

Analisis Potensi Lokasi dan Klasifikasi *Electronic Data Capture* (EDC) pada UMKM BNI Agen46

Analysis of Potential Locations and Classification of Electronic Data Capture (EDC) in MSMEs BNI Agen46

FIQHRI MULIANDA PUTRA^{1,4*}, MARIMIN², SONY HARTONO WIJAYA³,
REINALDY JALU NUSANTARA⁴

Abstrak

Dalam era digitalisasi, peran agen-agen bank menjadi semakin penting dalam memberikan layanan keuangan kepada masyarakat. Bank BNI sebagai salah satu bank terkemuka di Indonesia, memiliki jaringan agen yang luas untuk mendekatkan layanan perbankan kepada nasabah. Dalam upaya mengoptimalkan jaringan agennya, Bank BNI melakukan analisis spasial menggunakan metode *clustering K-means* untuk menentukan lokasi potensial pendirian Agen46 baru di DKI Jakarta. Selain itu, juga dilakukan pembuatan model klasifikasi *random forest* Agen46 produktif dan non-produktif untuk mengoptimalkan penggunaan mesin EDC dan menghemat biaya operasional. Berdasarkan analisis spasial dengan metode *clustering K-means*, ditemukan tujuh lokasi potensial untuk pendirian Agen46 baru di DKI Jakarta, yaitu kecamatan Jagakarsa, Makasar, Pesanggrahan, Grogol Petamburan, Taman Sari, Tambora, dan Johar Baru. Model klasifikasi yang dibuat berhasil membedakan Agen46 yang produktif dan non-produktif dengan akurasi yang tinggi. Selain itu, pembuatan model klasifikasi Agen46 menjadi penting dalam mengenali agen-agen yang tidak produktif, sehingga dapat dilakukan antisipasi dan penanggulangan yang cepat untuk memperbaiki efisiensi penggunaan mesin EDC. Hasil analisis prediksi dan model klasifikasi ini diharapkan dapat memberikan panduan dan dasar kebijakan yang lebih baik bagi Bank BNI dalam menentukan lokasi penempatan mesin EDC Agen46 di masa depan. Dengan demikian, diharapkan Bank BNI dapat mempercepat proses pengklasifikasian Agen46, meningkatkan pemanfaatan mesin EDC, dan mengoptimalkan efisiensi biaya terkait dengan agen-agen BNI.

Kata Kunci: Agen46, bank, BNI, *electronic data capture*, *K-means*, klasifikasi, *random forest*

Abstract

In the era of digitalization, the role of bank agents has gained increasing significance in delivering financial services to the public. Bank BNI, a prominent financial institution in Indonesia, has established an extensive network of agents to facilitate access to banking services for customers. In an effort to optimize its agent network, Bank BNI conducts spatial analysis using the K-means Clustering method to determine potential locations for establishing new Agen46 outlets in DKI Jakarta. Additionally, a random forest classification model for productive and non-productive Agen46 agents is developed to optimize the use of EDC machines and save operational costs. Based on the spatial analysis using the K-means Clustering method, seven potential locations for new Agen46 outlets in DKI Jakarta are identified, namely the districts of Jagakarsa, Makasar, Pesanggrahan, Grogol Petamburan, Taman Sari, Tambora, and Johar Baru. The classification model demonstrates high accuracy in distinguishing between productive and non-productive Agen46 agents. Moreover, the Agen46 classification model plays a crucial role in identifying non-productive agents, enabling timely intervention and mitigation measures to improve the efficiency of EDC machine usage. The results of the prediction analysis and classification model are expected to provide better guidance and policy foundation for Bank BNI in determining the placement locations of Agen46 EDC machines in the future. Thus, it is anticipated that Bank BNI can expedite the Agen46 classification process, enhance the utilization of EDC machines, and optimize cost efficiency related to BNI agents.

Keywords: Agen46, bank, BNI, *clustering*, *classification*, *electronic data capture*, *K-means*, *random forest*

¹ Program Studi Profesi Insinyur, Sekolah Pascasarjana, IPB University;

² Departemen Teknologi Industri Pertanian, Fakultas Teknologi Pertanian, IPB University;

³ Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, IPB University;

⁴ Data Management and Analytics, PT Bank Negara Indonesia (Persero) Tbk, Jakarta;

* Penulis Korespondensi: Tel/Faks: +6281281796176; Surel: fiqhrmulianda@ipb.ac.id, fiqhrmp@gmail.com

PENDAHULUAN

Perbankan merupakan sektor yang memiliki peran penting dalam perekonomian, dan Bank BNI (PT Bank Negara Indonesia (Persero) Tbk) merupakan salah satu bank pemerintah yang mendapatkan kepercayaan dari masyarakat di Indonesia. Keputusan masyarakat dalam memilih Bank BNI sebagai tempat menabung dipengaruhi oleh faktor-faktor seperti reputasi bank, layanan nasabah, keamanan, kenyamanan, dan kemudahan bertransaksi (Anggraini dan Dewi 2021). Kemajuan teknologi komputer juga membawa dampak signifikan dalam bisnis jasa perbankan, dimana peningkatan kualitas layanan dapat meningkatkan kepuasan nasabah dan mendorong penggunaan layanan perbankan yang lebih luas (Sari dan Wati 2020).

Keberhasilan pemerintah Indonesia dalam meningkatkan indeks inklusi keuangan melalui OJK tidak terlepas dari berbagai upaya yang dilakukan, termasuk melalui inovasi layanan *branchless banking* yang sangat penting. *Branchless banking* merupakan program penyediaan layanan perbankan atau layanan keuangan melalui kerjasama dengan pihak lain, didukung oleh teknologi informasi, dengan tujuan untuk menyentuh jasa keuangan hingga pelosok desa.

Branchless banking memiliki dampak positif yang signifikan terhadap inklusi keuangan. Program ini telah membantu memberikan layanan perbankan dasar kepada masyarakat dengan kondisi ekonomi rendah, serta efektif dalam mengurangi biaya dan waktu akses terhadap layanan perbankan. Keberadaan *branchless banking* mendorong lembaga perbankan di Indonesia untuk mengembangkan berbagai layanan keuangan guna mendorong inklusi keuangan. Salah satunya adalah PT Bank Negara Indonesia (Persero) Tbk yang telah mengembangkan inovasi layanan keuangan terkait inklusi keuangan melalui Agen46. Penelitian Ainiyah *et al.* (2021) menunjukkan bahwa sebagai penyedia layanan keuangan tanpa kantor untuk *financial inclusion*, keberadaan Agen46 sangat bermanfaat bagi masyarakat Banjarnegara dalam memenuhi kebutuhan layanan keuangan mereka.

Inklusi keuangan tidak hanya memiliki dampak positif terhadap pertumbuhan ekonomi (Sarma dan Pais 2011), tetapi juga meningkatkan pertumbuhan yang inklusif dan mengurangi kesenjangan regional (Hanning dan Jensen 2010). Akses terhadap layanan keuangan juga memungkinkan masyarakat dari kalangan menengah ke bawah untuk berpartisipasi dalam kegiatan ekonomi produktif seperti pendidikan dan kewirausahaan, sehingga memungkinkan mereka keluar dari perangkap kemiskinan (Demirguc Kunt dan Klapper 2013). Selain itu, dari perspektif makro, inklusi keuangan juga berkontribusi terhadap stabilitas keuangan suatu negara (Han dan Melecky 2013).

Bank BNI memiliki visi misi untuk meningkatkan pemasaran produk melalui layanan digital dan BNI Agen46. BNI Agen46 adalah agen perbankan yang menyediakan layanan perbankan kepada masyarakat melalui Layanan Laku Pandai, Layanan Keuangan Digital (LKD), dan Layanan e-Payment. Pada tahun 2021, jumlah BNI Agen46 telah mencapai 157,632 dan menjangkau 499 kota/kabupaten di seluruh Indonesia (PT Bank Negara Indonesia (Persero) Tbk 2021).

Penelitian yang dilakukan oleh Putri *et al.* (2023) terkait faktor-faktor yang mempengaruhi penerapan pembayaran digital pada Usaha Mikro, Kecil, dan Menengah (UMKM) di Surakarta dalam menghadapi era revolusi industri 4.0 menunjukkan beberapa temuan. Persepsi kemudahan penggunaan berpengaruh terhadap persepsi kemanfaatan dan sikap UMKM di Kota Surakarta dalam menerapkan pembayaran digital. Selain itu, persepsi kemanfaatan juga mempengaruhi sikap dan niat UMKM di Kota Surakarta untuk menerapkan pembayaran digital. Kepercayaan juga berpengaruh terhadap sikap dan niat UMKM di Kota Surakarta dalam menerapkan pembayaran digital, sedangkan sikap juga mempengaruhi niat UMKM di Kota Surakarta untuk menerapkan pembayaran digital.

Pemanfaatan mesin EDC (*Electronic Data Capture*) sebagai media transaksi non-tunai juga menjadi perhatian dalam industri perbankan. Faktor-faktor seperti kemudahan penggunaan,

manfaat, biaya, dan keamanan memengaruhi pemanfaatan mesin EDC oleh Usaha Mikro, Kecil, dan Menengah (UMKM) (Sutrisno dan Wijaya 2018). Kemudahan penggunaan mesin EDC penting bagi UMKM karena dapat memperlancar proses pembayaran dan mengurangi kesalahan transaksi. Selain itu, manfaat yang dirasakan oleh UMKM seperti efisiensi waktu dan peningkatan kepercayaan pelanggan juga menjadi faktor yang memengaruhi adopsi mesin EDC. Penelitian Nurfadilah *et al.* (2020) menganalisis pengaruh manajemen pelanggan *merchant* EDC dan agen46 terhadap peningkatan jumlah pelanggan di Kantor Cabang BNI Ltd Sengkang. Hasilnya menunjukkan bahwa manajemen pelanggan *merchant* EDC dan Agen46 memiliki pengaruh positif dan signifikan terhadap peningkatan jumlah pelanggan. Manajemen pelanggan *merchant* EDC memiliki pengaruh dominan dalam meningkatkan jumlah pelanggan.

Penelitian oleh Ma'arif dan Nursyamsi (2021) mengenai faktor-faktor yang mempengaruhi pemanfaatan mesin EDC sebagai media transaksi non-tunai pada UMKM di Bank Rakyat Indonesia Cabang Semarang menunjukkan bahwa kemudahan penggunaan, manfaat, biaya, dan keamanan memiliki pengaruh signifikan terhadap pemanfaatan mesin EDC oleh UMKM. Dalam upaya meningkatkan pemanfaatan mesin EDC pada UMKM, penelitian tersebut merekomendasikan Bank Rakyat Indonesia Cabang Semarang untuk memberikan pelatihan penggunaan mesin EDC yang efektif dan efisien, serta menawarkan biaya yang terjangkau bagi para pemilik UMKM. Penelitian lain yang dilakukan oleh Lestari dan Dewi (2020) menggunakan analisis kluster dengan algoritma *K-means* untuk menganalisis data transaksi EDC di Surabaya. Hasil analisis menunjukkan bahwa data transaksi EDC dapat dikelompokkan menjadi tiga kelompok, yang mewakili pola perilaku pelanggan yang berbeda. Hal ini menunjukkan bahwa analisis potensi dan pola transaksi EDC dapat membantu dalam memahami kebutuhan dan preferensi pelanggan dalam penggunaan layanan perbankan.

Penelitian lain dilakukan oleh Hussain R *et al.* (2019) menggunakan metode *random forest* untuk memprediksi kesulitan keuangan bank Islam di Malaysia. Hasil penelitian tersebut menunjukkan bahwa model *random forest* dapat memprediksi dengan akurat kesulitan keuangan bank Islam di Malaysia. Penggunaan metode ini dapat memberikan wawasan yang lebih baik dalam mengidentifikasi risiko dan mengambil tindakan yang tepat untuk menjaga stabilitas keuangan bank. Metode *Analytical Hierarchy Process* (AHP) dan Sistem Informasi Geografis (SIG) juga dapat digunakan dalam menentukan potensi lokasi ATM BNI di suatu wilayah, seperti yang ditunjukkan oleh Hutagaol dan Sudarsono (2015). Penelitian ini memberikan rekomendasi lokasi ATM yang optimal berdasarkan kriteria seperti kepadatan penduduk, aksesibilitas, dan keberadaan kompetitor. Pendekatan ini dapat membantu Bank BNI dalam mengidentifikasi lokasi yang strategis untuk memperluas jangkauan layanan perbankan dan meningkatkan aksesibilitas bagi nasabah.

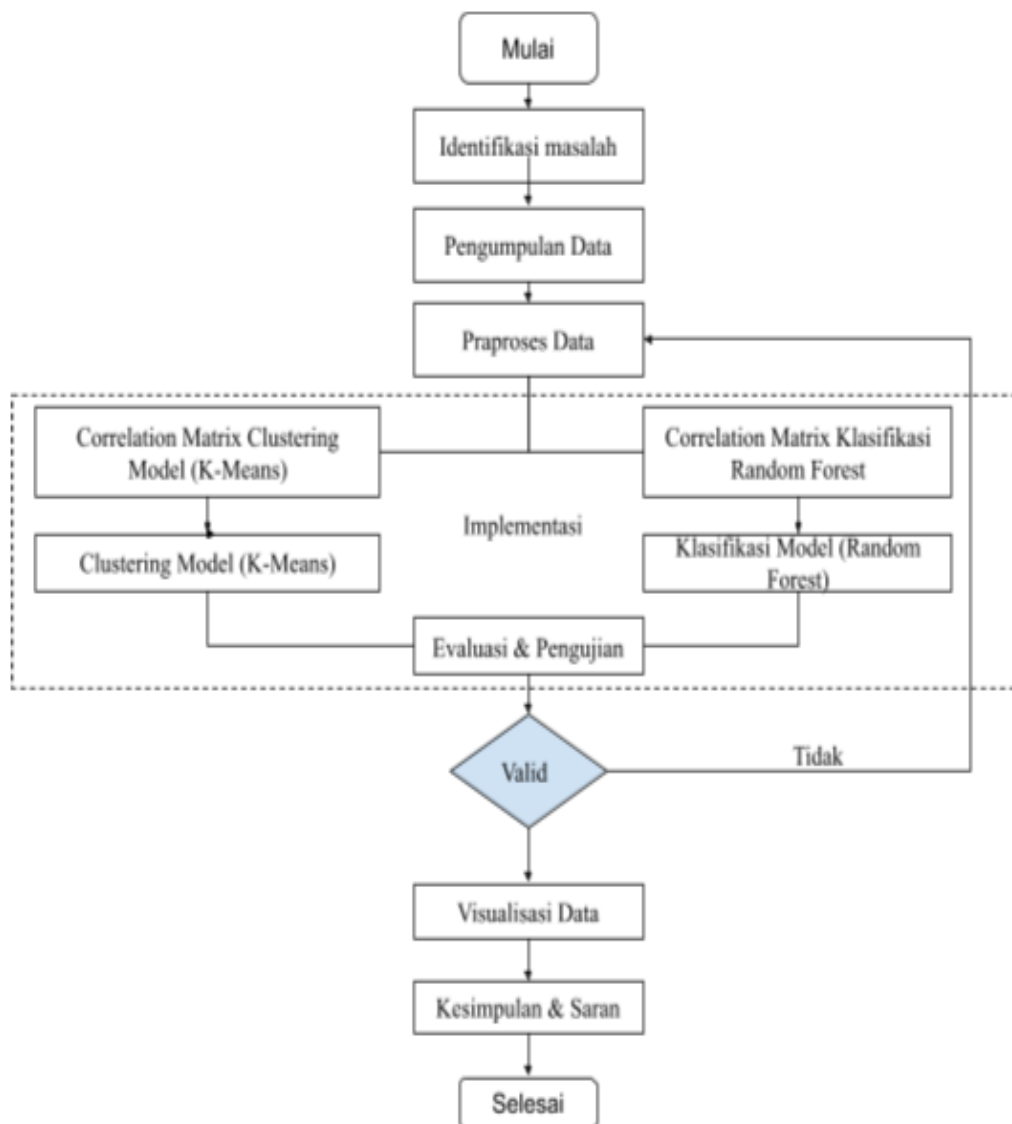
Dalam konteks Bank BNI di DKI Jakarta, disarankan untuk melakukan analisis potensi Agen46 menggunakan metode *K-means* dan prediksi Agen46 produktif dan non-produktif dengan metode *random forest*. Penggabungan analisis potensi lokasi menggunakan metode clustering *K-means* dan klasifikasi menggunakan metode *random forest* membuat Bank BNI dapat memperoleh pemahaman yang lebih baik tentang UMKM BNI Agen46, yang berpotensi menggunakan EDC secara aktif dan menguntungkan. Pendekatan ini akan memungkinkan Bank BNI untuk mengoptimalkan strategi pemasaran dan penyebaran Agen46 di wilayah-wilayah dengan potensi tinggi, serta memberikan pendekatan yang lebih terarah dalam memberikan layanan dan dukungan kepada UMKM BNI Agen46. Selain itu, penting bagi Bank BNI untuk melakukan analisis mendalam terhadap perilaku masyarakat dalam menggunakan mesin EDC guna memperkuat posisinya dalam industri perbankan dan meningkatkan kepuasan nasabah. Dengan memahami preferensi, kebutuhan, dan harapan nasabah terkait penggunaan mesin EDC, Bank BNI dapat mengembangkan strategi yang lebih efektif dalam meningkatkan penerimaan dan adopsi teknologi tersebut.

METODE

Tahap penelitian yang dilakukan meliputi identifikasi masalah, pengumpulan data, pra proses data, *modelling clustering* menggunakan *K-means*, klasifikasi menggunakan *random forest*, visualisasi data, evaluasi hasil, dan penarikan kesimpulan dan saran. Gambar 1 menjelaskan alur dari penelitian yang dilakukan.

Pengumpulan Data

1. Studi literatur atau pustaka adalah tahap awal dalam teknik pengumpulan data pada suatu studi kasus. Metode ini dilakukan dengan cara mencari sumber referensi dari berbagai buku, karya ilmiah, dan jurnal yang dianggap penting dan mendukung. Pada tahap ini, dilakukan telaah terhadap sumber pustaka untuk mendukung studi kasus secara utuh. Telaah pustaka dapat dimulai dari mengkaji studi kasus terdahulu serta melihat teori-teori yang digunakan untuk mendukung studi kasus, seperti buku, jurnal, atau paper yang berkorelasi dengan topik analisis geospasial *clustering K-means* dan klasifikasi *random forest*.
2. *Data collection*. Area studi adalah wilayah DKI Jakarta. Data yang digunakan dalam studi kasus ini adalah data EDC Agen46 pada Januari 2022, data Agen46 yang disetujui, dan data demografi Jakarta dari BPS. Data dibagi menjadi 2 kelompok, yaitu data internal dan data eksternal. Pada tahap pemilihan data internal, dari 51 atribut yang tersedia, dipilih 24 atribut dapat dilihat pada Tabel 1.



Gambar 1 Alur penelitian

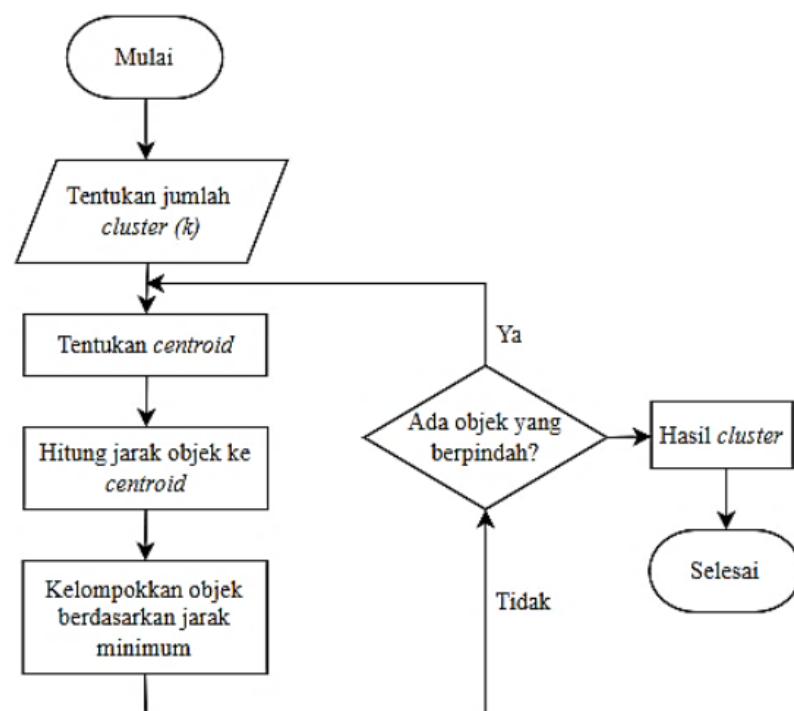
Tabel 1 Data Eksternal dan Internal

Data Eksternal	Data Internal
Jumlah ATM, jumlah EDC, jumlah transaksi, volume penjualan, casa <i>merchant</i> , casa <i>non-merchant</i> , alamat kecamatan, <i>latitude</i> , <i>longitude</i> .	Data demografi Jakarta kota, kecamatan, luas (km ²), jumlah penduduk, harga rata-rata rumah, kepadatan penduduk, serta <i>latitude</i> dan <i>longitude</i> .
Jumlah tabungan, saldo tabungan, jumlah giro, saldo giro, jumlah deposito, saldo deposito, jumlah pinjaman, baki debit pinjaman.	Data administrasi DKI Jakarta disajikan dalam format json.
Volume penjualan bulan ini, volume penjualan satu bulan sebelumnya, volume penjualan dua bulan sebelumnya.	
Jumlah transaksi bulan ini, jumlah transaksi satu bulan sebelumnya, jumlah transaksi dua bulan sebelumnya, kategori.	

Praproses Data

Setelah data terkumpul, tahap selanjutnya adalah pra-pengolahan yang meliputi pembersihan data dan penggabungan dataset.

1. Pembersihan data. Pada tahap ini, dilakukan penghapusan data duplikat dengan menggunakan fungsi *remove duplicates*. Selain itu, nilai-nilai yang hilang akan ditangani dengan metode tertentu, seperti menggantinya dengan nilai 0 atau rata-rata dari data. Proses pembersihan *missing value* penting untuk memudahkan pembelajaran algoritma *machine learning* yang digunakan.
2. Penggabungan data. Untuk *clustering*, digunakan 6 variabel yaitu kecamatan, harga rata-rata rumah, kepadatan penduduk, jumlah Agen46 per kecamatan, jumlah ATM per kecamatan, dan jumlah transaksi *current month*. Sedangkan untuk klasifikasi, digunakan 20 variabel yaitu jumlah EDC, jumlah transaksi, *sales volume*, casa *merchant*, casa *non-merchant*, jumlah tabungan, saldo tabungan, jumlah giro, saldo giro, jumlah deposito, saldo deposito, jumlah pinjaman, baki debit pinjaman, sales volume *current month*, sales volume 1 bulan sebelumnya, sales volume 2 bulan sebelumnya, jumlah transaksi *current month*, jumlah transaksi 1 bulan sebelumnya, jumlah transaksi 2 bulan sebelumnya, dan kategori.



Gambar 2 Flowchart K-means

Matriks Korelasi

Pada tahap ini, dilakukan proses matriks korelasi untuk menunjukkan keterkaitan antara kumpulan atribut setelah data dibersihkan pada tahap sebelumnya. Setiap atribut acak (X_i) dalam tabel berkorelasi dengan masing-masing nilai lain dalam tabel (X_j). Nilai besar dalam matriks ini menunjukkan adanya kolinearitas yang serius antara atribut yang terlibat. Hal ini memungkinkan kita untuk melihat pasangan antar atribut yang memiliki korelasi tertinggi.

Matriks korelasi memastikan bahwa semua atribut memiliki dasar yang sama dalam hal analisis, sehingga setiap analisis dapat digambarkan sebagai analisis saling ketergantungan. Masalah yang terjadi adalah terkadang atribut tidak memiliki status yang sama. Dalam kasus seperti itu, peneliti dapat memeriksa bagaimana beberapa atribut bergantung pada yang lain dan mungkin tertarik untuk mengetahui bagaimana urutan berikutnya bergantung pada yang datang lebih awal.

Modelling

Ada 2 tahap *modelling* yang dilakukan yaitu sebagai berikut:

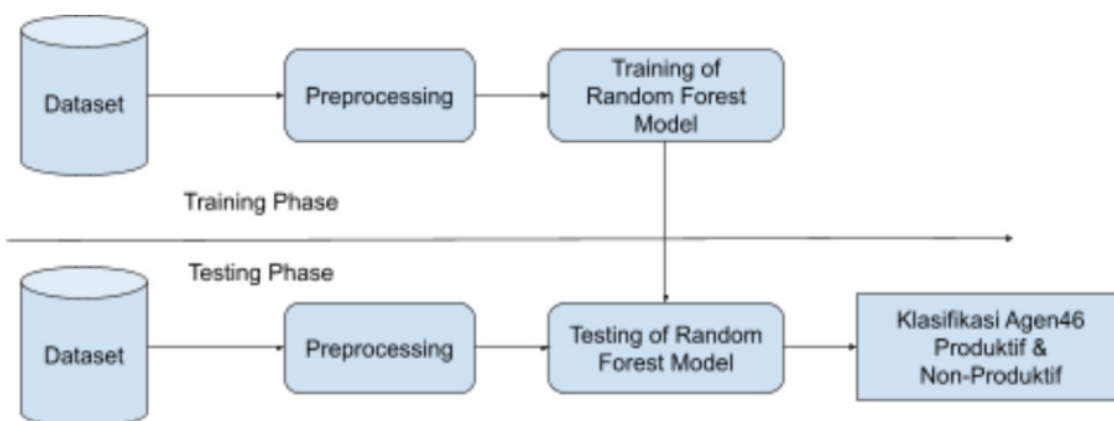
1. Clustering model

Tahap ini merupakan tahap implementasi algoritma *K-means* atau pemodelan data dengan *K-means*. Tahap implementasi *clustering* daerah potensi lokasi Agen46 menggunakan *K-means* dapat dilihat dalam *flowchart* pada Gambar 2 (Jain *et al.* 1999). Tahap *clustering* menggunakan *K-means*, berdasarkan Gambar 3.2, terdiri dari langkah-langkah berikut:

- Menentukan jumlah *cluster* (k) - tahap awal dalam menentukan jumlah *cluster*, pada penelitian ini menggunakan 7 *cluster*.
- Menentukan *centroid* - satu pusat data dipilih untuk mewakili suatu *cluster*.
- Menghitung jarak objek ke *centroid* - jarak antara objek dan *centroid* dihitung menggunakan persamaan *euclidean distance* pada persamaan 1.
- Mengelompokkan objek berdasarkan jarak minimum - objek dikelompokkan ke dalam *cluster* berdasarkan jarak minimum terhadap *centroid*, sehingga didapatkan 3 *cluster* dengan beberapa objek sebagai anggota *cluster*.
- Memperhatikan perpindahan objek - jika objek mengalami perpindahan *cluster*, maka proses diulang dari tahap 2. Namun jika tidak terdapat perpindahan objek terhadap *cluster*, maka iterasi selesai.

2. Klasifikasi model

BNI Agen46 diklasifikasikan ke dalam kelas produktif dan non-produktif yang ada berdasarkan label dengan menggunakan algoritma *random forest*. Data yang telah melewati *preprocessing* data akan dibagi menjadi 2 bagian yaitu data *training* dan data *testing* seperti yang ditunjukkan pada Gambar 3.



Gambar 3 Tahapan *modelling random forest*

Pada tahap ini dilakukan proses klasifikasi dengan menggunakan algoritma *random forest*. Pada tahap ini, mesin akan diajari untuk mengenali pola atau dokumen yang ada agar dapat mengklasifikasikan sebuah data ke dalam dua kelas, yaitu kelas positif dan kelas negatif. Data yang sudah melalui proses *preprocessing* dibagi menjadi dua bagian, yaitu data *training* dan data *testing* (Breiman L 2001). Berikut ini adalah langkah-langkah algoritma *random forest* dalam melakukan klasifikasi:

- a. Buat sampel D_i dengan mengambil data secara acak dari dataset D .
- b. Gunakan sampel data D_i untuk membangun tree ke- i ($i=1, 2, \dots, k$).
- c. Ulangi langkah satu dan dua sebanyak k kali.
- d. Hitung suara (*vote*) untuk setiap target yang diprediksi dari setiap *tree*.
- e. Hasil klasifikasi didapat dengan menghitung suara terbanyak dari *tree* yang dibangun.

Implementasi dan Pengujian

Implementasi dilakukan dengan menggunakan *jupyter notebook* dengan bahasa pemrograman *python*. Tahap pengujian dilakukan untuk menguji kinerja mesin yang telah dibangun, menghitung akurasi dan mengidentifikasi klasifikasi dari algoritma *random forest* dengan menggunakan *confusion matrix*. *Confusion matrix* didapatkan dengan menghitung *accuracy*, *precision*, *recall*, dan *f1-score*. Pengukuran kinerja yang digunakan adalah *f1-score* karena jumlah antar kelas tidak seimbang. Kemudian digunakan juga indeks *jaccard* dan *log loss*. Pada tahap pengujian, dataset dipisahkan menjadi data latih dan data uji (*splitting data*) menjadi 70%:30%.

Visualisasi Data

Pada tahap ini, visualisasi dilakukan menggunakan *library Folium* untuk memvisualisasikan hasil *clustering* potensi Agen46 di DKI Jakarta dalam bentuk visualisasi spasial.

Kesimpulan dan Saran

Tahapan ini merupakan tahapan akhir dari penelitian, dimana hasil dari penelitian ini ditarik kesimpulan dan saran untuk penelitian selanjutnya.


HASIL DAN PEMBAHASAN

Evaluasi Hasil *Clustering* Lokasi Agen46

Berikut ini adalah visualisasi sebaran Agen46 yang ada di DKI Jakarta yang ditampilkan pada Gambar 4.

Pada penelitian ini, eksperimen dilakukan dengan menggunakan data yang telah diperoleh dengan menggunakan algoritma *K-means*. Eksperimen pertama adalah dengan mengelompokkan berdasarkan kecamatan. Penentuan daerah potensial lokasi Agen46 menjadi tujuh kategori yang merupakan jumlah kluster (k) terbaik yang ditunjukkan dengan metode siku. Berdasarkan metode *elbow*, jumlah *cluster* menunjukkan penurunan berbentuk siku-siku pada $k=7$. Hal ini menunjukkan bahwa pembagian wilayah potensial Agen46 berdasarkan 7 kategori merupakan nilai *cluster* terbaik.

Setelah mendapatkan nilai *cluster* dari hasil lokasi *clustering* BNI Agen46 berdasarkan kriteria kepadatan penduduk per kecamatan, rata-rata harga rumah per kecamatan, jumlah transaksi per kecamatan, jumlah Agen46 per kelurahan, jumlah ATM BNI per kelurahan muncul perbedaan warna dan didapatkan hasil *cluster* sebanyak 7 *cluster* di DKI Jakarta pada Gambar 5.



Gambar 4 Visualisasi sebaran Agen46 di DKI Jakarta

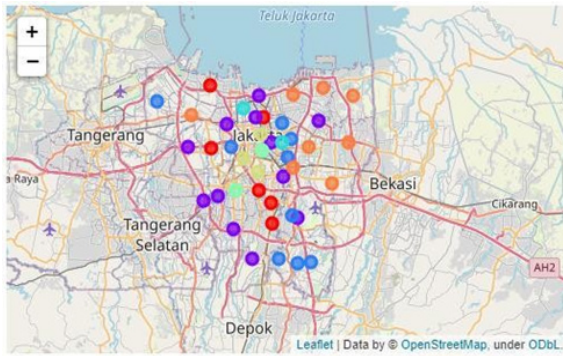
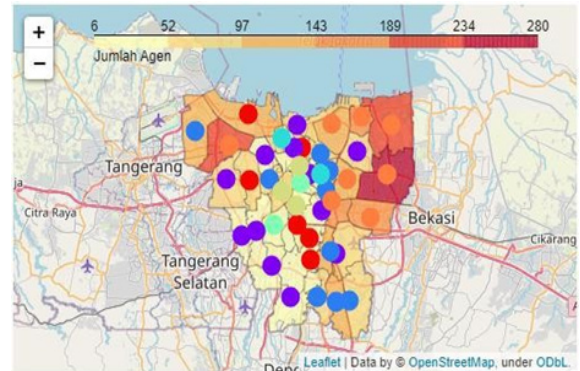
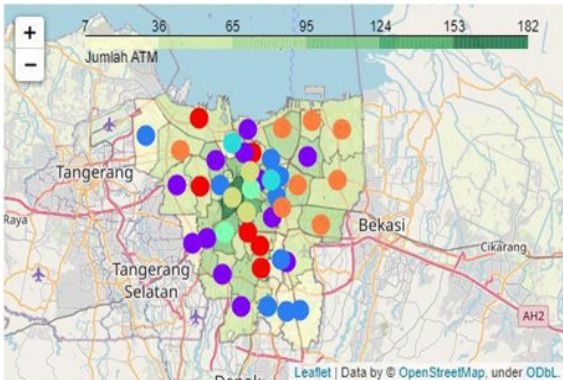
- *Cluster 0* (merah): Agen46 sedang, ATM sedang, transaksi tinggi, harga rumah rendah, kepadatan sedang.
- *Cluster 1* (ungu): Agen46 sedikit, ATM sedang, transaksi rendah, harga rumah sedang, kepadatan sedang.
- *Cluster 2* (biru tua): Agen46 medium, ATM sedikit, transaksi sedang, harga rumah rendah, kepadatan sedang.
- *Cluster 3* (biru muda): Agen46 medium, ATM sedikit, transaksi sedang, harga rumah sedang, kepadatan tinggi.
- *Cluster 4* (hijau): Agen46 sedikit, ATM banyak, transaksi sedang, harga rumah tinggi, kepadatan rendah.
- *Cluster 5* (hijau muda): Agen46 banyak, ATM banyak, Transaksi sedang, harga rumah sedang, kepadatan rendah.
- *Cluster 6* (oranye): Agen46 banyak, ATM sedang, transaksi sedang, harga rumah rendah, kepadatan tinggi.

Berdasarkan hasil *clustering* 42 kelurahan di DKI Jakarta, diperoleh hasil sebagai berikut:

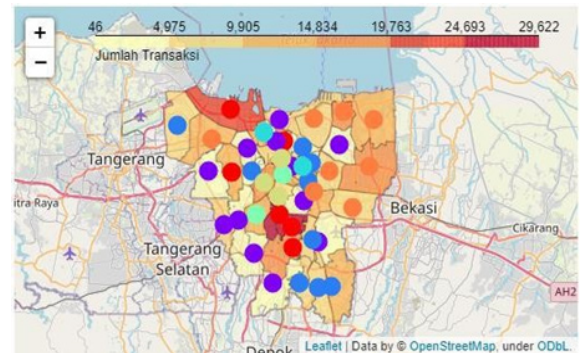
- *Cluster 0*: Pasar Minggu, Penjaringan, Kebon Jeruk, Mampang Prapatan, Pancoran.
- *Cluster 1*: Jagakarsa, Makassar, Pesanggrahan, Grogol Petamburan, Taman Sari, Pademangan, Kelapa Gading, Kembangan, Cilandak, Tebet, Kebayoran Lama, Monday.
- *Cluster 2*: Pasar Rebo, Cipayang, Ciracas, Kramat Jati, Matraman, Kalideres, Palmerah, Kemayoran, Cempaka Putih.
- *Cluster 3*: Tambora, Johar Baru.//
- *Cluster 4*: Kebayoran Baru, Menteng.
- *Cluster 5*: Tanah Abang, Gambir, Setiabudi.
- *Cluster 6*: Duren Sawit, Cakung.

Kemudian hasil visualisasi hasil *cluster* dengan masing-masing variabel dapat dilihat pada Gambar 6, Gambar 7, Gambar 8, Gambar 9, dan Gambar 10.

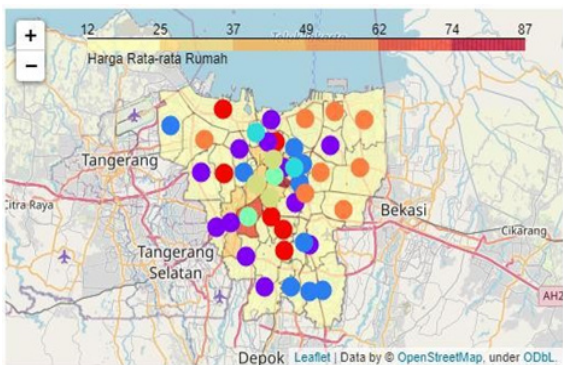
Dari 7 *cluster* yang ada, terdapat 2 *cluster* yang berpotensi untuk menjadi lokasi Agen46. Pertama adalah *cluster 1*, yang memiliki ciri Agen46 sedikit, ATM sedang, transaksi rendah, harga rumah sedang, dan kepadatan sedang. Lokasi *cluster* ini terdapat di kecamatan Jagakarsa, Makassar, Pesanggrahan, Grogol Petamburan, dan Taman Sari. Kedua adalah *cluster 3*, dengan ciri Agen46 sedang, ATM sedikit, transaksi sedang, harga rumah sedang, dan kepadatan tinggi. Lokasi *cluster* ini berada di kecamatan Tambora dan Johar Baru.

Gambar 5 Visualisasi Hasil *cluster*Gambar 6 Hasil *cluster* kecamatan dengan jumlah agen

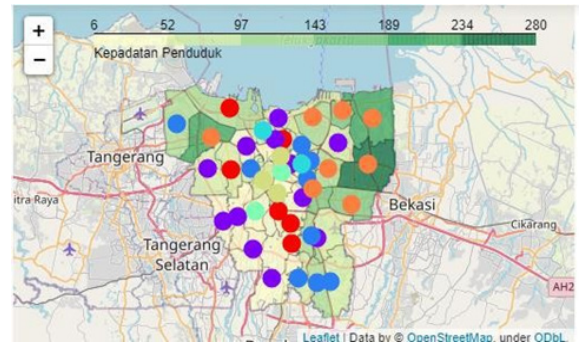
Gambar 7 Hasil visualisasi cluster kecamatan dengan jumlah ATM



Gambar 8 Hasil visualisasi cluster kecamatan dengan jumlah transaksi



Gambar 9 Visualisasi hasil cluster kecamatan dengan rata-rata harga rumah



Gambar 10 Visualisasi hasil cluster kecamatan dengan kepadatan penduduk

Evaluasi Model *Clustering*

Dalam penelitian ini, dilakukan evaluasi model *clustering* menggunakan *correlation matrix*. Hasil perhitungan korelasi dari setiap pasang variabel dapat dilihat pada Gambar 11.

Berdasarkan Gambar 11, korelasi linear positif yang kuat artinya hubungan antar variabel dikatakan positif jika nilai variabel yang satu meningkat, nilai variabel yang lain juga meningkat, semakin cerah warna korelasinya, semakin tinggi korelasinya. Korelasi positif antara variabel jumlah ATM dengan rata-rata harga rumah adalah 0.47, artinya semakin banyak ATM maka semakin tinggi rata-rata harga rumah di daerah tersebut. Selain itu, terdapat hubungan linear antara *jml_trx_cm* dan *sales_volume_cm* dengan angka 0.54. Hal ini menunjukkan bahwa jumlah *trx_cm* di DKI Jakarta berpengaruh terhadap *sales_volume_cm* pada bulan Februari 2022.


Evaluasi Hasil Klasifikasi Agen46

Berdasarkan strategi klasifikasi EDC *merchant* Agen46 yang termasuk kriteria Agen46 produktif adalah adanya transaksi diatas 30 hari atau DPK Agen46 diatas 150 ribu atau CASA non-*merchant* diatas 150 ribu, sedangkan untuk EDC *merchant* Agen46 yang termasuk kriteria non-produktif adalah EDC yang tidak ada transaksi di 3 bulan terakhir.


Agen46 yang tidak produktif berpotensi merugikan BNI. Berdasarkan data EDC Agen46 per Januari 2022, terdapat 85491 mesin EDC, dimana 51832 mesin merupakan EDC aktif dan 33659 mesin merupakan EDC non-aktif dengan kriteria di atas. Mesin EDC pada Agen46 non-produktif yang memiliki nilai prediksi tinggi perlu dipindahkan agar tidak membuang sumber daya. Hal ini tentu membantu pihak bank merencanakan pemasangan mesin EDC di lokasi tertentu dengan lebih tepat sasaran.

Dari Gambar 12 dapat dilihat visualisasi sebaran EDC Agen46 tergolong non-produktif dengan warna hijau dan produktif dengan warna merah. Dari Gambar 13 dapat dilihat visualisasi sebaran EDC Agen46 tergolong non-produktif dengan warna coklat dan produktif dengan warna ungu. Gambar 14 memperlihatkan visualisasi sebaran EDC Agen46 yang non-aktif (tidak adanya transaksi 3 bulan terakhir) dan perlu di-*redeployment*. Warna hijau menggambarkan EDC tergolong produktif, warna hijau tua menunjukkan EDC produktif, sedangkan warna ungu menunjukkan EDC tergolong sangat produktif. Oleh karena itu, EDC Agen46 yang tergolong prioritas *redeployment* bisa ditarik atau dipindahkan ke Agen46 atau *merchant* lainnya.


Berdasarkan data yang dihasilkan dari visualisasi tersebut, diperoleh 991 EDC prioritas *redeployment* di DKI Jakarta dari data yang sudah difilter. Jika biaya operasional EDC adalah Rp 120,000 per bulan, maka *redeployment* dapat menghemat biaya sebesar Rp 118,920,000 pada EDC yang non-produktif. Mesin EDC pada Agen46 non-produktif yang memiliki nilai prediksi tinggi perlu dipindah agar tidak membuang sumber daya. Hal ini tentu akan membantu pihak bank dalam merencanakan pemasangan mesin EDC di lokasi tertentu secara lebih tepat sasaran.



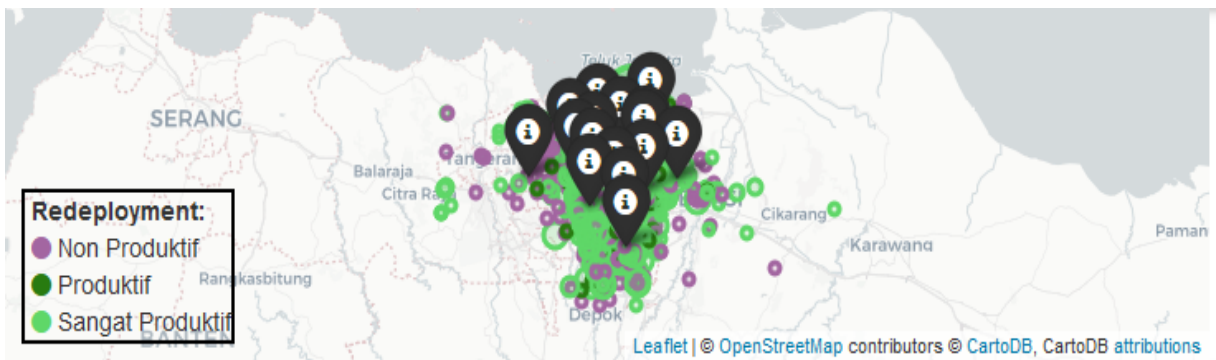
Gambar 11 Correlation matrix variabel clustering



Gambar 12 Agen EDC46 berdasarkan jumlah transaksi bulan ini (Januari 2022)



Gambar 13 EDC Agen46 berdasarkan jumlah transaksi 1 bulan sebelumnya (Desember 2021)



Gambar 14 Visualisasi distribusi EDC Agen46 prioritas untuk redeployment

Dari 85,491 baris data yang telah terkumpul, terdapat 19,920 kuadran produktif dan 65,571 kuadran non-produktif. Dataset yang digunakan tidak seimbang (jumlah data dari setiap kelas target sangat berbeda), sehingga metrik yang digunakan adalah *f1-score*. Agen46 dengan Kelas Non-Produktif 76.7% dan Produktif 23.3%.

Dari Gambar 15 dapat dilihat bahwa Model Kurva ROC *random forest* baik dengan nilai AUC 0.98. Semakin tinggi tingkat *True Positive* (TP) dan semakin kecil tingkat *False Positive* (FP), semakin baik ambangnya. Oleh karena itu, dipilih model dengan AUC terbesar, karena untuk setiap titik memiliki TP yang lebih tinggi dan/atau FP yang lebih rendah. Terkadang untuk data yang tidak seimbang, orang lebih suka menggunakan *precision* daripada *false positive rate*. Karena *precision* tidak memiliki variabel *true negatives* dalam perhitungannya. Presisi = $TP / (TP + FP)$.

Evaluasi Model Klasifikasi *Random Forest*

1. Klasifikasi *Confusion Matrix*

Hasil klasifikasi menggunakan *random forest* yang diukur dengan *confusion matrix* terdapat 14,750 Agen46 non-produktif dan 5 Agen46 produktif yang diklasifikasi sebagai non-produktif. Terdapat 2 Agen46 non produktif dan 2302 Agen46 produktif yang diklasifikasi sebagai produktif.

Pengujian Model dengan akurasi tertinggi berdasarkan *accuracy*, *precision*, *recall*, dan *f1-score* dapat dilihat pada Tabel 2. Berdasarkan uji performansi model yang dibangun sangat baik dilihat dari nilai *accuracy* sebesar 99.98%, *precision* sebesar 99.96%, *recall* sebesar 99.95% dan *F1-score* sebesar 99.92%.

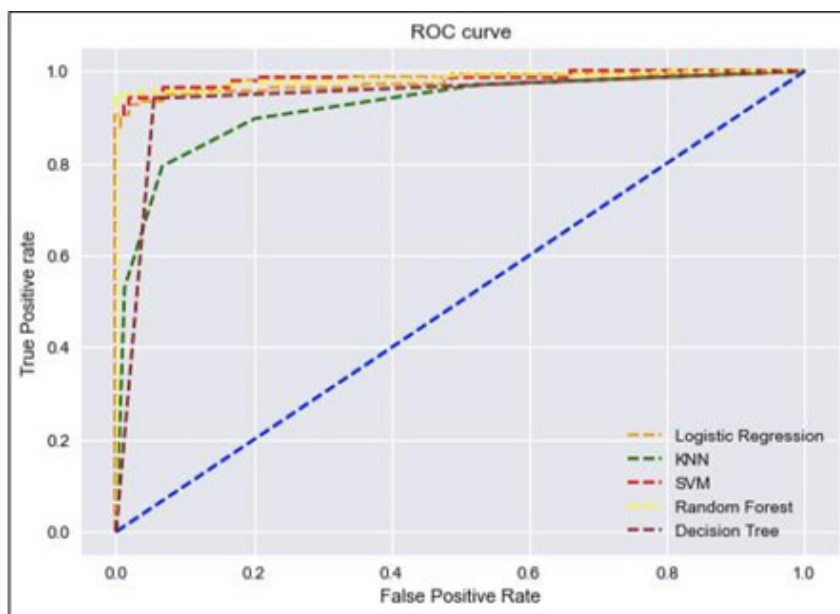
2. Matriks Korelasi dan *Feature Importances*

Pada Gambar 16 terlihat bahwa plot menampilkan *feature importances* (fitur yang berpengaruh) dalam model klasifikasi *random forest*, yaitu fitur *casa_all* dan *casa_non_*

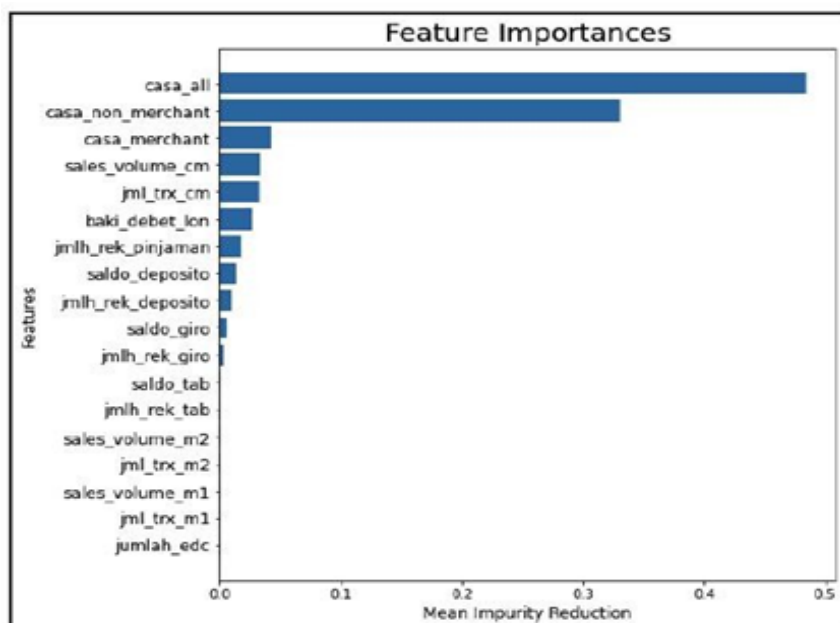
merchant yang paling membantu model untuk membedakan Agen46 produktif dan non-produktif. Kedua fitur tersebut berada di daftar teratas, hal ini tidak mengherankan karena kedua fitur tersebut memang berkorelasi.

3. *Jaccard Index* dan *Log Loss*

Langkah selanjutnya adalah dilakukan pengolahan *jaccard index* untuk melihat evaluasi akurasi hasil pengujian di atas. Dari pengujian tersebut nilai *jaccard index* sebesar 94% yang berarti metode *random forest* berhasil mengklasifikasikan Agen46 dengan tepat. Selanjutnya dicari nilai *log loss* untuk evaluasi. Rentang nilai evaluasi ini adalah dari 0 hingga 1. Dari pengujian yang dilakukan dengan metode *random forest* untuk memprediksi EDC Agen46 di Bank BNI, diperoleh nilai 0.92 yang berarti mendekati 1 dari evaluasi yang terjadi di Bank BNI. Maka dari hasil tersebut berarti mesin EDC yang memiliki nilai prediksi tinggi perlu dipindahkan agar tidak memboroskan sumber daya (*potensial loss*). Hal ini tentunya dapat membantu bank dalam merencanakan dengan baik pemasangan mesin EDC di lokasi tertentu secara lebih tepat sasaran.



Gambar 15 Model klasifikasi kurva ROC dengan AUC 0.98



Gambar 16 Feature importances

SIMPULAN

Dari hasil analisis spasial menggunakan metode *clustering K-means*, dapat disimpulkan bahwa terdapat tujuh lokasi yang berpotensi menjadi lokasi Agen46 BNI yang baru di DKI Jakarta. Lokasi-lokasi tersebut terdapat pada *cluster* satu yang meliputi kecamatan Jagakarsa, Makasar, Pesanggrahan, Grogol Petamburan, dan Taman Sari, serta *cluster* tiga yang meliputi kecamatan Tambora dan Johar Baru. Selanjutnya, berhasil dibuat model klasifikasi Agen46 produktif dan non-produktif dengan akurasi 99% yang diharapkan dapat mempercepat proses pengklasifikasian Agen46.

Hasil dari *clustering* BNI dapat memberikan gambaran umum sebaran Agen46 di DKI Jakarta. Sedangkan hasil dari klasifikasi BNI dapat membantu dalam melakukan antisipasi dan penanggulangan secara cepat terhadap EDC Agen46 yang non-produktif, sehingga dapat menghemat *cost efficiency* terhadap EDC. Dalam hal kebijakan menempatkan mesin EDC Agen46 Bank BNI di daerah yang tepat dan berkembangnya UMKM BNI Agen46, hasil analisis ini dapat membantu pihak bank dalam mendapatkan analisa yang mendalam sehingga dapat menghasilkan keputusan yang lebih baik di masa depan.

DAFTAR PUSTAKA

- Ainiyah GZ, Nurkholik F, Kurniati E. 2021. Analisis Penerapan Agen46 Sebagai Penyedia Layanan Keuangan Tanpa Kantor (Branchless Banking) dan Upaya Pendorong Financial Inclusion. *Medikonis*, 12(2), 20-32. <https://doi.org/10.52659/medikonis.v12i2.41>.
- Anggraini DA, Dewi NK. 2021. Analisis faktor-faktor yang mempengaruhi keputusan masyarakat dalam memilih Bank BNI sebagai tempat menabung. *Journal of Applied Accounting and Taxation*, 4(1), 53-60.
- Breiman L. 2001. *Random Forests*. *Machine learning*, 45(1), 5-32.
- Demirguc KA, Klapper L. 2013. *Measuring Financial Inclusion: The Global Findex Database*. The World Bank.
- Han R, Melecky M. 2013. Financial Inclusion for Stability: Access to Bank Deposits and the Growth of Deposits in the Global Financial Crisis. International Monetary Fund.
- Hanning C, Jensen C. 2010. Financial inclusion, growth, and inequality: A model application to Colombia and Indonesia. *World Development*, 38(6), 834-856.
- Hussain R, Kamaruddin A, Azi SM, N, Ahmad N. 2019. Predicting Financial Distress of Islamic Banks in Malaysia: A *Random forest* Approach. *Journal of Islamic Accounting and Business Research*, 10(3), 466-482.
- Hutagaol V, Sudarsono B. 2015. Penentuan Potensi Lokasi ATM BNI Menggunakan Analytical Hierarchy Process (AHP) dan Sistem Informasi Geografis (SIG) (Studi Kasus: Kecamatan Tembalang). *Jurnal Geodesi Undip* 4(2) 25-32.
- Jain AK, Murty MN, Flynn PJ .1999. *Data Clustering: A review*. *ACM computing surveys (CSUR)*, 31(3), 264-323.
- Lestari YA, Dewi RK. 2020. *Clustering Analysis of EDC Transaction Data Using K-means Algorithm*. *Journal of Physics: Conference Series*, 1535(1), 012060.
- Ma'arif A, Nursyamsi A. 2021. Faktor-faktor yang mempengaruhi pemanfaatan mesin EDC sebagai media transaksi non-tunai pada usaha mikro kecil dan menengah (UMKM) di Bank Rakyat Indonesia Cabang Semarang. *Jurnal Ekonomi Bisnis dan Kewirausahaan*, 15(1), 27-36.
- Nurfadilah AR, Tui S, AR I. 2020. Analisis Pengelolaan Nasabah Merchant EDC dan Agen 46 Terhadap Peningkatan Nasabah Tabungan Pada PT. Bank Negara Indonesia (Persero) Tbk. Kantor Cabang Sengkang. *Master of Management Journal*, 1(2), 222-230.
- Sari EP, Wati DK. 2020. The Effect of Service Quality on Customer Satisfaction in the Banking Sector. *Journal of Applied Management (JAM)*, 18(4), 591-602.

- Sarma M, Pais J. 2011. Financial inclusion and development. *Journal of International Development*, 23(5), 613-628.
- Sutrisno A, Wijaya T. 2018. Analisis Perilaku Penggunaan Kartu Debit Dalam Pembayaran Non-Tunai (Studi Kasus Pada Bank BNI Wilayah Surabaya). *Journal of Chemical Information and Modelling*, 53(9), 1689-1699.
- PT Bank Negara Indonesia (Persero) Tbk. 2021. Annual Report 2020. Diakses pada 22 Februari 2023 dari <https://www.bni.co.id/id-id/tentang-bni/investor-relations/laporan-tahunan-dan-keuangan>.
- Putri I, Hindrayani A, Totalia S. 2023. Faktor-Faktor Yang Memengaruhi Penerapan Metode Pembayaran Digital Pada Usaha Mikro, Kecil, dan Menengah (UMKM) di Surakarta Dalam Menghadapi Era Revolusi Industri 4.0. *Jurnal Pendidikan Ekonomi (JUPE)*, 11(2), 202-211. <https://doi.org/10.26740/jupe.v11n2.p202-211>.