

آشکارسازی و تعیین مکان متون فارسی-عربی در تصاویر ویدئویی

محی الدین مرادی، سعید مظفری و علی اصغر ارجوی

دانشکده مهندسی برق و کامپیوتر، 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 آژشیو 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 هر می 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 گوشش‌های تصنیعی نواحی غیرمتنی، تحلیل هیستوگرام انجام می‌شود. ضرایب تبدیل فوریه کسینوسی گسسته بلوك‌های 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 متشکل 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 گسسته، طبقه‌بندی SVM.

۱- مقدمه

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 روند جداسازی متن از پس‌زمینه می‌تواند امری چالش‌برانگیز باشد. از جمله خصوصیات مورد استفاده جهت آشکارسازی متن، می‌توان به نحوه قرار گیری 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]

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

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

در گذشته، تلاش های 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 قرار گیری 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 فریم های متوالی، تعیین موقعیت زمانی- مکانی و نیز جداسازی زیرنویس های موجود در تصویر بهره می گیرد. در [Zhao, et al., 2011] یک سامانه خودکار آشکارسازی متن براساس نقاط گوشه که یکی از ویژگی های مهم نواحی متنی است، استفاده شده است. بلوک های متنی می توانند از طریق تغییر رنگ میان نواحی متنی و پس زمینه مجاور آن تشخیص داده شوند. نواحی دارای متن می توانند به صورت تقریبی از طریق محاسبه چگالی پیکسل های در حال تغییر و پیکسل های 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 قبل تشخیص است. در استخراج متن ذاتی موجود در تصویر به دلیل آنکه اغلب سامانه های 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 قسمت بندی اجزا به هم متصل شده پیچیده به بخش های ساده تر مورد استفاده قرار می گیرند. در مرجع [Li, et al., 2011] روش استخراج متن بر اساس نقاط کلیدی متن ارائه شده است. نقاط کلیدی متن به عنوان نقاطی تعریف می شوند که هم زمان 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 می توان گفت در تحقیقات انجام شده جهت آشکارسازی متن در تصاویر از دو گروه الگوریتم آشکارسازی با عنوان آشکارسازی بر اساس ناحیه و

۲- بررسی مراحل مختلف استخراج متن از تصاویر ویدئویی

به طور کلی سامانه های 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 روش های متعددی مشخص می شود. در مرحله تعیین مکان متن، مکان متن در داخل تصویر مشخص شده و در اطراف آن کادری کشیده می شود. در بسیاری از موارد، مرحله آشکارسازی و تعیین مکان به صورت همزمان با یکدیگر صورت می گیرند. در مرحله استخراج و ارتقای متن، اجزای متن از بخش پس زمینه تصویر جدا شده و تصویر، قطعه قطعه می شود. نواحی متن به طور معمول وضوح پایینی دارند، لذا در معرض نوفه قرار داشته و لازم است ارتقا داده شوند. در این تحقیق، هدف معرفی روشهای رخصوص مراحل آشکارسازی و تعیین مکان متن فارسی در تصاویر ویدئویی است و لذا موضوعات شامل مراحل ردیابی مکان متن، استخراج و ارتقای متن و تشخیص حروف در این نوشتار مد نظر نخواهد بود.



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

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

الگوریتم هایی که جهت استخراج متن از تصاویر ویدئویی ارائه شده اند، همگی نواقصی دارند که این مطلب ناشی از وجود تغییرات گسترده متن و تصاویر ویدئویی است. از جمله این موارد می توان به پایین بودن 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 (كلمات و خطوط)

۳-۲- آشکارسازی متن بر اساس بافت تصویر

در این روش، با فرض وجود بافت ویژه 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 نوفه روی مشخصه‌های بافت پیکسل‌های مجاور اثری نداشته باشد، آنگاه اثر نوفه 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 تعیین‌دهی آن به وجود می‌آید. با این وجود عمدترين مسئله در اين گونه الگوریتم‌ها، پيچيدگي محاسباتي است؛ زيرا تمامي نواحی تصویر تحت جستجو قرار گرفته و تحیيل بافت تصویر زمان زيادي نياز خواهد داشت. نگرانی ديجري که در اين روش وجود دارد مربوط به دقت انتخاب نواحی متنی است. با توجه به اينکه تحليل 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 خواهند بود [Jung, et al., 2004, Cai, et al., 2002].

۴-۱- خصوصیات مستقل از نوع زبان

الف- تباین: نواحی متنی در مقایسه با نواحی غیر متنی نسبت به ناحیه پس‌زمینه خود دارای تباین قابل توجهی دارند. میزان این تباین، با توجه به میزان پيچيدگي ناحیه پس‌زمینه، متغیر است. چنانچه ناحیه پس‌زمینه ناحیه سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

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

۳-۱- 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 تباین 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 دسته‌ای قوانین، از نواحی متنی جدا خواهد شد. در ادامه، با استفاده از اپراتورهای ریخت‌شناسی^۱ 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 در نتیجه 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 مجموعه‌ای 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 خواهند بود. با گروه‌بندی اجزای کوچک به اجزای بزرگ‌تر، همه نواحی تصویر مشخص می‌شوند. این روش‌ها به طور عمومی از سه مرحله زیر

^۱Morphological Operators

پ- کوچک‌ترین نسبت ابعاد کلمات: زبان چینی زبانی نویسه محور است. به عبارت دیگر در این زبان یک نویسه به تنها یی می‌تواند یک مفهوم مستقل داشته باشد. زبان‌های فارسی و انگلیسی بر اساس کلمات می‌باشند 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 زبان‌ها با یکدیگر متفاوت است.

ت- توزیع آماری تکانه‌ها در جهات مختلف: تکانه‌ها در حروف انگلیسی عمده‌تر در جهت عمودی قرار دارند و به همین دلیل بسیاری از الگوریتم‌های استخراج متن بر اساس تکانه‌های عمودی استوارند. در زبان‌های فارسی و چینی این موضوع متفاوت است و به همین دلیل الگوریتم‌هایی که بر این اساس برای زبان انگلیسی تهیه شده‌اند، برای زبان‌های فارسی و چینی قابل اعمال نیستند.

ث- جهت قرارگیری متن در تصویر: متن در تصاویر باید به گونه‌ای قرارگیرد تا در کنار محتويات دیگر موجود در تصاویر ویدئویی به طور معمول متن فارسی به صورت افقی نوشته شده و لذا کافی است برای زبان‌هایی همانند فارسی و انگلیسی فقط متن افقی مورد توجه قرار گیرد.

۵- اهمیت زبان فارسی و ویژگی‌های آن

نویسه‌های زبان فارسی در چندین زبان دیگر از جمله عربی، اردو و پشتو مورد استفاده قرار می‌گیرند. 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 یک‌چهارم جمعیت کل کره زمین را تشکیل می‌دهند، توانایی 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- نویسه‌های خط فارسی روی یک خط فرضی معروف به خط مبنا به صورت شکسته و متصل به یکدیگر نوشته می‌شوند. به دلیل اتصال حروف به یکدیگر، بلوکی از نویسه‌ها می‌تواند تشکیل شود. در زبان فارسی حروف کوچک و بزرگ همانند آنچه برای زبان انگلیسی در نظر گرفته می‌شود، وجود ندارد.

ب- نویسه‌های فارسی با توجه به مکان قرارگیری آنها در کلمه می‌توانند بیش از یک شکل داشته باشند. با توجه به

ساده‌ای باشد، در آن صورت حتی متن دارای تباین پایین نیز قابل شناسایی است. چنانچه ناحیه پس‌زمینه دارای بافت پیچیده‌ای باشد، فقط نواحی متنی دارای تباین بالا قابل تشخیص‌اند.

ب- رنگ: در اغلب جملات، رنگ نویسه‌های متنی مشابه است و تغییر نمی‌کند. با این وجود در فرآیند فشرده‌سازی با اقلاف، در لبه‌های متن و پس‌زمینه مقداری تداخل رنگ ایجاد می‌شود.

پ- متحرک یا ثابت‌بودن متن در تصویر: متن در تصویر جایگاه ثابت یا متحرکی دارد. اغلب پیام‌های بازرسانی و اخبار فوری و مواردی امثال آن به صورت زیرنویس متحرک در پایین تصویر نوشته می‌شوند. این موضوع سبب افزایش اهمیت فرآیند ریابی متن خواهد شد. جهت حرکت متن با توجه به نوع زبان به کار رفته می‌تواند 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 می‌کند.

۴- خصوصیات وابسته به زبان

الف- چگالی تکانه‌های موجود در متن: تکانه‌های ایجاد شده توسط یک قلم، حرکات یا علامت‌هایی هستند که در هنگام نوشتن توسط قلم ایجاد می‌شوند. تکانه درواقع چهارچوب یک نوشته را نمایش می‌دهد. در زبان انگلیسی و فارسی چگالی تکانه‌های موجود در نواحی مختلف متنی به طور معمول مقدار یکسانی است. در زبان‌هایی همانند کره‌ای و چینی، این چگالی می‌تواند در نواحی مختلف متن تقفاوت داشته باشد. برای مثال اگر چه در زبان چینی برخی حروف فضای یکسانی را اشغال می‌کنند، ولی تعداد تکانه‌های موجود در آنها با یکدیگر تقفاوت دارد.

ب- کوچک‌ترین اندازه قلم به کار رفته در متن: در تصویر جهت نمایش تمامی تکانه‌های موجود در یک متن لازم است با توجه به چگالی تکانه‌های موجود در حروف، کوچک‌ترین اندازه قلم قابل استفاده تعیین شود. به عنوان نمونه نویسه‌های چینی به دلیل چگالی بالای تکانه‌های موجود در آنها، در مقایسه با نویسه‌های انگلیسی و فارسی، فضای بیشتری را اشغال کرده و به همین دلیل این نویسه‌ها باید با اندازه قلم بزرگ‌تری نمایش داده شوند. چنانچه بخواهیم روش‌های استخراج متن مبتنی بر تکانه زبان‌های چینی، کره‌ای و انگلیسی را به زبان فارسی اعمال کنیم در آن صورت به دلیل این تقفاوت نتایج مطلوبی حاصل نمی‌شود.



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


[2 تا ۳ ثانیه)

مفهوم بلوک نویسه‌ها، یک نویسه می‌تواند در ابتدا، 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، Traffieic، 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 به طور تقریبی یکسان است. برای مثال چنانچه قلم‌های متداول ده‌گانه فارسی با اندازه بیست را در نظر بگیریم، در یک تصویر پال ارتفاع همه آنها به طور 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 به طور معمول میان ۱۵ تا ۲۵ متری است. از این رو به عنوان یک فرض منطقی اولیه، می‌توان اندازه قلم موجود در تصویر را برابر ۲۰ در نظر گرفت.



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

در شکل (۲) روندnamای طرح پیشنهادی نشان داده شده است. جهت کاهش حساسیت طرح استخراج متن به تعییر اندازه قلم، در ابتدای هر مسه وضوحی تصویر ورودی ایجاد می‌شود (بخش ۱-۶). سپس جهت استخراج لبه‌ها با استفاده از آشکارساز لبه، چهار طرح تکانه^۱ (SM) افقی، عمودی و مورب تولید می‌شوند (بخش ۲-۶). به منظور استخراج گوشه‌های نواحی متنی، با استخراج گوشه‌های تصنیعی سطوح مختلف هر مسه، تصویر گوشه تصنیعی^۲ ACI، شده (بخش ۳-۶) و با رسم هیستوگرام افقی هنجارسازی شده و اعمال محدودیت‌های ابتکاری، اندازه واقعی قلم به کمک تصویر گوشه تصنیعی تخمین زده می‌شود (بخش ۴-۶). در ادامه به منظور 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^۳ استفاده می‌شود (بخش ۶-۶). در نهایت با رسم نمودارهای افقی و عمودی، مکان دقیق متن در تصویر ویدئویی مشخص خواهد شد

¹ Stroke Map

² Artificial Corner Image

³ 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 پس‌زمینه 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 می‌گردد (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 سه وضوحی 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. متاسفانه 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 سه وضوحی 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 سه وضوحی 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 به‌طور معمول تکانه‌هایی در

فصل نهم

شیوه حلا

پرداز و دارو

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 ، ، ۹۰، ۴۵ و ۱۳۵ درجه از طریق یک اپراتور گشایش با المان ساختاری دارای طول بیست‌پیکسل، در جهت مربوطه امتداد داده می‌شوند شکل (۶). این پردازش مشکل کم‌بودن چگالی تکانه‌ها در نواحی متنی را مرفوع می‌نماید، ولی سبب افزایش لبه‌های اضافی در نواحی غیر متنی خواهد شد. برای غلبه بر این مشکل مفهوم گوشةٌ تصنیعی معروفی می‌شود. محل برخورد دو تکانه امتداد داده شده را یک گوشةٌ 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 بیست‌پیکسل جهت اپراتور گشایش بر این اساس است که با توجه به اینکه اندازه قلم پایه برابر بیست در نظر گرفته شده است لذا با استفاده از اپراتور گشایش با المان ساختاری دارای طول بیست‌پیکسل، می‌توان تکانه‌های مختلف داخل یک کلمه و نیز تکانه‌های کلمات مختلف داخل یک سطر از متن فارسی را به مقدار کافی امتداد داده تا این طریق علاوه‌بر افزایش چگالی 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 پس‌زمینه است. در توجیه این پدیده کافی است به تغییرات گرادیان لبه‌ها در یک تصویر توجه شود. یکی از ویژگی‌های نواحی متنی، تغییرات شبه پریویدیک گرادیان لبه افقی است. از این رو با افزایش طول لبه‌های موجود در تصویر، در نواحی متنی نسبت به نواحی غیر متنی تغییرات شبه گرادیان لبه در امتداد افقی، رشد بیشتری خواهد داشت. به‌طور کلی یک ناحیه متنی دارای ترکیب شبه 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 رابطهٔ زیر یک تصویر گوشةٌ 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 پس‌زمینه، به راحتی توسط فرآیند آستانه‌گذاری حذف شده و تشخیص لبه‌های مربوط به نواحی متنی آسان‌تر انجام می‌شود. با توجه به ویژگی‌های بیان شده در خصوص متن فارسی و دلایل انتخاب اندازه قلم پیش فرض ۲۰ مجموعه‌ای مشکل از هشتاد تصویر ویدئویی شامل قلم‌های متنوع با اندازهٔ قلم حدود بیست‌پیکسل 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 مرحلهٔ 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، ۸، ۱۰ پیکسل و کوچک‌تر از سه‌پیکسل از تصاویر لبه حذف می‌شوند. این مقادیر طی یک فرایند تجربی مشخص شده‌اند که در زیر به آن خواهیم پرداخت. در ابتدا با تخصیص مقادیر پیش‌فرض مختلف به لبه‌های بزرگ و کوچک، این مقادیر را روی هشتاد تصویر ویدئویی جمع آوری شده با اندازهٔ قلم بیست‌پیکسل 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 به‌گونه‌ای است که به ترتیب برای جهت‌های افقی، عمودی، مورب ۴۵ و ۱۳۵ درجه چنانچه لبه‌ای بزرگ‌تر از ۱۵، ۸، ۱۰ پیکسل و کوچک‌تر از سه‌پیکسل 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).


۳-۶ آشنایی با مفهوم گوشةٌ تصنیعی و

استفاده از آن در تشخیص نواحی متنی

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




(الف)



(ب)




(ج)




(ت)

(شكل ٦) - تصاویر لبه ۰، ۴۵، ۹۰ و ۱۳۵ درجه امتداد داده شده



(الف)



(ب)



(ج)



(ت)

(شكل ٥) - تصاویر طرح تکانه ۰، ۴۵، ۹۰ و ۱۳۵ درجه

درجه

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰


۶-۴ 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.

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



(الف)



(ب)


(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


$$ACI(x,y) = AND(SMx,SMy) \quad (1)$$

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

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 گوشة 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 64×64 ضریب برای هر بلوک، تعداد کل ترکیبات موجود برابر 1.8×10^{19} 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 آسان تر فرآیند تحریبی 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 64×64 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 پنجاه‌درصد 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 نظیر 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 پردازش‌ها 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)^۱ با ابعاد 8×8 ، یکی از روش‌هایی است که در ساخت تصویر شدت بافت مورد استفاده قرار می‌گیرد. ضرایب DCT مربوط به یک بلوک 8×8 تصویر $f(x,y)$ با رابطه زیر بیان می‌شوند [Lim, et al., 2000, Zhong, et al., 1999]

۶-۶ ایجاد بردار مشخصه و آموزش SVM

روش SVM یک روش پیاده‌سازی تقریبی از روش کمینه‌سازی خط‌پذیری ساختاری^۱ است. دلایل استفاده از SVM آموزش‌دهی آسان، عدم نیاز به تعداد نمونه‌های زیاد و امکان تعمیم‌دهی 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 Φ 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 معروفی تابع 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^۲ زیر است که در آن بیان‌گر انحراف از استاندارد است.

$$k(x, x_i) = e^{-\frac{|x - x_i|}{2\sigma^2}} \quad (7)$$



(شکل ۱۲)- ساختار SVM به عنوان آشکارساز متن

ویدئویی شامل قلم‌های متعدد با اندازه قلم حدود بیست پیکسل از تصاویر موجود در پایگاه داده، ضرایب AC را که در آنها میان مقدار متوسط اندازه نواحی متغیر و غیر متغیر بیشترین تفاوت وجود دارد انتخاب می‌کنیم. به عبارت دیگر، پس از اعمال تبدیل فوریه کسینوسی گسسته روی بلوک‌های 8×8 تصویر خاکستری ورودی، جهت مؤثربرودن ضرایب DCT در تشخیص نواحی متغیر فارسی، از میان ۶۴ ضریب ایجاد شده برای هر بلوک، ضرایبی که به بهترین صورت، نشان‌گر تغییر فرکانس مکانی مورب، افقی و عمودی نواحی دارای متن، انتخاب می‌شوند. نتایج تجربی حاکی از وجود نوزده ضریب با وزن بلوک 8×8 ، با کمک نوزده ضریب انتخاب شده در مرحله قبل، $T(i,j)$ از طریق رابطه زیر محاسبه می‌شود. در این رابطه اندیس‌ها به شماره ضریب 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 به طور معمول به نواحی دارای متن مربوط هستند مورد تأکید خواهد 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 8×8 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

¹ Structural Risk Minimization
² Radial Basis Function

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

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

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

پس از محاسبه مشخصه های فوق، در جمع 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^۱ 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 و N تعداد بلوک های افقی و عمودی موجود در یک تصویر و MTI_{LR} , MTI_{UD} , MTI_A میانگین شدت بافت در کل تصویر، ناحیه واقع در همسایگی بالا - پایین و ناحیه واقع در همسایگی چپ - راست ناحیه

^۱ 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 کوچکتری 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 40×80 و چنانچه اندازه قلم پایه از 120 در 240 می شوند. چنانچه اندازه قلم پایه در محدوده 120 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 گوش و تصویر شدت بافت اعمال می شوند. به عبارت دیگر، در این روابط، F یکبار با تصویر گوش و بار دیگر، با تصویر شدت بافت جایگزین می شود. در این روابط، $M_2, M_1, \mu, I_H, Et, E_h$ و w ارتفاع و عرض بلوک بزرگ و h به ترتیب بیان گر انرژی، آنتروپی، 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

$$E = \sum_{i,j \in Bl} F(i,j)^2 \quad (18)$$

$$Et = \sum_{i,j \in Bl} F(i,j) \log F(i,j) \quad (19)$$

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


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

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.

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

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

چنانچه این روابط برقرار شوند، مفهوم آن متن‌بودن بلوک (i,j) 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 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 نخواهند بود. با وجود آنکه موضوع استخراج متن از تصویر ویدئویی موضوع جدیدی نیست؛ ولی جهت استخراج متن فارسی از

R هستند. این موضوع در شکل (۱۴) 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} 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 (۱۵) نمایش داده شده است. فرض کنیم $H_{prof}(i)$ نمایش‌گر پروفایل افقی هنجارسازی شده شدت بافت خط نام از ناحیه بلوک متن بازبینی شده باشد شکل (۱۵- ب). پروفایل افقی هنجارسازی شده، $H_{prof}(i)$ به صورت زیر بیان می‌شود.

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

در این رابطه، (i) تعداد بلوک‌های موجود در آمین ردیف است. به‌طور مشابه، پروفایل عمودی هنجارسازی شده شدت بافت (شکل (۱۵- ب)، $V_{prof}(j)$) به صورت زیر به دست می‌آید که در آن (j) تعداد بلوک‌های موجود در آمین ستون است.

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

-۸- پیاده سازی و آزمون

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

$$P.R = \frac{C}{C + FP} \quad (۲۲)$$

خطای مثبت^۳ (*FP*): چنانچه نواحی غیرمنتی به صورت نواحی متنی آشکار شوند، خطایی 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^۴ (*FN*): چنانچه نواحی متنی به صورت نواحی غیر متنی آشکار شوند، خطایی 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 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 Mozaffaril., 2011] و [Halima, et al., 2010, Ahmad, et al., 2012] که توسط مؤلفان این مقاله در قبل در سال ۲۰۱۰, ۲۰۱۱ کنفرانس ارائه شده است و نیز روش های ارائه شده در مراجع [] 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 این پایگاه داده به صورت پال بسوه و دارای ابعاد 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 پویانمایی، تصاویر مسابقات ورزشی، فیلم های سینمایی، تصاویر پویانمایی، تصاویر مستند، تصاویر مربوط به آگهی های بازرگانی و تصاویری که بر اثر بایگانی 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 صدرصد بیشتر است.

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

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

^۱ Precision Rate

^۲ Recall rate

^۳ False Positive

^۴ 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
ج	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 پایین بودن نمره نهایی اختصاص داده شده به روش پیشنهادی شوند، می‌توان به وجود نوفه و پایین بودن سطح تباین و روشنایی تصویر اشاره کرد. از جمله نقاط قوت این الگوریتم، مقاوم بودن آن در مقابل تغییر اندازه و سبک قلم، حرکت متن، پیچیدگی پس زمینه 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 متون 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 به طور اختصار به صورت زیر بیان کرد: افزایش سطوح هرم چند وضوحی 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] Ahmad, et al., 2010، پیاده‌سازی شده و نتایج حاصل از پسنج روش مذکور با به کار گیری پایگاه داده در جدول (۲) نشان داده شده است. شایان ذکر است در مراجع [Halima, et al., 2010, Ahmad, et al., 2012] تأکید بر متون عربی است که آشکارسازی متن عربی به دلیل افزایش تکانه‌های ناشی از اعراب، از متن فارسی آسان‌تر خواهد بود.

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


روش‌های موجود

	نرخ فراخوانی	نرخ دقت	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 پس زمینه به صورت پیچیده است. در تصویر (ب) یک صحنۀ پویانمایی نشان داده شده است که در آن به دلیل پایین بودن تباین و روشنایی، خطای مثبت و منفی هر دو اتفاق افتاده‌اند. تصویر (پ) مثالی از خطوط متنی متحرک همراه با پس زمینه پیچیده متحرک را نمایش می‌دهد. در این تصویر به دلیل سرعت بالای پس زمینه، خطای مثبت رخ داده است. تصویر (ت) نمونه‌ای از وجود قلم با اندازه متفاوت است که به طور دقیق متن در آن آشکارشده است. تصویر (ث) نمونه‌ای از وجود متن فارسی و انگلیسی بوده که به دلیل وجود نوفه، خطای منفی رخ داده است. در تصویر (ج) هر دو متن ثابت و متحرک به صورت همزمان وجود دارند. تصویر (ج) نمونه‌ای از تصویر با پس زمینه پیچیده است. در تصویر (ح) متن دارای چرخش و اندازه قلم متفاوت است. در این تصویر به دلیل 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)



(ب)



(ت)



(ث)



(ج)



(ج)



(ح)

(شكل ۱۶)- نمونه هایی از متن آشکار شده در تصاویر ویدئویی

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰



فصل نهم
فصل نهم



(شکل ۱۷)- اثر برخی از متغیرهای موجود در متن داخل تصاویر روی نرخ فرخوانی، نرخ دقیق 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 گوشهای 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 دقیق 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 2nd 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 بازناسی تصاویر دیجیتال و فشرده سازی ویدئو است.

نشانی رایانامه 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 ۱۳۸۶، ۱۳۸۰ و ۱۳۷۸ از دانشگاه صنعتی امیرکبیر دریافت کرد. ایشان فرست مطالعاتی خود را بهمدت 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 رایانامه 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 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 می باشد. زمینه های تحقیقاتی ایشان طراحی مدارهای مجتمع آنالوگ و مدل سازی ترانزیستورهای SOI, MOS است.

نشانی رایانامه 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 segmenting 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, 6th Iranian Conference on Machine Vision and Image Processing (MVIP), 2010

Moradi, M., Mozaffari, S., Orouji A.A., Farsi/Arabic text extraction from video images , 19th 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

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰



فصلنامه
پردازش داده ها