

PREDIKSI OPERASI SESAR DENGAN MACHINE LEARNING

Agung Wibowo¹, Ida Darwati², Oky Irnawati³

Universitas Bina Sarana Informatika

Jl. Kemal Raya No. 18, Ringroad Barat, Cengkareng, Jakarta Barat

E-mail : agung.awo@bsi.ac.id¹, ida.idd@bsi.ac.id², oky.okt@bsi.ac.id³

Abstract

The cost of childbirth with a cesarean section at this time is doubled compared to the cost of a normal delivery, this is certainly mandatory for families. Machine learning can be one option to predict the possibility of labor by cesarean. Previous researchers had made predictions by classifying the cesarean operation dataset, but the accuracy of the test results showed different results. This paper verifies test results by retesting using the Multi Layer Preceptron (MLP) algorithm. Previous researchers did not carry out the process of dividing the dataset into training and testing datasets. This study divides the dataset into training and testing datasets so that its accuracy can be accounted for. The test results showed that the best accuracy was in the range of 56% and the dataset identified as underfit.

Abstrak

Biaya persalinan dengan operasi sesar saat ini biaya nya berlipat dibandingkan dengan biaya persalinan normal hal ini tentunya wajib diantisipasi oleh keluarga. Machine learning dapat menjadi salah satu opsi untuk memprediksi kemungkinan persalinan dengan sesar. Peneliti sebelumnya sudah melakukan prediksi dengan cara mengklasifikasikan dataset operasi sesar, tetapi akurasi hasil uji menunjukkan hasil yang berbeda. Paper ini melakukan verifikasi hasil uji dengan melakukan uji ulang menggunakan algoritma Multi Layer Preceptron (MLP). Peneliti sebelumnya tidak melakukan proses pembagian dataset menjadi dataset training dan testing. Penelitian ini membagi dataset dibagi menjadi dataset *training* dan *testing* sehingga nilai akurasinya dapat pertanggungjawabkan. Hasil uji menunjukkan bahwa akurasi terbaik berada pada kisaran 56% dan dataset nya teridentifikasi *underfit*.

I. PENDAHULUAN

Biaya persalinan dengan operasi sesar saat ini biaya nya berlipat bahkan bisa melewati angka 400% dibandingkan dengan biaya persalinan normal. Biaya persalinan yang besar ini harus dipersiapkan sejak awal kehamilan. Tahun 2018 di UCI *machine learning repository* menyertakan dataset operasi sesar yang sebelumnya telah diuji menggunakan mesin pembelajaran. Istilah pembelajaran mesin itu sendiri pertama kali diperkenalkan tahun 1959 oleh Arthur Samuel (Fayyad, Smyth, P, & Shapiro, 1996). Tahun 1970-an pembelajaran mesin dan analitik data digunakan pada sistem informasi layanan kesehatan (Han, Kamber, & Pei, 2006.). Peran pembelajaran mesin dalam bidang data mining dan pemrosesan dataset yang besar meningkat dengan penemuan beberapa algoritma seperti metode support vector machine pada 1990-an (Kantardzic, 2003). Tahun 1970-an pembelajaran mesin dan analitik data digunakan pada sistem informasi layanan kesehatan (Han, Kamber, &

Pei, 2006.). Pembelajaran kontrol mesin dapat menyarankan indikasi untuk pengambilan keputusan dan dapat menjadi jawaban atas batasan kemampuan manusia dalam hal subjektivitas karena kelelahan (Candelieri, 2011). InTech. Tahun 2018 diperkirakan bahwa big data dan pembelajaran mesin dapat menghasilkan \$100 miliar per tahun untuk pengambilan keputusan, inovasi dan peningkatan efisiensi uji klinis (Manyika, et al., 2011). Pengetahuan yang diperoleh dengan machine learning dapat digunakan untuk memprediksi tren kondisi pasien secara singkat dan mengurangi biaya layanan kesehatan. Teknologi informasi dapat digunakan untuk memenuhi kebutuhan dokter dalam mengambil keputusan operasional mereka, selain itu teknik pembelajaran mesin juga dapat digunakan untuk membantu dokter mendiagnosis pasien terutama dalam kasus ketika hasil sulit diprediksi dan memilih metode operasi terbaik (Milovic & Milovic, 2012).

II. MASALAH

Masalah yang diangkat dalam paper ini ada 2 masalah: 1. Biaya persalinan dengan operasi sesar mahal sehingga perlu diprediksi agar dapat diantisipasi sebelumnya. 2. Uji dataset operasi sesar sebelumnya menunjukkan hasil yang berbeda dan perbedaannya cukup signifikan sehingga perlu diuji ulang. Penelitian sebelumnya yang sudah menggunakan dataset “*Caesarian Section Classification*” berdasarkan pencarian menggunakan google cendikia, ditemukan ada 6 hasil. Enam hasil penelusuran yang diperoleh dijadikan tabel state of the art seperti yang terlihat pada tabel 1.

Tabel 1. State of the art penggunaan “*Caesarian Section Classification*”.

No	Author	Tahun	Judul	Publikasi	Keterangan
1	Gharehchopogh, F. S., Mohammadi, P., & Hakimi, P	2012	Application of decision tree algorithm for data mining in healthcare operations: A case study.	Jurnal	Dataset digunakan sebagai sampling uji metode
2	Ayyappan, G	2018	Various classifications for caesarian section classification dataset.	Jurnal	Uji dataset
3	Amin, Z., M. & Ali, A.	2018	Performance Evaluation of Supervised Machine Learning Classifiers for Predicting Healthcare Operational Decisions	Technical Report	Uji dataset
4	Yanev, N., Valev, V., Krzyzak, A., & Suliman, K. B.	2019	Supervised classification using graph-based space partitioning	Jurnal	Dataset digunakan sebagai sampling uji metode
5	Ayyappan, G., & SivaKumar	2019	Meta classifications for Acute Inflammations Data Set	Jurnal	Dataset digunakan sebagai pembandingan uji metode
6	Rodriguez, I. D. J., Killian, T., Son, S. H., & Gombolay, M	2019	Interpretable Reinforcement Learning via Differentiable Decision Trees	preprint	Dataset digunakan sebagai sampling uji metode
7	Haag, L. V. M.	2019	The Robson classification in use: Weaknesses and difficulties when working with the Robson classification system	Jurnal	Dataset digunakan sebagai sampling uji metode

Dari tabel 1 ada 2 penulis yang secara khusus menguji dataset *Caesarian Section Classification* dari hasil uji mereka disederhanakan menjadi tabel perbandingan hasil yang sebagaimana terlihat di tabel 2.

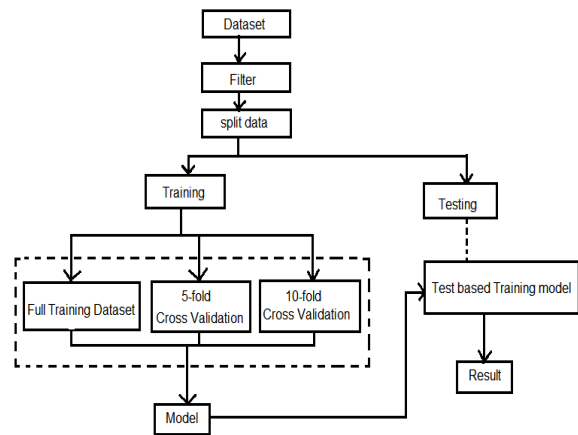
Tabel 2. Hasil perbandingan uji dataset *Caesarian Section Classification* peneliti sebelumnya.

Evaluasi Performa dari Supervised Machine Learning Classifiers dalam Memprediksi Layanan Kesehatan Operasi Sesar			Macam Klasifikasi untuk Operasi sesar menggunakan caesarian section classification dataset	
Classifier	TP Rate	ROC Area	Classifier	Accuracy
SVM	0.763	0.755	Bayes.BayesNet	62.5%
Random Forrest	0.950	0.994	Functions.SMO	61.25%
Naive Bayes	0.763	0.842	Lazy.LBK	56.25%
kNN	0.950	0.995	Meta.AdaboostM1	62.5%
Logistic Regression	0.775	0.875	Tress.J48	65%

Peneliti sebelumnya melakukan uji dataset sepenuhnya, artinya algoritma yang diujikan diujiterapkan pada seluruh instance dalam dataset atau seluruh dataset diuji.

III. METODE PENELITIAN

Metode penelitian dalam paper ini menggunakan alur kerja berikut:



Gambar 1. Alur kerja penelitian uji dataset *Caesarian Section Classification*.

Dataset yang digunakan adalah *Caesarian Section Classification*, dataset ini dapat diunduh di UCI machine learning repository. Sebelum di-split menjadi menjadi dataset *Training* dan *Testing* dilakukan filter berupa penghapusan data yang duplikat. Dataset di-split menjadi dataset training dan testing dengan komposisi 80% *Training* dan 20% *testing* pembagian dataet ini tidak dilakukan oleh peneliti sebelumnya. Dataset *training* selanjutnya akan diuji dengan algoritma *Multi Layer Preceptron* (MLP). Publikasi hasil penelitian [amir] algoritma kNN menunjukkan hasil yang paling tinggi.

Algoritma kNN bekerja dengan cara mencari dan menghitung jarak tetangga terdekat. Penentuan k terdekat dilakukan dengan menghitung dan membandingkan jarak dari data uji ke data latih, lalu dipilih beberapa k data dengan jarak terdekat. kelas data uji ditentukan dari mayoritas kelas k data latih terdekat (Adinugroho & Sari, 2018). MLP merupakan model Adaptive Neural Network yang paling banyak digunakandalam studi maupun praktis untuk permasalahan

klasifikasi sederhana. Struktur jaringan MLP memiliki lapisan tersembunyi (*hidden layer*), dengan *hidden layer* garis keputusannya menjadi tidak kaku seperti decision tree. Algoritma pembelajaran MLP yang paling populer digunakan adalah *back propagation*. Algoritma ini menggunakan dua tahap: tahap 1, perhitungan maju digunakan untuk menghitung galts atau *loss function* antara keluaran aktual dengan target. Tahap 2, perhitungan mundur, mempropagasikan balik galat tersebut untuk memperbaiki bobot (Suyanto, 2018). Algoritma propagasi balik dapat dijelaskan sebagai berikut:

Inisialisai AJS {arsitektur jaringan syaraf}

Inisialisai LR {learning rate}

Inisialisai ST {kondisi berhenti}

Inisialisai SW {bobot sinaptik}

- Secara acak tentukan masukan dalam interval tertentu, misal $[0, 1]$ atau $[-1, +1]$ atau lainnya


1. **REPEAT**

- Lakukan perhitungan maju berupa (masukan * SW)
- Lakukan perhitungan loss function antara luaran jaringan dengan target
- Lakukan perhitungan mundur berupa perbaikan(SW) berdasarkan LR

UNTIL ST terpenuhi

Hasil akhir pelatihan jaringan adalah bobot-bobot sinaptik dan bias yang mampu memetakan pola dan kelas target dengan kesalahan minimum.

Struktur dari MLP secara dapat diilustrasikan sebagai berikut:



Gambar 2. Struktur sederhana dari *Multi Layer Preceptron*.

MLP digunakan karena MLP tersedia di WEKA sebagai alternatif lain dari kNN. Training dataset sendiri dilakukan dengan 3 cara: Fullset training, 5-fold cross validation training dan 10-fold cross validation training. Hasil dari training akan menghasilkan model. Model hasil training

selanjutnya diujikan kembali pada dataset testing untuk dibandingkan akurasi hasilnya. Hasil Training dan testing akan dibandingkan sehingga dapat ditarik kesimpulan uji.


IV. HASIL DAN PEMBAHASAN

Dataset dibagi dengan komposisi 80% Training dan 20% Testing. Pada hasil training dengan konfigurasi training dengan *epoch* 1000, MLP dengan 2 hidden layer, Learning Rate 0.3 dan Momentum 0.2. Pengujian dilakukan dengan 3 cara: a. Training full seluruh dataset training; b. Training dengan uji 5-fold cross validation dan c. Training dengan uji 10-fold cross validation. Hasil uji ketiga cara tersebut dapat lihat pada Tabel 3 berikut.

Tabel 3. Error Per-epoch Dataset Training

Training Test	5 - fold CV	10 - fold CV
0.0376	Fold 1 : 0.0144	Fold 1 : 0.0778
	Fold 2 : 0.0594	Fold 2 : 0.0776
	Fold 3 : 0.0134	Fold 3 : 0.0785
	Fold 4 : 0.1025	Fold 4 : 0.0899
	Fold 5 : 0.0208	Fold 5 : 0.0554
		Fold 6 : 0.0919
		Fold 7 : 0.0427
		Fold 8 : 0.0294
		Fold 9 : 0.1055
		Fold 10 : 0.0456

Dari tabel 3 dapat divisualisakan (lihat gambar 3) error per-epoch dari setiap langkah training model. Dari gambar 2 dapat dilihat bahwa nilai error-nya fluktuatif, tidak stabil atau tidak memiliki kecenderungan menurun.



Gambar 3. Visualisasi Error Per-epoch Dataset Training tabel 3.

Hasil training dari menghasilkan nilai akurasi yang berbeda, hasil uji terbesar adalah 95% dan

terendah adalah 38.33%. hasil training juga menunjukkan *confusion matrix* hasil prediksi

Tabel 4. Hasil *confusion matrix* dari proses training

All Training Set	Training [5-fold CV]	Training [10-fold CV]
a b <- class 24 2 a = 0 1 33 b = 1 : 95%	a b <-class 11 15 a = 0 22 12 b = 1 :38.33%	a b <-class 13 13 a = 0 22 12 b = 1 :41.67%

klasifikasi menggunakan MLP. Akurasi dan *confusion matrix* dari proses training dapat dilihat pada tabel 4.

Tabel 4. Akurasi dan *Confusion Matrix Training*. Model hasil training selanjutnya diujicoba menggunakan dataset testing. Hasil testing menunjukkan hasil berikut:

<i>Correctly Classified Instances</i>	9	56.25 %
<i>Incorrectly Classified Instances</i>	7	43.75 %
<i>Kappa statistic</i>		0.1515
<i>Mean absolute error</i>		0.4203
<i>Root mean squared error</i>		0.6036

Confusion matrix menunjukkan hasil 5 dari 7 instance berhasil diklasifikasikan pada class a (dioperasi sesar) dengan benar, dan dari 9 yang seharusnya diklasifikasi dengan class b (tidak dioperasi sesar) hanya 4 yang benar. Selisih akurasi dari hasil training dan testing dapat dilihat pada tabel 5 berikut.

Tabel 5. Selisih Akurasi Antara Hasil Training dan Testing

	All Training set	5-fold CV	10-fold CV
Selisih Akurasi	38.75%	17.9167%	14.5833%

Tabel 5 menunjukkan bahwa selisih hasil terbesar diperoleh dengan hasil *training full dataset* dan terendah adalah hasil training menggunakan *10-fold cross validation*.

V. KESIMPULAN

Report (Amin & Ali, 2018) tidak menyertakan variabel yang digunakan saat pengujian. Dataset

yang digunakan tidak dibagi menjadi dataset training dan testing. kNN pada WEKA adalah IBk dalam kelompok klasifikasi Lazy. Hasil pengujian menggunakan algoritma MLP, berdasarkan nilai akurasi dapat disimpulkan bahwa akurasi terbaik dari dataset *Caesarian Section Classification* berada diantara 38% - 56%. Hasil pengujian menggunakan MLP tidak jauh dari hasil uji (Ayyappan, Various classifications for caesarian section classification dataset data set, 2018) dikisaran akurasi 56%. Perbedaan hasil training dan testing yang cukup signifikan dapat dikategorikan datasetnya underfit. Peneliti selanjutnya terbuka untuk meningkatkan prediksi akurasi.

VI. DAFTAR PUSTAKA

- Adinugroho, S., & Sari, Y. A. (2018). *Implementasi Data mining*. Malang, Indonesia: UB Press.
- Amin, M. Z., & Ali, A. (2018). *Application of decision tree algorithm for data mining in healthcare operations: A case study*. California, USA: Wavi AI Research Foundation.
- Ayyappan, G. (2018). Various classifications for caesarian section classification dataset data set. *Indian Journal of Computer Science and Engineering (IJCE)*, 9(6), 145-147.
- Ayyappan, G., & SivaKumar, K. (2019). Meta classifications for Acute Inflammations Data Set. *Indian Journal of Computer Science and Engineering*, 10(1), 26-27.
- Bonvicini, L., Candela, S., Evangelista, A., Berta, D., Casoli, M., Lusvardi, A., et al. (2014). *Public and private pregnancy care in Reggio Emilia Province: an observational study on appropriateness of care and delivery outcomes*. BMC Pregnancy Childbirth.
- Candelieri, A. D. (2011). Data Mining in Neurology. In *Knowledge Oriented Applications in Data Mining* (pp. 261-276). Rijeka, Croatia: InTech.
- Fayyad, U., Smyth, P., & Shapiro, G. P. (1996). From Data Mining to Knowledge Discovery in Database. *American*

- Association for Artificial Intelligence*, 37-54.
- Haag, L. (2019). *The Robson classification in use: Weaknesses and difficulties when working with the Robson classification system*. Kaunas: Lithuanian University of Health Sciences.
- Han, J., Kamber, M., & Pei, J. (2006.). *Data Mining: Concepts and Techniques, 2nd Edition*. Massachusetts, USA: Morgan Kaufmann Publishers.
- Kantardzic, M. (2003). *Data Mining: Concepts, Models, Methods, and Algorithms*. New Jersey: John Wiley & Sons.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., et al. (2011). *Big data: The next frontier for innovation, competition, and productivity*. The McKinsey global Institute.
- Milovic, B., & Milovic, M. (2012). Prediction and Decision Making in Health Care using Data Mining. *International Journal of Public Health Science (IJPHS)*, 1(2), 69-78.
- Rodriguez, I. J., Silva, A., Killiam, T., Son, S.-H., & Gombolay, M. (2019). *Towards Interpretable, Online Reinforcement Learning with Differentiable Decision Trees*. arXiv.
- Suyanto. (2018). *Machine Learning Tingkat Dasar dan Lanjut*. Bandung, Indonesia: Informatika.
- Yanev, N., Valev, V., Krzyzak, A., & Sulaiman, K. B. (2019). Supervised classification using graph-based space partitioning. *Pattern Recognition Letters*, 128, 122-130.