

Perbandingan Metode Ensemble Learning pada Klasifikasi Penyakit Diabetes

Lingar Maretva Cendani¹⁾, Adi Wibowo²⁾

Departemen Ilmu Komputer/Informatika, Universitas Diponegoro

¹⁾ linggarmc@students.undip.ac.id, ²⁾ bowo.adi@live.undip.ac.id

Abstrak

Diabetes merupakan salah satu penyakit dalam dunia medis yang ditandai dengan kadar gula dalam darah yang tinggi pada penderitanya. Menurut data dari Organisasi Kesehatan Dunia (WHO), pada rentang tahun 1980 sampai 2014, terjadi peningkatan kasus penderita diabetes dari 108 juta menjadi 422 juta. Ensemble Learning yang merupakan salah satu metode dalam Machine Learning dapat digunakan untuk melakukan klasifikasi penyakit diabetes. Pada penelitian ini, dilakukan perbandingan 3 metode Ensemble Learning, yaitu Bagging, Boosting, dan Stacking pada 3 buah dataset. 3 dataset yang digunakan adalah Pima Indians Diabetes, Frankfurt Hospital Diabetes, dan Sylhet Hospital Diabetes. Dari hasil eksperimen ensemble learning yang dilakukan pada ketiga buah dataset, didapatkan bahwa metode Boosting dapat mengungguli metode Bagging dan Stacking. Pada dataset 1, didapatkan akurasi tertinggi sebesar 81.82 % dengan model Gradient Boosting, Extreme Gradient Boosting, dan Cat Boosting. Pada dataset 2, didapatkan akurasi tertinggi sebesar 99.25 % dengan menggunakan model Light Gradient Boosting. Sedangkan akurasi tertinggi pada dataset ketiga adalah 100% dengan menggunakan model Light Gradient Boosting dan Cat Boosting.

Kata kunci : Bagging, Boosting, Diabetes, Ensemble Learning, Stacking

Abstract

Diabetes is a disease in the medical world characterized by high blood sugar levels in the sufferer. According to data from the World Health Organization (WHO), between 1980 and 2014, there was an increase in diabetes cases from 108 million to 422 million. Ensemble Learning, which is one of the Machine Learning paradigms, can be used to classify diabetes. In this study, 3 Ensemble Learning methods were compared, namely Bagging, Boosting, and Stacking on 3 datasets. The 3 datasets used were Pima Indians Diabetes, Frankfurt Hospital Diabetes, and Sylhet Hospital Diabetes. From the results of ensemble learning experiments conducted on the three datasets, it was found that the Boosting method could outperform the Bagging and Stacking methods. In dataset 1, the highest accuracy is 81.82% with Gradient Boosting, Extreme Gradient Boosting, and Cat Boosting models. In dataset 2, the highest accuracy is 99.25% using the Light Gradient Boosting model. While the highest accuracy in the third dataset is 100% using the Light Gradient Boosting and Cat Boosting models.

Keywords : Bagging, Boosting, Diabetes, Ensemble Learning, Stacking

1 PENDAHULUAN

Diabetes merupakan salah satu penyakit dalam dunia medis yang ditandai dengan kadar gula dalam darah yang tinggi pada penderitanya. Diabetes merupakan salah satu faktor utama penyebab penyakit jantung koroner dan stroke iskemik [1]. Diabetes dapat terjadi ketika pankreas tidak menghasilkan insulin yang cukup bagi tubuh, atau dapat juga terjadi ketika tubuh tidak dapat secara efektif menggunakan insulin yang dihasilkannya. Insulin adalah hormon yang mengatur gula darah. Diabetes merupakan salah satu penyakit dengan pertumbuhan tertinggi di dunia. Menurut data dari Organisasi Kesehatan Dunia (WHO), pada rentang tahun 1980 sampai 2014, terjadi peningkatan kasus penderita diabetes dari 108 juta menjadi 422 juta. Jumlah ini meningkat lebih cepat pada negara - negara yang berpenghasilan rendah atau menengah [2].

Penelitian di dunia medis untuk melakukan klasifikasi suatu penyakit sudah banyak dilakukan. Salah satu metode yang paling banyak digunakan adalah machine learning. Machine learning dapat melakukan pembelajaran dari data sehingga memungkinkan komputer untuk melakukan klasifikasi atau prediksi berdasarkan data tersebut [3]. Penggunaan machine learning pada dunia medis dapat mengurangi biaya dan mempercepat waktu diagnosa beberapa kali lipat.

Terdapat beberapa penelitian mengenai klasifikasi diabetes yang telah dilakukan sebelumnya, Smith dkk. [4] menggunakan ADAPtive learning routine (ADAP) pada dataset Pima Indians Diabetes dan didapatkan nilai sensitivitas dan spesifisitas algoritme mereka adalah 76 %. Bhoi, S.K. [5] menggunakan beberapa algoritma *supervised learning* pada dataset yang sama, dan didapatkan algoritma terbaik yaitu Logistic Regression dengan nilai akurasi sebesar 76.80 %. Hasil ini tidak berbeda jauh dengan penelitian yang dilakukan Agatsa dkk. [6] yang memperoleh nilai akurasi tertinggi sebesar 77.92 % dengan algoritma SVM, begitupula penelitian yang dilakukan Sisodia, D., dan Sisodia, D. S. [7] yang mendapatkan akurasi sebesar 76.30 % dengan menggunakan Naive Bayes. Sedangkan penelitian yang dilakukan oleh Savvas dkk. [8] pada data yang sama, dengan menggunakan RBF SVM dan Polynomial SVM menghasilkan akurasi yang lebih baik, yaitu dengan akurasi tertinggi 84,71 % untuk *Normal Cases*, dan 82,41 % untuk *Abnorm Cases*. Metode dengan menggunakan Backward Elimination dan algoritma SVM yang dilakukan oleh Maulidina dkk. [9] didapatkan hasil yang lebih baik, yaitu 85.71 % dengan presentase data training sebesar 90% dan dilakukan *feature selection*. Daanouni dkk. [10] Mencoba menggunakan data yang berbeda yaitu dataset Frankfurt hospital. Dataset ini memiliki fitur yang sama dengan dataset Pima Indians Diabetes, dan didapatkan hasil nilai akurasi tertinggi sebesar 98.20 % dengan algoritma Decision Tree.

Paper ini mengusulkan penggunaan Ensemble Learning untuk diperbandingkan tiap algoritmanya pada klasifikasi penyakit diabetes. Ensemble Learning merupakan salah satu paradigma machine learning dimana beberapa model (*base-models*) dilatih untuk memecahkan yang sama dan digabungkan untuk mendapatkan hasil yang lebih baik. Penggunaan ensemble learning pada klasifikasi penyakit diabetes telah dilakukan sebelumnya oleh Nai-Arun dan Sittidech [11] dengan menggunakan data dari Sawanpracharak Regional Hospital dengan total 48,763 records. Hasil eksperimen menggunakan metode Bagging dan Boosting didapatkan akurasi sebesar 95.312 % dan 95.304 % untuk kedua metode, dengan menggunakan Decision Tree sebagai *base-classifiers*. Penggunaan ensemble learning juga dilakukan pada penyakit

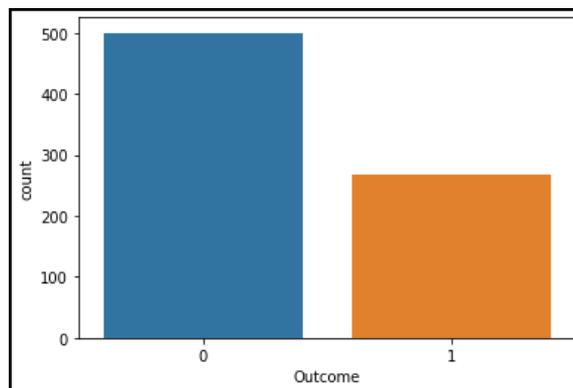
lain, seperti pada kanker serviks yang dilakukan oleh Mung, P. S. dan Phyu, S. [12] yang mendapatkan hasil berupa nilai akurasi 99.89 % dengan metode Boosting menggunakan SVM sebagai *base-classifier*, dan nilai akurasi 98.59 % dengan menggunakan metode Bagging dan Decision Tree sebagai *base-classifier*. Penelitian - penelitian tersebut membuktikan bahwa ensemble learning dapat memberikan hasil akurasi yang tinggi dan lebih baik dibandingkan dengan hanya menggunakan *base classifier* sendiri.

2 METODE PENELITIAN

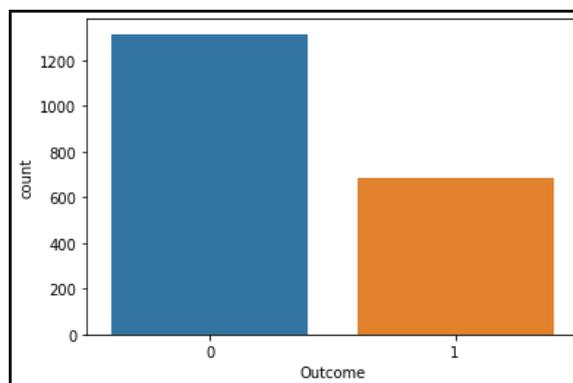
2.1 DATASET

Digunakan 3 buah dataset yang berbeda, yaitu Pima Indians Diabetes (PID) [13] yang telah digunakan pada beberapa penelitian sebelumnya [4, 5, 6, 7, 8, 9], Frankfurt Hospital Diabetes [14] yang digunakan pada penelitian Daanouni dkk. [10], dan Early Stage Diabetes Risk Prediction Dataset [15].

Dataset 1 yaitu Pima Indians Diabetes didapat dari National Institute of Diabetes and Digestive and Kidney Diseases (NIDDK) yang merupakan data hasil diagnosa wanita dengan umur minimal 21 tahun, dan memiliki garis keturunan atau darah dari suku Pima Indian, Amerika Serikat. Dataset 1 mengandung 768 record dengan jumlah 268 data positif dan 500 data negatif.



Gambar 1 Perbandingan Data Positif dan Negatif pada Dataset 1



Gambar 2 Perbandingan Data Positif dan Negatif pada Dataset 2

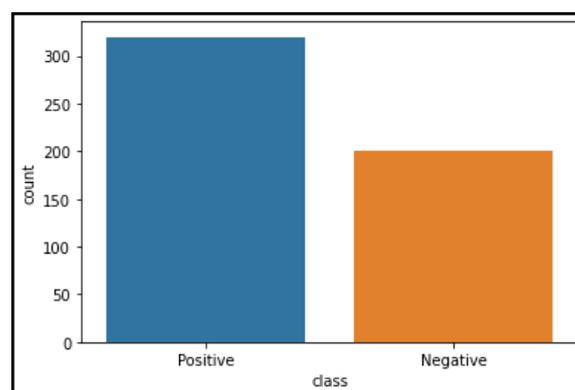
Dataset Diabetes Suku Pima Indians dan Dataset Frankfurt Hospital memiliki fitur yang sama, yaitu 8 fitur numerik, yang masing - masing adalah : Pregnancies, Glucose, BloodPressure, SkinThickness, Insulin, BMI, DiabetesPedigreeFunction, Age.

Dataset 2 didapatkan dari rumah sakit di Frankfurt, Jerman. Fitur yang dimiliki pada dataset ini sama dengan fitur yang ada pada dataset 1. Pada dataset 2, terdapat 2000 data, dengan 684 data positif dan 1316 data negatif.

Tabel 1 Keterangan Fitur Pada Dataset 1 & 2

No	Fitur	Deskripsi
1	Pregnancies	Jumlah kehamilan
2	Glucose	Konsentrasi glukosa plasma selama 2 jam
3	BloodPressure	Tekanan darah diastolik (mm Hg)
4	SkinThickness	Ketebalan lipatan kulit trisep (mm)
5	Insulin	Kadar serum insulin selama 2 jam (mu U/ml)
6	BMI	Body Mass Index (Indeks Massa Tubuh)
7	DiabetesPedigreeFunction	Kemungkinan diabetes berdasarkan riwayat keturunan keluarga
8	Age	Usia

Pregnancies menunjukkan seberapa banyak kehamilan yang pernah dialami pasien, Glucose menunjukkan konsentrasi glukosa plasma selama 2 jam dalam tes glukosa oral, BloodPressure merupakan tekanan darah diastolik pasien dengan satuan mm Hg, SkinThickness menunjukkan ketebalan lipatan kulit trisep pasien dengan satuan mm, Insulin merupakan kadar serum insulin pasien selama 2 jam dengan satuan mu U/ml, BMI menunjukkan Body mass index pasien, DiabetesPedigreeFunction menunjukkan kemungkinan diabetes berdasarkan riwayat keturunan keluarga, dan Age menunjukkan usia pasien.



Gambar 3 Perbandingan Data Positif dan Negatif pada Dataset 3

Dataset 3 didapatkan dari Sylhet Diabetes Hospital di Sylhet, Bangladesh yang memiliki total 520 records, dengan 320 data positif dan 200 data negatif. Dataset 3 memiliki 16 buah fitur, dengan 14 fitur boolean, 1 fitur string (Gender), dan 1 fitur numerik (Umur).

Tabel 2 Keterangan Fitur Pada Dataset 3

No	Fitur	Deskripsi
1	Age	Usia
2	Sex	Jenis kelamin
3	Polyuria	Buang air berlebihan
4	Polydipsia	Sering haus
5	Sudden Weight Loss	Penurunan berat badan secara tiba-tiba
6	Weakness	Kelemahan tubuh
7	Polyphagia	Banyak makan (rasa lapar berlebih dan nafsu makan meningkat)
8	Genital thrush	Ruam pada area kelamin
9	Visual Blurring	Penglihatan Kabur
10	Itching	Gatal - gatal
11	Irritability	Mudah marah
12	Delayed Healing	Penyembuhan luka berlangsung lambat
13	Partial Paresis	Berkurangnya kemampuan untuk bergerak pada sebagian badan
14	Muscle stiffness	Kekakuan otot
15	Alopecia	Rambut rontok tiba - tiba
16	Obesity	Obesitas atau kegemukan

2.2 PRAPEMROSESAN DATA

Sebelum dilakukan proses klasifikasi dengan menggunakan ensemble learning, data terlebih dulu dilakukan prapemrosesan. Prapemrosesan yang dilakukan terhadap data adalah melakukan MinMax Scaling pada tiap fitur dengan rentang antara 0 dan 1. Proses scaling ini dilakukan pada tiap dataset. Sedangkan dataset 3 yang memiliki fitur boolean dan string, dilakukan prapemrosesan tambahan yaitu melakukan konversi dari nilai kategorikal ke numerik.

Setelah dilakukan MinMax Scaling, kemudian dilakukan Data Splitting, yaitu membagi data menjadi data training dan data testing, dengan presentase data training sebesar 80% dan data testing 20%.

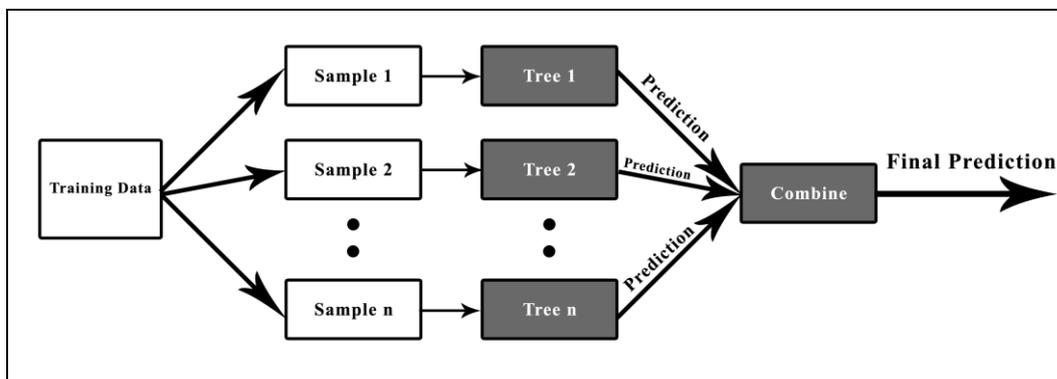
2.3 ENSEMBLE LEARNING

Ensemble Learning adalah paradigma pembelajaran mesin dimana beberapa model (biasanya disebut "*weak learners*") dilatih untuk memecahkan masalah yang sama dan digabungkan untuk mendapatkan hasil yang lebih baik. Hipotesis utamanya adalah bahwa ketika model yang lemah digabungkan, kita dapat memperoleh model yang lebih akurat.

Ensemble Learning terbagi menjadi 3 model, yaitu Bagging, Boosting, dan Stacking. Persamaan dari 3 model tersebut adalah semuanya menggunakan beberapa *base model* atau model dasar berupa beberapa model machine learning.

2.4 BAGGING

Bagging adalah salah satu metode Ensemble Learning yang menggunakan menggunakan hanya satu tipe *base-model* dengan melakukan pembelajaran secara paralel dan independen pada tiap *base-model*, dan kemudian digabungkan untuk mendapatkan hasil yang terbaik.



Gambar 4 Bagging Ensemble Learning

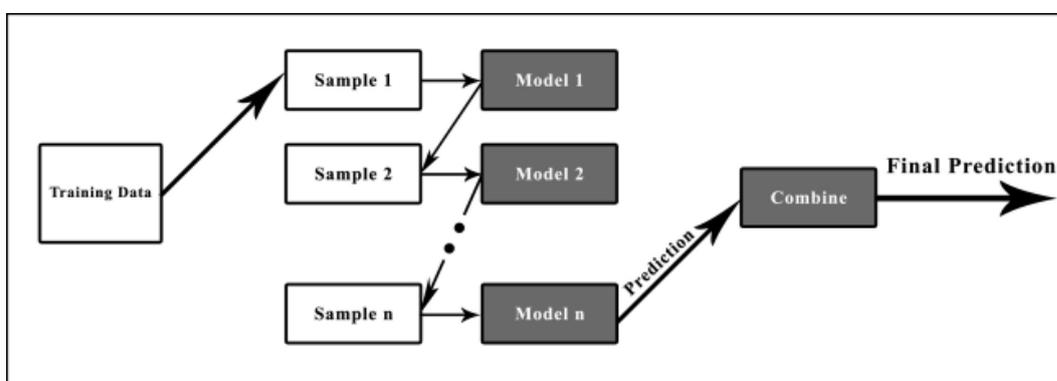
Model yang akan digunakan pada bagging ensemble learning adalah :

1. Bagging
2. Random Forest
3. Extra Trees

Base-model yang digunakan adalah Decision Tree, karena pada penelitian - penelitian sebelumnya selalu memberikan hasil yang terbaik [10, 11, 12].

2.5 BOOSTING

Boosting adalah salah satu metode Ensemble Learning yang menggunakan hanya satu tipe model *base-model* dengan melakukan pembelajaran secara sekuensial secara adaptif (hasil dari sebuah *base-model* tergantung dari hasil *base-model* sebelumnya), dan kemudian digabungkan untuk mendapatkan hasil yang terbaik.



Gambar 5 Boosting Ensemble Learning

Model yang akan digunakan pada boosting ensemble learning adalah :

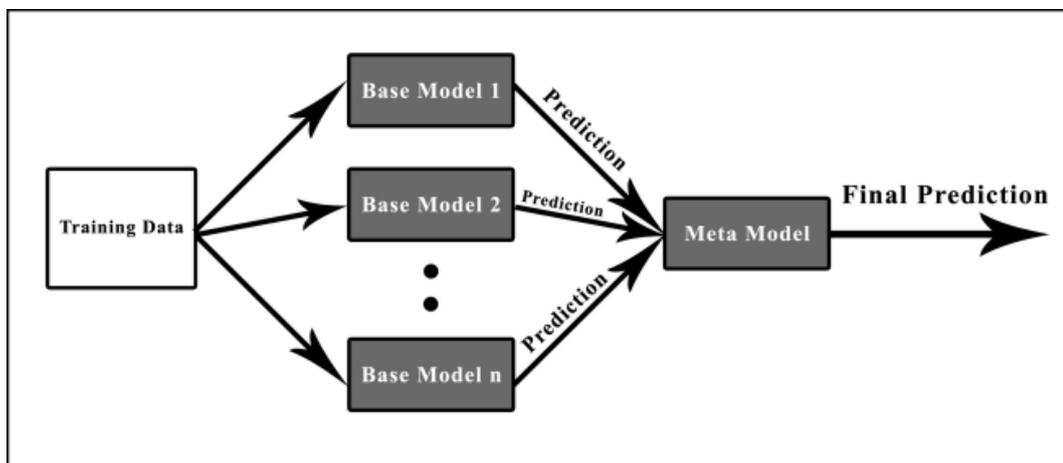
1. Adaptive boosting (AdaBoost)
2. Gradient Boosting Machines (GBM)

3. Extreme Gradient Boosting Machine (XGBM)
4. Light Gradient Boosting Machine (LGBM)
5. CatBoost

Base-model yang digunakan adalah Decision Tree, karena pada penelitian - penelitian sebelumnya selalu memberikan hasil yang terbaik [10, 11, 12].

2.6 STACKING

Stacking adalah salah satu metode Ensemble Learning yang menggunakan beberapa *base-models* dengan melakukan pembelajaran secara paralel dan independen pada tiap *base-model* dan kemudian dikombinasikan dengan menggunakan satu algoritma meta learning untuk memberikan output dari hasil kombinasi *base-models*.



Gambar 6 Stacking Ensemble Learning

Arsitektur model Stacking melibatkan dua atau lebih *base model*, atau biasa disebut sebagai model level-0, dan meta model yang menggabungkan prediksi base model disebut sebagai model level-1.

Base-model yang akan digunakan pada eksperimen stacking ensemble learning ini ada 5 model, yaitu :

1. Logistic Regression
2. Support Vector Machine (SVC)
3. Naive Bayes (Gaussian NB)
4. K-Nearest Neighbour
5. Decision Tree

Sedangkan *meta-model* yang akan digunakan adalah Logistic Regression.

2.7 EVALUATION MODELS

Metrik evaluasi yang digunakan untuk tiap model adalah Accuracy, Precision, dan Recall. Ketiga metrik tersebut dihitung dengan menggunakan nilai confusion matrix yang mengandung nilai true positive (TP), true negative (TN), false positive (FP), dan false negative (FN). Akurasi menghitung jumlah true positive dan true negative dibagi keseluruhan data.

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (1)$$

Precision menghitung true positive dibagi jumlah keseluruhan data yang diprediksi sebagai positif.

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

Sedangkan Recall menghitung true positive dibagi keseluruhan data yang benar positif.

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

3 HASIL DAN PEMBAHASAN

Dari 3 buah dataset yang masing - masing sudah dilakukan prapemrosesan dan dibagi menjadi data training dan testing, kemudian dilakukan klasifikasi dengan menggunakan 3 jenis ensemble learning dan metode - metode didalamnya.

Untuk dataset 1 (Pima Indians Diabetes Database), didapatkanlah hasil sebagai berikut :

Tabel 3 Hasil Eksperimen Dataset 1

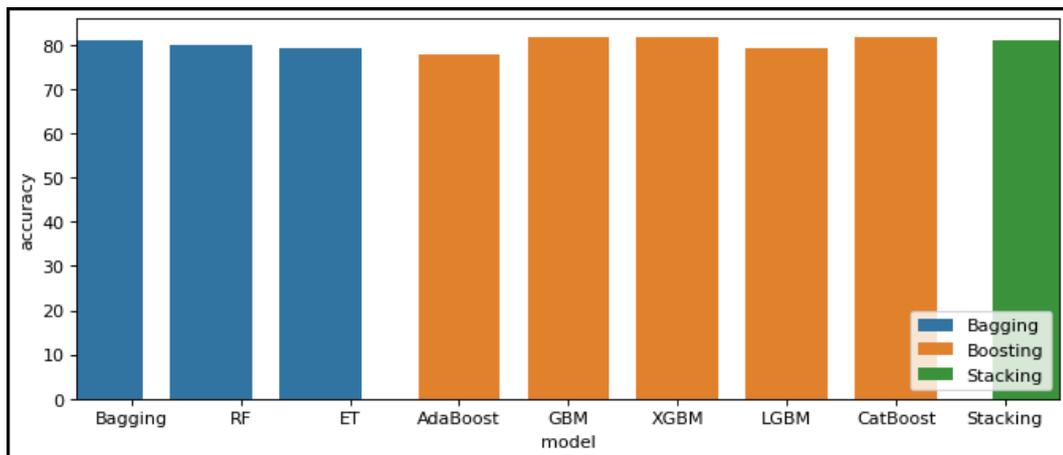
No	Metode Ensemble	Model	Accuracy	Precision	Recall
1	Bagging	Bagging	81.17%	78.13%	76.31%
		Random Forest	79.87%	76.29%	75.97%
		Extra Trees	79.22%	75.50%	75.50%
2	Boosting	Adaptative Boosting	77.92%	74.01%	74.56%
		Gradient Boosting	81.82%	78.56%	78.56%
		Extreme Gradient Boosting	81.82%	78.56%	78.56%
		Light Gradient Boosting	79.22%	75.51%	76.09%
		Cat Boosting	81.82%	78.67%	77.96%
3	Stacking	Stacked Generalization	81.17%	78.65%	75.11%

Dari hasil eksperimen yang dilakukan pada dataset 1, didapatkan akurasi tertinggi sebesar 81.82% pada 3 Model, yaitu Gradient Boosting, Extreme Gradient Boosting, dan CatBoost yang ketiganya merupakan Boosting Ensemble Learning. Sedangkan nilai Precision dan Recall ketiganya tidak terpaut jauh, dengan nilai 78.56 untuk masing - masing Precision dan Recall pada Gradient Boosting dan Extreme Boosting. CatBoost sendiri memiliki Precision sebesar 78.67% dan Recall sebesar 77.96%.

Nilai Precision dipengaruhi oleh hasil perhitungan False Positive dari model. Maka dari itu nilai Precision dapat menunjukkan kasus negatif yang diklasifikasikan sebagai positif oleh model. Nilai Precision dari CatBoost lebih tinggi daripada nilai precision dari Gradient Boosting maupun Extreme Gradient Boosting. Maka dari itu, CatBoost lebih baik dalam menangani pasien negatif yang diklasifikasikan sebagai positif oleh model.

Nilai Recall dipengaruhi oleh False Negative dari kasus diabetes, atau dengan kata lain dapat menjelaskan seberapa besar pasien positif diabetes yang diklasifikasikan sebagai negatif. Maka dari itu, nilai Recall dari Gradient Boosting dan Extreme Boosting yang lebih besar dari CatBoost menunjukkan bahwa kedua model lebih baik dalam menangani False Negative.

Untuk ensemble learning dengan metode bagging sendiri memiliki akurasi tertinggi pada model Bagging dengan nilai akurasi sebesar 81.17%, begitupula dengan hasil akurasi dengan metode Stacking.



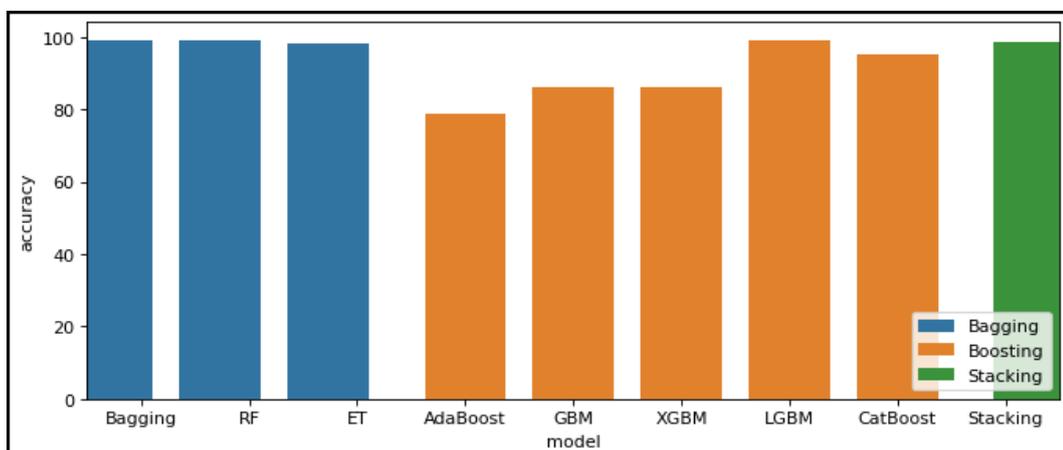
Gambar 7 Grafik Akurasi Hasil Eksperimen Pada Dataset 1

Hasil akurasi terendah didapatkan pada model Adaptative Boosting dengan nilai akurasi sebesar 77.92 %. Dataset 2 yang didapat dari Frankfurt Hospital di Jerman memiliki fitur yang sama dengan Dataset 1, namun memiliki data yang lebih banyak. Hasil dari eksperimen ensemble learning pada Dataset 2 adalah sebagai berikut :

Tabel 4 Hasil Eksperimen Dataset 2

No	Metode Ensemble	Model	Accuracy	Precision	Recall
1	Bagging	Bagging	99.25%	99.45%	98.82%
		Random Forest	99.00%	99.27%	98.84%
		Extra Trees	98.25%	98.74%	97.26%
2	Boosting	Adaptative Boosting	78.75%	75.80%	74.03%
		Gradient Boosting	86.00%	85.55%	81.43%
		Extreme Gradient Boosting	86.25%	85.21%	82.44%
		Light Gradient Boosting	99.25%	99.23%	99.03%
		Cat Boosting	95.25%	95.88%	93.19%
3	Stacking	Stacked Generalization	98.50%	98.09%	98.48%

Secara keseluruhan hasil akurasi yang didapatkan pada eksperimen ensemble learning pada dataset 2 lebih tinggi dibandingkan dataset 1. Hal ini dapat terjadi karena jumlah dataset 2 jauh lebih banyak daripada dataset 1, sehingga model dapat belajar secara lebih baik.



Gambar 8 Grafik Akurasi Hasil Eksperimen Pada Dataset 2

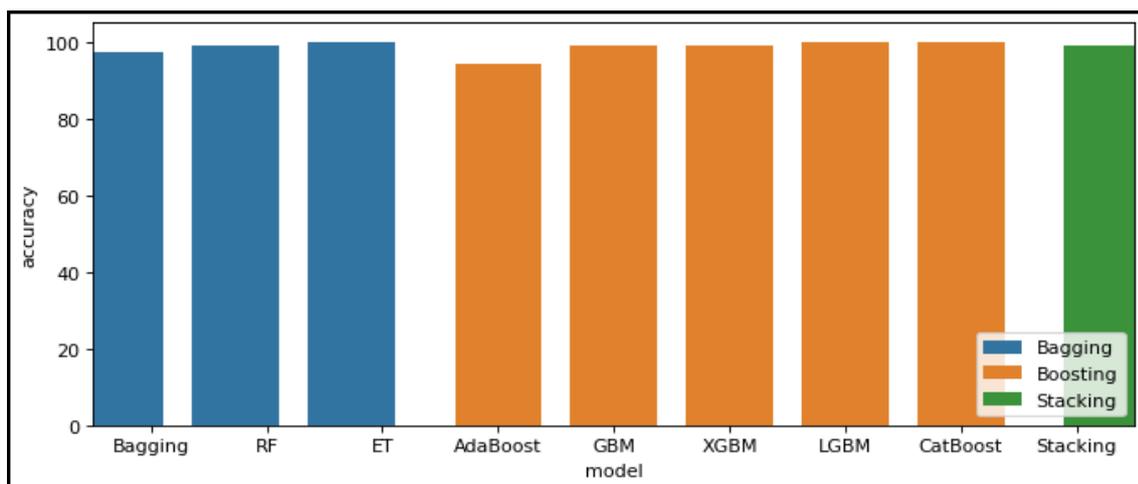
Selain itu hal ini juga dapat disebabkan karena data yang digunakan memiliki pola yang berbeda. Dari hasil eksperimen pada dataset 2, didapatkan hasil akurasi tertinggi pada model Light Gradient Boosting, dan Bagging dengan nilai akurasi sebesar 99.25 %. Sama seperti pada dataset sebelumnya, akurasi dari Boosting dapat mengungguli metode Bagging dan Stacking. Untuk nilai Precision dan Recall ketiga algoritma tersebut, didapat yang terbaik adalah pada metode Light Gradient Boosting dengan nilai Precision 99.23 % dan Recall 99.03 %. Meskipun begitu, Adaptive Boosting yang termasuk dalam metode Boosting, memiliki akurasi yang jauh dibawah rata - rata model lain, yaitu sebesar 78.75 %. Untuk hasil Stacking didapatkan akurasi sebesar 98.50 %.

Dataset 3 yang didapat dari rumah sakit di Sylhet, Bangladesh memiliki fitur yang berbeda dengan Dataset 1 dan 2. Eksperimen ensemble learning pada dataset 3 mendapatkan hasil sebagai berikut :

Tabel 5 Hasil Eksperimen Dataset 3

No	Metode Ensemble	Model	Accuracy	Precision	Recall
1	Bagging	Bagging	97.11%	96.76%	97.18%
		Random Forest	99.03%	98.78%	99.22%
		Extra Trees	100%	100%	100%
2	Boosting	Adaptive Boosting	94.23%	94.93%	92.96%
		Gradient Boosting	99.03%	98.78%	99.21%
		Extreme Gradient Boosting	99.03%	98.78%	99.21%
		Light Gradient Boosting	100%	100%	100%
		Cat Boosting	100%	100%	100%
3	Stacking	Stacked Generalization	99.03%	98.78%	99.21%

Dengan jumlah data yang lebih sedikit daripada dataset 1, ensemble learning yang dilakukan pada dataset 3 dapat memberikan hasil yang jauh lebih baik.



Gambar 9 Grafik Akurasi Hasil Eksperimen Pada Dataset 3

Didapatkan hasil akurasi tertinggi 100% pada model Extra Trees Light Gradient Boosting dan CatBoost, begitupula nilai Recall dan Precision pada ketiga model tersebut juga mencapai 100%. Sedangkan nilai akurasi Stacking hanya mencapai 99.03 %. Adaptive Boosting kembali memberikan hasil terendah, yaitu hanya mencapai nilai akurasi sebesar 94 %.

4 KESIMPULAN

Dari hasil eksperimen 3 metode ensemble learning, yaitu Bagging, Boosting, dan Stacking yang dilakukan pada 3 buah dataset yang berbeda, didapatkan nilai akurasi yang berbeda - beda pada tiap dataset.

Dataset 1 memiliki nilai akurasi terbaik sebesar 81.82 % pada 3 model di metode Boosting, yaitu Gradient Boosting, Extreme Gradient Boosting, dan Cat Boosting. Sedangkan dataset 2 mendapatkan akurasi nilai tertinggi sebesar 99.25 %, pada model Light Gradient Boosting dan model Bagging. Sedangkan pada dataset 3 didapatkan nilai akurasi tertinggi 100% pada 2 model Boosting yaitu Light Gradient Boosting dan Cat Boosting, serta 1 model Bagging yaitu Extra Trees.

Dari hasil ketiga dataset, diketahui bahwa metode Boosting selalu mendapatkan hasil terbaik. Pada dataset 2 dan 3, metode Bagging dapat mengimbangi Boosting, namun Boosting masih memberikan hasil yang lebih baik pada nilai Precision dan Recall. Sedangkan metode Stacking tidak pernah memberikan hasil terbaik pada 3 dataset yang ada. Maka dari itu, metode Boosting dapat mengungguli metode Bagging dan Stacking. Light Gradient Boosting yang merupakan salah satu metode Boosting memberikan hasil akurasi tertinggi pada Dataset 2 dan Dataset 3. Namun Adaptive Boost yang termasuk pada metode Boosting selalu memberikan hasil akurasi paling rendah diantara model yang lain.

DAFTAR PUSTAKA

- [1] Emerging Risk Factors Collaboration. (2010). Diabetes mellitus, fasting blood glucose concentration, and risk of vascular disease: a collaborative meta-analysis of 102 prospective studies. *The Lancet*, 375(9733), 2215-2222.
- [2] World Health Organization. *Diabetes*. 2021. URL: <https://www.who.int/en/news-room/fact-sheets/detail/diabetes>, diakses tanggal 7 Juni 2021.
- [3] S. J. Russell, P. Norvig, J. F. Canny, J. M. Malik, and D. D. Edwards, "Artificial Intelligence: A Modern Approach", vol. 2. Prentice hall Englewood Cliffs, 1995.
- [4] Smith, J. W., Everhart, J. E., Dickson, W. C., Knowler, W. C., Johannes, R. S., "Using the ADAP learning"
- [5] Bhoi, S. K. (2021). Prediction of Diabetes in Females of Pima Indian Heritage: A Complete Supervised Learning Approach. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(10), 3074-3084.
- [6] Agatsa, D. A., Rismala, R., & Wisesty, U. N. (2020). Klasifikasi Pasien Pengidap Diabetes Menggunakan Metode Support Vector Machine. *eProceedings of Engineering*, 7(1).
- [7] Sisodia, D., & Sisodia, D. S. (2018). Prediction of diabetes using classification algorithms. *Procedia computer science*, 132, 1578-1585.
- [8] Savvas Karatsiolis, Christos N. Schizas, "Region based Support Vector Machine Algorithm for Medical Diagnosis on Pima Indian Diabetes DataSet", 2012.
- [9] Maulidina, F., Rustam, Z., Hartini, S., Wibowo, V. V. P., Wirasati, I., & Sadewo, W. (2021, March). Feature optimization using Backward Elimination and Support Vector Machines (SVM) algorithm for diabetes classification. In *Journal of Physics: Conference Series (Vol. 1821, No. 1, p. 012006)*. IOP Publishing.

- [10] Daanouni, O., Cherradi, B., & Tmiri, A. (2019, October). Predicting diabetes diseases using mixed data and supervised machine learning algorithms. In Proceedings of the 4th International Conference on Smart City Applications (pp. 1-6).
- [11] Nai-Arun, N., & Sittidech, P. (2014). Ensemble learning model for diabetes classification. In Advanced Materials Research (Vol. 931, pp. 1427-1431). Trans Tech Publications Ltd.
- [12] Mung, P. S., & Phyu, S. (2020, February). Ensemble Learning Method for Enhancing Healthcare Classification. Proceedings of the 10th International Workshop on Computer Science and Engineering (WCSE 2020).
- [13] UCI Machine Learning. Pima Indians Diabetes Database. 2016. URL: <https://www.kaggle.com/uciml/pima-indians-diabetes-database>, diakses tanggal 7 Juni 2021.
- [14] John. diabetes. 2017. URL: <https://www.kaggle.com/johndasilva/diabetes>, diakses tanggal 7 Juni 2021.
- [15] Ishan Dutta. Early Stage Diabetes Risk Prediction Dataset. 2020. URL: <https://www.kaggle.com/ishandutta/early-stage-diabetes-risk-prediction-dataset>, diakses tanggal 7 Juni 2021.