

PENGECAMAN KEROSAKAN KECIL BERDASARKAN FASTER R-CNN

Nur Shafinaz binti Omar¹

¹*Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia,
43600 UKM Bangi, Selangor Darul Ehsan, Malaysia*

Abstrak

Teknologi pengecaman kerosakan kecil memainkan peranan penting dalam pelbagai bidang seperti keselamatan, automasi, dan pemantauan. Cabaran utama dalam pengesahan kerosakan kecil termasuk kepekaan atau gangguan dari luar seperti cahaya, bayang-bayang, dan kontras yang rendah. Meskipun terdapat kemajuan dalam kecerdasan buatan dan penglihatan komputer, pengesahan kerosakan kecil masih menjadi isu mencabar. Penyelidik terdahulu dalam sains komputer telah cuba menyelesaikan masalah ini dengan menguji pelbagai algoritma pengesahan objek. Walaupun terdapat keberhasilan, masih terdapat kekurangan prestasi algoritma tersebut terutamanya dalam ketepatan dan tempoh masa bagi pengenalpastian kerosakan kecil. Kajian ini bertumpu pada penggunaan model Faster R-CNN yang telah dibuktikan memberikan prestasi baik dalam pengesahan objek kecil menggunakan teori yang melibatkan struktur model dan konsep pengesahan objek. Antara algoritma pengecaman yang digunakan adalah You Only Look Once (YOLO) dan Single Shot Detector (SSD). Selain itu, kajian terhadap *Transfer Learning* ditambah bagi meningkatkan lagi prestasi pengecaman kerosakan kecil kontena. Pendekatan ini diharapkan dapat mengatasi kelemahan dalam algoritma pengesahan kerosakan kecil yang sedia ada. Model ini juga mampu beroperasi dalam pelbagai keadaan dan persekitaran. Pengecaman kerosakan kecil pada set data kerosakan kontena di industri dicadangkan untuk menyediakan data berkualiti tinggi untuk analisis lanjutan. Pengecaman

kerosakan kontena seperti kemek, berlubang dan calar perlu ditengahkan bagi menjamin kualiti barang di pelabuhan agar kerugian peniaga boleh diminimakan. Keputusan kajian membuktikan pengecaman kerosakan kecil berdasarkan Faster R-CNN mempunyai ketepatan yang bagus iaitu sebanyak 80% ke atas.

Kata kunci: [Pengecaman kerosakan kecil, Faster R-CNN, Transfer Learning]

Pengenalan

Kecerdasan buatan (AI) merupakan pengetahuan penting yang memberikan banyak kelebihan, seperti meringankan urusan atau kerja manusia. AI digunakan dalam pelbagai bidang termasuk keselamatan, automasi, dan penjagaan kesihatan, seperti pengesanan penyakit dan *chatbot* untuk mengenal pasti tanda-tanda awal penyakit mental. Pengenalpastian kerosakan kecil menggunakan AI merujuk kepada pengenalan objek kecil dalam imej, yang sering kali meliputi kurang daripada 1% daripada imej. Ini penting dalam pengesanan jauh, bantuan pemanduan, dan pengawasan. Walaupun objek kecil sukar untuk dikesan, pengecaman ini adalah penting untuk menjamin kualiti barang di industri.

Projek ini bertujuan membangunkan model pengecaman kerosakan kecil menggunakan Faster R-CNN dan menambahbaik model tersebut dengan menggunakan *Transfer Learning*. Projek ini menggunakan set data kontena yang mempunyai kerosakan kecil di pelabuhan, bertujuan membantu kelancaran proses pemeriksaan kontena. Pada tahun 2020, pemeriksaan kontena menyebabkan kesesakan di pelabuhan, menyebabkan masalah seperti kerosakan sayur-sayuran. Projek ini akan memudahkan pemeriksaan kerosakan kecil pada kontena di industri.

Justifikasi dan kepentingan projek ini adalah membantu meningkatkan kualiti pemeriksaan kontena dan mengurangkan masalah kesesakan di pelabuhan, yang boleh menyebabkan kerosakan barang. Selain itu, pemeriksaan kontena ini juga penting untuk memastikan kontena dalam keadaan yang baik tiada kerosakan seperti lubang, kemek atau segala kerosakan kecil pada kontena yang membolehkan kerosakan pada barang pengguna justeru memberi kerugian kepada pihak industri.

Hasil projek ini dapat memberi manfaat besar kepada industri logistik dan perdagangan seperti dapat meminimumkan kerugian dan kelancaran memeriksa kontena. Metodologi yang digunakan ialah *Agile*, salah satu model dalam Software Development Life Cycle (SDLC). *Agile* dipilih kerana fleksibiliti dan kemampuannya untuk menangani perubahan data secara tiba-tiba. Proses *Agile* akan dibincangkan secara terperinci dibawah.


Laporan ini disusun mengikut struktur berikut: pengenalan, metodologi kajian, hasil kajian, perbincangan, dan kesimpulan. Pendahuluan memberi latar belakang dan objektif kajian, metodologi menerangkan pendekatan dan kaedah yang digunakan, hasil kajian merangkumkan dapatan utama, perbincangan menilai dan menginterpretasi hasil, dan kesimpulan memberikan ringkasan keseluruhan kajian serta saranan untuk kajian masa depan.

Metodologi Kajian

Software Development Life Cycle atau dikenali sebagai SDLC merupakan metodologi yang digunakan untuk merencanakan, merancangkan, mengembangkan, menguji dan mengimplementasikan. Terdapat beberapa model dalam SDLC antaranya ialah *Waterfall*, *Iterative*, *Spiral*, *V-Shape* serta *Agile*. Namun demikian, model SDLC yang akan digunakan sepanjang

perjalanan projek ialah *Agile*. Beberapa kelebihan *Agile* antaranya ialah (“The Benefits & Advantages of Agile | Wrike Agile Guide” n.d.):

- i) Fleksibel dan dapat menangani perubahan data secara tiba tiba dengan baik walaupun terdapat perubahan dalam masa yang singkat.
- ii) *Agile* melibatkan pengguna dalam proses pembangunan seperti menawarkan maklum balas pengguna. Ini akan membuatkan produk lebih selari dengan keinginan pengguna.
- iii) Mengurangkan risiko kerana boleh melihat halangan atau masalah dengan lebih jelas.



Rajah 1 Proses *Agile*


Proses *Agile* merangkumi 6 proses iaitu konsep, permulaan, iterasi, ujian, dan penghasilan. (Shcherbinin 2024) Fasa konsep juga dikenali sebagai fasa keperluan atau perancangan kerana pada permulaan fasa projek hendaklah membuat dokumentasi dan membuat senarai utama keperluan yang diperlukan sepanjang perjalanan projek dengan mengumpulkan segala idea yang diutarakan. Bagi projek ini, saya mencari set data yang bersesuaian dan mencari bahan rujukan yang sedikit sebanyak membantu projek ini.

Fasa yang kedua ialah fasa permulaan iaitu dengan mengagihkan tugas saya seperti *gantt chart* iaitu dengan menganalisis tugas atau kerja yang perlu dilakukan pada tempoh yang ditentukan. Fasa yang ketiga ialah fasa iterasi iaitu fasa untuk membangunkan perisian projek. Fasa ini mengambil tempoh yang paling lama antara fasa yang lain kerana selepas selesai setiap iterasi, ujian akan dilaksanakan untuk meningkatkan kualiti produk. Bagi projek ini, saya akan membuat pengaturcaraan pengecaman kerosakan kecil bagi set data yang dipilih iaitu kerosakan di kontena. Seterusnya, fasa ujian. Terdapat empat jenis ujian yang akan dijalankan iaitu ujian unit, ujian interasi, ujian penerimaan dan ujian sistem. Setiap ujian ini harus dilaksanakan supaya perisian projek bebas daripada ralat dan berfungsi sepenuhnya. Akhir sekali, fasa penghasilan tinjauan iaitu pada fasa ini perisian sudah selesai dibangunkan dan boleh digunakan oleh pengguna. Namun demikian, pemilik projek haruslah memikirkan kemungkinan masalah yang akan dihadapi dan mengenalpasti kekurangan dan kelebihan perisian.

Dalam projek ini, kaedah pengumpulan data yang digunakan adalah melalui penggunaan set data sedia ada yang mengandungi imej-imej kontena dengan kerosakan kecil. Set data ini diperoleh daripada sumber yang berkaitan dengan industri pelabuhan yang menyimpan rekod pemeriksaan kontena. Kaedah pengumpulan data ini dipilih kerana beberapa alasan. Pertama, ia memastikan bahawa data yang digunakan adalah relevan dan tepat, memandangkan ia diambil dari situasi sebenar dalam industri. Ini penting untuk memastikan model pengecaman kerosakan kecil yang dibangunkan dapat berfungsi dengan baik dalam persekitaran yang sebenar. Kedua, penggunaan set data sedia ada mengurangkan masa dan kos yang diperlukan untuk mengumpul data baru. Tambahan pula, set data ini memenuhi kriteria pengecaman objek kecil kerana imej-imej yang diambil dan ditapis mengandungi kerosakan yang kecil dalam skala yang berbeza, seperti calar,

lubang atau keretakkan pada kontena. Ini memastikan bahawa model yang dilatih menggunakan set data ini mampu mengenalpasti kerosakan kecil pada kontena dengan tepat.

Bgi kaedah analisis data, Data mentah ini diproses secara manual iaitu setiap gambar diteliti, ditapis serta dibuang mengikut ciri-ciri yang telah ditetapkan bagi menjalankan projek ini. Seterusnya, proses menganotasi gambar secara manual menggunakan *imglabel*. Proses anotasi ini dilakukan untuk memudahkan sistem pengecaman mengidentifikasi kerosakan kecil yang terdapat pada kontena. Sebagai contoh rajah 2, terdapat beberapa kerosakan kontena telah dianotaskan dalam satu gambar. Anotasi gambar ini akan secara terus masuk ke fail set data dalam komputer.



Rajah 2 Anotasi set data dengan mengidentifikasi kerosakan kontena

Selain itu, bagi menilai keberkesanannya hasil projek, penilaian pra-pemprosesan seperti ketepatan, ingatan, skor F1 dan *confusion matrix* atau dipanggil sebagai matriks kekeliruan digunakan untuk melakukan penilaian projek ini. Penilaian ini sering digunakan untuk menguji atau melihat bagaimana model prestasi pembelajaran mendalam ini dijalankan semasa proses pengujian. Sebagai contoh, *confusion matrix* ini digunakan untuk memberikan gambaran mengenai ketepatan model dengan menujukkan jumlah kes benar dan kes ramalan dalam setiap kelas. Bagi projek ini, pengujian dilakukan dengan melihat sama ada ramalan positif bagi kes sebenar positif iaitu Kerosakan_Kontena dapat diidentifikasi dengan baik. Selain itu, *confusion matrix* ini juga dapat melihat sama ada model ini dapat meramal negatif pada kes sebenar negatif iaitu *Background* atau dipanggil latar belakang.

Oleh itu, *confusion matrix* amatlah penting bagi menganalisis prestasi model dan mengidentifikasi kesalahan model dalam melakukan pengecaman. Dengan adanya *confusion matrix* ini kita dapat memahami kelemahan dan kekuatan model serta dapat memudahkan melakukan penambahbaikan pada masa akan datang.

Keputusan dan Perbincangan


Keputusan pengujian mendapati ketepatan pengecaman kerosakan kecil di kontena majoriti mendapati 90% ketepatan. Ini menunjukkan penggunaan *transfer learning* sangat membantu dalam mempercepatkan proses pengecaman dan meningkatkan prestasi model yang baik. Walaupun begitu, terdapat beberapa gambar yang mempunyai pengecaman bawah 50%. Hal ini kerana, imej tersebut mempunyai ciri-ciri yang tidak memenuhi pengecaman objek kecil. Ciri-ciri ini termasuklah kualiti gambar iaitu dari segi pisel yang kurang, keamatian cahaya pada gambar, bayang bayang serta latar belakang yang mengelirukan.




Rajah 3 Contoh Keputusan pengujian bagi pengecaman kerosakan kecil di kontena

Rajah 3 menunjukkan beberapa kerosakan kecil kontena yang mempunyai ketepatan bawah 50%. Berdasarkan imej ini, kerosakan kecil kontena yang mempunyai ketepatan 30% itu mempunyai kerosakan yang sangat kecil iaitu lubang, menjadikan model sukar untuk membuat pengecaman yang mempunyai ketepatan yang tinggi.

Namun demikian terdapat juga gambar yang mempunyai 90% ketepatan. Rajah 4 dibawah, merupakan contoh bagi gambar yang mempunyai ketepatan 80% keatas.



Rajah 4 Contoh keputusan pengujian bagi pengecaman kerosakan kecil di kontena



Rajah 5 Pengujian *confusion matrix* bagi Sistem Pengecaman Kerosakan Kecil


Berdasarkan rajah 5, pengujian menggunakan *confusion matrix* dapat dapat kita lihat prestasi model secara terperinci dan lebih jelas. Bagi pengecaman projek ini, kita dapat *True Labels* bagi Kerosakan_Kontena dan *Predicted Labels* bagi Kerosakan_Kontena mempunyai 192 imej gambar yang berjaya dikesan sebagai Kerosakan_Kontena. Namun demikian, terdapat juga *false negatives* iaitu pengecaman Kerosakan_Kontena dikesan sebagai *Background* atau dikenali sebagai latar belakang. Selain itu, tiada imej yang dikesan dan diramal sebagai *Background* dan tiada juga *false positives* dan *true negative* iaitu *Background* dikesan sebagai Kerosakan_Kontena dan *Background*.

```
EPOCH: 100.000  trn_loss: 0.014  val_loss: 0.341  (8208.30s - 0.00s remaining)
Accuracy: 0.8348
Recall: 0.8348
F1 Score: 0.9100
```

Rajah 6 Keputusan pengujian bagi Sistem Pengecaman Kerosakan Kecil

Rajah 6 di atas menunjukkan prestasi model Faster R-CNN untuk pengesanan kerosakan kecil kontena selepas dilatih selama 100 *epoch*. Dengan *trn_loss* yang rendah (0.014), model berjaya belajar dengan baik daripada data latihan dan mengurangkan ralat semasa latihan. *Val_loss* (0.341) yang hanya sedikit lebih tinggi daripada *trn_loss* menunjukkan model tidak mengalami *overfitting* yang ketara, menandakan keseimbangan baik antara pembelajaran dan generalisasi. Ketepatan model sebanyak 83.48% menunjukkan bahawa model mampu mengklasifikasikan lebih daripada 83% contoh dengan betul, sementara pengingatan (recall) juga sebanyak 83.48% menunjukkan keupayaan model untuk mengesan kes-kes positif dengan baik. Skor F1 yang tinggi (91%) menekankan keseimbangan yang baik antara pengingatan dan ketepatan, membuktikan model berfungsi dengan cemerlang dalam mengenal pasti kerosakan kecil pada kontena.

Menurut kajian lepas, secara perbandingan, kaedah penuh tanpa penggunaan *Transfer Learning* memberikan prestasi yang jauh lebih rendah tetapi kemudian meningkat dengan ketara dan mencapai puncaknya pada *epoch* ke-50. Keputusan ini membuktikan bahawa *Transfer Learning* memberikan hasil terbaik apabila mempunyai sedikit masa atau *epoch* untuk latihan (“Analysis of Transfer Learning on Faster R-CNN for Vehicle Detection” 2018). Daripada kajian ini kita dapat rumuskan bahawa penambahan *Transfer Learning* dalam model dapat membantu model meningkatkan ketepatan, kelajuan dan efisien model. Justeru, jelaslah penambahan *Transfer Learning* ini dapat meningkatkan prestasi dan kelajuan model ini.



Rajah 7 Contoh perbezaan menggunakan *Transfer Learning* dan tidak menggunakan *Transfer Learning* berdasarkan mAP (“Analysis of Transfer Learning on Fater R-CNN for Vehicle Detection” 2018).

Daripada graf garisan ini kita dapat lihat bahawa permulaan bagi *Transfer Learning* agak tinggi berbanding latihan penuh. Ini membuktikan bahawa *Transfer Learning* dapat meningkatkan kelajuan dan seterusnya dapat meningkatkan prestasi model. Dengan memulakan dari titik yang lebih maju, model dapat mengenali ciri-ciri yang lebih kompleks dan mencapai ketepatan yang lebih tinggi. Akhir sekali, memasukkan *Transfer Learning* sebagai teknik penambahbaik model adalah strategi berbekesan untuk meningkatkan prestasi model dengan lebih cepat dan efisien. Ia bukan sahaja mempercepatkan proses pembangunan model tetapi juga mengurangkan keperluan untuk sumber daya pengiraan yang besar dan menjadikannya pilihan yang bijak dalam banyak aplikasi pembelajaran mesin.

Hasil kajian ini menunjukkan bahawa model Faster R-CNN yang dilatih untuk mengesan kerosakan kecil pada kontena dapat berfungsi dengan baik, dengan ketepatan sebanyak 83.48% dan skor F1 sebanyak 91%. Implikasi ini sangat penting dalam industri logistik dan pengurusan kontena, di mana pengesanan awal dan tepat terhadap kerosakan dapat mengurangkan kos pembaikan dan meningkatkan efisiensi operasi. Dalam bidang ilmu, kajian ini menyumbang kepada kemajuan dalam pengesanan objek dan analisis imej menggunakan pembelajaran mendalam, memperkuatkan lagi kebolehgunaan model-model seperti Faster R-CNN dalam aplikasi dunia sebenar.

Walaupun hasil kajian ini menunjukkan prestasi yang baik, terdapat beberapa aspek yang boleh diperbaiki. Pertama, kajian ini boleh diperluaskan dengan menggunakan set data yang lebih besar dan lebih pelbagai untuk menguji generalisasi model pada pelbagai jenis kerosakan dan kontena. Selain itu, kajian lanjut boleh menumpukan pada pengoptimuman *hyperparameter* model dan penggunaan teknik augmentasi data untuk meningkatkan lagi ketepatan dan kebolehan model dalam mengesan kerosakan yang lebih halus. Penyelidik lain juga boleh meneroka integrasi model

pengesanan kerosakan ini dengan sistem IoT untuk menyediakan pemantauan masa nyata dan pengurusan inventori yang lebih efisien.

Kesimpulan

Kesimpulannya, projek ini berjaya membangunkan model pengecaman kerosakan kecil menggunakan Faster R-CNN yang dilatih dengan teknik *Transfer Learning*, menghasilkan ketepatan lebih daripada 80% dan membuktikan keberkesanan dalam mengesan kerosakan kecil pada kontena di industri. Penggunaan metodologi *Agile* memastikan fleksibiliti dan ketepatan dalam pembangunan model, sementara penilaian menggunakan metrik seperti ketepatan, pengingatan, dan skor F1 menunjukkan prestasi yang kukuh dan seimbang. Oleh hal yang demikian, jelaslah penggunaan Faster R-CNN dan penambahan *Transfer Learning* dapat membantu memberikan keputusan prestasi model yang bagus dan tinggi. Walaubagaimanapun, terdapat cabaran seperti kualiti gambar dan gangguan luaran seperti latar belakang, model masih dapat membantu meningkatkan kualiti pemeriksaan kontena yang memberi kebaikan dalam mengurangkan kerugian dalam industri logistik, dan meminimumkan masalah kesesakan di pelabuhan. Namun demikian, penambahbaik seperti menambah set data kerosakan kecil kontena dan menukar *pretrain* model yang memiliki set data latihan yang lebih spesifik kepada pengecaman objek kecil amatlah digalakkkan. Hasil ini bukan sahaja menunjukkan peningkatan signifikan dalam pengesan objek kecil tetapi juga menegaskan potensi kecerdasan buatan dalam aplikasi praktikal yang kritikal.

Penghargaan

Alhamdulilah, setinggi kesyukuran kehadrat Illahi kerana dengan izin dan limpah rahmatNya, projek tahun akhir ini dapat disiapkan.

Setinggi penghargaan dan ucapan terima kasih saya dahulukan kepada penyelia projek tahun akhir saya, Dr. Afzan Adam di atas tunjuk ajar, teguran, nasihat dan galakan kalian sepanjang saya melaksanakan tesis ini. Bimbingan yang tidak ternilai ini hanya mampu saya ucapkan jutaan terima kasih dan didoakan semoga jasa baik kalian di beri ganjaran yang tinggi oleh Allah SWT. Amin.

Ucapan jutaan terima kasih juga saya tujuhan kepada Fakulti Teknologi dan Sains Maklumat serta kolej KIY kerana menyediakan kemudahan seperti rangkaian internet dan mini perpustakaan kerana memudahkan proses menyiapkan projek tahun akhir saya.

Di samping itu, ucapan jutaan terima kasih saya tujuhan kepada ahli keluarga saya, terutamanya kedua ibu bapa saya, En. Omar bin Johari dan Pn. Noranita Binti Bahaudin. Doa yang tidak pernah putus dari kalian membuatkan saya dapat menyiapkan projek tahun akhir saya.

Tidak dilupakan juga rakan-rakan seperjuangan saya yang telah banyak membantu secara langsung atau tidak langsung, memberi semangat dan membimbang untuk terus melangkah ke garisan akhir. Mereka yang sanggup menahan mata bersama-sama dari matahari mula bangun sehingga matahari bangun semula bagi menyiapkan tugas tesis ini. Tanpa kalian, perjalanan menyiapkan tesis ini tidak dapat disiapkan dengan lebih baik. Semoga kita sama-sama beroleh kejayaan di dunia dan juga di akhirat dan semoga kita dapat bertemu semula di masa akan datang. Amin.

Terima kasih saya ucapan kepada semua atas segalanya. Jasa baik kalian tidak mungkin saya ungkapkan satu persatu dan budi kalian mungkin tidak dapat saya balas. Semoga Allah SWT sentiada memberkati dan memberi ganjaran ke atas budi kalian. Amin.

RUJUKAN

Analysis of Transfer Learning on Faster R-CNN for Vehicle Detection.

2018.

<https://openlibrarypublications.telkomuniversity.ac.id/index.php/soft/article/viewFile/8440/8293> [21 Mei 2024].

Shcherbinin, I. 2024. The Agile Software Development Life Cycle: All You Need to Know. <https://distantjob.com/blog/agile-software-development-life-cycle/>.

The Benefits & Advantages of Agile | Wrike Agile Guide. (n.d.). <https://www.wrike.com/agile-guide/benefits-of-agile/>.

Nur Shafinaz Binti Omar (A187808)

Dr. Ts. Afzan Adam

Fakulti Teknologi & Sains Maklumat,
Universiti Kebangsaan Malaysia