

Implementasi Algoritma YOLO11 untuk Deteksi Logo Situs Judi Online pada Konten Video *Reel* Instagram

1stAhmad Mu'min Faisal
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
ahmadfaisal.tech@gmail.com

2ndAhmad Wali Satria Bahari Johan
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
ahmadsatria@telkomuniversity.ac.id


3rdTanzilal Mustaqim
Program Studi Informatika
Universitas Telkom
Surabaya, Indonesia
tanzilal@telkomuniversity.ac.id

Abstrak—Promosi judi online yang masif di platform media sosial Instagram, khususnya melalui konten video reel, telah menjadi tantangan sosial yang serius. Volume konten promosi yang tinggi dan sulit diidentifikasi secara manual karena logo yang disamarkan memerlukan solusi deteksi otomatis. Penelitian ini bertujuan mengembangkan sistem yang mampu mendeteksi logo situs judi online dari video reel sebagai input dan menghasilkan lokasi logo sebagai output. Pentingnya penelitian ini terletak pada penyediaan alat bantu bagi otoritas atau platform dalam mengurangi penyebaran konten ilegal tersebut, karena metode deteksi yang ada belum disesuaikan dengan lingkungan media sosial yang dinamis. Untuk mengatasi masalah ini, sistem deteksi objek diimplementasikan menggunakan algoritma YOLO11. Metodologi penelitian meliputi akuisisi data video dari Instagram, ekstraksi frame, anotasi manual untuk membuat dataset khusus, dan augmentasi data fotometrik untuk meningkatkan ketahanan model. Dua skenario pelatihan dilakukan untuk mengevaluasi dampak augmentasi. Hasil pengujian menunjukkan bahwa sistem yang dikembangkan cukup efektif, mencapai performa terbaik dengan mean Average Precision (mAP50) sebesar 72,9%. Secara khusus, model yang dilatih dengan data augmentasi menunjukkan Precision yang lebih baik yaitu 90,4% untuk kelas logo judi. Precision yang tinggi ini penting untuk menghasilkan sistem deteksi yang dapat diandalkan dan praktis, karena dapat meminimalkan kesalahan identifikasi, sehingga pendekatan ini cocok untuk moderasi konten di dunia nyata.

Kata Kunci—deteksi objek, YOLO11, logo judi online, instagram reels, computer vision, deep learning

I. PENDAHULUAN

Judi online telah menjadi permasalahan yang berkembang di Indonesia, dengan laporan yang menunjukkan peningkatan keterlibatan pengguna dan transaksi keuangan yang signifikan, yang menimbulkan berbagai masalah sosial dan personal [1], [2]. Fenomena ini diperkuat oleh kampanye promosi yang agresif, dengan Instagram menjadi platform utama untuk aktivitas tersebut [3]. Taktik promosi yang umum melibatkan reposting video reel yang sudah ada dan menyisipkan logo situs judi online, yang sering disamarkan sebagai konten berita atau hiburan [4], seperti yang ditunjukkan pada Gambar 1. Volume dan kehalusan promosi ini membuat deteksi manual tidak praktis, sehingga diperlukan sistem otomatis.



GAMBAR 1
(CONTOH VIDEO INSTAGRAM REEL YANG SERING DIGU- NAKAN UNTUK PROMOSI)

Meskipun berbagai pendekatan deteksi logo telah dikembangkan dalam literatur, sebagian besar fokus pada logo komersial umum dan belum secara khusus menangani tantangan deteksi logo yang disamarkan atau dimodifikasi dalam konteks media sosial. Penelitian-penelitian sebelumnya menunjukkan performa yang bervariasi, dengan mAP berkisar antara 51%-70% pada dataset standar, namun masih memiliki keterbatasan dalam adaptasi terhadap variasi visual yang ekstrem.

Penelitian ini bertujuan mengatasi gap tersebut dengan mengembangkan sistem deteksi khusus untuk logo situs judi online menggunakan algoritma YOLO11 terkini. Kontribusi utama meliputi: (1) pembuatan dataset khusus untuk logo judi online pada Instagram Reels, (2) evaluasi efektivitas augmentasi data fotometrik, dan (3) analisis trade-off precision-recall untuk aplikasi moderasi konten praktis.

II. KAJIAN TEORI

A. Deteksi Logo dalam Computer Vision

Deteksi logo merupakan tugas computer vision yang menantang karena karakteristik logo yang beragam dalam hal ukuran, orientasi, dan kondisi visual. Pendekatan modern umumnya menggunakan deep learning dengan arsitektur CNN untuk ekstraksi fitur otomatis. Tantangan utama meliputi deteksi objek kecil, variasi skala yang ekstrem, dan adaptasi terhadap modifikasi visual.

Penelitian terdahulu menunjukkan bahwa pendekatan berbasis YOLO dan R-CNN dapat mencapai performa yang kompetitif pada dataset standar seperti QMUL-OpenLogo dan Open Brands Dataset, dengan mAP berkisar 50%-70% [5]– [9]. Namun, performa tersebut umumnya menurun signifikan ketika dihadapkan pada logo yang dimodifikasi atau dalam konteks media sosial yang dinamis.

B. Algoritma YOLO11


YOLO (You Only Look Once) merupakan keluarga algoritma deteksi objek yang menggunakan pendekatan one-

stage detection, memungkinkan prediksi bounding box dan klasifikasi objek secara simultan dalam satu forward pass [10].

Keunggulan utama YOLO terletak pada kecepatan inferensi yang tinggi dibandingkan metode two-stage seperti R-CNN.

YOLO11 adalah iterasi terbaru yang dikembangkan Ultralytics dengan inovasi arsitektur Cross-Stage Partial with Self-Attention (C2PSA). Modul C2PSA menggabungkan efisiensi cross-stage partial networks dengan kemampuan contextual

modeling dari self-attention mechanism, menghasilkan peningkatan signifikan dalam deteksi objek kecil dan berdekatan [11].



GAMBAR 2

(ARSITEKTUR YOLO11 DENGAN MODUL C2PSA [11])

89,8%, Recall 82,6%, mAP50 89,3%, dan mAP50-95 79,5% [11]. Karakteristik dataset yang mencakup objek dengan variasi ukuran ekstrem menjadi justifikasi pemilihan YOLO11m untuk deteksi logo pada Instagram Reels.

C. Metrik Evaluasi

1) *Intersection over Union (IoU)*: IoU adalah metrik yang mengukur kesamaan antara kotak prediksi dan kotak kebenaran [12]:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

di mana A dan B masing-masing merepresentasikan area kotak prediksi dan kotak kebenaran. Nilai IoU berkisar antara 0 hingga 1, dengan 1 menunjukkan tumpang tindih sempurna.

2) *Precision dan Recall*: Precision mengukur kemampuan model mendeteksi hanya objek yang relevan, sedangkan Recall mengukur kemampuan model mendeteksi seluruh objek yang relevan [13]:

$$P = \frac{TP}{TP + FP}, \quad R = \frac{TP}{TP + FN} \quad (2)$$

di mana TP adalah True Positive, FP adalah False Positive, dan FN adalah False Negative.

3) *Mean Average Precision (mAP)*: mAP menghitung rata-rata nilai Average Precision (AP) untuk semua kelas dalam dataset [13]:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

jukkan superioritas YOLO11m dengan metrik: Precision

di mana N adalah jumlah total kelas dan AP_i adalah Average Precision untuk kelas ke- i . Evaluasi menggunakan mAP50 (IoU threshold 0,50) dan mAP50-95 (rata-rata IoU threshold 0,50-0,95).


III. METODE

Penelitian dilakukan melalui proses sistematis yang melibatkan akuisisi data, pra-pemrosesan, pelatihan model, dan evaluasi, seperti yang diilustrasikan pada Gambar 3.

A. Akuisisi Data dan Pra-pemrosesan

Dataset khusus dikurasi dengan mengumpulkan 300 Instagram Reels: 150 berisi logo situs judi online dan 150 dengan logo non-judi. Video diunduh menggunakan library **instaloader**. Untuk memastikan keragaman, 30 logo berbeda dari setiap kategori dikumpulkan, dengan lima contoh video berbeda untuk setiap logo.

Dataset dibagi menjadi set pelatihan (60%), validasi (20%), dan pengujian (20%). Dari setiap video, 10 frame representatif diekstrak pada interval seragam, menghasilkan total 3.000 frame. Frame-frame ini dianotasi secara manual menggunakan Label Studio dengan dua kelas: **gamblingsite** dan **nongam-blingsite**.



GAMBAR 3
(DIAGRAM BLOK METODOLOGI PENELITIAN SECARA KESELURUHAN)

B. Augmentasi Data

Untuk meningkatkan ketahanan model dan mencegah overfitting, set pelatihan menjalani augmentasi fotometrik. Untuk setiap gambar pelatihan asli, lima versi augmentasi dibuat:

- Penyesuaian kecerahan ($\pm 20\%$)
- Penyesuaian saturasi ($\pm 20\%$)
- Pepper noise (mempengaruhi 1% piksel)

Proses ini memperluas set pelatihan beranotasi dari 1.654 gambar menjadi 9.924 gambar, sementara set validasi dan

pengujian tetap tidak berubah.

C. Pelatihan Model

Dua skenario pelatihan berbeda dilakukan untuk mengevaluasi efektivitas augmentasi data:

- 1) **Model Dasar:** Dilatih pada set pelatihan asli tanpa augmentasi.
- 2) **Model Augmentasi:** Dilatih pada set pelatihan yang diperluas dengan augmentasi.

Kedua model menggunakan arsitektur YOLO11m, memanfaatkan transfer learning dengan bobot yang telah dilatih

sebelumnya pada dataset COCO. Parameter pelatihan utama dirinci dalam Tabel 1. Semua augmentasi bawaan dinonaktifkan untuk mengisolasi efek dari dataset augmentasi yang disiapkan secara manual.

TABEL 1
(PARAMETER PELATIHAN UTAMA)

Parameter	Nilai
Epochs	50
Patience	10
Batch Size	1
Image Size	1280
Rectangular Training	True
Built-in Augmentation	Disabled

IV. HASIL DAN PEMBAHASAN

Kedua model dievaluasi pada set pengujian yang sama untuk memastikan perbandingan yang adil. Metrik utama adalah Precision, Recall, dan mean Average Precision pada threshold IoU 0,50 (mAP50) dan 0,50-0,95 (mAP50-95).


A. Analisis Kuantitatif

Hasil pengujian akhir dirangkum dalam Tabel II. Model Dasar mencapai mAP50 keseluruhan yang sedikit lebih tinggi (72,9%). Namun, Model Augmentasi menunjukkan Precision yang jauh lebih tinggi yaitu **90,4%** untuk kelas target **gamblingsite**. Ini merupakan peningkatan penting, karena precision yang tinggi meminimalkan false positive—salah menandai konten yang tidak berbahaya—yang sangat penting untuk sistem moderasi konten praktis.


TABEL 2
(PERFORMA MODEL PADA SET PENGUJIAN)

Metrik	Kelas	Model Dasar	Model Augmentasi
Precision	all	0,874	0,895
	gamblingsite	0,852	0,904
	nongamblingsite	0,895	0,885
Recall	all	0,571	0,552
	gamblingsite	0,719	0,673
	nongamblingsite	0,422	0,432
mAP50	all	0,729	0,707
	gamblingsite	0,802	0,771
	nongamblingsite	0,657	0,643
mAP50-95	all	0,457	0,445
	gamblingsite	0,542	0,524
	nongamblingsite	0,371	0,365

Peningkatan precision ini diperoleh dengan mengorbankan Recall yang sedikit lebih rendah (67,3% vs. 71,9%), menunjukkan bahwa Model Augmentasi lebih konservatif dan mungkin melewatkan beberapa logo judi (*false negatives*). Trade-off ini diperjelas lebih lanjut oleh confusion matrices pada Gambar 4. Model Augmentasi hanya membuat 3 prediksi false positive untuk kelas **gamblingsite**, dibandingkan dengan 17 oleh Model Dasar.



(a) Model Dasar



(b) Model Augmentasi

GAMBAR 4

(Confusion matrix pada set pengujian untuk (a) Model Dasar dan (b) Model Augmentasi. Model Augmentasi secara signifikan mengurangi false positive untuk kelas 'gam-blingsite')

B. Analisis Kualitatif

Inspeksi visual hasil mengkonfirmasi temuan kuantitatif. Gambar 5 menunjukkan contoh prediksi model. Model Augmentasi berhasil menghindari false positive yang dibuat oleh Model Dasar (Gambar 5a). Kedua model dapat gagal mendeteksi logo kecil atau terintegrasi (*false negatives*), seperti yang terlihat pada Gambar 5b. Gambar 5c menunjukkan deteksi true positive yang berhasil oleh Model Augmentasi dengan skor confidence yang tinggi.


Performa mAP50 sebesar 72,9% yang dicapai menunjukkan efektivitas YOLO11 pada dataset media sosial yang menantang, melampaui beberapa baseline pada domain serupa. Untuk aplikasi moderasi konten praktis, Model Augmentasi dengan precision 90,4% untuk kelas gambingsite menjadi pilihan optimal karena meminimalkan risiko false positive yang dapat merugikan konten legitimate.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi logo situs judi online pada Instagram Reels menggunakan algoritma YOLO11. Kontribusi utama meliputi pembuatan dataset



(a) Kasus False Positive oleh Model Dasar.



(b) Kasus False Negative oleh kedua model.



(c) Kasus True Positive oleh Model Augmentasi.

GAMBAR 5
(PERBANDINGAN KUALITATIF HASIL DETEKSI)

khusus dengan 3.000 frame terannotasi dan evaluasi komprehensif terhadap dampak augmentasi data fotometrik.

Hasil eksperimen menunjukkan bahwa YOLO11m mencapai mAP50 sebesar 72,9% pada dataset yang dikurasi. Temuan penting adalah bahwa augmentasi data secara signifikan meningkatkan precision untuk kelas gambingsite menjadi 90,4%, meskipun dengan trade-off penurunan recall. Untuk aplikasi moderasi konten praktis, model dengan precision tinggi lebih diutamakan karena meminimalkan risiko false positive.

Penelitian selanjutnya dapat diarahkan pada: (1) ekspansi dataset dengan variasi logo yang lebih luas, (2) integrasi algoritma object tracking untuk efisiensi komputasi, dan (3) evaluasi pada platform media sosial lainnya untuk generalisasi yang lebih baik.

REFERENSI

- [1] Pusat Pelaporan dan Analisis Transaksi Keuangan (PPATK), "Mendunia, 2 dekade menjaga Indonesia: Laporan tahunan ppak tahun 2023," Pusat Pelaporan dan Analisis Transaksi Keuangan (PPATK), Jakarta, Indonesia, Tech. Rep., 2023, sK Nomor 0005.26232766/JI.3.1/SK.ISSN/2018.09. [Online]. Available: <https://www.ppatk.go.id>
- [2] N. M. Santosa, A. S. Putri, D. A. Kinanti, Jovanka, and T. Supriyadi, "Dampak sosial dan psikologis dari perjudian online," *WELL_BEING Psychological Journal*, vol. 1, no. 1, pp. 64–73, June 2024.
- [3] Populix, "Understanding the impact of online gambling ads exposure," Populix, Jakarta, Indonesia, Tech. Rep., February 2024, accessed: October 28, 2024. [Online]. Available: <https://info.populix.co/reports/online-gambling-in-indonesia>
- [4] —, "Indonesia darurat judi online: Ironi peristiwa, modus bandar & sikap pemerintah," Populix, Tech. Rep., 2024, accessed: October 28, 2024. [Online]. Available: <https://info.populix.co/id/reports/whitpaper-indonesia-darurat-judi-online>
- [5] J. Wang, W. Min, S. Hou, S. Ma, Y. Zheng, and S. Jiang, "Logodet-3k: A large-scale image dataset for logo detection," *ACM Trans. Multimedia Comput. Commun. Appl.*, vol. 18, no. 1, Jan. 2022. [Online]. Available: <https://doi.org/10.1145/3466780>
- [6] Q. Hou, W. Min, J. Wang, S. Hou, Y. Zheng, and S. Jiang, "Foodlogodet-1500: A dataset for large-scale food logo detection via multi-scale feature decoupling network," in *Proceedings of the 29th ACM International Conference on Multimedia*, ser. MM '21. ACM, Oct. 2021, pp. 4670–4679. [Online]. Available: <http://dx.doi.org/10.1145/3474085.3475289>

- [7] X. Li, S. Hou, B. Zhang, J. Wang, W. Jia, and Y. Zheng, "Long-range dependence involucional network for logo detection," *Entropy*, vol. 25, no. 1, 2023. [Online]. Available: <https://www.mdpi.com/1099-4300/25/1/174>
- [8] X. Jiang, K. Sun, L. Ma, Z. Qu, and C. Ren, "Vehicle logo detection method based on improved yolov4," *Electronics*, vol. 11, no. 20, p. 3400, 2022. [Online]. Available: <https://doi.org/10.3390/electronics11203400>
- [9] F. Leng, "A gradient balancing approach for robust logo detection," in *Proceedings of the 29th ACM International Conference on Multimedia (MM '21)*. Virtual Event, China: ACM, 2021, pp. 4765–4769. [Online]. Available: <https://doi.org/10.1145/3474085.3479201>
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," 2016, arXiv:1506.02640 [cs.CV]. [Online]. Available: <https://arxiv.org/abs/1506.02640>
- [11] N. Jegham, C. Y. Koh, M. Abdelatti, and A. Hendawi, "Evaluating the evolution of yolo (you only look once) models: A comprehensive benchmark study of yolo11 and its predecessors," 2024, arXiv:2411.00201 [cs.CV]. [Online]. Available: <https://arxiv.org/abs/2411.00201>
- [12] H. Rezatofighi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, "Generalized intersection over union: A metric and a loss for bounding box regression," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2019.
- [13] R. Padilla, S. L. Netto, and E. A. B. da Silva, "A survey on performance metrics for object-detection algorithms," in *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 2020, pp. 237–242.