

ایجاز: یک سامانه عملیاتی برای خلاصه‌سازی تک‌سندي متون خبری فارسی

آصف پورمعصومی، محسن کاهانی، سید احمد طوسی، احمد استیری و هادی قائمی

آزمایشگاه فناوری وب، گروه کامپیوتر، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

چکیده

امروزه با رشد چشم‌گیر اسناد منتشر شده در وب و نیاز اساسی به نگهداری، دسته‌بندی، بازیابی و پردازش آنها، توجه به پردازش زبان طبیعی و بهره‌گیری از ابزارهایی نظیر خلاصه‌سازی خودکار و مترجم‌های ماشینی، بیش از پیش احساس می‌شود. خلاصه‌سازی خودکار به عنوان هسته مرکزی طیف گسترده‌ای از ابزارهای پردازش‌گر متن مانند سامانه‌های تصمیم‌یاب، سامانه‌های پرسش‌وپاسخ، موتورهای جستجو و غیره از سال‌ها پیش مطرح شده و همواره به عنوان یک موضوع مهم مورد بررسی و تحقیق قرار گرفته است. در این مقاله، سامانه‌ای به نام «ایجاز» به منظور خلاصه‌سازی خودکار تک‌سندي متون فارسی ارائه شده است. در این سامانه از تجربیات سامانه‌های مشابه داخلی و خارجی استفاده شده است؛ و با استفاده از پارامترهای جدید، دقت سامانه خلاصه‌سازی ارائه شده به میزان قابل توجهی بهبود یافته است. همچنین برای اولین بار با بهره‌گیری از یک پیکرۀ بزرگ خلاصه‌سازی و ابزار ارزیابی استاندارد، عملیات مقایسه و ارزیابی صورت گرفته است.

واژگان کلیدی: پردازش زبان فارسی، خلاصه‌سازی خودکار تک‌سندي، متون خبری.

۱- مقدمه

در وب امروزی با توجه به گسترش روزافزون حجم اطلاعات و داده‌های انتشار یافته، دسترسی مناسب به اطلاعات موردنیاز در کوتاه‌ترین زمان ممکن، همواره یکی از چالش‌های محققان و پژوهشگران حال حاضر است.

خلاصه‌سازی خودکار سند، تولید یک نسخه مختصرتر از سند اصلی توسط یک برنامه رایانه‌ای است؛ به نحوی که ویژگی‌ها و نکات اصلی سند اولیه حفظ شود (Mani, 1999).

سامانه‌های خلاصه‌سازی خودکار را می‌توان براساس اسناد ورودی به دو دسته تک‌سندي^۱ و چندسندي^۲ تقسیم کرد. در سامانه‌های خلاصه‌سازی تک‌سندي، ورودی سامانه خلاصه‌ساز تنها یک سند است؛ اما در سامانه‌های خلاصه‌سازی چندسندي، ورودی چندین سند با موضوعی

¹ Single Document

² Multi Document

سامانه SweSum همیشه اولین جمله به عنوان یکی از جمله‌های مهم متن در نظر گرفته می‌شود، در FarsiSum نیز به جمله‌های اول، وزن زیادی داده می‌شود که البته این موضوع، چندان مناسب نیست. تحقیقات آماری صورت گرفته بر روی پیکره پاسخ (Behmadi, 2013) (این پیکره شامل متون خبری و خلاصه‌های مربوط به آنها است) نشان می‌دهد که شناس انتخاب شدن جملات پایانی در متن خلاصه، حدوداً برابر با نصف شناس حضور جملات ابتدایی است. این مطلب تا حدودی با معیار تعریف شده در خلاصه‌سازهای ماشینی یادشده متفاوت است.

سامانه ارائه شده در (کریمی، ۱۳۸۵)، یک خلاصه‌ساز تک‌سندي است که عملکردش بر مبنای گزینش جملات است. در این سامانه برای گزینش جملات خروجی از یک روش ترکیبی استفاده شده که ترکیبی از دو روش، زنجیره‌لغوی و نظریه گرف است و خروجی نهایی می‌تواند کلی یا بر اساس پرس‌وجوی کاربر باشد. در (مشکی، ۱۳۸۶) پس از بررسی چالش‌های مربوط به پردازش متون فارسی، انواع روش‌های موجود در خلاصه‌سازی مورد بررسی قرار گرفته است. در (مشکی، ۱۳۸۸) یک نمونه ابزار برای خلاصه‌سازی متون فارسی پیاده‌سازی شده است. این ابزار برای خلاصه‌سازی چندسندي متون فارسی مورد استفاده قرار گرفته و مدل خروجی آن انتخابی بوده و از یک روش مبتنی بر خوشبندی بهره می‌گیرد. در (اخوانت، ۱۳۸۷) سامانه PARSUMIST ارائه شده است که با استفاده از رویکرد آماری و در نظر گرفتن تعدادی از ویژگی‌های زبان‌شناسی زبان فارسی، خلاصه را تولید می‌کند.

در (Honarpisheh, 2007) یک سامانه خلاصه‌ساز چندسندي چندزبانی ارائه شده است که براساس^۱ SVR^۲ عمل می‌کند. خلاصه حاصله، از نوع گزینشی بوده، روش مورد استفاده جزو دسته آماری محسوب می‌شود. در (ستوده، ۱۳۸۹) با الهام از شیوه انسان در تفکر، به جای گزینش مهم‌ترین جملات، زنجیره‌ای از جملات در متن انتخاب می‌شود که با یکدیگر، همبستگی و ارتیاط بیشتری داشته باشند. اگرچه ممکن است هر یک از جملات زنجیره، به تنها یکی مهمن باشند؛ اما ممکن است با در نظر گرفتن جملات در زنجیره، پازلی را تکمیل کنند و این پازل در کل بیان گر مفهوم متن است. در این خلاصه‌سازی، هدف آن است که از هر پاراگراف، جمله‌ای برجسته به شکلی انتخاب

می‌کند و فاقد زیرم موضوعات ضد و نقیض خواهد بود (Mihalcea, 2005) (Svore, 2007).

انسان‌ها با توجه به هوش و شعور ذاتی خود قادر به درک و فهم مفاهیم موجود در متن و ارتباط بین آنها هستند و این در حالی است که انجام این عملیات توسط ماشین، کار سیار دشوار و پیچیده‌ای است.

هدف نهایی سامانه‌های خلاصه‌سازی، تولید خلاصه‌هایی با کیفیت نزدیک به خلاصه‌های انسانی است؛ اما برای رسیدن به این مهم، چالش‌های زیادی وجود دارد. مهم‌ترین مشکل در گام نخست، انتخاب مناسب‌ترین جملات متن اصلی است به نحوی که مطالب مهم و اصلی متن را پوشش داده و در عین حال فاقد افزونگی و جملات تکراری یا شبیه بهم باشد. عمدۀ تمرکز سامانه‌های خلاصه‌سازی به این موضوع اختصاص دارد.

پردازش‌هایی که بر روی متن‌های زبان طبیعی صورت می‌گیرد اغلب نیازمند عملیات پیش‌پردازش است؛ به طوری که دقت این پیش‌پردازش‌ها تأثیر بهسزایی بر نتایج اعمال الگوریتم‌ها در مراحل بعدی دارد. هرقدر دقت این پیش‌پردازش‌ها بیشتر باشد، الگوریتم‌ها به نتایج واقعی خود نزدیک‌تر خواهند شد.

ساختار این مقاله به شرح زیر است. در بخش دوم مروری بر کارهای گذشته و در بخش سوم روش پیشنهادی برای خلاصه‌سازی تک‌سندي متون فارسی ارائه خواهد شد. ارزیابی کار نیز در بخش چهارم آمده است. در پایان نیز نتیجه‌گیری و کارهای آینده ذکر شده است.

۲- مروری بر کارهای گذشته

لازم به ذکر است که کارهای انجام‌شده در زمینه پیاده‌سازی ابزارهای خلاصه‌سازی خودکار فارسی، بسیار اندک هستند (Dalianis, 2000) (Poormasoomi, 2011) (Kiyoumarsi, 2011) (Mazdak, 2004) (آخوانت، ۱۳۸۷) (کریمی، ۱۳۸۵) (مشکی، ۱۳۸۸) (مشکی، ۱۳۸۶) (ستوده، ۱۳۸۹). سنجش صحت و دقت روش‌های مطرح شده، بهدلیل عدم استفاده از یک پیکره متون متحدد و ابزار ارزیابی یکپارچه و استاندارد، قابل محاسبه و قیاس نیست.

از جمله خلاصه‌سازهای خودکار برای زبان فارسی می‌توان FarsiSum را نام برد (Mazdak, 2004) که نسخه تغییریافته SweSum است (Dalianis, 2000) که برای متون سوئی مورد استفاده قرار می‌گیرد. با توجه به اینکه ایده اصلی این سامانه بر مبنای سامانه SweSum است و در

¹ Support Vector Regression



بزرگ‌ترین زیررشته مشترک و کلیدوازه‌ها را پیاده‌سازی کرده است.

در (2009) Schilder، سامانه FastSum نیز ابتدا یک مرحله پیش‌پردازش انجام می‌گیرد که نشانه‌گذاری و جداسازی جملات را به عهده دارد؛ سپس روال ساده‌سازی جملات انجام می‌شود تا اجزای بی‌همیت جمله را حذف کند. تمام جملاتی که در کلماتشان حداقل دو تطابق کامل و یا سه تطابق فازی با توصیف موضوع^۳ نداشته باشند، حذف می‌شوند. چهار ویژگی که در این روش استفاده می‌شوند عبارتند از: فرکانس عنوان موضوع، فرکانس توصیف موضوع، فرکانس کلمه محتوا و فرکانس سند. درنهایت خلاصه نهایی از فهرست جملات وزن داده شده و بعد از مرحله حذف اطلاعات اضافی، حاصل می‌شود.

در این مقاله با در نظر گرفتن تمامی عوامل دخیل در خلاصه‌سازی و همچنین ارائه پارامترهای جدید، سامانه ایجاز برای خلاصه‌سازی تک‌سنندی متون فارسی ارائه شده است که خلاصه تولید شده را نسبت به سایر سامانه‌های خلاصه‌ساز موجود به‌طور قابل ملاحظه‌ای بپسود بخشیده است.

شود که ارتباط و همبستگی خوبی با جملات برجسته پارگرافهای دیگر داشته باشد.

در (2011) Kiyomarsi، با بهره‌گیری از خلاصه‌سازی فازی، سعی شده است با استفاده از ویژگی‌های خاص زبان و همچنین منطق فازی، متن ورودی به شکلی مناسب خلاصه شود. از آنجا که این خلاصه‌سازی، گرینشی بوده و سعی در انتخاب جملات مهم‌تر و مناسب‌تر برای خلاصه دارد، یک سری ویژگی برای جملات تعریف می‌شود و منطق فازی برای انتخاب جملات، استفاده شده است. در (Poormasoomi، 2011) با ارائه یک روش جدید برای استخراج روابط معنایی موجود در متن (LSA^۱) و استفاده از تکنیک برچسب‌زنی معنایی نقش لغات (SRL^۲)، روشنی جدید برای خلاصه‌سازی ارائه شده است.


با توجه به اینکه در سال‌های گذشته، ابزار و پیکرۀ مناسب برای ارزیابی خلاصه‌سازها وجود نداشته است، به همین دلیل ارزیابی مناسبی از سامانه‌های معرفی شده، موجود نیست. در ادامه، مهم‌ترین خلاصه‌سازهای موجود برای سایر زبان‌های دنیا معرفی خواهند شد.

سامانه CATS یک سامانه خلاصه‌سازی چندسندی با توجه به عنوان مشخص شده توسط کاربر است (Farzindar، 2005). در این سامانه ابتدا اسناد به صورت موضوعی تجزیه شده و سپس این موضوعات با موضوعات مشخص شده در سؤال، تطبیق داده می‌شوند. قسمت‌های موضوعی که شامل موارد مرتبط با موضوع است، فهرست شده و با توجه به احتمالشان مرتب می‌شوند. بخش‌هایی که به سایر بخش‌ها شباهت دارند، حذف شده و در مرحله آخر جملات با بیشترین امتیاز تا زمانی که خلاصه‌ای شامل حداقل ۲۵۰ کلمه ایجاد شود، انتخاب می‌شوند.

MEAD یکی از معروف‌ترین سامانه‌های خلاصه‌سازی چندسندی است (Radev، 2004). نسخه ۱ و ۲ این خلاصه‌ساز در دانشگاه میشیگان در سال ۲۰۰۱ – ۲۰۰۰ پیاده‌سازی شده است. در حال حاضر نسخه‌های انگلیسی، چینی، زانپی و هلندی آن موجود است. سامانه MEAD با استفاده از خوشه‌بندی، جملات مرکزی در هر خوشه را شناسایی کرده و خلاصه‌هایی را تولید می‌کند. این سامانه، الگوریتم‌های مختلفی از خلاصه‌سازی از جمله الگوریتم‌های مبتنی بر موقعیت، مبتنی بر مرکز جرم،

۳- روش پیشنهادی

در پیاده‌سازی سامانه ایجاز از روال شکل (۱) برای خلاصه‌سازی متون استفاده می‌شود.



(شکل - ۱): روال به کار رفته در سامانه ایجاز جهت خلاصه‌سازی متون زبان فارسی

در سامانه طراحی شده برای خلاصه‌سازی تک‌سنندی متون، عملیات زیر به ترتیب انجام می‌شود:

^۳ Topic Description

انتخاب متن ورودی:

نرم‌السازی متن: در اولین گام باید متن برای استفاده در گام‌های بعدی به شکلی استاندارد درآیند. این اصلاحات شامل یکسان‌سازی انواع نویسه‌ها نظیر «ی» عربی و «ی» فارسی و موارد مشابه است. همچنین اصلاحات دیگری نیز بهمنظور پردازش دقیق‌تر متن در این مرحله صورت می‌گیرد که خارج از بحث اصلی این مقاله است.

(Shamsfard, 2011)

با توجه به اینکه به طور عمومی میزان فشرده‌سازی بسیار بالا است و خلاصه‌های تولیدی باید بسیار فشرده باشند، بنابراین باید متن کم‌همیت را حذف شوند. یکی از متونی که می‌تواند به عنوان متن کم‌همیت قلمداد شود، متنی است که به عنوان توضیح اضافه‌تر مطرح می‌شود. یکی از راه‌های ایجاد توضیح اضافه، استفاده از کلمات خاص مانند "متلاً" است؛ اما راه دیگری نیز وجود دارد که در آن، این اطلاعات اضافه، درون پرانتز یا علامتی شبیه به آن قرار می‌گیرند. این علامت، علامتی نظیر { }، []، () ... هستند. از آنجایی که هدف نهایی، خلاصه‌سازی متن و رسیدن به جملات اصلی است، می‌توان متون اضافه‌ای که در میان این علامت‌ها جهت توضیحات اضافه گنجانده می‌شوند، تشخیص داده و حذف کرد. برای انجام این کار نیز از عبارات منظم استفاده شده است. همچنین با استفاده از درخت تجزیه و بدست آوردن کلمات توصیفی و عبارات توصیفی در مورد افراد یا اماكن و یا نهادهای اسمی می‌توان آن عبارات را نیز حذف کرد.

جداسازی جملات: در این مرحله با استفاده از علائم جداکننده جملات و درنظرگرفتن یک سری قواعد خاص، جمله‌های تشکیل‌دهنده متن استخراج می‌شود. به عنوان مثال علامت نقطه همیشه پایان‌دهنده یک جمله نیست. این علامت می‌تواند به عنوان ممیز در یک عدد اعشاری هم لحاظ شود. از این‌رو می‌توان با توجه به اجزای قبل و بعد آن دقت نوع کاربرد آن را تا حدی قاعده‌مند ساخت.

جداسازی کلمات: جداسازی کلمات با استفاده از علائم جداکننده و با درنظرگرفتن اصلاحات اعمال‌شده در مرحله نرم‌السازی، انجام می‌شود.

حذف کلمات ایست: پس از جداسازی کلمات، در این مرحله، کلمات پر تکرار و بی‌همیت (ایست‌واژه‌ها) نظیر "که"، "است"، "در" و ... با استفاده از فهرست گردآوری شده، حذف می‌شوند (Tashakori, 2002).

ریشه‌یابی^۱: به منظور افزایش دقت پردازش‌های آماری، در این مرحله ریشه‌یابی کلمات انجام می‌شود.

اعمال عوامل مختلف تعیین اهمیت جملات: در این گام از پارامترهای مختلفی برای تعیین اهمیت جملات استفاده شده است. پس از محاسبه مقادیر این پارامترها برای هر یک از جملات، ترکیب خطی از این معیارها به عنوان وزن جمله که بیان‌گر میزان اهمیت آن است، محاسبه می‌شود. در ادامه جزئیات این معیارها و نحوه محاسبه آنها توضیح داده شده است.

مرتب‌سازی جملات بر اساس وزن: پس از محاسبه وزن

جملات، جمله‌ها براساس وزنشان مرتب‌سازی می‌شوند. انتخاب جملات براساس نرخ فشرده‌سازی: در گام نهایی جملات براساس نرخ فشرده‌سازی و به ترتیب اهمیتشان انتخاب شده و براساس موقعیتشان در متن اصلی، در خلاصه قرار داده می‌شوند. در این گام با استفاده از محاسبه شباهت معنایی جملات، جمله‌های تکراری حذف می‌شوند.

۱-۳ اعمال فاکتورهای مختلف جهت تعیین اهمیت جملات

برای تعیین جمله‌های مهم، باید پارامترهای مختلفی را در نظر گرفت. در این مرحله، با کمک دانشجویان زبان‌شناسی و افرادی که در تولید پیکره خلاصه‌سازی حضور داشته‌اند و همچنین با بهره‌گیری از روش‌های آماری، پارامترهای مختلفی که می‌تواند در اهمیت جملات، نقش داشته باشد، استخراج شده است. ویژگی‌های مهم جملات در جدول (۱) آورده شده است.

پس از تعیین هر یک از این فاکتورها برای جملات، ترکیب خطی این وزن‌ها، به عنوان وزن نهایی هر جمله در نظر گرفته می‌شود و درنهایت جملات با بیشترین وزن، متناسب با نرخ فشرده‌سازی، انتخاب خواهد شد. برای محاسبه وزن پارامترهای مختلف از روش‌های یادگیری ماشین می‌توان استفاده کرد. در این مقاله از روش کمترین مربعات برای محاسبه وزن فاکتورها استفاده شده است.

۱-۱-۳ میزان شباهت با زمینه

هر متنی که با شیوه نگارش مناسب، نوشته شده باشد، به‌حتیم دارای زمینه (Context) است. به‌طور عمومی در متن خبری تک‌سندي، تنها یک زمینه وجود دارد. برای انتخاب

¹ Stemming



کم است. هر چقدر جمله‌ای با استفاده از کلمات کمتری بتواند معنای بیشتری را منتقل نماید، اهمیت آن بیشتر خواهد بود. معیار زیر برای تعیین میزان اطلاع‌رسانی جملات در نظر گرفته شده است:

$$x_2^i = \frac{|S_{NS}^i|}{|S^i|} \quad (2)$$

در این رابطه $|S_{NS}^i|$ تعداد کلمات غیر ایست جمله i و $|S^i|$ هم طول جمله (برحسب تعداد کل کلمات) آن است.

۳-۱-۳- تأثیر طول جمله

به‌طور عمومی جملات با طول متوسط برای خلاصه‌سازی مناسب و جملاتی که دارای طول زیاد و یا طول خیلی کوتاه هستند، چندان مناسب خلاصه‌سازی نیستند. برای این‌که جملات خیلی طولانی و یا خیلی کوتاه در خلاصه انتخاب نشوند، می‌توان حد آستانه‌ای تعریف کرد و سپس جملاتی را که خارج از آن حد آستانه هستند، حذف کرد. البته در روش پیشنهادی، هیچ جمله‌ای براساس طول به صورت کامل حذف نمی‌شود. به‌همین دلیل معیار زیر برای مشخص کردن تأثیر طول جملات در نظر گرفته شده است:

$$x_3^i = -RS^i \cdot \log(RS^i) - (1 - RS^i) \cdot \log(1 - RS^i) \quad (3)$$

به‌طوری‌که

$$RS^i = \frac{|S^i|}{\text{Max}_{j=1:n}(|S^j|)}$$

در این معیار، RS^i اندازه نسبی طول جمله بر حسب کلمه است. نمودار پارامتر λ برای جملات مختلف در شکل (۲) نشان داده شده است. جملات دارای طول نسبی خیلی زیاد و یا خیلی کم ارزش کمتری در این پارامتر دارند.

۴-۱-۳- موقعیت جمله در متن

یکی از مهم‌ترین اصول حرفه‌ای نگارش متون خبری و علمی این است که جملات مهم در ابتدای متن قرار گیرند. برای متون انگلیسی این موضوع بارها و بارها آزموده و در سامانه‌های مختلف، نتایج آن بررسی شده است. با بررسی‌های انجام شده بر روی متون خبری فارسی این قاعده تا حدود زیادی تأیید می‌شود. البته به‌دلیل ضعف شیوه انتقال خبر و عدم حرفه‌ای بودن اکثر خبرگزاری‌ها، متأسفانه

جملات مهم، باید در ابتداء زمینه اصلی متن را استخراج کنیم. زمینه متن در حقیقت کلماتی هستند که با تکرارهای فراوان، اهمیت یک مفهوم خاص را در آن متن می‌رسانند. برای استخراج بردار زمینه متن، کارهای زیر انجام می‌شود:

۱. استخراج کلمات موجود در جمله؛
۲. حذف کلمات ایست؛
۳. ریشه‌یابی کلمات؛
۴. محاسبه فراوانی کلمات.

(جدول -۱): ویژگی‌های استخراج شده در مورد جملات متن

نماد	توضیح ویژگی
X ₁	میزان شباهت با زمینه
X ₂	تأثیر کلمات ایست
X ₃	تأثیر طول جمله
X ₄	موقعیت جمله در متن
X ₅	عبارات پر اهمیت
X ₆	تأثیر ضمایر
X ₇	عبارات اشاره و عبارات تعیین‌کننده درون جملات
X ₈	عبارات خاص
X ₉	میزان شباهت با عنوان متن

فرکانس کلمه w_j در جمله i که آن را با $F(w_j^i)$ نشان می‌دهیم، برابر است با تقسیم تعداد تکرار ریشه کلمه j ام از جمله i ام متن. پس از محاسبه بردار فرکانس کلمات که به عنوان بردار زمینه متن در نظر گرفته می‌شود، شباهت بردار جملات با بردار زمینه محاسبه می‌شود. برای تعیین شباهت بین جملات با بردار زمینه از فرمول زیر استفاده می‌شود:


رابطه (۱)

$$x_1^i = \frac{\sum_j F(w_j^i)}{\text{Max}_k \{\sum_j F(w_j^k)\}}$$

با توجه به رابطه (۱)، هر چه جمله‌ای شامل کلمات پر تکرار متن باشد، آنگاه شباهت آن با بردار زمینه بیشتر بوده و لذا اهمیت آن جمله بیشتر می‌شود.

۳-۱-۲- تأثیر کلمات ایست

گاهی اوقات تعداد کلمات یک جمله زیاد اما کلمات کلیدی و مهم آن کم است. به‌طور عمومی چنین جملاتی دارای تعداد زیادی کلمات ایست هستند و به‌همین دلیل بار معنایی آنها



(شکل-۳): نمودار تعیین اهمیت جملات براساس موقعیت نسبی آنها

۵-۱-۳- عبارات پراهمیت

برخی عبارات خاص درون جمله هستند که اهمیت جمله را افزایش می‌دهند. این عبارات درواقع اطلاعات خاص و مهمی را در اختیار قرار می‌دهند و همین امر موجب می‌شود جملات حاوی آنها اهمیت ویژه‌ای داشته باشند. البته تعیین میزان اهمیت هر یک از عبارات خاص می‌تواند سنته به نوع متن صورت گیرد. در این مقاله دسته‌های زیر برای عبارات خاص توصیه می‌شود:

تاریخ

زمان

عدد

قیمت

وزن

کلمات انگلیسی

نقل قول


درصد

اسامی خاص (افراد، مکان و زمان)

برای جمع آوری اسامی افراد از پیکره استاندارد همشهری استفاده شده (AleAhmad, 2009) است. پس از بررسی اطلاعات به دست آمده، مشخص شد برخی از این اسامی در سایر نقش‌ها نیز به کرات به کار می‌روند، از این‌رو از فهرست نهایی حذف شدند. نمونه‌هایی از این اسامی عبارتند از «پیام»، «نیاز»، «عظیم»، «بهمن» و غیره.

یکی از مسائلی که بهشت در تعیین اهمیت جملات و درنهایت خلاصه‌سازی کمک می‌کند، مشخص کردن اسامی مکان است. درواقع جملاتی که به مکان خاصی در قالب اسم مکان اشاره می‌کنند، می‌توانند اهمیت ویژه‌ای داشته باشند. می‌توان این اسامی را در گروه‌های:

در بخش زیادی از متون خبری، شاهد آن هستیم که جملات انتهایی، نیز می‌توانند جزء مهم‌ترین جملات باشند. به همین دلیل برای متون خبری فارسی، فرمول زیر برای تعیین اهمیت موقعیت جمله در متن پیشنهاد شده است:



(شکل-۲): نمودار ارزش‌گذاری جملات براساس معیار طول

$$x_4^i = \frac{PS^i}{Max_{j=1:n}(PS)} \quad \text{رابطه (۴)}$$

به طوری که

$$PS^i = 1 + (0.5 * (PS^i + C) * \log(0.5 * (PS^i + C))) + ((1 - 0.5 * (PS^i + C)) * \log(1 - 0.5 * (PS^i + C)))$$

در این رابطه x_4^i موقعیت نسبی جمله در متن است.

PS^i ارزش مؤثر موقعیت نسبی جمله i است که براساس ابتدا و انتهای متن به آن اضافه شده است. در این مقاله مقدار C به‌طور شهودی و با توجه به نمونه‌های متن خبری که توسط تیم تولید پیکره بررسی شده، به دست آمده که برابر با 0.47 در نظر گرفته شده است. نمودار تأثیر این پارامتر و میزان تفاوت جملات ابتدایی و انتهایی در شکل (۳) نشان داده شده است.

بدین ترتیب در رابطه به کار برد شده که مبتنی بر بررسی‌های آماری صورت گرفته بر روی پیکره پاسخ (Behmadi, 2013) است، جملات ابتدایی دارای اهمیت بیشتری حتی در مقایسه با جملات انتهایی هستند و جملات میانی در درجه اهمیت پایین‌تری قرار می‌گیرند.

فصل نهم
فصل نهم



در رابطه بالا $|S_{PR}|^i$ تعداد ضمایر موجود در جمله و BP_3^i در مواردی که ضمیر در سه کلمه اول ظاهر شود، برابر با یک و در بقیه موارد صفر است. در رابطه پیشنهادی، هر چه تعداد ضمایر بیشتر باشد وزن منفی جمله، بیشتر و اهمیت آن کمتر خواهد بود. همچنین درصورتی که ضمیر در سه کلمه اول جمله رخ دهد، وزن منفی آن بیشتر خواهد بود. برای یافتن ضمایر در جمله بایستی براساس فهرستی از ضمایر، جستجویی درون جملات صورت گیرد. فهرست ضمایر فارسی در جدول (۲) نشان داده شده است.

(جدول - ۲): لیست ضمایر فارسی

ضمیر پیوسته	مثال	ضمایر گستته	مثال
من	کتاب من	من	کتابم
تو	کتاب تو	تو	کتابت
او	کتاب او	او	کتابش
ما	کتاب ما	ما	کتابمان
شما	کتاب شما	شما	کتابتان
آنها	کتاب آنها	آنها	کتابشان

برای تعیین ضمایر از عبارات باقاعده^۱ جهت سرعت بیشتر در اجرای کار استفاده شده است. به این صورت که درون جملات به دنبال ضمایر در قالب عبارات باقاعده هستیم. تعداد و محل تطابق نیز مهم خواهد بود.

۳-۷-۱-۳- عبارات اشاره و عبارات تعیین‌کننده درون جملات

تعیین عبارات اشاره نیز می‌تواند تأثیر به سزایی در افزایش دقت خلاصه‌سازی داشته باشد. عبارات اشاره درواقع عباراتی هستند که برای اشاره به شخصی یا موضوعی خاص بیان می‌شوند. برای استخراج این عبارات نیز می‌توان از عبارات باقاعده استفاده کرد. به عنوان مثال به طور معمول قبل از نام افراد، کلماتی مانند «آقای»، «خانم»، «دکتر»، «حجت‌الاسلام»، «سرهنگ»، «سرپرداز»، «ستوان»، «سرلشگر»، «سردار»، «تیمسار»، «بانو» و از این قبیل موارد می‌آید. برخی عبارات اشاره نیز وجود دارند که وجود آنها درون جمله بر اهمیت جمله می‌افزاید. این قبیل عبارات می‌توانند مانند «در نتیجه»، «بنابراین»، «در مجموع» و «در پایان» باشند.

^۱ Regular Expression

اسامی کشورها

اسامی استان‌ها

اسامی شهرها

اسامی بخش‌ها

دسته بندی و استخراج کرد.

همان‌طور که ذکر شد اگر جمله‌ای دارای هر کدام از موارد فوق باشد براحتی آن افزوده می‌شود.

به منظور تشخیص عبارات خاص در متن، ابتدا قاعدة گرامری هر یک از دسته‌ها تعیین شده و برای هر کدام، جهت تطبیق یک عبارت باقاعده نوشته می‌شود.

پس از این‌که تعداد تکرار هریک از موارد بالا نسبت به طول جمله به دست آمد، ترکیب خطی آنها به عنوان وزن

x_5^i در نظر گرفته شد.

$$x_5^i = \frac{|S_{IMP}^i|}{|S^i|} \quad (5)$$

۴-۱-۶- تأثیر ضمایر

وجود ضمایر می‌تواند نشان‌دهنده عدم اهمیت جمله باشد چون ضمایر به چیزهای دیگری اشاره دارند که در جملات قبل آمده‌اند. به عبارت دیگر، جمله‌ای که حاوی ضمیر، به‌ویژه در کلمات ابتدایی جمله باشد، حاوی توضیحات بیشتر برای جمله‌ای است که ضمیر به آن ارجاع می‌دهد. بنابراین نسبت به جمله‌ای که به آن ارجاع داده شده، اهمیت کمتری دارد. همچنین وجود ضمیر در یک جمله درصورتی که عملیات ادغام ضمایر صورت نگیرد و جمله مرجع آن ضمیر هم در خلاصه انتخاب نشود، باعث می‌شود تا خوانایی خلاصه پایین بیاید. البته موقعیت ضمیر در جمله نیز اهمیت دارد. اگر ضمیری در کلمات ابتدایی جمله ظاهر شود، به‌طور تقریبی می‌توان گفت که آن جمله برای توصیف بیشتر جملات قبل است و به همین دلیل اهمیت کمتری دارد.

اگر ضمیر در کلمات میانی و انتهایی یک جمله ظاهر شود مشکل حالت قبل را ندارد؛ اما مشکلی دیگری که برای آن جمله پیش می‌آید، این است که خوانایی آن پایین می‌آید. به همین دلیل برای وجود ضمیر در جمله، ضرب منفی در نظر گرفته شده است. فرمول محاسبه تأثیر ضمیر در جمله به صورت زیر در نظر گرفته شده است:

$$x_6^i = -\frac{BP_3^i + |S_{PR}|^i}{1 + |S^i|} \quad (6)$$

۳-۹- میزان شباهت با عنوان متن

یکی از روش‌های قدیمی و ابتدایی در خلاصه‌سازی متون، روش مبتنی بر عنوان است (Edmundson, 1969). در این روش، شباهت جمله با عنوان محاسبه و سپس جملاتی که بیشترین شباهت با عنوان را داشته باشند، به عنوان جملات خلاصه برگردانده می‌شوند. در روش پیشنهادی در سامانه طراحی شده هم این معیار تعییه شده است و در صورتی که کاربر عنوان خبر را وارد کند، خلاصه متن با توجه به عنوان تولید خواهد شد.

شباهت هر جمله با عنوان خبر با استفاده از رابطه زیر محاسبه می‌شود:

$$x_9^i = \frac{|S^i \cap T|}{\sqrt{|S^i| \cdot |T|}} \quad (9)$$

در رابطه بالا $|S^i \cap T|$ تعداد کلمات مشترک بین جمله S^i و عنوان بوده و مخرج کسر هم جذر حاصل ضرب طول جمله و عنوان (برحسب کلمه) است.

۳-۲- ترکیب فاکتورهای مختلف برای تعیین

جملات مهم و تولید خلاصه

پس از محاسبه ویژگی‌های مختلف که در بخش‌های پیشین به آنها پرداخته شد، ترکیب خطی این پارامترها به عنوان ارزش نهایی جملات در نظر گرفته می‌شود.

$$Y = W_0 + \sum_{i=1}^9 W_i X_i \quad (10)$$

برای محاسبه وزن پارامترهای مختلف از روش‌های یادگیری ماشین می‌توان استفاده کرد. یکی از این روش‌های پرکاربرد، بهره‌گیری از روش کمترین مربعات (Strutz, 2010) می‌باشد.

برای این منظور ابتدا پانزده سند خبری برای عمل خلاصه‌سازی انتخاب و به کمک پنج نفر از افراد خبره خلاصه‌های مرتبط تولید شد. پس از آنکه برای هر سند پنج خلاصه مجزا فراهم شد، میانگین نظرات داوران در مورد حضور (۱) یا عدم حضور (۰) هر جمله از متن اصلی در متن خلاصه به عنوان برچسب عددی جمله مربوطه تعیین شد.

همچنین جملات حاوی کلمات موجود در عنوان

اصلی مقاله یا خبر و کلمات کلیدی مشخص شده توسط کاربر، امتیاز بیشتری کسب می‌کنند. بدیهی است در صورتی که درون جمله، کلمه کلیدی وجود داشته باشد، آن جمله، مطلب مهمی را بیان می‌کند و بایستی نمره بالایی از لحاظ اهمیت به آن جمله، نسبت داده شود. البته برخی عبارات نیز درون جمله وجود دارند که باعث کاهش اهمیت جمله می‌شوند. از جمله این موارد می‌توان به «مثالاً»، «مانند»، «همانند» و «همچون» اشاره کرد. از نوع کلمات استفاده شده، معلوم است که جملات حاوی این عبارات، در صدد بیان توضیح بیشتری در مورد مطالب قبلی بیان شده هستند. درنتیجه در هنگام خلاصه‌سازی، گزینه مناسبی برای حذف از خلاصه نهایی هستند.

وزن مربوط به عبارات اسمی اشاره مثبت و منفی بهصورت زیر در نظر گرفته شد:

$$x_7^i = \frac{|S^i| + |S_{pp}^i| - |S_{NP}^i|}{2 \cdot |S^i|} \quad (7)$$

که $|S_{NP}^i|$ برابر است با تعداد کلمات اشاره مثبت در جمله A^i و $|S_{pp}^i|$ برابر است با تعداد کلمات اشاره منفی در جمله A^i است.

۳-۱-۸- عبارات خاص

عبارات خاص عباراتی هستند که با علائمی از قبیل گیوه و یا مانند آن از بقیه متن مجزا شده‌اند. بررسی متون خلاصه انسانی نشان می‌دهد متن‌های موجود در این بخش‌ها مورد توجه خلاصه‌گرهای انسانی قرار گرفته و لذا در سامانه پیشنهادی مؤلفه‌ای با همین عنوان برای تعیین میزان اهمیت جملات حاوی آنها نیز در نظر گرفته شده است.

$$x_8^i = \frac{|S_{SPC}^i|}{|S^i|} \quad (8)$$

که $|S_{SPC}^i|$ برابر با تعداد عبارات خاص به کار رفته در داخل علائم ذیل است:

«»، <>>, <>

$|S^i|$ هم طول جمله بر اساس تعداد کلمه است.

فصل نهم



بنابراین y_1 بیان‌گر مهم‌ترین جمله و y_m بیان‌گر کم‌اهمیت‌ترین جمله است؛ سپس با توجه به نرخ فشرده‌سازی، جملات با بیشترین وزن انتخاب می‌شوند.

(جدول-۲): مقدار تخصیص داده شده به پارامترها

مقدار	توضیح ویژگی	وزن
۹۱	مقدار فاصله از مبدأ	w_0
۱۰	میزان شباهت با زمینه	w_1
۸	تأثیر کلمات ایست	w_2
-۱	تأثیر طول جمله	w_3
۶	موقعیت جمله در متن	w_4
-۱۰	عبارات پر اهمیت	x_5
۲۹	تأثیر ضمایر	x_6
-۱۴۲	عبارات اشاره و عبارات تعیین‌کننده درون جملات	x_7
۲۰۸	عبارات خاص	x_8
۲۴	میزان شباهت با عنوان متن	x_9

(جدول-۳): نمونه نظرات داوران برای سه جمله s_i از متن

	E1	E2	E3	E4	E5	میانگین آراء
S1	1	1	0	1	1	0.8
S2	0	1	1	0	0	0.4
S3	1	0	1	1	1	0.8

برای اینکه در خلاصه تولیدشده، جملات تکراری وجود نداشته باشد، هر جمله نامزد، با جملات انتخاب شده قبلی مقایسه می‌شود و فقط در صورتی که شباهت آن با جملات قبلی از حد آستانه α کمتر باشد (در این سامانه $\alpha = 0.5$) در نظر گرفته شده است)، به عنوان جمله خلاصه، در نظر گرفته شده و به فهرست جملات انتخاب شده، افزوده می‌شود. برای تعیین شباهت جملات با یکدیگر هم معیار زیر در نظر گرفته شده است:

$$Sim(i, j) = \frac{|S^i \cap S^j|}{\sqrt{|S^i| \cdot |S^j|}} \quad (13)$$

که $|S^i|$ و $|S^j|$ به ترتیب طول جملات i و j است. در این سامانه α برابر با در نظر گرفته شده است.

مثال ۱: اگر بنابر جدول (۳)، متن اصلی یک سند شامل جملات $\{S_1, S_2, S_3\}$ فرض شود و E_5 نشان‌دهنده مجموعه افراد خبره باشد؛ آنگاه تلاقی سطر i ام و ستون z ام، بیان‌گر انتخاب (۱) یا عدم انتخاب (۰) جمله i ام توسط فرد خبره z ام است. میانگین داده‌های سطر i ام تعیین کننده برچسب جمله i ام است. این برچسب می‌تواند به عنوان میزان مقبولیت جمله مربوطه جهت انتخاب شدن برای قرارگرفتن در متن خلاصه تلقی شود. اگر مقدار برچسب برای یک جمله برابر با یک باشد به این معناست که این جمله توسط تمامی افراد خبره به عنوان جمله مهم، تشخیص داده شده و حائز بالاترین درجه اهمیت است. همچنین اگر مقدار برچسب جمله‌ای برابر با صفر باشد، نشان‌دهنده آن است که جمله مذکور توسط هیچ یک از افراد خبره به عنوان جمله مهم متن، تشخیص داده نشده و لذا دارای پایین‌ترین درجه اهمیت است.

پس از محاسبه بردار مؤلفه‌های هر یک از جملات متن اصلی (به صورتی که در بخش ۱-۳ بیان شد) و اختصاص برچسب هر جمله (به نحوی که در قسمت قبل بیان شد)، حال می‌توان با استفاده از روش LMS مقادیر مربوط به وزن هر مؤلفه (W_i) را بر اساس رابطه ۱۱ و ۱۲ محاسبه کرد.

$$Y_{n \times l} = X_{n \times p} \cdot W_{p \times l} \quad (11)$$


$$W = [X^T X]^{-1} [X^T Y] \quad (12)$$

در روابط ۱۱ و ۱۲، ماتریس X شامل بردارهای ویژگی کلیه جملات (با p مؤلفه) موجود در کل اسناد پیکره آموزشی است. همچنین برچسب هر یک از جملات مربوطه در بردار Y قرار داده شده است. با توجه به این نکته که میزان اهمیت هر جمله (v_i) را می‌توان به صورت ترکیب خطی مؤلفه‌های x_j ($1 \leq j \leq p$) توسط رابطه ۱۲ قابل ضرایب وزنی w_j محاسبه است.


در جدول (۲) مقادیر w_i های به دست آمده مربوط به پیکره آموزشی درج شده است.

برای خلاصه‌سازی سند ورودی جدید با m جمله، ابتدا بردار ویژگی (X) هر یک از جملات، تعیین و برآورد رابطه ۱۱ میزان اهمیت هر جمله (Y) مربوطه مشخص می‌شود. در ادامه بردار Y به صورت نزولی مرتب می‌شود.







(شکل-۵): رابطه نرخ فراخوانی مجدد با آستانه‌های حدی مختلف



(شکل-۴): رابطه خطای گزینش جملات با آستانه‌های حدی متفاوت



(شکل-۶): رابطه اندازه دقت با آستانه‌های حدی مختلف



(شکل-۷): رابطه اندازه معیار F با آستانه‌های حدی مختلف

بدیهی است هر چه میزان حد آستانه‌ای بیشتر باشد، تعداد جملات قابل استفاده در مجموعه خلاصه کمتر می‌شود.

جهت ارزیابی دقت وزن‌های محاسبه شده با استفاده از روش کمترین مجذور مربعات، مجدداً برچسب تمامی جملات پیکره به کمک رابطه خطی ارائه شده محاسبه شد. آنگاه برای محاسبه خطای اندازه‌گیری این روش از یک حد آستانه β برای تعیین انتخاب یا عدم انتخاب یک جمله در خلاصه نهایی استفاده شد. به عنوان نمونه اگر $\beta = 0.5$ باشد همه جملاتی در خلاصه نهایی منتخب افراد خبره قرار می‌گیرند که هم توانسته باشند در حداقل نیمی از خلاصه‌های تولیدشده توسط این افراد حضور یابند و هم برچسب به دست آمده از رابطه خطی مذکور از این حد آستانه‌ای بزرگتر باشد. در غیر این صورت در تشخیص جمله مناسب خطای رخ داده است. با این توصیف کیفیت روش محاسبه وزن‌های به دست آمده برای حدود آستانه‌ای مختلف مورد بررسی قرار گرفت.

در شکل (۴) نمودار خطابه‌ازی حدود آستانه‌ای متمایز نشان داده شده است. برای به دست آوردن حد آستانه‌ای مناسب به غیر از توجه به مقدار خطای نرخ دقت و نرخ فراخوانی مجدد نیز مورد ملاحظه قرار گرفته است. با فرض بازیابی 30% از جملات یک متن در فرآیند خلاصه‌سازی، همان‌گونه که در نمودارهای ۶، ۵ و ۷ نیز دیده می‌شود با انتخاب حد آستانه‌ای برابر با $4/0$ می‌توان به کمترین خطای ممکن دست پیدا کرد. در این مجموعه، مجذور مربعات خطای برای 782 جمله، حدود $5/9$ به دست آمده است.



توجه به اینکه تنظیم وزن‌ها براساس متون خبری صورت گرفته، لذا این پیکره بهترین گزینه برای ارزیابی خلاصه‌ساز پیشنهادی است. مشخصات این پیکره در جدول (۴) ذکر شده است.

(جدول -۴): مشخصات پیکرهٔ پاسخ

تعداد خلاصه‌ها به ازای هر سند	تعداد خبرگزاری‌های انتخاب شده	تعداد موضوعات	تعداد استناد پیکره
۵	۷	۶	۱۰۰

جهت ارزیابی خلاصه‌های تولیدشده نیاز به ابزاری جهت تعیین میزان شباهت خلاصه‌های تولید شده توسط انسان (خلاصه‌های هدف) و خلاصه‌های تولیدشده با ماشین است. به همین منظور برای ارزیابی کیفیت خلاصه‌های تولیدشده، از ابزار ارزیابی خودکار خلاصه‌سازی ماشینی^۲ (استری، ۱۳۹۱) استفاده شده است. این ابزار با استفاده از معیارهای شباهت مبتنی بر هم‌رخدادی، میزان شباهت بین خلاصه‌های انسانی و خلاصه‌های تولیدشده به وسیله ماشین را مشخص می‌کند.

تنها سامانه خلاصه‌ساز فارسی در دسترس (قابل دانلود یا روی خط) سامانه خلاصه‌ساز FarsiSum است. به همین دلیل از این سامانه برای مقایسه با سامانه تولیدشده، استفاده شده است. برای تولید خلاصه توسط سامانه FarsiSum، متون موجود در پیکرهٔ ایجادشده به FarsiSum داده شده و خلاصه‌های برگردانده شده در فایل ذخیره شدن. یکصد سند برای ارزیابی خلاصه‌سازی انتخاب شد. نرخ فشرده‌سازی هم سی درصد در نظر گرفته شد. از یکصد سند ورودی، سامانه FarsiSum تنها برای ۶۸ عدد از آنها، خلاصه تولید کرد. برای ۲۷ مورد هیچ گونه خلاصه‌ای برگردانده نشد. یک مورد، کل متن برگردانده شد و در چهار مورد هم سامانه با خطای نرم‌افزاری مواجه شده و خروجی مشخصی نداشت.

بنابراین با توجه به مشکلاتی که سامانه FarsiSum برای تولید خلاصه داشت، درنهایت ارزیابی برروی ۶۸ سند خبری انجام شد.

پس از اجرای دو نرم‌افزار به‌ازای ۶۸ سند موجود، خلاصه‌های تولیدشده، با استفاده از ابزار ارزیابی خلاصه‌سازی فارسی با خلاصه‌های انسانی مقایسه شدند که نتایج آنها به تفکیک معیار به کار رفته در ذیل آورده شده

^۲ این ابزار در آزمایشگاه فناوری و ب دانشگاه فردوسی مشهد تولید شده است.

۴- سامانهٔ ایجاز

سامانهٔ ایجاز در حال حاضر در مورد متون خبری با دقت بالا قابل استفاده است و می‌توان با بررسی انواع متون علمی، ادبی و غیره و در نظر گرفتن عوامل دخیل در خلاصه‌سازی هر کدام از انواع متون، سامانهٔ تولیدشده را گسترش داده و دقت آن را به‌ازای انواع متون بهبود بخشید. در تولید این سامانه، با بهره‌گیری از یک تیم خبره زبان‌شناسی، ویژگی‌های مهمی که در تولید خلاصه می‌توانند مؤثر باشند جمع‌آوری شد و در ادامه با استفاده از روش‌های یادگیری ماشین، ترکیب خطی ای از این پارامترها به عنوان وزن مؤثر جملات به کار گرفته شد.

این سامانه در دو نسخه تحت وب و تحت ویندوز تولید شد. در شکل (۸) تصویری از نسخه تحت وب را مشاهده می‌کنید که از طریق نشانی ijaz.um.ac.ir قابل استفاده است.




(شکل -۸): تصویری از نسخه تحت وب ایجاز

سامانهٔ تحت وب ایجاز قابلیت دریافت متن به سه صورت: (الف) فایل متنی (ب) متن (ج) نشانی اینترنتی صفحهٔ وب خبر را دارد و می‌توان نرخ فشرده‌سازی را نیز به دلخواه تولید کرد.

۵- ارزیابی

برای یک ارزیابی مناسب و دقیق، احتیاج به یک مجموعه داده مناسب و استاندارد است. به همین منظور، از پیکرهٔ استاندارد پاسخ^۱ با تعداد یکصد سند که با رعایت استانداردهای لازم تولید شده‌اند، استفاده شد. به علاوه با


^۱ این پیکره در آزمایشگاه فناوری و ب دانشگاه فردوسی مشهد تولید شده است.



(شکل-۱۱): مقایسه میانگین بررسی ویژه n گرم‌های مشابه در کل متن

۴-۵- ارزیابی با بررسی ویژه چند کلمه‌ای‌های مشابه در جملات


در این معیار، تمام نتایی‌های مشترک بین دو متن ($i < n$) در جملات، تشکیل و میزان انطباق آنها مورد ارزیابی قرار می‌گیرد. این معیار بیشترین شباهت به عملکرد امتیازدهی انسانی به خلاصه‌ها را دارد.



(شکل-۱۲): ارزیابی میانگین با بررسی ویژه n گرم‌های مشابه در جملات

۵-۵- ارزیابی با بررسی طولانی‌ترین زیر رشته مشترک

در این معیار ارزیابی، از الگوریتم‌های محاسبه طولانی‌ترین زیررشته مشترک بین دو رشته^۱ استفاده می‌شود.




(شکل-۱۳): ارزیابی میانگین با بررسی طولانی‌ترین زیررشته مشترک

است. نتایج سامانه طراحی شده در نمودار با برچسب Ijaz نمایش داده شده است.

۵-۱- ارزیابی با بررسی n گرم‌های مشابه در کل متن


این معیار، روشه است که مبتنی بر فراخوانی n نتایی‌ها بین یک خلاصه سیستمی و مجموعه‌ای از خلاصه‌های انسانی است. در این معیار تعداد n نتایی‌های مشترک بین خلاصه‌های انسانی و خلاصه ماشینی بر کل تعداد نتایی‌های موجود در خلاصه انسانی تقسیم می‌شود.



(شکل-۹): مقایسه میانگین n گرم‌های مشابه در کل متن

۵-۲- ارزیابی با بررسی n گرم‌های مشابه در جملات

در این معیار n نتایی‌هایی که مورد ارزیابی قرار می‌گیرند، فقط از لغات موجود در یک جمله و نه تمام متن ساخته می‌شوند.



(شکل-۱۰): مقایسه میانگین n گرم‌های مشابه در جملات

۵-۳- ارزیابی با بررسی ویژه چند کلمه‌ای‌های مشابه در کل متن

در این معیار به جای در نظر گرفتن تنها n نتایی‌های مشترک بین دو متن، تمام نتایی‌های مشترک بین دو متن ($i < n$) تشکیل و میزان انطباق آنها مورد ارزیابی قرار می‌گیرد.

فصل نهم
پردازش داده ها



¹ LCS (Longest Common Subsequence)

۶- نتیجه‌گیری و کارهای آینده

امروزه با توجه به حجم گسترده مطالب موجود و کمبود وقت و از طرفی ناکارآمدی سیستم‌های خلاصه‌سازی موجود، وجود یک سامانه قدرتمند برای خلاصه‌سازی حجم انبوه کتب، مقالات و اخبار در سطح وب بهشدت احساس می‌شود. چنان‌که شاهد هستیم علی‌رغم اینکه بحث خلاصه‌سازی از سال ۱۹۶۰ مطرح شده است، اما همچنان ضعف‌های زیادی در این زمینه وجود دارد و کارهای بسیاری برای رسیدن به وضعیتی مطلوب در این زمینه بایستی انجام پذیرد.

مشکل خلاصه‌سازی در زبان فارسی به‌مراتب بیشتر از زبان‌های دیگر است. پیچیدگی‌های زبانی موجود و همچنین عدم وجود ابزارهای با دقت مناسب برای کار با زبان فارسی از جمله مشکلات فعلی پردازش متون فارسی است. به عبارت دیگر با استفاده از ابزارهای پردازش متن دقیق‌تر، برای زبان فارسی می‌توان دقت نهایی مقادیر تولیدشده برای هر یک از ویژگی‌های استخراج شده در این مقاله را افزایش داد. از طرف دیگر توجه به حوزه معنایی و استفاده از رابطه‌های معنایی میان جملات و مفاهیم موجود در سند از دیگر پیشنهادهایی است که برای کارهای آتی می‌تواند مطرح شود.

سپاس‌گزاری

در این قسمت، لازم می‌دانیم از زحمات جناب آقای دکتر جهانگیری، دانشجویان گروه زبان‌شناسی و اعضای آزمایشگاه فناوری وب دانشگاه فردوسی مشهد به‌ویژه جناب مهندس رضا سعیدی، کمال سپاس‌گزاری را داشته باشیم.

مراجع


اخوانست، شمس فرد، عرفانی جوراچی، "PARSUMIST: خلاصه‌ساز تک‌سنندی و چندسنندی متون فارسی"، چهاردهمین کنفرانس ملی سالانه انجمن کامپیوتر ایران، دانشگاه صنعتی امیرکبیر، ایران، تهران، ۱۳۸۷.

استیری، احمد. کاهانی، محسن. کیوانلو شهرستانکی، زهره. پورمعصومی، آصف. "ارائه یک ابزار ارزیابی خودکار خلاصه‌سازهای ماشینی فارسی". چهارمین کنفرانس فناوری اطلاعات و دانش، دانشگاه صنعتی نوشیروانی بابل، ۱۳۹۱.

۶-۶- ارزیابی با بررسی ۲ کلمه‌ای‌های مشابه

با فاصله آزاد

به هر جفت کلمه (با حفظ ترتیب) در جمله، Skip-bigram گفته می‌شود. این معیار با اندازه‌گیری تعداد bigram‌های مشترک بین خلاصه ماشینی و خلاصه‌های مرجع محاسبه می‌شود.



(شکل - ۱۴): ارزیابی با بررسی ۲ گرم‌های مشابه با فاصله آزاد

۷- ارزیابی با بررسی تعداد لغات مشابه دو متن

به عنوان ساده‌ترین معیار شباهت دو متن می‌توان تعداد واژگان مشترک بین آنها را در نظر گرفت. در این معیار تعداد واژگان مشترک بین خلاصه ماشینی با هریک از خلاصه‌های انسانی محاسبه و بر تعداد کل واژگان در خلاصه‌های انسانی تقسیم می‌شود.



(شکل - ۱۵): ارزیابی با بررسی تعداد لغات مشابه دو متن

همان‌طور که مشخص است در تمامی معیارهای به کار رفته در ابزار ارزیابی خودکار خلاصه‌سازها، سامانه خلاصه‌ساز طراحی شده ایجاز برتری قابل ملاحظه‌ای نسبت به ابزار FarsiSum دارد. با توجه به اینکه پرداختن به جزئیات و ویژگی این معیارها خارج از حوزه این مقاله است، از ذکر توضیحات بیشتر در ارتباط با جنبه‌های کیفی این معیارها خودداری شده است؛ اما تفاوت قابل توجه سامانه ایجاز و FarsiSum در تمامی این معیارها، نشان‌گر عملکرد مناسب این سامانه است.

Mani, I., Maybury, M., "Advances in Automatic Text Summarization", The MIT Press, 1999.

Mazdak, N., Hassel, M., "FarsiSum-a persiantext summarizer", Master thesis, Departmentof linguistics, Stockholm University, 2004.

McKeown, K., Barzilay, R., Vasileios Hatzivassiloglou, D., "Tracking and Summarizing News on a Daily Basis with Columbia's Newsblaster", 2001.

Mihalcea, R. and Tarau, P. "An Algorithm for Language Independent Single and Multiple Document Summarization". In Proceedings of the International Joint Conference on Natural Language Processing, Korea, 2005.

Poormasoomi, A., Kahani, M., Varasteh, S., Kamyar, H., "Context-based Persian multi-document summarization (global view)", IALP, Malaysia, 2011.

Radev, D., Allison, T. et all, "MEAD - A platform for multidocument multilingual text summarization.", In Proceedings of the 4th International Conference on Language Resources and Evaluation (LREC 2004), Lisbon, Portugal, May 2004.

Shamsfard, M., "Challenges and open problems in Persian text processing," in 5th Language & Technology Conference (LTC): Human Language Technologies as a Challenge for Computer Science and Linguistics, 2011, pp. 65-69.

Strutz, T., "Data Fitting and Uncertainty," A practical introduction to weighted least squares and beyond. Vieweg+ Teubner,2010.

Svore, K., Vanderwende, L. and Burges, C., "Enhancing single-document summarization by combining Rank Net and third-party sources". In Proceedings of the EMNLP-CoNLL, 2007.

Tashakori, M., and et al., "Bon: The persian stemmer," in EurAsia-ICT 2002: Information and Communication Technology, ed: Springer, 2002, pp. 487-494.



آصف پورمعصومی مدارک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر (گرایش نرمافزار) به ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۰ از دانشگاه فردوسی مشهد دریافت کرده است. زمینه تحقیقاتی مورد علاقه

ایشان شامل ابزارهای پردازش زبان طبیعی، کاوش فرآینده سیستم‌های تصمیم‌گیری است.

نشانی رایانمۀ ایشان عبارت است از:

Asef.pms@gmail.com

ستوده حمیدرضا، اکبرزاده توتوچی، محمدرضا، تشهه لب، محمد، "خلاصه‌سازی متن بر اساس گزینش با استفاده از رویکرد انسان‌شناختی"، مجموعه مقالات هجدهمین کنفرانس مهندسی برق ایران، دانشگاه صنعتی اصفهان، اصفهان، ایران، ۱۳۸۹.

کریمی، زهره، شمس فرد، مهرنوش، "سیستم خلاصه‌سازی خودکار متن فارسی"، دوازدهمین کنفرانس بین المللی انجمن کامپیوتر ایران- تهران، ۱۳۸۵، صفحه ۱۲۷۶.

مشکی، محسن، "بررسی روش‌های خلاصه‌سازی متن غیرساخت یافته‌های فارسی"، سمینار کارشناسی ارشد، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران، ۱۳۸۶.

مشکی، محسن، "خلاصه‌سازی چندسندی اخبار فارسی برای تولید خلاصه‌های پیشینه‌خبر"، هفدهمین کنفرانس مهندسی برق ایران، صفحه ۳۰۴، تهران، ۱۳۸۸.

AleAhmad ,A., and et al, "Hamshahri: A standard Persian text collection", Journal of Knowledge-Based Systems, July 2009, Vol. 22 No.5, p.382-387.

Behmadi ,B. , Kahani ,M. , Toosi ,SA., Poormasoomi ,A., Estiri ,A., "Pasokh: A standard corpus for the evaluation of Persian text summarizers," in 3th International eConference of Computer and Knowledge Engineering (ICCKE), 2013, pp. 471-475.

Dalianis, H., "SweSum - A TextSummarizer for Swedish, Technical report", TRITANA-P0015, IPLab-174, NADA, KTH, 2000.

Edmundson ,H.P., "New Methods in Automatic Extracting.", Journal of the Association for Computing Machinery, April 1969, 16(2):p264-285 .

Farzindar, A., Rozon, F., and Lapalme, G., "CATS a topic-oriented multi-document summarization system", at DUC 2005.

Honarpisheh, M.,Ghassem-Sani, Gh.,Mirroshandel, Gh., "A Multi-Document Multi-Lingual Automatic Summarization System", Proceedings of the 3rd International Joint Conference on natural language processing (IJCNLP), pp. 733-738, 2007.

Kiyomarsi, F., Rahimi Esfahani F., "Optimizing Persian Text Summarization Based on Fuzzy Logic Approach" International Conference on Intelligent Building and Management Proc of CSIT, 2011, vol.5 ,IACSIT Press, Singapore.

محسن کاهانی استاد گروه مهندسی کامپیوتر دانشگاه فردوسی مشهد و مدیر آزمایشگاه فناوری وب است.

ایشان دکترای خود را در رشته مهندسی کامپیوتر از دانشگاه ولنگونگ استرالیا در سال ۱۳۷۷ اخذ کرده است. زمینه تحقیقاتی مورد علاقه ایشان شامل وب‌معنایی، پردازش زبان طبیعی، سیستم‌های تصمیم‌گیر و مهندسی نرم‌افزار است.

نشانی رایانمۀ ایشان عبارت است از:

kahani@um.ac.ir

سیداحمد طوسی مدارک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر (گرایش هوش مصنوعی) بهترتب در سال‌های ۱۳۸۱ و ۱۳۹۱ از دانشگاه فردوسی مشهد دریافت کرده است.

زمینه تحقیقاتی مورد علاقه ایشان شامل ابزارهای پردازش زبان طبیعی، سیستم‌های چندعامله، سیستم‌های تصمیم‌گیر است.

نشانی رایانمۀ ایشان عبارت است از:

ahmad.toosi@alumni.um.ac.ir

احمد استیری مدارک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر (گرایش نرم‌افزار) بهترتب در سال‌های ۱۳۸۷ و ۱۳۹۱ از دانشگاه فردوسی مشهد دریافت کرده است. زمینه تحقیقاتی مورد علاقه ایشان شامل ابزارهای پردازش زبان طبیعی، سیستم‌های چندعامله، سیستم‌های تصمیم‌گیر است.

نشانی رایانمۀ ایشان عبارت است از:

ahmad.estiry66@gmail.com

هادی قائمی در حال تحصیل در مقطع کارشناسی ارشد در دانشگاه فردوسی مشهد است. زمینه تحقیقاتی مورد علاقه ایشان شامل ابزارهای پردازش زبان طبیعی، پردازش الگو، است.

نشانی رایانمۀ ایشان عبارت است از:

Hadi.qaemi@stu.um.ac.ir

پیوست

ویژگی کام برای جمله آم متن	x_k^i
طول جمله بر اساس تعداد کلمات (ایست واژه + غیر ایست واژه)	$ S^i $
طول جمله براساس تعداد اشارات مثبت	$ S_{PP}^i $
طول جمله براساس تعداد اشارات منفی	$ S_{NP}^i $
طول جمله براساس تعداد واژه‌های بالهمیت	$ S_{IMP}^i $
طول جمله براساس تعداد اسمی خاص مکان	$ S_{LOC}^i $
طول جمله براساس تعداد اسمی خاص زمان	$ S_{Time}^i $
طول جمله براساس تعداد زیر متن خاص قرار گرفته در میان جفت علائم ویژه	$ S_{SPC}^i $
بسامد کلمه زام جمله آم در کل متن	$F(W_j^i)$
طول نسبی جمله آم در متن	RS^i
شماره ترتیب جمله آم در متن	PS^i
ارزش مطلق موقعیت ترتیبی جمله آم در متن	\hat{PS}^i
طول جمله براساس تعداد ضمایر	$ S_{PR}^i $
اگر در سه کلمه اول جمله آم ضمیر وجود داشته باشد برابر با یک و در غیر اینصورت برابر با صفر است	BP_3^i

