LOGIC: Jurnal Penelitian Informatika
Vol. 2, Issue 2, pp. 1–5 (2024)
doi: https://doi.org/10.25124/logic.v2i2

TUTORIAL ARTICLE

Accuracy vs. Precision

Hilal H. Nuha[1,*] and Vidia Ilyana HAM[2]

[1]*Fakultas Informatika, Telkom University, Bandung, Indonesia*
[2]*Ma'had Al Imarat, Bandung, Indonesia*
[*]Corresponding author: hilalnuha@ieee.org

Abstrak

Apa itu *accuracy*? *Accuracy* (Akurasi) adalah metrik evaluasi yang mengukur proporsi total prediksi benar, baik positif maupun negatif, terhadap keseluruhan sampel data yang diuji. Lalu apa itu *precision*? *Precision* (Presisi) adalah metrik evaluasi yang mengukur tingkat kebenaran dari seluruh prediksi yang dikategorikan sebagai kelas positif oleh sistem. Makalah tutorial ini membahas secara komprehensif perbedaan mendasar antara dua metrik evaluasi utama dalam klasifikasi kecerdasan buatan tersebut. Meskipun sering dianggap sama dalam konteks umum, keduanya memiliki batasan implikasi operasional yang sangat berbeda pada pemodelan sains data. Makalah ini menyajikan formulasi matematika dasar, studi literatur yang mengaplikasikan metrik tersebut, serta panduan langkah demi langkah simulasi kalkulasi manual berbasis *Confusion Matrix*. Diharapkan tutorial ini dapat menjadi acuan praktis bagi mahasiswa dan peneliti pemula dalam mengevaluasi model klasifikasi secara tepat.

Kata kunci: *Accuracy, Precision, Confusion Matrix, Classification Metric*

1 Pendahuluan

Apa itu *precision*? *Precision* (Presisi) adalah metrik evaluasi yang mengukur tingkat kebenaran dari seluruh prediksi yang dikategorikan sebagai kelas positif oleh sistem. Lalu apa itu *accuracy*? *Accuracy* (Akurasi) adalah metrik evaluasi yang mengukur proporsi total prediksi benar, baik positif maupun negatif, terhadap keseluruhan sampel data yang diuji.

Dalam bidang sains data, pengolahan citra, dan sistem kecerdasan buatan, evaluasi performa model klasifikasi merupakan tahapan yang sangat penting untuk memastikan sistem yang dibangun benar-benar dapat diandalkan sebelum diterapkan pada kondisi nyata. Tanpa evaluasi yang tepat, sebuah model dapat terlihat baik pada permukaan namun sebenarnya menyimpan kelemahan tersembunyi, misalnya cenderung salah mengenali kelas tertentu meskipun angka keberhasilannya tampak tinggi. Dua metrik yang paling sering digunakan untuk mengukur performa tersebut adalah Presisi (*Precision*) dan Akurasi (*Accuracy*), yang masing-masing menyoroti aspek berbeda dari hasil prediksi model.

Secara konseptual, kedua metrik ini dapat dirangkum sebagai berikut:

- **Precision**: Mengukur tingkat kebenaran dari seluruh prediksi yang dikategorikan sebagai kelas positif oleh sistem.
- **Accuracy**: Mengukur proporsi total prediksi yang benar (positif maupun negatif) terhadap keseluruhan sampel data.

Penentuan metrik yang tepat sangat mempengaruhi keandalan sistem dalam implementasi nyata, terutama pada kasus-kasus yang memiliki konsekuensi berbeda antara kesalahan positif palsu dan negatif palsu. Oleh karena itu, pemahaman yang mendalam mengenai perbedaan mendasar antara Precision dan Accuracy menjadi bekal penting bagi mahasiswa maupun peneliti pemula sebelum melangkah lebih jauh ke tahap pemodelan dan evaluasi sistem klasifikasi.

2 Landasan Teori & Formulasi

2.1 Confusion Matrix

Apa itu *confusion matrix*? *Confusion Matrix* (Matriks Konfusi) adalah sebuah tabel kontingensi yang digunakan untuk merangkum dan mengevaluasi kinerja suatu model klasifikasi dengan cara membandingkan hasil prediksi model terhadap kondisi aktual (*ground truth*) dari setiap sampel data. Dasar kalkulasi kedua metrik ini berasal dari tabel kontingensi 2×2 yang dikenal sebagai *Confusion Matrix* tersebut, seperti ditunjukkan pada Tabel 1. Tabel ini membandingkan hasil prediksi model dengan kondisi aktual (*ground truth*) dari data, sehingga setiap sampel dapat dikelompokkan ke dalam salah satu dari empat kemungkinan hasil. Keempat komponen tersebut adalah *True Positive* (TP) untuk prediksi positif yang benar, *True Negative* (TN) untuk prediksi negatif yang benar, *False Positive* (FP) untuk prediksi positif yang salah, dan *False Negative* (FN) untuk prediksi negatif yang salah. Keempat nilai inilah yang selanjutnya menjadi komponen dasar dalam menghitung Accuracy maupun Precision.

Untuk memahami keempat komponen tersebut secara lebih detail, berikut diuraikan definisi masing-masing beserta

© H.H. Nuha et al. 2024. Published by Telkom University.

Tabel 1: Matriks Konfusi (*Confusion Matrix*) 2x2

	Kenyataan (+)	**Kenyataan (-)**
Prediksi (+)	True Positive (TP)	False Positive (FP)
Prediksi (-)	False Negative (FN)	True Negative (TN)

ilustrasinya menggunakan konteks sistem deteksi *email spam*, di mana kelas "Spam" diperlakukan sebagai kelas positif (+) dan kelas "Normal" diperlakukan sebagai kelas negatif (−).

- **True Positive (TP)**: Terjadi ketika sistem memprediksi suatu sampel sebagai kelas positif, dan prediksi tersebut memang benar sesuai kondisi aktualnya. Ilustrasinya, sebuah email yang sebenarnya memang *spam* dan berhasil diprediksi oleh sistem sebagai *spam* termasuk dalam kategori TP, karena sistem berhasil "menangkap" ancaman yang sesungguhnya.
- **True Negative (TN)**: Terjadi ketika sistem memprediksi suatu sampel sebagai kelas negatif, dan prediksi tersebut juga benar sesuai kondisi aktualnya. Ilustrasinya, sebuah email normal yang memang bukan *spam* dan diprediksi oleh sistem sebagai email normal termasuk dalam kategori TN, sehingga pengguna dapat tetap menerima email tersebut di kotak masuk tanpa gangguan.
- **False Positive (FP)**: Terjadi ketika sistem memprediksi suatu sampel sebagai kelas positif, padahal kondisi aktualnya adalah negatif. Ilustrasinya, sebuah email normal (bukan *spam*) yang keliru diprediksi oleh sistem sebagai *spam* termasuk dalam kategori FP, yang sering disebut sebagai *false alarm* karena email penting berpotensi tidak sampai ke kotak masuk pengguna.
- **False Negative (FN)**: Terjadi ketika sistem memprediksi suatu sampel sebagai kelas negatif, padahal kondisi aktualnya adalah positif. Ilustrasinya, sebuah email yang sebenarnya *spam* namun keliru diprediksi oleh sistem sebagai email normal termasuk dalam kategori FN, sehingga ancaman *spam* tersebut lolos dan tetap masuk ke kotak masuk pengguna.

Keempat kategori inilah yang nantinya akan dihitung ulang secara numerik pada simulasi manual di Bagian 4 menggunakan skenario deteksi *email spam* yang sama, sehingga pembaca dapat melihat secara langsung bagaimana definisi konseptual di atas diterjemahkan ke dalam angka.

2.2 Formulasi Matematika

Setelah keempat komponen *Confusion Matrix* diperoleh, Accuracy dan Precision dapat dihitung secara matematis menggunakan persamaan yang berbeda satu sama lain. Akurasi dihitung dengan membagi seluruh prediksi benar (TP dan TN) terhadap total observasi, disimbolkan pada Persamaan (1), sehingga metrik ini menggambarkan performa model secara menyeluruh tanpa membedakan jenis kesalahan yang terjadi.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

Berbeda dengan Accuracy, Presisi hanya berfokus pada ketepatan hasil prediksi yang dikategorikan positif oleh sistem, tanpa mempertimbangkan kebenaran prediksi negatif. Formulasinya disimbolkan pada Persamaan (2), yaitu jumlah TP dibagi dengan seluruh prediksi positif yang dihasilkan (TP ditambah FP).

$$\text{Precision} = \frac{TP}{TP + FP} \tag{2}$$

Perbedaan penyebut pada kedua persamaan inilah yang menjadi akar mengapa nilai Accuracy dan Precision dapat berbeda cukup signifikan, terutama pada data yang tidak seimbang (*imbalanced dataset*).

3 Kapan Accuracy atau Precision Lebih Penting?

Pemilihan metrik evaluasi yang tepat tidak dapat dilepaskan dari konteks permasalahan dan konsekuensi yang ditimbulkan oleh masing-masing jenis kesalahan prediksi. Pada kasus dengan distribusi kelas yang relatif seimbang dan biaya kesalahan yang setara antara *False Positive* dan *False Negative*, Accuracy sudah cukup representatif untuk menggambarkan performa model secara umum. Namun pada kasus dengan data tidak seimbang atau ketika salah satu jenis kesalahan memiliki dampak yang jauh lebih besar dibandingkan yang lain, Precision (atau metrik lain seperti *Recall*) menjadi jauh lebih relevan dibandingkan Accuracy semata.

3.1 Studi Kasus di Bidang Medis

Dalam sistem diagnosis medis berbasis kecerdasan buatan, misalnya deteksi kanker atau penyakit menular, Accuracy yang tinggi dapat menyesatkan apabila jumlah pasien sehat jauh lebih banyak dibandingkan pasien sakit. Sebagai ilustrasi, jika dari 1000 pasien hanya 20 orang benar-benar mengidap penyakit tertentu, model yang selalu memprediksi "sehat" untuk semua pasien akan tetap memperoleh Accuracy sebesar 98% meskipun gagal total mendeteksi pasien yang sakit. Dalam konteks ini, *False Negative* (pasien sakit yang diprediksi sehat) jauh lebih berbahaya karena dapat menunda penanganan medis dan mengancam nyawa, sehingga metrik seperti *Recall* atau *Sensitivity* biasanya menjadi prioritas utama dibandingkan Accuracy maupun Precision semata. Meski demikian, Precision tetap penting dijaga agar sistem tidak terlalu banyak menghasilkan *False Positive* yang dapat memicu kecemasan pasien serta pemeriksaan lanjutan yang tidak perlu dan membebani biaya layanan kesehatan.

Ilustrasi Perhitungan. Perhatikan dua skenario model pada populasi $N = 1000$ pasien dengan 20 pasien benar-benar sakit dan 980 pasien sehat, sebagaimana dirangkum pada Tabel 2.

Model A merepresentasikan model "malas" yang selalu memprediksi "sehat" untuk seluruh pasien, sehingga:

$$\text{Accuracy}_A = \frac{0 + 980}{1000} = 0.98\,(98\%) \tag{3}$$

Meskipun Accuracy terlihat sangat tinggi, model ini sama

Tabel 2: Perbandingan Dua Skenario Model Diagnosis Medis

Parameter	Model A	Model B
TP	0	15
FN	20	5
FP	0	50
TN	980	930

sekali tidak berguna secara klinis karena seluruh 20 pasien sakit gagal terdeteksi (*Recall* $= 0\%$), sehingga nilai Precision-nya pun tidak dapat didefinisikan $(0/0)$.

Model B merepresentasikan model yang benar-benar berupaya mendeteksi pasien sakit meskipun menghasilkan beberapa *False Positive*:

$$\text{Accuracy}_B = \frac{15 + 930}{1000} = 0.945\ (94.5\%) \tag{4}$$

$$\text{Precision}_B = \frac{15}{15 + 50} = 0.231\ (23.1\%) \tag{5}$$

Meskipun Accuracy Model B sedikit lebih rendah dibandingkan Model A, Model B jauh lebih bermanfaat secara klinis karena berhasil mendeteksi 15 dari 20 pasien sakit (*Recall* $= 75\%$), walaupun Precision-nya rendah akibat banyaknya *False Positive* yang perlu diverifikasi lebih lanjut oleh tenaga medis. Perbandingan ini menegaskan bahwa Accuracy semata tidak cukup untuk menilai kelayakan model diagnosis pada data yang tidak seimbang.

3.2 Studi Kasus di Bidang Cybersecurity

Berbeda dengan kasus medis, pada sistem keamanan siber seperti deteksi *phishing* atau *intrusion detection system* (IDS), Precision yang tinggi umumnya menjadi prioritas utama dibandingkan Accuracy. Hal ini disebabkan karena setiap peringatan (*alert*) yang dihasilkan sistem biasanya akan ditindaklanjuti secara manual oleh tim keamanan, sehingga *False Positive* yang terlalu banyak akan membuang waktu dan sumber daya analis untuk memeriksa ancaman yang sebenarnya tidak nyata. Sebagai contoh, sistem deteksi *phishing* dengan Precision rendah akan sering menandai email normal sebagai berbahaya, sehingga pengguna menjadi terbiasa mengabaikan peringatan (*alert fatigue*) dan pada akhirnya justru mengabaikan ancaman yang benar-benar nyata. Oleh karena itu, meskipun Accuracy tetap diperhatikan sebagai gambaran umum performa sistem, Precision yang tinggi lebih diutamakan agar setiap peringatan yang dikeluarkan benar-benar dapat dipercaya dan efisien untuk ditindaklanjuti oleh tim keamanan.

Ilustrasi Perhitungan. Perhatikan dua skenario sistem deteksi *phishing* pada $N = 1000$ email, di mana 50 email di antaranya benar-benar *phishing* dan 950 email bersifat normal, sebagaimana dirangkum pada Tabel 3.

Sistem C merepresentasikan model dengan ambang deteksi longgar yang menandai banyak email sebagai *phishing*, termasuk banyak email normal:

$$\text{Accuracy}_C = \frac{45 + 895}{1000} = 0.94\ (94\%) \tag{6}$$

$$\text{Precision}_C = \frac{45}{45 + 55} = 0.45\ (45\%) \tag{7}$$

Tabel 3: Perbandingan Dua Skenario Sistem Deteksi Phishing

Parameter	Sistem C	Sistem D
TP	45	40
FN	5	10
FP	55	5
TN	895	945

Meskipun Accuracy Sistem C terlihat tinggi, Precision-nya hanya 45%, yang berarti lebih dari separuh peringatan yang dikeluarkan sistem ternyata salah (*false alarm*). Kondisi ini berpotensi menimbulkan *alert fatigue* pada tim keamanan karena harus memeriksa 100 peringatan padahal hanya 45 di antaranya yang benar-benar ancaman nyata.

Sistem D merepresentasikan model dengan ambang deteksi yang lebih ketat sehingga lebih selektif dalam menandai email sebagai *phishing*:

$$\text{Accuracy}_D = \frac{40 + 945}{1000} = 0.985\ (98.5\%) \tag{8}$$

$$\text{Precision}_D = \frac{40}{40 + 5} = 0.889\ (88.9\%) \tag{9}$$

Sistem D menghasilkan Accuracy sekaligus Precision yang jauh lebih baik dibandingkan Sistem C, dengan hanya 5 *false alarm* dari 45 peringatan yang dikeluarkan, meskipun sedikit lebih banyak email *phishing* yang lolos terdeteksi ($FN = 10$). Perbandingan ini menunjukkan bahwa dalam konteks cybersecurity, Precision yang tinggi lebih diutamakan agar sumber daya tim keamanan dapat difokuskan pada peringatan yang benar-benar valid, meskipun harus mengorbankan sebagian kecil kemampuan deteksi (*Recall*).

4 Referensi Penelitian Terkait

Penerapan metrik evaluasi Accuracy dan Precision secara aktif diimplementasikan oleh berbagai peneliti untuk mengukur performa sistem cerdas pada berbagai domain penelitian, mulai dari klasifikasi teks, citra, hingga data tabular. Penggunaan kedua metrik ini secara bersamaan pada studi-studi tersebut menunjukkan bahwa Accuracy dan Precision saling melengkapi dalam menilai kualitas model secara komprehensif, tidak hanya dari sisi kebenaran keseluruhan tetapi juga ketepatan prediksi kelas positif. Berikut adalah beberapa contoh penelitian yang relevan dengan topik klasifikasi dan evaluasi model:

1. **Shofura et al.** [1] meneliti pengaruh jumlah faktor dan data terhadap performa klasifikasi cuaca bulanan menggunakan *Artificial Neural Network* (ANN), di mana Accuracy dan Precision digunakan untuk membandingkan pengaruh variasi jumlah fitur dan volume data terhadap kualitas klasifikasi.
2. **Azzahra et al.** [2] melakukan klasifikasi komentar *toxic* pada media sosial menggunakan *Support Vector Machine* (SVM) yang dikombinasikan dengan seleksi fitur *Chi-Square*, dengan Precision menjadi indikator penting untuk memastikan komentar yang ditandai sebagai *toxic* benar-benar tepat sasaran.

3. **Hasibuan et al.** [3] mengembangkan algoritma klasifikasi untuk memprediksi tingkat kelulusan mahasiswa pada studi kasus pembelajaran *e-learning*, di mana Accuracy digunakan sebagai indikator utama keandalan model dalam mengidentifikasi kelompok mahasiswa berisiko.
4. **Ridho dan Nuha** [4] menerapkan metode *Extreme Learning Machine* (ELM) untuk mendeteksi situs *phishing*, sebuah studi yang relevan dengan pembahasan kasus cybersecurity pada makalah ini karena Precision yang tinggi menjadi kunci agar sistem tidak salah menandai situs sah sebagai berbahaya.
5. **Khrisna et al.** [5] memanfaatkan *Convolutional Neural Network* (CNN) untuk memprediksi interaksi *RNA-binding protein*, yang menunjukkan bahwa metrik klasifikasi seperti Accuracy dan Precision juga banyak diadopsi pada domain bioinformatika di luar aplikasi teks maupun citra konvensional.
6. **Farhan et al.** [6] mengembangkan metode deteksi kebakaran berbasis video menggunakan kombinasi CNN dan YOLO versi 4, di mana Precision yang tinggi sangat krusial untuk mengurangi kesalahan deteksi (*false alarm*) pada sistem peringatan dini kebakaran.

Keenam studi di atas memperlihatkan bahwa pemilihan dan interpretasi metrik evaluasi, baik Accuracy maupun Precision, senantiasa disesuaikan dengan karakteristik domain permasalahan masing-masing, sejalan dengan pembahasan pada Bagian 3 mengenai kapan salah satu metrik lebih diutamakan dibandingkan yang lain.

5 Simulasi Perhitungan Manual

Untuk memperjelas pemahaman konseptual dan formulasi matematika yang telah dibahas sebelumnya, bagian ini menyajikan simulasi perhitungan manual pada kasus sederhana. Skenario yang digunakan adalah sistem deteksi *email spam* dengan total $N = 10$ sampel data, di mana setiap sampel memiliki label aktual dan hasil prediksi yang telah ditentukan sebelumnya. Rincian hasil klasifikasi terhadap kesepuluh sampel tersebut adalah sebagai berikut:

- Sampel 1–3: Aktual Spam (1), Prediksi Spam (1) $\rightarrow$ $3 \times$ TP
- Sampel 4: Aktual Spam (1), Prediksi Normal (0) $\rightarrow$ $1 \times$ FN
- Sampel 5: Aktual Normal (0), Prediksi Spam (1) $\rightarrow$ $1 \times$ FP
- Sampel 6–10: Aktual Normal (0), Prediksi Normal (0) $\rightarrow$ $5 \times$ TN

Rekapitulasi parameter:

$$\text{TP} = 3, \quad \text{TN} = 5, \quad \text{FP} = 1, \quad \text{FN} = 1$$

5.1 Kalkulasi Accuracy

Berdasarkan rekapitulasi parameter di atas, nilai Accuracy dapat dihitung dengan menjumlahkan seluruh prediksi benar (TP dan TN) kemudian membaginya dengan total seluruh sampel data. Perhitungan tersebut menggunakan Persamaan (1) sebagai berikut:

$$\text{Accuracy} = \frac{3+5}{3+5+1+1} = \frac{8}{10} = 0.8 \text{ (atau } 80\%) \quad (10)$$

Hasil ini menunjukkan bahwa dari sepuluh sampel yang diuji, sistem berhasil mengklasifikasikan delapan sampel dengan benar, baik kategori spam maupun normal, sehingga tingkat akurasi keseluruhan sistem mencapai 80%.

5.2 Kalkulasi Precision

Berbeda dengan Accuracy, perhitungan Precision hanya melibatkan sampel yang diprediksi sebagai kelas positif (spam) oleh sistem, yaitu gabungan dari TP dan FP. Menggunakan Persamaan (2), diperoleh hasil sebagai berikut:

$$\text{Precision} = \frac{3}{3+1} = \frac{3}{4} = 0.75 \text{ (atau } 75\%) \quad (11)$$

Nilai ini menunjukkan bahwa dari empat sampel yang diprediksi sebagai spam oleh sistem, hanya tiga di antaranya yang benar-benar spam, sedangkan satu sampel merupakan *false alarm* (email normal yang salah diklasifikasikan sebagai spam), sehingga tingkat presisi sistem berada pada angka 75%.

6 Kesimpulan

Akurasi memberikan gambaran menyeluruh terhadap kebenaran prediksi sistem, sedangkan Presisi menekankan pada tingkat kepercayaan hasil tebakan positif sistem tanpa banyak memicu sinyal palsu (*False Positive*). Sebagaimana ditunjukkan oleh studi literatur maupun simulasi manual pada makalah ini, kedua metrik dapat menghasilkan nilai yang berbeda pada dataset yang sama, sehingga bergantung hanya pada satu metrik saja berpotensi memberikan gambaran performa model yang kurang tepat. Pemilihan metrik evaluasi harus disesuaikan dengan karakteristik kasus pemodelan data, misalnya pada kasus deteksi spam atau phishing yang sensitif terhadap *false alarm*, Precision sebaiknya menjadi pertimbangan utama, sedangkan pada kasus dengan distribusi kelas yang seimbang, Accuracy dapat menjadi indikator yang cukup representatif. Dengan memahami karakteristik dan batasan masing-masing metrik, mahasiswa dan peneliti pemula diharapkan mampu memilih serta menginterpretasikan hasil evaluasi model klasifikasi secara lebih tepat dan bertanggung jawab.

AI Statement

Penulis menggunakan alat bantu AI untuk membantu penyusunan draf awal dan pemeriksaan tata bahasa pada naskah ini. Alat bantu tersebut juga digunakan untuk merapikan struktur penulisan dan format LaTeX agar sesuai dengan gaya selingkung jurnal. Meskipun demikian, seluruh substansi matematis, hasil kalkulasi, serta referensi yang dikutip telah diuji dan diverifikasi penuh oleh penulis untuk menjamin keakuratannya.

Acknowledgment and Funding

Penelitian dan pembuatan tutorial ini didukung oleh Fakultas Informatika Telkom University dan Ma'had Al Imarat. Penulis mengucapkan terima kasih kepada kedua institusi tersebut atas fasilitas dan dukungan yang diberikan selama proses penyusunan makalah ini. Tidak terdapat sumber pendanaan eksternal khusus yang digunakan dalam penelitian dan penulisan tutorial ini.

CoI Statement

Para penulis menyatakan tidak ada konflik kepentingan dalam penulisan makalah ini. Tidak terdapat hubungan finansial, personal, maupun profesional dengan pihak mana pun yang dapat mempengaruhi objektivitas isi tutorial ini. Seluruh proses penulisan dilakukan secara independen tanpa intervensi dari pihak ketiga.

Ethics Clearance Statement

Penelitian ini tidak menggunakan subjek manusia atau hewan yang membutuhkan izin komite etik khusus. Seluruh data yang digunakan dalam simulasi perhitungan manual pada makalah ini bersifat ilustratif dan dibuat sendiri oleh penulis untuk kebutuhan pembelajaran. Dengan demikian, tidak ada isu privasi maupun keselamatan subjek penelitian yang perlu dipertimbangkan lebih lanjut.

Referensi

[1] S. Shofura, S. Suryani, L. Salma, and S. Harini, "The effect of number of factors and data on monthly weather classification performance using artificial neural networks," *International Journal on Information and Communication Technology (IJoICT)*, vol. 7, no. 2, pp. 23–35, 2021.

[2] N. Azzahra, D. Murdiansyah, and K. Lhaksmana, "Toxic comment classification on social media using support vector machine and chi square feature selection," *International Journal on Information and Communication Technology (IJoICT)*, vol. 7, no. 1, pp. 64–76, 2021.

[3] M. A. Hasibuan, R. Andreswari, M. Lubis, F. Perdana, and H. Fakhrurroja, "Classification algorithm for predicting the graduation level: Case study of e-learning in telkom university," in *Intelligent Sustainable Systems: Selected Papers of WorldS4 2022, Volume 1*, pp. 317–326, Springer, 2023.

[4] M. R. Ridho and H. H. Nuha, "Application of extreme learning machine (elm) classification in detecting phishing sites," in *2022 5th International Conference of Computer and Informatics Engineering (IC2IE)*, pp. 60–64, IEEE, 2022.

[5] A. Khrisna, H. H. Nuha, and S. Andi, "The use of convolutional neural networks for rna protein prediction," in *2023 3rd International Conference on Intelligent Cybernetics Technology Applications (ICICyTA)*, pp. 39–43, 2023.

[6] M. S. Farhan, F. Sthevanie, and K. N. Ramadhani, "Video based fire detection method using cnn and yolo version 4," *Indonesian Journal on Computing (indo-JC)*, vol. 7, no. 2, pp. 65–78, 2022.