





دانشگاه الزهرا(س)

دانشکده فنی و مهندسی

پایان نامه

جهت اخذ درجه کارشناسی ارشد

رشته مهندسی کامپیوتر - گرایش هوش مصنوعی

## عنوان

بازشناسی متون فارسی مبتنی بر کد گذاری شکل و اطلاعات معنایی زمینه

استاد راهنما

دکتر رضا عزمی

دکتر بهروز قلیزاده

دانشجو

زهرا سادات مرتضوی طباطبائی

اسفندماه سال ۱۳۹۱

کلیه دستاوردهای این تحقیق متعلق به دانشگاه الزهراء(س)  
است.

لُفْحَيْمَةُ

تمامی شلهوچان اسلام، حاشیان بی ذمه و نشانه ک

در راه ملکت شهل لاذد و در الممال خرب

و

ما در خلزون کنمام تجریهای خوب زندگی را میخون

حضرت پیر مهرستان هستم

## قدرتانی

خداوند مهریان را شکرم که هرچه دارم از اوست

سپاس و ستایش خداوند را که به من توفیق داد تا بیماری و مدد او این پیان نامه را به پیان رسانم

بر خود واجب می دانم که، از استاد راهنمایی بزرگوار و لوزم جناب آقای دکتر عزمی که با داشت وقت نظر خاص خود مراد

تکمیل این پژوهش راهنمایی کردند، از جناب آقای دکتر بکیر که داوری این پیان نامه را برعهد داشتند، خانواده عزیزم و از تامی

کسانی که در طول دوران تحصیل باراهنمایی های ارزشمند علمی و معنوی خود، مریاری نمودند سپسکناری نموده و از خداوند برای این

عزیزان آرزوی توفیق و سر بلندی نایم. همچنین از مرکز تحقیقات مخابرات ایران که از این پیان نامه حمایت کرده است،

قدرتانی می کنم.

## چکیده

بازشناسی متون چاپی، از جمله زمینه‌های پرکاربرد بازشناسی الگو است. تاکنون تحقیقات متعددی در زمینه‌ی بازشناسی متون چاپی فارسی و عربی صورت گرفته است اما این تحقیقات، غالباً با محدودیت‌های فراوانی به ویژه در حوزه‌ی عملیاتی شدن، همراه بوده‌اند. کلیه‌ی تحقیقات انجام شده در این حوزه را می‌توان در قالب سه رویکرد مبتنی بر جداسازی حروف، رویکرد مبتنی بر بازشناسی شکل کلی زیرکلمات و رویکرد ترکیبی، تقسیم‌بندی نمود. در این پژوهش سعی شده است تا دو راهکار در زمینه‌ی رویکرد بازشناسی مبتنی بر شکل کلی کلمات و رویکرد ترکیبی ارائه شود.

در راهکار نخست که مبتنی بر رویکرد شکل کلی کلمات می‌باشد، ابتدا به ارائه‌ی الگوی باینری محلی هرمی، به عنوان یک روش استخراج ویژگی مستقل از چرخش و کارا در حوزه‌ی تشخیص زیرکلمات چاپی پرداخته شده و سپس با بهره‌گیری از خوشه‌بندی فازی و شبکه‌های عصبی توابع پایه شعاعی، عملیات بازشناسی انجام می‌پذیرد. آزمایشات صورت گرفته حاکی از آن است که راهکار پیشنهادی با دققی در حدود ۹۷.۸۱ درصد، قادر به تفکیک و تشخیص زیرکلمات چاپی می‌باشد.

در راهکار دوم که مبتنی بر رویکرد ترکیبی است، نخست، گروهی از حروف ابتداء، میانه و انتهای کلمات، که با دقت بالایی قابل جداسازی و بازشناسی می‌باشند، به عنوان حروف شاخص مشخص می‌شوند و سپس با بهره‌گیری از الگوریتم ژنتیک و عملگرهای مورفولوژی، مجموعه‌ای از عملگرهای مورفولوژی به همراه عناصر ساختاری بهینه که قادر به توصیف مناسب هر یک از گروه‌ها هستند مشخص شده و زیر کلمات هر یک از گروه‌ها بر اساس این حروف شاخص، کدگذاری می‌شوند. سپس یک دیکشنری تصویری، بر اساس زیرکلمات کد شده، ایجاد شده و در نهایت، عملیات بازشناسی زیرکلمات از طریق یک شبکه عصبی توابع پایه شعاعی و به کارگیری ویژگی موجک صورت پذیرفته است، صورت می‌پذیرد.

در پایان این پژوهش نیز به منظور بکارگیری اطلاعات معنایی زمینه، به بررسی بهره‌گیری از مدل زبانی SRILM در سطح کلمه و زیرکلمه بر روی یک سیستم پیشنهادی، پرداخته شده است.

## کلمات کلیدی

بازشناسی متون، خوشه‌بندی فازی، شبکه عصبی توابع پایه شعاعی، الگوریتم ژنتیک، مدل زبانی

## فهرست مطالب

۱	.....	فصل اول
۱	.....	مقدمه
۲	.....	- ۱-۱ بازشناسی الگو
۴	.....	- ۲-۱ طرح مسئله
۶	.....	- ۳-۱ اهداف و نوآوری ها
۸	.....	- ۴-۱ سازمان دهی مستند
۸	.....	- ۵-۱ خلاصه
۹	.....	فصل دوم
۱۰	.....	۱-۲ - بازشناسی متون چاپی
۱۲	.....	۲-۲ - کاربرد های سیستم بازشناسی متون
۱۲	.....	۳-۲ - چالش های فارروی بازشناسی متون فارسی
۱۳	.....	۱-۳-۲ - خصوصیات ساختاری زبان فارسی
۱۴	.....	۲-۳-۲ - تعداد زیاد کلاس های مورد بازشناسی
۱۵	.....	۴-۲ - مراحل کاری سیستم های بازشناسی حروف
۱۶	.....	۱-۴-۲ - پیش پردازش
۲۳	.....	۲-۴-۲ - جداسازی حروف
۲۵	.....	۳-۴-۲ - نمایش و استخراج ویژگی
۲۸	.....	۵-۲ - رویکردهای بازشناسی متون
۲۸	.....	۱-۵-۲ - رویکرد مبتنی بر جداسازی حروف
۳۳	.....	۲-۵-۲ - رویکرد مبتنی بر شکل کلی
۳۵	.....	۳-۵-۲ - رویکرد ترکیبی مبتنی بر جداسازی و شکل کلی
۳۸	.....	۶-۲ - جمع بندی
۳۹	.....	فصل سوم
۴۰	.....	۱-۳ - مقدمه
۴۱	.....	۲-۳ - سیستم پیشنهادی مبتنی بر شکل کلی
۴۱	.....	۱-۲-۳ - مرحله ای اول آموزش: تشکیل دیکشنری تصویری
۴۹	.....	۲-۲-۳ - مرحله ای دوم آموزش - آموزش شبکه عصبی توابع شعاعی پایه

۵۲	۳-۲-۳- مرحله‌ی بازشناسی
۵۵	۳-۳- پیاده‌سازی و آزمون
۵۵	۱-۳-۳- پایگاه داده
۵۷	۲-۳-۳- روش آزمون
۷۳	<b>فصل چهارم</b>
۷۴	۱-۴- مقدمه
۷۵	۲-۴- مراحل کاری روش ارائه شده مبتنی بر رویکرد ترکیبی
۷۵	۱-۲-۴- مرحله‌ی اول آموزش: روش پیشنهادی برای شناسایی حروف شاخص
۸۴	۲-۲-۴- مرحله‌ی دوم آموزش: تشکیل دیکشنری تصویری
۸۶	۳-۲-۴- مرحله‌ی سوم آموزش: آموزش شبکه‌ی عصبی توابع پایه شعاعی
۸۹	۱-۳-۴- پایگاه داده
۸۹	۲-۳-۴- روش آزمون
۸۹	۳-۳-۳- معیارهای ارزیابی
۹۰	۴-۳-۳- بررسی آزمایشات و تحلیل نتایج
۹۲	<b>فصل پنجم</b>
۹۳	۱-۵- مقدمه
۹۴	۲-۵- روش پیشنهادی بازشناسی با بهره‌گیری از مدل زبانی SRILM
۹۴	۱-۲-۵- پیش پردازش
۹۶	۲-۲-۵- مدل زبانی
۱۰۳	۳-۲-۵- مرحله‌ی نهایی بازشناسی با استفاده از مدل زبانی
۱۰۷	<b>فصل ششم</b>
۱۰۸	۱-۶- نتیجه گیری
۱۱۰	۲-۶- توسعه‌های آتی

## فهرست جداول

---

جدول ۳-۱: درصد طبقه بندی درست در سه خوشه‌ی نزدیک تر با معیارهای فاصله‌ی متفاوت ..... ۶۱
جدول ۳-۲: نتایج بدست آمده در شعاع‌های متفاوت و همسایگی ثابت ..... ۶۳
جدول ۳-۳: نتایج بدست آمده در شعاع‌های متفاوت و همسایگی ثابت ..... ۶۳
جدول ۳-۴: نتایج بدست آمده در شعاع‌های متفاوت و همسایگی ثابت ..... ۶۴
جدول ۳-۵: نتایج بدست آمده با روش‌های متفاوت دستیابی به تصاویر در سطوح ..... ۶۵
جدول ۳-۶: نتایج بدست آمده با معیارهای شباهت متفاوت ..... ۶۶
جدول ۳-۷: نتایج بدست آمده با توسعه‌های مختلف الگوی باینری محلی ..... ۶۷
جدول ۳-۸: نتایج بدست آمده از سایر ویژگی‌ها ..... ۶۸
جدول ۳-۹: درصد طبقه بندی درست در اولین خوشه‌ی نزدیک با معیارهای فاصله‌ی متفاوت ..... ۶۹
جدول ۳-۱۰-۱: درصد طبقه بندی صحیح در روش پیشنهادی ..... ۷۰
جدول ۳-۱۰-۲: درصد طبقه بندی صحیح در روش پیشنهادی ..... ۷۲
جدول ۴-۱: کلاس‌های مربوط به حروف شاخص در [۱۱] ..... ۷۶
جدول ۴-۲: کلاس‌های مربوط به حروف شاخص ..... ۷۷

## فهرست شکل ها

۱۴	شکل ۲-۱- مشخصات حروف فارسی
۱۶	شکل ۲-۲- مراحل کاری سیستم های بازشناسی متن
۱۷	شکل ۲-۳- نمونه ای از تصاویر آزمایش و تصاویر رفع چرخش شده [۱۰]
۱۸	شکل ۲-۴- تصحیح حفه های ناشی از خطای قلم
۱۹	شکل ۲-۵- از بین بردن نویز همسایگی
۲۰	شکل ۲-۶- هیستوگرام افقی برای جداسازی خطوط [۱۲]
۲۰	شکل ۲-۷- قطعات عمودی متصل برای تعیین پهنهای قلم
۲۲	شکل ۲-۸- نوار زمینه اولیه
۲۲	شکل ۲-۹- هیستوگرام عمودی
۲۴	شکل ۲-۱۰- به کارگیری منحنی پیرامون کلمه برای جداسازی [۲۷]
۲۶	شکل ۲-۱۱- دسته بندی روش های نمایش و توصیف شکل [۳۸]
۲۹	شکل ۲-۱۲- جداسازی بر اساس کانتور بالایی [۱۱]
۳۰	شکل ۲-۱۳- مراحل روش جداسازی پیشنهادی در [۴۰]
۳۱	شکل ۲-۱۴- شیوه برچسب گذاری کانتور برای اعمال روش جداسازی [۴۱]
۳۱	شکل ۲-۱۵- جداسازی بر مبنای برچسب زنی به کانتور زیر کلمه [۴۲]
۳۴	شکل ۲-۱۶- سیستم شیرعلی برای بازشناسی زیر کلمات [۴۷]
۳۶	شکل ۲-۱۷- سیستم بازشناسی متن ارائه شده در [۱۱]
۳۷	شکل ۲-۱۸- روندnamای تقریبی سیستم بازشناسی متن فارسی ارائه شده در [۵۴]
۴۳	شکل ۲-۱- مراحل تشکیل دیکشنری تصویری به وسیله FCM
۴۴	شکل ۲-۲- مراحل تشکیل دیکشنری تصویری
۴۷	شکل ۲-۳- انتقال هرمی در سه سطح
۴۹	شکل ۲-۴- مراحل آموزش شبکه عصبی توابع پایه شعاعی
۵۰	شکل ۲-۵- معماری شبکه عصبی توابع پایه شعاعی
۵۳	شکل ۲-۶- مراحل بازشناسی شیوه ای پیشنهادی
۵۶	شکل ۲-۷- توزیع زیر کلمات
۵۶	شکل ۲-۸- نمونه هایی از پایگاه داده زیر کلمات در ۵ فونت
۵۸	شکل ۲-۹- مراحل آزمون الگوی باینری محلی
۶۱	شکل ۲-۱۰- میانگین درصد طبقه بندی درست در سه خوشه ای نزدیک تر با معیارهای فاصله ای متفاوت
۶۸	شکل ۲-۱۱- میانگین درصد طبقه بندی درست برای هریک از ۵ فونت
۷۱	شکل ۲-۱۲- میانگین درصد طبقه بندی درست به وسیله ای روش پیشنهادی برای هریک از ۵ فونت
۸۰	شکل ۲-۱- نمونه ای از عناصر ساختاری
۸۱	شکل ۲-۲- نمونه ای از یک کروموزم
۸۳	شکل ۲-۳- (A) عملگر تقاطع عمودی و (B) عملگر تقاطع افقی
۸۳	شکل ۲-۴- عملگر جهش
۸۵	شکل ۲-۵- مراحل ایجاد دیکشنری تصویری

.....	.....	.....
.....	.....	.....
.....	.....	.....

# فصل اول

مقدمه

## ۱-۱- بازشناسی الگو

بازشناسی الگو یکی از خصوصیات انسان و دیگر موجودات زنده است و در بسیاری از مسائل روزمره نقش کاربردی دارد. الگو توصیف انسان از اشیاء است [۱].

انسان در هر لحظه عمل بازشناسی را انجام می‌دهد و می‌تواند به راحتی صداها و یا چهره‌ی افراد را تشخیص دهد و یا متون چاپی و یا حتی دست نویس را به سرعت خوانده و گفته‌ها و سخنان را تشخیص داده درک کند و یکی از خصوصیات مهم انسان نیز همین قابلیت او در بازشناسی و تحلیل الگوهای پیچیده است.

انسان علاوه بر این قدرت یادگیری و تعمیم دانسته‌های خود را نیز دارد. در انسان‌ها، یادگیری از طریق فرایندهای مشخص و تغییرات در سیستم عصبی اتفاق می‌افتد. فعالیت یادگیری معمولاً شامل مجموعه‌ای از مشاهدات در رابطه با پدیده‌های طبیعی و فرایندی برای تبدیل آن اطلاعات به دانش می‌باشد. سیستم های مصنوعی از طریق تغییراتی که به نمایش‌های داخلی خود، داده‌ها، مدل‌ها و یا ساختارها می‌دهند، یادگیری می‌کنند. این ماشین‌ها برای حل وظایف معینی ساخته می‌شوند و هدف از یادگیری آن‌ها، بهبود کارایی‌شان در آن وظایف توسط یادگیری از محیط، آموزگاران و تجربیات خودشان در دستیابی به اهداف مشخص می‌باشد.

بازشناسی الگو را می‌توان یک مسئله‌ی روانشناسی- فیزیولوژیکی در نظر گرفت که در رابطه بین انسان و یک محرک فیزیکی است. به طوری که ایجاد نوعی ارتباط بین داده‌های دریافتی و مجموعه‌ای از اطلاعات دسته‌بندی شده با توجه به تجربیات گذشته است.

اگرچه شناسایی الگو توسط انسان به سادگی صورت می‌پذیرد به طور مثال یک متن را با دقت بالا مطالعه کرده آن را درک می‌کند ولی این کار توسط یک ماشین مانند رایانه به سختی و در مواردی با دقت

بسیار پایین انجام می‌پذیرد و از آن جایی که انسان علاقه مند است کارهای خود را به ماشین بسپارد ارائه‌ی سیستم‌هایی برای بازشناسی خودکار الگوها مطرح است.

در علوم و مهندسی معمولاً دو نوع الگوی مکانی و زمانی مطرح می‌شوند. حروف، اثر انگشت، چهره‌ی انسان، نمونه‌هایی از الگوهای مکانی و سیگنال گفتار، نوار قلب مثال‌هایی از الگوهای زمانی هستند.

شناسایی الگو برای تحلیل داده‌های پزشکی، تحلیل تصاویر اشعه  $\text{X}$ ، پیش‌بینی آب و هوا، تشخیص چهره، تحلیل بافت و موارد بسیار دیگر کاربرد دارد.

به طور کلی روش‌های بازشناسی الگو به دو دسته‌ی اساسی تقسیم می‌شود.

## ۱-روش‌های مبتنی بر تئوری تصمیم‌گیری

### ۲-روش‌های ساختاری

کلاس الگو مجموعه‌ای از الگوها می‌باشند که خواص مشترکی دارند. در روش اول الگوی ورودی می‌تواند به یکی از کلاس‌های از پیش تعریف شده اختصاص داشته باشد. مشخصات خاصی از الگوی ورودی به صورت کمی اندازی گیری می‌شوند و درایه‌های یک بردار را تشکیل می‌دهند و بعد این روش به دنبال یک کلاس مناسب برای نسبت دادن الگو به آن می‌گردد. در این حالت تابعی تعریف می‌شود که بر مبنای آن هر کلاسی که به ازای بردار الگو بیشترین و یا کمترین مقدار بر حسب نوع تابع تصمیم گیری را دارا باشد، الگوی ورودی به آن کلاس اختصاص می‌یابد.

در روش دوم الگوها به صورت سمبولی نمایش داده می‌شوند (رشته‌ها و یا درخت) و شناخت الگو بر مبنای تطبیق سمبول و یا مدل‌هایی که با کمک سمبول‌ها جملات گرامری خاص برای هر کلاس در نظر می‌گیرند، صورت می‌گیرد [۳، ۲].

## ۲-۱ - طرح مسئله

رشد و پیشرفت دانش بشر بسیار مدیون پیدایش خط و امکان ثبت و نگهداری اطلاعات به صورت نوشتاری می باشد. به مرور زمان کتاب ها و بایگانی روزنامه ها به صورت منابع عظیمی از اطلاعات نوشته بر روی کاغذ می باشند. در عصر کنونی با توجه به رشد سریع فناوری اطلاعات نیاز شدیدی به سیستم هایی احساس می شود که به توانند با دقت و سرعت اطلاعات نوشتاری موجود را خوانده و ذخیره کنند.

بازشناسی متون، به تحلیل تصویر اسناد و تشخیص متون موجود در آن ها می پردازد و یکی از موضوعات مورد بحث در شناسایی الگو می باشد و همانند مقوله شناسایی گفتار از همان ابتدای ظهور بحث شناسایی الگو مطرح بوده است. یکی از دلایل این امر کاربرد خیلی زیاد حروف و علائم و متون است.

بازشناسی متون که شامل خواندن متن از روی سند و تبدیل کردن متن به فرمتی است که می توان آن را تغییر داد. یک راه کارآمد برای تبدیل متون به فایل های داده می باشد که ممکن است تایپ کردن آن ها مدت ها به طول انجامد. با توجه به این که متن در تصویر قابل دسترسی نمی باشد و حروف از یکسری نقاط تشکیل می شود که در کنار هم تصویر متن را می سازند. یک سیستم بازشناسی متن، تصویر را تحلیل کرده و شکل حروف را بر اساس پراکندگی نقاط در تصویر به متن قابل تغییر تبدیل می کند و بدین وسیله سند غیر الکترونیکی به سند الکترونیکی تبدیل می گردد.

با پیدایش وسایل ارتباط جمعی الکترونیکی و به عرصه در آمدن کامپیوتر، نیاز شدیدی به سیستم هایی احساس شده که بتوانند با دقت و سرعت اطلاعات نوشتاری موجود را خوانده و ذخیره کنند. در این راستا تلاش برای حرکت به سوی ادارات بدون کاغذ، حجم بزرگی از اسناد کاغذی روبش شده و به صورت تصویری ذخیره شده اند. وجود یک سیستم بازشناسی متون در کنار این حجم عظیم که امکان جستجو در میان مجموعه ای اسناد و ویرایش آن ها را فراهم می کند بسیار ضروری به نظر می رسد، ضمن این که حجم مورد نیاز برای ذخیره سازی متن، بسیار کمتر از حجم لازم برای ذخیره سازی تصویر است.

بازشناسی متن به دو دسته‌ی بازشناسی نویسه‌های گستته و بازشناسی متون پیوسته تقسیم می‌شود.

بازشناسی نویسه‌های گستته که به بازشناسی حروف گستته و ارقام می‌پردازد در بسیاری از سیستم‌های ثبت نام کاغذی برای بازشناسی اطلاعات وارد شده توسط کاربران مورد استفاده قرار می‌گیرد و با توجه به امکان محدود کردن کاربر در استفاده از نویسه‌های مشخص این نوع بازشناسی ساده‌تر می‌باشد.

بازشناسی متون پیوسته به دو بخش دستنویس و چاپی تقسیم می‌شود. بازشناسی متون چاپی از بازشناسی متون دست نویس ساده‌تر است و کاربرد بیشتری دارد به طوری که برای اکثر زبان‌های دنیا محصولات تجاری قابل قبولی وجود دارد.

امروزه سیستم‌های بازشناسی متون توانایی بازشناسی متون تایپی لاتین را با دقت و سرعت بالا دارند. ولی در شناسایی متون دستنویس لاتین و هم چنین متون فارسی و عربی که نوشتار تایپی آن‌ها هم به صورت پیوسته است، با مشکل رو برو هستند از جمله خصوصیاتی که امر تشخیص متون فارسی را دشوار می‌کنند ساختار نوشتاری پیوسته این متون، جهت نوشتاری از راست به چپ، همپوشانی عمودی حروف، یکسان بودن ساختار بدنی گروهی حروف و تفاوت در تعداد و جای نقاط، شکل‌های متفاوت هر حرف بر حسب قرار گرفتن در ابتداء، انتهای، وسط و یا جدا بودن حروف می‌باشند.

سه رویکرد کلی برای بازشناسی متون فارسی و عربی وجود دارد. رویکرد اول که رویکرد بازشناسی مبتنی بر جداسازی حروف است، ابتدا پس از پردازش‌های اولیه حروف از هم جدا و در مرحله بعد شناسایی می‌شوند. در این روش، مراحل جداسازی و بازشناسی از هم مستقل هستند. در این حالت مجموعه بزرگی از کلمات قابل شناسایی خواهند بود.

در رویکرد دوم که رویکرد بازشناسی بدون جداسازی حروف، بازشناسی کلمه بدون جداسازی حروف آن و با استفاده از شکل کلی کلمه صورت می‌گیرد. در این حالت مجموعه محدودی از کلمات قابل شناسایی خواهند بود.

در رویکرد سوم که یک رویکرد ترکیبی از دو رویکرد اول می‌باشد سعی می‌شود علاوه بر استفاده از اطلاعات شکل کلی کلمه از اطلاعات حروف تشکیل دهنده آن نیز به نوعی استفاده کند.

### ۱-۳-۱- اهداف و نوآوری‌ها

هدف از انجام این پژوهش، ارائه راه حل برای چالش‌هایی می‌باشد که در بخش طرح مسئله ذکر شد. در ادامه اشاره‌ای بر نوآوری‌هایی که در این پژوهش ارائه شده است، خواهد شد. این نوآوری‌ها به سه دسته کلی تقسیم می‌شوند: روشی مبتنی بر رویکرد ترکیبی، روشی مبتنی بر شکل کلی، و ارائه‌ی یک ویژگی جدید در حوزه‌ی بازناسی متن، که نوآوری‌های انجام شده در هر کدام از آن‌ها به صورت جداگانه ذکر خواهد شد.

- استخراج ویژگی و کدگذاری شی

- الگوی باینری محلی یکی از بهترین روش‌های موضوعی بیانگر بافت می‌باشد که در سال‌های اخیر به طور گستردگی در کاربردهای متفاوت مورد استفاده قرار گرفته شده است. تفکیک کنندگی بالا، تغییرات یکنواخت سطح خاکستری و کارایی محاسباتی، این روش را به یکی از مناسب‌ترین روش‌ها برای آنالیز تصویر تبدیل کرده است.

این روش تا به حال در حوزه‌های مختلف تصویر مانند تشخیص بافت، تشخیص چهره، آشکارسازی عیوب بافتی پارچه یا فرش، تشخیص شیء در ویدئو و غیره استفاده شده است ولی در این پایان نامه با ایجاد تغییراتی در این روش و ارائه‌ی الگوی باینری محلی هرمی با توجه به مزایای این روش مانند مستقل از چرخش بودن و سرعت استخراج از آن برای اولین بار جهت تشخیص زیر کلمات فارسی استفاده شده است.

- کدگذاری زیرکلمات با بازشناسی حروف شاخص به وسیله‌ی عملگرهای مورفولوژی به همراه عناصر ساختاری بهینه‌ی بدست آمده از الگوریتم ژنتیک.
- رویکرد مبتنی بر شکل کلی
  - ارائه روشی جدید در بازشناسی متون مبتنی بر شکل کلی زیرکلمه، براساس خوشه بندی فازی و شبکه‌های عصبی توابع پایه‌ی شعاعی .
  - رویکرد مبتنی بر جداسازی و شکل کلی(ترکیبی)
- در روش ارائه شده مبتنی بر این رویکرد، ابتدا گروهی از حروف در ابتدا، میانه و انتهای کلمه که با دقت بالایی جداسازی و بازشناسی می‌شوند به عنوان حروف شاخص در زیرکلمه مشخص شده و با استفاده از الگوریتم ژنتیک، ترتیبی از عملگرهای مورفولوژی همراه با عناصر ساختاری بهینه برای توصیف هریک از آن‌ها مشخص می‌شود. سپس به وسیله‌ی این مجموعه، حروف شاخص شناسایی شده و زیر کلمات کد می‌شوند و از روی زیرکلمات کد شده دیکشنری تصویری تشکیل می‌شود. در مرحله‌ی بعدی به ازای هریک از مدخل‌های دیکشنری شبکه‌ی عصبی، توابع پایه‌ی شعاعی به وسیله ویژگی بدست آمده از تبدیل موجک شکل کلی زیر کلمه آموزش داده می‌شود. در مرحله‌ی بازشناسی از این دیکشنری و شبکه‌های آموزش داده شده برای تشخیص نهایی زیرکلمه استفاده می‌گردد.
- اطلاعات زمینه
  - استفاده از مدل زبانی SRILM در کنار سیستم بازشناسی متون

## **۱-۴- سازماندهی مستند**

ساختار فصول آتی پایان نامه به شرح زیر است:

در فصل دوم، به بررسی مفاهیم و تعاریف، کاربردهای سیستم بازشناسی متون، معماری کلی سیستم‌های بازشناسی متون، چالش‌های موجود، رویکردهای کلی و مرور کارهای انجام شده مبتنی بر هریک از رویکردها، پرداخته خواهد شد. فصل سوم در کنار معرفی ویژگی جدید در حوزه‌ی بازشناسی متون روشی نیز برای بازشناسی متون مبتنی بر رویکرد شکل کلی زیرکلمه ارائه شده است. فصل چهارم شامل شرح روش مبتنی بر رویکرد ترکیبی ارائه شده است. در فصل پنجم مدل زبانی SRILM توضیح داده شده است. و در نهایت فصل پنجم نتیجه‌گیری و توسعه‌های آتی را شامل می‌شود.

## **۱-۵- خلاصه**

در این فصل مسئله‌ی مورد بررسی در این پژوهش مطرح شد و پس از آن اهداف و نوآوری‌های برجسته-ی پژوهش مورد بحث و بررسی قرار گرفت. این فصل نگاهی کلی بر اهداف و نوآوری‌های مطرح در این پژوهش را ارائه داده است.

## فصل دوّم

پیشینه‌ی تحقیق