

پارس مورف: تحلیلگر صرفی زبان فارسی

وحید مواجی^۱، محرم اسلامی^۲ و بهرام وزیرنژاد^۳

دانشگاه صنعتی شریف و دانشگاه زنجان^۴

چکیده:

در مقاله حاضر می‌کوشیم مبنای نظری، نحوه طراحی و عملکرد سامانه تحلیل‌گر صرفی زبان فارسی با عنوان اختصاری "پارس مورف" را معرفی کنیم. پارس مورف سامانه‌ای مبتنی بر قواعد صرفی زبان فارسی است که ساخت درونی کلمات فارسی را با توجه به نظام تصریف و نظام واژه‌سازی زبان، تجزیه و تحلیل و مقوله دستوری و نقش هر کدام از اجزای سازنده کلمه را مشخص می‌کند. پارس مورف با استفاده از یک واژگان در حدود ۴۵۰۰۰ واژه‌ای و نیز در چارچوب قواعد صرفی زبان فارسی که بر یک تحقیق جامع زبان‌شناختی استوار است می‌تواند واژه‌های پیچیده و نیز صورت‌های ممکن تصریفی و حتی واژه‌های خارج از واژگان را تحلیل کند. دقت نسخه اول پارس مورف حدود ۹۵٪ است که افزودن اطلاعات نحوی و مسائل مربوط به هم‌نویسه‌ها و نیز لحاظ کردن ویژگی‌های خط فارسی می‌تواند این دقت را به ۱۰۰٪ نزدیک کند. از پارس مورف می‌توان در مطالعات محض زبانی و نیز پردازش ماشینی زبان فارسی استفاده کرد.

واژگان کلیدی: پارس مورف، تحلیل‌گر صرفی، زبان فارسی، واژه‌سازی، تصریف، اشتقاق و ترکیب.

۱- مقدمه

صرف یا ساختواژه^۱ به عنوان بخشی از زبان‌شناسی ناظر بر مطالعه ساخت درونی کلمات و روابط نظام‌مند صورت و معنا در کلمات است (Booij, Geert., 2007). وقتی صحبت از ساخت (کلمه) می‌شود، تلویحاً می‌پذیریم که کلمه دارای اجزایی است و در نتیجه هر کدام از اجزا نقش و جایگاه مشخصی در ساخت کلمه دارد. در این تحقیق پس از صورت‌بندی ساخت درونی کلمه، سامانه‌ای را طراحی کرده‌ایم که قادر است به طور خودکار ساخت درونی کلمات فارسی را تحلیل و اجزای سازنده کلمه را مشخص کند. پیش از ورود به بحث اصلی، در ادامه به اختصار به مبانی صرف اشاره می‌کنیم تا در جریان بحث در خصوص عملکرد پارس مورف، ابهامی وجود نداشته باشد.

ساختواژه از دو نظام مستقل تصریف^۲ و واژه‌سازی^۳ تشکیل می‌شود و در تصریف صورت-کلمه‌ها^۴ مورد بحث قرار

می‌گیرد. هر کدام از واژه‌ها^۵ با توجه به جایگاهشان در جمله می‌توانند صورت-کلمه‌های متفاوت داشته باشند که در اصطلاح غیردقیق به آنها کلمه^۶ نیز می‌گویند. صورت-کلمه‌ها واژه‌های جدید نیستند، بلکه صورت تصریفی واژه به حساب می‌آیند. در نظام واژه‌سازی، واژه‌ها بسیط و یا پیچیده‌اند. واژه‌های بسیط می‌توانند با هم ترکیب شوند و واژه مرکب بسازند و از طرف دیگر واژه‌های بسیط و یا مرکب می‌توانند با عناصر واژه‌ساز (تکواژه‌های اشتقاقی) زبان ترکیب شوند و به ترتیب واژه‌های پیچیده مشتق و یا مرکب-مشتق بسازند. به نمونه‌های زیر توجه کنید:

الف) واژه بسیط: /کار/

ب) صورت کلمه: کار، کارها، کارش، کارشه

ج) واژه مشتق: /کارگر، کارمند، کارایی، کاری(کارکن)/

د) واژه مرکب: /کارخانه‌ساز، کاربلد، کارآگاه، کارنامه/

³ word-formation

⁴ word-forms

⁵ lexemes

⁶ word

¹ morphology

² inflection

ه) واژه مرکب-مشتق: کاردرمانی، کارخانه‌چی، کارمندمحور، کاردرمانگری/

با توجه به نمونه‌های ارائه‌شده در مثال ۱، دستگاه صرف دو نقش اساسی برعهده دارد: تصریف و واژه‌سازی (Bauer, 1983). (طباطبایی ۱۳۸۲ ص ۶). واژه بسیط (الف) واژه‌ای است که از یک ریشه تشکیل شده است. صورت-کلمه (ب) صورت‌های تصریف شده یک واژه را می‌گویند. از ج ۱ تا ۵۱ واژه‌های پیچیده را می‌بینیم که در چارچوب امکانات واژه‌سازی زبان درست شده‌اند. واژه مشتق (ج) واژه‌ای است که در ساختمان آن یک واژه بسیط یا واحد واژگانی بسیط و یک یا چند تکواژ اشتقاقی به کار رفته است. واژه مرکب واژه‌ای است که از دو یا چند واژه بسیط یا واحد واژگانی بسیط درست شده باشد. واژه مرکب - مشتق (ه) واژه‌ای است که در ساختمان آن دو یا چند واژه بسیط یا واحد واژگانی بسیط و یک یا چند تکواژ اشتقاقی به کار رفته باشد. با توجه به مثال‌های بالا می‌بینیم که بخشی از تکواژهای مقید، واژه جدید نمی‌سازند (مانند ب) که به آنها تکواژهای غیراشتقاقی و به‌تسامح کل آنها را تکواژهای تصریفی می‌گوییم. بخشی دیگر (در ج و ه) واژه جدید می‌سازند که به آنها تکواژهای اشتقاقی می‌گوییم. به عبارت دیگر در تصریف با واژه‌پردازی سروکار داریم، اما در اشتقاق با واژه‌سازی (طباطبایی ۱۳۷۶ ص ۱۵). ستاک (stem) به‌صورت-کلمه‌ای اطلاق می‌شود که وندهای تصریفی از آن حذف شده باشند. ستاک می‌تواند بسیط یا پیچیده باشد و ستاک بسیط همان ریشه است (Booij, Geert., 2007).

در طراحی پارس مورف، ساخت تصریفی کلمه در زبان فارسی (اسلامی و علیزاده ۱۳۸۸) به‌صورت ساختماندهای در نظر گرفته شده است و جایگاه طبقات مختلف وندهای تصریفی در ساختمان انواع کلمات مشخص شده است. پارس مورف در تحلیل تصریفی کلمه ابتدا ستاک را شناسایی می‌کند و متناسب با ساخت تصریفی پیش‌بینی شده برای آن نوع ستاک به دنبال انواع وندهای تصریفی در جایگاه‌های خاص، با در نظر گرفتن صورت‌های مختلف نوشتاری هرکدام از طبقات، می‌گردد. یافتن وندی به‌عنوان مثال در جایگاه دوم پس از ستاک اسمی، نشان می‌دهد که جایگاه اوّل خالی مانده است. در بخش ۲ در مقاله حاضر به‌طور کامل به موضوع ساخت تصریفی کلمه در زبان فارسی پرداخته‌ایم.

اگر ستاک پیچیده باشد، پارس مورف با اعمال قواعد واژه‌سازی زبان فارسی، ستاک مورد نظر را از حیث مشتق یا مرکب‌بودن تجزیه و تحلیل و اجزای سازنده آن را با ذکر مقوله دستوری و نقش آنها مشخص می‌کند. به دلیل معتبر

نبودن فاصله به عنوان مرز کلمه در متون فارسی، پارس مورف در تجزیه ستاک‌های پیچیده ترکیب‌های بالقوه را نیز به عنوان گزینه‌های بعدی در اختیار ما می‌گذارد. به‌عنوان مثال ستاک پیچیده "کارگر" در بخش اشتقاق به عنوان کلمه مشتق شناسایی و یا در ترکیب گفته می‌شود که در فارسی ممکن است آن ترکیب "کار (N1) + گر (Adv)" یعنی اسم + قید باشد که این دو کلمه بی‌فاصله در کنار هم آمده‌اند. در بخش ۳ به عملکرد پارس مورف در ریشه‌یابی و تعیین اجزای واژه‌های پیچیده خواهیم پرداخت.

در تمامی تحقیقات مربوط به پردازش‌های خودکار زبانی در زبان فارسی، به‌خصوص در پردازش متن فارسی برای مقاصد مختلف اعم از ترجمه ماشینی، تبدیل متن به گفتار و غیره از نوعی تحلیل گر صرفی استفاده می‌شود؛ اگر چه در اغلب مواقع تحلیل گرهای صرفی در تحقیقات پیشین محدود، هدف‌محور و فاقد پشتوانه جامع زبان‌شناختی است. به عنوان مرور پیشینه پژوهش در ادامه تنها به مواردی اشاره می‌کنیم که در تحلیل ساخت درونی کلمه فارسی نگاه ساخت‌مند داشته‌اند و با یک رویکرد زبان‌شناختی-مهندسی به تحلیل صرفی کلمه فارسی پرداخته‌اند. در این خصوص ابتدا می‌توان به مطالعات دقیقی اشاره کرد که در پروژه شیراز (Megerdooian, et al., 2000) در طراحی ترجمه سامانه ماشینی فارسی-انگلیسی اشاره کرد که در میانه راه متوقف شد. دومین مورد از طراحی تحلیل خودکار فارسی مربوط به تحلیل گر تصریفی زبان فارسی است که در سامانه تبدیل متن به گفتار فارسی "گویا" به کار گرفته شد (اسلامی و همکاران ۱۳۸۳) که تنها به تحلیل تصریفی کلمه محدود می‌شد. آماده‌سازی متن معیار برای زبان فارسی ۱ با عنوان اختصاری STeP1 سامانه دیگری است که قادر است کلمات فارسی را از نظر صرفی تجزیه و تحلیل کند (شمس‌فرد ۱۳۸۳). STeP1 با استفاده از واژگان زبانی زبان فارسی (اسلامی و همکاران ۱۳۸۳) و قواعد صرفی که طراحان آن در نظر گرفته‌اند کار می‌کند.

اگرچه STeP1 در تجزیه کلمه به اجزای سازنده آن تا حد زیادی موفق عمل می‌کند، ولی مبنای علمی زبان‌شناختی آن نیاز به بازنگری دارد تا از اشکالات فعلی پرهیز شود. به‌عنوان مثال برای کلمه "دانشگاه" سه ریشه در نظر می‌گیرد، به ترتیب "دانشگاه، دانش، دان" که نشان می‌دهد حداقل منظور پدیدآورندگان آن از "ریشه" در مفهوم علمی آن اصطلاح نیست. یا در کلمه "دانشگاهایمان" علاوه بر اختصاص سه ریشه فوق هم‌زمان دو تحلیل زیر برای آن ارائه می‌شود:

الف) اسم + علامت جمع + ی + ضمیر ملکی اول
شخص جمع که در آن "دانشگاه" ریشه است، به
صورت "دانشگاه + ها + ی + مان".

ب) اسم + گاه + علامت جمع + ی + ضمیر ملکی اول
شخص جمع که در آن "دانش" ریشه است، به
صورت "دانش + گاه + ها + ی + مان".

چنانچه می‌بینیم هیچ مبنای علمی برای ریشه‌بودن
"دانشگاه" یا "دانش" در مثال فوق وجود ندارد؛ از طرف
دیگر اجزای تجزیه شده لزوماً واحدهای نظام واژه‌سازی و
نظام تصریف نیستند. به عنوان مثال "ی" در مثال بالا چه
عنوان و نقش زبانی دارد؟ جز اینکه به خاطر شرایط
واژ-واجی در زنجیره واجی کلمه ظاهر شده است. همچنین
کلماتی مانند "کفش‌هایم" یا "کفش‌هایمن" را STeP1
نمی‌تواند تجزیه کند و هیچ ریشه‌ای برای این قبیل
تصریف‌ها و صورت-کلمه‌ها و همچنین برخی ستاک‌های
پیچیده و بسیط خارج از واژگان پیدا نمی‌کند. این در
حالیست که پارس مورف با دقت کامل موارد فوق را تجزیه و
تحلیل می‌کند.

پارس مورف، تحلیل‌گر صرفی زبان فارسی، که با زبان
برنامه‌نویسی پایتون^۱ نوشته شده است بر یک مبنای به‌طور
کامل علمی زبانی استوار است و در چارچوب ساختمان صرفی
کلمه فارسی به تجزیه و تحلیل و تعیین نقش هر کدام از اجزا
در درون کلمه می‌پردازد. پس از صورت‌بندی دقیق اطلاعات
نظام تصریف و واژه‌سازی در زبان فارسی سعی کردیم در
مرحله اجرا و طراحی سامانه پارس مورف تمامی آن اطلاعات
را به شکل دقیق به کار بگیریم. در حال حاضر پارس مورف با
استفاده از آخرین ویرایش واژگان زبانی فارسی (اسلامی،
شریفی/آتشگاه، علیزاده/مجیری و زندی، ۱۳۸۳) که حدود
۴۵۰۰۰ واژه در آن قرار دارد و در چارچوب قواعد صرفی زبان
فارسی که در اختیار دارد، با دقت بالای ۹۵٪ می‌تواند ساخت
درونی کلمات فارسی را تحلیل کند. نیز می‌تواند با استفاده از
امکانات و اطلاعات صرفی که در اختیار دارد کلمات خارج از
واژگان را نیز از حیث تصریف و واژه‌سازی تجزیه و تحلیل
کند.

۲- نظام تصریف زبان فارسی

چنانچه در مقدمه گفتیم، در طراحی پارس مورف رویکرد
ساخت-بنیاد اتخاذ شده است که به موجب آن عناصر صرفی
تشکیل‌دهنده کلمه در یک ارتباط ساختاری و نظام‌مند با

همدیگر قرار دارند و در ساخت کلمه، اجزای هر کدام عنوان و
نقش منحصر به فردی دارند. پارس مورف صورت واژگانی
کلمه را از واژگان زبانی فارسی (اسلامی و همکاران
۱۳۸۳) می‌گیرد و در چارچوب نظام تصریف کلمه در زبان
فارسی (اسلامی و علیزاده ۱۳۸۸) به تحلیل تصریفی کلمه
می‌پردازد. در واژگان زبانی مقوله دستوری هر کدام از واژه‌ها
مشخص شده است و بعد از شناسایی واژه با توجه به مقوله
دستوری آن ساخت تصریفی را برای آن در نظر می‌گیرد. اگر
در ساختمان کلمه از وابسته‌های تصریفی پیش‌بینی شده در
جایگاه‌های خاص مورد یا مواردی وجود داشته باشد، در آن
صورت عنوان هر کدام را مشخص می‌کند. واژه ممکن است
بدون هیچ‌گونه وند تصریفی در جمله به کار رود که در چنین
شرایطی واژه و کلمه صورت یکسانی خواهند داشت.
وابسته‌های تصریفی عناصر اختیاری در ساختمان کلمه
هستند و پارس مورف قادر است حتی با استفاده از قواعد
تصریف که در اختیار دارد کلمات خارج از واژگان را شناسایی
و عناصر آن را مشخص کند و اگر ستاک ناشناخته پیچیده
باشد، اجزای آن را هم با توجه به قواعد واژه‌سازی روشن
می‌کند. درخصوص کلمه در کلمه‌ها (words within word)
نیز در پارس مورف تمهیداتی اندیشیده شده است که در
گزینه‌های بعدی که در اختیار کاربر قرار می‌دهد به آنها اشاره
می‌کند. کلمه در کلمه‌ها واژه‌هایی هستند که در درون آنها
می‌توان کلمات دیگری نیز پیدا کرد، مانند "مادر" که در
عین حال واژه بسیط و دو کلمه مجزا ("ما + در") است. البته
در شناسایی کلمه در کلمه‌ها در پارس مورف از قواعد صرفی
استفاده کرده‌ایم.

در ادامه به ساخت تصریفی اسم و فعل اشاره
می‌کنیم. شایان ذکر است که در زبان فارسی، صفات‌ها بالقوه
اسم هستند و با اشتقاق صفر به اسم تبدیل می‌شوند و
صورت‌های تصریفی اسم را می‌پذیرند. این موارد در طراحی
پارس مورف لحاظ شده است. در ساخت تصریفی اسم، هسته
صورت واژگانی اسم و عنصر اجباری است که می‌تواند
وابسته‌های تصریفی اختیاری داشته باشد که به همین دلیل
در ساخت تصریفی اسم در درون () قرار دارند.

[اسم] [لنگه جمع]؛ [واژه یسهای شخص مذکور مصل]	[واژه یسهای مبنی]؛ [کرد اسمیه]	[واژه یسهای مبنی]؛ [کرد اسمیه]
--	--------------------------------	--------------------------------

ساختار تصریفی اسم (اسلامی و علیزاده ۱۳۸۸)
چنانچه در ساخت تصریفی اسم می‌بینیم، اسم بالقوه
می‌تواند در سه جایگاه، وابسته‌هایی بپذیرد که این جایگاه‌ها

¹ Python

معتبر هستند و هرگونه جابه‌جایی در نظم وابسته‌ها منجر به کلمه بدساخت می‌شود. در هر کدام از جایگاه‌ها نیز صورت‌های مختلف تکواژ (به‌عنوان مثال تکواژهای مختلف جمع در جایگاه اول) یا طبقات گوناگونی از وابسته‌ها به کار می‌رود که حضور یکی از آنها مانع حضور بقیه گونه‌های یک تکواژ و یا دیگر طبقات مربوط به آن جایگاه می‌شود. بنابراین پارس‌مورف هیچ‌گاه دو تکواژ جمع یا دو تکواژ مربوط به جایگاه دوم یا سوم در ساختمان اسم شناسایی نمی‌کند. به این محدودیت در اصطلاح توزیع تکمیلی^۱ می‌گویند که پارس‌مورف در تحلیل ساخت تصریفی کلمه محدودیت بالا را از نظر تصریف و واژه‌سازی لحاظ می‌کند. در واژه‌سازی نیز پارس‌مورف تکرار تکواژ مثلاً "گر" را به‌طور هم‌زمان در ساختمان کلمه مجاز نمی‌داند.

تحلیل ساخت تصریفی فعل به دلیل پذیرفتن پیشوند و پسوند تصریفی دشوارتر است. در واژگان زایا، بن مضارع و بن ماضی صورت‌های واژگانی فعل در نظر گرفته شده است و پارس‌مورف با توجه به این موضوع ساخت تصریفی فعل را تحلیل می‌کند. در ادامه ساخت تصریفی فعل فارسی را می‌بینیم که محدودیت‌های ذکرشده در خصوص اسم در فعل نیز مشاهده می‌شود.

$$[\text{تکواژ: نام}] = [\text{تکواژ: فعل}] + [\text{تکواژ: نهاد}] + [\text{تکواژ: مفعول}] + [\text{تکواژ: مضاف}] + [\text{تکواژ: مضاف‌به}] + [\text{تکواژ: مفعول‌فعل}]$$

ساختار تصریفی فعل (اسلامی و علیزاده ۱۳۸۸)

دیگر اقسام کلمه مانند صفت‌ها، قیده‌ها، اعداد، حروف اضافه نیز ساخت تصریفی خاص خود را دارند که در طراحی پارس‌مورف به‌طور کامل مورد توجه بوده‌اند.

۳- نظام واژه‌سازی زبان فارسی

نظام واژه‌سازی زبان فارسی نیز همانند نظام تصریف این زبان در طراحی پارس‌مورف با دقت صورت‌بندی شده است. دو شیوه عمده واژه‌سازی یعنی اشتقاق^۲ و ترکیب^۳ در زبان فارسی عمده‌ترین شیوه‌های واژه‌سازی هستند. پارس‌مورف با مراجعه به واژگان زایای زبان فارسی (اسلامی و همکاران ۱۳۸۳) و نیز با توجه به امکانات اشتقاق و ترکیب به تجزیه کلمات مشتق و مرکب می‌پردازد.

۳-۱- اشتقاق در زبان فارسی

فهرست تکواژهای اشتقاقی با استفاده از ساخت اشتقاقی واژه در فارسی امروز (کلباسی، ۱۳۷۱) و اشتقاق پسوندی در زبان فارسی امروز (کشانی، ۱۳۷۱) و نیز ملاحظات نویسندگان این

^۱ complementary distribution

^۲ derivation

^۳ compounding

مقاله تهیه شد و پارس‌مورف با در اختیار داشتن این فهرست و الگوهای اشتقاق به تجزیه کلمات مشتق فارسی می‌پردازد. در الگوهای اشتقاق مشخص شده است که هر کدام از تکواژهای اشتقاقی به چه نوع ستاکی از نظر مقوله افزوده می‌شود و واژه حاصل از رهگذر اشتقاق چه مقوله دستوری خواهد داشت. به‌عنوان مثال کلمه "دانشگاهی" به‌صورت "دان(V1) + ش(N=اسم‌ساز) + گاه(N=اسم‌ساز) + ی(N=اسم‌ساز)" تجزیه می‌شود. پارس‌مورف با در اختیار داشتن امکانات ذکر شده می‌تواند کلمات خارج از واژگان را نیز تجزیه و تحلیل کند و نیز ترکیب‌های بالقوه را برای کلمه مورد نظر در گزینه‌های بعدی پیشنهاد کند. نظر به عدم قطعیت در استفاده از فاصله در متون فارسی به‌عنوان مرز کلمه، پارس‌مورف این قابلیت را دارد که علاوه‌بر تجزیه و تحلیل کلمه در سطح اشتقاق برای کلمه مورد نظر صورت‌های ترکیبی نیز در نظر بگیرد. با افزودن اطلاعات نحوی به پارس‌مورف در موارد مشکوک به اشتقاق یا ترکیب یا دو کلمه مستقل بدون فاصله می‌توان از گزینه‌هایی دیگری استفاده کرد که پارس‌مورف ارائه می‌کند.

مسئله مهم دیگر در تجزیه کلمات مشتق، موضوع هم‌نویسه‌ها^۴ است که کار تجزیه خودکار کلمه را دچار مشکل می‌کند. به‌عنوان مثال "ی" با ساخت واجی "i/" می‌تواند در نقش‌های زیر به کار رود: الف) تکواژ اشتقاقی (یای نسبت) که به‌طور معمول اسم را به صفت و برعکس صفت را به اسم تبدیل کند. به‌عنوان مثال در کلمات "دانشگاهی، زیبایی"، ب) در نقش "یای" نکره به‌عنوان مثال در "کتابی" در جمله "کتابی خریدم" که اشاره به کتاب نامعین می‌کند، ج) در نقش "یای" بند موصولی‌ساز، به‌عنوان مثال در "پسری" در جمله "پسری که دیدی" و د) در نقش واژه‌بست ربطی، به‌عنوان مثال در "تو پسری" به معنی "تو پسر هستی". علاوه‌بر صورت‌های یکسان تکواژهای اشتقاقی و غیراشتقاقی نوع دیگری از هم‌نویسه هست که در آنها بین صورت واژگانی و صورت تصریفی ابهام وجود دارد. به‌عنوان مثال "مردم" که به‌صورت‌های زیر تجزیه می‌شود:

الف) مردم(N1)

ب) مرد(N1) + am (واژه بست ربطی)

ج) مرد(N1) + am (واژه بست شخصی یعنی مرد من)

د) مُرد(V2) + am (واژه بست شخصی)

البته در ساخت‌های مبهم از اطلاعات واژه‌سازی و تصریفی برای رفع ابهام استفاده می‌شود. به‌عنوان مثال در

^۴ homographs

"دانشگاهی‌ها"، پارس مورف به هیچ وجه "ی" را "یای" غیر اشتقاقی قلمداد نمی‌کند، چون قبل از تکواژ جمع آمده است.

۳-۲- ترکیب در زبان فارسی

با توجه به تعریفی که از ترکیب در مقدمه مقاله حاضر ارائه کردیم، اصول و الگوهای ترکیب صورت‌بندی و پارس‌مورف با مراجعه به واژگان زبانی فارسی (اسلامی و همکاران ۱۳۸۳) و با در دست داشتن الگوهای ترکیب (طباطبایی، ۱۳۸۳) کلمات مرکب را شناسایی و اجزای ترکیب را با ذکر مقوله دستوری آنها مشخص می‌کند.

واژه‌های بسیط و واحدهای واژگانی غیرپیچیده (مانند بن‌های مضارع) در چارچوب الگوهای ترکیب (همان) می‌توانند با هم ترکیب شوند و واژه مرکب درست کنند. در اغلب مواقع اجزای واژه مرکب خود مدخل‌های واژگانی در واژگان برنامه هستند که در آن صورت مقوله‌های دستوری اجزای ترکیب و نیز مقوله دستوری واژه مرکب مشخص است. کلمات مرکب خارج از واژگان نیز با مراجعه به واژگان برنامه و با در نظر گرفتن الگوهای ترکیب تجزیه می‌شوند.

درخصوص کلمات مرکب - مشتق نیز، پارس‌مورف قواعد اشتقاق و ترکیب را هم‌زمان لحاظ می‌کند و این واژه‌ها را به اجزای سازنده‌اش تجزیه می‌کند که در آن نقش و مقوله دستوری هر کدام از اجزا مشخص شده است. به عنوان مثال کلماتی مانند "کارخانه‌چی" و یا "دانشجو" را به ترتیب به صورت "کار(N1) + خانه (N1) + چی (N=تکواژ اشتقاقی اسم‌ساز) و "دان(V1) + ش (N=تکواژ اشتقاقی اسم‌ساز) + جو (V1)" تجزیه می‌کند.

۴- نتیجه‌گیری

در این تحقیق، سامانه تحلیل صرفی کلمه در زبان فارسی با عنوان پارس‌مورف را معرفی کرده‌ایم که بر پایه یک مطالعه دقیق زبان‌شناختی از نظام صرفی زبان فارسی استوار است. پارس‌مورف قادر است ساخت درونی کلمه فارسی را از حیث نظام تصریف و واژه‌سازی تجزیه و تحلیل کند و برای هر کدام از اجزا در درون کلمه عنوان و نقش زبانی خاصی اختصاص دهد. در اجرای این تحقیق پس از صورت‌بندی دقیق نظام تصریف و واژه‌سازی، الگوریتم عملیاتی برنامه تحلیل‌گر فارسی پی‌ریزی و تکمیل شد. پارس‌مورف به لحاظ نظری بر پایه علمی استوار است و نسخه اول آن قادر است با دقت بالای ۹۵٪ ساخت درونی کلمات فارسی را تجزیه و تحلیل کند و با

افزودن اطلاعات مربوطه به هم‌نویسه‌ها و افزودن اطلاعات نحوی و نیز رفع خطای برنامه که جزء جدانشدنی فرآیند توسعه نرم‌افزار است، این دقت به نزدیک ۱۰۰٪ خواهد رسید. پارس‌مورف می‌تواند در دو زمینه به‌طور کامل مجزا به کار گرفته شود و یاریگر محققان در این دو زمینه باشد. در مطالعات زبان‌شناختی محض؛ به عنوان مثال در تهیه منابع زبانی برای زبان فارسی و نیز در زمینه انواع پردازش خودکار زبان فارسی، به‌طور مشخص در تبدیل متن به گفتار، ترجمه ماشینی، استخراج اطلاعات، خلاصه‌سازی متون و غیره به کار گرفته شود.

۵- منابع

اسلامی، محرم، شریفی آتشگاه، مسعود، علیزاده لمجیری، صدیقه و زندی، طاهره. ۱۳۸۳. واژگان زبانی فارسی، مجموعه مقالات اولین کارگاه پژوهشی زبان فارسی و رایانه، دانشگاه تهران، تهران.

اسلامی، محرم و علیزاده، صدیقه. ۱۳۸۸. ساخت تصریفی کلمه در زبان فارسی، زبان و ادب فارسی، نشریه دانشکده ادبیات و علوم انسانی دانشگاه تبریز، سال ۵۲، شماره مسلسل ۲۱۱، ایران.

شمس‌فرد، مهرنوش. ۱۳۸۸. STeP1: تهیه متن معیار برای زبان فارسی. آزمایشگاه پردازش زبان طبیعی، دانشگاه شهید بهشتی، ایران.

طباطبائی، علاءالدین. ۱۳۷۶. فعل بسیط فارسی و واژه‌سازی، مرکز نشر دانشگاهی تهران، ایران.

طباطبائی، علاءالدین. ۱۳۸۲. اسم و صفت مرکب در زبان فارسی، مرکز نشر دانشگاهی، تهران، ایران.

کشانی، خسرو. ۱۳۷۱. اشتقاق پسوندی در زبان فارسی امروز، مرکز نشر دانشگاهی تهران، ایران.

کلباسی، ایران. ۱۳۷۱. ساخت اشتقاقی واژه در فارسی امروز. موسسه مطالعات و تحقیقات فرهنگی، تهران، ایران.

Bauer, Laurie., 1983. English Word- Formation, CUP, Cambridge.

Booij, Geert., 2007. The Grammar of Words, 2nd edition, Oxford University Press.

Megerdooimian, Karine., 2000. Persian Computational Morphology, A Unification-Based Approach, NMSU, CRL, Memoranda in Computer and Cognitive Science, (MCCS-00-321).



وحید مواجی مدرک کارشناسی خود را

در رشته مهندسی کامپیوتر در سال ۱۳۸۳ از دانشگاه علم و صنعت ایران اخذ نمود. وی در سال ۱۳۸۵ مدرک کارشناسی ارشد خود را در رشته

مهندسی کامپیوتر از دانشگاه صنعتی شریف دریافت نمود. وی همچنین از سال ۱۳۸۹ در رشته زبان‌شناسی رایانشی در مقطع کارشناسی ارشد در دانشگاه صنعتی شریف مشغول به تحصیل می‌باشد. زمینه‌های تحقیقاتی وی شامل زبان‌شناسی رایانشی، صرف و مهندسی نرم‌افزار می‌باشد.

نشانی رایانامک ایشان عبارت است از:

vaji@alum.sharif.edu



محمدرضا اسلامی در سال ۱۳۷۰ در رشته

مترجمی زبان انگلیسی از دانشگاه علامه طباطبائی فارغ‌التحصیل شد. سپس در سال ۱۳۷۳ در رشته زبان‌شناسی همگانی دوره کارشناسی ارشد را دانشگاه تهران

به پایان رسانید و در سال ۱۳۷۹ در همان رشته و همان دانشگاه موفق به اخذ مدرک دکترا شد. از ایشان بیش از ۳۰ مقاله در نشریات و همایش‌های داخلی و خارجی به چاپ رسیده است، و همچنین صاحب تألیفاتی می‌باشند. وی هم‌اکنون عضو هیئت علمی دانشگاه زنجان می‌باشد و زمینه‌های تخصصی ایشان، زبان‌شناسی همگانی، واج‌شناسی آهنگ و آواشناسی و پردازش رایانه‌ای زبان طبیعی (NLP) می‌باشد.

نشانی رایانامک ایشان عبارت است از:

meslami@znu.ac.ir



بهرام وزیرنژاد به عنوان عضو هیات علمی

در دانشگاه صنعتی شریف مشغول به فعالیت آموزشی و پژوهشی است. ایشان دکترای خود را در رشته مهندسی پزشکی از دانشگاه صنعتی امیرکبیر دریافت نموده

است. وی طی سال‌های ۲۰۰۷ تا ۲۰۰۸ به عنوان پژوهشگر مهمان در دانشگاه سیدنی مشغول به فعالیت تحقیقاتی بود. از او حدود ۲۰ مقاله در کنفرانس‌ها و نشریات معتبر داخلی و خارجی به چاپ رسیده است. تحقیقات ایشان شامل حوزه‌های پردازش گفتار و زبان طبیعی، تعامل انسان و ماشین، هوش مصنوعی و زبان‌شناسی رایانشی می‌باشد.

نشانی رایانامک ایشان عبارتست از:

bahram@sharif.edu

فصلنامه



سال ۱۳۹۰ شماره ۱ پیاپی ۱۵

