

# تشخیص اختلال در رشد کودکان به کمک

## معماری مبتنی بر انتقال یادگیری به روش

### چکانش دانش

حمیرا سرابی سرورانی<sup>۱</sup>، فردین ابدالی محمدی<sup>۲\*</sup>

دانشجوی کارشناسی ارشد مهندسی فناوری اطلاعات، دانشکده برق و کامپیوتر، دانشگاه رازی، کرمانشاه، ایران<sup>۱</sup>

دانشیار گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشکده برق و کامپیوتر، دانشگاه رازی، کرمانشاه، ایران<sup>۲\*</sup>

#### چکیده

تقویت دستگاه‌های پزشکی با اینترنت اشیا و فناوری هوش مصنوعی تشخیصی، ضمن در نظر گرفتن محدودیت‌های این سامانه‌ها، پتانسیل مدرن‌سازی و ارتقای رویکرد تشخیصی نسل‌های آینده سامانه‌های اینترنت اشیا را در حوزه سلامت دارد. یکی از دستگاه‌های پرکاربرد در پاراکلینیک، دستگاه رادیوگرافی است. ارزیابی خودکار ناهنجاری‌ها و سن استخوان از تصاویر رادیوگرافی دست چپ، به رادیولوژیست‌ها، متخصصان اطفال و پزشکی قانونی در تصمیم‌گیری در مورد وضعیت رشد جوانان کمک می‌کند. دستگاه‌های اینترنت اشیا در پزشکی به علت محدودیت منابع قادر به پردازش حجم زیاد داده‌ها نیستند. در این مقاله، با استفاده از یک مدل چکانش دانش تجزیه‌شده از شبکه‌های عصبی پیچشی معلم به شبکه دانش آموز برای طبقه‌بندی سن استخوان استفاده شده است. این روش از حجم محاسبات موردنیاز برای دستگاه‌های لبه می‌کاهد. ارزیابی روش ارائه با استفاده از مجموعه داده‌های اطلس دست دیجیتال انجام شده است. نتیجه روش با معیارهای دقت، بازیافت، صحت و میانگین خطای مطلق ارزیابی شده است. مدل پیشنهادی ۹۶/۴۷ درصد دقت آزمون را برای طبقه‌بندی سن استخوان به دست می‌آورد.

واژگان کلیدی: انتقال یادگیری، تشخیص سن، چکانش دانش، ناهنجاری رشد.

## Diagnosing Children's Developmental Disorders By A Transfer Learning Based Architecture Using Knowledge Distillation

Homeyra Sarabi Sarvarani<sup>1</sup>, Fardin Abdali Mohammadi<sup>2\*</sup>

Master student of Information Technology Engineering, Razi University, Kermanshah, Iran<sup>1</sup>

Associate Professor, Faculty of Electrical and Computer Engineering, Department of Computer Engineering, Razi University, Kermanshah, Iran<sup>2\*</sup>

#### Abstract

Enhancing medical devices with Internet of Things (IoT) and diagnostic artificial intelligence technology, while considering the constraints of these systems, has the potential to modernize and enhance the diagnostic approach of future generations of Internet of Things systems in healthcare. The radiography device, commonly used in paraclinical settings, is widely used in various hospital departments. The automated assessment of abnormalities and bone age from radiographic images of the left hand assists radiologists, pediatricians, and forensic experts in determining the developmental stage of young individuals. The IoT devices in medicine are unable to process large amounts of data due to limited resources. This article uses a teacher-student network for bone age classification, using the decomposed knowledge distillation model of convolutional neural networks. This approach minimizes the computational resources needed for edge devices. The proposed method is comprised of two sequential steps. In the preprocessing step, the initial phase involves the elimination of non-clinical data and artifacts. This is followed by the extraction of region of interest (ROI). In this phase of the

\* Corresponding author

\* نویسنده عهده‌دار مکاتبات



procedure, only the hand portion of the patient's X-ray remains for further evaluation. The subsequent phase involves the delineation of the boundaries of the region of interest. This is necessary because, in certain age groups, some bones are not ossified. Consequently, reliance on bones as landmarks is precluded. In the second step, The extracted ROI from the preceding step is utilized to train the teacher model. The student model utilizes the teacher model's knowledge to learn how to predict patient age. Therefore, the present study puts forth transfer learning methodologies founded on the distillation of knowledge, with the aim of facilitating the transference of knowledge between teacher and student models.

The proposed method is based on the data set of the Digital Hand Atlas (DHA) database. The evaluation criteria used in this work are Accuracy, recall, precision and mean absolute error (MAE). The proposed model achieves 96/47% test accuracy for bone age classification.

**Keywords:** Developmental Disorders, Knowledge Distillation, Bone Age, Deep Learning

اختلالات رشد ژنتیکی (مانند سندرم ترنر، مشکلات ارتوپدی یا ارتودنسی) که در آن، زمان و نوع درمان (جراحی، بریس و غیره) بر اساس رشد کودک انجام می‌شود [۸]. به‌تازگی، ارزیابی سن استخوانی جایگاه قابل توجهی در دانشگاه و علم پزشکی به‌دست آورده‌است. روش‌های دستی به‌دلیل پیچیدگی و شباهت زیاد الگوهای استخوانی در برخی سنین مستعد تفسیرپذیری پزشک معالج هستند؛ این مشکل، انگیزه را برای توسعه روش‌های خودکار ارزیابی سن استخوانی مبتنی بر هوش مصنوعی افزایش داده‌است. برای افزایش دقت و سرعت ارزیابی سن استخوان، روش‌های زیادی به‌کمک رایانه توسعه یافته‌اند.

توسعه و پژوهش در ارزیابی خودکار سن استخوان با استفاده از الگوریتم‌های هوش مصنوعی، منجر به ارتقای راه‌حل‌های تجاری شده‌است؛ اگرچه روش‌های خودکار ممکن است، به‌طور قابل توجهی کارایی ارزیابی سن استخوان را افزایش دهند، با این‌حال، فناوری‌های نوظهور مانند مدل‌های یادگیری عمیق که نتایج خوبی را در تشخیص سن استخوانی ارائه داده‌اند با چالش‌هایی از جمله تعداد پارامترهای زیاد، پیچیدگی محاسباتی بالا و محدودیت اجرا بر روی دستگاه‌های با قدرت پردازش کم در فناوری‌هایی چون یادگیری بر روی دستگاه<sup>۳</sup>، افزودن هوشمندی به دستگاه‌های لبه و اینترنت اشیا مواجه‌اند؛ برای مثال، در [۹] مدلی مبتنی بر شبکه‌های عصبی پیچشی با تعداد نه لایه بر روی تصاویر پایگاه داده‌ای اطلس دست دیجیتال (DHA)<sup>۴</sup>، آموزش داده شده‌است، در این آموزش برای یک تصویر متعلق به کودک ده ساله با وضوح  $256 \times 256$  نزدیک به  $84/04$  مگابایت پارامتر ایجاد شده‌است. با فرض استفاده از نوع داده‌ای ممیز شناور اعشاری که هشت بایت است، اندازه مدل  $640$  مگابایت خواهد بود که تا حدودی بزرگ است؛ بنابراین، استفاده از روش‌هایی برای تسهیل و کاهش پیچیدگی محاسباتی

## ۱- مقدمه

ارزیابی سن استخوان به پزشکان کمک می‌کند تا مرحله بلوغ اسکلتی کودکان را تخمین بزنند. این کار با رادیوگرافی اشعه ایکس از دست چپ انجام می‌شود [۱]. در روش سنتی گرتولچ-پایل<sup>۱</sup> استخوان‌های تصویر اشعه ایکس با تصاویر موجود در یک اطلس استاندارد رشد استخوان مقایسه می‌شوند. این اطلس از تصاویر اشعه ایکس کودکان دیگر که دارای رشد نرمال هستند، تشکیل شده‌است [۲]. پزشکان سن استخوانی کودک را بر اساس اینکه تصویر گرفته‌شده از مراجعه‌کننده با کدام تصویر استاندارد در اطلس بیشترین مطابقت را دارد، تعیین می‌کنند. در دیگر روش بالینی، تانر وایت هاوس (TW)<sup>۲</sup> [۳، ۴]، ارزیابی سن استخوان بر یک نظام امتیازدهی متکی است که سطح بلوغ اسکلتی را برای بیست ناحیه انتخاب‌شده در استخوان‌های خاص بررسی می‌کند. بسته به ظاهر استخوان در نواحی انتخاب‌شده و بر اساس شاخص‌های بلوغ، یک امتیاز عددی به استخوان‌های منتخب اختصاص داده می‌شود. تفاوت بین سن استخوانی کودک و سن تقویمی آن‌ها ممکن است، نشان‌دهنده مشکل رشد باشد [۵]. مطالعه سن استخوان می‌تواند به تعیین سرعت یا کندی رشد اسکلت کودک کمک کند؛ همچنین سن استخوان را می‌توان برای پیش‌بینی برخی موارد مربوط به کودکان به‌کار برد؛ برای مثال، یک کودک تا چه زمانی رشد خواهد کرد، زمان شروع بلوغ چه وقت خواهد بود و تخمین قد نهایی کودک چقدر خواهد بود [۶]؛ این آزمایش همچنین می‌تواند به پزشکان در درمان کودکان مبتلا به بیماری‌های مؤثر بر رشد، کمک کند؛ از جمله: ۱. بیماری‌هایی که بر سطح هورمون‌های رشد تأثیر می‌گذارند (مانند کمبود هورمون رشد، کم‌کاری تیروئید، بلوغ زودرس و اختلالات غده فوق کلیوی) [۷]. ۲.

منظور تشخیص سن استخوانی استفاده شد. در این مقاله با به کارگیری یک مدل چکانش دانش پیشرفته تر تلاش در بهبود عملکرد روش پیشین خود دارد. بر خلاف روش پیشین، از رویکرد یادگیری مشترک برای چکانش دانش معلم در لایه پاسخ همراه با دانش معلم در نقشه‌های ویژگی لایه‌های میانی استفاده شده است.

در این روش برای تجزیه نقشه‌های ویژگی مدل‌های معلم و دانش‌آموز از تجزیه تاکر<sup>۴</sup> استفاده شده است که تنسورها<sup>۵</sup> به دلیل پیچیدگی کم به راحتی برای دانش‌آموزان قابل درک است. گفتنی است این روش در هیچ یک از روش‌های گذشته استفاده نشده است. به اختصار مهم‌ترین نوآوری‌های این مقاله عبارت‌است از:

۱- توسعه یک روش جدید تشخیص سن استخوانی که از پارادایم چکانش دانش با کمینه کاهش دقت به جای مدل‌های شبکه عصبی عمیق بسیار پیچیده استفاده می‌کند.

۲- استفاده از نقشه‌های ویژگی از لایه‌های میانی در ترکیب با خروجی لایه نهایی در مدل معلم به منظور استفاده به عنوان دانش جدیدی که به مدل دانش‌آموز منتقل می‌شود.

در ادامه مقاله، بخش دوم کارهای مرتبط را تشریح می‌کند؛ سپس بخش سوم روش پیشنهادی را ارائه می‌دهد. در بخش چهارم نتایج گزارش شده است و بخش پنجم نیز مقایسه نتایج را نشان می‌دهد. در انتها، در بخش ششم نتیجه‌گیری مقاله آورده شده است.

## ۲- کارهای مرتبط

روش‌های مبتنی بر شبکه عصبی پیچشی<sup>۶</sup> به طور معمول بر تشخیص نواحی کلیدی در استخوان‌های دست برای پیش‌بینی سن استخوان تکیه می‌کنند. بیشتر این روش‌ها بر اساس مکان‌یابی مناطق مورد علاقه<sup>۷</sup> (ROI) دسته‌بندی را انجام می‌دهند. این روش‌های مبتنی بر تقسیم‌بندی از روش TW الهام گرفته شده‌اند که تصاویر را بر اساس ROI‌های شناسایی شده تجزیه و تحلیل می‌کند؛ با این حال، این روش‌ها تنها می‌توانند در بالاترین حد سه ناحیه کلیدی را پیدا کنند. برخی از روش‌های ارائه شده مانند [۱۳-۱۷] برای تشخیص نواحی کلیدی نیازمند حاشیه‌نویسی دستی اضافی‌اند.

مدل‌های یادگیری عمیق ضروری است؛ از این رو، ارائه راهکارهای مناسب برای چالش‌های مطرح شده در توسعه مدل‌های یادگیری بهینه ضروری است. بسیاری از پژوهش‌گران با پیشنهاد روش‌های مختلف مانند فشرده‌سازی مدل، هرس و به اشتراک‌گذاری پارامتر، تجزیه، پالایه‌های پیچشی<sup>۱</sup> فشرده انتقال یافته و چکانش دانش (KD)<sup>۲</sup> سعی در توسعه مدل‌های یادگیری سبک‌وزن کرده‌اند. در میان این روش‌ها، چکانش دانش روشی جامع برای نظارت بر آموزش مدل دانش‌آموزان سبک‌وزن<sup>۳</sup> با استفاده از دانش استخراج شده از یک مدل شبکه معلم پیشرفته است. به دلیل اینکه تمامی مدل‌های ارائه شده با استفاده از فشرده‌سازی، هرس و تجزیه، برای افزایش دقت به ویژگی‌های تمامی نواحی استخراج شده از دست نیازمندند، وابستگی به حجم داده‌ها همچنان باقی مانده است؛ به عبارتی در تعداد داده‌های ورودی تغییری ایجاد نشده است و فقط سیاست‌هایی برای کم کردن و یا فشرده‌سازی پارامترها به کار گرفته شده است.

در مدل ارائه شده در این مقاله هدف فشرده‌سازی و یا هرس پارامترها نیست، بلکه هدف ارائه یک پارادایم برای کم کردن تعداد ورودی‌های شبکه عصبی عمیق در کنار ارائه دقت قابل قبول است. به همین دلیل یک چکانش دانش مبتنی بر معلم و دانش‌آموز استفاده شده است. شبکه معلم یک مدل پیشرفته است که با تمام نواحی ورودی، آموزش داده شده است و بر عملکرد مدل دانش‌آموز که تنها با یک ناحیه از این نواحی آموزش داده شده است، نظارت دارد؛ در نتیجه یک مدل دانش‌آموز ساده و کم حجم با قابلیت اجرا بر روی دستگاه‌ها با محدودیت منابع پردازشی، یادگیری و پیش‌بینی را انجام می‌دهد [۱۰، ۱۱].

مراحل انجام این مقاله بدین شرح است: ابتدا در بخش پیش‌پردازش مناطق زائد موجود در تصویر حذف می‌شوند و تصویر دست کامل استخراج می‌شود. نخستین نوآوری ارائه شده در این مقاله مربوط به بخش استخراج نواحی مورد علاقه از تصویر است. با طراحی یک الگوریتم و استفاده از تکنیک‌های پردازش تصویر، تمام مناطق دست اعم از انگشتان و مچ به درستی شناسایی و استخراج شدند. استخراج این نواحی نقش مهمی در بهبود یادگیری ویژگی‌های آموزنده در شبکه‌های عصبی عمیق دارد. دیگر نوآوری ارائه شده در این مقاله مربوط به بخش آموزش و پیش‌بینی مدل است که یک روش چکانش دانش جدید پیشنهاد شده است. در کار معرفی شده پیشین توسط نویسندگان در [۱۲] از یک مدل پایه چکانش دانش به

<sup>4</sup> Tucker Decomposition

<sup>5</sup> Tensors

<sup>6</sup> Convolution Neural Network (CNN)

<sup>7</sup> Region Of Interest (ROI)

<sup>1</sup> Convolution

<sup>2</sup> Knowledge Distillation (KD)

<sup>3</sup> Lightweight Student Model



در [۱۸]، یادگیری عمیق و یادگیری ماشین کلاسیک برای تولید یک مدل پیش‌بینی قابل اعتماد استفاده شده‌است. در [۱۹]، نویسنده ابتدا مدل U-Net را برای به‌دست‌آوردن مناطق کلیدی با برچسب‌دهی دستی آموزش داده‌است؛ سپس، یک مدل تشخیص نقطه کلیدی برای تراز کردن رادیوگرافی‌های دست در یک فضای مختصات مشترک استفاده شده که میانگین خطای مطلق (MAE) ۶/۳ ماه برای مردان و ۶/۴۹ ماه برای زنان به‌دست آوردند. در مدل‌های [۲۰] و [۲۱] نیز از مدل تشخیص شی R-CNN برای استخراج ROIها استفاده شده‌است. وضعیت رشد هر ROI به‌ترتیب به‌وسیله معماری‌های RNN و VGG-19 بررسی شده‌است. استخراج ویژگی و تشخیص سن هر ROI در [۲۲] با یک شبکه VGG-13 انجام شده‌است و نتیجه‌گیری نهایی نیز به‌وسیله یک روش ترکیبی<sup>۲</sup> بین مدل‌های VGG انجام شد که از رأی‌گیری استفاده کرده‌است. در [۲۳]، یک شبکه چندمقیاسی (MMANet) ارائه شده که ترکیبی از یک شبکه جدید چندمقیاسی (MMCA) و یک ماژول ستون فقرات ResNet برای بهبود نمایش ROIها و حذف مناطق پس‌زمینه برای دستیابی به بهبود عملکرد استفاده شده‌است. نتایج تجربی نشان می‌دهد که MMANet این مدل میانگین خطای مطلق ۳/۸۸ ماه را در مجموعه داده چالشی سن استخوان RSNA به‌دست آورده‌است.

اگرچه با تقسیم‌بندی قسمت‌های مختلف تصویر دست و استفاده از مدل‌های یادگیری عمیق برای هر قسمت به‌صورت جداگانه قدرت یادگیری از داده‌ها و دقت مدل‌ها بالا رفته است، این افزایش تعداد مناطق استخراج‌شده و شبکه‌های تشخیصی، تعداد پارامترها و پیچیدگی در پیاده‌سازی مدل‌ها را به‌شدت بالا برده‌است؛ به همین دلیل در این مقاله یک مدل دانش‌آموز ساده و کم‌حجم با قابلیت اجرا بر روی دستگاه‌های با محدودیت منابع پردازشی ارائه شده‌است که تنها با یک ناحیه از نواحی استخراج‌شده آموزش داده می‌شود و در کنار دانش مدل پیشرفته معلم (که با تمام کانال‌های داده‌ای آموزش داده شده‌است) یادگیری و پیش‌بینی را انجام می‌دهد.

### ۳- مدل پیشنهادی

مدل پیشنهادی برای تشخیص سن استخوانی در این مقاله شامل دو مرحله «پیش‌پردازش» و «آموزش و پیش‌بینی» مدل است. در مرحله نخست نواحی دلخواه ROI استخراج می‌شوند. در مرحله دوم یک مدل مبتنی بر چکانش دانش از شبکه عمیق معلم به شبکه سبک‌وزن دانش‌آموز، برای آموزش و پیش‌بینی مدل معرفی شده‌است. در بخش بعدی هر کدام از این مراحل تشریح می‌شوند.

### ۳-۱- پیش‌پردازش

تصاویر رادیولوژی دست، همواره همراه با نواحی زائد هستند. این نواحی چالش‌های قابل توجهی را برای روش‌های مبتنی بر یادگیری عمیق ایجاد می‌کنند. در جهت کمک به استخراج مؤثر ویژگی‌های آموزنده، در ابتدا با استفاده از دودویی کردن تصویر، آستانه‌گذاری و لبه‌یابی ناحیه اصلی دست استخراج شده‌است. این عملیات باعث حذف پس‌زمینه و نواحی اضافه از تصویر می‌شود؛ سپس به‌دلیل تفاوت مراحل استخوان‌سازی در قسمت مچ دست و انگشتان و البته به‌منظور افزایش دقت شبکه عصبی پیچشی، یک تقسیم‌بندی بر روی دست انجام شده‌است؛ در نتیجه یک سری ROI کامل خودکار با توجه به هندسه دست استخراج شده‌است. این تقسیم‌بندی با استفاده از مختصات لبه‌های مچ دست، نوک انگشتان و مرکز دست انجام می‌شود. نواحی استخراج‌شده شامل تمام نواحی است که در روش TW استفاده شده، به‌علاوه مدل تنها به بررسی مفاصل در این نواحی محدود نیست و دیگر مفاصل را نیز تحت پوشش قرار داده‌است.

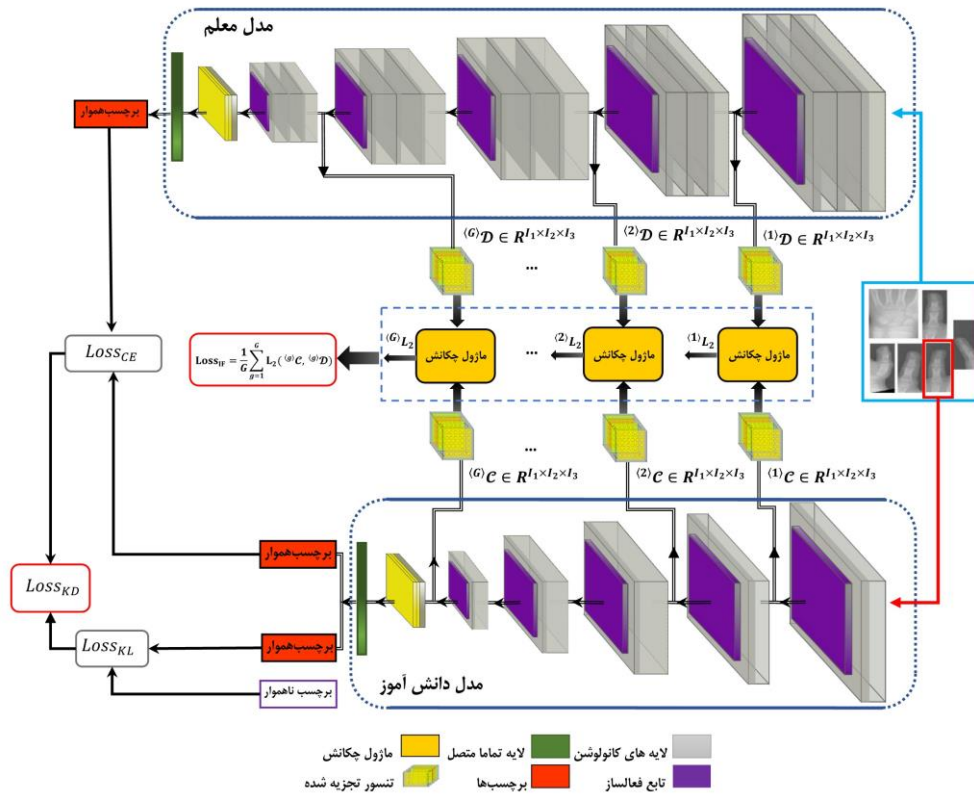
به‌منظور جداسازی نواحی موردنظر، ابتدا مختصات پیکسل‌های مرزی دست ذخیره می‌شود. به‌وسیله مختصات این پیکسل‌ها وسط دست مشخص و در موازات با آن یک خط افقی کشیده می‌شود که تصویر را به دو قسمت تقسیم‌بندی می‌کند و همان‌طور که در شکل (۲) مشخص است قسمت پایین مربوط به ناحیه مچ است (ناحیه ۱) که به‌طور کامل خودکار قابل استخراج است. در بخش بعد برای استخراج نواحی دو تا شش نیاز به پیدا کردن مختصات نواحی مربوط به انگشت‌هاست؛ برای این منظور از الگوریتم پوش محدب<sup>۳</sup> در جهت پیدا کردن مختصات انگشت‌ها استفاده شده‌است.

خروجی این الگوریتم در شکل (۱) نشان داده شده‌است. در واقع محل تلاقی خطوط حاصل از نوک انگشت‌ها هستند که به‌طور کامل خودکار به‌دست می‌آیند. بعد از انجام تقسیم‌بندی بر روی تصویر، برش نواحی انجام می‌شود. برش این نواحی با محاسبه مختصات پیکسل‌های مرزی، عرض انگشت‌ها و مختصات نقاط مربوط به سرانگشت‌ها انجام می‌شود. به این صورت که بین دو نقطه سرانگشت با مرکز دست و یا سرانگشت با وسط مچ یک خط مستقیم کشیده و تصویر بر مبنای این خط چرخانده می‌شود؛ سپس تابع برش نواحی فراخوانی می‌شود.

<sup>1</sup> Mean Absolute Error(MAE)

<sup>2</sup> Ensemble

<sup>3</sup> Convex hull



(شکل-1): معماری کلی مدل چکانش دانش ارائه شده  
(Figure-1): The general architecture of the presented knowledge Distillation model

### ۳-۲- مدل چکانش دانش

مدل عمیق معلم، از پیش با استفاده از شش ناحیه استخراج شده از تصاویر رادیولوژی در بخش پیش پردازش آموزش داده شده است. در کنار آن مدل دانش آموز سعی دارد با تقلید از دانش معلم که به دو شکل پاسخ محور و مبتنی بر ویژگی به دانش آموز چکانده می شود و همچنین دانش خود که با استفاده از بررسی تنها یک ناحیه از نواحی استخراج شده به دست آورده است، سن استخوانی را تشخیص دهد. خروجی مدل شبکه عصبی دانش آموز به کار رفته به صورت منطق رگرسیون است که به وسیله یک لایه Softmax تبدیل به خروجی برجسب طبقه ها می شود. در نتیجه خروجی نهایی تنها به صورت عددهایی است که برجسب طبقه جاری را نشان می دهد. در کل در روش پیشنهادی، تابع محاسبه خطای کلی  $Loss_{Total}$  به صورت زیر تعریف می شود:

$$Loss_{Total} = \alpha(Loss_{KD}) \pm (1 - \alpha)(Loss_{IF}) \quad (1)$$

در این رابطه  $Loss_{KD}$  به دانش پاسخ محور اشاره دارد؛ همچنین خطای  $Loss_{IF}$  به دانش موجود بین نقشه ویژگی های لایه های میانی در هر دو مدل معلم و دانش آموز اشاره دارد که محاسبه این دو تابع به ترتیب در بخش های ۳-۲-۱ و ۳-۲-۲ تشریح می شوند.

در این مقاله، مدل چکانش دانش همراه با یادگیری مشترک دو شبکه معلم و دانش آموز برای طراحی یک طبقه بندی سبک وزن به کار گرفته شده است. مطابق شکل (۱)، دو مدل معلم و دانش آموز وجود دارند که از رویکرد یادگیری مشترک برای چکانش دانش معلم در لایه پاسخ همراه با دانش معلم در نقشه های ویژگی لایه های میانی استفاده شده است. با توجه به شکل، مدل KD همراه با یادگیری مشترک برای طراحی یک طبقه بندی سبک وزن به کار گرفته شد.

### ۳-۲-۱- چکانش پاسخ محور

چهارچوب مدل های چکانش دانش مبتنی بر دو شبکه عصبی عمیق با نام های شبکه معلم و شبکه دانش آموز هستند. مدل معلم از طریق ایجاد برجسب های هموار در لایه آخر، دانش خود را به مدل دانش آموز انتقال می دهد و زمینه یادگیری دانش آموز را فراهم می سازد. هدف بهینه سازی چکانش دانش، به کمینه رساندن فاصله بین خروجی دانش آموزان و پیش بینی معلم و همچنین فاصله بین خروجی و برجسب واقعی است که از طریق کمینه سازی تابع خطای زیر امکان پذیر است:

$$Loss_{KD} = \beta(Loss_{KL}) \pm (1 - \beta)(Loss_{CE}) \quad (2)$$

$$\mathcal{L}_{CE}(Y, P(K_{Si}, T)) = \sum_i -Y_i \log P^{(i)}(K_{Si}, T) \quad (6)$$

در این توابع  $P^{(i)}(K_i, T)$  احتمال خروجی شبکه‌های دانش‌آموز و معلم برای طبقه  $i$ ام را نشان می‌دهد:

$$P(K_i, T) = \frac{\exp(K_i/T)}{\sum_j \exp(K_j/T)} \quad (7)$$

در اینجا  $K$  نمونه ماتریس ورودی برای مدل معلم  $(K_{Di})$  و مدل دانش‌آموز  $(K_{Si})$  است.  $T$  نیز به‌عنوان دمای چکانش تعریف می‌شود که یک پارامتر مرتبط با درجه نرم‌شدن خروجی مدل‌هاست.

### ۳-۲-۲- چکانش ویژگی محور

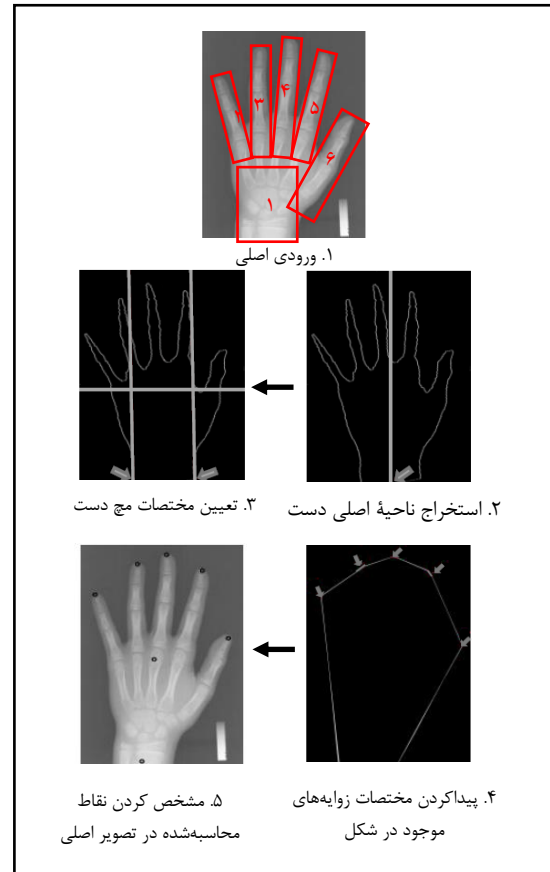
شبکه‌های عصبی عمیق در یادگیری ویژگی‌ها در سطوح مختلف لایه‌های درونی خود با افزایش انتزاع عملکرد خوبی ارائه کرده‌اند. این موضوع به‌عنوان یادگیری بازنمایی شناخته می‌شود؛ بنابراین، هم خروجی لایه آخر و هم خروجی لایه‌های میانی (نقشه‌های ویژگی) می‌توانند به‌عنوان دانش برای نظارت بر آموزش مدل دانش‌آموز استفاده شوند. به‌طور خاص، دانش مبتنی بر استخراج ویژگی از لایه‌های میانی تعمیم خوبی از دانش مبتنی بر پاسخ است؛ به علاوه برای آموزش شبکه‌های کم‌عمق به‌وسیله شبکه‌های عمیق مدل معلم از تعداد  $X$  لایه و مدل دانش‌آموز از تعداد  $Z$  لایه تشکیل شده‌اند. از هر دو مدل معلم و دانشجو تعداد  $G$  لایه انتخاب و ماتریس نگاشت ویژگی آن‌ها استخراج می‌شود. فاصله دانش این لایه‌ها با یکدیگر بررسی می‌شود و تابع بهینه‌سازی این روش سعی در به کمترین حد رساندن این فاصله دارد [۱۰، ۱۱].

برای شبکه‌های عصبی عمیق معلم و دانش‌آموز که به‌ترتیب از  $X$  و  $Z$  لایه تشکیل شده‌اند، خروجی هر لایه به لایه بعدی انتقال پیدا می‌کند. اگر خروجی هر لایه تابعی از  $Y = F(WK \pm b)$  باشد، آن‌گاه خروجی لایه پایانی برای هر کدام از مدل‌ها برابر با معادله (۸) است:

$$Y^{(X)} = {}^{(X)}F({}^{(X)}W {}^{(X-1)}F({}^{(X-1)}W \dots ({}^1F({}^1WK \pm {}^1b)) \dots) \pm {}^{(X-1)}b \pm {}^{(X)}b \quad (8)$$

که  $b^X$  و  $W^X$  به‌ترتیب به بایاس و تنسور وزن لایه  $X$  اشاره دارند. ساختار تنسورها به‌دلیل ابعاد بالا همراه با پیچیدگی و دشواری در محاسبه اختلاف بین تنسورها هستند. به همین دلیل مدل پیشنهادی در تلاش است که با استفاده از تجزیه تاکر این پیچیدگی را خرد کند و یک

که ضریب  $\beta$  نشان‌دهنده وزن استفاده‌شده برای متعادل کردن خطای مبتنی بر برچسب‌های نرم و سخت است.  $Loss_{KL}$  به روش Kullback-Leibler اشاره دارد که فاصله بین برچسب‌های نرم (خروجی‌های) مدل‌های معلم و دانش‌آموز را اندازه‌گیری می‌کند.  $L_{CE}$  نیز به تابع خطای آنتروپی بین برچسب‌های واقعی  $Y$  (سخت) و نرم (خروجی) مدل دانش‌آموز اشاره دارد.



(شکل-۲): مراحل جداسازی مناطق مورد نظر (ROIها)  
(Figure-2): Separation steps of regions (ROIs)

تابع  $Loss_{KL}$  به صورت زیر اندازه‌گیری می‌شود:

$$Loss_{KL} = \frac{1}{N} \sum_{i=1}^N \mathcal{L}_{KL}(P^{(i)}(K_{Di}, T), P^{(i)}(K_{Si}, T)) \quad (3)$$

$$\mathcal{L}_{KL}(P(K_{Di}, T), P(K_{Si}, T)) = \sum_i -P^{(i)}(K_{Di}, T) \log P^{(i)}(K_{Si}, T) \quad (4)$$

تابع  $L_{CE}$  نیز به صورت زیر اندازه‌گیری می‌شود:

$$Loss_{CE} = \frac{1}{N} \sum_{i=1}^N \mathcal{L}_{CE}(P^{(i)}(K_{Si}, T), Y) \quad (5)$$

مدل عمیق دانش‌آموز از تعداد  $Z$  لایه تشکیل شده‌است که خروجی هر لایه به لایه بعدی انتقال پیدا می‌کند. اگر خروجی هر لایه دانش‌آموز تابعی از  $H = F(WK \pm b)$  باشد، آن‌گاه معادله (۱۴) به مدل عمیق تجزیه‌شده دانش‌آموز اشاره دارد:

$$(14) \quad H^{(Z)} = \langle Z \rangle F(\langle Z \rangle \mathcal{L}, \langle Z \rangle A^{(1)}, \langle Z \rangle A^{(2)}, \dots, \langle Z \rangle A^{(N)}) \times (\dots ({}^1 F(\langle {}^1 \mathcal{L}, \langle {}^1 A^{(1)}, \langle {}^1 A^{(2)}, \dots, \langle {}^1 A^{(N)} \rangle K \pm \langle {}^1 b \rangle) \dots) \pm \langle {}^{Z-1} b \rangle \pm \langle Z \rangle b)$$

فرمت تاکر حاصل‌شده برای تنسور هر لایه از مدل دانش‌آموز به فرم معادله (۱۵) است:

$$(15) \quad \langle g \rangle \mathcal{K} \cong \langle g \rangle \mathcal{D} \times_1 \langle g \rangle S^{(1)} \times_2 \langle g \rangle S^{(2)} \times_1 \dots \times_1 \langle g \rangle S^{(N)} = \langle \langle \langle g \rangle \mathcal{D}, \langle g \rangle S^{(1)}, \langle g \rangle S^{(2)}, \dots, \langle g \rangle S^{(N)} \rangle \rangle$$

که  $\langle g \rangle \mathcal{K}$  تنسور نگاشت ویژگی لایه  $g$  ام حاصل‌شده از هر تابع  $\langle g \rangle F$  در مدل دانش‌آموز است؛ همچنین  $\langle g \rangle \mathcal{D}$  و  $S^{(j)}$  به ترتیب به تنسور هسته حاصل از تجزیه نگاشت ویژگی و ماتریس عامل در مرتبه  $j$  ام اشاره دارند. هر نمونه از این معادله به فرم زیر قابل بازنویسی است:

$$(16) \quad \langle g \rangle \mathcal{K}_{k_1, \dots, k_N} \cong \sum_{r_1=1}^{I_1} \sum_{r_2=1}^{I_2} \dots \sum_{r_N=1}^{I_N} \langle g \rangle \mathcal{D}_{k_1, \dots, k_N} (\langle g \rangle S_{(k_1, r_1)}^{(1)}, \langle g \rangle S_{(k_2, r_2)}^{(2)}, \dots, \langle g \rangle S_{(k_N, r_N)}^{(N)})$$

پس از استخراج تنسورهای هسته تجزیه‌شده نقشه‌های ویژگی از لایه‌های میانی مدل‌های دانش‌آموز و معلم، قدم آخر در چکانش دانش مبتنی بر ویژگی انتقال دانش از معلم به دانش‌آموز در قالب ماژول چکانش است. به همین دلیل تابع  $LOSS_{IF}$  مبتنی بر نرم اقلیدوسی  $L_2$  تعریف شده‌است که با استفاده از ضریب  $\alpha$  بر عملکرد مدل دانش‌آموز نظارت دارد. به طور کلی، خطای این روش را می‌توان به صورت معادله (۱۷) فرموله کرد:

#### ۴- نتایج

این بخش داده‌ها، پارامترهای ارزیابی و خروجی‌های مدل‌های پیشنهادی معلم و دانش‌آموز را تجزیه و تحلیل می‌کند.

نمونه ساده‌تر از تنسورها را برای محاسبات سریع‌تر ایجاد کند. برای تجزیه تنسورهای مربوط به لایه‌های معلم و دانش‌آموز، در مدل پیشنهادشده ابتدا تنسور وزن  $W$  لایه‌ها تجزیه می‌شوند. معادله (۹) به فرم تجزیه‌شده یک تنسور وزن  ${}^x W$  با استفاده از تجزیه تاکر اشاره دارد:

$$(9) \quad \langle x \rangle W \cong \langle x \rangle Q \times_1 \langle x \rangle M^{(1)} \times_2 \langle x \rangle M^{(2)} \dots \times_N \langle x \rangle M^{(N)} =$$

که  $\langle x \rangle Q \in R^{I_1 \times I_2 \times \dots \times I_N}$  نشان‌دهنده تنسور هسته وزن لایه  $x$  ام،  $M^{(i)}$  به ماتریس عامل در مرتبه  $i$  ام و  $\times_1$  ( $i = 1, 2, \dots, N$ ) به حاصل ضرب بین تنسور هسته و ماتریس‌های عامل اشاره دارند؛ همچنین هر نمونه از معادله (۹) را می‌توان به فرم معادله (۱۰) بیان کرد:

$$(10) \quad \langle x \rangle W_{r_1, \dots, r_N} \cong \sum_{i_1=1}^{I_1} \sum_{i_2=1}^{I_2} \dots \sum_{i_N=1}^{I_N} \langle x \rangle q_{r_1, \dots, r_N} (\langle x \rangle M_{(X_1, i_1)}^{(1)}, \langle x \rangle M_{(X_2, i_2)}^{(2)}, \dots, \langle x \rangle M_{(X_N, i_N)}^{(N)})$$

در ادامه اگر  $\langle g \rangle \mathcal{J}$  به تنسور نگاشت ویژگی لایه  $g$  ام حاصل‌شده از هر تابع  $\langle g \rangle F$  در مدل معلم اشاره کند، فرمت تاکر حاصل‌شده برای تنسور هر لایه از مدل معلم به فرم زیر است:

$$(12) \quad \langle g \rangle \mathcal{J} \cong \langle g \rangle \mathcal{C} \times_1 \langle g \rangle V^{(1)} \times_2 \langle g \rangle V^{(2)} \times_1 \dots \times_1 \langle g \rangle V^{(N)} = \langle \langle \langle g \rangle \mathcal{C}, \langle g \rangle V^{(1)}, \langle g \rangle V^{(2)}, \dots, \langle g \rangle V^{(N)} \rangle \rangle$$

که  $\langle g \rangle \mathcal{C} \in R^{I_1 \times I_2 \times \dots \times I_N}$  به تنسور هسته تجزیه‌شده از لایه  $g$  ام مدل معلم اشاره دارد؛ همچنین  $V^{(i)}$  به ماتریس عامل در مرتبه  $i$  ام مدل معلم اشاره دارد. هر مورد از معادله (۱۲) به صورت معادله (۱۱) نمایش داده می‌شود.

$$(13) \quad \langle g \rangle \mathcal{J}_{k_1, \dots, k_N} \cong \sum_{j_1=1}^{I_1} \sum_{j_2=1}^{I_2} \dots \sum_{j_N=1}^{I_N} \langle g \rangle \mathcal{C}_{k_1, \dots, k_N} (\langle g \rangle V_{(k_1, j_1)}^{(1)}, \langle g \rangle V_{(k_2, j_2)}^{(2)}, \dots, \langle g \rangle V_{(k_N, j_N)}^{(N)})$$



#### ۴-۱- مجموعه داده

در این مقاله از تمام نمونه‌های موجود در مجموعه داده عمومی و در دسترس اطلس دست دیجیتال [۲۴] استفاده شده است. این مجموعه داده یک معیار عمومی برای سنجش روش‌های ارزیابی سن استخوانی است که از ۱۴۰۰ تصویر رادیوگرافی اشعه ایکس دست چپ کودکان آسیایی، اروپایی، آمریکایی و آفریقایی در سنین صفر تا هجده سال تشکیل شده است. مزیت این مجموعه داده را می‌توان در دو بخش پوشش تمام سنین رشد و همه نژادها بیان کرد. تقسیم‌بندی داده‌ها در مراحل آموزش و آزمون به این شکل است: هفتاد درصد داده‌ها برای آموزش مدل و پانزده درصد برای اعتبارسنجی و پانزده درصد باقی‌مانده برای آزمون استفاده شده است. عملکرد مدل طبقه‌بندی از طریق دقت (معادله ۱۸)، صحت (معادله ۱۹)، بازیافت (معادله ۲۰)، معیار F1 (معادله ۲۱) و میانگین خطای مطلق (معادله ۲۲) تعیین می‌شود. MAE به‌عنوان مجموع خطاهای مطلق تقسیم بر حجم نمونه (تفاوت بین مقدار پیش‌بینی شده و مقدار واقعی) محاسبه می‌شود که در آن  $x_i$  برچسب و  $y_i$  سن استخوان تخمین زده شده است.

$$Accuracy = \frac{TP \pm TN}{TP \pm FP \pm FN \pm TN} \quad (18)$$

$$Precision = \frac{TP}{TP \pm FP} \quad (19)$$

$$Recall = \frac{TP}{TP \pm FN} \quad (20)$$

$$F1 = \frac{2(Recall * Precision)}{(Recall \pm Precision)} \quad (21)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (22)$$

#### ۴-۲- ارزیابی مدل‌های دانش آموز و معلم

در این مقاله تعداد شش ناحیه مختلف از هر تصویر موجود در پایگاه داده‌ای اطلس استخراج شده است. این نواحی با اسم ROI نام‌گذاری شده‌اند و شامل ناحیه مچ ROI1 و انگشتان ROI2-ROI6 است. در گام نخست مدل پیشرفته معلم با استفاده از تمام نواحی یک تا شش آموزش داده می‌شود. در گام دوم شش مدل مختلف دانش آموز با یک ناحیه از این نواحی استخراج شده، تحت نظارت معلم خود آموزش داده می‌شوند. درحقیقت برای مقایسه عملکرد مدل‌های مختلف دانش آموز با استفاده از این نواحی مختلف تعداد شش مدل دانش آموز به صورت مستقل آموزش داده شد. هر مدل دانش آموز به طور مستقل با استفاده از دانش دریافت شده از مدل عمیق معلم و یک ناحیه ROI متفاوت آموزش دید. جدول (۱) نتایج

به دست آمده از شش مدل دانش آموز و مدل معلم را نمایش می‌دهد. این جدول عملکرد مدل معلم را با شش مدل دانش آموز از نظر دقت، صحت، بازیافت، معیار F1 و میانگین خطای مطلق مقایسه می‌کند که مدل دانش آموز در هر یک از شش ناحیه به طور متوسط به دقت ۸۷/۸ و میانگین خطای ۰/۰۶۲ هم‌گرا شده است. در کنار مدل‌های مختلف و سبک‌وزن دانش آموز، مدل پیشرفته و عمیق معلم قرار دارد که با استفاده از تمام نواحی آموزش دیده است و به دقت ۹۷/۰ و میانگین خطای ۰/۰۳۶ هم‌گرا شده است. مقایسه این نتایج نشان می‌دهند که مدل دانش آموز کمابیش به خوبی مدل معلم خود عمل می‌کند و توانسته با بررسی تنها یک ناحیه و استفاده از دانش معلم خود تشخیصی نزدیک به آن داشته باشد؛ در نهایت از میان مدل‌های دانش آموز مدل شش که به بیشترین دقت دست یافته بود انتخاب شد.

(جدول ۱): مقایسه عملکرد شش مدل دانش آموز و مدل معلم

(Table-1): Performance comparison of six student models and teacher models

مدل	ناحیه	دقت	صحت	بازیافت	معیار F1-	میانگین خطای مطلق
دانش آموز ۱	ROI #1	۰/۸۷	۰/۵۳	۰/۵۶	۰/۸۳	۰/۰۸
دانش آموز ۲	ROI #2	۰/۸۲	۰/۵۵	۰/۵۰	۰/۹۰	۰/۰۳
دانش آموز ۳	ROI #3	۰/۹۳	۰/۶۴	۰/۶۵	۰/۹۲	۰/۰۹
دانش آموز ۴	ROI #4	۰/۸۴	۰/۵۴	۰/۵۵	۰/۸۰	۰/۰۲
دانش آموز ۵	ROI #5	۰/۸۶	۰/۵۵	۰/۵۶	۰/۸۶	۰/۰۴
دانش آموز ۶	ROI #6	۰/۹۲	۰/۶۵	۰/۶۲	۰/۸۲	۰/۰۸
میانگین		۰/۸۷	۰/۶۰	۰/۶۰	۰/۸۵	۰/۰۶
معلم	ROI #1-#6	۰/۹۷	۰/۷۶	۰/۷۷	۰/۹۸	۰/۰۳

به منظور ارزیابی پیچیدگی مدل دانش آموز از نظر تعداد پارامترها، پیچیدگی محاسباتی، حافظه مصرفی و نرخ فشرده‌سازی در مقایسه با مدل معلم، پیچیدگی و اندازه شبکه‌ها در مرحله آموزش و آزمون برای مدل‌های دانش آموز-۶ و معلم در جدول (۲) مقایسه شده است. با توجه به جدول، در مرحله آموزش مدل دانش آموز در حدود تعداد ۲/۴۴ میلیون پارامتر تولید شده است که این عدد برای مدل معلم به طور تقریبی عدد بزرگ ۹/۳۵ میلیون است. تعداد محاسبات این مرحله برای مدل دانش آموز حدود ۰/۴۵ گیگافلاپ و میزان حافظه گرافیکی مورد نیاز ۰/۹ گیگابایت است. در مرحله آزمون مدل دانش آموز در حالی که به طور تقریبی ۰/۱۲ گیگابایت حافظه گرافیکی استفاده می‌کند در ۰/۴۵ گیگافلاپ

کرده‌است؛ همچنین تمام نمونه‌های که به اشتباه دسته‌بندی شده‌اند به دسته اصلی خود به طور کامل نزدیک‌اند؛ برای مثال برای دسته شانزده سال، تعداد کمی از نمونه‌ها به اشتباه هفده یا پانزده سال دسته‌بندی شده‌اند.

سن (پیش بینی شده)	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸
۰	۱۴	۴	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۱	۴	۵۹	۳	۱	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۲	۳	۵	۲۸	۰	۱	۳	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۳	۴	۴	۳	۳۰	۰	۱	۱	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۴	۴	۴	۳	۲۹	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۵	۱	۴	۵	۴	۲۸	۴	۳	۱	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰
۶	۱	۰	۰	۰	۴	۰	۵۳	۱	۴	۱	۱	۰	۰	۰	۰	۰	۰	۰	۰
۷	۰	۴	۰	۳	۳	۴	۴	۵۴	۱	۳	۰	۰	۰	۰	۰	۰	۰	۰	۰
۸	۰	۰	۰	۰	۴	۰	۴	۵۵	۵	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰
۹	۰	۰	۰	۰	۳	۰	۳	۴	۴۸	۴	۴	۲	۰	۰	۰	۰	۰	۰	۰
۱۰	۰	۰	۰	۰	۴	۰	۳	۰	۷۸	۴	۷	۴	۳	۰	۰	۰	۰	۰	۰
۱۱	۰	۰	۰	۰	۰	۰	۴	۳	۶	۸۰	۷	۳	۳	۴	۰	۰	۰	۰	۰
۱۲	۰	۰	۰	۰	۰	۰	۳	۳	۰	۸۵	۳	۳	۳	۴	۰	۰	۰	۰	۰
۱۳	۰	۰	۰	۰	۰	۰	۰	۵	۵	۵	۵	۳	۱	۰	۰	۰	۰	۰	۰
۱۴	۰	۰	۰	۰	۰	۰	۰	۲	۱	۳	۸۰	۳	۴	۳	۰	۰	۰	۰	۰
۱۵	۰	۰	۰	۰	۰	۰	۰	۰	۱	۴	۴	۶	۳	۱	۰	۰	۰	۰	۰
۱۶	۰	۰	۰	۰	۰	۰	۰	۰	۳	۰	۴	۱	۶۷	۴	۱	۰	۰	۰	۰
۱۷	۰	۰	۰	۰	۰	۰	۰	۰	۴	۴	۸	۴	۶	۳	۰	۰	۰	۰	۰
۱۸	۰	۰	۰	۰	۰	۰	۰	۰	۴	۱	۴	۵	۳	۰	۰	۰	۰	۰	۰
سن (پیش بینی شده)	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸

(شکل-۴): ماتریس درهم‌ریختگی مدل دانش‌آموز  
(Figure-4): The confusion matrix of the student's model

جدول (۳) عملکرد مدل معلم را بر اساس معیارهای دقت، صحت، بازیافت، حساسیت و میانگین خطای مطلق گزارش می‌کند. عملکرد مدل دانش‌آموز برای نوزده گروه سنی در معیارهای مختلف به طور مستقل در جدول (۴) ارزیابی شده‌است. طبق جدول (۴)، میانگین معیارهای ارزیابی برای نوزده طبقه فعالیت به ترتیب با دقت ۹۴/۷۲، صحت = ۶۴/۷۲، بازیافت = ۶۴/۷۳ و حساسیت ۹۶/۸۹ به دست آمده‌است. این مقادیر نشان می‌دهند که مدل دانش‌آموز به خوبی سن را تشخیص می‌دهد؛ علاوه بر این، مدل دانش‌آموز ارائه‌شده با یک ناحیه ROI و پیچیدگی بسیار کمتر از معلم کمابیش همان عملکرد مدل معلم را تکرار می‌کند.

در ادامه به منظور نمایش گرافیکی مقایسه مدل دانش‌آموز-۶ با معلم نمودار میله‌ای عملکرد آن‌ها در شکل (۵) نمایش داده شده‌است. در این نمودار عملکرد دو مدل بر مبنای چهار معیار ارزیابی دقت، صحت، بازیافت و امتیاز F1 گزارش شده‌است؛ در ضمن به منظور نمایش بهتر اختلاف‌ها اعداد این نمودار بین صفر تا صد گزارش شده‌است. همان گونه که در نمای کلی نمودار قابل مشاهده است اختلاف معناداری بین عملکرد دانش‌آموز-۶ و معلم وجود ندارد؛ تنها اختلاف قابل ذکر امتیاز F1 بین این دو مدل است که آن میانگین وزنی بین دقت و حساسیت است، اما از سوی دیگر معیاری که در مدل‌های طبقه‌بندی اهمیت بیشتری دارد دقت است که در این نمودار مشاهده می‌شود اختلاف زیادی بین دو مدل وجود ندارد.

تکمیل می‌شود و همچنین دارای نرخ فشرده‌سازی ۸/۲۵ است که آن را سبک‌وزن می‌کند. این ویژگی‌ها علاوه بر ارائه دقت بالا، آن را برای استقرار در دستگاه‌های لبه مناسب می‌کند.

(جدول-۲): مقایسه مدل‌های دانش‌آموز-۶ و معلم از نظر پیچیدگی و اندازه شبکه در مراحل آموزش و آزمون  
(Table-2): Comparison of student-6 and teacher models in terms of complexity and network size in two phases of training and testing

مرحله	مدل	تعداد پارامترها	محاسبات (گیگافلاپ)	حافظه گرافیکی	نرخ فشرده‌سازی
آموزش	دانش‌آموز-۶	~۲/۴۴M	~۰/۴۵	۰/۰۹ G	×۳/۸۸
	معلم	~۹/۳۵M	~۲/۵۴	۱/۴۴ G	×۱
آزمون	دانش‌آموز-۶	~۰/۰۸M	~۰/۰۱۲	۰/۰۲ G	×۸/۲۵
	معلم	~۰/۶۶M	~۰/۱۴	۰/۱۱ G	×۱

ماتریس درهم‌ریختگی برای ارزیابی طبقه‌بندی مدل‌ها استفاده می‌شوند. در شکل (۳) و شکل (۴) ماتریس درهم‌ریختگی مدل‌های معلم و دانش‌آموز نشان داده شده‌است. در این ماتریس‌ها مجموعه مثبت صحیح (TP) به نمونه‌هایی اشاره دارد که به درستی طبقه‌بندی شده‌اند و یک عامل کلیدی در ارزیابی اثربخشی مدل‌های طبقه‌بندی هستند و با قطر اصلی ماتریس نشان داده می‌شود. تعداد سطرها و ستون‌های این ماتریس به تعداد طبقه‌های مدل اشاره دارد؛ لذا سطرها و ستون‌های این ماتریس ۱۹×۱۹ شامل گروه‌های سنی مختلف است.

سن (پیش بینی شده)	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸
۰	۱۰	۴	۳	۴	۰	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۱	۳	۳۰	۶	۸	۳	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۲	۴	۴	۲۳	۴	۱	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۳	۳	۴	۳	۳۰	۳	۱	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۴	۴	۴	۷	۴	۳۱	۱	۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
۵	۱	۳	۵	۳	۳	۲۵	۲	۳	۱	۴	۱	۰	۰	۰	۰	۰	۰	۰	۰
۶	۴	۴	۱	۰	۰	۰	۵۰	۴	۳	۳	۱	۰	۰	۰	۰	۰	۰	۰	۰
۷	۰	۴	۰	۳	۳	۴	۴	۲۰	۴	۸	۲	۰	۰	۰	۰	۰	۰	۰	۰
۸	۰	۰	۰	۰	۳	۰	۵	۵۲	۵	۵	۰	۰	۰	۰	۰	۰	۰	۰	۰
۹	۰	۰	۰	۰	۳	۳	۳	۳	۳۸	۴۴	۴	۴	۰	۰	۰	۰	۰	۰	۰
۱۰	۰	۰	۰	۰	۴	۰	۳	۴	۴	۷۸	۰	۶	۵	۳	۰	۰	۰	۰	۰
۱۱	۰	۰	۰	۰	۰	۰	۳	۴	۵	۷۵	۵	۷	۳	۴	۰	۰	۰	۰	۰
۱۲	۰	۰	۰	۰	۰	۰	۳	۰	۳	۵	۷۰	۵	۷	۵	۰	۰	۰	۰	۰
۱۳	۰	۰	۰	۰	۰	۰	۳	۰	۳	۵	۶۰	۹	۶	۵	۰	۰	۰	۰	۰
۱۴	۰	۰	۰	۰	۰	۰	۰	۰	۴	۴	۴	۶	۷۶	۵	۰	۰	۰	۰	۰
۱۵	۰	۰	۰	۰	۰	۰	۰	۰	۱	۳	۸	۷	۵۵	۶	۰	۰	۰	۰	۰
۱۶	۰	۰	۰	۰	۰	۰	۰	۰	۳	۶	۶	۳	۵۷	۵	۰	۰	۰	۰	۰
۱۷	۰	۰	۰	۰	۰	۰	۰	۰	۳	۵	۴	۵	۳	۵۳	۵	۰	۰	۰	۰
۱۸	۰	۰	۰	۰	۰	۰	۰	۰	۴	۳	۷	۹	۵۷	۹	۰	۰	۰	۰	۰
سن (پیش بینی شده)	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸

(شکل-۳): ماتریس درهم‌ریختگی مدل معلم  
(Figure-3): The confusion matrix of the teacher's model

با مقایسه درایه‌های این دو ماتریس با هم می‌توان نتیجه گرفت که عملکرد مدل دانش‌آموز بسیار نزدیک به عملکرد مدل معلم است. این موضوع بسیار حائز اهمیت است که مدل دانش‌آموز برای هر یک از نوزده طبقه موجود در مجموعه داده بیشتر تعداد نمونه‌ها را به درستی دسته‌بندی

<sup>1</sup> True Positive

(جدول-۳): عملکرد مدل معلم بر اساس معیارهای دقت،

صحت، بازیافت، حساسیت و میانگین خطای مطلق

(Table-3): The performance of the teacher model based on the criteria of accuracy, Precision, recall, sensitivity and Mean Absolute Error

ردیف	دقت	صحت	بازیافت	حساسیت	میانگین خطای مطلق
۰	۰/۹۸ ± ۰/۲۶	۰/۶۰ ± ۰/۱۹	۰/۵۶ ± ۰/۱۲	۰/۹۹ ± ۰/۱۵	۰/۰۰۷
۱	۰/۹۷ ± ۰/۱۴	۰/۷۸ ± ۰/۲۵	۰/۶۰ ± ۰/۵۶	۰/۹۹ ± ۰/۸۲	۰/۰۲
۲	۰/۹۷ ± ۰/۱۳	۰/۷۰ ± ۰/۶۱	۰/۶۸ ± ۰/۴۶	۰/۹۸ ± ۰/۵۳	۰/۰۱۶
۳	۰/۹۷ ± ۰/۱۳	۰/۷۵ ± ۰/۴۷	۰/۶۹ ± ۰/۰۱	۰/۹۹ ± ۰/۹۹	۰/۰۱۷
۴	۰/۹۷ ± ۰/۵۷	۰/۷۶ ± ۰/۳۵	۰/۶۵ ± ۰/۳۳	۰/۹۹ ± ۰/۰۷	۰/۰۱۲
۵	۰/۹۶ ± ۰/۵۴	۰/۶۷ ± ۰/۸۳	۰/۷۸ ± ۰/۱۶	۰/۹۷ ± ۰/۴۴	۰/۰۱۱
۶	۰/۹۸ ± ۰/۱۴	۰/۸۷ ± ۰/۵۸	۰/۹۰ ± ۰/۷۹	۰/۹۹ ± ۰/۱۰	۰/۰۰۹
۷	۰/۹۶ ± ۰/۸۴	۰/۷۵ ± ۰/۵۴	۰/۷۵ ± ۰/۳۱	۰/۹۸ ± ۰/۹۶	۰/۰۰۴
۸	۰/۹۷ ± ۰/۶۲	۰/۸۲ ± ۰/۹۱	۰/۸۶ ± ۰/۵۲	۰/۹۸ ± ۰/۰۰	۰/۰۱۱
۹	۰/۹۶ ± ۰/۳۵	۰/۷۵ ± ۰/۲۸	۰/۷۲ ± ۰/۱۶	۰/۹۸ ± ۰/۷۷	۰/۰۱۳
۱۰	۰/۹۶ ± ۰/۵۱	۰/۷۸ ± ۰/۷۵	۰/۸۲ ± ۰/۶۰	۰/۹۷ ± ۰/۸۰	۰/۰۱۲
۱۱	۰/۹۶ ± ۰/۴۰	۰/۷۸ ± ۰/۷۵	۰/۸۴ ± ۰/۲۶	۰/۹۷ ± ۰/۸۶	۰/۰۱
۱۲	۰/۹۶ ± ۰/۰۷	۰/۸۲ ± ۰/۳۸	۰/۷۷ ± ۰/۶۵	۰/۹۸ ± ۰/۰۸	۰/۰۱۲
۱۳	۰/۹۵ ± ۰/۲۳	۰/۸۰ ± ۰/۵۶	۰/۸۰ ± ۰/۶۸	۰/۹۷ ± ۰/۳۹	۰/۰۰۹
۱۴	۰/۹۵ ± ۰/۱۲	۰/۸۰ ± ۰/۰۷	۰/۷۴ ± ۰/۷۴	۰/۹۸ ± ۰/۲۵	۰/۰۱۳
۱۵	۰/۹۵ ± ۰/۱۸	۰/۷۵ ± ۰/۰۵	۰/۶۸ ± ۰/۴۵	۰/۹۸ ± ۰/۸۰	۰/۰۸۴
۱۶	۰/۹۷ ± ۰/۴۲	۰/۸۳ ± ۰/۵۳	۰/۸۱ ± ۰/۰۸	۰/۹۸ ± ۰/۴۳	۰/۰۱۹
۱۷	۰/۹۷ ± ۰/۴۱	۰/۷۲ ± ۰/۷۷	۰/۸۸ ± ۰/۲۲	۰/۹۷ ± ۰/۶۵	۰/۰۰۸
۱۸	۰/۹۷ ± ۰/۰۴	۰/۸۱ ± ۰/۹۳	۰/۹۲ ± ۰/۹۱	۰/۹۸ ± ۰/۱۸	۰/۰۰۶

(جدول-۴): عملکرد مدل دانش آموز-۶ بر اساس معیارهای

دقت، صحت، بازیافت، حساسیت و میانگین خطای مطلق

(Table-4): The performance of Student-6 model based on the criteria of accuracy, Precision, recall, sensitivity and Mean Absolute Error

ردیف	دقت	صحت	بازیافت	حساسیت	میانگین خطای مطلق
۰	۰/۹۶ ± ۰/۵۸	۰/۴۳ ± ۰/۹۰	۰/۳۷ ± ۰/۳۵	۰/۹۸ ± ۰/۹۲	۰/۰۱۳
۱	۰/۹۵ ± ۰/۲۰	۰/۵۰ ± ۰/۹۴	۰/۵۰ ± ۰/۸۲	۰/۹۷ ± ۰/۷۷	۰/۰۰۹
۲	۰/۹۶ ± ۰/۳۰	۰/۶۱ ± ۰/۴۹	۰/۴۶ ± ۰/۰۱	۰/۹۸ ± ۰/۴۸	۰/۰۰۸
۳	۰/۹۵ ± ۰/۴۷	۰/۵۰ ± ۰/۴۸	۰/۴۱ ± ۰/۰۴	۰/۹۷ ± ۰/۴۳	۰/۰۱۰
۴	۰/۹۶ ± ۰/۲۳	۰/۵۲ ± ۰/۳۳	۰/۵۶ ± ۰/۱۶	۰/۹۷ ± ۰/۴۴	۰/۰۱۱۲
۵	۰/۹۵ ± ۰/۸۴	۰/۶۳ ± ۰/۹۰	۰/۷۳ ± ۰/۶۴	۰/۹۷ ± ۰/۳۰	۰/۰۰۸
۶	۰/۹۷ ± ۰/۱۹	۰/۸۰ ± ۰/۳۶	۰/۸۰ ± ۰/۷۳	۰/۹۸ ± ۰/۵۰	۰/۰۱
۷	۰/۹۴ ± ۰/۲۲	۰/۵۷ ± ۰/۱۱	۰/۶۴ ± ۰/۶۴	۰/۹۶ ± ۰/۵۱	۰/۰۰۷
۸	۰/۹۵ ± ۰/۱۷	۰/۷۲ ± ۰/۷۸	۰/۷۲ ± ۰/۴۵	۰/۹۷ ± ۰/۸۱	۰/۰۱۴
۹	۰/۹۴ ± ۰/۲۲	۰/۶۴ ± ۰/۳۸	۰/۵۲ ± ۰/۵۴	۰/۹۷ ± ۰/۷۹	۰/۰۱۲
۱۰	۰/۹۴ ± ۰/۴۳	۰/۷۴ ± ۰/۲۴	۰/۷۲ ± ۰/۲۹	۰/۹۶ ± ۰/۶۴	۰/۰۲۱
۱۱	۰/۹۴ ± ۰/۳۱	۰/۴۰ ± ۰/۶۰	۰/۶۹ ± ۰/۴۰	۰/۹۶ ± ۰/۳۷	۰/۰۱
۱۲	۰/۹۳ ± ۰/۹۲	۰/۷۰ ± ۰/۰۹	۰/۷۱ ± ۰/۱۸	۰/۹۶ ± ۰/۸۱	۰/۰۱۳
۱۳	۰/۹۲ ± ۰/۴۳	۰/۶۹ ± ۰/۱۳	۰/۶۳ ± ۰/۶۸	۰/۹۶ ± ۰/۵۳	۰/۰۱۸
۱۴	۰/۹۳ ± ۰/۱۸	۰/۷۶ ± ۰/۹۴	۰/۶۶ ± ۰/۱۸	۰/۹۷ ± ۰/۳۵	۰/۰۱
۱۵	۰/۹۴ ± ۰/۹۰	۰/۶۸ ± ۰/۹۵	۰/۶۳ ± ۰/۳۶	۰/۹۷ ± ۰/۹۳	۰/۰۰۷
۱۶	۰/۹۵ ± ۰/۹۷	۰/۷۱ ± ۰/۵۷	۰/۷۲ ± ۰/۶۲	۰/۹۷ ± ۰/۸۷	۰/۰۱۱
۱۷	۰/۹۵ ± ۰/۴۳	۰/۶۶ ± ۰/۰۵	۰/۷۵ ± ۰/۷۸	۰/۹۷ ± ۰/۵۵	۰/۰۱۳
۱۸	۰/۹۷ ± ۰/۱۱	۰/۷۱ ± ۰/۲۳	۰/۹۱ ± ۰/۰۸	۰/۹۷ ± ۰/۶۲	۰/۰۱

۳-۴- تحلیل عملکرد مدل چکانش دانش پیشنهادی


در مقایسه با سایر تکنیک‌های چکانش دانش

در این بخش تحلیل عملکرد بین مدل چکانش دانش ارائه شده و سه رویکرد دیگر که بر اساس سایر مدل‌های چکانش دانش انجام می‌شود. این مقایسه‌ها در رابطه با

اندازه‌گیری‌های دقت، دقت، یادآوری و ویژگی طراحی شده‌اند، برای این مقایسه‌ها، روش‌های KD زیر انتخاب می‌شوند:

۱. O-KD: این مدل نخستین مطالعه در مورد چکانش دانش است که شبکه دانش آموز بر اساس ویژگی‌های ایجاد شده توسط لایه پایانی شبکه معلم آموزش داده می‌شود و در اصطلاح روش دانش پاسخ‌محور نام دارد.
۲. FitNet: این روش نخستین مطالعه چکانش دانش مبتنی بر ویژگی است. در این مدل شبکه دانش آموز بر اساس نقشه‌های ویژگی لایه‌های میانی شبکه معلم آموزش داده می‌شود.

۳. T-KD: در این مدل، چند معلم بر آموزش و عملکرد مدل دانش آموز نظارت دارند. دانش لایه‌های میانی و دانش لایه پایانی هر معلم با هم ادغام و به دانش آموز منتقل می‌شود. علاوه بر این، هر معلم به طور تصادفی گروهی از لایه‌های دانش آموزی را به صورت جداگانه آموزش می‌دهد.



(شکل-۵): نمودار میله‌ای عملکرد مدل دانش آموز-۶ و مدل

معلم با چهار معیار ارزیابی دقت، صحت، بازیافت و امتیاز F1 (Figure-5): Comparing performance of Student-6 and teacher model by Accuracy, Precision, Recall, and F1-measure

روش‌های ارائه شده در جدول (۵) بر روی مجموعه داده اطلس دست دیجیتال پیاده‌سازی شده‌اند. خروجی آن‌ها با مدل چکانش دانش پیشنهادی ما مقایسه شده‌است. بر این اساس، دانش آموز مدل چکانش دانش ما از بهترین مدل دانشجویی O-KD، T-KD، و FitNet از نظر چهار معیار ارزیابی بسیار بهتر عمل می‌کند. با توجه به جدول، معیارهای ارزیابی برای روش پیشنهادی دقت = ۹۷٪، صحت = ۷۶٪، بازیافت = ۷۶٪ و حساسیت = ۹۸٪ است که نشان‌دهنده برتری مدل پیشنهادی برای طبقه‌بندی نسبت به مدل‌های دیگر است.

برای اثبات برتری و تصادفی نبودن نتایج روش ارائه شده نسبت به سه روش دیگر از طریق آزمون t یک ارزیابی انجام شده و نتایج این آزمون در جدول (۶) نشان داده شده‌است. آزمون t یک آمار استنباطی است که برای

تعیین اینکه آیا تفاوت معنی‌داری بین میانگین دو گروه و نحوه ارتباط آن‌ها وجود دارد یا خیر استفاده می‌شود.

(جدول-۵): تحلیل عملکرد مدل چکانش دانش پیشنهادی در مقایسه با سایر تکنیک‌های چکانش دانش

(Table-5): performance analysis of the proposed knowledge Distillation model compared to other knowledge Distillation models

مدل	دقت	صحت	بازیافت	حساسیت
O-KD	0.74 ± 0.78	0.59 ± 0.90	0.58 ± 0.47	0.78 ± 0.17
FitNet	0.78 ± 0.99	0.58 ± 0.85	0.57 ± 0.8	0.77 ± 0.90
T-KD	0.89 ± 0.8	0.61 ± 0.70	0.60 ± 0.43	0.89 ± 0.84
مدل پیشنهادی	0.97 ± 0.8	0.76 ± 0.82	0.76 ± 0.6	0.98 ± 0.002

روش‌های ذکرشده در جدول (۷) با استفاده از الگوریتم‌های مختلف پیاده‌سازی شده‌اند، از یادگیری ماشین گرفته تا شبکه‌های CNN. با توجه به نتایج به‌دست‌آمده به‌وسیله همه مدل‌های ذکرشده به‌طور کامل واضح است که روش ارائه‌شده در این مقاله عملکرد بهتری در مقایسه با دیگر روش‌ها دارد. به طوری که استراژی ما می‌تواند تمام نوزده طبقه سن استخوانی را با دقت ۹۶/۴۷٪ و میانگین خطای مطلق ۰/۰۸۷ طبقه‌بندی کند که بسیار بالاتر از سایر رویکردهاست.

(جدول-۷): مقایسه نتایج مدل پیشنهادی با سایر روش‌های

ارائه‌شده بر روی مجموعه داده اطلس دست دیجیتال

(Table-7): Comparing the results of the proposed model and other methods presented on the digital hand atlas dataset

روش	ROI	دقت	میانگین خطای مطلق
CNN [۲۵]	بله	۸۳/۴	-
Regression [۲۶]	خیر	-	۴/۷
CNN [۲۷]	خیر	-	۴/۱۴
SVM [۲۸]	خیر	-	۶/۰۵
Fuzzy Classifiers [۲۹]	خیر	۷۹	-
Histogram [۳۰] technique	خیر	-	۱/۷۰
CNN+ SVR [۳۰]	خیر	۶۷	-
CNN [۳۱]	خیر	-	۵/۹۰
CNN [۹]	بله	۸۳	-
Capsule Network [۳۲]	خیر	۹۰/۸۵	-
DNN [۳۳]	خیر	۸۸/۱۱	۳/۵۸
Hidden Markov [۳۴]	خیر	۹۱/۱۰	-
KD [۱۲]	بله	۹۵/۱۶	۰/۰۲۲
روش پیشنهادی	بله	۹۶/۴۷	۰/۰۱۲

## ۵- مقایسه روش پیشنهادی با سایر مطالعات ارزیابی سن استخوان

تاکنون چندین روش مختلف ارزیابی خودکار سن استخوانی ارائه شده‌است که تمام این روش‌ها بر مبنای دو روش سنتی GP و TW هستند. بخش عمده‌ای از این روش‌ها بر روی تصاویر خصوصی و یا محدود به رده سنی و نژاد خاص آزمایش شده‌اند که به دلیل عدم دسترسی به اطلاعات آن‌ها این نتایج قابل مقایسه و تکرار نیستند. از بین روش‌های ارائه‌شده تعداد کمی روش وجود دارد که بر روی مجموعه داده‌های DHA طراحی و آزمایش شده‌اند. در این بخش یک مقایسه بین روش‌های اجراشده بر روی DHA و روش ارائه‌شده در این مقاله انجام شده، همان‌طور که در جدول نشان داده شده، این مقایسه بر مبنای دو معیار دقت و میانگین خطای مطلق صورت گرفته‌است.

(جدول-۶): مقایسه نتایج آزمون آماری T روش پیشنهادی با

دیگر روش‌های چکانش دانش

(Table-6): Comparing the results of the T-test of the proposed method and other knowledge extraction methods

معیار	مدل	TStatistic	TCritical	p-Value
دقت	O-KD	- ۵/۸۳۳۷	۵/۴۵۲۲	۰/۰۰۵۴۲
	FitNet	- ۰/۰۰۸۷	۱/۱۳۵۴	۰/۰۱۷۳
	T-KD	- ۲/۱۲۲	۱/۱۳۳۸	۰/۰۴۵۷۷
حساسیت	O-KD	- ۴/۷۵۲۱	۲/۰۷۵۵	۰/۰۰۸۶۲
	FitNet	- ۵/۲۰۰۱	۲/۶۵۶۳	۰/۰۱۲۳
	T-KD	- ۰/۳۵۳۳	۱/۰۰۱۲	۰/۰۳۷۶
معیار F1-	O-KD	- ۷/۸۴۴۳	۲/۷۵۹۳	۰/۰۰۸۹
	FitNet	- ۱/۳۰۵۴	۱/۰۹۶۳	۰/۰۰۶۳
	T-KD	- ۱/۰۰۷۸	۱/۴۶۳۷	۰/۰۳۱۲
ویژگی	O-KD	- ۶/۴۵۷۳	۲/۶۶۴	۰/۰۰۷۵
	FitNet	- ۳/۶۷۳۳	۰/۸۵۲۲	۰/۰۶۶۳
	T-KD	- ۰/۸۸۸۳	۱/۷۸۴۲	۰/۰۳۵۴
صحت	O-KD	- ۸/۴۱۲	۳/۵۸۵۵	۰/۰۰۸۵
	FitNet	- ۶/۳۶۸۷	۲/۹۴۳۳	۰/۰۰۱۱
	T-KD	- ۱/۰۴۵۹	۱/۶۵۷	۰/۰۲۷

در مقاله ارائه‌شده در [۳۲] نویسندگان از یک مدل شبکه‌های عصبی کپسولی استفاده کردند که از دو لایه نورون‌های داخلی استفاده می‌کند، اما این روش آن گونه که در جدول نیز اشاره شده از هیچ الگوریتم ROI به منظور استخراج نقاط مهم استفاده نکرده‌است؛ لذا نمی‌تواند روش مطمئنی برای تشخیص سن استخوانی باشد؛ همچنین در مقاله ارائه‌شده در [۳۴] نویسندگان روشی مبتنی بر مدل مخفی مارکوف ارائه داده‌اند، اما مشکل این روش عدم توجه به تنوع در مدل یادگیری است که سبب کاهش جامعیت آن در مشاهده با داده دیده نشده است.

## ۶- نتیجه‌گیری

در این مقاله یک معماری جدید مبتنی بر چکانش دانش تجزیه‌شده به دو شکل مبتنی بر پاسخ و ویژگی از شبکه معلم به شبکه دانش‌آموز برای ارزیابی سن استخوان طراحی و آزمایش شد. این روش به‌طور کامل خودکار بر

- machine learning techniques: a systematic literature review and meta-analysis," *PloS one*, vol. 14, no. 7, p. e0220242, 2019.
- [4] P. Sousa-e-Silva et al., "Skeletal age assessed by TW2 using 20-bone, carpal and RUS score systems: Intra-observer and inter-observer agreement among male pubertal soccer players," *Plos one*, vol. 17, no. 8, p. e0271386, 2022.
- [5] Y. M. Wang, T. H. Tsai, J. S. Hsu, M. F. Chao, Y. T. Wang, and T. S. Jaw, "Automatic assessment of bone age in Taiwanese children: a comparison of the Greulich and Pyle method and the Tanner and Whitehouse 3 method," *The Kaohsiung Journal of Medical Sciences*, vol. 36, no. 11, pp. 937-943, 2020.
- [6] T. Widek, P. Genet, T. Ehammer, T. Schwark, M. Urschler, and E. Scheurer, "Bone age estimation with the Greulich-Pyle atlas using 3T MR images of hand and wrist," *Forensic Science International*, vol. 319, p. 110654, 2021.
- [7] D. D. Martin, A. D. Calder, M. B. Ranke, G. Binder, and H. H. Thodberg, "Accuracy and self-validation of automated bone age determination," *Scientific Reports*, vol. 12, no. 1, p. 6388, 2022.
- [8] A. Elhakeem, M. Frysz, K. Tilling, J. H. Tobias, and D. A. Lawlor, "Association between age at puberty and bone accrual from 10 to 25 years of age," *JAMA network open*, vol. 2, no. 8, pp. e198918-e198918, 2019.
- [9] H. Sarabi Sarvarani and F. Abdali-Mohammadi, "An Ensemble Convolutional Neural Networks for Detection of Growth Anomalies in Children with X-ray Images," *Journal of AI and Data Mining*, vol. 10, no. 4, pp. 479-492, 2022.
- [10] M. Sepahvand, F. Abdali-Mohammadi, and A. Taherkordi, "Teacher-student knowledge distillation based on decomposed deep feature representation for intelligent mobile applications," *Expert Systems with Applications*, vol. 202, p. 117474, 2022.
- [11] M. Sepahvand, F. Abdali-Mohammadi, and A. Taherkordi, "An adaptive teacher-student learning algorithm with decomposed knowledge distillation for on-edge intelligence," *Engineering Applications of Artificial Intelligence*, vol. 117, p. 105560, 2023.
- [12] F. Abdali-Mohammadi, M. Mardanpour, M. Sepahvand, H. Sarabi, "A Bone Age Assessment based on a hybrid Knowledge Distillation Paradigm using single ROI," available online at: <https://www.authorea.com/doi/full/10.22541/au.166869703.37960946>
- [13] C. Liu, H. Xie, Y. Liu, Z. Zha, F. Lin, and Y. Zhang, "Extract Bone Parts Without Human Prior: End-to-end Convolutional Neural Network for Pediatric Bone Age Assessment," in *Medical Image Computing and Computer Assisted Intervention -*

روی مجموعه داده‌های DHA شامل ۱۴۰۰ تصویر مج دست از کودکان سالم صفر تا هجده ساله از نژادهای آسیایی، اسپانیایی، سیاه‌پوست و قفقازی اجرا شد. در قسمت پیش‌پردازش یک قطعه‌بندی بر روی تصاویر انجام می‌شود و شش ناحیه مختلف از تصاویر شامل تمامی ROIهای روش TW از تصاویر جدا می‌شود. در طول آموزش مدل، تصاویر با تغییر اندازه و چرخش به طور مصنوعی تقویت می‌شوند تا تعداد تصاویر افزایش یافته و دقت بالاتری حاصل شود. در بخش تشخیص سن، یک شبکه معلم با ساختار پیشرفته CNN بر روند یادگیری یک مدل دانش‌آموز ساخته شده از معماری ساده CNN نظارت می‌کند که دانش‌آموز را به تقلید از رفتار مدل معلم هدایت می‌کند. مدل دانش‌آموز با استفاده از دانش منتقل شده معلم که حاوی داده‌هایی از نقشه‌های ویژگی لایه‌های میانی معلم و همچنین آخرین لایه خروجی آن است، آموزش داده می‌شود. با بهره‌گیری از این بینش مفید، مدل دانش‌آموز می‌تواند شیوه معلم را با شباهت زیاد تقلید کند و دانش‌آموز را به جای معلم دقیق‌تر کند؛ درحالی‌که معماری را به مراتب پیچیده‌تر نگه می‌دارد. در قسمت نتایج و ارزیابی مدل، آزمون‌های مختلفی از جمله آزمون‌های شبکه از پیش آموزش دیده انجام می‌شود. عملکرد بهتر نظام طراحی شده در مقایسه با سایر روش‌ها به وسیله نتایج تمامی آزمون‌ها تأیید می‌شود. دقت روش پیشنهادی ۹۲/۴۷ درصد و به میانگین خطای ۰/۸۷ درصد دست می‌یابد. برای تقویت روش پیشنهادی، قصد داریم از روش‌های جدیدی مانند انتقال یادگیری برای افزودن دانش در یک مدل بزرگ به مدل کوچک‌تر با تنظیم دقیق استفاده کنیم تا آن را در دستگاه‌های لبه قابل استفاده کنیم.

با توجه به کاربرد این روش‌ها در پزشکی قانونی، باید حفظ محرمانگی داده‌ها [۳۵] را در نظر گرفت؛ به علاوه در صورت تهاجم به این نظام‌ها، عواقب قانونی به وجود می‌آید و ممکن است نظام مورد سو استفاده قرار گیرد [۳۶].

## 7-References

## ۷-مراجع

- [1] F. Cavallo, A. Mohn, F. Chiarelli, and C. Giannini, "Evaluation of bone age in children: a mini-review," *Frontiers in Pediatrics*, vol. 9, p. 580314, 2021.
- [2] A. Tekin and K. Cesur Aydın, "Comparative determination of skeletal maturity by hand-wrist radiograph, cephalometric radiograph and cone beam computed tomography," *Oral Radiology*, vol. 36, pp. 327-336, 2020.
- [3] A. L. Dallora, P. Anderberg, O. Kvist, E. Mendes, S. Diaz Ruiz, and J. Sanmartin Berglund, "Bone age assessment with various

- [23] Z. Yang, C. Cong, M. Pagnucco, and Y. Song, "Multi-scale multi-reception attention network for bone age assessment in X-ray images," *Neural Networks*, vol. 158, pp. 249-257, 2023.
- [24] C. S. Politzer, J. D. Bomar, H. C. Pehlivan, P. Gurusamy, E. W. Edmonds, and A. T. Pennock, "Creation and validation of a shorthand magnetic resonance imaging bone age assessment tool of the knee as an alternative skeletal maturity assessment," *The American Journal of Sports Medicine*, vol. 49, no. 11, pp. 2955-2959, 2021.
- [25] M. N. Meqdad, H. T. Rauf, and S. Kadry, "Bone Anomaly Detection by Extracting Regions of Interest and Convolutional Neural Networks," *Applied System Innovation*, vol. 6, no. 1, p. 21, 2023. [Online]. Available: <https://www.mdpi.com/2571-5577/6/1/21>.
- [26] C. Chen, Z. Chen, X. Jin, L. Li, W. Speier, and C. W. Arnold, "Attention-Guided Discriminative Region Localization and Label Distribution Learning for Bone Age Assessment," (in eng), *IEEE J Biomed Health Inform*, vol. 26, no. 3, pp. 1208-1218, Mar 2022, doi: 10.1109/jbhi.2021.3095121.
- [27] C. Spampinato, S. Palazzo, D. Giordano, M. Aldinucci, and R. Leonardi, "Deep learning for automated skeletal bone age assessment in X-ray images," (in eng), *Med Image Anal*, vol. 36, pp. 41-51, Feb 2017, doi: 10.1016/j.media.2016.10.010.
- [28] M. Kashif, T. M. Deserno, D. Haak, and S. Jonas, "Feature description with SIFT, SURF, BRIEF, BRISK, or FREAK? A general question answered for bone age assessment," *Computers in biology and medicine*, vol. 68, pp. 67-75, 2016.
- [29] A. K. Alshamrani and A. C. Offiah, "Applicability of two commonly used bone age assessment methods to twenty-first century UK children," *European radiology*, vol. 30, pp. 504-513, 2020.
- [30] X. Pan, Y. Zhao, H. Chen, D. Wei, C. Zhao, and Z. Wei, "Fully Automated Bone Age Assessment on Large-Scale Hand X-Ray Dataset," *International journal of biomedical imaging*, vol. 2020, no. 1, p. 8460493, 2020.
- [31] Y. A. Ding, F. Mutz, K. F. Cõco, L. A. Pinto, and K. S. Komati, "Bone age estimation from carpal radiography images using deep learning," *Expert Systems*, vol. 37, no. 6, p. e12584, 2020, doi: <https://doi.org/10.1111/exsy.12584>.
- [32] J. Jasper Gnana Chandran, R. Karthick, R. Rajagopal, and P. Meenalochini, "Dual-Channel Capsule Generative Adversarial Network Optimized with Golden Eagle Optimization for Pediatric Bone Age Assessment from Hand X-Ray Image," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 37, no. 02, p. MICCAI 2019, Cham, D. Shen et al., Eds., 2019. Springer International Publishing, pp. 667-675.
- [14] S. M. S. Hosseini et al., "Atlas of digital pathology: A generalized hierarchical histological tissue type-annotated database for deep learning," 2019, pp. 11747-11756.
- [15] S. Koitka, M. S. Kim, M. Qu, A. Fischer, C. M. Friedrich, and F. Nensa, "Mimicking the radiologists' workflow: Estimating pediatric hand bone age with stacked deep neural networks," *Medical Image Analysis*, vol. 64, p. 101743, 2020.08.01. 2020, doi: <https://doi.org/10.1016/j.media.2020.101743>.
- [16] C. González, M. Escobar, L. Daza, F. Torres, G. Triana, and P. Arbeláez, "SIMBA: Specific Identity Markers for Bone Age Assessment," in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2020*, Cham, A. L. Martel et al., Eds., 2020. 2020: Springer International Publishing, pp. 753-763.
- [17] D. Wang, K. Zhang, J. Ding, and L. Wang, "Improve Bone Age Assessment by Learning from Anatomical Local Regions," in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2020*, Cham, A. L. Martel et al., Eds., 2020. 2020: Springer International Publishing, pp. 631-640.
- [18] A. Wibisono et al., "Deep learning and classic machine learning approach for automatic bone age assessment," in *2019 4th Asia-Pacific Conference on Intelligent Robot Systems (ACIRS)*, 2019: IEEE, pp. 235-240.
- [19] V. I. Iglovikov, A. Rakhlin, A. A. Kalinin, and A. A. Shvets, "Paediatric bone age assessment using deep convolutional neural networks," in *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*, 2018. Springer, pp. 300-308.
- [20] S. Deshmukh and A. Khaparde, "Faster region-convolutional neural network oriented feature learning with optimal trained recurrent neural network for bone age assessment for pediatrics," *Biomedical Signal Processing and Control*, vol. 71, p. 103016, 2022.
- [21] I. Salim and A. B. Hamza, "Ridge regression neural network for pediatric bone age assessment," *Multimedia Tools and Applications*, vol. 80, no. 20, pp. 30461-30478, 2021.
- [2] S. J. Son et al., "TW3-based fully automated bone age assessment system using deep neural networks," *IEEE Access*, vol. 7, pp. 33346-33358, 2019.



- [33] Z. Li et al., "Bone age assessment based on deep neural networks with annotation-free cascaded critical bone region extraction," *Frontiers in Artificial Intelligence*, vol. 6, p. 1142895, 2023.
- [34] P. Sousa-e-Silva et al., "Intra-observer reproducibility and inter-observer agreement of Fels skeletal age assessments among male tennis players 8–16 years," *BMC Pediatrics*, vol. 23, no. 1, p. 196, 2023/04/26 2023, doi: 10.1186/s12887-023-03965-8.
- [35] A. Hassan Pour Askari, A. Khatibi Bardsiri, M. Mohammadi Ghanat Ghestani, "IoT privacy for the transmission of data in the field of health using blockchain", *signal and data processing*, vol.21, no. 3, pp. 149-178, 2024
- [36] M. khaloei, M. Homayounpour, M. Amirmazlaghani, "A survey on vulnerability of deep neural networks to adversarial examples and defense approaches to deal with them", *signal and data processing*, vol. 20, no. 2, pp. 113-144, 2023



#### فردین ابدالی محمدی پزشک

عمومی و دانشیار گروه مهندسی کامپیوتر و فناوری اطلاعات دانشگاه رازی کرمانشاه است. زمینه‌های پژوهشی ایشان انفورماتیک پزشکی، انفورماتیک زیست‌پزشکی، پردازش سیگنال و تصویر، داده‌کاوی، یادگیری ماشین و شبکه‌های یادگیری عمیق است.

نشانی رایانامه ایشان عبارت است از:

fardin.abdali@razi.ac.ir



#### حمیرا سرابی سرورانی

کارشناسی‌ارشد مهندسی فناوری اطلاعات از دانشگاه رازی کرمانشاه است. زمینه‌های پژوهشی وی پردازش تصاویر، سیگنال و شبکه‌های یادگیری عمیق است.

نشانی رایانامه ایشان عبارت است از:

h.sarabi@stu.razi.ac.ir