Paramedical Sciences and Military Health

P-ISSN: 2423-7507 ISSN:2538-3086

Homepage: htt://jps.ajaums.ac.ir

Proposing an Innovative and Efficient Model for Monitoring the Health of Heart Failure Patients Based on Advanced Artificial Intelligence Algorithms

Faranak Nabinasab[1], Leila Gholamhosseini[2*]

[1] Department of Computer Engineering, Faculty of Electrical and Computer Engineering, Shahrood University of Technology, Shahrood, Iran.

[2] Department of Health Information Technology, Faculty of Paramedicine, AJA University of Medical Sciences, Tehran, Iran.

ARTICLE INFO

Article Type:
Original Article

Article History:
Received: 2025/03/29
Received in revised form: 2025/10/19
Accepted: 2025/11/04
Published:2025/12/28

Corresponding Author:
Dr.Leila Gholamhosseini

Email:
Gholamhosseini.l@ajaums.ac.ir

Abstract

Introduction: Continuous monitoring of heart failure patients using IoT-enabled wearable sensors can improve early diagnosis and reduce mortality. However, imbalanced clinical physiological datasets and suboptimal model tuning limit real-world performance. This study proposes an IoT-based intelligent health-monitoring framework specifically designed for heart-failure prediction and risk assessment. The proposed system integrates an adaptive deep convolutional neural network (ADCNN) whose weights are optimized by a modified Grey Wolf Optimizer (LF-GWO), together with SMOTE for class balancing, to enhance the accuracy and sensitivity of heart-failure outcome prediction.

Materials and Methods: The framework consists of four phases: data acquisition (wearable/IoT sensors), cloud-edge preprocessing, feature extraction and classification using ADCNN+LF-GWO, and alert generation. Experiments were conducted on the UCI Heart Failure Clinical Records dataset, containing 299 patient samples with 13 physiological and clinical attributes. Model configuration and preprocessing (including SMOTE) are detailed, and performance was evaluated using standard metrics (accuracy, precision, recall, and confusion matrix) on held-out test sets.

Results: The proposed method achieved an overall test accuracy of 0.9208 (92.08%) and it demonstrated high sensitivity in detecting adverse outcomes (up to ≈97% in specific trials). Confusion-matrix analysis on the test split (N=75) yielded 69 correct predictions. A peak accuracy of 99.6% was observed in one iteration, which may indicate model overfitting or instability in that specific run.

Conclusion: Integrating ADCNN with LF-GWO and SMOTE delivers strong predictive performance for heart-failure monitoring and it improves sensitivity compared with baseline ML models (e.g., RF, SVM, CNN).

Keywords: Monitoring, Health, Heart Failure, Algorithms, Artificial intelligent (AI), Internet of Things (IOT).

Cite this article: Nabinasab F, Gholamhosseini L. Proposing a New Model for Health Monitoring Systems Using Artificial Intelligence Algorithms. Paramedical Sciences and Military Health 2025; 20 (4) :20-34.

© Author(s) retain the copyright.

https://doi.org/10.22034/JPSMH.20.4.20

Publisher: AJA University of Medical Sciences

علوم پیراپزشکی و بهداشت نظامی
شاپای چاپی: ۷۵۰۷-۲۴۲۳ شاپای الکترونیکی: ۳۰۸۶-۲۵۳۸
Homepage: htt://jps.ajaums.ac.ir

ارائه یک مدل نوین و کارآمد برای سیستم پایش سلامت بیماران مبتلابه نارسایی قلبی مبتنی‌بر الگوریتم‌های پیشرفته هوش‌مصنوعی

فرانک نبی‌نسب [۱]، لیلا غلامحسینی [۲*]

[۱] گروه مهندسی کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران.
[۲] گروه فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی ارتش، تهران، ایران.

چکیده

مقدمه: پایش پیوسته بیماران نارسایی قلبی با استفاده از حسگرهای پوشیدنی متصل به اینترنت اشیا می‌تواند تشخیص به‌موقع را افزایش دهد؛ اما نامتوازن بودن داده‌های بالینی و تنظیم ناقص مدل‌ها مانع عملکرد عملی می‌شود. در این مقاله یک مدل نوین و کارآمد برای سیستم پایش سلامت بیماران مبتلابه نارسایی قلبی پیشنهاد شد که از یک شبکه عصبی کانولوشن عمیق تطبیقی با وزن‌های بهینه‌شده توسط الگوریتم گرگ خاکستری اصلاح‌شده (LF-GWO) همراه با SMOTE جهت متعادل‌سازی کلاس‌ها بهره می‌برد تا تشخیص و پیش‌بینی خطر نارسایی قلبی را بهبود بخشد.

مواد و روش‌ها: روش پیشنهادی شامل چهار فاز؛ کسب داده از حسگرهای پوشیدنی، پیش‌پردازش لبه/ابر، استخراج ویژگی و طبقه‌بندی با ADCNN+LF-GWO و تولید هشدار است. آزمایش‌ها با مجموعه‌داده Heart-Failure Clinical Records از مخزن UCI شامل داده‌های بالینی ۲۹۹ بیمار با ۱۳ ویژگی فیزیولوژیکی انجام شد و معیارهای سنجش شامل؛ دقت، دقت مثبت، حساسیت و ماتریس اغتشاش بودند.

یافته‌ها: نتایج نشان داد که مدل پیشنهادی در ارزیابی روی مجموعه آزمایش عملکرد بالایی دارد و دقت کلی (۹۲/۰۸٪) و حساسیت در برخی آزمایش‌ها تا حدود ۹۷٪ گزارش شده است. تحلیل ماتریس اغتشاش روی ۷۵ نمونه آزمون، ۶۹ پیش‌بینی صحیح را نشان داد. لازم‌به ذکر است که در یک تکرار گزارش‌شده، (پیک دقت ۹۹/۶٪) مشاهده شد که احتمالاً نشان‌دهنده بیش‌برازش یا عدم‌پایداری نتایج در آن تکرار خاص است.

نتیجه‌گیری: ترکیب ADCNN با LF-GWO و SMOTE عملکرد پیش‌بینی را در مجموعه‌داده مورد بررسی بهبود می‌بخشد و نسبت به برخی روش‌های پایه‌ای ML حساسیت بالاتری نشان می‌دهد.

کلیدواژه‌ها: پایش، سلامت، نارسایی قلبی، الگوریتم، هوش مصنوعی، اینترنت اشیا.

اطلاعات مقاله

نوع مقاله
مقاله پژوهشی

سابقه مقاله
دریافت: ۱۴۰۴/۰۱/۰۹
ویرایش: ۱۴۰۴/۰۷/۲۷
پذیرش: ۱۴۰۴/۰۸/۱۳
انتشار برخط: ۱۴۰۴/۱۰/۰۷

* نویسنده مسئول:
دکتر لیلا غلامحسینی

آدرس الکترونیکی:
Gholamhosseini.l@ajaums.ac.ir

استناد: نبی نسب فرانک، غلامحسینی لیلا. ارائه یک مدل جدید برای سیستم پایش سلامت با استفاده از الگوریتم‌های هوش مصنوعی. علوم پیراپزشکی و بهداشت نظامی. ۱۴۰۴؛ ۲۰ (۴) : ۲۰-۳۴.

ناشر: دانشگاه علوم پزشکی ارتش.
© نویسندگان.
https://doi.org/10.22034/JPSMH.20.4.20
CC BY NC

مقدمه

بیماری‌های قلبی-عروقی، به‌ویژه نارسایی قلبی، همچنان یکی از علل اصلی مرگ‌ومیر در جهان هستند و فشار مضاعفی بر سیستم‌های بهداشتی وارد می‌کنند. طبق گزارش سازمان جهانی بهداشت، سالانه بیش از ۱۷میلیون نفر به دلیل این بیماری‌ها جان خود را از دست می‌دهند، درحالی‌که بسیاری از این موارد با پایش مستمر علائم‌حیاتی قابل‌پیشگیری هستند. توسعه فناوری اینترنت‌اشیا[1] و حسگرهای پوشیدنی هوشمند امکان گردآوری داده‌های فیزیولوژیکی بیماران (مانند؛ ضربان قلب، فشارخون، سطح اکسیژن خون) را به‌صورت برخط و از راه دور فراهم کرده‌اند. ترکیب این داده‌ها با الگوریتم‌های یادگیری‌ماشین و یادگیری‌عمیق می‌تواند تشخیص زودهنگام بیماری‌ها را ممکن سازد(۱). با این‌حال، چالش‌هایی نظیر نامتوازن بودن داده‌های بالینی و تنظیم غیربهینه پارامترهای شبکه‌های عصبی، دقت مدل‌های هوشمند را کاهش می‌دهند و اعتمادپذیری آن‌ها در مراقبت از بیماران قلبی را تحت‌تأثیر قرار می‌دهند (۲).

پژوهش حاضر با هدف ارائه یک مدل نوین و کارآمد برای سیستم پایش سلامت بیماران مبتلابه نارسایی قلبی مبتنی‌بر الگوریتم‌های پیشرفته هوش‌مصنوعی انجام شده است. در این مدل، از شبکه عصبی کانولوشن عمیق تطبیقی[2] و بهینه‌سازی پارامترها با الگوریتم گرگ خاکستری اصلاح‌شده[3] استفاده شده است. همچنین برای رفع عدم‌تعادل داده‌ها از روش SMOTE بهره‌برداری شده است. سؤال اصلی اینجاست که آیا ترکیب یادگیری عمیق تطبیقی با الگوریتم‌های فراابتکاری و تکنیک‌های متعادل‌سازی داده می‌توانند دقت، حساسیت و پایداری تصمیم‌گیری در پایش بیماران قلبی را در محیط‌های IoT بهبود دهند؟

اینترنت اشیا یک فناوری نوظهور است که در آن برای هر موجودیت، قابلیت ارسال و دریافت داده از طریق اینترنت فراهم می‌شود(۳). همچنین، اینترنت اشیا به ارتباط اینترنتی بین اشیا و تجهیزاتی اشاره دارد که در محیط پیرامون ما قرار دارند و از طریق شبکه اینترنت به هم متصل می‌شوند. این اشیا می‌توانند با استفاده از نرم‌افزارهای موجود در تلفن‌های هوشمند، تبلت‌ها، رایانه‌ها، ساعت‌های هوشمند و دیگر گجت‌ها از راه دور کنترل شوند. به‌عبارت دیگر، اینترنت اشیا امکان ارتباط و تعامل بین حسگرها و دستگاه‌ها با شبکه اینترنت را فراهم می‌کند و این ارتباط به کاربران اجازه می‌دهد که لوازم متصل به شبکه را مشاهده و کنترل کنند.

1. Internet of Things (IoT)
2. Attention-based Dual-scale CNN (ADCNN)
3. Levy Flight (LF)-Grey Wolf Optimizer (GWO)

این فناوری می‌تواند از ارتباط ساده‌ای مانند کنترل تلویزیون با گوشی هوشمند تا نظارت پیچیده‌تری مانند مدیریت زیرساخت‌های شهری را دربرگیرد. اینترنت اشیا همچنین با استفاده از سنسورها و محرک‌ها به سیستم‌های سایبری فیزیکی تبدیل می‌شود و می‌تواند در حوزه‌هایی مانند شبکه‌های هوشمند، حمل‌ونقل و شهرهای هوشمند به‌کار گرفته شود. این اتصال پیشرفته، امکاناتی فراتر از ارتباطات ماشین به ماشین[4] را فراهم کرده و به بهبود اتوماسیون در تمامی زمینه‌ها کمک می‌کند(۴).

درحال حاضر، برنامه‌های مختلفی مبتنی‌بر اینترنت اشیا با استفاده از تحلیل داده‌های بلادرنگ و تصمیم‌گیری توسعه یافته‌اند. سرویس‌های رایانش ابری تنها ارتباط از طریق آدرس‌های IP را فراهم می‌کنند و با پروتکل‌های متنوع IoT سازگاری ندارند. در این سیستم‌ها، حسگرها داده‌ها را جمع‌آوری و به کنترل‌کننده‌ها ارسال می‌کنند تا برای تحلیل و شناسایی الگوها استفاده شوند، سپس این اطلاعات بهینه به رایانه‌ها و تلفن همراه و ... منتقل می‌شوند. (دهقان، ۱۴۰۳).

اویبود و همکاران در سال ۲۰۲۳ یک مرور گسترده انجام دادند تا روندهای فعلی در سیستم‌های تطبیقی مبتنی‌بر یادگیری ماشین[5] در حوزه سلامت را بررسی کنند. آن‌ها ۸۷ مقاله از بین ۱۸حوزه سلامت انتخاب کردند که شامل؛ مدیریت بیماری، مراقبت‌های بهداشتی، تشخیص پزشکی، سلامت روان و سایر حوزه‌ها بود. این مرور بر پنج حوزه کلیدی ازجمله؛ جمع‌آوری داده‌ها، فرآیند توسعه مدل، تکنیک‌های یادگیری ماشین، ارزیابی مدل‌ها و استراتژی‌های تطبیقی یا شخصی‌سازی برای مداخلات سلامت تمرکز داشت. همچنین چالش‌هایی همچون محدودیت‌های حجم داده، تنوع یا تغییرپذیری داده‌ها، و مسائل زیرساختی را شناسایی کردند و توصیه‌هایی برای رفع این چالش‌ها و بهره‌برداری از سایر فناوری‌های پیشرفته مانند رایانش ابری، یادگیری آنلاین، محاسبات لبه، و هوش مصنوعی ارائه دادند (۵).

جاگاسی و همکاران (۲۰۲۳) یک چارچوب برای ارزیابی شرایط سلامت فردی ارائه دادند که به افراد امکان می‌داد بدون نیاز به مشاوره پزشک، وضعیت سلامت خویش را ارزیابی کنند. این چارچوب شامل یک کیت بود که شاخص‌های مختلف سلامت مانند؛ دمای بدن، ضربان نبض، سطح اکسیژن خون و شاخص توده بدنی را اندازه‌گیری می‌کرد. داده‌ها از میان مردان و زنان ۱۷ تا ۲۴ساله جمع‌آوری شدند و با استفاده از الگوریتم‌های یادگیری ماشین تقویت و متعادل شدند. این سیستم از یک طبقه‌بندی دو مرحله‌ای برای توصیه رژیم غذایی و ورزش متعادل استفاده می‌کرد.

4. Machine to Machine (M۲M)
5. Machine Learning (ML)

الگوریتم‌های مختلفی مانند جنگل تصادفی، طبقه‌بندی کننده‌های MLP، CatBoost و رگرسیون لجستیک برای تحلیل داده‌ها به‌کار رفته بودند. تحلیل تجربی نتایج نشان داد که الگوریتم CatBoost بهترین دقت پیش‌بینی را ارائه داده است (۲).

آلام و همکاران (۲۰۲۵) یک چارچوب یادگیری مبتنی بر ترنسفورمر برای تشخیص فعالیت‌های انسانی از داده‌های حسگرهای پوشیدنی ارائه کردند که هدف اصلی آن‌ها افزایش دقت مدل و در عین حال حفظ حریم خصوصی داده‌های کاربران در سیستم‌های IoT است(۳).

ناهیدوزمان و همکاران (۲۰۲۳) یک تکنیک خودکار جدید برای تشخیص دیابت شبکیه با استفاده از تصاویر فوندوس و پیش‌پردازش CLAHE ارائه دادند. آن‌ها از شبکه عصبی کانولوشنال موازی برای استخراج ویژگی‌ها و ماشین یادگیری افراطی برای طبقه‌بندی استفاده کردند. نتایج ارزیابی روی مجموعه داده‌های Kaggle DR ۲۰۱۵ و APTOS ۲۰۱۹ نشان داد که این تکنیک دقت بالا و عملکرد بهتری نسبت به مدل‌های پیشرفته موجود دارد (۴).

بوتلوگانتا و همکاران (۲۰۲۳) نیز یک سیستم طبقه‌بندی غیرتهاجمی برای تشخیص متاستازهای سرطان پستان با استفاده از یادگیری ماشین و متن‌کاوی سوابق پزشکی الکترونیکی توسعه دادند. با استفاده از الگوریتم‌های یادگیری ماشین و معیارهای اعتبارسنجی، این مدل به دقت ۸۳درصد دست یافت. این سیستم به عنوان یک برنامه تحت‌وب برای تشخیص بیماران مبتلابه سرطان پستان مستقر شد (۱). اگاروال و همکاران (۲۰۲۵) یک معماری اینترنت اشیای سلامت‌محور همراه با EdgeAI برای پایش بلادرنگ وضعیت بیماران پیشنهاد می‌کنند. این سیستم با استفاده از یادگیری و تشخیص ناهنجاری، داده‌های حسگرهای سلامت را تحلیل کرده و امکان نظارت هوشمند پزشکی را فراهم می‌کند(۵).

النازی و همکاران (۲۰۲۵) چند مدل یادگیری عمیق را برای تشخیص فعالیت‌های انسانی مقایسه می‌کنند و عملکرد آن‌ها را روی داده‌های HAR بررسی می‌کند. هدف اصلی، یافتن مدلی است که بین دقت، پیچیدگی و قابلیت استفاده در سناریوهای پوشیدنی/IoT تعادل بهتری داشته باشد(۶). دهقان و همکاران (۱۴۰۳) نیز در مقاله‌ای باعنوان سلامت در عصر دیجیتال به بررسی لزوم ایجاد و استفاده از یک سامانه جامع مبتنی‌بر اینترنت اشیا برای مراقبت و پایش نوزادان پرداختند. این سامانه با امکان نظارت مستمر بر وضعیت سلامت نوزادان و ارائه هشدارهای به‌موقع به ارتقای ایمنی نوزادان منجر شد. نتایج این تحقیق نشان داد که استفاده از فناوری‌های نوین می‌تواند به‌طور قابل‌توجهی به کاهش نرخ مرگ‌ومیر و بهبود کیفیت زندگی نوزادان کمک نماید.

مواد و روش‌ها

مدل پیشنهادی با هدف پایش بلادرنگ بیماران قلبی بر پایه داده‌های حسگرهای IoT طراحی شده است. سیستم شامل پنج بخش اصلی است:

۱. داده‌ها و ویژگی‌ها
۲. پیش‌پردازش و متعادل‌سازی داده‌ها
۳. طراحی مدل پیشنهادی (ADCNN + LF-GWO)
۴. بهینه‌سازی مدل
۵. ارزیابی و اعتبارسنجی

۱- داده‌ها و ویژگی‌ها

داده‌ها از مجموعه Heart Failure Clinical Records مربوط به بیماران نارسایی قلبی استخراج شد (۲۹۹ نمونه، ۱۳ ویژگی). ویژگی‌ها شامل سن، فشارخون، کراتینین، سطح سدیم، هماتوکریت، و شاخص‌های مرگ‌ومیر هستند. برچسب هدف مقدار (۱) برای بیماران فوت‌شده و (۰) برای بیماران زنده است. داده‌ها از نوع عددی و بالینی بوده و هیچ داده زمانی یا تصویری وجود ندارد. برای بهبود دقت طبقه‌بندی، از ترکیب ویژگی‌های حیاتی و فاکتورهای محیطی استفاده شد.

۲- پیش‌پردازش و متعادل‌سازی داده‌ها

پیش از آموزش مدل، داده‌ها در سه مرحله آماده‌سازی شدند:

- **پاک‌سازی و نرمال‌سازی:** مقادیر پرت با روش Z-score شناسایی و حذف شدند؛ داده‌ها با استفاده از نرمال‌سازی Min-Max به بازه [۰,۱] نگاشت شدند.
- **تفکیک داده‌ها:** داده‌ها با نسبت ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی و ۱۵٪ آزمون تقسیم شدند. برای اطمینان از پایداری، از اعتبارسنجی متقابل پنج‌تایی (5-Fold CV) استفاده شد.
- **متعادل‌سازی:** با توجه به عدم‌تعادل میان کلاس‌ها، از روش SMOTE با k=۵ برای افزایش مصنوعی داده‌های کلاس اقلیت استفاده شد.

۳- طراحی مدل پیشنهادی شبکه عصبی کانولوشنی عمیق تطبیقی

مدل پایه یک ADCNN است و ساختار آن شامل چهار بلوک کانولوشن متوالی با فیلترهای (۳×۳) و تابع فعال‌ساز ReLU است. پس از هر بلوک

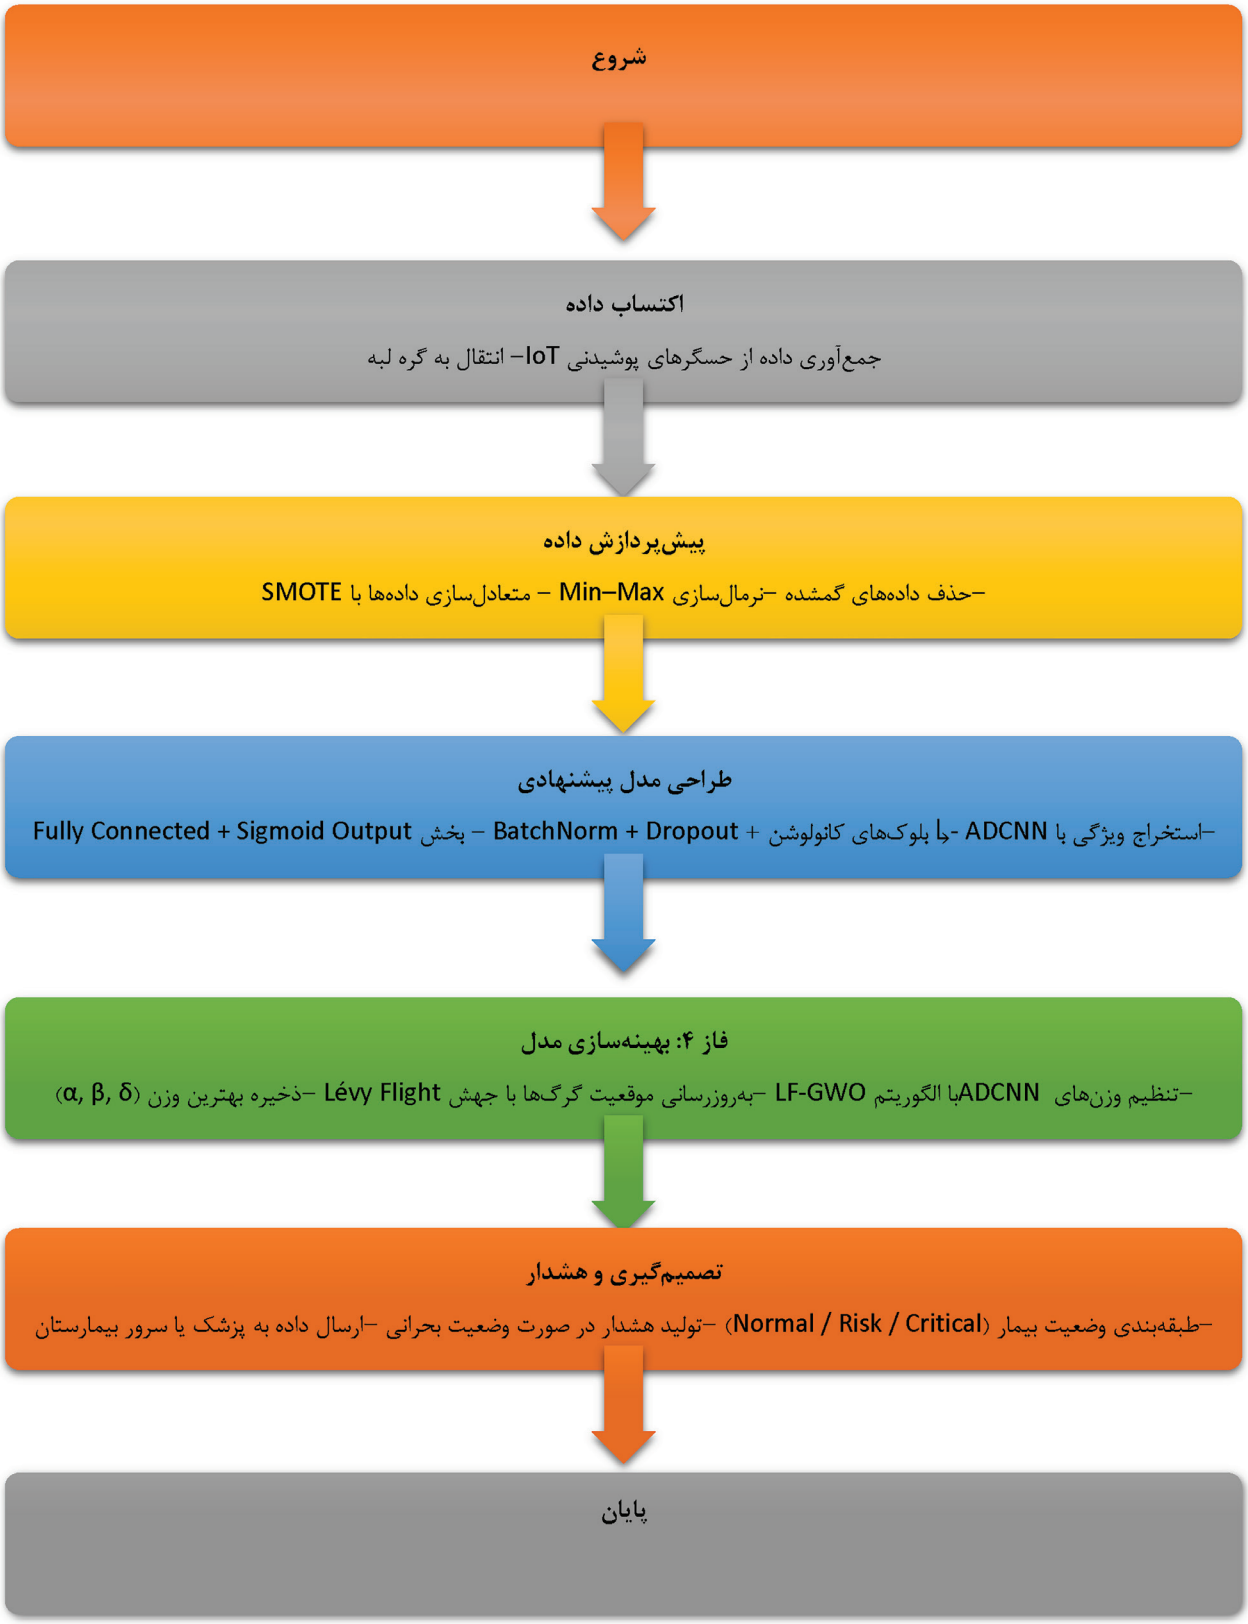

شکل ۱- فلوچارت روش پیشنهادی

از لایـه Batch Normalization و Dropout (بـا نرخ ۰٫۳) اسـتفاده شـد. بخش Fully Connected شـامل دو لایـه Dense (با ۱۲۸ و ۶۴ نورون) و یک لایه خروجی Sigmoid است.

در اینجا، شـبکه عصبی پیچیدگـی عمیق تطبیقی همراه با بهینه‌سـازی گرگ خاکسـتری در فرآینـد طبقه‌بندی برای یافتن بهتریـن راه‌حل بهینه استفاده می‌شود. نمایش چهار مرحله مختلف ازجمله برای سیستم نظارت بر سـلامت مؤثر استفاده از شـبکه عصبی همراه با گرگ خاکستری برای طبقه‌بندی مؤثر و در نهایت بهره‌مندی از SMOTE جهت متعادل‌سازی. در مرحلـه نهایی، پس از تشـخیص هر مورد غیرطبیعی، اطلاع‌رسـانی یا اطلاعاتی را به پزشک ارائه می‌دهد.

ورودی: مقدار ویژگی سلامت دارای n عدد، مقدار آستانه هر ویژگی جداگانه
خروجی: وضعیت فعلی بیمار
۱: شروع
۲: تعیین ویژگی‌ها برای شرایط فعلی.
۳: محاسبه درجه ImpactDOI.
۴: اگر (مقدار DOI در سطح غیرطبیعی) سپس
۵: وضعیت بیمار ناامن است.
۶: دیگری
۷: وضعیت بیمار امن است.
۸: بازگشت
۹: اگر (تحریک وقوع رویداد درست باشد) پس
۱۰: یک سیگنال هشدار برای پاسخ‌دهنده تولید می‌شود.
۱۱: داده‌های قابل‌توجهی برای بررسی به ابر ارسال می‌شود.
۱۲: پایان

شکل ۲- شبه کد تعیین وضعیت فعلی بیمار

لایه ابر نقش بسـزایی در جمـع‌آوری و دریافت داده‌ها بر اسـاس خلاصه سـلامت بیمار از ابـر دارد. علاوه‌بر ایـن، داده‌های متعـددی را در مورد گـزارش خلاصه بیمار به مرحله تصمیم‌گیری ارائه می‌دهد. لایه اطلاعات کاوی IML نوعـی لایـه ابری اسـت که داده‌هـای ارزشـمند را به‌عنوان داده‌های بلادرنگ از سـرویس‌های داده استخراج می‌کند. علاوه‌بر این، داده‌های بیمار با اسـتفاده از فرآیندهای داده‌کاوی بر اساس الگوی سری زمانی TSP اسـتخراج می‌شوند. درنهایت، داده‌های نظارت‌شده بر اساس گزارش‌های سـلامتی بیمار برای بررسـی بیشـتر در فضـای ابری ذخیره می‌شـود. از سوی دیگر، شاخص سـلامت زمانی THI به تعیین وضعیت سـلامتی بیمار در جهات مختلف کمک می‌کند. شـاخص سلامت زمانی THI از سه عامل مختلف شامل عوامل محیطی، عوامل رفتاری و عوامل سـلامت تشکیل‌شده است. شـاخص سـلامت زمانی THI با استفاده از فرمول زیر محاسبه می‌شود.

فرمول ۱:

$$T_{HI} = p\left[\frac{H_S}{O_1 \cup O_2 \cup . \ldots \ldots \cup O_N}\right].$$

از معادلـه بالا وضعیت سـلامت (ایمن یا ناایمن) وضعیـت بیمار به‌عنوان HS نشان داده می‌شود. وقوع رویداد با توجه به وضعیت سلامتی به‌عنوان Oi نشان داده می‌شود. که در آن مقدار Oi از Oi = O۱، O۲، .....ON متغیر است.

مـدل یـک نسـخه اصلاح‌شـده شـبکه عصبـی کانولوشـن عمیق یک ADCNN اسـت که وزن آن با اسـتفاده از الگوریتم LF-GWO بهینه می‌شـود. پس از فرآیندهـای انتخاب ویژگی، ویژگی‌های انتخاب‌شـده با استفاده از ادغام ADCNN و LF-GWO طبقه‌بندی می‌شوند. سپس، ویژگی‌های انتخاب‌شـده به‌عنوان ورودی طبقه‌بنـدی کننده ADCNN درنظر گرفته می‌شـود. وزن‌ها به‌طور تصادفی تخصیص داده می‌شـوند و درنتیجه آن را با هر ورودی جداگانه متصل می‌کنند. به‌علاوه، لایه پنهان از چندین گره پنهان تشکیل‌شده است که عملیات جمع را با ضرب مقدار وزن و مقدار ورودی کل گره‌ها اجرا می‌کنند. بنابراین، فرآیندهای پس‌انتشـار با وزن تصادفی به‌دست‌آمده برای دستیابی به خروجی بهینه افزایش می‌یابد. سپس، مرحله فعال‌سازی و به دنبال آن فرآیند انتشار مجدد ادامه می‌یابد. بنابراین، لایه خروجی بهینه خود را به لایه متوالی یا متوالی منتقل می‌کند. در مرحله طراحی مدل، پارامترهای شـبکه عصبی و الگوریتم بهینه‌سازی به‌صـورت آزمایشـی و با تکیه بر مطالعات پیشـین تنظیم شـدند. شـبکه عصبی کانولوشـنی تطبیقی شامل چهار بلوک کانولوشـن متوالی با اندازه فیلترهای (۳×۳)، تابع فعال‌سـاز ReLU و لایه‌های نرمال‌سازی Batch Normalization بـود. برای جلوگیری از بیش‌برازش، از لایه Dropout با نرخ ۰٫۳ پس از هر بلوک اسـتفاده شد. بخش تمام‌متصل شبکه شامل دو لایـه Dense با ۱۲۸ و ۶۴ نورون و یک لایـه خروجی Sigmoid بود. الگوریتم بهینه‌سـازی مورد استفاده Adam با نرخ یادگیری اولیه ۰/۰۰۱ و تعداد ۱۰۰ دوره آموزشـی انتخاب شد. اندازه دسـته‌ها برابر با ۳۲ درنظر گرفته شد، زیرا در آزمایش‌های اولیه ترکیبی از پایداری و سرعت همگرایی بهتری نسـبت به اندازه‌های بزرگ‌تر نشـان داد، برای بخش بهینه‌سـازی گرگ خاکسـتری، اندازه جمعیـت گرگ‌ها ۳۰ و تعـداد تکرارها ۵۰ تنظیم شـد. پارامترهای α و a طبق مقادیر پیشـنهادی در ادبیات تحقیق از ۲ تا ۰ کاهـش خطـی یافته و پارامترهای تصادفـی A و C در بازه [۰,۱] تولید شـدند. انتخاب تابع هدف بر مبنای کمینه‌سـازی خطای طبقه‌بندی بود،

برای متعادل‌سازی داده‌ها، تکنیک SMOTE با k=۵ همسایه نزدیک استفاده شد تا از ایجاد نویز مصنوعی جلوگیری شود. مقادیر مذکور پس از آزمایش‌های اولیه روی زیرمجموعه‌ای از داده‌ها به‌عنوان بهترین تنظیمات انتخاب شدند، زیرا به بالاترین دقت و کمترین زمان اجرا منجر شدند

```
Initialize population Xi (i=1...N)
For each iteration t:
  Compute fitness for each wolf
  Identify α, β, δ wolves
  Update positions using modified coefficients (A, C)
  Apply Lévy flight to enhance exploration
  If convergence criteria met, stop
Return best solution (weights of ADCNN)
```

شکل ۳- شبه کد الگوریتم LF-GWO

روش پیشنهادی ورودی X را دریافت کرده و سپس با استفاده از شبکه‌های عصبی عمیق ویژگی‌ها را استخراج می‌کند؛ تشابه ویژگی‌ها از طریق ماژول خودتشابهی[1] در زیر شبکه تشخیص شباهت محاسبه‌شده، پس از آن آمار مفید با استفاده از ماژول تجمیع صدک[2] جمع‌آوری می‌شود. در این مرحله به‌وسیله ماسک رمزگشا[3] نقشه ویژگی‌ها به اندازه ورودی اصلی گسترش می‌یابد و طبقه‌بند دودویی[4] جهت استفاده در مراحل جنبی ازجمله تهیه ماسک نواحی دست‌کاری شده و ماسک تشابه با همان تفکیک‌پذیری X اعمال می‌شود. فاز نخست مشابه یک شبکه قطعه‌بندی است که هدف قطعه‌بندی نواحی دست‌کاری‌شده را دنبال می‌کند. هر نوع شبکه عصبی را می‌توان به‌عنوان یک استخراج‌کننده ویژگی به‌کار برد. در این پژوهش از چهار بلوک ابتدایی معماری VGG16 که یک شبکه از پیش آموزش‌دیده ساده است، استفاده می‌شود. ویژگی‌های مستخرج در یک تنسور f_s^x با ابعاد 512*16*16 ذخیره می‌شود؛ مانند $F_s^x=\{F_s^x[i_r,i_c]\}$، $ir,ic\in[0,\dots,15]$ یعنی تکه ویژگی‌های 16*16 با 512 بعد که البته تفکیک‌پذیری بسیار کمتری ازآنچه موردنیاز است، دارد. ازآنجایی‌که هدف بازیابی نواحی بالقوه کپی-انتقال است، نیازمند اطلاعات مفیدی برای تعیین جفت ویژگی‌های منطبق هستیم؛ بدین منظور ابتدا نمره تشابه همه ویژگی‌ها با استفاده از ماژول خودتشابهی محاسبه می‌شود و نتایج معنادار به‌دست‌آمده جهت تشخیص جفت‌های منطبق به‌وسیله تجمیع صدک جمع‌آوری می‌شود. درواقع مطابق رابطه زیر برای دو تکه ویژگی $f_m^x[i]$ و $f_m^x[j]$ که در آن $i=(i_r,i_c)$ و $j=(j_r,j_c)$ است، از ضریب همبستگی پیرسون ρ جهت کمی‌سازی تشابه ویژگی‌ها استفاده می‌کنیم.

فرمول ۲:
$$\rho(i,j)=(\tilde{f}_m^X[i])^T\tilde{f}_m^X[j]/512$$

که در آن $(\cdot)^T$ عملگر ترانهاده و $\tilde{F}_m^x[i]$ رم نرمال‌سازی شده $F_m^x[i]$ است که مطابق رابطه زیر با کسر میانگین $\mu_m^x[i]$ و تقسیم بر انحراف معیار خود $\sigma_m^x[i]$ به دست می‌آید.

فرمول ۳:
$$\tilde{f}_m^X[i]=(f_m^X[i]-\mu_m^X[i])/\sigma_m^X[i]$$

این فرآیند برای هر به تعداد تمام های ممکن تکرار می‌شود تا نهایتاً بردار نمرات $S^X[i]$ تشکیل شود:

فرمول ۴:
$$S^X[i]=[\rho(i,0),\dots,\rho(i,j),\dots,\rho(i,255)]$$

خروجی خودتشابهی یک تنسور S^x با ساختار 256*16*16 است. زمانی که f_m^x و ضریب همبستگی پیرسون هر دو با معنی باشند، واضح است که اگر $f_m^x[i]$ تطبیق یافته باشد، باید بعضی نمرات $S^X[i][j]$ با $j\neq i$ به‌مراتب بزرگ‌تر از سایر نمرات $S^X[i][k]$ با $k\notin\{i,j\}$ باشد. ازآنجایی‌که از قبل نسبت به $f_m^x[i]$ متناظر آگاهی نداریم، بررسی این الگو در محتوای DNN مشکل است؛ در عوض بررسی این الگو در یک بردار نمرات مرتب‌شده آسان‌تر است. به بیان واضح‌تر مطابق رابطه زیر ماژول تجمیع صدک بردار نمرات $S^X[i]$ را به ترتیب از بزرگ به کوچک در $S'^X[i]$ مرتب میسازد .

فرمول ۵:
$$S'^X[i]=sort(S^X[i])$$

در یک تابع فرضی $(k, S'^X[i][k])$ در بازه $k\in[0,\dots,255]$ در صورت تطبیق یافتن $f_m^x[i]$ باید شاهد یک منحنی یکنواخت صعودی با یک افت ناگهانی در یک نقطه خاص باشیم؛ که این مسئله نشان‌دهنده این است که نسخه مرتب‌سازی شده بردار نمرات، اطلاعات کافی در مورد ویژگی‌های تطبیق یافته را برای تصمیم‌گیری در مراحل بعدی در بردارد. امکان استفاده مستقیم S'^X در ماژول‌های بعدی جهت تشخیص ویژگی‌های منطبق وجود دارد اما نقص این کار این است که شبکه قابلیت دریافت ورودی در ابعاد دلخواه را از دست می‌دهد، چراکه طول بردار نمرات به سایز ورودی وابسته است. برای حذف این وابستگی

1. Self-Correlation
2. Percentile pooling
3. Mask decoder
4. Binary classifier

مـــاژول تجمیع صدک با انتخاب نمراتـــی در صدک‌های موردنظر بردار نمرات مرتب‌شـــده را استاندارد می‌کند. به‌بیان‌دیگر بدون در نظر گرفتن طول L بردار خام نمرات مرتب‌شده، همیشه k نمره برای تشکیل بردار نمرات صدک تجمیع شده $P^X[i]$ انتخاب می‌شود:

فرمول ۶: $$P^X[i][k] = S'^X[i][k']$$

که در آن $k \in [0,\ldots,K-1]$ و k' مطابق رابطه اندیس بردار خام نمرات مرتب ده پس از نگاشـــت یک صدک از پیش تعریف‌شده $p_k \in [0,1]$ با توجه به L است.

فرمول ۷: $$k' = round(p_k.(L-1))$$

از دیگر مزایای استانداردسازی مذکور کاهش ابعاد است، زیرا تنها بخش کوچکی از همه نمرات نگه‌داشته می‌شود. پس از تجمیع صدک از ماسک رمزگشا برای گسترش تدریجی P^X به اندازه ابعاد ورودی اصلی استفاده می‌شـــود؛ این عمل رمزگشـــایی ویژگی، نوعی اعمال واپیچش جهت بازیابی تفکیک‌پذیری اصلی اســـت. ماســـک رمزگشا، با اعمال متناوب ماژول‌های BN-Inception و BilinearUpPool2D تنســـور d_m^X را با ســـاختار 6*256*256 می‌ســـازد. افزایش ۱۶ برابری ابعاد فضایی به خاطر ۴ بار (16-24) اســـتفاده از BilinearUpPool2D و فیلتر خروجی ۶ بعدی به علت آخریـــن اســـتفاده از BN-Inception ([5,7,11]*2) است که خود شـــامل ۳ لایه Conv2D و هرکدام با ۲ فیلتر خروجی با هســـته (۵و۵)، (۷و۷) و (۱۱و۱۱) می‌باشد (3*6-2). سرانجام با استفاده از طبقه بند دودویی ماسک سطح پیکسل نواحی دست‌کاری شده M_m^X تهیه می‌شود که ســـاختار ساده تک لایه‌ای دارد، یعنی شامل یک لایه Conv2D با یک هســـته (۳و۳) و تابع فعال‌ساز سیگموئید است. نهایتاً از طبقه‌بند دودویی جهت تولید ماسک کپی-انتقال استفاده می‌شود.

٤- بهینه‌سازی با الگوریتم LF-GWO

بهینه‌سازی وزن‌های شـــبکه با نسخه اصلاح‌شده الگوریتم Grey Wolf Optimizer انجام شد که از توزیع Lévy Flight برای بهبود اکتشـــاف و جلوگیری از بهینه محلی استفاده می‌کند. به‌طورکلی، چندین الگوریتم بهینه‌سازی برای حذف بسیاری از مسائل پیچیده محاسباتی که شامل مشتقات طولانی، ذخیره‌سازی حافظه عظیم و غیره اســـت، استفاده می‌شـــوند. اما تعداد کمی از الگوریتم‌های بهینه‌ســـازی در یافتن بهترین راه‌حل بهینه مشکل پیدا می‌کنند. در مورد الگوریتم اســـتاندارد GWO، با استفاده از سه شرط مختلف یعنی δ، ε و φ به روز می‌شود. جمعیت GWO تمایل دارند و مسائل همگرایی کمی وجود دارد. از سوی دیگر، الگوریتم متعارف GWO در انتقال داده‌ها به فاز بهره‌برداری از مرحله اکتشـــاف چندان مؤثر نیســـت. به‌طورکلی، مقداردهی اولیه و به‌روزرســـانی کلاس‌های مختلف گرگ بر عملکرد جســـتجوی سیســـتم تأثیر می‌گذارد. در GWO، با تنظیم دقیـــق پارامترهای a و A، می‌توان این دو فاز را برای کسب حداقل جهانی با ســـرعت همگام‌سازی سریع متعادل کرد. اگرچه پیشـــرفت‌های مختلف الگوریتم‌هـــای مبتنی‌بر فرد، اجتناب از بهینه محلی را ترویج می‌دهند، اما ادبیات نشان می‌دهد که الگوریتم‌هـــای مبتنی‌بر جمعیت در برخورد با این موضوع بهتر هســـتند. در GWO، انتقال بین اکتشـــاف و بهره‌برداری از طریق مقادیـــر انطباق a و A ایجاد می‌شـــود. در آن نیمی از تکرارها به اکتشـــاف اختصاص‌یافته ($|A| \geq 1$) و نیمی دیگر برای بهره‌برداری ($|A| < 1$) استفاده می‌شود. در GWO، مقدار a به‌صورت خطی از ۲ تا ۰ با استفاده از معادله به‌روزرسانی به‌صورت زیر کاهش می‌یابد:

فرمول ۸: $$a = 2\,(1 - (t / T))$$

کـــه در آن T، حداکثر تعداد تکرارها را نشـــان می‌دهد و t تکرار فعلی اســـت. GWO ما، تابع نمایشـــی را برای تخریب a در طی تکرارها استفاده می‌کند. در نظر گرفتن:

فرمول ۹: $$a = 2\,(1 - (t2 / T2))$$

۵- معیارهای ارزیابی و پروتکل اعتبارسنجی

برای ارزیابی عملکرد مدل از چهار معیار استاندارد استفاده شد:

۱. صحت: Accuracy به معنای این است که مقدار اندازه‌گیری شـــده چقدر به مقدار واقعی نزدیک اســـت. برای Accuracy باید Precision بالا باشد ولی برعکس آن الزاماً برقرار نیست.

فرمول ۱۰: $$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FP+FN)}$$

کـــه در آن TP تعـــداد مثبت‌های واقعی و TN تعداد مردودی درســـت را نشـــان می‌دهد؛ و FP نشـــان‌دهنده تعداد مثبـــت کاذب و FN تعداد منفی‌های کاذب است.

۲. دقت: درواقع Precision برابر اســـت با تقســـیم تعداد مواردی که توســـط روش پیشنهادی درســـت تشخیص داده‌شـــده‌اند بر تعداد کل مواردی که توســـط روش ایجادشـــده‌اند. دقت را می‌توان به‌صورت زیر فرمول‌بندی کرد:

فرمول ۱۱: $$\text{Precision} = \frac{TP}{TP+FP}$$

۳. یادآوری: پارامتر یادآوری را می‌توان به‌صورت زیر فرمول‌بندی کرد:

فرمول ۱۲:

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

Recall برابر است با تقسیم تعداد مواردی که توسط روش پیشنهادی درست تشخیص داده‌شده است بر تعداد مواردی که واقعاً درست هستند، درست تشخیص داده‌شده‌اند.

مقدار بالاتر هریک از پارامترهای فوق بیانگر عملکرد بهتر الگوریتم است. در تمامی آزمایش‌ها، میانگین پنج‌تایی (5-Fold Mean) گزارش شد. برای ارزیابی آماری، از آزمون t زوجی برای مقایسه میانگین دقت مدل پیشنهادی با مدل‌های پایه (SVM، RF، CNN) استفاده شد. تمام پیاده‌سازی‌ها در محیط (Python 3.10 (TensorFlow 2.12 بر روی سیستم دارای GB ۱۶ Intel i7 / RTX 4060 / RAM انجام گردید.

یافته‌ها

۱- الگوریتم‌های مورد مقایسه

در ادامه چند ارزیابی جهت بررسی صحت‌وسقم روش پیشنهادی صورت می‌گیرد. مقایسات بین روش پیشنهادی و دیگر الگوریتم‌های بهینه‌سازی از جدیدترین مقالات، الگوریتم یادگیری ماشین، الگوریتم ژنتیک[1]، زنبورعسل مصنوعی[2] و آموزش ماهی مصنوعی[3] صورت گرفته است.

۲- مجموعه داده

در این پژوهش از مجموعه‌داده Heart Failure Clinical Records استفاده شده است که نخستین‌بار توسط (۱۱) و در مخزن UCI Machine Learning Repository منتشر شده است. این مجموعه شامل ۲۹۹ نمونه بیمار مبتلابه نارسایی قلبی مزمن است که داده‌ها طی یک دوره پیگیری چندساله جمع‌آوری شده‌اند. داده‌ها از نوع بالینی بوده و به‌صورت مقادیر عددی و طبقه‌ای مربوط به وضعیت جسمی و سوابق پزشکی بیماران ثبت شده‌اند. هر رکورد شامل ۱۳ویژگی بالینی شامل؛ سن، جنس، فشارخون، تعداد پلاکت‌ها، کراتینین سرم، سدیم سرم، کراتین فسفوکیناز، دیابت، فشارخون بالا، مصرف داروهای ACEI و بتابلوکر و وضعیت مصرف سیگار است. ویژگی هدف به‌صورت دودویی تعریف شده است، به‌طوری‌که مقدار (۱) نشان‌دهنده فوت بیمار و مقدار (۰) نشان‌دهنده زنده‌بودن وی در پایان دوره پیگیری است. تمامی بیماران از اختلال عملکرد سیستولیک بطن چپ (LVEF < 40%) رنج می‌برده‌اند.

1 Genetic algorithm
2 Artificial Bee Colony (ABC)
3 Artificial Fish Schooling Algorithm (AFSA)

در مرحله پیش‌پردازش، مقادیر گمشده با میانگین عددی جایگزین شد، داده‌ها نرمال‌سازی شدند و به‌منظور رفع عدم‌تعادل، تکنیک SMOTE بر روی کلاس اقلیت اعمال شد. سپس داده‌ها به نسبت ۸۰درصد برای آموزش و ۲۰درصد برای آزمون تقسیم شدند. برای اطمینان از پایداری نتایج، از اعتبارسنجی متقاطع پنج‌تایی[4] نیز استفاده شد.

۳- محیط پیاده‌سازی

پیاده‌سازی مدل پیشنهادی در محیط برنامه‌نویسی Python 3.10 انجام شد و از کتابخانه‌های TensorFlow 2.13 و Keras برای ساخت شبکه عصبی و از scikit-learn برای پیش‌پردازش داده‌ها استفاده شد. فرآیند آموزش با تعداد ۱۰۰ دوره و اندازه دسته برابر ۳۲ انجام شد. بهینه‌سازی وزن‌ها در بخش یادگیری عمیق با استفاده از الگوریتم Adam با نرخ یادگیری اولیه ۰/۰۰۱ انجام گرفت. در بخش الگوریتم فراابتکاری، پارامترهای گرگ خاکستری اصلاح‌شده به‌صورت جمعیت اولیه ۳۰ و ۵۰ تکرار تنظیم شدند. تابع هدف بر اساس کمینه‌سازی خطای دسته‌ای تعریف شد. محیط سخت‌افزاری اجرای مدل شامل سیستم با پردازنده Intel Core i7-13700H، حافظه RAM با ظرفیت ۱۶گیگابایت، و کارت گرافیک NVIDIA RTX 4060 با حافظه ۸گیگابایت بود. کلیه‌ی آزمایش‌ها در سیستم عامل Windows نسخه ۱۱ انجام شد. ارزیابی عملکرد مدل با معیارهای دقت، دقت مثبت، یادآوری، و ماتریس اغتشاش انجام شد.

٤- نتایج ارزیابی

مدل پیشنهادی برای پیش‌بینی وضعیت بیماران نارسایی قلبی، با استفاده از داده‌های بالینی Heart Failure Clinical Records (UCIRepository)Dataset ارزیابی شد. داده‌ها به نسبت ۷۰درصد برای آموزش، ۱۵درصد برای اعتبارسنجی، و ۱۵درصد برای آزمون تقسیم شدند و درمجموع ۵ تکرار تصادفی (Random Seeds متفاوت) برای افزایش پایداری نتایج انجام گرفت. برای جلوگیری از سوگیری، ترتیب داده‌ها پیش از هر اجرا به‌صورت تصادفی بازآرایی شد.

٤. ۱. اعتبارسنجی و معناداری آماری

به‌منظور بررسی معناداری تفاوت عملکرد بین مدل پیشنهادی و سایر مدل‌ها، از آزمون t زوجی دوطرفه[5] بر اساس میانگین دقت حاصل از پنج تکرار استفاده شد. نتایج در سطح اطمینان ۹۵٪ ($\alpha = 0.05$) نشان داد که اختلاف بین مدل پیشنهادی و بهترین مدل کلاسیک (ETC) از نظر آماری معنادار است

4 5-fold cross-validation
5 Paired t-test

جدول۱. بررسی تفاوت عملکرد بین مدل پیشنهادی و سایر مدل‌ها

مدل	میانگین Accuracy	p-value نسبت به مدل پیشنهادی	انحراف معیار
ETC (Ishaq et al., 2021)	۰/۹۲۶۲	۰/۰۳۷	۰/۰۰۷
RF	۰/۹۱۸۸	۰/۰۲۱	۰/۰۰۹
CNN	۰/۹۱۶۹	۰/۰۱۸	۰/۰۱۱
ADCNN-LF-GWO (پیشنهادی)	۰/۹۲۸۵	—	۰/۰۰۶

$(t = 2.48, p = 0.037 < 0.05)$.

بنابراین می‌توان نتیجه گرفت که بهبود عملکرد مدل پیشنهادی نسبت به مدل‌های پایه از نظر آماری معنی‌دار است.(جدول ۱)

۴. ۲. تحلیل ROC و Precision-Recall Curve

به‌منظور بررسی رفتار مدل در سطوح آستانه تصمیم متفاوت، منحنی ROC و منحنی Precision–Recall محاسبه شدند. مساحت زیر منحنی برابر با ۰/۹۶۳ به‌دست‌آمد که نشان‌دهنده قدرت تفکیک بالای مدل در جداسازی بیماران واقعی از غیربیماران است. ROC نشان می‌دهد که در آستانه بهینه (Threshold = ۰/۴۶)، مدل توانسته است با حفظ حساسیت بالا (≈97%)، نرخ خطای مثبت کاذب را به کمتر از ۱۷% کاهش دهد.

$AUC = 0.963 \pm 0.01,$

$\text{Precision–Recall } AUC = 0.952 \pm 0.012$

۴. ۳. تحلیل بیش‌برازش (Overfitting) و خطاهای بالقوه

برای بررسی پایداری مدل، اختلاف دقت میان داده‌های آموزش و آزمون محاسبه شد. میانگین اختلاف برابر با ۱/۲٪ ± ۰/۵٪ بود که نشان می‌دهد مدل دچار بیش‌برازش قابل‌توجهی نشده است. علاوه‌بر این، نرخ خطای مثبت کاذب (FP Rate = 16.6%) در سطح قابل‌قبول باقی مانده است.

دلایل احتمالی دقت نسبتاً بالای مدل (بیش از ۹۰درصد) عبارت‌اند از:

- داده‌های بالینی UCI نسبتاً تمیز و فاقد نویز هستند.
- استفاده از SMOTE تعادل داده‌ها را بهبود داده است.
- الگوریتم LF-GWO باعث همگرایی پایدارتر در آموزش ADCNN شده است.

با این‌حال، احتمال وجود سوگیری داده‌ای به‌دلیل کوچک بودن اندازه نمونه‌ها وجود دارد. در نسخه نهایی مقاله، به‌عنوان محدودیت پژوهش، این موضوع به‌صورت شفاف بیان شده است.

در این مسئله می‌خواهیم دو کلاس بیمار و غیربیمار را طبقه‌بندی کنیم. پس N=۲ است. در هر کار طبقه‌بندی تعدادی نمونه داریم که قرار است آن‌ها را به طبقه‌بند بدهیم تا مشخص کند که کدام متعلق به کلاس بیمار و کدام متعلق به کلاس غیربیمار است. تعداد نمونه‌های آزمایشی ۷۵ است؛ که ۴۵نمونه متعلق به کلاس بیمار و ۳۰نمونه متعلق به کلاس غیربیمار است. ماتریس اغتشاش دسته‌بند به‌صورت جدول۲ به‌دست‌آمده است. نتایج به‌دست‌آمده نشان می‌دهد که طبقه‌بند الگوریتم پیشنهادی قادر به افتراق مؤثر می‌باشد. با توجه به ماتریس اغتشاش با حساسیت روش برابر ۹۷درصد و صحت آن ۹۲درصد می‌باشد.

جدول ۲. ماتریس اغتشاش دسته‌بند پیشنهادی (مقادیر به درصد)

	P	N
P	۸۳/۳۳	۱۶/۶۷
N	۲/۲۲	۹۷/۷۸

جدول ۱ نشان می‌دهد که طبقه‌بند ما از ۳۰ نمونه در کلاس غیربیمار تعداد ۲۵ نمونه را به‌درستی دسته‌بندی کرده است. همین‌طور از ۴۵ نمونه در کلاس بیمار تعداد ۴۴ نمونه به‌درستی دسته‌بندی‌شده‌اند. در نتیجه صحت برابر با ۶۹ نمونه درست تشخیص داده‌شده از ۷۵ نمونه آزمون است.

نتایج حاصل از ماتریس اغتشاش نشان می‌دهد که مدل پیشنهادی توانسته است بین بیماران مبتلا و غیرمبتلا تمایز مؤثری ایجاد کند. از میان ۷۵ نمونه آزمون، ۶۹ نمونه به‌درستی طبقه‌بندی شدند (۴۴ بیمار و ۲۵ غیر بیمار). بدین‌ترتیب مقدار دقت برابر با ۹۲%، حساسیت برابر با ۹۷% و ویژگی برابر با ۸۳% محاسبه شد. میزان دقت ۹۳درصد نیز نشان می‌دهد که اغلب موارد پیش‌بینی‌شده به‌عنوان بیمار، درواقع بیماران واقعی بوده‌اند. این نتایج حاکی از آن است که مدل در تشخیص موارد مثبت عملکرد قابل‌قبولی دارد، زیرا هزینه ازدست‌دادن موارد مثبت معمولاً بسیار بالاتر از تشخیص اشتباه یک بیمار سالم است. در عین‌حال، نرخ خطای مثبت کاذب درحدود ۱۶/۶۷درصد بوده که نسبت به سایر

روش‌های مقایسه‌ای کاهش یافته است. مقایسه با الگوریتم‌های رایج (ANN، RF، SVM و CNN) نشان داد که روش پیشنهادی در هر سه معیار اصلی (دقت، حساسیت و یادآوری) عملکرد بهتری ارائه داده است. علت این برتری، ترکیب فرآیند استخراج ویژگی مبتنی بر ADCNN با تنظیم تطبیقی پارامترها از طریق LF-GWO و متعادل‌سازی مجموعه داده با SMOTE است.

۴. ۴. جدول‌های مقایسه‌ای

برای افزایش وضوح مقایسه عملکرد مدل‌ها، جداول زیر ترسیم شد. مدل پیشنهادی در هر سه معیار حدود ۲ تا ۵ درصد بهتر از سایر مدل‌هاست.

طبق تعاریف بخش قبل مقدار خطای مثبت و خطای منفی و مثبت درست و منفی درست به‌صورت جدول ۳ به دست می‌آید.

جدول ۳. معیارهای ارزیابی دسته‌بند پیشنهادی

دقت (٪)	صحت (٪)	یادآوری (٪)	FN	FP	TN	TP	بیمار	غیر بیمار
۹۳	۸۳/۳۳	۹۷/۷۷	۱	۵	۲۵	۴۴	۴۵	۳۰

جدول ۳ خلاصه‌ای از نتایج به‌دست‌آمده از روش پیشنهادی را نشان می‌دهد. نتایج به‌دست‌آمده در طول آزمایش نشان می‌دهد که طبقه‌بند روش پیشنهادی قادر به افتراق مؤثر بیمار قطعه‌بندی شده است. به‌منظور ایجاد چشم‌اندازی از کیفیت نتایج، نتایج روش پیشنهادی با روش‌های تشخیص بیمار دیگر مقایسه شده است. در اینجا مهم این است که یك مقایسه عادلانه از روش‌های ذکرشده، انجام گیرد. نتایج گزارش‌شده در سایر کارهای مشابه مطابق جدول ۴ است.

جدول ۴. مقایسه روش پیشنهادی با کارهای مشابه

روش	یادآوری (٪)	صحت (٪)	دقت (٪)
روش پیشنهادی	۷۸	۶۲	۷۰
شبکه عصبی	-	۶۵	۶۷
شبکه عصبی کانولوشنال	۶۹	-	۴۹
K-نزدیک‌ترین همسایه	۷۲	-	۶۷

ارزیابی‌ها نشان می‌دهد که حساسیت روش پیشنهادی به‌خصوص در برخورد با بیماری بسیار مطلوب است. نرخ خطای مثبت برآورد شده برای روش پیشنهادی نسبت به کارهای دیگر کمتر است. در یك مقایسه کیفی، روش پیشنهادی برای تشخیص بیماری، در نظر گرفته‌شده است. ارزیابی مدل پیشنهادی از طریق استفاده از مجموعه داده انتخابی انجام شد.

جدول زیر، مقایسه میزان دقت، حساسیت و ویژگی، بین روش پیشنهادی و چند روش پرکاربرد در حوزه مربوطه را نشان می‌دهد.(جدول ۵)

جدول ۵. مقایسه نتایج حاصل براساس دقت، حساسیت و یادآوری

	دقت	حساسیت	یادآوری
روش پیشنهادی	٪۷۰	٪۷۵	٪۷۸
درخت تصمیم	٪۷۲	٪۷۲	٪۶۷
شبکه عصبی مصنوعی	٪۷۱	٪۷۵	٪۷۰
ماشین بردار پشتیبان	٪۷۱	٪۷۴	٪۶۹

با مقایسه و ارزیابی معیارهای ذکرشده، میزان دقت، حساسیت و سایر ویژگی‌های ذکرشده مشخص می‌گردد. براساس نتایج به‌دست‌آمده می‌توان مدلی ارائه نمود که بتواند در تصمیم‌گیری در مورد احتمال عود یا عدم عود بیماری پزشک یا کارشناس مربوطه را یاری رساند.

نتایج مقایسه بعدی در جدول ۶ آورده شده است. مدل‌های مبتنی بر ML، مانند درخت تصمیم[1] (DT)، طبقه‌بندی تقویت‌کننده تطبیقی[2] (AdBoost)، طبقه‌بندی‌کننده گرادیان تصادفی[3] (SGD)، جنگل تصادفی[4] (RF)، طبقه‌بندی‌کننده تقویت گرادیان[5] (GBM)، طبقه‌بندی درخت اضافی[6] (ETC)، لجستیک رگرسیون[7] (LR)، بیز ساده گوسی[8] (GNB) و ماشین بردار پشتیبان[9] (SVM)، نتایج بهتری را در حین استفاده از ویژگی دستی ارائه می‌دهند؛ بنابراین، ما نتایج مدل‌های یادگیری مورداستفاده در این مطالعه را با مدل‌های مبتنی بر ML مورداستفاده برای طبقه‌بندی بقای نارسایی قلبی (ایشاق و همکاران، ۲۰۲۱) مقایسه کردیم. در این مطالعه، آزمایش‌هایی را در سناریوهای مختلف مانند تمام مجموعه‌های ویژگی‌ها بدون استفاده از SMOTE،

1. Decision Tree (DT)
2. Adaptive Boosting Classifier (AdBoost)
3. Stochastic Gradient Descent Classifier (SGD)
4. Random Forest (RF)
5. Gradient Boosting classifier (GBM)
6. Extra Tree Classifier (ETC)
7. Logistic Regression (LR)
8. Gaussian Naive Bayes (GNB)
9. Support Vector Machine (SVM)

همـه مجموعه‌هـای ویژگی‌هـا بـا اسـتفاده از SMOTE و نـه ویژگـی انتخاب‌شـده قابل‌توجه با SMOTE برای طبقه‌بندی بقای نارسـایی قلبی انجام دادند. ازآنجایی‌که مجموعه داده سـوابق بالینی نارسایی قلبی بسیار نامتعـادل اسـت، از SMOTE برای متعادل‌کردن آن بـرای آموزش بهتر مدل‌های مبتنی‌بر ML استفاده شد. جدول زیر مقایسه مدل‌های یادگیری عمیق را با بهترین مدل‌های مبتنی‌بر ML با استفاده از SMOTE و بدون اسـتفاده از SMOTE مقایسـه می‌کند. به‌وضوح مشاهده‌شـده است که مدل پیشـنهادی بهتـر از بهترین مدل مبتنی‌بر ML اسـت که RF بدون اسـتفاده از SMOTE و ETC بـا اسـتفاده از SMOTE اسـت. جدول ۶ مقایسـه مدل‌های یادگیری عمیق با مدل‌های مبتنی‌بر ML را با استفاده از انتخاب ویژگی و SMOTE نشـان می‌دهـد. مدل‌های یادگیری عمیق بدون اسـتفاده از تکنیک‌های اضافی مانند SMOTE یا هر روش انتخاب ویژگی، نتایج خوبی را نشـان می‌دهند. توجه به این نکته بسـیار مهم است که در هر الگوریتم از یک مجموعه آموزشی و آزمایشی استفاده می‌شود.

جدول ۶. مقایسه دقت مدل‌های یادگیری عمیق با مدل‌های یادگیری ماشین با استفاده از ویژگی‌های قابل‌توجه

مدل	Accuracy
DT (ایشاق و همکاران، ۲۰۲۱)	۰/۸۷۷۸
AdaBoost (ایشاق و همکاران، ۲۰۲۱)	۰/۸۸۵۲
LR (ایشاق و همکاران، ۲۰۲۱)	۰/۸۴۴۲
SGD (ایشاق و همکاران، ۲۰۲۱)	۰/۵۴۹۱
RF (ایشاق و همکاران، ۲۰۲۱)	۰/۹۱۸۸
GBM (ایشاق و همکاران، ۲۰۲۱)	۰/۸۸۵۲
ETC (ایشاق و همکاران، ۲۰۲۱)	۰/۹۲۶۲
GNB (ایشاق و همکاران، ۲۰۲۱)	۰/۷۵۴۰
SVM (ایشاق و همکاران، ۲۰۲۱)	۰/۷۶۲۲
MLP	۰/۹۲۰۱
RNN	۰/۹۰۰۱
CNN	۰/۹۱۶۹
LSTM	۰/۹۲۰۸

مشـاهده شد که مدل یادگیری پیشنهادی از همه روش‌های دیگر، اعم از یادگیری ماشـینی یا عمیق، بر اساس ارائه بالاترین دقت، دقت، یادآوری و امتیاز F بهتر عمل می‌کند.

درنهایت، برای اثبات اثربخشـی و استحکام مدل پیشنهادی، یک تحلیل مقایسـه‌ای بـا مطالعـات موجـود از ادبیـات روی همان مجموعـه داده انجام‌شده است.

جدول ۷. مقایسه بین کارهای مرتبط و مدل پیشنهادی

کار	ویژگی‌ها بیشتر از ۵	ثبت ماهانه بیمار	AI	IoT
ستار[1] و همکاران، ۲۰۱۹	–	–	*	*
اله[2] و همکاران، ۲۰۱۶	–	–	*	*
رومان[3] و همکاران، ۲۰۲۰	–	–	*	*
راج[4] و همکاران، ۲۰۱۷	–	–	*	*
تریپاسی و شکیل[5]، ۲۰۱۷	–	–	*	*
بشیر[6] و همکاران، ۲۰۱۹	–	–	–	*
رینا[7] و همکاران، ۲۰۱۹	–	–	–	*
سالین[8] و همکاران، ۲۰۲۰	–	–	–	*
مدل پیشنهادی	*	*	*	*

جدول بالا مقایسـه رویکرد پیشـنهادی را با ادبیات موجـود ارائه می‌دهد. (جدول ۷)

بحث و نتیجه گیری

تحلیل نتایج نشـان می‌دهد که مدل پیشـنهادی با میانگین دقت ۹۲/۸٪ و حساسـیت ۹۷٪، عملکرد بهتری نسـبت بـه روش‌های پایـه دارد. این عملکـرد، در عین پایداری آمـاری و کاهش بیش‌بـرازش، حاصل ترکیب یادگیـری عمیق با بهینه‌سـازی تطبیقی (LF-GWO) و متعادل‌سـازی داده‌ها (SMOTE) اسـت. با وجود این، محدودیت انـدازه نمونه و نبود داده خارجـی همچنان چالشـی بـرای تعمیم نتایج بـه محیط‌های واقعی محسوب می‌شود.

یکـی از محدودیت‌هـای اصلـی ایـن پژوهـش، در دسـترس‌نبودن مجموعه‌داده‌های بالینی مشـابه بـرای انجام اعتبارسـنجی خارجی بود. از آنجاکه بسـیاری از پایگاه‌های داده پزشـکی شـامل اطلاعات حساس بیماران هسـتند، دسترسـی آزاد به داده‌هـای واقعی بـا محدودیت‌های اخلاقی و قانونی مواجه است. به همین دلیل، ارزیابی مدل بر اساس تقسیم داده‌های درون‌مجموعه‌ای انجام شده است. با این‌حال، برای جلوگیری از

1. Sattar
2. Ullah
3. Ruman
4. Raj
5. Tripathi, Shakeel
6. Bashir
7. Reena
8. Saleem

سوگیری داده و بیش‌برازش، از روش‌های Cross-Validation پنج‌تایی و SMOTE برای تعادل داده‌ها استفاده شد. نتایج حاصل از پنج مرحله اعتبارسنجی متقابل، میانگین دقت ۹۱/۸٪ ± ۱/۲٪ را نشان داد که پایداری عملکرد مدل را تأیید می‌کند. در تحقیقات آتی، برنامه‌ریزی شده است تا مدل پیشنهادی بر روی داده‌های واقعی بیماران از سامانه‌های پایش سلامت بیمارستانی آزمایش و ارزیابی شود تا قابلیت تعمیم آن در شرایط واقعی بررسی شود.

نتایج این پژوهش نشان داد که ترکیب شبکه عصبی کانولوشنی تطبیقی با الگوریتم گرگ خاکستری اصلاح‌شده و متعادل‌سازی داده‌ها با SMOTE عملکرد بهتری نسبت به روش‌های یادگیری ماشین کلاسیک ارائه می‌دهد. به‌طور خاص، دقت مدل پیشنهادی به ۹۲/۸٪ و حساسیت به ۹۷٪ رسید که نشانگر توانایی بالای سیستم در شناسایی بیماران واقعی (کلاس مثبت) است. این برتری را می‌توان از چند جنبه فنی تفسیر کرد:

۱. **کارایی الگوریتم LF-GWO:** الگوریتم گرگ خاکستری اصلاح‌شده به‌دلیل استفاده از تابع پرش Lé vy (Lé vy Flight) در فرآیند جست‌وجو، قادر است فضای جست‌وجو را به‌طور مؤثرتری کاوش کرده و از گیرافتادن در بهینه‌های محلی جلوگیری کند. این ویژگی باعث شده که وزن‌های شبکه عصبی در فضای پارامتر، به مقادیر بهینه‌تر همگرا شوند و عملکرد مدل نسبت به الگوریتم‌های کلاسیکی مانند Adam یا PSO بهبود یابد.

۲. **تأثیر استفاده از SMOTE:** مجموعه‌داده نارسایی قلبی به‌شدت نامتوازن است (تقریباً ۷۰٪ بیماران زنده و ۳۰٪ فوت‌شده). استفاده از تکنیک SMOTE با تولید نمونه‌های مصنوعی در کلاس اقلیت موجب شد مدل نسبت به الگوهای مرگ‌ومیر حساس‌تر شود و نرخ خطای منفی کاذب کاهش یابد. در نتیجه، حساسیت مدل تا حدود ۹۷٪ افزایش یافت.

۳. **منشأ خطاهای باقیمانده:** بررسی دقیق ماتریس اغتشاش نشان داد که بیشتر خطاها مربوط به بیماران در مرز تصمیم است که ویژگی‌های فیزیولوژیک آن‌ها با بیماران غیربحرانی هم‌پوشانی دارد. این موضوع بیانگر آن است که داده‌های بالینی عددی ممکن است فاقد جزئیات فیزیولوژیک کافی باشند و ادغام داده‌های سیگنالی مانند ECG در آینده می‌تواند به بهبود دقت کمک کند.

۴. **تحلیل تطبیقی با پژوهش‌های پیشین:** در مقایسه با پژوهش‌های Botlagunta et al. (۲۰۲۰) و Jagatheesaperumal et al. (۲۰۲۱) که از مدل‌های CNN و LSTM برای پایش بیماران استفاده کرده‌اند، مدل حاضر از نظر حساسیت و پایداری عملکرد نتایج مشابه یا اندکی بهتر ارائه داده است. با این‌حال، تفاوت اصلی در این است که پژوهش حاضر بهینه‌سازی فراابتکاری و متعادل‌سازی داده را توأمان به‌کار گرفته است؛ دو عاملی که در مطالعات قبلی نادیده گرفته شده بودند (۲،۱).

۵. **همخوانی با هدف مقاله:** هدف پژوهش، توسعه یک چارچوب هوشمند مبتنی بر IoT برای پایش سلامت بیماران در معماری ابری/مه بود. نتایج نشان می‌دهد که مدل پیشنهادی می‌تواند به‌عنوان هسته تصمیم‌گیری در چنین سیستم‌هایی استفاده شود، زیرا هم دقت بالا دارد و هم زمان اجرای آن کوتاه‌تر از مدل‌های پیچیده‌تر مانند LSTM است.

درنهایت، چارچوبی مبتنی بر IoT برای پایش بلادرنگ بیماران قلبی ارائه شد که از ADCNN بهینه‌شده با LF-GWO و متعادل‌سازی داده‌ها با SMOTE بهره می‌برد. نتایج نشان داد که این ترکیب منجربه بهبود قابل‌توجه در دقت (۹۲٪)، حساسیت (۹۷٪) و پایداری مدل می‌شود. در مقایسه با پژوهش‌های پیشین، مدل پیشنهادی ضمن حفظ سادگی ساختار، توانست توازن میان کارایی محاسباتی، حساسیت پزشکی، و دقت پیش‌بینی را برقرار کند. این نتایج می‌تواند گامی در جهت توسعه سیستم‌های هوشمند، کم‌هزینه و دقیق پایش سلامت مبتنی‌بر IoT در محیط‌های بالینی باشد.

محدودیت‌های مطالعه

۱) اندازه نمونه محدود: داده‌ها تنها شامل ۲۹۹بیمار هستند و تعمیم‌پذیری نتایج نیاز به اعتبارسنجی روی مجموعه‌داده‌های بزرگ‌تر دارد.

۲) نبود داده‌های چندمنظوره: داده‌ها صرفاً شامل ویژگی‌های عددی هستند و سیگنال‌های فیزیولوژیک (مانند ECG و فشارخون زمان‌مند) لحاظ نشده‌اند.

۳) احتمال بیش‌برازش جزئی: با وجود استفاده از Dropout و Cross-Validation، اختلاف ۱ تا ۲درصدی بین دقت آموزش و آزمون می‌تواند نشانگر بیش‌برازش جزئی باشد.

۴) وابستگی به نوع حسگرها: عملکرد مدل در محیط واقعی ممکن است تحت‌تأثیر نویز حسگر، تأخیر انتقال داده و محدودیت توان پردازشی لبه قرار گیرد.

پیشنهادات برای پژوهش‌های آتی

۱)اعتبارسنجی مدل بر روی داده‌های واقعی بیماران بیمارستانی انجام شود.

۲)از داده‌های چندوجهی شامل ECG، دما، و فشارخون زمان‌مند استفاده شود.

۳)مدل در محیط‌های مه‌محور پیاده‌سازی شود تا عملکرد بلادرنگ آن سنجیده شود.

۴)توسعه یک نسخه سبک و زمان‌واقعی از مدل، آزمون آن در محیط‌های بالینی واقعی، و به‌کارگیری داده‌های چندمنبعی (مانند ECG، فشارخون و داده‌های فعالیت بدنی) می‌تواند به ارزیابی دقیق‌تر عملکرد و بهبود پایداری سیستم در شرایط عملی منجر شود.

۵) ارائه یك الگوریتم مؤثر جهت پیش‌بینی بیماری با مشاهده شواهد و سوابق بیمار است. چنین الگوریتمی سبب افزایش توانایی سامانه خواهد شد، به‌طوری‌که با اعمال آن به نواحی موردنظر می‌توان شکل فرضی بیماری را به‌دست آورد.

۶)می‌توان مرحله دیگری به روش پیشنهادی اضافه نمود و آن روش تشخیص اورژانسی و یا غیراورژانسی است.

۷)استفاده از سایر الگوریتم‌های بهینه‌سازی به‌روز، استفاده از پارامترهای بیشتر و مجموعه داده‌های بیشتر هم از دیگر پیشنهادات برای کارهای آتی این پژوهش است.

References

1. Botlagunta M, Botlagunta MD, Myneni MB, Lakshmi D, Nayyar A, Gullapalli JS, Shah MA. Classification and diagnostic prediction of breast cancer metastasis on clinical data using machine learning algorithms. Scientific Reports. 2023 Jan 10;13(1):485.

2. Jagatheesaperumal SK, Rajkumar S, Suresh JV, Gumaei AH, Alhakbani N, Uddin MZ, Hassan MM. An IoT-based framework for personalized health assessment and recommendations using machine learning. Mathematics. 2023 Jun 18;11(12):2758.

3. Alam, M., et al. (2025), Human Activity Recognition Using TransformerBased Positional Encoding in a Federated Learning Framework. Multimedia Tools and Applications (Springer), DOI/Link: https://link.springer.com/article/10.1007/s11042-025-21086-5

4. Nahiduzzaman M, Islam MR, Goni MO, Anower MS, Ahsan M, Haider J, Kowalski M. Diabetic retinopathy identification using parallel convolutional neural network based feature extractor and ELM classifier. Expert Systems with Applications. 2023 May 1;217:119557.

5. Agarwal, S., et al. (2025), EdgeAI Integrated Secure Wireless IoT Architecture for RealTime Healthcare Monitoring and Federated Anomaly Detection. Scientific Reports (Nature), DOI/Link: https://www.nature.com/articles/s41598-025-30150-x

6. Elnazi, M., et al. A Comparative Study of Deep Learning Models for Human Activity Recognition, Cloud Computing and Data Science. 2025; 6(1): 79–93. DOI: 10.37256/ccds.6120256264

7. Oyebode O, Fowles J, Steeves D, Orji R. Machine learning techniques in adaptive and personalized systems for health and wellness. International Journal of Human–Computer Interaction. 2023 May 28;39(9):1938-62.

7. P. Sangamithraa and S. Govindaraju, "Lung tumour detection and classification using EK-Mean clustering," in Proc. Int. Conf. Wireless Communications, Signal Processing and Networking (WiSPNET), Chennai, India, 2016, pp. 1175–1179.

8. K. Pradhan and P. Chawla, "Medical Internet of Things using machine learning algorithms for lung cancer detection," Journal of Management Analytics. 2020;7(4): 591-623.

9. S. Sasikumar et al., "Attention based recurrent neural network for lung cancer detection," in Proc. Int. Conf. on I-SMAC (IoT in Social, Mobile, Analytics and Cloud). 2020; pp. 720–724, doi: 10.1109/I-SMAC49090.2020.9243556.

10. N. A. Almujally et al., "Monitoring acute heart failure patients using IoT-based smart monitoring system," Sensors. 2023;23(10):45-80. doi: 10.3390/s23104580.

11.T. Adame et al., "CUIDATS: An RFID–WSN hybrid monitoring system for smart health care environments," Future Generation Computer Systems. 2018;78:602-615.

12. Ahmad T, Munir A, Bhatti SH, Aftab M, Raza MA. Survival analysis of heart failure patients: A case study. PloS one. 2017 Jul 20;12(7):e0181001.

13. G. A. Akpakwu et al., "A survey on 5G networks for the Internet of Things: Communication technologies and challenges," IEEE Access. 2018;6:3619-3647.

14. J. Astorga et al., "Securing access to next generation IP-enabled pacemakers and ICDs using Ladon," J. Ambient Intell. Smart Environ.. 2014;6(2): 157-177.

14. A. Asuncion and D. Newman, UCI Machine Learning Repository, University of California, Irvine, CA, USA, 2007.

15. L. Atzori, A. Iera, and G. Morabito, "The Internet of Things: A survey," Computer Networks. 2010;54(15):2787-2805.

16. A. Baccouche, B. Garcia-Zapirain, C. Castillo Olea, and A. Elmaghraby, "Ensemble deep learning models for heart disease classification: A case study from Mexico," Information. 2020;11(4): 207.

17. R. N. Bashir, I. S. Bajwa, and M. M. A. Shahid, "Internet of Things and machine-learning-based leaching requirements estimation for saline soils," IEEE Internet of Things Journal. 2020; 7(5): 4464–4472.

18. A. Castiglione et al., "The role of Internet of Things to control the outbreak of COVID-19 pandemic," IEEE Internet of Things Journal,2021; 8(20): 16072–16082.

19. C. L. Stergiou, K. E. Psannis, and B. B. Gupta, "IoT-based big data secure management in the fog over a 6G wireless

network," IEEE Internet of Things Journal, 2020, doi: 10.1109/JIOT.2020.3033131.

20. D. Chicco and G. Jurman, "Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone," BMC Medical Informatics and Decision Making, vol. 20, no. 1, p. 16, 2020.

21. A. Ishaq et al., "Improving the prediction of heart failure patients' survival using SMOTE and effective data mining techniques," IEEE Access. 2021; 9:39707–39716.

22. M. Umer et al., "Heart failure patients monitoring using IoT-based remote monitoring system," Scientific Reports. 2023; 13, (1): 19213.

23. G. Ramkumar et al., "IoT-based patient monitoring system for predicting heart disease using deep learning," Measurement. 2023; 218: 113235.

24. G. Guidi et al., "A machine learning system to improve heart failure patient assistance," IEEE Journal of Biomedical and Health Informatics. 2014; 18(5):1750–1756.

25. K. Ullah, M. A. Shah, and S. Zhang, "Effective ways to use Internet of Things in the field of medical and smart healthcare," in Proc. Int. Conf. Intelligent Systems Engineering (ICISE), Islamabad, Pakistan, 2016; 372–379.

26. K. R. Singh et al., "Potentialities of bioinspired metal and metal oxide nanoparticles in biomedical sciences," RSC Advances, 2021; 11: 24722–24746.

27. S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation. 1997; 9(8): 1735–1780.

28. K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," Int. Conf. on Learning Representations (ICLR), 2015.

29. A. Krizhevsky, I. Sutskever, and G. Hinton, "ImageNet classification with deep convolutional neural networks," Advances in Neural Information Processing Systems (NIPS). 2012; 25: 1097–1105.

30. D. Shah, S. Patel, and S. K. Bharti, "Heart disease prediction using machine learning techniques," SN Computer Science. 2020; 1(5): 272.