



Research Paper

Developing a Mobile Application for Early Prediction of Hypertension in Children



*Hamidreza Tahmasbi¹, Reza Besharati²

1. Department of Computer Engineering, Faculty of Engineering, Kashmar Branch, Islamic Azad University, Kashmar, Iran.

2. Department of Nursing, Faculty of Nursing, Kashmar Branch, Islamic Azad University, Kashmar, Iran.



Citation Tahmasbi H, Besharati R. [Developing a Mobile Application for Early Prediction of Hypertension in Children (Persian)]. *Journal of Modern Medical Information*. 2024; 10(2):206-219. <https://doi.org/10.32598/JMIS.10.2.6>

doi <https://doi.org/10.32598/JMIS.10.2.6>

Article Info:

Received: 04 Dec 2023

Accepted: 06 Jun 2024

Available Online: 01 Jul 2024

Key words:

Hypertension, Mobile applications, Early diagnosis, Child health, Machine learning

ABSTRACT

Objective Early diagnosis of hypertension in children is necessary to minimize the risks and consequences of this complication. This study aims to design and create a mobile application for diagnosing and predicting hypertension in children using machine learning methods so that the parents can continuously control and monitor their children's blood pressure.

Methods In this applied-developmental study that was conducted in 2022, the values related to 19 factors affecting hypertension were collected from 1287 primary school children aged 7-13 years were first collected using questionnaires and measurements. Then, by combining the outputs of three machine learning methods (multi-layer perceptron, support vector machine (SVM) and random forest [RF]), a model was presented for a more accurate diagnosis of hypertension using Weka software, version 3.7.8 and Python programming language. To measure the effectiveness of the model, the 10-fold cross-validation method was used, and the paired t-test was used to compare its performance with other methods. $P < 0.05$ was considered statistically significant. Finally, the proposed model was implemented in an Android mobile application.

Results The proposed model's precision, sensitivity and specificity were 91.74%, 83.5% and 94.49%, respectively, and had better performance in predicting hypertension in children than other methods. These values were significantly different from those of compared methods ($P < 0.05$).

Conclusion The proposed model performs better in diagnosing and predicting hypertension in children. The developed mobile application is thus useful for early diagnosis of hypertension in children. Parents can use this application to be informed about their children's blood pressure status and consult a doctor immediately if there is a danger.

* Corresponding Author:

Hamidreza Tahmasbi, PhD.

Address: Department of Computer Engineering, Faculty of Engineering, Kashmar Branch, Islamic Azad University, Kashmar, Iran.

Tel: +98 (915) 1046117

E-mail: htahma@gmail.com



Copyright © 2024 The Author(s);

This is an open access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC: <https://creativecommons.org/licenses/by-nc/4.0/legalcode.en>), which permits use, distribution, and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

Extended Abstract

Introduction

Today, an increasing number of children and teenagers suffer from hypertension due to poor lifestyle, including poor nutrition, low physical activity, overweight or obesity. There is evidence that high blood pressure and cardiovascular disease in adulthood originate in childhood. Early identification of children with hypertension or at higher risk of hypertension is necessary to minimize the risks and consequences of this condition.

Today, the use of machine learning methods as a useful and effective solution in predicting and controlling hypertension has received special attention. On the other hand, diagnosing and predicting high blood pressure with the help of a mobile application can increase the ability to monitor blood pressure due to its ease of use for many people. In this study, we aim to design and develop a mobile application for diagnosing and predicting hypertension in children, using machine learning methods, so that parents can continuously control and monitor their children's blood pressure.

Methods

In this applied-developmental study that was conducted in 2022, first, the values related to 19 factors affecting hypertension were collected from 1287 primary school children aged 7-13 years using questionnaires and measurements with the written consent of their parents. After data preprocessing and preparation, three commonly used machine learning methods in hypertension diagnosis and prediction, including multi-layer perceptron (MLP), support vector machine (SVM) and random forest (RF), were separately applied to the data set and performed the prediction. In the proposed model, four categories of normal blood pressure, pre-hypertension, stage 1 hypertension and stage 2 hypertension were con-

sidered as the observation framework. Then, the results obtained from the three mentioned learning methods were combined using the Dempster-Shafer evidence theory for the final prediction. Model implementation was done using Weka software, version 3.8.6 and Python programming language. To measure the effectiveness of the model, the 10-fold cross-validation method and the paired t-test were used for comparison. $P < 0.05$ was considered statistically significant. Finally, the proposed model was implemented using the Kiwi software, version 2.1.0 development kit in an Android mobile application.

Results

The rates of precision, sensitivity and specificity for the proposed model and three machine learning methods are shown in Table 1. The rates for the proposed model in comparison with other new methods for diagnosing and predicting hypertension are presented in Table 2. The results showed that the precision, sensitivity and specificity for the proposed model were significantly higher than those of the three machine learning methods and those of other methods. The results of the paired t-test for comparing the accuracy of the proposed model and other methods are shown in Table 3. Considering that the $P < 0.05$, it can be said that the difference in the effectiveness between the proposed model and learning methods and other methods was statistically significant.

Conclusion

These results showed that the proposed model can better predict and diagnose hypertension in children and can help improve accuracy and reduce the error rate. By using the developed mobile application, parents can find out about their children's blood pressure status and see a doctor immediately if there was any danger. This application, in addition to being a basis for timely and appropriate prevention and treatment of hypertension in children, can help make decisions for the allocation of health resources and necessary policies.

Table 1. The performance of the proposed model and three machine learning methods

Method	Precision	Sensitivity	Specificity
MLP	84.92	69.89	89.95
SVM	75.71	51.44	83.83
RF	86.38	72.77	90.92
Proposed method	91.74	83.5	94.49

Table 2. The performance of the proposed model and other methods

Method	Precision	Sensitivity	Specificity
Ambika et al. 2020 [13]	86.64	73.52	91.1
Zhao et al. 2021[17]	87.11	74.22	91.4
Chai et al. 2021 [19]	85.15	70.5	90.11
Fitriyani et al. 2019 [23]	87.66	75.34	91.78
Fang et al. 2021 [25]	89.44	78.88	92.96
Proposed method	91.74	83.5	94.49

Table 3. Results of the paired t-test

Method	P
MLP	0.0018
SVM	0.0064
RF	0.0007
Ambika et al. 2020 [13]	0.0039
Zhao et al. 2021[17]	0
Chai et al. 2021 [19]	0.0104
Fitriyani et al. 2019 [23]	0.0021
Fang et al. 2021 [25]	0.0079

Ethical Considerations

Compliance with ethical guidelines

This study was approved by [Mashhad University of Medical Sciences](#) (Code: MUMS.IR 038.1401.REC).

Funding

This research did not receive any grant from funding agencies in the public, commercial, or non-profit sectors.

Authors' contributions

Conceptualization, formal analysis, methodology, investigation, supervision: All authors; Software, writing, funding acquisition, and resources: Hamidreza Tahmasbi.

Conflicts of interest

The authors declared no conflict of interest.



مقاله پژوهشی

ارائه مدل و برنامه کاربردی مبتنی بر تلفن همراه برای پیش‌بینی زودهنگام فشار خون بالا در کودکان

*حمیدرضا طهماسبی^۱، رضا بشارتی^۲

۱. گروه مهندسی کامپیوتر، دانشکده مهندسی، واحد کاشمر، دانشگاه آزاد اسلامی، کاشمر، ایران.
۲. گروه پرستاری، دانشکده پرستاری، واحد کاشمر، دانشگاه آزاد اسلامی، کاشمر، ایران.



Citation Tahmasbi H, Besharati R. [Developing a Mobile Application for Early Prediction of Hypertension in Children (Persian)]. *Journal of Modern Medical Information*. 2024; 10(2):206-219. <https://doi.org/10.32598/JMIS.10.2.6>

doi <https://doi.org/10.32598/JMIS.10.2.6>

چکیده

هدف تشخیص زودهنگام کودکان با فشار خون بالا و یا در معرض افزایش فشار خون، برای به حداقل رساندن خطرات و پیامدهای این عارضه ضروری است. این مطالعه با هدف طراحی و ایجاد یک برنامه کاربردی مبتنی بر تلفن همراه برای تشخیص و پیش‌بینی فشار خون بالا در کودکان، با استفاده از روش‌های یادگیری ماشین انجام شد. به‌طوری‌که والدین بتوانند با ورود اطلاعاتی که به‌راحتی از کودکان قابل دست‌یابی است، بر فشار خون فرزندان خود کنترل و نظارت مداوم داشته باشند.

روش‌ها در این مطالعه کاربردی توسعه‌ای که در سال ۱۴۰۱ انجام شد، ابتدا مقادیر ویژگی‌های مؤثر بر فشار خون بالا در ۱۲۸۷ کودک دبستانی با استفاده از پرسش‌نامه و اندازه‌گیری، جمع‌آوری و سپس مدلی مبتنی بر ترکیب نتایج خروجی ۳ روش یادگیری ماشین شبکه عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی برای تشخیص دقیق‌تر کودکان با فشار خون بالا با استفاده از نرم‌افزار داده‌کاوی Weka و زبان برنامه‌نویسی پایتون ارائه شد. برای سنجش کارایی مدل از روش اعتبارسنجی متقابل ۱۰ تکه برابر و آزمون آماری تی زوجی استفاده شد که میزان P کمتر از ۰/۰۵ معنادار در نظر گرفته شد. درنهایت، مدل پیشنهادی در قالب یک برنامه کاربردی قابل‌استفاده در گوشی تلفن همراه پیاده‌سازی شد.

یافته‌ها دقت، حساسیت و ویژگی در مدل پیشنهادی به ترتیب ۹۱/۷۴ درصد، ۸۳/۵ درصد و ۹۴/۴۹ درصد بود و نسبت به روش‌های مشابه از عملکرد بهتری در پیش‌بینی فشار خون بالا در کودکان برخوردار است. مقادیر این معیارها در مدل پیشنهادی نسبت به روش‌های مقایسه‌شده، اختلاف قابل‌توجهی دارد. در نتایج حاصل از آزمون آماری، مقادیر P به‌دست‌آمده کمتر از ۰/۰۵ بود و اختلاف دقت مدل پیشنهادی در مقایسه با روش‌های مشابه از نظر آماری معنادار بود.

نتیجه‌گیری مدل پیشنهادی در تشخیص و پیش‌بینی فشار خون بالا در کودکان بهتر عمل کرده و می‌تواند به بهبود دقت کمک کند. برنامه کاربردی پیاده‌سازی‌شده بر مبنای مدل پیشنهادی برای تشخیص به‌موقع فشار خون بالا در کودکان مفید بود و والدین با استفاده از این برنامه می‌توانند از وضعیت فشار خون کودکان خود مطلع شده و در صورت وجود خطر سریعاً به پزشک مراجعه کنند.

اطلاعات مقاله:

تاریخ دریافت: ۱۳ آذر ۱۴۰۲

تاریخ پذیرش: ۱۷ خرداد ۱۴۰۳

تاریخ انتشار: ۱۱ تیر ۱۴۰۳

کلیدواژه‌ها:

فشار خون بالا، برنامه کاربردی همراه، تشخیص زودهنگام، سلامت کودک، یادگیری ماشین

* نویسنده مسئول:

دکتر حمیدرضا طهماسبی

نشانی: کاشمر، دانشگاه آزاد اسلامی، واحد کاشمر، دانشکده مهندسی، گروه مهندسی کامپیوتر.

تلفن: ۱۰۴۶۱۱۷ (۹۱۵) +۹۸

پست الکترونیکی: htahma@gmail.com



Copyright © 2024 The Author(s);

This is an open access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC: <https://creativecommons.org/licenses/by-nc/4.0/legalcode.en>), which permits use, distribution, and reproduction in any medium, provided the original work is properly cited and is not used for commercial purposes.

مقدمه

ایسلام و همکاران [۱۴] نیز از روش‌های یادگیری ماشین درخت تصمیم^۱، جنگل تصادفی^۲، رگرسیون خطی^۳، تقویت گرادیان^۴، تقویت گرادیان شدید^۵ و روش آنالیز تشخیص خطی^۶ برای پیش‌بینی فشار خون بالا و همچنین شناسایی عوامل مؤثر بر این عارضه استفاده کردند. ارزیابی آن‌ها نشان داد روش‌های رگرسیون خطی، تقویت گرادیان شدید و آنالیز تشخیص خطی با دقتی حدود ۹۰ درصد، بهتر از روش‌های جنگل تصادفی و درخت تصمیم بوده و ویژگی‌های سن و شاخص توده بدنی، عوامل مؤثر در فشار خون بالا در مجموعه داده مورد بررسی بوده‌اند. در تحقیق مشابه، آنج و همکاران [۱۵] از روش‌های درخت تصمیم، بیزن ساده^۷، نزدیک‌ترین k همسایه^۸، شبکه‌های عصبی مصنوعی^۹، ماشین بردار پشتیبان^{۱۰}، جنگل تصادفی، رگرسیون خطی، رأی‌گیری و تقویت گرادیان شدید برای پیش‌بینی فشار خون بالا استفاده کردند. یافته‌های آن‌ها بیانگر عملکرد بهتر روش جنگل تصادفی نسبت به سایر روش‌های مقایسه‌شده بود.

الکعبی و همکاران [۱۶] با استفاده از ۳ روش درخت تصمیم، جنگل تصادفی و رگرسیون لجستیک، مدلی برای پیش‌بینی فشار خون بالا پیشنهاد کردند. در این مطالعه، روش جنگل تصادفی با دقت پیش‌بینی ۸۲/۱ درصد، کارایی بهتری در تشخیص وجود فشار خون بالا داشت. ژائو و همکاران [۱۷] با استفاده از روش یادگیری جنگل تصادفی روشی برای پیش‌بینی فشار خون بالا از روی ویژگی‌هایی که از افراد و بدون نیاز به ابزار تخصصی خاصی به دست می‌آید، ارائه کردند. دقت این روش حدود ۸۲ درصد بود و ویژگی‌های سن، دور کمر، شاخص توده بدنی و سابقه خانوادگی فشار خون را به‌عنوان عوامل اصلی فشار خون بالا در مجموعه داده مورد نظر شناسایی کرده است.

چای و همکاران [۱۸] روش‌های مختلف یادگیری ماشین را برای تشخیص فشار خون بالا در نوجوانان ۱۳ تا ۱۷ ساله بررسی کردند. یافته‌های آن‌ها نشان داد روش یادگیری تقویت گرادیان سبک^{۱۱} در مقایسه با سایر روش‌ها برای تشخیص فشار خون بالا عملکرد بهتری داشته است. آن‌ها همچنین در مطالعه دیگری [۱۹] با توسعه روش یادگیری شبکه‌های عصبی مصنوعی، مدلی با دقت ۷۶ درصد در پیش‌بینی فشار خون بالا در نوجوانان

فشار خون بالا در بزرگسالی یک عامل بسیار رایج در افزایش خطر حمله قلبی، بیماری‌های قلبی-عروقی و مرگ‌ومیر است [۴-۱]. شواهد زیادی وجود دارد که نشان می‌دهد فشار خون بالا و بیماری‌های قلبی-عروقی در بزرگسالی از دوران کودکی منشأ می‌گیرند [۵، ۶]. امروزه تعداد فزاینده‌ای از کودکان و نوجوانان به دلایلی از قبیل شیوه زندگی، تغذیه، عدم فعالیت فیزیکی، اضافه‌وزن و چاقی، دچار فشار خون بالا می‌شوند. بررسی انجام‌شده در مطالعه [۷] افزایش قابل توجه در ابتلای کودکان و نوجوانان به فشار خون بالا در دو دهه اخیر در جهان را گزارش می‌کند. در ایران نیز در مطالعه جامعی که انجام شده [۸]، شیوع فشار خون در کودکان ایرانی بالا گزارش شده و باتوجه به افزایش سال‌به‌سال آن، بر نیاز به توجه بیشتر به این عارضه در کودکان تأکید شده است. فشار خون بالا حتی در دوران کودکی خطر ابتلا به تصلب شریانی و بیماری‌های قلبی-عروقی را افزایش می‌دهد [۵]. فشار خون کودکان نیازمند اقدامات برنامه‌ریزی‌شده برای به حداقل رساندن افزایش فشار خون در بزرگسالان و بیماری‌های قلبی-عروقی در آینده است [۸].

باتوجه به پیامدهای درازمدت فشار خون بالای کنترل‌نشده در کودکان برای سلامتی، شناسایی زودهنگام کودکان پر فشار خون و یا در معرض خطر ابتلا به فشار خون و شروع پیشگیری از فشار خون بالا در اوایل زندگی ضروری است و این موضوع به یکی از مهم‌ترین چالش‌های بهداشت عمومی در سراسر جهان تبدیل شده است [۳، ۷]. فشار خون بالا معمولاً بدون علامت است و باعث می‌شود شانس تشخیص زودهنگام آن به شدت کاهش یابد [۹]. در سال‌های اخیر استفاده از روش‌های یادگیری ماشین به‌عنوان یک راهکار مفید و مؤثر در پیش‌بینی و کنترل بیماری‌ها از اهمیت خاصی برخوردار شده است. یادگیری ماشین شاخه‌ای از هوش مصنوعی است که علوم کامپیوتر، آمار و نظریه تصمیم را برای یادگیری و استخراج الگوهای پیچیده از حجم انبوهی از داده‌ها ترکیب می‌کند. مطالعات انجام‌شده در ۲ دهه اخیر، سودمند بودن استفاده از یادگیری ماشین برای تشخیص و پیش‌بینی فشار خون را نشان می‌دهند. به طوری که مورد توجه بسیاری از پژوهشگران قرار گرفته است [۲، ۴، ۱۰-۱۲]. به‌عنوان مثال آمبیکا و همکاران [۱۳] با توسعه روش یادگیری ماشین بردار پشتیبان، یک سیستم پشتیبان تصمیم برای پیش‌بینی ابتلا به فشار خون بالا از روی اطلاعات سوابق پزشکی و شیوه زندگی افراد با دقت ۹۱/۸۸ درصد پیشنهاد کردند.

1. Decision Tree (DT)
2. Random Forest (RF)
3. Linear Regression (LR)
4. Gradient Boosting Machine (GBM)
5. EXtreme Gradient Boosting
6. Linear Discriminant Analysis (LDA)
7. Naive Bayesian (NB)
8. K-nearest Neighbors (KNN)
9. Artificial Neural Network (ANN)
10. Support Vector Machine (SVM)
11. LightGBM

[۲۶]، نمونه‌های ورودی به یکی از ۴ دسته نرمال، پیش فشار خون بالا، فشار خون بالای مرحله ۱ و فشار خون بالای مرحله ۲ دسته‌بندی می‌شوند. امروزه گوشی‌های تلفن همراه به بخشی جدایی‌ناپذیر از زندگی اکثر مردم تبدیل شده‌اند. تشخیص و پیش‌بینی فشار خون بالا به کمک گوشی تلفن همراه به دلیل سهولت استفاده برای بسیاری از مردم، می‌تواند توانایی نظارت بر فشار خون را افزایش دهد. در برنامه کاربردی پیاده‌سازی شده، والدین می‌توانند با ورود اطلاعاتی که به راحتی از کودکان و بدون نیاز به ابزار تخصصی خاصی قابل دست‌یابی است بر فشار خون فرزندان خود کنترل و نظارت مداوم داشته باشند.

مواد و روش‌ها

این پژوهش از نوع کاربردی توسعه‌ای بود که در آن ابتدا مدلی برای پیش‌بینی فشار خون بالا در کودکان دبستانی با استفاده از روش‌های یادگیری ماشین ارائه شد و سپس با استفاده از این مدل پیشنهادی، یک برنامه کاربردی قابل استفاده در گوشی تلفن همراه برای تشخیص و پیش‌بینی فشار خون بالا در کودکان طراحی و پیاده‌سازی شد. نمونه آماری ۱۲۸۷ نفر از دانش‌آموزان بین ۷ تا ۱۳ ساله دبستان‌های شهر کاشمر شامل ۵۴۲ پسر و ۷۴۵ دختر بودند که مقادیر مربوط به ۱۹ ویژگی مؤثر در فشار خون این دانش‌آموزان با رضایت کتبی والدین آن‌ها جمع‌آوری شد. این ویژگی‌ها در جدول شماره ۱ مشاهده می‌شوند. مقادیر ویژگی‌های جنسیت، سن، میزان مصرف نمک، سابقه مصرف داروهای مؤثر بر فشار خون، سابقه بیماری‌های دیابت، قلبی، کلیوی و سایر بیماری‌ها و سابقه خانوادگی پرفشاری خون از طریق پرسش‌نامه تکمیل شده توسط والدین دانش‌آموزان، به دست آمد. قد هر دانش‌آموز در حالت کاملاً ایستاده بدون کفش و کلاه، برحسب سانتی‌متر و وزن هر دانش‌آموز بدون کفش و با حداقل لباس ممکن برحسب کیلوگرم، اندازه‌گیری شد. مقدار اعشاری به دست آمده برای وزن، به نزدیک‌ترین عدد صحیح قبل و یا بعد آن گرد شد. شاخص توده بدنی به صورت نسبت وزن برحسب کیلوگرم به مجذور قد برحسب متر مربع برای هر دانش‌آموز محاسبه شد. نبض نیز با استفاده از کورنومتر برای مدت ۱ دقیقه اندازه‌گیری شد.

فشار خون سیستولیک و دیاستولیک برحسب میلی‌متر جیوه، در وضعیت نشسته و پس از استراحت ۵ دقیقه‌ای فرد دانش‌آموز، ۲ بار و به فاصله ۵ دقیقه با دستگاه فشارسنج عقربه‌ای اندازه‌گیری شد. میانگین ۲ بار اندازه‌گیری، به عنوان فشار خون نهایی فرد در نظر گرفته شد. از مقادیر فشار خون سیستولیک و دیاستولیک برای تعیین مقدار ویژگی تشخیص توسط فرد خیره و دسته‌بندی هر دانش‌آموز به یکی از ۴ دسته فشار خون نرمال، پیش فشار خون بالا، فشار خون بالای مرحله ۱ و فشار خون بالای مرحله ۲ با توجه به دستورالعمل آکادمی پزشکی اطفال آمریکا [۲۶] (جدول شماره ۲) استفاده شد و کاربرد دیگری در این پژوهش نداشته است. براساس این دسته‌بندی، تعداد نمونه‌های متعلق به هر دسته در ردیف ۱۹ جدول شماره ۱ مشاهده می‌شود.

پیشنهاد کردند. دهقاندار و همکاران [۲۰] از شبکه‌ها عصبی مصنوعی برای تشخیص فشار خون بالا و چاقی در دانش‌آموزان ۷ تا ۱۸ ساله استفاده کردند. این روش، فشار خون سیستولیک را با دقت ۷۴ درصد و فشار خون دیاستولیک را با دقت ۷۹ درصد تشخیص داد.

برخی از مدل‌های موفق پیشنهادی برای تشخیص و پیش‌بینی فشار خون بالا از ترکیب نتایج خروجی چند روش یادگیری مختلف استفاده کرده‌اند. این رویکرد ترکیبی یک راهکار سودمند برای بهبود دقت دسته‌بندی است و مطالعات مختلف نشان داده‌اند ترکیب روش‌های یادگیری در مقایسه با هر یک از روش‌های یادگیری استفاده شده در ترکیب، دقت بیشتری داشته [۲۱] و نقش مؤثری در افزایش دقت تشخیص فشار خون بالا و عوامل مؤثر بر آن دارد [۲۲، ۲۳]. فیتزپاتی و همکاران [۲۳] روشی با ترکیب الگوریتم‌های یادگیری ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی چندلایه^{۱۲} و ماشین درخت تصمیم و یک مدل رگرسیون لجستیک برای پیش‌بینی فشار خون ارائه کردند. این روش برای تشخیص فشار خون در مردان دقتی برابر ۸۵/۷۳ درصد و در زنان دقتی برابر ۷۵/۷۸ درصد داشته است.

کانگائی و همکاران [۲۴] با استفاده از روش‌های درخت تصمیم، جنگل تصادفی و رگرسیون خطی یک مدل ترکیبی برای پیش‌بینی فشار خون بالا پیشنهاد کردند. در این مدل، هر یک از ۳ روش یادگیری به صورت مستقل عمل پیش‌بینی را انجام داده و نتیجه نهایی از طریق میانگین نتایج آن‌ها به دست می‌آید. یک مدل ترکیبی نیز توسط فنگ و همکاران [۲۵] پیشنهاد شد که نتایج خروجی ۲ روش یادگیری نزدیک‌ترین k همسایه و تقویت گرادیان سبک را برای پیش‌بینی فشار خون بالا براساس میانگین وزنی آن‌ها ترکیب می‌کند. ارزیابی آن‌ها نشان داد این مدل دقتی حدود ۸۶ درصد دارد.

باتوجه به ضرورت تشخیص زودهنگام یا پیش‌بینی مداوم فشار خون در دوران کودکی برای به حداقل رساندن خطر فشار خون بالا و عوارض آن، هدف این مقاله ارائه مدلی توسعه یافته با استفاده از روش‌های یادگیری ماشین برای تشخیص و پیش‌بینی فشار خون بالا در کودکان دبستانی و پیاده‌سازی مدل پیشنهادی در قالب یک برنامه کاربردی مبتنی بر تلفن همراه برای استفاده والدین کودکان است. در مدل پیشنهادی، عمل تشخیص و پیش‌بینی فشار خون بالا با ترکیب نتایج حاصل از ۳ روش یادگیری ماشین متداول با استفاده از تئوری ترکیب شواهد دمپستر شافر^{۱۳} انجام شد. اغلب روش‌های پیشنهادی در مطالعات مرتبط، نمونه ورودی را به یکی از ۲ دسته فشار خون نرمال و فشار خون بالا دسته‌بندی می‌کنند. در حالی که در مدل ارائه شده در این مقاله، با توجه به دستورالعمل آکادمی پزشکی اطفال آمریکا

12. Multilayer Perceptron (MLP)

13. Dempster-Shafer

جدول ۱. ویژگی‌های جمع‌آوری‌شده مربوط به کودکان دبستانی در مجموعه داده‌ها

ردیف	عنوان ویژگی	توضیحات
۱	جنسیت	♂: پسر، ♀: دختر
۲	سن	به سال، بین ۷ تا ۱۳
۳	قد	برحسب سانتی‌متر
۴	وزن	برحسب کیلوگرم
۵	شاخص توده بدنی	برحسب کیلوگرم بر مترمربع تا ۲ رقم اعشار
۶	نبض	در مدت ۱ دقیقه به عدد صحیح
۷	میزان مصرف نمک	♂: کم نمک، ♀: معمولی، ۲: پر نمک
۸	سابقه مصرف داروهای مؤثر بر فشار خون	♂: دارد، ♀: ندارد
۹	سابقه بیماری دیابت	♂: دارد، ♀: ندارد
۱۰	سابقه بیماری قلبی	♂: دارد، ♀: ندارد
۱۱	سابقه بیماری کلیوی	♂: دارد، ♀: ندارد
۱۲	سابقه سایر بیماری‌ها	♂: دارد، ♀: ندارد
۱۳	سابقه پرفشاری والدین	♂: هیچ‌کدام، ♀: پدر یا مادر، ۲: هر دو
۱۴	سابقه پرفشاری حداقل ۱ برادر/خواهر	♂: دارد، ♀: ندارد
۱۵	سابقه پرفشاری حداقل ۱ پدربزرگ/مادربزرگ	♂: دارد، ♀: ندارد
۱۶	سابقه پرفشاری حداقل ۱ عمو / عمه/دایی/خاله	♂: دارد، ♀: ندارد
۱۷	فشار خون سیستولیک	برحسب میلی‌متر جیوه
۱۸	فشار خون دیاستولیک	برحسب میلی‌متر جیوه
		♂: نرمال (۱۰۶۱ نمونه)
۱۹	تشخیص	۱: پیش فشار خون بالا (۶۲ نمونه) ۲: فشار خون بالای مرحله ۱ (۱۲۱ نمونه) ۳: فشار خون بالای مرحله ۲ (۴۳ نمونه)

جدول ۲. دسته‌بندی فشار خون کودکان برحسب فشار سیستولیک و دیاستولیک [۲۶]

دسته فشار خون	فشار خون سیستولیک (میلی‌متر جیوه)	و/یا	فشار خون دیاستولیک (میلی‌متر)
فشار خون نرمال	کمتر از ۱۲۰	و	کمتر از ۸۰
پیش فشار خون بالا	۱۲۰ تا ۱۲۹	و	کمتر از ۸۰
فشار خون بالای مرحله ۱	۱۳۰ تا ۱۳۹	یا	۸۰ تا ۸۹
فشار خون بالای مرحله ۲	۱۴۰ به بالا	یا	۹۰ به بالا

یادگیری را به‌عنوان شواهد در نظر گرفته و با روی هم‌گذاری آن‌ها، یک تابع باور تولید می‌کند که براساس آن، پیش‌بینی نهایی انجام می‌شود. در مدل پیشنهادی، ۴ دسته فشار خون نرمال، پیش‌فشار خون بالا، فشار خون بالای مرحله ۱ و فشار خون بالای مرحله ۲ به‌عنوان چارچوب مشاهدات در نظر گرفته شدند. خروجی روش‌های یادگیری به‌عنوان شواهد با هم ترکیب شده و براساس مقادیر باور حاصل‌شده، دسته با بزرگ‌ترین مقدار باور به‌عنوان دسته نمونه ورودی تعیین می‌شود. در صورت وجود عدم قطعیت برای پیش‌بینی فشار خون در نمونه ورودی، این نمونه به هیچ دسته‌ای تعلق نمی‌یابد. روش ترکیبی با زبان برنامه‌نویسی پایتون پیاده‌سازی شد.

برای ارزیابی کارایی مدل ارائه‌شده همانند اغلب مطالعات مشابه [۱۴، ۱۵، ۱۷، ۱۸، ۲۳] از روش اعتبارسنجی متقابل ۱۰ تکه برابر^{۱۷} استفاده شده است. معیارهای ارزیابی شامل دقت^{۱۸}، حساسیت^{۱۹} و ویژگی^{۲۰} بوده که به‌صورت فرمول شماره ۱ محاسبه می‌شوند.

$$1. (1) Accuracy = \frac{\sum_{i=1}^m \frac{TP_i + TN_i}{TP_i + FN_i + FP_i + TN_i}}{m}$$

$$(2) Sensitivity_{macro} = \frac{\sum_{i=1}^m \frac{TP_i}{TP_i + FN_i}}{m}$$

$$(3) Specificity_{macro} = \frac{\sum_{i=1}^m \frac{TN_i}{TN_i + FP_i}}{m}$$

در این روابط، m بیانگر تعداد دسته‌ها می‌باشد. TP_i (True Positive) تعداد نمونه‌های متعلق به دسته i است که درست تشخیص و دسته‌بندی شده‌اند. TN_i (True Negative) تعداد نمونه‌های متعلق به سایر دسته‌ها است که در دسته i دسته‌بندی نشده‌اند. FP_i (False Positive) تعداد نمونه‌هایی است که به اشتباه در دسته i دسته‌بندی شده‌اند. FN_i (False Negative) نیز تعداد نمونه‌های متعلق به دسته i است که اشتباهی در دسته دیگری دسته‌بندی شده‌اند.

مدل ارائه‌شده در قالب یک برنامه کاربردی اندرویدی قابل استفاده بر روی گوشی تلفن همراه، با استفاده از چارچوب ساخت نرم‌افزار کیوی (Kivy) و زبان برنامه‌نویسی پایتون پیاده‌سازی شد. در این برنامه کاربردی، کاربر اطلاعات درخواست‌شده را وارد کرده و سپس با کلیک بر روی مشاهده نتیجه، نتیجه پیش‌بینی را در یکی از دسته‌های نرمال، پیش‌فشار خون بالا، فشار خون بالای مرحله ۱ و فشار خون بالای مرحله ۲ مشاهده می‌کند.

کیفیت داده‌ها و آماده‌سازی آن‌ها نقش مهمی در افزایش کارایی مدل یادگیری دارند [۱۳]. بنابراین پیش‌پردازش داده‌های جمع‌آوری‌شده به‌عنوان اولین گام در مدل پیشنهادی مورد توجه قرار گرفته است. در این مرحله، برای جانشینی مقادیر نامشخص از روش میانه/مد^{۱۴} [۲۷] استفاده شد. براین اساس، در اطلاعات جمع‌آوری‌شده مربوط به ۵۸ دانش‌آموز، مقدار ویژگی میزان مصرف نمک نامشخص بود که مقدار «مصرف طبیعی» که بیشترین تکرار را در بین مقادیر این ویژگی در مجموعه داده دارد، برای آن‌ها منظور شد. مجموعه داده جمع‌آوری‌شده نامتوازن است. به‌طوری‌که تعداد نمونه‌های دارای فشار خون نرمال نسبت به سایر نمونه‌ها بسیار بیشتر هستند. مسئله نامتوازن بودن داده‌ها در اکثر داده‌های پزشکی وجود دارد و معمولاً باعث می‌شود دقت مدل یادگیری تحت تأثیر قرار گرفته و نمونه‌های متعلق به دسته اقلیت به‌عنوان نمونه‌های دسته اکثریت دسته‌بندی شوند [۲۳، ۲۸]. برای غلبه بر این مشکل و متوازن‌سازی داده‌ها در مدل پیشنهادی از روش معروف SMOTE^{۱۵} استفاده شد. در این روش، برای دسته‌های با تعداد نمونه‌های کمتر، نمونه‌های جدیدی در همسایگی نمونه‌های متعلق به آن دسته‌ها تولید شده و در نتیجه بین تعداد نمونه‌های متعلق به هر یک از دسته‌ها، توازن ایجاد می‌شود. با متوازن‌سازی داده‌های جمع‌آوری‌شده، تعداد نمونه‌های دسته‌های پیش‌فشار خون بالا، فشار خون مرحله ۱ و فشار خون مرحله ۲ به ترتیب به ۱۰۵۴، ۱۰۶۴ و ۱۰۳۲ نمونه افزایش یافت. پس از متوازن‌سازی داده‌ها، با استفاده از روش نرمال‌سازی متداول حداقل حداکثر، مقادیر همه ویژگی‌ها به مقادیری در بازه ۰-۱ تبدیل شدند.

پس از پیش‌پردازش داده‌ها، ساخت و یادگیری مدل انجام شد. در مدل پیشنهادی به‌منظور افزایش دقت در تشخیص و پیش‌بینی فشار خون بالا از رویکرد ترکیبی استفاده شد. ابتدا ۳ روش یادگیری ماشین متداول استفاده‌شده در تشخیص و پیش‌بینی فشار خون بالا [۲، ۴، ۱۲]، شامل شبکه‌های عصبی مصنوعی چندلایه، ماشین بردار پشتیبان و جنگل تصادفی، به‌صورت مجزا روی مجموعه داده‌ها اعمال و عمل پیش‌بینی انجام شد. بدین منظور از ماژول‌های نرم‌افزار داده‌کاوی Weka نسخه ۳/۷/۸ با پارامترهای پیش‌فرض استفاده شد. سپس نتایج حاصل از ۴ روش یادگیری مذکور با استفاده از تئوری ترکیب شواهد دمپستر شافر جهت پیش‌بینی نهایی با هم ترکیب شدند. ویژگی‌های بازیابی صریح عدم قطعیت و قاعده ترکیب شواهد در این تئوری باعث استفاده از آن در مدل پیشنهادی شده است. در تئوری ترکیب شواهد دمپستر شافر، باور^{۱۶} مقداری است که برای بیان قطعیت یک گزاره یا رویداد به کار می‌رود. قاعده ترکیب شواهد در این تئوری، ۲ بدنه شواهد مستقل تعریف‌شده در یک چارچوب مشاهدات را با هم ترکیب کرده و به ۱ بدنه شواهد تبدیل می‌کند [۲۱]. این تئوری، نتایج خروجی روش‌های

17. 10-fold cross validation

18. Accuracy

19. Sensitivity

20. Specificity

14. Mean / Mode

15. Synthetic Minority Over-sampling Technique

16. Belief

جدول ۳. کارایی مدل پیشنهادی و روش‌های یادگیری شرکت‌کننده در ترکیب (درصد)

روش	دقت	حساسیت	ویژگی
شبکه عصبی پرسپترون چندلایه	۸۴/۹۲	۶۹/۸۹	۸۹/۹۵
ماشین بردار پشتیبان	۷۵/۷۱	۵۱/۴۴	۸۳/۸۳
جنگل تصادفی	۸۶/۳۸	۷۲/۷۷	۹۰/۹۲
مدل پیشنهادی	۹۱/۷۴	۸۳/۵	۹۴/۴۹

استفاده از روش‌های یادگیری ماشین ارائه شد. مدل پیشنهادی در قالب یک برنامه کاربردی قابل استفاده بر روی گوشی تلفن همراه پیاده‌سازی شد تا والدین بتوانند نظارت و کنترل مداوم بر فشار خون کودکان خود داشته باشند.

با هدف افزایش دقت در مدل ارائه شده، ۳ روش یادگیری مشهور در تشخیص و پیش‌بینی فشار خون بالا شامل شبکه‌های عصبی مصنوعی چندلایه، ماشین بردار پشتیبان و جنگل تصادفی با استفاده از تئوری ترکیب شواهد دمستر شافر با هم ترکیب شدند. مقایسه نتایج به دست آمده در جدول شماره ۳ برای مدل پیشنهادی نسبت به هر یک از روش‌های یادگیری مشارکت کننده در ساخت مدل نشان می‌دهد مدل پیشنهادی در هر سه معیار دقت، حساسیت و ویژگی به ترتیب با مقادیر ۹۱/۷۴ درصد، ۸۳/۵ درصد و ۹۴/۴۹ درصد برتری دارد. اختلاف این مقادیر در مدل پیشنهادی نسبت به ۳ روش شبکه‌های عصبی مصنوعی چندلایه، ماشین بردار پشتیبان و جنگل تصادفی قابل توجه است. این نتیجه، بار دیگر تصدیق کننده این ادعاست که ترکیب روش‌های یادگیری می‌تواند با غلبه بر محدودیت هر یک از روش‌های شرکت کننده در ترکیب به بهبود دقت پیش‌بینی و تشخیص بیماری کمک کنند. مقایسه کارایی ۳ روش شبکه‌های عصبی مصنوعی چندلایه، ماشین بردار پشتیبان و جنگل تصادفی با هم نشان می‌دهد که روش جنگل تصادفی نسبت به ۲ روش دیگر، عملکرد بهتری داشته و روش ماشین بردار پشتیبان روی مجموعه داده مورد مطالعه کمترین کارایی را در تشخیص و پیش‌بینی فشار خون داشته است.

بررسی نتایج به دست آمده برای مدل پیشنهادی در مقایسه با سایر روش‌های جدید دیگر در جدول شماره ۴ نیز برتری مدل پیشنهادی در همه معیارها را نشان می‌دهد. مدل پیشنهادی و روش ارائه شده توسط آمبیکا و همکاران [۱۳] فشار خون نمونه ورودی را به ۴ دسته فشار خون نرمال، پیش فشار خون، فشار خون بالای مرحله ۱ و فشار خون بالای مرحله ۲ تقسیم می‌کنند. سایر روش‌های مقایسه شده، نمونه‌ها را به یکی از ۲ دسته نرمال و فشار خون بالا دسته‌بندی می‌کنند. بعد از مدل پیشنهادی، روش ارائه شده توسط فنگ و همکاران [۲۵] که پیش‌بینی را بر اساس ترکیب نتایج خروجی ۲ روش یادگیری نزدیک‌ترین k همسایه و تقویت گرادیان سبک بر روی داده‌های متوازن انجام می‌دهد،

یافته‌ها

تعداد نمونه‌های دسته‌های پیش فشار خون بالا، فشار خون مرحله ۱ و فشار خون مرحله ۲ پس از متوازن سازی در مدل پیشنهادی به ترتیب از ۶۲، ۱۲۱ و ۴۳ به ۱۰۵۴، ۱۰۶۴ و ۱۰۳۲ نمونه افزایش یافت.

جدول شماره ۳ نتایج به دست آمده برای هر یک از معیارهای دقت، حساسیت و ویژگی در مدل پیشنهادی و همچنین روش‌های یادگیری شرکت کننده در ترکیب شامل شبکه عصبی پرسپترون چندلایه، ماشین بردار پشتیبان و جنگل تصادفی را نشان می‌دهد. مقادیر پررنگ در این جدول بیانگر بیشترین مقدار در هر معیار هستند. این یافته‌ها نشان می‌دهند مقادیر به دست آمده از هر سه معیار مورد مقایسه در مدل پیشنهادی از ۳ روش یادگیری استفاده شده در ترکیب، به طور چشم‌گیری بیشتر هستند.

مقایسه کارایی مدل پیشنهادی با روش‌های جدید دیگر برای تشخیص و پیش‌بینی فشار خون بالا روی مجموعه داده مورد مطالعه نیز در جدول شماره ۴ مشاهده می‌شود. برای مدل پیشنهادی در هر سه معیار دقت، حساسیت و ویژگی، مقادیر بیشتری نسبت به روش‌های مورد مقایسه به دست آمده است که در جدول با مقادیر پررنگ نشان داده شده است.

به منظور بررسی معنادار بودن میزان بهبود دقت در مدل پیشنهادی از نظر آماری نسبت به روش‌های مقایسه شده، از آزمون آماری تی زوجی با سطح معنی داری ۰/۰۵ استفاده شد. این آزمون بین مقادیر دقت مدل پیشنهادی و هر یک از روش‌های دیگر به صورت جداگانه انجام شد. مقادیر P به دست آمده در جدول شماره ۵ مشاهده می‌شود. این نتایج نشان می‌دهند مقادیر P به دست آمده برای همه روش‌ها کمتر از ۰/۰۵ هستند. تصویر شماره ۱ بخشی از رابط کاربری برنامه پیاده‌سازی شده بر مبنای مدل پیشنهادی را نشان می‌دهد.

بحث

باتوجه به اهمیت تشخیص و پیش‌بینی زودهنگام فشار خون بالا در کودکان، در این پژوهش یک مدل توسعه یافته برای پیش‌بینی و تشخیص فشار خون بالا در کودکان دبستانی با



تصویر ۱. بخشی از رابط کاربری برنامه کاربردی مبتنی بر تلفن همراه

جدول ۴. کارایی مدل پیشنهادی در مقایسه با سایر روش‌ها (درصد)

روش	دقت	حساسیت	ویژگی
آمبیکا و همکاران [۱۳] ۲۰۲۰	۸۶/۶۴	۷۳/۵۲	۹۱/۱
ژائو و همکاران [۱۷] ۲۰۲۱	۸۷/۱۱	۷۴/۲۲	۹۱/۴
چای و همکاران [۱۹] ۲۰۲۱	۸۵/۱۵	۷۰/۵	۹۰/۱۱
نیتريانی و همکاران [۲۳] ۲۰۱۹	۸۷/۶۶	۷۵/۳۴	۹۱/۷۸
فنگ و همکاران [۲۵] ۲۰۲۱	۸۹/۴۴	۷۸/۸۸	۹۲/۹۶
مدل پیشنهادی	۹۱/۷۴	۸۳/۵	۹۴/۴۹

جدول ۵. مقادیر P آزمون تی بین دقت مدل پیشنهادی و روش‌های مقایسه‌شده

روش	P
شبکه عصبی پرسپترون چندلایه	۰/۰۰۱۸
ماشین بردار پشتیبان	۰/۰۰۶۴
جنگل تصادفی	۰/۰۰۰۷
آمبیکا و همکاران [۱۳] ۲۰۲۰	۰/۰۰۳۹
ژائو و همکاران [۱۷] ۲۰۲۱	۰
چای و همکاران [۱۹] ۲۰۲۱	۰/۰۱۰۴
نیتريانی و همکاران [۲۳] ۲۰۱۹	۰/۰۰۲۱
فنگ و همکاران [۲۵] ۲۰۲۱	۰/۰۰۷۹

یک ابزار ارزشمند برای تشخیص فشار خون بالا در کودکان، اولین گام در مراقبت از فشار خون بالا باشد و از عوارض و هزینه‌های ناشی از این بیماری بکاهد. والدین با استفاده از این برنامه کاربردی به‌عنوان یک سامانه هشدار اولیه، می‌توانند از وضعیت فشار خون کودکان خود مطلع شده و در صورت وجود خطر برای بررسی دقیق‌تر به پزشک مراجعه کنند. این برنامه کاربردی، علاوه بر مبنایی برای پیشگیری و درمان به‌موقع و مناسب، می‌تواند به تصمیم‌گیری در تخصیص منابع بهداشتی و سیاست‌گذاری‌های لازم نیز کمک کند. باتوجه به مطالعات انجام‌شده، در هیچ‌یک از پژوهش‌های انجام‌شده تاکنون، برنامه کاربردی مشابهی طراحی و پیاده‌سازی نشده است.

اگرچه رویکرد ترکیبی پیشنهادشده از دقت بهتری در تشخیص و پیش‌بینی فشار خون بالا برخوردار است، ولی استفاده موازی از چند روش یادگیری ماشین و ترکیب نتایج آن‌ها، باعث افزایش زمان اجرایی و پیچیدگی محاسبات می‌شود. هرچند در کاربردهای نظیر پزشکی که با حیات انسان‌ها سروکار دارند، دقت و اعتماد در اولویت است، توصیه می‌شود در پژوهش‌های آینده، ارائه راهکارهایی به‌منظور کاهش زمان اجرایی و پیچیدگی محاسبات در مدل ترکیبی مد نظر باشد. همچنین باتوجه به اینکه مدل پیشنهادی فقط بر روی مجموعه داده‌های کودکان دبستانی یک منطقه جغرافیایی مورد بررسی قرار گرفته است، در پژوهش‌های آینده، تعمیم مدل ارائه‌شده و ارزیابی آن بر روی مجموعه داده‌های مربوط به کودکان سایر نواحی و مناطق مفید خواهد بود. ارزیابی برنامه کاربردی پیاده‌سازی‌شده و همچنین توسعه آن به‌عنوان یک سامانه پایش از راه دور فشار خون، به‌طوری‌که هشدارها و اعلان‌های مناسب را به‌صورت خودکار به پزشک و یا مرکز درمانی ثبت‌شده در برنامه، ارسال کند تا خدمات مراقبت‌های بهداشتی و سلامت، بلافاصله و به‌موقع به کودکان ارائه شود نیز مورد توجه است.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

این مطالعه دارای تأییدیه اخلاقی به شماره IR.MUMS. REC.1401.038 از دانشگاه علوم پزشکی مشهد است.

حامی مالی

این مقاله از طرف هیچ گونه نهاد یا مؤسسه‌ای حمایت مالی نشده و تمام منابع مالی آن از طرف نویسندگان تأمین شده است.

کارایی بهتری دارد. کارایی روش فیتربانی و همکاران [۲۳] که مبتنی بر ترکیب نتایج خروجی ۳ روش یادگیری شبکه‌های عصبی مصنوعی چندلایه، ماشین درخت تصمیم و ماشین بردار پشتیبان به کمک رگرسیون لجستیک است و کارایی روش ژائو و همکاران [۱۷] که با استفاده از روش جنگل تصادفی عمل پیش‌بینی را انجام می‌دهد، به ترتیب پس از روش فنگ و همکاران [۲۵] قرار دارند. روش آمبیکا و همکاران [۱۳] که توسعه‌یافته روش ماشین بردار پشتیبان است، در مقایسه با نتایج به‌دست‌آمده برای روش ماشین بردار پشتیبان در جدول شماره ۳ عملکرد بسیار خوبی داشته است. با وجود این، این روش در مقایسه با روش‌های جدید مقایسه‌شده در جدول شماره ۴، به‌جز روش چای و همکاران [۱۹]، عملکرد پایین‌تری داشته است. روش چای و همکاران [۱۹] به‌عنوان مدلی توسعه‌یافته از روش شبکه‌های عصبی مصنوعی چندلایه نسبت به سایر روش‌های جدول شماره ۴ عملکرد پایین‌تری دارد. مقایسه مقادیر ۳ معیار دقت، حساسیت و ویژگی برای این روش در جدول شماره ۴ با مقادیر به‌دست‌آمده این معیارها برای روش شبکه‌های عصبی مصنوعی چندلایه در جدول شماره ۳ نشان می‌دهند که روش چای و همکاران [۱۹] به‌عنوان مدلی توسعه‌یافته از شبکه‌های عصبی مصنوعی چندلایه، با اختلاف ناچیزی از شبکه‌های عصبی مصنوعی چندلایه برتری دارد. عملکرد نه چندان مطلوب روش چای و همکاران [۱۹] می‌تواند به این دلیل باشد که این روش عمل پیش‌بینی را بر روی داده‌های نامتوازن انجام می‌دهد.

نتیجه‌گیری

باتوجه به نتایج حاصل از آزمون تی در جدول شماره ۵، از آنجایی که مقادیر P به‌دست‌آمده کمتر از ۰/۰۵ هستند، می‌توان نتیجه گرفت اختلاف دقت مدل پیشنهادی در مقایسه با روش‌های یادگیری استفاده‌شده در ترکیب و همچنین سایر روش‌های مورد مقایسه، از نظر آماری معنادار است. به‌طور خلاصه نتایج بیانگر این هستند که مدل ترکیبی پیشنهادی، پیش‌بینی و تشخیص فشار خون بالا در کودکان را بهتر انجام داده و به بهبود دقت و کاهش میزان خطا کمک می‌کند. در حالت معمولی اندازه‌گیری فشار خون به تجهیزات نیاز دارد که همیشه به‌راحتی در دسترس نیست و ممکن است برای برخی از مردم نیز عملی نباشد. برنامه کاربردی پیاده‌سازی‌شده بر مبنای مدل پیشنهادی با قابلیت استفاده بر روی گوشی معمولی تلفن همراه، در تشخیص زودهنگام فشار خون بالا در کودکان مفید بوده و به دلیل عدم نیاز به دسترسی به داده‌های بالینی و ژنتیکی و همچنین سهولت استفاده از آن می‌تواند توسط افراد معمولی، از جمله والدین استفاده شود. این برنامه کاربردی با کاربری آسان، با دریافت اطلاعات اولیه جمعیت‌شناختی، اطلاعات سبک زندگی و سوابق بیماری خانوادگی و همچنین برخی داده‌های معمولی که به‌راحتی در کودکان قابل اندازه‌گیری هستند، می‌تواند به‌عنوان

مشارکت نویسندگان

مفهوم‌سازی، روش‌شناسی، اعتبارسنجی، تحلیل، تحقیق و بررسی: همه نویسندگان، منابع، نگارش پیش‌نویس، ویراستاری و نهایی‌سازی نوشته: حمیدرضا طهماسبی

تعارض منافع

بنابر اظهار نویسندگان این مطالعه تعارض منافع ندارد.



References

- [1] Nematollahi MA, Jahangiri S, Asadollahi A, Salimi M, Dehghan A, Mashayekh M, et al. Body composition predicts hypertension using machine learning methods: A cohort study. *Sci Rep.* 2023; 13(1):6885. [DOI:10.1038/s41598-023-34127-6] [PMID]
- [2] Chowdhury MZI, Naeem I, Quan H, Leung AA, Sikdar KC, O'Beirne M, et al. Prediction of hypertension using traditional regression and machine learning models: A systematic review and meta-analysis. *Plos One.* 2022; 17(4):e0266334. [DOI:10.1371/journal.pone.0266334] [PMID]
- [3] Tozo TAA, Gisi ML, Brand C, Moreira CMM, Pereira BO, Leite N. Family history of arterial hypertension and central adiposity: Impact on blood pressure in schoolchildren. *BMC Pediatr.* 2022; 22(1):497. [DOI:10.1186/s12887-022-03551-4] [PMID]
- [4] Martinez-Ríos E, Montesinos L, Alfaro-Ponce M, Pecchia L. A review of machine learning in hypertension detection and blood pressure estimation based on clinical and physiological data. *Biomed Signal Process Control.* 2021; 68:102813. [DOI:10.1016/j.bspc.2021.102813]
- [5] Hamoen M, de Kroon MLA, Welten M, Raat H, Twisk JWR, Heymans MW, et al. Childhood prediction models for hypertension later in life: A systematic review. *J Hypertens.* 2019; 37(5):865-77. [DOI:10.1097/HJH.0000000000001970] [PMID]
- [6] Hardy ST, Urbina EM. Blood pressure in childhood and adolescence. *Am J Hypertens.* 2021; 34(3):242-9. [DOI:10.1093/ajh/hpab004]
- [7] Song P, Zhang Y, Yu J, Zha M, Zhu Y, Rahimi K, et al. Global prevalence of hypertension in children: A systematic review and meta-analysis. *JAMA Pediatr.* 2019; 173(12):1154-63. [DOI:10.1001/jamapediatrics.2019.3310] [PMID]
- [8] Akbari M, Moosazadeh M, Ghahramani S, Tabrizi R, Kollahdoz F, Asemi Z, et al. High prevalence of hypertension among Iranian children and adolescents: A systematic review and meta-analysis. *J Hypertens.* 2017; 35(6):1155-63. [DOI:10.1097/HJH.0000000000001261] [PMID]
- [9] Frey L, Menon C, Elgendi M. Blood pressure measurement using only a smartphone. *Npj Digit Med.* 2022; 5(1):86. [DOI:10.1038/s41746-022-00629-2] [PMID]
- [10] Visco V, Izzo C, Mancusi C, Rispoli A, Tedeschi M, Virtuoso N, et al. Artificial intelligence in hypertension management: An ace up your sleeve. *J Cardiovasc Dev Dis.* 2023; 10(2):74. [DOI:10.3390/jcdd10020074] [PMID]
- [11] Cai A, Zhu Y, Clarkson SA, Feng Y. The use of machine learning for the care of hypertension and heart failure. *JACC Asia.* 2021; 1(2):162-72. [DOI:10.1016/j.jacasi.2021.07.005] [PMID]
- [12] Silva GFS, Fagundes TP, Teixeira BC, Chiavegatto Filho ADP. Machine Learning for hypertension prediction: A systematic review. *Curr Hypertens Rep.* 2022; 24(11):523-33. [DOI:10.1007/s11906-022-01212-6] [PMID]
- [13] Ambika M, Raghuraman G, SaiRamesh L. Enhanced decision support system to predict and prevent hypertension using computational intelligence techniques. *Soft Comput.* 2020; 24(17):13293-304. [Link]
- [14] Islam SMS, Talukder A, Awal MA, Siddiqui MMU, Ahamad MM, Ahammed B, et al. Machine learning approaches for predicting hypertension and its associated factors using population-level data from three South Asian Countries. *Front Cardiovasc Med.* 2022; 9:839379. [DOI:10.3389/fcvm.2022.839379] [PMID]
- [15] Oanh TT, Tung NT. Predicting hypertension based on machine learning methods: A case study in Northwest Vietnam. *Mobile Netw Appl.* 2022; 27:2013–23. [DOI:10.1007/s11036-022-01984-w]
- [16] AlKaabi LA, Ahmed LS, Al Attiyah MF, Abdel-Rahman ME. Predicting hypertension using machine learning: Findings from Qatar Biobank Study. *Plos One.* 2020; 15(10):e0240370. [DOI:10.1371/journal.pone.0240370] [PMID]
- [17] Zhao H, Zhang X, Xu Y, Gao L, Ma Z, Sun Y, et al. Predicting the risk of hypertension based on several easy-to-collect risk factors: A machine learning method. *Front Public Health.* 2021; 9:619429. [DOI:10.3389/fpubh.2021.619429] [PMID]
- [18] Chai SS, Goh KL, Cheah WL, Chang YHR, Ng GW. Hypertension prediction in adolescents using anthropometric measurements: Do machine learning models perform equally well? *Appl Sci.* 2022; 12(3):1600. [DOI:10.3390/app12031600]
- [19] Chai SS, Cheah WL, Goh KL, Chang YHR, Sim KY, Chin KO. A multilayer perceptron neural network model to classify hypertension in adolescents using anthropometric measurements: A cross-sectional study in Sarawak, Malaysia. *Comput Math Methods Med.* 2021; 2021:2794888. [DOI:10.1155/2021/2794888] [PMID]
- [20] Dehghandar M, Hassani Bafrani A, Dadkhah M, Qorbani M, Kelishadi R. [Diagnosis of obesity and hypertension in Isfahani students using artificial neural network (Persian)]. *J Health Biomed Inf.* 2021; 8 (1):12-23. [Link]
- [21] Tahmasbi H, Jalali M, Shakeri H. [An expert system for heart disease diagnosis based on evidence combination in data mining (Persian)]. *J Health Biomed Inform.* 2017; 3(4):251-8. [Link]
- [22] Ren L, Zhang H, Seklouli AS, Wang T, Bouras A. Stacking-based multi-objective ensemble framework for prediction of hypertension. *Expert Syst Appl.* 2023; 215:119351. [DOI:10.1016/j.eswa.2022.119351]
- [23] Fitriyani NL, Syafrudin M, Alfian G, Rhee J. Development of disease prediction model based on ensemble learning approach for diabetes and hypertension. *IEEE Access.* 2019; 7:144777-89. [DOI:10.1109/ACCESS.2019.2945129]
- [24] Kanegae H, Suzuki K, Fukatani K, Ito T, Harada N, Kario K. Highly precise risk prediction model for new-onset hypertension using artificial intelligence techniques. *J Clin Hypertens.* 2020; 22(3):445-50. [DOI:10.1111/jch.13759] [PMID]
- [25] Fang M, Chen Y, Xue R, Wang H, Chakraborty N, Su T, et al. A hybrid machine learning approach for hypertension risk prediction. *Neural Comput Appl.* 2021; 35:14487–97. [DOI:10.1007/s00521-021-06060-0]
- [26] Rao G. Diagnosis, epidemiology, and management of hypertension in children. *Pediatrics.* 2016; 138(2):e20153616. [DOI:10.1542/peds.2015-3616] [PMID]
- [27] Tahmasbi H, Amoozgar M, Adine H. [Replacement of missing values and its effect on the classification accuracy in medical data mining (Persian)]. *J Health Biomed Inf.* 2015; 2(1):24-32. [Link]
- [28] Wang YC, Cheng CH. A multiple combined method for rebalancing medical data with class imbalances. *Comput Biol Med.* 2021; 134:104527. [DOI:10.1016/j.combiomed.2021.104527] [PMID]

This Page Intentionally Left Blank