

## استقرار بهینه پهپادها بمنظور بهبود عملکرد شبکه در محیط شهری

محمد ابراهیم ابراهیم طوسی\*<sup>۱</sup>، سید امین الله ایزدی اونجی<sup>۲</sup>

۱. کارشناس ارشد مهندسی هوافضا، دانشکده فناوری های نوین، دانشگاه علم و صنعت، تهران، ایران.

۲. استاد دانشکده برق، دانشگاه علوم و فنون هوایی شهید ستاری، تهران، ایران.

### چکیده

پارامترهای سیگنال بی سیم نقش مهمی در عملکرد شبکه های بی سیم و همچنین تجربه ی کاربری ما از این شبکه ها دارند. این پارامترها شامل عواملی مانند پروفایل کانال و نسبت سیگنال به نویز بوده که هر کدام از این پارامترها می توانند به طور مستقیم یا غیرمستقیم بر روی کیفیت ارتباطات بی سیم تأثیر بگذارند. دریافت بهینه این پارامترها در سیستم های ارتباطی بی سیم پیشرفته امروزی، روشی ضروری می باشد. یکی از این روش ها استفاده از یادگیری عمیق برای تخمین پروفایل کانال و نسبت سیگنال به نویز می باشد. یادگیری عمیق که شاخه ای از هوش مصنوعی است، به طور گسترده ای در تخمین پروفایل کانال و نسبت سیگنال به نویز استفاده می شود، زیرا این تکنیک ها می توانند الگوهای پیچیده موجود در داده های سیگنال را شناسایی کنند. مدل ها با یادگیری از داده های آموزشی، می توانند ویژگی های کلیدی کانال و SNR را استخراج کرده و تخمین های دقیقی ارائه دهند. در این مقاله یک روش تخمین پروفایل کانال و نسبت سیگنال به نویز برای هر دو استاندارد سیگنال های بی سیم LTE و 5G با استفاده از یادگیری عمیق پیشنهاد و از یک شبکه ترکیبی LSTM-CNN برای آموزش استفاده شده است. با استفاده از شبکه آموزش داده شده، به نتیجه تقریباً ۹۴ درصدی بر روی داده های تست می رسیم.

واژه های کلیدی: پروفایل کانال، نسبت سیگنال به نویز، یادگیری عمیق، LSTM-CNN, 5G, LTE

## Estimation of channel profile and signal-to-noise ratio in wireless receivers using deep learning

Mohammad Ebrahim Ebrahim Toosi\*<sup>1</sup>, Seyyed Amin Allah Izadi Onji<sup>2</sup>

1. Aerospace Engineering, Science and Technology University, Tehran, Iran.

2. Faculty of Electrical Engineering, Shahid Sattari's aviation science and technology University of Tehran, Iran

### Abstract

Signal parameters are critical in determining the performance of wireless networks and the user experience they provide. These parameters, such as the channel profile and signal-to-noise ratio (SNR), can significantly affect the quality of wireless communications, either directly or indirectly. Accurate estimation of these parameters is essential in modern wireless communication systems. A promising approach to achieve this is through the application of deep learning techniques, which are widely used for estimating the channel profile and SNR due to their ability to capture complex patterns in signal data. By learning from training data, deep learning models can effectively extract key features related to the channel and SNR, resulting in more precise estimations. This paper proposes a novel method for estimating the channel profile and SNR for both LTE and 5G wireless standards using a deep learning-based approach, specifically a hybrid LSTM-CNN network architecture. The trained model demonstrates an accuracy of approximately 94% on the test dataset.

**Key words:** channel profile, signal-to-noise ratio, deep learning, LTE, 5G, LSTM-CNN.

دیگر، نسبت سیگنال به نویز پایین، نشان‌دهنده این است که نویز به میزان زیادی بر سیگنال غلبه کرده است، که این وضعیت می‌تواند منجر به افزایش نرخ خطای بیت و کاهش نرخ داده مؤثر شود [۱۰]. تخمین پروفایل کانال و نسبت سیگنال به نویز، دو پارامتر کلیدی در بهبود عملکرد سیستم‌های مخابراتی بی‌سیم به‌شمار می‌روند. تخمین پروفایل کانال به سیستم‌ها اجازه می‌دهد تا تخصیص منابعی همچون پهنای باند و توان را بهینه‌سازی کنند و تداخلات بین کاربران را کاهش دهند، که در نتیجه بهره‌وری طیفی افزایش می‌یابد [۱۱]. همچنین، سیستم‌های مخابراتی می‌توانند مدولاسیون و کدگذاری را بر اساس شرایط کانال تنظیم کرده و به این ترتیب، نرخ داده و کیفیت ارتباط را بهبود بخشند [۱۲]. این امر به‌ویژه در شرایطی که کانال دچار تغییرات سریع است، مانند زمانی که کاربران در حال حرکت هستند، اهمیت پیدا می‌کند و به سیستم کمک می‌کند تا با تغییرات سازگار شود و ارتباط پایدار بماند [۱۳]. در سیستم‌های MIMO، تخمین پروفایل کانال برای شکل‌دهی پرتو ضروری است که از تداخل کاسته و سیگنال را در مقصد تقویت می‌کند [۱۴]. در شبکه‌های 5G و 6G، که از باندهای فرکانسی بالا مانند موج میلی‌متری استفاده می‌کنند، تخمین پروفایل کانال برای مقابله با تضعیف شدید سیگنال‌ها امری ضروری است [۱۵]. این تخمین همچنین به بهبود امنیت ارتباطات کمک می‌کند، زیرا می‌تواند حملات احتمالی را شناسایی و رمزگذاری سیگنال‌ها را تقویت کند [۱۶].

تخمین نسبت سیگنال به نویز نیز به بهینه‌سازی عملکرد شبکه‌های مخابراتی کمک شایانی می‌کند. این تخمین به شبکه‌ها امکان می‌دهد تا به‌صورت پویا پهنای باند و توان ارسال را تخصیص دهند و در نتیجه کارایی طیف افزایش یافته و تداخلات کاهش یابد [۱۷]. همچنین، سیستم‌های مخابراتی با استفاده از این تخمین می‌توانند پارامترهای مدولاسیون و کدگذاری را بهینه کرده و سرعت داده‌ها را بر اساس شرایط کانال افزایش دهند [۱۸]. بهبود کیفیت خدمات در سیستم‌های حساس به تأخیر، مانند تماس‌های ویدئویی نیز یکی دیگر از مزایای این تخمین است، زیرا با تنظیم پارامترهای سیستم، کیفیت ارتباطات حفظ می‌شود [۱۹]. تخمین دقیق نسبت سیگنال به نویز همچنین به کاهش تداخلات در شبکه‌های بی‌سیم و افزایش امنیت ارتباطات کمک کرده و سیستم‌های رمزنگاری را تقویت می‌کند [۲۰، ۲۱].

این مقاله به‌طور خاص بر روی تخمین پروفایل کانال و نسبت سیگنال به نویز در سیستم‌های LTE و 5G متمرکز شده است. در حالی که استفاده از مدل LSTM-CNN در تحقیقات قبلی مطرح شده، نوآوری اصلی این تحقیق در کاربرد خاص این مدل در شرایط چالش‌برانگیز این دو استاندارد بی‌سیم نهفته است. مدل ما با داده‌های آموزشی متنوع و ویژگی‌های خاص این استانداردها توانسته به دقت تقریباً ۹۴ درصدی دست یابد. این نتایج در شرایط نویزی و محیط‌های پیچیده به‌خوبی کارایی مدل را نشان می‌دهد. همچنین، به بررسی و

پارامترهای سیگنال بی‌سیم نقش مهمی در عملکرد شبکه‌های بی‌سیم و همچنین تجربه‌ی کاربری ما از این شبکه‌ها دارند. این پارامترها شامل عوامل مختلفی هستند که هر کدام از این پارامترها می‌توانند به‌طور مستقیم یا غیرمستقیم بر روی کیفیت ارتباطات بی‌سیم تأثیر بگذارند. به عنوان مثال، افزایش توان سیگنال می‌تواند دامنه پوشش را افزایش دهد، اما همزمان ممکن است تداخل با سایر شبکه‌ها را بیشتر کند. در مقابل، کاهش نویز می‌تواند کیفیت ارتباط را بهبود بخشد، اما ممکن است نیاز به استفاده از تکنولوژی‌های پیچیده‌تری داشته باشد [۱]. این پارامترها نه تنها در حوزه‌های تخصصی مانند شبکه‌های موبایل و اینترنت اشیا<sup>۱</sup> اهمیت دارند، بلکه در زندگی روزمره‌ی ما نیز تأثیرات قابل توجهی دارند [۲]. تخمین پروفایل کانال در سیستم‌های مخابرات بی‌سیم، یک مرحله کلیدی برای بهبود عملکرد سیستم است [۳]. پروفایل کانال، توصیف دقیقی از نحوه انتقال سیگنال از فرستنده به گیرنده، از جمله تأخیر زمانی، تضعیف، و تغییر فاز امواج در محیطی با موانع و پراکنندگی‌ها ارائه می‌دهد [۴]. تخمین دقیق پروفایل کانال به سیستم اجازه می‌دهد تا با تطبیق خود با شرایط کانال، بهره‌وری طیفی و کیفیت خدمات را بهبود بخشد [۵]. مدل‌سازی و تخمین کانال معمولاً با استفاده از مدل‌های ریاضی انجام می‌شود که رفتار واقعی سیگنال در کانال را شبیه‌سازی می‌کنند [۶]. برای مثال، مدل خطی رابطه ۱، یکی از ساده‌ترین و پرکاربردترین مدل‌ها در این حوزه است [۳].

$$y = Hx + n \quad (1)$$

در رابطه ۱،  $y$  بردار سیگنال دریافتی در گیرنده،  $H$  ماتریس کانال که شامل اطلاعات پروفایل کانال مانند تضعیف و تغییر فاز،  $x$  بردار سیگنال ارسالی و  $n$  بردار نویز است که معمولاً به صورت یک نویز گاوسی با میانگین صفر و واریانس مشخص مدل می‌شود [۷]. نسبت سیگنال به نویز<sup>۲</sup> یکی از مهم‌ترین پارامترهای ارزیابی کیفیت سیگنال در سیستم‌های مخابراتی و نشان‌دهنده نسبت توان سیگنال مطلوب به توان نویز مزاحم در یک کانال ارتباطی است. نسبت سیگنال به نویز معمولاً به صورت دسی‌بل (dB) بیان می‌شود که به صورت رابطه ۲ است.

$$SNR = 10 \log_{10} \left( \frac{P_{signal}}{P_{noise}} \right) \quad (2)$$

در رابطه ۲،  $P_{signal}$  توان سیگنال دریافتی و  $P_{noise}$  توان نویز موجود در کانال است [۸].

به دلیل نویز کمتری که در سیگنال وجود دارد، هرچه نسبت سیگنال به نویز بالاتر باشد، کیفیت سیگنال دریافتی بهتر است. در واقع، نسبت سیگنال به نویز بالا، به معنای توان بیشتر سیگنال نسبت به نویز است که موجب بهبود کیفیت و کاهش خطای سیستم می‌شود [۹]. از سوی

در رابطه ۶،  $R_{yx}$  ماتریس کوواریانس بین مشاهدات  $y$  و سیگنال‌های ارسالی  $x$ ، و  $R_{xx}$  ماتریس کوواریانس سیگنال‌های ارسالی است [۲۵].

### ۲-۳- روش حداکثر شباهت<sup>۳</sup>

روش حداکثر شباهت بر پایه یافتن پارامترهای کانال است که احتمال وقوع داده‌های مشاهده‌شده را بیشینه می‌کند. این روش در شرایط نویز گاوسی سفید مشابله روش کمترین مربعات است [۲۶]. فرمول تخمین در این روش به صورت راب ۷ است.

$$\hat{H}_{ML} = (X^H X)^{-1} X^H Y \quad (7)$$

در اینجا، این روش با LS یکسان است [۲۷].

### ۲-۴- روش فیلترهای انطباقی<sup>۴</sup>

روش فیلترهای انطباقی برای تخمین پروفایل کانال مناسب محیط‌های متغیر با زمان هستند. فیلترهای تطبیقی با استفاده از الگوریتم‌هایی مانند LMS یا RLS پارامترهایشان را به‌طور مداوم به‌روز می‌کنند تا تخمین بهتری ارائه دهند [۲۸].

### ۲-۵- روش تخمین کور<sup>۵</sup>

تخمین کور در مواقعی استفاده می‌شود که اطلاعات یا آگاهی از سیگنال‌های ارسالی در دسترس نیست. یکی از روش‌های رایج در این زمینه استفاده از تجزیه مقدارهای منفرد<sup>۶</sup> بر روی ماتریس مشاهدات است [۲۹].

### ۳- روش‌های متداول تخمین نسبت سیگنال به نویز

#### ۳-۱- روش تخمین مبتنی بر انرژی

این روش با استفاده از انرژی سیگنال دریافتی و انرژی نویز، نسبت سیگنال به نویز را تخمین می‌زند. انرژی سیگنال دریافتی از رابطه ۸ بدست می‌آید [۳۰].

$$E_y = \frac{1}{N} \sum_{n=1}^N |y(n)|^2 \quad (8)$$

سپس انرژی نویز  $E_n$ ، به‌طور جداگانه از بخش‌های بدون سیگنال (فقط نویز) به صورت رابطه ۹ محاسبه می‌شود.

$$E_n = \frac{1}{M} \sum_{m=1}^M |n(m)|^2 \quad (9)$$

در رابطه ۱۸،  $M$  تعداد نمونه‌هایی است که فقط شامل نویز هستند. نسبت سیگنال به نویز به صورت رابطه ۱۰ تخمین زده می‌شود.

$$SNR_{est} = \frac{E_y - E_n}{E_n} \quad (10)$$

توسعه روش‌های جدید تخمین پروفایل کانال و نسبت سیگنال به نویز با استفاده از یادگیری عمیق پرداخته و به مقایسه نتایج با تکنیک‌های سنتی پرداخته شده است. این پژوهش به‌وضوح مزایای قابل توجهی در بهینه‌سازی تخمین‌های موجود به همراه دارد.

این مقاله به این صورت سازماندهی شده است که در بخش ۲، به مرور روش‌های متداول تخمین پروفایل کانال و نسبت سیگنال به نویز پرداخته شده است. در بخش ۳، روش پیشنهادی و ساختار مدل LSTM-CNN تشریح شده است. سپس در بخش ۴، نتایج شبیه‌سازی‌ها و ارزیابی‌ها ارائه و در نهایت، در بخش آخر، نتیجه‌گیری و پیشنهادات آینده مطرح شده است.

### ۲- روش‌های متداول تخمین پروفایل کانال

#### ۲-۱- روش کمترین مربعات<sup>۱</sup>

روش کمترین مربعات یکی از روش‌های متداول برای تخمین پروفایل کانال در سیستم‌های مخابراتی است. این روش بر پایه کمینه‌سازی مجموع مربعات اختلافات بین داده‌های اندازه‌گیری شده و داده‌های پیش‌بینی شده توسط مدل کانال است. هدف این روش حداقل کردن مجموع مربعات خطاها برای به دست آوردن بهترین تخمین از پارامترهای کانال است [۲۲]. مدل کانال به صورت رابطه زیر بیان می‌شود:

$$Error = \|y - Hx\|_2^2 \quad (3)$$

با استفاده از روش کمترین مربعات، تخمین ماتریس کانال  $H$  به صورت رابطه ۴ می‌باشد.

$$\hat{H} = (X^T X)^{-1} X^T Y \quad (4)$$

در رابطه ۴،  $X$  ماتریس سیگنال‌های ارسالی و  $Y$  ماتریس مشاهدات است. این تخمین در شرایط نویز سفید گاوسی دقت بالایی دارد [۲۳].

#### ۲-۲- روش حداقل میانگین مربعات<sup>۲</sup>

روش حداقل میانگین مربعات یک روش پیشرفته برای تخمین پروفایل کانال است که با کمینه‌سازی میانگین مربعات خطای تخمین عمل می‌کند. این روش از اطلاعات آماری نویز و سیگنال‌ها برای بهبود دقت تخمین استفاده می‌کند [۲۴]. فرمول تخمین کانال در این روش به صورت رابطه ۶ است.

$$\hat{H}_{MMSE} = R_{yx} R_{xx}^{-1} \quad (6)$$

<sup>4</sup> Adaptive Filtering

<sup>5</sup> Blind Estimation

<sup>6</sup> Singular Value Decomposition (SVD)

<sup>1</sup> Least Squares (LS)

<sup>2</sup> Minimum Mean Square Error (MMSE)

<sup>3</sup> Maximum Likelihood (ML)

### ۳-۲- روش تخمین حداکثر شباهت<sup>۱</sup>

این روش بر اساس یافتن تخمینی است که احتمال وقوع داده‌های مشاهده شده را حداکثر می‌کند. تابع چگالی احتمال سیگنال دریافتی از طریق رابطه ۱۱ بدست می‌آید.

$$p(y(n) | \sigma_s^2, \sigma_n^2) \quad (11)$$

تخمین سیگنال به نوبت به صورت رابطه ۱۲ محاسبه می‌شود.

$$SNR_{ML} = \frac{\hat{\sigma}_s^2}{\hat{\sigma}_n^2} \quad (12)$$

در رابطه ۱۲،  $\hat{\sigma}_n^2$  می‌تواند از بخش‌هایی از سیگنال که شامل نویز خالص هستند (بخش‌های بدون سیگنال) تخمین زده شود [۳۱].

### ۳-۳- روش کمترین مربعات

این روش به دنبال کمینه‌سازی مجموع مربعات خطا بین سیگنال دریافتی و مدل پیش‌بینی شده است. نسبت سیگنال به نویز به صورت رابطه ۱۳ محاسبه می‌شود.

$$SNR_{LS} = \frac{\alpha^2 \cdot Var(y(n))}{Var(y(n) - \alpha y(n) - \beta)} \quad (13)$$

در رابطه ۱۳،  $Var(\cdot)$  واریانس یک سیگنال را نشان می‌دهد [۳۲].

### ۳-۴- روش تخمین بر اساس میانگین و واریانس

این روش از اطلاعات آماری مانند میانگین و واریانس سیگنال‌های دریافتی و نویز استفاده می‌کند. نسبت سیگنال به نویز به صورت رابطه ۱۴ تعریف می‌شود.

$$SNR = \frac{\sigma_s^2}{\sigma_n^2} \quad (14)$$

سپس تخمین سیگنال به نویز از رابطه ۱۵ بدست می‌آید.

$$SNR_{est} = \frac{\sigma_y^2 - \sigma_n^2}{\sigma_n^2} \quad (15)$$

در رابطه ۱۵،  $\sigma_n^2$  واریانس نویز است که می‌تواند از قسمت‌های بدون سیگنال (که فقط نویز وجود دارد) تخمین زده شود. همچنین  $\sigma_s^2$  از تفاوت واریانس کل سیگنال دریافتی و واریانس نویز به دست می‌آید [۳۳].

### ۳-۵- روش تخمین طیفی

این روش از ویژگی‌های طیفی سیگنال دریافتی استفاده می‌کند. نسبت سیگنال به نویز به صورت رابطه ۱۶ تعریف می‌شود.

$$SNR(f) = \frac{P_s(f)}{P_n(f)} \quad (16)$$

برای محاسبه نسبت سیگنال به نویز کل، از میانگین‌گیری در تمامی فرکانس‌ها استفاده می‌شود [۳۴].

### ۴- شبیه‌سازی‌ها و نتایج

#### ۴-۱- شبیه‌سازی

مدل هیبریدی CNN-LSTM ترکیبی از شبکه‌های عصبی پیچشی (CNN) و شبکه حافظه کوتاه‌مدت بلند (LSTM) است که برای تحلیل داده‌های مکانی-زمانی استفاده می‌شود [۳۵]. CNN برای استخراج ویژگی‌های مکانی و LSTM برای مدل‌سازی وابستگی‌های زمانی کاربرد دارد. این مدل به‌ویژه در تشخیص فعالیت‌های انسانی و پیش‌بینی سری‌های زمانی موثر است [۳۶، ۳۷]. پیش‌بینی باینری و چندکلاسه دو رویکرد اصلی در یادگیری ماشین برای دسته‌بندی داده‌ها هستند. تنوع ورودی به مدل‌ها کمک می‌کند تا با داده‌های متنوع آموزش ببینند و دقت آن‌ها را افزایش دهند. این تنوع همچنین از بیش‌برازش جلوگیری کرده و مقاومت مدل‌ها را در برابر تغییرات و نویز بهبود می‌بخشد [۳۸، ۳۹]. در نهایت، مدل‌ها با داده‌های متنوع توانایی عمومی‌سازی بهتری پیدا می‌کنند [۴۰]. شبیه‌سازی‌ها معمولاً برای اعتبارسنجی تکنیک‌های تخمین پارامتر کانال بی‌سیم استفاده می‌شوند. جعبه ابزار MATLAB Communication، LTE و 5G برای مدل‌سازی کانال‌های محو بی‌سیم و تولید مجموعه داده سیگنال دریافتی فرکانس رادیویی استفاده می‌شوند یک نسبت سیگنال به نویز بین [20, -10] دسی‌بل و یک پروفایل کانال در [EPA EVA ETU] برای سیستم LTE و در ['TDL-A', 'TDL-B', 'TDL-C', 'TDL-D', 'TDL-E'] برای سیستم 5G انتخاب می‌شود. مجموعه داده‌های ورودی برای پیش‌بینی به صورت تصادفی قرار داده شده است. برای تنوع ورودی، مجموعه داده‌ای سازماندهی می‌شود که در آن ورودی‌های متعدد از برچسب‌های داده مرجع مشلیه در توالی‌های ورودی با طول‌های دلخوا ترکیب شده‌اند (یعنی ۱، ۵ و ۱۵). بسته به هدف پیش‌بینی (یعنی پروفایل کانال و نسبت سیگنال به نویز)، برچسب‌ها بر این اساس به هر دنباله ورودی اختصاص داده شده است. این تحقیق بر روی سیستم‌های تک آنتن انجام شده است و می‌توان آن‌را به سیستم‌های چند آنتنه گسترش داد.

#### ۴-۲- تولید مجموعه داده LTE

برای تولید مجموعه داده LTE، مثال تخمین و یکسان‌سازی کانال لینک پایین رونده متلب را اتخاذ شده است. مجموعه داده شامل ۵۴۰۰۰ ورودی می‌باشد. جدول ۱ مدل کانال LTE را شرح می‌دهد.

#### ۴-۳- تولید مجموعه داده 5G

برای تولید مجموعه داده 5G، مثال سنتز داده‌های یادگیری عمیق برای تخمین کانال 5G متلب را اتخاذ شده است. مجموعه داده

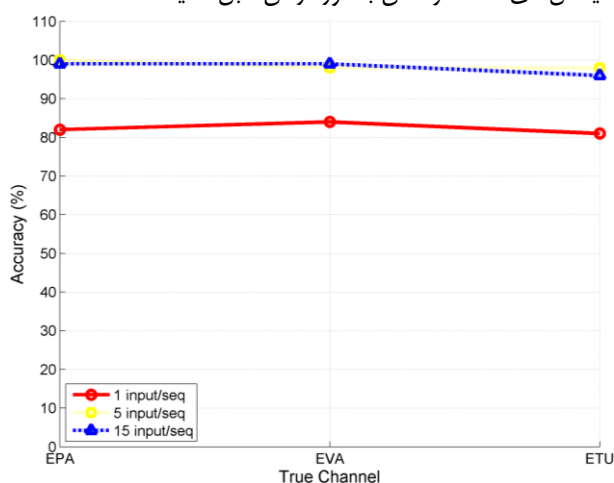
<sup>1</sup> Maximum Likelihood

شامل ۱۲۰۰۰ ورودی می باشد. جدول ۲ مدل کانال 5G را شرح می‌دهد.


جدول ۱- مجموعه داده LTE

Parameter	Value	Comment
ModelType	'GMEDS'	Rayleigh
NRxAnts	1	1 Rx antenna
DelayProfile Variable	[EPA EVA ETU]	
DopplerFreq - Variable	[0 60 120]	
MIMOCorrelation	'Low'	No MIMO
InitTime	0	
NTerms	16	Fading oscillators
InitPhase	'Random'	
NormalizePathGains	'On'	
NormalizeTxAnts	'On'	
PilotAverage	'UserDefined'	
FreqWindow	9	RE Freq average
TimeWindow	9	RE Time average

پیش بینی زیر ۹۰ درصد است. هرچه تنوع ورودی بیشتر باشد، دقت بالاتر می رود. به عبارت دیگر، دقت پیش‌بینی با استفاده از پنج ورودی در هر دنباله تقریباً ۹۸ درصد است. با استفاده از مدل LSTM-CNN، افزایش تنوع در داده‌های ورودی (زمان و فرکانس) باعث بهبود دقت شده است. این نتایج نشان‌دهنده قدرت مدل در تشخیص و تفکیک الگوهای پیچیده سیگنالی است. همچنین نشان می‌دهد که مدل پیشنهادی می‌تواند به خوبی در شرایط مختلف محیطی (تغییرات فرکانسی و زمانی) عملکرد ثابتی ارائه دهد. به دلیل اینکه دقت پیش‌بینی پیش‌بینی چند کلاس مرسوم به اندازه کافی بالا است، پیش‌بینی باینری مورد نیاز نیست. عملکرد پیش‌بینی سیگنال‌های دامنه فرکانس با حوزه زمان قابل مقایسه است.



شکل ۱- دقت پیش‌بینی پروفایل کانال چند کلاس LTE حوزه زمان



شکل ۲- دقت پیش‌بینی پروفایل کانال چند کلاس LTE حوزه فرکانس

شکل ۳، دقت پیش‌بینی پروفایل کانال چند کلاس 5G حوزه زمان را نشان می‌دهد. همان‌طور که مشاهده می‌شود، با افزایش تعداد داده‌های ورودی و استفاده از تنوع بیشتر در ورودی‌ها، خطای nMSE کاهش یافته و بهبود عملکرد مدل در تخمین پروفایل کانال به وضوح قابل مشاهده است. نتایج این شکل نشان می‌دهد که مدل LSTM-CNN توانسته است در محیط‌های پیچیده‌تر با نویز بالا نیز عملکرد خوبی داشته باشد. همچنین شکل ۴ دقت پیش‌بینی پروفایل کانال

جدول ۲- مجموعه داده 5G

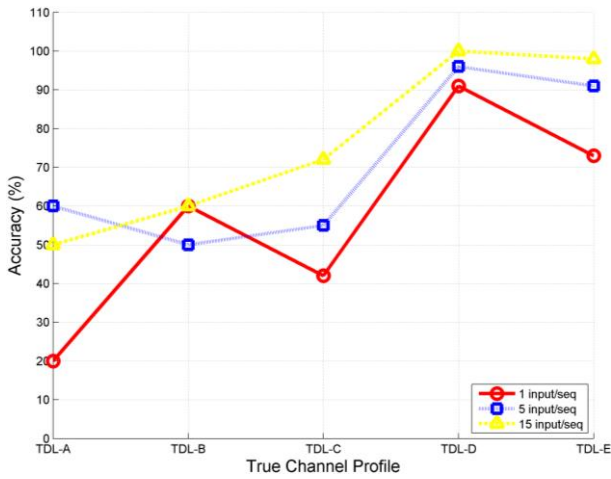
Parameter	Value
ModelType	Rayleigh
NRxAnts	1
DelayProfile - Variable	[TDL-A, TDL-B, TDL-C, TDL-D, TDL-E]
DelaySpread - Variable	randi([1 300])*1e-9
MaxDopplerShift - Variable	[0, 50, ..., 550]
MIMOCorrelation	'Low'
KFactorScaling	false
Polarization	Co-Polar
InitTime	0
NormalizePathGains	true
NumSinusoids	48
NormalizeChannelOutputs	true

#### ۴-۴- ساخت مدل CNN-LSTM

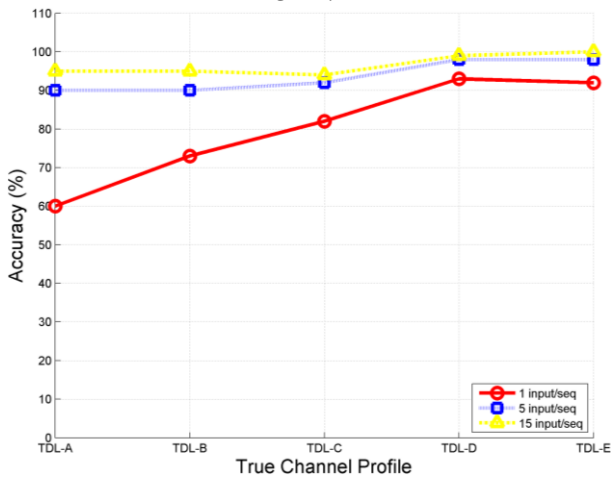
جعبه ابزار آموزش یادگیری عمیق متلب برای ساخت و شبیه سازی مدل استفاده شده است. مدل CNN از مثال طبقه بندی مدولاسیون با یادگیری عمیق متلب انتخاب و با یک مدل LSTM تلفیق شده است. در کاربردهای دنیای واقعی، آموزش را می‌توان به صورت آفلاین و به طور مداوم با استفاده از سیگنال‌های فرکانس رادیویی دنیای واقعی انجام داد. جدول ۳ آموزش مدل CNN-LSTM را نشان می‌دهد.

#### ۴-۵- پیش‌بینی پروفایل کانال

شکل‌های ۱ و ۲ دقت پیش‌بینی پروفایل کانال در سیستم LTE شبیه سازی شده با تنوع ورودی‌های مختلف با استفاده از پیش‌بینی چند کلاس و باینری برای سیگنال‌های حوزه زمان و دامنه فرکانس را نشان می‌دهد. با توجه به شکل، بدون تنوع ورودی دقت



شکل ۵- دقت پیش‌بینی پروفایل کانال چند کلاس 5G حوزه فرکانس



شکل ۶- دقت پیش‌بینی پروفایل کانال باینری 5G حوزه فرکانس


جدول ۳- آموزش CNN-LSTM

Parameter	Value
Training percentage	80
Validation percentage	10
Test percentage	10
Mini-batch size	256
Max epoch	12
Training method	SDGM
Initial learning rate	2e-2
Learn rate schedule	piecewise
Learn rate drop period	9
Learn rate drop factor	0.1

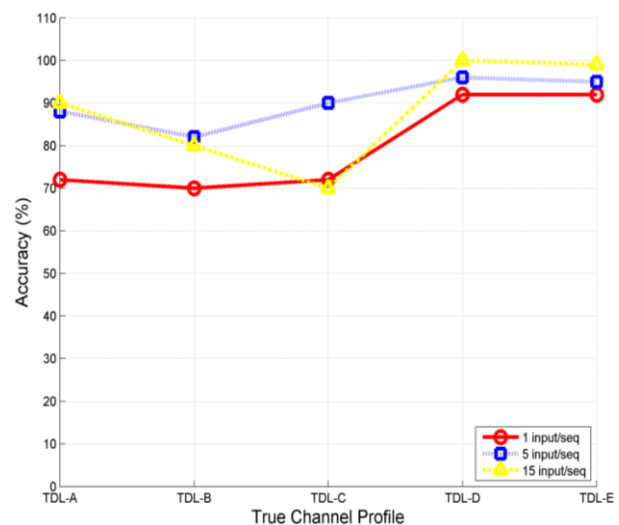
#### ۴-۶- پیش‌بینی نسبت سیگنال به نویز

دقت پیش‌بینی سیگنال به نویز در یک سیستم LTE شبیه‌سازی شده با استفاده از پیش‌بینی‌های مرسوم چند کلاس برای سیگنال‌های حوزه زمان، حدود ۱۰۰ درصد است. شکل ۷، دقت پیش‌بینی سیگنال به نویز چند کلاس LTE در حوزه فرکانس را نشان می‌دهد. با توجه به شکل، دقت پیش‌بینی‌های چند کلاس مرسوم برای سیگنال‌های دامنه فرکانس به طور غیرقابل قبولی زیر تقریباً ۶۰ درصد است. تنوع ورودی نیز نمی‌تواند پیش‌بینی‌ها را بهبود بخشد. شکل ۸، دقت پیش‌بینی سیگنال به نویز باینری LTE، و شکل ۹ دقت پیش‌بینی سیگنال به نویز چند کلاس 5G در حوزه فرکانس را

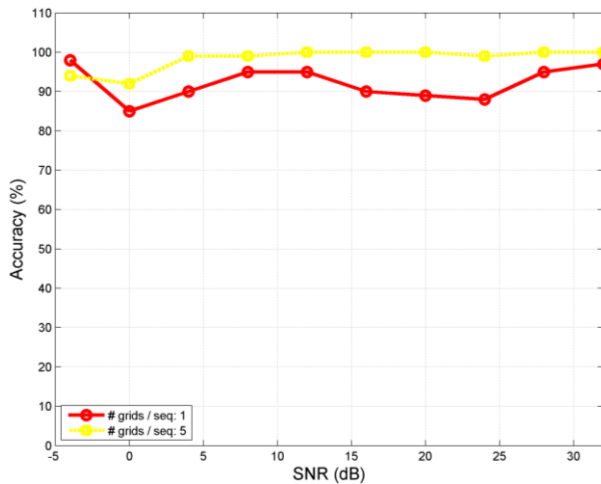
باینری 5G حوزه زمان را نشان می‌دهد که نشان دهنده دقت مدل در پیش‌بینی پروفایل کانال‌های باینری است. شکل ۵ نشان دهنده دقت پیش‌بینی پروفایل کانال چند کلاس 5G حوزه فرکانس است. همانطور که مشاهده می‌شود، مدل با افزایش تنوع در داده‌های ورودی دقت پیش‌بینی بهتری در تمامی کلاس‌ها ارائه داده است. شکل ۶ نیز به دقت پیش‌بینی پروفایل کانال باینری 5G حوزه فرکانس اشاره دارد. این شکل کارایی مدل CNN-LSTM را در تخمین پروفایل کانال بر اساس مدل کانال باینری در حوزه فرکانس را به تصویر می‌کشد. دقت پیش‌بینی‌های چند کلاس مرسوم برای سیگنال‌های حوزه زمان و دامنه فرکانس به طور غیرقابل قبولی زیر ۸۰ درصد است. تنوع ورودی نمی‌تواند پیش‌بینی‌ها را بهبود بخشد. با این حال، پیش‌بینی باینری که برای کاهش عدم قطعیت و پیچیدگی پیش‌بینی استفاده می‌شود، دقت پیش‌بینی را به ترتیب برای تنوع ورودی پنج تایی تا تقریباً ۹۰ و ۹۵ درصد افزایش می‌دهد. تنوع ورودی برای پیش‌بینی باینری نیز موثر است. عملکرد پیش‌بینی سیگنال‌های دامنه فرکانس کمی بهتر از حوزه زمان است.



شکل ۳- دقت پیش‌بینی پروفایل کانال چند کلاس 5G حوزه زمان



شکل ۴- دقت پیش‌بینی پروفایل کانال باینری 5G حوزه زمان



شکل ۹- دقت پیش‌بینی SNR چند کلاسه 5G حوزه فرکانس

جدول ۳- عملکرد پیش‌بینی SNR برای ورودی‌های حوزه زمانی LTE

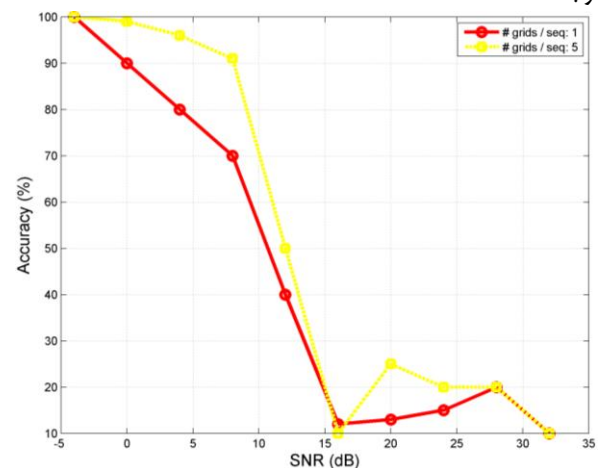
Range & Resolution	# Grids / seq	Accuracy (%)	nMSE
[-4, 0, ..., 32]	1	98	0
[-4, -2, ..., 32]	1	99	0
[-20, -16, ..., 32]	1	98	0
[-20, -18, ..., 32]	5	86	$5 * 10^{-4}$
[-20, -18, ..., 0]	1	100	0

جدول ۴ دقت پیش‌بینی نسبت سیگنال به نویز دامنه زمانی 5G را ۹۹ درصد و nMSE صفر را با استفاده از یک ورودی برای محدوده‌ها و وضوح‌های مختلف نسبت سیگنال به نویز نشان می‌دهد. همچنین شامل یک ورودی رایج بوده که توسط تکنیک‌های تخمین مرسوم به دست آمده است (به عنوان مثال [-۴، -۲، ...، ۳۲] دسی‌بل). از آنجائیکه هر پیش‌بینی فقط از یک شبکه استفاده می‌کند، تأخیر پیش‌بینی ۰/۵ میلی‌ثانیه است. به طور خلاصه، عملکرد پیش‌بینی نسبت سیگنال به نویز برای داده‌های حوزه زمانی 5G به سبب استفاده از تاخیرهای مسیر متعدد و اختلالات کانال ناشی از جابجایی داپلر، قابل توجه است.


جدول ۴- عملکرد پیش‌بینی SNR برای ورودی‌های حوزه زمانی 5G

Range & Resolution	# Grids / seq	Accuracy (%)	nMSE
[-4, 0, ..., 32]	1	99	0
[-4, -2, ..., 32]	1	99	0
[-20, -16, ..., 32]	1	99	0
[-20, -18, ..., 32]	2	98	0

نشان می‌دهد. با توجه به این دو شکل، پیش‌بینی باینری دقت پیش‌بینی را با استفاده از پنج ورودی در هر دنباله به تقریباً ۹۶ درصد افزایش می‌دهد. عملکرد پیش‌بینی سیگنال‌های حوزه زمان بهتر از دامنه فرکانس است. به همین صورت، جدول ۴ دقت پیش‌بینی نسبت سیگنال به نویز حوزه زمانی و nMSE برای سیستم LTE را برای طیف وسیعی از سیگنال به نویزها و ترکیب‌ها با استفاده از یک ورودی نشان می‌دهد. ۴ ترکیب از ۵ ترکیب دارای حداقل ۹۸ درصد دقت و nMSE صفر هستند. همچنین شامل یک ترکیب رایج که توسط تکنیک‌های تخمین مرسوم استفاده می‌شود (به عنوان مثال [-۴، -۲، ...، ۳۲] دسی‌بل)، می‌باشد. دقیق‌ترین آنها (به عنوان مثال [-۲۰، -۱۸، ...، ۳۲] دسی‌بل) دارای دقت پایین ۸۶ درصد و NMSE برابر با  $5 \times 10^{-4}$  است. عملکرد nMSE معمولی تکنیک‌های تخمین بین  $10^{-2}$  و  $10^{-3}$  است. از آنجائیکه هر پیش‌بینی از ورودی یک شبکه استفاده می‌کند، تأخیر پیش‌بینی یک میلی‌ثانیه است. به طور خلاصه، عملکرد پیش‌بینی نسبت سیگنال به نویز برای داده‌های دامنه زمانی LTE به سبب استفاده از سیگنال‌های مدولاسیون متعدد و تاخیرهای مسیر متعدد و اختلالات کانال ناشی از جابجایی داپلر، قابل توجه است.



شکل ۷- دقت پیش‌بینی SNR چند کلاسه LTE حوزه فرکانس



شکل ۸- دقت پیش‌بینی SNR باینری LTE حوزه فرکانس

جدول ۵- دقت پیش‌بینی پروفایل کانال

تعداد ورودی ها	۱	۵	۱۵
LTE چند کلاس حوزه زمان	۸۲٪	۹۹٪	۹۸٪
LTE چند کلاس حوزه فرکانس	۸۴٪	۹۸٪	۱۰۰٪
5G چند کلاس حوزه زمان	۶۲٪	۶۲٪	۶۲٪
5G چند کلاس حوزه فرکانس	۸۱٪	۸۱٪	۸۱٪
5G باینری حوزه زمان	۸۰٪	۸۸٪	۸۷٪
5G باینری حوزه فرکانس	۸۲٪	۹۵٪	۹۸٪

## ۶-مراجع

- [1] E. Mozaffariahrar, F. Theoleyre, and M. Menth, "A survey of Wi-Fi 6: Technologies, advances, and challenges," *Future Internet*, vol. 14, no. 10, pp. 293, 2022.
- [2] R. Prasad, "Challenges and Future Directions of Wireless Communication Networks," *IEEE Communications Magazine*, vol. 60, no. 1, pp. 102–108, Jan. 2022.
- [3] H. Ye, G. Y. Li, and B.-H. Juang, "Deep learning based channel estimation for beamforming in millimeter-wave massive MIMO systems," *IEEE Journal of Selected Topics in Signal Processing*, vol. 13, no. 5, pp. 989–1000, Sep. 2019.
- [4] W. Xia, G. Shi, H. He, and X. Yang, "A survey on deep learning-based massive MIMO channel estimation," *IEEE Communications Surveys & Tutorials*, vol. 22, no. 4, pp. 2821–2843, Fourthquarter 2020.
- [5] C. Luo, J. Zhang, Y. Jin, and M. Lei, "Deep learning-based channel estimation and feedback in multiuser MIMO systems," *IEEE Wireless Communications Letters*, vol. 8, no. 4, pp. 1284–1287, Aug. 2019.
- [6] Z. Gao, L. Dai, Z. Wang, S. Chen, and L. Hanzo, "Compressive-sensing-based multiuser detector for the large-scale SM-MIMO uplink," *IEEE Transactions on Vehicular Technology*, vol. 65, no. 10, pp. 8725–8730, Oct. 2016.
- [7] S. Hu, F. Rusek, and O. Edfors, "Beyond massive MIMO: The potential of data transmission with large intelligent surfaces," *IEEE Transactions on Signal Processing*, vol. 66, no. 10, pp. 2746–2758, May 2018.
- [8] Z. Wei, L. Dai, W. Yang, and K. J. Chen, "Deep Learning for BeamSpace Channel Estimation in Millimeter-Wave Massive MIMO," *IEEE Transactions on Communications*, vol. 68, no. 12, pp. 7282–7296, Dec. 2020.
- [9] J. Zhang, E. Björnson, and M. Matthaiou, "Prospective Multiple Antenna Technologies for Beyond 5G," *IEEE Journal on Selected Areas in Communications*, vol. 38, no. 8, pp. 1637–1660, Aug. 2020.
- [10] H. Yang, A. Alkhateeb, and G. Y. Li, "Artificial Intelligence Enabled Wireless Transmission for 6G: Opportunities and Challenges," *IEEE Communications Magazine*, vol. 58, no. 1, pp. 60–65, Jan. 2020.
- [11] T. Jiang, H. V. Poor, and Y. Liu, "Secure Communication in Multiuser MIMO-OFDM Systems with Artificial Noise," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 8, pp. 8239–8244, Aug. 2020.
- [12] P. S. R. M. De Leon, L. A. T. De Oliveira, M. C. B. B. Silva, and R. D. A. Moura, "Data-Driven Optimal Control for Smart Grids: A Review," *IEEE Transactions on Smart Grid*, vol. 12, no. 2, pp. 1142–1153, Mar. 2021.
- [13] S. H. H. M. M. Saeed, N. M. Shafiee, M. T. M. Saad, and F. I. N. B. A. Rahman, "A Comprehensive Review of Wireless Sensor Network Applications in Smart Cities," *IEEE Access*, vol. 9, pp. 56826–56846, 2021.
- [14] M. A. Khalil, K. F. A. S. Khodari, and A. M. M. Salama, "6G Wireless Networks: The Future of Intelligent Communications," *IEEE Communications Magazine*, vol. 59, no. 12, pp. 50–56, Dec. 2021.
- [15] C. Chen, Y. Xu, and R. Zhang, "Machine Learning for Wireless Communications: A Comprehensive Survey," *IEEE Transactions on Communications*, vol. 69, no. 5, pp. 3443–3474, May 2021.

جدول ۶- دقت پیش‌بینی نسبت سیگنال به نویز

Grids / seq	۱	۵
LTE چند کلاس حوزه زمان	۹۹٪	۱۰۰٪
LTE چند کلاس حوزه فرکانس	۵۶٪	۶۰٪
LTE باینری حوزه فرکانس	۹۰٪	۹۷٪
5G چند کلاس حوزه زمان	۹۹٪	۱۰۰٪
5G چند کلاس حوزه فرکانس	۹۳٪	۹۹٪

## ۴-۷- نتایج پیش‌بینی

همانند برنامه‌های یادگیری عمیق در سایر حوزه‌ها ( به عنوان مثال در بینایی کامپیوتر)، عملکردهای پیش‌بینی یادگیری عمیق از جمله الگوی دقت، میانگین و واریانس مبتنی بر داده‌ها هستند و به طور شهودی و تجربی ( آزمون و خطا) به دست می‌آیند. جدول ۴ میانگین دقت پیش‌بینی پروفایل کانال و نسبت سیگنال به نویز با استفاده از پیش‌بینی چند کلاس و پیش‌بینی باینری است. ورودی‌های سیگنال حوزه زمان و دامنه فرکانس و تنوع ورودی برای LTE و سیستم‌های 5G می‌باشد.

## ۵-نتیجه‌گیری

در این مقاله، رویکردی مبتنی بر شبکه عصبی ترکیبی LSTM-CNN برای تخمین پروفایل کانال و نسبت سیگنال به نویز در سیستم‌های LTE و 5G ارائه شد. مدل پیشنهادی با استفاده از داده‌های متنوع ورودی شامل پارامترهای زمانی و فرکانسی، توانست به دقت بالایی در تخمین پروفایل کانال دست یابد و خطای میانگین مربعات نرمالیزه را به طور قابل توجهی کاهش دهد. نتایج به دست آمده نشان‌دهنده پایداری و کارایی مدل در شرایط نویزی مختلف و محیط‌های پیچیده بی‌سیم است. علاوه بر این، مدل توانست در تخمین سیگنال به نویز نیز عملکرد موفقی داشته باشد، به طوری که در تمامی حالات آزمایش شده، دقت تخمین در محدوده‌های فرکانسی مختلف بالا بود. همچنین در پیش‌بینی باینری (دو کلاس مختلف) برای پروفایل کانال، مدل پیشنهادی توانست به دقت قابل توجهی دست یابد و الگوهای پیچیده سیگنال‌های دریافتی را به درستی تشخیص دهد. این نشان می‌دهد که رویکرد ما توانایی خوبی در دسته‌بندی سیگنال‌ها و کاهش خطاهای طبقه‌بندی دارد. مقایسه نتایج با مدل‌های دیگر نشان داد که رویکرد ترکیبی LSTM-CNN در

- [27] X. Liu, Y. Zhang, and G. Wu, "Machine Learning for Wireless Communications: A Comprehensive Survey," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 2, pp. 979-1002, Secondquarter 2022.
- [28] D. R. Adhikari, S. Sharma, and N. D. Kumar, "The Role of Deep Learning in Wireless Networks: A Survey," *IEEE Access*, vol. 10, pp. 323-339, 2022.
- [29] F. A. Abdi, S. K. Kumar, and H. F. Khan, "Emerging Applications of AI in Wireless Networks," *IEEE Access*, vol. 10, pp. 1556-1571, 2022.
- [30] H. L. Van Trees, "Detection, Estimation, and Modulation Theory, Part I," New York: Wiley-Interscience, 2001.
- [31] S. M. Kay, "Fundamentals of Statistical Signal Processing: Estimation Theory," Upper Saddle River, NJ: Prentice Hall, 1993.
- [32] A. H. Sayed, "Adaptive Filters," New York: Wiley, 2008.
- [33] H. L. Van Trees, "Detection, Estimation, and Modulation Theory, Part I," New York: Wiley-Interscience, 2001.
- [34] P. Stoica and R. Moses, "Spectral Analysis of Signals," Upper Saddle River, NJ: Prentice Hall, 2005.
- [35] Z. Wang, H. Zhang, H. Xie, Y. Yang, and J. Tang, "A comprehensive survey on CNN-LSTM based deep learning models for time series forecasting," *J. Mach. Learn. Res.*, vol. 23, pp. 1-36, 2022.
- [36] Y. Zhang, Y. Liu, and H. Li, "Human activity recognition using CNN-LSTM hybrid networks for real-time data streams," *Pattern Recognit. Lett.*, vol. 152, pp. 31-38, 2022.
- [37] J. Chen, M. Gao, and Y. Zhou, "An enhanced CNN-LSTM hybrid model for stock market prediction with attention mechanism," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 34, no. 4, pp. 1597-1609, Apr. 2023.
- [38] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Proc. 25th Int. Conf. Neural Inf. Process. Syst.*, Lake Tahoe, NV, USA, 2012, pp. 1097-1105.
- [39] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, pp. 436-444, 2015.
- [40] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, Cambridge, MA: MIT Press, 2016.
- [16] M. Rahman, M. S. M. A. H. M. Haris, and K. F. A. S. Khodari, "A Novel Machine Learning-Based Approach for Optimal Resource Allocation in 5G Networks," *IEEE Access*, vol. 9, pp. 10224-10234, 2021.
- [17] S. Kumari, R. D. Alshahrani, A. A. Alshehri, and M. A. Qader, "A Survey on Artificial Intelligence Techniques in Wireless Communication Systems," *IEEE Access*, vol. 9, pp. 25715-25741, 2021.
- [18] A. Kumar, K. S. Alavi, and A. Abouzeid, "Reinforcement Learning for Future Wireless Networks: A Survey," *IEEE Access*, vol. 9, pp. 67909-67927, 2021.
- [19] Z. Wei, J. Li, and C. Shen, "Deep Learning Based Channel Estimation for mmWave Massive MIMO Systems," *IEEE Transactions on Wireless Communications*, vol. 20, no. 1, pp. 50-63, Jan. 2021.
- [20] T. S. H. N. A. M. Saad, S. M. A. R. B. A. Rahman, and N. M. Shafiee, "Deep Learning Techniques for Wireless Networks: A Comprehensive Survey," *IEEE Access*, vol. 9, pp. 89969-89989, 2021.
- [21] N. M. J. K. Ali, M. N. A. K. Mohd, and I. A. A. Rahman, "Deep Learning Based Approaches for Massive MIMO Channel Estimation," *IEEE Access*, vol. 9, pp. 138401-138418, 2021.
- [22] H. Y. S. B. H. Alahmadi, A. H. A. M. A. Rahman, and M. M. N. A. F. Alshahrani, "An Overview of Machine Learning Applications in Wireless Communications," *IEEE Access*, vol. 10, pp. 1559-1571, 2022.
- [23] S. H. Lee, J. Kim, and D. Lee, "Machine Learning for Wireless Networks: A Survey on the Current Trends," *IEEE Access*, vol. 10, pp. 147-162, 2022.
- [24] Zhang, W. Yang, Y. Zhang, and S. Chen, "Machine Learning-Based Optimization for Wireless Communication: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 1, pp. 105-123, Firstquarter 2022.
- [25] H. Yang, A. Alkhateeb, and G. Y. Li, "A Survey on Deep Learning for 6G Wireless Networks," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 3, pp. 1300-1328, Thirdquarter 2022.
- [26] C. Liu, H. Zhu, and J. Liu, "Machine Learning for Next Generation Wireless Networks: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 4, pp. 2223-2249, Fourthquarter 2022.