

Klasifikasi Fetal Cardiotocography Menggunakan Pendekatan Boosting Classifier

Gede Angga Pradipta¹, Putu Desiana Wulaning Ayu²

Institut Teknologi dan Bisnis STIKOM Bali

e-mail: ¹angga_pradipta@stikom-bali.ac.id, ²wulaning_ayu@stikom-bali.ac.id

Diajukan: 3 November 2023; Direvisi: 25 November 2023; Diterima: 28 November 2023

Abstrak

Fetal cardiotography, sebuah alat penting dalam pemantauan kesehatan janin selama kehamilan. Fetal cardiotography memberikan informasi vital tentang kesehatan janin, termasuk detak jantung janin dan aktivitas gerakan janin. Ini membantu dokter dan perawat untuk memantau kesehatan janin secara berkala selama kehamilan. Dengan mengamati pola detak jantung janin, fetal Cardiotocography dapat membantu mendeteksi dini masalah kesehatan janin, seperti hipoksia (kurangnya oksigen), ketidakseimbangan cairan ketuban, atau masalah dengan plasenta. Integrasi antara penggunaan machine learning untuk mendukung diagnosa dokter terhadap kondisi detak jantung janin ini menjadi sangat diperlukan. Adanya sebuah sistem berbasis AI menjadikan permasalahan subjektivitas dalam hasil diagnosa dapat diminimalisir. Pada penelitian ini mengembangkan sebuah model machine learning yang berbasiskan pada teknik boosting. Kombinasi antara outlier detection dan feature selection dianalisis dan kemudian diujicobakan pada tiga jenis algoritma boosting. Hasil dari eksperimen menunjukkan bahwa kombinasi antara local outlier factor, chi square dan extrem gradient boosting mampu memberikan performa terbaik yaitu dengan nilai akurasi sebesar 99.3%, presisi dengan 99.1%, recall 99.1% dan F-Measure sebesar 99.1%.

Kata kunci: *Fetal, Cardiotocography, Outlier detection, Selection feature, Boosting.*

Abstract

Fetal cardiotography, an important tool in monitoring fetal health during pregnancy, provides vital information about the fetus's health, including fetal heart rate and fetal movement activity. This helps doctors and nurses monitor fetal health regularly during pregnancy. By observing fetal heart rate patterns, fetal cardiotography can help detect early fetal health problems, such as hypoxia (lack of oxygen), amniotic fluid imbalance, or placental problems. The integration of machine learning to support doctors' diagnosis of fetal heart rate conditions is highly necessary. The existence of an AI-based system minimizes the subjectivity issues in diagnosis results. This study develops a machine learning model based on boosting techniques. The combination of outlier detection and feature selection is analyzed and then tested on three types of boosting algorithms. The results of the experiments show that the combination of local outlier factor, chi-square, and extreme gradient boosting provides the best performance with an accuracy of 99.3%, precision of 99.1%, recall of 99.1%, and F-Measure of 99.1%.

Keywords: *Fetal, Cardiotocography, Outlier detection, Selection feature, Boosting.*

1. Pendahuluan

Fetal cardiotocography (CTG) adalah alat penting dalam obstetri yang digunakan untuk memantau denyut jantung janin (FHR) dan kontraksi uterus selama kehamilan dan persalinan. Ini memainkan peran penting dalam menilai kesejahteraan janin dan membimbing keputusan klinis untuk memastikan persalinan yang aman. Dengan merekam dan menganalisis pola FHR, CTG menyediakan informasi berharga tentang oksigenasi janin dan status neurologis, membantu penyedia layanan kesehatan mendeteksi tanda-tanda distress janin dan mengintervensi dengan cepat bila diperlukan [1], [2], [3]. Selama bertahun-tahun, kemajuan teknologi telah mengarah pada pengembangan berbagai teknik pemantauan CTG, termasuk pemantauan eksternal tradisional dan metode pemantauan internal yang lebih canggih. Meskipun penggunaannya yang luas, interpretasi CTG janin tetap merupakan tugas yang kompleks dan subjektif, sering kali membutuhkan tenaga profesional kesehatan yang terampil untuk menginterpretasi data dengan akurat dan membuat keputusan klinis yang tepat. Pengantar ini bertujuan untuk memberikan gambaran

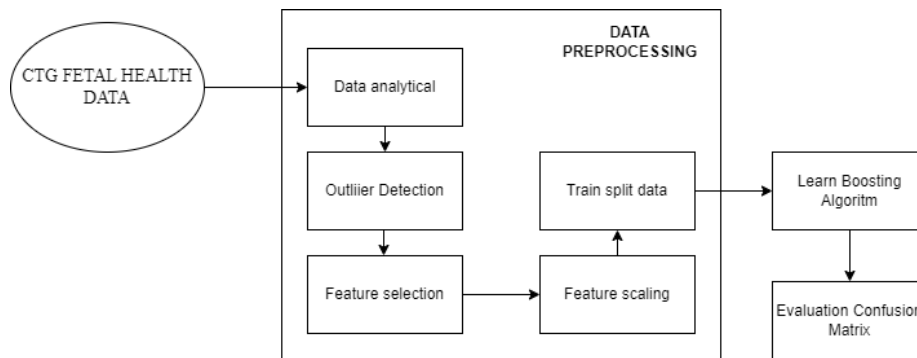
tentang fetal cardiotocography, signifikansinya dalam obstetri, teknik pemantauan saat ini, dan tantangan dalam interpretasi, dengan menyoroti pentingnya penelitian dan inovasi yang berkelanjutan dalam meningkatkan praktik pemantauan janin untuk hasil ibu dan bayi yang lebih baik. Penggunaan teknologi *artificial intelligence (AI)* untuk pemantauan kesehatan janin dalam kandungan telah banyak diadopsi. Penggunaan metode machine learning digunakan untuk mengklasifikasikan dan mengidentifikasi kelainan pada organ ataupun tumbuh kembang janin pada masa kehamilan.

Beberapa objek atau organ yang diteliti adalah seperti fetal anatomi. Penelitian [4] memprediksi berat badan janin menggunakan pendekatan metode *Iterative Random Hough Transform (IRHT)* dan *Fuzzy C Means (FCM)* pada data citra USG. Ukuran lingkaran kepala dan lingkaran abdomen diukur dengan metode IRHT dan kemudian dikalibrasi dengan pengukuran manual dokter. Kemudian penelitian [5], [6] menggunakan pendekatan *Convolutional Neural Network* untuk melakukan identifikasi anatomi janin yaitu lingkaran kepala. Permasalahan tepi dari lingkaran kepala yang relatif samar menjadi tantangan utama penelitian. Arsitektur CNN yang diberi nama GAC Net digunakan untuk mendeteksi tepi dari lingkaran kepala janin. Berikutnya anatomi janin yang diidentifikasi adalah plasenta. Penelitian tentang identifikasi dan klasifikasi kesehatan plasenta juga menjadi penting dalam perkembangan janin. Penelitian [7] mengidentifikasi plasenta dengan tahapan awal yaitu melakukan segmentasi terhadap objek tersebut. Metode segmentasi yang digunakan adalah dengan pendekatan CNN dengan arsitektur U-Net. Hasil pengujian menunjukkan terhadap 1364 citra, metode usulan mampu mendeteksi hasil segmentasi yang dilakukan oleh paramedis. Kemudian penelitian [8] juga melakukan identifikasi terhadap organ plasenta dengan menggunakan 30 fitur yang terdiri dari *patient demographics, clinical characteristics, dan biochemical parameters*. Metode decision tree digunakan untuk mengklasifikasikan data latih yang dimiliki dan diuji pada data uji dengan hasil akurasi 96.4%, presisi 96.8%, recall 99.4%, AUC sebesar 98.6. Berbeda dengan penelitian sebelumnya, penelitian pada [9] menggunakan objek plasenta pada citra MRI. Metode ekstraksi tekstur digunakan sebagai fitur yang menghasilkan data latih. Selanjutnya metode Random Forest, Naive Bayes, K-Nearest Neighbors (KNN), dan *Multilayer Perceptron* digunakan dan dibandingkan hasilnya. Selain plasenta, objek organ lain yang diidentifikasi adalah amniotic fluids atau air ketuban. Pada penelitian [10], [11], [12] mengidentifikasi seperti melakukan segmentasi dan klasifikasi cairan ketuban. Segmentasi cairan ketuban menghadapi tantangan tingkat kesamaran dan noise yang tinggi pada objek tersebut. Kemudian *Region of Interest (ROI)* hasil segmentasi diekstrak fiturnya menggunakan pendekatan tekstur dan bentuk yang kemudian diklasifikasikan ke dalam dua kategori yaitu clear dan echogenic.

Kemudian organ yang tidak kalah pentingnya untuk pertumbuhan janin adalah tali pusat janin. Tali pusat, adalah struktur vital yang menghubungkan janin dengan plasenta selama masa kehamilan. Ini merupakan jalur komunikasi utama antara janin dan plasenta, yang memberikan nutrisi, oksigen, dan zat-zat lain yang dibutuhkan oleh janin untuk pertumbuhan dan perkembangan [13], [14]. Penelitian [15], [16] menggunakan metode ekstraksi texture dan umbilical coiling index (UCI) untuk mengklasifikasikan tali pusat janin ke dalam 3 kategori yaitu normal, hypocoiling, dan hypercoiling. Metode multiclassifier voting digunakan untuk mempelajari pola data latih yang dihasilkan. Organ lainnya yang tidak kalah penting adalah jantung janin. pemantauan denyut jantung janin (FHR) dan kontraksi uterus selama kehamilan dan persalinan menjadi hal yang sangat krusial harus di-monitoring. Untuk memudahkan analisis, teknologi AI dan *machine learning* pada penelitian sebelumnya telah digunakan. Pada penelitian [17] menggunakan data cardiotocography untuk klasifikasi denyut jantung janin kedalam dua kategori yaitu normal dan abnormal. Penelitian ini mengusulkan metode *Bagging Ensemble classifier* dan kemudian dibandingkan dengan beberapa metode machine learning konvensional. Selanjutnya penelitian [18] mengklasifikasikan data cardiotocography menggunakan pendekatan neural network dengan topologi yaitu *sub-adaptive neuro fuzzy inference system (MLA-ANFIS)*. Pada penelitian yang berbeda kombinasi dari *uterine contraction (UC)* dan *fetal heart rate (FHR)* kemudian mengklasifikasikannya menggunakan metode machine learning ke dalam dua kategori yaitu pathological dan normal.

Berdasarkan dari studi literature di atas, pada penelitian ini mengembangkan sebuah model berbasis pada konsep *boosting* dan melakukan analisis dan eksperimen dari beberapa parameter metode tersebut untuk mengklasifikasikan jenis fetal heart rate (FHR). Kombinasi antara *selection feature* dan metode *boosting classifier* diuji dan dianalisis untuk mendapatkan performa yang terbaik dalam mengklasifikasikan data cardiotocography.

2. Metode Penelitian
2.1 Rancangan Model



Gambar 1. Tahapan Proses Model Klasifikasi Fetal Cardiotocography.

Tahapan pengembangan model dimulai dari proses pra pemrosesan data yang terdiri dari proses data eksplorasi dan analisis, pendeteksian outlier/noise, proses seleksi fitur, scaling fitur dan split data laith dan uji. Kemudian setelah pra pemrosesan data dilanjutkan dengan proses *learning* menggunakan algoritma boosting dan terakhir dievaluasi dengan metode confusion matrix dengan parameter pengukuran akurasi, presisi, recall, dan F-Measure.

2.2 Karakteristik Data

Dalam penelitian ini, dataset cardiotocography yang digunakan diperoleh dari Repositori University of California Irvine Machine Learning, yang merupakan dataset publik[19]. Dataset tersebut terdiri dari 2126 data tentang wanita hamil yang berada dalam trimester ketiga kehamilan mereka. Dataset ini terdiri dari 21 atribut yang digunakan dalam pengukuran FHR dan UC pada CTG, seperti yang tercantum dalam Tabel 1.

Menurut standar National Institute of Child Health and Human Development, variabel-variabel dengan risiko utama yang digunakan untuk menentukan kondisi janin berdasarkan deskripsi FHR adalah laju jantung dasar, variasi jantung dasar, jumlah akselerasi per detik, jumlah deceleration awal, lambat, dan variabel per detik, jumlah deceleration yang berkepanjangan per detik, dan pola sinusoidal serta kontraksi uterus yang dapat dilihat dari tonus uterus dasar, frekuensi kontraksi, durasi, dan kekuatan. CTG janin dihasilkan oleh SisPorto 2.0 (Speculum, Lisbon, Portugal), yang merupakan program untuk menganalisis hasil CTG secara otomatis.

Tabel 1. Atribut Dataset Cardiotogram.

Variable symbol	Variable Description
BV	Baseline Value (FHR beats per minute)
AC	Accelerations (number of accelerations per second)
FM	Fetal Movement (number of fetal movement)
UC	Uterine Contractions (number of uterine contractions per second)
LD	Light Decelerations (number of light decelerations per second)
SD	Severe Decelerations (number of severe decelerations per second)
PD	Prolonged Decelerations (number of prolonged decelerations per second)
ASTV	Abnormal Short-Term Variability
MSTV	Mean Value of Short-Term Variability
ALTV	Percentage of Time with Abnormal Long-Term Variability
MLTV	Mean Value of Long-Term Variability
HW	Histogram Width (Width of FHR histogram)
HMax	Histogram Max (Maximum of FHR histogram)
Hmin	Histogram Min (Minimum of FHR histogram)
NP	Number of Histogram Peaks
NZ	Number of Histogram Zeroes
HMo	Histogram Mode
HMe	Histogram Mean
HMed	Histogram Median
HV	Histogram Variance
HT	Histogram Tendency
NSP	Fetal Health (Fetal state class code, N=normal, S= Suspected, P=Pathological)

2.3 Metode Selection Feature Chi Square

Seleksi fitur chi-square adalah metode statistik yang digunakan untuk mengevaluasi hubungan antara fitur kategorikal dan variabel target kategorikal. Ini menilai apakah ada hubungan yang signifikan antara setiap fitur dan variabel target dengan membandingkan frekuensi yang diamati dari pasangan fitur-target dengan frekuensi yang diharapkan di bawah asumsi independensi. Uji chi-square adalah uji hipotesis yang digunakan untuk menentukan apakah ada hubungan yang signifikan antara dua variabel kategorikal. Ini menghitung statistik chi-square (χ^2) berdasarkan perbedaan antara frekuensi yang diamati dan yang diharapkan. Untuk setiap pasangan fitur-target, frekuensi yang diharapkan (E) dihitung dengan asumsi independensi antara fitur dan variabel target. Ini dihitung sebagai hasil kali frekuensi marginal dari fitur dan variabel target, dibagi oleh total ukuran sampel. Frekuensi yang diamati (O) mewakili jumlah aktual kejadian untuk setiap pasangan fitur-target dalam kumpulan data. Statistik chi-square dihitung menggunakan rumus:

$$\chi^2 = \sum \frac{(O - E)^2}{E} \tag{1}$$

Dimana χ^2 adalah statistik chi-square, O adalah frekuensi yang diamati, dan E adalah frekuensi yang diharapkan. Derajat kebebasan (df) untuk uji chi-square dihitung sebagai hasil kali jumlah kategori dalam variabel fitur dikurangi satu dan jumlah kategori dalam variabel target dikurangi satu. Fitur dengan nilai chi-square tinggi dan nilai p yang rendah (diperoleh dari distribusi chi-square) dianggap memiliki hubungan yang signifikan dengan variabel target dan dipilih untuk dimasukkan ke dalam model prediktif. Sebaliknya, fitur dengan nilai chi-square rendah dan nilai p yang tinggi dianggap memiliki sedikit kekuatan prediktif dan mungkin dikecualikan dari model.

2.4 Metode Boosting

2.4.1 Gradient Boosting Classifier

Gradient Boosting adalah teknik pembelajaran mesin ensemble yang digunakan untuk masalah regresi dan klasifikasi. Ini membangun model prediktif yang kuat dengan menggabungkan beberapa *weak learner* secara berurutan. Ide dasar di balik *gradient boosting* adalah untuk mengoptimalkan fungsi kerugian dengan menambahkan *weak learner* secara iteratif untuk meminimalkan kesalahan. Gradient boosting dimulai dengan model awal yang memprediksi nilai rata-rata variabel target. Pada setiap iterasi, pembelajar lemah baru ditambahkan ke dalam ensemble untuk memperbaiki kesalahan yang dilakukan oleh model sebelumnya. Fungsi kerugian, $L(y, F(x))$, mengukur perbedaan antara nilai target sebenarnya y dan prediksi $F(x)$. Tujuannya adalah untuk meminimalkan fungsi kerugian ini dengan memperbarui parameter model. Gradient descent digunakan untuk meminimalkan fungsi kerugian dengan secara iteratif menyesuaikan parameter model ke arah gradien negatif dari fungsi kerugian. Gradien dari fungsi kerugian terhadap nilai prediksi dihitung, dan parameter model diperbarui ke arah yang mengurangi kerugian. Algoritma boosting secara berurutan menambahkan pembelajar lemah ke dalam ensemble, dengan setiap pembelajar dilatih untuk meminimalkan kesalahan residu fungsi kerugian. Prediksi pembelajar lemah digabungkan menggunakan jumlah tertimbang untuk menghasilkan prediksi akhir model ensemble.

Formula matematis untuk algoritma ini adalah:

y_i menjadi variabel target untuk observasi ke i , dan x_i menjadi vektor fitur yang terkait dengan observasi ke- i .

1. Inisialisasi Model:

$$F_0(x) = \text{rata-rata}(y) \tag{1}$$

2. Untuk setiap iterasi m dari 1 hingga M :

- Hitung gradien negatif dari fungsi kerugian:

$$r_{im} = - \frac{\partial L(y_i, F_{m-1}(x_i))}{\partial F_{m-1}(x_i)} \tag{2}$$

- Sesuaikan pembelajar lemah (mis., pohon keputusan) ke gradien negatif:

$$h_m(x) = \text{argmin}_h \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + h(x_i)) \tag{3}$$

- Perbarui model dengan menambahkan versi tertimbang dari pembelajar lemah:

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x) \tag{4}$$

Dimana:

- η adalah gradien negatif untuk observasi i pada iterasi mm .
- $h_m(x)$ adalah pembelajar lemah (mis., pohon keputusan) pada iterasi mm .
- η adalah tingkat pembelajaran, mengontrol ukuran langkah setiap pembaruan.
- $L(y, F(x))$ adalah fungsi kerugian, mengukur perbedaan antara nilai target sebenarnya y dan prediksi $F(x)$.

3. Hasil dan Pembahasan

3.1. Eksperimen Deteksi Outlier

Pada penelitian ini deteksi outlier diuji coba pada tiga metode yaitu *local outlier factor*, *covariance estimator*, dan *isolation forest*. *Outlier* dapat memengaruhi analisis data dengan memberikan informasi yang tidak tepat atau biasa, sehingga mengidentifikasi dan menghapus *outlier* dapat meningkatkan kualitas data. *Outlier* dapat menyebabkan *overfitting*, di mana model beradaptasi terlalu baik dengan data pelatihan. Hasil dari proses deteksi outlier ditunjukkan pada Tabel 2 dibawah ini.

Tabel 2. Deteksi *Outlier* pada Data Latih

No	Metode	Input Instances	Inliers	Outliers
1	Local Outlier Factor	2128	1988	140
2	Covariance Estimator	2128	1914	214
3	Isolation Forest	2128	1914	214

3.2. Eksperimen Feature Selection dan Algoritma Boosting

Pada eksperimen ini, setiap hasil dari deteksi outlier pada ketiga metode di atas kemudian diuji coba dengan mengombinasikan dengan metode seleksi fitur *Chi-Square*. Eksperimen ini bertujuan untuk mengetahui kombinasi antara metode deteksi outlier dan seleksi fitur yang terbaik. Pada proses *learning* pada eksperimen ini menggunakan metode berbasis boosting yaitu *Gradient Boosting*, *Extreme Gradient Boosting* dan *AdaBoost*. Tabel 3 menunjukkan hasil eksperimen kombinasi deteksi *outlier*, *selection feature* dan metode *Gradient Boosting*. Metode evaluasi model menggunakan teknik cross fold validation dengan jumlah 5 fold. Berdasarkan dari hasil eksperimen ini, kombinasi antara local outlier factor, chi square dan extrem gradient boosting mampu memberikan performa terbaik yaitu dengan nilai akurasi sebesar 99.3%, presisi dengan 99.1%, recall 99.1% dan F-Measure sebesar 99.1%.

Tabel 3. Hasil performa *Gradient Boosting*

Method	Akurasi %	Presisi %	Recall %	F-Measure %
Local Outlier Factor + Chi Square	98.9	98.9	98.9	98.9
Covariance Estimator + Chi Square	99.1	99.1	99.1	99.1
Isolation Forest + Chi Square	98.5	98.8	98.8	98.8

Tabel 4. Hasil performa *Extreme Gradient Boosting*

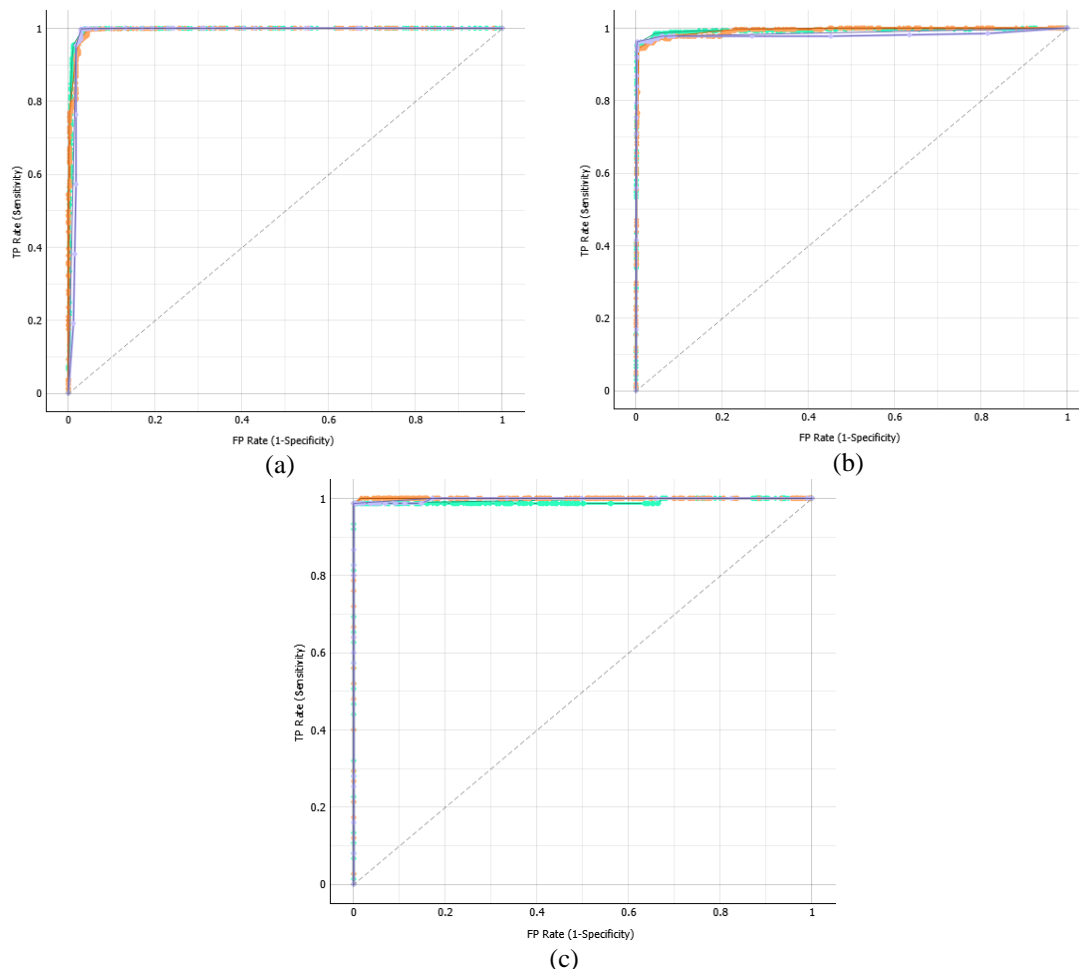
Method	Akurasi%	Presisi%	Recall%	F-Measure%
Local Outlier Factor + Chi Square	99.3	99.1	99.1	99.1
Covariance Estimator + Chi Square	98.8	98.8	98.8	98.8
Isolation Forest + Chi Square	98.5	99.1	99.1	99.1

Tabel 5. Hasil performa *AdaBoost*

Method	Akurasi%	Presisi%	Recall%	F-Measure%
Local Outlier Factor + Chi Square	98.9	98.6	98.6	98.6
Covariance Estimator + Chi Square	99.4	98.8	98.8	98.8
Isolation Forest + Chi Square	99.4	98.7	98.7	98.7

Kemudian analisis performa dari metode tersebut juga digambarkan dalam kurva ROC. Kurva ROC memplotting tingkat True Positive (TP) terhadap tingkat False Positive (FP) pada berbagai threshold pengklasifikasi. Area di bawah kurva ROC (AUC - Area Under the Curve) adalah ukuran umum dari kualitas model klasifikasi, di mana nilai AUC mendekati 1 menunjukkan model yang lebih baik, sedangkan

nilai mendekati 0.5 menunjukkan kinerja model yang kurang baik. Pada Gambar 2. Terlihat bahwa model extrem gradient boosting mampu menghasilkan area under curve yang mendekati nilai 1. Hal ini menunjukkan kombinasi model hasil eksperimen sebelumnya memberikan performa klasifikasi yang sangat baik. Garis warna hijau menunjukkan performa model pada label 1, garis orange menunjukkan performa model pada label 2, dan garis ungu pada label 3.



Gambar 2. Kurva ROC pada Kombinasi Terbaik yaitu Local Outlier Factor + Chi Square dan Extreme Gradient Boosting. (a) ROC pada Label 1, (b) ROC pada label 2, dan (c) ROC pada Label 3.

4. Kesimpulan

Fetal cardiotography memberikan informasi vital tentang kesehatan janin, termasuk detak jantung janin dan aktivitas gerakan janin. Ini membantu dokter dan perawat untuk memantau kesehatan janin secara berkala selama kehamilan. Dengan mengamati pola detak jantung janin, fetal cardiotography dapat membantu mendeteksi dini masalah kesehatan janin, seperti hipoksia (kurangnya oksigen), ketidakseimbangan cairan ketuban, atau masalah dengan plasenta. Pada penelitian ini mencoba mengembangkan sebuah model deteksi otomatis terhadap kondisi janin dengan membaginya menjadi 3 kategori yaitu Normal, Suspected, dan Pathological. Dari hasil eksperimen yang dilakukan diketahui bahwa pengaruh dari adanya proses outlier detection dan selection feature mampu memberikan performa model yang meningkat. Berdasarkan dari hasil eksperimen, kombinasi antara local outlier factor, chi square dan extrem gradient boosting mampu memberikan performa terbaik yaitu dengan nilai akurasi sebesar 99.3%, presisi dengan 99.1%, recall 99.1% dan F-Measure sebesar 99.1%. Hasil penelitian ini merupakan model dasar yang untuk selanjutnya dapat digunakan untuk pengembangan ke tahapan pembuatan prototipe dan diujikan pada lingkungan sebenarnya.

Daftar Pustaka

- [1] H. Baker, N. Pilarski, V. A. Hodgetts-Morton, and R. K. Morris, "Comparison of visual and computerised antenatal cardiotocography in the prevention of perinatal morbidity and mortality. A systematic review and meta-analysis," *European Journal of Obstetrics and Gynecology and Reproductive Biology*, vol. 263. Elsevier Ireland Ltd, pp. 33–43, Aug. 01, 2021. doi: 10.1016/j.ejogrb.2021.05.048.
- [2] L. A. Zhu *et al.*, "Fetal physiology cardiotocography training, a regional evaluation," *J Gynecol Obstet Hum Reprod*, vol. 50, no. 6, Jun. 2021, doi: 10.1016/j.jogoh.2020.102039.
- [3] C. Bruin, S. Damhuis, S. Gordijn, and W. Ganzevoort, "Evaluation and Management of Suspected Fetal Growth Restriction," *Obstetrics and Gynecology Clinics of North America*, vol. 48, no. 2. W.B. Saunders, pp. 371–385, Jun. 01, 2021. doi: 10.1016/j.ogc.2021.02.007.
- [4] G. A. Pradipta and P. D. Wulaning Ayu, "Fetal weight prediction based on ultrasound image using fuzzy C means clustering and Iterative Random Hough Transform," in *Proceedings - 2017 1st International Conference on Informatics and Computational Sciences, ICICoS 2017*, Institute of Electrical and Electronics Engineers Inc., Oct. 2017, pp. 71–76. doi: 10.1109/ICICoS.2017.8276340.
- [5] M. Ghelich Oghli *et al.*, "Automatic fetal biometry prediction using a novel deep convolutional network architecture," *Physica Medica*, vol. 88, pp. 127–137, Aug. 2021, doi: 10.1016/j.ejmp.2021.06.020.
- [6] X. Wang, W. Wang, and X. Cai, "Automatic measurement of fetal head circumference using a novel GCN-assisted deep convolutional network," *Comput Biol Med*, vol. 145, Jun. 2022, doi: 10.1016/j.compbimed.2022.105515.
- [7] Hu Ricky, Singla Rohit, Yan Ryan, Mayer Chantal, and Rholing N Robert, "Automated Placenta Segmentation with a Convolutional Neural Network Weighted by Acoustic Shadow Detection," in *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2019, pp. 6718–6723.
- [8] C. Yu, S. Feng, J. Liu, and Y. Chen, "Prediction of hysterectomy in pernicious placenta previa by machine learning," *Asian Journal of Surgery*, vol. 46, no. 5. Elsevier (Singapore) Pte Ltd, pp. 1957–1958, May 01, 2023. doi: 10.1016/j.asjsur.2022.11.068.
- [9] V. Romeo *et al.*, "Machine learning analysis of MRI-derived texture features to predict placenta accreta spectrum in patients with placenta previa," *Magn Reson Imaging*, vol. 64, pp. 71–76, Dec. 2019, doi: 10.1016/j.mri.2019.05.017.
- [10] P. D. W. Ayu, S. Hartati, A. Musdholifah, and D. S. Nurdianti, "Amniotic Fluids Classification Using Combination of Rules-Based and Random Forest Algorithm," in *Communications in Computer and Information Science*, Springer Science and Business Media Deutschland GmbH, 2021, pp. 267–285. doi: 10.1007/978-981-16-7334-4_20.
- [11] P. D. W. Ayu, S. Hartati, A. Musdholifah, and D. S. Nurdianti, "Amniotic fluid classification based on volume and echogenicity using single deep pocket and texture feature," *ICIC Express Letters*, vol. 15, no. 7, pp. 681–691, Jul. 2021, doi: 10.24507/icicel.15.07.681.
- [12] P. D. W. Ayu, S. Hartati, A. Musdholifah, and D. S. Nurdianti, "Amniotic fluid segmentation based on pixel classification using local window information and distance angle pixel," in *Applied Soft Computing*, Elsevier Ltd, Aug. 2021. doi: 10.1016/j.asoc.2021.107196.
- [13] N. Orlando *et al.*, "Umbilical cord blood: Current uses for transfusion and regenerative medicine," *Transfusion and Apheresis Science*, vol. 59, no. 5. Elsevier Ltd, Oct. 01, 2020. doi: 10.1016/j.transci.2020.102952.
- [14] D. J. Wilke, J. P. Denier, T. Y. Khong, and T. W. Mattner, "Estimating umbilical cord flow resistance from measurements of the whole cord," *Placenta*, vol. 103, pp. 180–187, Jan. 2021, doi: 10.1016/j.placenta.2020.09.066.
- [15] G. A. Pradipta, R. Wardoyo, A. Musdholifah, and I. N. H. Sanjaya, "Machine learning model for umbilical cord classification using combination coiling index and texture feature based on 2-D Doppler ultrasound images," *Health Informatics J*, vol. 28, no. 1, Mar. 2022, doi: 10.1177/14604582221084211.
- [16] G. A. Pradipta, R. Wardoyo, A. Musdholifah, and I. N. H. Sanjaya, "Improving classification performance of fetal umbilical cord using combination of SMOTE method and multiclassifier voting in imbalanced data and small dataset," *International Journal of Intelligent Engineering and Systems*, vol. 13, no. 5, pp. 441–454, Oct. 2020, doi: 10.22266/ijies2020.1031.39.

-
- [17] A. Subasi, B. Kadasa, and E. Kremic, "Classification of the cardiotocogram data for anticipation of fetal risks using bagging ensemble classifier," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 34–39. doi: 10.1016/j.procs.2020.02.248.
- [18] M. S. Iraji, "Prediction of fetal state from the cardiotocogram recordings using neural network models," *Artif Intell Med*, vol. 96, pp. 33–44, May 2019, doi: 10.1016/j.artmed.2019.03.005.
- [19] K. Bache and M. Lichman, "UCI Machine Learning Repository," UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>].