

Deteksi Crack Dan Studi Perbandingan Berdasarkan Faster R-CNN Dan Mask R-CNN

Nailah Rahdatul'Aisy¹, Sella Amelia Putri¹, Ranita Claudia Br Purba¹, Muhammad Ikhwal¹,
Robbiul Jauza Erbila¹, Perani Rosyani¹

¹Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Pamulang , Kota Tangerang Selatan , Indonesia

(Email : ¹Aisynaila757@gmail.com, ²sellaaprilia254@gmail.com, ³claudiaranita260@gmail.com,
⁴Mikhwal50@gmail.com, ⁵robbijau@gmail.com, ⁶dosen00837@unpam.ac.id

Abstrak - Metode pendekripsiannya celah yang cerdas merupakan jaminan penting untuk realisasi operasi dan pemeliharaan yang cerdas, dan sangat penting untuk keselamatan lalu lintas. Dalam beberapa tahun terakhir, pengenalan retakan perkerasan jalan berdasarkan computer vision semakin menarik perhatian. Dengan terobosan teknologi algoritma pembelajaran mendalam umum dalam beberapa tahun terakhir, algoritma deteksi berdasarkan pembelajaran mendalam dan jaringan saraf convolutional telah mencapai hasil yang lebih baik di bidang pengenalan retak. Dalam makalah ini, pembelajaran mendalam diselidiki untuk secara cerdas mendekripsi retakan jalan, dan *Faster R-CNN* dan *Mask R-CNN* dibandingkan dan dianalisis. Hasil menunjukkan bahwa strategi pelatihan bersama sangat efektif, dan kami dapat memastikan bahwa *Faster R-CNN* dan *Mask R-CNN* menyelesaikan tugas deteksi celah saat dilatih dengan hanya 130+ gambar dan dapat mengungguli YOLOv3. Namun, strategi pelatihan bersama menyebabkan penurunan efektivitas kotak pembatas yang terdeteksi oleh *Mask R-CNN*.

Kata Kunci: Deep Learning, Mask R-CNN, Deteksi Retakan, Faster R-CNN, Pemantauan Cerdas

Abstract - The intelligent gap detection method is an important guarantee for the realization of intelligent operation and maintenance, and it is very important for traffic safety. In recent years, the introduction of pavement cracks based on computer vision has attracted more and more attention. With the breakthrough of general deep learning algorithm technology in recent years, detection algorithms based on deep learning and convolutional neural networks have achieved better results in the field of crack recognition. In this paper, deep learning was investigated to intelligently detect road cracks, and Faster R-CNN and Mask R-CNN were compared and analyzed. Results show that the joint training strategy is very effective, and we can confirm that Faster R-CNN and Mask R-CNN complete the gap detection task when trained with only 130+ images and can outperform YOLOv3. However, joint strategy training led to a decrease in the effectiveness of the bounding box which was detected by the Mask R-CNN.

Keywords: Deep Learning, Mask R-CNN, Crack Detection, Faster R-CNN, Intelligent Monitoring

1. PENDAHULUAN

Di bidang penelitian pengenalan retakan jalan yang terutama didasarkan pada visi komputer, metode penting terutama mencakup metode pemrosesan citra digital, yang terutama membedakan fitur secara manual dan menggunakan banyak aturan fitur untuk merancang beberapa kondisi pengenalan fitur, dan jaringan konvolusional berdasarkan pembelajaran mendalam. , yang mengadopsi jaringan untuk secara otomatis menyelidiki fitur informasi sehingga jaringan dapat terus menyesuaikan diri sesuai dengan aturan tertentu untuk mencapai keluaran data input sama atau mendekati label. Dalam sepuluh tahun terakhir, banyak sarjana telah melakukan pemeriksaan mendalam tentang pengenalan retakan jalan terutama berdasarkan pengolahan citra digital. Hoang [1] mengusulkan metode cerdas untuk mengklasifikasikan retakan jalan secara otomatis untuk meningkatkan efektivitas survei berkala kondisi perkerasan aspal. Metode baru tergantung pada algoritma kecerdasan komputasi dan metode pemrosesan gambar. Lei et al. [2] mengusulkan pendekatan pendekripsiannya retak baru yang didasarkan sepenuhnya pada titik pusat retak khususnya, pendekatan titik pusat retak untuk mengatasi masalah kritis ini. Dengan jumlah gambar yang sedikit, pendekatan baru ini dapat dengan cepat dan tepat menemukan retakan pada gambar yang terkumpul. Selanjutnya, Ying et al. [3] memperkenalkan cara baru untuk mendekripsi dan mengklasifikasikan retakan dengan citra digital, yang memanfaatkan algoritme pembesaran citra. Namun, dengan pesatnya pertumbuhan jarak tempuh jalan, informasi tentang retakan perkerasan jalan sudah masif, sehingga ide pengkodean tradisional berdasarkan pengalaman untuk

mengatur logika mengalami kesulitan untuk memenuhi kebutuhan yang sebenarnya. Pada saat yang sama, perangkat keras komputer juga berkembang pesat, mengarah pada terobosan dalam algoritme terkait pembelajaran mendalam. Dalam beberapa tahun terakhir, algoritma deep learning yang dapat diterapkan secara luas menjadi semakin populer, dan perangkat keras komputer serta jaringan saraf convolutional telah menjadi inti dari deep learning [4]. Oleh karena itu, algoritma pendekripsi berdasarkan deep learning dan convolutional neural network telah mencapai hasil yang lebih baik di bidang pengenalan crack.

Untuk mengukur lebar atau panjang cacat, banyak peneliti telah mengusulkan metode kuantifikasi berbasis pembelajaran mendalam. Kim dkk. [5] memperkenalkan kerangka kerja evaluasi retak baru untuk konstruksi beton yang mendekripsi retak menggunakan masker dan komunitas saraf konvolusional total berbasis lokasi (*Mask R-CNN*) dan menghitung retak menggunakan beberapa operasi morfologis pada masker retak yang terdeteksi. Kalfarisi et al. [6] mengusulkan kerangka kerja terpadu untuk penggunaan teknologi pemodelan jaring realitas yang memungkinkan evaluasi kuantitatif dengan visualisasi terintegrasi dari struktur yang diperiksa. Keefektifan dan kekokohan metode yang dikembangkan dievaluasi, dan penggunaan berbagai contoh aktual, termasuk perkerasan jalan, jembatan, terowongan bawah tanah, bangunan, dan menara air, ditetapkan. Wu dkk. [7] mengadopsi gambar untuk merakit model mesh melalui pendekatan fotogrametri. Model dengan retakan beranotasi memungkinkan visualisasi intuitif dan evaluasi kuantitatif dari ribuan retakan yang terdeteksi. Selain itu, Peng et al. [8] mengusulkan pendekatan visi komputer untuk pengenalan retakan jembatan dan kuantifikasi lebar melalui pembelajaran karakteristik hibrid. Selanjutnya, Guo et al. [9] memperkenalkan pendekatan visi komputer untuk identifikasi, kuantifikasi, dan visualisasi microcracks, terutama berdasarkan pembelajaran mendalam. Baru-baru ini, Bang et al. [10] mengusulkan deteksi berbasis pembelajaran mendalam dan kuantifikasi kerusakan struktural dengan mengadopsi lampu terstruktur dan kamera kedalaman.

Banyak sarjana lain telah meningkatkan kinerja model dengan hasil deteksi yang lebih baik. Han dkk. [11] mengusulkan blok pengambilan sampel dengan penerapan jaringan saraf convolutional, sehingga mengembangkan jaringan segmentasi semantik tingkat piksel baru. Li dkk. [12] mengusulkan jaringan fusi karakteristik multilayer yang sepenuhnya didasarkan pada jaringan saraf konvolusional berbasis wilayah yang lebih cepat (*Faster R-CNN*) untuk mendapatkan deteksi cacat permukaan terowongan otomatis dengan presisi yang berlebihan. Ju Huyan dkk. [13] mengusulkan perpaduan jaringan deteksi sensitivitas, yang mampu memantau retakan yang tidak tertutup dan tertutup dengan latar belakang yang sangat rumit. Selain itu, Malini et al. [14] menggunakan pendekatan regularisasi untuk mendapatkan kinerja total yang lebih besar terutama berdasarkan model pemantauan jaringan saraf convolutional (CNN). Cha dkk. [15] mengusulkan pendekatan berbasis visi menggunakan arsitektur CNN yang mendalam untuk memantau retakan beton kecuali untuk menghitung fitur cacat. Mogalapalli et al. [16] mengusulkan metode berbasis pembelajaran transfer kuantum untuk berbagai tugas klasifikasi gambar. Pang dkk. [17] mengusulkan pendekatan segmentasi cacat retak dua tahap yang sepenuhnya didasarkan pada komunitas deteksi target untuk menyelesaikan masalah ketidakseimbangan kecerahan yang ekstrem dan kebingungan masif pada gambar permukaan bendungan. Sekar dkk. [18] memperkenalkan metode multitasking *Faster R-CNN* baru yang menggunakan metode penyelarasan region of interest dan global average pooling untuk memantau berbagai retakan jalan.

Banyak peneliti telah menambahkan fungsi klasifikasi untuk cacat luar biasa. Trana dkk. [19] mengusulkan metode komputerisasi berurutan dua langkah untuk mendekripsi retakan dan mengklasifikasikan tingkat keparahan perkerasan aspal. Liu dkk. [20] memperkenalkan model baru yang menggabungkan pembelajaran mendalam berbasis piksel dan wilayah untuk memasok pengetahuan teknologi inspeksi perkerasan untuk saling memperoleh kelas kesengsaraan, lokasi, dan informasi geometris. Selain itu, Mondal et al. [21] menganalisis data visual yang ditangkap melalui sensor yang dipasang pada robot, dan kerusakan dapat didekripsi dan dikategorikan secara mandiri. Studi saat ini mengusulkan penggunaan metode berbasis pembelajaran mendalam untuk tujuan ini. Hou dkk. [22] memperkenalkan pembelajaran transfer dengan model Cascade Mask RCNN untuk identifikasi dan lokasi cacat. Dhiman dkk. [23] mengusulkan dua metode terutama berdasarkan evaluasi stereo-visi lingkungan jalan sebelum kendaraan, dan mereka juga merancang

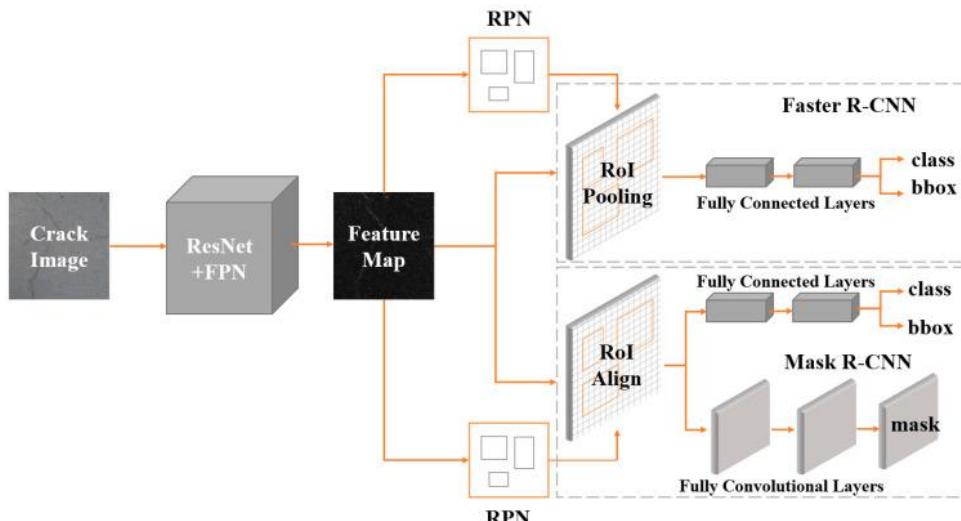
dua model untuk deteksi lubang berbasis pembelajaran mendalam. Metode pemantauan cerdas [24 , 25 , 26] akan menjadi jaminan penting untuk realisasi operasi dan pemeliharaan cerdas.

Faster R-CNN dan *Mask R-CNN* telah terbukti sukses di bidang penglihatan umum, seperti pada [27]. Namun, penelitian pendekripsi retakan mengingat karakteristik citra jalan masih belum memadai. Kami secara eksperimental memvalidasi model kami menggunakan dua metode ini untuk tugas spesifik deteksi retakan jalan. Untuk mempercepat pelatihan, kami melatih model kami dengan strategi pelatihan bersama menggunakan pembelajaran pra-pelatihan dan migrasi. Hasilnya menunjukkan bahwa kami dapat membuat *R-CNN* dan *Mask R-CNN* lebih cepat dengan hasil yang baik hanya dengan menggunakan 130+ gambar.

2. METODE DAN ANALISIS

2.1 Metode

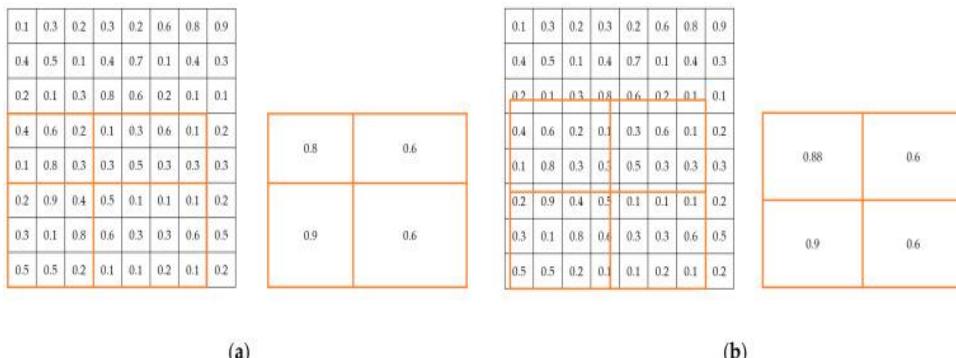
Pipa *Faster R-CNN* [28] dan *Mask R-CNN* [29] disajikan di Gambar 1, dimana dapat dibagi menjadi tiga komponen utama. (1) Ekstraksi fitur: kami menggunakan ResNet [30] dan FPN [31] sebagai ekstraktor fitur untuk *Faster R-CNN* dan *Mask R-CNN*. Ekstraktor fitur mengirimkan lima peta fitur dengan berbagai ukuran ke jaringan berikut setelah ekstraksi fitur. (2) Jaringan proposal wilayah (RPN): lima RPN identik memperoleh lima peta fitur, yang kemudian digunakan untuk menghasilkan proposal wilayah. Secara khusus, RPN menghasilkan jangkar dengan ukuran berbeda untuk mendapatkan sejumlah peta fitur proposal wilayah yang ditentukan. (3) CNN Wilayah (R-CNN): komponen R-CNN dari *Faster R-CNN* menyatuhan peta fitur proposal wilayah ke dalam ukuran yang sama dan kemudian memasukkan semuanya ke dalam lapisan yang terhubung sepenuhnya untuk klasifikasi dan regresi. Untuk *Mask R-CNN*, cabang konvolusi penuh ditambahkan untuk mengimplementasikan tugas segmentasi instance



Gambar 1. Pipa Faster R-CNN Dan Mask R-CNN

Pipeline of Faster R-CNN dan Mask R-CNN: RPN dilatih secara terpisah. Selain itu, cabang mask dan cabang bbox menggunakan ekstraktor fitur RoI yang berbeda, dan cabang mask memperoleh hasil yang lebih baik melalui peta fitur yang lebih besar.

Dua perbedaan utama antara *Mask R-CNN* dan *Faster R-CNN* adalah sebagai berikut. (1) Penambahan komponen mask (lapisan konvolusional penuh) ke R-CNN memungkinkan tugas segmentasi instance (Gambar 1). (2) Untuk masalah misalignment antara peta fitur dan RoI pada gambar asli, diusulkan RoIAlign, yang merupakan versi perbaikan dari RoIPooling (Gambar 2).

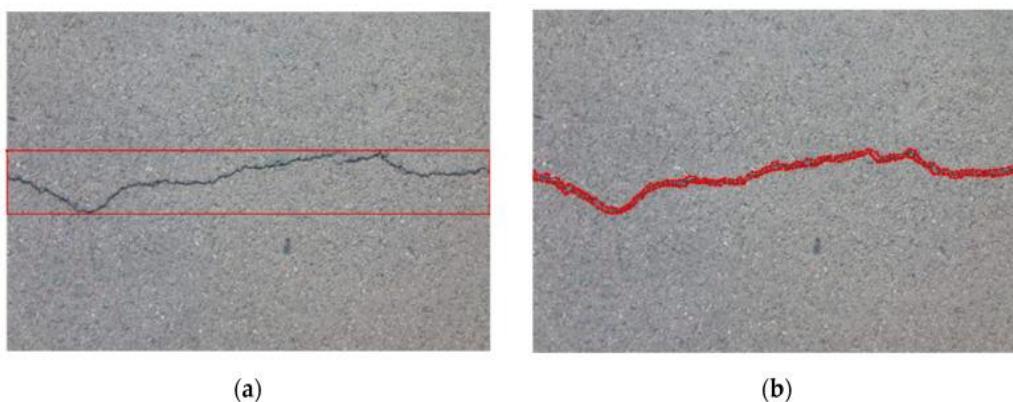


Gambar 2. Diagram visualisasi RoI Pooling dan RoI Align

Diagram visualisasi RoI Pooling dan RoI Align: Asumsikan bahwa ukuran output adalah (2, 2). RoIAlias menggunakan metode interpolasi bilinear untuk meningkatkan akurasi. (a) Pengumpulan ROI. (b) Penyelarasan ROI.

Diagram visualisasi RoI Pooling dan RoI Align: Asumsikan bahwa ukuran output adalah (2, 2). RoIAlias menggunakan metode interpolasi bilinear untuk meningkatkan akurasi. (a) Pengumpulan ROI. (b) Penyelarasan ROI.

Faster R-CNN memilih persegi panjang untuk memberi label retakan pada gambar, dan *Mask R-CNN* menggunakan poligon untuk menggambarkan retakan pada gambar 3.



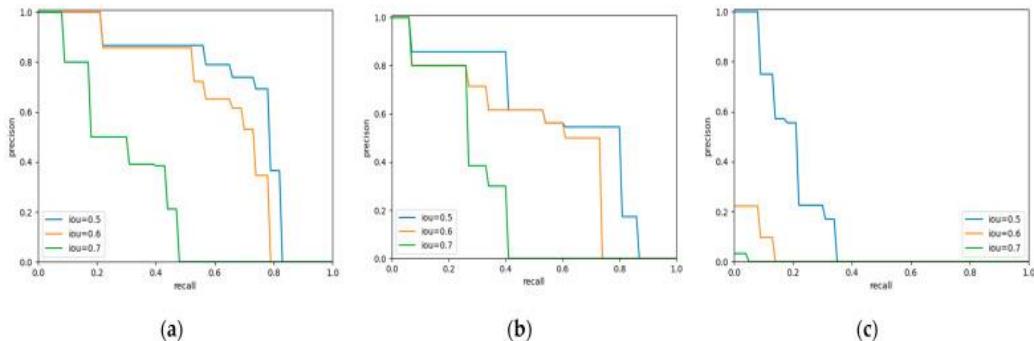
Gambar 3. Pelabelan retakan. (a) Pelabelan R-CNN Lebih Cepat; (b) Pelabelan Topeng R-CNN.

Kami menggunakan backbone berdasarkan pra-pelatihan ImageNet dan melakukan strategi finetuning untuk melatih jaringan kami. Ukuran gambar input diatur ke 800×500 untuk memastikan kecepatan pelatihan model (juga dibatasi oleh memori GPU), meskipun pendekatan kami tidak memerlukan spesifikasi ukuran gambar input. Kami menetapkan lima tingkat pembelajaran yang berbeda untuk melatih kedua jaringan: 0,02, 0,01, 0,005, 0,0025, dan 0,0002. Kami menggunakan pengoptimal SGD untuk pelatihan. Selain itu, metode seperti normalisasi batch dan pemanasan digunakan dalam proses pelatihan untuk meningkatkan efeknya. Kami menggunakan PyTorch 1.8 dan CUDA 11.1 untuk pelatihan. Tugas tersebut dilakukan pada platform kerja Ubuntu 20.04.3 dan dilatih pada satu GPU NVIDIA GTX 1080 Ti.

2.2. Analisis

Kami melakukan perbandingan menggunakan metode populer YOLO. Kurva PR dari kotak pembatas dari ketiga metode ditunjukkan pada Gambar 4, dan jelas bahwa *Faster R-CNN* memiliki keunggulan dalam deteksi, sedangkan YOLO v3 hampir tidak kompeten untuk tugas kita. Selain itu, YOLOv3 membutuhkan waktu pelatihan yang lebih lama. Tampaknya

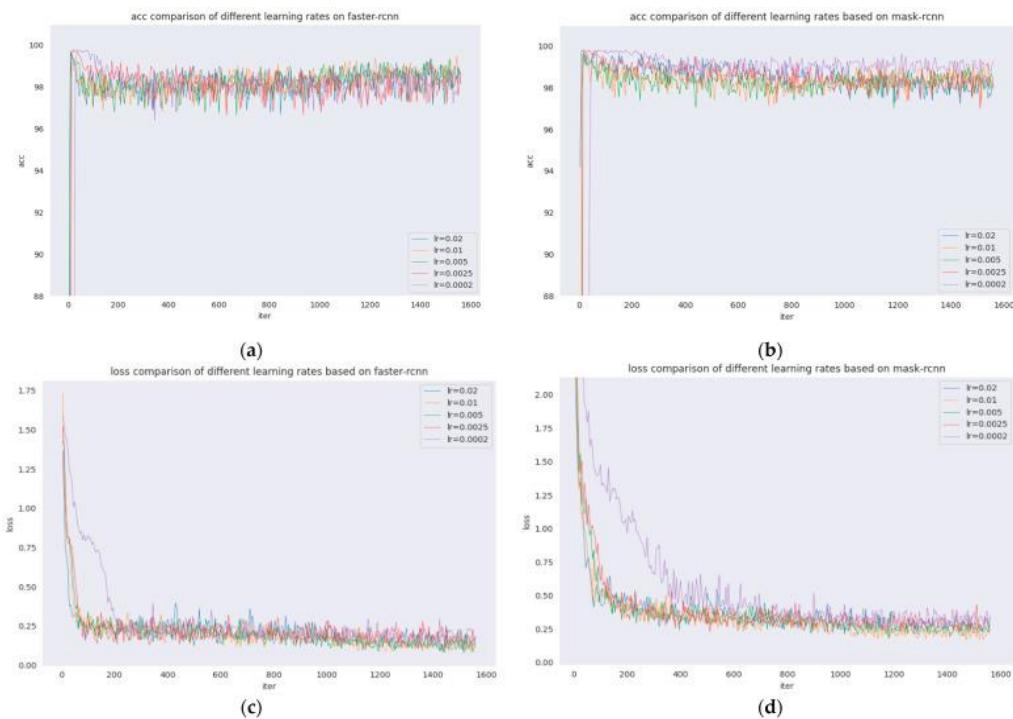
menggunakan YOLO v3 untuk tugas spesifik pendekripsi retakan trotoar dan hanya dengan sejumlah kecil data tidak memberikan hasil yang diinginkan.



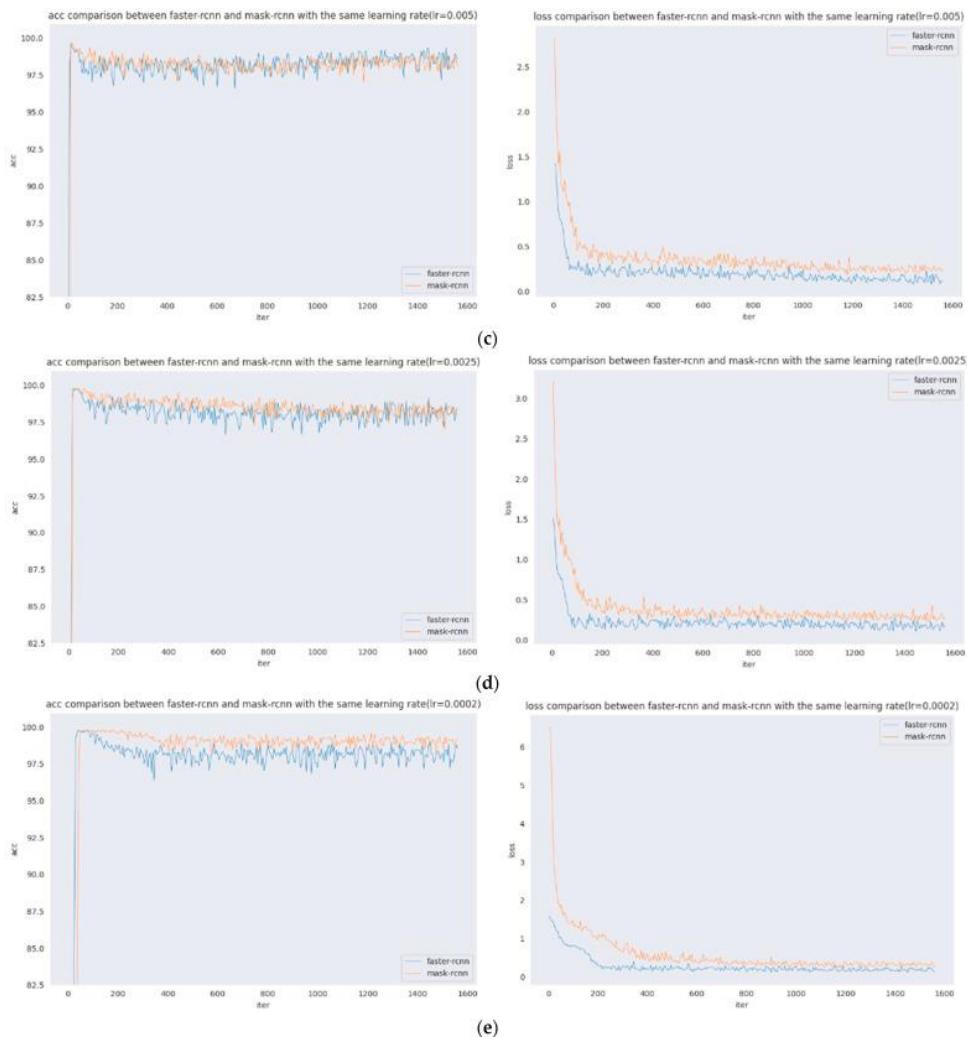
Gambar 4. Kurva presisi-recall dari kotak-kotak pembatas dalam model yang berbeda. (a) R-CNN yang lebih cepat. (b) Topeng R-CNN. (c) YOLO v3.

Pelatihan bersama adalah strategi umum dalam pembelajaran mendalam yang dapat mempercepat pelatihan dan seringkali memperoleh hasil yang baik. Namun, untuk model *Faster R-CNN* dan *Mask R-CNN* dengan hubungan upstream dan downstream, tidak diketahui berapa banyak hasil yang akan terpengaruh hanya dengan menjumlahkan kerugiannya dan menggunakan pelatihan bersama. Eksperimen berikut membandingkan pendekripsi crack oleh *Faster R-CNN* dan *Mask R-CNN* setelah menetapkan learning rate yang berbeda. Lima tingkat pembelajaran ditetapkan: 0,02, 0,01, 0,005, 0,0025, dan 0,0002.

Tingkat pembelajaran *Faster R-CNN* dan *Mask R-CNN* diselidiki dan dibandingkan, yang disajikan di Gambar 5 dan Gambar 6. Perbandingan acc dan loss plot berdasarkan learning rate yang berbeda dari *Faster R-CNN* dan *Mask R-CNN* dibahas dalam makalah ini.



Gambar 5. Berbagai Analisis Tingkat Pembelajaran. (a) Keakuratan berbagai tingkat pembelajaran Faster R-CNN. (b) Keakuratan berbagai tingkat pembelajaran dari Mask R-CNN. (c) Hilangnya berbagai kecepatan pembelajaran R-CNN yang Lebih Cepat. (d) Hilangnya berbagai tingkat pembelajaran Mask R-CNN.



Gambar 6. Perbandingan Acc Dan Loss Antara Faster R-CNN Dan Mask R-CNN

Dari gambar terlihat bahwa acc dan loss kedua algoritma tidak banyak berubah setelah dilakukan penyesuaian learning rate. Nilai acc dari *Faster R-CNN* dan *Mask R-CNN* stabil di sekitar 98, hilangnya *Faster R-CNN* stabil di sekitar 0,25, dan hilangnya *Mask R-CNN* stabil di sekitar 0,4. Namun, ketika learning rate 0,0002, hasilnya lebih buruk, seperti yang terlihat dari perbandingan kelompok hasil deteksi sebelumnya, tetapi plot acc dan loss memiliki hasil yang lebih diinginkan, yang menunjukkan bahwa model akan overfitted ketika learning rate disesuaikan menjadi 0,0002.

Di dalam gambar 5, kecepatan pembelajaran yang berbeda dari *Faster R-CNN* dan *Mask R-CNN* disajikan di mana gambar 5a menunjukkan perbandingan menurut lima tingkat pembelajaran untuk *Faster R-CNN*; gambar 5b menunjukkan perbandingan acc dari lima tingkat pembelajaran untuk *Mask R-CNN*; Gambar 5c menunjukkan perbandingan kerugian dari lima kecepatan pembelajaran untuk *Faster R-CNN*; Dan gambar 5d menunjukkan perbandingan kerugian dari lima tingkat pembelajaran untuk *Mask R-CNN*.

Perbandingan akurasi vs plot kerugian untuk laju pembelajaran yang sama dari *Faster R-CNN* dan *Mask R-CNN* disajikan. Gambar 5 menunjukkan perbandingan acc dan loss plot untuk learning rate yang sama dari lima kelompok *Faster R-CNN* dan *Mask R-CNN*. Seperti yang terlihat dari gambar: tingkat pembelajaran adalah 0,02, dan 0,01 acc ditunjukkan sebagai berikut: tahap awal *Mask R-CNN* lebih tinggi, dengan peningkatan iter, sedikit menurun, dan kemudian *Faster R-CNN* lebih tinggi secara signifikan; learning rate adalah 0,005 ketika perbedaan antara keduanya tidak

signifikan; tingkat pembelajaran adalah 0,0025 ketika *Mask R-CNN* awal lebih tinggi, dan kemudian perbedaan antara keduanya tidak signifikan. Kehilangan *Faster R-CNN* selalu lebih rendah daripada *Mask R-CNN*, dan loss *Faster R-CNN* stabil, sekitar 0,25, dan loss *Mask R-CNN* stabil, sekitar 0,4. Kehilangan *Faster R-CNN* selalu lebih rendah daripada *Mask R-CNN*. Karena fungsi kerugian *Mask R-CNN* meningkat, Lmasker, nilai loss dari *Mask R-CNN* akan semakin besar.

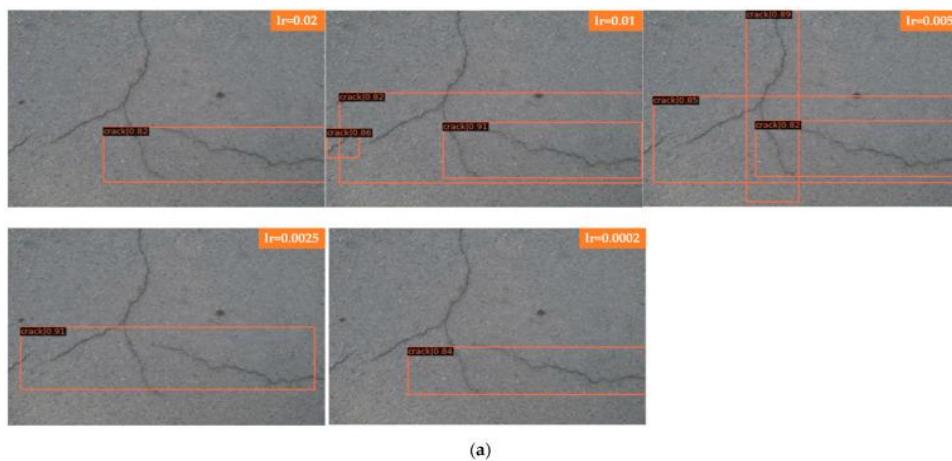
Dalam *Faster R-CNN*, setiap ROI memiliki dua keluaran: satu keluaran adalah hasil klasifikasi, yang merupakan label dari kerangka prediksi, dan keluaran lainnya adalah hasil regresi, yang merupakan koordinat kerangka prediksi. Namun, *Mask R-CNN* menambahkan keluaran ketiga, topeng objek, yang berarti topeng adalah keluaran untuk setiap ROI, dan cabang diimplementasikan melalui jaringan FCN. Fungsi kerugian *Mask R-CNN* adalah 1.2 dan terdiri dari tiga bagian: L_c (s,Lb o xDanLmasker), Di mana L_c sDanLb o xkonsisten dengan klasifikasi dan kerugian regresi yang didefinisikan dalam *Faster R-CNN*. Dalam *Mask R-CNN*, untuk cabang mask yang baru ditambahkan, dimensi output dari setiap ROI adalah $K \times m \times m$, di mana $m \times m$ menunjukkan ukuran mask dan K menunjukkan kategori K , sehingga total dari K binary mask adalah dihasilkan di sini. Setelah didapatkan prediksi mask, dicari nilai fungsi sigmoid untuk setiap nilai titik piksel dari mask tersebut, dan hasil yang diperoleh digunakan sebagai salah satu input untuk Lmasker (fungsi kerugian lintas-entropi). Perlu dicatat bahwa hanya ROI sampel positif yang digunakan untuk menghitung Lmasker, dan definisi sampel positif sama dengan deteksi target, yang didefinisikan sebagai sampel positif dengan IOU lebih besar dari 0,5. Nyatanya, Lmaskers sangat mirip dengan L_c , kecuali yang pertama dihitung berdasarkan titik piksel dan yang terakhir dihitung berdasarkan gambar, jadi mirip dengan L_c , meskipun topeng K diperoleh di sini, hanya topeng yang sesuai dengan kebenaran dasar yang valid dalam perhitungan fungsi kerugian lintas-entropi.

Di dalam gambar 6, kumpulan gambar ini menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* dengan *learning rate* yang sama, dimana Gambar 6a menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* saat *learning rate* 0,02; gambar 6b menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* ketika *learning rate* 0,01; gambar 6c menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* ketika *learning rate* 0,005; gambar 6d menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* saat *learning rate* 0,0025; Dan gambar 6e menunjukkan perbandingan *acc* dan *loss* antara *Faster R-CNN* dan *Mask R-CNN* saat *learning rate* 0,0002.

3. HASIL DAN PEMBAHASAN

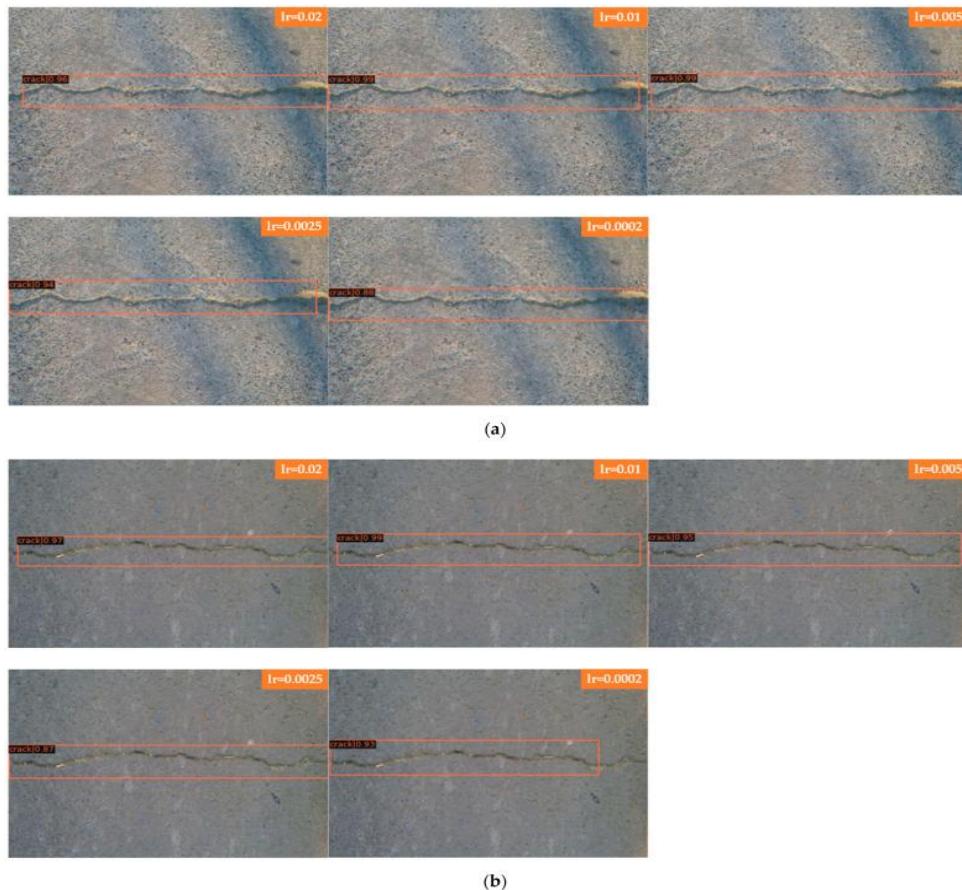
Empat set hasil yang berbeda dipilih untuk perbandingan: perbandingan retakan tunggal vs retakan bercabang, perbandingan retakan dengan atau tanpa gangguan sinar matahari, perbandingan retakan dalam dan dangkal, dan perbandingan retakan lurus dan melengkung.

3.1 Retak Tunggal Dan Retakan Bifurkasi



Gambar 7. Retak Tunggal Dan Retakan Bifurkasi

3.2 Retak Dengan Atau Tanpa Interferensi Sinar Matahari



Gambar 8. Retak Dengan Atau Tanpa Interferensi Sinar Matahari

4. KESIMPULAN

Dengan peningkatan jarak tempuh jalan yang cepat, metode pemantauan retakan jalan tradisional mengalami kesulitan memenuhi permintaan, dan teknologi pemantauan cerdas menjadi semakin mendesak. Pada penelitian ini, metode deep learning diselidiki untuk mendeteksi retakan jalan dengan perbandingan Faster R-CNN dan Mask R-CNN. Berikut poin-poin dalam penelitian ini yang dapat disimpulkan.

1. Untuk gambar retakan yang sama dengan set pelatihan data yang sama, kotak pembatas deteksi *Faster R-CNN* lebih lengkap daripada *Mask R-CNN*, dan dalam penelitian ini, di mana strategi pelatihan bersama mengarah ke kesulitan dalam regresi kotak pembatasnya, skor-thr *Faster R-CNN* lebih tinggi. Pada saat yang sama, kami melihat bahwa jenis pelatihan ini efektif. Kedua model mampu mendeteksi retakan lebih baik dengan hanya melatih 130+ gambar, dan penggunaan pengoptimal SGD membuat model tidak peka terhadap pengaturan kecepatan pembelajaran. Namun, deteksi retakan yang lebih kompleks lebih sensitif terhadap laju pembelajaran, dan hasil deteksi terburuk diperoleh saat laju pembelajaran adalah 0,0002.
2. Metode kami bekerja lebih baik daripada YOLOv3, karena kedua model ideal untuk mendeteksi retakan tunggal, dan kedua algoritme memiliki hasil deteksi yang ideal untuk mendeteksi retakan terang dan gelap. Selain itu, kedua algoritma dapat mendeteksi retakan lurus dengan baik. Untuk deteksi retakan yang dalam dan dangkal, *Faster R-CNN* bekerja dengan baik dalam dataset ini.

3. *Faster R-CNN* dan *Mask R-CNN* memerlukan lebih banyak dataset untuk melatih retakan kompleks, dan dataset dalam percobaan ini memiliki retakan tunggal melintang yang lebih banyak dan retakan yang kurang kompleks.
4. Acc dan loss *Faster R-CNN* tidak jauh berbeda di bawah lima tingkat pembelajaran yang ditetapkan dalam percobaan ini, dan kasus *Mask R-CNN* sama dengan *Faster R-CNN*.
5. Pada tingkat pembelajaran yang sama, acc dari *Faster R-CNN* lebih tinggi daripada *Mask R-CNN* ketika tingkat pembelajaran lebih dari 0,005, dan tingkat pembelajaran dari *Mask R-CNN* lebih tinggi daripada *Faster R-CNN* saat kecepatan pembelajaran kurang dari 0,005; nilai loss *Faster R-CNN* lebih kecil dari *Mask R-CNN*.

Untuk pekerjaan selanjutnya, bagaimana menggunakan sejumlah kecil data berlabel secara lebih efektif untuk mencapai hasil yang lebih baik akan menjadi tujuan penelitian kami. Model prateklatihan yang lebih cocok, pembelajaran aktif, augmentasi data, dll., Mungkin berguna untuk tujuan tersebut. Mempertimbangkan bahwa metode pembelajaran mendalam terus berkembang dan algoritme meningkat, kami akan menyelidiki algoritme yang lebih sempurna atau menyempurnakan algoritme yang ada untuk mendapatkan hasil deteksi yang lebih canggih di masa mendatang.

REFERENCES

- Hoang ND Klasifikasi Retak Perkerasan Aspal Menggunakan Pengolahan Citra Berbasis Laplacian Pyramid dan Pendekatan Hybrid Computational. *Komputer. Intell. Ilmu saraf*. 2018; 2018 :16. doi: 10.1155/2018/1312787. [[Artikel gratis PMC](#)] [[PubMed](#)] [[CrossRef](#)] [[Google Scholar](#)]
- Lei B., Wang N., Xu PC, Song GB Metode Deteksi Crack Baru untuk Inspeksi Jembatan Menggunakan UAV Memasukkan Pemrosesan Gambar. *J. Aerosp. Eng.* 2018; 31 :13. doi: 10.1061/(ASCE)AS.1943-5525.0000879. [[Ref Silang](#)] [[Google Cendekia](#)]
- Ying L., Teknik Berbasis Transformasi Salari E. Beamlet untuk Deteksi dan Klasifikasi Retakan Perkerasan. *Comput.-Aided Civil. Infrastruktur. Eng.* 2010; 25 :572–580. doi: 10.1111/j.1467-8667.2010.00674.x. [[Ref Silang](#)] [[Google Cendekia](#)]
- Myllyaho L., Raatikainen M., Männistö T., Mikkonen T., Nurminen JK Tinjauan pustaka sistematis tentang metode validasi untuk sistem AI. *J.Syst. Lembutw.* 2021; 181 :111050. doi: 10.1016/j.jss.2021.111050. [[Ref Silang](#)] [[Google Cendekia](#)]
- Kim B., Cho S. Penilaian retakan beton berbasis citra menggunakan mask dan jaringan saraf convolutional berbasis wilayah. *Struktur. Mengontrol Pemantauan Kesehatan.* 2019; 26 :e2381. doi: 10.1002/stc.2381. [[Ref Silang](#)] [[Google Cendekia](#)]