مجله علوم پزشکی رازی دوره ۳۰، شماره ۱، فروردین ۱۴۰۲ http://rjms.iums.ac.ir

مقاله پژوهشی

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 ملاحظه ای 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 کرونا (ACVO) و ماشین بردار پشتیبان (SVM) برای پیش‌بینی مرگ بیماران بستری‌شده 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 بستری‌شده 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 مجموعه‌داده‌های 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.

کلیدواژه‌ها

انفارکتوس قلبی،

شوک کاردیوژنتیک،

یادگیری ماشین با نظارت،

دسته‌بندی،

مدل ACVO-SVM

تاریخ دریافت: ۱۴۰۱/۱۱/۱۶

تاریخ چاپ: ۱۴۰۲/۰۱/۱۹

شیوه استناد به این مقاله:

Emami H, 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.

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

Razi Journal of Medical Sciences. 2023;30(1):151-166. http://rjms.iums.ac.ir

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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

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, 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.

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

مقدمه

شوک کاردیوژنیک (Cardiogenic shock-CS) (۱ و ۲) به‌عنوان 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 می شود تا بطن چپ قلب که مسئول پمپاژ اصلی خون است به‌درستی کار نکند. شوک کاردیوژنیک به‌عنوان علت اصلی مرگ در بیماران حاد قلبی شناخته می‌شود، به‌ویژه در شرایطی که بیمار دچار اختلال در عملکرد بطن چپ به دلیل انفارکتوس میوکارد (Myocardial infarction) با افزایش قطعه‌ی ST (STEMI) است. درمان سریع شوک کاردیوژنیک در احیاء بیماران و جلوگیری از آسیب بیشتر به اندام‌های دیگر نقش اساسی دارد. بسته به شرایط بیمار، راهکارهای درمانی مختلفی برای شوک 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 (۲و ۳). علی رغم پیشرفت‌های چشمگیر در حوزه پزشکی برای درمان بیماران قلبی، درمان شوک کاردیوژنیک هنوز به‌عنوان 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 مورداستفاده در مقایسه با سال‌های قبل پیشرفت چندان 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 شوک کاردیوژنیک پرداخته شده است. بررسی آن‌ها نشان داد که روش درمانی revascularization زودهنگام مرگ‌ومیر بیماران STEMI-CS را کاهش می‌دهد، بااین‌حال، 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 (۴و ۶)، محققان به بررسی روش‌های مختلف درمانی شوک کاردیوژنیک پرداخته‌اند. یافته‌های محققان نشان می‌دهد که میزان مرگ‌ومیر در بیماران مبتلا به شوک کاردیوژنیک در محدوده ۴۰ تا ۵۰٪ در طول دو دهه گذشته باقی مانده است و راهبردهای درمانی پیشرفت قابل‌توجهی نداشته‌اند. بای و همکاران (۳) از روش‌های یادگیری ماشین نظیر الگوریتم گرادیان تقویت شدید (Extreme gradient boosting) (XGBoost)، رگرسیون خطی (Logistic regression) (LR)، ماشین بردار پشتیبان (Support vector machine) (SVR) و رگرسیون LASSO (Least absolute shrinkage and selection 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 به‌عنوان یک نتیجه آشکار از مطالعات صورت گرفته حاصل می‌شود این است که مقابله با شوک کاردیوژنیک هنوز به‌عنوان یک چالش اساسی مطرح است.

یادگیری ماشین به‌عنوان 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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

learning) یکی از راهکارهای اصلی در یادگیری ماشین است که با استفاده از داده‌های آموزشی یک مدل یادگیرنده ایجاد می‌شود به‌نحوی‌که 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. ازجمله 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 پیش بینی ریسک STEMI-CS را نشان می‌دهد.

یکی از چالش‌های اساسی در استفاده از این دسته‌بندها تنظیم دقیق پارامترهای این مدل‌ها است به‌نحوی‌که 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 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-coronavirus optimization algorithm) (ACVO) 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 داده ها فراهم کند. به‌طور خلاصه، نوآوری های 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

جدول ۱- لیست روش های تشخیص ریسک مرگ در بیماران STEMI-CS

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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

SVM

• ارزیابی مدل پیشنهادی بر روی مجموعه داده آزمون شامل بیماران STEMI-CS و مقایسه آن با سایر روش‌های مطرح

پس‌ازاین 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. درنهایت، 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 به‌نحوی‌که داده‌ها به‌صورت خطی یا ابر صفحه قابل‌تفکیک 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، $X_i=\{x_{i1},x_{i2},...,x_{im}\}$ 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 ابرصفحه‌های جداکننده برای تقسیم اشیاء داده در مجموعه داده D به تعدادی کلاس مجزا است. ابر صفحه (Hyperplane) جداکننده تو سط برخی از نقاط داده در فضای حالت ساخته می‌شود که بردارهای پشتیبان نامیده می‌شوند. هدف بیشینه کردن فاصله بین ابر صفحه جداکننده و نقاط داده از طریق حل روابط زیر است:

$$f(x)=w\,\varphi(x)+b \qquad (۱)$$

$$\text{minimize}\quad \frac{1}{2}\|w\|^2+C\sum_{i=1}^{n}(\zeta_i+\zeta_i^*)$$

$$\text{subject to}\quad \begin{cases} y_i-\langle w,x_i\rangle-b & \le \varepsilon+\zeta_i \\ \langle w,x_i\rangle-b-y_i & \le \varepsilon+\zeta_i^* \\ \zeta_i,\zeta_i^* & \ge 0 \end{cases} \qquad (۲)$$

پارامتر w نشان‌دهنده بردار نرمال، b یک عدد اسکالر، و 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 به‌صورت زیر در نظر بگیریم:

$$w=\sum_{i=1}^{N}(\alpha_i-\alpha_i^*)x_i \qquad (۳)$$

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

$$f(x)=\sum_{i=1}^{N}(\alpha_i-\alpha_i^*)K(x,x_i)+b \qquad (۴)$$

$K(x,x_i)$ 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.

$$K(x,x_i)=\varphi(x_i)\times\varphi(x_j) \qquad (۵)$$

در سال‌های اخیر، توابع کرنل مختلفی توسعه یافته است. از بین این توابع، تابع پایه چندجمله‌ای (Polynomial basis function) (PBF)، سیگموئد 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 به‌صورت زیر

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

فرموله بندی شده است.

$$K(x, x_i) = \exp(-\|x_i - x\| / 2\gamma^2) \quad (۶)$$

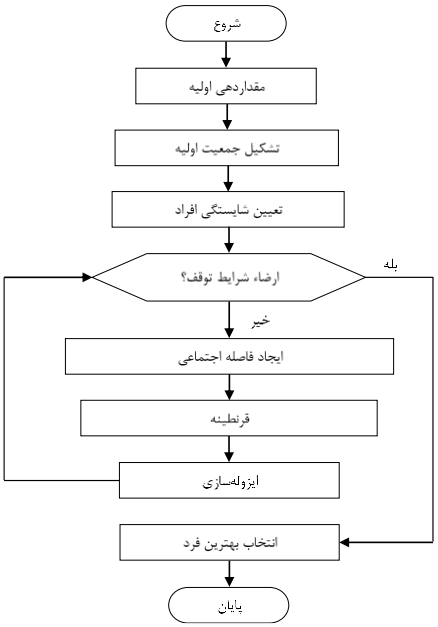
تنظیم دقیق پارامترهای C، γ و ε برای بهبود کارایی دسته‌بندی الگوریتم SVM بسیار ضروری است. در این پژوهش، الگوریتم آنتی کرونا برای تخمین مقادیر بهینه برای پارامترهای SVM ارائه شده است.

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 فلوچارت 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 را افزایش داده و ارتباطات 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 ایزوله‌کردن، 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



شکل ۱- فلوچارت الگوریتم آنتی‌کرونا

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

۲ فلوچارت مدل ACVO-SVM را نشـــان می‌دهد. در ادامه به بررسی مؤلفه‌های مدل پیشنهادی پرداخته شده است.

تشـــکیل جمعیت اولیه: همان‌گونه که در شـــکل ۲ نشـــان داده شـــده اســـت، مرحله اول در مدل ACVO-SVM، تشـــکیل جمعیت اولیه اســـت که به‌صـــورت زیر مدل‌سازی شده است.

$$P=[P_1,P_2,...,P_N] \quad (۷)$$

ازآنجایی که بهینه‌ســـازی پارامتر SVM و انتخاب ویژگی های مؤثر بیماران باید به‌طور 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 به‌صورت زیر مدل‌سازی شده است:

$$P_i=\{p_1,p_2,p_3,f_1,f_2,...,f_{24},s\} \quad (۸)$$

متغیرهای p_1، p_2 و p_3 اعداد اعشـــاری هســـتند که حاوی مقادیر کاندید برای پارامتر های C، γ و ε هســـتند. مقادیر اولیه این متغیرها به‌صـــورت تصـــادفی مقداردهی می‌شـــوند. مرز جســـتجو برای متغیر p_1 برابر [0, 100]، برای متغیرهای p_2 و p_3 برابر [0, 1] اســـت. هر کدام از متغیر های p_{ij} به‌صـــورت زیر مقداردهی می‌شود:

$$p_{ij}=r\times(p_{\max j}-p_{\min j})+p_{\min j} \quad (۹)$$

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

$$s=\begin{cases}1 & \text{if } P_i \text{ is healthy}\\ 0 & \text{if } P_i \text{ is in quarantine}\\ -1 & \text{if } P_i \text{ is in isolation}\end{cases} \quad (۱۰)$$

ارزیابی جمعیت: پس از مقداردهی اعضای جمعیت، شایستگی هر فرد با تابع شایستگی ارزیابی می‌شود. در این الگوریتم، فرض شـــده اســـت که افراد ســـالم دارای شایستگی بیشتری هستند. شایستگی هر فرد به‌وسیله میـــانگین مربعـــات خطـــا (MSE) حـــاصـــل از روش اعتبارســـنجی متقابل 10-fold برای الگوریتم SVM سنجیده شده است. تابع شایستگی به‌صورت زیر تعریف شده است:

$$MSE=\frac{1}{n}\sum_{i=1}^{n}(\hat{X}_i-X_i)^2 \quad (۱۱)$$

در رابطه بالا، n بیانگر تعداد داده های موجود در مجموعه داده، $\hat{X}_i$ برچســـب پیش‌بینی‌شـــده را نشـــان می‌دهد و X_i برچسب موجود در مجموعه داده آموزشی را نشـــان می‌دهد. اعضـــای جمعیت که مقدار MSE کمتری کسب کنند شایستگی بیشتری خواهند داشت.

فاصله‌گذاری: پس از تشکیل جمعیت اولیه، الگوریتم ســـعی می‌کند تا فاصـــله اجتماعی را در بین اعضـــای جمعیت فراهم کند. بدیهی اســـت که تمامی افراد در فاصله‌گذاری اجتماعی شرکت نمی‌کنند و فقط بخشی از جمعیت در این کار شـــرکت می‌کنند. در هر مرحله به تعداد m نفر از اعضای جمعیت در فاصله‌گذاری اجتماعی شـــرکت می‌کنند تا تعاملات اجتماعی خود را کاهش دهند. رابطه زیر برای مدل‌ســـازی فرآیند فاصـــله‌گذاری اجتماعی پیشنهاد شده است:

$$P_i^{t+1}=P_i^t+D_1^t+D_2^t \quad (۱۲)$$

در رابطه بالا، t نشـــان‌دهنده تکرار جاری الگوریتم اســـت. D_1 فاصـــله‌گذاری در مجاورت فرد P_i و ســـایر افراد را کنترل می‌کند. D_2 فاصله بین فرد P_i و بهترین فرد جمعیت P^* را کنترل می‌کند. هدف D_1 و D_2 هدایت فرد به منطقه ایمن اســـت. D_1 به‌صـــورت زیر تعریف شده است:

$$D_1^t=\alpha_{ij}^t\times sd_{ij}^t\times U(-1,1) \quad (۱۳)$$

$U(-1,+1)$ یک عدد تصادفی یکنواخت با مقدار ۱+ یا ۱- است. sd_{ij}^t حداقل فاصله فیزیکی بین P_i و هر فرد دیگر در جمعیت اســـت که به‌صـــورت زیر تعریف شـــده است:

$$sd_{ij}^t=\begin{cases}\Delta-d_{ij}^t & \text{if } (d_{ij}^t<\Delta)\\ d_{ij}^t & \text{if } (d_{ij}^t\geq\Delta)\end{cases} \quad \text{where} \quad (۱۴)$$

$$d_{ij}^t=\|P_i^t-P_j^t\|$$

d_{ij}^t فاصله فعلی بین P_i و P_j را نشان می‌دهد. Δ

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

فاصله فیزیکی ایمن بین افراد در تکرار t است. مقدار Δ بر اساس پروتکل‌های کنترل کرونا تعیین می‌شود. α_{ij}^t نرخ سرایت از فرد P_j به فرد P_i را نشان می‌دهد، که به‌صورت زیر تعریف شده است:

$$\alpha_{ij}^t = e^{-\left(\frac{d_{ij}^t}{\Delta}\right)} \quad (۱۵)$$

D_2^t به‌صورت زیر تعریف شده است:

$$D_2^t = \beta_{ij}^t \times V \times (P^* - P_i^t) \quad (۱۶)$$

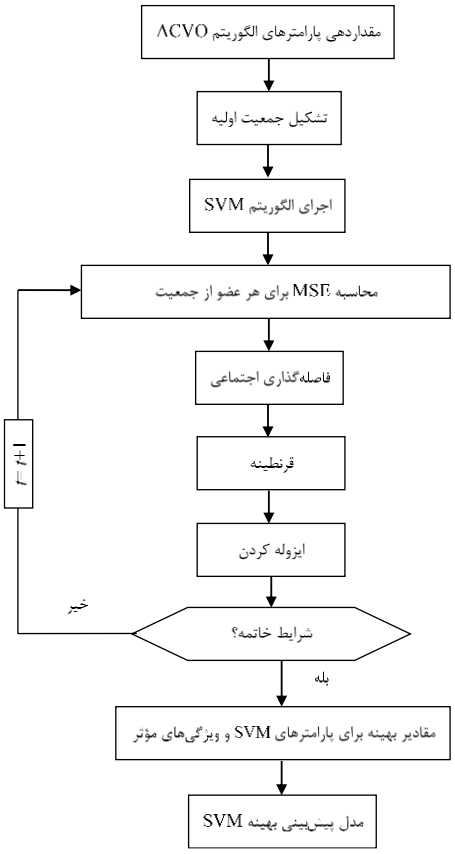
در رابطه بالا، β_{ij}^t نرخ سرایت بیماری از فرد P^* به فرد P_i است. V اندازه گام حرکت است که میزان حرکت P_i به سمت P^* را کنترل می‌کند. مقدار متغیر V بر اساس توزیع لِوی محاسبه می‌شود. P^* بهترین عضو جمعیت در تکرار t است.

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 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 به‌صورت تصادفی چند متغیر از فرد مشکوک را انتخاب می‌کند و سپس با استفاده از رابطه زیر هر متغیر انتخاب شده را بروز رسانی می‌کند.

$$p_{ik}^{t+1} = p_{ik}^t + U(-1,+1) \times rand \quad (۱۷)$$

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



شکل ۲- مدل پیشنهادی ACVO-SVM

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

رابطه زیر بروز رسانی می‌کند.

$$p_{ij}^{t+1} = \frac{1}{2}\left(p_{ij}^{t} + (\gamma \times p_{j}^{*t})\right) \qquad (۱۸)$$

در این رابطه، p_{ij}^{t} نشان‌دهنده عنصر j در فرد P_i در تکرار t است. p_{j}^{*t} نشان‌دهنده عنصر j 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 می شود در غیر این صورت دوره بستری تمدید می شود. الگوریتم مراحل فاصله‌گذاری اجتماعی، قرنطینه و ایزوله کردن را به تعداد معین که توسط کاربر تعیین می شود، تکرار می‌کند تا درنهایت شرایط خاتمه ارضاء شوند. در نهایت، بهترین فرد جمعیت انتخاب شده و به‌عنوان جواب بهینه معرفی می‌شود (۲۸). بهترین فرد شامل مقادیر بهینه برای پارامترهای SVM و ویژگی‌های مؤثر در مرگ‌ومیر بیماران مبتلا به STEMI-CS است.

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 داده های آموزشی و ۲۰٪ از رکورد ها 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}		رگ مقصر revascularization	۱۳۸	۰/۳۴
f_{22}		کامل revascularization	۲۶	۰/۰۶

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

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

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

جدول ٤- مقایسه عملکرد مدل ACVO-SVM با ترکیبات مختلف ویژگی‌ها بر روی مجموعه داده‌های آموزشی و آزمون

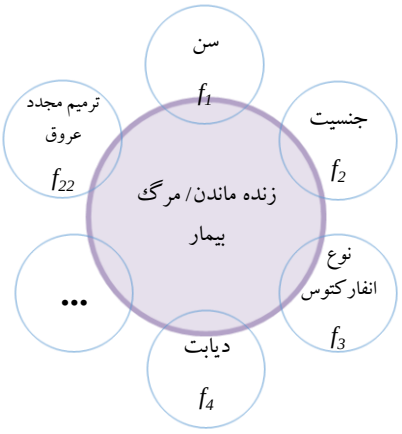
مدل ترکیب ویژگی	مجموعه داده آموزشی			مجموعه داده آزمون		
	دقت	بازخوانی	F_1	دقت	بازخوانی	F_1
M1	۸۴/۹	۴۵/۳	۵۹/۱	۸۱/۴	۴۶/۱	۵۸/۸
M2	۸۴/۵	۴۴/۸	۵۸/۶	۸۱/۱	۴۵/۶	۵۸/۴
M3	۸۳/۷	۴۲/۳	۵۶/۲	۸۰/۳	۴۴/۳	۵۷/۱
M4	۸۱/۹	۴۱/۷	۵۵/۳	۷۹/۵	۴۲/۸	۵۵/۶
M5	۸۱/۳	۴۰/۸	۵۴/۳	۷۸/۹	۴۱/۲	۵۴/۱

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 ۱۰، ۱ 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 می شوند، 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 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 ازنظر پیش‌بینی وضعیت بیماران دارد. مدل‌های M2 و M3 به‌ترتیب 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 افزوده شدن ویژگی جنسیت میزان کیفیت تفکیک بیماران افزوده شده و این موضوع با افزوده شدن سایر ویژگی‌ها نیز صدق می‌کند. با افزوده شدن دو ویژگی مداخلات عروقی از راه پوست و جراحی بای پس عروق کرونری مقدار معیار F_1 به میزان قابل‌توجهی 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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]



Model 1: [f_1, f_2, f_3, …, f_{22}]

Model 2: [$\not{f}_1$, f_2, f_3, …, f_{22}]

Model 3: [f_1, $\not{f}_2$, f_3, …, f_{22}]

Model 4: [f_1, f_2, $\not{f}_3$, …, f_{22}]

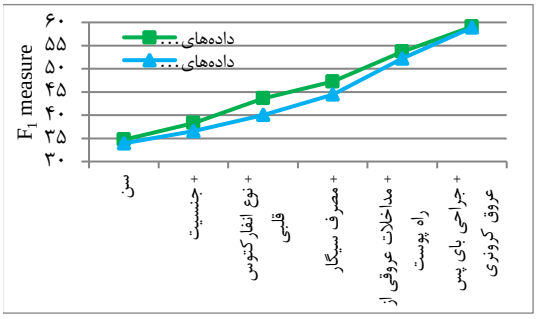
….

Model 11: [$\not{f}_1$, $\not{f}_2$, f_3, …, f_{22}]

Model 12: [$\not{f}_1$, f_2, $\not{f}_3$, …, f_{22}]

….

شکل ۳- برخی از مدل‌های ترکیب ویژگی



شکل ٤- تأثیر ویژگی‌های مختلف در مدل M1 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 تو سط 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.

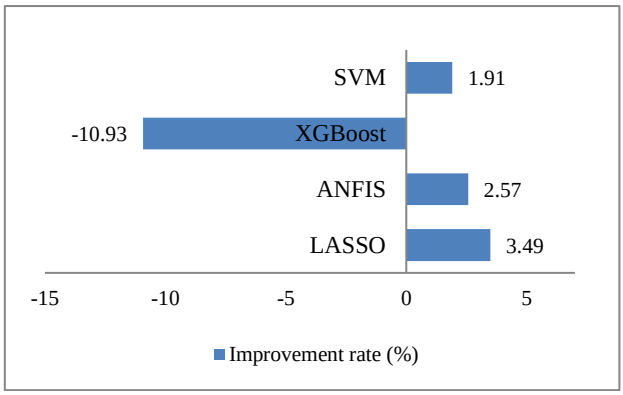
جدول ۵- مقایسه عملکرد مدل‌های پیش‌بینی کننده بر روی مجموعه داده‌های آموزشی و آزمون

مدل	مجموعه داده آموزشی			مجموعه داده آزمون		
	دقت	بازخوانی	F_1	دقت	بازخوانی	F_1
LASSO	۸۴/۲	۴۳/۱	۵۷	۸۰/۹	۴۴/۲	۵۷/۲
ANFIS	۸۳/۲	۴۴	۵۷/۶	۸۰/۶	۴۶/۱	۵۸/۶
XGBoost	۹۱/۷	۷۹/۴	۸۵/۱	۷۹/۱	۴۳/۷	۵۶/۳
SVM	۸۲/۷	۴۴/۶	۵۷/۹	۷۹/۵	۴۵/۳	۵۷/۷
ACVO-SVM	۸۴/۹	۴۵/۳	۵۹/۱	۸۱/۴	۴۶/۱	۵۸/۸

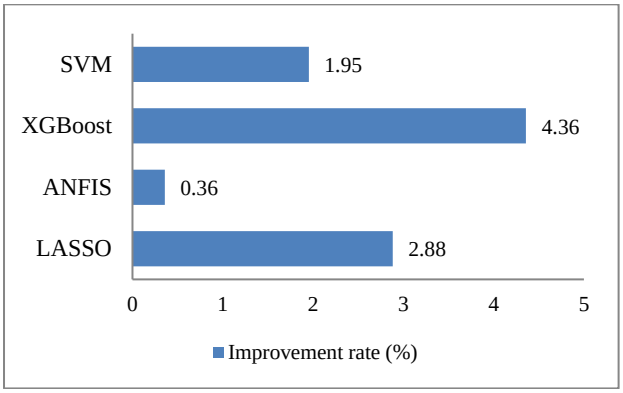
بحث

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 بیمارن 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 پیشنهاد گردید. روش 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 مدل های 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 روش های 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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]



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

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 ا ست. یافته‌های این پژوهش هم سو با مطالعات 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 آنفارکتوس 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 دموگرافیکِ بیمار نظیر سن و جنسیت، مصرف

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

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 موثر در مرگ و میر بیماران هستند. آن ها نشان دادند که هر چقدر سن بیماران بیشتر باشد، اثرپذیری راهبردهای درمانی کاهش و احتمال مرگ نیز افزایش می یابد. 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. همان گونه 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. درمطالعات دیگر (۲و ۳) نیز به اهمیت ویژه مصرف سیگار در تشخیص ریسک مرگ بیماران STEMI-CS پرداخته شده است. همان گونه 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 موئد 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 موثر است. در مطالعات گذشته (۲و ۳۲) 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 ببیند و در کاربرد های واقعی به عنوان یک سیستم تصمیم‌یار پزشکی استفاده شود.

یکی از محدودیت های اصلی این پژوهش و نیز روش های 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 به‌منظور تعیین نقاط قوت و ضعف آن ها 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 محدودیت ها، 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

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

پیشـــنهادی ACVO-SVM و ســـایر روش‌های مورد مقایسه بر روی مجموعه داده‌های مختلف ارزیابی گردند تا میزان پایداری آن‌ها مشخص شود.

نتیجه‌گیری

در این پژوهش، یک مدل یادگیری ماشـــین نظارتی برای تعیین وضعیت بیماران مبتلا به شوک کاردیوژنیک نا شی از انفارکتوس قلبی با افزایش قطعه ST ارائه شده اســـت. در مدل پیشـــنهادی ACVO-SVM از الگوریتم بهینه‌ســـازی ACVO برای تخمین پارامترهای بهینه مدل SVM استفاده شده است تا روند آموزش SVM با کارایی بی شتری صورت گیرد. مدل پی شنهادی بر روی یک مجموعه داده از بیماران دارای شـــوک کاردیوژنیک ارزیابی شـــده و نتایج با مدل‌های LASSO، ANFIS، XGBoost و SVM مقای سه گردید. نتایج ن شان داد که روش پیشـــنهادی از عملکرد مطلوبی در مقابل ســـایر مدل های طبقه بند مطرح برخوردار اســـت. همچنین م شخص شد که سن، جن سیت، نوع انفارکتوس قلبی، م صرف سیگار، مداخلات عروقی از راه پو ست و جراحی بای پس عروق کرونری به‌عنوان مؤثرترین عوا مل 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 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,

[Downloaded from rjms.iums.ac.ir on 2026-11-21]

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-leads 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, Padhinhare 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.

[Downloaded from rjms.iums.ac.ir on 2026-11-21]