

# طبقه‌بندی تصاویر بافتی نويزدار با استفاده از شبکه عصبی عمیق و الگوی دودویی محلی کامل

جواد آسليمی ضامنجانى<sup>۱</sup>، محمدحسین شکور<sup>۲</sup>، محسن رحمانی<sup>۳</sup>

## چکیده:

الگوی دودویی محلی یک توصیفگر پرکاربرد در استخراج ویژگی از تصاویر بافتی است. شبکه‌های عصبی عمیق کانولوشن نیز از بهترین ابزار طبقه‌بندی با دقت بسیار بالا به شمار می‌رود. نوآوری اول این پژوهش ارائه یک ساختار برای ترکیب ویژگی‌های الگوی دودویی محلی و شبکه عصبی عمیق کانولوشن برای طبقه‌بندی تصاویر بافتی نويزدار است که دقت بسیار بالایی را برای طبقه‌بندی تصاویر بافتی نويزدار فراهم می‌کند. این روش از دو ابزار استخراج ویژگی تشکیل شده است. در یک ابزار، با استفاده از الگوی دودویی محلی کامل ویژگی‌های محلی تصاویر بافتی، در قالب هیستوگرام سه بعدی استخراج می‌شود. در ابزار دوم ویژگی‌های بافتی با استفاده از شبکه عصبی عمیق کانولوشن DenseNet-121 کاهش داده می‌شود. این بخش که در فرآیند ترکیب ویژگی‌ها بکارگرفته شده است، با استفاده از شبکه عصبی کانولوشن کم عمق، ابعاد هیستوگرام سه بعدی را، برای ترکیب با ویژگی‌های عمیق، به صورت قابل توجهی کاهش می‌دهد. دقت مدل پیشنهادی، روی مجموعه‌های داده نويزی Outex، CUReT و UIUC با نويز گوسی، نويز نقطه‌ای و نويز فلفل نمکی با شدتهای مختلف، ارزیابی شده است و دقت طبقه‌بندی روش پیشنهادی برای مقادیر مختلف نويز، بهبودی بین ۳ تا ۱۵ درصد داشته است.

## کلیدواژه‌ها

طبقه‌بندی تصاویر بافتی، تصاویر بافتی نويزدار، شبکه عصبی عمیق، الگوی دودویی محلی

## ۱ مقدمه

تجزیه و تحلیل بافت از اوایل دهه ۷۰ مورد توجه محققان قرار گرفته است و در طول سال‌های گذشته با موفقیت در تعداد زیادی از وظایف حوزه بینایی رایانه، مانند ناحیه‌بندی تصاویر، طبقه‌بندی تصاویر، فشرده سازی تصاویر و ویدیو، بازیابی تصاویر بر اساس محتوا استفاده شده است [۱]. بافت<sup>۱</sup> یک ویژگی اساسی ظاهر تمام سطوح طبیعی است و در سرتاسر تصاویر طبیعی وجود دارد و تجزیه و تحلیل بافت یکی از بخش‌های مهم سیستم‌های بینایی ماشین است. یک سیستم بینایی ماشین باید بتواند به خوبی با دنیای بافت پیرامون خود روبه‌رو شود [۲، ۳]. استخراج ویژگی

این مقاله در تیرماه ۱۴۰۰ دریافت، در شهریورماه بازنگری و در مهرماه همان سال پذیرفته شد.

<sup>۱</sup> دانشجوی کارشناسی ارشد نرم افزار، دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه اراک، اراک، ایران.

رایانامه: [javad.asalimi@gmail.com](mailto:javad.asalimi@gmail.com)

<sup>۲</sup> دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه اراک، اراک، ایران  
رایانامه: [mh-shakoor@araku.ac.ir](mailto:mh-shakoor@araku.ac.ir)

<sup>۳</sup> دانشکده فنی و مهندسی، گروه مهندسی کامپیوتر، دانشگاه اراک، اراک، ایران  
رایانامه: [m-rahmani@araku.ac.ir](mailto:m-rahmani@araku.ac.ir)

<sup>1</sup> Texture

تعداد ویژگی‌های استخراج شده در این روش برابر با  $2^p$  است. یکی از مشکلات روش الگوی دودویی محلی اولیه، ابعاد بالای بردار ویژگی است. مشکل دیگر این روش حساسیت به چرخش است. اوجالا و همکاران [۱۳] الگوهای دودویی محلی "یکنواخت" را به عنوان ویژگی‌های اساسی بافت محلی تصویر معرفی کردند و با استفاده از آن یک روش غیرحساس به تغییر شدت روشنایی و چرخش<sup>۱۱</sup> برای طبقه‌بندی بافت ارائه کردند.

الگوی دودویی محلی دارای انواع نمونه‌های توسعه یافته است که ویژگی‌هایی را از بافت تصاویر استخراج می‌کنند که قدرت تفکیک‌پذیری بیشتری دارند. ژيو و همکاران الگوی دودویی محلی کامل<sup>۱۲</sup> (CLBP) [۱۴] را ارائه کردند که در آن فقط از علامت<sup>۱۳</sup> تفاضل الگوی دودویی استفاده نشده بلکه هم از علامت تفاضل (CLBP\_S) و هم از اندازه<sup>۱۴</sup> تفاضل (CLBP\_M) استفاده شده است. این روش با ترکیب اطلاعات نقطه مرکزی (CLBP\_C) به عنوان مؤلفه سوم به دقت بالایی در طبقه‌بندی بافت دست یافته است. این روش تاکنون از بین دهها روش مختلف ارائه شده بهترین دقت را ارائه کرده است. ژائو و همکاران [۱۵] روش الگوی دودویی محلی شمارشی کامل<sup>۱۵</sup> (CLBC) را ارائه کردند که برای استخراج ویژگی، بدون توجه به همگن یا ناهمگن بودن الگوها، فقط از تعداد یک‌های کد دودویی محلی استفاده کرده است.

یک مشکل اصلی در عملگرهای محلی حساسیت به نويز است و الگوی دودویی محلی نیز دارای همین مشکل است. روش‌های الگوی دودویی محلی مختلفی برای مقاوم سازی در برابر نويز ارائه شده است. لیائو و همکاران [۱۶] روشی به نام الگوهای دودویی محلی غالب<sup>۱۶</sup> (DLBP) ارائه کردند که در آن فقط به الگوهای همگن توجه نشده بلکه فارغ از همگن یا ناهمگن بودن الگوها، به فراوانی آنها توجه شده است. تن و همکاران [۱۷] روشی برای تشخیص چهره در معرض نور کنترل نشده ارائه دادند که از یک توصیفگر قدرتمند بافت محلی به نام الگوی سه تایی محلی<sup>۱۷</sup> (LTP) تشکیل شده است. LTP الگوی دودویی محلی را به کدهایی با سه مقدار توسعه داده است. این روش با تعیین یک پارامتر آستانه  $t$  که مقدار آن توسط کاربر مشخص می‌شود، روش مقایسه با پیکسل مرکزی را به نحوی تغییر داده که مقاومت آن در برابر نويز افزایش یافته است. روش‌های دیگری نیز مانند ILBP [۱۸] ارائه شده که در آن بجای نقطه مرکزی از میانگین کل نقاط هر همسایگی استفاده شده است. شکور و تاجری پور [۴] روشی به نام الگوی آنتروپی محلی ارائه کردند که نسبت به چرخش و

از بافت و طبقه‌بندی آن به دلیل وجود تعداد زیاد طبقات بافت‌های طبیعی و پویایی‌های مربوط به هر طبقه (مثل تغییرات در دوره تناوب، جهت گیری الگوها و تصادفی بودن آنها) یک مسأله پیچیده است. علاوه بر این، پویایی‌های خارجی نیز پیچیدگی این مسأله را افزایش می‌دهد. منظور از پویایی خارجی، تنوع ناشی از تغییر در شرایط تصویربرداری، مانند تغییر در روشنایی<sup>۱</sup>، چرخش<sup>۲</sup>، زاویه دید<sup>۳</sup>، مقیاس<sup>۴</sup> و نويز است [۳]. ضمن این که بسیاری از روشهای پیش پردازش نیز به راحتی قابل اعمال به بافت نیست و ممکن است منجر به از دست رفتن داده‌های اصلی بافت شود [۴]. پردازش تصاویر هوایی و ماهواره‌ای [۵، ۶] برای طبقه‌بندی کاربری اراضی مناطق مختلف و همچنین بررسی وضعیت توسعه شهری، سنجش از دور، کنترل کیفیت اتوماتیک، پردازش تصاویر پزشکی [۷، ۸] و آشکارسازی عیوب بافتی [۹] تنها تعدادی از کاربردهای پردازش و تجزیه و تحلیل بافت تصاویر است.

رویکردهای تجزیه و تحلیل بافت بسیار متنوع هستند و عمدتاً به وسیله روش‌های استخراج ویژگی، از یکدیگر متمایز می‌شوند. روش‌های استخراج ویژگی بافت به چهار دسته تقسیم می‌شوند: (۱) روشهای آماری<sup>۵</sup>، (۲) روشهای ساختاری<sup>۶</sup>، (۳) روشهای مبتنی بر مدل<sup>۷</sup> و (۴) روشهای مبتنی بر تبدیل<sup>۸</sup> (یا مبتنی بر پردازش فرکانس) [۱۰]. در میان این روش‌ها بیشترین کاربرد را روش‌های آماری به خود اختصاص داده‌اند [۴، ۱۰]. از جمله روش‌های مهم آماری برای استخراج ویژگی بافت، روش‌های ماتریس هم‌رخدادی<sup>۹</sup> و الگوی دودویی محلی<sup>۱۰</sup> (LBP) است [۴].

روش‌های مختلف الگوی دودویی محلی به عنوان یکی از برجسته‌ترین روش‌های استخراج ویژگی بافت ظاهر شده‌اند و انواع متعددی از الگوی دودویی محلی برای طیف متنوعی از مسائل از جمله طبقه‌بندی بافت، تشخیص بافت پویا، تطبیق تصاویر، بازرسی بصری، بازیابی تصاویر ارائه شده است [۳]. الگوی دودویی محلی نخستین بار توسط اوجالا و همکاران [۱۱] معرفی شد. در مدل ابتدایی الگوی دودویی محلی با مقایسه مقدار هر پیکسل با پیکسل‌های مجاور در یک همسایگی مربعی  $3 \times 3$  و در نظر گرفتن علامت مقایسه، یک کد دودویی محلی را برای هر پیکسل ایجاد می‌شد [۱۲] و این کد برای توصیف ساختار محلی بافت تصویر بکار می‌رفت [۳]. اگر تعداد نقاط همسایگی  $P$  باشد،

<sup>1</sup> Illumination

<sup>2</sup> Rotation

<sup>3</sup> View Point

<sup>4</sup> Scale

<sup>5</sup> Statistical Methods

<sup>6</sup> Structural Methods

<sup>7</sup> Model-Based Methods

<sup>8</sup> Transform-Based Methods

<sup>9</sup> Co-occurrence Matrix

<sup>10</sup> Local Binary Pattern

<sup>11</sup> Invariance to Rotation and Illumination

<sup>12</sup> Completed Local Binary Pattern

<sup>13</sup> Sign

<sup>14</sup> Magnitude

<sup>15</sup> Completed Local Binary Count

<sup>16</sup> Dominant Local Binary Patterns

<sup>17</sup> Local Ternary Pattern

قابل استفاده هستند. چندین مجموعه داده تصویری مقیاس بزرگ برای پیش آموزش این شبکه ها استفاده می شود که مهمترین آنها مجموعه داده ImageNet [۲۶] است. لایه های کانولوشن، که به عنوان استخراج کننده ویژگی عمل می کنند، کمتر نسبت به یک مجموعه داده خاص وابسته می شوند و قابلیت انتقال خوبی دارند ولی لایه های کاملاً متصل CNN، که نقش آنها طبقه بندی است، توانایی تعمیم و انتقال پذیری کمتری دارند و نیاز به آموزش مجدد بر روی مجموعه داده هدف دارند [۲۷].

مدل های محبوب عمومی CNN می توانند گزینه های خوبی برای استخراج ویژگی ها باشند، از جمله AlexNet [۲۳]، VGGNet [۲۸]، GoogleNet [۲۹]، ResNet [۳۰] و DenseNet [۳۱]. به طور کلی، فعالیت های صورت گرفته در حوزه طبقه بندی بافت با شبکه های عصبی عمیق به سه بخش تقسیم می شود. بخش اول استفاده از مدل های عمومی CNN از پیش آموزش دیده و بخش دوم انجام عملیات تنظیم دقیق<sup>۵</sup> بر روی روی شبکه با استفاده از مجموعه داده های بافتی و بخش سوم استفاده از مدل های CNN پیشنهادی (ابداعی) [۳۲] است.

سیمپوی و همکاران در [۳۳-۳۵] برای طبقه بندی بافت، از خروجی لایه های کانولوشن به عنوان ویژگی های استخراج شده استفاده کرده و آن را با روش های کدگذارهای سنتی ترکیب کرده اند. در این مدل ها از چهار نوع CNN برای استخراج ویژگی استفاده شده است. در [۳۳] آخرین لایه کانولوشن به عنوان ویژگی های استخراج شده، به تحلیلگر مؤلفه های اصلی<sup>۶</sup> (PCA) و ماشین بردار پشتیبان<sup>۷</sup> (SVM) اعمال شده است. آندراشیک و والان [۳۶] با الهام از شبکه های عصبی عمیق و رویکرد بانک فیلتر، یک معماری با نام T-CNN<sup>۸</sup> برای تجزیه و تحلیل بافت تصاویر ارائه دادند که با قرار دادن یک توصیفگر (لایه) بین لایه کانولوشن و لایه کاملاً متصل، اطلاعات شکل کلی اشیاء را حذف کرده است. این توصیفگر به عنوان لایه ای با نام لایه ادغام میانگین عمومی<sup>۹</sup> شناخته می شود. لین و همکاران [۳۷] یک مدل دو خطی<sup>۱۰</sup> (B-CNN) برای شناسایی بافت ارائه دادند که از ترکیب دو شبکه عصبی عمیق کانولوشن ایجاد شده است. خروجی لایه های کانولوشن، بعد از فعال سازی، با استفاده از ضرب خارجی و سپس یک لایه ادغام ترکیب شده و برای طبقه بندی به لایه کاملاً متصل اعمال شده اند.

ژانگ و مارسزالک [۳۸] با بررسی ترکیب های مختلف چند توصیفگر و طبقه بندی کننده<sup>۱۱</sup> نشان دادند که برای دستیابی به بهترین عملکرد، لازم است ترکیبی از چندین توصیفگر به همراه

تغییر روشنایی غیر حساس است و در برابر نویز نیز مقاوم است. ژائو و همکاران [۱۹] روش الگوی دودویی محلی مقاوم کامل<sup>۱</sup> (CRLBP) را ارائه کردند که در مقابل نویز مقاوم است و به جای مقایسه پیکسل های همسایگی با مقدار پیکسل مرکزی، از میانگین شدت روشنایی محلی پیکسل ها به عنوان سطح آستانه استفاده کرده است.

شکور و تاجری پور [۲۰] یک روش طبقه بندی بافت مقاوم در برابر نویز ارائه کردند که با تکرار فیلتر میانگین گیر برای بافت های نویزی، دقت طبقه بندی را به میزان قابل توجهی افزایش داده است. برای دست یابی مقدار بهینه تکرار اعمال این فیلتر، از واریانس بافت استفاده شده است. یکی دیگر از انواع الگوی دودویی محلی مقاوم در برابر نویز روش MRELBP [۲۱] است که نسبت به سایر انواع الگوی دودویی محلی عملکرد بسیار خوبی در مقابل نویز از خود نشان داده است [۳]. در این روش، به جای استفاده از مقادیر یک پیکسل به عنوان سطح آستانه از میانه پیکسل ها به عنوان سطح آستانه استفاده شده است. شکور و بوستانی [۲۲] روش RMLBP را ارائه کردند که در آن به جای استفاده از مقادیر پیکسل های همسایگی، از میانگین نقاط روی شعاع استفاده شده است. با این تغییر اثر نویز کاهش یافته است. این روش قابل اعمال به نسخه های مختلف LBP است.

یک محدودیت الگوی دودویی محلی آن است که برای برخی از انواع داده ها حتی با افزایش ویژگی ها و توسعه الگوی دودویی نیز نمی توان دقت طبقه بندی را از یک حد بیشتر کرد. لذا می بایست از روش های قدرتمند ر دیگر استفاده کرد یا الگوی دودویی را با آنها ترکیب کرد. یکی از این روش های بسیار قدرتمند شبکه های عصبی عمیق است.

در سال های اخیر، شبکه های عصبی عمیق کانولوشن<sup>۲</sup> (CNN) چشم انداز بسیاری از زمینه های بینایی رایانه را به طرز چشمگیری تغییر داده و منجر به پیشرفت های شگفت آوری در وظایفی مانند تشخیص اشیاء، تشخیص صحنه و تشخیص چهره شده اند. عملکرد برجسته AlexNet [۲۳] در چالش شناخت داده های بزرگ ImageNet (ILSVRC<sup>۳</sup>) باعث شد بسیاری از محققان توجه خود را از روش های سنتی به سمت شبکه های عصبی کانولوشن معطوف کنند [۲۴]. الگوی شبکه های عصبی عمیق کانولوشن رویکرد تجزیه و تحلیل بافت را نیز تغییر داده است و شبکه های عصبی کانولوشن نتایج چشمگیری را در حوزه طبقه بندی بافت، به ویژه در شرایط متغیر تصویربرداری، ارائه داده اند [۲۵]. یادگیری انتقالی<sup>۴</sup> یکی از قابلیت های مهم این شبکه ها است. یادگیری انتقالی یعنی شبکه هایی که از پیش بر روی یک مجموعه تصاویر آموزش دیده اند، در زمینه های دیگر (و مشابه)

<sup>5</sup> Fine-Tune

<sup>6</sup> Principal Component Analysis

<sup>7</sup> Support Vector Machine

<sup>8</sup> Texture CNN

<sup>9</sup> Global Average Pooling

<sup>10</sup> Bilinear

<sup>11</sup> Classifier

<sup>1</sup> Completed Robust Local Binary Pattern

<sup>2</sup> Convolutional Neural Network

<sup>3</sup> ImageNet Large Scale Visual Recognition Challenge

<sup>4</sup> Transfer Learning

معروف پیشین، که عمدتاً مبتنی بر استفاده از یک روش استخراج ویژگی هستند به صورت قابل توجهی افزایش یافته است.


## ۲ روشهای پایه

در این قسمت الگوی دودویی محلی، الگوی دودویی محلی کامل و شبکه‌های عصبی عمیق کانولوشن را تشریح می‌کنیم.

### ۱-۲ الگوی دودویی محلی

الگوی دودویی محلی [۱۲]، یک عملگر بافت ساده اما کارآمد است. در این روش هر پیکسل از تصویر با یک کد الگوی دودویی برچسب گذاری می‌شود. مقدار هر برچسب الگوی دودویی در یک همسایگی با شعاع (R) و تعداد نقاط همسایگی (P) مشخص می‌شود.

در شکل ۱ یک همسایگی و نحوه محاسبه الگوی دودویی محلی را نشان شده است. روابط ۱ و ۲ نحوه محاسبه الگوی دودویی محلی را نشان داده که در آن شعاع همسایگی، P تعداد نقاط موجود در همسایگی،  $E_c$  شدت روشنایی نقطه مرکزی و  $E_p$  نیز شدت روشنایی نقاط موجود در همسایگی است. R شعاع یک همسایگی متقارن مدور برای محاسبه الگوی دودویی محلی مشخص است، لذا نقطاتی که دقیقاً بر روی یک پیکسل منطبق نمی‌شوند از طریق درون یابی محاسبه می‌شوند.



شکل ۱) یک همسایگی (p, r)، به شعاع r و شامل p پیکسل برای محاسبه عملگر LBP

مقادیر استخراج شده به وسیله این عملگر به عنوان ویژگی‌های بافت محلی تصویر استفاده می‌شود. الگوی دودویی محلی پایه در مجموع  $2^P$  ویژگی تولید می‌کند. این مقادیر به عنوان بازه‌های هیستوگرام استفاده می‌شود. روابط ۱ و ۲ نحوه محاسبه الگوی دودویی محلی را نمایش می‌دهند [۱۳].

$$LBP_{p,r} = \sum_{p=0}^{P-1} s(E_p - E_c) * 2^p \quad (1)$$

$$s(E_p - E_c) = \begin{cases} 1 & E_p \geq E_c \\ 0 & E_p < E_c \end{cases} \quad (2)$$

مهمترین مشکلات روش الگوی دودویی محلی اولیه ابعاد بالای بردار ویژگی استخراج شده ( $2^P$ ) و حساسیت به چرخش است. اوجالا و همکاران [۱۳] برای رفع این مشکلات الگوی دودویی محلی یکنواخت غیر حساس به چرخش را ارائه دادند که با نماد  $LBP_{p,r}^{riu2}$  نشان داده شده است. این عملگر با استفاده از رابطه ۳ و با توجه به میزان یکنواختی رابطه ۴ محاسبه می‌شود [۱۳]:

طبقه‌بندی کننده‌ای که بتواند از اطلاعات مکمل آنها استفاده موثر کند، بکارگرفته شود. آنها نشان دادند که استفاده ترکیبی از توصیفگرهای متعدد معمولاً نتایج بهتری را حتی نسبت به استفاده از تفکیک پذیرترین توصیفگر منفرد حاصل می‌کند.

ژانگ و همکاران [۳۹] روشی ارائه دادند که در آن برای تشخیص تومورهای بدخیم و خوش خیم از ترکیب الگوی دودویی محلی و شبکه‌های عصبی عمیق کانولوشن استفاده شده است. ژانگ و همکاران [۴۰] یک روش برای طبقه‌بندی تصاویر چهره ارائه دادند که از ترکیب الگوی دودویی محلی و چندین شبکه عصبی کانولوشن با ساختار مختلف شده است که برای استخراج ویژگی استفاده می‌شوند. انور و همکاران [۴۱] با ترکیب الگوی دودویی محلی، با معماری‌های یادگیری عمیق یک معماری با نام TEX-Net ارائه دادند که در آن برای شناسایی بافت و طبقه‌بندی تصاویر سنجش از راه دور از یک معماری عمیق دو بخشی استفاده شده است. یک بخش این معماری، مدل استاندارد RGB است و بخش مکمل با الگوی دودویی محلی کدگذاری شده و سپس به فضای سه بعدی نگاشت شده است.

در این پژوهش یک روش برای طبقه‌بندی تصاویر بافتی نويزدار ارائه شده که همانند روش‌های پیشرفته و جدید طبقه‌بندی بافت، برای استخراج ویژگی‌های بافتی متمایزکننده، از ترکیب شبکه عصبی کانولوشن عمیق و روش‌های سنتی استفاده شده است. این روش از دو دسته ویژگی تشکیل شده است. دسته اول، ویژگی‌های محلی تصاویر بافتی است که با اعمال الگوی دودویی محلی کامل (CLBP) بر روی تصاویر، استخراج شده و در مقابل نویز مقاوم است. برای استخراج ویژگی‌های دسته دوم از تصاویر بافتی، از شبکه عصبی کانولوشن عمیق DenseNet-121 از پیش آموزش دیده استفاده شده است. نوآوری اول روش پیشنهادی انتخاب دو توصیفگر و پارامترهای مناسب آنها است به نحوی است که ویژگی‌های مکمل و مقاوم در برابر نویز ارائه کرده است به نحوی که ترکیب این دو نوع ویژگی در روش پیشنهادی، موجب افزایش دقت طبقه‌بندی نسبت به استفاده تنها از هر یک از این دو توصیفگر شده است. علاوه بر این، روش پیشنهادی نسبت به هر دو روش مذکور و روش‌های پیشرفته پیشین، مقاومت بیشتری در برابر نویز دارد. نوآوری دوم این پژوهش یک بخش کاهش ویژگی است که در فرآیند ترکیب ویژگی‌ها به کار گرفته شده است. این روش که یک روش باناظر<sup>۱</sup> است که با استفاده از شبکه عصبی کانولوشن کم عمق هیستوگرام الگوی دودویی محلی را، برای ترکیب با ویژگی‌های شبکه عصبی عمیق، به فضای دیگر و با تعداد ویژگی‌های کمتر نگاشت کرده و ابعاد آن را به صورت قابل توجهی کاهش داده است. بر اساس نتایج حاصل از پیاده سازی، دقت طبقه‌بندی مدل ارائه شده بر روی مجموعه‌های داده بافتی مختلف با شدت نویز گوسی و فلفل نمکی متفاوت نسبت به روش‌های

<sup>1</sup> Supervised

[1] تجزیه می‌شود. LBP پایه فقط از مؤلفه علامت استفاده کرده و عملگر  $CLBP\_S$  مانند LBP پایه (روابط ۱ و ۲) محاسبه می‌شود. مؤلفه بزرگی، دارای مقادیر پیوسته است. برای اینکه بتوان  $CLBP\_M$  را مثل LBP پایه به صورت مقادیر ۱ و -۱ کدگذاری کرد مقدار آن از رابطه ۵ و ۶ محاسبه می‌شود [۱۴ و ۱۵].

$$CLBP\_M_{P,R} = \sum_{p=0}^{P-1} t(m_p - c) * 2^p \quad (5)$$

$$t(x, c) = \begin{cases} 1 & x \geq c \\ 0 & x < c \end{cases} \quad (6)$$

مقدار  $c$  یک سطح آستانه است که ژئو و همکاران [۱۴] این مقدار را برابر با میانگین  $m_p$  در سرتاسر تصویر انتخاب کردند. مشابه LBP پایه می‌توان نسخه غیر حساس نسبت به چرخش و یکنواخت این عملگر را نیز تعریف کرد ( $CLBP\_M_{P,R}^{(c)}$ ). برای اینکه مؤلفه  $CLBP\_C$  نیز رشته دودویی تولید کند و با دو مؤلفه قبل سازگار باشد عملگر  $CLBP\_C$  از رابطه ۷ محاسبه شده است.  $t$  از رابطه ۶ محاسبه شده و  $C_I$  برابر میانگین شدت روشنایی تمام تصویر است.

$$CLBP\_C_{P,R} = t(g_c - c_i) \quad (7) [14]$$

معمولاً از هیستوگرام  $CLBP\_C$ ،  $CLBP\_S$  و  $CLBP\_M$  به عنوان ویژگی تصاویر استفاده می‌شود. هیستوگرام این سه عملگر را می‌توان به صورت اتصال<sup>۵</sup> یا به صورت الحاق<sup>۶</sup> ترکیب کرد که در روش اول تعداد ویژگیها برابر با جمع هر یک از ویژگیها خواهد شد و در روش دوم تعداد آنها برابر با حاصلضرب ویژگیها می‌شود. در الگوی دودویی کامل [۱۴] استفاده از روش دوم بیشترین دقت را تولید می‌کند.

یکی از راههای افزایش دقت طبقه‌بندی، استفاده از رویکرد چند مقیاسی<sup>۷</sup> یا چند وضوحی<sup>۸</sup> است. در این رویکرد با به کارگیری چندین عملگر با  $(P, R)$  مختلف و ترکیب ویژگیهای استخراج شده، می‌توان به دقت‌های بالاتری دست یافت [۱۳]. این روش با الهام از تصاویر و بافت‌ها دنیای واقعی ایجاد شده است که از ساختارهای مختلف و در مقیاس‌های مختلف تشکیل شده‌اند. روش چند مقیاسی دقت بهتری از روش تک مقیاسی ارائه می‌دهد ولی موجب افزایش ابعاد بردار ویژگی را می‌شود [۴۲].

### ۳-۲ شبکه عصبی عمیق کانولوشن

ساختار کلی شبکه عصبی کانولوشن (CNN) را می‌توان با توالی لایه‌های کانولوشن، لایه‌های تجمع یا ادغام<sup>۹</sup>، توابع غیرخطی<sup>۱۰</sup> و لایه‌های کاملاً متصل<sup>۱۱</sup> خلاصه کرد [۴۳]. ساختار کلی شبکه عصبی عمیق کانولوشن در شکل ۲ آورده شده است. لایه‌های کانولوشن مانند لایه‌های استخراج کننده ویژگی عمل می‌

$$LBP_{P,R}^{(c)} = \begin{cases} \sum_{p=0}^{P-1} (g_p - g_c) & \text{if } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{otherwise} \end{cases} \quad (3)$$

مقدار عملگر یکنواختی ( $U$ ) از رابطه ۴ به دست می‌آید [۱۳].

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (4)$$

اصطلاح "یکنواخت"<sup>۱۱</sup> به معنی تعداد محدودی تغییر صفر به یک یا برعکس در نمایش دورانی الگو است. در این روش، برای الگوهایی که دارای بیش از دو تغییر از صفر به یک یا برعکس هستند، یک برجسب یکسان در نظر گرفته شده است. در این پژوهش برای محاسبه مقادیر الگوی دودویی محلی از نگاشتriu2 استفاده شده است. تعداد الگوهای تولید شده در این روش  $P+1$  عدد است. این نگاشت تعداد ویژگیهای استخراج شده را به صورت قابل توجهی کاهش داده است.  $P$  مورد از این ویژگیها یکنواخت است و از ترکیب کلیه الگوهای غیر یکنواخت یک ویژگی دیگر تولید شده است لذا مجموعاً  $P+1$  ویژگی استخراج می‌شود.

### ۲-۲ الگوی دودویی محلی کامل

در این پژوهش از روش الگوی دودویی محلی کامل<sup>۲</sup> ( $CLBP$ ) [۱۴] برای استخراج ویژگی تصاویر بافتی استفاده شده است. در این روش، بر خلاف LBP پایه، فقط از علامت تفاضل الگوی دودویی استفاده نشده بلکه هم از علامت<sup>۳</sup> تفاضل ( $CLBP\_S$ ) و هم از اندازه<sup>۴</sup> تفاضل ( $CLBP\_M$ ) استفاده می‌شود. در این روش علاوه بر این دو مؤلفه، از اطلاعات نقطه مرکزی ( $CLBP\_C$ ) به عنوان مؤلفه سوم استفاده شده است و با ترکیب این ۳ نوع اطلاعات به دقت بالایی در طبقه‌بندی تصاویر بافتی دست یافته است.  $CLBP\_S$  در واقع همان LBP محاسبه شده در رابطه ۳ است ولی برای محاسبه  $CLBP\_M$  از اندازه تفاضل استفاده شده است.

در شکل ۱ الف می‌توان تفاوت بین  $g_p$  و  $g_c$  را به سادگی صورت تفریق ( $d_p = g_p - g_c$ ) محاسبه کرد. بردار تفاضل محلی  $[d_1, d_2, \dots, d_{P-1}]$  ساختار محلی تصویر در اطراف  $g_c$  را مشخص می‌کند. به خاطر استفاده از تفاضل، مقدار این بردار نسبت به تغییر شدت روشنایی غیرحساس است و ویژگی بهتری از تصویر اصلی ارائه می‌دهد. این مقدار را می‌توان به دو مؤلفه اندازه و علامت به صورت رابطه ۴ تجزیه کرد [۱۴].

$$d_p = s_p * m_p \quad \begin{cases} s_p = \text{sgn}(d_p) \\ m_p = |d_p| \end{cases} \quad (4)$$

به این ترتیب بردار ویژگی  $[d_1, d_2, \dots, d_{P-1}]$  به دو بردار علامت  $[s_1, s_2, \dots, s_{P-1}]$  و بردار اندازه یا بزرگی  $[m_1, m_2, \dots, m_{P-1}]$

<sup>5</sup> Concatenation

<sup>6</sup> Jointly

<sup>7</sup> Multi-Scale

<sup>8</sup> Multiresolution

<sup>9</sup> Pooling layers

<sup>10</sup> Non-linearity

<sup>11</sup> Fully Connected Layers

<sup>1</sup> Uniform

<sup>2</sup> Completed Local Binary Pattern

<sup>3</sup> Sign

<sup>4</sup> Magnitude




یکدیگر متصل شده‌اند. در این معماری برای ترکیب ویژگی‌ها، آنها را به یکدیگر متصل<sup>۲</sup> می‌کنند؛ به این صورت هر لایه، خروجی‌های تمام لایه‌های قبلی (دانش تجمعی<sup>۳</sup>) را دریافت کرده و نقشه-نقشه‌های ویژگی خود را به همه لایه‌های بعدی منتقل می‌کند. در این معماری، شبکه به چندین بلوک با اتصال متراکم<sup>۴</sup> تقسیم شده است. بلوک‌های DenseNet بسیار باریک و فشرده هستند. به عنوان مثال، ۱۲ فیلتر در یک لایه قرار دارد. این شبکه می‌تواند الگوهای متنوع تری را آموزش ببیند زیرا طبقه بند DenseNet از ویژگی‌های تمام سطوح پیچیدگی (تمام لایه‌ها) استفاده می‌کند. این معماری به گونه‌ای است که اثر نظم‌دهی<sup>۵</sup> مدل را دارد و در وظایفی که دارای داده آموزشی کوچک هستند، کمتر دچار بیش‌برازش<sup>۶</sup> می‌شود [۳۱]. این خاصیت برای داده‌های بافتی که دارای مجموعه داده‌های کوچک هستند مناسب است. ساختار کلی معماری DenseNet در شکل ۳ آورده شده است.

در این پژوهش از دو شبکه عصبی کانولوشن استفاده شده است که شبکه اصلی که وظیفه استخراج ویژگی از تصاویر بافتی را برعهده دارد، معماری DenseNet-121 است. ساختار معماری DenseNet-121 در جدول ۱ نشان داده شده است.

#### ۲-۴ مجموعه‌های داده

بسیاری از مطالعات تجزیه و تحلیل بافت فقط بر روی مجموعه داده‌های کوچکی مانند برخی از داده‌های Outex مورد ارزیابی قرار گرفته‌اند که شامل داده‌های آموزش و تست مجزا هستند، در حالی که مجموعه‌های بافتی چالش برانگیزتری مانند UIUC، CUREt نیز وجود دارند که شامل تعداد نمونه‌ها یا کلاس‌های بافتی بیشتر با تغییرات بزرگتر هستند. به همین منظور در این مقاله از سه مجموعه داده بافتی معروف Outex [۴۵]، UIUC [۴۶] و CUREt [۴۷] استفاده شده است. این مجموعه‌های داده، شامل انواع مختلفی از تصاویر بافتی هستند. مجموعه داده CUREt شامل ۶۱ طبقه بافتی از مواد مختلف است که در شرایط مختلف تصویربرداری، در محیط کنترل شده آزمایشگاهی ثبت شده است. برای هر کلاس، ۹۲ تصویر از بین تصاویر با زاویه دید کمتر از ۶۰ درجه انتخاب شده است. یکی از ویژگی‌های مهم این داده‌ها شباهت بسیار نزدیک تصاویر برخی از کلاس‌ها به کلاس‌های دیگر است بطوری که در اغلب مقالات دقت طبقه بندی روی داده‌های CUREt را کاهش یافته است. مجموعه داده UIUC شامل ۲۵ کلاس و ۴۰ تصویر در هر کلاس است. این مجموعه داده دارای تغییرات قابل توجهی در مقیاس و دیدگاه است، و همچنین دارای جزئیات بیشتر نسبت به CUREt

کنند. لایه‌های ادغام برای کاهش تدریجی ابعاد ویژگی و در نتیجه کاهش پارامترها و پیچیدگی محاسباتی مدل استفاده شده و لایه-های کاملاً متصل برای طبقه‌بندی هستند [۴۳، ۴۴].



شکل ۲ ساختار کلی شبکه عصبی عمیق کانولوشن (CNN) [۲۴]

شبکه کانولوشن برای تجزیه و تحلیل بافت ابزار مناسبی هستند و کارایی بالایی دارند؛ زیرا لایه‌های کانولوشن را می‌توان با بانک‌های فیلتری مقایسه کرد که به طور گسترده در تجزیه و تحلیل بافت استفاده شده است [۳۶]. CNNها با جایگزینی فیلترهای دست‌ساز با یک معماری سلسله مراتبی و با استفاده از یک الگوریتم قدرتمند یادگیری، تا حد زیادی روشهای سنتی بانک فیلتر را بهبود داده‌اند [۴۳].

جدول ۱ ساختار معماری DenseNet-121 [۳۱]

Layers	DenseNet-121
Convolution	7×7 conv, stride 2
Pooling	3×3 max pool, stride 2
Dense Block(1)	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer(1)	1×1 conv
	2×2 average pool, stride 2
Dense Block(2)	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer(2)	1×1 conv
	2×2 average pool, stride 2
Dense Block(3)	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$
Transition Layer(3)	1×1 conv
	2×2 average pool, stride 2
Dense Block(4)	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$
Classification Layer	7×7 global average pool
	1000D fully-connected, softmax

اغلب مدل‌های CNN می‌توانند گزینه‌های خوبی برای استخراج ویژگی از تصاویر باشند. معماری DenseNet [۳۱] در مقایسه با سایر معماری‌های آموزش دیده می‌تواند موجب بهبود جریان (انتقال) اطلاعات و مقادیر شبیه<sup>۱</sup> (در انتشار روبه‌عقب) در شبکه شود. در این معماری برای اطمینان از جریان (انتقال) حداکثری اطلاعات بین لایه‌های شبکه، همه لایه‌ها مستقیماً به

<sup>2</sup> Concatenate

<sup>3</sup> Collective Knowledge

<sup>4</sup> Dense Block


<sup>5</sup> Regularization

<sup>6</sup> Overfitting

<sup>1</sup> Gradient

جدول ۲ مشخصات داده UIUC و CURET و دو مجموعه از

نام مجموعه داده	ابعاد تصویر	تعداد کلاس	نمونه‌های هر کلاس	تقسیم‌بندی آموزش/آزمایش
UIUC	۶۴۰×۴۸۰	۲۵	۴۰	خیر
CURET	۲۰۰×۲۰۰	۶۱	۹۲	خیر
Outex	۱۲۸×۱۲۸	۲۴	۲۰	بله
	۱۲۸×۱۲۸	۶۸		



شکل ۳ ساختار کلی (یک بلوک ۵ لایه) معماری DenseNet [۳۱]

شبکه‌های عصبی عمیق همانند بانک‌های فیلتری عملی می‌کنند که به طور گسترده در تجزیه و تحلیل بافت مورد استفاده قرار گرفته است. در این شبکه‌ها فیلترها در یک ساختار سلسله مراتبی قرار گرفته‌اند که در سطوح مختلف، ویژگی‌هایی با میزان پیچیدگی مختلف را شناسایی می‌کنند. ویژگی اساسی این شبکه‌های الگوریتم یادگیری است که موجب شده تا فیلترها آموزش داده شوند و بتوانند ساختارهای متنوع و با پیچیدگی متفاوت را شناسایی کنند. با توجه به اینکه بافت‌های طبیعی دارای سطوح مختلف پیچیدگی هستند، این شبکه‌ها می‌توانند به خوبی آموزش ببینند تا الگوهای مختلف بافتی را از یکدیگر تفکیک کنند. به همین دلیل از شبکه عصبی عمیق به عنوان یکی از روش‌های استخراج ویژگی در روش پیشنهادی استفاده شده است. با توجه به اینکه مجموعه‌های داده بزرگ بافتی، برای آموزش شبکه‌های عصبی عمیق موجود نیست، برای استخراج ویژگی با شبکه عصبی عمیق از معماری DenseNet-121 از پیش آموزش دیده بر روی مجموعه داده ImageNet، استفاده شده است. روش‌های مختلف الگوی دودویی محلی جدید، با روش‌های مختلف از جمله استفاده از میانگین شدت روشنایی پیکسل‌ها در هر همسایگی


است [۳۲]. نمونه‌هایی از تصاویر مجموعه داده CURET را با مقادیر نویز متفاوت، در شکل ۴ آورده شده است.

پایگاه داده Outex شامل مجموعه‌های آزمایشی<sup>۱</sup> بسیاری است. این مجموعه‌های آزمایشی در شرایط روشنایی، چرخش و مقیاس مختلف جمع‌آوری شده‌اند. دو مجموعه آزمایشی توسعه یافته این مجموعه داده با نام‌های Outex\_TC\_11n و Outex\_TC\_23n [۴۸] برای ارزیابی مقاومت الگوریتم‌ها در مقابل نویز طراحی شده است. در این دو مجموعه داده نمونه‌های آموزش و تست به صورت از پیش تعیین شده تفکیک شده است. برای آموزش از تصاویر بدون نویز و برای تست، از تصاویر آموزشی که به وسیله نویز گوسی با  $\sigma = 5$  خراب شده‌اند، استفاده می‌شود. جزئیات این سه مجموعه داده در جدول ۲ آورده شده است.

### ۳ روش پیشنهادی

در این پژوهش روشی برای طبقه‌بندی تصاویر بافتی نویزدار ارائه شده است که مبتنی بر ترکیب ویژگی‌های الگویی دودویی محلی و عمیق است. در این روش از دو نوع (روش) استخراج ویژگی استفاده شده است که در یک نوع، با استفاده از الگوی دودویی محلی کامل (CLBP) ویژگی‌های تصاویر بافتی نویزدار استخراج شده است و در نوع دوم، برای استخراج ویژگی از شبکه عصبی کانولوشن عمیق استفاده شده است. دیاگرام روش پیشنهادی اول را در شکل ۵ آورده شده است.

<sup>1</sup> Test Suite



شکل ۴ نمونه‌هایی از تصاویر مجموعه داده CURET با میزان SNR مختلف

### جدول ۳ ابعاد هیستوگرام سه بعدی CLBP\_S/M/C به ازای تعداد نقاط و شعاع همسایگی مختلف

ابعاد هیستوگرام	شعاع همسایگی	تعداد نقاط همسایگی
$2 \times 10 \times 10$	۱	۸
$2 \times 18 \times 18$	۲	۱۶

در نوع دوم استخراج ویژگی با استفاده از معماری عمیق DenseNet-121 از پیش آموزش دیده بر روی مجموعه داده ImageNet، ویژگی‌های تصاویر بافتی در قالب یک بردار خطی (با ۱۰۲۴ ویژگی) استخراج شده است.

برای استخراج ویژگی از تصاویر به وسیله این معماری عمیق لایه‌های کاملاً متصل آن حذف شده است. آخرین لایه ماقبل لایه‌های کاملاً متصل در این شبکه لایه ادغام میانگین عمومی<sup>۲</sup> است. این لایه همان لایه انرژی است که آندراشیک و والان [۳۶] برای حذف اطلاعات شکل کلی اشیاء در معماری T-CNN ارائه کردند، بنابراین در توصیف بافت بسیار موثر عمل می‌کند. خروجی این لایه یک بردار با ۱۰۲۴ ویژگی است که به عنوان ویژگی‌های نوع دوم استفاده شده است.

برای آموزش معماری عمیق از رویکردی مشابه یادگیری انتقالی به همراه تنظیم دقیق وزن‌ها<sup>۳</sup>، استفاده شده است. در ابتدای آموزش مدل پیشنهادی، وزن‌های اولیه معماری عمیق DenseNet-121 برابر با وزن‌های از پیش آموزش دیده این معماری بر روی مجموعه داده ImageNet قرار داده شده و در فرآیند یادگیری، مقدار وزن‌های این معماری نیز تنظیم شده و این

(یا در کل تصویر) به عنوان معیار مقایسه (سطوح آستانه)، مقاومت خوبی در مقابل نویز از خود نشان داده‌اند. با ترکیب ویژگی‌های عمیق و الگوی دودویی محلی می‌توان ویژگی‌هایی را بدست آورد که هم قدرت تفکیک بالایی داشته باشد، هم آموزش ببیند تا الگوهای بافتی متنوع و با میزان پیچیدگی متفاوت را شناسایی کند و هم در مقابل نویز مقاوم باشد. روش پیشنهادی در این پژوهش با انتخاب پارامترهای مناسب این دو توصیفگر و ارائه یک تبدیل برای کاهش ویژگی هیستوگرام الگوی دودویی محلی، به دقت بالایی برای طبقه‌بندی تصاویر بافتی نويزدار دست یافته است.

برای استخراج اولین نوع ویژگی از تصاویر بافتی نويزدار، الگوی دودویی محلی کامل با  $(P=16$  و  $R=2)$  بر روی این تصاویر اعمال شده است. مانند آنچه در [۱۴] به عنوان CLBP\_S/M/C معرفی شده، از هیستوگرام سه بعدی الگوی‌های دودویی محلی، به عنوان ویژگی‌های استخراج شده از تصاویر بافتی استفاده شده است

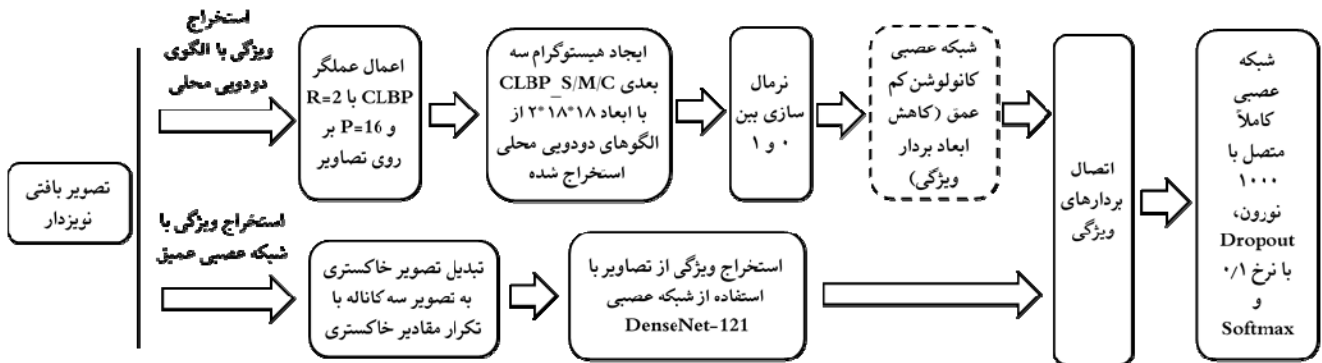
ابعاد هیستوگرام CLBP\_S/M/C به ازای تعداد نقاط و شعاع همسایگی مختلف در جدول ۳ آورده شده است. در استخراج ویژگی با الگوی دودویی محلی، اگرچه برخی از نگاشته‌ها مانند  $u_2$  ممکن است عملکرد بالایی را برای بافت‌های نویزی فراهم کنند، اما اولاً بدلیل اینکه ویژگی‌های بسیار زیادی را استخراج کرده و بسیار کند هستند و ثانیاً نسبت به چرخش حساس هستند، به همین دلیل در این پژوهش از نگاشت  $riu_2$  استفاده شده است. این نگاشت هم نسبت به چرخش غیر حساس است و ضمن اینکه ویژگی‌های بسیار کمی را استخراج کرده، برای داده‌های نویزی عملکرد خوبی ارائه می‌کند.

<sup>2</sup> Global Average Pooling

<sup>3</sup> Fine-Tune

<sup>1</sup> Threshold





شکل ۵ دیاگرام روش پیشنهادی. در این روش از الگوی دودویی محلی کامل و شبکه عصبی عمیق DenseNet-121 برای استخراج ویژگی از تصاویر بافتی نویزدار استفاده شده است.

یک فرآیند آموزش نظارت شده، خروجی لایه‌های پنهان MLP می‌تواند به عنوان یک تبدیل داده نظارت شده در نظر گرفته شود. اگر تعداد نورونهای لایه پنهان کوچکتر از ورودی باشد، نقش کاهش ابعاد را نیز ایفا می‌کند [۴۹].

مانند MLP، شبکه عصبی کانولوشن نیز می‌تواند به عنوان یک تبدیل داده نظارت شده استفاده شود. در این پژوهش هیستوگرام الگوهای دودویی محلی مانند یک تصویر به یک شبکه عصبی کانولوشن کم عمق اعمال شده است تا در یک فرآیند آموزش نظارت شده ویژگی‌های اساسی آن استخراج شده و ابعاد ویژگی‌ها کاهش یابد. به عبارت دیگر پس از فرآیند آموزش، این شبکه عصبی ویژگی‌ها را به فضای موثرتر تبدیل کرده و ابعاد آن را کاهش می‌دهد. در جریان آموزش کل مدل (شامل فیلترهای کانولوشن شبکه DenseNet-121 و شبکه کاملاً متصل) این شبکه کم عمق نیز آموزش داده شده و فیلترهای کانولوشن آن متناسب با مقادیر برجسب‌های تصاویر بافتی تنظیم شده است. به این صورت به وسیله شبکه عصبی کانولوشن کم عمق ویژگی‌هایی از هیستوگرام استخراج شده که بیشترین تاثیر برای تشخیص بافت متناظر را داشته باشد و این ویژگی‌ها در اختیار طبقه‌بند قرار داده شده است.

لایه کانولوشن ابتدایی شبکه‌های عصبی کانولوشن، ویژگی‌های ساده‌ای مثل لبه‌ها را تشخیص می‌دهد. لایه‌های بعدی آموزش می‌بینند تا ویژگی‌های بزرگتر و پیچیده تر را از ترکیب‌های ساده و غیرخطی خروجی‌های لایه‌های قبلی تشخیص دهند. با توجه به اینکه هیستوگرام الگوهای دودویی محلی ساختاری ساده دارد، برای استخراج ویژگی از آن، از شبکه عصبی کانولوشن کم عمق استفاده شده است.

در آزمایشات عملی صورت گرفته، برای مجموعه‌های داده OuteX\_TC\_11n و CUReT، UIUC، روش پیشنهادی با استفاده از روش کاهش ویژگی و بدون آن، تغییراتی کمتر از ۰.۵ درصد داشت و در اکثر آزمایشات منجر به افزایش دقت شده است. (به دلیل همین نزدیکی میزان دقت‌ها، دقت مربوط به عدم استفاده از روش کاهش ویژگی در جدول‌ها ذکر نشده است) در خصوص مجموعه داده OuteX\_TC\_23n

وزن‌ها بدون تغییر نبوده است. این روش تاثیر بسیار زیادی در افزایش دقت طبقه‌بندی و همچنین افزایش سرعت همگرایی مدل پیشنهادی داشته است.

برای ترکیب دو نوع ویژگی، ابتدا هیستوگرام الگوهای دودویی محلی بین ۰ و ۱ نرمال‌سازی شده و سپس در روشی مشابه [۴۹] از شبکه عصبی کانولوشن کم عمق به عنوان نوعی تبدیل<sup>۱</sup> و برای کاهش ابعاد آن استفاده شده است. سپس خروجی شبکه عصبی کم عمق به ویژگی‌های استخراج شده با روش عمیق متصل<sup>۲</sup> شده است. به این صورت بردار ویژگی روش پیشنهادی تشکیل شده است. روند تشکیل بردار ویژگی روش پیشنهادی به همراه ابعاد ویژگی‌های استخراج شده در هر مرحله و نحوه اتصال آن‌ها در شکل ۶ آورده شده است. برای طبقه‌بندی تصاویر از شبکه عصبی کاملاً متصل با ۱۰۰۰ نورون و همچنین یک لایه Dropout با نرخ پایین (۰.۱) استفاده شده است.

### ۳-۱) کاهش ابعاد بردار ویژگی و تبدیل داده<sup>۳</sup>

یکی از نوآوری‌های این پژوهش استفاده از شبکه عصبی کم عمق به عنوان نوعی تبدیل و کاهش ابعاد بردار ویژگی برای هیستوگرام الگوی دودویی محلی کامل است. هدف از تبدیل داده، تغییر فضای ویژگی اصلی داده‌ها به فضای دیگر و با ویژگی‌های بهتر است. تبدیل داده معمولاً با کاهش ابعاد بردار ویژگی ترکیب می‌شود، یعنی ابعاد فضای ویژگی تبدیل شده کوچکتر از ابعاد فضای ویژگی اصلی است. روشی که به طور گسترده برای تبدیل داده‌ها و کاهش ابعاد آن مورد استفاده قرار می‌گیرد، تحلیل مولفه‌های اصلی (PCA) است. PCA یک روش بدون ناظر است، بنابراین تضمینی وجود ندارد که فضای ویژگی آن برای کارهای نظارت شده، مانند طبقه‌بندی یا رگرسیون مناسب‌ترین باشد. شبکه عصبی پرسپترون چند لایه (MLP)، که یک روش نظارت شده است، می‌تواند به عنوان یک تبدیل داده استفاده شود. پس از

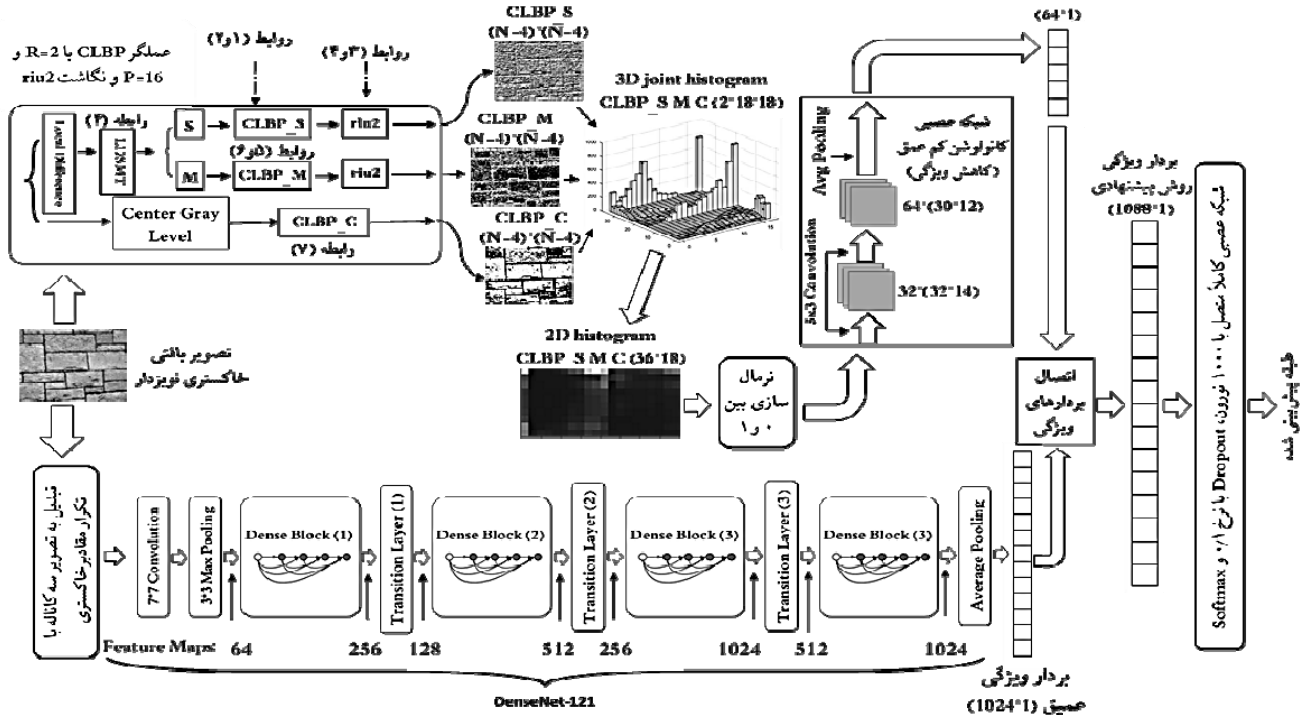
<sup>1</sup> Transformation

<sup>2</sup> Concatenate

<sup>3</sup> Data Transformation

استفاده از روش کاهش ویژگی موجب شده تا در مقایسه با عدم استفاده از آن دقت طبقه‌بندی افزایش ۲ درصدی داشته باشد. با توجه به نتایج این آزمایش‌ها، این شبکه کم عمق بعد از فرآیند یادگیری، به خوبی ویژگی‌های موثر هیستوگرام الگوهای دودویی محلی را، که برای تمایز نمونه‌های هر مجموعه بافتی مناسب است، استخراج کرده و ویژگی‌هایی با ابعاد کمتر از هیستوگرام

اصلی ارائه داده که به دقت طبقه بندی آسبیبی نمی‌رساند. معماری این شبکه کم عمق در جدول ۴ آورده شده است. برای کاهش ابعاد بردار ویژگی، لایه انتهایی این شبکه نیز لایه ادغام میانگین عمومی انتخاب شده است.



شکل ۶ دیاگرام روش پیشنهادی

جدول ۶ مقایسه ابعاد بردار ویژگی روش پیشنهادی در مقایسه با روش‌های پیشرفته پیشین

تعداد ویژگی‌ها	روش
۱۰۸۸	روش پیشنهادی
۱۳۵۲	CLBP_S/M/C(R=3, P=24)
۲۰۰	CRLBP (R= 1, P= 8)
۱۳۵۲	CRLBP (R= 3, P= 24)
۲۲۰۰	CLBP (MS3)
۲۰۰	RMCLBP (R= 1, P= 8)
۴۲۰	LTP
۱۲۹۶	BRINT
۵۹۶	ScatNet (NNC)
۲۰۴۸	PCANet
۲۴۰۰	SSLBP (MS)
۶۵۵۳۶	FV-VGGVD (SVM)

تعداد ویژگی‌های روش پیشنهادی در مقایسه با روش‌های پیشرفته پیشین در جدول ۶ آورده شده است. روش‌هایی که در این جدول به آنها اشاره شده، روش‌هایی هستند که دارای مقاومت حداقلی در برابر نویز هستند. همانطور که در جدول ۶ مشخص است تعداد ویژگی‌های روش پیشنهادی نسبت به سایر روش‌های عمیق مثل FV-VGGVD و روش قدرتمند SSLBP بسیار کمتر است و با این حال به دلیل ترکیب ویژگی‌های مختلف،

جدول ۴ معماری شبکه عصبی کم عمق مورد استفاده برای استخراج ویژگی از هیستوگرام الگوی دودویی محلی

شماره لایه	لایه‌های شبکه کم عمق
۱	32 filter, 3x3 conv, stride 2, activation= ReLU
۲	64 filter, 3x3 conv, stride 2, activation= ReLU
۳	Global Average Pooling

ابعاد بردار ویژگی روش پیشنهادی با و بدون روش کاهش ویژگی در جدول ۵ آورده شده است. تعداد ویژگی‌ها با استفاده از روش کاهش ویژگی حدود ۳۸ درصد کاهش یافته است. علاوه بر کاهش تعداد ویژگی، تعداد پارامترهای قابل یادگیری کل مدل (شامل هر دو شبکه عصبی و لایه کاملاً متصل) حدود ۸ درصد کاهش یافته است. البته روش کاهش ویژگی بار پردازشی کمی (نسبت به کل هزینه پردازشی مدل) به همراه دارد.

جدول ۵ مقایسه ابعاد بردار ویژگی هر یک از نوع‌های اطلاعاتی

ابعاد بردار ویژگی		نوع استخراج ویژگی
با استفاده از روش کاهش ویژگی	بدون استفاده از روش کاهش ویژگی	
۱۰۲۴	۱۰۲۴	معماری عمیق DenseNet-121
۶۴	۶۴۸	CLBP
۱۰۸۸	۱۶۷۲	مجموع

در روش‌های الگوی دودویی محلی یکی از راه‌های دست یافتن به دقت‌های بالاتر استفاده از رویکرد چند مقیاسی است. این رویکرد موجب افزایش ابعاد بردار ویژگی می‌شود. روش پیشنهادی تنها از یک مقیاس استفاده کرده و با ترکیب الگوی دودویی محلی با یادگیری عمیق، دقت طبقه‌بندی را نسبت به روش‌های مذکور به صورت چشمگیری افزایش داده است.

[۱۹] و [۲۱] و [۲۲] برای ارزیابی کارایی روش‌های پیشنهادی مورد استفاده قرار گرفته است.

در ارزیابی مدل بر روی این دو مجموعه داده برای آموزش و آزمون از داده‌های نویدار استفاده شده و همچنین دقت طبقه‌بندی روش پیشنهادی را بر روی داده‌های بدون نویز نیز بررسی شده است. برای ارزیابی کارایی این مدل بر روی مجموعه داده Outex از دو مجموعه آموزشی Outex\_TC\_11n و Outex\_TC\_23n استفاده شده است که برای ارزیابی مقاومت الگوریتم‌ها در مقابل نویز طراحی شده‌اند. دقت طبقه‌بندی مدل پیشنهادی بر روی این سه مجموعه داده، نسبت به تمامی روش‌های پیشین به صورت قابل توجهی بالاتر است. این مدل برخلاف برخی روش‌ها که منحصراً یا برای SNR بالا و یا SNR پایین مناسب هستند، عملکرد خوبی برای مقادیر SNR کم و زیاد دارد.

برای مقایسه کارایی روش پیشنهادی (یعنی استفاده از ترکیب ویژگی‌های عمیق و دست‌ساز) با روشی که تنها مبتنی بر استخراج ویژگی با شبکه عصبی عمیق است، نیز از معماری DenseNet-121 استفاده شده است. برای آموزش شبکه عصبی عمیق نیز از رویکرد یادگیری انتقالی و تنظیم دقیق<sup>۱</sup> وزن‌ها استفاده شده است. طبقه‌بندی کننده این روش دارای ساختاری مشابه شبکه کاملاً متصل روش پیشنهادی است. تنظیمات و پارامترهای آموزش روش عمیق در مرحله یادگیری انتقالی مشابه تنظیمات و پارامترهای آموزش روش پیشنهادی است، یعنی تابع هزینه cross-entropy، ۳۰ مرحله آموزش، نرخ یادگیری از نوع ExponentialDecay با مقدار اولیه ۰,۰۵ و نرخ کاهش ۰,۹۶. در فرآیند تنظیم دقیق وزن‌ها تعداد مراحل ۲۰ و نرخ یادگیری ۰,۰۰۱ انتخاب شده است و بقیه تنظیمات و پارامترهای آموزش مشابه تنظیمات و پارامترهای آموزش روش پیشنهادی است.

یکی از دلایل مهم افزایش دقت طبقه‌بندی روش پیشنهادی نسبت به روش‌های پیشین این است که این مدل از روش‌های مختلف استخراج ویژگی استفاده کرده و ویژگی‌های بیشتری را با یکدیگر ترکیب کرده که اطلاعات مکملی دارند. ترکیب این ویژگی‌ها منجر به تولید بردار ویژگی متمایز کننده‌تری شده و در مقابل نویز نیز مقاوم است. دلیل دیگر استفاده از معماری DenseNet-121 است، که بخشی از بردار ویژگی این مدل با استفاده از آن ایجاد شده است. این شبکه ویژگی‌های سطوح پیچیدگی مختلف (تمام لایه‌ها) را به شبکه عصبی کاملاً متصل ارائه کرده است، به

عملکرد بهتری نسبت به تمامی روش‌ها در مقابل نویز ارائه کرده است. با توجه به اینکه روش پیشنهادی در این پژوهش ترکیب روش الگوی دودویی محلی و شبکه عصبی عمیق است، طبیعتاً ابعاد بردار ویژگی آن نسبت به برخی روش‌های پیشین که مبتنی بر یک روش استخراج ویژگی هستند، بالاتر است.

## ۴ نتایج پیاده سازی

برای ارزیابی کارایی روش پیشنهادی، از این روش برای طبقه‌بندی سه مجموعه داده بافتی معروف Outex، UIUC و CURET با مقادیر نویز مختلف استفاده شده و دقت طبقه‌بندی این روش با روش‌های پیشرفته پیشین مقایسه شده است. پیاده سازی با زبان برنامه‌نویسی پایتون و با کتابخانه Keras [۵۰]، واسط برنامه‌نویسی سطح بالای کتابخانه TensorFlow، انجام شده است. برای محیط اجرا از دو روش مختلف استفاده شده و پیاده سازی و آزمایش بر روی آن‌ها انجام شده است. محیط اول سرویس ابری Google Colab و محیط دوم ویندوز ۱۰ با پردازنده Core i7 8565u و حافظه ۸ گیگابایت است. در فرآیند آموزش مدل پیشنهادی، که شامل تنظیم وزن‌های شبکه عصبی کاملاً متصل، شبکه عصبی کم عمق کاهش ویژگی و شبکه عصبی عمیق DenseNet-121 است، از تابع هزینه cross-entropy استفاده شده است. تعداد مراحل<sup>۱</sup> آموزش ۳۰ و نرخ یادگیری از نوع ExponentialDecay با مقدار اولیه ۰,۰۵ و نرخ کاهش<sup>۲</sup> ۰,۹۶ انتخاب شده است.

برای مقادیر اولیه به وزن‌های شبکه DenseNet-121 از وزن‌های از پیش آموزش دیده این شبکه بر روی مجموعه داده ImageNet استفاده شده است و این موضوع در سرعت همگرایی و حتی میزان دقت طبقه‌بندی مدل، نسبت به مقادیر اولیه تصادفی وزن‌ها، تاثیر قابل توجهی داشته است.

به تمام نمونه‌های مجموعه‌های داده UIUC و CURET نویز گوسی با نسبت سیگنال به نویز<sup>۳</sup> مختلف یعنی ۳، ۵، ۱۰، ۱۵، ۳۰ اضافه شده است. همچنین به تمام نمونه‌های این دو مجموعه داده نویز لفل نمکی با تراکم ۵، ۱۵ و ۳۰ درصد اضافه شده است و علاوه بر آن از نویز نقطه‌ای<sup>۴</sup> با  $\sigma$  نیز استفاده شده است. (این نویز از نوع ضرب شونده است.) نمونه‌هایی از تصاویر مجموعه داده CURET با نویز گوسی با شدت مختلف در شکل ۴ آورده شده است.

برای ارزیابی کارایی روش پیشنهادی از معیار دقت<sup>۵</sup> استفاده شده است. در مسائل طبقه‌بندی معیار دقت، مهمترین معیار ارزیابی است و در روش‌های مختلف پیشین مانند [۱۳] و [۱۴] و

<sup>۱</sup> Epoch

<sup>۲</sup> Decay Rate

<sup>۳</sup> SNR

<sup>۴</sup> Speckle

<sup>۵</sup> Accuracy

<sup>۶</sup> Fine-Tune

بالاتر به خاطر افزایش چشمگیر هزینه پردازشی و ابعاد بردار ویژگی است. در خصوص تعیین تعداد نورون‌های طبقه‌بند ابتدا از ۱۰۰۰ نورون استفاده شد (با الهام طبقه‌بند شبکه DenseNet-121) و برای اطمینان از کافی بودن تعداد نورون‌ها، این تعداد در آزمایشات مختلف تا ۱۵۰۰ افزایش پیدا کرد ولی منجر به بهبود طبقه‌بندی نشد لذا همان ۱۰۰۰ نورون، به عنوان تعداد نورون‌های طبقه‌بند در نظر گرفته شد. برای جلوگیری از بیش برآورد طبقه‌بند مدل پیشنهادی، پیش از لایه Softmax از Dropout با نرخ ۰٫۱ استفاده شده است. پیاده‌سازی Dropout در keras به صورت معکوس<sup>۲</sup> است. در این پیاده‌سازی به صورت رندم با نرخ تعیین شده (p) ورودی‌ها برابر با صفر قرار داده شده و به بقیه ورودی‌ها در  $(1/(1-p))$  ضرب می‌شوند تا مجموع تمام ورودی‌ها ثابت بماند. این موضوع موجب افزایش نرخ یادگیری حقیقی می‌شود و باید نرخ یادگیری الگوریتم SGD را کاهش داد. با توجه به اینکه نرخ یادگیری و تعداد مراحل یادگیری در رویکرد تنظیم دقیق وزن‌ها از اهمیت بالایی برخوردار است، از نرخ پایین Dropout استفاده شد و همچنین چندین لایه Dropout بکارگرفته نشد تا تنظیم پارامترهای مختلف شبکه برای فرآیند تنظیم دقیق وزن‌ها دچار پیچیدگی نشود. تمام آزمایش‌ها ابتدا بر روی مجموعه داده CURET اعمال شد که تعداد طبقات بیشتری دارد و نمونه‌های طبقات مختلف شباهت زیادی به یکدیگر دارند پس از آن، بر روی مجموعه UIUC و Outex آزمایش صورت گرفت. در خصوص نرخ یادگیری، با توجه به اینکه آموزش مدل پیشنهادی با رویکردی مشابه با تنظیم دقیق وزن‌ها صورت گرفته است ابتدا از نرخ یادگیری ثابت ۰٫۰۱ استفاده شد ولی سرعت همگرایی بسیار پایین بود لذا نرخ یادگیری به ۰٫۰۵ افزایش پیدا کرد ولی این نرخ، موجب ایجاد پرش (افزایش و کاهش) زیاد دقت ارزیابی در مراحل پایانی شده و همگرایی صورت نمی‌گرفت لذا از نرخ کاهش‌ی‌نمایی با مقدار اولیه ۰٫۰۵ استفاده شد که در طول روند آموزش با نرخ ۰٫۹۶ کاهش پیدا کرده است.

#### ۴-۲ زمان پردازش

شبکه‌های عصبی کانولوشن عمیق معمولاً زمان پردازش و میزان حافظه مصرفی بیشتری از روش‌های الگوی دودویی محلی و سایر روش‌های دست ساز دارند ولی در عوض منجر به دستیابی به دقت‌های طبقه‌بندی بالاتری می‌شوند. این روش‌ها معمولاً قابلیت اجرا بر روی پردازنده‌های گرافیکی را داشته و با این روش، مشکل زمان پردازشی آن‌ها تا حد زیادی بر طرف می‌شود. بیشتر روش‌های پیشین طبقه‌بندی بافت که مقاومت آنها در مقابل نویز ارزیابی شده است، مبتنی بر انواع الگوی دودویی محلی هستند. چون روش پیشنهادی در این پژوهش ترکیب روش الگوی دودویی محلی و شبکه عصبی عمیق است، طبیعتاً زمان پردازش و میزان حافظه مصرفی آن، از روش‌های پیشین بیشتر است ولی مدل

همین دلیل می‌تواند الگوهای متنوع تر و غنی تری را بیاموزد. دقت طبقه‌بندی داده‌های بافتی با استفاده از معماری DenseNet-121 (فقط استفاده از روش عمیق) بعد از روش پیشنهادی جزء بالاترین دقت‌ها و نزدیک به روش پیشنهادی است. این موضوع بیانگر کارایی بالای این معماری است و یکی از دلایل عمده کارایی روش پیشنهادی نیز استفاده از این شبکه عصبی عمیق است. دلیل دیگر استفاده از طبقه‌بندی کننده قدرتمند یعنی شبکه عصبی کاملاً متصل با تعداد مناسب نورون است که توانایی استفاده از ترکیب ویژگی‌های مختلف استخراج شده را دارد.

#### ۴-۱ جزئیات شبیه‌سازی

برای طراحی روش پیشنهادی ابتدا، صرفاً بر روی ترکیب ویژگی‌های CLBP و شبکه عصبی عمیق DenseNet-121 تمرکز شده است. برای این منظور ابتدا از ترکیب ویژگی‌های شبکه عصبی عمیق DenseNet-121 از پیش آموزش دیده با هر یک از ویژگی‌های (هیستوگرام) عملگرهای مختلف CLBP به صورت جداگانه، به عنوان بردار ویژگی استفاده شد، ولی ترکیب این ویژگی‌ها با شبکه عصبی عمیق منجر به افزایش دقت قابل توجهی نسبت به استفاده تنها از شبکه عصبی عمیق نشد. به دلیل عدم افزایش دقت حتی برای داده‌های بدون نویز، احتمالاً این ویژگی‌ها اطلاعات مکملی نسبت به یکدیگر نداشته‌اند. برای این ترکیب از هر دو نگاشت u2 وriu2 استفاده شده است. در مرحله بعد، از ادغام ویژگی‌های (هیستوگرام) سه عملگر با یکدیگر استفاده شد و این ویژگی‌های محلی با ویژگی‌های شبکه عصبی عمیق ترکیب شد. این روش نیز با هر دو نگاشت u2 وriu2 منجر به افزایش چشمگیر دقت طبقه‌بندی نسبت به استفاده تنها از شبکه عصبی عمیق نشد. در مرحله بعد از هیستوگرام سه بعدی الگوی دودویی محلی استفاده شد. این هیستوگرام در [۱۴] بیشترین دقت طبقه‌بندی را ارائه کرده است. با توجه به ابعاد بالای این هیستوگرام برای محاسبه آن فقط از نگاشت riu2 استفاده شده است. ترکیب این هیستوگرام با شبکه عصبی عمیق، منجر به افزایش دقت طبقه‌بندی و همچنین افزایش مقاومت آن در برابر نویز شد (نسبت به شبکه عصبی عمیق) ولی این ترکیب منجر به افزایش ابعاد بردار ویژگی روش پیشنهادی نسبت به شبکه عصبی عمیق شد. برای کاهش ابعاد بردار ویژگی، از چندین معماری ابداعی شبکه عصبی کانولوشن کم عمق استفاده شد (معماری‌های بین یک تا ۴ لایه) و با شبکه عصبی کانولوشن کم عمق پیشنهادی بهترین دقت طبقه‌بندی ارائه شد. در خصوص انتخاب شعاع و تعداد نقاط همسایگی، ابتدا از رویکرد چند مقیاسی با شعاع ۱ و ۲ (تعداد نقاط همسایگی ۸ و ۱۶) استفاده شد ولی در طی آزمایشات متعدد مشخص شد شعاع ۱ (تعداد نقاط همسایگی ۸) تأثیری در افزایش دقت طبقه‌بندی ندارد، به همین دلیل فقط از شعاع ۲ (و تعداد نقاط همسایگی ۱۶) استفاده شده است. عدم استفاده از شعاع

<sup>2</sup> Inverted

<sup>1</sup> Concatenate



سه آزمایش، به عنوان دقت نهایی آن نرخ SNR در نظر گرفته شده است. در هر مرتبه، ۲۰ تصویر از هر کلاس به صورت تصادفی برای آموزش انتخاب شده و از ۲۰ تصویر باقیمانده به عنوان نمونه‌های آزمایش استفاده شده است.

دقت طبقه‌بندی مدل پیشنهادی بر روی این مجموعه داده با مقادیر نویز گوسی مختلف و همچنین دقت طبقه‌بندی سایر روش‌های پیشرفته پیشین در جدول ۸ آورده شده است. ابعاد تصاویر این مجموعه داده به  $267 \times 200$  تغییر داده شد. (نزدیک به ابعاد مجموعه داده ImageNet) با استفاده از مدل پیشنهادی دقت طبقه‌بندی نسبت به روش‌های پیشرفته پیشین، خصوصاً برای SNRهای پایین، به صورت قابل توجهی افزایش یافته است.

جدول ۸ مقایسه دقت مدل پیشنهادی با سایر روش‌های پیشرفته پیشین برای مجموعه داده UIUC نویزی

روش	دقت (%)				
	SNR=3	SNR=5	SNR=10	SNR=15	SNR=30
LTP(R=1,P=8)	۶۰,۲۴	۶۲,۴۷	۶۶,۱۴	۷۳,۰۰	۷۷,۴۴
LBP/VAR	۵۶,۳۵	۵۵,۱۴	۶۴,۵۹	۷۱,۸۱	--
LBP_VAR_Entropy	۷۱,۰۲	۷۴,۲۹	۷۸,۰۴	۷۹,۴۰	--
CLBP_S/M/C (R=3, P=24)	۶۲,۸۵	۶۷,۵۴	۸۱,۶۴	۸۷,۶۵	۹۰,۳۸
CRLBP (R=3, P=24) $\alpha=1$	۷۶,۵۵	۷۹,۲۰	۸۸,۵۷	۹۲,۷۴	۹۳,۰۸
RMCLBP (R=1, P=8)	۸۲,۶۳	۸۵,۶۶	۹۱,۵۲	۹۱,۹۲	۹۳,۴۱
Mean-C + RMCLBP (R=1, P=8)	۸۶,۶۲	۹۰,۹۸	۹۲,۹۲	۹۳,۴۳	۹۳,۹۷
RFLCLBP (R=3, P=24; n=opt)	۸۷,۱۹	۹۲,۳۲	۹۴,۲۸	۹۴,۶۴	۹۴,۸۰
DenseNet-121	۹۲,۷۱	۹۵,۸۳	۹۵,۰۰	۹۸,۱۲	۹۶,۰۴
روش پیشنهادی	۹۴,۲۰	۹۷,۴۰	۹۸,۴۰	۹۸,۲۰	۹۹,۴۷

در شدت‌های بالای نویز گوسی دقت روش پیشنهادی نسبت به بهترین روش پیشین حدود ۷ درصد افزایش یافته است که بیانگر مقاومت بالای روش پیشنهادی در مقابل نویز گوسی است. نکته قابل توجه در نتایج این مجموعه داده این است که دقت طبقه‌بندی مدل پیشنهادی، برای بیشترین مقادیر نویز گوسی از دقت طبقه‌بندی داده‌های بدون نویز بهترین روش‌های پیشین موجود در جدول مثل RMCLBP (حتی با اعمال فرآیند پیش پردازش) و CRLBP هم بالاتر است. در این مجموعه داده بیشترین مقدار نویز گوسی دقت طبقه‌بندی شبکه عصبی DenseNet-121 را تنها در حدود ۴ درصد کاهش داده است. این موضوع نشان دهنده مقاومت نسبی ویژگی‌های استخراج شده توسط این شبکه در برابر نویز گوسی است.

دقت روش پیشنهادی در شرایط وجود نویز گوسی از هر دو روش الگوی دودویی محلی کامل و شبکه عصبی عمیق

پیشنهادی توانسته دقت طبقه‌بندی را نسبت به روش‌های قبلی به صورت قابل توجهی افزایش دهد. از طرفی برخلاف برخی روش‌ها که منحصراً یا برای SNR بالا و یا SNR پایین مناسب هستند، مدل پیشنهادی عملکرد خوبی برای مقادیر SNR کم و زیاد فراهم کرده است. علاوه بر این، مرحله آموزش و مرحله طبقه‌بندی روش پیشنهادی قابلیت اجرا بر روی پردازنده‌های گرافیکی<sup>۱</sup> (GPU) را داشته و این موضوع به طور چشمگیری موجب بهبود زمان اجرای این روش شده است.

زمان اجرای بخش‌های مختلف روش پیشنهادی بر روی مجموعه‌های داده مختلف در جدول ۷ آورده شده است.

جدول ۷ مقایسه زمان اجرای روش پیشنهادی بر روی مجموعه‌های داده مختلف

مراحل طبقه‌بندی روش پیشنهادی برای یک تصویر	مجموعه داده	زمان اجرای مدل پیشنهادی (میلی ثانیه)	
		محیط اول (GPU)	محیط دوم (CPU)
استخراج ویژگی با CLBP (R=2, P=16)	UIUC	۶۹	۵۷
	CUReT	۵۱	۴۳
	Outex	۲۰,۳	۱۹
یک مرحله آموزش مدل پیشنهادی (بدون CLBP)	UIUC	۱۱,۲	۶۶۰
	CUReT	۹,۲	۴۵۷
	Outex	۴,۸	۱۸۹
پیش بینی طبقه تصویر (بدون محاسبه CLBP)	UIUC	۲,۹	۱۲۰
	CUReT	۲,۹	۸۳,۴
	Outex	۱,۱	۲۷

با استفاده از GPU زمان آموزش روش پیشنهادی بین ۳۹ تا ۵۸ برابر و زمان پیش‌بینی (طبقه‌بندی) نیز بین ۲۴ تا ۴۱ برابر سریعتر شده است. به دلیل سربارهای ناشی از موازی‌سازی هر چه ابعاد تصاویر بزرگتر باشد (زمان پردازش هر تصویر بیشتر) باشد، افزایش سرعت بیشتر است. آموزش روش پیشنهادی (و همه شبکه‌های عصبی) به زمان زیادی نیاز دارد ولی با استفاده از GPU این زمان به شدت بهبود یافته است. بعد از اتمام آموزش مدل پیشنهادی، زمان طبقه‌بندی یک تصویر با این روش با استفاده از GPU، حدود ۵ درصد بیشتر از زمان محاسبه الگوی دودویی محلی کامل آن تصویر است. یعنی اگر از زمان آموزش صرف نظر کنیم، روش پیشنهادی برای طبقه‌بندی تصاویر، ۵ درصد نسبت به الگوی دودویی محلی کامل کندتر است در صورتی که دقت آن به شکل چشمگیری افزایش یافته و در مقابل نویز نیز مقاوم‌تر است.

#### ۳-۴ مقایسه نتایج برای مجموعه داده UIUC

در ارزیابی مجموعه داده UIUC، برای هر نرخ SNR، داده‌ها با سه تقسیم‌بندی متفاوت به داده آموزش و داده آزمون تقسیم و آموزش و ارزیابی مدل انجام شده است و میانگین دقت طبقه‌بندی

<sup>1</sup> Graphics Processing Unit

دقت روش پیشنهادی در تمام شدت‌های نویز گوسی و نقطه‌ای و بیشتر شدت‌های نویز فلفل نمکی از استفاده تنها از الگوی دودویی محلی کامل و شبکه عصبی عمیق بیشتر است. برای نمونه‌های این مجموعه داده، مقاومت روش پیشنهادی در مقابل نویز گوسی و نقطه‌ای بیشتر از مقاومت آن در مقابل نویز فلفل نمکی است.

افزایش دقت طبقه‌بندی روش پیشنهادی نسبت به شبکه عصبی عمیق DenseNet-121، نشان می‌دهد که ویژگی‌های الگوی دودویی محلی (با پارامترهای انتخاب شده) دارای اطلاعات مکمل ویژگی‌های شبکه عصبی عمیق است و ترکیب این ویژگی‌ها اطلاعات متمایز کننده‌تری را از هر یک از روش‌های الگوی دودویی محلی و شبکه DenseNet-121 ارائه کرده است. شبکه عصبی DenseNet-121 نیز نسبت به تمام روش‌های پیشین دقت طبقه‌بندی بالاتری به دست آورده است. چون در این شبکه نقشه‌های ویژگی لایه‌های مختلف به طبقه‌بند اعمال شده است، بردار ویژگی آن شامل سطوح مختلف پیچیدگی است و به همین دلیل توانمندی زیادی در شناسایی الگوهای متنوع بافتی متنوع دارد. استفاده از شبکه عصبی کاملاً متصل با تعداد مناسب نورون، به عنوان طبقه‌بند در دقت بالای طبقه‌بندی تاثیر گذار است چون توانسته از ویژگی‌های مکمل به خوبی بهره‌برداری کند.

#### ۴-۳ مقایسه نتایج برای مجموعه داده CURET

در ارزیابی مجموعه داده CURET داده‌ها با سه تقسیم‌بندی متفاوت به داده آموزش و داده آزمون تقسیم و آموزش و ارزیابی مدل انجام شده است و میانگین دقت طبقه‌بندی سه آزمایش، به عنوان دقت نهایی آن نرخ SNR در نظر گرفته شده است. در هر بار تقسیم، ۴۶ تصویر از هر کلاس به صورت تصادفی برای آموزش انتخاب شده و از ۴۶ تصویر باقیمانده به عنوان نمونه‌های آزمایش استفاده شده است. دقت طبقه‌بندی مدل پیشنهادی و سایر روش‌های پیشرفته پیشین بر روی مجموعه داده CURET با مقادیر مختلف نویز گوسی در جدول ۱۱ آورده شده است.

دقت طبقه‌بندی روش پیشنهادی نسبت به تمام روش‌های پیشرفته پیشین، خصوصاً برای شدت‌های بالای نویز گوسی، به صورت قابل توجهی افزایش داده است. در روش پیشنهادی بیشترین مقدار نویز گوسی، نسبت به داده‌های بدون نویز، تنها موجب ۳،۲۲ درصد افت دقت طبقه‌بندی شده است، در حالی که در بهترین روش پیشین، یعنی RMCLBP، بیشترین مقدار نویز گوسی موجب کاهش حدود ۱۰ درصدی دقت طبقه‌بندی (نسبت به داده‌های بدون نویز) شده است. این موضوع نشان دهنده قدرت مدل پیشنهادی در حذف تاثیر نویز گوسی برای این مجموعه داده است. بیشترین مقدار نویز در شبکه عصبی DenseNet-121 (استفاده تنها از ویژگی عمیق) موجب کاهش ۱۳ درصدی دقت نسبت به داده‌های بدون نویز شده است. همچنین بیشترین مقدار

DenseNet-121، نیز بیشتر است و روش پیشنهادی توانسته ویژگی‌های تفکیک پذیرتری را از تصاویر استخراج نماید. دقت طبقه‌بندی روش پیشنهادی بر روی مجموعه داده UIUC با مقادیر مختلف نویز فلفل نمکی در جدول ۹ آورده شده است. نویز فلفل نمکی با  $\text{density}=30$  شدت تخریب زیادی داشته و با جایگزینی حدود یک سوم پیکسل‌ها با مقادیر سفید یا سیاه، موجب تخریب شدید الگوهای بافتی شده است.

جدول ۹ دقت مدل پیشنهادی برای مجموعه داده UIUC با مقادیر مختلف نویز فلفل نمکی

روش	دقت (%)		
	density = 5	density = 15	density = 30
CLBP_S/M/C(R=1, P=8)	۸۶,۸۱	۸۷,۵۳	۷۹,۷۲
CLBP_S/M/C(R=2, P=16)	۹۰,۸۲	۹۰,۰۰	۸۲,۹۳
DenseNet-121	۹۶,۸۸	۹۵,۰۶	۸۳,۱۰
روش پیشنهادی	۹۹,۰۰	۹۶,۲۶	۸۵,۴۰

دقت روش پیشنهادی برای داده‌های تخریب شده با نویز نمک و فلفل، در همه شدت‌های نویز، از الگوی دودویی محلی کامل بیشتر است. در بیشتر شدت‌های نویز عملکرد روش پیشنهادی از شبکه عمیق DenseNet-121 نیز بهتر است. در نویز فلفل نمکی با  $\text{density}=15$  استفاده تنها از شبکه عصبی عمیق فقط ۰,۱ درصد نسبت به روش پیشنهادی دقت بالاتری ارائه است. دقت روش پیشنهادی بر روی این مجموعه داده با مقادیر مختلف نویز نقطه‌ای<sup>۱</sup> به همراه دقت شبکه عصبی عمیق DenseNet-121 و الگوی دودویی محلی کامل با دو شعاع مختلف در جدول ۱۰ آورده شده است. این نویز از نوع ضرب شونده است و  $\sigma$  انحراف معیار استاندارد است.

جدول ۱۰ دقت مدل پیشنهادی برای مجموعه داده UIUC با مقادیر مختلف نویز نقطه‌ای

روش	دقت (%)		
	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.3$
CLBP_S/M/C(R=1, P=8)	۸۶,۸۱	۸۰,۳۸	۷۴,۰۷
CLBP_S/M/C(R=2, P=16)	۹۰,۸۲	۸۷,۵۹	۸۰,۸۵
DenseNet-121	۹۶,۸۸	۹۶,۲	۹۲,۵
روش پیشنهادی	۹۹,۰۰	۹۸,۲۶	۹۴,۶۰

<sup>1</sup> Speckle noise

روی مجموعه داده CURET با شدت‌های مختلف نویز نقطه‌ای آورده شده است.

جدول ۱۳ دقت مدل پیشنهادی برای مجموعه داده CURET با مقادیر

مختلف نویز نقطه‌ای

دقت (%)				روش
بدون نویز	$\sigma=5$	$\sigma=15$	$\sigma=30$	
۹۵,۲۸	۸۷,۲۶	۸۰,۲۶	۷۴,۹۸	CLBP_S/M/C(R=1, P=8)
۹۵,۰۵	۹۰,۳۱	۸۴,۵۸	۷۹,۵۳	CLBP_S/M/C(R=2, P=16)
۹۸,۳۳	۹۹,۶۸	۹۸,۶۹	۹۷,۱۴	DenseNet-121
۹۹,۶۲	۹۹,۳۶	۹۸,۹۰	۹۸,۰۰	روش پیشنهادی

روش پیشنهادی دقت بالایی در تفکیک نمونه‌های مجموعه داده CURET با وجود نویز فلفل نمکی و نویز نقطه‌ای ارائه داده است و روش پیشنهادی دقت بالاتری از الگوی دودویی محلی با شعاع و تعداد همسایگی مختلف و شبکه عصبی DenseNet-121 ارائه کرده است.

دلیل این قدرت تفکیک پذیری در شرایط مختلف نویز گوسی نویز فلفل نمکی و نویز نقطه‌ای و شرایط بدون نویز نیز استفاده از ترکیب ویژگی‌های دو توصیفگر الگوی دودویی محلی و شبکه عصبی عمیق DenseNet-121 است که اطلاعات مکمل دارند. و همچنین استفاده از شبکه عصبی کاملاً متصل با تعداد مناسب نورون به عنوان طبقه‌بند در افزایش دقت طبقه‌بندی موثر است. در این مجموعه داده در شدت بالای نویز گوسی دقت طبقه‌بندی خوبی توسط شبکه عصبی عمیق DenseNet-121 ارائه نشده است. این موضوع به خاطر تعداد بالای طبقات و همچنین شباهت بسیار زیاد تصاویر برخی از کلاس‌ها به کلاس‌های دیگر است که در نویزهای بالا، تفکیک نمونه‌های هر کلاس را مشکل‌تر می‌نماید و باید برای دستیابی به دقت بالاتر، از توصیفگر قدرتمندتری استفاده کرد. استفاده از ترکیب ویژگی‌ها باعث ایجاد مقاومت بالا در مقابل نویز به خصوص در شدت‌های بالای نویز شده است و دقت طبقه‌بندی را به صورت چشمگیر افزایش داده است. به عبارت دیگر افزودن ویژگی‌های الگوی دودویی محلی کامل، موجب افزایش مقاومت شبکه عصبی عمیق در برابر نویز شده است. هر چند یکی از عوامل قدرت روش پیشنهادی استفاده از شبکه عصبی قدرتمند DenseNet-121 است ولی در شرایط نویز شدید، استفاده از ترکیب ویژگی‌ها موجب جبران ضعف‌های این شبکه شده است.

نویز در الگوی دودویی محلی کامل موجب کاهش حدود ۴۸ درصدی دقت طبقه‌بندی شده است. مقایسه این مقادیر با افت دقت ۳,۲۲ درصدی روش پیشنهادی بیانگر این است که ترکیب ویژگی‌ها در روش پیشنهادی، موجب افزایش چشمگیر مقاومت در برابر نویز شده است.

جدول ۱۱ مقایسه دقت مدل پیشنهادی با سایر روش‌های پیشرفته پیشین برای مجموعه داده CURET با نویز گوسی

دقت (%)						روش
SNR=100	SNR=30	SNR=15	SNR=10	SNR=5	SNR=3	
۸۷,۸۲	۸۵,۲۸	۷۹,۴۴	۶۸,۷۳	۴۷,۷۲	--	DLBP
۸۸,۳۷	۸۵,۳۳	۸۰,۳۸	۷۱,۴۰	۶۳,۴۰	--	DBWP
۹۲,۲۲	۹۰,۱۵	۸۶,۶۶	۸۴,۵۵	۷۷,۴۸	۷۰,۶۷	LTP(MS9)
۹۱,۵۶	۸۵,۹۹	۷۸,۹۸	۷۴,۹۰	۶۵,۷۴	۵۶,۳۱	NTLBP(MS9)
۹۶,۸۱	۹۵,۳۹	۹۳,۶۹	۹۰,۹۲	۸۶,۱۱	۸۰,۴۵	BRINT1_CS_CM(MS9)
۹۵,۵۱	۹۵,۸۷	۸۷,۲۳	۷۲,۷۷	۵۱,۳۵	۴۷,۷۷	CLBP_S/M/C (R=3, P=24)
۹۶,۰۶	۹۵,۹۰	۹۳,۵۶	۸۵,۵۸	۶۹,۶۷	۶۶,۵۵	CRLBP (R= 3, P= 24)
۹۵,۱۶	۹۶,۲۶	۹۵,۸۷	۹۴,۱۶	۸۹,۸۳	۷۸,۲۳	RMCLBP (R= 1, P= 8)
۹۶,۷۱	۹۶,۶۲	۹۶,۲۰	۹۶,۴۳	۸۹,۳۳	۸۶,۷۰	Mean-C + RMCLBP (R=1, P= 8)
۹۶,۱۷	۹۵,۷۸	۹۲,۸۱	۸۶,۰۶	۷۱,۲۸	--	DLBP+NGF
۹۸,۳۳	۹۸,۷۵	۹۸,۱۱	۹۷,۸۶	۹۳,۳۰	۸۵,۳۵	DenseNet-121
۹۹,۶۲	۹۹,۵۹	۹۹,۳۴	۹۹,۴۹	۹۸,۶۷	۹۶,۵۷	روش پیشنهادی

جدول ۱۲ دقت مدل پیشنهادی برای مجموعه داده CURET با مقادیر مختلف نویز فلفل نمکی

دقت (%)				روش
بدون نویز	density = 5	density = 15	density = 30	
۹۵,۲۸	۹۳,۰۰	۸۶,۰۲	۷۴,۶۲	CLBP_S/M/C(R=1, P=8)
۹۵,۰۵	۹۴,۴۲	۸۶,۱۳	۷۲,۱۴	CLBP_S/M/C(R=2, P=16)
۹۸,۳۳	۹۷,۷۸	۹۶,۵۳	۹۰,۳۳	DenseNet-121
۹۹,۶۲	۹۸,۵۰	۹۶,۶۶	۹۱,۰۰	روش پیشنهادی

دقت طبقه‌بندی روش پیشنهادی بر روی مجموعه داده CURET با شدت‌های مختلف نویز فلفل نمکی در جدول ۱۲ آورده شده است. لازم به ذکر است که در نویز فلفل نمکی با density=30 حدود یک سوم پیکسل‌ها با مقدار سفید یا سیاه جایگزین شده و تاثیر شدیدی بر روی تخریب الگوهای بافتی دارد. در جدول ۱۳ دقت طبقه‌بندی روش پیشنهادی در مقایسه با الگوی دودویی کامل و شبکه عصبی عمیق DenseNet-121 بر

ارائه کرده است. این موضوع نیز نشان دهنده استخراج اطلاعات مکمل به وسیله الگوی دودویی محلی و شبکه عصبی عمیق DenseNet-121 است که قدرت تمایز بیشتری از استفاده تنها از هر یک از ویژگی‌ها و همچنین روش‌های قبلی دارد. همچنین طبقه بندی کننده مورد استفاده در این پژوهش نیز توانایی استفاده از این ویژگی‌های مکمل را دارد.

جدول ۱۴ مقایسه دقت روش پیشنهادی با سایر روش‌های پیشرفته پیشین برای مجموعه داده Outex نويزی با نويز گوسی با  $\sigma=5$

دقت (%)		روش
Outex TC 23n	Outex TC 11n	
۹۱,۵	۹۷,۱	SSLBP
۷۹,۲	۹۱,۵	MRELBP
۷۶,۸	۹۱,۹	LEP
۵,۶	۱۱,۹	CLBP
۱۵,۴	۲۶,۷	CLBC
۲۷,۴	۶۱,۹	BRINT
۴۵,۳	۷۷,۱	ScatNet (NNC)
۵۰,۷	۷۴,۰	PCANet
۷۱,۵	۹۳,۱	FV-VGGVD (SVM)
۸۶,۵۴	۹۶,۶۷	DenseNet-121
۹۱,۷۶	۹۹,۷۹	روش پیشنهادی

## ۵ نتیجه گیری و پیشنهادات آینده

در این پژوهش با ترکیب توصیفگر الگوی دودویی محلی کامل (CLBP) و شبکه عصبی عمیق کانولوشن DenseNet-121 از پیش آموزش دیده، یک روش برای طبقه‌بندی تصاویر بافتی نويزدار ارائه کردیم. این روش از دو نوع استخراج ویژگی تشکیل شده است. در نوع اول استخراج ویژگی از الگوی دودویی محلی کامل با  $(P=16$  و  $R=2)$  استفاده شده است. در نوع دوم، با استفاده از شبکه عصبی عمیق کانولوشن DenseNet-121 ویژگی‌های تصاویر بافتی نويزدار استخراج شده و با ترکیب آنها با هیستوگرام سه بعدی الگوهای دودویی محلی، بردار ویژگی روش پیشنهادی تشکیل شده است. نوآوری دوم این پژوهش استفاده از شبکه عصبی کانولوشن کم عمق به عنوان تبدیل و برای کاهش ابعاد ویژگی هیستوگرام الگوهای دودویی محلی است. این روش یک روش نظارت شده است که ابعاد ویژگی‌های الگوهای دودویی محلی را به صورت قابل توجهی کاهش داده و بار پردازشی کمی (نسبت به هزینه پردازشی آموزش کل مدل) به همراه دارد.

## ۴-۴ جمع بندی دقت طبقه‌بندی روش پیشنهادی بر روی مجموعه‌های داده مختلف

برای سهولت ارزیابی عملکرد روش پیشنهادی بر روی مجموعه‌های مختلف، میانگین دقت طبقه‌بندی روش پیشنهادی در مقادیر مختلف نويز به همراه میانگین دقت بهترین روش پیشین و میانگین دقت الگوی دودویی محلی کامل و شبکه عصبی DenseNet-121 در جدول ۱۵ آورده شده است.

## ۴-۵ مقایسه نتایج برای مجموعه داده Outex

برای ارزیابی کارایی روش پیشنهادی بر روی مجموعه‌داده Outex از دو مجموعه آموزشی Outex\_TC\_11n و Outex\_TC\_23n استفاده شده است که برای ارزیابی مقاومت الگوریتم‌ها در مقابل نويز طراحی شده‌اند. این دو مجموعه آزمایشی در [۳] استفاده شده است و به وسیله آنها، دقت طبقه‌بندی ۳۰ روش مختلف الگوی دودویی محلی و چندین نسخه مختلف از ۳ رویکرد یادگیری عمیق، در شرایط وجود نويز ارزیابی شده است.

در این دو مجموعه تصاویر با روش‌شنایی 'inca' و زاویه صفر برای آموزش و همان تصاویر با نويز گوسی با انحراف معیار استاندارد ۵ برای آزمون استفاده شده است. Outex\_TC\_11n دارای ۲۴ کلاس بافتی و Outex\_TC\_23n دارای ۶۸ کلاس بافتی است. دقت طبقه‌بندی روش پیشنهادی و سایر روش‌های پیشرفته پیشین بر روی مجموعه داده Outex در جدول ۱۴ آورده شده است. در این مجموعه داده هم، دقت مدل پیشنهادی از تمام روش‌های پیشرفته پیشین از جمله روش‌های قدرتمند MRELBP و SSLBP بیشتر است. مجموعه Outex\_TC\_23n نسبت به تمامی مجموعه‌های داده مورد استفاده در این پژوهش از تعداد طبقات بافتی بیشتری برخوردار است. ترکیب ویژگی‌های مختلف در روش پیشنهادی دقت طبقه‌بندی را نسبت به استفاده مجزا از الگوی دودویی محلی و معماری DenseNet-121 به صورت قابل توجهی افزایش داده است. هر چند یکی از عوامل قدرت و تفکیک‌پذیری روش پیشنهادی استفاده از شبکه عصبی قدرتمند DenseNet-121 است ولی استفاده از این شبکه به تنهایی منجر به دستیابی به دقت قابل توجه بر روی مجموعه Outex\_TC\_23n نشده است ولی با استفاده ترکیبی از توصیفگرها، منجر به استخراج ویژگی‌های متمایز کننده‌ای شده است و دقت طبقه‌بندی را برای این مجموعه پیچیده نسبت به بهترین روش‌های پیشین نیز افزایش داده است. این موضوع نشان دهنده این است که الگوی دودویی محلی کامل ویژگی‌های مکملی را نسبت به شبکه عصبی عمیق DenseNet-121 استخراج کرده و مقاومت آن را در برابر نويز افزایش داده است. تعداد ویژگی‌های روش SSLBP ۲۴۰۰ عدد است که بیش از دو برابر تعداد ویژگی‌های روش پیشنهادی است ولی روش پیشنهادی، دقتی بالاتر از آن



جدول ۱۵ میانگین دقت طبقه‌بندی روش پیشنهادی، الگوی دودویی محلی کامل و شبکه عصبی عمیق DenseNet-121

میانگین دقت برای هر مجموعه داده و نوع نويز						روش
CURET			UIUC			
نويز نقطه‌ای	نويز فلغل نمکی	نويز گوسی	نويز نقطه‌ای	نويز فلغل نمکی	نويز گوسی	
-	-	۹۳,۶۶	-	-	۹۳,۰۰	بهترین روش پیشین مقاوم به نويز
۸۷,۳۷	۸۶,۹۴	۷۵,۰۸	۸۵,۵۱	۸۸,۲۷	۸۰,۱۳	CLBP با بهترین پارامترها
۹۸,۴۶	۹۵,۷۴	۹۵,۲۸	۹۵,۰۵	۹۲,۷	۹۵,۷۶	DenseNet-121
۹۸,۹۷	۹۶,۴۵	۹۸,۸۸	۹۷,۰۵	۹۳,۴۵	۹۷,۷۸	روش پیشنهادی

طبقه‌بندی را نسبت به روش‌های قبلی به صورت قابل توجهی افزایش داده است. علاوه بر این پیاده‌سازی روش پیشنهادی با استفاده از GPU موجب افزایش سرعت ۳۹ تا ۵۸ برابری در مرحله آموزش و نیز ۲۴ تا ۴۱ برابری در زمان پیش‌بینی (طبقه‌بندی) شده است.

الگوی دودویی محلی ویژگی‌های بافتی (ریز ساختارها) تصاویر را استخراج می‌کند و در مقابل نويز مقاومت نسبی دارد. ویژگی‌های این عملگر (هیستوگرام) برای تجزیه و تحلیل بافت عملکرد خوبی ارائه کرده است (نه طبقه‌بندی سایر تصاویر). شبکه عصبی denseNet121 عملکرد بالایی در طبقه‌بندی تصاویر بافتی و همچنین سایر تصاویر مثل اشیاء ارائه داده است. به همین دلیل ممکن است روش پیشنهادی عملکرد مناسبی در طبقه‌بندی سایر تصاویر ارائه دهد ولی تضمینی وجود ندارد که این روش برای طبقه‌بندی اشیاء نیز در مقابل نويز مقاوم باشد و یا اینکه ترکیب این دو ویژگی موجب بهبود دقت طبقه‌بندی در سایر تصاویر گردد.

ایده استفاده از ترکیب ویژگی‌های چندین توصیفگر می‌تواند توسعه یابد و در کنار الگوی دودویی محلی و شبکه عصبی کانولوشن عمیق، از سایر توصیفگرها نیز استفاده شود تا دقت طبقه‌بندی افزایش یابد. بهره‌گیری از طبقه‌بندی‌کننده‌های متفاوت و همچنین نحوه مختلف ترکیب ویژگی‌ها یا استفاده از روش‌های گروهی<sup>۱</sup> نیز می‌تواند در پژوهش‌های آینده موجب بهبود دقت طبقه‌بندی گردد. یکی دیگر از مواردی که در پژوهش‌های آینده باید مد نظر قرار بگیرد بررسی تاثیر بخش‌ها و پارامترهای مختلف شبکه عصبی در عملکرد روش پیشنهادی است. برای مثال بررسی تاثیر استفاده از ادغام حداکثری به جای ادغام میانگین یا تاثیر استفاده از نمونه‌های مختلف ReLU به عنوان تابع فعال ساز از موارد مهمی است که می‌تواند در پژوهش‌های آینده مورد توجه قرار گیرد. انجام فرآیندهای پیش پردازش مختلف بر روی تصاویر نیز می‌تواند در کاهش مراحل و زمان آموزش تاثیرگذار باشد.

## منابع و مآخذ:

[1] Cataldo S. D., Ficarra E., "Mining Textural Knowledge in Biological Images: Applications, Methods and Trends",

<sup>1</sup> Ensemble

برای طبقه‌بندی نیز از شبکه عصبی کاملاً متصل با ۱۰۰۰ نورون استفاده شده است. در این پژوهش مجموعه‌های داده معروف بافتی UIUC و CURET با مقادیر مختلف نويز گوسی، نويز فلغل نمکی و نويز نقطه‌ای با استفاده از روش پیشنهادی طبقه‌بندی شده است. همچنین برای ارزیابی روش پیشنهادی در مقابل نويز گوسی از دو مجموعه Outex نیز استفاده شده است. دقت طبقه‌بندی مدل ارائه شده نسبت به تمامی روش‌های گذشته، که عمدتاً مبتنی بر استفاده از یک روش استخراج ویژگی هستند، به صورت قابل توجهی افزایش یافته است. از طرفی تعداد ویژگی‌های روش پیشنهادی، نسبت به تعداد ویژگی‌های برخی روش‌های قدرتمند پیشین کمتر و البته از برخی از آن‌ها بالاتر است. دقت طبقه‌بندی روش پیشنهادی نسبت به استفاده تنها از الگوی دودویی محلی و شبکه عصبی عمیق DenseNet-121 نیز در شدت‌های مختلف نويز گوسی، نقطه‌ای و فلغل نمکی ارزیابی شده است و در اکثر موارد استفاده از روش پیشنهادی دقت بالاتری از استفاده تنها از هر یک از توصیفگرها ارائه داده است. میزان افت دقت طبقه‌بندی روش پیشنهادی در اثر وجود نويز گوسی نسبت به روش‌های پیشین بسیار کمتر است و این روش به خوبی با اثرات نويز گوسی مقابله کرده است. مقاومت روش پیشنهادی در مقابل نويز گوسی و نقطه‌ای بیشتر از نويز فلغل نمکی است. یکی از روش‌های استخراج ویژگی شبکه عصبی عمیق کانولوشن DenseNet-121 از پیش آموزش دیده است که دقت بالایی در طبقه‌بندی مجموعه تصاویر ImageNet ارائه داده است. استفاده از طبقه‌بندی‌کننده شبکه عصبی کاملاً متصل با تعداد مناسب نورون، نیز در افزایش دقت تاثیر گذار است. برخلاف برخی روش‌ها که منحصراً یا برای نسبت سیگنال به نويز بالا و یا نسبت سیگنال به نويز پایین مناسب هستند، روش پیشنهادی عملکرد خوبی برای مقادیر نسبت سیگنال به نويز کم و زیاد فراهم می‌کند. یک نوع استخراج ویژگی روش پیشنهادی مبتنی بر شبکه‌های عصبی عمیق است. شبکه‌های عصبی عمیق معمولاً زمان پردازش و میزان حافظه مصرفی بیشتری از روش‌های الگوی دودویی محلی و سایر روش‌های دست ساز دارند. چون مدل پیشنهادی در این پژوهش ترکیب الگوی دودویی محلی و شبکه عصبی عمیق است، طبیعتاً زمان پردازش و میزان حافظه مصرفی آن، از روش‌های پیشین که مبتنی بر یکی از روش‌ها است، بیشتر است ولی روش پیشنهادی دقت

- [14] Guo Z., Zhang L., Zhang D., "A Completed Modeling of Local Binary Pattern Operator for Texture Classification", *IEEE Transactions on Image Processing*, vol. 19, no. 6, pp. 1657–1663, 2010, doi:10.1109/TIP.2010.2044957.
- [15] Zhao Y., Huang D., Jia W., "Completed Local Binary Count for Rotation Invariant Texture Classification", *IEEE Transactions on Image Processing*, vol. 21, no. 10, pp. 4492–4497, 2012, doi:10.1109/TIP.2012.2204271.
- [16] Liao S., Law M. W. K., Chung A. C. S., "Dominant Local Binary Patterns for Texture Classification", *IEEE Transactions on Image Processing*, vol. 18, no. 5, pp. 1107–1118, 2009, doi:10.1109/TIP.2009.2015682.
- [17] Tan X., Triggs B., "Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions", *IEEE Transactions on Image Processing*, vol. 19, no. 6, pp. 1635–1650, 2010, doi:10.1109/TIP.2010.2042645.
- [18] Jin H., Liu Q., Lu H., Tong, X., "Face Detection Using Improved LBP Under Bayesian Framework", *Third International Conference on Image and Graphics (ICIG'04)*, pp. 306–309, 2004, doi:10.1109/ICIG.2004.62.
- [19] Zhao Y., Jia W., Hu R. X., Min H., "Completed Robust Local Binary Pattern for Texture Classification", *Neurocomputing*, vol. 106, pp. 68–76, 2013.
- [20] Shakoor M.H., Tajeripour F., "Repeating Average Filter for Noisy Texture Classification". *Scientia Iranica*, Sharif University of Technology. 24, no.3, pp. 1419–1436, 2017.
- [21] Liu L., Lao S., Fieguth P. W., Guo Y., Wang X., Pietikäinen M., "Median Robust Extended Local Binary Pattern for Texture Classification", *IEEE Transactions on Image Processing*, vol. 25, no. 3, pp. 1368–1381, 2016, doi:10.1109/TIP.2016.2522378.
- [22] Shakoor, M.H., Boostani, R., "Radial Mean Local Binary Pattern for Noisy Texture Classification", *Multimedia Tools and Applications*, vol. 77, pp. 21481–21508, 2018, doi:10.1007/s11042-017-5440-0.
- [23] Krizhevsky A., Sutskever I., Hinton G. E., "ImageNet classification with deep convolutional neural networks. Commun", *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017. doi:10.1145/3065386.
- [24] Wang P., Zhang X., Hao Y., "A Method Combining CNN and ELM for Feature Extraction and Classification of SAR Image", *Journal of Sensors*, 2019, doi:10.1155/2019/6134610
- [25] Bello-Cerezo R., Bianconi F., Di Maria F., Napoletano P., Smeraldi F., "Comparative Evaluation of Hand-Crafted Image Descriptors vs. Off-the-Shelf CNN-Based Features for Colour Texture Classification under Ideal and Realistic Conditions", *Applied Sciences*, vol. 9, no.4, 738, 2019, doi:10.3390/app9040738.
- [26] Russakovsky O., Deng J., Su H., Krause J., Satheesh S., and et al. "ImageNet Large Scale Visual Recognition Challenge", *International Journal of Computer Vision*, vol. 115, pp. 211–252, 2015, doi:10.1007/s11263-015-0816-y.
- [27] Bell S., Upchurch P., Snavely N., Bala K., "Material recognition in the wild with the Materials in Context Computational and Structural Biotechnology Journal, Vol. 15, pp.56–67, 2017, doi:10.1016/j.csbj.2016.11.002.
- [2] Tuceryan M., Jain A. K., Chen C., Pau L., Wang P. (Eds.), *Handbook of Pattern Recognition and Computer Vision*, second ed., World Scientific Publishing Co., River Edge, NJ, USA, 1998, pp. 207–248.
- [3] Liu L., Fieguth P., Guo Y., Wang X., Pietikäinen M., "Local Binary Features for Texture Classification: Taxonomy and Experimental Study", *Pattern Recognition*, vol. 62, pp. 135–160, 2017, doi:10.1016/j.patcog.2016.08.032.
- [۴] محمدحسین شکور، فرشاد تاجری پور، "الگوی انتروپی محلی جهت استخراج ویژگیهای تصاویر بافتی"، *مجله ماشین بینایی و پردازش تصویر*، دوره ۳، شماره ۲، ص ۷۳ تا ۸۵، ۱۳۹۵.
- [5] Kandaswamy U., Adjeroh D. A., Lee M. C., "Efficient Texture Analysis of SAR Imagery", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 9, pp. 2075–2083, Sept. 2005, doi:10.1109/TGRS.2005.852768.
- [6] He C., Li S., Liao Z., Liao M., "Texture Classification of PolSAR Data Based on Sparse Coding of Wavelet Polarization Textons", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 8, pp. 4576–4590, 2013, doi:10.1109/TGRS.2012.2236338.
- [7] Sutton R. N., Hall E. L., "Texture Measures for Automatic Classification of Pulmonary Disease", *IEEE Transactions on Computers*, vol. C-21, no. 7, pp. 667–676, 1972, doi:10.1109/T-C.1972.223572.
- [8] López E. F., García Á. M., Blanco L. S., Marinero J. C. F., Turiel J. P., "Automatic Gauze Tracking in Laparoscopic Surgery Using Image Texture Analysis", *Computer Methods and Programs in Biomedicine*, vol. 190, 2020, 105378, doi:10.1016/j.cmpb.2020.105378.
- [9] Tajeripour F., Kabir E., Sheikhi A. "Fabric Defect Detection Using Modified Local Binary Patterns", *EURASIP Journal on Advances in Signal Processing*, 783898, 2008, doi:10.1155/2008/783898.
- [10] Bharati M. H., Liu J. J., MacGregor J. F., "Image texture analysis: methods and comparisons", *Chemometrics and Intelligent Laboratory Systems*, vol. 72, pp. 57–71, 2004, doi:10.1016/j.chemolab.2004.02.005.
- [11] Ojala T., Pietikainen M., Harwood D., "Performance Evaluation of Texture Measures with Classification Based on Kullback Discrimination of Distributions", *Proceedings of 12th International Conference on Pattern Recognition*, vol.1, pp. 582–585, 1994, doi:10.1109/ICPR.1994.576366.
- [12] Ojala T., Pietikäinen M., Harwood D., "A Comparative Study of Texture Measures With Classification Based on Featured Distributions", *Pattern Recognition*, vol. 29, no. 1, pp. 51–59, 1996, doi:10.1016/0031-3203(95)00067-4.
- [13] Ojala T., Pietikainen M., Maenpaa T., "Multiresolution Grayscale and Rotation Invariant Texture Classification with Local Binary Patterns". *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol. 24, no. 7, pp. 971–987, 2002.

- [40] Tang J., Su Q., Su B., Fong S., Cao W., Gong X., "Parallel Ensemble Learning of Convolutional Neural Networks and Local Binary Patterns for Face Recognition", *Computer Methods and Programs in Biomedicine*, vol 197, 2020.
- [41] Anwer R. M., Shahbaz Khan F., Weijer J. V. D., Molinier M., Laaksonen J., "Binary Patterns Encoded convolutional neural networks for texture recognition and Remote Sensing Scene Classification", *ISPRS Journal of Photogrammetry and Remote Sensing*, pp. 74–85, vol 138, 2018.
- [42] Chan CH., Kittler J., Messer K., "Multi-scale Local Binary Pattern Histograms for Face Recognition". *Advances in Biometrics. ICB. Lecture Notes in Computer Science*, vol 4642. pp 809–818, 2007, doi: 10.1007/978-3-540-74549-5 85.
- [43] Andrearczyk V., Whelan P. F., *Biomedical Texture Analysis Fundamentals, Tools and Challenges*, the Elsevier and MICCAI Society Book Series, Academic Press, pp. 95–129, 2017.
- [44] Ding Y., Cheng Y., Cheng X., Li B., You X., and et al. "Noise-Resistant Network: a Deep-Learning Method for Face Recognition under Noise". *EURASIP Journal on Image and Video Processing* volume, 43, 2017, <https://doi.org/10.1186/s13640-017-0188-z>.
- [45] Ojala T., Maenpaa T., Pietikainen M., Viertola J., J. Kyllonen and et al, "Outex – New Framework for Empirical Evaluation of Texture Analysis Algorithms", *Object recognition supported by user interaction for service robots*, vol.1, pp. 701–706, 2002, doi: 10.1109/ICPR.2002.1044854.
- [46] Lazebnik S., Schmid C., Ponce J., "A Sparse Texture Representation Using Local Affine Regions", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 8, pp. 1265–1278, 2005, doi:10.1109/TPAMI.2005.151.
- [47] Dana K. J., Ginneken B. V., Nayar S. K., Koenderink J. J. "Reflectance and Texture of Real-World Surfaces", *ACM Transactions on Graphics*. 18(1). pp. 1–34. 1999, doi:10.1145/300776.300778.
- [48] <http://lagis-vi.univ-lille1.fr/datasets/outex.html>
- [49] Valls J.M., Aler R., Galván I.M, Camacho D., "Supervised data transformation and dimensionality reduction with a 3-layer multi-layer perceptron for classification problems", *Journal of Ambient Intelligence and Humanized Computing*, 2021. <https://doi.org/10.1007/s12652-020-02841-y>
- [50] Chollet, F., and et al. (2015). Keras. <https://keras.io>.
- Database", 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 3479–3487, 2015, doi:10.1109/CVPR.2015.7298970.
- [28] Simonyan K., Zisserman A., "Very Deep Convolutional Networks for Large-Scale Image Recognition" *International Conference on Learning Representations* 2015.
- [29] Szegedy C. et al., "Going deeper with convolutions", 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1–9, 2015, doi:10.1109/CVPR.2015.7298594.
- [30] He K., Zhang X., Ren S., Sun J., "Deep Residual Learning for Image Recognition", 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778, 2016, doi:10.1109/CVPR.2016.90.
- [31] Huang G., Liu Z., Maaten L. V. D., Weinberger K. Q., "Densely Connected Convolutional Networks", 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2261–2269, 2017, doi:10.1109/CVPR.2017.243.
- [32] Liu L., et al. "From BoW to CNN: Two Decades of Texture Representation for Texture Classification" *International Journal of Computer Vision*, vol. 127, pp. 74–109, 2019, doi: 10.1007/s11263-018-1125-z.
- [33] Cimpoi M., Maji S., Kokkinos I., Vedaldi A., "Deep Filter Banks for Texture Recognition, Description, and Segmentation". *International Journal of Computer Vision*, vol. 118, pp. 65–94, 2016, doi: 10.1007/s11263-015-0872-3.
- [34] Cimpoi M., Maji S., Kokkinos I., Mohamed S., Vedaldi A., "Describing Textures in the Wild," 2014 IEEE Conference on Computer Vision and Pattern Recognition, pp. 3606–3613, 2014, doi:10.1109/CVPR.2014.461.
- [35] Cimpoi M., Maji S., Vedaldi A., "Deep Filter Banks for Texture Recognition and Segmentation", 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 3828–3836, 2015, doi:10.1109/CVPR.2015.7299007.
- [36] Andrearczyk V., Whelan P. "Using Filter Banks in Convolutional Neural Networks for Texture Classification." *Pattern Recognition Letters*, vol. 84, pp. 63–69, 2016. 10.1016/j.patrec.2016.08.016.
- [37] Lin T., RoyChowdhury A., Maji S., "Bilinear CNN Models for Fine-Grained Visual Recognition", 2015 IEEE International Conference on Computer Vision (ICCV), pp. 1449–1457, 2015, doi:10.1109/ICCV.2015.170.
- [38] Zhang, J. Marszałek, M. Lazebnik, S. Lazebnik, C. Schmid. "Local Features and Kernels for Classification of Texture and Object Categories: A Comprehensive Study". *International Journal of Computer Vision*, vol 73, pp. 213–238, 2007. doi:10.1007/s11263-006-9794-4
- [39] Zhang S., Han F., Liang Z., Tan J., Cao W., Gao Y., Pomeroy M., Ng Ke., Hou W., "An Investigation of CNN Models for Differentiating Malignant from Benign Lesions Using Small Pathologically Proven Datasets", *Computerized Medical Imaging and Graphics*, vol. 77, 101645, 2019.



محمد حسین شکور مدرک کارشناسی و ارشد خود را در رشته کامپیوتر به ترتیب از دانشگاه شیراز و اصفهان دریافت کردند. ایشان دکترای خود را در رشته هوش مصنوعی از دانشگاه شیراز اخذ نمودند. تخصص ایشان پردازش تصویر و یادگیری عمیق است و هم‌اکنون عضو هیات علمی دانشگاه اراک می‌باشند.



جواد آسلیمی ضامنجان‌ی مدرک کارشناسی و کارشناسی ارشد خود را در رشته نرم افزار در سال‌های ۱۳۹۲ و ۱۴۰۰ از دانشگاه اراک دریافت کرده اند زمینه‌های پژوهشی مورد علاقه وی یادگیری و بینایی ماشین است.



محسن رحمانی مدرک کارشناسی کامپیوتر خود را از دانشگاه شیراز اخذ کردند، ایشان مدارک ارشد و دکترای خود را در رشته کامپیوتر از دانشگاه علم و صنعت ایران دریافت کرده اند. تخصص ایشان پردازش سیگنال و هوش مصنوعی است. ایشان هم‌اکنون عضو هیات علمی دانشگاه اراک هستند.