

## Automatic Detection of Breast Cancer from Digital Mammography Images By YOLO Artificial Intelligence Algorithm

Zahra Samadi<sup>1</sup>, Mohammad Norouzi<sup>2✉</sup>, Seyyed Omid Shahdi<sup>2</sup>, Mona Haddad Zahmat Kesh<sup>3</sup>

1. Department of Biomedical Engineering, Qa.c., Islamic Azad University, Qazvin, Iran

2. Department of Electrical Engineering, Qa.C., Islamic Azad University, Qazvin, Iran

3. Department of Pharmaceutical Biotechnology-Nuclear Pharmacy, School of Pharmacy, Guilan University of Medical Sciences, Rasht, Iran

Received: 2025/12/04  
Accepted: 2026/02/16

\*Corresponding Author:  
mh.norouzi@iaau.ac.ir

Ethics Approval:  
not applicable

### Abstract

**Introduction:** Early detection of breast cancer in digital mammography remains technically challenging, particularly for small or low-contrast lesions embedded within dense fibroglandular tissue. Structural noise and subtle lesion margins often reduce localization accuracy and increase false-negative interpretations in screening settings. To address these limitations, this study proposes a lightweight object-detection framework based on YOLOv11n, enhanced with targeted preprocessing and heatmap-guided spatial attention to improve lesion detectability and localization precision.

**Methods:** Digital mammography images from the VinDr-Mammo dataset were used for model development and evaluation under standardized training conditions. The proposed framework incorporated contrast-limited adaptive histogram equalization (CLAHE), bilateral filtering, and spatial attention guidance during training. Performance was quantitatively assessed using Precision, Recall, mean Average Precision (mAP@0.5 and mAP@0.5:0.95), and inference time, and compared against YOLOv5, YOLOv8, EfficientDet-D0, and Faster R-CNN.

**Results:** The YOLOv11n-based framework achieved precision of 70.24%, recall of 68.01%, mAP@0.5 of 68.28%, and mAP@0.5:0.95 of 40.82%. Compared with reference models, the proposed approach improved mAP@0.5 by 6–9% and Recall by 5–7%, while maintaining real-time inference speed (<40 ms per image). The increase in Recall reflects a measurable reduction in false-negative detections, which is clinically relevant for early-stage lesion identification. Concurrently, the maintained Precision indicates controlled false-positive rates, supporting the practical applicability of screening.

**Conclusion:** The proposed YOLOv11n-based framework demonstrates robust detection performance and real-time feasibility, suggesting its potential as a pre-clinical decision-support module for mammography CAD systems. However, external multi-center validation, radiologist-in-the-loop studies, and workflow integration assessment are required before clinical deployment.

**Keywords:** Breast Cancer; Digital Mammography; Heatmap; YOLOv11; Computer-Aided Diagnosis



## Introduction

Breast cancer screening using digital mammography aims to detect early-stage lesions before clinical symptoms emerge; however, diagnostic sensitivity decreases in cases involving small (<5 mm), low-contrast, or dense-tissue-embedded masses. These diagnostic ambiguities directly affect lesion-level detection accuracy rather than merely image-level classification, underscoring the need for precise localization algorithms.

Computer-aided diagnosis (CAD) systems have been developed to support radiologists by improving diagnostic consistency and reducing workload. Early CAD systems relied on handcrafted features and classical machine learning classifiers, such as Support Vector Machines (SVMs), k-Nearest Neighbors (KNNs), and Ensemble Tree Classifiers (ETCs). In mammography, these approaches are limited by their dependence on manually engineered texture descriptors and their inability to robustly model multi-scale spatial relationships between lesion morphology and surrounding parenchymal patterns, leading to reduced localization robustness in dense breasts.

More recently, deep learning, particularly CNN-based methods, has achieved notable success in medical image analysis. However, many CNN-based mammography studies have primarily focused on image-level classification (benign vs. malignant), rather than lesion-level detection and bounding-box localization. This classification-centric paradigm does not directly address the clinical requirement for spatially explicit lesion delineation necessary for biopsy planning, interval change monitoring, and structured reporting.

Object detection architectures, such as Faster R-CNN, EfficientDet, and YOLO (You Only Look Once), offer a promising alternative by simultaneously performing classification and localization. Among these, YOLO-based models are particularly attractive due to their single-stage design and real-time inference capabilities. Nevertheless, a clear gap remains in optimizing lightweight object detectors for mammographic constraints, including dense breast texture interference, subtle lesion boundaries, and the need for real-time performance without compromising localization precision.

To address these challenges, this study proposes an optimized YOLOv11n-based

framework tailored for digital mammography. By integrating targeted preprocessing and spatial attention guidance, the proposed approach aims to enhance lesion detectability while preserving real-time performance suitable for clinical CAD applications.

## Materials and Methods

This study developed and evaluated a real-time deep learning-based detection framework for automated breast lesion localization using the publicly available VinDr-Mammo dataset, which contains high-resolution full-field digital mammograms with radiologist-annotated bounding boxes for breast masses. The dataset includes diverse breast density categories and lesion sizes, enabling evaluation under clinically heterogeneous imaging conditions. The experimental workflow was structured in three progressive stages: (1) Baseline images without preprocessing (Stage A), (2) Contrast-enhanced and denoised images (Stage B), and (3) Contrast-enhanced images with integrated heatmap-guided spatial attention during training (Stage C). These stage labels replace the earlier 1D/2D/3D terminology to avoid dimensional ambiguity and clarify that all inputs remain two-dimensional mammographic images. Targeted preprocessing included Contrast Limited Adaptive Histogram Equalization (CLAHE) to enhance local contrast and bilateral filtering to suppress high-frequency noise while preserving edge information, particularly in dense breast tissues. In the final stage, heatmap-guided spatial attention was integrated during training to implicitly direct the model toward clinically relevant regions and improve sensitivity to subtle lesions. The YOLOv11n architecture was selected as the primary detection backbone due to its lightweight design and suitability for real-time inference. For comparative evaluation, YOLOv5, YOLOv8, EfficientDet-D0, and Faster R-CNN were implemented under identical training conditions. Models were trained using transfer learning with standardized hyperparameters, including fixed input resolution, batch size, optimizer configuration, and early stopping criteria. Performance evaluation was conducted using Precision, Recall, mAP@0.5, mAP@0.5:0.95, Box Loss convergence analysis, and inference time per image. Statistical significance across dataset configurations was assessed using paired t-tests on per-image detection metrics,

with  $p < 0.05$  considered statistically significant. The unit of comparison was per-image performance across matched test samples, ensuring reproducibility and methodological transparency. This structured methodology enabled a systematic analysis of both architectural impact and preprocessing contribution to detection accuracy and clinical feasibility.

## Results

The experimental results demonstrated that the YOLOv11n-based framework achieved precision of 70.24%, recall of 68.01%, mAP@0.5 of 68.28%, and mAP@0.5:0.95 of 40.82%.

Compared with Faster R-CNN (Precision 61.3%, Recall 59.8%) and EfficientDet-D0

(Precision 64.7%, Recall 61.5%), the proposed model demonstrated balanced improvements across sensitivity- and specificity-related metrics. The 6–9% gain in mAP@0.5 indicates more accurate bounding-box alignment, particularly in small lesion scenarios.

The incorporation of heatmap-guided spatial attention reduced the average false-positive detections per image by approximately 0.08 and false-negative detections by approximately 0.06 in Stage C compared with Stage A ( $p < 0.05$ ), providing quantitative support for the claim of performance improvement rather than relying solely on descriptive assertions.

Inference time remained below 40 ms per image, compared to approximately 76 ms for Faster R-CNN.

**Table 1: Performance Comparison between YOLO Architectures on VinDr-Mammo Dataset**

| Model           | mAP <sub>0.5</sub> (%) | mAP <sub>0.5:0.95</sub> (%) | Precision    | Recall       | F1-Score    |
|-----------------|------------------------|-----------------------------|--------------|--------------|-------------|
| Faster R-CNN    | 59.4                   | 34.1                        | 61.3         | 59.8         | -           |
| EfficientDet-D  | 61.8                   | 36.9                        | 64.7         | 61.5         | -           |
| YOLOv5n         | 60.7                   | 37.2                        | 63.9         | 62.4         | 0.64        |
| YOLOv8n         | 65.3                   | 38.6                        | 66.1         | 64.9         | 0.67        |
| <b>YOLOv11n</b> | <b>68.28</b>           | <b>40.82</b>                | <b>70.24</b> | <b>68.01</b> | <b>0.71</b> |

## Discussion

The results indicate that the superior performance of the proposed YOLOv11n framework arises from the combined effect of targeted preprocessing, heatmap-guided spatial attention, and an optimized lightweight detection architecture. CLAHE enhanced local contrast around lesion boundaries, while bilateral filtering reduced background noise without degrading structural detail. These preprocessing steps improved feature separability in dense breast tissue. In addition, heatmap-guided spatial attention directed the network toward clinically relevant regions during training, thereby improving sensitivity for small and low-contrast lesions and reducing false-positive activations in fibroglandular areas.

From an architectural perspective, YOLOv11n achieved a favorable balance between detection accuracy and computational efficiency. Compared with two-stage detectors such as Faster R-CNN, the single-stage design reduced inference latency while maintaining competitive localization performance. Compared with EfficientDet-D0, the model demonstrated greater robustness to dense mammographic patterns, suggesting improved

adaptation to small-object detection in complex anatomical backgrounds. The real-time inference capability (<40 ms per image) supports feasibility for integration into high-throughput screening workflows.

However, several limitations must be considered. The evaluation was conducted on a single public dataset, limiting generalizability across imaging devices, acquisition protocols, and patient populations. Pixel-level segmentation accuracy was not assessed, and no prospective radiologist-in-the-loop validation was performed. Therefore, the framework should be regarded as a pre-clinical decision-support prototype rather than a fully validated clinical tool.

For clinical translation, external multi-center validation, structured reader studies, workflow integration assessment, and regulatory evaluation are required. The most practical near-term application would be as a second-reader or triage module within CAD systems, where threshold calibration and false-positive management must be carefully optimized. Overall, while technically promising, the clinical impact of the proposed model depends on rigorous validation and integration within real-world diagnostic settings.

## Conclusion

This study presents a technically robust and computationally efficient breast lesion detection framework that demonstrates measurable improvements in localization accuracy and inference speed under controlled experimental evaluation. However, due to single-dataset training and the absence of

prospective clinical validation, the generalizability of the results remains to be confirmed. The proposed framework should be considered a promising research-stage CAD component requiring external validation before clinical translation. Future work will focus on multi-center validation, multi-modal data integration, and prospective clinical evaluation.

## References

1. Brockton NT, Cook LS, Magliocco AM, Shemanko CS, Vogel HJ, Khan M, et al. The Breast to Bone (B2B) Cohort Study to Prevent, Detect, and Improve Treatment of Metastatic Disease: Baseline Assessment, Description, and Progress. *Int J Environ Res Public Health*. 2025;22(2):242. doi: 10.3390/ijerph22020242.
2. Wang H, Liu J, Liu K. The screening value of mammography for breast cancer: an overview of 28 systematic reviews with evidence-mapping. *J Cancer Res Clin Oncol*. 2025;151(4):842-854
3. Ciurescu S, Cerbu S, Dima CN, Borozan F, Părvănescu R, Ilaş DG, Cîtu C, Vernic C, Sas I. AI in 2D Mammography: Improving Breast Cancer Screening Accuracy. *Medicina (Kaunas)*. 2025;61(5):809. doi: 10.3390/medicina61050809.
4. Dadzie AK, Iddir SP, Ganesh S, Ebrahimi B, Rahimi M, Abtahi M, et al. Artificial intelligence in the diagnosis of uveal melanoma: advances and applications. *Exp Biol Med (Maywood)*. 2025;250:10444. doi: 10.3389/ebm.2025.10444.
5. Obuchowicz B, Zarzecka J, Strzelecki M, Jakubowska M, Obuchowicz R, Piórkowski A, et al. Improving Endodontic Radiograph Interpretation with TV-CLAHE for Enhanced Root Canal Detection. *J Clin Med*. 2025;14(15):5554. doi: 10.3390/jcm14155554.
6. Kernick K, Woudstra R, Berjanskii M, MacKay S, Wishart DS. Heatmapper2: web-enabled heat mapping made easy. *Nucleic Acids Res*. 2025;53(W1):W316-W323. doi: 10.1093/nar/gkaf385.

# تشخیص خودکار سرطان پستان از تصاویر ماموگرافی دیجیتال با استفاده از الگوریتم هوش مصنوعی YOLO

مجله علمی  
بیماری‌های پستان ایران  
۱۴۰۵؛ ۱۹(۱): ۳۱-۴۸

زهرا صمدی<sup>۱</sup>، محمد نوروزی<sup>۲</sup>، سید امید شهدی<sup>۳</sup>، مونا حداد زحمت‌کش<sup>۳</sup>

<sup>۱</sup>گروه مهندسی پزشکی، مهندسی برق، مکترونیک و مهندسی پزشکی، دانشگاه آزاد قزوین، قزوین، ایران  
<sup>۲</sup>گروه مهندسی برق، دانشکده مهندسی برق، مکترونیک و مهندسی پزشکی، دانشگاه آزاد قزوین، قزوین، ایران  
<sup>۳</sup>گروه بیوتکنولوژی دارویی و داروسازی هسته‌ای، دانشکده داروسازی، دانشگاه علوم پزشکی گیلان، رشت، ایران

## چکیده

**مقدمه:** سرطان پستان یکی از شایع‌ترین و مرگ‌بارترین سرطان‌ها در میان زنان است و تشخیص زودهنگام آن نقش تعیین‌کننده‌ای در موفقیت درمان دارد. با وجود پیشرفت‌های ماموگرافی، تشخیص دقیق تومورهای کوچک یا کم‌کنتراست، به‌ویژه در کاربردهای زمان‌لحظه‌ای، همچنان چالش‌برانگیز است. در حالی که بیشتر مطالعات پیشین بر طبقه‌بندی کلی تصاویر تمرکز داشته‌اند، مکان‌یابی دقیق ضایعات کمتر مورد توجه قرار گرفته است. پژوهش حاضر با هدف رفع این خلأ، یک سامانه‌ی هوشمند مبتنی بر مدل YOLOv11n را همراه با پیش‌پردازش هدفمند و نقشه‌های حرارتی برای شناسایی و مکان‌یابی خودکار تومورهای پستان در تصاویر ماموگرافی دیجیتال ارائه می‌دهد.

تاریخ ارسال: ۱۴۰۴/۰۹/۱۳  
تاریخ پذیرش: ۱۴۰۴/۱۱/۲۷

نویسنده مسئول:  
mh.norouzi@iau.ac.ir

**روش بررسی:** در این مطالعه، تصاویر ماموگرافی دیجیتال از پایگاه داده VinDr-Mammo استخراج و به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند. به‌منظور بهبود کیفیت داده‌ها، از داده‌افزایی هدفمند، بهبود کنتراست با روش CLAHE، فیلتر دوطرفه و تولید نقشه‌های حرارتی استفاده شد. سپس عملکرد مدل‌های YOLO و مرجع تحت شرایط یکسان با استفاده از شاخص‌های Recall، Precision و میانگین دقت (mAP<sub>0.5</sub> و mAP<sub>0.5:0.95</sub>) ارزیابی گردید.

**یافته‌ها:** نتایج نشان داد مدل مبتنی بر YOLOv11n بهترین عملکرد را با Precision= ۷۰/۲۴، Recall= ۶۸/۰۱ و mAP<sub>0.5</sub>= ۶۸/۲۸ و mAP<sub>0.5:0.95</sub>= ۴۰/۸۲ به دست آورد. همچنین، این مدل نسبت به YOLOv5 و Faster R-CNN بهبود ۶ تا ۹ درصدی در دقت مکان‌یابی ضایعات و زمان استنتاج کمتر از ۴۰ میلی‌ثانیه را نشان داد. استفاده از نقشه‌های حرارتی موجب کاهش مثبت‌های کاذب در پستان‌های متراکم و افزایش حساسیت در تشخیص توده‌های کوچک شد.

**نتیجه‌گیری:** رویکرد پیشنهادی جدید مبتنی بر ترکیب YOLOv11n و نقشه حرارتی می‌تواند به‌عنوان یک راهکار سریع، پایدار و دقیق در سامانه‌های کمک‌تشخیصی بالینی مورد استفاده قرار گیرد و با کاهش بار کاری رادیولوژیست‌ها، نقش مؤثری در تشخیص زودهنگام سرطان پستان ایفا کند.

**واژه‌های کلیدی:** سرطان پستان، ماموگرافی دیجیتال، سامانه کمک تشخیصی، نقشه حرارتی، الگوریتم YOLO

## مقدمه

سرطان پستان یک بیماری شایع و مرگ‌بار در میان زنان سراسر جهان است و سهم قابل توجهی از مرگ‌ومیر ناشی از سرطان را به خود اختصاص می‌دهد (۱). طبق گزارش GLOBOCAN 2022، سالانه بیش از ۲/۳ میلیون مورد جدید از سرطان پستان در جهان شناسایی می‌شود که حدود ۱۲ درصد از کل موارد سرطان‌ها را شامل می‌گردد (۲). تشخیص زودهنگام تومورهای پستان، به‌ویژه در مراحل اولیه، درمان موفق و کاهش عوارض ناشی از پیشرفت بیماری بسیار موثر است (۳). اهمیت این موضوع در کشورهای در حال توسعه، از جمله ایران، بسیار بالا است. نکته نگران‌کننده آن است که میانگین سن ابتلا به سرطان پستان در زنان ایرانی حدود یک دهه کمتر از میانگین جهانی گزارش شده است؛ به‌طوری‌که بخش قابل توجهی از بیماران در سنین پیش‌ازبایستی تشخیص داده می‌شوند. این ویژگی اپیدمیولوژیک، اهمیت غربالگری زودهنگام، تشخیص دقیق و استفاده از ابزارهای تشخیصی کم‌خطا را در نظام سلامت ایران دوچندان می‌سازد. علاوه بر این، محدودیت‌های دسترسی به خدمات تشخیصی پیشرفته در برخی مناطق کشور، نیاز به راهکارهای هوشمند، مقرون‌به‌صرفه و قابل‌انکاف را افزایش داده است (۴).

ماموگرافی به عنوان رایج‌ترین روش جهت غربالگری سرطان پستان شناخته می‌شود، زیرا می‌تواند ضایعات را پیش از ظهور علائم بالینی آشکار شناسایی کند (۵). مطالعات متعدد نشان داده‌اند که خطاهای انسانی در تفسیر ماموگرافی که ناشی از تداخل بافتی، نویز بالا، تفاوت چگالی بافت پستان و پیچیدگی الگوهای تصویری است، می‌تواند منجر به مثبت‌های کاذب، منفی‌های کاذب و در نتیجه انجام بی‌وفایی‌های غیرضروری یا تأخیر در تشخیص شود. این مسئله نه‌تنها پیامدهای بالینی و روانی برای بیماران دارد، بلکه هزینه‌های نظام سلامت را نیز افزایش می‌دهد (۶،۷). بر اساس یک مطالعه ملی، که داده‌های ۲۰۱۰ تا ۲۰۲۱ را تحلیل کرده، نشان داده شده است که میزان مرگ‌ومیر و سال‌های زندگی از دست‌رفته بر اثر سرطان پستان نیز در بسیاری از استان‌ها افزایش یافته، که این امر ضرورت تقویت زیرساخت‌های غربالگری و به‌کارگیری راهکارهای تشخیصی سریع و دقیق‌تر را، به‌ویژه در مناطق با منابع محدود، برجسته می‌سازد (۸).

در سال‌های اخیر، از هوش مصنوعی (Artificial Intelligence) و یادگیری عمیق (Deep Learning) در تحلیل تصاویر پزشکی بسیار استفاده می‌شود. این فناوری‌ها با استفاده از شبکه‌های عصبی، قابلیت استخراج خودکار ویژگی‌ها و تحلیل پیچیده‌ترین الگوهای بافتی را دارند (۹). از این‌رو، توسعه سامانه‌های کمک‌تشخیصی (Computer-Aided Diagnosis; CAD) مبتنی بر هوش مصنوعی به‌عنوان ابزارهای پشتیبان تصمیم‌گیری بالینی، به یک ضرورت اجتناب‌ناپذیر در تصویربرداری پزشکی تبدیل شده است؛ سامانه‌هایی که بتوانند با دقت بالا، سرعت مناسب و قابلیت اعتماد، رادیولوژیست را در تشخیص ضایعات پستان یاری دهند (۱۰). این اهمیت در زمینه‌ی ایران نیز کاملاً محسوس است، چراکه افزایش بار بیماری و افزایش فشار بر مراکز تشخیصی، نیاز به تکنولوژی‌های پشتیبان با تفسیر سریع‌تر و خطای کمتر را برجسته می‌کند. داده‌های ملی نشان داده‌اند که باوجود تلاش‌های مستمر برای گسترش خدمات غربالگری، هنوز چالش‌های جدی در توزیع عدالت دسترسی و تشخیص زودهنگام وجود دارد، که می‌تواند با به‌کارگیری سامانه‌های هوش مصنوعی بهبود یابد (۸).

با وجود پیشرفت‌های چشمگیر در به‌کارگیری یادگیری عمیق در تحلیل تصاویر ماموگرافی، بخش قابل توجهی از پژوهش‌های پیشین بر طبقه‌بندی کلی تصاویر (سالم/بیمار) متمرکز بوده‌اند و در مکان‌یابی دقیق توده‌ها، به‌ویژه ضایعات کوچک یا کم‌کنتراست، عملکرد محدودی داشته‌اند (۱۱). همچنین، بسیاری از مدل‌های پیشنهادی از معماری‌های سنگین با هزینه محاسباتی بالا استفاده کرده‌اند که کاربرد آن‌ها را در محیط‌های بالینی واقعی با محدودیت مواجه می‌سازد. علاوه بر این، ارزیابی مقایسه‌ای و نظام‌مند معماری‌های مختلف تشخیص اشیاء در زمان لحظه‌ای، به‌ویژه نسخه‌های جدید خانواده (You Only Look Once) YOLO، در حوزه ماموگرافی دیجیتال به‌طور جامع مورد بررسی قرار نگرفته است. این محدودیت‌ها به‌ویژه در نظام سلامت کشورهایمانند ایران، که نیازمند راهکارهای سریع، کم‌هزینه و قابل پیاده‌سازی در مراکز تشخیصی با منابع محدود هستند، اهمیت بیشتری پیدا می‌کند. از این‌رو، نیاز به مدل‌هایی که علاوه بر دقت بالا، از نظر سرعت استنتاج و مصرف منابع محاسباتی نیز بهینه باشند، به‌عنوان یک چالش کلیدی مطرح است.

پیامدهای بالینی و پیشنهادهایی برای تحقیقات آینده به پایان می‌رسد.

## مواد و روش‌ها

### نوع مطالعه

این پژوهش از نوع مطالعه‌ی توسعه و ارزیابی مدل در حوزه‌ی مهندسی پزشکی و پردازش تصاویر پزشکی با هدف تحقیق، طراحی، آموزش و ارزیابی یک سامانه‌ی هوشمند مبتنی بر الگوریتم YOLO جهت تشخیص خودکار تومورهای پستان در تصاویر ماموگرافی است. فرایند کلی پژوهش شامل مراحل جمع‌آوری داده، پیش‌پردازش و داده‌افزایی، آموزش مدل‌ها، ارزیابی کمی عملکرد و تحلیل تطبیقی نتایج بود. به‌منظور اطمینان از صحت مقایسه، کلیه مدل‌ها تحت شرایط آزمایشی یکسان آموزش و ارزیابی شدند.

### جامعه‌ی داده و روش نمونه‌گیری

داده‌های مورد استفاده از پایگاه داده‌ی VinDr-Mammo استخراج شدند؛ این پایگاه یکی از مجموعه‌های عمومی و معتبر در زمینه‌ی ماموگرافی دیجیتال است که تصاویر را با وضوح بالا و همراه با برچسب‌گذاری رادیولوژیست‌های متخصص ارائه می‌دهد. این پایگاه داده دارای اطلاعات مکان‌یابی توده‌ها به‌صورت کادرهای مرزی ( Bounding Box) به همراه برچسب‌های تشخیصی می‌باشد. هر تصویر شامل دو نما از هر پستان است: نمای کرانیوکودال (CC) و مایل-جانبی (MLO) (۱۷).

برای افزایش دقت و کاهش سوگیری، تنها تصاویری وارد فرایند آموزش و ارزیابی شدند که دارای کیفیت تشخیصی مناسب و حاوی نواحی دارای توده یا کلسیفیکاسیون تأییدشده توسط سه رادیولوژیست خبره بودند. تصاویر دارای نویز شدید، برچسب‌گذاری ناقص یا حاشیه‌های غیرتشخیصی از مطالعه حذف گردیدند. نمونه‌ها به‌صورت تصادفی و با حفظ توازن میان تصاویر دارای ضایعه و تصاویر طبیعی به سه مجموعه‌ی آموزش (۸۰ درصد)، اعتبارسنجی (۱۰ درصد) و آزمون (۱۰ درصد) تقسیم شدند، تا از نشت اطلاعات بین مجموعه‌ها جلوگیری شود.

به‌منظور بررسی تأثیر مراحل مختلف پیش‌پردازش، داده‌ها در سه سطح تعریف شدند:

الگوریتم YOLO به‌عنوان یکی از پیشرفته‌ترین روش‌های تشخیص اشیاء در زمان لحظه‌ای، به دلیل توازن مناسب میان دقت و سرعت، گزینه‌ای جذاب برای کاربردهای بالینی محسوب می‌شود (۱۲). در میان نسخه‌های مختلف این خانواده، YOLOv11n به‌عنوان معماری سبک‌تر و بهینه‌شده، پتانسیل بالایی برای کاهش هزینه محاسباتی و افزایش قابلیت پیاده‌سازی در سامانه‌های بالینی دارد (۱۳). انتخاب YOLOv11n در این پژوهش مبتنی بر این فرض است که معماری‌های سبک‌تر، در صورت طراحی و آموزش مناسب، می‌توانند بدون افت قابل‌توجه دقت، پاسخگوی نیازهای تشخیص فوری در محیط‌های واقعی ماموگرافی باشند. نوآوری اصلی پژوهش حاضر در ارزیابی مقایسه‌ای معماری‌های YOLOv5، YOLOv8، YOLOv11n و همچنین ارائه یک روش ترکیبی مبتنی بر YOLOv11n همراه با پیش‌پردازش هدفمند (شامل CLAHE و Bilateral Filtering) و استفاده از نقشه‌های حرارتی برای هدایت توجه مکانی مدل است.

در این روش، از روش بهبود کنتراست تطبیقی محدودشده (CLAHE: Contrast Limited Adaptive Histogram Equalization) به‌منظور افزایش وضوح ضایعات کم‌کنتراست، از فیلتر دوطرفه برای کاهش نویز همراه با حفظ لبه‌ها و از نقشه‌های حرارتی برای تقویت تمرکز مکانی مدل بر نواحی مشکوک استفاده شده است؛ راهبردهایی که به‌طور هدفمند برای غلبه بر چالش‌های ذاتی تصاویر ماموگرافی انتخاب شده‌اند (۱۴-۱۶).

هدف اصلی این پژوهش، طراحی و ارزیابی یک سامانه‌ی هوشمند برای شناسایی و مکان‌یابی دقیق توده‌های پستانی در تصاویر ماموگرافی است. اهداف ویژه‌ی این پژوهش عبارت‌اند از طراحی مدل تشخیص خودکار تومورهای پستان با دقت بالا و بررسی قابلیت کاربرد این مدل در سامانه‌های کمک‌تشخیصی بالینی برای تشخیص زودهنگام سرطان پستان. در ادامه، ابتدا مواد و روش‌های پژوهش شامل توصیف پایگاه داده، مراحل پیش‌پردازش، معماری مدل و معیارهای ارزیابی ارائه می‌شود. سپس نتایج کمی و کیفی حاصل از مقایسه مدل‌ها گزارش و تحلیل می‌گردد. در بخش بحث، یافته‌ها در مقایسه با مطالعات پیشین تفسیر شده و نقاط قوت و محدودیت‌های پژوهش مورد بررسی قرار می‌گیرد. درنهایت، مقاله با نتیجه‌گیری و ارائه

تشخیص و هزینه محاسباتی انتخاب شد. در این مطالعه، تغییری در ساختار اصلی معماری‌ها اعمال نشد، اما تنظیمات آموزشی و ابعاد ورودی متناسب با تصاویر ماموگرافی بهینه‌سازی گردید.

آموزش تمامی مدل‌ها با استفاده از بهینه‌ساز AdamW، نرخ یادگیری ۰/۰۰۲، اندازه دسته ۱۶ و اندازه‌ی ورودی تصاویر در مدل برابر با  $1024 \times 1024$  پیکسل تعیین شد تا جزئیات ریز بافتی در تصاویر ماموگرافی حفظ شود. برای بهبود تعمیم‌پذیری مدل، از داده‌افزایی‌های مختلفی مانند چرخش تصادفی، وارون‌سازی افقی، تغییر مقیاس و تغییر شدت روشنایی استفاده شد.

### شاخص‌های ارزیابی عملکرد مدل

جهت ارزیابی عملکرد مدل، از شاخص‌های استاندارد تشخیص اشیا شامل دقت (Precision)، حساسیت (Recall) و میانگین دقت متوسط (Mean Average Precision: mAP) استفاده گردید.

دو شاخص اصلی:

- $mAP_{0.5}$ : میانگین دقت در آستانه‌ی هم‌پوشانی ۰/۵ ( $IOU = 0.5$ )
- $mAP_{0.5:0.95}$ : میانگین دقت در بازه‌ی آستانه‌های ۰/۵ تا ۰/۹۵

علاوه بر این، نرخ مثبت کاذب (False Positive) و منفی کاذب (False Negative) به‌طور مشخص محاسبه و تحلیل گردید.

لازم به ذکر است که انتخاب شاخص‌های Precision، Recall و mAP به‌عنوان معیارهای اصلی ارزیابی، مبتنی بر الزامات بالینی سامانه‌های کمک‌تشخیصی ماموگرافی انجام شده است. در کاربردهای CAD، حساسیت بالا (Recall) برای جلوگیری از دست رفتن ضایعات بدخیم و کاهش منفی‌های کاذب از اهمیت حیاتی برخوردار است، در حالی که Precision بالا نقش مهمی در کاهش مثبت‌های کاذب، جلوگیری از ارجاع‌های غیرضروری و کاهش بار کاری رادیولوژیست‌ها ایفا می‌کند. شاخص mAP نیز به‌عنوان معیار ترکیبی، توانایی مدل را در تشخیص و مکان‌یابی دقیق ضایعات در سطوح مختلف هم‌پوشانی بیان می‌نماید. از این‌رو، مفید بودن یا نبودن مدل‌های پیشنهادی در این پژوهش نه صرفاً بر اساس دقت کلی، بلکه بر پایه‌ی

- D1: تصاویر خام با برچسب‌های اصلی،
- D2: تصاویر با بهبود کنتراست و حذف نویز،
- D3: مجموعه‌ی نهایی شامل تصاویر بهینه‌سازی‌شده و داده‌افزایی هدفمند.

### پیش‌پردازش و بهبود کیفیت تصاویر

جهت بهبود وضوح و افزایش قابلیت تشخیص توده‌های کم‌کنتراست، چند مرحله پیش‌پردازش انجام شد. در قدم اول از روش بهبود کنتراست محدودشده (CLAHE) برای افزایش کنتراست موضعی ضایعات استفاده شد تا جزئیات بافتی در نواحی با شدت خاکستری پایین تقویت شود. سپس فیلتر دوطرفه (Bilateral Filtering) به‌منظور کاهش نویز و حفظ لبه‌های ساختاری بافت پستان به کار گرفته شد. همچنین، داده‌افزایی هدفمند شامل چرخش کنترل‌شده، وارونگی افقی، تغییر مقیاس و تنظیم کنتراست انجام شد. این داده‌افزایی‌ها به‌طور خاص با هدف افزایش پایداری مدل در شناسایی توده‌های کوچک و کم‌کنتراست طراحی شدند که در بسیاری از سامانه‌های کمک‌تشخیصی متداول نادیده گرفته می‌شوند.

### استفاده از نقشه‌های حرارتی برای هدایت توجه مکانی

به‌منظور بهبود تمرکز مدل بر نواحی دارای اهمیت تشخیصی و مکان‌یابی دقیق ضایعات، از تحلیل نقشه‌های حرارتی دوطرفه مبتنی بر نواحی توده استفاده شد. این نقشه‌ها در فرایند آموزش به مدل کمک کردند تا تمرکز مکانی خود را بر نواحی بالینی مهم افزایش دهد و اثر نواحی پس‌زمینه و بافت‌های متراکم غیرمرتبط کاهش یابد. استفاده از این رویکرد موجب کاهش مثبت‌های کاذب و افزایش حساسیت مدل در تشخیص ضایعات شد.

### معماری مدل آموزشی

مدل آموزشی بر پایه‌ی الگوریتم YOLO است. این مدل یک معماری پیشرفته جهت تشخیص اشیاء در لحظه است که قادر به شناسایی دقیق توده‌های پستانی می‌شود. در این پژوهش، سه معماری مبتنی بر YOLO شامل YOLOv5، YOLOv8 و YOLOv11n مورد ارزیابی قرار گرفتند (۱۹ و ۱۸). مدل YOLOv11n به‌عنوان نسخه‌ای سبک و بهینه‌شده، با هدف ایجاد توازن میان دقت

نظر دقت تشخیص، مکان‌یابی، سرعت استنتاج و نرخ خطا مقایسه گردید (۲۱-۱۸)، که ضمن دستیابی به دقت و حساسیت بالاتر، از پایداری تشخیص مناسب و زمان پاسخ‌گویی سازگار با کاربردهای بالینی فوری برخوردار باشد. این رویکرد امکان ارزیابی هم‌زمان عملکرد تشخیصی و قابلیت پیاده‌سازی عملی در سامانه‌های CAD را فراهم می‌سازد.

### خلاصه روش‌شناسی

تعریف شفاف شاخص‌های ارزیابی، راهبرد مقایسه منصفانه و ثبت دقیق زمان استنتاج، این امکان را فراهم می‌سازد که نتایج پژوهش حاضر نه تنها از منظر الگوریتمی، بلکه از دیدگاه کاربرد بالینی نیز قابل تفسیر و ارزیابی باشند. بدین ترتیب، روش پیشنهادی می‌تواند به‌عنوان مبنایی برای تصمیم‌گیری در انتخاب معماری مناسب جهت توسعه سامانه‌های کمک‌تشخیصی ماموگرافی در محیط‌های واقعی مورد استفاده قرار گیرد.

به‌منظور افزایش قابلیت بازتولیدپذیری پژوهش، تمامی تنظیمات آموزشی، پارامترهای شبکه و مراحل پیش‌پردازش به‌صورت استاندارد و شفاف تعریف شدند. استفاده از پایگاه داده عمومی و معماری‌های متن‌باز، امکان تکرار و توسعه پژوهش حاضر را برای سایر محققان فراهم می‌سازد.

توازن میان حساسیت، دقت مکان‌یابی و نرخ خطاهای تشخیصی ارزیابی شده است.

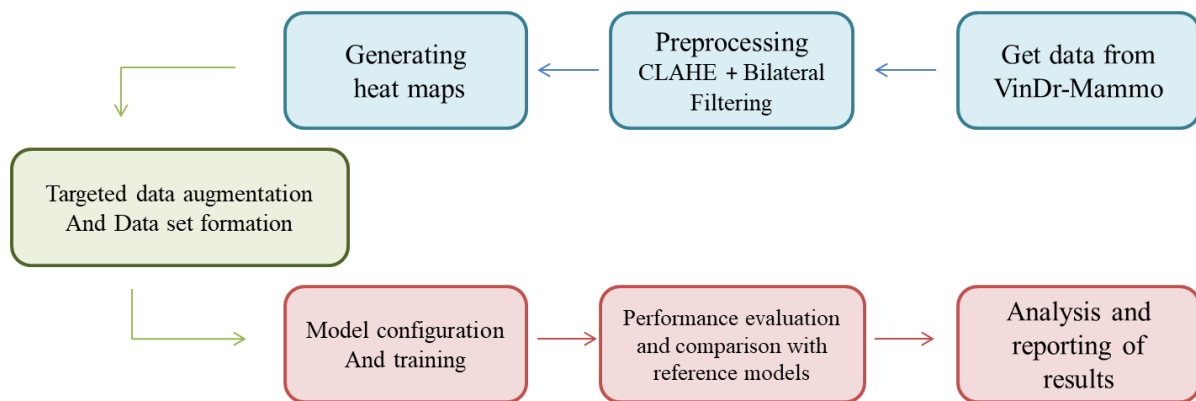
### محیط اجرایی و مشخصات سخت‌افزاری

کلیه مدل‌سازی بر روی یک ایستگاه کاری مجهز به پردازنده گرافیکی NVIDIA، حافظه RAM معادل ۳۲ گیگابایت و پردازنده چند هسته‌ای انجام شد. و در محیط برنامه‌نویسی Python با استفاده از چارچوب PyTorch اجرا شدند. فرآیند آموزش روی یک سیستم مجهز به پردازنده Intel Core i9 انجام شد.

به‌منظور ثبت کامل نتایج و اطمینان از قابلیت بازتولید، کلیه تنظیمات مدل، وزن‌ها و داده‌ها توسط سامانه‌ی Weights & Biases ذخیره‌سازی شد. همچنین زمان آموزش، زمان استنتاج و میزان مصرف منابع محاسباتی برای هر مدل ثبت گردید تا قابلیت استفاده در محیط‌های بالینی واقعی مورد ارزیابی قرار گیرد.

### راهبرد مقایسه با روش‌های پیشین

به‌منظور انجام یک مقایسه منصفانه، کلیه مدل‌ها با استفاده از مجموعه داده یکسان، پیش‌پردازش مشابه و معیارهای ارزیابی یکسان آموزش و آزمون شدند. عملکرد مدل YOLOv11n با مدل‌های مرجع شامل YOLOv5، YOLOv8، Faster R-CNN و EfficientDet-D0 از



شکل ۱: الگوریتم پیشنهادی شناسایی خودکار توده‌های پستان مبتنی بر YOLO

Fig 1: Proposed YOLO-based algorithm for automatic breast tumor detection

### مراحل الگوریتم

۱. دریافت داده‌ها: تصاویر ماموگرافی دیجیتال و برچسب‌های مربوطه از پایگاه داده VinDr-Mammo بارگذاری می‌شوند.
۲. تقسیم داده‌ها: مجموعه داده به سه بخش آموزش، اعتبارسنجی و آزمون به نسبت ۸۰٪، ۱۰٪ و ۱۰٪ تقسیم می‌شود.
۳. پیش‌پردازش تصاویر: برای هر تصویر ورودی:

۱. دریافت داده‌ها: تصاویر ماموگرافی دیجیتال و برچسب‌های مربوطه از پایگاه داده VinDr-Mammo بارگذاری می‌شوند.

۹. مقایسه با مدل‌های مرجع: نتایج مدل پیشنهادی با YOLOv8، YOLOv5 و Faster R-CNN و EfficientDet-D0 از نظر دقت، سرعت و نرخ خطا مقایسه می‌شود.

۱۰. تحلیل و گزارش نتایج: نتایج کمی و کیفی تحلیل و برای کاربرد در سامانه‌های کمک تشخیصی بالینی گزارش می‌گردد.

## یافته‌ها

### ۱. آموزش مدل

فرآیند آموزش مدل پیشنهادی در هر سه مجموعه داده‌ی D1 تا D3 روند پایدار داشت. منحنی خطای آموزش به صورت پیوسته کاهش یافت و پس از حدود ۱۲۰ اپوک پایدار شد که نشان‌دهنده‌ی یادگیری مؤثر و عدم بیش‌برازش بود.

انجام عملیات بهبود کنتراست (CLAHE) و کاهش نویز (Bilateral Filtering) در داده‌های D2 و D3 موجب سرعت بخشیدن به همگرایی مدل گردید.

۳-۱. بهبود کنتراست محلی با استفاده از روش CLAHE

۳-۲. کاهش نویز همراه با حفظ لبه‌ها با فیلتر دو طرفه

۴. تولید نقشه‌های حرارتی: براساس نواحی توده مشخص شده، نقشه‌های حرارتی دو طرفه تولید و به‌عنوان اطلاعات کمکی مکانی آماده می‌شوند.


۵. داده‌افزایی هدفمند: اعمال چرخش، وارونگی افقی، تغییر مقیاس و تنظیم کنتراست به منظور افزایش تنوع داده‌ها و بهبود شناسایی ضایعات کوچک.

۶. پیکربندی مدل YOLO: تنظیم پارامترهای آموزشی شامل نرخ یادگیری، اندازه دسته، ابعاد ورودی و بهینه‌ساز AdamW.

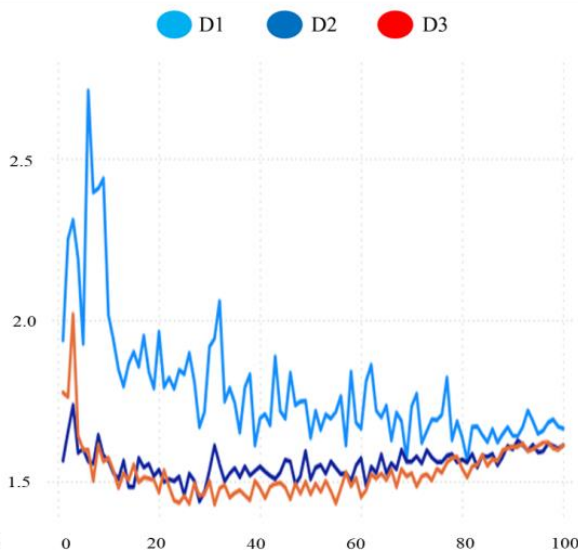
۷. آموزش مدل: مدل YOLO با استفاده از تصاویر پیش‌پردازش شده و نقشه‌های حرارتی، تحت نظارت یادگیری عمیق آموزش داده می‌شود.

۸. ارزیابی عملکرد: عملکرد مدل بر روی مجموعه آزمون با معیارهای Precision، Recall،  $mAP_{0.5}$ ،  $mAP_{0.5:0.95}$  نرخ مثبت کاذب و منفی کاذب محاسبه می‌گردد.

The box loss error value during training over 100 epochs



The box loss error value during validation over 100 epochs



شکل ۲: خطای BOX LOSS در طول ارزیابی و آموزش برای هر سه مدل

Fig 2: BOX LOSS error during evaluation and training for all three models

(False Positive) و منفی کاذب (False Negative) ارزیابی شد. انتخاب این معیارها به دلیل اهمیت بالینی تشخیص صحیح ضایعات بدخیم و حداقل‌سازی خطاهای تشخیصی، به‌ویژه کاهش موارد منفی کاذب، صورت گرفت.

### ۲. ارزیابی کمی عملکرد مدل

عملکرد مدل‌ها با استفاده از معیارهای استاندارد شامل دقت (Precision)، حساسیت (Recall)، میانگین دقت میانگین شده ( $mAP@0.5$ ) و نرخ خطای مثبت کاذب

تومورهای پستان در سه مجموعه داده در جدول ۱ آورده شده است. تمام مقادیر میانگین نتیجه سه اجرای مستقل بوده و همراه با انحراف معیار (±SD) گزارش شده‌اند.

مبنای مفید بودن مدل، دستیابی همزمان به حساسیت بالا، دقت مناسب و پایداری عملکرد در تصاویر چالش‌برانگیز تعریف شد. نتایج کمی مدل در تشخیص و مکان‌یابی

جدول ۱: مقادیر شاخص‌های عملکرد مدل در سه سطح داده‌ی مختلف (D۳، D۲، D۱) همراه با میانگین و انحراف معیار

Table 1: Model performance metrics across three different dataset configurations, reported with mean and standard deviation

| performance metrics         | D1 (mean ± SD) | D2 (mean ± SD) | D3 (Final ± SD) |
|-----------------------------|----------------|----------------|-----------------|
| Precision, %                | 61.43 ± 1.8    | 65.71 ± 1.4    | 70.24 ± 1.2     |
| Recall, %                   | 58.96 ± 1.6    | 63.82 ± 1.3    | 68.01 ± 1.1     |
| mAP <sub>0.5</sub> (%)      | 59.71 ± 1.9    | 63.14 ± 1.5    | 68.28 ± 1.2     |
| mAP <sub>0.5:0.95</sub> (%) | 34.25 ± 1.5    | 37.94 ± 1.2    | 40.82 ± 1.0     |

میلی‌متر، میانگین دقت مدل ۷۴٫۲٪ ± ۱٫۰ و در ضایعات کوچک‌تر از ۵ میلی‌متر برابر ۱۱/۳ ± ۶۴٪/۷ که علت این کاهش هم پوشانی بافتی و کنتراست پایین است. استفاده از نقشه‌های حرارتی منجر به افزایش میانگین حساسیت در تشخیص ضایعات کوچک به میزان ۶/۴ درصد (p= ۰/۰۳۲) شد و نرخ منفی کاذب در این گروه از ضایعات را به طور معناداری کاهش داد که نشان‌دهنده‌ی نقش موثر هدایت توجه مکانی در بهبود تشخیص توده‌های کم کنتراست است.

#### ۴. مقایسه با روش‌های پیشین

به‌منظور ارزیابی اثربخشی مدل، عملکرد YOLOv11n با مدل‌های مرجع شامل EfficientDet-Faster R-CNN و YOLOv5، D0 و YOLOv8 مقایسه شد (۱۸-۲۱). نتایج در جدول ۲ خلاصه شده‌اند:

افزایش عملکرد مدل از D۱ به D۳ از نظر آماری معنی‌دار بود (p < ۰/۰۵) که نشان‌دهنده‌ی اثر مثبت مراحل پیش‌پردازش و نقشه‌های حرارتی در بهبود دقت است. افزون بر این، تحلیل نرخ خطا نشان داد که در مجموعه D۳، مدل YOLOv11n نرخ FP را به‌طور متوسط به ۰/۲۱ مورد در هر تصویر و نرخ FN را به ۰/۱۸ کاهش داده است، در حالی که این مقادیر برای YOLOv5 به‌ترتیب ۰/۳۲ و ۰/۲۷ و برای Faster R-CNN برابر با ۰/۳۵ و ۰/۲۹ گزارش شد. این کاهش معنادار در FP و FN بیانگر افزایش قابلیت اطمینان بالینی مدل پیشنهادی و کاهش خطر تشخیص‌های نادرست است.

#### ۳. ارزیابی عملکرد بر اساس نوع و اندازه‌ی ضایعه

نتایج تفکیکی نشان داد مدل در شناسایی توده‌های ماکروسکوپی (Mass Lesions) عملکرد بهتری نسبت به میکروسکوپی‌کاسیون‌ها دارد. در ضایعات بزرگ‌تر از ۱۵

جدول ۲: مقایسه مدل YOLOv11n با سایر مدل‌ها

Table1: Comparison of YOLOv11 with other reference models

| Model                    | Recall (%)   | Precision (%) | Inference time (ms/image) | mAP <sub>0.5:0.95</sub> (%) | mAP <sub>0.5</sub> (%) |
|--------------------------|--------------|---------------|---------------------------|-----------------------------|------------------------|
| Faster R-CNN             | 59.8         | 61.3          | 76                        | 34.1                        | 59.4                   |
| EfficientDet-D           | 61.5         | 64.7          | 65                        | 36.9                        | 61.8                   |
| YOLOv5                   | 62.4         | 63.9          | 52                        | 37.2                        | 62.7                   |
| YOLOv8                   | 64.9         | 66.1          | 42                        | 38.6                        | 65.3                   |
| <b>Proposed YOLOv11n</b> | <b>68.01</b> | <b>70.24</b>  | <b>39</b>                 | <b>40.82</b>                | <b>68.28</b>           |

عین حال زمان استنتاج (Inference Time) را تا ۳۵ درصد کاهش داده است. تحلیل عمیق‌تر نتایج جدول ۲ نشان می‌دهد که برتری YOLOv11n در شناسایی

همان‌طور که در جدول (۲) مشاهده می‌شود، مدل YOLOv11n نسبت به مدل‌های پایه به‌طور متوسط ۴/۷ تا ۸/۹ درصد بهبود در شاخص‌های mAP نشان داده و در


جعبه‌های مکانی، بیانگر هم‌راستایی قابل‌توجه پیش‌بینی‌های مدل با نشانه‌گذاری‌های متخصصان رادیولوژی است. در این شکل، نقشه‌های حرارتی نقش مهمی در برجسته‌سازی نواحی دارای اهمیت تشخیصی ایفا کرده و توجه شبکه را از بافت‌های غیرمرتبط به سمت ضایعات واقعی هدایت می‌کنند.

به‌کارگیری نقشه‌های حرارتی موجب بهبود تمرکز مدل بر نواحی غیرمتقارن و کم‌کنتراست، به‌ویژه در پستان‌های متراکم شده و به کاهش موارد مثبت کاذب انجامیده است. در مجموع، تحلیل کیفی نتایج تصویری موید آن است که ترکیب پیش‌پردازش هدفمند، نقشه‌های حرارتی و معماری YOLOv11n نه تنها دقت مکان‌یابی ضایعات را افزایش می‌دهد، بلکه با ارائه‌ی شواهد بصری قابل تفسیر، قابلیت اعتماد و کاربردپذیری بالینی سامانه‌های کمک‌تشخیصی را نیز بهبود می‌بخشد.

ضایعات کوچک عمدتاً ناشی از معماری سبک‌تر، حفظ جزئیات مکانی در ابعاد ورودی بالا و ترکیب مؤثر پیش‌پردازش هدفمند با نقشه‌های حرارتی است. در حالی که EfficientDet-D0 اگرچه از نظر دقت کلی عملکرد قابل قبولی دارد، اما نرخ FN بالاتر و هزینه محاسباتی بیشتر آن، کارایی این مدل را در کاربردهای تشخیص لحظه‌ای و محیط‌های بالینی محدود می‌سازد.

### ۵. تحلیل کیفی و تصویری نتایج

تحلیل کیفی خروجی‌های مدل نشان داد که سامانه‌ی پیشنهادی قادر است نواحی مشکوک را با دقت مکانی بالا شناسایی کرده و محدوده‌ی توده‌های پستانی را به‌صورت قابل‌اعتماد تعیین نماید. همان‌طور که در شکل ۳ مشاهده می‌شود، مقایسه‌ی تصویر خام ماموگرافی، نقشه‌ی حرارتی تولیدشده و خروجی نهایی مدل YOLOv11n با



شکل ۳: نمونه‌ای از تحلیل کیفی خروجی مدل YOLOv11n: (A) تصویر خام ماموگرافی، (B) نقشه‌ی حرارتی هدایت‌کننده‌ی توجه مکانی و (C) خروجی نهایی مدل با جعبه‌ی مکانی پیش‌بینی‌شده برای ضایعه. نقشه‌ی حرارتی ناحیه‌ی دارای اهمیت تشخیصی را برجسته کرده و به بهبود دقت مکان‌یابی توده کمک نموده است.

**Fig 3: Example of qualitative analysis of YOLOv11 model outputs: (A)Raw mammography image, (B)Heatmap for spatial attention guidance, (C)Final model output with predicted lesion bounding box. The heatmap highlights diagnostically relevant regions and improves lesion localization accuracy.**

از منظر کاربردی، این یافته‌ها حاکی از آن است که مدل می‌تواند به‌عنوان یک ماژول کمک‌تشخیصی در سامانه‌های CAD ماموگرافی مورد استفاده قرار گیرد و با کاهش بار کاری رادیولوژیست‌ها، افزایش یکنواختی تشخیص و کاهش خطاهای انسانی، به بهبود فرآیند غربالگری و تشخیص زودهنگام سرطان پستان کمک کند.

### ۶. جمع‌بندی یافته‌ها و تفسیر بالینی

نتایج این پژوهش نشان می‌دهد که مدل پیشنهادی مبتنی بر YOLOv11n قادر است به‌طور هم‌زمان میانگین دقت بالا، حساسیت مناسب و زمان پردازش پایین را فراهم آورد. کاهش معنادار نرخ FN و FP، به‌ویژه در ضایعات کوچک و کم‌کنتراست، بیانگر پایداری و قابلیت اعتماد بالینی این سامانه است.

## بحث

نتایج این پژوهش نشان داد که مدل پیشنهادی YOLOv11n در مقایسه با نسخه‌های پیشین YOLO (۱۸-۱۹) و سایر مدل‌های مرجع، عملکرد برتری در شناسایی و مکان‌یابی دقیق ضایعات پستان، به‌ویژه توده‌های کوچک و کم‌کنتراست، ارائه می‌دهد. این برتری نه‌تنها در شاخص‌های کمی نظیر Precision، mAP و Recall مشهود است، بلکه در کاهش خطاهای تشخیصی، به‌ویژه منفی‌های کاذب، نیز به‌طور معناداری نمود یافته است؛ موضوعی که از منظر بالینی با تشخیص زودهنگام و بهبود پیامدهای درمانی سرطان پستان ارتباط مستقیم دارد (۲۲-۲۴).

تحلیل روند آموزش مدل بر اساس شکل ۲ نشان می‌دهد که YOLOv11n دارای روندی پایدار و همگرا در کاهش Box Loss، به‌ویژه در مجموعه داده نهایی (D۳) بوده و پس از حدود ۱۲۰ اپوک به همگرایی رسیده است. در حالی که مدل‌های مرجع نوسانات بیشتری در منحنی‌های خطا نشان داده‌اند (۲۰، ۲۱) که می‌تواند ناشی از حساسیت بالاتر آن‌ها به نویز بافتی و عدم بهره‌گیری از پیش‌پردازش هدفمند باشد. کاهش یکنواخت Box Loss در YOLOv11n نشان می‌دهد که ترکیب پیش‌پردازش هدفمند و هدایت توجه مکانی نقش مؤثری در تثبیت فرآیند یادگیری داشته است.

نتایج حاصل از ارزیابی مدل در سه سطح مختلف داده (جدول ۱) نشان‌دهنده بهبود تدریجی و معنادار عملکرد مدل از مجموعه داده خام (D۱) به مجموعه داده نهایی (D۳) است. در این روند، مقدار Precision از ۶۱/۴۳٪ به ۷۰/۲۴٪ و Recall از ۵۸/۹۶٪ به ۶۸/۰۱٪ افزایش یافته است که بیانگر کاهش هم‌زمان مثبت‌های کاذب و منفی‌های کاذب است. همچنین عملکرد برتری نسبت به YOLOv5 و YOLOv8 ارائه داده است، به‌طوری‌که بهبود Recall در بازه‌ای حدود ۴ تا ۷ درصد نسبت به این مدل‌ها مشاهده می‌شود (۱۸، ۱۹). به‌طور مشابه، شاخص‌های مکان‌یابی نیز در مدل YOLOv11n بهبود قابل توجهی را نشان می‌دهند؛ به‌گونه‌ای که mAP<sub>0.5</sub> در داده‌های خام از ۵۹/۷۱٪ به ۶۸/۲۸٪ و در داده نهایی mAP<sub>0.5:0.95</sub> از ۳۴/۲۵٪ به ۴۰/۸۲٪ ارتقا یافته است و در مقایسه با YOLOv5 و YOLOv8 بهبود حدود ۶ تا ۹ درصدی داشته است که بیانگر توانایی بالاتر مدل پیشنهادی

در مکان‌یابی دقیق جعبه‌های مرزی، به‌ویژه در تشخیص ضایعات کوچک و کم‌کنتراست است. این یافته‌ها با گزارش مطالعات اخیر هم‌راستا است که نشان داده‌اند نسخه‌های جدیدتر معماری YOLO در کاربردهای تصویربرداری پزشکی، به‌ویژه ماموگرافی دیجیتال، دقت مکانی بالاتری نسبت به نسخه‌های پیشین ارائه می‌دهند (۲۵).

ارزیابی اثربخشی مدل YOLOv11n (جدول ۲) نشان می‌دهد که تفاوت عملکرد میان معماری‌های YOLOv11n، EfficientDet-D0 و Faster R-CNN (۲۰، ۲۱) صرفاً یک اختلاف عددی ساده نیست، بلکه بازتابی از تفاوت‌های بنیادین در طراحی معماری، راهبرد استخراج ویژگی، پیچیدگی محاسباتی و میزان انطباق هر مدل با ماهیت تصاویر ماموگرافی است. YOLOv11n توانسته است به‌صورت هم‌زمان در چهار محور کلیدی شامل Precision، Recall، کیفیت مکان‌یابی (mAP) و سرعت استنتاج عملکرد متعادل‌تری ارائه دهد.

از منظر شاخص‌های بالینی، مدل پیشنهادی با دستیابی به Precision برابر با ۷۰/۲۴٪ و Recall برابر با ۶۸/۰۱٪ عملکرد متعادل‌تری نسبت به Faster R-CNN (۶۱/۳٪)، EfficientDet-D0 (۵۹/۸٪) و EfficientDet-D0 (۶۴/۷٪، ۶۱/۵٪) ارائه می‌دهد. افزایش هم‌زمان دقت و حساسیت نشان‌دهنده کاهش مثبت‌های کاذب و منفی‌های کاذب است؛ موضوعی که برای کاربردهای غربالگری و تشخیص زودهنگام سرطان پستان اهمیت بالینی بالایی دارد. در سامانه‌های CAD ماموگرافی، Recall بالاتر مستقیماً با کاهش احتمال نادیده‌ماندن ضایعات واقعی و کاهش تأخیر تشخیصی مرتبط است.

مقایسه YOLOv11n با EfficientDet-D0 در خصوص mAP نیز نشان می‌دهد که اگرچه EfficientDet در برخی کاربردهای تصویری عمومی عملکرد قابل قبولی دارد، در تصاویر ماموگرافی دیجیتال mAP<sub>0.5:0.95</sub> پایین‌تری از خود نشان داده است. این مسئله می‌تواند به حساسیت بالاتر EfficientDet نسبت به نویز بافتی، چگالی بالای پستان و محدودیت آن در استخراج ویژگی‌های ظریف مرتبط با ضایعات کوچک نسبت داده شود. در مقابل، ترکیب پیش‌پردازش هدفمند و هدایت توجه مکانی در YOLOv11n موجب پایداری بیشتر عملکرد مدل در شرایط پیچیده تصویری شده است؛ یافته‌ای که با

و در نتیجه بهبود کیفیت ویژگی‌های ورودی شبکه گردید. مطالعات پیشین نشان داده‌اند که استفاده از CLAHE در تصاویر ماموگرافی می‌تواند حساسیت مدل‌های یادگیری عمیق را در شناسایی ضایعات کم‌کنتراست به‌طور معناداری افزایش دهد (۲۶،۳۵). بهبود کیفیت داده‌ی ورودی نقش اساسی در افزایش دقت استخراج ویژگی‌ها توسط لایه‌های ابتدایی شبکه ایفا کرده است.

دومین عامل مؤثر، ادغام نقشه‌های حرارتی در فرآیند آموزش مدل بود که موجب هدایت توجه مکانی شبکه به نواحی بالینی معنادار شد. برخلاف بسیاری از مطالعات پیشین که شبکه را صرفاً بر اساس داده خام آموزش داده‌اند (۲۹-۳۱)، در این پژوهش مدل به‌صورت ضمنی به تمرکز بر نواحی مشکوک هدایت شد. این رویکرد نه تنها باعث افزایش حساسیت در تشخیص ضایعات کوچک شد، بلکه نرخ مثبت‌های کاذب در نواحی بافتی متراکم را نیز کاهش داد. مطالعات مبتنی بر مکانیزم‌های توجه و نقشه‌های حرارتی گزارش کرده‌اند که هدایت توجه مکانی می‌تواند تفسیرپذیری مدل و هم‌راستایی آن با منطق بالینی را به‌طور قابل توجهی بهبود بخشد (۲۷،۳۶). این ویژگی مدل را از منظر تفسیرپذیری و هم‌راستایی با منطق بالینی، به سامانه‌های CAD قابل اعتمادتر نزدیک می‌کند.

سومین عامل، انتخاب معماری YOLOv11n به‌عنوان یک مدل سبک و بهینه‌شده بود. YOLOv11n با حفظ توانایی تشخیص دقیق، هزینه محاسباتی کمتری نسبت به مدل‌های سنگین‌تری مانند Faster R-CNN و EfficientDet-D0 دارد (۲۰،۲۱). نتایج نشان داد که این معماری توانسته است توازن مناسبی میان دقت تشخیص و سرعت استنتاج برقرار کند، به‌طوری‌که زمان پردازش کمتر از ۴۰ میلی‌ثانیه، امکان استفاده از مدل را در کاربردهای تشخیص لحظه‌ای فراهم می‌سازد. مطابق با گزارش‌های اخیر، معماری‌های سبک تشخیص اشیاء برای کاربردهای بالینی لحظه‌ای، به‌ویژه در ماموگرافی دیجیتال، مزیت قابل توجهی نسبت به مدل‌های سنگین‌تر دارند (۳۷). این ویژگی برای محیط‌های بالینی پرتراکم که زمان پاسخ‌گویی اهمیت حیاتی دارد، یک مزیت کلیدی محسوب می‌شود.

در مقایسه با مطالعات پیشین، پژوهش حاضر چند تمایز اساسی دارد. بسیاری از پژوهش‌های قبلی در حوزه ماموگرافی دیجیتال بر طبقه‌بندی کلی تصاویر (سالم/بیمار) متمرکز بوده‌اند و مکان‌یابی دقیق ضایعات را یا نادیده گرفته

گزارش‌های پیشین در حوزه تشخیص ضایعات ماموگرافی هم‌راستا است (۲۶،۲۷).

از نظر کارایی محاسباتی، YOLOv11n با زمان استنتاج حدود ۳۹ میلی‌ثانیه به‌ازای هر تصویر، سریع‌ترین مدل در میان روش‌های مقایسه‌شده محسوب می‌شود، در حالی که مدل‌های سنگین‌تر مانند Faster R-CNN با وجود دقت پایین‌تر، زمان پردازش بیشتری (حدود ۷۶ میلی‌ثانیه) نیاز دارند (۲۰). این اختلاف قابل توجه در سرعت استنتاج، کاربرد عملی مدل‌های دومرحله‌ای را در محیط‌های بالینی پرتراکم و برنامه‌های غربالگری انبوه با محدودیت جدی مواجه می‌سازد؛ موضوعی که در مطالعات اخیر نیز به‌عنوان یکی از موانع اصلی استقرار بالینی این مدل‌ها گزارش شده است (۲۸).

در مقایسه با روش‌های کلاسیک مبتنی بر یادگیری ماشین نظیر SVM، KNN و ETC که معمولاً دقت و حساسیتی در بازه ۵۵ تا ۶۵ درصد گزارش کرده‌اند (۲۹-۳۱)، مدل YOLOv11n پیشنهادی با Precision بیش از ۷۰٪ و Recall بالاتر از ۶۸٪ برتری محسوس‌ی نشان می‌دهد. این اختلاف عددی را می‌توان به توانایی محدود روش‌های کلاسیک در مدل‌سازی روابط فضایی پیچیده و وابستگی آن‌ها به ویژگی‌های دستی نسبت داد.

همچنین، در مقایسه با مدل‌های CNN کلاسیک نظیر VGG، PiDiNet و ResNet که عمدتاً برای طبقه‌بندی تصویر به‌کار رفته‌اند (۳۲-۳۴)، مزیت اصلی روش پیشنهادی در قابلیت تشخیص و مکان‌یابی هم‌زمان ضایعات است. بسیاری از مطالعات CNN محور، اگرچه دقت طبقه‌بندی مناسبی گزارش کرده‌اند، اما شاخص‌های مکانی نظیر mAP را ارائه نکرده یا مقادیر پایین‌تری (کمتر از ۶۵٪) گزارش داده‌اند. دستیابی به mAP<sub>0.5</sub> برابر با ۶۸.۲۸٪ در این پژوهش نشان می‌دهد که رویکرد مبتنی بر YOLO برای کاربردهای CAD ماموگرافی عملی‌تر و از نظر بالینی معنادارتر است (۲۲،۲۳).

تحلیل نتایج نشان می‌دهد که بهبود عملکرد مدل پیشنهادی حاصل یک عامل منفرد نیست، بلکه نتیجه‌ی هم‌افزایی چند مؤلفه‌ی کلیدی در طراحی روش پیشنهادی است. نخست، استفاده از پیش‌پردازش هدفمند شامل CLAHE و فیلتر دوطرفه موجب افزایش کنتراست موضعی ضایعات و کاهش نویز بافتی شد. این امر باعث برجسته‌سازی مرزهای توده‌ها در بافت‌های متراکم پستان

استفاده از داده‌های چندوجهی و ارزیابی بالینی طولی تمرکز کنند. همچنین، توسعه و بومی‌سازی چنین سامانه‌هایی می‌تواند نقش مؤثری در ارتقای برنامه‌های ملی غربالگری و زیرساخت‌های سلامت دیجیتال ایفا کند.

### نتیجه‌گیری

نتایج این پژوهش نشان می‌دهد که روش پیشنهادی مبتنی بر معماری سبک YOLOv11n، همراه با پیش‌پردازش هدفمند و هدایت توجه مکانی، یک رویکرد عملی، سریع و قابل اعتماد برای شناسایی و مکان‌یابی دقیق ضایعات پستان در تصاویر ماموگرافی ارائه می‌دهد. بهبود معنادار شاخص‌های Precision، Recall و mAP به‌ویژه در تشخیص توده‌های کوچک و کم‌کنتراست، در کنار کاهش هم‌زمان مثبت‌های کاذب و منفی‌های کاذب، بیانگر افزایش قابلیت اطمینان بالینی مدل پیشنهادی است. نوآوری اصلی این پژوهش در ارائه یک روش یکپارچه برای تشخیص و مکان‌یابی لحظه‌ای ضایعات پستان نهفته است که می‌تواند به‌عنوان ابزار پشتیبان تصمیم‌گیری در سامانه‌های CAD ماموگرافی به کار گرفته شود. با وجود محدودیت‌هایی نظیر ارزیابی مبتنی بر یک پایگاه داده عمومی و نبود اعتبارسنجی بالینی مستقیم، نتایج حاکی از پتانسیل بالای این روش برای کاهش بار کاری رادیولوژیست‌ها، افزایش یکنواختی تشخیص و ارتقای برنامه‌های غربالگری سرطان پستان است. اعتبارسنجی چندمرکزی و ارزیابی در محیط‌های بالینی واقعی، مسیرهای پژوهشی آینده در این حوزه را تشکیل می‌دهند.

### سپاس‌گزاری

این مقاله از رساله مقطع دکترای تخصصی مهندسی پزشکی - بیوالکترونیک دانشگاه اسلامی آزاد قزوین استخراج شده است.

### تعارض منافع

نویسندگان هیچ گونه تعارض منافی ندارند.

### References

1. Thomas NS, Norris E. Understanding the delays in diagnosis of breast cancer in India using blogs and YouTube videos. BMC

یا به‌صورت محدود بررسی کرده‌اند (۳۱-۳۳). مطالعات مروری اخیر نیز بر کمبود تحقیقات متمرکز بر تشخیص و مکان‌یابی هم‌زمان ضایعات در ماموگرافی تأکید کرده‌اند (۳۸). در مقابل، این مطالعه با تمرکز صریح بر تشخیص و مکان‌یابی دقیق توده‌ها، خروجی‌هایی ارائه می‌دهد که قابلیت استفاده مستقیم در سامانه‌های CAD بالینی را دارند. همچنین، در حالی که برخی مدل‌های پیشین به بهبود دقت به بهای افزایش پیچیدگی محاسباتی پرداخته‌اند، روش پیشنهادی نشان می‌دهد که با طراحی مناسب پیش‌پردازش و هدایت توجه، می‌توان با معماری‌های سبک نیز به عملکرد بالینی مطلوب دست یافت.

از منظر تحلیل خطا، کاهش هم‌زمان نرخ مثبت‌های کاذب (حدود ۰/۲۱) و منفی‌های کاذب (حدود ۰/۱۸) در هر تصویر در مجموعه داده نهایی، بیانگر افزایش قابلیت اطمینان بالینی مدل است؛ عاملی که می‌تواند از بیوپسی‌های غیرضروری و تأخیر درمانی جلوگیری کند (۳۹).

با وجود نتایج امیدوارکننده، این مطالعه دارای محدودیت‌هایی نیز هست. نخست، ارزیابی مدل تنها بر روی یک پایگاه داده عمومی دوبعدی انجام شده است و بررسی عملکرد آن در داده‌های چندمرکزی، چنددستگاهی و با تنوع جمعیتی بیشتر می‌تواند به افزایش تعمیم‌پذیری نتایج کمک کند. مطالعات اخیر بر ضرورت اعتبارسنجی چندمرکزی مدل‌های هوش مصنوعی پیش از کاربرد بالینی تأکید دارند (۴۰). دوم، اگرچه نتایج شبیه‌سازی‌شده نشان‌دهنده پتانسیل مدل در کاهش خطای انسانی است، عدم انجام ارزیابی بالینی مستقیم با حضور رادیولوژیست‌ها یکی از محدودیت‌های این پژوهش محسوب می‌شود. همچنین، زمان آموزش نسبتاً بالا به دلیل ابعاد بزرگ ورودی می‌تواند در آینده با روش‌هایی نظیر pruning یا quantization بهینه‌سازی شود. این راهکارها در مطالعات اخیر به‌عنوان رویکردهای مؤثر برای کاهش هزینه محاسباتی مدل‌های عمیق پیشنهاد شده‌اند (۴۱). پژوهش‌های آینده می‌توانند بر بهینه‌سازی بیشتر مدل،

Public Health. 2025;25(1):2792. DOI: 10.1186/s12889-025-24132-x.

2. Bray F, Laversanne M, Sung H, Ferlay J, Siegel RL, Soerjomataram I, Jemal A. Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*. 2024;74(3):229-63. DOI: 10.3322/caac.21834.
3. Brockton NT, Cook LS, Magliocco AM, Shemanko CS, Vogel HJ, Khan M, Kopciuk KA. The Breast to Bone (B2B) Cohort Study to Prevent, Detect and Improve Treatment of Metastatic Disease: Baseline Assessment, Description and Progress. *International Journal of Environmental Research and Public Health*. 2025;22(2):242. DOI: 10.3390/ijerph22020242.
4. Rahimzadeh S, Bentham J, Burczynska B, Farzadfar F, Di Cesare M. Spatiotemporal disparity of breast cancer incidence in Iranian female populations at the district level from 2000 to 2021: Bayesian disease mapping. *Plos one*. 2025;20(9):e0330017. DOI: 10.1371/journal.pone.0330017
5. Shi J, Li J, Gao Y, Chen W, Zhao L, Li N, Tian J, Li Z. The screening value of mammography for breast cancer: an overview of 28 systematic reviews with evidence mapping. *Journal of Cancer Research and Clinical Oncology*. 2025;151(3):1-20. DOI: 10.1007/s00432-025-06122-z.
6. Koninckx P, Ussia A, Page G. Breast cancer screening in women taking hormone replacement therapy needs updating. *Authorea Preprints*. 2023;10. DOI: 10.52054/FVVO.16.1.001.
7. Ciurescu S, Cerbu S, Dima CN, Borozan F, Pârvănescu R, Ilaș DG, Cîtu C, Vernic C, Sas I. AI in 2D Mammography: Improving Breast Cancer Screening Accuracy. *Medicina*. 2025;61(5):809. DOI: 10.3390/medicina61050809.
8. Pasokh Z, Mazidimoradi A, Hamidian M, Shahabinia Z, Kiani M, Salehiniya H. National and Subnational Burden of Female Breast Cancer in Iran from 2010 to 2021. *Diseases*. 2025;14(1):15. DOI: 10.3390/diseases14010015.
9. Dadzie AK, Iddir SP, Ganesh S, Ebrahimi B, Rahimi M, Abtahi M, Son T, Heiferman MJ, Yao X. Artificial intelligence in the diagnosis of uveal melanoma: advances and applications. *Experimental Biology and Medicine*. 2025;250:10444. DOI: 10.3389/ebm.2025.10444
10. Hadjiiski L, Cha K, Chan HP, Drukker K, Morra L, Näppi JJ, Sahiner B, Yoshida H, Chen Q, Deserno TM, Greenspan H. AAPM task group report 273: recommendations on best practices for AI and machine learning for computer-aided diagnosis in medical imaging. *Medical physics*. 2023;50(2):e1-24. DOI: 10.1002/mp.16188.
11. Jailin C, Mohamed S, Iordache R, Milioni De Carvalho P, Ahmed SY, Abdel Sattar EA, Moustafa AF, Gomaa MM, Kamal RM, Vancamberg L. AI-based cancer detection model for contrast-enhanced mammography. *Bioengineering*. 2023;10(8):974. DOI: 10.3390/bioengineering10080974.
12. Yuan M, Zhang C, Wang Z, Liu H, Pan G, Tang H. Trainable spiking-YOLO for low-latency and high-performance object detection. *Neural Networks*. 2024;172:106092. DOI: 10.1016/j.neunet.2023.106092.
13. Mao M, Hong M. YOLO object detection for real-time fabric defect inspection in the textile industry: A review of YOLOv1 to YOLOv11. *Sensors (Basel, Switzerland)*. 2025;25(7):2270. DOI: 10.3390/s25072270.
14. Obuchowicz B, Zarzecka J, Strzelecki M, Jakubowska M, Obuchowicz R, Piórkowski A, Zarzecka-Francica E, Lasek J. Improving endodontic radiograph interpretation with TV-CLAHE for enhanced root canal detection. *Journal of Clinical Medicine*. 2025;14(15):5554. DOI: 10.3390/jcm14155554.
15. Maus J, Nikulin P, Hofheinz F, Petr J, Braune A, Kotzerke J, van den Hoff J. Deep learning based bilateral filtering for edge-preserving denoising of respiratory-gated PET. *EJNMMI physics*. 2024;11(1):58. DOI: 10.1186/s40658-024-00661-z.
16. Kernick K, Woudstra R, Berjanskii M, MacKay S, Wishart DS. Heatmapper2: web-enabled heat mapping made easy. *Nucleic Acids Research*. 2025:gkaf385. DOI: 10.1093/nar/gkaf385
17. Nguyen HT, Nguyen HQ, Pham HH, Lam K, Le LT, Dao M, Vu V. VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography. *Scientific Data*. 2023;10(1):277. DOI: 10.1038/s41597-023-02100-7.

18. Sun K, Tang M, Li S, Tong S. Mildew detection in rice grains based on computer vision and the YOLO convolutional neural network. *Food Science & Nutrition*. 2024;12(2):860-8. DOI: 10.1002/fsn3.3798. DOI: 10.3390/diagnostics14242875.
19. Shia WC, Ku TH. Enhancing Microcalcification Detection in Mammography with YOLO-v8 Performance and Clinical Implications. *Diagnostics*. 2024;14(24):2875. DOI: 10.3390/diagnostics14242875.
20. Karako K, Mihara Y, Arita J, Ichida A, Bae SK, Kawaguchi Y, Ishizawa T, Akamatsu N, Kaneko J, Hasegawa K, Chen Y. Automated liver tumor detection in abdominal ultrasonography with a modified faster region-based convolutional neural networks (Faster R-CNN) architecture. *Hepatobiliary Surgery and Nutrition*. 2022;11(5):675. DOI: 10.21037/hbsn-21-43.
21. Nawaz M, Nazir T, Baili J, Khan MA, Kim YJ, Cha JH. CXray-EffDet: Chest disease detection and classification from X-ray images using the EfficientDet model. *Diagnostics*. 2023;13(2):248. DOI: 10.3390/diagnostics13020248.
22. Carriero A, Groenhoff L, Vologina E, Basile P, Albera M. Deep learning in breast cancer imaging: State of the art and recent advancements in early 2024. *Diagnostics*. 2024;14(8):848. DOI: 10.3390/diagnostics14080848.
23. Perez-Nunez JR, Rodriguez C, Vasquez-Serpa LJ, Navarro C. The challenge of deep learning for the prevention and automatic diagnosis of breast cancer: A systematic review. *Diagnostics*. 2024;14(24):2896. DOI: 10.3390/diagnostics14242896.
24. Amin A, Koteshwara P, PC S, Mathew S. A systematic literature review on mammography: deep learning techniques for breast cancer detection with global and Asian perspectives. *BMC Cancer*. 2025 Dec;25(1):1-23. DOI: 10.1186/s12885-025-14876-5.
25. Lam QT, Le MH, Lee IT, Le NQ. Evaluating YOLO for dental caries diagnosis: a systematic review and meta-analysis. *Evidence-Based Dentistry*. 2025:1-4. DOI: 10.1038/s41432-025-01180-1
26. Ciurescu S, Cerbu S, Dima CN, Borozan F, Părvănescu R, Ilaș DG, Cîtu C, Vernic C, Sas I. AI in 2D Mammography: Improving Breast Cancer Screening Accuracy. *Medicina*. 2025;61(5):809. DOI: 10.3390/medicina61050809.
27. Zeng A, Houssami N, Noguchi N, Nickel B, Marinovich ML. Frequency and characteristics of errors by artificial intelligence (AI) in reading screening mammography: a systematic review. *Breast cancer research and treatment*. 2024;207(1):1-3. DOI: 10.1007/s10549-024-07353-3.
28. Park J, Witowski J, Xu Y, Trivedi H, Gichoya J, Brown-Mulry B, Westerhoff M, Moy L, Heacock L, Lewin A, Geras KJ. A Multi-Modal AI System for Screening Mammography: Integrating 2D and 3D Imaging to Improve Breast Cancer Detection in a Prospective Clinical Study. *arXiv preprint arXiv:2504.05636*. 2025. DOI: 10.48550/arXiv.2504.05636.
29. Rao KS, Terlapu PV, Jayaram D, Raju KK, Kumar GK, Pemula R. Intelligent ultrasound imaging for enhanced breast cancer diagnosis: ensemble transfer learning strategies. *IEEE Access* 2024; 12: 22243–63 [Internet]. 2024. DOI:10.1109/ACCESS.2024.3358448.
30. Ghazalnaz Sharifonnasabi F, Makhdoom I. Comparison of Deep Learning and Machine Learning Algorithms to Diagnose and Predict Breast Cancer. In *International Conference on Information Technology and Applications 2022*(pp 31-43). Singapore: Springer Nature Singapore. DOI:10.1007/978-981-99-8324-7\_4
31. Batool A, Byun YC. Toward improving breast cancer classification using an adaptive voting ensemble learning algorithm. *IEEE Access*. 2024;12:12869-82. DOI: 10.1109/ACCESS.2024.3356602
32. Xu M, Huang J, Huang K, Liu F. Incorporating tumor edge information for fine-grained bi-rads classification of breast ultrasound images. *IEEE Access*. 2024;12:38732-44. DOI: 10.1109/ACCESS.2024.3374380
33. Hamed G, Marey M, Amin SE, Tolba MF. Automated breast cancer detection and classification in full field digital mammograms using two full and cropped detection paths approach. *IEEE Access*. 2021;9:116898-913. DOI: 10.1109/ACCESS.2021.3105924.

34. Ji Z, Sun H, Yuan N, Zhang H, Sheng J, Zhang X, Ganchev I. BGRD-TransUNet: A novel TransUNet-based model for ultrasound breast lesion segmentation. *IEEE Access*. 2024;12:31182-96. DOI: 10.1109/ACCESS.2024.3368170.
35. Sutjiadi R, Sendari S, Herwanto HW, Kristian Y. Deep learning for segmentation and classification in mammograms for breast cancer detection: a systematic literature review. *Advanced Ultrasound in Diagnosis and Therapy*. 2024;8(3):94-105. DOI: 10.37015/AUDT.2024.230051
36. Mayo RC, Kent D, Sen LC, Kapoor M, Leung JW, Watanabe AT. Reduction of false-positive markings on mammograms: a retrospective comparison study using an artificial intelligence-based CAD. *Journal of digital imaging*. 2019;32(4):618-24. DOI: 10.1007/s10278-018-0168-6.
37. Park J, Witowski J, Xu Y, Trivedi H, Gichoya J, Brown-Mulry B, Westerhoff M, Moy L, Heacock L, Lewin A, Geras KJ. A Multi-Modal AI System for Screening Mammography: Integrating 2D and 3D Imaging to Improve Breast Cancer Detection in a Prospective Clinical Study. *arXiv preprint arXiv:2504.05636*. 2025. DOI: 10.48550/arXiv.2504.05636.
38. Lotter W, Diab AR, Haslam B, Kim JG, Grisot G, Wu E, Wu K, Onieva JO, Boyer Y, Boxerman JL, Wang M. Robust breast cancer detection in mammography and digital breast tomosynthesis using an annotation-efficient deep learning approach. *Nature medicine*. 2021 Feb;27(2):244-9. DOI: 10.1038/s41591-020-01174-9.
39. Parhizkari M, Shabanzadeh M, Abbasi F, Saremi S. A comprehensive review on breast cancer detection and using machine learning techniques: Methods, and challenges ahead. *Advances in Applied Nano-Bio Technologies*. 2025:24-45. DOI: 10.18502/aanbt.v6i1.18227
40. Pedemonte S, Tsue T, Mombourquette B, Vu YN, Matthews T, Hoil RM, Shah M, Ghare N, Zingman-Daniels N, Holley S, Appleton CM. A deep learning algorithm for reducing false positives in screening mammography. *arXiv preprint arXiv:2204.06671*. 2022. DOI: 10.1148/ryai.230033.
41. Luo L, Wang X, Lin Y, Ma X, Tan A, Chan R, Vardhanabhuti V, Chu WC, Cheng KT, Chen H. Deep learning in breast cancer imaging: A decade of progress and future directions. *IEEE Reviews in Biomedical Engineering*. 2024. DOI: 10.1109/RBME.2024.3357877.