

۱۳۸۷/۱۰/۲۶  
۱۳۸۷/۱۰/۲۶



دانشگاه شهید بهشتی  
دانشکده علوم ریاضی

پایان نامه کارشناسی ارشد  
ریاضی محض

عنوان:

الگوریتم : *Libra*

روشی جدید برای یافتن موظیف بر مبنای جبر خطی

۱۳۸۷ / ۱۰ / ۲۶

استاد مشاور:

استاد راهنما:

دکتر مهدی صادقی

دکتر چنگیز اصلاح‌چی

نگارش:

علیرضا شیخ‌عطار

زمستان ۱۳۸۶



## دانشگاه شهید بهشتی

«بسم الله تعالى» +

### صور تجلیسه دفاع از پایان نامه دانشجویان دوره کارشناسی ارشد»

ان ۱۴۰۲/۱۱/۸ مورخ ۳۹۳۲/۰۰/۸۶ تا/۵ هجری شماره ۱۱/۸/۱۱۱۸

۲۹۹۰۱

بازگشت به مجوز دفاع شماره ۳۹۳۲/۰۰/۸۶ تا/۵ هجری شماره ۱۱/۸/۱۱۱۸ جلسه هیأت داوران ارزیابی پایان نامه: آقای علیرضا

شیخ عطار شماره شناسنامه: ۲۶۸۹ صادره از: تهران متولد: ۱۳۶۰ دانشجوی دوره کارشناسی ارشد: ریاضی محض

با عنوان:

### الگوریتم Libra: روش جدید برای یافتن موظیف بر مبنای جبر خطی

به راهنمایی:

#### آقای دکتر چنگیز اصلاح چی

طبق دعوت قبلی در تاریخ ۸۶/۱۱/۱۰ تشکیل گردید و بر اساس رأی هیأت داوری و با عنایت به ماده ۲۰ آئین نامه کارشناسی ارشد مورخ ۷۵/۱۰/۲۵ پایان نامه مزبور با نمره ۱۹,۷۵ و درجه ناگای مورد تصویب قرار گرفت.

#### امضاء

#### نام دانشگاه

#### مرتبه علمی

۱- استاد راهنما: آقای دکتر چنگیز اصلاح چی

۲- مشاور: آقای دکتر مهدی صادقی

۳- داور: آقای دکتر سهرابعلی یوسفی

۴- داور: آقای دکتر حمید پژشک

۵- مدیر گروه: آقای دکتر علیرضا سالمکار

	شهید بهشتی	دانشیار
	پژوهشگاه مهندسی زیستیک	استادیار
	شهید بهشتی	استادیار
	تهران	دانشیار
	شهید بهشتی	استادیار

## الگوریتم :Libra

روشی جدید برای یافتن موتیف بر مبنای جبرخطی

چکیده

امروزه یک مسئله‌ی کلی در بیوانفورماتیک، یافتن الگوهای تقریباً مشابه (موتیف) روی توالی‌های DNA و پروتئین می‌باشد که توجه بسیاری از زیست‌شناسان و دانشمندان علوم کامپیوتر و ریاضی را به خود جلب کرده است. به طور خاص، یافتن مکان‌های اتصال یک فاکتور نسخه برداری روی DNA از مهم‌ترین مسائل پیدا کردن موتیف‌ها به شمار می‌آید. الگوریتم‌های بسیاری برای یافتن موتیف‌ها ارائه شده است اما به سختی می‌توان ازین آنها بهترین را انتخاب کرد. این در حالی است که به جز تعریف بیولوژیک موتیف، تعریف روشی در محاسبات کامپیوتری برای آن ارائه نشده است که به توافق همه رسیده باشد. علاوه بر آن تقریباً همه‌ی الگوریتم‌های موجود در مقابل داده‌های گوناگون حساس هستند و دیده شده است که الگوریتمی برای DNA‌های گونه‌های مختلف به طور موفقیت‌آمیز کار می‌کند اما برای گونه‌های پیچیده‌تری مانند انسان موفقیت‌آمیز نیست. بالاخره اینکه الگوریتم‌های متفاوت اغلب پارامترهای متفاوتی به عنوان ورودی در نظر می‌گیرند که قابل تبدیل به هم نیستند. یعنی به سختی می‌توان شرایط یکسانی را برای مقایسه الگوریتم‌ها فراهم کرد. با توجه به این دلایل مقایسه عملکرد الگوریتم‌های موجود کاری بسیار مشکل است. وجود چنین تقایصی انگیزه‌ای شد تا الگوریتمی ارائه دهیم که اولاً هر گونه از داده‌ها را بدون حساسیت پذیرد و ثانیاً با کمترین پارامترهای لازم بتواند به جوابی راضی کننده در زمانی معقول دست یابد. ما در این پایان‌نامه ابتدا با دسته‌بندی الگوریتم‌های موجود آن‌ها را بررسی می‌کیم. در گام بعد الگوریتمی به نام Libra ارائه می‌دهیم که بر مبنای جبرخطی ابتدا فضای جستجو را به زیرقطعه‌هایی از توالی‌های DNA کاهش داده و سپس با نگرشی جدید از شباهت در موتیف، قطعه‌های مشابه را پیدا می‌کنیم. سپس از روی آنها مدلی برای موتیف می‌سازیم و آنگاه با مدل‌هایی که از موتیف بدست می‌آوریم به جواب‌های راضی کننده‌ای در زمانی معقول دست می‌یابیم. در پایان این الگوریتم را با یکی از معروف‌ترین الگوریتم‌های موجود به نام MEME مقایسه خواهیم کرد.

واژه‌های کلیدی: ۱) فضای برداری، ۲) گراف، ۳) هم‌دیفی دوگانه و چندگانه، ۴) پیچیدگی محاسباتی.

۱	۱	۱. مقدمه
۱	۱	۱.۱ نگاهی بر زیست‌شناسی مولکولی
۱	۱	۱.۱.۱ پیش‌درآمد
۲	۲	۱.۱.۲ DNA
۱۲	۱۲	۲. مسئله‌ی یافتن موتیف
۱۲	۱۲	۲.۱ پیش‌درآمد
۱۳	۱۳	۲.۲ صورت مسئله‌ی یافتن موتیف
۱۵	۱۵	۳.۱ مدل‌هایی برای توصیف موتیف
۱۷	۱۷	۴.۱ سختی مسئله‌ی یافتن موتیف
۱۷	۱۷	۴.۱.۱ پیچیدگی محاسباتی و تقریب‌پذیری
۱۸	۱۸	۴.۱.۲ مسئله‌ی یافتن موتیف NP-سخت است
۲۰	۲۰	۳. الگوریتم‌های یافتن موتیف
۲۰	۲۰	۱.۳ پیش‌درآمد
۲۱	۲۱	۲.۳ جستجو برای موتیف‌های شناخته‌شده
۲۴	۲۴	۳.۳ جستجو برای موتیف‌های جدید
۲۴	۲۴	۱.۳.۳ پیش‌درآمد
۲۵	۲۵	۲.۳.۳ الگوریتم‌های شمارشی
۳۰	۳۰	۳.۳.۳ الگوریتم‌های بهینه‌سازی قطعی
۳۶	۳۶	۴.۳.۳ الگوریتم‌های بهینه‌سازی تصادفی
۴۰	۴۰	۴. مواد و روش الگوریتم <i>Libra</i>
۴۰	۴۰	۱.۴ هم‌ردیفی موضعی دوگانه
۴۳	۴۳	۲.۴ گام اول: کم کردن فضای جستجو
۴۷	۴۷	۳.۴ گام دوم: یافتن زیرشته‌های شبیه به هم
۴۹	۴۹	۴.۴ گام سوم: یافتن مدلی برای موتیف
۵۴	۵۴	۵. پیاده سازی الگوریتم <i>Libra</i>
۵۴	۵۴	۱.۵ زمان اجرای الگوریتم <i>Libra</i>
۵۵	۵۵	۲.۵ کارایی الگوریتم <i>Libra</i>

۶۱	۶. نتیجه و بحث
۶۱	۱.۶ معیارهایی برای مقایسه‌ی الگوریتم‌های یافتن موتیف
۶۸	۲.۶ مقایسه‌ی الگوریتم <i>MEME</i> و <i>Libra</i>
۷۵	۷. مراجع

## مقدمه

### ۱.۱ نگاهی بر زیست‌شناسی مولکولی

#### ۱.۱.۱ پیش‌درآمد

ماده‌ی وراثتی در همه‌ی موجودات زنده  $DNA^1$  است [۱]. زمانی که یک سلول در بدن موجود زنده در حال تقسیم شدن است، برگردانهایی از  $DNA$  ساخته می‌شود و هر سلول نوزاد یک برگردان از  $DNA$  را دریافت می‌کند. توالی<sup>۲</sup>  $DNA$  همه‌ی اطلاعات وراثتی یک موجود زنده که ژن<sup>۳</sup> نام دارد را در بر دارد که به عنوان الگوی ساخت  $RNA^4$  به کار می‌رود. سپس  $RNA$  می‌تواند همانند یک قالب برای تولید پروتئین مورد استفاده قرار گیرد. بروز صفات سلول و انجام فعالیت‌های حیاتی، به عهده‌ی پروتئین‌ها می‌باشد.

<sup>۱</sup> Deoxy-ribonucleic Acid

<sup>۲</sup> Sequence

<sup>۳</sup> Gene

<sup>۴</sup> Ribonucleic acid

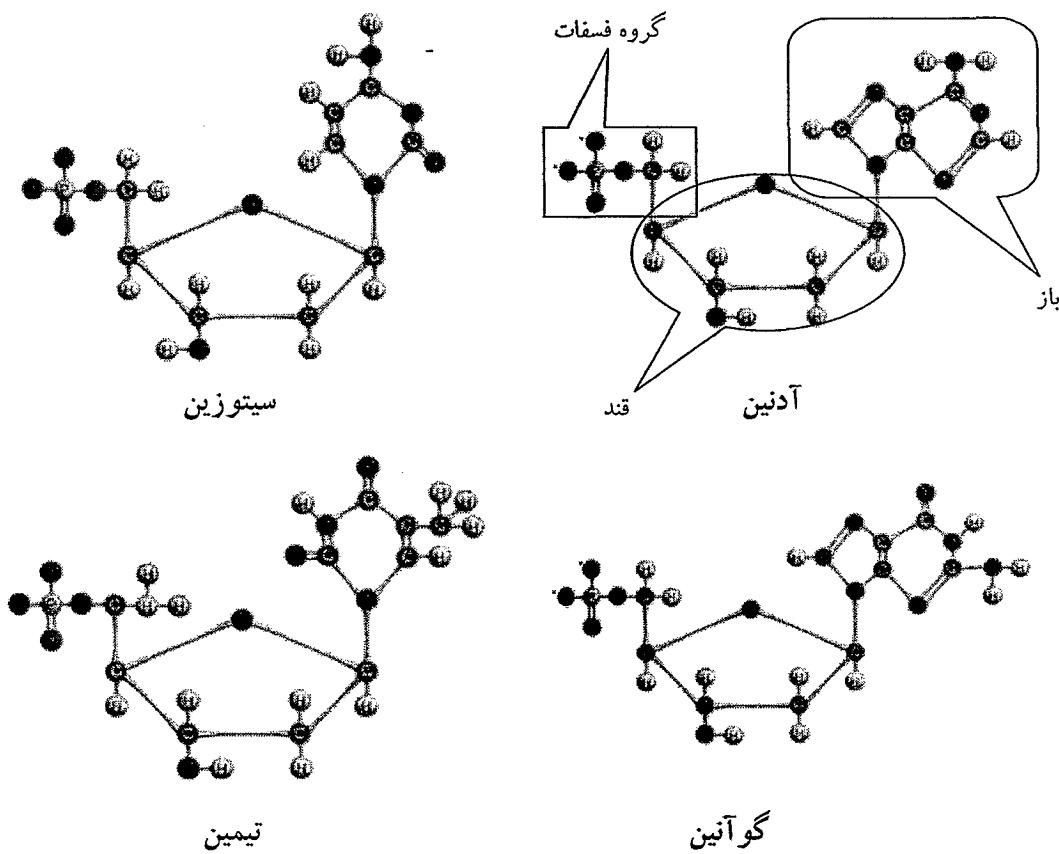
**DNA ۲.۱.۱**

*DNA* زنجیرهای از نوکلئوتیدهای<sup>۵</sup> به هم متصل می‌باشد. هر نوکلئوتید از سه قسمت تشکیل شده است(شکل ۱.۲.۱.۱):

۱) یک عدد مولکول قند

۲) یک عدد گروه فسفات

۳) یکی از چهار بازآلی یعنی آدنین<sup>۶</sup>(A)، سیتوزین<sup>۷</sup>(C)، گوانین<sup>۸</sup>(G) و یا تیمین<sup>۹</sup>(T). نوکلئوتیدهای متفاوت دارای بازهای آلی متفاوتی هستند. لذا صرف نظر از چگونگی اتصال نوکلئوتیدها به یکدیگر، توالی نوکلئوتیدها را با توالی بازهای آلی شان مشخص می‌کنیم. این چهار بازآلی در واقع حروف رمز برای توالی *DNA* هستند.



شکل ۱.۲.۱.۱

<sup>۵</sup> Nucleotide

<sup>۶</sup> Adenine

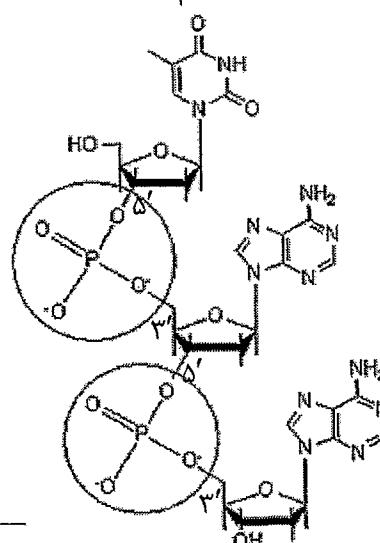
<sup>۷</sup> Cytosine

<sup>۸</sup> Guanine

<sup>۹</sup> Thymine

قندی که در هر نوکلئوتید وجود دارد دارای دو کربن به نام کربن شماره‌ی سه و کربن شماره‌ی پنج می‌باشد که به ترتیب به صورت کربن  $^3$  و کربن  $^5$  نشان می‌دهیم. گروه فسفات که به کربن  $^5$  هر نوکلئوتید متصل است به کربن  $^3$  نوکلئوتید بعدی می‌پیوندد(شکل ۲۰.۱.۱). به این صورت پیوندی به نام فسفو-دی-استر<sup>۱۰</sup> نوکلئوتیدها را مانند یک زنجیر به هم متصل می‌کند. ساختار *DNA* به شکل دو رشته‌ی مارپیچ در هم تنیده می‌باشد(شکل ۳۰.۱.۱). اگر این مارپیچ از هم باز شود، حاصل دو رشته‌ی موازی از نوکلئوتیدهایی خواهد بود که جفت جفت روبروی هم قرار گرفته‌اند(شکل ۴۰.۱.۱). پیوندهای هیدروژنی موجود بین جفت بازآلتی روبروی هم، این دو رشته را به هم چسبانده‌است. هر جفت بازآلتی روبروی هم، شامل یک باز پورین<sup>۱۱</sup> (*A*) یا یک باز پریمیدین<sup>۱۲</sup> (*C*) می‌باشد که طبق قانون، *G* فقط با *C* جفت می‌شود و *A* فقط با *T*. لذا با دانستن توالی یکی از دو رشته‌ی *DNA*، رشته‌ی مقابله آن به طور یکتا بدست می‌آید. در واقع دو رشته مکمل یکدیگرند. این رابطه بین دو رشته‌ی *DNA* را رابطه‌ی مکملی می‌گوئیم. برای همین اغلب اوقات توالی *DNA* را با یک رشته بیان می‌کنند.

از آنجایی که پیوند فسفو-دی-استر، کربن‌های  $^5$  را به  $^3$  هم متصل می‌کند، زنجیره‌ی نوکلئوتیدها دارای جهت بوده و این جهت را به صورت  $^3 \rightarrow ^5$  نشان می‌دهند. هنگام تشکیل مارپیچ، رشته‌ها به صورت موازی مقابله قرار می‌گیرند. یعنی اگر روی یکی از رشته‌ها در جهت  $^3 \rightarrow ^5$  حرکت کنیم، رشته‌ی دیگر را در جهت  $^5 \rightarrow ^3$  خواهیم دید. به جهت  $^3 \rightarrow ^5$  ( $^5 \rightarrow ^3$ ) بالادست<sup>۱۳</sup> (پائین دست<sup>۱۴</sup>) گویند.



شکل ۲۰.۱.۱

پیوند فسفو-دی-استری: از پیوند کربن  $^5$  به کربن  $^3$ ، دو نوکلئوتید متوالی به هم متصل می‌گردند.

<sup>۱۰</sup> *Phospho diester*

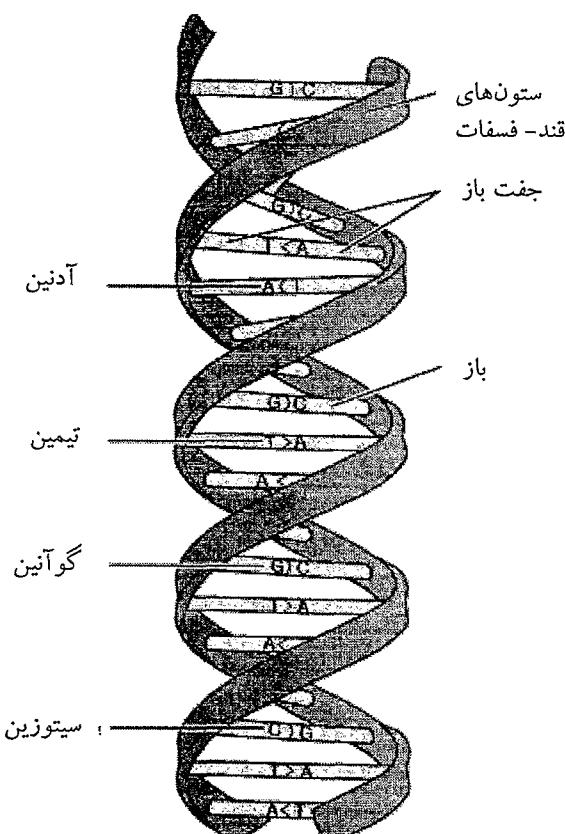
<sup>۱۱</sup> *Purine*

<sup>۱۲</sup> *Pyrimidine*

<sup>۱۳</sup> *Upstream*

<sup>۱۴</sup> *Downstream*

تعداد توالی‌های DNA در یک سلول موجودات زنده‌ی گوناگون، متفاوت است. در هر سلول انسان، ۴۶ توالی DNA وجود دارد که هر DNA در یک کروموزوم<sup>۱۵</sup> بسته‌بندی شده‌است. این ۴۶ کروموزوم به صورت ۲۳ جفت در سلول انسان یافت می‌شود. هر ژن ناحیه‌ای بر روی DNA است که شامل اطلاعاتی از یک خصوصیت وراثتی می‌باشد. همه‌ی اطلاعات وراثتی ذخیره‌شده در کروموزوم‌های یک موجود زنده را، ژنوم آن موجود می‌نامند. در ژنوم انسان نزدیک به ۱۰۰۰۰ ژن وجود دارد که طول ژنهای شناسایی شده بین ۱۰۰ تا ۲۳۰۰۰۰ نوکلئوتید است [۲].

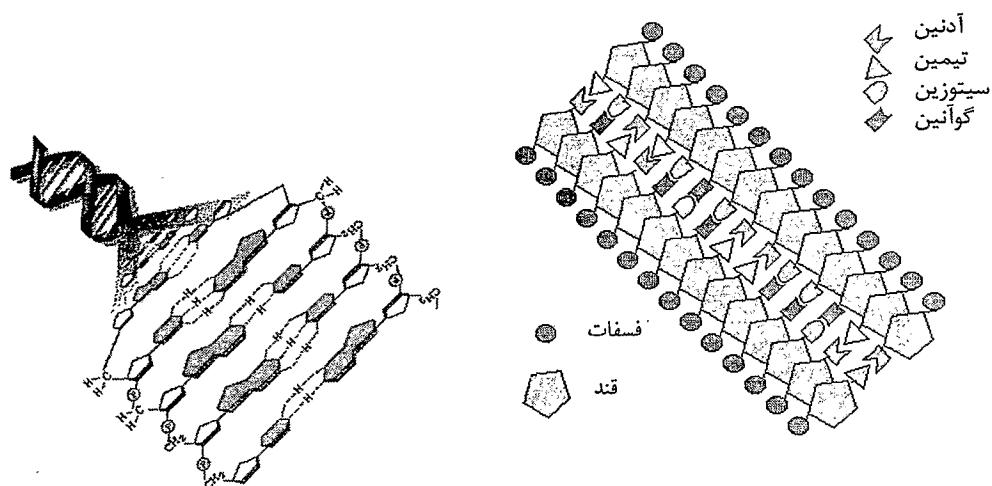


شکل ۳.۲.۱.۱

در سال ۱۹۵۳، تقریباً ۲۰ سال بعد از کشف ساختمان مولکولی DNA، ساختمان سه بعدی DNA بوسیله‌ی جیمز واتسون و فرانسیس کریک کشف شد. واتسون و کریک با استفاده از مطالعات تفرق اشعه‌ی X رشته‌های DNA که

<sup>۱۵</sup> Chromosome

بوسیله‌ی فرانکلین و ویلکینز تهیه شده بود و همچنین ساختمان مدل‌ها و استنباط‌های شخصی، مدل فضایی خود را ارائه دادند. در سال ۱۹۶۲ واتسون، کریک و ویلکینز به خاطر اهمیت کشف ساختمان DNA مشترکاً جایزه‌ی نوبل را دریافت کردند. مدل پیشنهادی آنان را در این شکل می‌بینیم.



شکل ۴.۲.۱.۱

سمت چپ: یک توالی DNA باز شده.

سمت راست: ساختار مکملی توالی DNA.

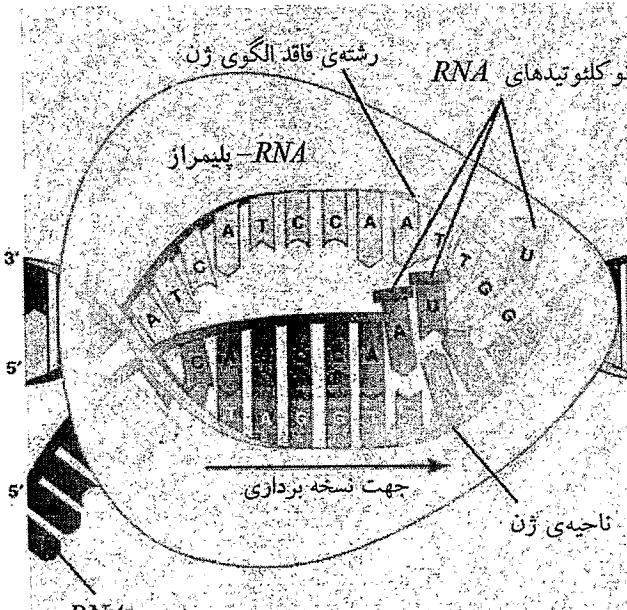
### ۳.۱.۱ mRNA، نسخه‌برداری و ترجمه

بروز خصوصیات وراثتی ذخیره‌شده در DNA، در گرو ترجمه‌ی یک ژن به رشته‌ای از پروتئین است. این کار به صورت زیر انجام می‌پذیرد:



هر ژن روی یکی از دو رشته‌ی DNA قرار دارد. ابتدا این دو رشته در مکانی که ژن وجود دارد از هم جدا می‌شود و از روی توالی ژن، مکمل آن ساخته می‌شود (شکل ۱.۳.۱.۱). به این تک رشته‌ی

مکملی  $mRNA$ <sup>۱۶</sup> (پیک) می‌گویند. ساختمان  $mRNA$  شبیه به ساختمان  $DNA$  است.  $mRNA$  بازهای  $A$ ،  $G$  و  $C$  را دارد اما به جای باز  $T$ ، بازآلی دیگری به نام اوراسیل<sup>۱۷</sup> ( $U$ ) را به کار گرفته است. پس طبق قانون مکملی هر توالی ژن یک و تنها یک رشته‌ی  $mRNA$  را می‌سازد که در آن به جای باز  $T$ ، باز  $U$  دیده می‌شود. ساخته شدن  $mRNA$  از  $DNA$  را نسخه‌برداری می‌نمند که توسط آنزیمی به نام  $-RNA$ -پلیمراز<sup>۱۸</sup> انجام می‌پذیرد.



شکل ۱.۳.۱.۱

در این مرحله، نوکلئوتیدها به ترتیب وارد  $-RNA$ -پلیمراز می‌شوند و پس از تطبیق به باز مکمل موجود در رشته‌ی  $DNA$  به نوکلئوتید قبلی متصل می‌شوند. در خاتمه،  $-RNA$ -پلیمراز از رشته‌ی  $DNA$  جدا می‌شود و تک رشته‌ای  $mRNA$  که الگوی ساخت پروتئین می‌باشد، بدست می‌آید.

روی  $DNA$  زیررشته‌هایی موجود است که حاوی اطلاعاتی از جمله تنظیم بیان ژن، نقطه‌ی شروع ژن و تعداد نسخه‌برداری‌های لازم از روی آن می‌باشد [۳]. این قطعات را عناصر تنظیم کننده گویند. اگر در جهت  $3' \rightarrow 5'$  روی  $DNA$  حرکت کنیم، بالادست نقطه‌ی آغاز ژن یکی از عناصر تنظیم کننده به نام *Promoter* وجود دارد (شکل ۲.۳.۱.۱). ناحیه‌ی *Promoter* آنزیم  $-RNA$ -پلیمراز را از نقطه‌ی آغاز نسخه‌برداری مطلع می‌سازد.

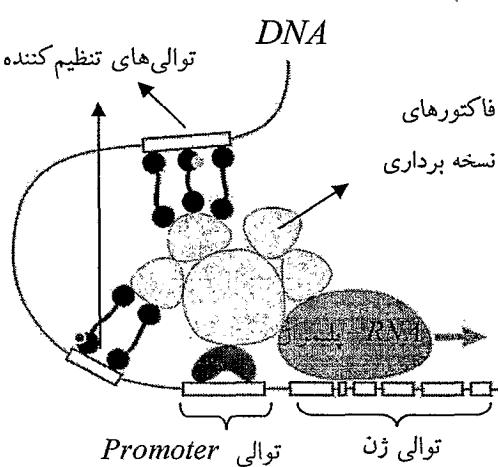
پس آن که فاکتورهای نسخه‌برداری زیررشته‌ای از *Promoter* را برای اتصال تشخیص می‌دهند، به  $DNA$  می‌چسبند و نسخه‌برداری از ژن را کنترل می‌کنند. در واقع این فاکتورها  $-RNA$ -پلیمراز را

<sup>۱۶</sup> messenger RiboNucleic Acid

<sup>۱۷</sup> Uracil

<sup>۱۸</sup> RNA – Polymerase

از موقعیت مکانی ژن مطلع می‌سازند. مکانی از *Promoter* که فاکتورهای نسخه‌برداری به آن می‌چسبند معمولاً<sup>۱۹</sup> به طول پنج تا ۳۰ نوکلئوتید است که به آن مکان اتصال فاکتور نسخه‌برداری<sup>۲۰</sup> گویند. هرچند که هر فاکتور نسخه‌برداری مکان مخصوصی برای اتصال دارد اما بعضی از این مکان‌ها به بعضی دیگر شبیه است [۳]. به این مکان‌های اتصال شبیه به هم یک موتیف<sup>۲۱</sup> گویند (شکل ۲.۳.۱.۱). پس انگیزه‌ی یافتن موتیف‌ها روشن است: یافتن یک موتیف منجر به یافتن مکان‌های اتصال و تجلی یک ژن می‌شود و می‌توان بیان آن ژن را تحت کنترل خود درآورد.



بالادست ناحیه‌ی ژن توالی‌هایی به نام توالی‌های تنظیم-کننده وجود دارد که حاوی اطلاعاتی از جمله تنظیم بیان ژن، نقطه‌ی شروع ژن و تعداد نسخه‌برداری‌های لازم می‌باشد. یکی از این تنظیم-کننده‌ها توالی *Promoter* نام دارد فاکتور نسخه‌برداری روی آن متصل می‌گردد و نسخه‌برداری از ژن آغاز می‌شود.

شکل ۲.۳.۱.۱

<sup>۱۹</sup> *Transcription Factor Binding Site*  
<sup>۲۰</sup> *Motif*



GTGCGGTAATAGCCACTCCCAGGCCGTATAACGCTCAATTGCGTAAGCCAAGGTGAACGTCCTCGAC : PRM ۱  
 ACITTCAGCTCAATTGCGTCATTGCGCCCCGATGGTGCATCGCATGAAAGAACGTCCTCGCT : PRM ۲  
 CCTCTGATCACCACAGAACTAGCCGACCCAAATTAAAGTCTCATTTGTCACACTACACGGAGGCTCAGG : PRM ۳  
 CAATTGGATTGCGCCATCCACTCGCGCTGCATCGCATCGCCGCTGAAACCGATGGCGGGAAATC : PRM ۴  
 CTGTCAGCGGGTCCGATTGAGTTAGCTGTTGCGCCACTCOOCATGACATATGCACGTAAA : PRM ۵  
 GTGTGCTCTTCCCCATCATTGCCCAACTGGACAGGCCAAGACAGGTGAGTTGGCCCTTGCTC : PRM ۶  
 CGTCGGCTAACAGTGTAGATTACATCACTATGCTCTATCCAAACAGCGTTAATCTGTAAAGTA : PRM ۷

### ۳.۳.۱.۱ شکل

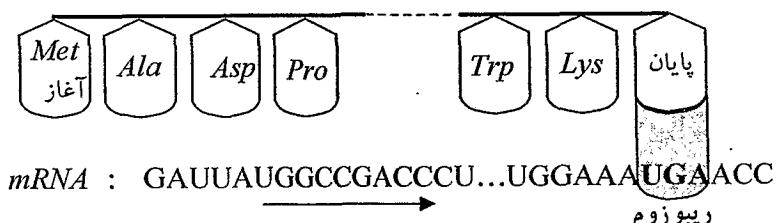
در شکل بالا هفت توالی Promoter می‌بینید که فاکتور نسخه برداری مشترکی به آن‌ها متصل شده است. مکان‌های اتصال این فاکتور نسخه برداری که به صورت پررنگ مشخص شده، شبیه به هم می‌باشد. این مکان‌ها موظیف نام دارد.

به طور مجزا هر سه نوکلئوتید متوالی را روی mRNA یک کدون<sup>۱۱</sup> می‌نامند. نقطه‌ی آغاز ترجمه‌ی mRNA به پروتئین، اوّلین کدون AUG است(شکل ۴.۳.۱.۱). یک ریبوزوم به این مکان می‌چسبد و شروع به خواندن کدون‌ها می‌کند [۴]. این ریبوزوم نسبت به هر کدون یک آمینواسید مخصوص را به زنجیر پروتئین در حال ساخت می‌چسباند و همین کار را برای کدون بعدی انجام می‌دهد. این کار وقتی خاتمه می‌پذیرد که به یکی از کدون‌های UAA، UAG و یا UGA برسد. در ابتدا به نظر می‌رسد  $4 \times 4 \times 4 = 64$  یعنی ۶۴ آمینواسید وجود داشته باشد. اما در تحقیقات آزمایشگاهی جدول ۱.۳.۱.۱ بدست آمده است که در آن تعدادی از کدون‌های متفاوت آمینواسید یکسانی را مشخص می‌کنند. طبق این جدول ۲۰ نوع آمینواسید متفاوت موجود است. در نهایت ریبوزوم با استفاده از mRNA پروتئین را می‌سازد و زن تجلی می‌یابد.

	U	C	A	G
U	UUU Phe UUC Phe UUA Leu UUG Leu	UCU Ser UCC Ser UCA Ser UCG Ser	UAU Tyr UAC Tyr UAA Stop UAG Stop	UGU Cys UGC Cys UGA Stop UGG Trp
C	CUU Leu CUC Leu CUA Leu CUG Leu	CCU Pro CCC Pro CCA Pro CCG Pro	CAU His CAC His CAA Gln CAG Gln	CGU Arg CCG Arg CGA Arg GGG Arg
A	AUU Ile AUC Ile AUA Ile AUG Met	ACU Thr ACC Thr ACA Thr ACG Thr	AAU Asn AAC Asn AAA Lys AAG Lys	AGU Ser AGC Ser AGA Arg AGG Arg
G	GUU Val GUC Val GUA Val GUG Val	GCU Ala GCC Ala GCA Ala GCG Ala	GAU Asp GAC Asp GAA Glu GAG Glu	GGU Gly GGC Gly GGA Gly GGG Gly

جدول ۱.۳.۱.۱

<sup>۱۱</sup> Codon



شکل ۴.۳.۱.۱

ریبوزوم با شناسایی کدون *AUG* شروع به خواندن *mRNA* می‌کند و به هر سه نوکلوتید متوالی یک اسیدآمینه را طبق جدول روی رو به پروتئین در حال ساخت می‌حسابند تا در خاتمه به یکی از کدون‌های *UAG*, *UAA* و یا *UGA* برسد.

## ۲۰.۱ راهبردهای اخیر

همان‌طور که در بخش ۳.۱.۱ توضیح داده شد، فاکتورهای نسخه‌برداری، بیان ژن را با اتصال به ناحیه‌ی خاصی از *Promoter* کنترل می‌کنند. مشخص کردن مکان‌های اتصال روی توالی‌های *DNA* هنوز یک مسئله‌ی سخت در زیست‌شناسی مولکولی باقی مانده است. مهم‌ترین عامل سختی این مسئله آن است که فاکتورهای نسخه‌برداری به مکان‌های بسیار متنوعی متصل می‌شوند که پیش‌بینی توالی این مکان‌ها، از قبل بسیار مشکل می‌باشد. هرچند که مکان‌های اتصال یک فاکتور نسخه‌برداری الگوی مشابهی دارند اما این الگوها به طور دقیق مشخص نیست. در نتیجه پیدا کردن آن کاری بسیار مشکل است.

یک راه برای فائق آمدن بر این مشکل استفاده از آزمایش‌های زیست‌شناسی است که اغلب پُرهزینه و زمان‌بر<sup>۲۲</sup> است. دسترسی اخیر به توالی‌های کامل ژنوم، تلاش دانشمندان را به کشف طرز کار تنظیم ژن توسط فاکتورهای نسخه‌برداری با استفاده از تحلیل محاسباتی برانگیخت. الگوریتم‌ها و ابزارهای جستجو برای عناصر تنظیم کننده به دو دسته‌ی عمده تقسیم می‌شوند:

<sup>۲۲</sup> Time Consuming

(۱) روش‌هایی که مکان‌های اتصال شناخته شده را جستجو می‌کنند. پیدا کردن مکان‌های جدید اتصال در تعدادی توالی *Promoter* منجر به یافتن طرز کار ژن(های) جدید می‌شود. لذا این الگوریتم‌ها قادر به یافتن الگوی جدیدی برای مکان‌های اتصال و در نتیجه ژن(های) جدید نیستند.

(۲) روش‌هایی که به دنبال الگوهای جدیدی برای مکان اتصال فاکتورهای نسخه‌برداری روی توالی‌های *Promoter* می‌گردند. این الگوریتم‌ها بیش از الگوریتم‌های دسته‌ی اول با سختی مسئله رویرو هستند. در فصل سه الگوریتم‌های موجود را دقیق‌تر بررسی می‌کنیم.

### ۳.۱ خط مشی ما

الگوریتم ما از لحاظ تقسیم بندی بخش ۲۰.۱ در دسته‌ی دوم می‌گنجد. یعنی الگوریتم *Libra* به دنبال الگوهای جدیدی برای مکان اتصال فاکتورهای نسخه‌برداری در مجموعه‌ای از توالی‌های *Promoter* می‌گردد که این توالی‌ها تنظیم‌کننده‌ی ژن مشترکی دارند. طول توالی‌های *Promoter* در بعضی موارد به چندهزار نوکلتوتید هم می‌رسد. لذا طول زیاد توالی‌ها نیز مسئله را سخت می‌کند (در فصل دو سختی مسئله‌ی یافتن موتفیف‌ها را به طور دقیق‌تر بررسی خواهیم کرد). در نتیجه کم کردن فضای جستجو کمک شایانی برای رسیدن به جواب در زمان معقول‌تری خواهدبود. ما به چهار نوکلتوتید  $A$ ،  $C$ ،  $G$  و  $T$  به ترتیب چهار پایه‌ی مرتب فضای برداری  $\mathbb{R}^4$  نسبت می‌دهیم. پس به جای رشته‌ای از نوکلتوتیدها، دنباله‌ای از بردارها داریم. یک تابع پیش‌بینی تعریف می‌کنیم و با استفاده از هر چهار نوکلتوتید، نوکلتوتید پنجم را با یک بردار تخمین می‌زنیم. بر اساس فاصله‌ی اقلیدسی، فاصله‌ی هر نوکلتوتید را تا بردار تخمین زده شده رتبه‌بندی می‌کنیم و رتبه‌ی نوکلتوتید پنجم را محاسبه می‌کنیم. این رتبه یکی از اعداد یک، دو، سه و یا چهار خواهدبود. سپس رتبه‌ی هر نوکلتوتید را با میانگین رتبه‌ی نوکلتوتید بعدی و قبلی آن تعویض می‌کنیم و این کار را ۱۵ بار انجام خواهیم داد تا نمودار هموارتری بدست آوریم. چون مکان‌های اتصال فاکتورها توالی‌های شبیه به هم هستند انتظار داریم در نموداری که بدست آورده‌ایم به طور مشابهی پیش‌بینی شده باشد. یعنی نمودار در آن مکان‌ها شبیه به هم باشند. لذا با استفاده از نمودار توالی *DNA* را به قطعاتی تکه‌تکه می‌کنیم و تکه‌های شبیه به هم را در یک مجموعه قرارخواهیم داد. در این صورت چهار مجموعه به ترتیب برای قطعاتی که در آن جا

نمودار نزولی، صعودی، مقعر به بالا و مقعر به پائین می‌باشد را بدست می‌آوریم. تا اینجا فضای جستجو را به تکه‌های بدست آمده محدود کرده‌ایم. هم‌دیفی تکه‌های بدست آمده را بدست می‌آوریم و با استفاده از قطعاتی که نسبت به تعریف ما شبیه به هم هستند، الگویی برای موتیف بدست می‌آوریم. در نهایت مکان‌هایی را روی توالی *DNA* جستجو می‌کنیم که به الگو شبیه هستند. این مکان‌ها پیشنهادی برای موتیف خواهد بود. در فصل چهار الگوریتم *Libra* را به دقت شرح خواهیم داد.

## مسئله‌ی یافتن موتیف

### ۱.۲ پیش‌درآمد

زیست‌شناسان در آزمایشگاه توالی‌های مختلف *Promoter* را با فاکتورهای نسخه‌برداری متفاوتی مورد آزمایش قرار می‌دهند. سپس توالی‌های *Promoter* را بر حسب اینکه فاکتور یکسانی به آنها متصل شده‌باشد، دسته‌بندی می‌کنند. این توالی‌ها در واقع ژن یکسانی را شناسایی می‌کنند. به این مجموعه از *Promoter*‌ها توالی‌های هم‌خانواده<sup>۱</sup> می‌گوییم. مشاهده نشان داده است که مکان اتصال<sup>۲</sup> در توالی‌های هم‌خانواده به هم شبیه هستند. یعنی در هر جایگاه<sup>۳</sup> از توالی‌های هم‌خانواده، فراوانی یکی از چهار نوکلئوتید *A*، *C*، *G* و *T* بیش از بقیه است. البته در بعضی جایگاه‌ها ممکن است بیش از یک نوکلئوتید از زیادترین فراوانی برخوردار باشند. می‌دانیم که مشاهدات تجربی هیچ تعریف جامع و مانعی برای شباخت ارائه نمی‌کند. با این حال به این مکان‌های شبیه به هم موتیف گویند. در واقع مشاهده شده است که مکان اتصال فاکتورهای نسخه‌برداری نیز موتیف هستند.

<sup>۱</sup> *orthologous*

<sup>۲</sup> *Binding Site*

<sup>۳</sup> *Position*

## ۲.۲ صورت مسئله‌ی یافتن موتیف

فرض کنید  $S_n, S_{n-1}, \dots, S_1, S_0, \dots, S_{-1}$  توالی DNA هم‌خانواده باشند. می‌دانیم این توالی‌ها دارای جهت هستند(بخش ۲.۱.۱). همه‌ی  $n$  توالی مذکور را در یک جهت پشت سر هم قرار می‌دهیم و رشته‌ی حاصل را  $S$  می‌نامیم. در واقع رشته‌ی  $S$  دنباله‌ای از همه‌ی نوکلوتیدهای  $S_n, S_{n-1}, \dots, S_1, S_0, \dots, S_{-1}$  می‌باشد. فرض کنید  $s_i$  و  $s_j$  به ترتیب دو زیررشته‌ی<sup>۱</sup> هم‌طول از توالی‌های  $S_i$  و  $S_j$  باشند(شکل ۱.۲.۲). فاصله‌ی همینگ<sup>۲</sup> دو زیررشته‌ی  $s_i$  و  $s_j$  به صورت زیر تعریف می‌شود:

فاصله‌ی همینگ<sup>۳</sup> دو زیررشته‌ی  $s_i$  و  $s_j$  : اگر  $k = s_i(k) = s_j(k)$  امین نوکلوتید زیررشته‌ی  $s_i$  باشد به تعداد اعضای مجموعه‌ی  $\{s_i(k), k=1, \dots, l\} \setminus \{s_j(k), k=1, \dots, l\}$  که در آن  $|s_i| - |s_j|$  طول زیررشته‌ی  $s_i$  می‌باشد، فاصله‌ی همینگ دو زیررشته‌ی  $s_i$  و  $s_j$  گویند و آن را با  $d_H(s_i, s_j)$  نشان می‌دهیم. خلاصه‌تر آنکه به تعداد جایگاه‌هایی که در آن‌ها دو زیررشته‌ی  $s_i$  و  $s_j$  نوکلوتیدهای غیریکسان دارند فاصله‌ی همینگ دو زیررشته‌ی  $s_i$  و  $s_j$  گویند.

دو زیررشته‌ی  $s_i$  و  $s_j$  به طول  $l$  را شبیه بهم گوئیم، اگر  $d_H(s_i, s_j) \leq l$  باشد. مقدار  $d$  به دلخواه تغییر می‌کند. به طور دقیق‌تر دو زیررشته‌ی  $s_i$  و  $s_j$  را شبیه بهم با پارامتر  $(l, d)$  گوئیم. ساده‌ترین تعریف موتیف به صورت زیر است:

**موتیف [۵]:** فرض کنید رشته‌ی  $S$  به دو زیرمجموعه‌ی جدا از هم به نام  $B$  و  $M$  افزای شده است. اگر مجموعه‌ی  $M$  شامل زیرقطعه‌هایی دو به دو شبیه بهم با پارامتر  $(l, d)$  باشد که شبیه آنها در مجموعه‌ی  $B$  به ندرت یافت شود، مجموعه  $M$  را موتیف می‌نامند. مجموعه‌ی  $B$  پس زمینه<sup>۴</sup> نام دارد(شکل ۱.۲.۲).

<sup>۱</sup> Subsequence

<sup>۲</sup> Hamming Distance

<sup>۳</sup> Background

CCCGAGGCCGTACGCTCAATTGCGTAAGCGCAAGGTGAAACGTCCCGAC : $S_1$   
 ACTTCAGCTCCAATTGCGTCATTCGGCCCCGATGGTGCATCGCATGAAAGAAT : $S_2$   
 GGTCTGATCGCCGAGCCAATTAAAGTCTCATTTCGTCACACTACACGAGGCTCAGG : $S_3$   
 CAATTGGGATTGCGCCATCCATTCCGGCTGCATCGATCCGCCGCTTATGGGCGGGAAATC : $S_4$   
 GTGTCAAGGGCT : $S_5$       ATTGAGTTAGGTGTTGCGCCACTCCCATGACGCACGTAAG : $S_6$   
 TCATTGCCCAACTCGACACGGCGAAGACAGGCCCTTGCTC : $S_7$   
 CAGTGTAGATTACATCACTATGCTCTATCCAATGTAAGTA : $S_8$   
**AATTGCGTAAGC : $S_1$**   
**AATTGCGTCATT : $S_2$**   
**CATTTCGTCACA : $S_3$**   
**GATTGCCCATC : $S_4$**   
**GTTTGCGCCACT : $S_5$**   
**CATTGCCCAACT : $S_6$**   
**GATTACATCACT : $S_7$**

شکل ۱.۲.۲

مجموعه توالی‌های  $\{S_1, S_2, \dots, S_7\} = S$  و مجموعه زیرشته‌های  $\{S_1, S_2, \dots, S_5\} = S$  را می‌بینید که دو به دو به هم شبیه هستند. مجموعه  $S$  یک موتیف است. نوکلئوتیدهای پس‌زمینه کرمگ و عناصر موتیف پررنگ مشخص شده‌اند.

کلی‌ترین صورت مسئله‌ی یافتن موتیف، مطابق با ساده‌ترین تعریف موتیف می‌باشد:

مسئله‌ی یافتن موتیف (در حالت کلی): برای  $n$  توالی همانواده‌ی  $S_1, S_2, \dots, S_n$  که در یک جهت پشت سرهم قرار گرفته‌اند، دو مجموعه‌ی پس‌زمینه ( $B$ ) و موتیف ( $M$ ) را بیابید.

الگوریتم‌ها برای نمایش دادن یک موتیف آن را به صورت‌های گوناگونی توصیف می‌کنند. هر یک از این توصیفات را یک مدل برای موتیف گوئیم. تعاریف گوناگون موتیف و صورت مسئله‌های متفاوت برای آن زائدی‌های همین مدل‌های گوناگون است. پس هر الگوریتمی به طور خاص به دنبال بهترین پیشنهاد برای موتیف طبق تعریف خود است. در فصل سه الگوریتم‌های متفاوت برای یافتن موتیف را بررسی خواهیم کرد.

### ۳.۲ مدل‌هایی برای توصیف موتیف

فرض کنید  $M = \{s_1, s_2, \dots, s_k\}$  یک موتیف شامل  $k$  زیررشه‌ی هماندازه به طول  $l$  باشد. برای راحتی کار، چهار نوکلئوتید  $A$ ،  $C$ ،  $G$  و  $T$  را به صورت چهارتایی مرتب  $N = (A, C, G, T)$  در نظر می‌گیریم. فرض کنید  $k$  زیررشه‌ی هم‌طول  $s_1, s_2, \dots, s_k$  را در ماتریس  $C = [c_{ij}]_{k \times l}$  ذخیره کرده‌ایم به طوریکه  $c_{ij}$  برابر با نوکلئوتید  $j$ -ام در زیررشه‌ی  $i$ -ام است. در این صورت موتیف  $M$  را می‌توان به سه روش توصیف کرد [۶]:

(۱) مدل ماتریس وزن جایگاه ( $PWM$ ): در این مدل موتیف  $M$  به صورت یک

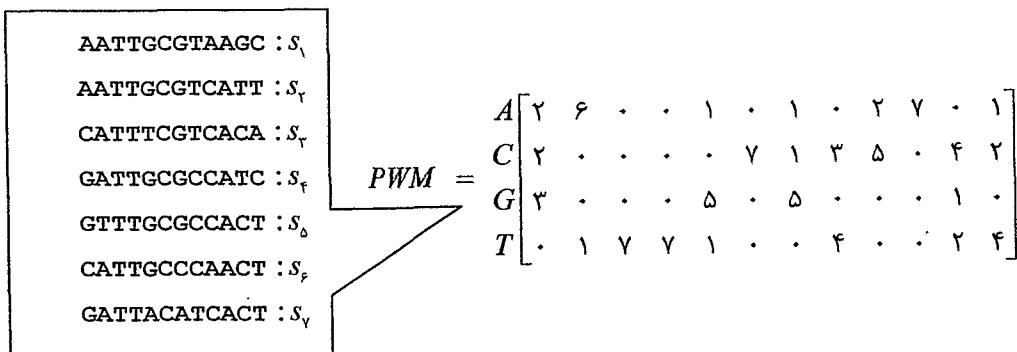
ماتریس  $4 \times l$  به نام ماتریس وزن جایگاه توصیف می‌شود. اگر

باشد آنگاه  $f_{ij}$  برابر با تعداد نوکلئوتید  $N(i)$  واقع در ستون  $j$ -ام ماتریس  $C$

است (شکل ۲.۳.۱). اگر  $j$ -امین نوکلئوتید  $s_k$  را با  $(j)$  نشان دهیم، آنگاه  $s_k$  را

شبیه به مدل  $PWM$  گوئیم اگر  $\sum_{s_k}^{PWM} = \sum_j PWM(s_k(j), j)$  به اندازه‌ی کافی

بزرگ باشد. مقدار  $\sum_{s_k}^{PWM}$  را امتیاز شباهت  $s_k$  به مدل  $PWM$  می‌نامیم.



شکل ۱.۳.۲

ماتریس  $PWM$  فراوانی هر نوکلئوتید را در هر ستون نشان می‌دهد.