

## تشخیص بیدرنگ تصادف در ترافیک شهری با اینترنت اشیاء و ترکیب سازوکار توجه با ماشین بردار پشتیبان در چارچوب ابرمحور

صفورا اخلاقی\*

دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه آزاد اسلامی واحد قزوین، قزوین، ایران

پست الکترونیکی: [Safoura.Akhlaghi@gmail.com](mailto:Safoura.Akhlaghi@gmail.com)

### چکیده

تشخیص بیدرنگ تصادف در شبکه‌های حمل‌ونقل هوشمند برای کاهش تلفات و مدیریت ترافیک حیاتی است اما نرخ هشدار کاذب بالا، هزینه محاسباتی و محدودیت پهنای باند دوربین‌های شهری چالش اصلی محسوب می‌شود. این پژوهش چارچوبی سبک و مقیاس‌پذیر برای آشکارسازی مطمئن تصادف ارائه می‌کند که همزمان دقت بالا و هزینه ارتباطی پایین را هدف می‌گیرد. در مرحله لبه، تنها هنگام مشاهده نشانه خطر (تغییرات ناگهانی و غیرعادی در داده‌های حسگرها) افزایش بیش از ۳۵۰ پاسکال در نیروی ضربه، کاهش سرعت بیش از ۶۰ درصد در کمتر از ۱ ثانیه، چند ثانیه ویدئو به کارسان میانی ارسال می‌شود؛ در کارسان، همگام‌سازی زمانی مکانی و پاکسازی انجام می‌گیرد. سپس یک استخراج‌گر سبک با هم‌آمیختگی تفکیک‌پذیر عمقی، دو بلوک Inception با اتصالات باقیمانده و توجه کانالی، نمایه ۲۵۶ بعدی نرمال‌شده می‌سازد. این نمایه با ماشین بردار پشتیبان مبتنی بر هسته تابع شعاعی و کالیبراسیون احتمال طبقه‌بندی می‌شود و با هموارسازی زمانی و هم‌نظری چندمنبع، هشدارهای بی‌مورد کاهش می‌یابد. آزمایش‌های

انجام شده نشان داد که روش پیشنهادی به دقت ۹۹ درصد، بازخوانی ۹۹ درصد، دقت مثبت ۹۸ درصد و صحت ۹۸/۵ درصد دست یافت. ماتریس آشفتگی آزمایش تنها ۷ خطا از ۴۰۰ نمونه را نشان داد. نسبت به خطوط مبنا DenseNet121، ResNet-50، VGG-19 و InceptionV3، بهبود دقت بین ۱/۶ تا ۴/۲ واحد درصد و بهبود حساسیت بین ۲ تا ۷ واحد درصد حاصل شد.

**کلیدواژه‌ها:** تشخیص بیدرنگ تصادف، ترافیک شهری، اینترنت اشیاء، استخراج ویژگی، ماشین بردار پشتیبان

### ۱- مقدمه

رشد چشمگیر جمعیت جهان و گسترش شهرنشینی موجب افزایش مداوم تعداد خودروها در شبکه‌های معابر شده است؛ پیامدی که تراکم و اندازه ترافیک را بالا برده و به دنبال آن زمان سفر را طولانی‌تر، مصرف سوخت را بیشتر و انتشار دی‌اکسیدکربن را افزون است. مسائلی که از منظر پایداری شهری اهمیت حیاتی دارند [۱، ۲]. هم‌زمان، شواهد بین‌المللی نشان می‌دهد با بزرگ‌تر شدن مقیاس ترافیک، شمار سوانح رانندگی منجر به جرح و فوت نیز افزایش می‌یابد و هزینه‌های مستقیم و غیرمستقیم سنگینی بر سیستم سلامت و بهره‌وری نیروی کار تحمیل می‌کند

\* نویسنده مسئول

مواجهه با هم‌بستگی‌های مکانی- زمانی داده‌های ترافیکی و نیاز به تحلیل برخط کارایی محدودی دارند و نتایج‌شان در محیط‌های پویا افت می‌کند [۱۲]. این شکاف‌ها ضرورت طراحی چارچوب‌هایی دقیق، مقیاس‌پذیر و ایمن را نشان می‌دهد که بتوانند از داده‌های پربعد و چندوجهی برای پیش‌بینی مؤثر سوانح بهره بگیرند. مشارکت‌های اصلی تحقیق به شرح زیر است:

۱. چارچوب سه‌مرحله‌ای کم‌هزینه و مقیاس‌پذیر: ارسال ویدئو فقط هنگام نشانه خطر، همگام‌سازی و پاکسازی در کارسان، سپس تصمیم‌گیری با هموارسازی زمانی و هم‌نظری چندمنبع. این طراحی هم‌زمان پهنای باند و نهفتگی را کاهش می‌دهد و نرخ هشدار بی‌مورد را پایین می‌آورد.

۲. استخراج ویژگی فشرده و دقیق: معرفی استخراج‌گر سبک با هم‌آمیختگی تفکیک‌پذیر عمقی، دو بلوک Inception با اتصالات باقیمانده و توجه کانالی که نمایه ۲۵۶ بعدی نرمال شده تولید می‌کند. این ترکیب با محاسبه کمتر از خطوط مبنا ویژگی‌های متمایزتر می‌سازد.

۳. بهبود دقت: روش پیشنهادی نسبت به VGG-19، DenseNet121، ResNet-50 و InceptionV3 به ترتیب بین ۱/۶ تا ۴/۲ واحد درصد بهبود در دقت و بین ۲ تا ۷ واحد درصد بهبود در حساسیت نشان داد.

## ۲- کارهای پیشین

مرور نظام‌مند [۱۳] راهبردهای پیش‌بینی ایمنی جاده‌ای در بستر اینترنت وسایل نقلیه نشان می‌دهد آموزش توزیع‌شده روی گره‌های لبه، حریم خصوصی را حفظ می‌کند و جامعیت داده‌ها را بالا می‌برد. ضعف‌های رویکرد متمرکز وابستگی به کارساز مرکزی، گلوگاه انتقال و تأخیر به‌روشنی تبیین شده است. چارچوب‌های معیارسنجی و سناریوهای ارزیابی برای مقایسه منصفانه مدل‌ها پیشنهاد می‌شود. نویسندگان موارد کاربردی و الزامات پیاده‌سازی در مقیاس واقعی را مرور می‌کنند. جمع‌بندی کار، قابلیت

[۳]. بنابراین، نیاز به ابزارهای مؤثر برای پایش و هدایت جریان حرکت وسایل نقلیه با هدف کاهش سوانح و بهبود کارایی شبکه حمل‌ونقل بیش از پیش احساس می‌شود. در دهه‌های اخیر، اینترنت اشیاء به عنوان زیربنای سامانه‌های حمل‌ونقل هوشمند در حوزه‌های گوناگون (خدمات درمانی و تولید تا خانه‌های هوشمند و برنامه‌ریزی شهری) گسترش یافته و با اتصال دستگاه‌ها و حسگرها، گردآوری/تبادل/پردازش برخط داده را میسر کرده است [۴]. بر مبنای همین بستر، اینترنت وسایل نقلیه با اتصال خودروها به انواع حسگرها، واحدهای کنار جاده و شبکه‌ها، ارتباطات قابل‌اعتماد میان وسیله‌نقلیه به وسیله‌نقلیه، وسیله‌نقلیه به زیرساخت و وسیله‌نقلیه به عابر را فراهم می‌کند و بدین ترتیب، دید مشترکی از وضعیت راه ایجاد می‌شود [۵]. همگرایی خودروهای متصل و خودران با این زیست‌بوم می‌تواند پایش برخط، کنترل ترافیک مبتنی بر داده، کاهش سوانح و ارائه خدمات امدادی خودکار را تسهیل کرده و با پیش‌بینی ریسک‌ها، جریان عبور و مرور را بهینه و تجربه سفر را ارتقا دهد [۶،۷].

پیشرفت تحلیل داده و چارچوب‌های یادگیری ماشین و یادگیری عمیق بر بستر اینترنت وسایل نقلیه گامی مهم در جهت تصمیم‌سازی هوشمند و هشدار زودهنگام مخاطرات برداشته است: مدل‌ها با استفاده از داده‌های حجیم خودروها و زیرساخت‌ها، ریسک‌ها را پیش‌بینی، الگوهای جریان را بهبود و احتمال وقوع حادثه را کم می‌کنند [۸،۹]. مرورهای جامع نشان می‌دهد رویکردهای داده‌محور می‌توانند سامانه‌های مدیریت ترافیک را از حالت انفعالی به وضعیت پویا و واکنش‌گر به شرایط در حال تغییر تبدیل کنند و در مدیریت بحران مؤثر باشند [۱۰]. با این حال، چالش‌های بنیادین همچنان پابرجاست: ناهمگنی و حجم بالای داده، عدم ایستایی و وابستگی‌های شدید مکانی-زمانی و نیز ملاحظات امنیتی در شبکه‌های اینترنت وسایل نقلیه، ارزیابی و پیش‌بینی دقیق سوانح را دشوار می‌کند [۱۱]. علاوه بر این، بسیاری از الگوهای متعارف در

می‌شود. چارچوب پیشنهادی نشان می‌دهد بدون اتکای کامل به ارتباطات بی‌سیم همه خودروها نیز می‌توان سامانه پرهیز از برخورد ساخت. پیش‌بینی پویا امکان سازگاری سریع با تغییرات صحنه ترافیک را فراهم می‌کند. سامانه زمان واکنش را کاهش داده و قابلیت استقرار عملی را حفظ می‌نماید. استقلال نسبی از زیرساخت‌های ارتباطی گسترده، مزیت کلیدی رویکرد است.

در تحقیق دیگری [۱۸]، یک سامانه پیش‌بینی تصادف شهری مبتنی بر مدل مارکوف پنهان توسعه یافته است که فراتر از سرعت صرف، عوامل محیطی، راننده و وسیله را لحاظ می‌کند. ساختار احتمالاتی، وضعیت‌های پنهان ایمن/خطر را بهتر بازنمایی می‌کند. ادغام داده‌های جریان ترافیک و هواشناسی دقت و حساسیت پیش‌بینی را افزایش می‌دهد. نتایج برای هشدار زود هنگام و مدیریت ریسک در شبکه‌های خودرویی قابل استفاده است. چارچوب، پایه‌ای برای تصمیم‌یارهای ایمنی در محیط‌های شهری فراهم می‌آورد.

در [۱۹] سامانه‌ای سه‌لایه بر پایه اینترنت اشیا برای تشخیص رخداد‌های تصادف طراحی شده است. الگوریتم تابیدگی زمانی پویای چندبعدی (MDTW) برای تفکیک الگوهای حرکتی حادثه از حرکات عادی به‌کار می‌رود. معماری لبه-ابر انتقال کارآمد و پردازش سریع داده‌ها را ممکن می‌کند. در ارزیابی‌ها، عملکرد از روش‌های متعارف مانند ماشین بردار پشتیبان و نزدیک‌ترین همسایه بهتر گزارش می‌شود. سامانه قابلیت پایش برخط و اطلاع‌رسانی سریع به مراکز امدادی را برجسته می‌کند. در تحقیق دیگری یک رویکرد کلان‌داده برای تحلیل برخط ترافیک و برآورد آنی ریسک تصادف در شبکه‌های بین خودرویی ارائه شده است [۲۰]. چگالی ترافیک و سرعت متوسط به‌عنوان شاخص‌های لحظه‌ای خطر محاسبه می‌شوند. چارچوب برای به‌روزرسانی پیوسته با جریان داده زنده طراحی شده است. مقیاس‌پذیری در زیرساخت‌های هوشمند و سازگاری با شبکه‌های سبز بررسی می‌شود. خروجی،

یادگیری فدرال در بهبود تحلیل ترافیک و ایمنی را تأیید می‌کند.

پژوهش [۱۴] بر عدم قطعیت مسیر عابران در ارتباط وسیله‌نقلیه به عابر متمرکز است و برای سنجش خطر، یک شاخص خطر معرفی می‌کند. شبکه حافظه کوتاه مدت بلند (LSTM) برای پیش‌بینی مسیر عابر به‌کار می‌رود تا پنجره زمانی هشدار افزایش یابد. سازوکار هشدار برخورد وسیله‌نقلیه به عابر طراحی و با داده‌های واقعی و شبیه‌سازی‌شده اعتبارسنجی می‌شود. نتایج دقتی نزدیک به ۹۸ درصد در پیش‌بینی و کاهش هشدارهای کاذب را گزارش می‌کند. رویکرد، مبنایی برای سامانه‌های ایمنی شهری مبتنی بر پیش‌بینی مسیر فراهم می‌آورد.

در [۱۵] آشکارسازی بیدرنگ اشیا با YOLOv4 با پیش‌بینی موقعیت آینده خودرو تلفیق شده است. اطلاعات حرکتی خودرو در چارچوب یادگیری ماشین ادغام می‌شود تا مسیرهای آتی دقیق‌تر برآورد شود. معماری پرهیز از برخورد بر بستر اینترنت وسایل نقلیه ارائه و تحلیل می‌گردد. مقایسه‌ها نشان می‌دهد دقت پیش‌بینی حرکت نسبت به روش‌های مرجع به‌طور معناداری بهبود یافته است. کارایی سامانه در صحنه‌های پرترافیک و محدودیت‌های زمانی واقعی نیز نشان داده می‌شود.

یک مدل پیش‌بینی برخورد مبتنی بر شبکه عصبی در [۱۶] معرفی شده است که با الگوریتم ژنتیک برای تنظیم ابرپارامترها بهینه‌سازی شده است. تمرکز بر پیش‌گیری از تصادم‌های عقب به جلو در بستر اینترنت وسایل نقلیه قرار دارد. ارزیابی ریسک با اتکا به پیوندهای وسیله‌نقلیه به زیرساخت و وسیله نقلیه به وسیله نقلیه انجام می‌شود. ترکیب یادگیری عمیق با بهینه‌سازی تکاملی پایداری و دقت پیش‌بینی را ارتقا می‌دهد. نتایج، برتری معنادار نسبت به خطوط پایه را در سناریوهای برخورد نشان می‌دهد.

در [۱۷] با استفاده از YOLOv3 و مدل‌سازی دینامیک حرکت، موقعیت آینده خودروها به‌صورت برخط پیش‌بینی

تولید هشدارهای به موقع برای مدیریت ترافیک و ایمنی را امکان پذیر می سازد.

در [۲۱]، محدودیت های مدل های سنتی در پیش بینی تصادف شناسایی و الگوریتمی مبتنی بر شبکه های هم آمیختی پیشنهاد شده است. استخراج خودکار ویژگی ها وابستگی به مهندسی دستی را کاهش می دهد. نتایج حاکی از کاهش خطا و بهبود دقت پیش بینی نسبت به روش های مرجع است. سازگاری با داده های تصویری و حسی در شبکه های بین خودرویی نشان داده می شود. مسیر بهره گیری از یادگیری عمیق برای پیش بینی ایمن تر در محیط های پرتلاطم ترافیکی تقویت می گردد.

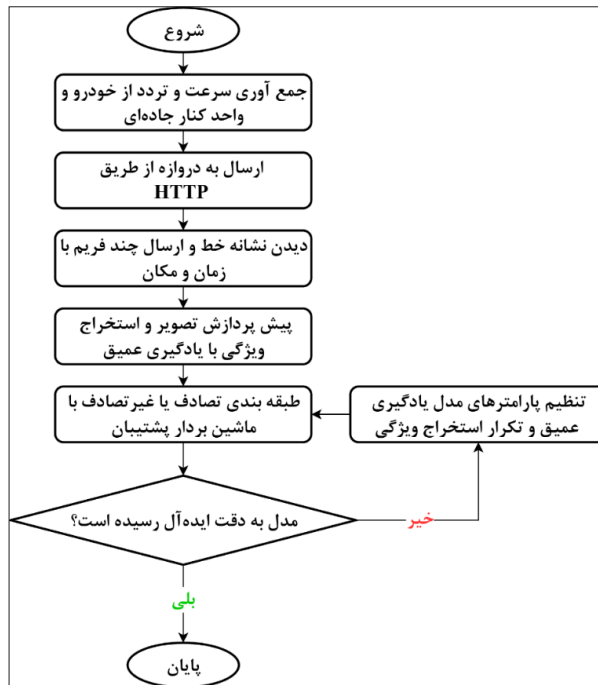
در [۲۲] یک سامانه تشخیص تصادف و اعزام امداد مبتنی بر یادگیری عمیق معرفی شده است که با نصب دوربین وب مجهز به وای فای در حاشیه بزرگراه، عبور خودروها را پیوسته پایش می کند و ویدئو را به ابر می فرستد. در لایه ابری، شبکه عصبی عمیق تحلیل ویدئو را انجام داده و وقوع حادثه را به صورت برخط شناسایی می کند. در صورت تشخیص، پیام هشدار و موقعیت به نزدیک ترین اتاق کنترل ارسال می شود تا عملیات امداد فعال گردد. تمرکز بر سادگی استقرار کنار جاده و مقیاس پذیری پردازش ابری است. محدودیت اصلی، وابستگی به پایداری ارتباط و پوشش شبکه است. در [۲۳] یک سامانه یکپارچه تشخیص، اعلان خودکار و برآورد شدت تصادف ارائه شده که از واحد درون خودرویی برای گردآوری داده هایی مانند سرعت، نوع خودرو و وضعیت کیسه هوا بهره می گیرد. اطلاعات حسگرها به ابر ارسال و با روش های یادگیری ماشین، وقوع و شدت حادثه پیش بینی می شود. مزیت مهم، ترکیب تشخیص با تخمین شدت برای مدیریت بهتر منابع امدادی است. نقطه ضعف کلیدی این است که همه خودروها به واحد درون خودرویی مجهز نیستند. این امر پوشش سامانه را در ناوگان های ناهمگن محدود می کند.

در [۲۴] سامانه ای مبتنی بر شبکه های عصبی هم آمیختی برای دسته بندی دودویی حادثه / غیر حادثه

طراحی شده است. ویدئوی زنده دوربین به سرور منتقل و با مدل هم آمیختی پردازش می شود تا برچسب لحظه ای تولید گردد. برای آموزش، مجموعه داده ای از ویدئوهای یوتیوب ساخته شده و دقت حدود ۹۵ درصد گزارش می شود. تمرکز صرف بر تشخیص است و ماژول های اعزام / نجات در نظر گرفته نشده اند. وابستگی به کیفیت و شرایط محیطی ویدئو می تواند بر پایداری دقت اثر بگذارد. در [۲۵] یک چارچوب بینایی محور برای تشخیص و امداد تصادف در ترافیک آمیخته و شرایط دید ضعیف معرفی شده است. مدل از YOLOV3 از پیش آموزش دیده بهره برده و با داده های باران، مه و دید کم به کمک افزایش داده آموزش داده می شود. ورودی سامانه، ویدئوی زنده دوربین های کنار جاده است و خروجی، تشخیص آنی رخداد و هشدار می باشد. دقت ۹۲/۵ درصد و نرخ هشدار کاذب ۷/۵ درصد گزارش شده است. هدف، حفظ کارایی در سناریوهای دشوار بصری و پشتیبانی از عملیات امداد است.

در [۲۶] ترکیب اینترنت اشیا و یادگیری ماشین برای تشخیص تصادف و فعال سازی ماژول امداد به کار گرفته شده است. داده های حادثه با کیت اینترنت اشیا جمع آوری و به جای ابر، بر بستر رایانش مه به صورت محلی پردازش می شوند تا تأخیر کاهش یابد. هسته تصمیم گیری بر الگوریتم های یادگیری ماشین تکیه دارد و اعلان به صورت محلی / ناحیه ای انجام می شود. پیچیدگی سیگنال های چندوجهی به ویژه ویدئو می تواند دقت را محدود کند. با این حال، معماری مه محور برای پهنای باند محدود و نیاز به واکنش سریع مزیت عملی دارد.

در [۲۷] روشی بر پایه یادگیری عمیق تجمیعی با داده چندوجهی دوربین داشبورد ارائه شده است. ویدئو و صوت هم زمان گردآوری می شوند و با ترکیب شبکه هم آمیختی و واحد بازگشتی دروازه دار، تشخیص و طبقه بندی حادثه انجام می گیرد. هم افزایی دو مدالیته برای بهبود دقت طراحی شده است. محدودیت مهم، آسیب پذیری



شکل ۱. روندنمای روش پیشنهادی

تصاویر به همراه زمان و مکان به سامانه‌ی مرکزی ارسال می‌گردد. مرحله ۲ (استخراج ویژگی تصویری): سامانه مرکزی همین تصاویر را پردازش می‌کند و آنها را به مجموعه‌ای از ویژگی‌های تصویری خلاصه و قابل استفاده تبدیل می‌کند تا به جای تکیه بر ویدئوی خام، نمایی فشرده از صحنه داشته باشیم. مرحله ۳ (طبقه‌بندی دودویی با ماشین بردار پشتیبان): بر پایه این ویژگی‌ها، یک طبقه‌بند ماشین بردار پشتیبان تصمیم می‌گیرد تصادف رخ داده است یا خیر. در صورت تصادف بودن خروجی مدل، یک هشدار صادر می‌شود و به مراکز اطلاع داده می‌شود. روندنمای روش پیشنهادی در شکل ۱ نشان داده شده است.


### ۳-۱- مرحله اول. جمع‌آوری داده بر بستر اینترنت اشیا

در مرحله ۱ یک معماری چندلایه بر پایه اینترنت خودروها اجرا می‌شود تا داده‌ها برای تشخیص و پیشگیری از تصادف به صورت پیوسته جمع‌آوری و برای تحلیل آماده شود. لایه پایین دو منبع اصلی دارد: خودرو و واحدهای کنار جاده‌ای. روی خودرو، دستگاه

دوربین داشبورد در لحظه برخورد و اتکای صرف به دوربین (بدون حسگرهای اینترنت اشیا) است که می‌تواند مثبت کاذب را افزایش دهد. با این وجود، برای ناوگان‌های مجهز به دوربین مسیر استقرار کم‌هزینه فراهم می‌شود. در [۲۸] یک چارچوب یادگیری ماشین برای تشخیص خودکار تصادف با تکیه بر حسگرهای چندوجهی درون خودرو معرفی شده است. ترکیب شبکه هم‌آمیختگی و ماشین بردار پشتیبان، پس از انتخاب ویژگی‌های شاخص، برای تصمیم‌گیری به کار می‌رود. دقت آزمون حدود ۸۵ درصد گزارش شده که برای کاربردهای ایمنی-حیاتی کفایت مرزی دارد و نیازمند بهبود است. جزئیات مازول اینترنت اشیا و یکپارچه‌سازی حسگرها به خوبی تشریح شده است. تمرکز بر استخراج ویژگی‌های پرمعنا از داده متنوع، بنیانی برای ارتقای قابلیت اتکا فراهم می‌کند. جدول ۱ مقایسه‌ای از مزایا و معایب کارهای گذشته را نشان می‌دهد.

### ۳- روش پیشنهادی

افزایش ترافیک شهری، دیر فهمیدن وقوع تصادف باعث بالا رفتن تلفات، طولانی شدن رسیدن امداد و بسته شدن مسیرها می‌شود. تکیه بر گزارش مردم یا پایش دستی دوربین‌ها کند و پرخاست؛ از طرفی نور و هوا عوض می‌شود، پهنای باند محدود است و خود تصادف هم رخداد نادری است، پس اگر مراقب نباشیم هشدارهای بی‌خودی زیاد می‌شود. بنابراین به سامانه‌ای نیاز داریم که با تکیه بر داده‌های اینترنت اشیا و تصاویر، سریع، دقیق و با هشدار کاذب کم بتواند وقوع تصادف را تشخیص دهد. برای حل این مسئله، یک روش سه‌فازی پیشنهاد می‌کنیم. مرحله ۱ (جمع‌آوری و ارسال داده با اینترنت اشیا): خودروها و واحدهای کنار جاده اطلاعاتی مانند سرعت، تعداد عبوری خودروها و وضعیت تقاطع را به یک دستگاه میانی می‌فرستند؛ اگر نشانه‌ای از خطر دیده شد، دوربین داشبورد یا کنار جاده فقط برای چند ثانیه فعال می‌شود و



شکل ۲. معماری پیشنهادی برای جمع‌آوری داده

به مراحل بعدی برای استخراج ویژگی تصویری و تصمیم‌گیری با تاخیر کم و هزینه ارتباطی کنترل‌شده وارد می‌شود. معماری پیشنهادی برای جمع‌آوری داده‌ها در شکل ۲ نشان داده شده است.

### ۳-۲. مرحله دوم. استخراج ویژگی


در مرحله ۲ خروجی مرحله ۱ یعنی قاب‌های  $224 \times 224 \times 3$  پس از پیش‌پردازش وارد یک استخراج‌کننده سبک و دقیق می‌شود که برای کار بیدرنگ طراحی شده است. معماری استخراج‌کننده ویژگی در شکل ۳ نشان داده شده است. زنجیره از یک بلوک آغازین هم‌آمیختگی شروع می‌شود و با چند بلوک هم‌آمیختگی تفکیک‌پذیر عمقی برای کاهش هزینه محاسبه ادامه پیدا می‌کند. سپس دو ماژول Inception با شاخه‌های موازی هسته‌های متفاوت، الگوهای

تشخیص عیب در خودرو داده‌های وضعیت مثل سرعت، سطح سوخت، وضعیت باتری و کدهای خطای موتور را فراهم می‌کند و گیرنده مکان‌یاب مختصات طول و عرض جغرافیایی، زمان و در صورت امکان ارتفاع را ثبت می‌کند. در سوی دیگر، واحدهای کنار جاده‌ای در تقاطع‌ها و حاشیه راه اطلاعات زمینه‌ای ترافیک را فراهم می‌کند؛ از جمله زمان‌بندی چراغ‌ها، طول صف‌ها، زمان‌انتظار در هر مرحله چراغ و حجم عبوری در بازه‌های زمانی مشخص. برای انتقال داده از لایه پایین، ارتباطات سبک و قابل اعتماد به‌کار می‌رود و خودرو و واحدهای کنار جاده‌ای داده‌های خام و خلاصه را با پروتکل انتقال ابرمتن روی بسترهای سلولی (وای‌فای) به کارساز میانی می‌فرستند.

هر منبع یک شناسه یکتا دارد و هر پیام شامل برچسب زمان، برچسب مکان، نوع منبع و بدنه داده است. کارساز میانی فقط نقش نقطه تجمع، همگام‌سازی دریافت چندمنبعی، ساخت بسته یکتا و میانگیر حلقه‌ای کوتاه را بر عهده دارد تا در صورت قطعی کوتاه شبکه، داده‌ها از دست نروند؛ سپس داده به ابر ارسال می‌شود. همگام‌سازی زمانی پیام‌ها با پروتکل زمان شبکه انجام می‌شود و برچسب زمان به زمان هماهنگ جهانی تبدیل می‌شود؛ برای هم‌ترازسازی مکانی، نقاط مکان‌یاب به شناسه قطعه راه نگاشت می‌شود تا تحلیل‌ها بر پایه قطعه‌های ثابت انجام شود.

در ابر عملیات داده‌ای انجام می‌شود: پاک‌سازی و نرمال‌سازی مقادیر، ساخت تجمیع‌های پنجره‌ای (مثلاً پنجره‌های ۱ دقیقه و ۵ دقیقه با اسلاید ۳۰ ثانیه)، و برچسب‌گذاری رویدادهای نامعمول (مثل جهش ناگهانی طول یا افت شدید سرعت) به‌صورت پرچم‌های کم‌حجم کنار داده اصلی. در ادامه، در همان ابر گام‌های کاهش بعد و انتخاب ویژگی اجرا و داده آماده ورود به مرحله مدل‌سازی می‌شود. خروجی نهایی مرحله ۱ یک جریان چندمنبعی همگام‌شده با زمان و مکان، همراه با داده‌ها (شناسه منبع، نوع اندازه‌گیری، واحد، کیفیت)، تجمیع‌های پنجره‌ای و پرچم‌های ریسک است که مستقیماً





شکل ۳. مدل استخراج ویژگی

$$\hat{Y}_c(i, j) = \sum_{u, v} K_c(u, v) \cdot X_c(i+u, j+v) \quad (2)$$

$$Z_k(i, j) = \sum_c P_{k,c} \cdot \hat{Y}_c(i, j) \quad (3)$$

خروجی این بلوکها به ترتیب به ابعاد  $32 \times 56 \times 56$  و سپس  $28 \times 28 \times 64$  می رسد. پس از آن یک ماژول Inception با چند شاخه موازی اعمال می شود؛ نگاشت خروجی حاصل هم نشانی کانالی شاخه ها است که در رابطه (۴) نشان داده شده است:

$$A = \text{Concat}(F_1(X), F_2(X), \dots, F_B(X)). \quad (4)$$

میان بر باقیمانده (اتصال اول) خروجی این ماژول را با ورودی هم تراز جمع می کند تا گرادیانها پایدار بمانند:

$$H_1 = \sigma(BN(A) + SX) \quad (5)$$

که در آن S مسیر تنظیم کننده و  $\sigma$  تابع فعال ساز است. مسیر استخراج سپس با تکرار الگوی هم آمیختی + تجمیع به نگاشت  $14 \times 14 \times 128$  می رسد و وارد بلوک دوم Inception می شود. در انتهای این ناحیه، ماژول توجه برای برجسته سازی کانالهای مهم به کار می رود؛ نسخه سبک توجه کانالی به صورت روابط (۶) تا (۸) عمل می کند که  $\delta$  فعال ساز میانی و  $\sigma$  سیگموید است.

$$s_c = \frac{1}{HW} \sum_{i,j} H_c(i, j) \quad (6)$$

مکانی در مقیاسهای گوناگون را می گیرند و هر کدام با یک اتصال میان بر جمع می شوند تا گرادیان پایدار بماند. میان این دو ناحیه، لایه های تجمیع اندازه نگاشت ها را کم می کنند و در انتها یک ماژول توجه کانالی اهمیت هر کانال را وزن دهی می کند تا ویژگی های مرتبط با برخورد برجسته شوند.

نگاشت نهایی  $14 \times 14 \times 256$  با میانگین گیری سراسری به یک بردار کم حجم تبدیل می شود؛ این بردار ویژگی استاندارد برای مرحله ۳ است. اگر بخواهیم طبقه بندی را در همین ماژول انجام بدهیم، یک هم آمیختی  $1 \times 1$  و سافت مکس هم افزوده می شود، ولی در سناریوی استخراج ویژگی همین بردار خروجی تحویل طبقه بند می شود. ورودی تصویر با اندازه  $224 \times 224 \times 3$  ابتدا وارد بلوک آغازین هم آمیختی می شود و پس از تجمیع میان گیری به نگاشت  $112 \times 112 \times 16$  می رسد. هر لایه هم آمیختی برای کانال خروجی c به صورت رابطه (۱) محاسبه می شود.

$$Y_c(i, j) = \sum_{c'} \sum_{u, v} W_{c,c'}(u, v) \cdot X_{c'}(i+u, j+v) + b_c \quad (1)$$

در ادامه از لایه های هم آمیختی تفکیک پذیر عمقی استفاده می شود تا هزینه محاسبه کم شود. گام اول هم آمیختی عمقی روی هر کانال به تنهایی انجام می شود و گام دوم هم آمیختی  $1 \times 1$  برای آمیختن کانال ها است که به ترتیب در روابط (۲) و (۳) نشان داده شده اند.

می‌رود. در مسئله دودویی با داده‌های برچسب‌دار  $(x_i, y_i)$  هدف ماشین بردار پشتیبان یافتن ابرصفحه جداساز  $w^T x + b = 0$  با بیشترین حاشیه است. اگر داده‌ها خطی جدایی‌پذیر باشند، می‌توان قیود زیر را تحمیل کرد:

$$\begin{cases} w^T x_i + b \geq 1, & \text{if } y_i = +1 \\ w^T x_i + b \leq -1, & \text{if } y_i = -1 \end{cases} \quad (12)$$

حاشیه هندسی برابر  $\frac{2}{\|w\|}$  است، پس بیشینه‌سازی حاشیه معادل با کمینه‌سازی  $\frac{1}{2}\|w\|^2$  تحت قیود فوق است. در عمل نقاط نوفه وجود دارد. ماشین بردار پشتیبان نرم‌حاشیه با معرفی متغیرهای خطا  $\xi_i \geq 0$  و پارامتر جریمه  $C > 0$  مسئله را به شکل زیر حل می‌کند:

$$\min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (13)$$

$$y_i [w^T x_i + b] \geq 1 - \xi_i, \quad \xi_i \geq 0$$

با تشکیل لاگرانژین و حذف متغیرهای اولیه، به مسئله دوگان می‌رسیم:

$$\max_{\alpha \in \mathbb{R}^n} W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i^T x_j) \quad (14)$$

که در آن شروط زیر باید برقرار باشد:

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad (15)$$

جواب بهینه  $\alpha^*$  معمولاً کم‌بعد است؛ نقاطی که  $\alpha_i^* > 0$  دارند بردار پشتیبان‌اند و مرز تصمیم را می‌سازند. تابع تصمیم نهایی به صورت زیر است:

$$f(x) = \sum_{i=1}^n \alpha_i^* y_i (x_i^T x) + b^* \quad (16)$$

اگر جداسازی خطی در فضای ورودی دشوار باشد، داده‌ها را با نگاشت غیرخطی  $\phi(\cdot)$  به فضای ویژگی با ابعاد

$$a = \sigma(W_2 \cdot \delta(W_1 s)) \quad (7)$$

$$H_c(i, j) = a_c H_c(i, j) \quad (8)$$

اتصال باقیمانده (اتصال دوم) دوباره به صورت رابطه‌ی (۹) اعمال می‌شود و نمای نهایی ویژگی با اندازه  $256 \times 14 \times 14$  تولید می‌گردد.

$$H_2 = \sigma(BN(H') + S'H_1) \quad (9)$$

برای تبدیل نگاشت فضایی به بردار ویژگی کم‌حجم، میانگین‌گیری سراسری روی هر کانال انجام می‌شود:

$$z_k = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W H_{2,k}(i, j) \quad (10)$$

بردار  $z$  سپس با نرمال‌سازی  $L_2$  یکنوا می‌شود تا برای طبقه‌بند پایدار باشد:


$$z' = \frac{z}{\|z\|_2 + \varepsilon} \quad (11)$$

### ۳-۳. مرحله سوم. طبقه‌بندی


در فاز ۳، بردار ویژگی  $256$  بعدی خروجی فاز ۲ به طبقه‌بند ماشین بردار پشتیبان داده می‌شود تا بین تصادف و غیرتصادف تصمیم بگیرد. پیش از آموزش، ویژگی‌ها با استانداردسازی ساده هم مقیاس می‌شوند تا مؤلفه‌های پرنوسان کنترل شوند. هسته پیشنهادی تابع شعاعی است و ابرپارامترهای  $C$  و گاما با اعتبارسنجی متقابل و جستجو شبکه‌ای انتخاب می‌شوند تا بهترین تعادل بین دقت و پایداری به دست آید. برای خروجی شفاف، نمره تصمیم ماشین بردار پشتیبان با کالیبراسیون پلات به احتمال تبدیل می‌شود.

برای کاهش هشدار بی‌مورد، میانگین‌گیری زمانی کوتاه روی احتمال‌ها و هم‌نظر کردن چند منبع در ابر به کار





شکل ۴. نمودار دقت آموزش و اعتبارسنجی



شکل ۵. نمودار خطای آموزش و اعتبارسنجی.

دوره ۱۲۰ زیر ۱ درصد می ماند که نشانه نبود بیش برآزش معنادار و تعمیم پذیری خوب است. این رفتار با افزایش داده، نرمال سازی یکنواخت و طراحی سبک استخراج گر همسو است و نشان می دهد مرز تصمیم گیری ثبات شکل گرفته است. بر مبنای این نمودار، انتخاب بهترین وزن ها با معیار بیشینه دقت اعتبارسنجی در بازه ۱۰۰ تا ۱۴۰ اپیاک توجیه پذیر است و ادامه آموزش سود حاشیه ای اندک دارد شکل ۵ روند خطای آموزش و اعتبارسنجی را نشان می دهد. کاهش خطای آموزش در ۱۰ تا ۱۵ دوره نخست و رسیدن به سطوح بسیار پایین بیانگر همگرایی سریع است. خطای اعتبارسنجی از مقدار بالا در ابتدا به حوالی ۰/۷ در حدود دوره ۲۵ تا ۳۰ می رسد و سپس با نوسان های مقطعی در دوره های ۴۰ تا ۵۰ به سمت یک مرحله پایدار میل می کند؛ این جهش های کوتاه می تواند ناشی از دسته های سخت، افزایش داده تهاجمی یا ناهمخوانی سبک صحنه باشد. فاصله پایدار میان خطای آموزش بسیار کم و خطای اعتبارسنجی بزرگتر، همراه با دقت بالای شکل ۴، حاکی از اعتماد بیش از حد مدل روی نمونه های آسان و

بالا تر می بریم. محصول داخلی در فضای  $\phi$  را با یک تابع کرنل به صورت رابطه (۱۷) محاسبه می کنیم.

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (17)$$

این ترغیب بدون محاسبه صریح  $\phi$  امکان مدل سازی غیرخطی را فراهم می کند. در نتیجه نرم حاشیه هسته ای، دوگان به شکل زیر است:

$$\max_{\alpha} W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (18)$$


طبق رابطه (۱۷)، تابع تصمیم نهایی به صورت رابطه (۱۹) است:

$$f(x) = \sum_{i=1}^n \alpha_i^* y_i K(x_i, x) + b^* \quad (19)$$

#### ۴. آزمایش ها و نتایج

در این بخش روش پیشنهادی را به صورت جامع ارزیابی می کنیم و عملکرد آن را در شرایط یکسان با چهار خط مبنا مقایسه می کنیم: VGG-19 [۲۹]، ResNet-50 [۳۰]، DenseNet121 [۳۱] و InceptionV3 [۳۲]. برای رعایت انصاف آزمایشی، همه مدل ها با ورودی هم اندازه و طرح افزایش داده یکسان آموزش دیده اند و ابر پارامترها بر پایه اعتبارسنجی تنظیم شده اند. معیارهای گزارش شده شامل فراخوانی، دقت مثبت، صحت و دقت است. مجموعه داده استفاده شده برای انجام آزمایش ها از مرجع [۳۳] گرفته شده است.

شکل ۴ روند دقت آموزش و اعتبارسنجی را نشان می دهد. منحنی ها نشان می دهند روش پیشنهادی پس از چند ده دوره به ناحیه پایدار می رسد؛ دقت آموزش از حدود ۰/۷ در ابتدا به نزدیک ۰/۹۹ می رسد و دقت اعتبارسنجی از حدود ۰/۵۸ به حدود ۰/۹۸ در حوالی دوره های ۹۰ تا ۱۱۰ می رسد. شکاف میان دو منحنی در ابتدا قابل توجه است اما به تدریج کم شده و بعد از حدود



شکل ۶. مقایسه اثر پارامتر C در ماشین بردار پشتیبان بر شاخص‌های ارزیابی روی بخش آزمون: (الف)  $C=0.1$ ، (ب)  $C=0.3$ ، (ج)  $C=0.5$ ، (د)  $C=0.7$ . با افزایش C حاشیه کوچک می‌شود و مدل از کم‌برازش به سمت بیش‌برازش میل می‌کند؛ C‌های کوچک محافظه‌کار و با فراخوانی پایین‌تر، C‌های بزرگ با مثبت کاذب بیشتر همراه است. بهترین توازن دقت و حساسیت در  $C=0.5$  به دست می‌آید و بالاترین صحت و دقت کلی ثبت می‌شود.


حضور نمونه‌های اقلیتی سخت است.

شکل ۶ تاثیر مقدار پارامتر C بر دقت مدل را نشان می‌دهد. در مقدار کم (الف) حاشیه بزرگ نگه داشته می‌شود و مدل گرایش به ساده‌سازی دارد. نتیجه این است که دقت مثبت و فراخوانی حدود ۹۵ تا ۹۶ درصد بوده و صحت نزدیک ۹۵/۵ درصد است، در حالی که دقت به دلیل غلبه نمونه‌های آسان به حدود ۹۸/۳ درصد می‌رسد. این الگو نشانه کم‌برازش و محافظه‌کاری در مرز تصمیم است که به از دست رفتن بخشی از نمونه‌های حادثه منجر می‌شود. افزایش ملایم C می‌تواند توازن بهتری میان خطاهای نوع اول و دوم ایجاد کند و صحت را بالا ببرد.

با افزایش C (ب) مرز تصمیم سخت‌تر می‌شود و خطاهای مثبت کاذب کاهش می‌یابد؛ از این‌رو دقت مثبت تا حوالی ۹۸/۵ درصد بالا می‌رود اما فراخوانی به حدود ۹۵/۳ درصد افت می‌کند. صحت در حدود ۹۷ درصد قرار می‌گیرد و دقت نزدیک ۹۸/۶ درصد است. این رفتار بیانگر تمایل مدل به انتخاب‌گری بیشتر است؛ یعنی هشدار کمتر ولی جاافتادگی بیشتر. برای سناریوهای

ایمنی، چنین عدم تعادل می‌تواند مطلوب نباشد چون از دست دادن حادثه هزینه بالایی دارد.  $C=0.5$  (ج) بهترین توازن را میان معیارها نشان می‌دهد؛ دقت مثبت نزدیک ۹۹ درصد، فراخوانی نزدیک ۹۹/۸ درصد، صحت حدود ۹۹/۴ درصد و دقت حوالی ۹۹/۶ درصد است. هم‌زمان هم حساسیت بالا حفظ می‌شود هم دقت هشدار، که با هدف کاهش مثبت کاذب و منفی کاذب همسو است. چنین نقطه‌ای با منحنی‌های همگرایی پیش‌تر نیز سازگار است و نشان می‌دهد تنظیم C به ۰/۵ مرز تصمیم را برای داده‌های چندمنبعی و شرایط متغیر پایدار می‌کند. افزایش بیشتر C (د) موجب کوچک‌شدن حاشیه و تمایل به برآزش بیش از حد می‌شود. فراخوانی همچنان بسیار بالا و نزدیک ۹۹/۲ درصد باقی می‌ماند اما دقت مثبت به حدود ۹۷/۴ درصد افت می‌کند و صحت حوالی ۹۸/۳ درصد قرار می‌گیرد؛ دقت نیز نزدیک ۹۹/۱ درصد است.

این الگو حاکی از افزایش مثبت کاذب در برابر ۰/۵ است. در کاربرد تشخیص حادثه که هزینه هشدار بی‌مورد هم مهم است، مقدار ۰/۵ انتخاب متعادل‌تری نسبت به ۰/۷



شکل ۷. مقایسه روش استخراج ویژگی مدل پیشنهادی با خطوط مبنا VGG-19، ResNet-50، DenseNet121 و InceptionV3 در چهار معیار (الف) فراخوانی، (ب) دقت، (ج) صحت و (د) دقت مثبت.


برای مدل پیشنهادی حدود ۹۸/۵ درصد است و از VGG-19 حدود ۹۶/۵، DenseNet121 حدود ۹۵/۵، ResNet-50 حدود ۹۴/۵ و InceptionV3 حدود ۹۲/۵ درصد فراتر می‌رود. صحت بالا یعنی هم مثبت کاذب و هم منفی کاذب پایین است. ترکیب ویژگی‌های چندمقیاسی، توجه کانالی و دسته‌بند ماشین بردار پشتیبان با ۷ و C تنظیم شده باعث تمایز بهتر میان حادثه واقعی و رویدادهای شبه‌حادثه شده است. این ویژگی برای هشدار برخط در ترافیک شهری حیاتی است. در شکل ۷ (د) دقت مثبت مدل پیشنهادی حدود ۹۸ درصد است و بالاتر از DenseNet121 و VGG-19 هر دو حوالی ۹۶ درصد، ResNet-50 حدود ۹۵ درصد و InceptionV3 حدود ۹۳ درصد قرار می‌گیرد. دقت بالاتر یعنی کاهش هشدار بی‌مورد که برای مراکز امدادی اهمیت عملی دارد. مازول‌های چندمقیاسی و توجه کانالی با کاهش اثر اجسام مزاحم و شبه‌تصادف، مرزهای اشتباه را محدود می‌کند و اجماع زمانی از جهش‌های کاذب جلوگیری می‌کند.

جدول ۲ مقایسه نتایج روش پیشنهادی را جدیدترین مراجع که در سال‌های ۲۰۲۳ تا ۲۰۲۵ منتشر شده‌اند، مقایسه می‌کند.

ارائه می‌دهد. شکل ۷ مقایسه مدل پیشنهادی استخراج‌کننده ویژگی را با مدل‌های موجود نشان می‌دهد. در (الف) روش پیشنهادی بالاترین حساسیت را نشان می‌دهد و حوالی ۹۹ درصد قرار می‌گیرد، در حالی که VGG-19 حدود ۹۷، DenseNet121 حدود ۹۵، ResNet-50 حدود ۹۴ و InceptionV3 نزدیک ۹۲ درصد است.

برتری در فراخوانی یعنی احتمال از دست دادن حادثه کمتر است که برای کاربرد ایمنی کلیدی است. ترکیب ویژگی‌های چندمقیاسی با توجه کانالی و نمایه فشرده ۲۵۶ بعدی همراه با میانگین‌گیری زمانی و هم‌نظری منابع، نمونه‌های مرزی را بهتر پوشش می‌دهد. به همین دلیل مدل پیشنهادی در سناریوهای دشوار مانند نور و هوا متغیر حساسیت خود را حفظ می‌کند. در شکل ۷ (ب) دقت کلی مدل پیشنهادی نزدیک ۹۹ درصد و بالاتر از VGG-19 حدود ۹۷/۴، DenseNet121 حدود ۹۷، ResNet-50 حدود ۹۶ و InceptionV3 حدود ۹۴/۷ درصد است. این نتیجه نشان می‌دهد مرز تصمیم نه تنها نمونه‌های حادثه را به خوبی بازیافت می‌کند بلکه در نمونه‌های غیرحادثه هم پایدار است.

در شکل ۷ (ج) میانگین هارمونیک دقت مثبت و فراخوانی




شکل ۹. ماتریس آشفتگی آزمایش

### ۵. نتیجه‌گیری و کارهای آینده

در این پژوهش یک چارچوب سه‌مرحله‌ای برای تشخیص بیدرنج تصادف در ترافیک شهری معرفی شد که با ارسال گزینشی ویدئو از لبه هنگام مشاهده نشانه خطر، همگام‌سازی و پاک‌سازی در کارساز میانی و استخراج ویژگی سبک (هم‌آمیختی تفکیک‌پذیر عمقی، دو بلوک Inception با اتصال باقیمانده و توجه کانالی) نمایه ۲۵۶ بعدی نرمال شده می‌سازد. این نمایه با ماشین بردار پشتیبان هسته تابع شعاعی و کالیبراسیون احتمال طبقه‌بندی می‌شود و با هموارسازی زمانی و اجماع چندمنبع نرخ هشدار بی‌مورد کاهش می‌یابد. در مقایسه منصفانه با خطوط مبنا (DenseNet121, ResNet-50)، VGG-19 و InceptionV3) روش پیشنهادی به دقت ۹۹ درصد، فراخوانی ۹۹ درصد، دقت مثبت ۹۸ درصد و صحت ۹۸/۵ درصد رسید و در ماتریس آشفتگی آزمایش تنها ۷ خطا از ۴۰۰ نمونه ثبت شد. جستجوی ابرپارامترها نشان داد  $C=0.5$  برای ماشین بردار پشتیبان توازن بهینه بین حساسیت و ویژگی فراهم می‌کند. این نتایج دلالت بر تعمیم‌پذیری خوب، پایداری در شرایط دید دشوار و آمادگی استقرار در مقیاس شهری دارد. در کارهای آینده بر گسترش‌پذیری و پایداری سامانه تمرکز می‌کنیم؛ نخست، ارزیابی میان‌دامنه‌ای روی شهرها و دوربین‌های ناهمگون همراه با روش‌های تطبیق حوزه برای کاهش افت دقت در انتقال بین محیط‌ها. دوم، بهره‌گیری از پیش‌آموزش خودنظارتی روی ویدئوهای بدون برچسب و استقرار

جدول ۲: مقایسه روش پیشنهادی و سایر مراجع

| مرجع         | دقت | صحت   | فراخوانی | دقت مثبت |
|--------------|-----|-------|----------|----------|
| روش پیشنهادی | ۹۹٪ | ۹۸/۵٪ | ۹۹٪      | ۹۸٪      |
| [۳۴]         | ۹۷٪ | ۹۶٪   | ۹۸٪      | ۹۴٪      |
| [۳۵]         | ۹۸٪ | ۹۴٪   | ۹۵٪      | ۹۳٪      |
| [۳۶]         | ۹۷٪ | ۹۴٪   | ۹۶٪      | ۹۲٪      |



شکل ۸. ماتریس آشفتگی آموزش

ماتریس آشفتگی شکل ۸ نشان می‌دهد مدل در آموزش عملکردی نزدیک به ایده‌آل دارد؛ از مجموع ۱۶۰۰ نمونه تنها ۱۱ مورد خطا ثبت شده است. برای کلاس تصادف، فراخوانی حدود ۹۹/۲۵ درصد و دقت مثبت حدود ۹۹/۳۷ درصد است و صحت نزدیک ۹۹/۳۱ درصد به دست می‌آید؛ در سوی مقابل، برای کلاس غیرتصادف ویژگی حدود ۹۹/۲۸ درصد گزارش می‌شود. نرخ مثبت کاذب برابر ۰/۰۰۶۳ و نرخ منفی کاذب ۰/۰۰۷۵ است که توازن خطاها را میان دو کلاس تأیید می‌کند.

ماتریس آشفتگی تست در شکل ۹ نشان می‌دهد مدل روی ۴۰۰ نمونه شامل ۲۰۰ حادثه و ۲۰۰ غیرحادثه تنها ۷ خطا دارد؛ ۴ مورد از نوع منفی کاذب و ۳ مورد از نوع مثبت کاذب. دقت کلی ۹۸/۲۵ درصد، بازیابی کلاس حادثه ۹۸ درصد و دقت مثبت برای حادثه ۹۸/۵ درصد است و صحت ۹۸/۳ درصد به دست می‌آید. نسبت کم منفی کاذب نشان می‌دهد مدل در از دست ندادن رخدادها واقعی موفق عمل می‌کند، در حالی که سطح مثبت کاذب نیز پایین باقیمانده است. این الگو بیانگر تعمیم‌پذیری خوب از آموزش به تست و پایداری مرز تصمیم در سناریوهای متنوع است.

- [14] Pan, R., Jie, L., Zhang, X., Pang, S., Wang, H., & Wei, Z. (2022). A V2P collision risk warning method based on LSTM in IoV. *Security and Communication Networks*.
- [15] Chang, C.-C., Ooi, Y.-M., & Sieh, B. H. (2021). IoV-based collision avoidance architecture using machine learning prediction. *IEEE Access*, 9, 115497–115505.
- [16] Chen, C., Xiang, H., Qiu, T., Wang, C., Zhou, Y., & Chang, V. (2018). A rear-end collision prediction scheme based on deep learning in the Internet of Vehicles. *Journal of Parallel and Distributed Computing*, 117, 192–204.
- [17] Chang, C.-C., Lin, W.-M., & Lai, C.-A. (2019). Using real-time dynamic prediction to implement IoV-based collision avoidance. *Applied Sciences*, 9(24), 5370.
- [18] Aung, N., Zhang, W., Dhelim, S., & Ai, Y. (2018). Accident prediction system based on hidden Markov model for vehicular ad-hoc network in urban environments. *Information*, 9(12), 311.
- [19] Kumar, N., Sood, S. K., & Saini, M. (2023). IoV-fog-assisted framework for accident detection and classification. *ACM Transactions on Embedded Computing Systems*.
- [20] Tantaoui, M., Laanaoui, M. D., & Kabil, M. (2021). Big data accident prediction system in green networks and intelligent transportation systems. In *Emerging trends in ICT for sustainable development: The proceedings of NICE2020 international conference* (pp. 121–127). Springer International Publishing.
- [21] Zhao, H., Cheng, H., Mao, T., & He, C. (2019, May). Research on traffic accident prediction model based on convolutional neural networks in VANET. In *2019 2nd International Conference on Artificial Intelligence and Big Data (ICAIBD)* (pp. 79–84). IEEE.
- [22] Rajesh, G., Benny, A. R., Harikrishnan, A., Abraham, J. J., & John, N. P. (2020, July). A deep learning based accident detection system. In *2020 international conference on communication and signal processing (ICCSP)* (pp. 1322–1325). IEEE.
- [23] Fogue, M., Garrido, P., Martinez, F. J., Cano, J. C., Calafate, C. T., & Manzoni, P. (2013). A system for automatic notification and severity estimation of automotive accidents. *IEEE Transactions on mobile computing*, 13(5), 948–963.
- [24] Ghosh, S., Sunny, S. J., & Roney, R. (2019, March). Accident detection using convolutional neural networks. In *2019 international conference on data science and communication (IconDSC)* (pp. 1–6). IEEE.
- [25] Wang, C., Dai, Y., Zhou, W., & Geng, Y. (2020). A vision-based video crash detection framework for mixed traffic flow environment considering low-visibility condition. *Journal of advanced transportation*, 2020(1), 9194028.
- [26] Bhakat, A., Chahar, N., & Vijayashery, V. (2021, August). Vehicle accident detection & alert system using IoT and artificial intelligence. In *2021 Asian conference on innovation in technology (ASIANCON)* (pp. 1–7). IEEE.
- [27] Choi, J. G., Kong, C. W., Kim, G., & Lim, S. (2021). Car crash detection using ensemble deep learning and multimodal data from dashboard cameras. *Expert systems with applications*, 183, 115400.

یادگیری فدرال برای حفظ حریم خصوصی و کاهش هزینه برچسب‌گذاری.

## ۶. مراجع

- [1] Arefin, M. S., Mahin, M. I. S., & Mily, F. A. (2025). Real-time rapid accident detection for optimizing road safety in Bangladesh. *Heliyon*, 11(4).
- [2] Musa, A. A., Malami, S. I., Alanazi, F., Ounaies, W., Alshammari, M., & Haruna, S. I. (2023). Sustainable traffic management for smart cities using Internet-of-Things-oriented intelligent transportation systems (ITS): Challenges and recommendations. *Sustainability*, 15(13), 9859.
- [3] Oladeji, E. O., Ezeme, C., Baiyewu, L. A., Okunola, M. O., & Ogunlade, S. O. (2024). The catastrophic cost of motorcycle road traffic injuries: Experience from a major reference centre in a lower-middle income country. *Injury*, 111314.
- [4] Kaledio, P., Oloyede, J., Olaoye, F., & Lucas, D. (2023). The internet of things: Transforming industries, empowering connectivity, and shaping the future.
- [5] Aldhanhani, T., Abraham, A., Hamidouche, W., & Shaaban, M. (2024). Future trends in smart green IoV: Vehicle-to-everything in the era of electric vehicles. *IEEE Open Journal of Vehicular Technology*.
- [6] Amlan, K. N. H., Uddin, M. S., Mahmud, T., & Riyan, N. B. (2023). IoT, cloud computing, and sensing technology for smart cities. In *Intelligent techniques for cyber-physical systems* (pp. 267–291). CRC Press.
- [7] Deng, B., Nan, J., Cao, W., & Wang, W. (2023). Survey on integration of network communication into vehicle real-time motion control. *IEEE Communications Surveys & Tutorials*.
- [8] Wang, X., Zhu, H., Ning, Z., Guo, L., & Zhang, Y. (2023). Blockchain intelligence for Internet of Vehicles: Challenges and solutions. *IEEE Communications Surveys & Tutorials*.
- [9] Dikshit, S., Atiq, A., Shahid, M., Dwivedi, V., & Thusu, A. (2023). The use of artificial intelligence to optimize the routing of vehicles and reduce traffic congestion in urban areas. *EAI Endorsed Transactions on Energy Web*, 10.
- [10] Sohail, A., Cheema, M. A., Ali, M. E., Toosi, A. N., & Rakha, H. A. (2023). Data-driven approaches for road safety: A comprehensive systematic literature review. *Safety Science*, 158, 105949.
- [11] Taslimasa, H., Dadkhah, S., Neto, E. C. P., Xiong, P., Ray, S., & Ghorbani, A. A. (2023). Security issues in Internet of Vehicles (IoV): A comprehensive survey. *Internet of Things*, 100809.
- [12] Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., & Matsopoulos, G. K. (2023). A review of ARIMA vs. machine learning approaches for time series forecasting in data-driven networks. *Future Internet*, 15(8), 255.
- [13] Reddy, K. R., & Muralidhar, A. (2023). Machine learning-based road safety prediction strategies for Internet of Vehicles (IoV) enabled vehicles: A systematic literature review. *IEEE Access*.

- [28] Hozhabr Pour, H., Li, F., Wegmeth, L., Trense, C., Doniec, R., Grzegorzec, M., & Wismüller, R. (2022). A machine learning framework for automated accident detection based on multimodal sensors in cars. *Sensors*, 22(10), 3634.
- [29] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [30] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [31] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [32] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- [33] Pathik, N., Gupta, R. K., Sahu, Y., Sharma, A., Masud, M., & Baz, M. (2022). AI enabled accident detection and alert system using IoT and deep learning for smart cities. *Sustainability*, 14(13), 7701.
- [34] Javed, R., Mazhar, T., Aoun, M., Shahzad, T., Al-AlShai-kh, H. A., Ghadi, Y. Y., ... & Khan, M. A. (2025). Deep Learning and IoT-Enabled Accident Detection and Reporting for Smart Cities Domain. *KSII Transactions on Internet & Information Systems*, 19(4).
- [35] Shah, A., Mahant, A., Sayyed, A., Kanhegaonkar, V., Mirajkar, R., & Bagade, J. (2024, December). Real-Time Accident Detection and Notification System Using Convolutional Neural Networks. In *2024 4th International Conference on Innovative Sustainable Computational Technologies (CISCT)* (pp. 1-5). IEEE.
- [36] Balasubramanian, S. B., Balaji, P., Munshi, A., Almukadi, W., Prabhu, T. N., & Abouhawwash, M. (2023). Machine learning based IoT system for secure traffic management and accident detection in smart cities. *PeerJ Computer Science*, 9, e1259.