Scientific Journal of Radar
Vol. 12, No. 1, Spring and Summer2024, Serial No. 31, pp. 121- 142
ISSN: 2322-4347, E-ISSN: 2980-8979

A Review of Target Classification Methods in Ground-Based Surface Surveillance Radars

M. Moradbeigi, M. Farhang*, A. Sheikhi

* Associate Professor, Department of Telecommunications and Electronics, Electrical and Computer Engineering, Shiraz University, Shiraz, Iran

(Received: 2024/05/01, Revised: 2024/07/31, Accepted: 2024/08/24, Published: 2024/10/01)

DOR: https://dor.isc.ac/dor/ 20.1001.1.23454024.1403.12.1.10.3

ABSTRACT

Automatic Target Recognition (ATR) in Ground Surveillance Radar (GSR) systems is of paramount importance due to its critical applications across defense, security, and civilian domains. This paper provides a comprehensive review of the evolution of ATR systems, tracing their progression from foundational, manually engineered methods to modern advanced techniques, with a particular focus on machine learning (ML) and deep learning (DL) approaches. It analyzes a wide spectrum of features utilized for target classification, ranging from conventional descriptors—such as mean Radar Cross-Section (RCS) and micro-Doppler signatures—to complex representations automatically extracted by deep learning architectures, such as autoencoders. Furthermore, various target classification methodologies and major domain-specific challenges, including the scarcity of large-scale, high-quality datasets, are evaluated. Finally, a comparative analysis of different ATR techniques is presented in terms of classification performance, computational complexity, and implementation constraints, concluding with a discussion on emerging trends and future research directions in this field.

Keywords: Ground surveillance radar, target classification, neural networks, feature extraction

Cite this article: Moradbeigi, M., Farhang, M. & Sheikhi, A., "A Review of Target Classification Methods in Ground Surface Surveillance Radars." *Radar*, vol. 12, no. 1, pp. 121- 142. 2024.

DOR: https://dor.isc.ac/dor/ 20.1001.1.23454024.1403.12.1.10.3

© The Author(s). retain the copyright and full publishing rights

Publisher: Imam Hossein University

Corresponding Author Email: mfarhang@shirazu.ac.ir

"رادار"
سال دوازدهم، شماره ۱، بهار و تابستان ۱۴۰۳، ص ۱۲۱- ۱۴۲
شاپا الکترونیکی: ۴۰۲۴ -۲۳۴۵ شاپا چاپی: ۴۰۳۲ -۲۳۴۵

علمی – پژوهشی

مروری بر روش‌های دسته‌بندی اهداف در رادارهای مراقبت سطحی زمین پایه

مرتضی مرادبیگی[۱]، محمود فرهنگ[۲*]، عباس شیخی[۳]

۱- دانشجوی دکتری، ۲- دانشیار ۳- استاد، گروه مخابرات و الکترونیک، برق و کامپیوتر، دانشگاه شیراز، شیراز، ایران

(دریافت: ۱۴۰۳/۰۳/۰۴، بازنگری: ۱۴۰۳/۰۵/۲۷، پذیرش: ۱۴۰۳/۰۶/۰۱، انتشار: ۱۴۰۳/۰۶/۱۱)

DOR: https://dor.isc.ac/dor/ 20.1001.1.23454024.1403.12.1.10.3

چکیده

تشخیص و دسته‌بندی خودکار اهداف (ATR) در سامانه‌های رادار نظارتی زمینی به دلیل کاربردهای حیاتی در حوزه‌های دفاعی، امنیتی و غیرنظامی، از اهمیت بالایی برخوردار است. این مقاله، سیر تحول سامانه‌های ATR را از روش‌های اولیه و دستی تا تکنیک‌های پیشرفته امروزی، به‌ویژه رویکردهای مبتنی بر یادگیری ماشین و یادگیری عمیق، بررسی می‌کند. در این مقاله، ویژگی‌های مختلف مورداستفاده برای طبقه‌بندی اهداف، از جمله ویژگی‌های سنتی مانند متوسط سطح مقطع راداری (RCS) و اثرات میکرو - داپلر، و همچنین ویژگی‌های پیچیده‌ای که به‌صورت خودکار توسط مدل‌های یادگیری عمیق مانند خودرمزنگارها استخراج می‌شوند، مورد تحلیل و بررسی قرار می‌گیرد. همچنین، روش‌های طبقه‌بندی اهداف و چالش‌های کلیدی این حوزه، مانند کمبود داده‌های باکیفیت و بزرگ، ارزیابی می‌شوند. در نهایت، عملکرد، الزامات محاسباتی و محدودیت‌های پیاده‌سازی روش‌های مختلف ATR را به‌صورت مقایسه‌ای ارائه می‌دهد و به بحث در مورد آینده این حوزه پرداخته می‌شود.

کلیدواژه‌ها: رادار مراقبت زمینی، دسته‌بندی اهداف، شبکه‌های عصبی، استخراج ویژگی

۱. مقدمه

رادارهای مراقبت زمینی[1] که به طور خاص برای کشف و ردیابی اهداف متحرک زمینی مانند وسایل نقلیه، افراد و حیوانات طراحی شده‌اند، نقش حیاتی در امنیت مرزی، تشخیص نفوذ و آگاهی از میدان نبرد ایفا می‌کنند [۱]. در این سامانه‌ها، شناسایی خودکار اهداف[2] فراتر از یک کشف ساده، به شناسایی و طبقه‌بندی دقیق اهداف می‌پردازد تا امکان تصمیم‌گیری آگاهانه و کاهش خطرات ناشی از هشدارهای کاذب را فراهم آورد [۲]. درگذشته، عملیات دسته‌بندی در GSR به‌صورت دستی و بر اساس صدای داپلر اهداف از طریق مهارت‌های شنیداری اپراتورهای انسانی آموزش‌دیده انجام می‌شد که به دلیل وابستگی به تفسیر انسانی، کند و نامطمئن بود [۲]. این روش، باوجوداینکه درک اولیه‌ای از نوع و ماهیت هدف را فراهم می‌کرد، دارای محدودیت‌هایی در سرعت، ثبات و دقت بود که به‌ویژه در محیط‌های پیچیده و با اهداف متعدد، منجر به خطای بالایی می‌شد [۲]. نیاز به غلبه بر این محدودیت‌ها، نیروی محرکه اصلی برای توسعه شناسایی

[1] Ground surveillance radar (GSR)
[2] Atomatic Target Recognition (ATR)

استناد: مرادبیگی، مرتضی، فرهنگ، محمود و شیخی، عباس، "مروری بر روش‌های دسته بندی اهداف در رادارهای مراقبت سطحی زمینی." *رادار*، ۱۲(۱)، ۱۲۱- ۱۴۲، ۱۴۰۳.

DOR: https://dor.isc.ac/dor/ 20.1001.1.23454024.1403.12.1.10.3

© نویسنده(گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.

ناشر: دانشگاه جامع امام حسین(ع).

رایانامه نویسنده مسئول: mfarhang@shirazu.ac.ir

خودکار اهداف در سامانه‌های راداری شد.

تمرکز اصلی این مقاله بر GSR که عمدتاً رادارهایی با حد تفکیک در برد پایین و حد تفکیک در داپلر متوسط هستند، است. شایان‌ذکر است که سایر فناوری‌های راداری نیز به طور قابل‌توجهی به حوزه ATR کمک کرده‌اند، از جمله رادارهای روزنه ترکیبی[1] که تصاویر با وضوح‌بالا از اهداف ثابت ارائه می‌دهند [۳, ۴] و رادارهای با پروفایل برد با وضوح‌بالا[2] که اطلاعات ساختاری را فراهم می‌کنند [۵, ۶]؛ همانند رادارهای خودرویی که برای رانندگی خودران ضروری هستند [۷, ۸] که در این مقاله به آنها پرداخته نمی‌شود. بااین‌وجود، ATR با چالش‌های مهمی روبرو است. سیگنال‌های راداری در دنیای واقعی با بازتاب‌های پیچیده، تداخل و کلاتر دچار اختلال می‌شوند [۱]. علاوه بر این، کمبود مجموعه‌داده‌های بزرگ، باکیفیت و متنوع، یک مانع اصلی برای آموزش مدل‌های یادگیری عمیق در این حوزه باقی می‌ماند [۹]. این مقاله، روش‌شناسی‌های ATR برای رادارهای مراقبت زمینی را مرور کرده، انتقال از طراحی ویژگی‌های دستی به یادگیری عمیق داده‌محور را تحلیل می‌کند و خلاصه‌ای جامع از آخرین دستاوردهای این حوزه ارائه می‌دهد.

در این مقاله در بخش ۲ روش‌های استخراج ویژگی مورداستفاده در GSRها ارائه می‌گردد. در بخش ۳ انواع متداول روش‌های جداسازی اهداف در رادارهای زمینی معرفی می‌شوند. در بخش ۴ و ۵، چالش‌های دسته‌بندی اهداف و روش‌های تلفیق بررسی می‌شوند. در بخش ۶ نتیجه‌گیری و نگاهی به آینده دسته‌بندی اهداف مورد بحث واقع می‌شود.

۲. روش‌های استخراج ویژگی

یکی از قابلیت‌های کلیدی رادار GSR، توانایی آن در استخراج طیف داپلر اهداف است. این ویژگی به دلیل حرکت‌های منحصربه‌فرد هر هدف، امکان شناسایی آن‌ها را فراهم می‌کند. بااین‌حال، پدیده میکرو - داپلر[3] یک فرایند غیرایستا[4] است، هرچند می‌توان آن را در بازه‌های زمانی کوتاه، ایستا در نظر گرفت [۱۰]. ویژگی میکرو - داپلر، به طیف داپلر تولید شده ناشی از حرکات غیر از حرکت بدنه اصلی هدف اشاره می‌کنند. میکرو حرکات کوچک یک جسم و حتی حرکات قسمت‌هایی از یک هدف، مانند حرکت دست‌وپای انسان، ارتعاشات موتور خودرو، حرکت چرخ‌های موتورسیکلت و...، از طریق امضای میکرو - داپلر قابل‌مشاهده هستند.

[1] Synthetic aperture radar (SAR)
[2] High range resolution profile (HRRP)
[3] Micro Doppler
[4] Non-stationary

از نظر تاریخی، سامانه‌های شناسایی خودکار اهداف به شدت بر روی ویژگی‌های اصطلاحاً دست‌ساز[5] تکیه داشته‌اند. این ویژگی‌ها توسط متخصصان و بر اساس دانش خاص هر حوزه طراحی می‌شدند تا خصوصیات متمایز اهداف را به‌دقت نشان دهند [۱]. این روش، قبل از ظهور رویکردهای مبتنی بر یادگیری عمیق، اساس طبقه‌بندی اهداف در رادار را تشکیل می‌داد و اثربخشی آن به شدت به دانش طراحان و محیط موردنظر وابسته بود.

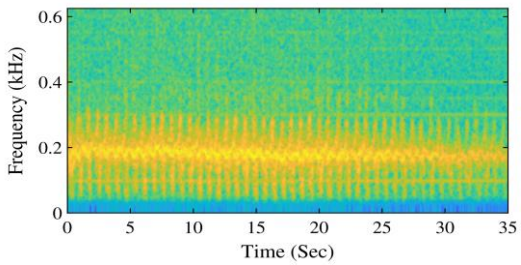
برای استخراج این ویژگی‌ها، از تبدیل‌های زمان - فرکانس به طور گسترده استفاده می‌شود که نقش مهمی در پردازش سیگنال‌های غیرایستا ایفا می‌کنند و عامل‌های حاصل از آن‌ها، ویژگی‌های خاصی از رفتار هدف را آشکار می‌سازند. در ادامه، روش‌های متداول استخراج ویژگی برای دسته‌بندی اهداف زمینی در رادارهای GSR بررسی خواهند شد.

۲-۱. محتوای طیفی طیف‌نگاشت[6]

طیف‌نگاشت یک نوع نمایش زمان - فرکانس است که از داده‌های خام راداری به دست می‌آید و می‌تواند رفتارهای متمایز از اهداف متفاوت را نشان دهد [۱۱]. طیف‌نگاشت سیگنال $x[n]$، به‌صورت رابطه (۱) تعریف می‌گردد [۱۲]:

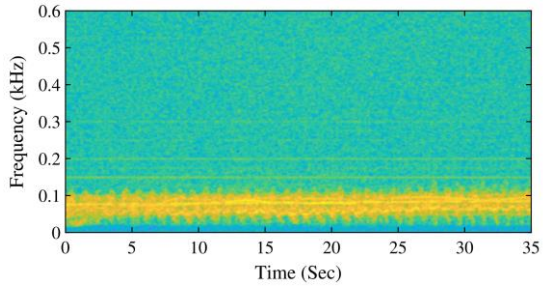
$$S[n,k]=\left|\sum_{r=-\infty}^{\infty}x[r]w[n-r]e^{-j2\pi rk/N}\right|^2, \quad k=0,1,\ldots,N-1 \qquad (1)$$

که n اندیس زمان گسسته، k اندیس فرکانس گسسته، N تعداد نقاط مورداستفاده در محاسبه تبدیل فوریه گسسته[7] و $w[n]$ تابع پنجره است. حد تفکیک طیف‌نگاشت به‌وسیله اندازه پنجره (N_w)، مشخص می‌شود. هر چه تابع پنجره کوچک‌تر باشد، حد تفکیک زمان بهتر و حد تفکیک فرکانس کمتر است. [۱۲, ۱۳]. محتوای طیفی سیگنال اکوی هدف به‌عنوان یکی از پرکاربردترین ویژگی‌ها در مأموریت دسته‌بندی اهداف رادار مورداستفاده قرار می‌گیرد. در شکل (۱) نمونه‌ای از طیف طیف‌نگاشت مربوط به سه نوع هدف زمینی را مشاهده می‌نمایید.

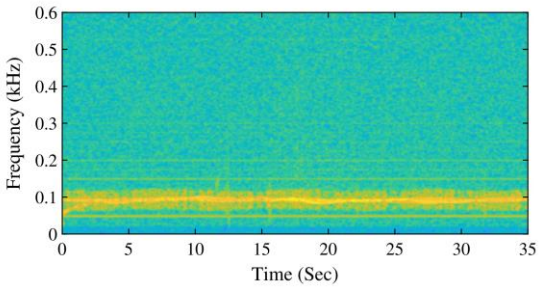


الف) انسان

[5] Hand-crafted features
[6] Spectrogram
[7] Discrete Fourier transform



ب) حیوان



ج) خودرو سواری

شکل (۱). نمونه‌ای از نمایش طیف‌نگاشت مربوط به هدف زمینی [۳۳].

۲-۲. ضرایب کپستروم

در [۱۴] ضرایب کپستروم[1] به‌عنوان یک ویژگی برای طبقه‌بندی اهداف استفاده شده است. کپستروم نتیجه‌ی گرفتن تبدیل فوریه معکوس[2] از طیف لگاریتم سیگنال است. انواع کپستروم‌ها به‌صورت کپستروم مختلط، حقیقی، توان و فازی هستند. کپستروم $c[n]$ سیگنال زمان گسسته $x[n]$ به‌صورت رابطه (۲) تعریف می‌شود.

$$c[n]=F^{-1}\left\{\log\left(\left|F\left\{x[n]\right\}\right|\right)\right\} \quad (۲)$$

که دراین‌رابطه F و F^{-1} به ترتیب، تبدیل فوریه گسسته و معکوس آن هستند.

روش MFCC[3] یک نوع دیگری از نمایش کپستروم است. در این روش به‌جای مقیاس خطی مقادیر فرکانس کپستروم عادی، از مقیاس لگاریتم در کپستروم فرکانس مل استفاده می‌شود که تقریب بهتری از پاسخ سیستم شنیداری انسان است. مقیاس لگاریتم برای نمایش اکوی سیگنال ناشی از رادار مراقبت زمینی پالس داپلر نیز بهتر است؛ زیرا بیشتر انرژی سیگنال در باندهای فرکانسی پایین است [۱۴]. در شکل (۲) ضرایب کپستروم مربوط به یک نفر پیاده، چندین نفر پیاده و خودرو سواری نشان‌داده‌شده است.

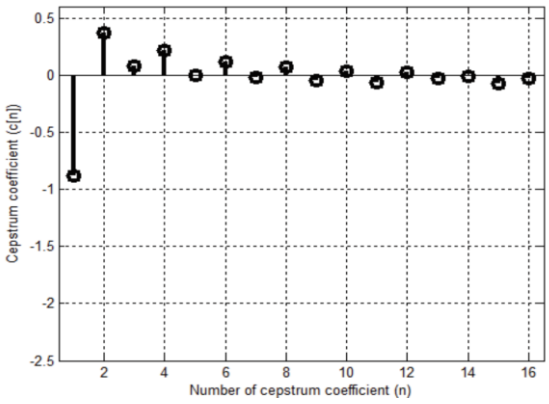
[1] Cepstrum
[2] Inverse Fourier Transform
[3] Mel frequency cepstrum coefficient

۲-۳. سطح مقطع راداری[4]

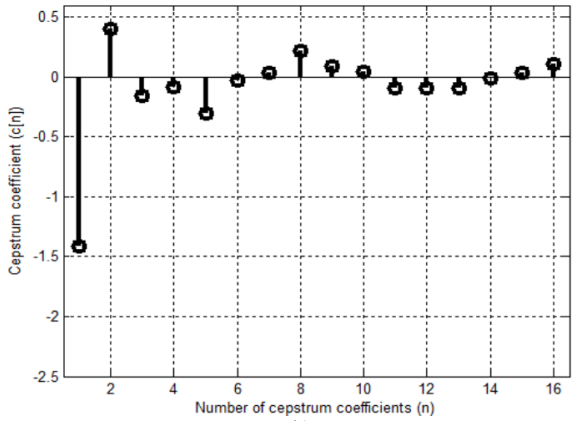
یکی از اساسی‌ترین و پرکاربردترین ویژگی‌ها برای طبقه‌بندی اهداف در رادار، سطح مقطع راداری است. این ویژگی، میزان شدت بازتاب سیگنال‌های راداری از یک هدف را کمی‌سازی می‌کند [۱۵].

RCS یک مقدار ثابت نیست، بلکه به‌شدت نوسانی است و تحت‌تأثیر تغییرات عواملی مانند شکل، اندازه و جهت‌گیری هدف قرار می‌گیرد [۱۵]. این نوسان ذاتی، هم یک چالش و هم یک فرصت برای طبقه‌بندی است. برای استفاده در طبقه‌بندی، از دنباله‌های RCS می‌توان ویژگی‌های مختلفی استخراج کرد که به‌طورکلی به دودسته تقسیم می‌شوند:

ویژگی‌های آماری: این ویژگی‌ها شامل میانگین[5]، واریانس[6]، چولگی[7] و کشیدگی[8] هستند و خصوصیات توزیع کلی مقادیر

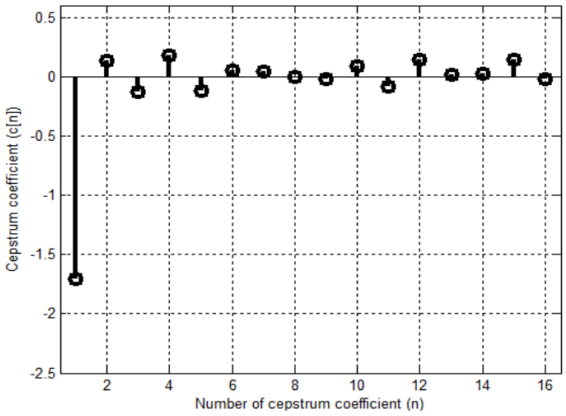


الف) یک نفر پیاده



ب) چندین نفر پیاده

[4] Radar Cross Section (RCS)
[5] Mean
[6] Variance
[7] Skewness
[8] Kurtosis



ج) خودرو سواری

شکل (۲). ضرایب کپستروم مربوط سه نوع هدف زمینی الف: یک نفر پیاده، ب: چندین نفر پیاده و ج: خودرو سواری [۱۵].

RCS را نشان می‌دهند. میانگین بیانگر مقدار متوسط و کلی دنباله‌ی RCS در طول زمان است. در مقابل، واریانس میزان نوسان و تغییرپذیری RCS را حول میانگین آن نشان می‌دهد. در نهایت، چولگی و کشیدگی به‌عنوان آمارگان مرتبه بالاتر شناخته می‌شوند و شکل کامل‌تر توزیع احتمال دنباله‌ی RCS را توصیف می‌کنند؛ کشیدگی، میزان قله‌ای بودن یا سنگینی دنباله‌ها را مشخص می‌سازد که اطلاعات غنی‌تر و بیشتری از ویژگی‌های آماری RCS هدف نسبت به میانگین و واریانس برای تمایز هدف استخراج می‌کنند. این ویژگی‌ها می‌توانند با استفاده از معیارهایی مانند واگرایی کولبک - لایبلر[1] (KL) برای مقایسه دنباله‌ها مورد تحلیل قرار گیرند [۱۶]. در بخش ۱۲.۲ در خصوص این دو ویژگی توضیحات بیشتری ارائه می‌گردد.

ویژگی‌های پویا: این ویژگی‌ها بر الگوهای تغییر RCS در طول زمان تمرکز دارند. این ویژگی‌ها منعکس‌کننده‌ی الگوهای تغییرپذیری زمانی[2] RCS هستند. این ویژگی‌ها، اطلاعاتی فراتر از ویژگی‌های آماری (مانند میانگین و واریانس) ارائه می‌دهند و نشان می‌دهند که چگونه دنباله‌ی RCS در طول زمان در حال نوسان و تغییر است. در [۱۶]، برای استخراج این ویژگی‌ها از توزیع الگوهای متغیر[3] دنباله‌ی RCS استفاده شده است که به طور مؤثری دینامیک‌های پنهان هدف را برای تمایز بهتر ثبت می‌کنند.

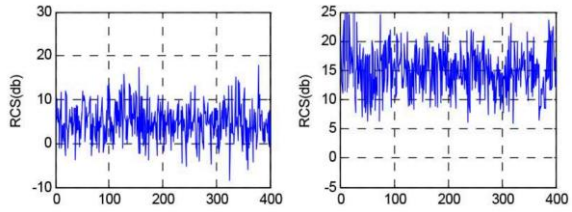
در رادارهای GSR، RCS همچنان یک ویژگی اصلی برای شناسایی انواع اهداف از جمله انسان، حیوانات و انواع خودروهای سبک‌وسنگین محسوب می‌شود [۱۶]. متوسط سطح مقطع راداری نفر پیاده m^2 ۱، خودرو سبک m^2 ۱۰ و خودرو سنگین و تانک m^2 ۱۰۰ است. در شکل (۳) چندین مدل دنباله RCS مربوط به انواع هدف را مشاهده می‌نمایید [۱۶].

۲-۴. تبدیل چرپلت[4] و گشتاورهای زرنیک[5]

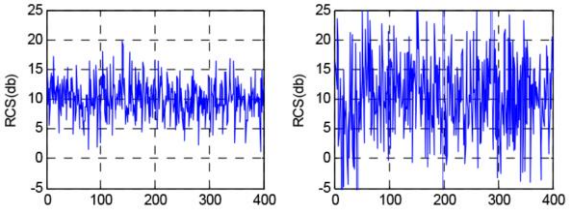
در مبحث دسته‌بندی اهداف زمینی، به‌ویژه با استفاده از داده‌های رادار پالس داپلر نظارت زمینی با وضوح پایین، می‌توان از تبدیل چرپلت و گشتاورهای زرنیک به‌عنوان ویژگی‌هایی کارآمد بهره برد. تبدیل چرپلت به این دلیل انتخاب می‌شود که سیگنال‌های داپلر حاصل از حرکت اهدافی چون انسان، وسایل نقلیه چرخ‌دار و حیوانات، سیگنال‌هایی غیرایستا هستند. تبدیل چرپلت می‌تواند این سیگنال‌های غیرایستا را به مجموعه‌ای از توابع پایه چرپلت تجزیه کند و ساختارهای زمان - فرکانس محلی شده‌ی آن‌ها را به طور مؤثری ثبت و استخراج نماید [۱۸].

دنباله زمانی گسسته سیگنال دریافتی رادار که شامل تعداد q چرپلت است به‌صورت زیر نمایش داده می‌شود:

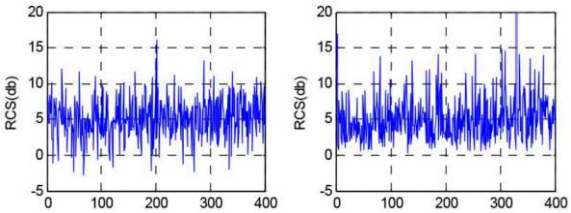
که در آن a_k دامنه سیگنال برگشتی، τ موقعیت در زمان، ω_k موقعیت در فرکانس، α_k نرخ چرپ که $0<\alpha,\omega<2\pi$ و β_k کنترل‌کننده مدت‌زمان چرپلت شماره q است [۱۷]. در شکل (۴) نمونه‌ای از تبدیل چرپلت یک سیگنال شبیه‌سازی شده قابل‌مشاهده است.



الف: دو دنباله RCS با میانگین متفاوت

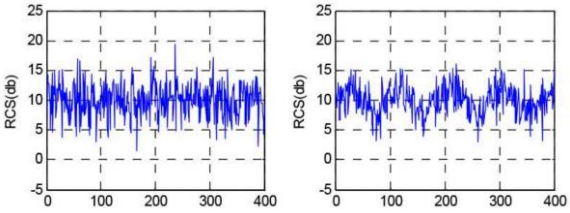


ب: دو دنباله RCS با واریانس متفاوت



ج: دو دنباله RCS با آمارگان مرتبه بالاتر متفاوت

[1] Kolback-Leibler divergence
[2] Temporal variation patterns
[3] Varying patterns
[4] Chirplet transform
[5] Zernike moments

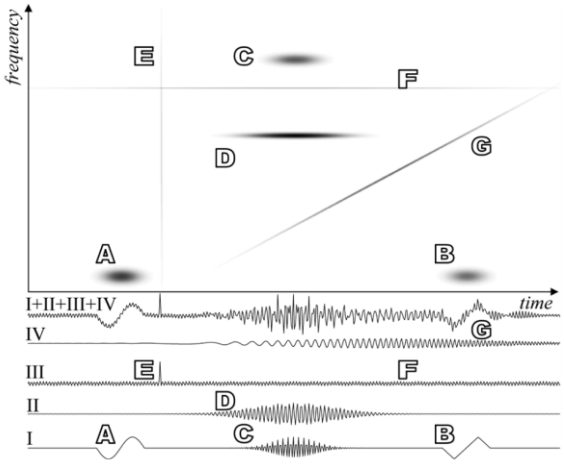


د: دو دنباله RCS با رفتار متناوب و غیرمتناوب

شکل (۳). چندین مدل دنباله RCS [۱۶].

$$X[n]=\sum_{k=1}^{q}a_k e^{-\frac{\beta_k (n-\tau_k)^2}{2}+j\frac{\alpha_k (n-\tau_k)^2}{2}+j\omega_k (n-\tau_k)^2} \qquad (۳)$$

در مرحله بعد، برای استخراج ویژگی‌های متمایز و قابل‌اعتماد برای دسته‌بندی، از گشتاورهای زرنیک استفاده می‌شود. تبدیل چرپلت، نمایش سیگنال در صفحه زمان - فرکانس را به یک تصویر دوبعدی تبدیل می‌کند و گشتاورهای زرنیک بر روی عامل‌های چرپلت یا همین تصویر زمان - فرکانس اعمال می‌شوند تا ویژگی‌های مرتبط تعیین گردند. مهم‌ترین مزیت گشتاورهای زرنیک این است که آن‌ها ویژگی‌هایی با عدم تغییرپذیری نسبت به چرخش[1] هدف، ایجاد می‌کنند. این ویژگی باعث می‌شود که الگوریتم دسته‌بندی نهایی در برابر تغییرات سرعت و جهت‌گیری[2] هدف مقاومت و عدم تغییرپذیری بالایی داشته باشد، در نتیجه یک رویکرد مؤثر برای تشخیص هدف زمینی فراهم می‌شود [۱۸].



شکل (۴). تبدیل چرپلت سیگنال شبیه‌سازی شده متشکل از مجموع چندین سیگنال [۱۸].

۲-۵. توزیع ویگنر ویل[3]

توزیع ویگنر - ویل یک ابزار کلیدی برای تحلیل و استخراج ویژگی از سیگنال‌های غیرایستای راداری، به‌ویژه جهت دسته‌بندی اهداف زمینی است. WVD، سیگنال داپلر هدف را به یک تصویر دوبعدی در صفحه زمان - فرکانس تبدیل می‌کند که الگوی انرژی سیگنال را بر حسب زمان و فرکانس لحظه‌ای نمایش می‌دهد.

به دلیل احتمال وجود ارتباط فاز بین هارمونیک‌های سیگنال، طیف‌های توان و انرژی، توانایی استخراج فرکانس‌های با فاز مرتبط[4] را دارا نمی‌باشند. به بیان دیگر طیف‌های توان و انرژی، قادر به جداسازی فرکانس‌های لحظه‌ای با فاز مرتبط که در دنباله زمانی در حال پردازش موجود هستند، نمی‌باشند. این خاصیت مهم‌ترین نقطه‌ضعف تخمین‌گرهای طیف توان است [۱۹].

توزیع ویگنر - ویل[5] و نمونه‌های اصلاح شده آن با کرنل‌های مختلف یک ابزار تخمین بهینه سیگنال‌های LFM[6] که به‌صورت گسترده در کاربردهای راداری استفاده می‌شوند، هستند [۱۹].

در مبحث دسته‌بندی اهداف، از خود تصویر زمان - فرکانس WVDیا ویژگی‌های خاص استخراج شده از آن به‌عنوان ویژگی استفاده می‌شود:

۱. ویژگی‌های مبتنی بر تصویر[7]: در برخی روش‌ها، خود تصویر زمان - فرکانس[8] حاصل ازWVD که نمایشگر الگوی میکرو - داپلر هدف (حرکت اندام‌ها در انسان یا بخش‌های چرخنده در وسایل نقلیه) است، پس از کاهش ابعاد، مستقیماً به‌عنوان بردار ویژگی برای دسته‌بندی استفاده می‌شود.

۲. ویژگی‌های استخراجی: برای دستیابی به ویژگی‌های با ابعاد کمتر و مقاوم‌تر، ویژگی‌های آماری یا هندسی خاصی از روی نقشه WVD استخراج می‌شوند. مهم‌ترین این ویژگی‌ها شامل استخراج فرکانس‌های لحظه‌ای[9] و الگوی انرژی حول آن‌هاست. همچنین، می‌توان از گشتاورهای آماری[10] یا گشتاورهای تصویری[11] مانند گشتاورهای زرنیک برای ثبت شکل توزیع انرژی و ساخت یک بردار ویژگی با ابعاد کم و مقاوم استفاده کرد.

مزیت اصل توزیع ویگنر که از ویژگی‌های مرسوم تحلیل دو طیفی (نوعی تحلیل آماری مرتبه بالا که روابط فازی بین مؤلفه‌های فرکانسی را حفظ و استخراج می‌کند) تبعیت می‌کند و به‌صورت مفصل در [۲۰] توضیح داده شده است، کیفیت این ویژگی‌های استخراجی را تضمین می‌کند: ۱. حساسیت پایین

[1] Rotation Invariant
[2] Orientation
[3] Wigner-Ville Distribution (WVD)

[4] Phased-coupled frequencies
[5] Winger-Ville distribution
[6] Linearly frequency modulated
[7] Map based features
[8] Time-frequency image
[9] Instantaneous frequencies
[10] Statistical moments
[11] Image moments

نسبت به نویزهای جمع‌شونده با توزیع متقارن، این ویژگی اجازه کاهش اثرات نویز را می‌دهد. ۲. عدم حساسیت نسبت به جابه‌جایی یا چرخش، این ویژگی اجازه حذف نویزهای حرکت ناشی از جابه‌جایی یا چرخش هدف را می‌دهد. ۳. آشکارسازی مقاوم مؤلفه‌های طیف فوریه که از لحاظ فاز با یکدیگر مرتبط هستند، از مؤلفه‌هایی که دارای فاز مرتبط نمی‌باشند. این خصوصیت برای استخراج دقیق فرکانس‌های لحظه‌ای میکرو داپلر که بر تمایز اهداف زمینی تکیه دارد، بسیار حیاتی است.

بااین‌حال یکی از مهم‌ترین نقاط ضعف این توزیع‌ها وجود تعداد زیاد سیگنال‌های ناخواسته[1] هنگام پردازش سیگنال‌های FMغیرخطی و یا چندمولفه‌ای است. این اسپورها می‌توانند ویژگی‌های واقعی سیگنال مورد بررسی را بپوشانند. همچنین، توزیع‌های مرتبه بالاتر ویگنر دارای عیب‌های جدی هستند که ازآن‌جمله می‌توان به پیچیدگی محاسباتی زیاد و نرخ‌پردازش پایین نام برد [۱۹].

۲-۶. بردارهای ویژه

تجزیه به مقادیر ویژه[2] یک روش مؤثر و مقاوم جهت تجزیه هر ماتریس به فضایی با پایه‌های متعامد است [۲۱]. در بین مقادیر ویژه به‌دست‌آمده، مقدار ویژه بزرگ‌تر نشانگر سهم بیشتر بردار ویژه متناظر با آن در ساخت سیگنال هدف است. در [۲۱] نشان‌داده‌شده است که بردارهای ویژه متناظر با بزرگ‌ترین مقدار ویژه بیش از ٪۹۰ انرژی هدف را در بردارند و می‌توان از آن‌ها در جهت شناسایی اهداف استفاده نمود.

۲-۷. ضرایب تجزیه بسته موجک

روش تحلیل بسته موجک[3] یک ابزار قدرتمند برای استخراج ویژگی از سیگنال‌های غیرایستای راداری است که برای دسته‌بندی اهداف به کار می‌رود. ابتدا هر سیگنال به زیر سیگنال‌های تجزیه بسته موجک[4] تقسیم می‌گردد. بسته‌های موجک تعمیمی از پایه‌های موجک با درنظرگرفتن ترکیبات خطی توابع موجک هستند. یک تابع موجک دارای سه شاخص است: jاندیس مقیاس[5]، k اندیس انتقال[6] و n عامل نوسان[7] است:

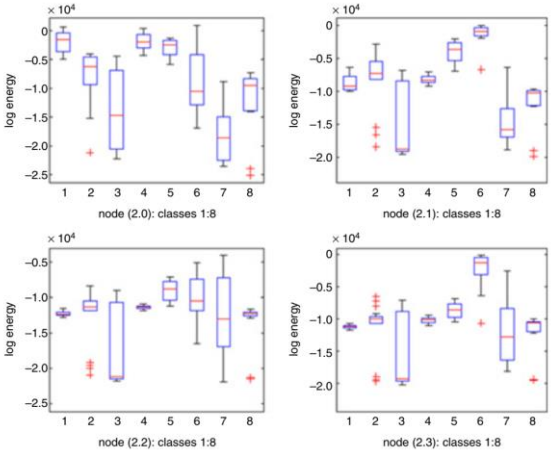
$$W_{j,k}^{n} = 2^{j/2} W^{n}\left(2^{j}t - k\right) \qquad (۴)$$

این تجزیه به معنی تقسیم طیف سیگنال به چندین کانال فرکانسی با تفکیک‌پذیری بالا است. پس از آن، برای ساخت بردار ویژگی‌های متمایز و قابل‌استفاده برای دسته‌بندی، ویژگی‌ها استخراج می‌گردند. این ویژگی‌های استخراجی، اطلاعات آماری و انرژی هر زیرباند فرکانسی[8] از سیگنال را به‌صورت عددی خلاصه می‌کنند. این ویژگی‌ها شامل آنتروپی لگاریتم انرژی[9] (۵) و آنتروپی نرم[10] (۶) می‌شوند [۲۴].

$$E = \sum_{n} \log\left(W_{j,n}^{n2}\right) \qquad (۵)$$

$$E = \sum_{n} \left|W_{j,n}^{2}\right|^{p}, \quad 1 \le p \qquad (۶)$$

این ویژگی‌ها، میزان پراکندگی و توزیع انرژی را در زیربندهای مختلف فرکانسی (که هر کدام ممکن است با حرکت یک بخش خاص از هدف زمینی مرتبط باشد) کمی‌سازی می‌کنند. در نهایت، این بردار ویژگی (شامل آنتروپی‌های استخراج شده از زیربندها) به یک جداساز (مانند شبکه‌های عصبی) داده می‌شود تا عمل تشخیص و تمایز اهداف زمینی انجام شود [۲۵]. در شکل (۵) نمایش لگاریتم انرژی در تجزیه بسته موجک مربوط به اهداف زمینی را مشاهده می‌کنید.



شکل (۵). نمایش لگاریتم انرژی در تجزیه بسته موجک مربوط به اهداف زمینی [۲۴].

روش تحلیل بسته موجک با فراهم‌سازی حد تفکیک زمان - فرکانس دلخواه[11]، تحلیل سیگنال‌های با طبیعت غیرایستا را ممکن می‌سازد. این روش دارای نمایش زمانی بهتری نسبت به تحلیل فوریه و حد تفکیک فرکانسی بهتری نسبت به تحلیل موجک است [۲۴]. این قابلیت بسیار مهم است، زیرا سیگنال‌های داپلر اهداف زمینی، مانند حرکات چرخ‌ها یا اندام‌های بدن ساختارهای زمان - فرکانس محلی شده‌ای دارند که به تفکیک هم در زمان و هم در فرکانس نیاز دارند.

[1] Spurious signals
[2] Singular Value decomposition (SVD)
[3] Wavelet packet analysis (WPA)
[4] Wavelet packet decomposition (WPD)
[5] Scale indece
[6] Translation indice
[7] Oscilation parameter
[8] Sub-band
[9] Log Energy Entropy
[10] Norm Entropy
[11] Arbitrary time-frequency resolution

۲-۸. ضریب‌های مدل خود هم‌بسته[1]

ضریب‌های مدل خود همبسته که از توابع خودهمبستگی سیگنال استخراج می‌شوند، به‌عنوان ویژگی‌های کلیدی در مبحث دسته‌بندی اهداف زمینی در GSR، بر اساس روش پیشگویی زمانی به کار می‌روند.

ایده اصلی دسته‌بندی بر اساس پیشگویی زمانی این است که اگر ما بتوانیم مقادیر آینده سیگنال مربوط به یک کلاس مشخص را به وسیله‌ی مدل پیشگو[2] به طور دقیق و با خطای کم پیش‌بینی کنیم، آن‌گاه آن سیگنال متعلق به آن کلاس خواهد بود. مدل‌های AR، از طریق استخراج ضریب‌های AR، این تابع پیشگویی را بر اساس رابطه سیگنال با خودش در زمان‌های گذشته (همان خودهمبستگی) پیاده‌سازی می‌کنند. این ضرایب AR که الگوی تکراری و دینامیکی سیگنال داپلر (به‌ویژه سیگنال‌های صوتی رادار) را توصیف می‌کنند، به‌عنوان بردار ویژگی خطی[3] هدف عمل می‌کنند و به الگوریتم جداساز داده می‌شوند. دو روش شناخته شده تخمین AR مدنظر قرار گرفته است: ۱- تکنیک حداقل مربعات[4] که برای سیگنال‌های با توزیع گوسی بهینه است و ۲- تکنیک کومولانت[5] که برای سیگنال‌های غیرگوسی بهتر است. در این راستا، ضرایب استخراج شده با این روش‌ها، خواص آماری و دینامیکی منحصربه‌فرد هر هدف (مانند تانک، خودرو، یا انسان در حال راه‌رفتن) را در خود فشرده می‌کنند و ابزاری کارآمد برای تمایز اهداف در سامانه‌های تشخیص خودکار راداری فراهم می‌آورند [۲].

۲-۹. آمارگان مرتبه بالاتر[6]

برخلاف آمارگان مرتبه دوم، الگوریتم آمارگان مرتبه بالاتر بر مبنای استفاده از ممان طیف مرتبه بالاتر[7] برای تحلیل مشخصات فرایند تصادفی است [۲۷،۲۶]. از جمله فواید این تکنیک می‌توان به کاهش اثر نویز گوسی، کاهش لوب‌های کناری، بازسازی مناسب فاز سیگنال و شناسایی مشخصات رفتار غیرخطی داده‌ها، اشاره کرد. الگوریتم‌های مبتنی بر HOS به دلیل مقاومت در برابر نویزهای گوسی و توانمندی در مدل‌سازی کانال‌های غیرخطی، ابزاری ایدئال برای تحلیل سیگنال‌های غیرگوسی در محیط‌های عملیاتی رادار هستند [۲۷].

کاربرد اصلی HOS در این حوزه، استخراج اطلاعات فاز و سرکوب نویزهایی است که آمارگان مرتبه دوم (مانند طیف توان) قادر به انجام آن نیستند. از جمله فواید این تکنیک می‌توان به کاهش اثر نویز گوسی (به دلیل صفر بودن کومولانت‌های مرتبه بالاتر نویز گوسی)، کاهش لوب‌های کناری، بازسازی مناسب فاز سیگنال و شناسایی مشخصات رفتار غیرخطی داده‌ها، اشاره کرد. این مزیت‌ها در تحلیل سیگنال‌های میکرو - داپلر حاصل از حرکت اندام‌های انسان یا بخش‌های چرخنده خودروها که اغلب غیرگوسی و غیرخطی هستند، حیاتی است.

در نهایت، کومولانت‌های مرتبه سوم یا چهارم سیگنال به‌عنوان بردار ویژگی به الگوریتم جداساز داده می‌شوند تا اهداف زمینی را بر اساس خواص غیرخطی و غیرگوسی سیگنال آن‌ها از یکدیگر متمایز سازند.

۲-۱۰. ماتریس کواریانس[8]

ماتریس کواریانس در مبحث دسته‌بندی اهداف زمینی در GSR، نقشی دوگانه ایفا می‌کند: اول به‌عنوان یک توصیفگر ویژگی ساختاری مقاوم[9] و دوم به‌عنوان هسته یک دسته‌بند هندسی[10]. آقای پراکلی و همکاران روش ماتریس کوواریانس را به‌عنوان روش جدید توصیف نواحی تصویر معرفی کردند و نشان دادند که این روش نسبت به سایر روش‌های دسته‌بندی تصاویر برتری دارد [۴۵]. این برتری به‌واسطه‌ی توانایی ماتریس در ثبت ساختار آماری سیگنال است. ماتریس کوواریانس چندین ویژگی را که ممکن است همبسته باشند با یکدیگر ترکیب می‌کند. عناصر روی قطر اصلی ماتریس کوواریانس بیانگر واریانس هر ویژگی و عناصر غیر قطر اصلی نشانگر همبستگی بین ویژگی‌ها هستند. دانستن همبستگی بین این ویژگی‌ها، یک ویژگی مهم سیگنال‌های راداری است. در نهایت میانگین‌گیری در فرایند محاسبه کوواریانس، نویز را فیلتر می‌کند [۴۵].

در این رویکرد، فرایند دسته‌بندی بر مبنای خود ماتریس کواریانس استوار است؛ به این صورت که ماتریس کوواریانس هدف ناشناس به‌عنوان بردار ویژگی نهایی در نظر گرفته می‌شود و هدف به کلاسی تخصیص داده می‌شود که با ماتریس کوواریانس نمونه اولیه آن کلاس کمترین فاصله را با آن داشته باشد [۴۵].

۲-۱۱. تموج[11] و پهنای باند تموج

در سامانه‌های شناسایی هدف راداری، تحلیل الگوی زمانی نوسان سیگنال بازگشتی از هدف (تموج هدف)، و کمیت‌سازی آن از طریق پهنای باند نوسان، به‌عنوان یک دسته ویژگی با مبنای

[1] Auto regressive (AR) coefficient
[2] Predictive model
[3] Linear feature vector
[4] Least squares
[5] Cumulant
[6] Higher order statistic (HOS)
[7] Higher order moment spectra
[8] Covariance matrix
[9] Robust structural feature descriptor
[10] Geometric classifier core
[11] Fluctuation

فیزیکی و مکمل مطرح شده است. این نوسانات که در دامنه و فاز سیگنال راداری ظاهر می‌شوند، برآیند مستقیم دینامیک هدف و پیچیدگی الکترومغناطیسی آن هستند. عواملی مانند تداخل سازنده و مخرب پرتوهای بازگشتی از پراکنده‌کننده‌های[1] متعدد روی هدف (پدیده درخشش[2])، ارتعاشات مکانیکی (مانند لرزش موتور) و به‌ویژه حرکت‌های ریز[3] مانند چرخش پره‌های توربین‌جت یا ملخ‌ها، الگوهای نوسان متمایز و تکرارپذیری را ایجاد می‌کنند. ازاین‌رو، این نوسانات دیگر نویز محسوب نمی‌شوند، بلکه حامل اطلاعاتی ارزشمند از ساختار و حالت دینامیکی هدف هستند [۶۳].

پهنای باند نوسان به‌عنوان معیاری برای نرخ تغییرات زمانی عمل می‌کند و اطلاعات کلیدی را فراهم می‌سازد. یک هدف ساده و صلب (مانند یک کره) نوسانات آرامی با پهنای باند باریک دارد، درحالی‌که یک هدف با دینامیک پیچیده (مانند یک هواپیمای بال ثابت با موتورهای در حال کار یا یک پهپاد چند پره) به دلیل اجزای متحرک، سیگنالی با نوسان سریع و پهنای باند وسیع‌تر تولید می‌کند. استخراج ویژگی‌هایی همچون زمان همبستگی سیگنال، گسترش طیفی چگالی توان نوسانات و گشتاورهای تصویر زمان - فرکانس، امکان تمایز بین اهدافی با ابعاد مشابه اما ساختارهای مکانیکی متفاوت را فراهم می‌آورد. با ادغام این ویژگی‌های مبتنی بر نوسان در چارچوب پردازش سیگنال پیشرفته و طبقه‌بندهای یادگیری ماشین، قابلیت اطمینان و دقت سامانه‌های شناسایی هدف راداری غیر همکار به طور چشمگیری ارتقا می‌یابد [۶۳].

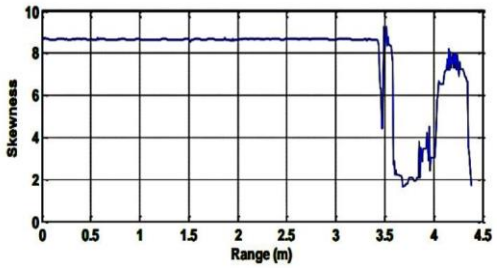
۲-۱۲. کشیدگی و چولگی

در پردازش سیگنال‌های راداری، استخراج ویژگی‌های آماری پیشرفته از توزیع سیگنال بازگشتی؛ به‌ویژه در حوزه شناسایی اهداف غیر همکار؛ نقش حیاتی ایفا می‌کند. در این میان، میزان کشیدگی و چولگی به‌عنوان گشتاورهای آماری مرتبه‌ی سوم و چهارم، ابزارهای قدرتمندی برای کمّی‌سازی رفتار غیرگوسی سیگنال هدف هستند. برخلاف اهداف ساده یا کلاتر[4] که توزیع دامنه‌ی سیگنال آن‌ها اغلب به توزیع رایلی یا ویبول نزدیک است، اهداف پیچیده (مانند هواپیما، وسایل نقلیه) به دلیل وجود چندین پراکنده‌کننده‌ی قوی و پدیده‌هایی چون درخشش، اغلب سیگنال‌هایی با توزیع‌های دنباله‌دار سنگین[5] تولید می‌کنند [۶۴-۶۵].

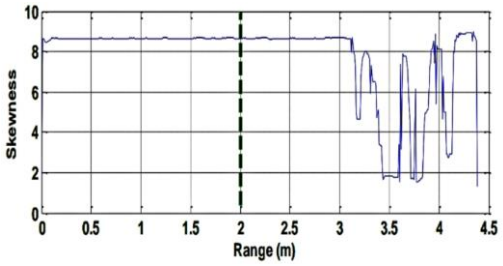
میزان کشیدگی بالا نشان‌دهنده‌ی دم‌های سنگین در توزیع دامنه است که به معنی وقوع مکرر نمونه‌های با دامنه‌ی بسیار زیاد (پالس‌های قوی ناشی از تداخل سازنده) در کنار نمونه‌های با دامنه‌ی متوسط است [۶۵]. ازسوی‌دیگر، میزان تقارن، چولگی احتمالی توزیع را اندازه‌گیری می‌کند که می‌تواند ناشی از غالب‌بودن یک یا چند پراکنده‌کننده در یک سمت هندسی هدف باشد [۶۴].

این ویژگی‌های آماری، اطلاعاتی مرتبط با ساختار فیزیکی و هندسه الکترومغناطیسی هدف ارائه می‌دهند. به‌عنوان‌مثال، یک هدف کشیده با پراکنده‌کننده‌های غالب در دو انتها (مانند یک موشک)، ممکن است در زوایای معین توزیع دامنه‌ای با تقارن خاصی از خود نشان دهد. در مقابل، یک هدف متقارن مدور (مانند مخزن کروی) ممکن است توزیع متقارن‌تری داشته باشد. به طور مشابه، هدفی با تعداد زیادی پراکنده‌کننده‌ی باقدرت مشابه (مانند یک کلاتر) توزیعی نزدیک به رایلی و در نتیجه کشیدگی پایین دارد، درحالی‌که هدفی با چند نقطه‌ی درخشان غالب (مانند یک هواپیمای جنگنده) توزیعی با دنباله‌های سنگین و کشیدگی بالا را ایجاد می‌کند. این ویژگی‌ها عموماً نسبت به جابه‌جایی‌های کوچک در زاویه‌ی دید، نویز و حتی برخی تغییرات در حد تفکیک رادار، مقاوم‌تر از ویژگی‌های منحصراً مبتنی بر شکل (مانند پروفایل برد یا وضوح‌بالا) هستند.

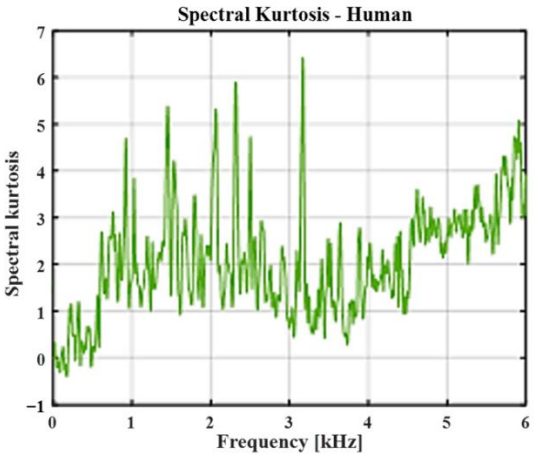
در سامانه‌های شناسایی هدف، میزان کشیدگی و چولگی معمولاً به‌تنهایی استفاده نمی‌شوند، بلکه به‌عنوان بخشی از یک بردار ویژگی ترکیبی، همراه با ویژگی‌های حوزه‌ی زمان، فرکانس و زمان - فرکانس (مانند پهنای باند نوسان یا ضرایب موجک) وارد طبقه‌بند می‌شوند. این ترکیب امکان تشخیص دقیق‌تر بین کلاس‌های هدف (مثلاً تمایز هواپیما از بالگَرد، یا تشخیص نوع وسیله‌ی نقلیه) و همچنین جداسازی بهتر هدف از کلاتر محیطی را فراهم می‌سازد. پژوهش‌های تجربی نشان داده که ادغام این توصیفگرهای آماری ساده ولی معنادار در چارچوب‌های یادگیری ماشین، به‌ویژه در شرایط نسبت سیگنال به نویز متوسط و در مواجهه با اهداف با ابعاد مشابه، می‌تواند منجر به بهبود چشمگیر نرخ تشخیص صحیح شود.



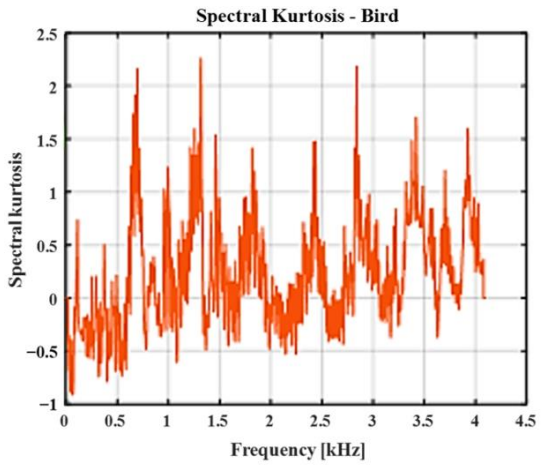
[1] Scaterer
[2] Glint
[3] Micromotion
[4] Clutter
[5] Heavy-Tailed



شکل (۶). تحلیل چولگی اهداف برای دو نوع هدف زمینی [۶۴].



الف: انسان



ب: پرنده

شکل (۷). کشیدگی طیفی اهداف [۶۵].

در شکل (۶) تحلیل چولگی و در شکل (۷) کشیدگی طیفی دو مدل هدف در رادارهای GSR قابل‌مشاهده است.

۲-۱۳. استخراج ویژگی بر پایه یادگیری عمیق

ظهور یادگیری عمیق با ادغام فرایندهای استخراج ویژگی و طبقه‌بندی در یک مدل واحد سرتاسر[1]، انقلابی در زمینه شناسایی خودکار اهداف ایجاد کرده است [۷]. این رویکرد، پاسخی مستقیم به محدودیت‌های ذاتی روش‌های سنتی مهندسی ویژگی بود که به شدت به دانش و تخصص انسانی وابسته بودند.

مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی[2]، توانایی منحصربه‌فردی در یادگیری خودکار ویژگی‌های سلسله‌مراتبی، پیچیده و غیرخطی دارند [۷, ۲۸]. این ویژگی‌ها به طور مستقیم از داده‌های راداری خام یا با حداقل پیش‌پردازش استخراج می‌شوند و نیاز به مراحل پرزحمت و زمان‌بر طراحی دستی ویژگی‌ها را به‌کلی از بین می‌برند [۲۹, ۳۰, ۳۱]. در بسیاری از موارد، ویژگی‌های یاد گرفته‌شده توسط این مدل‌ها، از ویژگی‌های دست‌ساز سنتی قوی‌تر و تفکیک‌پذیرتر هستند که در نتیجه به عملکرد بهتری در تشخیص اهداف منجر می‌شود [۲۹].

استفاده از یادگیری عمیق در ATR به نوع نمایش داده ورودی نیز وابسته است:

- CNNهای یک‌بعدی[3]: این شبکه‌ها برای پردازش مستقیم داده‌های راداری دارای توالی زمانی طراحی شده‌اند [۳۲].
- CNNهای دوبعدی[4]: این شبکه‌ها روی داده‌هایی که به فرم تصویر تبدیل شده‌اند، مانند طیف نگاره‌های میکرو - داپلر، اعمال می‌شوند [۶, ۳۳].
- شبکه‌های عصبی گراف[5]: این روش رویکردی نوظهور است که داده‌های پروفایل برد با وضوح‌بالا را به‌عنوان گراف مدل‌سازی می‌کند تا روابط بین مراکز پراکندگی هدف را به‌خوبی درک کند [۳۴].

۲-۱۴. شبکه‌های باور عمیق[6]

در زمینه‌ی دسته‌بندی اهداف متحرک زمینی با استفاده از رادارهای مراقبت زمینی، شبکه باور عمیق به‌عنوان یک دسته‌بند نسل جدید مطرح است که توانایی حل چالش‌های یادگیری ویژگی و طبقه‌بندی در سیگنال‌های پیچیده‌ی راداری را دارد. DBN در این زمینه، یک معماری یادگیری عمیق است که از چندین لایه ماشین بولتزمن محدود شده[7] به‌صورت پشته‌ای تشکیل شده است و با یک‌لایه نهایی دسته‌بندی مانند SVM برای تصمیم‌گیری ترکیب می‌شود.

DBN، برخلاف روش‌های سنتی که به استخراج دستی

[1] End-to-end

[2] Convolutional neural network (CNN)
[3] 1 dimentional CNN (1D-CNN)
[4] 2D-CNN
[5] Graph neural network (GNN)
[6] Deep belief network (DBN)
[7] Restricted Boltzmann machines (RBMs)

ویژگی‌هایی نظیر ضرایب کپستروم یا آنتروپی موجک نیاز دارند، قابلیت یادگیری و استخراج خودکار ویژگی‌های سطح بالا[1] را از داده‌های ورودی خام راداری (مانند عامل‌های سیگنال پالس یا نمایش‌های زمان - فرکانس) داراست.

روش DBN به‌عنوان یک دسته‌بند، از یک فرایند دومرحله‌ای بهره می‌برد: ابتدا، آموزش اولیه بدون نظارت[2] RBM ها، یک فضای ویژگی بهینه برای نمایش داده‌ها ایجاد می‌کند؛ سپس، تنظیم دقیق با نظارت[3]، شبکه را برای تفکیک کلاس‌های هدف (مانند اهداف زمینی مختلف) بهینه می‌سازد.

۲-۱۵. خودرمزگذارها[4]

خودرمزگذارها به‌عنوان یک ابزار اساسی در حوزه یادگیری عمیق در مبحث دسته‌بندی اهداف هستند. کاربرد اصلی آن‌ها در این زمینه، نه لزوماً به‌عنوان یک دسته‌بند مستقیم، بلکه به‌عنوان یک استخراج‌کننده ویژگی بدون نظارت و یک فیلتر نویز مقاوم است. ساختار AE شامل یک رمزگذار[5] است که داده‌های ورودی سیگنال راداری (مانند طیف داپلر یا پروفایل‌های بُرد) را به یک نمایش فشرده و با بُعد کم[6] در لایه میانی شبکه تبدیل می‌کند، و یک رمزگشا[7] که سعی می‌کند سیگنال اصلی را از این کد فشرده بازسازی کند.

در بحث تشخیص اهداف زمینی، چالش اصلی، وجود کلاتر و پیچیدگی بالای سیگنال‌های میکرو - داپلر است. خودرمزگذارها، به‌ویژه خودرمزگذارهای پشته‌ای[8] یا خودرمزگذارهای انقباضی[9] با فرایند آموزش بدون نظارت، مجبور می‌شوند تا اطلاعات مهم و متمایزکننده مربوط به هدف را در فضای فشرده خود حفظ کنند، درحالی‌که نویز و اطلاعات اضافی را حذف می‌کنند [۱]. این نمایش فشرده با بُعد کم که توسط رمزگذار تولید می‌شود، عملاً به‌عنوان یک بردار ویژگی بهینه عمل می‌کند. در مرحله بعد، این ویژگی‌های خودکار استخراج‌شده، به یک دسته‌بند نهایی (مانند SVM یا Softmax) وارد می‌شوند تا عمل نهایی تفکیک اهداف (مانند انسان، خودرو و غیره) بادقت و سرعت بالاتری انجام شود.

۳. انواع جداسازها

پس از استخراج ویژگی‌های دست‌ساز، الگوریتم‌های یادگیری ماشین[10] کلاسیک مانند K نزدیک‌ترین همسایه[11]، ماشین‌های بردار پشتیبان[12]، درختان تصمیم‌گیری[13] و جنگل‌های تصادفی[14] برای تفکیک بین دسته‌های هدف مورداستفاده قرار می‌گیرند [۲۷, ۴۱, ۴۲]. این الگوریتم‌ها عموماً از نظر محاسباتی کارآمدتر و ساده‌تر از روش‌های یادگیری عمیق هستند و ویژگی‌هایی که از آن‌ها استفاده می‌کنند، اغلب دارای یک تفسیر فیزیکی مستقیم هستند. بااین‌حال، محدودیت‌های روش‌های سنتی باعث شده که معماری‌های یادگیری عمیق که قادر به یادگیری سرتاسری هستند، به رویکرد غالب برای طبقه‌بندی هدف در سامانه‌های رادار نظارتی زمینی تبدیل شوند.

۳-۱. SVM

SVM یک روش یادگیری ماشین تحت نظارت برای کلاسه‌بندی باینری در بحث شناسایی الگو است. این کلاسه‌بندی کننده یک صفحه چندوجهی را به‌منظور جداسازی الگوی داده‌ها در دو کلاس ایجاد می‌کند. برداری که معرف این صفحه چندوجهی است را بردارهای پشتیبان[15] می‌نامند [۴۳]. مرزهای تصمیم‌گیری در مرحله آموزش انتخاب می‌شوند. در مرحله شناسایی، در مورد این که بردار ویژگی جدید متعلق به کدام کلاس است تصمیم‌گیری می‌شود. این کار با مقایسه بردار ویژگی جدید با صفحات چندبعدی تصمیم‌گیر انجام می‌شود. به همین خاطر SVMدر مرحله شناسایی هزینه محاسباتی بالایی ندارد [۴۲].

۳-۲. مدل مخفی مارکوف[16]

الگوریتم دسته‌بندی‌کننده مدل مخفی مارکوف برای تصمیم‌گیری در [۴۴، ۶۰] به‌کاررفته است. HMM به‌عنوان یکی از بهترین ابزارهای دسته‌بندی فعالیت‌های مختلف به شمار می‌رود. HMM گسسته به‌وسیله المان‌های خود که در ادامه آورده می‌شود توصیف می‌گردد [۱۲]:

- تعداد حالت‌های HMM، N، و توپولوژی حالت‌ها،
- تعداد سمبل‌های مختلف مشاهده شده، M،
- احتمال گذر بین حالت‌های مختلف، a_{ij}،
- چگالی توزیع احتمال مشاهدات خروجی از حالت jام، b_{ij}،
- احتمال حالت اولیه، π_i

در حالت کلی مسئله HMM به‌صورت رابطه (۳) مشخص می‌گردد:

[1] High-level features
[2] Unsupervised pre-training
[3] Supervised fine-tuning
[4] Autoencoders (AEs)
[5] Encoder
[6] Low-dimensional
[7] Decoder
[8] Stacked autoencoders (SAE)
[9] Contractive autoencoders
[10] Machine Learning Algorithem (ML)
[11] K-Nearest Neighbor (KNN)
[12] Support Vector Machine (SVM)
[13] Decision Tree (DT)
[14] Random Forest (RF)
[15] Support Vectors
[16] Hidden Markov model (HMM)

$$\lambda = (A, B, \pi) \quad (۳)$$

که A، B و π به ترتیب ماتریس‌های احتمال گذر بین حالت‌های مختلف، چگالی توزیع احتمال مشاهدات خروجی و احتمال حالت اولیه هستند.

۳-۳. مدل‌سازی آماری

روش آماری، ساختاری را برای ترکیب اطلاعات پیشین در مورد دسته‌های مختلف اهداف و مدل‌های مبتنی بر مشاهده در اختیار قرار می‌دهد. با استفاده از این مدل‌های آماری می‌توان به یک راه‌حل بهینه برای مسئله دسته‌بندی دست‌یافت [۲۳]. اطلاعات پیشین آماری معمولاً به‌وسیله یادگیری آماری مربوط به دسته‌های مختلف با استفاده از بانک داده‌های آموزشی به دست می‌آیند [۲۳]. با استفاده از این مدل‌های آماری می‌توان ناحیه‌های تصمیم‌گیری را مشخص نمود. مهم‌ترین نقطه‌ضعف این روش نیاز به بانک داده‌های آموزشی است. عملکرد دسته‌بندی نیز به شدت وابسته به‌اندازه داده‌های آموزشی بستگی دارد. سایر محدودیت‌های دسته‌بندی به روش آماری شامل موارد زیر است: ۱- عدم توانایی برای گسترش فضای دسته‌ها ۲- عدم توانایی کشف رابطه بین خواص هدف و فرایند آماری مدل شده [۲۳].

۳-۴. مدل ترکیب گوسی[1]

روش‌های جداسازی بر پایه مدل ترکیب گوسی به‌صورت گسترده در تشخیص صوت به کار رفته‌اند [۳۱]. در [۴۷] دسته‌بندی اهداف بر پایه GMM انجام شده است. دلیل استفاده از این روش در مسائل کلاسه‌بندی اهداف، امکان تخمین هر تابع چگالی احتمال به‌وسیله تعداد محدودی ترکیب گوسی است.

معمولاً برای تخمین مدل ترکیب از الگوریتم بازگشتی بیشینه‌کردن امید ریاضی[2] استفاده می‌شود. متأسفانه عملکرد این الگوریتم به مقدار اولیه و میل آن به اکسترمم محلی وابسته است. همچنین الگوریتم EMبرای تخمین تعداد مؤلفه‌های گوسی مناسب نمی‌باشد که این موضوع تأثیر مخربی بر عملکرد کلاسه‌بندی می‌گذارد. یادگیری حریص که برای GMMدر [۴۶] پیشنهاد شده است، نقاط منفی الگوریتم EMرا پوشش می‌دهد. الگوریتم یادگیری حریص به دانستن تعداد مؤلفه‌های گوسی نیازی ندارد و به‌صورت ذاتی مرتبه مدل را تخمین می‌زند [۲۲].

۳-۵. کمترین واگرایی[3]

در [۴۸] به روش‌های مبتنی بر کمترین واگرایی به‌منظور دست‌یابی به دسته‌بندی مطمئن اهداف متحرک زمینی پرداخته شده است. روش کمترین واگرایی یک دسته‌بند آماری جایگزین است که به‌جای روش سنتی بیشینه احتمال عمل می‌کند و بر اساس اندازه‌گیری فاصله بین توزیع‌های آماری سیگنال بنا شده است. در این مقاله مسئله ATR با استفاده از اطلاعات میکرو - داپلر به‌دست‌آمده از رادار زمینی با حد تفکیک پایین مورد بررسی قرار گرفته است. روش کمترین واگرایی با استفاده از اندازه‌گیری فواصل مختلف برای دسته‌بندی پیشنهاد شده است. روش پیشنهادی نسبت به مدل‌کردن خطا مقاوم بوده و برای اهداف با نسبت سیگنال به نویز پایین و سناریوهای با تعداد داده‌های آموزشی پایین کارا است. کلاسه‌بندی کننده MDبا استفاده از تقریب‌های محاسباتی مؤثر مربوط به فاصله بین GMMها پیاده‌سازی شده است.

روش کمترین واگرایی که شامل بیشینه‌کردن احتمال(ML^4) و استفاده از انواع فاصله است در کاربردهای بازیابی تصویر، تشخیص صدا و... عملکرد مقاوم نسبت به خطا در مدلینگ از خود نشان داده است [۴۸].

روش پیشنهادی MD، کلاس هدف را بر اساس کمترین فاصله بین تخمین توزیع اکوهای دریافتی (سیگنال ورودی هدف ناشناس) و مدل آماری کلاس‌های اهداف که از قبل تعریف شده‌اند، تعیین می‌کند. این مدل‌های آماری، غالباً با استفاده از مدل ترکیب گوسی نمایش داده می‌شوند.

ایده کلی استفاده از روش MD ۱- بهره‌بردن از مقاوم‌بودن تخمین‌گر MD ۲- پیاده‌سازی با بار محاسبات بهینه به‌وسیله تخمین فاصله بین GMMها است.

بنابراین، کمترین واگرایی یک راهبُرد دسته‌بندی است که به‌جای تمرکز بر حداکثرسازی احتمال، بر به‌حداقل‌رساندن تفاوت آماری بین توزیع‌های سیگنال مشاهده‌شده و توزیع‌های مدل شده کلاس‌های هدف تمرکز دارد.

۳-۶. نزدیک‌ترین همسایه

الگوریتم نزدیک‌ترین همسایه نوعی از الگوریتم‌های یادگیری ماشین تحت نظارت است که در مسائل دسته‌بندی و رگرسیون[5] مورداستفاده قرار می‌گیرد [۴۹]. الگوریتم KNN از تشابه ویژگی[6] برای پیش‌بینی مقادیر یا کلاس‌های نقاط داده جدید استفاده می‌کند که به این معنی است که برای یک نقطه‌ی داده‌ی جدید، KNN با محاسبه‌ی فاصله‌ی متریک[7] (مانند فاصله‌ی اقلیدسی) بین این نقطه‌ی جدید و تمام نمونه‌های موجود در مجموعه‌ی

[1] Gaussian mixture mode (GMM)
[2] Expectation maximization (EM)
[3] Minimum divergence (MD)
[4] Maximum likelihood
[5] Regression
[6] Feature similarity
[7] Metric distance

آموزشی، k نزدیک‌ترین همسایه را شناسایی می‌کند. سپس، طبقه‌بندی با تخصیص مقداری صورت می‌گیرد که بیشترین فراوانی را در میان k همسایه‌ی منتخب داشته باشد (مثلاً رأی اکثریت). این سادگی و وابستگی مستقیم به داده‌های محلی، آن را به یک روش غیرپارامتریک[1] و مؤثر برای دسته‌بندی اهداف راداری (به‌ویژه در فضاهای ویژگی با ابعاد نسبتاً پایین) تبدیل کرده است.

۳-۷. شبکه‌های عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی (CNN) به دلیل توانایی استثنایی خود در پردازش داده‌های شبکه‌ای، به سنگ بنای طبقه‌بندی خودکار اهداف راداری تبدیل شده‌اند [۳۹, ۴۰, ۴۹, ۵۱, ۵۲]. کارایی آن‌ها به طور حیاتی به پیش‌پردازش و نمایش سیگنال‌های راداری وابسته است. با تبدیل سیگنال‌های راداری یک‌بعدی خام به نمایش‌های دوبعدی مانند طیف نگاره‌های زمان - فرکانس، پروفایل‌های برد با وضوح‌بالا یا سایر اشکال تصویربرداری راداری، می‌توان به طور مؤثر از قابلیت‌های اثبات‌شده CNN در شناسایی تصویر بهره برد [۱, ۵, ۸, ۵۰, ۵۱, ۵۲, ۶۱].

انواع CNN مورداستفاده:

1D-CNN[2]: این شبکه‌ها برای پردازش مستقیم دنباله‌های داده راداری خام (مانند سلول‌های برد، سری‌های زمانی داپلر) عالی عمل می‌کنند. آن‌ها برای رادارهای با وضوح پایین مؤثر هستند و با کاهش مسائل بیش برازش، به دقت‌های بالایی دست یافته‌اند. برای مثال، مطالعات نشان داده‌اند که این شبکه‌ها می‌توانند به‌دقت تقریبی ۹۲٪ در طبقه‌بندی اهدافی مانند وسایل نقلیه، عابران پیاده و حیوانات دست یابند [۳۲].

2D-CNN: این شبکه‌ها بر روی نمایش‌های دوبعدی داده‌های راداری اعمال می‌شوند. برای داده‌های با وضوح‌بالا، معماری‌های پیشرفته‌ای مانند شبکه‌های VGG3 مبتنی بر Inception (IVGG) [۳۳] برای طبقه‌بندی اهداف از سیگنال‌های HRRP و SAR به کار گرفته شده‌اند و دقت‌های بالایی به دست آورده‌اند [۳۳, ۴۰, ۵۱, ۵۳, ۵۴].

۳-۸. شبکه‌های عصبی بازگشتی[4] و مکانیزم‌های توجه[5]

شبکه‌های عصبی بازگشتی، به‌ویژه شبکه‌های حافظه طولانی کوتاه - مدت[6]، برای ماهیت ترتیبی داده‌های راداری که اطلاعات در آن‌ها در طول زمان آشکار می‌شود، بسیار مناسب هستند [۱۵, ۳۰, ۵۱, ۵۲, ۵۵]. این شبکه‌ها قادر به ثبت روابط زمانی و وابستگی‌هایی هستند که برای طبقه‌بندی پویای هدف حیاتی است. ادغام مکانیزم‌های توجه در این شبکه‌ها یک پیشرفت قابل‌توجه را نشان می‌دهد، زیرا به مدل اجازه می‌دهد به طور پویا بر روی مهم‌ترین بخش‌های سیگنال ورودی تمرکز کند. [۵۱].

۳-۹. معماری‌های نوظهور

علاوه بر CNNها و RNN ها، چندین معماری یادگیری عمیق پیشرفته دیگر نیز در حال بررسی هستند:

شبکه‌های عصبی گراف (GNN): این شبکه‌ها یک راهکار نوآورانه برای پردازش داده‌های سیگنال راداری ارائه می‌دهند که ذاتاً دارای ساختار غیراقلیدسی هستند. در کاربرد رادار، برخلاف شبکه‌های کانولوشنال سنتی که سیگنال (مانند طیف میکرو - داپلر یا نمایش‌های زمان - فرکانس) را به‌عنوان یک تصویر (گرید اقلیدسی) در نظر می‌گیرند، GNN سیگنال راداری را به‌عنوان یک گراف مدل می‌کند. گره‌ها[7] در این گراف می‌توانند مراکز پراکندگی برجسته[8] هدف یا ویژگی‌های استخراج‌شده از هر ناحیه زمانی/فرکانسی باشند و یال‌ها[9] روابط متقابل و وابستگی‌های فضایی یا زمانی بین این مراکز را نشان می‌دهند. این شبکه‌ها با پردازش داده‌هایی که به‌صورت گراف ساختار یافته‌اند، روابط پیچیده و غیراقلیدسی بین مراکز پراکندگی را ثبت کرده و کاربرد خود را در شناسایی اهداف پروفایل بُرد با تفکیک‌پذیری بالا یا سیگنال میکرو - داپلر پیدا کرده‌اند [۳۴]. توانایی GNN در مدل‌سازی تأثیرات دینامیکی و تعاملی بین قسمت‌های مختلف هدف (مثلاً همبستگی حرکت بازوها و پاها در یک انسان در حال راه‌رفتن) منجر به استخراج ویژگی‌های متمایز و مقاوم در برابر تغییرات جهت یا سرعت هدف می‌شود.

ترانسفورمرهای بینایی[10]: این مدل‌ها با اقتباس از معماری ترانسفورمر که در پردازش زبان طبیعی موفقیت‌آمیز بوده، برای تجزیه‌وتحلیل نمایش‌های تصویری سیگنال‌های راداری (مانند طیف‌های میکرو - داپلر) به کار می‌روند. مکانیسم توجه که هسته اصلی ترانسفورمر است، به شبکه این امکان را می‌دهد تا وابستگی‌های بلندمدت[11] بین قسمت‌های مختلف سیگنال در زمان و فرکانس را ثبت کند. این امر برخلاف CNNها است که فقط می‌توانند وابستگی‌های محلی را در اندازه پنجره کانولوشن

[1] Non-parametric
[2] 1 dimensional CNN
[3] Visual Geometry Group Networks
[4] Recarrent Neural Network (RNN)
[5] Attention mechanism
[6] Long Short-Term Memories (LSTMs)
[7] Nodes
[8] Dominant scattering centers
[9] Edges
[10] Vision transformers (ViT)
[11] Long-range dependencies

خود ثبت کنند. با استفاده از ViTها می‌توان به طور هم‌زمان بر روی الگوهای حرکتی در بخش‌های مختلف طیف داپلر (مثلاً داپلر تنه و داپلر اندام‌ها) توجه کرد و به‌این‌ترتیب، اطلاعات بیشتری از دینامیک هدف برای دسته‌بندی استخراج نمود. بااین‌حال، این مدل‌ها نیز برای کارایی خود در طبقه‌بندی اهداف مورد بررسی قرار گرفته‌اند، اما شدت محاسباتی بالای آن‌ها (به دلیل عملیات توجه) در حال حاضر مناسب‌بودن آن‌ها را برای وظایف در زمان واقعی، بدون بهینه‌سازی گسترده محدود می‌کند [۵۱].

۴. چالش‌های دسته‌بندی اهداف

۴-۱. جمع‌آوری بانک داده[1]

یکی از مهم‌ترین و پایه‌ای‌ترین چالش‌ها در توسعه و ارزیابی سامانه‌های شناسایی خودکار اهداف راداری، به‌ویژه برای رادارهای مراقبت زمینی، موضوع کمبود مجموعه‌داده‌های بزرگ، باکیفیت و متنوع است [۹, ۳۲, ۵۱, ۵۶, ۵۷, ۵۸, ۵۹]. برخلاف شناسایی تصویر اپتیکی، جمع‌آوری داده‌های راداری در دنیای واقعی فرایندی گران‌قیمت و زمان‌بر است که اغلب با محدودیت‌های امنیتی همراه بوده و مستلزم تجهیزات راداری تخصصی و برچسب‌گذاری[2] دقیق هر سیگنال در آزمایش‌های میدانی کنترل‌شده است [۹, ۵۱, ۵۶, ۵۷]. سیگنال‌های اهداف متحرک زمینی (مانند انسان، وسایل نقلیه یا حیوانات) نه‌تنها به‌شدت تحت‌تأثیر زاویه دید رادار، سرعت هدف، و محیط قرار دارند، بلکه تنوع درونی هر کلاس هدف (مانند الگوهای مختلف حرکت انسان) بسیار بالاست. این کمبود داده‌ها، یک گلوگاه اصلی برای مدل‌های یادگیری عمیق (مانند DBNs یا CNNs) ایجاد می‌کند که به داشتن اشتهای سیری‌ناپذیر برای داده معروف هستند و معمولاً به حجم بالایی از مشاهده‌ها (اغلب هزاران نمونه در هر کلاس) نیاز دارند تا بازنمایی‌های ویژگی مؤثر را یاد بگیرند، به‌خوبی تعمیم‌پذیر[3] باشند و از بیش برازش[4] جلوگیری کنند [۹, ۳۹, ۴۰, ۵۱]. در مقابل، مدل‌های یادگیری ماشین سنتی (مانند SVM و GMM) می‌توانند با تعداد متوسطی از داده‌ها به عملکرد قابل‌قبولی دست یابند، زیرا آن‌ها به ویژگی‌های دست‌ساز از پیش تعریف‌شده متکی هستند که پیچیدگی مسئله را کاهش می‌دهد [۳۱, ۳۸].

محدودیت و عدم دسترسی عمومی به بانک‌های داده جامع، معتبر و استاندارد، یک بده‌بستان مهم را برای سامانه‌های نظارتی زمینی آنلاین ایجاد می‌کند که اغلب تحت محدودیت‌های سخت‌افزاری و جمع‌آوری داده عمل می‌کنند. برای حل این معضل، دو نوع داده مورداستفاده قرار می‌گیرد: داده‌های واقعی که برای ثبت پیچیدگی‌های محیط و داده‌های شبیه‌سازی‌شده [۳۰, ۵۷] که برای ساخت مجموعه‌داده‌های بزرگ ضروری هستند [۹, ۵۱]. بااین‌حال، ممکن است یک شکاف شبیه‌سازی - به - واقعیت[5] وجود داشته باشد. به همین دلیل، برای پر کردن این شکاف و توسعه الگوریتم‌های قابل‌تعمیم‌تر، از فن‌هایی مانند افزایش داده[6]، تولید داده‌های مصنوعی (با استفاده از شبکه‌های عصبی) و یادگیری انتقالی[7] به طور رایج استفاده می‌شود [۵۱, ۵۶, ۵۷, ۵۸]. در بسیاری از مقالات روش‌های جایگزین شبیه‌سازی سیگنال راداری را پیشنهاد کرده‌اند که در ادامه به این موضوعات پرداخته می‌شود.

مدل‌سازی عاملی: این مدل با درنظرگرفتن ویژگی‌های منحصربه‌فرد فیزیکی اهداف به دست می‌آید. این روش در مواقعی که داده‌های آموزشی دردسترس نیستند مناسب است [۲۲]. اطلاعات فیزیکی پیشین معمولاً در مدل‌های مختلف عاملی استفاده می‌شوند. می‌توان از ویژگی‌های فیزیکی هدف برای تولید سیگنال اکوی مصنوعی رادار استفاده کرد. این اکوها برای ساخت بانک داده مصنوعی مفید هستند. بانک داده‌های مصنوعی برای آموزش جداکننده مبتنی بر روش آماری استفاده می‌شود. بر خلاف جداکننده‌های آماری، این روش شامل جمع‌آوری داده‌های آموزش که ممکن است هزینه‌بر و پیچیده باشند، نمی‌شود. علاوه بر این، اندازه بانک داده مصنوعی را می‌توان بدون محدودیت افزایش داد.

عیب استفاده از اطلاعات فیزیکی پیشین وجود عدم تطبیق مدل‌سازی است. در بسیاری از کاربردهای راداری، نمی‌توان به مدل دقیق برای دسته‌های مختلف اهداف دست‌یافت. معایب دسته‌بندی‌کننده‌های آماری و مدل‌های فیزیکی را می‌توان به وسیله‌ی روش ترکیبی جبران کرد. در این روش، می‌توان به‌وسیله هر دو اطلاعات پیشین آماری و فیزیکی جداساز را آموزش داد. در نتیجه هر دو منبع اطلاع آماری و فیزیکی در جداکننده شرکت می‌کنند [۲۳].

یک روش مدل‌سازی عاملی، بر پایه مدل‌سازی حرکت[8] است که در [۲۲] ارائه شده است. مدل حرکت انسان به‌وسیله مدل بیومکانیکی[9] بدن انسان توسعه‌یافته است. نفر پیاده با استفاده از مدل‌های حرکت بیومکانیکی مدل‌سازی شده که از مدل گلوله و

[1] Database collection
[2] Labeling
[3] Generalization
[4] Overfitting
[5] Simulation-to-reality gap
[6] Data augmentation
[7] Transfer learning
[8] Locomotion modeling
[9] Biomechanical model

میله[1] استفاده شده است. مدل حرکت انسان باتوجه‌به داده‌های واقعی به‌دست‌آمده و توصیف‌کننده حرکت اجزاء بدن انسان در طول زمان است. مدل حرکت دو نفر با استفاده از جمع آثار حرکت دو نفر به‌صورت مستقل ایجاد شده است. خودرو با حرکت آهسته به‌عنوان یک هدف نقطه‌ای با یک شتاب آرام مدل شده است [۲۳].

شبکه‌های مولد متخاصم[2]: یکی از چالش‌های عمده در پیاده‌سازی یادگیری عمیق، کمبود داده‌های آموزشی حقیقی است؛ زیرا جمع‌آوری داده‌های راداری میدانی پرهزینه و زمان‌بر است. شبکه‌های مولد متخاصم با ارائه یک راه‌حل مبتنی بر تولید داده‌های مصنوعی[3] به این مشکل پاسخ می‌دهند. از این شبکه‌ها (شامل یک مولد[4] و یک متمایزکننده[5]) برای حل چالش حیاتی کمبود داده با تولید مجموعه‌داده‌های آموزشی مصنوعی استفاده می‌شود تا داده‌های محدود دنیای واقعی را تقویت کنند [۵۱]. مولد تلاش می‌کند تا سیگنال‌های راداری مصنوعی (مانند طیف میکرو داپلر) تولید کند که قابل‌تمایز از داده‌های واقعی نباشد، درحالی‌که متمایزکننده سعی می‌کند بین داده‌های واقعی و تولیدشده تفاوت قائل شود. با این فرایند متخاصم، GAN می‌تواند سیگنال‌هایی تولید کند که نه‌تنها شبیه به داده‌های واقعی هستند، بلکه تنوع[6] ذاتی در داده‌های راداری (مانند تغییرات سرعت، جهت، یا زوایای دید) را نیز در بر می‌گیرند. این داده‌های مصنوعی غنی‌شده، سپس برای آموزش مدل‌های دسته‌بندی اصلی (مانند CNN یا DBN) به کار می‌روند و کارایی آن‌ها را به‌شدت افزایش می‌دهند.

۴-۲. زمان لازم برای استخراج ویژگی

ویژگی‌های دست‌ساز: برای استخراج این ویژگی‌ها، از تکنیک‌های پردازش سیگنال مانند تبدیل فوریه سریع[7] استفاده می‌شود که در مرحله استنتاج از نظر محاسباتی بسیار کارآمد هستند. بااین‌حال، باید در نظر داشت که طراحی، انتخاب و بهینه‌سازی اولیه این ویژگی‌ها به تخصص و زمان قابل‌توجهی از سوی انسان نیاز دارد [۳۰].

ویژگی‌های مبتنی بر شبکه عصبی: فرایند یادگیری سرتاسری این مدل‌ها از نظر محاسباتی بسیار فشرده است و بسته به پیچیدگی مدل و اندازه داده‌ها، به زمان زیادی برای آموزش نیاز دارد [۳۵, ۳۶]. این مرحله تقریباً به‌صورت انحصاری یک فرایند برون‌خط[8] است. اما پس از اتمام آموزش، مرحله استنتاج (طبقه‌بندی) بسیار سریع انجام می‌شود که امکان استفاده از این مدل‌ها را به‌صورت برخط[9] و در زمان واقعی فراهم می‌کند [۳۷].

۴-۳. الزامات محاسباتی و محدودیت‌های پیاده‌سازی

الزامات محاسباتی و محدودیت‌های پیاده‌سازی در دسته‌بندی اهداف متحرک زمینی یک ملاحظه حیاتی در طراحی سامانه‌های GSR است، چرا که هدف نهایی، دستیابی به عملکرد بلادرنگ[10] است. در روش‌هایی که از ویژگی‌های دست‌ساز استفاده می‌کنند، اصلی‌ترین بار محاسباتی در فاز استخراج ویژگی متمرکز است. برای مثال، استخراج ویژگی‌های مبتنی بر تجزیه بسته موجک [۲۴]، تبدیل چرپلت [۶۲] یا تخمین طیف‌سنجی و گشتاورهای مرتبه بالاتر از داده‌های سری زمانی غیرایستا، عملیات محاسباتی بسیاری را طلب می‌کنند [۱۹]. برای مطابقت با نرخ داده‌های راداری، این فرایندها مستلزم استفاده از تکنیک‌های پردازش موازی و سامانه‌های محاسبات سریع هستند [۲۶]. پس از استخراج ویژگی، دسته‌بندهای کلاسیک مانند ماشین‌های بردار پشتیبان یا مدل‌های مخلوط گاوسی، در مرحله استنتاج[11] سربار محاسباتی نسبتاً کمتری نسبت به شبکه‌های عمیق دارند و پیاده‌سازی آن‌ها اغلب ساده‌تر است [۴۸].

در مقابل، مدل‌های مبتنی بر شبکه‌های عصبی عمیق، حجم محاسباتی را به طور قابل‌توجهی افزایش می‌دهند، زیرا فرایند یادگیری و استخراج ویژگی‌ها در دل معماری شبکه ادغام شده است. این شبکه‌ها برای آموزش مؤثر و جلوگیری از بیش برازش، نیازمند حجم بالایی از داده‌های برچسب خورده و اجرای مکرر عملیات ضرب و جمع ماتریسی بزرگ در هر لایه هستند که این امر، به‌ویژه در فاز آموزش[12]، به پردازش موازی سنگین و حافظه دسترسی سریع نیاز دارد. بااین‌حال، شبکه‌های عصبی قابلیت مدل‌سازی مدل‌های غیرخطی پیچیده‌تری را ارائه می‌دهند و می‌توانند الگوهای پنهانی را که در روش‌های دست‌ساز نادیده گرفته می‌شوند، کشف کنند [۲]؛ بنابراین، یک بده‌بستان اساسی بین دقت بالاتر و الزامات سخت‌افزاری و مصرف توان بالا وجود دارد.

برای عملیاتی ساختن این الگوریتم‌ها در محیط‌های عملیاتی رادارهای GSR که محدودیت‌های SWaP[13] (اندازه، وزن، و توان مصرفی) حیاتی هستند، سخت‌افزارهای موازی و تکنیک‌های بهینه‌سازی نرم‌افزاری ضروری است.

[1] Stick model
[2] Generative adversarial networks (GAN)
[3] Synthetic data
[4] Generator
[5] Discriminator
[6] Variability
[7] Fast Fourier Transform (FFT)
[8] Offline
[9] Online
[10] Real-time
[11] Inference
[12] Training
[13] Size, weight and power

جدول (۱): مقایسه رویکردهای سنتی و یادگیری عمیق

دسته‌بندی	ویژگی‌های کلیدی	ویژگی‌ها/الگوریتم‌های معمول	مزایا	محدودیت‌ها
روش‌های سنتی	متکی بر مهندسی ویژگی دست‌ساز و تحلیل آماری کلاسیک.	RCS، میکرو - داپلر، GMM، SVM، Random Forests	ویژگی‌های قابل‌تفسیر؛ به طور بالقوه نیاز محاسباتی کمتری برای مدل‌های ساده‌تر	دقت/پایداری پایین در داده‌های نویزی یا با وضوح پایین؛ تعمیم ضعیف؛ وابستگی به دانش متخصص
رویکردهای یادگیری عمیق	ویژگی‌ها را مستقیماً از داده‌های خام یاد می‌گیرند (یادگیری سرتاسری).	CNN، RNN، Attention، Vision Transformers، GNN	عملکرد برتر در سناریوهای پیچیده؛ دقت بالا؛ استخراج خودکار ویژگی	نیاز محاسباتی بالا؛ نیازمند مجموعه‌داده‌های بزرگ و متنوع؛ پتانسیل بیش برازش

آرایه‌های گیت قابل‌برنامه‌ریزی در میدان[1] به دلیل توانایی ذاتی در ارائه پردازش موازی با تأخیر کم[2] و انعطاف‌پذیری بالا، به بستر اصلی برای پیاده‌سازی هسته‌های محاسباتی فشرده تبدیل شده‌اند. علاوه بر FPGA، استفاده از واحدهای پردازش گرافیکی[3] برای تسریع فاز آموزش مدل‌های عمیق یا اجرای سریع استنتاج در سامانه‌های بزرگ‌تر رایج است. همچنین، فن‌هایی مانند کوانتیزه‌سازی مدل[4]، هرس وزن[5] و استفاده از دسته‌بندهای با کمترین واگرایی که با تقریب‌های کارآمد، عملکرد مناسب را با هزینه‌ای پایین‌تر از روش‌های حداکثر درست‌نمایی[6] ارائه می‌دهند، برای تعدیل الزامات سخت‌افزاری در مرحله استنتاج به طور گسترده‌ای مورد بررسی قرار گرفته‌اند [۴۸].

جدول (۱)، یک نمای کلی تطبیقی از این دو الگوی روش‌شناختی (روش‌های سنتی و روش‌های یادگیری عمیق) را ارائه می‌دهد و بده‌بستان‌های اساسی بین قابلیت تفسیر و عملکرد را برجسته می‌کند.

۵. یادگیری جمعی و راهبردهای تلفیق

باتوجه‌به محدودیت‌های طبقه‌بندی‌کننده‌های منفرد در دستیابی به عملکرد بهینه در سناریوهای پیچیده، رویکردهای پیشرفته‌تری مانند یادگیری جمعی[7] و تکنیک‌های تلفیق داده[8] به‌عنوان راه‌حل‌های مؤثر موردتوجه قرار گرفته‌اند. این رویکردها با بهره‌گیری از هم‌افزایی چندین مدل یا منبع اطلاعاتی، به طور قابل‌توجهی دقت، پایداری و قدرت تعمیم‌پذیری سامانه‌های شناسایی خودکار هدف (ATR) را بهبود می‌بخشند [۵۱, ۵۵].

۵-۱. یادگیری جمعی

یادگیری جمعی یک آبَر - رویکرد قدرتمند در یادگیری ماشین است که به‌جای تکیه بر یک مدل واحد، از خرد جمعی چندین مدل مستقل برای پیش‌بینی نهایی استفاده می‌کند. هدف اصلی این روش، کاهش واریانس و بایاس مدل، و در نتیجه، دستیابی به عملکردی برتر و پایدارتر از هر مدل به‌تنهایی است. سه تکنیک اصلی در یادگیری جمعی شامل موارد زیر است:

۵-۱-۱. تجمیع[9]

این تکنیک با ایجاد نسخه‌های مختلف از مجموعه‌داده اصلی (با نمونه‌برداری تصادفی و جایگزینی) و آموزش یک مدل مشابه بر روی هر یک از آن‌ها، مجموعه‌ای از طبقه‌بندی‌کننده‌های مستقل را ایجاد می‌کند. پیش‌بینی نهایی با رأی‌گیری (برای طبقه‌بندی) یا میانگین‌گیری (برای رگرسیون) از خروجی تمام مدل‌ها به دست می‌آید. الگوریتم جنگل تصادفی[10] یک نمونه برجسته از این روش است [۳۳, ۵۱].

۵-۱-۲. تقویت[11]

در این رویکرد، مدل‌ها به‌صورت متوالی و وابسته به یکدیگر آموزش داده می‌شوند. هر مدل جدید بر نقاط ضعفی که مدل قبلی در طبقه‌بندی آن‌ها دچار خطا شده، تمرکز می‌کند. با اختصاص وزن‌های بیشتر به نمونه‌های دشوار، این تکنیک به‌تدریج دقت کلی سیستم را افزایش می‌دهد. الگوریتم‌هایی مانند AdaBoost و XGBoost نمونه‌هایی از این رویکرد هستند [۳۳, ۵۱].

[1] Field-Programmable Gate Array (FPGAs)
[2] Low-latency
[3] GPUs
[4] Model quantization
[5] Weight pruning
[6] Maximum likelihood
[7] Ensemble learning
[8] Data fusion
[9] Bagging
[10] Random forest
[11] Boosting

۵-۱-۳. انباشتگی[1]

این یک روش پیشرفته‌تر است که در آن، پیش‌بینی‌های مدل‌های پایه[2] به‌عنوان ویژگی‌های ورودی برای یک مدل جدید به نام متا - طبقه‌بندی‌کننده[3] استفاده می‌شوند. متا - طبقه‌بندی‌کننده، وظیفه ترکیب هوشمندانه خروجی‌های مدل‌های پایه را برای تولید پیش‌بینی نهایی بر عهده دارد. این ساختار لایه‌ای امکان یادگیری از خطاهای مدل‌های اولیه را فراهم می‌کند [۵۱].

۵-۵. همجوشی داده

همجوشی داده فرایند ترکیب اطلاعات از چندین منبع یا کانال مختلف برای به‌دست‌آوردن یک درک جامع‌تر و دقیق‌تر از یک پدیده است. در زمینه شناسایی هدف با رادار، این فن‌ها می‌توانند اطلاعاتی را از کانال‌های مختلف یک رادار (مانند رادار دو - قطبی) یا از حسگرهای متعدد (مانند رادار، دوربین، و Lidar) ادغام کنند [۵۱]. این رویکرد به طور مؤثری نویز را کاهش داده و پایداری طبقه‌بندی را در شرایط محیطی چالش‌برانگیز بهبود می‌بخشد [۵۱]. دو راهبرد اصلی تلفیق داده عبارت‌اند از:

۵-۵-۱. همجوشی ویژگی[4]

در این راهبرد، ویژگی‌های استخراج‌شده از منابع داده مختلف در سطح ویژگی با یکدیگر ترکیب می‌شوند و سپس به یک طبقه‌بندی‌کننده واحد وارد می‌شوند. این رویکرد به طبقه‌بندی‌کننده اجازه می‌دهد تا روابط پیچیده بین انواع مختلف داده را کشف کند و یک نمایش غنی‌تر و جامع‌تر از هدف ایجاد نماید [۵۱]. برای مثال، می‌توان ویژگی‌های میکرو - داپلر و HRRP را قبل از طبقه‌بندی با یکدیگر ادغام کرد.

۵-۵-۲. همجوشی تصمیم[5]

این راهبرد در سطح بالاتر انجام می‌شود. در این حالت، هر منبع داده یا هر طبقه‌بندی‌کننده به‌صورت مستقل عمل کرده و یک تصمیم اولیه می‌گیرد. سپس، تصمیمات مستقل با استفاده از روش‌هایی مانند رأی‌گیری اکثریت، میانگین وزن‌دار یا منطق فازی ترکیب می‌شوند تا یک تصمیم نهایی و قوی‌تر تولید شود [۵۱]. این روش به‌ویژه زمانی مفید است که مدل‌ها بر روی داده‌های کاملاً متفاوت آموزش‌دیده‌اند.

تکنیک‌های تلفیق داده، به‌ویژه در سامانه‌های رادار، با فراهم‌کردن یک دید چند - بعدی از هدف، به طور مؤثری دقت شناسایی را در برابر شرایط نویزی بهبود می‌بخشند.

[1] Stacking
[2] Base models
[3] Meta-classifier
[4] Feature fusion
[5] Decision fusion

در جدول (۲)، مقایسه مروری مقالات در حوزه دسته‌بندی اهداف زمینی در رادارهای مراقبت سطحی قابل‌مشاهده است. در این جدول ویژگی‌های استخراجی، اهداف مورد بررسی، نوع طبقه‌بند مورداستفاده، دقت عملکرد دسته‌بندی اهداف، نوع پردازش از حیث برخط بودن یا نبودن، واقعی یا شبیه‌سازی بودن داده‌ها و تعداد داده‌های مورداستفاده، بررسی می‌گردند.

۶. نتیجه‌گیری و نگاهی به آینده

این مقاله مروری جامع بر روند تحول شناسایی خودکار اهداف در سامانه‌های رادار مراقبت زمینی ارائه داد. نتایج بررسی‌ها نشان داد که این حوزه از روش‌های اولیه مبتنی بر ویژگی‌های دست‌ساخته، مانند سطح مقطع راداری (RCS)، امضای میکرو - داپلر و ضرایب موجک، به سمت رویکردهای داده‌محور و مبتنی بر یادگیری عمیق حرکت کرده است. اگرچه روش‌های سنتی از نظر سادگی محاسباتی و تفسیرپذیری دارای مزیت بودند، اما در بسیاری از کاربردهای عملی با محدودیت‌هایی در تعمیم‌پذیری، وابستگی به طراحی دستی ویژگی‌ها و حساسیت به شرایط عملیاتی مواجه بوده‌اند.

در مقابل، ظهور مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی (CNN)، بازگشتی (RNN)، معماری‌های مبتنی بر مکانیزم توجه، و مدل‌های مبتنی بر بازنمایی‌های زمان - فرکانس، افق‌های جدیدی را در توسعه سامانه‌های ATR ایجاد کرده است. این مدل‌ها به دلیل توانایی در استخراج خودکار ویژگی از داده خام راداری، قادرند الگوهای پیچیده و غیرخطی را بهتر مدل‌سازی کرده و اثر عواملی همچون تغییر زاویه دید، سرعت، حرکت دورانی اجزا، پوشش گیاهی و شرایط محیطی را مؤثرتر از روش‌های سنتی جبران کنند. همچنین، استفاده از راهبردهای یادگیری جمعی، تلفیق داده و همجوشی تصمیم، با بهره‌گیری از نقاط قوت چند مدل یا چند منبع داده، موجب بهبود دقت، پایداری و قابلیت اطمینان در دسته‌بندی اهداف شده است.

باوجود این پیشرفت‌ها، چالش کمبود داده‌های واقعی، بزرگ‌مقیاس، باکیفیت و متنوع همچنان یکی از موانع اصلی توسعه سامانه‌های داده‌محور در این حوزه به شمار می‌رود. ازاین‌رو، یکی از مهم‌ترین مسیرهای آینده، استفاده از شبیه‌سازی‌های فیزیکی پیشرفته، تولید داده مصنوعی و مدل‌های مولد عمیق مانند GANها برای غنی‌سازی مجموعه‌داده‌های آموزشی است. ترکیب هدفمند داده‌های واقعی و مصنوعی می‌تواند به توسعه مدل‌هایی باقابلیت تعمیم بالاتر منجر شود. علاوه بر این، انتظار می‌رود معماری‌های چند حسگری که داده‌های راداری را با ویدئو، لیدار یا حسگرهای حرارتی ترکیب

می‌کنند، در مأموریت‌های حساس و محیط‌های پیچیده عملکرد به‌مراتب بهتری ارائه دهند.

در مجموع، آینده ATR در رادارهای مراقبت زمینی به‌سوی سامانه‌هایی هوشمندتر، خودتطبیق‌پذیرتر، مقاوم‌تر و قابل‌اعتمادتر در حال حرکت است؛ سامانه‌هایی که نه‌تنها از دقت و سرعت پردازش بالاتری برخوردار باشند، بلکه بتوانند عدم قطعیت را مدیریت کنند، در شرایط واقعی عملیاتی پایدار بمانند و با دریافت داده‌های جدید به‌صورت پیوسته به‌روزرسانی شوند. در این مسیر، توسعه مدل‌های سبک‌تر برای استقرار روی پلتفرم‌های با منابع محدود و نیز افزایش توضیح‌پذیری مدل‌های یادگیری عمیق، از دیگر اولویت‌های مهم پژوهشی خواهند بود. به‌طورکلی، تلفیق یادگیری عمیق، شبیه‌سازی هوشمند، و راهبردهای پیشرفته همجوشی و یادگیری جمعی، مسیر دستیابی به چارچوب‌های ATR قوی، کارآمد و عملیاتی را هموار خواهد کرد.

جدول (۲): مقایسه مروری مقالات

شماره مرجع	ویژگی‌های استخراج شده	طبقه‌بند مورداستفاده	نوع هدف	دقت طبقه‌بندی (٪)	پردازش (آفلاین/آنلاین)	تعداد مشاهدات هدف	نوع داده (واقعی/شبیه‌سازی)
[1]	طیف داپلر	GMM	انسان، وسیله نقلیه	۹۵< (بسته به کلاس)	آفلاین	نامشخص	واقعی
[2]	سیگنال‌های راداری صوتی	RBF-NN	کارکنان، وسایل نقلیه	آموزش ≈٪۸۷.۹، آزمایش ≈٪۶۷.۱	آفلاین	حدود ۱۲۰۰۰ نمونه	واقعی
[8]	میکرو - داپلر، ابرنقاط	یادگیری ماشین	وسایل نقلیه، عابران پیاده	۹۵<	آموزش آفلاین آزمایش آنلاین	۶۴۸۰	واقعی
[10]	میکرو - داپلر: STFT ، مدل‌سازی حرکات میکرو، تحلیل TF	مدل‌سازی بنیادی و تحلیل سیگنال	انسان‌ها، قطعات چرخان/لرزان، وسایل نقلیه، روتورها	نامشخص	نامشخص	نامشخص	هر دو
[11]	ویژگی‌های کپستروم و TF	مقاله تحلیلی	حرکت انسان (راه‌رفتن/دویدن)	نامشخص	آفلاین	۴۰۰	واقعی
[12]	سیگنال‌های داپلر	HMM ، سیستم خبره	انسان، وسیله نقلیه	۹۷	آفلاین	نامشخص	واقعی
[13]	میکرو - داپلر	تحلیل کیفی	پهپادها	۹۹	آفلاین	۲۰۹	واقعی
[15]	ویژگی‌های متنوع راداری	SVM, k-NN, درخت تصمیم	اهداف زمینی	۹۳	آفلاین	۲۷۷۵	نامشخص
[16]	دنباله‌های RCS	بر اساس واگرایی KL	هواپیما	۱۰۰	آفلاین	-	شبیه‌سازی‌شده
[19]	اسپکتروم سیگنال داپلر	تحلیل ویژگی	انسان، گوی متحرک	- (تحلیلی)	آفلاین	۲۰۰۰۰۰	واقعی
[21]	امضاهای راداری	مبتنی بر SVD	اهداف نظامی	۹۸	آفلاین	-	شبیه‌سازی‌شده
[22]	امضاهای داپلر	مشابه [۱] (GMM)	انسان، وسیله نقلیه	۹۶	آفلاین	نامشخص	واقعی

شماره مرجع	ویژگی‌های استخراج شده	طبقه‌بند مورداستفاده	نوع هدف	دقت طبقه‌بندی (٪)	پردازش (آفلاین/آنلاین)	تعداد مشاهدات هدف	نوع داده (واقعی/شبیه‌سازی)
[23]	داپلر (مدل - پایه)	مشابه [۱] (GMM)	فعالیت‌های انسانی	۹۵	آفلاین	۱۸۰۰	هر دو
[24]	آنتروپی انرژی - لگاریتمی بسته‌های موجک	طبقه‌بند (نوع مشخص نشده)	اهداف متحرک زمینی	۹۸	آفلاین	۴۵۲	واقعی
[28]	بی - اسپکتروم	CNN عمیق	هواپیما، وسایل نقلیه	٪۹۵<	آفلاین	۷۶۸۰	شبیه‌سازی‌شده
[29]	سیگنال‌های رادار با وضوح پایین	SVM, k-NN, MLP, Random Forest	انسان، وسیله نقلیه	مقایسه‌ای (SVM ~۹۳ بهتر)	آفلاین	-	واقعی
[30]	میکرو - داپلر	SVM, k-NN	انسان، حیوان، وسیله نقلیه	۹۰ < (برای بهترین ویژگی‌ها و بر اساس SNRهای مختلف)	آفلاین	۳۵۰۰۰۰	شبیه‌سازی
[31]	میکرو - داپلر (طیفی)	SVM, k-NN	انسان، وسیله نقلیه	۹۵	آفلاین	-	واقعی
[32]	سیگنال‌های رادار با وضوح پایین	D-CNN۱	انسان، وسیله نقلیه	حدود ۹۸	آفلاین	-	واقعی
[33]	سیگنال‌های رادار با وضوح پایین	D-CNN۲ چندکاناله	انسان، وسیله نقلیه	۹۸~۹۶	آفلاین	-	واقعی
[34]	پروفایل برد با وضوح‌بالا (HRRP)	شبکه عصبی گرافی (GNN)	هواپیما	۹۹	آفلاین	۱۷۵۲۰	شبیه‌سازی
[41]	میکرو - داپلر	CNN	وسایل نقلیه، عابران پیاده	۹۵	آفلاین	۲.۵ میلیون	شبیه‌سازی
[44]	امضاهای داپلر	HMM	کارکنان، وسایل نقلیه	۸۶	آفلاین	۵۳	واقعی
[48]	داپلر/زمان - فرکانس	حداقل واگرایی (مبتنی بر GMM)	انسان، وسیله نقلیه	۹۰~۸۰	آفلاین	-	شبیه‌سازی
[49]	امضاهای داپلر	k-NN وزن‌دار (W-kNN)	اهداف راداری	۹۹	آفلاین	۲۰۰۰۰	شبیه‌سازی
[55]	سیگنال‌های رادار با وضوح پایین	D-CNN۱	انسان، وسیله نقلیه	۹۹	آفلاین	-	واقعی

۶. مراجع

[1] Bilik, J. Tabrikian, and A. Cohen, "GMM-based target classification for ground surveillance Doppler radar," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 42, no. 1, pp. 267–278, Jan. 2006, doi: https://doi.org/10.1109/taes.2006.1603422.

[2] T. McConaghy, H. Leung, E. Bosse, and V. Varadan, "Classification of audio radar signals using radial basis function neural networks," *IEEE Transactions on Instrumentation and Measurement*, vol. 52, no. 6, pp. 1771–1779, Nov. 2003, doi: https://doi.org/10.1109/tim.2003.820450.

[3] A. Passah, S. N. Sur, A. Abraham, and D. Kandar, “Synthetic Aperture Radar image analysis based on deep learning: A review of a decade of research,” *Engineering Applications of Artificial Intelligence*, vol. 123, no. 3, p. 106305, Aug. 2023, doi: https://doi.org/10.1016/j.engappai.2023.106305.

[4] Passah, A., Sur, S. N., Abraham, A., & Kandar, D. (2023). Synthetic Aperture Radar image analysis based on deep learning: A review of a decade of research. *Engineering Applications of Artificial Intelligence*, *123*, 106305. https://doi.org/10.1016/j.engappai.2023.106305

[5] X. Li, C.-S. Li, and P. Wang, “MULTI-LOOK SAR ATR USING TWO-LEVEL DECISION FUSION OF NEURAL NETWORK AND SPARSE REPRESENTATION,” *Progress In Electromagnetics Research M*, vol. 46, no. 4, pp. 89–100, 2016, doi: https://doi.org/10.2528/pierm15092304.

[6] T. P. Chen, C. L. Lin, K. C. Fan, W. Y. Lin, and C. W. Kao, “Radar automatic target recognition based on real-life hrrp of ship target by using convolutional neural network*,” *6*, vol. 37, no. 4, pp. 733–752, Apr. 2021, doi: https://doi.org/10.6688/jise.202107_37(4).0001.

[7] W. Wang *et al.*, “High-Resolution Radar Target Recognition via Inception-Based VGG (IVGG) Networks,” *Computational Intelligence and Neuroscience*, vol. 2020, no. 6, pp. 1–11, Jul. 2020, doi: https://doi.org/10.1155/2020/8893419.

[8] P. Singh, S. Menkudale, S. Soni, V. R. Tank, and A. A. B. Raj, “Comprehensive Survey on Radar Systems and Its Target Classification Techniques,” *Journal of Electronics and Electrical Engineering*, vol. 7, no. 7, pp. 234–269, Feb. 2025, doi: https://doi.org/10.37256/jeee.4120255934.

[9] X. Cai, M. Giallorenzo, and K. Sarabandi, “Machine Learning-Based Target Classification for MMW Radar in Autonomous Driving,” *IEEE Transactions on Intelligent Vehicles*, vol. 8, no. 8, pp. 1–1, 2021, doi: https://doi.org/10.1109/tiv.2020.30489.

[10] Y. Liu, W. Li, L. Lu, and J. Zhou, “NUDT4MSTAR: A New Dataset and Benchmark Towards SAR Target Recognition in the Wild,” *Arxiv.org*, 2022. https://arxiv.org/html/2501.13354v1 (accessed Sep. 18, 2025).

[11] V. C. Chen, F. Li, S. Ho, and H. Wechsler, “Micro-Doppler effect in radar: phenomenon, model, and simulation study,” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 42, no. 1, pp. 2–21, Jan. 2006, doi: https://doi.org/10.1109/TAES.2006.1603402.

[12] B. Zrnić, M. Andrić, B. Bondzulić, S. Simić, and D. Bujaković, “Analysis of Radar Doppler Signature from Human Data,” *DOAJ (DOAJ: Directory of Open Access Journals)*, vol. 10, no. 10, Apr. 2014.

[13] D. M. Bujakovic, Z. M. Durovic, M. S. Andric, B. P. Bondzulic, and S. M. Simic, “Expert system based on hidden Markov models for recognition of radar targets,” *2022 30th Telecommunications Forum (TELFOR)*, vol. 12, no. 12, pp. 1–8, Nov. 2016, doi: https://doi.org/10.1109/telfor.2016.7818819.

[14] M. Leonardi, G. Ligresti, and E. Piracci, “Drones Classification by the Use of a Multifunctional Radar and Micro-Doppler Analysis,” *Drones*, vol. 6, no. 5, p. 124, May 2022, doi: https://doi.org/10.3390/drones6050124.

[15] M. S. Andric, D. M. Bujakovic, B. P. Bondzulic, and B. M. Zrnic, “Cepstrum-based analysis of radar Doppler signals,” *14*, vol. 14, no. 14, pp. 575–578, Oct. 2011, doi: https://doi.org/10.1109/telsks.2011.6143180.

[16] M. Rao and P. R. Kumar, “Radar Target Recognition and Classification Using Supervised Machine Learning Approaches,” *Algorithms for intelligent systems*, vol. 15, no. 15, pp. 345–358, Jan. 2022, doi: https://doi.org/10.1007/978-981-16-6332-1_30.

[17] Q. Cheng, L. Chen, and Y. Zhang, “Classification of RCS sequences based on KL divergence,” *The Journal of Engineering*, vol. 2019, no. 20, pp. 6475–6478, Aug. 2019, doi: https://doi.org/10.1049/joe.2019.0358.

[18] M. Alaee and H. Amindavar, "Chirplet-based target recognition using RADAR technology," *2008 5th IEEE Sensor Array and Multichannel Signal Processing Workshop*, Darmstadt, Germany, 2008, pp. 451-454, doi: 10.1109/SAM.2008.4606910.

[19] J. Cui and W. Wong, “The adaptive chirplet transform and visual evoked potentials,” *IEEE transactions on bio-medical engineering*, vol. 53, no. 7, pp. 1378–1384, Jul. 2006, doi: https://doi.org/10.1109/TBME.2006.873700.

[20] J.T. Astola *et al.*, “Application of Bispectrum Estimation for Time-Frequency Analysis of Ground Surveillance Doppler Radar Echo Signals,” *IEEE transactions on instrumentation and measurement*, vol. 57, no. 9, pp. 1949–1957, Sep. 2008, doi: https://doi.org/10.1109/tim.2008.917192.

[21] C. L. Nikias and M.R. Raghuveer, “Bispectrum estimation: A digital signal processing framework,” *Proceedings of the IEEE*, vol. 75, no. 7, pp. 869–891, Jul. 1987, doi: https://doi.org/10.1109/proc.1987.13824.

[22] V. Bhatnagar, A. K. Shaw, and R. W. Williams, “Improved automatic target recognition using singular value decomposition,” *22*, vol. 5, no. 22, pp. 2717–2720, Nov. 2002, doi: https://doi.org/10.1109/icassp.1998.678084.

[23] I. Bilik, J. Tabrikian, and A. Cohen, “Doppler based ATR for ground surveillance radar,” in *Proceedings of RADAR*, 2004, pp. 221–226.

[24] I. Bilik and J. Tabrikian, “Radar target classification using doppler signatures of human locomotion models,” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 43, no. 99, pp. 1510–1522, Jan. 2007, doi: https://doi.org/10.1109/taes.2007.4407474.

[25] H. Göksu, “Ground moving target recognition using log energy entropy of wavelet packets,” *Electronics Letters*, vol. 54, no. 4, pp. 233–235, Dec. 2017, doi: https://doi.org/10.1049/el.2017.4267.

[26] C. K. Chui, “Adapted Wavelet Analysis from Theory to Software (Mladen Victor Wickerhauser),” *SIAM Review*, vol. 38, no. 1, pp. 160–160, Mar. 1996, doi: https://doi.org/10.1137/1038018.

[27] S. M. Qasim, A. A. Khan, Saleh Alshebeili, and S. A. Abbasi, "FPGA based architecture for the computation of fourth-order cross moments," *International Conference on Intelligent and Advanced Systems*, vol. 28, no. 28, Nov. 2007, doi: https://doi.org/10.1109/icias.2007.4658615.

[28] J. M. Mendel, "Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications," *Proceedings of the IEEE*, vol. 79, no. 3, pp. 278–305, Mar. 1991, doi: https://doi.org/10.1109/5.75086.

[29] H. Zhu and Q. Li, "Target Classification by Conventional Radar Based on Bispectrum and Deep CNN," *Progress In Electromagnetics Research C*, vol. 130, no. 30, pp. 127–138, 2023, doi: https://doi.org/10.2528/pierc22102401.

[30] Y. You, R. Xie, J. Gu, T. Wang, P. Li, and Y. Rui, "Research on different classifiers of automatic target recognition and classification for low-resolution ground radar," *31*, vol. 14, no. 31, pp. 38–38, May 2022, doi: https://doi.org/10.1117/12.2631543.

[31] R. Amiri and A. Shahzadi, "Micro-Doppler based target classification in ground surveillance radar systems," *Digital Signal Processing*, vol. 101, no. 1, p. 102702, Jun. 2020, doi: https://doi.org/10.1016/j.dsp.2020.102702.

[32] Ammar Mesloub, Karim Abed-Meraim, and Adel Belouchrani, "Ground moving target classification based on micro-Doppler signature using novel spectral information features," *HAL (Le Centre pour la Communication Scientifique Directe)*, vol. 1, no. 1, Oct. 2017, doi: https://doi.org/10.23919/eurad.2017.8249195.

[33] R. Xie *et al.*, "Low-resolution ground surveillance radar target classification based on 1D-CNN," *1*, vol. 1, no. 1, pp. 12–12, Dec. 2019, doi: https://doi.org/10.1117/12.2559150.

[34] M. Xu, Y. Rui, Y. Wang, R. Xie, P. Li, and M. Liao, "Ground surveillance radar targets classification based on 2D multichannel adaptive weighted CNN," *1*, vol. 1409, no. 1, pp. 103–103, Mar. 2024, doi: https://doi.org/10.1117/12.3023245.

[35] L. Chen, P. Hu, Z. Pan, X. Sun, and Z. Wang, "HRRPGraphNet: A Graph Neural Network Based Approach for HRRP Radar Target Recognition," *arXiv (Cornell University)* , vol. 1, no. 1, Jul. 2024, doi: https://doi.org/10.48550/arxiv.2407.08236.

[36] K. W. Lau, Y. Abbas, and L.-M. Po, "AudioRepInceptionNeXt: A lightweight single-stream architecture for efficient audio recognition," *Neurocomputing*, vol. 578, no. 1, pp. 127432–127432, Feb. 2024, doi: https://doi.org/10.1016/j.neucom.2024.127432.

[37] W. Wang, C. Zhang, J. Tian, J. Ou, and J. Li, "A SAR Image Target Recognition Approach via Novel SSF-Net Models," *Computational Intelligence and Neuroscience*, vol. 2020, no. 1, pp. 1–9, Jul. 2020, doi: https://doi.org/10.1155/2020/8859172.

[38] Krithika R and Jayanthi A.N, "HIGH RESOLUTION RADAR TARGET RECOGNITION USING DEEP VIDEO PROCESSING TECHNIQUE," *ICTACT Journal on Image and Video Processing*, vol. 15, no. 2, pp. 3454–3462, Nov. 2024, doi: https://doi.org/10.21917/ijivp.2024.0489.

[39] P. Lang, "A Comprehensive Survey of Machine Learning Applied to Radar Signal Processing." Sep. 29, 2020. Available: https://arxiv.org/abs/2009.13702

[40] Q. Xiang *et al.*, "Quadruplet depth-wise separable fusion convolution neural network for ballistic target recognition with limited samples," *Expert Systems with Applications*, vol. 235, no. 1, pp. 121182–121182, Aug. 2023, doi: https://doi.org/10.1016/j.eswa.2023.121182.

[41] Dulani Meedeniya, Isuru Ariyarathne, Meelan Bandara, Roshinie Jayasundara, and C. Perera, "A Survey on Deep Learning-based Forest Environment Sound Classification at the Edge," *ACM Computing Surveys*, vol. 1, no. 1, Sep. 2023, doi: https://doi.org/10.1145/3618104.

[42] U. Chipengo, A. P. Sligar, S. M. Canta, M. Goldgruber, H. Leibovich, and S. Carpenter, "High Fidelity Physics Simulation-Based Convolutional Neural Network for Automotive Radar Target Classification Using Micro-Doppler," *IEEE Access*, vol. 9, no. 1, pp. 82597–82617, 2021, doi: https://doi.org/10.1109/access.2021.3085985.

[43] B. P. Bogert, "The quefrency alanysis of time series for echoes: Cepstrum pseudo-autocovariance, cross-cepstrum, and saphe cracking," *1*, vol. 1, no. 1, pp. 209–243, Jan. 1963.

[44] H. BYUN and S.-W. LEE, "A SURVEY ON PATTERN RECOGNITION APPLICATIONS OF SUPPORT VECTOR MACHINES," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 17, no. 03, pp. 459–486, May 2003, doi: https://doi.org/10.1142/s0218001403002460.

[45] M. Jahangir, K. M. Ponting, and J.W. O'Loghlen, "Robust Doppler classification technique based on hidden Markov models," *IEE Proceedings - Radar Sonar and Navigation*, vol. 150, no. 1, pp. 33–33, Jan. 2003, doi: https://doi.org/10.1049/ip-rsn:20030027.

[46] Oncel Tuzel, Fatih Porikli, and P. Meer, "Region Covariance: A Fast Descriptor for Detection and Classification," *Lecture Notes in Computer Science*, vol. 1, no. 1, pp. 589–600, May 2006, doi: https://doi.org/10.1007/11744047_45.

[47] D. A. Reynolds, "A Gaussian mixture modeling approach to text-independent speaker identification," *1*, vol. 1, no. 1, Aug. 1992.

[48] J. J. Verbeek, N. Vlassis, and B. Kröse, "Efficient Greedy Learning of Gaussian Mixture Models," *Neural Computation*, vol. 15, no. 2, pp. 469–485, Feb. 2003, doi: https://doi.org/10.1162/089976603762553004.

[49] I. Bilik and P. Khomchuk, "Minimum Divergence Approaches for Robust Classification of Ground Moving Targets," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 48, no. 1, pp. 581–603, Jan. 2012, doi: https://doi.org/10.1109/taes.2012.6129657.

HAND-CRAFTED VS. DEEP LEARNING ALGORITHMS," *International Journal of Innovation in Mechanical Engineering and Advanced Materials*, vol. 5, no. 3, pp. 99–99, Jan. 2024, doi: https://doi.org/10.22441/ijimeam.v5i3.24794.

[59] Z. Li and Y. Liu, "Onboard autonomous mission generation method based on user preference," *Advances in Space Research*, vol. 74, no. 1, pp. 437–453, Mar. 2024, doi: https://doi.org/10.1016/j.asr.2024.03.055.

[60] Zhang Bo-yan, "Survey of radar target recognition using one-dimensional high range resolution profiles," *Systems engineering and electronics*, vol. 1, no. 1, Jan. 2013.

[61] A. Ajurloo, M. Hadavi, M. Naibi, M. Bastani, "Short-term and Long-term Dependency Modeling of Consecutive Range Profiles for Radar Target Recognition", in Radar, 2015; vol. 3 no. 2. (In Persian) https://radar.ihu.ac.ir/article_202671.html

[62] A. Jahadsaravani. "Detection and tracking of aerial targets using convolutional neural networks". In Radar, 2021; vol. 10, no. 2, p. 1-14. (In Persian) https://radar.ihu.ac.ir/article_208812.html

[63] M. Alaee and H. Amindavar, "Chirplet-based target recognition using RADAR technology," *2008 5th IEEE Sensor Array and Multichannel Signal Processing Workshop*, Darmstadt, Germany, 2008, pp. 451-454, doi: 10.1109/SAM.2008.4606910.

[64] Tait, Peter. *Introduction to radar target recognition*. Vol. 18. IET, 2005. doi.org/10.1049/PBRA018E

[65] Pardhu, Thottempudi, and Vijay Kumar. "Novel implementations of clutter and target discrimination using threshold skewness method." *Traitement du Signal* 38.4 (2021): 1079-1085. doi:10.18280/ts.380418

[66] Kim, Ji-Hyeon, Soon-Young Kwon, and Hyoung-Nam Kim. "Spectral-Kurtosis and image-embedding approach for target classification in micro-Doppler signatures." *Electronics* 13.2 (2024): 376. doi:10.3390/electronics13020376

[50] Chai, Jing, H. Liu, and Z. Bao, "A W-KNN classifier to improve radar outlier rejection performance," in *IET*, Apr. 2009.

[51] B. Ahmad *et al.*, "A Review of Automatic Classification of Drones Using Radar: Key Considerations, Performance Evaluation and Prospects," *INDIGO (University of Illinois at Chicago)*, vol. 1, no. 1, May 2023, doi: https://doi.org/10.36227/techrxiv.22769693.

[52] Gong, "An introduction to radar automatic target recognition (ATR) technology in ground-based radar systems," *arXiv preprint*, no. arXiv:2310.14769. Oct. 23, 2023.

[53] B. Rahul, K. Rashmita, V. Thiruchelvam, and Y. Susiapan, "Improving accuracy for classifying audio based mel frequency features using artificial neural network in comparison with Random Forest algorithm," *AIP conference proceedings*, vol. 3161, no. 1, pp. 020095–020095, Jan. 2024, doi: https://doi.org/10.1063/5.0229242.

[54] M. Jahangir, I. A. Bashar, and J. B. Chris, "The application of performance metrics to staring radar for drone surveillance," in *IEEE*, Jan. 2021, pp. 382–385.

[55] D. Avola *et al.*, "Signal Enhancement and Efficient DTW-based Comparison for Wearable Gait Recognition," *Computers & Security*, vol. 137, no. 1, pp. 103643–103643, Feb. 2024, doi: https://doi.org/10.1016/j.cose.2023.103643.

[56] R. Xie, B. Dong, P. Li, and Y. Rui, "Automatic target recognition method for low-resolution ground surveillance radar based on 1D-CNN," in *Twelfth International Conference on Signal Processing Systems*, SPIE, Jan. 2021, pp. 48–55.

[57] R. Zhang, X. Wei, X. Li, and Z. Liu, "Analysis about the speckle of radar high resolution range profile," *Science China Technological Sciences*, vol. 54, no. 1, pp. 226–236, Dec. 2010, doi: https://doi.org/10.1007/s11431-010-4207-x.

[58] A. Rahman, L. G. Lie, Haris Wahyudi, and Fahri Heltha, "COMPARING ROTATION-ROBUST MECHANISMS IN LOCAL FEATURE MATCHING: