

## طراحی و پیاده‌سازی یک سیستم هوشمند فازی جهت پیش‌بینی درصد موارد مرگ و میر بیماران تروما در بخش مراقبت‌های ویژه

میترا منتظری<sup>۱</sup>، مهدی احمدی‌نژاد<sup>۲</sup>، مهدیه منتظری<sup>۳\*</sup>، محدثه منتظری<sup>۴</sup>

• پذیرش مقاله: ۱۳۹۸/۹/۲۰

• دریافت مقاله: ۱۳۹۷/۸/۳۰

**مقدمه:** بخش ICU بیمارستان یکی از بخش‌های پر هزینه در بخش سلامت ملی می‌باشد. این هزینه‌ها تا حد زیادی به مدت اقامت بیمار وابسته است. لذا پیش‌بینی طول مدت اقامت بیماران و درصد موارد مرگ‌ومیر در بخش مراقبت‌های ویژه اهمیت زیادی دارد. لذا در این پژوهش به طراحی سیستم هوشمند مبتنی بر منطق فازی جهت پیش‌بینی درصد موارد مرگ‌ومیر بیماران تروما در بخش مراقبت‌های ویژه پرداخته شد.

**روش:** داده‌های مورد نیاز برای طراحی سیستم، از پرونده‌های بیماران از سال ۹۱ - ۱۳۸۹ گردآوری شد، سپس سیستم با استفاده از داده‌های گردآوری شده از هر پرونده اجرا شد و میزان همخوانی تشخیص سیستم با تشخیص نهایی ثبت شده در پرونده بیمار مقایسه گردید. مدل پیشنهادی نروفازی با ۵ مدل هوشمند دیگر مقایسه گردید. این مقایسه بر اساس حساسیت، دقت، ویژگی و سطح زیر منحنی راک محاسبه و ارزیابی گردید.

**نتایج:** میزان دقت این ۶ مدل حدوداً به ترتیب ۸۳٪ و ۸۱٪، ۸۰٪، ۷۵٪، ۸۲٪ و ۸۱٪ است.

**نتیجه‌گیری:** مدل نروفازی بهترین مدل ارزیابی شد و دارای بالاترین میزان دقت است. از نظر سطح زیر منحنی ROC مجدداً این مدل بیشترین سطح زیر منحنی را دارد؛ لذا به‌کارگیری مدل نروفازی در زمینه تشخیص و پیش‌بینی درصد موارد مرگ و میر بیماران تروما در بخش مراقبت‌های ویژه پیشنهاد می‌شود. این امر در تحقیقات مرتبط با حوزه سلامت و به خصوص در تخصیص منابع درمانی برای افرادی که پرمخاطره پیش‌بینی می‌شوند از اهمیت بالایی برخوردار است.

**کلید واژه‌ها:** بیماران تروما، بخش مراقبت‌های ویژه، دسته‌بندی، پیش‌بینی، مدل‌های هوشمند، ANFIS Naïve Bayes، SVM، AdaBoost، Random Forest، INN

**ارجاع:** منتظری میترا، احمدی‌نژاد مهدی، منتظری مهدیه، منتظری محدثه. طراحی و پیاده‌سازی یک سیستم هوشمند فازی جهت پیش‌بینی درصد موارد مرگ‌ومیر بیماران تروما در بخش مراقبت‌های ویژه. مجله انفورماتیک سلامت و زیست پزشکی ۱۳۹۹؛ ۱۷(۱): ۹-۱۰.

۱. کارشناسی ارشد هوش مصنوعی، مرکز تحقیقات انفورماتیک پزشکی، پژوهشکده آینده‌پژوهی در سلامت، دانشگاه علوم پزشکی کرمان، کرمان، ایران

۲. فلوشیپ مراقبت‌های ویژه، دانشیار، گروه بیهوشی، دانشگاه علوم پزشکی کرمان، کرمان، ایران

۳. دانشجوی دکتری انفورماتیک پزشکی، مرکز تحقیقات انفورماتیک پزشکی، پژوهشکده آینده‌پژوهی در سلامت، دانشگاه علوم پزشکی کرمان، کرمان، ایران

۴. دانشجوی دکتری نرم افزار کامپیوتر، مربی، بخش کامپیوتر، دانشکده حضرت فاطمه (س)، دانشگاه فنی و حرفه‌ای، کرمان، ایران

\* نویسنده مسئول: مهدیه منتظری

**آدرس:** کرمان، ابتدای جاده هفت باغ علوی، پردیس دانشگاه علوم پزشکی کرمان، پژوهشکده آینده‌پژوهی در سلامت، مرکز تحقیقات انفورماتیک پزشکی

• Email: MahdiehMontazeri@yahoo.com

• شماره تماس: ۰۳۴-۳۱۳۲۵۴۰۶

## مقدمه

بیشترین میزان مرگ‌ومیر در بیمارستان‌ها مربوط به بخش مراقبت‌های ویژه می‌باشد. در ایالات متحده آمریکا روزانه چهار میلیون بیمار در بخش مراقبت‌های ویژه پذیرش می‌شوند که متوسط میزان مرگ‌ومیر این افراد ۱۹٪-۸٪ یا حدود پانصد هزار مرگ در سال می‌باشد [۱-۳].

بخش مراقبت‌های ویژه بیمارستان یکی از بخش‌های پر هزینه در بخش سلامت ملی می‌باشد؛ که این بودجه در سال ۲۰۰۵ در ایالات متحده آمریکا حدود ۸۱/۷ میلیارد دلار بوده است. هزینه بخش مراقبت‌های ویژه حدود ۱۳/۷٪ هزینه‌های بیمارستان و ۴/۱٪ مصرف سلامت ملی و ۶۶٪ تولید ناخالص داخلی می‌باشد [۴].

این هزینه‌ها تا حد زیادی به مدت اقامت بیمار در بخش مراقبت‌های ویژه بر می‌گردد [۵،۶]. به همین دلیل منافع قابل توجهی در پیش‌بینی طول مدت اقامت بیمار و درصد موارد مرگ‌ومیر در بخش مراقبت‌های ویژه می‌باشد. متغیرهای قابل توجهی در میزان مرگ‌ومیر بیمار و طول اقامت آن‌ها در بخش مراقبت‌های ویژه وجود دارد که یکی از بهترین مراجع جهت این امر استفاده از سیستم آپاچی می‌باشد. متغیرهایی مانند سن، جنس، درجه حرارت، فشارخون، تعداد تنفس، سدیم، گلوکز، آلومین، پتاسیم، هماتوکریت، آلومین،  $PCO_2$ ،  $PCO_2$ ،  $PH$ ،  $Fio_2$  [۷].

در چند دهه اخیر، هوش مصنوعی با استفاده از ابزارهای سیستم‌های هوشمند در پزشکی جایگاه مؤثری پیدا کرده است [۲۰-۸]. سیستم‌های هوشمند به سیستم‌هایی اطلاق می‌شود که می‌توانند رفتارهایی مشابه رفتارهای هوشمند انسانی از جمله درک شرایط پیچیده، شبیه‌سازی فرآیندهای تفکری، شیوه‌های استدلالی انسان، پاسخ موفق به آن، یادگیری و توانایی کسب دانش و استدلال برای حل مسائل داشته باشند [۲۱-۲۳]. کاربرد، هوش مصنوعی در پزشکی با هدف اصلی پردازش و آنالیز اطلاعات پزشکی و ارتباطات بین این اطلاعات و استفاده‌کنندگان مربوطه است که این اطلاعات براساس دانش و تجربه حاصل از عملکرد سیستم‌های مختلف در پزشکی و درمان می‌باشد. یکی از کاربردهای مهم هوش مصنوعی در پزشکی، شناسایی و تشخیص بیماری‌ها است [۲۴-۲۷]. این کاربرد شامل مدل‌های تشخیصی با استفاده از روش‌های مختلف تصمیم‌گیری تخمینی و سیستم‌های هوشمند می‌باشد. این مدل‌ها براساس دانش و تجربیات مختلف از سیستم مورد نظر که پیشاپیش این اطلاعات به کامپیوتر داده

می‌شود و مدل یا سیستم مورد نظر با آن اطلاعات و یا مدل قبلی مقایسه و ارزیابی می‌گردد و در نتیجه تفاوت و یا تشخیص نوع تغییرات حاصل در مدل مورد مطالعه را نسبت به مدل طبیعی نشان می‌دهد. مواردی مثل شناسایی الگوهای مختلف در تصاویر پزشکی و غیرپزشکی [۳۱-۲۸]، تشخیص خودکار بیماری‌ها از روی سیگنال [۳۲]، دسته‌بندی و شناخت سلول‌های مختلف خونی توسط کامپیوتر و میزان مرگ‌ومیر از انواع دیگر این گروه هستند.

با پیروی و اتخاذ روش‌های مطلوب مکانیزه برای جمع‌آوری داده‌ها، حتی قبل از ورود بیماران به بخش‌های بیمارستان‌ها، می‌توان مدت توقف بهینه آن‌ها را مشخص کرد. از هنگام ورود بیماران به بخش‌های مختلف بیمارستان تا زمان خروج آن‌ها درصد قابل توجهی از بودجه و زمان، صرف ثبت، پردازش و ذخیره اطلاعات پزشکی در سیستم‌های دستی رایج می‌شود. در حالی که با ایجاد یک سیستم هوشمند بیمارستانی جامع نه تنها هزینه پردازش و ذخیره اطلاعات به حداقل ممکن می‌رسد، بلکه امکان دسترسی سریع به سوابق بیماری نیز فراهم می‌شود.

کلیه منابعی که به نحوی اشاره به این نوآوری دارد را می‌توان به چهار دسته تقسیم کرد: دسته اول: روش‌های ریاضی، دسته دوم: آماری، دسته سوم: استخراج داده، دسته چهارم: چند مرحله‌ای. در دسته اول از روش‌های ریاضی برای محاسبه مدت‌زمان اقامت بیمار در ICU (Intensive Care Unit) استفاده می‌کنند [۳۳]. روش‌های ریاضی متداول معمولاً به صورت میانگین یا میانه محاسبه می‌گردد [۳۴]؛ اما این روش بسیار ساده و مبتدی برای محاسبه مدت‌زمان اقامت در ICU می‌باشد. به طوری که Garg و همکاران در مطالعه خود [۳۵] ثابت کردند که چگونه این روش‌ها گمراه‌کننده می‌باشند. دسته دوم شامل روش‌های آماری مانند لجستیک رگرسیون، رگرسیون خطی، کوواریانس می‌باشند [۳۶] Freitas و همکاران در مطالعه‌ای [۳۷] از مدل رگرسیون برای آنالیز ارتباط چند متغیر تعیین کننده مدت‌زمان اقامت استفاده نمودند. نتایج نشان داد سن، نوع پذیرش و نوع بیمارستان ارتباط مؤثری با مدت‌زمان اقامت بیمار دارند. روش‌های نمره‌دهی نیز جزء این روش می‌باشند. به عنوان مثال APACHE یک سیستم نمره‌دهی است که در سال ۱۹۸۱ مطرح گردید و در سال ۱۹۸۵ نسخه ویرایش یافته آن تحت عنوان APACHE II [۳۸] به وجود آمد. در کنار این روش نمره‌دهی SAPS نیز مطرح گردید که در سال ۱۹۹۳ Le Gall و همکاران [۳۹] از رگرسیون لجستیک برای توسعه SAPS II استفاده نمود.

- عدم وجود سیستم هوشمند فازی به عنوان همکار پزشک در تشخیص درصد موارد مرگومیر بیماران تروما در بخش مراقبت‌های ویژه در کشور.
  - طراحی سیستم مبتنی بر قوانین که فهم آسان، انعطاف‌پذیر بالا، تحمل اطلاعات غیردقیق و قابلیت مدل سازی اعمال پیچیده اختیاری غیرخطی را میسر می‌سازد. این روش با تکنیک‌های کنترلی شرطی مخلوط می‌شود و بر اساس زبان ساده محاوره‌ای بنا شده است.
- بنابراین، هدف این پژوهش به طراحی سیستم هوشمند مبتنی بر منطق فازی جهت پیش‌بینی درصد موارد مرگومیر بیماران تروما در بخش مراقبت‌های ویژه بود. تاکنون، سیستم‌های هوشمند متعددی برای کمک به تشخیص بیماری‌ها توسعه یافته است؛ اما مطالعاتی جهت پیش‌بینی طول مدت بستری و درصد موارد مرگومیر بیماران تروما در بخش مراقبت‌های ویژه با منطق فازی گزارش نشده است.

### روش

این مطالعه یک مطالعه مقطعی است که بر روی بیماران مراجعه کننده به بخش مراقبت‌های ویژه بیمارستان شهید باهنر انجام شد. منابع دانش برگزیده شده برای ایجاد سیستم پیش‌بینی درصد موارد مرگومیر بیماران تروما در بخش مراقبت‌های ویژه در این پژوهش شامل مقالات تخصصی مرتبط با طول مدت بستری بیماران تروما در بخش مراقبت‌های ویژه و نیز پزشکان متخصص و خبره در این خصوص است. ابتدا پس از مشاوره هدفمند با افراد خبره، پارامترهای مؤثر در پیش‌بینی درصد مرگومیر بیماران تروما بستری در بخش مراقبت‌های ویژه و ارتباطات میان پارامترهای کلینیکی در خصوص تصمیم‌گیری در این موضوع و همچنین درجه ارتباط آن‌ها تعیین شدند. در نهایت نرم‌افزاری جهت ورود اطلاعات و پیش‌بینی درصد مرگومیر بیماران طراحی و پیاده‌سازی گردید (شکل ۱). از نرم‌افزار طراحی شده جهت این منظور برای گردآوری داده‌های مورد نیاز جهت ثبت اطلاعات بیماران تروما بستری در بخش مراقبت‌های ویژه، استفاده شد. نرم‌افزار بر اساس بررسی متون تخصصی و نظر دو پزشک متخصص و خبره که در بیمارستان باهنر شاغل و عضو هیئت علمی دانشگاه علوم پزشکی کرمان هستند، طراحی شد و شامل اطلاعات دموگرافیک بیمار، نشانه‌های جسمی و یافته‌های پاراکلینیکی بود. اطلاعات دموگرافیک بیمار شامل سن و

روش دسته سوم [۳۹-۴۲] به منظور پیش‌بینی مدت زمان اقامت و میزان مرگومیر براساس تکنیک‌های داده‌کاوی مانند دسته‌بندی [۴۳،۴۴]، خوشه‌بندی و غیره می‌باشند. این تکنیک‌ها با در نظر رفتن روابط بین متغیرها به دنبال الگوی مناسبی در پایگاه داده‌های بسیار بزرگ می‌باشند. در تعدادی از مطالعات [۴۵،۴۶] از روش شبکه‌های عصبی و رگرسیون لجستیک به منظور پیش‌بینی مرگومیر در ICU استفاده شده است. در مطالعه‌ای Ribas ثابت کرد روش SVM (Support Vector Machine) عملکرد بهتری نسبت APACHE II دارد در همین زمان در مطالعه انجام شده توسط Kim و همکاران [۴۷] ثابت شده است، ANN، SVM و DT عملکرد بهتری نسبت به سیستم نمره‌دهی APACHE III بر روی بیماران ICU دارند. در تعدادی از مطالعات [۴۸،۴۹] عملکرد شبکه عصبی نسبت به رگرسیون لجستیک نشان داده شده است. در مطالعات دیگر [۴۷،۵۲-۵۰] عملکرد بهتر شبکه عصبی و SVM را ثابت کرده است. McCoy و Das [۵۳] برای پیش‌بینی طول مدت اقامت و میزان مرگومیر از روش‌های ماشین یادگیری استفاده نموده است.

دسته چهارم از چند حالت و یک روال تصادفی برای گذار بین حالات استفاده می‌کند [۵۴]. روش Coxian روشی است که در این دسته قرار می‌گیرد. در این روش نمایشی از مدت زمان پیوسته از اقامت بیمار در بیمارستان به عنوان یک سری از مراحل ترتیبی که بیمار تا زمانی که بیمارستان را ترک می‌کند، بیان می‌کند [۵۵]. Golüke و همکاران [۵۶] از توزیع چندمرحله‌ای شرطی برای مدل مدت‌زمان اقامت بیماران استفاده نموده است. در مطالعه Wang و همکاران [۵۷] از روش Time Slicing Cox regression که فرم توسعه‌یافته Cox regression می‌باشد برای پیش‌بینی مرگومیر در ICU استفاده نموده است.

طراحی و پیاده‌سازی یک سیستم هوشمند فازی جهت پیش‌بینی درصد موارد مرگومیر بیماران تروما در بخش مراقبت‌های ویژه می‌تواند توسط سیستم‌های فازی و سیستم‌ها مبتنی بر دانش یا مبتنی بر قواعد باشد [۵۸]. قلب یک سیستم فازی، یک پایگاه دانش بوده که از قواعد اگر-آنگاه فازی تشکیل شده است. یک قاعده اگر-آنگاه فازی یک عبارت اگر-آنگاه بوده که بعضی کلمات آن به وسیله توابع تعلق پیوسته مشخص شده‌اند. از جمله دلایلی که ضرورت طراحی چنین سیستمی را مشخص می‌کنند می‌توان به این موارد اشاره کرد:

جنسیت بیمار بود. هم‌زمان با آن نرم‌افزار نیز جهت گردآوری داده‌ها برای مرحله طراحی و ارزیابی سیستم هوشمند فازی، تهیه گردید. پس از آماده شدن نسخه اولیه محصول آموزشی دو نفر از اساتید دانشگاه پس از ملاحظه نمودن این نسخه نظرات خود را اعلام نمودند و محصول آموزشی طبق نظرات ایشان ارتقاء یافت. روایی و کارآمد بودن نرم‌افزار مورد تأیید پزشکان متخصص قرار گرفت. سپس اطلاعات حدود ۵۰۰ بیمار در نرم‌افزار ثبت گردید.

داده‌ها توسط کارشناس و به وسیله نرم‌افزار وارد سیستم شد و پیش‌پردازش‌های لازم صورت گرفت و جهت تجزیه و تحلیل نتایج با استفاده از مدل نروفازی (ANFIS) و از نرم‌افزار Matlab نسخه ۲۰۱۰ استفاده شد. این پایگاه داده دارای ۱۹ متغیر تشخیص بیماری می‌باشد که در جدول ۱ نشان داده شد. در این پژوهش منحصراً از اطلاعات بالینی ثبت شده در پرونده پزشکی بیماران استفاده شد و نیازی به استفاده از داده‌های هویتی بیماران نبود، لذا هویت بیماران در زمان بررسی پرونده‌ها محفوظ و محرمانه بود.

در این مطالعه، به دلیل وجود بخش مراقبت‌های ویژه ترومای دانشگاه علوم پزشکی کرمان در بیمارستان باهنر و فراوانی تعداد پرونده‌های پزشکی بیماران موجود در بخش مدارک پزشکی آن، جامعه پژوهش شامل پرونده‌های بیمارانی تعیین گردید که در سال‌های ۱۳۸۹ تا ۱۳۹۱ در بخش مراقبت‌های ویژه بیمارستان باهنر بستری بوده‌اند. تعداد این پرونده‌ها حدود ۵۰۰ مورد بود. به دلیل محدود بودن تعداد نمونه جامعه، نمونه‌گیری انجام نشد. داده‌های مورد نیاز برای طراحی سیستم، از پرونده‌های بیماران جامعه پژوهش گردآوری شد. سیستم با استفاده از داده‌های گردآوری شده از هر پرونده اجرا شد و نتیجه تشخیص سیستم ثبت و با تشخیص نهایی ثبت شده در پرونده بیمار مقایسه گردید. حساسیت، ویژگی، دقت و سطح زیر منحنی راک سیستم محاسبه و ارزیابی گردید. در مراحل طراحی و توسعه سیستم، جهت کسب دانش پزشکی و شناسایی پارامترهای مهم و تأثیرگذار مربوط به تشخیص موارد مهم در پیش‌بینی درصد موارد مرگ و میر با دو پزشک متخصص بیهوشی با فلوشیپ مراقبت‌های ویژه مصاحبه شد و

Design by: Mitra Montazeri, mmontazeri@eng.uk.ac.ir

شکل ۱: نمای نرم‌افزار بخش ICU

جدول ۱: متغیرهای تشخیص در میزان مرگومیر بیماران در بخش مراقبت‌های ویژه

شماره ردیف	نوع متغیر تشخیص بیماری	نوع ریسک فاکتور
۱	Age	Input
۲	Sex	Input
۳	From Ward	Input
۴	Time of Stay	Input
۵	Urgent Surgery	Input
۶	M. Ventilator	Input
۷	History of Hospitalization	Input
۸	T-°C	Input
۹	MAP	Input
۱۰	HR	Input
۱۱	Art-PH	Input
۱۲	Na	Input
۱۳	K	Input
۱۴	Ser/Cr	Input
۱۵	HCT	Input
۱۶	WBC	Input
۱۷	GCS	Input
۱۸	RR	Input
۱۹	D.C	Output

### تنظیمات مدل‌های پیشنهادی

با توجه به این که در هر دسته‌بندی، به تعداد نمونه‌هایی که به کلاس مثبت و منفی تعلق دارند به ترتیب با P و N نمایش می‌دهند می‌توان تعریف زیر را بیان کرد:  
 N نمایش می‌دهند می‌توان تعریف زیر را بیان کرد:  
 FP= به نمونه‌هایی که به گروه منفی تعلق دارند و اشتباهاً توسط طبقه‌بندی کننده به عنوان مثبت طبقه‌بندی شده‌اند.

TP= به نمونه‌هایی که به گروه مثبت تعلق دارند و درست پیش‌بینی شدند.  
 TN= به نمونه‌هایی که به گروه منفی تعلق دارند و درست پیش‌بینی شدند.  
 FN= به نمونه‌هایی که به گروه مثبت تعلق دارند و اشتباهاً توسط طبقه‌بندی کننده به عنوان منفی طبقه‌بندی شده‌اند.

در نتیجه روابط ۱ تا ۳ بیان می‌شود:

$$\text{نرخ درست مثبت} = \frac{TP}{P} \quad (۱)$$

$$\text{نرخ خطای مثبت} = \frac{FP}{N} \quad (۲)$$

$$\text{دقت دسته‌بندی} = \frac{TP+TN}{P+N} \quad (۳)$$

### • تخمین دقت

برای تخمین دقت الگوریتم شش مدل، از اعتبارسنجی ضربدری استفاده شد. اعتبارسنجی ضربدری که گاهی تخمین گردشی نیز نامیده می‌شود، یک روش ارزیابی است که مشخص می‌کند نتایج یک تحلیل آماری بر روی یک مجموعه داده تا چه اندازه قابل تعمیم و مستقل از داده‌های آموزشی است. این تکنیک به طور ویژه در کاربردهای پیش‌بینی مورد استفاده قرار می‌گیرد تا مشخص شود مدل مورد نظر تا چه اندازه در

عمل مفید خواهد بود. به‌طور کلی یک دور از اعتبارسنجی ضربدری شامل افراز داده‌ها به دو زیرمجموعه مکمل، انجام تحلیل بر روی یکی از آن زیرمجموعه‌ها (داده‌های آموزشی) و اعتبارسنجی تحلیل با استفاده از داده‌های مجموعه دیگر است (داده‌های اعتبارسنجی یا آزمایشی). برای کاهش پراکندگی، عمل اعتبارسنجی چندین بار با افرازهای مختلف انجام و از نتایج اعتبارسنجی‌ها میانگین گرفته می‌شود.

نرمالیزه اقلیدسی برای یافتن نمونه آموزشی نزدیک به نمونه آزمون معین استفاده می‌کند و همان کلاس آموزشی را با این نمونه آموزش پیش‌بینی می‌کند. اگر چند نمونه فاصله یکسان با نمونه آزمایش دارند، از نمونه اول استفاده می‌شود. در مدل SVM پارامتر پیچیدگی روی ۱ قرار دارد و  $\epsilon$  برای خطای دور (نباید تغییر یابد) روی  $1E-12$  تنظیم شده است. تابع هسته در این مطالعه، هسته چند جمله‌ای [۵۱] استفاده شده است. پارامتر تحمل (نباید تغییر کند) روی  $0/001$  تنظیم شده است.

پنج مدل ماشین یادگیری اجرا شده‌اند و نتایج حاصل از اجرای این ۵ مدل در جدول ۲ خلاصه شد. این ۶ مدل از نظر ویژگی، حساسیت، سطح زیر منحنی راک و دقت دسته‌بندی مقایسه شدند و در هر بررسی بهترین مقدار برجسته شده است که از نظر دقت دسته‌بندی مدل ماشین نرو فازی (ANFIS) دارای بالاترین دقت است.

همان‌طور که در این جدول دیده شد، مدل ANFIS نسبت به ۵ مدل ماشین یادگیری سطح زیر منحنی راک بیشتری دارند. در نمودار راک مقادیر ۰ تا  $0/5$  بیانگر دسته‌بندی تصادفی و  $0/5$  تا ۱ بیانگر توانمندی تشخیصی کلی مدل است. موفقیت در دستیابی به اهداف بالا را می‌توان در موارد زیر خلاصه نمود:

**اهداف کوتاه‌مدت:** در این هدف سیستم آموزشی همکار کادر دانشگاه‌های علوم پزشکی کرمان اعم از هیئت‌علمی و کارکنان بخش ICU در سطح بیمارستان باهنر راه‌اندازی گردید و مخاطبان این سیستم پزشکان و پرستاران بخش ICU بیمارستان باهنر دانشگاه علوم پزشکی کرمان می‌باشند.

**اهداف بلندمدت:** این سیستم به صورت متمرکز در سطح کل بیمارستان‌های کشور نصب و راه‌اندازی گردد تا تمامی کادر دانشگاه‌های علوم پزشکی کشور (افراد) که به نوعی با این سیستم در ارتباط می‌باشند با آن در ارتباط و از خروجی آن جهت آموزش استفاده نمایند. همچنین مشابه این سیستم می‌توان برای بخش‌های دیگر بیمارستان‌ها استفاده نمود.

هنگامی که جمع‌آوری داده‌های بیشتر سخت، پرهزینه و یا غیرممکن باشد، استفاده از اعتبارسنجی ضربدری کمک می‌کند تا از فرضیات بایاس شده با داده‌های فعلی که قابل‌تعمیم نیستند، دوری شود. در روش پیشنهادی از اعتبارسنجی ضربدری از نوع  $k$ - لایه و نوع یکی-بیرون استفاده شد. در روش  $k$  - لایه داده‌ها به  $k$  زیرمجموعه افراز می‌شوند. از این  $k$  زیرمجموعه، هر بار یکی برای اعتبارسنجی و  $k-1$  تای دیگر برای آموزش به کار می‌روند. این روال  $k$  بار تکرار می‌شود و همه داده‌ها دقیقاً  $k$  بار برای آموزش و یک بار برای اعتبارسنجی به کار می‌روند. در نهایت میانگین نتیجه این  $k$  بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود. البته می‌توان از روش‌های دیگر برای ترکیب نتایج استفاده کرد. به‌طورمعمول از اعتبارسنجی ضربدری  $10$ -لایه استفاده می‌شود.

در روش یکی-بیرون همان‌طور که از اسم این روش پیداست در هر مرحله یکی از داده‌ها برای اعتبارسنجی بیرون گذاشته می‌شود و بقیه داده‌ها برای آموزش استفاده می‌شوند. این روش در واقع همان روش  $k$ - لایه است که در آن  $k$  برابر تعداد داده‌ها در نظر گرفته شده است. این روش از نظر محاسباتی بسیار پرهزینه است؛ زیرا فرآیند آموزش و اعتبارسنجی به تعداد بسیار زیادی تکرار می‌شود.

### عملکرد مدل‌های پیشنهادی

در این پژوهش مدل نروفازی با ۵ مدل ماشین یادگیری INN, Trees Random Forest, Naïve Bayes, SVM, AdaBoost در مدل دسته‌بندی Random Forest تعداد درختان به کاربرده شده و حداکثر عمق به ترتیب ۱۰ و ۰ است و در مدل AdaBoost دسته‌بند پایه Decision Stump (۵۳) می‌باشد. آستانه وزن برای هرس وزن و تعداد مراحل اجرا ۱۰۰ و ۱۰ تعیین شد. در طبقه‌بندی دیگر Naïve Bayes از دقت عددی پیش‌فرض  $0/1$  برای ویژگی‌های عددی در هنگام ساخت طبقه‌بندی با نمونه‌های آموزش صفر استفاده شد. مدل INN از فاصله

جدول ۲: نتایج حاصل از عملکرد ۶ مدل SVM، AdaBoost، 1NN Trees Random Forest، ANFIS، Naïve Bayes

ردیف	مدل هوشمند	دقت دسته‌بندی	حساسیت	ویژگی	میانگین ویژگی - حساسیت	سطح زیر منحنی راک
۱	ANFIS	۸۳/۶۷۳۵	۰/۹۷۴۴	۰/۳۰۰	۰/۸۳۷۹	۱
۲	Naïve Bayes	۸۱/۳۶۲۷	۰/۹۰۷	۰/۴۴۶	۰/۸۱۴	۰/۷۹۷۵
۳	SVM	۸۰/۱۶۰۳	۰/۹۱۵	۰/۳۵۶	۰/۸۰۲	۰/۶۳۶
۴	1NN	۷۵/۵۵۱۱	۰/۸۶۹	۰/۳۰۷	۰/۷۵۶	۰/۵۸۸
۵	AdaBoost	۸۲/۱۶۴۳	۰/۹۶	۰/۲۷۷	۰/۸۲۲	۰/۷۴۷

### بحث و نتیجه‌گیری

بیشترین میزان مرگ‌ومیر در بیمارستان‌ها مربوط به بخش مراقبت‌های ویژه می‌باشد. بخش مراقبت‌های ویژه بیمارستان یکی از بخش‌های پرهزینه در بخش سلامت ملی می‌باشد. این هزینه‌ها تا حد زیادی به مدت اقامت بیمار در بخش مراقبت‌های ویژه بر می‌گردد. به همین دلیل منافع قابل توجهی در پیش‌بینی درصد موارد مرگ‌ومیر در بخش مراقبت‌های ویژه می‌باشد. ابزارهای طبقه‌بندی اتوماتیک به عنوان یک ابزار کمک تشخیص باعث کاهش بار کاری پزشکان می‌گردد. این پژوهش به طراحی و پیاده‌سازی یک سیستم هوشمند نروفازی جهت پیش‌بینی درصد موارد مرگ‌ومیر بیماران تروما در بخش مراقبت‌های ویژه می‌پردازد. دسته‌بندی که بدین منظور در این پژوهش مورد استفاده قرار گرفته است شامل دسته‌بندی‌های ANFIS، Naïve Bayes، SVM، 1NN، Trees Random Forest می‌باشد. این الگوریتم‌ها بر اساس معیارهای حساسیت، دقت و ویژگی ارزیابی شدند که مدل ANFIS بهترین مدل ارزیابی شد و دارای بالاترین میزان دقت است. از نظر سطح زیر منحنی راک مدل ANFIS بیشترین سطح زیر منحنی دارند؛ لذا به‌کارگیری مدل ANFIS در زمینه پیش‌بینی درصد موارد مرگ‌ومیر بیماران تروما در بخش مراقبت‌های ویژه پیشنهاد می‌شود. این امر در تحقیقات مرتبط با حوزه سلامت و به خصوص در تخصیص منابع

درمانی برای افرادی که پرمخاطره پیش‌بینی می‌شوند از اهمیت بالایی برخوردار است. در طول ارزیابی، سیستم خبره نورو فازی عملکردهای قابل توجهی زیر را دارد:

- یک رویکرد هوشمند ساده
- آسان برای درک و اجرای
- سهولت اجرای
- کاربرپسند و عملکرد کارآمدتری ارائه می‌دهد
- توانایی نمایانگر عدم قطعیت‌های ذاتی دانش بشر با متغیرهای زبانی
- تعامل ساده متخصص دامنه با طراح مهندس سیستم
- تفسیر آسان نتایج، به دلیل نمایش قوانین طبیعی
- گسترش آسان پایه دانش از طریق اضافه کردن قوانین جدید
- استحکام در رابطه با اختلالات احتمالی در سیستم
- یادگیری سریع، سازگاری بر روی خط، خودتنظیم با هدف دستیابی به خطای کوچک جهانی ممکن، پیچیدگی محاسباتی کوچک.

### تعارض منافع

بدین‌وسیله نویسندگان تصریح می‌نمایند که هیچ‌گونه تضاد منافی در خصوص پژوهش حاضر وجود ندارد.

### References

1. Angus DC, Linde-Zwirble WT, Sirio CA, Rotondi AJ, Chelluri L, Newbold RC, et al. The effect of managed care on ICU length of stay: implications for medicare. *JAMA* 1996;276(13):1075-82.
2. Wu AW, Pronovost P, Morlock L. ICU incident reporting systems. *J Crit Care* 2002;17(2):86-94. doi: 10.1053/jcrc.2002.35100.

3. Young MP, Birkmeyer JD. Potential reduction in mortality rates using an intensivist model to manage intensive care units. *Eff Clin Pract* 2000;3(6):284-9.
4. Halpern NA, Pastores SM. Critical care medicine in the United States 2000–2005: an analysis of bed numbers, occupancy rates, payer mix, and costs. *Crit Care Med* 2010;38(1):65-71. doi: 10.1097/CCM.0b013e3181b090d0.

5. Rapoport J, Teres D, Lemeshow S, Avrunin JS, Haber R. Explaining variability of cost using a severity-of-illness measure for ICU patients. *Medical care* 1990;338-48.
6. Rapoport J, Teres D, Lemeshow S, Gehlbach S. A method for assessing the clinical performance and cost-effectiveness of intensive care units: a multicenter inception cohort study. *Crit Care Med* 1994;22(9):1385-91. doi: 10.1097/00003246-199409000-00006.
7. Rapoport J, Teres D, Zhao Y, Lemeshow S. Length of stay data as a guide to hospital economic performance for ICU patients. *Medical Care* 2003;386-97.
8. Abbasi R, Montazeri M, Zare M. A rule based classification model to predict colon cancer survival. In 1th Afzalipour International Medical congress on Pathology; 2015 Nov 25; Kerman: Afzalipour Hospital; 2015. p. 19-20.
9. Afzali F, Heidari Z, Montazeri M, Ahmadian L, Zahedi MJ. Futures studies in health: choosing the best intelligent data mining model to predict and diagnose liver Cancer in early stage. *Journal of Health and Biomedical Informatics* 2015;2(3):133-40. [In Persian]
10. Madadzadeh F, Ezati Asar M, Bahrapour A, Montazeri M. Liver Disease Recognition: A Discrete Hidden Markov Model Approach. 3rd International Conference on Science and Engineering; 2016 Jun 2; Istanbul, Turkey: Vira Institution; 2016.
11. Madadzadeh F, Bahrapour A, Mousavi SM, Montazeri M. Using Advanced Statistical Models to Predict the Non-Communicable Diseases. *Iran J Public Health* 2015;44(12):1714-5.
12. Madadzadeh F, Montazeri M, Bahrapour A. Predicting the survival in breast cancer using Hidden Markov Model. 10th International Breast Cancer Congress; 2015 Feb 25-27; Tehran: Shahid Beheshti University of Medical Sciences; 2015. [In Persian]
13. Madadzadeh F, Montazeri M, Bahrapour A. Predicting of liver disease using Hidden Markov Model. *Razi Journal of Medical Sciences* 2016;23(146):66-74. [In Persian]
14. Montazeri M, Bahrololoum A, Nezamabadi-pour H, Baghshah MS, Montazeri M. Cooperating of local searches based hyperheuristic approach for solving traveling salesman problem. *International Conference on Evolutionary Computation Theory and Applications*; 2011 Oct 24; Science and Technology Publications; 2011. p. 329-32. doi: 10.5220/0003675103290332
15. Montazeri M. HHFS: Hyper-heuristic feature selection. *Intelligent Data Analysis* 2016; 20(4): 953-74. doi: 10.3233/IDA-160840
16. Montazeri M. Intensity adjustment and noise removal for medical image enhancement. *Journal of Health and Biomedical Informatics* 2016;3(1):38-47. [In Persian]
17. Montazeri M, Montazeri M. Machine learning models for predicting the diagnosis of liver disease. *Koomesh* 2014;16(1):53-9. [In Persian]
18. Montazeri M, Montazeri M, Beygzadeh A, Zahedi MJ. Identifying efficient clinical parameters in diagnose of liver disease. *Health MED* 2014;8(10):1115.
19. Montazeri M, Montazeri M, Montazeri M, editors. *Future studies in health care: a new approach in intelligent diagnosis of liver disease by selecting the best decision tree model*. Second National Conference on the Future Study; 2014 Feb 19; Tehran: Yadegar Company; 2014.
20. Montazeri M, Montazeri M, Montazeri M, Beigzadeh A. Machine learning models in breast cancer survival prediction. *Technol Health Care* 2016;24(1):31-42. doi: 10.3233/THC-151071.
21. McLeod R, Schell GP. *Management Information Systems*. USA: Pearson/Prentice Hall; 2007.
22. Zwass V. *Management Information Systems*: William C Brown Pub; 1992.
23. Turban E, Rainer RK, Potter RE. *Introduction to Information Technology*. Vietnam: John Wiley & Sons.; 2005 .
24. Nguyen TP, Ho TB. Detecting disease genes based on semi-supervised learning and protein-protein interaction networks. *Artif Intell Med* 2012;54(1):63-71. doi: 10.1016/j.artmed.2011.09.003.
25. Heckerling PS, Gerber BS, Tape TG, Wigton RS. Use of genetic algorithms for neural networks to predict community-acquired pneumonia. *Artificial Intelligence in Medicine* 2004;30(1):71-84. doi.org/10.1016/S0933-3657(03)00065-4
26. Montazeri M, Baghshah MS, Enhesari A. Hyper-Heuristic algorithm for finding efficient features in diagnose of lung cancer disease. *J Basic Appl Sci Res* 2013;3(10): 134-40.
27. Ehtemam H, Montazeri M, Khajouei R, Hosseini R, Nemati A, Maazed V. Prognosis and Early Diagnosis of Ductal and Lobular Type in Breast Cancer Patient Iran J Public Health 2017;46(11):1563-71.
28. Jiang J, Trundle P, Ren J. Medical image analysis with artificial neural networks. *Comput Med Imaging Graph* 2010;34(8):617-31. doi: 10.1016/j.compmedimag.2010.07.003.
29. Montazeri M, Montazeri M, Saryazdi S. Eye detection in digital images: challenges and solutions. 2nd National Conference of Electrical Engineering; 2016 Jan 19; Esfahan: Islamic Azad University of Khomeini Shahr; 2016.
30. Montazeri M, Nezamabadi-pour H. Automatic extraction of eye field from a gray intensity image using intensity filtering and hybrid projection function. In 2011 International Conference on Communications, Computing and Control Applications (CCCA); 2011 Mar 3-5; Hammamet, Tunisia: IEEE; 2011. p. 1-5. doi: 10.1109/CCCA.2011.6031433
31. Montazeri M, Nezamabadi-pour H, Montazeri M. Automatically eye detection with different gray intensity image conditions. *Computer Technology and Application* 2012;3(8).
32. Übeyli ED, Güler İ. Improving medical diagnostic accuracy of ultrasound Doppler signals by combining

- neural network models. *Computers in Biology and Medicine*. 2005;35(6):533-54. doi.org/10.1016/j.combiomed.2004.03.006
33. Cheng TH, Hu PJ. A data-driven approach to manage the length of stay for appendectomy patients. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*. 2009;39(6):1339-47. doi: 10.1109/TSMCA.2009.2025510
34. Awad A, Bader-El-Den M, McNicholas J. Patient length of stay and mortality prediction: A survey. *Health Serv Manage Res* 2017;30(2):105-20. doi: 10.1177/0951484817696212
35. Garg L, McCLEAN S, Meenan BJ, Millard P. Phase-type survival trees and mixed distribution survival trees for clustering patients' hospital length of stay. *Informatica* 2011;22(1):57-72.
36. Guzman Castillo M. Modelling patient length of stay in public hospitals in Mexico: University of Southampton; 2012.
37. Freitas A, Silva-Costa T, Lopes F, Garcia-Lema I, Teixeira-Pinto A, Brazdil P, et al. Factors influencing hospital high length of stay outliers. *BMC Health Serv Res* 2012;12:265. doi: 10.1186/1472-6963-12-265.
38. Knaus WA, Draper EA, Wagner DP, Zimmerman JE. APACHE II: a severity of disease classification system. *Critical care medicine*. 1985;13(10):818-29.
39. Le Gall J-R, Lemeshow S, Saulnier F. A new simplified acute physiology score (SAPS II) based on a European/North American multicenter study. *JAMA* 1993;270(24):2957-63.
40. Kim WO, Kil HK, Kang JW, Park HH. Prediction on Lengths of Stay in the Postanesthesia Care Unit Following General Anesthesia: Preliminary Study of the Neural. *J Korean Med Sci* 2000;15:25-30.
41. Pofahl WE, Walczak SM, Rhone E, Izenberg SD. Use of an artificial neural network to predict length of stay in acute pancreatitis. *The American Surgeon* 1998;64(9):868.
42. Azari A, Janeja VP, Mohseni A. Predicting hospital length of stay (PHLOS): A multi-tiered data mining approach. 12th International Conference on Data Mining Workshops; 2012 Dec 10; Brussels, Belgium: IEEE; 2012. doi: 10.1109/ICDMW.2012.69
43. Meadows K, Gibbens R, Gerrard C, Vuylsteke A. Prediction of patient length of stay on the intensive care unit following cardiac surgery: a logistic regression analysis based on the cardiac operative mortality risk calculator, EuroSCORE. *J Cardiothorac Vasc Anesth* 2018;32(6):2676-82. doi: 10.1053/j.jvca.2018.03.007.
44. Xie J, Su B, Li C, Lin K, Li H, Hu Y, et al. A review of modeling methods for predicting in-hospital mortality of patients in intensive care unit. *J Emerg Crit Care Med* 2017;1(8): 1-10. doi: 10.21037/jeccm.2017.08.03
45. Silva Á, Cortez P, Santos MF, Gomes L, Neves J. Mortality assessment in intensive care units via adverse events using artificial neural networks. *Artif Intell Med* 2006;36(3):223-34. doi: 10.1016/j.artmed.2005.07.006.
46. Silva Á, Cortez P, Santos MF, Gomes L, Neves J. Rating organ failure via adverse events using data mining in the intensive care unit. *Artif Intell Med* 2008;43(3):179-93. doi: 10.1016/j.artmed.2008.03.010.
47. Kim S, Kim W, Park RW. A comparison of intensive care unit mortality prediction models through the use of data mining techniques. *Healthc Inform Res* 2011; 17(4): 232-43. doi: 10.4258/hir.2011.17.4.232
48. Dybowski R, Gant V, Weller P, Chang R. Prediction of outcome in critically ill patients using artificial neural network synthesised by genetic algorithm. *Lancet* 1996;347(9009):1146-50. doi: 10.1016/S0140-6736(96)90609-1.
49. Clermont G, Angus DC, DiRusso SM, Griffin M, Linde-Zwirble WT. Predicting hospital mortality for patients in the intensive care unit: a comparison of artificial neural networks with logistic regression models. *Crit Care Med*. 2001;29(2):291-6. doi: 10.1097/00003246-200102000-00012.
50. Ribas VJ, López JC, Ruiz-Sanmartín A, Ruiz-Rodríguez JC, Rello J, Wojdel A, et al. Severe sepsis mortality prediction with relevance vector machines. *Conf Proc IEEE Eng Med Biol Soc* 2011;2011:100-3. doi: 10.1109/IEMBS.2011.6089906.
51. Citi L, Barbieri R. PhysioNet 2012 Challenge: Predicting mortality of ICU patients using a cascaded SVM-GLM paradigm. *Computing in Cardiology* 2012; 39:257-60.
52. Delen D, Walker G, Kadam A. Predicting breast cancer survivability: a comparison of three data mining methods. *Artificial intelligence in medicine*. 2005;34(2):113-27.
53. McCoy A, Das R. Reducing patient mortality, length of stay and readmissions through machine learning-based sepsis prediction in the emergency department, intensive care unit and hospital floor units. *BMJ Open Qual* 2017;6(2):e000158. doi: 10.1136/bmjopen-2017-000158.
54. Pérez A, Chan W, Dennis RJ. Predicting the length of stay of patients admitted for intensive care using a first step analysis. *Health Services and Outcomes Research Methodology*. 2006;6(3-4):127-38.
55. Faddy M, McClean S. Analysing data on lengths of stay of hospital patients using phase-type distributions. *Applied Stochastic Models in Business and Industry* 1999;15(4):311-7.
56. Golüke N, Huibers C, Stalpers S, Taekema D, Vermeer S, Jansen P. An observational, retrospective study of the length of stay, and its influencing factors, among elderly patients at the Emergency Department. *European Geriatric Medicine*. 2015;6(4):331-5.
57. Wang Y, Chen W, Heard K, Kollef MH, Bailey TC, Cui Z, et al. Mortality prediction in icus using a novel time-slicing cox regression method. *AMIA Annual Symposium Proceedings*; 2015: American Medical Informatics Association.
58. Zadeh LA. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems* 1978;1(1):3-28. doi.org/10.1016/S0165-0114(99)80004-9

## Design and Implementation of a Fuzzy Intelligent System for Predicting Mortality in Trauma Patients in the Intensive Care Unit

Montazeri Mitra<sup>1</sup>, Ahmadinejad Mahdi<sup>2</sup>, Montazeri Mahdih<sup>3\*</sup>, Montazeri Mohadeseh<sup>4</sup>

• Received: 21 Nov, 2018

• Accepted: 11 Dec, 2019

**Introduction:** The intensive care unit is one of the most costly parts of the national health sector. These costs are largely attributable to the length of stay in the intensive care unit. For this reason, there are significant benefits in predicting patients' length of stay and the percentage of deaths in intensive care units. Therefore, in this study, a fuzzy logic based intelligent system was designed to predict the percentage of deaths in trauma patients in the intensive care unit.

**Method:** Data needed to design the system were collected from patient files from 2010 to 2012. Then, the system was run using data collected from each file and the system diagnosis was compared with the final diagnosis recorded in the patient file. The proposed neuro-fuzzy model was compared with five other intelligent models. This comparison was calculated and evaluated based on sensitivity, accuracy, specificity, and the area under the ROC curve.

**Results:** The accuracy of these six models was approximately 83%, 81%, 80%, 75%, 82% and 81%, respectively.

**Conclusion:** The neuro-fuzzy model was evaluated as the best model and had the highest accuracy. This model also had the highest area under the ROC curve. Therefore, it is recommended to use neuro-fuzzy model to diagnose and predict the percentage of deaths in trauma patients in the intensive care unit. This is important in health-related research particularly in allocating therapeutic resources to people at risk.

**Keywords:** Trauma Patients, Intensive Care Unit, Classification, Prediction, Intelligent Models, ANFIS Naïve Bayes, Trees Random Forest 1NN, AdaBoost, SVM

• **Citation:** Montazeri M, Ahmadinejad M, Montazeri M, Montazeri M. Design and Implementation of a Fuzzy Intelligent System for Predicting Mortality in Trauma Patients in the Intensive Care Unit. *Journal of Health and Biomedical Informatics* 2020; 7(1): 10-9. [In Persian]

1. M.Sc. in Artificial Intelligent, Medical Informatics Research Center, Institute for Futures Studies in Health, Kerman University of Medical Sciences, Kerman, Iran
2. Fellowship of Intensive Care Medicine, Associate Professor, Anesthesiology Computer Dept., Faculty of Medicine, Kerman University of Medical Sciences, Kerman, Iran
3. Ph.D. Student in Medical Informatics, Medical Informatics Research Center, Institute for Futures Studies in Health, Kerman University of Medical Sciences, Kerman, Iran
4. Ph.D. Student in Computer Software, Lecturer, Computer Dept., Technical and Vocational University, Kerman, Iran

\*Corresponding Author: Mahdih Montazeri

Address: Medical Informatics Research Center, Institute for Futures Studies in Health, Kerman University of Medical Sciences, Haft-bagh highway, Kerman, Iran

• Tel: 034-31325406

• Email: mahdihmontazeri@yahoo.com