

# PENGESANAN DAN PENGELASAN KETULAN UNTUK MAMOGGRAM MENGGUNAKAN PEMBELAJARAN MENDALAM

Cheah Yen Hong

Assoc. Prof. Dr. Shahnorbanun Sahran

*Fakulti Teknologi dan Sains Maklumat, Universiti Kebangsaan Malaysia*

## ABSTRAK

Kanser payudara adalah salah satu penyakit yang paling berbahaya bagi wanita yang mengalami morbiditi yang tinggi. Cara yang berkesan untuk mengurangkan kematian adalah untuk mengesan kanser lebih awal dengan pemeriksaan. Secara klinikal, pendekatan terbaik untuk pemeriksaan untuk wanita Asia ialah imej ultrasound yang digabungkan dengan biopsi. Walau bagaimanapun, biopsi adalah invasif dan ia mendapat maklumat yang tidak komprehensif mengenai ketulan tersebut. Tujuan kajian ini adalah untuk membina model untuk pengesanan automatik, segmentasi, dan klasifikasi ketulan payudara dengan imej mamogram. Berdasarkan pembelajaran yang mendalam, teknik yang menggunakan Mask dengan kawasan rangkaian saraf convolutional dan Faster dengan kawasan rangkaian saraf convolutional telah dibangunkan bagi membandingkan model yang terbaik untuk pengesanan ketulan dan pembezaan antara benigna dan malignan. Kaedah yang dicadangkan menyediakan cara komprehensif dan tidak ceroboh (*noninvasive*) untuk mengesan dan mengklasifikasikan ketulan payudara.

## 1. PENGENALAN

Kanser payudara adalah salah satu punca utama kematian wanita di seluruh dunia. Menurut Global Cancer Incidence, Mortality and Prevalence(Globocan), jumlah kes kanser yang dijangka pada tahun 2018 ialah 23,218 kes dengan 12,458 kematian. Di Malaysia, kanser adalah masalah yang semakin meningkat dan terutama kanser payudara. (Dr Milton Lum., 2019)

Kanser payudara adalah tumor malignan yang terbentuk oleh saluran-saluran atau lobula yang tidak normal. Sekiranya struktur payudara berubah, ia boleh menghasilkan tumor. Tumor boleh diklasifikasikan kepada tumor benigna atau malignan mengikut histopatologi (contohnya, keupayaan pembezaan, pleiomorphik sel, nuklear kepada nisbah sitoplasma), atau petunjuk biologi klinikal (contohnya pencerobohan dan metastasis). Dan ia adalah salah satu penyakit

yang paling berbahaya bagi wanita yang mengalami morbiditi tertinggi. Di samping itu, perjalanan kanser payudara berkembang pesat. Oleh itu, diagnosis yang tertunda mungkin memberi impak yang besar kepada pesakit. Jika diagnosis kanser payudara boleh dilakukan lebih awal, kematianya boleh menurun. Pemeriksaan kanser payudara adalah kaedah yang berkesan untuk mengesan ketulan payudara yang tidak dapat ditentukan lebih awal.

Cara umum pemeriksaan payudara adalah diagnosis pengimejan, termasuk pencitraan resonans magnetik (MRI), mamografi, dan ultrasound payudara. Tanda-tanda yang berbeza dikaitkan dengan pendekatan pengimejan yang berbeza. MRI untuk pemeriksaan payudara sangat sensitif terhadap ketulan tisu lembut. Walau bagaimanapun, ia adalah mahal, dengan masa imbasan yang agak panjang dan dengan kadar positif palsu yang lebih tinggi. Pada masa ini, mamografi dan ultrasound payudara adalah pendekatan saringan yang paling biasa.

Ketulan yang dikesan boleh sama ada benigna atau malignan. Perbezaan antara tumor benigna dan malignan adalah bahawa tumor benigna mempunyai bentuk bulat atau bujur, manakala tumor maligna mempunyai bentuk bulatan yang sepadan dengan garis luar yang tidak teratur. Di samping itu, ketulan maligna akan kelihatan lebih putih berbanding mana-mana tisu yang mengelilinginya (Tang et al., 2009).

## 2. PENYATAAN MASALAH

Kanser payudara adalah penyakit kritis yang mempengaruhi banyak wanita di seluruh dunia. Mengesan kanser ini dalam peringkat pertama membantu menyelamatkan nyawa. Di samping itu, telah dilaporkan bahawa mamografi diklasifikasikan sebagai kaedah pengesanan kanser yang paling popular dan paling mudah pada tahap awalnya. Radiologi mempunyai keupayaan untuk meramalkan dan mempunyai ketepatan melebihi 90%. Walau bagaimanapun, ahli radiologi boleh terlepas 10% -15% daripada kanser payudara (Erickson, 2005). Hasil positif palsu boleh dikurangkan dengan pemeriksaan berganda dan membaca imej mammografi. Pemeriksaan berganda memerlukan mamogram yang sama untuk dianalisis oleh dua ahli radiologi yang berlainan pada masa yang berlainan. Pemeriksaan berganda ditunjukkan telah meningkatkan ketepatan pengesanan yang betul sebanyak 15% berbanding dengan pemeriksaan tunggal. Walau bagaimanapun, ini adalah prosedur yang memakan masa dan mahal. Kos ini boleh dikurangkan dengan menggunakan diagnosis membantu komputer (CAD) dan pengesanan berbantu komputer (CADe). Itu adalah sistem komputer yang boleh digunakan dalam diagnosis perubatan. Diagnosis ini mengandungi beberapa kaedah dan teknik, termasuk pangkalan data, pemprosesan imej, pembelajaran mesin dan analisis data.

Dalam kajian sebelumnya tentang klasifikasi kanser payudara, ciri tekstur tempatan adalah ciri penting. Mereka menggunakan diagnosis bantuan komputer dalam ultrasound

payudara untuk mengukur ketulan oleh ciri-ciri BI-RADS(Breast imaging reporting and data) termasuk bentuk, orientasi, margin, sempadan ketulan, corak echo, dan kelas ciri akustik posterior untuk mencari korelasi antara ciri-ciri imej yang diekstrak dan ketulan itu. Walau bagaimanapun, setiap ciri mempunyai perbezaan yang signifikan dalam korelasi hasil seksyen patologi. Satu lagi penyelidikan dari Shen W-C, Chang R-F, Moon WK pada 2007 menggunakan rangkaian neural buatan berdasarkan 5 ciri-ciri spikulasi, bentuk ellipsoid, corak cawangan, kecerahan nodul, bilangan lobulus untuk membezakan antara ketulan payudara benigna dan maligna. Selain itu, Li et al menggunakan pembelajaran mendalam dan pembelajaran statistik berdasarkan ciri untuk menilai kepadatan payudara dan membandingkan keberkesanan kaedah di atas . Hasilnya menunjukkan bahawa teknik menggunakan pembelajaran mendalam adalah lebih baik daripada pembelajaran statistik berdasarkan ciri.

Penyelidikan tentang pengesahan dan pengelasan ketulan payudara untuk imej mamogram dengan pembelajaran mendalam adalah masih kurang dalam kajian sebelum ini.

### **3. OBJEKTIF KAJIAN**

1. Untuk meneroka dan mengaplikasikan kaedah dan menggunakan algoritma Mask RCNN dan Faster RCNN dengan Pembelajaran Mendalam.
2. Membandingkan prestasi algoritma Mask RCNN dan Faster RCNN untuk pengesahan dan pengelasan ketulan payudara imej mamogram.

### **4. METOD KAJIAN**

Dalam pembangunan model, model proses yang digunakan ialah model Iteratif (Iterative). Berbeza dengan model air terjun (Waterfall model) yang lebih tradisional, yang memberi tumpuan kepada proses pembangunan langkah-demi-langkah yang ketat, model iteratif paling baik dianggap sebagai proses kitaran. Selepas fasa perancangan awal, segelintir peringkat kecil diulang berulang, dengan setiap selesai kitaran bertambah baik. Pernambahbaikan dengan cepat dan dilaksanakan pada setiap lelaran, yang membenarkan lelaran berikutnya menjadi lebih baik daripada yang terakhir.

#### **4.1 Fasa Perancangan & Keperluan**

Seperti kebanyakan projek pembangunan, langkah pertama adalah melalui peringkat perancangan awal untuk merancang butiran dokumen spesifikasi, menubuhkan keperluan perisian atau perkakasan, dan secara amnya bersedia untuk peringkat kitaran yang akan datang.

#### **4.2 Fasa Analisis & Reka Bentuk**

Setelah perancangan selesai, analisis dilakukan untuk mencatat logik perniagaan yang sesuai, model pangkalan data, dan sebagainya yang diperlukan pada tahap ini dalam projek. Peringkat reka bentuk juga berlaku di sini, mewujudkan sebarang keperluan teknikal (bahasa, lapisan data, perkhidmatan, dll) yang akan digunakan untuk memenuhi keperluan tahap analisis.

#### **4.3 Fasa Pelaksanaan**

Dengan perancangan dan analisis, proses pelaksanaan dan pengekodan sebenarnya dapat dimulai sekarang. Semua dokumen perancangan, spesifikasi, dan reka bentuk sehingga ke tahap ini dikodkan dan dilaksanakan ke dalam lelaran awal projek ini.

#### **4.4 Fasa Pengujian**

Setelah lelaran dibina telah dikodkan dan dilaksanakan, langkah seterusnya adalah melalui satu siri prosedur pengujian untuk mengenal pasti dan mencari sebarang potensi atau masalah yang telah timbul.

#### **4.5 Fasa Penilaian**

Setelah semua peringkat sebelumnya telah selesai, sudah tiba masanya untuk penilaian menyeluruh pembangunan hingga tahap ini. Ini membolehkan seluruh pasukan, serta pelanggan atau pihak luar lain, untuk memeriksa di mana projek ini berada, di mana ia perlu, apa yang boleh atau patut diubah, dan sebagainya.

Perkakasan dan perisian yang akan digunakan semasa pembangunan sistem menjadi panduan untuk pengguna dan penyelidik untuk menjalankan kajian.

Spesifikasi perkakasan harus bersesuaian untuk menampung pembangunan sistem kerana setiap perisian yang diguna memerlukan perkakasan yang mempunyai had tertentu supaya ia berjalan lancar. Pengguna memerlukan spesifikasi keperluan perkakasan yang mempunyai spesifikasi minimum yang disenaraikan berikut:

Jadual 4. 1 Keperluan Perkakasan

Perkakasan	Spesifikasi	
	Pengguna	Pembangun
Unit Pemprosesan Utama (CPU)	4GB	8GB ke atas
Ingatan Cakera Rawak (RAM)	Intel® Core™ i5 Processors	Intel® Core™ i5 Processors

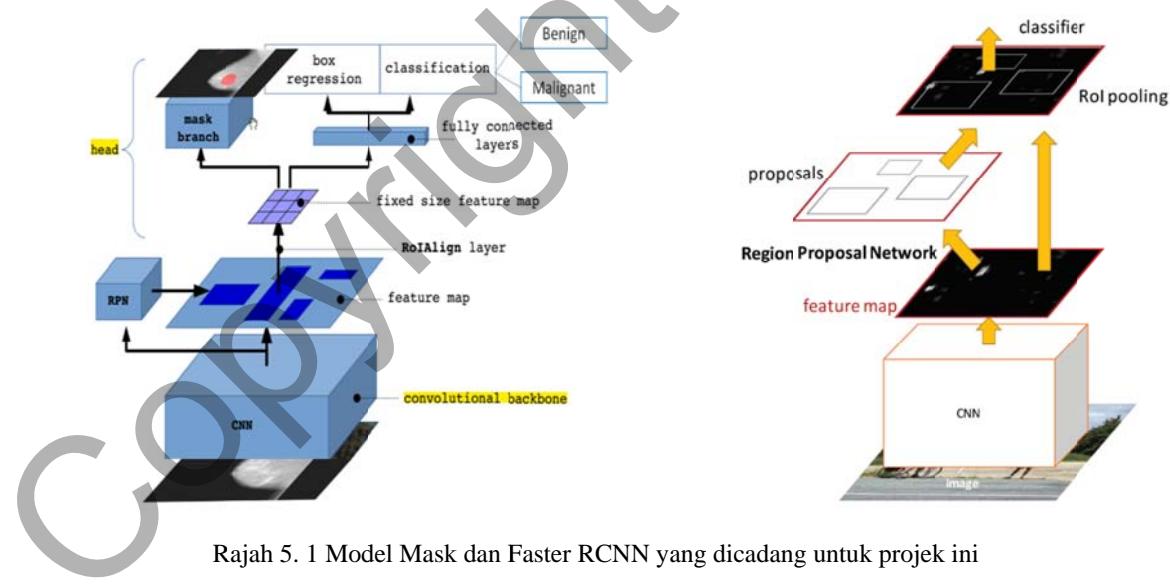
Cakera keras (Hard Disk Drive)	HDD	SSD
--------------------------------	-----	-----

Spesifikasi Keperluan Perisian yang sesuai juga akan melancarkan progress dalam pembangunan sistem. Spesifikasi perisian adalah seperti yang berikut:

Jadual 4. 2 Keperluan Perisian

Perisian	Penerangan
Python	Python adalah bahasa pengaturcaraan tujuan umum dan peringkat tinggi
Keras	Keras adalah perpustakaan rangkaian neural-sumber yang ditulis dalam Python. Ia mampu berjalan di atas TensorFlow. Direka untuk membolehkan percubaan cepat dengan rangkaian saraf yang mendalam.
Tensorflow	TensorFlow adalah perpustakaan perisian percuma dan sumber terbuka untuk aliran data dan pengaturcaraan berlainan dalam pelbagai tugas. Ia adalah perpustakaan matematik simbolik, dan juga digunakan untuk aplikasi pembelajaran mesin seperti rangkaian neural.

## 5 HASIL KAJIAN



Rajah 5. 1 Model Mask dan Faster RCNN yang dicadang untuk projek ini

Berdasarkan Rajah 5.1 merupakan 2 model yang dicadang untuk membuat perbandingan. Lapisan pertama ialah lapisan masukan pengguna. Kemudian, imej akan menjalani Mask R-CNN / Faster RCNN untuk mengekstrak ciri-ciri ketulan keluar dari imej. Klasifikasi menggunakan CNN adalah langkah terakhir untuk menentukan ketulan di bawah pemerhatian adalah kawasan

yang benigna atau malignan. Jika ia dikategorikan sebagai kawasan kanser, klasifikasi yang seterus akan dilakukan untuk menentukan patologi kanser, iaitu, benigna atau malignan.

Mask R-CNN (rangkaian neural convolutional serantau) dan Faster RCNN adalah rangka kerja dua peringkat: peringkat pertama mengimbas imej dan menghasilkan cadangan (kawasan yang mungkin mengandungi objek) dan peringkat kedua mengklasifikasikan cadangan dan menghasilkan kotak(bounding boxes), yang bezanya Mask RCNN juga akan menghasilkan topeng(mask) yang membatasi.

Sistem terdiri daripada modul-modul ini:

1. Tulang belakang (Backbone)

Bagi Mask RCNN, rangkaian neural convolutional standard (ResNet101) yang berfungsi sebagai pengekstrak ciri. Lapisan awal mengesan ciri tahap rendah (tepi dan sudut), dan kemudian lapisan secara berturut-turut mengesan ciri tahap tinggi (kereta, orang, langit). Peta ciri ini menjadi input untuk peringkat berikut.



Rajah 5. 2 Rangkaian Piramid (Feature Pyramid Network (FPN))

Ciri Rangkaian Piramid (Feature Pyramid Network (FPN)) diperkenalkan oleh pengarang Mask R-CNN yang sama sebagai pelanjutan yang lebih baik dapat mewakili objek pada pelbagai skala.

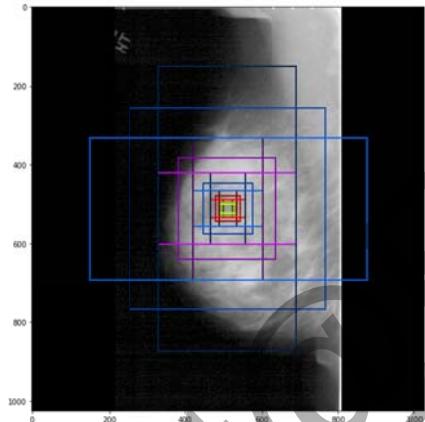
FPN memperbaiki piramid pengekstrakan ciri standard dengan menambah piramid kedua yang mengambil ciri tahap tinggi dari piramid pertama dan melepas mereka ke lapisan yang lebih rendah. Dengan berbuat demikian, ia membolehkan ciri-ciri pada setiap peringkat untuk mempunyai akses ke ciri tahap kedua, rendah dan lebih tinggi.

Pelaksanaan Mask RCNN adalah menggunakan tulang belakang ResNet101 + FPN.

Bagi Faster RCNN, Faster-RCNN terdiri daripada dua blok yang berkongsi tulang belakang. Ini bertujuan untuk menghasilkan ciri diskriminatif yang akan digunakan untuk menganggar objek calon dan juga untuk meramalkan kelas objek tersebut. Tulang belakang juga

merupakan rangkaian saraf konvolusional. Untuk tujuan ini, seni bina ResNet baru-baru ini, Resnet50 digunakan. Blok pertama, disebut Wilayah Proposal Network (RPN), dikhaskan untuk mencari kawasan di mana objek sangat mungkin muncul, sementara blok kedua hanyalah Fast-RCNN yang berfokus pada meramalkan kelas objek yang dicadangkan.

## 2. Region Proposal Network (RPN)



Rajah 5. 3 Ilustrasi ringkas menunjukkan kotak jangkar (anchor boxes)

RPN adalah rangkaian neural ringan yang mengimbas imej dalam fesyen tingkap gelongsor dan mendapati kawasan yang mengandungi objek. Kawasan-kawasan yang mengimbas RPN dipanggil anchor. Mana kotak yang diedarkan di atas kawasan imej, seperti yang ditunjukkan di sebelah kiri. Ini adalah pandangan mudah. Dalam praktiknya, terdapat kira-kira 200K saiz anchor dan nisbah aspek yang berbeza, dan mereka bertindih untuk menampung sebanyak mungkin imej.

Tingkap gelongsor dikendalikan oleh sifat convolutional RPN, yang membolehkan ia mengimbas semua kawasan selari (pada GPU). Tambahan pula, RPN tidak mengimbas imej secara langsung (walaupun kita menarik penanda pada imej untuk ilustrasi). Sebaliknya, RPN mengimbas ke atas peta ciri tulang belakang. Ini membolehkan RPN untuk menggunakan semula ciri yang diekstrak dengan cekap dan mengelakkan pengiraan pendua. Dalam Mask RCNN biasanya menggunakan imej yang lebih besar dan lebih banyak anchor jadi mungkin sedikit lebih lama.

RPN menghasilkan dua output untuk setiap jangkar(anchor). Kelas Anchor adalah salah satu daripada dua kelas: latar depan atau latar belakang (foreground or background). Kelas FG menunjukkan bahawa ada kemungkinan objek dalam kotak itu. Yang kedua, Pembetungan Kotak Bounding, adalah anchor latar depan(foreground) (juga dikenali sebagai anchor positif) mungkin

tidak berpusat sempurna di atas objek. Jadi RPN menganggarkan delta (perubahan% x, y, lebar, ketinggian) untuk memperbaiki kotak anchor agar sesuai dengan objek yang lebih baik.

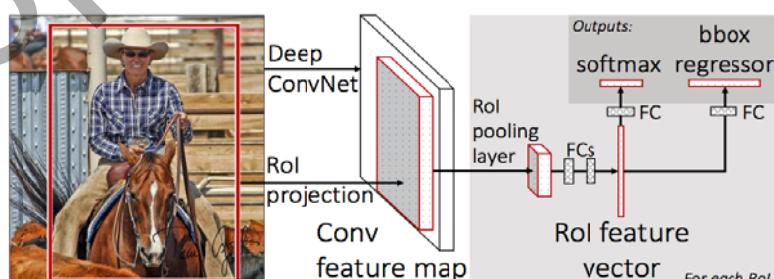
Menggunakan ramalan RPN, kami memilih anchor utama yang mungkin mengandungi objek dan memperbaiki lokasi dan saiznya. Sekiranya beberapa anchors tumpang tindih terlalu banyak, kita menyimpan yang mempunyai skor latar depan(foreground) tertinggi dan membuang sisanya (dirujuk sebagai Penindasan Non-maksimal(Non-max Suppression)). Selepas itu kami mempunyai cadangan akhir (wilayah minat(regions of interest)) yang kami lulus ke peringkat seterusnya.



Rajah 5. 4 Kotak anchor (bertitik) dan peralihan / skala yang digunakan untuk menyesuaikan objek dengan tepat (pepejal). Beberapa anchor boleh memetakan objek yang sama.

### 3. ROI Classifier & Bounding Box Refinement

Peringkat ini berjalan di wilayah minat (regions of interest ROI) yang dicadangkan oleh RPN. Dan seperti RPN, ia menghasilkan dua output untuk setiap ROI:



Rajah 5. 5 Illustrasi of stage 2

Kelas: Kelas objek dalam ROI. Tidak seperti RPN, yang mempunyai dua kelas (FG / BG), rangkaian ini lebih mendalam dan mempunyai keupayaan untuk mengklasifikasikan wilayah ke kelas tertentu (orang, kereta, kerusi, dll.). Ia juga boleh menjana kelas latar belakang (background class), yang menyebabkan ROI dibuang.

Pembungkusan Kotak Bounding: Sangat mirip dengan bagaimana ia dilakukan dalam RPN, dan tujuannya adalah untuk terus memperbaiki lokasi dan saiz kotak sempadan untuk merangkum objek tersebut.

#### 4. ROI Pooling

Oleh sebab pengelas tidak mengendalikan saiz input pembolehubah dengan sangat baik. Mereka biasanya memerlukan saiz input tetap. Bagaimanapun, disebabkan oleh langkah penghalusan kotak terikat di RPN, kotak ROI boleh mempunyai saiz yang berbeza. Disitulah ROI Pooling dimainkan.

ROI Pooling merujuk kepada pemangkapan sebahagian daripada peta ciri dan mengubah saiznya kepada saiz tetap. Ia sama pada dasarnya untuk memotong sebahagian daripada imej dan mengubah saiznya (tetapi terdapat perbezaan dalam butiran pelaksanaan). Walaubagaimanapun, ROIAlign untuk Mask RCNN sahaja akan sampel peta ciri pada titik yang berbeza dan gunakan interpolasi bilinear.

Setiap gambar dalam masalah pengesanan objek mungkin mempunyai objek yang berlainan dari kelas yang berbeza. Seperti yang disebutkan sebelumnya, kedua-dua klasifikasi dan lokalisasi model perlu dinilai.

Oleh itu, metrik ketepatan standard yang digunakan dalam masalah klasifikasi imej tidak dapat diterapkan secara langsung di sini, di sinilah mAP (mean Average Precision) digunakan.

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i$$

Rajah 5. 6 Pengiraan mean Average Precision

Berdasarkan matriks kekeliruan dan report klasifikasi, ketepatan model pengesanan dan pengelasan Mask RCNN adalah 34.50% dan Faster RCNN adalah 81.31%.

Seterusnya, Rajah 5.7 menunjukkan proses pengujian model Mask RCNN dan Faster RCNN.



Rajah 5. 7 Proses pengujian model

Pada mulanya, dataset imej ketulan payudara diambil dari The Digital Database for Screening Mammography (DDSM). Imej ditukar kepada .png untuk tujuan latihan. Setiap imej ketulan benigna atau malignan telah disediakan untuk latihan dan pengesahan. Imej dilabelkan dengan imej ground truth yang disediakan di laman web DDSM, VGG Image Annotator digunakan untuk melakukan pelabelan imej dan mengeksport label sebagai fail .json dan fail.csv. Selepas itu, dataset ini digunakan untuk melakukan latihan model. Google Colab digunakan untuk menjalankan model buat sementara waktu. Dalam proses ini, saya telah cuba menyesuaikan parameter untuk mendapatkan ketepatan lebih tinggi ramalan. Mask-RCNN dan Faster RCNN digunakan sebagai model projek ini dan dibandingkan untuk mengesan ketulan dalam imej dan mengklasifikasikannya menjadi benigna atau malignan.

Seterusnya, ditunjukkan perbandingan hasil output model Mask RCNN dan model Faster RCNN.



Rajah 5. 8 Kes  
Benign - kebenaran  
tanah

Rajah 5. 9 Ramalan  
Lokasi Ketulan  
Faster RCNN

Rajah 5. 10 Ramalan  
Lokasi Ketulan Mask  
RCNN

## 6 KESIMPULAN

Secara keseluruhannya, model pengesanan ketulan payudara telah dibangunkan mengikut objektif dan skop kajian yang telah dirancang. Untuk peningkatan mada depan, dicadangkan untuk mencari cara untuk membuangkan label ramalan dari Faster RCNN yang lebih. Tambahan pula, untuk mendapat ketepatan yang tinggi, jumlah set data boleh ditambah. Kedua, resolusi imej boleh dipertingkatkan. Ketiga, antaramuka sistem pengesanan yang lebih mesra pengguna dibangun. Sekiranya, pembangunan model pengesanan ketulan payudara akan dicapai, dan akan dijalankan dengan masa yang lebih singkat, kos lebih murah dan ketepatan yang tinggi.

## 7 RUJUKAN

- LeCun, Yann. Dan Bengio, Yoshua. dan Hinton, Goeffrey. 2015. Deep learning, nature. 521: 436-444
- Xing, F. dan Xie, Y. dan Yang, L. 2016. An automatic learning-based framework for robust nucleus segmentation IEEE Trans Med Imaging. 35 (2): 550-66
- Prasoon, A. dan Petersen, K. dan Igel, C. dan Lauze, F. dan Dam, E. dan Nielsen, M. 2013. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural

network Medical image computing and computer-assisted intervention - (MICCAI). 16th international conference, nagoya, Japan.16(Pt 2):246-53

Ribli, Dezso. dan Horvath, Anna. dan Unger, Zsuzsa. dan Pollner, Peter. dan Csaba, Istvan. 2017. Detecting and classifying lesions in mammograms with Deep Learning.

Zhantao Cao,Lixin Duan, Guowu Yang,Ting Yue,and Qin Chen . 2019. An experimental study on breast lesion detection and classification from ultrasound images using deep learning architectures.

Cheng HD. dan Shan J. dan Ju W. dan Guo YH. dan Zhang L. 2010. Automated breast cancer detection and classification using ultrasound images: A survey. Pattern Recog.

Zhang H. dan Wang KF. dan Wang FY. 2017. Advances and Perspectives on Applications of Deep Learning in Visual Object Detection.

Huang KQ. dan Ren WQ. dan Tan TN. 2014. A review on image object classification and detection. Chinese J Comput.

Kelly, KM. dan Dean J. dan Comulada WS. dan et al. 2010. Breast cancer detection using automated whole breast ultrasound and mammography in radiographically dense breasts.

Shen W-C. dan Chang R-F. dan Moon WK. dan et al. 2007. Breast ultrasound computer-aided diagnosis using BI-RADS features.

Andrey Sorokin. 2018. Lesion Analysis and Diagnosis with Mask-RCNN.

K. He, G. Gkioxari, P. Dollar, dan R. B. Girshick. 2017. ‘“Mask R-CNN,”’.

Shaoqing Ren, Kaiming He, Ross Girshick, dan Jian Sun. 2016. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks.

Yinghan Xu. 2018. Faster R-CNN (object detection) implemented by Keras for custom data from Google’s Open Images Dataset V4.