

Survei Implementasi *Artificial Intelligence* Pada Intelligent Visual Aircraft Recognition (I-Vacr) System

Arwin Datumaya Wahyudi Sumari^{1,2}, Dimas Eka Adinandra³, Aldi Surya Prana-
ta³, Afifah Milatina Nugraheni³, Satriya Dipa Satwika³, Ika Noer Syamsiana²

¹Lanud Abdulrachman Saleh, Komando Operasi Udara II, TNI Angkatan Udara

²Cognitive Artificial Intelligence Research Group (CAIRG), Jurusan Teknik Elektro,
Politeknik Negeri Malang

³Jurusan Teknologi Informasi, Politeknik Negeri Malang

Penulis Korespondensi: arwin.sumari@tni-au.mil.id

Abstrak — Objek udara yang terbang rendah dengan ketinggian rendah dari permukaan bumi dengan tujuan menghindari deteksi *Radio Detection and Ranging* (Radar) dapat mengindikasikan tindakan permusuhan dan dikategorikan sebagai ancaman terhadap kedaulatan negara di udara. Sebagai antisipasi, teknik *Visual Aircraft Recognition* (VACR) telah dikembangkan oleh Angkatan Darat Amerika Serikat untuk melatih para prajuritnya untuk mengenali dan mengidentifikasi objek udara dari jarak jauh menggunakan binokular. Namun, dengan beragamnya jenis dan nama objek udara memberikan beban kognitif dan dapat berdampak pada ketidaktepatan dalam mengenali dan mengidentifikasi objek udara yang diamati. Dalam artikel ilmiah dilakukan kajian pemanfaatan teknologi *Artificial Intelligence* (AI) untuk membangun *Intelligent VACR* (I-VACR) System melalui metode-metode dalam *machine learning* yakni Jaringan Syarat Tiruan, *Naïve Bayes Classifier* (NBC), *K-Nearest Neighbor* (KNN), dan *Support Vector Machine* (SVM). Hasil-hasil penelitian memperlihatkan bahwa keempat metode tersebut prospektif diaplikasikan sebagai elemen cerdas I-VACR.

Keywords: *Artificial Intelligence*, identifikasi, *machine learning*, objek udara, pengenalan, VACR

PENDAHULUAN

Mendeteksi, mengenali, dan mengidentifikasi kehadiran objek udara tak bersahabat yang dengan sengaja menghindari tangkapan sinyal *Radio Detection and Ranging* (Radar) telah menjadi perhatian militer. Lebih lagi, objek udara tak bersahabat selain berupaya terbang pada ketinggian yang rendah terhadap permukaan bumi atau *Nap-on-Earth* (NoE) (Nallusamy and Balaji, 2019) atau yang bersembunyi pada *radar shadow*, ia juga akan mematikan sistem *Identification Friend or Foe* (IFF) agar tidak dapat dikenali dan diidentifikasi. Dalam upaya mengantisipasi terjadinya tindak permusuhan, Angkatan Darat Amerika Serikat mengembangkan teknik yang disebut dengan *Visual Aircraft Recognition* (VACR)

(Headquarters Department of the Army, 2017). Pada esensinya, VACR memberikan pelatihan kepada para prajurit di garis depan agar memiliki kemampuan untuk mengenali dan mengidentifikasi objek udara dengan bantuan binokular atau teropong jarak jauh hanya berdasarkan pada karakteristik-karakteristiknya.

Teknik ini dikembangkan dengan tujuan untuk meningkatkan probabilitas pengenalan dan identifikasi objek udara musuh, dan mereduksi probabilitas terjadinya penembakan terhadap objek udara sendiri (*friendly fire*). Melaksanakan pengamatan jarak jauh menggunakan binokular secara terus

menerus dan ditambah dengan mengingat semua karakteristik serta jenis-jenis pesawat merupakan kegiatan *multi-tasking* yang telah memberikan beban kognitif bagi para prajurit pelaksana pengamatan di lapangan. Beban kognitif yang tinggi akan menjadi *cognitive overload* (Kirsh, 2000) dan dapat berdampak pada kelelahan sehingga akan menaikkan probabilitas kegagalan pengenalan dan identifikasi objek udara terutama objek-objek yang terbang dengan kecepatan tinggi. Untuk itu diperlukan satu solusi untuk membantu kemampuan berpikir para prajurit pengamat tersebut dengan mengimplementasikan teknologi *Artificial Intelligence* (AI).

Metode-metode AI telah banyak digunakan untuk membantu manusia dalam klasifikasi dan pengenalan objek-objek fisik, baik benda-benda mati maupun makhluk hidup seperti manusia dan hewan. Di dunia militer, deteksi, pengenalan, dan identifikasi objek udara baik pesawat udara militer maupun pesawat udara sipil telah dilakukan sejak Perang Dunia ke-2 dengan dikenalkannya Radar yang diinisiasi oleh Angkatan Bersenjata Inggris. Invensi model Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Networks* (ANN) oleh Warren McCulloch dan Walter Pitts pada tahun 1949 (McCulloch and Pitts, 1990) yang disebut dengan model McCulloch-Piits (MCP), telah membukajalanpemanfaatan Alpadaberbagai bidang termasuk di bidang militer. Invensi tersebut telah memicu pertemuan pertama para pakar AI di dunia dalam satu pertemuan ilmiah yang digagas oleh salah satunya

adalah Johh McCarthy, yang pada pertemuan tersebut mencetuskan terminologi AI dengan definisi *the science and engineering of making intelligent machines, especially intelligent computer programs. It is related to the similar task of using computers to understand human intelligence*. Pada tahun-tahun berikutnya telah ditemukan beragam metode AI baik yang berbasiskan pada peniruan cara sel syarat otak bekerja yakni ANN dgn beragam variannya seperti *Adaptive Resonance Theory* (ART), *Back Propagation Network* (BPN), dan *deep learning*, maupun dari bidang keilmuan statistik seperti *Linear Regression* dan *Logistic Regression*, serta dari pendekatan lain seperti *Support Vector Machine* (SVM), *K-Nearest Neighbors* (KNN), dan *K-Means*.

Guna mereduksi *cognitive overload* pada pengamatan udara untuk mendeteksi, mengenali, dan mengidentifikasi objek udara dari darat-ke-udara secara berkesinambungan dengan nyata-waktu (*real-time*), maka dalam artikel ilmiah ini diajukan *Intelligent VACR* (I-VACR) *system* dari perspektif 4 (empat) metode *machinelearning* yakni BPN, SVM, NBC, dan KNN. Untuk memudahkan pemahaman, artikel ilmiah ini disusun secara sistematis yang diawali dengan Bagian Pendahuluan dan dilanjutkan dengan Bagian Metode. Hasil-hasil kajian akan disampaikan pada Bagian Hasil dan Pembahasan. Artikel ilmiah akan ditutup dengan Bagian Kesimpulan yang akan menyampaikan kesimpulan dan langkah-langkah kedepan

METODE

Survei dilakukan pada literatur-literatur yang dipublikasikan dalam jurnal internasional, jurnal nasional, prosiding konferensi internasional dan nasional serta sumber-sumber ilmiah lain yang relevan. Sumber-

sumber tersebut mencakup situs IEEE Xplore, jurnal internasional terindeks pada ScimagoJR dan Scopus, serta jurnal nasional terindeks SINTA.

HASIL DAN PEMBAHASAN

Visual Aircraft Recognition (VACR)

VACR telah digunakan oleh Angkatan Darat Amerika Serikat untuk melatih para prajuritnya agar memiliki kemampuan tidak hanya mengenali, namun juga mengidentifikasi pesawat udara militer berdasarkan pada karakteristik-karakteristiknya melalui observasi jarak jauh dari darat-ke-udara (*ground-to-air*) menggunakan binocular (Headquarters Department of the Army, 2017) sebagaimana diperlihatkan pada Gambar 2. Karakteristik-karakteristik pesawat udara militer dibagi ke dalam empat kelompok besar yakni Sayap (*Wing*), Mesin (*Engine*), Badan (*Fuselage*), dan Ekor (*Tail*), disingkat dengan SMBE (WEFT), dimana masing-masing terdiri atas:

- a. Sayap, yang dikarakterisasi oleh diantaranya:
 - 1). Sayap tetap dengan lokasi instalasi di atas, di tengah, dan di bawah badan pesawat.
 - 2). Sayap putar yang terdiri atas rotor utama dan rotor ekor.
 - 3). Bentuk dengan konfigurasi lurus, delta, semi-delta, dan swept-back.
 - 4). Sayap kecil tambahan disebut *canard*, yang diinstalasi di bagian depan badan pesawat.
- b. Mesin, yang dikarakterisasi oleh:
 - 1). Jenis seperti baling-baling dan jet.
 - 2). Jumlah.
 - 3). Penempatan pada badan pesawat.
- c. Badan, yang dikarakterisasi oleh:
 - 1). Konfigurasi
 - 2). Bentuk kanopi.
- d. Ekor, yang dikarakterisasi oleh:
 - 1). Jumlah.
 - 2). Bentuk penstabil vertical (*fin*).
 - 3). Lokasi penempatan pada badan pesawat.

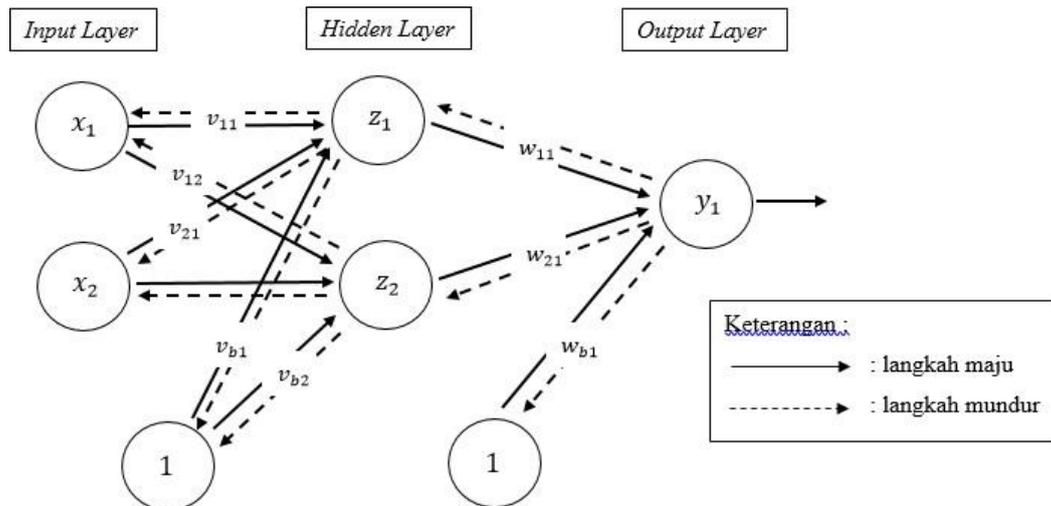
Back Propagation Network (BPN)

BPN merupakan salah satu teknik dalam *machine learning* dimana komputasi untuk membangun pengetahuan jaringan syarafnya mengemulasikan cara kerja sel-sel syaraf dalam otak manusia. BPN merupakan variasi dari model MCP baik dari segi komputasinya maupun dengan adanya penambahan mekanisme umpan-balik untuk memperbaiki pengetahuan yang dibangkitkan, yang disebut dengan mekanisme propagasi balik (*back propagation*). Secara umum arsitektur BPN sebagaimana diperlihatkan pada Gambar 3, terdiri atas tiga lapisan yakni: lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan luaran (*output layer*), yang mana di setiap lapisan dapat terdiri atas satu atau lebih simpul. Simpul-simpul pada lapisan masukan diberi simbol x_i dimana $i=1, \dots, n$, simpul-simpul pada lapisan tersembunyi diberi simbol z_y dimana $y=1, \dots, p$, dan simpul-simpul luaran diberi simbol k_j dimana $k=1, \dots, m$. BPN menyimpan pengetahuan dalam bentuk bobot-bobot (*weights*) antara lapisan masukan dengan lapisan tersembunyi yang diperlihatkan oleh simbol v_{ik} , dan antara lapisan tersembunyi dengan lapisan luaran yang diperlihatkan oleh simbol w_{kj} , sedangkan angka '1' merepresentasikan tegangan bias untuk mengaktifkan semua simpul-simpul pada lapisan tersembunyi dan lapisan luaran.

BPN menggunakan paradigma pembelajaran disupervisi (*supervised*), yang bermakna bahwa pembangkitan pengetahuan dilakukan dengan cara diberikan contoh yang wajib dicapai atau target. Untuk itu, diperlukan pelatihan (*training*) terhadap jaringan syaraf hingga memperoleh pengetahuan yang lengkap sebelum digunakan dengan cara mengukur perbedaan nilai hasil luaran pelatihan dengan nilai target guna menilai seberapa besar kesalahannya (*error*). Semakin kecil perbedaan, semakin lengkap pengetahuan yang telah berhasil

dibangkitkan oleh BPN. Salah satu cara mengukur perbedaan tersebut adalah dengan menggunakan pengukuran *Mean Squared Error (MSE)*. Melatih BPN pada esensinya adalah untuk mendapatkan keseimbangan antara kemampuan jaringan syaraf untuk mengenali pola-pola yang diajarkan atau diperlihatkan selama pelatihan

serta kemampuannya untuk memberi respon yang benar terhadap pola-pola masukan yang serupa dengan pola-pola yang telah diajarkan atau dilatihkan (Abdullah and Usman, 2016). Pola-pola tersebut dapat berupa kategori pesawat udara militer misal: *fighter*, *attacker*, dan *bomber* sebagai target yang dikenali dari karakteristik-karakteristiknya.



Gambar 1. Arsitektur BPN.

Pelatihan BPN meliputi tiga fase, yakni:

- a. Fase maju dimana pola-pola dimasukkan ke jaringan syaraf melalui lapisan masukan dan kemudian dihitung maju mulai dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang telah ditentukan.
- b. Fase propagasi balik dimana perhitungan kesalahan antara pengetahuan yang dibangkitkan dengan target dilakukan. Perbedaan yang dihasilkan kemudian dipropagasikan balik ke semua simpul yang terhubung dengan simpul-simpul di lapisan luaran.

- c. Fase pembaruan bobot untuk mereduksi perbedaan yang telah terjadi.

Algoritma pelatihan BPN disampaikan sebagai berikut (Prabowo et al., 2020):

0. Langkah 0. Inisialisasi bobot-bobot dengan mengambil nilai awal random yang cukup kecil.
1. Langkah 1. Jika kondisi pemberhentian belum terpenuhi ($epoch < maximum\ epoch$ dan $error\ target < MSE$), lakukan langkah-langkah 2 hingga 9.
2. Langkah 2. Untuk setiap pelatihan pola, lakukan langkah-langkah 3 hingga 8.

Langkah Maju (Feed Forward)

3. Langkah 3. Tiap simpul lapisan masukan ($x_i, i=1,2,3,\dots,n$) menerima sinyal masukan, x_i dan meneruskannya ke

semua simpul pada lapisan tersembunyi.

- Langkah 4. Tiap simpul pada lapisan t tersebut $y_i(z_j, j=1, 2, 3, \dots, p)$ menjumlahkan bobot-bobot masukan menggunakan Persamaan (2.1).

$$z_{ijn_{jj}} = v_{bjj} + \sum_{ii=1}^n x_{ii}v_{iijj} \quad (2.1)$$

Sinyal luaran diperoleh dengan melakukan komputasi menggunakan fungsi aktivasi pada Persamaan (2.2)

$$z_{jj} = ff(z_{ijn_{jj}}) = \frac{1}{1 + e^{-z_{netjj}}} \quad (2.2)$$

5. Langkah 5. Simpul-simpul luaran ($y_k, k=1,2,3,\dots,m$) menjumlahkan bobot-bobot sinyal masukan menggunakan fungsi aktivasi untuk memperoleh sinyal luaran menggunakan Persamaan (2.3).

$$z_{jj} = ff(z_{ijn_k}) \quad (2.3)$$

Langkah Mundur (Back Propagation)

6. Langkah 6. Simpul-simpul luaran ($y_k, k=1,2,3,\dots,m$) menerima pola-pola yang sesuai dengan pola pelatihan pada lapisan masukan dan menghitung nilai perbedaan serta menghitung koreksi bobot-bobot dan bias menggunakan Persamaan (2.4) hingga Persamaan (2.10).

$$\delta\delta_k = (t_k - y_k)ff'(y_{ijn_k}) = (t_k - y_k)y_k(1 - y_k) \quad (2.4)$$

Menghitung bobot-bobot terkoreksi untuk digunakan memperbaharui nilai bobot-bobot w_{jo} .

$$\Delta w_{jkk} = \alpha\delta\delta_k z_{jj} \quad (2.5)$$

dilanjutkan dengan menghitung bias terkoreksi.

$$\Delta w_{bk} = \alpha\delta\delta_k \quad (2.6)$$

dan mengirimkan δ ke simpul-simpul pada lapisan dibawahnya.

- 7 Langkah 7. Tiap simpul lapisan tersembunyi ($z_j, j=1,2,3,\dots,p$) menjumlahkan δ masukan.

$$\delta\delta_{ijn_{jj}} = \sum_{k=1}^m \delta\delta_k w_{jkk} \quad (2.7)$$

dikalikan dengan turunan fungsi aktivasi untuk menghitung perbedaan (error).

$$\delta_j = \delta\delta_{ijn_{jj}} ff'(z_{ijn_{jj}}) \quad (2.8)$$

kemudian hitung koreksi bobot

$$\Delta v_{iijj} = \alpha\delta\delta_j x_{ii} \quad (2.9)$$

dan menghitung bias terkoreksi

$$\Delta v_{bjj} = \alpha \delta_{jj} \quad (2.10)$$

Perbarui Bobot-Bobot dan Bias

8. Langkah 8. Simpul-simpul lapisan luaran ($y_k, k=1,2,3,\dots,m$) memperbaharui bobot-bobotnya dan bias menggunakan Persamaan (2.11).

$$w_{jjk}(new) = w_{jjk}(old) + \Delta w_{jjk} \quad (2.11)$$

Tiap simpul lapisan tersembunyi ($z_j, j=1,2,3,\dots,p$) memperbaharui bobot-bobotnya dan bias menggunakan Persamaan (2.12).

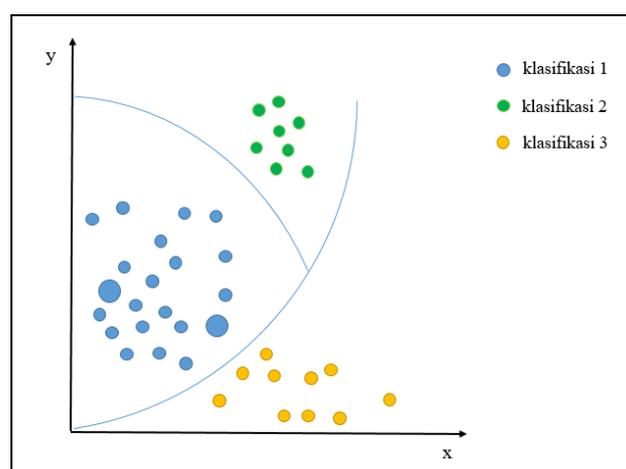
$$v_{iij}(new) = v_{iij}(old) + \Delta v_{iij} \quad (2.12)$$

9. Langkah 9. Tes kondisi berhenti.

Naïve Bayes Classifier (NBC)

Naïve Bayes Classifier (NBC) merupakan satu teknik *machine learning* berbasis statistik khususnya teorema Bayes yang ditemukan oleh Reverend Thomas Bayes pada abad ke-18. Komputasi Bayes sederhana sehingga dapat dijalankan dengan cepat, yang mana antar fitur satu dengan lainnya bersifat tidak saling bergantung (*mutually exclusive*) (Muhamad et al., 2017). Karena berdasarkan pada probabilitas, metode ini digunakan untuk menghitung peluang satu keadaan berdasarkan pada atribut-atribut yang

dimilikinya guna menentukan kelasnya (Somantri and Khambali, 2017). Peluang dalam konteks survei ini adalah kategori pesawat udara militer sebagai target dihadapkan pada atribut-atributnya. Atribut dan karakteristik memiliki makna yang sama. Target diperlukan karena NBC belajar dengan paradigma pembelajaran disupervisi. Gambar 2 memberikan ilustrasi cara NBC mengelompokkan objek-objek yang berbeda berdasarkan pada atribut-atributnya melalui klasifikasi.



Gambar 2. Ilustrasi klasifikasi NBC.

Teorema Bayes ditulis secara matematis pada Persamaan (2.13).

$$P(y|XX) = \frac{P(XX|y)P(y)}{P(XX)} \quad (2.13)$$

dimana:

XX = Pola XX yang berasal dari satu kelas spesifik.

y = hipotesis kelas pola dari pola yang belum diketahui.

$P(y|XX)$ = probabilitas hipotesis kelas dari pola y berdasarkan berdasarkan pola XX (*posteriori probability*).

$P(XX|y)$ = probabilitas pola XX dihadapkan pada hipotesis kelas dari pola y .

$P(y)$ = probabilitas hipotesis kelas dari pola y (*prior probability*).

$P(XX)$ = probabilitas pola XX .

Metode ini melakukan klasifikasi data berdasarkan nilai probabilitas, P dari sejumlah atribut x_{ii} dari tiap kelas pola y . Penulisan probabilitas tiap kelas k dan jumlah atribut a ditulis secara matematis pada Persamaan (2.14).

$$P = (y_k | x_1, x_2, \dots, x_a) \quad (2.14)$$

Peluang dikenalnya pola y sebagai kelas pola X dipengaruhi dari peluang y saat X , yakni peluang y dan peluang X . Ketentuan atribut

dalam pengategorian pola ke dalam satu kelas diperlihatkan pada Persamaan (2.15).

$$P(A_{ij} | C) = \frac{|A_{ij}|}{N_{C_{ij}}} \quad (2.15)$$

dimana $|A_{ij}|$ adalah contoh-contoh pola pelatihan dari kelas A_i yang menerima kelas C_j . Jika hasil perhitungan Persamaan

(2.15) mendapatkan nilai nol, maka perlu menggunakan pendekatan seperti Persamaan (2.16).

$$P(A_{ij} | C) = \frac{n_c + n_{e_{ij}} P}{n + n_{e_{ij}}} \quad (2.15)$$

dimana n merupakan jumlah dari hasil kelas C_j , n_c merupakan jumlah contoh dari kelas A_i yang menerima nilai C_j , n_{equiv} merupakan nilai pasti dari sampel yang ekuivalen, dan P merupakan peluang

estimasi prior. Nilai P merupakan $1/k$, dimana k merupakan jumlah kelas dalam variabel target. Untuk peluang dengan atribut kontinu dihitung dengan menggunakan Persamaan (2.16).

$$P(A_{ij} | C) = \frac{1}{\sqrt{2\pi\sigma_{iii}}} \exp \left[-\frac{(A_{ii} - \mu_{iii})^2}{2(\sigma_{iii})^2} \right] \quad (2.15)$$

Support Vector Machine (SVM)

Sama halnya dengan BPN dan NBC, SVM merupakan metode *machine learning* dengan paradigma pembelajaran disupervisi yang banyak digunakan untuk klasifikasi data linier dan non linier. SVM akan mencari *hyperplane* terbaik yang memisahkan objek yang

berasal dari dua kelas berbeda, dan memiliki kelebihan dalam menentukan jarak dengan cepat berdasarkan pada *support vector* (Cortes and Vapnik, 1995) serta kemampuannya untuk membentuk *hyperplane* pada dimensi yang

lebih tinggi sehingga dua kelas berbeda yang tidak dapat dipisahkan pada dimensi rendah, dapat dengan mudah dipisahkan pada dimensi yang lebih tinggi.

Diperlihatkan pada Gambar 3, dua kelas objek yakni objek berwarna biru dan oranye dipisahkan oleh sebuah garis *hyperplane*, dimana w adalah bidang normal dan b adalah bias terhadap pusat koordinat (Tan et al., 2019). Vektor yang memiliki jarak paling dekat

dengan *hyperplane* disebut dengan *support vector* yang ditunjukkan dengan dua objek

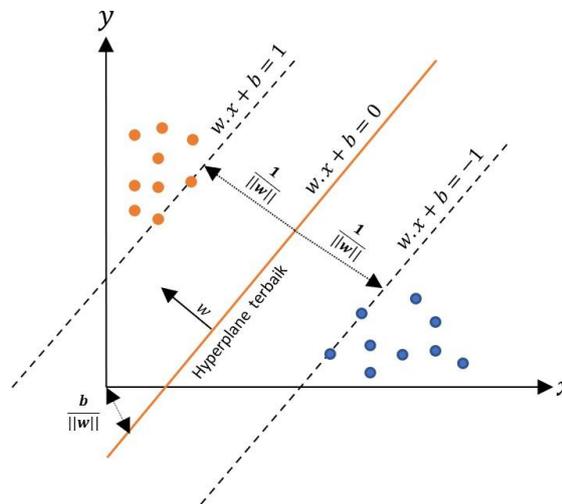
berwarna biru pada garis $(w \cdot x) + b = -1$ dan dua objek berwarna oranye pada garis $(w \cdot x) + b = 1$.

$$(w \cdot x) + b = 0 \tag{2.16}$$

SVM memisahkan objek yang berbeda atribut atau karakteristiknya menggunakan *hyperplane* dengan batas antar kelas terbesar.

Garis pembatas dari kedua kelas yang berbeda tersebut dapat dilihat Persamaan (2.17)

$$\begin{cases} (w \cdot x) + b \geq +1 \text{ for } y_{ii} = +1 \\ (w \cdot x) + b \leq -1 \text{ for } y_{ii} = -1 \end{cases} \tag{2.17}$$



Gambar 3. Ilustrasi *hyperplane* SVM

Dari Persamaan (2.17) dapat diketahui bahwa objek yang dikelompokkan pada kategori kelas pertama adalah objek yang memiliki nilai persamaan lebih besar atau sama dengan 1 ($(w \cdot x) + b \geq 1$), sedangkan objek yang

dikelompokkan pada kategori kelas kedua adalah objek yang memiliki nilai persamaan lebih kecil atau sama dengan -1 ($(w \cdot x) + b \leq -1$). Jika titik terpisah secara linier, maka fungsi untuk permukaan ini ditentukan dengan Persamaan (2.18).

$$f(x) = \left(\sum_{ii=1} a_{ii} y_{ii} (x_{ii} \cdot x) + b \right) \tag{2.18}$$

$(x_{ii}, y_{ii}) \in R^n \times \{-1, 1\}$

Terdapat fungsi kernel yang digunakan untuk menyelesaikan masalah non linier dengan

menggunakan fungsi Kernel Radial Basis Function (RBF).

$$k(x_{ii}, x_{jj}) = \exp \frac{(-||x_{ii} - x_{jj}||^2)}{2\sigma^2} \quad (2.18)$$

Langkah-langkah yang digunakan untuk melakukan pelatihan menggunakan RBF adalah sebagai berikut:

1. Melakukan perhitungan kernel dan inialisasi *hyperparameter* SVM seperti nilai $\alpha_i=0$; $\epsilon=0,1$; $\gamma=0,01$; $\lambda=1$; $C = 1$; σ kernel RBF = 2.

Keterangan:

γ : Gamma, berguna dalam melakukan *controlling* kecepatan pelatihan.

C : *Complexity* C, parameter ini digunakan dalam proses pelatihan yang nantinya

meminimalkan nilai kesalahan atau perbedaan pada klasifikasi.
 λ : *lagrange multiplier*, berguna untuk mencari support vector.
 ϵ : epsilon, digunakan dalam mengukur error pada klasifikasi.

2. Menghitung Matriks Hessian.

$$D_{ijj} = y_{ii}y_{jj}(k(x_{ii}, x_{jj}) + \lambda^2) \quad (2.19)$$

3. Menghitung nilai E_i (error rate).

$$E_{ii} = \sum_{ii=1}^n \alpha_{ii}D_{iii} \quad (2.20)$$

4. Menghitung nilai $\delta\alpha_i$.

$$\delta\alpha_{ii} = \min [\max[\gamma\gamma(1 - E_{ii}), \alpha_{ii}], C - \alpha_{ii}] \quad (2.21)$$

5. Memperbarui nilai $\delta\alpha_i$.

$$\alpha_{ii} = \alpha_{ii} + \delta\alpha \quad (2.21)$$

6. Menghitung nilai $w.x^+$ dan $w.x^-$ untuk mendapatkan nilai bias dengan menggunakan Persamaan (2.22) hingga persamaan (2.24).

$$w.x^+ = \alpha_{ii} \cdot \gamma\gamma_{ii} \cdot K(x, x^+) \quad (2.22)$$

$$w.x^- = \alpha_{ii} \cdot \gamma\gamma_{ii} \cdot K(x, x^-) \quad (2.23)$$

$$b = -\frac{1}{2}(w.x^+ + w.x_-) \quad (2.24)$$

Langkah-langkah yang dilakukan untuk melakukan proses pengujian pada pengetahuan SVM yang diperoleh dalam pelatihan adalah sebagai berikut:

1. Menghitung nilai $K(x, x_i)$ yang kemudian digunakan untuk menghitung nilai bobot (weight).

$$k(x_{ii}, x_{ii}) = \exp \frac{(-||x_{ii} - x||^2)}{2\sigma^2} \quad (2.25)$$

2. Menghitung nilai bobot dengan alpha yang didapatkan dari proses pelatihan.

$$w \cdot x = \alpha_{ii} \cdot \gamma_{ii} \cdot K(x_{ii}, x) \quad (2.26)$$

3. Menghitung nilai $f(x)$ dengan menggunakan Persamaan (2.27) dan menghitung hasil klasifikasi dengan menggunakan Persamaan (2.28).

$$f(x) = \sum_{i=1}^n \alpha_i \cdot y_i \cdot K(x_i, x) + b \quad (2.27)$$

$$k = \text{argmax}_k (f(x)) \quad (2.28)$$

dimana α_i adalah alfa ke-i, y_i adalah kelas data latih ke-i, dan $K(x_i, x)$ adalah fungsi kernel dengan x adalah data uji, x_i adalah data latih ke-i dan b adalah bias.

Hasil perhitungan dari proses testing berupa nilai -1 dan 1. Setelah semua data pengujian dihitung dengan semua kelas yang ada maka untuk menentukan kelas dilakukan dengan

menghitung jumlah hasil perhitungan pengujian terbanyak masuk ke kelas yang bersesuaian.

K-Nearest Neighbor

K-Nearest Neighbor (KNN) juga salah satu teknik dalam *machine learning* untuk tugas pengklasifikasian objek berdasarkan kemiripan atribut-atributnya dengan cara menghitung jarak antara kelas referensi dengan objek yang diuji. Sesuai dengan namanya, esensi dari KNN adalah menghitung jarak satu objek yang diuji dengan objek-objek

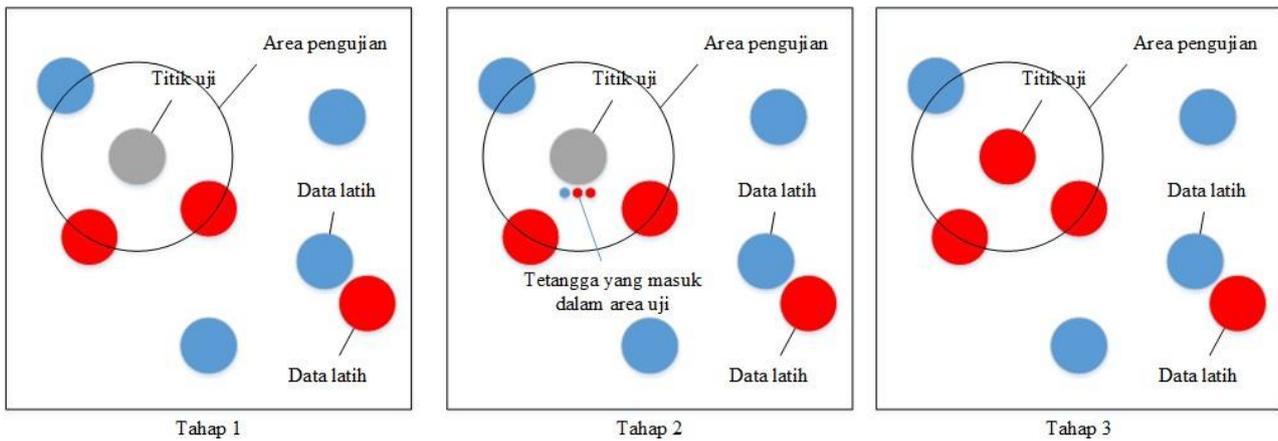
tetangga yang telah dikelompokkan ke dalam kelas masing-masing. Tetangga yang memiliki jarak terdekat dari objek yang diuji berhak mengklaim bahwa objek tersebut merupakan bagian dari kelompoknya. Pengujian jarak dilakukan dengan menggunakan Persamaan (2.29) dengan jumlah tetangga K sesuai dengan Persamaan (2.30) (Nadkarni, 2016).

$$d_{ii} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.29)$$

$$K = \sqrt{n} \quad (2.30)$$

dimana x_{ik} adalah nilai x pada objek pelatihan, x_{jk} adalah nilai x pada objek pengujian, n adalah jumlah objek, dan K adalah jumlah tetangga dan juga merupakan

hyperparameter KNN.



Gambar 4. Mekanisme KNN.

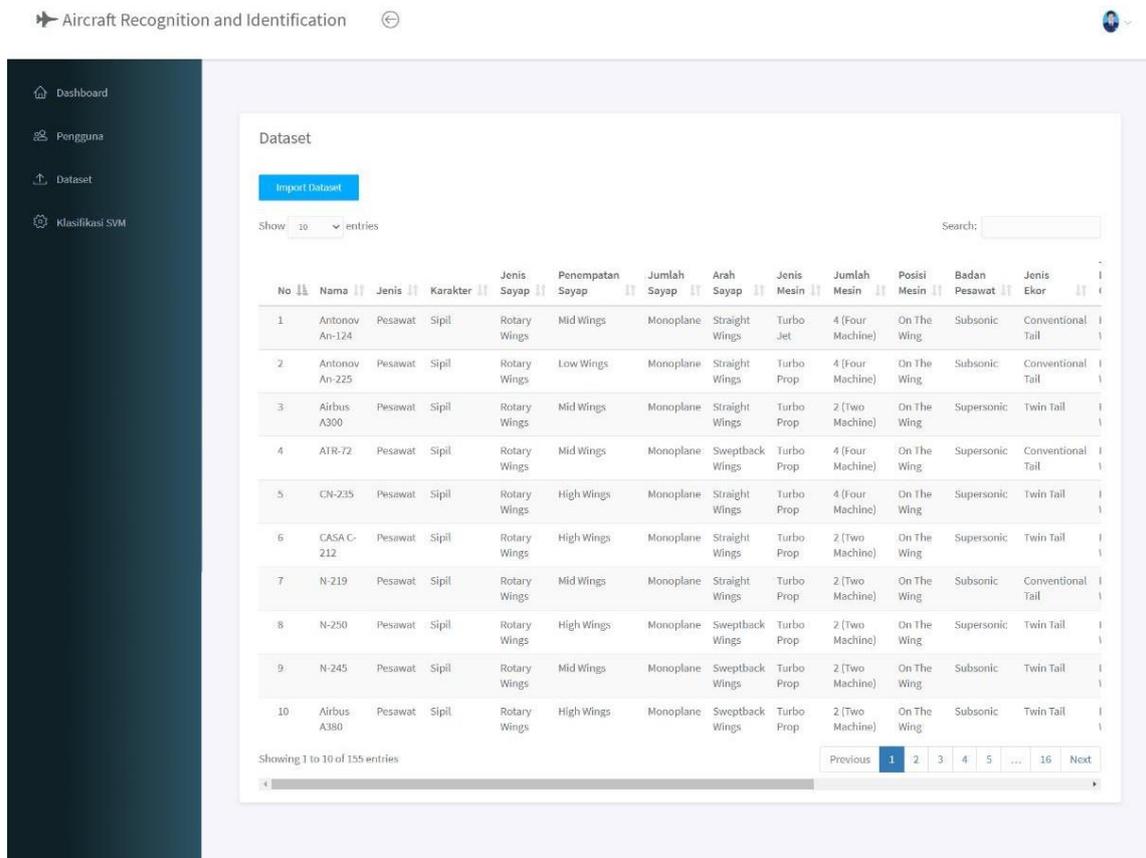
Mekanisme KNN adalah sebagai berikut:

1. Langkah 1 adalah menentukan letak titik uji yakni objek yang akan diuji. Selanjutnya menentukan jumlah tetangga terdekat (K) sebagai wilayah yang dilakukannya pengujian. Pada Gambar 6 terdapat tiga tetangga dimana dua tetangga adalah kelas berwarna merah dan satu tetangga adalah kelas berwarna biru.
2. Langkah 2 adalah menghitung jarak objek yang diuji dengan tetangga-tetangganya.
3. Langkah 3 objek yang diuji memiliki jarak terdekat dengan kelas berwarna merah. Maka objek yang diuji tersebut akan dimasukkan ke dalam kelas objek berwarna merah.

Penelitian mengenai pengenalan dan identifikasi objek udara khususnya pesawat udara militer menggunakan teknik-teknik AI dan *machine learning* tidak mudah ditemukan karena sifatnya yang khusus dengan pengguna yang spesifik yakni militer. Teknik-teknik berbasis jaringan syaraf dan pengembangannya yang digunakan untuk pengenalan dan identifikasi objek udara diantaranya menggunakan *Convolutional Neural Networks* (CNN) dengan data citra (Grosgeorge et al., 2020), untuk identifikasi

pesawat terbang tanpa awak menggunakan algoritma CenterNet (Tao et al., 2020), *Deep Convolutional Neural Network* (DCNN) dikombinasikan dengan *Principal Component Analysis* (PCA) untuk pemilihan fitur (Azam et al., 2021), dan jaringan *Single Shot multi-box Detector* (SSD) (Liu et al., 2020). Jaringan *Extreme Learning Machine* (ELM) (Zhao et al., 2021) dan *Region-based Convolutional Neural Networks* (RCNN) (Alshabani et al., 2021) juga telah digunakan untuk pengenalan dan identifikasi pesawat udara. Di sisi lain, penggunaan metode selain yang berbasis jaringan syaraf sangat jarang yang mana diantaranya adalah penggunaan SVM untuk pada sistem Radar (Choi et al., 2017) dan NBC yang dikombinasikan dengan fusi informasi (Sumari et al., 2022).

Dari hasil-hasil penelitian yang telah dilakukan dengan menggunakan metode BPN, NBC, SVM, dan KNN dengan jumlah objek pesawat udara sebanyak 155 buah pada rentang waktu November 2020 hingga Mei 2021 dengan menggunakan data teks yang dimasukkan ke dalam sistem. Tampilan basis data objek dan kinerja masing-masing metode diperlihatkan pada Gambar 5 dan Tabel 1.



Gambar 5. Tampilan basis data objek dalam sistem.

Tabel 1. Perbandingan kinerja metode-metode *machine learning*.

Metode	Jumlah Objek	Jumlah Fitur	Cara Klasifikasi	Akurasi Pengujian
BPN	155 (35 pesawat terbang sipil, 40 pesawat terbang sipil, 35 helikopter sipil, dan 40 helikopter militer)	13 → 5	Perbandingan	93,5%
NBC		9	Probabilitas	87,1%
SVM		12 ⇒ 10 + 2	<i>Hyperplane</i>	98,38%
KNN		13 → 7	Tetangga Terdekat	97%

Akurasi yang beragam dari masing-masing metode disebabkan pada teknik penyusunan fitur objek berdasarkan pada karakteristik-karakteristik objek untuk menyesuaikan cara pemasukan polanya. Simbol \rightarrow menunjukkan bahwa 13 fitur standar karakteristik objek difusikan menjadi 5 fitur yang dianggap paling representatif untuk BPN dan 7 fitur untuk

KNN, sedangkan simbol \Rightarrow menunjukkan

dilakukan pembagian kelompok fitur antara kelompok utama dan kelompok pendukung. Hal lain yang juga diperhitungkan adalah *hyperparameter* yang berbeda pada setiap metode dan memberi pengaruh signifikan pada akurasi baik pada pelatihan maupun pengujian.

KESIMPULAN

Berdasarkan dari survei dan penelitian yang telah dilakukan, dapat disimpulkan bahwa keempat metode *machine learning* yakni BPN, NBC, SVM, dan KNN prospektif digunakan sebagai inti dari I-VACR untuk pengenalan dan identifikasi pesawat udara militer berdasarkan pada data teks yang dimasukkan ke dalam sistem dari hasil pengamatan menggunakan binokular. Perbedaan kinerja masing-masing metode disebabkan karena perbedaan cara klasifikasi, jumlah dan macam

hyperparameter, dan fitur yang digunakan sebagai masukan. Dengan akurasi pengujian di atas 85%, keempat metode memberikan prospek untuk diaplikasikan pada sistem riil dan dioperasikan untuk mendukung sistem Radar. Langkah kedepan sedang dikerjakan saat ini dalam bentuk menggunakan data citra statis sebagai masukan bagi I-VACR untuk pengenalan dan identifikasi pesawat udara militer.

DAFTAR PUSTAKA

Abdullah, Usman, 2016. Sistem Cerdas untuk Klasifikasi Buah Kelapa Menggunakan Metode Backpropagation. Selondang Mayang 87-94.

Alshaibani, W.T., Helvaci, M., Shayea, I., Saad, S.A., Azizan, A., Yakub, F., Al-Shaibani, W.T., 2021. Airplane Type Identification Based on Mask RCNN and Drone Images. arXiv.org.

Azam, F., Rizvi, A., Khan, W.Z., Aalsalem, M.Y., Yu, H., Zikria, Y.B., 2021. Aircraft Classification Based on PCA and Feature Fusion Techniques in Convolutional Neural Network. IEEE Access 9, 161683-161694. <https://doi.org/10.1109/ACCESS.2021.3132062>

Choi, Y., Seol, S., Choi, I., 2017. Radar target

identification using a DTV-based

passive radar in South Korea, in: 2017 Progress in Electromagnetics Research Symposium - Fall (PIERS - FALL). pp. 892-895. <https://doi.org/10.1109/PIERS-FALL.2017.8293260>

Cortes, C., Vapnik, V., 1995. Support-vector Networks. *Machine Learning* 20, 273-297. <https://doi.org/10.1007/BF00994018>

Grosgeorge, D., Arbelot, M., Goupilleau, A., Ceillier, T., Allieux, R., 2020. Concurrent Segmentation and Object Detection CNNs for Aircraft Detection and Identification in Satellite Images, in: IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium. pp. 276-279. <https://doi.org/10.1109/IGARSS39084.2020.9323338>

Headquarters Department of the Army, 2017.

- TC 3-01.80 Visual Aircraft Recognition
Visual Aircraft Recognition.
- Kirsh, D., 2000. A Few Thoughts on Cognitive Overload. *Intellectica* 1, 19-51.
- Liu, J., Gangwu, J., Wang, X., Xu, B., Yu, P., 2020. Feature Extraction and Identification of Military Aircraft Based on Remote Sensing Image, in: *PervasiveHealth: Pervasive Computing Technologies for Healthcare*. Association for Computing Machinery, pp. 128-133. <https://doi.org/10.1145/3445815.3445837>
- Mcculloch, W.S., Pitts, W., 1990. A logical calculus on the ideas immanent in nervous activity. *Bulletin of Mathematical Biology* 52, 99-115.
- Muhamad, H., Prasojo, C.A., Sugianto, N.A., Surtiningsih, L., Cholissodin, I., 2017. Optimasi Naïve Bayes Classifier dengan Menggunakan Particle Swarm Optimization Pada Data Iris. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)* 4, 180-184.
- Nadkarni, P., 2016. Chapter 10 - Core Technologies: Data Mining and "Big Data," in: Nadkarni, P. (Ed.), *Clinical Research Computing*. Academic Press, pp. 187-204. <https://doi.org/https://doi.org/10.1016/B978-0-12-803130-8.00010-5>
- Nallusamy, T., Balaji, P., 2019. Optimization of NOE Flights Sensors and Their Integration, in: *Advances in Human and Machine Navigation Systems*. IntechOpen. <https://doi.org/10.5772/intechopen.86139>
- Prabowo, J.R., Santoso, R., Yasin, H., 2020. Implementasi Jaringan Syaraf Tiruan Backpropagation dengan Algoritma Conjugate Gradient untuk Klasifikasi Kondisi Rumah (Studi Kasus Di Kabupaten Cilacap Tahun 2018). *Jurnal Gaussian* 9, 41-49.
- Somantri, O., Khambali, M., 2017. Feature Selection Klasifikasi Kategori Cerita Pendek Menggunakan Naïve Bayes dan Algoritme Genetika, JNTETI.
- Sumari, A.D.W., Nugraheni, A.M., Yunhasnawa, Y., 2022. A Novel Approach for Recognition and Identification of Low-Level Flight Military Aircraft using *Naive Bayes Classifier* and Information Fusion. *International Journal of Artificial Intelligence Research (IJAIR)* 6, In Press.
- Tan, P.-N., Steinbach, M., Karpatne, A., Kumar, V., 2019. *Introduction to Data Mining*. Pearson.
- Tao, L., Hong, T., Guo, Y., Chen, H., Zhang, J., 2020. Drone identification based on CenterNet-TensorRT, in: *2020 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*. pp. 1-5. <https://doi.org/10.1109/BMSB49480.2020.9379645>
- Zhao, B., Tang, W., Pan, Y., Han, Y., Wang, W., 2021. Aircraft type recognition in remote sensing images: Bilinear discriminative *extreme learning machine* framework. *Electronics (Switzerland)* 10. <https://doi.org/10.3390/electronics10172046>