

Penerapan *Backpropagation* Neural Network (BPNN) Untuk Prediksi Kecanduan *Smartphone* Pada Remaja

Mochammad Anshori^{*1}, Ilamsyah², Lutfi Fatmawati³

^{1,2,3}Program Studi Informatika Institut Teknologi Sains dan Kesehatan RS dr. Soepraoen
Kesdam V/BRW Malang Indonesia

E-mail: ^{*1}moanshori@itsk-soepraoen.ac.id, ²haris@itsk-soepraoen.ac.id, ³wtkusuma@itsk-soepraoen.ac.id

Abstrak

COVID-19 yang disebabkan oleh coronavirus disease-2019 telah menyebar dengan cepat dan menyerang secara masif. Sebagai tindakan pencegahan maka dikeluarkan kebijakan lockdown. Kebijakan ini membatasi kegiatan sekolah, perkantoran, pertokoan, melarang bepergian dalam waktu tertentu, saling menjaga jarak dan mengurangi kerumunan di publik. Selama masa lockdown menghasilkan gaya hidup yang baru dimana kegunaan *smartphone* meningkat. Peningkatan ini didasari karena *smartphone* memiliki banyak fungsi seperti informasi, komunikasi, edukasi dan hiburan. Tetapi penggunaan *smartphone* yang berlebihan dapat menimbulkan efek candu khususnya pada remaja. Berlebihan dalam menggunakan *smartphone* membuat anak remaja menjadi insomnia, Tingkah laku pergaulan yang berbeda, kepercayaan diri yang rendah, bahkan kecemasan. Kompleksnya gejala kecemasan pada anak remaja cenderung sulit untuk dipahami, oleh karena itu diusulkan prediksi kecanduan *smartphone* dengan *backpropagation*. Pengujian parameter dilakukan untuk mendapatkan arsitektur jaringan syaraf tiruan yang tepat. Hasil pengujian parameter yang telah dilakukan adalah iterasi = 50, jumlah neuron pada hidden layer = 9 dan nilai learning rate = 0.3. Dengan model tersebut, maka didapatkan akurasi sebesar 99.49%, TPR sebesar 99.5% dan FPR sebesar 0.08%.

Kata Kunci—*Backpropagation*; Jaringan Saraf Tiruan; Kecanduan *Smartphone*; Pembelajaran Mesin; Jaringan Saraf

Abstract

COVID-19 caused by the coronavirus disease-2019 has spread rapidly and attacked massively. As a precaution, a lockdown policy was issued. This policy limits the activities of schools, offices, shops, prohibits traveling at certain times, maintains distance from one another and reduces crowds in the public. During the lockdown period resulted in a new lifestyle where the use of smartphones increased. This increase is based on the fact that smartphones have many functions such as information, communication, education and entertainment. But excessive use of smartphones can cause addictive effects, especially in adolescents. Excessive use of smartphones makes teenagers become insomniac, different social behavior, low self-confidence, and even anxiety. The complexity of anxiety symptoms in adolescents tends to be difficult to understand, therefore a prediction of smartphone addiction with *backpropagation* is proposed. Parameter testing is done to get the right artificial neural network architecture. The results of testing the parameters that have been carried out are iterations = 50, the number of neurons in the hidden layer = 9 and the learning rate = 0.3. With this model, an accuracy of 99.49%, TPR of 99.5% and FPR of 0.08% is obtained.

Keywords—*Backpropagation*, Artificial Neural Network, Smartphone Addiction, Machine Learning, Neural Network

1. PENDAHULUAN

COVID-19 (Coronavirus disease-2019) adalah virus yang pertama kali muncul di Wuhan, China pada Desember 2019 dan menyebar sangat cepat dan masif. Tepatnya pada 11 Maret 2020 dideklarasikan sebagai pandemi global oleh WHO (World Health Organization) [1]. Terhitung hingga bulan Juli 2020 berdasarkan data dari WHO terdapat sekitar 550 juta kasus dan 6 juta kematian yang telah dikonfirmasi [2]. Penyebaran yang banter ini mengakibatkan beberapa daerah menerapkan kebijakan *lockdown*. Kebijakan ini bertujuan sebagai tindakan pencegahan COVID-19 sehingga dapat memutus rantai penyebarannya.

Selama masa *lockdown* mengubah cara kebiasaan hidup kita menjadi hanya tetap didalam rumah [3]. *Lockdown* yang diterapkan dengan membatasi kegiatan sekolah, universitas, toko, sektor privat dan publik, mengontrol perbatasan dan transportasi, melarang perjalanan warga untuk beberapa hari, menjaga jarak dan mengurangi berkerumun di publik [4], [5]. Strategi ini dilakukan dalam mencegah infeksi antar individu selama masa pandemi. Akibat diterapkannya kebijakan *lockdown* memaksa terbiasa dengan kebiasaan hidup yang baru seperti belajar secara daring dan bekerja secara remot dari jarak jauh.

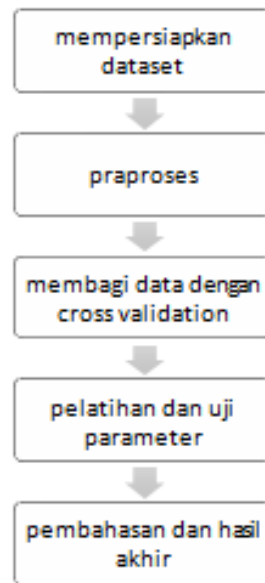
Gaya hidup yang paling signifikan berubah adalah ketergantungan terhadap internet dan perangkat pintar seperti tablet, laptop, dan smartphone / gawai. Smartphone memiliki kegunaan yang mirip dengan komputer tetapi dalam bentuk yang terbatas. Pada saat *lockdown*, smartphone menghadirkan banyak tujuan, fungsi dan kegunaan untuk informasi, komunikasi, edukasi dan hiburan [6]–[9]. Banyaknya fitur yang disediakan oleh smartphone membuat kenyamanan bagi penggunaannya. Tetapi penggunaan smartphone yang tidak tepat berpotensi merugikan seperti kecanduan internet [5] khususnya pada remaja. Selain itu orang tua yang lebih sibuk dengan pekerjaan/kesibukan/pendidikan, sehingga orang tua lebih banyak menghabiskan waktu dengan smartphone [10]. Gaya asuh anak ini yang membuat anak menghabiskan waktunya dan memicu anak menjadi kecanduan smartphone [11]. Hal ini menjadi masalah utama karena anak merasa kesepian [12].

Penelitian menunjukkan bahwa terjadi peningkatan kecanduan terhadap smartphone selama masa COVID19 [13]. Kecanduan terhadap smartphone pada remaja berefek pada mental disorders, apalagi lemahnya regulasi terhadap teknologi yang ada serta mengakibatkan insomnia dan social behaviour yang berbeda [11]. Lebih parahnya lagi kecanduan terhadap smartphone ini menghasilkan kecemasan pada anak. Anak-anak yang sering berinteraksi dengan layar smartphone akan lebih sering memiliki kepercayaan diri yang rendah [14]. Secara medis, kecanduan smartphone memicu computer vision syndrome, sakit di pergelangan tangan [15] dan cyberchondria [16]. Efek-efek ini dapat dikurangi apabila kita dapat memprediksi remaja tersebut telah mengalami kecanduan atau tidak.

Kecanduan smartphone pada kalangan anak-anak itu memberikan efek seperti sakau karena narkoba [12]. kecemasan pada anak cenderung sulit untuk dipahami oleh orang tua. Kompleksitas gejala yang ditunjukkan oleh anak-anak mengakitkannya menjadi susah untuk diamati [7]. Berdasarkan hal tersebut, penelitian ini bertujuan untuk prediksi kecanduan smartphone pada remaja. Pada penelitian ini kami menyajikan model prediksi dengan metode jaringan syaraf tiruan. Penulis akan menggunakan salah satu metode jaringan syaraf tiruan, yaitu backpropagation dalam melakukan prediksi terhadap kecanduan smartphone pada remaja.

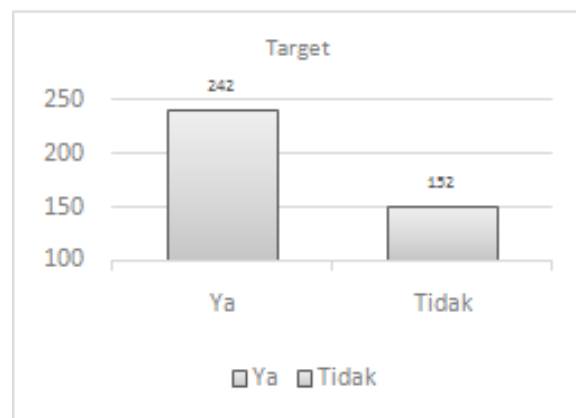
2. METODE PENELITIAN

Berdasarkan Gambar 1 secara umum ada 5 fase metodologi pada penelitian ini. Yang pertama adalah menyiapkan dataset. Kedua melakukan praproses data dari data mentah menjadi data matang yang siap dilakukan pemodelan. Ketiga adalah membagi dataset dengan menggunakan skema *cross validation* dengan $k\text{-fold} = 10$. Ke empat melakukan pelatihan dengan *backpropagation* dan uji parameternya. Terakhir melakukan pembahasan berdasarkan hasil evaluasinya.




Gambar 1. Metodologi Penelitian

Alur kerja pertama adalah akuisisi dataset. Penelitian ini menggunakan data sekunder didapatkan dari Mendeley dataset [17] yang berupa hasil kuesioner. Instrumen dari kuesioner terdiri dari 10 pertanyaan dengan instruksi pengisian yaitu skala 1 = sangat tidak setuju hingga skala 6 = sangat setuju. Dataset memiliki 394 baris data. Secara demografis, perbandingan data dari responden dapat dilihat pada Gambar 2.



Gambar 2. Demografi jenis kelamin dan kelas target

Berdasarkan Gambar 2 diatas, responden dengan kecanduan *smartphone* sebanyak 271, jumlah ini lebih banyak dari pada responden tidak kecanduan dengan jumlah 123. Usia dari responden berada pada rentang 11 hingga 13 tahun. Rata-rata responden yang mengisi kuesioner berusia 13 tahun yang menandakan mereka sedang menginjak masa remaja. Sebanyak 97% dari responden memiliki aplikasi media sosial yang terinstall di *smartphone* yang dimiliki. Penggunaan *smartphone* dalam sehari memiliki rentang antara 1 hingga lebih dari 9 jam dalam sehari. Dalam sehari, mayoritas responden menghabiskan waktu sekitar 7 hingga 9 jam. Sekitar sepertiga hari dari responden bersama dengan genggam *smartphone*. Kelas target pada dataset dalam bentuk biner, yaitu Yes dan No dengan Yes sebanyak 242 responden dan No sebanyak 152. Detil fitur pada dataset ditunjukkan pada Tabel 1.



Gambar 4. Arsitektur jaringan syaraf tiruan

Jenis jaringan syaraf tiruan yang digunakan adalah *backpropagation* karena termasuk kedalam salah satu algoritme yang populer digunakan. Metode ini termasuk kedalam metode *supervised learning* yang dapat digunakan dalam permasalahan klasifikasi [22]. *Backpropagation* memiliki 3 tahap dalam pembelajarannya, yaitu perambatan maju, perambatan mundur dan penyesuaian bobot [23]. Pengujian yang dilakukan terhadap *backpropagation* adalah pengujian parameter. Parameter yang akan diuji yaitu iterasi, *hidden neuron*, dan *learning rate*. Pengujian ini dilakukan karena sangat berpengaruh terhadap performa kinerja dari *classifier*.

Sebagai tolak ukur dalam melakukan perbandingan hasil, peneliti menggunakan acuan performa dari nilai akurasi. Formula dalam menghitung akurasi ditunjukkan pada persamaan (2) dibawah. Selain itu juga menggunakan TPR (*true positive rate*) dan FPR (*false positive rate*) untuk menghasilkan kurva ROC [24] dari model *backpropagation* yang telah dibuat. ROC disini berguna untuk memodelkan kesalahan / eror dari model klasifikasi yang dibangun. Untuk formula akurasi, FPR dan TPR dapat dilihat pada persamaan (3) dan persamaan (4). TP artinya aktual benar dan diprediksi benar, TN adalah aktual benar tapi prediksinya salah, FP adalah aktual salah tapi diprediksi benar dan FN adalah aktual salah dan diprediksi salah [24].

$$\text{akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$\text{TPR} = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

$$\text{FPR} = \frac{FP}{TN+FP} \times 100\% \quad (4)$$

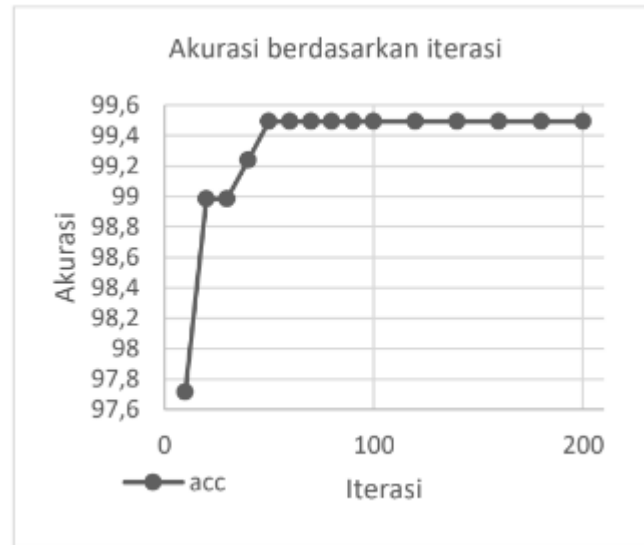
Tahap kelima adalah melakukan pembahasan untuk penarikan kesimpulan berdasarkan hasil pengujian parameter yang telah dilakukan. Tahap ini untuk membuktikan bahwa *backpropagation* dapat digunakan untuk melakukan prediksi dan mengetahui parameter untuk mendapatkan model paling tepat.

3. HASIL DAN PEMBAHASAN

Hasil dari penelitian ini dengan membandingkan nilai akurasi dari setiap pengujian parameter *backpropagation*. Penelitian ini dengan memanfaatkan aplikasi Weka dalam melakukan klasifikasi [25]. Sebelum melakukan klasifikasi, kami hapus salah satu buah fitur yang bernama No dari dataset karena tidak memiliki hubungan dengan fitur yang lainnya. Fungsi aktivasi yang digunakan pada *hidden neuron* adalah *sigmoid* yang ditunjukkan pada persamaan (5). Fungsi *sigmoid* dipilih karena cocok dan mampu dalam mengatasi permasalahan linear ataupun non-linier.

$$\text{sigmoid} = \frac{1}{1+e^{-(x)}} \quad (5)$$

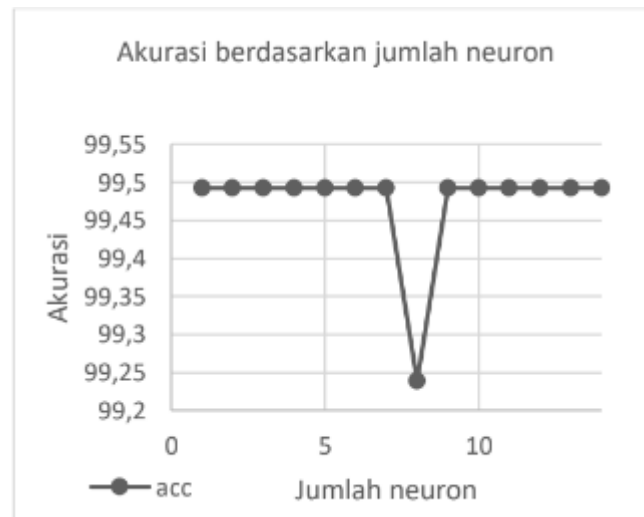
3.1. Pengujian Parameter Iterasi



Gambar 5. Pengujian parameter iterasi

Pengujian parameter iterasi dimulai dari 10 hingga 200 dengan kelipatan 10 di tiap pelatihannya. Hasil dari pengujian didapatkan bahwa akurasi yang optimal diraih saat iterasi bernilai 50 seperti yang ditunjukkan pada Gambar 5. Saat iterasi yang kecil, akurasi yang dihasilkan juga rendah. Seiring bertambahnya jumlah iterasi, akurasi juga semakin meningkat. Hal ini menunjukkan bahwa iterasi memiliki pengaruh terhadap performa dari *backpropagation*. Tetapi iterasi juga berpengaruh terhadap waktu komputasi selama proses pembelajaran.

3.2. Pengujian Parameter Jumlah Neuron

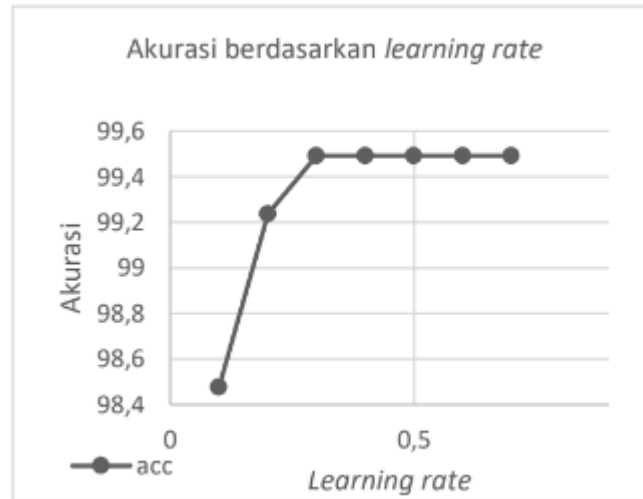


Gambar 6. Pengujian parameter jumlah neuron

Pengujian parameter jumlah neuron dilakukan dari 1 hingga 15. Banyaknya neuron berpengaruh terhadap kompleksitas model *backpropagation*. Semakin banyak neuron, maka semakin kompleks model yang disajikan. Pengujian ini juga berpengaruh terhadap konvergensi pembelajarannya. Dari Gambar 6 dapat diketahui bahwa saat banyaknya neuron yang minim, *classifier* telah dapat menghasilkan akurasi yang tinggi. Akan tetapi saat neuron = 8, terjadi penurunan performa. Inilah yang dimaksud dengan konvergensi dini dari banyaknya jumlah

neuron pada *hidden layer*. Kemudian ditentukan jumlah neuron yang digunakan adalah 9 supaya model cenderung tidak konvergensi dini.


3.3. Pengujian Parameter Learning Rate



Gambar 7. Pengujian parameter *learning rate*

Pengujian parameter *learning rate* yang diujikan memiliki rentang antara 0 hingga 1. Sehingga parameter yang diuji dimulai dari 0.1 hingga 0.9. Hasil pengujian ini menghasilkan nilai *learning rate* = 0.3 yang terbaik. Hal ini berdasarkan pada Gambar 7 dimana saat *learning rate* kecil belum dapat memberikan akurasi yang baik. Tetapi semakin meningkatnya nilai *learning rate* cenderung memberikan peningkatan juga terhadap nilai akurasinya

3.4. Pembahasan




Gambar 8. Arsitektur model *backpropagation*

Gambar 8 menunjukkan arsitektur akhir dari hasil pengujian parameter yang telah dilalui. Parameter dari hasil pengujian bertujuan untuk mendapatkan model *backpropagation* yang paling optimal. Berdasarkan Gambar 8 dapat diketahui bahwa jumlah neuron pada *hidden layer* sebanyak 9 yang berasal dari hasil pengujian parameter. Selain itu parameter optimal lainnya adalah iterasi = 50 dan *learning rate* = 0.3.

Tabel 2. *Confusion matrix*

Aktual	Prediksi	
	Ya	Tidak
Ya	242	0
Tidak	2	150

Dengan menggunakan model arsitektur *backpropagation* dari hasil pengujian, kemudian dilakukan pengenalan pola dengan model baru dan juga menerapkan *cross validation* dengan $k = 10$. Hasil pembelajaran ditunjukkan oleh tabel *confusion matrix*. Tabel 2 adalah tabel yang menunjukkan hasil prediksi dan aktual dari proses klasifikasi. Berdasarkan Tabel 2, angka pada tiap *cell* tersebut dapat digunakan untuk menghitung akurasi, TPR dan FPR. Hasil kalkulasi akurasi = 99.49%, TPR = 99.5% dan FPR = 0.008%. Akurasi yang didapatkan mendekati nilai akurasi maksimalnya, sehingga model yang didapat dapat dikatakan sudah optimal.



Gambar 9. ROC berdasarkan FPR dan TPR

Gambar 9 menunjukkan kurva ROC yang dihasilkan oleh FPR pada sumbu x dapat disebut juga dengan *sensitivity* dan TPR pada sumbu y sebagai *specifity* [26], [27]. Nilai area under ROC adalah 0,9982. Jika nilai kurva berada pada rentang 0.5 hingga 1 menandakan bahwa model prediksinya cenderung optimal. Oleh karena itu dengan *backpropagation*, nilai hasil ROC dapat dikatakan sangat mendekati optimal. Dengan demikian performa dari *classifier* sudah tepat dalam melakukan prediksi kecanduan *smartphone* pada remaja

4. KESIMPULAN DAN SARAN

Mengacu pada hasil dan pembahasan, *backpropagation* sebagai salah satu metode didalam jaringan syaraf tiruan dapat melakukan prediksi kecanduan terhadap *smartphone* pada remaja. Dilakukan pengujian parameter untuk mendapatkan parameter dalam membangun model klasifikasi yang terbaik. Diketahui bahwa parameter pada jaringan syaraf tiruan memiliki pengaruh terhadap performanya dalam melakukan pengenalan pola. Parameter yang diuji adalah iterasi, jumlah *neuron* pada *hidden layer* dan nilai *learning rate*. Model dari pengujian yang telah dilakukan menghasilkan akurasi maksimal yaitu 99.4924% dengan parameter iterasi sebanyak 50, *neuron* pada *hidden layer* berjumlah 9 dan nilai *learning rate* adalah 0.3.

DAFTAR PUSTAKA

- [1] N. Putri Aprilia, D. Pratiwi, and A. Barlianto Ariwibowo, "Sentiment Visualization of Covid-19 Vaccine Based On Naive Bayes Analysis," *J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, pp. 195–208, 2021, doi: 10.25126/jitecs.202162353.
- [2] "Coronavirus disease (COVID-19)." <https://www.who.int/emergencies/diseases/novel-coronavirus-2019> (accessed Jul. 13, 2022).
- [3] Z. A. Ratan, S. Bin Zaman, S. M. S. Islam, and H. Hosseinzadeh, "Smartphone overuse: A hidden crisis in COVID-19," *Heal. Policy Technol.*, vol. 10, no. 1, pp. 21–22, 2021, doi: 10.1016/j.hlpt.2021.01.002.
- [4] H. Saadeh *et al.*, "Smartphone Use Among University Students During COVID-19 Quarantine: An Ethical Trigger," *Front. Public Heal.*, vol. 9, no. July, pp. 1–11, 2021, doi: 10.3389/fpubh.2021.600134.
- [5] J. Zhao, B. Ye, L. Luo, and L. Yu, "The Effect of Parent Phubbing on Chinese Adolescents' Smartphone Addiction During COVID-19 Pandemic: Testing a Moderated Mediation Model," *Psychol. Res. Behav. Manag.*, vol. 15, no. March, pp. 569–579, 2022, doi: 10.2147/PRBM.S349105.
- [6] J. E. Chung *et al.*, "Smartphone addiction risk and daytime sleepiness in Korean adolescents," *J. Paediatr. Child Health*, vol. 54, no. 7, pp. 800–806, 2018, doi: 10.1111/jpc.13901.
- [7] M. Dhamayanti, R. G. Dwiwina, and R. Adawiyah, "Influence of Adolescents' Smartphone Addiction on Mental and Emotional Development in West Java, Indonesia Pengaruh Kecanduan Gawai pada Perkembangan Mental dan Emosional Remaja di Jawa Barat, Indonesia," *J. Med.*, vol. 51, no. 38, 2019.
- [8] C. F. Giraldo-jiménez, J. Gaviria-chavarro, A. Urrutia-valdés, J. F. Bedoya-pérez, and M. O. Sarria-paja, "Machine-Learning Predictive Models For Dependency On Smartphones Based On Risk Factors," 2021.
- [9] J. Park, J. E. Jeong, S. yeon Park, and M. J. Rho, "Development of the Smartphone Addiction Risk Rating Score for a Smartphone Addiction Management Application," *Front. Public Heal.*, vol. 8, no. September, pp. 1–11, 2020, doi: 10.3389/fpubh.2020.00485.
- [10] A. Sedyono and A. Ariwibowo, "Software requirement specification of intelligent system for monitoring and preventing smartphone addiction," *Proceeding 2017 Int. Conf. Smart Cities, Autom. Intell. Comput. Syst. ICON-SONICS 2017*, vol. 2018-Janua, pp. 54–58, 2017, doi: 10.1109/ICON-SONICS.2017.8267821.
- [11] O. Okfalisa, E. Budianita, M. Irfan, H. Rusnedy, and S. Saktioto, "The Classification of Children Gadget Addiction: The Employment of Learning Vector Quantization 3," *IT J. Res. Dev.*, vol. 5, no. 2, pp. 158–170, 2020, doi: 10.25299/itjrd.2021.vol5(2).5681.
- [12] I. D. Amalya, A. Rizqi, and F. A. Fadri, "The Relationship Between Smartphone Addiction and Loneliness Among Students," *Proc. ICECRS*, vol. 8, pp. 4–9, 2020, doi: 10.21070/icecrs2020421.

-
- [13] G. Serra, L. Lo Scalzo, M. Giuffrè, P. Ferrara, and G. Corsello, "Smartphone use and addiction during the coronavirus disease 2019 (COVID-19) pandemic: cohort study on 184 Italian children and adolescents," *Ital. J. Pediatr.*, vol. 47, no. 1, pp. 1–10, 2021, doi: 10.1186/s13052-021-01102-8.
- [14] L. N. Filaili, H. Rosyita, and P. Rahmawati Handayani, "Kecanduan Smartphone Dengan Kepercayaan Diri Pada Remaja Usia 12-15 Tahun Tingkat Sekolah Menengah Pertama Di Kecamatan Kramat Jati, Jakarta Timur," *J. Teknol. Inf.*, vol. 7, no. 2, pp. 116–123, 2021, doi: 10.52643/jti.v7i2.1905.
- [15] W. Lawanont and M. Inoue, "A development of classification model for smartphone addiction recognition system based on smartphone usage data," *Smart Innov. Syst. Technol.*, vol. 73, pp. 3–12, 2018, doi: 10.1007/978-3-319-59424-8_1.
- [16] F. C. Yam, O. Korkmaz, and M. D. Griffiths, "The association between fear of Covid-19 and smartphone addiction among individuals: the mediating and moderating role of cyberchondria severity," *Curr. Psychol.*, vol. 19, no. 0123456789, 2021, doi: 10.1007/s12144-021-02324-z.
- [17] W. Suprianto and D. Wanda, "Datasets for Smartphone Addiction and Cyberbullying Prevalence in Early Adolescents," vol. 3, 2021, doi: 10.17632/M6S3D8KVSM.3.
- [18] V. Gajera, R. Gupta, P. K. Jana, and I. S. Member, "An Effective Multi-Objective Task Scheduling Algorithm using Min-Max Normalization in Cloud Computing," *2016 2nd Int. Conf. Appl. Theor. Comput. Commun. Technol.*, pp. 812–816, 2016, doi: 10.1109/ICATCCT.2016.7912111.
- [19] M. Anshori, F. Mar'i, and F. A. Bachtiar, "Comparison of Machine Learning Methods for Android Malicious Software Classification based on System Call," *Proc. 2019 4th Int. Conf. Sustain. Inf. Eng. Technol. SIET 2019*, pp. 343–348, 2019, doi: 10.1109/SIET48054.2019.8985998.
- [20] Y. Sugianela, Q. L. Sutino, and D. Herumurti, "Eeg Classification for Epilepsy Based on Wavelet Packet Decomposition and Random Forest," *J. Ilmu Komput. dan Inf.*, vol. 11, no. 1, p. 27, 2018, doi: 10.21609/jiki.v11i1.549.
- [21] K. A. Widagdo, K. Adi, and R. Gernowo, "Kombinasi Feature Selection Fisher Score dan Principal Component Analysis (PCA) untuk Klasifikasi Cervix Dysplasia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, p. 565, 2020, doi: 10.25126/jtiik.2020702987.
- [22] K. Amadea, F. A. Bachtiar, and G. Pangestu, "Klasifikasi Pola Pergerakan Bola Mata Menggunakan Metode Multilayer Backpropagation," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, pp. 391–400, 2022, doi: 10.25126/jtiik.202295668.
- [23] C. Dewi, S. Sundari, and M. Mardji, "Texture Feature On Determining Quantity of Soil Organic Matter For Patchouli Plant Using Backpropagation Neural Network," *J. Inf. Technol. Comput. Sci.*, vol. 4, no. 1, pp. 1–14, 2019, doi: 10.25126/jitecs.20194168.
- [24] Z. Huang and D. Chen, "A Breast Cancer Diagnosis Method Based on VIM Feature Selection and Hierarchical Clustering Random Forest Algorithm," *IEEE Access*, vol. 10, pp. 3284–3293, 2022, doi: 10.1109/ACCESS.2021.3139595.

- [25] E. Frank, M. A. Hall, and I. H. Witten, "The WEKA workbench," *Data Min.*, pp. 553–571, 2017, doi: 10.1016/b978-0-12-804291-5.00024-6.
- [26] L. D. S. Rodrigues, E. T. Matsubara, and B. M. Nogueira, "Learning a Fast Bipartite Ranker for Text Documents Using Lexicographical Rankers and ROC Curves," *Proc. Int. Conf. Doc. Anal. Recognition, ICDAR*, vol. 1, pp. 1307–1312, 2018, doi: 10.1109/ICDAR.2017.215.
- [27] A. Swift, R. Heale, and A. Twycross, "What are sensitivity and specificity?," *Evid. Based. Nurs.*, vol. 23, no. 1, pp. 2–5, 2020, doi: 10.1136/ebnurs-2019-103225.