

شناسایی کلمات فارسی نستعلیق با استفاده از شبکه‌های عصبی مصنوعی

نفیسه صالحیان^۱، محمدرضا یزدچی^۲، علیرضا کریمیان^۳

۱- دانشگاه آزاد اسلامی واحد نجف آباد، دانشکده تحصیلات تکمیلی، mmail25@yahoo.com

۲- عضو هیات علمی گروه مهندسی پزشکی دانشگاه اصفهان، yazdchi@eng.ui.ac.ir

۳- عضو هیات علمی گروه مهندسی پزشکی دانشگاه اصفهان، karimian@eng.ui.ac.ir

چکیده

در این مقاله یک سیستم کامل برای شناسایی کلمات فارسی نستعلیق با استفاده از شبکه‌های عصبی مصنوعی پیاده‌سازی شده است. در مرحله پیش‌بردازش پس از یافتن بخش‌های متصل، سركش‌ها و زیرکش‌های حروف کشف و از تصویر حذف می‌گردند. با استفاده از یک الگوریتم تقطیع که بر اساس کانتور بالایی و پایینی کلمه عمل می‌کند، تصویر کلمه به دنباله‌ای از زیر کلمه‌ها شکسته می‌شود. پس از انجام عمل تقطیع، هشت ویژگی شامل سه توصیفگر فوریه و تعدادی ویژگی ساختاری گسسته برای نمایش زیر کلمه‌ها در فضای ویژگی بکار می‌روند. شناسایی با استفاده از یک شبکه عصبی پرسپترون چند لایه و بر اساس این بردارهای ویژگی انجام می‌شود. خطاها احتمالی در تشخیص زیر کلمه‌ها با استفاده از یک الگوریتم جستجو در لغتنامه سیستم اصلاح می‌شود. آزمایش سیستم بر روی یک نمونه شامل ۳۲۰ کلمه عملکرد مناسبی (۹۷٪ صحت) را نشان می‌دهد.

واژه‌های کلیدی

تقطیع، شبکه‌های عصبی مصنوعی، شناسایی کلمات


۱- مقدمه

عکس‌هایی در قالب JPEG در آمده است استفاده شده است. یک عامل مهم در سیستم‌های شناسایی حروف روش‌هایی استفاده شده در تقطیع متن مورد نظر است. سه روش برای تقطیع در سیستم‌های مذکور وجود دارد^{[۱] و [۹]: ۱- راهکار کلاسیک؛ در این روش کلمات به اجزاء قابل تشخیص شکسته می‌شوند. ۲- راهکار مبتنی بر شناسایی؛ این روش سعی در شکستن کلمات به حروف الفبای شناخته شده دارد. ۳- راهکار کلی^۱ در این روش سیستم، کلمه را به طور کامل و بدون نیاز به تقطیع شناسایی می‌کند. امتیاز روش کلی این است که مرحله شناسایی پیچیدگی چندانی ندارد. ولی سیستم قادر به شناسایی تعداد محدودی از کلمات است. دو روش دیگر بسیار قدرتمند عمل می‌کنند و محدودیتی در شناسایی کلمات ندارند. اما سیستم مربوط به آنها پیچیده‌تر است. تصویر}


شناسایی کلمات دستنویس کاربرد زیادی در کارهای بانکی (پردازش چک‌های بانکی)، شناسایی آدرس‌های پستی و Zip code ها و دارد. روش‌های شناسایی خودکار متون با عنوان کلی OCR^۲ شناخته شده، بر حسب اینکه متن به چه صورتی به سیستم ارائه می‌گردد، به دو دسته کلی تقسیم می‌شوند ۱- روش‌های بر خط^۳؛ در این روش‌ها کلمات و حروف توسط کاربر روی یک صفحه مخصوص رسم و به صورت یک دنباله از نقاط که توسط مختصاتشان مشخص می‌شوند در اختیار سیستم قرار داده می‌شود. ۲- روش‌های برون خط^۴؛ در این روش‌ها متن به صورت یک تصویر بدست آمده از Scanner یا دوربین‌های دیجیتال در اختیار سیستم قرار می‌گیرد. در این مقاله از روش برون خط به صورت کلمات نوشته شده با فونت نستعلیق که توسط نرم افزار Photoshop CS به صورت

دربافت می‌کند، که هر کدام از این سیگنال‌ها در یک وزن جدآگاههای ضرب شده‌اند. سیگنال‌های حاصل، بایکدیگر جمع شده (شکل ۲) و سپس به تابع محدود کننده تحويل داده می‌شوند. این تابع محدود کننده، خروجی نرون را در یک محدوده مشخص نگاه می‌دارد. خروجی این محدود کننده به تمام نرون‌های لایه بعد منتقل می‌شود. برای داشتن یک شبکه عصبی هوشمند باید وزن‌های مذکور محاسبه شوند. در این نوع شبکه خاص، سیستم با روش آموزش داده می‌شود و وزن‌های مذکور در این روش آموزشی محاسبه می‌شود.

برای آموزش شبکه، یک مجموعه از نمونه‌های ورودی و خروجی‌های صحیح مورد انتظار^۷ متناظر با هر ورودی تهیه شده سپس سیستم با این مجموعه آموزشی، آموزش داده می‌شود. به این صورت که با ورود یکی از نمونه‌ها به سیستم، خروجی براساس وزن‌های اولیه (در اولین مرحله وزن‌ها اعداد دلخواهی انتخاب می‌شوند) محاسبه می‌شود. سپس این خروجی با خروجی مورد انتظار مقایسه و یک سیگنال مربع خطأ محاسبه می‌شود. از این مربع خطأ برای اصلاح ضرائب (وزن‌ها) در هر لایه استفاده می‌شود. در هر مرحله از آموزش، مربع خطأ کاهش می‌باید. تمام این مراحل به طور چرخشی برای همه ورودی‌ها به ترتیب انجام می‌شود تا جائی که مربع خطأ از یک حدی کمتر شود. در این صورت گفته می‌شود که سیستم آموزش دیده است. سیستم هیچ‌گاه کاملاً آموزش نمی‌بیند ولی می‌توان عملکرد آن را تا حد امکان بهینه کرد.



شکل ۱- ساختار یک شبکه عصبی



شکل ۲- ساختار داخلی یک نرون

کلمات ابتدا تحت یک سری پیش‌پردازش برای مراحل بعدی آماده می‌شود. سپس در مرحله تقطیع براساس روش مبتنی بر شناسایی، کلمه به حروف یا زیرحروف تشکیل‌دهنده آن شکسته می‌شود. پس از آن یک مجموعه ویژگی از تصویر هر قطعه استخراج می‌شود. در مرحله بعدبا استفاده از شبکه‌های عصبی مصنوعی که با بردارهای ویژگی حاصل، آموزش دیده است، حروف شناسایی می‌شود. سپس با استفاده از یک الگوریتم سرج در لغتنامه، کلمه شناسایی می‌شود.

۲- مشخصات نوشتار فارسی

نوشتار حروف در فارسی در چند جهت با نوشتار در زبان انگلیسی متفاوت است ۱- شکل حروف فارسی تابعی از موقعیت حرف در کلمه است. برای یک حرف ممکن است چهار شکل متفاوت بسته به موقعیت حرف در کلمه (ابتدا کلمه، وسط، آخر و یا حرف جدا) وجود داشته باشد. بعضی از حروف در سبک‌های نوشتاری مختلف و در موقعیت ثابت در کلمه به شکل‌های متفاوتی نوشته می‌شوند. ۲- تعدادی از حروف فارسی قابلیت متصل شدن به یکدیگر را دارند. در حالی که بعضی دیگر به هیچ حرفی وصل نمی‌شوند. ۳- به علت اینکه حروف دارای شکل‌های متفاوتی در موقعیت‌های مختلف در کلمه هستند، بنابراین تعداد کلاس‌های قابل تشخیص توسط سیستم به مقدار زیادی افزایش می‌یابد. بنابراین روش شناسایی سیستم پیچیده‌تر می‌شود. ۴- بعضی از حروف فارسی دارای ۱، ۲ یا ۳ نقطه در بالا یا پایین خود هستند و گاهی تفاوت بین دو حرف در وجود یا عدم وجود و یا در تعداد این نقاط است. ۵- حروف فارسی برخلاف حروف لاتین از راست به چپ نوشته می‌شوند. جدول (۱)


حروفی که تفاوت آن‌ها در وجود و یا عدم وجود سرکش‌ها و نقاط و تعداد آن‌ها است، در ابتدا جزء یک کلاس تشخیص داده می‌شوند. پس از تشخیص کلاسی که حرف مورد نظر به آن تعلق دارد و اضافه کردن اطلاعات مربوط به سرکش‌ها و نقاط، حروف کاملاً ایکدیگر متمایز می‌شوند.

روش نوشتاری نستعلیق به خاطر زیبایی خاص آن معروف‌ترین روش نوشتاری فارسی است. در این مقاله، نستعلیق به عنوان روش نوشتاری کلمات برگزیده شده است.

۳- شبکه عصبی

شبکه عصبی استفاده شده در این مقاله یک شبکه پرسپترون چند لایه است. با توجه به شکل‌های (۱) و (۲) شبکه فوق به این صورت عمل می‌کند: هر نرون یک سیگنال از نرون‌های لایه قبلی

۴- سیستم پیاده سازی شده



۴-۱- پیش پردازش

با توجه به این که کلمات ورودی با فونت نستعلیق، توسط نرم افزار Adobe Photoshop CS به صورت عکس‌هایی در قالب JPG در آمده است، پس به نویززدایی از تصویر کلمه ورودی نیاز نیست. در این مرحله بخش‌های متصل در تصویر کلمه ورودی از یکدیگر جدا می‌شوند. برای یافتن اجزای متصل یک روند تکراری (و نه بازگشتی)، با میزان پیچیدگی محاسباتی پایین بکار رفته است. در این الگوریتم ابتدا بالاترین پیکسل سیاه تصویر کلمه ورودی پیدا می‌شود. سپس با استفاده از یک عنصر ساختاری ساده با ابعاد 3×3 ، هشت همسایگی پیکسل مورد نظر به صورت زیر پیدا شده، بررسی می‌شوند:

$$X_1 = imdilate(X, SE_1) \quad (1-1)$$

که در آن SE_1 عنصر ساختاری با ابعاد 3×3 و X ماتریس شامل پیکسل سیاه یافت شده و X_1 هشت همسایگی پیکسل مورد نظر می‌باشدند.

حال پیکسل‌های سیاه این هشت همسایگی مشخص می‌شوند. با در نظر گرفتن این پیکسل‌های سیاه به هم متصل یافت شده به صورت یک جزء واحد، هشت همسایگی آن بررسی شده، پیکسل‌های سیاه یافت شده به این جزء متصل اضافه می‌شوند. این روند ادامه داده می‌شود تا زمانی که دیگر در هشت همسایگی پیکسل‌های یافت شده هیچ پیکسل سیاهی یافت نشود. حال این جزء متصل یافت شده ذخیره شده، از تصویر کلمه حذف می‌شود. روند فوق برای تصویر حاصل تکرار می‌شود تا زمانی که همه اجزاء متصل یافت شده، به صورت مجرزاً ذخیره شوند و در تصویر حاصل هیچ پیکسل سیاهی باقی نماند. این الگوریتم تمام بخش‌های متصل را به درستی جدا می‌کند.

مختصات بالاترین نقطه سیاه از سمت راست‌ترین ستون هر جزء متصل در مراحل بعدی بسیار مفید و کارساز خواهد بود. یک الگوریتم پیمایش کانتور خارجی با شروع از این نقطه، نقاط روی

شناسایی کلمات فارسی نستعلیق شامل مراحل زیراست. ابتدا یک سری پیش‌پردازش شامل حذف سرکش‌ها و زیرکش‌ها و نقاط، بر روی کلمات انجام می‌پذیرد. سپس کلمات حاصل به حروف سازنده آن، حروف و در برخی موارد به ترکیبی ازدو حرف شکسته می‌شود. پس از آن مجموعه‌ای از ویژگی‌ها از تصویر هر زیر کلمه استخراج می‌شود. شناسایی بر اساس بردار ویژگی حاصل انجام می‌پذیرد. شناسایی با استفاده از شبکه عصبی پرسپترون چند لایه انجام می‌شود. ابتدا بردارهای ویژگی حاصل از حروف برای تمام نمونه‌ها (حروف) روی هر ویژگی هنجارسازی^۱ می‌شود. سپس شبکه عصبی با این بردارهای ویژگی هنجارسازی شده، آموخته داده می‌شود. از این پس شبکه عصبی آموخته دیده برای شناسایی حروف موردن استفاده قرار می‌گیرد. مرحله شناسایی با بهره‌گیری از اطلاعات مربوط به لغتنامه و الگوریتم جستجو (شکل ۳) کامل می‌شود.

جدول ۱- جدول حروف فارسی و شکل هر حرف در موقعیت‌های مختلف در کلمه

| | Character | Isolated | First | Middle | Last |
|----|-----------|----------|-------|--------|------|
| 1 | Alef | (ا) | (ا) | ا | ا |
| 2 | Be | ب | ب | ب | ب |
| 3 | Pe | پ | پ | پ | پ |
| 4 | Te | ت | ت | ت | ت |
| 5 | Se | ت | ت | ت | ت |
| 6 | Jim | ج | ج | ج | ج |
| 7 | Che | چ | چ | چ | چ |
| 8 | He | ح | ح | ح | ح |
| 9 | Khe | خ | خ | خ | خ |
| 10 | Dal | د | د | د | د |
| 11 | Zal | ذ | ذ | ذ | ذ |
| 12 | Re | ر | ر | ر | ر |
| 13 | Ze | ز | ز | ز | ز |
| 14 | Zhe | ڙ | ڙ | ڙ | ڙ |
| 15 | Sin | س | س | س | س |
| 16 | Shin | ش | ش | ش | ش |
| 17 | Sad | ض | ض | ض | ض |
| 18 | Zad | ڏ | ڏ | ڏ | ڏ |
| 19 | Ta | ط | ط | ط | ط |
| 20 | Za | ظ | ظ | ظ | ظ |
| 21 | Ayn | ع | ع | ع | ع |
| 22 | Ghayn | غ | غ | غ | غ |
| 23 | Fe | ف | ف | ف | ف |
| 24 | Ghaf | ق | ق | ق | ق |
| 25 | Kaf | ك | ك | ك | ك |
| 26 | Gaf | گ | گ | گ | گ |
| 27 | Lam | ل | ل | ل | ل |
| 28 | Mim | م | م | م | م |
| 29 | Noon | ن | ن | ن | ن |
| 30 | Waw | و | و | و | و |
| 31 | He | ه | ه | ه | ه |
| 32 | Ye | ي | ي | ي | ي |

۱-۱-۴- حذف سرکش

برای حذف سرکش‌های حروفی مثل "ک" و "گ" از مشخصاتی که سرکش را از سایر بخش‌های متصل کلمه مجزا می‌کند، استفاده می‌شود. این مشخصات عبارتند از: شب تقریبی ۴۵ درجه، طول و کشیدگی بدون خمیدگی سرکش. با استفاده از این سه مشخصه، سرکش شناسایی و حذف می‌شود: ابتدا کانتور خارجی هر بخش متصل بدست می‌آید (شکل ۶-ب). در حالی که این کانتور [۳] در جهت عقربه‌های ساعت پیمایش می‌شود، به وسیله تعیین کد زنجیره‌ای [۳] و [۶] هر پیکسل، کانتور پایینی هر بخش متصل به دست می‌آید. پیکسل‌هایی که کد زنجیره‌ای آنها در جهت غرب، شمال غربی یا جنوب غربی قرار دارند، کانتور پایینی بخش متصل را تشکیل می‌دهند (شکل ۶-ج). حال از بالاترین پیکسل کانتور پایینی شروع به پیمایش آن می‌نماییم. این پیمایش تا زمانی که شرط توقف غلط باشد، ادامه می‌یابد. شرط توقف وقتی برقرار می‌شود که حرکت در جهت قطری به سمت پایین و چپ (جنوب غربی) کمتر از تعداد دفعات مشخصی باشد (در این صورت شرط بدون خمیدگی بودن سرکش نقض می‌شود). با در نظر گرفتن طول و زاویه شیب سرکش پیدا شده، می‌توان آن را اعتبارسنجی کرد. حال با استفاده از مشخصات نقاط شروع و پایان سرکش، می‌توان آن را از تصویر کلمه حذف کرد (شکل ۶-د). این الگوریتم میزان صحت ۱۰۰٪ را در شناسایی و حذف سرکش‌ها نشان می‌دهد. در ادامه روش حذف سرکش به صورت الگوریتم آورده شده است:

روش حذف سرکش‌ها:

- ابتدا کانتور خارجی هر جزء متصل بدست می‌آید. برای

بدست آوردن کانتور خارجی از یک نقطه (بالاترین پیکسل جزءمتصل) شروع کرده، در جهت عقربه‌های ساعت یا خلاف آن لبه تصویر جزء متصل پیمایش می‌شود و به این ترتیب با مشخص کردن پیکسل‌های موجود بر لبه تصویر، کانتور خارجی جزءمتصل مربوط مشخص می‌شود [۳] (شکل ۶-ب).

- حال با تعیین کد زنجیره‌ای [۳] برای پیکسل‌های کانتور

خارجی، در حالی که کانتور خارجی در جهت عقربه‌های ساعت پیمایش می‌شود، می‌توان کانتور پایینی هر جزء متصل را مشخص کرد. به این صورت که وقتی کانتور خارجی در جهت عقربه‌های ساعت پیموده می‌شود، با تعیین پیکسل‌هایی که کد زنجیره‌ای آنها در جهت غرب، شمال غربی یا جنوب غربی قرار دارند، کانتور پایینی جزء متصل مشخص می‌شود (شکل ۶-ج).

کانتور خارجی را بدست آورد، ذخیره می‌کند. با رسیدن به نقطه شروع، این پیمایش متوقف شده، طول بدست آمده ذخیره می‌گردد. پیمایش پیکسل‌های بخش متصل از بالاترین پیکسل سیاه در تصویر کلمه شروع می‌شود. پس از یافتن آخرین پیکسل هر بخش متصل، این بخش به صورت یک عکس ذخیره شده، از تصویر کلمه حذف می‌شود. این کار مرتبًا تکرار می‌شود تا زمانی که دیگر پیکسل سیاهی در تصویر کلمه موجود نباشد [۳]. بخش‌های متصل یک کلمه در شکل [۴] مشاهده می‌شود. در این سیستم چون شناسایی کلمه برمبنای شناسایی حروف است، برای بازسازی کلمه شناسایی شده، ترتیب راست به چپ حروف بسیار مهم است. اما سرکش‌های حروفی مثل "ک" و "گ" و زیرکش‌های حروفی مثل "ع" و "غ" و "ح" و "خ" و ... معمولاً زودتر از حروف قبل از خود شناسایی شده، ترتیب راست به چپ حروف را دچار خطأ می‌کنند (شکل ۵). لذا برای تشخیص صحیح ترتیب راست به چپ حروف در این مرحله لازم است که سرکش‌ها و زیرکش‌ها حذف شوند. در این سیستم، شناسایی اولیه حروف بدون درنظر گرفتن نقاط حروف و سرکش‌ها و علائم اضافه‌ای مثل کلاه الف (ـ) و ... انجام می‌شود. پس از تعیین دسته‌ای که هر حرف به آن تعلق دارد، با اضافه کردن اطلاعات مربوط به تعداد نقاط حرف وجود یا عدم وجود سرکش‌ها و علائم اضافه، شناسایی کامل و حرف تشخیص داده می‌شود. پس در مرحله پیش‌پردازش نقاط و علائم اضافه نیز حذف می‌گردد.



(الف) (b)

شکل ۴- جداسازی بخش‌های متصل کلمه الف-کلمه ورودی ب- بخش‌های متصل



(الف) (ب)

شکل ۵- سرکش‌ها و زیرکش‌ها در تعیین ترتیب راست به چپ حروف زودتر از حرف قبل از خود تشخیص داده می‌شوند (الف) - زیرکش. (ب)- سرکش

۴-۱-۲- حذف زیرکش

برای شناسایی زیرکش‌ها از ویژگی‌های زیر استفاده می‌شود: تصویر زیرکلمه شامل زیرکش، به‌این‌صورت است که اگر از پایین‌ترین قطعه سیاه در اولین ستون سمت راست شروع کرده، ستون به ستون این قطعه سیاه به سمت چپ تا انتهای زیرکش دنبال شود، طول هم‌پوشانی این قطعه سیاه (زیرکش) با قطعه‌های سیاه بالایی و طول زیرکش نسبتاً بزرگ است، ثانیاً در اکثر ستون‌های زیرکش تعداد قطعه‌های سیاه بیشتر از یک می‌باشد. این ویژگی‌ها زیرکش را از سایر بخش‌های کلمه به خوبی مجزا می‌کند. بنابراین برای حذف زیرکش: از اولین ستون سمت راست که دارای بیش از یک قطعه سیاه است شروع کرده، مختصات پیکسل‌های ابتداء و انتهای پایین‌ترین قطعه سیاه این ستون ذخیره می‌شود (x_1, x_2, \dots, x_k). ستون مجاور سمت چپ ($(k+1)$ ام) ستون فعلی (k ام) بررسی می‌شود، اگر تعداد تداوم‌های موجود در ستون ($k+1$)ام در مجاورت قطعه سیاه فعلی (متعلق به ستون k ام) بیش از یک باشد، تداوم سیاه فعلی متعلق به زیرکش نیست (شکل ۷-ج). حال تعداد تداوم‌های ستون قبلی ($-k$ ام)، در محدوده x_1, x_2, \dots, x_k مربوط به ستون k ام بدست آورده می‌شود، اگر این تعداد برابر یک باشد، بررسی ستون به ستون به سمت چپ به همین روال ادامه داده می‌شود. اما اگر این تعداد برابر دو باشد، هم‌پوشانی زیرکش با قطعات بالا تمام شده است و به آخر زیرکش رسیده‌ایم. (شکل ۷-د)


تذکر: با انتقال از یک ستون به سمت دیگر به سمت چپ، متغیر k که تعیین کننده تعداد ستون‌های پیموده شده است، یک واحد اضافه می‌شود (طول زیرکش). اگر k در یک محدوده منطقی باشد، زیرکش معتبر است. پس از تعیین زیرکش مختصات شروع و پایان آن ذخیره شده، در مرحله بعدی با استفاده از این مختصات زیرکش از تصویر کلمه حذف می‌شود. میزان صحت حذف زیرکش‌ها با این روش برابر ۱۰۰٪ است. در ادامه روش حذف زیرکش به صورت الگوریتم آورده شده است:

روش حذف زیرکش‌ها:

- از آنجایی که زیرکش با قطعات بالایی خود هم‌پوشانی دارد بنابراین از سمت راست‌ترین ستونی که دارای بیش از یک قطعه سیاه است شروع کرده، مختصات پیکسل‌های ابتداء و انتهایی پایین‌ترین قطعه سیاه این ستون را بدست می‌آوریم. (x_1, x_2, \dots, x_k)
- ستون سمت چپ ($(k+1)$ ام) مجاور ستون فعلی (k ام) بررسی می‌شود، اگر در مجاورت قطعه سیاه فعلی (متعلق

- از بالاترین پیکسل کانتور پایینی جزء متصل شروع به پیمایش کرده و این پیمایش تا زمانی که شرط توقف غلط باشد، ادامه داده می‌شود. شرط توقف وقتی برقرار می‌شود که حرکت بیش از تعداد دفعات مشخص در جهت قطری به سمت پایین و چپ (جنوب غربی) نباشد (در این صورت شرط بدون خمیدگی بودن سرکش نقض می‌شود).


- در حین این پیمایش تعداد انتقال‌های صحیح، k_1 ، (یعنی در جهت جنوب غربی) و تعداد همه انتقال‌ها، k ، (یعنی طول این قطعه از کانتوری که پیمایش شده است) شمارش می‌شود. پس از برقرار شدن شرط توقف اگر k نسبتاً کوچک باشد و $\frac{k_1}{k}$ نیز نسبتاً بزرگ باشد یک سرکش کوچک پیدا شده است. اگر $\frac{k_1}{k}$ نیز نسبتاً بزرگ باشد، یک سرکش بزرگ پیدا شده است. برای هر جزءی که سرکش تشخیص داده شده است، تفاضل طول نقاط ابتدایی و انتهایی سرکش را بدست آورده و بر تفاضل عرض نقاط ابتدایی و انتهایی آن تقسیم می‌شود، به این ترتیب t_g زاویه جزء سرکش تشخیص داده شده محاسبه می‌شود. اگر این مقدار بین $1/4$ تا $1/9$ باشد، سرکش تشخیص داده شده معتبر است.
- حال مختصات نقاط شروع و پایان سرکش ذخیره شده و در مرحله بعد با استفاده از این مختصات سرکش از تصویر کلمه حذف می‌شود. (شکل ۶-د)



(الف)



(ب)



(ج)

شکل ۶-مراحل حذف سرکش: الف - کلمه ورودی ب - کانتور خارجی سرکش ج - کانتور پایینی سرکش د - نتیجه حذف سرکش در کلمه

الگوریتم حذف نقاط و علائم اضافه:

۱- اجزاء متصل بدست آیند.

۲- برای هر جزء متصل:

$Height1 \leq th1 * Est$ و $Width1 \leq tw1 * Est$ ۱-۱-اگر

$Width1 \leq tw2 * Est$ و $Height1 \leq th2 * Est$ ۱-۲-یا

$Height1 \leq th3 * Est$ و $Width1 \leq tw3 * Est$ باشد

۲-۱- اگر جزء متصل دیگری وجود داشت که پهنهای جزء متصل جاری به طور کامل در محدوده پهنهای آن قرار گیرد، جزء متصل جاری، یک CS است و باید حذف شود.

۲-۲- جزء متصل جاری از تصویر حذف گردد

را نشان می‌دهند.

منظور از CS (Characteristic Strokes) : تکه نوشته‌های مشخصه) نقطه‌های حروف و کلاه‌الف (~) و همزه می‌باشد. ثابت‌های عددی تعریف شده عبارتند از:

$th1=2.5$ ، $tw1=2.5$ (نقطه)

$th2=2.5$ ، $tw2=6$ (کلاه الف)

$th2=2$ ، $tw2=4$ (همزه)

پارامترهای الگوریتم به گونه‌ای در نظر گرفته شده‌اند که تا جایی که ممکن است زیرکلمه دیگری به جای نقطه‌ها یا علائم حذف نشود. این الگوریتم تمام نقاط و علائم اضافه را به درستی شناسایی و حذف می‌کند.

۴-۲- تقطیع و تعیین ترتیب راست به چپ

در اینجا چند روش تقطیع^{۱۰} معرفی می‌شود: روشی که برمبنای هیستوگرام عمودی^{۱۱} و یا خط زمینه^{۱۲-۱۳} است. این روش برای تقطیع کلمات نوشته شده به خصوص کلمات فارسی (نستعلیق) به خاطر تنوع نوع نوشтар آن مناسب نیست. دو روش دیگر که برای تقطیع کلمات فارسی (نستعلیق) مناسب‌تر به نظر می‌رسند عبارتند از: روش تقطیع با استفاده از اجزاء منفرد و منظم [۲] که اجزاء منظم را به عنوان محل‌های اولیه تقطیع در نظر می‌گیرد. روش دیگر روشی است که براساس آنالیز کانتور بالایی عمل می‌کند. از آنجایی که در روش‌های مبتنی بر آنالیز کانتور بالایی احتمال عدم تقطیع و تقطیع

به ستون k+1 فقط یک قطعه سیاه در ستون ۱ام

وجود داشته باشد، مختصات نقاط بالا و پایین این قطعه

سیاه را بدست می‌آوریم (x4, x3) در غیراین صورت تداوم

سیاه ستون ۱ام متعلق به زیرکش نیست (شکل ۷-ج).

- حال تعداد تداوم‌های ستون قبلی (k)، در محدوده

x4, x3 مربوط به ستون k+1 را بدست می‌آوریم، اگر

این تعداد برابر ۱ باشد، بررسی ستون به ستون به سمت

چپ به همین روال ادامه داده می‌شود. اما اگر این تعداد

برابر ۲ باشد یعنی همپوشانی زیرکش با قطعات بالا تمام

شده است و به آخر زیرکش رسیده‌ایم. بنابراین مختصات

ابتدا تداوم سیاه ستون فعلی (k+1) بدست می‌آوریم و

از این نقطه برای برش زیرکش استفاده می‌کنیم


(شکل ۷-د).

- اگر k از حد مشخصی بزرگ‌تر باشد، زیرکش معتبر می‌باشد.

ج

(ب)

(الف)



(د)

(ج)

شکل ۷- حذف زیرکش: الف - تصویر کلمه ورودی ب - نتیجه حذف زیرکش ج - حالتی که قطعه سیاه متعلق به زیرکش نیست
د - حالتی که به انتهای زیرکش رسیده است

۴-۳- حذف نقاط و علائم اضافه

تشخیص نقاط و علائم اضافه از روی ویژگی‌هایی مانند کوچکی اندازه و قرار گرفتن آن‌ها در محدوده زیرکلمه‌های بزرگ‌تر امکان‌پذیر است. این مشخصات به گونه‌ای در نظر گرفته می‌شود که هیچ زیرکلمه دیگری غیر از زیرکلمه مورد نظر در این محدوده قرار نگیرد. الگوریتم حذف این نقاط و علائم اضافه در ادامه آورده شده است:



شکل ۹- نمونه‌هایی از نتایج الگوریتم جداسازی "ر" چسبان در کلمه

۴-۳-۲-۴- شناسایی همپوشانی و انجام تقطیع مناسب

تقطیع با استفاده از کمینه‌های کانتور بالایی علاوه بر ناتوانی در تقطیع "ر" چسبان، برای مواردی مثل "ح" و "م" موجود در وسط کلمه (شکل (۸)) نیز قادر به انجام عمل تقطیع نمی‌باشد. این مشکل با یافتن همپوشانی‌ها و تقطیع مناسب در آن‌ها رفع می‌شود. برای شناسایی همپوشانی: در هر زیرکلمه از اولین ستون سمت راست شروع کرده، تعداد، طول و محل تداوم‌های سیاه موجود در ستون جاری بدست می‌آید. اگر تعداد تداوم‌ها بیش از یک باشد و درستون مجاور سمت راست پایین‌ترین تداوم سیاه آن هیچ پیکسل سیاهی یافت نشود، این ستون بعنوان شروع همپوشانی در نظر گرفته می‌شود. سپس به سمت چپ حرکت می‌کنیم تا دو قطعه همپوشانی بهم بپیونددند. به این ترتیب دوستونی که بین آنها همپوشانی وجود دارد بدست می‌آید. حال با پیمایش کانتور خارجی، اگر همپوشانی یافت شده مربوط به یک حلقه نباشد، در محلی از بخش بالای همپوشانی که دارای کمترین پهنا است، برش زده می‌شود. میزان صحت این الگوریتم ۱۰۰٪ می‌باشد.



شکل ۱۰- نمونه‌هایی از نتایج الگوریتم کشف همپوشانی و انجام تقطیع مناسب

۴-۴- یافتن کمینه‌های کانتور بالایی و انجام تقطیع

در هر زیرکلمه، با پیمایش کانتور خارجی در جهت خلاف فربه‌های ساعت و با استفاده از کد زنجیره‌ای، پیکسل‌هایی که در

زیادی (ایجاد بیش از یک برش بین دو حرف) کمتر از سایر روش‌ها است، پس این روش مناسب‌تر می‌باشد. در ادامه روش تقطیع و تعیین ترتیب راست به چپ حروف بیان می‌شود.

۴-۴-۱- تقطیع با استفاده از مینیموم‌های کانتور بالایی

در این روش [۴] کمینه‌های محلی کانتور بالایی به عنوان محل‌های اولیه انجام برش در نظر گرفته می‌شوند. سپس در صورت برقرار بودن مجموعه‌ای از شرایط (که در ادامه توضیح داده خواهد شد (بخش ۴-۲-۴)، تقطیع در این نقاط انجام می‌شود. با انجام یک سری اصلاحات در این روش می‌توان آن را برای تقطیع کلمات فارسی (نستعلیق) بهبود داد. از آنجا که در خط نستعلیق حرف "ر" چسبان و مواردی مثل "ح" موجود در وسط کلمه (شکل (۸)) بدون داشتن کمینه محلی پیش از خود نوشته می‌شوند، این روش قادر به تقطیع آنها نیست. بنابراین ابتدا یک الگوریتم جدید برای شناسایی و تقطیع این موارد بکار می‌رود. سپس کانتور بالایی با یک روش ساده بدست آمده و کمینه‌های محلی آن به عنوان نقاط اولیه تقطیع بدست می‌آید. آنگاه این نقاط اولیه اعتبار سنجی شده، در محل‌های معتبر به طریق مناسب تقطیع انجام می‌شود. این مراحل در ادامه توضیح داده شده است.



شکل ۸- حرف "ح" و "م" در وسط کلمه

۴-۴-۲- شناسایی و تقطیع "ر" چسبان

برای کشف "ر" چسبان از روشهای مشابه با روش کشف سرکش‌ها استفاده شده است. در پیدا کردن "ر" چسبان برخلاف آنچه در یافتن سرکش انجام شد، از پایین ترین نقطه کانتور پایینی در جهت خلاف عقربه ساعت شروع به پیمایش آن می‌نماییم. شرط توقف وقتی برقرار می‌شود که حرکت در جهت قطری و به سمت بالا و راست (شمال شرقی) کمتر از تعداد دفعات مشخصی باشد (در این صورت شرط بدون خمیدگی بودن نسبی "ر" چسبان نقض می‌شود). یعنی زمانی که به تعداد مشخصی انتقال در جهت‌هایی غیر از جهت شمال شرقی رسیدیم، پیمایش متوقف می‌شود. زمانی "ر" پیدا شده معتبر است که طول آن در یک محدوده منطقی باشد. در این صورت حرف "ر" از قسمت‌های دیگر زیرکلمه جدا می‌شود. میزان صحت این الگوریتم ۱۰۰٪ می‌باشد.

بر اساس میزان صحت شناسایی انتخاب می‌شود [۲]. در شناسایی حروف، هشت ویژگی شامل سه توصیفگر فوریه (توصیفگرهای ۱ تا ۳)، تعداد حلقه‌ها، نسبت ارتفاع به پهنا، نسبت نقاط سیاه به کل نقاط و اتصال چپ و راست حروف بیشترین میزان صحت را نشان می‌دهد. این ویژگی‌ها برای تمام حروف کلمات مورد آزمایش محسوب می‌شود. حال هر ویژگی بر روی تمام نمونه‌های حاصل از کل کلمات مورد آزمایش هنجارسازی می‌شود. در نتیجه میانگین هر ویژگی برابر صفر و واریانس آن برابر یک است.

۴-۴- شناسایی

سیستم شناسایی شامل یک شبکه عصبی پرسپترون چند لایه می‌باشد [۹]. این شبکه عصبی در اینجا شامل یک لایه پنهان و یک لایه خروجی است. باروش سعی و خطأ و درنظرگرفتن سیزده نرون در لایه پنهان و تابع غیر خطی تانژانت هیپرboleک برای لایه‌های پنهان و خروجی و تابع آموزشی (Resilient backpropagation) [۱۰] نتیجه آزمون نمونه‌های آموزشی ۹۶٪ و نتیجه آزمون نمونه‌های آزمایشی ۹۳٪ به دست می‌آید. لازم به ذکر است که در این مرحله از شناسایی نقاط و سرکش‌ها خود به عنوان دسته‌های خروجی مجازاً در نظر گرفته می‌شوند. سایر دسته‌ها شامل حروف یا بعضی از ترکیبات حروف که قابل تقطیع از یکدیگر نیستند (شکل ۱۳)، بدون نقطه و سرکش‌های آنها در نظر گرفته می‌شوند. تعداد کل نمونه‌های (حروف‌ها یا زیرکلمه‌ها) حاصل از همه کلمات تحت آزمایش و آموزش سیستم (کلمه ۳۲۰ کلمه) برابر ۱۸۰۵ نمونه است. شبکه عصبی با این بردارهای ویژگی، آموزش داده می‌شود و به عنوان سیستم شناسایی اولیه بکار می‌رود. حروفی که تفاوت آنها فقط در نقاط و سرکش‌ها می‌باشد مانند "ت" و "ب" یا "ک" و "گ" و "لام کوچک" (مثل لبه) در یک گروه قرار می‌گیرند. حال مرحله بعدی اضافه کردن اطلاعات مربوط به نقاط و سرکش‌ها به دسته‌بندی اولیه و جداسازی کامل حروف از یکدیگر است.



شکل ۱۳- زیرکلمه "کا" در کلمه "کاه" قابل تقطیع نیست

برای اضافه کردن نقاط به حروف، از میزان همپوشانی نقطه با حرف استفاده می‌شود. برای اضافه کردن سرکش‌ها به این نکته توجه می‌شود که آخرین پیکسل مربوط به سرکش، کمترین فاصله را با بالاترین پیکسل حرف مربوط به خود دارد.

جهت‌های غرب، شمال غربی و جنوب غربی می‌باشند مشخص می‌شوند. بدین ترتیب کانتور بالایی بدست می‌آید.



شکل ۱۱- کانتور بالایی کلمه "مگس"

حال برای هر بخش متصل در حین پیمایش کانتور بالایی، با استفاده از کد زنجیره‌ای، نقاطی که در آن‌ها یک روند کاهشی تبدیل به یک روند افزایشی می‌شود به عنوان کمینه‌های محلی کانتور بالایی ذخیره می‌شود. این نقاط به عنوان محل‌های اولیه تقطیع بکار می‌روند. برای جلوگیری از تقطیع زیادی مانند ایجاد برش در بین دندانه‌های حروفی مثل "س" و "ش" شرایط زیر بررسی می‌شود: فاصله مجاز بین دو تقطیع متواالی، فاصله مجاز محل تقطیع با شروع و پایان بخش متصل، حداقل پهنای مجاز خط در آن محل و شکل کانتور بالایی حروف. پس از تعیین قطعی محل‌های مجاز، برش در آن محل‌ها انجام می‌شود. میزان صحت تقطیع با این روش ۹۵٪ است.

موافق نجات

شکل ۱۲- نمونه‌هایی از نتایج تقطیع کلمات با استفاده از روش یافتن کمینه‌های محلی کانتور بالایی

۴-۵- یافتن ترتیب راست به چپ

برای یافتن ترتیب راست به چپ حروف (زیر کلمه‌ها)، از کلمه تقطیع شده فاقد سرکش‌ها و زیرکش‌ها و نقاط استفاده می‌شود. در این کلمه تقطیع شده، زیر کلمه‌ها بر اساس سمت راست‌ترین ستون آنها مرتب می‌شوند. بدین صورت ترتیب زیر کلمات مشخص می‌شود.

۴-۶- استخراج ویژگی

مهمترین عامل در شناسایی حروف، روش استخراج ویژگی است. در میان روش‌های استخراج ویژگی گوناگون مناسب‌ترین آن‌ها

نباشد، زیرکلمه‌هایی که حداقل اختلاف را با بردار ویژگی مورد نظر دارند در نظر می‌گیریم. سپس با استفاده از قوانین مناسب زیرکلمه‌ای که مناسب‌تر است، به عنوان نتیجه شناسایی مشخص می‌شود. این قوانین شامل شباهت‌های ظاهری زیرکلمه‌ها مانند کشیدگی، بلندی، میزان انحنا و حلقه‌های موجود در زیرکلمه است. عملکرد سیستم با این روش ۹۵٪ صحت در شناسایی زیرکلمه‌ها را نشان می‌دهد.

۴- الگوریتم جستجو

در این قسمت زیرکلمه‌های شناسایی شده توسط سیستم به ترتیب در یک بردار قرار داده می‌شود (معادل هر زیرکلمه یک عدد تعريف شده است). حال یک ماتریس که هر سطر آن شامل زیرکلمه‌های یک کلمه از لغت نامه سیستم می‌باشد، تهیه کرده، بردار خروجی سیستم با سطر به سطر این ماتریس مقایسه می‌شود. کلمه‌ای (سطری از ماتریس) از لغت نامه که حداقل خطای را نسبت به کلمه شناسایی شده توسط سیستم دارد به عنوان خروجی صحیح در نظر گرفته شده، بر اساس آن زیرکلمه‌هایی که اشتباهاً شناسایی شده‌اند اصلاح می‌شوند. میزان صحت شناسایی سیستم با استفاده از الگوریتم جستجو به ۹۷٪ افزایش می‌یابد.

۵- نتیجه گیری

با استفاده از مجموعه نمونه‌های آموزشی، سیستم برای شناسایی کلمات فارسی(نستعلیق) آموزش داده شد. سپس عملکرد آن بر روی مجموعه نمونه‌های آزمایشی ارزیابی شد. نتایج آزمایش مراحل مختلف سیستم شناسایی در جدول (۲) آورده شده است. بررسی نشان می‌دهد که الگوریتم جستجو با استفاده از دانش واژگانی افزایش نسبی خوبی در بازناسایی کلمه بوجود می‌آورد.

جدول ۲- نتایج آزمایش مراحل مختلف سیستم شناسایی

| | میزان صحت | ٪۱۰۰ | ٪۱۰۰ | ٪۹۵ |
|-------------------------------|-----------|------|------|-----|
| تقطیع | | | | |
| حذف زیرکش | | | | |
| شناسایی حروف بدون نقطه و سرکش | | | | |

| | میزان صحت | ٪۹۳ | ٪۹۵ | ٪۹۷ |
|-------------------------------|-----------|-----|-----|-----|
| الگوریتم جستجو | | | | |
| با نقطه و سرکش | | | | |
| شناسایی حروف بدون نقطه و سرکش | | | | |

اکنون با استفاده از دو روش می‌توان شناسایی حروف را کامل کرد. در روش اول یک بردار ویژگی جدید شامل موارد ذیل تشکیل داده می‌شود: هشت ویژگی استفاده شده در آموزش شبکه عصبی مرحله قبل، ویژگی‌های مربوط به تعداد نقاط هر حرف و موقعیت نقطه نسبت به حرف (بالاپایین)، وجود یا عدم وجود سرکش‌ها و کلاه الف، وجود یا عدم وجود دنباله "ت" و "ن" (چون در مرحله تقطیع در کمینه‌های محلی کانتور بالایی برش انجام می‌شود، وسط حروف بزرگی مثل "ت" و "ن" نیز برش داده می‌شود (شکل ۱۴)). به این ترتیب یک بردار ویژگی جدید شامل ۱۳ ویژگی تشکیل داده می‌شود. این بردار ویژگی پس از هنجارسازی طبق روش ذکر شده در بخش (۳-۴) به همراه خروجی‌های مورد انتظار، برای تعلم یک شبکه عصبی پرسپترون چند لایه جدید بکار می‌رود. آزمایش این روش میزان صحت تشخیص ۸۳٪ را نشان می‌دهد. این شبکه عصبی جدید نیز دارای ۱۳ نرون در لایه پنهان و تابع غیر خطی تانژانت هیپربولیک برای لایه‌های پنهان و خروجی و تابع آموزشی (Resilient back propagation) می‌باشد.

نجات شن

شکل ۱۴- تقطیع در وسط حروف "ن" و "ت"

در روش دوم براساس مشخصات حروف و مشاهده خروجی مربوط به شبکه عصبی اول، قوانینی بکار برده می‌شود که میزان صحت شناسایی سیستم را ارتقاء می‌دهد. این قوانین به همراه اطلاعات مناسب دیگر می‌توانند در تشخیص نهایی حروف به گونه‌ای بکار روند که خطاهای مربوط به خروجی شبکه عصبی اول نیز تا حد امکان اصلاح شود.

در اینجا بردار ویژگی شامل خروجی شبکه عصبی اول، تعداد نقاط و موقعیت آن‌ها نسبت به حرف، وجود یا عدم وجود کلاه الف و سرکش‌ها و دنباله حروف، چگونگی اتصال چپ و راست حروف و وجود یا عدم وجود حلقه کامل در حرف می‌باشد. سپس این بردار ویژگی را با بردار ویژگی تمام زیرکلمه‌ها (۸۴ زیرکلمه) مقایسه می‌کنیم. اگر بردار ویژگی مورد نظر با بردار ویژگی یکی از زیرکلمه‌ها کاملاً مشابه باشد، حرف مورد نظر شناسایی شده است. اما اگر بردار ویژگی مورد نظر با هیچ کدام از آن‌ها کاملاً مشابه

- 8- Normalization
- 9- Chain Code
- 10- Segmentation
- 11- Vertical Histogram

با سپاس از آقای دکتر پیمان ادبی، به خاطر هم‌فکری‌هایی که در پیشبرد این مقاله داشتند.

۵- تقدیر و تشکر

۶- مراجع

- [1] G.Nicchiotti, C.Scagliola; “A simple and effective cursive word segmentation method” hwr.nici.kun.nl/iwfhr-7-pp 499-503 2000
- [2] R. Safabakhsh, P.Adibi; “Nastaaligh handwritten word recognition using a continuous-density variable-duration HMM”, The Arabian Journal for Science and Engineering, Vol 30, No 1 B. April 2005
- [3] R.C.Gonzalez, R.E.Woods; “Digital Image Processing”, Prentice-Hall,Inc,pp,644-646,534-536,2004
- [4] C.Olivier, H.Miled; “Segmentation and Coding of Arabic Handwritten”, IEEE proc of 13 th Int .Conf. on Pattern Recognition , Vol.3 , pp.264-268,1996
- [5] C.Dunn, P.Wang; “Character Segmentation Techniques for Handwritten Text---A survey”, Proc. 11th Int'l Conf. Pattern Recognition, Vol. 2, p.577, Aug. 2001.
- [6] S. Tsujimoto, H. Asada; “Major Components of Complete Text reading System”, Proc. IEEE, Vol. 80, No. 7, pp. 1133-1149, July 1992.
- [7] M. Yamani, M. Noorzaily; “ Parking System Using Chain Code & A-Star Algorithm”, myais.fsktm.um.edu.my 2006
- [8] A.L.Betker1, T.Szturm2; “ Application of Feedforward Backpropagation Neural Network”, IEE ,2003
- [9] R. G. Casey, E. Lecolinet; “A Survey of Methods and Strategies in Character Segmentation” IEEE Trans. Pattern Anal.Mach. Intell., 18 (7) (1996), pp. 690–706.
- [10] S.Fritsch, F.Guenther; “The neuralnet package”, October 2008

۷- پی‌نوشت‌ها

- 1- Optical Character Recognition
- 2- Online
- 3- Offline
- 4- Classic Strategy
- 5- Recognition Based Strategy
- 6- Holistic Strategy
- 7- Target