

رده‌بندی تصاویر سرطان پوست با استفاده



از یادگیری عمیق جمعی دو سطحی

پویان جابری^۱، شہلا نعمتی^{۲*}، محمد احسان بصیری^۳

^۱ کارشناسی ارشد مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران

^{۲*} استادیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران

^۳ دانشیار گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران

چکیده

برخی از مشکلات پوستی خوش‌خیم و بی‌ضرر و برخی دیگر توده‌های بدخیمی هستند که با تشخیص به‌موقع می‌توانند همچنان بی‌ضرر بمانند. در این پژوهش، یک روش یادگیری عمیق جمعی دوسطحی برای رده‌بندی تصاویر پزشکی سرطان پوست پیشنهاد می‌شود. در مدل پیشنهادی از یادگیری عمیق در دو سطح استفاده شده‌است و سپس در هر سطح از الگوریتم CatBoost برای ترکیب این مدل‌ها استفاده می‌شود. نتایج مدل پیشنهادی با شبکه‌های عمیق تک‌سطح و پژوهش‌های مشابه پیشین مقایسه شده‌است. نتایج نشان می‌دهد که مدل پیشنهادی عملکرد بهتری در رده‌بندی تصاویر سرطان پوست دارد. عملکرد مدل پیشنهادی، چه در هر یک از کلاس‌ها و چه در کل، از تمامی مدل‌های یادگیری عمیق مستقل بهتر بوده‌است. همچنین نشان داده شده که استفاده از VGG-Ensemble در کنار روش پیشنهادی و ترکیب نتایج آن به کمک CatBoost و تشکیل یک مجمع دوسطحی، عملکرد آن را در هر کلاس نیز بهبود داده‌است.

واژگان کلیدی: یادگیری عمیق، یادگیری جمعی، سرطان پوست، خوش‌خیم، بدخیم.

Classification of skin cancer images using two-level ensemble deep learning

Pouyan Jaberi¹, Shahla Nemati^{2*}, Mohammad Ehsan Basiri³

Master Student, Department of Computer Engineering, Shahrekord University, Iran¹

Assistant Professor, Department of Computer Engineering, Shahrekord University, Iran²

Associate Professor, Department of Computer Engineering, Shahrekord University, Iran³

Abstract

Today, despite the tremendous advances in medical science and technology, access to a specialist doctor is still considered a major challenge. This challenge is of great importance for diseases such as cancer. Skin cancer is the 13th most common cancer in men and the 15th most common cancer in women. While some skin problems are benign and harmless, some of them can be malignant masses, which will remain harmless if they are diagnosed in time. When consulting a specialist doctor may be time-consuming and expensive, an intelligent system can be a fast alternative or, at least, an efficient preliminary treatment solution. For skin cancer, such intelligent system may utilize the images of suspicious skin masses labeled according to their benign or malignant state by specialist physicians. These labeled images are useful for training intelligent systems which should diagnose the potential problems in unseen new images.

In this research, a novel deep learning-based approach is proposed for the problem of classifying skin cancer images into two categories of benign and malignant images. In the proposed model, powerful

* Corresponding author

* نویسنده عهده‌دار مکاتبات

deep learning models for image classification including VGG, ResNet, and Inception are used in two levels. Specifically, we formed two ensembles; VGG ensemble which consists of VGG-16 and VGG-19 models and ResNet ensemble which consists of ResNet152, ResNet50, and Inception models. CatBoost algorithm is used in each level to combine the models on that ensemble. Finally, at the next level, two ensembles were combined using the CatBoost algorithm. The proposed ensemble model tries to improve the accuracy and consistency of the results by aggregating the deep models at its two levels. In order to show the utility of the proposed model, a subset of ISIC public dataset for skin cancer images is used for training and evaluation of models. The performance of the proposed ensemble model is compared with several deep neural networks and previous similar researches. Specifically, we compared the results achieved by the proposed model with those obtained by existing similar deep models and those used as building blocks of the proposed model. The results show that the proposed model performs better in classifying skin cancer images. The performance of the proposed model, both in each of the classes and in general, has been better than all independent deep learning models. It has also been shown that using VGG ensemble along with this proposed model by combining its results with the help of CatBoost and forming a two-level ensemble has improved its independent performance in each class.

Keywords: Deep Learning, Ensemble Learning, Skin Cancer, Benign, Malignant.

۱-مقدمه

برخلاف پیشرفت‌های شگرف در علوم پزشکی، همچنان دسترسی به پزشک و به‌ویژه پزشک متخصص نزد عموم یک چالش به‌شمار می‌رود؛ به‌ویژه که در شماری از نواحی جهان، نسبت تعداد پزشکان به جمعیت محلی بسیار کم‌تر از آستانه استاندارد است [۱]. مطابق داده‌های بانک جهانی، در جهان به‌ازای هر هزار نفر جمعیت تنها ۱.۸ نفر پزشک وجود دارد که این مقدار در کشور ایران به ۱.۶ می‌رسد (این نسبت‌ها براساس آخرین داده‌های موجود تا ۲۰۲۰ محاسبه و در شکل (۱) نشان داده شده‌است) [۱].



(شکل-۱): شمار پزشکان به هر هزار نفر جمعیت در کشورهای جهان براساس آخرین داده‌های موجود تا ۲۰۲۰ [۱].
(Figure-1): The number of doctors per thousand population in the countries of the world [۱].

تشخیص خودکار بیماری‌ها به‌صورت هوشمند می‌تواند دوره طلایی درمان بیماری را زودتر تشخیص داده و کمک کند بیماری به‌موقع درمان شود [۲]، [۳]. در سال‌های اخیر فناوری اطلاعات و به‌خصوص هوش مصنوعی در زمینه پزشکی و مراقبت‌های بهداشتی، پیشرفت‌های زیادی برای تشخیص و پیشنهاددهی درمان داشته‌است [۴]، [۵]. معمولاً منظور از هوش مصنوعی در پزشکی

استفاده از مدل‌های یادگیری ماشین برای جستجوی داده‌های پزشکی و کشف اطلاعاتی برای کمک به‌بهبود نتایج سلامت و تجربیات بیمار است.

در این پژوهش نمونه‌ای از زیرمسائل یادگیری ماشین یعنی رده‌بندی تصاویر سرطان پوست را بررسی خواهیم کرد؛ که یک نمونه از یادگیری نظارتی هستند. در این نوع مسائل، یک مجموعه داده شامل تعدادی تصویر و همچنین برچسب‌های متناظر با هر تصویر در اختیار مدل قرار می‌گیرد تا مدل بتواند با دیدن هر تصویر برچسب نظیر آن را تولید کند. ارزیابی مدل نیز با ارائه مجموعه تصاویری جدید که پیش‌تر توسط مدل دیده نشده‌است و مقایسه برچسب‌های پیش‌بینی‌شده توسط مدل با برچسب‌های واقعی آن‌ها انجام می‌گیرد [۴]، [۶]. نمای کلی مسئله رده‌بندی تصاویر سرطان پوست به‌عنوان یک مسئله یادگیری نظارتی در شکل (۲) نشان داده شده‌است.

از جمله چالش‌برانگیزترین مراحل در یادگیری ماشین به‌شکل سنتی، می‌توان به مهندسی ویژگی‌ها^۱ اشاره کرد که شامل شناسایی و استخراج ویژگی‌های اثرگذار در نتیجه موردنظر می‌شود تا با استفاده از یادگیری ماشین بتوان میان آن‌ها و نتیجه نهایی، رابطه‌ای کشف‌کرده و مدلی تشکیل داد، اما در رویکردهای نوین یادگیری ماشین و به‌ویژه یادگیری عمیق، تلاش براین است که این مرحله نیز به‌طور خودکار انجام شود. [۴]. یادگیری عمیق^۲ تلاش می‌کند تا ویژگی‌هایی سطح بالا و عموماً انتزاعی را از داده‌های خام ورودی استخراج و سپس از آن‌ها برای انجام

¹ Feature Engineering

² Deep Learning


عملیاتی چون خوشه‌بندی، رده‌بندی و... استفاده کند [۷]، [۸].

درخصوص تصاویر، خودکارسازی مرحله مهندسی ویژگی‌ها به این معناست که مدل بتواند تشخیص دهد که به کدام جزئیات موجود در تصویر ورودی توجه کند و چه چیزهایی را نادیده بگیرد، اما مشکل اصلی این است که اجرای چنین عملیاتی با شبکه‌های عصبی تمام‌متصل^۱ بسیار هزینه‌بر انجام می‌پذیرد؛ چراکه:

۱- تک‌تک پیکسل‌های موجود در تصویر باید به عنوان ورودی به شبکه راه پیدا کنند و برای تصاویر رنگی نیز هر کانال رنگ، خود نیازمند ورودی مجزا است و باتوجه به اینکه در یک شبکه تمام‌متصل، هر نورون به تمامی نورون‌های لایه پس از خود متصل است، تعداد اتصالات و در نتیجه تعداد پارامترها، بسیار زیاد می‌شود.

۲- در ورودی یک شبکه تمام‌متصل، تصاویر دوبعدی (و چندبُعدی - مثل تصاویر MRI) به ماتریس‌هایی یک‌بُعدی تبدیل می‌شوند؛ لذا شبکه نمی‌تواند از تجربه‌ای که در یافتن ویژگی‌ها در قسمتی خاصی از یک تصویر به دست آورده‌است، برای یافتن همان ویژگی‌ها در قسمت دیگری از یک تصویر دیگر نیز استفاده کند.

نتیجه آنکه ضروری است به‌شکلی بتوان ابعاد تصاویر را کاهش داد، ویژگی‌های اصلی موجود در تصاویر را نیز حفظ و یا حتی به‌شکلی رمزنگاری کرد [۹].



(شکل-۲): نمای کلی مسئله رده‌بندی تصاویر سرطان پوست

به عنوان یک مسئله یادگیری نظارتی [۶].

(Figure-2): Overview of the skin cancer classification problem as a supervised learning problem [6].

یکی از بهترین روش‌های استخراج ویژگی که به‌ویژه در داده‌های تصویری نیز کاربرد گسترده‌ای دارد، شبکه‌های عصبی کانولوشن^۲ (CNN) است [۱۰]. در این

نوع شبکه، استخراج ویژگی‌ها از طریق قراردادن پالایه‌هایی بر روی داده‌های ورودی انجام شده‌است و به‌طورمعمول با استفاده از لایه‌های ادغام نیز کاهش ابعاد انجام می‌پذیرد. درنهایت، آنچه حاصل می‌شود یک نقشه ویژگی بوده که دارای ابعادی بسیار کوچک‌تر از داده ورودی و دربردارنده ویژگی‌های اصلی موجود در داده‌است. حال بسته به هدف، می‌توان این نقشه ویژگی را به عنوان ورودی برای یک شبکه عصبی دیگر در نظر گرفت.

مشکل بعدی در شبکه‌های عصبی عمیق بزرگ استفاده شده در پردازش تصاویر دقت و اطمینان شبکه است. برای پاسخ به این مشکل از رویکردهای متفاوتی در یادگیری ماشین استفاده شده‌است. یکی از این رویکردها یادگیری جمعی^۳ است که تلاش می‌کند چندین مدل یادگیرنده را هم‌زمان به کار گرفته و نتیجه نهایی را از به هم پیوند دادن نتایج مدل‌های جداگانه به دست آورد [۱۱].

یادگیری جمعی عمیق روشی برای بهره‌مندی هم‌زمان از مزایای یادگیری جمعی و یادگیری عمیق است؛ به این‌سان که چند مدل یادگیری عمیق در کنار یکدیگر به کار گرفته شده و نتیجه نهایی با استفاده از روش‌های مرسوم در یادگیری جمعی فرآوری می‌شود. ایده بنیادین این است که یک مدل استوار بر یادگیری جمعی عمیق، در سنجش با مدل‌های مستقل، تعمیم‌پذیری بیشتر و برابندی بهتر را به همراه داشته‌باشد [۱۲].

در پژوهش حاضر، باتوجه به قدرت بالای مدل‌های مبتنی بر شبکه‌های عصبی کانولوشن برای استخراج ویژگی، مدلی ترکیبی برای به کارگیری پنج نوع شبکه کانولوشنی برتر پیشنهاد خواهد شد؛ همچنین برای استفاده هم‌زمان مزایای یادگیری جمعی و یادگیری عمیق از یادگیری جمعی عمیق استفاده خواهد شد.

در این پژوهش، روشی برای پیکربندی و پیاده‌سازی یک مدل مبتنی بر یادگیری جمعی عمیق برای رده‌بندی تصاویر پزشکی سرطان پوست پیشنهاد شده‌است. در مدل پیشنهادی یادگیری عمیق ترکیبی دوسطحی براساس پنج مدل کانولوشنی رایج و برتر سال‌های اخیر پیشنهاد شده‌است. به صورت دقیق‌تر مدل‌ها را به دو مجمع مجزا تقسیم کرده که خود مجمع در یک سطح بالاتر تشکیل مجمع جدیدی می‌دهند؛ یعنی خروجی مجمع سطح نخست خود به عنوان ورودی یک الگوریتم ترکیب‌کننده

³ Ensemble Learning

¹ Fully Connected

² Convolutional Neural Network (CNN)

دیگر در نظر گرفته شده و به این ترتیب مجمعی دولایه داریم. همچنین برای ترکیب کننده هر مجمع نیز برخلاف پژوهش های پیشین دوباره از یادگیری ماشین استفاده کردیم. انگیزه استفاده از پنج نوع شبکه کانولوشنی برتر، قدرت بالای مدل های مبتنی بر شبکه های عصبی کانولوشن برای استخراج ویژگی است. همچنین انگیزه استفاده از یادگیری جمعی عمیق نوآوری پژوهش حاضر نسبت به پژوهش های پیشین موارد زیر است:

- برخلاف پژوهش های پیشین و همچنین با هدف افزایش بایاس، در مدل پیشنهادی در سطح نخست مجمع، مدل های هم خانواده با معماری های مشابه در یک گروه قرار می گیرند.
- خروجی ترکیب کننده های مجامع VGG و ResNet خود به عنوان ورودی یک الگوریتم ترکیب کننده دیگر در نظر گرفته شده و به این ترتیب مجمعی دولایه پیشنهاد شده است.
- همچنین در روش پیشنهادی، برای ترکیب کننده هر مجمع نیز برخلاف دو پژوهش پیشین و استفاده از روشی چون رأی اکثریت یا میانگین گیری وزن دار، دوباره از یادگیری ماشین استفاده شده و الگوریتم CatBoost انتخاب شده است.

۲- پژوهش های پیشین

به طور کلی دو دسته از پژوهش های پیشین مورد بررسی قرار گرفتند:

- پژوهش هایی در خصوص عملکرد یادگیری عمیق جمعی (به ویژه در رده بندی تصاویر پزشکی)؛
 - پژوهش هایی که از شبکه های عصبی عمیق مطرح برای رده بندی تصاویر پزشکی استفاده کرده اند.
- بدیهی است که پژوهش های پرشماری در این دو مورد می توان یافت؛ لذا در این پژوهش، اغلب بر پژوهش های سال های اخیر و همچنین مقالات جامعی که شمار زیادی از پژوهش های مرتبط را بررسی کرده اند، تمرکز شده است که در ادامه به اختصار به آن ها اشاره خواهد شد.

۲-۱- یادگیری ژرف جمعی

پژوهش گانا و همکاران [۱۲]، از محدود پژوهش هایی است که به مرور جامع یادگیری عمیق جمعی و بررسی و مقایسه شاخص ترین مدل های مبتنی بر این روش پرداخته است. در این مقاله، پس از بررسی مختصر نظریه

یادگیری جمعی، روش های گوناگونی جهت تشکیل یک مجمع از جمله دسته بندی، توان افزایی و انباشتگی را بازبینی کرده و همچنین استفاده از مدل های یادگیری عمیق در مجمع ها را مورد بررسی قرار داده است.

کینی و همکاران [۱۳] اقدام به توسعه یک چارچوب به منظور تشخیص خودکار ابتلا به بیماری کووید-۱۹ بر پایه تصاویر CT سینه کرده اند که در آن تجهیزات پزشکی مجهز به اینترنت اشیا^۱ (IoT) متصل به شبکه های بوده که از طریق آن داده ها خود را به یک لایه ذخیره سازی داده ارسال می کنند. تشخیص بیماری در لایه مجزایی موسوم به لایه پردازش داده انجام شده و نتایج آن در یک لایه کاربردی به دست کاربران (از جمله پزشکان) می رسد.

لایه پردازش داده در این پژوهش از یک مجمع یادگیری عمیق تک سطحی تشکیل شده است، که از سه مدل DenseNet201، ResNet152V2 و InceptionResNetV2 بهره می برد؛ همچنین ترکیب نتایج سه مدل از روش رأی نسبی اکثریت انجام می شود. به بیانی دیگر، در ابتدا سه مدل مبتنی بر شبکه های عصبی کانولوشنی تصاویر را به عنوان ورودی دریافت کرده و یک پیش بینی درباره رده هر یک انجام می دهند) برای مثال اینکه آیا تصویر CT مورد نظر متعلق به بیماری مبتلا به کووید-۱۹ است یا خیر. (تصمیم نهایی براساس رأی نسبی اکثریت میان این سه مدل گرفته می شود که این بخش، ترکیب کننده نام دارد [۱۳].

در پژوهشی مشابه، داس و همکاران [۱۴] برای رده بندی تصاویر X-ray سینه برای تشخیص ابتلا به کووید-۱۹ از سه مدل DenseNet201، ResNet50V2 و InceptionV3 استفاده کرده اند. این بار نتیجه نهایی با نوعی میانگین گیری وزن دار انجام می شود که توسط همین پژوهش معرفی شده است. گفتنی است که دو مدل معرفی شده در [۱۳]، [۱۴] به دلیل تشابه با مدل پیشنهادی در پژوهش جاری، گزینه هایی برای مقایسه با روش پیشنهادی در نظر گرفته شده اند.

۲-۲- تشخیص تصاویر پزشکی با یادگیری عمیق

در [۱۵] مرور جامعی بر پژوهش های سال های اخیر در زمینه تشخیص سرطان پوست با روش های یادگیری عمیق انجام شده است. این بررسی نشان دهنده نقش بسیار پررنگ شبکه های عصبی کانولوشنی در بررسی و به ویژه رده بندی تصاویر پزشکی سرطان پوست با کمک یادگیری عمیق است.

¹ Internet of Things

دو رده خوش خیم و بدخیم تقسیم می شوند (به ترتیب شامل ۱۸۰۰ و ۱۴۹۷ تصویر). نمونه ای از تصاویر رده خوش خیم و بدخیم در شکل های (۳) و (۴) نشان داده شده است. این مجموعه داده به صورت آزاد در [۱۹] در دسترس است.

در پژوهش حاضر، ۴۰٪ مجموعه داده (۹۲۶ داده از رده خوش خیم و ۶۰۵ داده از رده بدخیم) برای آموزش و ۶۰٪ باقی مانده (۱۱۰۴ داده از رده خوش خیم و ۸۷۴ داده از رده بدخیم، یا به ترتیب ۵۶٪ و ۴۴٪) که هرگز در طی فرایند یادگیری به مدل ها نشان داده نشده، به منظور ارزیابی استفاده شده است. از ۴۰٪ داده های آموزشی مدل های پایه بر روی ۲۰٪ تصاویر برچسب دار موجود (۶۶۰ تصویر، شامل ۳۳۰ تصویر از هر رده، که تصادفی از مجموعه داده اصلی انتخاب شدند) آموزش دیده اند و ۲۰٪ باقی مانده از داده های آموزشی برای آموزش مدل های CatBoost استفاده شده اند.

۴- معماری مدل پیشنهادی

در این پژوهش با بهره گیری از پنج مدل کانولوشنی رایج و برتر سال های اخیر معماری پیشنهادی یادگیری عمیق ترکیبی دوسطحی که در **Error! Reference source not found.** نشان داده شده است پیشنهاد می شود. مدل های کانولوشنی استفاده شده در معماری پیشنهادی در ادامه معرفی خواهند شد.

۴-۱- مدل های پایه استفاده شده در

معماری پیشنهادی

• VGG-16

این شبکه در رقابت ImageNet سال ۲۰۱۴ جزو پنج شبکه برتر قرار گرفت. ورودی این شبکه، تصاویر رنگی (سه کاناله RGB) در ابعاد ۲۲۴×۲۲۴ بوده و همچنین این شبکه به طور پیش فرض از ۱۶ لایه تشکیل شده است [۱۷].

• VGG-19

دیگر شبکه برتر در رقابت ImageNet سال ۲۰۱۴، شبکه VGG-19 بود که در واقع گونه ارتقا یافته ای از VGG-16 بوده که شمار لایه های کانولوشن آن به ۱۹ عدد افزایش یافته است [۲۰].

• ResNet-50V2

شبکه ResNet50 از جمله شبکه های شناخته شده است و در رقابت ImageNet سال ۲۰۱۵ نیز از جمله شبکه های برتر بود. ResNet50V2 گونه اصلاح شده ای از

در [۱۶] کاسم و همکاران، با به کارگیری شبکه GoogLeNet برای استخراج ویژگی و یک مدل SVM برای رده بندی، اقدام به توسعه مدلی برای رده بندی تصاویر سرطان پستان در هشت کلاس از مجموعه داده ISIC 2019 کرده است. نویسندگان در [۱۷]، یک شبکه VGG-16 را بر روی ۱۲۸۰ تصویر سرطان پستان از آرشیو ISIC، برای رده بندی در دو کلاس، آموزش داده و ارزیابی کرده اند.

همچنین در [۱۸] عملکرد شبکه های ResNet50، InceptionV3، DenseNet169، InceptionResNetV2 و MobileNet را بر روی ۳۶۰۰ تصویر از آرشیو ISIC در یک کلاس (بدخیم یا غیربدخیم) مقایسه کرده است. بیشترین دقت با استفاده از ResNet50 حاصل شده است. مختصری از این پژوهش ها در جدول (۱) آورده شده است. همان گونه که در مقدمه ذکر شد، تمرکز پژوهش جاری بر روی معرفی روشی نوین بر مبنای یادگیری عمیق جمعی است؛ به منظور آزمایش و ارزیابی این روش، تصاویر سرطان پستان استفاده شده اند.

(جدول-۱): مدل های مورد بررسی در پژوهش های پیشین.

(Table-1): The models examined in previous researches.

پژوهش	توضیحات	مجموعه داده ها	سال
[۱۳]	ResNet152V2 ، DenseNet201 و Inception-ResNetV2 با استفاده رأی نسبی اکثریت	تصاویر CT سینه	۲۰۲۲
[۱۴]	DenseNet201 ، ResNet50V2 و InceptionV3 با میانگین گیری وزن دار	تصاویر X-ray سینه	۲۰۲۱
[۱۲]	مقاله مروری (روش های یادگیری عمیق جمعی)	-	۲۰۲۱
[۱۵]	مقاله مروری (تشخیص سرطان پوست با یادگیری عمیق)	-	۲۰۲۱
[۱۶]	GoogLeNet+SVM	ISIC 2019	۲۰۲۰
[۱۷]	VGG-16	آرشیو ISIC	۲۰۱۶
[۱۸]	CNN و چند ResNet50 دیگر برای مقایسه	آرشیو ISIC	۲۰۲۱

۳- مجموعه داده

مجموعه داده اصلی مورد استفاده، زیرمجموعه ای از (آرشیو ISIC) مرتبط با تصاویر پزشکی سرطان پستان است که در مجموع شامل ۳۲۹۷ تصویر رنگی (سه کاناله) ۲۲۴×۲۲۴ پیکسل می شود. این تصاویر به

انجام شده است. Inception V3 در جمع از یازده ماژول تشکیل شده که هریک دربرگیرنده لایه های ادغام و پالایه های کانولوشن با تابع ReLU است [۲۲].

۲-۴- ترکیب مدل ها در معماری پیشنهادی

ضمن استفاده از روش یادگیری انتقالی [۲۳]، مدل های پایه بر روی ۲۰٪ تصاویر برچسب دار موجود (۶۶۰ تصویر، شامل ۳۳۰ تصویر از هر رده، که به صورت تصادفی از مجموعه داده اصلی انتخاب شدند) آموزش دیده اند.


برخلاف پژوهش های پیشین و همچنین با هدف افزایش بایاس، پیکربندی سطح نخست مجمع به این شکل انجام می شود که مدل های هم خانواده با معماری های مشابه در کنار یکدیگر و در یک گروه قرار می گیرند؛ لذا به جای اینکه خروجی نهایی براساس رأی اکثریت یا میانگین گیری وزن دار از تمامی مدل های یاد شده به دست آید، این مدل ها در مدل پیشنهادی به دو مجمع مجزا به شکل زیر تقسیم شده است:

- VGG-Ensemble:
- VGG-16
- VGG-19
- ResNet-Ensemble:
- ResNet50V2
- ResNet152V2
- InceptionV3

سپس خودِ مجامع VGG و ResNet در یک سطح بالاتر تشکیل مجمع جدیدی می دهند؛ یعنی خروجی ترکیب کننده های مجامع VGG و ResNet خود به عنوان ورودی یک الگوریتم ترکیب کننده دیگر در نظر گرفته شده و به این ترتیب مجمعی دولایه داریم.


همچنین برای ترکیب کننده هر مجمع نیز برخلاف دو پژوهش پیشین و استفاده از روشی چون رأی اکثریت یا میانگین گیری وزن دار، مجدداً از یادگیری ماشین استفاده کرده و الگوریتم CatBoost انتخاب شده است. این مدل یادگیری جمعی توسط شرکت یاندکس توسعه داده شده و از روش تقویت گرادیان بهره می برد [۲۳]. از دلایل مهم انتخاب این مدل در پژوهش جاری، عملکرد به نسبت بهتر آن در برابر مدل های مشابه، به ویژه هنگام کار با مجموعه های داده کوچک تر است [۲۳]. همچنین در سنجش تجربی انجام شده در [۲۴]، عملکرد CatBoost در برابر دو الگوریتم محبوب مشابه متن باز دیگر در همین حوزه XGBoost و LightGBM مورد سنجش قرار گرفته و نتیجه بهتری نشان داده است. این بار نیز ۲۰٪ دیگری از داده ها برای آموزش مدل های CatBoost استفاده شده اند.

این شبکه است که عملکرد بهتری در قیاس با ResNet50 و ResNet101 دارد. ورودی این شبکه، $224 \times 224 \times 3$ واحد است. همچنین ایده اصلی خانواده ResNet استفاده از روشی موسوم به اتصال جهشی^۱ بوده که در آن خروجی برخی از لایه ها علاوه بر لایه بعدی خود، جهشی به طول چندلایه نیز داشته و به عنوان ورودی یک لایه ژرف تر نیز در نظر گرفته می شود. این امر در سهولت بهینه سازی شبکه و افزایش دقت (در قیاس با شبکه ای مشابه، اما بدون استفاده از این روش) مؤثر است [۱۸].



(شکل -۱): نمونه هایی از تصاویر رده خوش خیم.

(Figure-3): Examples of benign category images



(شکل -۲): نمونه هایی از تصاویر رده بد خیم.

(Figure-4): Examples of malignant category images.


• ResNet152V2

شبکه ResNet152 موفق به کسب مقام نخست در رقابت ImageNet سال ۲۰۱۸ در زمینه دفاع خصمانه شده است. معماری آن شامل ۱۵۲ لایه بود که یکی از ژرف ترین شبکه های مورد استفاده در این پژوهش محسوب می شود. این شبکه ۱۵۲ لایه کانولوشن دارد که به صورت یک درمیان اتصال جهشی انجام می دهند [۲۱].

• InceptionV3

این شبکه در دسامبر ۲۰۱۵ در مقام نخست رقابت ImageNet قرار گرفت و توسعه آن توسط شرکت گوگل

¹ Skip Connection



(شکل-۵): معماری مدل پیشنهادی.
(Figure-5): Architecture of the proposed

به طور معمول در آمار جهت سنجش کارایی یک مدل در رده‌بندی دودویی دو معیار دقت^۶ (P) و بازیابی^۷ (R) به کار می‌روند که به ترتیب به صورت روابط (۱) و (۲) نشان داده می‌شوند [۲۶]:

$$P = \frac{\text{مثبت صحیح}}{\text{مثبت کاذب} + \text{مثبت صحیح}} \quad (۱)$$

$$R = \frac{\text{مثبت صحیح}}{\text{منفی کاذب} + \text{مثبت صحیح}} \quad (۲)$$

به بهای چشم‌پوشی از بازیابی، می‌توان دقت را افزایش داد (و برعکس)؛ لذا توجه انحصاری به هر یک از دو معیار می‌تواند نتایجی گمراه‌کننده داشته باشد؛ پس نیاز است معیاری به کار ببریم که بتواند هر دو معیار یادشده را ترکیب کند و به عنوان شاخصی برای سنجش صحت به کار رود. برای این امر از امتیاز^۸ F1 استفاده می‌کنیم که در رابطه (۳) نشان داده شده است:

$$F_1 = \frac{2.P.R}{P+R} \quad (۳)$$

امتیاز F1 نوعی میانگین هارمونیک بوده که به طور معمول و همچنین در بیشتر مقالات بررسی شده در این پژوهش، برای سنجش صحت رده‌بندهای دودویی مورد استفاده قرار گرفته؛ لذا در این پژوهش نیز این معیار برای بررسی نهایی عملکرد مدل‌ها به کار خواهد رفت.

۶- نتایج ارزیابی

از مجموع تمام ۳۲۹۸ داده‌های برچسب‌دار تصویری ۶۰٪ باقی‌مانده (۱۱۰۴ داده از رده خوش‌خیم و ۸۷۴ داده از رده بدخیم، یا به ترتیب ۵۶٪ و ۴۴٪) که هرگز در طی فرایند یادگیری به مدل‌ها نشان داده نشده، به منظور ارزیابی استفاده شده است. امتیاز F1 برای هر مدل و در هر کلاس محاسبه و در **Error! Reference source not found.** و شکل (۷) نمایش داده شده است.

۵- روش مقایسه

برای بررسی و ارزیابی عملکرد مدل پیشنهادی حالت‌های زیر در نظر گرفته شده است:

۱- هفت مدل CNN مستقل بر روی مجموعه داده‌های همین پژوهش آموزش داده می‌شوند تا اساساً عملکرد مجمع‌ها در برابر عملکرد مدل‌های مستقل سنجیده شود. این مدل‌ها شامل تمامی پنج CNN مورد استفاده در سطح نخست مدل پیشنهادی (VGG-16، VGG-19، ResNet-50V2، ResNet-152V2 و InceptionV3) به علاوه DenseNet201 و InceptionResNetV2 می‌شوند.

۲- یک مجمع تک‌سطحی از همان پنج CNN مدل پیشنهادی تشکیل شده و خروجی هر CNN به عنوان ورودی یک مدل CatBoost در نظر گرفته می‌شود که این مدل در شکل (۶) نشان داده شده است.

۳- مدل‌های ارائه شده در پژوهش‌های [۱۳]، [۱۴] از نو بازسازی شده و بر روی مجموعه داده‌های همین پژوهش آموزش می‌بینند.

پارامتر مدل‌های CNN براساس [۲۵] و به صورت زیر انتخاب شده است:

- تابع اتلاف^۱: به دلیل وجود دو کلاس در مسئله، از تابع Binary Crossentropy استفاده شده است.
- بهینه‌ساز^۲: از الگوریتم آدام^۳ استفاده شده است.
- توابع فعال‌ساز^۴: لایه‌های هر لایه CNN: بدون هیچ تغییری و دقیقاً مطابق پیاده‌سازی پیش‌فرض هر مدل تعیین شده است.
- تابع فعال‌ساز لایه تمام‌متصل خروجی: به دلیل وجود دو کلاس در مسئله، تابع سیگموئید^۵ به کار رفته است.

^۱ Loss Function

^۲ Optimizer

^۳ Adam


^۴ Activation Function

^۵ Sigmoid

^۶ Precision


^۷ Recall

^۸ F1-score



(شکل-۶): معماری مجمع تک سطحی.

(Figure-6): Single-level ensemble architecture.



(شکل-۷): شکل نتایج نهایی.

(Figure-7): Illustration of the final results.

پیش‌بینی‌های VG-Ensemble بودند (درمقابل اما VGG-Ensemble در کلاس بدخیم عملکرد بهتری از هر دو مدل تشکیل‌دهنده خود، VGG-19 و VGG-16، نشان داد)؛ درحالی‌که، ازسوی دیگر برای نمونه می‌توان ResNet-Ensemble را مثال زد که هم دقت کلی آن و هم دقت آن در هر کلاس، از هر دو مدل تشکیل‌دهنده آن؛ یعنی ResNet50V2 و ResNet152V2 بیشتر است.

از نتایج، نخست می‌توان دریافت که استفاده از روش یادگیری جمعی به‌طورمعمول نتیجه بهتری از به‌کارگیری مدل‌های مستقل دارد. امتیاز F1 کلی هیچ‌یک از مدل‌های مستقل بهتر از مجامع نبود. تنها شماری از مدل‌های مستقل را می‌توان یافت که به‌صورت موردی و در یک کلاس، عملکرد بهتری از برخی از مجامع داشته باشند، برای مثال: پیش‌بینی‌های مدل VGG-16 در کلاس خوش‌خیم، دقیق‌تر از

(جدول-۲): نتایج نهایی براساس امتیاز F1.
(Table-2): Final results based on F1-score

نام مدل	F1 امتیاز خوش خیم	F1 امتیاز بدخیم	کل F1 امتیاز	توضیحات
VGG-16	۸۴	۸۰	۸۲	
VGG-19	۸۳	۸۰	۸۲	
ResNet50V2	۸۳	۸۱	۸۲	
ResNet152V2	۸۴	۸۰	۸۰	
InceptionV3	۸۳	۷۶	۸۰	
Densenet201	۸۱	۸۲	۸۱	
InceptionResNetV2	۸۲	۸۰	۸۱	
[۱۳]	۸۴	۸۲	۸۳	
[۱۴]	۸۴	۸۳	۸۳	بدخیم به همراه مدل پیشنهادی F1 بالاترین امتیاز
ResNet-Ensemble	۸۵	۸۲	۸۴	کل، به همراه مدل پیشنهادی F1 بالاترین امتیاز
VGG-Ensemble	۸۳	۸۱	۸۲	
مجمع تک سطحی	۸۳	۸۱	۸۲	
مدل پیشنهادی	۸۶	۸۳	۸۴	در خوش خیم، بدخیم و کل F1 بالاترین امتیاز

(جدول-۳): مطالعه موردی. پنج نمونه تصویر از نمونه های مثبت (بدخیم) و منفی (خوش خیم) که نتیجه مدل پیشنهادی و مدل های [۱۳]، [۱۴] متفاوت بوده است.
(Table-3): Case study. Five positive (malignant) and negative (benign) image samples from dataset on which the output of our proposed model and the two models presented in [13] and [14] are different

تصویر نمونه	واقعیت	مدل پیشنهادی	[۱۳]	[۱۴]
	منفی	منفی	مثبت	مثبت
	منفی	منفی	مثبت	مثبت
	منفی	منفی	مثبت	مثبت
	مثبت	مثبت	منفی	منفی
	مثبت	مثبت	منفی	منفی

این مثال خوبی است که چگونه دو مدل ضعیف تر می توانند خطاهای یکدیگر را جبران کرده و در قالب یک مجمع به نتایج بهتری دست پیدا کنند؛ لذا همچنان می توان از عملکرد یادگیری عمیق جمعی دفاع کرد و یا کمینه عملکرد آن را در برابر مدل های مستقل مورد آزمون قرارداد (با این فرض که به احتمال نتایج بهتری برای ارائه خواهد داشت) و اما درخصوص مدل پیشنهادی، از نتایج می توان دید که:

- ۱- عملکرد آن، چه در هر یک از کلاس ها و چه در کل، از تمامی CNN های مستقل بهتر بوده است.
- ۲- با آنکه عملکرد کلی آن برابر ResNet-Ensemble است، اما استفاده از VGG-Ensemble در کنار این مجمع و ترکیب نتایج آن به کمک CatBoost و تشکیل یک مجمع دوسطحی، عملکرد مستقل آن در هر کلاس را نیز بهبود داده است.
- ۳- عملکرد آن، باز هم چه در هر یک از کلاس ها و چه در کل، از عملکرد مجمع همتای تک سطحی آن بهتر است.

۷- مطالعه موردی

برای اینکه تحلیل جامع تری از تفاوت تشخیص مدل پیشنهادی دوسطحی و دو مدل معرفی شده در [۱۳]، [۱۴] داشته باشیم، یک مطالعه موردی ارائه می شود که در آن پنج نمونه تصویر مورد بررسی قرار گرفتند. نتایج در جدول (۳) نشان داده شده است.

همان‌گونه که در جدول (۳) مشخص شده، نتایج مدل پیشنهادی در موارد نشان داده شده به‌طورکامل متفاوت با مدل‌های مقایسه شده است. همچنین تشخیص درست در این موارد با مدل پیشنهادی بوده است. از آنجا که ساختار درونی لایه‌های این سه مدل شبیه است، تفاوت پاسخ‌ها را می‌توان در دوسطحی بودن تصمیم‌گیری مدل پیشنهادی و استفاده از روش تجمع مبتنی بر یادگیری ماشین در مدل پیشنهادی نسبت به روش‌های استفاده‌شده در [۱۳]، [۱۴] دانست.

۱-۷- پیچیدگی محاسباتی مدل پیشنهادی

در مقایسه با الگوریتم‌های مقایسه‌شده که به‌صورت تکی استفاده شده‌اند؛ یعنی VGG-16، VGG-19، ResNet-50V2 و InceptionV3 قطعاً پیچیدگی محاسباتی مدل پیشنهادی و مدل‌های مجمع تک‌سطحی بالاتر است. دلیل این امر استفاده سری (متوالی) پنج مورد از مدل‌ها در مجامع است. به‌صورت خاص اگر پیچیدگی محاسباتی مدل‌های VGG-16، VGG-19، ResNet-50V2 و InceptionV3 را به‌ترتیب m_1 تا m_5 بنامیم و پیچیدگی مدل‌های DenseNet201 و InceptionResNetV2 را نیز m_6 و m_7 بنامیم، پیچیدگی مدل تک‌سطحی پیشنهادی به‌صورت رابطه (۴) نشان داده شده است:

$$O(CatBoost) + \sum_{i=1}^5 O(m_i) \quad (4)$$

همچنین پیچیدگی مدل‌های ارائه‌شده در مراجع [۱۳] و [۱۴] به‌صورت زیر است:

$$\sum_{m \in \{m_3, m_4, m_6\}} O(m) + \sum_{i=4}^7 O(m_i) \quad (5)$$

که البته یک $O(n)$ به‌خاطر میانگین‌گیری نهایی یا استفاده از رأی‌گیری در لایه آخر مدل‌ها باید با مقادیر فوق جمع شود که به‌دلیل غلبه پیچیدگی مدل‌های m_1 تا m_7 بر $O(n)$ آن را حذف کردیم. در مورد مدل دوسطحی پیشنهادی چون سه‌بار (یک‌بار در هر مجمع و یک‌بار در سطح دوم) از الگوریتم CatBoost استفاده شده پیچیدگی محاسباتی کلی به‌صورت زیر است:

$$3 \times O(CatBoost) + \sum_{i=1}^5 O(m_i) \quad (6)$$

که درنهایت باتوجه به‌اینکه ضریب در پیچیدگی نهایی تأثیرگذار نیست می‌توان گفت همان مقدار مربوط به مجمع تک‌سطحی یعنی همان مقدار اشاره‌شده در رابطه (۴) خواهد بود.

در مورد الگوریتم CatBoost نیز همان‌گونه که در [۲۴] اشاره شده است پیچیدگی بخش‌های مختلف الگوریتم شامل محاسبه گرادیان (CalcGradient)، ساخت درخت (Build T)، محاسبه میانگین گرادیان برگ‌ها ($Calc\ values\ b_f^t$)، به‌روزرسانی پیش‌بینی‌ها (Update M) و محاسبه درخت مرتب (Calc ordered TS) به‌صورت زیر است:

$$\begin{aligned} CalcGradient &= O(s \times n) \\ Build\ T &= O(|C| \times n) \\ Calc\ values\ b_f^t &= O(n) \\ Update\ M &= O(s \times n) \\ Calc\ ordered\ TS &= O(N_{TS,n} \times n) \end{aligned} \quad (7)$$

که تمام موارد نسبت به n که همان تعداد داده‌های آموزشی است خطی است. همچنین همان‌گونه که در [۲۴] اشاره شده، بخش اصلی محاسبات مربوط به تابع Build T می‌باشد که در آن $|C|$ تعداد جای‌گشت‌های تصادفی ساخته‌شده اولیه برای تولید درخت‌های تصادفی براساس مجموعه داده آموزشی ورودی است. این مقدار برای مدل پیشنهادی با توجه به اینکه از CatBoost در خروجی مدل‌های m_1 تا m_5 استفاده شده (یک‌بار در مجمع نخست، یک‌بار در مجمع دوم و یک‌بار در سطح دوم) نسبت به تعداد ویژگی‌های اولیه مجموعه داده مقدار بسیار کوچکی است؛ بنابراین، پیچیدگی کل الگوریتم CatBoost خطی با ضریب کوچک و درنتیجه پیچیدگی کل مدل پیشنهادی همان ماکزیمم پیچیدگی مدل‌های m_1 تا m_5 است.

۸- نتیجه‌گیری و بحث

در این پژوهش روش یادگیری عمیق و یادگیری جمعی عمیق در رده‌بندی تصاویر برچسب‌دار پزشکی سرطان پوست به‌کار گرفته شد و عملکرد روش یادگیری جمعی عمیق مورد بررسی قرار گرفت و درنهایت یک مدل مبتنی بر یادگیری جمعی عمیق چندسطحی معرفی شد و از نظر کارایی با تعدادی از مدل‌های رایج و همچنین مدل ارائه‌شده در دو پژوهش مشابه مقایسه شد.

نتایج نشان دادند که کارایی استفاده از یادگیری جمعی عمیق نسبت به استفاده از مدل‌های مستقل یادگیری عمیق بهبود می‌یابد؛ چراکه عملکرد کلی تمامی مجمع‌ها همواره برابر یا بهتر از مدل‌های مستقل بوده است؛ لذا استفاده از یادگیری جمعی عمیق را می‌توان به‌طور کلی توصیه کرد مگر زمانی که محدودیت جدی در منابع

- [8] S. Dong, P. Wang, and K. Abbas, "A survey on deep learning and its applications," *Comput Sci Rev*, vol. 40, p. 100379, 2021.
- [9] R. Sun *et al.*, "Survey of Image Edge Detection," *Frontiers in Signal Processing*, vol. 2, p. 826967, 2022.
- [10] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, "Breast cancer histopathological image classification using convolutional neural networks," in *2016 international joint conference on neural networks (IJCNN)*, pp. 2560–2567, 2016.
- [11] X. Dong, Z. Yu, W. Cao, Y. Shi, and Q. Ma, "A survey on ensemble learning," *Front Comput Sci*, vol. 14, no. 2, pp. 241–258, 2020.
- [12] M. A. Ganaie, M. Hu, and others, "Ensemble deep learning: A review," *Engineering Applications of Artificial Intelligence*, vol. 115, p. 105151, 2021.
- [13] A. S. Kini *et al.*, "Ensemble deep learning and internet of things-based automated COVID-19 diagnosis framework," *Contrast Media Mol Imaging*, vol. 2022, 2022.
- [14] A. K. Das, S. Ghosh, S. Thunder, R. Dutta, S. Agarwal, and A. Chakrabarti, "Automatic COVID-19 detection from X-ray images using ensemble learning with convolutional neural network," *Pattern Analysis and Applications*, vol. 24, no. 3, pp. 1111–1124, 2021.
- [15] M. Dildar *et al.*, "Skin cancer detection: a review using deep learning techniques," *Int J Environ Res Public Health*, vol. 18, no. 10, p. 5479, 2021.
- [16] M. A. Kassem, K. M. Hosny, and M. M. Fouad, "Skin lesions classification into eight classes for ISIC 2019 using deep convolutional neural network and transfer learning," *IEEE Access*, vol. 8, pp. 114822–114832, 2020.
- [17] S. Kalouche, A. Ng, and J. Duchi, "Vision-based classification of skin cancer using deep learning," *2015, conducted on Stanford Machine Learning course (CS 229) taught*, 2016.
- [18] A. Sagar and D. Jacob, "Convolutional neural networks for classifying melanoma images," *bioRxiv*, pp. 2020–2025, 2021.
- [19] "Skin Cancer: Malignant vs Benign, Kaggle," Skin Cancer: Malignant vs Benign, Kaggle. Accessed: Jan. 01, 2022. [Online]. Available: <https://kaggle.com/datasets/fanconic/skin-cancer-malignant-vsbenign>
- [20] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [21] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," in *European conference on computer vision*, pp. 630–645, 2016.
- [22] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2818–2826, 2016.
- [23] M. Al-Sarem, F. Saeed, W. Boulila, A. H. Emara, M. Al-Mohaimed, and M. Errais,

سخت‌افزاری وجود داشته و یا به‌احتمال زمانی که دقت یک مدل خاص اختلاف چشم‌گیری با دیگر مدل‌های مورد‌استفاده در مجمع دارد.

همچنین به‌شیوه تجربی تأیید شد که به‌کارگیری یک مجمع چندسطحی به‌همراه ترکیب‌کننده‌ای هوشمند می‌تواند نتایج بهتری براساس معیار F1 به‌دست آورد، اما مشروط بر اینکه ابرپارامترهای آن به‌درستی تنظیم شوند. تعیین روشی جهت تنظیم درست این ابرپارامترها نیازمند پژوهش مجزایی است.

نتایج قابل‌اتکاتر نیازمند داده‌های بیشتر و متنوع‌تر است. درصورت دسترسی به منابع کافی، می‌توان مدل پیشنهادی این پژوهش را بر روی مجموعه‌داده‌های گسترده‌تری با رده‌های بیشتر (از جمله ISIC 2019) آموزش داد و امکان بازتولید نتایج را بررسی کرد. انتخاب بهترین ترکیب از جای‌گشت‌های ممکن انتخاب دو یا سه مدل برای قرارگیری در دو مجمع یا حتی انتخاب تعداد مجمع، می‌تواند به‌عنوان یک پژوهش جدید و در ادامه پژوهش حاضر انجام شود. همچنین به‌عنوان پیشنهاد دیگری برای پژوهش‌های آینده می‌توان به‌کارگیری الگوریتم‌های تجمیع دیگری را در هرکدام از سطوح ترکیب مشخص کرد.

9-References

۹- مراجع

- [1] "https://data.worldbank.org/indicator/SH.MED.PH.YS.ZS." Accessed: Nov. 04, 2022. [Online]. Available: <https://data.worldbank.org/indicator/SH.MED.PH.YS.ZS>
- [2] B. Rahimi, H. Nadri, H. L. Afshar, and T. Timpka, "A systematic review of the technology acceptance model in health informatics," *Appl Clin Inform*, vol. 9, no. 03, pp. 604–634, 2018.
- [3] M. E. Basiri, S. Nemati, M. Abdar, S. Asadi, and U. R. Acharya, "A novel fusion-based deep learning model for sentiment analysis of COVID-19 tweets," *Knowl Based Syst*, vol. 228, 2021, doi: 10.1016/j.knosys.2021.107242.
- [4] A. Garg and V. Mago, "Role of machine learning in medical research: A survey," *Comput Sci Rev*, vol. 40, p. 100370, 2021.
- [5] A. Barragán-Montero *et al.*, "Artificial intelligence and machine learning for medical imaging: A technology review," *Physica Medica*, vol. 83, pp. 242–256, 2021.
- [6] U. Kamath, J. Liu, and J. Whitaker, *Deep learning for NLP and speech recognition*, vol. 84. Cham, Switzerland: Springer, 2019.
- [7] M. Tsuneki, "Deep learning models in medical image analysis," *Journal of Oral Biosciences*, vol. 64, no. 3, pp. 312–320, 2022.

۱۳۸۷ و مدرک دکترای مهندسی کامپیوتر را از دانشگاه اصفهان در سال ۱۳۹۳ دریافت کرده‌است. وی اکنون دانشیار گروه مهندسی کامپیوتر دانشگاه شهرکرد است. ایشان مقاله‌های متعددی در زمینه‌های داده‌کاوی، تحلیل احساسات و ... نوشته‌است. علایق پژوهشی او پردازش زبان طبیعی، طراحی سامانه‌های هوشمند، تحلیل احساسات و داده‌کاوی است.

نشانی رایانامه ایشان عبارت است از:

basiri@sku.ac.ir

“Feature selection and classification using CatBoost method for improving the performance of predicting Parkinson’s disease,” in *Advances on Smart and Soft Computing*, Springer, pp. 189–199, 2021.

[24] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin, “CatBoost: unbiased boosting with categorical features,” *Adv Neural Inf Process Syst*, vol. 31, 2018.

[25] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O’Reilly Media, Inc., 2022.

[۲۶] فروتن راد جواد، حورعلی مریم، کیوان راد محمدعلی،

«دادگان پرسش‌وپاسخ زبان فارسی»، پردازش علائم و

داده‌ها، ۲۰ (۴)، صفحات ۱۰۷–۱۲۰، ۱۴۰۲.



پویان جابری مدرک کارشناسی

خود را در رشته مهندسی کامپیوتر

از مرکز آموزش عالی شهرضا و

مدرک کارشناسی ارشد را در

همان رشته از دانشگاه شهرکرد

دریافت کرده‌است. علایق پژوهشی

او پردازش سیگنال، ترکیب داده و یادگیری ماشین است.

نشانی رایانامه ایشان عبارت است از:

jaberi@stu.sku.ac.ir



شبهلا نعمتی مدرک

کارشناسی خود را در رشته

مهندسی کامپیوتر از دانشگاه

شیراز در سال ۱۳۸۴،

کارشناسی ارشد از دانشگاه

صنعتی اصفهان در سال ۱۳۸۷

و مدرک دکترای مهندسی کامپیوتر را از دانشگاه اصفهان

در سال ۱۳۹۵ دریافت کرده‌است. وی از سال ۱۳۹۶

استادیار گروه مهندسی کامپیوتر دانشگاه شهرکرد است. او

چندین مقاله در زمینه‌های ترکیب داده، تحلیل احساسات

و پردازش صوت و تصویر نوشته‌است. علایق پژوهشی او

پردازش سیگنال، ترکیب داده‌ها، تحلیل احساسات و

داده‌کاوی است.

نشانی رایانامه ایشان عبارت است از:

s.nemati@sku.ac.ir



محمداحسان بصیری مدرک

کارشناسی خود را در رشته

مهندسی کامپیوتر از دانشگاه

شیراز در سال ۱۳۸۵، کارشناسی

ارشد را از دانشگاه اصفهان در سال

سال ۱۴۰۳ شماره ۲ پیاپی ۶۰

فصلنامه



۹۰