

Identifikasi Fitur untuk Prediksi Penerimaan Program Listrik Prabayar: Kasus di PLN Tahuna

Feature Identification for Predicting Acceptance of Prepaid Electricity Programs: The Case at PLN Tahuna

Eko Riduwan¹, Diana Purwitasari^{2*}, Agus Budi Raharjo³

¹PT PLN(Persero) UP3 Tahuna

¹Magister Manajemen Teknologi, Institut Teknologi Sepuluh Nopember

^{2,3}Teknik Informatika, Institut Teknologi Sepuluh Nopember

E-mail: ¹eko.riduwan@pln.co.id, ²diana@if.its.ac.id, ³agus.budi@its.ac.id

Abstrak

Listrik Prabayar (LPB) bermanfaat bagi pemerintah, perusahaan listrik dan pelanggan. Perusahaan Listrik Negara (PLN) mempunyai program pemasaran untuk berpindah (migrasi) dari listrik pascabayar menjadi LPB. Pencapaian *Key Performance Indicator* (KPI) Program Pemasaran LPB PLN Tahuna pada 2021 hanya 1.185 pelanggan dari target 2.261 pelanggan. Hal ini memberikan peluang perbaikan karena program pemasaran saat ini belum mengoptimalkan penggunaan data sebagai dasar penentuan prospek pelanggan. Penelitian ini mengajukan metode identifikasi fitur dan skenario pemilihan algoritma pembelajaran mesin yang tepat untuk memprediksi penerimaan pelanggan listrik pasca bayar terhadap program prabayar. Identifikasi fitur dilakukan dengan pengukuran korelasi *Spearman*. Algoritma Pembelajaran mesin yang digunakan adalah Logistic Regression, Support Vector Machines, Decision Tree, dan Random Forest. Model-model yang dihasilkan dievaluasi menggunakan *confusion matrix* sehingga didapatkan model terbaik untuk studi kasus yang diajukan. Penelitian menunjukkan bahwa fitur tarif, daya, frekuensi terlambat membayar listrik, pemakaian rata-rata listrik bulanan (kWh) dan Kabupaten mempunyai korelasi signifikan dengan penerimaan LPB. Adapun model dengan algoritma Random Forest adalah model terbaik sesuai tujuan penelitian dengan *F1-Measure* tertinggi (95,17%).

Kata kunci: listrik prabayar, pembelajaran mesin, prediksi, pemasaran

Abstract

Prepaid Electricity (LPB) provides benefits for government, electricity companies and customers. The State Electricity Company (PLN) has a marketing program to migrate from postpaid electricity to LPB. The achievement of Key Performance Indicators (KPI) for the Annual PLN LPB Marketing Program in 2021 was only 1,185 customers out of a target of 2,261 customers. This achievement provides an opportunity for improvement because the current marketing program has not optimized the use of data to determine customer prospects. This study proposes feature identification methods and scenarios for selecting the suitable Machine Learning algorithm to predict postpaid electricity customer acceptance of prepaid programs. Feature identification is made by measuring the Pearson correlation. The machine learning algorithm candidates selected are Logistic Regression, Support Vector Machines, Decision Tree, and Random Forest. The resulting models are evaluated using a confusion matrix to obtain the best model for the proposed case study. The research shows that the features of tariff, power, frequency of late payment of electricity, average monthly electricity usage (kWh), and Regency significantly correlate with LPB revenue. The model with the Random Forest algorithm is the best model according to the research objectives, with the highest F1-Measure (95.17%).

Keywords: prepaid electricity, machine learning, prediction, marketing

1. PENDAHULUAN

Listrik Pra Bayar (LPB) dapat menjadi salah satu solusi penghematan energi pada ketenagalistrikan di negara maju dan berkembang [1] [2] [3]. Bagi pemerintah dan perusahaan listrik LPB diimplementasikan dengan tujuan penghematan energi [4] sehingga dijadikan LPB dijadikan media kampanye penghematan energi [5] atau untuk mengurangi tunggakan rekening listrik pelanggan dan pencurian listrik [6] [7]. Penggunaan LPB bagi pelanggan dianggap lebih mudah dalam mengontrol tagihan listrik, mudah dalam hal pembelian token dan juga tidak perlu mengantri [8], selain itu pelanggan beranggapan bahwa LPB lebih transparan dalam hal pembiayaan [9]. Perusahaan Listrik Negara (PLN) unit layanan Tahuna Sulawesi Utara (PLN Tahuna) di tahun 2021 mempunyai 87.651 pelanggan, diantaranya 31.383 pelanggan pascabayar dan 56.268 pelanggan Prabayar. Pada tahun 2021 terdapat 1.185 pelanggan yang melakukan perpindahan layanan (migrasi) dari listrik pascabayar menjadi LPB. Jumlah pelanggan migrasi tersebut jauh lebih kecil dari target yang ditetapkan oleh PLN Tahuna pada tahun 2021 yaitu sebesar 2.261 pelanggan. Program pemasaran migrasi pascabayar ke Prabayar yang dilakukan PLN Tahuna antara lain mengganti meter pelanggan menunggak, rumah tanpa penghuni dan sosialisasi. Sehingga parameter tersebut dapat menjadi faktor berpengaruh saat melakukan analisis data pelanggan untuk mencari kemungkinan kesediaan migrasi ke program Prabayar. PLN Tahuna memiliki data pelanggan dalam bentuk data transaksi bulanan dan data mutasi/perubahan status pelanggan. Akan tetapi data pelanggan tersebut belum dimanfaatkan dalam program pemasaran Prabayar. Seharusnya data tersebut dapat berperan besar dalam menentukan prospek pelanggan sebagai target pemasaran.

Program pemasaran LPB tidak berbeda dengan program pemasaran pada perusahaan lain seperti bank, telekomunikasi dan asuransi dan lain-lain. Program pemasaran di beberapa perusahaan tersebut telah berubah menjadi lebih baik, dengan memaksimalkan data pelanggan yang dimiliki perusahaan maka diperoleh program pemasaran lebih efisien. Secara umum, data di perusahaan digunakan untuk memprediksi keberhasilan program pemasaran pada segmen pelanggan tertentu, memprediksi jenis produk yang memiliki tingkat keberhasilan tinggi dan mencegah terjadinya *churn*. Data pelanggan dimanfaatkan dengan menggunakan teknik *data mining* atau yang lebih spesifik berupa pembelajaran mesin dengan berbagai macam algoritma yang dibandingkan dan diperbaiki tingkat akurasi [10]. Dapat disimpulkan bahwa perusahaan-perusahaan tersebut telah memanfaatkan data pelanggan yang dimilikinya, tidak sekedar data atau faktor yang berpengaruh dari perspektif pelanggan seperti jumlah keluarga, tingkat pendapatan dan lain-lain.

Penelitian sebelumnya, meneliti faktor yang menjadi pendorong penolakan implementasi LPB antara lain kurangnya sarana konsultasi dan edukasi dari pemerintah ataupun perusahaan listrik ke pelanggan dan juga terdapat faktor politis [1], faktor kebiasaan penggunaan listrik pascabayar, faktor ketidaktahuan pelanggan terhadap produk baru dan faktor persepsi terhadap listrik pascabayar [11]. Selain itu, penelitian lain menyebutkan terkait faktor pendukung penerimaan LPB antara lain pelanggan dengan pendapatan tinggi dalam kurun waktu lima tahun dan orang lanjut usia cenderung menolak LPB sedangkan keluarga kecil lebih cenderung menerimanya [4]. Lebih jauh, penelitian lain juga menyebutkan antara lain pendapatan tidak berpengaruh signifikan terhadap kemauan adopsi LPB, pengeluaran listrik berpengaruh positif dan signifikan serta jumlah anggota keluarga berpengaruh negatif dan signifikan [12]. Sasongko [13] meneliti dari persepektif program pemasaran, maka penerimaan program pemasaran LPB oleh masyarakat sangat dipengaruhi oleh periklanan, hubungan masyarakat, promosi penjualan serta promosi *online* dan Adliah [14] juga menambahkan pemasaran langsung (*direct marketing*) dan *personal selling* termasuk juga dengan penyebaran brosur [15] [16] [17]. Oleh karena itu penerimaan LPB tersebut dapat terjadi ketika pelanggan mendapatkan informasi jelas lewat berbagai program pemasaran [18]. Hal ini juga sejalan dengan penelitian oleh Rahman [19] memandang bahwa kualitas LPB dan kinerja karyawan PLN mempunyai korelasi pula dengan kepuasan pelanggan walaupun di beberapa tempat dengan harga yang lebih mahal [20] [21] [22]. Sehingga dapat ditarik kesimpulan bahwa penelitian sebelumnya terkait LPB dipengaruhi oleh

faktor *push* yaitu faktor negatif yang mendorong berpindah dari kondisi lama, faktor *pull* adalah faktor positif yang ditawarkan produk baru (LPB) dan faktor *mooring* yaitu karena alasan individu konsumen [23].

Beberapa penelitian tersebut di atas secara garis besar memberikan dua informasi utama. Pertama, penerimaan listrik Prabayar sejauh ini diukur dari beberapa faktor yang merupakan faktor eksternal dari perspektif PLN, yaitu faktor dari pelanggan. Kedua, program pemasaran yang dilakukan saat ini oleh PLN masih berupa program pemasaran dengan strategi konvensional dan belum mengoptimalkan penggunaan data pelanggan yang dimiliki.

Penelitian ini selanjutnya memberikan dua kontribusi utama, pertama melengkapi penelitian terdahulu terkait faktor yang mempengaruhi penerimaan pelanggan terhadap LPB yaitu dengan menambahkan perspektif penelitian. Jika penelitian terdahulu mengukur penerimaan LPB dari faktor pelanggan, maka penelitian ini menggunakan faktor data yang dimiliki PLN untuk mengukur penerimaan LPB. Kedua, penelitian ini mengusulkan sebuah model pembelajaran mesin yang berfungsi memprediksi penerimaan LPB, dimana model ini dapat dijadikan acuan tim pemasar PLN untuk memasarkan LPB dengan tujuan meningkatkan tingkat keberhasilan program pemasarannya.

2. METODE PENELITIAN

Tahapan program pemasaran LPB saat ini tidak melalui proses penentuan target pelanggan yang jelas. Target pelanggan program pemasar LPB umumnya adalah pelanggan pascabayar yang menunggak pembayaran listrik lebih dari tiga bulan, rumah-rumah kosong dan atas permintaan pelanggan. Alur program pemasaran LPB secara umum dimulai dengan tim pemasar PLN mendatangi pelanggan listrik pascabayar, jika pelanggan menerima berpindah ke listrik Prabayar maka tim pemasar akan meng-*update* data pelanggan dari pascabayar menjadi Prabayar agar rekening listrik tidak terbit di bulan berikutnya, namun jika pelanggan tidak menerima program LPB maka tim pemasar akan berpindah ke pelanggan lain.

Pada penelitian ini dilakukan identifikasi fitur data dan pembuatan model untuk memprediksi penerimaan program migrasi dari pascabayar ke LPB. Sehingga alur pemasaran LPB akan dimulai dengan prediksi pelanggan, apabila pelanggan diprediksi akan menerima LPB maka proses pemasaran dilanjutkan. Akan tetapi jika hasil prediksi tersebut menunjukkan hasil yang berbeda, maka tim pemasaran dapat mencari target pelanggan yang lain. Oleh karena itu hasil penelitian ini diharapkan dapat merubah proses pemasaran LPB di PLN Tahuna. Tahap penelitian yang keseluruhannya dilakukan dengan tools *KNIME Analytics Platform* dilakukan sesuai tahap pada Gambar 1, adapun *workflow* penelitian terdapat pada Gambar 2.

2.1 Persiapan Data


Tahap ini dimulai dengan import data mutasi dan data transaksi pelanggan. Data mutasi pelanggan digunakan sebagai data utama untuk memetakan pelanggan pascabayar melakukan migrasi ke Prabayar atau tidak. Data mutasi pelanggan berisi informasi personal serta *history* perubahan yang dilakukan pelanggan dalam bulan berjalan. Perubahan data pelanggan dapat berupa perubahan daya, perubahan tarif, perubahan nama dan perubahan yang lain. Seorang pelanggan PLN dapat melakukan perubahan daya lebih dari satu kali dalam satu tahun. Data mutasi yang digunakan dalam penelitian adalah data tahun 2021 bersumber dari data PLN Tahuna yaitu dengan total data sebanyak 6.025 pelanggan (Tabel 1). Pemetaan pelanggan menerima listrik Prabayar (Migrasi= "YES") ataupun menolaknya (Migrasi= "NO") didapat dari data mutasi ini. Data transaksi pelanggan adalah data yang memuat *history* pemakaian listrik pelanggan dalam satu bulan, sehingga data transaksi digunakan untuk meneliti perilaku pemakaian listrik pelanggan pascabayar, dimana perilaku pelanggan sangat berpengaruh pada keputusannya memilih pascabayar atau migrasi ke Prabayar [24]. Dalam penelitian ini, data transaksi bulanan pelanggan pascabayar selama 24 bulan.

Tabel 1. Data Mutasi Pelanggan PLN Tahun 2021

No	Jenis Mutasi	Jumlah Pelanggan
1	Pasang Baru	2.775
2	Perubahan Daya	3.269
3	Ubah Alamat	1
4	Ubah Nama	30

Tahap selanjutnya, data mutasi difilter dengan kategori "Jenis Mutasi : Perubahan Daya" dan "Jenis Pelanggan: Pascabayar". Setelah dilakukan pelabelan fitur migrasi menjadi dua kategori (YES dan NO) maka tahap selanjutnya adalah melakukan proses *join* antara data mutasi dan data transaksi berdasarkan ID Pelanggan. Hasil dari tahap ini adalah dataset dengan fitur ditunjukkan pada Tabel 2. Karakteristik Dataset dari Data Mutasi dan Transaksi Pelanggan PLN Tahun 2021.

Ketidakseimbangan data kelas (*imbalance*) akan membuat prediksi cenderung akurat hanya pada kelas yang dominan sehingga tahap selanjutnya dilakukan pengukuran *imbalance* data. Hasil pengukuran menunjukkan bahwa dataset penelitian memiliki data yang seimbang yaitu data label (Migrasi= "YES") sebesar 56% dan (Migrasi= "NO") sebesar 44% sehingga tidak diperlukan proses penyeimbangan data.



Gambar 1. Tahapan Pemodelan untuk Prediksi Penerimaan Migrasi ke LPB

Mengingat tipe target Migrasi berjenis binomial, maka pengukuran korelasi dilakukan dengan *Spearman's rank correlation coefficient*. Selanjutnya korelasi antara fitur dengan target label (Migrasi) diukur berdasarkan signifikansi hubungan, kekuatan hubungan dan juga arah hubungannya.

Tabel 2. Karakteristik Dataset dari Data Mutasi dan Transaksi Pelanggan PLN Tahun 2021

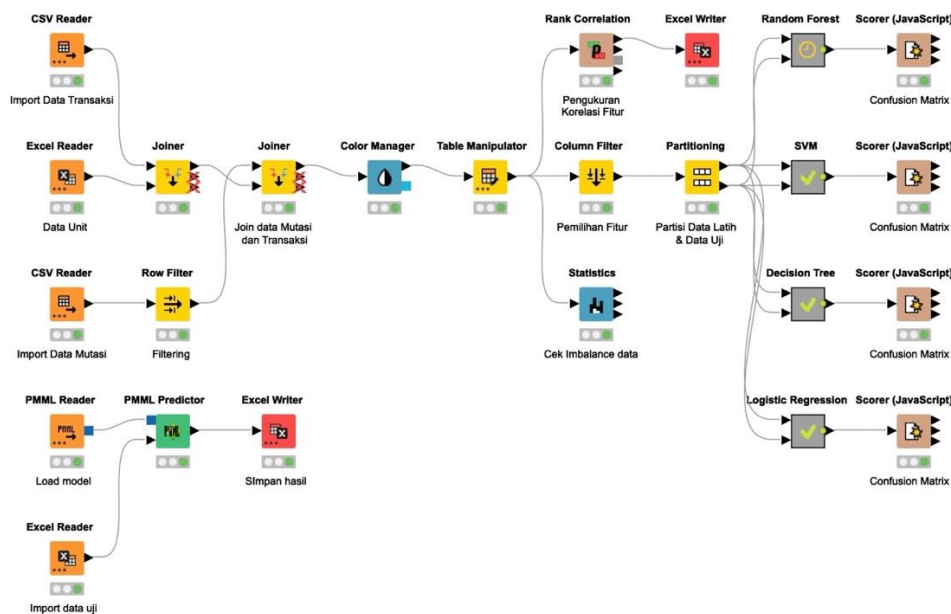
No	Nama	Keterangan	Tipe
1	Tarif	Tarif listrik yang dikategorikan menjadi, tarif: <ul style="list-style-type: none"> S : pelanggan tarif Sosial (cth: rumah ibadah, sekolah) R : pelanggan tarif Rumah Tangga (cth: rumah pribadi) B : pelanggan tarif Bisnis (cth: ruko, hotel) I : pelanggan tarif Industri (cth: pabrik, cold storage) P : pelanggan tarif Publik/Pemerintahan (cth: gedung pemerintah, lampu jalan) 	Nominal
2	Daya	Daya listrik terkontrak dengan PLN dalam satuan Volt Ampere (VA), antara lain: 450;900;1300;2200;3500;4400;5500;6600;7700;11000;23000;33000;41500	Numerical
3	Telat	Jumlah kali menunggak bayar dalam 24 bulan.	Numerical
4	kWh	Pemakaian listrik bulanan dalam satuan kWh	Numerical
5	Rp	Tagihan listrik bulanan (Rp)	Numerical
6	Unit_Layanan	Unit Layanan di bawah layanan PLN Tahun 2021, antara lain {Unit Petta, Unit Tamako, Unit Beo, Unit Melonguane, Unit Lirung, Unit Siau, Unit Tagulandang}	Nominal
7	Kabupaten	Kabupaten wilayah layanan PLN Tahun 2021, antara lain: {Kabupaten Kepulauan Sangehe, Kabupaten Kepulauan Talaud, Kabupaten Kepulauan Sitaro}	Nominal
8	Migrasi	Migrasi ke LPB <ul style="list-style-type: none"> YES : Pelanggan migrasi NO : Bukan pelanggan migrasi 	Nominal (target)

2.2 Pemodelan

Pemodelan pada penelitian ini menggunakan algoritma Logistic Regression (LR), Support Vector Machines (SVM), Decision Tree (DT) dan Random Forest (RF). Penguasaan beberapa algoritma ini didasarkan pada tipe fitur dan tipe target yaitu fitur nominal-numerical dan target nominal. Regresi logistik biner atau biasa disebut Regresi Logistik adalah bentuk regresi yang digunakan untuk memodelkan hubungan antara variabel dependen dan variabel independen, ketika variabel dependen adalah sebuah data dengan ukuran biner/dikotomi (misal: ya atau tidak, sukses atau gagal, bagus atau rusak, mati atau hidup). SVM adalah algoritma yang bekerja berdasarkan pemetaan nonlinier untuk mengubah data training asli ke dimensi yang lebih tinggi. Dimensi baru ini akan mencari hyperplane untuk memisahkan secara linier dan dengan pemetaan nonlinier yang tepat ke dimensi lebih tinggi, data dari dua kelas dipisahkan dengan hyperplane tersebut. DT adalah sebuah diagram alir yang berbentuk seperti struktur pohon yang mana setiap internal node menyatakan pengujian terhadap suatu atribut, setiap cabang menyatakan output dari pengujian tersebut dan leaf node menyatakan kelas-kelas/ distribusi kelas. RF adalah kumpulan dari *tree* yang merupakan kombinasi dari DT, dimana tree tersebut akan dibagi secara rekursif sesuai dengan data dan kelasnya yang bergantung pada hasil voting dari kelas yang terbentuk.

Tahap awal dari pemodelan adalah proses partisi data menjadi Data Pelatihan (DL) dan Data Uji (DU) dengan perbandingan DL:DU 80:20. Selanjutnya model akan dievaluasi dengan metrik *F-Measure* hal ini untuk memilih model dengan algoritma yang memiliki False Positive dan False Negative rendah. Sesuai dengan tujuan penelitian yaitu memprediksi penerimaan migrasi ke LPB untuk meningkatkan keberhasilan program pemasaran, maka algoritma dengan False Positive dan False Negative rendah dapat memprediksi lebih baik terhadap penerimaan migrasi LPB.

Model dengan hasil evaluasi terbaik selanjutnya disimpan dalam format *Predictive Model Markup Language* (PMML) yang merupakan format untuk menggambarkan model penambangan data yang antara lain terdiri dari input, transformasi yang digunakan untuk mengatur data serta beberapa parameter yang diperlukan [25]. PMML sendiri disusun dengan model pohon *cascade* khas *Extensible Markup Language* (XML) yaitu sebuah format teks yang pertama-tama dibuat oleh *World Wide Web Consortium* untuk menyederhanakan dan memudahkan pertukaran data antar server dengan memberikan standar penulisannya. Model yang tersimpan dalam format PMML ini selanjutnya dapat digunakan pada proses bisnis sehari-hari.



Gambar 2. Workflow Pemodelan dan Pengujian pada KNIME Analytics Platform

2.3 Pengujian

Tahap pengujian dilakukan dengan menggunakan data yang merepresentasikan kondisi riil dengan fitur dataset sesuai model. Data uji dalam format Excel terdiri dari data R1 daya 450 VA (R1-450) diambil 3 pelanggan dengan masing-masing mewakili 3 kabupaten yang berbeda demikian juga untuk pelanggan R1-900, R1-1300, R1-2200. Sehingga total dataset uji sebanyak 12 pelanggan. Adapun pengujian menggunakan pelanggan R1-450, R1-900, R1-1300, R1-2200 karena pelanggan dengan tarif ini mendominasi tarif dan daya di PLN Tahuna.

Tahap pengujian dalam data uji penelitian ini akan menggunakan 10 skenario pasangan fitur yang signifikan terhadap target. Skenario tersebut ditunjukkan pada Tabel 4. Selanjutnya model prediksi yang sebelumnya disimpan dalam format PMML dimuat ulang dan diujikan dengan data uji. Hasil pengujian yang diharapkan adalah respon (Migrasi= “YES”) atau (Migrasi= “NO”) dari masing-masing data uji.

3. HASIL DAN PEMBAHASAN

3.1 Korelasi fitur terhadap target label (Migrasi)

Pengukuran korelasi masing-masing fitur dalam dataset (Tabel 2) terhadap target (Migrasi) dilakukan dengan *Spearman's rank correlation coefficient* dimana ukuran korelasi berada pada +1 (korelasi positif maksimal) dan -1 (korelasi negatif maksimal).

Tabel 3. Korelasi Dataset terhadap Target Label Migrasi

No	Fitur	p-Value	Correlation Value	Keterangan
1	Tarif	0,001	0,093	Signifikan
2	Daya	0	-0,412	Signifikan
3	Telat	0	0,257	Signifikan
4	kWh	0	-0,309	Signifikan
5	Rp	2,148	-0,173	Tidak Signifikan
6	Nama Unit	5,801	0,189	Tidak Signifikan
7	Kabupaten	0	-0,514	Signifikan

Pengukuran korelasi fitur terhadap target label migrasi yang ditunjukkan Tabel 3 dengan nilai signifikansi α -value=0,05 maka dapat diketahui bahwa fitur Tarif dengan p-value=0,001 (lebih kecil dari 0,05) memiliki hubungan signifikan dengan target label Migrasi namun dengan tingkat korelasi yang sangat rendah. Fitur Daya (p-value = 0) mempunyai hubungan signifikan dengan target label Migrasi dan cukup berkorelasi negatif dengan target label Migrasi, hal ini berarti semakin besar daya maka semakin enggan pelanggan bermigrasi ke LPB. Sedangkan fitur Telat (p-value=0) mempunyai hubungan signifikan dan cukup berkorelasi dengan migrasi, hal ini berarti semakin sering pelanggan terlambat membayar listrik maka penerimaan migrasi ke LPB juga semakin besar. Fitur kWh (p-value = 0) mempunyai hubungan signifikan dan cukup berkorelasi negatif dengan target label Migrasi sehingga dapat diartikan bahwa semakin banyak pemakaian listrik pelanggan (kWh) semakin enggan menerima program migrasi ke LPB. Demikian pula dengan fitur Kabupaten (p-value = 0) berpengaruh signifikan terhadap migrasi dan berkorelasi negatif kuat. Sedangkan fitur tagihan listrik (Rp) dan Nama Unit masing-masing memiliki p-value=2,148 dan 5,801 (lebih tinggi dari 0,05) dapat dikatakan tidak memiliki pengaruh signifikan dan berkorelasi sangat rendah terhadap migrasi sehingga fitur Rp dan Nama Unit tidak digunakan dalam pembuatan model.

Pengujian selanjutnya difokuskan pada fitur yang memiliki korelasi signifikan terhadap penerimaan migrasi LPB. Beberapa skenario pengujian yang akan digunakan ditunjukkan pada Tabel 4, dimana masing-masing (\checkmark) menandakan fitur yang akan diujicobakan pada model yang terpilih. Adapun kombinasi skenario dalam pengujian didasarkan pada studi kasus penelitian yaitu di PLN Tahuna.

Tabel 4. Skenario Pengujian Fitur yang Siginifikan

Pengujian	Tarif	Daya	Telat	kWh	Kabupaten
Skenario 1	√	√			
Skenario 2	√		√		
Skenario 3	√			√	
Skenario 4	√				√
Skenario 5	√	√	√		
Skenario 6	√		√	√	
Skenario 7	√			√	√
Skenario 8	√	√	√	√	
Skenario 9		√	√	√	√
Skenario 10	√	√	√	√	√

3.2 Evaluasi perbandingan algoritma pembelajaran mesin

Algoritma yang digunakan dalam penelitian antara lain Logistic Regression (LR), Support Vector Machine (SVM), Decision Tree (DT) dan Random Forest (RF).

Tabel 5. Evaluasi Algoritma Berdasarkan F-Measure

Pengujian Fitur	Data Latih 80%				Algoritma RF dengan Data Latih :				
	LR	SVM	DT	RF	90%	70%	60%	50%	40%
Skenario 1	74,40	11,70	87,20	86,89	87,27	84,8	83,33	83,51	85,48
Skenario 2	68,85	62,07	76,16	77,46	65,08	69,25	65,24	68,96	60,26
Skenario 3	73,07	69,94	71,08	71,43	73,02	72,26	72,8	72,25	72
Skenario 4	78,87	NA	79,30	78,87	79,22	78,45	78,75	77,74	78,61
Skenario 5	73,54	76,60	94,24	94,56	87,69	89,8	90,62	90,91	92,27
Skenario 6	77,74	76,87	72,44	75,10	77,52	74,04	75,82	73,86	74,6
Skenario 7	61,46	68,52	72,18	80,28	76,12	86,5	82,35	79,61	81,66
Skenario 8	76,10	41,05	90,37	91,60	93,22	92,07	92,83	90,6	92,37
Skenario 9	4,26	9,72	84,21	87,36	82,93	87,34	87,86	87,44	85,45
Skenario 10	73,44	75,50	92,59	95,17	93,75	93,95	91,63	91,68	90,58

Berdasarkan Tabel 5 dapat ditentukan model terbaik dimana pada kasus prediksi penerimaan program LPB akan dipilih model dengan F-Measure tertinggi, yaitu algoritma yang memiliki *False Positive* (FP) dan *False Negative* (FN) rendah (1). Sesuai dengan tujuan penelitian yaitu memprediksi penerimaan migrasi ke LPB untuk meningkatkan keberhasilan program pemasaran, maka algoritma dengan *False Positive* kecil dan *False Negative* kecil dapat memprediksi lebih baik terhadap penerimaan migrasi LPB. Selanjutnya, dapat diketahui bahwa F-Measure tertinggi adalah algoritma Random Forest dengan fitur uji skenario 10 yaitu dengan score 95,17.

$$F\text{-Measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (1)$$

dimana,

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

dan,

$$Precision = \frac{TP}{TP+FN} \quad (3)$$

3.2 Hasil pengujian

Tabel 5 menunjukkan algoritma Random Forest memenuhi kriteria penelitian terbaik sehingga model dengan algoritma ini akan diujicobakan dengan data pelanggan yang akan digunakan dalam proses pemasaran LPB sebenarnya. Seperti yang ditunjukkan pada Gambar 1 dimana model yang dipilih selanjutnya disimpan dalam format *.PMML agar dapat digunakan dalam pengujian data sebenarnya sekaligus digunakan pada proses bisnis riil. Model pembelajaran mesin dengan algoritma Random Forest yang telah disimpan dibaca dengan menggunakan *node PMML Reader*, sedangkan data uji yang disiapkan dalam format *.xlsx dibaca menggunakan *node Excel Reader*, selanjutnya *node PMML Predictor* akan memprediksi output variabel target (migrasi) yang dihasilkan.

Selanjutnya pengujian dilakukan dengan mengambil contoh masing-masing tarif pelanggan sesuai data riil, dimana data R1 daya 450 VA (R1-450) diambil 3 pelanggan dengan masing-masing mewakili 3 kabupaten yang berbeda demikian juga untuk pelanggan R1-900, R1-1300, R1-2200. Selanjutnya hasil pengujian diperoleh *output PMML Predictor*, dimana dari 12 data pelanggan yang diuji yang terdiri dari masing-masing 4 pelanggan dari Kabupaten Sangihe, Talaud dan masing-masing 3 pelanggan tarif-daya R1-450, R1-900, R1-1300, R1-2200. Data tersebut diujicobakan pada model dengan 10 skenario fitur seperti tersebut di atas dengan hasil sebagai berikut:

Tabel 6. Hasil Ujicoba Data Pelanggan pada Model

tarif	daya	telat	kWh	kabupaten	Skenario									
					1	2	3	4	5	6	7	8	9	10
R1	450	2	48,02092	SANGIHE	YES	NO	YES	YES	YES	NO	YES	YES	YES	YES
R1	450	10	127,61	SITARO	YES	YES	NO	NO	YES	NO	NO	YES	YES	YES
R1	450	11	261,2482	TALAUD	YES	NO	YES	NO	YES	NO	NO	YES	YES	YES
R1	900	10	120,4801	SANGIHE	NO	YES	NO	YES	NO	NO	YES	NO	NO	NO
R1	900	6	534,5002	SITARO	NO	NO	YES	NO	NO	NO	NO	NO	NO	NO
R1	900	19	339,6562	TALAUD	NO	YES	YES	NO	YES	YES	NO	YES	NO	NO
R1	1300	19	70,90014	SANGIHE	NO	YES	NO	YES	YES	YES	YES	YES	YES	YES
R1	1300	1	287,8201	SITARO	NO	NO	YES	NO	NO	NO	NO	YES	NO	NO
R1	1300	1	315,3393	TALAUD	NO	NO	YES	NO	NO	NO	NO	YES	NO	NO
R1	2200	15	487,7063	SANGIHE	NO	YES	YES	YES	YES	YES	YES	YES	YES	YES
R1	2200	11	310,6504	SITARO	NO	NO	YES	NO	NO	NO	NO	NO	NO	NO
R1	2200	14	1167,474	TALAUD	NO	YES	YES	NO	YES	YES	NO	YES	NO	NO

Hasil pengujian data pada Tabel 5 menunjukkan variasi prediksi sesuai dengan skenario 1 - 10 dengan algoritma Random Forest. Namun sesuai dengan Tabel 5 maka prediksi terbaik adalah pada skenario 10 yang menggunakan fitur Tarif, Daya, Telat, kWh dan Kabupaten. Sehingga dapat diketahui bahwa terdapat pelanggan dengan kriteria tarif R1, daya 450 VA, frekuensi menunggak sebanyak 2 kali dalam kurun waktu 24 bulan, rata-rata pemakaian listrik 48,02 kWh/bulan dan berdomisili di Kabupaten Sangihe diprediksi menerima LPB. Pada lingkungan bisnis riil maka pelanggan seperti ini selanjutnya dijadikan target pemasaran LPB oleh tim pemasar PLN. Sedangkan terdapat pelanggan lain dengan kriteria tarif R1, daya 900 VA dengan frekuensi menunggak sebanyak 10 kali dalam 24 bulan, rata-rata pemakaian listrik (kWh) sebesar 120,48 kWh dan berdomisili di Kabupaten Sangihe diprediksi tidak menerima LPB. Artinya pelanggan tidak layak untuk dijadikan target pemasaran tim pemasar LPB.

Adapun hasil komparasi kesamaan hasil pada Tabel 6, dapat diamati bahwa skenario 5, 8 dan 9 memiliki hasil yang sama dan relatif sama dengan skenario 10. Hal ini memberikan alternatif penggunaan fitur data pelanggan berupa dataset yang terdiri dari fitur Daya, Telat, kWh dan Kabupaten cukup memberikan hasil prediksi yang baik, diikuti dengan dataset yang terdiri dari fitur Tarif, Daya, Telat dan kWh serta dataset dengan kumpulan fitur Tarif, Daya, Telat dan Kabupaten. Alternatif dataset dengan kumpulan fitur yang berbeda ini diperlukan jika dalam beberapa kasus fitur tertentu tidak dapat disajikan.

Pada penelitian yang dilakukan Kambule [1], Nugroho [4], Karim [11] dan Oseni [12] diketahui berbagai faktor yang mempengaruhi penerimaan LPB antara lain faktor politis, faktor edukasi dan sosialisasi, faktor usia, faktor pendapatan dan faktor persepsi pelanggan pascabayar terhadap LPB dimana faktor-faktor ini adalah faktor eksternal dari perspektif perusahaan listrik, yaitu faktor dari pelanggan. Adapun penelitian ini mengidentifikasi fitur dan model yang dihasilkan memberikan faktor-faktor tambahan yang mempengaruhi penerimaan LPB dari perspektif perusahaan listrik yaitu faktor Tarif pelanggan, Daya kontrak pelanggan, seberapa sering pelanggan terlambat membayar listrik, pemakaian energi listrik rata-rata pelanggan (kWh) dan domisili pelanggan (Kabupaten).

3.3 Pembahasan

Pengukuran korelasi fitur yang diteliti terhadap prediksi penerimaan migrasi dari listrik pascabayar ke LPB menunjukkan bahwa Tarif, Daya, Telat (frekuensi terlambat membayar listrik), kWh (rata-rata pemakaian listrik) serta Kabupaten berpengaruh sangat signifikan sedangkan Rp (tagihan) dan Nama Unit tidak mempunyai pengaruh signifikan. Fitur Tarif dan Telat berkorelasi positif dengan migrasi, artinya semakin sering pelanggan terlambat membayar listrik maka semakin diprediksi menerima migrasi ke LPB. Sedangkan fitur Daya, kWh dan Kabupaten berkorelasi negatif sehingga semakin besar daya dan pemakaian listrik rata-rata pelanggan maka semakin diprediksi menolak migrasi ke LPB.

Algoritma Random Forest dipilih menjadi model terbaik berdasarkan evaluasi bahwa nilai F1-Measure tertinggi (95,17%). Pemilihan model ini berdasarkan dengan tujuan penelitian yaitu memprediksi penerimaan LPB untuk meningkatkan keberhasilan program pemasaran, sehingga algoritma dengan False Positive dan False Negative rendah dapat memprediksi lebih baik terhadap penerimaan migrasi LPB.

Model yang dihasilkan dalam penelitian telah mampu memprediksi penerimaan migrasi ke LPB berdasarkan fitur data pelanggan yang diberikan dengan memberikan rekomendasi "YES" dan "NO". Rekomendasi tersebut selanjutnya digunakan dalam program pemasaran migrasi LPB di PLN Tahuna.

4. KESIMPULAN DAN SARAN

Kontribusi utama penelitian ini antara lain, pertama melengkapi penelitian terdahulu terkait faktor yang mempengaruhi penerimaan pelanggan terhadap LPB yaitu dengan menambahkan perspektif penelitian. Jika penelitian terdahulu mengukur penerimaan LPB dari faktor pelanggan, maka penelitian ini menggunakan faktor data yang dimiliki PLN untuk mengukur penerimaan LPB. Kedua, penelitian ini mengusulkan sebuah model pembelajaran mesin yang berfungsi memprediksi penerimaan LPB, dimana model ini dapat dijadikan acuan tim pemasar PLN untuk memasarkan LPB dengan tujuan meningkatkan tingkat keberhasilan program pemasarannya.

Metodologi penelitian dimulai dengan persiapan data mutasi dan data transaksi pelanggan PLN Tahuna, mengidentifikasi fitur sampai dengan terbentuk dataset penelitian. Selanjutnya dalam tahap pemodelan digunakan algoritma Logistic Regression (LR), Support Vector Machine (SVM), Decision Tree (DT) dan Random Forest (RF). Model selanjutnya diuji untuk mendapatkan model terbaik sesuai dengan tujuan penelitian, yaitu dengan menggunakan ukuran *F-Measure*.

Penelitian ini mengidentifikasi faktor yang berpengaruh terhadap penerimaan LPB oleh pelanggan antara lain, tarif pelanggan, daya kontrak pelanggan, seberapa sering pelanggan

terlambat membayar listrik, pemakaian energi listrik rata-rata pelanggan (kWh) dan domisili pelanggan (Kabupaten) sedangkan model pembelajaran mesin yang direkomendasikan dalam penelitian ini yaitu dengan menggunakan algoritma Random Forest dengan nilai F-Measure 95,17. Model ini selanjutnya dijadikan model prediksi yang dalam bisnis proses pemasaran LPB dijadikan penentu target pemasaran.

Scope pengambilan data yang terbatas pada unit PLN Tahuna tentu perlu dikembangkan dengan menambah data dari unit PLN lain sehingga score evaluasi model lebih baik dan lebih bisa memprediksi perilaku konsumen PLN lebih luas. Selain itu, memadukan antara data transaksi dan data mutasi dengan data sosial ekonomi pelanggan tentu akan memperkaya aspek penerimaan program pemasaran.

DAFTAR PUSTAKA

- [1] N. Kambule, K. Yessoufou, N. Nwulu and C. Mbohwa, "Exploring The Driving Factors Of Prepaid Electricity Meter Rejection In The Largest Township Of South Africa," *Energy Policy*, vol. 124, p. 199–205, 2019.
- [2] Y. Qiu, B. Xing and Y. D. Wang, "Prepaid Electricity Plan and Electricity Consumption Behavior," *Contemporary Economic Policy*, vol. 35, no. 1, pp. 125-142, 2017.
- [3] D. Tewari and T. Shah, "An Assessment Of South African Prepaid Electricity Experiment, Lessons Learned, And Their Policy Implications For Developing Countries," *Energy Policy*, vol. 31, pp. 911-927, 2003.
- [4] S. Nugroho, E. Zusman, R. Nakano, K. Takahasi, K. Koakutsu, R. L. Kaswanto, N. Arifin, A. Munandar, H. S. Arifin, M. Muchtar, K. Gomi and T. Fujita, "The Effect of Prepaid Electricity System on Household Energy Consumption – the Case of Bogor, Indonesia," *Procedia Engineering*, vol. 198, pp. 642-653, 2017.
- [5] S. T. Setyo, H. Iswandi and Y. Yulius, "Perancangan Kampanye Cara Pintar dalam Berhemat Listrik Prabayar," *SENI DESAIN DAN BUDAYA*, vol. 4, no. 39, p. 44, 2019.
- [6] F. M. Mwaura, "Adopting Electricity Prepayment Billing System To Reduce Non-Technical Energy Losses In Uganda: Lesson From Rwanda," *Utilities Policy*, pp. 72-79, 2012.
- [7] M. H. Pusri, V. Herlina and M. Yosefa, "Implementasi Strategi Penurunan Tunggakan Rekening Listrik Di PT PLN (Persero) Wilayah Sumbar Cabang Sungai Penuh Upj Air Hangat Timur Unit Pelayanan Sungai Tutung," *Jurnal Administrasi Nusantara Mahasiswa (JAN Maha)*, vol. 3, no. 1, pp. 47-61, 2021.
- [8] P. A. M. Putra, D. A. S. Santiari and T. B. Putra M., "Persepsi Masyarakat Terhadap Keefektifan Penggunaan Kwhmeter Prabayar Di Wilayah Betngandang Sanur Bali," *Majalah Ilmiah Teknologi Elektro*, vol. 17, no. 2, pp. 221-226, 2018.
- [9] O. Wagner and J. Wiegand, "Prepayment metering: Household experiences in Germany," *Renewable and Sustainable Energy Reviews*, vol. 98, pp. 407-414, 2018.
- [10] M. Al-Mashraie, S. H. Chung and H. W. Jeon, "Customer Switching Behavior Analysis In The Telecommunication Industry Via Push-Pull-Mooring Framework: A Machine Learning Approach," *Computers & Industrial Engineering*, vol. 144, p. 106476, 2020.
- [11] K. Karim, M. J. Tajibu and A. Akhmad, "Determination of Consumer Switching Barriers to Use Prepaid Electricity Systems in the Household Sector in Makassar, Indonesia," *International Journal of Energy Economics and Policy*, vol. 11, no. 1, pp. 193-199, 2021.
- [12] M. O. Oseni, "Assessing The Consumers' Willingness To Adopt A Prepayment Metering System In Nigeria," *Energy Policy*, vol. 86, pp. 154-165, 2015.

- [13] A. F. Sasonko, "Pengaruh Kegiatan Komunikasi Periklanan, Hubungan Masyarakat, Promosi Penjualan dan Promosi Online Terhadap Minat Migrasi Listrik Prabayar," *Borobudur Communication Review*, vol. 1, no. 2, pp. 87-94, 2021.
- [14] Adliah, Sugandi and A. W. Arsyad, "Strategi Komunikasi Pemasaran PT PLN (Persero) Dalam Mempromosikan Listrik Prabayar (Studi Pada Bagian Pemasaran PT PLN Jalan Gajah Mada Kota Samarinda)," *eJournal Ilmu Komunikasi*, vol. 6, no. 3, pp. 570-582, 2018.
- [15] N. Nuraini, "Efektivitas Brosur PT PLN dan Minat Menggunakan Listrik Prabayar Pada Masyarakat," *Jurnal Ilmu Komunikasi FLOW*, vol. 2, no. 8, 2015.
- [16] M. H. Absori and D. Ramdani, "Prepaid Electricity Marketing Communication Strategy at PT. PLN (Persero) Temanggung Customer Service Unit," *AFEBI Management and Business Review (AMBR)*, vol. 5, no. 1, pp. 47-53, 2020.
- [17] N. Makanjuola, O. Shoewu, L. Akinyemi and Y. Ajose, "Investigating the Problems of Prepaid Metering Systems in Nigeria.," *The Pacific Journal of Science and Technology*, vol. 16, no. 2, pp. 22-31, 2015.
- [18] L. Natika, "Pengambilan Keputusan Pembelian Listrik Prabayar Dalam Perspektif Faktor Perilaku Konsumen Pada PT PLN Rayon Subang," *JIA Fakultas Ilmu Administrasi (FIA) UNSUB*, vol. 23, pp. 59-68, 2019.
- [19] E. Rahman, "Pengaruh Kualitas Produk Listrik Prabayar dan Kinerja Karyawan Terhadap Kepuasan Pelanggan Pada PT PLN (Persero) Area Gorontalo Rayon Telaga," *JURNAL ILMIAH MANAJEMEN DAN BISNIS*, vol. 1, no. 2, pp. 268-281, 2018.
- [20] K. C. O'Sullivan, H. E. Viggers and P. L. Howden-Chapman, "The Influence Of Electricity Prepayment Meter Use On Household Energy Behaviour," *Sustainable Cities and Society*, vol. 13, pp. 182-191, 2014.
- [21] N. S. Rumengan, P. Kindangen and M. H. C. Pandowo, "Analisis Komparatif dari Kepuasan Pelanggan Antara Listrik Jenis Prabayar dan Pascabayar di Manado," *Jurnal EMBA*, vol. 9, no. 4, pp. 640-647, 2021.
- [22] A. F. Aribisala, "The Effects of Prepaid Metering Systems on Customer Satisfaction in Niger State, Nigeria," *Journal of Digital Food, Energy & Water Systems*, vol. 2, no. 2, pp. 19-32, 2021.
- [23] M. E. Isnitahnia, Karnowahadi and I. Nurkhayati, "The Effect Of Push, Pull And Mooring Factors To Switching Intention Of Post-Paid Electrical Customer'S To Prepaid Electrical," *Jurnal JOBS*, vol. 5, no. 1, pp. 2467-8790, 2019.
- [24] T. S. Tambunan, "Pengaruh Perilaku Konsumen terhadap Keputusan Pemilihan Penggunaan KWH Meter Listrik Pascabayar dan Prabayar pada PT PLN (Persero) Ranting Pancur Batu," *Jurnal Nasional Manajemen Pemasaran & SDM*, vol. 1, no. 2, pp. 66-83, 2020.
- [25] Gunawan, "The Oportunity Of Data Mining For Macroeconomic Data Analysis: A Case Analysis Of East Java Provice," *Jurnal Ekonomi dan Pembangunan*, vol. 29, no. 2, pp. 183-198, 2021.