

OPTIMASI AKURASI MODEL DECISION TREE MENGGUNAKAN RANDOM FOREST REGRESSION UNTUK PREDIKSI KUANTITAS PEMBELIAN BARANG PADA PERUSAHAAN MANUFAKTUR

Patlisan

Fakultas Teknologi Informasi, Program Studi Ilmu Komputer
Universitas Budi Luhur
Email: aicc.it84@gmail.com

Rusdah

Fakultas Teknologi Informasi, Program Studi Ilmu Komputer
Universitas Budi Luhur
Email: rusdah@budiluhur.ac.id

ABSTRAK

Decision Tree merupakan algoritma pengklasifikasian yang sudah teruji untuk pengambilan keputusan dalam banyak bidang permasalahan. Permasalahan pembelian dan jumlah kapasitas gudang di sektor manufaktur sangat riskan. Akurasi jumlah pembelian harus dikontrol sehingga dapat mengurangi resiko over kapasitas gudang. Untuk mendapatkan jumlah pembelian dan kapasitas yang ideal perlu identifikasi dan klasifikasi secara detail faktor-faktor permasalahan sistem pembelian dan pengelolaan gudang. Dari hasil penelitian model *Decision Tree* mampu memprediksi jumlah quantity pembelian akan tetapi pada data yang tidak berpola tingkat akurasi sangat kurang baik. Berbeda dengan metode *Random Forest regression* model ini mampu menunjukkan performa dan akurasi yang baik pada data yang berpola ataupun data dengan pola acak. Optimasi dengan *importance variabel* mampu meningkatkan akurasi menjadi 94,87% dari model *random forest regression*.

Kata kunci: *decision tree, random forest regression, gudang.*

ABSTRACT

Decision Tree is a classification algorithm that has been tested for decision-making in many problem areas. The problem of purchasing and the value of warehouse capacity in the manufacturing sector is very risky. The accuracy of the number of purchases must be controlled to reduce the risk of warehouse overcapacity. To get the ideal number of purchases and capacity, it is necessary to identify and classify in detail the factors that cause problems in the purchasing and warehouse management system. From the results of the research, the *Decision Tree* model can predict the amount of purchase quantity, but the data that is not patterned has a very poor level of accuracy. Unlike the *Random Forest regression* method, this model can show good performance and accuracy on patterned data or data with random patterns. Optimization with variable importance can increase the accuracy become 94,87% of the *random forest regression* model.

Keywords: *decision tree, random forest regression, warehouse.*

1. PENDAHULUAN

Warehouse merupakan sistem pergudangan atau logistik yang digunakan oleh perusahaan untuk menyimpan dan menyediakan barang untuk menunjang proses produksi. Untuk mengelola gudang biasanya didukung oleh sistem informasi warehouse management system (WMS). Dimana WMS yang baik dapat memberikan informasi yang akurat terkait keadaan barang.

Salah satu perusahaan manufaktur yang merupakan salah satu pemasok utama untuk suku cadang kopling (Clutch Assy) untuk kendaraan roda dua dan roda empat. Selaku pemasok utama untuk produk OEM (Original Equipment Manufacturer) dan harus menjamin keberlangsungan suku cadang selama minimal

sepuluh tahun dari masa produk dipasarkan. Hal inilah yang membuat sistem persediaan barang dan sistem *traceability* sangat berperan penting dalam menjaga rantai pasokan.

Tantangan pada sistem persediaan barang adalah bagaimana melakukan pengontrolan terhadap jumlah produk dan bahan baku yang cukup bervariasi baik dari segi kuantitas, lokasi dan kapasitas penyimpanan. Pengontrolan kapasitas merupakan tantangan utama, dimana kontrol terhadap *quantity* dan *area storage* gudang menjadi prioritas utama. Hal lain yang menjadi fokus perhatian dari sistem persediaan barang adalah bagaimana menjaga level stok agar tetap stabil di batas ambang bawah bertujuan agar barang yang disimpan memiliki aging yang efisien dan tidak menjadi barang yang tidak bergerak (*dead stock*), sehingga dapat menjaga proses produksi dan mengurangi risiko terhadap penyimpanan bahan baku. Perubahan pesanan dari pelanggan juga dapat mempengaruhi perubahan rencana produksi sehingga sistem pembelian dan persediaan barang sangat berperan penting dalam meminimalkan risiko dari timbulnya biaya tambahan. Ada beberapa faktor yang mempengaruhi permintaan pelanggan diantaranya perubahan permintaan global dan faktor bencana seperti banjir dan gempa bumi atau pandemik seperti covid-19 faktor ini mempengaruhi pada permintaan produk *OEM*. Jika terhadap spare part permintaan akan berubah pada permintaan (*forecast*) kedua. *Forecast* pertama biasanya akan dikirimkan pada akhir bulan berjalan untuk periode bulan berikutnya sedangkan *forecast* kedua dipertengahan bulan berjalan di week kedua atau ketiga.

1.1 Tinjauan Pustaka

Pada penelitian ini akan dibahas mengenai teori *decision tree* dan *random forest* serta teori pendukung seperti *warehouse management system* pada perusahaan manufaktur.

1.1.1 Decision Tree

Decision Tree adalah salah satu metode klasifikasi yang paling populer karena mudah diinterpretasikan oleh manusia. *Decision tree* digunakan untuk penanganan pola dan termasuk dalam pengenalan pola secara statistik.

Decision Tree adalah model prediksi yang dapat digunakan mewakili pengklasifikasian dan model regresi dalam operasi untuk pengambilan keputusan dengan strategi yang kemungkinan besar dapat mencapai tujuan (Rokach and Maimon 2008).

Decision Tree dilatih pada setiap lipatan, dan setiap simpul pohon dapat membagi *binary* item pada satu kriteria. Pemisahan dilakukan dengan mengikuti aturan pemisahan yang telah ditentukan (misalnya indeks Gini). Setiap *Decision Tree* diuji terhadap item yang tidak termasuk dalam lipatan pelatihannya, dan pengujian dilakukan baik untuk pohon dewasa dan untuk semua versi yang dipangkas. Untuk setiap kali lipat dan tingkat pemangkasan, kinerja dalam hal persentase item yang diklasifikasikan dengan benar dalam fase tes dihafal. Untuk setiap tingkat pemangkasan, kinerja rata-rata di antara lipatan dihitung dan tingkat pemangkasan yang mengarah ke kinerja terbaik dipilih. Item milik semua lipatan kemudian digunakan untuk melatih pohon terakhir, dipangkas hingga tingkat pemangkasan terbaik (Lolli et al. 2017).

Pada penelitian *Decision tree analysis approach to determine factors that affect the quote order lead time fulfillment*, (Gangsarwijaya et al. 2020) dengan menggunakan fishbone diagram untuk mengeksplorasi dan mencari alternatif *Leadtime* untuk proses pembelian dengan pendekatan *decision tree* menggunakan metode C5.0 dan J48. Metode ini mampu melakukan klasifikasi dengan menggunakan nilai akurasi tertinggi.

1.1.2 Random Forest

Random forest adalah salah satu algoritma yang sukses menangani dengan mengskalakan volume informasi dengan mempertahankan ke efisiensi statistik (Biau and Scornet 2016).


Algoritma *Random Forest* merupakan *ensemble classifier* yang digunakan untuk meningkatkan akurasi. Metode RF memiliki tingkat kesalahan yang rendah dibandingkan dari algoritma klasifikasi lainnya (Farnaaz and Jabbar 2016).

Keunggulan menggunakan metode RF diantaranya:

1. Hutan (*Forest*) yang dihasilkan dapat disimpan untuk referensi masa mendatang.
2. RF dapat mengatasi masalah *over fitting*.
3. Dalam akurasi RF dan variabel penting akan otomatis dihasilkan.

Saat membangun individual *Tree* di RF dilakukan pengacakan untuk memilih node terbaik untuk dipecah. Disamping itu RF juga menghasilkan *noisy tree* yang dapat mempengaruhi tingkat akurasi dan pengambilan keputusan

Random Forest dapat digunakan dalam masalah klasifikasi dan regresi. Dalam kasus regresi dimulai dengan *node root* dan kemudian dipisahkan berdasarkan hasil variable sampai leaf node tercapai dan hasilnya diberikan. Contoh tree dengan pola regresi dapat dilihat pada gambar 1.



Gambar 1. Contoh Tree dengan pola regresi [1]

Dari tinjauan studi *Applications of random forest feature selection for fine- scale genetic population assignment* (Sylvester et al.2018) dengan fokus permasalahan populasi genetik satwa penelitian ini menunjukkan metode *Random forest* dapat meningkatkan akurasi genome. Sedangkan penelitian *Random Forest vs Logistic Regression: Binary Classification for Heterogeneous Datasets*, (Kirasi ch, Smith and Sadler, 2018) ini menunjukkan metode random forest dapat meningkatkan akurasi secara konsisten.

1.1.3 Warehouse Management System

Warehouse management system adalah suatu sistem informasi yang dapat memenuhi kebutuhan dan dapat memberikan informasi stok secara akurat yang dikelola dengan baik, secara operasional dan secara penempatan lokasi (Richards and Gwynne 2011). *Warehouse management system* merupakan sistem informasi yang dirancang untuk mendukung dan mengoptimalkan fungsionalitas gudang dan manajemen distribusi. Sistem ini memfasilitasi dalam menggunakan teknologi otomatis yang disederhanakan yang berguna dalam kegiatan sehari-hari seperti perencanaan, pengorganisasian, penempatan, serta pengendalian sumber daya yang tersedia.

Warehouse management system adalah tindakan untuk mengkoordinasi dan mengendalikan segala sesuatu didalam gudang dan memastikan semua berjalan dengan cara yang paling optimal dan termasuk didalamnya:

1. Mengatur gudang beserta inventaris nya.
2. Memiliki dan memelihara peralatan yang sesuai.
3. Mengelola stok baru yang masuk ke fasilitas
4. Mengambil, mengemas, dan mengirimkan pesanan
5. Melacak dan meningkatkan kinerja gudang secara keseluruhan

2. METODOLOGI PENELITIAN

Metode penelitian yang digunakan pada penelitian ini adalah metode penelitian berbasis eksperimen dan *field research*. Tujuan penelitian ini adalah untuk membangun model yang dapat memprediksi jumlah pembelian barang dengan metode *decision tree* dan optimasi akurasi dengan menerapkan metode *Random Forest regression*. Perancangan model dibuat berdasarkan hasil studi literatur dan analisis. Selanjutnya rancangan model tersebut dijadikan pedoman pengujian dan implementasi..

2.1. Pengumpulan Data

Penelitian ini menggunakan histori transaksi harian dari proses pembelian barang, produk struktur, inventory dan rencana produksi. Data tersebut menjadi acuan sebagai informasi dari masa lalu, untuk digunakan dalam proses data training menggunakan metode *decision tree* yang akan dioptimalkan dengan metode *random forest regression*.

2.2. Data Understanding

Memahami kelengkapan data dengan menganalisa data baik secara statistik maupun secara visual. Dari proses analisa dapat ditentukan atribut atau label yang sesuai maupun yang tidak sesuai sehingga memudahkan pemahaman data secara menyeluruh

2.3. Preprocessing

Setelah memahami data, data akan dimasukkan ke dalam format yang sudah ditentukan untuk dilakukan pengecekan apakah *ada missing value* dan data di *cleansing* serta memastikan format data sudah sesuai dengan metode yang akan memproses data

2.4. Pemodelan Data


Dalam proses pemodelan data *training* dan data *testing* data diproses untuk mendapatkan model yang sesuai dengan metode *Decision Tree*. Dalam penelitian ini implementasi model akan dilakukan menggunakan bahasa pemrograman python dan konsep Prototipe akan dicoba dengan *google colab* sebelum dijadikan Prototipe dan dievaluasi.

2.5. Proses Prediksi dan Optimalisasi

Setelah data sesuai dengan model untuk metode *decision tree*. Data akan diuji untuk mendapat nilai akurasi yang terbaik. Dan kemudian akan di optimalisasi dengan metode *random forest regression*.

2.6. Langkah-Langkah Penelitian

Penelitian ini mengadopsi *model Cross-industry standard process for data mining* (CRISP-DM). Alasan peneliti menggunakan model CRISP-DM daripada model lain adalah model CRISP-DM merupakan metode yang sudah memiliki standarisasi untuk pengelolaan data mining. Dan model CRISP-DM dari literatur yang dikumpulkan peneliti merupakan model yang cocok untuk menerapkan metode *decision tree* dalam hal prediksi. Model ini juga sudah teruji sejak di publikasi pada tahun 1999. Gambar 2 menggambarkan diagram CRISP-DM dari penelitian CRISP-DM *Towards a Standard Process Model for Data Mining*.



Gambar 2. Diagram CRISP-DM (Wirth and Hipp 2000) [2]

3. HASIL DAN PEMBAHASAN

Untuk pengumpulan data peneliti akan menggunakan data dengan pemilihan kriteria-kriteria yang memang secara aktual akan berpengaruh terhadap perubahan. Langkah pertama menentukan model atau produk barang jadi yang sering mengalami perubahan. Data model barang jadi diuraikan pada Tabel 1.

Tabel 1. Data Model

No	Model	Keterangan
1	KFL	OEM dan Spare part
2	B74	Spare part
3	2DP	OEM dan spare part
4	KYZ	OEM
5	K36	Spare part

Kemudian memilih kriteria bahan baku pendukung untuk model pada tabel 1 yang diuraikan pada Tabel 2.

Tabel 2. Kriteria Bahan Baku

No	Bahan Baku	Keterangan
1	ABSORBER	Kategori 1
2	BOLT	Kategori 2
3	BOSS	Kategori 3
4	BUSH	Kategori 4
5	CAM	Kategori 5
6	COLLAR	Kategori 6
7	DAMPER	Kategori 7
8	FACE MOVEBALE	Kategori 8
9	GEAR	Kategori 9
10	KANAGU	Kategori 10


Dari tabel 1 merupakan barang jadi dan tabel 2 merupakan kriteria bahan baku peneliti akan fokus untuk mempelajari perubahan-perubahan yang terjadi pada barang jadi dan bahan baku yang sudah ditentukan. Data yang didapat harus diolah sehingga atribut dapat digunakan untuk melakukan model prediksi. Pada proses pengumpulan data didapat atribut awal diuraikan pada tabel 3.

Tabel 3. Atribut dataset

Atribut	Keterangan	Tipe Data
<i>Partno</i>	<i>Menyatakan atribut "partno" yang merupakan identifikasi barang</i>	<i>Varchar</i>
<i>Tahun</i>	<i>Menyatakan atribut "tahun" merupakan identifikasi tahun transaksi</i>	<i>Integer</i>
<i>Bulan</i>	<i>Menyatakan atribut "bulan" merupakan identifikasi bulan transaksi</i>	<i>Integer</i>
<i>Hari</i>	<i>Menyatakan atribut "hari" merupakan identifikasi hari transaksi</i>	<i>Integer</i>
<i>PO</i>	<i>Menyatakan atribut label merupakan nilai yang akan diprediksi</i>	<i>Decimal</i>
<i>BOM</i>	<i>Menyatakan atribut "bom" merupakan jumlah penggunaan bahan baku</i>	<i>Decimal</i>
<i>Produksi</i>	<i>Menyatakan atribut "produksi" merupakan jumlah rencana produksi</i>	<i>Integer</i>
<i>Stok</i>	<i>Menyatakan atribut "stok" merupakan jumlah stok barang</i>	<i>Decimal</i>

Pada penelitian prediksi jumlah kuantitas pembelian atribut PO merupakan penentu untuk melakukan model prediksi dan sedangkan untuk optimasi atribut BOM dan Hari sebagai penunjang berlaku hanya pada model *random forest regression*. Sedangkan model *decision tree* optimasi dilakukan dengan memilih kriteria entropi dan jumlah *maxdepth*.

Pemodelan data untuk proses prediksi akurasi pembelian dengan decision tree dan *random forest regression* dengan menentukan label yang diwakili oleh atribut po dan variabel pendukung lainnya. Adapun proses pemodelan model prediksi digambarkan pada flow Gambar 3.



Gambar 3. Flow pemodelan prediksi [3]

Dari diagram diatas dapat diuraikan bagaimana pemodelan data dari proses prediksi dimana:

1. Proses pertama Input data (dataset) proses pertama yang dilakukan adalah memasukkan dataset.
2. Setelah dataset di input lakukan proses split data training dan testing dengan rasio yang ideal.
3. Dan dilakukan Fit model dengan rasio data training dan testing.
4. Pemilihan metode decision tree atau random forest regression.
5. Melakukan Optimasi decision tree dengan entropy dan maxdepth sedangkan random forest regression dengan importance variabel
6. Cek akurasi.
7. Tampilkan hasil prediksi

Proses pertama adalah menentukan dataset untuk uji model dataset dimana dataset sudah dalam format csv. Format dataset diuraikan pada Tabel 4.

Tabel 4. Dataset Prediksi


	<i>Partno</i>	<i>Tahun</i>	<i>Bulan</i>	<i>Hari</i>	<i>PO</i>	<i>Produksi</i>	<i>BOM</i>	<i>Stok</i>
0	119-04G39-00	2019	1	3	7500	550	1	495
1	119-04G39-00	2019	1	4	7500	400	1	400
2	119-04G39-00	2019	1	7	2000	558	1	558
3	119-04G39-00	2019	1	8	2000	600	1	600
4	119-04G39-00	2019	1	9	6000	605	1	605
5	119-04G39-00	2019	1	11	7500	900	1	900
6	119-04G39-00	2019	1	14	7500	558	1	558
7	119-04G39-00	2019	1	16	7500	205	1	205
8	119-04G39-00	2019	1	16	7500	605	1	605
9	119-04G39-00	2019	1	21	7500	600	1	600

Parameter pengujian model di uraikan pada tabel 5.

Tabel 5. Paramater pengujian

<i>No</i>	<i>Parameter</i>	<i>DT</i>	<i>RFR</i>
1	Jumlah record	130	130
2	Training data	(96,5)	(96,18)
3	Testing data	(33,5)	(33,18)
4	Estimator	-	1000
5	Random state	24	24
6	Criteria	Entropy	-
7	Max Depth	3	-
8	Importance Variable	-	Stok, Produksi, Partno_2DP- E7674-02
9	Akurasi	72,73%	93,68%

Dari hasil pengujian dengan parameter diatas didapat hasil gambaran pohon keputusan dengan metode dengan *decision tree* yang diuraikan pada Gambar 4 dan hasil pohon keputusan dengan *random forest regression*.




Gambar 4. Pohon Keputusan Metode DT

Dari uraian pohon keputusan dapat nilai pohon keputusan diuraikan dalam bentuk Tabel 6 parameter dan nilai dari pohon keputusan tersebut.

Tabel 6. Parameter dan Nilai Pohon Keputusan

Level	Parameter	Value
1	Produksi	1500
	Operator	<=
	Entropy	3.1
	Samples	97
	Value	[1, 6, 28, 13, 8, 6, 7, 13, 1, 2, 2, 10]
Dst.		

Kemudian hasil prediksi metode *decision tree* diuraikan pada Gambar 5 grafik perbandingan aktual dan prediksi.



Gambar 5. Grafik Aktual vs Prediksi[5]

Dari grafik hasil prediksi terlihat ada beberapa perbedaan diantara aktual dan prediksi diantaranya pada hari ke 7,8 dan 23. Dimana hasil prediksi pada hari cukup lebih besar jauh dari aktual. Sedangkan pada hari ke 23 hasil prediksi terlihat lebih kecil dari aktual. Visualisasi ini menunjukkan rendahnya nilai akurasi prediksi dengan metode *decision tree*.

Pada metode *random forest regression* data akan ditransformasi dari row kedalam bentuk kolom untuk atribut Partno. Transformasi data diuraikan dalam Tabel 7.

Tabel 7. Transformasi dataset


	Tahun	Bulan	Hari	Po	Produksi	BOM	Stok	Partno_119-04G39-00	Partno_119-04G63-00	Partno_192-04G22-00	Partno_22111-K36-A000-H1	Partno_23113-KYZ-9010-Y1
count	130.0	130.0	130.000000	130.000000	130.000000	130.000000	130.000000	130.000000	130.000000	130.000000	130.000000	130.000000
mean	2019.0	1.0	13.746154	2507.569231	1134.192308	1.592308	1381.530769	0.076923	0.030769	0.023077	0.184615	0.107692
std	0.0	0.0	8.250263	2029.747042	790.820231	1.553671	2138.352242	0.267500	0.173360	0.150729	0.389486	0.311191
min	2019.0	1.0	2.000000	500.000000	18.000000	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
25%	2019.0	1.0	7.000000	1000.000000	568.500000	1.000000	200.000000	0.000000	0.000000	0.000000	0.000000	0.000000
50%	2019.0	1.0	14.000000	1500.000000	800.000000	1.000000	500.000000	0.000000	0.000000	0.000000	0.000000	0.000000
75%	2019.0	1.0	21.000000	3456.000000	1840.000000	1.000000	1156.000000	0.000000	0.000000	0.000000	0.000000	0.000000
max	2019.0	1.0	31.000000	7500.000000	4018.000000	6.000000	7300.000000	1.000000	1.000000	1.000000	1.000000	1.000000

Pada metode random forest regression terdapat metode optimasi dengan menggunakan importance variable dimana variable diuraikan dalam Tabel 8.

Tabel 8. Importance Variable

No	Variable	Importance Value
1	Stok	0.82
2	Produksi	0.2
3	Partno_2DP-E7674-02	0.05

Dari penggunaan *importance variable* metode RFR menghasilkan pohon keputusan yang diuraikan dalam gambar 6.



Gambar 6. Pohon keputusan model RFR [6]

Dari uraian pohon keputusan nilai dan parameter diuraikan dalam Tabel 9.

Tabel 9. Parameter nilai pohon keputusan metode RFR


Level	Parameter	Value
1	Stok	1500
	Operator	<=
	Squared Error	4509666.5
	Samples	97
	Value	2425.5
<i>Dst.</i>		

Perbedaan parameter antara metode DT dan RFR adalah metode DT menggunakan *Entropy* dan value dalam bentuk lebih dari satu nilai sedangkan RFR menggunakan *squared error* dan *value* hanya memiliki satu nilai. Hasil optimasi akurasi metode RFR dapat dilihat pada Tabel 10.

Tabel 10. Hasil Optimasi Metode RFR

<i>Total Data</i>	<i>Akurasi Sebelum Optimasi</i>	<i>Akurasi sesudah Optimasi</i>
130	93,68%	94,87%

Dari proses optimasi RFR hasil prediksi diuraikan dalam Gambar 9 grafik prediksi vs aktual.



Gambar 7. Grafik Prediksi Metode RFR

Dari grafik hasil prediksi metode RFR dapat dilihat pada hari ke 7 dan 9 serta hari ke 29 yang terdapat perbedaan signifikan akan tetapi perbedaan ini lebih kecil dari metode DT yang telah diuji sebelumnya. Dari hasil visualisasi ini dapat disimpulkan metode RFR dapat melakukan optimasi dengan menggunakan *importance variable* secara nilai tingkat optimasi tidak terlalu signifikan akan tetapi metode ini mampu meningkatkan akurasi 1.19% dengan data uji 33 row dan data testing 99 row.

4. KESIMPULAN

Dengan model *decision tree* dan variabel kriteria entropi tingkat akurasi untuk prediksi quantity pembelian kurang maksimal. Artinya model *decision tree* tidak cukup baik untuk memprediksi jenis data pembelian pada perusahaan manufaktur yang cenderung memiliki pola data yang acak. Akan tetapi berbeda dengan *random forest regression* model ini sangat efektif untuk meningkatkan akurasi dengan menentukan *importance variabel* yang tepat, sehingga proses optimasi akurasi akan signifikan meningkat pada jumlah data tertentu, sehingga model ini sangat berhasil dan cocok untuk memprediksi quantity pembelian pada perusahaan manufaktur.

Saran untuk penelitian selanjutnya dengan metode *decision tree* atau *random forest regression* perhatikan field studi kasus terutama untuk model *decision tree* karena model ini sangat berpengaruh pada jenis data. Untuk *random forest regression* pada jenis data yang bersifat numerical harusnya cukup efektif. Untuk field studi yang dapat diteliti pada dua model ini di sektor manufaktur diantaranya memprediksi KPI karyawan, memprediksi jumlah pembayaran dan memprediksi reject produk pada proses manufaktur.

DAFTAR PUSTAKA

- [1] Rokach L, Maimon O, 2008 "Decision Trees". Lecture Notes in Mathematics.
- [2] Lolli F, Ishizaka A, Gamberini R, Balugani E, Rimini B, 2017 "Decision Trees for Supervised Multi-criteria Inventory Classification". Procedia Manuf [Internet].
- [3] Gangsarwijaya N, Anindhita R, Widaningrum DL, 2020 "Decision tree analysis approach to determine factors that affect the quote order lead time fulfillment". IOP Conf Ser Earth Environ
- [4] Biau G, Scornet E., 2016 "A random forest guided tour".
- [5] Farnaaz N, Jabbar MA., 2016 "Random Forest Modeling for Network Intrusion Detection System". Procedia Comput Sci [Internet].
- [6] Kirasich K, Smith T, Sadler B., 2018 "Random Forest vs Logistic Regression": SMU Data Science Review [Internet].
- [7] Richards, Gwynne., 2011 "Warehouse Management"
- [8] Sylvester EVA, Bentzen P, Bradbury IR, Clément M, Pearce J, Horne J, et al., 2018 "Applications of random forest feature selection for fine-scale genetic population assignment".
- [9] Wirth R, Hipp J., 2000 "CRISP-DM: towards a standard process model for data mining. Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining, 29-39". Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining [Internet].