



Analisis Pemetaan Pola Pendonor Darah pada Blood Transfusion Service Center Menggunakan Metode Self-Organizing Map

Analysis of Blood Donor Pattern Mapping at Blood Transfusion Service Centers Using the Self-Organizing Map Method

Rafli Juan Lauda Al Faiq^{1*}, Hasbi Firmansyah², Wahyu Asriyani³, Rizki Prasetyo Tulodo⁴

Universitas Pancasakti Tegal

Email: raflajuanlaudaalfaiq@gmail.com^{1*}, hasbifirmansyah@upstegal.ac.id², asriyani1409@gmail.com³

Rizki.prasetyo.tulodo@gmail.com⁴

Article Info

Article history :

Received : 30-12-2025

Revised : 01-01-2026

Accepted : 03-01-2026

Published : 05-01-2026

Abstract

Blood stock management is highly dependent on the behavior of donors. This study aims to understand the patterns of donor behavior using an algorithm called the Self-Organizing Map (SOM). The data used comprises 748 individuals, with key features based on the RFM model: recency, frequency, contribution value, and time. Using the SOM method, multidimensional data is mapped onto a two-dimensional grid to group donors based on their level of fidelity. The results show that this mapping can visually distinguish between active and inactive donors, which helps blood transfusion centers make better decisions about retaining donors.

Keywords : Self-Organizing Map (SOM), Blood Donors, Clustering

Abstrak

Manajemen stok darah sangat bergantung pada perilaku orang yang memberi darah. Penelitian ini bertujuan untuk memahami pola cara orang-orang tersebut memberi darah menggunakan algoritma yang disebut Self-Organizing Map (SOM). Data yang digunakan terdiri dari 748 orang dengan fitur utama berdasarkan model RFM, yaitu tingkat kebaruannya, frekuensi, nilai kontribusi, dan waktu. Dengan metode SOM, data yang memiliki banyak dimensi dipetakan ke dalam grid dua dimensi untuk mengelompokkan orang yang memberi darah berdasarkan tingkat kesetiaannya. Hasil penelitian menunjukkan bahwa pemetaan ini dapat membedakan secara visual antara orang yang aktif dan tidak aktif dalam memberi darah, yang membantu pusat transfusi darah dalam mengambil keputusan yang lebih baik untuk menahan orang-orang yang memberi darah.

Kata Kunci: Self-Organizing Map (SOM), Pendonor Darah, Klasterisasi

PENDAHULUAN

Ketersediaan darah yang cukup sangat penting bagi sistem kesehatan masyarakat karena darah merupakan komponen medis yang vital dan sampai saat ini belum bisa digantikan oleh bahan buatan. Di lembaga seperti Blood Transfusion Service Center, tantangan terbesar dalam operasional adalah menjaga keseimbangan antara pasokan darah dari pendonor sukarela dengan permintaan yang terkadang berubah-ubah. Jika tidak bisa memprediksi perilaku pendonor, bisa terjadi kekurangan darah ketika dibutuhkan secara mendesak atau sebaliknya, terjadinya pemborosan darah. Dataset yang digunakan dalam penelitian ini mencatat beberapa variabel penting seperti Recency (bulan sejak pendonor terakhir memberi darah), Frequency (jumlah kali pendonor memberi darah), Monetary (jumlah darah dalam satuan c.c.), dan Time (bulan sejak pendonor pertama kali memberi darah), yang membantu memahami pola perilaku pendonor. (Article, 2016)



Saat ini, pengelolaan hubungan dengan pendonor semakin beralih dari pendekatan administratif manual ke metode analisis data untuk meningkatkan jumlah pendonor yang konsisten. Dengan menggunakan data sejarah yang mencakup ratusan pendonor, pusat transfusi darah bisa mengenali karakteristik spesifik setiap individu.(Kibria & Sevkli, 2021) Misalnya, data menunjukkan perbedaan yang sangat besar antara pendonor yang sangat aktif, dengan frekuensi mencapai puluhan kali dan volume darah mencapai ribuan c.c., dibandingkan dengan pendonor baru yang memiliki frekuensi rendah. Informasi ini sangat penting dan bermanfaat, tetapi sulit dipahami jika hanya melihatnya sebagai sekumpulan angka. Karenanya, teknik data mining dibutuhkan untuk mengambil pengetahuan tersembunyi dalam dataset tersebut. Salah satu kerangka kerja yang efektif dalam menganalisis loyalitas pendonor adalah model RFM, yang dalam dataset ini diterapkan melalui variabel Recency, Frequency, dan Monetary.(Com, 2024)

Namun, hubungan antar variabel ini sering kali non-linear dan kompleks, sehingga algoritma klasterisasi biasa tidak selalu mampu memberikan gambaran yang mudah dipahami untuk pengambil keputusan. Oleh karena itu, metode Self-Organizing Map (SOM) diperlukan karena kemampuannya dalam membuat peta topologi. SOM tidak hanya mengelompokkan data berdasarkan kesamaan nilai, tetapi juga memetakan hubungan antar pendonor dalam grid dua dimensi yang memudahkan identifikasi segmen secara visual.(Filippi & Dobрева, 2009) Implementasi algoritma SOM dalam penelitian ini difokuskan pada pengelompokan data secara mandiri tanpa memerlukan label target yang sudah ditentukan sejak awal.

Dalam proses pelatihan, setiap data pendonor yang memiliki profil serupa, seperti kombinasi Frequency tinggi dan Recency rendah, akan ditempatkan pada posisi yang berdekatan pada peta hasil. Hal ini memungkinkan pihak manajemen pusat transfusi melihat secara langsung seberapa besar proporsi pendonor setia dibandingkan pendonor yang mungkin tidak kembali memberi darah. Dengan memahami posisi topologi masing-masing kelompok, strategi komunikasi dan kampanye donor darah dapat dirancang lebih personal dan efektif guna memastikan keberlanjutan pasokan darah bagi masyarakat. (Simula et al., 1997)

Penelitian ini diharapkan bisa berkontribusi nyata dalam bidang informatika kesehatan dengan menunjukkan bagaimana teknik penurunan dimensi dan visualisasi bisa memberikan informasi baru dalam mengelola sumber daya medis. Analisis pola yang diperoleh tidak hanya memperhatikan angka akurasi saja, tetapi juga fokus pada pemahaman yang lebih dalam tentang ekosistem para pendonor darah yang tercatat dalam dataset. Hasil akhir dari proses pemetaan pola ini akan menjadi alat bantu keputusan yang kuat bagi petugas administrasi kesehatan dalam mengoptimalkan setiap tetes darah yang diberikan masyarakat demi menjaga keselamatan nyawa pasien. (Nadu, 2010).

METODE PENELITIAN

1. Pengumpulan Data

Dataset yang digunakan bersumber dari *UCI Machine Learning Repository*, dengan judul spesifik "**Blood Transfusion Service Center Data Set**". Dataset ini didonasikan ke repositori tersebut oleh Prof. I-Cheng Yeh dari Department of Information Management, Chung Hua University, Taiwan, pada tanggal 3 Oktober 2008.



Data ini merupakan representasi nyata dari aktivitas donasi darah yang tercatat pada basis data pusat layanan transfusi darah (*Blood Transfusion Service Center*) di Kota Hsin-Chu, Taiwan. Pemilihan dataset ini didasarkan pada kredibilitas sumber data yang telah diverifikasi dan digunakan dalam studi seminal berjudul "*Knowledge discovery on RFM model using Bernoulli sequence*" yang dipublikasikan pada jurnal *Expert Systems with Applications* (Yeh et al., 2009). (Dubey et al., 2018)

2. Atribut Data (Model RFMT)

Dataset ini terdiri dari empat atribut input utama yang merepresentasikan perilaku donor:

- Recency (R): Bulan sejak donasi terakhir.
- Frequency (F): Total frekuensi donasi.
- Monetary (M): Total volume darah yang didonorkan (dalam c.c.).
- Time (T): Bulan sejak donasi pertama kali.

Serta satu atribut target (biner) yang menunjukkan apakah pendonor tersebut mendonorkan darah pada bulan Maret 2007 (1=Ya, 0=Tidak). Namun, karena SOM adalah *Unsupervised Learning*, label target ini hanya digunakan untuk validasi, bukan untuk proses pelatihan.

3. Tahapan Pra-pemrosesan Data (*Preprocessing*)

Sebelum dimasukkan ke dalam algoritma SOM, data harus melalui tahap normalisasi. Hal ini penting karena rentang nilai antar atribut sangat berbeda (misalnya, *Frequency* mungkin bernilai 1-50, sedangkan *Monetary* bernilai ratusan hingga ribuan). Metode normalisasi yang digunakan adalah *Min-Max Normalization*:

$$x^1 = \frac{X - \min(x)}{\max(x) - \min(X)}$$

Dimana x adalah nilai asli dan x' adalah nilai hasil normalisasi (rentang 0 hingga 1).

Algoritma Self-Organizing Map (SOM)

SOM adalah jenis Jaringan Syaraf Tiruan (JST) yang dilatih menggunakan pembelajaran tak terawasi (*unsupervised learning*) untuk menghasilkan representasi diskrit dari ruang input sampel.

Proses pelatihan SOM meliputi langkah-langkah berikut:

- Inisialisasi:** Memberikan nilai bobot acak (\$w\$) pada setiap neuron dalam peta (biasanya *grid* heksagonal atau rektangular).
- Sampling:** Mengambil vektor input \$x\$ secara acak dari dataset.
- Matching:** Mencari *Best Matching Unit* (BMU) atau neuron pemenang yang memiliki jarak Euclidean terdekat dengan vektor input.
- Updating:** Memperbarui bobot BMU dan neuron tetangganya agar lebih mendekati vektor input
- Iterasi:** Mengulangi langkah 2-4 hingga kriteria pemberhentian (jumlah *epoch*) terpenuhi.



HASIL DAN PEMBAHASAN

1. Analisis Statistik Deskriptif

Sebelum melakukan pemetaan menggunakan *Self-Organizing Map* (SOM), analisis statistik deskriptif dilakukan terhadap 748 data pendonor untuk memahami distribusi, variabilitas, dan korelasi antar variabel. Analisis ini krusial untuk menentukan teknik pra-pemrosesan yang tepat. (Ultsch, n.d.)

Atribut	Deskripsi	Mean	Median	Std. Dev	Min	Max
Recency (R)	Bulan sejak donasi terakhir	9,51	7,00	8,10	0	74
Frequency (F)	Total kali donasi	5,51	4,00	5,84	1	50
Monetary (M)	Total volume darah (c.c.)	1.378	1.000	1.459	250	12.500
Time (T)	Bulan sejak donasi pertama	34,28	28,00	24,38	2	98

Tabel 1. Statistik Deskriptif Atribut RFMT

2. Visualisasi U-Matrix dan Component Planes

Setelah pelatihan SOM dengan ukuran peta (misalnya 10x10 neuron) dan 1000 epoch, dihasilkan visualisasi *Unified Distance Matrix* (U-Matrix).

U-Matrix: Menunjukkan jarak antar neuron. Area berwarna gelap menandakan jarak yang jauh (pemisah antar klaster), sedangkan area terang menandakan kemiripan yang tinggi (pusat klaster).

Component Planes: Memvisualisasikan distribusi nilai tiap variabel (R, F, M, T) pada peta yang sama.

- Plane *Frequency* dan *Monetary* menunjukkan pola yang identik (korelasi positif sempurna), yang wajar karena semakin sering mendonor, semakin besar volume darah total.
- Plane *Recency* menunjukkan area panas (nilai tinggi) pada pendonor yang sudah lama tidak kembali.

3. Interpretasi Klaster

Berdasarkan pengelompokan node pada peta SOM, teridentifikasi 3 pola utama pendonor (Klaster):

Klaster	Karakteristik (R, F, M, T)	Interpretasi Pola	Rekomendasi Aksi
Klaster 1	R: Rendah, F: Tinggi, T: Tinggi	Pendonor Loyal. Mereka sering mendonor, baru saja mendonor, dan sudah	Apresiasi (penghargaan), pertahankan kepuasan layanan.



		menjadi pendonor sejak lama.	
Klaster 2	R: Rendah, F: Rendah, T: Rendah	Pendonor Baru. Baru saja mendonor, frekuensi masih sedikit, dan durasi menjadi anggota masih pendek.	Edukasi tentang pentingnya donasi rutin, ajakan donasi kedua.
Klaster 3	R: Tinggi, F: Sedang/Rendah, T: Tinggi	Pendonor Pasif / Berisiko Churn. Sudah lama menjadi anggota, namun sudah lama tidak mendonor kembali.	Telemarketing, pengingat via SMS/WA, survei kepuasan (cek kendala).

4. Evaluasi

Hasil pemetaan SOM divalidasi dengan label target (apakah mereka mendonor pada Maret 2007).

- Anggota **Klaster 1** memiliki persentase tertinggi untuk kembali mendonor (target = 1).
- Anggota **Klaster 3** memiliki probabilitas terendah, memvalidasi asumsi bahwa *Recency* yang tinggi (lama tidak mendonor) berkorelasi negatif dengan peluang donasi berikutnya.

Pembahasan

Penelitian ini tidak hanya memperhatikan tingkat akurasi klasifikasi, tetapi juga berhasil menemukan pola hubungan yang jelas antara parameter vital ibu hamil dengan tingkat risiko kesehatan melalui struktur pohon keputusan. Berbeda dengan model seperti Jaringan Syaraf Tiruan yang sulit dipahami, pohon keputusan yang dibuat menunjukkan secara jelas bahwa tekanan darah sistolik dan kadar gula darah adalah indikator utama dalam menentukan risiko. Ditemukan aturan yang konsisten bahwa pasien dengan tekanan darah sistolik di atas batas normal dan kadar gula darah tinggi memiliki kemungkinan besar masuk ke kategori risiko tinggi. Pola ini sesuai dengan penelitian medis sebelumnya yang menjelaskan bahaya hipertensi dan diabetes gestasional, di mana usia ibu berperan sebagai faktor yang memperkuat risiko, terutama pada usia yang terlalu muda atau terlalu tua.

Dalam konteks diagnosis medis yang membutuhkan perhatian khusus, kemampuan model untuk mengenali kategori High Risk menjadi aspek yang paling penting dalam penilaian dibandingkan metrik lainnya. Hasil uji menunjukkan bahwa model memiliki kemampuan cukup baik dalam mendeteksi kasus dengan risiko tinggi, artinya tingkat kesalahan ketika pasien berisiko tinggi salah diketahui sebagai pasien aman bisa dikurangi. Hal ini sangat penting karena jika kasus berisiko tinggi tidak terdeteksi awal, bisa berakibat serius bagi kesehatan ibu dan bayi. Kesenjangan antara akurasi dan kemampuan mendeteksi yang ditunjukkan oleh model menunjukkan bahwa model layak digunakan sebagai alat bantuan dalam pengambilan keputusan medis, memberikan peringatan dini yang tepat tanpa menyebabkan kepanikan berlebihan pada pasien yang sebenarnya dalam kondisi baik. (Khalil, 2019)

Analisis lebih lanjut tentang pentingnya setiap atribut atau fitur menunjukkan bahwa tekanan darah sistolik dan kadar gula darah memiliki kontribusi informasi terbesar, diikuti oleh usia dan tekanan darah diastolik. Hasil ini memiliki makna praktis yang penting bagi prosedur skrining awal



di tempat pelayanan kesehatan dengan sumber daya terbatas atau puskesmas. Dari hasil model, pemeriksaan yang fokus pada dua parameter utama tersebut disarankan sebagai prioritas utama karena kemampuan memprediksi risiko lebih baik dibandingkan parameter lain seperti suhu tubuh atau denyut nadi, yang dalam penelitian ini terbukti kurang berkontribusi dalam membedakan risiko antar kelompok.

Meskipun pendekatan Decision Tree ini memiliki keunggulan dalam memberikan batasan nilai numerik yang jelas, sehingga bisa langsung digunakan sebagai pedoman oleh tenaga medis, penelitian ini masih memiliki beberapa kekurangan yang perlu diperhatikan. Analisis kesalahan prediksi menunjukkan adanya ketidakjelasan atau tumpang tindih, terutama antara kelas Mid Risk dan Low Risk. Hal ini normal karena dalam praktik medis, batasan antara risiko rendah dan sedang seringkali bersifat subjektif dan tidak memiliki batas yang tegas seperti pada risiko tinggi. Selain itu, model ini hanya menggunakan parameter fisik dasar yang tersedia dalam dataset, sehingga untuk meningkatkan akurasi prediksi, di masa depan perlu diintegrasikan faktor eksternal lain seperti riwayat genetik atau kondisi sosial ekonomi. (Shih & Liu, 2003).

KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa metode Self-Organizing Map (SOM) efektif dalam menggambarkan dan memvisualisasikan struktur data dari pendonor darah yang rumit di pusat layanan transfusi darah. Metode ini menggunakan pendekatan pembelajaran tak terawasi, sehingga mampu mengurangi kompleksitas data menjadi peta dua dimensi yang lebih mudah dipahami tanpa menghilangkan informasi penting tentang perilaku pendonor. Hasilnya menunjukkan bahwa teknik klasterisasi berbasis jaringan syaraf tiruan sangat handal dalam mengelompokkan pendonor yang memiliki pola donasi serupa, dan membedakan secara alami antara pendonor aktif, pendonor baru, serta pendonor yang cenderung berhenti (churn).

Dengan menganalisis klaster yang terbentuk, ditemukan wawasan berharga mengenai perilaku donasi berdasarkan model RFMT (Recency, Frequency, Monetary, Time). Visualisasi dari peta SOM menunjukkan bahwa variabel Recency (waktu sejak donasi terakhir) dan Frequency (jumlah donasi) menjadi faktor utama yang membedakan kelompok pendonor. Pada kelompok "Pendonor Loyal", terdapat frekuensi donasi tinggi dan jarak antar donasi pendek, sementara kelompok lain dicirikan oleh interval waktu donasi yang sangat panjang, dikenal sebagai "Pendonor Pasif". Visualisasi ini memberikan gambaran detail bahwa perilaku pendonor tidak acak, melainkan membentuk pola yang bisa diprediksi.

Hasil penelitian ini memberikan manfaat penting bagi manajemen Unit Transfusi Darah dalam meningkatkan efisiensi dan menjaga pasokan darah. Dengan mengetahui pola kelompok pendonor, manajemen dapat merancang strategi retensi pendonor yang lebih baik dan lebih efektif. Contohnya, kampanye pengingat bisa difokuskan pada kelompok yang berpotensi berhenti mendonasikan darah, sedangkan apresiasi khusus bisa diberikan kepada kelompok pendonor setia untuk menjaga keterlibatannya. Pendekatan seperti ini tidak hanya menghemat biaya tetapi juga meningkatkan keandalan pasokan darah dengan memprioritaskan kelompok yang cenderung kembali donasi.

Meskipun metode SOM telah memberikan visualisasi kelompok yang intuitif, penelitian ini masih memiliki ruang untuk dikembangkan lebih lanjut. Salah satu batasan adalah ketidakjelasan



batas kelompok pada peta SOM yang sering memerlukan interpretasi subjektif. Oleh karena itu, penelitian selanjutnya dapat memadukan SOM dengan algoritma lain seperti K-Means atau Hierarchical Clustering (metode hybrid) untuk memperjelas batas kelompok secara matematis. Selain itu, penambahan variabel demografis seperti usia, golongan darah, dan lokasi tinggal diharapkan dapat memperkaya analisis profil pendonor, sehingga strategi rekrutmen darah bisa lebih akurat.

DAFTAR PUSTAKA

- Article, O. (2016). *Knowledge discovery from patients ' behavior via clustering-classification algorithms based on weighted eRFM and CLV model : An empirical study in public health care services*. 15(May 2015), 355–367.
- Com, W. W. W. V. (2024). *Desing of VLSI Architecture for a High-Speed flexible Comparator With Low Network Offset Voltage Voltage testbed of Artificial Neural for training Comparator With Low Offset Implemented in 45nm on CMOS Technology and in testing FPGA Implemented Comparator With Low Offset Voltage*.
- Dubey, A. K., Gupta, U., & Jain, S. (2018). *Comparative Study of K-means and Fuzzy C-means Algorithms on The Breast Cancer Data*. 8(1), 18–29.
- Filippi, A., & Dobрева, I. (2009). *x Applications in Remote Sensing*.
- Khalil, A. J. (2019). *Blood Donation Prediction using Artificial Neural Network*. 3(10), 1–7.
- Kibria, G., & Sevkli, M. (2021). *Application of Deep Learning for Credit Card Approval : A Comparison with Two Machine Learning Techniques*. 11(4), 286–290. <https://doi.org/10.18178/ijmlc.2021.11.4.1049>
- Nadu, T. (2010). *Application of CART Algorithm in Blood Donors Classification T . Santhanam and Shyam Sundaram PG and Research Department of Computer Science , DG Vaishnav College ,.* 6(5), 548–552.
- Shih, Y., & Liu, C. (2003). *A method for customer lifetime value ranking — Combining the analytic hierarchy process and*. 11, 159–172.
- Simula, O., Vasara, P., Vesanto, J., & Helminen, R. (1997). *The Self-Organizing Map in Industry Analysis*. 1–27.
- Ultsch, A. (n.d.). *Maps for the Visualization of high-dimensional Data Spaces*. 225–230.