

# آشکارسازی و تعیین مکان متون فارسی-عربی در تصاویر ویدئویی

محی الدین مرادی، سعید مظفری و علی اصغر اروجی

دانشکده مهندسی برق و کامپیووتر، دانشگاه سمنان، سمنان، ایران

## چکیده

استخراج اطلاعات متنی از تصاویر ویدئویی، در کاربردهایی نظیر تحلیل معنایی ویدئو، بازبایی اطلاعات متنی و بازبایی اطلاعات مربوط به تصاویر ویدئویی آرشیو شده نقش مهمی دارد. در این مقاله، روشی جهت استخراج متن فارسی-عربی از تصاویر ویدئویی ارائه می‌شود. در ابتدا، جهت کاهش حساسیت به اندازه قلم، بر اساس تصویر ورودی هرمی دارای سه وضوح ایجاد می‌شود. سپس با استفاده از آشکارساز لبه، لبه‌های موجود در تصویر استخراج و با یافتن مکان تلاقی لبه‌ها، تصویرگوشه تصنیعی ایجاد می‌شود. جهت حذف گوششده‌های تصنیعی نواحی غیرمتنی، تحلیل هیستوگرام انجام می‌شود. ضرایب تبدیل فوریه کسینوسی گستته به لوك‌های تصویر استخراج و با ترکیب تعدادی از آنها، تصویر شدت بافت حاصل می‌شود. در ادامه جهت جداسازی نواحی متنی از غیرمتنی، با یک طبقه‌بندی کننده، با تلفیق مشخصه‌های حاصل از تصویرگوشه تصنیعی و تصویر شدت بافت، برداری مشکل از مشخصه‌ها تشکیل می‌شود. در پایان، با رسم نمودارهای هنجاری‌سازی شده شدت بافت، بازبینی نهایی انجام شده و تفکیک خطوط متنی انجام می‌شود.

واژگان کلیدی: متون فارسی-عربی، ویدئو، آشکارسازی متن، گوشش تصنیعی، تبدیل فوریه کسینوسی گستته، طبقه‌بندی SVM

## ۱- مقدمه

در میان محتویات معنایی موجود در تصاویر ویدئویی، اطلاعات متنی اهمیت فراوانی دارد. آشکارسازی و استخراج متن از تصاویر ویدئویی، یکی از موضوعات چالش‌برانگیز، معروف و شناخته شده در تحقیقات بینایی ماشین و تشخیص الگوست، به طوری که امروزه محققان فراوانی در این زمینه مشغول به فعالیت هستند. با توجه به تحقیقات فراوانی که در خصوص بینایی ماشین و تشخیص الگو انجام شده است، تکامل یافته‌های موجود در بازبایی محتویات از داخل تصاویر ویدئویی، موضوعی ضروری است. امروزه بسیاری از تصاویر ویدئویی حاوی اطلاعات متنی شامل متن مرتبط با صدای ویدئو، ترجمه متن، نتایج مسابقات ورزشی یا تلویزیونی، وضعیت بورس یا آب و هوا، اخبار فوری و موارد مشابه آنها هستند. یکی از کاربردهای پرطرفدار اطلاعات

متنی، اضافه کردن اطلاعات متنی به تصویر، جهت اندیس‌گذاری و جستجوی خودکار متن براساس اندیس‌های موجود در ویدئوست. این موضوع نیاز به استخراج متن از تصاویر ویدئویی را به طور چشم‌گیری افزایش داده است. در این تحقیق سعی شده رهیافت مناسبی برای استخراج متن فارسی ارائه شود.

متن می‌تواند با سبک‌ها، اندازه‌ها و جهت‌های گوناگون در تصویر قرار گیرد. از این رو جداسازی متن از پس‌زمینه، می‌تواند امری چالش‌برانگیز باشد. از جمله خصوصیات مورد استفاده جهت آشکارسازی متن، می‌توان به نحوه قرارگیری متن در تصویر، میزان بسامد نویسه‌ها در نواحی متنی، همبستگی مکانی میان نویسه‌ها و توزیع رنگ در نواحی متنی اشاره کرد. علاوه بر مشکلات موجود در استخراج متن از تصاویر ویدئویی، دستگاه‌های نوری شناخت نویسه نیز محدودیت‌هایی دارند [Jung, et al., 2004].

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

تصاویر، پیچیدگی زیاد پس زمینه در برخی از تصاویر،  
تغییرات در اندازه، رنگ و جهت قرارگیری متن در تصاویر  
اشارة کرد [Jung, et al., 2004, Liang, et al., 2005, Zhang, et al., 2008]

در گذشته، تلاش‌های متعددی جهت استخراج متن از تصاویر ویدئویی انجام گرفته است. برخی از خصوصیات متنی استفاده شده جهت استخراج نواحی متنی از تصاویر ویدئویی عبارتند از: رنگ و سطح خاکستری نواحی متنی و پس زمینه، اختلاف در شدت روشنایی و تباين نواحی متنی و پس زمینه، تفاوت ساختاری موجود در بافت تصویر، جهت قرارگیری متن در تصویر و بعد هندسی ناحیه متنی.

در مرجع [Xiaoqian, et al., 2012] روش مبتنی بر استخراج لبه، جهت افزایش کارایی و دقت سامانه پیشنهادی از تصحیح محتوای فریم‌های متوالی، تعیین موقعیت زمانی-مکانی و نیز جداسازی زیرنویس‌های موجود در تصویر بهره می‌گیرد. در [Zhao, et al., 2011] یک سامانه خودکار آشکارسازی متن براساس نقاط گوشه که یکی از ویژگی‌های مهم نواحی متنی است، استفاده شده است. بلوک‌های متنی می‌توانند از طریق تغییر رنگ میان نواحی متنی و پس زمینه مجاور آن تشخیص داده شوند. نواحی دارای متن می‌توانند به صورت تقریبی از طریق محاسبه چگالی پیکسل‌های در حال تغییر و پیکسل‌های پایدار مجاور مورد شناسایی قرار گیرند [Wonjun and Changick., 2009]. در مرجع [Shivakumara, et al., 2011] متن مصنوعی اضافه شده به تصویر و متن ذاتی موجود در تصویر قابل تشخیص است. در استخراج متن ذاتی موجود بر متن افقی تأکید بهدلیل آنکه اغلب سامانه‌های موجود بر متن افقی تأکید دارند، تمرکز سامانه بر جهت متن استوار است. در حوزه فرکانس، لاپلاسین به تشخیص نواحی متنی کمک کرده و تحلیل اسکلت جهت قسمت‌بندی اجزا به هم متصل شده پیچیده به بخش‌های ساده‌تر مورد استفاده قرار می‌گیرند. در مرجع [Li, et al., 2011] روش استخراج متن بر اساس نقاط کلیدی متن ارائه شده است. نقاط کلیدی متن به عنوان نقاطی تعریف می‌شوند که هم‌زمان بافت قوی در جهات عمودی، افقی و قطری دارند. نقاط کلیدی متن از طریق سه باند فرعی فرکانس بالای تبدیل موجک استخراج گشته و افزایش دقت و کارایی را در پی خواهد داشت.

به طور کلی می‌توان گفت در تحقیقات انجام شده جهت آشکارسازی متن در تصاویر از دو گروه الگوریتم آشکارسازی با عنایوین آشکارسازی بر اساس ناحیه و

## ۲- بررسی مراحل مختلف استخراج متن از تصاویر ویدئویی

به طور کلی سامانه‌های استخراج متن، طبقات مختلفی دارند که عنوان هر یک از این طبقات همراه با نحوه ارتباط میان آنها با یکدیگر در شکل (۱) نمایش داده شده است [Jung, et al., 2004]

در مرحله آشکارسازی، وجود یا عدم وجود متن در تصویر از طریق روش‌های متعددی مشخص می‌شود. در مرحله تعیین مکان متن، مکان متن در داخل تصویر مشخص شده و در اطراف آن کادری کشیده می‌شود. در بسیاری از موارد، مرحله آشکارسازی و تعیین مکان به صورت همزمان با یکدیگر صورت می‌گیرند. در مرحله استخراج و ارتقای متن، اجزای متن از بخش پس زمینه تصویر جدا شده و تصویر، قطعه قطعه می‌شود. نواحی متن به طور معمول وضوح پایینی دارند؛ لذا در معرض نویه قرار داشته و لازم است ارتقا داده شوند. در این تحقیق، هدف معرفی روشی در خصوص مراحل آشکارسازی و تعیین مکان متن فارسی در تصاویر ویدئویی است؛ لذا موضوعات شامل مراحل ریدیابی مکان متن، استخراج و ارتقای متن و تشخیص حروف در این نوشتار مد نظر نخواهند بود.



(شکل ۱)- مراحل مورد نیاز جهت استخراج متن از تصاویر ویدئویی

## ۳- مرواری بر تحقیقات انجام شده جهت استخراج متن از تصاویر ویدئویی

الگوریتم‌هایی که جهت استخراج متن از تصاویر ویدئویی ارائه شده‌اند، همگی نواقصی دارند که این مطلب ناشی از وجود تغییرات گسترده متن و تصاویر ویدئویی است. از جمله این موارد می‌توان به پایین‌بودن تفاوت شدت روشنایی در

[Jung, et al., 2004, Liang, et al., 2005, Zhang, et al., 2008, Wonjun and Changick., 2009]

#### ۱- استخراج اجزای بهم متصل شده

۲- تحلیل اجزای بهم متصل شده جهت تشخیص متن یا غیر متن بودن آنها

۳- پردازش نهایی جهت اتصال اجزای گوناگون متن به یکدیگر (کلمات و خطوط)

#### ۲-۳- آشکارسازی متن بر اساس بافت تصویر

در این روش، با فرض وجود بافت ویره در نواحی متنی، از طریق تحلیل‌های مبتنی بر بافت تصویر، جداسازی نواحی متن از پس‌زمینه امکان‌پذیر است. در الگوریتم‌های آشکارسازی مبتنی بر بافت تصویر، مقادیر پیکسل‌ها بررسی می‌شوند و چنانچه نوافه روی مشخصه‌های بافت پیکسل‌های مجاور اثری نداشته باشد، آنگاه اثر نوافه پس‌زمینه در آشکارسازی نواحی متنی حذف خواهد شد. در طراحی طبقه‌بندی کننده‌های بافت تصویر، از آموزش‌های آماری استفاده می‌شود. از این رو سامانه دارای مقاومت بالاتری بوده و امکان تعمیم‌دهی آن به وجود می‌آید. با این وجود عمده‌ترین مسئله در این گونه الگوریتم‌ها، پیچیدگی محاسباتی است؛ زیرا تمامی نواحی تصویر تحت جستجو قرار گرفته و تحلیل بافت تصویر زمان زیادی نیازخواهد داشت. نگرانی دیگری که در این روش وجود دارد مربوط به دقت انتخاب نواحی متنی است. با توجه به اینکه تحلیل بافت، بر اساس همسایگی پیکسل‌ها عمل می‌کند، امکان دستیابی به دقت موجود در روش‌های مبتنی بر اجزای بهم متصل شده وجود نخواهد داشت.

#### ۴- طبقه‌بندی خصوصیات کلی متن در زبان‌های مختلف

در حالت کلی خصوصیات متن به دو دسته تقسیم می‌شوند. دسته اول شامل خصوصیاتی است که مستقل از نوع زبان‌اند. دسته دوم شامل خصوصیاتی است که از زبانی به زبان دیگر متفاوت خواهد بود [Jung, et al., 2004, Cai, et al., 2002].

#### ۱-۴- خصوصیات مستقل از نوع زبان

**الف- تباین:** نواحی متنی در مقایسه با نواحی غیر متنی نسبت به ناحیه پس‌زمینه خود تباين قابل توجهی دارند. میزان این تباين، با توجه به میزان پیچیدگی ناحیه پس‌زمینه، متغير است. چنانچه ناحیه پس‌زمینه ناحیه

آشکارسازی بر اساس بافت تصویر استفاده شده است [Jung, et al., 2004, Lienhart and Wernicke., 2002 , Kim, et al., 2003]

#### ۳- آشکارسازی متن بر اساس ناحیه

در روش آشکارسازی بر اساس ناحیه از مشخصه‌های مربوط به نواحی متنی استفاده می‌شود. از جمله این مشخصات می‌توان به سطح خاکستری نواحی متن و پس‌زمینه اشاره کرد. در این روش می‌توان از طریق تفاوت مشخصه‌های نواحی متنی و پس‌زمینه، متن را استخراج کرد. در این روش در ابتدا لبه‌ها و اجزای بهم متصل شده استخراج می‌شوند. در مرحله بعد، این ساختارها با یکدیگر گروه بزرگ‌تری را تشکیل داده و در نتیجه، بلوکی از یک ناحیه متن را مشخص می‌کنند. این روش خود به دو صورت قابل پیاده‌سازی است [Jung, et al., 2004, Liang, et al., 2005, Zhang, et al., 2008]

##### الف- استخراج متن بر اساس لبه‌ها

این روش بر اساس وجود تباين بالا میان نواحی متن و پس‌زمینه استوار است و از این طریق، امکان جداسازی متن از پس‌زمینه فراهم می‌شود. در این روش، ابتدا لبه‌های موجود در تصویر از طریق یک آشکارساز لبه، همانند Canny، استخراج می‌شوند و نواحی غیر متنی بر اساس دسته‌ای قوانین، از نواحی متنی جدا خواهد شد. در ادامه، با استفاده از اپراتورهای ریخت‌شناسی<sup>۱</sup> و یا فیلترهای هموارکننده، لبه‌های تأییدشده با یکدیگر ادغام می‌شوند. کارایی در این روش به مقدار قابل توجهی، به آشکارساز لبه بستگی دارد. در برخی مواقع لبه‌های نواحی متن و پس‌زمینه به راحتی قابل تشخیص نبوده و درنتیجه الگوریتم‌های مبتنی بر لبه، فقط در کاربردهای مشخصی قابل استفاده هستند [Xiaoqian, et al., 2012, Zhao, et al., 2011]

##### ب- استخراج متن بر اساس اجزای بهم متصل شده

در این روش متن به صورت مجموعه‌های از اجزای مستقل بهم متصل شده در نظر گرفته می‌شوند. در این وضعیت هر یک از اجزا دارای شدت روشنایی، توزیع رنگ و منحنی بسته مشخصی خواهد بود. با گروه‌بندی اجزای کوچک به اجزای بزرگ‌تر، همه نواحی تصویر مشخص می‌شوند. این روش‌ها به طور عمومی از سه مرحله زیر

<sup>۱</sup> Morphological Operators

**پ- کوچکترین نسبت ابعاد کلمات:** زبان چینی زبانی نویسه محور است. به عبارت دیگر در این زبان یک نویسه به تنها می تواند یک مفهوم مستقل داشته باشد. زبان های فارسی و انگلیسی بر اساس کلمات می باشند و برای ایجاد یک کلمه لازم است چندین نویسه به یکدیگر متصل شوند. از این رو کوچکترین نسبت ابعاد کلمات با معنی مستقل، در این زبان ها با یکدیگر متفاوت است.

**ت- توزیع آماری تکانه ها در جهات مختلف:** تکانه ها در حروف انگلیسی عمدها در جهت عمودی قرار دارند و به همین دلیل بسیاری از الگوریتم های استخراج متن بر اساس تکانه های عمودی استوارند. در زبان های فارسی و چینی این موضوع متفاوت است و به همین دلیل الگوریتم هایی که بر این اساس برای زبان انگلیسی تهیه شده اند، برای زبان های فارسی و چینی قابل اعمال نیستند.

**ث- جهت قرار گیری متن در تصویر:** متن در تصاویر باید به گونه ای قرار گیرد تا در کنار محتویات دیگر موجود در ویدئو به آسانی برای بیننده قابل درک باشد. از این رو در تصاویر ویدئویی به طور معمول متن فارسی به صورت افقی نوشته شده و لذا کافی است برای زبان هایی همانند فارسی و انگلیسی فقط متن افقی مورد توجه قرار گیرد.

## ۵- اهمیت زبان فارسی و ویژگی های آن

نویسه های زبان فارسی در چندین زبان دیگر از جمله عربی، اردو و پشتو مورد استفاده قرار می گیرند. درواقع حدود نیم میلیارد از مردم کره زمین با این حروف سر و کار دارند. زبان عربی، زبان به کار رفته در قرآن بوده و اغلب مسلمانان، که جمعیتی در حدود یک چهارم جمعیت کل کره زمین را تشکیل می دهند، نوانی ای خواندن زبان عربی را دارند. با این وجود هنوز آشکارسازی متن فارسی از تصاویر ویدئویی مورد توجه جدی قرار نگرفته است. برخی از خصوصیات متن فارسی عبارتند از:

**الف-** نویسه های خط فارسی روی یک خط فرضی معروف به خط مينا به صورت شکسته و متصل به یکدیگر نوشته می شوند. به دلیل اتصال حروف به یکدیگر، بلوکی از نویسه ها می تواند تشکیل شود. در زبان فارسی حروف کوچک و بزرگ همانند آنچه برای زبان انگلیسی در نظر گرفته می شود، وجود ندارد.

**ب-** نویسه های فارسی با توجه به مکان قرار گیری آنها در کلمه می توانند بیش از یک شکل داشته باشند. با توجه به

ساده ای باشد، در آن صورت حتی متن دارای تباین پایین نیز قابل شناسایی است. چنانچه ناحیه پس زمینه دارای بافت پیچیده ای باشد، فقط نواحی متنی دارای تباین بالا قابل تشخیص اند.

**ب- رنگ:** در اغلب جملات، رنگ نویسه های متنی مشابه است و تغییر نمی کند. با این وجود در فرآیند فشرده سازی با اتلاف، در لبه های متن و پس زمینه مقداری تداخل رنگ ایجاد می شود.

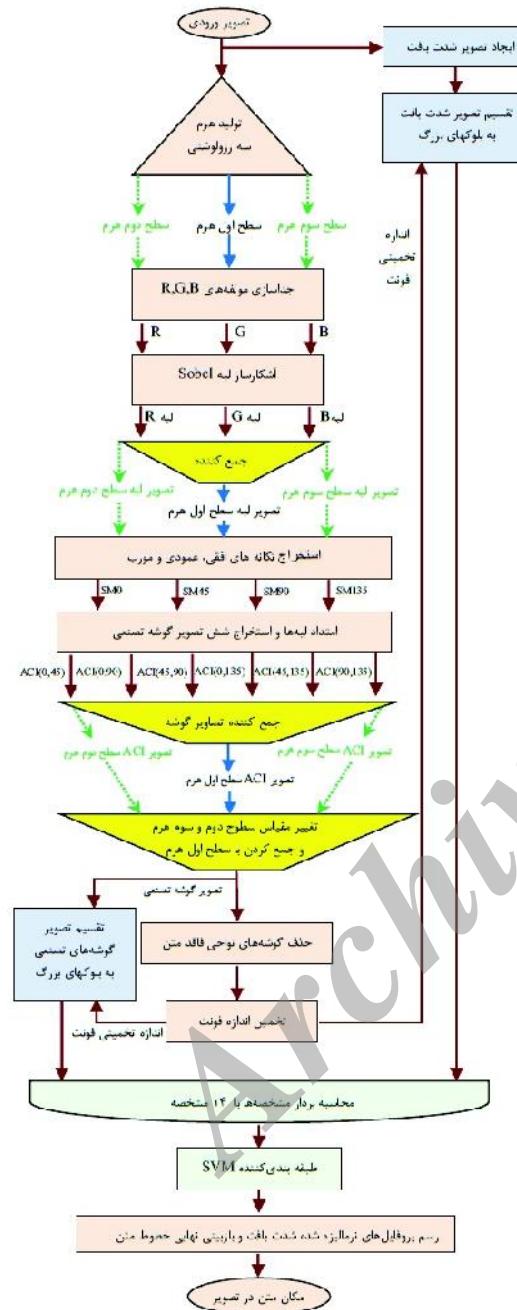
**پ- متحرک** یا ثابت بودن متن در تصویر: متن در تصویر جایگاه ثابت یا متحرکی دارد. اغلب پیام های بازار گانی و اخبار فوری و مواردی امثال آن به صورت زیرنویس متحرک در پایین تصویر نوشته می شوند. این موضوع سبب افزایش اهمیت فرآیند ردیابی متن خواهد شد. جهت حرکت متن با توجه به نوع زبان به کار رفته می تواند تغییر کند. به عنوان مثال در زبان فارسی به طور عمومی متن از طرف چپ به طرف راست و یا از پایین به طرف بالا حرکت می کند.

## ۴- خصوصیات وابسته به زبان

**الف- چگالی تکانه های موجود در متن:** تکانه های ایجاد شده توسط یک قلم، حرکات یا علامت هایی هستند که در هنگام نوشتن توسط قلم ایجاد می شوند. تکانه در واقع چهار چوب یک نوشته را نمایش می دهد. در زبان انگلیسی و فارسی چگالی تکانه های موجود در نواحی مختلف متنی به طور معمول مقدار یکسانی است. در زبان هایی همانند کره ای و چینی، این چگالی می تواند در نواحی مختلف متن تفاوت داشته باشد. برای مثال اگر چه در زبان چینی برخی حروف فضای یکسانی را اشغال می کنند، ولی تعداد تکانه های موجود در آنها با یکدیگر تفاوت دارد.

**ب- کوچکترین اندازه قلم به کار رفته در متن:** در تصویر جهت نمایش تمامی تکانه های موجود در یک متن لازم است با توجه به چگالی تکانه های موجود در حروف، کوچکترین اندازه قلم قابل استفاده تعیین شود. به عنوان نمونه نویسه های چینی به دلیل چگالی بالای تکانه های موجود در آنها، در مقایسه با نویسه های انگلیسی و فارسی، فضای بیشتری را اشغال کرده و به همین دلیل این نویسه ها باید با اندازه قلم بزرگتر نمایش داده شوند. چنانچه بخواهیم روش های استخراج متن مبتنی بر تکانه زبان های چینی، کره ای و انگلیسی را به زبان فارسی اعمال کنیم در آن صورت به دلیل این تفاوت نتایج مطلوبی حاصل نمی شود.

(بخش ۷-۶). در این روش، در هر ثانیه فقط دو فریم مورد بررسی قرار می‌گیرند. این انتخاب بر اساس حداقل زمانی که مغز جهت رؤیت و درک کامل یک تصویر پیچیده لازم دارد [Leon and Gasulll., ۲۰۰۵]



شکل ۲)- طرح پیشنهادی جهت آشکارسازی و تعیین مکان متن فارسی- عربی از تصاویر ویدئویی

مفهوم بلوک نویسه‌ها، یک نویسه می‌تواند در ابتداء، وسط، انتهای و یا در حالت تنها قرار بگیرد.

پ- برخی از قلم‌ها در زبان فارسی رایج‌تر بوده و در کتب، مقالات و نامه‌های رسمی از آنها استفاده می‌شود. این قلم‌ها عبارتند از Yaghut، Traffiic، Nazanin، Mitra، Lotus

[Khosravi and Kabir., 2010] Titr، Homa، Zar ت- مستقل از نوع و سبک قلم، برای یک اندازه قلم مشخص، ارتفاع همه قلم‌ها به‌طور تقریبی یکسان است. برای مثال چنانچه قلم‌های متداول ده گانه فارسی با اندازه بیست را در نظر بگیریم، در یک تصویر پال ارتفاع همه آنها به‌طور تقریبی برابر ۱۷ تا ۲۳ پیکسل خواهد بود. از این رو سعی می‌کنیم تصویر را بر اساس ارتفاع قلم هنجارسازی کنیم. این امر ناشی از این واقعیت است که هر اندازه قلمی را می‌توان با یک ارتفاع معادل‌سازی کرد. در اغلب متون فارسی موجود در تصاویر ویدئویی، اندازه قلم به‌طور معمول میان ۱۵ تا ۲۵ متغیر است. از این رو به عنوان یک فرض منطقی اولیه، می‌توان اندازه قلم موجود در تصویر را برابر ۲۰ در نظر گرفت.

## ۶- طرح پیشنهادی

در شکل (۲) روندnamای طرح پیشنهادی نشان داده شده است. جهت کاهش حساسیت طرح استخراج متن به تغییر اندازه قلم، در ابتدا هر م سه وضوحی تصویر ورودی ایجاد می‌شود (بخش ۱-۶). سپس جهت استخراج لبه‌ها با استفاده از آشکارساز لبه، چهار طرح تکانه<sup>۱</sup> (SM) افقی، عمودی و مورب تولید می‌شوند (بخش ۲-۶). به‌منظور استخراج گوشتهای نواحی متنی، با استخراج گوشتهای تصنیعی سطوح مختلف هر م، تصویر گوشة تصنیعی<sup>۲</sup> ACI، شده (بخش ۳-۶) و با رسم هیستوگرام افقی هنجارسازی شده و اعمال محدودیت‌های ابتکاری، اندازه واقعی قلم به‌کمک تصویر گوشة تصنیعی تخمین زده می‌شود (بخش ۴-۶). در ادامه به‌منظور شناسایی بافت نواحی مختلف تصویر، از روی تصویر ورودی تصویر شدت بافت ایجاد می‌شود (بخش ۵-۶). سپس بردار مشخصه‌ها محاسبه شده و جهت جداسازی نواحی متن، از طبقه‌بندی کننده SVM<sup>۳</sup> استفاده می‌شود (بخش ۶-۶). در نهایت با رسم نمودارهای افقی و عمودی، مکان دقیق متن در تصویر ویدئویی مشخص خواهد شد

<sup>1</sup> Stroke Map

<sup>2</sup> Artificial Corner Image

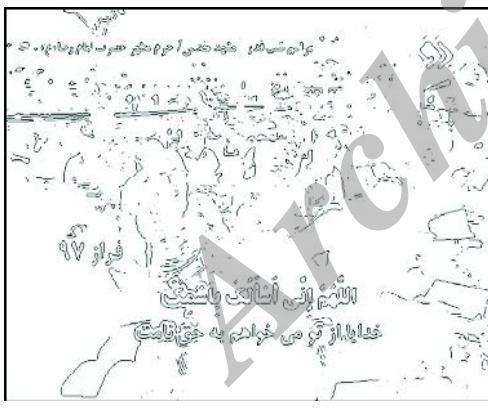
<sup>3</sup> Support Vector Machine

جهت افقی، عمودی و مورب دارند. از این رو چنانچه ناحیه‌ای از تصویر دارای چگالی بالایی از لبه در این جهات باشد (بهویژه افقی و عمودی) آنگاه به احتمال زیاد این ناحیه دارای متن خواهد بود. در صورت استخراج لبه از روی تصویر خاکستری، در برخی از تصاویر دارای متنون رنگی، با خطای عدم تشخیص لبه‌های متنی از پس زمینه مواجه می‌شویم. لذا جهت غلبه بر مشکلات ناشی از رنگی بودن تصویر، تصویر به سه مؤلفه رنگ‌های سبز، آبی و قرمز تفکیک شده و سه اپراتور آشکارساز لبه Sobel به تصاویر مؤلفه‌های رنگی اعمال می‌شوند. سپس با ادغام لبه‌های موجود در سه مؤلفه رنگ، یک تصویر لبه ایجاد می‌شود.

شکل (۴- ب).



(الف)



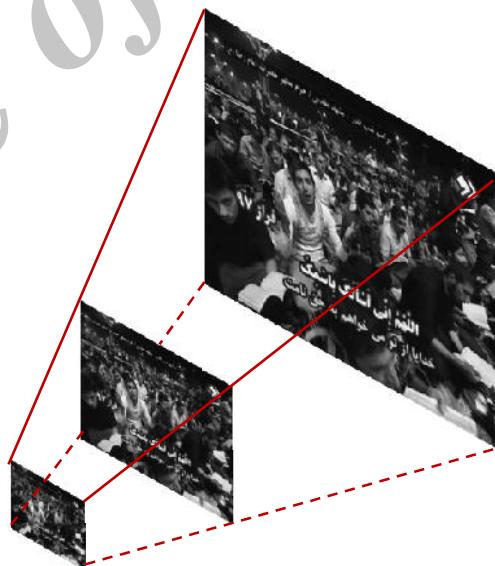
(ب)

شکل (۴)- الف: تصویر ورودی ب: تصویر لبه

با توجه به ویژگی‌هایی اپراتور آشکارساز لبه Sobel، در روش پیشنهادی از این آشکارساز لبه استفاده می‌شود. این اپراتور دارای مشخصه ایزوتروپیک بوده و درنتیجه پاسخ یکنواختی را در تمامی جهات ایجاد می‌کند. لبه‌های آشکار شده توسط این اپراتور دارای چگالی بالایی بوده و سبب

## ۶-۱ ایجاد هرم سه‌وضوحي جهت کاهش حساسیت آلگوریتم به تغییرات اندازه قلم

یکی از مشکلات موجود در موضوع استخراج متن از تصاویر ویدئویی، تغییر اندازه قلم متن موجود در تصاویر است. چنانچه بتوان در ابتدا اندازه قلم را مشخص کرد، آنگاه آشکارسازی متن با دقت بیشتری انجام می‌شود. متأسفانه تاکنون هیچ روش مؤثری در این خصوص ارائه نشده است. جهت کاهش حساسیت آلگوریتم پیشنهادی به تغییر اندازه قلم و رفع خطای احتمالی ناشی از اندازه قلم پیش‌فرض بیست تصویر ورودی از طریق یک فیلتر گوسی، به صورت متوالی فیلتر می‌شود تا یک هرم سه‌وضوحي مرتبط با آن ایجاد شود شکل (۳). در ساخت این هرم، وضوح در هر مرحله به نصف حالت پیشین خود کاهش داده می‌شود. همان‌گونه که در ادامه شرح داده خواهد شد، تمامی پردازش‌های لازم جهت استخراج گوشه‌های تصنیعی، روی هر سه سطح هرم انجام شده و با افزودن گوشه‌های تصنیعی سطوح مختلف به یکدیگر، یک تصویر گوشی حاصل خواهد شد.



شکل (۳)- هرم سه‌وضوحي تصویر ورودی

## ۶-۲ آشکارسازی لبه‌ها

یکی از مشخصه‌های مهم نواحی متنی در تصویر لبه است و می‌تواند جهت استخراج متن از تصاویر ویدئویی مورد استفاده قرار گیرد. متنون فارسی به طور معمول تکانه‌هایی در

فصلنامه  
دولتی

در خصوص استخراج متون چینی و یا انگلیسی به کار روند، امکان آشکارسازی دقیق متن فارسی وجود نخواهد داشت. به عنوان اولین تلاش جهت رفع مشکل و افزایش چگالی تکانه‌ها در نواحی متنی، می‌توان تکانه‌ها را امتداد داد.

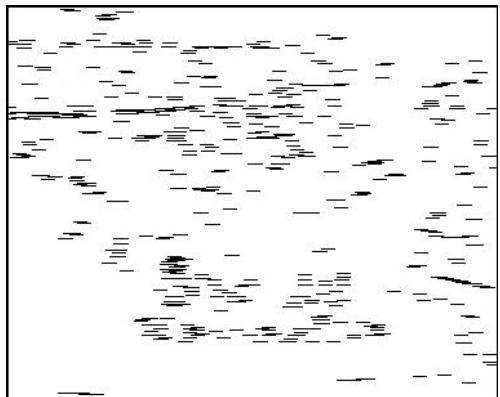
از این رو با توجه به اندازه قلم پایه، هر یک از تکانه‌های ۰، ۹۰، ۴۵ و ۱۳۵ درجه از طریق یک اپراتور گشايش با المان ساختاری دارای طول بیست پیکسل، در جهت مربوطه امتداد داده می‌شوند شکل (۶). این پردازش مشکل کم‌بودن چگالی تکانه‌ها در نواحی متنی را مرفوع می‌کند؛ ولی سبب افزایش لبه‌های اضافی در نواحی غیر متنی خواهد شد. برای غلبه بر این مشکل مفهوم گوشة تصنیعی معروفی می‌شود. محل برخورد دو تکانه امتداد داده شده را یک گوشة تصنیعی می‌نامیم. صفت تصنیعی به این گوشه‌ها ناشی از این واقعیت است که این گوشه‌ها، از طریق تکانه‌های امتداد داده شده حاصل می‌شوند و نه از طریق محل تلاقی تکانه‌های واقعی موجود در تصویر. انتخاب المان ساختاری با طول بیست پیکسل جهت اپراتور گشايش بر این اساس است که با توجه به اینکه اندازه قلم پایه برابر بیست در نظر گرفته شده است لذا با استفاده از اپراتور گشايش با المان ساختاری دارای طول بیست پیکسل، می‌توان تکانه‌های مختلف داخل یک سطراز متن فارسی را به مقدار کافی امتداد داده تا این طریق علاوه بر افزایش چگالی تکانه، امتداد تکانه‌ها با یکدیگر برخورد کرده و گوشه‌های مصنوعی ایجاد شوند. چنانچه اثر امتدادهای تکانه‌ها در روند رشد تعداد گوشه‌های تصنیعی مورد بررسی قرار گیرند، نتایج حاکی از رشد چشم‌گیر گوشه‌های تصنیعی در نواحی متن، در مقایسه با نواحی پس زمینه است. در توجیه این پدیده کافی است به تغییرات گرادیان لبه‌ها در یک تصویر توجه شود. یکی از ویژگی‌های نواحی متنی، تغییرات شبیه پریویدیک گرادیان لبه افقی است. از این رو با افزایش طول لبه‌های موجود در تصویر، در نواحی متنی نسبت به نواحی غیر متنی تغییرات شبیه گرادیان لبه در امتداد افقی، رشد بیشتری خواهد داشت. به طور کلی یک ناحیه متنی دارای ترکیب شبیه منظمی از لبه‌های افقی، عمودی و مورب است. لذا با افزایش طول تکانه‌ها، نرخ رشد گوشه‌های تصنیعی نواحی متنی در اغلب موارد بیشتر خواهد بود.

پس از استخراج لبه‌ها در چهار جهت اصلی، از محل تلاقی هر دو لبه متفاوت، مطابق رابطه زیر یک تصویر گوشة تصنیعی (ACI) ایجاد می‌شود.

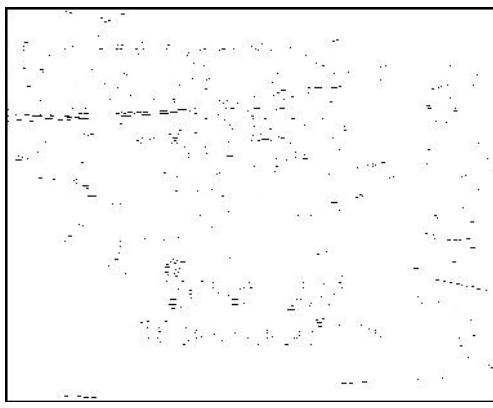
افزایش لبه در نواحی متنی خواهد شد. با توجه به عدم آشکارسازی تمامی لبه‌ها توسط این اپراتور، نواحی دارای تباين پایین مربوط به پس زمینه، به راحتی توسط فرآيند آستانه گذاري حذف شده و تشخيص لبه‌های مربوط به نواحی متنی آسان‌تر انجام می‌شود. با توجه به ویژگی‌های بيان شده در خصوص متن فارسی و دلایل انتخاب اندازه قلم پیش فرض ۲۰، مجموعه‌ای مشکل از هشتاد تصویر ویدئوی شامل قلم‌های متنوع با اندازه قلم حدود بیست پیکسل از تصاویر موجود در پایگاه داده، که در بخش (۷) به آن پرداخته خواهد شد، تهیه شد. اگرچه می‌توان جهت افزایش دقت و حصول به نتایج مطلوب‌تر تعداد تصاویر ویدئویی را بیش‌تر انتخاب کرد، اما به دلیل وجود اغلب پارامترهای متغیر مربوط به متن در تصاویر انتخاب شده و نیز افزایش سرعت پیاده‌سازی در مرحله آموزش طبقه‌بندی کننده SVM، انتخاب هشتاد تصویر کافی و مناسب خواهد بود. جهت حذف لبه‌های مربوط به نواحی غیر متنی و تفکیک لبه‌های نواحی متنی در جهت‌های افقی، عمودی، مورب ۴۵ و ۱۳۵ درجه، به ترتیب لبه‌های بزرگ‌تر از ۱۵، ۱۸، ۸، ۱۰ پیکسل و کوچک‌تر از سه پیکسل از تصاویر لبه حذف می‌شوند. این مقادیر طی یک فرایند تجربی مشخص شده‌اند که در زیر به آن خواهیم پرداخت. در ابتدا با تشخیص مقادیر پیش فرض مختلف به لبه‌های بزرگ و کوچک، این مقادیر را روی هشتاد تصویر ویدئویی جمع آوری شده با اندازه قلم بیست پیکسل اعمال می‌نماییم؛ سپس با استفاده از مشاهده نتایج، بهترین مقادیری که می‌توانند لبه‌های مربوط به متن را حفظ کرده و لبه‌های بزرگ و کوچک مربوط به نواحی غیر متن را حذف نمایند، مشخص می‌کنیم. نتایج به گونه‌ای است که به ترتیب برای جهت‌های افقی، عمودی، مورب ۴۵ و ۱۳۵ درجه چنانچه لبه‌ای بزرگ‌تر از ۱۵، ۱۸، ۸، ۱۰ پیکسل و کوچک‌تر از سه پیکسل باشد، آنگاه این لبه مربوط به متن خواهد بود. درنهایت با انجام این پردازش چهار طرح تکانه (SM) حاصل خواهد شد که در هر یک فقط یکی از لبه‌های افقی، عمودی، مورب ۴۵ درجه و مورب ۱۳۵ درجه حضور دارند شکل (۵).

### ۶-۳ آشنایی با مفهوم گوشة تصنیعی و استفاده از آن در تشخیص نواحی متنی

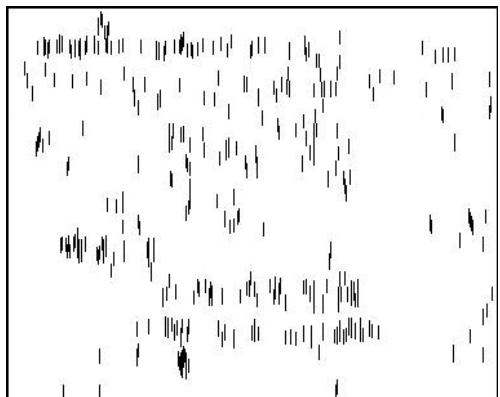
با توجه به پایین‌بودن چکالی تکانه‌ها در زبان فارسی، چنانچه جهت استخراج متن فارسی الگوریتم‌های ارائه شده



(الف)



(الف)



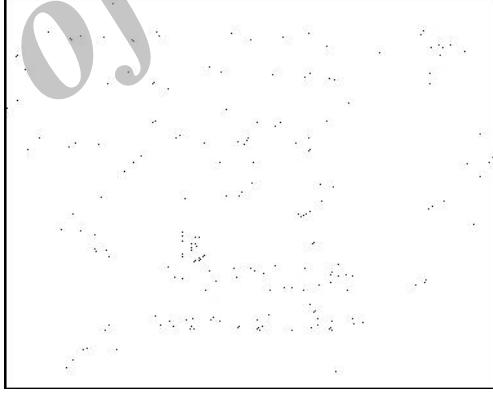
(ب)



(ب)



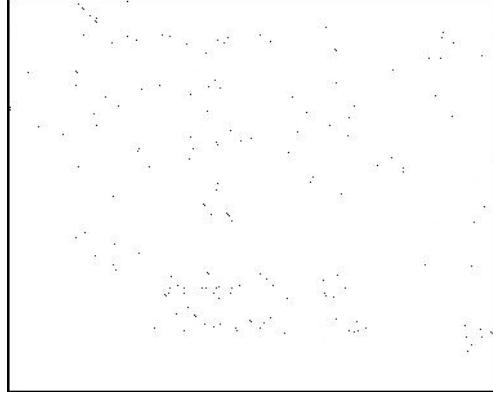
(ج)



(د)



(ت)



(ت)

(شكل ٥) - تصاویر طرح تکانه ٠، ٩٠، ٤٥ و ١٣٥ درجه امتداد داده شده

(شكل ٦) - تصاویر لبه ٠، ٩٠، ٤٥ و ١٣٥ درجه امتداد

فصلنامه  
دولتی

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰  
پردازش و داروی علیه

www.SID.ir

۶

## ۴-۶ تخمین اندازه واقعی قلم

با محاسبه تعداد گوشه‌های تصنیعی موجود در هر خط از تصویر گوشه تصنیعی، هیستوگرام افقی مربوط به تصویر گوشه تصنیعی از طریق رابطه زیر قابل ترسیم خواهد بود (شکل ۸-الف).

$$H(i) = \sum_j ACI(i, j) \quad (2)$$

پس از رسم هیستوگرام افقی، جهت حذف گوشه‌های نواحی غیر متنی و تخمین اندازه قلم، از میانگین ستون‌های هیستوگرام،  $m$ ، استفاده می‌شود.

$$m = \frac{\sum_i H(i, j)}{Num(H(i))} \quad (3)$$



(شکل ۸- الف)- هیستوگرام تصویر گوشه تصنیعی  
ب- حذف گوشه‌های تصنیعی نظیر نواحی غیر متنی

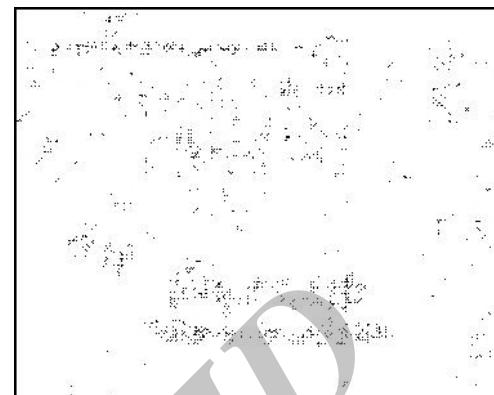
با حذف ستون‌هایی از هیستوگرام که از  $m$  کمتر هستند، بسیاری از ستون‌های مربوط به نواحی غیر متنی حذف خواهند شد شکل (۸- ب). سپس گوشه‌های نظیر این ستون‌ها از تصویر گوشه تصنیعی حذف می‌شوند شکل (۹). در توجیه استفاده از مقدار میانگین جهت حذف گوشه‌های

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

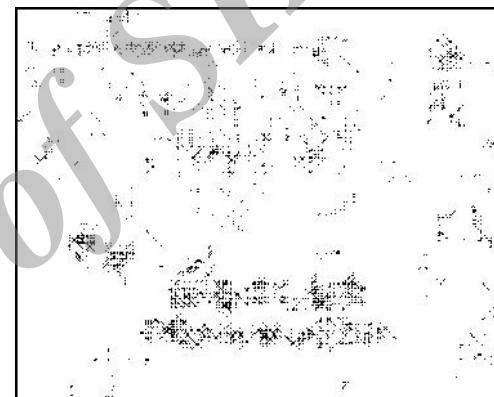
$$ACI_{x,y} = AND(SMx, SMy) \quad (1)$$

$$x, y = 0, 45, 90, 135 \quad x \neq y$$

با افزودن شش گوشه تصنیعی به یکدیگر، یک تصویر گوشه تصنیعی نهایی حاصل خواهد شد (شکل ۷-الف).



(الف)



(ب)

شکل ۷- الف- تصویر گوشه تصنیعی سطح اول هرم  
ب- تصویر گوشه تصنیعی حاصل از سه تصویر موجود در هرم  
سه وضوحی

پس از استخراج گوشه‌های تصنیعی موجود در سطوح دوم و سوم هرم، تصاویر گوشه سطوح دوم و سوم هرم، جهت رسیدن به اندازه‌ای برابر با اندازه سطح اول هرم، تغییر مقیاس داده می‌شوند. گوشه‌های تصنیعی تصاویر گوشه تغییر مقیاس یافته، به تصویر گوشه مربوط به اولین سطح هرم اضافه شده و تصویر گوشه حاصل شده دارای این ویژگی است که تا حد زیادی می‌تواند سبب کاهش وابستگی روش پیشنهادی به تغییرات در اندازه قلم شود شکل (۷- ب).

$$AC_{uv} = \frac{1}{8} C_u C_v \times$$

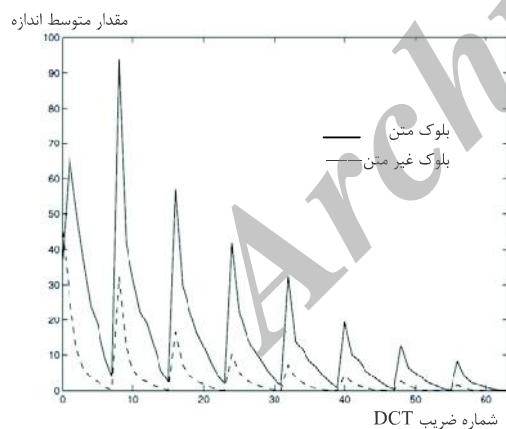
$$\sum_{x=0}^7 \sum_{y=0}^7 f(x,y) \cos \frac{(2x+1)u\pi}{16} \cos \frac{(2y+1)v\pi}{16}$$

$$C_u, C_v = \begin{cases} 1 & u, v \neq 0 \\ \frac{1}{\sqrt{2}} & u, v = 0 \end{cases} \quad (4)$$

در رابطه بالا  $u$  و  $v$  مختصات عمودی و افقی را نمایش داده و مقادیر آنها میان ۰ تا ۷ تغییر می‌کند. انتخاب مجموعه ضرایبی که بتوانند میان نواحی متنی و غیرمتنی تصاویر ویدئویی تمایز قائل کرده و نواحی دارای متن را آشکارسازی نمایند، می‌تواند از طریق یک فرایند تجربی انجام گیرد. با توجه به وجود ۶۴ ضریب برای هر بلوک، تعداد کل ترکیبات

$$\text{موجود برابر } 1.8 \times 10^{19} \text{ می‌باشد.}$$

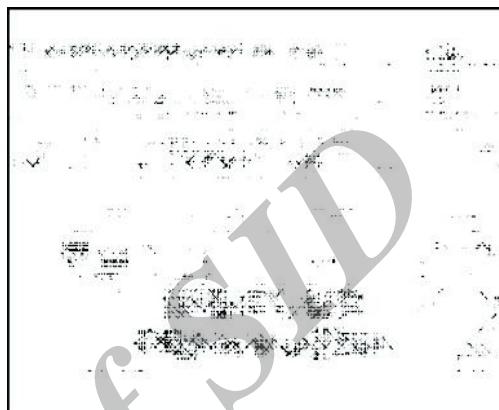
درنتیجه، با توجه به تعدد ترکیبات موجود انتخاب مناسب ضرایب از طریق یک فرایند تجربی کار آسانی نخواهد بود. یکی از روش‌های تسهیل‌کننده جهت انجام آسان‌تر فرآیند تجربی فوق، استفاده از روشی است که جزئیات کامل آن در [Crandall, et al., 2003] ذکر شده است. بهطور خلاصه این روش مبتنی بر محاسبه مقدار متوسط اندازه هر یک از ۶۴ ضریب، در نواحی متنی و غیر متنی است. مقدار متوسط اندازه ضرایب در نواحی متنی و غیر متنی برای تعدادی از تصاویر موجود در پایگاه داده در شکل (۱۰) نشان داده شده است.



شکل (۱۰)- مقدار متوسط اندازه ضرایب برای نواحی متنی و غیر متنی

همان‌گونه که در این شکل نشان داده شده است، برخی از ضرایب، اختلاف بیشتری را برای نواحی متنی و غیر متنی نشان می‌دهند. با رسم این نمودار برای هشتاد تصویر

نواحی غیر متنی، کافیست به این نکته توجه شود که بهطور معمول چگالی گوشه‌ها در نواحی متنی نسبت به میانگین آن در کل تصویر گوشه بیشتر است. میانگین عرض ستون‌های باقی‌مانده در هیستوگرام را محاسبه کرده و مقدار به‌دست آمده، تخمینی از مقدار واقعی قلم موجود در متن خواهد بود. چنانچه این تخمین با مقدار قلم پایه بیش از پنجاه درصد اختلاف داشته باشد، آنگاه اندازه قلم پایه با مقدار به‌دست آمده از مرحله تخمین، جایگزین می‌شود.



شکل (۹)- تصویر گوشه تصنیعی حاصل از حذف گوشه‌های نظریه ستون‌های باریک در هیستوگرام افقی

چنانچه اندازه قلم از مقدار نصف ارتفاع تصویر بیشتر شود، آنگاه در محاسبه اندازه قلم خطأ رخ داده است و یا متنی در تصویر وجود ندارد. در این حالت، جهت استخراج متن احتمالی در تصویر، با فرض اندازه قلمی برابر قلم پایه، ادامه برداش‌ها جهت آشکارسازی متن انجام خواهد شد.

## ۶-۵ ایجاد تصویر شدت بافت

تصویر شدت بافت، تصویری است که بافت نواحی مختلف تصویر را مشخص می‌کند. یکی از مزایای استفاده از بافت تصویر، تشخیص نواحی متنی با قلم کوچک است. روش استفاده از تبدیل فوریه کسینوسی گسسته (DCT)<sup>۱</sup> با ابعاد  $8 \times 8$ ، یکی از روش‌هایی است که در ساخت تصویر شدت بافت مورد استفاده قرار می‌گیرد. ضرایب DCT مربوط به یک بلوک  $8 \times 8$  تصویر  $f(x,y)$  با رابطه زیر بیان می‌شوند [Lim, et al., 2000, Zhong, et al., 1999]

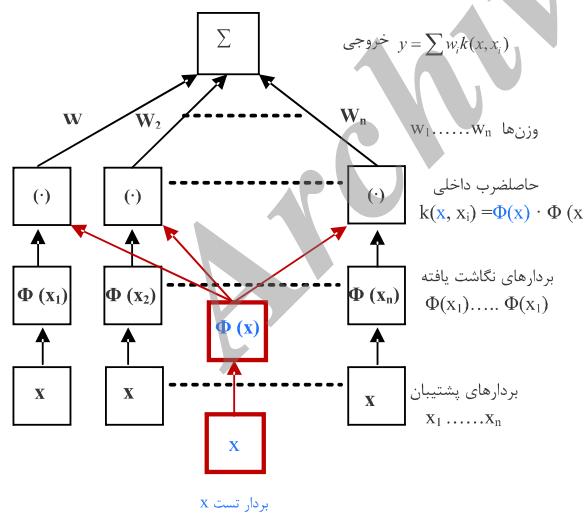
<sup>۱</sup> Descrete Cosine Transform

## ۶-۶ ایجاد بردار مشخصه و آموزش SVM

روش SVM یک روش پیاده‌سازی تقریبی از روش کمینه‌سازی خطرپذیری ساختاری<sup>۱</sup> است. دلایل استفاده از SVM آموزش دهی آسان، عدم نیاز به تعداد نمونه‌های زیاد و امكان تعمیم دهی آسان آن است.

ساختار SVM به عنوان آشکارساز متن، در شکل (۱۲) نشان داده شده است. همان‌گونه که در شکل مشخص شده است، این ساختار از سه لایه تشکیل می‌شود. ورودی شبکه از طریق تعدادی از پیکسل‌های تصویر، که با یکدیگر یک بلوک بزرگ را تشکیل می‌دهند، تأمین می‌شود. لایه پنهان، یک نگاشت غیرخطی  $\Phi$  از فضای ورودی به فضای مشخصه انجام داده و حاصل ضرب نقطه‌ای میان ورودی خود و بردارهای نگاشت یافته را محاسبه می‌کند. در عمل، دو مرحله بالا با معرفیتابع هسته  $k$  می‌تواند در یک گام انجام شوند. این محاسبه به صورت حاصل ضرب نقطه‌ای دو الگوی نگاشت داده شده با رابطه  $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$  تعریف می‌شود. تابع هسته به کار رفته در این مقاله، تابع مینا شعاعی<sup>۲</sup> زیر است که در آن  $\Phi$  بیان‌گر انحراف از استاندارد است.

$$k(x, x_i) = e^{-\frac{|x - x_i|}{2\sigma^2}} \quad (V)$$



(شکل ۱۲) - ساختار SVM به عنوان آشکارساز متن

<sup>۱</sup> Structural Risk Minimization

<sup>۲</sup> Radial Basis Function

ویدئویی شامل قلم‌های متنوع با اندازه قلم حدود بیست پیکسل از تصاویر موجود در پایگاه داده، ضرایب AC را که در آنها میان مقدار متوسط اندازه نواحی متنی و غیر متنی بیشترین تفاوت وجود دارد انتخاب می‌کنیم. به عبارت دیگر، پس از اعمال تبدیل فوریه کسینوسی گستته روی بلوک‌های  $8 \times 8$  تصویر خاکستری ورودی، جهت مؤثر بودن ضرایب ایجاد شده برای هر بلوک، ضرایبی که به بهترین صورت، نشان‌گر تغییر فرکانس مکانی مربوب، افقی و عمودی نواحی دارای متن، انتخاب می‌شوند. نتایج تجربی حاکی از وجود نوزده ضرایب با ویژگی فوق خواهد بود. با فرض  $T(i,j)$  به عنوان شدت بافت  $(i,j)$  این بلوک  $8 \times 8$ ، با کمک نوزده ضرایب انتخاب شده در مرحله قبل،  $T(i,j)$  از طریق رابطه زیر محاسبه می‌شود. در این رابطه اندیس‌ها به شماره ضرایب انتخاب شده اشاره دارند.

$$\begin{aligned} T(i,j) = & k_{00} |AC_{00}| + k_{01} |AC_{01}| + k_{02} |AC_{02}| + k_{03} |AC_{03}| \\ & + k_{04} |AC_{04}| + k_{07} |AC_{07}| + k_{10} |AC_{10}| + k_{11} |AC_{11}| + k_{12} |AC_{12}| \\ & + k_{13} |AC_{13}| + k_{17} |AC_{17}| + k_{20} |AC_{20}| + k_{21} |AC_{21}| + k_{22} |AC_{22}| \\ & + k_{27} |AC_{27}| + k_{30} |AC_{30}| + k_{31} |AC_{31}| + k_{37} |AC_{37}| \end{aligned} \quad (5)$$

در این رابطه  $k_{i,j}$  ضرایب وزن‌دهی مربعی هستند که محاسبه آنها از طریق رابطه زیر صورت می‌گیرد. با استفاده از ضرایب  $k_{i,j}$  فرکانس‌های مکانی بالاتر که به‌طور معمول به نواحی دارای متن مربوط هستند مورد تأکید خواهند بود.  
[Kenneth and Barnerl., 2008]

$$k_{i,j} = \begin{cases} 0 & u = v = 0 \\ \frac{(u+v)^2}{2} & u + v \geq 1 \end{cases} \quad (6)$$

پس از محاسبه شدت بافت همه بلوک‌های  $8 \times 8$  تصویر ورودی، با کنار هم قرارگیری این مقادیر، تصویر شدت بافت حاصل می‌شود. جهت مشاهده بهتر این تصویر با هشت برابر بزرگنمایی در شکل (۱۱) نشان داده شده است.



(شکل ۱۱) - تصویر شدت بافت

$$\mu = \frac{1}{w \times h} \sum_{i,j \in Bl} F(i,j) \quad (12)$$

$$M_1 = \frac{1}{w \times h} \sum_{i,j \in Bl} (F(i,j) - \mu)^2 \quad (13)$$

$$M_2 = \frac{1}{w \times h} \sum_{i,j \in Bl} (F(i,j) - \mu)^3 \quad (14)$$

پس از محاسبه مشخصه های فوق، در جمیع برای هر بلوک بزرگ، چهارده مشخصه به دست می آید. مقادیر مربوط به تمامی بردارهای مشخصه میان  $0$  و  $1$  هنجارسازی شده و با ورود این مشخصه ها به یک طبقه بندی کننده SVM، متن یا پس زمینه بودن هر یک از بلوک های بزرگ تعیین می شوند. جهت آزمایش روش پیشنهادی، از  $2871$  قاب تصویر موجود در پایگاه داده استفاده شده است. از این تعداد چهارصد قاب انتخاب شده و پس از تعیین چشمی بلوک های بزرگ متنی و غیر متنی، در مرحله آموزش از آنها استفاده شده است.

## ۷-۶ رسم نمودارهای هنجارسازی شده شدت بافت و بازبینی نهایی خطوط متن

با فرض آنکه  $MTI(R)$  نمایش گر شدت بافت متوسط<sup>۱</sup> ناحیه بلوک متنی  $R$  باشد شکل (۱۴)، آنگاه مقدار آن به صورت زیر محاسبه می شود [Qian and Liu .., 2006]

$$MTI(R) = \frac{1}{N(R)} \sum_{i \in R} \sum_{j \in R} T(i,j) \quad (15)$$

در رابطه بالا  $N(R)$  تعداد بلوک های موجود در ناحیه  $R$  است. چنانچه شدت بافت متوسط به قدر کافی بزرگ باشد، آنگاه ناحیه  $R$  نامزد شده، یک ناحیه متنی است. وضعیت ناحیه  $R$  توسط خصوصیات بلوک متن و تباین میان ناحیه متن و پس زمینه به صورت زیر تعیین می شود.

$$MTI(R) > \max \{ MTI_{LR}, MTI_{UD}, MTI_A \} \quad (16)$$

$$MTI_A = \frac{1}{M \times N} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} T(i,j) \quad (17)$$

در رابطه بالا  $M$  تعداد بلوک های افقی و عمودی موجود در یک تصویر و  $MTI_A$ ,  $MTI_{LR}$ ,  $MTI_{UD}$ ، به ترتیب میانگین شدت بافت در کل تصویر، ناحیه واقع در همسایگی بالا - پایین و ناحیه واقع در همسایگی چپ - راست ناحیه

<sup>۱</sup> Mean Texture Intensity

علامت خروجی،  $y$ ، توسط وزن دهی به خروجی لایه پنهان مشخص می شود و وضعیت طبقه را نمایش خواهد داد. جهت آموزش، طبقه متن با  $+1$  و طبقه غیر متن با  $-1$  نمایش داده می شود [Shin, et al., 2000]

جهت تشخیص نواحی متنی از نواحی غیر متنی با توجه به اندازه قلم به دست آمده در مرحله تخمین قلم، تصویر ورودی به نواحی کوچک تری به نام بلوک بزرگ تقسیم می شود شکل (۱۳). جهت کاهش خطای احتمالی در تخمین قلم، چنانچه اندازه قلم پایه از چهل کمتر باشد، ابعاد بلوک های بزرگ  $40 \times 80$  و چنانچه اندازه قلم پایه از  $120$  بیش تر باشد، ابعاد بلوک های بزرگ  $120 \times 240$  در نظر گرفته می شوند. چنانچه اندازه قلم پایه در محدوده  $40$  تا  $120$  باشد، آنگاه هر بلوک بزرگ، در جهت عمودی دارای اندازه ای برابر با قلم پیکسل و در جهت افقی، دارای اندازه ای برابر با دو قلم پیکسل است. جهت استخراج چهارده مشخصه، روابط  $8$  تا  $14$  بر تصویر گوشه و تصویر شدت بافت اعمال می شوند. به عبارت دیگر، در این روابط  $F$  یکبار با تصویر گوشه و بار دیگر، با تصویر شدت بافت جایگزین می شود. در این روابط،  $M_2, M_1, \mu, I_H, E, Et$  و  $w$  ارتفاع و عرض بلوک بزرگ،  $h$  به ترتیب بیان گر انرژی، آتروپی، همسانی، اینرسی، میانگین، گشتاور مرتبه اول و گشتاور مرتبه دوم یک بلوک بزرگ هستند [Shivakumara, et al., 2009]



(شکل ۱۳) - تقسیم بندی تصویر به بلوک های بزرگ

$$E = \sum_{i,j \in Bl} F(i,j)^2 \quad (8)$$

$$Et = \sum_{i,j \in Bl} F(i,j) \log F(i,j) \quad (9)$$

$$H = \sum_{i,j \in Bl} \frac{1}{1 + (i-j)^2} F(i,j) \quad (10)$$

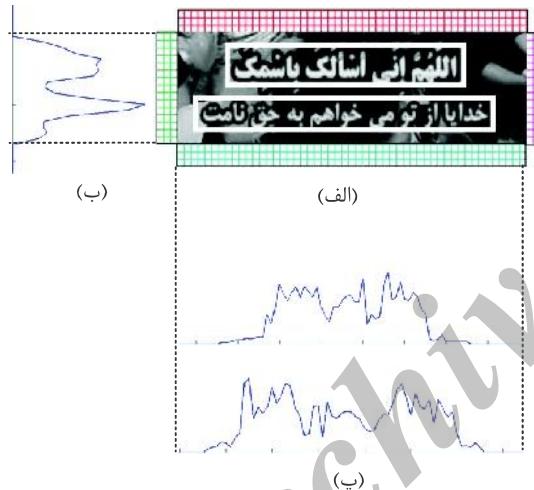
$$I = \sum_{i,j \in Bl} (i-j)^2 F(i,j) \quad (11)$$

در پروفایل نمایش افقی هنجارسازی شده شدت بافت، از طریق درههای میان دو قله مجاور یکدیگر، به‌طور دقیق می‌توان سطراها را از هم تفکیک و جداسازی کرد. در کادر پیرامون خطوط متنه، برخی از بلوک‌های پس‌زمینه ممکن است در میان خطوط متنه باقی بمانند. جهت حذف نواحی غیر متنه موجود میان خطوط و رسم کادر احاطه‌کننده دقیق‌تر پیرامون هر یک از خطوط، از دو رابطه تجربی زیر استفاده می‌شود.

$$Hprof(i) > \max\{MTI_{UD}, MTI_A, mean(Hprof(i))\} \quad (20)$$

$$Vprof(j) > \max\{MTI_{LR}, MTI_A, mean(Vprof(j))\} \quad (21)$$

چنانچه این روابط برقرار شوند، مفهوم آن متن‌بودن بلوک (j,i) آم است. با استفاده از شکل (15) مشاهده می‌شود که اغلب بلوک‌های پس‌زمینه، بطور مؤثری حذف شده است و کادرهای احاطه‌کننده دقیقی در اطراف متن حاصل می‌شود.



(شکل ۱۵)- الف- ناحیه نامزد متن همراه با خطوط متنه تفکیک شده ب- پروفایل افقی هنجارسازی شده شدت بافت بافت پ- پروفایل‌های عمودی هنجارسازی شده شدت بافت هر یک از خطوط متنه موجود

## ۷- مجموعه داده مورد استفاده

در بررسی نتایج حاصل از الگوریتم‌های پردازش تصویر، انتخاب پایگاه داده اهمیت فراوانی دارد. چنانچه انتخاب تصاویر مورد استفاده در پایگاه داده به درستی صورت نگیرد، در آن صورت نتایج به دست آمده چندان قابل اعتماد نخواهد بود. با وجود آنکه موضوع استخراج متن از تصویر ویدئویی موضوع جدیدی نیست؛ ولی جهت استخراج متن فارسی از

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

R هستند. این موضوع در شکل (14) نشان داده شده است. ناحیه همسایگی R در جهت افقی در هر طرف دارای مقدار W بلوک و در جهت عمودی در هر طرف دارای مقدار H بلوک است. محاسبه مقادیر  $MTI_{UD}$ ،  $MTI_{LR}$ ،  $MTI_A$  از طریق رابطه مربوط به محاسبه  $MTI_A$  بوده و فقط ناحیه محاسبه متفاوت است.



(شکل ۱۴)- کادر احاطه‌کننده یک بلوک متن، همراه با بلوک نواحی همسایگی بالا، پایین، چپ و راست.

به‌طور معمول کادر متن دقیق مربوط به هر خط متن، از طریق نمودارهای افقی و عمودی در حوزه پیکسل با استفاده از چگالی لبه و یا اطلاعات شدت روشنایی پیکسل حاصل می‌شود. در این بخش سعی داریم روش تعیین مکان متن در ویدئو را با استفاده از نمودارهای هنجارسازی شده شدت بافت بلوکی به دست آوریم. مثالی از چگونگی استخراج یکی از نواحی بلوک متن در یک تصویر ویدئویی همراه با کادرهای احاطه‌کننده مربوط به آن و نمودارهای هنجارساز افقی و عمودی مربوطه، در شکل (15) نمایش داده شده است. فرض کنیم (i) نمایش‌گر پروفایل افقی هنجارسازی شده شدت بافت (شکل ۱۵-ب)، به صورت زیر بیان می‌شود.

$$Hprof(i) = \sum_{j \in R} \frac{T(i,j)}{HN(i)} \quad (18)$$

در این رابطه،  $HN(i)$  تعداد بلوک‌های موجود در آمین ردیف است. به‌طور مشابه، پروفایل عمودی هنجارسازی شده شدت بافت (شکل ۱۵-پ)،  $Vprof(j)$  به صورت زیر به دست می‌آید که در آن  $VN(j)$  تعداد بلوک‌های موجود در آمین ستون است.

$$Vprof(j) = \sum_{i \in R} \frac{T(i,j)}{VN(j)} \quad (19)$$

## ۸- پیاده سازی و آزمون

جهت آزمون مقاومت و کارایی روش های ارائه شده در آشکارسازی متن از تصاویر ویدئویی، از معیاری نرخ دقت<sup>۱</sup> (P.R) و نرخ فراخوانی<sup>۲</sup> (R.R) استفاده می شود[۱]. نرخ دقت به صورت زیر تعریف می شود.

$$P.R = \frac{C}{C + FP} \quad (۲۲)$$

خطای مثبت<sup>۳</sup> (FP): چنانچه نواحی غیرمنتی به صورت نواحی متنی آشکار شوند، خطای که در این حالت رخ می دهد خطای مثبت است.

در این رابطه تعداد نواحی متنی که به درستی به عنوان ناحیه متن آشکار شده اند با C نمایش داده شده است. نرخ فراخوانی به صورت زیر تعریف می شود:

$$R.R = \frac{C}{C + FN} \quad (۲۳)$$

خطای منفی<sup>۴</sup> (FN): چنانچه نواحی متنی به صورت نواحی غیر متنی آشکار شوند، خطای که در این حالت رخ می دهد خطای منفی است.

به طور معمول میان نرخ فراخوانی و نرخ دقت مصالحه ای برقرار است. لذا جهت اندازه گیری دقیق تر، به طور معمول نمره نرخ فراخوانی و نرخ دقت از طریق فرمول زیر محاسبه می شود.

$$Score = \frac{2 \times P.R \times R.R}{P.R + R.R} \quad (۲۴)$$

در نمره، اثر هر دو پارامتر در نظر گرفته می شود و از این رو معیار درست تری جهت بررسی الگوریتم های استخراج متن از ویدئو است. نتایج حاصل از بررسی تصاویر ویدئویی موجود در پایگاه داده، نشان گر نرخ فراخوانی ۸۹/۲۳ و نرخ دقت ۸۳/۱۲ هستند. درنتیجه، نمره حاصل از روش پیشنهادی با برابر با ۸۶/۱۰ است. جهت مقایسه روش پیشنهادی با روش های دیگر، روش ارائه شده در این مقاله را با دو روش ارائه شده در مراجع [Moradi and Mozaffari], [2010, 2011] که توسط مؤلفان این مقاله در قبل در دو کنفرانس ارائه شده است و نیز روش های ارائه شده در مراجع [Halima, et al., 2010, Ahmad, et al., 2012] که از جمله نوین ترین روش های پیشنهادی است مقایسه می کنیم. با توجه به این که امکان دسترسی به پایگاه داده این دو روش

تصاویر ویدئویی، پایگاه داده معتبری وجود ندارد. از این رو در این تحقیق، پایگاه داده مناسب، جهت استخراج متن فارسی از تصاویر ویدئویی ارائه می شود. با توجه به طیف وسیع فرمات های تصاویر ویدئویی و مشخصات تصاویر تشکیل دهنده ویدئو، پایگاه داده ایجاد شده باید تمامی حالات ممکن را پوشش دهد. با توجه به استفاده ایران از سیستم رنگی پال، تمامی تصاویر ویدئویی مورد استفاده در ۵۷۶×۷۲۰ پیکسل هستند. جهت ایجاد این پایگاه داده از شصت نماهنگ ویدئویی استفاده شده است. پارامترها و نکاتی که جهت ایجاد این پایگاه داده در نظر گرفته شده است در جدول زیر مشخص شده است. برای دست یابی به این متغیرها از تصاویر خبری، تصاویر مسابقات ورزشی، فیلم های سینمایی، تصاویر پویانمایی، تصاویر مستند، تصاویر مربوط به آگهی های بازار گانی و تصاویری که بر اثر پایگانی طولانی دارای کیفیت پایین باشند، استفاده شده است. شایان ذکر است با توجه به اینکه متن موجود در یک تصویر می تواند چندین ویژگی داشته باشد؛ لذا مجموع درصد های موجود در جدول زیر از صدر صد بیشتر است.

(جدول ۱)- ویژگی های موجود در پایگاه داده و درصد آنها

درصد	نوع تصویر مورد نیاز	ویژگی
۱۵	تصاویر با روشنایی متفاوت	روشنایی
۱۲	تصاویر دارای تباين کم و زياد	کنتراست
۸۶	تصاوير رنگی	رنگ بودن
۱۴	تصاویر سیاه و سفید	افق رنگ بودن
۱۳	تصاویر با متون دوران یافته	دوران
۴۷	تصاویر دارای متن با اندازه و سبک مختلف	اندازه و سبک قلم به کاررفته
۳۲	تصاویر با پس زمینه های ساده و پیچیده	پیچیدگی پس زمینه
۴۳	تصاویر دارای نوشه	مقاومت در برابر نوشه
۳۸	تصاویر ویدئویی که در یک صحنه به صورت همزمان چندین اندازه و سبک قلم مختلف وجود دارند	تغییر اندازه و سبک قلم در داخل یک تصویر
۳۱	تصاویر دارای متن ثابت و متحرك، به گونه ای که متن متتحرك در جهات اصلی در تصویر حرکت نماید	ثابت و متتحرك بودن متن
۲۳	استفاده از تصاویری که متن موجود به صورت همزمان در دو جهت چپ و راست دارای حرکت باشند	جهت حرکت متن

<sup>۱</sup> Precision Rate

<sup>۲</sup> Recall rate

<sup>۳</sup> False Positive

<sup>۴</sup> False Negative

(جدول ۳)- نرخ دقت، نرخ فراخوانی و نمره در تصاویر نمونه

تصویر	نرخ دقت	نرخ فراخوانی	نمره
الف	۱	۰/۸۳	۰/۹۰
ب	۰/۸۵	۰/۶۶	۰/۷۴
پ	۰/۸۰	۱	۰/۸۸
ت	۱	۰/۸۷	۰/۹۳
ث	۱	۰/۴۰	۰/۵۷
ج	۱	۱	۱
چ	۰/۷۵	۱	۰/۸۵
ح	۰	۰/۳۳	۰

اثر برخی متغیرهای موجود در متن که می‌توانند در نمره نهایی الگوریتم استخراج متن از تصاویر ویدئویی تأثیر داشته باشند در نمودار شکل (۱۷) نشان داده شده است. همان‌گونه که در این نمودار نشان داده شده است، کمترین مقدار مربوط به ستون دوران متن است. به عبارت دیگر، این روش مقاومت خوبی در مقابل دوران متن ندارد و در صورت دوران متن، توانایی آشکارسازی آن را نخواهد داشت. با توجه به این نمودار، از جمله پارامترهای دیگری که پس از دوران، می‌توانند سبب پایین‌بودن نمره نهایی اختصاص داده شده به روش پیشنهادی شوند، می‌توان به وجود نوفه و پایین‌بودن سطح تباین و روشنایی تصویر اشاره کرد. از جمله نقاط قوت این الگوریتم، مقاومت بودن آن در مقابل تغییر اندازه و سبك قلم، حرکت متن، پیچیدگی پس‌زمینه و سیاه و سفید بودن تصویر است.

## ۹- نتیجه‌گیری

همان‌گونه که نتایج نشان می‌دهند، با تکمیل پایگاه داده و بهینه‌سازی روش‌های موجود در دو مقاله [Moradi and Mozaffaril., 2010,2011]، ارائه شده توسط مؤلفان این مقاله و ارائه برخی از نوآوری‌هایی که در زیر به اختصار به آنها اشاره می‌شود، نتایج بهتری جهت آشکارسازی و استخراج متنون فارسی و عربی از تصاویر ویدئویی حاصل می‌شوند. دلایل افزایش نمره در روش پیشنهادی نسبت به دو روش ارائه شده قبل توسط مؤلفان با توجه به مطالب ارائه شده در بخش ۶ را می‌توان بهطور اختصار به صورت زیر بیان کرد: افزایش سطوح هرم چندوضوحی از دو به سه؛ استفاده از مؤلفه‌های رنگی تصویر ورودی به جای استفاده از تک تصویر خاکستری ورودی؛ تغییر روش تشخیص اندازه قلم به کار رفته در متن و عدم

وجود نداشته و لازم است نتایج براساس پایگاه داده یکسانی گزارش شوند، لذا این دو روش موجود در [Halima, et al., 2012] ۲۰۱۰، Ahmad, et al., 2012] پیاده‌سازی شده و نتایج حاصل از پنج روش مذکور با به کارگیری پایگاه داده در جدول (۲) نشان داده شده است. شایان ذکر است در مراجع [Halima, et al., 2010, Ahmad, et al., 2012] تأکید بر متنون عربی است که آشکارسازی متن عربی بهدلیل افزایش تکانه‌های ناشی از اعراب، از متن فارسی آسان‌تر خواهد بود.

(جدول ۲)- مقایسه نرخ دقت، نرخ فراخوانی و نمره در

روش‌های موجود

روش	نرخ دقت	نرخ فراخوانی	نمره
Moradi and Mozaffaril., 2010	۷۲/۸	۷۸/۵۴	۷۵/۵۰
Moradi and Mozaffaril., 2011	۸۱/۸۰	۸۷/۵۴	۸۴/۵۷
Halima, et al., 2010	۹۱/۲۳	۹۲/۴۷	۹۱/۴۵
Ahmad, et al., 2012	۹۵	۹۶	۹۵/۴۹
روش ارائه شده در این مقاله	۸۳/۱۲	۸۹/۲۳	۸۶/۱۰

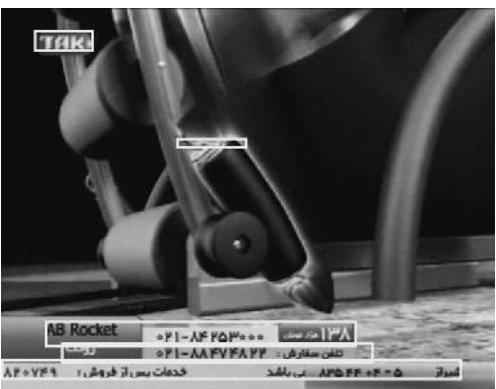
تعدادی از تصاویر پایگاه داده و نتایج حاصل از روش پیشنهادی در شکل (۱۶) نشان داده شده است. در این شکل تصویر (الف) یک صحنۀ فیلمبرداری شده در خارج استودیو است که در آن پس‌زمینه به صورت پیچیده است. در تصویر (ب) یک صحنۀ پویانمایی نشان داده شده است که در آن به‌دلیل پایین‌بودن تباین و روشنایی، خطای مثبت و منفی هر دو اتفاق افتاده‌اند. تصویر (پ) مثالی از خطوط متنی متحرک همراه با پس‌زمینه پیچیده متحرک را نمایش می‌دهد. در این تصویر به‌دلیل سرعت بالای پس‌زمینه، خطای مثبت رخ داده است. تصویر (ت) نمونه‌ای از وجود قلم با اندازه متفاوت است که به‌طور دقیق متن در آن آشکارشده است. تصویر (ث) نمونه‌ای از وجود متن فارسی و انگلیسی بوده که به‌دلیل وجود نوفه، خطای منفی رخ داده است. در تصویر (ج) هر دو متن ثابت و متحرک به صورت همزمان وجود دارند. تصویر (چ) نمونه‌ای از تصویر با پس‌زمینه پیچیده است. در تصویر (ح) متن دارای چرخش و اندازه قلم متفاوت است. در این تصویر به‌دلیل چرخش متن در تشخیص ناحیه متنی خطای منفی رخ داده است. نرخ دقت، فراخوانی و نمره تصاویر نمونه، در جدول (۳) نشان داده شده است.



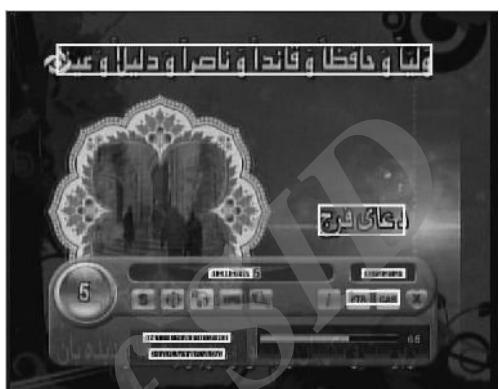
(الف)



(ب)



(پ)



(ت)



(ث)



(ج)



(ج)

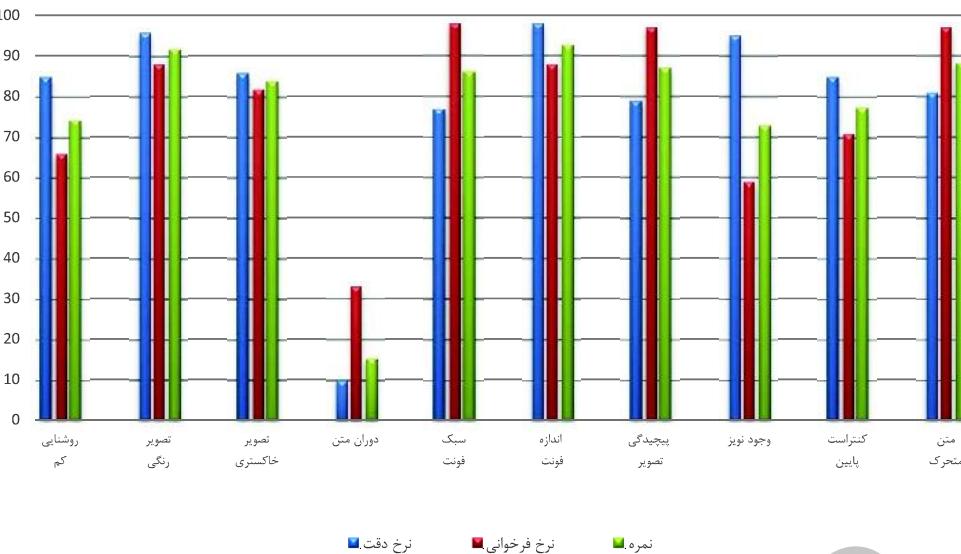


(ج)

(شکل ۱۶) - نمونه‌هایی از متن آشکار شده در تصاویر ویدئویی

فصلنامه  
دولتی

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰



(شکل ۱۷)- اثر برخی از متغیرهای موجود در متن داخل تصاویر روی نرخ فراخوانی، نرخ دقیقت و نمره الگوریتم استخراج متن از تصاویر ویدئویی

Halima, B.M., Karray, H., Alimi, A. M., A comprehensive method for Arabic video text detection, localization, extraction and recognition, lecture notes in computer science, Advances in Multimedia Information Processing (2010), p.p 648-659

Jung ,K., Kim, K.I., and Jain, A.K., Text information extraction in images and video: A survey, Pattern Recognition 37(5) (2004) 977–997

Kim, K.I., Jung, K., and Hyung, J. , Texture-based approach for text detection in images using support vector machines and continuously adaptive mean shift algorithm, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25(12) (2003), pp. 1631–1639

Khosravi, H., Kabir, E., Farsi font-recognition based on Sobel–Roberts features, Pattern Recognition Letter 31(1) (2010) 75–82

Kenneth, S.L., Barner, E., Weighted DCT coefficient based text detection, in IEEE Int. Conf. on International Conference on Acoustics, Speech, and Signal Processing (ICASSP) (2008), pp. 1341–1344

Leon, M., A. Gasull, Text Detection In Images And Video Sequences, in International Conference on Multimedia, Image Processing and Computer Vision (Madrid, Spain, 2005)

Lim, Y.K., Choi, S.H., and Lee, S.W., Text extraction in MPEG compressed video for content-based indexing, in Proceedings of the International Conference

استفاده از پارامترهای نامناسب در حذف گوشی‌های تصنیعی نواحی غیر متنی؛ عدم استفاده از محدودیت‌های هندسی و اپراتورهای مورفولوژی جهت حذف نواحی غیر متنی و در نتیجه حذف خطای ناشی از روش‌های ابتکاری موجود در مرجع [Moradi and Mozaffari.,2010]؛ تکمیل و بهینه‌سازی پایگاه داده به کار رفته در مراجع [Moradi and Mozaffari.,2010,2011]؛ بهینه‌سازی بردار استفاده شده در طبقه‌بندی کننده SVM و حذف برخی از مشخصه‌ها جهت افزایش سرعت و دقیقت در مرحله طبقه‌بندی نواحی دارای متن از نواحی فاقد متن.

## مراجع

Ahmad, A. M. A., Alqutami, A. J., Atoum , A Robust Algorithm for Arabic Video Text Detection, Proceedings of the 2011 2<sup>nd</sup> International Congress on Computer Applications and Computational Science Advances in Intelligent and Soft Computing (145) (2012), pp 261-266

Cai, M., Song, J., and Lyu, M.R., A New Approach for Video Text Detection, in IEEE Int. Conf. on Image Processing, (2002), pp. I-117 – I-120

Crandall, D., Antani, S., and Kasturi. R., Extraction of special effects caption text events from digital video, in IEEE International Journal on Document Analysis and Recognition (IJDAR) 5 (2003), pp. 138–157

Videos. Image Processing, IEEE Transactions, 20(3) (2011), pp. 790–799

Zhong,Y., Zhang, H., and Jain, A.K., Automatic caption localization in compressed video, in IEEE Int. Conf. Image Processing, 2 (1999), pp. 96–100



**محی الدین مرادی** مدرک کارشناسی ارشد خود را در رشته الکترونیک در سال ۱۳۸۹ از دانشگاه سمنان دریافت کرد و در حال حاضر دانشجوی دکترای الکترونیک در دانشگاه صنعتی خواجه نصیرالدین طوسی می باشد. موضوعات تحقیقاتی ایشان بازشناسی آماری الگو، پردازش و بازنگاری تصاویر دیجیتال و فشرده سازی ویدئو است.

نشانی رایانمۀ ایشان عبارت است از:

**Mohieddin.Moradi@gmail.com**

**سعید مظفری** مدرک کارشناسی، کارشناسی ارشد و دکترای خود را در رشته الکترونیک به ترتیب در سال های ۱۳۷۸ و ۱۳۸۰، ۱۳۸۶ و ۱۳۸۷ از دانشگاه صنعتی امیرکبیر دریافت کرد. ایشان فرصت مطالعاتی خود را به مدت یک سال در دانشگاه صنعتی برانشوایگ در کشور آلمان سپری کرد. وی از سال ۱۳۸۷ در دانشکده مهندسی برق و کامپیوتر دانشگاه سمنان مشغول به فعالیت است. زمینه های تحقیقاتی ایشان پردازش تصویر، شناسایی الگو و پردازش متون است.

نشانی رایانمۀ ایشان عبارت است از:

**mozaffari@semnan.ac.ir**



علی اصغر ارجوی در سال ۱۳۴۵ در نیشابور متولد شد. ایشان مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی الکترونیک به ترتیب در سال های ۱۳۶۸، ۱۳۷۱، ۱۳۷۱ از دانشگاه علم و صنعت ایران دریافت کرد. وی در سال ۱۳۸۴ موفق به اخذ مدرک دکتری از انسٹیتو فنی هند (IIT) شد. ایشان از سال ۱۳۷۱ در دانشکده مهندسی برق و کامپیوتر دانشگاه سمنان مشغول به فعالیت است. زمینه های تحقیقاتی ایشان طراحی مدارهای مجتمع آسالوگ و مدل سازی ترانزیستورهای SOI, MOS است.

نشانی رایانمۀ ایشان عبارت است از:

**aorouji@ieee.org**

rence on Pattern Recognition, (Barcelona, Spain, 2000), pp. 409–412

Liang ,J., Doermann, D., and Li, H.P., Camera-based analysis of text and documents: A survey, Document Analysis and Recognition 7(2-3) (2005) 84–104

Li, Z., Liu, G., Quin, X., Guo, D., and Jiang, H., Effective and Efficient video text extraction using key text points, IET Image Processing, 5(8) (2011), pp. 671–683

Lienhart, R., Wernicke, A., Localizing and seg-enting text in images and videos, IEEE Transactions on Circuits and Systems for Video Technology, 12(4) (2002), pp. 256–268

Moradi, M., Mozaffari, S., Orouji A.A., Farsi/Arabic text extraction from video images by corner detection, 6<sup>th</sup> Iranian Conference on Machine Vision and Image Processing (MVIP), 2010

Moradi, M., Mozaffari, S., Orouji A.A., Farsi/Arabic text extraction from video images , 19<sup>th</sup> Iranian Conference on Electrical Engineering (ICEE), 2011

Qian, X., Liu, G., Text detection localization and segmentation in compressed videos, in IEEE Int. Conf. International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2 (2006)

Shivakumara, P., Trung, Q.P., and Chew, L. T., A Laplacian Approach to Multi-Oriented Text Detection in Video, Pattern Analysis and Machine Intelligence, IEEE Transactions, 33(2) (2011), pp. 412 – 419

Shin, C.S., Kim, K.I., Park, M.H. and Kim, H.J., Support vector machine-based text detection in digital video, in IEEE Signal Processing Society Workshop, 2 (2000), pp. 634–641

Shivakumara, P., Phan, T.Q. and Tan, C.L., A robust Wavelet transform based technique for video text detection, in IEEE 10th Int. Conf. on Document Analysis and Recognition (2009), pp. 1285–1289

Wonjun, K., Changick, K., A new approach for overlay text detection and extraction from complex video scene, IEEE Trans. Image Process, 18(2) (2009), pp. 401–411

Xiaoqian, L., Weiqiang ,W., Robustly Extraction Captions in Videos Based on Stroke-Like Edges and Spatio-Temporal Analysis: IEEE Transactions 14(2) (2012), pp. 482 – 489

Zhang ,J., Kasturi, R., Extraction of text objects in video documents: Recent progress, in Eighth International Association for Pattern Recognition (IAPR) Workshop on Document Analysis Systems (Nara, Japan, 2008), pp. 5–17

Zhao, X., Kai-Hsiang, L., Yun, F., Yuxiao, H., Yuncai, L., and T.S. Huang, Text From Corners: A Novel Approach to Detect Text and Caption in