

**discrimination of sea chaff in search mode based on deep learning algorithm**

S.V Alavi panah zo , N.Zarei \*, M. Molazadeh Golmahaleh

\*Assistant Professor, Imam Hossein University, Tehran, Iran  
(Received:2022 /04/28, Revised: 2022/07/15, Accepted: 2022/08/15, Published: 2022/09/21)

DOR: <https://dor.isc.ac/dor/20.1001.1.23454024.1401.10.1.10.9>**ABSTRACT**

Today, the importance of electronic warfare in the field of defense is not hidden. Among the various techniques of electronic warfare, chaff can play an effective role, which we discussed in this research. The chaff has many capabilities. Among these capabilities, it can be mentioned that it is easy to make and use, low cost jamming and wide band frequency coverage. It can also refer to deception in angle and distance, angle tracking error, and effect on the victim's radar in time, frequency, and polarization domain. Many features can be used for discrimination of chaff from target (ship). In this research, among the various features to discrimination it, the fluctuation feature, which is the variation of radar cross section, has been used. Also, in this research, in order to achieve better discrimination rate and less error, different deep learning algorithms and networks have been used. In addition, while we were able to discriminate the target of chaff based on deep learning, we achieved better recognition rate than the works that have been published so far. For example, in this study, we achieved a 15% improvement in performance compared to the resent published articles in the signal to noise ratio power of 6 dB and in the signal to noise ratio of 12 dB, the discrimination rate is 99.5%. Furthermore, we proposed the most suitable structure among the various deep learning structures in this application.

**Keywords:** Electronic warfare, Chaff, target, discrimination, deep learning

This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

**Publisher:** Imam Hussein University\*Corresponding Author Email: [Zareina@ihu.ac.ir](mailto:Zareina@ihu.ac.ir)

## علمی - پژوهشی

# تشخیص هدف از چف دریایی در مد جستجو مبتنی بر الگوریتم یادگیری عمیق

سید وحید علوی پناه<sup>۱</sup>، نادعلی زارعی<sup>۲\*</sup>، مهدی ملازاده<sup>۳</sup>

۱- کارشناسی ارشد، ۲و۳- استادیار، دانشگاه جامع امام حسین (ع)، تهران، ایران

(دریافت: ۱۴۰۱/۰۲/۰۸، بازنگری: ۱۴۰۱/۰۴/۲۴، پذیرش: ۱۴۰۱/۰۵/۲۴، انتشار: ۱۴۰۱/۰۶/۳۰)

DOR: <https://dor.isc.ac/dor/20.1001.1.23454024.1401.10.1.10.9>



\* این مقاله یک مقاله با دسترسی آزاد است که تحت شرایط و ضوابط مجوز Creative Commons Attribution (CC BY) توزیع شده است.

نویسندگان ©

ناشر: دانشگاه جامع امام حسین (ع)

## چکیده

امروزه اهمیت جنگ الکترونیک در حوزه دفاعی بر کسی پوشیده نیست. از بین تکنیک‌های مختلف جنگ الکترونیک، چف می‌تواند نقش مؤثری را ایفا کند. چف دارای قابلیت‌های متعددی است. از جمله می‌توان به سهولت ساخت و به‌کارگیری آن، اخلاص ارزان‌قیمت و پوشش باند فرکانسی وسیع آن اشاره کرد. همچنین می‌توان به فریب در زاویه و فاصله، ایجاد خطای دریایی و تأثیر بر رادار قربانی در ابعاد زمان، فرکانس و پلاریزاسیون اشاره نمود. برای تشخیص چف از ویژگی‌های متعددی می‌توان بهره برد. در این پژوهش از بین ویژگی‌های مختلف جهت تشخیص آن، از ویژگی تموج که همان میزان تغییرات سطح مقطع راداری می‌باشد، استفاده شده است. همچنین در این پژوهش جهت دستیابی به دقت تشخیص بهتر و خطای کمتر، از الگوریتم‌ها و شبکه‌های مختلف یادگیری عمیق استفاده شده است. در این راستا ضمن اینکه توانستیم شناسایی هدف از چف را مبتنی بر یادگیری عمیق انجام دهیم، به دقت تشخیص بهتر از کارهایی که تاکنون منتشر شده است، دست یابیم. به‌عنوان مثال در نسبت توان سیگنال به نویز ۶dB در این پژوهش به بهبود عملکرد ۱۵٪ نسبت به مقالاتی که در این حوزه منتشر شد، دست یافتیم و در نسبت توان سیگنال به نویز ۱۲dB دقت تشخیص ۹۹٫۵٪ درصد حاصل شده است. علاوه بر این توانستیم در این کاربرد، از بین ساختارهای مختلف یادگیری عمیق، مناسب‌ترین ساختار را پیشنهاد دهیم.

## کلیدواژه‌ها: جنگ الکترونیک، چف، هدف، تشخیص، یادگیری عمیق

### ۱- مقدمه

تشخیص آن از کشتی بر اساس شبکه‌های مختلف یادگیری عمیق<sup>۴</sup> مورد ارزیابی قرار گرفته است. در این راستا دستیابی به ویژگی متمایزکننده کشتی از ابر چف و نیز پردازشگر دقیق‌تر تشخیص‌دهنده هدف اصلی (همان کشتی) مبتنی بر فرایند آموزش و تست الگوریتم موردتوجه بوده است.

از اثرات راهبردی و مهم تشخیص چف می‌توان به بالابردن توان نظامی در مقابله با تهدیدات دریایی (هوایی) در شرایط جنگ الکترونیک نام برد. با حل این مسئله می‌توان به یکی از چالش‌های موجود در جنگ الکترونیک آن هم در حوزه دریایی پایان داد. یکی از اهداف این پژوهش ارائه الگوریتمی جهت مجهز کردن رادارها در راستای شناسایی و طبقه‌بندی اهداف مختلف از جمله چف می‌باشد. رادارهای مجهز به الگوریتم‌های شناسایی و طبقه‌بندی نوع هدف، می‌توانند؛ مانند چشم انسان که علاوه بر دیدن موقعیت اشیاء، نوع آن را هم تشخیص می‌دهد، به کاربر در تصمیم‌گیری صحیح کمک کنند [۱۱]. زمانی که از چف در روش خود محافظ استفاده می‌شود، تکنیک‌های

از زمان‌های گذشته تا به امروز انسان همیشه به دنبال پیداکردن راه‌های جنگ الکترونیک جهت مقابله با دشمن بوده است. این مقابله وقتی حساس‌تر شد که روزبه‌روز راه‌ها و تجهیزات حمله الکترونیکی پیشرفته‌تر شده است؛ بنابراین، مقابله هوشمندانه‌تر موردتوجه قرار گرفت. در طول سال‌های جنگ‌های مختلف روش‌های متفاوتی برای مقابله با ابزار جنگی همچون موشک به وجود آمد. روش‌هایی مثل چف<sup>۱</sup>، دکوی<sup>۲</sup> و فلر<sup>۳</sup> که هرکدام قابلیت‌های خاص خود را دارا هستند. یکی از مهم‌ترین روش‌های مقابله با موشک‌های تعقیب‌کننده رادیویی، چف می‌باشد.

در این پژوهش بر اساس نتایج و مقالات منتشر شده در خصوص رفتار و ویژگی‌های چف، ویژگی مناسب انتخاب و نحوه

Zareina@ihu.ac.ir

\*رایانامه نویسنده مسئول:

1- Chaff  
2- Decoy  
3- Flare

هدف ارزیابی شده و با انتخاب ویژگی مناسب به همراه معیار آن، برای تشخیص اقدام گردد. برای بررسی ویژگی‌ها لازم است پارامترهای سیگنال‌های بازگشتی از چف و هدف را استخراج و تحلیل کرد و سپس پارامتر متمایزکننده هدف و چف را به‌عنوان ویژگی پیشنهاد داد. بدین منظور، در بخش دوم به رفتار و ویژگی چف و نیز معیار تشخیص آن از هدف کشتی، به همراه تحلیل ریاضی می‌پردازیم. شبیه‌سازی و نمایش داده‌های چف و هدف در بخش سوم ارائه شده است. در بخش چهارم به بررسی شبکه‌های مختلف یادگیری عمیق جهت تشخیص هدف از چف خواهیم پرداخت. در بخش پنجم به مقایسه نتایج دقت تشخیص هدف از چف مبتنی بر شبکه‌های مختلف می‌پردازیم و نهایتاً در بخش ششم، با توجه به دقت تشخیص، مناسب‌ترین شبکه پیشنهاد می‌شود. همچنین به مقایسه دقت تشخیص شبکه پیشنهادی این مقاله و مقاله [۱] خواهیم پرداخت.

## ۲- رفتار و ویژگی چف

صرف‌نظر از نوع هدف، یک رادار سیگنال یکسانی را ارسال می‌کند و اهداف به دلیل اختلافات فیزیکی و ساختاری که با یکدیگر دارند، اثرات متفاوتی بر روی سیگنال ارسالی از رادار خواهند گذاشت که از همین موارد اختلاف به‌عنوان ویژگی‌هایی، برای بیان نوع هدف می‌توان بهره برد.

از جمله این ویژگی‌ها می‌توان به سطح مقطع راداری و میزان تغییرات آن، همبستگی زمانی نمونه‌ها، تموج، رفتار طیفی چف، مدل توزیع چف در فضا، تقارن در کشتی و چف، پراکندگی پژواک در حوزه زمان فرکانس و اثر قطبش (پلاریزاسیون) آن اشاره کرد [۱]. به‌عنوان مثال در مقاله [۵] از بحث تقارن جهت تمایز بین چف و هدف استفاده شده که اثر پرش فرکانس در این روش نیز تحلیل شده است. در مقاله [۶] نیز از ویژگی پژواک کشتی در حوزه زمان و فرکانس جهت تشخیص هدف استفاده شده است. ویژگی انتخابی در این پژوهش، تغییرات سطح مقطع راداری که به تموج نیز معروف است، می‌باشد.

وقتی که تعداد زیادی از دوقطبی‌های چف به‌صورت تصادفی توزیع شده باشند، صرف‌نظر از نوع توزیع هرکدام از دوقطبی‌ها،  $pdf^6$  کل آن با توجه به قضیه حد مرکزی، دارای توزیع گوسی است [۱]. شکل (۱) تابع خودهمبستگی رفتار نمونه‌های ابر چف، حاصل از آزمایش واقعی با رادار باند  $x$ ، را نشان می‌دهد.

گمراه‌سازی و فریب بیشترین کاربرد را دارند که در این مقاله، گمراه‌سازی رادار مبتنی بر ابر چف موردنظر است. مقصود از گمراه‌سازی این است که اهداف کاذب توسط ابر چف در مکان‌هایی متفاوت با مکان سکوی تحت حفاظت و اطراف آن ایجاد شوند.

نکته مثبت چف سادگی ساخت و هزینه کم آن، سهولت به‌کارگیری و تأثیر آن بر انواع رادارها است [۱]. در حوزه تشخیص اخلاص چف مقالات انگشت شماری منتشر شده است که برای نمونه به تعدادی از آنها اشاره می‌کنیم.

مقاله [۱] که یکی از مقالات حوزه چف می‌باشد به تشخیص هدف از چف در فضای چندبعدی پرداخته است. مقاله مذکور در نهایت طبقه‌بند SVM<sup>۱</sup> را که کارایی عملکرد مناسب‌تری نسبت به بقیه طبقه‌بندها داشته انتخاب و مناسب‌ترین ویژگی را پیشنهاد داده است.

مقاله [۲] که در سال ۲۰۲۰ منتشر گردید به تشخیص چف بر مبنای نمونه‌های پروفایل فاصله<sup>۲</sup> و شبکه کانولوشنی با استفاده از نرم‌افزار پایتون و نرم‌افزار متلب اشاره کرده است. نویسنده در این مقاله با استفاده از شبکه کانولوشنی به دقت تشخیص ۸۷٪ در نرم‌افزار متلب و دقت تشخیص ۹۳٪ در نرم‌افزار پایتون به‌زای مقدار سیگنال به چف<sup>۳</sup> ۵dB دست‌یافته است. در مقاله [۳] نیز از ویژگی قطبش برای تشخیص چف استفاده شده است.

مقاله [۴] به موضوع طبقه‌بندی سیگنال اخلاص، از جمله ابر چف که اولین مرحله فرآیند ضد اخلاص می‌باشد، پرداخته است. در این مقاله از سه زیرشبکه (1D-CNN، 2D-CNN و شبکه فیوژن) برای طبقه‌بندی استفاده شده است. نتایج تجربی نشان می‌دهد که روش پیشنهادی دقت طبقه‌بندی مطلوبی را در مقایسه با بقیه روش‌ها مانند یادگیری ماشین و RF<sup>۴</sup> ارائه می‌دهد.

مقاله [۱۰] به موضوع مکان‌یابی مبتنی بر قدرت سیگنال دریافتی با استفاده از ترکیب دو شبکه عصبی معروف (CNN, LSTM) پرداخته است. در این مقاله با استفاده از روش پیشنهادی به میانگین خطای ۰,۰۷ متر دست یافته‌اند، که منجر به بهبود دقت مکان‌یابی شده است.

در مقاله [۱۱] جهت تشخیص اهداف راداری از شبکه عصبی عمیق GMDH<sup>۵</sup> استفاده شده است. روش پیشنهادی استفاده شده نسبت به باقی روش‌های ذکر شده در مقاله مذکور به میزان ۵٪ باعث بهبود عملکرد شده است.

جهت تشخیص چف از هدف، ابتدا باید ویژگی‌های چف و

1- Support Vector Machine

2- Range Profile

3- Signal chaff rate

4- Random forest

5- Group Method of Data Handling

6- Probability Density Function

### ۳- تولید داده‌های چف و هدف

نمودار شکل (۱) مینا و مرجع اصلی تولید نمونه‌های چف در این پژوهش می‌باشد. ما می‌خواهیم به مدل درست نمونه‌های چف برسیم. از طرفی می‌دانیم که باتوجه به پراکندگی زیاد چف نسبت به هدف در عمل، نمونه‌های چف همبستگی کمتری نسبت به هدف دارد.

طبق نمودار شکل (۱) تابع خودهمبستگی نمونه‌های ابر چف که حاصل از آزمایش واقعی می‌باشد در  $R(\tau) = 0.1$  نمونه‌ها ناهمبسته هستند که این مقدار در زمان  $\tau = 15ms$  می‌باشد یعنی:

$$R(\tau) = E[x(t)x(t+\tau)] = 0.1 \quad (5)$$

رابطه تابع خودهمبستگی شکل (۱) را به صورت زیر می‌توان در نظر گرفت.

$$R(\tau) = \left| \frac{1}{\sqrt{2\pi}\sigma} \right| e^{-\frac{\tau^2}{2\sigma^2}} \quad (6)$$

و فرم نرمالیزه آن را به صورت

$$R(\tau) = e^{-a\tau^2} \quad (7)$$


می‌توان در نظر گرفت. باتوجه به روابط (۵) و (۷) مقدار  $\alpha$  محاسبه می‌شود و تابع همبستگی را می‌توان شبیه‌سازی نمود. برای طراحی فیلتر مولد نمونه‌های چف از تابع خودهمبستگی برای این تحقیق استفاده شده است. نحوه عملکرد فیلتر مولد بدین صورت است که با اعمال نویز گوسی سفید به ورودی فیلتر، در خروجی آن نمونه‌های مورد نظر به دست خواهد آمد که طیف آن میزان همبستگی نمونه‌ها را نشان می‌دهد.

باتوجه به اینکه ورودی فیلتر مولد نویز گوسی سفید می‌باشد خروجی نیز به صورت گوسی خواهد بود. از طرفی دامنه نمونه‌های چف دارای pdf گوسی<sup>۲</sup> است و در خروجی به دامنه رایلی نیاز داریم، برای این کار باید قدرمطلق خروجی را محاسبه کنیم. در این صورت بلوک دیاگرام مولد نمونه‌های چف با pdf رایلی و psd دلخواه به صورت شکل زیر خواهد بود.



شکل (۴): نمایش بلوک دیاگرام مولد نمونه‌های چف

تابعی که جهت شبیه‌سازی در این تحقیق از آن برای طراحی فیلتر مولد نمونه‌های چف استفاده شده است تابع یول والکر<sup>۳</sup> می‌باشد که ورودی این تابع برای به دست آوردن ضرایب فیلتر،



شکل (۱): نمایش تابع خودهمبستگی نمونه‌های ابر چف حاصل از آزمایش واقعی با رادار باند X [۱].

ملاحظه می‌گردد، نمونه‌های ابر چف دارای همبستگی زمانی در حدود ۱۵ ms می‌باشند. این در حالی است که نمونه‌های حاصل از اهداف دریایی دارای همبستگی بیشتری هستند. از جمله دلایل بیشتر بودن میزان همبستگی نمونه‌های هدف می‌توان به صلب بودن هدف و متراکم بودن طیف داپلر هدف اشاره کرد در صورتی که دوقطبی‌های ابر چف صلب نبوده و لذا طیف داپلر چف دارای گستردگی بیشتری می‌باشد. باتوجه به رابطه معکوس بین میزان زمان همبستگی و میزان تموج نمونه‌ها، می‌توان گفت میزان تموج نمونه‌های ابر چف بیشتر از میزان تموج نمونه‌های هدف می‌باشد. به عبارتی می‌توان گفت:

$$\tau_{chf} < \tau_{targ} \rightarrow \text{fluc}_{chf} > \text{fluc}_{targ} \quad (8)$$

در نهایت از چنین نابرابری می‌توان برای تشخیص هدف از چف استفاده نمود.

اگر یک محور  $x$  را در نظر بگیریم و فرض کنیم دیپل‌های چف در هر بازه زمانی  $\tau$ ، یک حرکت گسسته به اندازه  $b$  داشته باشند که  $m$  بار به سمت راست (با احتمال  $p$ ) و  $(n-m)$  بار به سمت چپ (با احتمال  $q$ ) حرکت دارند می‌توان گفت بعد از  $n$  قدم، دیپل در زمان  $t = n\tau$  در موقعیت  $x$  مطابق با رابطه (۲) قرار گرفته است.

$$x = mb - (n-m)b = (2m-n)b \quad (2)$$

در خصوص ویژگی مدل توزیع چف در فضا، دوقطبی‌های آن به طور تصادفی و مطابق تلاطم‌های موجود، حرکتی به صورت افت‌وخیزهای تصادفی<sup>۱</sup> دارند.

$$P_n(m) = C_n^m (1-P)^{n-m} \quad (3)$$

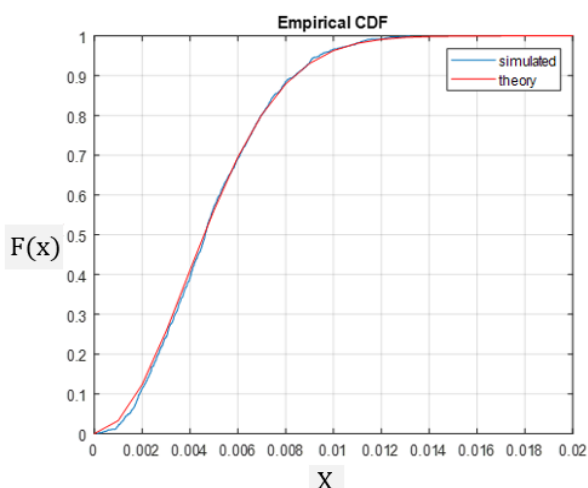
$$p(x, t) = \frac{1}{\sigma_x(t)\sqrt{2\pi}} \exp\left(-\frac{(x-x_0(t))^2}{2\sigma_x^2(t)}\right) \quad (4)$$

در این رابطه که برای نحوه توزیع دیپل‌ها در فضا می‌باشد، وابستگی آن به مرکز  $x_0(t)$  و انحراف استاندارد  $\sigma_x(t)$  به زمان مشهود است.

2- Gaussian distribution

3- Yule-Walker


1- Random walk



شکل (۶): نمایش مقایسه cdf داده‌های چف شبیه‌سازی شده و نظریه

از آنجایی که دسترسی به نمونه‌های واقعی هدف ممکن نبود در این پروژه مجبور به شبیه‌سازی نمونه‌های هدف هستیم. با تغییر میزان مدت زمان همبستگی به نمونه‌های هدف نیز دسترسی خواهیم داشت. برای هدف کشتی، میزان مدت زمان همبستگی را برابر  $\tau = 150ms$  در نظر می‌گیریم.

در شکل (۷) به مقایسه psd نمونه‌های هدف تولید شده با psd تئوری آمده است.



شکل (۷): مقایسه psd هدف تولید شده با psd تئوری

ملاحظه می‌گردد، نمودار psd نمونه‌های تولید شده هدف با psd تئوری انطباق دارند. شکل زیر نیز مقایسه cdf داده‌های شبیه‌سازی شده هدف و حالت تئوری را نمایش می‌دهد.

تابع همبستگی می‌باشد.

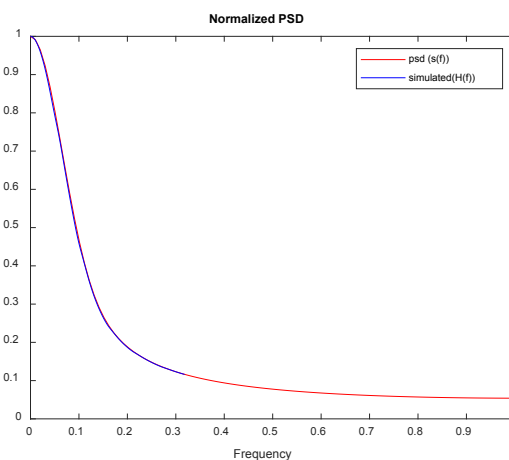
از آنجایی که تبدیل فوریه تابع خودهمبستگی، چگالی طیف توان و یا psd می‌باشد و با در نظر گرفتن شکل (۴) و با فرض اینکه چگالی طیف توان چف مورد نظر  $S_y(f)$  باشد، خواهیم داشت:

$$S_y(f) = |H(f)|^2 S_x(f) \quad (۸)$$

که  $S_x(f)$  چگالی طیف توان نویز سفید ورودی و  $H(f)$  پاسخ فرکانسی فیلتر مربوطه است. با توجه به اینکه نویز ورودی شکل (۴) گوسی سفید می‌باشد، چگالی طیف توان آن واحد بوده و بنابراین داریم:


$$H(f) = \sqrt{S_y} f \quad (۹)$$

با توجه به طراحی فیلتر مورد نظر و تولید نمونه‌های چف برای اطمینان از درستی داده‌های تولیدی به بررسی و مقایسه psd نظریه و نمونه‌های تولیدی ابر چف می‌پردازیم. نمودار (۵) مقایسه psd نمونه‌های ابر چف با psd نظریه حاصل شده را نشان می‌دهد.



شکل (۵): مقایسه psd چف تولید شده با psd نظریه

ملاحظه می‌گردد که پاسخ فرکانسی که شبیه‌سازی شده است انطباق مناسبی با psd حالت نظریه (مطلوب) دارد. این انطباق دو نمودار نشان از صحت طیف نمونه‌های چف ایجاد شده می‌باشد. cdf نمونه‌های تولیدی ابر چف را نیز باید مورد توجه قرار داد. بدین منظور نتایج بررسی cdf داده‌های شبیه‌سازی شده و حالت نظریه در شکل زیر آمده است.



شکل (۹): ساختار نورون مصنوعی و مقایسه آن با نورون طبیعی [۹]

مدل ریاضی دو ساختار بالا را می‌توان به صورت روابط زیر بیان کرد:

$$y = x_1 w_1 + x_2 w_2 + \dots + x_m w_m \quad (10)$$

$$y = \sum_{i=1}^m x_i w_i \quad (11)$$

نمایش برداری روابط بالا می‌تواند به صورت فرمول (۱۲) نیز باشد.

$$y = [x_1 \ x_2 \ \dots \ x_m] \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{bmatrix} \quad (12)$$


برای نمایش کلی یک نورون مصنوعی می‌توان به رابطه زیر اشاره کرد:

$$y = f(Z) = f(w^T x + w_0) \quad (13)$$

که در این رابطه  $w$  بردار وزن‌ها،  $x$  بردار ورودی‌ها و  $w_0$  بایاس را نشان می‌دهد.

در حوزه تشخیص و دسته‌بندی بر مبنای یادگیری عمیق، چندین پارامتر مهم باید در مدل‌ها لحاظ شود. پارامترهایی مانند توابع فعال‌ساز و تابع اتلاف<sup>۲</sup> یا هزینه می‌توانند در خروجی مدل شبکه تأثیر بسزایی داشته باشد.

توابع فعال‌ساز در واقع مانند گیتی هستند که در هر نورون وجود دارد. ورودی این گیت همان ورودی‌های هر نورون در هر لایه است و خروجی آن به لایه بعدی منتقل می‌شود. اگر از توابع فعال‌ساز استفاده نشود، وزن‌ها و مقدار بایاس فقط یک معادله خطی را ایجاد می‌کنند. اما این معادله خطی برای حل مسائل پیچیده نمی‌توانند به ما کمک کنند. به‌طور کلی، شبکه‌های عصبی از توابع فعال‌ساز استفاده می‌کنند تا بتوانند به شبکه در یادگیری



شکل (۸): نمایش مقایسه cdf داده‌های هدف شبیه‌سازی شده و تئوری


ملاحظه می‌گردد، نمودار cdf نمونه‌های تولید شده هدف با cdf تئوری انطباق دارند و صحت داده‌های تولید شده هدف را نشان می‌دهد.

#### ۴- شبکه‌های مختلف یادگیری عمیق

الگوریتم‌های یادگیری عمیق زیرمجموعه‌ای از الگوریتم‌های یادگیری ماشین هستند که هدف آن‌ها کشف چندین سطح از بازنمودهای (نمایش)های توزیع شده از داده ورودی است. شبکه‌های عصبی یادگیری عمیق با الهام از مغز انسان ساخته شده‌اند. مغز انسان از واحدهای کوچکی به نام نورون<sup>۱</sup> تشکیل شده است [۸]. یادگیری عمیق نوعی شبکه عصبی مصنوعی است که با استفاده از تکنیک‌های ریاضی ساختاری مشابه با ساختار مغز انسان را ارائه می‌کند. معمولاً شبکه‌های عمیق طوری طراحی می‌شوند که در ساختار خود از نوع یادگیری بدون نظارت استفاده کنند؛ زیرا داده‌های امروزی که برای پردازش آنها از هوش مصنوعی استفاده می‌کنند بسیار زیاد شامل میلیون‌ها داده است و تهیه این داده‌ها به صورت دستی عملاً غیرممکن است [۱۱]. در شکل زیر دو ساختار طبیعی و مصنوعی نورون و مقایسه آن دو باهم را مشاهده می‌کنید.

بهبود عملکرد و کاهش پیچیدگی محاسباتی می‌باشد [۱۲]. به‌طور کلی، یک شبکه CNN از سه لایه اصلی تشکیل می‌شود که عبارت‌اند از: لایه کانولوشن، لایه پولینگ (ادغام) و لایه تماماً متصل.

تعداد لایه‌های استفاده شده شبکه کانولوشن در این پژوهش دو لایه می‌باشد. در لایه اول شبکه از یک فیلتر با سایز ۱۶ و در لایه دو از یک فیلتر با سایز ۳۲ استفاده شده است. لایه‌های مختلف وظایف مختلفی را انجام می‌دهند. در شکل (۱۱) یک معماری کلی از شبکه عصبی کانولوشن برای دسته‌بندی تصاویر به‌صورت لایه به لایه نمایش داده است. در هر شبکه عصبی کانولوشن دو مرحله برای آموزش وجود دارد. مرحله پیش‌خور<sup>۳</sup> و مرحله پس انتشار<sup>۴</sup>.




شکل (۱۱): یک مثال ساده از معماری شبکه عصبی کانولوشن [۹]

دومین شبکه، شبکه عصبی بازگشتی دسته‌ای دیگر از شبکه‌های عصبی می‌باشد. به‌صورت خلاصه به این خانواده از شبکه‌ها، شبکه RNN نیز گفته می‌شود. شبکه عصبی بازگشتی برای پردازش داده سری زمانی و داده ترتیبی مناسب است. برای شبکه بازگشتی مؤلفه زمان اهمیت زیادی دارد، درحالی‌که در شبکه CNN توجه به مؤلفه زمانی دیده نمی‌شود. شبکه RNN و شبکه LSTM دو عضو از خانواده شبکه بازگشتی هستند. تعداد لایه‌های استفاده شده شبکه بازگشتی در این پژوهش چهار لایه می‌باشد. در لایه‌های اول و دوم شبکه از یک فیلتر با سایز ۶۴ و در لایه‌های سوم و چهارم از یک فیلتر با سایز ۳۲ استفاده شده است.

داده‌های پیچیده کمک و پیش‌بینی قابل‌قبولی را در خروجی ارائه دهند [۹]. این نوع توابع شامل دو دسته‌ی خطی و غیرخطی هستند. در این پژوهش از توابع خطی سیگموئید<sup>۱</sup> و ReLU استفاده شده است.

در شکل زیر تابع فعال‌ساز سیگموئید نمایش داده شده است.



شکل (۱۰): تابع فعال‌ساز سیگموئید [۹]

در مورد تابع هزینه در واقع می‌توان گفت که میزان خطا در هر بار اجرای شبکه عصبی را برای داده‌های آموزشی نمایش می‌دهد. در شبکه‌های عصبی توابع هزینه مختلفی وجود دارد که در این پژوهش از تابع MSE برای رسیدن به خروجی مطلوب شبکه استفاده گردیده است. رابطه (۱۴) به تابع MSE<sup>۲</sup> اشاره دارد.

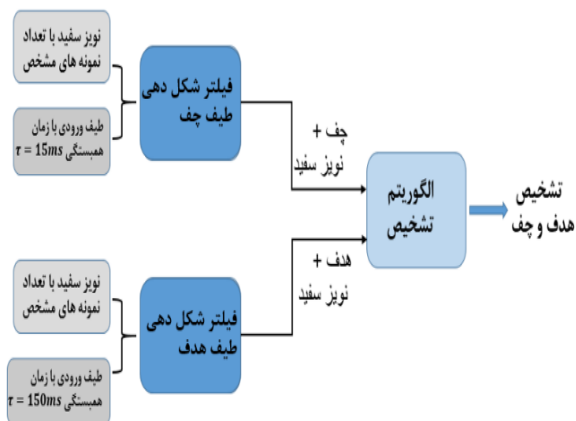
$$MSE\ loss = \frac{1}{N} \sum_{i=1}^N (y_p - y_t)^2 \quad (14)$$

به‌طور کلی در حوزه یادگیری عمیق نحوه انتخاب و استفاده از توابع فعال‌ساز و هزینه و تعداد لایه‌های هر شبکه باتوجه به نوع پژوهش کاربر می‌تواند مورد استفاده قرار دهد. در حوزه یادگیری عمیق شبکه‌های مختلفی را در اختیار داریم؛ مانند شبکه‌های کانولوشنی و بازگشتی که هر شبکه ساختار و معماری مخصوص به خود را دارد. این شبکه‌ها بسته به کاربردهای متفاوت و نوع داده‌ها انتخاب می‌شوند. در این پژوهش از ۳ نوع شبکه مختلف جهت رسیدن به خروجی مطلوب استفاده شده است.

اولین شبکه استفاده شده در این پژوهش شبکه‌های عصبی کانولوشن (CNN) می‌باشد که یکی از مهم‌ترین روش‌های یادگیری عمیق هستند. در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی رایانه و مخابرات است. به‌عنوان مثال از شبکه عصبی کانولوشنی می‌توان جهت تخمین ورود سیگنال فضایی جهت پردازش استفاده نمود که نسبت به سایر روش‌ها مانند MUSIC و دیگر الگوریتم‌های سنتی دارای

3- feed forward  
4- back propagation

1- Sigmoid  
2- Mean Squared Error



شکل (۱۴): نمایش طرح بلوکی پیشنهادی جهت تشخیص


همان‌طور که در بخش مقدمه گفته شد، در این پژوهش هدف اهداف این است که از شبکه‌های مختلف یادگیری عمیق جهت تشخیص استفاده شود و با یکدیگر مقایسه گردد. این نکته باید ذکر گردد که در شبکه‌های مختلف یادگیری عمیق تنظیم پارامترهای شبکه مانند نرخ یادگیری، تعداد لایه‌ها، مقدار تکرار آموزش شبکه، توابع فعال‌ساز و... به نوع پژوهش و تجربه محقق بستگی دارد. از الگوریتم‌های یادگیری عمیق در بسیاری از فعالیت‌ها و پژوهش‌های علمی استفاده شده است. در [۷] به موضوع طبقه‌بندی فعالیت‌های انسانی با استفاده از شبکه‌های عصبی بازگشتی پرداخته است. دقت طبقه‌بندی این شبکه عصبی بازگشتی به ۹۸٫۸٪ رسیده است.

دو مجموعه داده ورودی استفاده شده در این شبکه شامل ۲۰۰۰ سیگنال تولید شده توسط فیلتر شکل‌دهی می‌باشد که از این مجموعه ۱۰۰۰ سیگنال به هدف و ۱۰۰۰ سیگنال به چف تعلق دارد. همچنین برای هر دسته از سیگنال‌ها برچسبی نسبت به هر سیگنال در نظر گرفته شده است. از آنجایی که در این تحقیق دو نوع سیگنال داریم از اعداد ۰ و ۱ برای برچسب استفاده شده است.

نوع سیگنال	برچسب
چف	[0]
هدف	[1]

بنابراین، در خروجی شبکه که آموزش می‌دهیم، کافی است تشخیص دهیم نوع داده خروجی صفر می‌باشد یا یک.

لازم به ذکر می‌باشد که دپتای ورودی به شبکه در شرایطی تولید شده است که نسبت سیگنال به چف برابر با -۳dB می‌باشد.




شکل (۱۲): سمت چپ: بلوک دیاگرام شبکه بازگشتی با یک گام زمانی، سمت راست: همان شبکه به صورت یک گراف محاسبه باز شده [۹]

سومین شبکه به کار گرفته شده در این پژوهش شبکه LSTM<sup>۱</sup> می‌باشد. بزرگ‌ترین ویژگی LSTM امکان یادگیری وابستگی بلندمدت است که توسط شبکه‌های عصبی بازگشتی امکان‌پذیر نیست. از کاربردهای این نوع شبکه می‌توان به مقاله [۱۳] اشاره کرد. در این مقاله جهت حل مشکل تصادفات گسترده در مقیاس جهانی به استفاده از خودروهای خودران اشاره کرده است که بر اساس شبکه LSTM آموزش داده می‌شوند تا بتوانند از تصادفات جلوگیری کنند.

LSTM برای حل مشکل پدیده ناپدید شده گرادیان در شبکه‌های عصبی بازگشتی به وجود آمدند که تغییر عمده آن جایگزین کردن لایه میانی RNN با یک بلاک که بلاک LSTM نام دارد است. تعداد لایه‌های استفاده شده شبکه LSTM در این پژوهش دولا می‌باشد. در هر دولا به شبکه از یک فیلتر با ساین ۳۲ استفاده شده است.

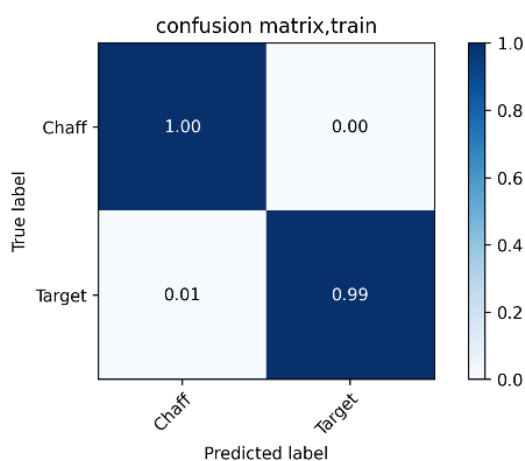
### ۵- شبیه‌سازی تشخیص هدف از چف

در این پژوهش از دو مجموعه داده ورودی برای ارزیابی الگوریتم پیشنهادی استفاده شده است. در شکل زیر طرح پیشنهادی این پژوهش جهت آموزش شبکه و سپس تشخیص آمده است.



شکل (۱۳): شبکه بازگشتی و واحد LSTM [۹]

شبکه‌های مختلف، از ماتریس آشفتگی<sup>۱</sup> استفاده می‌کنیم. جدول یا ماتریس درهم‌ریختگی، نتایج حاصل از تشخیص را بر اساس اطلاعات واقعی موجود، نمایش می‌دهد. در ادامه ماتریس درهم‌ریختگی برای داده‌های آموزش شبکه LSTM نمایش داده شده است.



شکل (۱۷): ماتریس آشفتگی داده‌های آموزش (LSTM)


همان‌طور که مشاهده می‌کنید نحوه کارکرد این ماتریس بدین صورت می‌باشد که در یک محور آن برچسب درست داده وجود دارد و در یک محور دیگر آن برچسب پیش‌بینی داده.

به‌عنوان مثال در داده‌های آموزش شبکه LSTM می‌باشد، از ۱۰۰۰ داده درست هدف ۹۹۳ داده به‌عنوان هدف شناخته شده است و فقط ۷ داده به‌اشتباه چف تشخیص داده شده است که میزان خطا می‌باشد. حال همین جدول یا ماتریس به‌صورت درصد در شکل (۱۷) نمایش داده شده است.


پارامتر صحت<sup>۲</sup> متداول‌ترین معیار اندازه‌گیری کیفیت یک دسته‌بند است که در این پژوهش به دنبال این پارامتر هستیم. از آنجایی که نمودارهای دقت و خطا بر حسب تعداد تکرار (epochs) در هر ۳ شبکه تا حدودی شبیه به هم هستند، بنابراین از نمایش نمودارهای دو شبکه بعدی صرف‌نظر می‌کنیم و فقط ماتریس آشفتگی شبکه‌ها که پارامتر صحت را نشان می‌دهد، نمایش می‌دهیم. شکل (۱۸) خروجی دقت و خطای شبکه CNN را نشان می‌دهند.

بعد از اینکه شبکه‌های عصبی با شرایط ذکر شده توسط دیتای ورودی آموزش داده شد، حال با استفاده از دیتای تست شبکه‌های موردنظر مورد ارزیابی قرار می‌گیرند. تعداد سیگنال‌های تست تولید شده ۲۰۰ عدد در نظر گرفته شده است که شامل ۱۰۰ سیگنال هدف و ۱۰۰ سیگنال چف می‌باشد. تست شبکه‌ها بدین صورت می‌باشد که شبکه‌های مختلف با استفاده از دیتای تست، در  $\frac{S_t}{N}$  های مختلف ارزیابی می‌شوند. منظور از  $S_t$  در اینجا ترکیب داده‌های تست چف و تست هدف می‌باشد.

در نمودارهای زیر خروجی‌های مربوط به شبکه LSTM را مشاهده می‌کنید. همان‌طور که در نمودارها مشخص است شبکه بعد از ۴۰ بار تکرار آموزش به نقطه مطلوبی در دو پارامتر دقت و خطا رسیده است.



شکل (۱۵): نمودار دقت تشخیص بر اساس داده‌های آموزش

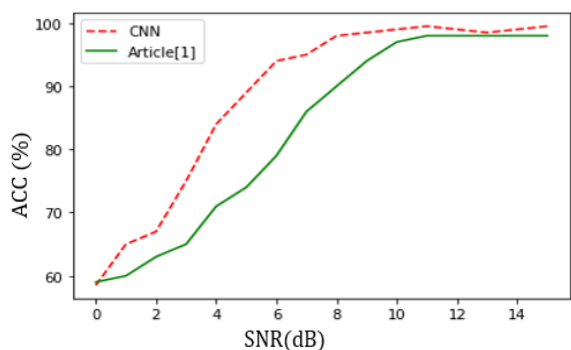


شکل (۱۶): نمودار تابع هزینه بر اساس داده‌های آموزش

برای درک بهتر و نمایش مطلوب‌تر خروجی‌های آموزش

1- Confusion Matrix

2- Accuracy



شکل (۲۱): مقایسه تشخیص هدف از چف روش پیشنهادی در این پژوهش با روش مقاله [۱]

در شکل (۲۱) ملاحظه می‌گردد، شبکه کانولوشنی در مقایسه با مقاله [۱] عملکرد به مراتب بهتری در نسبت سیگنال به نویزهای مختلف داشته است.

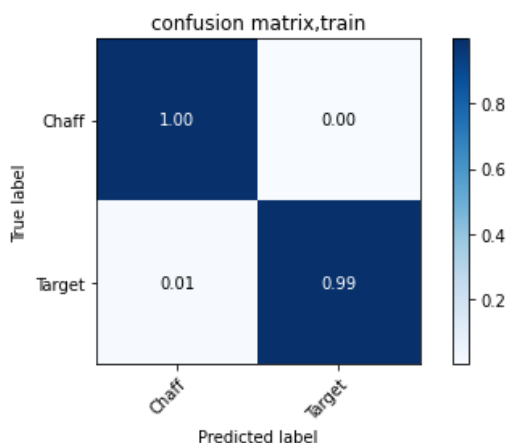
جدول (۱): مقایسه شبکه پیشنهادی و مقاله [۱] در دو SNR مختلف

	CNN	مقاله [۱]
۶dB	٪۹۴	٪۷۹
۱۲dB	٪۹۹٫۵	٪۹۸

### ۶- نتیجه‌گیری


باتوجه به نمایش نمودارهای دقت تشخیص و تابع هزینه در آموزش و تست و همچنین نمایش ماتریس آشفتگی متناسب با هر بخش در شبکه‌های مختلف یادگیری عمیق، داده‌های تست را با SNR های مختلف در شبکه‌های آموزش دیده ارزیابی می‌کنیم. در شکل (۲۱) نمودار مربوط به دقت تشخیص شبکه‌های مختلف در SNR های مختلف داده‌های تست آمده است و شبکه‌ها نسبت به یکدیگر مقایسه شده‌اند. ملاحظه می‌گردد، با بهبود SNR، دقت تشخیص هدف از چف در شبکه‌های مختلف افزایش می‌یابد. اما نکته قابل توجه در نمودار شکل (۲۰) عملکرد بهتر شبکه کانولوشنی (CNN) نسبت به دو شبکه دیگر یعنی RNN و LSTM می‌باشد. همچنین، باتوجه به نمودارهای شکل (۲۱)، ملاحظه می‌گردد، شبکه کانولوشنی در SNR های پایین نسبت به روش پیشنهادی مقاله [۱] عملکرد بهتری داشته است. جدول (۱) نیز به مقایسه بین روش پیشنهادی این مقاله و روش مقاله [۱] در دو SNR مختلف پرداخته است که حاکی از برتری روش پیشنهادی این پژوهش می‌باشد.

علاوه بر موارد فوق، باتوجه به محدودیت اجرای آزمون‌های آزمایشگاهی چف در اتاق آنتن و نیز عدم دسترسی به نرم‌افزار




شکل (۱۸): ماتریس آشفتگی داده‌های آموزش (CNN)

همانند دو شبکه گذشته ماتریس آشفتگی مربوط به آموزش شبکه RNN به عنوان خروجی شبکه، به صورت ماتریس نمایش می‌دهیم. این شبکه از ۴ لایه برگشتی ساختار آن تشکیل شده است.



شکل (۱۹): ماتریس آشفتگی داده‌های آموزش (RNN)



شکل (۲۰): نمودار دقت تشخیص بر اساس نسبت توان سیگنال به نویز داده‌های تست در شبکه‌های مختلف

ملاحظه می‌گردد، از بین سه شبکه استفاده شده در این پژوهش، شبکه کانولوشنی عملکرد بهتری دارد.

تولید داده‌های ابر چف، شبیه‌سازی آن حائز اهمیت است که در این پژوهش توانستیم به این امر مهم دست پیدا کنیم.

## ۷- مراجع

- [1] Zarei, N. A., Nayebi, M. M., Amin, A., Reeis Danaei, M., Aalami, H. "Discrimination of the Target from Chaff in Multi-dimensional Space", JR\_RADAR-5-4\_1-10, 2018.
- [2] U. Kaydok, "Chaff Discrimination Using Convolutional Neural Networks and Range Profile Data", 2020 IEEE International Radar Conference (RADAR), pp. 373-377, 2020.
- [3] X. Shao, H. Du & J. Xue, "A recognition method depended on enlarge the difference between target and chaff," 2007 International Conference on Microwave and Millimeter Wave Technology, pp. 1-4, 2007.
- [4] G. Shao, Y. Chen & Y. Wei, "Deep Fusion for Radar Jamming Signal Classification Based on CNN," in IEEE Access, vol. 8, pp. 117236-117244, 2020.
- [5] Tang G., et al., "Symmetry measurement of radar echoes and its application in ship and Chaff discrimination", IET Internation Conference on Radar, pp. 138-141, 2009.
- [6] T. Guangfu, Z. Ke, Z. Hongzhong & Z. Zhenzhen, "A novel discrimination method of ship and chaff based on sparseness for naval radar," 2008 IEEE Radar Conference, pp. 1-4, 2008.
- [7] Y. Kim & Y. Li, "Human Activity Classification With Transmission and Reflection Coefficients of On-Body Antennas Through Deep Convolutional Neural Networks," in IEEE Transactions on Antennas and Propagation, vol. 65, no. 5, pp. 2764-2768, May 2017.
- [8] Chollet, F. "Deep learning with python", Manning Publications Co., 2017
- [9] tutorial-learning-deep-<https://howsam.org/free>.
- [10] F. Mahdavi, H. Zayyani & R. Rajabi, "RSS localization using an optimized fusion of two deep neural networks", IEEE Sens. Lett., vol. 5, no. 12, Dec. 2021.
- [11] S. Talati, M. Akbari Sani & M. R. Hassani Ahangar " Identifying Radar Targets using the GMDH Deep Neural Network", <https://civilica.com/doc/1184611>, 2019.
- [12] X. Lian, S. Li, H. Chen, Y. Zhang, X. Cui & B. Guo, "DOA Estimation Based on CNN in L-type Mutual Matrix," 2021 6th International Conference on Communication, Image and Signal Processing (CCISP), pp. 1-6, 2021.
- [13] O. Güneş & ö. Morgül, "LSTM Based Classification of Targets using FMCW Radar Signals," 2021 29th Signal Processing and Communications Applications Conference (SIU) , pp. 1-4, 2021.

