تشخیص اختلال در رشد کودکان به‌کمک معماری مبتنی بر انتقال یادگیری به روش چکانش دانش

حمیرا سرابی سروارنی[۱]، فردین ابدالی محمدی[۲*]

دانشجوی کارشناسی‌ارشد مهندسی فناوری اطلاعات، دانشکدهٔ برق و کامپیوتر، دانشگاه رازی، کرمانشاه، ایران[۱]

دانشیار گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشکدهٔ برق و کامپیوتر، دانشگاه رازی، کرمانشاه، ایران[۲*]

چکیده

تقویت دستگاه‌های پزشکی با اینترنت اشیا و فناوری هوش مصنوعی تشخیصی، ضمن درنظرگرفتن محدودیت‌های این سامانه‌ها، پتانسیل مدرن‌سازی و ارتقای رویکرد تشخیصی نسل‌های آیندهٔ سامانه‌های اینترنت اشیا را در حوزهٔ 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 به‌علت 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 شبکهٔ دانش‌آموز برای طبقه‌بندی سن استخوان استفاده شده‌است. این روش از حجم محاسبات موردنیاز برای دستگاه‌های لبه می‌کاهد. ارزیابی روش ارائه با استفاده از مجموعه‌داده‌های اطلس دست دیجیتال انجام شده‌است. نتیجهٔ روش با معیارهای دقت، بازیافت، صحت و میانگین خطای مطلق ارزیابی شده‌است. مدل پیشنهادی ۹۶/۴۷ درصد دقت آزمون را برای طبقه‌بندی سن استخوان به‌دست 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 [1], Fardin Abdali Mohammadi [2*]

Master student of Information Technology Engineering, Razi University, Kermanshah, Iran[1]

Associate Professor, Faculty of Electrical and Computer Engineering, Department of Computer Engineering, Razi University, Kermanshah, Iran[2*]

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

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

• تاریخ ارسال مقاله: ۱۴۰۲/۶/۲۴ • تاریخ پذیرش: ۱۴۰۳/۹/۱۴ • تاریخ انتشار: ۱۴۰۳/۱۲/۳۰ • نوع مطالعه: پژوهشی

سال ۱۴۰۳ شمارهٔ ۴ پیاپی ۶۲

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

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, permission 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

۱-مقدمه

ارزیابی سن استخوان به پزشکان کمک می‌کند تا مرحلهٔ بلوغ اسکلتی کودکان را تخمین بزنند. این کار با رادیوگرافی اشعهٔ ایکس از دست چپ انجام می‌شود[۱]. در روش سنتی گرئولیچ-پایل[1] استخوان‌های تصویر اشعهٔ ایکس با تصاویر موجود در یک اطلس استاندارد رشد استخوان مقایسه می‌شوند. این اطلس از تصاویر اشعهٔ 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)[2] [۳, ۴]، ارزیابی سن استخوان بر یک نظام امتیازدهی متکی است که سطح بلوغ اسکلتی را برای بیست ناحیهٔ 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، نشان‌دهندهٔ مشکل رشد باشد[۵]. مطالعهٔ 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 غدهٔ فوق کلیوی)[۷]. ۲. 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 توسعهٔ 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، بااین‌حال، 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[3]، 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)[4]، آموزش داده شده‌است، در این آموزش برای یک تصویر متعلق به کودک ده ساله با وضوح ۲۵۶ × ۲۵۶ نزدیک به۸۴/۰۴ مگابایت پارامتر ایجاد شده‌است. با فرض استفاده از نوع داده‌ای ممیز شناور اعشاری که هشت بایت است، اندازهٔ مدل ۶۴۰ مگابایت خواهد بود که تاحدودی بزرگ است؛ بنابراین، استفاده از روش‌هایی برای تسهیل و کاهش پیچیدگی محاسباتی

1 Greulich-Pyle
2 Tanner Whitehouse

3 On Device Learning
4 Digital Hand Atlas

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

مدل‌های یادگیری عمیق ضروری است؛ ازاین‌رو، ارائهٔ راهکارهای مناسب برای چالش‌های مطرح‌شده در توسعهٔ مدل‌های یادگیری بهینه ضروری است. بسیاری از پژوهش‌گران با پیشنهاد روش‌های مختلف مانند فشرده‌سازی مدل، هرس و به‌اشتراک‌گذاری پارامتر، تجزیه، پالایه‌های پیچشی[1] فشردهٔ انتقال‌یافته و چکانش دانش (KD)[2] سعی در توسعهٔ مدل‌های یادگیری سبک‌وزن کرده‌اند. در میان این روش‌ها، چکانش دانش روشی جامع برای نظارت بر آموزش مدل دانش‌آموزان سبک‌وزن[3] با استفاده از دانش استخراج‌شده از یک مدل شبکهٔ معلم پیشرفته است. به‌دلیل اینکه تمامی مدل‌های ارائه‌شده با استفاده از فشرده‌سازی، هرس و تجزیه، برای افزایش دقت به ویژگی‌های تمامی نواحی استخراج‌شده از دست نیازمندند، وابستگی به حجم داده‌ها همچنان باقی مانده‌است؛ به عبارتی در تعداد داده‌های ورودی تغییری ایجاد نشده‌است و فقط سیاست‌هایی برای کم‌کردن و یا فشرده‌سازی پارامترها به‌کار گرفته شده‌است.

در مدل ارائه‌شده در این مقاله هدف فشرده‌سازی و یا هرس پارامترها نیست، بلکه هدف ارائهٔ یک پارادایم برای کم‌کردن تعداد ورودی‌های شبکهٔ عصبی عمیق در کنار ارائهٔ دقت قابل‌قبول است. به همین دلیل یک چکانش دانش مبتنی بر معلم و دانش‌آموز استفاده شده‌است. شبکهٔ معلم یک مدل پیشرفته است که با تمام نواحی ورودی، آموزش داده‌شده‌است و بر عملکرد مدل دانش‌آموز که تنها با یک ناحیه از این نواحی آموزش داده‌شده‌است، نظارت دارد؛ درنتیجه یک مدل دانش‌آموز ساده و کم‌حجم 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 ارائه‌شده 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 به‌درستی شناسایی و استخراج شدند. استخراج این نواحی نقش مهمی در بهبود یادگیری ویژگی‌های آموزنده در شبکه‌های عصبی عمیق دارد. دیگر نوآوری ارائه‌شده در این مقاله مربوط به بخش آموزش و پیش‌بینی مدل است که یک روش چکانش دانش جدید پیشنهاد شده‌است. در کار معرفی‌شدهٔ پیشین توسط نویسندگان در [۱۲] از یک مدل پایهٔ چکانش دانش به منظور تشخیص سن استخوانی استفاده شد. در این مقاله با به‌کارگیری یک مدل چکانش دانش پیشرفته‌تر تلاش در بهبود عملکرد روش پیشین خود دارد. بر خلاف روش پیشین، از رویکرد یادگیری مشترک برای چکانش دانش معلم در لایهٔ پاسخ همراه با دانش معلم در نقشه‌های ویژگی لایه‌های میانی استفاده شده‌است.

در این روش برای تجزیهٔ نقشه‌های ویژگی مدل‌های معلم و دانش‌آموز از تجزیهٔ تاکر[4] استفاده شده‌است که تنسورها[5] به‌دلیل پیچیدگی کم به‌راحتی برای دانش‌آموزان قابل درک است. گفتنی است این روش در هیچ یک از روش‌های گذشته استفاده نشده‌است. به‌اختصار مهم‌ترین نوآوری‌های این مقاله عبارت‌است از:

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

۲- استفاده از نقشه‌های ویژگی از لایه‌های میانی در ترکیب با خروجی لایهٔ نهایی در مدل معلم به‌منظور استفاده به‌عنوان دانش جدیدی که به مدل دانش‌آموز منتقل می شود.

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

۲- کارهای مرتبط

روش‌های مبتنی بر شبکهٔ عصبی پیچشی[6] به‌طور معمول بر تشخیص نواحی کلیدی در استخوان‌های دست برای پیش‌بینی سن استخوان تکیه می‌کنند. بیشتر این روش‌ها بر اساس مکان‌یابی مناطق مورد علاقه[7] (ROI) دسته‌بندی را انجام می‌دهند. این روش‌های مبتنی بر تقسیم‌بندی از روش TW الهام گرفته شده‌اند که تصاویر را بر اساس ROIهای شناسایی‌شده تجزیه‌وتحلیل می‌کند؛ بااین‌حال، این روش‌ها تنها می‌توانند در بالاترین حد سه ناحیهٔ کلیدی را پیدا کنند. برخی از روش‌های ارائه‌شده مانند [۱۳-۱۷] برای تشخیص نواحی کلیدی نیازمند حاشیه‌نویسی دستی اضافی‌اند.

[1] Convelution
[2] Knowledge Distillation (KD)
[3] Lighweight Student Model
[4] Tucker Decomposition
[5] Tensors
[6] Convolution Nural Network (CNN)
[7] Region Of Interest (ROI)

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]
[DOI: 10.61186/jsdp.21.4.1]

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 نقطهٔ کلیدی برای ترازکردن رادیوگرافی‌های دست در یک فضای مختصات مشترک استفاده‌شده که میانگین خطای مطلق[1](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 به‌وسیلهٔ معماری‌های RNN و VGG-19 بررسی شده‌است. استخراج ویژگی و تشخیص سن هر ROI در [۲۲] با یک شبکهٔ VGG-13 انجام شده‌است و نتیجه‌گیری نهایی نیز به‌وسیلهٔ یک روش ترکیبی[2] بین مدل‌های VGG انجام شد که از رأی‌گیری استفاده کرده‌است. در [۲۳]، یک شبکهٔ چندمقیاسی (MMANet) ارائه شده که ترکیبی از یک شبکهٔ 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 مجموعه‌دادهٔ 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 پیشرفتهٔ 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 مرحلهٔ «پیش‌پردازش» و «آموزش و پیش‌بینی» مدل است. در مرحلهٔ نخست نواحی دلخواه ROI استخراج می‌شوند. در مرحلهٔ دوم یک مدل مبتنی بر چکانش دانش از شبکهٔ عمیق معلم به شبکهٔ سبک‌وزن دانش‌آموز، برای آموزش و پیش‌بینی مدل معرفی شده‌است. در بخش بعدی هرکدام 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 دودویی‌کردن تصویر، آستانه‌گذاری و لبه‌یابی ناحیهٔ 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 شبکهٔ عصبی پیچشی، یک تقسیم‌بندی بر روی دست انجام شده‌است؛ درنتیجه یک‌سری ROI کامل خودکار با توجه به هندسهٔ 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 قرارداده‌است.

به‌منظور جداسازی نواحی موردنظر، ابتدا مختصات پیکسل‌های مرزی دست ذخیره می‌شود. به‌وسیلهٔ 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 ناحیهٔ مچ است (ناحیه ۱) که به طور کامل خودکار قابل استخراج است. در بخش بعد برای استخراج نواحی دو تا شش نیاز به پیداکردن مختصات نواحی مربوط به انگشت‌هاست؛ برای این منظور از الگوریتم پوش محدب[3] در جهت پیداکردن مختصات انگشت‌ها استفاده شده‌است

خروجی این الگوریتم در شکل (۱) نشان داده شده‌است. درواقع 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 محاسبهٔ مختصات پیکسل‌های مرزی، عرض انگشت‌ها و مختصات نقاط مربوط به سرانگشت‌ها انجام می‌شود. به این صورت که بین دو نقطهٔ 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.

[1] Mean Absolute Error(MAE)
[2] Ensemble
[3] Convex hull

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]
[DOI: 10.61186/jsdp.21.4.1]

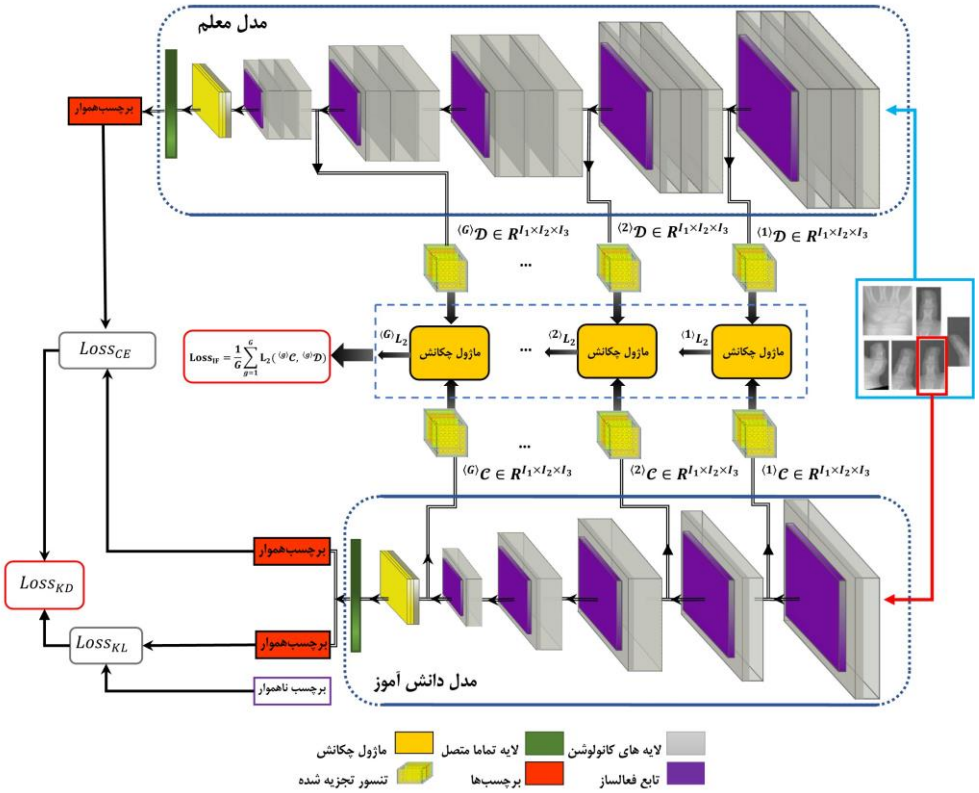

(شکل-۱): معماری کلی مدل چکانش دانش ارائه‌شده

(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 ناحیهٔ استخراج‌شده از تصاویر رادیولوژی در بخش پیش‌پردازش آموزش داده شده‌است. در کنار آن مدل دانش‌آموز سعی دارد با تقلید از دانش معلم که به دو شکل پاسخ‌محور و مبتنی بر ویژگی به دانش‌آموز چکانده می‌شود و همچنین دانش خود که با استفاده از بررسی تنها یک ناحیه از نواحی استخراج‌شده به‌دست آورده‌است، سن استخوانی را تشخیص دهد. خروجی مدل شبکهٔ عصبی دانش‌آموز به‌کار رفته به صورت منطق رگرسیون است که به‌وسیلهٔ یک لایهٔ Softmax تبدیل به خروجی برچسب طبقه‌ها می‌شود. در نتیجه خروجی نهایی تنها به‌صورت عددهایی است که برچسب طبقه جاری را نشان می‌دهد. درکل در روش پیشنهادی، تابع محاسبهٔ خطای کلی $\text{Loss}_{\text{Total}}$ به‌صورت زیر تعریف می‌شود:

$$\text{Loss}_{\text{Total}} = \alpha(\text{Loss}_{KD}) \pm (1-\alpha)(\text{Loss}_{IF}) \quad (۱)$$

در این رابطه Loss_{KD} به دانش پاسخ‌محور اشاره دارد؛ همچنین خطای Loss_{IF} به دانش موجود بین نقشهٔ ویژگی‌های لایه‌های میانی در هر دو مدل معلم و دانش‌آموز اشاره دارد که محاسبهٔ این دو تابع به‌ترتیب در بخش‌های ۳-۲-۱ و ۳-۲-۲ تشریح می‌شوند.

در این مقاله، مدل چکانش دانش همراه با یادگیری مشترک دو شبکهٔ معلم و دانش‌آموز برای طراحی یک طبقه‌بندی سبک‌وزن به‌کار گرفته شده‌است. مطابق شکل (۱)، دو مدل معلم و دانش‌آموز وجود دارند که از رویکرد یادگیری مشترک برای چکانش دانش معلم در لایهٔ پاسخ همراه با دانش معلم در نقشه‌های ویژگی لایه‌های میانی استفاده شده‌است. با توجه به شکل، مدل KD همراه با یادگیری مشترک برای طراحی یک طبقه‌بندی سبک‌وزن به‌کار گرفته شد.

۳-۲-۱- چکانش پاسخ‌محور

چهارچوب مدل‌های چکانش دانش مبتنی بر دو شبکهٔ عصبی عمیق با نام‌های شبکهٔ معلم و شبکهٔ دانش‌آموز هستند. مدل معلم از طریق ایجاد برچسب‌های هموار در لایهٔ آخر، دانش خود را به مدل دانش‌آموز انتقال می‌دهد و زمینهٔ یادگیری دانش‌آموز را فراهم می‌سازد. هدفِ بهینه‌سازی چکانش دانش، به‌کمینه‌رساندن فاصلهٔ بین خروجی دانش‌آموزان و پیش‌بینی معلم و همچنین فاصلهٔ بین خروجی و برچسب واقعی است که از طریق کمینه‌سازی تابع خطای زیر امکان‌پذیر است:

$$\text{Loss}_{\text{KD}} = \beta(\text{Loss}_{\text{KL}}) \pm (1-\beta)(\text{Loss}_{\text{CE}}) \quad (۲)$$

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

که ضریب β نشان‌دهندهٔ وزن استفاده‌شده برای متعادل‌کردن خطای مبتنی بر برچسب‌های نرم و سخت است. Loss_{KL} به روش Kullback-Leibler اشاره دارد که فاصلهٔ 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.

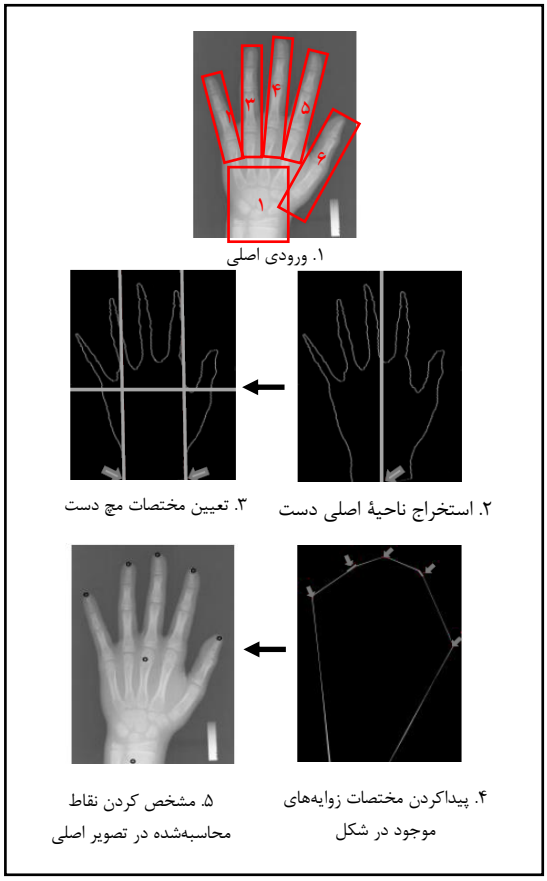

(شکل-۲): مراحل جداسازی مناطق مورد نظر (ROIها)
(Figure-2): Separation steps of regions (ROIs)

تابع Loss_{KL} به صورت زیر اندازه‌گیری می‌شود:

$$\mathrm{Loss}_{\mathrm{KL}} = \frac{1}{\mathrm{N}}\sum_{i=1}^{N}\mathcal{L}_{KL}\left(P^{(i)}(K_{Di},T),\mathrm{P}^{(i)}(K_{Si},T)\right) \quad (۳)$$

$$\mathcal{L}_{KL}\left(P(K_{Di},T),\mathrm{P}(K_{Si},T)\right) = \sum_{i}-\mathrm{P}^{(i)}(K_{Di},T)\log\mathrm{P}^{(i)}(K_{Si},T) \quad (۴)$$

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

$$\mathrm{Loss}_{\mathrm{CE}} = \frac{1}{N}\sum_{i=1}^{N}\mathcal{L}_{CE}\left(\mathrm{P}^{(i)}(K_{Si},T),\mathrm{Y}\right) \quad (۵)$$

$$\mathcal{L}_{CE}\left(\mathrm{Y},\mathrm{P}(K_{Si},T)\right) = \sum_{i}-\mathrm{Y}_i\log\mathrm{P}^{(i)}(K_{Si},T) \quad (۶)$$

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

$$\mathrm{P}(K_i,T) = \frac{\exp\left(K_i/T\right)}{\sum_j \exp\left(K_j/T\right)} \quad (۷)$$

در اینجا K نمونهٔ 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 درجهٔ نرم‌شدن خروجی مدل‌هاست.

۳-۲-۲- چکانش ویژگی‌محور

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 لایهٔ 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 به‌وسیلهٔ 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. فاصلهٔ 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 لایهٔ بعدی انتقال پیدا می‌کند. اگر خروجی هر لایه تابعی از $Y = F(WK \pm b)$ باشد، آن‌گاه خروجی لایهٔ پایانی برای هر کدام از مدل‌ها برابر با معادلهٔ (۸) است:

$$Y^{\langle X\rangle} = {}^{\langle X\rangle}F\left({}^{\langle X\rangle}W\ {}^{\langle X-1\rangle}F\left({}^{\langle X-1\rangle}W\left(\ldots\left({}^{1}F\left({}^{1}WK \pm {}^{1}b\right)\right)\ldots\right) \pm {}^{\langle X-1\rangle}b\right) \pm {}^{\langle X\rangle}b\right) \quad (۸)$$

که $^{x}\mathrm{b}$ و $^{x}\mathrm{W}$ به‌ترتیب به بایاس و تنسور وزن لایهٔ x ام اشاره دارند. ساختار تنسورها به‌دلیل ابعاد بالا همراه با پیچیدگی و دشواری در محاسبهٔ اختلاف بین تنسورها هستند. به همین دلیل مدل پیشنهادی در تلاش است که با استفاده از تجزیهٔ تاکر این پیچیدگی را خرد کند و یک

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]
[DOI: 10.61186/jsdp.21.4.1]

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

$$
\begin{aligned}
{}^{\langle x\rangle}W \cong {}^{\langle x\rangle}\mathcal{Q} \times_1 {}^{\langle x\rangle}M^{(1)} \times_2 {}^{\langle x\rangle}M^{(2)} \dots \\
\times_N {}^{\langle x\rangle}M^{(N)} =
\end{aligned}
\tag{۹}
$$

$$
[\![{}^{\langle x\rangle}\mathcal{Q}, {}^{\langle x\rangle}M^{(1)}, {}^{\langle x\rangle}M^{(2)}, \dots, {}^{\langle x\rangle}M^{(N)}]\!], 1 \le X
$$

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

$$
{}^{\langle x\rangle}\mathrm{W}_{r_1,\dots,r_N} \cong \sum_{i_1=1}^{I_1} \sum_{i_2=1}^{I_2} \dots \sum_{i_N=1}^{I_N} {}^{\langle x\rangle}q_{r_1,\dots,r_N} \tag{۱۰}
$$

$$
({}^{\langle x\rangle}M^{(1)}_{(X_1,i_1)}, {}^{\langle x\rangle}M^{(2)}_{(X_2,i_2)} \dots {}^{\langle x\rangle}M^{(N)}_{(X_N,i_N)})
$$

$$
\begin{aligned}
Y^{\langle X\rangle} = {}^{\langle X\rangle}F([\![{}^{\langle X\rangle}\mathcal{Q}, {}^{\langle X\rangle}M^{(1)}, {}^{\langle X\rangle}M^{(2)}, \dots, {}^{\langle X\rangle}M^{(N)}]\!] \\
\times {}^{\langle X-1\rangle}F([\![{}^{\langle X-1\rangle}\mathcal{Q}, {}^{\langle X-1\rangle}M^{(1)}, {}^{\langle X-1\rangle}M^{(2)}, \dots, {}^{\langle X-1\rangle}M^{(N)}]\!] \\
\times (\dots ({}^{1}F([\![{}^{\langle 1\rangle}\mathcal{Q}, {}^{\langle 1\rangle}M^{(1)}, {}^{\langle 1\rangle}M^{(2)}, \dots, {}^{\langle 1\rangle}M^{(N)}]\!] K \\
\pm {}^{\langle 1\rangle}b)) \dots) \pm {}^{\langle X-1\rangle}b) \pm {}^{\langle X\rangle}b)
\end{aligned}
\tag{۱۱}
$$

در ادامه اگر ${}^{\langle g\rangle}\mathcal{J}$ به تنسور نگاشت ویژگی لایهٔ 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:

$$
\begin{aligned}
{}^{\langle g\rangle}\mathcal{J} \\
\cong {}^{\langle g\rangle}\mathcal{C} \times_1 {}^{\langle g\rangle}V^{(1)} \times_2 {}^{\langle g\rangle}V^{(2)} \times_1 \dots \times_1 {}^{\langle g\rangle}V^{(N)} \\
= [\![{}^{\langle g\rangle}\mathcal{C}, {}^{\langle g\rangle}V^{(1)}, {}^{\langle g\rangle}V^{(2)}, \dots, {}^{\langle g\rangle}V^{(N)}]\!]
\end{aligned}
\tag{۱۲}
$$

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

$$
{}^{\langle g\rangle}\mathcal{J}_{k_1,\dots,k_N} \cong \sum_{j=1}^{I_1} \sum_{j_2=1}^{I_2} \dots \sum_{j_N=1}^{I_N} {}^{\langle g\rangle}\mathcal{C}_{k_1,\dots,k_N} \tag{۱۳}
$$

$$
\left({}^{\langle g\rangle}V^{(1)}_{(k_1,j_1)}, {}^{\langle g\rangle}V^{(2)}_{(k_2,j_2)} \dots {}^{\langle g\rangle}V^{(N)}_{(k_N,j_N)} \right)
$$

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

$$
\begin{aligned}
H^{\langle Z\rangle} \\
= {}^{\langle Z\rangle}F([\![{}^{\langle Z\rangle}\mathcal{L}, {}^{\langle Z\rangle}A^{(1)}, {}^{\langle Z\rangle}A^{(2)}, \dots, {}^{\langle Z\rangle}A^{(N)}]\!] \\
\times (\dots ({}^{1}F([\![{}^{\langle 1\rangle}\mathcal{L}, {}^{\langle 1\rangle}A^{(1)}, {}^{\langle 1\rangle}A^{(2)}, \dots, {}^{\langle 1\rangle}A^{(N)}]\!] K \\
\pm {}^{\langle 1\rangle}b)) \dots) \pm {}^{\langle Z-1\rangle}b) \pm {}^{\langle Z\rangle}b)
\end{aligned}
\tag{۱۴}
$$

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

$$
\begin{aligned}
{}^{\langle g\rangle}\mathcal{K} \\
\cong {}^{\langle g\rangle}\mathcal{D} \times_1 {}^{\langle g\rangle}S^{(1)} \times_2 {}^{\langle g\rangle}S^{(2)} \times_1 \dots \\
\times_1 {}^{\langle g\rangle}S^{(N)} \\
= [\![{}^{\langle g\rangle}\mathcal{D}, {}^{\langle g\rangle}S^{(1)}, {}^{\langle g\rangle}S^{(2)}, \dots, {}^{\langle g\rangle}S^{(N)}]\!]
\end{aligned}
\tag{۱۵}
$$

که ${}^{\langle g\rangle}\mathcal{K}$ تنسور نگاشت ویژگی لایهٔ 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 هستهٔ حاصل از تجزیه نگاشت ویژگی و ماتریس عامل در مرتبهٔ j ام اشاره دارند. هر نمونه از این معادله به فرم زیر قابل بازنویسی است:

$$
\begin{aligned}
{}^{\langle g\rangle}\mathcal{K}_{k_1,\dots,k_N} \cong \sum_{r=1}^{I_1} \sum_{r_2=1}^{I_2} \dots \sum_{r_N=1}^{I_N} {}^{\langle g\rangle}\mathcal{D}_{k_1,\dots,k_N} (\\
{}^{\langle g\rangle}S^{(1)}_{(k_1,r_1)}, {}^{\langle g\rangle}S^{(2)}_{(k_2,r_2)} \dots {}^{\langle g\rangle}S^{(N)}_{(k_N,r_N)})
\end{aligned}
\tag{۱۶}
$$

پس از استخراج تنسورهای هستهٔ 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 $\mathrm{Loss_{IF}}$ مبتنی بر نرم اقلیدوسی $\mathrm{L_2}$ تعریف شده‌است که با استفاده از ضریب α بر عملکرد مدل دانش‌آموز نظارت دارد. به طور کلی، خطای این روش را می‌توان به صورت معادلهٔ (۱۷) فرموله کرد:

۴- نتایج

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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

۴-۱- مجموعه‌داده

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

$$Accuracy = \frac{TP \pm TN}{TP \pm FP \pm FN \pm TN} \quad (۱۸)$$

$$Precision = \frac{TP}{TP \pm FP} \quad (۱۹)$$

$$Recall = \frac{TP}{TP \pm FN} \quad (۲۰)$$

$$F1 = \frac{2(Recall * Precision)}{(Recall \pm Precision)} \quad (۲۱)$$

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - x_i| \quad (۲۲)$$

۴-۲- ارزیابی مدل‌های دانش‌آموز و معلم

در این مقاله تعداد شش ناحیهٔ مختلف از هر تصویر موجود در پایگاه داده‌ای اطلس استخراج شده‌است. این نواحی با اسم ROI نام‌گذاری شده‌اند و شامل ناحیهٔ مچ ROI1 و انگشتان ROI2-ROI6 است. در گام نخست مدل پیشرفتهٔ معلم با استفاده از تمام نواحی یک تا شش آموزش داده می‌شود. در گام دوم شش مدل مختلف دانش‌آموز با یک ناحیه از این نواحی استخراج شده، تحت نظارت معلم خود آموزش داده می‌شوند. درحقیقت برای مقایسهٔ عملکرد مدل‌های مختلف دانش‌آموز با استفاده از این نواحی مختلف تعداد شش مدل دانش‌آموز به‌صورت مستقل آموزش داده شد. هر مدل دانش‌آموز به‌طور مستقل با استفاده از دانش دریافت‌شده از مدل عمیق معلم و یک ناحیهٔ ROI متفاوت آموزش دید. جدول (۱) نتایج به‌دست‌آمده از شش مدل دانش‌آموز و مدل معلم را نمایش می‌دهد. این جدول عملکرد مدل معلم را با شش مدل دانش‌آموز از نظر دقت، صحت، بازیافت، معیار F1 و میانگین خطای مطلق مقایسه می‌کند که مدل دانش‌آموز در هر یک از شش ناحیه به طور متوسط به دقت ۸۷/۸ و میانگین خطای ۰۶۲ /۰ هم‌گرا شده‌است. در کنار مدل‌های مختلف و سبک‌وزن دانش‌آموز، مدل پیشرفته و عمیق معلم قرار دارد که با استفاده از تمام نواحی آموزش دیده‌است و به دقت ۰/۹۷و میانگین خطای ۰/۰۳۶ هم‌گرا شده‌است. مقایسهٔ این نتایج نشان می‌دهند که مدل دانش‌آموز کمابیش به‌خوبی مدل معلم خود عمل می‌کند و توانسته با بررسی تنها یک ناحیه و استفاده از دانش معلم خود تشخیصی نزدیک به آن داشته باشد؛ درنهایت از میان مدل‌های دانش‌آموز مدل شش که به بیشترین دقت دست یافته بود انتخاب شد.

(جدول-۱): مقایسهٔ عملکرد شش مدل دانش‌آموز و مدل معلم
(Table-1): Performance comparison of six student models and teacher models

مدل	ناحیه	دقت	صحت	بازیافت	معیار F1-	میانگین خطای مطلق
دانش‌آموز ۱	ROI #1	۰/۸۷	۰/۵۳	۰/۵۶	۰/۸۳	۰/۰۸
دانش‌آموز ۲	ROI #2	۰/۸۳	۰/۵۵	۰/۵۰	۰/۹۰	۰/۰۳
دانش‌آموز ۳	ROI #3	۰/۹۳	۰/۶۴	۰/۶۵	۰/۹۲	۰/۰۹
دانش‌آموز ۴	ROI #4	۰/۸۴	۰/۵۴	۰/۵۵	۰/۸۰	۰/۰۲
دانش‌آموز ۵	ROI #5	۰/۸۶	۰/۵۵	۰/۵۶	۰/۸۶	۰/۰۴
دانش‌آموز 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

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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]
[DOI: 10.61186/jsdp.21.4.1]

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

(جدول-۲): مقایسهٔ مدل‌های دانش‌آموز-۶ و معلم از نظر پیچیدگی و اندازهٔ 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)	حافظهٔ 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 داده‌شده‌است. در این ماتریس‌ها مجموعهٔ مثبت صحیح[1] (TP) به نمونه‌هایی اشاره دارد که به‌درستی 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.

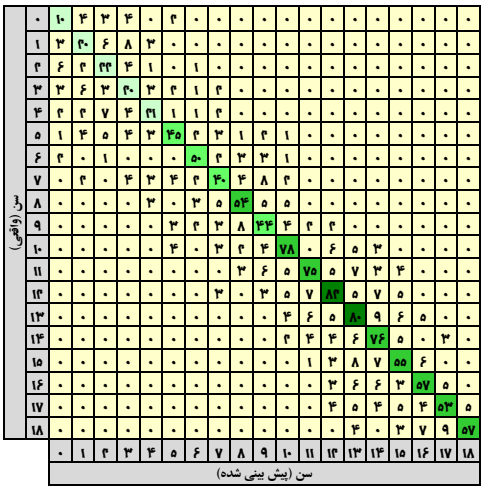

(شکل-۳): ماتریس درهم‌ریختگی مدل معلم

(Figure-3): The confusion matrix of the teacher's model

با مقایسهٔ 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 طبقهٔ موجود در مجموعه‌داده بیشتر تعداد نمونه‌ها را به‌درستی دسته‌بندی کرده‌است؛ همچنین تمام نمونه‌های که به اشتباه دسته‌بندی شده‌اند به دستهٔ اصلی خود به طور کامل نزدیک‌اند؛ برای مثال برای دستهٔ شانزده سال، تعداد کمی از نمونه‌ها به‌اشتباه هفده یا پانزده سال دسته‌بندی شده‌اند.

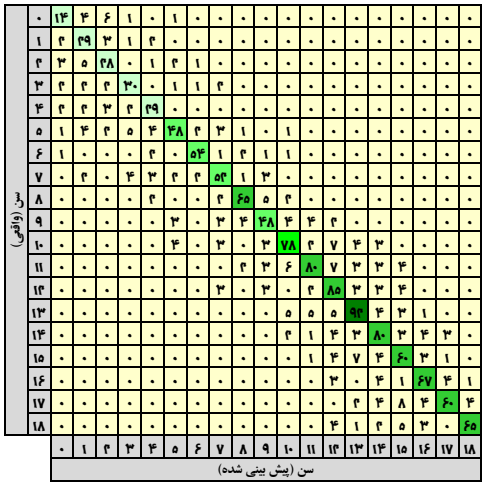

(شکل-۴): ماتریس درهم‌ریختگی مدل دانش‌آموز

(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 می‌کنند. 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 به‌دست آمده‌است. این مقادیر نشان می‌دهند که مدل دانش‌آموز به‌خوبی سن را تشخیص می‌دهد؛ علاوه‌بر این، مدل دانش‌آموز ارائه‌شده با یک ناحیهٔ ROI و پیچیدگی بسیار کمتر از معلم کمابیش همان عملکرد مدل معلم را تکرار می‌کند.

در ادامه به‌منظور نمایش گرافیکی مقایسهٔ 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.

[1] True Positive

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

(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	۰/۸۳ ± 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	۰/۷۳ ± 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 دانش‌آموز-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	۰/۰۹
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	۰/۰۱۰۱
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	۰/۶۳ ± 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	۰/۵۸ ± 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	۰/۶۹ ± ۰/۴۰	۰/۷۸ ± ۰/۷۴	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	۰/۰۷۹
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 ارائه‌شده 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 شبکهٔ دانش‌آموز بر اساس ویژگی‌های ایجاد شده توسط لایهٔ پایانی شبکهٔ معلم آموزش داده می‌شود و در اصطلاح روش دانش پاسخ‌محور نام دارد.

۲. FitNet : این روش نخستین مطالعهٔ چکانش دانش مبتنی بر ویژگی است. در این مدل شبکهٔ دانش‌آموز براساس نقشه‌های ویژگی لایه‌های میانی شبکهٔ معلم آموزش داده می‌شود.

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

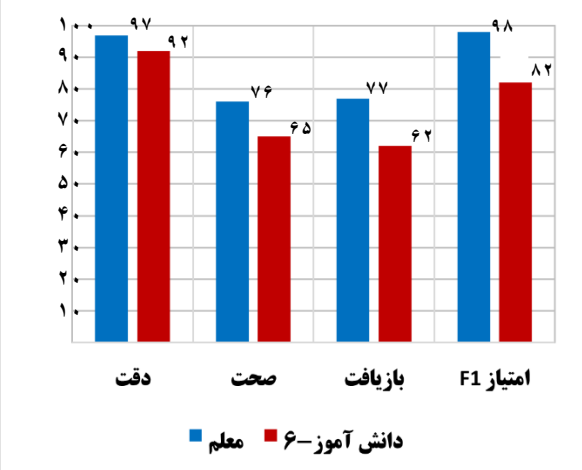

(شکل-۵): نمودار میله‌ای عملکرد مدل دانش آموز-۶ و مدل معلم با چهار معیار ارزیابی دقت، صحت، بازیافت و امتیاز F1

(Figure-5): Comparing performance of Student-6 and teacher model by Accuracy, Precision, Recall, and F1-measure

روش‌های ارائه‌شده در جدول (۵) بر روی مجموعه‌دادهٔ اطلس دست دیجیتال پیاده‌سازی شده‌اند. خروجی آن‌ها با مدل چکانش دانش پیشنهادی ما مقایسه شده‌است. بر این اساس، دانش‌آموز 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 نشان‌دهندهٔ برتری مدل پیشنهادی برای طبقه‌بندی نسبت به مدل‌های دیگر است.

برای اثبات برتری و تصادفی‌نبودن نتایج روش ارائه‌شده نسبت به سه روش دیگر از طریق آزمون t یک ارزیابی انجام شده و نتایج این آزمون در جدول (۶) نشان‌داده‌شده‌است. آزمون t یک آمار استنباطی است که برای

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

تعیین اینکه آیا تفاوت معنی‌داری بین میانگین دو گروه و نحوهٔ 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	۰/۷۴ ± ۰/۷۸	۰/۵۹ ± ۰/۹۰	۰/۵۸ ± ۰/۴۷	۰/۷۸ ± ۰/۱۷
FitNet	۰/۷۸ ± ۰/۹۹	۰/۵۸ ± ۰/۸۵	۰/۵۷ ± ۰/۰۸	۰/۷۷ ± ۰/۹۰
T-KD	۰/۸۹ ± ۰/۰۸	۰/۶۱ ± ۰/۷۰	۰/۶۰ ± ۰/۴۳	۰/۸۹ ± ۰/۸۴
مدل پیشنهادی	**۰/۹۷ ± ۰/۰۸**	**۰/۷۶ ± ۰/۸۲**	**۰/۷۶ ± ۰/۰۶**	**۰/۹۸ ± ۰/۰۰۰۲**

۵- مقایسهٔ 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 ردهٔ سنی و نژاد خاص آزمایش شده‌اند که به‌دلیل عدم دسترسی به اطلاعات آن‌ها این نتایج قابل مقایسه و تکرار نیستند. از بین روش‌های ارائه‌شده تعداد کمی روش وجود دارد که بر روی مجموعه‌داده‌ای 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): مقایسهٔ 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	$T_{Statistic}$	$T_{Critical}$	p-Value
دقت	O-KD	- ۵/۸۲۳۷	۵/۴۵۲۲	۰/۰۰۵۴۲
	FitNet	- ۰/۰۰۸۷	۱/۱۳۵۴	۰/۰۱۷۳
	T-KD	- ۲/۱۲۳	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	۰/۰۳۷

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

(جدول-۷): مقایسهٔ نتایج مدل پیشنهادی با سایر روش‌های ارائه‌شده بر روی مجموعه‌دادهٔ 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 [۲۰]	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**

در مقالهٔ 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 اشاره‌شده از هیچ الگوریتم ROI به منظور استخراج نقاط مهم استفاده نکرده‌است؛ لذا نمی‌تواند روش مطمعنی برای تشخیص سن استخوانی باشد؛ همچنین در مقالهٔ 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 دادهٔ 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 شبکهٔ معلم به شبکهٔ دانش‌آموز برای ارزیابی سن استخوان طراحی و آزمایش شد. این روش به طور کامل خودکار بر

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

روی مجموعه‌داده‌های DHA شامل ۱۴۰۰ تصویر مچ 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 ناحیهٔ 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 شبکهٔ معلم با ساختار پیشرفتهٔ CNN بر روند یادگیری یک مدل دانش‌آموز ساخته‌شده از معماری سادهٔ CNN نظارت می‌کند که دانش‌آموز را به تقلید از رفتار مدل معلم هدایت می‌کند. مدل دانش‌آموز با استفاده از دانش منتقل‌شدهٔ معلم که حاوی داده‌هایی از نقشه‌های ویژگی لایه‌های میانی معلم و همچنین آخرین لایهٔ خروجی آن است، آموزش داده می‌شود. با بهره‌گیری از این بینش مفید، مدل دانش‌آموز می‌تواند شیوهٔ معلم را با شباهت زیاد تقلید کند و دانش‌آموز را به‌جای معلم دقیق‌تر کند؛ درحالی‌که معماری را به‌مراتب پیچیده‌تر نگه می‌دارد. در قسمت نتایج و ارزیابی مدل، آزمون‌های مختلفی از جمله آزمون‌های شبکهٔ ازپیش آموزش‌دیده انجام می‌شود. عملکرد بهتر نظام طراحی‌شده در مقایسه با سایر روش‌ها به‌وسیلهٔ 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 قابل‌استفاده 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].

۷-مراجع 7-References

[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. Tekın 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 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 –

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

[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.2021.309512.۸

[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. Côco, 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, DLMIA 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.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]

2354001, 2023/02/01 2022, doi: 10.1142/S0218001423540014.

[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. khalooei, 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 رایانامهٔ ایشان عبارت‌است 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.

شانی رایانامهٔ ایشان عبارت‌است از:
h.sarabi@stu.razi.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-12]

[DOI: 10.61186/jsdp.21.4.1]