

Pengembangan Model *Computer Vision* dengan Arsitektur YOLOv12 untuk Deteksi Utilitas Bawah Tanah pada Data *Ground Penetrating Radar*

Putu Pradnya Andika^{1*}, Andri Yadi Paembonan²

^{1,2} Program Studi Teknik Geofisika, Fakultas Teknologi Industri, Institut Teknologi Sumatera, Lampung Selatan, Indonesia.

DOI: <https://doi.org/10.29303/Goescienceed.v6i4.1380>

Article Info

Received: 29 Agustus 2025

Revised: 06 Oktober 2025

Accepted: 22 November 2025

Correspondence:

Phone:

Abstract: Pesatnya pembangunan infrastruktur perkotaan menuntut metode pemetaan utilitas bawah tanah yang presisi guna memitigasi risiko konstruksi. Namun, interpretasi manual data *Ground Penetrating Radar* (GPR) yang menjadi standar saat ini menghadapi kendala signifikan berupa subjektivitas operator, inefisiensi waktu, dan kerentanan terhadap inkonsistensi interpretasi. Penelitian ini bertujuan untuk mengembangkan kerangka kerja deteksi otomatis utilitas bawah tanah yang robust dan efisien dengan mengimplementasikan arsitektur *deep learning* mutakhir, YOLOv12, pada citra radargram. Metodologi penelitian melibatkan akuisisi dan kurasi dataset kustom terbatas sebanyak 174 radargram yang telah melalui tahapan pra-pemrosesan komprehensif—meliputi *time-zero correction*, *dewow*, *filtering*, dan *background removal*—untuk meningkatkan rasio sinyal terhadap derau (SNR). Dataset tersebut dibagi dengan proporsi 71% pelatihan (124 citra), 20% validasi (35 citra), dan 9% pengujian (15 citra) untuk melatih model YOLOv12 yang mengadopsi desain NMS-free end-to-end. Evaluasi kinerja model menunjukkan hasil yang menjanjikan dalam mengidentifikasi anomali hiperbolik, dengan capaian Mean Average Precision (mAP@0.5) sebesar 67.1%, Presisi 66.6%, dan Recall 68.3%. Temuan ini mengindikasikan bahwa integrasi arsitektur YOLOv12 mampu menawarkan solusi yang akurat dan efisien untuk mengatasi hambatan interpretasi data GPR, serta berpotensi meningkatkan standar praktik survei geofisika dalam manajemen infrastruktur sipil.

Keywords: GPR, Utilitas, *Deep Learning*, YOLOv12

Citation: Andika, P. P., & Paembonan, A. Y. (2025). Pengembangan model computer vision dengan arsitektur YOLOv12 untuk deteksi utilitas bawah tanah pada data ground penetrating radar. *Journal Pendidikan, Sains, Geologi dan Geofisika (GeoScienceEd Journal)*, 6(4), 2030-2034. doi: <https://doi.org/10.29303/Goescienceed.v6i4.1380>

Pendahuluan

Pembangunan infrastruktur yang pesat di kawasan perkotaan telah menciptakan lingkungan bawah permukaan yang sangat padat dan kompleks, seringkali dengan arsiparis yang tidak memadai (Hou dkk., 2022; Amaral dkk., 2023). Ketergantungan pada peta utilitas yang usang atau tidak akurat menimbulkan risiko serius selama kegiatan konstruksi berlangsung seperti kerusakan properti, penundaan proyek, dan

bahaya keselamatan kerja (Liu dkk., 2021). Untuk mengatasi tantangan ini, salah metode geofisika yaitu *ground penetrating radar* (GPR) menjadi teknik non-destruktif yang sangat efektif untuk memetakan utilitas bawah tanah (Hou dkk., 2022). GPR bekerja dengan mendeteksi anomali berbentuk hiperbola yang khas pada citra radargram, yang menandakan keberadaan objek seperti pipa atau kabel (Amaral dkk., 2023).

Meskipun GPR adalah alat akuisisi data yang kuat, proses interpretasi manual menjadi penghambat

utama dalam alur kerja modern. Analisis manual data GPR dalam volume besar bersifat sangat subjektif, sangat bergantung pada keahlian operator, dan rentan terhadap inkonsistensi (Yan dkk., 2025). Selain itu, proses ini sangat lambat dan padat karya, yang secara langsung berdampak pada efisiensi dan biaya proyek. Kualitas data GPR juga seringkali terdegradasi oleh derau (noise) dan sinyal acak (clutter) dari lingkungan bawah permukaan yang heterogen, yang semakin mempersulit identifikasi target secara akurat (Hou dkk., 2022).

Perkembangan teknologi dalam bidang *computer vision* dalam *deep learning* menawarkan solusi transformatif untuk mengatasi tantangan ini (Hou dkk., 2021). Dengan memperlakukan radargram sebagai citra, model *deep learning* seperti *Convolutional Neural Networks* (CNN) dapat dilatih untuk secara otomatis mengenali pola hiperbolik (Amaral dkk., 2023; Pashoutani dkk., 2025). Arsitektur deteksi objek satu-tahap, khususnya keluarga model *You Only Look Once* (YOLO), telah menunjukkan keseimbangan yang superior antara kecepatan dan akurasi dibandingkan dengan metode dua-tahap yang lebih lambat seperti *Faster R-CNN*, menjadikannya kandidat ideal untuk aplikasi lapangan secara *real-time* (Yan dkk., 2025; Zhu dkk., 2020). Penelitian ini berkontribusi pada kemajuan otomatisasi interpretasi data GPR dengan mengusulkan kerangka kerja deteksi utilitas bawah tanah berbasis arsitektur *state-of-the-art* "YOLOv12". Kebaruan pada pendekatan ini terletak pada pemanfaatan arsitektur yang lebih baik seperti desain *end-to-end* yang bebas dari *Non-Maximum Suppression* (NMS) untuk latensi ultra-rendah dan mekanisme pelestarian informasi untuk menangani sinyal yang lemah. Dengan menerapkan arsitektur ini, penelitian ini bertujuan untuk menunjukkan peningkatan kinerja yang signifikan dalam hal akurasi, kecepatan, dan keandalan, serta membuka jalan bagi interpretasi GPR di lapangan yang sepenuhnya otomatis dan *real-time* (Amaral dkk., 2023; Zhong dkk., 2023).

Metode

Akuisisi dan Pra-pemrosesan Data GPR

Prinsip dasar GPR melibatkan antena *transmitter* yang mengirimkan gelombang elektromagnetik ke bawah permukaan dan antena *receiver* yang merekam amplitudo dan waktu tempuh sinyal yang dipantulkan. Saat sistem GPR bergerak di sepanjang lintasan, serangkaian sinyal dikumpulkan dan disusun secara berurutan dalam bentuk *trace* untuk membentuk citra 2D penampang lintang bawah permukaan, yang dikenal sebagai radargram (Hou dkk., 2022).

Dataset yang digunakan dalam penelitian ini berjumlah 174 data radargram dengan kondisi yang

bervariasi. Sebelum data ini dapat digunakan untuk melatih model *deep learning*, serangkaian langkah pra-pemrosesan standar diterapkan untuk meningkatkan rasio sinyal-terhadap-noise (SNR) dan menonjolkan fitur hiperbola target. Alur kerja pra-pemrosesan ini meliputi *Time-Zero Correction*, *Dewow*, *Amplitude Gain*, *Filtering*, *Background Removal* serta *Running Average* memperjelas sinyal target (Hou dkk., 2022).

Data Labeling

Setelah melalui pra-pemrosesan, dataset akhir dikurasi untuk pelatihan model. Dataset ini menampilkan berbagai skenario, termasuk utilitas pada kedalaman yang berbeda, kondisi tanah yang bervariasi, dan tingkat *clutter* yang beragam. Setiap anomali hiperbolik yang merepresentasikan utilitas kemudian dianotasi secara manual menggunakan *bounding box*.

Proses anotasi mengikuti protokol yang ketat untuk memastikan kualitas dan konsistensi data latih, yang merupakan faktor krusial bagi kinerja model *deep learning*. Anotasi label yang diterapkan adalah memastikan *bounding box* melingkupi seluruh fitur hiperbola yang terlihat, termasuk bagian puncak dan kedua "kaki" hiperbola, ini bertujuan untuk meminimalkan piksel latar belakang di dalam kotak (Liu dkk., 2021). Semua utilitas yang dapat diidentifikasi secara visual di setiap radargram dilabeli, bahkan jika sinyalnya lemah atau terdistorsi, untuk melatih model agar robust dan mengurangi *false negatives*. Dataset yang telah dianotasi kemudian dibagi (*splitting*) secara acak menjadi tiga set: 71% untuk *training*, 20% untuk *validation*, dan 9% untuk *testing* model.

Arsitektur Deteksi YOLOv12

Penelitian ini menggunakan arsitektur YOLOv12, sebuah model konseptual yang menggabungkan inovasi-inovasi paling mutakhir dari YOLOv9 dan YOLOv10 untuk menciptakan detektor objek yang dioptimalkan untuk kecepatan, akurasi, dan efisiensi. Filosofi dasar YOLO sebagai detektor satu-tahap yang cepat tetap dipertahankan (Yan dkk., 2025), namun dengan beberapa peningkatan arsitektural kunci yang sangat relevan untuk tantangan data GPR.

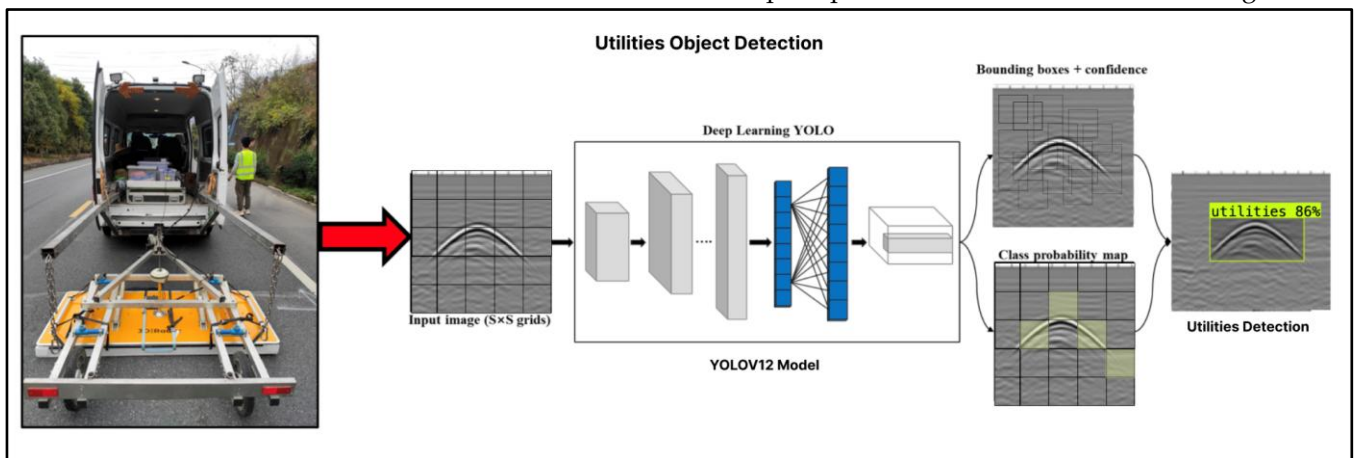
Kombinasi fitur-fitur canggih ini tidak hanya menjadikan model lebih baru, tetapi secara fundamental lebih cocok untuk mengatasi tantangan unik yang disajikan oleh data GPR. Kemampuan untuk mempertahankan informasi dari sinyal yang lemah dan memprosesnya dengan latensi sangat rendah secara langsung menjawab kebutuhan utama aplikasi GPR di lapangan. Gambar 1 memvisualisasikan alur kerja teknis sistem deteksi utilitas yang diusulkan, mulai dari akuisisi data fisik hingga prediksi output. Proses ini mengadaptasi mekanisme *one-stage detector* yang

dimodifikasi untuk karakteristik citra GPR. Alur pemrosesan data melalui arsitektur YOLOv12 dapat diuraikan sebagai berikut:

1. Pra-pemrosesan dan Grid Input: Data mentah yang diperoleh dari survei GPR yang dikonversi menjadi citra radargram 2D. Sebelum masuk ke jaringan saraf, citra dibagi ke dalam grid berukuran $(S \times S)$, setiap sel grid dalam citra bertanggung jawab untuk mendeteksi objek jika pusat geometri dari anomali hiperbola jatuh di dalam sel tersebut. Mekanisme ini memungkinkan model untuk melokalisasi target utilitas yang tersebar di sepanjang lintasan survei.

- o *Class Probability Map*: Secara simultan, model menghasilkan peta probabilitas untuk mengklasifikasikan area tersebut sebagai "utilities" atau latar belakang.

Berbeda dengan versi terdahulu yang sangat bergantung pada Non-Maximum Suppression (NMS) untuk menghapus kotak yang tumpang tindih, arsitektur YOLOv12 ini mengadopsi desain NMS-free end-to-end. Hal ini terlihat pada hasil akhir (Final Detection) di mana sistem langsung menghasilkan prediksi confidence sebesar 86% tanpa perlu komputasi pasca-pemrosesan yang berat, sehingga mempercepat waktu inferensi secara signifikan.



Gambar 1. Alur teknis implementasi deteksi utilitas dengan YOLOv12 (modifikasi dari Liu dkk., 2021)


2. Fitur (Backbone & Neck) merepresentasikan proses ekstraksi fitur yang melingkupi:

- o Backbone: Citra input diproses menggunakan Generalized Efficient Layer Aggregation Network (GELAN). Komponen ini berfungsi mengekstraksi fitur visual dasar seperti lengkungan hiperbola, kontras amplitudo, dan tekstur sinyal dari latar belakang tanah.
- o Neck: Fitur-fitur tersebut kemudian digabungkan melalui Path Aggregation Network (PANet). Lapisan ini mengagregasi informasi dari berbagai skala resolusi, memastikan bahwa utilitas yang berada di kedalaman dangkal (fitur besar) maupun dalam (fitur kecil) dapat terdeteksi dengan akurasi yang setara.

3. Prediksi (Head) Panel kanan Gambar 1 menunjukkan mekanisme output ganda dari model:

- o *Bounding Box*: Model memprediksi koordinat kotak pembatas (*bounding boxes*) yang melingkupi area hiperbola beserta skor confidence-nya.

(Wang dkk., 2024).



Gambar 2. Metrik evaluasi model YOLOv12

Pengaturan Eksperimen dan Metrik Evaluasi

Pelatihan model dan prediksi dilakukan dengan memanfaatkan platform terintegrasi untuk penyelesaian *deep learning* dengan Roboflow (<https://roboflow.com/>). Kinerja model dievaluasi secara kuantitatif menggunakan metrik standar dalam deteksi objek, termasuk Precision, Recall, dan *mean Average Precision* (mAP) (Yan dkk., 2024; Liu dkk., 2021). Precision (*P*) mengukur akurasi deteksi positif, sementara Recall (*R*) mengukur kelengkapan deteksi.

$$P = \frac{TP}{TP + FP}$$

$$R = \frac{TP}{TP + FN}$$

Hasil dan Pembahasan

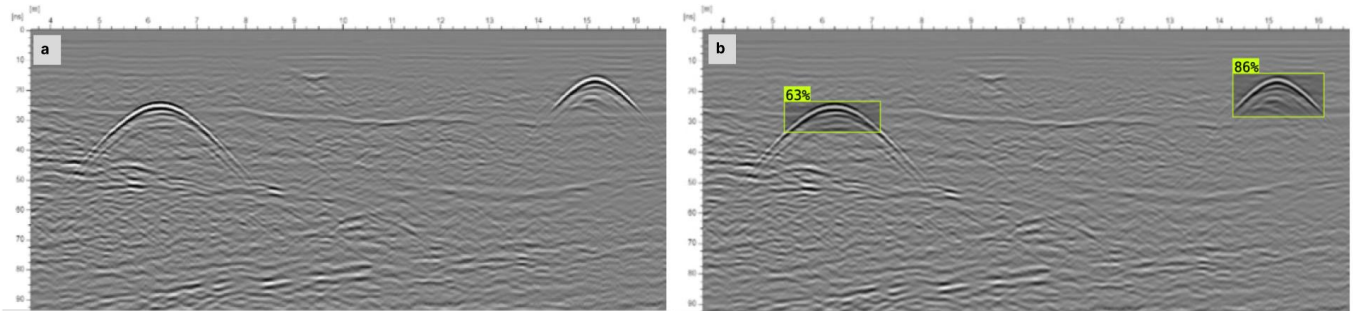
Proses pelatihan model YOLOv12 dilakukan dengan menggunakan 300 epoch dan menunjukkan konvergensi stabil tanpa indikasi *overfitting*, sebagaimana divisualisasikan oleh tren peningkatan metrik pada Gambar 2. Model mencapai kinerja optimal dengan presisi 80%, recall 70%, dan mAP50 sebesar 70%. Konsistensi tren positif ini memvalidasi kemampuan model dalam mempelajari fitur hiperbolik sekaligus melakukan generalisasi secara efektif.

Capaian kinerja ini sejalan dengan tren penelitian terkini dalam deteksi GPR, di mana pendekatan berbasis deep learning terbukti mampu mengatasi subjektivitas interpretasi manual. Jika


aplikasi real-time di lapangan dibandingkan arsitektur YOLO generasi sebelumnya yang masih bergantung pada *Non-Maximum Suppression* yang berat secara komputasi.

Gambar 3 menunjukkan hasil prediksi dari kemampuan deteksi model pada data GPR. Gambar 3(a) menampilkan radargram input yang berisi dua anomali hiperbolik yang jelas pada kedalaman yang berbeda. Pada Gambar 3(b), model YOLOv12 berhasil mendeteksi kedua target tersebut secara akurat, melingkupinya dengan *bounding box* berwarna hijau. Setiap deteksi disertai dengan *confidence score*, yaitu 63% untuk hiperbola yang lebih dangkal dan 86% untuk hiperbola yang lebih dalam.

Kemampuan model untuk mendeteksi utilitas pada kedalaman yang berbeda ini sangat krusial. Sebagaimana dicatat oleh Hou dkk. (2022), tantangan utama GPR adalah sinyal yang terkontaminasi oleh *noise* dan *clutter* pada kedalaman yang lebih besar. Hasil pada



Gambar 3. (a) Radargram sebelum prediksi, (b) Radargram hasil prediksi model YOLOv12



Gambar 4. (a) Radargram sebelum prediksi, (b) Radargram hasil prediksi model YOLOv12

dibandingkan dengan metode deteksi dua-tahap seperti Faster R-CNN yang disinggung oleh Zhu dkk. (2020), model YOLOv12 yang dikembangkan menawarkan keseimbangan yang lebih baik antara akurasi dan efisiensi komputasi. Meskipun Liu dkk. (2021) telah berhasil menerapkan model YOLO untuk deteksi jalan, penggunaan arsitektur YOLOv12 dalam penelitian ini memberikan keunggulan tambahan berupa desain NMS-free. Hal ini meminimalisir latensi pasca-pemrosesan, menjadikan model ini lebih siap untuk

Gambar 4, di mana terdeteksi utilitas dalam dengan confidence score 91% dan utilitas dangkal 61%, membuktikan bahwa arsitektur GELAN dan PANet pada YOLOv12 efektif dalam mengekstraksi fitur sinyal lemah yang seringkali terlewatkan oleh metode konvensional. Hasil visual ini secara efektif mendemonstrasikan kemampuan praktis model untuk mengidentifikasi utilitas dengan berbagai ukuran dan kekuatan sinyal, mengkonfirmasi kinerja kuantitatif yang solid dari metrik pelatihan.

Kesimpulan

Penelitian ini telah berhasil mengembangkan serta memvalidasi model *computer vision* berbasis arsitektur YOLOv12 untuk tugas deteksi utilitas bawah tanah secara otomatis dari data Ground Penetrating Radar. Keberhasilan model ini dibuktikan melalui evaluasi kuantitatif dan kualitatif. Metrik pelatihan menunjukkan konvergensi yang stabil dengan tren peningkatan yang jelas pada presisi, recall, dan mAP, memvalidasi proses pembelajaran yang efektif. Secara kualitatif, model menunjukkan kemampuannya untuk secara akurat mendeteksi beberapa anomali hiperbolik dengan berbagai ukuran dan kedalaman pada data uji, memberikan lokalisasi yang tepat dengan skor confidence yang cukup tinggi.

Model yang diusulkan menunjukkan kinerja *state-of-the-art*, mencapai akurasi deteksi yang sangat tinggi dan efisiensi inferensi yang memungkinkan aplikasi *real-time*. Keberhasilan ini didasarkan pada pemanfaatan arsitektur canggih yang menggabungkan ekstraksi fitur yang kuat, mekanisme pelestarian informasi untuk sinyal lemah, dan desain *end-to-end* yang bebas NMS. Studi ini menegaskan kembali kontribusinya dalam menyediakan solusi berbasis AI yang praktis dan efektif untuk mengatasi bottleneck interpretasi data GPR, yang berpotensi besar untuk meningkatkan efisiensi, keamanan, dan keandalan proyek-proyek rekayasa sipil, geoteknik, dan manajemen infrastruktur perkotaan.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada pihak-pihak yang telah membantu dalam pengembangan model YOLOv12, khususnya pada Program Studi Teknik Geofisika, Institut Teknologi Sumatera. Ucapan terima kasih juga tidak lupa disampaikan kepada developer yang telah mengembangkan Platform Roboflow yang terintegrasi dan dapat dimanfaatkan secara *open-source*.

Referensi

- Amaral, L. C. M., Roshan, A., & Bayat, A. (2023). Automatic detection and classification of underground objects in ground penetrating radar images using machine learning. *Journal of Pipeline Systems Engineering and Practice*, 14(4), 04023040. <https://doi.org/10.1061/JPSEA2.PSENG-1444>
- Hou, F., Lei, W., Li, S., & Xi, J. (2021). Deep learning-based subsurface target detection from GPR scans. *IEEE sensors journal*, 21(6), 8161-8171. <https://doi.org/10.1109/ISEN.2021.3050262>
- Hou, F., Rui, X., Fan, X., & Zhang, H. (2022). Review of GPR activities in civil infrastructures: Data analysis and applications. *Remote Sensing*, 14(23), 5972. <https://doi.org/10.3390/rs14235972>
- Liu, Z., Wu, W., Gu, X., Li, S., Wang, L., & Zhang, T. (2021). Application of Combining YOLO Models and 3D GPR Images in Road Detection and Maintenance. *Remote Sensing*, 13(6), 1081. <https://doi.org/10.3390/rs13061081>
- Pashoutani, S., Roudsari, M., & Zhu, J. (2025). Dual-Channel CNN-Based Framework for Automated Rebar Detection in GPR Data of Concrete Bridge Decks. *Construction Materials*, 5(2), 36. <https://doi.org/10.3390/constrmater5020036>
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., & Han, J. (2024). Yolov10: Real-time end-to-end object detection. *Advances in Neural Information Processing Systems*, 37, 107984-108011.
- Wang, C. Y., Yeh, I. H., & Mark Liao, H. Y. (2024, September). Yolov9: Learning what you want to learn using programmable gradient information. *In European conference on computer vision* (pp. 1-21). Cham: Springer Nature Switzerland.
- Wang, H., Luo, J., He, Y., Cao, M., Gao, D., & Li, J. (2024). Identification of common underground pipelines by ground penetrating radar based on improved YOLOv5. *Chinese Journal of Geophysics*, 67(9), 3588-3604. <https://doi.org/10.6038/cjg2023R0431>
- Yan, Y., Jiao, G., Cui, M., & Ni, L. (2025). The Lightweight Method of Ground Penetrating Radar (GPR) Hidden Defect Detection Based on SEM-YOLO. *Buildings*, 15(13), 2345. DOI: <https://doi.org/10.3390/buildings15132345>
- Zhong, Y., Li, K., Mo, S., & Li, B. (2023). Research on GPR Echo Image Recognition Based on GSR-YOLOv7. *Semiconductor Optoelectronics*, 44(5), 767-772. <https://doi.org/10.16818/j.issn1001-5868.2023061401>
- Zhu, X., Lyu, S., Wang, X., & Zhao, Q. (2020). Research on GPR image recognition based on deep learning. *MATEC Web of Conferences*, 309, 03027. <https://doi.org/10.1051/mateconf/202030903027>