ITRC
ICT Research Institute
(Iran Telecommunication Research Center)

Journal of Information and Communication Technology

Iranian Society of Information and Communication Technology

Volume …, Issue …, Date …, pp …-…

Fading Channel Classification Using Wavelet Transform and LDA Ensemble Learning Algorithm

Abbass Najafian*, Mohammadali Sebghati**
* M.Sc., ICT Department, Faculty of Engineering, IRIB University, Tehran, Iran
** Faculty Member, ICT Department, Faculty of Engineering, IRIB University, Tehran, Iran

Received: …, Revised: …, Accepted: …
Paper type: …

Abstract

Channel fading is one of the fundamental challenges in wireless communications, for which various solutions have been proposed. Identifying the type of fading is essential for selecting an appropriate mitigation strategy in communication links. Telecommunication channel fading is classified into different categories based on frequency selectivity severity and time-varying characteristics. Channel type detection is a classification problem, where suitable features are first extracted from the channel impulse response (CIR), followed by the application of a classification algorithm. In this paper, we propose a method for classifying fading channels in OFDM systems. The features are extracted from the scalogram obtained by applying the wavelet transform to the CIR, and the channel type is determined using the Linear Discriminant Analysis (LDA) algorithm with ensemble learning via the random subspace method. The wavelet transform is applied to the estimated CIR to approximate real-world conditions, where the channel is estimated using pilot symbols. The proposed method is evaluated for classifying eight simulated channel models, combining four multipath profiles based on the COST207 standard and two Doppler shifts (50 Hz and 200 Hz). Experiments assess the impact of various parameters on classification accuracy. Simulation results indicate that the proposed method achieves an average classification accuracy of 86% at a SNR of 3 dB, representing an improvement of at least 27% over competing methods. Moreover, the proposed method demonstrates greater robustness to increased channel estimation errors resulting from reduced pilot overhead, exhibiting up to 25% less performance degradation than competing methods. This improved robustness is achieved while simultaneously extracting a lower-dimensional feature vector.

Keywords: Fading channel classification, Wavelet transform, Scalogram, Machine learning, OFDM.

دوفصلنامه
فناوری اطلاعات و ارتباطات ایران

سال ... ، شماره ... ، فصل ... ، صفحه ... الی ...

طبقه‌بندی کانال‌های محوشونده با استفاده از تبدیل موجک و الگوریتم یادگیری جمعی مبتنی بر LDA

عباس نجفیان*، محمدعلی سبقتی[1]**

*کارشناس ارشد، دانشگاه صداوسیما، داشکده فنی و مهندسی رسانه

**عضو هیأت علمی، دانشگاه صداوسیما، دانشکده فنی و مهندسی رسانه

تاریخ دریافت: ... تاریخ بازبینی: ... تاریخ پذیرش: ...

نوع مقاله: پژوهشی

چکیده

محوشوندگی کانال یکی از چالش‌های اساسی ارتباطات بی‌سیم است که برای مقابله با آن راه‌حل‌های مختلفی ارائه شده است. شناخت نوع محوشوندگی برای انتخاب راه‌حل مناسب در لینک‌های مخابراتی لازم است. محوشوندگی کانال‌های مخابراتی بر اساس شدّت فرکانس‌گزینی و تغییرات زمانی به صورت‌های مختلف دسته‌بندی می‌شوند. تشخیص نوع کانال یک مسأله طبقه‌بندی است که در آن، ابتدا ویژگی‌های مناسب از پاسخ کانال استخراج می‌شود، سپس الگوریتم طبقه‌بندی روی این ویژگی‌ها اجرا می‌گردد. در این مقاله، روشی برای طبقه‌بندی کانال‌های محوشونده در سیستم OFDM پیشنهاد کرده‌ایم که ویژگی‌ها را از مقیاس‌نگاره حاصل از اعمال تبدیل موجک روی پاسخ کانال استخراج می‌کند و از الگوریتم LDA با یادگیری گروهی به روش زیرفضای تصادفی نوع کانال را تعیین می‌نماید. تبدیل موجک روی تخمین پاسخ کانال اعمال می‌شود تا به شرایط واقعی نزدیک باشیم. پاسخ کانال به کمک پایلوت تخمین زده می‌شود. روش پیشنهادی برای طبقه‌بندی ۸ نوع کانال شبیه‌سازی شده است که نتیجه ترکیب چهار مدل چندمسیره بر اساس استاندارد COST207 و دو شیفت داپلر ۵۰ و ۲۰۰ هرتز است. در آزمایش‌ها تأثیر پارامترهای مختلف روی دقت طبقه‌بندی ارزیابی شده است. نتایج شبیه‌سازی‌ها نشان می‌دهد میانگین دقت طبقه‌بندی با روش پیشنهادی در سیگنال به نویز ۳ دسی‌بل برابر ۸۶ درصد است که نسبت به روش‌های رقیب حداقل ۲۷ درصد بهبود دارد. همچنین عملکرد روش پیشنهادی نسبت به افزایش خطای تخمین کانال در اثر کاهش سربار پایلوت تا ۲۵ درصد کمتر از روش‌های رقیب افت می‌کند، در حالی که بردار ویژگی را با ابعاد کمتری استخراج می‌نماید.

واژگان کلیدی: طبقه‌بندی کانال محوشونده، تبدیل موجک، مقیاس‌نگاره، یادگیری ماشین، OFDM.

[1] نویسنده مسئول: محمدعلی سبقتی sebghati@iribu.ac.ir

۱- مقدمه

پدیده محوشوندگی کانال یکی از چالش‌های مهم در ارتباطات بی-سیم است. با گسترش حوزه‌های ارتباطی در انواع محیط‌های شلوغ و گره‌های متحرک با سرعت بالا، تغییرات پاسخ کانال در زمان و فرکانس شدیدتر می‌شود که تنوّع کانال‌ها را بیشتر می‌کند [۱]. محوشوندگی کانال منجر به افت عملکرد در لینک‌های بی‌سیم می‌شود. برای مقابله با این مشکل، باید اثرات مخرّب کانال جبران شود. در این راستا، اطلاع از نوع کانال برای طراحی و انتخاب تنظیمات مناسب در لینک مؤثر است. بدین ترتیب، به جای طراحی لینک برای بدترین شرایط محوشوندگی، پارامترهای لینک متناسب با نوع محوشوندگی تغییر می‌کند. به این عملیات وفقی‌سازی لینک گفته می‌شود [۲]. پیش‌نیاز لازم برای وفقی‌سازی لینک، طبقه‌بندی کانال مخابراتی است [۳]. به طور سنتی، کانال‌ها با ترکیب دو نوع محوشوندگی تخت و فرکانس‌گزین متناسب با شدت تغییرات فرکانسی و محوشوندگی کند و سریع متناسب با شدت تغییرات زمانی، به چهار نوع تقسیم می‌شوند [۴]. این طبقه‌بندی بر اساس مقایسه پهنای باند همدوسی کانال با پهنای باند سیگنال و زمان همدوسی کانال با زمان ارسال سیگنال صورت می‌گیرد [۵]. امروزه با افزایش تنوّع کانال‌های مخابراتی، مسأله طبقه‌بندی کانال پیچیده‌تر شده است. بدین ترتیب هم تعداد کلاس‌ها افزایش یافته است، هم ویژگی‌های بهتری برای تفکیک کانال‌های نزدیک به یکدیگر لازم است و هم الگوریتم‌های طبقه‌بندی جدید و کارآمدتر ارائه شده است.

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین در حوزه‌های مختلف مخابرات بی‌سیم از جمله طبقه‌بندی کانال مورد توجه قرار گرفته است [۶-۸]. استخراج ویژگی‌های مناسب همراه با الگوریتم طبقه‌بندی کارآمد دقت طبقه‌بندی را افزایش می‌دهد. در پژوهش‌های پیشین، روش‌های مختلفی برای طبقه‌بندی کانال، توسعه یافته است. در [۹]، محیط‌های برودکست در مخابرات فوق پهن‌باند[1] با استفاده از روش SVM[2]، طبقه‌بندی شده است. برای طبقه‌بندی، چهار ویژگی از پاسخ ضربهٔ کانال استخراج می‌شود که عبارت است از: انرژی سیگنال دریافتی، تعداد مسیرهایی که ۸۵ درصد کل انرژی را شامل می‌شوند، مقدار مؤثر تأخیر انتشار و تأخیر اضافی[3]. ترکیب‌های مختلف سه ویژگی انتخاب شده از این گزینه‌ها، بردارهای ویژگی سه بعدی مختلفی را به عنوان ورودی طبقه‌بندی کننده SVM می‌سازد. شرایط این سناریوها شامل یک وضعیت دید مستقیم[4] و سه وضعیت دید غیرمستقیم[5] با درنظر گرفتن اجسامی‌مانند بتن، شیشه و دیوار چوبی است. یک روش جدید برای طبقه‌بندی کانال در شبکه‌های حسگر بی‌سیم در [۱۰] ارائه شده است. این روش از مؤلفه‌های آماری به دست آمده از تابع چگالی احتمال و مشخصات طیف زمان- فرکانس سیگنال دریافتی استفاده می‌کند. سپس ویژگی‌های حاصل شده به طبقه‌بندی کننده KNN[6] داده می‌شود. در پژوهشی که در [۳] ارائه شده است، کانال‌های موجود در لینک‌های 802.11ad توسط طبقه‌بندی کننده جنگل تصادفی به دو دستهٔ LOS و NLOS تقسیم شده‌اند. ویژگی‌های استخراج شده از پاسخ ضربهٔ کانال عبارت است از ضریب K (در محوشوندگی مدل رایس)، مقدار موثر تأخیر انتشار، میانگین تأخیر اضافی، اندازه بهرهٔ تمام ضربه‌های کانال، چهار ضربهٔ بزرگ کانال و ضربهٔ غالب کانال. ضریب K میزان LOS بودن کانال را تعیین می‌کند و برابر است با نسبت انرژی سیگنال در مسیر LOS به انرژی آن در مسیرهای NLOS. کارایی این روش برای یک مسأله طبقه‌بندی باینری ساده که بین دو حالت LOS و NLOS تمایز قائل می‌شود تایید شده است. شبیه‌سازی‌ها نشان می‌دهد که تنها ویژگی تک مقداری یا اسکالری که همواره عملکرد مطمئنی ارائه می‌دهد، میانگین تأخیر اضافی است. در [۱۱]، یک طبقه‌بندی کننده باینری با الگوریتم SVM معرفی شده است که هدف آن، تشخیص سناریوی قطار پرسرعت است. بردار ویژگی انتخاب شده برای طبقه‌بندی، شامل اندازهٔ تخمین فاز و اختلاف فاز است.

استفاده از یادگیری عمیق در طبقه‌بندی کانال رویکرد دیگری است که جذّابیت روزافزون یافته است. Lu و همکاران در زمینه مخابرات فوق پهن باند، یک رویّه دو مرحله‌ای ارائه می‌دهد که یادگیری عمیق را برای طبقه‌بندی کانال و تنظیم نرخ ارسال به کار می‌گیرد [۱۲]. در گام اول، یک طبقه‌بندی کننده بر مبنای شبکه عصبی عمیق، نوع کانال را به دست می‌آورد. در واقع، بردار ویژگی به صورت تحلیلی محاسبه نمی‌شود بلکه شبکهٔ آموزش داده شده، ویژگی‌ها را استخراج می‌کند. دیتاست شامل چهار مدل کانال IEEE 802.15.3a است. در گام دوم، نرخ ارسال بر اساس نوع کانال تنظیم می‌شود. در [۱۳]، یک روش یادگیری عمیق ارائه شده است که از ساختار CNN[7] و LSTM[8] برای طبقه‌بندی کانال‌های LOS و NLOS

[1] Ultra-Wideband (UWB)
[2] Support Vector Machine (SVM)
[3] Excess delay
[4] Line-of-Sight (LOS)
[5] Non-Line-of-Sight (NLOS)
[6] K-Nearest Neighbours (KNN)
[7] Convolutional Neral Network (CNN)
[8] Long-Short Term Memory (LSTM)

استفاده می‌کند. بردار ویژگی‌ها از پاسخ ضربهٔ کانال استخراج شده است و سپس برای طبقه‌بندی کانال‌های فوق پهن‌باند به یک شبکه عصبی CNN-LSTM داده می‌شود. در [۱۴]، سه روش معروف یادگیری ماشین برای طبقه‌بندی کانال‌های بی‌سیم در سیستم OFDM[1] به کار رفته است. این روش‌ها عبارتند از : KNN، SVM و شبکه‌های عصبی. بردار ویژگی شامل اطلاعات حالت کانال است که با استفاده از پایلوت‌ها در زیرحامل‌های برگزیده در حوزه فرکانس به دست می‌آید. در [۱۵]، عملکرد طبقه‌بندی‌کننده‌های مبتنی بر یادگیری ماشین برای کانال‌های 5G و فراتر از 5G با استفاده از ضریب توسعه واریانس بهبود یافته است. مجموعه ویژگی‌ها، شامل متغیرهای مدل کانال از جمله اتلاف مسیر، ضریب K، پراکندگی کانال و گستردگی زاویه‌ای است که اطلاعاتی دربارهٔ هر دو نوع محوشوندگی مقیاس- بزرگ و مقیاس- کوچک می‌دهد. نتایج شبیه‌سازی نشان می‌دهد که در طبقه‌بندی کانال با الگوریتم‌های KNN، SVM، جنگل تصادفی و مدل‌های گوسی، بهبود حاصل شده است. همچنین، با استفاده از تبدیل Chirplet خطی روی دامنه سیگنال که نتیجه آن به یک شبکهٔ CNN داده می‌شود، روشی برای طبقه‌بندی کانال‌های محوشونده معرفی شده است [۱۶].

طبقه‌بندی کانال بر اساس بردار ویژگی‌ها انجام می‌شود، بنابراین استخراج ویژگی نقش حیاتی را در طبقه‌بندی کانال ایفا می‌کند. روش‌های مرسوم برای استخراج تحلیلی ویژگی اغلب در استخراج ویژگی‌های جامع کانال بی‌سیم، مقیاس پذیری محدودی از خود نشان می‌دهند. موضوع بسیار مهم، معرفی ویژگی‌هایی است که بتوانند کانال‌هایی با شباهت‌های نامحسوس را نیز متمایز کنند. بدین منظور رویکردی بر مبنای استخراج ویژگی‌های ظریف با نام اثر انگشت کانال ارائه شده است. برای مثال، استخراج ویژگی در [۱۷] با اعمال یک شبکهٔ عصبی عمیق پیچشی[2] به تصویر طیف‌نگارهٔ[3] کانال انجام می‌شود. در این شبکه از لایه‌های پیچشی برای استخراج ویژگی از تصویر ورودی و از لایهٔ تمام متصل برای طبقه‌بندی استفاده می‌شود. در مقاله [۱۸] یک شبکه عصبی پیچشی برای تفکیک کانال‌های فوق پهن‌باند در استاندارد IEEE 802.15.4a ارائه شده است. مرجع [۱۹] روش متفاوتی را برای استخراج اثر انگشت ارائه کرده است که در آن، وزن‌های شکل‌دهی پرتو[4] به عنوان ویژگی انتخاب می‌شوند.

همانطور که در مرور ادبیات پژوهش مشاهده شد، در روش‌های پیشین، ویژگی‌های طبقه‌بندی به طور مستقیم یا از پاسخ ضربهٔ کانال یا پاسخ فرکانسی کانال یا ترکیبی از هر دو استخراج می‌شوند؛ لذا با افزایش توان نویز که منجر به کاهش دقت تخمین پاسخ کانال می‌شود، قدرت تفکیک‌پذیری این ویژگی‌ها کاهش می‌یابد و در نتیجه دقت طبقه‌بندی افت می‌کند [۲۰]. برای غلبه بر این چالش، ما از تبدیل موجک پیوسته[5] استفاده می‌کنیم، چون قابلیت تحلیل چند-رزولوشنی[6] و تفکیک مؤلفه‌های سیگنال از نویز در مقیاس‌های فرکانسی مختلف را دارد [۲۱]. همچنین در این پژوهش، با استفاده از انحراف معیار ضرایب موجک در طول زمان، تغییرات پاسخ کانال با زمان نیز در ویژگی استخراج شده لحاظ می‌شود تا تفکیک کانال‌های محوشونده سریع و کند از یکدیگر امکان‌پذیر باشد. در روش‌های پیشین، تغییرات پاسخ کانال با زمان در ویژگی‌های استخراج شده لحاظ نمی‌شود و فقط در مرجع [۲۲] که ویژگی‌ها را از طیف زمان-فرکانس استخراج می‌کند، درکنار SNR، شیفت داپلر نیز برای طبقه‌بندی به کار می‌رود. بنابراین نوآوری این مقاله در نحوه استخراج ویژگی‌های طبقه‌بندی از روی CWT است و در الگوریتم طبقه‌بندی تغییری ایجاد نشده است.

در روش پیشنهادی، از اطلاعات زمان-مقیاس حاصل از تبدیل موجک برای تعریف ویژگی‌ها استفاده می‌کنیم. در این روش، تغییرات پاسخ کانال هم متناسب با فرکانس و هم در طول زمان تأثیرگذار است، بنابراین توانایی خوبی برای طبقه‌بندی کانال در شرایط مختلف از جمله شیفت‌های داپلر متنوّع ارائه می‌دهد. بدین منظور دو روش برای ساخت بردار ویژگی پیشنهاد می‌شود. در روش اول با کنار هم قرار دادن تخمین پاسخ فرکانسی کانال در چندین سمبل OFDM که به کمک پایلوت‌ها و درونیابی در سایر زیرحامل‌ها حاصل شده است، طیف‌نگارهٔ پاسخ کانال به دست می‌آید. در روش دوم، با کنار هم قرار دادن پاسخ ضربهٔ کانال و اعمال تبدیل موجک پیوسته، مقیاس‌نگارهٔ[7] پاسخ کانال به دست می‌آید. در هر دو روش، به ترتیب، انحراف معیار فرکانس‌ها و مقیاس‌های مختلف به عنوان بردار ویژگی به طبقه‌بندی کننده اعمال می‌شود. الگوریتم‌های مورد استفاده برای طبقه‌بندی عبارتند از درخت تصمیم[8] و تحلیل تفکیک خطی[9] که به ترتیب از روش‌های یادگیری جمعی Bagging و زیرفضای تصادفی[10] در آنها استفاده شده است.

[1] Orthogonal Frequency Division Multiplexing (OFDM)
[2] Deep Convolutional Neural Network (DCNN)
[3] Spectrogram
[4] Beamforming
[5] Continuous Wavelet Transform (CWT)
[6] Multi-resolution
[7] Scalogram
[8] Decision tree
[9] Linear Discriminant Analysis (LDA)
[10] Random subspace

در بخش دوم مقاله، فرمول‌بندی مسأله به همراه پارامترهای مدل COST207 برای کانال ارائه شده است. در بخش سوم، روش پیشنهادی برای استخراج ویژگی از مقیاس‌نگارهٔ پاسخ کانال به همراه نحوهٔ ساخت دیتاست شرح داده شده است. در بخش چهارم، ساختار شبیه‌سازی لینک و روش پیشنهادی در محیط MATLAB به همراه پارامترهای شبیه‌سازی بیان شده‌است. بخش پنجم به ارائه و بررسی نتایج شبیه‌سازی‌ها و خلاصهٔ این پژوهش می‌پردازد و در بخش ششم نیز جمع‌بندی و نتیجه‌گیری انجام می‌شود.

۲- مدلسازی مسئله

در این بخش، ابتدا ساختار لینک OFDM و چارچوب تخمین پاسخ کانال در آن بیان می‌شود. سپس، کانال‌های انتخاب شده از مدل COST207 برای مسألهٔ طبقه‌بندی معرفی شده‌اند.

۲-۱- فرمول‌بندی

اگر پالسی با مدت زمان محدود در یک کانال محوشونده متغیر با زمان ارسال شود، سیگنال دریافتی به صورت دنباله‌ای از پالس‌ها خواهد بود. بنابراین یک مشخصه کانال محوشونده، گستردگی سیگنال در زمان است. مسأله دیگر، تغییر پاسخ کانال با گذشت زمان به دلیل پویایی محیط انتشار است. بنابراین، اگر ارسال پالس را به صورت مداوم تکرار کنیم، دنبالهٔ پالس‌های دریافتی در گیرنده متفاوت خواهد بود. لذا، می‌توان معادل پایین‌گذر کانال را توسط پاسخ ضربهٔ متغیر با زمان به فرم زیر توصیف کرد [۲۳]:

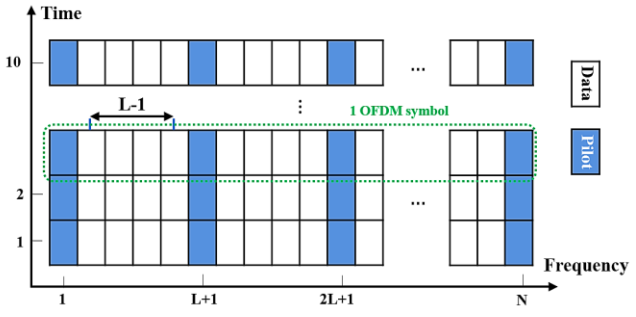
$$c(\tau,t)=\sum_{n}\alpha_n(t)\,e^{-j\omega_c\tau_n(t)}\delta\big(\tau-\tau_n(t)\big) \qquad (۱)$$

در یک سمبل OFDM، زیر حامل‌هایی با دامنه و فاز مشخص که پایلوت نامیده می‌شوند، به منظور تخمین کانال ارسال می‌شوند. در گیرنده، پایلوت‌های دریافتی درون‌یابی و پاسخ فرکانسی کانال تخمین زده می‌شود. برای تخمین پاسخ ضربهٔ کانال، می‌توان از پاسخ فرکانسی تخمینی معکوس تبدیل فوریه گرفت. اگر طول زمانی هر سمبل OFDM برابر T و تعداد سمبل‌های ارسال شده برابر M باشد، تخمینی که m-امین سمبل OFDM از پاسخ ضربهٔ کانال خواهد داشت، معادل پاسخ کانال به ضربهٔ اعمال شده در لحظه mT درنظر گرفته می‌شود که m از 0 تا M-1 متغیر است. همچنین فرض می‌شود که پاسخ کانال به ضربه‌های اعمال شده در لحظه mT، تا T ثانیه بعد معتبر هستند و $T \ll T_c$ که T_c زمان همدوسی کانال است. طول پاسخ ضربه برابر طول پیشوند چرخشی در نظر گرفته می‌شود زیرا برای کاهش ISI[1] در لینک OFDM، طول پیشوند چرخشی به گونه ای تنظیم می‌شود که تمام انعکاس‌های سیگنال دریافتی در آن بازهٔ قرار گیرند. در شبیه‌سازی لینک OFDM با N زیرحامل، پاسخ ضربهٔ تخمین زده شده در هر سمبل دارای N نمونه خواهد بود. اگر N_{cp} تعداد نمونه‌های پیشوند چرخشی باشد، N_{cp} نمونهٔ اول پاسخ ضربه به عنوان پاسخ غالب کانال انتخاب می‌شود. با متصل کردن M پاسخ ضربه به طول N_{cp} به یکدیگر، یک بردار شامل M تخمین از پاسخ ضربه در زمان‌های مختلف به صورت زیر حاصل می‌شود:

$$\hat{h}(n)=\sum_{m=0}^{M-1}\hat{c}_{N_{cp}}\big(n-mN_{cp},m\big)\,; \qquad (۲)$$
$$0\le n\le MN_{cp}-1$$

که در آن $\hat{c}_{N_{cp}}(n,m)$ تخمین پاسخ کانال در سمبل شماره m است و در بازهٔ $0\le n\le N_{cp}-1$ کوتاه شده است. مقیاس‌نگارهٔ پاسخ کانال با اعمال تبدیل موجک پیوسته به بردار $\hat{h}(n)$ به دست می‌آید.

شیوهٔ تخصیص پایلوت‌ها در صفحهٔ زمان- فرکانس در شکل ۱ نمایش داده شده است که به آن چینش بلوکی گفته می‌شود. در هر تحقّق از کانال محوشونده، ۱۰ سمبل OFDM ارسال می‌شود که در هر یک از آنها، پایلوت‌هایی به فاصلهٔ L-1 زیرحامل در حوزه فرکانس وجود دارد. برای تخمین کانال در سمبل‌های فاقد پایلوت، از درونیابی spline استفاده می‌شود. برای عملکرد بهتر این نوع درونیابی، زیرحامل‌های اول و آخر در یک سمبل OFDM پایلوت در نظر گرفته می‌شوند. تأثیر فاصلهٔ پایلوت‌ها، که وابسته به پارامتر L است، بر دقت طبقه‌بندی کانال در بخش نتایج شبیه‌سازی ارائه شده است.



شکل ۱. الگوی شانه‌ای برای تخصیص پایلوت در صفحهٔ زمان-فرکانس

[1] Inter-Symbol Interference (ISI)

۲-۲- مدل‌های کانال محوشونده

در این پژوهش، به منظور شبیه‌سازی کانال‌های محوشونده از مدل‌های استاندارد COST207 استفاده کرده‌ایم که در پژوهش‌های گذشته نیز به کار رفته است [۲۴-۲۸]. این استاندارد شامل مدل‌های چند مسیره برای کانال‌های مخابراتی در نواحی روستایی (RA[۱])، شهری معمولی (TU[۲])، شهری بد (BU[۳]) و تپه ماهور (HT[۴]) است. برای محیط روستایی از مدل ۶ مسیره و برای باقی محیط‌ها از یکی از مدل‌های ۱۲ مسیره برای شبیه‌سازی استفاده شده است. با ترکیب این چهار نوع چندمسیرگی با دو شیفت فرکانسی داپلر ۵۰ و ۲۰۰ هرتز که معرّف کند و سریع بودن محوشوندگی است، ۸ حالت برای کانال‌های محوشونده تشکیل می‌شود که عبارتند از محوشوندگی کند ناحیه روستایی (SRAF[۵])، محوشوندگی سریع ناحیه روستایی (FRAF[۶])، محوشوندگی کند ناحیه معمول شهری (STUF[۷])، محوشوندگی سریع ناحیه معمول شهری (FTUF[۸])، محوشوندگی کند ناحیه بد شهری (SBUF[۹])، محوشوندگی سریع ناحیه بد شهری (FBUF[۱۰])، محوشوندگی کند ناحیه تپه ماهور (SHTF[۱۱]) و محوشوندگی سریع ناحیه تپه ماهور (FHTF[۱۲]). جداول ۱ تا ۴ مشخصات مدل‌های مختلف برای کانال‌های مذکور را نمایش می‌دهند.

تغییرات بهرهٔ هر مسیر نسبت به زمان به ازای شیفت داپلرهای ۵۰ و ۲۰۰ هرتز برای مدل ۶ مسیره، در شکل ۲ نمایش داده شده است. نمودارهای خط پر، بهرهٔ واقعی مسیرها و نمودارهای خط‌چین، بهرهٔ تخمینی را در SNR = 20dB و با استفاده از ۱۰ سمبل OFDM نمایش می‌دهد. فاصلهٔ بین دو پایلوت (L) و تعداد کل زیرحامل‌ها (N) به ترتیب برابر ۱۰ و ۵۱۲ درنظر گرفته شده است.

جدول ۱. تأخیر و بهرهٔ مدل ۶ مسیرهٔ کانال COST207 برای مناطق روستایی

Path No.	Propagation Delay (μs)	Path power (lin.)	(dB)	Delay Spread (μs)
Rural Area: 6-path channel model				
0	0	1	0	0.1
1	0.1	0.4	-4	
2	0.2	0.16	-8	
3	0.3	0.06	-12	
4	0.4	0.03	-16	
5	1.5	0.01	-20	

جدول ۲. تأخیر و بهرهٔ مدل ۱۲ مسیرهٔ کانال COST207 برای مناطق معمول شهری

Path No.	Propagation Delay (μs)	Path power (lin.)	(dB)	Delay Spread (μs)
Typical Urban: 12-path channel model				
0	0	0.4	-4	1
1	0.2	0.5	-3	
2	0.4	1	0	
3	0.6	0.63	-2	
4	0.8	0.5	-3	
5	1.2	0.32	-5	
6	1.4	0.2	-7	
7	1.8	0.32	-5	
8	2.4	0.25	-6	
9	3	0.13	-9	
10	3.2	0.08	-11	
11	5	0.1	-10	

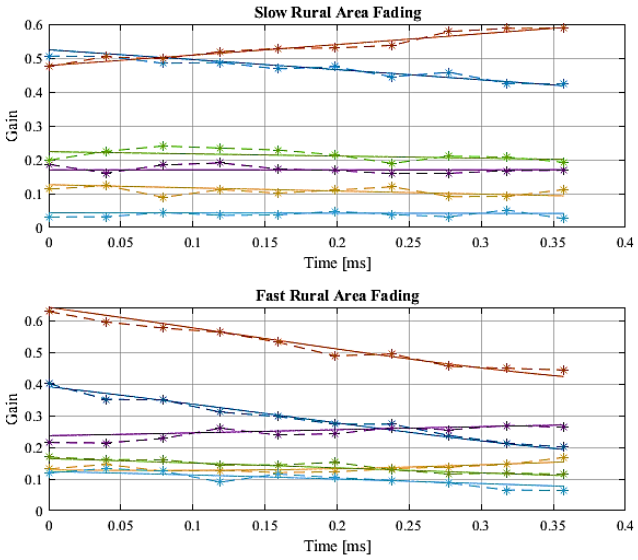
جدول ۳. تأخیر و بهرهٔ مدل ۱۲ مسیرهٔ کانال COST207 برای مناطق بد شهری

Path No.	Propagation Delay (μs)	Path power (lin.)	(dB)	Delay Spread (μs)
Bad Urban: 12-path channel model				
0	0	0.2	-7	2.5
1	0.2	0.5	-3	
2	0.4	0.79	-1	
3	0.8	1	0	
4	1.6	0.5	-2	
5	2.2	0.63	-6	
6	3.2	0.25	-7	
7	5	0.2	-1	
8	6	0.79	-2	
9	7.2	0.2	-7	
10	8.2	0.1	-10	
11	10	0.03	-15	

جدول ۴. تأخیر و بهرهٔ مدل ۱۲ مسیرهٔ کانال COST207 برای مناطق تپه ماهور

Path No.	Propagation Delay (μs)	Path power (lin.)	(dB)	Delay Spread (μs)
Hilly Terrain: 12-path channel model				
0	0	0.1	-10	5
1	0.2	0.16	-8	
2	0.4	0.25	-6	
3	0.6	0.4	-4	
4	0.8	1	0	
5	2	1	0	
6	2.4	0.4	-4	
7	15	0.16	-8	
8	15.2	0.13	-9	
9	15.8	0.1	-10	
10	17.2	0.06	-12	
11	20	0.04	-14	

[1] Rural Area
[2] Typical Urban
[3] Bad Urban
[4] Hilly Terrain
[5] Slow Rural Area Fading
[6] Fast Rural Area Fading
[7] Slow Typical Urban Fading
[8] Fast Typical Urban Fading
[9] Slow Bad Urban Fading
[10] Fast Bad Urban Fading
[11] Slow Hilly Terrain Fading
[12] Fast Hilly Terrain Fading



شکل ۲. تغییرات بهرهٔ مدل ۶ مسیرهٔ کانال COST207 برحسب زمان برای مناطق روستایی

به منظور استخراج ویژگی از روی $\hat{h}(n)$ راهکارهای مختلفی پیشنهاد شده است. به عنوان مثال در [۱۲] از شبکه عصبی و در [۱۶] از تبدیل زمان- فرکانس روی پاسخ کانال استفاده شده است تا ویژگی‌های لازم برای طبقه‌بندی از خروجی این عملیات استخراج شود. هر کانال را استخراج و سپس به طبقه‌بندی کننده اعمال کرد. در ادامه، روش پیشنهادی برای استخراج بردار ویژگی و طبقه‌بندی کانال از روی آن تشریح می‌شود.

۳- استخراج ویژگی و طبقه‌بندی کانال

در این بخش، یک روش جدید برای استخراج ویژگی با استفاده از پاسخ تخمینی کانال ارائه می‌شود. در بردار ویژگی حاصل، تغییرات زمانی پاسخ کانال نیز لحاظ می‌شود تا تعیین محوشوندگی سریع و کند مقدور باشد. در نهایت، روش‌های یادگیری ماشین استفاده شده برای طبقه‌بندی کانال معرفی می‌شوند.

۳-۱- استخراج ویژگی با استفاده از پاسخ کانال

در یک لینک OFDM که تخمین کانال را به کمک پایلوت‌ها انجام می‌دهد، پاسخ فرکانسی کانال در زیرحامل‌های پایلوت به دست می‌آید و سپس با درون‌یابی پاسخ کانال در زیرحامل‌های داده تخمین زده می‌شود. بنابراین در شبیه‌سازی، تخمین پاسخ فرکانسی کانال از روی پایلوت‌های آلوده به نویز و درونیابی نتایج، به کمک روش spline انجام می‌شود. با اعمال IFFT[1] روی پاسخ فرکانسی تخمین زده شده، پاسخ ضربهٔ آن به دست می‌آید. هدف ما استخراج ویژگی‌ها از روی نمایش زمان-مقیاس است. با متصل کردن M پاسخ ضربه به یکدیگر و اعمال تبدیل موجکِ پیوسته، نمایش زمان-مقیاس کانال بدست می‌آید. نمایش زمان-مقیاس کانال با تبدیل موجک پیوسته روی مقیاس‌های گسسته شده به صورت زیر محاسبه می‌شود:

$$C(l,m) = \sum_{n=0}^{MN_{cp}-1} \hat{h}(n)\, 2^{-\frac{l}{\nu}}\, \psi^*\left(\frac{n-m}{2^{\frac{l}{\nu}}}\right) \qquad (۳)$$

$$l = 1,2,\dots,d \quad m = 0,1,\dots,MN_{cp}-1$$

پارامتر ν که VPO[2] نامیده می‌شود، مقداری برای تعیین مقیاس تابع موجک است. این پارامترها نشان می‌دهد برای 2^l برابر شدن مقیاس، تعداد ν مقیاس میانی لازم است. بنابراین VPO که برابر تعداد مقیاس‌های تبدیل موجک است طول بردار ویژگی را تعیین می‌کند. تأثیر پارامتر ν بر دقت طبقه‌بندی در شبیه‌سازی ارزیابی شده است. در نمایش زمان-مقیاس کانال که با $C(l,m)$ نمادگذاری شده‌است، متغیر m و l به ترتیب نشانگر زمان و مقیاس است. برای ساخت بردار ویژگی یک بعدی به طول d از روی ماتریس مقیاس‌نگاره با ابعاد $d \times MN_{cp}$، به نحوی که تغییرات زمانی در آن لحاظ شود، انحراف معیار داده‌های هر مقیاس در طول زمان محاسبه و به عنوان ویژگی آن مقیاس در نظر گرفته می‌شود. با کنارهم قرار دادن انحراف معیار تمام مقیاس‌ها در طول زمان، بردار ویژگی به صورت زیر ساخته می‌شود:

$$FV(l) = \sqrt{\frac{1}{MN_{cp}-1}\sum_{m=0}^{MN_{cp}-1} |C(l,m)-\mu(l)|^2} \qquad (۴)$$

$$k = 1,2,\dots,d$$

که در آن $\mu(l)$ میانگین هر مقیاس در طول زمان برابر است با:

$$\mu(l) = \frac{1}{MN_{cp}} \sum_{m=0}^{MN_{cp}-1} C(l,m) \qquad (۵)$$

دلیل انتخاب انحراف معیار برای استخراج ویژگی از مقیاس‌نگارهٔ کانال این است که برای تفکیک کانال‌ها از منظر تغییرات زمانی، کافی است تغییرات پاسخ کانال را در طول زمان دنبال کنیم. انحراف معیار هر مقیاس نشان می‌دهد که چه مقدار تغییرات حول میانگین

[1] Inverse Fast Fourier Transform (IFFT)

[2] Voices Per Octave (VPO)

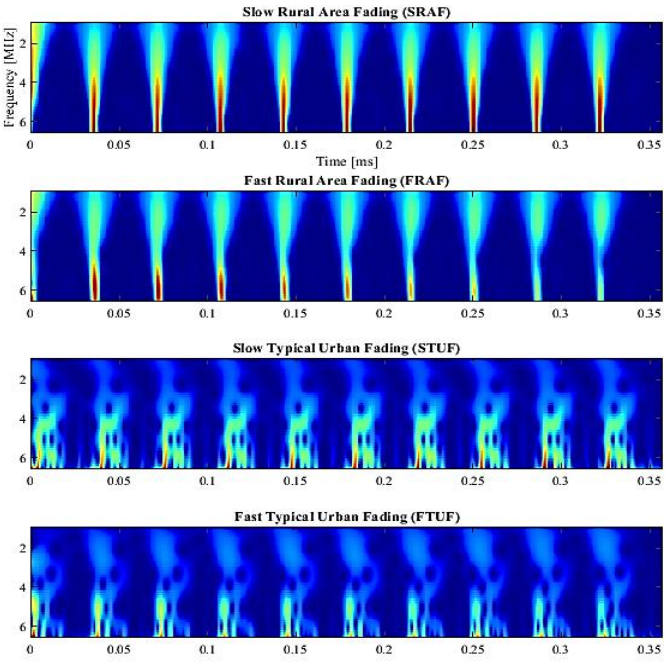
زمانی هر مقیاس وجود دارد.

نمونه‌هایی از مقیاس‌نگارهٔ دو نوع کانال با شیفت داپلر ۵۰ و ۲۰۰ هرتز در شکل ۳ نمایش داده شده است. نمایش زمان-مقیاس شکل ۳ با استفاده از تخمین کانال در ۱۰ سمبل OFDM که فاصلهٔ بین پایلوت‌های آن (L) برابر ۵ است در حضور نویز با SNR=20dB بدست آمده است. موجک مورد استفاده از نوع Morse(γ, P^2) است که تبدیل فوریه آن برابر است با

$$\Psi_{P,\gamma}(\omega) = a\,\omega^{\frac{P^2}{\gamma}} e^{-\omega^{\gamma}} U(\omega) \qquad (۶)$$

در رابطهٔ (۶)، $U(\omega)$ تابع پله و a ثابت نرمالیزاسیون است. پارامتر P^2 طول زمانی و تعداد نوسانات موجک و پارامتر γ تقارن موجک را تعیین می‌کند به نحوی که در حالت $\gamma = 3$ موجک کاملاً متقارن است. افزایش پارامتر P^2 منجر به افزایش طول زمانی موجک و در نتیجه کاهش رزولوشن زمانی و افزایش رزولوشن فرکانسی می‌شود لذا برای برقراری مصالحه بین رزولوشن زمانی و فرکانسی $P^2 = 30$ در نظر گرفته شده است. همچنین کاهش پارامتر γ منجر به افزایش رزولوشن زمانی موجک می‌شود لذا برای دنبال کردن تغییرات زمانی کانال $\gamma = 1$ انتخاب شده است. مزیت موجک Morse این است که بسیاری از موجک‌های تحلیلی مورد استفاده، حالت خاصی از تعمیم یافتهٔ این موجک هستند [۲۹]. برای مثال موجک کوشی دارای $\gamma = 1$ و موجک بسل دارای $\gamma = 0.25$ و $P^2 = 2$ هستند. پارامتر دیگری که باید تعیین شود، مقدار ν است. طول بردار ویژگی وابسته به ν است و با افزایش آن، ابعاد بردار ویژگی نیز افزایش می‌یابد. با آزمایش مقادیر مختلف، مقدار ν برابر ۲۰ در نظر گرفته شده است، زیرا مصالحه قابل قبولی بین دقت طبقه‌بندی و ابعاد بردار ویژگی برقرار می‌کند. نتیجه این ارزیابی در فصل نتایج شبیه‌سازی آمده است.

مقیاس‌نگاره‌های پاسخ کانال‌ها به کمک CWT با تنظیمات فوق، در شکل۳ رسم شده است. همان گونه که در این شکل مشخص است، مقیاس‌نگاره‌های کانال‌های مختلف تفاوت محسوسی دارند. به عنوان مثال، سرعت تغییرات توان مقیاس‌ها با زمان در کانال‌های محوشوندهٔ سریع بیشتر از کانال‌های محوشوندهٔ کند است. در این مقاله، بردار ویژگی را به نحوی پیشنهاد کرده‌ایم که چنین تفاوت-هایی را به طور کمّی لحاظ کند.



شکل ۳. مقیاس‌نگاره‌های کانال‌های RA و TU با دو نوع محوشوندگی سریع و کند

۲-۳- طبقه‌بندی کانال با استفاده از ویژگی‌های استخراج شده

پس از استخراج بردار ویژگی از مقیاس‌نگاره کانال، این بردارها به الگوریتم طبقه‌بندی کننده تحویل داده می‌شود. در روش پیشنهادی، از طبقه‌بندی کنندهٔ LDA[1] با استفاده از روش یادگیری جمعی زیرفضای تصادفی استفاده می‌شود. پارامترهای این روش عبارتند از: تعداد ویژگی‌های نمونه‌برداری شده در هر مرحله از یادگیری (q)، ابعاد بردار ویژگی (d) و تعداد مراحل یادگیری در هر تحقق از دیتاست (r). مراحل الگوریتم زیرفضای تصادفی به صورت زیر است [۳۰]:

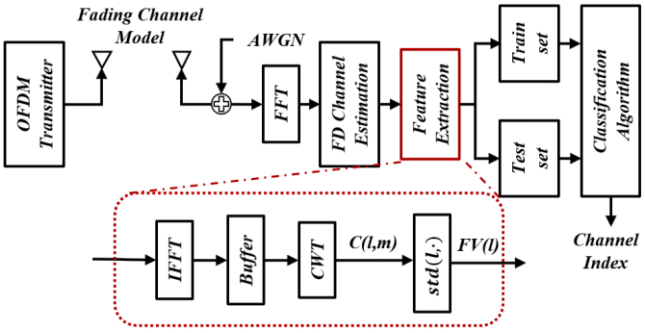
۱. انتخاب بدون جایگذاری q متغیر (ویژگی) از بین d متغیر بردار ویژگی.
۲. آموزش یک الگوریتم یادگیری نسبتاً ضعیف با استفاده از q متغیر انتخاب شده.
۳. تکرار مراحل ۱و۲ تا تحقق r مرحله از یادگیری.
۴. طبقه‌بندی با میانگین‌گیری نتایج r یادگیرنده و انتخاب کلاسی که بیشترین میانگین نتایج را دارد.

به طور کلی، روش‌های طبقه‌بندی نمونه‌ای، چندین طبقه‌بندی-کننده را آموزش می‌دهند و در فرآیند رأی‌گیری، نتایج هریک از

[1] Linear Discriminant Analysis (LDA)

آنها را ترکیب می‌کنند. میانگین نتایج چندین طبقه‌بندی کننده، نوع کلاس را تعیین می‌کند. در حالت $\nu = 20$، ابعاد بردار ویژگی برابر ۵۷ است و پارامترهای q و r در روش زیرفضای تصادفی به ترتیب برابر با ۲۹ و ۳۰ انتخاب شدند.

دیتاست مورد نیاز با شبیه‌سازی چندین تحقّق از هر نوع کانال محوشونده به دست می‌آید. با شبیه‌سازی ۵۰۰ تحقّق برای هر نوع کانال، معادل ۴۰۰۰ تحقّق برای تمام کانال‌ها حاصل می‌شود. ساخت دیتاست برای هر نوع کانال با تغییر یک پارامتر و ثابت نگه داشتن پارامترهای دیگر انجام شده است؛ به این صورت که با فرض L=5 و $\nu = 20$، به ازای هر یک از ۵ مقدار مختلف SNR، ۵۰۰ تحقق از هر کانال شبیه‌سازی شده است. همین روند با فرض SNR=20dB به ازای ۵ مقدار مختلف L صورت گرفته است. برای بررسی تأثیر پارامتر ν نیز با فرض SNR=20dB و L=5 برای هر یک از ۹ مقدار مختلف ν، ۵۰۰ تحقق از هر کانال شبیه‌سازی شده است. در شکل ۴ ساختار استخراج ویژگی و طبقه‌بندی انواع کانال‌های محوشونده نمایش داده شده است.



شکل ۴. دیاگرام بلوکی برای ساخت دیتاست در تمام کانال‌ها

همان گونه که مشخص است، پس از استخراج ویژگی، داده‌ها به دو دستهٔ آموزش و آزمایش تقسیم می‌شوند. برای بررسی تأثیر SNR بر دقّت طبقه‌بندی، مجموعه داده‌ای که در SNR=20dB ساخته شده است به عنوان داده‌های آموزش و اعتبارسنجی و داده‌های ساخته شده در مابقی SNRها به عنوان دادهٔ آزمایش در نظر گرفته می‌شوند. در اعتبارسنجی الگوریتم یادگیری ماشین از روش اعتبارسنجی متقابل با k لایه[1] استفاده می‌شود که k برابر با ۵ فرض شده است. همچنین، برای بررسی تأثیر سربار پایلوت بر دقّت طبقه‌بندی، بردارهای ویژگی ساخته شده با فرض پایلوت بودن تمام زیرحامل‌ها ($L = 1$)، به عنوان داده‌های آموزش و اعتبارسنجی و داده‌های ساخته شده در دیگر مقادیر L، به عنوان داده‌های آزمایش در نظر گرفته می‌شوند.

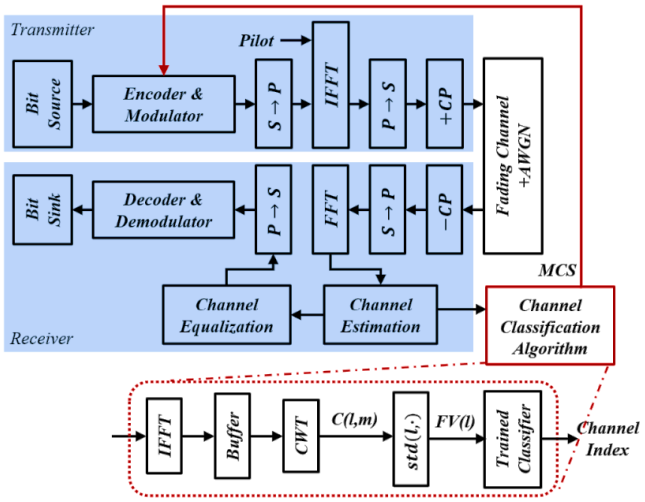
۴- روند شبیه‌سازی

در روند شبیه‌سازی روش پیشنهادی برای طبقه‌بندی کانال در این بخش تشریح شده است. در شکل ۵، لینک OFDM شبیه‌سازی شده مشاهده می‌گردد. در فرستنده، ابتدا دنبالهٔ بیت‌های پیام وارد مدولاتور QAM[2] شده و پس از افزودن سمبل‌های پایلوت در میان سمبل‌های موازی شدهٔ داده، IFFT با N نقطه اعمال می‌شود. سپس، اعداد مختلط بدست آمده به صورت سری در می‌آیند و پیشوند چرخشی به طول $\frac{N}{8}$ اعمال می‌شود. سیگنال معادل پایین‌گذر حاصل، از مدل پایین‌گذر کانال محوشونده عبور کرده و نویز سفید گاوسی نیز به آن اضافه می‌شود. در گیرنده، پس از اعمال FFT با N نقطه و استخراج پایلوت‌ها، فاصلهٔ بین پایلوت‌ها با روش spline درون‌یابی می‌شود و تخمینی از پاسخ فرکانسی کانال بدست می‌آید. پس از تخمین پاسخ فرکانسی کانال، دو مسیر وجود دارد: یک مسیر برای متعادل‌سازی[3] اثر کانال، دمدولاسیون و در نهایت آشکارسازی بیت‌های پیام و مسیر دیگر برای اجرای الگوریتم طبقه‌بندی کانال. در مسیر دوم، با اعمال IFFT، پاسخ ضربهٔ کانال تخمین زده شده و N_{cp} نمونهٔ اول آن به عنوان پاسخ غالب، در بافر ذخیره می‌شود. با جمع آوری ۱۰ مرحله تخمین از پاسخ ضربه، تبدیل موجک پیوسته اعمال شده و بردار ویژگی به دست می‌آید. در نهایت، بردار ویژگی به مدل از پیش آموزش داده شده وارد می‌شود و محتمل‌ترین نوع کانال در خروجی به دست می‌آید. به کمک طبقه‌بندی کانال می‌توان وفقی‌سازی لینک انجام داد [۳۱]. پارامترهای مربوط به شبیه‌سازی لینک و طبقه‌بندی کانال در جدول ۵ نمایش داده شده است.

جدول ۵. پارامترهای لینک شبیه‌سازی شده و طبقه‌بندی

پارامتر	مقدار
نرخ نمونه‌برداری	5×10^6
تعداد زیرحامل ها (N)	512
طول پیشوند چرخشی (N_{cp})	64
تعداد سمبل های OFDM	10
نرخ اعمال پایلوت (L)	1, 5, 10, 15, 20
شیفت فرکانسی داپلر	50, 200
SNR	3, 6, 10, 15, 20
VPO (ν)	4:2:20
نوع موجک	Morse(1,30)
نوع درونیابی	Spline
نوع متعادل کننده	Least Square (LS)
نوع کانال محوشونده	SRAF, FRAF, STUF, FTUF, SBUF, FBUF, SHTF, FHTF.

[1] K-fold cross-validation
[2] Quadrature Amplitude Modulation (QAM)
[3] Equalization



شکل ۵. بلوک دیاگرام لینک OFDM شبیه‌سازی شده

۵- نتایج شبیه‌سازی

در این بخش، به بررسی نتایج روش پیشنهادی پرداخته می‌شود. برای بررسی تأثیر هر پارامتر بر دقت طبقه‌بندی کانال و مقایسهٔ نتایج روش پیشنهادی با دیگر روش‌های طبقه‌بندی کانال، آزمایش‌هایی انجام شده است. این آزمایش‌ها برای بررسی تأثیر پارامترهای زیر بر طبقه‌بندی کانال است:

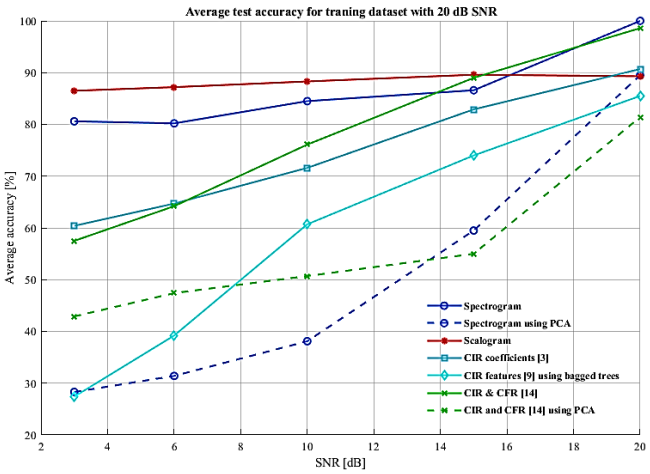
- روش استخراج بردار ویژگی
- سربار پایلوت (L)
- VPO (ν)

در تمام آزمایش‌های انجام شده، برای آموزش مدل از دیتاست SNR=20dB و برای آزمایش مدل از سایر SNRها استفاده می‌شود.

۵-۱- روش استخراج بردار ویژگی

در این آزمایش به بررسی تأثیر استخراج بردار ویژگی بر دقت طبقه‌بندی کانال پرداخته می‌شود. دقت روش پیشنهاد شده با روش‌های مراجع [۳]، [۹] و [۱۴] مقایسه شده است. بردار ویژگی در این مراجع به ترتیب عبارت است از: ضرایب پاسخ ضربهٔ کانال، ویژگی‌های پاسخ ضربهٔ کانال و پاسخ ضربهٔ کانال به همراه پاسخ فرکانسی آن. علاوه بر روش‌های مراجع مذکور، دقت طبقه‌بندی با استخراج ویژگی از طیف زمان-فرکانس (طیف‌نگاره) به جای مقیاس‌نگاره در روش پیشنهادی نیز بررسی شده است. مدل طبقه‌بندی‌کنندهٔ LDA، با استفاده از دیتاست با مشخصات SNR=20dB، L=5 و $\nu = 20$ آموزش داده شده و در SNRهای دیگر آزمایش شده است. میانگین دقت طبقه‌بندی با روش‌های مختلف در شکل ۶ نمایش داده شده است. در این شکل مشاهده می‌شود وقتی SNR تست برابر همان SNR آموزش یعنی 20 dB است دقت روش‌های استخراج ویژگی از طیف زمان-فرکانس و ترکیب پاسخ‌های ضربه و فرکانس کانال بهتر از دقت طبقه‌بندی بر اساس ویژگی‌های مستخرج از مقیاس‌نگاره است که در این مقاله پیشنهاد کرده‌ایم. با کاهش SNR دقت این روش‌ها مشابه روش‌های دیگر به طور قابل ملاحظه‌ای افت می‌کند، در حالیکه دقت روش پیشنهادی کمترین افت را دارد و وقتی SNR کاهش می‌یابد از دقت همه روش‌های رقیب بالاتر می‌ماند. این نتیجه نشان می‌دهد روش پیشنهادی مقاومت خوبی در برابر نویز دارد و با افزایش سطح نویز، عملکرد آن کمتر از روش‌های دیگر افت می‌کند.

با استفاده از روش مرجع [۹] در استخراج ویژگی، برای ویژگی‌های مستخرج از پاسخ ضربهٔ کانال، طبقه‌بندی کنندهٔ جنگل تصادفی دقت بیشتری نسبت به LDA دارد لذا، از روش جنگل تصادفی [۳۲-۳۴] برای طبقه‌بندی استفاده شده است. طول بردار ویژگی نیز در روش پیشنهادی و روش‌های [۳] و [۹] به ترتیب برابر ۵۷، ۶۴ و ۴ است. همچنین از PCA[1] برای کاهش بعد بردار ویژگی مستخرج از پاسخ زمان-فرکانس و بردار ویژگی به دست آمده با روش مرجع [۱۴]، استفاده می‌شود. به این ترتیب، ابعاد بردار ویژگی مستخرج از پاسخ زمان-فرکانس از ۵۱۲ به ۵۷ و ابعاد بردار ویژگی به دست آمده با روش [۱۴] از ۵۷۶ به ۲۰۰ کاهش می‌یابد.



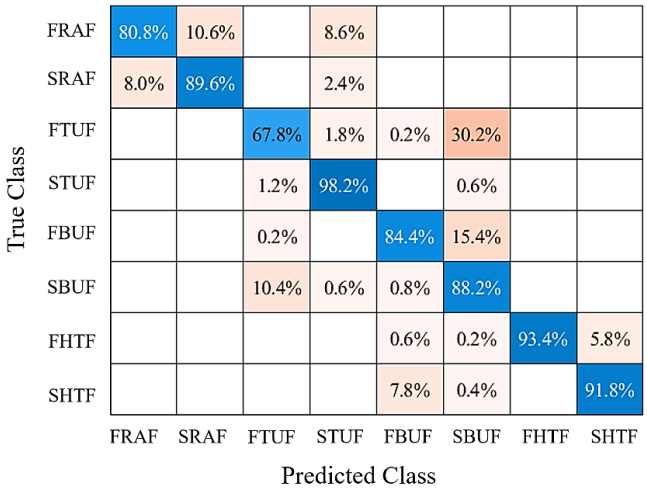
شکل ۶. دقت طبقه‌بندی روش پیشنهادی و سایر روش‌ها برحسب SNR

نتایج شبیه‌سازی‌ها نشان می‌دهد استفاده از نمایش زمان-مقیاس کانال برای استخراج ویژگی، دقت بیشتری نسبت به سایر روش‌ها دارد. شکل ۶ دقت روش‌های مختلف را بر حسب SNR نمایش می‌دهد. از آنجا که دقت روش‌ها در کلاس‌های متفاوت تغییر

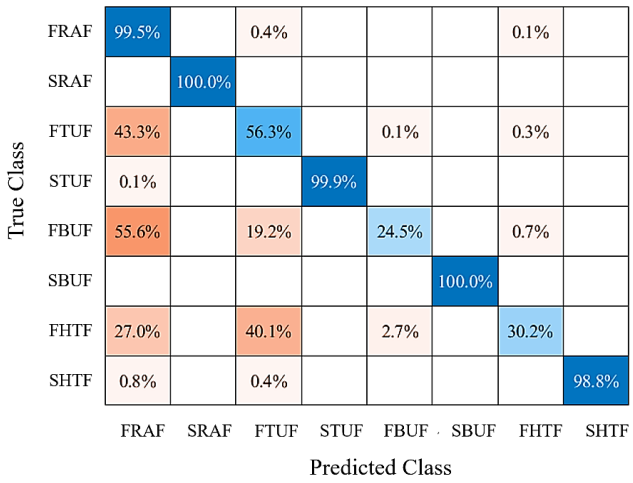
[1] Principal Component Analysis (PCA)

می‌کند، میانگین دقت هر ۸ کلاس محاسبه و رسم شده است. با توجه شکل ۶، دقت روش پیشنهادی در SNR=10dB برابر با ۸۹ درصد می‌شود که از همه روش‌های دیگر بیشتر است. دقت روش مرجع [۱۴] در همین SNR مقدار ۷۶/۱۱ درصد است. طبیعتاً کاهش SNR به 3dB که به معنای تخریب شرایط است، عملکرد همه روش‌ها را بدتر می‌کند. در این شرایط دقت روش مرجع [۱۴] به کمتر از ۶۰ درصد کاهش می‌یابد، درحالیکه دقت روش پیشنهادی ۸۶/۷۷ درصد می‌شود؛ یعنی نه تنها از دقت روش رقیب در SNR یکسان بهتر است، بلکه همچنان از دقت آن در SNR=10 dB (شرایط بهتر) بالاتر می‌ماند. این تحلیل، مقاومت روش پیشنهادی در برابر افزایش توان نویز را به خوبی نشان می‌دهد. البته وقتی SNR خیلی خوب باشد (بیش از 16 dB)، دقت روش رقیب بهتر از روش پیشنهادی است. همچنین، شکل ۶ نشان می‌دهد استخراج ویژگی از روی موجک بهتر از استخراج ویژگی از نمایش زمان-فرکانس است و با تعداد ویژگی بسیار کمتری به دقت مطلوب می‌رسد.

ماتریس درهم‌ریختگی برای روش پیشنهادی و روش مرجع [۱۴]، که دقت آن بالاتر از روش‌های مراجع دیگر است، به ترتیب در شکل‌های ۷ و ۸ نمایش داده شده است. این مقادیر برای روش رقیب به ازای SNR=10 dB استخراج شده‌است ولی برای روش پیشنهادی در SNR=3 dB (شرایط بدتر) محاسبه گردیده است؛ بنابراین مقایسه‌ای سختگیرانه به نفع رقیب است. با این حال در شکل ۸ مشاهده می‌شود که روش مرجع [۱۴] دقت مناسبی در طبقه‌بندی کانال‌های محوشوندهٔ سریع و کند ندارد زیرا در ساخت بردار ویژگی، تغییرات زمانی کانال در نظر گرفته نمی‌شود؛ ولی روش پیشنهادی می‌تواند کانال‌های محوشونده را از هر دو جنبه تغییرات زمانی و فرکانسی، با دقت مناسبی تفکیک کند. تابع چگالی احتمال[1] چهار مقیاس از مقیاس‌نگارهٔ پاسخ کانال، به ازای کانال‌های مختلف در شکل ۹ نمایش داده شده است.



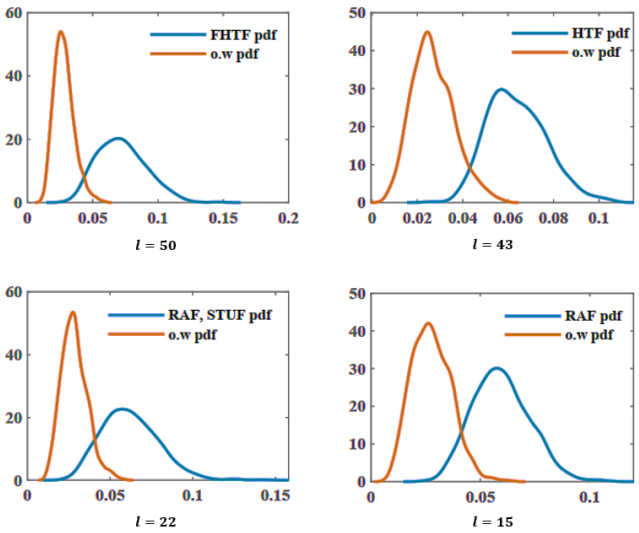
شکل ۷. ماتریس درهم‌ریختگی برای طبقه‌بندی با روش پیشنهادی



شکل ۸. ماتریس درهم‌ریختگی برای طبقه‌بندی با روش [۱۴]

همان گونه که مشاهده می‌شود، صرفاً با در نظر گرفتن چهار مقیاس از مقیاس‌نگارهٔ پاسخ کانال، با دقت مناسبی می‌توان برخی کانال‌ها را از یکدیگر تفکیک کرد. مقیاس ۴۳ می‌تواند کانال‌های FHTF و SHTF را از دیگر کانال‌ها تفکیک کند. همچنین، برای تفکیک کانال‌های FHTF و SHTF از یکدیگر، می‌توان از مقیاس ۵۰ استفاده کرد که کانال FHTF را از سایر کانال‌ها متمایز می‌کند. به همین ترتیب، مقیاس شمارهٔ ۲۲ می‌تواند کانال‌های SRAF، FRAF و STUF را از سایر کانال‌ها تمایز دهد. لذا، با استفادهٔ همزمان از مقیاس‌های ۲۲ و ۱۵، کانال STUF از دیگر کانال‌ها قابل تمایز است. برای تفکیک تمامی‌کانال‌ها با دقت مناسب، لازم است از تمام مقیاس‌های نمایش زمان-مقیاس پاسخ کانال استفاده شود که مبنای روش پیشنهادی است.

[1] Probability Density Function (PDF)



شکل ۹. تابع چگالی احتمال کانال‌های مختلف در مقیاس‌های ۵۰، ۴۳، ۲۲ و ۱۵

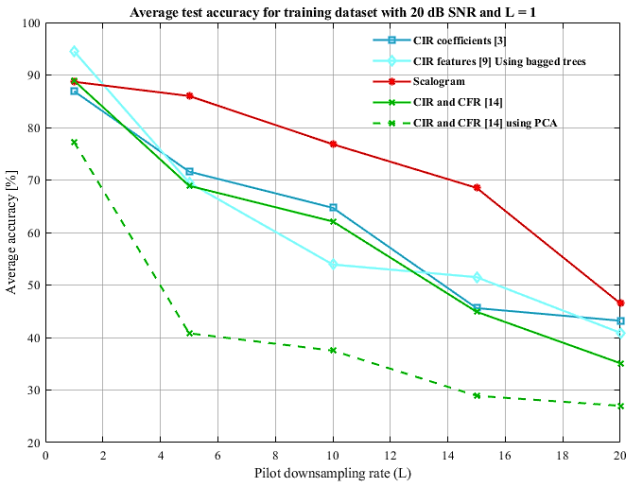
۵-۲- سربار پایلوت

یکی از پارامترهای مؤثر در تخمین کانال و در نتیجه دقت طبقه‌بندی کانال از روی پاسخ تخمینی، سربار پایلوت است. سربار پایلوت کمتر به معنای سهم بیشتری برای داده کاربران است، ولی از سوی دیگر اطلاعات موجود برای تخمین و درون‌یابی پاسخ کانال را کمتر می‌کند. لذا در تعیین این پارامتر یک مصالحه لازم است. هدف از این آزمایش، بررسی تأثیر سربار پایلوت بر نتیجه طبقه‌بندی است. در شکل ۱۰ دقت طبقه‌بندی روش‌های مختلف برحسب سربار پایلوت نمایش داده شده است. مدل طبقه‌بندی‌کننده با دیتاست SNR=20dB، L=1 و $\nu = 20$ آموزش داده شده و در مقادیر دیگر برای L آزمایش شده است. همان گونه که در این شکل مشاهده می‌شود، دقت روش پیشنهادی بهتر از روش‌های دیگر است؛ همچنین با افزایش طول پایلوت‌ها یعنی کاهش سربار پایلوت که خطای تخمین کانال را افزایش می‌دهد، دقت طبقه‌بندی این روش کمتر از روش‌های دیگر افت می‌کند. این نتیجه اثبات می‌کند روش پیشنهادی نسبت به خطای تخمین کانال مقاومت بیشتری نشان می‌دهد.

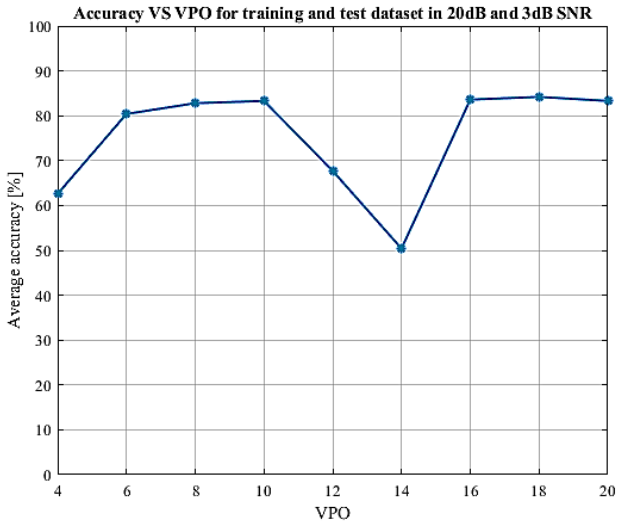
۵-۳- بررسی تغییرات VPO

مقدار ν، تعیین کنندهٔ ابعاد بردار ویژگی است. برای بررسی تأثیر ابعاد بردار ویژگی بر دقت طبقه‌بندی، مدل طبقه‌بندی کننده به ازای هر یک از مقادیر تعریف شده برای ν، در SNR=20dB آموزش و در SNR=3dB آزمایش می‌شود. شکل ۱۱ دقت طبقه‌بندی روش پیشنهادی را برحسب پارامتر ν نمایش می‌دهد.

همان طور که مشاهده می‌شود دقت طبقه‌بندی به ازای مقادیر ν کمتر از ۱۶ خوب نیست و پس از آن نتیجه بهتری حاصل می‌گردد، ولی با افزایش بیشتر تغییر قابل توجّهی دیده نمی‌شود. بنابراین در $\nu = 20$ که به تعداد ۵۷ ویژگی می‌انجامد، مصالحه مناسبی بین ابعاد بردار ویژگی و دقت طبقه‌بندی برقرار می‌شود.



شکل ۱۰. دقت طبقه‌بندی روش پیشنهادی و سایر روش‌ها برحسب سربار پایلوت



شکل ۱۱. دقت طبقه‌بندی روش پیشنهادی برحسب مقادیر مختلف برای VPO

۶- جمع‌بندی و نتیجه‌گیری

در این پژوهش، روش جدیدی برای طبقه‌بندی کانال‌های مخابراتی مبتنی بر تبدیل موجک و الگوریتم یادگیری ماشین ارائه شد. روش پیشنهاد شده از مقیاس‌نگارهٔ کانال محوشونده برای استخراج ویژگی‌ها و از الگوریتم LDA با روش یادگیری جمعی زیرفضای تصادفی برای طبقه‌بندی استفاده می‌کند. مقیاس‌نگارهٔ پاسخ کانال در یک لینک OFDM، با تخمین پاسخ ضربهٔ کانال روی چندین

سمبل و اعمال تبدیل موجک به دنباله‌ای از نتایج تخمین بدست می‌آید. بردار ویژگی با محاسبهٔ انحراف معیار هر مقیاس استخراج می‌شود. بدین ترتیب ابعاد بردار ویژگی قابل کنترل است و بردار حاصل یا کوچکتر از بردار ویژگی روش‌های رقیب یا برابر آنهاست. با این حال نتایج آزمایش‌های مختلف با شبیه‌ساز مزایای زیر را در روش پیشنهادی نشان می‌دهد:

- دقت روش پیشنهادی بهتر از روش‌های رقیب است.
- روش پیشنهادی نسبت به نواقص و مشکلات واقعی مانند افزایش سطح نویز یا خطای تخمین کانال مقاومت بیشتری دارد.

باتوجه به توسعه روزافزون بسترهای مخابراتی، در پژوهش‌های آینده طبقه‌بندی کانال‌های جدید مانند 5G و نسل‌های فراتر، ارتباطات V2X[1] که شیفت داپلر بیشتری دارند، و کاربردهای مشابه می‌تواند با روش پیشنهادی مورد مطالعه قرار گیرد. همچنین می‌توان با افزایش ابعاد، آن را برای ارتباطات MIMO نیز توسعه داد.

مراجع

[1] Rappaport, T.S., Wireless communications: principles and practice. 2024: Cambridge University Press.
[2] Tse, D. and P. Viswanath, Fundamentals of wireless communication. 2005: Cambridge university press.
[3] Kurniawan, E., L. Zhiwei, and S. Sun. Machine learning-based channel classification and its application to IEEE 802.11 ad communications. in GLOBECOM 2017-2017 IEEE Global Communications Conference. 2017. IEEE.
[4] Proakis, J.G. and M. Salehi, Contemporary communication systems using MATLAB. (No Title), 2000.
[5] Haykin, S., Communication systems. 2008: John Wiley & Sons.
[6] Kurniawan, E., et al. Machine learning-based channel-type identification for IEEE 802.11 ac link adaptation. in 2018 24th Asia-Pacific Conference on Communications (APCC). 2018. IEEE.
[7] Wen, C.-K., et al., Channel estimation for massive MIMO using Gaussian-mixture Bayesian learning. IEEE Transactions on Wireless Communications, 2014. 14(3): p. 1356-1368.
[8] Yan, D., et al., Deep reinforcement learning based resource allocation for network slicing with massive MIMO. IEEE Access, 2023.
[9] Ying, R., T. Jiang, and Z. Xing. Classification of transmission environment in UWB communication using a support vector machine. in 2012 IEEE Globecom Workshops. 2012. IEEE.
[10] Eskola, M. and T. Heikkilä, Classification of radio channel disturbances for industrial wireless sensor networks. Ad Hoc Networks, 2016. 42: p. 19-33.
[11] Kang, Y.Y., et al. Support vector machine-based wireless channel classification for adaptive AFC in LTE downlink. in 2017 IEEE 85th Vehicular Technology Conference (VTC Spring). 2017. IEEE.
[12] Lu, Z., et al. UWB Channel Classification Based on Deep-Learning for Adaptive Transmission. in 2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). 2019. IEEE.
[13] Jiang, C., et al., UWB NLOS/LOS classification using deep learning method. IEEE Communications Letters, 2020. 24(10): p. 2226-2230.
[14] Li, X., et al. On Wireless Channel Classification Based on CP-OFDM System. in 2021 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB). 2021. IEEE.
[15] Zaki, A., et al., 5G and beyond: Channel classification enhancement using VIF-driven preprocessing and machine learning. Electronics, 2023. 12(16): p. 3496.
[16] Baldini, G. and F. Bonavitacola. Fading Channel Classification Based on Convolutional Neural Network with General Linear Chirplet Transform. in 2023 17th European Conference on Antennas and Propagation (EuCAP). 2023. IEEE.
[17] Yu, Y., F. Liu, and S. Mao, Fingerprint extraction and classification of wireless channels based on deep convolutional neural networks. Neural processing letters, 2018. 48(3): p. 1767-1775.
[18] ShirinAbadi, P.A. and A. Abbasi. UWB channel classification using convolutional neural networks. in 2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). 2019. IEEE.
[19] Deng, R., et al., Channel fingerprint based beam tracking for millimeter wave communications. IEEE Communications Letters, 2019. 24(3): p. 639-643.
[20] Kim, Y., J. Bang, and T. Kim, Blind Channel Estimation Based on K-Means Clustering with Resource Grouping in Fading Channel. Mathematics, 2026. 14(3): p. 400.
[21] Huang, Y., et al. Low signal-to-noise ratio speech classification with wavelet. in Journal of Physics: Conference Series. 2020. IOP Publishing.
[22] Kojima, S., et al., CNN-based joint SNR and Doppler shift classification using spectrogram images for adaptive modulation and coding. IEEE Transactions on Communications, 2021. 69(8): p. 5152-5167.
[23] Proakis, J.G. and M. Salehi, Digital communications. 2008: McGraw-hill.
[24] Kucharczyk, M., et al., Equalizer parameters' adjustment based on an oversampled channel model for OFDM modulation systems. Electronics, 2024. 13(5): p. 843.
[25] Makhija, D., R. Bera, and S. Dhar, Comparative Evaluation of NOMA and OFDMA over Multipath Fading Rayleigh Channels in Downlink SISO System. Journal of The Institution of Engineers (India): Series B, 2025. 106(4): p. 1163-1172.
[26] Wang, C.-X., et al., An enhanced 6G pervasive channel model towards standardization. Science China Information Sciences, 2025. 68(6): p. 162301.
[27] Pätzold, M., Mobile radio channels. 2011: John Wiley & Sons.
[28] Barbosa Filho, J.M.L., et al., Wideband channel sounding simulation tool and sounding sequences evaluation. IEEE Latin America Transactions, 2022. 20(4): p. 562-572.
[29] Olhede, S.C. and A.T. Walden, Generalized morse wavelets. IEEE Transactions on Signal Processing, 2002. 50(11): p. 2661-2670.
[30] Ho, T.K., The random subspace method for constructing decision forests. IEEE transactions on pattern analysis and machine intelligence, 1998. 20(8): p. 832-844.
[31] Molisch, A.F., Wireless communications. Vol. 34. 2012: John Wiley & Sons.
[32] Breiman, L., Classification and regression trees. 2017: Routledge.
[33] Loh, W.Y., Classification and regression trees. Wiley interdisciplinary reviews: data mining and knowledge discovery, 2011. 1(1): p. 14-23.
[34] Breiman, L., Random forests. Machine learning, 2001. 45: p. 5-32.

[1] Vehicle-to-Everything