



PEMANFAATAN *ARTIFICIAL INTELLIGENCE* UNTUK OPTIMALISASI PNBP: STUDI KASUS BEA LELANG PADA LELANG INDONESIA

Galuh Mafela Mutiara Sujak

Direktorat Jenderal Kekayaan Negara, Kementerian Keuangan, Surabaya
galuhmafela@gmail.com

Hanif Noer Rofiq*

Direktorat Jenderal Kekayaan Negara, Kementerian Keuangan, Jakarta
hanif.noer94@gmail.com

*Alamat Korespondensi: hanif.noer94@gmail.com

ABSTRACT

Misclassification of auction objects can result in an inaccuracy of the Auction Fee that is imposed, resulting in under/overpayment of government revenue, a decline in public reputation, and differences in auction fee data in SIMPONI and Portal Lelang Indonesia. These errors can be anticipated by adding verification step by the Auctioneer. Meanwhile, the increase in the frequency of auctions is disproportionate to the number of Auctioneer, thus a mechanism that can assist the Auctioneer to do verification without adding additional work is needed. The authors propose the use of a Convolutional Neural Network to carry out the automatic classification of auction objects in the form of Buildings, Demolition, Cars, and Motorcycles. The dataset was obtained from the Portal Lelang Indonesia. The results of training and validation accuracy were 96.13% and 96.50%. The model is then applied to a dashboard for manual testing, and 100% accuracy results are obtained from all the images tested.

Keywords: CNN, Deep Learning, Image Classification, Portal Lelang Indonesia, Auction Fee

ABSTRAK

Kesalahan pemilihan sifat objek lelang saat pengajuan permohonan lelang dapat mengakibatkan kurang tepatnya tarif PNBP Bea Lelang yang dikenakan sehingga berakibat pada kurang/lebih bayar Penerimaan Negara; penurunan reputasi publik terhadap pelayanan lelang; serta tidak padunya data aplikasi SIMPONI dengan Portal Lelang Indonesia. Verifikasi oleh pejabat lelang merupakan salah satu upaya untuk mengantisipasi kesalahan tersebut, namun semakin bertambahnya frekuensi lelang yang tidak sepadan dengan penambahan jumlah pejabat lelang, maka diperlukan mekanisme yang dapat membantu pejabat lelang dalam melakukan verifikasi secara cepat tanpa menambah pekerjaan. Untuk mengatasi masalah tersebut, penulis mengusulkan pemanfaatan *Artificial Intelligence* berupa *Convolutional Neural Network* untuk melakukan klasifikasi otomatis objek lelang berupa Bangunan, Bongkaran, Mobil, dan Motor. Dataset berasal dari Portal Lelang Indonesia. Didapatkan hasil akurasi training sebesar 96.13% dan validasi 96,50%. Model kemudian diaplikasikan pada *dashboard* sederhana untuk dilakukan uji model secara manual. Dari pengujian manual, didapatkan hasil akurasi 100% dari seluruh gambar yang diujikan.

Kata kunci: CNN, Deep Learning, Klasifikasi Gambar, Portal Lelang Indonesia, Tarif Bea Lelang

KLASIFIKASI JEL: C45, M15

CARA MENGUTIP:

Sujak, G. M. M. & Rofiq, H. N. (2024). Pemanfaatan artificial intelligence untuk optimalisasi PNBP: Studi kasus bea lelang pada lelang Indonesia. *Jurnal Indonesian Treasury Review: Jurnal Perbendaharaan, Keuangan Negara dan Kebijakan Publik*, 9(2), 112-124.

PENDAHULUAN

Bea Lelang merupakan salah satu Penerimaan Negara Bukan Pajak (PNBP) yang dihasilkan oleh pelaksanaan lelang Direktorat Jenderal Kekayaan Negara (DJKN). Berdasarkan Peraturan Pemerintah Nomor 62 Tahun 2020 tentang Perubahan atas Peraturan Pemerintah Nomor 3 Tahun 2018 tentang Jenis dan Tarif atas Jenis Penerimaan Negara Bukan Pajak yang Berlaku Pada Kementerian Keuangan, bea lelang dibayar oleh penjual dan/atau pembeli tergantung jenis lelang dan sifat objek yang dilelang (Barang Bergerak atau Barang Tidak Bergerak). Sebagai contoh, terhadap Pembeli Lelang Non Eksekusi Wajib Barang Milik Negara/Daerah dikenakan tarif 1,5% dari pokok lelang untuk Barang Tidak Bergerak (BTB), serta 2% dari pokok lelang untuk Barang Bergerak (BB). Hampir seluruh jenis lelang memiliki tarif yang berbeda tergantung sifat objek lelang. Kesalahan pemilihan jenis lelang maupun kesalahan interpretasi sifat objek lelang dapat menimbulkan selisih pada bea yang seharusnya diterima oleh negara. Di sisi lain, pemungutan bea lelang merupakan proses yang cukup panjang, dimulai dari proses penentuan bea lelang oleh penjual saat mengajukan permohonan lelang melalui Portal Lelang Indonesia sampai dengan bea lelang tersebut dimasukkan pada Aplikasi SIMPONI dan disetorkan ke kas negara oleh Bendahara Penerimaan.

Dalam kuesioner pendahuluan yang penulis lakukan, Bendahara Penerimaan sering menemukan kesalahan dalam penetapan tarif bea lelang. Apabila ditemukan kesalahan, maka langkah yang dilakukan adalah melakukan konfirmasi ke Pejabat Lelang; memperbaiki tarif bea lelang di Rincian Hasil Lelang; memberitahukan kepada pemenang lelang bahwa terdapat kesalahan perhitungan bea lelang sekaligus menyampaikan perhitungan yang benar sehingga pemenang lelang diinstruksikan untuk melunasi jumlah sesuai perhitungan yang sebenarnya.

Kesalahan penerapan tarif bea lelang menjadikan optimalisasi PNBP tidak tercapai, seperti munculnya risiko potensi kurang bayar/lebih bayar atas PNBP, risiko terjadinya perbedaan data antara Portal Lelang Indonesia dengan SIMPONI, hingga penurunan reputasi Kementerian Keuangan c.q. DJKN. Pada Bab V Undang-Undang Republik Indonesia Tahun 2009 tentang Pelayanan Publik, menyebutkan bahwa penyelenggaraan pelayanan publik sekurang-kurangnya harus memiliki empat belas komponen standar, di antaranya adalah komponen biaya/tarif. Adanya ralat kurang bayar atau lebih bayar berpengaruh pada aspek biaya Standar Pelayanan, sehingga akan menurunkan kepercayaan dan kepuasan pengguna layanan.

PENERAPAN DALAM PRAKTIK

- Kesalahan pengenaan tarif Penerimaan Negara Bukan Pajak (PNBP) Bea Lelang terjadi salah satunya karena kesalahan Pemohon Lelang dalam memilih Sifat Barang saat mengajukan permohonan lelang.
- Untuk mengatasi kesalahan pemilihan Sifat Barang tersebut, diusulkan penggunaan *Artificial Intelligence* berupa *Convolutional Neural Network* (CNN) untuk mengklasifikasikan gambar objek lelang secara otomatis saat permohonan lelang dilakukan.
- Hasil klasifikasi akan membantu Pejabat Lelang dalam memverifikasi "Sifat Barang" pada permohonan lelang yang diajukan, serta digunakan sebagai dasar penentuan tarif secara otomatis saat permohonan lelang diajukan sehingga kesalahan pengenaan besaran PNBP bea lelang dapat diminimalisasi.

Berdasarkan informasi yang penulis himpun dari kuesioner pendahuluan yang penulis lakukan, beberapa penyebab terjadinya kesalahan pemilihan bea lelang oleh Penjual adalah adanya perbedaan persepsi terhadap jenis lelang dan sifat objek lelang akibat kurangnya pengetahuan pemohon, *human error* seperti salah klik, serta kurangnya ketelitian dari Pejabat Lelang ketika melakukan verifikasi. Verifikasi merupakan salah satu hal yang dapat dilakukan untuk mencegah kesalahan Permohonan Lelang yang diajukan. Namun data "Sifat Objek Lelang" yang dimasukkan oleh Pemohon ke Portal Lelang Indonesia tidak termasuk dalam hal yang dapat diverifikasi Pejabat Lelang melalui Portal Lelang Indonesia. Sehingga kesempatan Pejabat Lelang untuk mengetahui kesalahan pemilihan Sifat Objek Lelang ialah melalui pemeriksaan berkas fisik setelah verifikasi *online* disetujui di Portal Lelang Indonesia.

Mengingat semakin tingginya frekuensi lelang serta ditambah dengan kebijakan *zero growth* Kementerian Keuangan, diperlukan mekanisme yang dapat membantu Pejabat Lelang dalam melakukan verifikasi secara cepat tanpa memperbanyak pekerjaan yang telah ada. Dalam melakukan otomasi pekerjaan, banyak bidang yang telah bergerak menuju penerapan *Artificial Intelligence* (AI), contohnya pada bidang akuntansi dan auditing (Kokina & Davenport, 2017; Hasan, 2021). AI juga dipergunakan untuk secara otomatis menurunkan kelemahan sistem pengendalian internal di suatu organisasi (Askary et al, 2018). Tidak hanya di sektor privat, AI kini juga telah dilirik dan diimplementasikan pada sektor publik (van Noordt & Misuraca, 2022; Ahn & Chen, 2022).

Salah satu bagian dari AI adalah *Deep Learning* yang meniru arsitektur *neural network* otak. Ketika otak menerima informasi baru, maka otak akan mencoba untuk membandingkannya dengan informasi yang telah tersedia. Konsep yang sama dipakai oleh *Deep Learning* sehingga bisa memecahkan permasalahan melalui *labelling* dan kategorisasi (Jakhar & Kaur, 2020). Contohnya adalah pengklasifikasian gambar untuk tujuan tertentu (Kothari et al, 2018; Abu et al, 2019) seperti klasifikasi jenis bunga (Kothari et al., 2018); klasifikasi bahasa isyarat (Kembuan et al., 2020); klasifikasi penyakit COVID-19, pneumonia, dan kanker paru-paru berdasarkan gambar *x-ray* dan CT paru-paru (Ibrahim et al, 2021), klasifikasi jenis makanan (Samraj et al 2020); serta klasifikasi tokoh wayang Pandawa (Wisnudhanti & Candra, 2020).

Implementasi *Deep Learning* dalam identifikasi dan klasifikasi gambar dapat diadopsi untuk verifikasi sifat objek lelang. Hasil klasifikasi gambar kemudian digunakan sebagai dasar untuk menentukan tarif bea lelang yang seharusnya dikenakan. Untuk dapat mengimplementasikan hal ini, diperlukan *input* berupa foto objek lelang pada Portal Lelang Indonesia. Dengan diselenggarakannya lelang secara *online* sejak tahun 2014 yang mewajibkan setiap permohonan untuk dilengkapi dengan foto objek lelang (Direktorat Jenderal Kekayaan Negara, 2020), implementasi *Deep Learning* untuk klasifikasi objek lelang dapat dilaksanakan.

Salah satu metode *Deep Learning* yang paling populer untuk deteksi objek dan klasifikasi gambar adalah *Convolutional Neural Network* (CNN) (Hossain & Sajib, 2019; Kembuan et al, 2020). Penelitian ini mengusulkan penggunaan *Artificial Intelligence* berupa *Deep Learning* melalui *Convolutional Neural Network* (CNN) untuk menganalisis gambar objek lelang yang diunggah. *Output* penelitian adalah sebuah model yang dapat mengoptimalkan penerimaan negara melalui pengklasifikasian objek lelang secara otomatis. Sedangkan tujuan dari penelitian ini adalah untuk mengoptimalkan PNBP Bea Lelang dengan cara mengurangi kesalahan pemilihan sifat objek lelang melalui klasifikasi yang dilakukan oleh *Artificial Intelligence*. Hasil klasifikasi yang dihasilkan kemudian menjadi dasar pengenaan tarif bea lelang secara otomatis berdasarkan gambar yang diunggah pada saat permohonan lelang diajukan.

STUDI LITERATUR

Continous Improvement dalam Lelang Indonesia

Lelang Indonesia merupakan lelang yang diselenggarakan oleh Kementerian Keuangan c.q. Direktorat Jenderal Kekayaan Negara (DJKN) c.q. Kantor Pelayanan Kekayaan Negara dan Lelang

(KPKNL). Lelang telah dilaksanakan sejak tahun 1908 yang ditandai dengan terbitnya *Vendu Reglement* (VR) atau Peraturan Lelang. Seiring dengan Teori *Continous Improvement*, yaitu adanya perbaikan secara terus-menerus, berkesinambungan, dan berkelanjutan (Wijayati et al., 2013; Sutarto, 2015; Supriyanto et al., 2019; Wicaksono dan Supriyanto, 2023), proses bisnis lelang terus dilakukan perbaikan yang ditandai dengan beragam perubahan, seperti pembaruan peraturan perundang-undangan, sampai dengan hadirnya lelang secara *online* melalui Portal Lelang Indonesia.

Portal Lelang Indonesia merupakan aplikasi berbasis *website* dan *mobile* untuk membantu proses bisnis lelang, mulai dari pelaksanaan sebelum lelang, lelang, serta setelah lelang. Pengembangan Portal Lelang Indonesia terus dilakukan, sejak tahun 2019, permohonan lelang oleh Pemohon telah dapat dilakukan melalui Modul Permohonan Online pada Portal Lelang Indonesia (Direktorat Jenderal Kekayaan Negara, 2020). Dengan mengacu pada prinsip perbaikan terus-menerus, maka Portal Lelang Indonesia akan selalu dilakukan *maintenance* serta pengembangan supaya dapat meningkatkan efektivitas, efisiensi, serta meningkatkan kepuasan pengguna.

Optimalisasi

Optimalisasi menurut Kamus Besar Bahasa Indonesia berasal dari kata dasar *optimal*, yang berarti terbaik/paling menguntungkan. Optimalisasi PNBP dapat diartikan sebagai hasil yang dicapai sesuai dengan keinginan secara efektif dan efisien. Optimalisasi juga dapat diartikan sebagai suatu ukuran yang menyebabkan tercapainya tujuan (Wardhana, 2018). Dari pengertian di atas, optimalisasi merupakan upaya untuk mencapai tujuan yang diinginkan secara efektif dan efisien. Dinarjito, 2017 mengaitkan optimalisasi dengan Penerimaan Negara Bukan Pajak (PNBP) sebagai suatu upaya yang dijalankan untuk memaksimalkan, mengefektifkan, dan mengefisienkan PNBP sesuai dengan aturan yang berlaku dengan tujuan untuk membiayai kegiatan dalam rangka mendukung tugas-tugas pokok Kementerian/Lembaga dalam rangka pelayanan publik. Optimalisasi PNBP sejauh ini dilaksanakan supaya pendapatan negara melalui PNBP bisa mencapai hasil yang maksimal. Namun sebenarnya, selain untuk meningkatkan PNBP yang masuk ke kas negara, optimalisasi juga dapat diterapkan pada aspek pencatatan, seperti dalam Penelitian yang dilakukan oleh Karim, 2022 yang mencari solusi untuk meningkatkan akurasi pencatatan perkawinan siri di Kabupaten Boalem melalui aplikasi SIMKAH Web.

Artificial Intelligence

Istilah *Artificial Intelligence* (AI) pertama kali diperkenalkan oleh John McCarthy (Ertel, 2017; Mintz & Brodie, 2019) pada tahun 1955. Pada saat itu, AI didefinisikan sebagai sesuatu yang bertujuan untuk menciptakan mesin yang bisa berperilaku seakan-akan mereka memiliki kemampuan untuk berpikir. Beberapa definisi dari AI sendiri kemudian mulai terbentuk seiring dengan berkembangnya teknologi tersebut. Plant, 2011 mendefinisikan AI sebagai sebuah studi dan implementasi atas suatu teknik yang memungkinkan alat atau mesin untuk dapat melakukan kegiatan yang memerlukan kemampuan berpikir seperti manusia.

Dalam ranah publik, *Artificial Intelligence* telah dimanfaatkan untuk membantu administrasi dan pelayanan, contohnya pada Pemerintah Kota Bandung yang menerapkan *Artificial Intelligence* melalui aplikasi e-SATRIA (*Electronic Self Assesment Tax Reporting Apps*), GAMPIL (*Gadget Aplication Mobile for Licence*), BIMMA (*Bandung Integrated Manpower Management Application*), dan SITARUNG (Supriyadi & Asih, 2020). Beberapa contoh skenario lain mengenai pemanfaatan *Artificial Intelligent* di ranah pemerintahan juga dipaparkan oleh Fauzan, 2020 berupa implementasi *Artificial Intelligence* pada proses pengawasan dan pengendalian kepegawaian pada seleksi jabatan pimpinan tinggi, serta penggunaan *sentiment analysis* pada pengawasan dan pengendalian Kode Etik dan Disiplin PNS.

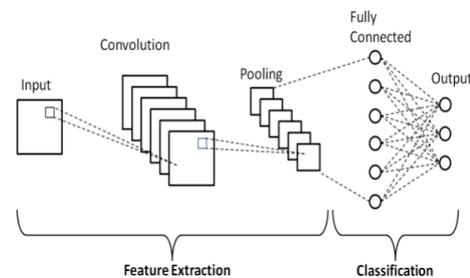
Pemanfaatan *Artificial Intelligence* dalam pelayanan publik tersebut ternyata meningkatkan kepuasan masyarakat terhadap pelayanan publik, mengefisienkan alur birokrasi, serta meningkatkan produktivitas pemerintahan karena beberapa tugas telah didelegasikan kepada mesin (Supriyadi & Asih, 2020). Kelebihan yang sama juga dirasakan pada bidang keamanan siber, *Artificial Intelligence* dianggap memiliki potensi besar untuk meningkatkan efektivitas dan efisiensi pertahanan siber melalui pemantauan dan analisis aktivitas jaringan untuk mendeteksi serangan dan ancaman potensial (Farid et al., 2023). Dengan demikian, pemanfaatan *Artificial Intelligence* dalam pemerintahan bukan lagi merupakan hal yang baru sehingga implemmentasi *Artificial Intelligence* dalam proses bisnis lelang yang diselenggarakan oleh DJKN merupakan hal yang memungkinkan.

Deep Learning

Deep learning merupakan salah satu bagian dari *Artificial Intelligence* (Campesato, 2020) yang meniru arsitektur *neural network* otak dan kemampuan pengambilan keputusan manusia (McBee et al, 2018; Jakhar dan Kaur, 2020). *Deep learning* menjadi salah satu alat yang diandalkan untuk *image processing* (McBee et al., 2018; Jiao dan Zhao, 2019). *Image processing* merupakan teknik yang meliputi penciptaan gambar, kompresi

gambar, *encoding*, *image deblurring*, segmentasi gambar, klasifikasi dan deteksi pola dan gambar, deteksi perubahan, anotasi gambar, dan lain sebagainya (Jiao & Zhao, 2019). Salah satu bagian dari *Deep Learning* adalah *Convolutional Neural Network* (CNN) yang berupa *Neural Network* atau Jaringan Neural yang khusus digunakan untuk tugas deteksi pola pada gambar yang kompleks (O'Shea & Nash, 2015; Krizhevsky et al., 2017; Zaccone & Karim, 2018; Campesato, 2020; Kembuan et al., 2023). Berbeda dengan algoritma deteksi pola lainnya, CNN memiliki kedua fitur ekstraksi dan klasifikasi (Phung & Rhee, 2018; Phung & Rhee 2019). Skema arsitektur dasar dari CNN dapat dilihat pada Gambar 1. Struktur Dasar CNN berikut.

Gambar 1 Struktur Dasar CNN



Sumber: Phung & Rhee (2019)

Arsitektur dasar CNN memiliki fitur ekstraksi yang terdiri dari *input layer*, *convolution layer*, dan *pooling layer*; serta fitur klasifikasi yang terdiri dari *fully-connected layer* dan *output layer*. *Input layer* menentukan ukuran tetap untuk gambar input, sehingga gambar bisa diubah ukurannya jika memang diperlukan. *Convolutional Layer* memiliki filter-filter kecil berupa matriks kecil dengan dimensi rata-rata 3x3, atau 5x5, 7x7, bahkan 1x1. Filter-filter ini melakukan "scanning" atau pemindaian gambar, kemudian menghasilkan *output* berupa *feature map* yang berisi bilangan nyata (Campesato, 2020). Selanjutnya, *pooling layer* akan mengurangi ukuran gambar dengan tetap mempertahankan informasi yang ada.

Secara teknis, *pooling* berarti mengurangi ukuran data menggunakan fungsi agregasi lokal (Hope et al, 2017) atau membagi suatu region menjadi subregion yang lebih kecil (Zaccone & Karim, 2018). Fitur klasifikasi kemudian menggabungkan *output* dari fitur ekstraksi melalui *fully connected layers*. Pada akhirnya, muncul satu *output neuron* untuk setiap kategori objek di *layer output*. Keluaran dari klasifikasi adalah hasil klasifikasi (Phung & Rhee, 2019). Dalam aplikasi nyata, terdapat banyak layer pada masing-masing fitur ekstraksi dan klasifikasi (Phung & Rhee, 2019), sehingga arsitektur CNN bisa menjadi sangat kompleks (Campesato, 2020).

METODOLOGI PENELITIAN

Penelitian ini dilakukan dengan mengadopsi metode *Design Science Research* (DSR) yang dikenalkan oleh Peffers et al (2007). DSR merupakan sebuah metode yang berfokus pada pemecahan masalah sekaligus pengembangan sistem, oleh karena itu, tahapan penelitian berdasarkan DSR mencakup antara lain *Problem Identification; Objectives of a Solution; Design and Development; Demonstration; Evaluation*, dan *Communication* (Peffers et al, 2007; March et al, 2008). Ilustrasi dari model DSR dapat dilihat pada Gambar 2. Karena keterbatasan waktu, maka penelitian kali ini hanya sampai pada langkah kelima, yakni Evaluasi.

Problem Identification

Langkah pertama dalam DSR adalah *Problem Identification*, yaitu mengidentifikasi permasalahan yang dihadapi. Dari latar belakang yang telah dijelaskan, penelitian ini berfokus pada masalah kesalahan pemilihan sifat objek lelang oleh pemohon lelang. Dampak dari kesalahan pemilihan sifat objek lelang tersebut dapat mengakibatkan kekeliruan pada besaran tarif bea lelang, sehingga salah satunya berdampak pada kurang/lebih bayar PNBP.

Objective of Solution

Langkah selanjutnya adalah menentukan tujuan penelitian atau *Objective of Solution*. Tujuan utama dari penelitian ini adalah untuk mengoptimalkan PNBP Bea Lelang dengan cara mengurangi kesalahan pemilihan sifat objek lelang melalui mekanisme yang efektif tanpa perlu menambah beban pekerjaan pejabat lelang.

Design and Development

Langkah ketiga sekaligus langkah yang menghasilkan *artifact* atau *prototype* adalah *Design and Development*. Untuk menjawab permasalahan dan mencapai tujuan, Penelitian ini mengusulkan pemanfaatan *Artificial Intelligence*, yaitu pembuatan Model *Convolutional Neural Network* untuk melakukan klasifikasi gambar objek lelang secara otomatis, sehingga pemohon lelang tidak perlu memilih jenis objek lelang saat mengajukan permohonan. Hasil dari klasifikasi objek kemudian

digunakan untuk menentukan tarif bea lelang sesuai dengan peraturan yang berlaku.

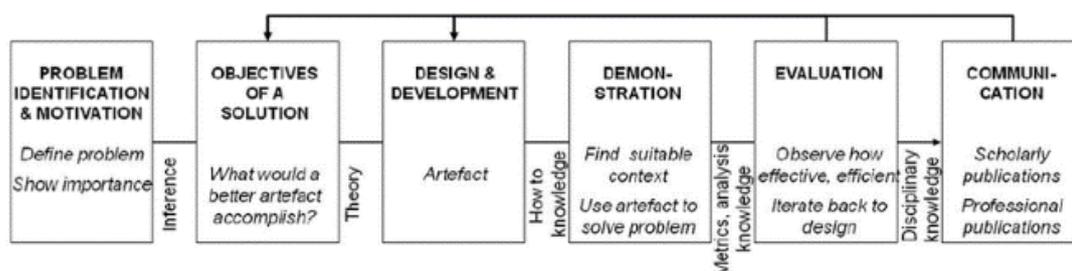
Dalam pembuatan dan pengembangan desain, digunakan *Deep Learning* berupa *Convolutional Neural Network* (CNN) untuk mengklasifikasi objek yang diajukan permohonan lelang melalui Portal Lelang Indonesia. Penulis menggunakan empat kategori gambar objek lelang, yaitu bangunan (barang tidak bergerak), bongkaran (barang bergerak), mobil (barang bergerak), dan motor (barang bergerak). Pemilihan empat kategori gambar tersebut dilakukan atas dasar survei pendahuluan yang dilakukan oleh penulis. Dari survei pendahuluan tersebut, diketahui bahwa frekuensi paling banyak terjadinya kesalahan penentuan bea lelang terdapat pada jenis lelang non eksekusi wajib. Dengan demikian penulis menggunakan gambar kategori barang yang sering dilelang pada jenis lelang tersebut, antara lain mobil, motor, dan bongkaran. Sedangkan bangunan, merupakan kategori barang yang jarang dilelang pada jenis lelang non eksekusi wajib, namun merupakan kategori barang yang sering dilelang pada jenis lelang eksekusi. Melihat banyaknya data gambar yang tersedia pada kategori tersebut, maka penulis memasukkan bangunan untuk digunakan sebagai contoh kategori barang tidak bergerak.

Model CNN yang dibangun dijalankan dengan menggunakan komputer dengan spesifikasi AMD Ryzen 7 Pro 5845, NVIDIA GeForce RTX 3070 TI 8GB dan RAM 16GB pada *Operating Sistem* Windows 11 yang telah terinstall Python 3.9 dan TensorFlow 2.10.1 dengan CUDA 12 dan CuDNN 8.7. Proses pembuatan model dilakukan melalui tiga tahap, yaitu pengumpulan data; *data preparation*; dan *modelling*.

Pengumpulan Data

Data yang digunakan berasal dari Portal Lelang Indonesia dalam kurun waktu 20 Januari 2023 sampai dengan 21 Februari 2023. Pengambilan gambar yang dilakukan secara manual serta keterbatasan spesifikasi komputer yang digunakan menyebabkan penulis hanya memperoleh 1.000 gambar yang terbagi rata ke dalam empat kategori sesuai jenis barang yang

Gambar 2 Model *Design Process Research*



Sumber: Peffers et al (2007)

sering dilelang ditambah satu contoh kategori barang bergerak, yaitu rumah, bongkaran, mobil, dan motor. Dalam hal keterbatasan jumlah *dataset* gambar, Shahinfar et al, 2020 menyatakan bahwa 150-500 gambar per kategori sudah dianggap cukup untuk mendapatkan akurasi klasifikasi. Hal ini juga sejalan dengan penelitian yang dilakukan oleh Barz dan Denzler, 2020 yang menggunakan sebanyak 250 gambar per kategori karena adanya keterbatasan *dataset*. Contoh dari *sample dataset* dapat dilihat pada Gambar 3, sedangkan pembagiannya dilihat pada Tabel 1.

Tabel 1 Dataset yang Digunakan

Nama	Jumlah
Bangunan	250
Bongkaran	250
Mobil	250
Motor	250
Total	1.000

Sumber: Diolah Penulis

Data Preparation

Data dari Portal Lelang Indonesia memiliki ekstensi *file* dan ukuran yang berbeda-beda (jpeg, png, jpg). Dengan demikian, diperlukan *data preparation process* untuk memastikan bahwa data tidak menimbulkan masalah sehingga dapat digunakan dalam pemodelan (Diaz et al, 2021). Langkah pertama dari *data preparation* yang dilakukan adalah menyamakan semua ekstensi *file* gambar menjadi satu format dan ukuran. Oleh karena komputer tidak melihat gambar sebagaimana kita melihat tampilan gambar tersebut, melainkan berdasarkan *pixel* dan warna (Zaccone & Karim, 2018), maka semua gambar disamakan ke dalam format jpg dan diseragamkan menjadi ukuran 512 x 512 *pixel*.

Dataset kemudian dibagi menjadi data *train* dan data validasi dengan proporsi 80% data untuk data *train* dan 20% sisanya untuk data validasi. Sehingga terdapat 800 gambar untuk data *train* dan 200 gambar untuk data validasi. Data *train* adalah data yang digunakan untuk melatih model CNN sedangkan data validasi adalah data yang digunakan untuk mengevaluasi model dari CNN yang telah dilatih. Pembagian data menjadi 80:20 untuk data *train* dan data validasi didasarkan pada Teori *Pareto Analysis*, dikenal juga dengan aturan 80/20 yang menyatakan bahwa sejumlah kecil persentase (20%) menentukan hasil pada persentase lain yang lebih besar (80%) (Lipovetsky, 2009). Penggunaan *Pareto Analysis* 80/20 banyak digunakan dalam analisis menggunakan *Deep Learning*, contohnya penggunaan 80% gambar X-Ray sebagai data *train* dan 20% gambar X-Ray sebagai data validasi untuk diagnosa COVID-19 yang dilakukan oleh Hemdan menunjukkan kinerja klasifikasi yang baik dengan skor f1 masing-masing 0,89 dan 0,91 untuk normal

dan COVID-19 (Hemdan et al, 2020). Ismael et al (2019) juga menggunakan rasio 80:20 dalam mengklasifikasikan gambar MRI sebagai deteksi kanker otak. Lebih jauh lagi, Ismael et al (2019) menyatakan bahwa meskipun pembagian *dataset* menjadi 80:20 merupakan hal yang lumrah dilakukan pada *deep learning*, rasio tersebut menunjukkan hasil akurasi yang lebih tinggi daripada rasio populer lain (rasio 70:30 dan 75:25), yakni mencapai 99% dengan menggunakan rasio 80:20. Sedangkan rasio 70:30 menghasilkan akurasi 97%, dan rasio 75:25 menghasilkan akurasi 98%.

Karena jumlah data *train* yang sedikit, dilakukan augmentasi pada data *train* untuk menambah variasi. Augmentasi data adalah teknik yang lazim digunakan pada *dataset* yang kecil (Ottoni et al, 2023). Pada dasarnya, augmentasi gambar adalah menciptakan *dataset* baru yang berbeda dari data input (Harianto et al, 2021; Wen et al, 2022) untuk melatih model *deep learning* dan menghindari *overfitting* (Allaire, 2018 dalam Ottoni et al, 2023; Elgendy, 2020 dalam Ottoni et al, 2023).

Beberapa teknik augmentasi data yang dilakukan seperti melakukan *flip*, rotasi, perubahan tingkat kecerahan, dan *zoom* (Harianto et al, 2021; Chhabra & Kumar, 2022). Harianto et al (2021) menggunakan augmentasi data untuk meningkatkan efisiensi RCNN yang lebih cepat dalam mendeteksi gambar kendaraan bermotor. Ottoni et al (2021), mengaplikasikan augmentasi data berupa *shifting* dan *zoom* untuk mengklasifikasikan bangunan, dan menghasilkan akurasi sampai 95,6% pada langkah uji kasus pertama. Sedangkan dalam penelitian ini, Penulis menggunakan augmentasi data sesuai Tabel 2.

Tabel 2 Macam Augmentasi Data

No	Augmentasi	Parameter
1	<i>Rotation</i>	10 derajat
2	<i>Width shift</i>	10%
3	<i>Height shift</i>	10%
4	<i>Horizontal flip</i>	<i>True</i>
5	<i>fill_mode</i>	<i>Reflect</i>

Sumber: Diolah Penulis

Augmentasi rotate dilakukan dengan cara memutar gambar sampai dengan maksimal 10 derajat di kedua arah. Augmentasi *width shift* dan *height shift* dilakukan sampai dengan 10% pada gambar dan augmentasi *fill_mode* dilakukan untuk mengisi *pixel* yang hilang ketika transformasi dengan cara merefleksikan tepi *pixel* terakhir.

Modelling

Struktur *Convolutional Neural Network* yang digunakan terangkum dalam Tabel 3. Tabel 3 merangkum seluruh *layer* dari model yang telah dibuat. *Layer (type)*, merupakan jenis *layer* yang digunakan. Dimensi pertama yang bernilai "none"

Gambar 3 Sample dataset



Sumber: Diolah Penulis

mewakili besaran *batch* yang mana pada saat model dibuat, besaran *batch* tersebut belum terdefinisi. “None” berarti ukuran *batch* bisa berupa apa saja (Geron, 2019). Dimensi “None” akan digantikan dengan ukuran *batch* pada saat dilakukan *fitting* data pada model, yang mana pada penelitian ini ukuran *batch* yang digunakan adalah 32.

Layer pertama adalah *convolutional (Conv2D)* dengan jumlah *filter* 16, kemudian diikuti oleh *max pooling layer* yang membagi setiap dimensi spasial sebesar 2. Pada *layer-layer convolutional* berikutnya

Tabel 3 Struktur CNN yang digunakan

Layer (type)	Output Shape	Param #
conv2d_4 (Conv2D)	(None, 510, 510, 16)	448
max_pooling2d_2 (MaxPooling 2D)	(None, 255, 255, 16)	0
conv2d_5 (Conv2D)	(None, 253, 253, 32)	4640
max_pooling2d_3 (MaxPooling 2D)	(None, 126, 126, 32)	0
conv2d_6 (Conv2D)	(None, 124, 124, 64)	18496
max_pooling2d_4 (MaxPooling 2D)	(None, 62, 62, 64)	0
conv2d_7 (Conv2D)	(None, 60, 60, 128)	73856
max_pooling2d_5 (MaxPooling 2D)	(None, 30, 30, 128)	0
flatten_1 (Flatten)	(None, 115200)	0
dense_2 (Dense)	(None, 512)	58982912
dropout_1 (Dropout)	(None, 512)	0
dense_3 (Dense)	(None, 4)	2052

 Total params: 59,082,404
 Trainable params: 59,082,404
 Non-trainable params: 0

Sumber: Diolah Penulis

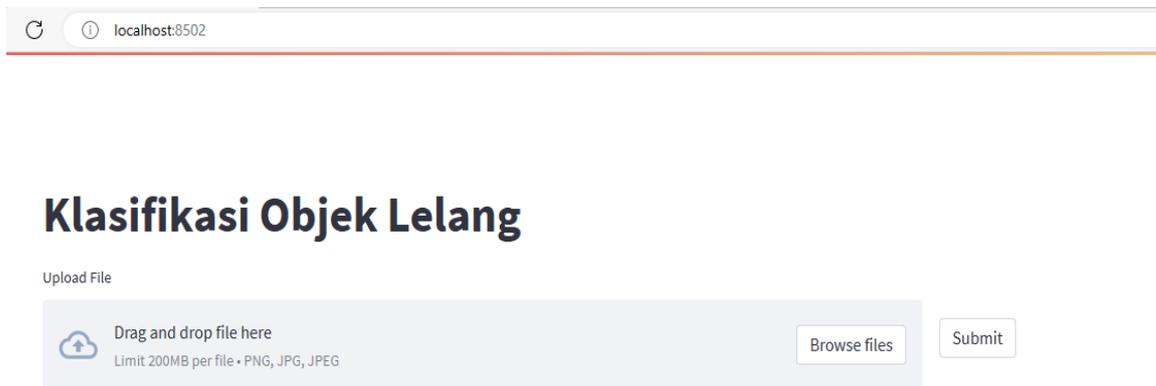
dilakukan pengandaan filter. Pengandaan setelah *pooling layer* merupakan hal yang wajar dilakukan (Geron, 2019). Jumlah *filter* digandakan sebanyak 2 kali lipat hingga *filter* pada *convolutional layer* keempat berjumlah 128.

Flatten layer menggabungkan semua fitur yang dipelajari dari *convolutional layer* yang telah ditentukan sebelumnya yang pada akhirnya akan digunakan pada jaringan yang terhubung sepenuhnya (*fully-connected network*) (Kanani & Padole, 2019).

Jaringan pada *neural network* merupakan hal yang kompleks. Untuk jaringan yang besar tentunya akan memiliki kelemahan berupa waktu eksekusi yang lambat sehingga membuatnya sulit untuk menangani *overfitting*. Untuk mengatasi permasalahan tersebut, digunakanlah teknik *dropout*. Ide utama dari *dropout* adalah untuk secara acak mengeluarkan unit (sekaligus dengan koneksinya) dari jaringan *neural* saat masa *training*. (Srivastava, 2014). Pada jaringan yang terhubung sepenuhnya, digunakan satu *hidden layer* dengan 512 *neuron* dan satu *Dropout Layer* dengan *Dropout Rate* sebesar 0,5. Kemudian di akhir, terdapat *layer output* dengan empat *neuron* yang menggunakan fungsi *softmax*. Pada model yang digunakan, dihasilkan parameter yang dapat di-*train* sebanyak 59.082.404 parameter.

SoftMax merupakan fungsi aktivasi *output layer*. Fungsi aktivasi merupakan fungsi non linear yang biasa digunakan pada CNN (Hope et al, 2017). Fungsi aktivasi menentukan nilai matematis dari sinyal *output*, berdasarkan sinyal yang diterima dari koneksi input dengan *neuron* lain, kemudian dikumpulkan berdasarkan bobot sesuai sinyal yang diterima masing-masing (Zaccone & Karim, 2018).

Gambar 4 Tampilan Utama *Dashboard*



Sumber: *Dashboard* Diolah Penulis

Rectified Linear Unit (ReLU) merupakan fungsi aktivasi (Hope et al., 2017; Campesato, 2020) yang mengikuti *convolutional layer* dan dapat digunakan juga pada *max pooling layer*, khususnya pada jaringan awal dengan tujuan untuk mengurangi jumlah ruang yang dibutuhkan jaringan (Zaccone & Karim, 2018). Pada *feature maps* yang dihasilkan *convolutional layer*, bisa saja dihasilkan nilai negatif. Tujuan ReLU adalah untuk mengganti nilai negatif (jika ada) tersebut dengan 0. ReLU dapat digambarkan pada fungsi berikut:

$$\text{ReLU}(x) = x \text{ if } x \geq 0; \text{ dan}$$

$$\text{ReLU}(x) = 0 \text{ if } x < 0$$

Dari serangkaian proses yang dilalui, pada akhirnya *SoftMax*-lah yang memberikan “ranking klasifikasi” terhadap hasil identifikasi gambar. (Zaccone & Karim, 2018). Fungsi *SoftMax* memetakan nilai suatu *dataset* ke nilai lain dengan *range* 0 sampai dengan 1, dengan jumlah probabilitas yang jumlahnya sama dengan satu. Dalam kasus CNN, *SoftMax* akan memetakan nilai dari *layer* tersembunyi paling akhir pada *neuron* di *output layer*. Jika nilai indeks sama, maka gambar telah terklasifikasikan, jika tidak maka dianggap tidak cocok. (Campesato, 2020).

Penulis menggunakan *Callbacks* berupa *EarlyStopping*. *EarlyStopping* digunakan untuk menghentikan *training model* secara otomatis apabila tidak terdapat peningkatan pada pengukuran yang dipantau (Kazi et al, 2020). Dalam hal ini metrik yang dipantau adalah *loss* dari validasi dan batasan yang diberikan adalah 10 *epoch* dengan parameter *restore_best_weight* untuk menggunakan nilai terbaik dari pengukuran yang dipantau saat *training*.

Demonstration

Model yang telah dibuat kemudian diimplementasikan pada sebuah *dashboard* sederhana. *Dashboard* yang dibangun memungkinkan pengguna untuk melakukan simulasi secara langsung sekaligus menguji kinerja

model. Contoh implementasi model pada *dashboard* dapat dilihat pada Gambar 4. Cara kerja pengujian manual melalui *dashboard* adalah dengan cara mengunggah gambar pada menu unggah yang telah disediakan. Setelah gambar di-submit maka *dashboard* akan secara otomatis melakukan klasifikasi gambar.

Evaluation

Evaluasi merupakan tahap penting dalam DSR. Melalui evaluasi, dapat dikatakan apakah teknologi yang dikembangkan berfungsi atau tidak sesuai dengan tujuan yang diinginkan (Venable et al, 2012).

Secara teoretis, Penelitian ini menggunakan metrik evaluasi akurasi. Dalam *training* yang dilakukan, model memiliki tingkat akurasi awal sebesar 33,25% dengan *loss* sebesar 1,784 dan akurasi dari validasi sebesar 40% dengan *loss* pada validasi sebesar 1.369 di *epoch* pertama. Akurasi ini terus meningkat sejalan dengan penurunan *loss* sepanjang *training* yang dilakukan hingga *training* berhenti pada *epoch* ke 49 karena penggunaan *EarlyStopping* yang berarti sejak *epoch* ke 39 tidak terdapat peningkatan selama 10 kali berturut-turut dari *loss* pada validasi.

Model pada *epoch* ke 49 memiliki akurasi *training* sebesar 95,63% dan akurasi validasi sebesar 95,49%. Namun, karena penggunaan dari parameter *restore_best_weights* pada *EarlyStopping* maka model yang dipakai adalah model dari *epoch* ke 39 yang memiliki akurasi *training* sebesar 96.13% dengan *loss* sebesar 0.1203; dan akurasi validasi 96,50% dengan *loss* sebesar 0,1047. Grafik akurasi *training* dan validasi dapat dilihat pada Gambar 5, sedangkan *loss* dari *training* dan validasi dapat dilihat pada Gambar 6.

Hasil klasifikasi pada data validasi dapat dilihat pada Tabel 4. Hasil klasifikasi objek Bangunan dan Mobil mencapai 100%, sedangkan objek Bongkaran memiliki ketepatan klasifikasi paling rendah. Hal tersebut dikarenakan

Tabel 4 Hasil Klasifikasi

	Hasil Klasifikasi				Total	Benar (%)
	Bangunan	Bongkaran	Mobil	Motor		
Bangunan	50	0	0	0	50	100%
Bongkaran	3	44	1	2	50	88%
Mobil	0	0	50	0	50	100%
Motor	0	1	0	49	50	98%

Sumber: Diolah Peneliti

Tabel 5 Hasil Uji Manual Melalui *Dashboard*

	Hasil Klasifikasi				Total	Benar (%)
	Bangunan	Bongkaran	Mobil	Motor		
Bangunan	5	0	0	0	5	100%
Bongkaran	0	5	0	0	5	100%
Mobil	0	0	5	0	5	100%
Motor	0	1	0	5	5	100%

Sumber: Diolah Peneliti

bongkaran terdiri dari berbagai macam barang dan bentuk yang berbeda-beda.

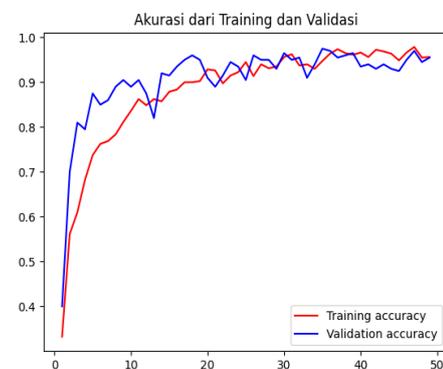
Penulis melakukan pengujian model melalui *dashboard* dengan lima gambar untuk setiap kategori. Pengujian dilakukan dengan data gambar yang didapat dari Portal Lelang Indonesia pada tanggal 2 Maret 2023. *Output* dari *dashboard* adalah klasifikasi gambar beserta besaran bea lelang setelah gambar selesai diunggah. Contoh hasil pengujian secara manual melalui *dashboard* dapat dilihat pada Gambar 7. Sedangkan hasil klasifikasi dari seluruh uji coba gambar tersaji dalam Tabel 5 dengan simpulan model dapat mendeteksi 100% benar pada semua gambar yang diuji.

Pembahasan

Evaluasi model dalam Penelitian ini dilakukan melalui dua hal, yang pertama adalah Evaluasi menggunakan *Evaluation Metric* berupa Akurasi, dan yang kedua evaluasi melalui uji coba manual pada *dashboard*. Kedua evaluasi tersebut ditujukan untuk mengevaluasi apakah model dapat mengatasi kesalahan penetapan yang biasa terjadi saat Pemohon tidak tepat dalam menetapkan jenis objek lelang. Dengan menggunakan *Artificial Intelligence*, tugas pemohon dalam menentukan jenis objek lelang digantikan oleh model yang telah dikembangkan. Melalui *metrics evaluation*, model menunjukkan akurasi *training* sebesar 96,13% dan validasi 96,50%. Sedangkan evaluasi dari *dashboard* menunjukkan bahwa model dapat diimplementasikan dan menunjukkan akurasi 100% dari seluruh gambar yang diujikan. Dengan mekanisme tersebut, verifikasi sifat objek lelang yang harus dilakukan Pejabat Lelang menjadi lebih akurat dan cepat.

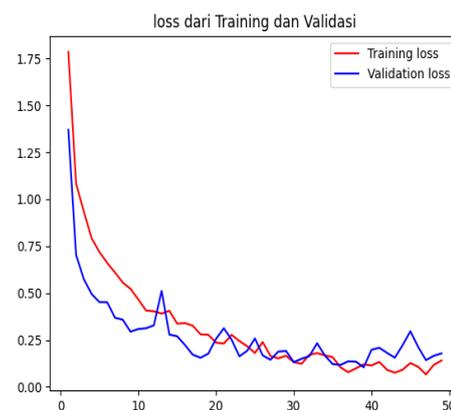
Hasil dari klasifikasi gambar kemudian digunakan sebagai *input* untuk menetapkan besaran bea lelang sesuai tarif yang berlaku. Tarif bea lelang tersebut sesuai dengan Peraturan Pemerintah Republik Indonesia Nomor 62 Tahun 2020 yang ditentukan oleh jenis lelang dan sifat

Gambar 5 Akurasi dari *Training* dan Validasi



Sumber: Diolah Penulis

Gambar 6 Loss dari *Training* dan Validasi

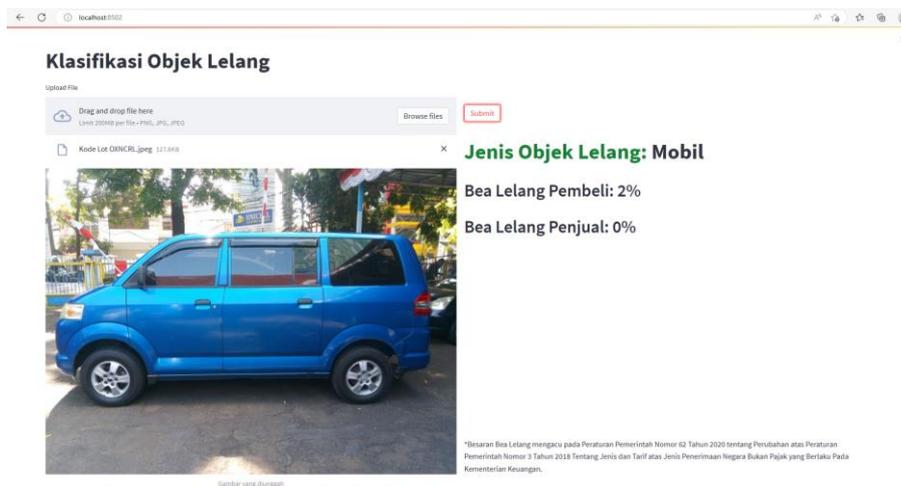


Sumber: Diolah Penulis

barang (Tabel 6). Dalam kasus ini Penulis menggunakan perhitungan tarif sesuai jenis lelang Non Eksekusi Wajib Barang Milik Negara/Daerah (BMN/D).

Klasifikasi dan pengenaan tarif secara otomatis seperti yang ditunjukkan pada *dashboard* merupakan suatu mekanisme yang dapat

Gambar 7 Hasil Uji *Dashboard*



Sumber: *Dashboard* Diolah Peneliti

mengatasi permasalahan kesalahan penetapan bea lelang sekaligus optimalisasi PNPB Bea Lelang. Hal tersebut dapat dijelaskan sebagai berikut, bahwa dengan diimplementasikannya *Artificial Intelligence* untuk melakukan klasifikasi gambar objek lelang, maka sesuai dengan akurasi model, maka setiap permohonan yang diajukan akan secara otomatis terklasifikasi sifat objeknya tanpa perlu dilakukan pemilihan manual oleh Pemohon Lelang. Dengan demikian, faktor kesalahan karena kurangnya pengetahuan pemohon dan *human error* bisa berkurang. Setelah itu, sifat objek lelang yang merupakan hasil dari klasifikasi otomatis *Artificial Intelligence* akan dijadikan dasar penetapan tarif penetapan bea lelang sesuai dengan peraturan perundangan yang berlaku, hal ini berarti pejabat lelang telah dibantu oleh *Artificial Intelligence* dalam melakukan verifikasi "Sifat Barang" pada permohonan lelang yang diajukan. Melalui mekanisme tersebut, verifikasi "Sifat Barang" dapat dikerjakan dengan cepat tanpa menambah pekerjaan Pejabat Lelang. Ketika pengenaan tarif bea lelang telah sesuai sejak awal permohonan, maka koreksi kesalahan tarif bea lelang tidak akan terjadi. Hal ini berarti risiko kurang bayar ataupun lebih bayar penerimaan negara atas PNPB bea lelang dapat diturunkan.

KESIMPULAN

Kesalahan pemilihan sifat objek lelang dapat mengakibatkan kurang/lebih bayar Penerimaan Negara; penurunan reputasi publik terhadap pelayanan lelang; serta tidak padunya data antara aplikasi SIMPONI dengan Portal Lelang Indonesia. Pemanfaatan *Artificial Intelligence* untuk mengklasifikasi gambar objek lelang dapat menurunkan kesalahan manusia atas pemilihan sifat objek lelang tersebut. Hasil dari klasifikasi kemudian dipergunakan sebagai dasar penentuan

Tabel 6 Tarif Bea Lelang Non Eksekusi Wajib
BMN/D

Kategori Gambar	Sifat Barang	Bea Lelang Penjual	Bea Lelang Pembeli
Bangunan	Barang Tidak Bergerak	0%	1,5%
Bongkaran	Barang Bergerak	0%	2%
Mobil	Barang Bergerak	0%	2%
Motor	Barang Bergerak	0%	2%

Sumber: PP No 62 Tahun 2020

tarif bea lelang sesuai dengan Peraturan Perundangan yang berlaku.

Model yang dikembangkan dalam penelitian memiliki akurasi *training* sebesar 96,13% dan akurasi validasi sebesar 96,50%. Model kemudian diimplementasikan ke dalam *dashboard* sederhana sehingga dapat digunakan oleh *end user* dengan cara mengunggah gambar yang akan diuji / diajukan permohonannya. Dari uji manual model melalui *dashboard*, model dapat otomatis 100% mendeteksi dua puluh gambar yang diujikan dan memberikan besaran tarif bea lelang yang seharusnya dikenakan. Untuk mendapatkan klasifikasi gambar yang akurat, diperlukan standardisasi resolusi minimal gambar yang diunggah, serta posisi dan komposisi foto yang merepresentasikan objek yang akan dilelang.

Dengan akurasi 96%, AI dapat diterapkan untuk membantu Pejabat Lelang dalam memverifikasi sifat objek lelang melalui klasifikasi kategori gambar secara otomatis. Diharapkan ke depannya melalui penerapan AI, kesalahan pengenaan tarif bea lelang akibat kesalahan pemilihan sifat objek lelang dapat diminimalisasi, sehingga Penerimaan Negara atas bea lelang beserta pencatatannya menjadi lebih akurat dan optimal.

IMPLIKASI DAN KETERBATASAN

Penulis menyadari bahwa dalam penulisan karya tulis ini masih terdapat kekurangan, baik pada proses pengumpulan data maupun data yang digunakan. Data yang digunakan dalam penelitian ini hanya mencakup data selama satu bulan. Kategori barang dan perhitungan tarif PNBP Bea Lelang yang digunakan juga tidak mencakup semua jenis lelang yang ada. Pengembangan lebih lanjut dapat menggunakan *dataset* yang lebih besar dan lebih bervariasi mengingat lelang secara *online* telah ada sejak 2014.

PENGHARGAAN

Penulis mengucapkan terima kasih kepada para pihak yang telah membantu kelancaran penulisan karya tulis ini, baik pada saat pra penulisan maupun sampai saat proses penulisan dilakukan. Ucapan terima kasih tersebut Penulis sampaikan kepada Para Pejabat Lelang di Kantor Pelayanan Kekayaan dan Lelang Surabaya serta Bendahara Penerimaan pada Kantor Pelayanan Kekayaan Negara dan Lelang yang telah mengisi kuesioner sebagai survei pendahuluan yang penulis lakukan sehingga karya tulis dapat diselesaikan dengan baik.

REFERENSI

- Abu, M. A., Indra, N. H., Rahman, A. H. A., Sapiee, N. A., & Ahmad, I. (2019). A study on image classification based on deep learning and tensorflow. *International Journal of Engineering Research and Technology*, 12(4), 563-569.
- Ahn, M. J., & Chen, Y. C. (2022). Digital transformation toward AI-augmented public administration: The perception of government employees and the willingness to use AI in government. *Government Information Quarterly*, 39(2), 101664.
- Askary, S., Abu-Ghazaleh, N., & Tahat, Y. A. (2018). Artificial intelligence and reliability of accounting information. In *Challenges and Opportunities in the Digital Era: 17th IFIP WG 6.11 Conference on e-Business, e-Services, and e-Society, I3E 2018, Kuwait City, Kuwait, October 30–November 1, 2018, Proceedings 17* (pp. 315-324). Springer International Publishing.
- Barz, B., & Denzler, J. (2020). deep learning on small datasets without pre-training using cosine loss. Paper presented at The IEEE Winter Conference on Applications of Computer Vision.
- Bente, G., Baptist, O., & Leuschner, H. (2012). To buy or not to buy: Influence of seller photos and reputation on buyer trust and purchase behavior. *International Journal of Human-Computer Studies*, 70(1), 1-13.
- Campesato, O. (2020). *Artificial intelligence, machine learning, and deep learning*. United States of America: Mercury Learning and Information.
- Chhabra, M., & Kumar, R. (2022). an advanced vgg16 architecture-based deep learning model to detect pneumonia from medical images. In *Emergent Converging Technologies and Biomedical Systems: Select Proceedings of ETBS 2021* (pp. 457-471). Singapore: Springer Singapore.
- Diaz, O., Kushibar, K., Osuala, R., Linardos, A., Garrucho, L., Igual, L., ... & Lekadir, K. (2021). Data preparation for artificial intelligence in medical imaging: A comprehensive guide to open-access platforms and tools. *Physica medica*, 83, 25-37.
- Dinarjito, A. (2017). optimalisasi penerimaan negara bukan pajak pada lembaga penyiaran publik televisi republik indonesia (LPP TVRI). Substansi: Sumber Artikel Akuntansi Auditing dan Keuangan Vokasi, 1(1), 107-122.
- Direktorat Jenderal Kekayaan Negara (2020). 112 Tahun Lelang di Indonesia: Eksistensi, Peran, dan Pengembangannya di Era Digital (Media Kekayaan Negara Ed. 34 Tahun XI/2020 PP. 18-32). Jakarta: Direktorat Jenderal Kekayaan Negara.
- Farid, I., Reksoprodjo, A. H., & Suhirwan, S. (2023). pemanfaatan artificial intelligence dalam pertahanan siber. NUSANTARA: *Jurnal Ilmu Pengetahuan Sosial*, 10(2), 779-788.
- Fauzan, I. (2020). Artificial Intelligence (AI) pada proses pengawasan dan pengendalian kepegawaian—sebuah eksplorasi konsep setelah masa pandemi berakhir. *Civil Service Journal*, 14(1 Juni), 31-42.
- Geron, A (2019). Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. United States of America: O' Riley Media.
- Ertel, W., & Black, N. T. (2018). *Introduction to artificial intelligence* (2nd 2017 ed.). Springer International Publishing AG. <https://doi.org/10.1007/978-3-319-58487-4>
- Hariato, R. A., Pranoto, Y. M., & Gunawan, T. P. (2021, April). Data augmentation and faster rcnn improve vehicle detection and recognition. In *2021 3rd East Indonesia Conference on Computer and Information Technology (EIconCIT)* (pp. 128-133). IEEE.
- Hasan, A. R. (2021). Artificial Intelligence (AI) in accounting & auditing: A Literature review. *Open Journal of Business and Management*, 10(1), 440-465.
- Hemdan, E. E. D., Shouman, M. A., & Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. arXiv preprint arXiv:2003.11055.

- Hilton, Marudut Sianturi, & Salman Faris. (2022). the influence of digital marketing and advertising on customer satisfaction with price as a moderating variable (case study of online shopping at shopee. *International Journal of Applied Finance and Business Studies*, 10(1), 47-53. <https://doi.org/10.35335/ijafibs.v10i1.52>
- Hope, T., Resheff, Y. S., & Lieder, I. (2017). *Learning tensorflow: A guide to building deep learning systems*. United States of America: O'Reilly Media, Inc.
- Ibrahim, D. M., Elshennawy, N. M., & Sarhan, A. M. (2021). Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Computers in biology and medicine*, 132, 104348.
- Ismael, S. A. A., Mohammed, A., & Hefny, H. (2020). An enhanced deep learning approach for brain cancer MRI images classification using residual networks. *Artificial intelligence in medicine*, 102, 101779.
- Jakhar, D., & Kaur, I. (2020). Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and experimental dermatology*, 45(1), 131-132.
- Kanani, P., & Padole, M. (2019). Deep learning to detect skin cancer using google colab. *International Journal of Engineering and Advanced Technology Regular Issue*, 8(6), 2176-2183.
- Jiao, L., & Zhao, J. (2019). A survey on the new generation of deep learning in image processing. *IEEE Access*, 7, 172231-172263.
- Karim, F. (2022). Optimalisasi pencatatan nikah terhadap fenomena perkawinan sirri di Kabupaten Boalem. *Humantech: Jurnal Ilmiah Multidisiplin Indonesia*, 1(7), 942-948.
- Kazi, M. K., Eljack, F., & Mahdi, E. (2020). Predictive ANN models for varying filler content for cotton fiber/PVC composites based on experimental load displacement curves. *Composite Structures*, 254, 112885.
- Kembuan, O., Rorimpandey, G. C., & Tengker, S. M. T. (2020, October). Convolutional neural network (CNN) for image classification of Indonesia sign language using Tensorflow. In 2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS) (pp. 1-5). IEEE.
- Kim, R. Y. (2020). The impact of COVID-19 on consumers: Preparing for digital sales. *IEEE Engineering Management Review*, 48(3), 212-218.
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of emerging technologies in accounting*, 14(1), 115-122.
- Kothari, J. D. (2018). A case study of image classification based on deep learning using TensorFlow. *International Journal of Innovative Research in Computer and Communication Engineering*, 6(7), 3888-3892.
- Krizanova, A., Lăzăroi, G., Gajanova, L., Kliestikova, J., Nadanyiova, M., & Moravcikova, D. (2019). The effectiveness of marketing communication and importance of its evaluation in an online environment. *Sustainability*, 11(24), 7016
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Li, S. (2018). *Application of recurrent neural networks in toxic comment classification* (Doctoral dissertation, The University of California).
- Lipovetsky, S. (2009). Pareto 80/20 law: derivation via random partitioning. *International Journal of Mathematical Education in Science and Technology*, 40(2), 271-277.
- Ma, J., & Li, Q. (2005, June). The key factors influence customer purchase decision on retail web site. In *Proceedings of ICSSSM'05. 2005 International Conference on Services Systems and Services Management, 2005*. (Vol. 1, pp. 223-226). IEEE.
- March, S. T., & Storey, V. C. (2008). Design science in the information systems discipline: an introduction to the special issue on design science research. *MIS quarterly*, 725-730.
- McBee, M. P., Awan, O. A., Colucci, A. T., Ghobadi, C. W., Kadom, N., Kansagra, A. P., ... & Auffermann, W. F. (2018). Deep learning in radiology. *Academic Radiology*, 25(11), 1472-1480.
- Mintz, Y., & Brodie, R. (2019). Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy & Allied Technologies*, 28(2), 73-81.
- Otoni, A. L. C., de Amorim, R. M., Novo, M. S., & Costa, D. B. (2023). Tuning of data augmentation hyperparameters in deep learning to building construction image classification with small datasets. *International Journal of Machine Learning and Cybernetics*, 14(1), 171-186.
- O'Shea, K., & Nash, R. (2015). *An introduction to convolutional neural networks*. Ithaca: Cornell University Library.
- Peffers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A design science research methodology for information systems research. *Journal of management information systems*, 24(3), 45-77.

- Phung, V. H., & Rhee, E. J. (2018). A deep learning approach for classification of cloud image patches on small datasets. *Journal of information and communication convergence engineering*, 16(3), 173-178.
- Phung, V. H., & Rhee, E. J. (2019). A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences*, 9(21), 4500.
- Plant, R. (2011). An introduction to artificial intelligence. In *32nd Aerospace Sciences Meeting and Exhibit* (p. 294).
- Rahmatyah, S. (2022). Analisis Kualitas Pelayanan Pajak Kendaraan Bermotor (Pkb) Dan Surat Tanda Nomor Kendaraan (Stnk) Pada SAMSAT Wilayah Kota Kendari. *Sibatik Journal: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, Dan Pendidikan*, 1(11), 2371-2382.
- Samraj, A., Sowmiya, D., Deepthisri, K. A., & Oviya, R. (2020, November). Food genre classification from food images by deep neural network with tensorflow and Keras. In *2020 Seventh International Conference on Information Technology Trends (ITT)* (pp. 228-231). IEEE.
- Shahinfar, S., Meek, P., & Falzon, G. (2020). "How many images do I need?" Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring. *Ecological Informatics*, 57, 101085.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Supriyadi, E. I., & Asih, D. B. (2020). Implementasi Artificial Intelligence (Ai) Di Bidang Administrasi Publik Pada Era Revolusi Industri 4.0. *Jurnal RASI*, 2(2), 12-22.
- Supriyanto, A., Benty, D. D. N., & Rochmawati. (2019). Kaizen: Quality Improvement Innovation Higher Education in the Industrials Revolution 4.0. *The 4th International Conference on Education and Management (COEMA 2019)*, 108-113.
- Sutarto. (2015). *Manajemen Mutu Terpadu (MMT-TQM) - teori dan penerapan di lembaga pendidikan*. UNY Press.
- van Noordt, C., & Misuraca, G. (2022). Artificial intelligence for the public sector: results of landscaping the use of AI in government across the European Union. *Government Information Quarterly*, 39(3), 101714.
- Venable, J., Pries-Heje, J., & Baskerville, R. (2012). A comprehensive framework for evaluation in design science research. In *Design Science Research in Information Systems. Advances in Theory and Practice: 7th International Conference, DESRIST 2012, Las Vegas, NV, USA, May 14-15, 2012. Proceedings 7* (pp. 423-438). Springer Berlin Heidelberg.
- Wen, Q., Sun, L., Yang, F., Song, X., Gao, J., Wang, X., & Xu, H. (2022). *Time series data augmentation for deep learning: A survey*. Ithaca: Cornell University Library, arXiv.org. doi:https://doi.org/10.24963/ijcai.2021/63_1.
- Wicaksono, W. A. (2023). Implementasi continuous improvement pada aktivitas belajar di pondok pesantren. *Evaluasi: Jurnal Manajemen Pendidikan Islam*, 7(1), 22-33.
- Widiyanto, I., & Prasilowati, S. L. (2015). Perilaku pembelian melalui internet. *Jurnal manajemen dan kewirausahaan*, 17(2), 109-122.
- Wijayati, P. H., Suyata, & Sumarno. (2013). Model Evaluasi Pembelajaran Berbasis Kaizen Di Sekolah Menengah Atas. *Jurnal Penelitian Dan Evaluasi Pendidikan*, 17(2), 318-332. <https://doi.org/https://doi.org/10.21831/pep.v17i2.1703>
- Wisnudhanti, K., & Candra, F. (2020, October). image classification of pandawa figures using convolutional neural network on raspberry Pi 4. In *Journal of Physics: Conference Series* (Vol. 1655, No. 1, p. 012103). IOP Publishing.
- Zaccone, G., & Karim, M. R. (2018). *Deep Learning with TensorFlow: Explore neural networks and build intelligent systems with python*. Birmingham, United States of Kingdom: Packt Publishing Ltd.
- Republik Indonesia (2009). Undang Undang Republik Indonesia Nomor 25 Tahun 2009 tentang Pelayanan Publik
- Republik Indonesia (2020). Peraturan Pemerintah Nomor 62 Tahun 2020 tentang Perubahan atas Peraturan Pemerintah Nomor 3 Tahun 2018 tentang Jenis dan Tarif atas Jenis Penerimaan Negara Bukan Pajak yang berlaku pada Kementerian Keuangan