



شبکه‌ی عصبی آگاه از فیزیک برای تخمین کانال مقاوم در برابر داپلر کسری در سیستم‌های OTFS راه آهن پرسرعت

رضا مرادی

دانشجوی کارشناسی ارشد، مجتمع برق، جنگال و مهندسی سایبرنتیک، دانشگاه مالک اشتر تهران
ebnemoljem.moradi@gmail.com

محمد حسین مدنی

استاد، مجتمع برق، جنگال و مهندسی سایبرنتیک، دانشگاه مالک اشتر تهران
madani1355@yahoo.com

چکیده

ارتباطات راه آهن پرسرعت (HSR) یکی از سناریوهای کلیدی در شبکه‌های نسل ششم (6G) محسوب می‌شود که نیازمند انتقال قابل اطمینان داده در سرعت‌های بالای ۵۰۰ کیلومتر بر ساعت است. مدولاسیون حوزه‌ی تأخیر-داپلر متعامد (OTFS) به عنوان یک شکل موج امیدوارکننده برای مقابله با محو شدگی دوگانه انتخابی ناشی از تحرک بالا مطرح شده است. با این حال، پدیده‌ی داپلر کسری باعث نشت انرژی در حوزه‌ی تأخیر-داپلر شده و دقت تخمین کانال را به شدت کاهش می‌دهد. روش‌های سنتی مبتنی بر شبکه بندی ثابت و نیز رویکردهای یادگیری عمیق صرفاً داده محور، به ترتیب از محدودیت‌های دقت و تعمیم پذیری رنج می‌برند. در این مقاله، یک چارچوب شبکه‌ی عصبی آگاه از فیزیک (PINN) برای تخمین کانال مقاوم در برابر داپلر کسری در سیستم‌های OTFS ریلی پرسرعت پیشنهاد می‌شود. معماری پیشنهادی با تلفیق یک شبکه‌ی عصبی عمیق، یک لایه‌ی تصحیح فیزیکی و یک تابع هزینه‌ی چندمؤلفه‌ای، قیود فیزیکی شامل محدوده‌ی داپلر، پایستگی انرژی، پراکندگی تأخیر-داپلر و پیوستگی زمانی را در فرآیند آموزش شبکه درونیابی می‌کند. این رویکرد، ضمن حفظ تفسیرپذیری فیزیکی، نیاز به داده‌های آموزشی را به شدت کاهش می‌دهد. نتایج شبیه سازی نشان می‌دهند که روش پیشنهادی در مقایسه با روش‌های پیشرفته‌ی موجود، بهبودی حدود ۱۰ تا ۵۰ برابری در دقت تخمین ارائه می‌دهد، تعداد راهنماهای مورد نیاز را تا ۷۰٪ کاهش می‌دهد، مقاومت استثنایی در برابر داپلر کسری از خود نشان می‌دهد و با تنها ۵٪ داده‌های آموزشی به عملکرد قابل قبولی دست می‌یابد. این مزایا، چارچوب پیشنهادی را به عنوان یک راه حل کارآمد و عملی برای تخمین کانال در ارتباطات راه آهن پرسرعت نسل آینده معرفی می‌کند.

واژگان کلیدی: OTFS، داپلر کسری، تخمین کانال، شبکه‌های عصبی آگاه از فیزیک (PINN)، راه آهن پرسرعت، یادگیری با نمونه‌های محدود.

مقدمه

نسل ششم (6G) ارتباطات بی سیم، چشم انداز اتصال همگانی را در سناریوهای گوناگون از جمله راه آهن پرسرعت^۱ (HSR)، ماهواره های مدار پایین^۲ (LEO)، خودرو به همه چیز^۳ (V2X) و پهپادها ترسیم می کند (Cheng et al., 2018). در این میان، ارتباط قطار به زمین در HSR برای ایمنی، بهره وری و تجربه مسافران حیاتی است (Jiang et al., 2025). این سناریوها به انتقال قابل اطمینان داده در سرعت های بالای ۵۰۰ کیلومتر بر ساعت با نرخ ۱۵۰ مگابیت بر ثانیه نیاز دارند، اما حرکت نسبی شدید باعث تغییرات داپلر قابل توجهی می شود. مدولاسیون OFDM که در 4G و 5G غالب است، به شدت آسیب پذیر است، زیرا انحرافات فرکانسی کوچک قایمیت زیر حامل ها را از بین برده و تداخل بین زیر حامل ها^۴ (ICI) و بین سمبل ها^۵ (ISI) ایجاد می کند (Anonymous, 2025a; Anonymous, 2025b).

برای غلبه بر این محدودیت، مدولاسیون حوزه زمان-فرکانس مکان متعامد^۶ (OTFS) به عنوان شکل موجی متحول کننده برای تحرک پذیری بالا مطرح شده است (Hadani et al., 2017). برخلاف OFDM که در حوزه زمان-فرکانس^۷ (TF) عمل می کند، OTFS سمبل ها را در حوزه تأخیر-داپلر^۸ (DD) مالتی پلکس می کند؛ جایی که کانال ها حتی در تحرک شدید، دارای پراکندگی و رفتار شبه ایستا هستند. این ویژگی به OTFS امکان می دهد تا از تنوع کامل در حوزه TF بهره مند شود و تضمین کند که همه نمادهای DD در یک قاب، محو شدگی یکسانی دارند؛ بنابراین، OTFS برای سیستم های نسل آینده در محیط های محو شدگی دوگانه انتخابی امیدوار کننده است (Anonymous, 2026a).

با وجود استحکام ذاتی OTFS، تخمین دقیق کانال در سناریوهای HSR چالش برانگیز است. گیرنده باید اطلاعات وضعیت کانال (CSI) را دقیق و بی درنگ به دست آورد. یکی از موانع عمده، پدیده داپلر کسری است؛ جایی که تغییرات داپلر مضرب صحیحی از فاصله زیر حامل ها نیست (Litao et al., 2026). برخلاف داپلر صحیح که پراکندگی حوزه DD را حفظ می کند، داپلر کسری نیست انرژی در بین بین های داپلری ایجاد کرده، پراکندگی را از بین برده و تداخل بین داپلری^۹ (IDI) به وجود می آورد که دقت تخمین را به شدت کاهش می دهد (Anonymous, 2025c; Anonymous, 2026b).

تحقیقات گسترده ای برای تخمین کانال OTFS در شرایط داپلر کسری انجام شده است. روش های سنتی مبتنی بر راهنمای درونیابی شده، سمبل های راهنما را در شبکه DD قرار داده و با روش های آستانه ای باز یابی می کنند (Anonymous, 2025d)، اما به دلیل تداخل بین داپلری (IDI) با افت دقت مواجه اند. برای کاهش این مشکل، الگوریتم های مبتنی بر مدل شامل باز یابی پراکنده با آستانه گذاری نرم (FISTA)، کاهش گرادیان هم مختصات، تعقیب انطباقی متعامد (OMP) (Anonymous, 2025e)، یادگیری بیزین پراکنده (SBL) (Anonymous, 2025f) و روش ماتریس پنسپیل پیشنهاد شده اند. حسگری فشرده نیز برای بهره گیری از پراکندگی کانال در حوزه DD با وضوح داپلری بالا استفاده شده است (Anonymous, 2025g). اگرچه این روش ها تضمین نظری دارند، اما به شبکه بندی ثابت گسسته حوزه DD محدود می شوند. روش های برون شبکه ای (OGSBL) برای رفع این محدودیت معرفی شدند، اما از دقت کوانتیزاسیون ناکافی و خطای تقریب تیلور رنج می برند. الگوریتم A&M رویکردی با پیچیدگی پایین برای تخمین تأخیر، داپلر و بهره کسری ارائه می دهد (Anonymous, 2026c). روش های جدیدتر از همبستگی

¹ High-Speed Railway

² Low Earth Orbit

³ Vehicle-to-Everything

⁴ Inter-Carrier Interference

⁵ Inter-Symbol Interference

⁶ Orthogonal Frequency-Division Multiplexing

⁷ Time-Frequency

⁸ Delay-Doppler

⁹ Inter-Doppler Interference

دنباله‌های Zadoff-Chu برای تخمین کانال در حضور داپلر کسری در ارتباطات LEO استفاده می‌کنند (Guo et al., 2023). با این حال، این رویکردها همچنان مدل محور و وابسته به پیش فرض‌های دست ساز هستند. به موازات این تحولات، یادگیری عمیق (DL) در طراحی لایه فیزیکی بی سیم ظهور کرده است. در تخمین کانال OTFS، معماری‌های ResNet با راهنمای درون یابی بهبود قابل توجهی در تحرک بالا نشان داده‌اند (Anonymous, 2025h). شبکه‌های عصبی عمیق (DNN) برای تخمین داپلر کسری توسعه یافته‌اند (Anonymous, 2025i). برای غلبه بر چالش داپلر کسری، طیف گسترده‌ای از رویکردهای یادگیری عمیق توسعه یافته‌اند که هریک از زاویه‌ای به بهبود تخمین کانال در سیستم OTFS می‌پردازند. شبکه‌های گشایش عمیق نظیر PGDA-Net، با نداشت دقیق الگوریتم‌های کاهش گرادیان به لایه‌های شبکه، ضمن حفظ تفسیرپذیری ریاضی، کارایی محاسباتی را افزایش می‌دهند. در ادامه، شبکه AR-Unet با تلفیق معماری Unet و مکانیزم توجه باقیمانده، به طور خاص برای تخمین مقاوم در برابر داپلر کسری طراحی شده است (Lei et al., 2026). در رویکردی موازی، چارچوب‌های PnP با تلفیق انعطاف پذیری روش‌های بهینه سازی کلاسیک و تعمیم پذیری مدل‌های داده محور (Anonymous, 2025j)، و همچنین چارچوب‌های سرتاسری قابل آموزش با ساختار مدولار (Anonymous, 2026d)، عملکرد قابل توجهی را در شرایط داپلر کسری به ثبت رسانده‌اند. از سوی دیگر، روش‌های مبتنی بر یادگیری عمیق نه تنها به کاهش تأخیر محاسباتی تا ۵۵٪ دست یافته‌اند (Anonymous, 2025k)، بلکه شبکه‌های U-Net مجهز به توجه، با تلفیق هوشمندانه تخمین‌های اولیه و توان دریافتی سیگنال، بهبودی بیش از ۵ دسی بل در معیار NMSE ارائه می‌دهند (Anonymous, 2025l). در نهایت، معماری‌های ترکیبی CNN-Transformer نیز برای پیش بینی دقیق کانال‌های پراکنده در شرایط تحرک بالا توسعه یافته‌اند (Anonymous, 2025k).

با وجود این پیشرفت‌ها، روش‌های صرفاً داده محور با محدودیت‌های بنیادین مواجه‌اند: فاقد تفسیرپذیری فیزیکی و لذا به داده‌های آموزشی گسترده نیاز دارند که در HSR هزینه بر است و در شرایط خارج از توزیع (سرعت‌های فوق العاده، توپوگرافی جدید) عملکردشان به شدت تضعیف می‌کند. این شکاف تعمیم پذیری، نگرانی جدی برای سیستم‌های ایمنی-حساس است. شبکه‌های عصبی آگاه از فیزیک^۱ (PINN) راه حلی قانع کننده ارائه می‌دهند که تخمین مبتنی بر مدل و یادگیری عمیق را با بهره گیری از اطلاعات پیشینی محیط ترکیب می‌کند (Goutay et al., 2022). محققان این مفهوم را برای حل معادلات دیفرانسیل جزئی معرفی کردند و سپس به مخابرات بی سیم راه یافت. گوتای و همکاران مدل سازی کانال مبتنی بر PINN را با تعمیم پذیری و تفسیرپذیری بهبود یافته ارائه دادند. پژوهش‌های دیگری PINN را به تخمین کانال MIMO آگاه از محیط با توجه متقابل (Anonymous, 2025l)، تخمین به کمک نقشه‌های RSS تحت محدودیت راهنما، تخمین و آشکارسازی مشترک در FBMC-OQAM، شبکه‌های آگاه از معادله هلمهولتز برای بازسازی نقشه رادیویی و دوقلوهای دیجیتال آگاه از فیزیک برای RIS تعمیم دادند. رویکردهای جدیدتر، PINN را با U-Net و توجه متقابل برای تلفیق تخمین‌ها با RSS ترکیب کرده‌اند (Anonymous, 2025l). این تحقیقات نشان می‌دهند که PINN دارای تعمیم پذیری، تفسیرپذیری و استحکام، به ویژه در سناریوهای با راهنمای محدود است (Goutay et al., 2022).

با این حال، کاربرد PINN در تخمین کانال OTFS تحت داپلر کسری در HSR تقریباً ناشناخته است. چارچوب‌های PINN موجود عمدتاً بر OFDM، MIMO و FBMC متمرکز بوده و به ساختار پراکندگی منحصربه فرد حوزه DD و چالش‌های داپلر کسری در OTFS نپرداخته‌اند. همچنین روش‌های فعلی تخمین کانال OTFS - سنتی، مدل محور یا داده محور - فاقد ادغام اصولی قوانین فیزیکی انتشار هستند که هم تضمین عملکرد و هم تعمیم پذیری فراتر از داده‌های آموزشی را فراهم می‌آورند.

¹ Physics-Informed Neural Networks




مقاله حاضر با ارائه چارچوب شبکه عصبی آگاه از فیزیک و آگاه از داپلر رای تخمین کانال مقاوم در برابر داپلر کسری در سیستم های OTFS ریلی پرسرعت، این شکاف را پر می کند. مشارکت های اصلی عبارتند از:

۱. معماری PINN آگاه از داپلر: طراحی چارچوبی نوین که مدل انتشار فیزیکی کانال های HSR (شامل محو شدگی دوگانه انتخابی، ساختار پراکندگی DD و الگوهای نشت انرژی داپلر کسری) را به عنوان تعدیل ساز در آموزش شبکه درون یابی می کند. این معماری، دانش حوزه ای انتشار امواج را با یادگیری بازنمایی در شبکه های عمیق تلفیق می کند.
۲. تابع هزینه مقید به قیود فیزیکی: تابع هزینه جامعی که قیود متعدد فیزیکی را شامل می شود: (الف) معادله کانال مرتبط کننده نمادهای ارسالی و دریافتی OTFS در حوزه DD، (ب) پایداری انرژی برای تخمین های فیزیکی معقول، (پ) روابط فیزیکی داپلر ناشی از حرکت نسبی قطار و ایستگاه و (ت) تعدیل سازی ترویج دهنده پراکندگی که ساختار ذاتی حوزه DD را حفظ می کند. این قیود تضمین می کنند خروجی شبکه حتی با داده های آموزشی محدود، از سازگاری فیزیکی برخوردار باشد.
۳. قابلیت یادگیری با نمونه های محدود: با بهره گیری از قیود فیزیکی به عنوان سوگیری های استقرار، چارچوب پیشنهادی تخمین دقیق کانال را حتی با داده های آموزشی بسیار محدود امکان پذیر می سازد. این مزیت حیاتی در HSR که جمع آوری داده های جامع در تمام شرایط عملیاتی غیرممکن است، بسیار ارزشمند است. منظم سازی فیزیکی پیچیدگی نمونه ها را کاهش داده و به شبکه امکان تعمیم به شرایط دیده نشده را می دهد.

ساختار مقاله به این ترتیب است: بخش دوم به مدل سازی سیستم و فرمول بندی مسئله اختصاص دارد. بخش سوم معماری شبکه ی عصبی آگاه از فیزیک (PINN) پیشنهادی را تشریح می کند. بخش چهارم نتایج شبیه سازی را ارائه می دهد و بخش پنجم نیز به نتیجه گیری و مسیرهای آینده می پردازد.

مدل سازی سیستم و فرمول بندی مسئله

در این بخش، مدل ریاضی سیستم OTFS در سناریوی راه آهن پرسرعت همراه با اثرات داپلر کسری ارائه می شود. سپس، فرمول بندی مسئله ی تخمین کانال به عنوان یک مسئله ی بهینه سازی با قیود فیزیکی بیان می گردد که مبنای طراحی شبکه ی عصبی آگاه از فیزیک (PINN) در بخش بعدی خواهد بود. شکل ۱، جریان سیگنال را از فرستنده با مدولاسیون OTFS در حوزه DD، از طریق کانال راه آهن پرسرعت با نشت انرژی ناشی از داپلر کسری تا گیرنده و چارچوب PINN پیشنهادی نشان می دهد. چارچوب PINN شامل شبکه ی عصبی عمیق، لایه ی تصحیح فیزیکی و تابع هزینه ی چندمؤلفه ای است و خروجی آن، تخمین کانال ($\hat{H}$) می باشد.



شکل ۱: مدل سیستم مدولاسیون OTFS در سناریوی راه آهن پرسرعت با اثرات داپلر کسری و چارچوب پیشنهادی تخمین کانال مبتنی بر شبکه‌ی عصبی آگاه از فیزیک (PINN)

مدولاسیون OTFS در حوزه‌ی تأخیر-داپلر

سیستم OTFS با یک جفت تبدیل‌های سیمپلکتیک - فوری‌ی متعامد (OTFS) تعریف می‌شود که سمبل‌های حوزه‌ی تأخیر-داپلر را به حوزه‌ی زمان-فرکانس (TF) و سپس به حوزه‌ی زمان نگاشت می‌کند [۵]. یک قاب OTFS شامل N نماد در حوزه‌ی زمان (با فاصله‌ی T) و M زیرحامل در حوزه‌ی فرکانس (با فاصله‌ی Δf) است که در آن $N \times M$ نماد در حوزه‌ی DD قرار می‌گیرند. رابطه‌ی بین حوزه‌ی DD و TF به‌صورت زیر تعریف می‌شود [۶]:

$$X_{TF}[n, m] = \frac{1}{\sqrt{NM}} \sum_{k=0}^{N-1} \sum_{l=0}^{M-1} X_{DD}[k, l] \cdot e^{j2\pi \left(\frac{nk}{N} - \frac{ml}{M} \right)} \quad (1)$$

که در آن $X_{DD}[k, l]$ سمبل در حوزه‌ی DD با اندیس‌های داپلر k و تأخیر l است. پس از اعمال تبدیل فوری‌ی گسسته‌ی معکوس (IDFT) در بعد فرکانس و افزودن پیشوند چرخشی (CP)، سیگنال حوزه‌ی زمان به‌صورت زیر حاصل می‌شود:

$$s(t) = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} X_{TF}[n, m] \cdot g_{tx}(t - nT) \cdot e^{j2\pi m \Delta f (t - nT)} \quad (2)$$

که در آن $g_{tx}(t)$ تابع شکل‌دهی پالس در فرستنده است.

مدل کانال با اثرات داپلر کسری

کانال بی سیم در سناریوی HSR به صورت یک کانال محو شدگی دوگانه انتخابی (زمان-فرکانس) با P مسیر مستقل مدل سازی می شود. پاسخ ضربه‌ی کانال در حوزه‌ی زمان-تأخیر به صورت زیر بیان می گردد (Jiang et al., 2025):

$$h(\tau, \nu) = \sum_{i=1}^P h_i \cdot \delta(\tau - \tau_i) \cdot \delta(\nu - \nu_i) \quad (3)$$

که در آن h_i بهره‌ی مختلط مسیر i -ام با توزیع رایلی یا ریس τ_i تأخیر مسیر i -ام، ν_i تغییر فرکانس داپلر مسیر i -ام است. تغییر فرکانس داپلر ناشی از حرکت نسبی قطار با سرعت v نسبت به ایستگاه زمینی به صورت زیر محاسبه می شود [۷]:

$$\nu_i = \frac{v \cdot f_c}{c} \cdot \cos(\theta_i) \quad (4)$$

که در آن f_c فرکانس حامل، c سرعت نور و θ_i زاویه‌ی ورود مسیر i -ام است. پس از نمونه برداری در حوزه‌ی DD، تغییرات داپلر به صورت گسسته‌ی نرمال شده به صورت زیر نمایش داده می شوند:

$$\tilde{\nu}_i = \frac{\nu_i}{\Delta f} = \alpha_i + \beta_i \quad (5)$$

که در آن $\alpha_i \in \square$ جزء صحیح داپلر و $\beta_i \in (-0.5, 0.5)$ جزء کسری داپلر است.

تأثیر داپلر کسری: در حالت ایده‌آل با داپلر صحیح ($\beta_i = 0$)، ماتریس کانال در حوزه‌ی DD یک ماتریس پراکنده با درونیایی‌های غیرصفر محدود است؛ اما در حضور داپلر کسری ($\beta_i \neq 0$)، نشت انرژی در بین تمامی بین‌های داپلری رخ می دهد و ساختار پراکندگی از بین می رود [۸]. ماتریس کانال در حوزه‌ی DD به صورت زیر قابل بیان است (Anonymous, 2026b):

$$\mathbf{H}_{DD} = \sum_{i=1}^P h_i \cdot \Delta_{\tau_i} \otimes \Delta_{\nu_i} \quad (6)$$

که در آن Δ_{τ_i} ماتریس جابه‌جایی تأخیر و Δ_{ν_i} ماتریس جابه‌جایی داپلر است. برای داپلر کسری، ماتریس Δ_{ν_i} به صورت یک ماتریس چرخشی کامل^۱ با درونیایی‌های غیرصفر در تمامی سطرها و ستون‌ها ظاهر می شود که همان نشت انرژی را نشان می دهد.

رابطه‌ی ورودی-خروجی در حوزه‌ی DD

با در نظر گرفتن کانال فوق، رابطه‌ی بین نمادهای ارسالی و دریافتی در حوزه‌ی DD به صورت زیر نوشته می شود (Anonymous, 2025g):

$$\mathbf{Y}_{DD} = \mathbf{H}_{eff} \cdot \mathbf{X}_{DD} + \mathbf{W} \quad (7)$$

¹ Full-circulant

که در آن $\mathbf{Y}_{DD} \in \mathbb{C}^{NM \times 1}$ بردار نمادهای دریافتی (مرتب شده به صورت ستونی)، $\mathbf{X}_{DD} \in \mathbb{C}^{NM \times 1}$ بردار نمادهای ارسالی، $\mathbf{W} \in \mathbb{C}^{NM \times 1}$ نویز گاوسی سفید افزودنی (AWGN) با توان σ_w^2 ، $\mathbf{H}_{eff} \in \mathbb{C}^{NM \times NM}$ ماتریس کانال مؤثر در حوزه DD که شامل اثرات داپلر صحیح و کسری است و به صورت زیر محاسبه می شود:

$$\mathbf{H}_{eff} = \sum_{i=1}^P h_i \cdot (\mathbf{F}_N \otimes \mathbf{I}_M) \cdot \Delta_{v_i} \cdot (\mathbf{F}_N^H \otimes \mathbf{I}_M) \cdot \Delta_{\tau_i} \quad (8)$$

که در آن $\mathbf{F}_N$ ماتریس تبدیل فوریه گسسته (DFT) با اندازه $N \times N$ است.

فرمول بندی مسئله تخمین کانال با راهنما

در سیستم های OTFS، تخمین کانال معمولاً با قرار دادن سمبل های راهنما (Pilot) در موقعیت های مشخص در شبکه DD انجام می شود. فرض می کنیم که در موقعیت های $\mathbf{P} = \{(k_p, l_p)\}_{p=1}^{N_p}$ سمبل های راهنما با مقدار مشخص قرار داده شده اند. همچنین، برای جلوگیری از تداخل راهنما-داده، بازه هایی (Guard) با مقدار صفر در اطراف راهنماها در نظر گرفته می شود (Anonymous, 2025d).

سیگنال دریافتی در موقعیت های راهنما به صورت زیر است:

$$\mathbf{Y}_{pilot} = \mathbf{H}_{eff}^{(pilot)} \cdot \mathbf{X}_{pilot} + \mathbf{W}_{pilot} \quad (9)$$

که در آن $\mathbf{H}_{eff}^{(pilot)}$ زیرماتریس کانال مربوط به موقعیت های راهنما است. با توجه به پراکندگی کانال، تعداد مسیرهای مؤثر P بسیار کوچکتر از NM است $P \ll NM$.

هدف تخمین کانال، یافتن ماتریس کانال کامل $\mathbf{H}_{eff}$ (یا معادلاً ضرایب $\{h_i, \tau_i, v_i\}_{i=1}^P$) از روی سیگنال دریافتی $\mathbf{Y}_{pilot}$ و سمبل های راهنما $\mathbf{X}_{pilot}$ است. این یک مسئله معکوس^۱ به شدت ill-posed است، به ویژه زمانی که تعداد راهنماها محدود باشد.

قیود فیزیکی حاکم بر کانال

برای غلبه بر ill-imposed مسئله و بهبود تخمین، از قیود فیزیکی زیر استفاده می شود که به عنوان دانش پیشین در شبکه عصبی آگاه از فیزیک درون یابی می شوند (Goutay et al., 2022):

الف) معادله کانال در حوزه DD: تخمین کانال باید رابطه ی ورودی-خروجی را در حوزه DD ارضا کند:

$$\mathbf{R}_1(\mathbf{H}) = \left\| \mathbf{Y}_{pilot} - \mathbf{H} \cdot \mathbf{X}_{pilot} \right\|_2^2 \quad (10)$$

این قیود، تطابق دادهای را تضمین می کند.

¹ Inverse Problem

ب) رابطه‌ی فیزیکی داپلر-زاویه: تغییرات داپلر با زاویه‌ی ورود و سرعت قطار مرتبط است. برای یک قطار با سرعت مشخص v ، داپلر هر مسیر در بازه‌ی $[-v_{\max}, +v_{\max}]$ قرار دارد که $v_{\max} = \frac{vf_c}{c}$. این قید به صورت یک تابع جریمه در تابع هزینه اعمال می‌شود:

$$R_2(\hat{v}) = \sum_{i=1}^P \max(0, |\hat{v}_i| - v_{\max})^2 \quad (11)$$

پ) پایستگی انرژی: توان کل سیگنال دریافتی برابر با توان ارسالی ضربدر بهره‌ی کانال به علاوه‌ی نویز است. این اصل به صورت قید نرم‌افزاری در تابع هزینه اعمال می‌شود:

$$R_3(\mathbf{H}) = \left(E[\|\mathbf{Y}\|^2] - E[\|\mathbf{Y}\|^2] \right)^2 \quad (12)$$

ت) پراکندگی در حوزه‌ی DD: کانال در حوزه‌ی DD دارای ساختار پراکنده است، به‌ویژه در حضور داپلر کسری که باعث نشت انرژی می‌شود اما همچنان تعداد مسیرهای مؤثر محدود است. این قید با تعدیل سازی ℓ_1 یا $\ell_{2,1}$ بر روی ضرایب کانال اعمال می‌شود:

$$R_4(\mathbf{H}) = \|\mathbf{H}\|_1 \quad (13)$$

فرمول‌بندی نهایی مسئله‌ی تخمین با قیود فیزیکی

با ترکیب قیود فوق، مسئله‌ی تخمین کانال به عنوان یک مسئله‌ی بهینه‌سازی با قیود فیزیکی به صورت زیر فرمول‌بندی می‌شود:

$$\mathbf{H}^* = \arg \min_{\mathbf{H}} L_{\text{data}}(\mathbf{H}) + \lambda_1 R_1(\mathbf{H}) + \lambda_2 R_2(\mathbf{H}) + \lambda_3 R_3(\mathbf{H}) + \lambda_4 R_4(\mathbf{H}) \quad (14)$$

که در آن $L_{\text{data}}(\mathbf{H}) = \|\mathbf{Y}_{\text{pilot}} - \mathbf{H} \cdot \mathbf{X}_{\text{pilot}}\|_2^2$ تابع خطای داده، $(\lambda_1, \lambda_2, \lambda_3, \lambda_4)$ ضرایب وزنی برای تعادل بین قیود مختلف، (R_1, R_2, R_3, R_4) به ترتیب قیود تطابق داده، محدوده‌ی داپلر، پایستگی انرژی و پراکندگی هستند.

حل مستقیم این مسئله‌ی بهینه‌سازی با روش‌های کلاسیک به دلیل غیرخطی بودن و ابعاد بالای ماتریس کانال $NM \times NM$ دارای پیچیدگی محاسباتی بالا و بعضاً غیرقابل حل است. به‌ویژه، حضور داپلر کسری باعث می‌شود که ماتریس کانال کاملاً متراکم شود و روش‌های پراکنده‌محور کارایی خود را از دست بدهند (Anonymous, 2025c).

برای غلبه بر این چالش‌ها، در بخش بعدی یک چارچوب شبکه‌ی عصبی آگاه از فیزیک (PINN) پیشنهاد می‌شود که قیود فیزیکی فوق را به عنوان توابع جریمه در تابع هزینه‌ی آموزش شبکه درون‌یابی می‌کند. این رویکرد، توانایی یادگیری الگوهای



پیچیده از داده را با تضمین های فیزیکی ترکیب می نماید و به ویژه در شرایط داده های آموزشی محدود، عملکردی برتر از روش های صرفاً داده محور و مدل-محور ارائه می دهد (Goutay et al., 2022).

معماری شبکه ی عصبی آگاه از فیزیک (PINN) پیشنهادی

در این بخش، چارچوب شبکه ی عصبی آگاه از فیزیک (Physics-Informed Neural Network) برای تخمین کانال مقاوم در برابر داپلر کسری در سیستم های OTFS ریلی پرسرعت ارائه می شود. هدف اصلی، تلفیق هم افزاگرانه ی یادگیری داده محور با قوانین بنیادین فیزیک حاکم بر انتشار امواج است. این تلفیق به شبکه امکان می دهد تا تخمین هایی دقیق، پایدار و قابل تعمیم به شرایط دیده نشده ارائه دهد، به ویژه زمانی که داده های آموزشی محدود هستند (Goutay et al., 2022).

نمای کلی معماری

معماری پیشنهادی از سه مؤلفه ی اصلی تشکیل شده است که به صورت زنجیره ای به یکدیگر متصل می شوند:

۱. شبکه ی عصبی عمیق (DNN): یک شبکه ی پیش خواه با چندین لایه ی پنهان که بردار ویژگی های ورودی را به تخمینی اولیه از پارامترهای کانال (بهره، تأخیر و داپلر) نگاشت می کند.
۲. لایه ی نگاشت فیزیکی: یک لایه ی بدون پارامتر قابل آموزش که تخمین های خام شبکه را با اعمال قیود فیزیکی اصلاح کرده و به فضای معتبر فیزیکی هدایت می کند.
۳. بازسازی ماتریس کانال و محاسبه ی توابع هزینه: با استفاده از پارامترهای اصلاح شده، ماتریس کانال مؤثر بازسازی شده و سپس تابع هزینه ی چندهدفه محاسبه می شود.

ساختار شبکه ی عصبی عمیق

الف) لایه ی ورودی: بردار ورودی شبکه به جای کل قاب OTFS، تنها از سیگنال های دریافت شده در موقعیت های راهنما استفاده می کند تا حجم محاسبات را کاهش دهد. این بردار شامل قسمت حقیقی و موهومی سیگنال دریافتی در موقعیت های راهنما، مختصات موقعیت راهنماها در شبکه ی DD و اطلاعات جانبی شامل سرعت لحظه ای قطار و نسبت سیگنال به نویز تخمینی است. ترکیب این اطلاعات به شبکه کمک می کند تا وابستگی کانال به پارامترهای حرکت را درک کند.

ب) لایه های پنهان: شبکه شامل L لایه ی پنهان با ساختار زیر است:

- لایه های کاملاً متصل: هر لایه دارای d_l نرون با تابع فعال سازی Leaky ReLU است که به دلیل مزیت آن در جلوگیری از مشکل "مرگ نرون ها" انتخاب شده است.

- نرم سازی دسته ای: پس از هر لایه برای تسریع آموزش و کاهش وابستگی به مقاداردهی اولیه اعمال می شود.

- Dropout: با نرخ ۰.۱ تا ۰.۲ برای جلوگیری از بیش برآزش استفاده می شود.

- اتصالات باقیمانده: برای شبکه های با عمق بیشتر، اتصالات باقیمانده به کار می روند تا مشکل محو شدن گرادیان مرتفع گردد.



ج) لایه‌ی خروجی: خروجی شبکه، پارامترهای کانال برای P مسیر مؤثر است که شامل بهره‌ی مختلط (با دو خروجی برای قسمت حقیقی و موهومی)، تأخیر نرمال شده و داپلر نرمال شده می‌باشد. برای تضمین محدوده‌های فیزیکی، از تابع سیگموئید برای تأخیر (خروجی بین صفر و $\tau_{\max}$ و تابع تانژانت هیپربولیک برای داپلر (خروجی بین $-v_{\max}$ و $v_{\max}$ استفاده می‌شود.

لایه‌ی تصحیح فیزیکی

این لایه هیچ پارامتر قابل‌آموزشی ندارد و مجموعه‌ای از عملیات‌های قطعی مبتنی بر قوانین فیزیک را روی خروجی شبکه اعمال می‌کند:

الف) اعمال محدوده‌ی داپلر: با توجه به سرعت لحظه‌ای قطار v ، حداکثر داپلر $v_{\max} = \frac{vf_c}{c}$ محاسبه شده و داپلرهای تخمینی به این بازه محدود می‌شوند:

$$\hat{v}_i^{(\text{phys})} = \text{clip}(\hat{v}_i, -v_{\max}, +v_{\max}) \quad (15)$$

ب) مرتب‌سازی و انتخاب مسیرهای مؤثر: مسیرها بر اساس توان $|\hat{h}_i|^2$ مرتب‌سازی شده و مسیرهایی با توان کمتر از آستانه حذف می‌شوند تا ساختار پراکنده‌ی کانال حفظ گردد.

ج) نرم‌سازی بهره‌ها برای پایستگی انرژی: بهره‌ها نرم‌سازی می‌شوند تا توان کل کانال با توان واقعی سیگنال دریافتی مطابقت داشته باشد:

$$\hat{h}_i^{(\text{phys})} = \hat{h}_i \cdot \frac{\sqrt{\mathbb{E}[\|\mathbf{Y}_{\text{pilot}}\|^2]}}{\sqrt{\sum_{j=1}^P |\hat{h}_j|^2 + \sigma_w^2}} \quad (16)$$

د) بازسازی ماتریس کانال: با استفاده از پارامترهای اصلاح شده و تبدیل‌های استاندارد حوزه‌ی DD، ماتریس کانال مؤثر بازسازی می‌شود:

$$\mathbf{H}_{\text{eff}} = \sum_{i=1}^P \hat{h}_i^{(\text{phys})} \cdot (\mathbf{F}_N \otimes \mathbf{I}_M) \cdot \Delta_{\hat{v}_i} \cdot (\mathbf{F}_N^H \otimes \mathbf{I}_M) \cdot \Delta_{\hat{\tau}_i} \quad (17)$$

تابع هزینه‌ی چندهدفه

تابع هزینه‌ی کل شبکه از ترکیب وزنی پنج مؤلفه تشکیل شده است که هر کدام هدف مشخصی را دنبال می‌کنند:

$$\mathbf{L}_{\text{total}} = \mathbf{L}_{\text{data}} + \lambda_1 \mathbf{L}_{\text{physics}} + \lambda_2 \mathbf{L}_{\text{sparsity}} + \lambda_3 \mathbf{L}_{\text{energy}} + \lambda_4 \mathbf{L}_{\text{smooth}} \quad (18)$$

الف) خطای داده: اصلی‌ترین مؤلفه که تطابق تخمین کانال با مشاهدات را تضمین می‌کند. این مؤلفه، میانگین مربعات قدرمطلق اختلاف بین سیگنال دریافتی واقعی و سیگنال بازسازی شده از روی ماتریس کانال تخمینی را اندازه‌گیری می‌کند:



$$L_{\text{data}} = \frac{1}{N_p} \sum_{p=1}^{N_p} \left| Y_p - \mathbf{H}_{\text{eff}}^{(p)} \cdot X_p \right|^2 \quad (19)$$

ب) خطای فیزیکی داپلر: این مؤلفه، تخمین‌های داپلر را که خارج از محدوده‌ی مجاز بر اساس سرعت قطار قرار گرفته‌اند، جریمه می‌کند:

$$L_{\text{physics}} = \frac{1}{P} \sum_{i=1}^P \max(0, |\hat{v}_i| - v_{\text{max}})^2 \quad (20)$$

استفاده از تابع حداکثر باعث می‌شود تنها داپلرهای خارج از محدوده جریمه شوند.

ج) خطای پراکندگی: با توجه به ساختار پراکنده‌ی کانال در حوزه‌ی DD، این مؤلفه مجموع قدرمطلق بهره‌ها و داپلرها را جریمه می‌کند تا شبکه تمایل به یافتن مسیرهای مؤثر کمتر داشته باشد:

$$L_{\text{sparsity}} = \frac{1}{P} \sum_{i=1}^P \left(|\hat{h}_i| + \delta |\hat{v}_i| \right) \quad (21)$$

که در آن δ یک ضریب کوچک برای تنظیم اهمیت نسبی داپلر است.

د) خطای پایستگی انرژی: این مؤلفه اختلاف بین توان سیگنال دریافتی واقعی و توان سیگنال بازسازی‌شده را جریمه می‌کند:

$$L_{\text{energy}} = \left(\frac{1}{N_p} \sum_{p=1}^{N_p} |\hat{Y}_p|^2 - \frac{1}{N_p} \sum_{p=1}^{N_p} |Y_p|^2 \right)^2 \quad (22)$$

ه) خطای پیوستگی زمانی: این مؤلفه برای کاربردهای واقعی که کانال به‌صورت پیوسته در حال تغییر است، طراحی شده و تغییرات داپلر بین قاب‌های متوالی را جریمه می‌کند:

$$L_{\text{smooth}} = \frac{1}{P} \sum_{i=1}^P |\hat{v}_i(t) - \hat{v}_i(t-1)|^2 \quad (23)$$

ضرایب وزنی $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ با استفاده از روش جستجوی شبکه‌ای روی مجموعه‌ی اعتبارسنجی تنظیم می‌شوند.

شبکه‌ی عصبی عمیق مورد استفاده در چارچوب PINN پیشنهادی، شامل یک لایه‌ی ورودی، تعداد L لایه‌ی پنهان با اتصالات باقیمانده و یک لایه‌ی خروجی است. جدول ۱، جزئیات کامل هر لایه از جمله نوع لایه، ابعاد ورودی و خروجی، تعداد پارامترهای قابل آموزش، تابع فعال‌سازی و توضیحات تکمیلی را به‌صورت شماتیک ارائه می‌دهد. این معماری به‌گونه‌ای طراحی شده است که ضمن کاهش حجم محاسبات با استفاده از تنها سیگنال‌های راهنما، با بهره‌گیری از تکنیک‌های نرم‌سازی دسته‌ای، Dropout و اتصالات باقیمانده، از بیش‌برازش جلوگیری کرده و آموزش شبکه‌های عمیق را پایدار می‌سازد. در لایه‌ی خروجی، از توابع فعال‌سازی متفاوتی برای تضمین قرارگیری پارامترهای تخمینی در محدوده‌های فیزیکی معتبر استفاده شده است.

استراتژی آموزش شبکه



الف) تولید داده‌های آموزشی: داده‌های آموزشی با شبیه‌سازی کانال‌های ریلی پرسرعت در فرکانس باند میلی‌متری (۲۸ گیگاهرتز) تولید می‌شوند. سرعت قطار در بازه‌ی ۱۰۰ تا ۵۰۰ کیلومتر بر ساعت، تعداد مسیرها بین ۲ تا ۶، نسبت سیگنال به نویز در بازه‌ی ۰ تا ۳۰ دسی‌بل و جزء کسری داپلر به‌صورت یکنواخت در بازه‌ی (۰.۵، ۰) انتخاب می‌شود تا شبکه با انواع مختلف نشت انرژی آشنا گردد [۲، ۸]. مجموعه‌ی داده به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تقسیم می‌شود.

ب) پیش‌پردازش داده: تمام ورودی‌ها پیش از ورود به شبکه با روش Z-Score نرم‌سازی می‌شوند تا میانگین صفر و واریانس واحد داشته باشند.

ج) الگوریتم بهینه‌سازی: از بهینه‌ساز Adam با نرخ یادگیری اولیه‌ی $\eta = 10^{-3}$ استفاده می‌شود که در طول دوره‌های آموزش به‌صورت نمایی کاهش می‌یابد. اندازه‌ی بچ بین ۳۲ تا ۱۲۸ و تعداد دوره‌ها ۵۰۰ تا ۱۰۰۰ در نظر گرفته می‌شود. برای جلوگیری از آموزش بیش از حد، از تکنیک توقف زودهنگام بر اساس عملکرد مجموعه‌ی اعتبارسنجی استفاده می‌شود.

جدول ۱: معماری شبکه‌ی عصبی عمیق مبتنی بر PINN پیشنهادی.

Layer	Layer Type	Input Dimension	Output Dimension	Activation Function
Input	Dense (Fully Connected)	$2N_p + 4$	d_1	Leaky ReLU
Hidden 1	Dense (Fully Connected) + BN + Dropout	d_1	d_2	Leaky ReLU
Hidden 2	Dense (Fully Connected) + BN + Dropout	d_2	d_3	Leaky ReLU
Hidden 3	Dense (Fully Connected) + BN + Dropout	d_3	d_4	Leaky ReLU
Hidden 4	Dense (Fully Connected) + BN + Dropout	d_4	d_5	Leaky ReLU
...	(more hidden layers as ... needed)	...	...	Leaky ReLU
Hidden L	Dense (Fully Connected) + BN + Dropout	d_{L-1}	d_L	Leaky ReLU
Output (Gain - Real)	Dense (Fully Connected)	d_L	P	Linear



Output (Gain - Imag)	Dense (Fully Connected)	d_L	P	Linear
Output (Delay)	Dense (Fully Connected)	d_L	P	Sigmoid
Output (Doppler)	Dense (Fully Connected)	d_L	P	Tanh

نتایج شبیه سازی

تنظیمات شبیه سازی


شبیه سازی ها بر اساس مدولاسیون OTFS با پارامترهای زیر انجام شده است. فرکانس حامل ۲۸ گیگاهرتز (باند میلی متری)، تعداد زیر حامل ها $M = 64$ ، تعداد نمادهای زمانی $N = 16$ و فاصله ی زیر حامل ها $\Delta f = 15$ کیلوهرتز در نظر گرفته شده است. سرعت قطار در بازه ی ۱۰۰ تا ۵۰۰ کیلومتر بر ساعت، تعداد مسیرهای مؤثر کانال $P = 4$ و جزء کسری داپلر β به صورت یکنواخت در بازه ی (۰.۵، -۰.۵) انتخاب می شود.

روش پیشنهادی (PINN) با پنج روش پیشرفته مقایسه شده است: SBL (Anonymous, 2025f)، OGSBL (Jiang et al., 2025)، AR-Unet (Lei et al., 2026) و DNN (Anonymous, 2025i). معیار اصلی ارزیابی، خطای میانگین مربعات نرمال شده (NMSE) است.

نتایج و بحث

الف) مقایسه ی عملکرد بر حسب نسبت سیگنال به نویز


همان طور که در شکل ۲ مشاهده می شود، عملکرد همه ی روش ها با افزایش نسبت سیگنال به نویز (SNR) بهبود می یابد. روش OMP با افزایش SNR به یک خطای اشباع می رسد که به دلیل وابستگی ذاتی این روش به شبکه بندی ثابت حوزه ی DD است و نمی تواند داپلرهای کسری را به خوبی مدل سازی کند. روش های SBL و OGSBL عملکرد بهتری از خود نشان می دهند و در سطوح بالای SNR به دقت قابل قبولی دست می یابند. روش AR-Unet به عنوان یک روش یادگیری عمیق داده محور، عملکرد بسیار خوبی ارائه می دهد و از روش های مبتنی بر مدل پیشی می گیرد. با این حال، روش پیشنهادی PINN بهترین عملکرد را در تمامی محدوده های SNR ارائه می دهد و بهبود چشمگیری نسبت به سایر روش ها دارد. شیب تندتر منحنی PINN نشان دهنده ی بهره وری بالاتر این روش از افزایش توان سیگنال است؛ به گونه ای که با افزایش SNR، دقت تخمین آن به مراتب سریع تر از سایر روش ها بهبود می یابد.



شکل ۲: مقایسه‌ی NMSE بر حسب SNR ($\beta=0.3$, $P=4$, $N_p = 16$)

(ب) تأثیر تعداد سیگنال‌های راهنما بر عملکرد


شکل ۳ تأثیر تعداد راهنما را بر دقت تخمین کانال در SNR ثابت نشان می‌دهد. روش OMP با افزایش تعداد راهنما بهبود محدودی نشان می‌دهد و حتی با تعداد زیادی راهنما نیز به دقت مطلوب نمی‌رسد. روش‌های SBL و OGSBL با افزایش راهنماها بهبود قابل توجهی دارند، اما همچنان به تعداد زیادی راهنما نیازمندند. روش AR-Unet با تعداد متوسطی از راهنماها به اشباع می‌رسد و افزایش بیشتر تأثیر چشمگیری بر دقت آن ندارد. روش پیشنهادی PINN با تعداد بسیار کمی راهنما (حدود یک‌سوم تعداد راهنماهای مورد نیاز سایر روش‌ها) به دقتی معادل بهترین عملکرد روش‌های رقیب دست می‌یابد. این بدان معناست که روش پیشنهادی می‌تواند تعداد راهنماهای مورد نیاز را به‌طور چشمگیری کاهش دهد و در نتیجه بازده طیفی را به‌شدت افزایش دهد. با افزایش بیشتر تعداد راهنماها، PINN همچنان از سایر روش‌ها پیشی می‌گیرد و بهبودی چندین برابری نسبت به بهترین روش رقیب ارائه می‌دهد.



شکل ۳: مقایسه‌ی NMSE بر حسب تعداد راهنماها ($\beta=0.3$, $P=4$, dB SNR=15)

(ج) مقاومت در برابر داپلر کسری


شکل ۴ تأثیر جزء کسری داپلر (β) را بر عملکرد روش‌های مختلف نشان می‌دهد. در حالت داپلر صحیح ($\beta=0$)، همه‌ی روش‌ها عملکرد نسبتاً خوبی دارند، اما با افزایش β و نزدیک شدن به بیشینه‌ی مقدار کسری، عملکرد روش‌های سنتی به شدت تخریب می‌شود. روش OMP بیشترین حساسیت را به داپلر کسری نشان می‌دهد و خطای آن تا چندین ده برابر افزایش می‌یابد. روش‌های SBL و OGSBL نیز تخریب قابل توجهی دارند، هرچند با شیب کمتری نسبت به OMP. روش AR-Unet که بر پایه‌ی یادگیری عمیق طراحی شده است، مقاومت نسبتاً خوبی در برابر داپلر کسری نشان می‌دهد، اما همچنان منحنی آن شیب قابل توجهی دارد. در مقابل، روش پیشنهادی PINN به وضوح مقاوم‌ترین روش است و افزایش خطای آن در بدترین حالت داپلر کسری، بسیار ناچیز و در حد کسری از افزایش خطای سایر روش‌هاست. نکته‌ی قابل توجه این است که عملکرد PINN حتی در بدترین حالت داپلر کسری، همچنان بهتر از عملکرد AR-Unet در بهترین حالت (داپلر صحیح) است که نشان‌دهنده‌ی قدرت بالای رویکرد آگاه از فیزیک در مدیریت پدیده‌های چالش برانگیز است.



شکل ۴: مقاومت روش‌های مختلف در برابر داپلر کسری ($P=4$ ، $N_p = 16$ ، $SNR=15$)

(د) قابلیت یادگیری با نمونه‌های محدود

شکل ۵، یکی از مهم‌ترین مزیت‌های روش پیشنهادی را نشان می‌دهد: قابلیت یادگیری با نمونه‌های آموزشی بسیار محدود. روش DNN پایه (بدون قیود فیزیکی) به شدت به حجم داده‌های آموزشی وابسته است و با درصد بسیار کمی از داده‌ها، عملکردی بسیار ضعیف دارد. حتی با افزایش داده‌های آموزشی، این روش تا زمانی که به حجم قابل توجهی از داده دست نیابد، عملکرد قابل قبولی از خود نشان نمی‌دهد. روش AR-Unet که از معماری پیشرفته‌تری برخوردار است، وابستگی کمتری به حجم داده نشان می‌دهد، اما همچنان برای دستیابی به دقت بالا به داده‌های آموزشی نسبتاً زیادی نیاز دارد. در مقابل، روش پیشنهادی PINN با درصد بسیار کمی از داده‌های آموزشی (کمتر از یک‌دهم داده‌های مورد نیاز سایر روش‌ها) به دقتی دست می‌یابد که برای بسیاری از کاربردهای عملی کاملاً قابل قبول است. این قابلیت استثنایی به دلیل استفاده از قیود فیزیکی به عنوان دانش پیشین است که نقش یک منظم‌ساز قوی را ایفا کرده و نیاز به داده‌های آموزشی را به شدت کاهش می‌دهد. به عبارت دیگر، PINN با تکیه بر قوانین فیزیک، اطلاعات از دست‌رفته را جبران کرده و حتی با داده‌های اندک نیز تخمینی پایدار و دقیق ارائه می‌دهد.



شکل ۵: قابلیت یادگیری با نمونه‌های محدود ($\beta=0.3$, $P=4$, $N_p=16$, $SNR=15$)

نتیجه گیری

در این مقاله، یک چارچوب شبکه‌ی عصبی آگاه از فیزیک (PINN) برای تخمین کانال مقاوم در برابر داپلر کسری در سیستم‌های OTFS راه‌آهن پرسرعت ارائه شد. معماری پیشنهادی با تلفیق یک شبکه‌ی عصبی عمیق، یک لایه‌ی تصحیح فیزیکی، و یک تابع هزینه‌ی چندمؤلفه‌ای، قیود فیزیکی شامل محدوده‌ی داپلر، پایستگی انرژی، پراکندگی حوزه‌ی DD و همواری زمانی را در فرآیند آموزش شبکه درونیابی می‌کند. این رویکرد ضمن حفظ تفسیرپذیری فیزیکی، نیاز به داده‌های آموزشی را به شدت کاهش می‌دهد.

نتایج شبیه‌سازی نشان داد که روش پیشنهادی در مقایسه با روش‌های پیشرفته‌ی موجود مانند OGSBL، SBL، و AR-Unet، بهبودی حدود ۱۰ تا ۵۰ برابری در دقت تخمین ارائه می‌دهد. همچنین، روش پیشنهادی تعداد راهنماهای مورد نیاز را تا ۷۰٪ کاهش می‌دهد، مقاومت استثنایی در برابر داپلر کسری از خود نشان می‌دهد و با تنها ۵٪ داده‌های آموزشی به عملکرد قابل قبولی دست می‌یابد. این مزایا، چارچوب پیشنهادی را به عنوان یک راه‌حل کارآمد و عملی برای تخمین کانال در ارتباطات راه‌آهن پرسرعت نسل آینده معرفی می‌کند.

برای تحقیقات آینده، گسترش چارچوب پیشنهادی به سیستم‌های MIMO-OTFS با ابعاد بالاتر، استفاده از داده‌های اندازه‌گیری‌شده واقعی از خطوط راه‌آهن برای ارزیابی عملی، و طراحی نسخه‌های سبک‌تر شبکه برای کاهش زمان استنتاج و مناسب‌سازی برای پیاده‌سازی بلادرنگ، پیشنهاد می‌شود. همچنین، ترکیب روش پیشنهادی با تکنیک‌های یادگیری تقویتی برای تنظیم خودکار ضرایب وزنی تابع هزینه و بهبود عملکرد در شرایط متغیر کانال، می‌تواند به عنوان یک جهت تحقیقاتی جذاب دنبال شود.



منابع

- Anonymous. (2025a). Efficient Channel Estimation Utilizing Channel Sparsity in the Delay Domain for OTFS Systems. IEEE Vehicular Technology Conference (VTC). Oslo, Norway. Jun. 2025.
- Anonymous. (2025b). Low-Complexity Channel Estimation in OTFS Systems With Fractional Effects. IEEE Wireless Communications Letters. Vol. 14. No. 10. pp. 3069–3073. Oct. 2025.
- Anonymous. (2025c). Fractional Parameter Estimation and Cramér–Rao Bound for OTFS-Based ISAC Systems. IEEE Transactions on Wireless Communications. Nov. 2025.
- Anonymous. (2025d). Channel Estimation for OTFS using Pilots with Cyclic Prefix in Fractional Doppler Channels. IEEE International Conference on Communications (ICC). Montreal, QC, Canada. Jun. 2025.
- Anonymous. (2025e). Fractional Doppler Impact on OMP Based Multiuser OTFS Channel Estimation. IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Hefei, China. Oct. 2025.
- Anonymous. (2025f). Compress Sensing-based OTFS Channel Estimation: High Doppler Resolution. IEEE International Conference on Communications (ICC). Hong Kong. Jul. 2025.
- Anonymous. (2025g). Correlation Information-Aided Channel Estimation with Fractional Doppler for OTFS-Enabled LEO Satellite Communications. IEEE Global Communications Conference (GLOBECOM). Taipei, Taiwan. Dec. 2025.
- Anonymous. (2025h). Deep Learning-Based Fractional Doppler-Resilient Channel Estimation for OTFS Systems. 2025 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Hefei, China. Oct. 2025.
- Anonymous. (2025i). Deep Learning-based OTFS Channel Estimation and Symbol Detection with Plug-and-Play Framework. IEEE Transactions on Communications. Early Access. Nov. 2025.
- Anonymous. (2025j). Reduced-latency DL-based Fractional Channel Estimation in OTFS Receivers. IEEE International Conference on Communications (ICC). Barcelona, Spain. May 2025.
- Anonymous. (2025k). Hybrid CNN-Transformer Based Sparse Channel Prediction for High-Mobility OTFS Systems. arXiv preprint. Oct. 2025.
- Anonymous. (2025l). Physics-Informed Neural Networks for Wireless Channel Estimation with Limited Pilot Signals. NeurIPS Workshop on Machine Learning for Wireless. Dec. 2025.
- Anonymous. (2026a). ADMM-Based Delay-Doppler Domain Channel Estimation for OTFS Systems. IEEE Transactions on Communications. Jan. 2026.
- Anonymous. (2026b). A&M based fractional delay and Doppler channel estimation in OTFS. npj Wireless Technology. Vol. 2. Article 52. 2026.
- Anonymous. (2026c). ResNet-Based Deep Learning for OTFS Channel Estimation With Pilot Superimposition. IEEE Access. Vol. 14. pp. 66054–66068. Apr. 2026.
- Anonymous. (2026d). Environment-Aware MIMO Channel Estimation in Pilot-Constrained Upper Mid-Band Systems. IEEE International Conference on Communications (ICC). Barcelona, Spain. May 2026.
- Cheng, X. and Liu, D. and Zhu, Z. and Li, S. (2018). A ResNet-DNN based channel estimation and equalization scheme in FBMC/OQAM systems. 2018 10th International Conference on Wireless Communications and Signal Processing (WCSP). Hangzhou, China. 2018. pp. 1–5.
- Goutay, M. and Hoydis, J. and Cammerer, S. and Moura, J. M. F. (2022). Physics-informed neural networks for wireless channel modeling. IEEE Transactions on Wireless Communications. Vol. 21. No. 11. pp. 9245–9257. Nov. 2022.



- Guo, L. and Gu, P. and Zou, J. and Liu, G. and Shu, F. (2023). DNN-Based Fractional Doppler Channel Estimation for OTFS Modulation. *IEEE Transactions on Vehicular Technology*. Vol. 72. No. 11. pp. 15062–15067. Nov. 2023.
- Hadani, R. and Rakib, S. and Tsatsanis, M. and Monk, A. and Goldsmith, A. J. and Molisch, A. F. and Calderbank, R. (2017). Orthogonal time frequency space modulation. *IEEE Wireless Communications and Networking Conference (WCNC)*. San Francisco, CA, USA. 2017. pp. 1–6.
- Jiang, Z. and Liu, K. et al. (2025). Fractional Doppler channel estimation for OTFS high-speed railway train-to-ground communication system. *Physical Communication*. Vol. 72. p. 102788. Oct. 2025.
- Lei, Y. and Liu, Y. and Liu, G. and Wan, L. and Yang, K. (2026). Superimposed-Pilot OTFS Under Fractional Doppler: Modular End-to-End Learning. *arXiv preprint*. arXiv:2601.22523. Jan. 2026.
- Litao, L. and Tang, B. and Chen, Z. and Tang, J. and Wong, K. K. and Chae, C. B. and Zhang, X. Y. (2026). Joint Channel and AoA Estimation in OTFS System with Fractional Doppler Channels. *IEEE Transactions on Vehicular Technology*. 2026 (in press).
- Raissi, M. and Perdikaris, P. and Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*. Vol. 378. pp. 686–707. Feb. 2019.