E-ISSN : 2988-1986
https://ejournal.cahayailmubangsa.institute/index.php/kohesi

Kohesi: Jurnal Multidisiplin Saintek
Volume 11 No 2 Tahun 2026

PERBANDINGAN KINERJA ALGORITMA *RANDOM FOREST* DAN *DECISION TREE* DALAM MODEL PREDIKSI STROKE OTAK

Comparison of Random Forest and Decision Tree Algorithm Performance in Brain Stroke Prediction Model

Noel
Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara
Jln. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia

*e-mail: noel852003@gmail.com

Abstrak

Stroke adalah gangguan neurologis akibat terganggunya aliran darah ke otak, dan merupakan salah satu penyebab utama kematian serta disabilitas di dunia. Prediksi dini berbasis pembelajaran mesin dapat membantu pencegahan dan penanganan stroke. Penelitian ini membandingkan kinerja algoritma *Random Forest* dan *Decision Tree* dalam memprediksi stroke menggunakan dataset *Brain Stroke Prediction* (4.981 data pasien) yang sangat tidak seimbang, dengan dan tanpa teknik penyeimbangan *Random Undersampling* (*RUS*). Kinerja model dievaluasi menggunakan 5-*fold stratified cross-validation* dengan 5 kali pengulangan dan metrik *accuracy*, *sensitivity*, *specificity*, *precision*, *F1-score*, *ROC-AUC*, dan *PR-AUC*. Tanpa penyeimbangan, kedua model mencapai akurasi tinggi (sekitar 95%) tetapi gagal mendeteksi kelas minoritas, dengan *sensitivity* mendekati 0%. Setelah menerapkan *RUS*, *sensitivity* meningkat tajam menjadi sekitar 77% untuk *Decision Tree* dan 81% untuk *Random Forest*, dengan *Random Forest* sebagai model terbaik (*ROC-AUC* 0,82). Hasil ini menunjukkan bahwa teknik penyeimbangan data berperan penting dalam meningkatkan kemampuan model mendeteksi kasus stroke pada dataset yang sangat tidak seimbang.

Kata kunci: *Decision Tree*, *Random Forest*, *Random Undersampling*, Stroke, Teknik Penyeimbangan

Abstract

Stroke is a neurological disorder caused by disrupted blood flow to the brain and is one of the leading causes of death and disability worldwide. Early machine-learning-based prediction can support stroke prevention and treatment. This study compares the Random Forest and Decision Tree algorithms in predicting stroke using the highly imbalanced Brain Stroke Prediction dataset (4,981 patient records), with and without the Random Undersampling (RUS) balancing technique. Model performance was evaluated using 5-fold stratified cross-validation with five repetitions and the accuracy, sensitivity, specificity, precision, F1-score, ROC-AUC, and PR-AUC metrics. Without balancing, both models achieved high accuracy (around 95%) but failed to detect the minority class, with sensitivity close to 0%. After applying RUS, sensitivity increased sharply to about 77% for Decision Tree and 81% for Random Forest, with Random Forest as the best model (ROC-AUC 0.82). These results show that data balancing techniques play an important role in

Article History
Received: Juli 2026
Reviewed:Juli 2026
Published: Juli 2026

Plagiarism Checker
No 237.u873247.fh8374

Copyright : Author
Publish by : Kohesi

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

improving the model's ability to detect stroke cases in highly imbalanced datasets.

Keywords: *balancing technique, Decision Tree, Random Forest, Random Undersampling, Stroke*

PENDAHULUAN

Stroke adalah gangguan neurologis yang ditandai dengan penyumbatan pembuluh darah. Gumpalan terbentuk di otak dan mengganggu aliran darah, menyumbat arteri dan menyebabkan pembuluh darah pecah, sehingga menyebabkan perdarahan. Pecahnya pembuluh darah yang menuju ke otak selama stroke menyebabkan kematian sel-sel otak secara tiba-tiba karena kekurangan oksigen. Stroke juga dapat menyebabkan depresi dan demensia [1]. Penyakit ini merupakan penyebab kematian nomor dua di dunia [2]. Stroke dapat timbul pada siapapun, namun lebih sering pada usia tua karena degradasi pada dinding pembuluh darah [3]. Selain itu, stroke juga lebih sering timbul dan lebih berdampak secara negatif terhadap wanita [4].

Disabilitas jangka panjang akibat stroke dapat mengganggu kemampuan melakukan aktivitas sehari-hari atau kembali ke dunia kerja [5]. Kelainan saraf dan gangguan pencernaan merupakan beberapa contoh dampak sekunder akibat perubahan hormon yang terjadi akibat stroke [6]. Pemulihan disabilitas fisik pasca stroke bisa dilakukan melalui terapi fisik baik dalam rumah sakit ataupun lingkungan rumah [7]. Untuk mengurangi beban stroke, strategi pencegahan sangat penting, terutama seiring pertumbuhan dan penuaan populasi [8]. Salah satunya adalah prediksi stroke menggunakan pembelajaran mesin, yaitu komputer diberikan data pasien lalu membangun model prediksi dengan algoritma tertentu. Berbagai penelitian telah dilakukan untuk mengevaluasi algoritma terbaik dalam memprediksi stroke. Namun, data medis seperti data pasien stroke umumnya sangat tidak seimbang, di mana jumlah pasien yang tidak terkena stroke jauh lebih banyak daripada yang terkena. Kondisi ini membuat model cenderung bias terhadap kelas mayoritas, sehingga sejumlah penelitian menerapkan *balancing technique* untuk mengatasinya.

Dalam penelitian ini, *Random Undersampling* (*RUS*) digunakan sebagai balancing technique dan kinerjanya dibandingkan dengan kondisi tanpa penyeimbangan. Dua algoritma klasifikasi diuji, yaitu *Random Forest* dan *Decision Tree*. Kontribusi penelitian ini adalah menunjukkan sejauh mana penerapan balancing technique memengaruhi kemampuan kedua algoritma dalam mendeteksi kelas minoritas pada dataset stroke yang sangat tidak seimbang, dengan evaluasi yang menekankan *sensitivity* dan bukan sekadar akurasi.

TINJAUAN LITERATUR

Random Forest

Random Forest yang dikemukakan oleh Breiman merupakan algoritma *machine learning* dengan banyak *Decision tree*. Ini adalah kombinasi dari metode *Bagging* dan *Random Subspaces*. Metode ini telah membuktikan keberhasilannya dalam masalah regresi dan klasifikasi [9] dalam beberapa tahun terakhir dan merupakan salah satu algoritma pembelajaran mesin terbaik yang digunakan di berbagai bidang [10].

Random Forest merupakan salah satu jenis metode *bootstrap aggregating* yang memiliki cara kerja dengan membangkitkan sejumlah *tree* dari data sample dimana pembuatan satu *tree* pada saat proses *training* tidak bergantung terhadap *tree* sebelumnya kemudian dalam pengambilan keputusannya diambil berdasarkan *voting* terbanyak [11]. Dua konsep yang menjadi dasar dari *Random Forest* adalah membangun *ensemble* dari *tree via bagging* dengan

replacement dan penyeleksian fitur secara acak untuk tiap *tree* yang dibangun. Berikut merupakan penjelasan dari konsep dasar pada algoritme *Random Forest* [12]. Pertama, setiap sampel yang dipilih dari dataset untuk melatih setiap pohon dapat digunakan kembali untuk melatih pohon lainnya. Kedua, fitur yang digunakan saat melatih setiap pohon adalah subset dari fitur yang ada dalam dataset. *Random Forest* memiliki dua parameter utama: parameter m, yang menentukan persentase jumlah pohon yang akan digunakan, dan parameter k, yang menentukan jumlah maksimal fitur yang dipertimbangkan saat proses percabangan pada setiap pohon [11].

Decision Tree

Decision Tree adalah salah satu metode yang sangat kuat yang umumnya digunakan dalam berbagai bidang, seperti machine learning, pengolahan citra, dan identifikasi pola. *Decision Tree* merupakan model berurutan yang menggabungkan serangkaian uji dasar dengan efisien dan bersatu padu, di mana fitur numerik dibandingkan dengan nilai ambang batas dalam setiap uji [13].

Ibomoiye Domor Mienye [14] mengutip Ross Quinlan yang mengembangkan algoritma ID3 dan C4.5, algoritma yang terakhir adalah versi perbaikan dari yang sebelumnya. Pada *Decision Tree* ID3 hanya fitur tipe kategorikal yang dapat digunakan, dan fitur tipe numerik tidak dapat diterapkan. Perbaikan dalam C4.5 termasuk penggunaan rasio perolehan informasi (IGR) dan bukan perolehan informasi seperti pada ID3. Kedua, pemangkasan dapat dilakukan saat membangun pohon atau setelah pembangunan pohon. Ketiga, C4.5 dapat menangani atribut-atribut yang berisi fitur-fitur yang kontinu.

Prediksi Stroke dengan *Machine Learning*

Penerapan pembelajaran mesin untuk prediksi stroke telah banyak diteliti dalam beberapa tahun terakhir. Dritsas dan Trigka mengevaluasi sejumlah algoritma untuk memprediksi risiko stroke dan menemukan bahwa pendekatan berbasis *ensemble* memberikan kinerja terbaik [15]. Biswas dkk. melakukan analisis komparatif terhadap beberapa *classifier* untuk prediksi stroke dan menyoroti pentingnya pemilihan algoritma serta penanganan data yang tepat [16]. Tazin dkk. menerapkan beberapa algoritma pembelajaran mesin untuk deteksi stroke dan menyoroti pentingnya penyeimbangan data dalam meningkatkan kinerja model [17].

Namun, sebagian besar penelitian ini menghadapi tantangan yang sama, yaitu dataset stroke yang sangat tidak seimbang, di mana proporsi pasien tanpa stroke jauh lebih besar daripada pasien stroke. Liu dkk. secara khusus menangani persoalan ini dengan mengusulkan pendekatan hybrid untuk prediksi stroke pada dataset medis yang tidak seimbang . Penelitian-penelitian tersebut menjadi dasar bagi studi ini dalam membandingkan kinerja Random Forest dan Decision Tree pada kondisi data tidak seimbang [18].

Penanganan Ketidakseimbangan Kelas

Ketidakseimbangan kelas (*class imbalance*) terjadi ketika salah satu kelas memiliki jumlah sampel yang jauh lebih sedikit dibanding kelas lain. Kondisi ini membuat model klasifikasi cenderung bias terhadap kelas mayoritas sehingga menurunkan kemampuan mendeteksi kelas minoritas, yang justru sering kali merupakan kelas yang paling penting dalam konteks medis [19]. Untuk mengatasinya, terdapat beberapa kelompok pendekatan, di antaranya pendekatan berbasis data (*resampling*), berbasis algoritma, *cost-sensitive learning*, dan *ensemble* [19]. Pendekatan berbasis data paling banyak digunakan karena dapat diterapkan tanpa bergantung pada algoritma tertentu, melalui *oversampling* (menambah sampel kelas minoritas) atau *undersampling* (mengurangi sampel kelas mayoritas).

Random Undersampling (*RUS*) merupakan teknik *undersampling* paling awal dan sederhana, yang bekerja dengan menghapus sampel kelas mayoritas secara acak hingga kedua kelas seimbang. Kelebihannya adalah sederhana dan cepat, sedangkan kekurangannya adalah berpotensi membuang informasi yang berguna dari kelas mayoritas [19]. Untuk menghindari kebocoran data (*data leakage*), proses penyeimbangan idealnya hanya diterapkan pada data latih di dalam setiap *fold* validasi silang.

METODE PENELITIAN

Kumpulan Data

Kumpulan data yang digunakan dalam eksperimen ini berasal dari Brain Stroke Prediction dataset (kaggle.com). Dataset ini terdiri dari 4981 data pasien dengan 11 atribut dan 2 kelas: stroke dan non-stroke. Fitur yang dipilih adalah jenis kelamin, usia, penderita hipertensi, penderita penyakit jantung, status pernikahan, tipe pekerjaan, tempat tinggal, kadar glukosa dalam darah, indeks massa tubuh, dan status merokok.

Pra-pemrosesan

Sebelum data dapat dilatih, data melalui tahap pra-pemrosesan. Atribut kategorikal biner (jenis kelamin, status pernikahan) dikonversi menjadi nilai numerik, sedangkan atribut kategorikal dengan lebih dari dua nilai (tipe pekerjaan, tempat tinggal, status merokok) dikodekan menggunakan *one-hot encoding*. Dari 4.981 pasien, sebanyak 4.733 tidak menderita stroke dan 248 menderita stroke.

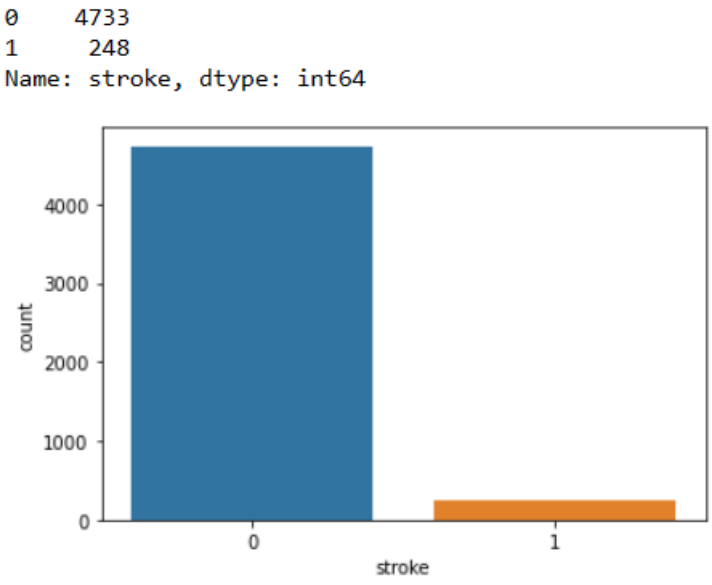

Gambar 1 Perbandingan data pasien tidak stroke (0) dan stroke (1) dalam dataset

Setelah dibandingkan, bisa dilihat pada kelas target terdapat perbandingan antara pasien tidak terkena stroke dan pasien yang terkena stroke yang sangat besar. Ketidakseimbangan tersebut disebut sebagai *class imbalance*. Fenomena *class imbalance* ini dapat memunculkan hasil yang tidak baik untuk prediksi kelas minoritas pada model prediksi, yaitu untuk yang terkena stroke. Teknik penyeimbangan yang diterapkan untuk mengatasi masalah tersebut adalah *Random Undersampling* (*RUS*).

Klasifikasi

Algoritma klasifikasi digunakan untuk memprediksi apakah pasien terkena stroke atau tidak. Algoritma yang digunakan dalam penelitian ini adalah: *Random Forest* dan *Decision tree*. *Decision Tree* dikonfigurasi dengan kriteria *gini* dan kedalaman maksimum 5, sedangkan *Random Forest*

menggunakan 250 pohon. Untuk menjamin hasil yang dapat direproduksi, *random state* ditetapkan bernilai tetap pada seluruh proses.

Setiap algoritma diuji dalam dua kondisi, yaitu tanpa penyeimbangan dan dengan penerapan *RUS*, sehingga diperoleh empat skenario perbandingan. Kinerja model dievaluasi menggunakan *5-fold stratified cross-validation* dengan 5 kali pengulangan. Pada skenario dengan *RUS*, proses penyeimbangan hanya diterapkan pada data latih di setiap *fold*, sedangkan data uji dibiarkan dalam distribusi aslinya untuk menghindari kebocoran data (*data leakage*) dan menjaga penilaian tetap realistis.

Metode Evaluasi

Kinerja setiap model dievaluasi menggunakan metrik *accuracy*, *sensitivity*, *specificity*, *precision*, *F1-score*, *ROC-AUC*, dan *PR-AUC*. Karena dataset sangat tidak seimbang, akurasi saja dapat menyesatkan—model yang selalu memprediksi kelas mayoritas tetap memperoleh akurasi tinggi. Oleh karena itu, evaluasi difokuskan pada *sensitivity* (kemampuan mendeteksi pasien stroke) dan *PR-AUC*, yang lebih informatif pada kondisi prevalensi kelas positif yang rendah. Setiap metrik dilaporkan sebagai nilai rata-rata beserta simpangan baku dari seluruh *fold*.

HASIL DAN PEMBAHASAN

Tanpa *Balancing*

Pada kondisi tanpa *balancing* pada *dataset*, kedua model mencapai akurasi yang sangat tinggi, yaitu 94,7% untuk *Decision Tree* dan 94,8% untuk *Random Forest* bisa dilihat pada Tabel 1. Namun, nilai akurasi ini cukup menyesatkan. Nilai *sensitivity* kedua model mendekati nol, 0,013 untuk *Decision Tree* dan 0,002 untuk *Random Forest*, yang berarti model hampir tidak pernah berhasil mengenali pasien yang benar-benar terkena stroke. Hal ini merupakan dampak langsung dari ketidakseimbangan kelas: karena lebih dari 95% data adalah pasien non-stroke, model dapat memperoleh akurasi tinggi hanya dengan memprediksi seluruh pasien sebagai non-stroke. Nilai *F1-score* yang sangat rendah (0,024 dan 0,005) menegaskan bahwa kedua model gagal pada kelas minoritas

Metrik	Decision Tree	*Random Forest*
Accuracy	0,947 ± 0,001	0,948 ± 0,001
Sensitivity	0,013 ± 0,005	0,002 ± 0,002
Specificity	0,996 ± 0,001	0,998 ± 0,001
Precision	0,139 ± 0,052	0,052 ± 0,046
F1-score	0,024 ± 0,009	0,005 ± 0,004
ROC-AUC	0,800 ± 0,007	0,798 ± 0,006
PR-AUC	0,151 ± 0,004	0,140 ± 0,009

Tabel 1 Hasil evaluasi tanpa balancing

```
[[4713   20]
 [ 245    3]]
The classification report is:
              precision    recall  f1-score   support

           0       0.95      1.00      0.97      4733
           1       0.13      0.01      0.02       248

    accuracy                           0.95      4981
   macro avg       0.54      0.50      0.50      4981
weighted avg       0.91      0.95      0.93      4981

Sensitivity: 0.0121
Specificity: 0.9958
ROC-AUC    : 0.7997
PR-AUC     : 0.1512
```

Gambar 2 Hasil evaluasi *Decision Tree* tanpa balancing technique

```
[[4723   10]
 [ 247    1]]
The classification report is:
              precision    recall  f1-score   support

           0       0.95      1.00      0.97      4733
           1       0.09      0.00      0.01       248

    accuracy                           0.95      4981
   macro avg       0.52      0.50      0.49      4981
weighted avg       0.91      0.95      0.93      4981

Sensitivity: 0.0040
Specificity: 0.9979
ROC-AUC    : 0.7979
PR-AUC     : 0.1404
```

Gambar 3 Hasil evaluasi *Random Forest* tanpa balancing technique

***Random Undersampling* (*RUS*)**

Setelah penerapan *RUS* pada data latih, kemampuan kedua model mendeteksi pasien stroke meningkat tajam. Nilai *sensitivity Decision Tree* naik dari 0,013 menjadi 0,773, dan *Random Forest* dari 0,002 menjadi 0,811 yang bisa dilihat pada Tabel 2. Sebagai konsekuensinya, akurasi menurun menjadi 68,6% dan 71,5%, dikarenakan model kini juga menghasilkan sejumlah false positive pada kelas mayoritas. Secara keseluruhan, *Random Forest* dengan *RUS* memberikan kinerja terbaik, dengan *sensitivity* tertinggi (0,811), *ROC-AUC* tertinggi (0,817), serta *F1-score* dan *PR-AUC* yang lebih unggul dibanding model lainnya. Nilai simpangan baku yang kecil pada seluruh metrik menunjukkan bahwa hasil ini stabil dan tidak bergantung pada pembagian data tertentu

Metrik	*Decision Tree* + *RUS*	*Random Forest* + *RUS*
Accuracy	0,686 ± 0,013	0,715 ± 0,005
Sensitivity	0,773 ± 0,025	0,811 ± 0,020
Specificity	0,681 ± 0,014	0,710 ± 0,006
Precision	0,113 ± 0,005	0,128 ± 0,001

F1-score	0,197 ± 0,008	0,221 ± 0,002
ROC-AUC	0,765 ± 0,007	0,817 ± 0,005
PR-AUC	0,112 ± 0,004	0,154 ± 0,006

Tabel 2 Hasil evaluasi menggunakan *Random Undersampling*

```
[[3224 1509]
 [  56  192]]
The classification report is:
              precision    recall  f1-score   support

           0       0.98      0.68      0.80      4733
           1       0.11      0.77      0.20       248

    accuracy                           0.69      4981
   macro avg       0.55      0.73      0.50      4981
weighted avg       0.94      0.69      0.77      4981

Sensitivity: 0.7742
Specificity: 0.6812
ROC-AUC    : 0.7653
PR-AUC     : 0.1116
```

Gambar 4 Hasil evaluasi *Decision Tree* menggunakan *Random Undersampling*

```
[[3360 1373]
 [  47  201]]
The classification report is:
              precision    recall  f1-score   support

           0       0.99      0.71      0.83      4733
           1       0.13      0.81      0.22       248

    accuracy                           0.71      4981
   macro avg       0.56      0.76      0.52      4981
weighted avg       0.94      0.71      0.80      4981

Sensitivity: 0.8105
Specificity: 0.7099
ROC-AUC    : 0.8174
PR-AUC     : 0.1537
```

Gambar 5 Hasil evaluasi *Random Forest* menggunakan *Random Undersampling*

Perlu dicatat bahwa nilai *precision* pada kedua model setelah penyeimbangan relatif rendah sekitar 0,11–0,13. Hal ini wajar terjadi pada dataset dengan prevalensi kelas positif yang sangat rendah: ketika model dituntut menangkap sebanyak mungkin kasus stroke, jumlah false positive ikut meningkat sehingga *precision* menurun. Dalam konteks deteksi dini stroke, *sensitivity* yang tinggi umumnya lebih diutamakan daripada *precision*, karena melewatkan pasien yang benar-

benar berisiko (false negative) berakibat jauh lebih fatal daripada memberikan peringatan berlebih.

Kurva *ROC* dan *Precision-Recall*

Untuk memberikan gambaran kinerja yang tidak bergantung pada satu ambang keputusan, Gambar 6 menyajikan kurva *ROC* dan kurva *Precision-Recall* untuk keempat skenario. Pada kurva *ROC*, *Random Forest* dengan *RUS* memperoleh area di bawah kurva tertinggi (AUC = 0,81), diikuti *Random Forest* dan *Decision Tree* tanpa penyeimbangan. Kurva *Precision-Recall* menegaskan kembali tantangan pada data yang sangat tidak seimbang: seluruh model memiliki *precision* yang rendah pada tingkat recall tinggi, sehingga PR-AUC berada jauh di atas garis dasar prevalensi (sekitar 0,05) namun tetap moderat.

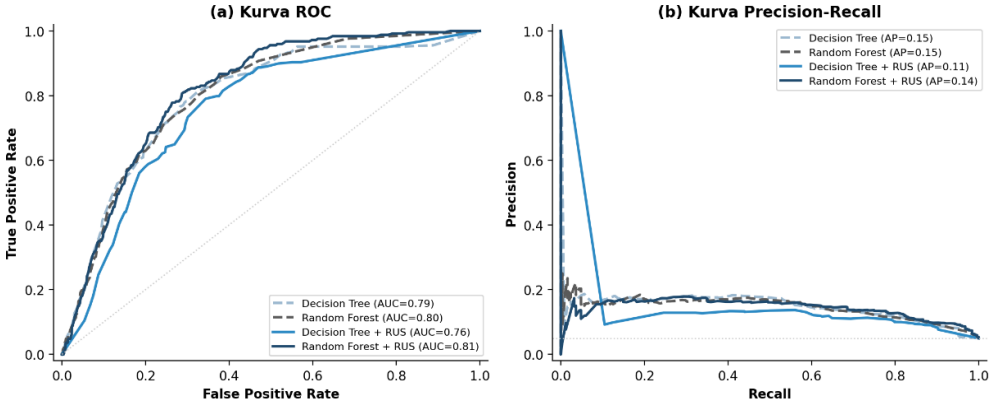

Gambar 6 *Kurva ROC* dan *Precision-Recall* untuk keempat skenario

Analisis Kepentingan Fitur

Untuk memahami faktor yang paling berpengaruh dalam prediksi, dihitung nilai *feature importance* dari model *Random Forest* dengan *RUS*, dirata-rata dari seluruh *fold* validasi silang (Gambar 7). Tiga fitur numerik mendominasi, yaitu usia (0,37), kadar glukosa darah (0,18), dan indeks massa tubuh (0,16), yang bersama-sama menyumbang sekitar 71% dari total kepentingan fitur. Hal ini sejalan dengan pengetahuan medis bahwa usia lanjut, kadar glukosa tinggi, dan obesitas merupakan faktor risiko utama stroke. Fitur lain seperti hipertensi, status pernikahan, dan penyakit jantung memberikan kontribusi yang jauh lebih kecil. Temuan ini menunjukkan bahwa model tidak hanya mencapai kinerja deteksi yang baik, tetapi juga menangkap pola yang secara klinis relevan, sehingga meningkatkan kepercayaan terhadap hasil prediksi.

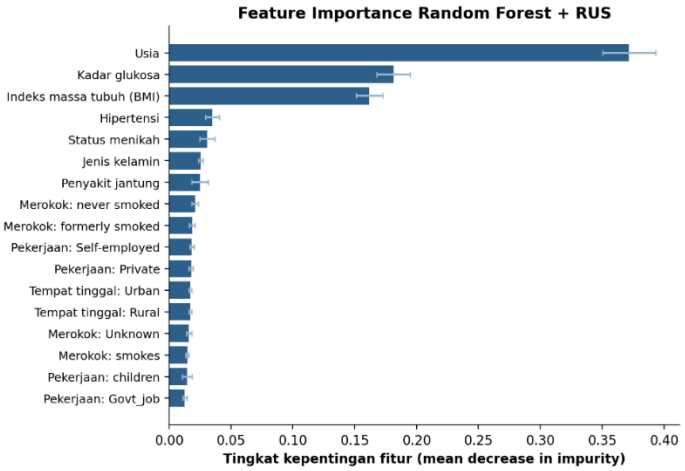

Gambar 7 *Feature importance Random Forest* dengan *RUS* (rata-rata seluruh fold)

KESIMPULAN

Penelitian ini membandingkan kinerja algoritma *Random Forest* dan *Decision Tree* dalam memprediksi stroke pada dataset yang sangat tidak seimbang, dengan dan tanpa penerapan *Random Undersampling* (*RUS*). Hasil menunjukkan bahwa tanpa penyeimbangan, kedua model memperoleh akurasi yang sangat tinggi (sekitar 95%) tetapi gagal mendeteksi pasien stroke, dengan *sensitivity* mendekati nol. Hal ini menegaskan bahwa akurasi bukanlah ukuran yang memadai untuk data yang tidak seimbang.

Setelah penerapan *RUS*, kemampuan kedua model mendeteksi pasien stroke meningkat tajam. *Sensitivity Decision Tree* naik menjadi 0,773 dan *sensitivity Random Forest* menjadi 0,811. Secara keseluruhan, *Random Forest* dengan *RUS* memberikan kinerja terbaik, dengan *sensitivity* dan *ROC-AUC* tertinggi (0,811 dan 0,817). Peningkatan *sensitivity* ini disertai penurunan *precision*, yang merupakan konsekuensi wajar dari rendahnya prevalensi kelas positif. Dalam konteks deteksi dini stroke, kemampuan menangkap kasus positif umumnya lebih diutamakan.

Dengan demikian, dapat disimpulkan bahwa teknik penyeimbangan data berperan penting dalam meningkatkan kualitas model prediksi pada dataset medis yang tidak seimbang. Penelitian selanjutnya dapat membandingkan *RUS* dengan teknik penyeimbangan lainnya, menguji algoritma klasifikasi yang lebih beragam, serta menggunakan dataset yang lebih besar untuk memperkuat generalisasi hasil.

REFERENSI

[1] D. Kuriakose and Z. Xiao, “Pathophysiology and treatment of stroke: Present status and future perspectives,” *International Journal of Molecular Sciences*, vol. 21, no. 20. 2020. doi: 10.3390/ijms21207609.

[2] V. L. Feigin *et al.*, “World Stroke Organization (WSO): Global Stroke Fact Sheet 2022,” *International Journal of Stroke*, vol. 17, no. 1. 2022. doi: 10.1177/17474930211065917.

[3] M. Yousufuddin and N. Young, “Aging and ischemic stroke,” *Aging*, vol. 11, no. 9. 2019. doi: 10.18632/aging.101931.

[4] K. M. Rexrode, T. E. Madsen, A. Y. X. Yu, C. Carcel, J. H. Lichtman, and E. C. Miller, “The Impact of Sex and Gender on Stroke,” *Circ Res*, vol. 130, no. 4, 2022, doi: 10.1161/CIRCRESAHA.121.319915.

[5] M. M. Martin-Saez and N. James, “The experience of occupational identity disruption post stroke: a systematic review and meta-ethnography,” *Disabil Rehabil*, vol. 43, no. 8, 2021, doi: 10.1080/09638288.2019.1645889.

[6] Y. Ge, M. Zadeh, C. Yang, E. Candelario-Jalil, and M. Mohamadzadeh, “Ischemic Stroke Impacts the Gut Microbiome, Ileal Epithelial and Immune Homeostasis,” *iScience*, vol. 25, no. 11, 2022, doi: 10.1016/j.isci.2022.105437.

[7] E. C. Chiu, F. C. Chi, and P. T. Chen, “Investigation of the home-reablement program on rehabilitation outcomes for people with stroke: A pilot study,” *Medicine (United States)*, vol. 100, no. 26, 2021, doi: 10.1097/MD.0000000000026515.

[8] P. B. Gorelick, “The global burden of stroke: persistent and disabling,” *The Lancet Neurology*, vol. 18, no. 5. 2019. doi: 10.1016/S1474-4422(19)30030-4.

[9] F. T. Kurdi, “*Random Forest* Machine Learning Technique for Automatic Vegetation Detection and Modelling in LiDAR Data,” *International Journal of Environmental Sciences & Natural Resources*, vol. 28, no. 2, 2021, doi: 10.19080/ijesnr.2021.28.556234.

[10] C. M. YEŞİLKANAT, “Spatio-temporal estimation of the daily cases of COVID-19 in worldwide using *Random Forest* machine learning algorithm,” *Chaos Solitons Fractals*, vol. 140, 2020, doi: 10.1016/j.chaos.2020.110210.

[11] N. Widjiyati, "Implementasi Algoritme *Random Forest* Pada Klasifikasi Dataset Credit Approval," *Jurnal Janitra Informatika dan Sistem Informasi*, vol. 1, no. 1, 2021, doi: 10.25008/janitra.v1i1.118.
[12] T. Lu, Y. Huang, W. Zhao, and J. Zhang, "The Metering Automation System based Int*RUS*ion Detection Using *Random Forest* Classifier with SMOTE+ENN," in *Proceedings of IEEE 7th International Conference on Computer Science and Network Technology, ICCSNT 2019*, 2019. doi: 10.1109/ICCSNT47585.2019.8962430.
[13] B. Charbuty and A. Abdulazeez, "Classification Based on *Decision Tree* Algorithm for Machine Learning," *Journal of Applied Science and Technology Trends*, vol. 2, no. 01, pp. 20–28, Mar. 2021, doi: 10.38094/jastt20165.
[14] I. D. Mienye, Y. Sun, and Z. Wang, "*Prediction* performance of improved *decision tree*-based algorithms: A review," in *Procedia Manufacturing*, 2019. doi: 10.1016/j.promfg.2019.06.011.
[15] E. Dritsas and M. Trigka, "Stroke Risk Prediction with Machine Learning Techniques," Sensors, vol. 22, no. 13, p. 4670, 2022, doi: 10.3390/s22134670.
[16] N. Biswas, K. M. M. Uddin, S. T. Rikta, and S. K. Dey, "A comparative analysis of machine learning classifiers for stroke prediction: A predictive analytics approach," Healthcare Analytics, vol. 2, p. 100116, 2022, doi: 10.1016/j.health.2022.100116.
[17] T. Tazin, M. N. Alam, N. N. Dola, M. S. Bari, S. Bourouis, and M. M. Khan, "Stroke Disease Detection and Prediction Using Robust Learning Approaches," Journal of Healthcare Engineering, vol. 2021, art. 7633381, 2021, doi: 10.1155/2021/7633381.
[18] T. Liu, W. Fan, and C. Wu, "A hybrid machine learning approach to cerebral stroke prediction based on imbalanced medical dataset," Artificial Intelligence in Medicine, vol. 101, art. 101723, 2019, doi: 10.1016/j.artmed.2019.101723.
[19] M. Carvalho, A. J. Pinho, and S. Brás, "Resampling approaches to handle class imbalance: a review from a data perspective," Journal of Big Data, vol. 12, no. 1, art. 71, 2025, doi: 10.1186/s40537-025-01119-4.