

## آشکارسازی عمیق MIMO در حضور خطای تخمین کانال

حسین خالقی بیزکی<sup>۱</sup>، استاده، مهدی طیب‌مسعود<sup>۲</sup>، دانشجوی دکترای تخصصی

۱- مجتمع دانشگاهی برق و کامپیوتر - دانشگاه صنعتی مالک اشتر - تهران - ایران - bizaki@yahoo.com  
 ۲- مجتمع دانشگاهی برق و کامپیوتر - دانشگاه صنعتی مالک اشتر - تهران - ایران - mahdi.tm@gmail.com

**چکیده:** ظرفیت سیستم‌های مخابرات بی‌سیم را می‌توان با بکار بردن چند آنتن در فرستنده و چند آنتن در گیرنده به نحو قابل‌ملاحظه‌ای افزایش داد. در چنین سیستم‌هایی، که MIMO نام دارند، گیرنده با دانشی که از کانال دارد، به آشکارسازی سیگنال ارسالی می‌پردازد. روش‌های مختلفی برای آشکارسازی بهینه و زیربهینه سمبل‌های ارسالی پیشنهاد شده است. اخیراً مفاهیم یادگیری عمیق و استفاده از شبکه‌های عصبی به‌منظور آشکارسازی در حد بهینه و حجم محاسبات کمتر در فرآیند تست، در مقایسه با سایر روش‌های سنتی پیشین، بکار گرفته شده است. در صورتی که اطلاعات کانال در گیرنده با خطا همراه باشد، کارایی این نوع آشکارساز کاهش یافته و در نتیجه نرخ خطای بیت افزایش می‌یابد. با توجه به اینکه در عمل، گیرنده تخمینی از کانال میان فرستنده و گیرنده را در اختیار دارد و نه مقدار دقیق آن را، مقاله حاضر روشی بهبودیافته برای آشکارسازی مبتنی بر یادگیری عمیق و مقاوم در برابر خطای تخمین کانال، پیشنهاد می‌کند. در این روش آشکارسازی با استفاده از ماتریس کوواریانس تخمین‌گر کانال و استفاده از مفاهیم یادگیری عمیق، یک آشکارساز مقاوم در برابر خطای تخمین کانال پیشنهاد و به صورت تحلیلی مورد بررسی قرار گرفته است. نتایج شبیه‌سازی مبین کارایی روش پیشنهادی در سیستم‌های MIMO است.

**واژه‌های کلیدی:** سیستم‌های چند ورودی و چند خروجی (MIMO)، آشکارسازی مقاوم، یادگیری عمیق، خطای تخمین کانال.

## Deep MIMO Detection with Imperfect CSI

Hosein Khaleghi, Associate Professor<sup>1</sup>, Mahdi Tayeb Masoud, Ph.D. Student<sup>2</sup>

1- Faculty of Electrical and Computer Engineering, Malek Ashtar University of Technology, Tehran, Iran, Email: bizaki@yahoo.com  
 2- Faculty of Electrical and Computer Engineering, Malek Ashtar University of Technology, Tehran, Iran, Email: mahdi.tm@gmail.com

**Abstract:** It is possible to noticeably increase the capacity of wireless communication systems through the use of multiple antennas both in the transmitter and in the receiver. In such systems, which are referred to in short as MIMO, the receiver uses its knowledge of the channel to detect the transmitted signal. Different methods have been proposed for optimal and sub-optimal detection of the transmitted signals. Recently, principles of deep learning and implementing neural networks have been employed as a near optimal approach for MIMO detection with fewer calculations during the testing process compared to traditional methods. In the event an error occurs in the receiver's channel estimation process, this type of detector suffers a drop in performance and as a result, BER will increase. Given that in practice, the receiver only has an estimation of the CSI instead of the exact values, the current study presents an enhanced detection method based on deep learning, which is also robust against channel estimation error. In this detection method, by using the covariance matrix of the channel estimator and the principles of deep learning, a robust detector against channel estimation error is proposed and comprehensively evaluated. Numerical simulations confirm the performance of the proposed method.

**Keywords:** Multiple Input Multiple Output (MIMO), Robust Detection, Deep Learning, Channel Estimation Error.

تاریخ ارسال مقاله: ۱۴۰۰/۰۲/۲۷

تاریخ اصلاح مقاله: ۱۴۰۰/۱۱/۱۸

تاریخ پذیرش مقاله: ۱۴۰۰/۱۱/۱۹

نام نویسنده مسئول: حسین خالقی

نشانی نویسنده مسئول: ایران - تهران - لویزان - دانشگاه صنعتی مالک اشتر - دانشکده مهندسی برق و کامپیوتر.



## ۱- مقدمه

فناوری چند ورودی - چند خروجی (MIMO) [۱]، امروزه در بسیاری از سیستم‌های مخابراتی مدرن بکار گرفته شده است. نیاز روزافزون به ارسال داده با نرخ بیت بالا، به‌ویژه در سیستم‌های مخابرات بی سیم و همچنین محدودیت سیستم‌های موجود در برآورده ساختن این نیاز سبب شده که در سال‌های اخیر سیستم‌های مخابرات مبتنی بر MIMO به خاطر استفاده مؤثر از پهنای باند بسیار مورد توجه قرار گیرند [۲ و ۳]. استفاده از این فناوری می‌تواند بهبود قابل توجهی در افزایش ظرفیت سیستم ایجاد کند، اما مشکل چالشی آن، پیچیدگی محاسباتی در آشکارسازی است [۴].

روش‌های آشکارسازی مرسوم، از رویکردهای خطی و غیرخطی برای آشکارسازی استفاده می‌کنند. به‌عنوان مثال، روش‌های اجبار صفر (ZF) [۵] و کمینه میانگین مربعات خطا (MMSE) [۶] از رویکرد خطی و روش آشکارسازی مبتنی بر حداقل فاصله یا بیشینه شباهت (ML) [۷] از رویکرد غیرخطی بهره می‌برند. اگرچه روش ML در تئوری، عملکرد بهینه جهت آشکارسازی دارد، اما پیچیدگی محاسباتی بالای آن موجب شده است که در عمل قابل استفاده نباشد [۸]. الگوریتم کدگشایی کروی (SD) به‌منظور حل مشکل پیچیدگی محاسباتی ML پیشنهاد شده است [۹]. در این الگوریتم بجای جستجوی کامل فضای داده، از جستجوی تئوری بهره گرفته شده است و لذا پیچیدگی کمتری نسبت به ML دارد ولی دیگر بهینه نیست. روش‌های غیرخطی دیگری نیز مانند جبران ساز بازخورد تصمیم (DFE) [۱۰] و ارسال تقریبی پیام (AMP) [۱۱] نیز با اینکه دقت بالایی در آشکارسازی دارند، ولی با چالش بالا بودن پیچیدگی محاسباتی مواجهند. در تمامی آشکارسازهای کلاسیک معرفی شده، فرآیند آشکارسازی به دو مرحله تخمین CSI و به‌کارگیری این دانش برای آشکارسازی استوار است. لذا هرگونه خطا در تخمین اطلاعات کانال، باعث افت دقت آشکارسازی خواهد بود.

در سال‌های اخیر، جهان با انقلابی در حوزه یادگیری ماشین مواجه بوده است. در بسیاری از زمینه‌های مهندسی، مانند بینایی ماشین، نشان داده شده است که رایانه‌ها می‌توانند با زوج‌هایی از ورودی‌ها و خروجی‌های مورد انتظار، تغذیه شوند، و توابعی که به آن‌ها مربوط می‌شود را یاد بگیرند. این روال‌ها سپس می‌تواند برای آشکارسازی خروجی‌های ناشناخته ورودی‌های آتی، بکار گرفته شوند.

با پیشرفت و توسعه راه‌کارهای مبتنی بر یادگیری ماشین، مسائل پیچیده و چالش‌برانگیزی در حوزه ارتباطات بی‌سیم با این راه‌کارها بازتعریف و حل شده‌اند. در [۱۲] با استفاده از شبکه‌های عصبی کانولوشنی یک روش کارآمد برای همسان‌سازی کور کانال پیشنهاد شده است. در [۱۳] روشی مبتنی بر یادگیری عمیق برای آشکارسازی MIMO و کدگشایی کانال به صورت توأم پیشنهاد شده است. همچنین به‌منظور بهبود عملکرد الگوریتم‌های تکرارپذیر برای آشکارسازی MIMO، یک ساختار یادگیری عمیق در [۱۴] معرفی شده است.

به‌عنوان یک کاربرد قابل توجه، در [۱۵] یک الگوریتم مبتنی بر یادگیری ماشین با عملکرد نزدیک به بهینه و پیچیدگی کمتر نسبت به ML پیشنهاد شده است. مهم‌ترین دستاورد این روش، معرفی ساختار DetNET به‌عنوان یک شبکه یادگیری عمیق برای آشکارسازی MIMO است. DetNET از یک شبکه کانولو شنی و از تکنیک گرادینان کاهش برای تخمین سمبل‌ها استفاده می‌کند. درعین حال روش پیشنهادی یک الگوریتم سریع است که می‌تواند به‌صورت بلادرنگ پیاده‌سازی شود. در این روش فرض شده است که اطلاعات کانال به صورت کامل در اختیار است.

یکی از روش‌های پرکاربرد برای تخمین کانال، ارسال سیگنال‌های از پیش معینی به نام سیگنال‌های آموزش، توسط فرستنده در بازه‌های زمانی معین است [۱۶]. در روش دیگر کانال را به‌صورت کور تخمین می‌زنند [۱۷]. در هر صورت، در عمل تمامی این روش‌ها مقدار دقیق ماتریس کانال را در اختیار قرار نمی‌دهند؛ بلکه کانال را به‌صورت تخمینی و همراه با خطا به دست می‌آورند. اما یکی از چالش‌های مطرح در زمینه آشکارسازی، مقاومت در برابر خطای تخمین کانال است. در عمل به دلیل ماهیت متغیر با زمان کانال و همچنین محدودیت‌های عملی، اطلاعات در دسترس از کانال با خطا همراه خواهد بود. وجود این خطای تخمین در ماتریس کانال باعث کاهش کارایی و افت عملکرد آشکارسازی شده و نرخ خطای آشکارسازی سمبل‌ها در گیرنده را افزایش خواهد داد [۱۸].

برای یک سیستم MIMO، اثر تخمین ناکامل کانال در صورت استفاده از آشکارساز ML، در مقالات متعددی مورد بررسی قرار گرفته است [۵ و ۶]. به‌صورت مشابه در [۱۹]، یک سیستم MIMO تک کاربره در نظر گرفته شده و یک راهکار چرخشی برای تخمین کانال و آشکارسازی سمبل‌ها به صورت توأم پیشنهاد شده است. اما راهکار پیشنهادی برای سیستم‌های چندکاربره قابل استفاده نیست. چراکه در این سیستم‌ها تعداد سمبل‌های داده و پایلوت، نحوه چینش آن‌ها و تخصیص توان بهینه، برای چند کاربر باید به‌صورت هم‌زمان در نظر گرفته شود. این مهم در حضور خطای تخمین کانال مورد بررسی قرار گرفته است [۱۷]. در [۲۰] استفاده از ماتریس‌های کوواریانس کانال به‌جای تخمین مستقل تمامی کانال‌های تداخلی، برای افزایش مقاومت گیرنده MMSE در برابر خطای تخمین کانال پیشنهاد شده است. راهکارهای کور نیز برای آشکارسازی MIMO در [۱۷ و ۲۱] پیشنهاد شده است. مشکل اصلی این روش‌ها ابهام در آشکارسازی سمبل‌ها است.

هدف این مقاله، به‌کارگیری روش یادگیری ماشین عمیق در مسئله کلاسیک آشکارسازی MIMO، و بهبود عملکرد آن در حضور خطای تخمین کانال است. در ابتدا بر اساس روش تحلیلی، یک مدل مبتنی بر یادگیری عمیق برای آشکارسازی مقاوم به خطای تخمین کانال معرفی شده، و عملکرد آن با روش محاسباتی مورد ارزیابی قرار می‌گیرد.

## ۲- مدل سیستم

مطابق شکل ۱، یک سیستم مخابراتی MIMO با  $N_t$  عدد آنتن فرستنده و  $N_r$  عدد آنتن گیرنده در نظر گرفته می‌شود. فرض می‌شود که محیط میان آنتن‌های فرستنده و گیرنده مملو از پراکنده‌کننده است. به این ترتیب بین مجموعه آنتن‌های فرستنده و گیرنده،  $N_t \times N_r$  کانال برای ارسال سیگنال وجود خواهد داشت. در فرستنده، سیگنال‌های ارسال پس از کدگذاری در بخش‌های  $N_t$  تایی دی مالتی پلکس شده و پس از مدولاسیون بر روی  $N_t$  آنتن فرستنده قرار می‌گیرند. کانال میان آنتن‌های فرستنده و گیرنده از نوع فیدینگ تخت در نظر گرفته شده است. اگر سیگنال دمالتی پلکس شده باند پایه متناظر با آنتن‌های فرستنده را در هر زمان با بردار  $\mathbf{x} = [x_1, x_2, \dots, x_{N_t}]^T$  و سیگنال‌های دریافتی آنتن‌های گیرنده در باند پایه را با بردار  $\mathbf{y} = [y_1, y_2, \dots, y_{N_r}]^T$  نشان دهیم، رابطه بین ورودی و خروجی‌های کانال مفروض به صورت ماتریسی زیر قابل بیان است.

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n} \quad (1)$$

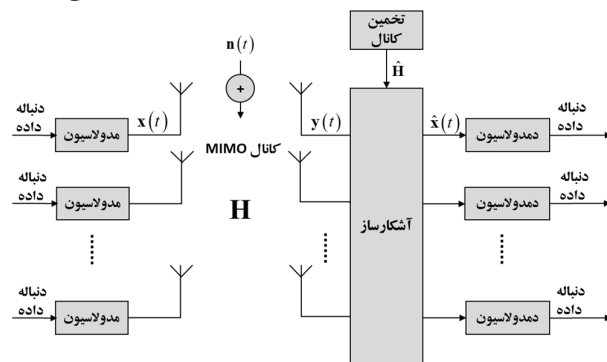
که در این رابطه  $\mathbf{n} = [n_1, n_2, \dots, n_{N_r}]^T$  بردار نویز گوسی مختلط جمع شونده با میانگین صفر و ماتریس کوواریانس  $\sigma_n^2 \mathbf{I}$  است. اگر محیط میان فرستنده و گیرنده طبق فرض پر از پراکنده‌سازها باشد، آنگاه ماتریس  $\mathbf{H}$  یک ماتریس مختلط با ابعاد  $N_r \times N_t$  است که عناصر آن متغیرهای تصادفی مستقل از هم با توزیع مختلط گوسی در نظر گرفته می‌شوند.

مدل استاندارد MIMO خطی به صورت زیر در نظر گرفته می‌شود:

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n} \quad (2)$$

که در آن  $\mathbf{y} \in \mathbb{R}^N$  بردار دریافتی،  $\mathbf{H} \in \mathbb{R}^{N \times K}$  ماتریس کانال،  $\mathbf{x} \in \{\pm 1\}^K$  یک بردار نامعلوم از سمبل‌های باینری مستقل با احتمال یکسان،  $\mathbf{n} \in \mathbb{R}^N$  بردار نویز با متغیرهای گوسی مستقل با متوسط صفر و واریانس  $\sigma^2$  است.

فرض می‌کنیم که اطلاعات حالت کانال (CSI) و  $\mathbf{H}$  به صورت دقیق معلوم‌اند. هدف ما آشکارسازی  $\mathbf{x}$  با استفاده از الگوریتمی مبتنی بر یادگیری عمیق است که  $\mathbf{y}$  و  $\mathbf{H}$  را به عنوان ورودی دریافت می‌کند



شکل ۱: مدل سیستم MIMO

و  $\hat{\mathbf{x}}$  را تخمین می‌زند.

اولین گام انتخاب یک ساختار آشکارسازی است. یک ساختار ممکن می‌تواند تابع  $\hat{\mathbf{x}}_\theta(\mathbf{H}, \mathbf{y})$  باشد، که سمبل‌های نامعلوم را بر اساس  $\mathbf{H}$  و  $\mathbf{y}$  داده شده آشکارسازی می‌کند. فرآیند یادگیری، مسئله یافتن  $\theta$  در یک مجموعه محتمل است که منجر به آشکارسازی  $\hat{\mathbf{x}}_\theta(\mathbf{H}, \mathbf{y})$  خواهد شد. با انتخاب مجموعه پارامتر و توابع مختلف، انواع مختلفی از آشکارسازها توصیف خواهند شد که مصالحه‌های بین دقت و پیچیدگی خواهند داشت.

برای یافتن بهترین آشکارساز، یک تابع زیان  $l(\mathbf{x}; \hat{\mathbf{x}}_\theta(\mathbf{H}, \mathbf{y}))$  که فاصله بین سمبل صحیح و تخمین آن را اندازه می‌گیرد، تعریف می‌کنیم. سپس، مجموعه پارامترهای شبکه یادگیری  $\theta$ ، که منجر به کمینه شدن تابع هزینه روی توزیع مدل MIMO می‌شوند را می‌یابیم.

$$\min_{\theta} E\{l(\mathbf{x}; \hat{\mathbf{x}}_\theta(\mathbf{H}, \mathbf{y}))\} \quad (3)$$

که در آن امید ریاضی، نسبت به تمام متغیرهای تصادفی در رابطه (۱) است. یادگیری برای آشکارسازی، به صورت یافتن بهترین مجموعه از پارامترهای  $\theta$  از ساختار  $\hat{\mathbf{x}}_\theta(\mathbf{H}, \mathbf{y})$  که تابع زیان مورد انتظار را روی توزیع در رابطه (۱) کمینه می‌کنند، تعریف می‌شود. فرض می‌شود که اطلاعات کانال به صورت کامل در دسترس است.

## ۲-۱- آشکارسازی MIMO بر اساس یادگیری عمیق

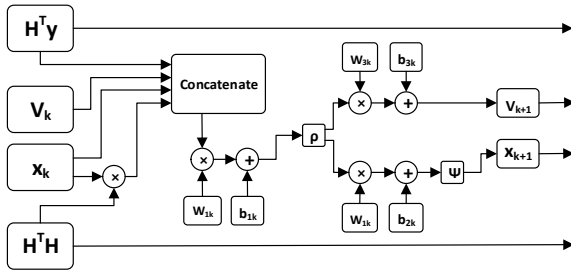
در این بخش، ساختار یک آشکارساز مبتنی بر یادگیری عمیق که به صورت اختصاصی برای آشکارسازی MIMO طراحی شده است و به صورت اختصا صی برای آشکارسازی MIMO طراحی شده است و DetNet نام دارد، معرفی می‌شود. با توجه به اینکه دقت بالای آشکارسازی در حد بهینه مدنظر است و فرض شده است که اطلاعات کانال به صورت کامل در دسترس است، لذا به منظور استفاده از آماره بسنده، رابطه (۲) را به صورت زیر بازنویسی می‌کنیم [۱۲]:

$$\mathbf{H}^T \mathbf{y} = \mathbf{H}^T \mathbf{H} \mathbf{x} + \mathbf{H}^T \mathbf{n} \quad (4)$$

رابطه (۴) نشان می‌دهد که دو جزء مهم در ساختار آشکارسازی باید  $\mathbf{H}^T \mathbf{y}$  و  $\mathbf{H}^T \mathbf{H} \mathbf{x}$  باشند. بر اساس راهکار گرادیان کاهش برای بهینه‌سازی، رابطه تکرارپذیر زیر در نظر گرفته می‌شود:

$$\hat{\mathbf{x}}_{k+1} = \prod \left[ \hat{\mathbf{x}}_k - \delta_k \frac{\partial \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2}{\partial \mathbf{x}} \Big|_{\mathbf{x} = \hat{\mathbf{x}}_k} \right] \quad (5)$$

که در آن  $\hat{\mathbf{x}}_k$  تخمین در تکرار  $k$ ام است.  $\prod(\cdot)$  یک عملگر غیرخطی و  $\delta_k$  نرخ یادگیری را مشخص می‌کند. هر تکرار یک ترکیب خطی از  $\mathbf{x}_k$ ،  $\mathbf{H}^T \mathbf{y}$  و  $\mathbf{H}^T \mathbf{H} \mathbf{x}$  است که با یک عملگر غیرخطی دنبال می‌شود. به منظور پیاده‌سازی آشکارساز مبتنی بر یادگیری عمیق، در DetNET از شبکه‌های عصبی تماماً متصل استفاده شده است. ساختار هر پرسپترون در شبکه تماماً متصل در شکل ۲ نمایش داده شده است. با توجه به شکل ۲ می‌توان نوشت:



شکل ۳۱: ساختار یک لایه از شبکه یادگیری عمیق DetNet [۱۵]

خطای نرمالیزه شده به صورت:

$$NMSE = \frac{E \left[ |h_{ij} - \hat{h}_{ij}^*|^2 \right]}{E \left[ |h_{ij}|^2 \right]} = e^2 \quad (12)$$

لذا می توان نوشت:

$$\begin{aligned} \mathbf{H} &\sim CN(0, \mathbf{I}) \\ \hat{\mathbf{H}} &\sim (1 - \rho^2) CN(0, \mathbf{I}) \\ \Delta \mathbf{H} &\sim \rho CN(0, \mathbf{I}) \end{aligned} \quad (13)$$

با توجه به اینکه خطای تخمین کانال تصادفی است،  $\mathbf{H}$  یک متغیر تصادفی بوده و رابطه آشکارسازی را می توان به صورت متوسط عملکرد آن نسبت به خطای تخمین کانال در نظر گرفت. با جایگذاری در رابطه (۵) خواهیم داشت:


$$\begin{aligned} \hat{x}_{k+1} &= \prod \left[ E_{\Delta H} \left\{ \hat{x}_k - \delta_k \frac{\partial \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2}{\partial \mathbf{x}} \Big|_{\mathbf{x} = \hat{x}_k} \right\} \right] \\ &= \prod \left[ E_{\Delta H} \left\{ \hat{x}_k - \delta_k \mathbf{H}^T \mathbf{y} + \delta_k \mathbf{H}^T \mathbf{H} \hat{x}_k \right\} \right] \\ &= \prod \left[ E_{\Delta H} \left\{ \hat{x}_k - \delta_k (\hat{\mathbf{H}} + \Delta \mathbf{H})^T \mathbf{y} + \delta_k (\hat{\mathbf{H}} + \Delta \mathbf{H})^T (\hat{\mathbf{H}} + \Delta \mathbf{H}) \hat{x}_k \right\} \right] \\ &= \prod \left[ E_{\Delta H} \left\{ \hat{x}_k - \delta_k (\hat{\mathbf{H}} + \Delta \mathbf{H})^T \mathbf{y} + \delta_k (\hat{\mathbf{H}} + \Delta \mathbf{H})^T (\hat{\mathbf{H}} + \Delta \mathbf{H}) \hat{x}_k \right\} \right] \\ &= \prod \left[ \hat{x}_k - \delta_k \hat{\mathbf{H}}^T \mathbf{y} + \delta_k E_{\Delta H} \left\{ \Delta \mathbf{H}^T \right\} \mathbf{y} + \delta_k E_{\Delta H} \left\{ (\hat{\mathbf{H}} + \Delta \mathbf{H})^T (\hat{\mathbf{H}} + \Delta \mathbf{H}) \right\} \hat{x}_k \right] \\ &= \prod \left[ \hat{x}_k - \delta_k \hat{\mathbf{H}}^T \mathbf{y} + \delta_k E_{\Delta H} \left\{ \hat{\mathbf{H}}^T \hat{\mathbf{H}} + \hat{\mathbf{H}}^T \Delta \mathbf{H} + \Delta \mathbf{H}^T \hat{\mathbf{H}} + \Delta \mathbf{H}^T \Delta \mathbf{H} \right\} \hat{x}_k \right] \\ &= \prod \left[ \hat{x}_k - \delta_k \hat{\mathbf{H}}^T \mathbf{y} + \delta_k \hat{\mathbf{H}}^T \hat{\mathbf{H}} \hat{x}_k + \delta_k E_{\Delta H} \left\{ \Delta \mathbf{H}^T \Delta \mathbf{H} \right\} \hat{x}_k \right] \\ &= \prod \left[ \hat{x}_k - \delta_k \hat{\mathbf{H}}^T \mathbf{y} + \delta_k \hat{\mathbf{H}}^T \hat{\mathbf{H}} \hat{x}_k + \delta_k R_{\Delta H} \hat{x}_k \right] \end{aligned}$$

در نهایت خواهیم داشت:

$$\hat{x}_{k+1} = \prod \left[ \hat{x}_k - \delta_k \hat{\mathbf{H}}^T \mathbf{y} + \delta_k \hat{\mathbf{H}}^T \hat{\mathbf{H}} \hat{x}_k + \delta_k R_{\Delta H} \hat{x}_k \right] \quad (14)$$

که در آن ماتریس کوواریانس خطای تخمین کانال گیرنده بوده و به صورت زیر تعریف می شود:

$$\mathbf{R}_{\Delta H} = E \left\{ \Delta \mathbf{H}^H \Delta \mathbf{H} \right\} \quad (15)$$



شکل ۳۲: ساختار پرسپترون در شبکه یادگیری عمیق تماماً متصل

$$q_{k+1} = \rho(W_K q_k + b_k) \quad (6)$$

که در آن  $\rho$  تابع فعال سازی است. با توجه به رابطه (۶) و برای آشکارساز DetNet با  $L$  لایه، می توان نوشت:

$$\begin{aligned} q_k &= \hat{x}_{k-1} - \delta_k \mathbf{H}^T \mathbf{y} + \delta_k \mathbf{H}^T \mathbf{H} \hat{x}_{k-1} \\ z_k &= \rho(W_{1K} q_k + b_{1k}) \\ \hat{x}_{k+1} &= \psi_{tk}(W_{1K} z_k + b_{2k}) \\ \hat{v}_{k+1} &= W_{3K} z_k + b_{3k} \\ \hat{x}_1 &= 0 \\ \hat{v}_1 &= 0 \end{aligned} \quad (7)$$

که در آن  $v_k$  متغیر اضافی به منظور بهبود عملکرد شبکه عمیق و  $\psi_t(x)$  یک تابع فعال سازی خطی به صورت زیر است:

$$\psi_t(x) = -1 + \frac{\rho(x+t)}{|t|} - \frac{\rho(x-t)}{|t|} \quad (8)$$

تخمین نهایی به صورت  $\hat{x}_\theta(\mathbf{y}, \mathbf{H}) = \text{sign}(\hat{x}_L)$  تعریف می شود. با توجه به رابطه (۷)، ساختار یک لایه از شبکه آشکارسازی عمیق را می توان مطابق شکل ۳ ترسیم کرد. بر اساس رابطه (۷)، پارامترهای DetNet که در طول فاز یادگیری بهینه می شوند عبارتند از:

$$\theta = \{W_{1k}, B_{1k}, W_{2k}, B_{2k}, W_{3k}, B_{3k}, t_k\}_{k=1}^L \quad (9)$$

### ۳- بررسی تأثیر خطای تخمین کانال


در عمل ماتریس  $\mathbf{H}$  با استفاده از سیگنال های پایلوت در گیرنده تخمین زده می شود و این تخمین با خطا همراه خواهد بود. تخمین کانال با  $\hat{\mathbf{H}}$  نمایش داده شده و می توان آن را به صورت مجموع ماتریس کانال بدون خطا و ماتریس خطای تخمین به صورت زیر در نظر گرفت.

$$\mathbf{H} = \hat{\mathbf{H}} + \Delta \mathbf{H} \quad (10)$$

که در آن  $\Delta \mathbf{H}$  خطای تخمین است که با  $\mathbf{H}$  ناهمبسته است. در [۵] و [۶] نشان داده شده است که  $\Delta \mathbf{H}$  مستقل و با توزیع یکسان (iid) است که دارای توزیع مختلط گوسی با میانگین صفر است. ضریب همبستگی بین کانال واقعی و نمونه تخمین زده آن به صورت زیر قابل محاسبه است.

$$\rho = \frac{E[h_{ij} \hat{h}_{ij}^*]}{\sqrt{E[|h_{ij}|^2] E[|\hat{h}_{ij}^*|^2]}} = \frac{1}{\sqrt{1+e^2}} \quad (11)$$

که در آن  $h_{ij}$  و  $\hat{h}_{ij}^*$  به ترتیب عناصر  $(i, j)$  ماتریس های  $\mathbf{H}$  و  $\hat{\mathbf{H}}$  و  $e$  واریانس خطای تخمین است. در صورت تعریف میانگین مربعات



شکل ۴: نمودار ضرر شبکه عمیق به ازای داده‌های آموزش و ارزیابی

مطابق آن با حدود ۳۰ epoch، تغییر در روند افت هزینه و یا افزایش دقت مدل رخ نمی‌دهد. به‌منظور کنترل بیش‌برازش در این مدل از روش تعمیم به کمک K-Fold cross validation استفاده شده است (k=10).

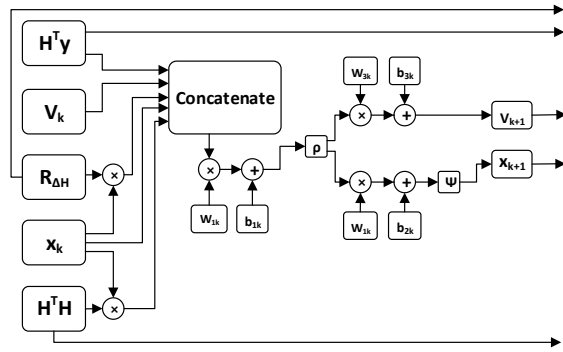
در فرآیند آموزش و تست، ماتریس H به‌صورت تصادفی با عناصر i.i.d از توزیع  $N(0,1)$  تولید می‌شود. هر نمونه به‌صورت مستقل در یک آزمایش مشابه تولید می‌شود. ماتریس خطای کانال نیز تصادفی با توزیع مختلط گوسی در نظر گرفته شده که مستقل از ماتریس تخمین کانال بوده و به‌صورت زیر است:

$$\begin{aligned} \mathbf{H} &\sim CN(0, \mathbf{I}) \\ \hat{\mathbf{H}} &\sim (1 - \rho^2) CN(0, \mathbf{I}) \\ \Delta \mathbf{H} &\sim \rho CN(0, \mathbf{I}) \end{aligned} \quad (17)$$

#### ۴-۱- مقایسه با DetNET

به‌منظور بررسی عملکرد ساختار پیشنهادی، مقایسه با روش مر سوم DetNET، در این زیر بخش مورد توجه قرار گرفته است. در شکل ۷، منحنی‌های نرخ خطای بیت حاصل از شبیه‌سازی در برابر نسبت سیگنال به نویز دریافتی، با فرض  $\rho = 0.1$ ، تعداد ۴ آنتن فرستنده و ۴ آنتن گیرنده و مدولاسیون BPSK برای شبکه آشکارساز عمیق، با و بدون لحاظ کردن مقاوم‌سازی نشان داده شده است.

منحنی‌های حاصل از شبیه‌سازی‌ها نشان می‌دهند که در صورت خطا در تخمین کانال، عملکرد آشکارساز عمیق DetNet به نحو قابل‌ملاحظه‌ای کاهش می‌یابد. مشاهده می‌شود که این کاهش عملکرد به‌ویژه در زمانی که خطای تخمین کانال افزایش می‌یابد، قابل‌توجه است ( $\rho = 0.1$ ). منحنی‌ها نشان می‌دهند که وقتی از روش پیشنهادی مقاوم برای آشکارسازی استفاده می‌شود، تفاوت عملکرد آشکارسازی با حالتی که اطلاعات ماتریس کانال بدون خطا در گیرنده موجود است، در سیگنال به نویزهای بالا چیزی در حدود 2dB است. بر این اساس و مطابق شبیه‌سازی‌ها به‌وضوح مشاهده می‌شود که روش مقاوم پیشنهادی، نسبت به روش DetNet بهبود قابل‌ملاحظه‌ای در آشکارسازی حاصل کرده است.



شکل ۵: نمودار دقت شبکه عمیق به ازای داده‌های آموزش و ارزیابی


نتایج به‌دست‌آمده در رابطه (۱۱)، نشان می‌دهد کوواریانس خطای تخمین می‌تواند به‌عنوان یک ورودی در ساختار شبکه DetNET برای افزایش مقاومت در برابر خطای تخمین بکار برده شود. لذا رابطه (۷) را می‌توان به‌صورت زیر بازنویسی کرد:

$$\begin{aligned} q'_k &= \hat{\mathbf{x}}_{k-1} - \delta_k \mathbf{H}^T \mathbf{y} + \delta_k \mathbf{H}^T \mathbf{H} \hat{\mathbf{x}}_{k-1} + \delta_k R_{\Delta H} \mathbf{x} \\ z'_k &= \rho (W_{1K} q'_k + b_{1k}) \\ \hat{\mathbf{x}}_{k+1} &= \psi_{tk} (W_{1K} z'_k + b_{2k}) \\ \hat{\mathbf{v}}_{k+1} &= W_{3K} z'_k + b_{3k} \\ \hat{\mathbf{x}}_1 &= 0 \\ \hat{\mathbf{v}}_1 &= 0 \end{aligned} \quad (16)$$


با توجه به رابطه (۱۲)، ساختار شبکه یادگیری عمیق DetNet را می‌توان به‌صورت شکل ۴ اصلاح کرد.

#### ۴- شبیه‌سازی

در این بخش، عملکرد آشکارساز پیشنهادی را با استفاده از شبیه‌سازی رایانه‌ای نشان می‌دهیم. تمامی شبیه‌سازی‌های توسط یک رایانه مشابه و مبتنی بر فریم‌ورک Tensorflow 2.4 انجام شده است. در مدل پیاده‌سازی شده، نرخ یادگیری برابر ۰.۰۱ و از بهینه‌ساز متداول ADAM بهره گرفته شده است. همگرایی در شبکه عمیق پیشنهاد شده زمانی اتفاق می‌افتد که تابع هزینه به کمینه خود نزدیک شده باشد و در واقع با افزایش تکرار در توالی آموزش مدل، پیشرفتی در دقت مدل حاصل نشود. این مهم در شکل‌های ۵ و ۶ نشان داده شده است که



شکل ۵: نمودار دقت شبکه عمیق به ازای داده‌های آموزش و ارزیابی



شکل ۹: منحنی‌های نرخ خطای بیت جهت مقایسه با آشکارسازهای ZF [۵] و MMSE [۶]


آنتن فرستنده ۲، تعداد آنتن گیرنده ۲ و مدولاسیون QPSK فرض شده است. مطابق شکل ۹، مشاهده می‌شود که آشکارسازهای ZF و MMSE علی‌رغم دقت پایین‌تر آشکارسازی نسبت به آشکارسازهای بهینه مانند ML، افت عملکرد قابل توجهی در برابر خطای تخمین کانال دارند. اما آشکارساز پیشنهادی مقاوم مبتنی بر شبکه عمیق، عملکرد بهتری نسبت به دو آشکارساز ZF و MMSE در حضور خطای تخمین دارد؛ ضمن اینکه عملکرد کلی آن در صورت وجود دانش کامل نسبت به CSI، از این دو آشکارساز بهتر است.

### ۵- نتیجه

در هنگامی که اطلاعات کانال در بخش گیرنده یک سیستم مخابراتی MIMO به علت عدم دقت در اندازه‌گیری، خطای کوانتیزاسیون و غیره، همراه با خطا باشد، عملکرد روش‌های آشکارسازی معمول و از جمله آشکارسازی عمیق DetNet، کاهش قابل ملاحظه‌ای خواهد داشت. در این مقاله روشی برای مقاوم‌سازی آشکارساز DetNet در هنگامی که اطلاعات کانال در گیرنده همراه با خطا باشد، برای بهبود آشکارسازی ارائه گردید. روش پیشنهادی با شبیه‌سازی مورد بررسی قرار گرفت و کارایی آن نسبت به آشکارسازی‌های معمول و DetNet در حالتی که ماتریس کانال به صورت تقریبی در اختیار است، نشان داده شد. نتایج شبیه‌سازی مبین کارایی روش پیشنهادی در سیستم‌های MIMO است.

### مراجع

- [1] I. E. ATAR, "Capacity of multi-antenna gaussian channels," *European Transactions on Telecommunications*, vol. 10, pp. 585-595, 1999.
- [2] A. J. PAULRAJ, D. A. GORE, R. U. NABAR, and H. BOLCSKEI, "An overview of MIMO communications - a key to gigabit wireless," *Proceedings of the IEEE*, vol. 92, no. 2, pp. 198-218, Feb. 2004.
- [3] D. Gesbert, M. Shafi, Da-shan Shiu, P. J. Smith, and A. Naguib, "From theory to practice: an overview of MIMO space-time




شکل ۷: منحنی‌های نرخ خطای بیت جهت مقایسه با راهکار DetNet

### ۴-۲- بررسی اثر ابعاد شبکه MIMO

باهداف بررسی اثر تغییر تعداد آنتن‌های گیرنده و فرستنده در ساختار شبکه MIMO، در این زیربخش، عملکرد راه‌کار پیشنهادی در مقایسه با روش DetNet، با فرض  $\rho = 0.1$ ، تعداد ۸ آنتن فرستنده و ۸ آنتن گیرنده و مدولاسیون BPSK برای شبکه آشکارساز عمیق، با و بدون لحاظ کردن مقاوم‌سازی مورد ارزیابی قرار گرفته است. مطابق شکل ۸، مشاهده می‌شود که با افزایش ابعاد شبکه MIMO، حساسیت آشکارساز DetNet نسبت به خطای تخمین کانال افزایش یافته و دقت آشکارسازی به صورت قابل توجهی افت پیدا می‌کند. مشاهده می‌شود که عملکرد آشکارساز مقاوم تا حدود 4dB بهتر از آشکارساز DetNet است.

### ۴-۳- مقایسه با سایر روش‌های آشکارسازی

با توجه به اینکه آشکارساز عمیق پیشنهادی بر اساس آشکارساز DetNet پایه‌ریزی شده است، در زیربخش‌های قبل، عملکرد آن با این روش مورد ارزیابی قرار گرفت. به منظور درک بهتر از عملکرد راه‌کار پیشنهادی، در این قسمت مطالعه عملکرد آن در مقایسه با آشکارسازهای دیگر در شرایط حضور خطای تخمین مورد توجه قرار گرفته است. در این شبیه‌سازی مقدار  $\rho \in \{0.05, 0.1, 0.2\}$ ، تعداد



شکل ۸: منحنی‌های نرخ خطای بیت جهت بررسی تغییر ابعاد شبکه MIMO

- Topics in Signal Processing*, vol. 12, no. 1, pp. 144–159, Feb. 2018.
- [13] T. Wang, L. Zhang, and S. C. Liew, “Deep Learning for Joint MIMO Detection and Channel Decoding,” in *2019 IEEE 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pp. 1–7, Sep. 2019.
- [14] H. He, C.-K. Wen, S. Jin, and G. Y. Li, “A Model-Driven Deep Learning Network for MIMO Detection,” in *2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, pp. 584–588, Nov. 2018.
- [15] N. Samuel, T. Diskin and A. Wiesel, “Deep MIMO detection,” *2017 IEEE 18th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*, pp. 1-5, 2017.
- [16] M. Biguesh and A. B. Gershman, “Training-based MIMO channel estimation: a study of estimator tradeoffs and optimal training signals,” *IEEE Transactions on Signal Processing*, vol. 54, no. 3, pp. 884–893, Mar. 2006.
- [17] S. Shahbazpanahi, A. B. Gershman, and J. H. Manton, “Closed-form blind MIMO channel estimation for orthogonal space-time block codes,” *IEEE Transactions on Signal Processing*, vol. 53, no. 12, pp. 4506–4517, Dec. 2005.
- [18] H. Artés, D. Seethaler, and F. Hlawatsch, “Efficient detection algorithms for MIMO channels: A geometrical approach to approximate ML detection,” *Signal Processing, IEEE Transactions on*, vol. 51, pp. 2808–2820, Dec. 2003.
- [19] K. J. Kim and J. Yue, “Joint channel estimation and data detection algorithms for MIMO-OFDM systems,” in *Conference Record of the Thirty-Sixth Asilomar Conference on Signals, Systems and Computers.*, vol. 2, pp. 1857–1861, Nov. 2002.,
- [20] J. Wang and D. P. Palomar, “Robust MMSE Precoding in MIMO Channels With Pre-Fixed Receivers,” *IEEE Transactions on Signal Processing*, vol. 58, no. 11, pp. 5802–5818, Nov. 2010.
- [21] D. Guo and X. Wang, “Blind detection in MIMO systems via sequential Monte Carlo,” *IEEE Journal on Selected Areas in Communications*, vol. 21, no. 3, pp. 464–473, Apr. 2003.
- coded wireless systems,” *IEEE Journal on Selected Areas in Communications*, vol. 21, no. 3, pp. 281–302, Apr. 2003.
- [4] S. Yang and L. Hanzo, “Fifty Years of MIMO Detection: The Road to Large-Scale MIMOs,” *IEEE Communications Surveys Tutorials*, vol. 17, no. 4, pp. 1941–1988, Fourthquarter 2015.
- [5] C. Wang, E. K. S. Au, R. D. Murch, W. H. Mow, R. S. Cheng, and V. Lau, “On the Performance of the MIMO Zero-Forcing Receiver in the Presence of Channel Estimation Error,” *IEEE Transactions on Wireless Communications*, vol. 6, no. 3, pp. 805–810, Mar. 2007.
- [6] E. Eraslan, B. Daneshrad, and C. Lou, “Performance Indicator for MIMO MMSE Receivers in the Presence of Channel Estimation Error,” *IEEE Wireless Communications Letters*, vol. 2, no. 2, pp. 211–214, Apr. 2013.
- [7] Xu Zhu and R. D. Murch, “Performance analysis of maximum likelihood detection in a MIMO antenna system,” *IEEE Transactions on Communications*, vol. 50, no. 2, pp. 187–191, Feb. 2002.
- [8] J. Kim, S. Moon, and I. Lee, “A new reduced complexity ML detection scheme for MIMO systems,” *IEEE Transactions on Communications*, vol. 58, no. 4, pp. 1302–1310, Apr. 2010.
- [9] A. A. Farhoodi and M. Fazelifar, “Sphere Detection in MIMO Communication Systems with Imperfect Channel State Information,” in *6th Annual Communication Networks and Services Research Conference (cnsr 2008)*, pp. 228–233, May 2008.
- [10] X. Zhu and R. D. Murch, “MIMO-DFE based BLAST over frequency selective channels,” in *GLOBECOM’01. IEEE Global Telecommunications Conference (Cat. No.01CH37270)*, vol. 1, pp. 499–503, Nov. 2001.
- [11] C. Jeon, R. Ghods, A. Maleki, and C. Studer, “Optimality of large MIMO detection via approximate message passing,” in *2015 IEEE International Symposium on Information Theory (ISIT)*, pp. 1227–1231, Jun. 2015.,
- [12] F. Liang, C. Shen, and F. Wu, “An Iterative BP-CNN Architecture for Channel Decoding,” *IEEE Journal of Selected*