

## KLASIFIKASI PERSEPSI TERHADAP TEKNOLOGI DALAM HUBUNGAN ANTARPERSONAL BERDASARKAN INTERAKSI DIGITAL

Panny Agustia Rahayuningsih<sup>[1]</sup>; Riski Annisa<sup>[2]</sup>; Anna<sup>[3]</sup>; Rizki Syahwal Ludiansyah<sup>[4]</sup>; Rini Afriani<sup>[5]</sup>

Program Studi Informatika, Fakultas Teknik dan Informatika  
Universitas Bina Sarana Informatika  
[panny.par@bsi.ac.id](mailto:panny.par@bsi.ac.id)

### INFO ARTIKEL

**Diajukan :**  
30-10-2025

**Diterima :**  
05-11-2025

**Diterbitkan:**  
01-12-2025

**Kata Kunci :**  
*ensemble learning, hubungan interpersonal, klasifikasi, persepsi teknologi, interaksi digital*

### INTISARI

Revolusi teknologi digital telah mengubah cara manusia menjalin hubungan interpersonal, namun persepsi masyarakat terhadap peran teknologi dalam komunikasi sangat bervariasi. Sebagian memandang teknologi sebagai alat yang memperkuat konektivitas sosial, sementara lainnya menganggapnya sebagai ancaman terhadap keintiman hubungan. Penelitian ini bertujuan mengklasifikasikan persepsi individu terhadap pengaruh teknologi dalam hubungan interpersonal berdasarkan pola interaksi digital menggunakan pendekatan machine learning. Data dikumpulkan melalui survei online terhadap 387 responden usia produktif yang aktif menggunakan media sosial, mencakup 18 variabel yang mengukur karakteristik demografi dan pola interaksi digital. Metode ensemble learning yang mengombinasikan Random Forest, XGBoost, Support Vector Machine, dan Logistic Regression melalui teknik soft voting digunakan untuk mengklasifikasikan persepsi menjadi dua kategori: positif dan non-positif. Data melalui tahap pra-pemrosesan meliputi encoding variabel kategorikal, imputasi missing value dengan median, dan normalisasi menggunakan StandardScaler. Evaluasi model menggunakan stratified 5-fold cross-validation menghasilkan performa yang sangat baik dengan akurasi 82,18%, precision 81,65%, recall 79,13%, F1-score 80,26%, dan ROC-AUC 90,26%. Analisis feature importance mengidentifikasi kepuasan terhadap interaksi digital sebagai prediktor terkuat, diikuti waktu penggunaan media sosial dan perasaan cemas tanpa akses digital. Temuan ini memberikan wawasan objektif tentang faktor-faktor pembentuk persepsi masyarakat dan berkontribusi pada pengembangan program literasi digital yang lebih efektif serta desain platform komunikasi yang mendukung kesejahteraan pengguna.

## I. PENDAHULUAN

Revolusi teknologi informasi dan komunikasi telah mengubah lanskap interaksi manusia secara fundamental. Kemajuan pesat dalam teknologi digital, khususnya smartphone dan platform media sosial, telah menciptakan paradigma baru dalam cara manusia menjalin dan memelihara hubungan interpersonal (Valkenburg & Peter, 2013). Teknologi komunikasi digital memungkinkan individu terhubung secara real-time tanpa dibatasi jarak geografis, memperluas jangkauan jaringan sosial dan memberikan peluang baru untuk membangun hubungan interpersonal (Ellison et al., 2014). Pandemi COVID-19 semakin mempercepat adopsi teknologi komunikasi digital sebagai medium utama interaksi sosial (Nguyen et al., 2020). Namun, di balik kemudahan tersebut, muncul kekhawatiran mengenai kualitas interaksi yang tercipta melalui medium digital. Fenomena

technoference, yaitu gangguan dalam interaksi tatap muka akibat penggunaan perangkat teknologi, menunjukkan bahwa kehadiran smartphone dapat mengurangi kualitas percakapan dan menurunkan tingkat empati antar komunikator (Dwyer et al., 2018; Kushlev et al., 2019). Penggunaan teknologi berlebihan dalam konteks relasional telah dikaitkan dengan penurunan kepuasan hubungan dan berkurangnya kesejahteraan psikologis individu (McDaniel et al., 2018; Sbarra et al., 2019). Berkurangnya isyarat komunikasi nonverbal seperti ekspresi wajah dan intonasi suara dalam komunikasi digital berpotensi menimbulkan miskomunikasi (Fullwood, 2015; Sherman et al., 2013). Persepsi individu terhadap peran teknologi dalam hubungan interpersonal sangat bervariasi dan dipengaruhi oleh pola penggunaan teknologi, karakteristik demografis, dan pengalaman personal (Center, 2021). Sebagian orang memandang teknologi sebagai alat yang

memberdayakan untuk memperkuat konektivitas sosial, sementara yang lain melihatnya sebagai ancaman terhadap keintiman hubungan manusiawi. Persepsi ini tidak hanya mencerminkan sikap individual, tetapi juga mempengaruhi perilaku komunikasi dan kualitas hubungan yang dibangun (Venkatesh et al., 2016).

Meskipun telah banyak penelitian yang mengeksplorasi hubungan antara teknologi dan komunikasi interpersonal, mayoritas studi masih menggunakan pendekatan kualitatif atau kuantitatif konvensional dengan sampel terbatas yang memiliki keterbatasan dalam mengidentifikasi pola kompleks dari data interaksi digital yang bersifat multidimensional (Baym, 2015; Miller et al., 2016). Machine learning, khususnya metode ensemble learning, telah menunjukkan keunggulan dalam tugas klasifikasi dengan tingkat akurasi tinggi pada berbagai domain aplikasi (Zhou et al., 2020). Metode ini menggabungkan prediksi dari beberapa model pembelajaran untuk menghasilkan performa yang lebih baik dibandingkan model individual, dan dapat mengidentifikasi pola kompleks dari data multidimensional yang mencakup berbagai aspek interaksi digital, karakteristik pengguna, dan persepsi terhadap teknologi (Sagi & Rokach, 2018).

Penelitian ini bertujuan untuk mengklasifikasikan persepsi individu terhadap pengaruh teknologi dalam hubungan interpersonal berdasarkan pola interaksi digital mereka menggunakan metode ensemble learning yang menggabungkan Random Forest, XGBoost, Support Vector Machine (SVM), dan Logistic Regression melalui teknik soft voting. Dengan memanfaatkan data kuesioner dari 387 responden yang mencakup 18 variabel dan 1 kelas penggunaan teknologi dan kualitas hubungan interpersonal, penelitian ini berupaya mengidentifikasi pola-pola yang dapat memprediksi persepsi individu secara akurat.

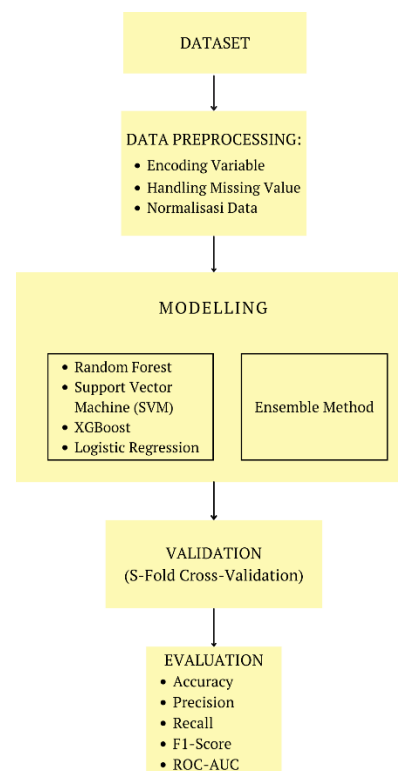
Hasil penelitian ini diharapkan dapat memberikan kontribusi teoretis dalam memahami dinamika komunikasi interpersonal di era digital, serta memberikan implikasi praktis bagi pengembangan strategi komunikasi yang lebih efektif dan program literasi digital yang membantu individu mengelola penggunaan teknologi secara lebih bijaksana untuk meningkatkan kualitas hubungan interpersonal mereka.

## II. BAHAN DAN METODE

### Desain Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksploratif-prediktif yang bertujuan mengklasifikasikan persepsi individu terhadap penggunaan teknologi digital dalam

hubungan interpersonal menggunakan teknik machine learning. Kerangka kerja penelitian mengikuti tahapan algoritma data mining yang sistematis, dimulai dari dataset 387 responden dengan 18 atribut 1 kelas, pra-pemrosesan data, pemodelan menggunakan ensemble learning (Random Forest, XGBoost, SVM, dan Logistic Regression dengan teknik soft voting), validasi stratified 5-fold cross-validation, evaluasi performa model, analisis feature importance, hingga pengujian model final. Seluruh tahapan penelitian digambarkan pada Gambar 1.



Gambar 1. Flowchart Tahapan Algoritma Data Mining

Gambar 1 menunjukkan 11 tahapan penelitian: (1-3) pra-pemrosesan data, (4) pembagian training-testing set, (5-6) training model ensemble dengan soft voting, (7-8) validasi dan evaluasi menggunakan metrik accuracy, precision, recall, F1-Score, dan ROC-AUC, (9) analisis feature importance, (10) pengujian pada testing set, dan (11) model final dengan performa optimal.

### Pengumpulan Data

Penelitian ini menggunakan survei online untuk mengeksplorasi bagaimana orang melihat pengaruh teknologi terhadap hubungan mereka dengan orang lain. Sebanyak 387 orang usia produktif yang aktif menggunakan media sosial dipilih untuk mengisi kuesioner. Mereka dipilih karena kelompok ini paling sering berinteraksi

secara digital, jadi mereka paling merasakan bagaimana cara berkomunikasi berubah karena teknologi.

Kuesioner berisi 18 pertanyaan yang menggali latar belakang responden dan kebiasaan mereka dalam berinteraksi secara digital. Jawaban awalnya dikelompokkan menjadi tiga: Rendah, Sedang, dan Tinggi. Namun untuk memudahkan analisis, kategori ini disederhanakan menjadi dua kelompok saja:

- Kelompok "Positif" (kelas 1) untuk yang berpandangan baik tentang teknologi (kategori Tinggi)
- Kelompok "Non-Positif" (kelas 0) untuk yang netral atau kurang setuju (gabungan kategori Sedang dan Rendah)

Data dari survei kemudian dianalisis menggunakan teknik machine learning untuk menemukan pola dan membuat model prediksi yang bisa mengenali bagaimana sikap seseorang terhadap peran teknologi dalam hubungan personal mereka.

### Pra-pemrosesan Data

Sebelum klasifikasi, data melalui tiga tahap pra-pemrosesan untuk memastikan kualitas dan kompatibilitas dengan algoritma machine learning:

1. Encoding Variabel Kategorikal

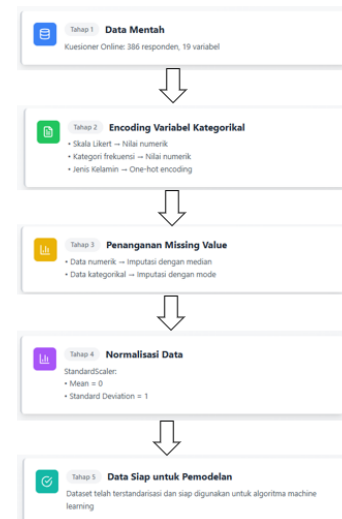
Fitur kategorikal dikonversi menjadi format numerik karena algoritma machine learning memerlukan input numerik. Variabel ordinal seperti skala Likert dikonversi menjadi nilai numerik berurutan, sedangkan variabel nominal seperti jenis kelamin menggunakan one-hot encoding yang mengubah setiap kategori menjadi kolom biner terpisah untuk menghindari asumsi hierarkis antar kategori (Hancock & Khoshgoftaar, 2020).

2. Penanganan Missing Value

Imputasi dilakukan menggunakan nilai median untuk setiap variabel numerik yang mengandung nilai hilang. Median dipilih karena lebih robust terhadap outlier dibandingkan mean dan telah terbukti efektif dalam pemodelan prediktif (Emmanuel et al., 2021; Jadhav et al., 2019).

3. Normalisasi Data

Menggunakan StandardScaler yang melakukan standarisasi dengan mean = 0 dan standard deviation = 1. Normalisasi sangat penting karena algoritma berbasis jarak seperti Support Vector Machine sensitif terhadap perbedaan skala fitur, sehingga tanpa normalisasi dapat menyebabkan bias dalam pembelajaran model (Ahsan et al., 2021; Singh & Singh, 2020).



Gambar 2. Alur Pra-pemrosesan Data

### Metode Klasifikasi

Penelitian ini menggunakan pendekatan ensemble learning untuk mengklasifikasikan persepsi masyarakat terhadap peran teknologi dalam hubungan interpersonal. Metode ensemble dipilih karena mampu menghasilkan prediksi yang lebih akurat dan stabil dengan mengombinasikan kekuatan dari beberapa algoritma berbeda (Dong et al., 2020; Sagi & Rokach, 2018). Empat algoritma yang diintegrasikan melalui teknik soft voting adalah Random Forest, XGBoost, Support Vector Machine (SVM), dan Logistic Regression.

Random Forest menangani kompleksitas data melalui agregasi banyak pohon keputusan yang dibangun secara acak untuk mengurangi overfitting (Belgiu & Drăguț, 2016). XGBoost mengoptimalkan prediksi dengan teknik gradient boosting yang secara iteratif memperbaiki kesalahan model sebelumnya (Chen & Guestrin, 2016). SVM mencari hyperplane optimal yang memaksimalkan margin pemisahan antar kelas untuk klasifikasi biner (Cervantes et al., 2020). Sedangkan Logistic Regression berfungsi sebagai baseline model dengan interpretasi probabilistik yang sederhana (Sperandei, 2014).

Data diklasifikasikan ke dalam dua kategori: persepsi positif dan non-positif. Evaluasi model menggunakan metrik accuracy, precision, recall, F1-score, dan confusion matrix untuk mengukur performa dari berbagai aspek (Grandini et al., 2020). Validasi dilakukan dengan k-fold cross-validation yang membagi data menjadi k bagian untuk memastikan konsistensi dan generalisasi model pada berbagai subset data (Berrar, 2019). Kombinasi ensemble learning ini diharapkan menghasilkan prediksi robust dan memberikan wawasan objektif tentang dampak teknologi terhadap hubungan sosial di era digital.

### Evaluasi Model

Untuk memastikan keandalan hasil klasifikasi persepsi terhadap teknologi dalam hubungan antarpersonal, penelitian ini menggunakan metode dan metrik evaluasi sebagai berikut:

#### 1. Stratified 5-Fold Cross Validation

Teknik validasi yang membagi dataset menjadi lima bagian dengan mempertahankan proporsi kelas seimbang pada setiap fold untuk mengurangi bias estimasi performa (Thabtah et al., 2020; Vabalas et al., 2019).

#### 2. Accuracy (Akurasi)

Mengukur proporsi total prediksi yang benar dari seluruh data, memberikan gambaran umum performa model (Grandini et al., 2020).

#### 3. Precision (Presisi)

Menilai ketepatan model dalam memprediksi kelas positif, penting untuk meminimalkan false positive (Chicco & Jurman, 2020).

#### 4. Recall (Sensitivitas)

Mengukur kemampuan model mendeteksi semua sampel yang sebenarnya positif (Chicco & Jurman, 2020; Saito & Rehmsmeier, 2015).

#### 5. F1-Score

Memberikan keseimbangan harmonik antara precision dan recall, berguna untuk data dengan distribusi kelas tidak seimbang (Grandini et al., 2020).

#### 6. ROC-AUC (Receiver Operating Characteristic - Area Under Curve)

Mengevaluasi kemampuan diskriminasi model pada berbagai threshold keputusan, dengan nilai mendekati 1 menunjukkan performa sangat baik (Hand, 2021).


### III. HASIL DAN PEMBAHASAN

#### Distribusi Kelas Persepsi

Distribusi kelas yang terdiri dari 60% persepsi positif dan 40% persepsi non-positif menunjukkan adanya ketidakseimbangan kelas moderat yang perlu ditangani menggunakan stratified cross-validation untuk menghindari bias model terhadap kelas mayoritas, sebagaimana ditampilkan pada Tabel 1 di bawah ini.

Tabel 1. Distribusi Kelas Target

Kelas	Jumlah Responden	Persentase
Positif	≈ 60%	Mayoritas
Non-Positif	≈ 40%	Minoritas



Gambar 3. Boxplot Perbandingan Persepsi Positif dan Non-Positif

Seperti terlihat pada Gambar 3, dominasi persepsi positif menunjukkan tingginya penerimaan terhadap penggunaan teknologi dalam interaksi sehari-hari. Meskipun demikian, keberadaan 40% responden dengan persepsi non-positif tetap signifikan karena mengindikasikan potensi isu seperti kelelahan digital dan kekhawatiran terhadap ketergantungan teknologi.

#### Evaluasi Performa Model Ensemble


Model ensemble yang mengombinasikan Random Forest, XGBoost, SVM, dan Logistic Regression menunjukkan performa stabil dan konsisten. Evaluasi menggunakan stratified 5-fold cross-validation menghasilkan akurasi rata-rata 82,18% dengan standar deviasi sangat kecil ( $\pm 0,43\%$ ), menunjukkan stabilitas tinggi.

Tabel 2. Hasil Validasi Ensemble dengan 5-Fold Cross-Validation

Metrik	Mean $\pm$ Std Dev	Rentang Performa
<b>Accuracy</b>	82.18% $\pm$ 0.43%	81.75% - 82.61%
<b>Precision</b>	81.65% $\pm$ 4.31%	77.34% - 86.00%
<b>Recall</b>	79.13% $\pm$ 3.56%	75.57% - 82.69%
<b>F1-Score</b>	80.26% $\pm$ 2.49%	77.77% - 82.75%
<b>ROC-AUC</b>	90.26% $\pm$ 2.47%	87.79% - 92.73%

Precision 81,65% menunjukkan akurasi tinggi ketika model memprediksi persepsi positif, sementara recall 79,13% mengindikasikan kemampuan model mendeteksi hampir 80% responden yang benar-benar berpersepsi positif. F1-Score 80,26% mengkonfirmasi keseimbangan baik antara precision dan recall.

Nilai ROC-AUC sebesar 90,26% yang ditampilkan pada Gambar 4 menunjukkan kurva ROC berada jauh di atas garis acuan, menandakan kemampuan model untuk membedakan kedua kelas dengan sangat baik pada berbagai *threshold*, sekaligus mencerminkan stabilitas performa yang didukung oleh rendahnya standar deviasi pada seluruh metrik evaluasi.



Gambar 4. Kurva ROC Model Ensemble

### Analisis Feature Importance

Analisis feature importance mengidentifikasi lima faktor utama yang paling berpengaruh dalam membentuk persepsi individu dapat dilihat pada tabel 3.

Tabel 3. Feature Importance (Top 5 Fitur)

No	Variabel
1	Kepuasan terhadap interaksi digital
2	Waktu penggunaan media sosial per hari
3	Perasaan cemas tanpa akses digital
4	Persepsi bahwa teknologi mempermudah komunikasi
5	Frekuensi memeriksa ponsel tanpa notifikasi

Semakin tinggi tingkat kepuasan terhadap interaksi digital dan waktu penggunaan media sosial, semakin besar peluang seseorang memiliki persepsi positif terhadap teknologi — meskipun berpotensi menimbulkan ketergantungan emosional. Faktor perasaan cemas tanpa akses digital menunjukkan adanya ketergantungan psikologis yang dapat berdampak negatif pada kesejahteraan dan kualitas interaksi tatap muka (Yildirim & Correia, 2015). Responden yang merasa teknologi mempermudah komunikasi cenderung memiliki persepsi positif karena merasakan efisiensi dan aksesibilitas platform digital (Ellison & Boyd, 2013). Sebaliknya, frekuensi memeriksa ponsel tanpa notifikasi mengindikasikan perilaku kompulsif yang dapat mengganggu konsentrasi dan mengurangi kualitas hubungan sosial langsung (Przybylski & Weinstein, 2017). Secara keseluruhan, persepsi terhadap teknologi dibentuk oleh kombinasi pengalaman positif, intensitas penggunaan, dan dampak psikologis yang saling berinteraksi.

### Implikasi Temuan Penelitian

Temuan penelitian ini memiliki implikasi teoretis dan praktis yang signifikan. Secara teoretis, penelitian ini mendemonstrasikan efektivitas ensemble learning dalam mengidentifikasi pola kompleks persepsi dan perilaku digital dengan akurasi di atas 82%, memberikan pendekatan yang lebih objektif dan terukur dibandingkan metode konvensional. Hasil ini mengkonfirmasi bahwa pola persepsi terhadap teknologi dapat diprediksi secara akurat berdasarkan karakteristik penggunaan dan pengalaman digital individu.

Secara praktis, hasil analisis feature importance dapat menjadi dasar pengembangan program literasi digital yang lebih targeted. Dengan mengidentifikasi kepuasan terhadap interaksi digital dan perasaan cemas tanpa akses sebagai faktor kunci, program edukasi dapat difokuskan pada membantu individu membangun hubungan yang lebih sehat dengan teknologi dan menemukan keseimbangan antara konektivitas digital dan interaksi tatap muka. Bagi pengembang platform komunikasi digital, temuan ini memberikan insight untuk memprioritaskan desain produk yang meningkatkan kepuasan pengguna dan mengurangi ketergantungan berlebihan melalui fitur-fitur yang mendorong penggunaan mindful dan memfasilitasi interaksi yang lebih bermakna.

### IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi berbasis ensemble learning untuk memprediksi persepsi individu terhadap peran teknologi dalam hubungan antarpersonal dengan akurasi tinggi. Model yang mengombinasikan Random Forest, XGBoost, SVM, dan Logistic Regression mencapai akurasi 82,18%, precision 81,65%, recall 79,13%, F1-Score 80,26%, dan ROC-AUC 90,26%. Distribusi data menunjukkan 60% responden memiliki persepsi positif dan 40% persepsi non-positif, mencerminkan bahwa meskipun teknologi diterima luas, masih terdapat proporsi signifikan yang mengalami keraguan atau dampak negatif.

Analisis feature importance mengidentifikasi kepuasan terhadap interaksi digital sebagai prediktor terkuat, diikuti waktu penggunaan media sosial, perasaan cemas tanpa akses digital, persepsi kemudahan komunikasi, dan frekuensi memeriksa ponsel kompulsif. Penelitian ini berkontribusi secara metodologis dengan mendemonstrasikan efektivitas ensemble learning dalam menganalisis komunikasi interpersonal di era digital dan memberikan pemahaman substantif tentang faktor pembentuk persepsi masyarakat. Temuan ini memiliki implikasi praktis untuk pengembangan

program literasi digital, desain platform komunikasi yang lebih human-centered, dan strategi intervensi yang membantu individu membangun hubungan lebih sehat dengan teknologi.

## V. UCAPAN TERIMA KASIH

Penelitian ini dapat terlaksana berkat dukungan pendanaan dari Yayasan Universitas Bina Sarana Informatika. Kami menyampaikan rasa terima kasih yang tulus atas kepercayaan dan bantuan yang diberikan. Dukungan ini tidak hanya memfasilitasi kelancaran penelitian, tetapi juga menjadi motivasi untuk terus berkontribusi dalam pengembangan ilmu pengetahuan dan teknologi di lingkungan akademik.

## VI. REFERENSI

- Ahsan, M. M., Mahmud, M. A. P., Saha, P. K., Gupta, K. D., & Siddique, Z. (2021). Effect of data scaling methods on machine learning algorithms and model performance. *Technologies*, 9(3), 52. <https://doi.org/10.3390/technologies9030052>
- Baym, N. K. (2015). *Personal Connections in the Digital Age* (2nd ed.). Polity Press.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Berrar, D. (2019). Cross-validation. In *Encyclopedia of Bioinformatics and Computational Biology* (pp. 542–545). Academic Press. <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>
- Center, P. R. (2021). *Social media use in 2021*. <https://www.pewresearch.org/internet/2021/04/07/social-media-use-in-2021/>
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189–215. <https://doi.org/10.1016/j.neucom.2019.10.118>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21, 6. <https://doi.org/10.1186/s12864-019-6413-7>
- Dong, X., Yu, Z., Cao, W., Shi, Y., & Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14(2), 241–258. <https://doi.org/10.1007/s11704-019-8208-z>
- Dwyer, R. J., Kushlev, K., & Dunn, E. W. (2018). Smartphone use undermines enjoyment of face-to-face social interactions. *Journal of Experimental Social Psychology*, 78, 233–239. <https://doi.org/10.1016/j.jesp.2017.10.007>
- Ellison, N. B., & Boyd, D. M. (2013). Sociality through social network sites. In *The Oxford Handbook of Internet Studies* (pp. 151–172). Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780199589074.013.0008>
- Ellison, N. B., Vitak, J., Gray, R., & Lampe, C. (2014). Cultivating social resources on social network sites. *Journal of Computer-Mediated Communication*, 19(4), 855–870. <https://doi.org/10.1111/jcc4.12078>
- Emmanuel, T., Maupong, T., Mpoeleng, D., Semong, T., Mphago, B., & Tabona, O. (2021). A survey on missing data in machine learning. *Journal of Big Data*, 8(1), 140. <https://doi.org/10.1186/s40537-021-00516-9>
- Fullwood, C. (2015). The role of personality in online self-presentation. In *Cyberpsychology*. Oxford University Press.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: An overview. *ArXiv*.
- Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: An interdisciplinary review. *Journal of Big Data*, 7(1), 94. <https://doi.org/10.1186/s40537-020-00369-8>
- Hand, D. J. (2021). Assessing the performance of classification methods. *International Statistical Review*, 89(1), 1–13. <https://doi.org/10.1111/insr.12419>
- Jadhav, A., Pramod, D., & Ramanathan, K. (2019). Comparison of performance of data imputation methods for numeric dataset. *Applied Artificial Intelligence*, 33(10), 913–933. <https://doi.org/10.1080/08839514.2019.1637138>
- Kushlev, K., Dwyer, R., & Dunn, E. W. (2019). The social price of constant connectivity. *Current Directions in Psychological Science*, 28(4), 347–352.

- <https://doi.org/10.1177/0963721419847200>
- McDaniel, B. T., Galovan, A. M., Cravens, J. D., & Drouin, M. (2018). "Technoference" and implications for mothers' and fathers' couple and coparenting relationship quality. *Computers in Human Behavior, 80*, 303-313. <https://doi.org/10.1016/j.chb.2017.11.019>
- Miller, D., Costa, E., Haynes, N., McDonald, T., Nicolescu, R., Sinanan, J., Spyer, J., Venkatraman, S., & Wang, X. (2016). *How the world changed social media*. UCL Press.
- Nguyen, M. H., Gruber, J., Fuchs, J., Marler, W., Hunsaker, A., & Hargittai, E. (2020). Changes in digital communication during the COVID-19 global pandemic. *Social Media + Society, 6*(3). <https://doi.org/10.1177/2056305120948255>
- Przybylski, A. K., & Weinstein, N. (2017). A large-scale test of the Goldilocks hypothesis. *Psychological Science, 28*(2), 204-215. <https://doi.org/10.1177/0956797616678438>
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8*(4), e1249. <https://doi.org/10.1002/widm.1249>
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS ONE, 10*(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Sbarra, D. A., Briskin, J. L., & Slatcher, R. B. (2019). Smartphones and close relationships: The case for an evolutionary mismatch. *Perspectives on Psychological Science, 14*(4), 596-618. <https://doi.org/10.1177/1745691619826535>
- Sherman, L. E., Michikyan, M., & Greenfield, P. M. (2013). The effects of text, audio, video, and in-person communication on bonding between friends. *Cyberpsychology, 7*(2). <https://doi.org/10.5817/CP2013-2-3>
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing, 97*, 105524. <https://doi.org/10.1016/j.asoc.2020.106524>
- Sperandei, S. (2014). Understanding logistic regression analysis. *Biochimica Medica, 24*(1), 12-18. <https://doi.org/10.11613/BM.2014.003>
- Thabtah, F., Hammoud, S., Kamalov, F., & Gonsalves, A. (2020). Data imbalance in classification: Experimental evaluation. *Information Sciences, 513*, 429-441. <https://doi.org/10.1016/j.ins.2019.11.004>
- Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2019). Machine learning algorithm validation with a limited sample size. *PLoS ONE, 14*(11), e0224365. <https://doi.org/10.1371/journal.pone.0224365>
- Valkenburg, P. M., & Peter, J. (2013). The differential susceptibility to media effects model. *Journal of Communication, 63*(2), 221-243. <https://doi.org/10.1111/jcom.12024>
- Venkatesh, V., Thong, J. Y., & Xu, X. (2016). Unified theory of acceptance and use of technology: A synthesis. *Journal of the Association for Information Systems, 17*(5), 328-376. <https://doi.org/10.17705/1jais.00428>
- Yildirim, C., & Correia, A. P. (2015). Exploring the dimensions of nomophobia. *Computers in Human Behavior, 49*, 130-137. <https://doi.org/10.1016/j.chb.2015.02.059>
- Zhou, Z. H., Wu, J., & Tang, W. (2020). Ensembling neural networks: Many could be better than all. *Artificial Intelligence, 137*(1-2), 239-263. [https://doi.org/10.1016/S0004-3702\(02\)00190-X](https://doi.org/10.1016/S0004-3702(02)00190-X)