

PEMBELAJARAN MENDALAM: PENGECEMAN TULISAN TANGAN LUAR TALIAN DENGAN MENGAJI JENIS MODEL DAN PENGOPTIMUM

¹Nor Badriyah Mat Said, ¹Afzan Adam

¹Fakulti Teknologi & Sains Maklumat
43600 Universiti Kebangsaan Malaysia

Abstrak

Tulisan tangan kekal sebagai medium komunikasi dan dokumentasi penting dalam pelbagai domain, terutamanya dalam sektor perubatan, pendidikan, perundangan dan pentadbiran. Walau bagaimanapun, peralihan daripada teks tulisan tangan luar talian kepada format digital memberikan pelbagai cabaran. Kepelbagaian dalam gaya penulisan dan pertindihan aksara menyumbang kepada kerumitan pengecaman tulisan tangan luar talian. Apabila transformasi digital semakin penting, membangunkan sistem yang berkesan untuk menukar kandungan tulisan tangan secara automatik kepada teks yang boleh diedit dan boleh dibaca mesin menjadi semakin penting. Sistem pengecaman tulisan tangan menggunakan pembelajaran mendalam telah menunjukkan hasil yang menjanjikan. Namun begitu, penyelidik telah mengenal pasti bahawa keberkesanan model sedemikian boleh berbeza-beza bergantung pada pilihan seni bina dan strategi pengoptimuman. Kajian ini meneroka keberkesanan tiga model pembelajaran mendalam iaitu CNN, LSTM dan CRNN untuk pengecaman tulisan tangan luar talian. Kajian ini memfokuskan kepada mengenal pasti model yang paling tepat berdasarkan penemuan daripada kajian sastera sedia ada. Setelah model yang paling sesuai dipilih, ia akan diuji lagi menggunakan tiga algoritma pengoptimuman berbeza iaitu Adam, RMSprop dan SGDM untuk menilai cara setiap pengoptimum mempengaruhi ketepatan model dan prestasi umum. Keputusan akhir menunjukkan bahawa CRNN dengan pengoptimum Adam mencapai ketepatan tertinggi pada 79.75% dengan menggunakan tujuh lapisan konvolusi dan tiga lapisan *Bidirectional* LSTM yang setiap satunya mempunyai bilangan unit sebanyak 512 unit.

Kata kunci: CRNN, LSTM, CNN, Adam, Pengecaman Tulisan Tangan

Abstract

Handwriting remains an important medium of communication and documentation in various domains, especially in the medical, educational, legal and administrative sectors. However, the transition from

offline handwritten text to digital formats presents various challenges. Diversity in writing styles and character overlaps contribute to the complexity of offline handwriting recognition. As digital transformation becomes increasingly important, developing an effective system to automatically convert handwritten content into editable and machine-readable text becomes increasingly important. Handwriting recognition systems using deep learning have shown promising results. However, researchers have identified that the effectiveness of such models can vary depending on the choice of architecture and optimization strategy. This study explores the effectiveness of three deep learning models, namely CNN, LSTM and CRNN for offline handwriting recognition. This study focuses on identifying the most accurate model based on findings from existing literature studies. Once the most appropriate model is selected, it will be further tested using three different optimization algorithms, namely Adam, RMSprop and SGDM, to evaluate how each optimizer affects the model accuracy and overall performance. The final results show that CRNN with Adam optimizer achieved the highest accuracy at 79.75% using seven convolutional layers and three Bidirectional LSTM layers, each with a unit count of 512 units.

1.0 PENGENALAN

Pengecaman tulisan tangan ialah proses di mana teks tulisan tangan ditukar secara automatik kepada format digital yang boleh difahami dan diproses oleh komputer. Teknologi ini memanfaatkan algoritma pembelajaran mesin dan Optical Character Recognition (OCR) untuk mengenali dan mentafsir aksara, perkataan dan juga keseluruhan ayat daripada imej atau input masa nyata, seperti menulis pada skrin sentuh. Setelah dikaji, terdapat dua jenis utama pengecaman tulisan tangan iaitu pengecaman tulisan tangan dalam talian dan luar talian (Kaur et al. 2023). Pengecaman dalam talian melibatkan tulisan tangan seperti yang ditulis pada peranti digital seperti tablet atau telefon pintar di mana sistem mengenali pergerakan pen atau stylus dalam masa nyata. Sebaliknya, pengecaman tulisan luar talian berkaitan dengan mengenali tulisan tangan daripada imej statik teks tulisan tangan seperti dokumen atau gambar yang diimbas.

Tulisan tangan masih digunakan secara meluas dalam banyak sektor seperti perubatan, pendidikan, perundangan dan pentadbiran. Menukar tulisan tangan kepada teks digital menjadikan ia lebih mudah untuk disimpan, diakses dan diambil semula. Contohnya, mendigitalkan rekod pesakit dalam penjagaan kesihatan meningkatkan kebolehcapaian dan mengurangkan ralat. Banyak kajian telah dibuat untuk pengecaman tulisan tangan tetapi pengecaman tulisan tangan merupakan tugas yang mencabar kerana kepelbagaian gaya

tulisan tangan dan kewujudan banyak aksara yang serupa (Khandokar et al. 2021). Peralihan daripada tulisan tangan luar talian kepada teks dan aksara digital kekal sebagai tugas yang mencabar kerana kepelbagaian gaya tulisan tangan, variasi aksara dan bunyi dalam dokumen tulisan tangan (Ullah et al. 2022). Walaupun kemajuan ketara telah dicapai dalam pengecaman tulisan tangan menggunakan pembelajaran mendalam, keberkesanan model rangkaian saraf yang diperoleh berbeza-beza bergantung pada jenis model dan seni binanya. Selain itu, walaupun teknologi pengecaman aksara tulisan tangan digunakan secara meluas dalam industri, ketepatan semasanya kekal kurang memuaskan, memberi kesan kepada prestasi dan kebolehgunaan keseluruhan (Saqib et al. 2022). Model rangkaian neural yang sama digunakan tetap akan memberi ketepatan yang tidak konsisten. Kajian ini akan membandingkan beberapa model algoritma pembelajaran mendalam seperti *Convolutional Neural Network* (CNN), *Long Short Term Memory* (LSTM), dan *Convolutional Recurrent Neural Network* (CRNN) berdasarkan kajian kesusasteraan untuk melihat model manakah yang paling sesuai digunakan. Kemudian, model terpilih diuji dengan beberapa pengoptimum seperti *Adam*, *RMSProp* dan *SGDM*. Kajian ini memfokuskan kepada tulisan tangan luar talian.

Objektif kajian ini adalah seperti berikut:

1. Untuk meneroka dan menilai seni bina rangkaian saraf yang berbeza iaitu CNN, LSTM dan LSTM berdasarkan kesusasteraan sedia ada bagi menentukan model paling tepat untuk mengendalikan gaya dan struktur tulisan tangan.
2. Untuk menguji model yang terpilih menggunakan pelbagai algoritma pengoptimuman seperti *Adam*, *RMSProp* dan *SGDM* bagi mengenal pasti pengoptimum yang paling berkesan untuk meningkatkan prestasi dan generalisasi model.

2.0 KAJIAN LITERATUR

Banyak pengkaji yang telah membuat penyelesaian bagi penukaran tulisan tangan kepada teks digital iaitu dengan membangunkan sistem pengecaman tulisan menggunakan pembelajaran mendalam. Membangunkan model ini adalah sukar kerana ia melibatkan pemahaman dalam pelbagai aspek dokumen tulisan tangan (Ullah et al. 2022).

Pembelajaran mendalam sangat dikenali pada masa kini dan membantu dalam meningkatkan prestasi pengecaman tulisan tangan (Kaur et al. 2023). Ia adalah sebahagian

daripada pembelajaran mesin yang dibangunkan pada asas rangkaian saraf tiruan. Dalam saraf tiruan, rangkaian nod berbeza digunakan yang dilatih oleh algoritma yang berbeza seperti otak manusia tetapi terdapat banyak perbezaan antara rangkaian saraf tiruan dan otak (Das et al. 2020). Terdapat banyak teknik pembelajaran mendalam yang boleh digunakan untuk membuat pengecaman tulisan tangan. Setelah menjalankan pencarian terhadap pengecaman tulisan tangan daripada sumber internet, banyak pengkaji menggunakan model pembelajaran mendalam seperti *Convolutional neural Network* (CNN), *Long Short Term Memory* (LSTM) dan *Covolution Recurrent Neural Network* (CRNN).

Bermula dengan kajian CNN terlebih dahulu, kajian oleh (Khandokar et al. 2021) menggunakan set data NIST mengaplikasikan dua lapisan konvolusi dengan diikuti dengan lapisan *max-pooling* setiap satu lapis. Pada akhir lapisan, model ditambah dengan dua lapisan bersambung penuh. Ketepatan yang diperoleh adalah 92.91%. Berbanding dengan kertas kerja oleh (Zin et al. 2021) menggunakan tiga lapisan konvolusi dan satu lapisan konvolusi penuh diikuti oleh lapisan *Max-Pooling* selepas setiap satu lapisan konvolusi. Model CNN ini mencapai ketepatan 98.7% untuk aksara individu dan 95.6% untuk perkataan penuh daripada set ujian 1,000 sampel. Sistem ini menyokong pelbagai jenis aksara, termasuk huruf besar dan huruf kecil, digit dan simbol asas matematik. Walaupun (Zin et al. 2021) mempunyai satu lapisan lebih daripada (Khandokar et al. 2021), namun ketepatan berubah jauh. Ini mungkin kerana, (Khandokar et al. 2021) tidak menggunakan sebarang pengoptimum di dalam seni binanya.


Seterusnya, bagi LSTM, (Nogra et al. 2019), telah membangunkan lima model LSTM berbeza telah diuji. Setiap satu dengan bilangan unit yang berbeza-beza dalam lapisan tersembunyi dan padat. Semua model menampilkan dua lapisan tersembunyi dan lapisan keluaran padat dengan 63 unit, sepadan dengan bilangan aksara Baybayin. Model berprestasi terbaik (Model B) mencapai ketepatan latihan sebanyak 95.6% dan ketepatan pengesahan sebanyak 92.9%. Model ini mempunyai 512 unit dalam lapisan tersembunyi pertama, 256 dalam lapisan tersembunyi kedua dan 128 dalam lapisan padat. Kajian lain (Das et al. 2020) menggunakan empat lapisan LSTM bagi mengkaji tulisan tangan Odia mencapai ketepatan 97.93%.

Beralih kepada kajian yang menggunakan *Convolution Recurrent Neural Network* (CRNN), seni bina ini adalah hibrid dimana menggabungkan CNN untuk mengekstrakan ciri

dan RNN. Seperti kajian (Idris et al. 2019), mereka menggunakan seni bina CRNN bagi pengesanan tulisan tangan menggunakan set data IAM . Tujuh lapisan konvolusi dan dua lapisan *Bidirectional* LSTM (Bi-LSTM) digunakan. Dalam kajian ini, lapisan bersambung penuh tidak digunakan. Model ini mencapai CER sebanyak 4.57% pada set data IAM. Ini bermakna, model dapat mengesan sebanyak 95.43% daripada 100%. Seterusnya, (Ackhar et al. 2019), membangunkan model CRNN bagi pengesanan tulisan tangan dalam sektor perubatan. Kajian ini menggunakan 13 lapisan konvolusi dan tiga lapisan Bi-LSTM. Terdapat sedikit perbezaan daripada (Idris et al. 2019), yang mengaplikasikan lapisan RNN terlebih dahulu sebelum lapisan konvolusi. (Ackhar et al. 2019), menggunakan lapisan konvolusi diikuti oleh lapisan RNN. Ketepatan yang diperoleh adalah 95% dimana tidak mempunyai perbezaan yang jauh dengan (Idris et al. 2019). Menggunakan lapisan konvolusi yang sangat banyak tetapi ketepatan tidak meningkat adalah satu perkara yang tidak bagus kerana menyebabkan model sangat kompleks.

3.0 METODOLOGI

Kajian ini menggunakan metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Terdapat enam fasa iaitu, pemahaman perniagaan, pemahaman data, penyediaan data, pemodelan, penilaian dan pembangunan. Rajah 1 menunjukkan model penuh CRISP-DM.



Rajah 1 Model CRISP-DM

3.1 Fasa Pemahaman Perniagaan

Fasa pemahaman perniagaan memberi tumpuan kepada mengenal pasti objektif dan keperluan pengesanan tulisan tangan. Matlamat utama adalah untuk meneroka model-model dan kaedah pengoptimum supaya sistem boleh mengesan teks tulisan tangan dengan tepat.

Selain itu, membolehkan pengguna memuat naik imej tulisan tangan dan memprosesnya menggunakan model pembelajaran mendalam yang terlatih. Setelah diproses, pengguna dapat melihat hasil pengecaman.

3.2 Fasa Pemahaman Data


Dalam fasa ini lebih menumpukan kepada penerokaan set data yang akan digunakan untuk melatih model pengecaman tulisan tangan. Kajian ini melibatkan pengecaman teks daripada tulisan tangan. Set data IAM dipilih untuk digunakan dalam kajian ini.

3.3 Fasa Penyediaan Data

Melibatkan mengubah data tulisan tangan mentah kepada format yang bersih dan boleh digunakan untuk melatih model pengecaman. Pra-pemprosesan mengambil input imej adalah untuk melaksanakan tugas pembersihan. Penyediaan data bermula dengan input imej akan ditukarkan kepada *grayscale*. Seterusnya, termasuk mengubah saiz semua imej tulisan tangan kepada saiz tetap untuk memastikan keserasian dengan rangkaian saraf. Kemudian, proses akan melibatkan normalisasi bagi nilai piksel. Itu adalah pra pemprosesan bagi kesemua model. Bagi set data IAM, ia akan dibahagikan kepada data latihan (70%) dan data ujian (30%).

3.4 Fasa Pemodelan

Model ini bermula dengan lima lapisan konvolusi. Lapisan ini bertanggungjawab untuk mengekstrak ciri hierarki daripada imej input seperti lengkung dan corak yang penting untuk mengenali aksara tulisan tangan. Selepas setiap operasi konvolusi, Penormalan kelompok digunakan untuk menormalkan peta ciri serta memastikan kestabilan dan penumpuan yang lebih pantas semasa latihan. Fungsi pengaktifan ReLU akan digunakan untuk memperkenalkan bukan lineariti dan membolehkan model mempelajari corak kompleks. Selain itu, lapisan *max-pooling* diselang-seli untuk mengurangkan dimensi ruang peta ciri sambil mengekalkan ciri yang paling terbaik. . Mengikuti lapisan konvolusi, seni bina merangkumi tiga lapisan *Bi-LSTM* dan setiap satu dengan 1024, 512 dan 64 unit. Lapisan ini menangkap kebergantungan temporal antara ciri ke hadapan dan ke belakang dalam jujukan. Output akhir daripada lapisan *Bi-LSTM* dihantar ke lapisan penyahkodan, di mana aksara diramalkan menggunakan fungsi kehilangan *Connectionist Temporal Classification* (CTC). Rajah 2 menunjukkan seni bina bagi model CRNN yang dipilih.



Rajah 2 Seni bina CRNN

3.5 Fasa Penilaian


Model pengecaman tulisan tangan yang terlatih diuji pada data yang tidak kelihatan untuk menilai keberkesannya. Objektif utama dalam pemprosesan model adalah untuk memastikan model itu digeneralisasikan dengan baik kepada gaya tulisan tangan baharu dan mengenali teks daripada pelbagai sampel dengan tepat. Ini adalah untuk mengelakkan masalah *underfitting* dan *overfitting*. Metrik penilaian seperti ketepatan dan *Word Error Rate* (WER) digunakan untuk mengukur prestasi model.

3.6 Fasa Pembangunan


Menyepadukan model pengecaman tulisan tangan terlatih ke dalam seni bina pelayan pelanggan. Pelayan bertanggungjawab untuk menjalankan model pembelajaran mendalam dan memproses sampel tulisan tangan yang dimuat naik manakala pelanggan menyediakan antara muka berasaskan web untuk pengguna. Reka bentuk pelayan pelanggan memastikan tugas intensif membolehkan sistem menyokong peranti dengan kuasa pemprosesan terhad. Penerapan juga melibatkan penyediaan tapak web di mana pengguna boleh memuat naik imej tulisan tangan serta melihat hasil pengecaman dan mengeksport atau menyimpan output secara pilihan. *Streamlit* digunakan sebagai rangka kerja untuk laman web. Rajah 3 hingga 6 merupakan antara muka bagi memuat naik imej, menukar imej tulisan tangan kepada teks, paparan output dan paparan pilihan eksport.




Rajah 3 Antara muka memuat naik imej



Rajah 4 Antara muka menukar imej tulisan tangan kepada teks



Rajah 5 Antara muka paparan output



Rajah 6 Antara muka paparan pilihan eksport

4.0 HASIL KEPUTUSAN

Untuk fasa ujian, pelbagai eksperimen telah dijalankan untuk menilai prestasi model pengecaman tulisan tangan menggunakan pengoptimum dan kadar pembelajaran yang berbeza. Tiga pengoptimum iaitu Adam, RMSprop dan SGDM telah diuji, masing-masing dengan kadar pembelajaran 0.00075, 0.001, 0.00125 dan 0.0015. Sebaliknya, kadar pembelajaran yang lebih tinggi boleh menyebabkan model bertumpu terlalu cepat, berpotensi melangkau penyelesaian optimum atau *overfit*. Eksperimen ini dijalankan selama 10 epoch untuk melihat kesan gabungan pengoptimuman dan kadar pembelajaran terhadap ketepatan model dan WER. Jadual 1 menunjukkan hasil keputusan.

Jadual 1 Hasil keputusan bagi pengoptimum yang berbeza dengan kadar pembelajaran berbeza

Pengoptimum	Kadar Pembelajaran	Latihan (WER)%	Latihan (ketepatan) %	Pengujian (ketepatan) %
Tiada	0.00075	0.00	0.00	0.00
	0.001	0.00	0.00	0.00
	0.00125	0.00	0.00	0.00
	0.0015	0.00	0.00	0.00
Adam	0.00075	26.25	73.75	73.94
	0.001	31.19	68.81	68.29
	0.00125	31.39	68.61	68.17
	0.0015	35.16	64.84	65.17
RmsProp	0.00075	26.48	73.16	73.31
	0.001	32.09	67.91	69.98
	0.00125	72.77	27.23	46.54
	0.0015	91.18	8.82	28.56
Sdgm	0.00075	0.00	0.00	0.00
	0.001	0.00	0.00	0.00
	0.00125	0.00	0.00	0.00
	0.0015	0.00	0.00	0.00

Model yang dilatih menggunakan pengoptimum Adam dengan kadar pembelajaran 0.00075 didapati mempunyai prestasi tertinggi selepas 10 epoch. Untuk menambah baik lagi keputusan, bilangan epoch latihan telah ditambah kepada 20, 30 dan 40 menggunakan konfigurasi yang sama. Jadual 2 menunjukkan perbezaan prestasi model antara 10 hingga 40 epoch.

Jadual 2 Perbezaan prestasi model antara 10 hingga 40 epoch

Bilangan Epoch	Ketepatan Ujian
10	73.94%
20	78.12%
30	79.29%
40	77.90

Prestasi yang dicapai kurang memuaskan dengan ketepatan tertinggi adalah 79.29%, eksperimen diteruskan dengan menguji pada bilangan lapisan konvolusi yang lain serta bilangan unit LSTM yang berbeza. Jadual 3 merupakan ketepatan yang diperoleh bagi bilangan lapisan konvolusi yang berbeza dan unit LSTM yang berbeza.

Jadual 3 Ketepatan bagi lapisan konvolusi yang berbeza dan bilangan unit LSTM yang berbeza

Lapisan Konvolusi	Unit LSTM	Ketepatan Pengujian
5	1024, 512, 64	73.94%
	1024, 1024, 1024	75.85%
	512, 512, 512	74.12%
7	1024, 512, 64	75.27%
	1024, 1024, 1024	74.96%
	512, 512, 512	77.35%

Ketepatan pengujian bagi model yang menggunakan tujuh lapisan konvolusi dengan setiap bilangan unit LSTM sebanyak 512 memperoleh ketepatan tertinggi. Jadi, model ini akan dilatih lagi sebanyak 20, 30 dan 40 epoch sehingga tertumpu. Jadual 4 merupakan keputusan bagi ketepatan pengujian model ini yang dilatih dengan bilangan epoch yang lain.

Jadual 4 Perbezaan prestasi model antara 10 hingga 40 epoch

Bilangan Epoch	Ketepatan Ujian
10	77.35%
20	79.75%
30	78.15%
40	79.21%

5.0 KESIMPULAN

Kesimpulannya, pembangunan sistem bermula dengan penyediaan dan prapemprosesan data imej tulisan tangan daripada dataset IAM. Ini diikuti dengan reka bentuk dan pelaksanaan model pembelajaran mendalam termasuk fasa latihan dan ujian. Model CRNN telah dipilih berdasarkan kajian literatur dan pelbagai teknik pengoptimuman telah digunakan untuk menilai kesannya terhadap prestasi. Selepas menguji tiga pengoptimum Adam, RMSprop, SGDM, Ketepatan tertinggi, 79.75% diperoleh bagi model CRNN dengan tujuh lapisan konvolusi dan tiga lapisan Bi-LSTM dengan setiap satunya mempunyai 512 unit. Sebaik sahaja model itu tertumpu, ia disepadukan ke dalam aplikasi berasaskan web menggunakan *Streamlit* yang menggabungkan kedua-dua komponen *front-end* dan *back-end*. Model terlatih dalam format .keras telah berjaya diintegrasikan di dalam web berasaskan rangka kerja *Streamlit*.

Semasa pembangunan projek ini, beberapa kekangan telah dihadapi. Satu kekangan utama ialah akses terhad kepada sumber pengkomputeran berprestasi tinggi, terutamanya GPU. Melatih model pembelajaran mendalam dengan set data yang besar seperti IAM memerlukan masa pemprosesan yang banyak dan disebabkan oleh had perkakasan, bilangan eksperimen dan gabungan penalaan terpaksa dikurangkan.

Cadangan pada masa hadapan adalah boleh menggunakan pembelajaran pemindahan pembelajaran dengan memperhalusi model yang telah dilatih pada set data yang besar. Selain itu, menggabungkan set data tulisan tangan tambahan daripada bahasa yang berbeza, alatan penulisan atau kumpulan demografi boleh meningkatkan keupayaan model untuk membuat generalisasi dan berprestasi baik pada tulisan tangan dunia sebenar.

6.0 PENGHARGAAN

Alhamdulillah, saya panjatkan rasa syukur ke hadrat Ilahi kerana dengan limpah kurnia dan izin-Nya, saya berjaya menyiapkan usulan projek ini dalam tempoh yang ditetapkan. Segala cabaran dan rintangan yang dihadapi sepanjang penyelidikan ini dapat diatasi dengan kesabaran dan keazaman.

Setinggi-tinggi penghargaan saya tujukan kepada penyelia saya, Dr. Afzan Adam, atas bimbingan dan tunjuk ajar, serta dorongan yang tidak pernah putus sepanjang pelaksanaan projek ini. Sokongan dan nasihat yang diberikan amat bermakna dalam memastikan kelancaran penyelidikan ini.

Akhir sekali, penghargaan khas buat keluarga, ibu bapa dan adik-beradik serta rakan-rakan yang sentiasa memberi dorongan, motivasi dan semangat sepanjang saya menempuh perjalanan akademik ini. Sokongan mereka amat berharga dalam memastikan kejayaan projek ini.

7.0 RUJUKAN

- Achkar, R., Ghayad, K., Haidar, R., Saleh, S. & Hajj, R.A. 2019. Medical Handwritten prescription Recognition using CRNN. *2019 International Conference on Computer, Information and Telecommunication Systems (CITS)*.
- Ahlawat, S., Choudhary, A., Nayyar, A., Singh, S. & Yoon, B. 2020. Improved handwritten digit recognition using convolutional neural networks (CNN). *Sensors* 20(12): 3344.
- Ahmad, N.F.H., Adam, A. & Nasrudin, M.F. 2023. Pengecaman Aksara Tulisan Tangan Menggunakan Pembelajaran Mendalam. <https://gaexcellence.com/jistm/article/view/2721>.
- Alwajih, F., Badr, E. & Abdou, S. 2022. Transformer-based models for Arabic online handwriting recognition. *International Journal of Advanced Computer Science and Applications* 13(5).
- B M Vinjit, Mohit Kumar Bhojak, Sujit Kumar, & Gitanjali Chalak. 2020. A Review on Handwritten Character Recognition Methods and Techniques. *IEEE Xplore*, hlm. 2020 International Conference on Communication and Signal Processing (ICCSP).
- Chen, F., Chen, N., Mao, H. & Hu, H. 2018. Assessing four Neural Networks on Handwritten Digit Recognition Dataset (MNIST). <https://arxiv.org/abs/1811.08278>.
- Donghee, S. 2021. The effects of explainability and causability on perception, trust, and acceptance: Implications for Explainable AI. *Elsevier*, hlm. College of Communication and Media Sciences, Zayed University.:
- Donghee, S., Bu, Z., & Frank A. Biocca. 2020. Beyond user experience: What constitutes algorithmic experiences? *International Journal of Information Management*.
- Idris, A.A. & Taha, D.B. 2022. Handwritten text recognition using CRNN. *8th International Conference on Contemporary Information Technology and Mathematics (ICCITM2022)*, Mosul University, Mosul-Iraq 9: 329–334.
- Jamshed Memon, Maira Sami, Rizwan Ahmed Khan, & Mueen Uddin. 2020. Handwritten Optical Character Recognition (OCR): A Comprehensive Systematic Literature Review (SLR). *ResearchGate*, hlm.
- Jin. 2023. Software development framework — iterative model - geek culture - medium. *Medium*. URL <https://medium.com/geekculture/software-development-framework-iterative-model-68584bfad773>
- Kaur, G. & Kumar, A. 2023. A study of Techniques and challenges in text recognition systems. *International Journal on Recent and Innovation Trends in Computing and Communication* 11(8): 342–356.

- Khandokar, I., Hasan, M., Ernawan, F., Islam, S. & Kabir, M.N. 2021. Handwritten character recognition using convolutional neural network. *Journal of Physics Conference Series* 1918(4): 042152.
- Manju Jose & Prakash Kumar. 2021. Offline cursive handwriting recognition using convolutional neural network. *Research Gate*, hlm. Journal of Xidian University.
- Nagender Aneja & Sandhya Aneja. 2018. Transfer Learning using CNN for Handwritten Devanagari Character Recognition. 2019 1st International Conference on Advances in Information Technology (ICAIT).
- Nogra, J.A., Romana, C.L.S. & Maravillas, E. 2019. LSTM Neural Networks for Baybáyin Handwriting recognition. *2019 IEEE 4th International Conference on Computer and Communication Systems (ICCCS)*: 62–66.
- Ribeiro, R., Pilastrri, A., Moura, C., Rodrigues, F., Rocha, R. & Cortez, P. 2020. Predicting the tear strength of woven fabrics via Automated Machine learning: an application of the CRISP-DM methodology. *In Proceedings of the 22nd International Conference on Enterprise Information Systems (ICEIS 2020)*: 548–555.
- Saleh Albahli1, Marriam Nawaz, Ali Javed, & Aun Irtaza. 2021. An improved faster-RCNN model for handwritten character recognition. *Arabian Journal for Science and Engineering*, hlm. King Fahd University of Petroleum & Minerals.
- Saqib, N., Haque, K.F., Yanambaka, V.P. & Abdelgawad, A. 2022. Convolutional-Neural-Network-Based Handwritten Character Recognition: An Approach with Massive Multisource Data. *Algorithms* 15(4): 129.
- Ullah, Z. & Jamjoom, M. 2022. An intelligent approach for Arabic handwritten letter recognition using convolutional neural network. *PeerJ Computer Science* 8: e995.
- Vellido, A. 2019. The importance of interpretability and visualization in machine learning for applications in medicine and health care. *Neural Computing and Applications* 32(24): 18069–18083.
- Zin, T.T., Thant, S., Pwint, M.Z. & Ogino, T. 2021. Handwritten character recognition on Android for basic education using convolutional neural network. *Electronics* 10(8): 904.

Nor Badriyah Mat Said (A195374)
 Ts. Dr. Afzan Adam
 Fakulti Teknologi & Sains Maklumat
 Universiti Kebangsaan Malaysia