

بررسی نظام واژه‌سازی به روش تجزیه تکوازی صوری

کاترین کریکونیوک (دانشجوی دکترای زبان‌شناسی در انسٹیتوی کریم‌سکی، کی‌یف، اوکراین)

سیستم امروزی واژه‌سازی زبان فارسی نتیجه تحول پیچیده تاریخی واژگان فارسی است. رایج‌ترین نوع فرایند واژه‌سازی در زبان فارسی (افزوond پیشوond و پسوند) مختص همه زبان‌های هندو‌اروپایی است. اما، در زبان فارسی، فرایند افزودن پسوند غالب است. زبان فارسی، به جز واژگانی که از زبان‌های ایرانی به ارت برده است، دارای لایه‌هایی گرانبار از واژه‌های به وام گرفته از زبان‌های عربی و ترکی و فرانسه و یونانی و جز آن است که، به شیوه‌های گوناگون، نظام واژه‌سازی زبان فارسی را تحت تأثیر قرار داده‌اند. با این حال، اغلب اوقات، ارزیابی همبستگی وام واژه‌ها و واژه‌های اصیل به صورت حسّی انجام می‌گیرد و نیاز به پژوهش دقیق‌تری دارد.

۱. معرفی روشن تجزیه تکوازی صوری

تحقیق در واژه‌سازی، گامی الزامی در راستای ایجاد تصوّر کلی از ساختار هر زبانی است. پیچیدگی نظام واژه‌سازی هر زبانی از رابطه تنگاتنگ آن با سطوح ساختاری دیگر زبان و انعطاف‌پذیری نظام و عدم امکان تمایز ساخت واژه (word formation) و صرف واژه (inflection) همچنین او تنوع و اهمیّت ارتباطی کارکردهای نظام ساخت واژه ناشی می‌شود.

دانشمندان بسیاری، مستقیم یا غیر مستقیم، موضوع ساخت واژه در زبان فارسی را مطالعه کرده‌اند. از پژوهشگران روسی و غربی، روبینچیک^۱، پیسیکوف^۲، اوچینیکووا^۳، بریلس^۴ و میس لِمْتن^۵ را می‌توان نام برد. زبان‌شناسان ایرانی از قبیل پرویز خانلری، خسرو فرشیدورد، علی‌اشرف صادقی، علاءالدین طباطبائی، و رضائی باعبدی به تحقیق در واژه‌سازی زبان فارسی پرداخته‌اند. برخی از نکات تکواژشناسی فارسی در پژوهش‌های زبان‌شناسی رایانه‌ای کارن مگردویان، محسن عرب سرخی، مهرنوش شمس‌فرد، و ساگوت و والتر^۶ معکس شده‌اند. اما، با وجود توصیف‌های گرامری متعدد زبان فارسی، تابه حال نظام ساخت واژگان فارسی به حیث کُلِّ چند بعدی و منشعب بررسی نشده است.

یکی از اولین تلاش‌ها در زمینه تحقیق درباره نظام واژه‌سازی زبان فارسی با استفاده از روش تکواژی صوری، به همت بیدوف^۷، زیرنظر پروفسور تیشچنکو^۸، در پایان نامه‌ای با عنوان «ساختار تکواژی زبان فارسی»^۹ براساس واژه‌نامه فارسی-ژاپنی آکازاکی (حدود شش هزار واژه)، صورت گرفت.

تکواژشناسی صوری، در سال‌های شصت قرن پیش، در چارچوب زبان‌شناسی ساختگرای روسی، پدید آمد. یکی از روش‌های مهم آن تجزیه تکواژی صوری است که اصول آن را بر اتچیکوف^{۱۰}، فیتیالوف^{۱۱}، و تسیتین^{۱۲}، به منظور ترجمه ماشینی در زمینه صرف واژه، معرفی کرده‌اند. در سال‌های ۱۹۶۳-۲۰۰۳، تیشچنکو، با اختیار روش تجزیه تکواژی صوری، تحقیق در نظام صرف واژه زبان‌های گوناگون را، با مروری بر نظام‌های زیرمجموعه‌ای صرف فعل در زبان‌های فرانسه و ایتالیایی و پرتغالی و اسپانیائی و فارسی و فنلاندی، انجام داد و آن پژوهشی بود در الگوهای تکیه^{۱۳} در واژه‌سازی اسمی زبان روسی همچنین تحلیل الگوهای صرف واژه‌های پُرکاربرد اوکراینی.

1) Yu. A. Rubinčik 2) L. S. Pešikov

3) I. K. Ovčinnikova

4) E. Ye. Beriels

5) A. K. S. Lambton

6) B. Saqor & G. Walter

7) O. Bedov

8) K. M. Tyschenko

9) "Morphological structure of the Persian language"

10) I. Bratchikov

11) S. Firjatov

12) G. Tseitin

13) accentuation models

روش تجزیهٔ تکوازی صوری مؤثرترین روش شناخت ساختار واژه شمرده می‌شود (۱۶, ۵→) که امکان به دست آوردن اطلاعاتی درباره واژه از راه تقطیع دقیق آن و دسته‌بندی همزمان اطلاعات به دست آمده را فراهم می‌سازد (Ibid, 25→). امکانات ترکیب‌بندی تکوازها (در زبان‌شناسی همزمانی) همیشه محدود است. از این‌رو، انتظار می‌رود که روند تجزیهٔ تکوازی مراحل محدودی را طی کند (۱۶, Ibid→). به علاوه، جنبهٔ صوری این روش اجازه می‌دهد که نسبت‌ها میان سازه‌های واژه‌ای اجمالاً نشان داده شود و ماهیّت آن نسبت‌ها ارزیابی و ساختار منطقی کل سیستم مشخص گردد.

در تجزیهٔ تکوازی صوری^{۱۴} هر سیستم زبانی، مجموعه‌ای از اصول روش شناختی اولیّه به کار می‌رود که شامل تمامیت، سادگی، هم‌ریختی، و صوری بودن تحقیق است.

تمامیت تجزیهٔ تکوازی، با استقرار همهٔ پدیده‌های زبان در حوزهٔ موضوع بررسی در مرحلهٔ اولیّه تحقیق، تأمین می‌شود که در یک یا چند منبع درج شده است.

садگی در تجزیهٔ تکوازی با انتخاب ابزار سادهٔ مطالعهٔ زبان و شفاف‌سازی روند تجزیه و تحلیل حاصل می‌شود و بررسی مجدهٔ کامل و بدون مغایرت با پژوهش‌صورت گرفته را امکان‌پذیر می‌سازد. در این مورد، باید مراقب بود که ابزار مطالعهٔ زبان از خودِ موضوع تحقیق پیچیده‌تر نباشد.

در فرمول‌بندی ریاضی‌وار، استفاده از دستگاه نشانه‌های صوری برای تکوازها و مقوله‌های دیگر واژه‌سازی ضرورت دارد. شیوهٔ سنتی برای نشان دادن مشخصات گرامری هر واژه پذیرفته نیست.

هم‌ریختی با اجتناب از تلفیق التقاطی ابزار متناقضی حاصل می‌شود که در چارچوب روش‌های دیگری پدید آمده‌اند. هم‌ریختی همچنین به انتخاب موضوع تحقیق مربوط می‌شود که مستلزم توجه تمام به گروه پدیده‌هایی است که وقوع^{۱۵} آنها بیشتر است و نه پدیده‌های دارای وقوع نادر. (11, 3→)

استفاده از نشانه‌هایی به منظور ترسیم نظام کلی واژه‌سازی در زبان فارسی تجزیهٔ ترکیب‌ها را امکان‌پذیر می‌سازد. فرمول نشانه‌گذاری واژه‌ها به صورت زیر است:

14) formalized morphological description

15) occurrence

$$R'' = mR' \cdot m_1 m R' \cdot 2 \dots$$

در این فرمول، R رادیکال (ریشه) یا واژه‌ای تجزیه‌ناپذیر در یکی از مقولات صرفی است که با نشانه‌های Aj (صفت) و Ad (فعل) و $Verb$ (قید) و N (اسم) و جز آن علامت‌گذاری می‌شود؛ m پیشوند یا پسوند است که عیناً با حروف لاتینی نوشته می‌شود. علامت ثانیه $(")$ به این معناست که واژه ترکیبی است و از یک یا چند رادیکال (ریشه) و یک یا چند وند تشکیل می‌شود. (\rightarrow)

کلمات مرکب، به ترتیب، به کوچک‌ترین واحدهای معنی‌دار و دارای نقش دستوری (تکواز) تجزیه می‌شوند. با این فرمول‌بندی، رهایی از معنی واژه و تمرکز روی ساختار میسر می‌گردد. به عنوان مثال:

$$behbudi-N'' = Aj+ W^*+ i$$

$$mi\ a'jam-i-Aj'' = Aj+ i$$

$$pesarâne-Ad'' = N+ \bar{ane}$$

$$xandidan-Verb'' = W+ an$$

از این مثال‌ها پیداست که، در قدم بعدی، الگوهای واژه‌سازی^{۱۶} به دست آمده بدون هیچ مشکلی گروه‌بندی می‌شوند که برای فهمیدن ساختار کلی نظام واژه‌سازی در زبان فارسی حائز اهمیت است.

۲. قواعد زبان‌شناختی در نظام واژه‌سازی زبان فارسی امروز

با کاربرد روش‌های آماری در زبان‌شناسی، کسب نتایج دقیق از پدیده‌های موضوع بررسی و مطالعه روابط آنها میسر می‌گردد.

قانون استو-زیپف^{۱۷} ناظر به نسبت تجربی توزیع کلمات در همه زبان‌هاست با توجه به بسامد آنها به ترتیب از بالا به پایین. امروزه این نسبت را با نام قانون زیپف می‌شناسند، هرچند زیپف تنها اظهار نظرهای استو و کُندُن^{۱۸} را کامل کرد (75، 4 →). زیپف، در اثر خود،

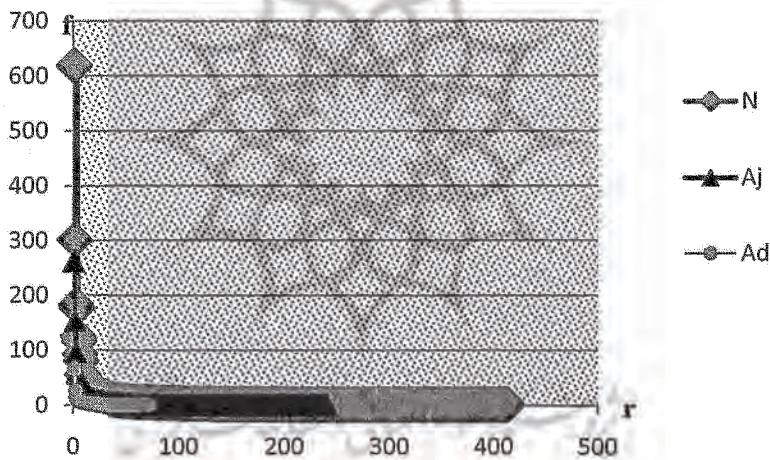
16) word formation patterns

17) Estoup-Zipf's law

18) Estoup J. B., E. Condon

زیست‌شناسی روان^{۱۹} (۱۹۳۵)، نشان داده است که بسامد واژه با رتبه آن (شمار تکواژه‌ای سازنده آن) نسبت معکوس دارد (۸۹، ا→). وی، در فرمول استو-گُندَن، ثابت γ را وارد کرد ($rf^Y = \text{const}$) که باید برای هر متنی محاسبه شود. زبان‌شناسان و ریاضی‌دانان دیگری از قبیل گیرو، ایول، ماندلبرُت، هرڈَن، برادْفورِد، هرثُر^{۲۰} این فرمول را کامل‌تر کردند. فرمول نهائی با افزودن چند متغیر به دست آمده و با داده‌های تجربی مطابقت بیشتری کرده است. قانون استو-زیپف، مانند همه مدل‌های آماری، ناظر به نزدیک شدن به واقعیّت است. در نمودار، این نسبت به صورت منحنی هذلولی درمی‌آید. (۲۲، ۶→)

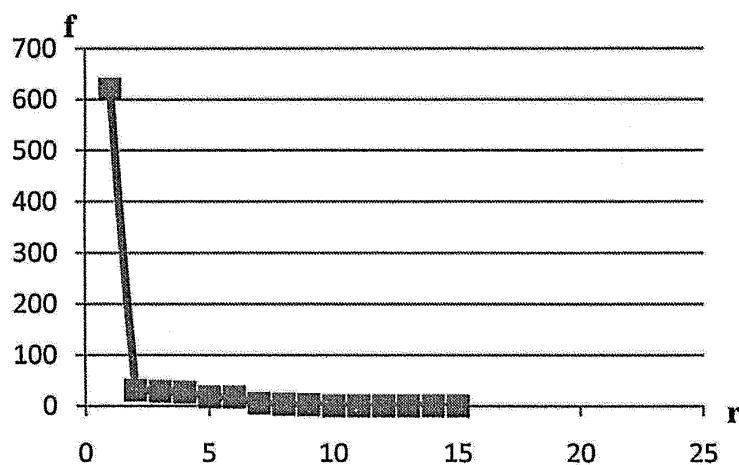
تجزیه تکواژی صوری بر روی واژه‌های واژه‌نامه نوین محمد قریب (۲۹۱۶۲ واژه) کارآمدی قانون استو-زیپف را در ساختار نظام واژه‌سازی زبان فارسی نمودار ساخت یعنی نشان داد که، هرچه رتبه عناصر (تکواژه‌ها) در واژه‌سازی بالاتر باشد، بسامد آنها کمتر است.



شکل ۱-قانون استو-زیپف ۱: توزیع رتبه‌ای-بسامدی مدل‌های واژه‌سازی اسم‌ها و صفت‌ها و قیدهای ترکیبی. آن شأنه شمار واژه‌هایی است که در مدل واژه‌سازی مندرج است. ۲-رتبه مدل واژه‌سازی است.

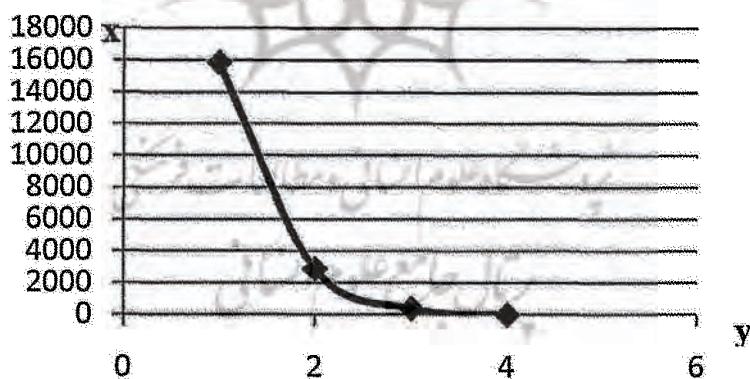
19) *The Psychobiology of Language. An Introduction to Dynamic Philology*. Boston, 1935.

20) P. Guiraud, G. Udny Yule, B. Mandelbrot, G. Herdan, S. C. Bradford, M. B. Arapov, Herz.

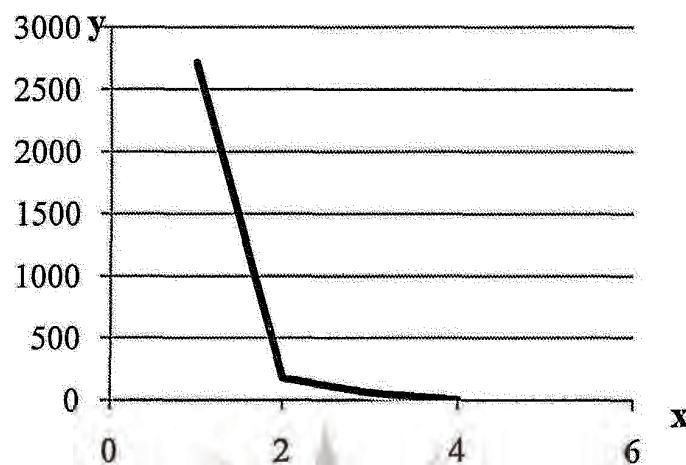


شکل ۲-قانون استو-زیپف ۱: توزیع رتبه‌ای-بسامدی مدل‌های واژه‌سازی فعل‌های ترکیبی.
 نشانهٔ شمار واژه‌هایی است که در مدل واژه‌سازی مندرج است؛ نشانهٔ رتبه مدل واژه‌سازی است.

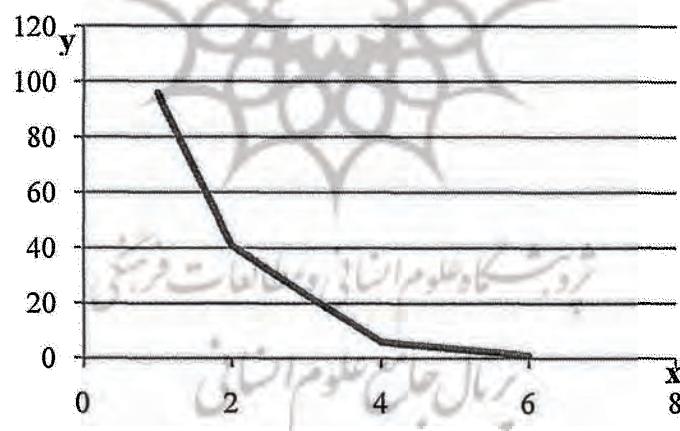
توزیع مدل‌های واژه‌سازی با در نظر گرفتن شمار تکواژها در آنها کارآمدی قانون استو-زیپف ۲ را نمودار ساخت یعنی نشان داد که هرچه شمار تکواژها در مدل‌های واژه‌سازی کمتر باشد، بسامد شمار مدل‌ها (ترکیبات) بیشتر می‌شود.



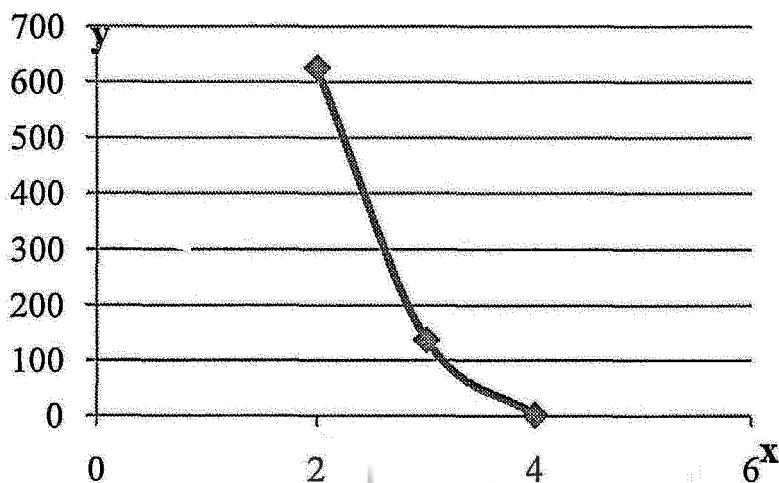
شکل ۳-قانون استو-زیپف ۲: توزیع مدل‌های واژه‌سازی اسم با در نظر گرفتن شمار تکواژها.
 نشانهٔ شمار واژه‌ها؛ نشانهٔ شمار تکواژها در مدل‌های واژه‌سازی است.



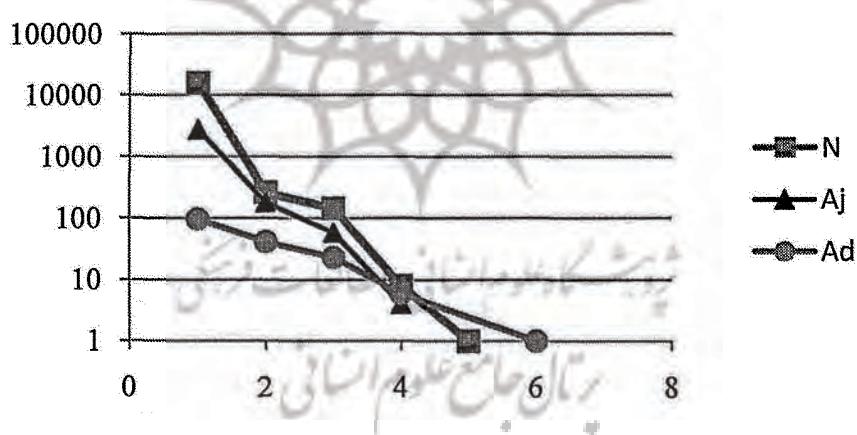
شکل ۴- قانون استو-زیپف ۲ توزیع مدل‌های واژه‌سازی صفت با درنظر گرفتن شمار تکواژها.
x نشانه شمار واژه‌ها؛ y نشانه شمار تکواژها در مدل‌های واژه‌سازی است.



شکل ۵- قانون استو-زیپف ۲ توزیع مدل‌های واژه‌سازی صفت با درنظر گرفتن شمار تکواژها.
x نشانه شمار واژه‌ها؛ y نشانه شمار تکواژها در مدل‌های واژه‌سازی است.



شکل ۶- قانون استو-زیپف ۲ توزیع مدل‌های واژه‌سازی فعل با درنظر گرفتن شمار تکوازها.
x نشانه شمار واژه‌ها؛ y نشانه شمار تکوازها در مدل‌های واژه‌سازی است.



شکل ۷- قانون استو-زیپف ۲ توزیع مدل‌های واژه‌سازی اسم و صفت و قید با درنظر گرفتن شمار تکوازها. (مقیاس لگاریتمی)
x نشانه شمار واژه‌ها؛ y نشانه شمار تکوازها در مدل‌های واژه‌سازی است.

نتیجه

در این مقاله، روش نوین بررسی نظام واژه‌سازی در زبان فارسی معرفی شده است. تجزیهٔ تکوازی صوری یکی از مؤثرترین روش‌های شناخت ساختار واژه است که کسب اطلاعاتی درباره واژه را از راه تجزیه آن و دسته‌بندی اطلاعات به دست آمده می‌سرمی‌سازد. طی تجزیهٔ تکوازی صوری هر دستگاه زبانی، مجموعه‌ای از اصول روش شناختی اوّلیه به کار می‌رود که تمامیت، سادگی، همپیوستگی، و خصلت صوری تحقیق را تضمین می‌کنند. کاربرد تجزیهٔ تکوازی صوری کارآمدی قانون استو-زیپف را در مطالعهٔ ساختار نظام واژه‌سازی زبان فارسی آشکار ساخته است.

منابع

1. Creutz, M. (2006). *Induction of the Morphology of Natural Language: Unsupervised Morpheme Segmentation with Application to Automatic Speech Recognition*. Dissertation for the Degree of Doctor of Science in Technology, Helsinki University of Technology (Espoo, Finland), p. 110.
2. Бєдов О. Морфологічна структура сучасної перської лексики (дипломна робота) / Олександр Бєдов. - Київ: 1997. (Препрінт).
3. Исследования в области вычислительной лингвистики и лингвостатистики. Сборник. Ответственный редактор-доцент В. М. Андрющенко. М., Изд-во МГУ, 1978. - 191 с.
4. Орлов'. К. Невидимая гармония. Сб. «Число и мысль». Вып. 3. - М.: «Знание», 1980. - С. 70-105.
5. Тищенко К. М. Глагольная парадигма романских языков/ дис. на соиск. уч. ст. канд. филолог. наук / К. Н. Тищенко. - Киев, 1969. - 160 с.
6. Тищенко К. М. Основи мовознавства: Системний підручник / Костянтин Миколайович Тищенко. - Київ: 308 с.: Видавничо-поліграфічний центр «Київський університет», 2007.

کتابنامه

- Dolamic, L. & Savoy, J. (2009). *Persian Language, is Stemming Efficient?* Available at:<http://www.uni-weimar.de/medien/webis/research/events/tir-09/tir09-papers-final/dolamic09-persian-language-is-stemming-efficient.pdf>.
- Lambton, A. K. S. (2003). *Persian Grammar*. Cambridge: Cambridge University Press, p. 332.

- MEGERDOOMIAN, K. (2000). *Unification-based Persian morphology*. Available at:
<http://citeserx.ist.psu.edu/viewdoc/download?doi=10.1.1.27.6355&terp=terp1&type=pdf>.
- Овчинникова, И., Мамед-заде, А.К. Учебник персидского языка. (Часть 1). -
Москва: Издательство Московского Университета, 1966. - 444 с.
- Бертельс Е. Э. Грамматика персидского языка. - Ленинград: Издание
Института живых восточных языков им. А. С. Енукидзе, 1926. - 127 с.
- Братчиков И. Л., Фитиалов С. Я., Ценчтин Г. С. О структуре словаря и
кодировке информации для машинного перевода. // В кн.: Материалы по
машинному переводу. - Л.: Изд-во ЛГУ, 1958. - с. 61-87.
- Конверський А. Є. Логіка (традиційна та сучасна): Підручник для студентів
вищих навчальних закладів. - Київ: Центр учебової літератури, 2008. - 536 с.
- Лингвистический энциклопедический словарь // Под ред. В. Н. Ярцевой.
Москва: «Советская энциклопедия», 1990. - 685 с.
- Рубинчик . А. Грамматика современного персидского литературного
языка. - М.: Издательская группа «Восточная литература» РАН, 2001.
- 600 с.
- Рубинчик . А. Предисловие // Персидско-русский словарь / [ред.]
- Рубинчик . А.]. В 2-хт. - 1.1. - М.: Сов. Энциклопедия, 1970. - С. 5-16.
- Тищенко К. М. Оптимальна морфологія перського дієслова // Вісник КДУ.
Іноз. Філологія. Вип. 25. - К.: КДУ, (о, 3, %, е).
- Тищенко К. М. Службові дієслова у підсистемі дієслів перської мови // К. Н.
Тищенко, А. Півторак // III сходознавці читання А. Кримського. Тези
міжнар. наук. конф. - К., 1999.
- Фитиалов С. Я. О построении формальной морфологии в связи с машинным
переводом: доклады на конференции по обработке информации,
машинному переводу и автоматическому чтению текста. - Москва:
Производственно-издательский комбинат ВИНИТИ, 1961. - 24 с.
- Фрумкна Р. М. Роль статистических методов в современных лингвистических
исследованиях // Математическая лингвистика. - М.: Изд-во «Наука»,
1973. - С. 165-182.
- Чурсин, Н. Н. Популярная информатика. - К.: Техника, 1982. - 158 с.

فرشیدورد، خسرو (۱)، فرهنگ پیشوندها و پسوندهای زبان فارسی (همراه گفتارهایی درباره دستور زبان فارسی)، انتشارات زقار، تهران ۱۳۸۶.

— (۲)، دستور مفصل امروز بر پایه زبان‌شناسی جدید: شامل پژوهش‌های تازه‌ای درباره آواشناسی و صرف و نحو فارسی معاصر و مقایسه آن باقواعد دستوری، انتشارات سخن، تهران ۱۳۸۲.
قریب، محمد، واژه‌دانه‌نوین، تهران ۱۳۴۶.

لغت‌نامه دهخدا، ۱۵ جلد، مؤسسه انتشارات و چاپ دانشگاه تهران ۱۳۷۷.

□

