

یک روش مبتنی بر یادگیری چنددقتی برای تطبيق تصاویر پزشکی چندکیفیتی

سیده سمیه آل حجت خسمخی و محمدرضا کیوانپور

تصویربرداری یا به عبارتی تطبيق چندکیفیتی^۱، از آنجایی که خواص فیزیکی متفاوتی، اساس کار روش‌های تصویربرداری قرار گرفته و نیز تمایزهایی که به دلیل تفاوت موقعیت مکانی بیمار و تغییر پارامترهای تصویربرداری ایجاد می‌شود، فرایند تطبيق کار دشواری بوده و بنابراین روش‌های مختلفی برای ساده کردن مسأله ارائه شده است. از بین معیارهای مشابهت فراوانی که برای تطبيق تصاویر چندکیفیتی وجود دارد، اطلاعات متقابل [۱] یکی از معیارهای مشابهت مبتنی بر شدت است که خودکار بوده و نیازی به تعریف سطوح و یا نقاط ویژه توسط کاربر ندارد، اما از آنجایی که نقاط متناظر در تصاویری که با کیفیت‌های متفاوت به دست آمده‌اند دارای شدت‌های متفاوتی هستند، در نتیجه محاسبه مقدار بیشینه مشابهت که با تخمین هیستوگرام متصل بین دو تصویر به دست می‌آید، زمان محاسبات را به طور قابل ملاحظه‌ای افزایش می‌دهد. این مسأله یکی از معایب این روش به ویژه در مورد تصاویر با حجم بالا است [۲]. ملاحظه می‌گردد عمومی‌ترین معیار مشابهت در زمینه تطبيق چندکیفیتی، نمی‌تواند پاسخ‌گوی مناسبی باشد.

با بررسی‌های بیشتر، این نتیجه حاصل می‌گردد که به طور کلی روش‌های تطبيق مبتنی بر شدت به بهینه‌سازی سراسری یا محلی معیار مشابهت بین تصاویر نیاز دارند اما روش‌های سراسری وقت‌گیر بوده و از دیگر سو، روش‌های محلی زمانی که میزان بی‌نظمی در تصاویر زیاد باشد نمی‌تواند به مقدار بهینه‌ای برسد [۳]. علاوه بر این اطلاعات متقابل و سایر معیارهای مشابهت مبتنی بر هیستوگرام شدت، پیکسل به پیکسل و با توجه به روابط بین پیکسل‌های متناظر محاسبه می‌شوند و پیکسل‌ها را با توجه به همسایگی‌های آن در نظر نمی‌گیرند و در نتیجه، بسیاری از اطلاعات مکانی سراسری در تصویر نادیده گرفته می‌شود. همچنین زمانی که شدت پیکسل‌های همسایه در دو تصویر ورودی و مرجع به طور تصادفی تغییر کند، این روش‌ها قادر نخواهند بود مقدار شدت پیکسل را تغییر دهند در حالی که اگر هر پیکسل با همسایگی‌های آن در نظر گرفته شود، شامل اطلاعات بیشتری نسبت به یک پیکسل است. برای غلبه بر مشکلات پیش‌گفته، روش‌های مبتنی بر یادگیری ارائه شده که در [۴] به طور جامع مورد تحلیل و بررسی قرار گرفته است. در این روش‌ها به جای به کارگیری یک معیار مشابهت ثابت که میزان مشابهت تصاویر ورودی و مرجع را اندازه می‌گیرد، یک تابع مشابهت از روی یک مجموعه تصاویر از پیش تطبيق یافته، آموزش داده می‌شود. فرایند آموزش با استفاده از یک مدل آموزشی تا زمانی تکرار می‌شود که تصویر ورودی و تصویر مرجع به بالاترین میزان مشابهت برسند.

مقایسه نتایج و عملکرد الگوریتم‌های مختلف تطبيق تصویر، انگیزه اصلی این پژوهش جهت طراحی و پیاده‌سازی الگوریتمی ترکیبی بوده که ضمن برخورداری از سرعت قابل قبول، نتایج دقیقی در برابر تصاویر

چکیده: هدف اصلی در روش‌های مختلف تطبيق تصویر، پیدا کردن پارامترهای تبدیل برای نگاشت دقیق یک تصویر بر روی مختصات تصویر دیگر است. در پزشکی، برقراری ارتباط دقیق میان داده‌های تصاویر پزشکی در کاربردهایی نظیر تشخیص و درمان از اهمیت بسیاری برخوردار است و بر این اساس، روش‌های متعددی برای تطبيق تصاویر ارائه شده است. مقایسه نتایج الگوریتم‌های مختلف، انگیزه اصلی این پژوهش گردیده تا بتوان الگوریتم جدید ترکیبی ارائه و پیاده‌سازی نمود که از دقت بالایی برای تطبيق تصاویر چندکیفیتی برخوردار باشد. خودکارسازی فرایند تطبيق با بهره‌گیری از رویکرد یادگیری ماشین، نوآوری مقاله حاضر نسبت به روش‌های پیشین به شمار می‌رود. به این منظور، روش پیشنهادی به نام یادگیری چنددقتی از ترکیب یک روش تجزیه چنددقتی و یک شبکه عصبی سلسله مراتبی بهره می‌گیرد که با استفاده از ویژگی‌های سراسری تصویر، پارامترهای تبدیل را یاد گرفته و از پارامترهای تبدیل به دست آمده از فرایند یادگیری، برای تطبيق تصاویر استفاده می‌کند. روش پیشنهادی بر روی پایگاه داده تصاویر پزشکی دانشگاه و اندریبلت پیاده‌سازی و آزمون شده و نتایج به دست آمده دقت قابل قبولی را برای روش پیشنهادی در مقایسه با سایر روش‌ها نشان می‌دهد.

کلید واژه: تطبيق تصویر، تطبيق تصویر چندکیفیتی، تصویربرداری پزشکی، درخت دوتایی تبدیل موجک مختلط.

۱- مقدمه

امروزه تصاویر پزشکی به طور فراگیر در مراقبت‌ها و تحقیقات پزشکی مورد استفاده قرار می‌گیرد. یافتن ارتباط دقیق میان اطلاعات موجود در تصاویر مختلف از اهمیت بسیاری در کاربردهای بالینی (معاینه، تشخیص و درمان) و همچنین علوم پایه پزشکی برخوردار است. تصاویر حاصل از سیستم‌های تصویربرداری پزشکی مختلف به تنهایی قادر به بیان خصوصیات کامل ساختاری و کارکردی بافت نیستند، بنابراین روش‌هایی که بتوانند اطلاعات موجود در تصاویر مختلف را ترکیب نمایند مورد توجه متخصصان قرار گرفته است. یک مرحله پیش‌پردازش کلیدی و اساسی برای ترکیب تصاویر، تطبيق^۱ نقاط مختلف تصاویر است. فرایند تطبيق، ویژگی‌های مختلف در تصاویر متفاوت را بر هم منطبق می‌کند به طوری که امکان ردگیری تغییرات اندازه یا شدت را در طول زمان یا افراد متعدد فراهم می‌سازد. در تطبيق تصاویر به دست آمده از چند سیستم

این مقاله در تاریخ ۲۹ شهریور ماه ۱۳۹۲ دریافت و در تاریخ ۱۹ فروردین ماه ۱۳۹۳ بازنگری شد.

سیده سمیه آل حجت خسمخی، گروه مهندسی کامپیوتر، دانشکده مهندسی برق-رایانه و فناوری اطلاعات، دانشگاه آزاد اسلامی، واحد قزوین، قزوین، ایران، (email: s.s.alehojat@gmail.com)

محمدرضا کیوانپور، گروه مهندسی کامپیوتر، دانشگاه الزهراء، تهران، ایران، (email: keyvanpour@alzahra.ac.ir)

و نیازی به داده‌های آموزشی ندارد. بردار ویژه لاپلاسین، یک گراف همسایگی می‌سازد که نمایش ساختاری تصویر را از روی نقاط داده‌ای که روی گراف همسایگی قرار گرفته‌اند تخمین می‌زند.

اولین روش برای یادگیری معیار مشابهت در تطبیق تصاویر پزشکی در [۱۲] مطرح شده است. Leventon و همکاران روشی برای تخمین توزیع شدت متصل از زوج تصاویر تطبیق‌یافته ارائه نمودند و سپس از روش بیشینه همسایگی برای تعیین معیار تنظیم برای زوج تصویر جدید استفاده کردند. در [۱۳] از همگرایی kullback - leibler برای تطبیق تصویر با استفاده از توزیع شدت متصل آموزش‌دیده و توزیع شدت تصاویر تست استفاده شده است.

در [۱۴] نیز یک معیار مبتنی بر یادگیری ارائه شده که مشابهت آماری بین هیستوگرام توزیع شدت مورد انتظار و مشاهده‌شده را اندازه‌گیری می‌کند. در این روش، نیاز به برچسب‌گذاری داده‌های آموزشی نیست بلکه یک نگاشت هیستوگرام غیر خطی، به طور تکراری، پراکندگی شدت بین داده مشاهده‌شده و داده آموزشی را اندازه‌گیری می‌کند. در [۱۵] با به کارگیری اطلاعات ساختاری استخراج‌شده از همبستگی بین پیکسل‌های همسایگی تصویر ورودی و تصویر مرجع حول یک مقدار شدت مورد نظر، معیار مشابهت آموزش داده می‌شود.

همان طور که ملاحظه می‌گردد روش‌های مبتنی بر یادگیری ارائه‌شده اگرچه از یک مدل یادگیری استفاده کرده‌اند اما پارامترهای تبدیل را یاد نمی‌گیرند بلکه سیستمی می‌سازند که با استفاده از یک زوج مختصات در تصویر مرجع، مختصات تبدیل‌یافته متناظر در تصویر ورودی به دست آید. با وجودی که روش‌های مطرح‌شده، نتایج دقیقی را برای تصاویر نویزی فراهم می‌کند اما از آنجایی که تصاویر حاصل از سیستم‌های تصویر برداری مختلف، دارای مقادیر شدت متفاوت هستند، از دو چالش عمده رنج می‌برند: زمان طولانی فرایند یادگیری و دقت پایین الگوریتم.

۳- بیان مسأله

تطبیق تصویر، روند نظیرکردن دو تصویر یا شیء به یکدیگر است که از دو منظر مختلف گرفته شده‌اند و تفاوت این تصاویر می‌تواند در زاویه ثبت آنها و یا حتی دستگاه گیرنده تصاویر باشد. در صورتی که بدانیم هر یک از تصاویر با چه تبدیلی به دیگری نگاشت می‌شود، می‌توان از اطلاعات هر دوی آنها استفاده کرد. در این مقاله، تطبیق روی تصاویر پزشکی مغز اعمال شده و از آنجایی که تمرکز مقاله حاضر روی تطبیق تصاویر به دست آمده از حسگرهای تصویربرداری مختلف است، ساختار مغز در طول فرایند تصویربرداری ثابت بوده و در نتیجه می‌توان مغز را به عنوان جسم صلب در نظر گرفت. تبدیلات سه‌بعدی یک جسم صلب شامل سه انتقال و سه چرخش (۶ درجه آزادی) است.

در فرایند تطبیق تصویر، یک تصویر به عنوان تصویر مرجع (تصویر هدف) و تصویر دیگر به عنوان تصویر شناور (ورودی) تعریف می‌شود. تصویر شناور در طول فرایند تطبیق، تبدیل داده می‌شود و به طور تکراری با تصویر مرجع مقایسه می‌شود.

یک تصویر سه‌بعدی U را می‌توان به صورت یک تابع $U: L_u \rightarrow R$ در نظر گرفت به طوری که $L_u \subseteq Z^3$ یک شبکه سه‌بعدی است و مختصات وکسل‌های U را تعریف می‌کند. یک وکسل در U ، یک سطر $(P, U(P))$ است که $P \in L_u$ مکان وکسل و $U(P) \in R$ شدت وکسل در مکان P است. اگر U یک مجموعه کامل از همه تصاویر سه‌بعدی مرجع باشد یعنی $U = \{u | u: L_u \rightarrow R\}$ ، یک ناحیه از U می‌تواند

حاصل از سیستم‌های تصویربرداری پزشکی مختلف ارائه نماید. هدف اصلی این پژوهش، خودکارسازی فرایند تطبیق تصویر با بهره‌گیری از رویکرد یادگیری ماشین است. روش پیشنهادی، ترکیبی از یک روش تجزیه چنددقتی^۱ مبتنی بر درخت دوتایی تبدیل موجک مختلط^۲ و یک شبکه عصبی سلسله‌مراتبی است که با استفاده از ویژگی‌های سراسری تصویر، پارامترهای تبدیل را از یک مجموعه تصاویر از پیش تطبیق یافته یاد می‌گیرد و در گام بعدی از پارامترهای تبدیل حاصل از یادگیری، برای تطبیق تصاویر استفاده می‌کند.

روش پیشنهادی در تطبیق تصاویر چندکیفیتی پزشکی CT و MRI سر و مغز پیاده‌سازی شده است. از آنجایی که مغز درون جمجمه ثابت و تغییر شکل محسوسی ندارد، لذا در این مقاله تبدیل جسم صلب مد نظر بوده و تصاویر مورد نظر تنها از جنبه اختلاف در جابجایی و دوران، مورد بررسی قرار می‌گیرند. نتایج بر روی پایگاه داده تصاویر پزشکی دانشگاه واندربیلت آزمون شده و نتایج به دست آمده، دقت قابل قبولی را برای روش پیشنهادی در مقایسه با سایر روش‌ها نشان می‌دهد.

مقاله حاضر در شش بخش تدوین شده است: در بخش ۲ پیشینه روش‌های مبتنی بر یادگیری مورد بررسی قرار می‌گیرد. بخش ۳ به بیان مسأله می‌پردازد و روش پیشنهادی در بخش ۴ تشریح می‌گردد. بخش ۵ پیاده‌سازی و آزمون روش ارائه‌شده را مورد تحلیل قرار می‌دهد و سرانجام بخش ۶ نتیجه‌گیری و توسعه‌های آتی روش پیشنهادی را در بر می‌گیرد.

۲- تطبیق تصویر چندکیفیتی مبتنی بر یادگیری

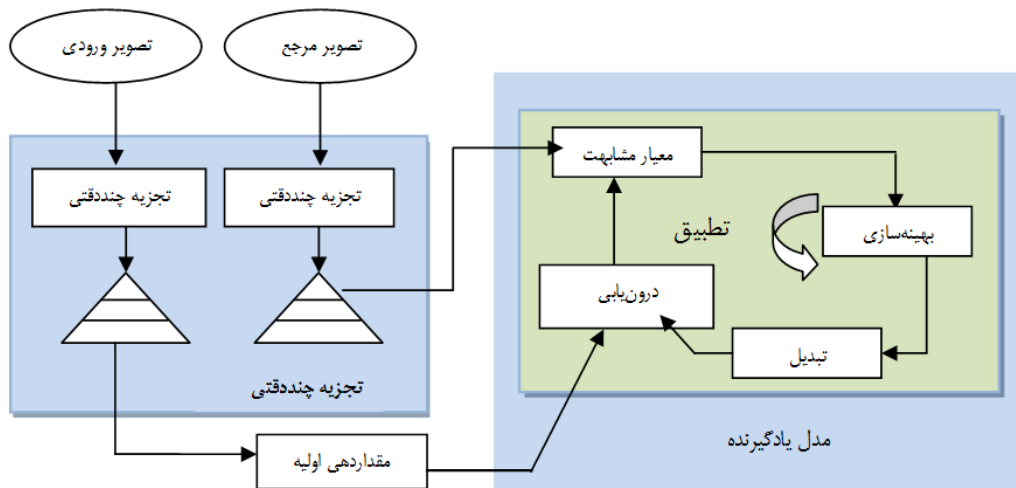
اگرچه روش‌های تطبیق تصویر می‌تواند با توجه به معیارهای متفاوتی دسته‌بندی شوند، مهم‌ترین گام در تطبیق تصویر، تعیین فضای ویژگی قبل از تطبیق است. بر طبق این معیار، کلیه روش‌های تطبیق به دو دسته مبتنی بر شدت و مبتنی بر ویژگی [۵] تقسیم می‌شوند. از آنجایی که تصاویر پزشکی، شامل اطلاعات و جزئیات قابل تمایز نمی‌باشد، استخراج نقاط مبتنی بر ویژگی دارای دقت کافی نبوده و حتی ممکن است نویز به عنوان یک ویژگی از تصویر تشخیص داده شود. از طرف دیگر روش‌های مبتنی بر شدت که از وابستگی آماری بین مقادیر سطوح خاکستری استفاده می‌کند، پیکسل‌های همسایگی را در نظر نمی‌گیرد که این امر سبب بالا رفتن زمان محاسبات می‌گردد.

تطبیق تصویر مبتنی بر یادگیری، روش تقریباً جدیدی است که برای رفع بهینه‌های سراسری و محلی روش‌های سنتی و فرار از افتادن الگوریتم در مینیمم‌های محلی ارائه شده است. روش‌های موجود به یادگیری فضای ویژگی و یا معیار مشابهت بین تصاویر می‌پردازد.

به طور مثال در [۶] و [۷] از شبکه عصبی برای استخراج یک مجموعه از نقاط کنترلی از تصاویری که باید تطبیق یابند جهت یادگیری فضای ویژگی استفاده می‌شود. کاربرد دیگر شبکه‌های عصبی در [۸] و [۹] دیده می‌شود به طوری که تطبیق با استفاده از شبکه‌های عصبی پیشرو، گاوسین-سیگموئید و توابع پایه شعاعی به دست آمده که مبتنی بر تعیین و تطابق نقاط کنترلی است. به طور مشابه، ماشین‌های بردار پشتیبان نیز برای مشخص کردن پارامترهای تبدیل غیر خطی با استفاده از تعدادی نقاط نشانه بین دو تصویر به کار برده شده‌اند [۱۰].

در [۱۱] از بردار ویژه لاپلاسین برای پیدا کردن یک نمایش ساختاری بهینه از تصاویر استفاده شده که این روش یادگیری، بدون ناظر بوده

1. Multi Resolution
2. Dual Tree Complex Wavelet Transform



شکل ۱: جایگاه روش پیشنهادی در یک سیستم تطبیق تصویر.

شدت، مقادیر بهینه زیادی حاصل می‌گردد. یکی از فاکتورهای مؤثر در فرار از افتادن الگوریتم در مینیمم‌های محلی، نرخ همگرایی است. نرخ همگرایی می‌تواند به عنوان یک ناحیه تعریف شود که اگر شروع الگوریتم در این ناحیه باشد، الگوریتم به یک مقدار بهینه صحیح همگرا خواهد شد و اگر شروع الگوریتم در این ناحیه نباشد به یک بهینه اشتباه همگرا می‌گردد و تطبیق به درستی انجام نمی‌شود. اندازه نرخ همگرایی، به ویژگی‌های تصویر و معیار مشابهت به کار رفته در آنها وابسته است و نرخ موفقیت الگوریتم را تحت تأثیر قرار می‌دهد. در روش پیشنهادی از آنجایی که فرایند تطبیق با استفاده از یک مجموعه تصاویر از پیش تطبیق یافته صورت می‌پذیرد، نرخ همگرایی افزایش می‌یابد. در واقع مزیت روش مبتنی بر یادگیری پیشنهادی نسبت به سایر روش‌ها در این است که نیاز به مقداردهی اولیه نداشته و یادگیری سبب افزایش نرخ همگرایی می‌گردد که این مسأله، عامل مؤثری در جلوگیری از افتادن الگوریتم در مینیمم‌های محلی است.

هدف مقاله حاضر در یک نگاه کلی، ارائه یک روش مبتنی بر یادگیری چنددقتی جهت تطبیق تصاویر در سطوح مختلف رزولوشن و جلوگیری از مینیمم‌های محلی به منظور افزایش دقت در تطبیق تصاویر چندکیفیتی است. به این صورت که در روش پیشنهادی به جای جستجوی تکراری در فضای تصویر، از یک مدل یادگیرنده در چند سطح رزولوشن استفاده می‌شود و بر خلاف سایر روش‌های مبتنی بر یادگیری که با یادگیری معیار مشابهت بین تصاویر، پارامترهای تبدیل بهینه را به دست می‌آورد، تمرکز روش پیشنهادی روی یادگیری پارامتر تبدیل است به طوری که به یک مقدار بهینه سراسری همگرا شود. شکل ۱ جایگاه روش پیشنهادی را در یک سیستم تطبیق تصویر نشان می‌دهد.

روش پیشنهادی که تطبیق مبتنی بر یادگیری چنددقتی (MLBR)^۱ نام دارد شامل دومرحله پیش تطبیق و تطبیق است و از ۳ گام تجزیه چنددقتی، یادگیری و تخمین پارامتر تبدیل تشکیل شده است. در مرحله پیش تطبیق از یک مجموعه تصاویر از پیش تطبیق یافته برای ایجاد مجموعه آموزش استفاده می‌شود و پارامترهای تبدیل با استخراج ویژگی‌های سراسری از زوج تصاویر آموزشی به دست می‌آید. استخراج ویژگی با به کارگیری روش تجزیه چنددقتی پیشنهادی، کاملاً خودکار بوده که سبب بالا رفتن دقت روش پیشنهادی می‌گردد. بردار ویژگی‌های استخراج شده از مجموعه تصاویر آموزشی به عنوان ورودی به مدل

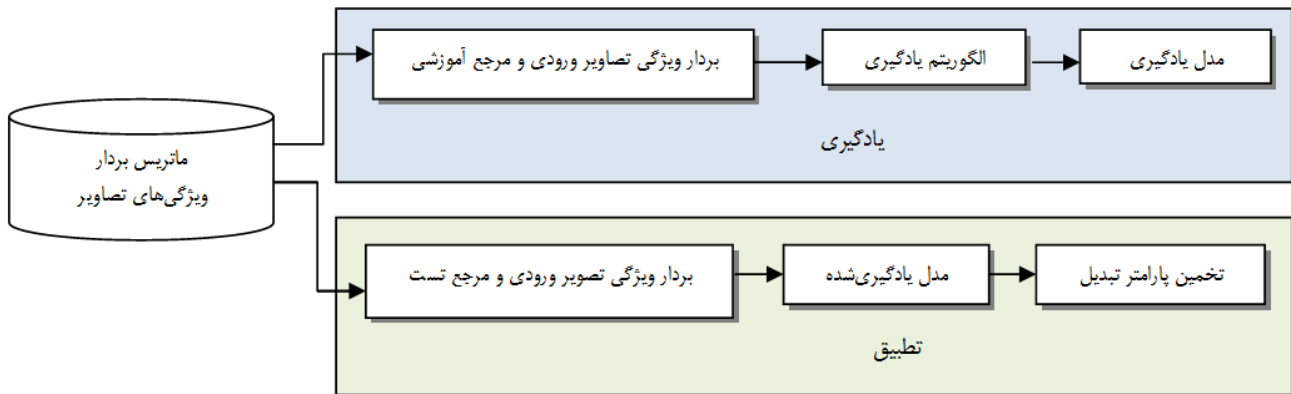
طوری تعریف شود که $U_{\Omega} = \{u | u: \Omega \rightarrow R\}$ و $\Omega \subseteq Z^2$. این تعریف به طور مشابه برای V که در این مقاله تصویر ورودی است، صادق است. $\hat{T} = \{T | T: R^2 \rightarrow R^2\}$ دسته‌ای از تبدیلات قابل تعریف از مجموعه نقاط در فضای R^2 است و هر تبدیل را می‌توان به صورت مجموعه‌ای از پارامترها مانند $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$ تعریف نمود به طوری که $n \in N$ درجه آزادی است. مشابهت بین تصویر مرجع U و تصویر انتقال یافته V ، با محاسبه $S(U, V_T)$ به دست می‌آید. تصویر ورودی V به طور تکراری تبدیل داده می‌شود و در هر تکرار، تابع مشابهت $S(U, V_T)$ ارزیابی می‌شود. در یک تعریف جامع، تطبیق تصویر فرایند پیدا کردن یک تبدیل $T^* \in \hat{T}$ است به طوری که طبق (۱)

$$S(u, v_{T^*}) = \max_{T \in \hat{T}} S(u, v_T) \quad (1)$$

یعنی به دست آوردن یک تبدیل $T = T^*$ که تابع مشابهت را بیشینه کند. در این مقاله هدف، پیدا کردن یک فضای پارامتری با ۶ آرگومان $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_n^*)$ است که به ازای آن $T^* = T_{\alpha^*}$ تابع مشابهت S را بیشینه کند.

۴- روش پیشنهادی

از آنجایی که تصاویر پزشکی، تصاویر با رزولوشن‌های پایین و متفاوت هستند، یکی از مهم‌ترین چالش‌ها در تطبیق تصاویر چندکیفیتی، پیدا کردن نقاط متناظر به دلیل ماهیت متفاوت دو تصویر است. ماهیت متفاوت دو تصویر به این دلیل است که تصاویر مورد مطالعه، دارای تغییرات شدت هستند. این تغییرات می‌تواند از چندگانگی منابع مانند تغییر روشنایی و یا حاصل از تصویربرداری با حسگرهای متفاوت باشد و به عبارتی دیگر به دلیل عدم وجود نداشت یک به یک بین مقادیر شدت در تصاویر چندکیفیتی، روش‌های پیش‌پردازش روی تصویر به تنهایی قادر نیستند به طور کامل تفاوت شدت بین دو تصویر را تصحیح کنند. رفع این چالش، اساس کار ایده پیشنهادی است بدین ترتیب که به جای استفاده مستقیم از شدت تصاویر برای محاسبه تناظر مکانی، تصاویر با استفاده از مقادیر فرکانس، تطبیق می‌یابند. در روش پیشنهادی به طور خودکار، آن وکسل‌هایی که مقادیر شدت آنها به طور چشم‌گیری در دو حجم متفاوت هستند، نادیده گرفته می‌شود که این مسأله باعث بالا رفتن دقت روش ارائه شده نسبت به روش‌های پیشین می‌گردد. عامل دیگری که در بالا بردن میزان دقت روش پیشنهادی مؤثر است، مدل یادگیری ارائه شده می‌باشد. در روش‌های پیشین وابسته به معیارهای مشابهت مبتنی بر



شکل ۲: مدل روش پیشنهادی.

از درخت دوتایی تبدیل موجک مختلط، اطلاعات آناتومی مهم در تصاویر پزشکی حفظ شده و از بلوری شدن تصویر جلوگیری می‌شود [۱۷]. دلیل دیگر که از درخت دوتایی تبدیل موجک مختلط برای تجزیه چنددقتی در این مقاله استفاده شده این است که سایر روش‌های تجزیه چنددقتی به دو گام پردازش نیاز دارد: اولاً تولید یک مجموعه تصاویر با رزولوشن‌های مختلف و سپس محاسبه شدت تصاویر متناظر آنها. روش پیشنهادی قادر است به طور هم‌زمان هرم تصاویر و شدت متناظر آنها را به دست آورد که ضمن بهبود دقت، باعث کاهش زمان محاسبات نیز می‌گردد.

یک تبدیل موجک مختلط به صورت (۲) تعریف می‌شود

$$\psi(x, y) = \psi(x)\psi(y) \quad (2)$$

به طوری که $\psi(x)$ و $\psi(y)$ دو موجک مختلط هستند و از (۳) و (۴) به دست می‌آیند

$$\psi(y) = \psi_h(y) + j\psi_g(y) \quad (3)$$

$$\psi(x) = \psi_h(x) + j\psi_g(x) \quad (4)$$

$\psi_h(x)$ و $\psi_h(y)$ تبدیلات موجک به دست آمده از فیلترهای بالاگذر و پایین‌گذر هستند که طبق (۵) به دست می‌آیند

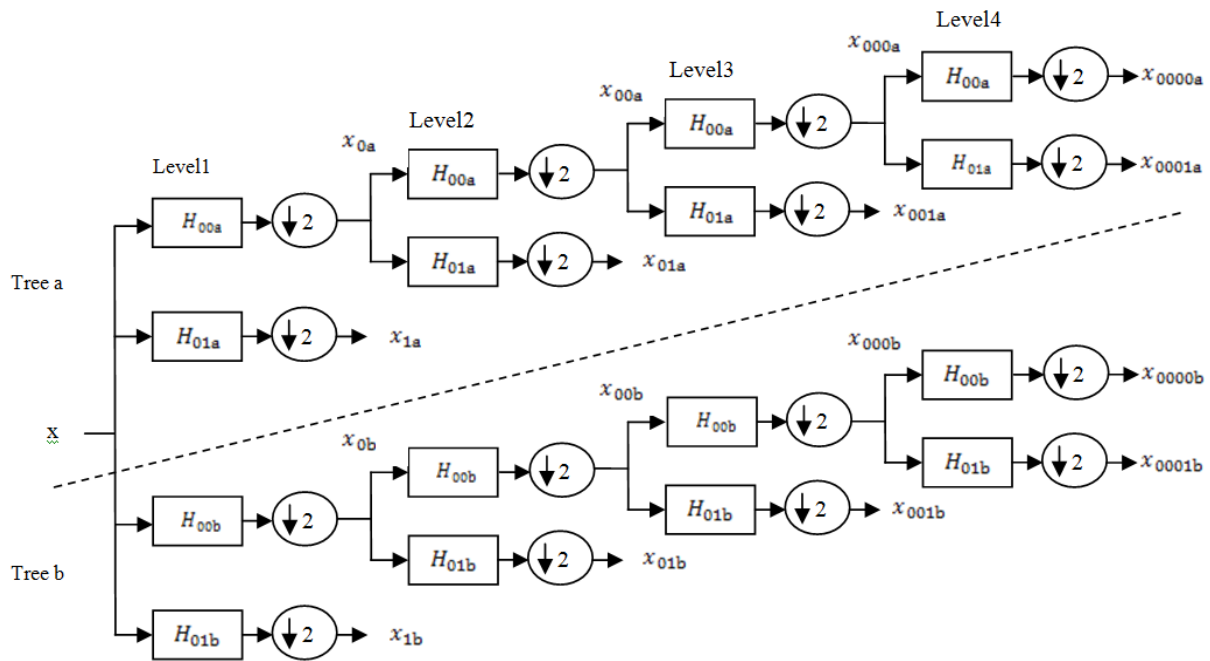
$$\begin{aligned} \psi(x, y) = [\psi_h(x) + j\psi_g(x)][\psi_h(y) + j\psi_g(y)] = \\ \psi_h(x)\psi_h(y) - \psi_g(x)\psi_g(y) + \\ j[\psi_g(x)\psi_h(y) + \psi_h(x)\psi_g(y)] \end{aligned} \quad (5)$$

یکی از موارد بسیار مهم در تجزیه توسط موجک، انتخاب سطح تجزیه مناسب به منظور حفظ دقت است. انتخاب یک سطح مناسب برای تجزیه موجکی و این که تا چه سطحی، تجزیه یک تصویر یا سیگنال ادامه یابد، وابسته به نوع سیگنال و تجربه است. معمولاً تا سطحی تجزیه ادامه می‌یابد که سیگنال یا تصویر هنوز محتوای فرکانسی مناسبی از تصویر اصلی را در بر داشته باشد و به عبارتی، فرکانس قطع را تا جایی پایین می‌بریم که تصویر تقریب نهایی کلیت تصویر اصلی را از دست نداده باشد. انجام پردازش‌ها در این سطح می‌تواند بسیار مفید باشد، چرا که ابعاد تصویر در هر سطح تجزیه نصف و تعداد پیکسل‌ها ۱ به ۴ می‌شود. در این مقاله، تصویر تا ۴ سطح تجزیه شده و ابعاد تصویر ۱ به ۱۶ و تعداد پیکسل‌ها ۱ به ۲۵۶ شده است. در اینجا از همبستگی بین دو سیگنال به عنوان معیاری برای انتخاب سطح تجزیه استفاده می‌شود. در واقع همبستگی بین دو سیگنال شباهت بین دو سیگنال بازسازی شده و اولیه را نشان می‌دهد و معیاری است برای یافتن درجه تجزیه. همبستگی بین سیگنال اولیه x و سیگنال تقریبی بازسازی شده y در (۶) آمده است

یادگیری داده می‌شود و مقادیر پارامتر متناظر به عنوان خروجی هدف در نظر گرفته می‌شود. وقتی پارامترهای تبدیل آموزش داده شد و مدل آموزش دید، مرحله تطبیق، سراسر است. بردار ویژگی‌های سراسری از یک تصویر تست به مدل آموزش دیده داده می‌شود و مقادیر پارامتر تخمین زده شده در خروجی خوانده می‌شود. این نوع از فرایند تطبیق، کل مسأله تطبیق را به رگرسیون برداری کاهش می‌دهد. پس از به دست آمدن پارامترهای تبدیل در هر سطح، پارامترهای تبدیل به ازای تمام سطوح محاسبه می‌گردد. پارامترهای تبدیل به دست آمده روی تصویر اعمال شده و با درون‌یابی تصویر، تصویر تطبیق یافته حاصل می‌گردد. شکل ۲ مدل روش پیشنهادی را نشان می‌دهد.

۴-۱ پردازش چنددقتی

در تطبیق تصاویر مغز که در این مقاله به طور خاص روی آن تمرکز شده، به دلیل ساختار پیچیده و تغییرات ساختار مغز در بخش‌های مختلف، وجود مینیم‌های محلی یک مسأله مهم به شمار می‌آید. از طرف دیگر از آنجایی که این تصاویر در معرض انواع متفاوتی از عوامل خارجی مانند نویز قرار دارند، تعیین یک بهینه سراسری از لحاظ محاسباتی، کار دشواری است به ویژه وقتی تصاویری که باید تطبیق یابند، نویزی باشد. همان طور که در بخش‌های قبل بیان گردید، برتری روش پیشنهادی نسبت به سایر روش‌های ارائه شده در حوزه تطبیق تصاویر پزشکی چندکیفیتی، افزایش دقت در به دست آوردن پارامترهای تبدیل بهینه است. بدین منظور روش تجزیه چنددقتی پیشنهاد شده که به جای استفاده مستقیم از شدت تصاویر برای محاسبه تناظر مکانی، تصاویر در حوزه فرکانس تطبیق می‌یابد و به طور خودکار آن وکسل‌هایی که مقادیر شدت آنها در دو حجم متفاوت است، نادیده گرفته می‌شود. پردازش چنددقتی یک تصویر، مبتنی بر مشاهده است و یک تصویر را با مقیاس‌های سخت و نرم نشان می‌دهد. مقیاس‌های سخت از یک تصویر، شامل شکل‌های اصلی و ویژگی‌های کلی تصویر است در حالی که مقیاس نرم شامل بافت و جزئیات بوده و دارای نویز است. از آنجایی که مقیاس‌های سخت، نسخه‌های آرام‌تری از تصاویر اولیه هستند محاسبه یک بهینه سراسری در این مقیاس‌ها، از لحاظ محاسباتی نسبت به تصویر اولیه کم‌هزینه‌تر بوده و با افزایش نرخ همگرایی، دقت روش ارائه شده به طور قابل قبولی افزایش می‌یابد. از بین روش‌های تجزیه چنددقتی متفاوتی که وجود دارد، از درخت دوتایی تبدیل موجک مختلط [۱۶] برای تجزیه تصاویر در سطوح رزولوشن متفاوت استفاده شده است زیرا اطلاعات بامعنی و مهم تصویر را حفظ می‌کند. تبدیل موجک علاوه بر نمایش اطلاعات ناحیه فرکانس، شامل اطلاعات ناحیه مکانی نیز می‌باشد و همچنین با تجزیه تصویر با استفاده



شکل ۳: تجزیه درخت دوتایی تبدیل موجک مختلط در سطح ۴ [۱۱].

پارامتر انتقال و ۳ پارامتر چرخش است، آموزش داده می‌شود که از این تبدیلات برای تنظیم تصاویر متناظر استفاده می‌شود. روش ارائه شده، پارامترهای تخمین را به طور مجزا به دست نمی‌آورد بلکه هر ۶ پارامتر را در چند سطح رزولوشن محاسبه می‌کند. مدل یادگیری پیشنهادی، شبکه عصبی است و دلیل انتخاب شبکه عصبی به عنوان یک مدل یادگیرنده این است که اولاً شبکه عصبی تابع خودیادگیرنده دارد به طوری که مختصات نقاط ویژگی و مقادیر مورد انتظار از دو تصویر به عنوان مثال های آموزشی به شبکه عصبی وارد شده و شبکه عصبی به طور خودکار، نگاشت مختصات تصویر را بدون تخمین مقدار هر پارامتر، به دست می‌آورد. ثانیاً شبکه عصبی تابع نگاشت غیر خطی دارد و می‌تواند اعوجاج‌های غیر خطی که توابع نگاشت مستقیم قادر به حل آن نیستند را حل کند [۱۸]. الگوریتم یادگیری شامل گام‌های زیر است:

- بردار ویژگی و متناظر آنها انتخاب می‌شود.
- شبکه عصبی ساخته می‌شود.
- شبکه عصبی آموزش داده می‌شود.
- نگاشت تبدیل مختصات تصویر برای تطبیق با شبکه عصبی کامل می‌شود.
- مختصات تبدیل شده با استفاده از شبکه عصبی درون‌یابی می‌شود تا تصویر تطبیق یافته را به دست آورد.

۴-۲-۱ ساختار شبکه عصبی

در روش پیشنهادی، ۴ شبکه عصبی در نظر گرفته شده که هر شبکه، پارامترهای تبدیل را در یک سطح رزولوشن به دست می‌آورد. هر شبکه عصبی از یک لایه ورودی، یک لایه پنهان و یک لایه خروجی تشکیل شده و هر نرون در لایه ورودی متناظر است با یک درایه بردار ویژگی که از تبدیل موجک مختلط دوتایی در سطح تقریب به دست آمده است. تعداد نرون‌های لایه پنهان با توجه به آزمون و خطا به دست آمده و در آنها از توابع انتقال سیگموئید استفاده گردیده و خروجی به صورت (۷) محاسبه شده است

$$Output = Z_i = \frac{Z}{1 + e^{-net_i}} \quad (7)$$


$$\rho(x, y) = \frac{\sum x_i y_i - \frac{1}{N} \sum x_i \sum y_i}{\sqrt{(\sum x_i^2 - \frac{1}{N} (\sum x_i)^2)(\sum y_i^2 - \frac{1}{N} (\sum y_i)^2)}} \quad (6)$$

که N تعداد باندهای اولیه است. شکل ۳ نتایج حاصل از اعمال تجزیه درخت دوتایی تبدیل موجک مختلط را در سطح ۴ در فضای یک بعدی نشان می‌دهد.

همان طور که در شکل ۳ ملاحظه می‌گردد دو مجموعه فیلتر پایین‌گذر H_{00} و بالاگذر H_{01} در هر سطح به تصویر اعمال می‌شود. تصاویر حاصل از عبور فیلتر پایین‌گذر، ضرایب تقریب تصویر را تولید می‌کند که یک تصویر کامل با سطح رزولوشن پایین‌تر است. از اعمال فیلتر بالاگذر روی تصویر، ضرایب جزئیات حاصل می‌گردد. از آنجایی که ضرایب تقریب اطلاعات کاملی از تصویر را شامل می‌شود، در مقاله حاضر از ضرایب تقریب حاصل از تجزیه استفاده می‌گردد. به این ترتیب، طیفی از تصاویر با استفاده از یک روش تجزیه چنددقتی به دست آمده و ضرایب حاصل از تجزیه از هر طیف استخراج شده و به عنوان ورودی به مدل یادگیرنده داده می‌شود.

۴-۲ یادگیری

در روش‌های متداول تطبیق تصویر، وقتی تصویر خیلی بزرگ است حجم محاسبات برای پیدا کردن پارامتر تبدیل بهینه بسیار سنگین می‌شود که کارایی روش را پایین می‌آورد. ثانیاً تصاویری که باید تطبیق یابند به دلیل وجود انواع اعوجاج‌ها، اغلب به طور جزئی تخریب شده‌اند که در این حالت، نگاشت مستقیم برای پیدا کردن پارامترهای تبدیل کار دشواری است. این مقاله از یک روش مبتنی بر یادگیری برای رفع موانع پیش گفته و جلوگیری از افتادن الگوریتم در مینیمم‌های محلی استفاده می‌کند. یک روش تجزیه چنددقتی، تصویر را در چند سطح متفاوت رزولوشن تجزیه می‌کند. به منظور افزایش دقت، یادگیری چنددقتی پیشنهاد گردیده، به این ترتیب که به ازای هر سطح رزولوشن، یک مدل یادگیرنده تعریف شده و فرایند یادگیری از پایین‌ترین سطح، شروع شده و به سمت سطوح بالاتر می‌رود. با استفاده از مدل یادگیرنده، تبدیلات لازم که شامل ۳



شکل ۴: نمایی از شبکه عصبی مدل پیشنهادی.

به دست آمده در هر تکرار تنظیم شده است. این فرایند، تکرار پیدا می‌کند تا زمانی که تابع MSE کمینه شود و بردار وزن به مقدار بهینه برسد [۱۸]. فرایند آموزش تکرار می‌شود تا زمانی که الگوریتم یادگیری به یک مقدار بهینه همگرا شود. زمانی که یک شبکه آموزش دیده در دسترس بود، گام بعدی که گام تطبیق است با استخراج ویژگی‌های تصویر و اعمال به شبکه عصبی آموزش دیده، پارامترهای بهینه تطبیق را در هر سطح تخمین می‌زند.

همان طور که ملاحظه می‌گردد، مزیت روش پیشنهادی در این است که فرایند آموزش در سطوح مختلف تصویر انجام می‌شود و به منظور افزایش دقت، به جای استفاده از مقادیر شدت تصاویر، یادگیری روی ضرایب فرکانسی درخت دوتایی تبدیل مویک مختلط صورت گرفته است.

۴-۲-۳ تطبیق

پارامترهای تطبیق ابتدا در پایین‌ترین سطح که تصویر با کمترین دقت است تخمین زده می‌شود به طوری که میزان تغییر مکان در این سطح، کم است. فرایند تخمین پارامتر از سخت‌ترین (پایین‌ترین) سطح به سمت سطوح نرم‌تر با استفاده از شبکه عصبی آموزش دیده به طور تکراری ادامه می‌یابد تا پارامترهای تبدیل را در بالاترین مقیاس (حجم‌های اولیه) به دست آورد.

تبدیل نهایی با ضرب پارامترهای تبدیل به دست آمده در هر سطح با استفاده از ضرب ماتریس‌ها به دست می‌آید. در هر تکرار، ۶ پارامتر تخمین زده شده و تبدیل مختصات همگن متناظر با i امین تکرار در ماتریس (۱۱) نشان داده شده است

$$M_i = \begin{bmatrix} r_{1y_i} & r_{1r_i} & r_{1z_i} & t_{x_i} \\ r_{2y_i} & r_{2r_i} & r_{2z_i} & t_{y_i} \\ r_{3y_i} & r_{3r_i} & r_{3z_i} & t_{z_i} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (11)$$

مستطیل زیرماتریس سمت راست، تبدیلات تخمین زده شده هستند و مستطیل زیرماتریس 3×3 سمت چپ، ماتریس چرخش است که متناظر است با چرخش تخمین زده شده (w_{xi}, w_{yi}, w_{zi}) که در جدول ۱ نشان داده شده است. تبدیل سراسری با ضرب ماتریس‌های تبدیلات مختصات همگن متناظر در هر تکرار مطابق (۱۲) به دست می‌آید

$$M = \pi_i M_i \quad (12)$$

به طوری که net ورودی شبکه بوده و تعداد نرون‌ها در لایه خروجی مساوی است با تعداد پارامترهایی که باید تخمین زده شود. توابع خطی نرون‌های لایه خروجی را به شکل ماتریسی مشخص می‌کند [۱۸]

$$Output = y = f(net) = W_k z \quad (8)$$

پارامترهای تبدیل با ۶ درجه آزادی، شامل سه پارامتر انتقال (t_x, t_y, t_z) و سه پارامتر چرخش (r_x, r_y, r_z) ، به عنوان خروجی‌های شبکه هستند. در شکل ۴ نمایی از شبکه عصبی نشان داده شده است.

۴-۲-۴ آموزش شبکه عصبی

همان طور که در بخش قبل بیان گردید، در روش پیشنهادی به منظور به دست آوردن ورودی‌های آموزشی از یک روش استخراج ویژگی خودکار به نام درخت دوتایی تبدیل مویک مختلط استفاده شده به طوری که ضرایب درخت دوتایی تبدیل مویک مختلط در هر سطح به عنوان ورودی به شبکه داده می‌شود و پارامترهای تبدیل با استفاده از شبکه عصبی در هر سطح، آموزش می‌بیند. در این مقاله از الگوریتم پس‌انتشار خطا برای آموزش شبکه عصبی و از الگوریتم لونیبرگ مارکوارت برای بهینه‌سازی استفاده شده است. فرایند خودیادگیری به طور تکراری ادامه می‌یابد و در ابتدا به شبکه، یک مجموعه از وزن‌های اولیه داده می‌شود. داده‌های نمونه ورودی و خروجی محاسبه و وزن‌ها با تفاضل بین خروجی و ورودی مورد انتظار به هنگام می‌شود. این روش از بردار ویژگی تصویر ورودی به عنوان ورودی به شبکه عصبی و از پارامترهای تبدیل تصویر مرجع به عنوان پارامترهای هدف استفاده می‌کند. شبکه عصبی آموزش داده می‌شود تا وزن‌های متناظر بین لایه‌های مختلف را تخمین بزند. فاز آموزش با مقادیری وزن‌های شبکه (W_0) آموزش داده می‌شود و سپس مطابق (۹) و (۱۰) وزن‌ها (W) و بایاس‌ها بر طبق بهینه‌سازی لونیبرگ مارکوارت به هنگام می‌شوند

$$\Delta \omega = -[\nabla^T \mathcal{E}]^{-1} \nabla \mathcal{E} \quad (9)$$

$$\Delta \omega = (J^T J + MI(J^T \mathcal{E})) \quad (10)$$

به طوری که $\nabla^T \mathcal{E}$ ماتریس هسیان، $\nabla \mathcal{E}$ شیب، J ماتریس ژاکوبین با توجه به وزن‌ها و μ پارامتری است که پایداری و نرخ همگرایی را کنترل می‌کند. I ماتریس یکک و \mathcal{E} به عنوان خطای بین خروجی مناسب و مقادیر محاسبه شده متناظر در نظر گرفته شده و پارامتر μ بر طبق نتایج

است اگر فاصله اقلیدسی از تبدیلات استاندارد طلایی $[t_x, t_y, t_z]$ و تبدیلات نهایی $[t'_x, t'_y, t'_z]$ متناظر آن کمتر از ۴ mm باشد (۴ mm بزرگترین بعد حجم تصاویر است).

علاوه بر معیار TRE که برای مقایسه خطای تطبیق بین روش‌های تطبیق به کار می‌رود، در این مقاله از یک معیار مبتنی بر اندازه‌گیری نرخ همبستگی بین تصاویر نیز برای مقایسه دقت روش‌های تطبیق استفاده شده است [۲۰]. بر اساس معیار نرخ همبستگی، یک روش دارای دقت بالاتری است در صورتی که مقدار مشابهت به دست آمده بین تصویر تطبیق‌یافته و تصویر مرجع بیشتر باشد.

۵-۲ روش آزمون

روش آزمون مورد استفاده در این پژوهش مطابق روش‌های آزمون رایج در مراجعی مانند [۱۲]، [۱۵] و [۲۱] می‌باشد.

در این راستا برای تنظیم پارامترهای پیش‌نیاز طرح پیشنهادی، انجام ارزیابی‌ها و همچنین مقایسه روش پیشنهادی با دیگر روش‌های مطرح در این حوزه، آزمون‌هایی انجام شده که نتایج آنها در بخش‌های بعدی بررسی می‌گردد و همه آزمون‌ها با استفاده از روش تکرار انجام می‌شود. با توجه به پارامترهای تنظیم اولیه، مقادیر تصادفی برای محورهای انتقال X و Y در محدوده $[150, -150]$ رسم شده و مقادیر تصادفی برای محور Z در محدوده $[70, -70]$ رسم شده و مقادیر تصادفی برای چرخش در بازه $[30, -30]$ قرار دارند.

برای ارزیابی دقت تصویر تطبیق‌یافته نهایی، ابتدا برای تصاویر تطبیق‌یافته در هر سطح، میانگین نرخ خطای تطبیق اندازه‌گیری می‌شود، سپس میانگین نرخ خطای تطبیق تصویر تطبیق‌یافته که از ضرب ماتریس تبدیل تمام سطوح به دست آمده، محاسبه می‌گردد.

برای مقایسه روش پیشنهادی با دیگر روش‌ها نیز به همین ترتیب میانگین نرخ خطای تطبیق برای آن روش‌ها محاسبه شده است.

۵-۳ مجموعه داده‌ای و استاندارد طلایی

در آزمایش‌ها از مجموعه تصاویر MRI-T₁ و CT که از بانک تصاویر پزشکی دانشگاه واندربیلست استخراج شده، استفاده شده است. مجموعه داده‌ای شامل تصاویر آموزشی برای یادگیری و تصاویر تست برای آزمون روش پیشنهادی می‌باشد و در همه آزمایش‌ها، تصویر CT به عنوان تصویر ورودی و تصویر T₁ به عنوان تصویر مرجع، در نظر گرفته شده است. بانک تصاویر پزشکی پروژه RIRE که در [۱۹] به آن اشاره شده از تصاویر پزشکی مغز با سیستم‌های تصویربرداری متفاوت از چندین بیمار تشکیل شده که مشخصات تصاویر در جدول ۲ آمده که تصاویری با اندیس زوج به عنوان زوج تصاویر آموزشی در نظر گرفته شده‌اند و تصاویری از بیمار که شماره اندیس آنها فرد است برای آزمون روش پیشنهادی به کار رفته‌اند. از آنجایی که در مجموعه تصاویر مورد آزمون، تصویر MRI-T₁ از بیمار شماره ۰۰۶ تصحیح نشده، از این تصویر به عنوان زوج آموزشی استفاده نشده است. برای ساخت زوج تصویر آموزشی که برای ارزیابی آزمایش‌های تطبیق به عنوان استاندارد طلایی به کار رود، تطبیق تصویر مبتنی بر اطلاعات متقابل (MI) با ۴ سطح شفافیت روی ۳ جفت تصاویر RIRE که در جدول ۲ به رنگ آبی نشان داده شده، اعمال شده است. علاوه بر این از سایر مجموعه‌های داده‌ای [۲۲] و [۲۳] نیز برای ارزیابی کارایی روش پیشنهادی استفاده شده که به دلیل کمبود فضا، نتایج حاصل از آن در این مقاله ارائه نشده است.

جدول ۱: ماتریس چرخش.

r_{11}	$\cos(\omega_{y1}) \cos(\omega_{z1})$
r_{12}	$-\cos(\omega_{y1}) \sin(\omega_{z1})$
r_{13}	$\sin(\omega_{y1})$
r_{21}	$\sin(\omega_{x1}) \sin(\omega_{y1}) \cos(\omega_{z1}) + \cos(\omega_{x1}) \sin(\omega_{z1})$
r_{22}	$-\sin(\omega_{x1}) \sin(\omega_{y1}) \sin(\omega_{z1}) + \cos(\omega_{x1}) \cos(\omega_{z1})$
r_{23}	$-\sin(\omega_{x1}) \cos(\omega_{y1})$
r_{31}	$-\cos(\omega_{x1}) \sin(\omega_{y1}) \cos(\omega_{z1}) + \sin(\omega_{x1}) \sin(\omega_{z1})$
r_{32}	$\cos(\omega_{x1}) \sin(\omega_{y1}) \sin(\omega_{z1}) + \sin(\omega_{x1}) \cos(\omega_{z1})$
r_{33}	$\cos(\omega_{x1}) \cos(\omega_{y1})$

اندیس i شماره هر تکرار را نشان می‌دهد.

۵- نتایج شبیه‌سازی و آزمون روش پیشنهادی

در این بخش، نتایج آزمون‌های انجام‌شده به همراه تحلیل هر یک از آزمون‌ها آورده شده و هدف از آزمون روش پیشنهادی، مقایسه نتایج حاصل از روش پیشنهادی با دیگر روش‌های مطرح می‌باشد. به منظور شبیه‌سازی کارایی روش ارائه‌شده در کاربردهای واقعی، از مجموعه تصاویر پزشکی مغز که از بانک تصاویر پزشکی دانشگاه واندربیلست به دست آمده استفاده شده است. بخش ۵-۱ معیار ارزیابی به کار رفته را توضیح می‌دهد، بخش ۵-۲ به بیان روش آزمون می‌پردازد، بخش ۵-۳ مجموعه داده‌ای مورد استفاده و استاندارد طلایی را توضیح می‌دهد و بخش ۵-۴ شامل آزمون‌های انجام‌شده است.

۵-۱ معیار ارزیابی

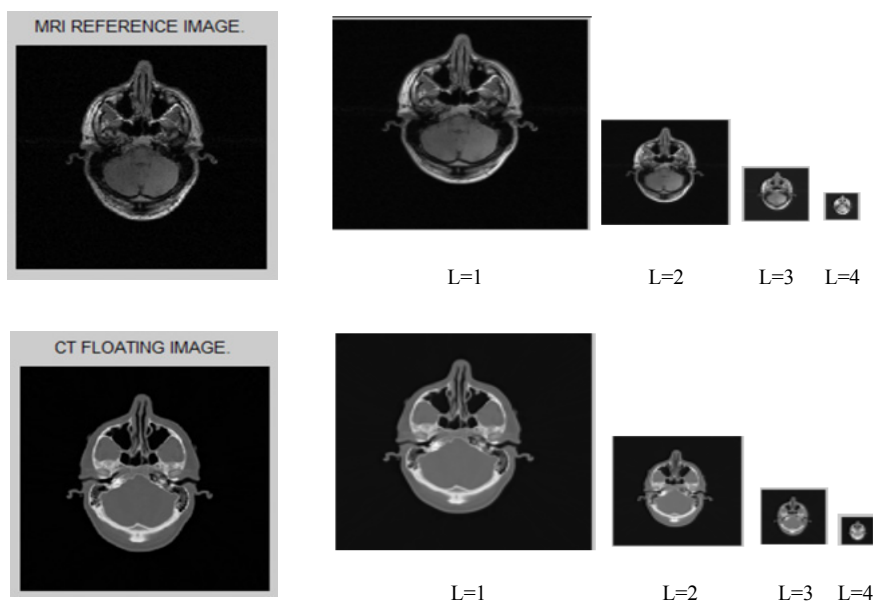
همان‌طور که قبلاً مطرح شد، عدم وجود نگاشت متناظر بین دو تصویر در تصاویر چندکیفیتی به دلیل متفاوت بودن شدت تصاویر و افتادن الگوریتم در مینیمم‌های محلی، یکی از عمده‌ترین چالش‌های ساختارهای تطبیق تصویر مطرح‌شده در پژوهش‌های پیشین می‌باشد. از آنجایی که هدف این پژوهش، ارائه یک روش تطبیق تصویر مبتنی بر یادگیری چنددقتی جهت تطبیق تصاویر با کیفیت‌های متفاوت می‌باشد، معیار دقت به منظور ارزیابی روش پیشنهادی در نظر گرفته شده است.

معیار دقت، مقایسه تصویر به دست آمده بعد از تطبیق با تصویر اولیه است. یک روش تطبیق، زمانی دقیق محسوب می‌شود که میانگین نرخ خطای به دست آمده به ازای تمام مجموعه داده‌ای از حد آستانه در نظر گرفته شده کمتر باشد. از آنجایی که هیچ استاندارد طلایی برای تعیین صحت تطبیق تصویر وجود ندارد، از پروژه RIRE^۱ به منظور ارزیابی نتایج تطبیق استفاده می‌شود [۱۹] که در آن کیفیت تطبیق به وسیله خطای تطبیق هدف^۲ (TRE) محاسبه می‌شود. TRE با مقایسه مکان‌هایی از یک مجموعه نقاط $\{p_i, 1 \leq i \leq M\}$ که به ترتیب با تبدیل T و تبدیل استاندارد طلایی G ، نگاشت داده شده‌اند، مطابق با (۱۳) محاسبه می‌شود

$$TRE = \frac{1}{M} \sum_{i=1}^M \|T(p_i) - G(p_i)\| \quad (13)$$

دقت با نرخ تطبیق صحیح اندازه‌گیری می‌شود. تطبیق تصویر صحیح

1. Retrospective Image Registration Evaluation
2. Target Registratin Error



شکل ۵: نتایج حاصل از تجزیه تصاویر MRI و CT در ۴ سطح.

جدول ۳: متوسط نرخ یادگیری برای چهار شبکه عصبی چندسطحی.

اندازه تصویر	MRNN	MLP
۶۴×۶۴	۰٫۷۶	۰٫۷۸
۱۲۸×۱۲۸	۰٫۸۲	۰٫۷۳
۲۵۶×۲۵۶	۰٫۷۹	۰٫۷۱
۵۱۲×۵۱۲	۰٫۸۷	۰٫۷۹

جدول ۲: مجموعه داده‌ای بانک تصاویر RIRE.

Scheme Matching	Resolution	Voxel size
pt-000	CT ۵۱۲×۵۱۲×۲۸	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۶	۱٫۲۵×۱٫۲۵×۴
pt-001	CT ۵۱۲×۵۱۲×۲۸	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۶	۱٫۲۵×۱٫۲۵×۴
pt-002	CT ۵۱۲×۵۱۲×۲۹	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۶	۱٫۲۵×۱٫۲۵×۴
pt-003	CT ۵۱۲×۵۱۲×۳۴	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۰	۱٫۲۵×۱٫۲۵×۴
pt-004	CT ۵۱۲×۵۱۲×۲۷	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۰	۱٫۲۵×۱٫۲۵×۴
pt-005	CT ۵۱۲×۵۱۲×۳۳	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۶	۱٫۲۵×۱٫۲۵×۴
pt-006	CT ۵۱۲×۵۱۲×۲۷	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۰	۱٫۲۵×۱٫۲۵×۴
pt-007	CT ۵۱۲×۵۱۲×۲۸	۰٫۶۵×۰٫۶۵×۴
	MR ۲۵۶×۲۵۶×۲۶	۱٫۲۵×۱٫۲۵×۴


۵-۱-۴ نتایج حاصل از تطبیق چندسطحی در برابر تطبیق تکسطحی

همان طور که پیشتر بیان گردید روش ارائه شده توسط تطبیق چنددقتی بهبود داده شده است. مطابق شکل ۵ تصاویر با استفاده از درخت دوتایی تبدیل موجک مختلط در ۴ سطح، تجزیه می‌شوند. تطبیق از سخت‌ترین سطح رزولوشن که سطح ۴ است شروع شده و بردار ویژگی تصاویر ورودی و مرجع به عنوان ورودی به شبکه عصبی داده می‌شود. یادگیری به طور تصادفی با وزن‌دهی اولیه شبکه شروع می‌شود و فرایند یادگیری سایر سطوح با شبکه عصبی متناظر با آن سطح انجام می‌شود. پارامترهای آموزش دیده در هر سطح به عنوان مقادیر اولیه به سطح بالاتر منتقل می‌شود. به کارگیری شبکه عصبی در سطوح مختلف نسبت به یک شبکه عصبی تکسطحی، سرعت نرخ یادگیری را بهبود می‌دهد و این مسأله باعث می‌شود سرعت فرایند تطبیق ضمن افزایش دقت، بالا رود. برای آزمون کارایی روش یادگیری چندسطحی نسبت به شبکه عصبی تکسطحی، یادگیری روی تصاویر با سطوح متفاوت دقت انجام شده است. جدول ۳ متوسط نرخ یادگیری را برای چهار شبکه عصبی چندسطحی در مقایسه با شبکه تکسطحی نشان می‌دهد. ملاحظه می‌گردد که برای تصویر در پایین‌ترین سطح دقت، تفاوت بین دو روش محسوس نیست اما زمانی که به سطوح بالاتر دقت رفته و اندازه تصویر بزرگ‌تر می‌شود نرخ یادگیری در روش‌های مبتنی بر شبکه عصبی چنددقتی به طور قابل ملاحظه‌ای بهبود می‌یابد. در ادامه، شکل ۶ متوسط نرخ یادگیری را برای یکی از پارامترها (زاویه چرخش)، در شبکه عصبی چندسطحی نسبت به شبکه عصبی تکسطحی، با یکدیگر مقایسه می‌کند. ملاحظه می‌گردد که شبکه عصبی چندسطحی، نرخ


۵-۴ آزمون‌های انجام شده

در این بخش، نتایج آزمون‌های انجام شده به همراه تحلیل هر یک از آزمون‌ها آورده شده است.

ابتدا به منظور ارزیابی روش پیشنهادی که مبتنی بر یادگیری در چند سطح رزولوشن است، نتایج حاصل از یک شبکه تکسطحی در مقابل یک شبکه چندسطحی تحلیل شده و سپس دقت روش ارائه شده، مورد آزمون قرار گرفته و نتایج حاصل از روش پیشنهادی با دیگر روش‌های مطرح در این حوزه مورد مقایسه و تحلیل قرار گرفته است. برای پیاده‌سازی از محیط Matlab ۷.۸.۰.۳۴۷ در کامپیوتر شخصی با CPU دارای سرعت ۴ GHz و RAM ظرفیت ۴ GB استفاده شده است.



شکل ۷: مقایسه متوسط خطای یادگیری پارامترهای انتقال برای چند نمونه آزمایشی.



شکل ۶: متوسط نرخ یادگیری زاویه چرخش در شبکه عصبی چندسطحی نسبت به شبکه عصبی تکسطحی.

جدول ۴: مقایسه روش پیشنهادی با سه روش با میانگین و انحراف معیار از میانه TRE.

روش	MI	KLD	BD	MLBR
	Mean ± Sd	Mean ± Sd	Mean ± Sd	Mean ± Sd
مجموعه داده pt-0.01	۰٫۶۹۰۶ ± ۰٫۱۱۵۹	۱٫۸۶۴۷ ± ۰٫۴۸۴۵	۰٫۶۳۸۵ ± ۰٫۱۳۴۵	۰٫۶۳۳۱ ± ۰٫۰۳۸۴
pt-0.03	۰٫۷۷۲۵ ± ۰٫۰۳۷۳	۲٫۸۱۴۷ ± ۰٫۴۱۶۸	۱٫۰۰۲۵ ± ۰٫۲۹۰۶	۰٫۷۵۴۵ ± ۰٫۰۲۷۶
pt-0.05	۰٫۶۰۵۱ ± ۰٫۲۰۴۳	۲٫۲۶۱۸ ± ۰٫۴۴۵۵	۰٫۹۹۱۸ ± ۰٫۶۲۵۸	۰٫۸۴۵۹ ± ۰٫۰۱۳۶
pt-0.05	۱٫۳۱۵۱ ± ۰٫۱۴۹۶	۲٫۲۶۶۹ ± ۰٫۵۴۳۵	۱٫۱۲۴۷ ± ۰٫۳۵۷۰	۰٫۷۵۶۵ ± ۰٫۲۴۸۸

[۱۲] و روش BD از [۲۱] با ۴ سطح رزولوشن در جدول ۴ نشان داده شده است. در جدول ۴ میانگین و انحراف معیار از مقادیر میانه TRE برای سه روش با یکدیگر مقایسه شده است.

MI: از آنجایی که این روش به مقادیر شدت تصویر وابسته نیست و مبتنی بر وابستگی آماری مقادیر هیستوگرام تصویر است، برای تطبیق تصاویر چندکیفیتی مناسب است. در مقایسه با دو روش KLD و BD از دقت قابل ملاحظه‌ای برخوردار است اما زمان محاسبات هیستوگرام متصل بسیار بالا بوده و خطر افتادن الگوریتم در در مینیمم محلی وجود دارد. KLD: این روش مبتنی بر دانش قبلی از توزیع شدت هیستوگرام متصل مورد انتظار از تصاویر آموزشی از پیش تنظیم شده است. هدف تطبیق دو تصویر ورودی و مرجع است به طوری که توزیع شدت هیستوگرام متصل مورد انتظار و مشاهده شده به طور قابل ملاحظه‌ای به یکدیگر نزدیک گردند.

BD: یک روش مبتنی بر یادگیری دیگر که برای ارزیابی آزمایش‌های انجام شده به کار می‌رود، معیار فاصله Bhatta charyya است که فاصله بین دو توزیع احتمال را اندازه می‌گیرد. با به کارگیری یک معیار فاصله Bhatta charyya با دانش قبلی از توزیع شدت متصل و ادغامی از یک جفت تصویر از پیش تطبیق یافته می‌توان تصاویر را تطبیق داد. همان طور که در جدول ۴ ملاحظه می‌گردد این روش از دقت قابل قبول برخوردار است و از آنجایی که از دانش قبلی استفاده می‌کند زمان فرایند تطبیق را به طور قابل ملاحظه‌ای کاهش می‌دهد.

ملاحظه می‌گردد که روش پیشنهادی در مقایسه با سه روش دیگر از خطای تطبیق کمتری برخوردار است. در شکل ۸ دقت فرایند تطبیق سه روش مبتنی بر یادگیری برای تصاویر بیماران مورد آزمون با یکدیگر مقایسه شده است.

علاوه بر معیار TRE که برای مقایسه خطای تطبیق بین روش‌های تطبیق به کار می‌رود، در این مقاله از یک معیار مبتنی بر اندازه‌گیری نرخ همبستگی بین تصاویر نیز برای مقایسه دقت روش‌های تطبیق استفاده شده است. بر این اساس یک روش دارای دقت بالاتری است در صورتی که مقدار مشابهت به دست آمده بین تصویر تطبیق یافته و تصویر مرجع بیشتر باشد. شکل ۹ نتایج حاصل از ارزیابی دقت با روش نرخ همبستگی را بین چند نمونه تصویر آزمون نشان می‌دهد. ملاحظه می‌گردد که روش

یادگیری رو به رشدی نسبت به شبکه عصبی تکسطحی دارد. شکل ۷ خطای یادگیری در روش پیشنهادی را برای ۳ پارامتر انتقال به ازای نمونه‌های آموزشی متفاوت نشان می‌دهد.

۵-۴-۲ آزمون روش پیشنهادی

در این بخش نتایج حاصل از ارزیابی کیفیت تصاویر تطبیق یافته با استفاده از معیار دقت و در مقایسه با سه روش مورد بررسی و تحلیل قرار گرفته و روش پیشنهادی بر اساس اجرای آزمون‌های تکراری ارزیابی شده است. معیار دقت، مقایسه تصویر به دست آمده بعد از تطبیق با تصویر اولیه است. یک روش تطبیق، زمانی دقیق محسوب می‌شود که میانگین نرخ خطای به دست آمده به ازای تمام مجموعه داده‌ای از حد آستانه در نظر گرفته شده کمتر باشد. هر چه میزان متوسط دقت به دست آمده بالاتر باشد، کیفیت تصویر تطبیق یافته نهایی ایجاد شده بهتر است.

در آزمایش‌ها این طور تعریف می‌شود که یک تطبیق موفق است اگر مقدار میانگین TRE متناظر آن کمتر از ۴ mm باشد (۴ mm بزرگ‌ترین بعد حجم تصاویر است) و به عبارتی فاصله اقلیدسی از تبدیلات استاندارد طلایی و تبدیلات نهایی کمتر از ۴ و کسل و مقدار ماکسیمم مطلق خطای سه چرخشی کمتر از ۴ درجه باشد.

در این مقاله، تبدیلات استاندارد طلایی، تبدیلات بهینه‌ای است که با به کارگیری روش مبتنی بر اطلاعات متقابل MI با ۴ سطح شفافیت به دست آمده است. همه تبدیلات استاندارد طلایی با پروژه RIRE ارزیابی شده و مقدار TRE کمتر از ۱ mm دارد.


مقادیر میانه TRE که از تبدیلات استاندارد طلایی مطابق [۱۹] برای بیمار pt-0.01، pt-0.02، pt-0.03، pt-0.04، pt-0.05، pt-0.07 به دست آمده به ترتیب ۰٫۹۶۹۲ mm، ۰٫۵۸۵۰ mm، ۰٫۷۵۷۷ mm، ۰٫۷۰۶۹ mm، ۰٫۹۸۱۳ mm و ۰٫۳۳۳۷ mm است.

تنظیم‌های اولیه از هر جفت تصویر تست با به کارگیری صد تبدیل صلب روی تبدیل استاندارد طلایی متناظر انجام می‌شود. پارامترهای انتقال X ، Y و Z از تبدیلات صلب به ترتیب در بازه $[-۱۵۰, ۱۵۰]$ ، $[-۱۵۰, ۱۵۰]$ و $[-۷۰, ۷۰]$ mm بوده، در حالی که همه پارامترهای چرخش بین $[-۳۰, ۳۰]$ درجه در نظر گرفته شده است. نتایج حاصل از آزمون ساختار پیشنهادی در مقایسه با سه روش MI از [۲]، KLD از


نتیجه حاصل از تطبیق تصاویر، مطلوب‌تر می‌گردد. در این مقاله از تبدیل صلبی برای تطبیق تصاویر چندکیفیتی شبیه‌سازی شده استفاده شد که در فعالیتهای آتی از تصاویر واقعی برای تطبیق تصاویر چندکیفیتی در زمان‌های مختلف و با در نظر گرفتن تبدیل آفین استفاده خواهد شد.

مراجع

- [1] J. P. W. Pluim, "Mutual information based registration of medical images: a survey," *IEEE Trans. on Medical Imaging*, vol. 22, no. 8, pp. 986-1004, Aug. 2003.
- [2] R. Suganya, K. Priyadharsini, and S. Rajaram, "Intensity based image registration by maximization of mutual information," *Int. J. of Computer Application*, vol. 1, no. 20, 5 pp., 2010.
- [3] J. Chen and J. Tian, "Real-time multi-modal rigid registration based on a novel symmetric-SIFT descriptor," *Progress in Natural Science*, vol. 19, no. 5, pp. 643-651, 10 May 2009.
- [4] M. R. Keyvanpour and S. Alehojat, "Analytical comparison of learning based methods to increase the accuracy and robustness of registration algorithms in medical imaging," *Int. J. of Advanced Science and Technology*, vol. 41, pp. 61-70, Apr. 2012.
- [5] B. Zitova, J. Flusser, and F. Sroubek, "Image registration: a survey," *Image and Vision Computing*, vol. 21, no. 11, pp. 977-1000, 2003.
- [6] G. Coppini, S. Diciotti, and G. Valli, "Matching of medical images by self-organizing neural networks," *Pattern Recognition Letters*, vol. 25, no. 4, pp. 341-352, Feb. 2004.
- [7] S. Wang, S. Lei, and F. Chang, "Image registration based on neural network," in *Proc. of the 5th Int. Conf. on Information Technology and Application in Biomedicine*, pp. 74-77, 30-31 May 2008.
- [8] M. Fornefett, K. Rohr, and H. S. Stiehl, "Elastic registration of medical images using radial basis functions with compact support," in *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, vol. 1, pp. 1063-6919, 23-25 Jun. 1999.
- [9] R. Rajeswari and A. A. Irudhayaraj, "Implementation of radial basis function for fMRI registration," *Int. J. of Computer Theory and Engineering*, vol. 3, no. 2, pp. 287-291, Apr. 2011.
- [10] S. Oldridge, S. Fels, and G. Miller, "Classification of image registration problems using support vector machines," in *Proc. of the Int. Conf. on Computer Vision*, pp. 360-366, 5-7 Jan. 2011.
- [11] C. Wachinger and N. Navab, "Manifold learning for multi-modal image registration," *BMVC*, 2010.
- [12] H. -M. Chan, A. C. S. Chung, S. C. H. Yu, A. Norbansh, and W. M. Wells, "Multi-modal image registration by minimizing kullback-leibler distance between expected and observed joint class histogram," in *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, vol. 2, p. 570, 18-20 Jun. 2003.
- [13] A. C. S. Chung, R. Gan, and W. M. Wells III, Robust Multi-Modal Image Registration Based on Prior Joint Intensity Distributions and Minimization of Kullback-Leibler Distance, HKUST CSE Technical Report, 2007.
- [14] R. Liao, et al., "Learning-based 2D/3D rigid registration using Jensen-Shannon divergence for image-guided surgery," *Medical Imaging and Augmented Reality, Lecture Notes in Computer Science*, vol. 4091, pp. 228-235, 2006.
- [15] D. Lee, et al., "Learning similarity measure for multi-modal 3D image registration," in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition, CVPR'2009*, pp. 186-193, 20-25 Jun. 2009.
- [16] C. Chau, L. Duval, and J. C. Pesquet, "Image analysis using a dual-tree M-band wavelet transform," *IEEE Trans. on Image Processing*, vol. 15, no. 6, pp. 2397-2412, Aug. 2006.
- [17] R. Mavudila, M. Cherkaoui, L. Masmoudi, and N. Hassanain, "A combined dual-tree complex wavelet (DT-CWT) and bivariate shrinkage for ultrasound medical images despeckling," *Int. J. of Computer Applications*, vol. 49, no. 14, pp. 42-49, Jul. 2012.
- [18] A. B. Abche, F. Yaacoub, A. Maalouf, and E. Karam, "Image registration based on neural network and fourier transform," in *Proc. of the 28th IEEE EMBS Annual Int. Conf.*, pp. 4803-4806, Aug. 2006.
- [19] J. West, et al., "Comparison and evaluation of retrospective intermodality image registration techniques," *SPIE Proc. on Medical Imaging: Image Processing*, vol. 2710, pp. 332-347, 1996.
- [20] A. Roche, G. Malandain, X. Pennec, and N. Ayache, "The correlation ratio as a new similarity measure for multimodal image registration," in *Proc. 1st Int. Conf. on Medical Image Computing and Computer-Assisted Intervention, MICCAI'98*, vol. 1496, pp. 1115-1124, 1998.
- [21] R. W. K. So and A. C. S. Chung, "Learning-based multi-modal rigid image registration by using Bhattacharyya distances," in *Proc. 33rd*



شکل ۸: میانگین خطای TRE تطبیق برای ۴ بیمار تست.



شکل ۹: مقایسه دقت تطبیق با استفاده از معیار مشابهت نرخ همبستگی.

پیشنهادی از مقدار بیشینه بالاتری از نرخ همبستگی نسبت به سایر روش‌ها برخوردار است.

۶- نتیجه‌گیری

در این مقاله، روش جدیدی به منظور تطبیق تصاویری که در طول زمان ثابت و بدون تغییر شکل هستند اما از نظر تصویربرداری با حسگرهای تصویربرداری مختلفی به دست آمده‌اند و دارای رزولوشن‌های متفاوتی هستند، ارائه شد. در روش پیشنهادی از آنجایی که تصاویر پزشکی با رزولوشن‌های پایین و متفاوت هستند، به جای استفاده مستقیم از شدت تصاویر برای محاسبه تناظر مکانی، تصاویر با استفاده از مقادیر فرکانس تطبیق داده شدند. به منظور تجزیه فرکانس تصاویر، با توجه به خواص مهمی که درباره درخت دوتایی تبدیل موجک مختلط ذکر گردید از این تبدیل در ۴ سطح تجزیه استفاده شد. نتایج نشان داد که در تجزیه درخت دوتایی تبدیل موجک مختلط، ضمن حفظ اطلاعات بامعنی تصویر، تناظریابی نقاط در سطح فرکانس راحت‌تر بوده و تأثیر عوامل خارجی از قبیل نویز و سایر اعوجاج‌های حاصل از تصویربرداری بر روی تصویر نادیده گرفته می‌شود. از طرف دیگر به منظور کاهش مینی‌م‌های محلی و بالابردن نرخ همگرایی، یادگیری پارامترهای تبدیل با استفاده از شبکه عصبی در سطوح مختلف رزولوشن پیشنهاد شد. به این صورت که جای جستجوی تکراری در فضای تصویر، از یک مدل یادگیرنده در چند سطح رزولوشن استفاده می‌شود و بر خلاف سایر روش‌های مبتنی بر یادگیری که با یادگیری معیار مشابهت بین تصاویر، پارامترهای تبدیل بهینه را به دست می‌آورد، روش پیشنهادی، پارامترهای تبدیل را تا زمانی که به یک مقدار بیشینه سراسری همگرا شود، یاد می‌گیرد. نتایج نشان می‌دهد که متوسط نرخ یادگیری در حالتی که تصاویر در چند سطح رزولوشن تجزیه می‌گردند نسبت به حالتی که یادگیری در یک سطح است، بیشتر می‌باشد. از آنجایی که برای یک تصویر با مقیاس بزرگ، نیاز به مقداردهی اولیه نبوده و سطوح بالاتر از اطلاعات سطوح پایین‌تر برای تطبیق تصویر استفاده می‌کنند و تطبیق تصاویر به صورت سلسله‌مراتبی در چند سطح صورت می‌پذیرد، این مسأله عامل مؤثری در جلوگیری از افتادن الگوریتم در مینی‌م‌های محلی بوده که بر افزایش دقت روش ارائه‌شده افزوده و

محمدرضا کیوان پور دوره‌ی کارشناسی خود را در سال ۱۳۷۶ در رشته‌ی مهندسی کامپیوتر (نرم‌افزار) در دانشگاه علم و صنعت به پایان رساند. همچنین مدرک کارشناسی ارشد خود را در رشته‌ی مهندسی کامپیوتر (نرم‌افزار) در سال ۱۳۷۹ و مدرک دکترای خود را در سال ۱۳۸۶ در رشته‌ی مهندسی کامپیوتر (نرم‌افزار) از دانشگاه تربیت مدرس اخذ کرد. وی هم‌اکنون به عنوان عضو هیات علمی دانشکده‌ی فنی و مهندسی دانشگاه الزهرا مشغول به فعالیت است. زمینه‌های علمی مورد علاقه‌ی وی پردازش تصویر و داده‌کاوی است.

Annual Int. Conf. of the IEEE on Biomedical Imaging: from Nano to Macro, pp. 368-371, Boston, Massachusetts, US, 2011.

- [22] D. L. Collins and A. P. Zijdenbos, "Design and construction of a realistic digital brain phantom," *IEEE Trans. Med. Img.*, vol. 17, no. 3, pp. 463-468, Jun. 1998.
- [23] C. A. Cocosco, V. Kollokian, R. K. S. Kwan, G. Bruce Pike, and A. C. Evans, "BrainWeb: online interface to a 3D MRI simulated brain database," *NeuroImage*, vol. 5, no. 4, 1997.

سیده سمیه آل حجت خستمخی دوره کارشناسی خود را در سال ۱۳۸۶ در رشته‌ی مهندسی کامپیوتر (نرم افزار) در دانشگاه آزاد اسلامی واحد لاهیجان به پایان رساند. همچنین مدرک کارشناسی ارشد خود را در رشته‌ی مهندسی کامپیوتر (نرم‌افزار) در سال ۱۳۹۲ از دانشگاه آزاد اسلامی واحد قزوین اخذ کرد. زمینه‌های علمی مورد علاقه‌ی وی پردازش تصویر و داده‌کاوی است.