

## Planter Deformity Detection Using Improved Deep Learning Model

Raheleh Khaleghizadeh<sup>1</sup>, Sara Motamed<sup>2\*</sup>, Elham Askari<sup>2</sup>

1. Ph.D. Student, Department of Computer Engineering, Ra.C., Islamic Azad University, Rasht, Iran

2. Assistant Professor, Department of Computer Engineering, FSh.C., Islamic Azad University, Fouman, Iran

### ARTICLE INFO:

#### Article History:

Received: 7 May 2025

Accepted: 27 Aug 2025

Published: 22 Sep 2025

#### \*Corresponding Author:

Sara Motamed

#### Email:

sara.motamed@iau.ac.ir

**Citation:** Khaleghizadeh R, Motamed S, Askari E. Planter Deformity Detection Using Improved Deep Learning Model. Journal of Health and Biomedical Informatics 2025; 12(2): 189-203. [In Persian]

**Introduction:** Flatfoot and other structural deformities of the foot are major causes of musculoskeletal disorders that can significantly impair quality of life. Early detection of these abnormalities is crucial for preventing the progression of complications and selecting appropriate treatment strategies. In recent years, the application of deep learning methods in biomechanics and medical informatics has gained significant momentum, providing powerful tools for the automated and accurate analysis of medical imaging data. This study aims to develop a novel deep learning-based model for detecting foot abnormalities, addressing structural, angular, and plantar pressure aspects simultaneously.

**Method:** Foot images from both healthy subjects and individuals with abnormalities were collected and preprocessed. Initially, the arch region of the foot was segmented using advanced segmentation techniques. The segmented images were then passed to an enhanced YOLO architecture integrated with the Convolutional Block Attention Module (CBAM), enabling the network to focus more effectively on critical regions. Additionally, angular measurements of the foot were extracted and combined with plantar pressure distribution data to achieve a more comprehensive assessment of foot abnormalities.

**Results:** Experimental evaluations demonstrated that the proposed model achieved an accuracy of 95.14% in detecting foot abnormalities. Comparative analyses with other state-of-the-art methods revealed that the developed approach outperformed competing techniques, not only in classification accuracy but also in computational efficiency and its ability to focus on clinically relevant regions of the foot. The integration of angular and pressure-related features with segmented image data significantly enhanced the system's robustness and precision in identifying various types of abnormalities.

**Conclusion:** The proposed model, with its relatively simple yet effective architecture, provides a reliable solution for the accurate identification of foot abnormalities. This approach can be applied in medical screening, orthopedic insole design, and patient monitoring during rehabilitation. Furthermore, given its computational efficiency and ease of deployment, the model can be integrated into clinical environments and rehabilitation centers. Overall, this research contributes to the advancement of intelligent systems in digital health and predictive medicine.

**Keywords:** Planter deformity, Flatfoot pressure, Deep learning, YOLO model, CBAM attention mechanism



CrossMark

مقاله پژوهشی

## تشخیص ناهنجاری کف پا با استفاده از یادگیری عمیق بهبود یافته

راحله خالقی زاده<sup>۱</sup>، سارا معتمد<sup>۲\*</sup>، الهام عسکری<sup>۲</sup>

۱. دانشجوی دکتری، گروه کامپیوتر، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران

۲. استادیار، گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران

### چکیده

**مقدمه:** صافی کف پا و دیگر ناهنجاری‌های ساختاری کف پا از عوامل اصلی در بروز اختلالات اسکلتی-عضلانی به شمار می‌آیند و می‌توانند کیفیت زندگی افراد را به‌طور چشمگیری کاهش دهند. تشخیص زودهنگام این مشکلات نقش مهمی در پیشگیری از پیشرفت عوارض و انتخاب روش‌های درمانی مناسب ایفا می‌کند. در سال‌های اخیر، استفاده از روش‌های مبتنی بر یادگیری عمیق در حوزه بیومکانیک و مهندسی پزشکی رشد قابل توجهی داشته است. این روش‌ها با بهره‌گیری از قابلیت‌های تحلیل خودکار داده‌های تصویری و بالینی، امکان ارائه مدل‌های دقیق‌تر و کاربردی‌تر را فراهم می‌سازند. پژوهش حاضر با هدف ارائه مدلی نوین برای تشخیص ناهنجاری‌های کف پا طراحی و پیاده‌سازی شده است که هم‌زمان به تحلیل ابعاد ساختاری، زاویه‌ای و فشاری کف پا می‌پردازد.

**روش کار:** در این مطالعه تصاویر کف پای افراد سالم و دارای ناهنجاری گردآوری و به‌عنوان داده ورودی به سیستم پردازش داده ارائه شد. ابتدا ناحیه قوس کف پا با بهره‌گیری از تکنیک‌های پیشرفته سگمنت‌بندی، استخراج گردید. سپس خروجی این مرحله به مدل YOLO بهبودیافته همراه با مکانیزم توجه CBAM وارد شد تا فرآیند شناسایی ناهنجاری‌ها با دقت و تمرکز بیشتری بر نواحی بحرانی انجام پذیرد. علاوه بر آن، به منظور تحلیل جامع‌تر، زوایای کف پا از تصاویر محاسبه شد و با الگوی توزیع فشار در کف پا ترکیب گردید تا یک نمایه چندوجهی از وضعیت کف پا حاصل شود.

**یافته‌ها:** نتایج حاصل از ارزیابی مدل بر روی داده‌های آزمایشی نشان داد که روش پیشنهادی توانست به دقت ۹۵/۱۴ درصد در شناسایی ناهنجاری‌های کف پا دست یابد. مقایسه عملکرد مدل با روش‌های مرسوم و رقیب حاکی از آن بود که مدل ارائه‌شده نه تنها در سطح دقت، بلکه در سرعت پردازش و قابلیت تمرکز بر نواحی حساس کف پا نیز عملکرد بهتری ارائه کرده است. ترکیب اطلاعات زاویه‌ای و فشار در کنار تصاویر سگمنت‌بندی‌شده، موجب افزایش قابل توجه توان مدل در شناسایی انواع ناهنجاری‌ها گردید.

**نتیجه‌گیری:** مدل معرفی‌شده با ساختاری ساده و در عین حال کارآمد، قابلیت شناسایی ناهنجاری‌های کف پا را با دقت بالا فراهم می‌سازد. این رویکرد می‌تواند به‌عنوان ابزاری ارزشمند در غربالگری‌های پزشکی، طراحی کفی‌های طبی و پایش روند درمان بیماران به کار گرفته شود. همچنین با توجه به سهولت پیاده‌سازی و سرعت پردازش، امکان استفاده از این مدل در محیط‌های بالینی و مراکز توانبخشی وجود دارد. بدین ترتیب، پژوهش حاضر می‌تواند زمینه‌ساز توسعه سامانه‌های هوشمندتر در حوزه سلامت دیجیتال و پزشکی پیش‌بینانه باشد.

**کلیدواژه‌ها:** ناهنجاری کف پا، فشار صافی پا، یادگیری عمیق، مدل YOLO، مکانیزم توجه CBAM

### اطلاعات مقاله

#### سابقه مقاله

دریافت: ۱۴۰۴/۲/۱۷

پذیرش: ۱۴۰۴/۶/۵

انتشار برخط: ۱۴۰۴/۶/۳۱

#### نویسنده مسئول:

سارا معتمد

#### ایمیل:

sara.motamed@iaau.ac.ir

#### ارجاع:

خالقی‌زاده راحله، معتمد سارا، عسکری الهام. تشخیص ناهنجاری کف پا با استفاده از یادگیری عمیق بهبود یافته. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۴؛ ۱۲(۲): ۱۸۹-۲۰۳.

## مقدمه

صافی کف پا یکی از ناهنجاری‌های شایع اسکلتی-عضلانی است که در آن قوس طولی داخلی پا کاهش یافته یا به طور کامل از بین می‌رود. این وضعیت می‌تواند باعث بروز مشکلات متعددی از جمله درد در ناحیه کف پا، زانو و کمر، اختلال در تعادل و کاهش توانایی‌های حرکتی گردد [۱]. پا به عنوان پایه اصلی در زنجیره حرکتی اندام تحتانی نقش کلیدی در حرکت و پایداری بدن ایفا می‌کند و بروز هرگونه اختلال در ساختار آن می‌تواند تأثیرات جبران‌ناپذیری بر عملکرد کل بدن داشته باشد. تأخیر در شناسایی این ناهنجاری‌ها علاوه بر تشدید علائم بالینی در بزرگسالی، اغلب نیازمند مداخلات درمانی تهاجمی‌تر خواهد بود و در موارد شدید، مداخله جراحی اجتناب‌ناپذیر می‌شود. بنابراین، توجه به شناسایی به‌موقع و دقیق صافی کف پا همواره از دغدغه‌های محققان و متخصصان ارتوپدی بوده است [۱].

یکی از مباحث کلیدی در این زمینه، موضوع هنجاریابی است که امکان ارزیابی، مقایسه و قضاوت علمی درباره طبیعی یا غیرطبیعی بودن قوس کف پا را فراهم می‌کند [۲]. از طریق هنجاریابی می‌توان معیارهایی برای جمعیت‌های مختلف ارائه داد و بر اساس آن وضعیت سلامت یا ناهنجاری را مشخص نمود. در داخل کشور نیز مطالعات متعددی روی وضعیت کف پا در گروه‌های سنی و جنسی مختلف انجام شده که اغلب شیوع بالای ناهنجاری‌های کف پا را گزارش کرده‌اند، اما نتایج این پژوهش‌ها دقت تشخیصی کافی نداشته‌اند و حتی ابزارهایی نظیر اسکن کف پا نیز همواره قادر به ارائه تشخیص دقیق نبوده‌اند [۳].

با توسعه فناوری‌های نوین، یادگیری ماشین و به‌ویژه یادگیری عمیق به‌عنوان ابزارهایی توانمند در حوزه پزشکی و توانبخشی مطرح شده‌اند [۴]. یادگیری عمیق با استفاده از شبکه‌های عصبی چندلایه قادر است الگوهای پیچیده را از داده‌های حجیم استخراج کند و در تشخیص ناهنجاری‌ها نقش بسزایی ایفا نماید [۵]. شبکه‌های عصبی پیچشی (CNN (Convolutional Neural Network) به دلیل ساختار لایه‌ای خود و قابلیت پردازش تصویر، کاربرد گسترده‌ای در حوزه‌هایی چون تحلیل تصاویر پزشکی، پردازش سیگنال و شناسایی الگوها پیدا کرده‌اند [۶]. نخستین مدل CNN با نام LeNet توسط LeCun در سال ۱۹۸۸ معرفی شد و به مرور در وظایف مختلفی از جمله تشخیص کاراکترها و کدپستی مورد استفاده قرار گرفت. امروزه این شبکه‌ها در حوزه‌های پزشکی از جمله شناسایی تصاویر رادیولوژیک، پردازش MRI و تشخیص ناهنجاری‌های ارتوپدی کاربرد گسترده‌ای یافته‌اند [۷،۸].

در ارتباط با کف پا، پژوهش‌های داخلی و خارجی متعددی انجام شده است. بسیاری از مطالعات به تعیین شاخص‌های قوس پا پرداخته‌اند و مقادیر طبیعی، کم یا زیاد بودن قوس را در گروه‌های مختلف سنی و جنسی گزارش کرده‌اند [۹-۱۱]. برای مثال، Staheli و همکاران با بررسی ۴۴۱ آزمودنی مرد و زن بین ۱ تا ۸۱ سال شاخص قوس پا را محاسبه کردند و دامنه طبیعی آن را در گروه‌های سنی مختلف مشخص نمودند [۱۲]. در حوزه هوش مصنوعی نیز تلاش‌های متعددی صورت گرفته است. Wafai و همکاران با استفاده از شبکه عصبی مصنوعی توانستند عدم تقارن فشار کف پا را در طول راه رفتن شناسایی کنند و دقتی بین ۸۷ تا ۱۰۰ درصد گزارش نمایند [۱۳]. سایر پژوهش‌ها نشان داده‌اند که روش‌های مبتنی بر یادگیری ماشین و شبکه‌های عصبی می‌توانند با دقت بالاتری نسبت به روش‌های سنتی در تشخیص ناهنجاری‌های کف پا عمل کنند [۱۴،۱۵].

علاوه بر این، تحقیقات جدید به بررسی فشار کف پا در شرایط خاص پرداخته‌اند. برای نمونه، Kadhem و همکاران ویژگی‌های فشار کف پا در افراد چاق را با استفاده از تکنیک‌های آماری بررسی کردند [۱۶]. Castro و همکاران تغییراتی در سیستم‌های اندازه‌گیری فشار کف پا ایجاد کرده و قابلیت‌های بیشتری به آن افزودند [۱۷] و Abbas و همکاران با روش ویدئوگرامتری فشار کف پا در سالمندان را ارزیابی نمودند و ارتباط آن را با وزن و ابعاد پا مورد بررسی قرار دادند [۱۸]. در حوزه طراحی سیستم‌های هوشمند، پژوهش‌های اخیر بر روی استفاده از کفش‌های سنجشی مجهز به حسگر و شبکه‌های عصبی عمیق برای شناسایی صافی کف پا متمرکز بوده‌اند [۱۹]. همچنین، الگوریتم‌های یادگیری عمیق در ترکیب با روش‌های پردازش تصویر توانسته‌اند در تحلیل رادیوگرافی‌های لترال پا عملکردی هم‌تراز یا حتی بهتر از متخصصان ارائه دهند [۲۰-۲۵].

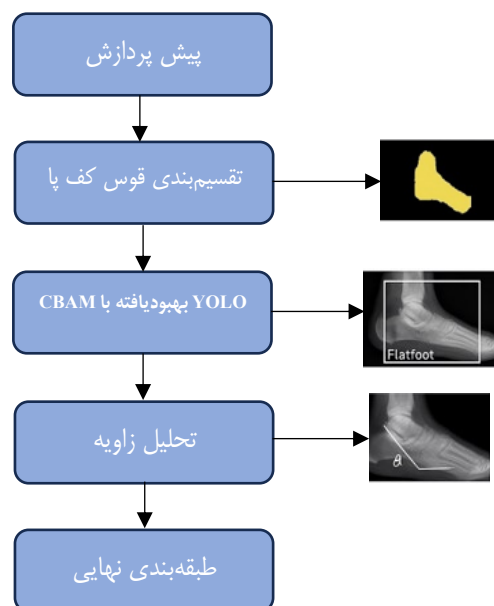
با وجود پیشرفت‌های چشمگیر، همچنان چالش‌هایی وجود دارد. یکی از این چالش‌ها کمبود داده‌های برچسب‌خورده برای آموزش مدل‌های عمیق است که می‌تواند دقت و قابلیت تعمیم‌پذیری آن‌ها را محدود سازد. به همین دلیل پژوهشگران اخیراً از مدل‌های مولد نظیر cGAN و GAN برای تولید داده‌های مصنوعی و رفع این مشکل استفاده کرده‌اند [۲۶،۲۷]. از سوی دیگر، مرور مطالعات مروری اخیر نشان می‌دهد که دستگاه‌های مختلف اندازه‌گیری فشار کف پا از جمله پلتفرمی و پوشیدنی هرکدام مزایا و محدودیت‌های خاص خود را دارند

[۲۸]. دستگاه‌های پلتفرمی دقت بالاتری دارند؛ اما کمتر قابل حمل‌اند، در حالی که دستگاه‌های پوشیدنی امکان استفاده روزمره و مکرر را فراهم می‌کنند.

تحقیقات سال‌های ۲۰۲۳ تا ۲۰۲۵ نیز حاکی از تلاش‌های گسترده در استفاده از شبکه‌های عمیق برای تحلیل تصاویر و داده‌های کف پا هستند. برای مثال، Zhang و Zheng از الگوریتم‌های یادگیری عمیق برای بهینه‌سازی پردازش تصویر استفاده کردند [۲۰]، احمد و همکاران تأثیر صافی کف پا را بر تعادل پویا بررسی نمودند [۲۱]. Nugroho و همکاران با طراحی ترازوهای اسکتر کف پا، امکان ثبت و تحلیل تصاویر کف پای کودکان را فراهم کردند [۲۲] و مطالعات دیگری بر استفاده از مدل‌های MobileNetV2 و U<sup>2</sup>-Net برای تشخیص دقیق‌تر ناهنجاری‌ها تأکید کرده‌اند [۲۳، ۲۹]. نتایج این پژوهش‌ها نشان می‌دهد که یادگیری عمیق می‌تواند به ابزار مهمی برای ارتقای تشخیص در حوزه ارتوپدی تبدیل شود، هرچند هنوز خلأهایی از جمله عدم وجود داده‌های استاندارد و جامع وجود دارد. با توجه به آنچه بیان شد، اگرچه پژوهش‌های متعددی در زمینه صافی کف پا انجام شده و مدل‌های مختلفی برای تحلیل تصاویر و داده‌های مرتبط ارائه گردیده است، هنوز مدلی جامع که بتواند تصاویر استاندارد را جمع‌آوری، استخراج و طبقه‌بندی کرده و هم‌زمان از دقت و سرعت کافی برخوردار باشد معرفی نشده است [۳۰]. از این رو، در این مطالعه مدلی ترکیبی مبتنی بر YOLOv5 و ماژول توجه CBAM پیشنهاد می‌شود. YOLOv5 به دلیل ساختار سبک، سرعت پردازش بالا و دقت مناسب، یکی از الگوریتم‌های مطرح در حوزه تشخیص اشیاء است و استفاده از آن در حوزه پزشکی نیز مورد توجه قرار گرفته است. ترکیب این شبکه با ماژول توجه CBAM سبب می‌شود که مدل بتواند به‌صورت پویا بر نواحی کلیدی تصویر تمرکز کند و نرخ خطای تشخیص کاهش یابد. هدف اصلی از ارائه این مدل، توسعه یک ابزار کاربردی برای محیط‌های بالینی است که بتواند پزشکان و متخصصان توانبخشی را در غربالگری و تشخیص سریع و دقیق صافی کف پا یاری نماید.

## روش کار

در این مطالعه، یک چارچوب ترکیبی برای تشخیص ناهنجاری‌های کف پا از روی تصاویر، پیشنهاد شده است. مدل پیشنهادی شامل سه مؤلفه اصلی سگمنت‌بندی دقیق ناحیه قوس پا، استخراج ویژگی‌های زاویه و فشار کف پا و در انتها تحلیل ساختار و تشخیص ناهنجاری‌ها براساس طبقه‌بندی ویژگی‌ها می‌باشد. سلسله مراحل مدل پیشنهادی در شکل ۱ نمایش داده شده است:



شکل ۱: سلسله مراحل مدل پیشنهادی

در ابتدا برای آموزش و ارزیابی مدل پیشنهادی، تصاویر کف پا از افراد سالم و بیمار در مراکز درمانی مختلف جمع‌آوری شدند. تمامی تصاویر به‌دست آمده بدون نیاز به برچسب داده‌ها آموزش می‌بینند. این به معنای این است که می‌توان از داده‌هایی که برچسب یا برچسب کامل ندارند، بهره برد و الگوهای مخفی و قابل استفاده را استخراج کرد. پس از جمع‌آوری داده‌ها، مرحله پیش‌پردازش را می‌توان انجام داد. این مرحله شامل عملیاتی مانند تغییر اندازه تصاویر، تصحیح روشنایی و تضاد و استانداردسازی داده‌ها است. هدف از پیش‌پردازش، آماده‌سازی داده‌ها برای مراحل بعدی مانند آموزش و ارزیابی مدل است. در این مرحله با استفاده از فیلترهای حذف نویز ابتدا نویزهای احتمالی تصاویر حذف خواهند شد، سپس با استفاده از فیلترهای بهبود کیفیت تصویر، وضوح تصویر بهبود خواهد یافت. هدف از این مرحله افزایش نسبی کیفیت تصویر است [۱۲].

برای افزایش تمرکز مدل تشخیص بر ناحیه حیاتی کف پا، از سگمنت‌بندی استفاده می‌شود تا ناحیه قوس داخلی پا به‌صورت ماسک باینری استخراج گردد. استخراج ماسک با استفاده از معادله ۱ انجام می‌گیرد.

$$\sigma\left(\sum_{i=1}^n w_i \cdot f_i(I(x, y)) + b\right) = S(x, y) \quad (1)$$

با توجه به معادله ۱،  $f_i$  فیلترهای کانولوشنی،  $w_i$  وزن‌های شبکه و  $\sigma$  تابع فعال‌سازی سیگموئید است. در ادامه تصویر ورودی با ماسک ضرب شده تا فقط ناحیه قوس به مدل تشخیص داده شود (معادله ۲):

$$S(x, y) \cdot I(x, y) = \hat{I}(x, y) \quad (2)$$

سپس بخش‌های انتخابی وارد مرحله استخراج ویژگی می‌شوند. در این مطالعه دو ویژگی اصلی زاویه پا و فشار پا استخراج خواهند شد. به‌منظور استخراج ویژگی‌های ذکر شده، از مدل بهبود یافته YOLO استفاده شد.

در مدل پیشنهادی و به‌منظور استخراج و طبقه‌بندی ناهنجاری‌های کف پا از معماری YOLOv5 استفاده شده است. مدل ارائه شده با مکانیزم توجه CBAM تقویت خواهد شد. این ماژول تمرکز شبکه را به‌صورت دینامیک روی نواحی و کانال‌های مهم افزایش می‌دهد. برای محاسبه صحیح زاویه، ابتدا باید مشخص شود که تصویر مربوط به پای راست است یا چپ، زیرا روش محاسبه زاویه برای هر پا متفاوت خواهد بود. تعیین موقعیت هر پا در تصویر با استفاده از جعبه محصور (Bounding Box) انجام می‌شود که توسط شبکه‌های YOLO تشخیص داده می‌شود. در تشخیص ناحیه زاویه پا، بخشی از پا که از پاشنه تا سر استخوان‌های کف پا امتداد دارد به‌عنوان ناحیه زاویه انتخاب می‌شود و ناحیه انگشتان پا از این محدوده حذف می‌گردد. درون این ناحیه، یک قطر مشخص برای هر پا تعریف می‌شود که مبنای محاسبه زاویه خواهد بود. سپس با استفاده از مختصات مرکز جعبه پیش‌بینی شده  $(X, Y)$ ، به‌همراه عرض  $(W)$  و ارتفاع  $(h)$  جعبه، نقاط محور جلو و عقب پا محاسبه می‌شود. این محاسبات توسط معادلات ۳ تا ۶ محاسبه می‌گردد:

$$P1_x = \left(x - \frac{w}{2}\right) \cdot W \quad (3)$$

$$P2_x = \left(x + \frac{w}{2}\right) \cdot W \quad (4)$$

$$P1_y = \left(y - \frac{h}{2}\right) \cdot H \quad (5)$$

$$P2_y = \left(y + \frac{h}{2}\right) \cdot H \quad (6)$$

با توجه به معادلات ۳ تا ۶،  $W$  و  $H$  به ترتیب عرض و ارتفاع تصویر هستند. برای ارزیابی دقت نقاط پیش‌بینی شده، فاصله اقلیدسی بین نقاط پیش‌بینی شده و نقاط مرجع (Ground Truth) توسط معادله ۷ محاسبه می‌شود:

$$Distance = \sqrt{(G_x - P_x)^2 + (G_y - P_y)^2} \quad (7)$$

این فاصله برای هر دو نقطه (جلویی و پشتی) محاسبه شده و میانگین آن‌ها به‌عنوان معیار دقت مدل در نظر گرفته می‌شود. برای افزایش دقت تشخیص، از زاویه‌های ساختاری پا استفاده می‌شود. زاویه Meary (بین تالوس و متاتارس اول) از روی نقاط کلیدی استخوان‌ها و معادله ۸ محاسبه می‌شود:

$$\theta = \cos^{-1}\left(\frac{v_1 \cdot v_2}{\|v_1\| \|v_2\|}\right) \quad (8)$$



با توجه به فرمول ۸، اگر  $\theta > 4^\circ$  باشد، نشانگر وجود صافی کف پا است. در انتها و به منظور طبقه‌بندی ویژگی‌های استخراج شده در مدل CBAM-YOLO، تمامی ویژگی‌های به دست آمده به لایه Fully Connected ارسال می‌شود تا تصمیم نهایی گرفته شود (معادله ۹):

$$y^{\wedge} = \text{Softmax}(W, [f_{yolo}, \theta] + b) \quad (9)$$

با توجه به معادله (۹)،  $f_{yolo}$  ویژگی‌های استخراج شده از آخرین لایه مدل YOLO،  $\theta$  زاویه تشخیص داده شده،  $y^{\wedge}$  احتمال کلاس‌بندی (سالم / صافی کف پا)،  $W$  وزن‌های لایه Fully Connected شبکه عصبی و  $b$  بایاس است.

ماژول CBAM یک مکانیزم توجه سبک و قابل افزودن است که به صورت ماژول جداگانه روی خروجی لایه‌های کانولوشنی قرار می‌گیرد. این ماژول در دو مرحله متوالی، ویژگی‌ها را پالایش می‌کند:

**توجه کانالی (Channel Attention):** این بخش یاد می‌گیرد که کدام کانال‌های ویژگی برای تشخیص نواحی بحرانی کف پا اهمیت بیشتری دارند. با استفاده از میانگین‌گیری سراسری (Global Average Pooling) و بیشینه‌گیری سراسری (Global Max Pooling) در بعد کانال و عبور آن‌ها از شبکه کوچک Fully Connected، وزن‌هایی تولید می‌شود که کانال‌های مهم را تقویت و کانال‌های غیرضروری را تضعیف می‌کند.

توجه مکانی (Spatial Attention) پس از تقویت کانال‌های مهم، این بخش یاد می‌گیرد که در هر نقشه ویژگی، کدام مکان‌ها (پیکسل‌ها) مهم‌تر هستند. با ترکیب اطلاعات مکانی از میانگین و بیشینه‌گیری روی بعد کانال و عبور آن‌ها از یک کانولوشن  $7 \times 7$ ، نقشه وزنی مکانی تولید می‌شود که نواحی کلیدی را برجسته می‌کند.

**مزیت در کاربرد پزشکی کف پا:** در تصاویر کف پا چه اسکن فشار و چه تصویر RGB (Red-Green-Blue) نواحی بحرانی مثل قوس میانی یا نقاط فشار غیرعادی ممکن است نسبتاً کوچک یا کنتراست پایینی داشته باشند؛ CBAM باعث می‌شود مدل توجه بیشتری به این نواحی متمایز، ولی کوچک داشته باشد و همچنین نویز پس‌زمینه (مثل لبه‌های کف پا یا سایه‌ها) را کاهش دهد، لذا ویژگی‌های مهم مرتبط با ناهنجاری را پررنگ‌تر و ویژگی‌های غیرمرتبط را کم‌رنگ‌تر کند. نتیجه این فرآیند در آزمایش‌های این مطالعه افزایش F1-Score و Recall بوده است، به‌ویژه در شناسایی موارد مرزی بین سالم و مبتلا، یا درجات مختلف صافی کف پا. در ادامه هاپیر پارامترهای YOLOv5 و مدل پیشنهادی در جدول ۱ نمایش داده شده است:

جدول ۱: هاپیر پارامترهای YOLOv5 و مدل پیشنهادی

هاپیر پارامتر	YOLOv5 پایه	YOLOv5 + CBAM پیشنهادی
اندازه ورودی (px)	۶۴۰×۶۴۰	۶۴۰×۶۴۰
Batch size	۱۶	۱۶
تعداد epoch	۱۰۰	۱۰۰
نرخ یادگیری اولیه	۰/۰۰۱	۰/۰۰۱
الگوریتم بهینه‌سازی	SGD (momentum=۰/۹۳۷)	AdamW
ضریب weight decay	۰/۰۰۰۵	۰/۰۰۰۵
ضریب کاهش LR	۰/۱ هر ۲۰ epoch	۰/۱ هر ۲۰ epoch
تابع زیان	CIoU + BCE	CIoU + BCE + CBAM loss
Anchor sizes	پیش‌فرض YOLOv5	پیش‌فرض YOLOv5
داده افزایی (Aug)	Flip, Scale, HSV	Flip, Scale, HSV + CutMix
ماژول توجه	—	CBAM

مجموعه داده موجود در این مطالعه شامل تصاویر اسکن شده کف پای افراد (بزرگسالان و کودکان) می‌باشد. این داده‌ها از مراکز بهداشتی، درمانگاه‌ها و بیمارستان‌ها و به صورت خصوصی جمع‌آوری شده است. ابعاد تصاویر موجود  $1024 \times 768$  و به صورت رنگی می‌باشد. از آنجایی که در این طرح قرار است روی بیماری‌های کف پا به تفکیک سن بررسی‌هایی صورت گیرد، تمامی تصاویر کف پای کودکان و بزرگسالان تفکیک شده است و ملاک تفکیک سن ۱۵ سال می‌باشد. همچنین از هر فرد چندین تصویر از جفت کف پا تهیه شده و اکثر

تصاویر مربوط به افراد با کف پای ناسالم می‌باشد. علاوه بر داده‌های خصوصی از یک مجموعه داده‌های عمومی که دیتاست مربوطه از مطالعه Khandoker و همکاران [۱۵] بود، استفاده شده است. شکل ۲ نمونه‌ای از تصاویر مجموعه داده‌های استفاده شده در مدل پیشنهادی را نمایش می‌دهد.



شکل ۲: نمونه‌ای از تصاویر مجموعه داده‌ها

همچنین جمعیت‌شناسی شرکت‌کنندگان و ویژگی‌های مجموعه داده در جدول ۲ نمایش داده شده است.

جدول ۲: ویژگی‌های شرکت‌کنندگان در مجموعه داده

کف پای نرمال			کف پای صاف			دسته بندی	ویژگی‌های شرکت‌کنندگان
تصویر	بیمار	جنسیت	تصویر	بیمار	جنسیت		
۵۴	۲۷	مرد	۹۲	۴۶	مرد	سن	۱۴-۲۴
۸۲	۴۱	زن	۵۶	۲۸	زن		۲۵-۳۵
۵۸	۲۹	مرد	۸۰	۴۰	مرد	۳۶-۵۰	
۱۱۸	۵۹	زن	۸۲	۴۱	زن		
۶۶	۳۳	مرد	۱۰۸	۵۴	مرد		
۱۲۰	۶۰	زن	۶۲	۳۱	زن		

مدل پیشنهادی در محیط پایتون و با بهره‌گیری از کتابخانه‌های TensorFlow و PyTorch پیاده‌سازی گردید. برای استفاده بهینه از مجموعه داده و دستیابی به ارزیابی پایدار، از روش اعتبارسنجی متقاطع-K تایی با  $K=10$  استفاده شد. در این روش، داده‌ها به ۱۰ بخش تقسیم و در هر تکرار، ۹ بخش برای آموزش و ۱ بخش برای آزمون استفاده شد تا در نهایت همه داده‌ها در فرآیند آموزش و آزمون قرار گیرند. نتایج نهایی، میانگین معیارهای عملکرد در تمام تکرارهای K-Fold است. به منظور کاهش خطر بیش‌برازش، علاوه بر K-Fold، تمهیدات زیر نیز به کار گرفته شد:

- **داده‌افزایی گسترده (Data Augmentation):** شامل چرخش، تغییر مقیاس، جابه‌جایی، تغییر شدت نور و رنگ (Hue, HSV (Saturation, Value برش تصادفی و ترکیب تصاویر با روش‌های CutMix و MixUp؛
- **تنظیم‌گرها (Regularization):** به کارگیری Dropout در لایه‌های انتهایی، استفاده از Weight Decay (L2) و کاهش تدریجی نرخ یادگیری؛
- **توقف زودهنگام (Early Stopping):** توقف فرآیند آموزش در صورت عدم بهبود عملکرد مجموعه اعتبارسنجی در چند دوره متوالی؛
- **Fine-Tuning محدود:** استفاده از مدل‌های پیش‌آموزش دیده YOLOV5 و به‌روزرسانی هدفمند وزن‌ها فقط روی لایه‌های مرتبط با ویژگی‌های ناهنجاری کف پا؛
- **اعتبارسنجی داخلی هر Fold:** جداسازی بخشی از داده‌های آموزشی در هر Fold به‌عنوان مجموعه اعتبارسنجی برای انتخاب بهینه فرآپارامترها و جلوگیری از بیش‌برازش.

مجموعه داده مورد استفاده شامل تصاویر کف پای افراد سالم و مبتلا به ناهنجاری‌های کف پا (بزرگسال و کودک) بوده و نمونه‌ها به صورت دقیق در دسته‌های مختلف برچسب‌گذاری شده‌اند. جدول ۳ تنظیمات کلیدی مدل پیشنهادی را نمایش می‌دهد.

جدول ۳: تنظیمات کلیدی مدل

تعداد لایه‌های کانولوشنال	ستون فقرات YOLO	نرخ یادگیری	بهینه‌ساز	اندازه دسته	تعداد تکرارهای آموزشی	تابع IOU استاندارد	روش اعتبارسنجی
۴	CSP Darkent53	۰/۰۰۰۱	Adam	۶۴	۱۰۰	$0.7 < IOU < 0.9$	K-Fold با k=10 CIoU Loss

همچنین پارامترهای ارزیابی عملکرد الگوریتم یادگیری ماشین مبتنی بر ماتریس آشفتگی است در جدول ۴ نمایش داده شده است. از نظر دسته‌بندی، اصطلاحاتی مانند صحیح مثبت (True Positive) TP، نادرست مثبت (False Positive) FP، درست منفی (True Negative) TN و منفی کاذب (False Negative) FN برای مقایسه برچسب کلاس‌ها استفاده می‌شود.

جدول ۴: فرم کلی ماتریس درهم‌ریختگی

	Selected as Negative	Selected as Positive
Negative	TN	FP
Positive	FN	TP

در توضیحات بیشتر باید اشاره کرد که در آزمایشات از سه معیار دقت (Precision)، فراخوانی (Recall) و امتیاز F (F-measure) در سطح فریم و سطح پیکسل برای ارزیابی استفاده شد. دقت به صورت تعداد تشخیص‌های درست مثبت تقسیم بر تعداد کل تشخیص‌ها و یادآوری به صورت تعداد تشخیص‌های درست مثبت تقسیم بر تعداد نمونه درست مطلق (Ground-truth)، تعریف می‌شوند. امتیاز F در واقع میانگین هارمونیک (mean Harmonic) دقت و یادآوری است و با توجه به معادلات ۱۰ تا ۱۲ محاسبه می‌گردند.

$$precision = \frac{TP}{TP+FP} \quad (10)$$

$$Recall = \frac{TP}{TP+FN} \quad (11)$$

$$F - measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

## نتایج

مدل پیشنهادی در محیط Google Colab با استفاده از زبان برنامه‌نویسی Python و کتابخانه‌های TensorFlow و PyTorch پیاده‌سازی شد. در نتایج مشاهده شد که مدل پیشنهادی توانسته است دقت بالایی در تشخیص مشکلات کف پا از تصاویر اسکن شده ارائه دهد. این میزان دقت در مقایسه با روش‌های سنتی و مدل‌های قبلی که در مقالات مرتبط بررسی شده‌اند، بهبود قابل توجهی نشان می‌دهد. همچنین به منظور عملکرد مدل پیشنهادی، این روش با روش‌های رقیب در مطالعات اخیر مورد بررسی قرار گرفته است. این بخش شامل نتایج آزمایش‌ها، مقایسه مدل پیشنهادی با مدل‌های دیگر و تحلیل دقیق هر روش برای انواع ناهنجاری‌های کف پا (صافی خفیف، متوسط، شدید) است. همچنین ماتریس درهم‌ریختگی، نمودار ROC و تحلیل خطا ارائه شده‌اند. جدول ۵ نشان دهنده نرخ تشخیص صافی کف پا از مدل‌های CNN، YOLOv4، MobileNetV2 + SVM و مدل پیشنهادی می‌باشد.

جدول ۵: جدول مقایسه عملکرد مدل‌ها

مدل تشخیص	F1 امتیاز (درصد)	صحت (درصد)	فراخوانی (درصد)	دقت (درصد)
CNN	۷۹/۳۶	۸۷/۹۰	۷۸/۶۰	۸۳/۲۷
YOLOv4	۸۹/۶۶	۹۲/۱۸	۹۰/۳۳	۹۱/۴۵
MobileNetV2 + SVM	۸۶/۴۰	۹۰/۵۵	۸۵/۱۰	۸۸/۷۲
مدل پیشنهادی	۹۴/۲۴	۹۶/۲۳	۹۴/۸۱	۹۵/۱۴


با بررسی جدول ۵ مشاهده می‌شود که مدل پیشنهادی توانسته دقت را به ۹۵/۱۴ درصد افزایش دهد. نرخ فراخوان روش پیشنهادی با ۹۴/۸۱ درصد، بالاتر از سایر روش‌ها است، که نشان‌دهنده توانایی بهتر در شناسایی ناهنجاری‌های کف پا است. همچنین مدل پیشنهادی با استفاده از مکانیزم توجه و ترکیب ویژگی‌ها، تعادل بهتری بین دقت و عملکرد پردازشی ایجاد کرده است. به‌منظور بررسی تأثیر هر یک از ویژگی‌های زاویه پا و فشار کف پا بر عملکرد مدل پیشنهادی، نتایج حاصل از هر حالت در جدول ۶ ارائه شده است.

جدول ۶: بررسی دقت مدل پیشنهادی در شرایط ورودی متفاوت

دقت (درصد)	روش‌ها
۹۱/۷۳	روش پیشنهادی با استفاده از ویژگی‌های زاویه پا
۹۳/۲۴	روش پیشنهادی با استفاده از ویژگی‌های فشار کف پا
۹۵/۱۴	روش پیشنهادی با استفاده از هر دو ویژگی‌های زاویه پا و فشار کف پا

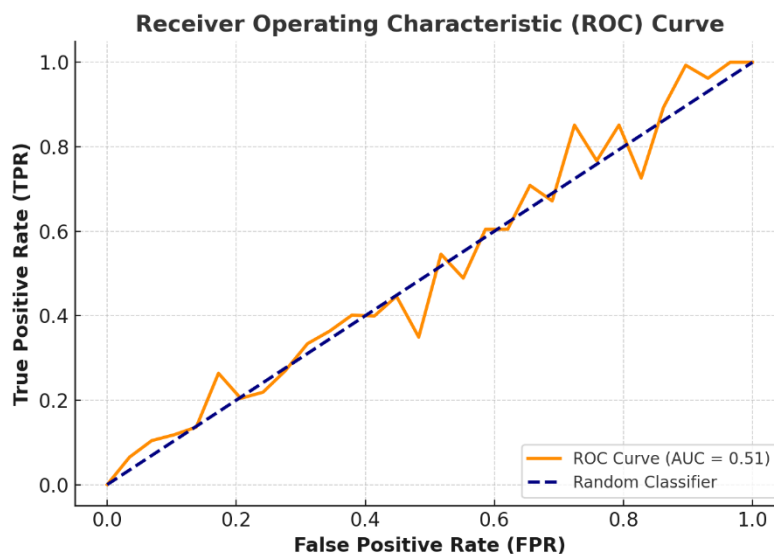
با بررسی جدول ۶، نتایج به‌دست‌آمده حاکی از آن است که استفاده تنها از ویژگی زاویه پا دقتی معادل ۹۱/۷۳ درصد شده است که نشان‌دهنده اهمیت ساختار استخوانی پا در تشخیص ناهنجاری‌ها می‌باشد. در حالت دوم، استفاده صرف از ویژگی‌های فشار کف پا، دقت را به ۹۳/۲۴ درصد افزایش داده است که بیانگر نقش تعیین‌کننده توزیع فشار در شناسایی صافی کف پا است. در نهایت، استفاده از هر دو ویژگی‌های زاویه و فشار باعث ارتقای قابل توجه دقت مدل به ۹۵/۱۴ درصد شده است. این افزایش نشان می‌دهد که ترکیب اطلاعات ساختاری و عملکردی، موجب بهبود توان تفکیک مدل در تشخیص صحیح بیماران از افراد سالم می‌شود. بنابراین، می‌توان نتیجه گرفت که مدل پیشنهادی در حالت ترکیبی دارای پایداری، دقت و قابلیت اطمینان بالاتری است و برای کاربردهای پزشکی عملی و سیستم‌های غربالگری خودکار، مناسب‌تر خواهد بود.

در این بخش به بررسی و تحلیل خطای به‌دست‌آمده از مدل پیشنهادی و تشخیص صافی کف پا پرداخته می‌شود. همچنین در بررسی مدل پیشنهادی صحت درستی مدل نیز بررسی گردیده و نتیجه در شکل ۳ نشان داده شده است:



شکل ۳: نمودار آموزش و اعتبار اتلاف در طول دوره‌ها

شکل ۳ نشان دهنده نمودار تغییرات Training Loss و Validation Loss در طول دوره‌های آموزش، بیانگر فرآیند یادگیری مدل پیشنهادی است. این نمودار یکی از مهم‌ترین ابزارها برای تحلیل رفتار مدل در حین یادگیری است. همان‌طور که دیده می‌شود، منحنی آبی که نمایانگر loss آموزش است، روند نزولی واضحی دارد. این کاهش یکنواخت بیانگر آن است که مدل در حال یادگیری ویژگی‌های مهم داده‌های آموزشی است و وزن‌ها به درستی در حال به‌روزرسانی هستند. منحنی نارنجی که مربوط به مجموعه اعتبارسنجی است، نیز کاهش قابل قبولی دارد، اما با نوسانات ملایم. این نوسانات طبیعی هستند و نشان‌دهنده این هستند که مدل ممکن است نسبت به داده‌هایی که ندیده کمی حساس باشد. یکی از نشانه‌های سرریز این است که منحنی training loss مرتب پایین برود، ولی validation loss بالا بماند یا افزایش یابد. در این نمودار چنین رفتاری مشاهده نمی‌شود. این موضوع تأیید می‌کند که مدل در حال یادگیری مؤثر و پایدار است و دچار سرریز نشده است. از حدود ۶۰ تکرار به بعد، هر دو منحنی به حالت تقریباً پایدار می‌رسند، که نشان می‌دهد مدل به نقطه اشباع یادگیری رسیده و یادگیری تثبیت شده است. بنابراین، نیازی به افزایش بیشتر تکرارها وجود ندارد. مدل پیشنهادی رفتار یادگیری مناسبی از خود نشان داده است. کاهش همزمان و یکنواخت دو loss اصلی نشان می‌دهد که هم داده‌های آموزشی و هم اعتبارسنجی به خوبی توسط مدل تعمیم داده شده‌اند. این روند نشان‌دهنده پایداری مدل، تنظیم صحیح فرآیندها و انتخاب معماری مناسب YOLO-CBAM است. به منظور ارزیابی دقیق‌تر عملکرد طبقه‌بندی مدل پیشنهادی، نمودار مشخصه عملکرد گیرنده (Receiver Operating Characteristic (ROC) (Characteristic True Positive Rate) مورد بررسی قرار گرفت. این نمودار نشان‌دهنده رابطه بین نرخ تشخیص صحیح (True Positive Rate) یا حساسیت و نرخ مثبت کاذب (False Positive Rate) در سطوح مختلف آستانه تصمیم‌گیری است که در شکل ۴ نشان داده شده است.



شکل ۴: نمودار مشخصه عملکرد گیرنده

شکل ۴ نشان‌دهنده نمودار مشخصه عملکرد گیرنده برای مدل پیشنهادی می‌باشد. این نمودار یکی از معیارهای کلیدی برای ارزیابی عملکرد مدل‌های دسته‌بندی، به‌ویژه در داده‌های پزشکی و عدم توازن کلاس‌ها، محسوب می‌شود. منحنی نارنجی رنگ مسیر عملکرد مدل را در سطوح مختلف آستانه نمایش می‌دهد. خط چین آبی نشان‌دهنده عملکرد یک طبقه‌بند تصادفی است؛ یعنی حداقل کیفیت قابل قبول. هرچه منحنی ROC بالاتر و به گوشه بالا-چپ نزدیک‌تر باشد، عملکرد مدل بهتر است. برای ارزیابی عملکرد مدل پیشنهادی مبتنی بر YOLO-CBAM در تشخیص صافی کف پا، از ماتریس درهم‌ریختگی (Confusion Matrix) استفاده شده است. این ماتریس در شکل ۵ نمایش داده شده است.



شکل ۵: ماتریس درهم ریختگی

شکل ۵ نشان‌دهنده آن است که مدل پیشنهادی دارای نرخ‌های بالای تشخیص صحیح مثبت (TP) و تشخیص صحیح منفی (TN) بوده و مقادیر خطای مثبت کاذب (FP) و منفی کاذب (FN) در آن نسبتاً پایین است. این نتایج بیانگر قدرت تفکیک بالا و اعتمادپذیری مناسب مدل در شناسایی شرایط صافی کف پا از تصاویر فشار کف پا می‌باشد. علاوه بر این، مقدار بالای امتیاز F1 نشان می‌دهد که مدل توانسته است توازن مناسبی میان حساسیت و دقت حفظ کند. این ویژگی‌ها، مدل پیشنهادی را به گزینه‌ای مناسب برای کاربردهای پزشکی واقعی تبدیل می‌کند؛ جایی که کاهش هشدارهای کاذب و جلوگیری از تشخیص‌های از دست‌رفته، اهمیت حیاتی دارند. به‌منظور ارزیابی سهم ماژول CBAM در عملکرد مدل، نسخه پایه YOLOv5 بدون این ماژول و نسخه بهبودیافته با CBAM تحت شرایط یکسان آموزش داده شدند.

جدول ۷: مقایسه YOLOv5 بدون و با ماژول CBAM

مدل تشخیص	دقت (درصد)	فراخوانی (درصد)	صحت (درصد)	امتیاز (درصد) F1
YOLOv5 بدون CBAM	۹۲/۱۰	۹۲/۴۰	۹۴/۰۰	۹۲/۲۵
YOLOv5 + CBAM پیشنهادی	۹۵/۱۴	۹۴/۸۱	۹۶/۲۳	۹۴/۲۴

همان‌طور که در جدول ۷ مشاهده می‌شود، افزودن CBAM باعث افزایش دقت از ۹۲/۱۰٪ به ۹۵/۱۴٪، افزایش فراخوانی از ۹۲/۴۰٪ به ۹۴/۸۱٪ و بهبود F1-Score از ۹۲/۲۵٪ به ۹۴/۲۴٪ شده است. این نتایج نشان می‌دهد که CBAM با تمرکز بیشتر بر نواحی بحرانی قوس کف پا، توانسته توان تفکیک مدل را ارتقاء دهد، بدون آن‌که زمان پیش‌بینی به‌طور محسوسی افزایش یابد.

جدول ۸: جدول مقایسه مطالعات مرتبط با تشخیص ناهنجاری کف پا مبتنی بر یادگیری عمیق

محدودیت‌ها	مزایا	دقت	روش	مرجع
نیاز به داده متنوع برای آموزش بالینی گسترده‌تر	ترکیب چندمنظوره داده‌ها (زاویه، فشار، تصویر)؛ تمرکز هوشمند بر نواحی بحرانی؛ سرعت پردازش بالا	۹۵/۱۴٪	مدل بهبودیافته YOLO + CBAM همراه با تحلیل زاویه‌ای، فشاری و ساختاری	پژوهش حاضر
پردازش پیچیده؛ نیاز به هم‌ترازسازی داده‌ها	ادغام داده فشار با تصویر؛ عملکرد بالا در تشخیص تیپ پا	۹۲/۵۵٪ (F1)	مدل ترکیبی VGG16 + KNN + Stacking با داده تصویری و فشاری	[۳۱]
محدود به تصاویر رادیولوژی؛ فاقد داده فشار	دقت بالا، پردازش سریع (≈ 11 s)	MAE زاویه Meary ≈ 1.59°	مدل YOLO-based برای landmark detection اندازه‌گیری خودکار زاویه‌ها	[۳۲]

جدول ۸: جدول مقایسه مطالعات مرتبط با تشخیص ناهنجاری کف پا مبتنی بر یادگیری عمیق (ادامه)

[۳۳]	مدل تشخیص خودکار نقاط عطف (Landmarks) برای تحلیل زاویه‌ای	ضریب همبستگی بالا با اندازه‌گیری انسانی	خودکارسازی کامل اندازه‌گیری زاویه‌ها	تنها برای زاویه تحلیل شده؛ فاقد اطلاعات سطح فشار
[۳۴]	مدل (Heatmap-in-) HHH (Heatmap) برای چند ناهنجاری	۸۵/۱٪	تشخیص چندگانه؛ سرعت و سادگی مدل	نیاز به نماهای مختلف (AP, Lat)
[۳۵]	مدل ترکیبی CNN + Random Forest بر اساس سه زاویه کلیدی پا	۹۳/۱۳٪	ترکیب چند زاویه برای افزایش دقت	فقط تصاویر جانبی؛ فاقد داده فشار یا ساختاری
[۳۶]	مدل LSTM برای بازسازی توزیع فشار کف پا در حین راه رفتن	$RMSE \approx 0.2/3 \pm 7/9$	کاهش نیاز به حسگر؛ دقت بالا در فشار	عدم تشخیص نوع ناهنجاری ساختاری
[۳۷]	مدل DeepLabV3+ برای سگمنت‌بندی قوس پا در تصاویر X-ray	ارزیابی کیفی عالی بر ۱۴۹۷ تصویر	تعین خودکار مورفولوژی قوس؛ دقت بالا	بدون اطلاعات فشار یا زاویه
[۳۸]	مدل DiffusionNet + Self-Attention برای طبقه‌بندی سه‌بعدی پا	۸۲/۹٪	تحلیل سه‌بعدی؛ مناسب برای پای بیماران دیابتی	داده محدود؛ عدم تمرکز بر نواحی فشار کف پا

جدول ۸، خلاصه‌ای از مطالعات پیشین در حوزه تشخیص ناهنجاری‌های کف پا مبتنی بر یادگیری عمیق را ارائه می‌دهد. همان‌گونه که مشاهده می‌شود، بیشتر پژوهش‌ها تنها بر یک بُعد از داده‌های کف پا — نظیر تصاویر رادیولوژی یا داده‌های فشار — متمرکز بوده‌اند و کمتر به ترکیب هم‌زمان ویژگی‌های ساختاری، زاویه‌ای و فشاری پرداخته‌اند. علاوه بر این، بسیاری از مدل‌های ارائه‌شده دقتی کمتر از ۹۳٪ گزارش کرده‌اند و از محدودیت‌هایی مانند حجم کم داده، زمان پردازش بالا و نبود اعتبارسنجی بالینی رنج می‌برند. در مقابل، مدل پیشنهادی این پژوهش با استفاده از معماری بهبودیافته YOLO همراه با مکانیزم توجه CBAM و ادغام چندوجهی داده‌ها، توانسته است دقت ۹۵/۱۴٪ را در شناسایی ناهنجاری‌های کف پا به دست آورد. این امر نشان‌دهنده توانایی بالای مدل در تمرکز بر نواحی بحرانی و تحلیل جامع وضعیت پا است و می‌تواند گامی مؤثر در توسعه سامانه‌های هوشمند تشخیص زودهنگام و طراحی ابزارهای کمکی در توانبخشی و ارتوپدی محسوب شود.

## بحث و نتیجه‌گیری

در این مطالعه، یک چارچوب نوین مبتنی بر یادگیری عمیق برای تشخیص ناهنجاری‌های کف پا، به‌ویژه صافی کف پا، ارائه شد. مدل پیشنهادی با ترکیب سه رویکرد اصلی شامل سگمنت‌بندی دقیق ناحیه قوس پا، به‌کارگیری مدل YOLOv5 بهبودیافته همراه با ماژول توجه CBAM و تحلیل زاویه‌ای ساختار پا توانست دقت چشمگیری در شناسایی بیماران از افراد سالم به دست آورد. نتایج آزمایش‌ها نشان داد که این مدل با دقت ۹۵/۱۴٪ عملکردی بهتر از مدل‌های پایه و نسخه‌های بدون تحلیل ترکیبی ارائه می‌دهد. این موضوع نشان می‌دهد که بهره‌گیری از اطلاعات چندوجهی و تمرکز بر نواحی بحرانی می‌تواند تأثیر قابل توجهی در افزایش کارایی مدل‌های تشخیصی داشته باشد. مقایسه با پژوهش‌های پیشین نیز اهمیت یافته‌ها را دوچندان می‌کند. بسیاری از مطالعات گذشته صرفاً به تحلیل تصاویر دوبعدی یا داده‌های فشار اکتفا کرده‌اند، در حالی که چارچوب پیشنهادی با ترکیب داده‌های ساختاری، زاویه‌ای و فشاری توانست تصویری جامع‌تر از وضعیت کف پا ارائه دهد. این مسئله نه تنها دقت را افزایش داده، بلکه قابلیت تعمیم مدل را برای شرایط متنوع‌تر تقویت کرده است.

با این حال، مطالعه حاضر بدون محدودیت نیست. نخست آن که حجم داده‌های مورد استفاده محدود بوده و بیشتر از یک جمعیت خاص گردآوری شده است؛ بنابراین برای اطمینان از تعمیم‌پذیری، لازم است مدل بر روی دیتاست‌های گسترده‌تر و متنوع‌تر آزمایش شود. دوم، تصاویر ورودی در شرایط کنترل شده به دست آمده‌اند و ممکن است در محیط‌های واقعی (مانند کلینیک‌ها یا خانه‌ها) کیفیت پایین‌تر تصاویر

بر عملکرد مدل تأثیر بگذارد. علاوه بر این، ارزیابی بالینی مستقل توسط متخصصان هنوز مورد نیاز است تا اعتبار یافته‌ها در عمل تأیید گردد. پیشنهاد می‌شود در تحقیقات آینده از مدل‌های مبتنی بر یادگیری انتقالی برای درک بهتر ساختارهای فضایی تصاویر استفاده شود و دقت طبقه‌بندی ارتقاء یابد. همچنین، ترکیب داده‌های چندمنبعی شامل تصاویر کف پا، توزیع فشار از طریق حسگرهای پوشیدنی، و اطلاعات کلینیکی نظیر سن، وزن و سابقه خانوادگی می‌تواند مسیر توسعه یک سیستم تشخیص هوشمند چندوجهی را هموار سازد. بهره‌گیری از الگوریتم‌های قابل تفسیر نیز می‌تواند اعتماد پزشکان و متخصصان را در استفاده از این ابزار افزایش دهد. از منظر کاربرد عملی، این مدل ظرفیت بالایی برای پیاده‌سازی در قالب یک اپلیکیشن موبایل یا دسکتاپ دارد که کاربران یا پزشکان بتوانند تنها با گرفتن یک تصویر ساده از کف پا، تحلیل اولیه‌ای از احتمال وجود صافی یا سایر ناهنجاری‌ها دریافت کنند. چنین ابزاری می‌تواند به‌عنوان یک سیستم غربالگری سریع در مدارس، باشگاه‌های ورزشی، یا کلینیک‌های فیزیوتراپی مورد استفاده قرار گیرد. در مجموع، پژوهش حاضر گامی مهم در جهت توسعه سامانه‌های هوشمند در حوزه سلامت دیجیتال به شمار می‌آید و می‌تواند بستر مناسبی برای تحقیقات پیشرفته‌تر در زمینه پزشکی پیش‌بینانه و توانبخشی فراهم آورد.

### تعارض منافع

هیچ گونه تضاد منافی بین نویسندگان وجود ندارد.

### کد اخلاق

جهت انجام این مطالعه کد اخلاق به شماره IR.KMU.REC.1404.351 از کمیته اخلاق دانشگاه علوم پزشکی کرمان اخذ شد.

### سهام مشارکت نویسندگان

مفهوم و طراحی روش، تجزیه و تحلیل و تفسیر داده‌ها: علیرضا اصغری کیاده، پیش نویس مقاله، تجزیه و تحلیل آماری و بازمینی مقاله توسط سارا معتمد انجام شده است.

### References

- [1]. Ghorbani M, Yaali R, Sadeghi H, Koumantakis GA. The impact of flatfoot on the correlation between functional movement scores, balance, agility, and core muscle strength in young females: a cross-sectional study. *Sci Rep* 2025;15(1):5077. doi: [10.1038/s41598-025-89364-8](https://doi.org/10.1038/s41598-025-89364-8)
- [2]. Sepasi H, Norbakhsh P. Measurement and Evaluation Physical Education. Tehran: Samt; 1997. p. 204-7. [In Persian]
- [3]. Akhavi R, Barzi D, Jashn S, Radmanesh M. Prevalence of foot and knee deformities among high school female students in Tehran District. *Hakim Res J* 2006;9(2):18-24. [In Persian]
- [4]. Cireşan D, Meier U, Gambardella LM, Schmidhuber J. Multi-column deep neural network for traffic sign classification. *Neural Netw* 2012;32:333-8. doi: [10.1016/j.neunet.2012.02.023](https://doi.org/10.1016/j.neunet.2012.02.023)
- [5]. Sheikhan A, Behnam H, Mohammadi MR, Noroozian M, Golabi P. Analysis of quantitative Electroencephalogram background activity in Autism disease patients with Lempel-Ziv complexity and Short Time Fourier Transform measure. 4th IEEE/EMBS International Summer School and Symposium on Medical Devices and Biosensors 2007 Aug 19; IEEE; 2007. p. 111-4. doi: [10.1109/CISP.2008.595](https://doi.org/10.1109/CISP.2008.595)
- [6]. Marrone S, Olivieri S, Piantadosi G, Sansone C. Reproducibility of deep CNN for biomedical image processing across frameworks and architectures. 27th European Signal Processing Conference; 2019 Sep 2-6; A Coruna, Spain: IEEE; 2019. p. 1-5. doi: [10.23919/EUSIPCO.2019.8902690](https://doi.org/10.23919/EUSIPCO.2019.8902690)
- [7]. Litjens G, Kooi T, Bejnordi BE, Setio AA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal* 2017;42:60-88. doi: [10.1016/j.media.2017.07.005](https://doi.org/10.1016/j.media.2017.07.005)
- [8]. Razzak MI, Naz S, Zaib A. Deep learning for medical image processing: Overview, challenges and the future. Classification in BioApps: Automation of decision making. Springer, Cham: 2017. p. 323-50. [https://doi.org/10.1007/978-3-319-65981-7\\_12](https://doi.org/10.1007/978-3-319-65981-7_12)
- [9]. Li Y, Shen L, Yu S. HEp-2 specimen image segmentation and classification using very deep fully convolutional network. *IEEE Trans Med Imaging* 2017;36(7):1561-72. doi: [10.1109/TMI.2017.2672702](https://doi.org/10.1109/TMI.2017.2672702)
- [10]. Anthony C, Redmond AC, Crane YZ, Menz HB. Normative values for the Foot Posture Index. *J Foot Ankle Res* 2007;1(10). doi: [10.1186/1757-1146-1-6](https://doi.org/10.1186/1757-1146-1-6)



- [11]. Ozlem EI, Omer A, Can K, Arslan Y. Flexible flatfoot and related factors in primary school children: a report of a screening study. *Rheumatol Int* 2006;26(11):1050-3. doi: [10.1007/s00296-006-0128-1](https://doi.org/10.1007/s00296-006-0128-1)
- [12]. Staheli LT, Chew DE, Corbett M. The longitudinal arch: a survey of eight hundred and eighty-two feet in normal children and adults. *J Bone Joint Surg Am* 1987;69(3):426-8.
- [13]. Wafai L, Zayegh A, Woulfe J, Begg R. Automated classification of plantar pressure asymmetry during pathological gait using artificial neural network. *Int J Environ Res Public Health* 2014;15(8):17-20. doi:[10.1109/MECBME.2014.6783244](https://doi.org/10.1109/MECBME.2014.6783244)
- [14]. Hill C, Gill T, Menz H, Taylor A. Prevalence and correlates of foot pain in a population-based study: the North West Adelaide health study. *J Foot Ankle Res* 2008;1(2). doi: [10.1186/1757-1146-1-2](https://doi.org/10.1186/1757-1146-1-2)
- [15]. Khandoker AH, Lai DTH, Begg RK, Palaniswami M. Wavelet-based feature extraction for support vector machines for screening balance impairments in the elderly. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2007;15:587-97. doi: [10.1109/TNSRE.2007.906961](https://doi.org/10.1109/TNSRE.2007.906961)
- [16]. Kadhem AD, Albert K, Gharineiat Z. Plantar pressure characteristics in obese individuals: a proposed methodology. 3rd International Conference on Imaging, Signal Processing and Communication (ICISPC); 2019. doi:[10.1109/ICISPC.2019.8935691](https://doi.org/10.1109/ICISPC.2019.8935691)
- [17]. Castro F, Savaris W, Araujo R, Costa A, Sanches M, De Carvalho A. Plantar pressure measurement system with improved isolated drive feedback circuit and ANN: Development and characterization. *IEEE Sensors Journal* 2020; 20(19):11034-43. doi: [10.1109/JSEN.2020.2998700](https://doi.org/10.1109/JSEN.2020.2998700)
- [18]. Abbas NS, Chong A, Al-Kharaz AA, Al-Hadeethi H. Relationships between foot dimensions and plantar pressure distributed in older people. In2020 IEEE 10th Symposium on Computer Applications & Industrial Electronics (ISCAIE) 2020 Apr 18; IEEE; 2020. p. 198-202.
- [19]. Kim JY, Hwang JY, Park E, Nam HU, Cheon S. Flat-feet prediction based on a designed wearable sensing shoe and a pca-based deep neural network model. *IEEE Access* 2020;8:199070-80. doi:[10.1109/ACCESS.2020.3033826](https://doi.org/10.1109/ACCESS.2020.3033826)
- [20]. Zhang Y, Zheng X. Development of image processing based on deep learning algorithm. In2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC); 2022 Apr 14; Dalian, China: IEEE; 2022. p. 1226-8. doi: [10.1109/IPEC54454.2022.9777479](https://doi.org/10.1109/IPEC54454.2022.9777479)
- [21]. Muhsin MA, Ghazwan A. The Impact of Flat Foot on The Clinical Measurement of Foot Posture and Dynamic Balance. *IEEE Jordan International Joint Conference on Electrical Engineering and Information Technology (JEEIT)*; 2023 May 22; Amman, Jordan; IEEE; 2023. p. 18-21. doi:[10.1109/JEEIT58638.2023.10185761](https://doi.org/10.1109/JEEIT58638.2023.10185761)
- [22]. Nugroho AN, Kamarukmi NE, Ghufroon A, Kurniatie MD. Scales feature foot scanners as parameters of flat feet in children *International Conference on Information Science and Technology Innovation (ICoSTEC)* 2023;2(1):122-6. <https://doi.org/10.35842/ICOSTEC.V2I1.49>
- [23]. Gül Y, Yaman S, Avcı D, Çilengir AH, Balaban M, Güler H. A novel deep transfer learning-based approach for automated Pes Planus diagnosis using X-ray image. *Diagnostics* 2023;13(9):1662. <https://doi.org/10.3390/diagnostics13091662>
- [24]. Ryu SM, Shin K, Shin SW, Lee SH, Seo SM, Cheon SU, et al. Automated diagnosis of flatfoot using cascaded convolutional neural network for angle measurements in weight-bearing lateral radiographs. *Eur Radiol* 2023;33(7):4822-32. doi: [10.1007/s00330-023-09442-1](https://doi.org/10.1007/s00330-023-09442-1)
- [25]. Noh WJ, Lee MS, Lee BD. Deep learning-based automated angle measurement for flatfoot diagnosis in weight-bearing lateral radiographs. *Scientific Reports* 2024;14(1):18411. doi:[10.1038/s41598-024-69549-3](https://doi.org/10.1038/s41598-024-69549-3)
- [26]. Chan HL, Liang JR, Chang YJ, Chen RS, Kuo CC, Hsu WY, et al. Enhancing plantar pressure distribution reconstruction with conditional generative adversarial networks from multi-region foot pressure sensing. *Biomedical Signal Processing and Control* 2025;100:107187. doi:[10.1016/j.bspc.2024.107187](https://doi.org/10.1016/j.bspc.2024.107187)
- [27]. Raj KA, Krishnan S, Chalil A, Venugopal V. Improving Foot Deformity Detection in Children: Synthetic Plantar Pressure Data Generation with GMM and GAN. In2024 4th Asian Conference on Innovation in Technology (ASIANCON); 2024 Aug 23; Bengaluru: IEEE; 2024. p. 1-6. <https://doi.org/10.1109/asiancon62057.2024.10838069>
- [28]. Detels K, Shin D, Wilson H, Zhou S, Chen A, Rosendorf J, et al. Clinical applications of plantar pressure measurement. *arXiv preprint arXiv:2401.04830*. 2024. <https://doi.org/10.48550/arXiv.2401.04830>
- [29]. Ryu SM, Shin K, Shin SW, Lee SH, Seo SM, Koh SH, et al. Enhanced diagnosis of pes planus and pes cavus using deep learning-based segmentation of weight-bearing lateral foot radiographs: a comparative observer study. *Biomed Eng Lett* 2025;15(1):203-15. <https://doi.org/10.1007/s13534-024-00439-3>
- [30]. Dindorf C, Dully J, Simon S, Perchthaler D, Becker S, Ehmann H, Diers C, Garth C, Fröhlich M. Toward automated plantar pressure analysis: machine learning-based segmentation and key point detection across multicenter data. *Frontiers in Bioengineering and Biotechnology* 2025;13:1579072. <https://doi.org/10.3389/fbioe.2025.1579072>
- [31]. Chae J, Kang YJ, Noh Y. A deep-learning approach for foot-type classification using heterogeneous pressure data. *Sensors*. 2020;20(16):4481. <https://doi.org/10.3390/s20164481>
- [32]. Noh WJ, Lee MS, Lee BD. Deep learning-based automated angle measurement for flatfoot diagnosis in weight-bearing lateral radiographs. *Sci Rep* 2024;14(1):18411. <https://doi.org/10.1038/s41598-024-69549-3>

- [33]. Ryu SM, Shin K, Shin SW, Lee SH, Seo SM, Cheon SU, et al. Automated landmark identification for diagnosis of the deformity using a cascade convolutional neural network (FlatNet) on weight-bearing lateral radiographs of the foot. *Comput Biol Med* 2022;148:105914. doi: [10.1016/j.compbiomed.2022.105914](https://doi.org/10.1016/j.compbiomed.2022.105914)
- [34]. Lee SJ, Yoon H, Bae S, Paik I, Moon JH, Park S, et al. Deep Learning-Based Landmark Detection Model for Multiple Foot Deformity Classification: A Dual-Center Study. doi: [10.3349/ymj.2024.0246](https://doi.org/10.3349/ymj.2024.0246)
- [35]. Alsaïdi FA, Moria KM. Flatfeet severity-level detection based on alignment measuring. *Sensors* 2023;23(19):8219. doi: [10.3390/s23198219](https://doi.org/10.3390/s23198219)
- [36]. Mun F, Choi A. Deep learning approach to estimate foot pressure distribution in walking with application for a cost-effective insole system. *J Neuroeng Rehabil* 2022;19(1):4. doi: [10.1186/s12984-022-00987-8](https://doi.org/10.1186/s12984-022-00987-8)
- [37]. Ning X, Ru T, Zhu J, Wu L, Chen L, Ma X, et al. Deep learning-assisted segmentation of X-ray images for rapid and accurate assessment of foot arch morphology and plantar soft tissue thickness. *Sci Rep* 2024;14(1):20028. doi: [10.1038/s41598-024-71025-x](https://doi.org/10.1038/s41598-024-71025-x)
- [38]. Li PL, Xiao QF, Yick KL, Liu QL, Zhang LY. A novel deep learning approach to classify 3D foot types of diabetic patients. *Sci Rep* 2025;15(1):13819. doi: [10.1038/s41598-025-98471-5](https://doi.org/10.1038/s41598-025-98471-5)