AUMJ Journal Alborz University of Medical Sciences
Alborz University of Medical Sciences Journal, Winter 2026, Vol. 15, No 1: 1- 16

Evaluation and comparison of machine learning models in predicting spirometric indices based on individual characteristics in Fasa county

Sareh Rafatmagham[1]
Neda Jafari [*2]
Azizollah Dehghan[3]
Mohammad Roshanzamir[4]

1- Department of Internal Medicine, School of Medicine, Fasa University of Medical Sciences, Fasa, Iran
2- Department of Internal Medicine, School of Medicine, Fasa University of Medical Sciences, Fasa, Iran ,
3- School of Health, Fasa University of Medical Sciences, Fasa, Iran
4- Department of Computer Engineering, School of Engineering, Fasa University, Fasa, Iran

* Corresponding Author:
nedajafari.med@gmail.com

Abstract

Introduction: Chronic respiratory diseases impose a substantial burden on public health. Accurate prediction of spirometric indices based on individual characteristics can enhance the diagnosis and management of these conditions. This study aimed to evaluate and compare the performance of machine learning models in predicting spirometric indices using individual features in the population of Fasa County.

Methods: This cross-sectional observational study was conducted on 5,450 individuals who attended pulmonary clinics between spring 2024 and autumn 2025. After excluding incomplete records, 4,615 eligible participants were included in the final analysis. Individual characteristics included age, sex, height, weight, and smoking status. Spirometric indices comprised forced vital capacity (FVC), forced expiratory volume in one second (FEV1), FEV1/FVC ratio, forced expiratory flow at 25–75% (FEF25–75), and peak expiratory flow (PEF). Five machine learning algorithms—Linear Regression, K-Nearest Neighbors, Support Vector Machine, Random Forest, and Gradient Boosting—were evaluated using mean squared error (MSE), root mean squared error (RMSE), and the coefficient of determination (R^2). The relative importance of individual features was assessed using the feature importance output of the Gradient Boosting model. All ethical principles were observed, and the study was approved under ethics code IR.FUMS.REC.1404.174.

Results: The Gradient Boosting model demonstrated the lowest error rates and the highest R^2 values across all spirometric indices, indicating superior performance compared to the other models. Age, height, and weight were the most influential predictors, whereas sex and smoking status had relatively lower contributions to model performance.

Conclusion: The Gradient Boosting model effectively captured nonlinear relationships and complex interactions between individual characteristics and spirometric indices. These findings suggest that machine learning approaches can support the development of localized predictive models and improve the interpretation of spirometry results in native populations.

Keywords: Spirometry, Respiratory Function Tests, Machine Learning, Pulmonary Disease, Chronic, Cross-Sectional Studies

How to cite this article: Rafatmagham S, Jafari N, Dehghan A, Roshanzamir M. Evaluation and comparison of machine learning models in predicting spirometric indices based on individual characteristics in Fasa county. Alborz University Medical Journal 2026; 15 (1) : 1-16

.Copyright © 2026 The Authors. Published by Alborz University of Medical Sciences
This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (https://creativecommons.org/licenses/by-.nc/4.0/). Non-commercial uses of the work are permitted, provided the original work is properly cited

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

AUMJ Journal
Alborz University of Medical Sciences
نشریه دانشگاه علوم‌پزشکی البرز، زمستان ۱۴۰۴، دوره ۱۵، شماره ۱، صفحه‌های ۱۶-۱

ارزیابی و مقایسه عملکرد مدل های یادگیری ماشین در پیش بینی شاخص های اسپیرومتری مبتنی بر ویژگی های فردی در شهرستان فسا

ساره رفعت مقام[1]
ندا جعفری[2*]
عزیزالله دهقان[3]
محمد روشن‌ضمیر[4]

چکیده

مقدمه: بیماری‌های تنفسی مزمن بار بالایی بر سلامت جامعه دارد و پیش‌بینی دقیق شاخص‌های اسپیرومتری با استفاده از ویژگی‌های فردی می‌تواند در تشخیص و مدیریت این بیماری‌ها مؤثر باشد. هدف این مطالعه، ارزیابی و مقایسه عملکرد مدل‌های یادگیری ماشین در پیش‌بینی شاخص‌های اسپیرومتری بر اساس ویژگی‌های فردی در جمعیت شهرستان فسا است.

روش کار: این مطالعه مشاهده‌ای مقطعی از ۵۴۵۰ مراجعه‌کننده به مطب ریه در بازه بهار ۱۴۰۳ تا پاییز ۱۴۰۴، پس از حذف داده‌های ناقص، ۴۶۱۵ فرد واجد شرایط وارد تحلیل نهایی شد. ویژگی‌های فردی شامل سن، جنسیت، قد، وزن و وضعیت سیگاری بودن بود و شاخص‌های اسپیرومتری نیز شامل FVC، FEV1، FEV1/FVC، FEF25-75 و PEF بود. همچنین، پنج الگوریتم یادگیری ماشین شامل رگرسیون خطی، الگوریتم کی-نزدیک‌ترین همسایه، ماشین بردار پشتیبان، جنگل تصادفی و تقویت گرادیان بر اساس معیارهای RMSE، MSE و R^2 ارزیابی شدند. اهمیت نسبی ویژگی‌ها نیز با خروجی feature_importances مدل تقویت گرادیان تحلیل شد.

یافته‌ها: مدل تقویت گرادیان در تمامی شاخص‌های اسپیرومتری کمترین خطا و بیشترین ضریب تعیین را داشت و عملکرد برتری نسبت به سایر مدل‌ها نشان داد. سن، قد و وزن بیشترین تأثیر را بر پیش‌بینی شاخص‌ها داشت، درحالی‌که جنسیت و وضعیت سیگاری بودن تأثیر کمتری داشت.

نتیجه‌گیری: مدل تقویت گرادیان قادر است روابط غیرخطی و تعاملات پیچیده بین ویژگی‌های فردی و شاخص‌های اسپیرومتری را شناسایی کند. این مطالعه نشان می‌دهد که استفاده از یادگیری ماشین می‌تواند در ایجاد مدل‌های پیش‌بینی محلی و بهبود تفسیر نتایج اسپیرومتری در جمعیت‌های بومی مفید باشد.

واژه‌های کلیدی: یادگیری ماشین، شاخص‌های اسپیرومتری، ویژگی‌های فردی، شهرستان فسا.

۱. گروه داخلی، دانشکده پزشکی، دانشگاه علوم پزشکی فسا، فسا، ایران
۲.گروه داخلی، دانشکده پزشکی، دانشگاه علوم پزشکی فسا، فسا، ایران
۳. دانشکده بهداشت، دانشگاه علوم پزشکی فسا، فسا، ایران
۴. گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه فسا، فسا، ایران

* نویسنده مسئول:
nedajafari.med@gmail.com

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

مقدمه

بیماری‌های تنفسی مزمن از جمله آسم، «بیماری مزمن انسدادی ریه[1]» و فیبروز ریوی، بار قابل‌توجهی بر سیستم‌های بهداشتی و کیفیت زندگی افراد در سراسر جهان تحمیل می‌کند (۱). پایش، ارزیابی و تحلیل دقیق عملکرد ریه با استفاده از اسپیرومتری به‌عنوان یک تست استاندارد و غیرتهاجمی، نقش حیاتی در مدیریت این بیماری‌ها، پیشگیری از پیشرفت آن‌ها و بهبود پیامدهای بالینی دارد (۲). در این راستا اسپیرومتری ابزاری کلیدی در ارزیابی حجم‌ها و جریان‌های هوایی قابل‌اندازه‌گیری در طی مانورهای دم و بازدم اجباری به شمار می‌رود و شاخص‌های حاصل از آن اطلاعات ارزشمندی در مورد وضعیت عملکرد تنفسی فرد ارائه می‌دهد و مبنای مهمی برای پیش‌بینی و برآورد وضعیت عملکرد ریوی به شمار می‌آید (۳). اگرچه این روش قادر به اندازه‌گیری حجم‌های غیر قابل تخلیه مانند «حجم باقی‌مانده[2]» و «ظرفیت کل ریه[3]» نیست.

شناخت دقیق عوامل فردی مؤثر بر شاخص‌های اسپیرومتری مانند سن، جنسیت، قد، وزن و وضعیت استعمال دخانیات، می‌تواند دقت تفسیر یافته‌های این آزمون را افزایش دهد و به طراحی مداخلات پیشگیرانه و درمانی مؤثرتر کمک کند. این موضوع در جمعیت‌هایی که مقادیر مرجع بومی برای «معادلات پیش‌بینی[4]» در دسترس نیست، اهمیت بیشتری دارد، زیرا استفاده از معادلات و استانداردهای غیربومی می‌تواند منجر به «کلاسه‌بندی نادرست[5]» یا برآورد شدت بیماری شود.

مطالعه‌های متعدد نشان داده است که با افزایش سن، به دلیل تغییرات ساختاری در ریه‌ها و کاهش الاستیسیته بافت ریه و قفسه سینه، FVC[6] و FEV_1[7] به‌صورت تدریجی کاهش می‌یابد (٤ و ٥). این کاهش در عملکرد ریه یک فرایند فیزیولوژیک مرتبط با پیری است. همچنین به طور کلی، مردان به دلیل داشتن جثه بزرگ‌تر و حجم ریوی بیشتر، مقادیر مطلق بالاتری از FVC و FEV_1 را در مقایسه با زنان نشان می‌دهند (٦). قد نیز یکی از قوی‌ترین عوامل تعیین‌کننده حجم ریه‌ها است. افراد بلندقدتر به طور معمول ریه‌های بزرگ‌تری دارند و در نتیجه، مقادیر بالاتری از FVC و FEV_1 را نشان می‌دهند (۷). این موضوع به خوبی در معادلات پیش‌بینی نرمال برای شاخص‌های اسپیرومتری لحاظ شده است (۸). همچنین، چاقی و افزایش BMI می‌توانند با محدود کردن حرکت دیافراگم و قفسه سینه، منجر به کاهش حجم‌های ریوی مانند FVC و FEV_1 شود (۹). افزون بر آن، التهاب مزمن ناشی از چاقی ممکن است بر عملکرد راه‌های هوایی کوچک تأثیر گذاشته و منجر به کاهش FEF25-75[8] شود (۱۰). از سوی دیگر، استعمال دخانیات یک عامل مهم شناخته شده برای آسیب به ساختار و عملکرد ریه‌ها است. مواد شیمیایی موجود در دخانیات می‌تواند منجر به التهاب مزمن، تخریب بافت ریه (آمفیزم)، افزایش تولید مخاط و تنگی راه‌های هوایی شود که همگی به کاهش شاخص‌های اسپیرومتری منجر می‌شود (۱۱ و ۱۲). تأثیر سیگار بر FEF25-75، به دلیل حساسیت این شاخص به تغییر در راه‌های هوایی کوچک، قابل‌توجه است (۱۳). مطالعه‌های دیگری نیز نشان داده است که ویژگی‌های فردی مانند سن، جنسیت، قد و وزن به‌عنوان قوی‌ترین عوامل دموگرافیک، به‌گونه‌ای طبیعی بر مقادیر نرمال شاخص‌های اسپیرومتری تأثیر می‌گذارد (١٤). همچنین، عوامل محیطی و رفتاری مانند استعمال دخانیات به گونه مستقیم با کاهش عملکرد ریه و افزایش خطر ابتلا به بیماری‌های تنفسی مرتبط است (١٥).

درک دقیق چگونگی تعامل این عوامل فردی با شاخص‌های اسپیرومتری در یک جمعیت خاص می‌تواند به ایجاد مقادیر مرجع منطقه‌ای، شناسایی گروه‌های در معرض خطر و بهبود تفسیر نتایج اسپیرومتری کمک کند. اگرچه اذعان می‌شود که عوامل بالینی و محیطی متعددی می‌تواند بر شاخص‌های اسپیرومتری تأثیرگذار باشد، اما مطالعه‌های متعددی در سطح جهانی نیز از ویژگی‌های دموگرافیک به‌عنوان پیش‌بینی‌کننده‌های اصلی در مدل‌های اولیه استفاده کرده‌اند. هدف این پژوهش، خلق یک ابزار تشخیص کامل نیست، بلکه کشف قابلیت و کارایی یادگیری ماشین در تحلیل الگوهای موجود در داده‌های پایه‌ای و فراگیر است. باوجود این، پژوهش جامعی که به پیشبینی با طیف وسیعی از ویژگی‌های فردی و شاخص‌های اصلی اسپیرومتری با استفاده از روش‌های پیشرفته یادگیری ماشین در جمعیت شهرستان فسا پرداخته باشد، مشاهده نشد. شهرستان فسا با ویژگی‌های نیمه‌صنعتی خود، ترکیبی از مواجهه با آلاینده‌های کشاورزی و صنعتی سبک دارد که می‌تواند بر سلامت ریه تأثیرگذار باشد. از طرفی،

1 COPD
2 RV
3 TLC
4 Reference Equations
5 Misclassification
6 Forced Vital Capacity
7 Forced Expiratory Volume in 1 Second
8 Forced Expiratory Flow between 25% and 75% of FVC

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

الگوی مصرف دخانیات در فسا، شامل مصرف سیگار و قلیان و مواجهه با دود غیرمستقیم، ممکن است منجر به تغییرات متفاوت در عملکرد ریه نسبت به سایر مناطق شود.

روش‌های آماری سنتی مانند رگرسیون خطی، باوجود سادگی، در شناسایی تعاملات پیچیده و اثرات غیرخطی محدودیت دارد. در نتیجه، روابط بین ویژگی‌های فردی و شاخص‌های اسپیرومتری می‌تواند ماهیتی غیرخطی و چندبعدی داشته باشد. در مقابل، الگوریتم‌های یادگیری ماشین قادر است بدون اتکا به این فرضیات، الگوهای پنهان و تعامل‌های چندمتغیره را شناسایی کند و پیش‌بینی‌هایی با دقت بالاتر ارائه دهد؛ بنابراین، پژوهش حاضر به دنبال ارزیابی دقیق قابلیت یادگیری ماشین در مدل‌سازی این روابط پیچیده است.

مطالعه حاضر با ارائه مدلی مبتنی بر یادگیری ماشین که قادر به پیش‌بینی شاخص‌های اسپیرومتری بر اساس ویژگی‌های فردی است، به دانش موجود در زمینه فیزیولوژی تنفس و عوامل مؤثر بر عملکرد ریه می‌افزاید. همچنین، بررسی اهمیت نسبی هر یک از ویژگی‌های فردی در پیش‌بینی شاخص‌های اسپیرومتری می‌تواند درک عمیق‌تری از سازوکارهای دخیل در عملکرد ریه فراهم کند. افزون بر آن، این پژوهش می‌تواند کاربردهای عملی متعددی داشته باشد، زیرا ایجاد مدل‌های پیش‌بینی محلی برای شاخص‌های اسپیرومتری می‌تواند به پزشکان در تفسیر دقیق‌تر نتایج این بررسی در جمعیت شهرستان فسا کمک کند و از تفسیرهای نادرست ناشی از استفاده از مقادیر مرجع عمومی جلوگیری نماید. شناسایی عوامل فردی با بیشترین تأثیر بر عملکرد ریه نیز می‌تواند به طراحی برنامه‌های پیشگیرانه و مداخلات بهداشتی هدفمند برای گروه‌های در معرض خطر در این منطقه منجر شود. به‌عنوان نمونه، اگر مشخص شود که استعمال دخانیات در این جمعیت تأثیر بسیار قوی بر کاهش FEF25-75 دارد، برنامه‌های ترک دخانیات می‌تواند اولویت بالاتری پیدا کند. افزون بر آن، مدل‌های یادگیری ماشین می‌تواند الگوهای پیچیده‌ای را در داده‌ها شناسایی کند که ممکن است با روش‌های آماری سنتی قابل‌تشخیص نباشد. این امر می‌تواند به شناسایی افراد مستعد کاهش عملکرد ریوی و ارائه مداخلات به‌موقع کمک کند. در نتیجه با درک بهتر عوامل مؤثر بر عملکرد ریه در سطح جامعه، می‌توان برنامه‌های ارتقای سلامت و پیشگیری از بیماری‌های تنفسی را به طور مؤثرتری طراحی و اجرا کرد.

باتوجه‌به بار بالای بیماری‌های تنفسی، نقش حیاتی اسپیرومتری در تشخیص و پایش این بیماری‌ها، تأثیر عوامل فردی بر شاخص‌های اسپیرومتری و محدودیت‌های روش‌های سنتی در تحلیل این روابط، انجام پژوهشی که با بهره‌گیری از روش‌های یادگیری ماشین این ارتباط را در جمعیت شهرستان فسا بررسی کند، امری ضروری و ارزشمند است.

این پژوهش عملکرد مدل‌های مختلف را مقایسه و نقاط قوت و ضعف هر روش را ارزیابی می‌کند. هدف اصلی این پژوهش، تعیین و مدل‌سازی با مجموعه‌ای از ویژگی‌های فردی شامل سن، جنسیت، قد، وزن و وضعیت استعمال دخانیات و شاخص‌های کلیدی اسپیرومتری شامل FEV_1، FVC، FEV_1/FVC، FEF25-75 و PEF[1] در جمعیت مراجعه‌کننده به مطب تخصصی ریه در شهرستان فسا و تعیین بهینه‌ترین مدل از نظر دقت پیش‌بینی در بین الگوریتم‌های مورد مقایسه است. هدف فرعی این پژوهش نیز ارزیابی قدرت پیش‌بینی مدل‌های یادگیری ماشین در تخمین شاخص‌های اسپیرومتری بر اساس ویژگی‌های فردی و شناسایی قوی‌ترین ارزیاب در بین روش‌های یادگیری ماشین است و همچنین، بررسی اهمیت نسبی ویژگی‌ها در بهترین مدل انتخاب شده برای درک بهتر سازوکارهای فیزیولوژیک در این جمعیت است. لازم به تأکید است که پژوهش حاضر با هدف تشخیص بیماری انجام نشده است، بلکه تمرکز آن صرفاً بر پیش‌بینی شاخص‌های عملکرد ریوی و تحلیل تأثیر ویژگی‌های فردی بر آن‌ها با بهره‌گیری از الگوریتم‌های یادگیری ماشین است.

روش بررسی

این پژوهش یک مطالعه مشاهده‌ای از نوع مقطعی است که به‌صورت «پس‌نگر[2]» و بر پایه تحلیل ثانویه داده‌های سرشماری از پرونده‌های بیماران انجام شد. معیار ورود شامل بیماران مراجعه‌کننده به مطب ریه در شهرستان فسا در بازه زمانی بهار ۱۴۰۳ تا پاییز ۱۴۰۴ است که نتایج تست اسپیرومتری و اطلاعات جمعیت‌شناختی آن‌ها در پرونده موجود است. داده‌ها به‌صورت ثانویه از پرونده‌های بایگانی‌شده استخراج شد. معیار خروج نیز شامل کامل نبودن اطلاعات پرونده بیمار یا عدم دسترسی به اطلاعات آنها است. همچنین، از کلیه تستهای گرفته شده از بیماران، «بهترین تست‌ها[3]» به تشخیص نرم‌افزار دستگاه اسپیرومتری Winspiro Spirolab برند MIR Italy انتخاب شد. انتخاب بهترین تست نیز بر

1 Peak Expiratory Flow
2 Retrospective
3 Best

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

اساس رعایت معیارهای پذیرش و تکرارپذیری طبق دستورالعمل‌های استاندارد ATS/ERS صورت گرفت.

دلیل حدود ۱۸ ماهه بودن دوره بررسی شامل محدودیت‌های زمانی و منابع، ثبات نسبی ویژگی‌ها و پروتکل‌ها، کاهش اثرات عوامل مخدوش‌کننده فصلی یا دوره‌ای و دسترسی به داده‌ها است. در راستای اطمینان‌بخشی به نمونه‌گیری و کاهش خطای نمونه‌گیری و دقت نظر بیشتر، کل مراجعه‌کنندگانی که اطلاعات آنها برای انجام مطالعه موجود باشد (اطلاعات کامل موردنیاز برای پژوهش شامل اطلاعات جمعیت‌شناختی و نتایج تست اسپیرومتری) به‌عنوان نمونه در نظر گرفته شد. به این معنا که هیچ‌گونه نمونه‌گیری احتمالی به عمل نیامد و به روش شمارش کامل از کل داده‌های واجد شرایط و در دسترس استفاده و جامعه و نمونه پژوهش یکسان در نظر گرفته شد. بااین‌حال، به‌منظور آموزش، اعتبارسنجی و ارزیابی عملکرد مدل‌های یادگیری ماشین، داده‌ها در ادامه به مجموعه‌های آموزش و آزمون تقسیم شدند که این امر صرفاً یک مرحله فنی در مدل‌سازی بوده و به معنای نمونه‌گیری آماری جدید نیست. باتوجه‌به اینکه حجم جامعه پژوهش بیش از ۵۰۰۰ تست است، تمامی موارد واجد شرایط وارد مطالعه می‌شود و بدین ترتیب حجم نمونه تضمین خواهد شد. همچنین، با عنایت به دردسترس‌بودن داده‌های کافی و استفاده از کل جامعه واجد شرایط، نیازی به برآورد حجم نمونه جداگانه نیست.

برای کاهش «تورش[1]» انتخاب و اطمینان از همگنی داده‌ها در راستای هدف اصلی پژوهش، یعنی مقایسه متدولوژیک مدل‌های پیش‌بینی، استفاده از داده‌های حاصل از چند مطب توصیه نمی‌شود، زیرا هر مرکز ممکن است از دستگاه‌های اسپیرومتری با برند، مدل، کالیبراسیون و الگوریتم‌های اندازه‌گیری متفاوتی استفاده کند که این ناهمگنی می‌تواند منجر به واریانس ناخواسته در مقادیر ثبت‌شده شاخص‌های اسپیرومتری شود و دقت نتایج را تحت‌تأثیر قرار دهد. افزون بر این، تفاوت در شرایط محیطی، نحوه نگهداری و فرکانس کالیبراسیون دستگاه‌ها در مراکز مختلف نیز می‌تواند منبع دیگری از خطا و نوسان داده‌ها باشد. براین‌اساس، تمرکز بر یک مطب فوق‌تخصصی که از دستگاه اسپیرومتری ثابت، کالیبره شده و دارای پروتکل‌های اجرایی یکنواخت استفاده می‌کند، امکان کنترل بهتر متغیرهای مخدوش‌کننده و افزایش صحت و قابلیت اطمینان داده‌ها را فراهم می‌سازد. این رویکرد برای دستیابی به اهداف فنی و مقایسه‌ای پژوهش حاضر از اهمیت ویژه‌ای برخوردار است.

برای بررسی موضوع، پژوهشگر پس از کسب اجازه‌های لازم و کد تأیید اخلاق (IR.FUMS.REC.1404.174) و هماهنگی با پزشک مربوطه، اطلاعات لازم را جمع‌آوری کرد. افزون بر آن، اجبار برای استفاده از خدمات اسپیرومتری به‌هیچ‌عنوان وجود نداشته و مراجعه‌کنندگان با رضایت آگاهانه به این تست پرداخته‌اند. همچنین، تمامی اطلاعات شرکت‌کنندگان به‌صورت محرمانه نگهداری شده و فقط برای اهداف پژوهش استفاده شد. برای حفظ حریم خصوصی، اطلاعات با استفاده از کد جایگزین شد و فقط پژوهشگران به کلید کد دسترسی داشتند. شرکت در این پژوهش هیچ‌گونه خطر یا آسیب جسمی یا روانی برای شرکت‌کنندگان ندارد، زیرا از داده‌های موجود استفاده می‌شود و مداخله‌ای روی شرکت‌کنندگان انجام نمی‌شود. با رعایت این ملاحظات اخلاقی، حقوق و سلامت شرکت‌کنندگان در این پژوهش تضمین خواهد شد. سنجش عملیاتی متغیرها نیز به شیوه زیر انجام شد.

متغیرهای مستقل: ویژگی‌های فردی مراجعه‌کنندگان در پژوهش حاضر شامل سن، جنسیت، قد، وزن و سیگاری بودن یا نبودن است که سن به سال بیان می‌شود. جنسیت نیز به‌صورت صفر و یک بیان میشود که صفر برای زنان و یک برای مردان. همچنین، قد به سانتی‌متر ارائه میشود. وزن نیز به کیلوگرم بیان میشود. افزون بر آن، وضعیت استعمال دخانیات به‌صورت صفر و یک بیان می‌شود که صفر برای افرادی که استعمال دخانیات ندارند و یک برای افرادی که به استعمال دخانیات میپردازند. ازآنجاکه اطلاعات مربوط به مدت‌زمان مصرف دخانیات، تعداد نخ سیگار در روز و شاخص بسته – سال در پرونده‌ها ثبت نشده بود، وضعیت استعمال دخانیات تنها به‌صورت یک متغیر دودویی (بلی/خیر) در مدل‌ها وارد شد که این موضوع می‌تواند به‌عنوان یکی از محدودیت‌های پژوهش حاضر در نظر گرفته شود.

افزون بر مقیاس‌بندی متغیرهای پیوسته، متغیرهای طبقه‌ای دوتایی (جنسیت و وضعیت استعمال دخانیات) که به‌صورت صفر و یک کدگذاری شده است، برای استفاده در مدل‌های رگرسیون خطی و ماشین بردار پشتیبان به‌عنوان «متغیرهای مجازی[2]» در نظر گرفته شد تا از تحمیل فرض ترتیبی یا پیوسته بودن جلوگیری شود.

متغیرهای وابسته: عامل‌های مورد بررسی اسپیرومتری نیز شامل موارد زیر است که جدول ۱ آن را نشان می‌دهد.

1 Bias

2 Dummy Variables

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

جدول ۱- نماد، عنوان و تعریف عملیاتی شاخص‌های اسپیرومتری

نماد	عنوان	تعریف عملیاتی
FVC	ظرفیت حیاتی اجباری	حجم کل هوایی که فرد پس از یک دم عمیق، با حداکثر تلاش و با سرعت تا آخر بازدم می‌تواند از ریه‌های خود خارج کند.
FEV_1	حجم بازدم اجباری در یک ثانیه	حجم هوایی که فرد در اولین ثانیه از بازدم اجباری (همان تستی که برای FVC انجام می‌شود) می‌تواند از ریه‌های خود خارج کند.
FEV_1/FVC	نسبت حجم بازدمی اجباری در یک ثانیه به ظرفیت حیاتی اجباری	تقسیم نسبت‌های ذکر شده که به‌صورت درصد بیان می‌شود.
FEF25-75	جریان بازدمی اجباری بین ۲۵ تا ۷۵ درصد ظرفیت حیاتی اجباری	میانگین سرعت جریان هوا در میانه بازدم اجباری، یعنی زمانی که بین ۲۵٪ تا ۷۵٪ از کل حجم بازدمی (FVC) خارج شده است.
PEF	حداکثر جریان بازدمی	حداکثر سرعتی که فرد می‌تواند هوا را در ابتدای بازدم اجباری از ریه‌های خود خارج کند.

بر اساس پژوهش‌های پیشین، رابطه بین شاخص‌های اسپیرومتری در تست‌های اسپیرومتری مانند FEV۱ و FVC با ویژگی‌های فردی مانند سن و قد به‌عنوان متغیر مستقل، غیرخطی است که استفاده از شیوه‌های آماری خاص خود را طلب می‌کند (۱۶). بااین‌حال، اکثر مطالعه‌های قبلی در ایران از رگرسیون خطی چندگانه برای ارائه معادلات مرجع اسپیرومتری استفاده کرده‌اند (۱۹، ۱۸، ۱۷ و ۲۰). روش‌های یادگیری ماشین در تجزیه‌وتحلیل داده‌های ریوی برای پیش‌بینی و برآورد وضعیت عملکرد ریوی و طبقه‌بندی بهتر بیماری دارای قدرت توضیح‌دهندگی بهتری از روش‌های سنتی است (۲۱). در این راستا، پیشرفت‌های اخیر در حوزه هوش مصنوعی مسیرهای نوینی را در مراقبت‌های بهداشتی گشوده است و امکان استخراج بینش‌های عمیق‌تری از داده‌های موجود را فراهم می‌کند؛ از جمله شناسایی الگوهایی که به‌سادگی از طریق تفسیر انسانی یا مدل‌سازی آماری سنتی قابل‌تشخیص نیست. در این میان، روش‌های یادگیری ماشین به‌عنوان یکی از کارآمدترین رویکردها در این زمینه شناخته می‌شود و در مطالعه‌های مختلف مرتبط با ارزیابی عملکرد ریوی نیز مورداستفاده قرار گرفته است (۲۱، ۱۶ و ۲۲).

تحلیل داده‌ها در این پژوهش با استفاده از نرم‌افزار «پایتون۱» انجام شد، زیرا این زبان یکی از قدرتمندترین و پرکاربردترین ابزارها در حوزه یادگیری ماشین، تحلیل آماری و علم داده است. کتابخانه‌های متعددی مانند Matplotlib، NumPy، Pandas، Scikit-learn و TensorFlow در پایتون، امکان پیاده‌سازی دقیق، مقایسه و ارزیابی مدل‌های یادگیری ماشین را فراهم می‌کند. پایتون همچنین قابلیت کار با داده‌های پیچیده، انجام پیش‌پردازش، نرمال‌سازی، تقسیم داده به مجموعه‌های آموزش و آزمون و محاسبه شاخص‌های ارزیابی مدل مانند RMSE و R^2 را در یک محیط یکپارچه دارد. افزون بر این، بسیاری از مطالعات مشابه در زمینه تحلیل داده‌های اسپیرومتری و مدل‌سازی پیش‌بینی‌کننده از پایتون به‌عنوان بستر اصلی استفاده کرده‌اند، بنابراین، انتخاب پایتون در این پژوهش بر اساس توان محاسباتی بالا، پشتیبانی گسترده از الگوریتم‌های یادگیری ماشین، سهولت پیاده‌سازی و استاندارد بودن آن در پژوهش‌های داده‌محور پزشکی انجام شده است.

در این پژوهش از ۵ الگوریتم مرتبط با یادگیری ماشین استفاده شد که در ادامه توضیح داده می‌شود.

۱- «ماشین بردار پشتیبان[۲]»

یکی از روش‌های پیشرفته و قوی آماری در زمینه تشخیص و طبقه‌بندی صحیح پیامدها بر اساس عوامل خطر مرتبط که اخیراً کاربرد فراوانی در علوم پزشکی پیدا کرده است، روش ماشین بردار پشتیبان است (۲۳). فرایند ساخت مدل شامل دو مرحله آموزش و آزمون است که در مرحله آموزش، مدل الگو و روابط موجود بین پیامد و پیشبین‌ها را یاد می‌گیرد و در انتهای مرحله آموزش، قابلیت تعمیم‌دهی مدل برازش داده شده توسط داده‌های آزمون مورد ارزیابی قرار می‌گیرد. ماشین بردار پشتیبان پیشبینیهای خود را با استفاده از ترکیبات خطی و غیرخطی بر روی مجموعه‌ای از داده‌های آموزش به نام بردارهای پشتیبان انجام می‌دهد. باتوجه به مزایایی

1 Python

2 Support Vector Machines - SVMs

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

که این روش نسبت به روش‌های کلاسیک آماری دارد و نیاز به پیشفرض خاصی در مورد داده‌ها نیست، شناسایی الگوی ارتباط از روی داده‌های گروه آموزش صورت می‌گیرد و از روی الگوی تشخیص‌داده شده توسط مدل، داده‌های جدید ارزیابی می‌شود. عدم اهمیت به ساختار داده‌ها و رده‌ها، قابلیت استفاده برای داده‌ها با ابعاد بالاتر و استفاده از اصول ریسک ساختاری، به‌منظور کاهش خطای مدل از مزایای دیگر این روش است (۲۴).

۲- «تقویت گرادیان[1]»

تقویت گرادیان یک الگوریتم یادگیری ماشین قدرتمند و کارآمد است که در هر دو حوزهٔ رگرسیون و طبقه‌بندی کاربرد دارد. این روش به‌ویژه برای مجموعه‌داده‌های بزرگ و پیچیده مناسب است، زیرا با ترکیب تدریجی مدل‌های ضعیف‌تر، کارایی مدل نهایی را بهبود بخشیده و درعین‌حال مصرف حافظه را بهینه می‌کند (۲۵).

۳- «الگوریتم کی-نزدیک‌ترین همسایه[2]»

نزدیک‌ترین همسایه یکی از روش‌های ساده و درعین‌حال مؤثر در حوزهٔ یادگیری ماشین است که بر پایهٔ شباهت میان نمونه‌ها عمل می‌کند. در این روش، طبقه‌بندی یا پیش‌بینی بر اساس نزدیک‌ترین نمونه‌ها در فضای ویژگی انجام می‌شود؛ به‌طوری که موارد مشابه در مجاورت یکدیگر قرار گرفته و موارد غیرمشابه در فواصل دورتری از هم واقع می‌شود (۲۶).

۴- «رگرسیون خطی[3]»

رگرسیون خطی یک روش پایه و پرکاربرد در یادگیری ماشین و آمار است که برای مدل‌سازی رابطه خطی بین یک متغیر وابسته یا پاسخ و یک یا چند متغیر مستقل یا پیش‌بین استفاده می‌شود. هدف از رگرسیون خطی، یافتن بهترین خط (در حالت یک متغیر مستقل) یا بهترین ابر صفحه (در حالت چند متغیر مستقل) است که بتواند رابطه بین این متغیرها را توصیف کند و مقادیر متغیر وابسته را بر اساس مقادیر متغیرهای مستقل پیش‌بینی کند.

۵-«جنگل تصادفی»[4]

جنگل تصادفی یک الگوریتم یادگیری ماشین و یک روش ترکیبی بر پایه مجموعه‌ای از درختان تصمیم است. این الگوریتم به‌صورت گسترده در مسائل طبقه‌بندی، پیش‌بینی و حتی رگرسیون استفاده می‌شود. در مقایسه با الگوریتم‌های سنتی، جنگل تصادفی دارای ویژگی‌های برجسته‌ای است که باعث گسترده شدن دامنه کاربرد آن شده است. از جمله این ویژگی‌ها می‌توان به‌دقت بالا در پیش‌بینی، کاهش احتمال «بیش برازش[5]»، توانایی مدیریت داده‌های بزرگ و پر بعد، قابلیت ارزیابی اهمیت ویژگی‌ها، انعطاف‌پذیری در کاربردهای مختلف و مقاومت نسبت به داده‌های آلوده به خطا اشاره کرد (۲۷).

پیش‌پردازش داده‌ها و آموزش مدل‌های یادگیری ماشین

«تنظیمات اولیه[6]» مدل‌ها بر اساس مقادیر پیش‌فرض کتابخانه Scikit-learn و با انجام آزمون مقادیر متداول صورت گرفت. برای هر مدل یادگیری ماشین، هایپرپارامترهای اصلی و مقادیر بررسی شده به شرح زیر بودند:

رگرسیون خطی: از مقادیر پیش‌فرض استفاده شد و تنظیم خاصی نیاز نبود.

الگوریتم کی - نزدیک‌ترین همسایه: تعداد همسایگان K در بازه ۳ تا ۱۵ مورد آزمون قرار گرفت و بهترین مقدار با استفاده از کمترین خطای اعتبارسنجی متقابل انتخاب شد.

ماشین بردار پشتیبان: از «کرنل شعاعی[7]» استفاده شد و پارامترهای C و Υ با روش جستجوی شبکه‌ای در مقادیر متداول [۱۰،۱،۰،۱] و [۱،۰،۱،۰،۰۱] بهینه شدند.

جنگل تصادفی: تعداد درخت‌ها بین ۱۰۰ تا ۳۰۰ و بیشینه عمق درخت بین ۵ تا ۳۰ بررسی شد و بهترین ترکیب بر اساس معیار RMSE روی مجموعه اعتبارسنجی انتخاب شد.

تقویت گرادیان: نرخ یادگیری در بازه ۰/۰۱ تا ۰/۲ و تعداد تخمین‌گرها بین ۱۰۰ تا ۳۰۰ مورد آزمون قرار گرفت. انتخاب بهترین مقدار بر اساس کمترین خطای RMSE روی مجموعه اعتبارسنجی انجام شد.

برای شناسایی نقاط پرت، ابتدا با استفاده از روش «محدوده بین چارکی[8]» مقادیر خارج از محدوده $Q1-1.5\times IQR, Q3+1.5\times IQR$ به‌عنوان نقاط پرت شناسایی شدند. بسته به شدت و نوع نقاط پرت، تصمیم به حذف آن‌ها یا اعمال **تبدیل داده** گرفته شد؛ به عنوان مثال، در متغیرهایی با

1 Gradiednt Boosting
2 K-nearest Neighbors Algorithm
3 Linear Regression
4 Random Forest
5 Overfitting
6 Hyperparameters
7 RBF
8 IQR

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

توزیع نرمال نقاط پرت شدید حذف شدند و در متغیرهای دارای توزیع نامتقارن از تبدیل لگاریتمی یا ریشه دوم برای کاهش اثر آن‌ها استفاده شد. همچنین، لازم است داده‌های عددی مقیاس‌بندی شود تا تأثیر متغیرهایی با دامنه‌های بزرگ‌تر بر نتایج مدل کاهش یابد. برای این منظور، از روش استانداردسازی استفاده شد که هر مقدار x از هر متغیر عددی به‌صورت زیر تبدیل شد:

$$\frac{x-\mu}{\sigma} = std^x$$

که در آن:

μ میانگین و σ انحراف معیار همان متغیر در مجموعه آموزش است. با این تبدیل، تمامی متغیرها دارای میانگین صفر و انحراف معیار یک شدند و آموزش مدل‌ها از تأثیر دامنه‌های مختلف متغیرها مستقل شد.

پس از آماده‌سازی داده‌ها، مجموعه‌داده به دو بخش اصلی تقسیم شد:

مجموعه آموزش که ۸۰ درصد داده‌ها برای آموزش مدل‌های یادگیری ماشین اختصاص می‌یابد. مدل‌ها با استفاده از این مجموعه‌داده، الگوها و روابط بین ویژگی‌های فردی و شاخص‌های اسپیرومتری را یاد می‌گیرند.

مجموعه تست که ۲۰ درصد باقیمانده داده‌ها برای ارزیابی عملکرد نهایی مدل آموزش‌دیده استفاده می‌شود. این مجموعه‌داده هرگز در مرحله آموزش استفاده نمی‌شود و برای ارزیابی توانایی مدل در تعمیم به داده‌های جدید و دیده نشده به کار می‌رود.

برای اطمینان از نماینده بودن هر دو مجموعه (آموزش و تست)، از روش تقسیم تصادفی استفاده شد، تا اطمینان حاصل شود که مجموعه آموزش و تست هر دو نماینده داده‌های کل جمعیت باشند، به‌خصوص اگر توزیع متغیر وابسته نامتقارن باشد. پس از توسعه مدل‌ها، می‌توان روش‌های انتخاب ویژگی را برای شناسایی مهم‌ترین ویژگی‌های فردی که بیشترین تأثیر را بر شاخص‌های اسپیرومتری دارند، به کار برد. این امر موجب بهبود دقت مدل می‌شود. روش‌هایی مانند RFE[1] از طریق مدل‌هایی مانند جنگل تصادفی یا تقویت گرادیان انجام می‌شود.

برای جلوگیری از وابستگی عملکرد مدل‌ها به یک تقسیم‌بندی خاص از داده‌ها و افزایش پایداری ارزیابی، از روش «اعتبارسنجی متقابل ۵-لایه‌ای[2]» استفاده شد. در این روش کل داده‌ها به ۵ بخش تقسیم شد و مدل پنج بار آموزش دید؛ هر بار چهار بخش برای آموزش و یک بخش برای اعتبارسنجی استفاده شد. میانگین امتیازها نیز به‌عنوان عملکرد نهایی مدل‌ها گزارش شد.

در ادامه، برای استانداردسازی فرایند ارزیابی و مقایسه، یک تابع ارزیابی تعریف شد تا محاسبهٔ تمامی معیارهای عملکرد مدل در یک روال واحد انجام گیرد. سپس، پنج مدل یادگیری ماشین شامل رگرسیون خطی، الگوریتم کی – نزدیک‌ترین همسایه، تقویت گرادیان، جنگل تصادفی و ماشین بردار پشتیبان، با استفاده از داده‌های آموزش برازش داده شده و عملکرد آن‌ها بر روی مجموعه تست با سه معیار اصلی رگرسیون مورد ارزیابی قرار گرفت. این سه معیار عبارت است از «میانگین مربعات خطا[3]»، «ریشه میانگین مربعات خطا[4]» و «ضریب تعیین[5]». در معیارهای میانگین مربعات خطا و ریشه میانگین مربعات خطا، مقادیر کمتر (نزدیک به صفر) نشان‌دهندهٔ خطای کمتر و عملکرد بهتر مدل است، درحالی‌که در معیار ضریب تعیین، مقادیر بالاتر (نزدیک به یک) نشان‌دهندهٔ قدرت توضیحی بهتر مدل است.

یافته‌ها

از ۵۴۵۰ جمعیت مورد مطالعه، ۲۴۹۸ نفر مرد و ۲۹۵۲ نفر زن بودهاند. همچنین، ۲۲۶ نفر استعمال کننده دخانیات و ۵۲۲۴ نفر بدون استعمال دخانیات بوده‌اند. افزون بر آن، میانگین سن ۲۱/۱۸ ± ۴۷/۶۳، میانگین قد ۱۳/۷۶ ± ۱۶۲/۱۸ و میانگین وزن ۱۸/۹۲ ± ۶۷/۰۱ بوده است.

در ادامه تابع df.corr در کتابخانهٔ Pandas برای محاسبهٔ ضریب همبستگی پیرسون بین ستون‌های عددی استفاده شد. ضریب پیرسون عددی بین۱- تا ۱ است که شکل ۱ میزان و جهت رابطهٔ خطی بین متغیرها را نشان می‌دهد.

1 Recursive Feature Elimination

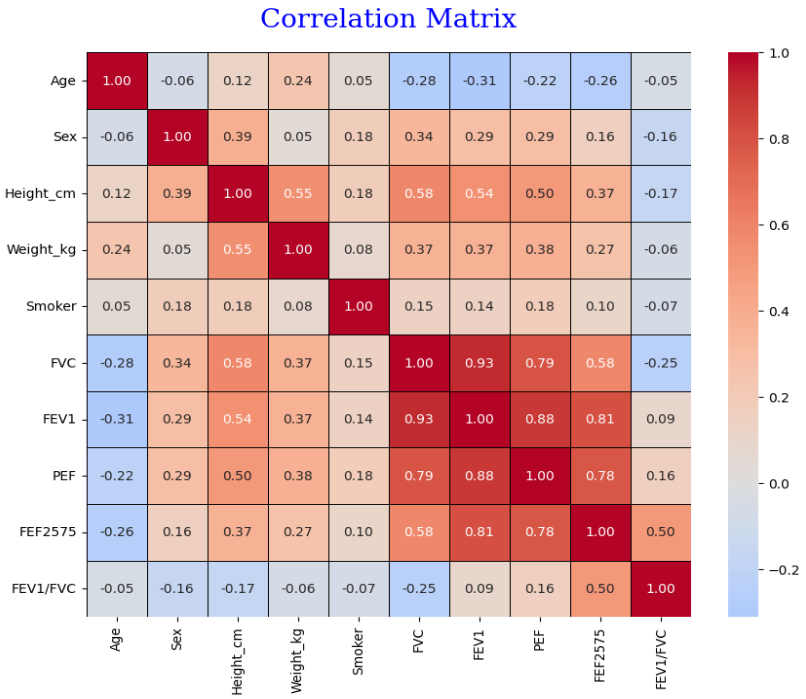
2 5-Fold Cross-Validation

3 MSE

4 RMSE

5 R2-Score

[Downloaded from aums.abzums.ac.ir on 2026-11-10]



شکل ۱- ماتریس همبستگی پیرسون بین ویژگی‌های فردی و شاخص‌های اسپیرومتری

تحلیل ماتریس همبستگی پیرسون نشان می‌دهد سن با FEV_1 و FVC همبستگی منفی متوسط دارد. این یافته با تغییرات فیزیولوژیک ناشی از پیری سازگار است؛ به‌طوری که با افزایش سن، الاستیسیته بافت ریه کاهش‌یافته و حجم‌های ریوی افت می‌کند. همبستگی مثبت قوی میان قد و FVC/FEV_1 نیز نشان می‌دهد که حجم ریوی رابطه ساختاری با ابعاد قفسه سینه دارد. در مقابل، وزن و وضعیت سیگاری بودن همبستگی خطی ضعیف نشان دادند؛ این امر بیانگر آن است که اثر این دو متغیر ممکن است غیرخطی یا وابسته به تعامل با سایر متغیرها باشد؛ مسئله‌ای که مدل‌های درختی توانایی بیشتری در کشف آن دارند. این یافته، توجیه‌کننده استفاده از مدل‌های غیرخطی در این پژوهش است.

در مرحله پیش‌پردازش، با هدف تضمین کیفیت داده‌ها و کاهش تأثیر نویز ناشی از مقادیر غیرعادی، از روش محدوده بین چارکی برای شناسایی و حذف نقاط پرت استفاده شد. این اقدام بر اساس ضرورت تمرکز مدل‌ها بر الگوهای فیزیولوژیک مرتبط با ویژگی‌های فردی در جمعیت عمومی و حذف موارد شدید بالینی که خارج از هدف پیش‌بینی ویژگی‌های فردی است صورت گرفت، زیرا برون‌یاب‌ها می‌توانند عمدتاً ناشی از خطای اندازه‌گیری، دمش غیراستاندارد یا بیماری‌های حاد باشند که مدل‌سازی روابط فیزیولوژیک پایه را مخدوش می‌سازند. با حذف ۸۳۵ رکورد که در شاخص‌های اسپیرومتری یا ویژگی‌های فردی به‌عنوان پرت شناسایی شد، حجم نهایی نمونه موردمطالعه به ٤٦١٥ رکورد کاهش یافت. اگرچه وجود نقاط پرت ممکن است نمایانگر موارد بالینی خاص باشد، اما هدف این مطالعه مدل‌سازی روابط فیزیولوژیک در جمعیت عمومی است. داده‌های بسیار دور از الگوی فیزیولوژیک می‌تواند الگوریتم‌ها را دچار بیش برازش کند و به همین دلیل حذف آن‌ها برای افزایش کیفیت مدل، منطقی است. مقایسه اولیه نتایج مدل‌ها قبل و بعد از حذف نقاط پرت نشان داد که انجام این مرحله موجب کاهش محسوس میزان خطای پیش‌بینی و افزایش ثبات عملکرد مدل‌ها شده است؛ بنابراین حذف داده‌های پرت نه‌تنها باعث کاهش حجم نمونه مؤثر نشد، بلکه کیفیت، قابلیت تعمیم و اعتبار نتایج نهایی را به طور معنی‌داری افزایش داد. نسبت نمونه حذف‌شده نیز کمتر از ۲۰ درصد بوده و همچنان حجم نمونه نهایی برای تحلیل‌های یادگیری ماشین کاملاً مناسب و قابل‌اتکا باقی‌مانده است.

همچنین، برای آماده‌سازی متغیرهای طبقه‌ای (جنسیت و وضعیت استعمال دخانیات) که به‌صورت باینری (۰ و ۱) کدگذاری شده‌اند، اطمینان حاصل شد که این متغیرها برای استفاده در مدل‌های رگرسیون

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

خطی و ماشین بردار پشتیبان به‌درستی به‌عنوان متغیرهای مجازی تفسیر شود، تا از تحمیل یک رابطه خطی غیرمنطقی جلوگیری شود. سپس مجموعه‌داده نهایی به نسبت ۸۰ درصد (۳۶۹۲ رکورد) به داده آموزش و ۲۰ درصد (۹۲۳ رکورد) به داده تست اختصاص داده شد. این تقسیم‌بندی نیز با استفاده از روش تقسیم تصادفی انجام شد.

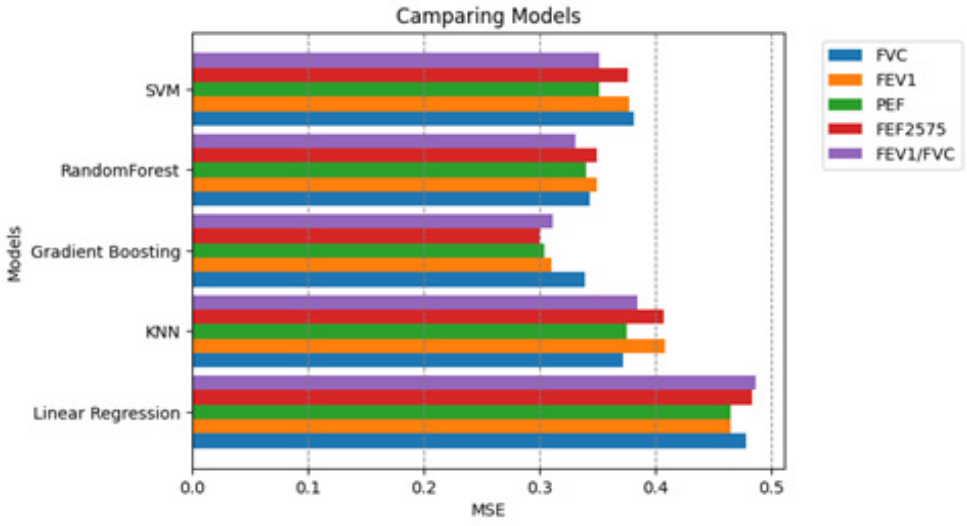
به‌منظور حاکمیت نظم متدولوژیک، جلوگیری از «تکرار کد[1]» و متمرکزسازی فرایند، یک «تابع پوششی[2]» به نام evaluate تعریف شد تا وظیفه تولید پیش‌بینی‌ها و محاسبه کلیه معیارهای ارزیابی عملکرد مدل را برای هر الگوریتم به‌صورت خودکار اجرا کند. سپس ۵ مدل ذکر شده با ۳ روش مورد اشاره ارزیابی می‌شود. جدول ۲ مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار میانگین مربعات خطا را نشان میدهد که هر چه کمتر باشد بهتر است.

جدول ۲- مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار میانگین مربعات خطا

عوامل	FVC	FEV_1	PEF	FEF25-75	FEV1/FVC
رگرسیون خطی	۰/٤٧٨٣	۰/٤٦٤٧	۰/٤٦٤٩	۰/٤٨٣٦	۰/٤٨٧١
الگوریتم کی - نزدیک‌ترین همسایه	۰/۳۷۲۱	۰/٤۰۷۸	۰/۳۷٥۷	۰/٤۰۷٤	۰/۳۸٤۱
تقویت گرادیان	۰/۳۳۹۱	۰/۳۱۰۳	۰/۳۰٤۱	۰/۳۰۰۱	۰/۳۱۱۹
جنگل تصادفی	۰/۳٤۳۱	۰/۳٤۹٦	۰/۳۳۹۸	۰/۳٤۹٦	۰/۳۳۱۱
ماشین بردار پشتیبان	۰/۳۸۱۲	۰/۳۷٦۹	۰/۳٥۱٦	۰/۳۷٦۲	۰/۳٥۱٥

تحلیل نمودار مقایسهٔ مدل‌ها (شکل ۲) حاکی از آن است که مدل تقویت گرادیان در معیار میانگین مربعات خطا، کمترین میزان خطا را داشته و رگرسیون خطی، بیشترین میزان خطا را نشان داده است.

شکل ۲- نمایش نموداری مقایسه عملکرد مدل‌ها بر اساس معیار میانگین مربعات خطا



1. Code Redundancy

2. Wrapper Function

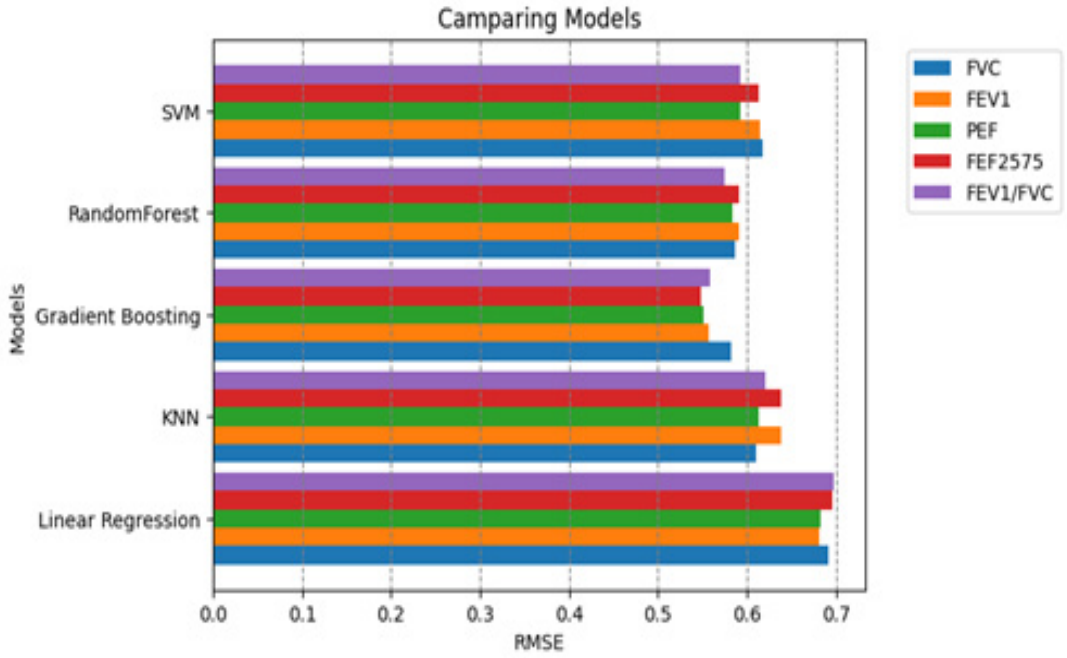
[Downloaded from aums.abzums.ac.ir on 2026-11-10]

جدول ۳ مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار ریشه میانگین مربعات خطا را نشان می‌دهد.

جدول ۳- مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار ریشه میانگین مربعات خطا

عوامل	FVC	FEV1	PEF	FEF25-75	FEV1/FVC
رگرسیون خطی	۰/٦٩١٦	۰/٦٨١٧	۰/٦٨١٩	۰/٦٩٥٤	۰/٦٩٧٩
الگوریتم کی – نزدیک‌ترین همسایه	٦١٠١/٠	۰/٦٣٨٦	۰/٦١٣١	۰/٦٣٨٢	۰/٦١٩٧
تقویت گرادیان	٥٨٢٣/٠	۰/٥٥٧١	۰/٥٥١٤	۰/٥٤٧٨	۰/٥٥٨٤
جنگل تصادفی	۰/٥٨٥٨	۰/٥٩١٣	۰/٥٨٢٩	۰/٥٩١٢	۰/٥٧٥٤
ماشین بردار پشتیبان	۰/٦١٧٤	۰/٦١٣٩	۰/٥٩٣٠	۰/٦١٣٣	۰/٥٩٢٩

شکل ۳ نمایش نموداری مقایسه عملکرد مدل‌ها بر اساس معیار ریشه میانگین مربعات خطا را نشان می‌دهد.



شکل ۳- نمایش نموداری مقایسه عملکرد مدل‌ها بر اساس معیار ریشه میانگین مربعات خطا

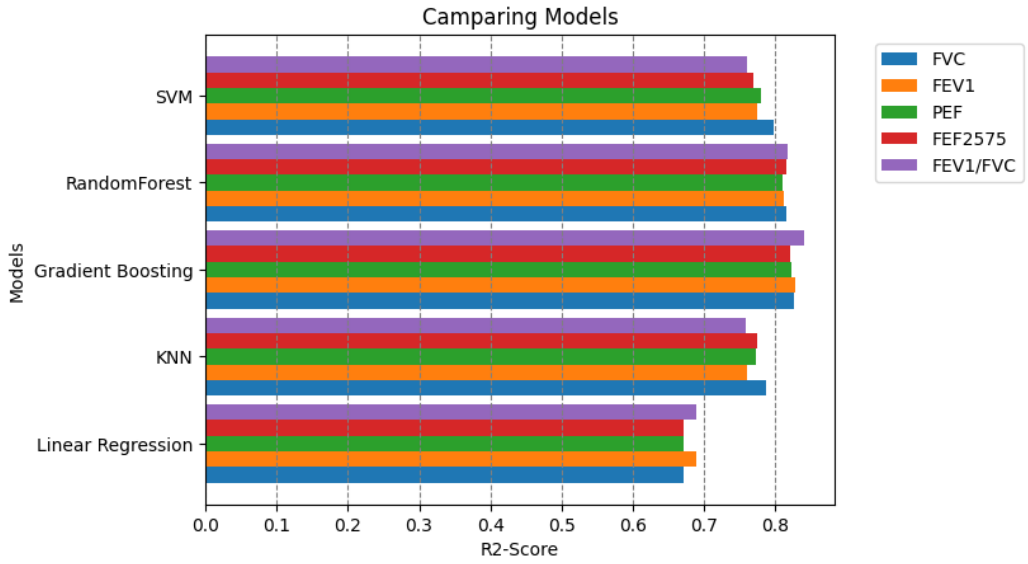
[Downloaded from aums.abzums.ac.ir on 2026-11-10]

جدول ٤، مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار ضریب تعیین را نشان می‌دهد و هر چه‌قدر به عدد ۱ نزدیک تر باشد بهتر است.

جدول ٤- مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس معیار ضریب تعیین

عوامل	FVC	FEV۱	PEF	FEF۲۵-۷۵	FEV۱/FVC
رگرسیون خطی	۰/٦٧١٦	۰/٦٨٨٣	۰/٦٧١٣	۰/٦٧٢١	۰/٧٩٨٦
الگوریتم کی - نزدیک‌ترین همسایه	۰/٧٨٧٥	۰/٧٥٩٦	۰/٧٧٢٥	۰/٧٧٤٨	۰/٢٩٥٧
تقویت گرادیان	۰/٨٢٦٩	۰/٨٢٨١	۰/٨٢٣١	۰/٨٢٠٦	۰/١١٤٨
جنگل تصادفی	۰/٨١٤٧	۰/٨١٢٥	۰/٨٠٩٧	۰/٨١٤٧	۰/٨١٨١
ماشین بردار پشتیبان	۰/٧٩٧٢	۰/٧٧٣٨	۰/٧٨٠١	۰/٧٦٨٤	۰/٧٦٠٤

شکل ٤، نمایش نموداری مقایسه عملکرد مدل‌ها بر اساس معیار ضریب تعیین را نشان می‌دهد.



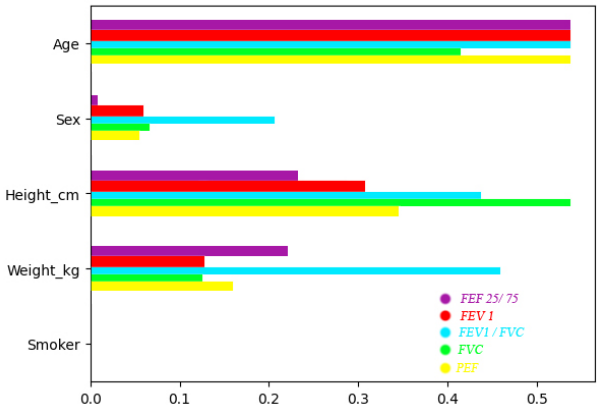
شکل ٤- نمایش نموداری مقایسه عملکرد مدل‌ها بر اساس معیار ضریب تعیین

نتایج ارزیابی مقایسه‌ای پنج مدل یادگیری ماشین بر اساس سه معیار ذکر شده، برتری قاطع مدل تقویت گرادیان را در پیش‌بینی تمامی شاخص‌های اسپیرومتری تأیید کرد. این مدل در تمام شاخص‌ها کمترین مقدار میانگین مربعات خطا و ریشه میانگین مربعات خطا و بالاترین مقدار ضریب تعیین را به دست آورد. مدل‌های خطی به دلیل فرض ساده خطی قادر به استخراج این الگوها نیست، درحالی‌که مدل‌های درختی و به‌ویژه تقویت گرادیان توانایی بالایی در یادگیری این الگوهای پیچیده دارد. مدل جنگل تصادفی و ماشین بردار پشتیبان نیز عملکرد قابل‌قبولی ارائه کرد، ولی همچنان نسبت به تقویت گرادیان دقت پایین‌تری داشت. به طور میانگین، ریشه میانگین مربعات خطا مدل تقویت گرادیان نسبت به رگرسیون خطی بین ۱۸ تا ۲۵ درصد کمتر بود که نشان‌دهنده دقت به‌مراتب بالاتر آن در برازش روابط میان متغیرها است. این اختلاف عملکرد بیانگر آن است که

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

روابط میان ویژگی‌های فردی و شاخص‌های اسپیرومتری ماهیتی غیرخطی داشته و شامل تعاملات چندمتغیره مانند اثر هم‌زمان سن، قد و جنس است؛ روابطی که مدل‌های خطی قادر به استخراج آن‌ها نیست. در مقابل، مدل‌های درختی مانند جنگل تصادفی و به‌ویژه تقویت گرادیان، با ساختار مرحله‌ای خود توانایی بیشتری در شناسایی این الگوهای پیچیده دارند. مدل ماشین بردار پشتیبان نیز در رتبه بعدی عملکرد قرار گرفت و به دلیل استفاده از «کرنل[1]» قادر به مدل‌سازی الگوهای غیرخطی است.

خروجی feature_importances_ مدل تقویت گرادیان که اهمیت نسبی هر یک از ویژگی‌های فردی را در پیش‌بینی شاخص‌های اسپیرومتری نشان می‌دهد، در شکل ۵ ارائه شده است.



شکل ۵- خروجی feature_importances_ مدل تقویت گرادیان برای هر یک از شاخص‌های اسپیرومتری

این یافته‌ها اهمیت نسبی هر یک از ویژگی‌های فردی سن، جنسیت، قد، وزن و وضعیت سیگاری بودن را در پیش‌بینی شاخص‌های اسپیرومتری با استفاده از مدل تقویت گرادیان نشان می‌دهد. اعداد بالاتر نشان‌دهنده تأثیر بیشتر آن ویژگی بر پیش‌بینی شاخص موردنظر است. همانگونه که مشاهده می‌شود، ویژگی‌های سن، قد و وزن در اکثر شاخص‌ها بیشترین اهمیت را دارد، درحالی‌که جنسیت و وضعیت سیگاری بودن تأثیر کمتری دارند. این یافته‌ها نشان می‌دهد که مدل تقویت گرادیان توانسته است روابط غیرخطی و پیچیده بین ویژگی‌های فردی و شاخص‌های اسپیرومتری را شناسایی کند. اهمیت بالای سن، قد و وزن با دانش فیزیولوژی ریه همخوانی دارد، زیرا این عوامل نقش کلیدی در حجم و عملکرد ریوی دارد. در مقابل، جنسیت و وضعیت سیگاری بودن تأثیر کمتری نشان می‌دهد که ممکن است به دلیل مقیاس‌بندی باینری یا اثرات غیرخطی و تعامل با سایر ویژگی‌ها باشد.

بحث

هدف این پژوهش، ارزیابی و مقایسه عملکرد مدل‌های یادگیری ماشین در پیش‌بینی شاخص‌های اسپیرومتری بر اساس ویژگی‌های فردی در جمعیت شهرستان فسا بود، امری که می‌تواند دانش موجود در زمینه «معادلات مرجعی محلی» و «پیش‌بینی عملکرد ریوی بدون تست مستقیم» را گسترش دهد. یافته‌های اصلی نشان داد که مدل تقویت گرادیان در مقایسه با سایر الگوریتم‌ها دقت پیش‌بینی بالاتری دارد. این مدل توانست روابط پیچیده، احتمالاً غیرخطی و تعاملی بین ویژگی‌های فردی و شاخص‌های اسپیرومتری را کشف کند. خروجی feature_importances نیز نشان داد که سن، قد و وزن سه متغیر با تأثیر قابل‌توجه و عمده بر پیش‌بینی شاخص‌ها است، درحالی‌که جنسیت و وضعیت سیگاری بودن تأثیر به نسبت کمتری داشت.

افزایش سن با کاهش قدرت الاستیک ریه، کاهش حجم ریوی و تغییرات ساختاری قفسه سینه همسو است؛ موضوعی که با فیزیولوژی ریه سازگار است. قد به‌عنوان یک شاخص ساختاری بدن بر حجم ریه تأثیر دارد: افراد بلندتر معمولاً ریه بزرگ‌تری دارند و بنابراین FVC و FEV_1 بالاتری دارند. وزن ممکن است با محدودیت مکانیکی قفسه سینه و دیافراگم به‌ویژه در افراد با چاقی یا اضافه‌وزن، بر عملکرد ریوی تأثیر بگذارد؛ یا اینکه وزن نماینده ترکیبی از ترکیب بدنی، چربی و توده عضلانی باشد که بر ریتم تنفس و ظرفیت ریوی اثرگذار است. اثر کم‌تر «جنسیت» و «وضعیت سیگاری بودن» در مدل می‌تواند به مقیاس‌بندی باینری، تعداد کم افراد سیگاری، یا تعامل با سایر متغیرها بستگی داشته باشد؛ یعنی شاید در این جمعیت سیگاری‌ها کمتر یا با ویژگی متفاوتی باشند؛ یا تأثیر سیگار در داده ما با متغیرهای دیگر خنثی شده باشد.

نتایج ما در اهمیت «سن» و «قد» با بسیاری از مطالعات اسپیرومتری همخوانی دارد. به‌عنوان نمونه، در مطالعه‌ای با جمعیت ایرانی، سن و قد به‌عنوان اصلی‌ترین پیش‌بین‌های FEV_1 و FVC گزارش شده است (۲۸). همچنین در گروه‌های جوان‌تر و حتی کودکان در پژوهشی از پاکستان، وزن نیز رابطه معناداری با شاخص‌های ریوی مانند FVC و FEV_1 داشته است (۲۹)، اما در برخی مطالعات، وزن یا BMI تأثیر منفی یا ناچیز بر عملکرد

1 Kernel

کرنل در ماشین بردار پشتیبان تابعی است که داده‌ها را به فضای بالاتر می‌برد تا الگوهای غیرخطی قابل‌تشخیص شوند، بدون آن‌که این تبدیل به‌صورت واقعی محاسبه شود.

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

ریوی یا برخی شاخص‌ها داشت. به‌عنوان نمونه، مطالعه روی افراد مبتلا به آسم نشان داد چاقی با کاهش معنی‌دار FEV_1 و FVC همراه است (۳۰). این تناقض‌ها با نتایج پژوهش ما که وزن اهمیت نسبی بالایی دارد، ممکن است به ویژگی‌های جمعیت مطالعه غیرآسمی. عمومی، تفاوت سبک زندگی، چاقی یا توزیع BMI و نیز تفاوت در مدل آماری و الگوریتم مورداستفاده بازگردد؛ بنابراین، یافته‌های ما مطابق با معادلات مرجع سنتی و استاندارد، نه تنها تأکید بر نقش مهم سن و قد دارد، بلکه وزن را نیز به‌عنوان یک متغیر با تأثیر واقعی در پیش‌بینی شاخص‌های ریوی در جمعیت فسا مطرح می‌کند. این موضوع شاخص است برای اینکه معادلات مرجع باید برای جمعیت محلی با ویژگی‌های جمعیتی، اقلیمی و رفتاری خاص طراحی شود.

از جمله محدودیت‌های این پژوهش می‌توان به تک‌مرکزی بودن مطالعه، استفاده از داده‌های ثانویه، ثبت ساده متغیر وضعیت سیگار به‌صورت باینری و تفاوت‌های احتمالی در کالیبراسیون و دقت دستگاه‌های اسپیرومتری اشاره کرد. افزون بر این، محدودیت زمانی پژوهشگر و دسترسی محدود به منابع داده‌ای و مالی، امکان گسترش حجم نمونه و افزودن متغیرهای بیشتر را کاهش داد.

با وجود این محدودیت‌ها، پژوهش حاضر گامی مهم در جهت ادغام روش‌های نوین یادگیری ماشین با سلامت تنفسی در ایران محسوب می‌شود و می‌تواند مبنایی برای پژوهش‌های گسترده‌تر، کاربردی‌تر و سیاست‌گذارانه در آینده باشد.

بر اساس نتایج به‌دست‌آمده، استفاده از مدل‌های یادگیری ماشین، به‌ویژه الگوریتم تقویت گرادیان، می‌تواند به عنوان ابزاری کارآمد در طراحی معادلات مرجع محلی و حتی به عنوان یک ابزار غربالگری اولیه برای شناسایی افراد در معرض خطر اختلالات ریوی مورداستفاده قرار گیرد. این ابزار می‌تواند در محیط‌های کم‌برخوردار که دسترسی به تجهیزات پیشرفته محدود است، به پزشکان و مراکز بهداشتی کمک کند تا بر اساس ویژگی‌های فردی، تصویر اولیه‌ای از وضعیت عملکرد ریوی افراد به دست آورند. همچنین توصیه می‌شود سیاست‌گذاران سلامت از به‌کارگیری مقادیر مرجع غیربومی پرهیز کرده و به تدوین استانداردهای محلی مبتنی بر داده‌های بومی توجه ویژه‌ای داشته باشند.

به پژوهشگران آینده نیز پیشنهاد می‌شود مطالعات چندمرکزی در مناطق مختلف ایران انجام دهند و متغیرهای بیشتری مانند شاخص دقیق مصرف دخانیات (بسته – سال)، نوع شغل، سطح فعالیت بدنی، شاخص چاقی مرکزی، عوامل محیطی از جمله میزان آلودگی هوا و شرایط اقلیمی را نیز در مدل‌های خود وارد کنند. همچنین ترکیب داده‌های جمعیت‌شناختی با داده‌های بالینی، تصویربرداری و بیومارکرها می‌تواند به ساخت مدل‌هایی دقیق‌تر و کاربردی‌تر منجر شود.

نتیجه‌گیری

پژوهش حاضر نشان داد که مدل تقویت گرادیان به‌عنوان یک الگوریتم یادگیری ماشین مؤثر، می‌تواند با دقت مناسب شاخص‌های کلیدی اسپیرومتری را بر اساس ویژگی‌های فردی در جمعیت محلی پیش‌بینی کند. اهمیت سن، قد و وزن در مدل، تأکیدی بر نقش ساختاری و فیزیولوژیک این عوامل در عملکرد ریوی است، امری که با یافته‌های مطالعات مرجع همسو است. در عین حال، نتایج این مطالعه چالش‌ها و تفاوت‌هایی را نسبت به بعضی مطالعههای پیشین نشان می‌دهد که می‌تواند به ویژگی‌های جمعیت، روش ثبت داده، مقیاس‌بندی متغیرها و نیز استفاده از مدل‌های پیشرفته نسبت داده شود.

اعلان‌ها

تشکر و قدردانی: از همه افرادی که در تهیه این پژوهش مشارکت داشته‌اند، تشکر می‌شود.

حمایت مالی: این پژوهش بدون هرگونه حمایت مالی انجام شده است.

تعارض منافع: نویسندگان گواهی می‌دهند که در این مطالعه تعارض منافعی نداشتند.

ملاحظات اخلاقی: در این پژوهش کلیه اصول اخلاقی رعایت شد و کد اخلاق IR.FUMS.REC.1404.174 نیز اخذ شده است.

استفاده از هوش مصنوعی: نویسندگان اعلام می‌دارند که در فرایند نگارش این مقاله از هیچ‌گونه فناوریهای هوش مصنوعی برای تولید محتوا، ایده، تجزیه وتحلیل و سایر موارد استفاده نشده است.

مشارکت نویسندگان: ساره رفعت مقام (تهیه طرح اولیه پژوهش، تدوین مبانی نظری، گردآوری داده‌های ثانویه و نگارش پیش‌نویس مقاله)، ندا جعفری (بازنگری طرح پژوهش، گردآوری داده‌های اولیه و نظارت علمی بر اجرای پژوهش)، عزیزالله دهقان (همکاری در اصلاح و تحلیل بخش آماری)، محمد روشن ضمیر (نظارت تخصصی بر بخش یادگیری ماشین). کلیه نویسندگان نسخه نهایی مقاله را مطالعه کرده و در تکمیل و تأیید آن مشارکت داشته‌اند.

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

References

1. World Health Organization. (2024). Chronic obstructive pulmonary disease (COPD). https://www.who.int/news-room/fact-sheets/detail/chronic-obstructive-pulmonary-disease-(copd)
2. Pellegrino, R., Viegi, G., Brusasco, V., Crapo, R. O., Burgos, F., Casaburi, R., … Wanger, J. (2005). Interpretative strategies for lung function tests. European Respiratory Journal, 26(5), 948–968.
3. Miller, M. R., Hankinson, J., Brusasco, V., Burgos, F., Casaburi, R., Coates, A., … Wanger, J. (2005). Standardisation of spirometry. European Respiratory Journal, 26(2), 319–338.
4. Knudson, R. J., Slatin, R. C., Lebowitz, M. D., & Burrows, B. (1976). The maximal expiratory flow-volume curve: Normal standards, variability, and effects of age, smoking, and body size. American Review of Respiratory Disease, 113(5), 587–600.
5. Sharma, G., & Goodwin, J. (2016). Effect of aging physiology on respiratory function and performance. Comprehensive Physiology, 6(4), 1603–1631.
6. Crapo, R. O., Morris, A. H., & Gardner, R. M. (1981). Reference spirometric values using techniques and equipment that meet ATS recommendations. American Review of Respiratory Disease, 123(6), 659–664.
7. Zapletal, A., Samanek, M., & Paul, T. (1987). Lung function in children and adolescents: Methods and reference values. Progress in Respiration Research, 22, 83–112.
8. Quanjer, P. H., Stanojevic, S., Cole, T. J., Baur, X., Hall, G. L., Culver, B. H., … Stocks, J. (2012). Multi-ethnic reference values for spirometry for the 3–95-year age range: The global lung function 2012 equations. European Respiratory Journal, 40(6), 1324–1343.
9. Jones, R. L., & Nzekwu, M. M. (2006). The effects of body mass index on lung volumes. Chest, 130(3), 827–833.
10. McClean, K. M., Kee, F., Young, I. S., & Elborn, J. S. (2008). Obesity and the lung: Epidemiology. Thorax, 63(7), 649–654.
11. Janoff, A. (1985). Elastase in tissue injury. Annual Review of Physiology, 47(1), 545–558.
12. Berg, K., & Wright, J. L. (2016). The pathology of chronic obstructive pulmonary disease: Progress in the 20th and 21st centuries. Archives of Pathology & Laboratory Medicine, 140(12), 1423–1428.
13. Martin, R. R., Lindsay, D., Despas, P., Bruce, D., Leroux, M., Anthonisen, N. R., & Macklem, P. T. (1975). The early detection of airway obstruction. American Review of Respiratory Disease, 111(2), 119–125.
14. Quanjer, P. H., Tammeling, G. J., Cotes, J. E., Pedersen, O. F., Peslin, R., & Yernault, J. C. (1993). Lung volumes and forced ventilatory flows. European Respiratory Journal, 6(Suppl. 16), 5–40.
15. Doll, R., & Peto, R. (1976). Mortality in relation to smoking: 20 years' observations on male British doctors. British Medical Journal, 2(6012), 1525–1536.
16. Loeloe, M. S., Sefidkar, R., Tabatabaei, S. M., Mehrparvar, A. H., & Jambarsang, S. (2025). Machine learning–based spirometry reference values for the Iranian population: A cross-sectional study from the Shahedieh PERSIAN cohort. Frontiers in Medicine, 12, 1480931.
17. Golshan, M., Nematbakhsh, M., Amra, B., & Crapo, R. O. (2003). Spirometric reference values in a large Middle Eastern population. European Respiratory Journal, 22(3), 529–534.
18. Razi, E., Mousavi, S. G. A., & Akbari, H. (2005). Spirometric standards for healthy Iranians dwelling in the centre of Iran. Tanaffos, 4(4), 19–26.
19. Etemadinezhad, S., & Alizadeh, A. (2011). Spirometric reference values for healthy adults in Mazandaran Province, Iran. Jornal Brasileiro de Pneumologia, 37(5), 615–620.
20. Aloosh, O., Torkashvand, M., Torkashvand, A., &

[Downloaded from aums.abzums.ac.ir on 2026-11-10]

Mohammadi, N. (2022). Evaluation of spirometric values in a healthy population referred to spirometry centers in Hamedan City, Iran. Journal of the Iranian Medical Council, 5(4), 661–667.

21. Taloba, A. I., & Matoog, R. T. (2025). Detecting respiratory diseases using machine learning-based pattern recognition on spirometry data. Alexandria Engineering Journal, 113, 44–59.
22. Helgeson, S. A., Quicksall, Z. S., Johnson, P. W., Lim, K. G., Carter, R. E., & Lee, A. S. (2025). [Article in JMIR AI].
23. Fatahi, M. (2015). Support vector machines: A survey (Master's thesis/Doctoral dissertation). Razi University.
24. Huang, S., Cai, N., Pacheco, P. P., Narrandes, S., Wang, Y., & Xu, W. (2018). Applications of support vector machine (SVM) learning in cancer genomics. Cancer Genomics & Proteomics, 15(1), 41–45.
25. Chen, H., Li, X., Feng, Z., Wang, L., Qin, Y., Skibniewski, M. J., et al. (2023). Shield attitude prediction based on Bayesian–LGBM machine learning. Information Sciences, 632, 105–129.
26. Shahrabi, J., & Zare, A. (2013). Data mining with Clementine. Tehran: Academic Jihad Press.
27. Liu, Y., Wang, Y., & Zhang, J. (2012). New machine learning algorithm: Random forest. In Proceedings of ICICA 2012 (pp. 246–252).
28. Sahebi, L., Rahimi, B., Shariat, M., et al. (2022). Normal spirometry prediction equations for the Iranian population. BMC Pulmonary Medicine, 22, 472. https://doi.org/10.1186/s12890-022-02273-8
29. Sadiq, S., Rizvi, N. A., Soleja, F. K., & Abbasi, M. (2019). Factors affecting spirometry reference range in growing children. Pakistan Journal of Medical Sciences, 35(6), 1587–1591.
30. Alqarni, A. A., Aldhahir, A. M., Siraj, R. A., Alqahtani, J. S., Alshehri, H. H., Alshamrani, A. M., et al. (2023). Prevalence of overweight and obesity and their impact on spirometry parameters in patients with asthma: A multicentre retrospective study. Journal of Clinical Medicine, 12(5), 1843.

[Downloaded from aums.abzums.ac.ir on 2026-11-10]