

UNJUK KERJA REAL-TIME DATA LOGGER BERBASIS MODEL CONVOLUTIONAL-RECURRENT NEURAL NETWORK-CONNECTIONIST TEMPORAL CLASSIFICATION (CRNN-CTC) UNTUK PEREKAMAN DATA SEVEN SEGMENT DISPLAY

BIRGITA PUTRI GRANIA EFFENDI¹, BUDI ADIPERDANA², FERRY FAIZAL^{2,*}

¹Program Studi Fisika, FMIPA, Universitas Padjadjaran
Jl. Raya Bandung-Sumedang Km.21 Jatinangor, Sumedang, Jawa Barat 45363

²Departemen Fisika, FMIPA, Universitas Padjadjaran
Jl. Raya Bandung-Sumedang Km.21 Jatinangor, Sumedang, Jawa Barat 45363

*Corresponding author
Email: ferry.faizal@unpad.ac.id

Submitted: 12/02/2025

Accepted: 15/02/2025

Published: 06/08/2025

Abstrak. Umumnya alat ukur digital jenis lama atau beberapa alat ukur digital praktis menampilkan hasil pengukurannya dengan struktur seven segment display, tetapi tidak banyak yang dapat menyimpan data hasil pengukurannya secara otomatis. Keperluan pencatatan data ukur untuk pemantauan atau kebutuhan eksperimen memerlukan otomatisasi, terutama jika dilakukan dalam waktu sangat panjang karena pencatatan data manual meningkatkan probabilitas terjadinya kesalahan manusia dalam mencatat. Sementara itu, modifikasi pada alat ukur untuk menambahkan data logger terlalu rumit sehingga dibutuhkan sistem yang dapat mencatat data hasil pengukuran tanpa perlu mengubah sistem yang ada. Penelitian ini bertujuan untuk mengembangkan sistem pencatat data real-time berbasis pengenalan karakter optik (OCR) untuk *seven segment* display agar dapat mengenali barisan bilangan desimal yang tertera pada display dengan panjang karakter yang berbeda dengan menggunakan *Convolutional-Recurrent Neural Networks* (CRNN) dan algoritma *Connectionist Temporal Classification* (CTC). Metode yang dipilih menilik dari tantangan segmentasi dari penelitian-penelitian yang sudah dilakukan ketika diterapkan dalam kasus pengenalan bilangan desimal seperti pada penelitian ini. Hasil pengujian model dan eksperimen menunjukkan sistem yang dibuat dapat digunakan sebagai *data logger* tanpa memodifikasi alat ukur dengan kemampuan generalisasi dibuktikan melalui tingkat akurasi model dalam mengenali karakter-karakter bilangan desimal yang dievaluasi dengan *Character Error Rate* (CER) 3,6% serta data yang dicatat dari eksperimen sesuai dengan yang ditampilkan pada display.

Kata kunci: CRNN, CTC, OCR pada seven segment display, pencatat data desimal otomatis

Abstract. Old digital measuring instruments and several types of modern, practical devices commonly display measurement results using a seven-segment display. However, these instruments often lack built-in functionality for automatic data storage. In scenarios where continuous data logging is required-for example, during prolonged monitoring or experimental procedures-manual data recording becomes impractical and increases the likelihood of human error. On the other hand, hardware modifications to integrate a dedicated



This work is licensed under a CC Attribution 4.0 International License.

DOI: <https://doi.org/10.24198/jiif.v9i2.64116>

e-ISSN: 2549-7014

data logger are frequently complex and not always feasible. This study aims to develop a real-time data logging system based on Optical Character Recognition (OCR) that can read and record decimal numbers directly from seven-segment displays without altering the existing instrument. The proposed system is designed to recognize sequences of decimal digits of varying lengths using a Convolutional-Recurrent Neural Network (CRNN) combined with the Connectionist Temporal Classification (CTC) algorithm. This method was selected due to its suitability in overcoming the segmentation challenges observed in prior research on decimal number recognition tasks. Experimental results show that the developed system can function effectively as a data logger without requiring any modification to the measuring device. The model demonstrates strong generalization capabilities, as reflected by its low Character Error Rate (CER) of 3.6%. Additionally, the values recorded by the system during testing consistently matched the numbers shown on the seven-segment display, confirming its practical accuracy and reliability in real-world data logging applications.

Keywords: CRNN, CTC, OCR on seven segment display, automated decimal data logger

1. Pendahuluan

Menurut Metode pencatatan data dimulai dari pencatatan manual oleh manusia sampai dengan pencatatan otomatis yang melibatkan perangkat. Pengambilan data secara manual memiliki kekurangan berupa probabilitas terjadi kesalahan manusia dan memakan waktu, terutama jika pengukurannya dilakukan dalam waktu yang cukup panjang, kemudian pencatatan hasil pengukuran dipermudah dengan melibatkan *data logger* sehingga hasil pengukuran dapat langsung disimpan secara berkala. Sayangnya, *data logger* memerlukan mikrokontroler dan kabel penghubung dengan tingkat kerumitan bervariasi pada rangkaiannya tergantung data yang dicatat, seperti kasus *PV grid fault detection* [1], pemantauan temperatur tanah [2], dan pemantauan getaran bangunan [3].

Alat ukur digital yang beredar di pasaran maupun alat ukur yang sudah tua menggunakan *seven segment display* untuk menampilkan hasil pengukurannya sehingga diperlukan proses yang lebih rumit dalam memodifikasi perangkat untuk memiliki *data logger* otomatis. Bermodalkan kamera dan model, kesulitan ini dapat ditangani dengan OCR (*Optical Character Recognition*) untuk mencatat data hasil pengukuran. Sebelumnya, pengenalan karakter pada *seven segment display* sudah dikembangkan melalui metode segmentasi dengan algoritma Otsu dan *random forest* [[4], *thresholding dan template matching* [5], *cascade RCNN* [6], dan pemanfaatan *pre-trained model* [7], [8]. Sayangnya, segmentasi yang telah ada tidak selalu cocok untuk gambar yang terdistorsi akibat pencahayaan, *blur* atau *noise* yang mengakibatkan karakter sulit dipelajari model. Kekurangan lain pada penelitian-penelitian tersebut adalah tidak dapat membaca bilangan desimal yang ditampilkan pada *seven segment display*, panjang karakter yang dapat dibaca tidak fleksibel, dan belum diaplikasikan untuk *data logger* meskipun pencatatan hasil pengenalan karakternya sudah dilakukan [5]. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem pencatat data *real-time* berbasis pengenalan karakter untuk *seven segment display*.

Sistem yang dikembangkan dalam penelitian ini menerapkan algoritma deteksi objek dengan algoritma *computer vision* pendeteksi obyek *You Only Look Once* (YOLO) untuk mendeteksi daerah *display*, kemudian model pengenalan karakter yang dibentuk dengan *Convolution-Recurrent Neural Networks* (CRNN) untuk mengenali barisan bilangan desimal yang tertera pada *display*. Penerapan algoritma CTC (*Connectionist*


Temporal Classification) pada pelatihan model pengenalan karakter sehingga model dapat membaca panjang karakter yang berbeda, dan pencatatan pembacaan *seven segment display* dari model pengenalan karakter pada *file* Excel yang akan diuji coba kemampuannya dalam melakukan pencatatan data otomatis melalui eksperimen sederhana.

2. Metode Penelitian

Penelitian ini menggunakan dataset yang dikumpulkan dari *dataset open-source* [9], pengambilan gambar pada alat ukur digital menggunakan *smartphone*, dan gambar generator dengan diterapkannya proses augmentasi pada kumpulan gambar tersebut. Gambar yang dikumpulkan dianotasi dengan platform Roboflow untuk keperluan pelatihan *custom YOLOv8* yang dipilih karena ukuran yang ringan, cepat dan akurat [10]. Selain itu, gambar juga diberikan label berdasarkan angka desimal yang tertera pada gambar *seven segment display* untuk keperluan pelatihan model OCR berbasis arsitektur CRNN dan algoritma CTC. Hasil pelatihan model YOLOv8 dan model OCR diintegrasikan menjadi suatu sistem kemudian dilakukan eksperimen sederhana untuk menguji ketepatan sistem dalam melakukan pencatatan data otomatis.

Sistem yang dibuat memerlukan kamera dan laptop dengan *input* berupa video yang menunjukkan *seven segment display* pada alat ukur digital. Setelah itu, *input* diberikan pada model YOLOv8 untuk dilakukan deteksi daerah *seven segment display* pada alat ukur digital menghasilkan *bounding boxes* pada *frame* video. YOLO mengklasifikasikan objek pada gambar atau video dalam sekali pemrosesan sehingga lokasi dan kelas objek langsung diprediksi dalam satu tahap [10] sehingga dapat memproses dengan cepat. Hasil deteksi daerah *seven segment display* dipotong sesuai *bounding boxes* tersebut, kemudian diteruskan sebagai *input* ke model pengenalan karakter berbasis CRNN-CTC setelah mengalami proses *preprocessing*. *Convolutional Neural Networks* (CNN) menggunakan konsep konvolusi untuk mempelajari fitur-fitur penting dari suatu data [11] menggunakan perkalian konvolusi (*element-wise multiplication* diikuti penjumlahan dalam daerah lokal) antara matriks konvolusi dengan matriks data [12]. Sementara itu, RNN (*Recurrent Neural Networks*) digunakan untuk memperhatikan urutan dari setiap karakter sehingga dapat berubah menjadi suatu kata yang utuh dan dapat dibaca karena RNN dapat mempelajari hubungan sesaat untuk setiap karakter [13]. Arsitektur RNN yang digunakan adalah bidirectional LSTM (*Long-Short Term Memory*) yaitu LSTM yang mempelajari data dalam dua arah dengan adanya algoritma untuk mengatur banyaknya informasi yang akan disimpan di dalam memori dan banyaknya informasi yang akan dilupakan [14]. Algoritma CTC yang digunakan adalah CTC *loss* untuk menghitung *loss* dari *output* RNN dan CTC *decoder* yang memiliki label "*blank*" sehingga dapat digunakan untuk menandai posisi ketika tidak ada karakter yang terbaca [15].


Kombinasi RNN dengan algoritma CTC yang digunakan mengakibatkan pelatihan pengenalan karakter tidak membutuhkan segmentasi per karakter terlebih dahulu [16] sehingga model dapat mempelajari hubungan *input* dan *output* tanpa perlu melakukan segmentasi serta model seolah menerima data dengan panjang karakter yang sama dengan adanya CTC *decoder* [17] sehingga dapat mengatasi pembacaan panjang karakter yang berbeda. Setelah model pengenalan karakter berbasis CRNN-CTC melakukan pembacaan dan *decode* pembacaan, hasil pembacaan disimpan ke *file* Excel. Ilustrasi mengenai skema sistem yang dikembangkan ditunjukkan pada Gambar 1.



Gambar 1. Ilustrasi rancangan sistem pencatat data real-time dengan CRNN-CTC

Pelatihan model CRNN-CTC menggunakan *optimizer* Adam dengan *learning rate* sebesar 0,0021 dan struktur pada Gambar 3 dengan *input shape* berdimensi 200 x 100 piksel dengan satu *channel*. Pelatihan model menggunakan *batch size* 6 dan menerapkan *early stop* dengan *patience* sebesar 10 sehingga iterasi *epoch* berhenti ketika tidak terjadi penurunan *loss* yang signifikan pada 10 *epoch* berturut-turut dengan *epoch* maksimal adalah 100. Nilai seluruh parameter ini didapatkan melalui pelatihan berulang dengan nilai yang dipilih secara acak sampai didapatkan hasil paling optimal.

Untuk menguji sistem yang sudah dibuat, perlu dilakukan uji coba melalui eksperimen sederhana menggunakan kamera *smartphone* yang dihubungkan pada komputer berisi model. Eksperimen pembakaran zat mudah terbakar menjadi pilihan untuk menguji sistem pencatat data yang dikembangkan dengan pengaturan eksperimen seperti yang ditunjukkan pada Gambar 2 karena keperluan perubahan angka timbangan terus menerus sebelum daya pada timbangan mati akibat fitur *auto power-off*.




Gambar 2. Ilustrasi susunan eksperimen

Eksperimen ini melibatkan zat mudah terbakar, seperti aseton, etanol dan alkohol 95%. Sumbu bakar dibuat dari kapas yang dipintal menyerupai sumbu. Data pengukuran yang dicatat oleh sistem pencatat data dari eksperimen dibandingkan dengan bilangan

desimal yang tertera pada *display* alat ukur untuk mengetahui keakuratan sistem yang dibuat. Data yang didapatkan dari eksperimen dilakukan persiapan data dengan proses pembersihan data untuk diolah menggunakan metode regresi linear sehingga dapat dihitung laju pembakaran dari setiap zat cair yang digunakan.

3. Hasil dan Pembahasan

Model YOLOv8 digunakan untuk melakukan deteksi daerah barisan bilangan yang ditampilkan pada *seven segment display* dilatih menggunakan *dataset* yang terdiri dari 3336 gambar pada *train set*, 368 gambar pada *validation set*, dan 358 gambar pada *test set* setelah data yang dianotasikan sudah ditambahkan dengan hasil augmentasi data. Hasil pelatihan model *custom YOLOv8* untuk deteksi daerah *seven segment display* memiliki *precision* 0,994, *recall* 1, *mAP50* 0,99 dan *mAP50-95* bernilai 0,817. Dari nilai metrik evaluasi, model yang dibuat memiliki nilai *mAP50-95* yang tinggi menunjukkan bahwa model ini dapat melakukan deteksi daerah *seven segment display* yang baik.




Gambar 3. Struktur model CRNN-CTC

Model pengenalan karakter yang disusun dengan CRNN-CTC memiliki struktur seperti yang diilustrasikan pada Gambar 3. Input berupa matriks gambar dalam format *grayscale* dipelajari pola dasar masing-masing karakter melalui lapisan konvolusi 2 dimensi dan direduksi dimensinya dengan lapisan *max pooling* diikuti dengan *batch normalization* untuk menstabilkan distribusi data sehingga dapat membantu mencegah *overfitting* masing-masing sebanyak 6 lapisan. Proses ini menghasilkan peta fitur 2 dimensi yang kemudian menggunakan *reshape* diubah menjadi 1 dimensi dan lapisan konvolusi 1 dimensi untuk menangkap pola sekuensial sehingga dapat melanjutkan ke lapisan BiLSTM tanpa kehilangan hubungan spasial maupun sekuensial. Setelah itu, lapisan BiLSTM digunakan supaya model mempelajari lebih banyak konteks bentuk karakter sehingga dapat melakukan pengenalan karakter lebih baik. Algoritma CTC yang digunakan pada model ini berperan dalam penerapan label “*blank*” pada posisi yang tidak ada karakternya sehingga model dapat mempelajari panjang karakter yang bervariasi dan perhitungan *loss* yang tidak melibatkan posisi label “*blank*” dengan operasi logaritmik dari probabilitas yang dapat *collapse* menjadi *ground truth label*.

Pelatihan model ini memberikan hasil akhir training *loss* adalah 0,323 dan *validation loss* 0,697 yang dihitung menggunakan CTC *loss* dengan penurunan masing-masing *loss* ditunjukkan pada Gambar 4. Berdasarkan grafik yang ditunjukkan pada Gambar 4, penurunan masing-masing *loss* terlihat stabil ditunjukkan dengan kurva *training loss* dan *validation loss* yang turun dengan stabil tanpa adanya lonjakan/puncak ketidakstabilan. *Validation loss* menunjukkan sedikit fluktuasi dengan adanya puncak kecil di sekitar *epoch* 40, tetapi lonjakan ini tidak besar sehingga model ini

menunjukkan kemampuan generalisasi yang baik. Hasil evaluasi pelatihan dari model ini memiliki ketepatan prediksi pada *test set* sebesar 90,37% dengan jumlah benar 197 dari 218 gambar pada *test set* dan CER sebesar 3,6% kesalahan pada tingkat karakter. Selanjutnya, kelayakan dari hasil pelatihan sistem yang dikembangkan ini dapat diketahui pada uji coba melalui eksperimen sederhana.




Gambar 4. Grafik Training Loss dan Validation Loss Model CRNN-CTC terhadap Epoch yang dihitung dengan CTC Loss

Uji coba sistem pencatat data *real-time* berbasis CRNN-CTC dilakukan melalui eksperimen pembakaran pada aseton, etanol dan alkohol 95%. Dalam eksperimen pembakaran aseton, aseton yang digunakan adalah 10,2 gram dengan sumbu kapas 0,5 gram. Eksperimen pembakaran etanol menggunakan 13,2 gram etanol dengan sumbu kapas 0,8 gram. Sementara itu, eksperimen pembakaran alkohol 95% menggunakan 14 gram alkohol 95% dengan sumbu kapas 0,7 gram. Pembakaran dilakukan sampai dengan cairan dalam wadah habis. Massa terakhir yang terekam dari masing-masing pembakaran adalah 4,1 gram pada eksperimen aseton, 2,2 gram pada eksperimen etanol, dan 6,6 gram pada eksperimen alkohol 95%. Perbedaan hasil akhir dalam proses pembakaran terjadi karena perbedaan kondisi sumbu kapas yang tidak diatur banyaknya bagian yang tercelup dan perbedaan sifat fisis pada setiap zat cair. Perbedaan hasil akhir dalam proses pembakaran terjadi karena perbedaan kondisi sumbu kapas yang tidak diatur banyaknya bagian yang tercelup dan perbedaan sifat fisis pada setiap zat cair.



Gambar 5. Pengenalan Bilangan Pecahan Desimal yang dilakukan oleh Sistem Pencatat Data Real-time pada Eksperimen Pembakaran Alkohol 95%, Aseton dan Etanol

Hasil pencatatan data yang didapatkan dari eksperimen pembakaran untuk menguji sistem yang dikembangkan memiliki hasil yang baik ditunjukkan dengan pencatatan data dari perubahan massa zat yang berkurang dengan cepat karena proses pembakaran tercatat dengan baik setiap detiknya. Berdasarkan hasil pencatatan data selama eksperimen berlangsung, evaluasi pencatatan data yang dilakukan sistem ini dibandingkan dengan angka yang tertera pada *seven segment display* sudah sesuai seperti yang ditunjukkan pada Gambar 5. Berdasarkan *timestamp* yang tercatat, sistem merespons setiap detik dengan pemrosesan diatur untuk setiap *frame* video yang terbaca



Gambar 6. Plot Data Massa terhadap Waktu dari Sampel Etanol, Alkohol 95% dan Aseton. Perbedaan Kemiringan yang Signifikan pada Kurva antar-Sampel menunjukkan Perbedaan Laju Pembakaran

Laju pembakaran zat dapat dihitung menggunakan regresi linear dengan data dari eksperimen pembakaran yang sudah dirapikan. Hasil plot data dari setiap data ditunjukkan pada Gambar 6 dengan warna hijau untuk alkohol 95%, warna biru untuk aseton dan warna etanol untuk aseton. Laju pembakaran ditunjukkan dari kemiringan garis yang terbentuk setelah dilakukan regresi linear. Laju pembakaran alkohol 95% didapatkan 0,03 gram/detik dengan R2 (koefisien determinasi) adalah 0,99 dan RMSE (*Root Mean Square Error*) adalah 0,13 gram. Laju pembakaran etanol didapatkan 0,05 gram/detik dengan R2 adalah 0,99 dan RMSE adalah 0,09 gram. Sementara itu, laju pembakaran aseton didapatkan 0,02 gram/detik dengan R2 (koefisien determinasi) bernilai 0,99 dan RMSE adalah 0,18 gram. Koefisien determinasi yang mendekati angka satu menunjukkan bahwa kurva yang dihasilkan dari regresi linear dapat mewakili titik-titik data dengan baik, sedangkan RMSE yang rendah menunjukkan tingkat kesalahan rata-rata yang terjadi antara titik data dengan hasil regresi cukup rendah. Kedua hal ini menunjukkan bahwa laju pembakaran masing-masing zat yang dihitung dengan metode regresi linear telah sesuai dengan keadaan eksperimen pembakaran.

Perbedaan kemiringan garis pada masing-masing zat yang digunakan terjadi karena perbedaan sifat fisis dan struktur kimianya. Dalam alkohol 95%, ada kandungan air sebanyak 5% dan etanol 95%. Kandungan air dalam alkohol 95% dapat meningkatkan suhu minimal yang diperlukan agar uap bahan bakar dapat menyala ketika ada sumber api (*flash point*) sehingga peningkatan kandungan air berakibat peningkatan *flash point* karena sifat fisis air yang memiliki titik uap lebih tinggi dibandingkan alkohol dan sulit

terbakar mengakibatkan air menyerap panas sehingga mengurangi jumlah uap bahan bakar yang tersedia untuk pembakaran mengakibatkan kebutuhan suhu yang lebih tinggi untuk terbakar [18], [19].

Dalam kasus aseton dan etanol, titik uap aseton adalah 56°C dan titik uap etanol adalah 78°C. Aseton lebih cepat menguap dilihat dari titik uapnya yang rendah sehingga aseton dapat mengalami penguapan sebelum terbakar sepenuhnya dan mengakibatkan pembakaran yang lebih lambat dibandingkan etanol. Sementara itu, etanol dapat terbakar lebih cepat karena lebih mudah bercampur dengan udara dan mengalami pembakaran yang lebih stabil. Hal ini juga dibuktikan dengan struktur kimia dari aseton (C_3H_6O) dan etanol (C_2H_6O) yang menunjukkan bahwa aseton memiliki struktur lebih kompleks dibandingkan etanol sehingga terbakar lebih lambat [20]. Dalam hal ini, kemurnian aseton yang rendah juga berpengaruh terhadap lambatnya pembakaran pada eksperimen

4. Kesimpulan

Sistem pencatat data real-time menggabungkan model custom YOLOv8 dengan mAP50 99% serta model CRNN-CTC dengan akurasi 90,37% dan CER 3,6%. Hasil pencatatan data dari eksperimen menggunakan sistem yang dikembangkan menunjukkan kesesuaian terhadap bilangan desimal yang tertera pada display alat ukur sehingga catatan data tersebut valid untuk digunakan. Sistem ini juga dapat mengatasi pembacaan data bilangan dengan panjang karakter yang berbeda. Pemanfaatan pengenalan karakter berbasis CRNN-CTC sebagai data logger dapat menjadi salah satu alternatif terutama jika pengukuran dilakukan dalam jangka panjang dan alat ukur yang digunakan adalah alat-alat komersial yang tidak memiliki fitur data logger.

Ucapan Terimakasih

Penelitian ini didanai dengan Hibah Riset Internal Unpad Nomor 1959/UN6.3.1/PT.00/2021. Penulis mengucapkan terima kasih kepada saudara Anda Suhandata atas bantuannya selama penelitian ini dilakukan.

Daftar Pustaka

1. R. Samkria et al., "Automatic PV Grid Fault Detection System with IoT and LabVIEW as Data Logger," *Comput. Mater. Contin.*, vol. 69, no. 2, pp. 1709–1723, 2021, doi: 10.32604/cmc.2021.018525.
2. G. N. Santiago and I. Ciampitti, "Multiple channels, low-cost, and dual data storage data logger for building a soil temperature network," *HardwareX*, vol. 20, no. September, p. e00582, 2024, doi: 10.1016/j.ohx.2024.e00582.
3. W. K. Ao, A. Pavic, B. Kurent, and F. Perez, "Novel FRF-based fast modal testing of multi-storey CLT building in operation using wirelessly synchronised data loggers," *J. Sound Vib.*, vol. 548, no. July 2022, 2023, doi: 10.1016/j.jsv.2023.117551.
4. V. N. Shenoy and O. O. Aalami, "Utilizing Smartphone-Based Machine Learning in Medical Monitor Data Collection: Seven Segment Digit Recognition," *AMIA ... Annu. Symp. proceedings. AMIA Symp.*, vol. 2017, pp. 1564–1570, 2017.
5. A. R. Syafeeza, N. A. Hamid, Y. C. Wong, M. F. Ramli, and Z. M. Noh, "Smart Data Recognition System for Seven Segment," vol. 4, no. 2, 2020.

6. U. Suttapakti, T. Titijaroonroj, W. Nunsong, and D. Kakanopas, "Seven Segment Display Detection and Recognition via Deep Learning Technique," 19th Int. Conf. Electr. Eng. Comput. Telecommun. Inf. Technol. ECTI-CON 2022, pp. 1–4, 2022, doi: 10.1109/ECTI-CON54298.2022.9795620.
7. L. M. Low, F. H. Mohd Salleh, Y. F. Law, and N. Z. Zakaria, "Detecting and recognizing seven segment digits using a deep learning approach," ITM Web Conf., vol. 63, p. 01007, 2024, doi: 10.1051/itmconf/20246301007.
8. K. Kanagarathinam and K. Sekar, "Text detection and recognition in raw image dataset of seven segment digital energy meter display," Energy Reports, vol. 5, pp. 842–852, Nov. 2019, doi: 10.1016/j.egyr.2019.07.004.
9. SachalZADI, "Seven-Segment-OCR." Accessed: Mar. 07, 2025. [Online]. Available: <https://github.com/SachalZADI/Seven-Segment-OCR/tree/master/Datasets>
10. Ultralytics, "YOLOv8 - Ultralytics YOLO Docs," 2022. [Online]. Available: <https://docs.ultralytics.com/models/yolov8/>
11. J. Ravi, "Handwritten alphabet classification in Tamil language using convolution neural network," Int. J. Cogn. Comput. Eng., vol. 5, no. March, pp. 132–139, 2024, doi: 10.1016/j.ijcce.2024.03.001.
12. M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," Computation, vol. 11, no. 3, 2023, doi: 10.3390/computation11030052
13. P. N., K. R., K. A., and V. Kakani, "A Bidirectional LSTM approach for written script auto evaluation using keywords-based pattern matching," Nat. Lang. Process. J., vol. 5, no. September, p. 100033, 2023, doi: 10.1016/j.nlp.2023.100033.
14. M. M. Misgar, F. Mushtaq, S. S. Khurana, and M. Kumar, "Recognition of offline handwritten Urdu characters using RNN and LSTM models Content courtesy of Springer Nature , terms of use apply . Rights reserved . Content courtesy of Springer Nature , terms of use apply . Rights reserved .," pp. 2053–2076, 2023.
15. W. J. L. Adams and D. L. Saaty, "CTC: CTC end2end," 2006.
16. N. Toiganbayeva et al., "KOHTD: Kazakh offline handwritten text dataset," Signal Process. Image Commun., vol. 108, no. June, p. 116827, 2022, doi: 10.1016/j.image.2022.116827.
17. Z. Chen, F. Yin, X. Y. Zhang, Q. Yang, and C. L. Liu, "MuLTReNets: Multilingual text recognition networks for simultaneous script identification and handwriting recognition," Pattern Recognit., vol. 108, 2020, doi: 10.1016/j.patcog.2020.107555.
18. I. A. Ibadurrohman, N. Hamidi, L. Yuliati, Winarto, and M. Mikami, "The impact of ethanol addition on the droplet combustion mechanism of saturated and unsaturated fatty acid/fatty acid methyl ester molecules," Fuel, vol. 334, no. P1, p. 126731, 2023, doi: 10.1016/j.fuel.2022.126731.
19. J. Martinka, P. Rantuch, and I. Wachter, "Impact of water content on energy potential and combustion characteristics of methanol and ethanol fuels," Energies, vol. 12, no. 18, 2019, doi: 10.3390/en12183491.
20. Y. Liu, W. Liu, H. Liao, W. Zhou, and C. Xu, "An experimental and kinetic modelling study on laminar premixed flame characteristics of ethanol/acetone mixtures," Energies, vol. 14, no. 20, pp. 1–18, 2021, doi: 10.3390/en14206713.