

## تخمین کanal و آشکارسازی سیگنال در سیستم‌های

### مبتنی بر OFDM با رویکرد یادگیری ماشین

فاطمه صباحی بیدگلی<sup>۱</sup>، امیر مسعود ربیعی<sup>۲\*</sup>

\*نویسنده مسئول، دریافت: ۰۰/۰۰/۰۰، بازنگری: ۰۰/۰۰/۰۰، پذیرش: ۰۰/۰۰/۰۰ (تاریخ‌ها توسط نشریه وارد می‌شوند)

<sup>۱</sup> دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران، تهران، ایران

<sup>۲</sup> استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران، تهران، ایران

#### چکیده

در سال‌های اخیر، با گسترش روزافزون شبکه‌های مخابرات داده میزان تقاضا برای استفاده از طیف فرکانسی بی‌سیم نیز افزایش یافته است. با توجه به محدودیت طیف فرکانسی، پاسخ‌گویی به این حجم از تقاضا، نیازمند افزایش بهره‌وری طیفی است. یکی از روش‌های بهبود بهره‌وری فناوری OFDM<sup>۱</sup> برای رسیدن به طرفیت بیشتر و بالا بردن نرخ ارسال و دریافت داده است. چالش اساسی در کانال‌های بی‌سیم، ماهیت فرکانس‌گزینی<sup>۲</sup> و تغییرپذیری این کانال‌ها با زمان است. این مسئله غالباً باعث می‌شود که تخمین کانال، فرآیندی پیچیده و همراه با خطا باشد که خود منجر به افزایش احتمال خطأ در آشکارسازی داده‌ها می‌شود. در نتیجه، تخمین کارآمد ضرایب کانال در سیستم‌های مخابرات بی‌سیم، همواره مورد توجه پژوهش‌گران این حوزه بوده است. در این مقاله، نخست تعدادی از روش‌های شناخته شده‌ی تخمین کانال‌های بی‌سیم را معرفی می‌کنیم. سپس با بیان برخی مشکلات این روش‌ها، روش‌های جدیدی را برای تخمین کانال مورد بررسی قرار می‌دهیم که بر مبنای یادگیری ماشین<sup>۳</sup> کار می‌کنند. در ادامه روش پیشنهادی خود را ارائه می‌دهیم که این روش می‌تواند چند نمونه از نقص‌های روش‌های روشی را برطرف کند، در پایان روش پیشنهادی را با برخی از روش‌های موجود در ادبیات مسئله، میزان پیچیدگی الگوریتم و نرخ خطای بیت آشکارسازی سابلیل‌ها مقایسه نموده و کارایی آن‌ها در سناریوهای مختلف بررسی می‌کنیم.

کلمات کلیدی: OFDM، تخمین کانال، یادگیری ماشین

- روش‌های مبتنی بر ارسال رشته داده‌ی آموزشی<sup>۵</sup>
- روش‌های کور<sup>۶</sup>
- روش‌های نیمه کور

#### ۱ - مقدمه

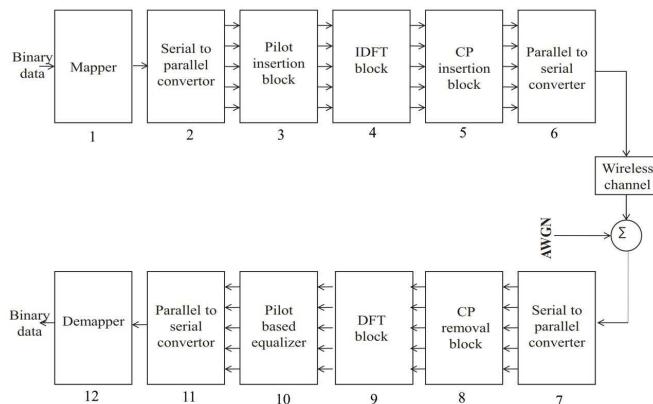
بدیهی است استفاده از این روش‌ها ممکن است باعث کاهش کارایی طیفی (در روش‌های مبتنی بر ارسال داده‌های آموزشی) یا افزایش پیچیدگی محاسباتی (در روش‌های کور یا نیمه کور) شود. لذا می‌توان به جای به کارگیری این روش‌ها برای تخمین کانال، از روش‌های مبتنی بر یادگیری ماشین برای تخمین ضرایب کانال و نیز آشکارسازی داده استفاده کرد. در این مقاله، ما در راستای بهبود عملکرد سیستم‌های OFDM برای آشکارسازی داده‌ها، از روش‌های مبتنی بر یادگیری ماشین در کنار روش‌های مرسوم استفاده می‌کنیم.

طی چند دهه‌ی اخیر، نسل‌های جدید سیستم‌های مخابرات بی‌سیم یکی پس از دیگری در حال معرفی و بهره‌برداری اند اما این سیستم‌ها همچنان با چالش‌ها و مشکلات گوناگونی مانند پایین بودن بهره‌وری طیفی<sup>۴</sup> روبرو هستند. به منظور بهبود بهره‌وری طیفی و بالا بردن نرخ ارسال و دریافت داده‌ها در سیستم‌های مخابرات بی‌سیم، از فناوری OFDM استفاده می‌شود. مسئله‌ی تخمین کانال در این فناوری از اهمیت بسیار بالایی برخوردار بوده و به همین دلیل همواره مورد توجه پژوهشگران بوده است. در یک تقسیم‌بندی کلی، روش‌های تخمین کانال به سه دسته تقسیم می‌شوند که عبارتند از:

روش پیشنهادی با روش های موجود از لحاظ نرخ خطای آشکارسازی سمبل ها را ارائه می کنیم. در پایان، به بیان کاستی های این روش ها پرداخته و پیشنهادهای برای کارهای آینده ارائه خواهیم داد.

## ۲- مدل سیستم

همانطور که در بخش قبل مطرح شد هدف از این مقاله، ارائه روشی برای آشکارسازی سیگنال به کمک ابزار یادگیری ماشین است. در این بخش ابتدا به بررسی روابط مربوط به نحوه ارسال اطلاعات در فرستنده و همچنین آشکارسازی سمبل های داده با توجه به روابط تخمین کاتال در گیرنده می پردازیم. سپس به کمک تخمین کاتال به وسیله یکی از روش های ذکر شده، از یادگیری ماشین برای آشکارسازی سمبل های ارسالی استفاده می کنیم.



شکل ۱: یک سیستم OFDM باند پایه [۹]

در شکل ۱، یک سیستم OFDM به صورت بلوکی از فرستنده تا گیرنده نمایش داده شده است [۸]. داده های فرستنده با استفاده از OFDM مدوله شده و وارد کاتال می شوند. داده ها به صورت سری وارد سیستم می شوند و مدولاسیون روی آنها انجام می گیرد. سپس توسط بلوك  $S/P$ <sup>۱۸</sup> به داده های موازی تبدیل می شوند. سیگنال پایلوت به همراه سیگنال های اصلی وارد بلوك  $IDFT$ <sup>۱۹</sup> می شود. در ادامه در بلوك  $CP$ <sup>۲۰</sup> که هدف آن حذف تاثیر ISI<sup>۲۱</sup> است، با توجه به طول فریم تعدادی از بیت های داده از انتهای فریم به ابتدای آن اضافه می شود. در نهایت داده ها به داده های سری تبدیل و سیگنال حاصل وارد کاتال می شود. سیگنال ارسالی پس از گذر از کاتال و اضافه شدن نویز در گیرنده دریافت می شود. گیرنده همه می این عملیات را به صورت بر عکس روی سیگنال دریافتی انجام می دهد تا امکان آشکارسازی داده ها فراهم شود.

خروجی بلوك ۱ برای پایلوت ها، برابر رشتہ ای از سمبل های ورودی است که در زمان های مختلف وارد سیستم می شوند. بعد از اعمال مدولاسیون روی داده های ورودی، آنها به صورت سمبل هایی موازی وارد بلوك بعدی می شوند. در بلوك ۳، در واقع نحوه قرار گیری سمبل های پایلوت در بلوك OFDM در کاتار سمبل های داده مشخص می شود که این مورد در ادامه توضیح داده می شود. در این بلوك، برای هر زیر حامل توان ارسالی را برابر  $P_k$  تنظیم می کنیم که  $P_k$  به معنای توان سمبل ارسالی در زیر حامل  $k$  است. این سمبل ها وارد بلوك ۴ می شوند و تبدیل IDFT روی آنها اعمال می گردد.  $[n]X[n]$  ها به عنوان ورودی وارد بلوك ۵ شده و با توجه با طول CP تعیین شده، CP به آنها اضافه می شود.  $[n]X_{cp}[n]$  خروجی بلوك ۵ در نظر گرفته می شود.  $[n]X_{cp}$  وارد بلوك ۶ شده و تمامی سمبل ها به فرم سری تبدیل

همان طور که بیان شد، مدولاسیون OFDM یک طرح مدولاسیون محبوب و پرطرفدار است که به طور گسترده در سیستم های بی سیم بهن باند،<sup>۷</sup> برای مقابله با اثر محوش دگی فرکانس گزین کاتال استفاده شده است [۱]. این مدولاسیون، عملیات مالتی پلکسینگ<sup>۸</sup> را با استفاده از تقسیم فرکانس، به صورت متعدد،<sup>۹</sup> اجرا می کند.

یکی از حیاتی ترین مسائل در سیستم های OFDM، در اختیار داشتن اطلاعات کاتال برای آشکارسازی داده ها است. به این منظور، معمولاً اطلاعات حالت کاتال قبل از آشکارسازی داده های ارسالی با استفاده از تعدادی پایلوت<sup>۱۰</sup> تخمین زده می شود تا در فرآیند آشکارسازی مورد استفاده قرار گیرد.

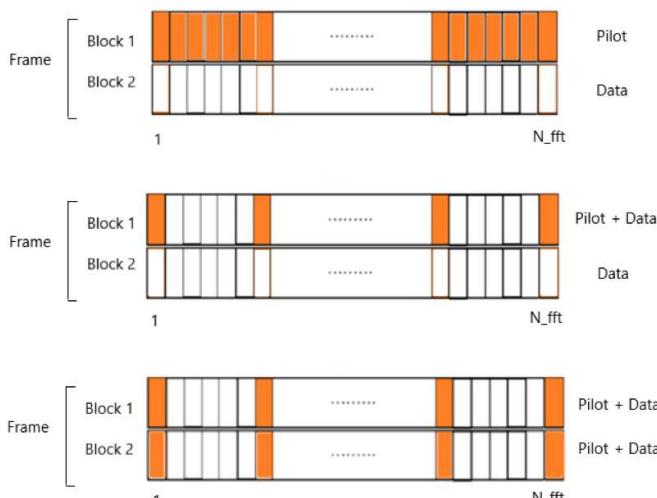
تاکنون پژوهش های فراوانی با هدف کاهش نرخ خطأ در هنگام آشکارسازی سمبل های ارسالی در یک سیستم OFDM انجام شده است. در گذشته برای تخمین کاتال از روش های تخمین کلاسیک استفاده می شد. دو روش تخمین کلاسیک<sup>۱۱</sup> حداقل مربعات (LS) و حداقل میانگین مربع خطأ (MMSE)<sup>۱۲</sup> به صورت گسترده و در شرایط مختلف مورد استفاده قرار گرفته و بهینه سازی شده اند [۲]. روش تخمین LS نیازی به آمار گان کاتال قبلی ندارد، اما عملکرد آن ممکن است چندان مناسب نباشد. تخمین MMSE به طور کلی با استفاده از آمار گان مرتبه دوم کاتال ها کار می کند و منجر به عملکرد بهتری در آشکارسازی می شود.

در حوزه مخابرات بی سیم، مکانیسم های هوشمند، به ویژه شبکه های عصبی مصنوعی، قبلاً استفاده شده اند. مثلاً برای دیکدینگ کاتال در [۳]، مدیریت ترافیک داده و یافتن مکان کاربر [۴]، تخمین کاتال و آشکارسازی [۵]، استفاده شده اند. در [۵]، نویسنده ای تخمین کاتال و آشکارسازی سمبل را برای سیستم های مبتنی بر OFDM با کاتال های فرکانس گزین پیشنهاد کرده اند. نشان داده شده است که الگوریتم پیشنهادی عملکرد بهتری از تخمین گر MMSE معمولی دارد. در [۶]، نویسنده ایک برآوردگر مبتنی بر DL<sup>۱۳</sup> با پیشخور<sup>۱۴</sup> آنلاین برای کاتال های فرکانس گزین پیشنهاد کرده اند. الگوریتم پیشنهادی در کلیدی سیاریوهای بررسی شده، عملکرد بهتری از برآوردگر خطی MMSE دارد. در مرجع [۷]، یک مدل 1D-CNN<sup>۱۵</sup> مبتنی بر DL برای تخمین کاتال و بازیابی داده های همسان شده پیشنهاد شده و عملکرد 1D-CNN با برآوردگرهای LS، MMSE و FFNN<sup>۱۶</sup> از نظر BER و MSE برای تکنیک های مدولاسیون مختلف مقایسه شده است. نشان داده شده است که 1D-CNN از هر دو برآوردگر کلاسیک LS و MMSE و نیز از برآوردگر FFNN بهتر عمل می کند.

یادگیری ماشین، مطالعه ای علمی الگوریتم ها و مدل های آماری مورد استفاده های سیستم های کامپیوتی است که به جای استفاده از دستور العمل های واضح از هوش مصنوعی، الگوریتم های یادگیری ماشین یک مدل ریاضی بر اساس «داده های نمونه» یا «داده های آموزش» به منظور پیش بینی یا تضمیم گیری بدون برنامه ریزی آشکار، ایجاد می کنند. هدف از یادگیری ماشین این است که رایانه ها و سامانه ها بتوانند به تدریج و با افزایش داده ها کارایی بهتری در انجام وظیفه هی محوله پیدا کند. گستره ای این وظیفه می تواند از تشخیص خود کار چهره با دیدن چند نمونه از چهره هی مورد نظر، تا فرآگیری شیوه های گام برداری روبات های دوپا با دریافت سیگنال پاداش و تنبیه باشد. طیف پژوهش هایی که در یادگیری ماشین انجام می شود گسترده است. یادگیری ماشین کمک فراوانی به صرف جویی در هزینه های عملیاتی و بهبود سرعت عمل تجزیه و تحلیل داده ها می کند.

ادامه ای این مقال به صورت زیر سازمان دهی شده است. در بخش ۲ یکی از روش های مرسوم برای تخمین کاتال معرفی خواهد شد تا به کمک آن بتوان پاسخ فرکانسی کاتال را تخمین زدو در ادامه بخشن. به بررسی این روش از لحاظ نرخ خطای بیت و آشکارسازی سمبل ها می پردازیم. در بخش ۳ روش جدیدی برای تخمین کاتال پیشنهاد می شود و در ادامه مقایسه ای از نظر پیچیدگی بین این روش ارائه شده و روش مرجع [۸] انجام می دهیم. در بخش ۴ نتایج شبیه سازی ها و مقایسه ای

یکی از چالش‌های اصلی در سیستم‌های مخابراتی مبتنی بر OFDM، مسئلهٔ تخمین کانال است. بدون داشتن تخمین مناسبی از کانال انتقال، آشکارسازی دقیق سمبول‌های ارسالی امکن نیست. روش‌های متعددی در گذشته برای تخمین کانال در این سیستم‌ها معرفی شده‌اند که در آن‌ها غالباً با



شکل ۲: نحوهٔ قرارگیری پایلوت‌ها و داده‌های اصلی در کنار هم الف، ب، ج

در شکل ۲ نحوهٔ قرارگیری پایلوت‌ها و داده‌های اصلی در کنار هم نشان داده شده است. دو بلوک OFDM در کنار هم قرار می‌گیرند. در شکل (۲ - الف) بلوک اول کاملاً پایلوت و بلوک دوم کاملاً دیتا ارسال شده است. در شکل (۲ - ب) بلوک اول دیتا و پایلوت در کنار هم و در بلوک بعدی کاملاً دیتا ارسال می‌شود. در شکل (۲ - ج) در هر دو بلوک اول و دوم مجموعه‌ای از پایلوت و دیتا باهم ارسال شده اند.

برای تخمین پاسخ فرکانسی با توجه به رابطهٔ (۶)، ماتریس کانال را برای زیرحاممل‌های پایلوت به دست می‌آوریم، این ماتریس یک ماتریس با ابعاد  $N \times 2 \times N_p$  (تعداد پایلوت‌ها  $\times$  نصف تعداد تایم اسلات زمانی) است که از آن برای آشکارسازی بیت‌های پایلوت استفاده می‌کنیم. بعد از تخمین زدن ماتریس کانال برای زیرحاممل‌های پایلوت، ماتریس کانال را برای زیرحاممل‌های داده‌های اصلی، با استفاده از رابطهٔ درون‌یابی (۷) به دست می‌آوریم. در ادامه، تخمین کانال را برای حالت گفته شده در بالا بدست آورده و آشکارسازی داده‌ها را از طریق آن‌ها انجام می‌دهیم. یادگیری و آموزش ما در این کار، بر اساس الگوی یادگیری معرفی شده در مرجع [۸] و [۱۰] است.

یک مدل ساده‌ی شبکه‌ی عصبی یک LP1 است که دارای یک لایه‌ی میانی پنهان است. طول این لایه به تعداد نورون‌ها (سلول عصبی<sup>۴</sup>) در نظر گرفته شده است. در خروجی آن لایه نیز یکتابع قرار دارد و همه‌ی مقادیر از آن تابع عبور می‌کنند.

### ۳- روش پیشنهادی

در این بخش روش پیشنهادی برای تخمین کانال را معرفی می‌کنیم. به این منظور ابتدا صورت مسئله را به صورت کلی بیان می‌کنیم سپس ساختار مدل DNN مورد استفاده را توضیح داده و در ادامه مراحل یادگیری را بررسی و تحلیل می‌کنیم.

### ۳-۱- صورت مسئله

یکی از چالش‌های اصلی در سیستم‌های مخابراتی مبتنی بر OFDM، مسئلهٔ تخمین کانال است. بدون داشتن تخمین مناسبی از کانال انتقال، آشکارسازی دقیق سمبول‌های ارسالی امکن نیست. روش‌های متعددی در گذشته برای تخمین کانال در این سیستم‌ها معرفی شده‌اند که در آن‌ها غالباً با

می‌شوند.  $X_{cp}[\mathbf{n}]$  وارد کانال شده و سپس با نویز سفید نرمال  $\mathbf{w}[\mathbf{n}]$  جمع می‌شود. به این ترتیب سیگنال دریافتی در گیرنده به صورت زیر نمایش داده می‌شود:

$$\mathbf{R}[\mathbf{n}] = X_{cp}[\mathbf{n}] * \mathbf{h}[\mathbf{n}] + \mathbf{w}[\mathbf{n}] \quad (۱)$$

که در آن سیگنال  $\mathbf{R}[\mathbf{n}]$  همان سیگنال دریافتی در گیرنده است. در رابطهٔ (۱)، عملگر کانولوشن است که به علت وجود CP، برای  $N = 1, \dots, N$  با کانولوشن گردشی برابر می‌شود. یعنی:

$$\mathbf{Xh}[\mathbf{n}] = X_{cp}[\mathbf{n}] * \mathbf{h}[\mathbf{n}] = X_{cp}[\mathbf{n}] \otimes \mathbf{h}[\mathbf{n}] \quad (۲)$$

پس از گذر از کانال، سیگنال وارد گیرنده می‌شود. در گیرنده، اولین بلوک نقش تبدیل داده‌های سری به موازی را بر عهده دارد. بعد از این بلوک، بلوک حذف CP قرار دارد.

$$\hat{\mathbf{Y}}[\mathbf{n}] = \frac{1}{N} \sum_{n=0}^{N-1} \hat{\mathbf{X}}[\mathbf{k}] e^{-\frac{2jnkn}{N}} = \sqrt{P_k} \mathbf{Y}[\mathbf{k}] + \mathbf{W}[\mathbf{k}] \quad (۳)$$

$\hat{\mathbf{Y}}[\mathbf{k}]$ ها پایلوت‌های دریافتی در گیرنده در زیرحاممل‌هایی که در آن‌ها سمبول پایلوت فرستاده‌ایم هستند. همچنین DFT،  $\mathbf{W}[\mathbf{k}]$  نویز است:

$$\mathbf{W}[\mathbf{k}] = \frac{1}{N} \sum_{n=0}^{N-1} \mathbf{w}(\mathbf{n}) e^{-\frac{j2nkn}{N}} \quad (۴)$$

خروجی این بلوک، وارد بلوک ۱۰ می‌شود که در آن، از طریق سمبول‌های پایلوت، پاسخ فرکانسی کانال را تخمین می‌زنیم:

$$\hat{\mathbf{H}}_p = \frac{\hat{\mathbf{Y}}_p}{Y_p} \quad (۵)$$

$$\hat{\mathbf{H}}_p = \left[ \frac{\hat{Y}_p[1]}{\sqrt{P_1} Y_p[1]}, \frac{\hat{Y}_p[2]}{\sqrt{P_2} Y_p[2]}, \dots, \frac{\hat{Y}_p[N_p]}{\sqrt{P_1} Y_p[N_p]} \right] \quad (۶)$$

به همین طریق  $\sqrt{P_1} Y_p[1]$ ،  $\sqrt{P_2} Y_p[2]$ ، ... هم پایلوت‌های ارسال شده توسعهٔ فرستنده در زیرحاممل‌های مختلف هستند و  $\hat{\mathbf{H}}_p$  تخمین پاسخ فرکانسی کانال به روش LS است.  $\mathbf{n}_p$  نیز تعداد کل سمبول‌های پایلوت را بیان می‌کند.

بعد از بدست آوردن این پاسخ فرکانسی، از طریق درون‌یابی<sup>۲۲</sup> به تخمین پاسخ فرکانسی داده‌های اصلی می‌پردازیم:

$$\hat{\mathbf{H}}[\mathbf{k}] = \left( 1 - \frac{1}{\mathbf{n}_p} \right) * \hat{\mathbf{H}}_p[\mathbf{m}] + \frac{1}{\mathbf{n}_p} * \hat{\mathbf{H}}_p[\mathbf{m}+1] \quad \mathbf{0} \leq \mathbf{m} < \mathbf{n}_p \quad (۷)$$

در این رابطهٔ پاسخ فرکانسی کانال را برای زیرحاممل‌های داده‌ی اصلی که بین دو زیرحاممل پایلوت قرار دارند بدست می‌آوریم. برای زیرحاممل‌های شامل پایلوت شماره‌ی  $m$  و  $m+1$  است و  $L$  فاصله‌ی بین دو پایلوت است که در اینجا برابر بر اساس تعداد پایلوت‌ها متغیر خواهد شد. پس از بدست آوردن پاسخ فرکانسی کانال برای داده‌های اصلی، به آشکارسازی سمبول‌های دریافتی می‌پردازیم.

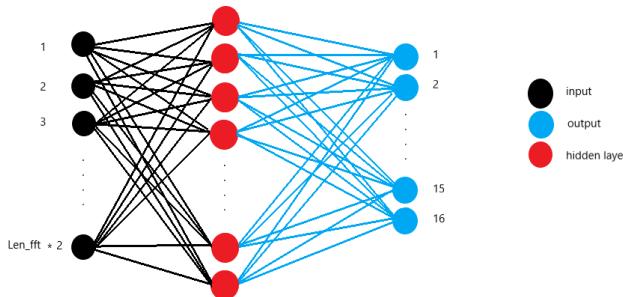
سمبول‌های خروجی بلوک ۱۰، وارد بلوک ۱۱ شده و به سمبول‌های سری تبدیل می‌شوند. سپس این سمبول‌ها وارد بلوک ۱۲ شده و در ابتدای بلوک، همه‌ی آن‌ها بر  $\sqrt{P_k}$  تقسیم می‌شوند تا اثر توان مورد نظر برای همه‌ی سمبول‌ها از بین برود. سپس دمدولاسیون روی آن‌ها اعمال می‌شود و بیت‌های آشکارسازی شده از آن بلوک خارج می‌شوند. ما این بیت‌ها را با بیت‌های ورودی اصلی مقایسه کرده و BER را بدست می‌آوریم.

سمبول‌های OFDM را به گونه‌ای فریم‌بندی می‌کنیم که در هر فریم، ۲ بلوک OFDM قرار داشته باشد. هر فریم را از کانال عبور می‌کند و پاسخ فرکانسی کانال برای دو بلوک OFDM موجود در یک فریم، یکسان است یعنی ماتریس کانال در این شبیه‌سازی که همان پاسخ فرکانسی کانال است یک ماتریس با ابعاد  $N * N$

برای قسمت آموزش مدل در حالت آفلاین هدف ما مینیمم کردن تابع هدف زیر است [۸]:

$$\text{Minimize } L = \frac{1}{N} \sum_K \left( \hat{\mathbf{X}}(\mathbf{K}) - \mathbf{X}(\mathbf{K}) \right)^2 \quad (8)$$

مدل DNN استفاده شده در مقاله [۵] دارای ۵ لایه است. این ۵ لایه شامل، ۳ لایه میانی و دو لایه برای ورودی و خروجی است. همچنین تابع غیرخطی استفاده شده در همه لایهها به جز لایه پایانی، همان تابع ReLU است و برای لایه پایانی از تابع سیگموید استفاده می شود. شبکه یادگیری که برای این کار پیشنهاد می کنیم به صورت نشان داده شده در شکل ۴ است.



شکل ۴: ساختار کلی شبکه یادگیری

همان طور که در شکل (۴) مشاهده می شود، کل سمبیل های دریافتی یک بلوک OFDM به عنوان ورودی شبکه در نظر گرفته می شوند (قسمت های حقیقی و موهومی جدا می شوند و هر دو ورودی پشت سر هم یک سمبول در نظر گرفته می شود). ما برای آشکارسازی کل سمبول های یک بلوک OFDM، تعدادی از این شبکه ها را استفاده می کنیم. تابع استفاده شده در لایه میانی تابع Relu و تابع استفاده شده در لایه آخر تابع خطی استفاده شده است. تابع بهینه سازی این شبکه بر اساس کوچکترین میانگین مربع خطأ (MMSE) است.

تفاوت مدل پیشنهادی با مدل مرجع [۸] علاوه بر الگوی شبکه یادگیری، این است که ورودی شبکه در مدل مرجع، همان سمبول های آشکارسازی هستند، اما در روش پیشنهادی ورودی شبکه همان سمبول های آشکارسازی شده اند. با این روش می توانیم کار شبکه را برای تخمین آسان تر کنیم. پس ابتدا در مرحله آفلاین، یک شبیه سازی با تعدادی پایلوت ثابت و الگوی یکسان انجام می دهیم. سپس به شبکه یادگیری خود را آموزش می دهیم. کanal را به کمک روش LS تخمین می زنیم، و سپس به کمک شبکه ی آموزش داده ها را آشکار سازی می کنیم. در ادامه، با همان الگوی ثابت، پایلوت ها را قرار می دهیم و از شبکه ی آموزش دیده شده، با توجه به ضرایب به دست آمده استاده می کنیم و در نهایت می توانیم نرخ خطای بیت آشکارسازی را با توجه به سمبول های آشکار شده از شبکه به دست بیاوریم.

#### ۴- نتایج شبیه سازی

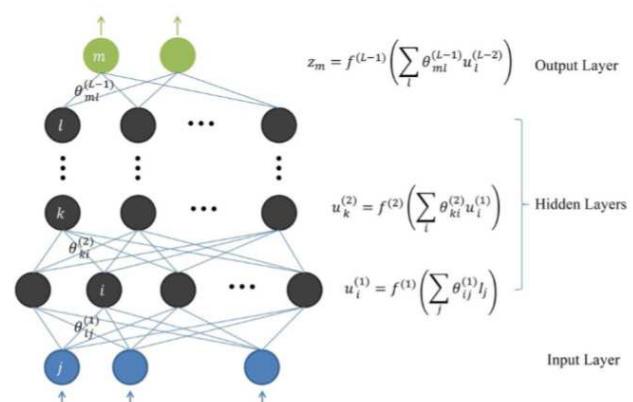
در بخش های قبلی یک روش معمولی برای تخمین کanal ارائه کردیم و بعد از آن رویکرد یادگیری ماشین را در تخمین کanal نشان دادیم. در بخش (۱-۳) روشی برای تخمین کanal و آشکارسازی سیگنال با استفاده از یادگیری ماشین ارائه شد که عملکرد آن روش را در این بخش خواهیم دید.

مبناهای کار این تحقیق، آشکارسازی سمبول های داده بوسیله الگوریتم های یادگیری ماشین است. برای مقایسه روش پیشنهادی خود با سایر روش ها، بعد از هر آزمایش نتایج نرخ خطای بیت به دست آمده را نشان می دهیم.

افزایش دقت تخمین میزان پیچیدگی نیز افزایش می باید. در این بخش روشی مبتنی بر یادگیری ماشین برای تخمین کanal معرفی می کنیم که از ابزار یادگیری ماشین استفاده می کند. هدف آن است که در عین رسیدن به دقت تخمین بالا و عملکرد مناسب، میزان پیچیدگی روش نیز قابل قبول باشد.

#### ۲-۳- ساختار یک مدل DNN<sup>۲۵</sup>

یک مدل DNN از لایه های مختلف تشکیل شده است. در این مدل یک لایه به عنوان لایه ورودی و یک لایه به عنوان لایه خروجی است. تعدادی لایه نیز به عنوان لایه های پنهان یا میانی داریم که باعث افزایش عملکرد و توانایی سیستم DNN می شوند.

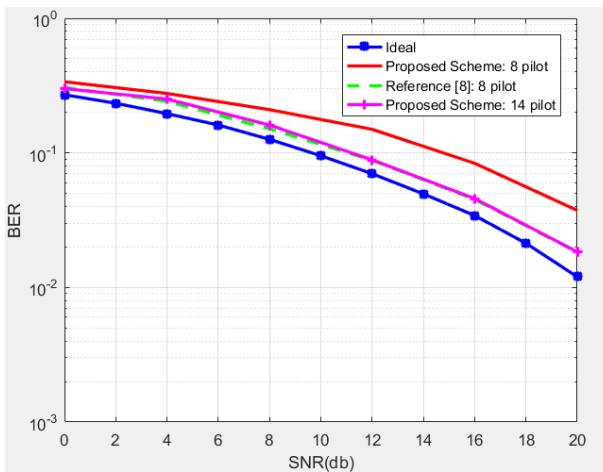


شکل ۳: مثالی از یک مدل یادگیری عمیق [۸]

تابع فعال ساز  $f$  همان تابع  $\sigma$  است که در شکل استفاده شده است. این تابع می تواند از مجموعه متنوعه از تابع های مختلف از جمله سافت مکس،  $\sigma$  سیگموید  $\sigma$  ReLU  $\sigma$  و با توجه به هدف و نوع یادگیری انتخاب شود.

#### ۳-۳- مراحل یادگیری

یادگیری به صورت آفلاین انجام می گیرد. در این مرحله ما با تعداد مشخص پایلوت ثابت و سمبول های داده متغیر و تصادفی، آموزش شبکه را انجام می دهیم. این پایلوت ها باید در هر دو مرحله آموزش و آزمایش ثابت باشند. این مدل ها با مشاهده مدولاسیون OFDM و کanal های بی سیم به عنوان جعبه های سیاه آموزش داده می شوند. در هر شبیه سازی، ابتدا تعدادی داده تصادفی به عنوان سمبول های ارسالی تولید می شود و بلوک OFDM مربوطه با دنباله ای از سمبول های پایلوت تشکیل می شود به طوری که سمبول های پایلوت در مراحل آموزش و استقرار ثابت باشند. کanal تصادفی بر اساس مدل های کanal شبیه سازی شده است. در اینجا از مدل کanal وینر II، به عنوان مدل کanal تصادفی استفاده می کنیم به طوری که کanal در طول زمان تغییرات زیادی نکرده باشد [۸]. سیگنال OFDM دریافت شده بر اساس فریم های تحت تاثیر کanal فعلی، از جمله نویز کanal بدست می آید. سیگنال دریافتی و داده های اصلی ارسال شده داده هایی که برای مرحله یادگیری به عنوان ورودی ارسال می شوند) به عنوان داده های آموزشی جمع آوری می شوند. در روش مرجع [۸]، ورودی مدل یادگیری شامل داده های دریافت شده از بلوک یادگیری (که شامل پایلوت و داده ای اصلی است) و یک بلوک دیتا نامشخص است. این مدل آموزش داده شده است تا تفاوت بین خروجی شبکه عصبی و داده های منتقل شده را به حداقل برساند. مرجع [۸]، برای اضافه کردن سمبول های پایلوت به داده، از روش شکل ۲-(الف) و ۲-(ب) استفاده کرده است.



شکل ۶: نمودار مقایسه‌ی نرخ خطای بیت در اثر تعداد پایلوت بیشتر

همان‌طور که در شکل ۶ دیده می‌شود، روش پیشنهادی با اضافه شدن تعداد کمی پایلوت (افزایش تعداد پایلوت از ۸ به ۱۴) می‌تواند نتایج‌های تقریباً مشابه با روش مرجع [۸] ارائه دهد. اما به علت اینکه روش مرجع [۸] از پیچیدگی زیادی برخوردار است و همچنین برای آموزش شبکه در مرحله‌ی آفلاین نیازمند تعداد نمونه‌های بیشتری نسبت به روش ارائه شده است می‌توان روش ارائه شده را روش مناسبی دانست.

#### ۴-۲- مقایسه‌ی پیچیدگی

دیدیم که با افزایش تعدادی پایلوت می‌توان در روش پیشنهادی به نرخ خطای بیت بهتری دست یافت. در این بخش می‌خواهیم تفاوت پیچیدگی دو روش مورد نظر را بررسی کنیم. جدول مقایسه‌ی پیچیدگی در زیر آورده شده است. این پیچیدگی نیز برای یک شبکه‌ی مجموعه‌ی یادگیری خواهد بود و ما در این روش  $L_p$  به شبکه‌ی نظیر این نیاز خواهیم داشت تا کل سمبول‌ها را آشکارسازی کند.  $L_p$  تعداد پایلوت‌ها در هر بلوک OFDM است. در این دو روش پارامترها به صورت زیر خواهند بود:

جدول ۱- پارامترهای شبیه‌سازی

روش پیشنهادی	روش [۸]	پارامترها
۱۲۸	۲۵۶	نورون‌های لایه اول
۶۴	۵۰۰	نورون‌های لایه دوم
-	۲۵۰	نورون‌های لایه سوم
-	۱۲۰	نورون‌های لایه چهارم
۱۶	۱۶	نورون‌های لایه پایانی
ReLU	ReLU	تابع لایه‌های میانی
خطی	سیگموید	تابع لایه پایانی

با توجه به مقادیر بالا و همچنین پیچیدگی‌های دو روش، اینگونه برداشت می‌شود که پیچیدگی روش مقاله از روش پیشنهادی بسیار بیشتر است پس می‌توان در نظر گرفت که با اضافه کردن مقداری پایلوت به یک فریم، تفاوت دو روش را جبران کرد و در عوض، هم میزان پیچیدگی کمتر است و هم تعداد نمونه‌هایی که برای آموزش شبکه در مرحله‌ی آفلاین اختصاص می‌دهیم کمتر است.

با توجه به مقادیر بالا و پیچیدگی‌های دو روش مورد مقایسه و نتایج حاصل از روش پیشنهادی اینگونه استنباط می‌گردد که از این بعد روش پیشنهادی نسبت به روش مرجع [۵] است.

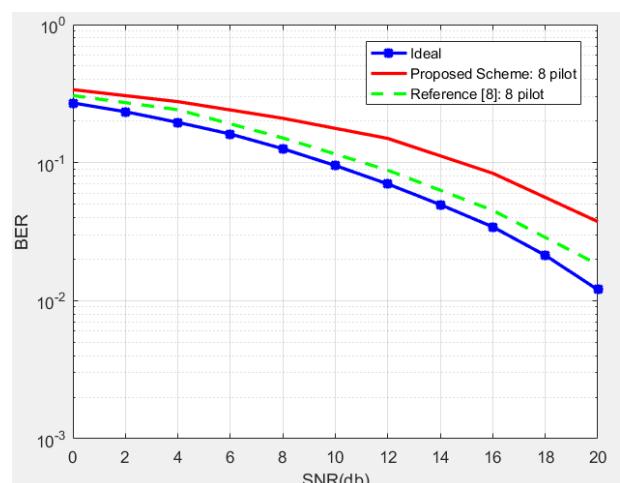
این الگوریتم پیشنهادی در چند سناریوی مختلف با الگوریتم مرجع [۸] مقایسه می‌شود: لازم به یادآوری است که تمامی مراحل آموزش آفلاین، در  $\text{SNR} = 40$  dB انجام می‌گیرد.

در این شبیه‌سازی، برای داده‌های اصلی از مدولاسیون 16QAM استفاده می‌شود. ما علاوه بر داده‌های اصلی برای تخمین کanal، یک سری داده به عنوان پایلوت همراه داده‌های اصلی ارسال می‌کنیم، مدولاسیون استفاده شده در پایلوت‌ها نیز مانند داده‌ها، 16QAM است.

پایلوت‌ها هم در زمان و هم در فرکانس می‌توانند با الگوهای مختلف قرار گیرند. شکل (۲) یک بلوک OFDM را که شامل زیرحمله‌ای مختلف است، نشان می‌دهد است (هر ستون در نمودار، نشان‌دهنده‌ی یک زیرحمله است). ابتدا سمبول‌های OFDM را فریم‌بندی می‌کنیم به‌گونه‌ای که در هر فریم، ۲ سمبول OFDM قرار داشته باشد. هر فریم را از کanal عبور می‌دهیم و فرض می‌کنیم کanal برای همه‌ی سمبول‌های موجود در یک فریم با هم برابر است. با توجه به این که  $N$  سمبول OFDM داریم پس تعداد  $N/2$  فریم داده به کanal ارسال خواهد شد که در طول همه‌ی آن فریم‌ها، کanal ثابت خواهد بود. پس ازینکه هر فریم از کanal عبور کرد به آن نویز گوسی سفید اضافه می‌شود و سپس سیگنال در گیرنده دریافت می‌شود.

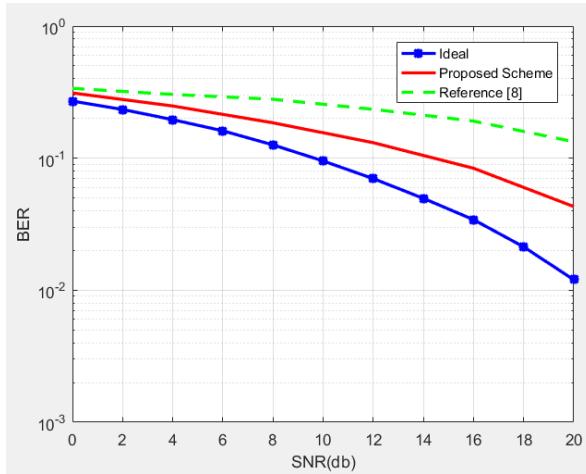
#### ۴- تأثیر تعداد پایلوت‌ها بر نرخ خطای بیت

در این بخش تأثیر تعداد پایلوت‌ها بر نرخ خطای بیت را بررسی می‌کنیم. همانطور که در فصل قبل عنوان کردیم، در مقاله‌ی مرجع [۸] نحوه‌ی ارسال پایلوت‌ها داده، به صورت شکل ۲-(ب) است. اما در الگوریتم پیشنهادی، الگوی ارسال پایلوت‌ها همراه داده به صورت شکل ۲-(ج) خواهد بود. در این قسمت می‌خواهیم اثر الگوریتم پیشنهادی را در رابطه با کم شدن تعداد پایلوت با الگوریتم مرجع [۸] مقایسه کنیم. در این آزمایش در روش مرجع تعداد ۸ پایلوت در کل یک فریم که شامل دو بلوک OFDM می‌شود قرار می‌گیرد به طوری که این ۸ پایلوت فقط در بلوک اول جایگذاری می‌شود. در روش پیشنهادی تعداد ۸ پایلوت در کل یک فریم قرار می‌گیرند با این تفاوت که این ۴ پایلوت در بلوک اول و ۴ پایلوت در بلوک دوم جایگذاری می‌شوند.



شکل ۵: نمودار مقایسه‌ی نرخ خطای بیت در اثر پایلوت

عبارت  $f_d$  هم فرکانس داپلر کانال را نشان می دهد که در واقع میزان تغییر کانال در طول زمان را بیان می کند.

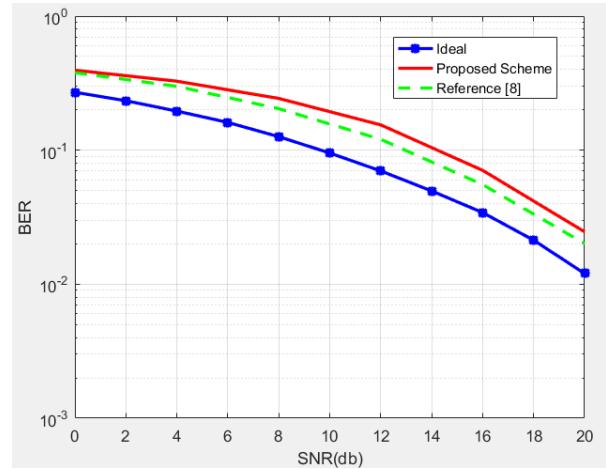


شکل ۸: نمودار مقایسه نرخ خطای بیت در اثر تغییر کانال

با توجه به شکل ۸ می توان ملاحظه نمود که اگر کانال آموزش تغییر کند روش مرجع لزوماً نتیجه مناسبی نخواهد داشت و از این جهت حساسیت روش ارائه شده در مرجع [۸] به داده های آموزشی بسیار بیشتر از روش پیشنهادی است. یادآوری می شود که در این حالت روش پیشنهادی به مراتب بهتر از مرجع [۸] عمل می کند هرچند که این روش نیز افت عملکردی مشهودی را نشان می دهد.

### ۳-۴- اثر حذف CP

مطالعات گذشته نشان داده است که حذف CP، آشکارسازی سیستم های OFDM را دچار مشکل می کند. وجود CP در سیستم باعث می شود کانولوشن خطی موجود به کانولوشن گردشی تبدیل شده و همسان سازی ساده امکان پذیر باشد. ولی در صورت حذف CP، این اتفاق دیگر رخ نمی دهد و به همین دلیل عملکرد سیستم دچار مشکل می شود. با استفاده از الگوریتم های یادگیری می توان به این مشکل غلبه کرد و به خطای بیتی با نرخ کم دست یافت. نتیجه هی دو روش مرجع [۸] و روش ارائه شده در صورت عدم وجود CP در نمودارهای شکل ۷ آورده شده است.



شکل ۷: نمودار مقایسه نرخ خطای بیت در اثر حذف CP

همانطور که در نمودار مشخص است تفاوت احتمال خطای بیت در هر دو روش خیلی کم است. هر چند که روش مرجع [۸] اندکی بهتر از روش پیشنهادی است، اما لازم است توجه شود که این میزان افت عملکرد در روش پیشنهادی با توجه به مزایای روش پیشنهادی، قابل چشمپوشی است. لازم به ذکر است که فاصله دو روش با افزایش SNR تغییر چندانی نمی کند و از این جهت هر دو روش از الگوی مشابهی پیروی می کنند.

### ۵- جمع بندی

در این مقاله، ابتدا سیستم های OFDM را توصیف کردیم و سپس به روش های مرسم تخمین کانال در این سیستم ها اشاره شد. دیدیم که می توان برای کاهش پیچیدگی و بهبود عملکرد از روش های یادگیری ماشین که امروزه مورد توجه بسیاری قرار گرفته اند استفاده کرد. پس به بررسی تخمین کانال و آشکارسازی سیگنال در سیستم های OFDM با استفاده از روش های یادگیری پرداختیم. در این میان، روش های مختلفی برای این کار پیشنهاد شده است که ما یکی از آن ها را به عنوان روش مرجع انتخاب کرد و روشی در مقابل آن پیشنهاد می دهیم. دیدیم که در سناریوی اثر تعداد پایلوت ها، روش پیشنهادی ما با وجود اینکه با تعداد پایلوت یکسان، عملکردی ضعیفتر از روش مرجع دارد اما با اضافه کردن تعداد محدودی پایلوت به شیکه، می توان این تفاوت را کاهش داد و در مقابل پیچیدگی را در حد بسیار زیادی کاهش داد. در سناریوی تغییر کانال، دیدیم که در روش مرجع، از کانال وینر II با خصوصیات خاص خود برای آموزش شبکه ی یادگیری خود لزوماً می شود. اگر به جای این کانال، از یک کانال رایلی استفاده کنیم عملکرد سیستم افت شدیدی خواهد داشت حال آن که در شرایط مشابه روش پیشنهادی نتیجه بهتری نسبت به روش مرجع خواهد داشت.

### مراجع

- [1] T. Hwang, C. Yang, G. Wu, S. Li, and G. Y. Li, "OFDM and its wireless applications: A survey," IEEE Trans. Veh. Technol., Vol. 58, No. 4, pp. 1673–1694, May 2009.
- [2] G. Y. Li, N. Seshadri, and S. Ariyavisitakul, "Channel estimation for OFDM systems with transmitter diversity in mobile wireless channels," IEEE J. Sel. Areas Commun., Vol. 17, No. 3, pp. 461–471, Mar. 1999.

### ۴- تغییر در نوع کانال

در قسمت قبل عنوان شد که کانال مورد استفاده در شبیه سازی، کانال وینر II است. در این قسمت به بررسی نتایج نرخ خطای بیت آشکارسازی سیبل ها در شرایطی که کانال مورد استفاده در سیستم کانال وینر II [۱۱] نباشد، می پردازیم. قابل انتظار است که وقتی این کانال تغییر کند و به کانال دیگری تبدیل شود لزوماً نتایج بهینه نخواهند بود. این حقیقت در نمودارهای شکل ۸ بررسی شده است. ویژگی های کانال مورد استفاده در زیر آورده شده است [۱۲]:

در تمامی نمودارها پارامترهای مورد استفاده کانال وینر در مرجع [۸] ذکر شده است، در این قسمت پارامترهای کانال را به صورت زیر در نظر می گیریم:

$$T_s = 10^{-4} \quad (9)$$

$$\tau = [0, 10^{-5}, 3.5 \times 10^{-5}, 12 \times 10^{-5}] \quad (10)$$

$$P_{db} = [0, -1, -1, -3] \quad (11)$$

$$f_d = 1 \quad (12)$$

عبارت  $T_s$  دوره هی نمونه برداری کانال را نشان می دهد. عبارت  $\tau$  در واقع همان میزان تاخیر مسیرهای کانال و عبارت  $P_{db}$  میزان توان هر مسیر را بیان می کند.

- [9] Pallaviram Sure, Chandra Mohan Bhuma ,” A survey on OFDM channel estimation techniques based on denoising strategies,” Engineering Science and Technology, an International Journal. 20 April 2017.
- [10] Jun Liu ,KaiMei , Xiaochen Zhang, Dongtang Ma, Senior Member and Jibo Wei, “Online Extreme Learning Machine-Based Channel Estimation and Equalization for OFDM Systems”, IEEE Wireless Communications Letters, Vol. 23, No. 7, July 2019.
- [11] P. Kyosti et al., “WINNER II channel models”, Eur. Commission, Brussels, Belgium, Tech. Rep. D1.1.2 IST-4-0-WINN27756 ER, Sep. 2007.
- [12] Cyril-Daniel Iskander ,Hi-Tek Multisystems. “A MATLABR - based Object - Oriented Approach to Multipath Fading Channel Simulation,” (<https://www.mathworks.com/matlabcentral/fileexchange/18869-a-matlab-based-object-oriented-approach-to-multipath-fading-channel-simulation>), MATLAB Central File Exchange. Retrieved August 28, 2022.
- [3] Lei Yang, Qing Zhao and Yindi Jing, “Channel Equalization and Detection with ELM-Based Regressors for OFDM Systems,” IEEE Communications Letters, Vol. 24, No. 1, Jan. 2020.
- [4] Ponnaluru, S, Penke, S, “Deep learning for estimating the channel in orthogonal frequency division multiplexing systems,” J. Ambient Intell. Hum. Comput., 2020.
- [5] G. Y. Li, N. Seshadri, and S. Ariyavisitakul, “Channel estimation for OFDM systems with transmitter diversity in mobile wireless channels,” IEEE Journal on Selected Areas in Communications, Vol. 17, No. 3, pp. 461–471, Mar. 1999.
- [6] Manisha Sutar,Vikram Patil, “LS and MMSE Estimation with Different Fading Channels for OFDM System,” International Conference of Electronics, Communication and Aerospace Technology (ICECA), Apr. 2017.
- [7] Chi-Cheng Kuo, and M. B. Basnet, “Improved Pilot-Aided Channel Estimation for MIMO-OFDM Fading Channels,” International Journal of Antennas and Propagation, 2013.
- [8] Hao Ye, Geoffrey Ye Li, and Biing-Hwang Juang, “Power of Deep Learning for Channel Estimation and Signal Detection in OFDM System“, IEEE Wireless Communications Letters, Vol. 7, No. 1, Feb. 2018.

<sup>16</sup> Feedforward Neural Network

<sup>17</sup> Bit Error Rate

<sup>18</sup> Serial to Parallel Converter

<sup>19</sup> Inverse Discrete Fourier Transform

<sup>20</sup> Cyclic Prefix

<sup>21</sup> Intersymbol Interference

<sup>22</sup> Interpolation

<sup>23</sup> شکل‌ها به ترتیب از بالا الف، ب و ج نامگذاری می‌شوند

<sup>24</sup> Nerve Cell

<sup>25</sup> Deep Neural Network

<sup>26</sup> Activator Function

<sup>27</sup> Softmax

<sup>28</sup> Sigmoid

<sup>29</sup> Rectified Linear Unit

<sup>30</sup> Wiener II

<sup>1</sup> Orthogonal Frequency Division Multiplexing

<sup>2</sup> Frequency selectivity

<sup>3</sup> Machine Learning

<sup>4</sup> Spectral Efficiency

<sup>5</sup> Training Data

<sup>6</sup> Blind

<sup>7</sup> Wideband

<sup>8</sup> Multiplexing

<sup>9</sup> Orthogonal

<sup>10</sup> Pilot

<sup>11</sup> Least Square

<sup>12</sup> Minimum Mean Square Error

<sup>13</sup> Deep Learning

<sup>14</sup> Feedforward

<sup>15</sup> One Dimensional Convolutional Neural Network