



Evaluasi Performa Perceptron dan Adaline Pada Klasifikasi Angka Partisipasi Sekolah di Indonesia

Nurhafizah Yazid¹, Juni Ismail²

¹Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

²Ilmu Komputer, Universitas Potensi Utama, Medan, Indonesia

E-Mail : ¹nurhafizahyazid6@gmail.com, ²juniismail@gmail.com

Article Info

Article history:

Received Mei 11, 2025

Revised Mei 21, 2025

Accepted Jun 20, 2025

Kata Kunci:

Angka Partisipasi Sekolah

Perceptron

Adaline

Jaringan syaraf tiruan

Klasifikasi Pendidikan

ABSTRAK

Penelitian ini mengevaluasi performa *Perceptron* dan *Adaline* dalam mengklasifikasikan data Angka Partisipasi Sekolah (APS) di Indonesia. Data APS yang digunakan diperoleh dari Badan Pusat Statistik (BPS), mencakup 38 provinsi dan kelompok usia 16–18 tahun selama periode 2021–2024. Setelah melalui proses *normalisasi*, data dilatih menggunakan *Perceptron* yang mengandalkan fungsi aktivasi *biner*, serta *Adaline* yang memanfaatkan fungsi aktivasi *linier* dengan optimasi berbasis *Mean Squared Error* (MSE). Hasil pengujian menunjukkan bahwa *Adaline* mampu mencapai akurasi 86,84% dalam satu *epoch*, sementara *Perceptron* mencapai akurasi 84,21% setelah dua *epoch*. Temuan ini mengindikasikan bahwa *Adaline* lebih efisien dan lebih akurat dalam memproses data APS yang telah dinormalisasi. Penelitian ini memberikan kontribusi dalam pengembangan teknik klasifikasi data pendidikan, yang dapat dimanfaatkan sebagai dasar untuk perumusan kebijakan pendidikan yang lebih tepat sasaran.

ABSTRACT

This study aims to evaluate and compare the performance of the Perceptron and Adaline algorithms in classifying School Participation Rates (Angka Partisipasi Sekolah, APS) in Indonesia. The APS data used in this research were obtained from the Indonesian Central Statistics Agency (BPS), covering 38 provinces and the 16–18 age group for the period 2021–2024. After a normalization process, the data were trained using the Perceptron algorithm, which applies a binary activation function and weight updates based on the delta rule, and the Adaline algorithm, which utilizes a linear activation function optimized using Mean Squared Error (MSE). The experimental results show that Adaline achieved an accuracy of 86.84% within a single epoch, while the Perceptron reached an accuracy of 84.21% after two epochs. These findings indicate that Adaline is more efficient and accurate when processing normalized APS data. The outcomes of this research are expected to contribute to the development of classification techniques for educational data and support the formulation of more targeted education policies.

This is an open access article under the CC BY-NC license.



Corresponding Author:

Nurhafizah Yazid,

Sistem Informasi, STIKOM Tunas Bangsa,

Jl. Jend Sudirman Blok A No. 1,2&3, Kec. Siantar Barat, Pematangsiantar, Sumatera Utara, 21127, Indonesia.

Email: nurhafizahyazid6@gmail.com

1. PENDAHULUAN

Angka Partisipasi Sekolah (APS) merupakan indikator penting untuk mengukur sejauh mana masyarakat memiliki akses terhadap pendidikan formal di Indonesia (Baidawi & Solikhun, 2024). Data dari Badan Pusat Statistik menunjukkan bahwa dalam beberapa tahun terakhir, angka partisipasi ini mengalami

peningkatan di berbagai rentang usia. Hal ini menunjukkan bahwa upaya pemerintah dalam memperluas akses pendidikan mulai membawa hasil (Naila Nur ‘Azizah et al., 2023). Pada tahun 2023, APS untuk kelompok usia 7–12 tahun tercatat sangat tinggi, yakni 99,16%, dan untuk usia 13–15 tahun juga masih cukup tinggi di angka 96,1%. Namun, saat memasuki usia 16–18 tahun, partisipasi menurun menjadi 73,42%, dan anjlok drastis pada kelompok usia 19–23 tahun yang hanya mencapai 28,96% (Kennedy et al., 2019). Penurunan tajam ini mengindikasikan bahwa banyak remaja tidak melanjutkan pendidikan ke jenjang lebih tinggi, yang tentu dapat berdampak negatif terhadap kualitas sumber daya manusia dalam jangka panjang (Sofia, 2017). Oleh karena itu, penting untuk melakukan analisis dan pengelompokan data APS agar pola penyebarannya bisa dipetakan, dan tren ke depan bisa diperkirakan sehingga kebijakan pendidikan bisa disusun dengan lebih tepat dan efektif (Mukhlisa & Kasim, 2021).

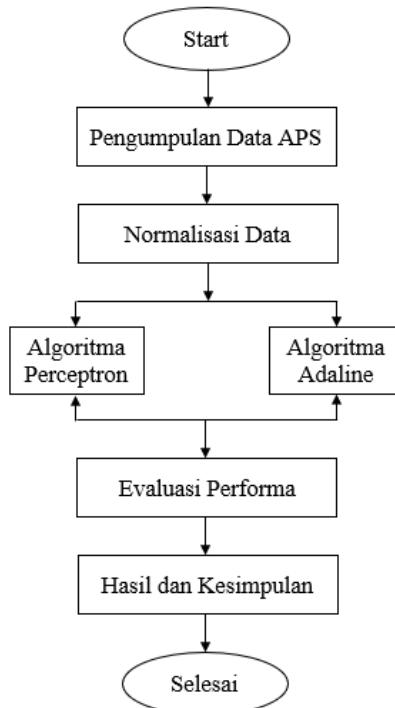
Belakangan ini, metode klasifikasi berbasis *jaringan syaraf tiruan* (*JST*) semakin banyak diterapkan dalam bidang pendidikan (Informatika, 2023). Salah satu metode paling dasar dalam *JST* adalah *Perceptron*, yang umum digunakan untuk membagi data ke dalam dua kelompok jika pola datanya bersifat *linier* (Saraf et al., 2024). Contohnya, model *Autonomous Perceptron* (*APM*) berhasil menunjukkan peningkatan dalam hal *akurasi* dan efisiensi pada berbagai *dataset* (Sagheer et al., 2019). *Adaline* (*Adaptive Linear Neuron*) adalah pengembangan dari *Perceptron* yang menawarkan pendekatan lebih kompleks. Model ini menggunakan aktivasi *linier* dan algoritma pembelajaran *delta rule*, sehingga lebih stabil dan cepat dalam proses pelatihan, khususnya untuk data yang tidak bisa dibedakan secara *linier* dengan mudah (Khotimah & Abdan, 2025). Studi yang membandingkan *Perceptron* dan *Adaline* untuk klasifikasi status gizi balita menemukan bahwa *Adaline* memiliki *akurasi* yang lebih tinggi (Irsyada & Ausytra, 2019). Selain itu, metode *JST* lain seperti *Multilayer Perceptron* (*MLP*) juga telah menunjukkan hasil yang baik dalam pendidikan. Sebagai contoh, algoritma ini digunakan untuk memprediksi kegagalan akademik mahasiswa dan mencapai tingkat *akurasi* hingga 86,9% (Haryawan & Sebatubun, 2020). Sementara itu, *Perceptron* juga diterapkan di SD Negeri 1 Kota Ternate untuk sistem penilaian siswa, dan berhasil mencapai *akurasi* sebesar 95,8% dalam mengklasifikasikan hasil belajar siswa (N. Kapita et al., 2020). Namun, sebagian besar penelitian di atas masih terbatas pada bidang seperti kesehatan, pengolahan gambar digital, atau data numerik sederhana (Budianti & Nurcahyo, 2024). Hingga kini, masih jarang ada penelitian yang secara khusus menilai efektivitas *Perceptron* dan *Adaline* dalam konteks pendidikan di Indonesia, khususnya untuk klasifikasi data APS (Mukhlisa & Kasim, 2021). Kekosongan ini memberikan peluang besar untuk mengeksplorasi kemampuan kedua algoritma tersebut dalam mengelompokkan data APS pendidikan nasional (Farhan et al., 2024).

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja dua algoritma *jaringan syaraf tiruan*, yaitu *Perceptron* dan *Adaline*, dalam mengelompokkan data Angka Partisipasi Sekolah (APS) di tingkat provinsi di Indonesia (Haryawan & Sebatubun, 2020). *Perceptron* bekerja dengan meniru fungsi dasar dari satu neuron, yang menerima *input* berupa angka, menjumlahkannya dengan bobot tertentu, lalu mengolahnya menggunakan fungsi aktivasi *biner* untuk mengkategorikan data ke dalam dua atau lebih kelompok (Taghinezhad & Ghasemzadeh, 2024). Model ini dilatih dengan cara menyesuaikan bobot berdasarkan aturan khusus agar dapat mengenali batas keputusan *linier* dalam data APS (No & Zahrah, 2024). Berbeda dari itu, *Adaline* menggunakan pendekatan yang sedikit lebih canggih. Ia memanfaatkan fungsi aktivasi *linier* dan menyesuaikan bobot menggunakan *delta rule* sebuah metode pembelajaran yang memungkinkan proses pelatihan berjalan lebih stabil, terutama saat menghadapi data yang tidak sepenuhnya bisa dipisahkan secara *linier* (Nasution & Nasution, 2022). Kelebihan utama *Adaline* adalah kemampuannya untuk meminimalkan kesalahan kuadrat saat proses pelatihan, sehingga tingkat kesalahan klasifikasi bisa lebih ditekan dibandingkan dengan *Perceptron*, terutama dalam kondisi data tertentu (Baidawi & Solikhun, 2024). Perbandingan ini diharapkan mampu memberikan gambaran yang lebih jelas dan berdasarkan data mengenai kekuatan serta keterbatasan masing-masing metode jika diterapkan pada data pendidikan (Kamalia & Nawangsih, 2025). Dengan demikian, penelitian ini dapat berkontribusi sebagai panduan dalam memilih metode klasifikasi yang paling tepat untuk data Angka Partisipasi Sekolah (APS), yang pada gilirannya bisa digunakan sebagai dasar dalam mengembangkan sistem pendukung keputusan serta merumuskan kebijakan pendidikan yang lebih efektif di tingkat nasional (Sonata et al., 2023). Lebih jauh lagi, penelitian ini juga berperan penting dalam memperluas pemahaman tentang analisis data pendidikan di Indonesia, khususnya untuk kasus klasifikasi Angka Partisipasi Sekolah (APS). Dengan menguji performa *Perceptron* dan *Adaline*, studi ini menyajikan analisis berbasis data terhadap dua metode *jaringan syaraf tiruan* yang masih jarang diterapkan secara langsung untuk pengelompokan APS (Rifaldi, 2025). Pendekatan ini tidak hanya membuka peluang untuk pemetaan wilayah berdasarkan tingkat partisipasi pendidikan secara lebih presisi, tetapi juga memberikan dasar yang kuat dalam penyusunan kebijakan yang lebih terarah dan relevan (Wijayakusuma & Emik Sapitri, 2020). Selain itu, temuan dari studi ini diharapkan dapat menjadi referensi yang bermanfaat secara praktis bagi para peneliti dan pengambil kebijakan, khususnya dalam memilih pendekatan klasifikasi terbaik untuk data pendidikan yang bersifat numerik dan memiliki kategori yang beragam.

Struktur artikel ini terdiri dari empat bagian utama. Pendahuluan membahas latar belakang, permasalahan, tujuan, dan kontribusi penelitian. Metode Penelitian menjelaskan secara rinci proses *eksperimen* algoritma yang digunakan, serta teknik evaluasi. Hasil dan Pembahasan menyajikan temuan utama dari *eksperimen* dan interpretasi hasil. Terakhir, Kesimpulan menyampaikan ringkasan hasil, implikasi penelitian, serta saran untuk pengembangan riset lanjutan di masa mendatang.

2. METODE PENELITIAN

Data yang digunakan dalam penelitian ini diperoleh dari situs resmi Badan Pusat Statistik (BPS), yang menyediakan *dataset* Angka Partisipasi Sekolah (APS) untuk 38 provinsi di Indonesia selama periode 2021 hingga 2024. *Dataset* tersebut memuat informasi mengenai persentase Angka Partisipasi Sekolah (APS) berdasarkan pada provinsi dan kelompok usia. Penelitian ini dirancang sebagai studi komparatif yang bertujuan untuk membandingkan kinerja dua algoritma *jaringan syaraf tiruan* (*JST*), yaitu *Perceptron* dan *Adaline*, dalam melakukan klasifikasi APS. Perbandingan difokuskan pada perbedaan *akurasi* yang dicapai oleh masing-masing model saat diterapkan pada data Angka Partisipasi Sekolah (APS). Alur penelitian secara keseluruhan disajikan pada Gambar 1, guna memastikan bahwa setiap tahapan proses penelitian dilakukan secara terstruktur dan sistematis.



Gambar 1. Rancangan Penelitian

Penelitian dimulai dengan melakukan pengumpulan data Angka Partisipasi Sekolah (APS) dari portal resmi Badan Pusat Statistik (BPS). Data yang dikumpulkan mencakup persentase partisipasi pendidikan pada jenjang usia 16-18 tahun di seluruh provinsi Indonesia. Selanjutnya, data yang telah diperoleh melalui tahap *normalisasi*, yakni proses pengubahan skala data agar seluruh nilai *input* berada dalam rentang yang seragam, yaitu antara 1 dan -1. *Normalisasi* ini penting untuk memastikan kestabilan dan efisiensi dalam proses pelatihan model algoritma. Setelah *normalisasi*, data diolah melalui dua jalur paralel, yaitu implementasi dengan menggunakan masing rumus (1), (2), (3), dan (4) untuk *Perceptron* dan rumus (5), (6), (7), (8), dan (9) untuk implementasi *Adaline*. Keduanya merupakan jenis *jaringan syaraf tiruan* yang digunakan untuk mengevaluasi performa data Angka Partisipasi Sekolah (APS). *Perceptron* bekerja dengan menggunakan fungsi aktivasi *biner* (*step function*) dan memperbarui bobot hanya ketika terjadi kesalahan klasifikasi, berdasarkan aturan delta sederhana. Sebaliknya, *Adaline* (*Adaptive Linear Neuron*) menggunakan fungsi aktivasi *linier* dan melakukan pembaruan bobot berdasarkan selisih antara *output linier* dengan nilai target, dengan mempertimbangkan kesalahan kuadrat rata-rata (*Mean Squared Error*). *Output* dari kedua model kemudian dievaluasi pada tahap evaluasi performa. Evaluasi dilakukan dengan menggunakan metrik *akurasi* untuk

menilai seberapa tepat masing-masing algoritma dalam melakukan prediksi target terhadap data Angka Partisipasi Sekolah. Akhir dari proses ini adalah tahap hasil dan kesimpulan, di mana hasil perbandingan performa kedua model dianalisis untuk mengetahui algoritma mana yang lebih optimal dalam konteks klasifikasi data Angka Partisipasi Sekolah (APS). Penelitian ditutup dengan tahap selesai, yang menandakan bahwa seluruh proses telah diselesaikan secara komprehensif.

$$y = f(\text{net}) = \begin{cases} 1, & \text{jika } \text{net} > 0 \\ 0, & \text{jika } -0 \leq \text{net} \leq 0 \\ -1, & \text{jika } \text{net} < -0 \end{cases} \quad (1)$$

$$\text{net} = \sum_{i=1}^n x_i w_i + b \quad (2)$$

$$\Delta w_i = \alpha \cdot t \cdot x_i \quad (3)$$

$$w_i^{\text{baru}} = w_i^{\text{lama}} + \Delta w_i \text{ dan } b^{\text{baru}} = b^{\text{lama}} + \alpha(t - y) \quad (4)$$

$$\text{net} = \sum_{i=1}^n x_i w_i + b \quad (5)$$

$$y = f(\text{net}) = \text{net} \quad (6)$$

$$E = (t - y)^2 = \sum_{i=1}^n x_i w_i - b \quad (7)$$

$$\Delta w_i = \alpha(t - y)x_i \quad (8)$$

$$w_i^{\text{baru}} = w_i^{\text{lama}} + \Delta w_i \text{ dan } b^{\text{baru}} = b^{\text{lama}} + \alpha(t - y) \quad (9)$$

Keterangan notasi:

- x_i = *input* ke-i
- w_i = bobot (weight) ke-i yang diberikan pada *input*
- b = bias yang digunakan untuk menggeser fungsi aktivasi
- net = total aktivasi
- y = *output* atau prediksi yang dihasilkan oleh model
- t = nilai target yang digunakan sebagai acuan dalam proses pembelajaran kedua algoritma
- Δw_i = perubahan bobot ke-i
- α = laju pembelajaran (*learning rate*)
- θ = ambang batas (*threshold*)
- E = adalah fungsi error (*Mean Squared Error*)

Pada tahap ini, data diklasifikasikan menggunakan *Perceptron* dan *Adaline*. Analisis dilakukan untuk melihat sejauh mana kedua algoritma mampu mengenali pola dalam data Angka Partisipasi Sekolah. Tahap akhir adalah evaluasi kinerja, yang dilakukan dengan menggunakan metrik *akurasi* guna menilai kemampuan model dalam memprediksi kategori Angka Partisipasi Sekolah (APS) secara tepat.

3. HASIL DAN PEMBAHASAN

Penelitian ini diawali dengan mengumpulkan data Angka Partisipasi Sekolah (APS) dari situs resmi Badan Pusat Statistik (BPS). Pemilihan data dari BPS dilakukan karena sumber ini bersifat resmi dan telah melalui proses verifikasi, sehingga dinilai kredibel dan layak dijadikan dasar dalam analisis. Fokus utama penelitian adalah kelompok usia 16–18 tahun, yang mencerminkan tingkat partisipasi pendidikan pada jenjang menengah atas. Data Angka Partisipasi Sekolah (APS) dikumpulkan dari 38 provinsi di Indonesia, mencakup periode waktu antara tahun 2021 hingga 2024. Seluruh data diakses melalui publikasi dan portal daring milik BPS, kemudian diproses dan disusun ulang agar sesuai dengan format yang dibutuhkan untuk pelatihan model. Tahap awal ini merupakan langkah penting yang membentuk dasar sebelum dilakukan *normalisasi* data dan proses pelatihan algoritma. Setelah data siap, dua algoritma *jaringan syaraf tiruan Perceptron* dan *Adaline* digunakan untuk melakukan klasifikasi terhadap data yang telah dipersiapkan. Rangkuman dari data Angka Partisipasi Sekolah (APS) yang digunakan dalam *eksperimen* ini ditampilkan dalam tabel pada bagian berikutnya.

Tabel 1. Data APS

Provinsi	2021	2022	2023	2024
Aceh	83,28	83,1	83,41	81,55
Sumatera Utara	78,66	78,66	79,25	78,59
Sumatera Barat	84,07	83,71	84,33	84,4
Riau	77,81	77,32	78,15	78,49
Jambi	72,5	72,53	72,46	71,97
Sumatera Selatan	71,53	70,93	71,71	70,8
Bengkulu	79,75	79,31	79,57	79,07
Lampung	71,72	71,14	71,74	72,35
Kep. Bangka Belitung	68,15	68,42	69,53	72,69
Kep. Riau	84,4	84,54	84,97	85,56
Dki Jakarta	72,32	72,1	72,5	79,95
Jawa Barat	67,8	68,66	68,58	71,15
Jawa Tengah	70,79	70,82	70,87	71,6
Di Yogyakarta	89,63	89,95	91,17	90,36
Jawa Timur	74,14	73,4	74,07	76,44
Banten	68,94	69,22	69,64	71,91
Bali	83,96	83,84	84,73	85,17
Nusa Tenggara Barat	77,49	77,43	77,46	77,81
Nusa Tenggara Timur	75,77	75,55	75,93	75,75
Kalimantan Barat	69,38	68,72	69,25	69,39
Kalimantan Tengah	66,7	66,32	66,32	68,33
Kalimantan Selatan	69,31	69,88	69,95	72,31
Kalimantan Timur	82,01	81,43	81,5	81,84
Kalimantan Utara	76,5	76,5	77,03	78,89
Sulawesi Utara	73,86	74,33	74,55	72,48
Sulawesi Tengah	76,32	75,84	76,29	74,16
Sulawesi Selatan	71,21	70,81	71	73,17
Sulawesi Tenggara	75,02	74,53	74,6	75,73
Gorontalo	71,3	71,68	71,7	72,7
Sulawesi Barat	71,22	70,85	71,57	72,09
Maluku	79,68	79,03	79,9	77,7
Maluku Utara	77,01	77,7	78,38	76,02
Papua Barat	81,21	80,56	80,58	75,32
Papua Barat Daya	0	0	0	81,14
Papua	63,98	65,93	64,15	80,38
Papua Selatan	0	0	0	71,68
Papua Tengah	0	0	0	47,65
Papua Pegunungan	0	0	0	56,09

Pada tahap selanjutnya, *dataset* dibagi menjadi dua bagian utama yaitu data *input* dan data target. Sebelum digunakan dalam pelatihan model, seluruh data melalui proses *normalisasi* ke dalam rentang nilai antara -1 hingga 1. Dalam skema ini, nilai 1 merepresentasikan provinsi dengan tingkat APS yang tinggi, sedangkan nilai -1 menunjukkan provinsi dengan Angka Partisipasi Sekolah (APS) yang rendah. *Normalisasi* ini dilakukan untuk memastikan bahwa data dari setiap tahun memiliki pengaruh yang seimbang dalam proses pembelajaran model. Adapun kolom X1, X2, dan X3 masing-masing mewakili kategori Angka Partisipasi Sekolah (APS) untuk tahun 2021, 2022, dan 2023. Sementara itu, kolom t berfungsi sebagai target yang mencerminkan kategori Angka Partisipasi Sekolah (APS) untuk tahun 2024. Hasil dari proses *normalisasi* ini disajikan dalam Tabel 2 di bagian selanjutnya.

Tabel 2. Hasil *Normalisasi* Data APS

Provinsi	X1	X2	X3	t
Aceh	1	1	1	1
Sumatera Utara	1	1	1	1
Sumatera Barat	1	1	1	1
Riau	1	1	1	1
Jambi	-1	-1	-1	-1
Sumatera Selatan	-1	-1	-1	-1
Bengkulu	1	1	1	1
Lampung	-1	-1	-1	-1
Kep. Bangka Belitung	-1	-1	-1	-1
Kep. Riau	1	1	1	1
Dki Jakarta	-1	-1	-1	1
Jawa Barat	-1	-1	-1	-1

Provinsi	X1	X2	X3	t
Jawa Tengah	-1	-1	-1	-1
DI Yogyakarta	1	1	1	1
Jawa Timur	1	1	1	1
Banten	-1	-1	-1	-1
Bali	1	1	1	1
Nusa Tenggara Barat	1	1	1	1
Nusa Tenggara Timur	1	1	1	1
Kalimantan Barat	-1	-1	-1	-1
Kalimantan Tengah	-1	-1	-1	-1
Kalimantan Selatan	-1	-1	-1	-1
Kalimantan Timur	1	1	1	1
Kalimantan Utara	1	1	1	1
Sulawesi Utara	1	1	1	-1
Sulawesi Tengah	1	1	1	-1
Sulawesi Selatan	-1	-1	-1	-1
Sulawesi Tenggara	1	1	1	1
Gorontalo	-1	-1	-1	-1
Sulawesi Barat	-1	-1	-1	-1
Maluku	1	1	1	1
Maluku Utara	1	1	1	1
Papua Barat	1	1	1	1
Papua Barat Daya	-1	-1	-1	1
Papua	-1	-1	-1	1
Papua Selatan	-1	-1	-1	-1
Papua Tengah	-1	-1	-1	-1
Papua Pegunungan	-1	-1	-1	-1

Tahapan selanjutnya adalah implementasi *Perceptron* pada data yang sudah dinormalisasikan sehingga model dapat melakukan proses pembelajaran dengan lebih efektif. Proses pelatihan dilakukan dengan memanfaatkan data tersebut untuk mengoptimalkan bobot dan bias pada jaringan. Hasil yang didapatkan dari pengujian kedua algoritma akan dibandingkan dengan *akurasi* yang telah diperoleh. Hasil pelatihan *Perceptron* disajikan pada Tabel 3.

Tabel 3. Hasil Implementasi Perceptron

X1	X2	X3	1	t	Net	F(Net)	ΔW_1	ΔW_2	ΔW_3	b	W1	W2	W3	b	Keterangan
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	-1	-1	-1	1	0	0	0	2	Tidak Valid
-1	-1	-1	1	-1	2	1	1	1	1	-1	1	1	1	1	Tidak Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	-1	4	1	-1	-1	-1	0	0	0	0	0	Tidak Valid
1	1	1	1	-1	0	-1	0	0	0	0	0	0	0	0	Valid
-1	-1	-1	1	-1	0	-1	0	0	0	0	0	0	0	0	Valid
1	1	1	1	0	-1	1	1	1	1	1	1	1	1	1	Tidak Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid

X1	X2	X3	1	t	Net	F(Net)	ΔW_1	ΔW_2	ΔW_3	b	W1	W2	W3	b	Keterangan
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
1	1	1	1	1	4	1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	1	-2	-1	-1	-1	-1	1	0	0	0	2	Tidak Valid
-1	-1	-1	1	1	2	1	0	0	0	0	0	0	0	2	Valid
-1	-1	-1	1	-1	2	1	1	1	1	-1	1	1	1	1	Tidak Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid
-1	-1	-1	1	-1	-2	-1	0	0	0	0	1	1	1	1	Valid

Berdasarkan hasil yang ditampilkan pada Tabel 3, diketahui bahwa *Perceptron* berhasil mengenali pola data Angka Partisipasi Sekolah (APS) pada 32 dari total 38 provinsi, dengan tingkat *akurasi* sebesar 84,21%. Model mampu menyesuaikan bobot dan bias dengan baik, dan proses pelatihan mencapai hasil optimal pada *epoch* ke-2. Setelah proses implementasi dan evaluasi pada *Perceptron* selesai dilakukan, langkah selanjutnya adalah menerapkan *Adaline*. Berbeda dari *Perceptron* yang menggunakan fungsi aktivasi *threshold* (ambang batas), *Adaline* memakai fungsi aktivasi *linier* serta memperbarui bobot berdasarkan nilai *Mean Squared Error* (MSE).

Pelatihan *Adaline* dilakukan menggunakan *dataset* dan parameter yang sama dengan *Perceptron*, sehingga memungkinkan dilakukannya perbandingan performa kedua model secara objektif. Proses ini menggunakan data *input* dan target yang telah *dinormalisasi* sebelumnya, seperti yang ditampilkan pada Tabel 2. Selama pelatihan, model menghitung nilai net, menghasilkan *output linier* (*y*), menghitung galat (*error*) menggunakan MSE, dan memperbarui bobot serta bias dengan metode *delta rule*. Proses berlangsung secara bertahap (iteratif) hingga model mencapai konvergensi, atau sampai perubahan bobot dan bias menjadi sangat kecil, yakni di bawah ambang batas toleransi sebesar 0,05. Hasil dari pelatihan *Adaline* disajikan dalam Tabel 4 dan 5 berikut.

Tabel 4. Hasil Implementasi Adaline

x1	x2	x3	1	t	net	$Y=f(\text{net})$	t-y
1	1	1	1	1	0	0	1
1	1	1	1	1	0,08	0,08	0,92
1	1	1	1	1	0,16	0,16	0,84
1	1	1	1	1	0,24	0,24	0,76
-1	-1	-1	1	-1	-0,16	-0,16	-0,84
-1	-1	-1	1	-1	-0,24	-0,24	-0,76
1	1	1	1	1	0,4	0,4	0,6
-1	-1	-1	1	-1	-0,34	-0,34	-0,66
-1	-1	-1	1	-1	-0,38	-0,38	-0,62
1	1	1	1	1	0,48	0,48	0,52
-1	-1	-1	1	1	-0,44	-0,44	1,44
-1	-1	-1	1	-1	-0,32	-0,32	-0,68
-1	-1	-1	1	-1	-0,36	-0,36	-0,64
1	1	1	1	1	0,5	0,5	0,5
1	1	1	1	1	0,54	0,54	0,46
-1	-1	-1	1	-1	-0,44	-0,44	-0,56
1	1	1	1	1	0,6	0,6	0,4
1	1	1	1	1	0,64	0,64	0,36
1	1	1	1	1	0,68	0,68	0,32
-1	-1	-1	1	-1	-0,54	-0,54	-0,46
-1	-1	-1	1	-1	-0,58	-0,58	-0,42
-1	-1	-1	1	-1	-0,62	-0,62	-0,38
1	1	1	1	1	0,78	0,78	0,22
1	1	1	1	1	0,78	0,78	0,22
1	1	1	1	-1	0,78	0,78	-1,78
1	1	1	1	-1	0,62	0,62	-1,62
-1	-1	-1	1	-1	-0,52	-0,52	-0,48
1	1	1	1	1	0,52	0,52	0,48
-1	-1	-1	1	-1	-0,58	-0,58	-0,42
-1	-1	-1	1	-1	-0,62	-0,62	-0,38
1	1	1	1	1	0,6	0,6	0,4
1	1	1	1	1	0,64	0,64	0,36
1	1	1	1	1	0,68	0,68	0,32
-1	-1	-1	1	1	-0,72	-0,72	1,72
-1	-1	-1	1	1	-0,6	-0,6	1,6
-1	-1	-1	1	-1	-0,48	-0,48	-0,52

x1	x2	x3	1	t	net	Y=f(net)	t-y
-1	-1	-1	1	-1	-0,52	-0,52	-0,48
-1	-1	-1	1	-1	-0,56	-0,56	-0,44

Tabel 5. Hasil Implementasi Adaline (2)

Δw_1	Δw_2	Δw_3	b	w1	w2	w3	b	Keterangan
0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	Valid
0,02	0,02	0,02	0,02	0,04	0,04	0,04	0,04	Valid
0,02	0,02	0,02	0,02	0,06	0,06	0,06	0,06	Valid
0,02	0,02	0,02	0,02	0,08	0,08	0,08	0,08	Valid
0,02	0,02	0,02	-0,02	0,1	0,1	0,1	0,06	Valid
0,02	0,02	0,02	-0,02	0,12	0,12	0,12	0,04	Valid
0,01	0,01	0,01	0,01	0,13	0,13	0,13	0,05	Valid
0,01	0,01	0,01	-0,01	0,14	0,14	0,14	0,04	Valid
0,01	0,01	0,01	-0,01	0,15	0,15	0,15	0,03	Valid
0,01	0,01	0,01	0,01	0,16	0,16	0,16	0,04	Valid
-0,03	-0,03	-0,03	0,03	0,13	0,13	0,13	0,07	Tidak Valid
0,01	0,01	0,01	-0,01	0,14	0,14	0,14	0,06	Valid
0,01	0,01	0,01	-0,01	0,15	0,15	0,15	0,05	Valid
0,01	0,01	0,01	0,01	0,16	0,16	0,16	0,06	Valid
0,01	0,01	0,01	0,01	0,17	0,17	0,17	0,07	Valid
0,01	0,01	0,01	-0,01	0,18	0,18	0,18	0,06	Valid
0,01	0,01	0,01	0,01	0,19	0,19	0,19	0,07	Valid
0,01	0,01	0,01	0,01	0,2	0,2	0,2	0,08	Valid
0,01	0,01	0,01	0,01	0,21	0,21	0,21	0,09	Valid
0,01	0,01	0,01	-0,01	0,22	0,22	0,22	0,08	Valid
0,01	0,01	0,01	-0,01	0,23	0,23	0,23	0,07	Valid
0,01	0,01	0,01	-0,01	0,24	0,24	0,24	0,06	Valid
0	0	0	0	0,24	0,24	0,24	0,06	Valid
0	0	0	0	0,24	0,24	0,24	0,06	Valid
-0,04	-0,04	-0,04	-0,04	0,2	0,2	0,2	0,02	Tidak Valid
-0,03	-0,03	-0,03	-0,03	0,17	0,17	0,17	-0,01	Tidak Valid
0,01	0,01	0,01	-0,01	0,18	0,18	0,18	-0,02	Valid
0,01	0,01	0,01	0,01	0,19	0,19	0,19	-0,01	Valid
0,01	0,01	0,01	-0,01	0,2	0,2	0,2	-0,02	Valid
0,01	0,01	0,01	-0,01	0,21	0,21	0,21	-0,03	Valid
0,01	0,01	0,01	0,01	0,22	0,22	0,22	-0,02	Valid
0,01	0,01	0,01	0,01	0,23	0,23	0,23	-0,01	Valid
0,01	0,01	0,01	0,01	0,24	0,24	0,24	0	Valid
-0,03	-0,03	-0,03	0,03	0,21	0,21	0,21	0,03	Tidak Valid
-0,03	-0,03	-0,03	0,03	0,18	0,18	0,18	0,06	Tidak Valid
0,01	0,01	0,01	-0,01	0,19	0,19	0,19	0,05	Valid
0,01	0,01	0,01	-0,01	0,2	0,2	0,2	0,04	Valid
0,01	0,01	0,01	-0,01	0,21	0,21	0,21	0,03	Valid

Secara keseluruhan, hasil pengujian menunjukkan bahwa *Adaline* memberikan performa yang lebih unggul dibandingkan *Perceptron* dalam mengklasifikasikan data Angka Partisipasi Sekolah (APS). Hanya dengan satu kali *epoch* pelatihan, *Adaline* berhasil mengklasifikasikan data secara tepat untuk 33 dari 38 provinsi, dengan *akurasi* mencapai 86,84%. Sebaliknya, *Perceptron* memerlukan dua kali *epoch* untuk mencapai *akurasi* 84,21%, dengan hasil klasifikasi yang benar pada 32 provinsi. Temuan ini menunjukkan bahwa *Adaline* lebih efisien dalam proses pelatihan serta lebih presisi dalam menangani data Angka Partisipasi Sekolah (APS) yang telah dinormalisasi. Hasil ini menegaskan potensi besar *Adaline* untuk diterapkan dalam analisis data pendidikan, khususnya dalam skala nasional, guna membantu pemetaan partisipasi pendidikan dan mendukung pengambilan kebijakan yang lebih tepat sasaran.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, tujuan yang telah dirumuskan dalam Bab Pendahuluan yaitu untuk menganalisis dan membandingkan performa *Perceptron* dan *Adaline* dalam mengklasifikasikan Angka Partisipasi Sekolah (APS) telah berhasil dicapai, sebagaimana dibuktikan melalui analisis di Hasil dan Pembahasan. Kedua algoritma terbukti mampu melakukan klasifikasi dengan tingkat *akurasi* yang cukup baik. Namun demikian, *Adaline* menunjukkan kinerja yang lebih unggul. Dengan hanya satu kali proses pelatihan (*epoch*), *Adaline* berhasil mencapai *akurasi* 86,84%, sementara *Perceptron*

membutuhkan dua *epoch* untuk mencapai 84,21%. Temuan ini mendukung hipotesis awal bahwa algoritma yang melakukan pembaruan bobot secara lebih stabil seperti yang dilakukan *Adaline* cenderung memberikan hasil klasifikasi yang lebih akurat, khususnya ketika digunakan pada data Angka Partisipasi Sekolah (APS). Untuk ke depannya, hasil penelitian ini membuka peluang untuk dikembangkan lebih lanjut, misalnya dengan mengeksplorasi penggunaan algoritma *jaringan syaraf tiruan* lainnya seperti *Multilayer Perceptron (MLP)* atau pendekatan deep learning, guna meningkatkan *akurasi* dan kemampuan model dalam menangani data pendidikan yang lebih kompleks dan bervariasi. Selain itu, penelitian lanjutan dapat diarahkan pada pengembangan sistem prediksi berbasis machine learning yang dapat digunakan oleh pemangku kebijakan untuk memantau dan meningkatkan partisipasi pendidikan di berbagai daerah secara lebih proaktif dan berbasis data. Dengan demikian, hasil penelitian ini diharapkan dapat berkontribusi secara praktis dalam mendukung pengambilan keputusan strategis di bidang pendidikan nasional.

REFERENCES

- Baidawi, T., & Solikhun. (2024). A Comparison of MADaline and Perceptron Algorithms on Classification with Quantum Computing Approach. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 8(2), 280–287. <https://doi.org/10.29207/resti.v8i2.5502>
- Budiarti, L., & Nurcahyo, G. W. (2024). Penerapan Metode Jaringan syaraf tiruan Backpropagation untuk Memprediksi Kualitas Makanan Kucing. 11(4), 390–397. <https://doi.org/https://doi.org/10.35134/komtekinfo.v12i1.561>
- Farhan, A. A., Rizkia, A., Budi, H. R., Ropik, I. A., Ghazi, S., Firly, N., & Indonesia, U. P. (2024). *Hipkin Journal of Educational Research*. 1(1), 49–60.
- Haryawan, C., & Sebatubun, M. M. (2020). Implementation of Multilayer Perceptron for Student Failure Prediction. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 18(2), 125. <https://doi.org/10.12962/j24068535.v18i2.a990>
- Informatika, P. S. (2023). AVOCADO STOCK PREDICTION SYSTEM IN FRUIT SHOPS A Case Study in Bantul City. 1(1), 1–9.
- Irsyada, R., & Ausytra, H. (2019). Penerapan Jaringan syaraf tiruan Model Adaline Pada Klasifikasi Status Gizi Balita (Berdasarkan Metode Antropometri). *Jurnal INVERTOR*, 2(1), 13–18.
- Kamalia, A. Z., & Nawangsih, I. (2025). IDENTIFIKASI POLA TINGKAT KESENJANGAN KETUNTASAN PENDIDIKAN DI INDONESIA DENGAN MENGGUNAKAN METODE K-MEDOIDS CLUSTERING IDENTIFICATION OF PATTERNS IN EDUCATIONAL COMPLETION DISPARITIES IN INDONESIA USING THE K-MEDOIDS CLUSTERING METHOD. 12(2), 321–330. <https://doi.org/10.25126/jtiik.2025129219>
- Kennedy, P. S. J., Tobing, S. J. L., Toruan, R. L., Tampubolon, E., & Nomleni, A. (2019). Isu Strategis Kesenjangan Pendidikan di Provinsi Nusa Tenggara Timur. *Prosiding Seminar Nasional Pendidikan FKIP*, 2(1), 619–629.
- Khotimah, D. K., & Abdan, M. R. (2025). Analisis Pendekatan Deep Learning untuk Meningkatkan Efektivitas Pembelajaran PAI di SMKN Pringkuwu. 5, 866–879. <https://doi.org/10.53299/jppi.v5i2.14666%OAnalisis>
- Mukhlisa, N., & Kasim, A. (2021). Open Government Data : Open Data Pada Sektor Pendidikan Dalam Mendukung Kebijakan. *KOLABORASI: Jurnal Administrasi Publik*, 7(2), 125–143. <https://doi.org/10.26618/kjap.v7i2.5489>
- N. Kapita, S., Mahdi, S., & Tempola, F. (2020). Penilaian Pengetahuan Siswa Dengan Jaringan syaraf tiruan Perceptron. *Techno: Jurnal Penelitian*, 9(1), 372. <https://doi.org/10.33387/tjp.v9i1.1712>
- Naila Nur 'Azizah, Meysihinur, & Aziza, M. (2023). Evaluasi Kebijakan Pendidikan. *Ta Lim Jurnal Pendidikan Agama Islam Dan Manajemen Pendidikan Islam*, 2(02), 47–54. <https://doi.org/10.59098/talim.v2i02.1255>
- Nasution, D., & Nasution, D. (2022). Perbandingan Adaline Berdasarkan Pola Input Data Dan Aktivasi Output Untuk Prediksi Data. 4(1), 96–105.
- No, V., & Zahrah, F. N. (2024). Edumatic : Jurnal Pendidikan Informatika Machine Learning untuk Deteksi Stres Pelajar : Perceptron sebagai Model Klasifikasi Efektif untuk Intervensi Dini. 8(2), 764–773. <https://doi.org/10.29408/edumatic.v8i2.28011>
- Rifaldy, F. (2025). MODEL PERCEPTRON UNTUK KLASIFIKASI KEPUASAN MAHASISWA. 16(1), 3–8.
- Sagheer, A., Zidan, M., & Abdelsamea, M. M. (2019). A novel Autonomous Perceptron model for pattern classification applications. *Entropy*, 21(8), 1–24. <https://doi.org/10.3390/e21080763>
- Saraf, J., Dengan, T., & Perceptron, A. (2024). Pengenalan pola bunga berbasis citra menggunakan jaringan syaraf tiruan dengan algoritma. 09, 365–373.
- Sofia, I. P. (2017). Konstruksi Model Kewirausahaan Sosial (Social Entrepreneurship) Sebagai Gagasan Inovasi Sosial Bagi Pembangunan Perekonomian. *Widyakala Journal*, 2(1), 2. <https://doi.org/10.36262/widyakala.v2i1.7>
- Sonata, F., Prayudha, J., Hutagalung, J., & Sipahutar, I. (2023). Jaringan syaraf tiruan untuk Memprediksi Jumlah Mahasiswa dengan Metode Perceptron (Studi Kasus : STMIK Triguna Dharma). *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika Dan Komputer)*, 22(2), 474. <https://doi.org/10.53513/jis.v22i2.9144>
- Taghinezhad, F., & Ghasemzadeh, M. (2024). A New Structure for Perceptron in Categorical Data Classification. 12(3), 409–421. <https://doi.org/10.22044/jadm.2024.14981.2594>
- Wijayakusuma, I. G. N. L., & Emik Sapitri, N. K. (2020). Penerapan Jaringan syaraf tiruan Dalam Pembentukan Model Peramalan Angka Melek Huruf di Kabupaten Karangasem. *Jurnal Matematika*, 10(1), 11. <https://doi.org/10.24843/jmat.2020.v10.i01.p119>

