

روشی نوین در طبقه‌بندی مقاوم به نوفه

تصاویر بافتی با استفاده از توصیف چندمقیاسه

توآمان الگوی دودویی محلی

سید محمد رضا جلالیان شهری^۱، هادی هادی‌زاده^۲، مرتضی خادمی^{۳*} و عباس ابراهیمی‌مقدم^۴

^{۱،۳و۴} گروه مهندسی برق، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

^۲ گروه مهندسی برق، دانشکده مهندسی، دانشگاه صنعتی قوچان، قوچان، ایران

چکیده

نخستین گام در طبقه‌بندی تصاویر بافتی، توصیف بافت با استفاده از استخراج ویژگی‌های تصویری مختلف از آن است. تاکنون روش‌های متعددی برای این موضوع توسعه یافته‌اند که از جمله مشهورترین آن‌ها می‌توان به روش الگوی دودویی محلی اشاره کرد. به منظور استخراج اطلاعات بافتی در مقیاس‌های مختلف، روش الگوی باینری محلی را می‌توان در یک چهارچوب چندمقیاسه پیاده‌سازی کرد. در این حالت، بردارهای ویژگی به دست آمده در سطوح مقیاس مختلف به یکدیگر پیوست می‌شوند تا یک بردار ویژگی برآیند با طول بیشتر را تولید کند؛ اما چنین روشی دو عیب مهم دارد؛ نخست این که، روش الگوی دودویی محلی به شدت نسبت به نوفه حساس و با افزودن نوفه به تصویر بافتی، بردارهای ویژگی به دست آمده ممکن است به شدت تغییر کنند. دوم این که، با افزایش تعداد مقیاس‌ها، طول بردار ویژگی به دست آمده نیز افزایش می‌یابد که این امر ضمن کاهش سرعت فرآیند طبقه‌بندی بافت، ممکن است دقت طبقه‌بندی را نیز کاهش دهد. برای رفع و یا کاهش این دو عیب، در این مقاله، روشی مبتنی بر الگوی دودویی محلی چندمقیاسه پیشنهاد می‌شود که از مقاومت بهتری در مقابل نوفه سفید گوسی برخوردار و در عین حال، طول بردار ویژگی تولیدی به وسیله آن به طور دقیق برابر با طول بردار ویژگی تولیدی به وسیله روش اصلی الگوی دودویی محلی در حالت تک‌مقیاسه است. آزمایش‌ها بر روی چهار گروه از پایگاه داده Outex انجام شده که آزمایش‌های انجام گرفته نشان‌دهنده برتری روش پیشنهادی نسبت به روش‌های موجود مشابه است.

واژگان کلیدی: استخراج ویژگی، الگوی دودویی محلی، بافت، طبقه‌بندی بافت، نوفه سفید گوسی.

A Novel Noise-Robust Texture Classification Method Using Joint Multiscale LBP

Seyed Mohammad Reza Jalalian Shahri¹, Hadi Hadizadeh², Morteza Khademi^{3*} & Abbas Ebrahimi-Moghadam⁴

^{1,3,4}Department of Electrical Engineering, Faculty of Engineering, Ferdowsi University of Mashhad, Mashhad, Iran.

²Department of Electrical Engineering, Faculty of Engineering, Quchan University of Technology, Quchan, Iran.

Abstract

In this paper we describe a novel noise-robust texture classification method using joint multiscale local binary pattern. The first step in texture classification is to describe the texture by extracting different features. So far, several methods have been developed for this topic, one of the most popular ones is Local Binary Pattern (LBP) method and its variants such as Completed Local Binary Pattern, Extended Local Binary Pattern, Local Temporary Pattern, Local Contrast Pattern, etc. In order to extract the features of a texture in different scales, the LBP method can be implemented in a multi-scale framework. For this purpose, the extracted feature vectors at different scales are usually concatenated together to produce the final feature vector with a longer length. But such a scheme has two main

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۰ شماره ۴ پیاپی ۵۰

تاریخ ارسال مقاله: ۱۳۹۷/۰۸/۱۵ • تاریخ پذیرش: ۱۴۰۰/۱۰/۱۸ • تاریخ انتشار: ۱۴۰۰/۱۲/۲۹ • نوع مطالعه: پژوهشی



shortcomings. First, the LBP method is very sensitive to noise, hence by adding noise to a texture image, its feature vectors may change significantly. Second, by increasing the number of the scales, the length of the final feature vector is increased accordingly. This action increases the classification process time, and it may reduce the classification accuracy. To mitigate these shortcomings, this paper presents a method based on multiscale LBP, which has a better resistance against white Gaussian noise, while the length of its final feature vector is equal to the length of the final feature vector produced by the original LBP method. To implement the proposed method, we used 17 circular binary masks that contain 8 directed first-order masks, 8 directed second-order masks and 1 undirected mask. These masks have positive and negative weightes and each group of these masks have different radius which after convolution with input image extract features in different scales. Experiments were performed on four test groups of Outex database. Experimental results show that the proposed method is superior to the existing state-of-the-art methods. The complexity of proposed method is also analyzed. The results show that in this method, despite obtaining excellent classification accuracy, the complexity of the method has not changed much and even its complexity is less than some of the existing state-of-the-art methods.

Keywords: feature extraction, Local Binary Pattern, texture, texture classification, white gaussian noise


۱- مقدمه

تکرار منظم یک عنصر تصویری در پردازش تصویر به عنوان بافت شناخته می شود. طبیعت اطراف ما سرشار از تصاویر بافت است. سطح قابل مشاهده هر شیء یک تصویر بافت است. بافت به طور معمول به صورت صاف یا زمخت، نرم یا سخت، مات یا براق و غیره توصیف می شود. تصویر بافت یا ناحیه ای را که دارای بافت خاص در تصویر است می توان با کمک تغییرات شدت روشنایی و یا رنگ آن ها شناسایی کرد [1]. تجزیه و تحلیل های مختلفی بر روی تصاویر بافتی قابل انجام است. دو مورد از پرکاربردترین این تجزیه و تحلیل ها، بخش بندی تصاویر بافت^۱ و طبقه بندی تصاویر بافتی^۲ است. در بخش بندی تصاویر بافت، هر تصویر باید شامل چندین بافت مختلف و الگوریتم باید توانایی تفکیک و تشخیص بافت های مختلف را داشته باشد و بتواند مرزهای بافت های مختلف را به خوبی شناسایی کند که با طبقه بندی تصاویر بافت متفاوت است. در طبقه بندی تصاویر بافتی، هر تصویر تنها شامل یک بافت است. و پایگاه داده شامل تصاویر بافتی مختلف است و الگوریتم باید توانایی جداسازی تصاویر بافتی یکسان و قراردادن آن ها در یک دسته مجزا را داشته باشد. در این مقاله تمرکز ما بر روی طبقه بندی تصاویر بافتی است. طبقه بندی بافت ها نیز به فرایند انتصاب یک بافت ناشناخته به یک مجموعه شناخته شده از دسته بافت گفته می شود. از کاربردهای طبقه بندی بافت ها می توان به سنجش از راه دور، تشخیص الگو، تصویربرداری پزشکی و بازرسی صنعتی اشاره کرد. گام نخست در طبقه بندی تصاویر بافتی، استخراج ویژگی های مناسب از آن ها است. برای این منظور، در دهه های گذشته، روش های متعددی

جهت استخراج ویژگی از تصاویر بافت توسعه یافته اند. از جمله مهم ترین آن ها می توان به تبدیلات فرکانسی مختلف همانند تبدیل موجک [2, 3]، بانک فیلترهای گابور [4, 5]، ماتریس هم رخداد سطوح خاکستری [6-8] و خانواده الگوی دودویی محلی [9-14] اشاره کرد.

یکی از مشهورترین و پرکاربردترین این روش ها، الگوی باینری محلی (LBP) است [12]. در LBP، هر یک از همسایگی های محلی تصویر ورودی بر اساس میزان شدت روشنایی پیکسل موجود در مرکز همسایگی تبدیل به یک کد دودویی می شوند؛ سپس، معادل دهدهی کد حاصله به عنوان یک برجسپ برای توصیف آن همسایگی استفاده می گردد.

بدین صورت، به هریک از ریزساختارهای موجود در تصویر بافتی ورودی (گوشه ها، خطوط مستقیم و مورب، حفره ها، خال ها و غیره) یک کد دهدهی اختصاص داده می شود. پس از آن، نمودار انباشتگی کدهای حاصله محاسبه شده و از آن به عنوان یک بردار ویژگی جهت توصیف آماری تصویر بافت ورودی استفاده می شود. در شکل (۱) نمونه هایی از همسایگی دایره ای با شعاعها (R) و تعداد همسایگی های (P) مختلف حول پیکسل مرکزی مشاهده می شود.



(شکل-۱): نمونه های همسایگی های دایره ای مختلف (۸، ۱)،

(۱۲، ۲/۵) و (۱۶، ۴) برای LBP

(Figure-1): The circular (8, 1), (12, 2.5) and (16, 4) neighborhoods for LBP.

¹ texture segmentation


² texture classification

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i)\} \quad (2)$$

$$i = 0, 1, \dots, P-1$$

که در آن، نماد ri بیان‌گر این است که عمل‌گر نسبت به چرخش حساس نیست. در عمل‌گر ROR ، عمل چرخش به سمت راست روی عدد دودویی P بیتی i بار انجام شده و کمینه اعداد به‌دست‌آمده به‌ازای i های بین 0 تا $P-1$ به‌عنوان الگوهای دودویی محلی انتخاب می‌شوند. با چرخش تصویر، نقاطی که در همسایگی در نظر گرفته شده‌اند با توجه به شکل همسایگی‌ها، روی محیط دایره دوران می‌کنند؛ بنابراین با استفاده از رابطه (۲)، عمل‌گر $LBP_{P,R}^{ri}$ نسبت به چرخش مقاوم می‌شود.

روش LBP جهت طبقه‌بندی تصاویر نسبت به نوفه بسیار حساس است؛ چرا که فقط با تغییر یک نمونه از همسایگان، ممکن است کد LBP به‌صورت فاحشی تغییر کند. از طرفی استفاده از مقیاس‌های مختلف در LBP محدودیت‌هایی دارد که در ادامه در مورد آن توضیح داده خواهد شد. این ایرادات موجب شد تا مطالعات مختلفی جهت بهبود روش الگوی باینری محلی انجام شود. چند نمونه از مهم‌ترین روش‌هایی که برای ارتقای عملکرد LBP ارائه شده‌اند، در شکل (۳) مشاهده می‌شوند؛ که در ادامه به شرح مختصر هر یک از این روش‌ها می‌پردازیم.



(شکل-۳): مدل مفهومی روش‌های توضیح داده شده در مقاله
(Figure-3): The conceptual model of the methods described in this paper

در شکل بهبودیافته LBP، معیاری به نام میزان همگنی یا یک‌نواختی تعریف می‌شود [15] که نشان‌دهنده تعداد جهش‌ها از صفر به یک و یک به صفر در کد دودویی تولیدی توسط الگوی دودویی محلی است. بنا به تعریف، الگوهایی که میزان یک‌نواختی آن‌ها (U) حداکثر برابر با U_T باشد، به‌عنوان الگوهای یک‌نواخت یا همگن تعریف می‌شوند. الگوی دودویی محلی در شکل جدید به‌صورت رابطه (۳) تعریف می‌شود:


در نسخه اولیه این روش، الگوهای دودویی محلی در یک همسایگی از تصویر به‌صورت رابطه (۱) تعریف می‌شوند:

$$LBP_{P,R} = \sum_{n=0}^{P-1} S(g_n - g_c) 2^n \quad (1)$$

$$S(x) = f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

که در آن، P نشان‌دهنده تعداد نقاط همسایه حول پیکسل مرکزی است. شدت روشنایی پیکسل‌های همسایه با g_n و شدت روشنایی پیکسل مرکزی با g_c نشان داده شده است. پیکسل‌های همسایه به فاصله R از پیکسل مرکزی قرار دارند. S نیز تابع علامت است.

نحوه عملکرد عمل‌گر LBP در شکل (۲) مشاهده می‌شود. همان‌طور که در شکل مشخص است، پس از انتخاب همسایگی‌ها دور پیکسل مرکزی، از یک نقطه شروع کرده و تمامی پیکسل‌های همسایه با پیکسل مرکزی مقایسه می‌شوند؛ بدین صورت که اگر مقدار آن‌ها از پیکسل مرکزی بزرگ‌تر یا مساوی باشد، مقدار ۱ و اگر کوچک‌تر از آن باشد، مقدار صفر به جای پیکسل همسایه قرار می‌گیرد؛ درنهایت همه این اعداد را کنار هم گذاشته و عدد دودویی P بیتی به‌دست می‌آید؛ سپس این عدد دودویی به عدد دهدهی تبدیل شده و به جای پیکسل مرکزی قرار می‌گیرد. کد به‌دست‌آمده همان کد LBP پیکسل مرکزی است. این عمل برای تمامی پیکسل‌های تصویر تکرار شده، و کد LBP تمامی ریزساختارهای تصویر محاسبه می‌شود. در رابطه (۱)، $LBP_{P,R}$ به‌نحوه اندیس‌گذاری پیکسل‌های موجود در همسایگی وابسته است.



(شکل-۲): مثالی از عملکرد عمل‌گر LBP

(Figure-2): An example illustrating the operation of the basic LBP operator

برای مقاوم‌کردن الگوی دودویی محلی نسبت به چرخش، با شیفت چرخشی عدد دودویی به‌دست‌آمده (از مقایسه پیکسل‌های همسایه و پیکسل مرکزی) و انتخاب کمینه مقدار ممکن طبق رابطه (۲) عمل می‌شود:

$$CLBP_M_{P,R} = \sum_{n=0}^{P-1} T(m_P, c) 2^n \quad (4)$$

$$T(x, c) = \begin{cases} 1, & x \geq c \\ 0, & x < c \end{cases}$$

که در آن T یک مقایسه‌کننده است، m_P تفاضل پیکسل‌های همسایه از پیکسل مرکزی و c مقدار متوسط تمام m_P ها است.

CLBP-C نیز به وسیله رابطه (۵) محاسبه می‌شود:

$$CLBP_C_{P,R} = \sum_{n=0}^{P-1} T(g_c, c) 2^n \quad (5)$$

در این رابطه، c بیان‌گر متوسط کل پیکسل‌های موجود در تصویر و پیکسل‌های مرکزی است. در نهایت اطلاعات بدست‌آمده از علامت، دامنه و پیکسل مرکزی با روش‌های مختلف با یکدیگر ترکیب شده و ویژگی‌های نهایی حاصل می‌شوند. عمل طبقه‌بندی نیز بر روی همین ویژگی‌ها انجام می‌شود. براساس نتایج و مشاهدات انجام‌شده در [9]، این روش از دقت طبقه‌بندی قابل قبولی برخوردار است.

در [11] روشی ارائه شد که بر خلاف LBP فقط رابطه بین پیکسل مرکزی با همسایه‌های آن مشخص می‌شود، بتواند رابطه مکانی پیکسل‌ها را در یک ناحیه محلی مشخص کند. این روش که $ELBP^2$ نامگذاری شده، دربرگیرنده اطلاعات مکانی بیش‌تری خواهد بود. $ELBP$ شامل سه توصیف‌گر شبه LBP به نام‌های $ELBP-CI$ ، $ELBP-NI$ و $ELBP-RD$ است که استخراج‌کننده اطلاعات از شدت پیکسل مرکزی و پیکسل‌های همسایه آن هستند. استراتژی این روش تقریباً مشابه LBP است. به عنوان مثال رابطه $ELBP_CI$ به صورت رابطه (۶) است:

$$ELBP_CI_{P,R}(x_c) = S(x_c - \beta) \quad (6)$$

که در آن s تابع علامت بوده و β متوسط تمام پیکسل‌های تصویر به عنوان آستانه و x_c پیکسل مرکزی است. اگر به جای مقدار آستانه در رابطه بالا از متوسط پیکسل‌های همسایه برای تولید دنباله باینری استفاده شود، $ELBP-NI$ به وسیله رابطه (۷) قابل محاسبه است:

$$ELBP_NI_{P,R}(x_c) = \sum_{n=0}^{P-1} S(x_{P,R,n} - \beta_{P,R}) 2^n \quad (7)$$

که $\beta_{P,R}$ متوسط پیکسل‌های همسایه در شعاع R و تعداد همسایگی P است. برای $ELBP_RD$ ، پیکسل‌های همسایه با پیکسل‌های همان موقعیت و در شعاعی به اندازه یک

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{n=0}^{P-1} S(g_n - g_c) 2^n, & U \leq U_T \\ P + 1, & otherwise \end{cases} \quad (3)$$

همان‌گونه که از رابطه (۳) مشاهده می‌شود؛ الگوهای دودویی محلی، که همگنی آن‌ها کوچکتر از مقدار U_T است به کدهای بین ۰ تا $P-1$ و به سایر الگوها کد $P+1$ تخصیص داده می‌شود. در صورت چرخش تصویر، با توجه به اینکه همسایگی به صورت دایروی در نظر گرفته شده است، نقاط موجود در همسایگی نیز روی محیط دایره حرکت می‌کنند؛ بنابراین شکل بهبودیافته این روش نیز نسبت به چرخش تصویر حساس نیست. در نهایت تعداد $P+2$ کد حاصل می‌شود. با مرتب‌کردن این کدها به صورت برداری، یک بردار ویژگی از طول $P+2$ حاصل می‌شود که از آن می‌توان به عنوان بردار ویژگی استفاده کرد. استفاده از الگوهای یکنواخت به جای تمامی الگوهای موجود، موجب ایجاد نتایج بهینه در بسیاری از کاربردها شده است. از طرفی در بسیاری از مقالات شواهدی وجود دارد که نشان‌دهنده پایدارتر بودن الگوهای یکنواخت است. برای مثال می‌توان به مقاومت بیشتر این الگوها نسبت به نوفه اشاره کرد. از طرفی تنها استفاده از الگوهای یکنواخت، تعداد کدهای LBP حاصله را به طور قابل توجهی کاهش می‌دهد و موجب کاهش پیچیدگی در مراحل بعدی طبقه‌بندی می‌شود. از بین معیارهای یکنواختی معتدده، الگوی $riu2$ از لحاظ کارایی و سرعت و تعداد کم ویژگی‌ها یکی از مناسب‌ترین الگوها است.

برخلاف وجود بیشترین اطلاعات تصویر در علامت بردار تفاضل پیکسل‌های مرکزی و پیکسل‌های همسایه، دامنه این بردار و همچنین خود پیکسل‌های مرکزی به تنهایی حاوی اطلاعات مفیدی هستند که اگر به درستی مورد استفاده قرار گیرند، می‌توانند موجب بهبود طبقه‌بندی شوند.

الگوی دودویی محلی کامل ($CLBP^1$) [9] برخلاف سایر روش‌ها که فقط از علامت تفاضل الگوی دودویی استفاده می‌کنند، هم از علامت ($CLBP-S$) و هم از اندازه این تفاضل ($CLBP-M$) استفاده می‌کند. ضمن این‌که اطلاعات پیکسل مرکزی ($CLBP-C$) هم مورد استفاده قرار می‌گیرد.

$CLBP-S$ که حاوی اطلاعات علامت بردار تفاضل است، مشابه رابطه (۱) به دست می‌آید. $CLBP-M$ نیز با کمک رابطه (۴) محاسبه می‌شود:

² Extended LBP

¹ Completed LBP

$$\sum_{(u,v) \in F^{j,d}} f^{j,d}(u,v)I(u,v)$$

که در آن $F^{j,d}$ مجموعه ماسک ورودی است که مرکز آن بر روی پیکسل (x,y) قرار دارد. در این صورت، $f^{j,d}(u,v)$ وزن پیکسلی از ماسک $F^{j,d}$ است که در موقعیت (u,v) آن ماسک حضور دارد. همان‌گونه که اشاره شد، وزن‌های ماسک‌ها دو مقدار مثبت و منفی به خود می‌گیرند که با f^+ و f^- نمایش داده می‌شوند. در صورتی که $F^{j+,d}$ قسمتی از ماسک با وزن مثبت و $F^{j-,d}$ قسمت دیگر آن با وزن منفی باشد، رابطه (۱۱) به صورت زیر بازنویسی می‌شود:

$$g^{j,d}(x,y) = f^+ \sum_{(u,v) \in F^{j+,d}} I(u,v) + f^- \sum_{(u,v) \in F^{j-,d}} I(u,v) \quad (12)$$

این خروجی‌ها، همان الگوهای شدت محلی هستند؛ سپس هر کدام از این تصاویر را که در خروجی ماسک‌ها قرار دارند، با هم مقایسه کرده و بیشینه مقدار آن‌ها انتخاب می‌شود. درنهایت با استفاده از تصاویر به‌دست‌آمده جدید و تصاویر خروجی ضرب‌شده در مرحله قبل، الگوی روشنایی محلی استخراج می‌شود؛ سپس هیستوگرام هر کدام از این الگوها استخراج شده و در کنار هم قرار گرفته و برای طبقه‌بندی استفاده می‌شوند. صحت طبقه‌بندی تصاویر درحالی‌که تصاویر ورودی آغشته به نوفه شوند، در این روش بهبود پیدا می‌کند. در این مقاله تلاش شده تا روش LCP به گونه‌ای بهبود یابد، تا ضمن استفاده از اطلاعات تصویر در مقیاس‌های مختلف به‌صورت هم‌زمان، طول بردار ویژگی نسبت به حالت تک‌مقیاسه ثابت بماند.

۲- روش پیشنهادی

همان‌گونه که در بخش قبل بیان شد، روش LBP دارای معایبی از جمله حساسیت زیاد نسبت به نوفه است. LBP یک‌نواخت تا حدودی این مشکل را با قراردادن کدهای غیریکنواخت و نوفه‌ای در یک انبار هیستوگرام حل کرده است؛ اما این روش نیز ممکن است برای تصاویر با لبه‌های نامنظم و اشکال پیچیده مفید واقع نشود. از طرفی روش‌های مبتنی بر LBP برای توصیف بافت در چندمقیاس، به‌طورمعمول هیستوگرام ویژگی‌ها را در مقیاس‌های متفاوت بدست‌آورده و سپس نتایج حاصله به یکدیگر ملحق می‌شوند تا یک بردار ویژگی برآیند به‌دست

واحد کمتر مقایسه می‌شوند که درنهایت رابطه (۸) به‌دست می‌آید:

$$ELBP_RD_{P,R,R-1}(x_c) = \sum_{n=0}^{P-1} S(x_{P,R,n} - x_{P,R-1,n})2^n \quad (8)$$

در [13] عملگر سه‌بعدی تحت عنوان الگوی محلی سه‌تایی (LTP^1) پیشنهاد شد که با مشکل موجود در نواحی ثابت عکس، مرتبط بود. در رمزگشایی سه‌بعدی، اختلاف بین پیکسل مرکزی و یک پیکسل همسایه براساس یک آستانه توسط سه مقدار (۱، ۰ یا -۱) کد می‌شود. الگوی سه‌تایی براساس اجزای مثبت و منفی آن‌ها به دو الگوی دوتایی تقسیم می‌شود؛ سپس هیستوگرام‌های این اجزا به یکدیگر ملحق می‌شوند.

در [14] مدل جدیدی به نام الگوی کنتراست محلی (LCP^2) ارائه شد که هدف آن، کم‌کردن حساسیت زیاد LBP نسبت به نوفه است. این مدل شامل سه قسمت محاسبه شدت کنتراست محلی، تولید الگوی روشنایی محلی و متصل‌کردن هیستوگرام‌های به‌دست‌آمده از مراحل قبل است. در این روش سه نوع ماسک دودویی تعریف می‌شود. ماسک‌های مرتبه اول، ماسک‌های مرتبه دوم و یک ماسک کلی که تصویر این ماسک‌ها در شکل (۴) مشاهده می‌شود. ماسک‌های مرتبه اول به‌صورت رابطه (۹) قابل نمایش هستند:

$$F^{j,1} = \{F^{1,1}, F^{2,1}, \dots, F^{8,1}\} \quad (9)$$

که در آن $F^{j,1}$ نشان‌دهنده ماسک j -ام ($j=1,2,\dots,8$) مرتبه اول است. ماسک‌های مرتبه دوم نیز به‌صورت رابطه (۱۰) قابل نمایش هستند:

$$F^{j,2} = \{F^{1,2}, F^{2,2}, \dots, F^{8,2}\} \quad (10)$$

که در آن $F^{j,2}$ نشان‌دهنده ماسک j -ام ($j=1,2,\dots,8$) مرتبه دوم است. ماسک بدون جهت نیز به‌صورت F^{undir} قابل نمایش است.

اگر I تصویر بافت ورودی باشد و $I(x,y)$ نمایانگر پیکسل موجود در مختصات (x,y) در I باشد، در این صورت $g^{j,d}(x,y)$ تصویر خروجی که حاصل ضرب تصویر ورودی با ماسک j -ام از مرتبه d که $d(=1,2)$ است به‌صورت زیر نشان داده می‌شود:

$$g^{j,d}(x,y) = \quad (11)$$


¹ Local Temporary Pattern

² Local Contrast Pattern

آید. در قسمت مقدمه مقاله در مورد LBP و نحوه به دست آوردن آن توضیح داده شد. در مدل استاندارد آن که ویژگی‌ها در یک مقیاس استخراج می‌شود، با توجه به شعاع و تعداد همسایگی می‌توان کدهای مختلفی استخراج کرد. به عنوان مثال $LBP_{1,8}$ و $LBP_{2,16}$ و $LBP_{3,24}$ و غیره. هر کدام از این کدهای LBP دارای ویژگی‌های منحصر به فردی هستند. به عنوان مثال $LBP_{1,8}$ ممکن است دارای اطلاعاتی باشد، که در $LBP_{2,16}$ موجود نباشد و همین‌طور برای بقیه کدها. حال اگر بهترین شعاع‌ها و بهترین همسایگی‌ها را برای الگوریتم خود به دست آورده و کدهای LBP همه آن‌ها را استخراج کرده و سپس یک بردار ویژگی را که متشکل از همه این شعاع‌ها و همسایگی‌ها می‌باشد، جهت طبقه‌بندی استخراج شود، بردار ویژگی بهبود یافته و دارای اطلاعات مفید بیشتری از مقیاس‌های مختلف تصویر است. دلیل دیگری که از مقیاس‌های مختلف جهت استخراج ویژگی استفاده می‌شود، وجود یکی از مهم‌ترین محدودیت‌ها در LBP یعنی پشتیبانی از منطقه مکانی کوچک است. به عنوان مثال ویژگی‌های به دست آمده در یک همسایگی 3×3 نمی‌توانند ساختارهای بزرگ مقیاسی را که ممکن است، ویژگی‌های غالب برخی بافت‌ها باشند، به خود بگیرند؛ بنابراین با داشتن کدها در مقیاس‌های مختلف می‌توان بهترین ویژگی‌ها را استخراج کرد که موجب بهبود دقت طبقه‌بندی شود.

اما این طرح دارای معایبی است؛ به عنوان مثال در صورتی که تعداد مقیاس‌های استفاده شده زیاد شوند، طول بردار ویژگی حاصله به طور چشم‌گیری افزایش می‌یابد. این به نوبه خود ممکن است، دقت توصیف و طبقه‌بندی تصاویر بافتی را کاهش دهد؛ چون در صورت وجود همبستگی بین ویژگی‌های حاصله، دقت طبقه‌بندی به دلیل وجود ویژگی‌های اضافه کاهش خواهد یافت. همچنین اگر تعداد ویژگی‌ها افزایش یابد، ممکن است که برای حصول به دقت طبقه‌بندی بالا، تعداد نمونه‌های آموزشی بالاتری نیاز باشد. بدیهی است که بار محاسباتی نیز با افزایش طول بردار ویژگی افزایش می‌یابد.

در روش پیشنهادی، روش‌های مشهور و شناخته شده LBP و LCP که در بخش قبل معرفی شدند؛ به گونه‌ای بهبود می‌یابد که اول این که، روش به دست آمده از مقاومت بالایی نسبت به نوفه برخوردار باشد. دوم این که، روش حاصله ضمن استفاده از اطلاعات تصویر در مقیاس‌های مختلف، دارای بردار ویژگی با طول کمینه باشد. در حقیقت، خواهیم دید که طول بردار ویژگی حاصله از روش پیشنهادی، برخلاف استفاده از مقیاس‌های مختلف برابر با طول بردار ویژگی روش LCP در یک مقیاس و در هر کدام از ماسک‌ها دقیقاً برابر با طول بردار ویژگی $LBP_{P,R}^{riu_2}$ (رابطه (۳)) خواهد شد.



(شکل-۴): ماسک‌های متفاوت استفاده شده در [14] و روش پیشنهادی. ردیف بالا، ماسک‌های مرتبه اول؛ ردیف پایین،

ماسک‌های مرتبه دوم و ماسک تکی سمت راست، ماسک بدون جهت

(Figure-4): An illustration of the directed and undirected difference masks used in the proposed method. Top row: directed first-order difference masks. Bottom row: directed second-order difference masks, right mask: undirected difference mask.

متفاوتی هستند. هر شعاع مشخص‌کننده مقیاسی است که در آن مقیاس ویژگی‌ها استخراج می‌شوند. اگر $F_{R_k}^{j,d}$ بیانگر ماسک j -ام ($j=1, \dots, 8$) مرتبه d -ام ($d=1, 2$) در شعاع (مقیاس) R_k باشد، ($k=1, \dots, K$) در این صورت برای استفاده از ماسک‌های مرتبه اول در مقیاس‌های مختلف، رابطه (۹) به صورت زیر تعریف می‌شود:

$$F_{R_k}^{j,1} = \{F_{R_k}^{1,1}, F_{R_k}^{2,1}, \dots, F_{R_k}^{8,1}\} \quad (13)$$

برای پیاده‌سازی روش پیشنهادی، ابتدا هفده ماسک دودویی با شعاع دلخواه R همانند شکل (۴) تعریف می‌شوند. در این ماسک‌ها قسمت مشکی دارای وزن منفی و قسمت سفید دارای وزن مثبت هستند؛ سپس در ادامه، تصویر ورودی با هر کدام از این ماسک‌ها پالایش^۱ (هم‌پیش) می‌شود. هر طبقه از ماسک‌ها دارای شعاع‌های

¹ Convolution

و دوم استراتژی‌های متفاوتی در نظر گرفته می‌شود که در ادامه به توضیح آن خواهیم پرداخت.

الف) ماسک‌های مرتبه اول:

پس از محاسبه رابطه (۱۷) مقادیر منفی تصاویر به‌دست‌آمده را نیز در کنار آن‌ها قرار داده تا اثرات چرخش تصویر نیز در نظر گرفته‌شوند؛ در نتیجه خواهیم داشت:

$$\hat{q}_{R_k}^j(x, y) = [q_{R_k}^j(x, y), -q_{R_k}^j(x, y)] \quad (18)$$

پس از محاسبات بالا، رابطه LBP جدید پیشنهادی که شامل مقیاس‌های مختلف جهت استخراج ویژگی می‌شود، به‌صورت رابطه (۱۹) به‌دست می‌آید:

$$NEW_LBP_{R_k}^1(x, y) = \sum_{j=1}^8 S(\hat{q}_{R_k}^j(x, y)) \quad (19)$$

که در آن S تابع علامت است. رابطه (۱۹) بیان‌گر تمامی الگوهای یک‌نواخت و غیریک‌نواخت موجود در تصویر است. جهت در نظر گرفتن الگوهای یک‌نواخت، که در مقدمه در مورد آن‌ها صحبت شد و مهم‌ترین قسمت ویژگی‌های استخراجی هستند، به‌صورت زیر عمل می‌شود:

$$NEW_LBP_{R_k}^{1,riu6}(x, y) = \begin{cases} \sum_{j=1}^8 S(\hat{q}_{R_k}^j(x, y)) & U(\hat{q}_{R_k}^j(x, y)) < 6 \\ 8 & otherwise \end{cases} \quad (20)$$

در رابطه بالا U معیار محاسبه یک‌نواختی است که به‌صورت زیر تعریف می‌شود:

$$U(\hat{q}_{R_k}^j(x, y)) = \sum_{j=0}^7 |S(\hat{q}_{R_k}^j(x, y)) - S(\hat{q}_{R_k}^{mod(j+1,7)}(x, y))| \quad (21)$$

همان‌طور که در رابطه (۲۰) مشاهده می‌شود درنهایت طول کد هیستوگرام نهایی که برخلاف استفاده از مقیاس‌های مختلف استخراج شده، ۹ است (یعنی برابر با طول هیستوگرام تولیدی توسط روش الگوی دودویی محلی استاندارد در یک مقیاس).

ب) ماسک‌های مرتبه دوم:

برای ماسک مرتبه دوم محاسبات به‌طور تقریبی مشابه ماسک مرتبه اول است؛ ولی معیار یک‌نواختی را به جای شش، دو در نظر می‌گیریم و رابطه (۲۲) حاصل می‌شود.

همچنین جهت استفاده از ماسک‌های مرتبه دوم در مقیاس‌های مختلف، رابطه (۱۰) نیز به‌صورت زیر بازنویسی می‌شود:

$$F_{R_k}^{j,2} = \{F_{R_k}^{1,2}, F_{R_k}^{2,2}, \dots, F_{R_k}^{8,2}\} \quad (14)$$

و درنهایت ماسک بدون جهت نیز به‌صورت $F_{R_k}^{undir}$ تعریف می‌شود؛ سپس تصویر ورودی در تک‌تک این ماسک‌ها هم‌پیچش و رابطه (۱۵) حاصل می‌شود:

$$g_{R_k}^{j,d}(x, y) = F_{R_k}^{j,2} \otimes I(x, y) \quad (15)$$

که در آن I تصویر بافت ورودی است و $I(x, y)$ نمایان‌گر پیکسل موجود در مختصات (x, y) در I است. $F_{R_k}^{j,d}$ مجموعه ماسک ورودی است که مرکز آن بر روی پیکسل (x, y) قرار دارد. K نشان‌دهنده تعداد مقیاس‌ها و R_k شعاع ماسک در مقیاس مورد نظر است.


پس از آن‌که تصویر ورودی I با ماسک $F_{R_k}^{j,d}$ هم‌پیچش شد، یک مقدار آستانه عمومی $T_{R_k}^{j,d}$ برای هر کدام از تصاویر خروجی $g_{R_k}^{j,d}(x, y)$ محاسبه می‌شود که از رابطه زیر به‌دست می‌آید:

$$T_{R_k}^{j,d} = \frac{1}{M} \sum_{(x,y) \in I} g_{R_k}^{j,d}(x, y) \quad (16)$$

در رابطه (۱۶) M تعداد پیکسل‌های تصویر $g_{R_k}^{j,d}(x, y)$ است. آستانه بالا همان متوسط تصویر $g_{R_k}^{j,d}(x, y)$ است؛ سپس آستانه را از حاصل هم‌پیچش به‌دست‌آمده در مقیاس‌های مختلف کم کرده و نتیجه، $q_{R_k}^{j,d}(x, y)$ نام‌گذاری می‌شود:

$$q_{R_k}^{j,d}(x, y) = \sum_{k=1}^K g_{R_k}^{j,d}(x, y) - \sum_{k=1}^K T_{R_k}^{j,d} \quad (17)$$

یکی از ایده‌های اصلی در رابطه (۱۷) آشکار می‌شود. خروجی‌های حاصل از هم‌پیچش تصویر ورودی I و ماسک‌های مورد نظر $(F_{R_k}^{j,d})$ در مقیاس‌های مختلف محاسبه و با یکدیگر جمع می‌شوند. برای آستانه $T_{R_k}^{j,d}$ نیز همین عمل در مقیاس‌های مختلف تکرار می‌شود. از کم کردن دو مقدار به‌دست‌آمده از یکدیگر می‌توان ویژگی‌ها را در تمام مقیاس‌ها به‌صورت یک‌جا و توان استخراج کرد. در نتیجه نیازی به پیوست بردارهای ویژگی در مقیاس‌های مختلف به‌صورت جداگانه نیست؛ سپس نوبت به استخراج کدهای روش پیشنهادی جهت طبقه‌بندی تصاویر می‌رسد که برای ماسک‌های مرتبه اول



(شکل-۵): نمودار گردش کار روش پیشنهادی برای ماسک‌های مرتبه اول. الف) بخش آموزش و آزمایش. ب) جزئیات بلوک استخراج

ویژگی مورد استفاده در (الف)

(Figure-5): The flowchart of the proposed method for the first-order masks. A) Training and testing parts. B) Details of the feature extraction block used in (A)

ویژگی به‌وسیله بیشینه‌گیری از تصاویر خروجی حاصل از هم‌پیش ماسک‌های مرتبه اول و دوم نیز استخراج می‌شود. بدین صورت که پس از این که بیشینه مقدار خروجی‌های حاصل از هم‌پیش تصویر ورودی و ماسک‌ها را محاسبه کردیم، با استفاده از الگوی زیر خروجی‌های مرحله قبل کد می‌شود.

$$NEW_LBP_{max}^d(x, y) = \begin{cases} 2 & q_{max}^d(x, y) > m_d + 0.5\sigma_d \\ 1 & q_{max}^d(x, y) < m_d - 0.5\sigma_d \\ 0 & \text{otherwise} \end{cases} \quad (23)$$

که در رابطه بالا، m_d میانگین و σ_d انحراف استاندارد ماتریس q_{max}^d می‌باشد. طبق رابطه (۲۳) ماتریس بیشینه به سه مقدار صفر، یک و دو نگاشت می‌شود.

معیار یک‌نواختی شش برای ماسک‌های مرتبه اول و دو برای ماسک‌های مرتبه دوم با آزمون و خطا و بر اساس نتایج حاصل از آزمایش‌های متعدد به‌دست آمده است.

$$NEW_LBP_{R_k}^{2,riu_2}(x, y) = \begin{cases} \sum_{j=1}^8 S(q_{R_k}^j(x, y)) & U(q_{R_k}^j(x, y)) < 2 \\ 9 & \text{otherwise} \end{cases} \quad (22)$$

ج) بیشینه‌گیری از خروجی ماسک‌ها:

علاوه بر هیستوگرام‌هایی که از هم‌پیش تصویر ورودی و ماسک‌های مرتبه اول و دوم به‌دست می‌آید، یک سری

(د) ماسک بدون جهت:

پس از هم‌پیچش این ماسک با تصویر ورودی، خروجی با کمک رابطه (۲۴) کد می‌شود:

$$NEW_LBP^{undir}(x, y) = \begin{cases} 2 & q^d(x, y) > m^+ \\ 1 & q^d(x, y) < m^- \\ 0 & otherwise \end{cases} \quad (24)$$

که در آن m^+ و m^- میانگین اعداد مثبت و منفی موجود در تصویر خروجی هم‌پیچش این ماسک با تصویر ورودی است.

(ه) پیوست کردن هیستوگرام‌ها:

پس از استخراج کدهای مختلف از ماسک‌های مرتبه اول و دوم و بدون جهت و همچنین ماتریس بیشینه، و تهیه هیستوگرام آن‌ها نوبت به پیوست آن‌ها به یکدیگر می‌رسد. بدین منظور ابتدا هیستوگرام‌های مربوط به ماسک بدون جهت، مرتبه اول و بیشینه این ماسک‌ها به یکدیگر پیوست می‌شوند. همچنین هیستوگرام‌های مربوط به ماسک بدون جهت، مرتبه دوم و بیشینه این ماسک‌ها نیز به‌صورت جداگانه به یکدیگر پیوست می‌گردند. درنهایت این دو هیستوگرام در کنار یکدیگر قرار گرفته و هیستوگرام نهایی را تشکیل می‌شوند؛ مراحل انجام روش پیشنهادی برای ماسک‌های مرتبه اول به‌صورت گرافیکی در شکل (۵) نشان داده شده است. توجه شود که نمودار گردش کار برای ماسک‌های مرتبه دوم به‌طور دقیق مانند نمودار گردش کار ماسک‌های مرتبه اول است؛ با این تفاوت که در بلوک دوم استخراج ویژگی به جای ماسک‌های مرتبه اول، ماسک‌های مرتبه دوم قرار می‌گیرند.

۳- نتایج شبیه‌سازی

جهت ارزیابی روش پیشنهادی، عملکرد آن را با چند روش مهم طبقه‌بندی تصاویر بافتی دیگر مقایسه کردیم. برای این منظور از پایگاه داده معتبر و استاندارد Outex [16] استفاده شده است. در آزمایش‌های انجام‌شده، هر یک از تصاویر بافتی استفاده‌شده ابتدا به سطح خاکستری تبدیل شد و همانند روند معمول استفاده‌شده در مراجع [12, 15, 17] سطح روشنایی کلیه پیکسل‌ها به اندازه ۱۲۸ واحد کاهش یافت و سپس با تقسیم مقادیر به‌دست‌آمده بر عدد ۲۰، نرمالیزه شدند. از آنجایی که در این مقاله، ارزیابی عملکرد روش‌های مختلف در مقابل نوفه گوسی مد نظر است، به تصاویر به‌دست‌آمده یک نوفه گوسی با میانگین

صفر و SNR مشخص بر حسب dB اضافه شد. همانند مراجع [12, 15, 17]، برای محاسبه میزان شباهت بین دو هیستوگرام، از معیار فاصله χ^2 و برای طبقه‌بندی از طبقه‌بند نزدیک‌ترین همسایه برای بررسی میزان صحت طبقه‌بندی و مقایسه با روش‌های دیگر استفاده شده است.

۳-۱- معرفی پایگاه داده Outex

پایگاه داده Outex دارای چندین زیرمجموعه (گروه) است که چهار زیرمجموعه به نام‌های TC10، TC11، TC12 و TC13 در این مقاله مورد استفاده قرار گرفته است. تصاویر موجود در این زیرمجموعه‌ها تحت سه سطح روشنایی مختلف به نام‌های ("horizon"، "inca" و "t184") و ۹ جهت متفاوت (۰، ۵، ۱۰، ۱۵، ۳۰، ۴۵، ۶۰، ۷۵ و ۹۰ درجه) جمع‌آوری شده‌اند. در ادامه به توصیف هر یک از این چهار گروه می‌پردازیم:

(۱) گروه TC10: تصاویر بافتی موجود در این گروه، جهت انجام آزمایش‌های سنجش میزان مقاومت به چرخش تصاویر بافتی طراحی شده که شامل ۲۴ طبقه و هر طبقه شامل بیست نمونه که تحت زوایای مختلف تهیه شده‌اند؛ است. همانند روال معمول استفاده‌شده در مقالات مشابه که از این گروه برای انجام آزمایش‌ها استفاده کرده‌اند، تعداد 20×24 تصویر با زاویه صفر درجه به‌عنوان نمونه‌های آموزشی و $24 \times 20 \times 8$ تصویر باقی‌مانده به‌عنوان تصاویر آزمون مورد استفاده قرار می‌گیرند.

(۲) گروه TC11: این پایگاه داده شامل ۹۶۰ تصویر متفاوت است که مشابه مقالات پیشین، ۴۸۰ تصویر آن برای آموزش و ۴۸۰ تصویر دیگر آن جهت آزمون مورد استفاده قرار می‌گیرند. این که کدام تصویر برای آموزش استفاده می‌شود و کدام یک برای آزمون، در پایگاه داده مشخص شده است.


(۳) گروه TC12: این پایگاه داده، شامل ۲۴ طبقه و ۹۱۲۰ تصویر بافتی متفاوت تحت ۹ زاویه متفاوت و سطوح روشنایی "horizon" و "t184" است. مشابه مقالات پیشین، تصاویر با جهت صفر درجه به‌عنوان تصاویر آموزشی و سایر تصاویر به‌عنوان تصاویر آزمون مورد استفاده قرار می‌گیرند.

(۴) گروه TC13: این گروه شامل ۶۸ طبقه بافتی است که هر طبقه شامل بیست تصویر است. مشابه مقالات پیشین، ده تصویر از هر طبقه این پایگاه داده به‌عنوان تصاویر آموزشی و بقیه تصاویر به‌عنوان تصاویر آزمایشی مورد استفاده قرار می‌گیرند.

بسیاری از مقالات معتبر در دوحالت بدون نوفه و نوفه‌ای در چهار سطح نویز گوسی مختلف (SNR=5, 10, 15, 30 dB) ارائه شده‌اند. به‌طور خاص، در جداول (۱)، (۳)، (۴) و (۵) عملکرد روش پیشنهادی با حالات مختلف چهار روش رقیب LBP, CLBP, LTP و LCP مقایسه شده است. برای سه روش LBP, CLBP و LTP مقایسه به‌ازای شعاع‌های (R=1,2,3) در حالت استفاده از الگوهای یک‌نواخت مقاوم به چرخش (riu_2) انجام شده که در هر حالت، تعداد پیکسل‌های موجود در هر همسایگی برابر با $8 \times R$ است. برای روش LTP، آستانه مربوطه برابر با ۵ در نظر گرفته شده است. برای روش LCP دو شعاع (R=4,5) و دو نوع معیار یکنواختی re و riu_2 جهت مقایسه در نظر گرفته شده است. در جدول (۵) علاوه بر روش‌های قبل، روش پیشنهادی با دو روش دیگر [17] LDDTP و [18] BM3DELBP مقایسه شده‌اند. در این جداول، روش پیشنهادی با نام NEW_LBP مشخص شده است.

از نتایج ارائه شده در جدول (۱)، مشاهده می‌شود که بر روی پایگاه TC10، در حالت بدون نوفه سه روش برتر به ترتیب $CLBP^{riu_2}$ (R=3, p=24)، $CLBP^{riu_2}$ (R=2, p=16) و روش پیشنهادی هستند. در این حالت، همان‌طور که مشاهده می‌شود، دقت طبقه‌بندی روش پیشنهادی نسبت به روش برتر تنها ۰/۱۸۹ درصد پایین‌تر است. همچنین، مشاهده می‌شود که در این حالت بدترین روش جهت طبقه‌بندی، LBP^{riu_2} (R=1, p=8) است. در سطوح نوفه‌ای با SNR=5 تا SNR=15 مشاهده می‌شود که روش LCP^{riu_2} (R=5) بهترین عملکرد و پس از آن، روش پیشنهادی با دقت اندکی پایین‌تر در رتبه دوم قرار دارد. درحقیقت، میزان افت دقت روش پیشنهادی نسبت به روش برتر در سطوح نویزی مختلف بین ۰/۱۵ تا ۱/۵۳ درصد است. همچنین مشاهده می‌شود که با افزایش سطح نویز از ۳۰dB به ۵dB، در کلیه روش‌ها دقت طبقه‌بندی تصاویر بافتی کاهش می‌یابد که قابل انتظار است.


در جدول (۲)، نتایج مقایسات بر روی پایگاه داده TC11 ارائه شده است. در این پایگاه داده، در حالت بدون نوفه سه روش برتر عبارت‌اند از: $CLBP^{riu_2}$ (R=3, p=24)، روش پیشنهادی و در نهایت $CLBP^{riu_2}$ (R=2, p=16). مشاهده می‌شود روش پیشنهادی با افت ۲/۹۳ درصدی در جایگاه دوم قرار دارد. در این حالت نیز LBP^{riu_2} (R=1, p=8) دارای کمترین دقت طبقه‌بندی است. در این جدول و در حالت نوفه‌ای مشاهده می‌شود که روش پیشنهادی در تمامی سطوح نوفه‌ای بهترین دقت



(شکل-۶): نمونه‌هایی از ۲۴ طبقه بافتی مختلف از

پایگاه داده Outex

(Figure-6): Examples of 24 different textures from the Outex database



(شکل-۷): نمونه‌هایی از تصاویر پایگاه داده OutexTC10 سطر نخست تصاویر بدون نوفه. سطر دوم و سوم تصاویر آغشته به نوفه گاوسی با SNRهای ۳۰ و ۱۰ دسی‌بل

(Figure-7): Examples of OutexTC10 database

images. First row shows examples of no-noise images. The second and third rows show example images with Gaussian noise with SNRs of 30 and 10 dB

نمونه‌هایی از تمامی طبقه‌های پایگاه داده Outex در شکل (۶) نشان داده شده است. همچنین، در شکل (۷)، نمونه‌هایی از تصاویر گروه TC10 به‌صورت بدون نوفه و درحالی‌که به آن‌ها نوفه سفید گوسی با SNRهای ده و سی دسی‌بل اضافه شده، نشان داده شده است.

۳-۲- نتایج آزمایش‌ها

در جداول (۱) تا (۵) نتایج حاصل از اعمال روش‌های مختلف طبقه‌بندی تصاویر بافتی بر روی هر یک از چهار گروه استفاده شده از پایگاه داده Outex و طبق روال

قرار دارد. میزان برتری روش پیشنهادی نسبت به روش LCP^{riu_2} ($R=5$) در سطوح مختلف نوفه‌ای بین ۳۰dB تا ۵dB بین ۰/۸۳ تا ۳/۹۶ درصد است.

طبقه‌بندی را دارد. دوباره، این نتایج نشان می‌دهند که روش پیشنهادی از مقاومت به نوفه بسیار خوبی در مقایسه با سایر روش‌ها بر روی این پایگاه داده برخوردار است. پس از روش پیشنهادی، روش LCP^{riu_2} ($R=5$) در جایگاه دوم

(جدول-۱): نتایج آزمایش‌های انجام داده شده بر روی پایگاه داده OutexTC10
(Table-1): Classification accuracy of various methods (%) on the OutexTC10 database

روش	OutexTC10				
	بدون نویز	30	15	10	5
LBP^{riu_2} ($R=1, p=8$)	84.81	32.65	21.95	14.42	9.53
LBP^{riu_2} ($R=2, p=16$)	89.40	65.00	40.74	31.28	14.84
LBP^{riu_2} ($R=3, p=24$)	95.08	74.28	52.24	35.63	16.33
LTP^{riu_2} ($R=1, p=8$)	94.14	41.04	25.65	18.05	9.53
LTP^{riu_2} ($R=2, p=16$)	96.95	71.09	49.14	34.90	18.70
LTP^{riu_2} ($R=3, p=24$)	98.20	81.15	59.19	43.15	20.26
$CLBP^{riu_2}$ ($R=1, p=8$)	96.56	73.93	50.44	35.31	15.78
$CLBP^{riu_2}$ ($R=2, p=16$)	98.72	84.79	62.53	45.55	22.63
$CLBP^{riu_2}$ ($R=3, p=24$)	98.93	87.94	66.95	47.50	20.57
LCP^{re} ($R=4$)	95.65	94.48	90.05	83.93	64.51
LCP^{re} ($R=5$)	96.93	95.29	92.08	88.91	71.30
LCP^{riu_2} ($R=4$)	97.63	95.60	91.54	86.56	69.56
LCP^{riu_2} ($R=5$)	98.65	96.90	94.30	91.64	80.10
NEW_LBP ($R_1=5.8, R_2=6$)	98.741	96.406	93.854	90.105	79.948

(جدول-۲): نتایج آزمایش‌های انجام داده شده بر روی پایگاه داده OutexTC11
(Table-2): Classification accuracy of various methods (%) on the OutexTC11 database

روش	OutexTC11				
	بدون نویز	30	15	10	5
LBP^{riu_2} ($R=1, p=8$)	29.38	29.38	17.92	13.33	7.62
LBP^{riu_2} ($R=2, p=16$)	47.92	47.92	35.42	28.33	14.17
LBP^{riu_2} ($R=3, p=24$)	55.83	55.83	42.71	27.92	16.25
LTP^{riu_2} ($R=1, p=8$)	87.29	33.54	20.63	13.75	9.58
LTP^{riu_2} ($R=2, p=16$)	86.88	58.54	38.33	29.58	18.75
LTP^{riu_2} ($R=3, p=24$)	90.00	61.46	48.54	32.50	15.21
$CLBP^{riu_2}$ ($R=1, p=8$)	93.96	65.83	45.42	32.92	16.88
$CLBP^{riu_2}$ ($R=2, p=16$)	94.79	80.00	62.50	44.58	22.92
$CLBP^{riu_2}$ ($R=3, p=24$)	97.50	77.92	57.92	39.38	17.50
LCP^{re} ($R=4$)	83.90	82.21	80.00	72.92	55.42
LCP^{re} ($R=5$)	87.71	84.38	79.79	71.88	56.67
LCP^{riu_2} ($R=4$)	93.75	87.71	80.42	76.04	61.46
LCP^{riu_2} ($R=5$)	92.29	87.71	84.58	81.46	65.21
NEW_LBP ($R_1=5.8, R_2=6$)	94.58	89.17	85.63	82.29	69.17

(جدول-۳): نتایج آزمایش‌های انجام داده شده بر روی پایگاه داده "OutexTC12-t184"
(Table-3): Classification accuracy of various methods (%) on the Outex TC12-"t184" database

روش	OutexTC12-"t184"				
	بدون نویز	30	15	10	5
LBP^{riu_2} ($R=1, p=8$)	65.46	28.01	19.86	15.46	9.58
LBP^{riu_2} ($R=2, p=16$)	82.27	59.49	40.42	29.86	13.08
LBP^{riu_2} ($R=3, p=24$)	85.05	69.28	47.87	34.05	16.25
LTP^{riu_2} ($R=1, p=8$)	75.88	34.75	22.46	16.16	10.02
LTP^{riu_2} ($R=2, p=16$)	90.16	65.63	46.74	33.26	17.45
LTP^{riu_2} ($R=3, p=24$)	93.59	75.72	53.61	38.03	20.05
$CLBP^{riu_2}$ ($R=1, p=8$)	90.30	65.53	44.38	32.52	14.47
$CLBP^{riu_2}$ ($R=2, p=16$)	93.54	78.47	59.79	44.24	21.46
$CLBP^{riu_2}$ ($R=3, p=24$)	95.32	82.59	63.40	45.76	21.39
LCP^{re} ($R=4$)	88.91	89.21	85.44	79.19	58.47
LCP^{re} ($R=5$)	91.64	90.67	86.90	82.66	69.58
LCP^{riu_2} ($R=4$)	94.12	90.49	86.69	80.41	65.48
LCP^{riu_2} ($R=5$)	96.18	92.59	89.21	84.65	74.00
NEW_LBP ($R_1=5.8, R_2=6$)	96.3	93.22	89.22	85.185	73.333

همان‌طور که مشاهده می‌شود، در حالت بدون نوفه، روش پیشنهادی دارای بالاترین دقت بوده و سه روش برتر

در جدول (۳) عملکرد روش‌های مختلف بر روی پایگاه داده "t184"-TC12 با یکدیگر مقایسه شده است.

در جدول (۴) عملکرد روش‌های مختلف بر روی پایگاه داده "horizon"-TC12 مورد بررسی قرار گرفته است. در این پایگاه داده روش پیشنهادی در حالت بدون نوفه با ۵۱٪ درصد اختلاف نسبت به روش $LCP^{riu_2}(R=5)$ و با ۳/۰۸ درصد اختلاف نسبت به روش $LCP^{riu_2}(R=4)$ در جایگاه اول از لحاظ دقت طبقه‌بندی قرار دارد. در این حالت روش $LBP^{riu_2}(R=1, p=8)$ دارای کمترین دقت طبقه‌بندی است. در حالت نوفه‌ای، همانند جدول (۴)، به‌ازای SNRهای ۳۰dB، ۱۵dB و ۵dB روش پیشنهادی نسبت به تمامی روش‌های دیگر از دقت بالاتری برخوردار است و پس از آن روش $LCP^{riu_2}(R=5)$ با افتی بین ۰/۳۲ تا ۰/۹۱ درصد در جایگاه دوم قرار دارد. به‌ازای SNR=5dB نیز مشاهده می‌شود که روش پیشنهادی با افت ناچیز ۰/۰۴ درصدی در جایگاه دوم قرار دارد.

به‌ترتیب عبارت‌اند از: روش پیشنهادی، $LCP^{riu_2}(R=5)$ و $CLBP^{riu_2}(R=3, p=24)$. روش پیشنهادی در این حالت به میزان ۰/۱۲ درصد نسبت به LCP و به میزان ۲/۰۲ درصد نسبت به CLBP برتری دارد. در این حالت مشاهده می‌شود، بدترین روش جهت طبقه‌بندی $LBP^{riu_2}(R=1, p=8)$ است. در حالت نوفه‌ای نیز مشاهده می‌گردد که در سطوح SNR ۳۰dB، ۱۵dB و ۵dB روش پیشنهادی نسبت به تمامی رقبا از دقت بالاتری برخوردار است و پس از آن روش $LCP^{riu_2}(R=5)$ در جایگاه دوم قرار دارد. میزان برتری روش پیشنهادی نسبت به LCP در این سه سطح SNR به‌ترتیب ۰/۷۴ درصد، ۰/۰۱ درصد و ۵۳۴ درصد است. بر خلاف سه سطح SNR یادشده، به‌ازای SNR = 5dB مشاهده می‌شود که روش پیشنهادی با افت ناچیز ۰/۶۶۷ درصدی پس از $LCP^{riu_2}(R=5)$ در جایگاه دوم قرار دارد.

(جدول-۴): نتایج آزمایش‌های انجام داده‌شده بر روی پایگاه داده "horizon"-OutexTC12

(Table-4): Classification accuracy of various methods (%) on the Outex TC12-"horizon" database

روش	OutexTC12-"horizon"				
	بدون نویز	30	15	10	5
$LBP^{riu_2}(R=1, p=8)$	63.68	31.41	21.09	16.02	9.24
$LBP^{riu_2}(R=2, p=16)$	75.21	56.46	38.63	26.24	14.19
$LBP^{riu_2}(R=3, p=24)$	80.79	67.64	47.06	34.51	17.18
$LTP^{riu_2}(R=1, p=8)$	73.96	37.52	24.17	17.18	10.69
$LTP^{riu_2}(R=2, p=16)$	86.94	66.55	44.88	33.17	17.94
$LTP^{riu_2}(R=3, p=24)$	89.42	76.39	55.02	39.54	19.24
$CLBP^{riu_2}(R=1, p=8)$	92.29	71.44	49.49	36.09	17.20
$CLBP^{riu_2}(R=2, p=16)$	93.91	81.16	63.96	46.99	23.15
$CLBP^{riu_2}(R=3, p=24)$	94.54	84.38	64.51	45.00	20.67
$LCP^{re}(R=4)$	92.31	91.06	86.48	82.06	60.37
$LCP^{re}(R=5)$	94.62	92.62	88.47	84.35	70.56
$LCP^{riu_2}(R=4)$	94.77	91.62	87.26	81.74	67.13
$LCP^{riu_2}(R=5)$	97.34	93.49	90.07	86.57	75.07
NEW_LBP ($R_1=5.8, R_2=6$)	97.85	93.91	90.39	87.48	75.023

(جدول-۵): نتایج آزمایش‌های انجام داده‌شده بر روی پایگاه داده OutexTC13

(Table-5): Classification accuracy of various methods (%) on the OutexTC13 database

روش	OutexTC13				
	بدون نویز	30	15	10	5
$LBP^{riu_2}(R=1, p=8)$	68.38	18.53	11.76	10.59	6.32
$LBP^{riu_2}(R=2, p=16)$	75.88	39.26	29.85	22.35	15.59
$LBP^{riu_2}(R=3, p=24)$	75.00	46.32	36.18	28.24	16.91
$LTP^{riu_2}(R=1, p=8)$	81.18	35.00	24.41	18.52	13.24
$LTP^{riu_2}(R=2, p=16)$	82.94	47.94	36.03	27.50	17.79
$LTP^{riu_2}(R=3, p=24)$	82.94	56.03	41.18	33.24	20.00
LDDTP($R=1$)	80.32	59.23	48.35	37.44	29.58
$CLBP^{riu_2}(R=1, p=8)$	84.62	50.88	40.29	31.47	19.71
$CLBP^{riu_2}(R=2, p=16)$	85.29	54.12	44.56	37.65	21.62
$CLBP^{riu_2}(R=3, p=24)$	85.59	56.91	44.26	37.06	20.59
$LCP^{re}(R=4)$	75.59	67.21	60.00	53.97	43.97
$LCP^{re}(R=5)$	71.32	65.44	57.21	53.53	46.47
$LCP^{riu_2}(R=4)$	80.29	70.00	61.76	58.82	49.26
$LCP^{riu_2}(R=5)$	78.68	71.03	64.12	58.09	48.97
BM3DELB	82.82	70.31	63.84	42.11	38.22
NEW_LBP ($R_1=5.8, R_2=6$)	78.68	73.82	66.62	62.76	52.21

دارای پردازشگر Intel(R) Core(TM) i7-7700CPU @ 360GHZ و حافظه رم GB32 است. همان‌طور که مشاهده می‌شود، برخلاف بهبود بسیار مناسب دقت دسته‌بندی در روش پیشنهادی، میزان پیچیدگی آن نسبت به روش‌های LBP و LTP افزایش داشته است که با توجه به سرعت زیاد LBP که از مهم‌ترین مزیت‌های آن است قابل پیش‌بینی نیز بود. روش پیشنهادی نسبت به روش‌های CLBP و LCP دقت و سرعت بالاتری را دارد.

۴- نتیجه‌گیری

در این مقاله روشی مقاوم به نوفه و چرخش جهت توصیف و طبقه‌بندی تصاویر بافتی بر مبنای الگوی دودویی محلی (LBP) چندمقیاسه ارائه شد. از مزایای روش پیشنهادی استخراج ویژگی‌های بافتی در مقیاس‌های مختلف به‌صورت توأمان است؛ به‌نحوی که طول بردار (هیس‌توگرام) ویژگی نهایی به‌دست‌آمده از هر ماسک به‌وسیله آن به‌طور دقیق برابر با طول بردار (هیس‌توگرام) ویژگی به‌دست‌آمده به‌وسیله روش اصلی LBP در حالت تک‌مقیاسه است. جهت ارزیابی روش پیشنهادی، عملکرد آن را بر روی چهار پایگاه داده OutexTC10, OutexTC11, OutexTC12 و OutexTC13 در سطوح مختلف نوفه سفید گوسی و همچنین در حالت بدون نوفه با چهار روش رقیب دیگر (LBP, LTP, LCP و CLBP) ارزیابی کردیم. نتایج تجربی به‌دست‌آمده، نشان دادند که بر روی پایگاه داده OutexTC10 روش پیشنهادی قابل رقابت با روش رقیب LCP است و با اُفتی بسیار ناچیز در جایگاه دوم قرار دارد. بر روی پایگاه‌های داده OutexTC11 و OutexTC13 در سطوح مختلف نوفه، روش پیشنهادی روش برتر بوده و بهترین دقت طبقه‌بندی را در بین روش‌های مقایسه‌شده دارد. بر روی پایگاه داده OutexTC12 نیز روش پیشنهادی در هر دو حالت نوفه‌ای و بدون نوفه روش برتر بوده و دارای دقت خوبی جهت طبقه‌بندی تصاویر بافتی است. همچنین، به‌طور کلی مشاهده شد که در مجموع، روش پیشنهادی در مقایسه با سایر روش‌ها به‌خصوص هنگامی که تصویر مورد نظر آغشته به نوفه شود، از دقت و کارایی بالایی برخوردار است. همچنین پیچیدگی روش‌های مختلف بر روی پایگاه داده OutexTC13 مورد سنجش قرار گرفت. نتایج حاصله در این آزمایش‌ها نشان‌دهنده عدم افزایش قابل توجه پیچیدگی روش پیشنهادی در مقابل افزایش قابل توجه دقت دسته‌بندی است. این نتایج در صورتی حاصل شد که در روش پیشنهادی، از ماسک‌های متفاوت مرتبه اول و دوم جهت ایجاد مقاومت

به‌طور کلی، با مشاهده نتایج ارائه‌شده در جداول (۳) و (۴) مشاهده می‌شود که روش پیشنهادی بر روی پایگاه داده TC12 در هر دو حالت نوفه‌ای و غیر نوفه‌ای از دقت طبقه‌بندی بالاتری نسبت به تمامی رقبا برخوردار است و تنها به‌ازای SNR=5dB قابل رقابت با روش پیشنهادی بر روی این پایگاه داده است.

در نهایت، در جدول (۵) عملکرد روش پیشنهادی با سایر روش‌ها بر روی پایگاه داده TC13 مورد مقایسه قرار گرفته است. در این پایگاه داده همان‌طور که مشاهده می‌شود، در حالت بدون نوفه‌ای روش پیشنهادی نسبت به روش برتر در حد ۶/۹ درصد پایین‌تر است. در این حالت بدترین روش نیز روش پیشنهادی است. برخلاف حالت بدون نوفه، هنگامی که به تصاویر نوفه سفید گوسی اعمال گردد، روش پیشنهادی از تمامی رقبا عملکرد بهتری از خود نشان می‌دهد که این امر نشان‌دهنده مقاومت به نوفه بالای روش پیشنهادی بر روی این پایگاه داده می‌باشد. پس از روش پیشنهادی، LCP^{riu2} (R=5) دومین روش برتر است که دقت آن بین ۲/۵ تا ۴/۶۷ درصد پایین‌تر از روش پیشنهادی در سطوح مختلف نوفه‌ای است.

(جدول ۶-): مقایسه پیچیدگی روش‌های متفاوت (دقیقه) در

پایگاه داده OutexTC13

(Table-2): Classification complexity of various methods (min) on the OutexTC13 database

روش	زمان
$(R=3, p=24)LBP^{riu2}$	0.134
$(R=3, p=24)LTP^{riu2}$	0.148
$(R=3, p=24)CLBP^{riu2}$	0.346
$(R=5)LCP^{riu2}$	0.601
$(R1=5.8, R2=6)NEW_LBP^{riu}$	0.214

در ادامه انجام آزمایش‌ها بر روی روش پیشنهادی، میزان پیچیدگی روش‌های مختلف در پایگاه داده OutexTC13 مورد بررسی قرار گرفت که نتیجه آن در جدول (۶) مشاهده می‌شود. نتایج نشان‌دهنده در این جدول میانگین مدت زمان ده بار اجرای برنامه در زمان‌های مختلف بر حسب دقیقه است. سیستمی که جهت شبیه‌سازی و اجرای کدها مورد استفاده قرار گرفته،

- [11] L. Liu, L. Zhao, Y. Long, G. Kuang, and P. Fieguth, "Extended local binary patterns for texture classification," *Image and Vision Computing*, vol. 30, pp. 86-99, 2012.
- [12] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern recognition*, vol. 29, pp. 51-59, 1996.
- [13] X. Tan and B. Triggs, "Enhanced local texture feature sets for face recognition under difficult lighting conditions," *IEEE transactions on image processing*, vol. 19, pp. 1635-1650, 2010.
- [14] T. Song, H. Li, F. Meng, Q. Wu, B. Luo, B. Zeng, et al., "Noise-robust texture description using local contrast patterns via global measures," *IEEE Signal Processing Letters*, vol. 21, pp. 93-96, 2014.
- [15] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 24, pp. 971-987, 2002.
- [16] T. Ojala, T. Maenpaa, M. Pietikainen, J. Viertola, J. Kyllonen, and S. Huovinen, "Outex-new framework for empirical evaluation of texture analysis algorithms," in *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, 2002, pp. 701-706.
- [17] J. He, H. Ji, and X. Yang, "Rotation invariant texture descriptor using local shearlet-based energy histograms," *IEEE Signal Processing Letters*, vol. 20, pp. 905-908, 2013.
- [18] I. El khadiri, A. Chahi, Y. El-Merabet, Y. Ruichek and R. Touahni, "Image classification with Local Directional Decoded Ternary Pattern," *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*, 2019, pp. 812-817,
- [19] S. R. Barburiceanu, S. Meza, C. Germain and R. Terebes, "An Improved Feature Extraction Method for Texture Classification with Increased Noise Robustness," *2019 27th European Signal Processing Conference (EUSIPCO)*, 2019, pp. 1-5



سید محمدرضا جلالیان شهری در سال ۱۳۹۲ مقطع کارشناسی خود را در رشته مهندسی برق مخابرات در دانشگاه بیرجند به پایان رسانده است. وی هم‌اکنون دانشجوی کارشناسی ارشد در همان رشته (گرایش سیستم) در دانشگاه فردوسی مشهد است. پژوهش‌های مورد علاقه ایشان در زمینه پردازش تصویر و بینایی ماشین است. نشانی رایانامه ایشان عبارت است از:

jalalianshahri@mail.um.ac.ir

به نوبه استفاده شده بود و همچنین ویژگی‌ها در مقیاس‌های مختلف استخراج شده بودند. به‌عنوان کار آینده قصد داریم تا روش پیشنهادی را به‌گونه‌ای بهبود دهیم که در مقابل سایر نوبه‌ها نیز از مقاومت بالایی برخوردار باشد و همچنین قصد داریم تا روشی جهت یافتن خودکار شعاع بهینه جهت افزایش دقت طبقه‌بندی روش پیشنهادی طراحی کنیم.

5- References

۵- مراجع

- [1] M. Pietikäinen, A. Hadid, G. Zhao, and T. Ahonen, *Computer vision using local binary patterns* vol. 40: Springer Science & Business Media, 2011.
- [2] Y. Dong, J. Feng, L. Liang, L. Zheng, and Q. Wu, "Multiscale sampling based texture image classification," *IEEE Signal Processing Letters*, vol. 24, pp. 614-618, 2017.
- [3] V.-L. Nguyen, N.-S. Vu, and P.-H. Gosselin, "A scattering transform combination with local binary pattern for texture classification," in *International Workshop on Content-based Multimedia Indexing*, 2016.
- [4] F. Bianconi and A. Fernández, "Evaluation of the effects of Gabor filter parameters on texture classification," *Pattern Recognition*, vol. 40, pp. 3325-3335, 2007.
- [5] J. Oh, S.-I. Choi, C. Kim, J. Cho, and C.-H. Choi, "Selective generation of Gabor features for fast face recognition on mobile devices," *Pattern Recognition Letters*, vol. 34, pp. 1540-1547, 2013.
- [6] P. Cavalin, L. Oliveira, A. Koerich, and A. Britto, "Wood defect detection using grayscale images and an optimized feature set," in *IEEE Industrial Electronics, IECON 2006-32nd Annual Conference on*, 2006, pp. 3408-3412.
- [7] P. R. Cavalin, M. N. Kapp, J. Martins, and L. E. Oliveira, "A multiple feature vector framework for forest species recognition," in *Proceedings of the 28th Annual ACM Symposium on Applied Computing*, 2013, pp. 16-20.
- [8] R. M. Haralick and K. Shanmugam, "Textural features for image classification," *IEEE Transactions on systems, man, and cybernetics*, pp. 610-621, 1973.
- [9] Z. Guo, L. Zhang, and D. Zhang, "A completed modeling of local binary pattern operator for texture classification," *IEEE Transactions on Image Processing*, vol. 19, pp. 1657-1663, 2010.
- [10] L. Liu, S. Lao, P. W. Fieguth, Y. Guo, X. Wang, and M. Pietikäinen, "Median robust extended local binary pattern for texture classification," *IEEE Transactions on Image Processing*, vol. 25, pp. 1368-1381, 2016.

هادی هادی‌زاده مدرک کارشناسی و



کارشناسی ارشد برق در گرایش الکترونیک خود را به‌ترتیب از دانشگاه صنعتی شاهرود در سال ۱۳۸۴ و دانشگاه علم و صنعت ایران در سال

۱۳۸۷ اخذ کرده است. وی مدرک دکترای خود را در رشته برق گرایش مخابرات از دانشگاه Simon Fraser کانادا در سال ۱۳۹۲ دریافت کرده و از همان سال به‌عنوان استادیار در دانشگاه صنعتی قوچان فعالیت می‌کند. زمینه‌های پژوهشی مورد علاقه ایشان پردازش و فشرده‌سازی تصاویر و ویدیوهای دیجیتال، شبکه‌های مخابراتی، بینایی و آموزش ماشین، بازشناسی الگو و مدل‌سازی سیستم بینایی مغز انسان است. دکتر هادی‌زاده از سال ۲۰۰۹ تاکنون، موفق به کسب ۲۲ عنوان و افتخار علمی مختلف از دانشگاه‌های داخلی و بین‌المللی شده است. ازجمله آنها می‌توان به کسب عنوان بهترین مقاله در کنفرانس بین‌المللی IEEE-ICME2012 در ملبورن استرالیا، دریافت گرنت Microsoft Research و Canon Information Systems Research Australia (CiSRA) و دریافت عنوان بهترین مقاله کنفرانس بین‌المللی مهندسی برق در دانشگاه تهران اشاره کرد. در سال ۲۰۱۳ نیز به‌عنوان دبیر اجرایی IEEE Signal Processing Society در حوزه ونکوور کانادا فعالیت کرده‌اند. ایشان تجربه کاری در شرکت‌های بین‌المللی همچون Icron Technologies و Dolby Laboratories را دارد.

نشانی رایانامه ایشان عبارت است از:

h.hadizadeh@qiet.ac.ir

مرتضی خادمی تحصیلات خود را در



مقاطع کارشناسی و کارشناسی ارشد مهندسی برق به‌ترتیب در سال‌های ۱۳۶۴ و ۱۳۶۶ در دانشگاه صنعتی اصفهان به پایان رسانده است. نامبرده از

سال ۱۳۶۶ الی ۱۳۷۰ به‌عنوان عضو هیأت علمی (مربی) در دانشگاه فردوسی مشهد به کار مشغول بود. پس از آن به دوره دکترای مهندسی برق در دانشگاه ولونگونگ (استرالیا) وارد شده و در سال ۱۳۷۴ موفق به دریافت درجه دکترا در مهندسی برق از دانشگاه یادشده، شد. دکتر خادمی از سال ۱۳۷۴ دوباره در دانشکده مهندسی دانشگاه فردوسی مشهد مشغول به فعالیت شد و اینک نیز استاد این دانشکده است. زمینه‌های علمی مورد علاقه

نامبرده شامل موضوعاتی مانند مخابرات ویدئویی، فشرده‌سازی ویدئو، پردازش تصویر، پردازش سیگنال‌های پزشکی و پنهان‌سازی اطلاعات در ویدئو است. نشانی رایانامه ایشان عبارت است از:

khademi@um.ac.ir

عباس ابراهیمی‌مقدم مدرک



کارشناسی برق گرایش الکترونیک خود را از دانشگاه صنعتی شریف در سال ۱۳۷۰ و در سال ۱۳۷۴ مدرک کارشناسی‌ارشد را از دانشگاه صنعتی

خواجه نصیر دریافت کرده است. ایشان مدرک دکترای خود را از دانشگاه McMaster کانادا دریافت کرده‌اند و از سال ۱۳۹۰ به‌عنوان استادیار در دانشگاه فردوسی مشهد فعالیت علمی می‌کنند. زمینه‌های پژوهشی مورد علاقه ایشان پردازش گفتار، پردازش تصویر و ویدئو، بینایی ماشین و پردازش سیگنال‌های حیاتی است.

نشانی رایانامه ایشان عبارت است از:

a.ebrahimi@um.ac.ir

