

Research Paper

Prediction of Coronary Artery Bypass Grafting Outcomes Based on Angiographic Images and Clinical Data Using Artificial Intelligence Algorithms

Alireza Eftekhari¹, Fatemeh Javaher Forooshzadeh², Marzieh Reshadatian¹, Seyed Masoud Rezaei^{1*}

1. Assistant Professor of Medical Physics, Department of Medical Physics, Faculty of Medicine, Ahvaz Jundishapur University of Medical Sciences, Ahvaz, Iran.

2. Department of Anesthesia, Ahvaz Anesthesiology and Pain Research Center, Ahvaz Jundishapur University of Medical Sciences, Ahvaz, Iran.

Use your device to scan
and read the article online



Citation Eftekhari A, Javaherforoshzadeh F, Reshadatian M, Rezaei SM. [Prediction of Coronary Artery Bypass Grafting Outcomes Based on Angiographic Images and Clinical Data Using Artificial Intelligence Algorithms (Persian)]. Jundishapur Journal of Medical Sciences. 2026; 25(3): 270-299.

 <https://doi.org/10.22118/jsmj.2025.515064.3885>

ABSTRACT

Background and Objectives Coronary artery disease is one of the leading causes of mortality worldwide, and coronary artery bypass grafting (CABG) is recognized as the standard treatment for patients with multivessel disease. Accurate prediction of postoperative outcomes in these patients is clinically important. In this study, we investigated a novel machine learning and deep learning framework that integrates multimodal data- including coronary angiography images, two-stage blood test results, and clinical variables- to predict postoperative survival and key biochemical outcomes (blood urea nitrogen [BUN], serum glutamic-oxaloacetic transaminase [SGOT], and serum glutamic-pyruvic transaminase [SGPT]).

Subjects and Methods The dataset comprised 152 patients who underwent CABG at two tertiary cardiac centers in Ahvaz over four years. Deep features were extracted from coronary angiography images using a ResNet-18 architecture and combined with biomarker and clinical data within machine learning pipelines. To reduce dimensionality and improve generalizability, feature selection techniques- including SelectKBest, SelectFromModel with Random Forest, Lasso, and ExtraTrees- were applied, along with a range of classifiers such as logistic regression, support vector classifier (SVC), k-nearest neighbors, XGBoost, LightGBM, and ensemble methods. Model performance was evaluated using five-fold cross-validation, an independent test set, and standard metrics including accuracy, precision, recall, F1-score, and AUC.

Results The results demonstrated that Lasso-based approaches, particularly when combined with logistic regression and SVC, performed best, yielding a cross-validated accuracy of 97.14% for survival prediction and 93.33%, 93.33%, and 99.05% for BUN, SGOT, and SGPT, respectively.

Conclusion Comparisons with conventional models indicated that multimodal data integration substantially improves predictive accuracy.

Keywords Coronary artery bypass grafting, Coronary angiography, Deep learning, Machine learning.

Received: 24 Dec 2025
Revised: 22 March 2026
Accepted: 24 April 2026

*** Corresponding Author:**
Seyed Masoud Rezaei

Address: Assistant Professor of Medical Physics, Department of Medical Physics, Faculty of Medicine, Ahvaz Jundishapur University of Medical Sciences, Ahvaz, Iran.

Tel: +989106108256

E-Mail: rezaei-sm@ajums.ac.ir

Extended Abstract

Introduction

Aging is accompanied by metabolic dysfunction, increased oxidative stress, chronic low-grade inflammation, and reduced efficiency of cellular repair pathways. Together, these changes may impair neural plasticity and weaken the mechanisms responsible for neuronal survival and maintenance (1). They can also increase the vulnerability of sensitive neural networks, particularly the dopaminergic system. Dopaminergic neurons are especially susceptible to mitochondrial dysfunction and reactive oxygen species because of their high metabolic demand. Therefore, identifying practical and inexpensive interventions that promote a neuroprotective environment is important for maintaining neurological health in older adults (2, 3).

Neurotrophic factors play a central role in neural homeostasis, neuronal survival, synaptogenesis, and neuroplasticity. Nerve growth factor (NGF) binds to the tropomyosin receptor kinase A (TrkA) and activates signaling pathways such as PI3K/Akt and MAPK/ERK, which contribute to cell survival, inhibition of apoptosis, neuronal differentiation, and synaptic plasticity. NGF may also bind to the p75 neurotrophin receptor, producing survival-promoting or regulatory responses depending on the cellular context (4–6). Glial cell line-derived neurotrophic factor (GDNF) is particularly important for the survival and function of dopaminergic neurons. It primarily acts through the GFR α 1/RET receptor complex, activating PI3K/Akt and Ras/MAPK signaling and protecting dopaminergic neurons against oxidative stress and mitochondrial dysfunction (7, 8).

Regular physical activity may increase neurotrophic support by improving vascular function, regulating metabolism, and activating the muscle–brain axis. Exercise-induced muscle contractions stimulate the release of myokines and peripheral signaling molecules that may improve cerebral blood flow, oxygen delivery, and neurotrophin-related gene expression (10–13). Moderate-intensity interval training (MIIT) may be particularly suitable for older adults because it is tolerable, practical, and can produce physiological adaptations without imposing excessive stress (14, 15).

Quercetin is a flavonoid with antioxidant and anti-inflammatory properties. By activating Nrf2-related pathways, reducing reactive oxygen species, and inhibiting NF- κ B signaling, quercetin may create a cellular environment that facilitates NGF/TrkA and GDNF/GFR α 1-RET signaling (18, 19). Therefore, MIIT and quercetin may have complementary effects: exercise may stimulate neurotrophic-factor production, while quercetin may reduce oxidative and inflammatory barriers to neurotrophic signaling. This study investigated the effects of eight weeks of MIIT, quercetin supplementation, and their combination on serum NGF and GDNF concentrations in older men.

Methods

Participants and Study Design

In this quasi-experimental study, 40 eligible older men were recruited from 60 initial volunteers using purposive convenience sampling. Sample size was calculated with G*Power for analysis of covariance (ANCOVA) (effect size = 0.30, α = 0.05, power = 80%). Inclusion criteria were age 60–75 years, body mass index 18.5–29.9 kg/m², general good health, no chronic disease, no nervous-system-affecting medication, less than 150 minutes of weekly physical activity, and normal sleep. Exclusion criteria included musculoskeletal injury, absence from >20% of sessions, nonadherence, or withdrawal. Participants were randomly assigned to four groups of 10 (MIIT, SUP, MIIT + SUP, control).

Measurements and Laboratory Procedures

Height and body mass were measured with a Seca 220 device. Blood was sampled 24 hours before the first session and 48 hours after the last; strenuous activity was avoided 48 hours beforehand. Samples were drawn from an antecubital vein (21-gauge), incubated for 30 minutes, and centrifuged at 1500 $\times$ g for 10 minutes at 4°C. Serum was aliquoted and stored at –80°C without repeated freeze–thaw cycles. NGF and GDNF were measured in triplicate by sandwich ELISA (absorbance 450 nm, reference 570 nm), quantified via four-parameter logistic regression, and repeated if the intra-assay CV exceeded 10%.

Training and Supplementation

MIIT was performed three times weekly for eight weeks with warm-up/cool-down. Weeks 1–4: eight two-minute intervals at 70–75% HRmax with two-minute recovery at 50%. Weeks 5–8: three-minute intervals at 75–80% HRmax. Heart rate was monitored with Polar H10. Supplementation groups consumed 500 mg quercetin daily after breakfast; control received placebo. Diet was held constant and assessed with three-day food records (Nutritionist IV).

Statistical Analysis

Data were reported as mean $\pm$ SD. Normality (Shapiro–Wilk), variance homogeneity (Levene), and ANCOVA assumptions were checked. One-way ANCOVA with baseline covariates and Bonferroni post hoc tests were used (SPSS version 26; P < 0.05).

Results

All 40 participants completed the study, with no between-group differences in diet.

NGF differed significantly between groups (F = 46.36, P < 0.001). It rose ~14% in MIIT (142.18 $\rightarrow$ 162.25 pg/mL) and ~17% in MIIT+SUP (145.52 $\rightarrow$ 170.81 pg/mL), both significantly higher than SUP and control (P < 0.001). MIIT vs. MIIT+SUP was not significant (P = 0.223), and quercetin alone did not differ from control (P = 1.000P).

GDNF also differed significantly (F = 47.73, P < 0.001), increasing ~15% in MIIT (5.23 $\rightarrow$ 6.03 pg/mL) and ~10% in MIIT+SUP (5.12 $\rightarrow$ 5.34 pg/mL), with both training groups exceeding SUP and control. Adding quercetin to MIIT gave

no significant additional effect ($P = 0.196$), and supplementation alone was not significant versus control ($P=0.50$).

Discussion

The main finding was that eight weeks of MIIT significantly increased serum NGF and GDNF in older men, whereas 500 mg/day of quercetin alone did not significantly affect either marker. Furthermore, combining quercetin with MIIT provided no statistically significant advantage over MIIT alone. These findings suggest that exercise was the primary stimulus responsible for the observed neurotrophic responses.

The increase in NGF may indicate enhanced systemic support for neuronal survival, repair, and synaptic plasticity through TrkA-mediated PI3K/Akt and MAPK/ERK signaling. Similarly, increased GDNF may support dopaminergic neurons because GDNF activates GFR α 1/RET-dependent pathways involved in neuronal survival and resistance to oxidative and mitochondrial stress (7). However, because only serum concentrations were assessed, these results should not be interpreted as direct evidence of changes in brain tissue or dopaminergic neurons.

MIIT may have stimulated neurotrophic responses through repeated activation of the muscle-brain axis. Muscle contractions can promote myokine release, improve endothelial function and cerebral perfusion, and activate transcriptional pathways involved in neurotrophin synthesis (38, 39). The alternating work-and-recovery pattern may also provide an adequate metabolic and hemodynamic stimulus while remaining tolerable for older adults (40).

Despite its antioxidant and anti-inflammatory properties, quercetin did not enhance NGF or GDNF responses. This may relate to the participants' relatively healthy status, the eight-week intervention duration, the selected dose, individual differences in quercetin bioavailability, or a ceiling effect from exercise. Quercetin may also have influenced oxidative or inflammatory processes that were not measured and were therefore not reflected in serum neurotrophic-factor concentrations.

The study was limited by its small sample, inclusion of men only, short intervention duration, and absence of oxidative-stress, inflammatory, cognitive, and motor-function outcomes. Quercetin bioavailability was also not measured. Future studies should include longer interventions, different quercetin doses, both sexes, and simultaneous assessment of biological and functional outcomes.

Conclusion

Eight weeks of MIIT significantly increased serum NGF and GDNF concentrations in older men. Daily supplementation with 500 mg of quercetin did not alter these neurotrophic factors independently or enhance their responses to training. MIIT may therefore be a practical, inexpensive nonpharmacological intervention to improve systemic neurotrophic support during aging. Nevertheless, direct neuroprotective effects cannot be confirmed without brain-specific measurements of cognition, motor function, inflammation, and oxidative stress.

Ethical Considerations

Compliance with ethical guidelines

This study was conducted in accordance with the ethical principles of the Declaration of Helsinki and relevant institutional guidelines. The study protocol was reviewed and approved by the appropriate institutional ethics committee of Ahvaz Jundishapur University of Medical Sciences. The study was registered under project No. U-03381. The confidentiality and privacy of all participants were maintained throughout the study, and all collected data were used solely for research purposes. Written informed consent was obtained from all participants prior to enrollment in the study.

Funding

This study was supported by Ahvaz Jundishapur University of Medical Sciences under research project No. U-03381.

Author's contributions

Seyed Masoud Rezaeijo: Conceptualization, methodology, supervision, project administration, validation, interpretation of results, and writing—review and editing. Fatemeh Javaherforooshzadeh: Conceptualization, methodology, supervision, clinical consultation, interpretation of results, and writing—review and editing. Marzieh Reshadatian: Methodology, scientific consultation, data interpretation, validation, and writing—review and editing. Alireza Eftekhari: Investigation, data collection, data curation, formal analysis, visualization, and writing—original draft preparation. All authors critically reviewed the manuscript, approved the final version, and agreed to be accountable for all aspects of the work.

Conflicts of interest

The authors declare that they have no competing interests or conflicts of interest related to this study

Acknowledgements

The authors would like to thank the staff of the participating hospitals in Ahvaz and Shiraz for their assistance with data collection and study coordination. The authors also gratefully acknowledge all participants who contributed to this research.

مقاله پژوهشی

پیش بینی پیامدهای پیوند بای پس عروق کرونر مبتنی بر تصاویر آنژیوگرافی و داده های بالینی با استفاده از الگوریتم های هوش مصنوعی

علیرضا افتخار^۱، فاطمه جواهر فروش زاده^۲، مرضیه رشادتیان^۱، سید مسعود رضایی جو^{۱*}

۱. استادیار گروه فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی جندی شاپور اهواز، اهواز، ایران.
۲. تحقیقات بیهوشی و درد اهواز، دانشگاه علوم پزشکی جندی شاپور اهواز، اهواز، ایران.

Use your device to scan
and read the article online



Citation Eftekhari A, Javaherforoozhzadeh F, Reshadatian M, Rezaei SM. [Prediction of Coronary Artery Bypass Grafting Outcomes Based on Angiographic Images and Clinical Data Using Artificial Intelligence Algorithms (Persian)]. Jundishapur Journal of Medical Sciences. 2026; 25(3): 270-299.

doi <https://doi.org/10.22118/jsmj.2025.515064.3885>

چکیده



زمینه و هدف: بیماری عروق کرونر یکی از علل اصلی مرگ و میر در سراسر جهان است و جراحی بایپس عروق کرونر (CABG) به عنوان درمان استاندارد در بیماران مبتلا به بیماری چندرگی شناخته می شود. پیش بینی دقیق پیامدهای پس از عمل در این بیماران از اهمیت بالینی قابل توجهی برخوردار است. در این مطالعه، یک چارچوب نوین مبتنی بر یادگیری ماشین و یادگیری عمیق بررسی شد که با ادغام داده های چندوجهی، شامل تصاویر آنژیوگرافی عروق کرونر، نتایج آزمایشهای خونی در دو مرحله و متغیرهای بالینی، با هدف پیش بینی بقای پس از عمل و برخی پیامدهای مهم بیوشیمیایی شامل نیتروژن اوره خون (BUN)، اسپارتات آمینوترانسفراز سرمی (SGOT) و آلانین آمینوترانسفراز سرمی (SGPT) توسعه یافت.

روش بررسی: مجموعه داده های این مطالعه شامل ۱۵۲ بیمار بود که طی یک دوره چهار ساله در دو مرکز تخصصی قلب در اهواز تحت جراحی بای پس عروق کرونر قرار گرفته بودند. ویژگیهای عمیق از تصاویر آنژیوگرافی عروق کرونر با استفاده از معماری ResNet-18 استخراج و سپس با داده های مربوط به نشانگرهای زیستی و متغیرهای بالینی در چارچوب الگوریتمهای یادگیری ماشین ادغام شدند. به منظور کاهش ابعاد داده ها و بهبود قابلیت تعمیم پذیری مدل، از روشهای مختلف انتخاب ویژگی شامل SelectKBest، روش SelectFromModel مبتنی بر Random Forest، Lasso و ExtraTrees استفاده شد. همچنین، طیفی از الگوریتمهای طبقه بندی شامل رگرسیون لجستیک، ماشین بردار پشتیبان (SVC)، نزدیکترین همسایه های K، XGBoost، LightGBM و روشهای ترکیبی مورد ارزیابی قرار گرفتند. عملکرد مدلها با استفاده از اعتبارسنجی متقاطع پنج تایی، یک مجموعه آزمون مستقل و شاخص های استاندارد شامل صحت، دقت، فراخوانی، امتیاز F1 و سطح زیر منحنی ROC (AUC) ارزیابی شد.

یافته ها: نتایج نشان داد روش های مبتنی بر Lasso، بهویژه در ترکیب با رگرسیون لجستیک و SVC، بهترین عملکرد را داشتند. دقت حاصل از اعتبارسنجی متقاطع برای پیش بینی بقا ۹۷/۱۴٪ بود و برای پیش بینی BUN، SGOT و SGPT به ترتیب ۹۳/۳۳٪، ۹۳/۳۳٪ و ۹۹/۰۵٪ به دست آمد.

نتیجه گیری: مقایسه با مدلهای متداول نشان داد که ادغام داده های چند وجهی می تواند دقت پیش بینی را به طور قابل توجهی بهبود بخشد.

کلیدواژه ها: یادگیری ماشین، یادگیری عمیق، پیوند بای پس عروق کرونر (CABG)، آنژیوگرافی کرونری.

تاریخ دریافت: ۳ دی ۱۴۰۴
دریافت اصلاحات: ۲ فروردین ۱۴۰۵
تاریخ پذیرش: ۴ اردیبهشت ۱۴۰۵

* نویسنده مسئول:

سید مسعود رضایی جو

نشانی: گروه فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی جندی شاپور اهواز، اهواز، ایران.

تلفن: ۰۹۱۰۶۱۰۸۲۵۶

رایانامه: rezaei-sm@ajums.ac.ir

مقدمه

بیماری‌های قلبی عروقی (Cardiovascular CVDs) یکی از مهم‌ترین چالش‌های سلامت جهانی هستند که سالانه نزدیک به ۱۸ میلیون مرگومیر را به همراه دارند و بار اجتماعی-اقتصادی قابل توجهی را به‌ویژه در کشورهای با درآمد کم و متوسط که دسترسی به مداخلات پیشرفته همچنان محدود است، تحمیل می‌کنند (۱). بیماری عروق کرونر (Coronary Artery Disease/CAD)، به‌عنوان مهم‌ترین عامل مرگومیر ناشی از بیماری‌های قلبی عروقی، اغلب با درگیری چندرگی همراه است و در بسیاری از موارد نیازمند جراحی بای‌پس عروق کرونر (Coronary Artery Bypass Grafting/CABG) است. امروزه، سالانه بیش از یک میلیون بیمار در سراسر جهان تحت این مداخله جراحی قرار می‌گیرند (۲). گرچه طی سال‌های اخیر پیشرفت‌هایی در تکنیک‌های جراحی، از جمله استفاده از روش‌های بدون پمپ و پیوند‌های شریانی، حاصل شده است، اما پیامدهای پس از عمل همچنان چالش‌برانگیز باقی مانده‌اند. مرگومیر، اختلال عملکرد کلیوی و نارسایی کبدی از جمله عوارض شایع پس از CABG هستند که به‌شدت تحت تأثیر بیماری‌های زمینه‌ای بیماران، پیچیدگی فرایند جراحی و شرایط محیطی حین عمل قرار می‌گیرند (۳).

ابزارهای پیش‌آگهی سنتی، نظیر EuroSCORE II و مدل‌های ریسک انجمن جراحان قفسه سینه (Society of Thoracic Surgeons/STS)، با در نظر گرفتن متغیرهای جمعیت‌شناختی، بالینی و عملیاتی، نقش اساسی در تخمین مرگومیر کوتاه‌مدت و عوارض پس از جراحی قلب باز ایفا کرده‌اند (۴). با پیشرفت‌های علم داده و پزشکی، استفاده از مدل‌های رگرسیون برای پیش‌بینی و ارزیابی خطرات پس از جراحی‌های قلبی همواره مورد توجه قرار گرفته است. این مدل‌ها به‌ویژه در تخمین مرگومیر کوتاه‌مدت و عوارض پس از عمل از اهمیت زیادی برخوردارند. با این حال، مدل‌های رگرسیون مانند EuroSCORE II و مدل‌های STS به دلیل وابستگی به متغیرهای جمعیت‌شناختی و بالینی، در شرایطی که داده‌ها ناممکن و دارای ابعاد بالا باشند، دچار چالش‌هایی می‌شوند. به‌ویژه در جمعیت‌های متنوع یا هنگام ترکیب داده‌های پیچیده‌ای همچون تصویربرداری پزشکی و نشانگرهای زیستی، این مدل‌ها قادر به ارائه پیش‌بینی‌های دقیق و کامل نیستند. در این راستا، ظهور الگوریتم‌های هوش مصنوعی (Artificial Intelligence) و یادگیری ماشین (Machine Learning)، به‌ویژه در زمینه‌های پیچیده‌ای مانند پردازش تصاویر پزشکی، این امکان را فراهم آورده است که پیش‌بینی‌ها را با دقت و شفافیت بیشتری انجام دهیم (۵). این الگوریتم‌ها به دلیل توانایی خود در شبیه‌سازی الگوهای غیرخطی و تعاملات پیچیده میان متغیرهای مختلف، می‌توانند تحلیل‌های دقیق‌تری ارائه دهند. برخلاف مدل‌های سنتی که عمدتاً به روابط خطی و ساده محدود می‌شوند، یادگیری ماشین و یادگیری عمیق قادرند به بررسی

ارتباطات پنهان و چندبعدی در داده‌های پزشکی، به‌ویژه در زمینه‌های پیچیده‌ای مانند مراقبت‌های قلبی عروقی بپردازند.

این فناوری‌ها با استفاده از مدل‌هایی مانند شبکه‌های عصبی کانولوشنی (Convolutional Neural Networks/CNN) در پردازش تصاویر پزشکی، یا شبکه‌های عصبی بازگشتی (Recurrent Neural Networks/RNN) در تحلیل داده‌های سری‌زمانی پزشکی، توانسته‌اند قابلیت‌های پیش‌بینی دقیق‌تری را در مواردی چون تشخیص بیماری‌های قلبی عروقی، پیش‌بینی عوارض پس از جراحی و شخصی سازی درمان‌ها فراهم کنند. به علاوه، ادغام داده‌های چندوجهی نظیر تصاویر آنژیوگرافی، اطلاعات بالینی و نشانگرهای زیستی در این مدل‌ها، امکان پیش‌بینی‌های دقیق‌تر و بهینه‌سازی تصمیمات درمانی را فراهم کرده است (۶).

یادگیری عمیق با خودکار سازی استخراج ویژگی‌ها از تصاویر آنژیوگرافی کرونری، که به‌عنوان روش استاندارد طلایی برای تجسم آناتومی و شناسایی تنگی‌های عروقی شناخته می‌شود، انقلابی در تحلیل تصاویر پزشکی ایجاد کرده است (۷). شبکه‌های عصبی کانولوشنی از پیش آموزش‌دیده، مانند معماری‌های ResNet (Residual Neural Network)، قادرند سری‌های آنژیوگرافی با وضوح بالا را به بردارهای ویژگی فشرده و متمایزکننده‌ای تبدیل کنند که جزئیات بافتی، مورفولوژیکی و پاتولوژیکی را در بر می‌گیرند. این ویژگی‌های استخراج‌شده به‌طور قابل توجهی از تفسیر دستی در انجام وظایف پیش‌آگهی پیشی گرفته و دقت پیش‌بینی را به‌طور چشمگیری افزایش می‌دهند (۸). علاوه بر این، هنگامی که این ویژگی‌های عمیق با فراداده‌های بالینی مانند سن، جنسیت، جزئیات رویه‌ای و نشانگرهای زیستی طولی ترکیب می‌شوند، امکان مدل‌سازی پیشرفته‌تری از مسیرهای پس از عمل فراهم می‌آید (۹). نشانگرهای زیستی مانند نیتروژن اوره خون (Blood Urea Nitrogen/BUN) و ترانس‌آمیناز گلوتامیک اگزوالوآستیک سرم (SGOT/Serum Glutamic-Oxaloacetic Transaminase) و ترانس‌آمیناز گلوتامیک پیروویک سرم (SGPT/Glutamic-Pyruvic Transaminase) به‌ویژه اهمیت دارند، زیرا افزایش این نشانگرها اغلب نشان‌دهنده استرس کلیوی و کبدی است که با افزایش مرگومیر و نارسایی اندام در گروه‌های جراحی قلب مرتبط است (۱۰).

شواهد نوین نشان می‌دهند که الگوریتم‌های یادگیری ماشین، از جمله جنگل‌های تصادفی، تقویت گرادیان و ماشین‌های بردار پشتیبان، در پیش‌بینی پیامدهای نامطلوب پس از CABG عملکرد برتری دارند و در بسیاری از مطالعات اعتبارسنجی مقادیر زیر منحنی (Area Under the Curve/AUC) بیش از ۰/۹۰ را به‌دست آورده‌اند (۱۱). به‌عنوان نمونه، مدل‌های مبتنی بر منظم‌سازی لاسو پایداری چشمگیری در انتخاب ویژگی نشان داده‌اند و متغیرهایی همچون نوسانات نشانگرهای زیستی و شاخص‌های مشتق‌شده از تصویربرداری را برای کاهش

بیانگر شیوع بالای بیماری پیشرفته عروق کرونر چندرگی در این جمعیت است؛ مواردی که عموماً در مراکز ارجاع سطح سوم مدیریت می‌شوند. علاوه بر داده‌های مربوط به نوع عمل، مجموعه داده شامل طیف گسترده‌ای از متغیرهای اختصاصی بیمار مانند تاریخ تولد، جنسیت و تشخیص‌های بالینی ثبت شده توسط پزشک معالج نیز بود. این داده‌های چندوجهی مبنایی ارزشمند برای ترسیم ویژگی‌های جمعیت‌شناختی و بالینی بیماران فراهم کردند و امکان تحلیل عمیق‌تر پیامدهای قلبی-عروقی، عوامل پیش‌آگهی و ویژگی‌های کلی بیماران را تسهیل نمودند.

تحلیل توزیع جنسیتی

بررسی توزیع جنسیتی در گروه‌های تشخیصی (شکل ۱) نشان‌دهنده غلبه قابل توجه بیماران مرد در تمامی دسته‌ها بود. مردان ۷۱٪ از موارد بای‌پس چهار یا چند شریان کرونری، ۶۳٪ از موارد سه شریانی، ۶۰٪ از موارد دو شریانی و ۶۰٪ از موارد یک شریانی را تشکیل دادند. همچنین، تمامی بیماران تحت عمل بای‌پس شریان کرونری داخلی پستانی دوگانه مرد بودند (۱۰۰٪)، در حالی که در بای‌پس پستانی تکی، ۷۰٪ مرد و ۲۹٪ زن بودند. به طور کلی، حضور زنان در تمامی گروه‌ها کمتر از مردان بود و از صفر درصد در بای‌پس‌های پستانی دوگانه تا حداکثر ۳۹٪ در بای‌پس‌های تک شریانی متغیر بود. این الگوی نابرابری جنسیتی با شواهد اپیدمیولوژیک جهانی هم‌خوانی دارد، زیرا مردان در مقایسه با زنان اغلب با درگیری چندرگی و پیشرفته‌تر بیماری‌های کرونری مواجه می‌شوند. چنین تفاوت‌هایی را می‌توان ناشی از ترکیبی از عوامل اجتماعی-اقتصادی، سبک زندگی، تفاوت‌های زیستی و نیز تفاوت در دسترسی و بهره‌گیری از خدمات بهداشتی در بافت جمعیتی ایران دانست.

ارزیابی نتایج ترخیص

ارزیابی نتایج ترخیص نشان‌دهنده مسیرهای بهبودی عمدتاً مثبت برای بیماران بود. به طوری که ۱۶۸۰ بیمار (۸۷٪) به بهبودی کامل رسیدند، ۸۳ بیمار (۴٪) به بهبودی نسبی دست یافتند و ۱۳۵ بیمار (۷٪) به دلیل عوارض بعد از عمل، جان خود را از دست دادند. سایر موارد شامل ترخیص به درخواست شخصی (۱۲ نفر، ۰٪)، انتقال به مراکز دیگر (۵ نفر، ۰٪)، پیگیری برنامه‌ریزی شده (۲ نفر، ۰٪) و تغییر وضعیت به بستری (۲ نفر، ۰٪) بودند. همان‌طور که در نمودار توزیع وضعیت ترخیص مشاهده می‌شود (شکل ۲)، زمانی که نتایج براساس نوع جراحی طبقه‌بندی شدند، بالاترین نرخ بهبودی کامل در گروه‌های بای‌پس دو شریان کرونری (۸۹٪) و سه شریان کرونری (۸۸٪) مشاهده شد، که میزان مرگ‌ومیر مربوط به این گروه‌ها به ترتیب ۷٪ و ۹٪ بود. در مقابل، بای‌پس آئورت-کرونری تک‌شریانی با میزان مرگ‌ومیر ۲۲٪ همراه بود که احتمالاً به دلیل بیماری‌های همراه یا چالش‌های ذاتی روش جراحی در این زیرگروه است.

بیش‌برازش در مجموعه داده‌های نامتعادل در اولویت قرار داده‌اند (۱۲). در جمعیت‌های خاورمیانه که شیوع CAD چندرگی به دلیل شیوع بالای عوامل خطر متابولیک بیشتر است، این رویکردهای یکپارچه می‌توانند به بهبود دقت پیش‌بینی پیامدها کمک کرده و تخصیص بهینه منابع را در مراکز درمانی سطح سوم تسهیل کنند (۱۳). علاوه بر این، به کارگیری روش‌های کاهش ابعاد مانند t-SNE موجب آشکارسازی بهتر تفکیک‌پذیری کلاس‌ها در فضاها با ابعاد بالا شده است و نشان می‌دهد که چگونه تعبیه‌های مبتنی بر تنظیم پیچیدگی می‌توانند تفسیرپذیری مدل‌های بقا و پیش‌بینی نشانگرهای زیستی را ارتقا دهند (۱۴).

در این مطالعه، ما از یک مجموعه داده جامع گردآوری شده از بیمارستان‌های ایران - شامل تصاویر آنژیوگرافی، نتایج آزمایش‌های خون دو مرحله‌ای و پروفایل‌های بالینی مربوط به ۱۵۲ بیمار تحت عمل قلب باز - استفاده کردیم تا خطوط لوله یادگیری ماشینی (ML pipelines) را برای پیش‌بینی بقا و سطوح SGPT، SGOT، BUN توسعه داده و اعتبارسنجی کنیم. خطوط لوله یادگیری ماشینی «Machine Learning Pipeline» خط لوله یادگیری ماشینی به مجموعه‌ای از مراحل منظم و پیوسته گفته می‌شود که داده‌ها را از حالت خام تا رسیدن به مدل نهایی پردازش می‌کند. در واقع مثل یک زنجیره‌ی مونتاژ است که هر مرحله کاری خاص انجام می‌دهد تا خروجی گام قبل آماده‌ی ورودی گام بعد شود.

تأکید اصلی این پژوهش بر استخراج عمیق ویژگی‌ها و به کارگیری اعتبارسنجی متقابل دقیق است تا با ارتقای مدل‌سازی پیش‌آگهی، تصمیم‌گیری بالینی مبتنی بر شواهد را تقویت کرده و در نهایت به کاهش عوارض پس از عمل در این جمعیت پرخطر کمک نماید.


روش بررسی

جمعیت مورد مطالعه و جمع‌آوری داده‌ها

این پژوهش از یک مجموعه داده بالینی جامع بهره‌برداری کرد که طی یک دوره چهارساله (۱۴۰۰ تا ۱۴۰۴) با همکاری بیمارستان گلستان و بیمارستان امام در اهواز، ایران، گردآوری شد. این دو مرکز به دلیل نقش محوری در ارائه خدمات تخصصی قلب و عروق و انجام مداخلات جراحی قلب باز، به عنوان مراکز مرجع در این حوزه شناخته می‌شوند. مجموعه داده شامل سوابق ۱۹۲۰ بیمار بود که همگی طی این دوره تحت عمل جراحی قلب باز قرار گرفتند.


در میان این بیماران، شایع‌ترین مداخله، پیوند بای‌پس آئورت-کرونری چندرگی بود؛ به گونه‌ای که بای‌پس چهار یا بیشتر شریان کرونری در ۸۵۹ بیمار، سه شریان در ۷۷۰ بیمار، دو شریان در ۱۷۱ بیمار و یک شریان در ۵۸ بیمار انجام شد. عمل‌های کمتر رایج شامل بای‌پس شریان کرونری داخلی پستانی تکی (۵۷ مورد) و دوگانه (۴ مورد) بودند. این توزیع جراحی

توزیع جنسیتی در دسته‌های تشخیصی



شکل ۱. توزیع جنسیتی را در دسته‌های مختلف تشخیصی برای ۱۹۲۰ بیماری که در طول دوره مطالعه چهارساله تحت عمل جراحی قلب قرار گرفتند، نشان می‌دهد و نسبت بیماران مرد و زن را در هر گروه نشان می‌دهد.

هیئت مپ درصد وضعیت ترخیص بر اساس دسته‌بندی‌های تشخیصی



شکل ۲. توزیع وضعیت ترخیص طبقه‌بندی‌شده بر اساس دسته‌بندی‌های تشخیصی را برای ۱۹۲۰ بیماری که در طول دوره چهار ساله تحت عمل جراحی قلب قرار گرفته‌اند، نشان می‌دهد.

نهادی انجام شد تا هم‌راستایی با اهداف روش‌شناختی مطالعه و حفظ کیفیت داده‌ها تضمین شود.

پس از پالایش بیشتر مجموعه داده‌ها، یک زیرگروه اصلی از ۱۵۲ بیمار ایجاد شد که هم تصاویر آنژیوگرافی و هم نتایج کامل آزمایش خون دومرحله‌ای برای آنها در دسترس بود. این آزمایش‌های خون که در فاصله دو روز از یکدیگر انجام شدند، طیف وسیعی از نشانگرهای زیستی مرتبط با بیماری‌های قلبی-عروقی را شامل می‌شدند، از جمله پروفایل‌های لیپیدی، آنزیم‌های کبدی و سایر پارامترهای بیوشیمیایی. جداول ۱ و ۲، داده‌های آزمایش خون مشترک برای این ۱۵۲ بیمار را برای هر دو مرحله آزمایش نشان می‌دهند. پروتکل دومرحله‌ای طولی امکان اندازه‌گیری دقیق تغییرات زمانی حاد در سطوح نشانگرهای زیستی را فراهم کرد که می‌تواند نشان‌دهنده پاسخ‌های فیزیولوژیکی پیش از عمل یا علائم اولیه عوارض باشد. این گروه پالایش‌شده از ۱۵۲ بیمار، با مجموعه داده‌های بالینی، تصویربرداری و آزمایشگاهی یکپارچه، مبنای محکمی برای مدل‌سازی آماری پیشرفته و تحلیل‌های هم‌بستگی میان متغیرهای جمعیت‌شناختی، یافته‌های رادیولوژیکی و پیامدهای پس از عمل فراهم کرد. فرایند دقیق جمع‌آوری داده‌ها، جامعیت و قابلیت اطمینان مجموعه داده‌ها را برای پاسخ به فرضیه‌های تحقیقاتی تأمین نمود.

در مورد بای‌پس‌های داخلی دوگانه پستانی، ۷۵/۰٪ از بیماران به بهبودی کامل رسیدند، ۲۵/۰٪ به بهبودی نسبی دست یافتند و هیچ‌یک از آنها مرگ‌ومیر نداشتند. درحالی‌که در بای‌پس‌های تک پستانی، ۷۵/۴٪ به بهبودی کامل، ۸/۸٪ مرگ‌ومیر و ۱۵/۸٪ به بهبودی نسبی دست یافتند. این تفاوت‌ها اهمیت پیچیدگی‌های جراحی و میزان درگیری عروقی را در پیش‌بینی پیامدهای پس از عمل نشان می‌دهند و بر ضرورت به‌کارگیری استراتژی‌های مدیریتی فردی برای بهینه‌سازی نتایج و کاهش خطرات مرگ‌ومیر در زیرگروه‌های آسیب‌پذیر تأکید می‌کنند.

بررسی اجمالی مجموعه داده‌های بالینی جامع

از میان ۱۹۲۰ بیمار اولیه، تصاویر آنژیوگرافی کرونری با وضوح بالا برای ۱۷۳ نفر بازیابی شد. این تصاویر که از طریق پروتکل‌های استاندارد آنژیوگرافی کرونری به‌دست آمده‌اند، نمای دقیقی از آناتومی شریان کرونری ارائه داده و ارزیابی دقیق انسدادها، شدت تنگی و ویژگی‌های پاتولوژیکی دیگر را برای برنامه‌ریزی و اجرای جراحی تسهیل کردند. گنجاندن این داده‌های تصویربرداری در مطالعه برای ارائه بینش‌های رادیولوژیکی بسیار حائز اهمیت بود و به درک بهتر عوامل آناتومیک و پاتوفیزیولوژیکی مؤثر بر نتایج جراحی کمک کرد. انتخاب این زیرمجموعه تصویربرداری با توجه به دسترسی و یکپارچگی سوابق در پایگاه‌های داده

جدول ۱. خلاصه آمار پارامترهای بالینی و آزمایشگاهی (مرحله ۱)

الف. پیل جمعیت‌شناسی و متابولیک پایه

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
سن (سال)	۸۵	۶۵/۰	۵۹/۰	۵۲/۰	۳۴	۸/۸۵	۵۸/۵۷
قند خون ناشتا (mg/dL)	۵۱۲	۱۸۳	۱۴۰	۱۰۳	۵۷	۸۵/۱۳	۱۶۲/۷
BUN (mg/dL)	۵۴	۱۹/۰	۱۶/۰	۱۲/۰	۷	۶/۷۰	۱۶/۶۱
کراتینین (mg/dL)	۲/۲	۱/۱	۱/۰	۰/۸	۰/۵	۰/۲۵	۰/۹۸
سدیم (mEq/L)	۱۵۷	۱۴۱	۱۳۹	۱۳۷	۱۲۲	۳/۵۸	۱۳۸/۹۸
پتاسیم (mEq/L)	۵/۸	۴/۷	۴/۳	۴/۱	۳/۳	۰/۴۸	۴/۴۰
کلسیم (mg/dL)	۱۰/۹	۹/۴	۹/۲	۸/۹	۷/۰	۰/۵۹	۹/۱۵

ب. کبد و مشخصات آنزیمی

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
بیلی روبین کل	۹/۳	۰/۹	۰/۷	۰/۵	۰/۲	۰/۸۵	۰/۸۳
بیلی روبین مستقیم	۱/۰	۰/۲	۰/۲	۰/۱	۰/۱	۰/۱۴	۰/۲۲
AST (U/L)	۲۵۱	۳۲	۲۷	۲۲	۱۳	۲۲/۷۱	۳۱/۲۵
ALT (U/L)	۲۱۶	۳۴	۲۳	۱۷	۸	۲۹/۳۳	۳۲/۸۸
LDH (U/L)	۲۵۸۲	۷۱۳	۵۸۸	۵۰۵	۲۸۳	۲۳۳/۵۱	۶۲۴/۵۸
CPK (U/L)	۶۶۳	۱۳۷	۱۱۹	۷۵/۵	۳۷	۷۸/۱۳	۱۲۳/۱۹
آلبومین (g/dL)	۵/۱	۴/۲	۴/۱	۳/۹	۲/۸	۰/۴۰	۴/۰۶
پروتئین کل (g/dL)	۸/۸	۷/۶	۷/۳	۷/۰	۵/۲	۰/۵۷	۷/۲۷

ج. مشخصات انعقادی

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
PT - بیمار	۲۱	۱۴/۲	۱۳/۰	۱۲/۰	۱۲	۱/۲۷	۱۳/۳۶
PT - کنترل	۱۲	۱۲/۰	۱۲/۰	۱۲/۰	۱۲	۰/۰۰	۱۲/۰۰
INR	۲/۰	۱/۲	۱/۱	۱/۰	۱/۰	۰/۱۶	۱/۱۵
PTT	۸۴	۳۴/۵	۳۰/۰	۳۰/۰	۳۰	۵/۷۷	۳۲/۷۴

د. شمارش کامل خون (CBC)

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
گلبول‌های سفید خون ($\mu\text{L}/10^3 \times$)	۲۲/۱	۸/۷۰	۷/۶۰	۶/۴۵	۳/۶	۲/۷۴	۷/۹۹
گلبول‌های قرمز خون ($\mu\text{L}/10^6 \times$)	۶/۸۳	۴/۹۷	۴/۵۷	۴/۱۱	۲/۷۷	۰/۷۱	۴/۵۷
هموگلوبین (g/dL)	۱۷/۰	۱۳/۸۰	۱۲/۷۰	۱۱/۷۰	۷/۶	۱/۸۰	۱۲/۷۲
هماتوکریت (%)	۵۰/۸	۴۲/۱۵	۳۹/۶۰	۳۶/۵۵	۲۴/۷	۴/۸۷	۳۹/۴۴
MCV (fL)	۱۱۲/۴	۹۰/۷۵	۸۷/۴۰	۸۴/۴۰	۵۹/۳	۷/۲۹	۸۷/۰۱
MCH (pg)	۳۷/۴	۳۳/۲۵	۳۲/۱۰	۳۱/۲۵	۲۴/۵	۱/۸۱	۳۲/۰۹
MCHC (g/dL)	۳۸/۱	۲۹/۸۰	۲۸/۳۰	۲۷/۲۰	۱۶/۴	۳/۱۹	۲۸/۱۵
پلاکت‌ها ($\mu\text{L}/10^3 \times$)	۶۲۹	۲۸۳/۵	۲۴۱/۰۰	۱۹۱/۵	۱۹	۸۷/۸۲	۲۴۷/۰۵

جدول ۲. خلاصه آمار پارامترهای بالینی و آزمایشگاهی (مرحله ۲)

الف. پنل جمعیت‌شناسی و متابولیک پایه

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
BS (mg/dL)	۵۰۱	۲۱۰	۱۸۱	۱۴۸	۷۴	۶۳/۱۲	۱۸۷/۹۰
BUN (mg/dL)	۵۶	۲۴	۱۹	۱۵	۶	۸/۱۵	۲۰/۱۵
CR (mg/dL)	۳/۲	۱/۱	۱	۰/۸	۰/۵	۰/۳۱	۱/۰۳۶
سدیم (mEq/L)	۱۶۱	۱۴۴	۱۴۲	۱۳۹	۱۳۲	۴/۳۲	۱۴۱/۷۲
پتاسیم (mEq/L)	۵/۵	۴/۵	۴/۳	۴	۲/۸	۰/۴۵	۴/۲۴
کلسیم (mg/dL)	۱۰/۴	۸/۸	۸/۴	۸/۰۵	۶/۵	۰/۶۶	۸/۳۹

ب. کبد و مشخصات آنزیمی

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
بیلی روبین کل	۵/۹	۱/۲۵	۰/۹	۰/۶	۰/۲	۰/۹۴	۱/۱۹
بیلی روبین مستقیم	۵/۲	۰/۵	۰/۳	۰/۲	۰/۱	۰/۵۳	۰/۴۸
ALK P (IU/L)	۱۹۹۵	۲۱۹	۱۸۴	۱۵۴	۸۹	۱۵۶/۰۳	۲۰۱/۵۰
SGOT (U/L)	۶۶۴	۶۶	۴۴	۳۴	۱۱	۸۱/۱۸	۶۶/۴۰
SGPT (U/L)	۳۸۹	۳۳/۵	۲۵	۲۰	۱۱	۳۷/۶۵	۳۳/۳۲
آلبومین (g/dL)	۴/۳	۳/۳۵	۳/۲	۳	۲/۳	۰/۳۵	۳/۱۷
پروتئین کل (g/dL)	۷/۷	۵/۸	۵/۶	۵/۳	۴/۱	۰/۵۴	۵/۵۵

ج. مشخصات انعقادی

پارامتر	بیشترین مقدار	P-75	میانه	P-25	کمترین مقدار	انحراف معیار	میانگین
PT - بیمار	۴۷	۱۴/۰۵	۱۳	۱۲	۱۲	۵/۰۶	۱۴/۲۳
PT - کنترل	۱۳	۱۲	۱۲	۱۲	۱۲	۰/۰۸	۱۲/۰۱
INR	۶	۱/۳	۱/۱	۱	۱	۰/۷۵	۱/۳۱
PTT	۱۲۰	۴۰	۳۰	۳۰	۳۰	۲۴/۱	۴۱/۲۱

د. شمارش کامل خون (CBC)

پارامتر	بیشترین مقدار	P-75	میان	P-25	کمترین مقدار	انحراف معیار	میانگین
گلبول‌های سفید خون ($\mu\text{L}/10^3 \times$)	۲۲/۲	۱۳/۷۵	۱۱/۹	۹/۷	۴	۳/۲۷	۱۱/۹۵
گلبول‌های قرمز خون ($\mu\text{L}/10^6 \times$)	۵/۳۱	۳/۸۶	۳/۵۸	۳/۲۵	۲/۵۶	۰/۵۰	۳/۵۷
هموگلوبین (g/dL)	۱۵/۳	۱۰/۷	۹/۸	۹	۶/۵	۱/۴۲	۹/۸۹
HCT (%)	۴۴/۲	۳۳/۲	۳۰/۷	۲۸/۱	۲۲/۹	۳/۹۵	۳۰/۹۱
MCV (fL)	۱۰۲/۹	۸۹/۸۵	۸۷/۱	۸۴/۴۵	۶۶/۷	۵/۶۵	۸۷/۰۴
MCH (pg)	۳۶/۳	۳۲/۹	۳۲	۳۰/۹	۲۷/۲	۱/۵۶	۳۱/۹۷
MCHC (g/dL)	۳۶/۵	۲۹/۳	۲۷/۸	۲۶/۸	۱۹/۷	۲/۴۷	۲۷/۷۷
پلاکت‌ها ($\mu\text{L}/10^3 \times$)	۵۱۳	۲۰۷	۱۷۹	۱۴۴	۶۱	۶۷/۰۰	۱۸۶/۳۰

توجه: «میزان طبیعی SGOT: کمتر از ۴۸ واحد در لیتر (مردان)، کمتر از ۳۱ واحد در لیتر (زنان)؛ میزان طبیعی SGPT: کمتر از ۴۱ واحد در لیتر (مردان)، کمتر از ۳۱ واحد در لیتر (زنان). محدوده طبیعی BUN: از ۷ تا ۲۱ میلی‌گرم در دسی‌لیتر؛ به صورت ۷ تا ۲۱ در مقابل ۲۱ میلی‌گرم در دسی‌لیتر تقسیم‌بندی شده است.»

زیرگروه‌های تشخیصی و اجزای طولی

زیرگروه‌های تشخیصی مربوط به ۱۵۲ بیمار شامل مجموعه‌ای چندوجهی از داده‌های تصویربرداری و بالینی بودند که برای ارزیابی جامع وضعیت قلبی-عروقی ضروری محسوب می‌شوند. تمامی بیماران تحت شش سری آنژیوگرافی استاندارد قرار گرفتند که تصاویری با کیفیت بالا از عروق کرونری ارائه می‌داد و امکان شناسایی دقیق ناهنجاری‌هایی همچون تنگی یا انسداد را - که در تصمیم‌گیری‌های جراحی اهمیت حیاتی دارند - فراهم می‌کرد. نمونه‌ای از این تصاویر شش‌گانه برای یک بیمار در شکل ۳ نمایش داده شده است. علاوه بر داده‌های تصویربرداری، مجموعه داده شامل نتایج آزمایش خون دو مرحله‌ای نیز بود که شاخص‌های بیوشیمیایی کلیدی مرتبط با وضعیت قلبی-عروقی و فرایند بهبودی پس از عمل را ثبت می‌کرد. همچنین متغیرهای بالینی تکمیلی شامل سن، تاریخ تولد، تشخیص پزشک و جنسیت به‌طور نظام‌مند مستندسازی شدند. این چهارچوب یکپارچه، امکان ارزیابی جامع بیمار را فراهم کرده و ارتباط بین یافته‌های تصویربرداری، داده‌های آزمایشگاهی و ارزیابی‌های بالینی را تقویت نمود تا استخراج بینش‌های بالینی معنادار امکان‌پذیر شود.

ازسوی دیگر، جنبه طولی مجموعه داده عمدتاً از آزمایش‌های خون دومرحله‌ای که با فاصله دو روز انجام شدند، به‌دست آمد. این طراحی با اندازه‌گیری‌های مکرر، امکان ردیابی نوسانات کوتاه‌مدت در شاخص‌های فیزیولوژیک را فراهم کرد؛ نوساناتی که می‌توانند بازتاب‌دهنده اثرات جراحی، سیر بیماری یا پاسخ‌های درمانی باشند. ترکیب داده‌های به‌دست‌آمده از نقاط زمانی مختلف، ظرفیت تشخیص الگوهای پویا در وضعیت سلامت بیماران - از جمله پایداری حین عمل و روند بهبودی - را افزایش داد. اگرچه تصاویر آنژیوگرافی تنها در یک نقطه زمانی ثبت شدند، اما داده‌های آزمایش خون بعدی یک بُعد طولی ارزشمند را به مجموعه


افزودند و در تعامل با تصویربرداری ایستا و داده‌های بالینی پایه، عمق تحلیلی مطالعه را به‌طور چشمگیری غنی‌تر ساختند.

رویه‌های پیش‌پردازش تصویر

نرمال‌سازی و نمونه‌برداری مجدد تصاویر تمام تصاویر آنژیوگرافی کرونری تحت پیش‌پردازش دقیق قرار گرفتند تا یکنواختی در وضوح و پروفایل‌های شدت تصاویر به‌دست آید. برای استانداردسازی ابعاد پیکسل‌ها، نمونه‌برداری مجدد انجام شد که در نتیجه، استخراج مداوم ویژگی‌های عمیق مورفولوژیکی و بافتی عروق در سراسر مجموعه داده‌ها تضمین گردید. علاوه بر این، تکنیک‌های نرمال‌سازی شدت برای هماهنگ‌سازی مقادیر پیکسل اعمال شدند که به‌طور مؤثر آرتیفکت‌های ناشی از تفاوت‌های پروتکلی یا تغییرات تجهیزات تصویربرداری را کاهش داد. این مراحل مقدماتی برای افزایش قابلیت همکاری و اطمینان از دقت الگوریتم‌های یادگیری ماشین بعدی که برای طبقه‌بندی خطر مرگ‌ومیر پس از جراحی قلب باز استفاده می‌شوند، بسیار حیاتی بودند.

تولید ماسک

تصاویر آنژیوگرافی اولیه که در فرمت DICOM ذخیره شده بودند، به‌منظور افزایش کارایی ذخیره‌سازی و تسهیل پردازش‌های محاسباتی به فرمت Nifti تبدیل شدند. این فرایند با استفاده از اسکریپت‌های پایتون و کتابخانه‌های تخصصی تصویربرداری پزشکی انجام گرفت. به‌طور هم‌زمان، ماسک‌های جامعی نیز در قالب Nifti تولید شدند که کل میدان تصویربرداری آنژیوگرافی را مشخص کرده و نواحی مورد نظر برای تحلیل را تعریف می‌کردند. این ماسک‌ها با بهره‌گیری از روش‌های مبتنی بر پایتون توسعه یافتند و ضمن تضمین سازگاری کامل با تصاویر اصلاح‌شده، امکان استخراج ویژگی‌های هدفمند را در مراحل بعدی پردازش و گردش کارهای یادگیری ماشین فراهم ساختند.



شکل ۳. شش سری از تصاویر آنژیوگرافی از یک بیمار نمونه.

روش استخراج ویژگی عمیق

ویژگی‌های عمیق از تصاویر پزشکی NifTI با استفاده از مدل از پیش آموزش دیده ResNet-18 استخراج شدند. ResNet-18، یک شبکه عصبی باقیمانده که ابتدا بر روی مجموعه داده ImageNet آموزش دیده است و به دلیل توانایی اش در یادگیری نمایش‌های سلسله‌مراتبی پیچیده از تصاویر، به طور گسترده شناخته شده است. برای تطبیق این مدل به منظور استخراج ویژگی‌ها به جای طبقه‌بندی، لایه نهایی کاملاً متصل حذف شد. این تغییر به شبکه امکان می‌دهد که یک بردار ویژگی ۵۱۲ بعدی برای هر تصویر تولید کند که نشان‌دهنده یک جاسازی فشرده اما غنی از اطلاعات بصری شناسایی شده در تصویر است.

ResNet-18 این نمایش را با پردازش تدریجی تصویر از طریق چندین لایه فیلترهای کانولوشنی انجام می‌دهد. لایه‌های ابتدایی ویژگی‌های سطح پایین مانند لبه‌ها و بافت‌ها را استخراج می‌کنند، در حالی که لایه‌های عمیق‌تر الگوهای پیچیده‌تر و انتزاعی‌تری از شکل، ساختار و مفاهیم بصری سطح بالاتر را رمزگذاری می‌نمایند. این مدل با استفاده از اتصالات باقیمانده خود، پایداری در طول فرایند آموزش را حفظ کرده و اطلاعات گرا دیان مهم را نگه می‌دارد، به طوری که امکان استخراج ویژگی‌های بسیار متمایز فراهم می‌شود. در نهایت، لایه جمع‌آوری میانگین جهانی اطلاعات مکانی را به یک بردار ثابت ۵۱۲ عنصری تبدیل می‌کند که به عنوان توصیفگر ویژگی عمیق عمل می‌کند.

استراتژی‌های ساختاردهی داده‌ها

این مجموعه داده‌ها برای ۱۵۲ بیمار که دارای داده‌های کامل آنژیوگرافی و نتایج آزمایش خون دومارحله‌ای (با فاصله دو روز) بودند، تکمیل شد. شش سری آنژیوگرافی استاندارد به طور یکنواخت برای تمام بیماران انجام شد و یک پایه تصویربرداری استاندارد برای تجزیه و تحلیل‌های مقایسه‌ای فراهم گردید. ویژگی‌های عمیق استخراج شده از این تصاویر، همراه با نشانگرهای زیستی از آزمایش‌های خون و متغیرهای بالینی (از جمله سن، تاریخ تولد، تشخیص پزشک و جنسیت)، در یک ساختار جدولی یکپارچه شدند. داده‌های مربوط به هر بیمار در یک ردیف قرار گرفت که شامل ستون‌هایی برای ویژگی‌های عمیق از شش سری تصویربرداری (همان‌طور که در شکل ۳ برای یک بیمار نشان داده شده است)، نتایج آزمایش خون و پارامترهای بالینی اختصاصی هر بیمار بود که با یک شناسه منحصر به فرد بیمار یکپارچه شدند. این مجموعه داده‌های یکپارچه به فرمت اکسل صادر شده و برای اجرای مدل‌سازی پیش‌بینی کننده استفاده شد، به طوری که امکان ارزیابی پیچیده پیامدهای مرگومیر با ترکیب دینامیک نشانگرهای زیستی زمان‌بندی شده با داده‌های تصویربرداری ثابت و ویژگی‌های بالینی فراهم گردید.

الگوریتم‌های انتخاب ویژگی و طبقه‌بندی

برای کاهش چالش‌های ناشی از فضا‌های ویژگی با ابعاد بالا و افزایش تعمیم‌پذیری مدل، مجموعه‌ای از روش‌های انتخاب ویژگی متنوع در دو الگوی ساختاردهی داده به کار گرفته شد. خطوط لوله مجزای انتخاب ویژگی برای ویژگی‌های عمیق و ویژگی‌های غیرعمیق طراحی شده و تکنیک‌های کاهش ابعاد، شامل رویکردهای مبتنی بر فیلتر و مدل‌های تعبیه‌شده، برای حذف افزونگی و اولویت‌بندی ویژگی‌های مهم به کار گرفته شدند. این فرایند انتخاب ویژگی به گونه‌ای طراحی شد که با انتخاب زیرمجموعه‌های بهینه از ویژگی‌ها، کارایی طبقه‌بندی را افزایش داده و خطر بیش‌برازش را کاهش دهد.

معماری آزمایشی از مجموعه‌ای از الگوریتم‌های انتخاب ویژگی برای کاهش ابعاد استفاده کرد و ویژگی‌های مهم عمیق و بالینی را برجسته ساخت. فیلترهای آماری تک‌متغیره، از جمله SelectKBest با ANOVA (F-value (f_classif) و اطلاعات متقابل (mutual_info_classif)، برای شناسایی ویژگی‌هایی که ارتباط قوی با متغیر نتیجه از طریق تحلیل واریانس و معیارهای نظری اطلاعات دارند، به کار گرفته شدند. به طور مکمل، استراتژی‌های انتخاب تعبیه‌شده شامل پیاده‌سازی‌های SelectFromModel با جنگل تصادفی، درختان اضافی و منظم‌سازی لاسو (از طریق رگرسیون لجستیک L1) بودند که به طور ذاتی اهمیت ویژگی‌ها را در طول فرایند آموزش ارزیابی کرده و آنها را از نظر سودمندی آماری و تفسیری متعادل می‌کنند. هر انتخابگر به طور خاص به گونه‌ای پیکربندی شد که ۲۰ ویژگی برتر را حفظ کرده و یکنواختی در انتخاب‌ها را ارتقا دهد، تا مقایسه‌ها بین روش‌های مختلف تسهیل گردد.

الگوریتم‌های طبقه‌بندی شامل مجموعه‌ای از الگوهای یادگیری ماشین سستی و گروهی بودند که به دلیل قابلیت کاربرد آنها در داده‌های زیست‌پزشکی انتخاب شده‌اند. طبقه‌بندی‌کننده‌های خطی شامل رگرسیون لجستیک، رویکردهای مبتنی بر فاصله شامل K-Nearest Neighbors (KNN) ماشین‌های بردار پشتیبان (Support Vector Machine/SVM) با هسته‌های تابع پایه خطی و شعاعی (Radial Basis Function/RBF) بودند. روش‌های مبتنی بر درخت گروهی، مانند جنگل تصادفی، درختان اضافی، تقویت گرادیان، (Extreme Gradient Boosting) و XGBoost (Gradient Boosting Machine) برای مدل‌سازی روابط غیرخطی پیچیده و تعاملات ویژگی‌های موجود در داده‌های ویژگی عمیق به کار گرفته شدند. علاوه بر این، یک درخت تصمیم‌گیری مستقل به عنوان معیاری قابل تفسیر استفاده شد. این الگوریتم‌ها براساس اثربخشی نشان داده‌شده در مطالعات مشابه و سازگاری با زیرمجموعه‌های ویژگی‌ها انتخاب شدند. مدل‌هایی که استفاده شده است مجموعه‌ای از

پرکاربردترین الگوریتم‌های یادگیری ماشین در مسائل طبقه‌بندی هستند و هر کدام ویژگی‌های منحصر به فردی دارند. مدل‌هایی مانند Logistic Regression و SVC بیشتر بر مرز تصمیم‌گیری بهینه تمرکز می‌کنند و برای داده‌های با ابعاد نه‌چندان زیاد یا زمانی که تفسیرپذیری اهمیت دارد مناسب‌اند. Logistic Regression با وجود سادگی، عملکرد قابل‌اتکایی ارائه می‌دهد و کنترل خوبی روی پیچیدگی مدل از طریق پارامترهایی مانند C دارد. در مقابل، SVC به‌ویژه با کرنل RBF قادر است مرزهای تصمیم‌گیری غیرخطی و پیچیده ایجاد کند، هرچند هزینه محاسباتی بیشتری دارد. از سمت دیگر، مدل‌هایی مانند KNN و Decision Tree ساختار ساده‌تری دارند؛ KNN بدون مرحله آموزش عمل می‌کند و تصمیم را براساس همسایگان نزدیک می‌گیرد، درحالی‌که Decision Tree ساختار if-else بهینه‌سازی شده تولید می‌کند و امکان تفسیر مستقیم تصمیمات را فراهم می‌سازد.

در خانواده مدل‌های ensemble، الگوریتم‌هایی نظیر Random Forest، Gradient Boosting، XGBoost، و LightGBM ترکیبی از قدرت یادگیری چندین درخت را برای افزایش دقت و کاهش overfitting به کار می‌گیرند. Random Forest با درخت‌های متعدد و تصادفی‌سازی داخلی، پایداری بالایی ارائه می‌دهد و نسبت به نویز مقاوم است. Gradient Boosting و نسخه‌های پیشرفته‌تر آن مانند XGBoost و LightGBM برپایه یادگیری تدریجی خطاهای مدل‌های قبلی بنا شده‌اند؛ این روش‌ها معمولاً دقت بالاتری ارائه می‌کنند، انعطاف‌پذیری زیادی دارند و در مسائل واقعی حجیم و پیچیده عملکرد بسیار قوی نشان می‌دهند. به‌ویژه LightGBM به دلیل ساختار درخت‌های مبتنی بر رشد برگ‌ها (leaf-wise) و بهینه‌سازی‌های سطح سیستم، سرعت و کارایی بالایی روی دیتاست‌های بزرگ ارائه می‌کند. این مجموعه مدل‌ها یک طیف کامل از سادگی تا پیچیدگی و از تفسیرپذیری تا بیشینه‌سازی دقت را پوشش می‌دهند.

چهارچوب‌های ارزیابی و تفسیرپذیری مدل

ارزیابی مدل از یک استراتژی چندوجهی استفاده کرد و شاخص‌های عملکرد رایج را با پروتکل‌های اعتبارسنجی دقیق ترکیب کرد تا دقت پیش‌بینی و اعتبار خارجی مدل را تعیین کند. معیارهای اصلی شامل دقت (نسبت طبقه‌بندی‌های صحیح)، دقت (نسبت مثبت‌های واقعی به مثبت‌های پیش‌بینی‌شده) $TP/(TP+FP)$ ، یادآوری $TP/(TP+FN)$ ، امتیاز F1 (میانگین هارمونیک دقت و یادآوری برای کلاس‌های نامتعادل) و مساحت زیر منحنی مشخصه عملکرد گیرنده (AUC) بودند که برای تمایز آستانه-آگوستیک استفاده شدند. این معیارها بر روی پارتیشن‌های اختصاصی برای اعتبارسنجی و آزمون محاسبه شدند.

برای جلوگیری از بیش‌برازش احتمالی و ارزیابی پایداری عملکرد، اعتبارسنجی متقابل ۵-fold-تودرتو در زیرمجموعه آموزشی به کار گرفته

جندی شاپور

زیرمجموعه آموزشی (۷۰٪)، اعتبارسنجی (۱۰٪) و آزمون (۲۰٪) تقسیم شدند و برای حفظ تناسب کلاس‌ها، طبقه‌بندی انجام شد. استانداردسازی ویژگی‌ها با استفاده از StandardScaler انجام شد و متغیرها به‌طوری که میانگین صفر و واریانس واحد داشته باشند، تبدیل شدند. یک رژیم اعتبارسنجی متقابل ۵ مرحله‌ای در داخل بخش آموزشی قرار داده شد تا تعمیم‌پذیری مدل افزایش یافته و خطر بیش‌برازش کاهش یابد. این چهارچوب با استفاده از تنظیم فرایارمتر از طریق جست‌وجوی شبکه (GridSearchCV) تقویت شد و امکان مقایسهٔ منصفانهٔ مدل‌ها براساس معیارهایی مانند دقت، صحت، یادآوری، امتیاز F1 و AUC را در مجموعه‌های اعتبارسنجی و آزمون فراهم کرد.

نتایج عملکرد در سطوح مختلف مستند شدند: نتایج اعتبارسنجی/آزمون انفرادی، به‌همراه میانگین و انحراف‌معیار مجموعه‌های اعتبارسنجی متقابل. پیش‌بینی‌ها برای هر جفت انتخابگر مدل-ویژگی به‌منظور بررسی‌های گذشته‌نگر ذخیره شدند. ویژگی‌های انتخاب‌شده از هر روش فهرست شده و برای مرجع به فرمت اکسل صادر گردیدند. تمامی نتایج در یک مخزن متمرکز جمع‌آوری شدند تا تحلیل‌های مقایسه‌ای اثربخشی اعتبارسنجی و تعمیم‌پذیری مجموعه آزمون به‌سادگی انجام شود. همان‌طور که در شکل ۴ نشان داده شده است، یک فلوجارت جامع روند یادگیری ماشین برای پیش‌بینی بقای پس از عمل و پیامدهای بیوشیمیایی (SGOT, BUN, SGPT) در بیماران تحت عمل بای‌پس عروق کرونر (CABG) را ارائه می‌دهد. این فلوجارت نحوه ادغام ویژگی‌های عمیق استخراج‌شده از تصاویر آنژیوگرافی کرونری با داده‌های بالینی و آزمایشگاهی را به‌طور کامل نشان می‌دهد و فرایند پیش‌بینی را در قالب یک مدل یادگیری ماشین گام‌به‌گام ترسیم می‌کند.

تنظیمات بهینه‌سازی هایپر پارامتر

این پروتکل بهینه‌سازی جست‌وجوی شبکه‌ای جامعی را برای هر طبقه‌بندی‌کننده ارائه داد تا عملکرد را به حداکثر رسانده و در عین حال پیچیدگی مدل را به‌طور بهینه تنظیم کند. برای رگرسیون لجستیک، پارامتر منظم‌سازی C در یک شبکه لگاریتمی (۰/۱، ۰/۰۱، ۱، ۱۰) بررسی شد. مدل‌های گروهی درختی مانند جنگل تصادفی و تقویت گرادیان بر روی ابرپارامترهایی همچون تعداد تخمین‌گرها ($n_estimators$) و حداکثر عمق درخت (max_depth) تنظیم شدند. به‌طور مشابه، بهینه‌سازی‌های مدل‌های XGBoost و LightGBM شامل نرخ یادگیری و $n_estimators$ بودند که برای تعادل همگرایی آموزش و کاهش خطر بیش‌برازش تنظیم گردیدند. برای ماشین‌های بردار پشتیبان، پارامترهای C و نوع هسته تغییر یافتند، درحالی‌که برای الگوریتم K-نزدیک‌ترین همسایه‌ها، تعداد همسایه‌ها و طرح‌های وزن‌دهی فاصله تنظیم شدند. این فضاها جست‌وجوی از پیش تعریف‌شده، بهینه‌سازی عادلانه را تضمین کرده و به‌این‌ترتیب اعتبار و قابلیت مقایسه نتایج را در بین روش‌های انتخاب ویژگی تقویت نمودند.


شد. در هر تکرار، مدل‌ها روی ۸۰٪ از داده‌های آموزشی دوباره آموزش داده‌شده و بر روی ۲۰٪ باقی‌مانده اعتبارسنجی شدند. تخمین‌های متریک مختص به هر fold تولید شد و میانگین‌ها و انحرافات استاندارد تجمع‌شده، بینش‌هایی در مورد تغییرپذیری و استحکام مدل فراهم کردند. انحرافات استاندارد پایین نشان‌دهندهٔ عملکرد ثابت و قابل‌اطمینان مدل در پارتیشن‌های مختلف داده بود.

بهینه‌سازی فرایارامترها از طریق جست‌وجوی شبکه‌ای در حلقهٔ اعتبارسنجی متقابل انجام شد. در این فرایند، پارامترهایی مانند ضرایب منظم‌سازی (برای مثال، C در رگرسیون لجستیک) و فرایارامترهای گروهی (مانند عمق درخت و تعداد برآوردگرها) تنظیم شدند تا پیکربندی‌های بهینه‌ای که به‌طور دقیق‌تری با داده‌های تجربی هماهنگ هستند، به‌دست آید و از پیش‌فرض‌ها دور شوند. تعمیم‌نهایی از طریق ارزیابی‌های مستقل مجموعه آزمون تأیید گردید و اثربخشی جفت‌سازی‌های مدل-انتخابگر در داده‌های جدید تأیید شد.

قابلیت تفسیر از طریق تحلیل‌های سراسری و سطح نمونه، تأثیر ویژگی‌ها را مورد بررسی قرار داد. انتخابگرهای تعبیه‌شده (مانند SelectKBest، SelectFromModel با جنگل تصادفی، Lasso [Shrinkage and Selection Operator Extra، و Trees) فهرست‌های رتبه‌بندی‌شده‌ای از ۲۰ ویژگی برتر تولید کردند. این ویژگی‌ها از طریق نمودارهای میله‌ای با مقادیر p تعدیل‌شده (با نرخ کشف کاذب یا مقادیر q) برای تأیید اهمیت آماری و کاهش خطاهای نوع اول تجسم شدند. نمایش مقادیر q به‌صورت لگاریتمی، ویژگی‌های برجسته را نمایش داد، درحالی‌که نقشه‌های حرارتی مثلی، تفاوت‌های AUC را در میان ترکیب‌های مختلف مدل-انتخابگر نشان دادند و خوشه‌های عملکردی را شناسایی کردند. نمودارهای منحنی نمرات اهمیت ویژگی، ارزیابی‌های مقایسه‌ای بین انتخابگرها را تسهیل کردند. نمودارهای خلاصه تجمعی، بزرگی و تأثیر جهت‌دار ویژگی‌ها بر پیامدها را مشخص کردند و متغیرهای مرتبط با افزایش ریسک را از متغیرهای محافظت‌کننده تفکیک کردند. همچنین، کاهش ابعاد از طریق t- (Distributed Stochastic Neighbor Embedding) SNE فضاها را با ویژگی با ابعاد بالا را به دو بعد نقشه‌برداری کرد و ساختارهای داده‌ای اساسی و تفکیک‌پذیری کلاس‌ها را تحت پارامترهای مختلف پیچیدگی روشن ساخت. در مجموع، این روش‌های تفسیری، مکانیسم‌های مبتنی بر ویژگی را آشکار کرده، شفافیت مدل را افزایش دادند و کاربرد بالینی مدل‌های پیش‌آگهی مبتنی بر ویژگی‌های عمیق را تقویت کردند.

پیکربندی آزمایشی

پیش‌پردازش مجموعه داده‌ها شامل حفظ ویژگی‌های عددی و اعمال برش مقادیر برای حذف ورودی‌های منفی بود تا تاب‌آوری مدل در برابر ناهنجاری‌های خاص دامنه تقویت شود. داده‌های پردازش‌شده به سه



شکل ۴. فلوجارتی که روند جامع یادگیری ماشین را برای پیش‌بینی بقای پس از عمل و پیامدهای بیوشیمیایی (SGPT، SGOT، BUN) در بیماران CABG نشان می‌دهد، که ویژگی‌های عمیق آنژیوگرافی کرونری را با داده‌های بالینی و آزمایشگاهی ادغام می‌کند.

یافته‌ها

بقای بیماران و سطوح بیوشیمیایی (SGPT، SGOT، BUN) انجام شد. اثربخشی مدل‌ها با استفاده از معیارهای عملکرد کلیدی شامل دقت، صحت، یادآوری، امتیاز F1 و AUC در هر دو مجموعه داده‌های اعتبارسنجی و آزمون ارزیابی شد. علاوه بر این، برای ارزیابی پایداری و تعمیم‌پذیری مدل‌ها، از اعتبارسنجی متقابل استفاده شد که آمار میانگین

ارزیابی عملکرد مدل

یک ارزیابی جامع بر روی چندین مدل یادگیری ماشین، که هر کدام با تکنیک‌های انتخاب ویژگی مختلف ترکیب شده بودند، برای پیش‌بینی

رگرسیون لجستیک و SVC (همراه با انحراف معیار پایین ۰/۰۳۸)، که نشان‌دهنده عملکرد پایدار در بین لایه‌های داده است. معیارهای AUC، که معیار محوری از قدرت تمایز است، به میانگین CV بی‌عیب و نقص ۱۰۰٪ برای رگرسیون لجستیک مبتنی بر Lasso و SVC رسیدند، که توانایی آنها را در تمایز بین کلاس‌های بقا با حداقل خطا تأیید می‌کند. برعکس، ترکیبات با پایداری کمتر، مانند SelectKBest_mutual_info با درخت تصمیم، میانگین CV دقت ۶۸/۵۷٪ را با انحراف معیار ۰/۰۷۱۳ ثبت کردند، که نشان‌دهنده حساسیت بیشتر به زیرمجموعه‌های ویژگی و واریانس بالقوه در قابلیت اطمینان پیش‌بینی است.

در مجموع، SelectFromModel مبتنی بر Lasso به عنوان قابل‌اعتمادترین انتخابگر ویژگی ظاهر شد، به‌ویژه هنگامی که با طبقه‌بندی‌کننده‌های خطی مانند رگرسیون لجستیک و SVC همراه شد، و AUCهای CV استثنایی و حداقل تغییرپذیری را به همراه داشت. این برتری نشان می‌دهد که مکانیسم القاکننده پراکندگی Lasso به‌طور ماهرانه‌ای ویژگی‌های نامربوط را حذف می‌کند و قابلیت تفسیر مدل و عملکرد آن را در پیش‌بینی بقا در مقایسه با رویکردهای اطلاعات متقابل، که گاهی اوقات در سازگاری بین ارزیابی‌های آزمون و CV دچار مشکل می‌شدند، افزایش می‌دهد.

برای مشاهده نتایج و تحلیل‌های دقیق‌تر، شکل ۵ هیت‌مپ مربوط به ارزیابی مدل‌های یادگیری ماشین برای پیش‌بینی بقا و پیامدهای بیوشیمیایی را نشان می‌دهد، که جزئیات مقایسه بین مدل‌ها و ویژگی‌ها را به‌طور واضح ترسیم کرده است.

ارزیابی عملکرد مدل نیتروژن اوره خون (BUN)

تجزیه و تحلیل مدل‌های پیش‌بینی سطح نیتروژن اوره خون (BUN) شامل مجموعه‌ای از روش‌های انتخاب ویژگی SelectKBest با استفاده از f_classif، mutual_info، و SelectFromModel با استفاده از جنگل تصادفی (RF)، Lasso، و ExtraTrees همراه با طبقه‌بندی‌کننده‌هایی از جمله رگرسیون لجستیک، جنگل تصادفی، تقویت گرادیان، SVC، XGBoost، KNN، درخت تصمیم‌گیری و LightGBM بود. معیارهای ارزیابی شامل دقت، صحت، یادآوری، امتیاز F1 و AUC در مراحل اعتبارسنجی، آزمون و اعتبارسنجی متقابل (CV) بودند، که آمار CV بینش‌هایی در مورد واریانس و بایاس مدل ارائه می‌داد (شکل ۶).

و انحراف معیار را محاسبه کرده و بینش‌هایی در مورد سازگاری و استحکام مدل‌ها فراهم کرد.


ارزیابی عملکرد مدل بقا

این بخش از ارزیابی مدل‌های یادگیری ماشین برای پیش‌بینی نتیجه بقا، مجموعه‌ای جامع از استراتژی‌های انتخاب ویژگی و طبقه‌بندی‌کننده‌ها را شامل می‌شود. انتخاب‌کننده‌های ویژگی مورد استفاده شامل SelectKBest با استفاده از توابع امتیازدهی f_classif و mutual_info، در کنار انواع SelectFromModel با استفاده از جنگل تصادفی (RF)، منظم‌سازی Lasso و گروه‌های ExtraTrees هستند. این موارد با طبقه‌بندی‌کننده‌های متنوعی، از جمله رگرسیون لجستیک، جنگل تصادفی، تقویت گرادیان، طبقه‌بندی‌کننده بردار پشتیبان (SVC)، XGBoost، K- نزدیک‌ترین همسایه‌ها (KNN)، درخت تصمیم و LightGBM ادغام شدند. عملکرد مدل‌ها از طریق معیارهای اعتبارسنجی، مجموعه آزمون و اعتبارسنجی متقابل (CV)، از جمله دقت، صحت، فراخوانی، امتیاز F1 و مساحت زیر منحنی مشخصه عملکرد گیرنده (AUC)، به‌طور دقیق ارزیابی شد. علاوه بر این، اعتبارسنجی متقابل مقادیر میانگین و انحراف معیار را برای سنجش استحکام و تعمیم‌پذیری مدل‌ها ارائه می‌دهد.

در ارزیابی‌های اعتبارسنجی، دقت مدل‌ها تنوع قابل‌توجهی را نشان داد، از ۶۶/۶۷٪ برای SelectKBest_mutual_info جفت‌شده با Decision Tree تا ۱۰۰٪ کامل برای SelectKBest_mutual_info جفت‌شده با Random Forest و LightGBM، که پتانسیل بیش‌برازش یا نقاط قوت خاص داده را در پیکربندی‌های خاص برجسته می‌کند. ارزیابی‌های مجموعه تست، که به عنوان شاخص مهمی برای کاربرد در دنیای واقعی عمل می‌کنند، دقت‌هایی از ۶۷/۷۴٪ (برای SelectFromModel_RF جفت‌شده با Decision Tree) تا ۹۰/۳۲٪ (که در چندین جفت‌سازی، مانند SelectKBest_f_classif با Random Forest، Decision Tree، XGBoost، Gradient Boosting و Forest به‌دست آمده است) را نشان داد. نکته قابل‌توجه این است که XGBoost و Forest عملکرد تست برتری را نشان دادند، و اغلب در هنگام هم‌ترازی با SelectKBest_f_classif یا mutual_info از دقت ۹۰٪ فراتر رفتند، که نشان‌دهنده کارایی آنها در ثبت روابط غیرخطی در داده‌های بقا است.

اعتبارسنجی متقابل، پایداری مدل را بیشتر روشن کرد، با میانگین دقت ۹۷/۱۴٪ برای SelectFromModel_Lasso یکپارچه با

نقشه حرارتی معیار بقا



شکل ۵. ارزیابی کامل چندین مدل یادگیری ماشین ترکیب‌شده با روش‌های مختلف انتخاب ویژگی برای پیش‌بینی بقا.

سرم (SGOT)

ارزیابی جامع مدل‌های پیش‌بینی‌کننده سطح ترانس آمیناز گلوتامیک اگزالواسستیک سرم (SGOT) با استفاده از انتخابگرهای ویژگی در ترکیب با طبقه‌بندی‌کننده‌های مختلف انجام شد. معیارهای ارزیابی شامل دقت، صحت، یادآوری، امتیاز F1 و AUC در مراحل اعتبارسنجی، آزمون و اعتبارسنجی متقابل مورد تجزیه و تحلیل قرار گرفتند. میانگین‌ها و انحراف معیار حاصل از CV انعطاف‌پذیری و استحکام مدل‌ها را روشن ساختند (شکل ۷).

نتایج اعتبارسنجی دامنه گسترده‌ای از عملکرد را نشان دادند؛ به‌طوری که دقت از ۴۰٪ در SelectFromModel_RF با SVC تا ۸۶/۶۷٪ در SelectKBest_f_classif با XGBoost متغیر بود، که بیانگر نقش تعیین‌کننده تعامل میان انتخابگر ویژگی و طبقه‌بندی‌کننده در عملکرد اولیه است. در مرحله آزمون، که شاخص کلیدی برای کاربرد عملی محسوب می‌شود، دقت بین ۵۱/۶۱٪ (برای مثال، SelectFromModel_RF با رگرسیون لجستیک و SVC) تا ۷۷/۴۲٪ (برای Lasso با رگرسیون لجستیک و SVC) قرار داشت. ترکیب اخیر همچنین به امتیاز F1 برابر با ۷۵/۸۸٪ دست یافت که نشان‌دهنده تعادل مناسب میان دقت و یادآوری است.

در تحلیل‌های CV، میانگین دقت برای SelectFromModel_Lasso همراه با رگرسیون لجستیک و SVC به ۹۳/۳۳٪ رسید (با انحراف معیار بین ۰/۰۳۸۱ تا ۰/۰۴۸۶)، که حاکی از پایداری بالا و حداقل ریسک بیش‌برازش است. معیارهای AUC نیز نتایج قانع‌کننده‌ای ارائه دادند، به‌طوری که میانگین CV برای Lasso-SVC به ۹۸/۶۴٪ رسید و توانایی تمایز چشمگیر کلاس‌ها را برجسته کرد. با این حال، مدل‌هایی مانند SelectFromModel_ExtraTrees با درخت تصمیم دقت کمتری نشان دادند (میانگین CV حدود ۵۹/۰۵٪ با انحراف معیار ۰/۱۰۲۶)، که بیانگر بی‌ثباتی بالقوه در مدیریت ویژگی‌ها است.

انتخاب مبتنی بر Lasso، به‌ویژه در ترکیب با مدل‌های خطی، به‌طور مداوم عملکرد بهتری نسبت به سایر روش‌ها داشت و دقت آزمون و AUC‌های CV تقریباً ایدئالی را ارائه کرد. در مقابل، رویکردهای mutual_info و ExtraTrees با افزایش واریانس و دقت کمتر از ۷۵٪ همراه بودند، که نشان می‌دهد منظم‌سازی مبتنی بر Lasso توانایی بالاتری در کاهش نویز و حذف ویژگی‌های غیرمرتبط در داده‌های مربوط به SGOT دارد. این نتایج، نقش کلیدی انتخاب پراکنده در بهبود مدل‌های پیش‌بینی‌کننده آنزیم‌ها در حضور متغیرهای مخدوش‌کننده را برجسته می‌کند.


نتایج مرحله اعتبارسنجی، اختلاف عملکرد قابل‌توجهی را نشان داد، به‌طوری که دقت برای SelectKBest_mutual_info با رگرسیون لجستیک و درخت تصمیم به پایین‌ترین حد خود، یعنی ۴۰٪ رسید، درحالی‌که برای مدل‌های مبتنی بر f_classif مانند رگرسیون لجستیک، SVC، KNN، و LightGBM دقت به ۷۳/۳۳٪ رسید. معیارهای مجموعه آزمون که برای ارزیابی تعمیم‌پذیری خارجی ضروری هستند، نسبتاً پایین بودند. برای SelectFromModel_ExtraTrees با درخت تصمیم و Lasso با تقویت گرادیان، دقت به ۷۷/۴۲٪ رسید، درحالی‌که در تنظیمات ضعیف‌تر مانند SelectKBest_mutual_info با درخت تصمیم، دقت به ۵۱/۶۱٪ کاهش یافت. این نتایج آزمون چالش‌های موجود در ترجمه موفقیت مدل‌ها در مراحل اعتبارسنجی به داده‌های دیده‌نشده را نشان می‌دهند، که احتمالاً به دلیل نویز ویژگی یا عدم تعادل کلاس در مجموعه داده‌های BUN است.

اعتبارسنجی متقابل، دیدگاه عمیق‌تری در مورد قابلیت اطمینان مدل‌ها ارائه داد. میانگین دقت برای مدل‌های برتر بین ۷۰ تا ۸۰ درصد متغیر بود و SelectFromModel_Lasso با رگرسیون لجستیک و SVC به دقت برجسته ۹۳/۳۳٪ (با انحراف معیار ۰/۰۷۱۳) دست یافت، که نشان‌دهنده سازگاری قوی در هر دو حالت است. مقادیر AUC در طول CV قابل‌توجه اما متوسط بودند و برای Lasso-SVC به حداکثر ۹۵/۲۱٪ رسیدند که نشان‌دهنده جدایی‌پذیری کلاس‌های خوب اما قابل‌بهبود است. مدل‌هایی که از Gradient Boosting یا Decision Tree استفاده می‌کردند، تنوع قابل‌توجهی را نشان دادند، که با انحراف معیار دقت CV ۰/۱۲۰۵ برای mutual_info با درخت تصمیم نمایان شد. این امر احتمالاً ناشی از تمایلات بیش‌برازش در انتخاب ویژگی‌ها است.

نوع Lasso از SelectFromModel به‌طور مداوم عملکرد را بهبود بخشید، به‌ویژه هنگامی که با رگرسیون لجستیک و SVC ترکیب شد و بهترین دقت CV و AUC را ارائه داد. در مقابل، انتخاب‌های mutual_info اغلب دقتی کمتر از ۷۰٪ داشتند، که نشان‌دهنده محدودیت‌هایی در تشخیص وابستگی‌های ویژگی‌های خاص BUN در مقایسه با تکنیک‌های منظم‌سازی مانند Lasso یا امتیازدهی آماری مانند f_classif است. این نتایج آزمون محور، ضرورت استفاده از منظم‌سازی برای افزایش دقت پیش‌بینی در ارزیابی‌های بالینی BUN را تقویت می‌کنند.


ارزیابی عملکرد مدل گلوتامیک اگزالواسستیک ترانس آمیناز

نقشه حرارتی معیار سطح نیتروژن اوره خون (BUN)



شکل ۶. عملکرد چندین مدل یادگیری ماشین را در پیش‌بینی نیتروژن اوره خون (BUN)، یک نشانگر مهم عملکرد کلیه که ممکن است بر نتایج پس از عمل در بیماران CABG تأثیر بگذارد، نشان می‌دهد که از طریق طیف وسیعی از معیارها ارزیابی شده و به صورت نقشه حرارتی نمایش داده شده است.

نقشه حرارتی معیار ترانس آمیناز گلوتامیک-اگرالواسیتیک سرم (SGOT)



شکل ۷. ارزیابی گسترده‌ای از مدل‌های متنوع یادگیری ماشین همراه با روش‌های مختلف انتخاب ویژگی برای پیش‌بینی ضریب SGOT. عملکرد مدل با استفاده از معیارهای چندگانه دقت، صحت، فراخوانی، امتیاز F_1 و AUC در هر دو مجموعه اعتبارسنجی و آزمون، در کنار میانگین‌ها و انحرافات استاندارد اعتبارسنجی متقابل برای سنجش سازگاری و استحکام، اندازه‌گیری شد.

ارزیابی عملکرد مدل گلوتامیک پیروویک ترانس آمیناز سرم (SGPT)

مدل‌های پیش‌بینی سطح ترانس‌آمیناز گلوتامیک پیروویک سرم (SGPT) با استفاده از انتخابگرهای ویژگی مختلف در ترکیب با طبقه‌بندی‌کننده‌های استاندارد مورد بررسی دقیق قرار گرفتند. معیارهای دقت، صحت، یادآوری، امتیاز F1 و AUC در مراحل اعتبارسنجی، آزمون و اعتبارسنجی متقابل (CV) ارزیابی شدند. نتایج CV که شامل میانگین و انحراف معیار بود، بینش دقیقی از پویایی عملکرد مدل‌ها ارائه کرد (شکل ۸).

دقت اعتبارسنجی دامنه‌ای از ۶۰٪ (برای مثال در SelectKBest و $_mutual_info$ با درخت تصمیم و SelectFromModel و ExtraTrees با SVC) تا ۸۶/۶۷٪ (برای چندین ترکیب مبتنی بر f_classif مانند Gradient Boosting و SVC) را نشان داد. این نتایج بیانگر قابلیت‌های متنوع مدل‌ها در مراحل آموزشی بودند. در مرحله آزمون، که شاخص کلیدی برای ارزیابی تعمیم‌پذیری خارجی محسوب می‌شود، دقت به ۸۷/۱۰٪ برای SelectFromModel_Lasso همراه با Gradient Boosting و درخت تصمیم رسید. این ترکیب همچنین به امتیاز F1 معادل ۸۶/۲۸٪ دست یافت که نشان‌دهنده تعادل مناسب میان دقت و یادآوری بود.

اعتبارسنجی متقابل این یافته‌ها را تقویت کرد؛ به‌طوری که میانگین دقت برای Lasso-SVC (با انحراف معیار ۰/۰۱۹۰) به ۹۹/۰۵٪ و برای Lasso-Logistic Regression (با انحراف معیار ۰/۰۲۳۳) به ۹۸/۱۰٪ رسید که بیانگر سازگاری تقریباً بی‌نقص است. معیارهای AUC در CV نیز نتایج برجسته‌ای ارائه دادند، به‌طوری که برای هر دو ترکیب Lasso-Logistic Regression و SVC به ۹۹/۷۱٪ رسیدند؛ عددی که نشان‌دهنده قدرت تمایز بسیار بالا همراه با واریانس ناچیز است. در مجموع، SelectFromModel مبتنی بر Lasso، به‌ویژه در ترکیب با رگرسیون لجستیک و SVC، بهترین عملکرد را نشان داد و با

ارائه نتایج آزمون پایدار و مقادیر CV تقریباً کامل، تعمیم‌پذیری قدرتمندی را تضمین کرد. در مقابل، رویکردهای $_mutual_info$ با دقت حدود ۸۰٪ و تغییرپذیری بالا (برای مثال، انحراف معیار ۰/۱۱۱۱ در جنگل تصادفی) عقب‌تر بودند که بیانگر ضعف در مدیریت ویژگی‌های بیش‌میبایی هم‌بسته نسبت به Lasso است. این تحلیل‌ها برتری Lasso را در مدل‌سازی SGPT تأیید کرده و نقش آن را در دستیابی به پیش‌بینی‌های دقیق و قابل‌اعتماد برجسته می‌سازد.


نقشه حرارتی فواصل AUC در ترکیبات مدل-انتخابگر

شکل ۹ نمایی بصری از عملکرد ترکیب‌های مختلف روش‌های انتخاب ویژگی و طبقه‌بندی‌کننده‌ها را هنگام اعمال بر روی ویژگی‌های عمیق ارائه می‌دهد. نقشه حرارتی حاصل با استفاده از کدگذاری رنگی طراحی شده است تا تنوع عملکرد مدل‌ها را به‌طور شفاف نشان دهد: سلول‌های آبی بیانگر اختلاف اندک در مقادیر AUC هستند که نشان‌دهنده عملکرد مشابه میان مدل‌ها است، درحالی که سلول‌های قرمز اختلافات بالای AUC و در نتیجه ناهمبستگی عملکرد مدل‌ها را نشان می‌دهند.


بررسی این نقشه حرارتی آشکار می‌سازد که بخش عمده‌ای از سلول‌ها با سایه‌های آبی تیره نمایش داده شده‌اند، که نشان‌دهنده سطح بالایی از سازگاری بین ترکیبات مختلف انتخابگرها و طبقه‌بندی‌کننده‌ها است. این الگو نشان می‌دهد که باوجود تنوع روش‌های مورد استفاده، بسیاری از خطوط لوله توانسته‌اند نتایج پیش‌بینی قابل‌مقایسه‌ای ارائه دهند. چنین سازگاری‌ای یافته‌ای امیدوارکننده محسوب می‌شود، زیرا نشان می‌دهد که رویکردهای مختلف قادرند به‌طور مؤثر اطلاعات موجود در مجموعه داده را به کار گیرند و انعطاف‌پذیری قابل‌توجهی در انتخاب مدل بدون کاهش کارایی فراهم کنند.

به بیان دیگر، این نقشه حرارتی نه تنها به عنوان ابزاری تشخیصی برای مقایسه عملکرد مدل‌ها عمل می‌کند، بلکه بر استحکام و تطبیق‌پذیری مجموعه داده در خطوط تحلیلی متنوع نیز تأکید دارد.

نقشه حرارتی معیار ترانس آمیناز گلوتامیک-پیرویک سرم (SGPT)



شکل ۸. ارزیابی جامعی از چندین مدل یادگیری ماشینی همراه با تکنیک‌های مختلف انتخاب ویژگی برای پیش‌بینی ضریب SGPT. عملکرد مدل با استفاده از چندین معیار دقت، یادآوری، امتیاز F1 و AUC در مجموعه‌های اعتبارسنجی و آزمایش، همراه با میانگین و انحراف معیار اعتبارسنجی متقابل برای ارزیابی سازگاری و استحکام، ارزیابی شد.



شکل ۹. نگاهی دقیق به این موضوع ارائه می‌دهد که چگونه مجموعه ویژگی‌های عمیق مختلف می‌توانند چهار پیامد بالینی مهم را پیش‌بینی کنند: بقای کلی، سطح نیتروژن اوره خون (BUN)، ترانس آمیناز گلوتامیک-اگزالواسیتیک سرم (SGOT) و ترانس آمیناز گلوتامیک-پیروویک سرم (SGPT).

که پیچیدگی تعداد مؤثر همسایه‌های در نظر گرفته شده در طول جاسازی را کنترل می‌کند و مقادیر پایین‌تر بر جزئیات ریزمقیاس تأکید می‌کنند، درحالی‌که مقادیر بالاتر الگوهای وسیع‌تری را ثبت می‌کنند (شکل ۱۰). با افزایش میزان سرگشتگی (perplexity) از ۵ تا ۱۰۰، تحول قابل توجهی در ساختار جاسازی داده‌ها مشاهده می‌شود. در سرگشتگی ۵، نقاط به‌طور گسترده در یک محدوده مختصاتی بزرگ پراکنده‌اند و

الگوریتم کاهش ابعاد t-SNE

پنل الف: وضعیت بقا

تصاویر دوبعدی t-SNE از مجموعه داده‌ها را که براساس وضعیت بیمار (آبی برای وضعیت ۰، نارنجی برای وضعیت ۱) رنگ‌آمیزی شده‌اند، در مقادیر رو به افزایش پیچیدگی ارائه می‌دهد. t-SNE یک تکنیک کاهش ابعاد غیرخطی است که ساختارهای داده محلی را حفظ می‌کند، به‌طوری

پنل ج: SGOT

در اینجا، جاسازی‌های t-SNE با استفاده از سطوح دوتایی ترانس آمیناز گلوتامیک اگزالواسیتیک سرم، که یک نشانگر زیستی برای سلامت کبد است، رنگ آمیزی شده‌اند. پارامتر سرگشتگی مانند قبل، جاسازی‌ها را تعدیل می‌کند.

با افزایش میزان سرگشتگی از ۵ تا ۱۰۰، الگوی توزیع نقاط تغییرات قابل توجهی را نشان می‌دهد. در سرگشتگی ۵، پراکندگی نقاط بسیار وسیع است و نقاط آبی و نارنجی به‌طور کامل با یکدیگر ترکیب شده‌اند که فقدان ساختار قابل تشخیص در سطح پیچیدگی پایین را برجسته می‌کند. با افزایش سرگشتگی به ۳۰، فشردگی آغاز شده و تجمع‌های سستی شکل می‌گیرند، اما همپوشانی قابل توجهی میان کلاس‌ها همچنان وجود دارد و هیچ خوشه‌بندی غالبی براساس سطح SGOT دیده نمی‌شود. در سرگشتگی ۵۰، نقاط به تدریج ادغام شده و خوشه‌های مهمی تشکیل می‌شود که در آنها نقاط نارنجی بیشتر در حاشیه قرار دارند؛ این امر بهبود نسبی در جداسازی و نمایانگر واریانس‌های اساسی مرتبط با SGOT است. در نهایت، در سرگشتگی ۱۰۰، جاسازی به‌طور چشمگیری متمرکز می‌شود، به گونه‌ای که نقاط آبی در هسته‌ای متراکم در مرکز تجمع یافته و نقاط نارنجی به‌طور نسبتاً ایزوله قرار می‌گیرند؛ این نشان‌دهنده تقویت تمایز طبقاتی با افزایش پیچیدگی و تسهیل ارزیابی بصری تفکیک‌پذیری مبتنی بر SGOT است.

پنل د: SGPT

این شکل نهایی، پیش‌بینی‌های t-SNE را نشان می‌دهد که با سطوح دوتایی گلوتامیک پیروویک ترانس آمیناز سرم (آبی برای سطح ۰، نارنجی برای سطح ۱)، یکی دیگر از شاخص‌های کلیدی آنزیم کبد، در سراسر طیف سرگشتگی، رنگ آمیزی شده‌اند.


با افزایش میزان سرگشتگی از ۵ تا ۱۰۰، الگوی توزیع نقاط تحولات چشمگیری را نشان می‌دهد. در سرگشتگی ۵، نقاط به‌طور گسترده پراکنده و رنگ‌های آبی و نارنجی به‌طور کامل با هم آمیخته شده‌اند که نشان‌دهنده غلبه نويز محلی بر الگوهای جهانی است. در سرگشتگی ۳۰، خوشه‌هایی محدود شکل می‌گیرند اما همپوشانی قابل توجه بین طبقات همچنان باقی است و این امر دیدگاه روشنی نسبت به تمایز مبتنی بر SGPT ارائه نمی‌دهد. در سرگشتگی ۵۰، فشردگی بیشتری رخ می‌دهد و نقاط نارنجی شروع به تفکیک به زیرگروه‌هایی در میان مناطق غالباً آبی می‌کنند که نشان‌دهنده جداسازی نسبی اما هنوز ناقص است. نهایتاً در سرگشتگی ۱۰۰، جاسازی به‌طور قابل توجهی منقبض شده و خوشه‌های متراکمی شکل می‌گیرد که در آن نقاط نارنجی به‌طور مشخص گروه‌بندی شده و توسط نقاط آبی احاطه شده‌اند، این امر بیانگر آن است که افزایش سردرگمی ساختار داده‌ها را نسبت به سطوح SGPT بهتر بازتاب می‌دهد.

همپوشانی قابل توجهی میان نقاط آبی و نارنجی وجود دارد که نشان‌دهنده جداسازی ضعیف کلاس‌ها و تمرکز صرف بر شباهت‌های محلی بدون آشکارسازی ساختار کلی است. با رسیدن به سرگشتگی ۳۰، توزیع نقاط فشرده‌تر می‌شود، هرچند که دسته‌ها هنوز به‌طور کامل تفکیک نشده‌اند و پراکندگی میان کلاسی حفظ شده است؛ در عین حال، نشانه‌هایی از خوشه‌بندی نوظهور و الگوهای اولیه قابل مشاهده است. در سرگشتگی ۵۰، انقباض بیشتری رخ می‌دهد و خوشه‌های نسبتاً سستی شکل می‌گیرند؛ نقاط آبی در نواحی مرکزی غالب می‌شوند، درحالی که نقاط نارنجی به تدریج به سمت حاشیه‌ها تمایل پیدا می‌کنند که حاکی از بهبود نسبی در تمایز طبقاتی است. در نهایت، در سرگشتگی ۱۰۰، جاسازی به شدت فشرده شده و خوشه‌های متراکم با جدایی مشخص شکل می‌گیرند؛ نقاط نارنجی در یک زیرگروه متمرکز قرار می‌گیرند و نقاط آبی عمدتاً فضای پیرامونی را اشغال می‌کنند، که نشان می‌دهد افزایش پیچیدگی منجر به آشکارسازی بهتر ساختارهای مرتبط با وضعیت در داده‌ها می‌شود.

پنل ب: فاکتور BUN

این شکل، پیش‌بینی‌های t-SNE را که با سطوح دوتایی نیتروژن اوره خون (BUN) رنگ آمیزی شده‌اند (آبی برای سطح ۱، نارنجی برای سطح ۰)، با استفاده از همان روند تصادفی نشان می‌دهد. BUN یک نشانگر بالینی است که اغلب با عملکرد کلیه مرتبط است و رنگ آمیزی دوتایی احتمالاً نشان‌دهنده آستانه‌های طبیعی در مقابل غیرطبیعی است.

با افزایش میزان سرگشتگی از ۵ تا ۱۰۰، تغییرات چشمگیری در ساختار توزیع نقاط مشاهده می‌شود. در سرگشتگی ۵، نقاط به صورت گسترده پراکنده و همپوشانی زیادی بین نقاط نارنجی (طبقه اکثریت) و آبی وجود دارد، به طوری که هیچ خوشه‌بندی مشخصی شکل نمی‌گیرد و واریانس‌های محلی نسبت به الگوهای طبقه‌بندی برتری دارند. با افزایش سرگشتگی به ۳۰، توزیع نقاط فشرده‌تر شده و خوشه‌بندی‌های اولیه پدیدار می‌شود، اما همچنان جداسازی قوی بین نقاط آبی و نارنجی مشاهده نمی‌شود که نشان‌دهنده تمایز محدود در این مقیاس است. در سرگشتگی ۵۰، خوشه‌ها فشرده‌تر شده و نقاط آبی به صورت گروه‌های کوچک و پراکنده در میان پس‌زمینه نارنجی ظاهر می‌شوند؛ این تفکیک جزئی، ارتباط متوسط بین سطح BUN و ساختار داده‌ها را منعکس می‌کند. نهایتاً در سرگشتگی ۱۰۰، جاسازی بسیار فشرده باعث شکل‌گیری خوشه‌های متمرکز نقاط آبی در مرکز و توزیع نقاط نارنجی در اطراف آنها می‌شود که جداسازی بهتر کلاس‌ها را نشان داده و حاکی از آشکارسازی روابط جهانی مرتبط با طبقه‌بندی BUN در سطوح پیچیده‌تر است.




شکل ۱۰. نمایش دوبعدی ویژگی‌های مربوط به SGPT و SGOT با استفاده از الگوریتم t-SNE در مقادیر مختلف Perplexity


یک روش گروهی که میانگین چندین درخت تصمیم‌گیری را می‌گیرد؛ و جنگل تصادفی (SelectFromModel_RF)، یکی دیگر از رویکردهای گروهی محبوب مبتنی بر درخت، بودند. هر روش دیدگاه منحصر به فردی در مورد اهمیت ویژگی‌ها ارائه داد. سپس ویژگی‌ها را براساس اهمیت آنها برای هر تکنیک رتبه‌بندی کردیم و برای تجزیه و تحلیل عمیق‌تر بر روی ۲۰ ویژگی برتر تمرکز کردیم. این ویژگی‌های برتر در شکل‌های ۱۱ تا ۱۴ نمایش داده شده‌اند و مقایسه بصری واضحی از آنچه هر روش به عنوان مرتبط‌ترین موارد برجسته می‌کند، ارائه می‌دهند.

تحلیل نمودارهای اهمیت ویژگی‌ها


برای مشخص کردن ویژگی‌هایی که بیشترین ارتباط را با نتیجه ما دارند، پنج تکنیک انتخاب ویژگی متفاوت اما مکمل را به کار بردیم. این تکنیک‌ها شامل اطلاعات متقابل (SelectKBest_mutual_info) که وابستگی بین متغیرها را اندازه‌گیری می‌کند؛ منظم‌سازی (LASSO) که به کاهش ضرایب ویژگی‌های کم‌اهمیت‌تر به صفر معروف است؛ آزمون (F-ANOVA) که تفاوت‌های بین گروه‌ها را ارزیابی می‌کند؛ درختان اضافی (SelectFromModel_Extra_Trees)،




شکل ۱۱. ۲۰ امتیاز برتر اهمیت ویژگی برای پیش‌بینی بقا، که با استفاده از پنج روش انتخاب ویژگی مختلف شناسایی شده‌اند.



شکل ۱۲. ۲۰ امتیاز برتر اهمیت ویژگی برای پیش‌بینی BUN، که با استفاده از پنج روش انتخاب ویژگی مختلف شناسایی شده‌اند.



شکل ۱۳. ۲۰ امتیاز برتر اهمیت ویژگی برای پیش‌بینی SGOT، که با استفاده از پنج روش انتخاب ویژگی مختلف شناسایی شده‌اند.



شکل ۱۴. ۲۰ امتیاز برتر اهمیت ویژگی برای پیش‌بینی SGPT، که با استفاده از پنج روش انتخاب ویژگی مختلف شناسایی شده‌اند.

بحث

Lasso است. در مقایسه با چهارچوب یادگیری ماشینی نینومیا و همکارانش برای انتخاب درمان در بازسازی عروق PCI در مقابل CABG (۱۸)، تمرکز مطالعه ما بر پیامدهای پس از عمل قرار داشت و با این وجود از قدرت تمایز بالاتر $AUC > ۰.۹۵$ برای چندین نقطه پایانی برخوردار بود. همچنین، مطالعه موری و همکارانش که تقویت گرادیان را برای پیش‌بینی ریسک پویا و رویدادهای حین عمل به کار گرفتند، دقتی در حدود ۸۵ تا ۹۰٪ برای مرگ‌ومیر گزارش کرد (۱۹)؛ اگرچه نتایج آنها قابل مقایسه است، اما نسبت به دقت اعتبارسنجی متقابل ما پایین‌تر بوده و اهمیت استخراج ویژگی عمیق از آنژیوگرافی را به‌عنوان ارزش افزوده نشان می‌دهد.

مدل‌های ریسک مرگ‌ومیر سنتی، همان‌طور که توسط کریم و همکارانش (۲۰) مرور شده است، غالباً به دلیل تکیه بر متغیرهای ایستا به دقتی کمتر از ۸۰٪ محدود می‌شوند. خط لوله ترکیبی ما، با استفاده از نمایش‌های سلسله‌مراتبی تصویر، این محدودیت را برطرف ساخته و به نقد رادست و همکارانش (۲۱) پاسخ می‌دهد که مدل‌های مبتنی بر ادعاها را فاقد حساسیت نسبت به ظرافت‌های تصویربرداری دانسته‌اند.

یافته‌های ما همچنین فراتر از دقت‌های گزارش‌شده در مرور سیستماتیک ما و همکارانش در یادگیری ماشینی برای CCTA هستند، جایی که حداکثر دقت ۸۵٪ برای پیش‌بینی رویدادهای نامطلوب عمده گزارش شد (۲۲). استفاده از ResNet-18 در مطالعه حاضر، به دلیل تولید بردارهای ویژگی غنی ۵۱۲ بعدی، پیش‌بینی‌های دقیق‌تری برای بقا و نشانگرهای زیستی ارائه داد. درحالی‌که ویلیامز و همکارانش در مطالعه SCOT-HEART حدود ۸۰٪ دقت برای پیش‌بینی CAD پرخطر با داده‌های CT گزارش کردند (۲۳)، مدل ما با گنجاندن نشانگرهای زیستی همچون BUN و آنزیم‌های کبدی، دامنه وسیع‌تری از پیش‌آگهی را پوشش داد و عوارض کلیوی و کبدی اغلب مغفول‌مانده در مطالعات تصویربرداری محور را در نظر گرفت.

مقایسه با دیگر مطالعات یادگیری عمیق نیز برتری رویکرد چندوجهی ما را نشان می‌دهد: از جمله کار تریودی و همکارانش روی ECG با AUC حدود ۰/۸۵ (۲۴) دربرابر ۰/۹۹ مدل ما برای SGPT؛ یا مطالعه برنلد و همکارانش بر روی CCTA با وضوح بالا ($AUC \sim 90\%$) (۲۵) که مشابه نتایج ما بود اما صرفاً بر تشخیص تمرکز داشت، درحالی‌که مدل حاضر نظارت بر پیامدهای پس از عمل را گسترش می‌دهد. یافته‌های زیرک و همکارانش (۲۶) و لین و همکارانش (۲۷) در تحلیل میوکارد و پلاک نیز با دقت‌های حدود ۸۰ تا ۹۰٪ همراه بود، اما مدل ما با ادغام آزمایش خون دو مرحله‌ای و تصویربرداری استاتیک، وضوح زمانی و تمایز بهتری ایجاد کرده است.

پیامدهای بالینی این یافته‌ها چشمگیر است. مدل‌های ما امکان طبقه‌بندی دقیق‌تر ریسک و مدیریت فردمحور در دوره عمل را فراهم می‌کنند؛ موضوعی که برای مراکز درمانی سطح سوم - مانند مراکز ایران که بار بیماری چندرگی بالا دارند - اهمیت ویژه‌ای دارد. به‌ویژه، شناسایی

در این مطالعه، ما اثربخشی ادغام ویژگی‌های عمیق استخراج‌شده از تصاویر آنژیوگرافی کرونری - با استفاده از مدل از پیش آموزش‌دیده ResNet-18 - را با داده‌های بالینی و نشانگرهای زیستی برای پیش‌بینی پیامدهای کلیدی پس از جراحی قلب باز، به‌ویژه پیوند CABG، نشان دادیم. مدل‌های طراحی‌شده با بهره‌گیری از ترکیبی از تکنیک‌های انتخاب ویژگی و طبقه‌بندی‌کننده‌ها به سطوح قابل توجهی از عملکرد دست یافتند؛ به‌گونه‌ای که دقت اعتبارسنجی متقابل در پیش‌بینی بقا، با استفاده از انتخاب مبتنی بر Lasso در کنار رگرسیون لجستیک یا طبقه‌بندی‌کننده‌های بردار پشتیبان، به $97/14\%$ رسید.

به همین ترتیب، در پیش‌بینی نشانگرهای زیستی همچون نیتروژن اوره خون (BUN)، ترانس آمیناز گلوتامیک اکزالواسستیک سرم SGOT و SGPT به ترتیب دقت‌های $93/33\%$ ، $93/33\%$ ، $99/05\%$ به‌دست آمد. این نتایج بیانگر استحکام رویکردهای مبتنی بر منظم‌سازی، به‌ویژه Lasso، در مدیریت داده‌های با ابعاد بالا هستند. یافته‌های ما بر ارزش هم‌افزایی ادغام داده‌های چندوجهی تأکید دارند؛ رویکردی که ویژگی‌های عمیق رادیولوژیکی را با دینامیک زمانی نشانگرهای زیستی و متغیرهای بالینی ترکیب کرده و موجب افزایش دقت پیش‌آگهی در جمعیتی می‌شود که با بیماری چندرگی پیشرفته مشخص می‌گردند.

در مقام مقایسه، رویکرد ما فراتر از مدل‌های سنتی طبقه‌بندی ریسک (مانند مدل‌هایی که صرفاً بر نمرات بالینی نظیر EuroSCORE متکی هستند) عمل می‌کند. این مدل‌ها، اگرچه بنیان‌گذار پیش‌بینی خطر در جراحی قلب باز بوده‌اند، اما در سناریوهای پیچیده CABG قدرت تمایز محدودی دارند. برای مثال، تقویت EuroSCORE توسط حجازی با استفاده از یادگیری ماشینی موجب بهبود پیش‌بینی مرگ‌ومیر شد، اما تحلیل آن به عوامل پیش‌عمل محدود بود؛ درحالی‌که ادغام ما از ویژگی‌های عمیق مشتق‌شده از تصویربرداری حین عمل و داده‌های آزمایش خون طولی، چشم‌اندازی پویا و جامع فراهم کرد که به مقادیر AUC برتر (تا 1.00) در اعتبارسنجی متقابل برای بقا منجر شد (۱۵). این یافته با گزارش بهنوش و همکارانش همسو است که دقت ۸۰ تا 90% را در پیش‌بینی مرگ‌ومیر یک‌ساله بیماران CABG مبتلا به فشار خون بالا صرفاً براساس داده‌های بالینی نشان دادند (۱۶)؛ باین‌حال، مدل‌های ما با ترکیب ورودی‌های مبتنی بر آنژیوگرافی فراتر رفته و به دقت $90/32\%$ در مجموعه آزمون برای بقا دست یافتند.

به‌طور مشابه، برخلاف مطالعه گذشته‌نگر المحروک و همکارانش درباره بیماری اصلی چپ محافظت‌نشده که مدل‌های جنگل تصادفی را با دقت حدود 85% در پیش‌بینی مرگ‌ومیر بیمارستانی گزارش کردند (۱۷)، روش‌های گروهی ما مانند XGBoost و LightGBM پایداری بیشتری را میان چین‌ها نشان دادند (انحراف معیار تا 0.190)؛ ویژگی‌ای که احتمالاً ناشی از کاهش ابعاد توسط انتخابگرهای تعبیه‌شده مانند

ضروری است.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

پژوهش حاضر پس از بررسی و تأیید کمیته اخلاق در پژوهش دانشگاه علوم پزشکی جندی شاپور اهواز و مطابق با اصول اخلاقی پژوهش های پزشکی انجام شد. محرمانگی اطلاعات بیماران در تمامی مراحل پژوهش رعایت شد و داده ها صرفاً در چارچوب اهداف پژوهش مورد استفاده قرار گرفتند. شماره U-03381.

حامی مالی

این پژوهش با حمایت دانشگاه علوم پزشکی جندی شاپور اهواز و در قالب طرح پژوهشی شماره U-03381 انجام شده است.

مشارکت نویسندگان

سید مسعود رضایی جو: طراحی و مفهوم‌پردازی پژوهش، تدوین روش‌شناسی، نظارت علمی، مدیریت طرح، تفسیر یافته‌ها و بازبینی علمی متن مقاله؛ فاطمه جواهر فروش‌زاده: مشارکت در طراحی مطالعه، روش‌شناسی، نظارت علمی و بالینی، تفسیر یافته‌ها و بازبینی متن مقاله؛ مرضیه رشادتیان: مشاوره علمی و روش‌شناختی، مشارکت در تحلیل و تفسیر داده‌ها و بازبینی مقاله؛ علیرضا افتخار: جمع‌آوری و آماده‌سازی داده‌ها، پردازش داده‌ها و تصاویر، انجام تحلیل‌ها، اجرای مدل‌های یادگیری ماشین و یادگیری عمیق و تهیه پیش‌نویس اولیه مقاله. کلیه نویسندگان نسخه نهایی مقاله را مطالعه و تأیید کرده‌اند.

تعارض منافع

نویسندگان اعلام می‌کنند که در ارتباط با پژوهش حاضر هیچ گونه تعارض منافی وجود ندارد.

تشکر و قدردانی

نویسندگان از معاونت تحقیقات و فناوری دانشگاه علوم پزشکی جندی شاپور اهواز به دلیل حمایت از این پژوهش و همچنین از مسئولان و کارکنان مراکز قلب مشارکت‌کننده در اهواز که در فرآیند جمع‌آوری داده ها و انجام این مطالعه همکاری داشتند، صمیمانه تشکر و قدردانی می‌کنند.

زیرگروه‌های پرخطر نظیر بیماران با مرگومیر بالا در CABG تک‌شریانی می‌تواند مداخلات هدفمند را تسهیل کرده و به کاهش بالقوه مرگومیر (۷٪ در گروه ما) بینجامد. علاوه بر این، ابزارهای تفسیرپذیری مانند نمودارهای اهمیت ویژگی و تجسم‌های t-SNE، با کاهش ماهیت جعبه‌سیاه مدل‌ها، اعتماد بالینی را افزایش داده و مسیر ادغام آنها در پرونده‌های الکترونیک سلامت را هموار می‌کنند.

با این وجود، محدودیت‌هایی باید مد نظر قرار گیرند. نمونه مطالعه، هرچند به‌طور جامع حاشیه‌نویسی شده، تنها شامل ۱۵۲ بیمار از دو مرکز درمانی ایران طی چهار سال است که می‌تواند تعمیم‌پذیری را محدود کند. همچنین، استفاده از ResNet-18 آموزش‌دیده بر تصاویر غیرپزشکی خطر تغییر دامنه را در پی دارد، هرچند تنظیم دقیق می‌تواند در آینده این محدودیت را کاهش دهد. فاصلهٔ دوروزهٔ آزمایش خون گرچه تغییرات حاد را ثبت می‌کند، اما توانایی پایش دینامیک‌های طولانی‌مدت را ندارد. در مطالعات آتی، اعتبارسنجی چندمرکزی آینده‌نگر با جمعیت‌های بزرگ‌تر، بهره‌گیری از معماری‌های پیشرفته (مانند ترانسفورمرها یا یادگیری فدرال) و بررسی روش‌های استنتاج علی می‌تواند دقت و عمق تحلیل را افزایش دهد. در مجموع، این کار با ادغام داده‌های چندوجهی، زمینه را برای پزشکی دقیق مبتنی بر هوش مصنوعی در جراحی قلب و عروق فراهم می‌کند و شکاف میان بینش‌های تصویربرداری و پیامدهای بالینی را پر می‌سازد.

نتیجه‌گیری

نتایج این مطالعه نشان داد که ادغام داده‌های چندوجهی شامل تصاویر آنژیوگرافی عروق کرونر، متغیرهای بالینی و شاخصهای آزمایشگاهی با استفاده از روشهای یادگیری ماشین و یادگیری عمیق، می‌تواند عملکرد مناسبی در پیش‌بینی پیامدهای پس از جراحی بایپس عروق کرونر داشته باشد. در میان روشهای بررسی‌شده، رویکردهای مبتنی بر انتخاب ویژگی Lasso، به ویژه در ترکیب با رگرسیون لجستیک و ماشین بردار پشتیبان، عملکرد بهتری نشان دادند. دقت بالای مدلها در پیش‌بینی بقا و شاخصهای بیوشیمیایی BUN، SGOT و SGPT بیانگر ظرفیت بالقوه این رویکرد برای توسعه ابزارهای پشتیبان تصمیمگیری بالینی است. با این حال، برای تأیید قابلیت تعمیم و کاربرد بالینی این مدلها، ارزیابی آنها در مطالعات آینده با حجم نمونه بیشتر و مجموعه داده‌های مستقل

References

- Mensah GA, Fuster V, Murray CJL, Roth GA. Global burden of cardiovascular diseases and risks collaborators (2023) global burden of cardiovascular diseases and risks 1990-2022. *JACC*. 2023;82(25):2350-473. [[10.1016/j.jacc.2023.11.007](#)] [[PMID](#)]
- Chong B, Jayabaskaran J, Jauhari SM, Chan SP, Goh R, Kueh MTW, et al. Global burden of cardiovascular diseases: projections from 2025 to 2050. *Eur J Prev Cardiol*. 2025;32(11):1001-15. [[10.1093/eurjpc/zwae281](#)] [[PMID](#)]
- Khalaji A, Behnoush AH, Jameie M, Sharifi A, Sheikhy A, Fallahzadeh A, et al. Machine learning algorithms for predicting mortality after coronary artery bypass grafting. *Front Cardiovasc Med*. 2022;9:977747. [[10.3389/fcvm.2022.977747](#)] [[PMID](#)]
- Kilic A, Goyal A, Miller JK, Gjekmarkaj E, Tam WL, Gleason TG, et al. Predictive utility of a machine learning algorithm in estimating mortality risk in cardiac surgery. *Ann Thorac Surg*. 2020;109(6):1811-9. [[10.1016/j.athoracsur.2019.09.049](#)] [[PMID](#)]
- Salehzehi S, Jafarpoor Nesheli S, Eftekhari A, Shojaei Rocky M, Vejdani Noghreiyani V, Bazazpour A, et al. Graph neural network-based multi-label classification of breast cancer using multiparametric MRI and clinical features. *Discov Oncol*. 2025;17(1):194. [[10.1007/s12672-025-04359-1](#)] [[PMID](#)]
- Rezaei SM, Eftekhari A, Rouhi S, Keshavarzi B, Mohammadi Z, Firouzabad LA, et al. Neighboring tissues as diagnostic windows: neighborhood effects in radiomic detection of pancreatic ductal adenocarcinoma. *Comput Methods Programs Biomed*. 2025;272:109056. [[10.1016/j.cmpb.2025.109056](#)] [[PMID](#)]
- Jafarpoor Nesheli S, Sabet M, Firoozi V, Heydarheydari S, Rezaei SM. Enhanced interpretability in breast cancer detection: combining grad-cam with selective layer freezing in deep learning. *Int J Imaging Syst Technol*. 2025;35(4):e70151. [[10.1002/ima.70151](#)]
- Paul JF, Rohnean A, Giroussens H, Pressat-Laffouilhère T, Wong T. Evaluation of a deep learning model on coronary CT angiography for automatic stenosis detection. *Diagn Interv Imaging*. 2022;103(6):316-23. [[10.1016/j.diii.2022.01.004](#)] [[PMID](#)]
- Meng Y, Du Z, Zhao C, Dong M, Pienta D, Tang J, et al. Automatic extraction of coronary arteries using deep learning in invasive coronary angiograms. *Technol Health Care*. 2023;31(6):2303-17. [[10.3233/THC-230278](#)] [[PMID](#)]
- Stef A, Bodolea C, Bocsan IC, Cainap SS, Achim A, Serban A, et al. The value of biomarkers in major cardiovascular surgery necessitating cardiopulmonary bypass. *Rev Cardiovasc Med*. 2024;25(10):355. [[10.31083/j.rcm2510355](#)] [[PMID](#)]
- Behnoush AH, Khalaji A, Rezaei M, Momtahn S, Mansourian S, Bagheri J, et al. Machine learning-based prediction of 1-year mortality in hypertensive patients undergoing coronary revascularization surgery. *Clin Cardiol*. 2023;46(3):269-78. [[10.1002/clc.23963](#)] [[PMID](#)]
- Feng X, Zhang C, Huang X, Liu J, Jiang L, Xu L, et al. Machine learning improves mortality prediction in three-vessel disease. *Atherosclerosis*. 2023;367:1-7. [[10.1016/j.atherosclerosis.2023.01.003](#)] [[PMID](#)]
- Preeshagul I, Gharbaran R, Jeong KH, Abdel-Razek A, Lee LY, Elman E, et al. Potential biomarkers for predicting outcomes in CABG cardiothoracic surgeries. *J Cardiothorac Surg*. 2013;8:176. [[10.1186/1749-8090-8-176](#)] [[PMID](#)]
- Chen C, Qin C, Qiu H, Tarroni G, Duan J, Bai W, et al. Deep learning for cardiac image segmentation: a review. *Front Cardiovasc Med*. 2020;7:25. [[10.3389/fcvm.2020.00025](#)] [[PMID](#)]
- Hijazi E. Enhancing mortality prediction after coronary artery bypass graft: a machine learning approach utilizing euroScore. *Future Sci OA*. 2024;10(1):FSO959. [[10.2144/fsoa-2023-0152](#)] [[PMID](#)]
- Behnoush AH, Khalaji A, Rezaei M, Momtahn S, Mansourian S, Bagheri J, et al. Machine learning-based prediction of 1-year mortality in hypertensive patients undergoing coronary revascularization surgery. *Clin Cardiol*. 2023;46(3):269-78. [[10.1002/clc.23963](#)] [[PMID](#)]
- Elmahrouk A, Daoulah A, Panduranga P, Rajan R, Jamjoom A, Kanbr O, et al. Leveraging machine learning to enhance postoperative risk assessment in coronary artery bypass grafting patients with unprotected left main disease: a retrospective cohort study. *Int J Surg*. 2024;110(11):7142-9. [[10.1097/JS9.0000000000002032](#)] [[PMID](#)]
- Ninomiya K, Kageyama S, Shiomi H, Kotoku N, Masuda S, Revaiah PC, et al. Can machine learning aid the selection of percutaneous vs surgical revascularization? *J Am Coll Cardiol*. 2023; 82(22): 2113-24. [[10.1016/j.jacc.2023.09.818](#)] [[PMID](#)]
- Mori M, Durant TJS, Huang C, Mortazavi BJ, Coppi A, Jean RA, et al. Toward dynamic risk prediction of outcomes after coronary artery bypass graft: improving risk prediction with intraoperative events using gradient boosting. *Circ Cardiovasc Qual Outcomes*. 2021;14(6): e007363. [[10.1161/CIRCOUTCOMES.120.007363](#)] [[PMID](#)]
- Karim MN, Reid CM, Cochrane A, Tran L, Alramadan M, Hossain M, et al. Mortality risk prediction models for coronary artery bypass graft surgery: current scenario and future direction. *J Cardiovasc Surg*. 2017; 58(6):931-42. [[10.23736/S0021-9509.17.09965-7](#)] [[PMID](#)]
- Rodseth RN, Smith D, Maslo C, Laubscher A, Thabane L. A critical analysis of Discovery Health's claims-based risk adjustment of mortality rates in South African private sector hospitals. *S Afr Med J*. 2022;113(1):13-6. [[10.7196/SAMJ.2023.v113i1.16768](#)] [[PMID](#)]
- Ma Y, Li M, Wu H. The machine learning models in major cardiovascular adverse events prediction based on coronary computed tomography angiography: systematic review. *J Med Int Res*. 2025;27:e68872. [[10.2196/68872](#)] [[PMID](#)]
- Williams MC, Guimarães ARM, Jiang M, Kwieciński J, Weir-McCall JR, Adamson PD, et al. Machine learning to predict high-risk coronary artery disease on CT in the Scot-Heart trial. *Open Heart*. 2025;12(2):e003162. [[10.1136/openhrt-2025-003162](#)] [[PMID](#)]

24. Trivedi RK, Chiu IM, Hughes JW, Rogers AJ, Ouyang D. (2025) Deep learning on electrocardiogram waveforms to stratify risk of obstructive stable coronary artery disease. *Eur Heart J Digit Health*. 2025;6(3):456–65. [[10.1093/ehjdh/ztaf020](https://doi.org/10.1093/ehjdh/ztaf020)] [PMID]
25. Brendel JM, Walterspiel J, Hagen F, Kübler J, Brendlin AS, Afat S, et al. Coronary artery disease detection using deep learning and ultrahigh-resolution photon-counting coronary CT angiography. *Diagn Interv Imaging*. 2025;106(2):68-75. [[10.1016/j.diii.2024.09.012](https://doi.org/10.1016/j.diii.2024.09.012)] [PMID]
26. Zreik M, Lessmann N, Van Hamersvelt RW, Wolterink JM, Voskuil M, Viergever MA, et al. Deep learning analysis of the myocardium in coronary CT angiography for identification of patients with functionally significant coronary artery stenosis. *Med Image Anal*. 2018;44:72–85. [[10.1016/j.media.2017.11.008](https://doi.org/10.1016/j.media.2017.11.008)] [PMID]
27. Lin A, Manral N, McElhinney P, Killekar A, Matsumoto H, Kwiecinski J, et al. Deep learning-enabled coronary CT angiography for plaque and stenosis quantification and cardiac risk prediction: an international multicentre study. *Lancet. Digit Health*. 2022;4(4):256–65. [[10.1016/S2589-7500\(22\)00066-8](https://doi.org/10.1016/S2589-7500(22)00066-8)] [PMID]
28. Zreik M, van Hamersvelt RW, Khalili N, Wolterink JM, Voskuil M, Viergever MA, et al. Deep learning analysis of coronary arteries in cardiac CT angiography for detection of patients requiring invasive coronary angiography. *IEEE Trans Med Imaging*. 2020;39(5):1545-57. [[10.1109/TMI.2019.2953054](https://doi.org/10.1109/TMI.2019.2953054)] [PMID]
29. Yang S, Koo BK, Hoshino M, Lee JM, Murai T, Park J, et al. CT angiographic and plaque predictors of functionally significant coronary disease and outcome using machine learning. *JACC Cardiovasc Imaging*. 2021;14(3):629-41. [[10.1016/j.jcmg.2020.08.025](https://doi.org/10.1016/j.jcmg.2020.08.025)] [PMID]
30. Gupta V, Petursson P, Rawshani A, Boren J, Ramunddal T, Bhatt DL, et al. End-to-end deep-learning model for the detection of coronary artery stenosis on coronary CT images. *Open Heart*. 2025;12(1):e002998. [[10.1136/openhrt-2024-002998](https://doi.org/10.1136/openhrt-2024-002998)] [PMID]
31. Lee H, Kang BG, Jo J, Park HE, Yoon S, Choi SY, et al. Deep learning-based prediction for significant coronary artery stenosis on coronary computed tomography angiography in asymptomatic populations. *Front Cardiovasc Med*. 2023;10:1167468. [[10.3389/fcvm.2023.1167468](https://doi.org/10.3389/fcvm.2023.1167468)] [PMID]
32. Lin A, Kolossváry M, Maurovich-Horvat P, Slomka PJ, Otaki Y, Tamarappoo B, et al. Machine learning from quantitative coronary computed tomography angiography predicts fractional flow reserve-defined ischemia and impaired myocardial blood flow. *Circ Cardiovasc Imaging*. 2022;15(10):e014369. [[10.1161/CIRCIMAGING.122.014369](https://doi.org/10.1161/CIRCIMAGING.122.014369)] [PMID]
33. Yuan N, Kwan AC, Duffy G, Theurer J, Chen JH, Nieman K, et al. Prediction of coronary artery calcium using deep learning of echocardiograms. *J Am Soc Echocardiogr*. 2023;36(5):474-81. [[10.1016/j.echo.2022.12.014](https://doi.org/10.1016/j.echo.2022.12.014)] [PMID]
34. van Hamersvelt RW, Zreik M, Voskuil M, Viergever MA, Išgum I, Leiner T. Deep learning analysis of left ventricular myocardium in CT angiographic intermediate-degree coronary stenosis improves the diagnostic accuracy for identification of functionally significant stenosis. *Eur Radiol*. 2019;29(5):2350–9. [[10.1007/s00330-018-5822-3](https://doi.org/10.1007/s00330-018-5822-3)] [PMID]



Authors retain the copyright and full publishing rights.
Published by [Ahvaz Jundishapur University of Medical Science](https://www.jundishapur.edu/).
This article is an open access article licensed under the Creative Commons Attribution-NonCommercial4.0
(<https://creativecommons.org/licenses/by-nc/4.0/>).