



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتابل جامع علوم انسانی

طرح پاییگاه متون زبان و ادب فارسی

آنها و عدم امکان گردآوری تمامی آنها حتی در کتابخانه‌های بزرگ، سبب شده است که کتابخانه‌ای را در این سرزمین پنهان‌وار نتوان سراغ کرد که تمامی این آثار را در خود جای داده باشد. پراکنده‌گی این آثار در کتابخانه‌های مختلف اعم از خصوصی و عمومی و بزرگ و کوچک مانع بزرگی برسر راه پژوهش محققان، دانشجویان و دانش آموختگان ماست و وقت بسیاری را ایشان به هدر می‌دهد. اکنون، در آغاز قرن بیست و یکم، با پیشرفت تکنولوژی این امکان فراهم آمده است که کتابخانه‌ای بزرگ را بتوان در حجمی بسیار اندک به اندازه یک کف دست جای داد و در کوتاه‌ترین زمان و بادقتی به کمال، به جست و جو در آنها پرداخت

متون زبان و ادب فارسی حاصل کوششهای طاقت فرسا، شور و شوق و نبوغ دانشمندان، فرهیختگان و ادبیان ایران بزرگ، در طول قرون، به عنوان میراثی گرانبهایه مارسیده است. میراثی که به تصدیق همگان به لحاظ غنا و عظمت و عمق و وسعت در ادبیات جهان بی نظیر است و سهم ایران و ایرانی را در پیشرفت علم، تمدن، فرهنگ و انسانیت ممتاز گردانیده است. این میراث عظیم چنانکه باید و شاید در دسترس فارسی‌زبانان و علاقه‌مندان این فرهنگ غنی، نیست. بسیاری از آنها با همت و کوشش محققان ارجمند در سده اخیر چاپ و منتشر شده و بسیاری دیگر هنوز در انتظار چاپ است. تنوع و فراوانی آثار چاپ شده و تولید و توزیع اندک شمار



مند که به مناسبتی نزدیک به هشت سال پیش سرگرم شروع شد، نتیجه این پروژه تحلیل متن فارسی بود، به پیشنهادیکی از دوستان، طراحی این سایت اینه که متون زبان و ادب فارسی را با هدف تحلیل متن پیگیری کرد و چون اجرای طرح هزینه سنگینی داشت، کار از مرحله طراحی و تهیه نرم افزار یا به عبارت بهتر تکمیل همان نرم افزار تحلیل متن یادشده، فراتر نرفت تا اینکه در سال ۱۳۷۷ گروه فرهنگ نویسی فرهنگستان زبان و ادب فارسی برای تهیه فرهنگ جامع زبان فارسی ایجاد چنین پایگاهی را در دستور کار خود قرار داد و با حداقل دو سال بحث و بررسی به نتایج مطلوبی رسید اما متأسفانه در مرحله اجرا به دلایل اداری، کار متوقف شد.

و فهرستها و گزارش‌های گونه گون و مورد نیاز را در اختیار اهل تحقیق و مطالعه قرارداد. کاری که دیگران پیش از ما به انجام رسانیده‌اند، از سایتهاي اینترنتی متعددی که در اروپا و امریکا ایجاد شده، بگذریم، پایگاه متون میراث مکتب عربی با پیش از یک میلیون صفحه متن، به نام "الوراق" مدتی است که مورد استفاده پژوهشگران آشنا به رایانه است. دیدن این پایگاه بزرگ متون در شبکه اینترنت^۱ که آثار عربی بسیاری از دانشمندان ایرانی همچون طبری، بیرونی، رازی، ابن سینا و... رانیز در خود جای داده از سویی مایه سرور و شادمانی است و از سویی دیگر مایه تأسف که چرا چنین پایگاهی از متون فارسی تاکنون فراهم نشده است.

پس از گذشت یک سال و متفق شدن اقدام فرهنگستان در این خصوص، نگارنده در سال ۱۳۸۰ طرح ایجاد پایگاه متون را به شورای گسترش زبان و ادب فارسی وزارت فرهنگ و ارشاد اسلامی عرضه نمود. نظر موافق مدیر محترم شورای گسترش و پیگیری جلدی ایشان خوشبختانه به نتیجه رسید و در پی موافقت وزیر محترم فرهنگ و ارشاد اسلامی و تصویب طرح، کار از تیر ماه ۱۳۸۱ به سفارش شورای گسترش زبان و ادب فارسی آغاز شد.

بنابر طرح مصوب قرار است که تمامی کتابهای چاپ شده به زبان فارسی -در هر زمانه و موضوعی- که تاریخ تألیف آنها پیش از ۱۳۰۰ هجری شمسی باشد،^۲ در این پایگاه وارد شود، اما به دلیل زیاد بودن حجم اطلاعاتی که باید وارد نرم افزار شود (بیش از پانصد هزار صفحه)، ورود اطلاعات در چندین مرحله و به صورت دوره‌ای یا فرقن به قرن انجام می‌شود و کتابهای انتخاب می‌شوند که در دسترس هستند و فعلاً در این مرحله برای جست و جوی کتابهای مشمول طرح که احیاناً در کشورهای دیگر چاپ شده‌اند و از آنها اطلاعی در دست نیست اقدامی نخواهد شد.

با توجه به موارد مذکور و نیز برای طراحی، تولید و آزمایش نرم افزار مورد نظر و رفع اشکالات احتمالی آن، در مرحله نخست تها کتابهایی که تاییمه قرن پنجم هجری قمری تألیف شده‌اند، انتخاب شد که بالغ بر ۲۰۰۰ صفحه می‌شود. این حجم برای آزمایش نرم افزار و نیز روش شدن جزئیات، مناسب به نظر می‌رسید. انتخاب این کتابها (بهترین چاپ) با توجه به نظر استادان زبان و ادب فارسی (مشاوران طرح) صورت گرفته است. فهرست این کتابها در پایان خواهد آمد.

اکنون که مرحله نخست طرح رو به اتمام است گزارشی از کار انجام شده و ویژگیهای نرم افزار تولیدشده جهت آگاهی و اظهار نظر پژوهشگران و دوستداران زبان و ادب فارسی تقدیم می‌شود؛ این پایگاه که علاوه بر استفاده عام، برای استفاده پژوهشگران زبان فارسی، ادبیات، تاریخ و دیگر رشته‌های علوم انسانی ایجاد خواهد شد می‌باشد در نهایت امر، پژوهش در زمینه‌های گوناگون فرهنگی به ویژه حوزه‌های زبان‌شناسی، دستور زبان، تاریخ زبان‌فارسی، سیک‌شناسی، نقد ادبی، فرهنگ‌نویسی (به ویژه فرهنگ تاریخی زبان فارسی)، آموزش زبان، واژه‌گزینی و تحقیقات ادبی را به نحو قابل توجهی تسهیل کند و ضریب اطمینان تحلیلها و استنتاجها را حتی المقدور افزایش دهد. بنابراین، نرم افزار موردنظر به گونه‌ای طراحی شده است که علاوه بر امکان استفاده عمومی از آن، قابل استفاده پژوهشگران باشد. برای تأمین این منظور موارد زیر مورد توجه بوده است:

۱. ورود اطلاعات: در مرحله ورود اطلاعات، در متن هیچ گونه

تغییری داده نشده است. حتی غلطهای چاپی به همان صورت باقی مانده‌اند. شماره صفحات نیز مطابق با متن اصلی است و تنها متن کتابها تایپ شده‌اند و زیرنویسها، نسخه‌بدلها، مقدمه مصحح و ... تایپ نشده‌اند. این تصمیم ضمن اینکه برای صرفه جویی در وقت گرفته شده، به دلیل محدودیت در حروف یا به اصطلاح کاراکترهای موجود در نرم افزار بوده است. مثلاً برای ۷ با دو نقطه، بـ که بالای آن نیز نقطه داشته باز که زیر آن نقطه داشته باشد، سـ با سه نقطه در زیر آن و ... کاراکتری موجود نیست و اگر برنامه نویسان طراحی هم بکنند از نظر مرتب کردن کلمات (یعنی تعیین جای این نشانه‌های جدید در جدول کاراکترها برای سورتینگ) و تهیه فهرستهای موردنظر از حوزه واژگان متن، برنامه مختلف خواهد شد. البته در آینده اگر این مشکلات برطرف شود امکان افزودن بخشهای حخلف شده وجود خواهد داشت.

برای هر کتاب شناسنامه‌ای ایجاد شده که اطلاعات زیر را در بر دارد: نام کتاب، موضوع، نویسنده، مترجم، مصحح، تاریخ تألیف، محل تألیف، نوع اثر (نظم، نثر، داستانی، علمی و ...)، محل چاپ، ناشر و تاریخ چاپ که در نهایت می‌توان این اطلاعات را جست و جو کرد و نیز فهرستهای لازم از آن تهیه نمود.

۲. اطمینان از صحبت اطلاعات وارد شده: اطمینان از درستی و صحبت متنی که در نرم افزار مورد استفاده قرار می‌گیرد اهمیت بسیار زیادی دارد. ویژگی عمدۀ و امتیاز این نرم افزار نسبت به کتاب و کتابخانه‌های معهود، در جست و جوی اینها آسان و سریعی است که می‌توان در آن انجام داد و نیز در گزارشها و فهرستهای متنوعی که می‌توان از متون تهیه کرد؛ بنابراین اگر اطمینانی به صحبت متن وجود نداشته باشد، صحبت گزارشها و نتیجه جست و جوها نیز مخدوش بوده و عملاً نرم افزار پایگاه متون به کاری نخواهد آمد. برای تأمین این منظور، از هر کتاب دو نسخه تهیه شد و نسخه‌ها جداگانه به دو گروه تایپیست و اگذارشده که آنها را در محیط واژه‌پرداز موردنظر با دستور العمل ویژه‌ای تایپ نمایند. پس از ورود اطلاعات، دو متن تایپ شده در رایانه، وارد محیط نرم افزاری شد که برای مقابله این دو متن تهیه شده است؛ به عبارت دیگر نمونه خوانی ماشینی صورت گرفته است. نرم افزار موردنظر موارد اختلاف دو متن را تعیین می‌کرد و کارشناس زبان و ادبیات فارسی با استفاده از کتاب، شکل غلط را حذف و عبارت درست را ایقا می‌کرد یا کلمات و عبارات زاید را حذف و احیاناً کلمات و عبارات جاافتاده را تایپ می‌کرد. در این تایپ حجم اطلاعات وارد شده دو متن تایپ شده و شماره صفحات باهم و متن اصلی مطابقت داده شد و اگر در متون تایپ شده، افتادگی در حد پارagraf و صفحه بود، تشخیص داده شد. پس از ویرایش و آماده سازی متن، مرحله‌ای دیگر برای تصحیح اطلاعات در نظر گرفته شده است، به

این ترتیب که متن آماده ورود در نرم افزار نهایی، ابتداء در نرم افزاری وارد می شود که برای جلوگیری از ورود کلماتی که در زبان وجود ندارد، تهیه شده است. کارشناس در این مرحله هر کلمه را فقط یک کلمه می کند و آن کلمه وارد بانک کلمات نرم افزار می شود. پس از آن در موارد مشابه، نرم افزار آن کلمه را درست و در حوزه واژگان زبان فارسی تشخیص می دهد و وارد پایگاه متون می کند. به این ترتیب کلماتی که در زبان وجود ندارد و احیاناً هر دو تاییست مانند هم تایپ کرده اند و طبعاً نمونه خوانی ماشینی هم در این موارد بقایه است، تصحیح می شود.

یک بار هم به وسیله نرم افزار، متن تبدیل به فهرست کلماتی می شود که بسامد آنها جلوی آنها درج شده است، کلماتی که یک یا دویار و سهبار در متن به کار رفته اند بازبینی می شوند، زیرا کلماتی که **مسائل اندک** کی دارند احتمال اینکه غلط باشد بیشتر است. متن تصحیح شده که باید همانند کتاب اصلی باشد در نرم افزار ذخیره می شود.

مرحله ای دیگر برای تصحیح وجود دارد که بعداً ذکر خواهد شد:

۳. از کتاب ذخیره شده در نرم افزار، یک نمونه چاپی تهیه و **جزای ویرایش و آماده سازی** متن به کارشناسان زبان و ادب فارسی **پیشنهاد** می شود.

ویرایش و آماده سازی متن شامل موارد زیر است:

۱. **تصحیح غلطهای چاپی و غیر چاپی** (به ویژه با استفاده از پادداشت‌های کارشناسان مرحله ۶ و مقالات **نقد** متون موردنظر که تا زمان اجرای این طرح به چاپ رسیده، گردآوری و کارشناسی شده است).

غلطهای غیر چاپی که شامل بدخوانی و تشخیص نادرست مصحح و... می شود با حفظ هر دو عبارت اصلی (غلط) و تصحیح ناقد (شکل صحیح) و با تأیید استادان مشاور طرح، جای یکی در متن و دیگری در حاشیه تعیین می شود.

۲. **تنظیم فاصله ها** (در این برنامه، رایانه هر حرف یا مجموعه حروف را که بین آنها فاصله نباشد یک کلمه تشخیص می دهد. یعنی دو طرف هر کلمه باید یک فاصله داشته باشد). بنابر این باید این کار بادقت و حوصله انجام شود.

اجزایی از کلمه که به لحاظ نحوی مستقل اند مانند: ضمایر متصل، یا نکره، الف ندا و... (پی چسبها) که توسط کارشناسان کدگذاری شده اند (← بند ۶)، در نرم افزار قابل شناسایی اند و طبعاً قابل جست و جو و....

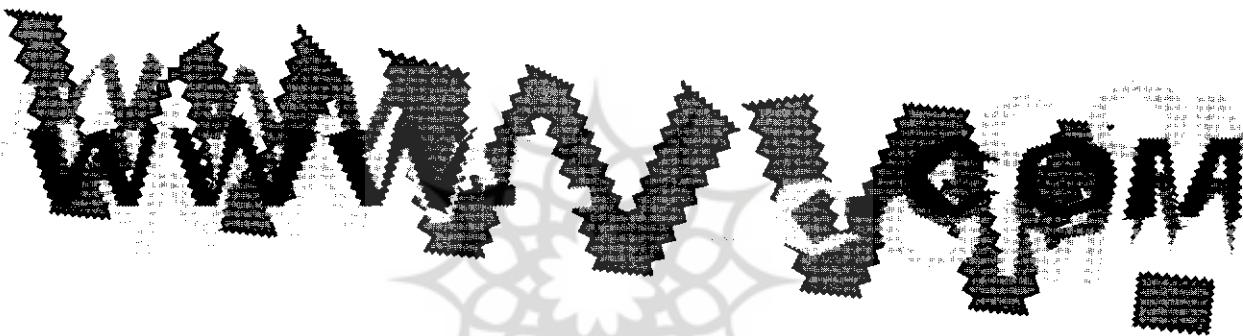
۳. **نشانه گذاری**: نقطه، نشانه پرسش، دو نقطه، نشانه تعجب و.... این کار عملاً یعنی تعیین جملات و بعد تعیین هویت جملات در نتیجه تسهیل جست و جو و فهرست گیریهای گونه گون. در

خانه‌ای و خانه‌یی انتخاب و به ترتیب جایگزین خانه‌ثی و خانه‌شده. یا کلماتی از قبیل درین، برین، ازین، دران، ازان، به شکل کامل آن و با فاصله: در این، بر این، از این، در آن، از آن تبدیل شد که حتی اگر در شعر هم باشد خللی ایجاد نخواهد کرد. این تغییر ضمناً مانع از بذخوانی و نیز تسهیل در جست و جو خواهد شد. مثلاً برین به معنی نبرین یا برین به معنی زوی این یکی نمی‌شود. پس از انجام این موارد روی کاغذ و اعمال اصلاحات در فایلهای ذخیره شده، یک نمونه چاپی دیگر از متن نهایی تهیه می‌شود و در اختیار گروه بازیسینی نهایی قرار می‌گیرد.^۵ سپس اصلاحات نهایی در متون ذخیره شده اعمال می‌شود و متنها برای اعمال کدگذاری (بند^۶) وارد نرم افزار می‌شوند. (همه اصلاحات موارد پنجمگانه در کپی فایلهای اصلی اعمال می‌شود و نسخه‌ای از فایلهای اصلی برابر با اصل کتابها جداگانه ذخیره و نگهداری می‌شود تا در صورت لزوم دسترسی به فایلهای اصلی ممکن باشد).

این صورت مقادیر خواهیم بود تمام جملات پرسشی و... را زمان انتخاب کنیم، به دلخواه مرتب کنیم و در آنها به جست و جو پردازیم. دو نقطه (:) نشانه گفت و گو است و با تعیین آن می‌توان فقط در گفت و گوهای یک متن به جست و جو پرداخت یا از آنها فهرستهایی به دلخواه تهیه کرد.

(در متون منظوم و نیز منشور، بیت یک واحد به شمار می‌آید و نیز مصراع، البته اگر تک بود) و جملات داخل آن با نقطه تعیین نمی‌شود، ولی نشانه‌های پرسش، تعجب، امر، گفت و گو ... را خواهد داشت.)

۴. حرکت گذاری کلمات در متن فارسی: به منظور ایجاد امکان جست و جوی دقیق و نیز امکان فهرست گیری و ایجاد تمایز بین کلمات مشابه در املا و متفاوت در تلفظ و معنا، این کلمات حرکت گذاری می‌شوند. کلماتی مانند: بُرد، کند که چهار گونه خوانده می‌شوند، یا کلماتی مانند: بین، شوید، جو، حکم، خرد، درد که سه گونه خوانده می‌شوند،^۷ در صورتی که بدون حرکت



۶. کدگذاری کلمات و عبارات به منظور ایجاد محیط مناسب در متون برای جست و جوهای تخصصی پژوهشگران و استادان و نیز تهیه بانکهای مورد نیاز ارشاد مختلف کاربران:
۱ - ۶. تعیین عبارات عربی (آیات قرآنی، احادیث، سخنان بزرگان، امثال و حکم، مصراع، شعر)
۲ - ۶. تعیین عبارات غیر فارسی و عربی "زبانها و لهجه‌ها"
۳ - ۶. تعیین عبارات فارسی: مصراع و شعر در متون نثر، ترجمه آیات قرآنی، ترجمه احادیث، سخنان بزرگان، امثال و حکم، هر کدام با کد جداگانه.

۴ - ۶. کدگذاری یای نکره، الف ندا و ضمایر منفصل و متصل (منظور از ضمیر متصل در این طرح، هر ضمیری است که به کلمه‌ای چسبیده باشد مانند: ۰ و در کو = (که او)، این کار برای تسهیل و دقت هر چه بیشتر در جست و جو و تهیه آمار و ازگانی و... انجام شده است).

۵ - ۶. کدگذاری فعل. تمام فعلهای هر متن روی کاغذ کدگذاری شده است. پس از ورود اطلاعات (متون) بانکی از افعال کلیه متون موجود در نرم افزار، تهیه می‌شود. در این بانک افعال که قاعدتاً به تدریج کامل تر می‌شود و شامل تمام ساختهای افعال اعم از زمانی و غیر زمانی خواهد شد، ساختهای گونه گون هر فعل ذیل مصدر خود را قرار می‌گیرد و در جست و جو نیز به آن مربوط می‌شود، مثلاً اگر کاربر رفتن را در یک متن جست و جو کند، تمام

ثبت شوند، با توجه به حجم بسیار زیاد متون (بالغ بر پانصد هزار صفحه)، عملکار جست و جو و فهرست گیریها بی فایده می‌شود. رفع مشکلات جست و جو برای کاربری که در مورد کلمات مشابه حضور ذهن ندارد نیز در نرم افزار پیش‌بینی شده است بدین صورت که هر گاه کاربر کلمه‌ای را برای جست و جو و گزارش گیری تعیین کرد، اگر آن کلمه مشابه داشته باشد، کلمات مشابه با حرکتها لازم در صفحه نمایشگر ظاهر می‌شود تا کاربر بتواند فقط کلمه مورد نظر یا همه کلمات یا هر تعداد از آنها را که خواست به دلخواه انتخاب نماید تا از نرم افزار گزارش صحیح و دلخواه خود را دریافت کند.^۸

۵. تصحیح رسم الخط و یکدست سازی در موارد خاص برای تسهیل در امر جست و جو. رسم الخط متون کهن فارسی در نسخه‌های چاپی نیز بسیار متفاوت است. این تفاوتها تاجیکی که در کار جست و جو خللی ایجاد نکند ایرادی ندارد و ضروری است که به جهت حفظ اصالت متن حتی الیکان حفظ شود، اما در این متون خانه‌ای را به صورت خانه‌یی، خانه‌ثی و خانه نیز نوشته‌اند، برای جست و جوی این کلمه باید چهار بار جست و جو انتخاب شود. فهرست گیرید یا هر چهار گونه برای جست و جو انتخاب شود. این صورت حاصل جست و جو نیز بی جهت طولانی خواهد شد و به خصوص اگر موردی باشد که گونه‌ها از نظر ترتیب الفبا ای تفاوت فاحش داشته باشند، بررسی گزارش دشوار خواهد شد. در مورد مذکور برای حفظ اصالت متن (نا حد ممکن)، با توجه به تلفظ، دو گونه

بر عکس) که کاربردهای بسیاری خواهد داشت مثلاً انتخاب پرسامدترین واژگان در زبان فارسی بار عایت مسائل مربوط، برای تأثیف کتابهای آموزش زبان فارسی به کودکان، نوجوانان، کم سوادان، غیر فارسی زبانان و نیز تعیین مدخلهای فرهنگی یک زبانه یادوزبانه برای گروههای یادشده.

۲. امکان شمارش کل کلمات هر متن یا همه متون انتخابی و شمارش کلمات (با حذف بسامد آنها) برای تعیین حوزه کمی واژگان هر متن و درنهایت واژگان زبان فارسی در هر دوره بازآغاز تا ۱۳۰۰ هجری به منظور تحلیل و بررسیهای زبانی و... مثلاً تعیین تفاوت دو کتاب در نسبت حوزه واژگان (بدون بسامد) به کل واژگان متن و بررسی تفاوت‌های دیگری که می‌توان آنها را ناشی از این تفاوت تلقی کرد.

۳. امکان مشاهده، کپی و تهیه پرینت از بیت یا جمله‌ای که واژه مورد جست و جو در آن به کار رفته با درج شماره صفحه و نام متن یا کدی که برای آن در نظر گرفته شده است.

۴. امکان مرتب‌سازی بیتها یا جمله‌های حاوی واژه مورد جست و جو به طرق مختلف و مورد نیاز پژوهشگر، مثلاً مرتب‌سازی به ترتیب تاریخ تأثیف متون از قدیم به جدید و بر عکس، الفبایی، نظم یا نثر بودن شواهد و...

۵. امکان وصل شدن از جمله در فهرست جمله‌ها (بند ۴) به همان جمله در متن اصلی و ادامه جست و جو.

۶. امکان انتخاب یک واژه از درون متن اصلی برای مشاهده موارد دیگر کاربرد آن (ادامه جست و جو) در همان متن و دیگر متون انتخابی کاربر.

۷. امکان جست و جو براساس ساخت پایه مصدر برای فعلها که از این طریق مثلاً می‌توان دریافت که در متن مورد نظر چه ساختهایی از یک مصدر وجود دارد و بررسی تحولات ساختهای در تاریخ زبان فارسی؛ و مهم تراز آن در اختیار داشتن شواهد برای هر مصدر که عموماً به شکل فعل در جمله به کار می‌رود و تسهیل و تسریع در کار فرهنگ نویسی.

۸. امکان تبدیل متن به ابیات و جملات متواالی (هر جمله از ابتدای سطر آغاز شود) و امکان مرتب کردن این جملات یا ابیات به صورت الفبایی بنابر آغاز جمله یا بیت و پایان جمله^۸ یا بیت. این امکان در مورد ابیات کاربرد خیلی روشنی دارد؛ با ترتیب الفبایی به سادگی ابیات مشابه در متون مختلف را می‌توان کنار هم دید و تاریخ اولین بار ثبت بیت در متون را دریافت و احیاناً نسبتهای مشکوک را تشخیص داد و به گوینده واقعی بیت رسید. از سوی دیگر تفاوت‌های ضبط بیت در متون مختلف و یافتن قدیم ترین کاربرد آن در تصحیح متون (نسخه‌های خطی) نیز مفید خواهد بود و می‌توان تصور کرد ارتباط این مرتب‌سازی را با مقوله‌های سبک‌شناسی، تاریخ زبان فارسی، فرهنگ تاریخی زبان فارسی و نیز تاریخ اندیشه در زبان فارسی^۹ و... در مورد جملات نیز مرتب‌سازی کم و بیش فوایدی خواهد داشت مانند بررسی نسبت وجود عناصر دستوری در آغاز یا پایان جملات در سبکهای مختلف، دوره‌های مختلف، موضوعات مختلف، انواع مختلف ادبی (حمسی، غنایی، تعلیمی و...).

۹. امکان جست و جوی جملات پرسشی، تعجبی و امری در کلیه متون یا متون انتخابی پژوهشگر و امکان مرتب کردن یافته‌های

ساختهای فعلی رفتن را (در صورت لزوم در جمله) با قید شماره صفحه و نام کتاب می‌تواند بیند و به هر صورت که خواست (کمی و پرینت) در اختیار داشته باشد. این امکان اساساً برای تأمین نیاز فرهنگ نویسان ایجاد شده است، یعنی معادل فیش نویسی روی کاغذ است که ذیل مدخل، شاهد را می‌نویسد. در مورد فعلها چون شکل مصدری فعل، در فرهنگ مدخل می‌شود، امکان تطبیق آن با ساختهای فعلی در رایانه به طور معمول وجود ندارد و رایانه نمی‌تواند ارتباط برود، رفته بود، می‌روم، برو و... را با رفتن تشخیص دهد. این کار، یعنی کدگزاری افعال، کلمات مشابه با آنها را - که فعل نیستند - نیز از آنها تمایز می‌کند و برای تسهیل در جست و جو مفید است. مثلاً برد (فعل) و برد (نوعی پارچه) بزید (فعل امر) و بزید (بست) نهشت (گذاشت) و نهشت (جنت) از این طریق از هم تمایز می‌شوند.

- تعیین هویتی‌های دیگر نیز ممکن است، اما به جهت وقتگیر بودن، در این مرحله از آنها صرف نظر شده، ولی توجه شده است که امکانات آن در نرم افزار فراهم باشد که در صورت لزوم بعده با این کدهای لازم دیگری را برای هویتی‌های دیگر افزود. هویتی‌ای از قبیل: اسم، صفت، صفت برتر، صفت برترین، صفت عددی، تمایز عددی و واحد شمارش، قید، صوت، جمع مکسر، اسم جمع، کلمات پرسشی، نام اشخاص، نام مکانها، نام کتابها و....^۶

موارد پنج گانه فوق (بند ۶) روی همان دو نسخه متن اصلی کتابها (که برای تایپ تهیه شده بود) انجام گرفته است و در متون آماده‌سازی شده (بند ۵) و اراده شده در نرم افزار، اعمال می‌شود. این مرحله یعنی اعمال کدگزاری‌های انجام شده روی کاغذ در نرم افزار که توسط کارشناسان زبان و ادبیات فارسی صورت می‌گیرد، آخرین مرحله تصحیح (پیش از عرضه نرم افزار) نیز خواهد بود، بدین صورت که کارشناسان مذکور در مطابقه متن اصلی و کلمات و عبارات کدگزاری شده آن با متن موجود در نرم افزار، خواه ناخواه با غلطها و افادگی‌های احتمالی مواجه خواهند شد - که احیاناً هر دو تایپیست مانند هم عمل کرده‌اند^۷ و به تصحیح آنها اقدام خواهند کرد.

امکانات نرم افزار

۱. قابلیت ایجاد بانک واژگان از همه متون ذخیره شده در نرم افزار یا متون انتخابی و مرتب کردن آنها به روشهای زیر:

الف) فهرست کردن الفبایی کل واژگان متن یا متون انتخابی بر اساس آغاز و از همراه با درج شماره بسامد آن در مجموعه مورد جست و جو به دو صورت: از آلف تا نی و از نی تا آلف به هر منظوری مثلاً تعیین مدخلهای یک فرهنگ عام یا خاص، بزرگ یا کوچک و...، در اختیار داشتن تمام کلمات زبان از آغاز تا ۱۳۰۰ برای واژه‌گزینی و نام گذاری در موارد عام و خاص، علمی و غیر علمی.

ب) فهرست کردن الفبایی کل واژگان متن یا متون انتخابی بر اساس پایان واژه همراه با درج شماره بسامد آن در مجموعه مورد جست و جو به دو صورت: از آلف تا نی و از نی تا آلف به منظورهای مختلف مثلاً شناختن پسوندهای زبان فارسی.

ج) فهرست بسامدی کل واژگان متن یا متون انتخابی به دو صورت صعودی و نزولی (از کم بسامدترین به پر بسامدترین و

حوزه وظایف خودنمی بیند^{۱۲} انتظار می رود مسئولان نهادهایی که به نحوی سازمان خود را مریبوط به این طرح می بینند به این امر توجه نمایند. به سرانجام رساندن این طرح که مورد تأیید شفاهی و کتبی استادان طراز اول ادبیات و زبان شناسی این مرز و بوم است و هم با اشراف و راهنمایی ایشان آغاز شده و تا کنون ادامه یافته است^{۱۳} باعث سر بلندی و افتخار، رشد فرهنگی، علمی و ادبی جامعه، حفظ میراث مکتوب، توسعه، تثبیت و تعمیق فرهنگ ایرانی - اسلامی و معرفی آن به جهانیان باریچ ترین و آسان ترین وسیله ممکن (لوح فشرده، اینترنت)، گسترش زبان و ادب فارسی در جهان، بازیابی هویت فرهنگی - تاریخی، معرفی بزرگان ایران اسلامی در طول تاریخ، کمک قابل توجه به مراکز و نهادهای پژوهشی کشور و جلوگیری از اتلاف وقت پژوهشگران، جلوگیری از اتلاف سرمایه و صرفه جویی در هزینه های پژوهشی و... خواهد بود و هر نهاد یا فردی که عهده دار به انجام رساندن این طرح شود بی شک نام خویش را جاودان کرده است. همین جایاً تصریح کنم که به عنوان طراح و مجری مرحله نخست این طرح، مطمئن ام هر کس دیگری

صورت الفباری بنابر آغاز جمله یافت و نیز پایان جمله یافت یا بنا بر تاریخ تالیف متون.
۱۰. امکان جست و جوی گفت و گو های کلیه متون یا متون انتخابی پژوهشگر و امکان مرتب سازی فهرست به دست آمده بنا بر ترتیب تاریخ تالیف متون یا ترتیب الفباری.

۱۱. امکان وارد کردن معنی لغات، می توان بعدها از این امکان استفاده کرد و پس از وارد کردن معنی لغات بدون هیچ کار اضافه ای، این لغتها و معنیها را با مثال و شاهدان به صورت یک فرهنگ، در نرم افزار در اختیار داشت.

امکانات دیگر

با توجه به بند ۶ ویرایش و آماده سازی متن، پس از کامل شدن اطلاعات وارد شده (حدود هزار عنوان کتاب^{۱۴} در بیش از پانصد هزار صفحه) مجموعه های بالریزش زیر را نیز در اختیار خواهیم داشت که به راحتی قابل تبدیل به کتاب و لوحهای فشرده مجزا نیز خواهند بود:

فرهنگ جامع امثال و حکم فارسی

فرهنگ جامع سخنان بزرگان (به فارسی)

مجموعه ترجمه احادیث

فرهنگ اقوال عربی در متون فارسی

فرهنگ احادیث عربی به کار رفته در متون فارسی

فرهنگ جامع اشعار (و مصراعهای) عربی به کار رفته در متون فارسی

فارسی

فرهنگ امثال و حکم عربی به کار رفته در متون فارسی

فرهنگ جامع اشعار فارسی به کار رفته در متون نظر فارسی (که سیاری از آنها در هیچ دیوانی یافته نمی شود).



که ادامه این کار را به عهده بگیرد از آنجا که به تنها ی کاری از پیش نخواهد برد و ناگزیر باید از راهنمایی و مشورت استادان و اهل فن استفاده کند، نتیجه یکی خواهد بود و من هم تجربه ناچیز خود را با کمال میل در اختیار خواهم گذاشت. به گمان من ادامه این طرح نیاز به ایجاد یک بنیاد علمی دارد که تواند با استفاده از امکانات و نیروی انسانی و علمی جامعه دانشگاهی این کار را ساماندهد و به همه جوانب آن پردازد. طبیعتاً ادامه این طرح به تألیف فرهنگ جامع زبان فارسی، فرهنگهای تخصصی، کتابهای آموزش زبان فارسی، تحقیقات بنیادی زبان شناسی و... منجر خواهد شد که هر کدام خود طرحی مفصل و گسترش دارد. نهادهایی مانند وزارت علوم، وزارت ارشاد، بنیاد ایران شناسی و به خصوص دانشگاه، فرهنگستان، پژوهشگاه علوم انسانی و دیگر نهادهای عهده دار فرهنگ نویسی که در گیر این نوع مسائل هستند، بهترین گرینه ها برای ادامه این طرح می توانند باشند. امر خطیر است و حساسیت بسیار می طبلد، امیدوارم که توانسته باشم در این گزارش حق مطلب را ادا کنم.

و همگی با درج تفاوتها و ضبطهای مختلف آنها و... و ناگفته پیداست که با تولید این اثر چه امکانات و سیعی برای پژوهشگران زبانی، ادبی، تاریخی، اجتماعی و... ایجاد خواهد شد و ضمن من بی نیاز ساختن ما از کارهای پراکنده و به ناچار ناقص در این زمینه ها سبب می شود که پس از این دیگر عمر شریف محققان این سرزمین صرف امور وقتگیری از این دست نگردد و دوران پژوهشگران اساسی کارگشا و نقد و تحلیل آغاز شود و شاهد تحقیقات علمی جدی تری در علوم انسانی به خصوص در حوزه زبان و ادبیات فارسی باشیم.^{۱۵}

اکنون با توجه به اینکه بانی طرح، شورای گسترش زبان فارسی، ادامه طرح در مراحل بعدی و حمایت از آن را در توان یاد را در

- فهرست متون قرن چهارم تاریخه قرن پنجم هجری
۱. آثار منظوم روکی
 ۲. تاریخ سیستان (قسمت اول)
 ۳. ترجمه السواد الاعظم
 ۴. تاریختنامه طبری
 ۵. ترجمه تفسیر طبری
 ۶. ترجمه رساله حی بن بقیان
 ۷. ترجمه قرآن موزه پارس
 ۸. تفسیر قرآن پاک
 ۹. تفسیر قرآن کمبریج
 ۱۰. تفسیری بر عشري از قرآن مجید
 ۱۱. حدود العالم من المشرق الى المغرب
 ۱۲. اشعار پراکنده قدیم ترین شعرای فارسی
 ۱۳. دانشنامه عالانی
 ۱۴. دانشنامه میسری
 ۱۵. اشعار باباطاهر همدانی
 ۱۶. دیوان دقیقی طوسی
 ۱۷. دیوان عسجدی مروزی
 ۱۸. دیوان عنصری بلخی
 ۱۹. دیوان فرخی سیستانی
 ۲۰. دیوان منوچهری دامغانی
 ۲۱. رگ‌شناسی یار ساله در نبض
 ۲۲. زین الاخبار گردیزی

سطر جایقتند.

۸. منظور از جمله در این طرح، در حال حاضر لزوماً به معنی دستوری جمله نیست، بلکه جمله تاجانی که مقصود مردم نظر کامل‌بیان شود ادامه خواهد داشت، یعنی کامل بودن شاهد برای واژگان فرنگ مد نظر بوده است. البته امکان تعیین جمله دستوری نیز وجود دارد که در صورت لزوم در مراحل بعد می‌توان بدان پرداخت.
۹. تذکر جناب آقای دکتر غلامحسین صدری افشار.
۱۰. تاکنون نزدیک به ۴۹۰ عنوان کتاب شناسایی و فهرست شده است و برآورده‌ی شود که این رقم با توجه به محدوده‌ای که پیش از این تعیین شد، از ۱۰۰۰ عنوان بیشتر نشود.
۱۱. در باب مسائل حقوقی این طرح نیز راهکارهایی اندیشیده شده است که حقوق مادی و معنوی مصححان محترمی که کتابشان در این طرح مورد استفاده قرار می‌گیرد، محفوظ بماند. پرداختن بدان در این مقاله به این جهت است که نحوه عرضه این نرم افزار که در این مورد تعیین کننده است، هنوز معلوم نیست.
۱۲. مرحله نخست طرح نیز تاکنون به دلیل نبود امکانات به اتمام نرسیده است. اگر امکانات فراهم شود این مرحله حداقل تا دو ماه دیگر به پایان خواهد رسید، ولی با ادامه وضع کوتی شاید بیش از ده ماه طول بکشد. (مشکل اصلی کمبود رایانه است)
۱۳. استادان محترم عبارت اند از: دکتر حسن انوری، دکتر تقی پورنامداریان، دکتر علی محمد حق شناس، دکتر حسین سامعی، دکتر محمد رضا شفیعی کدکنی، دکتر علی اشرف صادقی، دکتر پریوش صفاوی و دکتر مصطفی عاصی. با تکثر از حمایتها و راهنماییهای بی دریغشان به خصوص آقای دکتر سامعی که با دقت و حوصله فراوان و توجه به جزئیات، نکات مهمی را باداوری کردنند.

پانوشتها:

۱. کتابخانه الوراق با نشانی WWW.ALWARAQ.COM
۲. از آنجاکه طرح نیاگاه داده‌های زبان فارسی در پژوهشگاه علوم انسانی به مدیریت آقای دکتر مصطفی عاصی شامل متون تألیف شده‌ی پس از ۱۳۰۰ می‌شود، برای پرهیز از دوباره کاری و صرف هزینه مجدد، متون پس از این تاریخ از این طرح کنار گذاشته شد.
۳. فهرستی از این کلمات (مشابه در املاء و تلفظ و متفاوت در تلفظ و معنی: تاکنون ۲۵۰ مورد) (مشابه در املاء و تلفظ و متفاوت در معنی: تاکنون ۹۰ مورد) تهیه شده که به تدریج کامل می‌شود. برای کاربرد این فهرست پانوشت بعد.
۴. به این موارد گونه‌های اسم نیز افزوده می‌شود. مثلاً با انتخاب انوشیروان نیز ای جست و جو، تمام گونه‌های دیگر این نام که در متون موجود است (انوشروان، انوشه روان، نوشیروان، نوشین روان و...) در صفحه نمایشگر ظاهر می‌شود تا کاربر ضمن اشراف بر گونه‌های دیگر این نام، جست و جوی خود را کامل و بادقت به انجام برساند.
۵. این گروه کارشناسان متخصص زبان و ادب فارسی (فارغ التحصیلان دوره‌های کارشناسی ارشد و دکتری) هستند.
۶. اینجا باید از کوشش، دقت نظر و همدلیهای مهندسان گروه تحقیق در عملیات که مسئولیت برنامه نویسی و پشتیبانی فنی این نرم افزار را بر عهده دارند صمیمانه تشکر کنم که در ایجاد این امکانات بسیار مساعدت کرده‌اند.
۷. طبیعی است که در مواردی دو تا پیست مانند هم اشتباه کنند، مانند مواردی که در دو سطر متوالی یا با فاصله کلمات مشابه باشد و هنگام تایپ، چشم از روی سطر نخست به سطر مشابه بعدی بلغزد و یک یا چند