

PREDIKSI CHURN DAN SEGMENTASI PELANGGAN MENGUNAKAN BACKPROPAGATION NEURAL NETWORK BERBASIS EVOLUTION STRATEGIES

Junta Zeniarja¹, Ardytha Luthfiarta²

^{1,2}Fakultas Ilmu Komputer, Universitas Dian Nuswantoro Semarang
Jl. Nakula I No. 5-11 Semarang

Email: junta@dsn.dinus.ac.id¹, ardythaluthfi@dsn.dinus.ac.id²

Abstrak

Pelanggan merupakan bagian penting dalam memastikan keunggulan dan kelangsungan hidup perusahaan. Oleh karena itu perlu untuk memiliki sistem manajemen untuk memastikan pelanggan tetap setia dan tidak pindah ke pesaing lain, yang dikenal sebagai manajemen churn. Prediksi churn pelanggan adalah bagian dari manajemen churn, yang memprediksi perilaku pelanggan dengan klasifikasi pelanggan setia dan mana yang cenderung pindah ke kompetitor lain. Keakuratan prediksi ini mutlak diperlukan karena tingginya tingkat migrasi pelanggan ke perusahaan pesaing. Hal ini penting karena biaya yang digunakan untuk meraih pelanggan baru jauh lebih tinggi dibandingkan dengan mempertahankan loyalitas pelanggan yang sudah ada. Meskipun banyak studi tentang prediksi churn pelanggan yang telah dilakukan, penelitian lebih lanjut masih diperlukan untuk meningkatkan akurasi prediksi. Penelitian ini akan membahas penggunaan teknik data mining Backpropagation Neural Network (BPNN) in hybrid dengan Strategi Evolution (ES) untuk atribut bobot. Validasi model dilakukan dengan menggunakan validasi Palang 10-Fold dan evaluasi pengukuran dilakukan dengan menggunakan matriks kebingungan dan Area bawah ROC Curve (AUC). Hasil percobaan menunjukkan bahwa hibrida BPNN dengan ES mencapai kinerja yang lebih baik daripada Basic BPNN.

Kata kunci: data mining, churn, prediksi, backpropagation neural network, strategi evolusi.

Abstract

Customer is an important part in ensuring the triumph and survival of a company. Therefore it is necessary to have a management system to ensure customers remain loyal and do not move to another competitor, known as churn management. Customer churn prediction is part of the churn management, that predicting customer behavior by classifying which customer is loyal and which one has tended to move to other competitors. The accuracy of these predictions is absolutely necessary because of the high level of customer migration to the company's competitors. This is important because the cost used to reach new customers is much higher as compared to maintain the existing customer loyalty. Even though a lot of study about customer churn prediction has been done, further research is still needed to improve the accuracy of the prediction. This study will discuss the use of data mining techniques Backpropagation Neural Network (BPNN) in hybrid with a Evolution Strategies (ES) for attribute weighting. Validation of the model was done by using the 10-Fold Cross validation and evaluation of measurement were done by using the confusion matrix and the Area Under the ROC Curve (AUC). The experimental results show that the hybrid BPNN with ES achieved better performance than the Basic BPNN.

Keywords: data mining, pelanggan churn, prediction, backpropagation neural network, evolution strategies.

1. PENDAHULUAN

Pelanggan adalah aset yang paling penting dari semua jenis bisnis. Prospek usaha hanya mungkin dapat dilakukan dengan kehadiran pelanggan yang puas yang selalu setia dan membangun hubungan mereka dengan perusahaan. Untuk alasan ini, perusahaan harus merencanakan dan menerapkan strategi untuk menciptakan pelanggan, umumnya dikenal sebagai Customer Relationship Management (CRM). K. Tsiptsis dan A. Chorianopoulos [1] mendefinisikan CRM sebagai strategi yang terkait dengan mempertahankan, mengelola, dan meningkatkan hubungan pelanggan setia dan langgeng. Merujuk ke perspektif bisnis intelijen, proses manajemen *churn* dalam kerangka CRM terdiri dari dua bagian utama pemodelan analitis yang memprediksi bagi mereka yang cenderung *churn* atau tidak dan mendukung operator penyedia untuk membuat keputusan yang berharga dalam mempertahankan atau meningkatkan pelanggan baru. Oleh karena itu, artikel ini difokuskan pada pertimbangan dalam prediksi pelanggan *churn*. Prediksi *churn* pelanggan adalah bagian dari manajemen *churn*, yang memprediksi perilaku pelanggan dengan klasifikasi sebagai pelanggan setia dan mana yang cenderung untuk pindah ke kompetitor lain. "Pelanggan *churn*" berarti kehilangan klien. Ini memiliki arti yang sama seperti gesekan pelanggan, pembelotan pelanggan, dan perputaran pelanggan. *Churn* pelanggan juga didefinisikan oleh Hung et al. di mana layanan nirkabel industri telekomunikasi yang umum digunakan dalam jangka gerakan pelanggan dari satu operator ke yang lain [2]. Keakuratan prediksi ini mutlak diperlukan karena tingginya tingkat migrasi pelanggan untuk perusahaan pesaing. Manajemen *churn* merupakan

tugas penting bagi perusahaan untuk mempertahankan pelanggan yang berharga. Riset pemasaran menunjukkan bahwa rata-rata nilai pelanggan yang *churn* atau pindah ke pesaing lain dari perusahaan operator seluler adalah sekitar 2,2% per bulan. Hung et al. [2] menyebutkan bahwa ada sekitar 27% dari pelanggan hilang setiap tahun. Berdasarkan riset pasar, keadaan ini mendorong perusahaan untuk menyediakan biaya untuk dukungan penjualan, pemasaran, iklan, dan komisi untuk mendapatkan pelanggan layanan mobile dengan pelanggan baru adalah sekitar \$ 300 sampai \$ 600. Dengan demikian, biaya untuk mendapatkan pelanggan baru jauh lebih tinggi daripada mempertahankan yang baru dan karenanya, kemampuan untuk memprediksi *churn* pelanggan adalah suatu keharusan.


1.1 BPNN

BPNN didefinisikan sebagai contoh dari suatu metode pembelajaran. Memiliki jaringan *feed forward* beberapa layer dengan bobot pola pas yang dapat digunakan untuk memodelkan beberapa diagram antara variabel set input dan output [3]. Arsitektur jaringan ditunjukkan pada Gambar 1 yang terdiri dari tiga unit output dan hidden layer tunggal, yang dapat dilatih menggunakan *back propagation*. Node yang diarsir pada gambar adalah unit pengolahan. Tanda panah yang menghubungkan input ke unit tersembunyi dan unit tersembunyi ke unit keluaran mewakili bobot.

1.2 ES

ES adalah pendekatan lain untuk mensimulasikan evolusi alam, yang telah diusulkan di Jerman pada awal 1960-an. Ingo Rechenberg dan Hans-Paul Schwefel dari Technical University of Berlin adalah ES yang dikembangkan

pertama kali. Keduanya bekerja terowongan angin dari Institut Teknik Aliran dalam penelitian. Berdasarkan penelitian melelahkan dilakukan oleh mereka untuk menemukan solusi optimal, maka keduanya memutuskan untuk menggunakan perubahan acak dalam parameter untuk mendefinisikan bentuk berdasarkan mutasi alam. Oleh karena itu berdasarkan penelitian ini maka strategi evolusi diciptakan [4]. Tidak seperti GAs, ES hanya beroperasi sebagai operator mutasi. ES biasanya diterapkan dalam masalah optimasi teknis.



Gambar 1. Arsitektur Back Propagation

2. METODE

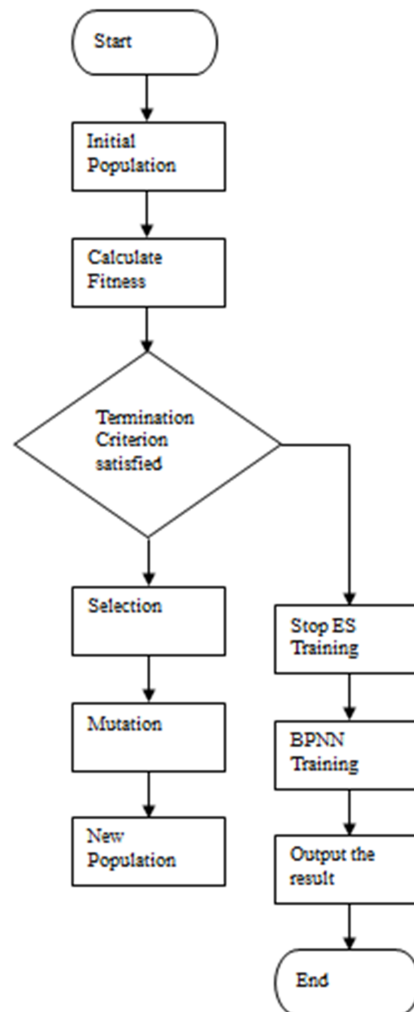
Ada empat metode penelitian yang umum digunakan yaitu penelitian tindakan, eksperimen, studi kasus, dan survey [5]. Penelitian eksperimen terdiri dari dua jenis, percobaan mutlak dan komparatif. Penelitian eksperimental umumnya dilakukan dalam memecahkan pengembangan, evaluasi, dan masalah proyek. Penelitian ini akan mengadopsi metode penelitian eksperimen komparatif yang akan membandingkan dua model klasifikasi untuk prediksi *churn* pelanggan. Model

pertama adalah dasar BPNN, dan model kedua adalah ES-BPNN.

2.1 Dataset

Untuk artikel ini, data set *churn* yang digunakan adalah UCI Repository dari Machine Learning Database di University of California, Irvine. Kumpulan data terdiri dari 20 variabel, dan berisi informasi dari sekitar 5000 pelanggan. Dari jumlah tersebut, 3333 diantaranya digunakan sebagai data training dan sisanya 1667 digunakan sebagai data uji. Indikasi apakah atau tidak pelanggan yang *churn* (meninggalkan perusahaan) juga termasuk dalam data.

2.2 Usulan Model



Gambar 2. Model ES-BPNN

2.3 Metode Evaluasi

Akurasi kinerja untuk memprediksi *churn* pelanggan dievaluasi oleh pengukuran evaluasi. Sejak BPNN adalah bagian dari teknik klasifikasi data mining, tabel confusion matrix dan ROC Curve (AUC) akan digunakan untuk mengukur akurasi model yang diusulkan [6].

2.4 Alat Penelitian

Alat penelitian yang digunakan untuk mendukung rancangan percobaan disajikan dalam artikel ini. Alat penelitian terdiri dari perangkat keras dan perangkat lunak. Kebutuhan hardware yang digunakan untuk menjalankan penelitian ini terdiri dari:

- OS : Windows 7 Ultimate 32-bit
- Processor : Intel® Core™ i3 370 Mobile
- RAM : Sodimm 4 GB DDR3 10600 Mhz
- GPU : Ati Mobility HD5470 512 MB

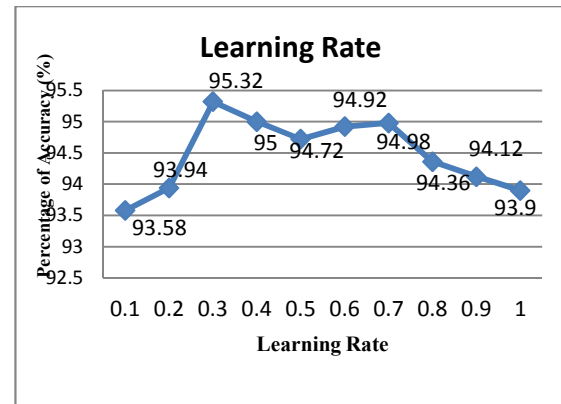
Software yang digunakan dalam penulisan ini adalah RapidMiner Versi 5.3. Persyaratan untuk menggunakan RapidMiner adalah Java Runtime Environment (JRE) versi 1.5 (resmi Java 5.0) atau lebih tinggi yang harus diinstal pada sistem.

3. HASIL DAN PEMBAHASAN


3.1 Backpropagation Training Network

Nilai dari siklus pelatihan jaringan syaraf ditentukan oleh trial and error, dalam hal ini dengan memasukkan nilai antara 50 sampai 1000. Metode yang sama juga digunakan untuk jumlah dan ukuran Hidden layer sebagai parameter kedua. Nilai default 0,3 dan 0,2 digunakan untuk tingkat pembelajaran dan momentum masing-masing. Nilai –

nilai yang mampu memberikan akurasi terbaik untuk pemilihan parameter jaringan saraf berikutnya dipilih.



Gambar 3. Nilai Learning Rate



Gambar 4. Nilai Momentum


Nilai *Learning Rate* dipilih dengan memasukkan nilai *Learning Rate* antara 0,1 sampai 0,9 dengan standar momentum 0,3. Nilai dari *training cycle* dan *hidden layer* dipilih berdasarkan percobaan sebelumnya. Hasil percobaan ditunjukkan dalam gambar 3 dan Gambar 4. Dari hasil, akurasi terbaik dicapai dengan *Learning Rate* 0,3. Metode yang sama diterapkan untuk memilih nilai momentum. Dengan memperbaiki nilai *Learning Rate* berdasarkan hasil percobaan untuk memilih harga *Learning Rate*, yang *Learning Rate*-nya adalah 0,3.

3.2 ES-BPNN

Tabel 1: Hasil Perbandingan

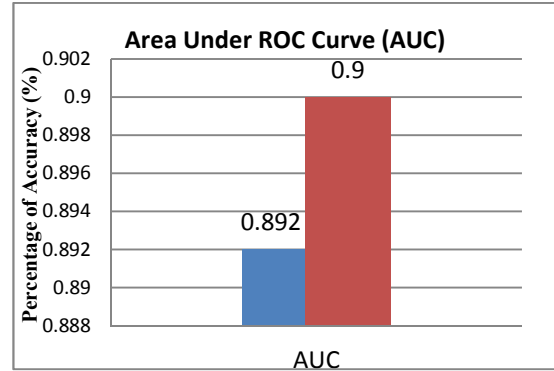
Comparison		Basic BPNN	ES-BPNN
Accuracy (Confusion Matrix)		95.32%	96.30%
Precision (Confusion Matrix)		92.62%	94.64%
Recall (Confusion Matrix)		73.13%	78.24%
Accuracy (AUC)		0.892	0.9
Execution time:		3 m. 52 s	5h. 24m. 06s

Pada tabel 1 di atas merupakan perbandingan akurasi antara *Basic BPNN* dan *ES-BPNN*. Hal ini menunjukkan bahwa *ES-BPNN* mengungguli di semua pengujian. Tapi waktu komputasi untuk *ES-BPNN* sangat panjang yaitu 5 jam 24 menit dan 06 detik, dibandingkan dengan *BPNN* dasar yang hanya membutuhkan waktu 3 menit 52 detik.



Gambar 5. Hasil Perbandingan Akurasi dari Basic BPNN dengan ES-BPNN

Gambar 5 menunjukkan hasil perbandingan nilai *accuracy*, *precision* dan *recall*. Dimana warna biru sebagai *Basic BPNN* dan warna merah sebagai *ES-BPNN*. Dari diagram diatas menunjukkan *ES-BPNN* lebih baik dibandingkan dengan *Basic BPNN* karena nilai *accuracy*, *precision* dan *recall* yang lebih tinggi yaitu 96.3%, 94.64% dan 78.24%.



Gambar 6. Hasil Perbandingan kurva ROC (AUC) dari Basic BPNN dengan ES-BPNN

Gambar 6 menunjukkan hasil perbandingan kurva ROC (AUC). Dimana warna biru sebagai *Basic BPNN* dan warna merah sebagai *ES-BPNN*. Dari diagram diatas menunjukkan *ES-BPNN* lebih baik dibandingkan dengan *Basic BPNN* karena nilai *AUC* yang lebih tinggi yaitu 0.9.

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Model yang diusulkan dari *ES-BPNN* menghasilkan akurasi yang lebih baik dengan 96,30% dibandingkan dengan *Basic BPNN* dengan 95,32%. Tapi waktu komputasi untuk *ES-BPNN* sangat panjang yaitu 5 jam 24 menit 6 detik, dibandingkan dengan *Basic BPNN* yang hanya membutuhkan waktu 3 menit 52 detik.

Meskipun *ES-BPNN* mencapai hasil yang lebih baik, tetapi waktu eksekusinya lebih lama. Kita bisa menggunakan *ES-BPNN* untuk memprediksi klasifikasi secara offline yang hasilnya membutuhkan akurasi yang lebih tinggi tanpa mempertimbangkan waktu eksekusi. Selanjutnya jika kasus tersebut untuk prediksi klasifikasi seperti jaringan

intrusion detection online, *Basic BPNN* lebih handal.

4.2 Saran

Penelitian ini memiliki beberapa keterbatasan, maka ada beberapa masalah dapat dipertimbangkan untuk pekerjaan di masa depan antara lain :

- 1) Meskipun *ES-BPNN* mencapai hasil yang lebih baik tapi waktu eksekusi yang bersangkutan, untuk pekerjaan di masa depan dapat diterapkan *ES-BPNN* dengan waktu yang lebih pendek.
- 2) Langkah Preprocessing dalam data mining memiliki bagian penting untuk meningkatkan akurasi kinerja sehingga pekerjaan berikutnya seleksi fitur dapat diterapkan.
- 3) Penelitian ini membandingkan *Back-Propagation Neural Network* dengan kombinasi *Evolutionary Strategies - Backpropagation Neural Network*, untuk masa depan dapat menggunakan teknik klasifikasi data mining lainnya seperti *Decision Tree (DT)*, *Support Vector Machine (SVM)* dapat diterapkan untuk *Evolutionary Strategies* atau teknik optimasi lain seperti *Genetic Algorithm (GA)*, *Particle Swam Optimization (PSO)*.
- 4) Penelitian ini menggunakan *UCI Churn Dataset* dari *learning repositori UCI Machine*, untuk pekerjaan di masa depan dataset publik lainnya tentang *churn* pelanggan dapat diterapkan seperti data set dari *Terdata Duke University* atau *ACM Piala KDD Cup*.

Chichester, UK: John Wiley & Sons, Ltd, 2010.

- [2] S.-Y. Hung, D. C. Yen, and H.-Y. Wang, "Applying data mining to telecom churn management," *Expert Systems with Applications*, vol. 31, no. 3, pp. 515–524, Oct. 2006.
- [3] I. Witten and E. Frank, "Data Mining: Practical machine learning tools and techniques," 2011.
- [4] M. Negnevitsky, *Artificial Intelligence : A Guide to Intelligent Systems*. Pearson Education Limited, 2005.
- [5] W. Dawson, *Projects in Computing and Information Systems A Student Guide*. 2009.
- [6] Gorunescu, *Data Mining Concepts, Models and Techniques*. 2011.

DAFTAR PUSTAKA

- [1] K. Tsipstsis and A. Chorianopoulos, *Data Mining Techniques in CRM*.