



Original article

Integration of Image and Tabular Data in a Siamese Network for Diabetic Patient Classification Using Thermography: A Multimodal EfficientNetB3-Based Approach

Zahra Ahmadi Rad¹, Hossein Ghayoumi Zadeh^{2*}, Ali Fayazi³, Khosro Rezaee⁴

1. M.Sc. Student, Department of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

2. Ph.D. in Biomedical Engineering, Associate Professor, Department of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

3. Ph.D. in Control Engineering, Associate Professor, Department of Electrical Engineering, Faculty of Engineering, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

4. Ph.D. in Biomedical Engineering, Associate Professor, Department of Biomedical Engineering, Meybod University, Meybod, Iran

ARTICLE INFO:

Article History:

Received: 18 Sep 2025

Accepted: 15 Feb 2026

Published: 20 Mar 2026

*Corresponding Author:

Hossein Ghayoumi Zadeh

Email:

h.ghayoumizadeh@vru.ac.ir

Citation: Ahmadi Rad Z, Ghayoumi Zadeh H, Fayazi A, Rezaee K. Integration of Image and Tabular Data in a Siamese Network for Diabetic Patient Classification Using Thermography: A Multimodal EfficientNetB3-Based Approach. Journal of Health and Biomedical Informatics 2026; 12(4): 315-33. [In Persian]

Abstract

Introduction: Diabetic foot is a serious chronic complication of diabetes that can lead to ulcers and limb amputation if not diagnosed early. While non-invasive techniques like thermography can prevent severe complications, traditional methods often fail to identify subtle thermal changes. This study developed an intelligent system for diabetic foot detection using thermographic images and numerical features.

Method: The Plantar Thermogram Database, containing 167 samples, was divided into training (116 samples), validation (25 samples), and test (26 samples) sets. A multimodal Siamese architecture based on EfficientNetB3 processed left and right foot thermograms simultaneously. Outputs were combined using $|L-R|$ and $L \odot R$ to model thermal asymmetry, then fused with normalized tabular features. Implementation used TensorFlow and Keras, with class weighting to address data imbalance.

Results: The model achieved 96.15% accuracy, 95% sensitivity, 100% specificity, 100% precision, 85.71% NPV, 97.44% F1-score, and 97.5% balanced accuracy on the test set. Learning curves showed rapid convergence with no overfitting and stable performance.

Conclusion: The proposed Siamese architecture, utilizing both image and tabular data, offers a non-invasive, rapid, and accurate approach for screening and monitoring diabetic patients, potentially facilitating early diagnostic clinical systems for diabetic foot detection.

Keywords: Diabetic foot, Thermography, Siamese architecture, Multimodal data, Early detection, EfficientNetB3



CrossMark

مقاله پژوهشی

ادغام داده‌های تصویری و جدولی در یک مدل سیامی برای طبقه‌بندی بیماران دیابتی با

استفاده از ترموگرافی: یک رویکرد چندوجهی مبتنی بر EfficientNetB3

زهرا احمدی راد^۱، حسین قیومی زاده^{۲*}، علی فیاضی^۳، خسرو رضایی^۴

۱. دانشجوی کارشناسی ارشد، گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران

۲. دکترای مهندسی پزشکی، دانشیار، گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران

۳. دکترای مهندسی کنترل، دانشیار، گروه مهندسی برق، دانشکده فنی و مهندسی، دانشگاه ولی عصر (عج) رفسنجان، رفسنجان، ایران

۴. دکترای مهندسی پزشکی، دانشیار، گروه مهندسی پزشکی، دانشگاه میبد، میبد، ایران

چکیده

مقدمه: پای دیابتی یکی از مهم‌ترین عوارض مزمن دیابت است که در صورت عدم تشخیص به‌موقع، می‌تواند به زخم‌های مزمن و حتی قطع عضو منجر شود. تشخیص زودهنگام این عارضه، به‌ویژه از طریق روش‌های غیرتهاجمی نظیر ترموگرافی، نقش کلیدی در پیشگیری از عوارض جدی دارد. با این حال، روش‌های سنتی مبتنی بر آستانه یا تحلیل‌های آماری، در شناسایی تغییرات حرارتی ظریف و نامتقارن میان دو پا کارایی کافی ندارند. پژوهش حاضر با هدف طراحی یک سامانه هوشمند برای تشخیص پای دیابتی، مبتنی بر تصاویر ترموگرافی و داده‌های عددی همراه، انجام شده است.

روش کار: در این مطالعه، از پایگاه داده Plantar Thermogram Database شامل ۱۶۷ نمونه استفاده شد که به سه مجموعه آموزش (۱۱۶ نمونه)، اعتبارسنجی (۲۵ نمونه) و آزمون (۲۶ نمونه) تقسیم گردید. معماری سیامی چندوجهی مبتنی بر EfficientNetB3 طراحی شد که دو تصویر ترموگرافی پای چپ و راست را به‌طور همزمان پردازش می‌کند. خروجی دو شاخه سیامی، پس از استخراج ویژگی، به‌وسیله عملیات تفاضل قدرمطلق (IL-RI) و ضرب‌عنصری (L⊙R) ترکیب شده و سپس با داده‌های عددی نرمال‌سازی‌شده ادغام می‌گردد. پیاده‌سازی مدل در بستر TensorFlow و Keras انجام شد و برای مقابله با عدم‌توازن داده‌ها، از وزن‌دهی کلاس‌ها در تابع زیان استفاده گردید.

یافته‌ها: مدل پیشنهادی در مجموعه آزمون با دقت کلی ۹۶/۱۵٪، حساسیت ۹۵٪ و ویژگی ۱۰۰٪ به عملکرد بالینی مطلوبی دست یافت. همچنین مقادیر دقت (Precision) برابر ۱۰۰٪، ارزش اخباری منفی (NPV) برابر ۸۵/۷۱٪، نمره F1 برابر ۹۷/۴۴٪ و دقت متوازن (Balanced Accuracy) برابر ۹۷/۵٪ به‌دست آمد. نتایج آموزش نشان داد که مدل بدون بروز بیش‌برازش، به سرعت همگرا شده و عملکردی پایدار بر روی داده‌های نادیده ارائه می‌دهد.

نتیجه‌گیری: این نتایج نشان می‌دهند که معماری سیامی پیشنهادی، با بهره‌گیری همزمان از داده‌های تصویری و عددی، می‌تواند به‌عنوان یک روش غیرتهاجمی، سریع و دقیق برای غربالگری و پایش بیماران دیابتی مورد استفاده قرار گیرد و زمینه توسعه سامانه‌های بالینی تشخیص زودهنگام پای دیابتی را فراهم آورد.

کلیدواژه‌ها: پای دیابتی، ترموگرافی، معماری سیامی، داده‌های چندوجهی، تشخیص زودهنگام، EfficientNetB3

اطلاعات مقاله

سابقه مقاله

دریافت: ۱۴۰۴/۶/۲۷

پذیرش: ۱۴۰۴/۱۱/۲۶

انتشار برخط: ۱۴۰۴/۱۲/۲۹

*نویسنده مسئول:

حسین قیومی زاده

ایمیل:

h.ghayoumizadeh@vru.ac.ir

ارجاع:

احمدی راد زهرا، قیومی زاده حسین، فیاضی علی، رضایی خسرو. ادغام داده‌های تصویری و جدولی در یک مدل سیامی برای طبقه‌بندی بیماران دیابتی با استفاده از ترموگرافی: یک رویکرد چندوجهی مبتنی بر EfficientNetB3. مجله انفورماتیک سلامت و زیست پزشکی ۱۴۰۴؛ ۱۲(۴): ۳۱۵-۳۳۳.

مقدمه

پای دیابتی (Diabetic Foot) یکی از عوارض جدی دیابت است که به‌صورت آسیب‌های بافتی در پا (از قبیل عفونت، زخم یا تخریب بافت‌ها) در حضور نوروپاتی و/یا بیماری‌های عروقی محیطی تعریف می‌شود [۱]. این عارضه در بیماران دیابتی شیوع قابل‌توجهی دارد؛ به‌طوری‌که شیوع جهانی آن حدود ۶٪ برآورد شده و تخمین زده می‌شود که ۱۵ تا ۲۵٪ افراد دیابتی در طول عمر خود به مشکلات پای دیابتی مبتلا شوند [۲]. عوارض پای دیابتی از مهم‌ترین عوامل ناتوانی، کاهش کیفیت زندگی و بستری شدن بیماران دیابتی به‌شمار می‌روند. همچنین این عارضه زمینه‌ساز عواقب وخیمی مانند قطع عضو است؛ براساس آمار، حدود ۸۵٪ قطع عضوهای مرتبط با دیابت، در پی یک زخم پای دیابتی رخ می‌دهد [۳]. احتمال نیاز به قطع عضو اندام تحتانی در مبتلایان به پای دیابتی به‌طور قابل‌توجهی افزایش می‌یابد؛ به همین دلیل، پیشگیری و مدیریت به‌موقع این عارضه در کاهش پیامدهای ناگوار یادشده نقشی حیاتی دارد [۴].

تشخیص و مداخله زودهنگام در مشکلات پای دیابتی (از قبیل زخم‌ها، عفونت یا التهاب) نقشی اساسی در جلوگیری از پیشرفت عوارض و کاهش خطر قطع عضو دارد. شناسایی به‌موقع علائم اولیه می‌تواند از بروز پیامدهای ویرانگری نظیر قطع اندام جلوگیری کند. در واقع، هرچه زخم پای دیابتی زودتر تشخیص داده شده و درمان آغاز گردد، شانس بهبودی بدون نیاز به اقدامات تهاجمی‌تر (مانند جراحی یا قطع عضو) بیشتر خواهد بود. به دلیل فقدان حس درد در بسیاری از بیماران مبتلا به نوروپاتی دیابتی، ممکن است زخم یا آسیب در پا تا مراحل پیشرفته بدون جلب توجه بیمار پیش‌رونده شود [۵]. بنابراین، راهنماهای بالینی بر غربالگری و معاینه منظم پای بیماران دیابتی تأکید دارند. برای نمونه، انجمن‌های بین‌المللی توصیه می‌کنند که همه بیماران دیابتی دست‌کم سالی یک‌بار معاینه کامل پا شوند و در صورت وجود عوامل خطر، این معاینات هر شش ماه یک‌بار تکرار گردند [۶]. این اقدامات با هدف شناسایی افراد در معرض خطر بالا و انجام مداخلات پیشگیرانه انجام می‌شوند تا از پیشرفت ضایعات جزئی به زخم‌های شدید و نیاز به بستری یا قطع عضو جلوگیری شود [۵]. تأخیر در ارجاع به متخصص پا یا درمان نامناسب می‌تواند به زخم‌های عمیق‌تر، کاهش شانس بهبودی و افزایش موارد بستری منجر شود؛ در مقابل، پایش مستمر و تشخیص زودهنگام می‌تواند سیر بیماری را به میزان چشمگیری تغییر دهد. روش‌های مرسوم معاینه پای دیابتی عمدتاً شامل معاینه چشمی و فیزیکی یا توسط پزشک یا پرستار، بررسی حس محافظتی با وسایلی نظیر مونوفیل‌امنت، و ارزیابی نبض‌های محیطی و گردش خون است. اگرچه این روش‌ها سنگ بنای مراقبت از پای دیابتی محسوب می‌شوند، اما محدودیت‌های قابل‌توجهی دارند. اولاً، ماهیت تدریجی و پنهان بسیاری از ضایعات پای دیابتی (به‌ویژه در حضور نوروپاتی) باعث می‌شود که آسیب‌های بافتی اولیه بدون درد و علامت بوده و از دید بیمار پنهان بمانند [۵]. بیماران مبتلا به نوروپاتی ممکن است فشارها و ضربات مکرر به پا را حس نکنند و در نتیجه، زخم‌ها تا زمانی که به مراحل پیشرفته برسند، شناسایی نشوند. ثانیاً، معاینه چشمی به تجربه و دقت فرد معاینه‌کننده وابسته است و تغییرات زیرجلدی یا التهابی خفیف ممکن است در مراحل اولیه با چشم غیرمسلح قابل تشخیص نباشند. به همین دلیل، اتکای صرف به معاینه فیزیکی می‌تواند به تشخیص دیر هنگام منجر شود؛ زمانی که ضایعه به مراحل شدیدتری رسیده است. پیامد این کاستی‌ها آن است که حتی با وجود رعایت مراقبت‌های استاندارد، میزان بروز مجدد زخم پا پس از بهبود اولیه همچنان بالا گزارش شده است (حدود ۴۰٪ در سال اول و ۶۰٪ طی سه سال اول). این آمار نشان می‌دهد که روش‌های فعلی کافی نبوده و نیاز به ابزارهای کمکی جهت ارتقای دقت و سرعت تشخیص احساس می‌شود [۷].

ترموگرافی مادون‌قرمز (Infrared Thermography) یک فناوری تصویربرداری پزشکی است که با اندازه‌گیری تشعشعات فروسرخ ساطع شده از سطح پوست، نقشه حرارتی بدن را به‌صورت غیرتماسی و کاملاً ایمن ارائه می‌کند [۸]. به بیان دیگر، دوربین ترموگرافی میزان انرژی حرارتی تابش‌یافته از پا را ثبت کرده و آن را به دما تبدیل می‌کند تا الگوی توزیع دمای پوست نمایش داده شود. این روش کاملاً غیرتهاجمی بوده، هیچ‌گونه تماس فیزیکی با پای بیمار ندارد و در کسری از دقیقه می‌تواند تصویر حرارتی کل کف پا را تهیه کند. ویژگی‌های مذکور سبب شده‌اند که ترموگرافی مادون‌قرمز به ابزاری ایده‌آل برای پایش مکرر و غربالگری پای دیابتی تبدیل شود [۹]. در سال‌های اخیر از این فناوری در حوزه‌های مختلف پزشکی بهره گرفته شده است و کاربرد آن در تشخیص غیرتهاجمی برخی بیماری‌ها (مانند اختلالات عروقی، تب، سرطان پستان و آرتریت‌های التهابی) به اثبات رسیده است. در زمینه دیابت نیز، ترموگرافی به‌عنوان یکی از مهم‌ترین روش‌های مکمل (به‌ویژه در قالب پزشکی از راه دور) برای پایش وضعیت پا مطرح شده است. سهولت استفاده و قابلیت تکرارپذیری بالای این روش، امکان پایش دوره‌ای پای بیماران در معرض خطر را بدون ایجاد ناراحتی برای بیمار و بدون نیاز به کارکنان تخصصی برای هر

نوبت معاینه فراهم می‌سازد [۱۰]. افزایش غیرطبیعی دمای پوست در ناحیه‌ای از پا می‌تواند به‌عنوان هشدار اولیه برای وجود یک فرآیند پاتولوژیک در آن ناحیه تلقی شود. از دیدگاه فیزیولوژیک، التهاب بافت‌ها با گشادشدن عروق خونی و افزایش جریان خون همراه است که به‌صورت موضعی دمای پوست را بالا می‌برد. بنابراین، در پای دیابتی، افزایش دمای موضعی معمولاً نمایانگر شروع یک فرآیند آسیب بافتی یا عفونت زیرسطحی است، حتی پیش از آن که تغییرات ظاهری مانند قرمزی یا زخم مشهود گردد. برای نمونه، بروز یک «نقطه داغ» (hot spot) در نقشه حرارتی کف پا - یعنی نقطه‌ای که به‌طور قابل ملاحظه‌ای گرم‌تر از نواحی مشابه در پای مقابل است - می‌تواند نشانه‌دهنده التهاب زیرجلدی یا آسیب بافتی در آستانه وقوع باشد [۱۱]. مطالعات نشان داده‌اند که اختلاف دمایی حدود ۲ درجه سانتی‌گراد یا بیشتر میان یک نقطه از کف پای بیمار و همان نقطه در پای طرف مقابل، با احتمال بالای شکل‌گیری زخم در آن محل همراه است. به بیان ساده‌تر، پیش از آن که پا دچار زخم باز و قابل مشاهده شود، تمایل به گرم‌تر شدن موضعی دارد که این امر ناشی از واکنش التهابی و افزایش متابولیسم بافتی در آستانه آسیب‌دیدگی است. ترموگرافی با آشکارسازی این تغییرات حرارتی ظریف، امکان شناسایی مشکلات پنهان بافتی را پیش از پیشرفت آن‌ها به مراحل غیرقابل بازگشت فراهم می‌کند [۱۲]. ترموگرافی مادون قرمز در مقایسه با روش‌های معاینه متداول، مزایای متعددی برای تشخیص و پایش پای دیابتی ارائه می‌دهد. نخست آن که این روش می‌تواند تغییرات حرارتی زودرسی را که گاهی روزها تا هفته‌ها پیش از بروز علائم بالینی رخ می‌دهند، آشکار کند. بدین ترتیب، زمان طلایی برای مداخله درمانی فراهم می‌شود؛ در حالی که در معاینه چشمی ممکن است ضایعه تا ظهور علائم واضح پنهان بماند. دوم آن که ترموگرافی روشی عینی و کمی است؛ تصاویر حرارتی و داده‌های دمایی حاصل را می‌توان ذخیره، مقایسه و به‌صورت کمی تحلیل کرد. این ویژگی برتری مهمی نسبت به معاینه فیزیکی دارد که تا حد زیادی کیفی و وابسته به مشاهده‌گر است. سوم اینکه ترموگرافی روشی ایمن و غیرتماسی است و می‌توان آن را به دفعات دلخواه (مثلاً به‌صورت هفتگی یا روزانه) بدون نگرانی از آسیب به بافت یا ایجاد ناراحتی برای بیمار انجام داد. مجموع این مزایا موجب شده است که ترموگرافی مادون قرمز به‌عنوان ابزاری مکمل و ارزشمند در کنار روش‌های استاندارد معاینه پا توصیه شود [۱۱]. کارگروه بین‌المللی پای دیابتی (International Working Group on the Diabetic Foot) نیز در دستورالعمل‌های خود، استفاده از پایش حرارتی را به‌عنوان روشی برای پیشگیری از ایجاد زخم پیشنهاد کرده است؛ این پیشنهاد عمدتاً بر پایه نتایج موفق چندین کارآزمایی بالینی تصادفی شده است. شواهد علمی منتشرشده مؤید اثربخشی این رویکرد هستند. برای نمونه، در سه کارآزمایی بالینی مستقل نشان داده شده است که پایش روزانه دمای کف پا در منزل، ابزاری بسیار مؤثر در کاهش موارد عود زخم پای دیابتی بوده است. در مطالعه دیگری، استفاده از حسگرهای حرارتی کف پا باعث شد ۹۷٪ زخم‌های پای دیابتی غیرتروماتیک در مرحله پیش از پیدایش زخم (تنها بر اساس اختلاف دمای موضعی بیش از ۲/۲ درجه) شناسایی شده و اقدامات پیشگیرانه به‌موقع صورت گیرد. چنین نتایجی نشان می‌دهند که بهره‌گیری از ترموگرافی می‌تواند به ارتقای چشمگیر مراقبت از پای دیابتی منجر شود. به عبارت دیگر، ترموگرافی مادون قرمز با فراهم آوردن امکان تشخیص سریع‌تر و دقیق‌تر، این پتانسیل را دارد که به کاهش بروز زخم‌های جدید، جلوگیری از پیشرفت آسیب‌های موجود، کاهش نیاز به قطع عضو، و در نهایت بهبود کیفیت زندگی بیماران دیابتی بینجامد [۱۱].

در دهه گذشته، استفاده از ترموگرافی برای تشخیص پای دیابتی به‌عنوان روشی غیرتهاجمی و کم‌هزینه مورد توجه قرار گرفته است. یکی از نخستین مطالعات کمی در این زمینه توسط Peregrina-Barreto و همکاران انجام شد که در آن با بهره‌گیری از مفهوم آنژیوزوم، کف پای هر فرد به چهار ناحیه عروقی تقسیم و دمای هر ناحیه به‌طور جداگانه تحلیل شد. آن‌ها شاخص «اختلاف دمای متقارن» (Estimated Temperature Difference) و برآوردگر «نواحی داغ» (Hot Spot Estimator) را معرفی کردند که امکان شناسایی اختلاف‌های دمایی غیرطبیعی حتی در نواحی کوچک را فراهم می‌ساخت. این روش توانست اختلاف‌هایی بیش از ۲/۲ درجه سانتی‌گراد را در برخی نواحی بیماران دیابتی شناسایی کند و نخستین گام در جهت کمی‌سازی تحلیل حرارتی به‌شمار می‌رفت. نقطه قوت اصلی این پژوهش، تفکیک آنژیوزومی و ارائه شاخص‌های کمی بود، اما استفاده از آستانه‌های تجربی و عدم بهره‌گیری از الگوریتم‌های یادگیری ماشین، دقت و قابلیت تعمیم آن را محدود می‌کرد [۱۳].

در ادامه، Hernandez-Contreras و همکاران مرور روایی جامعی بر مطالعات ترموگرافی در پای دیابتی منتشر کردند. این مرور چهار رویکرد اصلی تحلیل حرارتی را معرفی کرد: تحلیل مستقل هر پا، تحلیل نامتقارن بین دو پا، تحلیل توزیع دمایی، و تحلیل تحت بار (استرس). نتایج نشان داد که تحلیل نامتقارن رایج‌ترین روش مورد استفاده است، اما در مواردی مانند قطع عضو یا درگیری همزمان هر دو

پا، عملکرد آن کاهش می‌یابد. این مطالعه تصویری کلی از وضعیت پژوهش‌ها ارائه داد، اما داده تجربی جدید یا ارزیابی کمی نداشت و بر روش‌های آماری سنتی متمرکز بود [۱۴].

در پژوهش بعدی، Hernandez-Contreras و همکاران شاخص جدیدی به نام «شاخص تغییر حرارتی» (Thermal Change Index) معرفی کردند که میزان پراکندگی دما را نسبت به الگوی کنترل در هر آنژیوزوم اندازه‌گیری می‌کرد. این شاخص توانست پنج کلاس مختلف از الگوهای حرارتی را در بیماران دیابتی مشخص کند و نشان داد که دامنه نرمال تغییرات در افراد سالم حدود 0.7 ± 1.1 درجه سانتی‌گراد است. نقطه قوت این مطالعه، ارائه شاخصی کمی برای تشخیص تغییرات زودرس و غیرواضح بود که وابستگی به تفسیر چشمی را کاهش می‌داد، اما این روش نیز فاقد استفاده از مدل‌های یادگیری ماشین و ارزیابی دقت پیش‌بینی بود و اندازه نمونه محدودی داشت [۱۵].

در نهایت، Hernandez-Contreras و همکاران با هدف رفع وابستگی به تحلیل نامتقارن، مدلی آماری مبتنی بر «مدل ترکیبی بتا» (Beta Mixture Model) ارائه کردند که توزیع دمای هر پا را به‌طور مستقل و بدون نیاز به مقایسه با پای مقابل مدل می‌کرد. در این روش، دمای کف پا به چهار مؤلفه (انگشتان، سرماتارس‌ها، کف پا و پاشنه) تفکیک شد و میانگین هر مؤلفه به‌عنوان ویژگی استخراج گردید. نتایج نشان داد که مؤلفه‌های انگشتان و پاشنه بیشترین تفاوت دمایی را بین گروه دیابتی و کنترل دارند. این روش توانست الگوهای دمایی متمایز را به‌صورت کمی شناسایی کند، اما هیچ‌گونه ارزیابی دقت یا معیارهای طبقه‌بندی ارائه نشد و بر تخمین توزیع به‌جای پیش‌بینی فردمحور متمرکز بود [۱۶].

در سال‌های اخیر، پژوهش‌ها به سمت توسعه سامانه‌های پوشیدنی و به‌کارگیری یادگیری عمیق برای تحلیل ترموگرافی کف پا در بیماران دیابتی حرکت کرده‌اند. در مطالعه‌ای توسط Torreblanca González و همکاران، رویکردی نوین برای طراحی جوارب هوشمند ارائه شد که با استفاده از ترموگرافی و تحلیل آماری، نواحی بهینه برای قرارگیری حسگرها در کف پا را شناسایی کرد. در این پژوهش، ۹۳ شرکت‌کننده (۴۴ دیابتی و ۴۹ سالم) با دوربین FLIR E60bx در ۹ ناحیه کف و ۸ ناحیه پشتی پا، پیش و پس از راه رفتن ۱۰۰ متری تصویربرداری شدند و تحلیل خوشه‌بندی برای انتخاب پنج ناحیه کلیدی (پاشنه، قوس داخلی، سرماتارس اول، سرماتارس پنجم و انگشت اول) به‌کار رفت. نتایج نشان داد که بیماران دیابتی افزایش دمایی بیشتری نسبت به گروه کنترل دارند و این نواحی می‌توانند برای پایش مستمر دما و شناسایی زود هنگام نواحی پرخطر استفاده شوند. با این حال، این مطالعه از روش‌های یادگیری ماشین برای طبقه‌بندی خودکار بهره نبرد و بیشتر بر تحلیل دستی داده‌ها متکی بود [۱۷].

همچنین، Anaya-Isaza و Zequera-Díaz گامی فراتر نهاده و از روش‌های یادگیری عمیق برای تشخیص دیابت ملیتوس از تصاویر ترموگرافی کف پا استفاده کردند. آن‌ها با بهره‌گیری از پایگاه داده Plantar Thermogram Database شامل ۱۲۲ بیمار دیابتی و ۴۵ فرد سالم، داده‌های حرارتی را به تصاویر تک‌کاناله تبدیل و با مدل ResNet50v2 آموزش دادند. برای مقابله با کمبود داده، ۱۲ روش افزایش داده (چهار روش کلاسیک و هشت روش پیشنهادی) و یادگیری انتقالی از پایگاه‌های داده نظیر ImageNet به‌کار گرفته شد. این مدل با ترکیب خروجی دو پای چپ و راست توانست با دقت ۱۰۰٪ بیماران دیابتی را شناسایی کند که نشان‌دهنده تأثیر قابل‌توجه افزایش داده و یادگیری انتقالی در بهبود عملکرد مدل است. با وجود این، مطالعه یادشده فاقد تحلیل تفسیرپذیری مدل و بررسی حساسیت ویژگی‌ها بود و احتمال بیش‌برازش ناشی از اندازه محدود مجموعه داده همچنان مطرح است [۱۸].


در مجموع، مطالعات پیشین نشان داده‌اند که ترموگرافی می‌تواند ابزاری ارزشمند برای شناسایی اختلالات کف پا در بیماران دیابتی باشد، اما بیشتر آن‌ها بر روش‌های آماری سنتی یا شاخص‌های دستی تکیه داشته و از یادگیری ماشین و ادغام داده‌های چندمنبعی بهره نبرده‌اند. روش پیشنهادی حاضر با استفاده از معماری سیامی مبتنی بر EfficientNetB3 و ترکیب همزمان تصاویر حرارتی و داده‌های عددی، قادر است الگوهای پیچیده دمایی را به‌طور خودکار یاد بگیرد، از محدودیت تحلیل تقارن دو پا عبور کند، و با استفاده از داده‌های چندوجهی، دقت بالاتری در شناسایی زود هنگام پای دیابتی ارائه دهد.

روش کار

پایگاه داده Plantar Thermogram Database که در سال ۲۰۱۹ توسط Hernández-Contreras و همکاران منتشر شد، یکی از منابع مرجع در حوزه پای دیابتی محسوب می‌شود [۱۹]. این پایگاه شامل ترموگرام‌های کف پای ۱۲۲ بیمار دیابتی و ۴۵ فرد غیردیابتی (گروه کنترل) است که مجموعاً ۱۶۷ نمونه را تشکیل می‌دهند. جهت اطمینان از کفایت حجم نمونه برای آموزش مدل، تحلیل توان آزمون پس‌وقوعی (hoc power analysis post-) با در نظر گرفتن خطای نوع اول ($\alpha = 0.05$) انجام شد. نتایج نشان داد که توان آماری (power) برای تشخیص تفاوت‌های معنادار بین دو گروه بیش از ۰/۹۰ است که از حد استاندارد بالاتر بوده و کفایت داده‌ها را تأیید می‌کند.

داده‌ها به صورت فایل‌های تصویری و عددی سازمان‌دهی شده‌اند و برای هر آزمودنی، تصاویر حرارتی پای چپ و راست به طور جداگانه ارائه شده است. علاوه بر نقشه کامل کف پا، تقسیم‌بندی بر اساس چهار آنژیوزوم اصلی (MPA, MCA, LPA, LCA) نیز انجام گرفته است. در مجموع، این پایگاه شامل ۱۶۷ تصویر حرارتی و ۱۶۷۰ فایل دمایی است و یک اسکریپت متلب برای بازسازی سه‌بعدی ترموگرام‌ها در اختیار پژوهشگران قرار داده شده است.

فایل اکسل همراه این پایگاه داده نیز حاوی اطلاعات عددی و فراداده‌هاست؛ از جمله شناسه آزمودنی‌ها، گروه، جنسیت، پای مورد مطالعه، و داده‌های دمایی استخراج شده. وجود این فایل اکسل موجب می‌شود که علاوه بر پردازش مستقیم تصاویر، امکان تحلیل آماری و مقایسه ساختاریافته بین افراد و گروه‌ها فراهم گردد. از نظر ملاحظات اخلاقی، با توجه به این که پژوهش حاضر یک تحلیل ثانویه بر روی داده‌های عمومی و کاملاً بی‌نام (anonymized) است، بر اساس اصول بیانیه هلسینکی، نیاز به اخذ کد اخلاق مجدد یا رضایت‌نامه جدید وجود نداشته است. در نتیجه، این مجموعه داده، بستری ارزشمند و استاندارد برای توسعه و اعتبارسنجی الگوریتم‌های هوشمند محسوب می‌شود. در شکل ۱، نمونه‌هایی از تصاویر ترموگرافی دو گروه نشان داده شده است. بیماران دیابتی معمولاً الگوهای دمایی نامتقارن و نقاط داغ موضعی دارند، در حالی که افراد سالم توزیع دمایی همگن‌تری در کف پا نشان می‌دهند.



شکل ۱: نمونه‌هایی از تصاویر ترموگرافی کف پا در دو گروه کنترل (سالم) و Diabetic foot (DM) [۱۹]

معماری پیشنهادی


در این پژوهش، یک معماری سیامی چندوجهی برای طبقه‌بندی پای دیابتی ارائه شده است. در این رویکرد، ایده اصلی بر مقایسه مستقیم دو پای یک بیمار بنا شده است، چراکه مطالعات بالینی نشان داده‌اند عدم تقارن دمایی میان پای چپ و راست می‌تواند یکی از قوی‌ترین شاخص‌های بروز زخم یا التهاب در مراحل اولیه باشد. بر همین اساس، مدل ما به‌صورت دو شاخه موازی طراحی شد که هر یک، یک تصویر ورودی (پای چپ یا پای راست) را دریافت می‌کند. هر دو شاخه از یک بک‌بون مشترک به نام EfficientNetB3 برای استخراج ویژگی‌های عمیق استفاده می‌کنند. اشتراک وزن‌ها در این دو شاخه موجب می‌شود که ویژگی‌های استخراج‌شده از هر دو پا در یک فضای معنایی واحد قرار گیرند و هرگونه تفاوت یا شباهت میان آن‌ها به‌طور دقیق‌تری نمایان شود.

همان‌طور که در شکل ۲ مشخص است، برای مدل‌سازی این تفاوت‌ها، دو نوع ویژگی مکمل تعریف شد: نخست، اختلاف مطلق ($|L-R|$) که بیانگر میزان ناهمگونی حرارتی میان دو پا است؛ و دوم، ضرب عنصر به عنصر ($L \odot R$) که نشان‌دهنده میزان شباهت یا همپوشانی ویژگی‌های استخراج‌شده می‌باشد. ترکیب این دو نوع ویژگی به مدل امکان می‌دهد که هم تفاوت‌ها را آشکار سازد و هم اشتراکات را شناسایی کند. این طراحی به‌طور خاص برای تشخیص تغییرات کوچک، اما معنادار در الگوهای حرارتی بسیار سودمند است؛ تغییری که ممکن است در رویکردهای تک‌تصویری به‌سادگی نادیده گرفته شوند.

یکی از نقاط قوت این معماری، قابلیت ادغام داده‌های چندوجهی است. علاوه بر داده‌های تصویری، ویژگی‌های عددی استخراج‌شده از فایل‌های اکسل پایگاه داده (که اختلاف دمای نقاط متناظر پای راست و چپ را کمی‌سازی می‌کنند) نیز به مدل وارد می‌شوند. این داده‌ها پس از نرمال‌سازی، به لایه‌های متراکم وارد شده و سپس با بردار ویژگی‌های تصویری ادغام می‌گردند. بدین ترتیب، مدل از هم‌زمانی دو منبع اطلاعاتی متفاوت – یعنی داده‌های تصویری و داده‌های جدولی – بهره‌مند شده و می‌تواند الگوهایی را بیاموزد که صرفاً از یکی از این منابع قابل استخراج نیستند.

بخش نهایی مدل یا همان سر شبکه (Head) شامل چندین لایه متراکم همراه با Dropout و Batch Normalization است که هدف آن کاهش بیش‌برازش و بهبود تعمیم‌پذیری مدل می‌باشد. در انتها، یک لایه خروجی با تابع فعال‌ساز سیگموئید قرار دارد که احتمال تعلق هر نمونه به گروه دیابتی یا کنترل را تولید می‌کند.

مزیت کلیدی این معماری در آن است که به‌جای تحلیل مطلق یک تصویر منفرد، به‌طور ذاتی بر مقایسه جفتی تمرکز دارد. در بسیاری از بیماران، پای سالم می‌تواند مرجعی طبیعی برای پای دیگر باشد و اختلافات کوچک حرارتی که پیش‌نشان زخم یا التهاب هستند، به‌صورت برجسته‌تری آشکار می‌شوند. افزون بر این، ترکیب اطلاعات تصویری و جدولی در یک چارچوب واحد، قدرت مدل را در تشخیص الگوهای پنهان و روابط غیرخطی افزایش داده و احتمال شناسایی زود هنگام بیماران پرخطر را به‌شکل قابل‌توجهی بالا می‌برد. در نهایت، استفاده از EfficientNetB3 به‌عنوان بک‌بون مشترک موجب شده است که استخراج ویژگی‌ها هم از نظر دقت و هم از نظر بهینگی محاسباتی در سطح بالایی قرار گیرد، به‌گونه‌ای که معماری پیشنهادی هم از نظر علمی نوآورانه بوده و هم از نظر عملی قابلیت پیاده‌سازی در محیط‌های بالینی را دارد.



شکل ۲: ساختار مدل سیاهی پیشنهادی برای ادغام تصاویر ترموگرافی و داده‌های جدولی

در معماری پیشنهادی این پژوهش، شبکه EfficientNetB3 به‌عنوان بک‌بون مشترک برای استخراج ویژگی‌های سطح بالا از ترموگرام‌های کف پا مورد استفاده قرار گرفت. خانواده EfficientNet با معرفی مفهوم مقیاس‌دهی ترکیبی (compound scaling) توانست نشان دهد که افزایش همزمان عمق، عرض و رزولوشن شبکه به‌صورت متوازن، بهره‌وری محاسباتی و دقت مدل را به‌شکل چشمگیری بهبود می‌بخشد [۲۰]. در این رویکرد، برای هر سه بُعد اصلی شبکه، روابط زیر تعریف می‌شوند:

$$w=d, \quad r=\alpha^{\phi}, \quad \beta^{\phi}=\gamma^{\phi}$$

که در آن d عمق (تعداد لایه‌ها)، w عرض (تعداد کانال‌ها)، و r رزولوشن ورودی تصویر است. پارامتر ϕ ضریب مقیاس‌دهی است و γ, β, α مقادیر ثابتی هستند که با جستجوی بهینه انتخاب می‌شوند. محدودیت اصلی به صورت زیر بیان می‌شود:

$$\alpha. \beta^2. \gamma^2=2$$

که تضمین می‌کند افزایش سه‌جانبه ابعاد مدل، رشد متوازن پیچیدگی محاسباتی (FLOPs) را به همراه دارد. EfficientNetB3 در این خانواده، مدلی است که تعادل مناسبی میان دقت بالا و هزینه محاسباتی قابل قبول ارائه می‌دهد. ورودی استاندارد آن 300×300 پیکسل است که دقیقاً با ابعاد ترموگرام‌های استفاده‌شده در این پژوهش همخوانی دارد.

از نظر ساختار درونی، EfficientNetB3 مبتنی بر بلوک‌های MBConv (Mobile Inverted Bottleneck Convolution) است. هر بلوک MBConv شامل یک کانولوشن 1×1 توسعه‌دهنده (expansion)، یک کانولوشن عمقی (depthwise convolution) برای کاهش محاسبات، و یک کانولوشن 1×1 فشرده‌ساز (projection) است که در انتها با یک linear bottleneck خروجی می‌دهد. همچنین در این بلوک‌ها، مکانیزم SE (Squeeze-and-Excitation) تعبیه شده است که با یادگیری وزن‌های توجه (attention weights) برای هر کانال، قابلیت مدل را در تمرکز بر روی ویژگی‌های مهم افزایش می‌دهد.

انتخاب EfficientNetB3 برای معماری سیامی پیشنهادی به چند دلیل کلیدی انجام شد: نخست، این نسخه نسبت به مدل‌های سبک‌تر (مانند B0 و B1) ویژگی‌های غنی‌تری استخراج می‌کند و در عین حال از مدل‌های بزرگ‌تر (B5 تا B7) سبک‌تر و سریع‌تر است. دوم، ابعاد ورودی آن (۳۰۰ پیکسل) متناسب با تصاویر حرارتی کف پا بوده و نیازی به تغییرات شدید در پیش‌پردازش ایجاد نمی‌کند. سوم، به دلیل اشتراک وزن‌ها بین دو شاخه سیامی، استخراج ویژگی‌ها در هر دو پا در یک فضای مشترک انجام می‌شود و مقایسه دقیق بین پای چپ و راست امکان‌پذیر می‌گردد. به این ترتیب، EfficientNetB3 نه تنها یک بک‌بون قدرتمند برای استخراج ویژگی‌های عمیق و غیرخطی از ترموگرام‌هاست، بلکه به عنوان هسته اصلی در تشخیص عدم تقارن دمایی میان دو پا عمل کرده و زمینه را برای یادگیری الگوهای مرتبط با پای دیابتی فراهم می‌سازد.

شاخه سیامی و استخراج ویژگی‌های تطبیقی

در معماری پیشنهادی، بخش کلیدی برای مقایسه پای چپ و راست، شاخه سیامی (Siamese branch) است. در این ساختار، دو شاخه موازی تعریف می‌شوند که ورودی‌های آن‌ها به ترتیب ترموگرام پای چپ (X_L) و ترموگرام پای راست (X_R) هستند. هر شاخه از بک‌بون مشترک EfficientNetB3 استفاده می‌کند، به طوری که پارامترهای شبکه (θ) در هر دو مسیر یکسان و قابل اشتراک هستند. این اشتراک وزن تضمین می‌کند که ویژگی‌های استخراج‌شده از هر دو پا در یک فضای مشترک نهفته (embedding space) قرار گیرند. به صورت ریاضی، نمایش‌های ویژگی به شکل زیر تعریف می‌شوند:

$$h_L = f_{\theta}(X_L), \quad h_R = f_{\theta}(X_R)$$

که در آن $h_L, h_R \in \mathbb{R}^d$ بردارهای ویژگی استخراج‌شده با طول d هستند. برای مدل‌سازی عدم تقارن، دو عملگر ریاضی مکمل روی این بردارها اعمال می‌شوند، اختلاف مطلق (شدت ناهمگونی میان دو پا) و ضرب عنصر به عنصر (بیانگر شباهت‌ها و همپوشانی‌های موجود بین دو بردار ویژگی) که به صورت روابط ۱ و ۲ تعریف می‌گردد.



$$d = |h_L - h_R|$$

$$p = h_L \odot h_R$$

ترکیب این دو نوع ویژگی باعث می‌شود مدل هم به تفاوت‌ها حساس باشد و هم به شباهت‌ها توجه کند. در واقع، فضای نهایی ویژگی به‌صورت:

$$z = [d || p]$$

تعریف می‌شود، که در آن $||$ نشان‌دهنده الحاق (concatenation) است. این بردار z حاوی اطلاعات کامل‌تری از ارتباط میان دو پای بیمار بوده و به بخش‌های بعدی مدل (ادغام با داده‌های جدولی و سپس لایه‌های متراکم) منتقل می‌شود. مزیت اصلی این طراحی در آن است که مدل به‌جای تحلیل مطلق یک پا، بر تحلیل جفتی (pairwise analysis) تمرکز دارد. به لحاظ بالینی، مقایسه مستقیم پای چپ و راست یکی از معتبرترین راهکارها برای شناسایی تغییرات غیرطبیعی است؛ چرا که پای سالم به‌عنوان مرجع طبیعی عمل می‌کند و اختلاف‌های کوچک حرارتی (در حد چند درجه سانتی‌گراد) که ممکن است نشانه آغاز التهاب یا زخم باشند، با این رویکرد برجسته‌تر نمایان می‌شوند. بنابراین، شاخه سیاهی نقشه‌ی اساسی در آشکارسازی نامتقارن‌های دمایی داشته و باعث می‌شود معماری پیشنهادی نسبت به مدل‌های تک‌تصویری از حساسیت و دقت بالاتری برخوردار باشد.

ادغام داده‌های جدولی (Tabular Fusion)

در کنار داده‌های تصویری، این پژوهش از داده‌های عددی (جدولی) استخراج‌شده از فایل اکسل پایگاه داده نیز بهره می‌گیرد. این داده‌ها شامل اختلاف دمای نواحی متناظر پای راست و چپ هستند که به صورت ویژگی‌های عددی برای هر بیمار ثبت شده‌اند. به منظور استفاده همزمان از هر دو منبع اطلاعاتی، یک ماژول ادغام داده‌های جدولی (tabular fusion) طراحی شد. ابتدا داده‌های جدولی با استفاده از مقیاس‌گر مین-مکس نرمال‌سازی شدند:

$$x_i^{norm} = \frac{x_i - \min(x)}{\max(x) - \min(x)}$$

که در آن x_i مقدار ویژگی اولیه و x_i^{norm} مقدار نرمال‌شده آن است. سپس این بردار ویژگی به یک یا چند لایه‌ی متراکم (Dense) همراه با توابع فعال‌ساز غیرخطی (مانند ReLU) عبور داده می‌شود تا به فضای نهفته‌ی مشترک $\mathbb{R}^k$ نگاشت شود:

$$t = (W_t x^{norm} + b_t)$$

که در آن W_t ، b_t وزن‌ها و بایاس لایه‌ی متراکم و σ تابع فعال‌ساز است. در مرحله بعد، این بردار t با بردار ویژگی استخراج‌شده از شاخه‌های سیاهی z ادغام (concatenate) می‌شود:

$$u = [z || t]$$

که در آن u نمایش نهایی ادغام‌شده‌ای است که هم اطلاعات بصری (ویژگی‌های حرارتی و عدم تقارن) و هم اطلاعات عددی (اختلافات کمی ثبت‌شده در اکسل) را شامل می‌شود. این بردار ادغام‌شده در نهایت به بخش Head شبکه (لایه‌های متراکم نهایی و خروجی سیگموئید) ارسال می‌شود تا برچسب بیمار (دیابتی یا کنترل) پیش‌بینی گردد.

مزیت این طراحی در آن است که مدل تنها به داده‌های تصویری محدود نیست و می‌تواند از شاخص‌های عددی که بیانگر اختلافات ثبت‌شده دما هستند نیز استفاده کند. بدین ترتیب، معماری پیشنهادی یک چارچوب چندوجهی (multimodal) ایجاد می‌کند که حساسیت و دقت بالاتری در شناسایی بیماران پرخطر ارائه می‌دهد.

نتایج

پیش از بررسی عملکرد مدل، لازم به ذکر است که کلیه مراحل آماده‌سازی داده‌ها و طراحی شبکه با استفاده از زبان برنامه‌نویسی Python (نسخه ۳.۸) و کتابخانه‌های یادگیری عمیق TensorFlow (نسخه ۲.۱۰) و Keras پیاده‌سازی شده‌اند. فرآیند آموزش شبکه نیز به منظور تسریع محاسبات ماتریسی بر روی یک سیستم سخت‌افزاری مجهز به پردازنده گرافیکی (Graphics Processing Unit) انجام گرفت.

به منظور ارزیابی عملکرد معماری پیشنهادی، کل مجموعه داده شامل ۱۶۷ نمونه معتبر در سه بخش مجزا تقسیم شد تا امکان آموزش، تنظیم، و آزمون منصفانه مدل فراهم شود. بر این اساس، ۱۱۶ نمونه برای آموزش، ۲۵ نمونه برای اعتبارسنجی، و ۲۶ نمونه برای آزمون نهایی در نظر گرفته شد. فرآیند آموزش با استفاده از داده‌های آموزش انجام گرفت و تنظیم آبرپارامترها و پایش بیش‌برازش با تکیه بر مجموعه اعتبارسنجی صورت پذیرفت. در نهایت، عملکرد مدل تنها بر روی نمونه‌های آزمون که در مرحله یادگیری دیده نشده بودند ارزیابی شد تا معیاری بی‌طرفانه از توان تعمیم مدل ارائه گردد.

برای آموزش مدل پیشنهادی، از بهینه‌ساز Adam استفاده شد که یکی از پرکاربردترین الگوریتم‌های بهینه‌سازی در شبکه‌های عصبی عمیق است و به طور تطبیقی، نرخ یادگیری هر پارامتر را بر اساس تخمین مومنت‌های مرتبه اول و دوم گرادینت تنظیم می‌کند. نرخ یادگیری اولیه برابر با $\eta = 0.001$ در نظر گرفته شد و برای پایدارسازی فرآیند یادگیری، کاهش تطبیقی نرخ یادگیری (ReduceLROnPlateau) بر اساس عدم بهبود معیار اعتبارسنجی پیاده‌سازی گردید.

تابع زیان مورد استفاده، آنتروپی متقاطع دودویی (BCE (Binary Cross-Entropy) بود که به صورت زیر تعریف می‌شود:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

که در آن y_i برچسب واقعی و $\hat{y}_i$ احتمال پیش‌بینی شده برای نمونه i -ام است. از آنجا که مجموعه داده دچار عدم توازن کلاسی بود (تعداد نمونه‌های کلاس دیابتی کمتر از کلاس کنترل)، برای جبران این عدم توازن از وزن‌دهی کلاس‌ها در تابع زیان استفاده شد. وزن‌ها به صورت معکوس فراوانی هر کلاس محاسبه شدند:

$$w_c = \frac{N}{K \times n_c}$$


که در آن N تعداد کل نمونه‌ها، K تعداد کلاس‌ها و n_c تعداد نمونه‌های کلاس c است. بر این اساس، وزن‌های محاسبه‌شده برای کلاس‌ها به ترتیب $\{w_0=1.93, w_1=0.67\}$ بودند و در محاسبه زیان هر نمونه ضرب شدند. تابع زیان نهایی به صورت وزن‌دار بازنویسی شد:

$$L_{WBCE} = -\frac{1}{N} \sum_{i=1}^N w_{y_i} [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

فرآیند آموزش به صورت مینی بچ با اندازه دسته (batch size) برابر با ۸ و برای حداکثر ۱۰۰ دوره (epoch) انجام شد. همچنین از Early Stopping برای توقف خودکار در صورت عدم بهبود عملکرد اعتبارسنجی به مدت ۱۵ دوره متوالی استفاده گردید تا از بیش‌برازش جلوگیری شود.


روند تغییرات دقت (accuracy) مدل در طول دوره‌های آموزش و اعتبارسنجی در شکل ۳ نمایش داده شده است. همان‌طور که مشاهده می‌شود، دقت مدل در هر دو مجموعه آموزش و اعتبارسنجی با شیبی نسبتاً تند در مراحل ابتدایی افزایش یافته و پس از حدود ۱۰ دوره به مقداری نزدیک به ۰/۱ (۱۰۰٪) رسیده است. از این نقطه به بعد، نوسانات بسیار جزئی در مقادیر دقت مشاهده می‌شود که بیانگر پایداری فرآیند یادگیری است. دقت اعتبارسنجی از حدود ۰/۴ در شروع آموزش به مقدار ثابت نزدیک به ۰/۱ در میانه فرآیند رسیده و تا پایان تقریباً بدون افت باقی مانده است.

این همگرایی سریع و پایدار نشان می‌دهد که معماری سیامی پیشنهادی همراه با ادغام داده‌های جدولی توانسته است الگوهای حرارتی متمایزکننده را به خوبی بیاموزد، بدون آن‌که دچار بیش‌برازش بر روی داده‌های آموزشی شود. همچنین اختلاف ناچیز بین منحنی‌های آموزش و اعتبارسنجی در دوره‌های پایانی، گویای تعمیم‌پذیری مناسب مدل بر روی داده‌های جدید است.



شکل ۳: روند دقت مدل در مجموعه‌های آموزش و اعتبارسنجی


شکل ۴ روند تغییرات تابع زیان (loss) مدل را در داده‌های آموزش و اعتبارسنجی در طول ۳۰ دوره نمایش می‌دهد. در مراحل اولیه، کاهش تند و پیوسته‌ای در هر دو مجموعه دیده می‌شود که بیانگر یادگیری سریع مدل از الگوهای حرارتی است. پس از حدود ۱۰ دوره، مقادیر تابع زیان به کمتر از ۰/۱۵ رسیده و در ادامه با نوسانات اندک در محدوده پایین باقی مانده‌اند. همگرایی مقادیر آموزش و اعتبارسنجی بدون واگرایی قابل توجه، نشان می‌دهد که مدل دچار بیش‌برازش نشده و توان تعمیم مناسبی بر روی داده‌های جدید دارد.



شکل ۴: روند کاهش زیان مدل در داده‌های آموزش و اعتبارسنجی طی ۳۰ دوره، همراه با همگرایی پایدار و بدون نشانه‌ای از بیش‌برازش.


روندهای یادگیری در شکل‌های ۳ و ۴ نمایش داده شده‌اند. همان‌طور که در شکل ۴ (نمودار تابع زیان) مشاهده می‌شود، مدل در دوره ۱۴ به کمترین میزان خطای اعتبارسنجی (validation loss) دست یافت. پس از این نقطه، با وجود کاهش مداوم خطای آموزش (training loss)، خطای اعتبارسنجی دچار نوسان و افزایش نسبی شد که نشان‌دهنده آغاز فرآیند بیش‌برازش است. مکانیزم توقف زودهنگام (early stopping) با پارامتر صبر (patience) برابر با ۱۵ دوره، آموزش را در دوره ۲۹ متوقف کرد، چراکه در ۱۵ دوره متوالی پس از دوره ۱۴، بهبودی در خطای اعتبارسنجی حاصل نشد. در نهایت، برای تضمین حداکثر تعمیم‌پذیری مدل بر روی داده‌های جدید، وزن‌های مربوط به دوره ۱۴ (نقطه بهینه) به عنوان مدل نهایی بازیابی و ذخیره شدند. ثبات نمودار دقت پس از دوره ۱۰ نیز صحت این تصمیم را تأیید می‌کند.

شکل ۵ ماتریس درهم‌ریختگی (confusion matrix) مدل را بر روی مجموعه آزمون شامل ۲۶ نمونه نشان می‌دهد. مدل توانسته است هر ۶ نمونه کلاس کنترل (۰) را به درستی شناسایی کند و تنها یک نمونه از ۲۰ نمونه کلاس دیابتی (۱) را به اشتباه به عنوان کنترل طبقه‌بندی نماید. این نتایج معادل ویژگی (specificity) برابر با ۱۰۰٪ و حساسیت (sensitivity) برابر با ۹۵٪ هستند که نشان‌دهنده دقت بالای مدل در شناسایی بیماران دیابتی و افراد سالم است. همچنین نرخ خطای کلی تنها حدود ۳/۸٪ بوده که بیانگر عملکرد پایدار مدل در مواجهه با داده‌های دیده‌نشده می‌باشد.




شکل ۵: ماتریس درهم‌ریختگی مدل روی مجموعه آزمون (۲۶ نمونه) با حساسیت ۹۵٪ و ویژگی ۱۰۰٪

شکل ۶ توزیع نمرات پیش‌بینی‌شده مدل را برای هر دو کلاس کنترل $y = 0$ و دیابتی $y = 1$ در مجموعه آزمون نشان می‌دهد. محور افقی، احتمال پیش‌بینی‌شده $p(\text{DM})$ و محور عمودی، تعداد نمونه‌ها را نمایش می‌دهد. همان‌طور که مشاهده می‌شود، توزیع نمونه‌های دیابتی (نوارهای نارنجی) به‌وضوح در ناحیه مقادیر بالا ($0/8$ تا $0/1$) متمرکز است، در حالی که بیشتر نمونه‌های کنترل (نوارهای آبی) در ناحیه نزدیک به صفر قرار دارند. تنها همپوشانی جزئی بین دو کلاس دیده می‌شود که مربوط به یک نمونه false negative با مقدار احتمال حدود $0/18$ و دو نمونه false positive با احتمال حدود $0/6$ است. این تفکیک واضح نشان می‌دهد که مدل توانسته است مرز تصمیمی مشخص و جداکننده بین دو کلاس ایجاد کند و از قابلیت تفکیک‌پذیری بالایی در پیش‌بینی بیماران دیابتی برخوردار است.



شکل ۶: توزیع احتمال پیش‌بینی‌شده نمونه‌های کنترل و دیابتی در مجموعه آزمون

شکل ۷ نمایش دوبعدی ویژگی‌های نهان استخراج‌شده از بردارهای ادغام‌شده (concat_emb) در مجموعه آزمون را با استفاده از الگوریتم $t\text{-SNE}$ نشان می‌دهد. هر نقطه نماینده یک نمونه است و رنگ‌ها بیانگر برچسب واقعی کلاس‌ها می‌باشند (آبی برای کنترل و نارنجی برای دیابتی). همان‌طور که مشاهده می‌شود، نمونه‌های دیابتی عمدتاً در ناحیه پایینی و مرکزی فضا، و نمونه‌های کنترل در نواحی بالایی و پراکنده قرار گرفته‌اند که بیانگر جدایش‌پذیری نسبتاً مناسب دو کلاس در فضای ویژگی است. این خوشه‌بندی نشان می‌دهد که معماری سیامی پیشنهادی توانسته است الگوهای متمایز و قابل تفکیکی از داده‌های حرارتی و عددی استخراج کرده و نمونه‌های هم‌کلاس را در فضای نهان به یکدیگر نزدیک نماید.



شکل ۷: تحلیل $t\text{-SNE}$ ویژگی‌های ادغام‌شده در مجموعه آزمون

بحث و نتیجه‌گیری


هدف اصلی این پژوهش، ارائه یک معماری سیامی چندوجهی برای شناسایی دقیق بیماران دیابتی با استفاده از ترکیب تصاویر ترموگرافی و داده‌های بالینی بود. نتایج به‌دست‌آمده (دقت ۱۵/۹۶٪ و ویژگی ۱۰۰٪) نشان‌دهنده برتری قابل توجه این روش نسبت به رویکردهای تک‌وجهی و مدل‌های پایه است. برای درک بهتر جایگاه این پژوهش، لازم است عملکرد آن با سایر مطالعاتی که از همین پایگاه داده استاندارد (Plantar Thermogram Database) استفاده کرده‌اند، مقایسه شود.

اگرچه این پایگاه داده از سال ۲۰۱۹ در دسترس بوده است، بسیاری از مطالعات تنها بر پردازش تصویر یا استخراج ویژگی‌های دستی تمرکز داشته‌اند. به‌طور مثال، در مطالعه‌ای اخیر، محققان از مدل ResNet50V2 برای طبقه‌بندی همین مجموعه داده استفاده کردند، اما تنها به دقت ۸/۷۱٪ دست یافتند [۲۱]. علت این عملکرد پایین‌تر را می‌توان در نادیده گرفتن تقارن بین دو پا و استفاده صرف از شبکه‌های کانولوشنی متداول دانست که قادر به درک روابط ظریف بین پای چپ و راست نبودند. در مقابل، معماری پیشنهادی این مطالعه با استفاده از ساختار سیامی، این خلأ را پوشش داده است.

از سوی دیگر، رویکردهای مبتنی بر مهندسی ویژگی‌های دستی (hand-crafted feature engineering) نیز در مطالعات پیشین به کار گرفته شده‌اند. برای مثال، در پژوهشی که از شاخص تغییر حرارتی (TCI) بهره برده است [۲۲]، دقت ۱/۹۰٪ گزارش شد. مدل پیشنهادی این مطالعه نه‌تنها فرآیند استخراج ویژگی را به‌صورت خودکار و سرتاسر (end-to-end) انجام می‌دهد، بلکه با دستیابی به دقت ۱۵/۹۶٪ نشان می‌دهد که یادگیری عمیق در صورت معماری صحیح، برتر از شاخص‌های دستی عمل می‌کند.


همچنین، بررسی روند اخیر در توسعه شبکه‌های عصبی نشان می‌دهد که معماری‌های سیامی پتانسیل بالایی در ادغام ویژگی‌های چندگانه دارند. به‌طور مثال، در مطالعه‌ای بسیار اخیر، Wang و همکاران مدل S-VFNet را توسعه دادند که از یک ساختار سیامی برای ترکیب ویژگی‌های بصری و نقشه‌های برجستگی (saliency) به منظور تشخیص دقیق اشیاء در محیط‌های پیچیده استفاده می‌کند [۲۳]. با این حال، تمایز اصلی و نوآوری پژوهش حاضر نسبت به رویکردهایی نظیر کار Wang، در ماهیت ادغام چندوجهی ناهمگن (heterogeneous multimodal fusion) است. در حالی که مطالعات پیشین اغلب بر ترکیب جریان‌های مختلف داده‌های تصویری مانند RGB و saliency تمرکز داشته‌اند، مدل پیشنهادی این پژوهش داده‌های تصویری استخراج‌شده توسط EfficientNetB3 را با داده‌های جدولی (tabular/clinical data) در سطح ویژگی ادغام می‌کند. این راهبرد، مدل را قادر می‌سازد تا علاوه بر تحلیل تقارن تصویری، از اطلاعات فیزیولوژیک موجود در داده‌های عددی نیز بهره‌مند شود؛ رویکردی که در کارهای صرفاً مبتنی بر تصویر (vision-based) دیده نمی‌شود و عامل اصلی دستیابی به دقت ۹۶/۱۵٪ در این مطالعه بوده است.

شکل ۸ نمونه‌هایی از پیش‌بینی‌های درست مدل پیشنهادی برای بیماران دیابتی (true positives) را با بالاترین مقادیر اطمینان نشان می‌دهد. در هر ردیف، جفت تصاویر حرارتی پای چپ و راست افراد دیابتی نمایش داده شده است که احتمال پیش‌بینی شده مدل (p(DM)) در بالای هر جفت ذکر شده است. همان‌طور که مشاهده می‌شود، مدل در تمامی این موارد با اطمینان بالا (۰/۹۷ تا ۰/۱۰۰) برچسب دیابتی را به‌درستی تخصیص داده است. نواحی قرمز و زرد در نقشه‌های حرارتی بیانگر دمای بالاتر، و نواحی آبی و سبز بیانگر دمای پایین‌تر هستند. این الگوها نشان می‌دهند که مدل توانسته است نواحی گرم و نامتقارن را که اغلب نشانه التهاب یا اختلال جریان خون هستند، به‌عنوان شاخص‌های کلیدی پای دیابتی شناسایی کند. این نتایج تأیید می‌کنند که معماری پیشنهادی توانایی استخراج ویژگی‌های حرارتی مرتبط با پای دیابتی را با دقت بالا داشته و می‌تواند تفاوت‌های ظریف بین پای چپ و راست را به‌درستی تشخیص دهد.




شکل ۸: نمونه‌های طبقه‌بندی صحیح بیماران دیابتی به‌عنوان مثبت [۱۹]

شکل ۹ یک نمونه از پیش‌بینی اشتباه مدل پیشنهادی از نوع منفی کاذب (false negative) را نشان می‌دهد که در آن برچسب واقعی بیمار دیابتی $y=1$ بوده، اما مدل آن را به‌عنوان فرد سالم ($\text{pred}=0$) پیش‌بینی کرده است. همان‌طور که مشاهده می‌شود، نقشه حرارتی این نمونه، توزیع دمایی نسبتاً یکنواخت و متقارن در هر دو پا را نشان می‌دهد و فاقد نواحی قرمز یا زرد پرحرارت است. مدل نیز با اطمینان پایین $p(\text{DM})=0.18$ این نمونه را غیردیابتی تشخیص داده است. این خطا نشان می‌دهد که در مواردی که علائم حرارتی بسیار خفیف یا نامشهود هستند، مدل ممکن است در تشخیص دچار اشتباه شود. چنین مواردی، اهمیت استفاده از داده‌های چندوجهی و گسترش مجموعه داده را به منظور پوشش بهتر نمونه‌های دیابتی با شدت خفیف، برجسته می‌سازد.



شکل ۹: طبقه‌بندی اشتباه نمونه دیابتی به‌عنوان سالم [۱۹]

شکل ۱۰ نمونه‌هایی از پیش‌بینی‌های اشتباه مدل پیشنهادی از نوع مثبت کاذب (false positive) را نشان می‌دهد که در آن برچسب واقعی افراد سالم $y=0$ بوده، اما مدل آن‌ها را به‌اشتباه به‌عنوان بیماران دیابتی $\text{pred}=1$ طبقه‌بندی کرده است. در این موارد، اگرچه علائم حرارتی شاخصی از التهاب یا عدم تقارن قابل توجه در نقشه‌ها دیده نمی‌شود، اما وجود برخی نواحی با رنگ‌های مایل به صورتی یا بنفش در کناره‌های پا، باعث شده است که مدل با اطمینان متوسط 0.61 تا 0.57 $p(\text{DM})$ آن‌ها را به‌عنوان دیابتی پیش‌بینی کند. این نتایج نشان می‌دهند که مدل در مواردی که نواحی گرم موضعی ناشی از فشار یا نویز تصویربرداری وجود دارند، ممکن است دچار بیش‌تفسیر و خطای طبقه‌بندی مثبت کاذب شود.



شکل ۱۰: موارد پیش‌بینی اشتباه افراد سالم به‌عنوان دیابتی [۱۹]

برای ارزیابی دقیق عملکرد معماری پیشنهادی، نتایج آن با چند رویکرد پایه (baseline) که تنها از داده‌های تصویری استفاده می‌کنند مقایسه شد. نتایج این مقایسه در جدول ۱ نمایش داده شده است. این مدل‌های پایه شامل سه ساختار بودند: نخست، مدل EfficientNetV2-S با ورودی شش کاناله (channel-stack) که در آن دو تصویر حرارتی پای چپ و راست به صورت کانال‌های جداگانه روی هم انباشته شده و به عنوان ورودی یک تصویر با شش کانال به مدل داده شدند. دوم، EfficientNetV2-S با ورودی اتصال افقی (H-concat) که در آن دو تصویر چپ و راست در راستای افقی به یکدیگر متصل شده و به صورت یک تصویر پهن با عرض دو برابر وارد مدل گردیدند. سوم، مدل ResNet50V2 با ورودی افقی که ساختاری مشابه حالت دوم داشت، اما از یک‌بون ResNet50V2 به جای EfficientNetV2-S استفاده می‌کرد. این سه مدل پایه صرفاً بر تحلیل اطلاعات تصویری متکی بودند و هیچ‌گونه داده عددی (جدولی) را در فرآیند یادگیری لحاظ نمی‌کردند.

نتایج حاصل از آزمون این مدل‌ها بر روی مجموعه آزمون نشان داد که اگرچه هر سه روش پایه توانستند تا حدی بیماران مبتلا به پای دیابتی را از افراد سالم تفکیک کنند، اما عملکرد آن‌ها از نظر معیارهای کلیدی به‌طور قابل‌توجهی پایین‌تر از معماری پیشنهادی بود. به‌طور خاص، مدل ResNet50V2 اگرچه حساسیت ۱۰۰٪ را ثبت کرد، اما ویژگی آن صفر بود و تمام نمونه‌های گروه کنترل را به اشتباه در گروه دیابتی قرار داد که این امر بیانگر بروز مثبت‌های کاذب فراوان و ناتوانی مدل در تشخیص صحیح افراد سالم است. دو مدل مبتنی بر EfficientNetV2-S عملکرد نسبتاً بهتری داشتند و به دقت کلی ۹۲/۳٪، حساسیت ۱۰۰٪ و ویژگی ۶۶/۷٪ دست یافتند، اما همچنان چند نمونه مثبت کاذب تولید کردند که از نظر بالینی می‌تواند منجر به هشدارهای اشتباه و آزمون‌های غیرضروری شود. در مقابل، معماری پیشنهادی که بر پایه EfficientNetB3 و در قالب ساختار سیامی طراحی شده است، با بهره‌گیری از دو شاخه همتا برای استخراج ویژگی از تصاویر چپ و راست و محاسبه دو بردار ترکیبی $|L-R|$ و $L \odot R$ ، و همچنین ادغام این ویژگی‌های تصویری با داده‌های عددی بیمار در سطح ویژگی، توانست به دقت ۹۶/۱۵٪، حساسیت ۹۵٪، ویژگی ۱۰۰٪ و نمره F1 برابر با ۹۷/۴۴٪ دست یابد. این نتایج نشان می‌دهد که ادغام چندوجهی داده‌ها نقشی تعیین‌کننده در افزایش قدرت تعمیم، کاهش خطاهای مثبت و منفی کاذب، و بهبود عملکرد کلی مدل ایفا می‌کند.

در مجموع، این مقایسه بیانگر آن است که صرف افزایش عمق یا پیچیدگی معماری‌های بینایی به تنهایی تضمینی برای بهبود عملکرد در تشخیص پای دیابتی نیست؛ بلکه ترکیب داده‌های چندمنبعی (تصویری و عددی) و طراحی ساختارهای چندشاخه‌ای نظیر سیامی می‌تواند دقت و پایداری مدل را به‌طور چشمگیری ارتقا دهد. این یافته تأکید می‌کند که معماری پیشنهادی قادر است با درک جامع‌تر از الگوهای حرارتی و بالینی، در تشخیص زودهنگام پای دیابتی عملکردی قابل‌اعتماد و برتر نسبت به مدل‌های صرفاً تصویری ارائه دهد.

جدول ۱: مقایسه عملکرد مدل پیشنهادی EfficientNetB3 (سیامی+جدولی) با مدل‌های پایه صرفاً تصویری در مجموعه آزمون

روش	نوع ورودی	مدل	روش ادغام	دقت کلی	حساسیت	ویژگی	دقت مثبت	امتیاز F1
روش پیشنهادی	ترموگرام + داده جدولی	EfficientNetB3 (Siamese)	Embedding-level: $ L-R + L \odot R + \text{Late Tabular Fusion}$	۰/۹۶۱۵	۰/۹۵	۱/۰۰	۱/۰۰	۰/۹۷۴۴
مدل پایه شش کاناله	ترموگرام پای چپ و راست	EfficientNetV2-S	Channel stack ($300 \times 300 \times 6 \rightarrow 1 \times 1 \text{ Conv} \rightarrow 3\text{ch}$)	۰/۹۲۳۱	۱/۰۰	۰/۶۶۶۷	۰/۹۰۹۱	۰/۹۵۲۴
مدل پایه با الحاق افقی	ترموگرام پای چپ و راست	EfficientNetV2-S	Channel stack ($6\text{ch} \rightarrow 1 \times 1 \text{ Conv} \rightarrow 3\text{ch}$)	۰/۹۲۳۱	۱/۰۰	۰/۶۶۶۷	۰/۹۰۹۱	۰/۹۵۲۴
مدل پایه ResNet50V2	ترموگرام با الحاق افقی چپ و راست	ResNet50V2	Horizontal concat ($3 \times 600 \times 300$)	۰/۷۶۹۲	۱/۰۰	۰/۰۰	۰/۷۶۹۲	۰/۸۶۹۶



این پژوهش به ارائه و ارزیابی یک معماری سیامی چندوجهی مبتنی بر EfficientNetB3 برای تشخیص پای دیابتی با استفاده از ترموگرافی و داده‌های عددی همراه پرداخت. برخلاف اغلب پژوهش‌های پیشین که صرفاً بر تحلیل‌های آماری یا ویژگی‌های دستی متکی بودند، مدل پیشنهادی با بهره‌گیری از یادگیری عمیق و ادغام همزمان تصاویر ترموگرافی دو پا و داده‌های جدولی، توانست عملکرد قابل توجهی به دست آورد. معماری ارائه شده با استخراج ویژگی از دو تصویر چپ و راست و ترکیب آن‌ها به صورت $|L-R|$ و $L \odot R$ و همچنین الحاق این بردارها با داده‌های عددی نرمال‌سازی شده، قادر بود الگوهای ظریف و نامتقارن حرارتی را به طور مؤثر شناسایی کند. نتایج تجربی نشان داد که مدل پیشنهادی در مجموعه آزمون به دقت کلی ۹۶/۱۵٪، حساسیت ۹۵٪ و ویژگی ۱۰۰٪ دست یافت و از نظر شاخص‌هایی مانند F1 و دقت متوازن (Balanced Accuracy) نیز عملکرد بسیار بالایی داشت. مقایسه با مدل‌های پایه نظیر EfficientNetV2-S و ResNet50V2 که صرفاً داده‌های تصویری را دریافت می‌کردند، نشان داد که افزودن داده‌های جدولی و طراحی معماری سیامی، موجب بهبود چشمگیر دقت، کاهش مثبت‌های کاذب و افزایش پایداری پیش‌بینی‌ها شده است. این یافته‌ها نشان می‌دهد که ترکیب داده‌های چندوجهی در سطح ویژگی می‌تواند نقشی کلیدی در ارتقای قدرت تعمیم مدل‌های هوش مصنوعی در حوزه سلامت ایفا کند.

به طور کلی، نتایج این پژوهش اثبات می‌کند که استفاده از رویکردهای چندوجهی و یادگیری عمیق می‌تواند مسیری نوین برای توسعه سامانه‌های غیرتهاجمی، دقیق و سریع در غربالگری و پایش بیماران دیابتی فراهم آورد. با این حال، برای تعمیم‌پذیری بالینی این مدل، اجرای مطالعات آینده با حجم نمونه بیشتر، تنوع بالاتر در جمعیت بیماران، و بررسی مداخلات طولی ضروری به نظر می‌رسد. همچنین افزودن داده‌های تکمیلی نظیر فشار کف پا یا اطلاعات جریان خون می‌تواند دقت مدل را بیش از پیش افزایش دهد.

تعارض منافع

بین نویسندگان هیچ گونه تعارض منافع وجود ندارد.

حمایت مالی

این پژوهش در قالب رساله کارشناسی ارشد در دانشگاه ولی عصر (عج) رفسنجان انجام شده است و فاقد حمایت مالی می‌باشد.

اعلام استفاده از هوش مصنوعی (AI)

در فرایند آماده‌سازی این مقاله، از ابزار هوش مصنوعی مولد ChatGPT صرفاً به منظور بهبود نگارش، روان‌سازی جملات و اصلاح ساختار زبانی بخش‌هایی از متن استفاده شده است. طراحی پژوهش، توسعه مدل، کدنویسی، تحلیل داده‌ها، تفسیر و تدوین محتوای علمی مقاله توسط نویسندگان انجام شده است. تمامی مطالب تولیدشده یا ویرایش‌شده با کمک این ابزار، توسط نویسندگان به دقت بررسی شد.

کد اخلاق

این مطالعه دارای مجوز از کمیته اخلاق دانشگاه علوم پزشکی کرمان با کد IR.KMU.REC.1405.142 می‌باشد.

سهام مشارکت نویسندگان

تمامی نویسندگان در بخش‌های مختلف مشارکت داشته‌اند و از سهم مساوی برخوردار می‌باشند.

References

- [1]. Katsilambros N, Dounis E, Makrilakis K, Tentolouris N, Tsapogas P. Atlas of the diabetic foot. John Wiley & Sons; 2010. doi:10.1002/9781444317589
- [2]. Singh N, Armstrong DG, Lipsky BA. Preventing foot ulcers in patients with diabetes. JAMA 2005;293(2):217-28. doi: 10.1001/jama.293.2.217

- [3]. National Diabetes Data Group (US), National Institute of Diabetes, Digestive, Kidney Diseases (US). Diabetes in America. National Institutes of Health, National Institute of Diabetes and Digestive and Kidney Diseases; 1995.
- [4]. Karrer S. Diabetisches Fußsyndrom. Der Hautarzt 2011;62(7):493-503. [In German] doi: [10.1007/s00105-010-2112-7](https://doi.org/10.1007/s00105-010-2112-7)
- [5]. aan de Stegge WB, Mejaiti N, van Netten JJ, Dijkgraaf MG, van Baal JG, Busch-Westbroek TE, et al. The cost-effectiveness and cost-utility of at-home infrared temperature monitoring in reducing the incidence of foot ulcer recurrence in patients with diabetes (DIATEMP): study protocol for a randomized controlled trial. Trials 2018;19(1):520. doi: [10.1186/s13063-018-2890-2](https://doi.org/10.1186/s13063-018-2890-2)
- [6]. Rincón Y, Gil V, Pacheco J, Benítez I, Sánchez M. Evaluación y tratamiento del pie diabético. Revista Venezolana de Endocrinología Y Metabolismo 2012;10(3):176-87.
- [7]. Armstrong DG, Boulton AJ, Bus SA. Diabetic foot ulcers and their recurrence. N Engl J Med 2017;376(24):2367-75. doi: [10.1056/NEJMr1615439](https://doi.org/10.1056/NEJMr1615439)
- [8]. Ilo A, Romsa P, Mäkelä J. Infrared thermography and vascular disorders in diabetic feet. J Diabetes Sci Technol 2020;14(1):28-36. doi: [10.1177/1932296819871270](https://doi.org/10.1177/1932296819871270)
- [9]. Hidalgo Salvador E, Álvarez González F, Salvador Luna A. Application of Infrared thermography in legal medicine. Is it a valid test for an objective assessm. Cuad Med Forense 2014;20:77-84. <https://dx.doi.org/10.4321/S1135-76062014000200002>.
- [10]. Liu C, van Netten JJ, Van Baal JG, Bus SA, van Der Heijden F. Automatic detection of diabetic foot complications with infrared thermography by asymmetric analysis. J Biomed Opt 2015;20(2):26003. doi: [10.1117/1.JBO.20.2.026003](https://doi.org/10.1117/1.JBO.20.2.026003)
- [11]. Kurkela O, Lahtela J, Arffman M, Forma L. Infrared thermography compared to standard care in the prevention and care of diabetic foot: a cost analysis utilizing real-world data and an expert panel. Clinicoecon Outcomes Res 2023;15:111-23. doi: [10.2147/CEOR.S396137](https://doi.org/10.2147/CEOR.S396137)
- [12]. Lavery LA, Higgins KR, Lanctot DR, Constantinides GP, Zamorano RG, Armstrong DG, Athanasiou KA, Agrawal CM. Home monitoring of foot skin temperatures to prevent ulceration. Diabetes Care 2004;27(11):2642-7. doi: [10.2337/diacare.27.11.2642](https://doi.org/10.2337/diacare.27.11.2642)
- [13]. Peregrina-Barreto H, Morales-Hernandez LA, Rangel-Magdaleno JJ, Avina-Cervantes JG, Ramirez-Cortes JM, Morales-Caporal R. Quantitative estimation of temperature variations in plantar angiosomes: a study case for diabetic foot. Comput Math Methods Med 2014;2014:585306. doi: [10.1155/2014/585306](https://doi.org/10.1155/2014/585306)
- [14]. Hernandez-Contreras D, Peregrina-Barreto H, Rangel-Magdaleno J, Gonzalez-Bernal J. Narrative review: Diabetic foot and infrared thermography. Infrared Physics & Technology. 2016;78:105-17. doi: [10.1016/j.infrared.2016.07.013](https://doi.org/10.1016/j.infrared.2016.07.013)
- [15]. Hernandez-Contreras D, Peregrina-Barreto H, Rangel-Magdaleno J, Gonzalez-Bernal JA, Altamirano-Robles L. A quantitative index for classification of plantar thermal changes in the diabetic foot. Infrared Physics & Technology 2017;81:242-9. doi: [10.1016/j.infrared.2017.01.010](https://doi.org/10.1016/j.infrared.2017.01.010)
- [16]. Hernandez-Contreras DA, Peregrina-Barreto H, Rangel-Magdaleno JD, Orihuela-Espina F. Statistical approximation of plantar temperature distribution on diabetic subjects based on beta mixture model. IEEE Access 2019;7:28383 – 91. doi: [10.1109/ACCESS.2019.2902502](https://doi.org/10.1109/ACCESS.2019.2902502)
- [17]. Torrealblanca González J, Gómez-Martín B, Hernández Encinas A, Martín-Vaquero J, Queiruga-Dios A, Martínez-Nova A. The use of infrared thermography to develop and assess a wearable sock and monitor foot temperature in diabetic subjects. Sensors 2021;21(5):1821. doi: [10.3390/s21051821](https://doi.org/10.3390/s21051821)
- [18]. Anaya-Isaza A, Zequera-Diaz M. Detection of diabetes mellitus with deep learning and data augmentation techniques on foot thermography. IEEE Access 2022;10:59564-91.
- [19]. Hernandez-Contreras DA, Peregrina-Barreto H, de Jesus Rangel-Magdaleno J, Renero-Carrillo FJ. Plantar thermogram database for the study of diabetic foot complications. IEEE Access 2019;7:161296-307. doi: [10.1109/ACCESS.2019.2951356](https://doi.org/10.1109/ACCESS.2019.2951356)
- [20]. Tan M, Le Q. Efficientnet: Rethinking model scaling for convolutional neural networks. In International Conference on Machine Learning 2019; 6105-14. <https://doi.org/10.48550/arXiv.1905.11946>
- [21]. Panamonta V, Jerawatana R, Ariyaprayoon P, Looareesuwan P, Ongphiphadhanakul B, Sripradpradang C, et al. Plantar thermogram analysis using deep learning for diabetic foot risk classification. J Diabetes Sci Technol 2025;20(3):810–4. doi: [10.1177/19322968251316563](https://doi.org/10.1177/19322968251316563)
- [22]. Khandakar A, Chowdhury ME, Reaz MB, Ali SH, Abbas TO, Alam T, et al. Thermal change index-based diabetic foot thermogram image classification using machine learning techniques. Sensors 2022;22(5):1793. doi: [10.3390/s22051793](https://doi.org/10.3390/s22051793)
- [23]. Wang H, Jin L, Sun X, He Y. S-VFNet: a siamese object detection method based on salient features and visual features. Meas Sci Technol 2025;36(8):086113. doi: [10.1088/1361-6501/adf3d7](https://doi.org/10.1088/1361-6501/adf3d7)