

---

# PENGEMBANGAN VERIFIKASI INFORMASI CEK BANK DENGAN MENGGUNAKAN CNN-XGBOOST IMAGE CLASSIFICATION UNTUK VERIFIKASI TANDA TANGAN DAN PENGENALAN TULISAN TANGAN

Kevin Saputra Utomo<sup>1,\*</sup>, Yefta Christian<sup>2</sup> Andik Yulianto<sup>3</sup>

<sup>1,2,3</sup> Universitas International Batam, Fakultas Ilmu Komputer, Program Sistem Informasi, Jl. Gajah Mada, Tiban Indah Kota Batam 29426 INDONESIA

---

## Abstrak

Sistem bank menjadi lebih maju di mana banyak orang yang sekarang bahkan tidak memegang uang tunai dan melakukan transaksi melalui aplikasi atau transfer online. Namun, ada beberapa transaksi bank yang ketinggalan jaman, seperti cek bank tertulis. Verifikasi dan kliring cek bank tertulis membutuhkan tenaga kerja yang sangat besar. Oleh karena itu, ada berbagai penelitian yang dilakukan untuk membuat transaksi cek bank menjadi lebih efisien, salah satunya adalah penggunaan machine learning. Penelitian ini dilakukan dengan tujuan mengetahui akurasi CNN-XGBoost untuk verifikasi tanda tangan dan rekognisi angka dan huruf. Untuk pengembangan penelitian ini, sebuah simulasi verifikasi dan pengecekan informasi cek bank akan dilakukan dengan model CNN-XGBoost. Dataset yang dipakai untuk pelatihan model di penelitian ini adalah IDRBT bank cheque dataset, EMNIST Digit, dan EMNIST Letter. Dataset akan di preprocess menggunakan beberapa cara seperti menghilangkan background, grayscale, padding, pixel normalize, histogram equalization, gaussian blur, dan canny edge detection. Dari penelitian didapatkan hasil akurasi model untuk verifikasi tanda tangan sebesar 97.06%, untuk rekognisi huruf 98.76%, dan rekognisi angka 99.57%. Model tidak dapat digunakan untuk sepenuhnya menggantikan tenaga kerja manusia dalam kliring cek bank tertulis. Ini karena risiko kesalahan dalam transfer keuangan sangat berbahaya, kesalahan dalam transfer dapat menyebabkan uang yang dikirim jauh berbeda dari yang tertera di cek. CNN-XGBoost masih berguna untuk membantu ekstraksi informasi untuk membantu mengurangi tenaga kerja yang dibutuhkan.

## Kata Kunci:

CNN, XGBoost, Verifikasi tanda tangan, Pengenalan tulisan tangan, Cek bank

---

## Abstract

The bank system is becoming more advanced where many people are now not even holding cash and making transactions through apps or online transfers. However, there are some outdated bank transactions, such as written bank cheques. Verification and clearing of written bank cheques requires a huge amount of manpower. Therefore, there are various studies conducted to make bank cheque transactions more efficient, one of which is the use of machine learning. This study was conducted with the aim of determining the accuracy of CNN-XGBoost for signature verification and handwriting recognition of numbers and letters. For the development of this research, a simulation for verification and checking of bank cheque information will be carried out with the CNN-XGBoost model. The datasets used for model training in this research are IDRBT bank cheque datasets, EMNIST Digit, and EMNIST Letter. Datasets will be preprocessed using several methods such as removing background, grayscale, padding, pixel normalization, histogram equalization, gaussian blur, and canny edge detection. From the research conducted, the accuracy of the model for signature verification is 97.06%, for letter recognition 98.76%, and number recognition 99.57%. The model cannot be used to completely replace human labor in written bank cheque clearing. This is because the risk of errors in financial transfers is very dangerous, errors in transfers can cause the money sent to be much different from the stated amount. CNN-XGBoost is still useful for aiding information extraction to help reduce the labor required.

## Keywords:

CNN, XGBoost, Signature verification, handwriting recognition, Bank Cheque

---

\*Korespondensi

E-mail: 2131146.kevin@uib.edu

## 1. PENDAHULUAN

Sistem bank menjadi lebih maju di mana banyak orang yang bahkan tidak memegang uang tunai dan melakukan transaksi melalui aplikasi atau transfer online. Metode ini telah meningkatkan efisiensi transaksi keuangan, sehingga memudahkan orang untuk mengelola keuangan mereka dan melakukan transaksi dari mana saja dan kapan saja. Upaya untuk mengembangkan bank digital telah berkontribusi dalam meningkatkan kualitas dan layanan pelanggan, pengurangan biaya bisnis, dan memberi prioritas kepada jasa bank yang penting (Sikira, 2021). Namun, ada beberapa transaksi bank yang belum dihilangkan, seperti cek bank tertulis. Meskipun sebagian besar transaksi telah di digitalisasi, cek bank sudah ketinggalan zaman dan membutuhkan perbaikan dalam proses penggunaannya. Cek tertulis biasa masih digunakan oleh orang tua dan orang-orang yang tidak terbiasa dengan teknologi. Cek ini juga digunakan oleh orang-orang yang tidak mempercayai transaksi digital. Sebagian besar bank mencoba memperbaiki proses ini, itulah sebabnya sistem trunkasi cek dibuat.

Cara cek bank diproses adalah dengan menyetorkan cek ke bank penarik, kemudian bank akan meneruskannya ke lembaga kliring, lembaga kliring akan memverifikasi cek dan mengirimkannya ke bank pembayar. Kemudian bank pembayar akan memverifikasinya sekali lagi dengan database mereka, jika tidak ada kesalahan maka bank pembayar akan mengirimkan uang ke bank penarik sesuai dengan jumlah yang tertera di cek. Jika ada kesalahan, seperti rekening pembayar tidak memiliki cukup dana, maka cek akan ditolak dan akan dikirim ke lembaga kliring lagi, kemudian ke bank penarik untuk dikembalikan ke penarik sebagai transaksi yang gagal. Sebelum sistem pemotongan cek diimplementasikan, proses-proses tersebut dilakukan dengan mengirimkan cek fisik ke masing-masing bank dan lembaga kliring, serta semua proses verifikasi dilakukan secara manual oleh teller bank. Sistem trunkasi cek menghilangkan proses pengiriman cek secara fisik dari bank penarik ke lembaga kliring pusat dan bank pembayar. Hal ini dilakukan dengan mendigitalkan cek fisik menjadi bentuk elektronik untuk dikirimkan ke bank pembayar. Dengan diperkenalkannya sistem ini di beberapa negara, proses kliring cek bank telah berkurang hingga hanya membutuhkan waktu tiga hari untuk kliring transaksi bank berbeda dan satu hari untuk transaksi di bank yang sama.

Karena jumlah cek yang ditangani setiap hari sangat banyak, tenaga kerja yang dibutuhkan untuk memverifikasi cek bank juga sangat besar. Oleh karena itu, ada berbagai penelitian yang dilakukan untuk membuat transaksi cek bank menjadi lebih efisien, salah satunya adalah penggunaan machine learning. Penggunaan machine learning juga tidak harus menggantikan teller bank dalam verifikasi cek tertulis. Machine learning juga dapat digunakan untuk membantu sebagian tugas dari teller bank. Dengan banyaknya data yang harus dicek untuk validasi dan kliring sebuah cek, beberapa tugas yang dilakukan dapat diotomatiskan untuk membuat tenaga kerja yang dibutuhkan berkurang. Penelitian yang telah dilakukan adalah penggunaan verifikasi tanda tangan dan teks untuk membantu transaksi. Verifikasi tanda tangan digunakan agar verifikasi dapat mengecek apakah tanda tangan cek berbeda jauh dengan tanda tangan yang dituju dalam database, atau perbedaannya sangat sedikit. Jika akurasi rendah, cek akan ditolak, jika tidak jelas maka cek akan dikirim untuk verifikasi manual. Pengenalan tulisan tangan digunakan untuk memeriksa data yang telah ditulis di cek, kemudian secara otomatis akan dimasukkan ke dalam database dengan sedikit campur tangan manusia, sehingga mengurangi beban kerja dalam jumlah yang sangat besar. Berbagai penelitian telah dilakukan dengan model yang berbeda, model yang telah diuji coba adalah CNN, SVM, SIFT, R-CNN, dan OCR (Abdo et al., 2023; Agrawal et al., 2020; Jha et al., 2019). Dengan adanya model-model machine learning yang telah diteliti, masih banyak lagi model-model machine learning yang dapat digunakan dan diteliti untuk melihat apakah akurasi atau penggunaan model tersebut jauh lebih baik.

CNN-XGBoost (ConvXGB) digunakan sebagai model machine learning yang akan diuji dalam penelitian ini. ConvXGB merupakan model machine learning yang menggabungkan performa Convolutional Neural Network dan Extreme Gradient Boost. Algoritma ConvXGB menggabungkan kekuatan dari CNN dan XGBoost untuk mengurangi kompleksitas model dan jumlah parameter yang diperlukan untuk prediksi. Hal ini dicapai dengan menggunakan CNN tanpa lapisan akhir yang terhubung sepenuhnya dan menggunakannya sebagai lapisan ekstraksi fitur untuk penggabungan dan konvolusi, sementara menggunakan XGBoost sebagai lapisan klasifikasi akhir. Hal ini mengurangi risiko overfitting dan membuat model menjadi lebih efisien dan lebih mudah untuk dilatih (Thongsuwan et al., 2021). Alasan digunakannya ConvXGB dalam penelitian ini adalah karena model machine learning ini belum pernah diuji untuk verifikasi cek bank, meskipun berbagai penelitian telah menunjukkan bahwa penggabungan model CNN dan model XGB terkadang dapat memberikan hasil yang lebih akurat dibandingkan dengan masing-masing model secara individual (Babayomi et al., 2023; Ren et al., 2017). Model ConvXGB juga telah digunakan dalam sebuah penelitian untuk mengenali karakter Ethiopia dan memiliki akurasi yang lebih tinggi dibandingkan

dengan lapisan CNN konvensional yang terhubung penuh (Weldegebriel et al., 2020). Hal ini menunjukkan bahwa ConvXGB mungkin memiliki potensi untuk akurasi yang lebih tinggi dalam verifikasi cek bank dibandingkan dengan penelitian sebelumnya.

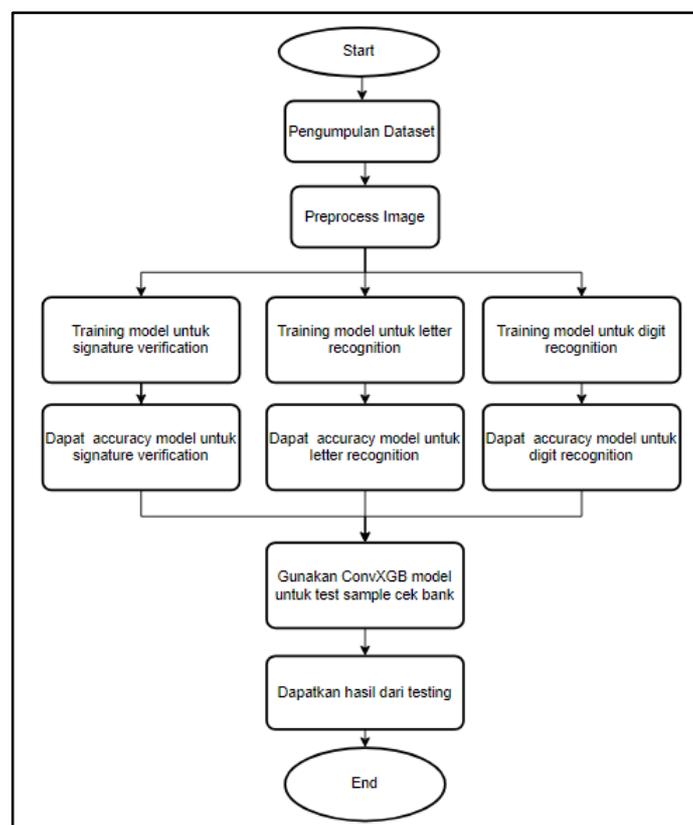
Kesimpulannya, penelitian ini akan dilakukan dengan tujuan untuk mengetahui akurasi ConvXGB untuk verifikasi tanda tangan dan rekognisi angka dan huruf. Untuk pengembangan penelitian ini, sebuah simulasi verifikasi dan pengecekan informasi cek bank akan dilakukan dengan model ConvXGB. Simulasi ini berguna untuk melihat sebenarnya masalah nyata apa yang dapat terjadi dalam kegunaan machine learning untuk menggantikan tenaga kerja proses kliring cek bank. Dengan penelitian ini, maka akan diharapkan penelitian berkontribusi untuk mengetahui apakah ConvXGB model dapat digunakan lebih baik untuk proses verifikasi cek bank dibandingkan model lainnya. Dengan demikian kecepatan dan permasalahan menggunakan model tersebut dapat terlihat dengan lebih baik. Jika pada saat testing sample cek bank terlihat bahwa model tidak dapat berfungsi dengan baik, maka akan dibahas apa cara alternatif atau kegunaan lain dalam penggunaan model ini dalam kliring cek bank. Dengan singkat penelitian ini dibuat untuk verifikasi tanda tangan, membaca tulisan huruf, dan membaca tulisan angka menggunakan model ConvXGB untuk kliring cek bank.

## 2. METODE

Pada bagian metodologi ini akan dijelaskan dataset yang digunakan dalam pembuatan model prediksi dan desain layer model. Metode preprocessing untuk dataset dan pola kerja keseluruhan dari penelitian juga akan dijelaskan.

### A. Flowchart Penelitian

Dari gambar 1 dapat dilihat proses kerja yang akan dilakukan untuk penelitian ini. Di dalam penelitian ini model convXGB akan dibagi menjadi tiga. Ini dibuat agar pada saat model membaca bagian angka seperti account number dan tanggal tidak terjadi kesalahan dalam membaca dan rekognisi angka sebagai huruf. Dengan cara dibagi menjadi tiga maka pada saat testing sample kemungkinan eror akan menjadi lebih kecil. Proses pengumpulan dataset, preprocess image, dan training model akan dijelaskan lebih lanjut section metode berikutnya.



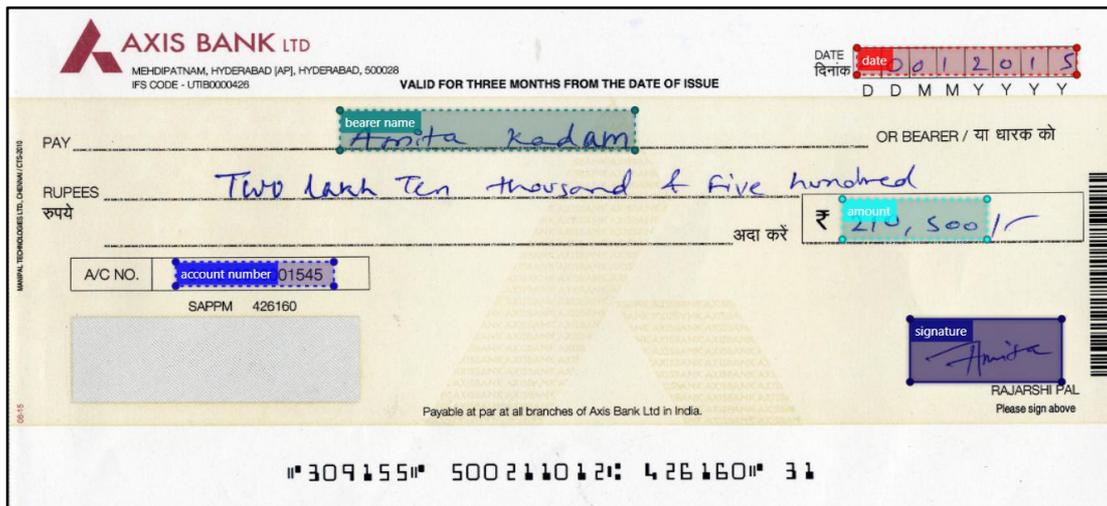
Gambar 1. Flowchart penelitian

## B. Dataset

Dataset yang digunakan untuk penelitian ini adalah dataset IDRBT Cek. IDRBT cek dataset merupakan dataset yang terdiri dari 112 gambar cek dari empat bank di India dan bank check segmentation database lainnya dari Kaggle (Dansena et al., 2017; Khan, 2021). Dataset masih berguna untuk penelitian ini karena tulisan yang dipakai masih menggunakan alfabet romawi yang dipakai oleh negara Indonesia dan negara yang menggunakan bahasa Inggris. Dataset ini didapatkan di internet dan akan diproses lebih lanjut untuk dapat digunakan dalam penelitian.

Proses yang dilakukan adalah untuk segmentasi gambar cek dan diberi label untuk dapat diproses oleh model. Gambar 2 adalah contoh salah satu gambar dan segmentasi yang dilakukan. Gambar di segmentasi menggunakan aplikasi VoTT dan diberi label "date", "bearer name", "amount", "account number", dan "signature". Label ini digunakan untuk ekstraksi informasi yang akan dilakukan dengan model yang akan diteliti. Segmentasi signature juga akan secara manual diberi label valid dan invalid tergantung dengan ada atau tidaknya tanda tangan dan tanda tangan yang tertimpa dengan tulisan lain.

Dari pembagian dataset ini, maka didapatkan 112 tanda tangan untuk dipakai dalam training. dari 112 gambar tersebut dibagi menjadi 20 tidak valid dan 92 yang valid. 112 gambar ini akan dipakai untuk training dan testing signature verification modelnya. Sedangkan dari segmentasi bearer name dipakai 200 huruf dari cek bank yang di label secara manual untuk digunakan dalam rekognisi huruf. 200 angka dari account number, date, dan amount juga dipakai untuk prediksi rekognisi angka. Dataset angka dan huruf hanya dipakai 200 per kategori karena label harus dilakukan secara manual. Prediksi juga dapat dilakukan dengan sample kecil karena training untuk angka dan huruf akan dilakukan menggunakan dataset lain, IDRBT dataset hanya dipakai untuk sample verifikasi dan prediksi.

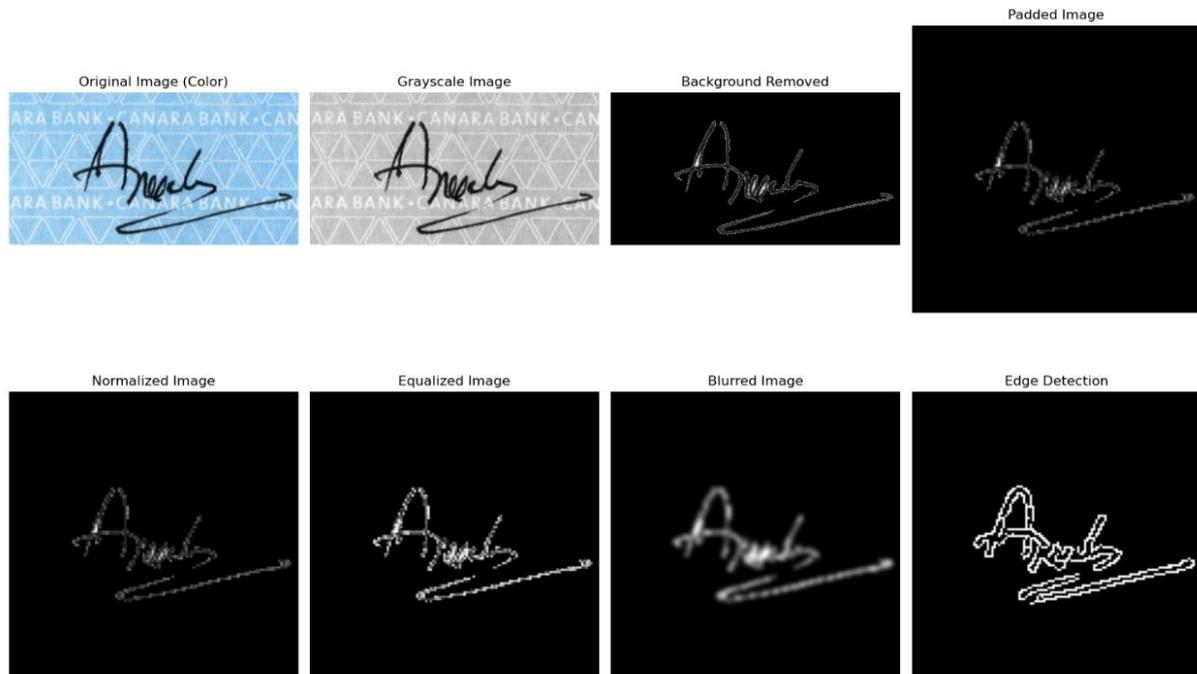


Gambar 2. Segmentasi data gambar cek

Selain dataset IDRBT, dataset EMNIST juga dipakai untuk melatih model convXGBoost untuk dapat rekognisi dan membaca tulisan tangan angka dan huruf. Karena beberapa angka dan huruf mirip antara satu sama lain, maka model yang membaca tulisan tangan akan dipisah menjadi 2, untuk membaca angka dan huruf. Dataset EMNIST memiliki dataset spesifik untuk angka dan huruf berupa EMNIST Letters dan EMNIST Digits. EMNIST Letters berupa 145600 gambar untuk 26 alfabet kapital (A-Z) dan 11 alfabet huruf kecil dengan beberapa huruf seperti c yang memiliki bentuk dan ukuran sama untuk dihiraukan (a-z) dan EMNIST Digits berupa 280000 gambar untuk 10 angka (0-9) (Cohen et al., 2017).

## C. Image Preprocessing

Berikut merupakan metode preprocessing yang dilakukan untuk database cek bank yang akan di sample dan digunakan untuk training model ConvXGB. Gambar 3 memperlihatkan sebuah sample image tanda tangan cek dan preprocessing yang dilakukan terhadap gambar tersebut di setiap prosesnya.



Gambar 3. Hasil preprocessing image tanda tangan cek bank

#### a. *Grayscale*

Grayscale dilakukan agar gambar cek dapat menghilangkan informasi warna. Warna bukanlah kriteria penting untuk mendeteksi validasi tanda tangan dan tulisan. CNN juga dapat bekerja lebih baik dalam melakukan feature extraction dari gambar tidak berwarna, dengan demikian training menjadi lebih cepat dan model menjadi lebih akurat.

#### b. *Remove Background*

Karena dataset yang didapatkan untuk cek bank merupakan scan dari berbagai cek, maka background dari scan tersebut harus dihilangkan. Ini dilakukan agar model dapat fokus terhadap kontur dan tepi tulisan tanpa perlu memikirkan background dari scan. Jadi model dapat fokus untuk melatih mendeteksi tanda tangan dan tulisan tangan tanpa terganggu latar belakang. Dengan metode ini akurasi untuk training akan menjadi lebih tinggi.

#### c. *Padding*

Padding digunakan untuk memastikan bahwa rasio aspek gambar tetap terjaga selama proses resizing. Jika gambar diubah ukurannya tanpa padding, bentuk huruf atau tanda tangan bisa menjadi lebih buram atau terdistorsi dan rusak. Dengan ditambahkan proses padding maka gambar akan ditambahkan ruang kosong agar gambar dapat diubah ukurannya sesuai yang diinginkan tanpa mengubah porsi.

#### d. *Normalize*

Normalisasi dilakukan untuk membuat nilai pixel dari resolusi  $[0,255]$  menjadi  $[0,1]$ . Normalisasi berguna untuk mempercepat training model dan membuatnya menjadi lebih stabil. Model seperti CNN bekerja lebih baik dengan data yang standar, terutama saat menggunakan lapisan aktivasi seperti ReLU yang sensitif terhadap skala input.

#### e. *Histogram Equalization*

Histogram equalization digunakan untuk meningkatkan kontras gambar agar intensitas pixel menjadi merata. Dengan meningkatkan kontras gambar, maka model dapat lebih mudah melihat pola dan bentuk dari tanda tangan dibandingkan gambar aslinya.

#### f. *Gaussian Blur*

Gaussian blur digunakan untuk mengurangi detail kecil yang tidak diinginkan karena gambar merupakan scan image. Dengan diberikan gaussian blur maka prediksi yang gagal karena distorsi atau noise

dapat dikurangi. Gaussian blur juga memberikan tepi dari tulisan menjadi lebih halus, ini berguna untuk edge detection preprocessing agar lebih gampang terdeteksi dan bentuk tidak pecah atau terpisah di edge detection.

**g. Canny Edge Detection**

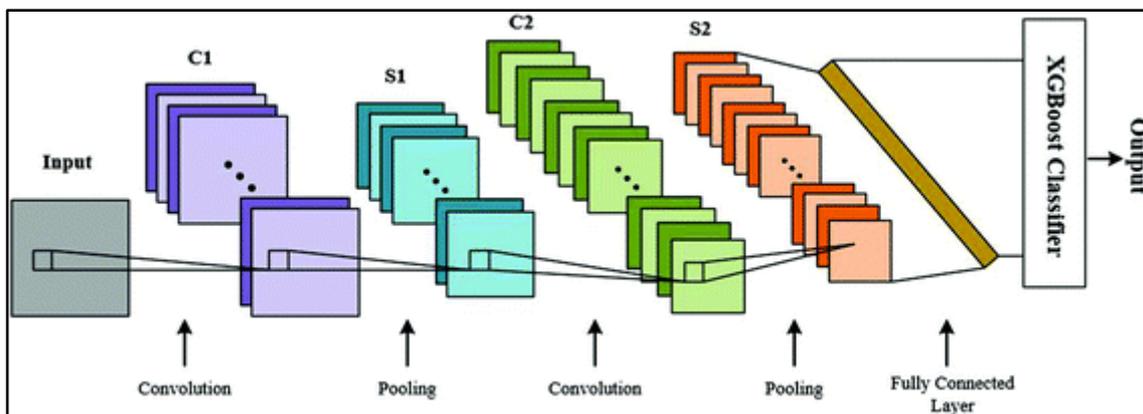
Edge detection berguna untuk mendeteksi tepi atau batas jelas dalam gambar. Berguna untuk memfokuskan training dalam pola sebuah tanda tangan dan tulisan. Dengan mendeteksi edge, model bisa fokus pada struktur penting tanpa perlu memproses seluruh gambar.

**D. Model Layers**

Model yang akan diteliti adalah model hybrid CNN-XGBoost yang juga dikenal sebagai ConvXGB. Model ini akan menggunakan CNN sebagai feature extractor, yaitu sebagai model yang mengambil fitur dari gambar seperti tepi, sudut, pola, dan bentuk dari tulisan dan tanda tangan. Ini dilakukan dengan lapisan convolution dan pooling yang digunakan untuk mengambil fitur gambar dan di flatten. Setelah itu XGBoost akan dipakai untuk mengklasifikasi gambar menggunakan decision tree. Setiap decision tree akan memperbaiki dan koreksi kesalahan pohon sebelumnya untuk meningkatkan akurasi model.

Model ini mempunyai keunggulan daripada model CNN biasa. Tentu ini tergantung tipe data yang dipakai untuk training dan juga tipe prediksi yang dilakukan. CNN mempunyai kemampuan yang bagus untuk mengambil dan ekstraksi fitur dan juga mengenali pola dari data. Sedangkan XGBoost mempunyai keunggulan dalam klasifikasi untuk dataset yang memiliki variasi dan noise yang tinggi. XGBoost berguna untuk data yang non-linear dan juga untuk mengurangi overfitting terhadap ukuran data yang kecil. Keunggulan ini berguna untuk model ini saat dipakai untuk training tanda tangan pengguna bank. Pada saat tanda tangan diberikan untuk sampling sebuah tanda tangan user mungkin hanya berjumlah 3 sampai 5 tanda tangan, jadi setiap tanda tangan satu user merupakan jumlah yang sangat kecil. XGBoost juga berguna untuk mengurangi waktu untuk training, jadi dengan akurasi yang cukup tinggi training model yang dilakukan tidak termasuk waktu yang lama.

Secara singkat, menggunakan CNN-XGBoost memiliki keunggulan ketahanan terhadap overfitting, dan akurasi klasifikasi. Pendekatan ini lebih efisien untuk dataset dengan variasi fitur yang kompleks atau ketika bekerja dengan dataset yang berjumlah sedikit, dibandingkan dengan pendekatan CNN murni yang mungkin membutuhkan lebih banyak data dan waktu pelatihan untuk mendapatkan performa yang sama. CNN-XGBoost model dapat dilihat arsitekturnya dalam gambar 4.



Gambar 4. CNN-XGBoost model (Ren et al., 2017)

**3. HASIL DAN PEMBAHASAN**

Hasil dari penelitian ini berupa akurasi dari model yang digunakan di dalam training untuk verifikasi tanda tangan dan pengenalan tulisan tangan. Koding dilakukan di google collab menggunakan bahasa python untuk mendapatkan hasilnya. Gambar 5 memperlihatkan summary dari model cnn yang digunakan untuk rekognisi angka.

Model: "sequential"

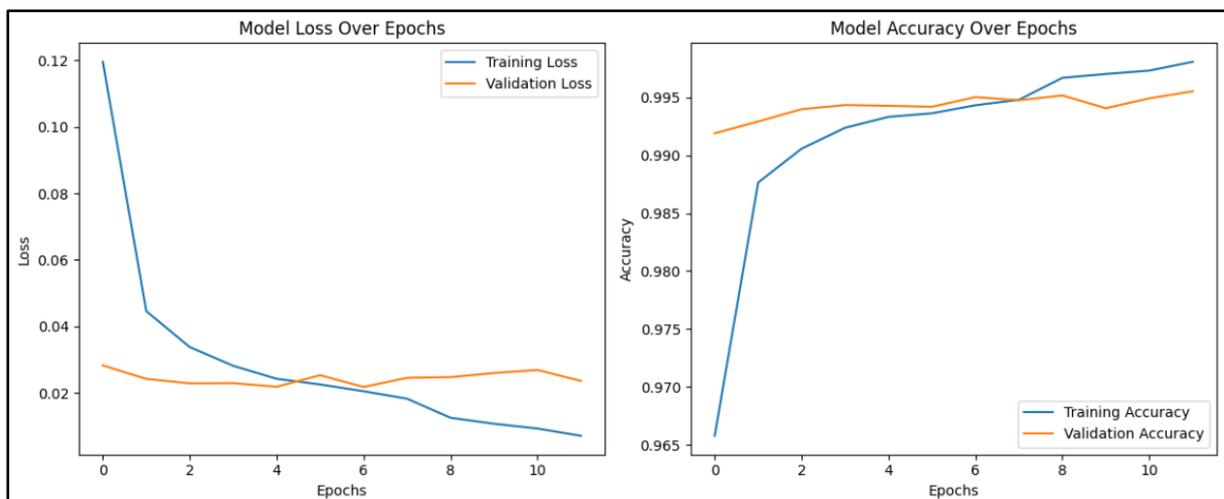
Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 26, 26, 32)	320
max_pooling2d (MaxPooling2D)	(None, 13, 13, 32)	0
conv2d_1 (Conv2D)	(None, 11, 11, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 5, 5, 64)	0
flatten (Flatten)	(None, 1600)	0
dense (Dense)	(None, 128)	204,928
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 62)	7,998

Total params: 231,742 (905.24 KB)  
Trainable params: 231,742 (905.24 KB)  
Non-trainable params: 0 (0.00 B)

Gambar 5. Summary CNN model

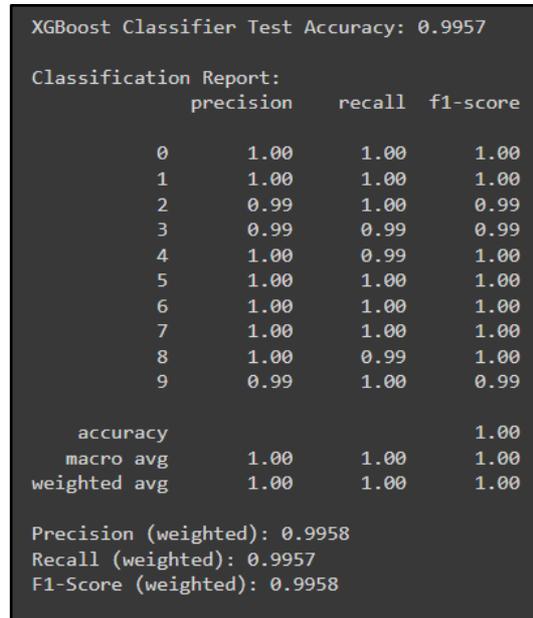
Penjelasan arsitektur dan hyperparameter model CNN yang dipilih adalah sebagai berikut. Convolutional layer awal menggunakan 32 filters karena jumlah dataset tidak terlalu banyak dan juga untuk meningkatkan efisiensi dalam training. Kernel size 3x3 untuk ekstraksi fitur sederhana dan kecil. Max pooling pertama dan kedua 2x2 untuk mengurangi overfitting dan mengurangi fitur map sebanyak setengah. Untuk convolutional layer kedua menggunakan 64 filter untuk mempelajari fitur yang lebih kompleks, biasa dengan mengandakan filter dan layer pertama. Model menggunakan early stopping 3 dimana jika validation akurasi tidak bertambah setelah 3 epoch maka model dihentikan training karena sudah dianggap training selanjutnya tidak akan meningkatkan akurasi dari model. Optimizer yang dipakai adalah adam (adaptive moment estimation) untuk proses klasifikasi.

Setelah model dilakukan fitting maka feature extraction telah dilakukan. Gambar 6 memperlihatkan akurasi dan juga loss setiap epoch pada saat fitting untuk feature extraction cnn. Setelah epoch 12 model dihentikan training agar tidak terjadi overfitting. Saat validation loss tidak ada peningkatan, maka secara koding training akan berhenti secara otomatis menggunakan fungsi early stopping agar model tidak terjadi overfitting.



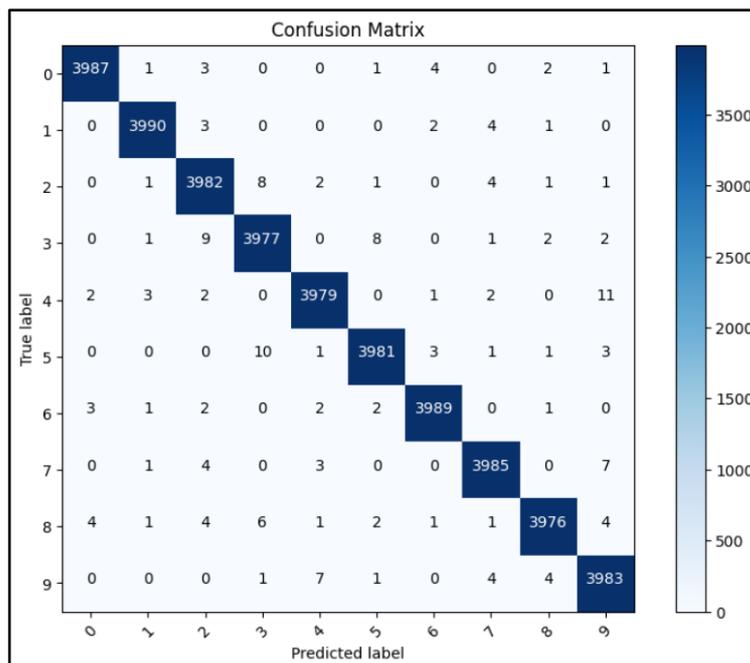
Gambar 6. Hasil ConvXGB dalam training dan testing rekognisi angka

Setelah itu akan dilakukan Xgboost model fitting untuk mengklasifikasi feature yang sudah di ekstrasi dengan CNN. Dari XGBoost classification ini didapatkan hasil model ConvXGB untuk rekognisi angka. Hasil model dapat dilihat di gambar 7.



Gambar 7. Hasil ConvXGB dalam training dan testing rekognisi angka

Dari hasil tersebut dapat dilihat bahwa gabungan CNN sebagai feature extraction dan XGBoost sebagai classification memperoleh akurasi 99.57%. Precision, recall dan F1-Score juga berkisar 99.57%. Jadi dari data tersebut dapat dilihat bahwa ConvXGB sangat bagus dalam memprediksi tulisan angka. Selain itu gambar 8 memperlihatkan confusion matrix untuk prediksi yang dilakukan oleh model. Confusion matrix berguna untuk melihat secara lebih detail bagian label mana yang paling sering salah diprediksi, seperti di dalam model ini prediksi yang paling sering salah dilakukan adalah angka 4 diprediksi sebagai angka 9 sebanyak 11 kali.



Gambar 8. Confusion matrix prediksi angka ConvXGB

Selain dari model ConvXGB untuk rekognisi angka, model juga di train untuk rekognisi huruf dan verifikasi tanda tangan. Hasil dari ConvXGB dalam rekognisi huruf adalah akurasi 98.76%. Hasil dari ConvXGB dalam verifikasi tanda tangan adalah akurasi 97.06%. Dari kedua hasil tersebut dapat terlihat bahwa ConvXGB dapat digunakan untuk rekognisi membaca tulisan angka dan huruf. ConvXGB juga dapat melihat validasi tanda tangan, jadi secara teori ConvXGB seharusnya dapat memverifikasi cek bank. Oleh karena itu akan dilakukan testing sample cek bank untuk melihat secara keadaan nyata apakah informasi yang di ekstrak dan verifikasi kliring cek bank dapat berjalan dengan lancar.

Akurasi model ini dapat dibandingkan dengan model model lain yang dipakai untuk verifikasi cek bank. Dari penelitian lain model CNN yang digunakan untuk rekognisi tulisan cek bank mendapat akurasi 99.14% (Chaudhary et al., 2019), model SIFT-SVM untuk signature verification mendapat akurasi 98.10% (Agrawal et al., 2020), dan model R-CNN untuk verifikasi signature bank dengan akurasi 97.4% (Abdo et al., 2023). Untuk perbandingan ini dapat dilihat bahwa CNN model memiliki akurasi lebih tinggi daripada ConvXGB untuk verifikasi tulisan huruf. Sedangkan ConvXGB memiliki akurasi lebih tinggi daripada model R-CNN dan lebih rendah dari gabungan model SIFT-SVM. Akurasi juga dipengaruhi dengan cara preprocessing image yang dilakukan, jadi perbandingan ini tidak pasti membuktikan bahwa ConvXGB memiliki performa lebih rendah. Ada beberapa model lain yang digunakan untuk verifikasi cek bank, tetapi rata rata tingkat akurasi ConvXGB sama dengan model lain, jadi dapat terlihat bahwa model ConvXGB secara teori dapat melakukan verifikasi dan rekognisi cek bank.

Model yang sudah di training akan digunakan dalam testing sebuah sample cek, cek sudah disegmentasi dengan VoTT dan di labelkan. Dalam sistem bank asli maka setiap kali user mengupload gambar cek maka ada sebuah aplikasi yang secara otomatis segmentasi gambar berdasarkan posisi cek bank, ini dapat dilakukan karena setiap cek bank biasanya mempunyai standar template yang sama jadi segmentasi dapat dilakukan dengan gampang. Untuk penelitian ini dilakukan segmentasi secara manual karena kegunaannya hanya untuk testing dan validasi kegunaan model. Setelah cek di segmentasi maka menggunakan python find contours function untuk memisahkan alfabet dan angka menjadi satu per satu. Ini dikarenakan model di training untuk membaca tulisan angka dan alfabet satu per satu. Gambar juga akan diberi preprocessing yang sama dalam training model. Gambar 8 berikut memperlihatkan hasil verifikasi cek dari model yang di train. Angka dari cek yang diperlihatkan di gambar xxx tidak terlihat sudah dilakukan preprocessing, ini dikarenakan image yang ditampilkan adalah grayscale segmentasi, sebelum di preprocess. Dalam koding image yang dipakai adalah image yang sudah diberi preprocessing seperti menghilangkan background, gaussian blur, dan lain lain.



Gambar 9. Verifikasi sample cek bank

Dari hasil yang diperoleh dapat dilihat bahwa ada beberapa kesalahan prediksi dalam ekstraksi informasi hasil cek bank. Model dapat mengetahui bahwa tanda tangan sesuai dengan tanda tangan yang sudah di train sebelumnya. Tetapi informasi jumlah uang yang perlu di transfer salah. Ini dikarenakan fungsi find contour membuat koma dalam gambar sebagai segmentasi angka tersendiri. Karena model tidak dilatih untuk membaca koma, maka model mengira bahwa koma adalah angka satu. Dari tulisan nama juga ada beberapa salah prediksi yang terjadi. Ini dapat memperlihatkan jika model ini dipakai secara langsung dalam sistem bank untuk menggantikan teller maka akan terjadi kesalahan fatal dalam transaksi keuangan

karena uang yang ditransfer dari jumlah 210300 menjadi 21013000. Masalah di eksperimen ini dapat gampang di selesaikan dengan secara manual segmentasi cek satu per satu angka dan hurufnya. Di kondisi nyata pada saat penggunaan model ini dalam situs bank maka kesalahan ini dapat di solusikan dengan permintaan bank agar penulis tidak menulis koma, atau melatih machine learning model yang dapat membaca koma.

Walaupun masalah ini dapat disolusikan dengan gampang salah satu masalah paling besar dalam menggantikan tenaga kerja dengan tenaga mesin adalah risiko jika terjadi kesalahan transaksi. Model ConvXGB memiliki akurasi di atas 97% untuk prediksi, tetapi masih ada kemungkinan 3% untuk salah prediksi, pada saat prediksi salah maka transaksi yang dilakukan dapat menyebabkan kasus yang besar. Transfer uang 4 juta bisa tertransfer 9 juta karena dari model yang terlatih angka 4 dan 9 bisa tertukar prediksinya. Selain itu tulisan tangan manusia memiliki bentuk yang berbeda beda, ada tulisan tangan yang jelek yang susah dibaca, seperti contoh gambar 9, dimana nama pemilik cek susah dibaca. Transfer bisa dinyatakan gagal karena verifikasi informasi gagal.

Dari hasil verifikasi sample tersebut dapat dilihat bahwa machine learning masih berfungsi untuk membantu bank teller dalam ekstraksi informasi, tetapi tidak bisa menggantikan secara sepenuhnya untuk kliring cek bank tertulis. Karena kesalahan yang kecil dalam kliring cek dapat merugikan bank secara besar. Tentu dari prediksi untuk account number dapat terlihat bahwa tenaga kerja dapat dibantu dalam mengisi beberapa informasi secara otomatis dan teller hanya perlu review data dan memperbaikinya sedikit sebelum di cek ke database untuk verifikasi dan mengkliring cek bank.

#### 4. SIMPULAN DAN SARAN

Kesimpulan dari penelitian ini adalah ConvXGB dapat verifikasi tanda tangan dan rekognisi tulisan angka dan huruf dengan akurasi yang tinggi. Akurasi 97.06% untuk verifikasi tanda tangan, 98.76% untuk rekognisi huruf, dan 99.57% untuk rekognisi angka. Jadi fungsi penelitian untuk dapat mengecek akurasi dari model untuk verifikasi tanda tangan dan rekognisi tulisan telah berhasil. Penelitian ini berkontribusi untuk memperlihatkan potensi ConvXGB untuk verifikasi cek bank lebih tinggi dari beberapa model lain walaupun ada model lain seperti SIFT-SVM yang memiliki akurasi lebih tinggi dalam verifikasi cek bank. Dengan penelitian ini diharapkan sebuah sistem gabungan manusia dan machine learning dapat dibuat untuk mempercepat verifikasi cek bank yang biasa memerlukan 1 hari untuk cek di kliring.

Sedangkan kegunaan ConvXGB untuk menggantikan tenaga kerja manusia hanya berhasil untuk membantu tugas kliring cek bank, tidak dapat menggantikannya secara penuh. Ini dikarenakan risiko kesalahan prediksi yang dapat terjadi, walau akurasi model sangat tinggi, jika akurasi tidak dapat dipastikan untuk selalu betul, maka ada kesalahan data dan transaksi yang dapat terjadi karena salah pembacaan tulisan. Pada saat transaksi keuangan terjadi maka risiko untuk mempercayai sepenuhnya model ConvXGB untuk menggantikan teller bank dalam kliring cek tertulis menjadi sangat berbahaya.

Saran yang dapat diberikan untuk melatih machine learning model dalam verifikasi cek bank adalah untuk melatihnya dengan satu tipe cek bank dengan dimensi tertentu. Ini dilakukan untuk membuat gampang segmentasi data yang ingin dilakukan. Setelah itu cek dapat disegmentasi secara otomatis karena dimensi setiap cek bank yang dipakai sama. Data IDRBT hanya 112 gambar maka segmentasi dapat dilakukan secara manual, tetapi jika dataset berjumlah sekitar 1000, maka segmentasi manual membutuhkan tenaga kerja yang cukup banyak.

Saran atau sugesti penelitian selanjutnya adalah menggunakan preprocessing image yang berbeda atau model lain yang dapat verifikasi cek bank dengan akurasi lebih tinggi. Dataset yang lain juga dapat dicoba untuk melihat perbedaan accuracy dalam tipe cek bank yang berbeda. Model Seperti GNN (Deep Graph Neural Networks) dan GAN (Hybrid Generative Adversial Network) belum digunakan untuk cek accuracy dan keunggulan dalam verifikasi cek bank. Model juga bisa digabungkan dengan model lain untuk ekstraksi fitur dan klasifikasinya. Image preoprocessing seperti random elastic deformation dan texture filtering juga dapat dipakai untuk melihat perbedaan accuracy. Dataset yang biasa dipakai merupakan huruf dan angka yang dipakai di bahasa inggris. Bahasa lain belum terlalu dilatih dan dicek menggunakan model model lain yang belum dicoba.

Saran lain untuk pelatihan machine learning adalah untuk mengecek image yang di preprocess sebelum training model. Di dalam penelitian ini kesalahan prediksi dalam verifikasi tanda tangan awalnya sangat buruk karena background scan gambar tidak dihilangkan. Jadi hilangkan semua fitur tidak penting yang tidak diperlukan untuk verifikasi dan klasifikasi training model dalam gambar sebelum fitting dilakukan.

### Daftar Pustaka

- Abdo, H. A., Abdu, A., Manza, R., & Bawiskar, S. (2023). *Extraction of Bank Cheque Fields Based on Faster R-CNN* (Vol. 4). Atlantis Press International BV. [https://doi.org/10.2991/978-94-6463-196-8\\_12](https://doi.org/10.2991/978-94-6463-196-8_12)
- Agrawal, P., Chaudhary, D., & Madaan, V. (2020). Automated bank cheque verification using image processing and deep learning methods. *Multimedia Tools and Applications*, 80, 5319–5350.
- Babayomi, M., Olagbaju, O. A., & Kadiri, A. A. (2023). *Convolutional XGBoost (C-XGBOOST) Model for Brain Tumor Detection*.
- Chaudhary, D., Agrawal, P., & Madaan, V. (2019). *Bank Cheque Validation Using Image Processing* (pp. 148–159). [https://doi.org/10.1007/978-981-15-0108-1\\_15](https://doi.org/10.1007/978-981-15-0108-1_15)
- Cohen, G., Afshar, S., Tapson, J., & Van Schaik, A. (2017). EMNIST: Extending MNIST to handwritten letters. *Proceedings of the International Joint Conference on Neural Networks, 2017-May*, 2921–2926. <https://doi.org/10.1109/IJCNN.2017.7966217>
- Dansena, P., Bag, S., & Pal, R. (2017). Differentiating Pen Inks in Handwritten Bank Cheques Using Multi-layer Perceptron. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10597 LNCS, 655–663. [https://doi.org/10.1007/978-3-319-69900-4\\_83](https://doi.org/10.1007/978-3-319-69900-4_83)
- Jha, M., Kabra, M., Jobanputra, S., & Sawant, R. (2019). Automation of Cheque Transaction using Deep Learning and Optical Character Recognition. *Proceedings of the 2nd International Conference on Smart Systems and Inventive Technology, ICSSIT 2019, Icssit*, 309–312. <https://doi.org/10.1109/ICSSIT46314.2019.8987925>
- Khan, M. S. U. (2021). A novel segmentation dataset for signatures on bank checks. *ArXiv*. <https://doi.org/10.34740/KAGGLE/DS/1041694.Dansena>
- Ren, X., Guo, H., Li, S., Wang, S., & Li, J. (2017). A novel image classification method with CNN-XGBoost model. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10431 LNCS, 378–390. [https://doi.org/10.1007/978-3-319-64185-0\\_28](https://doi.org/10.1007/978-3-319-64185-0_28)
- Sikira, R. (2021). Customers' Opinions on Reasons for Using Online Banking: Experience of Customers in Tanzania. *International Journal of Scientific Research and Management*, 9(05), 2185–2195. <https://doi.org/10.18535/ijstrm/v9i05.em02>
- Thongsuwan, S., Jaiyen, S., Padcharoen, A., & Agarwal, P. (2021). ConvXGB: A new deep learning model for classification problems based on CNN and XGBoost. *Nuclear Engineering and Technology*, 53(2), 522–531. <https://doi.org/10.1016/j.net.2020.04.008>
- Weldegebriel, H. T., Liu, H., Haq, A. U., Bugingo, E., & Zhang, D. (2020). A New Hybrid Convolutional Neural Network and eXtreme Gradient Boosting Classifier for Recognizing Handwritten Ethiopian Characters. *IEEE Access*, 8, 17804–17818. <https://doi.org/10.1109/ACCESS.2019.2960161>