

Identification of Important Features to Predict 30-Day Mortality in Heart Failure Patients with Cardiogenic Shock

Shiva Kanani^{1*}, Iraj Mahdavi², Naghmeh Ziaie³, Bagher Rahimpour Cami⁴

1. PhD Student in Industrial Engineering, Mazandaran University of Science and Technology, Babol, Iran

2. Professor, Department of Industrial Engineering, University of Science and Technology of Babol, Babol, Iran

3. Assistant Professor, Department of Cardiology, Fellowship of Heart Failure and Transplantation, Babol University of Medical Sciences, Rouhani Hospital Research Center, Babol, Iran

4. Assistant Professor, Department of Computer Engineering, University of Science and Technology of Babol, Babol, Iran

ARTICLE INFO:

Article History:

Received: 13 Jul 2024

Accepted: 9 Nov 2024

Published: 20 Dec 2024

*Corresponding Author:

Shiva Kanani

Email:

Shiva.kanani@ustmb.ac.ir

Citation: Kanani S, Mahdavi I, Ziaieb N, Rahimpour Cami B. Identification of Important Features to Predict 30-Day Mortality in Heart Failure Patients with Cardiogenic Shock. Journal of Health and Biomedical Informatics 2024; 11(3): 229-43. [In Persian]

Abstract

Introduction: Cardiovascular diseases remain a leading global cause of mortality, with ischemic heart disease projected to account for 23.3 million deaths by 2030. Heart failure and cardiogenic shock account for a significant proportion of these deaths and require timely treatment as medical emergencies. This study aims to predict mortality within one month in patients experiencing cardiogenic shock secondary to heart failure using a concise set of predictive features.

Method: An analytical cross-sectional study was conducted at Babol Razi Hospital, involving 201 adult patients (≥ 18 years) treated for cardiogenic shock in 2020. Data from 34 clinical variables, including age, history of cardiac surgery, pH levels, lactate concentration, diabetes status, and blood pressure, were meticulously analyzed. Mortality outcomes within one month were assessed via structured telephone follow-up. Logistic regression and Gradient Boosting Machine (GBM) algorithms were used for predictive modeling.

Results: The average age of patients was 69.44 ± 15.71 years. Among them, 47.7% died. The study identified age, lactate levels, diabetes, and initial confusion as significant predictors of mortality risk. Each additional year of age was associated with a 7% higher probability of mortality. Diabetic patients faced more than double the mortality risk compared to non-diabetics. Confusion at presentation increased the mortality risk fourfold, while elevated lactate levels raised it by 1.5 times.

Conclusion: Logistic regression and GBM algorithms demonstrated effectiveness in predicting one-month mortality among cardiogenic shock patients with heart failure based on selected features. This approach holds promise for improving referral processes and reducing costs in healthcare settings.

Keywords: Heart Failure, Cardiogenic Shock, Death Prediction, Logistic Regression, Feature Selection



CrossMark

مقاله پژوهشی

شناسایی ویژگی‌های مهم برای پیش‌بینی مرگ و میر ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک

شیوا کنعانی^{۱*}، ایرج مهدوی^۲، نغمه ضیایی^۳، باقر رحیم پورکامی^۴

۱. دانشجوی دکتری مهندسی صنایع، دانشگاه علوم و فنون بابل، بابل، ایران

۲. استاد، گروه مهندسی صنایع، دانشگاه علوم و فنون بابل، بابل، ایران

۳. استادیار، گروه قلب فلوشیپ نارسایی قلب و پیوند، دانشگاه علوم پزشکی بابل، مرکز تحقیقات بیمارستان روحانی بابل، بابل، ایران

۴. استادیار، گروه مهندسی کامپیوتر، دانشگاه علوم و فنون بابل، بابل، ایران

چکیده

مقدمه: بیماری قلبی یکی از علل اصلی مرگ‌ومیر است و پیش‌بینی می‌شود تا سال ۲۰۳۰ مرگ‌ومیر ناشی از بیماری‌های قلبی - عروقی به ۲۳/۳ میلیون نفر افزایش یابد. نارسایی قلبی و شوک کاردیوژنیک سهم بالایی از این مرگ‌ومیرها دارند و به‌عنوان اورژانس پزشکی نیازمند درمان به‌موقع هستند. هدف این پژوهش، پیش‌بینی سریع مرگ در بیماران نارسایی قلبی با شوک کاردیوژنیک با استفاده از ویژگی‌های کمتر است.

روش کار: این پژوهش به روش تحلیلی - مقطعی با نمونه‌گیری تمام شماری صورت گرفت. داده‌های ۲۰۱ بیمار قلبی بالای ۱۸ سال که در سال ۲۰۲۰ در بیمارستان روحانی بابل دچار شوک کاردیوژنیک شده بودند، بررسی شدند. از ۳۴ ویژگی مانند سن، سابقه جراحی قلب باز، pH، لاکتات، دیابت و فشارخون استفاده شد و مرگ یک‌ماهه از طریق تماس تلفنی بررسی شد. برای پیش‌بینی مرگ از رگرسیون لجستیک و الگوریتم GBM استفاده شد.

یافته‌ها: میانگین سن بیماران $15/71 \pm 69/44$ سال بود. از این تعداد، ۴۷/۷ درصد فوت کردند. چهار ویژگی شامل سن، لاکتات، دیابت و گلیسیمی به‌عنوان مهم‌ترین ویژگی‌ها انتخاب شدند. با یک سال افزایش در سن، احتمال مرگ ۷ درصد افزایش می‌یابد. احتمال مرگ در افراد دیابتی بیش از دوبرابر است. گلیسیمی خطر مرگ را ۴ برابر و افزایش لاکتات خطر مرگ را ۱/۵ برابر افزایش می‌دهد.

نتیجه‌گیری: نتایج نشان داد انتخاب ویژگی‌های مؤثر در پیش‌بینی مرگ بیماران نارسایی قلبی با شوک کاردیوژنیک با رگرسیون لجستیک و الگوریتم GBM امکان‌پذیر است و می‌تواند به بهبود برنامه‌های ارجاع درمانی و کاهش هزینه‌های پزشکی کمک کند.

کلیدواژه‌ها: نارسایی قلبی، شوک کاردیوژنیک، پیش‌بینی مرگ، رگرسیون لجستیک، انتخاب ویژگی

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۳/۴/۲۳

پذیرش: ۱۴۰۳/۸/۱۹

انتشار برخط: ۱۴۰۳/۹/۳۰

*نویسنده مسئول:

شیوا کنعانی

ایمیل:

Shiva.kanani@ustmb.ac.ir

ارجاع:

کنعانی شیوا، مهدوی ایرج، ضیایی نغمه، رحیم پورکامی باقر. شناسایی ویژگی‌های مهم برای پیش‌بینی مرگ و میر ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۳؛ ۲۲۹-۴۳ (۳): ۱۱

مقدمه

امروزه انواع بیماری‌های قلبی یکی از دلایل اصلی مرگ‌ومیر به شمار می‌رود. پیش‌بینی می‌شود باتوجه‌به روند کنونی تا سال ۲۰۲۵ میلادی بیشتر از ۳۵ تا ۶۰ درصد موارد مرگ‌ومیر در جهان از بیماری‌های قلبی -عروقی ناشی شود. در ایران ۴۴ درصد از مرگ‌ومیرها در کشور به دلیل بیماری قلبی و عروقی اتفاق می‌افتد. از این‌رو باتوجه‌به شیوع بیماری‌های قلبی در ایران و جهان، به‌کارگیری روش‌های داده‌کاوی جهت تشخیص درست و به‌موقع نوع درمان بیماری‌های قلبی به جهت بقاء، امری ضروری به نظر می‌رسد [۱].

یکی از انواع بیماری‌های قلبی، نارسایی قلبی می‌باشد و نارسایی قلبی یک سندرم کلینیکی است که به دنبال ناهنجاری ساختاری یا عملکردی قلب ایجاد می‌شود که باعث کاهش خون پمپاژ شده از قلب یا افزایش فشار داخل قلبی می‌گردد و با علائمی نظیر تنگی نفس، ارتوپنه، تورم اندام تحتانی مشخص می‌شود و در معاینه بالینی احتقان ریوی و افزایش فشار ورید ژوگولر یافت می‌شود [۲]. در واقع نارسایی قلبی با شوک کاردیوژنیک از موارد فوق‌حد و تهدیدکننده حیات می‌باشد؛ لذا یک اورژانس پزشکی محسوب می‌شود. بیماری که با شوک کاردیوژنیک مراجعه می‌کند در شرایط عادی نیست و پزشک در ابتدا سعی می‌کند به‌وسیله درمان حمایتی مانع ازدست‌رفتن بیمار شود. شوک کاردیوژنیک (Cardiogenic Shock) نیاز به تشخیص و درمان فوری دارد [۳]. درمان زودهنگام و مناسب این بیماری می‌تواند میزان مرگ‌ومیر را کاهش دهد. در تشخیص شوک کاردیوژنیک، چندین معیار بالینی اهمیت دارند. این معیارها شامل کاهش ایندکس قلبی به کمتر از ۲/۲ لیتر در دقیقه بر متر مربع و افت فشار خون سیستولیک (SBP(Systolic Blood Pressure)) به زیر ۹۰ میلی‌متر جیوه است که این کاهش فشار خون باید بیش از ۳۰ دقیقه طول بکشد یا نیاز به استفاده از داروهای وازوپرسور برای حفظ فشار خون سیستولیک بالای ۹۰ میلی‌متر جیوه وجود داشته باشد. علاوه بر این، علائم کاهش خون‌رسانی به بافت‌ها، مانند کاهش سطح هوشیاری، سردی پوست، کاهش ادرار (الیگوری)، یا افزایش لاکتات خون (بیش از ۲ میلی‌مول بر لیتر) دیده می‌شود. همچنین، فشار انسدادی شریان ریوی (Paop(Pulmonary Artery Occlusion Pressure)) معمولاً کمتر از ۱۵ میلی‌متر جیوه است [۴-۶].

تجزیه‌وتحلیل داده‌های با ابعاد بالا به‌عنوان یکی از چالش‌های اصلی محققان مطرح است. انتخاب ویژگی، راهکاری مؤثر برای حل این مشکل با حذف داده‌های نامربوط و زائد فراهم می‌کند. این امر می‌تواند زمان انجام پیش‌بینی را کاهش دهد. حجم زیاد و پیچیدگی داده‌های پزشکی به خصوص در زمینه بیماران نارسایی قلبی دارای شوک کاردیوژنیک در بعضی مواقع تصمیمات مهم برای پیش‌بینی مرگ و میر را برای پزشکان و ارائه‌دهندگان خدمات درمانی سخت و زمان‌بر می‌کند و خطر عدم درمان و مرگ در بیمار را افزایش می‌دهد؛ بنابراین، استفاده از تعداد متغیرهای کمتر و مهمی که ارتباط با مرگ این دسته از بیماران دارند و حذف متغیرهای بی‌ربط با مرگ بیماران، در داده‌های پزشکی به لحاظ پیچیدگی داده‌ها، پیش‌بینی و تشخیص بیماری، کاهش خطا و افزایش سرعت تصمیم‌گیری، پیشنهاد می‌گردد. استفاده از متغیرهای مهمی که ارتباط معناداری با متغیر پیش‌بینی مرگ دارند و حذف متغیرهای زائد به جلوگیری از اشتباهات پزشکی و بهبود عملکرد درمانی کمک می‌کند. مزایای اصلی این کاهش ویژگی عبارت‌اند از: ۱) کاهش در زمان درمان ۲) بهبود عملکرد پیش‌بینی، ۳) شناسایی ویژگی‌های مرتبط، ۴) بهبود کیفیت درمان و ۵) صرفه‌جویی در منابع در مراحل بعدی جمع‌آوری داده‌ها. هدف این مطالعه ارائه مدلی با کمترین تعداد متغیر برای پیش‌بینی مرگ بیماران نارسایی قلبی با شوک کاردیوژنیک و در نتیجه پیش‌بینی روش درمانی مناسب بیماری به‌منظور کاهش زمان و هزینه‌های درمان و ارائه خدمات بهتر به پزشکان می‌باشد. مطالعاتی در مورد پیش‌بینی مرگ در بیماران شوک قلبی انجام پذیرفته است که در جدول ۱ به برخی از آن‌ها اشاره شده است.

جدول ۱: جدول مرور ادبیات پیش‌بینی مرگ بیماران قلبی

نویسندگان	سال	منبع	نارسایی قلبی	شوگ قلبی	مرگ درون بیمارستانی	شوگ قلبی	مرگ ۳۰ روزه
Ostberg و همکاران	۲۰۲۲	[۷]	*	*	*	-	-
Krittana Wong و همکاران	۲۰۲۱	[۸]	*	-	*	-	-
Awan و همکاران	۲۰۱۹	[۹]	*	-	*	*	*
Rahman و همکاران	۲۰۲۲	[۱۰]	*	*	*	-	-
Chang و همکاران	۲۰۲۲	[۱۱]	*	*	*	-	-
Alotaibi	۲۰۱۹	[۱۲]	*	-	*	-	-
Li و همکاران	۲۰۱۶	[۱۳]	-	*	*	-	-
König و همکاران	۲۰۲۱	[۱۴]	*	-	*	-	-
Current Study	۲۰۲۴	-	*	*	*	*	*

همان طور که در بالا بیان شد، علی‌رغم تحقیقات گسترده در زمینه شوک کاردیوژنیک، هنوز برخی جنبه‌های این بیماری به‌طور کامل بررسی نشده است. یکی از مهم‌ترین شکاف‌ها در پیش‌بینی مرگ‌ومیر بیماران مبتلا به نارسایی قلبی است که به‌عنوان یکی از عوامل شوک کاردیوژنیک شناخته می‌شود. بیشتر مطالعات موجود بر بیماران مبتلا به انفارکتوس حاد تمرکز دارند و اطلاعات کمی در مورد بیماران نارسایی قلبی با شوک کاردیوژنیک در دسترس است. این کمبود داده‌ها می‌تواند به نادیده گرفتن ویژگی‌های مهم در پیش‌بینی نتایج بیماران منجر شود. از طرفی، به‌کارگیری روش‌های سریع و دقیق برای پیش‌بینی مرگ‌ومیر در این بیماران، به دلیل نرخ بالای مرگ‌ومیر و نیاز به درمان سریع، ضروری است.

تحقیقات قلبی بیشتر بر مدل‌هایی مبتنی بر داده‌های بانک‌های اطلاعاتی تمرکز کرده‌اند که صرفاً عوامل پیش‌بینی‌کننده مرگ ۳۰ روزه یا درون بیمارستانی را در گروه‌های سنی خاص شناسایی کرده‌اند. مطالعه حاضر، علاوه بر استفاده از اطلاعات بیماران بخش اورژانس بیمارستان روحانی بابل، به پیش‌بینی مرگ ۳۰ روزه بیماران بالای ۱۸ سال با شوک کاردیوژنیک می‌پردازد.

در واقع چالش‌های موجود شامل تمرکز برخی مطالعات بر مرگ درون بیمارستانی و برخی دیگر بر مرگ ۳۰ روزه، عدم بررسی هم‌زمان این دو، در پیش‌بینی‌ها است. مطالعه‌ای که بتواند هر دو مرگ درون بیمارستانی و ۳۰ روزه را برای بیماران بالای ۱۸ سال با شوک کاردیوژنیک به‌طور هم‌زمان پیش‌بینی کند، می‌تواند به بهبود دقت پیش‌بینی‌ها و توسعه راهبردهای درمانی مؤثرتر منجر شود.

نتیجه‌ای که به‌طور خلاصه از مرور ادبیات و مطالعه دقیق مقالات می‌توان گرفت و به‌عنوان شکاف تحقیق بیان کرد به شرح زیر می‌باشد:

- بیشتر تحقیقات گذشته بر بیماران مبتلا به انفارکتوس حاد تمرکز داشته‌اند و اطلاعات محدودی در مورد بیماران نارسایی قلبی با شوک کاردیوژنیک وجود دارد.
- مطالعات عمدتاً مرگ درون بیمارستانی یا مرگ ۳۰ روزه را جداگانه بررسی کرده‌اند و کمتر به‌طور هم‌زمان هر دو را برای بیماران بالای ۱۸ سال لحاظ کرده‌اند.

برای پیش‌بینی دقیق مرگ متغیرهای فراوانی تأثیرگذار می‌باشند می‌توانند دقت پیش‌بینی را بالا ببرند؛ اما هم‌زمان هم می‌توانند باعث بالابردن زمان برای اقدام درمانی بشوند. برای این منظور، شناسایی ویژگی‌های مهم و حذف متغیرهای کم‌اهمیت می‌تواند به کادر درمان و پزشکان برای پیش‌بینی سریع و دقیق مرگ کمک شایانی بکند.

Acharya و همکاران در یک مطالعه به بررسی فاکتورهای پیشگویی‌کننده مورتالیتی بیماران با شوک ناشی از انفارکتوس میوکارد حاد پرداختند. آن‌ها لیستی از فاکتورهای پیشگویی‌کننده در میزان مرگ‌ومیر بیماران تهیه کردند و به بررسی ارتباط آن‌ها با خطر مرگ‌ومیر و درمان‌های موجود پرداختند. آن‌ها سطح لاکتات، کراتینین و زمان رسیدن از شروع علائم به بیمارستان را به‌عنوان مهم‌ترین عوامل مؤثر در مورتالیتی زودرس و دیررس در بیماران با انفارکتوس حاد با تابلوی شوک کاردیوژنیک شناسایی کردند [۱۵].

در مطالعه Ueki و همکاران بر روی ۹۷۹ بیمار، فاکتورهای پیشگویی‌کننده مورتالیتی ۳۰ روزه بیماران مراجعه‌کننده با شوک، بدون توجه به اتیولوژی آن را بررسی کرد. آن‌ها به این نتیجه رسیدند که عملکرد کاردیورنال در بدو مراجعه بیماران و اتیولوژی شوک مهم‌ترین فاکتورهای پیش‌بینی‌کننده مورتالیتی هستند [۱۶].

Li و همکاران به بررسی عوامل پیشگویی‌کننده مورتالیتی درون بیمارستانی در ۲۵۳ بیمار که در بیمارستان با عوامل مختلفی دچار شوک کاردیوژنیک شدند و مداخلات درمانی آن‌ها پرداختند. نتایج این مطالعه نشان داد که عواملی مانند سن، گلوکز خون و ضربان قلب در پیش‌بینی مورتالیتی بیماران مؤثر هستند و در انتخاب درمانی مناسب می‌توانند سودمند باشند [۱۳].

در ادامه، Rong و همکاران در مطالعه‌ای به پیش‌بینی دقیق‌تر مرگ و میر ۳۰ روزه بیماران شوک کاردیوژنیک پرداختند. در این مطالعه، پیش‌بینی‌کننده سن، ضربان قلب، دما، تعداد گلبول‌های سفید خون WBC، شکاف آنیون و اسیدلاکتیک خون، توانستند به‌طور دقیق مرگ و میر ۳۰ روزه بیماران شوک کاردیوژنیک را پیش‌بینی کنند [۱۸].

در مطالعه Ostberg و همکاران به پیش‌بینی مرگ درون بیمارستانی، بیماران شوک قلبی با استفاده از مدل لاسو و رگرسیون لجستیک پرداخته شد. نتایج این مطالعه نشان داد که مدل لاسو از مدل رگرسیون لجستیک بهتر عمل کرده و عواملی مانند سن، نمره کمای گلاسکو، D-dimer، لاکتات، بیلی‌روبین و pH به‌عنوان پیش‌بینی‌کننده‌های مؤثر شناسایی شدند [۷].

معمون و همکاران، پیش‌بینی بقای بیماران نارسای قلبی را با استفاده از یادگیری ماشین برای تجزیه و تحلیل عوامل خطر ارائه کردند. همچنین، شش عامل خطر اصلی برای بیماران نارسای قلبی شامل کراتینین سرم، سن، EF، پلاکت‌ها و کراتینین فسفوکیناز شناسایی شدند [۱۸].

در مطالعه Harjola و همکاران که بر روی ۲۱۹ بیمار در فنلاند انجام شد، به بررسی نتایج مورتالیتی کوتاه‌مدت بیماران مراجعه‌کننده با شوک و پیش‌بینی‌کننده‌های آن پرداخت. نتایج نشان داد که عواملی مانند سن، کانفیوژن، EF پایین و لاکتات بالای سرم با مورتالیتی مرتبط هستند [۱۹].

در مطالعه Chaggar و همکاران در انگلستان بر روی پیش‌آگهی بیماران مراجعه‌کننده با شوک، بررسی مورتالیتی یک‌ساله ۵۹ بیمار نشان داد که سن بالا و عدد کراتینین بالای اولیه یا آسیب اولیه به کبد از موارد با پیش‌آگهی بد به شمار می‌روند [۲۰].

در مطالعه Demondion و همکاران با هدف بررسی عوامل پیش‌بینی‌کننده مستقل مرگ و میر ۳۰ روزه در بیماران مبتلا به شوک قلبی همراه با آنفراکتوس حاد میوکارد (AMI) (Acute Myocardial Infarction) و نیاز به حمایت خارجی (Extracorporeal Life Support) (ECLS) انجام شد. نتایج این مطالعه نشان داد که کاهش مدت زمان ایسکمی اندام انتهایی از مهم‌ترین عوامل مدیریت این گروه از بیماران است [۲۱]. رسیدن به ویژگی‌های مؤثر بر مرگ این دسته از بیماران می‌تواند ما را در پیش‌بینی دقیق و سریعی از مرگ یاری رساند و برای پزشکان و کادر درمان جهت اتخاذ تصمیمات مناسب، مؤثر واقع شود.


روش کار

در این پژوهش که از نوع تحلیلی - مقطعی می‌باشد، بیماران مبتلا به نارسای قلبی بالای ۱۸ سال که در بدو مراجعه در بیمارستان روحانی شهر بابل در کشور ایران دچار تابلوی شوک کاردیوژنیک شده‌اند، مورد ارزیابی قرار گرفته‌اند. اطلاعات دموگرافیک و بالینی و پاراکلینیکی بیماران در پرسش‌نامه‌هایی طراحی شده و تکمیل شد و مورتالیتیه یک‌ماهه آن‌ها از طریق تماس تلفنی بررسی شد. روش نمونه‌گیری تمام شماری می‌باشد.

اطلاعات ۲۰۱ بیمار نارسای قلبی با شوک کاردیوژنیک از بین بیماران بستری در بخش اورژانس قلب بیمارستان روحانی بابل در سال ۱۳۹۹ شناسایی و استخراج گردید که دارای ۳۴ ویژگی شامل فشارخون سیستول، فشارخون دیاستول، تعداد ضربان نبض، ریتم قلبی، اندام‌های انتهایی سرد، گیجی، لاکتات خون شرنای، سدیم، پتاسیم، pH، نارسای کلیوی، دیابت و... بودند.

مدل پیشنهادی در این پژوهش، یک رویکرد یادگیری با نظارت جهت پیش‌بینی مرگ بیماران نارسای قلبی دارای شوک کاردیوژنیک می‌باشد. در این مطالعه مجموعه داده به‌عنوان ورودی، وارد الگوریتم شد. در این مطالعه ابتدا داده‌ها به دو قسمت آموزشی (train) و آزمایشی (test) تقسیم گردید که در این جا به نسبت ۸۰ به ۲۰ می‌باشد و سپس تابع موردنظر بر روی داده‌ها اجرا شد. سپس مدل

جهت پیش‌بینی مرگ بیماران نارسایی قلبی دارای شوک کاردیوژنیک ایجاد گردید و ویژگی‌های مهم آن به‌منظور بالابردن سرعت سیستم شناسایی شد. سپس در مرحله آخر، به‌منظور سنجش دقت الگوریتم موردنظر، مدل آموزش‌دیده با مجموعه داده‌های آزمایش، مطابق با معیارهای ارزیابی، مورد آزمایش و بررسی قرار گرفت. در واقع، هدف این پژوهش پیش‌بینی مرگ بیماران نارسایی قلبی دارای شوک کاردیوژنیک با در نظر گرفتن ویژگی‌های مهم و کمتر به‌منظور بالابردن دقت سیستم می‌باشد. در زیر فلوچارتی از پیش‌بینی مرگ ۳۰ روزه بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک ارائه شده است.



شکل ۱: فلوچارت

پیش‌پردازش داده‌ها

پیش‌پردازش مجموعه داده برای نمایش مؤثر کیفیت داده‌ها ضروری است. مجموعه داده با استفاده از تکنیک‌هایی مانند حذف مقادیر از دست‌رفته، (Standard Scaler) SS و Min Max Scaler پیش‌پردازش شده است. مدیریت ارزش از دست‌رفته یک تکنیک پیش‌پردازش داده است که برای ایجاد یک مجموعه داده یک‌دست استفاده می‌شود؛ بنابراین، با تعیین اینکه آیا مجموعه داده حاوی مقادیر گمشده‌ای است یا خیر، شروع شد [۲۲، ۲۳]. مقادیر از دست‌رفته را می‌توان به روش‌های مختلفی، از جمله نادیده گرفتن کامل مقدار گم شده، جایگزینی آن با هر مقدار عددی، جایگزینی آن با مقدار حالت رایج برای آن ویژگی و یا جایگزینی آن با مقدار میانگین ویژگی مدیریت کرد. مجموعه داده بیماری نارسایی قلبی با تابلوی شوک کاردیوژنیک مورد استفاده در این مطالعه از دو مقدار گمشده تشکیل شده است. مقادیر از دست‌رفته با مقادیر میانگین ویژگی‌ها جایگزین گردید.

پیش‌بینی مرگ با همه ویژگی‌ها

در این فاز، پیش‌بینی مرگ این بیماران از طریق الگوریتم GBM (Gradient Boosting Machine) با همه ۳۴ ویژگی گرفته شده انجام شد. در زیر تعریفی از الگوریتم GBM آورده شده است.

الگوریتم GBM

الگوریتم GBM یکی از الگوریتم‌های یادگیری ماشین می‌باشد که بر پایه درخت تصمیم توسعه یافته است. با استفاده از روش کاهش گرادیان و یک مجموعه از درختان تصمیم، این الگوریتم داده‌های آموزش را بهتر فهمیده و در نتیجه عملکرد بهتری در پیش‌بینی برای داده‌های جدید ایجاد می‌کند؛ لذا یک الگوریتم یادگیری گروهی می‌باشد و از پیچیدگی مدل جلوگیری می‌کند [۲۴، ۲۵].

انتخاب ویژگی برای پیش‌بینی مرگ

در این فاز، اعمال الگوریتم آماری رگرسیون لجستیک برای تعیین ویژگی‌های مؤثر و مهم انجام شد. در زیر تعریفی از رگرسیون لجستیک آورده شده است.

رگرسیون لجستیک

رگرسیون یکی از روش‌های آماری پارامتریک می‌باشد. مدل‌های رگرسیونی به بررسی تأثیرات متغیرهای پیش‌بین بر روی متغیرهای وابسته می‌پردازد. در اصل می‌توان گفت رگرسیون، یک معادله‌ای است که پیشگویی یک متغیر وابسته (متغیری که می‌خواهیم آن را پیش‌بینی کنیم) را بر اساس یک یا چند متغیر مستقل (متغیری که به‌عنوان پیش‌بین در نظر گرفته‌ایم) مشخص می‌کند. رگرسیون لجستیک (Logistic Regression) یکی از انواع رگرسیون می‌باشد که در آن متغیر وابسته تحقیق به‌صورت دوجویی (دوطبقه‌ای) یا چندطبقه‌ای سنجیده شده است و هدف این مطالعه این است مدلی طراحی و آزمون شود که این متغیر را بتوان پیش‌بینی نمود. یک رگرسیون لجستیک دوجمله‌ای (Binomial Logistic Regression) (که اغلب به آن رگرسیون لجستیک گفته می‌شود)، احتمال این که یک مشاهده در یکی از دودسته متغیر وابسته دوگانه (dichotomous) بر اساس یک یا چند متغیر مستقل پیوسته یا طبقه‌ای قرار می‌گیرد را پیش‌بینی می‌کند. با استفاده از روش رگرسیون لجستیک دوجمله‌ای و مدل‌های آماری، آماردانان می‌توانند، روابط بین متغیرهای پیش‌بین را با متغیر وابسته دوجویی (دوطبقه‌ای) که به‌صورت ترتیبی یا اسمی سنجیده شده باشد بررسی نمایند [۲۶]. سپس داده‌ها با استفاده از رگرسیون لجستیک دوجمله‌ای در SPSS Statistics تجزیه و تحلیل شد.

پیش‌بینی مرگ با ویژگی‌های انتخابی

در فاز آخر، پیش‌بینی مرگ این بیماران از طریق الگوریتم گروهی GBM با ۴ ویژگی به‌دست‌آمده از طریق آنالیز آماری رگرسیون لجستیک انجام شد و مقایسه و ارزیابی عملکردی بین فاز اول و سوم انجام پذیرفت.

معیارهای ارزیابی

معیارهای ارزیابی مختلفی شامل دقت، امتیاز F1، صحت و یادآوری می‌باشد که با استفاده از ماتریس اغتشاش که در جدول ۲ مشاهده می‌کنید، برای تعیین کارایی تکنیک‌های پیش‌بینی مرگ ۳۰ روزه به دست می‌آید. ماتریس اغتشاش به محققان اجازه می‌دهد تا نرخ عملکرد نتیجه را در مسائل طبقه‌بندی بسته به چهار عامل اصلی شامل مثبت واقعی (پیش‌بینی مرگ است و بیمار فوت شده است) TP، مثبت کاذب (پیش‌بینی بقا است و بیمار زنده است) FP، منفی واقعی (پیش‌بینی مرگ است و بیمار زنده است) TN و منفی کاذب (پیش‌بینی بقا است و بیمار فوت شده است) FN شناسایی کنند. در صورتی که مدل بتواند شناسایی مناسب سطح خطر بالای مرگ ۳۰ روزه را افزایش دهد، نشان از دقت مدل می‌باشد [۳۰-۲۷].

جدول ۲: ماتریس درهم‌ریختگی

	ماتریس درهم‌ریختگی	برچسب شناخته شده	
		مثبت (P)	منفی (N)
برچسب پیش‌بینی شده	مثبت (P)	True positive (TP)	False negative (FN)
	منفی (N)	False positive (FP)	True negative (TN)

Specificity اندازه‌گیری می‌کند که انتساب به کلاس مثبت چقدر دقیق است و با فرمول زیر محاسبه می‌گردد:



$$Specificity = \frac{TN}{TN + FP}$$

دقت را می توان توسط فرمول زیر محاسبه نمود:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN \text{ (all data)}}$$

صحت که به عنوان مجموع موارد به درستی شناسایی شده محاسبه می شود، به این معنی است که نسبت بیمارانی که مرگ ۳۰ روزه تشخیص داده شده اند، واقعاً دارای ریسک مرگ هستند. صحت توسط فرمول زیر محاسبه می گردد:

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

بسته نرم افزاری مورد استفاده در مطالعه

کدهای برنامه نویسی استفاده شده در این مطالعه، از زبان برنامه نویسی R نسخه ۴.۲.۲ در محیط RStudio که به عنوان یک ابزار قدرتمند در فرایندهای یادگیری ماشین است، می باشد. تمام شکل ها و ماتریس اغتشاش و همه منحنی ها با استفاده از نرم فرار R رسم گردید.

هدف از این پژوهش، بهبود دقت پیش بینی مرگ در بیماران نارسای قلبی با شوک کاردیوژنیک با استفاده از روش آماری رگرسیون لجستیک است و از طرفی انتخاب ویژگی های مؤثر از بین ویژگی های متعددی که برای پیش بینی مرگ در بیماران انجام می شود می تواند کمک شایانی به تسریع انتخاب روش درمانی مناسب برای ارجاع بیمار به بخش های دیگر گردد.


نتایج

اطلاعات دموگرافیک و بالینی و پاراکلینیکی ۲۰۱ بیمار با ۳۴ ویژگی و مرگ ۳۰ روزه در پرسش نامه ها تکمیل شد و مرگ یک ماهه آن ها از طریق تماس تلفنی بررسی و تکمیل گردید. روش نمونه گیری تمام شماری است. یک مطالعه کوهورت آینده نگر بر روی بیماران مبتلا به نارسای قلبی است که در بدو مراجعه دچار تابلوی شوک کاردیوژنیک شده اند در سال ۲۰۲۰ مورد ارزیابی قرار گرفت. برچسب ویژگی خروجی (تعداد) به دو کلاس برای نشان دادن مرگ ۳۰ روزه و بهبود بیماری نارسای قلبی با تابلوی شوک کاردیوژنیک تقسیم می شود. پس از پیش پردازش داده ها ۸۰ درصد از داده (۱۶۱ بیمار) برای مجموعه داده آموزشی و ۲۰ درصد از داده (۴۰ بیمار) برای مجموعه داده آزمایشی منظور گردید. میانگین سن بیماران در این مطالعه ۶۹/۴۴±۱۵/۷۱ سال، از این تعداد ۴۷/۷ درصد فوت و ۵۲/۳ درصد زنده بودند. از نظر جنسیت، ۵۷/۲ درصد مرد و ۴۲/۸ درصد زن بودند که طبق جدول ۳ از مردان و زنان به ترتیب ۴۵/۲ و ۵۱/۱۷ درصد فوت و ۵۴/۸ و ۴۸/۸۳ درصد زنده ماندند.

جدول ۳: درصد فراوانی متغیر پیش بینی بر حسب جنسیت

جنسیت	زنده	فوت شده	جمع کل
مرد	۵۴/۸	۴۵/۲	۵۷/۲
زن	۴۸/۸۳	۵۱/۱۷	۴۲/۸

شکل ۲، رسم وابستگی جزئی متغیرهای عددی با مرگ ۳۰ روزه بیماران نارسایی قلبی با شوک کاردیوژنیک در بخش اورژانس قلب بیمارستان روحانی را نشان می‌دهد. با افزایش سن (بالا تر از ۵۷ سال) خطر مرگ ۳۰ روزه در بیماران نارسایی قلبی با شوک کاردیوژنیک افزایش می‌یابد. خطر مرگ ۳۰ روزه فشارخون سیستولی بالاتر از ۷۵ بیشتر از فشارخون سیستولی کمتر از ۶۵ می‌باشد. همچنین خطر مرگ ۳۰ روزه برای فشارخون دیاستول بالای ۵۰ بیشتر از فشارخون دیاستول کمتر از ۴۰ می‌باشد. خطر مرگ ۳۰ روزه بالاتر از ۲۰ برای ویژگی Lvef افزایش می‌یابد. همچنین شکل ۲ نشان می‌دهد با افزایش روز بستری بیماران خطر مرگ ۳۰ روزه کاهش می‌یابد و با افزایش تأخیر در رساندن بیمار به بیمارستان خطر مرگ نیز افزایش می‌یابد. با کاهش میزان pH کمتر از ۳/۷ خطر مرگ ۳۰ روزه در بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک نیز افزایش می‌یابد. افزایش Lactat بالاتر از ۲ ریسک مرگ ۳۰ روزه در بیماران نیز افزایش می‌یابد.



شکل ۲: وابستگی جزئی متغیرهای عددی با مرگ بیماران

تفسیر و گزارش خروجی تحلیل رگرسیون لجستیک دوجمله‌ای

هنگام انجام رگرسیون لجستیک دوجمله‌ای در SPSS Statistics جداول خروجی زیادی تولید می‌شود. در این بخش، تنها یک جدول اصلی مورد نیاز برای درک نتایج از روش رگرسیون لجستیک دوجمله‌ای، ارائه شده. با استفاده از رگرسیون لجستیک چهار ویژگی شامل سن، لاکتات، دیابت و گلیسمی به عنوان مهم‌ترین ویژگی‌ها از بین ۳۴ ویژگی، انتخاب شدند.

آزمون والد (Wald) برای تعیین معناداری آماری برای هر یک از متغیرهای مستقل استفاده می‌شود. اهمیت آماری آزمون در ستون (Sig) یافت می‌شود و انتظار این است که مقدار معنی‌داری زیر ۰/۰۵ باشد. این نتایج نشان می‌دهند که سن، دیابت، گلیسمی و لاکتات، به طور قابل توجهی به مدل پیش‌بینی اضافه شدند؛ اما سایر متغیرها به طور قابل توجهی به مدل اضافه نشده است. همچنین می‌توان از اطلاعات جدول “Variables in the Equation” برای پیش‌بینی احتمال وقوع یک رویداد بر اساس تغییر یک واحد در یک متغیر مستقل زمانی که سایر متغیرهای مستقل ثابت نگه داشته می‌شوند، استفاده شود. به عنوان مثال، جدول ۴ نشان می‌دهد با یک سال افزایش در سن، احتمال مرگ ۷ درصد افزایش می‌یابد ($P=0.001$, $OR=1.07$). احتمال مرگ در افراد دیابتی بیش از ۲ برابر است ($P=0.007$, $OR=2.057$).



ویژگی گنجی خطر مرگ را ۴ برابر افزایش می دهد (OR= ۴/۱۹، P=۰/۰۰۱). با افزایش در لاکتات، خطر مرگ حدود ۱.۵ برابر افزایش می یابد (OR= ۱/۴۶، P<۰/۰۰۱).

جدول ۴: متغیرهای مهم برای پیش بینی مرگ توسط آنالیز آماری رگرسیون لجستیک

Variables	B	S.E.	Wald	Df	Sig.	Exp(B)	95% Confidence Interval FOR Exp(B)	
							Lower	Upper
Age	-۰/۰۷۲	۰/۰۱۶	۲۰/۰۲۸	۱	۰/۰۰۰	۱/۰۷۵	۱/۰۴۱	۰/۰۱۰۹
Diabet (1)	۰/۷۲۱	۰/۴۰۵	۳/۱۷۴	۱	۰/۰۷۵	۲/۰۷۵	۰/۹۳	۴/۵۴۸
Confusion(1)	۱/۴۳۴	۰/۴۱۴	۱۲/۰۰۲	۱	۰/۰۰۱	۴/۱۹۶	۱.۸۶۴	۹/۴۴۵
Lactat	-۰/۳۸۲	۰/۱۰۵	۱۳/۰۸۵	۱	۰/۰۰۰	۱/۴۶۵	۱/۱۹۱	۱/۱۰۸
نوع ایزوتوپ دریافتی			۴/۰۰۰	۲	۰/۱۳۵			
نوع ایزوتوپ دریافتی (۱)	-۰/۷۳۷	۰/۵۳۳	۱/۹۱۵	۱	۰/۱۶۶	-۰/۴۷۸	-۰/۱۶۸	۱/۳۵۹
نوع ایزوتوپ دریافتی (۲)	۰/۳۰۹	۰/۷۱۰	-۰/۱۹۰	۱	۰/۶۶۳	۱/۳۶۳	-۰/۳۳۹	۵.۴۷۹
Na	-۰/۰۰۹	۰/۰۲۷	-۰/۱۱۰	۱	۰/۷۴۰	-۰/۹۹۱	-۰/۹۴۰	۱/۰۴۵
زمان رسیدن به بیمارستان			۴/۴۹۱	۴	۰/۳۴۴			
زمان رسیدن به بیمارستان (۱)	۰/۳۷۲	۰/۴۵۶	۰/۶۶۵	۱	۰/۴۱۵	۱/۴۵۰	۰/۵۹۴	۳/۵۴۴
زمان رسیدن به بیمارستان (۲)	۰/۸۶۱	۰/۵۶۴	۲/۳۳۷	۱	۰/۱۲۶	۲/۳۶۷	-۰/۷۸۴	۷/۱۴۲
زمان رسیدن به بیمارستان (۳)	۰/۶۲۵	۰/۶۸۸	-۰/۸۲۵	۱	۰/۳۶۴	۱/۸۶۹	-۰/۴۸۵	۷/۲۰۲
زمان رسیدن به بیمارستان (۴)	۲/۱۸۵	۱/۴۸۰	۲/۱۷۹	۱	۰/۱۴۰	۸/۸۹۱	-۰/۴۸۹	۱۶۱/۷۹۶
Constant	-۶.۲۴۳	۳/۶۸۰	۲/۸۷۹	۱	۰/۰۹۰	-۰/۰۰۲		

ارزیابی مدل ها

در ابتدا با استفاده از الگوریتم GBM که یک الگوریتم گروهی می باشد به پیش بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک پرداخته شد و همه ۳۴ ویژگی مؤثر بر مرگ را برای این پیش بینی در نظر شد. سپس با استفاده از متغیرهای مهم آنالیز آماری رگرسیون لجستیک، با استفاده از الگوریتم GBM به پیش بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک پرداخته شد. در قسمت آخر، مطابق جدول ۵ برای مقایسه عملکرد از معیارهای ارزیابی استفاده شد.

جدول ۵: معیارهای ارزیابی مدل GBM برای پیش بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک

Index	با همه ویژگی ها	با ویژگی های انتخابی
Sensitivity	۰/۷۶۲	۰/۹۰۵
Specificity	۰/۷۳۷	۰/۶۸۴
Pos Pred Value	۰/۷۶۲	۰/۷۶۰
Neg Pred Value	۰/۷۳۷	۰/۸۶۶
Precision	۰/۷۰۶۲	۰/۷۶
Recall	۰/۷۶۲	۰/۹۰۵
F1	۰/۷۶۲	۰/۸۲۶
Prevalence	۰/۵۰۲۵	۰/۵۲۵
Detection Rate	۰/۴	۰/۴۷۵
Detection Prevalence	۰/۵۲۵	۰/۶۲۵
Balanced Accuracy	۰/۷۴۹	۰/۷۹۴

در جدول ۶ یک مقایسه بین AUC و دقت پیش‌بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک انجام شد. باتوجه‌به جدول ۵ و ۶ استنباط می‌شود که می‌توان تعداد متغیرهای موردنیاز برای پیش‌بینی مرگ‌ومیر این دسته از بیماران را از ۳۴ به ۴ ویژگی کاهش داد و مقدار دقت را از ۰/۷۵ به ۰/۸۰ رساند.

جدول ۶: مقایسه AUC و دقت پیش‌بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک

Models	با همه ویژگی‌ها	با ویژگی‌های انتخابی
AUC	۰/۸۰۲	۰/۸۷۸
Accuracy	۰/۷۵	۰/۸۰

شکل ۳ ماتریس درهم‌ریختگی را برای مقایسه عملکرد نشان می‌دهد. همان‌طور که از این شکل برمی‌آید می‌توان فهمید با درنظرگرفتن متغیرهای مهم رگرسیون لجستیک با الگوریتم GMB عملکرد بهتر می‌شود.

ماتریس درهم‌ریختگی GBM با متغیرهای مهم رگرسیون لجستیک آماری		ماتریس درهم‌ریختگی GBM با کل متغیرها	
Predicted	Actual	Predicted	Actual
	Class1 Class2		Class1 Class2
Class1	19 6	Class1	17 5
Class2	2 13	Class2	4 14

شکل ۳: ماتریس درهم‌ریختگی برای مقایسه عملکرد

بحث و نتیجه‌گیری

در این پژوهش پیش‌بینی دقیق و سریع مرگ برای بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک با استفاده از تجزیه‌وتحلیل آماری رگرسیون لجستیک انجام پذیرفت. از آنجایی‌که بیماری نارسایی قلبی با تابلوی شوک کاردیوژنیک یک اورژانس پزشکی محسوب می‌شود و نیاز به درمان فوری دارد و درمان‌های انجام شده توسط پزشکان بر بقای بیماران تأثیر دارد این نتیجه به دست آمد که رگرسیون لجستیک با دقت بالایی مرگ این بیماران را پیش‌بینی می‌کند تا براین‌اساس نحوه ارجاع بیمار به بخش‌های دیگر درمانی را مدیریت کند. همچنین شناسایی ویژگی‌های مهم، ضمن پیش‌بینی دقیق‌تر و سریع‌تر مرگ در این دسته از بیماران با تریاژ زودهنگام و درمان به‌موقع در مراحل اولیه به کاهش احتمال مرگ‌ومیر این بیماران را کمک می‌کند.

در این پژوهش، با استفاده از تجزیه‌وتحلیل آماری رگرسیون لجستیک به بررسی عواملی پرداخته شد که می‌توانند مرگ ۳۰ روزه در بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک را پیش‌بینی کنند. نتایج نشان داد که عواملی همچون افزایش سن، کاهش pH خون، افزایش لاکتات، تأخیر در رساندن بیمار به بیمارستان، افزایش تعداد روزهای بستری، فشارخون سیستولی پایین و برخی متغیرهای دیگر، بر پیش‌بینی مرگ‌ومیر تأثیرگذار هستند. چهار ویژگی شامل سن، لاکتات، دیابت و گلیسمی به‌عنوان مهم‌ترین ویژگی‌ها از بین ۳۴ ویژگی، انتخاب شدند. از همین رو می‌توان نتیجه گرفت، شناسایی ویژگی‌های مهم، ضمن پیش‌بینی دقیق‌تر مرگ در این دسته از بیماران باعث بهبود تصمیم‌گیری‌های بالینی و اتخاذ راهبردهای درمانی مؤثرتر می‌شود که می‌تواند به افزایش بقاء و بهبود کیفیت زندگی بیماران منجر شود.

مطالعات پیشین نیز به تأثیر عوامل فیزیولوژیکی مانند pH خون و لاکتات بر پیش‌آگهی بیماران نارسایی قلبی اشاره کرده‌اند. از جمله، مطالعه Davodian و همکاران در «زمان و علل مرگ در انفارکتوس حاد میوکارد با شوک کاردیوژنیک» نشان داد سن، زمان رسیدن به بیمارستان، لاکتات بالا و فشارخون سیستولیک عوامل مؤثر در مرگ شناخته شده‌اند [۳۱]؛ بنابراین این نمودارها می‌توانند کمک شایانی حتی به کادر درمانی که متخصص نیستند برای دریافت اطلاعاتی در مورد وابستگی برخی ویژگی‌ها با مرگ بیماران کنند.

به‌علاوه، پژوهش‌هایی در زمینه پیش‌بینی مرگ بیماری نارسایی قلبی انجام شده است. برخی از مطالعات فقط به مرگ درون بیمارستانی پرداخته‌اند [۸،۱۳،۱۴]. و مقالات اندکی مانند Awan و همکاران مرگ ۳۰ روزه را هم در نظر گرفته‌اند [۹]. مطالعات کمی پیش‌بینی مرگ ۳۰ روزه بیماران نارسایی قلبی دارای شوک کاردیوژنیک را لحاظ کرده‌اند [۷،۱۰،۱۱]. باین وجود Nicolai مرگ درون بیمارستانی را در نظر گرفته است [۷] و برخی مطالعات یک پیش‌بینی اولیه از شوک کاردیوژنیک ارائه کرده‌اند [۱۴-۱۱].

مطالعه‌ای که بتواند تمام موارد شامل مرگ درون بیمارستانی و مرگ ۳۰ روزه بیماران نارسایی قلبی با شوک کاردیوژنیک را برای بیماران بالای ۱۸ سال لحاظ کند می‌تواند پیش‌بینی دقیق‌تری از مرگ برای اقدام درمانی بعدی در قسمت اورژانس ارائه دهد. از طرفی، به‌خاطر نرخ مرگ‌ومیر بالای این بیماری و نیاز به درمان سریع برای آن، به‌کارگیری روشی سریع برای پیش‌بینی می‌تواند از میزان مرگ‌ومیر این بیماری جلوگیری نماید بدین منظور، با استفاده از رویکرد انتخاب ویژگی برای به‌دست‌آوردن ویژگی‌های مؤثر و کمتر برای کادر درمان و پزشکان می‌توان به این مهم دست‌یافت. همان‌طور که در بالا اشاره شد، با یک سال افزایش در سن، احتمال مرگ ۷ درصد افزایش می‌یابد. احتمال مرگ در افراد دیابتی بیش از ۲ برابر است. ویژگی گلیسمی خطر مرگ را ۴ برابر افزایش می‌دهد. با افزایش در لاکتات، خطر مرگ ۱.۵ برابر افزایش می‌یابد.

از نقاط قوت این مطالعه ساده‌سازی فرآیند پیش‌بینی و افزایش کارایی مدل‌های پیش‌بینی با انتخاب ویژگی‌های کمتر، اما مهم برای پیش‌بینی مرگ‌ومیر بوده است. در این مطالعه، برخی یافته‌های غیرمنتظره نیز مشاهده شد. برای مثال، افزایش تعداد روزهای بستری با کاهش خطر مرگ ۳۰ روزه همراه بود که ممکن است نشان‌دهنده اثربخشی مراقبت‌های پزشکی طولانی‌تر باشد. این نتیجه غیرمنتظره نشان می‌دهد که شاید مدت‌زمان بیشتر بستری در بیمارستان بتواند به بهبود وضعیت بیماران کمک کند، هرچند که این موضوع نیازمند بررسی‌های بیشتر است. از جمله نقاط ضعف مطالعه نیز می‌توان به محدودیت‌هایی در دسترسی به برخی داده‌های بالینی که ممکن است تأثیرگذار باشند و محدودیت‌های زمانی و مکانی پژوهش که تنها بر روی داده‌های بیمارانی که در سال ۲۰۲۰ در بیمارستان روحانی بابل بستری بوده‌اند، انجام شده است می‌تواند دقت پیش‌بینی مدل‌ها را تحت‌تأثیر قرار دهد و بر تعمیم‌پذیری نتایج به سایر بیمارستان‌ها و زمان‌های مختلف تأثیر یافته‌های این پژوهش می‌تواند به بهبود فرایندهای درمانی و مدیریتی در بیماران نارسایی قلبی کمک کند. با استفاده از مدل‌های پیش‌بینی ارائه شده، پزشکان می‌توانند بیماران پرخطر را شناسایی کرده و درمان‌های متناسب را به‌موقع انجام دهند. این امر می‌تواند به کاهش مرگ‌ومیر و بهبود کیفیت زندگی بیماران منجر شود. همچنین، یافته‌های این پژوهش می‌تواند به توسعه راهبردهای جدید در مدیریت و درمان بیماران نارسایی قلبی کمک کند.

پژوهش حاضر نشان داد که مدل رگرسیون لجستیک با دقت بالایی می‌تواند مرگ ۳۰ روزه بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک را پیش‌بینی کند. با شناسایی ویژگی‌های مهم مانند سن، سطح لاکتات، دیابت و گلیسمی به‌منظور افزایش دقت پیش‌بینی، این مدل می‌تواند به‌عنوان ابزاری مؤثر در تصمیم‌گیری‌های بالینی و مدیریت بیماران پرخطر مورد استفاده قرار گیرد. این نتایج می‌تواند به بهبود فرایندهای درمانی و افزایش بقای بیماران کمک کند.

برای مطالعات آینده، می‌توان ارتباط بین فاکتورهای پیشگویی کننده مرگ بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک پس از ترخیص (مرگ ۳۰ روزه پس از ترخیص) را مورد ارزیابی قرارداد، تا عملکرد بهبود بیماران پس از ترخیص را افزایش داد. علاوه بر این پیش‌بینی ریسک مرگ سایر گروه نارسایی قلبی با استفاده از الگوریتم‌های انتخاب ویژگی الگوریتم‌های یادگیری ماشین پیشنهاد می‌گردد. جهت پیشنهاداتی در حوزه مدیریتی، باتوجه به اهمیت پیش‌بینی مرگ در برخی از بیماری‌های با ویژگی اورژانسی بودن درمان، استفاده از این متغیرهای مهم برای استفاده از آن‌ها در الگوریتم‌های یادگیری با در نظر گرفتن امکانات بیمارستان و بخش‌های درمانی می‌تواند منجر به ایجاد یک سیستم هدایت بهینه بیمار با در نظر گرفتن پیش‌بینی مرگ درست شود. این امر به‌ویژه در بیماران با شرایط ویژه و فوری

درمانی از اهمیت بالایی برخوردار است. به‌کارگیری چنین سیستم‌هایی می‌تواند فرایند ارجاع و مدیریت درمان بیماران را بهبود بخشیده و در نهایت منجر به افزایش کیفیت خدمات درمانی و کاهش ریسک مرگ‌ومیر در شرایط بحرانی شود. در این پژوهش پیش‌بینی دقیق و سریع مرگ برای بیماران نارسایی قلبی با تابلوی شوک کاردیوژنیک با استفاده از تجزیه و تحلیل آماری رگرسیون لجستیک انجام پذیرفته است. از آنجایی که بیماری نارسایی قلبی با تابلوی شوک کاردیوژنیک یک اورژانس پزشکی محسوب می‌شود و نیاز به درمان فوری دارد و درمان‌های انجام شده توسط پزشکان بر بقای بیماران تأثیر دارد، رگرسیون لجستیک با دقت بالایی مرگ این بیماران را پیش‌بینی می‌کند تا براین اساس نحوه ارجاع بیمار به بخش‌های دیگر درمانی را مدیریت کند. همچنین شناسایی ویژگی‌های مهم، ضمن پیش‌بینی دقیق‌تر و سریع‌تر مرگ در این دسته از بیماران با تریاژ زودهنگام و درمان به‌موقع در مراحل اولیه به کاهش احتمال مرگ‌ومیر این بیماران کمک می‌کند.

تقدیر و تشکر

بدین‌وسیله از تمامی افرادی که در انجام این پژوهش یاری کردند، قدردانی می‌گردد.

تعارض منافع

نویسندگان اعلام می‌دارند که هیچ‌گونه تعارض منافی در مطالعه حاضر وجود ندارد و این پژوهش فاقد حمایت مالی بوده است.

کد اخلاق

این مطالعه پس از تصویب در کمیته اخلاق معاونت پژوهشی دانشگاه علوم و فنون بابل با کد ۹۸/۳۴۲/۱ و با رعایت اصول اخلاقی تحقیقات پزشکی بر روی بیماران مبتلا به نارسایی قلبی با شوک کاردیوژنیک و بالای ۱۸ سال در بیمارستان روحانی شهر بابل انجام شد. تمام اطلاعات بیماران محرمانه بوده و فقط برای اهداف تحقیقاتی استفاده شده است. رضایت آگاهانه کتبی از تمام بیماران گرفته شده است. تمام اطلاعات جمع‌آوری شده به‌صورت بدون هویت بیماران ثبت شده است. این مطالعه طبق اصول اعلامیه هلسینکی و قوانین مربوط به تحقیقات پزشکی در کشور انجام شده است. همچنین، این پژوهش مستخرج از رساله مصوب معاونت پژوهشی دانشگاه علوم و فنون بابل مورخ ۱۳۹۸/۱۱/۳۰ می‌باشد.

سهام مشارکت نویسندگان

نقش فعال نویسنده اول و مسئول مقاله در طراحی مطالعه پژوهش و نوشتن مقاله، نقش نویسنده دوم تجزیه و تحلیل‌های مهندسی آن، نقش نویسنده سوم در گردآوری داده‌های پزشکی مقاله و تجزیه و تحلیل‌های پزشکی و نقش نویسنده چهارم در تجزیه و تحلیل و تفسیر داده‌های مقاله و درستی الگوریتم‌های آن و بازبینی و اصلاح موشکافانه مقاله می‌باشد.

References

- [1]. Bahrami B, Hosseini Shirvani MS. Diagnosis of heart disease by using datamining technique. Second National Conference on Applied Research in Computer Science and Information Technology; 2014 May 10-11; Tehran, Iran. Tehran: National Conference Publications; 2014. [Persian]
- [2]. Ponikowski P, Voors AA, Anker SD, Bueno H, Cleland JG, Coats AJ, et al. 2016 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. Eur Heart J 2016;37(27):2129-200. doi: 10.1093/eurheartj/ehw128
- [3]. Jentzer JC, Chonde MD, Dezfulian C. Myocardial dysfunction and shock after cardiac arrest. BioMed Research International 2015;2015(1):314796. <https://doi.org/10.1155/2015/314796>
- [4]. Killip III T, Kimball JT. Treatment of myocardial infarction in a coronary care unit: a two year experience with 250 patients. The American Journal of Cardiology. 1967;20(4):457-64. [https://doi.org/10.1016/0002-9149\(67\)90023-9](https://doi.org/10.1016/0002-9149(67)90023-9)
- [5]. Vahdatpour C, Collins D, Goldberg S. Cardiogenic Shock. J Am Heart Assoc 2019;8(8):e011991. doi: 10.1161/JAHA.119.011991.
- [6]. Reyentovich A, Thiele H. Clinical manifestations and diagnosis of cardiogenic shock in acute myocardial infarction. [2020 Nov 20]. Available from: <https://www.uptodate.com/contents/clinical-manifestations-and-diagnosis-of-cardiogenic-shock-in-acute-myocardial-infarction>



- [7]. Ostberg NP, Smilowitz NR. Emergency department presentation of patients diagnosed with cardiogenic shock. *Journal of the American College of Cardiology* 2022;79(9_Supplement):385.
- [8]. Krittanawong C, Virk HU, Hahn J, Al-Azzam FA, Greason K, Isath A, et al. Leveraging Machine Learning Models to Predict In-Hospital Mortality After Mitraclip. *Journal of the American College of Cardiology* 2021;77(18_Supplement_1):940.
- [9]. Awan SE, Bennamoun M, Sohail F, Sanfilippo FM, Chow BJ, Dwivedi G. Feature selection and transformation by machine learning reduce variable numbers and improve prediction for heart failure readmission or death. *PloS one* 2019;14(6):e0218760. <https://doi.org/10.1371/journal.pone.0218760>
- [10]. Rahman F, Finkelstein N, Alyakin A, Gilotra NA, Trost J, Schulman SP, et al. Using machine learning for early prediction of cardiogenic shock in patients with acute heart failure. *Journal of the Society for Cardiovascular Angiography & Interventions* 2022;1(3):100308. <https://doi.org/10.1016/j.jscai.2022.100308>
- [11]. Chang Y, Antonescu C, Ravindranath SR, Dong J, Lu M, Vicario F, et al. Machine Learning for Early Prediction of Cardiogenic Shock. *Journal of the American College of Cardiology* 2022;79(9_Supplement):278.
- [12]. Alotaibi FS. Implementation of machine learning model to predict heart failure disease. *International Journal of Advanced Computer Science and Applications* 2019;10(6). doi: 10.14569/IJACSA.2019.0100637
- [13]. Li X, Sousa-Casasnovas I, Devesa C, Juarez M, Fernandez-Aviles F, Martinez-Selles M. Predictors of in-hospital mortality among cardiogenic shock patients. Prognostic and therapeutic implications. *International Journal of Cardiology* 2016;224:114-8.
- [14]. König S, Pellissier V, Hohenstein S, Bernal A, Ueberham L, Meier-Hellmann A, Kuhlen R, Hindricks G, Bollmann A. Machine learning algorithms for claims data-based prediction of in-hospital mortality in patients with heart failure. *ESC Heart Failure* 2021;8(4):3026-36. <https://doi.org/10.1002/ehf2.13398>
- [15]. Acharya D. Predictors of outcomes in myocardial infarction and cardiogenic shock. *Cardiology in Review* 2018;26(5):255-66. doi: 10.1097/CRD.0000000000000190
- [16]. Ueki Y, Mohri M, Matoba T, Tsujita Y, Yamasaki M, Tachibana E, et al. Characteristics and predictors of mortality in patients with cardiovascular shock in Japan—results from the Japanese Circulation Society Cardiovascular Shock Registry—. *Circulation Journal* 2016;80(4):852-9. <https://doi.org/10.1253/circj.CJ-16-0125>
- [17]. Rong F, Xiang H, Qian L, Xue Y, Ji K, Yin R. Machine learning for prediction of outcomes in cardiogenic shock. *Frontiers in Cardiovascular Medicine* 2022;9:849688.
- [18]. Ali MM, Al-Doori VS, Mirzah N, Hemu AA, Mahmud I, Azam S, et al. A machine learning approach for risk factors analysis and survival prediction of Heart Failure patients. *Healthcare Analytics* 2023;3:100182. <https://doi.org/10.1016/j.health.2023.100182>
- [19]. Harjola VP, Lassus J, Sionis A, Køber L, Tarvasmäki T, Spinar J, et al. Clinical picture and risk prediction of short-term mortality in cardiogenic shock. *European Journal of Heart Failure* 2015;17(5):501-9. <https://doi.org/10.1002/ejhf.260>
- [20]. Chaggar PS, McKay E, Williams SG, Barnard J, Yonan N, Venkateswaran R, et al. Predictors of Survival in Critical Cardiogenic Shock Admissions to a Quaternary Heart Failure Unit in the UK. *The Journal of Heart and Lung Transplantation* 2017;36(4):S219-20.
- [21]. Demondion P, Fournel L, Golmard JL, Niculescu M, Pavie A, Leprince P. Predictors of 30-day mortality and outcome in cases of myocardial infarction with cardiogenic shock treated by extracorporeal life support. *European Journal of Cardio-Thoracic Surgery* 2014;45(1):47-54. <https://doi.org/10.1093/ejcts/ezt207>
- [22]. Jain A, Zongker D. Feature selection: Evaluation, application, and small sample performance. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 1997;19(2):153-8. doi: 10.1109/34.574797
- [23]. De Stefano C, Fontanella F, Marrocco C, Di Freca AS. A GA-based feature selection approach with an application to handwritten character recognition. *Pattern Recognition Letters* 2014;35:130-41. <https://doi.org/10.1016/j.patrec.2013.01.026>
- [24]. Malik A, Saggi MK, Rehman S, Sajjad H, Inyurt S, Bhatia AS, et al. Deep learning versus gradient boosting machine for pan evaporation prediction. *Engineering Applications of Computational Fluid Mechanics* 2022;16(1):570-87. <https://doi.org/10.1080/19942060.2022.2027273>
- [25]. Friedman JH. Greedy function approximation: a gradient boosting machine. *Annals of statistics* 2001;1189-232. doi:10.1214/aos/1013203451
- [26]. Bardenheier BH, Shefer A, Barker L, Winston CA, Sioneck CK. Public health application comparing multilevel analysis with logistic regression: immunization coverage among long-term care facility residents. *Annals of Epidemiology* 2005; 15(10): 749- 55. <https://doi.org/10.1016/j.annepidem.2005.03.001>
- [27]. Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters* 2006;27(8):861-74. <https://doi.org/10.1016/j.patrec.2005.10.010>
- [28]. Chawla NV. Data Mining for Imbalanced Datasets: An Overview. In: Maimon O, Rokach L. *Data Mining and Knowledge Discovery Handbook*. 1st ed. Boston: Springer; 2005. p. 853-67.

- [29]. Witten IH, Frank E, Hall AM. Data Mining: Practical Machine Learning Tools and Techniques. 3rd ed. Burlington, MA: Morgan Kaufmann; 2011
- [30]. Kubat M, Matwin S. Addressing the Curse of Imbalanced Training Sets: One Sided Selection. Proceedings of the Fourteenth International Conference on Machine Learning; 1997 Jul 8-12; Nashville, TN, USA. San Francisco: Morgan Kaufmann; 1997. p. 179-86.
- [31]. Davodian LW, Larsen JK, Povlsen AL, Josiassen J, Helgestad OK, Udesen NL, et al. Timing and causes of death in acute myocardial infarction complicated by cardiogenic shock (from the RETROSHOCK cohort). The American Journal of Cardiology 2022;171:15-22. <https://doi.org/10.1016/j.amjcard.2022.01.050>