

تشخیص متن چاپی فارسی با فونت ثابت با استفاده از شبه کلمات

محمدحسن شیرعلی شهرضا

کریم فائز

دانشجوی دوره دکترای برق، دانشگاه صنعتی امیرکبیر

چکیده:

در روش‌های معمول تشخیص متن، یا بد حروف هر کلمه جدا شده و سپس عمل تشخیص روی حروف مجزا انجام شود. استفاده از این روش در زبان فارسی مشکل است چون در زبان فارسی کلمات به صورت متصل نوشته می‌شوند و جدا کردن حروف یک کلمه بخصوص در مورد متون دست نویس به سادگی امکان پذیر نیست. در این مقاله روشی برای تشخیص متن با استفاده از «شبه کلمه» ارائه شده است. همه‌جنبین شبه کلمات مورد استفاده در زبان فارسی از نظر آماری بررسی شده و مشخص شده است که استفاده از روش تشخیص شبه کلمات عملآ امکان پذیر می‌باشد. مزیت عمده این روش سرعت زیاد آن می‌باشد، چون به جدا کردن حروف و سپس ترکیب حروف تشخیص داده شده نیازی ندارد. برای تشخیص شبه کلمات از روش تطبیق قالبها (Template matching) استفاده شده است. دقت تشخیص این روش ۹۶ درصد بوده و سرعت آن ۳ شبه کلمه (حدود ۵ حرف) در ثانیه می‌باشد.

لغات کلیدی: تشخیص الگو، تشخیص متن، تشخیص کلمات، تشخیص حروف عربی، تشخیص حروف فارسی.

Recognition of Fixed Font Printed Farsi Text Using Semi-Words

Karim Faez

M. H. Shirali-Shahreza

Associate prof., Amirkabir Univ.

Ph. D. Student, Amirkabir Univ.

Abstract:

In ordinary text recognition methods, characters of the text are first separated and then, the character recognition methods are applied on them. Since in Farsi texts, characters are connected to each other, separating the characters is a very difficult job. Therefore application of these methods will be very difficult and cumbersome, specially for handwritten texts.

This article introduces a new method for Farsi text recognition using "semi-words". Farsi semi-words are analyzed statistically and it is shown that appli-

cation of this method is much easier and faster than other methods. Finally, the accuracy and the speed of this method is compared with the other methods. The processing speed is 3 semi-words (5 characters) per second with a 96 percent recognition rate.

Key Words: Pattern recognition, Text recognition, Word recognition, Arabic/Farsi character recognition.

۱- مقدمه

[۱۳] اشاره کرد، ولی تا کنون سیستم تجاری برای خواندن اتوماتیک متون فارسی و عربی به بازار نیامده است. برای تشخیص حروف، در روش اول ابتدا حروف هر کلمه جدا شده و تشخیص، روی حروف جدا شده انجام می شود [۲][۹]. در روش دوم به جای تشخیص حروف، تشخیص کلمه انجام می شود و کل کلمه مورد تشخیص قرار می گیرد. اشکال روش اول برای حروف فارسی این است که جدا کردن حروف در زبان فارسی مشکل می باشد. روش دوم نیز به خاطر تعداد زیاد کلمات قابل پیاده کردن نیست مگر تعداد کلمات را به طریقی محدود کنیم. در این مقاله یک روش میانه که تشخیص با استفاده از «شبه کلمات» می باشد، پیشنهاد شده است. منظور از شبه کلمه، تعدادی حرف متصل به هم می باشد.

ساختار مقاله به صورت زیر است: در بخش ۲ ویژگیهای زبان فارسی از نقطه نظر تشخیص حروف بررسی شده است. در بخش ۳ شبه کلمه تعریف شده و نتایج آماری بررسی شبه کلمات در زبان فارسی ارائه شده است. در بخش ۴ نحوه ورود متن به کامپیوتر و پردازش‌های مقدماتی که روی آن انجام می شود، آمده است. در بخش ۵ روش استفاده شده برای تشخیص شبه کلمات توضیح داده شده و در بخش ۶ نتایج عملی و در بخش ۷ نتیجه گیری نهایی آمده است.

۲- ویژگیهای زبان فارسی از نظر تشخیص حروف
برای تشخیص حروف فارسی لازم است که ویژگیهای زبان فارسی را به خوبی شناخته و طراحی سیستم تشخیص حروف را متناسب با این ویژگیها انجام داد. ویژگیهای زبان فارسی از نقطه نظر تشخیص حروف در این بخش بیان می شود.

یکی از مسائل عمدۀ در کامپیوتر، وارد کردن اطلاعات (Data Entry) می باشد. از آنجا که عمدۀ اطلاعات ذخیره شده در کامپیوترها را اطلاعات نوشته شده (Text) تشکیل می دهد، برای وارد کردن این نوشته‌ها احتیاج به تایپ دوباره اطلاعات نوشته شده می باشد. برای اجتناب از تایپ مجدد متن‌های نوشته شده این ایده مطرح شد که کامپیوتر بتواند یک متن نوشته شده را به طور اتوماتیک خوانده و تشخیص دهد. البته کاربرد تشخیص حروف منحصر به وارد کردن یک متن به کامپیوتر نبوده و کاربردهای زیاد دیگری نیز دارد. یکی از کاربردهای عمدۀ تشخیص حروف در اداره پست برای تفکیک اتوماتیک نامه‌ها می باشد. همچنین با استفاده از تشخیص حروف در سیستم بانکی می توان عملیات مربوط به چک و دیگر اسناد بانکی را سریعتر انجام داد. در ضمن اگر خروجی تشخیص حروف به یک سیستم تبدیل متن به صوت یا یک سیستم تبدیل متن به خط بریل [۷] متصل شود می تواند به اشخاص نایین در خواندن کتاب و روزنامه کمک کند. استفاده دیگر تشخیص حروف در اتوماتیک کردن کارهای دفتری می باشد مثلاً می تواند در آرشیو کردن، ترجمه اتوماتیک و پاسخگویی اتوماتیک نامه‌ها استفاده شود.

گرچه بیش از ۳۰ سال از مطرح شدن ایده تشخیص حروف می گذرد [۱۲] هنوز این موضوع به عنوان موضوعی مهم مورد توجه متخصصین کامپیوتر بوده و تحقیق روی آن ادامه دارد. عمدۀ کارهای انجام شده در زمینه تشخیص حروف مربوط به زبان لاتین می باشد. نتیجه این تحقیقات به صورت سیستمهای تجاری که قادرند یک متن تایپ شده را بخوانند به بازار عرضه شده‌اند.

متأسفانه در زمینه تشخیص حروف فارسی و عربی خیلی کم کار شده است. اولین مقاله مربوط به تشخیص حروف چاپی فارسی در سال ۱۳۵۹ چاپ شده است [۱۴]. در مورد تشخیص حروف چاپی عربی می توان به مقالات [۸], [۹] و

مشکل دیگر نقطه این است که چون نقطه ها به یکدیگر می چسبند گاهی تشخیص بین دو نقطه یا سه نقطه امکان پذیر نیست.

۴-۲-علائم خاص

در زبان فارسی از علائم «تشدید»، «تنوین»، «همزه» و «مد» نیز استفاده می‌شود، گرچه بعضی از این علائم مختص زبان عربی می‌باشد ولی کمتر متن فارسی را می‌توان پیدا کرد که در آن این علائم موجود نباشد. این علائم روی حروف قرار می‌گیرند. مثالهایی برای این علائم، تشدید در کلمه «بچه»، تنوین در کلمه «حتماً»، مدد در کلمه «قرآن» و هم‌نوند کلمه «ئالا» می‌باشند.

علامت دیگر، علامت «یای کوتاه شده» یا «یای میانجی» («ء») می باشد که روی حرف «ه» قرار می گیرد مثلاً در عبارت «خانه دوست».

۲-۵۔ کشیدگی کلمات

در هنگام تایپ متن فارسی برای اینکه انتهای جملات در یک سنتون قرار گیرند، در کلمات آخر جمله از علامت «—» برای کشیده نوشتن کلمه استفاده می‌شود، که این علامت هیچ معنای خاصی نداشته و فقط برای زیبائی متن استفاده می‌شود. مانند کمله «باشد» که به صورت «باشد» نیز توشته می‌شود.

۲-۶. شکل‌های مختلف یک حرف

در زبان فارسی یک حرف می‌تواند تا چهار شکل مختلف داشته باشد. شکل هر حرف مناسب با محل قرار گرفتن آن حرف در کلمه می‌باشد. مثلاً حرف «عین» در اول کلمه به صورت «ع» در وسط کلمه به صورت «ع»، در آخر کلمه به صورت «ع» و در حالت منفرد به صورت «ع» نوشته می‌شود.

٢-٧- اعراب

در زبان فارسی صدایها موقع نوشتن کلمه نوشته نمی‌شوند ولی در محلهایی که احتمال اشتباه در موقع خواندن وجود دارد لازم است که برای بعضی از حروف، اعراب گذاشته شود. اعرابهایی که در زبان فارسی استفاده می‌شوند مشابه زبان عربی بوده و عبارتند از فتحه (ـ) ضمه (ـ) و کسره (ـ). اعراب در پالا و پایین حروف گذاشته شده و

۱-۲- نوشتن از راست به چپ

در زبان فارسی نوشتن از راست به چپ انجام می‌شود، برخلاف زبان انگلیسی که در آن از چپ به راست و یا در زبانهای دیگری که از بالا به پایین می‌نویسنند. بنابراین تشخیص حروف فارسی نیز باید از راست به چپ انجام شود تا عمل تصحیح نتایج به دست آمده یا تبدیل نتایج به دست آمده به صوت ساده‌تر باشد.

۲-۲ - مقصص بودن حروف

در زبان فارسی، حروف هنگام نوشتن به یکدیگر متصل می‌شوند برخلاف زبان انگلیسی که در آن حروف به صورت مجزا نوشته می‌شوند. البته حروف دست نویس انگلیس نیز به صورت متصل نوشته می‌شوند.

۳-۲- نقطه دار بودن بعضی حروف

در زبان فارسی، نقطه اهمیت زیادی داشته و ۵۰ درصد از حروف الفبای فارسی نقطه دارند. اهمیت نقطه از این نظر است که تعدادی از حروف فقط در تعداد یا محل نقاط با یکدیگر اختلاف دارند. جدول (۱) حروفی که فقط در تعداد یا محل نقاط با یکدیگر اختلاف دارند را نشان می‌دهد. چنانچه در این جدول دیده می‌شود، حروف می‌توانند بدون نقطه بوده یا یک تا سه نقطه داشته باشند.

اهمیت نقطه در زبان فارسی از این جهت بیشتر است که برای تبدیل یک فعل امر به فعل نهی حرف «ب» به حرف

جدول (۱)
حروفی که فقط در تعداد یا محل نقاط با یکدیگر اختلاف دارند

ب	ج	د	ه	ز	س	ش	ص	ط	ع	خ	غ	ذ	ث	ف
ت	ح	د	هـ	زـ	سـ	شـ	صـ	طـ	عـ	خـ	غـ	ذـ	ثـ	فـ

«ن» تبدیل می شود یعنی با تغییر جای یک نقطه یک جمله مشتبث به جمله منفی تبدیل می شود. مثلاً جمله «درس را بخوان» با جمله نهی آن یعنی «درس را نخوان» فقط در محابا، یک نقطه اختلاف دارند.

مشکل عملده نقطه در تشخیص حروف، این است که نقطه ممکن است با نویز موجود در تصویر یک متن اشتباه شود.

یک شبه کلمه می‌تواند خود یک کلمه مستقل باشد، مثل شبه کلمه «متنه» که یک کلمه کامل بوده و تمامی حروف آن به یکدیگر چسبیده‌اند، یا قسمی از یک کلمه باشد مثل شبه کلمه «کاً» در کلمه «کارخانه». چنانچه می‌دانیم الفبای فارسی از ۳۲ حررف تشکیل شده است. از نظر نگارش می‌توان این حروف را به دو دسته تقسیم کرد، دسته اول حروفی که موقع نوشتن می‌توانند به حرف بعد از خود متصل شوند و دسته دوم حروفی که نمی‌توانند به حرف بعد از خود متصل شوند و باید جدا نوشته شوند. چون در زبان فارسی حروف فقط خط زمینه به یکدیگر متصل می‌شوند، اگر انتهای حرفی روی خط زمینه قرار گیرد می‌توانند به حرف بعد از خودش متصل شود در غیراین صورت باید به صورت جدا نوشته شود، مثلاً حررف «ط» چون انتهای آن روی خط زمینه است به حرف بعد از خودش متصل می‌شود ولی حررف «و» نمی‌تواند به حرف بعد از خودش متصل شود. جدول (۲) الفبای فارسی از نظر نگارش را نشان می‌دهد.

جدول (۲)

الفبای زبان فارسی از نظر نگارش

حروف منفصله	حروف متصله
حروفی که به حرف بعد از خود متصل نمی‌شوند	حروفی که متصل نوشته می‌شوند

الف - ب - ت - س - ج - چ - ح
خ - س - ش - ص - ص - ط -
ظ - ع - غ - ف - ق - ک - گ -
د - م - ه - ه - ی -

۲- بررسی آماری شبه کلمات

برای بررسی امکان عملی بودن تشخیص متون فارسی با استفاده از شبه کلمات، مطالعه آماری روی ترجمه قرآن مجید به زبان فارسی [۱] انجام شد. نتایج این بررسی در جدول (۳) نشان داده شده است. در این جدول شبه کلمات بر اساس تعداد حروف موجود در آنها مرتب شده‌اند. با توجه به این نتایج می‌توان تعداد متوسط حروف یک شبه کلمه را به دست آورد. برای محاسبه تعداد متوسط حروف شبه کلمات از رابطه زیر استفاده شده است:

$$\bar{n} = \sum_{n=1}^6 n * p(n)$$

که n تعداد حروف موجود در شبه کلمه و $p(n)$ احتمال

خواندن صحیح آن را امکان پذیر می‌کند. جدا کردن اعراب از خود حروف در موقع تشخیص حروف کارآسانی نیست.

۸-۲- هم پوشانی حروف

در موقع حروفچینی یا تایپ متون فارسی، بعضی از حروف روی حرف قبلی قرار می‌گیرند مثلاً در هنگام چاپ کلمه «را» حررف «الف» روی حررف «ر» قرار می‌گیرد، این مسئله نیز کار تشخیص حروف فارسی را سخت تر می‌کند.

۹-۲- شکل خاص «لا»

در زبان فارسی به خاطر زیبایی متن هرگاه حروف «لام» و «الف» پشت سرهم قرار گیرند به صورت «لا» نوشته می‌شوند، این مسئله در هنگام مرتب کردن یا جستجوی یک متن فارسی توسط کامپیوتر، مشکل ایجاد می‌کند. در تشخیص حروف می‌توان شکل «لا» را به عنوان یک حرف مستقل در نظر گرفت.

۱۰-۲- اندازه متفاوت حروف

در زبان فارسی حروف از نظر اندازه یکسان نیستند، مثلاً حرف «ب» هنگام چاپ جای بیشتری از حررف «د» اشغال می‌کند. یکسان نبودن اندازه حروف به پیچیدگی تشخیص حروف فارسی کمک می‌کند.

۱۱-۲- نبودن فاصله بین کلمات

در زبان فارس برخلاف زبان انگلیسی که هر کلمه با کلمه بعد از آن به وسیله فاصله جدا می‌شود، بین کلمات فاصله وجود ندارد. به همین علت جدا کردن کلمات بدون توجه به تمامی جمله امکان پذیر نیست.

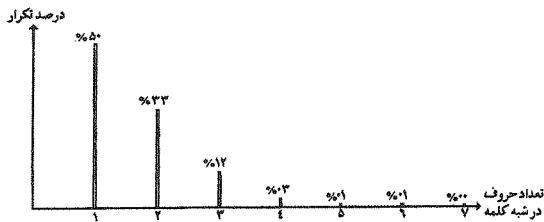
در تشخیص حروف، نبودن فاصله بین کلمات باعث می‌شود که عمل تصحیح متن تشخیص داده شده با استفاده از فرهنگ لغت، مشکل شود.

۱۳- شبه کلمه

۱۴- تعریف

در این مقاله برای تشخیص کلمات فارسی از قسمتهای متصل هر کلمه، که شبه کلمه می‌نامیم، استفاده شده است. در اینجا شبه کلمه را به صورت زیر تعریف می‌کنیم.

شبه کلمه = مجموعه‌ای از حروف الفبای فارسی گه به یکدیگر متصل باشند.



شکل (۱)

نمودار تکرار شبه کلمات در زبان فارسی

۴- پردازش‌های مقدماتی
برای آماده شدن یک متن اسکن شده جهت تشخیص حروف لازم است که یک سری پردازش‌های مقدماتی روی آن اعمال شود. در این بخش این پردازشها تشریح می‌شود.

۱- خواندن متن اسکن شده

یک متن یا تصویر بعد از اسکن شدن توسط دستگاه اسکنر باید تحت یک فرمت خاص روی دیسک ذخیره شود. برای ذخیره تصاویر، فرمتهای مختلفی وجود دارد، از بین این فرمتها، فرمت TIFF (Tag Image File Format) انتخاب شد. دلیل انتخاب فرمت TIFF قابلیت آن برای ذخیره سازی تصاویر بزرگ بود. مزیت دیگر فرمت TIFF این است که اطلاعات زیادی در مورد تصویر دارد.

فرمت TIFF به دو صورت تصاویر را ذخیره می‌کند، حالت معمولی و حالت فشرده، که به علت سادگی کار حالت معمولی TIFF انتخاب شد.

۲- جدا کردن خطوط متن

یک متن در زبان فارسی به صورت خط به خط و از راست به چپ نوشته می‌شود و معمولاً خطوط متواالی با فاصله از هم جدا می‌شوند. برای جدا کردن خطوط یک متن از نمای افقی جدا می‌شوند. برای جدا کردن دهنده فاصله بین خطوط می‌باشد. البته به علت وجود نویز در تصویر اسکن شده، ممکن است فاصله بین دو خط کاملاً سفید نباشد، برای حل این مشکل می‌توان با توجه به کیفیت متن حدی برای سفید بودن یک سطر از متن تعیین کرد و اگر نمای افقی آن سطر از آن حد کمتر بود، آن سطر را سفید در نظر گرفت. شکل (۲) نحوه جدا کردن خطوط متن با توجه به فاصله بین خطوط را نشان می‌دهد. البته در موقع جدا کردن خطوط متن باید توجه

وقوع آن می‌باشد. (n) p، با استفاده از رابطه زیر به دست آمده است:

$$p(n) = \frac{\text{تعداد شبے کلمات } n \text{ حرفی}}{\text{تعداد کل شبے کلمات}}$$

با قرار دادن نتایج جدول (۳) در روابط فوق خواهیم داشت:

$$\bar{n} = 1/75 = 1/0.0 + 2x/0.33 + 3x/0.12 + 4x/0.03 + 5x/0.01 + 6x/0.001$$

یعنی در زبان فارسی به طور متوسط ۱/۷۵ حرف در یک شبے کلمه وجود دارد و این کوچک بودن شبے کلمات، یکی از دلایل استفاده از شبے کلمات در تشخیص حروف است. دلیل دیگر مشکل بودن جداسازی حروف می‌باشد.

با توجه به نتایج به دست آمده (شکل ۱) حدود ۵۰٪ از شبے کلمات یک متن را شبے کلمات یک حرفی تشکیل می‌دهند. پس اگر سیستم تشخیص حروف فقط قادر به تشخیص شبے کلمات یک حرفی باشد می‌تواند ۵۰٪ از شبے کلمات متن را بخواند. اگر شبے کلمات ۲ و ۳ حرفی را نیز اضافه کنیم یعنی سیستم تشخیص حروف بتواند شبے کلمات یک، دو و سه حرفی را تشخیص دهد ۹۵٪ از شبے کلمات یک متن را تشخیص داده است.

اگر برای شبے کلمات ۴، ۵، ۶ و ۷ حرفی فقط شبے کلمات پُراستفاده را انتخاب کنیم دقت تشخیص به ۹۸٪ می‌رسد. برای ۲٪ باقیمانده می‌توان از روش جدا کردن حروف شبے کلمه استفاده کرد.

جدول (۳)

شمارش شبے کلمات در ترجمه قرآن مجید به زبان فارسی

نوع شبے کلمه	تعداد	میزان تکرار	احتمال وقوع
۱ حرفی	۳۰	۱۴۳۷۰.۵	۰/۵۰
۲ حرفی	۳۲۶	۹۵۰۷۸	۰/۲۳
۳ حرفی	۹۶۷	۲۴۵۵۶	۰/۱۲
۴ حرفی	۷۷۱	۸۵۹۳	۰/۰۳
۵ حرفی	۳۷۲	۲۶۴۳	۰/۰۱
۶ حرفی	۱۲۸	۵۴۳	۰/۰۱
۷ حرفی	۲۵	۸۲	۰/۰۰
جمع	۲۶۱۹	۲۸۰۵۰۰	۱/۰۰

داشت که نقطه حروف جدا نشود، چون بین نقاط هر حرف و خود حرف نیز فاصله خالی وجود دارد. به دو خط فرضی که یک سطر از متن را جدا می‌کنند کرسی بالا و کرسی پایین می‌گویند [۵].

خوب و عزیزی

کرسی بالا

کرسی پایین

ایران زیبا

کرسی بالا

کرسی پایین

شکل (۲)

روش جدا کردن خطوط متن



شکل (۲)

روش جدا کردن شبه کلمات

۵- تشخیص شبه کلمات

بعد از جدا کردن شبه کلمات، مهمترین قسمت کار یعنی تشخیص شبه کلمه انجام می‌گیرد. عمل تشخیص در دو مرحله انجام می‌شود در مرحله اول تشخیص مقدماتی شبه کلمه با توجه به تعدادی ویژگی خاص انجام شده و در مرحله دوم تشخیص نهایی با استفاده از روش تطبیق قالبها صورت می‌گیرد.

۱- تشخیص مقدماتی شبه کلمات

در تشخیص حروف با استفاده از شبه کلمات، تعداد شبه کلمات زیاد می‌باشد (بیش از هزار شبه کلمه) به همین دلیل تطبیق یک شبه کلمه ورودی با تک تک شبه کلمات موجود در سیستم تشخیص حروف وقت‌گیر می‌باشد. بنابراین به جای مقایسه شبه کلمه ورودی با تمامی شبه کلمات از روش طبقه‌بندی چند سطحی استفاده شده است.

در طبقه‌بندی چند سطحی [۱۰] (Multilevel Classification)، طبقه‌بندی با توجه به تعدادی ویژگی و در چندین مرحله انجام می‌شود. در مرحله اول با توجه به چند ویژگی، کلاس‌های مورد نظر به چند گروه تقسیم می‌شوند. در مراحل بعد این گروه‌ها با توجه به ویژگی‌های دیگری به گروه‌های کوچکتر تقسیم خواهند شد.

در این طرح اولین ویژگی استفاده شده برای تشخیص شبه کلمات، ابعاد شبه کلمه می‌باشد. یعنی با توجه به عرض شبه کلمات، آنها به ۱۶ گروه تقسیم شده‌اند. مثلاً شبه کلماتی که عرض آنها بین یک تا هشت نقطه باشد در گروه

البته در اینجا فرض شده است که خطوط متن، مستقیم و موازی با یکدیگر بوده و به صورت افقی نوشته شده باشند. اگر خطوط متن این شرایط را نداشته باشند باید به روش‌های پیچیده‌تری خطوط متن را جدا کرد.

۳-۴- پیدا کردن خط زمینه

در زبان فارسی، خط زمینه اهمیت دارد چون حروف فقط روی خط زمینه به یکدیگر متصل می‌شوند و به کمک خط زمینه می‌توان حروف به هم چسبیده را جدا کرد. همچنین از این خط می‌توان در تشخیص حروف از یکدیگر نیز کمک گرفت مثلاً حرف «د» روی خط زمینه واقع می‌شود در صورتی که حرف «ر» پایین خط زمینه واقع می‌شود. برای پیدا کردن خط زمینه از نمای افقی استفاده شده است. در این روش تعداد نقاط سیاه هر سطر از تصویر شمرده شده و سط्रی که تعداد نقاط سیاه آن حداقل باشد به عنوان خط زمینه انتخاب می‌شود. شکل (۳) خط زمینه را نشان می‌دهد.

پایینده باشی - خط زمینه

شکل (۳)

خط زمینه

انجام می‌گیرد. برای انجام عمل تشخیص از روش تطبیق الگوها [۱۱] (template Matching) استفاده شده است. در این روش الگوی ورودی با الگوهای مرجع تطبیق داده شده والگوی ورودی به الگوی که بهترین تطبیق (Best match) را با ورودی داشته باشد، طبقه بندی می‌شود.

برای تشخیص شبه کلمات، شبه کلمه ورودی را با شبه کلمات موجود در سیستم که در مرحله تشخیص مقدماتی مشخص شده اند. تطبیق داده و میزان مشابهت ورودی با شبه کلمات مرجع اندازه‌گیری می‌شود. الگوی ورودی به الگوی مرجعی که حداکثر تشابه را با آن دارد نسبت داده می‌شود. در واقع طبقه بندی به روش نزدیکترین همسایه (Nearest Neighbour) صورت می‌گیرد.

روش تطبیق الگوها، یکی از روش‌های اولیه [۱۲] برای تشخیص حروف می‌باشد. این روش برای تشخیص اعداد دست نویس استفاده شده [۱۱] و نتایج به دست آمده در مقایسه با سایر روش‌های تشخیص اعداد رضایت بخش بوده است [۱۵]. معایب عمدۀ روش تطبیق الگوها عبارتند از:

- ۱- نیاز به حافظه زیاد، چون در این روش لازم است که تمامی الگوهای مرجع در سیستم ذخیره شوند.
- ۲- حساس بودن به اندازه حروف، البته این مشکل را می‌توان با مقایس کردن شکل‌های ورودی حل کرد [۱۱].

از مزایای این روش، حذف مرحله استخراج ویژگی و سادگی طراحی می‌باشد. همچنین، یادگیری در این روش ساده می‌باشد. یعنی می‌توان الگوهای جدیدی را به راحتی به سیستم اضافه کرده یا الگوهایی که متناسب نیستند را حذف کرد.

در روش‌های دیگر تشخیص حروف ابتدا یکسری ویژگی استخراج شده و سپس تشخیص با توجه به آن ویژگیها انجام می‌شود. مثلاً در مرجع [۴] از گشتاورهای زرنیکی برای تشخیص اعداد فارسی استفاده شده است. در آن مرجع از شبکه عصبی برای طبقه بندی اعداد استفاده شده است. مشکل روش فوق این است که به تعداد زیادی نمونه از هر کلاس برای یادگیری شبکه عصبی نیاز بوده و به علت زیاد بودن تعداد کلاسها، یادگیری شبکه فوق العاده طولانی است. در مقاله حاضر چون تشخیص متن با فونت ثابت، مورد نظر بوده است مشکل حساس بودن روش تطبیق الگوها

یک قرارداده شده‌اند. البته برای اینکه احتمال طبقه بندی غلط (Misclassification) از بین بود، برای هر شبه کلمه علاوه بر گروهی که شبه کلمه در آن واقع می‌شود، دو گروه همسایه آن گروه نیز در نظر گرفته می‌شوند. مثلاً اگر شبه کلمه ورودی در گروه ۳ واقع شود، در مراحل بعدی با شبه کلمات گروه‌های ۲، ۳ و ۴ مقایسه می‌شود. اگر اندازه حروف استفاده شده در چاپ متن برای تمام حروف یکسان باشد (مثلاً در تایپ کامپیوتری که حروف در یک ماتریس 8×14 نقطه‌ای چاپ می‌شوند)، طبقه بندی بر اساس ابعاد شبه کلمه باعث جدا شدن شبه کلمات بر اساس تعداد حروف موجود در شبه کلمه می‌شود یعنی شبه کلمات، یک حرفی در یک گروه و شبه کلمات دو حرفی در یک گروه جای می‌گیرند و به این ترتیب شبه کلمات موجود در هر گروه دارای تعداد حروف یکسانی هستند. در مورد متون چاپی معمولی، ابعاد شبه کلمه به طور تقریبی تعداد حروف آن شبه کلمه را مشخص می‌کند. مثلاً شبه کلمات موجود در گروه ۲ معمولاً یک یا دو حرفی می‌باشد.

در مرحله دوم با توجه به تعداد اجزای هر شبه کلمه، آنها را طبقه بندی می‌کنیم.

جدول (۴) نحوه طبقه بندی چند شبه کلمه با توجه به تعداد اجزاء را نشان می‌دهد. این اجزاء شامل بدنه اصلی و نقاط و علائم می‌باشد.

جدول (۴)

طبقه بندی شبه کلمات با توجه به تعداد اجزای آنها

نام اجزای	بدنه اصلی	علائم	نقاط	بند	شیوه	جیز	لکت	بند	لک										
برو	برو	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل	مل

اگر عرض شبه کلمه بیشتر از ۱۲۸ نقطه (تقریباً ۱ سانتیمتر) یا تعداد اجزای آن بیش از ۷ جزء بود، شبه کلمه توسط این روش تشخیص داده نشده و کنار گذاشته می‌شود (Rejection). این شبه کلمات را باید توسط روش‌های دیگر مثلاً روش جدا کردن حروف تشخیص داد.

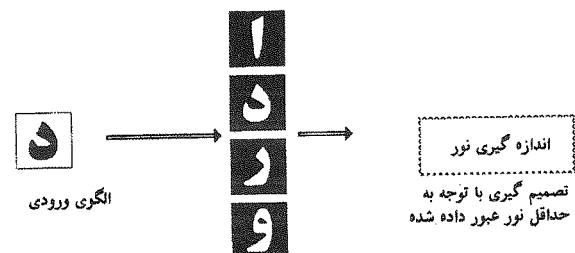
۲- تشخیص نهایی شبه کلمات
بعد از تشخیص مقدماتی، تشخیص نهایی شبه کلمه

به اندازه حروف وجود ندارد. همچنین از هر شبکه کلمه فقط یک شکل به عنوان الگوی مرجع در سیستم نگهداری شده است. برای تطبیق شبه کلمات از معیار فاصله ژاکارد (Jaccard) استفاده شده است [۱۱].
معیار ژاکارد به صورت زیر محاسبه می‌شود.

$$J = \frac{N_{11}}{N_{11} + N_{10} + N_{01}}$$

که در این رابطه N_{ij} نشان دهنده تعداد نقاطی است که در الگوی ورودی مقدار i داشته و در الگوی مرجع مقدار j داشته‌اند. این معیار، برای هر الگوی مقداری بین صفر تا یک دارد. برای بازناسی الگوی ورودی، ابتدا نزدیکترین همسایه به الگوی ورودی یعنی الگوی مرجع که معیار ژاکارد آن از بقیه الگوهای بیشتر است انتخاب می‌شود. اگر این معیار از حدی کمتر بود، الگوی ورودی کنار گذاشته می‌شود (Rejection).

روش تطبیق الگوهای معادل این است که شکل الگوهای مرجع را روی صفحه شفافی به صورت منفی چاپ کرده و این صفحه را روی الگوی ورودی قرار داده و میزان نوری که از تصویر ورودی منطبق شده با تصویر مرجع عبور می‌کند اندازه گیری شده و الگویی که حداقل نور را داشته باشد، به عنوان شکل الگوی ورودی تشخیص داده شود. در شکل (۵) این روش نشان داده شده است. [۱۲]



شکل (۵)
روش تطبیق الگوهای موجود در سیستم

۳- سرعت و دقیقت در تشخیص حروف
دو عامل عمده باعث شده‌اند که در تشخیص متن از روشهای پیشنهادی تشخیص حروف استفاده نشود. این دو عامل دقیقت کم و سرعت پایین روشهای تشخیص حروف می‌باشند. منظور از دقیقت در تشخیص این است که سیستم چند

در صد حروف را به درستی تشخیص می‌دهد. مثلاً اگر سیستم از هر ۱۰۰ حرف، ۹۸ حرف را درست تشخیص دهد، و دو حرف را تشخیص ندهد یا اینکه اشتباه تشخیص دهد، می‌گویند دقیقت سیستم ۹۸٪ است. مشکل تشخیص حروف این است که به دقیقت خیلی زیادی نیاز دارد، حتی دقیقت ۹۹٪ نیز قابل قبول نیست چون اگر سیستم فقط یک ذر صد از حروف را اشتباه تشخیص دهد، تعداد اشتباهات در یک صفحه از متن (اگر متن را ۲۴ سطری و هر سطر را ۷۵ حرفی در نظر بگیریم) ۱۸ حرف می‌باشد، که این تعداد اشتباه در یک صفحه خیلی زیاد است. البته دقیقت اکثر سیستمهای تشخیص حروف از ۹۵٪ نیز کمتر است. در مورد زبان عربی دقیقه‌ای گزارش شده از ۹۰٪ [۶] تا ۹۸٪ [۱۳] می‌باشد. در مورد زبان فارسی دقیقت گزارش شده برای جدا کردن حروف یک کلمه ۹۹٪ [۲] می‌باشد.

مسئله دیگر در تشخیص حروف سرعت سیستم می‌باشد، یعنی سیستم در هر دقیقه قادر به تشخیص چند حرف می‌باشد. سرعت خواندن یک انسان که در خواندن ضعیف بوده و مجبور به هجا کردن حروف در هنگام خواندن باشد حداقل ۱۵۰ کلمه در دقیقه می‌باشد (البته افراد ماهر قادرند تا ۱۰۰۰ کلمه را در یک دقیقه بخوانند). [۳]، پس سیستم تشخیص حروف باید لاقل سرعتی حدود ۱۵۰ کلمه در دقیقه داشته باشد. اگر به طور متوسط کلمات را ۴ حرفی فرض کنیم سرعت مورد نظر ۶۰۰ حرف در دقیقه یا ۱۰ حرف در ثانیه می‌باشد. سرعتهای گزارش شده در مورد تشخیص حروف چاپی عربی ۳۰ کلمه در دقیقه [۸] و ۴ حرف در ثانیه [۱۳] می‌باشد.

البته اگر زمان مورد نیاز برای وارد کردن متن به سیستم (مثلاً اسکن کردن متن) و زمان مورد نیاز برای ذخیره کردن یا چاپ نتایج به دست آمده نیز در نظر گرفته شوند سرعت این روشها به مراتب کمتر می‌باشد. مزیت عمله تشخیص حروف با استفاده از تشخیص شبکه کلمات به جای شکستن کلمات به حروف، بالا رفتن سرعت تشخیص می‌باشد چون در زمان مورد نیاز برای شکستن کلمات و سپس ترکیب حروف تشخیص داده شده صرفه‌جویی می‌شود.

۶- نتایج عملی

برنامه‌های مورد نیاز برای تشخیص حروف به روش تشخیص شبکه کلمات به زبان ۵ نوشته شده و روی یک کامپیوتر PC مدل ۴۸۶ اجرا شد، سپس برنامه‌های نوشته

به دست آمده در این تحقیق برای شبه کلمات بوده در صورتی که در نتایج قبلی [۹] و [۱۳] دقت گزارش شده مربوط به حروف می باشد. بدیهی است از آنجا که غلط بودن یک حرف در یک شبه کلمه باعث غلط شدن کل آن شبه کلمه می گردد، لذا دقت به دست آمده در این تحقیق از دقاهای گزارش شده قبلی بیشتر است.

سرعت به دست آمده برای تشخیص، ۳ شبه کلمه در ثانیه می باشد که با در نظر گرفتن تعداد متوسط ۱/۷۵ حرف برای هر شبه کلمه حدود ۵ حرف در ثانیه می باشد که سرعت مناسبی برای تشخیص حروف است.

شده روی قسمتی از کتاب داستان راستان [۶] امتحان شد. شکل (۶) یکی از متهای استفاده شده را نشان می دهد. دقت به دست آمده ۹۶٪ می باشد. یعنی این سیستم توانست ۹۶٪ از شبه کلمات را به درستی تشخیص دهد. از ۴٪ شبه کلمات باقیمانده ۲٪ اشتباه تشخیص داده شدند (Misclassification) و ۲٪ دیگر تشخیص داده نشدن (Rejection). علت اکثر اشتباهات در تشخیص نقطه های حروف می باشد، مثلاً «یا» و «با» با یکدیگر اشتباه می شوند. دلیل عدم تشخیص بعضی از شبه کلمات وجود اعراب روی آنها بوده است. باید توجه داشت که دقت

عرق کار

امام کاظم ، در زمینی که متعلق به شخص خودش بود ، مشغول کار و اصلاح زمین بود. فعالیت زیاد، عرق امام را از تمام بدنش جاری ساخته بود. علی بن ابی حمزه بطانی، در آین وقت رسید و عرض کرد: « قربانت گردم، چرا این کار را به عهده دیگران نمی گذاری؟ »
 - « چرا به عهده دیگران بگذارم ؟ افراد از من بهتر همواره از این کارها می گردند. »
 - « مثلاً چه کسانی ؟ »
 - « رسول خدا و امیر المؤمنین و همه پدران و اجدادم. اساساً کار و فعالیت در زمین از سنین پیغمبران و اوصیای پیغمبران و بندها شایسته خداوند است. »

شکل (۶)

نمونه ای از متن استفاده شده برای آزمایش سیستم [۶]

۷- نتیجه گیری:

معیار تشابه ژاکارد انجام شده است. در این مقاله نشان داده شد که استفاده از روش ارائه شده برای تشخیص متون فارسی با فوント ثابت مناسب است. در حالتی که متن شامل چندین فوント مختلف باشد یا در مورد متون دست نویس لازم است که قبل از تشخیص، شبه کلمات را مقیاس کرد.

در این مقاله تشخیص متون چاپی فارسی با استفاده از شبه کلمات انجام شده است. همچنین شبه کلمات از نظر آماری بررسی شده اند. طبقه بندی شبه کلمات در دو قسمت انجام شده است. در قسمت اول با استفاده از اندازه و تعداد اجزای هر شبه کلمه تشخیص مقدماتی داده شده و در قسمت بعد تشخیص نهایی به روش تطبیق الگوها و با استفاده از

منابع:

- [۱] آیتی، عبدالحمد- ترجمه قرآن مجید، انتشارات سروش، ۱۳۷۱ تهران.
- [۲] احمدزاده، محمدرضا-کبیر، احسان‌الله، «شکستن کلمات تایپ شده فارسی به حروف» گزارش اولین کنفرانس بین‌المللی کامپیوتر در علوم، فنون و پژوهشی در ایران، دانشگاه اصفهان، ۵ تا ۷ دیماه ۱۳۷۰، صفحات ۱ الی ۶.
- [۳] باطنی، محمدرضا-مسائل زبانشناسی نوین، انتشارات آگاه، تهران، چاپ سوم ۱۳۷۰.
- [۴] ختن‌زاد، علیرضا-شیرعلی شهرضا، محمدحسن، «تشخیص اعداد چاپی فارسی مستقل از اندازه و جایگایی با استفاده از گشتاورهای زرینیکی و به کمک شبکه‌های عصبی»، مجموعه مقالات کنفرانس مهندسی برق ایران، تهران-دانشگاه تربیت مدرس، ۳۰ الی ۴۲۴ اردیبهشت ۱۳۷۳، جلد ۵، صفحات ۴۱۷ الی ۴۲۴.
- [۵] فضائلی، حسیب‌اله-تعلیم خط، انتشارات سروش، چاپ ششم، ۱۳۷۰.
- [۶] مطهری، مرتضی-دانستان راستان، جلد اول، چاپ پانزدهم، انتشارات صدر-۱۳۷۰.
- [۷] نعیمی، محمود جعفری تزاد، «خودآموز دستگاه بریل برای معلولین بصری»، گزارش سمینار طراحی و کاربرد ریزپردازندۀ‌ها، دانشگاه صنعتی امیرکبیر، تهران، دوم الی چهارم خرداد ۱۳۶۸، صفحات ۱ الی ۱۴.
- [۸] H. Y. Abdelazim and M. A. Hashish, «Arabic typeset: an OCR approach," In Proceedings of EUSIPCO-90, Fifth European Signal Processing Conference, Vol. 2, pp.1019-1022, 1990.