



فرامرز هنروران^۱

او. سی. آر

وکاربردهای آن در کتابخانه‌ها و مراکز اطلاع‌رسانی

OCR

متخصصان سخت‌افزاری و نرم‌افزاری کامپیوتر و دستگاههای جانبی آن به فکر تهیه دستگاه‌ها و برنامه‌هایی باشند تا نیاز به صفحه کلید کامپیوتر را برای ورود اطلاعاتی که قبلاً بر روی کاغذ نقش بسته برطرف سازد. به غیر از عوامل برشمرده شده دو دلیل دیگر وجود و توسعه چنین برنامه‌هایی را تقویت می‌کند: (۱) حجم اطلاعاتی که بر روی کاغذ از زمان اختراع چاپ تاکنون درج شده نسبت به اطلاعاتی که بر روی حافظه‌های ثانویه کامپیوتر (دیسک و دیسکت، نوار مغناطیسی...) موجود است از میزان بسیار بالاتری برخوردار است و اگر قصد ورود تمامی این اطلاعات به کمک کاربران باشد انجامش به سالها وقت و تعداد بی‌شماری کامپیوتر نیاز داشته و هزینه فراوانی می‌طلبد؛ (۲) اشتباهاتی که توسط کاربر در هنگام ورود اطلاعات رخ می‌دهد در بیشتر موارد به ۸ درصد یا بالاتر می‌رسد و زمانی که جهت رفع این اغلاط تلف می‌شود بسیار زیاد است. وجود مسائل بالا منجر به تولید و تکمیل دستگاههای گوناگون پویشگر^۳ و نرم‌افزارهای مختلف شناسائی بصری و هوشمند حروف گردیده است. پویشگر وسیله‌ای است که یک صفحه چاپی - چه متنی و چه تصویری، یا ترکیبی از هر دو - را پویش می‌کند. طریقه عمل بدین صورت است که ابتدا نوری به صفحه چاپی از طریق یک منبع نوری (که برحسب نوع پویشگر به صورت خط به خط یا صفحه به صفحه است) تابانیده شده و نور منعکس شده از صفحه به طرف آرایه‌ای از دیودهای نوری^۴ هدایت می‌شود. این نور پس از برخورد با این دیودها نوسانات الکتریکی تولید می‌کند که منطبق با نقاط سیاه (یا رنگی) و زمینه کاغذ که تشکیل دهنده متن و یا تصویرند، می‌باشد این نوسانات به صورت قیاسی^۵ به کمک مدارات الکترونیکی پویشگر تقویت شده و تبدیل به اطلاعات رقمی^۶ که به صورت آرایه‌ای از اطلاعات دودویی و یا نقشه بیتی^۷ در آمده و به حافظه RAM^۸ (حافظه با دسترسی دلخواه) یا حافظه ثانویه کامپیوتر منتقل می‌گردد و در این مرحله است که کار نرم‌افزار او سی آر شروع می‌شود. این نرم‌افزارها نقشه بیتی تولید شده توسط پویشگر را خوانده و در حین فرایندی خاص قسمتهای سفید یا خالی صفحه پویش شده را مشخص می‌کند تا بدین طریق قادر شود محل خطوط متن و تصاویر احتمالی موجود را برای ادامه کار

چند سالی از بحث کتابخانه‌های بدون کتاب و اداره‌های بدون کاغذ^۹ می‌گذرد ولی با نگاهی اجمالی به وضعیت فعلی در دنیا به سادگی می‌توان متقاعد شد که هنوز راهی طولانی برای رسیدن به این مهم به طور نسبتاً آرمانی باقی مانده است. کاغذ به سبب سهولت استفاده و سندیتهش هنوز یکی از محمل‌های اصلی اطلاعات به شمار می‌رود. ولی حجم زیاد، عمر محدود، کندی بازیابی و انتقال آنچه بر این محمل نقش بسته استفاده از آن را در عصری که دستیابی و انتقال هر چه سریعتر اطلاعات را عامل تعیین کننده کرده است، چه در زمینه درج اطلاعات جدید و چه تکثیر اطلاعات قدیمی روزبه روز غیراقتصادی‌تر می‌سازد، از جهت دیگر تولید آن را با توجه به محدود بودن منابع گیاهی و وارد آوردن خسارات جبران‌ناپذیر به محیط‌زیست، هر روز به نقطه‌ای بحرانی‌تر نزدیک می‌سازد. مجموع این عوامل باعث شده که طی بیست و چند سال گذشته

OCR

در مرحله ماقبل آخر که در بعضی نرم افزارهای اوسی آر وجود دارد با کمک یک برنامه غلطیاب املائی، کلمات استخراج شده، بررسی شده و اغلاط احتمالی در موقع شناسایی کاراکترهای هر کلمه بدینوسیله تصحیح می شود. در پایان نرم افزار اوسی آر تمامی کاراکترهای مدرک را به صورت فایل متنی اسکی^{۱۶} یعنی به شکلی که در کامپیوتر قابل استفاده است تبدیل کرده و در این حال است که می توان متن را به نرم افزارهای واژه پرداز یا نرم افزارهای بانک اطلاعاتی متنی داد یا آن را به هر محل دیگر از طریق کامپیوتر منتقل کرد، تمام



مراحل بالا بسته به نوع مدرک و نوع نرم افزار و سخت افزار به کار رفته از یک تا چند دقیقه وقت می برد که در مقایسه با انجام این کار با کمک کاربر در اکثر موارد از سرعتی ۱۰ تا ۳۰ درصد بالاتر برخوردار است، و ذکر این نکته نیز خالی از فایده نیست که بر حسب تجربیاتی که انجام گرفته مشخص شده که هزینه پیدا کردن و تصحیح یک حرف (البته در الفبای لاتین) حدود ده هزار برابر هزینه تصحیح یک حرف رد شده بدلیل ناخوانا بودن یا غیرقابل تشخیص بودن از طرف نرم افزار اوسی آر است و همچنین تجربیات مشخص ساخته که استفاده از اوسی آر حدود ۵۰ درصد در هزینه ها صرفه جویی می کند.

اوسی آر در کتابخانه ها و مراکز اطلاع رسانی

کتابخانه ها و مراکز اطلاع رسانی از جمله مؤسساتی هستند که تهیه اطلاعات و انتقال آن اصلی ترین عامل وجودیشان بوده و هر چه در این امور سریعتر عمل کنند به هدفشان نزدیکتر می شوند. در کتابخانه های کنونی بویژه

خود تعیین کند. در مرحله اول تبدیل تصویر به متن، این نرم افزار سعی می کند تا با مقابله نقطه به نقطه^{۱۷} تصویر صفحه پویش شده سند با مجموعه کاراکترهای تعریف شده که نرم افزار اوسی آر به حافظه RAM کامپیوتر سپرده است کاراکترهای کاملاً مشابه را شناسایی کرده و از تصویر استخراج نماید. این مجموعه کاراکترهای تعریف شده شامل تمامی فونتهای پرکاربرد (فونت^{۱۸} مجموعه ای است از حروف چاپی در اندازه، شکل و سبک مشخص تشکیل شده از حروف بزرگ و کوچک، اعداد و علائم مختلف) الفبای لاتین (یونانی یا سریلیک) است. بدین سبب که در این مرحله از شناسایی حروف انطباق کامل لازم است اگر چگونگی تصویر پویش شده از لحاظ کیفیت پایین باشد این روش چندان کارآمد نبوده و باید از روش دیگری بهره برد که در مرحله بعدی موجب شناسایی کاراکترهای شناخته نشده در مرحله اول می شود. این روش وقت گیر به نام استخراج ویژگی^{۱۱} یا تحلیل ویژگی^{۱۲} یکی از روشهایی است که علاوه بر نرم افزارهای اوسی آر در نرم افزارهای ICR^{۱۳} (نرم افزارهایی برای استخراج حروف از متون خطی یا چاپ شده با فونتهای غیراستاندارد) نیز کاربرد وسیعی دارد. در این روش ابعاد، نسبت ابعاد حواشی، تعداد گوشه ها و لبه های هر کاراکتر مورد تجزیه و تحلیل قرار گرفته و تشابه آن با کاراکترهای تعریف شده سنجیده می شود، به عبارت دیگر، در این روش ارتفاع هر کاراکتر نسبت به خط کرسی محاسبه شده و هر کاراکتر به صورت ترکیبی از خطوط مستقیم و منحنی های باز و بسته در مقایسه با یکایک کاراکترهای تعریف شده مورد تجزیه و تحلیل قرار می گیرد تا از نتایج این تجزیه و تحلیل کاراکتر شناسایی شود. در مرحله سوم به دلیل آن که دو مرحله قبل امکان شناسایی تمامی کاراکترهای متن را نمی دهد، نرم افزار به دو روش (بسته به نوع نرم افزار) برای کشف کاراکترهای ناشناخته کمک می طلبد، یا علائمی همچون @ یا # را جایگزین کاراکترهای ناشناخته می کند و به کاربر اعلام می دارد که خود این علائم را پیدا کرده و کاراکتر مناسب را جایگزین این علائم سازد و یا: هر کاراکتر ناشناخته را بر روی صفحه نمایش کامپیوتر^{۱۴} مشخص کرده و از کاربر می خواهد تا کلید مربوط به این کاراکتر را بر روی صفحه کلید^{۱۵} کامپیوتر فشار دهد تا به جای کاراکتر مجهول کاراکتر صحیح جانشین شود.

OCR



به کار مشغول است دست به انتخاب یکی از این نرم افزارها زده یا کلاً با مزایا و معایب هر یک از آنها آشنا شود. این نرم افزارها عبارتند از:

۱. Omnipage Professional 5.0 از شرکت Caere
۲. Recognita Plus 2.0 International از شرکت Recognita
۳. TextBridge 2.0 از شرکت Xerox Imaging Systems
۴. WordScan Plus از شرکت Calera Recognition Systems

این مقایسه ها از چندین جنبه توسط هوارد اگلوشتاین^{۱۸} صورت گرفته و در مجله بایت مورخ اکتبر ۱۹۹۴ درج گردیده که پرداختن به تمامی آنها از حوصله این مقاله خارج است و تنها به ذکر نکات اساسی این مقایسه پرداخته می شود.

دو عامل اساسی در مقایسه نرم افزارهای اوسی آر صحت انجام کار و زمان نسبی انجام کار این نرم افزارهاست. صحت انجام کار اوسی آر عبارت است از حاصل تقسیم تعداد حروفی که به طور صحیح شناسایی شده بر تعداد کل حروف در یک سند بر حسب درصد. نتایج حاصل از مقایسه صحت کار این نرم افزارها در جدول ۱ مشخص است، که حاصل اوسی آر ۳۰ صفحه ۴ است.

زمان نسبی انجام کار نرم افزارهای اوسی آر یا به بیان دیگر سرعت انجام کار، عبارت است از حاصل تقسیم تعداد کلی حروفی که به طور صحیح اوسی آر شده به زمانی که صرف شناسایی حروف کل سند می شود. کلاً در نرم افزارهای اوسی آر صحت از سرعت مهم تر است. در این مقایسه نرم افزار TextBridge از سرعت بالا و صحت معقولی برخوردار بوده و OmniPage و WordScan از صحت بالا برخوردار بوده و Recognita سریع بوده ولی خطای زیاد داشته است. مزایای دیگری که یک نرم افزار اوسی آر می تواند داشته باشد عبارتند از:

۱. راحتی کارکردن با نرم افزار؛
۲. قابلیت کار با دستگاههای مختلف پوششگر؛
۳. تشخیص فونت های مختلف؛
۴. قابلیت شناسایی حروف زبانهای مختلف؛
۵. قیمت مناسب.

که از میان این نرم افزارها، TextBridge راحت ترین کاربرد

کتابخانه های کشورهای در حال توسعه همه چیز یا لااقل ۹۸ درصد اطلاعات موجود بر کاغذ نقش بسته است. از فهرست برگه تا یکایک نامه های بخش های مختلف یک کتابخانه - همان گونه که گفته شد - از مهمترین قابلیت یعنی امکان دستیابی و انتقال سریع بی بهره اند علاوه بر آن امکان جستجو، تصحیح، تجزیه و تحلیل آماری در آنها تنها به روش دستی امکان پذیر است. اما با استفاده از روش اوسی آر تمامی این اطلاعات در زمانی کوتاه و با هزینه ای پایین نسبت به روشهای دیگر خواهند توانست از تمامی قابلیت های ذکر شده بهره مند گردند. به طور مثال برای ارائه متن مقالات مجلات و روزنامه ها، دیگر نیازی به جستجو در میان صدها برگه در برگه دانه ها یا جستجو در میان صدها تصویر میکروفیلم، نخواهند بود. زیرا با استخراج متن این مقالات توسط اوسی آر و دادن این اطلاعات به برنامه های بانک اطلاعات متنی، به راحتی می توان به هر مقاله دست یافت و آن را به کمک خطوط مخابراتی به هر نقطه ای فرستاد؛ و صدها مورد استفاده دیگر که بسته به نوع کتابخانه و میزان وسعت آن متفاوت است.

معرفی چهار برنامه مشهور اوسی آر و مقایسه آنها با هم

حال که در مورد مزایای روش اوسی آر و کاربردهای آن در حوزه کتابداری و اطلاع رسانی بحث شد، به معرفی و مقایسه چهار برنامه اوسی آر که تحت برنامه ویندوز مایکروسافت^{۱۷} کار می کند، پرداخته می شود تا بتوان در ضمن این مقایسه با توجه به نیازهای کتابخانه یا مؤسسه ای که در آن

جدول ۱. مقایسه صحت کار اوسی آر در چهار نرم افزار*

	Omnipage	Recognita	TextBridge	Wordscan
سند تهیه شده توسط چاپگر چرخ خورشیدی	٪۹۹/۳	٪۹۷/۰	٪۹۹/۳	٪۹۸/۹
سند تهیه شده توسط چاپگر جوهرافشان لیزری	٪۹۹/۳	٪۹۶/۲	٪۹۸/۷	٪۹۹/۰
متن کپی شده *	٪۸۸/۹	٪۹۲/۳	٪۹۶/۴	٪۹۵/۳
متن فاکس شده **	٪۹۸/۸	٪۸۷/۴	٪۷۸/۱	٪۹۸/۰

* عدم صحت ۱ درصد بدان معنی است که در هر ۱۰۰ حرف یک حرف اشتباه شناسایی شده است.
 ** متن اصلی این دو مورد به توسط چاپگر لیزری با وضوح بالا تهیه شده است.

مجلات کامپیوتری داخلی گاه و بیگاه خبرهایی هر چند کوتاه و نیمه موثق در انجام این تلاش به اطلاع علاقه‌مندان و متخصصان می‌رسد که امید است این تلاشها به ثمر برسد و بزودی شاهد نرم‌افزاری مناسب برای خط فارسی باشیم.

مآخذ

1. Schantz, Herbert F. "Using OCR: Three Crucial Variables". in: Inform, 6 (June 1992) PP. 20-22.
2. Kahama, Paz Y. "Forms Removal: Saving Storage Space, improving OCR Performance". ibd. PP 12-18.
3. Longley, Denis & Shain, Michael, Dictionary of information technology. London: Macmillan, 1989.
4. Encyclopedia of Computer Science and Engineering. New York: Van Nostrand Reinhold Co. 1983.
5. Eglowstein, Howard, "Due Recognition for OCR" in: Byte, October 1994. PP. 145-148.

یادداشتها:

۱. کارشناس ارشد کتابداری و اطلاع‌رسانی دانشکده روانشناسی و علوم تربیتی دانشگاه تهران.

- 1- Optical Character Recognition (OCR)
- 2- Paperless Office
- 3- Scanner
- 4- Photodiodes' Matrix
- 5- Analog
- 6- Digital
- 7- Bitmap
- 8- Random Access Memory
- 9- Pixel by Pixel
- 10- Font
- 11- Feature Extraction
- 12- Featur analysis
- 13- Intelligent Character Recognition
- 14- Monitor
- 15- Keyboard
- 16- ASCII (American Standard Code for Information Interchange)
- 17- MS Windows
- 18- Howard Eglowatein

و کمترین قیمت را داشته و Recognita از بیشترین قابلیت در شناسایی حروف زبانهای اروپایی یا نوشته شده با خط لاتین و یونانی برخوردار بوده (حدود ۸۰ زبان) و در ضمن قابلیت کار بایش از ۱۰۰ نوع دستگاه پویسگر را دارد (این نتایج باتوجه به داده‌های جدول ۱ حاصل شده است).

لزوم وجود اوسسی آر برای زبان فارسی

با وجود آن که سالها از ورود کامپیوتر به ایران می‌گذرد و ایران به روایت مجلات مختلف کامپیوتری در سال ۱۹۹۴ یکی از واردکنندگان عمده تجهیزات سخت‌افزاری و دستگاههای جانبی کامپیوتر در خاورمیانه بوده و از لحاظ نیروی متخصص در زمینه نرم‌افزار و سخت‌افزار در رده‌های بالایی در منطقه برخوردار است، متأسفانه هنوز هیچ مؤسسه و شرکتی چه خصوصی و چه وابسته به دولت اقدامی در جهت طراحی و تولید یک برنامه حروفه‌ای اوسسی آر فارسی خوان نکرده است. شاید یکی از دلایل آن آشنا نبودن بسیاری از افراد با کاربردهای اوسسی آر و عوایدی است که از کار با آن حاصل می‌شود. البته نباید ناگفته گذارد که بر سر راه تهیه یک نرم‌افزار اوسسی آر مناسب و کارآمد برای خط فارسی مشکلات عدیده وجود دارد که عمده آن به سبب شکل خاص خط فارسی و زیاد بودن حروف این زبان، و (البته این مشکل تنها محدود به خط فارسی با عربی نیست، بلکه خط زبانهای دیگر همچون چینی و ژاپنی با مشکلی بسیار عظیم‌تر در این خصوص رو به رو بوده‌اند و توانسته‌اند این مشکل را به طریقی حل کنند) همچنین نبود پشتیبانی مالی از طرف مؤسسات دولتی و خصوصی است. با این وجود، از طریق

