

پیش‌بینی زمان پاسخگویی اورژانس با استفاده از شبکه عصبی عمیق بقا

محمد آرشی^{۱*}، فاطمه محمدی^۱، آرزو حبیبی راد^۱، ابوالفضل محمدزاده مقدم^۲

^۱ گروه آمار، دانشکده علوم ریاضی، دانشگاه فردوسی مشهد، مشهد، ایران

^۲ گروه عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

تاریخ دریافت: ۱۴۰۴/۰۸/۱۹

تاریخ پذیرش: ۱۴۰۵/۰۴/۰۱

چکیده

مان پاسخگویی اورژانس در حوادث ترافیکی، یکی از مهم‌ترین عوامل تعیین‌کننده کیفیت خدمات پزشکی پیش‌بیمارستانی به شمار می‌رود. پیش‌بینی دقیق این زمان و شناسایی عوامل کلیدی مؤثر بر آن، به تصمیم‌گیران حوزه سلامت امکان می‌دهد تا با اتخاذ راهبردهای هدفمند و بهبود فرآیندهای عملیاتی، زمان رسیدن تیم اورژانس به محل حادثه را کاهش دهند. این امر در نهایت کارایی سیستم فوریت‌های پزشکی را ارتقا داده و به کاهش نرخ بقای مصدومان حوادث ترافیکی کمک می‌کند. داده‌های مربوط به زمان پاسخگویی اورژانس از نوع داده‌های زمان تا رویداد هستند که یکی از ویژگی‌های اصلی این داده‌ها، وابستگی آن‌ها به مدت زمان است. به‌منظور پیش‌بینی زمان پاسخگویی و لحاظ‌کردن این ویژگی، معمولاً از مدل‌های نرخ خطر مبنا استفاده می‌شود. با این حال، عملکرد این مدل‌ها با توجه به فرضیاتی که دارند ممکن است با محدودیت‌هایی همراه شود. در مقابل، مدل‌های یادگیری ماشین به‌عنوان جایگزینی کارآمد مطرح شده‌اند. مهم‌ترین مزیت این روش‌ها آن است که به فرضیات محدودکننده مدل‌های نرخ خطر مبنا وابسته نیستند و توانایی مدل‌سازی روابط غیرخطی و اثرات تعاملی میان متغیرها را دارند. در این میان، شبکه‌های عصبی مصنوعی به‌عنوان یکی از مهم‌ترین روش‌های یادگیری ماشین در این حوزه شناخته می‌شوند. در این پژوهش از یک مدل شبکه عصبی مبتنی بر تحلیل بقا استفاده شده است که به‌طور هم‌زمان توانایی برآورد تابع بقا و پیش‌بینی زمان پاسخگویی اورژانس را دارد. این مدل با بهره‌گیری از چارچوب یادگیری چندوظیفه‌ای، وابستگی به مدت زمان را از طریق برآورد هم‌زمان تابع بقا در نظر می‌گیرد و به این ترتیب دقت پیش‌بینی زمان پاسخگویی را بهبود می‌بخشد. عملکرد این مدل با استفاده از ۲۸۵۰۷ گزارش مربوط به تصادفات ثبت‌شده در مرکز اورژانس پیش‌بیمارستانی شهر مشهد ارزیابی شده و نتایج آن با مدل‌های آماری و سایر رویکردهای یادگیری ماشین مقایسه گردیده است. نتایج نشان می‌دهد که مدل ارائه‌شده می‌تواند به‌عنوان جایگزینی کارآمد برای روش‌های متداول در پیش‌بینی زمان پاسخگویی اورژانس مورد استفاده قرار گیرد.

واژه‌های کلیدی: زمان پاسخگویی اورژانس، تحلیل بقای عمیق، یادگیری چند وظیفه‌ای، مدل‌های نرخ خطر مبنا، تابع بقا

رده‌بندی ریاضی: ۶۲N۰۱، ۶۸T۰۷

۱ مقدمه

طبق مطالعه فورمن و همکاران [۸] تصادفات ترافیکی یکی از مهم‌ترین علل مرگ‌ومیر و آسیب‌های جسمی در سراسر جهان به شمار می‌روند و

در نظر گرفتن این ویژگی عمدتاً از مدل‌های آماری نرخ خطر مبنا استفاده می‌شود. طبق مطالعه احمد و همکاران [۶]، مدل‌های نرخ خطر مبنا از پرکاربردترین روش‌های آماری برای تحلیل داده‌های مدت‌زمان در حوزه‌های مختلف به شمار می‌روند. این مدل‌ها شامل مدل زمان شکست شتابیده و مدل‌های خطرات متناسب کاکس هستند. در مدل زمان شکست شتابیده، متغیر وابسته میانگین زمان وقوع رویداد تعریف می‌شود، در حالی که در مدل کاکس، متغیر وابسته تابع نرخ خطر در نظر گرفته می‌شود. پژوهش‌های پیشین، کاربرد مدل‌های نرخ خطر مبنا را برای پیش‌بینی زمان پاسخگویی اورژانس و در نظر گرفتن ویژگی وابستگی به مدت زمان تایید کردند. به عنوان نمونه، لی و فازیو [۳۱] با استفاده از مدل رگرسیون کاکس مبتنی بر خطر نسبی، عوامل مؤثر بر زمان پاسخگویی و پاکسازی تصادفات بزرگراهی را تحلیل کردند. همچنین گور و همکاران [۷] زمان سفر را به عنوان داده زمان تا رویداد با استفاده از مدل زمان شکست شتابیده با توزیع لگ‌لوژیستیک مدل‌سازی کردند. داده‌های مربوط به خدمات فوریت‌های پزشکی^۲، از جمله زمان پاسخگویی، معمولاً با ناهمگنی مشاهده‌نشده همراه هستند. این ناهمگنی ناشی از ثبت‌نشدن برخی عوامل مؤثر مانند تفاوت در مهارت تیم‌های امدادی، شرایط لحظه‌ای ترافیک یا ویژگی‌های بیماران در داده‌ها ایجاد می‌شود. وجود ناهمگنی مشاهده‌نشده موجب تغییر در اثر متغیرهای توضیحی و کاهش دقت مدل‌های آماری می‌شود. به منظور لحاظ کردن این ناهمگنی، مدل‌های شکنندگی معرفی شده‌اند که در آن‌ها اثرات تصادفی به مدل افزوده می‌شود. برای مؤلفه تصادفی در این مدل‌ها، توزیع‌های مختلفی قابل فرض است. به عنوان نمونه، الکعبی و همکاران [۹] با استفاده از مدل پارامتری زمان شکست شتابیده و اویل همراه با مؤلفه شکنندگی، زمان پاسخگویی به تصادفات بزرگراهی در ابوظبی را مدل‌سازی کرده و دقت پیش‌بینی را بهبود دادند. همچنین حجتی و همکاران [۱۱] ناهمگنی مشاهده‌نشده را با افزودن پارامترهای تصادفی در مدل زمان شکست شتابیده لحاظ کردند. با وجود این، استفاده از مدل‌های آماری نرخ خطر مبنا با محدودیت‌هایی همراه است. این محدودیت‌ها ناشی از فرض‌هایی هستند که لزوماً در داده‌های واقعی زمان پاسخگویی اورژانس برقرار نیستند. از جمله این فرض‌ها می‌توان به فرض خطرات متناسب، فرض توزیع مشخص برای داده‌ها، ثابت بودن اثر متغیرها در طول زمان و وجود رابطه خطی میان متغیرهای توضیحی و وابسته اشاره کرد. به مطالعه کیم و همکاران [۱۴] مراجعه شود. یکی دیگر از رویکردهای رایج برای مدل‌بندی زمان پاسخگویی

بر اساس الگوهای موجود، انتظار می‌رود این مشکل در سال‌های آینده نیز شدت یابد. با افزایش جمعیت شهرهای بزرگ و گسترش استفاده از وسایل نقلیه، به‌طور طبیعی تعداد حوادث ترافیکی نیز افزایش یافته و این موضوع منجر به بالا رفتن هزینه‌های سیستم‌های بهداشتی در سطح جهانی شده است. خدمات فوریت‌های پزشکی پیش‌بیمارستانی از طریق ارائه مراقبت‌های اولیه سریع و انتقال به موقع مصدومان به مراکز درمانی، نقش کلیدی در کاهش پیامدهای منفی این حوادث ایفا می‌کنند. هرچه این خدمات در دقایق اولیه پس از آسیب سریع‌تر و با کیفیت‌تر انجام شود، احتمال مرگ‌ومیر و بروز معلولیت‌های ناشی از حوادث به‌طور قابل‌توجهی کاهش می‌یابد. در آسیب‌های شدید مانند ضربه مغزی یا خونریزی داخلی، حتی چند دقیقه تأخیر می‌تواند به‌طور تعیین‌کننده‌ای شانس بقای بیمار را تحت تأثیر قرار دهد. از این‌رو، وجود یک سیستم فوریت‌های پزشکی کارآمد که قادر به واکنش سریع و مؤثر به حوادث ترافیکی باشد، از مهم‌ترین عوامل کاهش مرگ‌ومیر و شدت جراحات ناشی از تصادفات محسوب می‌شود. زمان پاسخگویی اورژانس به فاصله زمانی میان دریافت تماس اضطراری (اطلاع‌رسانی حادثه) تا رسیدن آمبولانس به محل حادثه اطلاق می‌شود. بر اساس استانداردهای سازمان‌های بین‌المللی همچون سازمان بهداشت جهانی^۱ و انجمن‌های پزشکی اورژانس، زمان پاسخگویی ایده‌آل در مناطق شهری کمتر از هشت دقیقه است. به مطالعه سانچز مانگاس و همکاران [۳۴] مراجعه شود. با وجود اینکه کاهش زمان پاسخگویی همواره یکی از اولویت‌های اصلی سیستم اورژانس بوده است، عوامل متعددی از جمله تراکم ترافیک، پیچیدگی‌های جغرافیایی شهری، شرایط آب‌وهوایی و محدودیت‌های زیرساختی می‌توانند سبب تأخیر قابل‌توجه در رسیدن تیم اورژانس شوند. از این‌رو، پیش‌بینی دقیق زمان پاسخگویی برای برنامه‌ریزی مؤثر و کاهش آثار منفی ناشی از تأخیر در ارائه خدمات اورژانسی ضرورت دارد. داده‌های مربوط به زمان پاسخگویی اورژانس به عنوان نوعی از داده‌های مدت‌زمان در نظر گرفته می‌شوند که فاصله زمانی تا وقوع یک رویداد را توصیف می‌کنند. در این مطالعه، رویداد مورد نظر رسیدن آمبولانس به محل حادثه تعریف می‌شود. یکی از ویژگی‌های اساسی این نوع داده‌ها، وابستگی به مدت زمان است که آن‌ها را از سایر انواع داده‌ها متمایز می‌سازد. وابستگی به مدت زمان بدین معناست که زمان رسیدن اورژانس به محل حادثه به بازه زمانی سپری‌شده از لحظه اطلاع‌رسانی تا حضور آمبولانس وابسته است. به مطالعه واشینگتن و همکاران [۱۷] مراجعه کنید. برای

¹ World Health Organization (WHO)

² Emergency Medical System (EMS)

شتابیده را به صورت هم‌زمان دنبال می‌کند و وابستگی به مدت زمان را در پیش‌بینی لحاظ می‌نماید. این مدل نشان می‌دهد که چگونه یک شبکه عصبی عمیق می‌تواند مدل‌های آماری سنتی را تکمیل کند، به جای اینکه صرفاً جایگزین آن‌ها شود. هدف این مطالعه، بررسی و پیش‌بینی زمان پاسخگویی اورژانس در حوادث ترافیکی شهر مشهد در سال ۱۳۹۶ با استفاده از مدل MT-DNN است تا عوامل کلیدی مؤثر بر کارایی و سرعت خدمات فوریت‌های پزشکی شناسایی شوند. ساختار مقاله به شرح زیر تنظیم شده است. در بخش‌های ۲، ۳ و ۴ روش‌شناسی پژوهش و مدل تحلیل بقای عمیق تشریح می‌شود. در بخش ۵ داده‌های مورد استفاده معرفی می‌گردد. در بخش ۶ مدل‌های آماری و یادگیری ماشین و تنظیمات آن‌ها توضیح داده می‌شود. بخش ۷ به ارائه نتایج و بحث اختصاص دارد و در نهایت، بخش ۸ جمع‌بندی و پیشنهادهایی برای تحقیقات آینده ارائه می‌دهد.

۲ مدل‌های تحلیل بقا

داده‌های مربوط به مدت زمان پاسخگویی اورژانس، از نوع داده‌های زمان تا رویداد هستند. در این مطالعه، رویداد موردنظر، رسیدن آمبولانس به محل تصادف است. برای تحلیل این نوع داده‌ها، درک چند مفهوم پایه‌ای ضروری است؛ از جمله تابع بقا، تابع نرخ خطر، داده‌های سانسور شده، ویژگی وابستگی به مدت زمان و میانگین طول عمر. در ادامه، هر یک از این مفاهیم به اختصار توضیح داده می‌شود.

تعریف ۱.۰۲. تابع بقا^۵ احتمال آن را توصیف می‌کند که زمان بقا از یک زمان مشخص فراتر رود. به بیان دیگر، این تابع احتمال بقا تا زمان t را محاسبه می‌کند. عموماً این تابع، با استفاده از روش‌های ناپارامتری مانند کاپلان مایر یا نلسون آلن و یا روش‌های پارامتری و از روی تابع توزیع محاسبه می‌شود. متغیر تصادفی T که همان زمان بقا است همواره باید مثبت ($T > 0$) بوده و می‌تواند گسسته یا پیوسته باشد. تابع بقا در طول زمان t غیر صعودی است و به صورت زیر تعریف می‌شود:

$$S(t) = \Pr(T > t) = 1 - F(t), \quad 0 < t < \infty \quad (1)$$

تعریف ۲.۰۲. تابع نرخ خطر^۶ که با $h(t)$ نشان داده می‌شود، میزان مرگ و میر لحظه‌ای را نشان می‌دهد. این تابع شانس رخداد پیشامد را

اورژانس، استفاده از مدل‌های یادگیری ماشین از جمله جنگل تصادفی، مدل گرادیان تقویت شده و شبکه‌های عصبی مصنوعی است. آرکولزی و همکاران [۳۲] چهار مدل XGBoost، LGBM، MLP و رگرسیون لاسو را برای پیش‌بینی زمان پاسخ آمبولانس به کار گرفتند. همچنین هیل و همکاران [۱۰] با استفاده از مدل‌های یادگیری ماشین، از جمله مدل گرادیان تقویت شده، عوامل مؤثر بر زمان پاسخ اورژانس در شهر استکهلم را بررسی کردند و عملکرد برتر این مدل را نسبت به مدل‌های جنگل تصادفی، شبکه عصبی و رگرسیون خطی گزارش دادند. با این حال، اغلب مدل‌های یادگیری ماشین، میانگین زمان وقوع رویداد را به عنوان متغیر وابسته در نظر می‌گیرند و ویژگی وابستگی به مدت زمان را نادیده می‌گیرند. برخی مطالعات، از جمله تانگ و همکاران [۲۴]، نشان داده‌اند که عملکرد این مدل‌ها در برخی موارد ضعیف‌تر از مدل‌های زمان شکست شتابیده همراه با پارامتر تصادفی است. به منظور لحاظ کردن وابستگی به مدت زمان، پژوهشگران مدل‌های مبتنی بر تحلیل بقای عمیق را معرفی کرده‌اند که به جای پیش‌بینی میانگین زمان رویداد، تابع بقا را برآورد می‌کنند. در این چارچوب، ایشواران و همکاران [۱۳] مدل جنگل بقای تصادفی را توسعه دادند که با استفاده از مجموعه‌ای از درخت‌های تصمیم، تابع خطر تجمعی را به طور مستقیم تخمین می‌زند و فرضیات محدودکننده خطرات متناسب و روابط خطی بین متغیرهای توضیحی و وابسته را ندارد. همچنین هونهورن و همکاران [۱۲] مدل گرادیان تقویت شده را برای برآورد تابع بقا پیشنهاد کردند. در ادامه، شبکه‌های عصبی بقا مانند DeepSurv و DeepHit معرفی شدند که با استفاده از شبکه‌های عصبی عمیق، روابط غیرخطی و تعاملی میان متغیرها را مدل‌سازی می‌کنند و در بسیاری از کاربردها عملکرد بهتری نسبت به مدل کاکس و جنگل بقای تصادفی نشان می‌دهند. مدل DeepSurv توسط کاتزمن و همکاران [۱۶] و مدل DeepHit توسط لی و همکاران [۱۵] معرفی شدند. نقطه قوت اصلی این مدل‌ها این است که برخی از فرضیات محدودکننده مدل‌های نرخ خطر مینا را ندارند. با این حال، این مدل‌ها نمی‌توانند به طور مستقیم زمان پاسخگویی را پیش‌بینی کنند. در این مطالعه، از یک شبکه عصبی عمیق چند وظیفه‌ای^۳ (MT-DNN) استفاده می‌شود که علاوه بر برآورد تابع بقا، زمان پاسخگویی را نیز به صورت صریح پیش‌بینی می‌کند. این مدل که بر پایه شبکه‌های عصبی عمیق^۴ توسعه یافته است، اهداف دو مدل خطرات متناسب کاکس و زمان شکست

³Multi Task Deep Neural Network

⁴Deep Neural Networks

⁵Survival Function

⁶Hazard Function

۱.۲ مدل مخاطرات متناسب کاکس

مدل مخاطرات متناسب کاکس^۷ به صورت،

$$h(t, \mathbf{X}) = h_0(t) \times \exp(\beta_1 x_1 + \dots + \beta_p x_p) \quad (2)$$

است، که در آن $h_0(t)$ به عنوان تابع نرخ خطر پایه، نرخ وقوع رویداد را در حالتی که متغیرهای توضیحی در مدل حضور ندارند، بیان می‌کند. همچنین، x_p برای $p = 1, \dots, P$ ویژگی‌هایی هستند که بر نرخ خطر تأثیر می‌گذارند و β_p نیز میزان تأثیر هر یک از آن‌ها را مشخص می‌کند. همچنین P تعداد متغیرهای توضیحی است. بردار $\mathbf{X} = (x_1, \dots, x_p)$ شامل متغیرهای توضیحی یا همان ویژگی‌ها بوده که بردار $\beta^T = (\beta_1, \dots, \beta_p)^T$ ضرایب متناظر با هر یک از این متغیرها را نشان می‌دهد. بر اساس رابطه (۲)، خطر به عنوان یک تابع ضربی از یک خطر پایه و تابعی از متغیرهای توضیحی تعریف می‌شود. این مدل دارای فرض مخاطرات متناسب بوده که منظور از این فرض این است که نسبت مخاطره برای مشاهده i ام به مشاهده j ام مستقل از زمان باشد. فرض کنید نسبت خطر بر اساس مدل کاکس برای دو بردار تصادفی دلخواه $\mathbf{X}_i = (X_{i1}, X_{i2}, \dots, X_{ip})$ و $\mathbf{X}_j = (X_{j1}, \dots, X_{jp})$ به صورت زیر تعریف شود:

$$\frac{h(t | \mathbf{X}_i)}{h(t | \mathbf{X}_j)} = \frac{h_0(t) \exp(\beta \mathbf{X}_i)}{h_0(t) \exp(\beta \mathbf{X}_j)} = \exp(\beta(\mathbf{X}_i - \mathbf{X}_j)). \quad (3)$$

طبق رابطه (۳)، مشاهده می‌شود که نسبت خطر در طول زمان ثابت بوده و تابعی از متغیرهای توضیحی است. به دلیل وجود فرض مخاطرات متناسب، مدل کاکس یک مدل نیمه‌پارامتری محسوب می‌شود. به مطالعه اسلامی و همکاران [۱] مراجعه شود.

۲.۲ مدل زمان شکست شتابیده

مدل زمان شکست شتابیده (AFT)^۸ به صورت،

$$\ln t = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \epsilon \quad (4)$$

بوده که در آن ϵ عبارت خطا، $\beta^T = (\beta_1, \dots, \beta_p)^T$ پارامترهای مدل، $\mathbf{X}_i = (X_{i1}, \dots, X_{ip})$ بردار متغیرهای توضیحی برای مشاهده i ام است. در این مدل فرض می‌شود که رابطه خطی بین لگاریتم زمان بقا و متغیرهای توضیحی برقرار است. مدل (۴) را می‌توان بر اساس تابع نرخ خطر به صورت،

$$h(t, \mathbf{X}) = \exp(-\beta \mathbf{X}) \times h_0(\exp(-\beta \mathbf{X}) \times t)$$

در لحظه t با شرط آن که واحد آزمایشی تا این لحظه رویداد را تجربه نکرده باشد، بیان می‌کند.

اگر T گسسته باشد، تابع نرخ خطر به صورت $h(t) = \Pr(T = t | T \geq t)$ بوده و اگر پیوسته باشد، تابع نرخ خطر برابر با،

$$h(t) = \lim_{\Delta t \rightarrow 0} \frac{\Pr(t < T < t + \Delta t | T > t)}{\Delta t}$$

است.

با استفاده از رابطه $S(t) = \exp(-\int_0^t h(s) ds)$ و تابع نرخ خطر می‌توان تابع بقا را برآورد کرد. همچنین بر اساس تابع نرخ خطر می‌توان تابع نرخ خطر تجمعی را به دست آورد که با $H(t)$ نشان داده می‌شود و به صورت،

$$H(t) = \int_0^t h(s) ds$$

است. بنابراین، تابع بقا نیز از رابطه $S(t) = \exp(-H(t))$ محاسبه می‌شود.

تعریف ۳.۲. در کنار داده‌های زمان تا رویداد، وضعیت هر مشاهده نیز ثبت می‌شود که بیانگر کامل یا سانسور بودن داده است. داده کامل به مشاهده‌ای اطلاق می‌شود که اطلاعات آن از ابتدای مطالعه تا زمان وقوع رویداد به طور کامل در دسترس باشد. در مقابل، داده سانسور شده به حالتی اشاره دارد که زمان دقیق وقوع رویداد برای برخی داده‌ها به طور کامل مشاهده نشده باشد. سانسورها می‌توانند انواع مختلفی داشته باشند:

• سانسور راست

زمانی رخ می‌دهد که رویداد پس از پایان دوره مطالعه اتفاق بیفتد یا تا انتهای مطالعه مشاهده نشود.

• سانسور چپ

زمانی که رویداد قبل از شروع مطالعه برای داده رخ دهد.

تعریف ۴.۲. مساحت زیر منحنی تابع بقا، همان میانگین طول عمر است و به صورت،

$$E(T) = \int_0^{\infty} S(t) dt$$

تعریف می‌شود.

⁷Cox Proportional Hazards Model

⁸Accelerated Failure Time

که در آن بردار پارامترهای تصادفی مربوط به مشاهده^۹ n است و δ_n بردار جمله تصادفی است که می‌تواند از توزیع‌های مختلفی پیروی کند. برای اطلاعات بیشتر می‌توان به مطالعات والی و همکاران [۲۲] و تانگ و همکاران [۲۳] مراجعه کرد. مدل RPAFT به صورت زیر بیان می‌شود:

$$\log(T_i) = \beta^T \mathbf{X}_i + \beta_n^T \mathbf{Z}_i + \varepsilon_i. \quad (5)$$

در رابطه (۵)، T_i نشان‌دهنده زمان تا رویداد (زمان بقا یا زمان پاسخگویی) برای مشاهده^{۱۰} i ام است، \mathbf{X}_i بردار متغیرهای توضیحی با اثر ثابت و \mathbf{Z}_i بردار متغیرهای توضیحی با اثر تصادفی (یا متغیرهای مرتبط با مؤلفه شکنندگی مشترک که اثرات تصادفی یا ناهمگونی مشاهده بین خوشه‌ها را مدل می‌کند) را نشان می‌دهد. همچنین β بردار ضرایب ثابت، β_n بردار ضرایب تصادفی مربوط به مشاهده^{۱۱} i یا خوشه^{۱۲} مربوطه، و ε_i جمله خطای مدل AFT است که معمولاً از یک توزیع مشخص پیروی می‌کند. مؤلفه شکنندگی مشترک (\mathbf{Z}_i) تغییرات و ناهمگنی‌هایی را مدل می‌کند که توسط متغیرهای مشاهده‌شده توضیح داده نمی‌شوند و در عین حال امکان در نظر گرفتن همبستگی بین داده‌ها در یک خوشه را فراهم می‌کند.

۳ مدل‌های یادگیری ماشین

۱.۳ مدل جنگل تصادفی بقا

جنگل تصادفی^{۱۲} یا RF یکی از الگوریتم‌های یادگیری ماشین مبتنی بر درخت تصمیم است که برای مسائل رگرسیون و طبقه‌بندی استفاده می‌شود این مدل بر اساس درخت تصمیم است. یک مدل مبتنی بر درخت شامل تقسیم بازگشتی مجموعه داده به دو گروه بر اساس یک معیار مشخص است تا زمانی که یک شرط توقف از پیش تعیین‌شده برآورده شود. درخت‌های تصمیم جداگانه به راحتی قابل تفسیر هستند، اما این قابلیت تفسیر در جنگل‌های تصادفی از دست می‌رود، زیرا چندین درخت تصمیم تجمیع می‌شوند. با این حال، در ازای آن، RF اغلب در وظایف پیش‌بینی، عملکرد بسیار بهتری دارند. برای اطلاعات بیشتر به مطالعه شونلاو و زو [۲۵] مراجعه شود. مراحل اجرای روش جنگل تصادفی به صورت زیر است:

نشان داد. در این مدل، متغیرهای توضیحی بر زمان مؤثر وقوع رویداد تأثیر گذاشته و آن را شتاب می‌دهند یا کند می‌کنند. برای مدل‌سازی نرخ خطر پایه، معمولاً توزیع‌های وایبل، لگ‌نرمال و لگ‌لوژستیک فرض می‌شود.

۳.۲ مدل شکنندگی

در برخی مطالعات تحلیل بقا، ممکن است زیرگروه‌های مختلف جامعه دارای یک متغیر تصادفی مشترک مشاهده‌نشده باشند که بر زمان رویداد تأثیر می‌گذارد، اما در داده‌ها اندازه‌گیری یا ثبت نشده‌اند. عدم در نظر گرفتن اثر این متغیرها سبب می‌شود بخشی از تغییرات تابع نرخ خطر که می‌توانست توسط این عامل توضیح داده شود، با عبارت خطا جمع شود. این امر منجر به برآوردگرهای اریب برای پارامترهای رگرسیونی و تخمین‌های نادرست از اثرات متغیرهای مشاهده‌شده می‌گردد. به همین دلیل، در چنین شرایطی استفاده از مدل‌های آمیخته با اثرات تصادفی توصیه می‌شود که در چارچوب تحلیل بقا به مدل شکنندگی^۹ معروف است. ناهمگنی مشاهده‌نشده^{۱۰} معمولاً به صورت اثرات تصادفی فردی ظاهر می‌شود که با متغیرهای کمکی موجود در داده‌ها قابل توضیح یا اندازه‌گیری نیستند. به مطالعه مالچی و همکاران [۲] مراجعه شود. در مطالعات بقا، مدل‌های شکنندگی برای تبیین تغییرات ناشی از عوامل خطر مشاهده‌نشده به کار می‌روند. به مطالعه حوتی و احمدی [۳] مراجعه کنید. اگر این عامل تصادفی در مدل‌های AFT به کار رود به نام مدل‌های زمان شکست شتابیده با پارامتر تصادفی (RPAFT)^{۱۱} شناخته شده و امکان پیش‌بینی و تحلیل دقیق‌تری از عوامل مؤثر بر زمان رویداد را در حضور ناهمگنی مشاهده‌نشده فراهم می‌کند. ایده اصلی این رویکرد آن است که برخلاف مدل AFT که فرض می‌کند اثر تمامی پارامترهای مدل بین داده‌ها ثابت هستند، در مدل RPAFT برخی یا تمام ضرایب بین مشاهدات (یا زیرگروه‌ها) تغییر می‌کنند و این تغییرات توسط یک توزیع تصادفی مدل‌سازی می‌شوند. به عبارت دیگر، بر اساس مطالعه پروج و علی‌خان [۲۱]، افزودن مؤلفه شکنندگی به مدل AFT، امکان در نظر گرفتن تغییرات مشاهده‌نشده یا الگوهای خوشه‌بندی بین مشاهدات یا گروه‌ها را فراهم می‌کند. به این ترتیب، پارامترهای مدل برای هر مشاهده (یا خوشه) به صورت زیر تعریف می‌شوند:

$$\beta_n = \beta + \delta_n,$$

⁹Frailty Model

¹⁰Unobserved Heterogeneity

¹¹Random Parameter Accelerated Failure Time

¹²Random Forest

بقا مشابه هستند، تشکیل شوند. ایشواران و همکاران [۱۳] چارچوبی برای RSF ارائه کردند که در مراحل زیر شرح داده شده است:

گام ۱- تعداد B نمونه بوت‌استرپ تصادفی از داده‌های اصلی انتخاب می‌شود.

گام ۲- برای هر نمونه بوت‌استرپ یک درخت بقا ساخته می‌شود. در هر گره از درخت به صورت تصادفی m متغیر همانند الگوریتم RF رگرسیون انتخاب می‌شود و متغیری که بیشترین اختلاف را بین گره‌های فرزند ایجاد می‌کند به عنوان متغیر کاندید انتخاب می‌شود.

گام ۳- درخت تا بزرگ‌ترین حالت ممکن و تحت این محدودیت که گره برگ نباید مرگ منحصر به فرد کمتر از $d_0 \leq 0$ داشته باشد، رشد می‌کند.

گام ۴- برای هر درخت نرخ خطر تجمعی محاسبه می‌شود و در نهایت با میانگین‌گیری، نرخ خطر تجمعی گروهی به عنوان پیش‌بینی برای گره‌های پایانی به دست می‌آید.

گام ۵- با استفاده از داده‌هایی که مدل در فرایند آموزش ندیده است، خطای پیش‌بینی برای نرخ خطر تجمعی گروهی محاسبه می‌شود.

همان‌طور که در RF با هدف رگرسیون مدل‌های ضعیف درخت تصمیم به صورت تصادفی و مستقل آموزش می‌بینند در مدل RSF هم درخت‌ها به طور جداگانه با هدف برآورد تابع بقا آموزش می‌بینند. فرض کنید K نمایانگر یک گره پایانی در درخت باشد و مجموعه نمونه‌ها برای آموزش به صورت $D = \{(t_i^*, \delta_i, \mathbf{X}_i) \mid i = 1, \dots, n\}$ تعریف شود، که شامل زمان بقای مشاهده‌شده $T^* = \min(T, C)$ ، تابع نشانگر سانسور به صورت $\delta = 1$ برای حالت $T \leq C$ ، و بردار متغیرهای مستقل \mathbf{X} است. در تابع نشانگر سانسور، وقتی $\delta = 1$ به معنای وقوع رویداد است، و وقتی $\delta = 0$ به این معناست که مشاهده واقعی سانسور شده و فقط زمان سانسور قابل مشاهده است. در این صورت، تابع نرخ خطر یک گره پایانی با روش‌های ناپارامتری مثل کاپلان مایر یا نلسون-آلن به صورت،

$$\hat{h}(t) = \frac{\sum_{i \in D_N} \delta_i}{\sum_{i \in D_N} \mathbf{X}_i}$$

برآورد می‌شود. مدل RSF با ارائه معیار اهمیت متغیر برای هر متغیر توضیحی، تفسیری از متغیرهایی که نقش کلیدی در پیش‌بینی پیامد بقا دارند ارائه می‌دهد.

۱. تعداد B نمونه بوت‌استرپ به اندازه N از داده‌های آموزشی انتخاب می‌شود.

۲. درخت‌های تصمیم مستقل از هم بر روی هر نمونه بوت‌استرپ آموزش داده می‌شود.

۳. در هر تقسیم‌گره، $m \leq p$ متغیر از p متغیرهای ورودی به صورت تصادفی انتخاب می‌شود تا بهترین تقسیم پیدا شود. معمولاً مقادیر m برابر با \sqrt{p} است.

۴. بهترین متغیر و نقطه تقسیم از میان m متغیر، متغیری است که معیارهای ارزیابی از جمله مجموع مربعات خطا برای مسائل رگرسیون را کمینه کند. معیار مجموع مربعات خطا :

$$\sum_{i=1}^N (y_i - \hat{y}_i)^2$$

۵. پس از یافتن بهترین تقسیم برای گره، داده‌ها به دو منطقه و یا دو گره فرزند تقسیم می‌شود و فرآیند تقسیم روی هر یک از این دو منطقه تکرار می‌شود.

۶. تعداد T_B درخت به عنوان خروجی وجود خواهد داشت. برای پیش‌بینی یک نقطه جدید \mathbf{X} ، مشاهده جدید به هر کدام از درخت‌ها داده می‌شود.

۷. پیش‌بینی‌های درخت‌ها برای نمونه جدید ثبت می‌شود و در نهایت پیش‌بینی نهایی برای مشاهده جدید با میانگین‌گیری از پیش‌بینی‌های هر درخت برای رگرسیون تعیین می‌گردد.

$$\hat{f}(\mathbf{X}) = \frac{1}{B} \sum_{b=1}^B \hat{T}_b(\mathbf{X})$$

اگر مدل RF با هدف برآورد تابع بقا طراحی شود می‌تواند برای داده‌های زمان تا رویداد مناسب باشد زیرا ویژگی سانسور و وابستگی به مدت زمان را در این داده‌ها در نظر می‌گیرد. این مدل که جنگل بقای تصادفی^{۱۳} یا RSF نامیده می‌شود توسط ایشواران و همکاران [۱۳] پیشنهاد شد.

مدل RSF به طور مستقیم تابع نرخ خطر تجمعی را با استفاده از مجموعه‌ای از درخت‌های بقا برآورد می‌کند که فرض خطرات متناسب کاکس و اثر خطی متغیرهای توضیحی و وابسته را ندارد. برای اطلاعات بیشتر به مطالعه کیم و همکاران [۱۴] مراجعه شود. روش RSF یک رویکرد غیر پارامتری و غیرخطی برای تحلیل داده‌های بقا با سانسور راست است. با توجه به مطالعه پیکت و همکاران [۲۶] این مدل مبتنی بر درخت‌های بقا بوده که با تقسیم بازگشتی فضای متغیرهای توضیحی به دو ناحیه ساخته می‌شوند تا گروه‌هایی از مشاهدات که از نظر پیامد

۲.۳ مدل گرادیان تقویت شده بقا

ب. مدل پایه h_m به داده‌های $\{(x_i, r_{im})\}_{i=1}^n$ برازش داده می‌شود طوری که تابع زیان را به حداقل برساند.

$$h_m = \arg \min_{h \in H} \left[\sum_{i=1}^n L(r_{im}, h(\mathbf{X}_i)) \right]$$

ج. γ نیز طوری انتخاب می‌شود که رابطه زیر برقرار شود:

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, F_{m-1}(\mathbf{X}_i) + \gamma h_m(\mathbf{X}_i))$$

د. مدل بعدی تشکیل می‌شود: $F_m(\mathbf{X}) = F_{m-1}(\mathbf{X}) + \gamma_m h_m(\mathbf{X})$

گام ۳- مدل نهایی $F_M(\mathbf{X}) = F_0 + \sum_{m=1}^M \gamma_m h_m(\mathbf{X})$ می‌باشد.

در مدل GBM برای مسائل رگرسیون، تابع زیان، میانگین مربعات خطا است که باید کمینه شود.

$$\sum_{i=1}^n L(y_i, F(\mathbf{X}_i)) = \sum_{i=1}^n (y_i - F(\mathbf{X}_i))^2$$

این تابع زیان نسبت به $F(\mathbf{X}_i)$ پیوسته است، بنابراین گرادیان تابع زیان نسبت به $F(\mathbf{X}_i)$ ، برابر با $-2(y_i - F(\mathbf{X}_i))$ $\left[\frac{\partial L(y_i, F(\mathbf{X}_i))}{\partial F(\mathbf{X}_i)} \right]$ می‌باشد. پس در تکرار m ام داریم:

$$r_{im} = -\frac{1}{2} \left[\frac{\partial L(y_i, F(\mathbf{X}_i))}{\partial F(\mathbf{X}_i)} \right]_{F(\mathbf{X})=F_{m-1}(\mathbf{X})} = (y_i - F(\mathbf{X}_i))$$

برای مسائل رگرسیون، مدل پایه F_0 یک مقدار ثابت است که می‌تواند میانگین داده‌ها را در نظر گرفت. توجه کنید در مسائل رگرسیون مدل $\gamma_m h_m(\mathbf{X})$ به گونه ای انتخاب می‌شود که بتواند $y_i - F_{m-1}(\mathbf{X})$ ، که همان منفی گرادیان تابع زیان هستند را پیش بینی کند.

نرخ یادگیری ν عددی مثبت و معمولاً مقداری بین (۰،۱) دارد که سرعت یادگیری تقویت و میزان اثر هرکدام از مدل‌های پایه را کنترل می‌کند.

در مدل GBM برای داده‌های بقا یا GBM-Survival معمولاً مدل پایه همان درخت بقا^{۱۵} است و با ترکیب این درخت‌ها در مراحل متوالی، مدلی قوی برای پیش‌بینی زمان بقا یا خطر ساخته می‌شود. در هر گره برگ^{۱۶} یک تخمین از تابع بقا یا نرخ خطر ذخیره می‌شود. این الگوریتم نیز مانند مدل GBM برای مسائل رگرسیون، بر مبنای کمینه‌سازی تابع زیان و به‌روزرسانی افزایشی مدل عمل می‌کند، اما تفاوت اصلی در این است که برای داده‌های بقا، تابع زیان بر اساس تابع درست‌نمایی جزئی کاکس^{۱۷} یا سایر زیان‌های مخصوص بقا تعریف می‌شود. برای اطلاعات بیشتر می‌توان به مطالعات بای و همکاران [۲۷]، لی و همکاران [۱۸] و رضوی‌زاده و همکاران [۱۹] مراجعه کرد.

روش تقویت، یک روش یادگیری ماشین است که برای مسائل رگرسیون و طبقه‌بندی و تحلیل داده‌های بقا به‌کار می‌رود. هدف از الگوریتم تقویت، اعمال پی در پی یادگیرنده‌های ضعیف بر روی نسخه‌های تغییر یافته داده‌ها است طوری که خطاهای مدل‌های قبلی را کاهش دهد. مانند سایر مدل‌های تقویت، روش گرادیان تقویت شده^{۱۴} یا GBM ترکیب خطی از چندین مدل ضعیف است که به‌صورت تناوبی برای ایجاد یک مدل بر روی گرادیان‌های تابع زیان استفاده می‌شود. برای برازش مدل GBM به داده‌ها یک تابع زیان برای بهینه‌سازی، یک یادگیرنده ضعیف برای پیش‌بینی و یک مدل جمعی از تمام یادگیرنده‌های ضعیف برای به حداقل رساندن تابع زیان تعیین می‌گردد. بر اساس مطالعه ناتکین و نول [۲۰]، مدل GBM با مدل پایه درخت تصمیم به دقت پیش‌بینی بهتری دست می‌یابد. فرض کنید $\{(\mathbf{X}_1, y_1), \dots, (\mathbf{X}_n, y_n)\}$ داده‌هایی هستند که مدل برای یادگیری از آن‌ها استفاده می‌کند و هدف یادگیری مدلی مانند \hat{F} است که تابع زیان $L(y, \hat{F})$ را کمینه می‌کند. برای پیدا کردن $F(x)$ به صورت مرحله‌ای عمل می‌شود. در مرحله m یادگیرنده پایه h_m با وزن γ_m به مدل $F_{m-1}(x)$ اضافه می‌شود و تبدیل به مدل جدید $F_m(\mathbf{X}) = F_{m-1}(\mathbf{X}) + \gamma_m h_m(\mathbf{X})$ می‌شود. توجه شود که در GBM هدف، پیش‌بینی گرادیان تابع زیان مدل‌های قبلی است.

مدل جدید به گرادیان‌های خطای مدل قبلی برازش داده می‌شود و باید آن‌ها را پیش‌بینی کند. روند کلی مدل GBM برای مسائل رگرسیون بر اساس مطالعه گودرزی و همکاران [۵] در الگوریتم زیر توضیح داده شده است. این روش تا زمانی تکرار می‌شود که برخی از شرایط همگرایی ایجاد شود.

گام ۱- اولین مدل یک مقدار ثابت

$$F_0 = \arg \min_{\gamma} \sum_{i=1}^n L(y_i, \gamma)$$

انتخاب می‌شود.

گام ۲- برای $m = 1, \dots, M$ و برای $i = 1, \dots, n$:

الف. شبه مانده‌ها یا همان منفی گرادیان‌های تابع زیان با استفاده از فرمول تابع زیان و پیش‌بینی مدل قبلی که میانگین گرادیان‌ها داخل هر گره برگ است، محاسبه می‌شود:

$$r_{im} = - \left[\frac{\partial L(y_i, F(\mathbf{X}_i))}{\partial F(\mathbf{X}_i)} \right]_{F(\mathbf{X})=F_{m-1}(\mathbf{X})}$$

¹⁴Gradient Boosting Machine

¹⁵Survival Tree

¹⁶Leaf

¹⁷Cox partial likelihood

آزمایش مقادیر مختلف تعیین می‌شود تا بهترین عملکرد آموزشی شبکه عصبی به دست آید.

آموزش شبکه عصبی شامل دو مرحله از پیش‌انتشار و پس‌انتشار است. پیش‌انتشار فرآیندی است که در آن داده‌های ورودی به لایه ورودی ارسال می‌شود، توسط لایه پنهان پردازش می‌شود و در نهایت به لایه خروجی منتقل می‌گردد.

فرض کنید شبکه عصبی با یک لایه پنهان و یک لایه خروجی داشته باشیم، که تعداد گره‌های لایه ورودی، لایه پنهان و لایه خروجی به ترتیب برابر با n_1 ، n و m است. در این صورت مجموع وزن‌دار برای گره‌های لایه پنهان $j = 1, \dots, n_1$ به صورت،

$$\text{neth}_1 = \sum_{i=1}^n w_{ji}x_i + b_1$$

است، که در آن x_i متغیر مستقل i ام است، w_{ji} بردارهای وزن بین لایه ورودی و لایه پنهان هستند، و b_1 بایاس بین لایه‌های محاسبه شده است که به طور انعطاف‌پذیری برای تنظیم عملکرد شبکه عصبی طراحی شده است. سپس، neth_1 از توابع فعال‌سازی از جمله ReLU عبور می‌کند. تابع فعال‌سازی ReLU به صورت $\max(0, \text{neth}_1)$ است.

$$h_j = g(\text{neth}_1) = \max(0, \text{neth}_1).$$

h_j مقادیر گره‌های لایه پنهان هستند که دوباره در وزن‌های اتصالات بین لایه پنهان و لایه خروجی w_{mj} ضرب شده و با مقدار بایاس هر گره لایه خروجی جمع می‌شود. در نهایت از تابع فعال‌سازی لایه آخر $g(\cdot)$ عبور کرده و مقدار خروجی هر گره در لایه خروجی که همان Z است، به دست می‌آید. Z به صورت،

$$\text{Net}_z = \sum_{j=1}^{n_1} w_{mj}h_j + b_2$$

محاسبه می‌شود و

$$Z = g(\text{Net}_z) = \max(0, \text{Net}_z)$$

که در آن w_{mj} بردارهای وزن بین لایه پنهان و لایه خروجی هستند و b_2 بایاس بین لایه پنهان و لایه خروجی است.

اگر Z با خروجی مورد انتظار مطابقت نداشته باشد، خطای پیش‌بینی با استفاده از تابع ضرر انتخاب‌شده محاسبه خواهد شد. سپس، پس‌انتشار خطای پیش‌بینی را به نورون‌های شبکه باز می‌گرداند و از الگوریتم گرادیان کاهشی برای اصلاح وزن‌های نورون‌ها به منظور کاهش خطاهای پیش‌بینی استفاده می‌کند. هنگامی که خطای پیش‌بینی با انتظارات مطابقت داشت، پیش‌بینی شبکه عصبی انجام می‌شود. به مطالعه تانگ و همکاران [۲۴] مراجعه شود.

متغیر و نقطه تقسیمی در هر گره انتخاب می‌شود که تابع زیان لگاریتم درست‌نمایی جزئی کاکس را کمینه کرده باشند. که در آن $h_m(\mathbf{X})$ یک درخت تصمیم رگرسیون است که روی گرادیان منفی تابع زیان بقا آموزش داده می‌شود. پارامترهای درخت تصمیم بقا که شامل متغیر و نقطه تقسیم در هر گره درخت است. پیش‌بینی در هر گره برگ، میانگین باقی‌مانده‌های داخل آن گره است.

یکی از پرکاربردترین توابع زیان، منفی لگاریتم درست‌نمایی جزئی کاکس است که به صورت،

$$L(\beta) = - \sum_{i=1}^N \delta_i \left(f(\mathbf{X}_i) - \log \sum_{j \in R(T_i)} \exp(f(\mathbf{X}_j)) \right), \quad (6)$$

بوده، که در آن $R(T_i)$ مجموعه مشاهدات در معرض خطر در زمان T_i است.

گرادیان منفی تابع زیان نسبت به $f(\mathbf{X})$ برای نمونه i به صورت،

$$\begin{aligned} r_{im} &= - \frac{\partial L}{\partial f(\mathbf{X}_i)} \Big|_{f=f_{m-1}} \\ &= \delta_i - \sum_{l: i \in R(T_l)} \delta_l \frac{\exp(f_{m-1}(\mathbf{X}_i))}{\sum_{j \in R(T_l)} \exp(f_{m-1}(\mathbf{X}_j))}. \end{aligned}$$

محاسبه می‌شود. این گرادیان نشان می‌دهد که چه میزان تغییر در $f(\mathbf{X}_i)$ باعث بهبود درست‌نمایی می‌شود.

درخت‌های تصمیمی که در اینجا استفاده می‌شوند، همانند درخت‌های بقا هستند که تقسیم‌بندی داده‌ها را بر اساس زمان بقا و وضعیت سانسور انجام می‌دهند. بدین ترتیب، الگوریتم GBM-Survival می‌تواند روابط پیچیده بین متغیرها و الگوهای خطر را مدل کند.

محاسبه گرادیان‌های منفی تابع زیان با استفاده از پیش‌بینی‌های مدل قبلی باعث می‌شود مدل پایه جدید به طور غیرمستقیم در جهت کاهش خطا و زیان مدل قبلی گام بردارد.

۳.۳ شبکه عصبی بقا

شبکه‌های عصبی^{۱۸} یا ANN شامل سه نوع لایه از جمله لایه ورودی، لایه خروجی و لایه‌های پنهان هستند. تعداد نورون‌ها در لایه ورودی برابر با تعداد ویژگی‌های داده‌های ورودی است و تعداد نورون‌ها در لایه خروجی بستگی به هدف پیش‌بینی دارد. تعداد نورون‌های لایه پنهان بین تعداد نورون‌های لایه ورودی و تعداد نورون‌های لایه خروجی قرار می‌گیرد. به عبارتی، تعداد نورون‌ها در لایه پنهان ابرپارامتری است که با

شبکه عصبی را به دست آورد. شبکه عصبی مذکور DeepSurv نامیده می‌شود. DeepSurv یک شبکه عصبی عمیق مبتنی بر مدل مخاطرات متناسب کاکس است و روشی پیشرفته برای بقا و مدل‌سازی تعاملات غیرخطی بین ویژگی‌ها است. برای مطالعه بیشتر به مطالعه کاترمن و همکاران [۱۶] مراجعه شود.

۴ شبکه عصبی عمیق چند وظیفه‌ای

در چارچوب شبکه‌های عصبی، هنگامی که چند وظیفه باهم مرتبط هستند، می‌توان یک مدل واحد طراحی کرد که قادر به انجام همزمان همه این وظایف باشد. این رویکرد تحت عنوان یادگیری چند وظیفه‌ای^{۱۹} شناخته می‌شود. در یادگیری چندوظیفه‌ای، چندین کار مرتبط به‌طور هم‌زمان آموزش داده می‌شوند و دانش مشترک میان آن‌ها برای بهبود عملکرد کلی مدل به کار گرفته می‌شود. به‌عبارت دیگر در این رویکرد به جای آموزش مدل‌های جداگانه برای هر وظیفه، یک شبکه عصبی واحد آموزش داده می‌شود که با دریافت یک بردار ورودی (متغیرهای توضیحی)، چندین خروجی (اهداف یا متغیرهای وابسته) تولید می‌کند. در این ساختار، معمولاً بخشی از لایه‌ها و پارامترها میان وظایف مختلف به اشتراک گذاشته می‌شوند تا ویژگی‌های عمومی و مشترک که برای همه وظایف مفید هستند، استخراج شوند. این لایه‌های مشترک بر اساس ترکیبی از تابع زیان همه وظایف به‌روزرسانی می‌گردند.

علاوه بر لایه‌های مشترک، اغلب لایه‌های اختصاصی نیز برای هر وظیفه در نظر گرفته می‌شود تا جنبه‌های خاص و منحصر به فرد هر وظیفه مدیریت شود. این نوع معماری به اشتراک پارامتر سخت^{۲۰} معروف است. برای اطلاعات بیشتر می‌توان به مطالعات کاروانا [۲۸] و ژانگ و یانگ [۲۹] مراجعه کرد. از مهم‌ترین مزایای یادگیری چندوظیفه‌ای این است که در صورت مرتبط بودن وظایف، عملکرد آنها با اطلاعات مشترک هم‌دیگر بهبود می‌یابد و مدل یادگیری چند وظیفه‌ای می‌تواند به عنوان یک تنظیم‌کننده عمل کند و از بیش‌برازش به یک وظیفه خاص جلوگیری کند. با این حال، یکی از محدودیت‌های این رویکرد آن است که با افزایش تعداد وظایف، پیچیدگی مدل و هزینه محاسباتی آموزش به‌طور قابل‌توجهی افزایش می‌یابد. مدل مورد استفاده در این مطالعه، یک شبکه عصبی عمیق (منظور تعداد زیاد لایه‌های پنهان) دو وظیفه‌ای است که می‌تواند دو وظیفه برآورد تابع بقا و پیش‌بینی میانگین زمان پاسخگویی اورژانس را به‌طور هم‌زمان انجام دهد. این مدل با

در تحلیل بقا استفاده از شبکه‌های عصبی موجب دستیابی به پیش‌بینی‌های منعطف‌تری از زمان بقا نسبت به سایر روش‌های سنتی می‌گردد. در این بخش مدلی برای استفاده از پیش‌بینی‌کننده‌های شبکه عصبی با داده‌های بقای سانسور شده معرفی شده است. مدل‌های ANN برای حل مسائل پیش‌بینی و طبقه‌بندی در سال‌های اخیر به کار گرفته شده‌اند و در یک دهه اخیر علاقه زیادی به نحوه استفاده از آن‌ها برای پیش‌بینی زمان بقا به وجود آمده است. زمان وقوع رویداد برای هر مشاهده به عنوان یک متغیر تصادفی غیرمنفی مدل‌سازی می‌شود. توزیع T به مقادیر ورودی‌ها بستگی دارد. افراد با مقادیر مختلف برای ورودی‌ها، به طور کلی، توزیع زمان وقوع متفاوتی خواهند داشت. یک توصیف مفید از توزیع زمان‌های وقوع، تابع بقا است که در (۱) به آن اشاره شده است. همانطور که قبلاً گفته شد یکی از پرکاربردترین رویکردهای آماری در تحلیل داده‌های بقا، مدل مخاطرات متناسب کاکس است. چون در مطالعات داده‌های بقا از جمله مطالعات پزشکی و اورژانسی حضور داده‌های سانسور شده بسیار رایج است، مدل‌های شبکه عصبی نمی‌توانند این نوع داده‌ها را به‌صورت مستقیم تحلیل نمایند. اولین بار فراگی و سایمون [۳۳] معماری شبکه‌های عصبی را با مدل خطرات متناسب کاکس ترکیب نمودند تا از اطلاعات زمان بقا به همراه مشاهدات سانسور شده برای مدل‌سازی روابط غیرخطی استفاده کنند. از آن زمان، مطالعاتی در زمینه ترکیب معماری شبکه‌های عصبی در تحلیل بقا به وجود آمده است. به مطالعه مددی و مترجم [۴] مراجعه شود. با توجه به مدل کاکس در (۲) بردار پارامترهای مدل با ماکزیمم‌سازی تابع درست‌نمایی جزئی کاکس به صورت،

$$L_c(\beta) = \prod_{i=1}^N \left(\frac{\exp(\beta^T \mathbf{X}_i)}{\sum_{j \in R(T_i)} \exp(\beta^T \mathbf{X}_j)} \right)^{\delta_i} \quad (7)$$

با استفاده از روش نیوتن-رافسون برآورد می‌شود. مهم‌ترین قسمت مطالعه فراگی و سایمون [۳۳] جایگزینی تابع خطی $\beta^T \mathbf{X}_i$ در مدل کاکس با خروجی‌های $g(\mathbf{X}_i, \theta)$ یک شبکه عصبی بود. براین اساس مدل مخاطرات متناسب به صورت زیر،

$$h(t, \mathbf{X}_i) = h_c(\mathbf{X}_i) \exp(g(\mathbf{X}_i, \theta))$$

و تابع درست‌نمایی جزئی کاکس به صورت،

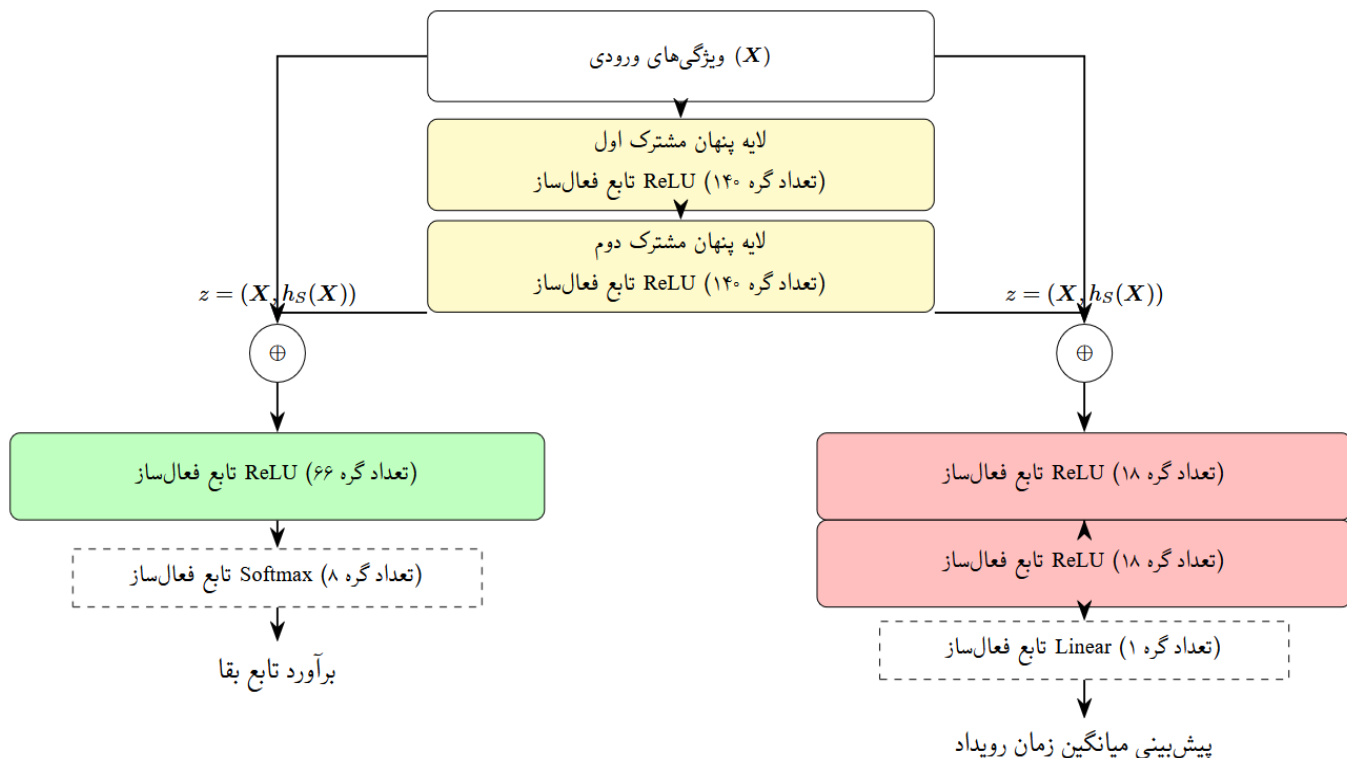
$$L_c(\theta) = \prod_{i=1}^N \left(\frac{\exp(g(\mathbf{X}_i, \theta))}{\sum_{j \in R_i} \exp(g(\mathbf{X}_j, \theta))} \right)^{\delta_i} \quad (8)$$

بازنویسی می‌گردد. با استفاده از روش نیوتن-رافسون می‌توان لگاریتم درست‌نمایی جزئی را به حداکثر رساند و پارامترهای (وزن‌های) بهینه

¹⁹Multi-Task Learning

²⁰Hard Parameter Sharing

بهره‌گیری از ویژگی‌های مشترک به‌دست‌آمده از فرآیند برآورد تابع بقا، ویژگی وابستگی به مدت زمان را در پیش‌بینی زمان پاسخگویی (یا زمان رسیدن به محل حادثه) لحاظ می‌کند. از آنجا که میانگین زمان پاسخگویی خود یکی از خروجی‌های قابل استخراج از تابع بقا است، این دو وظیفه با یکدیگر مرتبط هستند و یادگیری مشترک آن‌ها کارآمد خواهد بود.



شکل ۱: معماری شبکه عصبی چندوظیفه‌ای (MT-DNN) با دو لایه پنهان مشترک و دو وظیفه برآورد تابع بقا و پیش‌بینی میانگین زمان رویداد

الف) برای آموزش شبکه عصبی با هدف برآورد تابع بقا دو تابع زیان در نظر گرفته می‌شود:

تابع زیان منفی لگاریتم درست‌نمایی که به صورت،

$$L_1 = - \sum_{t=1}^{n_{out}} y_t \cdot \log \hat{y}_t$$

بوده که در آن n_{out} تعداد بازه‌هایی است که تابع بقا در آن بازه‌ها برآورد می‌شود. همچنین مقدار پاسخ واقعی است که از داده‌های مشاهده شده به دست می‌آید و میزان وقوع رویداد برای یک مشاهده در زمان t ام است و \hat{y}_t احتمال برآورد شده وقوع رویداد در بازه زمانی t ام است که خروجی مدلی است که وظیفه برآورد تابع بقا را انجام می‌دهد. تابع زیان رتبه بندی نیز به صورت،

$$L_2 = \sum_{i \neq j} A_{ij} \eta(\hat{H}(t_i | \mathbf{X}_i), \hat{H}(t_i | \mathbf{X}_j))$$

الگوریتم مدل چندوظیفه‌ای مبتنی بر MLP

۱. ویژگی‌های ورودی یا متغیرهای توضیحی \mathbf{X} به یک مدل پرسپترون چند لایه مشترک وارد می‌شوند.

۲. مدل پرسپترون چند لایه که بین وظایف مختلف مشترک می‌باشد بعد از دریافت متغیرهای توضیحی، ویژگی‌های زمانی مربوط به تحلیل داده‌های بقا یا $h_s(\mathbf{X})$ که بین دو وظیفه مشترک هستند را استخراج می‌کند.

۳. متغیرهای توضیحی به همراه ویژگی‌های بقا مشترک، به مدل پرسپترون چند لایه مخصوص هر وظیفه به عنوان ورودی وارد می‌شود.

۴. هر مدل مخصوص هر وظیفه با استفاده از لایه‌های پنهان، ویژگی‌های اختصاصی مربوط به خود را استخراج می‌کند.

بوده که در آن،

$$\eta(x, y) = \exp\left(\frac{y-x}{\sigma}\right)$$

و σ پارامتر مقیاس تعریف شده و

$$A_{i,j} = \begin{cases} 1 & \text{اگر } t_i < t_j \\ 0 & \text{در غیر این صورت} \end{cases}$$

است.

(ب) تابع زیان مربوط به آموزش شبکه عصبی دوم (با هدف پیش‌بینی میانگین زمان رویداد)، مجموع میانگین مربعات خطا (MSE)^{۲۱} بوده که دارای رابطه زیر است:

$$L_T = \frac{1}{K} \sum_{k=1}^K (T_k - \hat{T}_k)^2$$

در این فرمول K تعداد مشاهدات است. T_k و \hat{T}_k به ترتیب مدت زمان واقعی رویداد و زمان بقای تخمین‌زده شده توسط مدل است.

۵. با تابع زیان ترکیبی زیر لایه‌های MLP مشترک آموزش داده می‌شود:

$$L_{total} = L_1 + w_1 \cdot L_T + w_2 \cdot L_T$$

با استفاده از تابع زیان ترکیبی ویژگی‌های پنهان مشترک میان دو وظیفه استخراج می‌شود. وزن‌های مربوط به هر تابع زیان به‌عنوان ابرپارامتر در نظر گرفته شده و در فرآیند آموزش برآورد می‌شوند.

۵. پیش‌پردازش و توصیف داده‌ها


داده‌های اورژانس شامل اطلاعات ۲۸۵۰۷ مورد تصادف است که برای هر تصادف، ویژگی‌هایی مانند تاریخ، جنسیت، زمان تماس، ساعت رسیدن به محل حادثه، سن بیمار، شناسه تصادف (Accident-ID) و ID ثبت شده است. این داده‌ها مربوط به تصادفات شهر مشهد و زمان رسیدن آمبولانس به محل هر تصادف در سال ۱۳۹۶ هستند. متغیر زمان تماس نشان‌دهنده‌ی زمانی است که در هر تصادف با خدمات فوریت‌های پزشکی تماس گرفته شده است، و منظور از ساعت رسیدن به محل حادثه، زمان حضور تیم اعزامی اورژانس در محل تصادف است. برای هر تصادف، یک شناسه‌ی منحصر به فرد Accident ID در

نظر گرفته شده است. تکرار یکسان این کد در داده‌ها نشان می‌دهد که یک حادثه رخ داده و چند نفر در آن تصادف درگیر بوده‌اند. با استفاده از متغیر تاریخ، دو متغیر جدید با عنوان فصل و نوع روز ساخته شد تا تأثیر شرایط زمانی بر زمان پاسخ‌گویی اورژانس بررسی شود. متغیر نوع روز یک متغیر دو-دویی بوده که دارای دو سطح اول هفته و آخر هفته است. در این تقسیم‌بندی، روزهای شنبه تا چهارشنبه به‌عنوان روزهای اول هفته و روزهای پنج‌شنبه و جمعه به‌عنوان روزهای آخر هفته در نظر گرفته شده‌اند. همچنین، با استفاده از متغیرهای زمان تماس و ساعت رسیدن اورژانس به محل حادثه، دو متغیر دیگر با عنوان زمان شب و روز و ساعت اوج ترافیک تعریف شد. بازه زمانی بین ساعت ۶ صبح تا ۱۸ عصر به‌عنوان زمان روز و فاصله زمانی بین ۱۸ عصر تا ۶ صبح به‌عنوان زمان شب در نظر گرفته شد. علاوه بر این، متغیر ساعت اوج ترافیک دارای دو سطح، اوج ترافیک و خارج از اوج است؛ به‌طوری‌که بازه‌های زمانی هفت تا نه صبح و ۱۶ تا ۱۹ عصر به‌عنوان ساعات اوج ترافیک تعیین شدند. همچنین با محاسبه تفاضل بین دو متغیر زمان تماس و ساعت رسیدن اورژانس به محل حادثه، متغیر جدیدی با عنوان مدت زمان به دست می‌آید. این متغیر معادل زمان بقا در تحلیل داده‌های بقا بوده و مدت‌زمان پاسخ‌گویی اورژانس را برای هر تصادف نشان می‌دهد. در واقع، متغیر مدت زمان بیانگر فاصله زمانی (بر حسب دقیقه) از لحظه تماس با مرکز فوریت‌های پزشکی تا زمان رسیدن تیم اورژانس به محل حادثه است. معمولاً در مجموعه داده‌ها برخی مقادیر گمشده یا غیرواقعی وجود دارد که با به‌کارگیری روش‌های پیش‌پردازش داده‌ها برطرف می‌شوند. پس از حذف داده‌های گمشده، در نهایت ۲۱۰۵۹ رکورد برای توسعه مدل مورد استفاده قرار گرفت. پس از ساخت متغیرهای توضیحی جدید، متغیرهای ID، Accident-ID، تعداد تصادف، زمان تماس و ساعت رسیدن به محل حادثه از مجموعه داده حذف گردیدند. در این پژوهش، با توجه به اینکه زمان طلایی برای رسیدن اورژانس درون شهری برابر با هشت دقیقه در نظر گرفته می‌شود، بازه زمانی مطالعه نیز بر همین اساس تنظیم شده است. بنابراین، تصادفاتی که مدت زمان رسیدن آمبولانس در آن‌ها بیش از هشت دقیقه باشد، به‌عنوان داده‌های سانسور شده تلقی می‌شوند؛ در نتیجه، نوع سانسور در این پژوهش از نوع سانسور راست است. از میان کل داده‌ها، تعداد ۱۳۶۰۲ مورد (معادل با ۶۴٪ درصد) سانسور شده‌اند و برای ۷۴۵۶ تصادف (۳۵٪ درصد)، آمبولانس در کمتر از هشت دقیقه به محل حادثه رسیده است. در بین هفت متغیر توضیحی، متغیرهای جنسیت و سن بیمار از نوع متغیرهای فردی، و متغیرهای زمان شب

²¹Mean Squared Error

به صورت تصادفی، ۸۰ درصد از داده‌ها برای آموزش و اعتبارسنجی مدل و ۲۰ درصد برای آزمون مدل مورد استفاده قرار گرفتند. شکل ۲ توزیع مدت‌زمان پاسخ‌گویی اورژانس مشهد (به دقیقه) به تصادفات درون شهری را نمایش می‌دهد.

و روز، فصل، نوع روز و ساعت اوج ترافیک از نوع متغیرهای زمانی هستند. در میان این متغیرها، تنها متغیر سن بیمار عددی و پیوسته است. تمام متغیرهای طبقه‌بندی‌شده در مرحله آموزش مدل با روش One-Hot کدگذاری شدند و متغیر عددی سن بیمار نیز استاندارد گردید.



شکل ۲: توزیع مدت زمان پاسخ‌گویی اورژانس (به دقیقه) به تصادفات درون‌شهری مشهد

بقا برای ارزیابی عملکرد مدل MT-DNN استفاده شد. در مدل‌های RSF و GBM-Survival، از میانه‌ی مدت‌زمان پاسخ‌گویی اورژانس که از تابع بقای برآورد شده محاسبه می‌شود، برای پیش‌بینی مدت‌زمان پاسخ‌گویی اورژانس استفاده گردید. برای مدل RF، چهار ابرپارامتر شامل تعداد درخت‌ها، حداکثر عمق هر درخت، نرخ نمونه‌گیری برای آموزش هر درخت و تعداد متغیرهای انتخاب‌شده در هر گره تقسیم تنظیم گردید. به طور مشابه، GBM نیز دارای چهار ابرپارامتر شامل تعداد درخت‌ها، حداکثر عمق هر درخت، نرخ یادگیری و تعداد متغیرهای در نظر گرفته‌شده در هر درخت است. ابرپارامترهای اصلی مدل‌ها با استفاده از روش اعتبارسنجی متقابل K -Fold با مقدار $K = 5$ تنظیم شده‌اند. روش دقیق جستجوی ابرپارامترها با استفاده از روش Bayesian Optimization با کتابخانه Optuna انجام شد. در این روش، هر ترکیب از ابرپارامترها ارزیابی می‌شود و مقدار خطای مربوط به آن محاسبه می‌گردد. در نهایت، ترکیبی از ابرپارامترها که کمترین مقدار خطا را در معیارهای MAE و MAPE و بالاترین مقدار شاخص تطابق وابسته به زمان $(C\text{-td})$ ^{۲۵} دارد، به عنوان ترکیب بهینه انتخاب

۶ برازش مدل‌ها

در این مطالعه، مدل AFT با سه توزیع پایه شامل لگ‌نرمال، لگ‌لوژیستیک و وایبل به عنوان مدل‌های معیار در نظر گرفته شده و به داده‌ها برازش داده شد. همچنین، به منظور در نظر گرفتن ناهمگنی مشاهده‌نشده ناشی از اثرات تصادفی، مدل RPAFT با عرض از مبدأ تصادفی نیز به داده‌ها برازش یافت. در این مدل، متغیر تاریخ به عنوان عامل ایجادکننده همبستگی میان تصادف‌های رخ داده در یک روز، به صورت عرض از مبدأ تصادفی وارد مدل گردید. این مدل نیز با سه توزیع وایبل، لگ‌نرمال و لگ‌لوژیستیک برازش داده شد. عملکرد تمامی مدل‌های بقا با استفاده از سه معیار میانگین خطای مطلق^{۲۲} (MAE)، میانگین درصد خطای مطلق^{۲۳} (MAPE) و معیار اطلاع آکائیک^{۲۴} (AIC) مورد ارزیابی قرار گرفت. با توجه به عملکرد برتر مدل‌های RF و GBM در میان روش‌های یادگیری ماشین در مطالعه حمد و همکاران [۳۰]، این دو مدل به عنوان مدل‌های معیار در این مطالعه انتخاب شدند. در این پژوهش، از دو مدل RF و GBM با دو هدف پیش‌بینی میانگین زمان پاسخ‌گویی اورژانس و برآورد تابع

²²Mean Absolute Error

²³Mean Absolute Percentage Error

²⁴Akaike Information Criterion

²⁵Time-dependent Concordance Index

جدول ۱: خلاصه آمار توصیفی متغیرهای عددی و کیفی

متغیر	نوع متغیر	آمار توصیفی
سن بیمار	عددی	میانگین = ۳۰/۱۹، انحراف معیار = ۱۶/۹۵، حداقل = ۰/۵۰، چارک اول = ۱۹، میانه = ۲۸، چارک سوم = ۳۹، حداکثر = ۱۰۰
مدت زمان	عددی	میانگین = ۱۱/۷۸، انحراف معیار = ۳۰/۸۳، حداقل = ۰/۵۳، چارک اول = ۶/۹۵، میانه = ۹/۵۳، چارک سوم = ۱۳/۱۰، حداکثر = ۱۲۰
جنسیت	دو-دویی	تعداد = ۲۱۰۵۸، تعداد مقادیر یکتا = ۲، مقدار پرتکرار = مذکر، فراوانی مقدار پرتکرار = ۱۵۱۲۲
زمان شب و روز	دو-دویی	تعداد = ۲۱۰۵۸، تعداد مقادیر یکتا = ۲، مقدار پرتکرار = روز، فراوانی مقدار پرتکرار = ۱۲۴۳۷
ساعت اوج ترافیک	دو-دویی	تعداد = ۲۱۰۵۸، تعداد مقادیر یکتا = ۲، مقدار پرتکرار = خارج از اوج، فراوانی مقدار پرتکرار = ۱۶۹۸۴
نوع روز	دو-دویی	تعداد = ۲۱۰۵۸، تعداد مقادیر یکتا = ۲، مقدار پرتکرار = اول هفته، فراوانی مقدار پرتکرار = ۱۴۹۹۹
فصل	چند سطحی	تعداد = ۲۱۰۵۸، تعداد مقادیر یکتا = ۴، مقدار پرتکرار = تابستان، فراوانی مقدار پرتکرار = ۷۳۹۹

مرتبط با داده‌های بقا را که برای هر دو وظیفه مشترک هستند فراهم می‌کند. تعداد لایه‌های پنهان مشترک دو لایه است که هر لایه دارای ۱۴۰ گره (نورون) می‌باشد. همان‌طور که اشاره شد، ویژگی‌های استخراج شده از لایه‌های مشترک، به همراه متغیرهای توضیحی، به عنوان ورودی به شبکه‌های عصبی اختصاصی هر وظیفه ارسال می‌شوند. هر یک از این شبکه‌های اختصاصی نیز از نوع پرسپترون چندلایه کاملاً متصل هستند. شبکه عصبی مربوط به برآورد تابع بقا شامل یک لایه پنهان با ۶۶ گره و تابع فعال‌سازی ReLU است. تعداد گره‌های لایه خروجی این شبکه برابر با تعداد بازه‌های زمانی تعریف شده برای برآورد تابع بقا است که بر اساس حساسیت مورد نظر مطالعه تعیین می‌شود. در این پژوهش، هشت بازه زمانی یک دقیقه‌ای در نظر گرفته شده که متناسب با نیازهای عملی مدیریت اورژانس است. تابع فعال‌سازی لایه خروجی این شبکه سافت‌مکس است که احتمالات نسبی وقوع رویداد را در هر بازه زمانی محاسبه می‌کند. شبکه عصبی مربوط به پیش‌بینی میانگین

می‌شود. دو مدل شبکه عصبی، شامل مدل پیش‌بینی میانگین زمان رویداد (ANN) و مدل برآورد تابع بقا (DeepSurv)، به صورت جداگانه بر داده‌ها برازش داده شدند. به منظور بررسی میزان بهبود عملکرد حاصل از رویکرد یادگیری چندوظیفه‌ای، مدل MT-DNN به طور جداگانه با مدل‌های تک‌وظیفه‌ای شبکه عصبی (یعنی مدل اختصاصی برآورد تابع بقا و مدل اختصاصی پیش‌بینی میانگین زمان پاسخگویی) مقایسه گردید. به منظور انتخاب معماری نهایی مدل MT-DNN، ترکیب‌های مختلف ابرپارامترها بررسی و تنظیم گردید. این ابرپارامترها شامل تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه، نرخ یادگیری، نرخ ریزش و وزن‌های هر تابع زیان بودند. معماری نهایی مدل MT-DNN همراه با ابرپارامترهای بهینه شده در شکل ۱ نشان داده شده است. در این مطالعه، لایه‌های پنهان مشترک میان دو وظیفه از نوع پرسپترون چندلایه^{۲۶} کاملاً متصل^{۲۷} هستند و تابع فعال‌سازی آن‌ها ReLU انتخاب شده است. استفاده از این تابع فعال‌سازی امکان استخراج ویژگی‌های زمانی

²⁶Multi Layer Perceptron²⁷Fully Connected

$$MAPE = \frac{1}{k} \sum_{k=1}^K \frac{T_k - \hat{T}_k}{T_k} \times 100.$$

عملکرد مدل‌ها برای وظیفه برآورد توزیع زمان بقا (تابع بقا) با شاخص C-tد ارزیابی شده که به صورت،

$$C - td = \frac{\sum_{i \neq j} A_{i,j} \cdot B_{i,j}}{\sum_{i \neq j} A_{i,j}}$$

است و در آن،

$$A_{i,j} = \begin{cases} 1 & \text{اگر } t_i < t_j, \\ 0 & \text{در غیر این صورت} \end{cases}$$

و

$$B_{i,j} = \begin{cases} 1 & \text{اگر } \hat{H}(t_i | \mathbf{X}_i) > \hat{H}(t_j | \mathbf{X}_j), \\ 0 & \text{در غیر این صورت} \end{cases}$$

این شاخص توانایی مدل را در پیش‌بینی درست ترتیب وقوع رویدادها ارزیابی می‌کند و بر این فرض استوار است که مشاهداتی که زمان وقوع رویداد برای آن‌ها طولانی‌تر است، باید نرخ خطر کمتری نسبت به مواردی داشته باشند که رویداد زودتر برایشان رخ داده است. شاخص C-tد در تمام بازه‌های زمانی، مخاطره تجمعی را ارزیابی می‌کند، و از این رو می‌تواند وابستگی اثر متغیرها به زمان را نیز شناسایی کند. این ویژگی باعث می‌شود که شاخص C-tد در کاربردهایی مانند سیستم اورژانس که اثرات متغیرهای توضیحی ممکن است در طول زمان تغییر کند، بسیار مفید عمل کند. طبق شکل ۳، در زمان هشت دقیقه احتمال بقا برابر با ۰/۶ است. بدین معنی که در حدود ۶۰ درصد از تصادفات، تا زمان هشت دقیقه هنوز اورژانس به محل حادثه نرسیده است. همان‌طور که انتظار می‌رود، نمودار تابع بقا غیرصعودی است و به دلیل حجم بالای داده‌ها، به صورت منحنی مشاهده می‌شود. همچنین، نمودار تابع نرخ خطر روندی صعودی را نشان می‌دهد. افزایش نرخ خطر به این معناست که با گذشت زمان، احتمال رسیدن اورژانس به محل تصادف نیز افزایش می‌یابد.

زمان پاسخگویی نیز دارای دو لایه پنهان با تابع فعال‌سازی ReLU است که هر لایه ۱۸ گره دارد. لایه خروجی این شبکه تنها یک گره دارد، زیرا هدف پیش‌بینی یک مقدار عددی (میانگین زمان تا رویداد) است و از این رو تابع فعال‌سازی آن خطی انتخاب شده است. در مدل MT-DNN نرخ یادگیری برابر با ۰/۰۰۰۶ تنظیم شده است. همچنین برای هر لایه پنهان، یک لایه ریزش^{۲۸} با نرخ ریزش ۸ درصد اعمال گردیده است تا از بیش‌برازش جلوگیری شود. برای آموزش مدل، از الگوریتم بهینه‌سازی Adam استفاده شده است. برای اعمال زیان منفی لگاریتم درست‌نمایی^{۲۹} تابعی تعریف می‌شود که بازه‌های زمانی برای برآورد تابع بقا را برای مشاهدات سانسور شده و غیرسانسور شده تعیین کند.

تابع زیان رتبه‌بندی^{۳۰} نیز با استفاده از نرخ خطر تجمعی، ترتیب وقوع رویدادها را ارزیابی می‌کند. به این معنا که حوادثی که رویداد زودتر برایشان رخ داده است باید احتمال بقای کمتری (و نرخ خطر بیشتری) نسبت به حوادثی داشته باشند که همان رویداد را دیرتر تجربه کرده‌اند. هرچه مدل بتواند این ترتیب‌ها را دقیق‌تر پیش‌بینی کند، به معنای برآورد دقیق‌تر تابع بقا خواهد بود. بنابراین کاهش مقدار این زیان نشان‌دهنده بهبود کیفیت برآورد تابع بقا است. با توجه به عملکرد این تابع زیان باید تابعی تعریف شود که مشاهداتی که تا قبل از لحظه مقایسه t رویداد برایشان اتفاق افتاده است در محاسبه زیان در نظر گرفته نشوند.

عملکرد مدل‌های آماری از جمله AFT و RPAFT با استفاده از معیار AIC گزارش می‌شود که دارای رابطه زیر است:

$$AIC = 2p + n \ln L,$$

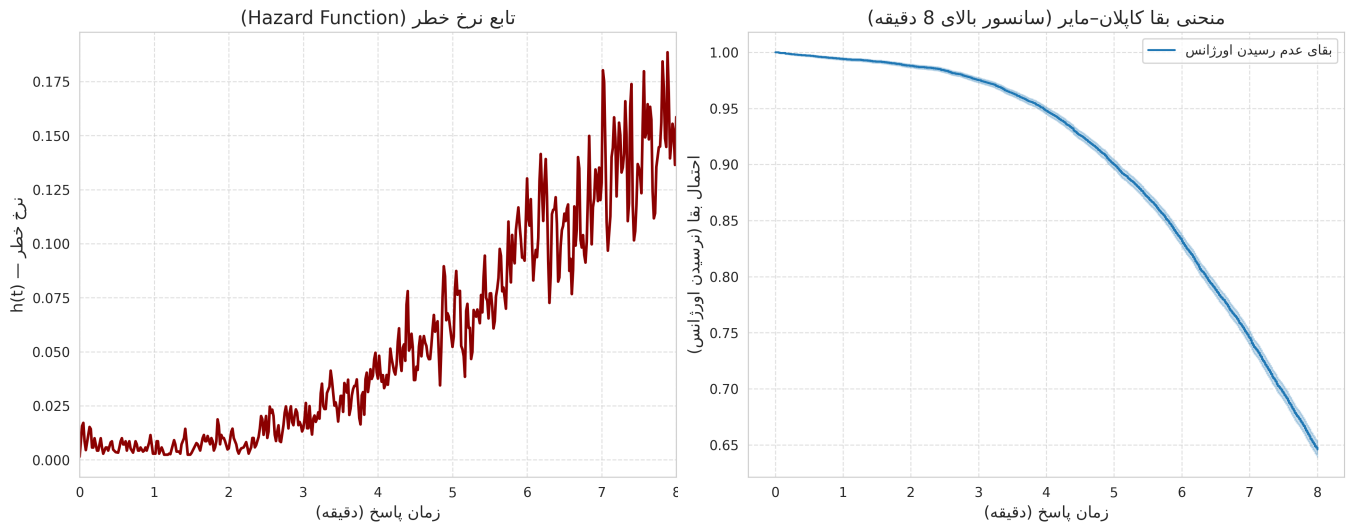
که در آن p تعداد پارامترهای مدل، n حجم نمونه و L مقدار ماکزیمم تابع درست‌نمایی برای مدل برآورد شده است. مدلی که مقادیر کمتری از معیار AIC را دارد، مدل بهتری برای برازش به داده‌ها است. همچنین عملکرد مدل برای پیش‌بینی میانگین مدت زمان رویداد با MAE و MAPE ارزیابی می‌شود.

$$MAE = \frac{1}{k} \sum_{k=1}^K |T_k - \hat{T}_k|,$$

²⁸Dropout

²⁹Negative Log-Likelihood Loss

³⁰Rank Loss



نمودار نرخ خطر مدت زمان پاسخگویی اورژانس

نمودار کاپلان-مایر مدت زمان پاسخگویی اورژانس

شکل ۳: نمودارهای تابع بقا و نرخ خطر مدت زمان پاسخگویی اورژانس (به دقیقه) به تصادفات درون شهری مشهد

ناهمگنی مشاهده‌نشده در داده‌ها است. به عبارت دیگر، تصادف‌های رخ داده در یک روز ممکن است تحت تأثیر عوامل مشترکی نظیر شرایط آب‌وهوایی و حجم ترافیک همان روز قرار گیرند که مستقیماً در داده‌ها اندازه‌گیری نشده‌اند. بنابراین، پارامترهای برآورد شده در مدل RPAFT پیش‌بینی‌های دقیق‌تر و قابل‌اعتمادتری از تأثیر متغیرهای مستقل ارائه می‌کنند. مدل‌های GBM و ANN در پیش‌بینی میانگین زمان رویداد، و همچنین مدل MT-DNN، عملکردی بهتر از مدل RPAFT نشان داده‌اند.

۷ نتایج و بحث

جدول ۲ عملکرد پیش‌بینی مدل‌های تحلیل بقا از جمله مدل AFT و مدل RPAFT را نشان می‌دهد. مدل AFT با توزیع لگ‌لوژیستیک در مقایسه با سایر توزیع‌ها عملکرد بهتری در معیارهای MAE، MAPE و AIC نشان می‌دهد و به عنوان مدل پایه انتخاب شده است. در مقایسه با این مدل پایه، مدل RPAFT با توزیع لگ‌لوژیستیک مقادیر کمتری در معیارهای MAE، MAPE و AIC ارائه می‌دهد که بیانگر وجود

جدول ۲: نتایج مدل زمان شکست شتابیده (AFT) و مدل زمان شکست شتابیده با عرض از مبدأ تصادفی (RPAFT) با توزیع‌های وایبل، لگ نرمال و لگ لوژیستیک با معیارهای ارزیابی MAE، MAPE و AIC برای داده‌های اورژانس مشهد

AIC	MAPE	MAE	مدل‌های تحلیل بقا
۵۲۶۰۸،۵۷	۲۰،۲۷۸	۱۷،۱۲۹۷	AFT(Weibull)
۵۱۰۸۳،۵۱	۳۳،۲۰۱	۱۱،۴۴۲۹	(Log-Logistic) AFT
۵۰۷۹۷،۲۲	۸۰،۲۲۱	۱۲،۷۴	(Log-Normal) AFT
۴۳۷۵۸،۴۳	۷۷،۶۷۲	۷،۵۶۰۹	(Log-Normal) RPAFT
۴۲۳۵۸،۸۷	۲۱،۴۰۲	۵،۳۹۱۲	(Log-Logistic) RPAFT

آن است که تمامی مدل‌های یادگیری ماشین عملکرد بهتری نسبت به مدل AFT با توزیع لگ‌لوژیستیک دارند؛ این امر بیانگر آن است که

جدول ۳ و جدول ۴ عملکرد مدل‌های یادگیری ماشین را در پیش‌بینی زمان پاسخگویی اورژانس نشان می‌دهد. نتایج حاکی از

وابستگی به مدت زمان در داده‌های بقا را در نظر بگیرند. برخلاف سایر مدل‌های یادگیری ماشین، شبکه عصبی با هدف برآورد تابع بقا (DeepSurv) عملکرد پیش‌بینی ضعیف‌تری نسبت به شبکه عصبی با هدف پیش‌بینی میانگین مدت‌زمان پاسخگویی اورژانس نشان می‌دهد. بهبود عملکرد مدل‌های RPAFT و یادگیری ماشین نسبت به مدل AFT با توزیع لگ‌لوژیستیک، بر اساس معیار MAE بیش از معیار MAPE است.

در نظر گرفتن روابط تعاملی و غیرخطی میان متغیرها موجب بهبود دقت پیش‌بینی می‌شود. همچنین عملکرد هر دو مدل RF و GBM در زمانی که وظیفه آن‌ها از پیش‌بینی میانگین زمان پاسخگویی به برآورد تابع بقا تغییر می‌یابد، تقریباً مشابه است. بنابراین میانه زمان پاسخگویی برآوردشده از تابع بقا می‌تواند به عنوان زمان پاسخگویی پیش‌بینی‌شده توسط مدل‌های RSF و GBM-Survival گزارش شود. با این حال، مدل‌های RF و GBM با هدف رگرسیون در پیش‌بینی دقیق زمان پاسخگویی اورژانس با محدودیت مواجه‌اند و نمی‌توانند ویژگی

جدول ۳: مقایسه نتایج مدل‌های یادگیری ماشینی از جمله جنگل تصادفی (RF)، جنگل بقای تصادفی (RSF)، گرادیان تقویت‌شده رگرسیون (GBM) و گرادیان تقویت‌شده بقا (GBM-Survival) با معیارهای ارزیابی MAE، MAPE و C-td برای داده‌های اورژانس مشهد

مدل‌های یادگیری ماشین	MAE	MAPE	C-td
RF	۴,۴۳۶	۵۱,۸۰	
RSF	۴,۵۳۴	۳۹,۳۴	۰/۶۱۶۸
GBM	۴,۴۳۱	۵۱,۸۴	
GBM-Survival	۴,۵۳۷	۳۹,۳۲	۰/۶۱۷۹

جدول ۴: مقایسه نتایج مدل‌های شبکه عصبی مصنوعی (ANN) و شبکه عصبی بقا (DeepSurv) با معیارهای ارزیابی MAE، MAPE و C-td برای داده‌های اورژانس مشهد

مدل‌های شبکه عصبی	MAE	MAPE	C-td
ANN	۵,۰۹۰۲	۶۰,۲۰	
DeepSurv	۶,۰۲۶۵	۶۲,۵۶	۰/۶۰۵۶

AFT نیز عملکرد برتری دارد. این یافته نشان می‌دهد که انجام هم‌زمان وظایف مرتبط، موجب بهبود عملکرد پیش‌بینی در هر یک از وظایف می‌شود. علاوه بر این، ساختار یادگیری چند وظیفه‌ای مدل را قادر می‌سازد تا ویژگی وابستگی به مدت زمان را در داده‌ها در نظر بگیرد که ویژگی مهمی برای مدل‌سازی داده‌های زمان تا رویداد است. این نتایج همچنین نشان‌دهنده آن است که مدل‌های مبتنی بر شبکه‌های عصبی عمیق می‌توانند به‌عنوان مکمل قدرتمندی در کنار مدل‌های آماری سنتی عمل کنند و در مواردی که داده‌ها پیچیدگی و ناهمگنی بالایی دارند، عملکرد بهتری ارائه دهند.

جدول ۵ عملکرد پیش‌بینی مدل MT-DNN را بر اساس معیارهای MAE، MAPE و C-td برای داده‌های اورژانس مشهد نشان می‌دهد. برخلاف مدل‌های یادگیری ماشین که هر یک به‌صورت تک‌وظیفه‌ای و با هدف پیش‌بینی میانگین زمان پاسخگویی یا برآورد تابع بقا به داده‌ها برآزش داده شدند، مدل MT-DNN این دو وظیفه را به‌صورت هم‌زمان و در یک چارچوب یادگیری چندوظیفه‌ای انجام می‌دهد. براساس نتایج، مدل MT-DNN بهترین عملکرد را هم در پیش‌بینی میانگین زمان پاسخگویی اورژانس بر اساس معیارهای MAE و MAPE و هم در برآورد تابع بقا بر اساس معیار C-td نسبت به مدل‌های تک‌وظیفه‌ای نشان داده است. نتایج بیانگر آن است که این مدل نسبت به مدل‌های

جدول ۵: نتایج مدل شبکه عصبی عمیق چند وظیفه‌ای (MT-DNN) با معیارهای ارزیابی MAE، MAPE و C-td در پیش‌بینی زمان پاسخگویی اورژانس مشهد

مدل هدف	MAE	MAPE	C-td
MT-DNN	۴,۸۵۴	۴۲,۰۹	۰,۶۰۸۸

تحلیل عوامل تاثیرگذار یا متغیرهای توضیحی می‌تواند عملکرد و منطق مدل در پیش‌بینی‌هایی که انجام می‌دهد را تایید کند. برای مدل MT-DNN اهمیت کلی متغیرها با استفاده از مقدار SHAP محاسبه شده است تا عوامل مؤثر بر زمان پاسخگویی اورژانس تعیین شوند. اهمیت متغیر شامل مجموع اثرات اصلی و متقابل متغیرها (یعنی اثر کل) است، در حالی که برآوردهای پارامتری مدل‌های آماری تنها اثرات اصلی متغیرها را نشان می‌دهند. اگرچه اهمیت متغیرها از نظر آماری معنی‌دار نیست، اما معنای فیزیکی آن می‌تواند نتایج پیش‌بینی را توضیح دهد. مقادیر SHAP از نظریه بازی‌های تعاونی گرفته شده‌اند. هر ویژگی به عنوان یک بازیکن در نظر گرفته شده و یک مقدار اهمیت برای آن اختصاص می‌یابد که نشان‌دهنده سهم آن ویژگی در توضیح تفاوت بین پیش‌بینی مدل با پیش‌بینی مدل پایه است. این روش با محاسبه سهم متوسط حاشیه‌ای هر ویژگی در تمامی ترکیبات ممکن،

اعتبار پیش‌بینی را به طور عادلانه بین ویژگی‌ها توزیع می‌کند. اهمیت متغیرها در داده‌های زمان پاسخگویی اورژانس مشهد به تصادفات در جدول ۶ نشان داده می‌شود. بر اساس نتایج به‌دست‌آمده از مقادیر SHAP، متغیر فصل تابستان بیشترین تأثیر را در پیش‌بینی زمان پاسخگویی اورژانس به تصادفات درون‌شهری مشهد داشته است. این امر عمدتاً به دلیل افزایش شدید ترافیک و حضور گسترده زائران در فصل تابستان می‌تواند به‌وجود آید. همچنین عوامل زمانی نظیر شب‌بودن حادثه، ساعات اوج ترافیک و نوع روز (آخر هفته یا ابتدای هفته) تأثیر قابل توجهی بر زمان رسیدن آمبولانس نشان می‌دهند. در مقابل، متغیر سن بیمار و برخی فصول سال سهم کمتری در تغییرات زمان پاسخگویی داشته‌اند که بیانگر غالب بودن شرایط ترافیکی و زمانی بر ویژگی‌های فردی است. برای پیاده‌سازی مدل روی داده‌ها، از نرم‌افزار پایتون نسخه ۳.۰۸ استفاده شده است.

در این مطالعه، یک مدل شبکه عصبی عمیق چند وظیفه‌ای با عنوان MT-DNN به منظور ترکیب شبکه عصبی با مدل مدت‌زمان مبتنی بر خطر و بر اساس ساختار یادگیری چندوظیفه‌ای بر داده‌ها برازش داده شد. این مدل با برآورد هم‌زمان تابع بقا، قادر است ویژگی وابستگی به مدت‌زمان را هنگام پیش‌بینی زمان پاسخگویی اورژانس در نظر بگیرد. ویژگی وابستگی به مدت زمان یکی از ویژگی‌های مهم داده‌های بقا است و بیان می‌کند که زمان رسیدن اورژانس به محل حادثه به مدت‌زمان پاسخگویی آن بستگی دارد. نتایج نشان داد مدل‌های RSF و GBM-Survival به ترتیب عملکرد بهتری نسبت به مدل‌های RF و GBM معمولی دارند، همچنین مدل گرادینان تقویت‌شده نسبت به مدل جنگل تصادفی برتری دارد. برخلاف مدل‌های یادگیری ماشین، مدل شبکه عصبی بقا (DeepSurv) عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی (ANN) نشان نداد. با این حال، مدل MT-DNN عملکرد پیش‌بینی شبکه‌های عصبی را بهبود داده و بهترین نتایج را

۸ نتیجه‌گیری

در میان تمامی مدل‌ها ارائه کرده است. این یافته‌ها کارایی به‌کارگیری ساختار یادگیری چندوظیفه‌ای را در حضور وظایف مرتبط، به‌منظور در نظر گرفتن ویژگی وابستگی به مدت‌زمان، تأیید می‌کنند. مدل MT-DNN تنها یک کاربرد ساده از روش‌های یادگیری ماشین نیست، بلکه رویکردی است که در آن شبکه‌های عصبی در چارچوب مدل‌های آماری تلفیق می‌شوند. در تحقیقات آینده، می‌توان در لایه‌های مشترک این مدل از شبکه‌های عصبی عمیق نظیر CNN استفاده کرد یا آن را برای تحلیل بقا در شرایط ریسک‌های رقابتی گسترش داد. همچنین می‌توان از سایر ساختارهای یادگیری چند وظیفه‌ای، از جمله اشتراک پارامتر نرم، بهره گرفت. از سوی دیگر، با توجه به اینکه مطالعه حاضر بر مدل‌سازی داده‌های زمان تا رویداد متمرکز است، می‌توان چارچوب چندوظیفه‌ای را به سایر داده‌های مدت‌زمان نیز تعمیم داد. به‌عنوان مثال، فرایند پاسخگویی اورژانس شامل چندین مرحله متوالی است که بهبود هر یک از آن‌ها می‌تواند به کاهش زمان کل پاسخگویی منجر شود. از جمله این مراحل می‌توان به فاصله زمانی اطلاع‌رسانی تا شروع حرکت واحد EMS و همچنین مدت زمان شروع حرکت تا رسیدن به

جدول ۶: اهمیت متغیرها بر اساس مقادیر SHAP در پیش‌بینی زمان پاسخگویی اورژانس به تصادفات درون‌شهری مشهد

مقدار SHAP	ویژگی
۰٫۹۷۷۹	فصل تابستان
۰٫۶۱۶۲	زمان شب و روز - شب
۰٫۵۵۶۳	جنسیت - مونث
۰٫۵۴۳۱	فصل پاییز
۰٫۴۹۸۸	ساعت اوج ترافیک - اوج
۰٫۴۹۱۰	نوع روز - آخر هفته
۰٫۴۸۵۶	جنسیت - مذکر
۰٫۴۷۶۰	زمان شب و روز - روز
۰٫۳۷۰۷	نوع روز - اول هفته
۰٫۲۹۰۴	ساعت اوج ترافیک - خارج از اوج
۰٫۰۶۷۱	فصل زمستان
۰٫۰۶۵۸	فصل بهار
۰٫۰۵۸۰	سن بیمار

می‌توان به نبود اطلاعات مربوط به متغیرهای مهمی مانند مسافت واقعی طی شده توسط آمبولانس، سابقه کاری تیم ارسالی اورژانس، تعداد افراد مجروح، نوع جراحت و مکان دقیق وقوع حادثه اشاره کرد. در پژوهش‌های آتی، می‌توان این متغیرها را نیز در تحلیل‌ها وارد کرد تا عوامل مؤثر بر زمان پاسخگویی بررسی شوند. داده‌های مورد مطالعه مربوط به شهرستان مشهد بوده که می‌توان آن را هم نقطه قوت (داده‌های واقعی و حجیم) و هم محدودیت مطالعه (عدم تعمیم‌پذیری به سایر مناطق کشور) دانست. پیشنهاد می‌شود در مطالعات آتی از داده‌های چندمرکزی استفاده شود تا تعمیم‌پذیری نتایج افزایش یابد. شناسایی این عوامل می‌تواند به مدیران و تصمیم‌گیرندگان در برنامه‌ریزی عملیاتی، مکان‌یابی یا جابه‌جایی ایستگاه‌ها و مدیریت منابعی مانند آمبولانس‌ها و نیروی انسانی کمک کند.

تقدیر و تشکر

نویسندگان از داوران محترم به خاطر دقت نظر و صرف وقت در مطالعه مقاله و ارائه پیشنهادات برای بهبود آن، تقدیر و تشکر می‌کنند.

محل حادثه اشاره کرد. در پژوهش‌های آینده، می‌توان هر یک از این مراحل را به صورت جداگانه پیش‌بینی کرده و میزان تأثیر آن‌ها را بر زمان نهایی پاسخگویی مورد بررسی قرار داد. در بسیاری از موارد، نمودار تابع نرخ خطر یک الگوی پیچیده را نشان می‌دهد که ترکیبی از افزایش و کاهش است. این نشان می‌دهد که عوامل مختلفی بر زمان پاسخگویی اورژانس تأثیر می‌گذارند و این تأثیرات در طول زمان تغییر می‌کند. در مطالعات آینده می‌توان به بررسی تأثیر متغیرهای وابسته به زمان در مطالعه اورژانس پرداخت. همچنین می‌توان در مدل RPAFT، اثرات متقابل متغیرها را نیز وارد کرد و علاوه بر آن، پارامترهای تصادفی دیگری را به همراه عرض از مبدأ تصادفی در مدل لحاظ نمود. بر اساس مطالعات پیشین در مناطق شهری مترام با وجود مسافت کوتاه، زمان سفر به دلیل ازدحام ترافیک طولانی‌تر است. همچنین نتایج برخی پژوهش‌ها نشان می‌دهد که عواملی مانند تعداد افراد مجروح و نوع جراحت نقش مهمی در زمان‌های پاسخگویی و نجات خدمات فوریت‌های پزشکی در تصادفات جاده‌ای ایفا می‌کنند. با این حال، مطالعه حاضر با محدودیت‌هایی همراه است که لازم است در تحقیقات آینده مورد توجه قرار گیرند. از جمله این محدودیت‌ها

مراجع

- [۱] اسلامی، ز.، نوروزی‌راد، م. و آرشی، م. (۱۳۹۹). برآوردگرهای تاوانیده در مدل رگرسیون کاکس. اندیشه آماری، ۱(۴۹)، ۵۳-۶۷.
- [۲] مالچی، ا.، حاجی‌زاده، ا. و احمدی، ک. (۱۳۹۱). مدل وایبل با اثرات شکنندگی در تحلیل بقای مبتلایان به سرطان کولورکتال. مجله علوم آماری، ۶(۱)، ۶۹-۸۲.
- [۳] حوتی، ف. و احمدی، ج. (۱۳۹۸). مدل شکنندگی نرخ خطر معکوس متناسب تعمیم‌یافته و استفاده از آن در تحلیل داده‌های مربوط به سرطان ریه. مجله علوم آماری، ۱۳(۲)، ۴۰۵-۴۲۵.
- [۴] مددی، م. و مترجم، ک. (۱۴۰۳). تحلیل داده‌های بقا با روش‌های مختلف یادگیری آماری. مجله علوم آماری، ۱۸(۲)، ۴۱۵-۴۳۴.
- [۵] گودرزی، ا.، سیاره، ع. و زمانی، ص. (۱۴۰۴). انتخاب متغیر در کوچک نواحی تحت مدل‌های AR-GARCH با الگوریتم تقویت گرادیان. مجله علوم آماری، ۱۹(۱)، ۱-۲۸.
- [6] Ahmed, S. S., Fountas, G., and Anastasopoulos, P. C. (2023). Analysis of urban travel time and travel distance: A fully parametric bivariate hazard-based duration modelling approach with correlated grouped random parameters. *Travel Behaviour and Society*, **31**, 271–283.
- [7] Gore, N., Arkatkar, S., and Joshi, G. (2023). A hazard-based model to derive travel time under congested conditions. *Transport Policy*, **138**, 1–16.
- [8] Foreman, K. J., Marquez, N., and Dolgert, A. (2018). Forecasting life expectancy, years of life lost, and all-cause and cause-specific mortality for 250 causes of death: reference and alternative scenarios for 2016–40 for 195 countries and territories. *The Lancet*, **392**(10159), 2052–2090.
- [9] Al Kaabi, A., Dissanayake, D., and Bird, R. (2012). Response time of highway traffic accidents in Abu Dhabi: Investigation with hazard-based duration models. *Transportation Research Record*, **2278**(1), 95–103.
- [10] Hill, P., Lederman, J., and Jonsson, D. (2025). Understanding EMS response times: a machine learning-based analysis. *BMC Medical Informatics and Decision Making*, **25**(1), 143.
- [11] Hojati, A. T., Ferreira, L., and Washington, S. (2013). Hazard based models for freeway traffic incident duration. *Accident Analysis and Prevention*, **52**, 171–181.
- [12] Hothorn, T., Bühlmann, P., and Dudoit, S. (2006). Survival ensembles. *Biostatistics*, **7**(3), 355–373.
- [13] Ishwaran, H., Kogalur, U. B., and Blackstone, E. H. (2008). Random survival forests. *The Annals of Applied Statistics*, **2**(3), 841–860.
- [14] Kim, E. J., Kang, M. J., and Park, S. H. (2025). Deep survival analysis model for incident clearance time prediction. *Journal of Intelligent Transportation Systems*, **29**(3), 305–318.
- [15] Lee, C., Zame, W., and Yoon, J. (2018). DeepHit: A deep learning approach to survival analysis with competing risks. *Proceedings of the AAAI Conference on Artificial Intelligence*, **32**(1).

- [16] Katzman, J. L., Shaham, U., and Cloninger, A. (2018). DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network. *BMC Medical Research Methodology*, **18**(1), 24.
- [17] Washington, S., Karlaftis, M. G., and Mannering, F. (2020). *Statistical and Econometric Methods for Transportation Data Analysis*. Chapman and Hall/CRC.
- [18] Li, P., Peng, Y., and Zheng, J. (2025). An empirical comparison between gradient boosting methods and cox's proportional hazards model for right-censored survival data. *Communications in Statistics-Simulation and Computation*, **54**(6), 2005–2019.
- [19] Razavizadeh, N. T., Salari, M., and Jafari, M. (2023). Comparison of Two Methods, Gradient Boosting and Extreme Gradient Boosting to Pre-dict Survival in Covid-19 Data. *Journal of Biostatistics and Epidemiology*, **9**(3), 378–387.
- [20] Natekin, A., and Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, **7**, 21.
- [21] Parvej, M., and Ali Khan, A. (2024). Bayesian extension of the Weibull AFT shared frailty model with generalized family of distributions for enhanced survival analysis using censored data. *Journal of Applied Statistics*, **51**(15), 3125–3153.
- [22] Wali, B., Khattak, A. J., and Liu, J. (2022). Heterogeneity assessment in incident duration modelling: Implications for development of practical strategies for small and large scale incidents. *Journal of Intelligent Transportation Systems*, **26**(5), 586–601.
- [23] Tang, J., Zheng, L., and Han, C. (2020). Statistical and machine-learning methods for clearance time prediction of road incidents: A methodology review. *Analytic Methods in Accident Research*, **27**, 100123.
- [24] Tang, J., Zheng, L., and Han, C. (2020). Statistical and Machine-learning Methods for Clearance Time Prediction of Road Incidents: A Methodology Review. *Analytic methods in accident research*, **27**, 100123.
- [25] Schonlau, M., and Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, **20**(1), 3–29.
- [26] Pickett, K. L., Suresh, K., and Campbell, K. R. (2021). Random survival forests for dynamic predictions of a time-to-event outcome using a longitudinal biomarker. *BMC Medical Research Methodology*, **21**(1), 216.
- [27] Bai, M., Zheng, Y., and Shen, Y. (2022). Gradient boosting survival tree with applications in credit scoring. *Journal of the Operational Research Society*, **73**(1), 39–55.
- [28] Caruana, R. (1997). Multitask learning. *Machine Learning*, **28**(1), 41–75.
- [29] Zhang, Y., and Yang, Q. (2021). A survey on multi-task learning. *IEEE Transactions on Knowledge and Data Engineering*, **34**(12), 5586–5609.
- [30] Hamad, K., Al-Ruzouq, R., and Zeiada, W. (2020). Predicting incident duration using random forests. *Transportmetrica A: Transport Science*, **16**(3), 1269–1293.

- [31] Lee, J. T., and Fazio, J. (2005). Influential factors in freeway crash response and clearance times by emergency management services in peak periods. *Traffic Injury Prevention*, **6**(4), 331–339.
- [32] Arcolezi, H. H., Cerna, S., and Guyeux, C. (2021). Preserving geo-indistinguishability of the emergency scene to predict ambulance response time. *Mathematical and Computational Applications*, **26**(3), 56.
- [33] Faraggi, D., and Simon, R. (1995). A neural network model for survival data. *Statistics in Medicine*, **14**(1), 73–82.
- [34] Sánchez-Mangas, R., García-Ferrer, A., and De Juan, A. (2010). The probability of death in road traffic accidents. How important is a quick medical response?. *Accident Analysis and Prevention*, **42**(4), 1048–1056.

پاییزه
فصلنامه
شماره

Deep neural network survival for emergency response time prediction

Mohammad Arashi^{1*}, Fateme Mohammadi¹,
Arezu Habibirad¹, Abolfazl Mohammadzadeh Moghadam²

¹ Department of Statistics, Faculty of Mathematical Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

² Department of Civil Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

Received: 2025/11/10

Accepted: 2026/06/22

Abstract

Emergency response time in traffic accidents is one of the key factors determining the quality of pre-hospital emergency medical services. Predicting this time and identifying the key factors affecting it enable decision-makers to improve the efficiency of emergency medical services, reduce response time, and ultimately save lives. The data related to emergency response time are considered as time-to-event data, whose main characteristic is their dependence on duration. To account for this property, baseline hazard models are commonly used; however, the performance of these models may be limited due to their underlying assumptions. In contrast, machine learning models provide an alternative approach for modeling emergency response time. Their main advantage lies in the ability to capture nonlinear and interactive relationships among variables without relying on restrictive assumptions of baseline hazard models. One of the most important machine learning methods in this context is artificial neural networks. In this study, a survival-based deep neural network model was employed to simultaneously estimate the survival function and predict emergency response time. By utilizing the concept of multi-task learning, this model can account for duration dependence while predicting response time through the concurrent estimation of the survival function. Using 28,505 traffic accident reports recorded by the Mashhad Emergency Medical Services, the performance of the proposed model was evaluated and compared with statistical models and other machine learning methods. The results indicate that the proposed model can serve as an efficient alternative to conventional methods for predicting emergency response time.

Keywords: Emergency Response Time, Deep Survival Analysis, Multi-Task Learning, Baseline Hazard Models, Survival Function

Mathematics Subject Classification: 62N01, 68T07.