



پژوهشگاه علوم انسانی و مطالعات فرهنگی



انجمن زبان‌شناسی ایران

هم اندیشی زبان فارسی در رایا سپهر

استخراج هستان شناسی برای دانشنامه معماری و شهرسازی

حامد ملک

دانشگاه صنعتی امیرکبیر

یحیی قابش

دانشگاه صنعتی شریف

۱۰ دی ۱۳۸۸



معرفی پروژه

- ❖ تشکیل پایگاه معرفتی عظیمی برای تاریخ معماری ایران از هزاره هفتم پیش از میلاد تا کنون
- ❖ انتشار محصول این طرح به صورت وبگاه
- ❖ دامنه جغرافیایی طرح همه جهان ایرانی (از سیحون تا خلیج فارس و از سند تا فرات) است.
- ❖ دامنه تاریخی موضوع طرح از روزگار پیش از تاریخ تا پایان دوره پهلوی اول را شامل می شود.



معرفی پژوهه

- ❖ دانشنامه متعارف ابزاری است که پیشینه تحقیق درباره عنوانی معین به نام «مدخل» را در اختیار عموم یا پژوهشگران قرار می دهد.
- ❖ در این دانشنامه همه محققان مؤلف بالقوه مقاله درباره هر مدخل شمرده می شوند.
- ❖ در این دانشنامه مداخل ثابت نیست و به ازای جستجو و نیاز مخاطبان، پیوسته بر مداخل افزوده می شود.
- ❖ اساس کار در این دانشنامه امکان جستجوی دقیق در همه مدارک مرتبط با تاریخ معماری و شهرسازی ایران زمین است.
- ❖ مجموعه اطلاعات به دو دسته «مدارک» و «مدخل» تقسیم می شوند.
- ❖ مدخل: واژه ای که اطلاعات حول آن گردآوری یا تولید می شود.
- ❖ مدرک: هر نوع منبع چاپی یا غیر چاپی مانند کتاب، فیلم، نسخه خطی و غیره است.



معرفی پروژه

- ❖ مجری این طرح فرهنگستان هنر و حامی اصلی آن وزارت مسکن و شهرسازی است.
- ❖ همکاران طرح: سازمان میراث فرهنگی، سازمان اسناد و کتابخانه ملی و دانشگاه شهید بهشتی
- ❖ طرح اکنون در مرحله تأسیس قرار دارد که هدف آن تهیه ۵۰۰۰ مدخل اولیه در وبگاه است.
- ❖ در مرحله کنونی زبان دانشنامه فارسی و انگلیسی است که در آینده به همه زبان هایی که اطلاعاتی در آن زبان وجود دارد گسترش خواهد یافت.



معرفی پروژه

<http://www.eiah.org>

The screenshot shows the homepage of the Encyclopedia of Iranian Architectural History. The main title is 'دانشنامه تاریخ معماری و شهرسازی ایران زمین' (Encyclopedia of Iranian Architectural History) in large, stylized Persian script. Below it is the subtitle 'encyclopedia of iranian architectural history'. On the left, there's a sidebar with sections like 'اصطلاحات' (Terms), 'کارنیوال' (Carnival), 'آخر' (Latest), 'تصویر کوچه‌ها' (Street view), 'نام جغرافیایی' (Geographical names), 'دوره تاریخی' (Historical period), 'عنوان اولیه' (Initial title), and 'آخرالالد و اخیرالعاد' (End of the world and beginning of the next). Each section has a small thumbnail image. The right side features a search bar, a navigation menu with items like 'جستجو', 'مستجد', 'مخفون اطلاعات دانشنامه', 'درباره دانشنامه', 'خبر دانشنامه', 'راهنمايی کاربران', 'تماس با دانشنامه', and 'الجمن'. There are also logos for 'دانشگاه پیشرفت' (University of Progress) and 'IRANIAN ACADEMY OF THE ARTS'. The bottom right corner has a watermark for 'دانشنامه تاریخ معماری و شهرسازی ایران زمین'.

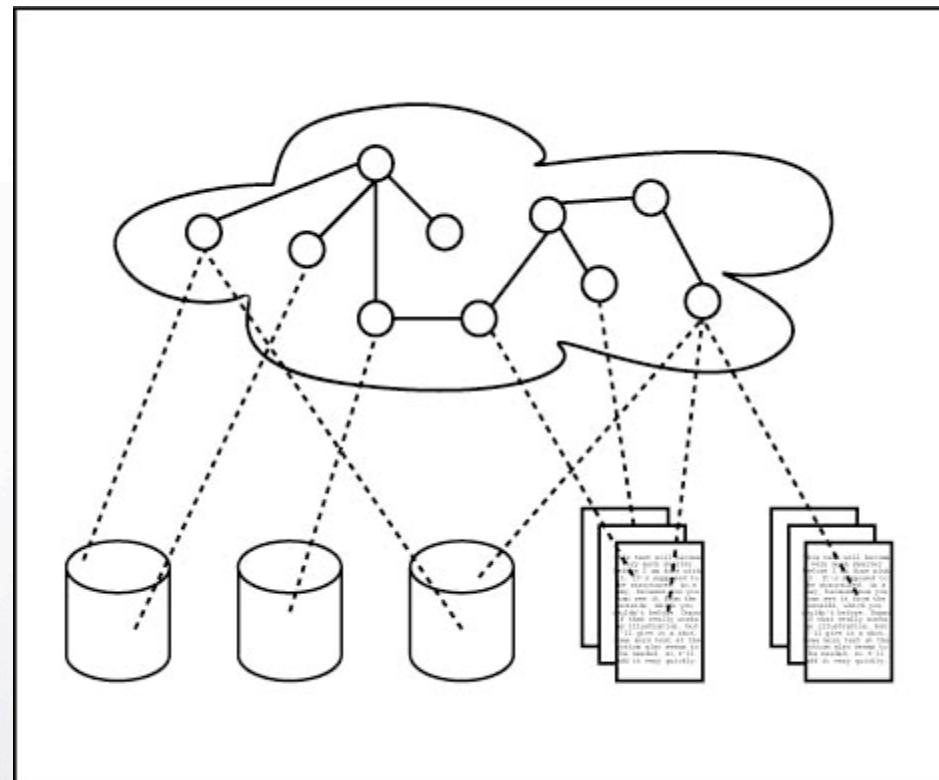


معماری اطلاعاتی

- ❖ استاندارد مورد استفاده برای بازنمایی و تبادل دانش استاندارد «مدل موضوعی» یا Topic Maps است.
- ❖ در این مدل، اطلاعات با استفاده از سه مفهوم موضوعات، وابستگی‌ها و رخدادها بازنمایی می‌شوند.
- ❖ موضوع: نماینده یک مفهوم مانند شخص، مکان، رویداد و غیره وابستگی: نحوه ارتباط بین موضوعات رخداد: نمایش رابطه بین موضوعات و منابع اطلاعاتی مرتبط
- ❖ مدل موضوعی را می‌توان نوع خاصی از فناوری وب معنایی دانست.

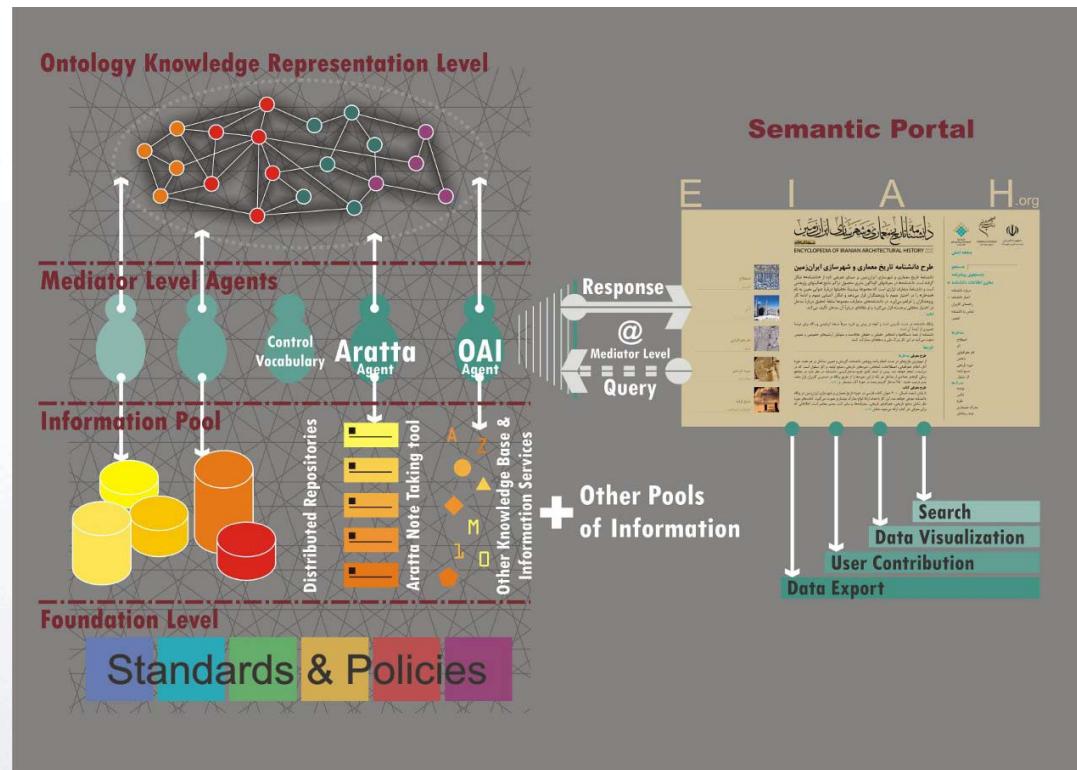


معماری اطلاعاتی





معماری اطلاعاتی





هستان شناسی

هستان شناسی سنگین

هستان شناسی سبک

مدل های مفهومی

(تعریف طبقات، ویژگی و روابط آنها)



معماری اطلاعاتی

پروژه آرَته

جستجوی تقریبی

پروژه استخراج اسامی خاص

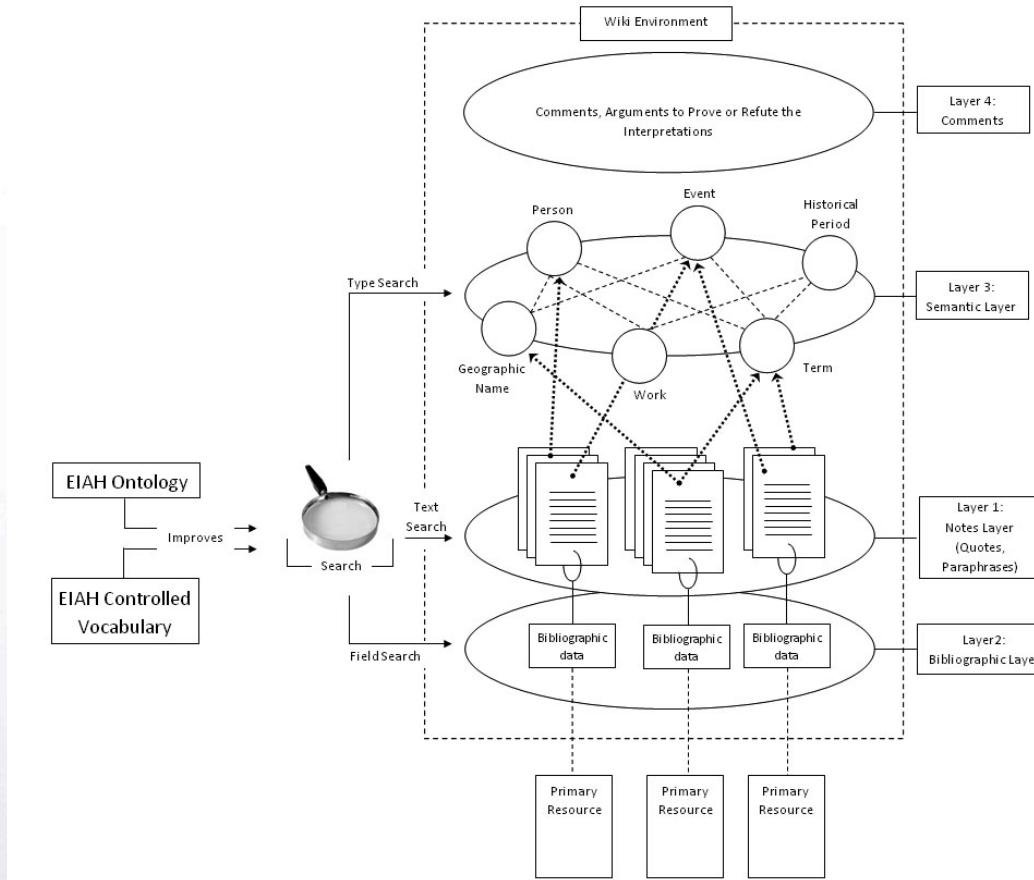


پروژه آرته

- ❖ هدف: ایجاد یک کتابخانه معنایی از یادداشت‌های تحقیقاتی
- ❖ نام پروژه برگرفته از نام تمدن باستانی گمشده‌ای به نام آرته است.
- ❖ بیش از ۱۰ هزار یادداشت تحقیقاتی



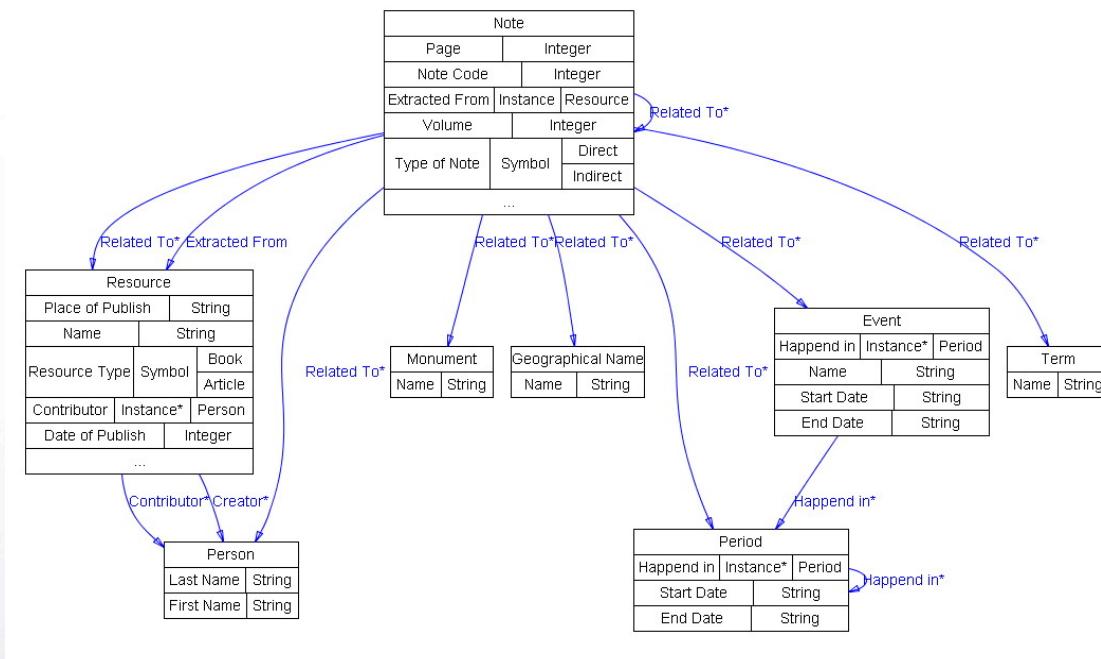
پروژه آرته



نمودار مدل داده



پروژه آرته



هستان شناسی آرته



پروژه آرته

❖ مدياويكي (Mediawiki)

❖ سمنتيك مدياويكي (Semantic Mediawiki)

❖ سمنتيك فرم (Semantic Form)

❖ استاندارد دابلين كور (Dublin Core)



جستجوی تقریبی

- ❖ هدف: یافتن عبارات و زیررشته هایی که تفاوت قابل اغماض با رشته مورد جستجو دارند.
- ❖ جستجوی تقریبی بی نقص نیاز وسیع به اطلاعات زبانی، واژگانی، معنایی و مانند آن دارد.
- ❖ در این پروژه به پیاده سازی شیوه هایی که توسط الگوریتم ها و جداول ساده قابل پیاده سازی هستند پرداخته شده است.
- ❖ برای این منظور از توصیف «جستجوی تقریبی برای زبان فارسی ایران» تهیه شده توسط شرکت فارسی وب شریف استفاده شده است.



جستجوی تقریبی

- ❖ غلط های کدگذاری: مانند استفاده از ناستاندارد از حروف عربی به جای حروف فارسی
- ❖ غلط های املایی معمول یا نامحسوس: مانند نوشتن کلمه «مؤمن» به شکل «مومن»
- ❖ تفاوت در اعراب گذاری عبارات و وجود یا عدم وجود نویسه های ضمیمنی
- ❖ همه موارد فوق در قالب این پروژه به موتور جستجوی آزاد لوسن «Lucene» پیاده سازی شده و قابل استفاده برای عموم است.



تشخیص اسامی خاص

- ❖ با توجه به حجم بالای متون نوشتاری و نیاز به برچسب‌گذاری آنها برای تولید مناسب هستان شناسی، استفاده از روش‌های خودکار یک الزامی است.
- ❖ ترجیح روش‌های آماری بر روش‌های زبان شناسی به دلیل استقلال روش از زبان
- ❖ انتخاب کتابخانه معنای آرته به عنوان منبع اصلی استخراج اسامی خاص
- ❖ پیاده سازی الگوریتم با کمک ابزارهای آزاد موجود



تشخیص اسامی خاص

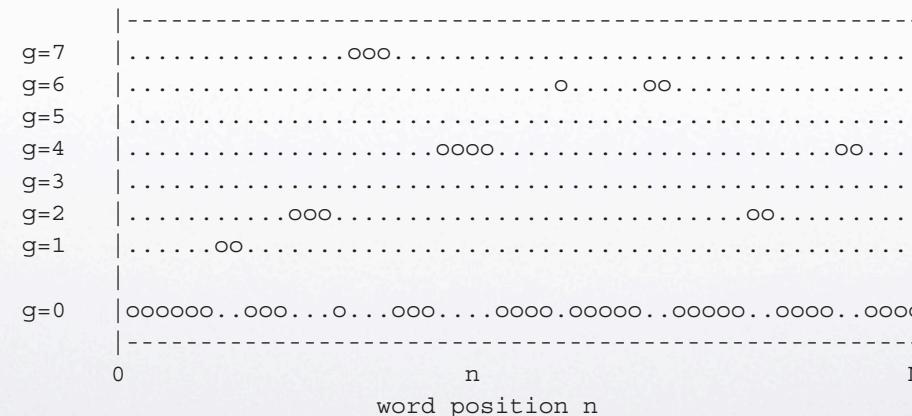
- ❖ اسامی به ۶ دسته یا کلاس تقسیم می شوند.
- ❖ اصطلاح: آتشگاه، خاتم کاری، کاروان سرا
- ❖ اثر: معبد آناهیتا، مسجد جامع اصفهان، حمام علی قلی آقا
- ❖ نام جغرافیایی: آباده، دریای مازندران، کرمان
- ❖ دوره تاریخی: آل بویه، ساسانیان، صفویه
- ❖ شخص: سلطان سنجر، لطف علی خان زند، شاه عباس
- ❖ منبع اولیه: آثار عجم، سلجوق نامه، سفرنامه ناصر خسرو



تشخیص اسمی خاص

دنباله ورودی: $w_1^N = w_1 \dots w_n \dots w_N$

دنباله خروجی: $g_1^N = g_1 \dots g_n \dots g_N$





تشخیص اسمی خاص

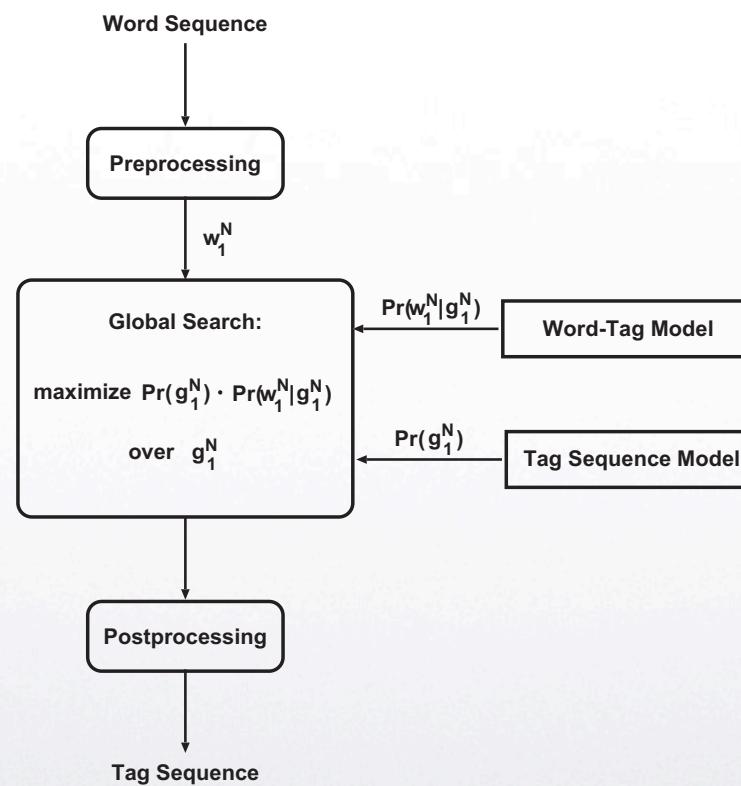
ایده اصلی مشابه روش معمول آماری برای POS Tagging است.

قانون تصمیم‌گیری بیز:

$$\begin{aligned} w_1^N \rightarrow \hat{g}_1^N &= \arg \max_{g_1^N} Pr(g_1^N | w_1^N) \\ &= \arg \max_{g_1^N} \{Pr(g_1^N, w_1^N)\} \\ &= \arg \max_{g_1^N} \{Pr(g_1^N) \cdot Pr(w_1^N | g_1^N)\} \end{aligned}$$



تشخیص اسمی خاص





تشخیص اسامی خاص

$$\arg \max_{g_1^N} Pr(g_1^N | w_1^N) = \arg \max_{g_1^N} \{Pr(g_1^N) \cdot Pr(w_1^N | g_1^N)\}$$

احتمال تعلق: مدل مرتبه صفر

$$Pr(w_1^N | g_1^N) = \prod_{n=1}^N p_0(w_n | g_n)$$

احتمال بایگرام POS: مدل مرتبه یک

$$Pr(g_1^N) = \prod_{n=1}^N p_1(g_n | g_{n-1})$$

آموزش: هر دو توزیع احتمالاتی بالا را با کمک نمونه های دستی تخمین می زنیم.



تشخیص اسامی خاص

$$\begin{aligned} p_0(w|g) &= \frac{p(w,g)}{p(g)} \\ &= \frac{p(w) \cdot p_0(g|w)}{p(g)} \end{aligned}$$

مسئله بهینه سازی نهایی:

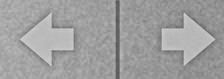
$$\arg \max_{g_1^N} Pr(g_1^N|w_1^N) = \arg \max_{g_1^N} \left\{ \prod_{n=1}^N \left[\frac{p_0(g_n|w_n)}{p(g_n)} \cdot p_1(g_n|g_{n-1}) \right] \right\}$$

برای حل مسئله بهینه سازی بدست آمده از روش برنامه ریزی پویا استفاده می کنیم.



تشخیص اسمی خاص

- ❖ تفاوت اصلی با POS Tagging در طول برچسب ها است که می تواند بیش از یک باشد.
- ❖ برای این منظور از یک مدل ساده طول استفاده می شود:
- ❖ هر برچسب با دو برچسب «شروع» یا «ادامه» جایگزین می شود.



تشخیص اسامی خاص

قانون تصمیم‌گیری بیز:

$$\begin{aligned} w_1^N \rightarrow \hat{g}_1^N &= \arg \max_{g_1^N} Pr(g_1^N | w_1^N) \\ &= \arg \max_{g_1^N} \{ Pr(w_1^N) \cdot Pr(g_1^N | w_1^N) \} \\ &= \arg \max_{g_1^N} \{ Pr(g_1^N, w_1^N) \} \end{aligned}$$

$$\begin{aligned} Pr(g_1^N, w_1^N) &= \prod_n Pr(g_n, w_n | g_1^{n-1}, w_1^{n-1}) \\ &= \prod_n [Pr(g_n | g_1^{n-1}, w_1^{n-1}) \cdot Pr(w_n | g_1^n, w_1^{n-1})] \end{aligned}$$

$$\begin{aligned} Pr(g_1^N, w_1^N) &= \prod_n Pr(g_n, w_n | g_1^{n-1}, w_1^{n-1}) \\ &= \prod_n [Pr(g_n | g_1^{n-1}, w_1^{n-1}) \cdot Pr(w_n | g_1^n, w_1^{n-1})] \end{aligned}$$



تشخیص اسامی خاص

قانون تصمیم‌گیری بیز نهایی:

$$\arg \max_{g_1^N} Pr(g_1^N | w_1^N) = \arg \max_{g_1^N} \left\{ \prod_n [p(g_n | g_{n-1}, w_{n-1}) \cdot p(w_n | g_{n-1}^n, w_{n-1})] \right\}$$

فرض اضافه:

$$p(w_n | g_{n-1}^n, w_{n-1}) = \begin{cases} p(w_n | g_n) & g_n = g_{n-1} \\ p(w_n | g_n, w_{n-1}) & g_n \neq g_{n-1} \end{cases}$$



تشخیص اسامی خاص

500	تعداد فیش های آموزش
56343	تعداد کلمات آموزش
100	تعداد فیش های آزمایش
12330	تعداد کلمات آزمایش

2862	اصطلاح
1347	اثر
842	نام جغرافیایی
107	دوره تاریخی
392	شخص
101	منبع اولیه



کارهای آینده

- ❖ هوشمندسازی الگوریتم های جستجو با کمک روش های پردازش زبان طبیعی
- ❖ استفاده از تکنیک های آماری بهبود کیفیت تشخیص اسمی خاص
- ❖ استفاده از تکنیک های زبان شناسی در الگوریتم تشخیص اسمی خاص



اطلاعات پیشتر

❖ وبگاه دانشنامه معماری و شهرسازی ایران زمین: www.eiah.org

❖ وبگاه پروژه آرته: <http://sohrab.eiah.org:3080/aratta>

hmalek@aut.ac.ir

tabesh@sharif.ir