

PEMBEZAAN LIPOMA DAN TUMOR LIPOMATOUS ATIPIKAL (ALT) MENGUNAKAN NNU-NET BAGI PENEMBERENGAN DAN PEMBELAJARAN MESIN BAGI PENGELASAN

¹Hamzah Sahirul Amri, ¹Shahnorbanun Sahran

¹Fakulti Tekonologi & Sains Maklumat

43600 Universiti Kebangsaan Malaysia

Abstrak

Pembezaan lipoma dan tumor lipomatous atipikal (ALT) adalah satu proses yang mencabar dan memerlukan biopsi untuk keputusan yang lebih tepat. Bagi membantu diagnosis, pendekatan radiomik telah dicadangkan menggunakan pembelajaran mesin (ML) dan pembelajaran dalam (DL). Kajian ini bertujuan untuk mengesahkan model radiomik dalam mengelas lipoma dan ALT dalam penggambaran MRI dari Hospital Canselor Tuanku Muhriz (HCTM) dan menambah sistem penemberengan automatik. Pengelasan akan dilakukan oleh modul Workflow for Optimal Radiomics (WORC), manakala penemberengan akan dibuat menggunakan model nnU-Net. Data pesakit MRI HCTM akan dikumpul dari tahun 2018 sehingga kini dalam format DICOM sebagai set data latihan dan ujian. Penemberengan setiap imej akan dilakukan secara automatik dan pengelasan akan menggunakan ciri radiomik dari objek yang telah dibahagikan dari gambar asal. WORC akan memastikan model ML yang digunakan adalah optimal mengikut ciri radiomik setiap kes. Penyelidikan yang dicadangkan ini bermatlamat untuk menyederhanakan proses diagnosis, mengurangkan subjektiviti dan menyumbang kepada peningkatan pengetahuan bidang osteologi dan teknologi DL dan ML yang berpotensi membuka peluang dalam aplikasi klinikal dan medikal.

Kata Kunci: Radiomik, Pengelasan, Penemberengan, Lipoma, ALT

Abstract

The differentiation of lipoma and atypical lipomatous tumors (ALTs) is a challenging process and requires a biopsy for more accurate results. To aid diagnosis, a radiomic approach has been proposed using machine learning (ML) and deep learning (DL). This study aims to validate the radiomic model in classifying lipoma and ALT in MRI imaging from Hospital Chancellor Tuanku Muhriz (HCTM) and adding an automatic segmentation system. Classification will be done by the Workflow for Optimal Radiomics (WORC) module, while segmentation will be done using the nnU-Net model. HCTM MRI

patient data will be collected from 2018 until now in DICOM format as a training and test set data. The segmentation of each image will be done automatically and the classification will use the radiomic features of the objects that have been segmented from the original image. WORC will ensure that the ML model used is optimal according to the radiomic characteristics of each case. This proposed research aims to simplify the diagnosis process, reduce subjectivity and contribute to the increase of knowledge in the field of osteology and DL and ML technology that has the potential to open opportunities in clinical and medical applications.

Kata Kunci: Radiomics, Classification, Segmentation, Lipoma, ALT

1.0 PENGENALAN

Dalam osteologi rawatan perubatan, tumor tisu lembut lipomatous adalah neo plasm yang sangat biasa berpunca daripada sel lemak. Tumor ini dibahagikan kepada beberapa subkumpulan, tetapi kebanyakannya adalah jinak dan dirujuk sebagai lipoma, manakala tumor malignan yang jarang ditemui dirujuk sebagai liposarcomas (Jebastin et al. 2020). Dalam amalan, alat Pengimejan Resonans Magnetik (MRI) boleh membezakan lipoma dan gred tinggi dengan mudah (Knebel et al. 2017, Brisson et al. 2013). Malangnya, beberapa subjenis liposarkoma gred rendah yang dipanggil tumor lipomatous atipikal (ALT) yang mewakili kira-kira 40 hingga 45 peratus liposarkoma mempunyai ciri MRI yang bertindih dan sangat serupa dengan lipoma (Knebel et al. 2017, Brisson et al. 2013, Leporq et al. 2020, Fletcher et al. 2002). Diagnosis pembezaan antara lipoma dan ALT adalah penting untuk strategi terapeutik. Dalam kes lipoma, pembedahan marginal dilakukan jika lipoma memberikan ketidakselesaan atau kesakitan kepada pesakit, manakala liposarcoma memerlukan potongan yang luas (Jebastin et al. 2020, Knebel et al. 2017). Walau bagaimanapun, terdapat keperluan perubatan untuk teknik bukan invasif memandangkan sifat biopsi yang invasif, mahal dan memakan masa. Tambahan pula, kebanyakan biopsi ini boleh dielakkan kerana tumor mesenchymal benign melebihi bilangan liposarcoma dengan faktor sekurang-kurangnya 100.

Bidang penyelidikan yang agak baru - radiomik, adalah sebahagian daripada analisis pengimejan perubatan untuk kanser (Fletcher et al. 2002, Gillies et al. 2016). Ia melibatkan penggunaan deskriptor matematik untuk mengubah imej perubatan kepada data kuantitatif berdimensi tinggi yang boleh dilombong (dirujuk sebagai radiomik). Kemudian, radiomik digunakan untuk melatih algoritma pembelajaran mesin (ML) untuk meramalkan hasil seperti antara keganasan atau kejinakan (Aerts et al. 2014). Kemajuan terkini dalam pembelajaran

mesin dan radiomik menawarkan jalan yang menjanjikan untuk meningkatkan ketepatan diagnostik tanpa memerlukan prosedur invasif. Dengan mengekstrak ciri kuantitatif daripada imej MRI praoperasi — seperti saiz tumor, bentuk, tekstur dan jarak dari tumor ke tulang sekeliling — model pembelajaran mesin boleh dilatih untuk membezakan antara lipoma dan ALT dengan berkesan. Model ini telah menunjukkan pencapaian kepekaan dan kekhususan yang tinggi, setanding atau mengatasi beberapa penilaian kualitatif tradisional oleh ahli radiologi (Narumol et al. 2023, Salvatore et al. 2023, Ieva et al. 2020). Sebagai contoh, pengelas pembelajaran mesin yang menggunakan ciri radiomik telah menunjukkan kawasan di bawah lengkung (AUC) 0.88 dalam membezakan jenis tumor ini (Narumol et al. 2023), menunjukkan potensi yang kukuh untuk alat diagnostik bukan invasif yang boleh menyelaraskan keputusan klinikal -membuat dan mengoptimumkan pendekatan rawatan. Kajian ini menggabungkan radiomik MRI dengan analisis ML untuk meramalkan keganasan pada pesakit dengan tumor tisu lembut lipomatous, dari segi klasifikasi antara lipoma dan ALT.

Membezakan antara lipoma jinak dan ALT memberikan cabaran besar dalam analisis perubatan. Salah satu ciptaan terbaik teknologi, isyarat MRI, masih bergelut untuk membantu dalam menggambarkan dengan tepat perbezaan antara jenis lipoma. Dalam konteks osteologi, ALT memerlukan pendekatan yang sangat meluas dalam rawatan kerana berbanding dengan lipoma jinak, ia adalah tumor mesenchymal yang agresif dan boleh bermetastasis kepada bentuk yang lebih malignan (Susan et al. 2023). Disebabkan penampilan mereka yang serupa, ciri-ciri MRI yang bertindih boleh merumitkan diagnosis, selalunya menuntut biopsi untuk penilaian yang lebih muktamad.

Tujuan pembangunan sistem adalah untuk mengesahkan keupayaan pembelajaran mesin untuk membezakan lipoma benign dan ALT berdasarkan ciri-ciri radiomik MRI serta menentukan keberkesanan Pembelajaran Mesin dalam mengelas tumor lipoma dan Pembelajaran Dalam dalam penemberengan tumor. Skop kajian ini ialah pembangunan model tertumpu kepada klasifikasi osteologi hanya dua jenis lipoma, iaitu lipoma benign dan ALT. Oleh itu, sistem ini dibangunkan sebagai sokongan tambahan kepada ahli radiologi bagi membantu membuat diagnosis bagi tumor lipoma melalui penggunaan Pembelajaran Mesin dan Pembelajaran Dalam serta menyediakan antara muka depan yang ringkas.

2.0 KAJIAN LITERATUR

2.1 Membezakan Lipoma dan ALT menggunakan ML

Pada dasarnya, algoritma Pembelajaran Mesin ialah algoritma statistik yang boleh belajar daripada data, biasanya data latihan, dan menggeneralisasikan kepada data baharu dan tidak kelihatan, biasanya data ujian, tanpa diprogramkan secara eksplisit (John et al. 1996). Dalam masalah klasifikasi, ML cemerlang dalam mencari corak dan menghasilkan ramalan yang menjanjikan, dan walaupun model itu tidak sesuai, terdapat banyak algoritma ML, seperti Regresi SVM dan LASSO yang menggunakan pendekatan yang berbeza, dan digabungkan dengan teknik seperti penalaan hiperparameter, memastikan keputusan yang tertakluk kepada penambahbaikan.

Apabila ML digunakan untuk masalah ini, kajian lepas menggunakan algoritma LASSO untuk mengklasifikasikan tumor. Dalam penemuan mereka, model tersebut berjaya mempunyai ketepatan 76%, dengan sensitiviti 70% dan kekhususan 81% (Sarah et al. 2023). Berbanding dengan ahli radiologi, 3 penduduk radiologi mencapai ketepatan 60 hingga 70%, sensitiviti 55 hingga 80% dan kekhususan 63 hingga 77%, manakala pakar radiologi mencapai ketepatan 90%, kepekaan 96% dan kekhususan 87%, semuanya dalam set data yang sama (Sarah et al. 2023). Penyelidikan lain menggunakan tiga pendekatan untuk set data, dengan imej berwajaran T1, FS-T2WI dan gabungan kedua-duanya (Yaozhou et al. 2022). Dengan set data T1, model itu mempunyai Kawasan Di Bawah Lengkung (AUC) sebanyak 0.952, AUC sebanyak 0.944 dalam FS-T2WI dan AUC sebanyak 0.968 apabila menggunakan kedua-duanya, manakala ahli radiologi mencapai 0.893 AUC (Yaozhou et al. 2022). Berdasarkan kertas kerja ini, algoritma ML boleh terbukti berguna untuk senario, malah mengatasi prestasi pakar radiologi biasa, walaupun mereka masih kalah dengan menghadiri ahli radiologi, versi mereka yang lebih pakar. Terdapat juga kajian yang menggunakan pendekatan pemilihan model ML automatik menggunakan modul Workflow for Optimal Radiomics (WORC) yang mempunyai algoritma untuk menetapkan model pembelajaran mesin yang sesuai mengikut ciri radiomik yang diekstrak juga dalam modul tersebut (Spaanderman et al. 2024).

2.2 Membandingkan ML and DL untuk membezakan Lipoma dan ALT

Tidak seperti pendekatan Pembelajaran Mesin, Pembelajaran Dalam memerlukan set data yang lebih besar dan lebih luas, di samping kuasa pengkomputeran yang lebih tinggi. Perbezaan utama antara algoritma Pembelajaran Dalam dan Pembelajaran Mesin ialah ML bermaksud komputer belajar daripada data menggunakan algoritma untuk melaksanakan tugas tanpa diprogramkan secara eksplisit, manakala DL menggunakan struktur kompleks algoritma yang dimodelkan pada otak manusia, seperti Rangkaian Neural Konvolusi (CNN) (Arne 2024).

Kerumitan yang lebih tinggi ini menghasilkan respons yang lebih fleksibel dan sangat tepat, walaupun pada kos yang jauh lebih tinggi berbanding menggunakan model ML.

Berbanding dengan model ML, penyelidikan lepas menguji algoritma DL ResNet50 terhadap model SVM ML, disimpulkan dengan ketepatan 92.11% dan 86.84%, kepekaan 95% dan 95% dan kekhususan masing-masing 88.89% dan 77.78% (Yuhan et al. 2022). Dari segi perbandingan yang jelas, kertas membandingkan dua pendekatan — Pembelajaran Mesin daripada ciri radiomik dengan dan tanpa pembetulan kelompok, dan Pembelajaran Mendalam daripada imej (Guillaume et al. 2022). Makalah ini juga menguji algoritma dalam setiap kategori antara satu sama lain, di mana mereka membandingkan Regresi Logistik (LR), Mesin Vektor Sokongan (SVM), Hutan Rawak (RF) dan Gradient Boosting (GB) untuk pendekatan ML (Guillaume et al. 2022). Model terbaik yang terhasil untuk kategori DL ialah model ResNet50, dengan AUC 0.87 ± 0.11 , manakala dalam kategori ML model terbaik menghasilkan AUC 0.83 ± 0.12 dengan pembetulan kesan kelompok dan 0.99 ± 0.02 tanpa (Guillaume et al. 2022). Dalam kedua-dua kertas kerja, model DL menunjukkan prestasi yang lebih tinggi berbanding rakan ML. Walau bagaimanapun, peningkatan ini perlu diperhatikan dengan peningkatan kos yang ketara juga, disebabkan sifat model Pembelajaran Dalam yang memerlukan saiz set data yang melampau untuk menjadi lebih baik atau paling teruk prestasinya pada tahap yang sama seperti model Pembelajaran Mesin.


2.3 Penemberengan Automatik (Automatic Segmentation) bagi Tumor

Dalam radiomik, langkah yang sangat penting ialah pemilihan bingkai atau segmen untuk digunakan daripada arca digital 3d. Dalam pengimejan MRI, Penemberengan imej perubatan kepada jenis tisu yang berbeza adalah penting untuk banyak kemajuan dalam penyelidikan ortopedik; walau bagaimanapun, teknik penemberengan secara manual boleh memakan masa dan kos (Lauren et al. 2022). Penyelidikan lepas telah membangunkan teknik penemberengan separa automatik pada imbasan MRI yang sama dua kali semasa menguji kebolehlungan imbasan dan imbasan semula, membandingkannya dengan penemberengan MRI manual dan cara ia dilakukan apabila digunakan pada kedua-dua imej MRI dan CT (Lauren et al. 2022). Secara kritikal, pendekatan separa automatik ini mengurangkan masa penemberengan sebanyak kira-kira 75%, yang menjanjikan untuk meningkatkan daya pemprosesan penyelidikan dan berpotensi untuk digunakan dalam menjana data latihan untuk algoritma DL (Lauren et al. 2022).

Dalam proses penemberengan automatik, penyelidikan lepas membandingkan Base Learners dengan rangka kerja SuperLearner pada pengoptimum Adam dan 75 zaman (Chin-Chieh et al. 2023). Untuk model DL mereka, mereka menggunakan TensorFlow untuk U-Net dan memperhatikan seni bina U-Net pada CPU NVIDIA Tesla V100 32GB berprestasi tinggi (Chin-Chieh et al. 2023). Algoritma DL SuperLearner menunjukkan prestasi yang unggul berbanding dengan Base Learners individu (Chin-Chieh et al. 2023). Sebuah pendekatan U-Net yang lebih fleksibel iaitu nnU-Net juga digunakan dalam kajian lain (Spaanderman et al. 2024). nnU-Net berbeza dari U-Net dalam aspek fleksibiliti dan keupayaannya untuk mengadaptasi dan menukar parameter mengikut data yang digunakan (Spaanderman et al. 2024). Terdapat penyelidikan lain yang menggunakan algoritma Fast-Grow-Cut dalam Slicer 3D dengan pembetulan manual untuk penyelidikan mereka, yang menghasilkan ROC-AUC sebanyak 0.926 untuk model ML mereka (Ieva et al. 2020).

3.0 METODOLOGI

Metodologi yang digunakan dalam pembangunan projek ini ialah Agile yang menggunakan pembangunan dan pengujian berterusan sepanjang hayat pembangunan perisian projek. Metodologi ini dipilih kerana ia merangkumi proses dinamik yang membenarkan perubahan walaupun telah jauh dalam proses pembangunan. Metodologi ini sesuai dengan projek ini yang memerlukan pembangunan nnU-Net dan WORC yang lebih fleksibel.



Rajah 1: Model Agile

3.1 Fasa Perancangan

Tujuan fasa ini ialah untuk menetapkan keperluan pengguna bagi aplikasi yang akan dibina. Kenal pasti jenis imej yang sesuai untuk latihan dan isu daripada lelaran sebelumnya, jika ada.

Sediakan prasyarat untuk latihan model dan ujian pada peranti yang berfungsi dan tentukan set data yang sesuai dengan kelas dan kenal pasti sebarang langkah prapemprosesan yang diperlukan untuk peningkatan imej. Dapatkan maklum balas daripada pakar untuk mengetahui keperluan output.

3.2 Fasa Reka Bentuk

Fasa ini untuk menentukan reka bentuk penampilan aplikasi dan selok-belok model. Hiperparameter yang penting untuk prestasi model dan perkara yang perlu ada dalam langkah prapemprosesan dikaji dan dikenalpasti. Data yang dikumpulkan dihuraikan dengan teliti, mengenalpasti jenis imej yang akan diterima ke dalam set data dan format ideal data input dan output. Had perkakasan mengikut tetapan nnU-Net dan WORC dikaji dan memastikan latihan dan ujian model dilakukan dengan mudah.

Kedua-dua model nnU-Net dan WORC menggunakan parameter yang telah ditentukan, termasuk bilangan epoch dan kadar pembelajaran untuk mencapai prestasi terbaik. Data yang telah diproses dimuatkan ke dalam struktur fail mengikut spesifikasi nnU-Net untuk melatih penemberengan tumor. Data seterusnya dimuatkan ke dalam modul WORC selepas diekstrak ciri radiomik menggunakan PyRadiomics bagi mencari model terbaik untuk mengelas lipoma. Model nnU-Net menggunakan struktur model U-Net, dimana ia disesuaikan untuk gambar MRI mengikut jenis gambar. Bagi projek ini, nnU-Net menggunakan tetapan gambar “3d_fullres”. Modul WORC menggunakan 5 jenis model Pembelajaran Mesin dan mencari model terbaik melalui teknik *cross-validation*.

Secara keseluruhan, penekanan diberikan kepada ketepatan dan kecekapan pemprosesan imej dengan memastikan bahawa model dapat membezakan tisu-tisu dalam imej MRI. Integrasi nnU-Net dan model terbaik WORC adalah kunci utama kepada keberkesanan sistem dalam pengelasan dan penemberengan yang lebih tepat dan dapat diaplikasikan dalam analisis radiomik.

3.3 Fasa Pembangunan

Pengekodan model dilakukan melalui persediaan latihan model konvensional. Setiap langkah perlu jelas dan ringkas tentang perkara yang dilakukannya, termasuk pemprosesan imej, pembersihan data, pengekstrakan ciri dan pemangkasan. Penggunaan pakej yang sesuai dan

aplikasi yang sesuai dilakukan dengan teliti. Pembangunan antara muka yang ringkas dilakukan menggunakan modul Flask dalam Python dan Papaya dalam JavaScript.

3.4 Fasa Pengujian

Fasa pengujian melibatkan penilaian prestasi model nnU-Net dan WORC menggunakan set data XNAT. Program dijalankan dengan penalaan hiperparameter berubah untuk hasil yang lebih tepat. Metrik penilaian seperti ketepatan, AUC, *Sensitivity*, *Specificity* dan Skor-f1 digunakan untuk menilai keberkesanan model. Hasil pengelasan oleh semua model dibandingkan sesama sendiri. Pengujian ini memastikan model dapat memberikan hasil yang konsisten dan tepat bagi set latihan dan pengujian. Jadual 1 dan 2 menunjukkan perbandingan metrik model-model WORC.

No.	Model Terbaik	Ketepatan	
		Latihan	Pengujian
1	SVM Poly	0.8158	0.4348
2	SVM Linear	0.7890	0.4348
3	SVM RBF	0.7612	0.7391

Jadual 1: Ketepatan model WORC

No.	Model Terbaik	Metrik			
		AUC	Sensitivity	Specificity	Skor-F1
1	SVM Poly	0.3939	0.7500	0.0909	0.3667
2	SVM Linear	0.4394	0.4167	0.4545	0.4348
3	SVM RBF	0.8333	0.6667	0.8182	0.7381

Jadual 2: Metrik penilaian model WORC

No.	Model	Parameter				
		Kernel	C	Coefficient	Degree	Gamma
1	SVM	Poly	556.479	0.8158	0.7391	0.04508
2	SVM	Linear	526553.904	0.7890	0.8000	0.00503

3	SVM	RBF	114348.130	0.7612	0.6667	0.00035
---	-----	-----	------------	--------	--------	---------

Jadual 3: Parameter model WORC

Jadual 3 menunjukkan parameter untuk model terbaik dari eksperimen WORC, iaitu model SVM dengan kernel RBF, nilai C sebanyak 114348.130, *coefficient* bernilai 0.7612, *degree* bernilai 0.6667 dan *gamma* bernilai 0.00035.

Namun, kekurangan data dan masa telah menghalang pengujian model nnU-Net yang sesuai. Oleh itu, model Pembelajaran Dalam tidak dapat dinilai bagi bab penemberengan sistem.


3.5 Fasa Pelepasan

Lakukan pengelasan menggunakan set data penilaian. Maklumbalas daripada individu dalam bidang yang berkaitan diambil untuk memberi gambaran tentang betapa bergunanya model itu dalam senario sebenar. Rekodkan pelbagai penilaian untuk mendapatkan ketepatan, ketepatan dan ingatan semula model yang lebih realistik, yang boleh menentukan masalah atau kunci ke arah menyelesaikan tugas.

4.0 HASIL

Keputusan kajian menunjukkan bahawa modul WORC berjaya mendapatkan model Pembelajaran Mesin yang mempunyai prestasi yang baik dalam pengelasan lipoma dari imej MRI. Model ini menunjukkan ketepatan yang tinggi dalam mengelaskan lipoma dan ALT mengikut metrik-metrik matriks kekeliruan dan AUC. Perbincangan hasil kajian menekankan kelebihan nnU-Net dan Pembelajaran Mesin dalam menyediakan analisis imej yang lebih cepat dan kurang subjektif berbanding penilaian normal. Ia juga berpotensi untuk meningkatkan ketepatan diagnosis penyakit yang lebih tepat.

Apabila memasuki sistem, pengguna akan disambut dengan skrin Log Masuk. Untuk memulakan sesi penemberengan dan pengelasan imej MRI, pengguna perlu log masuk.




Rajah 2: Halaman log masuk

Seterusnya, apabila pengguna telah log masuk, mereka akan dibawa ke antara muka untuk pengguna memuat naik gambar tumor dalam format imej MRI. Format gambar boleh dalam bentuk DICOM atau NIFTI. Antara muka tersebut adalah seperti dalam Rajah 3.



Rajah 3: Halaman utama selepas log masuk

Pengguna perlu menekan barisan “Choose File” untuk memilih gambar untuk dimuat naik. Selepas itu, butang “Submit” perlu ditekan untuk memuatnaik gambar dan melihat hasil penemberengan dan pengelasan.



Rajah 4: Halaman utama selepas mengelas imej

Rajah 4 menunjukkan hasil keputusan imej MRI yang telah melalui proses penemberengan dan pengelasan menggunakan ciri radiomik. Hasil penemberengan ditunjukkan melalui kawasan putih yang cerah dan ditutup oleh barisan berwarna jingga seperti yang ditunjukkan dalam Rajah 4.

Cadangan Penambahbaikan

Selepas menjalankan kajian yang menyeluruh, cadangan untuk menambahbaik sistem ini pada masa hadapan ialah melatih model dengan set data yang lebih tinggi. Sistem ini tidak dapat menggunakan set data yang lebih besar yang sepatutnya datang dari set data HUKM disebabkan kekangan masa. Seterusnya, menggunakan teknik augmentasi data seperti putaran, pembesaran, dan pengubahan warna untuk meningkatkan variasi dalam data latihan dan mengurangkan masalah ketidakseimbangan kelas (Shorten et.al 2019). Ini juga dapat mengatasi masalah kekurangan data. Selain itu, penalaan hyperparameter yang lebih komprehensif untuk mencari kombinasi parameter yang optimum juga akan membantu (NIPS 2011).

5.0 KESIMPULAN

Projek ini bertujuan untuk membangunkan dan menilai model nnU-Net bagi tugas penemberengan dan model-model ML melalui WORC bagi pengelasan tumbuhan lemak dalam imej MRI. Modul WORC ini ialah tulang belakang untuk mengekstrak ciri dan mempunyai cabang khusus untuk pengelasan. Ujian terhadap model ini menggunakan set data XNAT menunjukkan bahawa model ML mampu mencapai nilai AUC yang baik, menunjukkan ketepatan penemberengan yang bagus. Seterusnya, metrik lain seperti accuracy, sensitivity,

specificity, dan skor-F1 menunjukkan bahawa model ini dapat mengelas lipoma dan ALT dengan baik dan berkesan.

Model nnU-Net dan WORC menunjukkan beberapa kekuatan utama, termasuk ketepatan yang baik dalam penemberengan dan pengelasan. Ini membuktikan kemampuan model untuk membezakan antara imej lipoma dan ALT dengan berkesan. Namun, kekuatan model nnU-Net tidak dapat dikira dengan berkesan, oleh itu ini menunjukkan kekangan kajian pada masa ini. Walaubagaimanapun, pembuktian nnU-Net yang berkesan dalam kajian lepas (Spaanderman et al. 2024) masih memberi potensi bagi sistem ini. Penggunaan model radiomik hasil kajian WORC sebagai tulang belakang pengelasan dengan struktur yang menguji pelbagai model ML membolehkan pengesanan model yang terbaik dalam setiap situasi.

Kajian ini telah berjaya mencapai objektif utamanya. Pertama, model radiomik WORC yang dihasilkan telah menunjukkan ketepatan yang tinggi dalam pengelasan lipoma dan ALT. Kedua, model nnU-Net berjaya dibangunkan untuk penemberengan tumor, namun ia tidak dapat diuji lebih lanjut disebabkan kekurangan data dan pakar radiologi. Ketiga, walaupun prestasi kedua-dua model cukup memberangsangkan, terdapat banyak lagi penambahbaikan yang boleh dilakukan seperti menaikkan saiz set data, menular tetapan-tetapan model dan menambah variasi ke set data. Akhirnya, kekangan teknikal seperti keperluan pengkomputeran yang tinggi untuk melatih model juga menjadi cabaran yang perlu diatasi. Walaupun prestasi sistem cekap, masih banyak lagi perkara yang boleh dilakukan untuk meningkatkan ketepatan model-model yang diguna kerana telah didapati bahawa ia berpotensi untuk digunakan dalam aktiviti penemberengan dan pengelasan tisu radiologi.

6.0 PENGHARGAAN

Penulis kajian ini ingin mengucapkan setinggi-tinggi penghargaan ditujukan kepada penyelia Prof. Madya Dr. Shahnorbanun binti Sahran yang telah banyak membimbing dan memberi pandangan serta tunjuk ajar sepanjang menjalankan projek ini.

Seterusnya, penulis ingin mengucapkan ribuan terima kasih kepada semua pihak yang telah banyak membantu dalam memberikan tunjuk ajar dan semangat semasa mengalami kesukaran dalam menyiapkan projek tahun akhir ini. Segala bantuan yang telah dihulurkan amatlah dihargai kerana tanpa bantuan mereka, projek ini tidak dapat dilaksanakan dengan baik sekalipun. Semoga Tuhan merahmati dan memberikan balasan yang terbaik.

7.0 RUJUKAN

- Advances in Neural Information Processing Systems 24 (NIPS 2011). 25th Annual Conference on Neural Information Processing Systems 2011.
- Aerts, H.J.W.L., Velazquez, E.R., Leijenaar, R.T.H., et al. 2014. Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. *Nature Commun* 5:1–9.
- Anton, E.P., Ruijsink, B., Sidhu, B.S., et al. 2022. AI-enabled Assessment of Cardiac Systolic and Diastolic Function from Echocardiography. *ResearchGate*.
- Arne, W. 2024. Deep Learning vs. Machine Learning – What’s The Difference? *Levity*. 30 September: 1.
- Brisson, M., Kashima, T. Delaney, D., et al. 2013. MRI characteristics of lipoma and atypical lipomatous tumor/well-differentiated liposarcoma: retrospective comparison with histology and MDM2 gene amplification. *Skeletal Radiol* 42:635–647
- Chih-Chieh, L., Yasser, G.A., S, P.Y., Francesco, A., et al. 2023. AI-Based Automated Lipomatous Tumor Segmentation in MR Images: Ensemble Solution to Heterogeneous Data. *J Digit Imaging*. 36:1049
- Dyourri, A., & Walia, A.S., 2024. How to Build a Flask Python Web Application from Scratch. *DigitalOcean*.
- Fletcher, C., Unni, K. & Mertens, F. 2002. Pathology and genetics of tumours of soft tissue and bone. *International Agency for Research on Cancer*.
- Gillies, R.J., Kinahan, P.E. & Hricak, H., 2016. Radiomics: Images are more than pictures, they are data. *Radiology* 278:563–577.
- Guillaume, F., Reina, A., Hugo, B., et al., 2022. Prediction of lipomatous soft tissue malignancy on MRI: comparison between machine learning applied to radiomics and deep learning. *Eur Radio Exp*. 8(6):41.
- Ieva, M., Jeremy, H., Simon B., et al. 2020. Radiomics and Machine Learning Differentiate Soft-Tissue Lipoma and Liposarcoma Better than Musculoskeletal Radiologists. *Sarcoma*.
- Isensee, F., Jaeger, P. F., Kohl, S. A., et al. 2020. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods* 18(2):203-211.
- Jebastin, J.A.S., Perry, K.D. Chitale, D.A., et al. 2020. Atypical lipomatous tumor/well-differentiated liposarcoma with features mimicking spindle cell lipoma. *Int J of Surg* 28:336–340.
- Jonathan, G.R., Ciarán, M. L. & Saurabh, J., 2020. Improving the accuracy of medical diagnosis with causal machine learning. *Nat Commun*. 11:2108.
- Knebel, C., Lenze, U. Pohlig, F., et al. 2017. Prognostic factors and outcome of liposarcoma patients: a retrospective evaluation over 15 years. *BMC Cancer* 410:1471–2407

- Lauren, N.H., Brian, J.S., Charles, E.S., Brian, D.L., & Louis, E.D., 2022. Design and validation of a semi-automatic bone segmentation algorithm from MRI to improve research efficiency. *Scientific reports*. 12:7825.
- Leporq, B., Bouhamama, A., Pilleul, F., et al. 2020. MRI-based radiomics to predict lipomatous soft tissue tumors malignancy: a pilot study. *Cancer Imaging* 20:78.
- Nagano, S., Yokuchi, M., Setoguchi, T., et al. 2015. Differentiation of lipoma and atypical lipomatous tumor by a scoring system: implication of increased vascularity on pathogenesis of liposarcoma. *BMC Musculoskelet Disord*. 16:36.
- Narumol, S., Palanan, S., Nittaya, L., et al. 2023. Tumor-to-bone distance and radiomic features on MRI distinguish intramuscular lipomas from well-differentiated liposarcomas. *Journal of Orthop* 18:255.
- Raihan, M.J., Khan, M.A., Kee, S.H., & Nahid, A. (2023). Detection of the chronic kidney disease using XGBoost classifier and explaining the influence of the attributes on the model using SHAP. *Scientific Reports*, 13(1).
- Ruiz-Gonzalez, R., Gomez-Gil, J., Gomez-Gil, F.J., et al. 2014. An SVM-Based Classifier for Estimating the State of Various Rotating Components in Agro-Industrial Machinery with a Vibration Signal Acquired from a Single Point on the Machine Chassis. *Sensors (Basel)*, 14(11):201713-35.
- Salvatore, G., Matteo, I., Renato, C., et al. 2023. MRI radiomics-based machine learning for classification of deep-seated lipoma and atypical lipomatous tumor of the extremities. *Radiol Med* 128:989-998.
- Sarah, C.F., Oscar, L., Diana, E.D., Verena, K.N.R., et al. 2023. Development and Evaluation of MR-Based Radiogenomic Models to Differentiate Atypical Lipomatous Tumors from Lipomas. *Cancers (Basel)*. 15:2150.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*. 6(1), 1-48.
- Spaanderman, D.J., Hakkesteegt, S.N., Hanff, D.F., et al. 2024. Multi-center external validation of an automated method segmenting and differentiating atypical lipomatous tumors from lipomas using radiomics and deep-learning on MRI. *eClinicalMedicine* 76.
- Starmans, M.P.A., van der Voort, S.R., Phil, T., et al. (2021). An automated machine learning framework to optimize radiomics model construction validated on twelve clinical applications. *arXiv*.
- Susan, P.D.O. & Michael, R.C. 2023. Atypical lipomatous tumor / well differentiated liposarcoma. *PathologyOutlines*.
- Talaviya, A., 2023. CRISP-DM framework: A foundational data mining process model. *Medium*.
- Vos, M., Starmans, M.P.A., Timbergen, M.J.M., et al., 2019. Radiomics approach to distinguish between well differentiated liposarcomas and lipomas on MRI. *Br J Surg*. 106(13):1800-1809

- Yazhou, T., Jingjing, C., Jingyi, Z., & Guoguang, F., 2022. Differentiation Between Lipomas and Atypical Lipomatous Tumors of the Extremities Using Radiomics. *J Magn Reson Imaging*. 56:1746.
- Yuhan, Y., Yin, Z., Chen, Z., & Xuelei, M., 2022. Novel computer aided diagnostic models on multimodality medical images to differentiate WDLPS from lipomas approached by deep learning methods. *Orphanet Journal of Rare Diseases*. 17:158.

Copyright@FTSM
UKM