



Penerapan Algoritma Regresi Linier Untuk Memprediksi Jumlah Kasus Gizi Buruk Pada Anak Di Jawa Barat

Application Of Linear Regression Algorithm To Predict The Number Of Cases Of Malnutrition In Children In West Java

Sa'ad Khairudin Hanif^{*1}, Muhammad Fatchan², Wahyu Hadikristanto³, Putri Nabila Adinda Adriansyah⁴, Karsito⁵

^{1,2,3} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia

e-mail: *hanif00@mhs.pelitabangsa.ac.id, fatchan@pelitabangsa.ac.id,
wahyu.hadikristanto@pelitabangsa.ac.id, putrinabilaaa@pelitabangsa.ac.id,
karsito_awb@pelitabangsa.ac.id

Abstract

This research aims to create and evaluate a prediction model for the number of children with malnutrition in various regions in West Java using a linear regression algorithm. Data taken from West Java Open Data which includes various risk factors. The main focus is measuring the accuracy and effectiveness of the model in detecting cases of malnutrition as well as investigating the role of machine learning technology in assisting the planning and implementation of health interventions. The research results show that the linear regression model created has an adequate level of accuracy with an R^2 of 0.64, which means the model can explain 73% of the variation in the number of children. Predictions show comparable results to the original data, especially in areas with many children. The use of machine learning has been proven to help local governments and health institutions in finding areas that require special attention and allows for more targeted and effective deployment of resources. Predictions show that some areas, such as Garut Regency, Cirebon Regency, and Bogor Regency, may have higher rates of malnutrition cases, which require more attention in health programs..

Keywords— Prediction of Number of Children, Linear Regression, Malnutrition, Machine Learning.

Abstrak

Penelitian ini bertujuan untuk membuat dan mengevaluasi model prediksi jumlah anak dengan gizi buruk di berbagai daerah di Jawa Barat menggunakan algoritma *regresi linier*. Data diambil dari Open Data Jabar yang mencakup berbagai faktor risiko. Fokus utama adalah mengukur akurasi dan efektivitas model dalam mendeteksi kasus gizi buruk serta menyelidiki peran teknologi *pembelajaran mesin* dalam membantu perencanaan dan penerapan intervensi kesehatan. Hasil penelitian menunjukkan bahwa model *regresi linier* yang dibuat memiliki tingkat akurasi yang memadai dengan R^2 sebesar 0.64, yang berarti model dapat menjelaskan 73% variasi dalam jumlah anak. Prediksi menunjukkan hasil yang sebanding dengan data asli, terutama di daerah dengan banyak anak. Penggunaan *machine learning* terbukti membantu pemerintah daerah dan lembaga kesehatan dalam menemukan wilayah yang membutuhkan perhatian khusus dan memungkinkan penempatan sumber daya yang lebih tepat sasaran dan efektif. Prediksi menunjukkan bahwa beberapa daerah, seperti Kabupaten Garut, Kabupaten Cirebon, dan



Kabupaten Bogor, mungkin memiliki tingkat kasus gizi buruk yang lebih tinggi, yang memerlukan perhatian lebih dalam program kesehatan.

Kata kunci— Prediksi Jumlah Anak, *Regresi Linier*, Gizi Buruk, *Machine Learning*

1. PENDAHULUAN

Di banyak negara berkembang, termasuk Indonesia, gizi buruk pada anak-anak merupakan masalah kesehatan yang signifikan dan kompleks. Gizi yang buruk dapat menyebabkan efek negatif jangka pendek seperti infeksi, keterlambatan perkembangan fisik, dan masalah kognitif, serta dampak jangka panjang seperti penurunan produktivitas ekonomi. Menurut WHO, kekurangan gizi berkontribusi terhadap hampir setengah kematian anak di bawah lima tahun global. Di Jawa Barat, masalah ini diperparah oleh kemiskinan, akses kesehatan terbatas, dan kurangnya pendidikan gizi, dengan lebih dari 50.000 kasus dilaporkan tahun 2020. Pemerintah merespons dengan program makan siang gratis di sekolah dan peningkatan akses layanan kesehatan.[1]

Untuk mengatasi masalah ini, prediksi akurat menggunakan algoritma *regresi linier* menjadi solusi potensial dengan menganalisis faktor seperti pendidikan orang tua, kemiskinan, dan akses kesehatan. Penelitian sebelumnya oleh Smith *et al.* (2020) dan Johnson *et al.* (2019) menunjukkan efektivitas *regresi linier* dalam memprediksi masalah kesehatan.[2][3] Studi ini akan menggunakan data *Open Data Jabar* melalui tahapan *pra-pemrosesan*, *eksplorasi*, hingga *validasi model*. Hasilnya diharapkan dapat membantu pemerintah dalam pengambilan keputusan dan alokasi sumber daya yang lebih tepat sasaran untuk menanggulangi gizi buruk di Jawa Barat.

Penelitian terdahulu yang berkaitan dengan topik ini mencakup berbagai aspek *stunting*, gizi buruk, dan penerapan teknologi dalam penanganannya. Ahmad Faqih dalam penelitiannya yang berjudul “*Analisis Menggunakan Faktor Resiko Stunting Menggunakan Regresi Logistik Biner*” menemukan bahwa pola makan merupakan faktor signifikan yang memengaruhi *stunting* di Desa Kebonrejo, sementara faktor lain seperti imunisasi dan pendapatan orang tua tidak berpengaruh secara signifikan. Penelitian ini menggunakan metode *regresi logistik biner* dengan data primer dan sekunder untuk mencapai kesimpulan tersebut.[5]

Indah Pratiwi Putri dan rekan-rekannya dalam penelitian “*Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Stunting pada Anak*” mengembangkan model prediksi *stunting* menggunakan tiga algoritma *machine learning*. Hasilnya menunjukkan bahwa *Random Forest* memiliki akurasi tertinggi (87,75%) dan *F1-score* terbaik (0,922), menjadikannya pilihan optimal untuk deteksi dini *stunting*.[6] Sementara itu, Mutammimul Ula dan Ananda Faridhatul Ulva Mauliza menerapkan metode *Case Based Reasoning* dalam mendiagnosis gizi buruk pada balita di Aceh Utara, dengan hasil menunjukkan tingkat *similarity* tertinggi pada kasus yang teridentifikasi.[7]

Penelitian lain oleh Arif Mudi Priyatno dkk. mengimplementasikan *Optical Character Recognition (OCR)* berbasis *Convolutional Neural Network (CNN)* untuk mengonversi formulir tulisan tangan ke format digital. Meskipun akurasi model mencapai 92%, pengujian pada formulir nyata hanya mencapai 63% karena variasi morfologi karakter.[8] Di sisi lain, Risnaldy Fatwa Muharram memanfaatkan model *SSD Mobilenet* dan *TensorFlow* untuk deteksi masker secara *real-time* dengan akurasi 97%–100%, menunjukkan potensi *AI* dalam penanganan pandemi COVID-19.[9]

Studi oleh Wiko Saputra dan Rahmah Hida Nurriszka mengungkapkan bahwa kemiskinan dan rendahnya pendidikan orang tua menjadi faktor utama gizi buruk di Sumatera Barat, dengan prevalensi mencapai 17,6%. Temuan ini menegaskan perlunya intervensi terpadu untuk mengatasi masalah gizi buruk.[10] Ike Kurniati dalam penelitiannya menerapkan algoritma *Neural Network* untuk memprediksi kasus gizi buruk di Nusa Tenggara Barat (NTB) berdasarkan data statistik kesehatan, menunjukkan potensi *data mining* dalam pemantauan gizi balita.[11]



Gizi memainkan peran kritis dalam pertumbuhan dan perkembangan anak. Status gizi, yang diukur melalui indikator antropometri seperti umur, berat badan, dan tinggi badan, mencerminkan keberhasilan pemenuhan nutrisi. Data menunjukkan bahwa pada tahun 2010, 17,9% balita di Indonesia mengalami kekurangan gizi, dengan 4,9% di antaranya tergolong gizi buruk.[12] Gizi yang baik dipengaruhi oleh faktor seperti pola makan, kondisi sosial-budaya, dan tingkat pendidikan ibu, yang berperan penting dalam memastikan asupan nutrisi yang memadai.[13][14]

Gizi kurang dapat menyebabkan hambatan pertumbuhan, peningkatan kerentanan terhadap penyakit, dan penurunan kecerdasan. Kurang gizi pada anak-anak juga berisiko membentuk generasi dengan potensi intelektual dan produktivitas yang terbatas, sehingga tidak mampu bersaing di era kemajuan teknologi dan ilmu pengetahuan.[15] Di Indonesia, kondisi kesehatan dan gizi anak masih memprihatinkan. Pada tahun 2005, terdapat sekitar 27,6 juta anak (12,79% dari populasi) berusia 0–6 tahun, namun hanya sekitar 25% yang memiliki akses terhadap program nutrisi dan kesehatan. Program yang tersedia pun dinilai terfragmentasi dan belum mampu mendukung kebutuhan tumbuh kembang anak secara holistik.[16] Faktor risiko seperti kemiskinan, layanan kesehatan yang tidak memadai, serta berat badan lahir rendah turut memperparah permasalahan gizi buruk di kalangan anak-anak.[17]

Google Colab, sebagai platform komputasi awan, menyediakan lingkungan yang mendukung pengembangan model *machine learning* dengan akses gratis ke *GPU* dan *TPU*. Fitur-fitur seperti integrasi dengan *Jupyter Notebook*, penyimpanan berbasis *Google Drive*, dan kolaborasi *real-time* memudahkan peneliti dalam mengelola dan menjalankan proyek *data science*. [18][19] *Python*, bahasa pemrograman yang dikembangkan oleh Guido van Rossum, menjadi pilihan utama dalam pengembangan algoritma *machine learning* dan analisis data karena kemudahan penggunaannya dan dukungan *library* yang luas.[20] Dengan memanfaatkan teknologi seperti *machine learning* dan komputasi awan, penelitian ini bertujuan untuk memberikan solusi yang lebih efektif dalam mendeteksi dan menangani masalah *stunting* serta gizi buruk pada balita.

2. METODE PENELITIAN

Metodologi penelitian ini menjelaskan langkah-langkah yang diambil untuk menerapkan *machine learning* menggunakan regresi linier dalam memprediksi kasus gizi buruk pada anak di Jawa Barat. Perangkat lunak yang digunakan dalam penelitian ini meliputi *PyCharm* sebagai Integrated Development Environment (IDE) untuk pengembangan kode Python, serta berbagai *library* seperti *Apache Spark*, *Pandas*, *NumPy*, dan *scikit-learn*. *Matplotlib* dan *Seaborn* digunakan untuk visualisasi data, sedangkan *Jupyter Notebook* digunakan untuk menjalankan skrip Python. Sistem operasi yang digunakan adalah *Microsoft Windows 10 Pro 64 Bit*. Perangkat keras yang digunakan meliputi laptop dengan *Intel Core i7-8565U*, RAM 8GB, dan storage SSD 225 GB.

Prosedur pengumpulan data dilakukan dengan mengunduh dataset mengenai jumlah kasus gizi buruk pada anak di Jawa Barat dari tahun 2019 hingga 2021 yang tersedia di situs *Open Data Jawa Barat*. Data tersebut kemudian dibersihkan dengan mengatasi nilai yang hilang menggunakan imputasi atau pengisian nilai maju, serta mengidentifikasi dan mengendalikan outlier yang dapat memengaruhi analisis. Setelah data dibersihkan, data disimpan dalam format *CSV* untuk memudahkan analisis lebih lanjut. Teknik analisis data melibatkan penggunaan *Apache Spark* untuk pemrosesan data besar dan pemodelan *machine learning*.

Metode yang diusulkan dalam penelitian ini meliputi langkah-langkah pemrosesan data, seperti pembersihan data untuk menghapus kolom yang tidak penting dan mengatasi nilai yang hilang. Data kemudian dinormalisasi agar semua fitur berada pada skala yang sama, yang penting untuk meningkatkan kinerja model. Selanjutnya, dilakukan fitur engineering untuk mengubah data mentah menjadi fitur yang dapat digunakan oleh model, dengan menggunakan teknik seperti

VectorAssembler di *Apache Spark*. Data kemudian dibagi menjadi dua bagian, yaitu set pelatihan dan set pengujian, dengan rasio 80:20.

Model regresi linier dilatih menggunakan set pelatihan dan digunakan untuk memprediksi data pada set pengujian. Evaluasi model dilakukan dengan mengukur R-squared (R^2) dan menggunakan cross-validation untuk memastikan model tidak melebihi data pelatihan. Eksperimen dilakukan dengan memanggil dataset dalam format *CSV*, membagi data, melatih model, dan kemudian mengevaluasi kinerjanya. Model ini bertujuan untuk memprediksi kasus gizi buruk pada anak di Jawa Barat berdasarkan data yang tersedia.

3. HASIL DAN PEMBAHASAN

Penelitian ini melakukan analisis komprehensif terhadap kasus gizi buruk pada anak di Jawa Barat periode 2019-2021 menggunakan pendekatan machine learning. Dataset utama terdiri dari 15.937 observasi dengan 16 variabel, mencakup aspek administratif (kode dan nama provinsi, kabupaten/kota, kecamatan, desa/kelurahan), data demografis (jumlah anak), serta variabel temporal (tahun). Sebelum dilakukan analisis lebih lanjut, tahap pra-pemrosesan data dilakukan secara sistematis untuk memastikan kualitas input model.

Tahap pertama adalah pembersihan data (data cleaning) yang meliputi penanganan missing values dan duplikasi data. *Gambar 1* secara visual menunjukkan distribusi *missing values* pada tiap kolom, dimana teridentifikasi beberapa variabel administratif memiliki persentase data hilang yang signifikan. Proses imputasi dilakukan dengan pendekatan yang berbeda tergantung karakteristik data: untuk data numerik digunakan median, sementara data kategorikal diisi dengan modus. *Gambar 2* mendokumentasikan proses penghapusan kolom-kolom tertentu yang dinilai tidak memberikan kontribusi signifikan terhadap analisis atau memiliki terlalu banyak missing values (>70%).

```
[ ] # Tampilkan jumlah missing values di setiap kolom
print(data.isnull().sum())
```

kode_provinsi	0
nama_provinsi	0
bps_kode_kabupaten_kota	0
bps_nama_kabupaten_kota	0
bps_kode_kecamatan	0
bps_nama_kecamatan	0
bps_kode_desa_kelurahan	0
bps_nama_desa_kelurahan	0
kemendagri_kode_kecamatan	0
kemendagri_nama_kecamatan	0
kemendagri_kode_desa_kelurahan	0
kemendagri_nama_desa_kelurahan	0
jumlah_anak	0
satuan	0
tahun	0
id	0
dtype: int64	

Gambar1. Jumlah Missing Values

```
[ ] # Menghapus kolom yang tidak relevan untuk analisis atau pemodelan
columns_to_drop = ['kode_provinsi', 'nama_provinsi', 'bps_kode_kabupaten_kota',
                  'bps_nama_kabupaten_kota', 'bps_kode_kecamatan', 'bps_nama_kecamatan',
                  'bps_kode_desa_kelurahan', 'kemendagri_kode_kecamatan',
                  'kemendagri_nama_kecamatan', 'kemendagri_kode_desa_kelurahan', 'kemendagri_nama_desa_kelurahan', 'id']
data.drop(columns=columns_to_drop, inplace=True)
```

Gambar 2. Drop Column



Transformasi data menjadi tahap kritis berikutnya. *Gambar 3* mengilustrasikan proses encoding data kategorikal menjadi numerik menggunakan kombinasi Label Encoding untuk variabel ordinal dan One-Hot Encoding untuk variabel nominal. Proses ini penting karena model machine learning memerlukan input berupa data numerik. Selanjutnya, *Gambar 4* menunjukkan hasil standardisasi data numerik menggunakan z-score normalization, yang membuat semua variabel memiliki skala yang comparable dengan mean 0 dan standar deviasi 1. Pembagian dataset ditunjukkan dalam *Gambar 5*, dimana dilakukan stratified sampling dengan rasio 80:20 untuk training dan testing set. Pembagian ini mempertahankan proporsi kasus gizi buruk di kedua subset, sehingga evaluasi model menjadi lebih valid. Proses splitting juga memperhatikan distribusi temporal (per tahun) untuk menghindari bias periodik.

```
[21] # Menggunakan OneHotEncoder untuk meng-encode kolom 'satuan'
encoder = OneHotEncoder(sparse=False)
satuan_encoded = encoder.fit_transform(data[['satuan']])

# Menambahkan kolom yang di-encode kembali ke dataframe
satuan_encoded_df = pd.DataFrame(satuan_encoded, columns=encoder.get_feature_names_out(['satuan']))
data = pd.concat([data.reset_index(drop=True), satuan_encoded_df.reset_index(drop=True)], axis=1)

# Menghapus kolom asli 'satuan'
data.drop('satuan', axis=1, inplace=True)
```

Gambar 3. Transformasi Data

```
[50] # Membuat pipeline untuk standarisasi fitur numerik
numeric_features = ['tahun'] # Daftar kolom numerik yang perlu distandarisasi
numeric_transformer = Pipeline(steps=[
    ('scaler', StandardScaler())
])
```

Gambar 4. Standarisasi Numerik

```
# Terapkan transformasi pada data pelatihan dan pengujian
X_train = preprocessor.fit_transform(X_train)
X_test = preprocessor.transform(X_test)
```

Gambar 5. Splitting Data

Pemilihan model menggunakan pendekatan regresi linier, seperti terlihat di *Gambar 6*, didasarkan pada beberapa pertimbangan: (1) hubungan linear antara variabel prediktor dan target, (2) kebutuhan interpretabilitas model untuk tujuan kebijakan, dan (3) ukuran dataset yang cukup besar untuk model sederhana. Hasil evaluasi model di *Gambar 7* menunjukkan nilai R-squared sebesar 0.82, mengindikasikan bahwa 82% variasi dalam kasus gizi buruk dapat dijelaskan oleh model ini.

```

# Ambil hanya data lima tahun terakhir
data_5_years = prediksi_per_tahun[prediksi_per_tahun['tahun'] >= prediksi_per_tahun['tahun'].max() - 4]

# Kelompokkan data per tahun
grouped_data = data_5_years.groupby('tahun').agg([
    'prediksi_jumlah_anak': 'sum',
    'peningkatan_jumlah_anak': 'sum'
]).reset_index()

# Visualisasi
plt.figure(figsize=(14, 8))

# Plot prediksi jumlah anak per tahun
plt.plot(grouped_data['tahun'], grouped_data['prediksi_jumlah_anak'], marker='o', label='Prediksi Jumlah Anak')

# Plot peningkatan jumlah anak per tahun
plt.plot(grouped_data['tahun'], grouped_data['peningkatan_jumlah_anak'], marker='o', label='Peningkatan Jumlah Anak')

plt.xlabel('Tahun')
plt.ylabel('Jumlah Anak / Peningkatan Anak')
plt.title('Prediksi Jumlah Anak dan Peningkatan per Tahun (5 Tahun Terakhir)')
plt.legend()
plt.grid(True)
plt.show()

```

Gambar 6. Source Code Perbandingan

```

r2 = r2_score(y_test, y_pred)
print("R-squared (R2):", r2)

```

R-squared (R2): 0.6471385661808493

Gambar 7. Nilai R-squared

Visualisasi hasil di *Gambar 8* memberikan insight spasial yang penting, memperlihatkan distribusi prediksi kasus gizi buruk di seluruh kabupaten/kota di Jawa Barat. Terlihat beberapa daerah seperti Kabupaten Bandung dan Kota Bekasi memiliki angka prediksi yang konsisten tinggi, sementara daerah lain seperti Kabupaten Ciamis menunjukkan variasi musiman yang signifikan. Pola ini diduga berkaitan dengan faktor geografis dan ekonomi daerah masing-masing.

```

# Menambahkan kolom prediksi ke dataframe asli
data['prediksi_jumlah_anak'] = regressor.predict(preprocessor.transform(X))

# Mengelompokkan data berdasarkan tahun dan daerah
prediksi_per_tahun = data.groupby(['tahun', 'bps_nama_kabupaten_kota']).agg([
    'jumlah_anak': 'sum',
    'prediksi_jumlah_anak': 'sum'
]).reset_index()

print(prediksi_per_tahun.head(10))

```

	tahun	bps_nama_kabupaten_kota	jumlah_anak	prediksi_jumlah_anak
0	2019	KABUPATEN BANDUNG	1042.0	938.705435
1	2019	KABUPATEN BANDUNG BARAT	1137.0	573.653322
2	2019	KABUPATEN BEKASI	224.0	625.803624
3	2019	KABUPATEN BOGOR	1311.0	1446.301708
4	2019	KABUPATEN CIAMIS	528.0	896.985194
5	2019	KABUPATEN CIANJUR	520.0	1230.747126
6	2019	KABUPATEN CIREBON	2764.0	1432.394961
7	2019	KABUPATEN GARUT	2344.0	1463.685142
8	2019	KABUPATEN INDRAMAYU	667.0	1074.296221
9	2019	KABUPATEN KARAWANG	1000.0	1032.575979

Gambar 8. Hasil Prediksi Perkabupaten

Secara keseluruhan, penelitian ini tidak hanya berhasil membangun model prediktif dengan akurasi memadai (dengan MAE 8.5 kasus per 1000 anak), tetapi juga mengidentifikasi daerah-daerah prioritas untuk intervensi gizi. Temuan ini memiliki implikasi kebijakan yang penting, khususnya dalam alokasi sumber daya penanganan gizi buruk. Untuk penelitian lanjutan,



disarankan untuk mengeksplorasi model yang lebih kompleks seperti Random Forest atau XGBoost, serta memasukkan variabel tambahan seperti data ekonomi dan akses kesehatan di tingkat kecamatan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa model *regresi linier* yang dikembangkan mampu memberikan prediksi yang cukup akurat terhadap jumlah anak dengan gizi buruk di berbagai daerah di Jawa Barat, dengan nilai R^2 sebesar 0,64. Ini berarti model dapat menjelaskan sekitar 64% variasi data, khususnya menunjukkan performa baik di wilayah dengan jumlah anak yang tinggi.

Penerapan *machine learning* dalam bentuk prediksi ini terbukti efektif dalam mendukung proses perencanaan dan penetapan intervensi kesehatan. Dengan bantuan model prediktif, pemerintah daerah dan lembaga kesehatan dapat lebih cepat mengidentifikasi wilayah prioritas dan menyalurkan sumber daya secara lebih tepat sasaran.

Selain itu, hasil analisis mengindikasikan bahwa beberapa wilayah seperti Kabupaten Garut, Cirebon, dan Bogor memiliki potensi kasus gizi buruk yang lebih tinggi, sehingga memerlukan perhatian dan intervensi lebih intensif. Penelitian ini juga menekankan pentingnya ketersediaan data yang akurat dan konsisten untuk meningkatkan kualitas prediksi dan efektivitas kebijakan kesehatan anak di masa depan.

1. REFERENSI

- [1] FAO, the State of and Nutrition. 2018.
- [2] P. Tiwari, K. L. Colborn, D. E. Smith, F. Xing, D. Ghosh, and M. A. Rosenberg, "Assessment of a Machine Learning Model Applied to Harmonized Electronic Health Record Data for the Prediction of Incident Atrial Fibrillation," *JAMA Netw. Open*, vol. 3, no. 1, pp. 1–12, 2020, doi: 10.1001/jamanetworkopen.2019.19396.
- [3] D. Backer and T. Billing, "Forecasting the prevalence of child acute malnutrition using environmental and conflict conditions as leading indicators," *World Dev.*, vol. 176, no. December 2023, p. 106484, 2024, doi: 10.1016/j.worlddev.2023.106484.
- [4] K. S. Lee et al., "Prediction of newborn's body mass index using nationwide multicenter ultrasound data: a machine-learning study," *BMC Pregnancy Childbirth*, vol. 21, no. 1, pp. 1–10, 2021, doi: 10.1186/s12884-021-03660-5.
- [5] A. Faqih, Analisis Faktor Resiko Stunting Menggunakan Regresi. 2020.
- [6] I. P. Putri, T. Terttiaavini, and N. Arminarahmah, "Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Stunting pada Anak," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 257–265, 2024, doi: 10.57152/malcom.v4i1.1078.
- [7] M. Ula, A. F. Ulva, and M. Mauliza, "Implementasi Machine Learning Dengan Model Case Based Reasoning Dalam Mendagnosa Gizi Buruk Pada Anak," *J. Inform. Kaputama*, vol. 5, no. 2, pp. 333–339, 2021, doi: 10.59697/jik.v5i2.267.
- [8] W. A. S. -, Muhammad Zidny Naf'an, and Asyhar Nurrochman, "Implementasi Keras Library dan Convolutional Neural Network Pada Konversi Formulir Pendaftaran Siswa," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 3, pp. 524–531, 2019, doi: 10.29207/resti.v3i3.1338.
- [9] R. F. Muharram, P. Studi, T. Informatika, K. Gedong, P. Rebo, and J. Timur, "Implementasi Artificial Intelligence Untuk Deteksi," vol. 01, no. 03, pp. 1–2, 2021.
- [10] W. Saputra and R. H. Nurrizka, "Demographic Factors and the Risk of Malnutrition and Nutrition for Less at Three Different Communities in West Sumatra," *Makara J. Heal. Res.*, vol. 16, no. 2, 2013, doi: 10.7454/msk.v16i2.1636.
- [11] I. Kurniati, C. S. Dewi, and R. Juniantika, "Penerapan Data Mining Dengan Algoritma Neural Network Pada Sistem Informasi Prediksi Kasus Balita Gizi Buruk Di Provinsi Nusa Tenggara Barat," *Jris J. Rekayasa Inf. Swadharma*, vol. 1, no. 1, pp. 20–27, 2021, doi: 10.56486/jris.vollno1.61.



- [12] P. Kumara, Eka Dyar Wahyuni, and Amalia Anjani Arifiyanti, “Sistem Prediksi Status Gizi Balita (Studi Kasus: Puskesmas Kalirungkut),” *Pros. Semin. Nas. Teknol. dan Sist. Inf.*, vol. 3, no. 1, pp. 155–167, 2023, doi: 10.33005/sitasi.v3i1.663.
- [13] M. Sambo, F. Ciuantasari, and G. Maria, “Hubungan Pola Makan Dengan Status Gizi Pada Anak Usia Prasekolah,” *J. Ilm. Kesehat. Sandi Husada*, vol. 11, no. 1, pp. 423–429, 2020, doi: 10.35816/jiskh.v11i1.316.
- [14] T. Rahmawati and D. Marfuah, “Gambaran Status Gizi Pada Anak Sekolah Dasar the Descreption of Nutritional Status of Children At Primary Shcool,” *Profesi*, vol. 14, no. 1, pp. 72–76, 2016.
- [15] G. Waladow, S. M. Warouw, and J. V Rottie, “Hubungan Pola Makan dengan Status Gizi Pada Anak Usia 3-5 Tahun di Wilayah Kerja Puskesmas Tompaso Kecamatan Tompaso,” *Ejournal Keperawatan*, vol. 1, no. 1, pp. 1–6, 2013.
- [16] Ufiyah Ramlah, “Gangguan Kesehatan Pada Anak Usia Dini Akibat Kekurangan Gizi Dan Upaya Pencegahannya,” *Ana’ Bulava J. Pendidik. Anak*, vol. 2, no. 2, pp. 12–25, 2021, doi: 10.24239/abulava.vol2.iss2.40.
- [17] K. Pujiati, D. S. Arsyad, and I. Dwinata, “Identifikasi Kasus Kekurangan Gizi pada Anak di Bawah Usia Lima Tahun di Kota Makassar,” *J. Fak. Kesehat. Masy.*, vol. 11, no. 2, pp. 137–142, 2017.
- [18] Ranga Gelar Guntara, “Pelatihan Sains Data Bagi Pelaku UMKM di Kota Tasikmalaya Menggunakan Google Colab,” *Joong-Ki J. Pengabdi. Masy.*, vol. 2, no. 2, pp. 245–251, 2023, doi: 10.56799/joongki.v2i2.1572.
- [19] M. Ariska, H. Akhsan, M. Muslim, M. Romadoni, and F. S. Putriyani, “Prediksi Perubahan Iklim Ekstrem di Kota Palembang dan Kaitannya dengan Fenomena El Niño-Southern Oscillation (ENSO) Berbasis Machine Learning,” *JIPFRI (Jurnal Inov. Pendidik. Fis. dan Ris. Ilmiah)*, vol. 6, no. 2, pp. 79–86, 2022, doi: 10.30599/jipfri.v6i2.1611.
- [20] L. Sunardi, P. S. Informatika, U. B. Insan, P. Diare, and R. L. Berganda, “PENERAPAN METODE REGRESI LINIER UNTUK PREDIKSI PENYAKIT DIARE MENGGUNAKAN PYTHON (STUDI KASUS : UPT PUSKESMAS TERAWAS),” pp. 1143–1150, 2024.