



توسعه یک مدل یادگیری ماشین بانظارت برای پیش‌بینی مرگ بیماران مبتلا به شوک کاردیوژنیک ناشی از انفارکتوس قلبی

حجت امامی: دانشیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه بناب، بناب، ایران (*نویسنده مسئول) emami@ubonb.ac.ir

چکیده

زمینه و هدف: مطالعات متعددی نشان می‌دهند که میزان مرگ بیماران بستری شده به دلیل ابتلا به انفارکتوس میوکارد با افزایش قطعه ST (STEMI) در صورت وقوع شوک کاردیوژنیک (CS) به طور قابل ملاحظه‌ای افزایش می‌یابد. مشخصات دموگرافیک بیمار، نوع انفارکتوس قلبی، علائم بالینی، و روش‌های درمانی اتخاذ شده توسط پزشکان از عوامل مؤثر در مرگ بیماران STEMI-CS است. در این پژوهش، یک مدل ترکیبی یادگیری ماشین نظارتی با استفاده از الگوریتم بهینه‌سازی آنتی کرنا (ACVO) و ماشین بردار پشتیبان (SVM) برای پیش‌بینی مرگ بیماران بستری شده به علت عارضه STEMI-CS ارائه شده است. مدل پیشنهادی همچنین در تعیین مؤثرترین پارامترها در مرگ بیماران نیز مفید است.

روش کار: به منظور پیش‌بینی وضعیت بیماران مبتلا به STEMI-CS، روش ACVO-SVM ارائه شده است که با دریافت علائم بیمار، مشخصات دموگرافیک، و سابقه درمانی صورت گرفته، تشخیص می‌دهد که بیمار زنده خواهد ماند یا خیر. روش پیشنهادی از ترکیب الگوریتم ACVO و مدل SVM ساخته شده است. دلیل استفاده از الگوریتم ACVO، انتخاب مجموعه پارامترهای مؤثر در پیش‌بینی وضعیت بیماران و تعیین مقادیر بهینه برای پارامترهای مدل SVM است تا سیستم یادگیر کیفیت بیشتری در فرآیند آموزش داشته و کارایی مطلوبی در دسته‌بندی داده‌ها فراهم کند. برای ارزیابی مدل پیشنهادی از یک مجموعه داده حاوی اطلاعات ۴۱۰ بیمار بستری شده STEMI-CS در بیمارستان شهید مدنی دانشگاه علوم پزشکی تبریز، استفاده شده است. داده‌های جمع‌آوری شده مربوط به یک دوره ۱۰ ساله از سال ۱۳۸۸ تا ۱۳۹۷ است.

یافته‌ها: مدل پیشنهادی ACVO-SVM با مدل‌های پیش‌بینی کننده مطرحی همچون رگرسیون LASSO، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)، مدل گرادیان تقویت شدید (XGBoost) و مدل SVM استاندارد مقایسه شده است. نتایج آزمایش‌ها نشان می‌دهند که مدل ACVO-SVM در قیاس با همتایان خود از کارایی طبقه‌بندی بهتری برخوردار است. نتایج بر روی مجموعه داده آزمون نشان داد که مشخصه سن، جنسیت، نوع انفارکتوس قلبی، مصرف سیگار، مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری به‌عنوان مؤثرترین عوامل در مرگ بیماران STEMI-CS هستند.

نتیجه‌گیری: در این مطالعه، یک مدل یادگیری ماشین نظارتی برای تعیین وضعیت بیماران STEMI-CS ارائه شده است. نتایج به دست آمده حاکی از آن است که مدل پیشنهادی ACVO-SVM به سادگی بر روی مجموعه داده‌های آموزشی مختلف قابل آموزش بوده و توانایی مناسبی برای دسته‌بندی بیماران دارد. در این پژوهش، ارزیابی مدل‌ها بر روی یک مجموعه داده کوچک صورت گرفت. بنابراین، یکی از کارهای لازم برای بهبود این پژوهش، ارزیابی روش پیشنهادی و سایر مدل‌های همتا بر روی مجموعه داده‌های بزرگ به‌منظور تعیین نقاط قوت و ضعف آن‌ها است.

تعارض منافع: گزارش نشده است.

منبع حمایت‌کننده: حامی مالی ندارد.

شیوه استناد به این مقاله:

Emami H, Khani F. Development of a Supervised Machine Learning Model to Predict the Mortality in Patients with Cardiogenic Shock due to Myocardial Infarction. Razi J Med Sci. 2023;30(1): 151-166.

*انتشار این مقاله به‌صورت دسترسی آزاد مطابق با CC BY-NC-SA 3.0 صورت گرفته است.



Original Article

Development of a Supervised Machine Learning Model to Predict the Mortality in Patients with Cardiogenic Shock due to Myocardial Infarction

Hojjat Emami: Associate Professor, Department of Computer Engineering, Faculty of Engineering, University of Bonab, Bonab, Iran (* Corresponding author) emami@ubonab.ac.ir

Abstract

Background & Aims: According to the report released by world health organization (WHO), the ST-segment elevation myocardial infarction- cardiogenic shock (STEMI-CS) is one of the important factors in patient mortality within hospitals (1), (2), (3), (4). CS and its related complications need a huge financial and medical burden. Some researchers stated that high mortality and complication rates of STEMI-CS patients are associated with the lack of effective early preventive treatments. Given the risk of CS and the different risk factors associated with it, accurate clinical risk prediction tools need to be developed to accurately predict the onset of CS. Recently, researchers have been used various machine learning methods to predict the risk of mortality in STEMI-CS patients. Recently, machine learning (ML) methods were developed to establish predictive models to identify the in-hospital mortality risk of STEMI-CS patients. The existing methods achieved encouraging results; however, their performance is not ideal, and more effort is needed to improve the performance. The aim of this study is to present a hybrid machine learning method for predicting the risk of mortality in STEMI-CS patients. Our proposed method combines a powerful swarm intelligence strategy, anti-coronavirus optimization algorithm (ACVO) with support vector machine (SVM) in risk prediction phase. The proposed model is compared with standard support vector machine (SVM), least absolute shrinkage and selection operator (LASSO), and adaptive neuro fuzzy inference system (ANFIS) on a real-world benchmark dataset.

Methods: To predict the mortality status of STEMI-CS patients, we proposed the ACVO-SVM algorithm. The proposed method is a hybrid machine learning algorithm that combines the SVM with ACVO algorithm to identify the most effective parameters on the death of patients. The incentive mechanism of using ACVO is to optimally configure the parameters of SVM to improve its prediction performance. The proposed ACO-SVM is also useful in determining the optimal subset of features and treatment strategies that have the greatest impact in predicting the status of STEMI-CS patients. The proposed approach models the problem of predicting the status of patients as an optimization problem. In order to determine the most effective features in predicting the survival or death of STEMI-CS patients, the proposed ACVO-SVM model is trained with different combinations of patient characteristics and adopted treatment strategies. Then the best combination of features that provides the highest performance is considered as the superior combination. To select the most effective features, first all the features are considered for training the SVM model, then the remaining features are ignored one by one and the model with the same structure is trained. The models were compared based on accuracy, recall rate, F1 criterion. Finally, the best model is used to predict the status of patients in test dataset. The data set used to evaluate the proposed method includes 410 records of patients hospitalized due to STEMI-CS complications in Shahid Madani Hospital of Tabriz University of Medical Sciences. The collected data is related to a 10-year period from 2009 to 2018. This data set includes five categories of main characteristics, which are demographic characteristics, type of myocardial infarction, risk factors, clinical symptoms, and type of treatment used. It should be noted that 80% of the records of the data set are considered as training data, and 20% of the records are considered as the test data set. The proposed method is implemented in MATLAB software.

Results: Among $M1$ to $M5$ feature combination models, the experimental results show that the $M1$ model has higher performance on the training and test dataset in terms of predicting

Keywords

Myocardial Infarction, cardiogenetic shock, Supervised machine learning, Classification, ACVO-SVM

Received: 05/02/2023

Published: 08/04/2023

the patient's condition compared to other combination models. Model *M1* includes the combination of characteristics of age, sex, type of myocardial infarction, smoking, percutaneous vascular interventions and coronary artery bypass surgery. This shows that considering the mentioned features has the greatest effect on the final condition of STEMI-CS patients. The results are in line with previous studies (2), (3) in this field, which stated that age, gender, smoking, coronary artery bypass surgery and percutaneous vascular interventions have the greatest effect on the mortality rate of patients. The *M2* model ranks second in terms of efficiency in determining the status of patients, which shows that smoking also has a greater effect on the mortality of patients with STEMI-CS. Also, the *M3* model indicates that the use of the balloon pump treatment strategy, along with other demographic symptoms of the patient, history of heart infarction and smoking have a great effect on the mortality rate of patients. In summary, it can be concluded that the demographic characteristics of the patient such as age and gender, smoking, history of illness and the use of coronary bypass surgery and percutaneous vascular interventions have a great impact on the mortality of STEMI-CS patients. The proposed ACVO-SVM approach is compared with several other popular approaches, which include: standard SVM model, LASSO regression, ANFIS, and XGBoost. The experimental results justify that the proposed ACVO-SVM outperformed its counterparts.

Conclusion: In this study, a hybrid supervised machine learning model was presented to determine the status of patients with cardiogenic shock due to ST-segment elevation myocardial infarction. The proposed ACVO-SVM model uses an ACVO optimization algorithm to estimate the optimal parameters of the SVM model, making the SVM training process more efficient. The proposed model was evaluated using a dataset of patients with cardiogenic shock and the results were compared with the LASSO, ANFIS, XGBoost, and SVM models. The results showed that the proposed method worked well compared to other proposed classification models. We also found that age, gender, type of myocardial infarction, smoking, percutaneous vascular surgery, and coronary bypass transplantation surgery are the most effective factors for survival in STEMI-CS patients. In this research, the models were evaluated on a small dataset. Therefore, one of the necessary tasks to improve this research is to evaluate the proposed method and other counterpart models on large datasets to determine their strengths and weaknesses. Another limitation of this research is the lack of examination of all factors affecting the survival of STEMI-CS patients, such as blood sugar level and duration of ischemia. For this reason, it is necessary to investigate all factors affecting the mortality of STEMI-CS patients to improve the quality of classification and prediction of the final status of patients.

Conflicts of interest: None

Funding: None

Cite this article as:

Emami H, Khani F. Development of a Supervised Machine Learning Model to Predict the Mortality in Patients with Cardiogenic Shock due to Myocardial Infarction. *Razi J Med Sci.* 2023;30(1): 151-166.

***This work is published under CC BY-NC-SA 3.0 licence.**

مقدمه

شووک کاردیوژنیک (Cardiogenic shock-CS) (۱) و (۲) به عنوان یکی از مهم‌ترین فوریت‌های پزشکی، شامل ناتوانی قلب در پمپاژ خون غنی از اکسیژن به علت نارسایی شدید قلبی یا وقوع سکته قلبی است که منجر به آسیب جدی به عضله قلب می‌شود. این آسیب موجب می‌شود تا بطن چپ قلب که مسئول پمپاژ اصلی خون است به درستی کار نکند. شووک کاردیوژنیک به عنوان علت اصلی مرگ در بیماران حاد قلبی شناخته می‌شود، به ویژه در شرایطی که بیمار دچار اختلال در عملکرد بطن چپ به دلیل انفارکتوس میوکارد (Myocardial infarction) با افزایش قطعه‌ی ST (STEMI) است. درمان سریع شووک کاردیوژنیک در احیاء بیماران و جلوگیری از آسیب بیشتر به اندام‌های دیگر نقش اساسی دارد. بسته به شرایط بیمار، راهکارهای درمانی مختلفی برای شووک کاردیوژنیک ارائه شده‌اند که برخی از مهم‌ترین آن‌ها عبارت‌اند از: تنفس مصنوعی، استفاده از روش‌ها یا داروهایی برای انقباض و باز شدن عروق کرونری و استفاده از مکمل‌های اکسیژن (۲).

مطالعات صورت گرفته نشان می‌دهد، مرگ‌ومیر درون بیمارستانی در مورد بیماران مبتلا به STEMI-CS به میزان ۵۰٪ افزایش می‌یابد (۳). عوارض مربوط به STEMI-CS هزینه اقتصادی و پزشکی سنگینی دارد. برخی از محققان اعتقاد دارند که نرخ مرگ‌ومیر بیماران STEMI-CS به علت عدم انجام اقدامات پیشگیری و درمان زودهنگام است (۴). عوامل اصلی خطر منجر به مرگ بیماران STEMI-CS شامل سن بالا، جنسیت، سابقه انفارکتوس قلبی، نارسایی کلیه، قند خون و اقدامات درمانی ناکارآمد و با تأخیر است (۲ و ۳). علی‌رغم پیشرفت‌های چشمگیر در حوزه پزشکی برای درمان بیماران قلبی، درمان شووک کاردیوژنیک هنوز به عنوان یک چالش اساسی باقی مانده است و گزینه‌های درمانی محدودی برای آن وجود دارد (۵).

در مطالعات متعددی، محققان به بررسی کارایی راهکارهای مختلف درمان و عوامل مؤثر بر مرگ بیماران مبتلا به STEMI-CS پرداخته‌اند. جوانشیر و همکاران (۲) به بررسی روند مرگ درون بیمارستانی در بیماران STEMI-CS طی یک بازه ده ساله و ارتباط آن با میزان استفاده از راهبردهای درمانی جدید پرداخته‌اند. هدف

آن‌ها بررسی فاکتورهای مؤثر بر مرگ بیماران و تأثیر روش‌های نوین برای درمان بیماران است. بررسی آن‌ها نشان داد که راهکارهای درمانی مورد استفاده در مقایسه با سال‌های قبل پیشرفت چندانی نداشته است و اغلب بیماران تحت Revascularization قرار نگرفته‌اند. مطالعه صورت گرفته بر لزوم استفاده از روش‌های نوین تأکید دارد. در مرجع (۵)، به بررسی روش‌های درمانی شووک کاردیوژنیک پرداخته شده است. بررسی آن‌ها نشان داد که روش درمانی revascularization زودهنگام مرگ‌ومیر بیماران STEMI-CS را کاهش می‌دهد، با این حال، نرخ مرگ‌ومیر همچنان بالاست و راهکارهای درمانی محدود است. در این مطالعه، عنوان شد که تشخیص زودهنگام و اتخاذ راهبرد درمانی مناسب شانس زنده ماندن بیماران STEMI-CS را افزایش می‌دهد. در پژوهش‌های دیگر (۴ و ۶)، محققان به بررسی روش‌های مختلف درمانی شووک کاردیوژنیک پرداخته‌اند. یافته‌های محققان نشان می‌دهد که میزان مرگ‌ومیر در بیماران مبتلا به شووک کاردیوژنیک در محدوده ۴۰ تا ۵۰٪ در طول دو دهه گذشته باقی مانده است و راهبردهای درمانی پیشرفت قابل توجهی نداشته‌اند. بای و همکاران (۳) از روش‌های یادگیری ماشین نظیر الگوریتم گرادینت تقویت شدید (Extreme gradient boosting (XGBoost)، رگرسیون خطی (Logistic regression) (LR)، ماشین بردار پشتیبان (Support vector machine) (SVR) و رگرسیون Least absolute shrinkage and selection) LASSO (operator) برای پیش‌بینی ریسک کاردیوژنیک در بیماران پذیرش‌شده‌ی مبتلا به STEMI استفاده کردند. یافته‌های آن‌ها نشان داد که مدل LASSO در مقایسه با هم‌تایان خود به کارایی مطلوبی در پیش‌بینی ریسک CS دست یافته است. آنچه به عنوان یک نتیجه آشکار از مطالعات صورت گرفته حاصل می‌شود این است که مقابله با شووک کاردیوژنیک هنوز به عنوان یک چالش اساسی مطرح است.

یادگیری ماشین به عنوان یکی از شاخه‌های مطرح هوش مصنوعی، کاربردهای فراوانی در حوزه پزشکی دارد. این روش‌ها با تقلید رفتار انسان سعی دارند تا سیستمی هم سطح با هوش انسان و حتی فراتر از آن ایجاد کنند (۱۹). یادگیری نظارتی (Supervised)

است. به همین منظور، روش ACVO-SVM ارائه شده است که با دریافت علائم بیمار، مشخصات دموگرافیک و سابقه درمانی صورت گرفته، تشخیص می‌دهد که بیمار زنده خواهد ماند یا خیر. روش پیشنهادی از ترکیب الگوریتم بهینه‌سازی آنتی کرونا ویروس (Anti-ACVO) (coronavirus optimization algorithm) و مدل SVM ساخته شده است. دلیل استفاده از الگوریتم ACVO، تعیین مقادیر بهینه برای مدل پیش‌بینی‌کننده SVM است تا سیستم یادگیر کیفیت بیشتری در فرآیند آموزش داشته و کارایی مطلوبی در دسته‌بندی داده‌ها فراهم کند. به‌طور خلاصه، نوآوری‌های این پژوهش عبارت‌اند از:

- ترکیب الگوریتم ACVO با مدل SVM برای توسعه روش ACVO-SVM برای پیش‌بینی وضعیت زنده ماندن یا مرگ بیماران مبتلا به STEMI-CS. مدل پیشنهادی در تعیین زیرمجموعه بهینه از ویژگی‌ها و راهبردهای درمانی که بیشترین تأثیر را در پیش‌بینی وضعیت بیماران STEMI-CS دارد، مفید است.
- استفاده از الگوریتم ACVO برای تنظیم بهینه پارامترهای SVM برای بهبود عملکرد پیش‌بینی مدل

یکی از راهکارهای اصلی در یادگیری ماشین (learning) است که با استفاده از داده‌های آموزشی یک مدل یادگیرنده ایجاد می‌شود به‌نحوی که سیستم بتواند تابعی از ورودی به خروجی را فراگیرد. سپس با استفاده از مدل یادگیر سیستم سعی دارد تا در مورد داده‌های مشاهده نشده، تصمیم لازم را اتخاذ کند. از جمله مدل‌های معروف در یادگیری نظارتی می‌توان به درخت تصمیم (Decision tree) (DT)، SVM، بیز ساده (Naive Bayes) (NB)، LR، شبکه‌های عصبی مصنوعی (Artificial neural networks) (ANNs) و سیستم استنتاج فازی-عصبی تطبیقی (Adaptive neuro-fuzzy inference system) (ANFIS) اشاره کرد. جدول ۱ لیستی از مدل‌های پیش‌بینی ریسک STEMI-CS را نشان می‌دهد.

یکی از چالش‌های اساسی در استفاده از این دسته‌بندها تنظیم دقیق پارامترهای این مدل‌ها است به‌نحوی که به بهترین شکل آموزش ببینند و کارایی مطلوبی در فرآیند دسته‌بندی داده‌ها داشته باشند. در این پژوهش، با استفاده از مدل‌های یادگیری ماشین نظارتی، یک سیستم دسته‌بند ارائه شده است که در پیش‌بینی مرگ بیماران مبتلا به STEMI-CS مفید

جدول ۱- لیست روش‌های تشخیص ریسک مرگ در بیماران STEMI-CS

مرجع	الگوریتم مورد استفاده
(۷)	شبکه‌های عصبی مصنوعی (ANN)
(۸)	الگوریتم نزدیکترین همسایگی (k-NN)
(۹)	ماشین بردار پشتیبان (SVM)
(۱۰)	SVM
(۱۱)	شبکه عصبی کانولوشن (CNN)
(۱۲)	k-NN
(۱۳)	SVM
(۱۴)	CNN-LSTM
(۱۵)	شبکه Residual (ResNet)
(۱۶)	ANN
(۱۷)	CNN
(۱۸)	شبکه حافظه طولانی کوتاه مدت (LSTM)
(۳)	انقباض کمترین قدر مطلق (LASSO)
(۲۰)	الگوریتم جنگل تصادفی (RF)
(۲۱)	CNN
(۲۲)	Extra Tree ML
(۲۳)	ANN
(۲۴)	CNN

$$f(x) = w \varphi(x) + b \quad (1)$$

$$\begin{aligned} & \text{minimize} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) \\ & \text{subject to} \quad \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \zeta_i \\ \langle w, x_i \rangle - b - y_i \leq \varepsilon + \zeta_i^* \\ \zeta_i, \zeta_i^* \geq 0 \end{cases} \quad (2) \end{aligned}$$

پارامتر w نشان‌دهنده بردار نرمال، b یک عدد اسکالر، φ تابع کرنل است. متغیرهای ζ_i و ζ_i^* نشان‌دهنده پارامترهای کمبود (Slack parameters) است که حد پایین و بالای انحرافات اضافی را نشان می‌دهند. دلیل استفاده از متغیرهای کمبود این است که الگوریتم SVM دنبال مرزی باشد که کمترین خطای دسته‌بندی را داشته باشد. متغیر C بیانگر ضریب جریمه خطا است که برای تنظیم اختلاف بین عبارت تنظیم (Regularization) و ریسک تجربی در نظر گرفته شده است. $\frac{1}{2} \|w\|^2$ نشان‌دهنده عبارت تنظیم است. ε تابع خطا (Loss function) است که دقت داده‌های آموزشی را تعیین می‌کند. اگر متغیر w را به صورت زیر در نظر بگیریم:

$$w = \sum_{i=1}^N (\alpha_i - \alpha_i^*) x_i \quad (3)$$

در این صورت با استفاده از ضرایب لاگرانژ و محدودیت‌های بهینه، رابطه (۱) را می‌توان به صورت زیر تعریف کرد:

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (4)$$

$K(x, x_i)$ نشان‌دهنده تابع کرنل است که از طریق ضرب دو بردار داخلی x_i و x_j در فضای ویژگی $\varphi(x_i)$ و $\varphi(x_j)$ به دست می‌آید.

$$K(x, x_i) = \varphi(x_i) \times \varphi(x_j) \quad (5)$$

در سال‌های اخیر، توابع کرنل مختلفی توسعه یافته است. از بین این توابع، تابع پایه چندجمله‌ای (Polynomial basis function) (PBF)، سیگموئید و تابع پایه شعاعی (RBF). در این پژوهش، از تابع کرنل RBF در الگوریتم SVM استفاده کرده‌ایم زیرا پیکربندی آسانی دارد و از کارایی مطلوبی در قیاس با سایر توابع کرنل برخوردار است. تابع RBF به صورت زیر

SVM

• ارزیابی مدل پیشنهادی بر روی مجموعه داده آزمون شامل بیماران STEMI-CS و مقایسه آن با سایر روش‌های مطرح پس‌از این مقدمه کوتاه، در بخش ۲ به تشریح مدل SVM پرداخته شده است. بخش ۳ به توصیف کلی الگوریتم ACVO اختصاص دارد. بخش ۴ به تشریح عملکرد روش پیشنهادی ACVO-SVM می‌پردازد. در بخش ۵، نتایج آزمایش‌ها و بحث بر روی نتایج آورده شده است. در نهایت، بخش ۶ به نتیجه‌گیری و ارائه برخی کارهای آتی می‌پردازد.

روش کار

ماشین بردار پشتیبان (SVM): مدل SVM (۲۶) یک روش یادگیری ماشین با نظارت است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌شود. SVM در قیاس با شبکه‌های عصبی مصنوعی از کارایی بالاتری برخوردار است. اساس کار مدل SVM بر مبنای تقسیم‌بندی خطی داده‌ها است که در آن هدف یافتن بهترین خط یا ابر صفحه جدا ساز است که حاشیه امن بیشتری ایجاد کند. الگوریتم SVM داده‌ها را به یک فضای چندبعدی نگاشت می‌کند به نحوی که داده‌ها به صورت خطی یا ابر صفحه قابل تفکیک باشند (۲۷). سپس با یافتن خطوط پشتیبان سعی در یافتن معادله خطی دارد که بیشترین حاشیه امن را بین دسته‌ها ایجاد کند. فرض کنید $D = \{X_i, y_i\}_{i=1}^n$ نشان‌دهنده مجموعه داده‌ای با n شیء داده باشد که باید دسته‌بندی شود، $X_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ نشان‌دهنده شیء داده i با m ویژگی، و y_i برچسب رکورد داده X_i است. هدف الگوریتم SVM، ساخت یک مدل طبقه‌بند با استفاده از ابر صفحه‌های جداکننده برای تقسیم اشیاء داده در مجموعه داده D به تعدادی کلاس مجزا است. ابر صفحه (Hyperplane) جداکننده توسط برخی از نقاط داده در فضای حالت ساخته می‌شود که بردارهای پشتیبان نامیده می‌شوند. هدف پیشینه کردن فاصله بین ابر صفحه جداکننده و نقاط داده از طریق حل روابط زیر است:

را افزایش داده و ارتبانات را محدود کند. در مرحله قرنطینه، الگوریتم افراد مشکوک را برای جلوگیری از شیوع بیماری، قرنطینه می‌کند. برخی از افراد جامعه که در معرض ویروس قرار گرفته‌اند، باید قرنطینه شوند تا مشخص شود که مبتلا شده‌اند یا خیر. افراد باید به مدت معینی قرنطینه شوند تا تأثیر ویروس بر روی آن‌ها مشخص شود.

برخی از افرادی که پروتکل‌های بهداشتی را رعایت نکرده‌اند و به ویروس آلوده شده‌اند باید تحت مراقبت قرار گیرند تا بهبودی کامل حاصل گردد. در مرحله ایزوله کردن، الگوریتم از افراد آلوده مراقبت می‌کند تا سلامت خود را بازیابی کنند. هدف نهایی الگوریتم یافتن بهترین و سالم‌ترین فرد است که به‌عنوان الگوی جامعه در رعایت اصول بهداشتی شناخته می‌شود. الگوریتم به‌طور مکرر عملگرهای فاصله‌گذاری اجتماعی، قرنطینه و بستری را بر روی جمعیت اولیه اعمال می‌کند تا به بهترین فرد برسد تا آن را به‌عنوان جواب بهینه مسئله بهینه‌سازی معرفی کند.

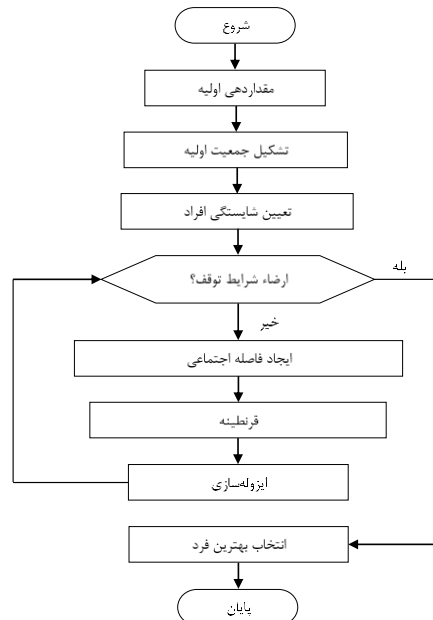
مدل ترکیبی ACVO-SVM: مدل ترکیبی ACVO-SVM برای بهینه‌سازی مقادیر پارامترهای الگوریتم SVM و انتخاب مجموعه پارامترهای مؤثر در پیش‌بینی وضعیت بیماران STEMI-CS پیشنهاد شده است. شکل

فرموله بندی شده است.

$$K(x, x_i) = \exp(-\|x_i - x\| / 2\gamma^2) \quad (6)$$

تنظیم دقیق پارامترهای C ، γ و ϵ برای بهبود کارایی دسته‌بندی الگوریتم SVM بسیار ضروری است. در این پژوهش، الگوریتم آنتی کرونا برای تخمین مقادیر بهینه برای پارامترهای SVM ارائه شده است.

الگوریتم بهینه‌سازی آنتی کرونا (ACVO): الگوریتم ACVO (۲۸) یک استراتژی هوش جمعی است که توسط امامی در سال ۲۰۲۲ برای حل مسائل عددی و مهندسی ارائه شده است. منبع الهام این الگوریتم، الگوی رفتاری افراد جامعه در رعایت پروتکل‌های بهداشتی برای حفظ سلامت و کاهش سرایت ویروس COVID-19 است. شکل ۱ فلوجارت الگوریتم ACVO را نشان می‌دهد. الگوریتم ACVO، یک استراتژی چندعاملی است که در آن هر عامل یک فرد در جامعه است که با رعایت پروتکل‌های بهداشتی سعی در حفظ سلامت خود و کاهش سرعت انتشار ویروس دارد. الگوریتم کار خود را با یک جمعیت اولیه از عامل‌های جستجو آغاز می‌کند. این الگوریتم از سه مرحله اصلی تشکیل شده است: فاصله‌گذاری اجتماعی، قرنطینه و ایزوله‌سازی. در مرحله فاصله‌گذاری اجتماعی، الگوریتم تلاش می‌کند تا فاصله فیزیکی ایمن بین افراد



شکل ۱- فلوجارت الگوریتم آنتی کرونا

میانگین مربعات خطا (MSE) حاصل از روش اعتبارسنجی متقابل 10-fold برای الگوریتم SVM سنجیده شده است. تابع شایستگی به صورت زیر تعریف شده است:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{X}_i - X_i)^2 \quad (11)$$

در رابطه بالا، n بیانگر تعداد داده های موجود در مجموعه داده، \hat{X}_i برچسب پیش بینی شده را نشان می دهد و X_i برچسب موجود در مجموعه داده آموزشی را نشان می دهد. اعضای جمعیت که مقدار MSE کمتری کسب کنند شایستگی بیشتری خواهند داشت.

فاصله گذاری: پس از تشکیل جمعیت اولیه، الگوریتم سعی می کند تا فاصله اجتماعی را در بین اعضای جمعیت فراهم کند. بدیهی است که تمامی افراد در فاصله گذاری اجتماعی شرکت نمی کنند و فقط بخشی از جمعیت در این کار شرکت می کنند. در هر مرحله به تعداد m نفر از اعضای جمعیت در فاصله گذاری اجتماعی شرکت می کنند تا تعاملات اجتماعی خود را کاهش دهند. رابطه زیر برای مدل سازی فرآیند فاصله گذاری اجتماعی پیشنهاد شده است:

$$P_i^{t+1} = P_i^t + D_1^t + D_2^t \quad (12)$$

در رابطه بالا، t نشان دهنده تکرار جاری الگوریتم است. D_1 فاصله گذاری در مجاورت فرد P_i و سایر افراد را کنترل می کند. D_2 فاصله بین فرد P_i و بهترین فرد جمعیت P^* را کنترل می کند. هدف D_1 و D_2 هدایت فرد به منطقه ایمن است. D_1 به صورت زیر تعریف شده است:

$$D_1^t = \alpha_{ij}^t \times sd_{ij}^t \times U(-1,1) \quad (13)$$

$U(-1,1)$ یک عدد تصادفی یکنواخت با مقدار +1 یا -1 است. sd_{ij}^t حداقل فاصله فیزیکی بین P_i و هر فرد دیگر در جمعیت است که به صورت زیر تعریف شده است:

$$sd_{ij}^t = \begin{cases} \Delta - d_{ij}^t & \text{if } (d_{ij}^t < \Delta) \\ d_{ij}^t & \text{if } (d_{ij}^t \geq \Delta) \end{cases} \quad \text{where} \quad (14)$$

$d_{ij}^t = \|P_i^t - P_j^t\|$ فاصله فعلی بین P_i و P_j را نشان می دهد. Δ

۲ فلوچارت مدل ACVO-SVM را نشان می دهد. در ادامه به بررسی مؤلفه های مدل پیشنهادی پرداخته شده است.

تشکیل جمعیت اولیه: همان گونه که در شکل ۲ نشان داده شده است، مرحله اول در مدل ACVO-SVM، تشکیل جمعیت اولیه است که به صورت زیر مدل سازی شده است.

$$P = [P_1, P_2, \dots, P_N] \quad (7)$$

از آنجایی که بهینه سازی پارامتر SVM و انتخاب ویژگی های مؤثر بیماران باید به طور همزمان در نظر گرفته شود، هر عضو جمعیت $P_i \in P$ از چندین ویژگی بیمار و ترکیب پارامترهای SVM تشکیل شده است. هر عضو جمعیت به صورت زیر مدل سازی شده است:

$$P_i = \{p_1, p_2, p_3, f_1, f_2, \dots, f_{24}, s\} \quad (8)$$

متغیرهای p_1 ، p_2 و p_3 اعداد اعشاری هستند که حاوی مقادیر کاندید برای پارامترهای C ، γ و ϵ هستند. مقادیر اولیه این متغیرها به صورت تصادفی مقداردهی می شوند. مرز جستجو برای متغیر p_1 برابر $[0, 100]$ ، برای متغیرهای p_2 و p_3 برابر $[0, 1]$ است. هر کدام از متغیرهای p_{ij} به صورت زیر مقداردهی می شود:

$$p_{ij} = r \times (p_{\max j} - p_{\min j}) + p_{\min j} \quad (9)$$

r یک عدد تصادفی با توزیع یکنواخت در بازه $[0, 1]$ است، $p_{\max j}$ و $p_{\min j}$ به ترتیب کران پایین و بالای متغیر p_i است. هر کدام از ویژگی های f_j یک متغیر باینری با مقدار ۱ است اگر ویژگی f_j برای ساخت مدل در نظر گرفته شود و زمانی که وجود ویژگی نادیده گرفته شود مقدار آن ۰ خواهد بود. متغیر پرچم s دارای یک مقدار صحیح بوده که نشان دهنده وضعیت سلامت فرد است. متغیر s به صورت زیر تعریف شده است:

$$s = \begin{cases} 1 & \text{if } P_i \text{ is healthy} \\ 0 & \text{if } P_i \text{ is in quarantine} \\ -1 & \text{if } P_i \text{ is in isolation} \end{cases} \quad (10)$$

ارزیابی جمعیت: پس از مقداردهی اعضای جمعیت، شایستگی هر فرد با تابع شایستگی ارزیابی می شود. در این الگوریتم، فرض شده است که افراد سالم دارای شایستگی بیشتری هستند. شایستگی هر فرد به وسیله

قرنطینه شوند. پس از مدت معین، اگر وضعیت جسمانی فرد بهتر از قبل باشد و یا تغییری نداشته باشد، فرد سالم تلقی می‌شود. در غیر این صورت فرد باید بستری شده و تحت مداوا قرار گیرد. در مرحله قرنطینه، الگوریتم به صورت تصادفی چند متغیر از فرد مشکوک را انتخاب می‌کند و سپس با استفاده از رابطه زیر هر متغیر انتخاب شده را بروز رسانی می‌کند.

$$p_{ik}^{t+1} = p_{ik}^t + U(-1, +1) \times rand \quad (17)$$

متغیر $rand$ یک عدد تصادفی در بازه $[0, 1]$ تولید می‌کند. p_{ik} بیانگر متغیر k در فرد P_i است.

ایزوله کردن: در مرحله ایزوله کردن، افرادی که به کرونا مبتلا شوند، از جمعیت جدا شده و تحت مداوا قرار می‌گیرند. در الگوریتم آنتی‌کرونا از روش پلاسما درمانی (۲۹) برای مداوای بیماران استفاده شده است. برای شبیه‌سازی این روش درمانی، الگوریتم ابتدا تعدادی عنصر از هر فرد را انتخاب می‌کند و آن‌ها را با

فاصله فیزیکی ایمن بین افراد در تکرار t است. مقدار Δ بر اساس پروتکل‌های کنترل کرونا تعیین می‌شود. α'_{ij} نرخ سرایت از فرد P_j به فرد P_i را نشان می‌دهد، که به صورت زیر تعریف شده است:

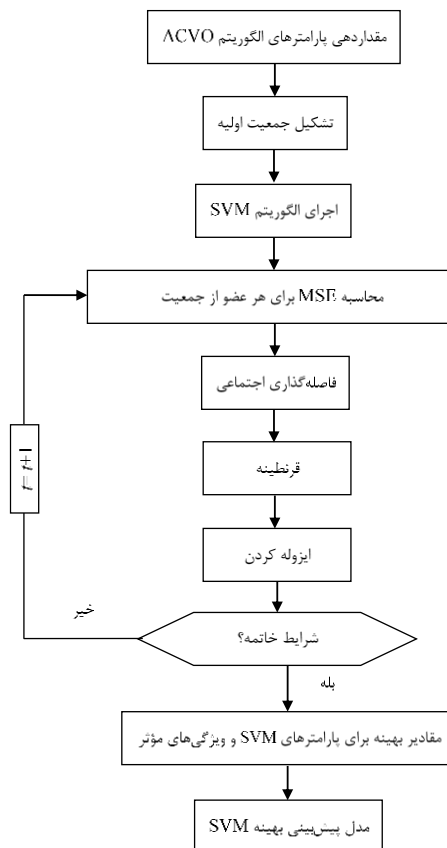
$$\alpha'_{ij} = e^{-\left(\frac{d_{ij}}{\Delta}\right)} \quad (15)$$

D_2^t به صورت زیر تعریف شده است:

$$D_2^t = \beta_{ij}^t \times V \times (P^* - P_i^t) \quad (16)$$

در رابطه بالا، β_{ij}^t نرخ سرایت بیماری از فرد P^* به فرد P_i است. V اندازه گام حرکت است که میزان حرکت P_i به سمت P^* را کنترل می‌کند. مقدار متغیر V بر اساس توزیع لوی محاسبه می‌شود. P^* بهترین عضو جمعیت در تکرار t است.

قرنطینه: در مرحله قرنطینه، افرادی که مشکوک به بیماری هستند به مدت q_d قرنطینه می‌شوند تا تمام جمعیت را مبتلا نکنند. برای پیاده‌سازی قرنطینه ابتدا به تعداد q فرد ضعیف از جمعیت انتخاب می‌شوند تا



شکل ۲- مدل پیشنهادی ACVO-SVM

رابطه زیر بروز رسانی می‌کند. فرد شامل مقادیر بهینه برای پارامترهای SVM و ویژگی‌های مؤثر در مرگ‌ومیر بیماران مبتلا به STEMI-CS است.

$$p_{ij}^{t+1} = \frac{1}{2}(p_{ij}^t + (\gamma \times p_j^{*t})) \quad (18)$$

در این رابطه، p_{ij}^t نشان‌دهنده عنصر z در فرد P_i در تکرار t است. p_j^{*t} نشان‌دهنده عنصر z از بهترین فرد است. γ میزان تأثیر بهبود p_j^{*t} بر روی متغیر p_{ij}^t نشان می‌دهد. پس از طی دوره بستری، اگر وضعیت جسمانی فرد بهبود یابد، فرد مرخص شده و به جمعیت جاری اضافه می‌شود در غیر این صورت دوره بستری تمدید می‌شود. الگوریتم مراحل فاصله‌گذاری اجتماعی، قرنطینه و ایزوله کردن را به تعداد معین که توسط کاربر تعیین می‌شود، تکرار می‌کند تا در نهایت شرایط خاتمه ارضاء شوند. در نهایت، بهترین فرد جمعیت انتخاب شده و به‌عنوان جواب بهینه معرفی می‌شود (۲۸). بهترین

یافته‌ها

مجموعه داده استفاده‌شده برای ارزیابی روش پیشنهادی شامل ۴۱۰ رکورد درباره بیماران بستری‌شده به دلیل عارضه STEMI-CS در بیمارستان شهید مدنی دانشگاه علوم پزشکی تبریز است (۲). ۸۰٪ از رکوردهای مجموعه داده به‌عنوان داده‌های آموزشی و ۲۰٪ از رکوردها به‌عنوان مجموعه داده آزمون در نظر گرفته شده‌اند. روش پیشنهادی ACVO-SVM با چندین روش مطرح دیگر مورد مقایسه قرار گرفته است که عبارت‌اند از: مدل استاندارد SVM، رگرسیون LASSO،

جدول ۲- مشخصات مجموعه داده مورداستفاده

کد	دسته ویژگی	مقدار ویژگی	تعداد	درصد
f_1	سن	[۲۰-۹۹]	۴۱۰	۱۰۰
f_2	جنسیت	مرد	۲۴۶	۰/۶۰
		زن	۱۶۴	۰/۴۰
f_3	نوع انفارکتوس قلبی	قدامی	۲۶۰	۰/۶۳
		غیرقدامی	۱۵۰	۰/۳۷
f_4	عوامل خطر	دیابت	۱۵۰	۰/۳۷
f_5		فشارخون بالا	۲۲۷	۰/۵۵
f_6		مصرف سیگار	۱۱۵	۰/۲۸
f_7		نارسایی کلیه	۳۱	۰/۰۸
f_8		سابقه‌ی جراحی بای پس عروق کرونری	۱۲	۰/۰۳
f_9		سابقه‌ی انفارکتوس میوکارد	۲۷	۰/۰۷
f_{10}	علائم بالینی	درد قفسه‌ی سینه	۳۸۵	۰/۹۴
f_{11}		علائم نارسایی و تنگی نفس	۱۰۲	۰/۲۵
f_{12}		اختلال هوشیاری	۸۳	۰/۲۰
f_{13}	درمان مورداستفاده	ترومبولیتیک	۲۱۵	۰/۵۲
f_{14}		تهویه‌ی مکانیکی	۳۳۶	۰/۸۲
f_{15}		درمان دارویی بدون ترومبولیتیک	۲۴۴	۰/۶۰
f_{16}		مصرف داروهای مهارکننده‌ی IIB/IIIA	۱۴۲	۰/۳۵
f_{17}		اینوتروپ	۲۲۹	۰/۵۶
f_{18}		مداخلات عروقی از راه پوست	۱۶۴	۰/۴۰
f_{19}		جراحی بای پس عروق کرونری	۴۰	۰/۱۰
f_{20}		بالون پمپ	۷۹	۰/۱۹
f_{21}		revascularization رگ مقصر	۱۳۸	۰/۳۴
f_{22}		revascularization کامل	۲۶	۰/۰۶

جدول ۳- پنج مدل ترکیبی از ویژگی‌ها با بالاترین کارایی در دسته‌بندی بیماران STEMI-CS

ویژگی‌ها و روش‌های درمانی	مدل ترکیب ویژگی
$f_1, f_2, f_3, f_6, f_{18}, f_{19}$	M1
$f_1, f_2, f_4, f_6, f_{18}, f_{19}$	M2
$f_1, f_2, f_3, f_4, f_6, f_{20}$	M3
$f_1, f_2, f_3, f_6, f_{18}, f_{19}$	M4
$f_1, f_2, f_4, f_{16}, f_{19}, f_{20}$	M5

جدول ۴- مقایسه عملکرد مدل ACVO-SVM با ترکیبات مختلف ویژگی‌ها بر روی مجموعه داده‌های آموزشی و آزمون

مجموعه داده آزمون			مجموعه داده آموزشی			مدل ترکیب ویژگی
F1	دقت	بازخوانی	F1	دقت	بازخوانی	
۵۸/۸	۸۱/۴	۴۶/۱	۵۹/۱	۸۴/۹	۴۵/۳	M1
۵۸/۴	۸۱/۱	۴۵/۶	۵۸/۶	۸۴/۵	۴۴/۸	M2
۵۷/۱	۸۰/۳	۴۴/۳	۵۶/۲	۸۳/۷	۴۲/۳	M3
۵۵/۶	۷۹/۵	۴۲/۸	۵۵/۳	۸۱/۹	۴۱/۷	M4
۵۴/۱	۷۸/۹	۴۱/۲	۵۴/۳	۸۱/۳	۴۰/۸	M5

به‌دست‌آمده با روش پیشنهادی ACVO-SVM را با استفاده از ترکیبات مختلف ویژگی‌ها بر روی مجموعه داده آموزشی و آزمون نشان می‌دهد. نتایج آزمایش‌ها نشان می‌دهند که مدل M1 نسبت به سایر ترکیبات ویژگی‌ها کارایی مطلوبی بر روی مجموعه داده آموزشی و آزمون از نظر پیش‌بینی وضعیت بیماران دارد. مدل‌های M2 و M3 به ترتیب در جایگاه دوم و سوم قرار دارند. لازم به ذکر است که مدل‌ها به ترتیب کارایی مرتب و شماره‌گذاری شده‌اند.

شکل ۴ تأثیر هر کدام از ویژگی‌ها را در مدل M1 بر روی کارایی دسته‌بندی بیماران STEMI-CS برحسب معیار F1 نشان می‌دهد. برای رسم شکل ۴ ابتدا فقط یکی از ویژگی‌ها در نظر گرفته شده و سپس یک‌به‌یک ویژگی‌های دیگر اضافه شدند. همان‌گونه که در شکل دیده می‌شود با افزودن شدن ویژگی جنسیت میزان کیفیت تفکیک بیماران افزوده شده و این موضوع با افزودن شدن سایر ویژگی‌ها نیز صدق می‌کند. با افزودن شدن دو ویژگی مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری مقدار معیار F_1 به میزان قابل توجهی افزایش یافته است که نشان می‌دهد این دو راهبرد درمانی نقش بسزایی در احیاء بیماران STEMI-CS دارد. همچنین نتایج آزمایش‌ها نشان داد که جنسیت مؤنث و سن بالا در بالا رفتن احتمال مرگ

ANFIS و XGBoost. در روش پیشنهادی ACVO-SVM، اندازه جمعیت اولیه برابر ۵۰ و تعداد تکرار الگوریتم ACVO برابر ۳۰۰۰ بار محاسبه تابع هدف در نظر گرفته شده است. همچنین، مقادیر بهینه برای پارامترهای C ، γ و ϵ در مدل SVM به ترتیب برابر ۱، ۰/۰۵ و ۰/۰۵ پیکربندی شده‌اند.

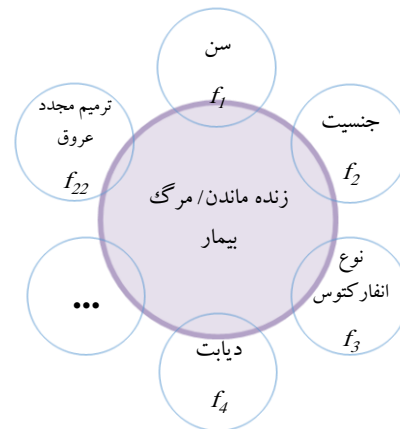
به‌منظور تعیین مؤثرترین فاکتورها در پیش‌بینی زنده ماندن یا مرگ بیماران STEMI-CS، مدل پیشنهادی ACVO-SVM با ترکیبات مختلف ویژگی‌های بیمار و راهکارهای درمانی اتخاذشده آموزش داده می‌شود. سپس بهترین ترکیب ویژگی‌ها که بیشترین کارایی را فراهم می‌کند به‌عنوان ترکیب برتر در نظر گرفته می‌شود. برای انتخاب مؤثرترین ویژگی‌ها، ابتدا تمامی ویژگی‌ها برای آموزش مدل SVM در نظر گرفته می‌شوند، سپس ویژگی‌های باقی‌مانده یک‌به‌یک نادیده گرفته شده و مدل با همان ساختار آموزش داده می‌شود. شکل ۳ نشان می‌دهد که چگونه ترکیبات ویژگی‌ها برای آموزش مدل ساخته می‌شوند. توجه به این نکته لازم است که در شکل ۳، تنها چند مدل از ترکیبات ارائه شده است و مدل‌های باقی‌مانده نادیده گرفته شده‌اند. در جدول ۳، پنج مدل ترکیبی که کارایی بالایی در پیش‌بینی وضعیت بیماران STEMI-CS دارند آورده شده و سایر مدل‌ها نادیده گرفته شده‌اند. جدول ۴ نتایج

جدول ۵- مقایسه عملکرد مدل‌های پیش‌بینی کننده بر روی مجموعه داده‌های آموزشی و آزمون

مدل	مجموعه داده آموزشی		مجموعه داده آزمون	
	دقت	F1	دقت	F1
LASSO	۸۴/۲	۴۳/۱	۸۰/۹	۴۴/۲
ANFIS	۸۳/۲	۴۴	۸۰/۶	۴۶/۱
XGBoost	۹۱/۷	۷۹/۴	۸۵/۱	۴۳/۷
SVM	۸۲/۷	۴۴/۶	۷۹/۵	۴۵/۳
ACVO-SVM	۸۴/۹	۴۵/۳	۸۱/۴	۴۶/۱


بحث

توسعه سیستم‌های هوشمند تصمیم‌یار در حوزه پزشکی یکی از نیازهای مبرم در عصر حاضر است. پژوهش حاضر به منظور توسعه یک مدل یادگیری ماشین نظارتی برای پیش‌بینی ریسک مرگ و میر بیماران STEMI-CS انجام شده است. به همین منظور، چندین مدل یادگیری ماشین شامل LASSO، ANFIS، XGBoost و SVM برای دسته‌بندی بیماران STEMI-CS بررسی شد و در نهایت مدل ترکیبی ACVO-SVM بر روی مجموعه داده آموزشی به دقت ۸۴/۹٪ و بر روی مجموعه داده آزمون، به دقت ۸۱/۴٪ رسیده است. مدل‌های LASSO و ANFIS تقریباً عملکرد مشابهی دارند. مدل XGBoost عملکرد بهتری بر روی داده‌های آموزشی دارد ولی در هنگام ارزیابی بر روی داده‌های آزمون کارایی پایین‌تری در مقایسه با سایر روش‌ها دارد. میزان کارایی روش پیشنهادی ACVO-SVM بر روی مجموعه آموزشی بر حسب معیار F1 برابر ۵۹/۱٪ است که در مقایسه با مدل‌های LASSO، ANFIS، XGBoost و SVM به ترتیب ۳/۴۹، ۲/۵۷، ۱۰/۹۳ و ۱/۹۱ بهبود را نشان می‌دهد. روش پیشنهادی ACVO-SVM بر حسب معیار F1 بر روی مجموعه داده آزمون به کارایی ۵۸/۸٪ رسیده است که نسبت به روش‌های LASSO، ANFIS، XGBoost و SVM به ترتیب در حدود ۲/۸۸، ۰/۳۶، ۴/۳۶ و ۱/۹۵٪ بهبود را نشان می‌دهد. این موضوع نشان می‌دهد که روش پیشنهادی در قیاس با سایر روش‌های مطرح از عملکرد مطلوبی در تخمین ریسک مرگ و میر بیماران STEMI-CS برخوردار است. با مقایسه مدل‌های SVM




- Model 1: $[f_1, f_2, f_3, \dots, f_{22}]$
- Model 2: $[f_2, f_3, \dots, f_{22}]$
- Model 3: $[f_1, f_2, f_3, \dots, f_{22}]$
- Model 4: $[f_1, f_2, f_3, \dots, f_{22}]$
-
- Model 11: $[f_1, f_2, f_3, \dots, f_{22}]$
- Model 12: $[f_1, f_2, f_3, \dots, f_{22}]$
-

شکل ۳- برخی از مدل‌های ترکیب ویژگی




شکل ۴- تأثیر ویژگی‌های مختلف در مدل MI بر روی کارایی مدل ACVO-SVM در پیش‌بینی وضعیت بیماران STEMI-CS

بیماران مبتلا به شوک کاردیوژنتیک نقش مؤثری دارد. جدول ۵ نتایج تولید شده توسط مدل‌های پیش‌بینی کننده را بر روی مجموعه داده آموزشی و آزمون نشان می‌دهد. نتایج نشان می‌دهند که مدل پیشنهادی ACVO-SVM در مقایسه با سایر مدل‌ها از کارایی بالاتری برخوردار است.



الف) مجموعه داده آموزشی



ب) مجموعه داده آزمون

شکل ۵- نرخ بهبود مدل ACVO-SVM در مقایسه با سایر مدل‌های پیش‌بینی کننده برحسب معیار F1

پیشین (۲، ۳، ۶، ۷، ۸، ۱۰) در این زمینه است که عنوان کرده‌اند سن، جنسیت، مصرف سیگار، جراحی بای پس عروق کرونری و مداخلات عروقی از راه پوست بیشترین تأثیر را در میزان مرگ‌ومیر بیماران-STEMI CS دارند. مدل M2 با کارایی ۵۸/۴٪ بر حسب معیار F1، در تعیین وضعیت بیماران، از نظر عملکرد در جایگاه دوم قرار دارد که نشان می‌دهد ویژگی‌های دیابت و مصرف سیگار در کنار ویژگی‌های سن، جنسیت، نوع انفارکتوس قلبی، جراحی بای پس عروق کرونری و مداخلات عروقی، تأثیر بیشتری در مرگ‌ومیر بیماران دارد. همچنین مدل ترکیب ویژگی M3 حاکی از آن است که استفاده از راهبرد درمانی بالون پمپ در کنار سایر علائم دموگرافیک بیمار، سابقه انفارکتوس قلبی و نیز مصرف سیگار تأثیر زیادی در میزان مرگ‌ومیر بیماران دارند. به‌طور خلاصه می‌توان نتیجه گرفت که علائم دموگرافیک بیمار نظیر سن و جنسیت، مصرف

و ACVO-SVM می‌توان به‌سادگی مشاهده کرد که استفاده از الگوریتم ACVO در تنظیم بهینه پارامترهای SVM به‌خوبی عمل کرده است و کارایی آن را به نحو مطلوبی بهبود داده است. شکل ۵ میزان بهبود روش پیشنهادی در مقایسه با سایر روش‌ها را برحسب معیار F1 بر روی مجموعه داده آموزشی و آزمون نشان می‌دهد.

برای تعیین ویژگی‌های مهم در پیش‌بینی وضعیت بیماران STEMI-CS، روش ACVO-SVM با چندین مدل ترکیب ویژگی آموزش داده شد. نتایج بررسی‌ها نشان داد که مدل M1 نسبت به سایر ترکیبات ویژگی‌ها، کارایی مطلوبی دارد. ویژگی‌های جنسیت، نوع انفارکتوس قلبی، مصرف سیگار، مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری که مدل M1 را تشکیل می‌دهند، از عوامل موثر در تعیین وضعیت بیماران است. یافته‌های این پژوهش هم‌سو با مطالعات

نیز تاکید شده است که الگوهای درمانی نظیر مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری در میزان مرگ و میر مؤثر است.

نتایج روش پیشنهادی ACVO-SVM و دیگر مدل‌های یادگیری ماشین همسو با دیگر مطالعات آماری و میدانی (۲) است که نشان می‌دهد روش‌های هوشمند یادگیری ماشین گزینه مناسبی برای پیش‌بینی ریسک مرگ و میر بیماران STEMI-CS است. یکی از مزایای اصلی روش پیشنهادی ACVO-SVM و سایر مدل‌های یادگیری ماشین این است که نیازی به دخالت انسان ندارند و با آموزش مناسب می‌توانند در مورد بیماران، تشخیص ریسک مناسبی ارائه کنند. همچنین روش پیشنهادی می‌تواند با مجموعه داده‌های بزرگ آموزش ببینند و در کاربرد های واقعی به عنوان یک سیستم تصمیم‌یار پزشکی استفاده شود.

یکی از محدودیت‌های اصلی این پژوهش و نیز روش‌های همتا، در دسترس نبودن مجموعه داده استاندارد و بزرگ-مقیاس برای ارزیابی مناسب مدل‌های پیش‌بینی است. در پژوهش حاضر، ارزیابی مدل‌ها بر روی یک مجموعه داده کوچک صورت گرفت. همچنین مجموعه داده مورد استفاده، فقط شامل مشخصات برخی از بیماران است که نمی‌تواند نماینده تمامی بیماران STEMI-CS باشد. بنابراین، یکی از کارهای لازم برای بهبود این پژوهش، ارزیابی روش پیشنهادی و سایر مدل‌های همتا بر روی مجموعه داده‌های بزرگ به منظور تعیین نقاط قوت و ضعف آن‌ها است. محدودیت دیگر روش پیشنهادی ACVO-SVM، عدم بررسی داده‌های گمشده در برخی از رکوردهای مجموعه داده است. این موضوع موجب می‌شود تا دقت مدل پیشنهادی کاهش یابد. لذا، باید راهکاری برای حذف تاثیر منفی این مشکل به کار گرفته شود. یکی دیگر از محدودیت‌ها، عدم بررسی همه عوامل مؤثر بر زنده ماندن بیماران STEMI-CS نظیر سطح قند خون و مدت‌زمان ایسکمی است. به همین دلیل نیاز است تمامی عوامل مؤثر در مرگ‌ومیر بیماران STEMI-CS بررسی شوند تا کیفیت دسته‌بندی و پیش‌بینی وضعیت نهایی بیماران بهبود یابد. همچنین نیاز است روش

سیگار، سابقه بیماری و استفاده از روش‌های درمانی جراحی بای پس عروق کرونری و مداخلات عروقی از راه پوست تأثیر زیادی در مرگ‌ومیر بیماران STEMI-CS دارد.

جوانشیر و همکاران (۲) در پژوهشی که در سال ۱۴۰۰ در بیمارستان شهید مدنی تبریز بر روی مرگ داخل بیمارستانی ۴۱۰ بیمار STEMI-CS انجام داده‌اند، به این نتیجه رسیده‌اند که مشخصات دموگرافیک شامل سن و جنسیت از عوامل مؤثر در مرگ و میر بیماران هستند. آن‌ها نشان دادند که هر چقدر سن بیماران بیشتر باشد، اثرپذیری راهبردهای درمانی کاهش و احتمال مرگ نیز افزایش می‌یابد. همچنین، بای و همکارانش (۳) در پژوهشی که بر روی ۲۲۸۲ بیمار STEMI-CS انجام داده‌اند به نتایج مشابه رسیده‌اند. این نتایج همسو با نتایج پژوهش حاضر است. بررسی چهار مدل برتر M1، M2، M3 و M4 نشان داد که مصرف سیگار یکی از عوامل اصلی در افزایش مرگ و میر بیماران STEMI-CS است. همان‌گونه که در جدول ۴ آمده است، در هنگامی که ویژگی مصرف سیگار با ویژگی‌های سن، جنسیت و نوع آنفارکتوس قلبی برای پیش‌بینی ریسک مرگ بیماران استفاده شده، کارایی مدل پیش‌بینی کننده بر روی مجموعه داده تست، از ۴۰/۱٪ به ۴۴/۴۶٪ برحسب معیار F1 افزایش پیدا کرده است. در مطالعات دیگر (۲ و ۳) نیز به اهمیت ویژه مصرف سیگار در تشخیص ریسک مرگ بیماران STEMI-CS پرداخته شده است. همان‌گونه که نتایج مدل‌های M2، M3 و M5 نشان می‌دهد، بیماری‌های زمینه‌ای همانند دیابت نیز در افزایش ریسک مرگ و میر بیماران نقش دارد. نتایج حاصل از روش پیشنهادی ACVO-SVM همسو با مطالعات پیشین (۲، ۳۰، ۳۱) است. آنفارکتوس قلبی نیز از عوامل بسیار مهم خطر مرگ است. مدل‌های ترکیب ویژگی M1، M3 و M4 که شامل ویژگی آنفارکتوس قلبی است مؤثر این مطلب است. علاوه بر مشخصات دموگرافیک، بیماری‌های زمینه‌ای و عوامل خطر، بررسی ترکیب ویژگی‌ها نشان داد که الگوهای درمانی مورد استفاده نیز در میزان مرگ و میر بیماران مؤثر است. در مطالعات گذشته (۲ و ۳۲)

infarction: A review. *Clin Cardiol*. 2019;42(4):484–93.

6. 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. *Eur J Heart Fail*. 2015;17(5):501–9.

7. Green M, Björk J, Forberg J, Ekelund U, Edenbrandt L, Ohlsson M. Comparison between neural networks and multiple logistic regression to predict acute coronary syndrome in the emergency room. *Artif Intell Med*. 2006;38(3):305–18.

8. Arif M, Malagore IA, Afsar FA. Detection and localization of myocardial infarction using K-nearest neighbor classifier. *J Med Syst*. 2012;36(1):279–89.

9. Sharma LN, Tripathy RK, Dandapat S. Multiscale Energy and Eigenspace Approach to Detection and Localization of Myocardial Infarction. *IEEE Trans Biomed Eng*. 2015;62(7):1827–37.

10. Berikol GB, Yildiz O, Özcan T. Diagnosis of Acute Coronary Syndrome with a Support Vector Machine. *J Med Syst*. 2016;40(4):1–8.

11. Acharya UR, Fujita H, Lih S, Hagiwara Y, Hong J, Adam M. Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Inf Sci (Ny) [Internet]*. 2017;415–416:190–8. Available from: <http://dx.doi.org/10.1016/j.ins.2017.06.027>

12. Sharma M, Tan RS, Acharya UR. A novel automated diagnostic system for classification of myocardial infarction ECG signals using an optimal biorthogonal filter bank. *Comput Biol Med [Internet]*. 2018;102(June):341–56. Available from: <https://doi.org/10.1016/j.compbiomed.2018.07.005>

13. Sharma LD, Sunkaria RK. Inferior myocardial infarction detection using stationary wavelet transform and machine learning approach. *Signal, Image Video Process*. 2018;12(2):199–206.

14. Lui HW, Chow KL. Multiclass classification of myocardial infarction with convolutional and recurrent neural networks for portable ECG devices. *Informatics Med Unlocked [Internet]*. 2018;13:26–33. Available from: <https://doi.org/10.1016/j.imu.2018.08.002>

15. Strodthoff N, Strodthoff C. Detecting and interpreting myocardial infarction using fully convolutional neural networks. *Physiol Meas*. 2019;40(1):1–11.

16. Wu CC, Hsu WD, Islam MM, Poly TN, Yang HC, Nguyen PA (Alex), et al. An artificial intelligence approach to early predict non-ST-elevation myocardial infarction patients with chest pain. *Comput Methods Programs Biomed [Internet]*. 2019;173:109–17. Available from: <https://doi.org/10.1016/j.cmpb.2019.01.013>

17. Baloglu UB, Talo M, Yildirim O, Tan RS,

پیشنهادی ACVO-SVM و سایر روش‌های مورد مقایسه بر روی مجموعه داده‌های مختلف ارزیابی کردند تا میزان پایداری آن‌ها مشخص شود.

نتیجه‌گیری

در این پژوهش، یک مدل یادگیری ماشین نظارتی برای تعیین وضعیت بیماران مبتلا به شوک کاردیوژنیک ناشی از انفارکتوس قلبی با افزایش قطعه ST ارائه شده است. در مدل پیشنهادی ACVO-SVM از الگوریتم بهینه‌سازی ACVO برای تخمین پارامترهای بهینه مدل SVM استفاده شده است تا روند آموزش SVM با کارایی بیشتری صورت گیرد. مدل پیشنهادی بر روی یک مجموعه داده از بیماران دارای شوک کاردیوژنیک ارزیابی شده و نتایج با مدل‌های ANFIS، LASSO، XGBoost و SVM مقایسه گردید. نتایج نشان داد که روش پیشنهادی از عملکرد مطلوبی در مقابل سایر مدل‌های طبقه‌بند مطرح برخوردار است. همچنین مشخص شد که سن، جنسیت، نوع انفارکتوس قلبی، مصرف سیگار، مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری به‌عنوان مؤثرترین عوامل در مرگ و میر بیماران مبتلا به STEMI-CS هستند.

References

1. Moskovitz JB, Levy ZD, Slesinger TL. Cardiogenic Shock. *Emerg Med Clin North Am*. 2015;33(3):645–52.
2. Javanshir E, Khani F, Aslanabadi N, Ghaffari S, Separham A. The Trend of Intra-Hospital Mortality Rate in ST-Segment Elevation Myocardial Infarction-Cardiogenic Shock (STEMI-CS) over One Decade, and Association with New Therapeutic Approaches. *J Isfahan Med Sch*. 2021;39(639):639–46.
3. Bai Z, Hu S, Wang Y, Deng W, Gu N, Zhao R, et al. Development of a machine learning model to predict the risk of late cardiogenic shock in patients with ST-segment elevation myocardial infarction. *Ann Transl Med*. 2021;9(14):1162–1162.
4. Thiele H, Ohman EM, De Waha-Thiele S, Zeymer U, Desch S. Management of cardiogenic shock complicating myocardial infarction: An update 2019. *Eur Heart J*. 2019;40(32):2671–83.
5. Shah AH, Puri R, Kalra A. Management of cardiogenic shock complicating acute myocardial

- Acharya UR. Classification of myocardial infarction with multi-lead ECG signals and deep CNN. *Pattern Recognit Lett* [Internet]. 2019;122:23–30. Available from: <https://doi.org/10.1016/j.patrec.2019.02.016>
18. Goto S, Kimura M, Katsumata Y, Goto S, Kamatani T, Ichihara G, et al. Artificial intelligence to predict needs for urgent revascularization from 12-lead electrocardiography in emergency patients. *PLoS One*. 2019;14(1):1–10.
19. Liu, Wen-Cheng, Chin-Sheng Lin, Chien-Sung Tsai, Tien-Ping Tsao, Cheng-Chung Cheng, Jun-Ting Liou W-S. A Deep-Learning Algorithm for Detecting Acute Myocardial Infarction. *EuroIntervention J Eur Collab with Work Gr Interv Cardiol Eur Soc Cardiol*. 2021;
20. Deng L, Zhao X, Su X, Zhou M, Huang D, Zeng X. Machine learning to predict no reflow and in-hospital mortality in patients with ST-segment elevation myocardial infarction that underwent primary percutaneous coronary intervention. *BMC Med Inform Decis Mak* [Internet]. 2022;2:1–16. Available from: <https://doi.org/10.1186/s12911-022-01853-2>
21. Wu L, Huang G, Yu X, Ye M, Liu L, Ling Y, et al. Deep Learning Networks Accurately Detect ST-Segment Elevation Myocardial Infarction and Culprit Vessel. *Front Cardiovasc Med*. 2022;9(March):1–11.
22. Manu Kumar Shetty, Shekhar Kunal, M.P. Girish, Arman Qamar, Sameer Arora, Michael Hendrickson, Padinhare P. Mohanan, Puneet Gupta, S. Ramakrishnan, Rakesh Yadav, Ankit Bansal, Geevar Zachariah, Vishal Batra, Deepak L. Bhatt, Anubha Gupta MG. Machine learning based model for risk prediction after ST-Elevation myocardial infarction: Insights from the North India ST elevation myocardial infarction (NORIN-STEMI) Registry. *Int J Cardiol*. 2022;
23. Al-Zaiti S, Besomi L, Bouzid Z, Faramand Z, Frisch S, Martin-Gill C, et al. Machine learning-based prediction of acute coronary syndrome using only the pre-hospital 12-lead electrocardiogram. *Nat Commun*. 2020;11(1):1–10.
24. Kavak S, Chiu XD, Yen SJ, Chen MYC. Application of CNN for Detection and Localization of STEMI Using 12-Lead ECG Images. *IEEE Access*. 2022;10:38923–30.
25. Cao Y, Liu W, Zhang S, Xu L, Zhu B, Cui H, et al. Detection and Localization of Myocardial Infarction Based on Multi-Scale ResNet and Attention Mechanism. *Front Physiol*. 2022;13(January):1–14.
26. Drucker H, Surges CJC, Kaufman L, Smola A, Vapnik V. Support vector regression machines. *Adv Neural Inf Process Syst*. 1997;155–61.
27. Raghavendra S, Deka PC. Support vector machine applications in the field of hydrology: A review. *Appl Soft Comput J* [Internet]. 2014;19:372–86. Available from: <http://dx.doi.org/10.1016/j.asoc.2014.02.002>
28. Emami H. Anti-coronavirus optimization algorithm. *Soft Comput* [Internet]. 2022; Available from: <https://doi.org/10.1007/s00500-022-06903-5>
29. Ye M, Fu D, Ren Y, Wang F, Wang D, Zhang F, et al. Treatment with convalescent plasma for COVID-19 patients in Wuhan, China. *J Med Virol*. 2020;0–1.
30. Acharya D. Predictors of outcomes in myocardial infarction and cardiogenic shock. *Cardiol Rev* 2018; 26(5): 255-66.
31. Bandyopadhyay D, Devanabanda AR, Tummala R, Chakraborty S, Hajra A, Amgai B, et al. Effect of diabetic ketoacidosis on the outcomes of ST-elevation myocardial infarction: An analysis of national inpatient sample. *Int J Cardiol Heart Vasc* 2019; 24: 100384.
32. Fengler K, Fuernau G, Desch S, Eitel I, Neumann FJ, Olbrich HG, et al. Gender differences in patients with cardiogenic shock complicating myocardial infarction: a substudy of the IABP-SHOCK II-trial. *Clin Res Cardiol* 2015; 104(1): 71-8.