

زبان فارسی و رایانه: برگزیده مقالات (۲ جلد)، به کوشش: حسین صامتی و محمود بی‌جن‌خان، سازمان مطالعه و تدوین کتب علوم انسانی دانشگاه‌ها (سمت)، ۱۳۸۹، ۱۲۶۶ صفحه.

ما در زمانه‌ای زندگی می‌کنیم که اطلاعات از هر سو به سمتمن روانه است: سپهری از اطلاعات. بخش عمده این اطلاعات در قالب زبان طبیعی است و از طریق رایانه‌ها به ما می‌رسد. به منظور دسترسی به این دانش ذخیره‌شده و همچنین، ایجاد میاناهای^۱ انسان-ماشین، پردازش زبان طبیعی، در جامعه اطلاعاتی چندزبانه امروزی، نقش پررنگ‌تری یافته است. برنامه‌های تصحیح دستور و املای کلمات، بازیابی اطلاعات در پایگاه‌های داده و ترجمه از زبانی به زبان دیگر از پرفروش‌ترین برنامه‌های پردازشی زبان‌اند. موفقیت این نرمافزارها تخیل فرد را پروار می‌کند، اما باید پذیرفت که این برنامه‌ها همچنان ازنظری هوش و کارآمدی، کمبودهای اساسی دارند. در واقع، هدف چاھطلبانه انسان برای ایجاد نرمافزار تولید و درک عمیق زبان طبیعی، که ابزاری قوی برای ترجمة خودکار و ارتباط دوسویه ماشین و انسان گردد، همچنان دور از دسترس می‌نماید. به نظر می‌رسد برای حل مسائل همچنان مکتوم این زمینه‌ها باید به علوم پایه، و در این مورد، علم زبان‌شناسی، توسل جست. مسائل زبان‌شناختی فارسی، از دیدگاه نظری، پیشینه و رشد قابل توجهی دارند، اما پردازش رایانه‌ای آن‌ها قدمت چندانی ندارد. شاید زمان آن رسیده باشد که با بسترسازی و ارائه "گسترشده‌تر محتوای تولیدی، پردازش زبان فارسی را جدی‌تر بگیریم. کتاب "زبان فارسی و رایانه" نگاهی دوچانبه، زبان‌شناختی و رایانشی، به مسائل مربوط به پردازش زبان فارسی دارد.

۹۴ مقاله‌ای که در قالب کتابی باعنوان "زبان فارسی و رایانه" در دو جلد و ۱۲۶۶ صفحه تدارک دیده شده‌اند، برگزیده‌ای هستند از مقالاتی که در زمینه زبان و خط فارسی در فضای رایانه‌ای تا خردادماه سال ۱۳۸۶ در هم‌اندیشی‌های مربوط به این موضوع، در کنفرانس بین‌المللی سالانه انجمن کامپیوترا ایران، کنفرانس مهندسی برق ایران، همایش زبان‌شناسی ایران و کارگاه زبان فارسی و رایانه، ارائه شده‌اند. به جز چهار مقاله انگلیسی (که در انتهای جلد دوم چاپ شده‌اند) بقیه مقالات به

1. interface

زبان فارسی‌اند. کتاب بر حسب موضوع اصلی مقالات به ده بخش تقسیم شده که چهار بخش نخست در جلد اول و شش بخش دیگر در جلد دوم ارائه گردیده است. این مقالات طیف وسیعی از موضوعات مختلف مربوط به گفتار و نوشتار فارسی، از جمله پردازش و بازشناسی متن و گفتار، دادگان، ریشه‌یاب و سامانه‌های خبره، را دربر دارد.

بخش اول کتاب باعنوان "پیکره و دادگان" حاوی دوازده مقاله است. سه مقاله اول به مبحث پردازش گفتاری در قالب تعیین مرز آوایی (همایون‌پور و احمدی، ۱۳۷۷)، و هجایی (غفاری مقدم و همکاران، ۱۳۷۶)، و واکداری، هجا و اجاج (همایون‌پور و آزاد، ۱۳۸۰) در گفتار فارسی می‌پردازند. ضرورت این مرزبندی در تهیه دادگان گفتاری آشکار می‌شود.

مقاله‌های شیخ‌زادگان و بی‌جن‌خان (۱۳۸۵) و فاضل و همکاران (۱۳۸۴) و اسلامی و بی‌جن‌خان (۱۳۷۴) به چگونگی تهیه دادگان گفتاری زبان فارسی می‌پردازنند. مقاله نخست، به معرفی و ذکر ویژگی‌های دادگان گفتاری می‌پردازد که در پژوهشکده پردازش هوشمند علام طراحی و پیاده‌سازی شده‌اند. دومین مقاله، روند طراحی و تهیه دادگان تلفنی اعداد متصل فارسی را شرح می‌دهد. این دادگان برای سامانه‌های بازشناسی خودکار گفتار طراحی شده است. آخرین مقاله، گزارشی است از چگونگی ایجاد اولین دادگان بزرگ گفتاری زبان فارسی (فارس دات)، که شامل ۳۸۶ جمله است که ۳۰۰ گویشور از ده منطقه زبانی در گردآوری آن نقش داشته‌اند. این مقاله، نیز، به تقطیع و برچسب‌دهی آوایی و اجاجی این دادگان می‌پردازد. همچنین، در مقاله پنجم (رضایی و همکاران، ۱۳۸۳) با هدف آموزش برخط (آنلاین)، تلفظ اجاجهای فارسی به صورت صوتی- تصویری، به همراه ارائه پایگاه اینترنتی آن تدارک دیده شده است. دادگان این طرح شامل سیگنال ویدئویی و صوتی تلفظ اجاجهای و گونه‌رسمی تلفظ الفبای فارسی است.

دو مقاله بعدی به مباحث مربوط به واژگان می‌پردازنند. در اثر نخست (اسلامی و همکاران، ۱۳۸۳)، براساس واژگان ذهنی فارسی‌زبانان و صورت‌بندی قواعد تصریف کلمه در زبان فارسی، حدود پنجاه و پنج هزار مدخل واژگانی تدارک دیده شده است. برنامه واحدسازی صرفی ارائه شده با ارجاع به واژگان و قواعد تصریف می‌تواند واحدهای زبانی (نوشتار یا گفتار) را به لحاظ صرفی پردازش کند. فامیان و آقاجانی (۱۳۸۵) به منظور طراحی شبکه واژگانی صفات زبان فارسی، پائزده طبقه اصلی و بیش از هفتاد طبقه فرعی معنایی از مقوله صفات ارائه کرده‌اند. رابط گرافیکی کاربر این شبکه با قابلیت‌های جستجو، نمایش و ارسال اطلاعات طراحی شده است.

زبان فارسی و رایانه: برگزیده مقالات

مقاله (صفابخش و شایگان، ۱۳۷۴) گزارشی است از تشکیل دادگان کلمات و حروف بهمنظر ایجاد مجموعه‌ای استاندارد برای آموزش و آزمایش همسان و مقایسه عملکرد الگوریتم‌ها برای بازشناسی خودکار حروف کلمات دستنویس (نستعلیق). گزارش ساخت نخستین پیکره چندزبانه برای فارسی (قاسمی‌زاده و همکاران، ۱۳۸۵) برپایه مدل MULTEXT بهمعرفی ویژگی‌های صرفی- نحوی فارسی و برچسبدهی پیکره متن ترجمه‌شده رمان ۱۹۸۴ به فارسی پرداخته است. چندزبانگی این‌پیکره، راه را برای ترجمه بین زبان‌ها هموار می‌کند. آخرین مقاله این بخش (حاجی عبدالحسینی، ۱۳۷۶) نیز اولین تلاش برای برچسبدهی یک پیکره رایانه‌ای فارسی را بهنمایش می‌گذارد. بهنظر می‌رسد این مقاله، و تاحدی دومقاله پیشین، بیش از آن که به مبحث دادگان پردازند، به روش برچسبدهی آن‌ها پرداخته‌اند.

عنوان بخش دوم کتاب، "پردازش متن" است. از میان دوازده مقاله این بخش، سومین مقاله (شمس‌فرد، ۱۳۸۵) دستاوردها و چالش‌های پردازش فارسی را بیان می‌کند. شمس‌فرد ابتدا به بررسی پیچیدگی‌ها (ویژگی‌ها)ی پردازش زبان فارسی، و سپس به معرفی فعالیت‌ها و پژوهش‌هایی می‌پردازد که در زمینه‌های پردازش واژگانی، ساختواری، نحوی، معنایی، تولیدی، یادگیری و ترجمة ماشینی، و همچنین تهیه منابع زبانی انجام شده‌اند.

سه مقاله اول، دوم و هفتم در صددند تا سامانه‌هایی برای دسته‌بندی موضوعی متون فارسی ارائه کنند. دسته‌بندی موضوعی، کاربردهای فراوانی در موتورهای جستجو، پاسخ‌گویی به سؤالات و بازیابی اطلاعات دارد. عربسرخی و فیلی (۱۳۸۵) با به کاربستن مدل احتمالاتی بیزی Bayesian و ایده نگهداری کلمات هم‌آیند برای رسیدن به نتایج بهتر، سامانه خود را تهیه کرده‌اند. در مقاله دوم (حاجی‌حسینی و الماس‌گنج، ۱۳۸۵)، اساس کار، روش تحلیل معنایی پنهان است که در آن نزدیکی کلماتی مشخص می‌شود که بیشتر در متن‌های همسنخ معنایی باهم رخ می‌دهند. این روش قابلیت بالایی در جداسازی موضوعی متون دارد. امامی‌آزادی و الماس‌گنج (۱۳۸۵) روش تحلیل معنایی پنهان احتمالاتی را (که هافمن برای بازیابی اطلاعات ارائه کرده بود) به کار برده‌اند. این روش، که زیربنای آماری محکمی دارد، باعث شده است شیوه‌های اصولی‌تری در تحلیل زبان و متون ایجاد شود. همچنین، با کنترل مدل، حین آموزش، و حذف متغیرهای پنهان نامناسب، عملکرد آن را بهبود داده‌اند.

دو مقاله تشكیری و مبیدی (۱۳۸۲) و بشیری و همکاران (۱۳۸۴) به دو شیوه از طراحی نمایه‌ساز خودکار برای متون فارسی می‌پردازند. در هر دو شیوه، ابتدا فهرستی از واژگان عمومی تهیه شده است. در مقاله نخست، در روند ساخت نمایه‌ساز خودکار، پساز شناسایی واژگان متن، واژگان عمومی آن حذف می‌شوند. در مقاله دیگر، الگوریتم ریشه‌یابی ارائه شده که وندها را مرحله به مرحله حذف می‌کند تا به ریشه واژه برسد. این الگوریتم دقت نمایه‌ساز را بهبود و حجم آن را کاهش می‌دهد.

شاهمیری و همکاران (۱۳۸۵) در راستای طرح‌های شناسایی نویسنده از روی نوشته، سامانه‌ای را طراحی کرده‌اند که هدف آن شناسایی اشعار شاهنامه است. به‌این‌منظور، پنجاه ویژگی اشعار فارسی در سه مقوله فیزیکی، مفهومی و آوایی دسته‌بندی شده و سپس، اشعار به دو روش پردازش آماری پارامترها و شبکه عصبی مصنوعی تحلیل شده‌اند. همچنین، عظیمی (۱۳۸۵) در مقاله‌اش، با پیش‌نهادن دوازده پرسش درباره ویژگی‌های آوایی، واجی و واژگانی، و بررسی آماری پاسخ‌ها به تمایز شاهات‌ها و تفاوت‌های اشعار حافظ، خواجه و سلمان می‌پردازد.

سامانه خلاصه‌سازی خودکار متون فارسی (کریمی و شمس‌فرد، ۱۳۸۵) براساس ترکیبی از روش‌های زنجیره‌واژگانی و روش‌های مبتنی بر گراف عمل می‌کند. نخستین بخش مقاله، به‌معرفی خلاصه‌سازی، انواع و نمونه‌های اجرایی شده آن پرداخته است. سپس، با پیش‌نهادن پنج معیار برای امتیازدهی جملات متن، جملات بابیشترین امتیاز را به عنوان خروجی انتخاب می‌کند. مقاله دیگر (صدرموسوی و شمس‌فرد، ۱۳۸۶) برای تشخیص روابط معنایی میان اجزای فعل طراحی شده است. روش ارائه شده، مبتنی بر دودسته قوانین، یکی مربوط به هر دسته‌معنایی و یکی مربوط به تشخیص نقش گروه‌های واژگانی است.

سامانه‌های استخراج اطلاعات به‌منظور پردازش اطلاعات مربوط به یک حوزه خاص، در محیط‌هایی که روزانه با حجم وسیعی از اطلاعات سروکار دارند، استفاده می‌شود (زبان فارسی و رایانه: ۲۸۹). سامانه استخراج اطلاعات مرصاد (رجیمی‌بور و همکاران، ۱۳۸۶) روی اخبار در حوزه نظامی تمرکز دارد. این سامانه، به‌وسیله الگوهایی متون را پردازش و اطلاعات را استخراج و ذخیره‌سازی می‌نماید. مقاله پایانی این بخش، گزارشی است از کارهای انجام‌شده برای ایجاد پایگاه داده‌های زبان فارسی در پژوهشگاه علوم انسانی (عاصی، ۱۳۷۴). مقاله به ویژگی‌های دادگان، گستره زبانی، منابع گردآوری داده‌ها، ساختار زبانی پیکره و ساختار رایانه‌ای آن، و همچنین کاربری‌های

زبان فارسی و رایانه: برگزیده مقالات

دادگان (انواع جستجو، گزارش‌ها، کاربران و ...) می‌پردازد. البته، این مقاله باید در بخش پیشین (پیکره و دادگان) گنجانده می‌شد.

بخش ۳: ریشه‌یاب و خطایاب. موتورهای جستجو، سامانه‌های بازیابی اطلاعات و ترجمه متون ازجمله زمینه‌هایی هستند که از دستاوردهای ریشه‌یابی برای بهبود روش‌هایشان سود جسته‌اند. ازین‌جا ده مقاله ارائه شده در این بخش، پنج مقاله به طراحی ریشه‌یاب‌های زبان فارسی اختصاص دارند. تشکری و میبدی (۱۳۸۰) در مقاله‌شان پساز بررسی شیوه ساخت مقوله‌های واژگانی (فعل، اسم، ضمیر) و البته بدون درنظر گرفتن نقش آن‌ها در جمله، الگوریتمی برای ریشه‌یابی خودکار واژگان طراحی کرده‌اند. مقاله سوم (یوسفان و همکاران، ۱۳۸۵)، پساز برشمرون دشواری‌های ریشه‌یابی زبان فارسی، به تدارک یک فرهنگ ریشه‌یاب، و درنهایت، روند طراحی یک شبکه‌زبان برنامه‌نویسی برای ریشه‌یابی افعال فارسی پرداخته است. حسامی‌فر و قاسم‌ثانی (۱۳۸۴) درابتدا مقاله‌شان رویکردهای مختلف نسبت به مسئله ریشه‌یابی را مرور کرده‌اند. سپس، باستفاده از تأثیر نقش کلمات روی الگوریتم‌های ساختواره فارسی، از آن برای ریشه‌یابی افعال فارسی استفاده کرده‌اند. در ریشه‌یاب ارائه شده توسط نصیری و همکارانش (۱۳۸۴)، به جای استفاده از اطلاعات ساختاری زبان، از یک مدل احتمالاتی برای ریشه‌یابی استفاده می‌شود. و درنهایت، نهمین مقاله (شاهمیری و همکارانش، ۱۳۸۵) با کمک شبکه عصبی مصنوعی پرسپترون^۱ چندلایه به طراحی سامانه خودکاری برای تعیین ریشه زبانی واژگان فارسی و عربی موجود در زبان فارسی می‌پردازد. دقت سامانه پیاده‌سازی شده تا ۹۲ درصد گزارش شده است.

از آن‌جاکه حجم اطلاعاتی وسیعی از طریق دستی یا به صورت خودکار وارد رایانه می‌شود و احتمال بروز خطایاب در این داده‌ها کم نیست، استفاده از خطایاب‌ها موجب کاهش هزینه و بالارفتمن سرعت تولید مستندات رایانه‌ای خواهد شد. دری نوگرانی و صبوریان (۱۳۸۵) در مقاله پنجم این بخش، پساز معرفی روش‌های مختلف خطایابی، به طراحی خطایابی برای زبان فارسی می‌پردازند که در آن پساز ریشه‌یابی واژه‌های پیوسته، خطایاب مشخص و پیشنهاد لازم به کاربر داده می‌شود. همچنین، سامانه ارائه شده در مقاله عربسرخی و همکاران (۱۳۸۵)، با استفاده از بخش‌های مختلف

1 . multi-layer perception

(واژه‌نامه، الگوریتم تشخیص خط و الگوریتم تصحیح خط)، خطاهای املایی زبان فارسی را به طور خودکار تصحیح می‌کند.

موضوع مقاله نخست این بخش (قدسی و بازرگان، ۱۳۷۴)، ارائه شیوه‌ای نرم‌افزاری برای تولید خودکار فونت‌ها به زبان متفاوت از راه پویش تصویر است. ایده ارائه شده در اینجا برای بازنگاری نویسۀ نیز قابل استفاده است. در مقاله هشتم (هم، مرادی و شیری قیداری، ۱۳۸۴) به دنبال رسیدن به چینش بهینه‌ای از جایگذاری ۳۲ حرفاً الفبای فارسی و همزه بروی صفحه کلید هستند. ویژگی چنین بهینه‌سازی، جلوگیری از جایه‌جایی زیاد انگشتان و تایپ دو حرفاً متوالی با یک انگشت (دست) و تقسیم بار تایپ بین دو دست است.

فولادی و ارومچیان (۱۳۸۵) با بهره‌گیری از پیکره به عنوان منبع یادگیری و با ارائه ساختوازه به صورت کمینه (تقسیم‌بندی به بن و پسوند)، نحوه استخراج ساختوازه را با یادگیری بدون نظرارت ارائه می‌کنند.

دوازده مقاله بخش چهارم کتاب به ارائه الگوریتم‌هایی برای تشخیص نویسۀ (OCR) و تشخیص دستخط اختصاص دارد. در مقاله فهیمی و تیمسار (۱۳۷۲) الگوریتمی ارائه شده است که با استفاده از روش ریخت‌شناسی می‌تواند حروف تایپ‌شده فارسی را بازنگاری کند. در مقاله دوم (عزمی و کبیر، ۱۳۷۶)، دو الگوریتم مختلف برای بازنگاری حروف چاپی فارسی روی بیست‌نوع فونت مختلف آزموده شده و میزان بازنگاری فونت‌ها توسط این الگوریتم، بالا گذاش شده است. الگوریتم بعدی، توسط عباسیان و کبیر (۱۳۷۷) و براساس ویژگی‌های پویا و ایستای نویسۀ‌های فارسی تنظیم شده است. در (سلیمانی و همکاران، ۱۳۸۵) الگوریتمی ارائه شده است که با میانگین زمانی ۰۰۰۵ ثانیه برای هر حرف به محاسبه داده‌های دست‌نوشته می‌پردازد و در تدوین آن از ترکیبی از رویکردهای فازی، ساختاری و آماری استفاده شده است. مظفری و همکاران (۱۳۷۵) به طراحی و پیاده‌سازی سامانه‌ای برای بازنگاری ارقام دست‌نویس با استفاده از روش‌های ساختاری می‌پردازند. در مقاله بعدی (مسروری و همکاران، ۱۳۷۹)، براساس استخراج ویژگی‌ها از کل کلمه، روشی پیشنهاد شده است که در آن از پروفایل‌های تصویر استفاده می‌شود. از آن‌جاکه بازنگاری قلم برای بازنگاری نویسۀ‌ها اجتناب‌ناپذیر است، نظام آبادی‌پور و همکارانش (۱۳۸۲)، روشی برای استخراج ویژگی‌های مناسب از تصویر متن و بازنگاری قلم آن ارائه کرده‌اند که نتایج آن مطلوب ارزیابی شده است.

زبان فارسی و رایانه: برگزیده مقالات

دسته دیگر مقالات این بخش، باهدفی یکسان، به مباحث مربوط به جداسازی حروف پرداخته‌اند: مقاله چهارم (نظام‌آبادی‌پور و همکارانش، ۱۳۷۹) باهدف آشکارسازی نقاط جداسازی در متون چاپی قدیمی به اصلاح یک الگوریتم قدیمی پرداخته است. صفات‌بخش و ادبی (۱۳۸۱) الگوریتم‌هایی را برای مراحل پیش‌پردازش، تقطیع و یافتن ترتیب راست‌به‌چپ قطعه‌ها برای کلمات دست‌نویس‌فارسی ارائه کردند که نتایج عملکردشان در حد مطلوبی گزارش شده است. جداسازی تصویری کلمات فارسی و لاتین باستفاده‌از یادگیری استقرایی قواعد (شش ویژگی برگرفته از تصویر و تدوین سیزده قاعدة کلی) موضوع مقاله صدویی یزدی و همکارانش (۱۳۸۱) است. "زنگیر فعال" روشی است که از آن برای یافتن مرز چیزهای موجود در تصویر استفاده می‌شود. گرایلو و کبیر (۱۳۸۵) به بررسی و ارزیابی این روش و چگونگی بهبود عملکرد آن در اصلاح گستگی‌های ناخواسته در متون چاپی فارسی می‌پردازند.

درنهایت، مقاله شهابی‌نژاد و رحمتی (۱۳۸۵) با مروری بر مطالعات تعیین هویت مبتنی بر دستخط، روشی برای تعیین و تأیید نویسنده به صورت برون خط (مبتنی بر متن) ارائه می‌کند.

بخش مربوط به ترجمه ماشینی نیز دوازده مقاله دربر دارد. در ابتدای این بخش، فضلی و فهیمی (۱۳۷۷) به بررسی چند شیوه بازنمایی معنایی، از جمله گراف‌های مفهومی پرداخته و نشان می‌دهند که می‌توان همین شیوه را گسترش داد تا دامنه وسیعی از جمله‌های فارسی را بپوشاند. سه مقاله بعدی (قاسم‌ثانی و سلیمانی، ۱۳۷۸؛ فیلی و قاسم‌ثانی، ۱۳۸۳؛ الف، فیلی و قاسم‌ثانی، ۱۳۸۳ ب)، به ترتیب با اساس قراردادن روش‌های تجزیه چارت، دستور درخت افزایشی همزمان و دستور یکسان‌سازی (مدل توسعه یافته دستور مستقل از متن) سامانه‌های مترجمی مختلفی را معرفی می‌کنند.

سه مقاله بعد مربوط‌اند به ساخت دستورهای رایانه‌ای: سجادی و عبدالله‌زاده بارفروش (۱۳۸۵) به بررسی نحوه عملکرد دستور پیوندی (دستور کلمه) برای زبان فارسی، عرب‌سرخی و همکاران (۱۳۸۵) به ارائه ایده تولید قواعد دستوری باستفاده از الگوریتم‌های ژنتیک، و شمس‌فرد و همکاران (۱۳۸۶) به ساخت برخی ابزارها و پیمانه‌های پایه‌ای پردازش زبان فارسی می‌پردازند. همچنین، مگردمیان (۱۳۸۳، ۱۳۸۵) در دو مقاله پایانی این بخش به ترتیب به تحلیل معنایی جزء فعلی افعال مرکب و شیوه ترجمه این افعال، و معرفی یک تحلیل‌گر صرفی برای زبان مورد استفاده در وبلاگ‌های فارسی با استفاده از فناوری ارائه شده در مرکز زیراکس می‌پردازد.

درنهایت، سه مقالهٔ پایانی این بخش، به سامانه‌های برچسبزنِ متن فارسی پرداخته‌اند. برچسبدهیِ متن در زمینه‌های بازشناسی گفتار، بازیابی اطلاعات، رفع ابهام معنی کلمات و تجزیه جمله‌ها کاربرد دارد. ثابتی و همکارانش (۱۳۸۶) به دو روش احتمالی و برمبانی تغییر سامانه برچسبزن، متن فارسی را پیاده‌سازی کرده‌اند. مقالهٔ کیخا و همکاران (۱۳۸۶) گزارشی است از کاربردِ درخت‌های تصمیم (از روش‌های یادگیری ماشین) در برچسبدهیِ متن و تهیهٔ برچسبزن MFT به صورتِ مستقل از متن. در مقالهٔ مگردومیان (۱۳۸۳) نیز به چالش‌های اساسی در تدوین برچسبزن فارسی و راه‌هایی برای حل آن‌ها پرداخته شده است.

سه بخشٔ بعدیٔ کتاب، به مباحثٔ پردازش گفتار اختصاص دارند. در بخشٔ ششم، دوازده مقالهٔ باموضوع تبدیلِ متن به گفتار ارائه شده است. نخستین مقاله (ابوطالبی و تبیانی، ۱۳۷۸) بامقدمه‌ای دربارهٔ روش‌های بازسازی گفتار آغاز می‌شود و بالانتخاب روش اتصال هجها و بررسی‌های دیگر، سامانه‌ای برای تبدیلِ متن فارسی به گفتار را پیاده‌سازی می‌کند. مقالهٔ دوم (شیخزاده نجار و همکاران، ۱۳۷۸) هم تحقیقی است برای تطبیق و پیاده‌سازی گفتارساز فارسی برمبانی گفتارساز کلات (Klatt). مقالهٔ اسلامی و همکارانش (۱۳۸۳) گزارشی است از بستهٔ نرم‌افزاری "گویا" که نوشتار فارسی را به گفتار تبدیل می‌کند. همچنین، همایونپور و نمنبات (۱۳۸۳) برپایهٔ روش بازسازی پیوندی مبتنی بر انتخابٔ واحد، سامانهٔ بازسازی گفتار "فارس بیان" را ارائه کرده‌اند. در مقالهٔ انگلیسی شیخان و همکاران (۱۳۸۵) نیز سامانهٔ گفتارساز فارسی دیگری ارائه شده که از سه زیربخش تشکیل شده است: پردازش گر زبان، تولیدگر نوای گفتار و تحلیل گر گفتار.

سامانه‌های تبدیلِ متن به گفتار از دو بخش تشکیل می‌شوند: تبدیلِ متن به زنجیرهٔ واج‌های تشکیل‌دهندهٔ آن، و تبدیلِ زنجیرهٔ واج‌ها به گفتار. مقاله‌های بعدی عمدتاً روی بخشٔ نخست این سامانه‌ها تمرکز دارند. همایونپور و حسینی‌نژاد (۱۳۷۸) برای تبدیلِ متن به واج‌های نظریش از شبکهٔ عصبی پرسپترون چندلایه سود جسته‌اند. نمنبات و همکاران (۱۳۸۵) باستفاده از همین شبکهٔ عصبی به مدل‌سازی دیرشِ واج پرداخته‌اند. مدل‌کردنِ دیرشِ واج با استفاده از روش مارس نیز در مقالهٔ دیگری (بحربنی و همایونپور، ۱۳۸۵) بررسی شده است. مقالهٔ نمنبات و کوچاری (۱۳۸۶) در نگه‌گیری میان کلمات را با استفاده از درختِ دسته‌بندی مدل‌سازی کرده است. و ابوطالبی و فغانی (۱۳۸۵) در راستای میزان فهم‌پذیری سیگنال گفتار، به ارائهٔ دادگان فارسی برای آزمون قافیهٔ اصلاح‌شده می‌پردازند.

زبان فارسی و رایانه: برگزیده مقالات

دو مقاله دیگر، یکی (معطر و همکاران، ۱۳۸۳) است که باستفاده از الگوی عبارات، به طور مبسوط به نرم‌السازی در زبان فارسی می‌پردازد. نرم‌السازی، تبدیل صورت‌های ناموجود در فرهنگ‌ها به صورتی است که معادل واج‌نگاری آن‌ها در فرهنگ موجود باشد. مقاله دیگر، نوشته بی‌جن‌خان و مرادزاده (۱۳۸۳)، به مسئله همنگاره‌های خط فارسی پرداخته است. توصیفات ارائه شده در حل مسئله همنگاره‌های فارسی در سامانه‌هایی چون تبدیل متن به گفتار و ترجمة مشینی بسیار کاربرد دارد.

در بخش بازشناسی گفتار هم دوازده مقاله ارائه شده است. در این میان، پنج مقاله (شیخان و همکاران، ۱۳۷۳؛ پرویزی و احمدی، ۱۳۸۰؛ الماس‌گنج و همکاران، ۱۳۸۰؛ صامتی و همکاران، ۱۳۸۳؛ الماس‌گنج و همکاران، ۱۳۸۳) به معرفی سامانه‌های بازشناسی گفتار فارسی می‌پردازنند. در مقاله نخست، از شبکه‌های عصبی مصنوعی و روش‌های هوش مصنوعی استفاده شده است، در دومی، با دایرة کلمات متوسط، گفتار پیوسته فارسی بازشناسی می‌شود. دو مقاله الماس‌گنج و همکارانش سامانه‌های شناور و را معرفی می‌کنند. و مقاله صامتی و همکارانش گزارشی است از سامانه‌ای که به صورت مستقل از گوینده عمل می‌کند.

مقالات دیگر این بخش، هریک به بحث‌وبررسی بخشی از مسائل مربوط به سامانه‌های بازشناسی گفتار می‌پردازند. بررسی و ایجاد ساختار برای همگونی واج‌های مجاور زبان فارسی (صامتی و همکاران، ۱۳۷۶)، راه‌هایی برای رفع مشکلات ناشی از ماهیت سیگنال (الماس‌گنج و همکاران، ۱۳۷۷)، روشی برای حل مسئله وابستگی به بافت در تلفظ کلمات (غلامپور و همکاران، ۱۳۷۹)، بازشناسی محل هجای تکیه‌بر کلمات (دهقان دهنوی و همکاران، ۱۳۸۰)، و استفاده از ویژگی نوایی و میزان تکیه هجاهای فارسی در فرایند بازشناسی گفتار پیوسته فارسی (الماس‌گنج، ۱۳۸۱) از موضوعات مختلف مورد بحث است.

باتوجه به آن که سامانه بازشناسی در انسان ساختاری سلسله‌مراتبی و دوسویه دارد، در مقاله بزدچی و همکارانش (۱۳۸۵) کارآیی شبکه‌های عصبی دوسویه در بازشناسی گفتار بررسی شده است؛ و در آنها، مقاله ویسیپور و همکاران (۱۳۸۵) برای مواجهه با کلمات خارج از واژگان (ناآشنا برای سامانه بازشناسی) از معیار اطمینان استفاده می‌کند، که مبنی است بر امتیازدهی کلمات برای اطمینان از صحت بازشناسی آن‌ها.

از مهم‌ترین راه‌های بهبود عملکرد، افزایش دقت و کاهش خطای سامانه‌های بازشناسی گفتار، استفاده از مدل‌های زبانی (اطلاعات آماری، دستوری و ...) است، و بخش هشتم هم به "مدل‌های

زبانی در بازناسنی گفتار" اختصاص دارد. مراحل طراحی و پیاده‌سازی یک رمزگشایی واج به کلمه (باباعلی و همکاران، ۱۳۸۳)، استفاده از تلفیقی از مدل‌های دستوری احتمالاتی به عنوان مدل زبانی (ممتأزی و همکاران، ۱۳۸۴)، استفاده از مدل دستور ساخت گروهی تعمیم یافته برای ساخت مدل زبانی (حافظی و همکاران، ۱۳۸۵)، استفاده از پیکره متنی زبان فارسی برای استخراج مدل زبانی (بحرانی و همکاران، ۱۳۸۵)، و استفاده از روش تحلیل معنایی پنهان احتمالاتی به منظور پرداختن به بعد معنایی زبان (امامی آزادی و همکاران، ۱۳۸۵)، موضوعات مقالات مطرح شده در این بخش‌اند.

شش مقاله بخش نهم، سامانه‌های خبرهای زبان فارسی ارائه کردند. نخستین مقاله، معرفی سامانه "پرس‌وجوی فارسی" است (سلطانی خسروشاهی و لوکس، ۱۳۷۹): یک رابط زبان فارسی برای دادگان رابطه‌ای، که به دادگان خاصی هم وابسته نیست. فهیمی و شمس‌فرد (۱۳۷۴) سامانه "دنا" را با استفاده از روش وابستگی‌های مفهومی برای درک متن فارسی تدوین کردند. درک متن عبارت است از تبدیل رودی زبان طبیعی به یک بازنمایی داخلی قابل پردازش توسط ماشین. "هستی" سامانه‌ای جهت استخراج دانش واژگانی و مفهومی از متون نوشتاری زبان فارسی و ساخت واژگان و هستانشناصی¹ براساس آن‌ها است. شمس‌فرد (۱۳۸۳) به معرفی این سامانه می‌پردازد. "دانای" (دادآبادی و پالهنگ، ۱۳۸۴) هم سامانه‌ای است که پس از دریافت یک جمله فارسی و تحلیل نحوی و معنایی جمله، ساختار ویژگی و قاب حالت جمله دریافتی را می‌سازد و به فرمان کاربر پاسخ می‌دهد. سامانه‌های پرسش‌وپاسخ شاخه‌ای از تحقیقات گروه بازیابی اطلاعات‌اند که به‌ویژه برای کاربرد در موتورهای جستجو به وجود آمده‌اند. در این سامانه‌ها سعی بر آن است که سؤال کاربر با جوابی کوتاه، دقیق و کامل پاسخ داده شود. مقاله شمس‌فرد و همکاران (۱۳۸۵) بررسی معماری و عملکرد یک سامانه پرسش‌وپاسخ به زبان فارسی است. رجبی و همکاران (۱۳۸۵) به معرفی روش‌هایی جهت تبدیل جمله‌های زبان فارسی به بازنمایی منطقی (درک متن) و همچنین تبدیل عبارت‌های منطقی به جمله‌های فارسی (تولید متن) می‌پردازند. در این مقاله، برای روند درک، از روش تحلیل معنایی مبتنی بر نحو و برای تولید از نظریه معنا- متن استفاده شده است.

بخش دهم با عنوان "سایر موضوعات" مقاله شیخ‌زادگان و همکاران (۱۳۷۴)، "بررسی درجه اهمیت واج‌های زبان فارسی گفتاری و تعیین ترتیب آن‌ها از نظر شناسایی گوینده" را دربر دارد، و

1. ontology

زبان فارسی و رایانه: برگزیده مقالات

درواقع، مطالعه درجه اهمیتِ واج‌ها از نظرِ قدرتِ تفکیک و تمایزِ گویندگانشان است و از نتایج آن در سامانه‌های شناسایی گوینده استفاده می‌شود.

در این کتاب به بسیاری از موضوعاتِ مطرح در پردازش رایانه‌ای زبان فارسی پرداخته شده، و از طیفِ مقالاتِ ارائه شده به خوبی نمایان است که تکمیلِ پژوهش‌های موجود و پرداختن به جنبه‌های کمتر کارشده نیاز به کارهای اساسی در آینده دارد. تدوین این مجموعه به همتِ دو استادِ ساعی، که خود در زمینه‌های مختلفِ دادگان و پردازشِ گفتار سال‌ها پژوهش کرده‌اند، بسیار ارزشمند است. به‌ویژه آن‌که این مجموعه نیاز جامعه زبان‌شناسان رایانه‌ای به دردست‌دادشتن منسجم دست‌آوردهای پردازشی زبان فارسی را برآورده می‌سازد. تقسیم‌بندی بخش‌های مختلفِ کتاب، موضوعاتِ عمده مطرح در زبان‌شناسی محاسباتی را نشان می‌دهد، هرچند در برخی موضوعات، تحقیقات چندانی در زمینه زبان فارسی دیده نمی‌شود.

محدودشدن کتاب به کنفرانس‌ها و همایش‌های نامبرده شده، از نظرِ محدودیتِ امکاناتی، که همیشه وجود داشته و دارد، و همچنین بالا رفتن حجمِ کتاب، قابلی درک است، اما از نظرِ محدودیت در انتخابِ مقالاتِ اصیل و ارزش‌دار در زمینه پردازشِ زبان فارسی، که اتفاقاً در این همایش‌ها ارائه نشده‌اند، خلاً بزرگی را ایجاد می‌کند. به‌ویژه آن‌که این کتاب می‌تواند منبع ارزش‌های برای دانشجویانی شود که بنابر نیاز روبه‌گسترشی تحقیقات در زمینه پردازش زبان فارسی، به‌سوی این زمینه تحقیقاتی گرایش می‌یابند. از طرفِ دیگر، به نظر می‌رسد آوردن تاریخچه مختصراً درباره هرموضوع و اهداف پیش‌ روی آن برای زبان فارسی، خواننده را در درکِ موقعیتِ زبان فارسی در رایاسپیره یاری می‌کرد.

از بهترین نکاتِ این کتاب، تدوینِ واژه‌نامهٔ برابرنهادهای اصطلاحاتِ تخصصی و یکسان‌سازی این اصطلاحات (تاختِ ممکن) در متنِ مقالات است. این کار از سردرگمی یا بدفهمی خواننده‌گان جلوگیری کرده و به کلیتِ کتاب نیز نظم و هماهنگی بخشیده است. از دیگر سو، نداشتن نمایه را شاید بتوان بزرگ‌ترین کمبودِ این مجموعه دانست. ازان‌جاکه این دو جلد به عنوان مرجعی برای تحقیقات رایانه‌ای روی زبان فارسی عمل خواهند کرد، بهتر بود دست‌کم نمایه‌ای موضوعی برای آن تدوین می‌شد.

محله زبان و زبان‌شناسی

در پایان، امید است همان‌طور که ویراستاران کتاب نیز ابراز کرده‌اند، در آینده روند تدوین مجموعه‌مقالات اصیل در این حوزه ادامه یابد.

صدیقه مرادی

منابع

عاصی، مصطفی (۱۳۸۵). "زبان فارسی در رایاپیه: جایگاه زبان فارسی در جهان نوین فناوری اطلاعات." نامه فرهنگستان. پاییز ۱۳۸۵، شماره ۳۱. ۵۹-۷۰.

Bird, Steven and Ewan Klein, and Edward Loper (2009). *Natural Language Processing with Python*. O'Reilly Media, Inc.

Bolshakov, Igor A. and Alexander Gelbukh (2004). *Computational Linguistics: Models, Resources, Applications*. Instituto Politecnico Nacional: Mexico.