

**PENERAPAN *DEEP NEURAL NETWORK* DENGAN
DROPOUT DAN *COST-SENSITIVE LEARNING* UNTUK
PREDIKSI PENYAKIT STROKE**

TUGAS AKHIR

**Cynthia Caroline
1118004**



INSTITUT
TEKNOLOGI
HARAPAN
BANGSA

Veritas vos liberabit

**PROGRAM STUDI INFORMATIKA
INSTITUT TEKNOLOGI HARAPAN BANGSA
BANDUNG
2022**

**PENERAPAN *DEEP NEURAL NETWORK* DENGAN
DROPOUT DAN *COST-SENSITIVE LEARNING* UNTUK
PREDIKSI PENYAKIT STROKE**

TUGAS AKHIR

**Diajukan sebagai salah satu syarat untuk memperoleh
gelar sarjana dalam bidang Informatika**

Cynthia Caroline

1118004



INSTITUT
TEKNOLOGI
HARAPAN
BANGSA

Veritas vos liberabit

**PROGRAM STUDI INFORMATIKA
INSTITUT TEKNOLOGI HARAPAN BANGSA
BANDUNG
2022**

ABSTRAK

Nama : Cynthia Caroline
Program Studi : Informatika
Judul : Penerapan *Deep Neural Network* dengan *Dropout* dan *Cost-Sensitive Learning* untuk Prediksi Penyakit Stroke

Stroke adalah kondisi yang terjadi ketika pasokan darah ke otak berkurang. Stroke terbagi 2 jenis, yaitu stroke iskemik yang disebabkan akibat penyumbatan dan stroke hemoragik yang disebabkan akibat pecahnya pembuluh darah. Tanpa darah, otak tidak dapat mendapat asupan oksigen sehingga sel yang terdampak akan segera mati. Pada penelitian ini, akan dibangun model prediksi penyakit stroke dengan menggunakan *Deep Neural Network* dengan *dropout* dan *Cost-Sensitive Learning* serta *Probability Tuning* untuk melakukan *handling* terhadap kelas yang tidak seimbang dari dataset. Dataset yang digunakan dalam penelitian ini adalah *Cerebral Stroke Prediction-Imbalanced Dataset* yang bersumber dari Kaggle. Data ini akan dilakukan *preprocessing* terlebih dahulu sebelum diolah lebih lanjut menjadi suatu model. Hasil akurasi tertinggi diraih oleh model *Deep Neural Network* adalah 84,50% dengan menggunakan *learning rate* 0,01, *hidden layer* 3, *epoch* 100, dan *activation function* tanh. Hasil ROC tertinggi diraih oleh model *Deep Neural Network* adalah 0,5303 dengan menggunakan *learning rate* 0,01, *hidden layer* 4, *epoch* 10, dan *activation function* tanh.

Kata kunci: Stroke, Deep Neural Network, Dropout, Cost-Sensitive Learning, Probability Tuning.

ABSTRACT

Name : Cynthia Caroline
Department : Informatics
Title : Implementation of Deep Neural Network with Dropout and Cost-Sensitive Learning for Stroke Prediction

A stroke is a condition that occurs when the blood supply to the brain is reduced. There are 2 types of stroke, namely ischemic stroke caused by blockage and hemorrhagic stroke caused by blood vessel rupture. Without blood, the brain cannot receive oxygen, so the affected cells will die immediately. In this study, a stroke prediction model will be built using a Deep Neural Network with dropout and Cost-Sensitive Learning and Probability Tuning to handle imbalanced classes from the dataset. The dataset used in this study is the Cerebral Stroke Prediction-Imbalanced Dataset sourced from Kaggle. This data will be preprocessed before being further processed into a model. The highest accuracy result achieved by the Deep Neural Network model is 84,50% using a learning rate of 0,01, hidden layer 3, epoch 100, and activation function tanh. The highest ROC result achieved by the Deep Neural Network model is 0,5303 using a learning rate of 0,01, hidden layer 4, epoch 10, and activation function tanh.

Keywords: Stroke, Deep Neural Network, Dropout, Cost-Sensitive Learning, Probability Tuning.

KATA PENGANTAR

Puji syukur kepada Tuhan yang Maha Esa karena atas berkat-Nya, penulis dapat membuat dan menyelesaikan tugas akhir dengan judul "PENERAPAN DEEP NEURAL NETWORK DENGAN DROPOUT DAN COST-SENSITIVE LEARNING UNTUK PREDIKSI PENYAKIT STROKE". Tugas akhir ini disusun sebagai salah satu syarat kelulusan di Institut Teknologi Harapan Bangsa. Pada kesempatan ini, penulis ingin menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Tuhan yang Maha Esa, karena berkat-Nya, penulis selalu mendapat pengharapan untuk menyelesaikan tugas akhir ini.
2. Bapak Ventje Jeremias Lewi Engel, M.T., CEH., selaku pembimbing tugas akhir yang senantiasa memberi dukungan, masukkan, semangat, ilmu-ilmu, dan saran kepada penulis selama tugas akhir dan selama pembuatan laporan tugas akhir ini.
3. Ibu Ir. Inge Martina, M.T., selaku penguji 1 tugas akhir. Terima kasih atas dukungan, masukkan, semangat, ilmu-ilmu, dan saran kepada penulis dalam menyelesaikan laporan tugas akhir ini.
4. Ibu Ken Ratri Retno Wardani, S.Kom, M.T., selaku penguji 2 tugas akhir. Terima kasih atas dukungan, masukkan, semangat, ilmu-ilmu, dan saran kepada penulis dalam menyelesaikan laporan tugas akhir ini.
5. Seluruh jajaran staff Insitut Teknologi Harapan Bangsa yang turut membantu kelancaran dalam menyelesaikan laporan tugas akhir ini.
6. Kedua orang tua tercinta yang selalu menyediakan waktu untuk memberikan doa, semangat dan dukungan yang tak habis-habisnya kepada penulis untuk menyelesaikan laporan tugas akhir ini.
7. Teman-teman yang turut membantu dan mendukung penulis dalam menyelesaikan laporan tugas akhir ini.

Penulis menyadari bahwa tugas akhir ini masih jauh dari kata sempurna dikarenakan keterbatasan waktu dan pengetahuan penulis. Oleh sebab itu, kritik dan saran untuk membangun kesempurnaan tugas akhir ini sangat diharapkan. Semoga tugas akhir ini dapat membantu para pihak yang membutuhkan.

Bandung, 26 Juni 2022
Hormat penulis,

A handwritten signature in black ink, appearing to read "Cynthia". A single horizontal line extends from the end of the "n" towards the right.

Cynthia Caroline

DAFTAR ISI

ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	viii
DAFTAR TABEL	xi
DAFTAR GAMBAR	xiii
BAB 1 PENDAHULUAN	1-1
1.1 Latar Belakang	1-1
1.2 Rumusan Masalah	1-3
1.3 Tujuan Penelitian	1-3
1.4 Batasan Masalah	1-4
1.5 Kontribusi Penelitian	1-4
1.6 Metodologi Penelitian	1-4
1.7 Sistematika Pembahasan	1-5
BAB 2 LANDASAN TEORI	2-1
2.1 Tinjauan Pustaka	2-1
2.1.1 <i>Deep Neural Network</i>	2-1
2.1.1.1 <i>Activation Function</i>	2-3
2.1.1.2 <i>Dropout</i>	2-6
2.1.2 <i>Imbalanced Class</i>	2-8
2.1.3 Teknik untuk mengatasi <i>Imbalanced Class</i>	2-8
2.1.3.1 <i>Data Sampling Algorithms</i>	2-9
2.1.3.2 Cost-Sensitive Learning	2-9
2.1.3.3 <i>Probability Tuning</i>	2-12
2.1.4 Mengatasi <i>Missing Value</i> dengan <i>Mean Imputation</i>	2-13
2.1.5 <i>Receiver Operating Characteristic (ROC) Curve</i>	2-13
2.1.6 Learning Curves	2-15
2.1.7 Pustaka Python	2-18
2.1.7.1 Pandas	2-18

2.1.7.2	Seaborn	2-19
2.1.7.3	Numpy	2-19
2.1.7.4	Matplotlib	2-20
2.1.7.5	Scikit-Learn	2-21
2.1.7.6	Keras	2-21
2.1.7.7	<i>Deep Neural Network (DNN) dalam Library Keras</i>	2-23
2.2	Tinjauan Studi	2-24
2.3	Tinjauan Objek	2-26
2.3.1	Stroke	2-27
2.3.2	Dataset	2-27
BAB 3	ANALISIS DAN PERANCANGAN SISTEM	3-1
3.1	Analisis Masalah	3-1
3.2	Kerangka Pemikiran	3-1
3.3	Urutan Proses Global	3-4
3.3.1	Proses <i>Training</i>	3-6
3.3.2	Proses <i>Testing</i>	3-7
3.4	Analisis Manual	3-7
3.4.1	Dataset	3-7
3.4.2	<i>Preprocessing</i>	3-8
3.4.2.1	Menghapus Kolom <i>id</i>	3-9
3.4.2.2	Data <i>Imputation</i>	3-9
3.4.2.3	Data <i>Encoding</i>	3-10
3.4.2.4	<i>Cleaning Outliers</i>	3-11
3.4.3	<i>Split Dataset</i> untuk <i>Training</i> dan <i>Testing</i>	3-14
3.5	Perhitungan <i>Deep Neural Network</i>	3-14
3.6	Perhitungan <i>Deep Neural Network</i> dengan <i>Dropout</i>	3-19
3.7	Perhitungan Cost untuk Cost-Sensitive Learning	3-27
BAB 4	IMPLEMENTASI DAN PENGUJIAN	4-1
4.1	Lingkungan Implementasi	4-1
4.1.1	Spesifikasi Perangkat Keras	4-1
4.1.2	Lingkungan Perangkat Lunak	4-1
4.2	Daftar <i>Class</i> dan <i>Method</i>	4-1
4.2.1	<i>Class DeepNeuralNetwork</i>	4-1
4.2.2	<i>Class DeepNeuralNetworkDropout</i>	4-3
4.2.3	<i>Fungsi sigmoid</i>	4-4
4.2.4	<i>Fungsi sigmoid_derivative</i>	4-4

4.2.5	<i>Fungsi tanh</i>	4-4
4.2.6	<i>Fungsi tanh_derivative</i>	4-5
4.2.7	<i>Fungsi ReLu</i>	4-5
4.2.8	<i>Fungsi ReLu_derivative</i>	4-5
4.3	Implementasi Perangkat Lunak	4-5
4.3.1	<i>Implementasi Preprocessing</i>	4-6
4.3.2	<i>Implementasi Deep Neural Network</i>	4-6
4.3.2.1	<i>Implementasi Training Deep Neural Network</i>	..	4-6
4.3.2.2	<i>Implementasi Testing Deep Neural Network</i>	..	4-6
4.3.3	<i>Implementasi Dropout</i>	4-7
4.3.3.1	<i>Implementasi Training Deep Neural Network</i> dengan <i>Dropout</i>	4-7
4.3.3.2	<i>Implementasi Testing Deep Neural Network</i> dengan <i>Dropout</i>	4-7
4.4	Pengujian	4-8
4.4.1	Skenario Pengujian <i>Deep Neural Network</i>	4-8
4.4.2	Pengujian <i>Deep Neural Network</i>	4-9
4.4.3	Pengujian <i>Deep Neural Network</i> dengan <i>Dropout</i>	4-15
4.4.4	Pengujian Tambahan dengan <i>Feature Selection Information Gain</i>	4-17
4.4.4.1	Pengujian <i>Deep Neural Network</i> dengan <i>Feature Selection Information Gain</i>	4-17
4.4.4.2	Pengujian <i>Deep Neural Network</i> dan <i>Dropout</i> dengan <i>Feature Selection Information Gain</i>	4-20
4.4.5	Pengujian tambahan dengan <i>Hidden Layer</i> yang Lebih Kecil	4-21
4.4.5.1	Pengujian <i>Deep Neural Network</i>	4-21
4.4.5.2	Pengujian <i>Deep Neural Network</i> dan <i>Dropout</i>	4-28
4.4.6	Pengujian <i>Deep Neural Network</i> Tanpa Menggunakan <i>Cost-Sensitive Learning</i> dan <i>Probability Tuning</i>	4-30
4.4.7	Pembahasan Pengujian	4-30

BAB 5 KESIMPULAN DAN SARAN 5-1

5.1	Kesimpulan	5-1
5.2	Saran	5-2

DAFTAR TABEL

2.1	<i>Confusion Matrix</i>	2-10
2.2	<i>Cost Matrix</i>	2-10
2.3	<i>Inisialisasi Cost Matrix</i>	2-10
2.4	<i>Model 1 Cost Matrix</i>	2-11
2.5	<i>Model 2 Cost Matrix</i>	2-11
2.6	Daftar metode yang digunakan dari <i>library</i> Pandas	2-18
2.7	Daftar metode yang digunakan dari <i>library</i> Seaborn	2-19
2.8	Daftar metode yang digunakan dari <i>library</i> Numpy	2-19
2.9	Daftar metode yang digunakan dari <i>library</i> Matplotlib	2-20
2.10	Daftar metode yang digunakan dari <i>library</i> Scikit-Learn	2-21
2.11	Daftar metode yang digunakan dari <i>library</i> Keras	2-21
2.12	Tinjauan Studi	2-24
4.1	Daftar <i>method</i> pada <i>class DeepNeuralNetwork</i>	4-1
4.2	Daftar <i>method</i> pada <i>class DeepNeuralNetworkDropout</i>	4-3
4.3	Penjelasan fungsi <i>sigmoid</i>	4-4
4.4	Penjelasan fungsi <i>sigmoid_derivative</i>	4-4
4.5	Penjelasan fungsi <i>tanh</i>	4-5
4.6	Penjelasan fungsi <i>tanh_derivative</i>	4-5
4.7	Penjelasan fungsi <i>ReLU</i>	4-5
4.8	Penjelasan fungsi <i>ReLU_derivative</i>	4-5
4.9	Kombinasi <i>Deep Neural Network</i>	4-8
4.10	Hasil pengujian <i>Deep Neural Network</i>	4-10
4.11	Hasil pengujian <i>Deep Neural Network</i> dengan <i>Dropout</i>	4-15
4.12	Hasil pengujian <i>Deep Neural Network</i>	4-18
4.13	Hasil pengujian <i>Deep Neural Network</i> dengan <i>information gain</i>	4-20
4.14	Hasil pengujian <i>Deep Neural Network</i> dan <i>Dropout</i> dengan <i>information gain</i>	4-20
4.15	Hasil pengujian <i>Deep Neural Network</i> dan <i>Dropout</i> dengan <i>information gain</i>	4-21
4.16	Pengujian tambahan dengan menggunakan <i>hidden layer</i> yang lebih kecil	4-21
4.17	Hasil pengujian <i>Deep Neural Network</i>	4-24
4.18	Hasil pengujian <i>Deep Neural Network</i> dengan <i>Dropout</i>	4-28

4.19 Hasil pengujian <i>Deep Neural Network</i> Tanpa Menggunakan Cost-Sensitive Learning dan Probability tuning	4-30
4.20 Hasil pengujian <i>Deep Neural Network</i> dengan <i>Dropout</i>	4-31

DAFTAR GAMBAR

2.1	<i>Neural Network</i> [14]	2-1
2.2	Neuron <i>nonlinear</i> [14]	2-2
2.3	Contoh arsitektur keseluruhan DNN yang akan digunakan	2-3
2.4	Fungsi <i>sigmoid</i>	2-4
2.5	Fungsi <i>tanh</i>	2-5
2.6	Fungsi ReLu	2-6
2.7	Dropout [12]	2-7
2.8	Arsitektur <i>Deep Neural Network</i> dengan <i>dropout</i>	2-8
2.9	Contoh ROC curve [14]	2-14
2.10	<i>Learning curves</i> garis lurus yang mengalami <i>underfitting</i>	2-15
2.11	<i>Learning curves</i> garis menurun yang mengalami <i>underfitting</i>	2-16
2.12	<i>Learning curves</i> yang mengalami <i>overfitting</i>	2-17
2.13	<i>Learning curves good fit</i>	2-17
2.14	Dua contoh otak yang mengalami stroke. Gambar A terkena 37,5% dan gambar B terkena 93,4%	2-27
3.1	Kerangka Pemikiran	3-2
3.2	Urutan Proses Global	3-5
3.3	<i>Flowchart</i> proses <i>training</i>	3-6
3.4	<i>Flowchart</i> proses <i>testing</i>	3-7
3.5	Penghapusan kolom menggunakan kode Python	3-9
3.6	Penghapusan kolom <i>id</i>	3-9
3.7	Data <i>imputation</i> menggunakan kode Python	3-10
3.8	Data <i>imputation</i>	3-10
3.9	<i>Encoding</i> menggunakan kode Python	3-11
3.10	<i>Encoding</i> pada fitur <i>gender</i> , <i>ever_married</i> , <i>work_type</i> , <i>residence_type</i> , dan <i>smoking_status</i>	3-11
3.11	<i>Cleaning outliers</i> menggunakan kode Python	3-11
3.12	<i>Boxplot</i> sebelum dilakukan data <i>cleaning</i>	3-12
3.13	<i>Boxplot</i> sesudah dilakukan data <i>cleaning</i>	3-13
3.14	Neuron yang dimatikan pada model DNN dan <i>dropout</i>	3-26
4.1	<i>Flowchart Dropout</i>	4-7
4.2	Arsitektur DNN dengan 5 <i>hidden layer</i>	4-9
4.3	Arsitektur DNN dengan 10 <i>hidden layer</i>	4-9
4.4	Arsitektur DNN dengan 20 <i>hidden layer</i>	4-9

4.5	Perbandingan akurasi berdasarkan jumlah <i>epoch</i> dan <i>learning rate</i>	.4-11
4.6	Perbandingan akurasi berdasarkan jumlah <i>hidden layer</i> dan <i>learning rate</i>	.4-12
4.7	Perbandingan akurasi berdasarkan jumlah <i>activation function</i> dan <i>learning rate</i>	.4-13
4.8	<i>Learning curve</i> model 1	.4-13
4.9	<i>Learning curve</i> model 2	.4-14
4.10	<i>Learning curve</i> model 3	.4-14
4.11	Perbandingan akurasi dan ROC berdasarkan jumlah <i>epoch</i>	.4-15
4.12	Perbandingan akurasi dan ROC berdasarkan jumlah <i>learning rate</i>	.4-16
4.13	Perbandingan akurasi dan ROC berdasarkan jumlah <i>rate</i>	.4-16
4.14	Hasil variabel yang paling berpengaruh dari <i>information gain</i>	.4-17
4.15	Akurasi berdasarkan jumlah <i>learning rate</i> , <i>hidden layer</i> , dan <i>epoch</i>	.4-18
4.16	Perbandingan <i>Learning curve</i> untuk setiap percobaan	.4-19
4.17	Arsitektur DNN dengan 2 <i>hidden layer</i>	.4-22
4.18	Arsitektur DNN dengan 3 <i>hidden layer</i>	.4-23
4.19	Arsitektur DNN dengan 4 <i>hidden layer</i>	.4-23
4.20	Akurasi dan ROC dari pengujian tambahan berdasarkan jumlah <i>epoch</i>	.4-25
4.21	Akurasi dan ROC dari pengujian tambahan berdasarkan jumlah <i>hidden layer</i>	.4-26
4.22	Akurasi dan ROC dari pengujian tambahan berdasarkan jumlah <i>learning rate</i>	.4-26
4.23	Perbandingan <i>Learning curve</i> untuk setiap percobaan	.4-27
4.24	Perbandingan akurasi dan ROC berdasarkan jumlah <i>epoch</i>	.4-29
4.25	Perbandingan akurasi dan ROC berdasarkan jumlah <i>rate</i>	.4-29
4.26	Perbandingan akurasi dan ROC berdasarkan jumlah <i>rate</i>	.4-29

DAFTAR REFERENSI

- [1] Kementerian Kesehatan Republik Indonesia, "Infodatin Pusat Data dan Informasi Kementerian Kesehatan RI Stroke Don't Be The One", Kementerian Kesehatan Republik Indonesia, 2019. [Online]. Available: <https://pusdatin.kemkes.go.id/resources/download/pusdatin/infodatin/infodatin-stroke-dont-be-the-one.pdf>. [Accessed: Oct 9, 2021].
- [2] G. Sailasya and G. L. A. Kumari, "Analyzing the Performance of Stroke Prediction using ML Classification Algorithms," *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 6, pp. 539-545, 2021.
- [3] M. S. Azam, M. Habibullah ,and H. K. Rana, "Performance Analysis of Various Machine Learning Approaches in Stroke Prediction," *International Journal of Computer Applications*, vol. 175, no. 21, pp. 11-15, 2020.
- [4] Maya B. S. and Asha T., "Predictive Model for Brain Stroke in CT using Deep Neural Network", *International Journal of Recent Technology and Engineering (IJRTE)*, vol. 9, no. 1, pp. 2011-2017, 2020.
- [5] C. Y. Hung, W. C. Chen, P. T. Lai, C. H. Lin, and C. C. Lee, "Comparing Deep Neural Network and Other Machine Learning Algorithms for Stroke Prediction in a Large-Scale Population-Based Electronic Medical Claims Database." *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 3110-3113, 2017.
- [6] J. Choi, S. Y. Seo, P. J. Kim, Y. S. Kim, S. H. Lee, J. H. Sohn, D. K. Kim, J. J. Lee and C. Kim, "Prediction of Hemorrhagic Transformation after Ischemic Stroke Using Machine Learning," *Journal of Personalized Medicine*, vol. 11, no. 9, pp. 1-11, 2021.
- [7] N. Someeh, M. A. Jafarabadi, S. M. Shamshirgaran, F. Farzipoor, "The outcome in patients with brain stroke: A deep learning neural network modeling," *Journal of Research in Medical Sciences*, vol. 25, no. 1, pp. 1-7, 2020.
- [8] S. Cheon, J. Kim, and J. Lim, "The Use of Deep Learning to Predict Stroke Patient Mortality," *International Journal of Environmental Research and Public Health*, vol. 16, no. 11, 2019.
- [9] B. Krawczyk and M. Wo'zniak, "Cost-Sensitive Neural Network with ROC-Based Moving Threshold for Imbalanced Classification," pp. 45-52, 2015.
- [10] C. Garbin, X. Zhu, and O. Marques, "Dropout vs. batch normalization: an empirical study of their impact to deep learning," *Multimedia Tools and*

- Applications*, vol. 79, no. 19, pp. 12777-12815, 2020.
- [11] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *Journal of Machine Learning Research*, vol. 15, pp. 1930-1958, 2014.
- [12] J. Grus, *Data Science from Scratch*, O'Reilly Media, Inc, 2015.
- [13] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow 2nd Edition*, O'Reilly Media, Inc, 2019.
- [14] S. Haykin, *Neural Networks and Learning Machines Third Edition*, Pearson, 2009.
- [15] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, H. Arshad, "State-of-the-art in artificial neural network applications: A survey," *Heliyon*, vol. 4, no. 11, 2018.
- [16] B. Krawczyk, "Learning From Imbalanced Data: Open Challenges and Future Directions," *Progress in Artificial Intelligence*, vol. 5, no. 4, pp. 221-232, 2016
- [17] Google Developers, "Imbalanced Data", "Google Developers", 2021. [Online]. Available: <https://developers.google.com/machine-learning/data-prep/construct/sampling-splitting/imbalanced-data>. [Accessed: May 15, 2022]
- [18] A. Fernández, S. García, M. Galar, R. C. Prati, B Krawczyk, and F. Herrera, "Learning from Imbalanced Data Sets," *Springer*, 2014.
- [19] J. Brownlee. "Cost-Sensitive Learning for Imbalanced Classification". *Machine Learning Mastery*. 2020. [Online]. Available: <https://machinelearningmastery.com/cost-sensitive-learning-for-imbalanced-classification/>. [Accessed: Jan 30, 2022].
- [20] K. Munir, H. Elahi, A. Ayub, F. Frezza, A. Rizzi, "Cancer Diagnosis Using Deep Learning: A Bibliographic Review," *Cancers*, vol. 11, no. 9, pp. 1235, 2019.
- [21] Y. Ma, H. He., *Imbalanced Learning: Foundations, Algorithms, and Applications 1st Edition*, Wiley, 2013.
- [22] J. Brownlee. "Tour of Evaluation Metrics for Imbalanced Classification". *Machine Learning Mastery*. 2020. [Online]. Available: <https://machinelearningmastery.com/tour-of-evaluation-metrics-for-imbalanced-classification/>. [Accessed: Jan. 30, 2022].
- [23] S. Dev, H. Wang, C.S. Nwosu, N. Jain, B. Veeravalli, and D. John, "A Predictive Analytics Approach For Stroke Prediction Using Machine Learning and Neural Networks", *Healthcare Analytics*, 2022.
- [24] A. Ashiquzzaman, A. K. Tushar, M. R. Islam, D. S. K. Im, J. H. Park, D. S.

- Lim, and J. Kim, "Reduction of Overfitting in Diabetes Prediction Using Deep Learning Neural Network," *IT Convergence and Security*, pp. 35-43, 2017.
- [25] C. Chugh, "Acute Ischemic Stroke: Management Approach" *Indian Journal of Critical Care Medicine*, vol. 23, pp. S140–S146, 2019.
- [26] B. Norrving, *Stroke and Cerebrovascular Disorders*, Oxford, 2014.
- [27] S. Tiwari, 2019. Cerebral Stroke Prediction-Imbalanced Dataset. [Online]. Available: <https://www.kaggle.com/shashwatwork/cerebral-stroke-predictionimbalanced-dataset> [Accessed: Oct 30, 2021].
- [28] National Heart, Lung, and Blood Institute. "Body Mass Index Table". [Online]. Available at: https://www.nhlbi.nih.gov/health/educational/lose_wt/BMI/bmi_tbl.pdf. [Accessed: Feb. 10, 2022].
- [29] A. E. Kitabchi, G. E. Umpierrez, J. M. Miles, J. N. Fisher, "Hyperglycemic Crises in Adult Patients With Diabetes," *Diabetes Care*, vol. 32 no. 7, pp 1335-1343, 2019.
- [30] P. Chantamit-o-pas and M. Goyal, "Prediction of Stroke Using Deep Learning Model," *International Conference on Neural Information Processing*, pp. 774–781, 2017.
- [31] M. Uzair and N. Jamil, "Effects of Hidden Layers on the Efficiency of Neural Networks," *2020 IEEE 23rd International Multitopic Conference (INMIC)*, pp. 1–6, 2020.