





Reza Janani¹ Reza Fatemi Mofrad^{*2}

PHD student of telecommunications at Malik Ashtar University of Technology, associate

((Received: 2022/12/27, Revised: 2023/05/12, Accepted: 2023/08/02, Published: 2023/09/28))

DOR: <https://dorl.net/dor/20.1001.1.23224347.1402.11.3.4.9>

Abstract:

*Today, strategic UAVs with their ultra-modern facilities in the fields of COMMAND, ELINT and high-resolution imaging and their guidance and navigation and sending and receiving information at a high rate through communication links with satellites are able to collect valuable information. which can disturb the balance of the battle scene and if needed, they will be able to act and destroy the country's strategic infrastructures. Therefore, in order to deal with this type of birds, it is felt to use an electronic warfare system that is capable of active and passive tracking with the ability to disrupt. In this system, due to the many advantages of antenna array and electronic beam shaping, this method has been used. Depending on the operational needs, these arrays should be capable of receiving several Mhz instant bandwidth signal over the entire operating frequency range x and Ku. In array antennas by sending and receiving broadband signals, the narrow beamforming structure will not respond to the beamforming, so wideband beamforming structures are used. In broadband structures, due to the increase in the number of beamforming coefficients from the M coefficients to the M * J coefficients, if the common optimization algorithms in wideband beam formation are used to determine the coefficients, computational complexity and therefore power The required processing and computational latency are very high, which is one of the challenges of beamforming in wideband systems. In this paper, in order to reduce the computational complexity, the deep learning method has been used and it is shown that the proposed method reduces the complexity by determining the coefficients significant while maintaining efficiency.*

Key words: phased array systems, Monitoring and electronic action, Wideband Beamforming, 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

Authors



*Corresponding Author Email: rezajanani2012@gmail.com

روشی نوین در شکل‌دهی پرتو وقتی پهن باند به روش یادگیری عمیق در یک سیستم آرایه‌ای

رضا جنانی^۱، رضا فاطمی مفرد^{۲*}

۱- دانشجوی دکتری، ۲- دانشیار، دانشگاه صنعتی مالک اشتر

(دریافت: ۱۴۰۱/۱۰/۰۶، بازنگری: ۱۴۰۲/۰۲/۲۲، پذیرش: ۱۴۰۲/۰۵/۱۱، انتشار: ۱۴۰۲/۰۷/۰۶)

DOR: <https://dorl.net/dor/20.1001.1.23224347.1402.11.3.4.9>

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

© نویسندگان

ناشر: دانشگاه جامع امام حسین (ع)

چکیده:

امروزه پهپادهای استراتژیک با امکانات فوق‌مدرن خود در حوزه‌های کامینت، الینت و تصویربرداری با قدرت تفکیک بالا و هدایت و ناوبری آنها و ارسال و دریافت اطلاعات با نرخ بالا از طریق لینک‌های ارتباطی با ماهواره‌ها، قادر به جمع‌آوری اطلاعات ارزشمندی هستند که می‌توانند توازن صحنه نبرد را برهم بزنند و در صورت نیاز قادر به اقدام و انهدام زیرساخت‌های استراتژیک کشور خواهند بود. لذا به منظور مقابله با این نوع از پرنده‌ها استفاده از سامانه‌ای جنگ الکترونیک که قادر به ردیابی فعال و غیرفعال با توانایی اعمال اختلال، احساس می‌شود. در این سامانه، بنا به مزیت‌های فراوان آرایه‌شدن آنتن‌ها و شکل‌دهی پرتو به صورت الکترونیکی، از این روش استفاده شده است. با توجه به نیازهای عملیاتی، این آرایه‌ها، بایستی توانایی دریافت سیگنالی پهن باند با پهنای باند لحظه‌ای چندین صد مگاهرتز در کل محدوده فرکانس کاری x و Ku را داشته باشد. در آنتن‌های آرایه‌ای با ارسال و دریافت سیگنال‌های پهن باند، ساختار شکل‌دهی پرتو باند باریک پاسخگوی شکل‌دهی پرتو نخواهد بود، لذا از ساختارهای شکل‌دهی پرتو پهن باند استفاده می‌شود. در ساختارهای پهن باند به دلیل افزایش تعداد ضرایب شکل‌دهنده از حالت M تایی به حالت $M*J$ تایی، در صورتی که از الگوریتم‌های رایج بهینه‌سازی در شکل‌دهی پرتو پهن باند به منظور تعیین ضرایب استفاده شود، پیچیدگی محاسباتی و لذا قدرت پردازش مورد نیاز و تاخیر محاسبات بسیار زیاد می‌باشد که این موضوع از چالش‌های شکل‌دهی پرتو در سیستم‌های پهن باند به حساب می‌آید. در این مقاله به منظور کاهش پیچیدگی محاسباتی از روش یادگیری عمیق استفاده شده است و نشان داده می‌شود که روش ارائه شده با حفظ کارایی باعث کاهش پیچیدگی قابل‌ملاحظه‌ای در تعیین ضرایب می‌گردد.

واژه‌های کلیدی: سیستم آرایه‌ای فازی، پایش و اقدام الکترونیکی، شکل‌دهی پرتو وقتی پهن باند، یادگیری عمیق

۱. مقدمه

صورت همزمان پایش و رهگیری نماید و در صورت لزوم اقدام الکترونیکی انجام دهد، احساس می‌شود. با توجه به مطالعات منابع آشکار مختلف که در خصوص باندهای فرکانسی این پرنده‌ها توضیحاتی داده‌اند و همچنین بررسی ماژول‌ها و مودم‌های معتبر که در این پهپادها از آنها به عنوان ابزار برقراری لینک استفاده می‌کنند، می‌توان به جمع‌بندی فرکانس‌های استفاده شده طبق شکل ۱ رسید [۱، ۲]. طبق شکل ۱ پهنای باندهای لحظه‌ای تا ۱ گیگاهرتز در باند C, X, KU مشاهده می‌شود. لذا به منظور پایش همزمان این پهنای باند نیازمند دریافت همزمان آن است. بنابراین سامانه بایستی به سمت پهن‌بند بودن سوق داده شود. شرط اصلی برای این کار استفاده از تجهیزات پهن‌بند است و با توجه به آرایه‌ای بودن سامانه، استفاده از شکل‌دهی پرتوی پهن‌بند مورد نیاز است. با توجه به مزایای فراوان ساختار آرایه‌فازی، در این سامانه از ساختار آرایه‌فازی و شکل‌دهی پرتوی پهن باند وقتی دیجیتال استفاده شده است [۳].

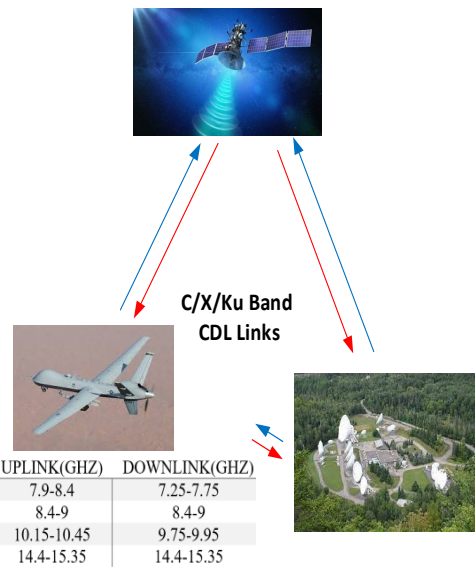
در جنگ‌های نوین استفاده از پهپادها با در اختیار داشتن امکانات مخابراتی و تصویربرداری با رزولوشن بالا امری رایج است. به منظور مقابله با این پرنده‌ها و اختلال بر عملکرد آنها وجود سامانه‌ای جامع به منظور جستجو، رهگیری، پایش و اقدام الکترونیکی علیه لینک‌های ماهواره‌ای (مخابراتی) آنها مورد نیاز است. اگر برای تشخیص حضور و رهگیری و اقدام علیه آنها اقدامات مقتضی صورت نگیرد، قطعاً یک ضعف بزرگ در سیستم دفاعی کشور بوجود می‌آید که می‌تواند صدمات جبران‌ناپذیری حاصل آورد.

یکی از ابعاد قدرت دفاعی و بازدارندگی نظامی در دنیای کنونی، مراقبت و صیانت از آسمان کشور توسط دیده‌بانی و پایش مستمر فضا از نظر الکترونیکی و مخابراتی است. بنابراین یک سامانه جامع کشف، رهگیری، پایش و اقدام علیه این نوع پهپادها که بتواند باند وسیعی از لینک‌های ارتباطی و تصویربرداری را به

الگوریتم‌های شکل‌دهی پرتو که ضرایب را به‌روزرسانی می‌کنند، شکل‌دهنده پرتو وقتی نامیده می‌شوند [۵].

در این مقاله یک ساختار شکل‌دهنده پرتوی پهن‌باند وقتی که بسیار پرکاربرد است، با عنوان شکل‌دهنده پرتوی حداقل واریانس محدود شده خطی (LCMV)^۲ به صورت اجمالی بیان خواهد شد. در حوزه شکل‌دهی پرتو به ویژه از نوع پهن‌باند، موضوع پیچیدگی محاسباتی بسیار حائز اهمیت است و چالشی بزرگ محسوب می‌شود، در صورتی که تعداد TDLها به همراه تعداد المان‌ها (سنسورها) زیاد شود، باعث افزایش ضرایب خواهد شد. حتی با وجود تکنولوژی‌های اخیر در حوزه سخت‌افزار، همچنان امکان این امر برای آرایه‌هایی با تعداد المان بالا فراهم نشده است [۶]. لذا در ادامه به منظور برطرف نمودن این مشکل ساختار و روش یادگیری عمیق پیشنهاد شده است و نتایج و عملکرد شکل‌دهی پرتوی پهن‌باند توسط یادگیری عمیق نشان می‌دهد که بهبود قابل توجهی نسبت به روش‌های پیشین به دست می‌آید. بنابراین الگوریتم‌های رایج، پیچیدگی محاسباتی بالایی به منظور تعیین ضرایب خواهند داشت [۶]. لذا بایستی از الگوریتم‌ها و روش‌هایی استفاده شود که باعث کاهش پیچیدگی محاسباتی خواهند شد.

شبکه‌های عصبی^۳ (NN) و یادگیری عمیق^۴، در چندین سال اخیر رشد چشمگیری داشته است، به طوری که در حوزه‌های مختلف نظیر پردازش گفتار [۷] و پردازش تصویر [۸] و ... ورود کرده است. بنابراین در صورت به‌کارگیری آن در شکل‌دهی پرتو می‌توان محدودیت روش‌های رایج شکل‌دهی پرتو پهن‌باند را حذف نمود. با این روش ویژگی‌های مربوط به سیگنال مورد نظر، استخراج می‌شود و در خروجی ساختار یادگیری عمیق، شبکه ضرایب به گونه‌ای تنظیم می‌شوند که همانند روش‌های مرسوم، پرتو به سمت سیگنال مورد نظر بوجود می‌آید و در سمت سیگنال‌های تداخل شکاف می‌افتد. به دلیل پردازش عظیم به صورت موازی در شبکه‌های NN و توانایی واحدهای پردازش گرافیکی (GPUs) این الگوریتم‌ها به خوبی اجرا می‌شوند و می‌تواند جایگزین امیدوارکننده‌ای برای شکل‌دهنده پرتوی رایج شوند. بنابراین پیشنهاد و ایده‌ی ارائه شده در این مقاله، شکل‌دهی پرتوی پهن‌باند وقتی بر اساس یادگیری عمیق است. و با توجه به نتایج و شبیه‌سازی‌های آن نشان داده خواهد شد که چگونه چالش اصلی پیاده‌سازی در الگوریتم‌های رایج برای مسأله-ی معیار تعریف شده، برطرف خواهد شد. با توجه به اینکه در



شکل ۱- طیف فرکانسی استفاده شده در لینکهای پهن‌باند.

ساختار شکل‌دهنده پرتوی مرسوم فقط برای سیگنال‌های باند باریک موثر است [۴]. وقتی پهنای باند سیگنال افزایش یابد، عملکرد آن به طور قابل توجهی کاهش می‌یابد. برای سیگنال‌های پهن‌باند، از آنجا که هر یک از آنها از تعداد بی‌نهایت مولفه فرکانس تشکیل شده‌اند، مقدار ضرایب شکل‌دهنده پرتو برای فرکانس‌های مختلف بایستی متفاوت باشد. به همین دلیل است که ساختار شکل‌دهنده باند باریک با یک ضریب ثابت برای هر المان آرایه در یک محیط باند پهن، به طور موثر کار نخواهد کرد. وزن‌های وابسته به فرکانس را می‌توان با استفاده از یک سری خطوط تأخیر (TDL)^۱ در حالت گسسته به دست آورد.

روش TDL یک فرآیند فیلترینگ زمانی را انجام می‌دهند تا برای هر یک از سیگنال‌های پهن‌باند دریافت شده در هر سنسور، یک پاسخ وابسته به فرکانس ایجاد کنند تا اختلاف فاز را برای اجزای فرکانس مختلف جبران کند. نتیجه‌ی شکل‌دهی پرتو پهن‌باند وقتی به این صورت خواهد بود که در جهت سیگنال‌های پهن‌باند تداخل کننده، تضعیف اعمال شود و سیگنال مورد نظر پهن‌باند از نظر مکانی استخراج شود. در نتیجه، یک پاسخ فضایی خاص از سیستم آرایه با "پرتوهای" در جهت سیگنال‌های مورد نظر و "تهی"هایی در سمت سیگنال‌های تداخل بدست می‌آید. در بسیاری از کاربردهای شکل‌دهی پرتو، اغلب با توجه به داده‌ی دریافتی از آرایه، ضرایب آرایه تنظیم می‌شوند تا بهینه‌ترین راه-حل برای سناریوی موجود ارائه شود. وقتی که محیط اطراف تغییر می‌کند، ضرایب شکل‌دهی پرتو نیز بایستی تغییر کنند.

^۲ Linear constraint minimum variance

^۳ Neural Network

^۴ Deep learning

^۱ Time delay line

سیگنال به عنوان ورودی شبکه معرفی شده است. با این روش و انجام مقایسه مشاهده گردید که زمان لازم برای پردازش الگوریتم نسبت به روش قبل به شدت کاهش پیدا می کند. (۵) همچنین در این فعالیتها فرض شده است که تعداد اسنپ-شاتها نامحدود می باشد که در شرایط عادی این امر قابل تصور نیست [۱۳].

بخش بندی مقاله شامل ۱- مدل ریاضی و ساختار شکل دهی پرتو پهن باند وقتی، ۲- محدودیت های روش های رایج، ۳- شکل دهی پرتو پهن باند به روش یادگیری عمیق ۵- نتیجه گیری خواهد بود.

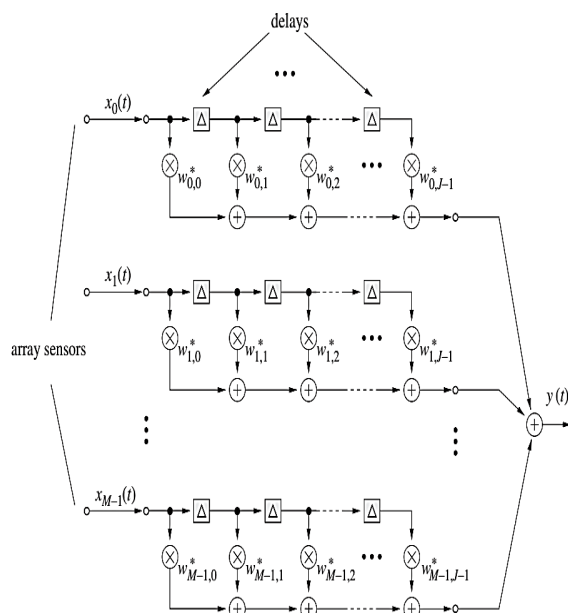
۲. مدل ریاضی و ساختار شکل دهی پرتو پهن باند

وقتی

در شکل ۲ ساختار یک شکل دهنده پرتو پهن باند نشان داده شده است. شکل دهنده پرتویی که از معماری فوق پیروی می کند، موج انتشار یافته را هم در مکان و هم در زمان نمونه برداری می کند. خروجی چنین شکل دهنده پرتو پهن باند پهن را می توان به صورت ۱ بیان کرد [۴]:

$$y(t) = \sum_{m=0}^{M-1} \sum_{l=0}^{J-1} x_m(t - iT_s) \times w_{m,l}^* \quad (1)$$

در رابطه فوق، x_m نمونه های سیگنال ورودی برای هر سنسور و $w_{m,l}$ نشان دهنده ضرایب است، که $J-1$ تعداد عناصر تأخیر (TDL) مرتبط با هر یک از M سنسور و T_s تأخیر بین تبها در



شکل ۲- ساختار کلی برای شکل دهنده پرتو پهن باند [14].

TDL است. در حالت نمایش برداری، رابطه ی ۱ به صورت زیر خواهد بود:

حال حاضر شبکه های عصبی عمیق در اکثر حوزه های مهندسی وارد شده اند. بنابراین ترکیب شبکه های عصبی و شکل دهی پرتو نیز فرصت مناسبی برای محققان می باشد تا در این زمینه کار کنند. فعالیت هایی که تا به حال در این حوزه انجام شده است دارای کمبودهایی می باشد همچنین نوآوری های مقاله در ادامه آورده شده است: که به شرح زیر است:

(۱) کاربرد شکل دهی پرتوی پهن باند به روش یادگیری عمیق در یکی از کاربردهای پدافند الکترونیکی و سامانه های جنگ الکترونیک اشاره شده در مقاله با حفظ محرمانگی آن، مورد استفاده قرار گرفته شده است. استفاده از این ایده در یک سامانه ی عملیاتی مورد نیاز کشور برای اولین بار انجام شده است، بنابراین عملکرد سامانه و محاسبات پیچیدگی الگوریتم ارائه شده، با توجه به پارامترهای سامانه به دست آمده است.

(۲) تمام مطالعات و کارهای صورت گرفته در حوزه ی شکل دهی پرتوی توسط یادگیری عمیق و شبکه ی عصبی به ۵ سال اخیر برمیگردد. که اکثر آنها در مورد بهبود عملکرد شکل دهی پرتو باند باریک متمرکز هستند و طراحی شکل دهی پرتو پهن باند تطبیقی حوزه زمان به طور کامل بررسی نشده است [۹، ۱۰].

(۳) در مبحث یادگیری عمیق در هر حوزه ای، به دست آوردن بانک اطلاعاتی مناسب و کارا، نحوه ی انتخاب ساختار شبکه، چیدمان شبکه و انتخاب پارامترهای آن که اصطلاحاً به آنها هایپر پارامتر گفته می شود، بسیار مهم می باشد به گونه ای که همواره شرکت های بزرگی نظیر Microsoft و Google همواره به منظور بهبود در هر کدام از عوامل ذکر شده در حال تلاش و پیشرفت است. از سوی دیگر، با توجه به اینکه طراحی شبکه بیش از آنکه حاصل تحلیل ریاضی قوی باشد، مستلزم بکارگیری تجربه و آزمون و خطا و مقایسه می باشد تا به عملکرد ایده آل برسد. لذا مقالات مختلف، متناسب با سناریوی به کار گرفته شده، شبکه ی خود را طراحی و آموزش داده اند که به طور قطع تمامی ۴ عامل ذکر شده در بالا متفاوت از ساختار به کار گرفته شده در مقاله می باشد. بنابراین با توجه به مسئله ی معیارمان به دست آوردن ساختار، چیدمان و انتخاب هایپر پارامترها می تواند از دیدگاه نویسندگان یکی از نوآوری های مقاله باشد.

(۴) یکی از نوآوری هایی که در این مقاله می توان به آن اشاره کرد در بخش یادگیری شبکه می باشد. در مقالات بررسی شده در این حوزه در روند یادگیری شبکه از ماتریس کوواریانس به عنوان اطلاعات ورودی شبکه استفاده شده است که این امر به دلیل محاسبات ماتریس کوواریانس و هم افزایش اندازه ی تصویر ورودی شبکه عصبی باعث پیچیدگی محاسبات قابل توجه خواهد شد. [۱۱، ۱۲] در صورتی که در مقاله اسنپ شات نمونه های

$$y(t) = w^H x(t) \quad (۲)$$

$$y(t) = \sum_{m=0}^{M-1} \sum_{i=0}^{J-1} e^{-j\Omega(m\sin\theta+i)} \times \omega_{m,i}^* \quad (۱۲)$$

بردار وزن w دارای MJ ضریب سنسور است:

$$w = [w_0, w_1, \dots, w_{J-1}]^T \quad (۳)$$

که هر کدام از ضرایب w_i شامل M ضریب مختلط مزدوج خواهد بود:

$$w_i = [w_{0,i} \ w_{1,i} \ \dots \ w_{M-1,i}]^T \quad (۴)$$

به طور مشابه، داده ورودی به صورت بردار x نشان داده می‌شود:

$$x = [x(t), x(t - T_s), \dots, (t - (J - 1)T_s)] \quad (۵)$$

که $x_i(t - iT_s)$ داده‌ی i ام از تمامی سنسورها و متناظر با i امین ضریب از بردار w است:

$$x(t - iT_s) = [x_0(t - iT_s) \ x_1(t - iT_s) \ \dots \ x_{M-1}(t - iT_s)]^T \quad (۶)$$

در صورتی که $J = 1$ باشد، ساختار شکل دهنده پرتو به حالت باند باریک خواهد بود. برای جبهه موج ورودی به صورت $e^{j\omega t}$ ، فرض می‌شود که $x_0(t) = e^{j\omega t}$ بنابراین:

$$x_m(t - iT_s) = e^{j\omega(t - (\tau_m + iT_s))} \quad (۷)$$

با $i = 0, \dots, J - 1$ و $m = 0, 1, \dots, M - 1$ خروجی آرایه به صورت زیر خواهد بود:

$$y(t) = e^{j\omega t} \sum_{m=0}^{M-1} \sum_{i=0}^{J-1} e^{-j\omega(\tau_m + iT_s)} \omega_{m,i}^* = e^{j\omega t} \times P(\theta, \omega) \quad (۸)$$

که $P(\theta, \omega)$ پاسخ شکل دهنده پرتو وابسته به زاویه و فرکانس است. که آن را به صورت برداری می‌توان نشان داد:

$$P(\theta, \omega) = w^H d(\theta, \omega) \quad (۹)$$

که $d(\theta, \omega)$ بردار هدایت شکل دهنده پرتو جدید و المان‌های آن به صورت $e^{-j\omega(\tau_m + iT_s)}$ است:

$$d(\theta, \omega) = [e^{-j\omega(\tau_0)} \ \dots \ e^{-j\omega(\tau_{M-1})} \ \dots \ e^{-j\omega(\tau_0 + T_s)} \ \dots \ e^{-j\omega(\tau_{M-1} + T_s)} \ \dots \ e^{-j\omega(\tau_0 + (J-1)T_s)} \ \dots \ e^{-j\omega(\tau_{M-1} + (J-1)T_s)}]^T \quad (۱۰)$$

برای آرایه‌ای که فاصله المان‌های آن برابر d است، $\tau_m = m\tau_1$ و $\omega\tau_m = \frac{m(2\pi d \sin\theta)}{\lambda}$ ، $m = 0, 1, \dots, M - 1$ جهت جلوگیری از aliasing بایستی شرط $d < \lambda_{min}/2$ برقرار باشد، در این شرط λ_{min} طول موج متناظر با بخشی از سیگنال با فرکانس ω_{max} خواهد بود. فرض می‌شود که فرکانس در نظر گرفته برای سیگنال ورودی به آرایه برابر $\omega \in [\omega_{min} \ \omega_{max}]$ و $d = \lambda_{min}/2$ است. در حالت گسسته، T_s بازه نمونه برداری زمانی سیستم است و T_s طبق تئوری نایکوئیست، نبایستی از نصف حداقل پریود بخشی از سیگنال که دارای بزرگترین فرکانس است، بزرگتر باشد [۱۵].

با در نظر گرفتن فرکانس نرمالیزه شده به صورت $\Omega = \omega T_s$ ، رابطه $\omega(m\tau_1 + iT_s)$ به $\mu\Omega\sin\theta + i\Omega$ تغییر خواهد یافت. در این رابطه $\mu = d/(cT_s)$ خواهد بود. پس بردار هدایت به صورت زیر است:

$$d(\theta, \omega) = [1 \ \dots \ e^{-j(M-1)\mu\Omega\sin\theta} \ \dots \ e^{-j\Omega} \ \dots \ e^{-j\Omega(\mu\sin\theta(M-1)+1)} \ \dots \ \dots \ e^{-j(J-1)\Omega} \ \dots \ e^{-j\Omega(\mu\sin\theta(M-1)+J-1)}]^T \quad (۱۱)$$

⁵ Transmit and receive

⁶ Hybrid Beamforming

در θ_0 دارای پاسخ شکل دهنده G_0 خواهد بود، که G_0 ثابت مختلط است، رابطه‌ی ۱۴ تنظیم می‌شود [۱۶]:

$$w^H d(\theta_0, \omega_0) = G_0 \quad (14)$$

همچنین مقدار توان خروجی یا واریانس به صورت رابطه‌ی ۱۵ داده می‌شود: [۱۷]

$$E[|y[n]|^2] = w^H R_{xx} w \quad (15)$$

که R_{xx} ماتریس کوواریانس داده‌های دریافت شده در آرایه است و به صورت زیر نوشته می‌شود:

$$R_{xx} = E[xx^H] \quad (16)$$

سیس مسئله‌ی شکل‌دهی پرتو به روش LCMV به صورت رابطه-ی زیر خواهد بود:

$$w = \underset{\text{subject to } d^H(\theta_0, \omega_0)w = G_0^*}{\operatorname{argmin}} w^H R_{xx} w \quad (17)$$

رابطه‌ی بالا یک مسئله بهینه‌سازی است. وجود یک محدودیت در رابطه می‌تواند به چندین محدودیت خطی برای افزایش کنترل پاسخ شکل دهنده منجر شود، به طور مثال داشتن جهت‌های ورود سیگنال و باندهای فرکانسی بیشتر. در صورتی که $I < M * J$ تعداد محدودیت‌های خطی اعمال شده بر w باشد، آنگاه محدودیت‌ها را می‌توان به صورت ماتریسی به صورت رابطه زیر نشان داد [۱۸، ۱۹]:

$$C^H w = f \quad (18)$$

C ماتریس ضرایب با ابعاد $MJ \times I$ است. درحالی که f بردار پاسخ با بعد I است. حل رابطه‌ی ۱۷ از طریق استفاده از روش فراست (بازگشتی) به صورت رابطه ۱۹ خواهد بود:

$$w[n+1] = C(C^H C)^{-1} f + P(w[n] - \mu R_{xx} w[n]) \quad (19)$$

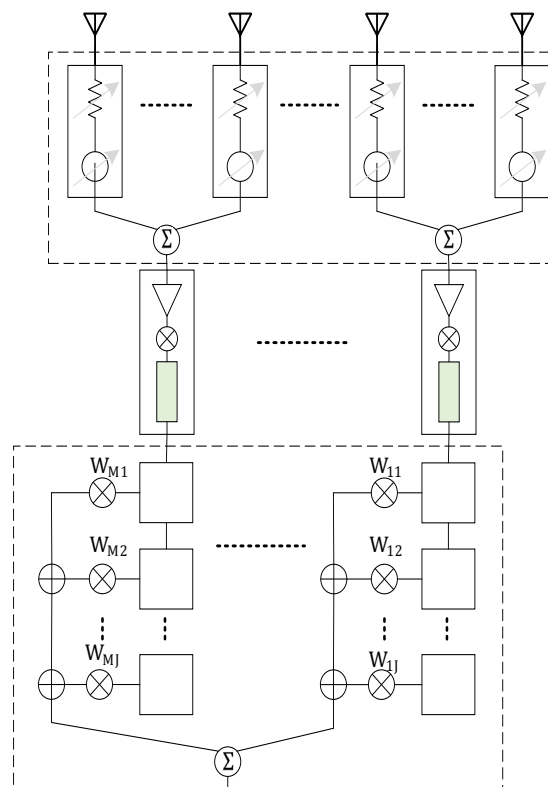
$$P = I - C(C^H C)^{-1} C^H$$

در رابطه فوق μ معادل گام بروزرسانی است که بایستی به صورت صحیح انتخاب شود. در صورت بزرگ بودن آن ممکن است سرعت همگرایی افزایش یابد اما دقت کم شود.

۳. محدودیت روش های رایج

هدف از این مقاله، پیشنهاد روشی جدید برای الگوریتم‌های موجود شکل‌دهی پرتو باند وسیع است به گونه‌ای که روش پیشنهاد شده چالش پیاده‌سازی الگوریتم‌های پیشین برای مسئله معیار تعریف شده را نداشته باشد. همچنین در این مقاله مسئله معیار برای اعمال الگوریتم پیشنهادی، آرایه‌ای است که قابلیت دریافت 1GHz باند لحظه‌ای در فرکانس کاری 6GHz~18GHz را داشته باشد.

در گیرندگی داشت، همچنین به صورت وقتی تداخل‌های پهن باند را خنثی نمود و تمام فعالیت‌هایی که در حوزه فیلترینگ فضایی دیجیتال در سطح المان انجام می‌شد را می‌توان در سطح زیرآرایه انجام داد. نمونه ساختار ترکیبی شکل‌دهی پرتو در شکل ۳ نشان داده شده است.



شکل ۳- ساختار شکل‌دهنده پرتو.

۲-۱. شکل‌دهی پرتو پهن باند به روش LCMV

اگر سیگنال مرجع در دسترس نباشد، اما جهت ورود سیگنال مورد نظر به همراه پهنای باند آن را بدانیم، آنگاه می‌توان برخی محدودیت‌ها را به ضرایب آرایه اعمال کرد و به طور وقتی توان یا واریانس خروجی شکل‌دهنده $\{E\{y(t)y(t)^*\}\}$ را تحت محدودیت‌های اعمال شده، کاهش داد. این مسیر به الگوریتم شناخته شده شکل‌دهنده پرتو وقتی LCMV منجر می‌شود. که پاسخ شکل‌دهنده تحت شرایط بهره و فاز مشخص به سمت زاویه‌ای مشخص که سیگنال مورد نظر تزریق می‌شود، محدود می‌گردد. درحالی که خروجی شکل‌دهنده برای زوایای ورود سیگنال متداخل دارای حداقل مقدار خواهد بود. همان‌طور که قبلاً اشاره شده بود پاسخ شکل‌دهنده نسبت به سیگنال دارای فرکانس ω و زاویه ورود θ به صورت $p(\theta, \omega) = w^H d(\theta, \omega)$ است. برای اطمینان از اینکه سیگنال با فرکانس ω_0 و زاویه ورود

$$B_s \cdot \Delta T_{max} \ll 1 \quad (21)$$

در رابطه بالا B_s نماد پهنای باند لحظه‌ای و ΔT_{max} نماد بیشترین اختلاف زمان دریافتی بین دو المان آرایه است.

در ادامه با توجه به فرضیات مسئله معیار، پهن باند بودن سیگنال بررسی می‌شود. در محاسبات جدول ۱، حاصلضرب $B_s \times \Delta T_{max}$ به دست می‌آید:

جدول ۱- محاسبات مربوط به $B_s \times \Delta T_{max}$

طول موج	$\lambda = \frac{c}{f} = \frac{3 \times 10^8 (m/s)}{18 \times 10^9 (Hz)} = 1.6 \text{ cm}$
فاصله بین حسگرها	$< \frac{\lambda}{2} = 0.8 \text{ cm}$
بیشترین فاصله‌ی بین حسگرهای آرایه	$\sqrt{2} \times 32 \times 0.8 \text{ cm} \cong 0.36 \text{ m}$
ΔT_{max}	$\frac{0.36 \text{ m}}{3 \times 10^8 (m/s)} = 1.2 \text{ ns}$
$B_s \times \Delta T_{max}$	$1 \times 10^9 \times 1.2 \times 10^{-9} = 1.2$

در تقریب مهندسی، غالباً یک دهم عددی را معادل خیلی کوچکتر از آن عدد می‌دانند. با توجه به این که عدد ۱/۲ از معیار عدد یک خیلی کوچکتر نیست بلکه حتی از عدد یک بزرگتر است، پس نتیجه می‌شود این سیگنال برای آرایه‌ی هدف، سیگنال پهن باند است. بنابراین به منظور عدم افت عملکرد شکل-دهی پرتو بایستی از ساختار پهن باند در طراحی الگوریتم شکل-دهی پرتو استفاده کرد.

موضوع پیچیدگی محاسباتی به منظور پیاده‌سازی به شدت چالش برانگیز است. پیچیدگی محاسباتی روش فراست مطرح شده در رابطه ۱۹ را مدنظر قرار دادیم که پیچیدگی محاسباتی آن در جدول ۳ محاسبه گردیده است. از آنجا که پیچیدگی محاسباتی در پیاده‌سازی، بیانگر تعداد ضرب‌های صورت گرفته در هر نمونه است [۱۴]، پارامتری که در تراشه FPGA بیانگر انجام این عملیات است، واحدهای DSP هستند، بنابراین تعداد DSPها بیانگر توان انجام عملیات‌های ضرب در FPGA است. طبق جدول ۲، حداکثر تعداد واحد DSP در آخرین نسل از تراشه‌های FPGA از شرکت Xilinx نشان داده شده است.

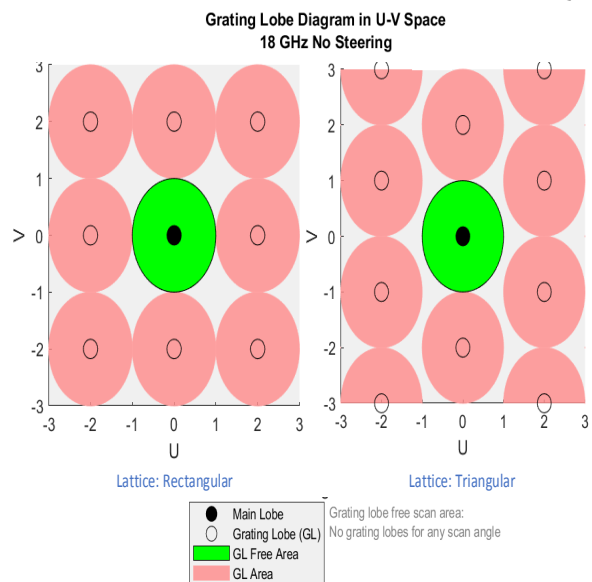
جدول ۲- مشخصات آخرین نسل از پردازنده‌های Xilinx [۲۲]

FPGA (Model)	DSP (Slice)
Kintex Ultra Scale FPGA	768-5520
Kintex Ultra Scale+ FPGA	1368-3528
Virtex Ultra Scale FPGA	600-2880

با توجه به اینکه این آرایه بایستی در رنج وسیع فرکانسی اسکن را انجام دهد، اما وجود عامل گریتینگ لوب^۷ مانع از این عمل می‌شود طبق رابطه ۲۰ برای این که در فرکانس کاری متناسب با طول موج λ ، در زاویه‌ی تتا گریتینگ لوب ایجاد نگردد، می‌بایست فاصله بین المان‌ها از d کمتر باشد [۲۰].

$$d = \frac{\lambda}{1 + \sin(\theta)} \quad (20)$$

برای فرکانس کاری ۱۸ گیگاهرتز و با فرض اسکن در فضای $\pm 90^\circ$ بایستی فاصله گذاری طبق رابطه‌ی ۲۰ برابر با $\lambda/2$ باشد. شکل ۴ محدوده‌ی اسکن بدون وجود گریتینگ لوب را برای دو ساختار (چینش) مستطیلی و مثلثی المان‌ها نشان می‌دهد. همانطور که مشاهده می‌شود در چینش مثلثی منطقه‌ی گریتینگ لوب از منطقه‌ی اسکن عاری از گریتینگ لوب فاصله‌ی بیشتری دارد. محورهای افقی و عمودی بر حسب فضای uv رسم شده‌اند. بنابراین از چینش مثلثی برای آرایه‌ی صفحه‌ای استفاده خواهد شد.



شکل ۴- منطقه‌ی اسکن بدون حضور گریتینگ لوب

سوالی که در ارتباط با فرضیه مسئله معیار پیش می‌آید این است که آیا پهنای باند لحظه‌ای سیگنال معادل با 1GHz در فرکانس کاری 6~18 GHz سیگنال پهن باند است؟ به عبارت دیگر برای شکل‌دهی پرتویی با این مشخصات، آیا بایستی از ساختار شکل-دهی پرتو پهن باند استفاده کرد؟ برای پاسخ به این پرسش از رابطه ۲۱ استفاده می‌کنیم به گونه‌ای که در صورت باند باریک بودن سیگنال بایستی رابطه‌ی ۲۱ برقرار باشد [۲۱]:

⁷ Grating lobe

$$T_{\text{Monitoring \& Track}} + T_{\text{Countermeasure}} \leq T_{\text{target maneuver time}} \quad (24)$$


در ادامه مقاله، از زمان محاسبه شده رابطه ی ۲۳ در انتخاب روش مناسب به منظور شکل‌دهی پرتو پهن باند وفقی استفاده خواهد شد.

در صورت محاسبه‌ی زمان ماندن هدف در پرتو آرایه طبق رابطه ۲۳ و مقایسه آن با حداقل زمان پردازش (متناسب با قوی‌ترین تراشه از نظر تعداد (DSP) نتیجه می‌شود که حتی با در اختیار داشتن پردازنده‌ی قوی از خانواده *virtex UltraScale+*، زمان پردازش از زمان ماندن هدف در پرتو بیشتر است و در نتیجه، هدف از حلقه ردیابی خارج می‌شود و در این حالت بایستی عملیات جستجو و ردیابی^{۱۵} برای هدف دوباره انجام شود که در یک منطقه عملیاتی عملکرد نامطلوبی محسوب می‌شود.

۴. شکل‌دهی پرتو پهن باند به روش یادگیری

عمیق

یادگیری عمیق شاخه‌ای از یادگیری ماشین و هوش مصنوعی است. هوش مصنوعی برگرفته شده از هوش انسان است کوچکترین واحد تشکیل دهنده در این ساختار نورون نام دارد، در این واحد مطابق شکل ۵ پالس‌های الکتریکی از طریق شاخه‌هایی به نام دنتریت وارد هسته سلول شده و پس از انجام پردازش‌های مورد نیاز از طریق شاخه اکسون به نورون‌های دیگر منتقل می‌شود.



شکل ۵- شمایی از نورون در ساختار ذهن انسان.

در هوش مصنوعی نیز همین روند اجرا خواهد شد مطابق شکل ۶ داده‌های ورودی پس از ضرب شدن در ضرایب مشخص با هم جمع شده و پس از عبور از یک عملگر غیرخطی وارد نورون‌های

<i>Virtex Ultra Scale + FPGA</i>	2280-12288
----------------------------------	------------

هر کدام از خانواده‌های تراشه شرکت Xilinx در جدول فوق دارای مدل‌های مختلفی هستند، که بالاترین مقدار DSP به مدلی از خانواده *Virtex Ultra Scale+* تعلق دارد.

جدول ۳- پیچیدگی محاسباتی الگوریتم frost

FROST Complexity
$M = M_1 * M_2$ number of sensors $N =$ number of snapshots $J =$ number of TDLs $I =$ number of Constraints $\textcircled{1} C(C^H C)^{-1} f \rightarrow O[2I^2 M J + I^3 + M J I]$ $\textcircled{2} C(C^H C)^{-1} C^H w[n] \rightarrow O[2I^2 M J + I^3 + (M J)^2 I + (M J)^2]$ $\textcircled{3} C(C^H C)^{-1} C^H R_{xx} w[n] \rightarrow O[2I^2 M J + I^3 + (M J)^2 I + (M J)^2 + (M J)^3]$ Total Complexity = $[\textcircled{1} + \textcircled{2} + \textcircled{3}] * N$

با توجه به بیان پیچیدگی و انتخاب نرخ نمونه‌برداری، رابطه‌ی ۲۲ محاسبه‌ی زمانی را انجام می‌دهد.

$$Time\ Consume = \frac{Total\ complexity}{virtex\ ultra\ scale} \times sampling\ time \quad (22)$$

نحوه جهت‌یابی سامانه، بر مبنای Steering Beam خواهد بود. یعنی با توجه به آرایه‌فازی موجود در سامانه در باند مذکور، شروع به بیم‌گذاری خواهد شد و در هر بیمی کل باند 6-18GHz به صورت جارویی پایش خواهد شد. نکته بسیار مهم برای این نوع پایش مکانی و فرکانسی، زمان بندی بهینه خواهد بود تا بتوان به ماکزیمم POI^A دست یافت. به منظور زمان بندی اعمال عملیات بر روی هدف در ابتدا بایستی زمان ماندن هدف در پرتوی آرایه محاسبه شود. در رابطه ۲۳ مدت زمان ماندن یک هدف در پهنای پرتوی سیستم آرایه‌ای به دست می‌آید. به منظور این که زمان در بدترین شرایط محاسبه گردد، فاصله پروازی از سیستم آرایه‌ای حداقل مسافت در نظر گرفته شده است.

$$F35\ maximum\ speed \quad (23)$$

worst case as ceiling

array beamwidth

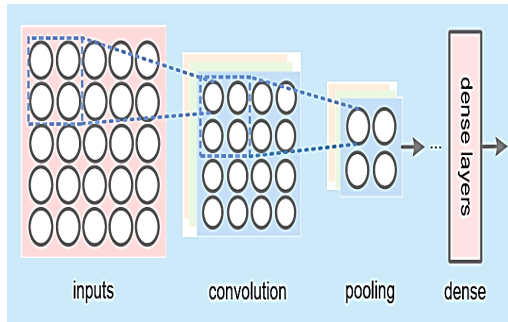
cross range = worst case ceiling \times beamwidth

$$target\ maneuver\ time = \frac{cross\ range}{speed}$$

طبق رابطه‌ی فوق نتیجه می‌شود که بایستی مجموع زمان اعمال ردیابی و مانیتورینگ و اخلاص برابر یا کوچکتر از زمان ماندن هدف در پرتو باشد [۲۳].

⁸ Probability of intercept

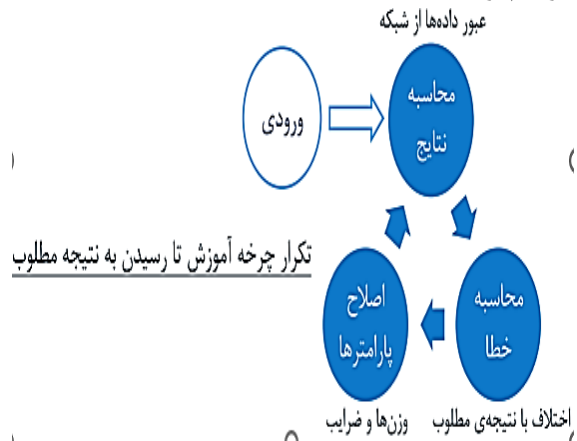
دیگر خواهند شد. ورودی ساختار DNN می‌تواند اطلاعاتی از سیگنال دریافتی باشد و خروجی آن، ماتریس ضرایب شکل دهنده‌ی پرتو که به حالت بهینه نزدیک هستند. یک ساختار DNN از لایه‌های مختلفی تشکیل شده است [۲۴] که در شکل ۷ یک مدل از معماری ساختار DNN به تصویر کشیده شده است در این شکل، تمام نوروها با نوروهای سایر لایه‌ها در اتصال هستند،



شکل ۸- ساختار CNN [۲۴].

۲ مرحله‌ای که در ساختار DNN مورد توجه قرار دارد به شرح زیر است: در مرحله یادگیری، ساختار DNN با منابع سیگنال مستقر در DOA های مختلف آموزش می‌یابد و پس از آموزش، ضرایب ساختار DNN به گونه‌ای تنظیم می‌شوند که در مرحله آزمایش، DNN قادر خواهد بود تا ماتریس ضرایب بهینه مربوط به شکل‌دهی پرتو پهن باند وقتی-تقویتی را برای منابع سیگنال دریافت شده از جهت‌های ورود ناشناخته پیدا کند. روش و الگوریتم آموزش شبکه به منظور یافتن ضرایب ساختار مطابق شکل ۹ است.

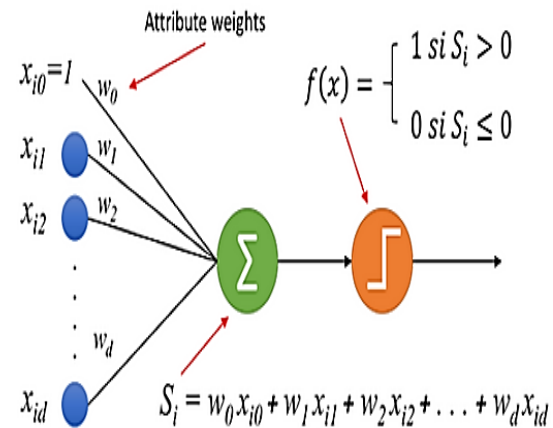
در واقع مطابق شکل ۹، با اصلاح پارامترها به دنبال کاستن خطا خواهیم بود.




شکل ۹- روند آموزش شبکه و اصلاح ضرایب.

مطابق با شکل ۱۰ اگر به ازای پارامترهای مختلف خطاهای مختلفی به دست آید در نهایت سطحی خواهیم داشت که به آن

شکل ۶- شمایی از کوچکترین واحد عملیاتی در هوش مصنوعی. در این ساختار از چندین لایه مخفی بین لایه‌ی ورودی و خروجی به منظور استخراج ایده‌آل ویژگی‌های مهم استفاده شده است.



شکل ۷- معماری کاملاً متصل از نوع feedforward NN [۲۴].



شکل ۷- معماری کاملاً متصل از نوع feedforward NN [۲۴].

همچنین در شکل ۸ یکی دیگر از معماری‌های DNN مشاهده می‌شود، به این معماری 10 CNN گفته می‌شود. قبل از لایه‌های متراکم، لایه‌های کانولوشن و لایه‌های پولینگ^{۱۱} اضافه می‌شوند. هر خروجی در لایه‌های کانولوشن با ضرب نقطه‌ای بین یک

⁹ Deep Neural network

¹⁰ Convolutional neural network

¹¹ pooling

$$\Delta W_1 = \frac{\partial L}{\partial W_2} \rightarrow W'_1 = W_1 - \alpha(\Delta W_1)$$

$$\Delta W_0 = \frac{\partial L}{\partial W_0} \rightarrow W'_0 = W_0 - \alpha(\Delta W_0)$$

در رابطه‌ی ۲۵ ضریب α ، نرخ یادگیری است. در سال ۲۰۱۲ الگوریتم بهینه سازی ADAM معرفی گردید که نسبت به الگوریتم SGD کارآمدتر می‌باشد [25]. این الگوریتم بر اساس بهینه‌سازی مبتنی بر گرادیان مرتبه اول توابع هدف تصادفی و تخمین تطبیقی لحظه‌های مرتبه پایین‌تر می‌باشد. این روش از نظر پیاده‌سازی ساده است، از نظر محاسباتی کارآمد است، نیاز به حافظه کمی دارد و برای مسائلی که از نظر داده‌ها و یا پارامترها بزرگ هستند، مناسب است. رابطه‌ی ۲۶ و ۲۷ الگوریتم adam را نشان می‌دهد.

$$m_l = \beta_1 m_{l-1} + (1 - \beta_1) \nabla W_l \quad (26)$$

$$v_l = \beta_2 v_{l-1} + (1 - \beta_2) [\nabla W_l]^2$$

در رابطه‌ی بالا ضریب β_1 و β_2 به ترتیب ضریب فروپاشی گرادیان^{۱۶} و ضریب فروپاشی مربع گرادیان^{۱۷} می‌باشد.

$$W_{l+1} = W_l - \frac{\alpha m_l}{\sqrt{v_l}} \quad (27)$$

۴-۱. طراحی شبکه یادگیری عمیق مبتنی بر


شکل دهی پرتو وقتی پهن باند

معماری پیشنهادی شبکه بر اساس ساختار یادگیری عمیق مطابق شکل ۱۳ است. در این معماری هسته‌ی اصلی شبکه لایه کانولوشنال و عملگر غیرخطی است. به منظور افزایش قابلیت شبکه، افزایش سرعت، دقت و حفظ مقادیر خروجی لایه‌ها در محدوده‌ی استاندارد، جلوگیری از over fitting از لایه‌های drop out، batch norm و average pooling استفاده شده است. همچنین در لایه آخر، ویژگی‌های استخراج شده وارد یک لایه‌ی تمام متصل^{۲۵} شده و شبکه به منظور استخراج ضرایب شکل‌دهی پرتو از لایه‌ی رگرژن^{۱۸} بهره برده است. ورودی معماری پیشنهادی، نمونه‌های سیگنال دریافتی از آرایه و خروجی آن، بردار ضرایب برای آرایه آنتن پهن‌باند است. جزییات معماری پیشنهادی در جدول ۴ بیان شده است.

در بخش آموزش دادن به شبکه، نیاز به نمونه‌های سیگنال دریافتی توسط آرایه است. ماتریسی از نمونه‌های سیگنال دریافتی به صورت رابطه‌ی ۲۸ خواهد بود که البته بایستی نرمالیزه شود:


سطح خطا^{۱۲} گفته می‌شود. در این سطح در صورتی که با شیب منفی^{۱۳} حرکت صورت گیرد، به نقطه حداقل خطا می‌رسد و در آن نقطه ضرایب شبکه قابل اطمینان و بهینه است و شبکه مرحله‌ی آموزش را با موفقیت طی کرده است.

• مقادیر مختلف تابع هزینه ← تشکیل یک سطح ناهموار (Loss surface)




شکل ۱۰- سطح خطا و نقطه حداقل خطا (محلی و گلوبال).

روش اصلاح پارامترها به روش تکنیک انتشار به عقب^{۱۴} انجام می‌شود در واقع پس از اینکه خطا طبق شکل ۹ محاسبه شد، حال با کمک مشتق گرفتن رابطه‌ی خطا نسبت به ضرایب که به آن SGD^{۱۵} گفته می‌شود، در جهتی که در شکل ۱۱ نشان داده شده است، مقدار ضرایب به دست می‌آید.



شکل ۱۱- جهت اصلاح پارامترها در لایه‌های شبکه یادگیری عمیق و این روند طبق شکل ۱۲ تا زمانی انجام می‌شود که مقدار خطا به کمترین مقدار خود برسد و ضرایب طبق رابطه‌ی ۲۵ بروز می‌شود.



شکل ۱۲- تکرار اصلاح وزن‌ها تا رسیدن به خطای گلوبال

$$\Delta W_2 = \frac{\partial L}{\partial W_2} \rightarrow W'_2 = W_2 - \alpha(\Delta W_2) \quad (28)$$

¹⁶ Gradient Decay Factor

¹⁷ Squared gradient decay factor

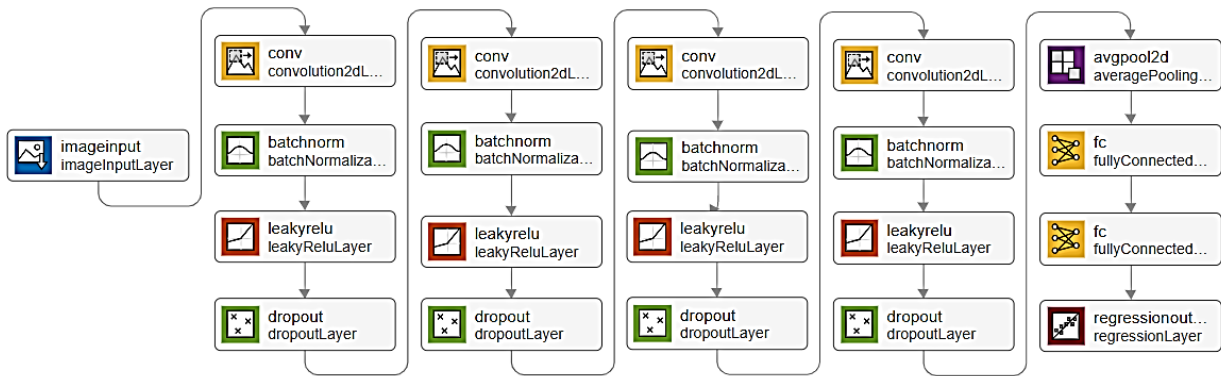
¹⁸ regression

¹² Loss Surface

¹³ Gradient descent

¹⁴ Back propagation

¹⁵ Stochastic Gradient Descent

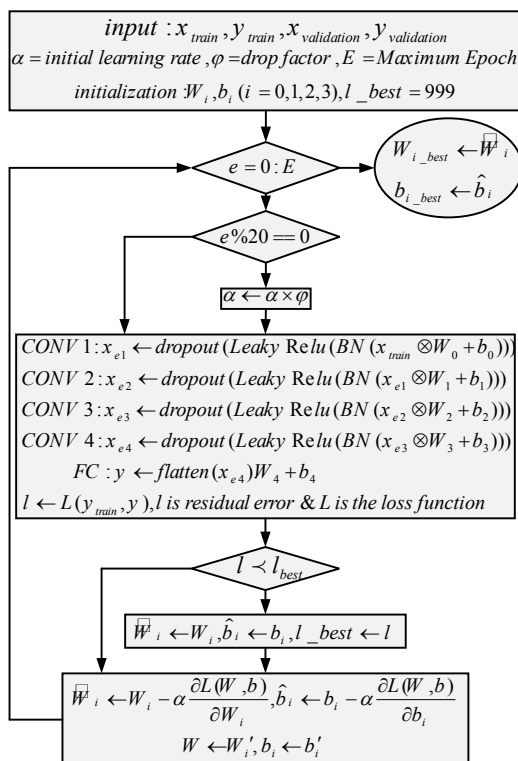


شکل ۱۳- ساختار اولیه شبکه WBBCNN برای شکل دهی پرتو پهن باند.

جدول ۴- جزئیات ساختار شبکه WBBCNN.

لایه	ابعاد خروجی از لایه‌ها	توضیح لایه
لایه ورودی	32 * 400 * 1	تصویر با ابعاد $N * M * N$ (تعداد المان‌ها و N تعداد اسنپ‌شات)
Conv1	32 * 400 * 32	به تعداد ۳۲ کرنل (فیلتر) با اندازه ۳*۳ و گام‌های ۱ و SAME padding
Conv2	32 * 400 * 64	به تعداد ۶۴ کرنل (فیلتر) با اندازه ۳*۳ و گام‌های ۱ و SAME padding
Conv3	32 * 400 * 128	به تعداد ۱۲۸ کرنل (فیلتر) با اندازه ۳*۳ و گام‌های ۱ و SAME padding
Conv4	32 * 400 * 256	به تعداد ۲۵۶ کرنل (فیلتر) با اندازه ۳*۳ و گام‌های ۱ و SAME padding
Leaky relu	No Change to layers	دارای تابع فعال ساز به صورت $f(x) = \begin{cases} x & x \geq 0 \\ 0.01x & x < 0 \end{cases}$
average-Pooling	No Change to layers	کرنل‌هایی با اندازه ۵*۵ و گام‌های ۱ و SAME padding
Drop out	Reduce 20 percent	با حذف تصادفی نورون‌ها به منظور جلوگیری از Overfitting با درصد حذف ۲۰ درصد
Fully-Connected1	12800 * 1	دارای MN نورون
Fully-Connected2	1280 * 1	دارای JM نورون
لایه خروجی	1280 * 1	دارای $JM \times 1$ گره (N تعداد المان‌ها و J تعداد ضرایب هر المان)

گرفته می‌شود. پیاده‌سازی شکل ۱۳ در شکل ۱۴ نشان داده‌می‌شود.



شکل ۱۴- فلوجارت پیاده سازی الگوریتم یادگیری عمیق

از آنجاکه ورودی لایه‌های کانولوشنال بایستی به فرمت تصویر باشد، پس ضرایب را به صورت ماتریس وارد شبکه می‌کنیم.

$$Sig = \begin{bmatrix} x_{1,1} & \dots & x_{1,N} \\ \vdots & \ddots & \vdots \\ x_{M,1} & \dots & x_{M,N} \end{bmatrix} \quad (28)$$

$$Sig_{normalize} = \frac{Sig}{Max(Sig)}$$

در نتیجه جفت‌های ورودی و خروجی به صورت $(Sig^m, weights^m)$ است که m مجموعه جفت ضرایب ورودی/خروجی و $weights^m$ ماتریس ضرایب آرایه پهن باند خواهد بود. ضرایب $weights^m$ از الگوریتم‌های رایج شکل دهی پرتو همانند LCMV به دست می‌آید. بعد از مرحله آموزش انتظار می‌رود بردارهای وزن توسط ورودی‌هایی که قبلاً در مرحله آموزش استفاده نشده بودند اما توزیعی همانند ورودی‌های آموزش دارند، تخمین زده شوند [۲۶]. در این ساختار در شرایط کم بودن SNR و ورودی، کم بودن تعداد اسنپ‌شات‌ها^{۲۷} (نمونه‌های در دسترس) و وجود خطاهای جهت ورود و آرایه، عملکرد مناسبی داشته باشد. همچنین این ساختار نسبت به الگوریتم‌های کلاسیک دارای حجم پردازش بسیار کمتری است. علاوه بر مزیت‌های اشاره شده در این ساختار نیازی به دانستن اطلاعات جهت ورود سیگنال نیست. در این ساختار، وقتی و تقویتی بودن (مقاوم بودن) شکل دهی پرتو پهن باند نیز در نظر

۵. نتایج شبیه‌سازی

هدف از شبیه‌سازی در روش یادگیری عمیق، آموزش دادن معماری شبکه طراحی به منظور تعیین ضرایب این ساختار است. در ابتدا از طریق رابطه کلاسیک LCMV، ورودی و خروجی شکل‌دهنده پرتو برای معماری شبکه طراحی شده، تعیین می‌شود. بدین صورت که ورودی، ماتریس سیگنال دریافتی الگوریتم LCMV و خروجی آن ضرایب شکل‌دهنده پرتو خواهد بود. مجموع جفت ورودی و خروجی به شبکه اعمال می‌شود. سناریوی تعریف شده طبق جدول ۶ است همچنین برای تولید داده‌های آموزش، جهت ورود سیگنال تداخل و سیگنال مطلوب با گام‌های 0.1° از زاویه $90^\circ \sim -90^\circ$ تغییر خواهد کرد. سخت افزار شبیه سازی، کامپیوتری با جدول ۵ می‌باشد.

جدول ۶- فرضیات شبیه سازی برای الگوریتم یادگیری عمیق.

$M = 32$	تعداد کانال‌های نمونه بردار
$J = 40$	تعداد خط تأخیرها
$\theta_0 = 0^\circ, \theta_1 = 40^\circ$ $\theta_0 = 30^\circ, \theta_1 = -20^\circ$	زاویه ورود سیگنال هدف و تداخل
$N_h = 10000, N_r = 400$	تعداد اسنپ شات (کم و زیاد)
-20 dB	SIR
10 dB	SNR
$\Omega_l = [0.4\pi]$	پهنای باند لحظه‌ای نرمالیزه
$\Delta d = 0.5\lambda_{min}$	فاصله بین المان‌ها

نتایج خروجی برای شکل‌دهی پرتو برای داده‌های تست طبق جدول ۶ در شکل ۱۶ تا شکل ۱۸ نشان داده می‌شود.

جدول ۵- مشخصات کامپیوتر استفاده شده

CPU	11th Gen Intel-Core i5 @ 2.60GHz
GPU	Nvidia Geforce RTX 3060 1320 MHz acceleration frequency 3584 Cuda core 12.7 TFLOP/S
GPU	12 GB
Dedicated RAM	16 GB
CPU RAM	


نمودار آموزش شبکه در شکل ۱۵ است. همان‌طور که در این شکل نشان داده شده است با افزایش تکرار (epoch)، خطا

Initializing input data normalization.

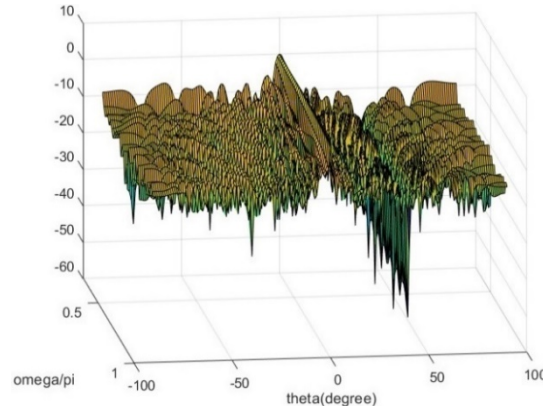
Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch RMSE	Validation RMSE	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:28	17.47	897.26	152.5622	402538.8438	0.0010
2	20000	00:06:02	0.04	0.82	0.0008	0.3352	0.0010
3	40000	00:11:33	0.05	0.68	0.0015	0.2341	0.0001
4	60000	00:17:04	0.02	0.53	0.0002	0.1427	0.0001
5	80000	00:22:34	0.04	0.41	0.0008	0.0829	1.0000e-05
6	100000	00:28:06	0.04	0.37	0.0009	0.0693	1.0000e-05
7	120000	00:33:37	0.01	0.35	5.0261e-05	0.0612	1.0000e-06
8	140000	00:39:09	0.01	0.35	8.2938e-05	0.0596	1.0000e-06
9	160000	00:44:39	1.65	0.34	1.3612	0.0593	1.0000e-07
10	180000	00:50:15	0.03	0.34	0.0006	0.0592	1.0000e-07
10	180010	00:50:21	0.11	0.34	0.0058	0.0592	1.0000e-07

Training finished: Max epochs completed.


شکل ۱۵- نمایش خطا به صورت RMSE و Loss در حین آموزش شبکه.



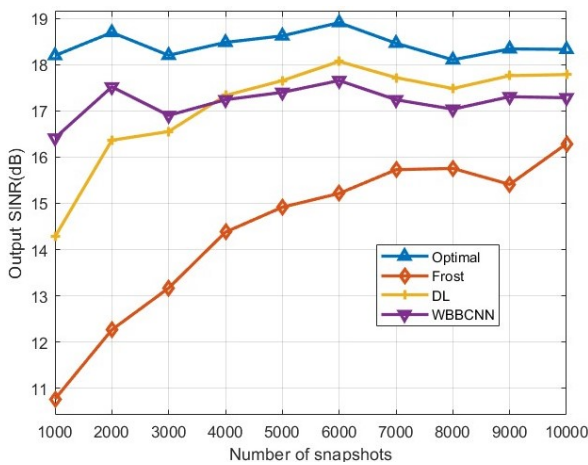
شکل ۱۷- شکل دهی پرتو برای فراست با اسنپ‌شات پایین ($N_r = 400$) همچنین در این ساختار، همانطور که گفته شد، آموزش شبکه به گونه ای انجام شده است که کل زوایای $90^\circ \sim -90^\circ$



شکل ۱۶- شکل دهی پرتو برای فراست با اسنپ‌شات بالا، $N_r = 10000$



(الف)



(ب)

شکل ۲۰- خروجی SINR در مقابل تعداد اسنپ شات ها.

الف) محدوده اعداد ۲۰۰ تا ۹۰۰ است. ب) محدوده اعداد ۱۰۰۰ تا ۱۰۰۰۰ است.

محاسبات پیچیدگی (تعداد ضرب) برای روش پیشنهاد شده در جدول ۷ نشان داده شده است.

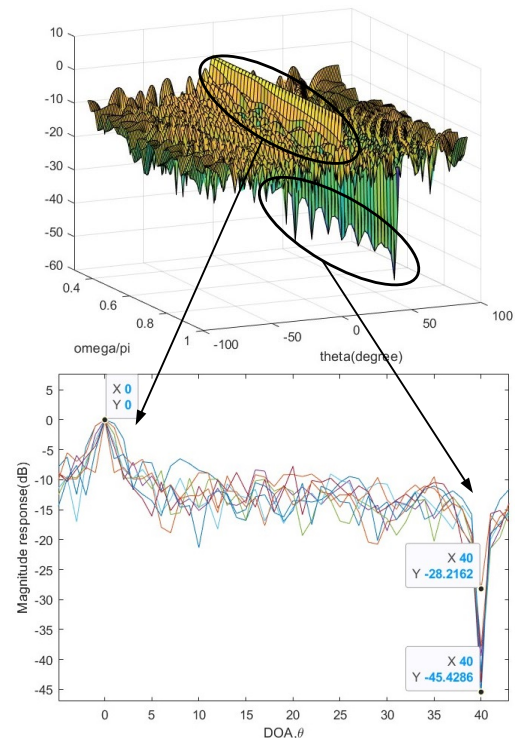
جدول ۷- پیچیدگی محاسباتی روش WBBCNN

WBBCNN	
$M = M_1 * M_2$	number of sensors
N	number of snapshots
J	number of TDLs
ks	size of kers in CNN layer
ch_{in} & ch_{out}	size of input & output channel
① Conv1	$\rightarrow O[(M * N) * ks^2 * ch_{in1} * ch_{out1}]$
② Conv2	$\rightarrow O[(M * N) * ks^2 * ch_{in2} * ch_{out2}]$
③ Conv3	$\rightarrow O[(M * N) * ks^2 * ch_{in3} * ch_{out3}]$
④ Conv4	$\rightarrow O[(M * N) * ks^2 * ch_{in4} * ch_{out4}]$
⑤ fc	$\rightarrow 2 * O[(M * N) * ch_{out4} * (M * J)]$
Total Complexity = [① + ② + ③ + ④ + ⑤]	


پس از تعیین پارامترهای شبکه توسط gpu این روش همانند الگوریتم frost در تراشه‌ی fpga پیاده می‌شود. که زمان مورد نیاز برای تشکیل پرتو پایدار طبق رابطه‌ی ۲۲ به دست می‌آید. برای به دست آوردن زمان مورد نیاز از روی پیچیدگی محاسباتی، تعداد منابع DSP را برابر با ۴۰۰۰ و نرخ نمونه برداری را 2GSPS در نظر گرفته ایم. طبق مقایسه‌ی صورت

پوشش داده شود، بنابراین با جابه‌جا کردن پرتوی اصلی و تغییر جایگاه ورود سیگنال تداخل، شبیه‌سازی عملکرد ساختار یادگیری عمیق مطابق با شکل ۱۹ است.

در شکل ۲۰ نتایج مقادیر SINR خروجی بر حسب تعداد اسنپ شات ها نشان داده شده است. در این شکل، ساختار پیشنهادی با حالت ایده آل (لاگرانژ)، الگوریتم فراست و شکل دهی پرتوی به روش Diagonal Loading مقایسه شده است. همانطور که مشاهده می‌شود، عملکرد الگوریتم‌های فراست و diagonal loading با داشتن تعداد اسنپ شات‌های بسیار زیاد به سمت حالت ایده آل در حرکت هستند و پارامتر SINR بالاتر می‌رود، در ساختار پیشنهاد شده، عملکرد تا حد زیادی مستقل از تعداد اسنپ شات‌ها بوده و به حالت ایده آل نزدیک می‌باشد. و حتی در تعداد اسنپ شات کم عملکرد قابل قبولی دارد.



شکل ۱۸- خروجی شکل دهی پرتو حاصل از WBBCNN با $N_f = 400$



شکل ۱۹- خروجی شکل دهی پرتو حاصل از WBBCNN در حالت

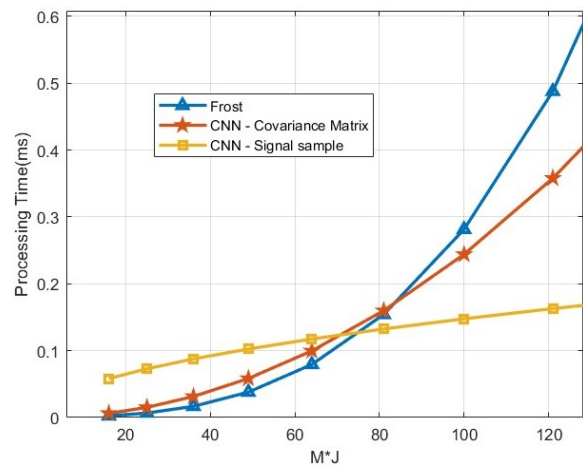
$N_f = 400$ با offBroadside

مقایسه با الگوریتم کلاسیک با تعداد اسنپ شات های فراوان می‌باشد.

۷. مراجع

- [1]. Giagkos, A., et al. Comparing approaches for coordination of autonomous communications UAVs. in 2016 International Conference on Unmanned Aircraft Systems (ICUAS). 2016. IEEE. DOI: 10.1109/ICUAS.2016.7502551
- [2]. Zolanvari, M., R. Jain, and T. Salman, *Potential data link candidates for civilian unmanned aircraft systems: A survey*. IEEE Communications Surveys & Tutorials, 2020. DOI: 10.1109/COMST.2019.2960366
- [3]. Melvin, W.L. and J.A. Scheer, *Principles of Modern Radar Vol. II: Advanced Techniques*, 2013 by SciTech Publishing. Edison, NJ.
- [4]. Liu, W. and S. Weiss, *Wideband beamforming: concepts and techniques*. Vol. 17. 2010: John Wiley & Sons.
- [5]. Chen, P., et al., Robust covariance matrix reconstruction algorithm for time-domain wideband adaptive beamforming. IEEE Transactions on Vehicular Technology, 2018. DOI: 10.1109/TVT.2018.2885596
- [6]. Monzingo, R.A. and T.W. Miller, *Introduction to adaptive arrays*. 2004: Scitech publishing.
- [7]. سدیدیپور، س.س.، همکاران، شباهت معنایی جملات فارسی با استفاده از تطبیق فضای برداری و یادگیری عمیق. پدافند الکترونیکی و سایبری، ۲۰۲۲.
- [8]. ناصحی، م.، م.، عشوریان، ح. امامی، شناسایی سریع مکان و نوع وسیله نقلیه در تصاویر با استفاده از روش یادگیری عمیق. پدافند الکترونیکی و سایبری، ۲۰۲۲.
- [9]. Li, Y., X. Yang, and F. Liu, *Fast and robust adaptive beamforming method based on complex-valued RBF neural network*. The Journal of Engineering, 2019. 2019(19): p. 5917-5921. DOI: 10.1049/joe.2019.0275
- [10]. Luijten, B., et al. Deep learning for fast adaptive beamforming. in ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2019. IEEE. DOI: 10.1109/ICASSP.2019.8683478
- [11]. Sallam, T. and A.M. Attiya, *Convolutional neural network for 2D adaptive beamforming of phased array antennas with robustness to array imperfections*. International Journal of Microwave and Wireless Technologies, 2021. DOI: 10.1017/S1759078721001070
- [12]. Ramezanpour, P., M.J. Rezaei, and M.R.

گرفته در شکل ۲۱ برای دو روش Frost و WBBCNN در حالت ماتریس کوواریانس و نمونه های سیگنال، واضح است که در روش Frost به دلیل اینکه در رابطه پیچیدگی از توان های محاسباتی $([M]^3)$ استفاده شده است، به زمان پردازش بیشتری نیاز دارد.



شکل ۲۱- زمان مورد نیاز پردازش بر حسب حاصلضرب تعداد کانال TDL و

بنابراین با افزایش تعداد ضرایب و تعداد المان‌ها به شدت پیچیدگی افزایش می‌یابد. زمان محاسبات به دست آمده در روش WBBCNN بسیار کمتر از روش Frost بوده و همچنین در حالت استفاده از نمونه های سیگنال، پیچیدگی با افزایش حاصلضرب تعداد کانال ها و TDL به شدت کمتر از حالت ماتریس کوواریانس است. این زمان کمتر از زمان محاسبه شده مانند هدف در پهنای پرتو در رابطه ی ۲۳ می- باشد. بنابراین قابلیت پیاده سازی و اجرای عملکرد مطلوب را خواهد داشت.

در ارتباط با معایب استفاده از یادگیری عمیق می‌توان به این نکته اشاره کرد که آموزش شبکه با توجه به ساختار و داده‌ی آموزش می‌تواند بسیار زمان‌بر باشد و به سخت افزار بسیار قوی و مخصوصا کارت گرافیک (GPU) مناسب نیاز داریم.

۶. نتیجه گیری

در این مقاله استفاده از الگوریتم و معماری شبکه را به عنوان جایگزینی مناسب برای شکل‌دهی پرتو پهن باند وقتی برای آرایه ای عملیاتی که دارای المان های زیاد و تعداد ضرایب شکل دهنده ی بزرگ است، معرفی شد. در روش WBBCNN پیچیدگی محاسباتی نسبت به الگوریتم‌های کلاسیک شکل-دهی پرتو پهن باند وقتی کاهش می‌یابد به طوری که روش سنتی برای آرایه‌ی هدف قابلیت پیاده سازی را نداشت در حالی که روش پیشنهاد شده بر این محدودیت غلبه کرده است. همچنین در این روش مشاهده می‌شود که شکل‌دهی پرتو پهن باند توانایی قابل قبولی برای به دست آوردن SINR دارد و قابل

- [25]. Kingma, D.P. and J. Ba, *Adam: A method for stochastic optimization*. arXiv preprint arXiv:1412.6980, 2014. DOI: 10.48550/arXiv.1412.6980
- [26]. Goodfellow, I., Y. Bengio, and A. Courville, *Deep learning*. 2016: MIT press.
- Mosavi, *Deep-learning-based beamforming for rejecting interferences*. IET Signal Processing, 2020. DOI: 10.1049/iet-spr.2019.0495
- [13]. Lin, T. and Y. Zhu, *Beamforming design for large-scale antenna arrays using deep learning*. IEEE Wireless Communications letters, 2019. DOI: 10.1109/LWC.2019.2943466
- [14]. Zhao, Y., W. Liu, and R.J. Langley, *Adaptive wideband beamforming with frequency invariance constraints*. IEEE Transactions on Antennas and Propagation, 2011. DOI: 10.1109/TAP.2011.2110630
- [15]. Oppenheim, A.V. and R.W. Schaffer, *Digital signal processing (Book)*. Research supported by the Massachusetts Institute of Technology, Bell Telephone Laboratories, and Guggenheim Foundation. Englewood Cliffs, N. J., Prentice-Hall, 1975.
- [16]. Liu, Y., et al., *Robust adaptive wideband beamforming based on time frequency distribution*. IEEE Transactions on Signal Processing, 2019. 67(16): p. 4370-4382. DOI: 10.1109/TSP.2019.2929924
- [17]. Frost, O.L., *An algorithm for linearly constrained adaptive array processing*. Proceedings of the IEEE, 1972. 60(8): p. 926-935. DOI: 10.1109/PROC.1972.8817
- [18]. Steyskal, H., *Wide-band nulling performance versus number of pattern constraints for an array antenna*. IEEE Transactions on Antennas and Propagation, 1983. 31(1): p. 159-163. DOI: 10.1109/TAP.1983.1142993
- [19]. Takao, K. and K. Komiyama, *An adaptive antenna for rejection of wideband interference*. IEEE Transactions on Aerospace and Electronic Systems, 1980(4): p. 452-459. DOI: 10.1109/TAES.1980.308974
- [20]. Mailloux, R.J., *Phased array antenna handbook*. 2017: Artech house.
- [21]. Van Trees, H.L., *Optimum array processing: Part IV of detection, estimation, and modulation theory*. 2004: John Wiley & Sons.
- [22]. UltraScale Architecture and Product Data Sheet: Overview. 2017.
- [23]. Skolnik, M.I., *Introduction to radar*. Radar handbook, 1962. 2: p. 21.
- [24]. Wang, T., et al., *Deep learning for wireless physical layer: Opportunities and challenges*. China Communications, 2017. 14(11): p. 92-111. DOI: 10.1109/CC.2017.8233654