

ساختارهای داده نمایه‌سازی ژنوم و توالی‌های پروتئینی

عادله اسعدی شالی

دانشجوی دکتری علم اطلاعات و دانش‌شناسی؛
دانشگاه شیراز adelehasadi@gmail.com

دریافت: ۱۳۹۴/۰۵/۱۹ | پذیرش: ۱۳۹۴/۰۵/۱۹



فصلنامه | علمی پژوهشی
پژوهشگاه علوم و فناوری اطلاعات ایران
شما (جایی) ۲۲۵۱-۸۲۲۳
شنا (الکترونیکی) ۲۲۵۱-۸۲۳۱
نمایه در SCOPUS، ISC، LISTA
jipm.irandoc.ac.ir
دوره ۳۱ | شماره ۲ | صص ۵۸۱-۶۰۰
زمستان ۱۳۹۴

چکیده: ساختار داده ابزاری برای ذخیره و بازیابی بوده و به طور کلی، روش منطقی و ریاضی یک سازماندهی خاص از داده‌ها نامیده می‌شود. کشف توالی‌های مختلف ژنوم و پروتئین در جانداران مختلف نیاز به نمایه‌سازی آن و نوع ساختار داده متناسب، جهت بازیابی سریع‌تر را افزایش داده است. ساختارهای داده رشته‌ای در طول سال‌های اخیر پر کاربردترین ساختارهای داده نمایه‌سازی ژنوم بوده است.

به لحاظ روش پژوهش، این مقاله مروری بوده و با بررسی مقالات مختلف مرتبط، سه نوع ساختار داده نمایه‌سازی پایگاه‌های ژنوم از جمله رشته‌ای، درخت پسوندی، آرایه پسوندی و نمودار مارپیچ مستقیم کلمه معرفی می‌شود. نتایج پژوهش نشان می‌دهد که درخت پسوندی و نمودار مارپیچ مستقیم کلمه ساختارهایی با حجم بالا بوده و آرایه پسوندی حجم کمتری را در حافظه اشغال می‌کند. درخت پسوندی و نمودار مارپیچ مستقیم کلمه، نسبتاً پویا بوده اما آرایه پسوندی ساختاری مرتب‌شده است و تغییر داده‌ها در این ساختار به سختی صورت می‌گیرد. آرایه پسوندی می‌تواند بر روی حافظه‌های جانبی ذخیره پیاده‌سازی شود؛ هر چند بازیابی داده‌ها در آن به کندی صورت می‌گیرد. اما در مورد نمودار مارپیچ مستقیم کلمه ذخیره‌سازی در حافظه جانبی امکان نداشته و درخت‌های پسوندی نیز ناکارآمد هستند.

کلیدواژه‌ها: ساختار داده، ژنوم، نمایه‌سازی، درخت پسوندی، آرایه پسوندی، نمودار مارپیچ مستقیم کلمه، فایل مقلوب

۱. مقدمه و بیان مسئله

سازماندهی مناسب داده‌ها برای بازیابی آسان و سریع آنها که به ساختار و یا ساختمان داده^۱ معروف است، از موضوعات مهم در علوم اطلاع‌رسانی و کامپیوتر است. ساختار داده ابزاری برای ذخیره و بازیابی بوده و به‌طور کلی، روش منطقی و ریاضی یک سازماندهی خاص از داده‌ها نامیده می‌شود (جباریه ۱۳۷۹، ۴۸). ساختار داده روشی برای سازماندهی اطلاعات برای انجام هرچه بهتر عملیات پردازشی می‌باشد. هدف ساختمان داده سازماندهی داده‌ها در جهت کاهش هزینه‌های استفاده از منابع موجود و نیز کاهش استفاده از فضای حافظه، زمان پردازندۀ، میزان پهنای باند شبکه، میزان مراجعه به دیسک و یا مواردی مشابه است. الگوریتم طراحی شده باستی با مصرف بهینه منابع بتواند جواب مناسب را با توجه به میزان منابع در اختیار تولید نماید.

الگوریتم به عنوان مراحل حل یک مسئله یا انجام یک کار، مجموعه‌ای متشابه از دستورالعمل‌هایی است که برای رسیدن به خروجی‌های مطلوب با شروع از یک حالت اولیه به کار می‌رود (شیریف‌زاده ۱۳۸۶). در طراحی پایگاه‌های اطلاعاتی، الگوریتم‌های طراحی شده بستگی مستقیم به نوع ساختار داده و نوع داده دارد. استفاده از ساختارهای داده مناسب با نوع داده، نحوه ارتباط داده‌ها و نحوه دسترسی و استفاده از داده‌ها امکان طراحی الگوریتم‌های مناسب در برنامه‌نویسی و طراحی پایگاه‌های اطلاعاتی را خواهد داد. لذا، آشنایی با ساختارهای داده از اهمیت بهسزایی برخوردار است.

۲. نوع نیازها در بازیابی اطلاعات مربوط به ژن

داده‌های مربوط به پایگاه‌های اطلاعاتی ژنوم و توالی‌های پروتئینی نوع خاصی از داده‌های حر斐 است که با داده‌های حر斐 مورد استفاده در متون متفاوت هستند. ژنوم انسانی حاوی بیش از سه میلیارد ذره رمزی DNA است. DNA از چهار بلوک شیمیایی به نام نوکلئوتیدها تشکیل شده که شامل آدنین (A)، گوانین (G)، سیتوسین (C) و تیمین (T) هستند. این کد چهار حر斐 میلیون‌ها و حتی میلیاردها بار در سراسر ژنوم تکرار شده است. ساختار داده پایگاه‌های ژنوم باید به گونه‌ای باشد که امکان بازیابی هر نقطه از این توالی وجود داشته باشد. در ادامه به شرح ویژگی‌های این نوع داده خواهیم پرداخت.

با گسترش تحقیقات در حوزه علوم زیستی و کشف توالی‌های مختلف ژنوم و پروتئین جانداران مختلف، حجم پایگاه‌های اطلاعات ژنوم افزایش یافته است. به عنوان مثال، ژنوم انسانی

1. data structure

دارای در حدود ۳ بیلیون جفت نوکلئوتید بوده و پایگاه‌های اطلاعات ژنوم انسانی بیش از ۱۵ بیلیون جفت نوکلئوتید را در بر گرفته است و برای ذخیره‌سازی آن ۴۵ گیگابایت حافظه صرف خواهد شد (Sadakane & Shibuya 2001, 1).

بایواینفورماتیک^۱ علمی است که با بهره‌گیری از علوم ریاضیات کاربردی، اطلاع‌رسانی، آمار و علوم کامپیوتر به بررسی مسائل زیست‌شناسی می‌پردازد. بیشتر پژوهش‌های این حوزه عبارت‌اند از:

- ◊ تطبیق^۲ و مقایسه توالی‌های ژن و پروتئین در داخل یک گونه و یا بین گونه‌های مختلف جانداران که ارتباط بین گونه‌های مختلف جانداران را مشخص کرده و روند تکاملی آنها را نشان می‌دهد؛
- ◊ یافتن ژن خاص و بازیابی نظیر به نظری رشتہ مورد نظر از طریق رونویسی آر ان‌ای^۳ از ژن (Sung 2005)؛
- ◊ تطبیق توالی‌های کوچک ژن و اتصال آنها و تشکیل ژنوم کامل؛
- ◊ پیش‌بینی ساختارهای پروتئینی و تجلی‌های ژن^۴ ناشناخته با بررسی شباهت توالی‌های آن با توالی‌های ژن‌هایی با عملکرد مشخص (Bioinformatic 2007).

توالی‌های تکرار^۵ ژن نیز در پژوهش‌ها نقش مهمی داشته و بررسی آنها در روند یک پژوهش به کرات ضرورت می‌یابد. بررسی ویژگی‌ها و موقعیت توالی‌های تکراری در ژنوم نقشی کلیدی در بررسی، ارزیابی و مقایسه ژنوم دارد (Abouelhoda, Kurtz, & Ohlebusch 2002). حجم توالی‌های تکراری در ژنوم سیار بالاست به گونه‌ای که ۵۰ درصد از ۳ بیلیون جفت ژنوم انسان را توالی‌های تکراری تشکیل داده است. هرچه جاندار تکامل یافته‌تر باشد، توالی‌های تکرار در ژنوم او بیشتر است؛ مثلاً در مقایسه با انسان، ۷ درصد از ژنوم کرم و ۳ درصد از ژنوم مگس دارای توالی تکرار هستند. وجود توالی‌های تکرار با بروز بیماری نیز رابطه مستقیم داشته و منجر به سیاری از بیماری‌های ژنتیکی می‌شود. در نتیجه، نیاز به بازیابی آنها از موارد دیگری بود که ضرورت ایجاد پایگاه‌های بازیابی ژن را بیشتر نمایان ساخت (Miyamoto 2004).

بر اساس موارد مطرح شده در این بخش می‌توان این گونه نتیجه گرفت که در پژوهش‌های مربوط به حوزه بایواینفورماتیک، پایگاه‌های اطلاعاتی با امکان بررسی دقیق توالی‌های مختلف به دست آمده از نمونه‌های مختلف، تعیین نوع توالی جدید بر اساس توالی‌های قبل و یا گونه‌های

1. bioinformatic
4. gene expression

2. alignment
5. repetitive sequences

3. RNA

دیگر و بررسی تفاوت گونه‌های مختلف از طریق بررسی توالی ژنوم و پروتئین آنها و نیز امکان بازیابی هر نقطه از این توالی ژنوم مطلوب است.

سازماندهی اطلاعات و چگونگی دستیابی آسان و سریع آنها از ارکان علم اطلاع‌رسانی به شمار می‌رود. شیوه‌های سازماندهی اطلاعات بسته به نوع داده‌های آنها متغیر است. ژن‌ها و پروتئین‌ها رشته‌هایی حاوی اطلاعاتی هستند که از تکرار ۴ حرف به وجود آمده‌اند و همین ساختار تفاوت‌هایی را در نحوه سازماندهی آنها ایجاد خواهد کرد. بررسی نیازهای اطلاعاتی محققان زیست‌شناسی و ساختارهای داده و شیوه‌های نمایه‌سازی ژنوم و پروتئین‌ها ما را با شیوه‌های سازماندهی این نوع داده‌ها آشنا خواهد کرد. این مقاله به معرفی انواع ساختار داده‌های عمومی و کاربرد آنها در سازماندهی ژنوم می‌پردازد.

۳. انواع ساختارهای داده

ساختارهای داده‌ها انواع گوناگونی دارند که هر کدام مناسب برنامه‌های مختلفی هستند. در کل، ساختارهای داده به سه نوع کلی ایستا، نیمه‌ایستا و پویا تقسیم می‌شوند. هر یک از انواع این ساختارها دارای ویژگی‌های خاصی هستند. به عنوان مثال، ایجاد تغییر در ساختارهای ایستا هزینه‌بر بوده و امکان تغییر وجود ندارد. در نوع پویا تغییرات مجاز بوده و در نوع نیمه‌ایستا تغییرات در شرایطی خاص امکان‌پذیر است.

آرایه‌ها^۱ ساختارهای داده‌ای از نوع ایستا، پشته و صفح از نوع نیمه‌ایستا و درخت‌ها^۲، گراف‌ها^۳ و لیست‌های پیوندی^۴ از نوع پویا هستند. شکل ۱ انواع ساختارهای داده ایستا، نیمه ایستا و پویا را نشان می‌دهد. در ادامه هر یک از این ساختارها به طور اجمالی معرفی می‌گردد.



شکل ۱. انواع ساختارهای داده (امیر جلیلی ایرانی ۱۳۹۱)

1. array

2. tree

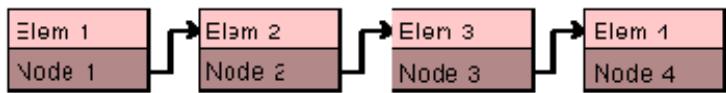
3. graph

4. linked list

آرایه: آرایه‌ها پر کاربردترین ساختار داده مورد استفاده برای ذخیره مجموعه‌ای از عناصر اطلاعاتی هستند (Parlante 2001). یک آرایه، نمایه‌ای خطی^۱ و شامل مجموعه‌ای از عناصر است که به صورت متواالی در حافظه ذخیره شده و اگر مرتب نشده باشد، به صورت خطی قابل بازیابی می‌باشد. اطلاعات اگر پراکنده بوده و مرتب نشده باشد، کامپیوتر مجبور است برای پیدا کردن داده *n* از یک مجموعه داده، به ترتیب از ابتدای آرایه پردازش نموده، عنصر مورد جست‌وجو را با عنصر اول، دوم و ... تا دستیابی به عنصر مورد نظر مقایسه کرده، و به داده مورد نظر برسد که به این ترتیب در صورتی که حجم داده‌ها زیاد باشد، زمان زیادی صرف جست‌وجو خواهد شد. در مقابل، جست‌وجوی دودویی فقط بر روی آرایه مرتب شده امکان‌پذیر است. بدین صورت که در آرایه مرتب شده مانند فرهنگ لغت، جست‌وجو از وسط لیست شروع شده و با مقایسه واژه مورد جست‌وجو با واژه قرار گرفته در وسط لیست برای حرکت بر روی لیست به منظور دستیابی به واژه مورد نظر مشخص می‌شود و جست‌وجو تا دستیابی به واژه مربوطه ادامه می‌یابد. سرعت بازیابی اطلاعات در روش دوم بیشتر است. تنها نقطه ضعف این الگوریتم هزینه‌بربودن حذف و اضافه داده‌ها از آرایه می‌باشد.

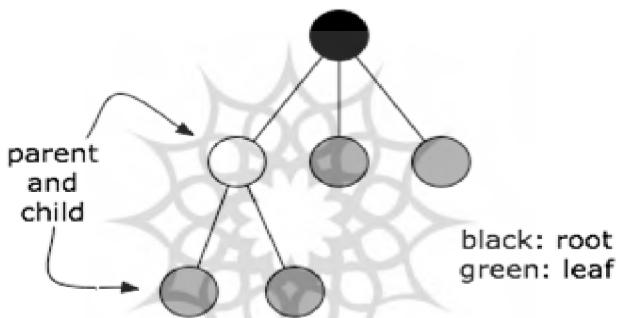
صف و پشته: پشته و صف جزء ساختار داده‌های نیمه‌ایستا هستند. گاهی می‌خواهیم در عمل حذف و یا اضافه نمودن داده‌ها در هر مکانی از آرایه، محدودیت ایجاد کنیم؛ به طوری که فقط عملیات حذف و اضافه در ابتدا و انتهای لیست صورت گیرد. در این حالت از پشته استفاده می‌کنیم. پشته، لیست خطی است که عملیات حذف و اضافه تنها از یک طرف آن صورت می‌گیرد. در هر لحظه فقط عنصر بالائی پشته قابل دسترس است. صف، ساختمان داده‌ای است که کلیه عملیات اضافه از یک سر آن و کلیه عملیات حذف از انتهای دیگر آن انجام می‌پذیرد. صف در نرم‌افزارهایی که صف انتظار را برای دسترسی به منبعی برقرار می‌کنند، کاربرد دارد (تنها، آیت ۱۳۸۷).

لیست‌های پیوندی: لیست پیوندی نوع دیگری از ساختارهای داده خطی پویا است و شامل مجموعه‌ای از عناصری است که با یک نظم خاص کنار هم قرار گرفته‌اند. به این ترتیب که هر عنصر داده‌ای اشاره گری^۲ به عنصر بعد از خود دارد. لیست‌های پیوندی ساختارهای داده پویا بوده و حذف، اضافه و افزایش حجم اطلاعات در آن امکان‌پذیر است. شکل ۱ نشان‌دهنده یک لیست پیوندی است.



شکل ۲. ساختار یک لیست پیوندی (Kovacs 1998)

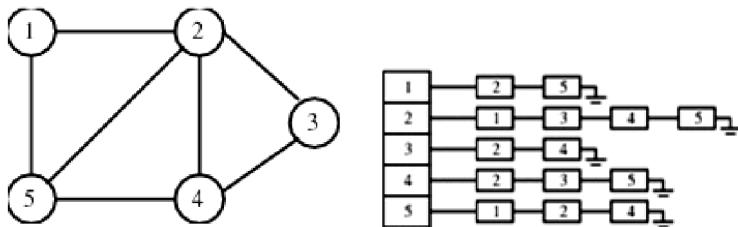
درخت‌ها و گراف‌ها: این دو نوع ساختار داده مشابه بوده و غیرخطی هستند. درخت‌ها ساختار داده‌ای هستند که با یک گره^۱ ریشه آغاز شده و هر ریشه دارای یک و یا چند برگ می‌باشد. ریشه در بالای ساختار نمایش داده می‌شود و برگ‌ها در زیر ریشه قرار می‌گیرند. درخت‌ها ساختار سلسله‌مراتبی دارند. این بدان معنی است که هر گره می‌تواند تنها یک گره والدین داشته باشد. شکل ۳ ساختار یک درخت را نشان می‌دهد.



شکل ۳. ساختار یک درخت (Black 2004)

گراف، ساختار داده پویا و غیرخطی است که از گره‌ها تشکیل شده و هر گره مانند درخت‌ها داده‌ای را شامل می‌شود، ولی برخلاف درخت‌ها هر گره می‌تواند با گره‌های دیگر در ارتباط باشد (Bell college n.d.). همچنین، بین اجزای آن رابطه سلسله‌مراتبی مثل درخت‌ها (رابطه والدین و فرزندان در درخت پسوندی) برقرار نیست و رابطه بین اجزای آن بر اساس احتمال وجود برقرار شده است (Mehta & Sahni 2005). شکل زیر ساختار یک گراف را نشان می‌دهد.

1. node



شکل ۴. ساختار یک گراف (Skiena 2008)

۴. شاخص‌های ارزیابی ساختارهای داده

برای ارزیابی پایگاه‌ها و ساختارهای داده به کار رفته در پایگاه، چند خصیصه را مورد بررسی قرار می‌دهند. این خصیصه‌ها عبارت‌اند از:

- ◊ حجم کم مورد نیاز برای ساختن و بازیابی اطلاعات؛
- ◊ سرعت جست‌وجو؛
- ◊ انعطاف‌پذیری، پویایی و امکان بهروزرسانی آسان؛
- ◊ در پایگاه‌های اطلاعاتی بزرگ، نمایه باید به سمت حافظه‌های جانبی پیش برود (Navarro 2003).

۵. ساختارهای داده مناسب پایگاه‌های اطلاعاتی ژنوم

معروف‌ترین ساختار داده متن مورد استفاده در موتورهای کاوش و پایگاه‌های اطلاعاتی متون که به دلیل پویایی و حجم پایین، کاربرد زیادی دارند، نمایه مقلوب^۱ و یا فایل مقلوب^۲ هستند (Puglisi, Smyth, & Turpin 2005). فایل‌های مقلوب نوعی لیست پیوندی هستند (مقسمی ۱۳۸۶) که به عنوان ساختار داده کمکی^۳ و نمایه‌ای برای فایل اصلی به کار می‌رود (پائو ۱۳۷۸؛ Black 2994؛ Black 1386). به این ترتیب، فایل مقلوب بر اساس کلمات موجود در متون یک پایگاه اطلاعاتی مرتب شده و در فهرست فایل مقلوب هر کلمه دارای شماره‌های مدارک مرتبط با آن است و کلمات به شماره‌های مدارک از طریق یک اشاره‌گر (شبیه به یک لیست پیوندی) پیوند دارند. زمانی که به دنبال یک ساختار داده در کلمه محور باشیم، فایل‌های مقلوب بسیار مناسب

1. inverted index

2. inverted file

۳. در متون، گاه این نمایه با نام list Postings file و یا Inverted list نیز مطرح می‌شود.

۴. این نوع ساختار داده‌ها به نمایه و یا شاخص خارجی (external index) معروف است (Black 2004).

است. این فایل حجم زیادی اشغال نکرده و می‌تواند موقعیت کلمات در متون مختلف را نیز نگهداری کند و جست‌وجوی دقیق‌تری را ارائه دهد. تطبیق‌پذیری این ساختار امکان چندین نوع پرس‌وجو^۱ (عین کلمه، استفاده از عملگرهای بولی، رتبه‌بندی کلمات و غیره) را می‌دهد (Grossi & Vitter 2005). به دلیل اینکه جست‌وجو در این ساختار باید از نوع عبارت و واژه باشد، این ساختار به نمایه کلمه‌محور معروف است و برای سازماندهی توالی‌های ژن و نیز زبان‌های شرق آسیا که ساختاری رشته‌ای دارند، مناسب نیست.

ساختارهای تمام‌متن مانند آرایه‌پسوندی، درخت پسوندی و گراف مارپیچ مستقیم کلمه از جمله ساختار داده‌های ارائه‌شده برای حل این مشکل هستند. بسیاری از مسائل زیست‌شناسی مثل، جست‌وجوی توالی‌های ژنی، بازیابی توالی‌های تکرار، اتصال توالی‌ها، تطبیق توالی ژن و سازماندهی توالی ژن‌ها از طریق این ساختار امکان‌پذیر است. این نوع ساختارهای داده به تمام‌متن^۲ معروف است که در آن، کل متن و حروف موجود در متن قابل بازیابی بوده و در تلاش است نمایه را جایگزینی برای کل متن نماید (Grossi 2004). این نوع ساختار داده در نمایه‌سازی خودکار پایگاه‌های ژنوم به کار برد می‌شوند. این مقاله به معرفی سه نوع ساختار داده رشته‌ای^۳، درخت پسوندی، آرایه‌پسوندی و گراف مارپیچ مستقیم کلمه خواهد پرداخت. قبل از بررسی این سه نوع ساختار، تعریف^۴ که مبنای ساختن ساختارهای دیگر است، معرفی می‌شود.

۶. ساختار داده تعریف

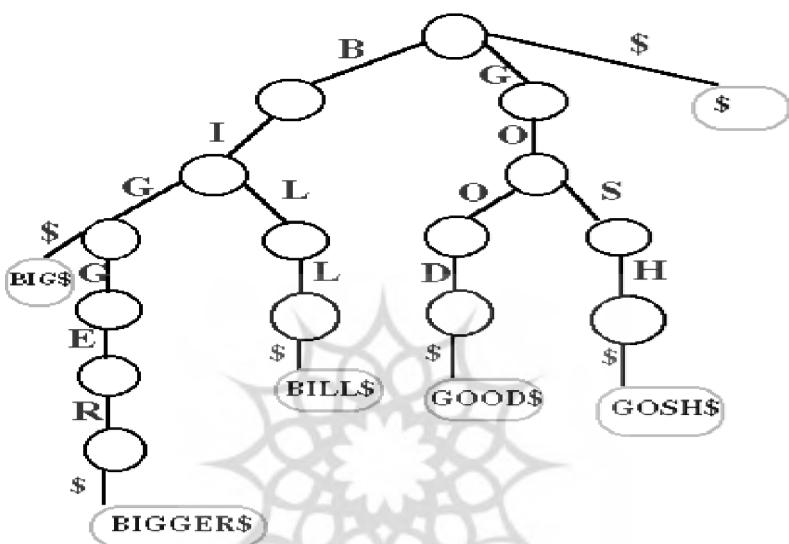
تعریف که برگرفته از کلمه بازیابی^۵ بوده و نوعی ساختار داده است که برای سازماندهی و جست‌وجوی فرهنگ‌ها استفاده می‌شود (Mehta & Sahni 2005, 1-28). به علاوه، با توجه به اینکه این ساختار داده توانایی جست‌وجوی حرف به حرف را دارد، از این ساختار در تحلیل‌های لغوی برای ترجمه‌متون، جست‌وجوهای کتابشناختی، بررسی غلط‌های املایی، پردازش زبان طبیعی استفاده می‌شود (Aoe, Morimoto, & Sato 1992). این ساختار در دهه ۱۹۶۰ توسط «فردکین»^۶ ارائه شده و یکی از قدیمی‌ترین ساختارهای داده به شمار می‌رود (Gent et al 2007). یک ساختار داده تعریف است برای جست‌وجوی رشته‌ای با تعداد حروف الفبای پایه مشخص، که هر یک از لبه‌های آن با نویسه‌ای مشخص شده، و مسیر ریشه تا برگ نشان‌دهنده یک رشته می‌باشد (Sung 2005). ساختار تعریف در اصل درختی است که برای ذخیره و بازیابی رشته‌ای از نشانه‌ها^۷ به کار

1. query
4. trie
7. symbols

2. full text
5. retrieval

3. string data structure
6. Fredkin

می‌رود و ایده مهم و متمایزتری از ساختار درخت‌ها این است که در تری، توالی‌های دارای پیشوندهای مشابه، گره‌ها و لبه‌های مشترک خواهند داشت (Gent et al. 2007). به عنوان مثال، اگر کلمات یک متن در نظر گرفته شود، ساختار تری کلمات BIG, BIGGER, BILL, GOOD GOSH آن به شکل زیر خواهد بود.



شکل ۵. ساختار تری (McGill University 1997)

در ساختار تری هر یک از حروف کلمات به عنوان یک گره از ساختار درختی در نظر گرفته شده است. به این ترتیب که تمامی کلماتی که دارای حروف آغازین مشابه باشند، در زیر یک شاخه قرار خواهند گرفت و حروف به ترتیب حضور در متن از ریشه تا انتهای شاخه (آخرین حرف یک رشته) ذخیره خواهد شد. این ساختار برای بازیابی متن می‌تواند به کار رود، اما هنوز نمی‌توان آن را در نمایه‌سازی ژنوم به کار برد (امکان بازیابی بخشی از یک کلمه وجود ندارد). نوع دیگری از تری‌ها که پایه ساختن درخت‌های پسوندی است، تری پسوندی است که در آن تمامی پسوندهای ممکن در یک کلمه در نظر گرفته شده و روابط درختی بین آنها برقرار می‌شود. پسوند رشته^۱ S^n به طول n زیررشته‌ای از رشته S است که ابتدای آن از هر قسمت از رشته S و انتهای این زیررشته n می‌باشد. برای مثال، اگر رشته GOOGOL\$ در نظر گرفته شود، (که \$

۱. رشته، مجموعه کاراکترهایی را گویند که در انتهای آنها علامت \$ وجود داشته باشد.

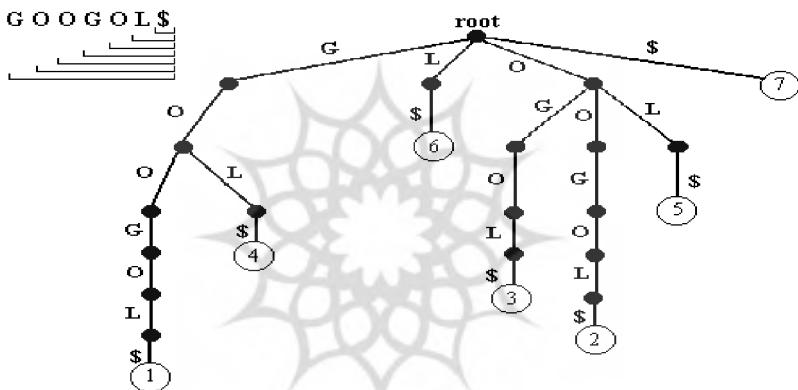
نشان‌دهنده انتهای رشته باشد) مجموعه پسوند‌های GOOGOL\$ به شکل زیر خواهد بود:

```
GOOGOL$  
OOGOL$  
OGOL$  
GOL$  
OL$  
L$  
$
```

و تری پسوندی زیر را خواهد داشت:

رشته: GOOGOL\$

موقعیت: ۱۲۳۴۵۶۷



شکل ۶. تری پسوندی رشته \$ GOOGOL (McGill University 1997)

تری پسوندی امکان جست‌وجوی هر قسمت از یک کلمه را فراهم می‌آورد. در توالی DNA نیز از طریق این ساختار می‌توان هر بخشی از توالی ژنوم را بازیابی نمود (McGill University 1997). مشکل عمدۀ در استفاده از این ساختار، حجم زیاد نمایه و نیز سرعت پایین ایجاد این ساختار است. پیچیدگی زمانی جست‌وجوی آن $O(md^m)$ تعداد حروف الفبا است) و به طور میانگین فضای مورد نیاز برای ذخیره داده‌ها بر اساس این ساختار برابر $O(n^2)$ می‌باشد (Mäkinen, Navarro 2005)؛ به این معنی که برای ذخیره‌سازی n تعداد کاراکتر فضایی به اندازه n^2 نیاز است. در نتیجه، هزینه بالایی را به سیستم تحمیل خواهد نمود. هر کاراکتر

۱. به عنوان مثال، توالی‌های ژن ۴ حرف الفبا دارند.

گره خاصی را اشغال می‌نماید و شاخه‌هایی با کاراکترهای مشابه جداگانه تکرار می‌شوند. این موارد منجر به افزایش حجم ساختار می‌شود. ساختار داده درخت پسوندی با فشرده‌سازی و ساختار نمودار مارپیچ مستقیم کلمه با خلاصه‌سازی ساختارهایی برای اصلاح تری پسوندی به شمار می‌روند (Crochemore & Lecroq n. d.).

۷. درخت پسوندی

جست‌وجوی متون ساختاربندی نشده مثل توالی‌های ژن و برخی از زبان‌های شرق آسیا، مشکل جدیدی در نمایه‌سازی متون ایجاد نمود. آرایه و درخت پسوندی^۱ از ساختارهای داده پر کاربرد متون ساختاربندی نشده هستند (Grossi & Vitter 2005). الگوریتم ایجاد درخت پسوندی برای نخستین بار در سال ۱۹۷۳ توسط واینر^۲ ارائه شد و کاربردی‌های زیادی در نمایه‌سازی پیدا کرد (Crochemore & Lecroq n. d.).

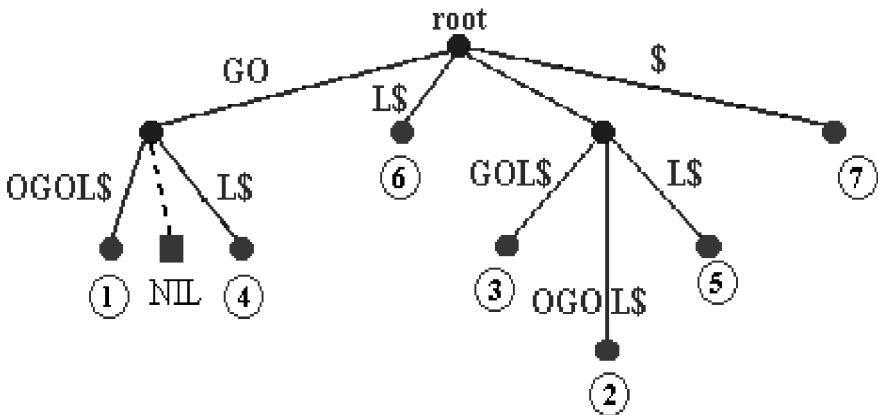
درخت پسوندی رشتة S به نشانه T شکل فشرده تری پسوندی بوده و دارای ویژگی‌های زیر است:

- ◊ درخت پسوندی دارای n انتهای شاخه می‌باشد که از شماره ۱ تا n شماره گذاری شده است.
- ◊ هر گره (به استثنای گره انتهایی) حداقل دارای دو گره فرزند است. به این ترتیب که در تری پسوندی هر گره که دارای یک فرزند باشد با گره بعدی یکی می‌شود (Sung 2005).
- ◊ همه لبه‌های خارج شده از گره‌ها با نویسه‌های متفاوت شروع می‌شوند.
- ◊ مجموعه راه‌های ایجاد شده از ریشه تا انتهای شاخه‌ها، شامل کلیه پسوند‌های موجود برای رشتة S هستند (Grossi & Italiano 1996).

درخت پسوندی رشتة GOOGOL\$ به شکل زیر خواهد بود:

1. suffix tree

2. Weiner

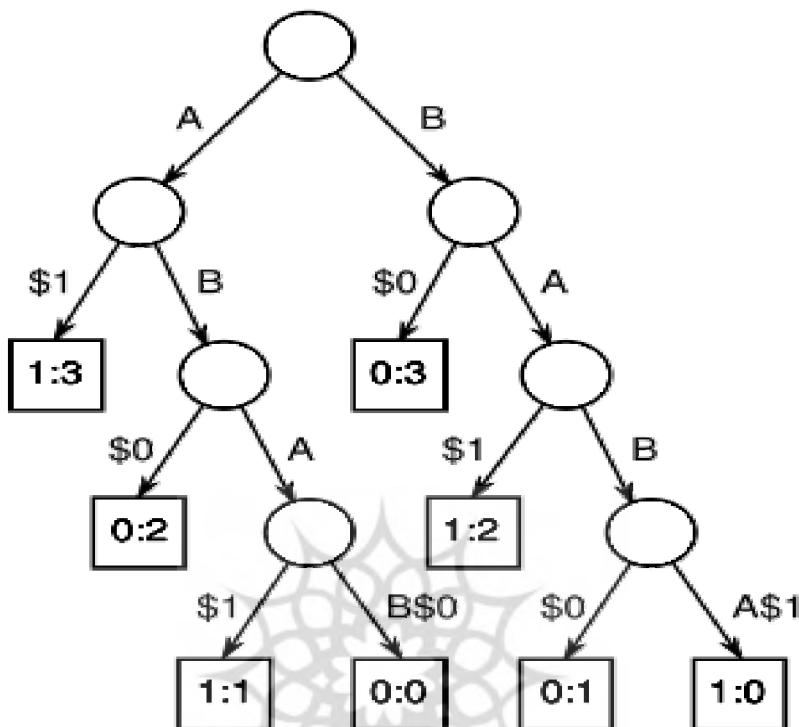


شکل ۷. درخت پسوندی رشته GOOGOL\$ (McGill University 1997)

ساخت یک رشته با فضای حافظه‌ای $O(n^2)$ در تری پسوند به (n) در ساختار درخت بهبود یافته است (Grossi & Vitter 2005) و زمان بازیابی زیررشته m برابر با $O(n + m)$ است. همچنین، زمان ساخت این ساختار در بدترین حالت برابر با $O(n^2)$ می‌باشد (Stoye 2006).

درخت پسوندی تعیم یافته امکان استفاده از درخت پسوندی در چندین رشته و متن‌های مختلف را می‌دهد و از این طریق می‌توان با استفاده از ساختار درخت پسوندی به جستجو در یک پایگاه اطلاعاتی وسیع مانند توالی‌های DNA و پروتئین پرداخت. مثال زیر ساختار درخت تعیم یافته را بهتر نمایان می‌کند. شکل زیر درخت پسوندی تعیم یافته برای رشته‌های ABAB و BABA است.

پرتال جامع علوم انسانی



شکل ۸. درخت پسوندی تعمیم یافته (Wikipedia 2002)

به این ترتیب، با اختصاص کاراکترهای انتهایی اختصاصی برای هر رشته می‌توان رشته‌ها را از هم جدا نمود. از سوی دیگر، برای جداسازی هر یک از لبه‌ها بخش اول جفت شاخص برای مشخص کردن رشته مربوطه به کار رفته و بخش دوم ابتدای زیررشته را نشان می‌دهد. در نتیجه، در کل برای نمایش برچسب لبه‌ها، سه قسمت (i, j) خواهد داشت که از نشان‌دهنده رشته مربوطه، j ابتدای زیررشته و انتهای آن خواهد بود (Mehta & Sahni 2005, 4-29).

۸. آرایه پسوندی

«مانبر^۱ و مایرز^۲» در سال ۱۹۹۳ آرایه پسوندی^۳ را برای نمایه‌سازی طراحی کردند که از نظر ساختار شباهت زیادی با درخت پسوندی داشت، اما ساختار آن به شکل درخت نبود (Schurmann, & Stoye 2005).

1. Manber

2. Myers

3. suffix array

فرهنگ مرتب‌سازی شده. این ساختار برای تطبیق رشته‌ها، تحلیل ژنوم و فشرده‌سازی متون استفاده می‌شود (Dementiev, Karkkainen, & Sanders 2006).

اگر $S[1..n]$ یک رشته به طول n و با حروف الفبایی Σ باشد و $\$\text{به عنوان کاراکتر پایانی منحصر به فرد} \text{رشته در نظر گرفته شود، به ازای هر } n = 1, 2, \dots, S[i..n] \text{ پسوندی از رشته } S \text{ خواهد بود. آرایه پسوندی } (SA[1..n]) \text{ مجموعه پسوندهای } S \text{ با ترتیب الفبایی می‌باشد. برای مثال، شکل زیر پسوندهای رشته } GOOGOL\$ \text{ است؛}$

موقعیت پسوند

GOOGOL\$.۱
OOGOL\$.۲
OGOL\$.۳
GOL\$.۴
OL\$.۵
L\$.۶
\\$.۷

به این ترتیب آرایه پسوندی این رشته به مطابق جدول ۱ خواهد بود (Hon, Lam, & Sadakane 2007).

جدول ۱. آرایه پسوندی رشته \$GOOGOL\$

S پسوند رشته	$SA[i]$	i
\$	۷	۱
GOL\$	۴	۲
GOOGOL\$	۱	۳
L\$	۶	۴
OOGOL\$	۲	۵
OGOL\$	۳	۶
OL\$	۵	۷

با بررسی این ساختار و درخت پسوندی می‌توان دریافت که این ساختار حجم کمتری خواهد داشت. آرایه پسوندی برای نمایه‌سازی ژنوم در حدود ۴ برابر حجم کمتر نسبت به درخت پسوندی اشغال می‌کند (Manber & Myers 1993). جستجوی دودویی با توجه به ترتیب فرنگی آن سرعت بازیابی اطلاعات را بالا بردé است. اما همین، ساختار به روزرسانی اطلاعات را مشکل نموده است.

مقایسه این ساختار با فایل‌های مقلوب که یکی از پرکاربردترین ساختار جست‌وجو در پایگاه‌های اطلاعاتی به شمار می‌رود، نشان می‌دهد که:

- ◊ جست‌وجوهای عبارتی آرایه‌های پسوندی در مقایسه با فایل‌های مقلوب بهتر انجام می‌شود؛
- ◊ آرایه‌پسوندی محدودیت جست‌وجوی صرف کلمات را ندارد؛
- ◊ فایل‌های مقلوب، فضای زمان جست‌وجوی مناسب‌تری نسبت به آرایه‌پسوندی دارند (Seki et al. 2005).

با وجود کاربردهای گسترده آرایه‌پسوندی، هنوز حجم زیاد ساختار و زمان زیاد برای ایجاد ساختار، از محدودیت‌های آن به شمار می‌رود.

۹. نمودار مارپیچ مستقیم کلمه

نمودار مارپیچ مستقیم کلمه^۱ نوعی گراف است که امکان بازیابی بخش‌هایی از یک کلمه را می‌دهد و یکی از ساختارهای مورد استفاده در پایگاه‌های داده ژنوم است. نمودار مارپیچ مستقیم کلمه شکل خلاصه‌شده‌تری است. در این ساختار تعداد گره‌ها کمتر شده است و تقریباً مشابه‌تری روابط بین کاراکترهای موجود در رشته را ارائه می‌نماید (Mehta & Sahni 2005, 2-30). نخستین بار بولمر^۲ این ساختار را طراحی نمود. به‌طور کلی، یک نمودار مارپیچ مستقیم کلمه شامل ویژگی‌های زیر است:

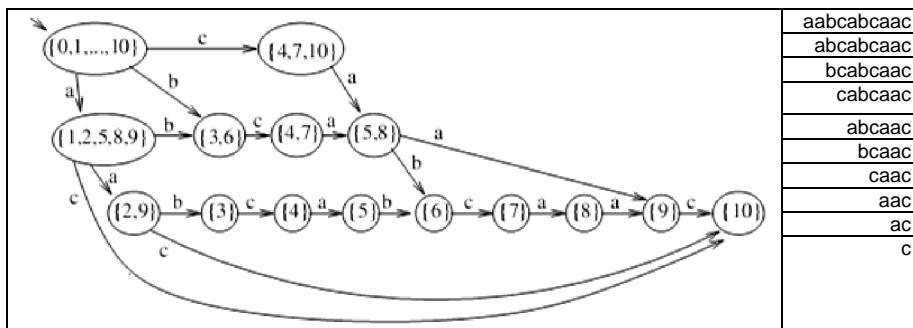
- ◊ دو گره کاملاً مشخص به عنوان گره ابتدایی و گره پایانی وجود دارد؛
- ◊ لبه‌ها با زیررشته‌ای از رشته اصلی S برچسب‌گذاری می‌شوند؛
- ◊ برچسب‌های لبه‌ایی که یک گره مشابه را ترک می‌کنند، باید نویسه مشابه داشته باشند؛
- ◊ هر پسوند از رشته S مربوط به مسیری از گراف است که از گره ابتدایی آغاز شده و به گره پایانی ختم می‌شود. به این ترتیب که مطابق ترتیب حروف پسوندها، برخی از برچسب‌های لبه‌ها به هم ملحق می‌شوند و از تکرار گره‌هایی باله‌های مشابه جلوگیری می‌کنند (Inenaga et al. 2005).

به عنوان مثال، اگر $s = aabcaabcac$ باشد ساختار نمودار مارپیچ مستقیم کلمه آن به‌شكل زیر خواهد بود:

1. Directed Acyclic Word Graph (DAWG)

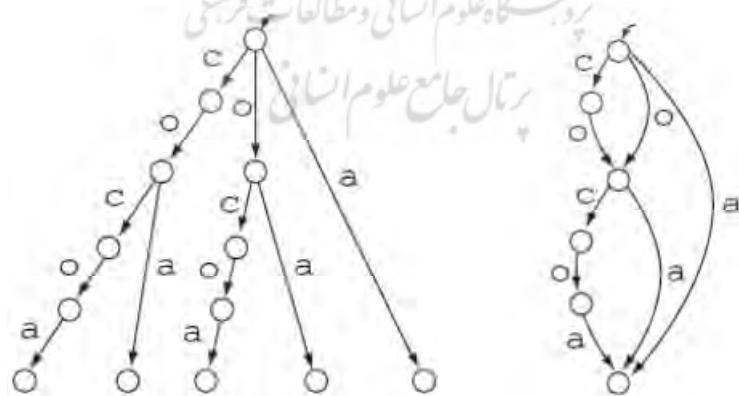
2. Bulmer

$$S = a \ a \ b \ c \ a \ b \ c \ a \ a \ c$$

$$1 \ 2 \ 3 \ 4 \ 5 \ 6 \ 7 \ 8 \ 9 \ 10$$
پسوندهای رشته S 

شکل ۹. نمودار مارپیچ مستقیم کلمه برای رشته (Ehrenfeucht & McConnell 2002) aabcabcaac

گره ابتدایی در سمت چپ با پیکان مشخص شده است که گرهی خالی و بدون نویسه می‌باشد. به تعداد حروف الفبای رشته S ، لبه‌هایی با نویسه‌های متفاوت گره ابتدایی را ترک می‌کنند. لبه‌ها به گره‌هایی می‌رسند که مکان‌های نویسه مربوط به برچسب لبه قبل را نشان دهند. سپس نویسه بعدی پسوندها، به ساختار اضافه می‌شود و در صورتی که بخشی از نویسه‌های پسوندها با هم مشابه داشته باشند، لبه‌ها ملحق شده و یک مسیر واحد را به وجود می‌آورند. با این بررسی، تفاوت‌های این ساختار با تری پسوندی مشخص خواهد شد. شکل ۹ تفاوت بین ساختار نمودار مارپیچ مستقیم کلمه را با تری پسوندی برای رشته cocoa نشان می‌دهد.



شکل ۱۰. تری پسوندی (شکل سمت چپ) و نمودار مارپیچ مستقیم کلمه (شکل سمت راست) برای رشته

(Miyamoto et al. 2004) cocoa

نمودار مارپیچ مستقیم کلمه ساختار تری پسوندی را به شکل افقی، درخت پسوندی آن را به صورت عمودی فشرده می‌کند (Jain 2004). نوع جدیدی از نمودار مارپیچ مستقیم کلمه با نام نمودار مارپیچ مستقیم کلمه فشرده،¹ عملکردی مشابه درخت‌های پسوندی را در مورد نمودار مارپیچ مستقیم کلمه اعمال می‌کند (Jain 2004). به این ترتیب که گره‌های متواالی بدون انشاعاب، با هم ادغام شده و یک گره را ایجاد می‌کنند و به صورت باز هم تعداد گره‌ها کاهش خواهد یافت. نمودار مارپیچ مستقیم کلمه با زمان (n) ساخته شده و جست‌وجوی زیررشته در این ساختار نیز با زمان ($S + m$) خطی می‌باشد. اما برای ذخیره‌سازی داده‌هایی با طول n به فضایی به اندازه ۱۵۰ نیاز است (Navarro 2003). ساختار نمودار مارپیچ مستقیم کلمه در مقایسه با درخت پسوندی کاربرد کمتری داشته است (Jain 2004).

۱۰. بحث و نتیجه‌گیری

اگر تعریف ذیل برای نمایه‌سازی و مدرک را پذیریم، نمایه راهنمایی برای مدرک، بخشی از مدرک، یا تعدادی از مدارک موجود در پایگاه اطلاعات است که برای آشکارساختن ماهیت آنها ساخته می‌شود (اشرفی‌ریزی و کاظم‌پور ۱۳۸۶) و مدرک عبارت است از هر نوع نوشته خطی، چاپی، عکسی، و یا به صورت‌های دیگر و هر شیء مادی که بتوان از محتوای آن اطلاعی به دست آورد (سلطانی ۱۳۷۹). از سوی دیگر، می‌دانیم که نمایه‌سازی روش بنیادین سازماندهی اطلاعات است (نیازی ۱۳۸۱-۱۳۸۵) و سازماندهی اطلاعات از ارکان مهم علم کتابداری و اطلاع‌رسانی است. پس، می‌توان گفت که علم کتابداری و اطلاع‌رسانی محدود به حوزه اطلاعات متنی وابسته به زبان‌های گفتاری بشر نیست و وظیفه سازماندهی همه اشکال اطلاعات بشر را بر عهده دارد. این مقاله سعی داشته است به نمایه‌سازی ماشینی تمام‌متن نویسه‌محور² بپردازد و برخی ساختارهای ذخیره و بازیابی داده‌ها در این نوع نمایه‌سازی را معرفی نماید.

در این مقاله سه نوع نمایه‌توالی‌های ژنوم، درخت پسوندی، آرایه‌پسوندی و نمودار مارپیچ مستقیم کلمه معرفی و برخی ویژگی‌های آنها مورد بررسی قرار گرفت.

به طور کلی، ارزیابی ساختارهای داده از چهار منظر بیشتر حائز اهمیت است:

- ◊ کم حجم‌بودن ساختار داده که با میزان کارایی آن در ارتباط مستقیم است؛
- ◊ پویایی و امکان به روزرسانی اطلاعات؛
- ◊ امکان ذخیره‌سازی در حافظه‌های جانبی؛ و

◇ سرعت جستجوی اطلاعات.

با بررسی ساختارهای داده معرفی شده در این مقاله، ارزیابی ساختارها به این ترتیب خواهد بود که درخت پسوندی و نمودار مارپیچ مستقیم کلمه ساختارهایی با حجم بالا هستند، حال آنکه آرایه پسوندی با توجه به خطی بودن ساختار، حجم کمتری را در حافظه اشغال خواهد نمود. درخت پسوندی و نمودار مارپیچ مستقیم کلمه نسبتاً پویا بوده و امکان به روزرسانی داده‌ها در این ساختارها وجود دارد، اما آرایه پسوندی ساختاری مرتب شده بوده و تغییر داده‌ها در این ساختار به سختی صورت می‌گیرد. آرایه پسوندی می‌تواند بر روی حافظه‌های جانبی ذخیره پیاده‌سازی شود؛ با وجود اینکه بازیابی داده‌ها در آن به کندی صورت می‌گیرد؛ اما در مورد نمودار مارپیچ مستقیم کلمه امکان ذخیره‌سازی در حافظه جانبی امکان نداشته و این کار در مورد درخت‌های پسوندی نیز ناکارآمد می‌باشد. از سوی دیگر، با توجه به اینکه آرایه پسوندی ساختاری مرتب شده است، سرعت جستجوی اطلاعات در آن از دیگر ساختارها بیشتر خواهد بود.

فهرست منابع

اشرفی‌ریزی، حسن، و زهرا کاظم‌پور. ۱۳۸۶. ارزیابی نمایه و نمایه‌سازی: معیارها و استانداردها. علوم و فناوری اطلاعات ۲۳ (۱ و ۲). (دسترسی در اردیبهشت ۱۳۹۴) از http://jipm.irandoc.ac.ir/files/site1/user_files_e1671e/admin-A-10-1-44-aae09b7.pdf

پائو، میراندالی. ۱۳۷۸. مفاهیم بازیابی اطلاعات. ترجمه اسدالله آزاد و رحمت‌الله فتاحی. مشهد: دانشگاه فردوسی مشهد.

- تنه، جعفر، ناصر آیت. ۱۳۸۷. ساختمان داده‌ها و الگوریتم‌ها. تهران: دانشگاه پیام نور.
- جباریه، علیرضا. ۱۳۷۹. ساختمان داده‌ها ۱ و ۲. تهران: جهان نو.
- جلیلی ایرانی، امیر. ۱۳۹۱. ساختمان داده‌ها. ۱۰. <http://amirjalili.ir/?cat=10> (دسترسی در خرداد ۱۳۹۴)
- سلطانی، پوری، و فروردین راستین. ۱۳۷۹. داشتمنه کتابداری و اطلاع‌رسانی. تهران: فرنگ معاصر.
- شریف‌زاده، مناف. ۱۳۸۵. آشنایی با طراحی الگوریتم. روزنامه ایران آتلاین، ۱۴ بهمن [\(دسترسی در اردیبهشت ۱۳۹۴\)](http://www.magiran.com/npview.asp?ID=1336456)
- مقسمی، حمیدرضا. ۱۳۸۶. ذخیره و بازیابی اطلاعات. تهران: گسترش علوم پایه.
- نیازی، سیمین. ۱۳۸۵-۱۳۸۱. نمایه‌سازی. در دائرة المعارف کتابداری و اطلاع‌رسانی. (ج. ۲). تهران: کتابخانه ملی جمهوری اسلامی ایران. / <http://portal.nlai.ir/daka/Wiki%20Pages/> (دسترسی در اردیبهشت ۱۳۹۴)
- Abouelhoda, Mohamed Ibrahim, Stefan Kurtz, & Enno Ohlebusch. 2002. The enhanced suffix array and its applications to genome analysis. Proceedings of the 2nd Workshop on Algorithms in Bioinformatics, LNCS 2452, Springer-Verlag, (pp. 449-463). http://www.dbis.informatik.hu Berlin.de/dbisold/lehre/SS05/genome_syntax/AboKurOHL2002.pdf

(accessed 2015)

- Aoe, Jun -Ichi, Katsushi Morimoto, & Takashi Sato. 1992. An Efficient Implementation of Trie Structures. *Sofware -Practice and Experience*, 22 (9): 695-721.
<http://sc.snu.ac.kr/~xuan/spe777ja.pdf> (aaccessed 2015)
- Bell College (n.d.). *Software Development 2, Graph data structures*.
http://hamilton.bell.ac.uk/swdev2/notes/notes_18.pdf (accessed 2015)
- Bioinformatics. 2007. *Encyclopedia of Wikipedia*. <http://en.wikipedia.org/wiki/Bioinformatics> (accessed 2008)
- Black, Paul E. 2004. external index, in Dictionary of Algorithms and Data Structures [online], Paul E. Black, ed., U.S. National Institute of Standards and Technology. 17 December 2004.
<http://www.nist.gov/dads/HTML/externalindx.html> (accessed 2015)
- Crochemore, Maxime, and Thierry Lecroq (n.d.). Suffix Tree. <http://www-igm.univ-mlv.fr/~lecroq/articles/suffix.pdf> (accessed 2008)
- Dementiev, R., Kärkkäinen J, & P Sanders. 2006. Better external memory suffix array construction, Journal of Experimental Algorithmics (JEA), 12(3-4): 1-24.
<http://dl.acm.org/citation.cfm?id=1402296> (accessed 2015).
- Ehrenfeucht, Andrzej, & Ross M. McConnell. 2001. String Searching. In Mehta, Dinesh P; sahni, Sartaj, (ed), *Handbook of data structures and applications* (pp. 30-54) Chapman & hall/CRC: Boca Raton. <http://www.cs.colostate.edu/~rmm/dawgs.pdf> (accessed 2015)
- Generalised suffix tree (n.d.). Encyclopedia of Wikipedia.
http://en.wikipedia.org/wiki/Generalised_suffix_tree (accessed 2015)
- Gent, Ian P., Christopher Jefferson, Ian Miguel, and Peter Nightingale. 2007. Data Structures for Generalised Arc Consistency for Extensional Constraints. In AAAI 2007: 191-197. <http://www.cs.st-andrews.ac.uk/~pn/AAAI07.pdf> (accessed 2015)
- Grossi, Roberto. 2004. *Recent Advances on Text Indexing and String Algorithms*. Paper presented at the bioinformatics Seminar, University of Rennes. <http://www.di.unipi.it/~grossi> (accessed 2015)
- _____, and Giuseppe F Italiano. 1996. Suffix trees and their applications in string algorithms. Rapporto di Ricerca CS-96-14, Università "Ca' Foscari" di Venezia, Italy.
<http://www.di.unipi.it/~grossi/IND/survey.pdf> (accessed 2015)
- _____, and Jeffrey Scott Vitter. 2005. Compressed suffix arrays and suffix trees with applications to text indexing and string matching. *SIAM journal on computing* 35 (2): 378-405.
<http://www.di.unipi.it/~grossi/PAPERS/sicomp05.pdf> (accessed 2015)
- Hon, Wing-Kai, Tak-Wah Lam, and Kunihiko Sadakane. 2007. A Space and Time Efficient Algorithm for Construction Compressed Suffix Arrays. *Algorithmica* 48 (1): 28-36.
<http://www.cs.nthu.edu.tw/~wkhon/papers/HLSSY05.pdf> (accessed 2015)
- Inenaga, Shunsuke et al. (eds). (2005). On-Line Construction of Compact Directed Acyclic Word Graphs? *Discrete Applied Mathematics* 146 (2): 156-179.
http://www.shino.ecei.tohoku.ac.jp/~ayumi/papers/SPIRE2001_SCDAWG.pdf (accessed 2015)
- Jain, Anoop. 2004. Performance Analysis of Horizontally Compacted String Indexes. masters thesis, Indian institute of science, Bangalore, MA. <http://dsl.serc.iisc.ernet.in/publications/thesis/anoop.pdf> (accessed 2015)
- Kovacs, Daniel. 1998. Tutorial on Linked Lists.
<http://www.fortunecity.com/skyscraper/false/780/linklist.html> (accessed 2008)
- Mäkinen Veli, Gonzalo Navarro 2005. Succinct suffix arrays based on run-length encoding Combinatorial Pattern Matching, 45-56. Berlin: prigner
<http://personales.dcc.uchile.cl/~gnavarro/ps/njc05.pdf> (accessed 2015)
- Manber, Udi, and Gene Myers. 1993. Suffix arrays: A new method for on-line string searches. *SIAM Journal on Computing* 22 (5): 935-948. <http://www.webglimpse.net/pubs/suffix.pdf> (accessed

2008)

- McGill University: School of Computer Science. 1997. Data structures and algorithms. <http://www.cs.mcgill.ca/~cs251/OldCourses/1997/topic24/> - 22k (accessed 2008)
- Mehta, Dinesh P, and Sartaj Sahni (ed). 2005. *Handbook of data structures and applications*. Chapman & hall/CRC: Boca Raton.
- Miyamoto, Satoru, Shunsuke Inenaga, Masayuki Takeda, and Ayumi Shinohara. 2004. Ternary directed acyclic word graphs. *Theoretical Computer Science: Implementation and Application of Automata* 328 (1-2): 97-111. <http://www.cpe.ku.ac.th/~anan/courses/phd-seminar/S16/S16-paper.pdf> (accessed 2008)
- Navarro, Gonzalo. 2003. Current Challenges in Textual Databases. Presented at the 4th Mexican International Conference on Computer Science Computer Society. <http://www.infor.uva.es/Investigacion/Descargas/navarro.Sep04.pdf> (accessed 2008)
- Parlante, Nick. 2001. *Linked list Basics*. <http://cslibrary.stanford.edu/103/LinkedListBasics.pdf> (accessed 2008)
- Puglisi, Simon J., William F. Smyth, and Andrew Turpin. 2005. suffix Arrays: What Are They Good For? In *ACM International conference proceeding series*; Vol. 170. Proceedings of the Seventeenth Australasian Database Conference (ADC2006), 49, (pp. 17-18). Hobart, Australia: Australian Computer Society, Inc. <http://www.crpit.com/confpapers/CRPITV49Puglisi.pdf> (accessed 2008)
- Sadakane, Kunihiko, and Tetsuo Shibuya. 2001. Indexing huge genome sequences for solving various problems. In H. Matsuda, et al. (eds), *Proceedings of the 12th Genome Informatics (GIW01) 2001* (Universal Academy Press, 2001) 175-183. *Proceedings of the 12th Genome Informatics (GIW01)*, (pp. 175-183): Universal Academy Press. <http://www-math.mit.edu/~lippert/18.417/papers/indexing-huge-genome-sequences.pdf> (accessed 2008)
- Schurmann, Klaus-Bernd, and Jens Stoye. 2005. An Incomplex Algorithm for Fast Suffix Array Construction. In *Proceedings of the 7th Workshop on Algorithm Engineering and Experiments*, <http://www.siam.org/meetings/alenex05/papers/07kschuermann.pdf> (accessed 2008)
- Seki, Kazuhiro. 2005. Text Retrieval and Analysis Suffix Trees and Suffix Arrays. <http://www.lair.indiana.edu/courses/textir/l590-9.ppt> (accessed 2008)
- Skiena, Steven. 2008. The Stony Brook Algorithm Repository, Graph Data Structures. <http://www.cs.sunysb.edu/~algorith/> (accessed 2008)
- Stoye, Jens. 2006. Suffix trees, Affix trees, and some of their applications. Bielefeld University, Jens Stoye's Recent Talks, Birkenkeld, May 17. <http://www.techfak.uni-bielefeld.de/~stoye/talks/20060517birkenkeld.pdf> (accessed 2008)
- Sung, Wing-Kin. 2005. Suffix Tree and Suffix Array, Lecture 4 from Combinatorial methods in bioinformatics. http://www.comp.nus.edu.sg/~ksung/cs5238/note/Lect4-suffixtree_2005.pdf (accessed 2008)

عادله اسعدی شالی

متولد سال ۱۳۶۰، دارای مدرک کارشناسی ارشد در رشته علم اطلاعات و دانش‌شناسی از دانشگاه تهران است. ایشان هم‌اکنون دانشجوی دکتری علم اطلاعات و دانش‌شناسی دانشگاه شیراز است. ارتباطات و اطلاعات، رفتار اطلاع‌یابی، ذخیره و بازیابی اطلاعات از جمله علایق پژوهشی وی است.

