

## نشست دو روزه حل مسأله در بیوانفورماتیک

نوکلئوتیدی وجود ندارد و تعداد آنها بسیار محدود است. به دلایل تجربی مشخص شده که هاپلوتیپها را می توان به بلوک هایی با تنوع محدودی از هاپلوتیپها تقسیم بندی کرد. در هر بلوک تعداد کمی از SNPها (SNPهای نماینده) کافی خواهند بود که به طور منحصر به فرد هاپلوتیپهای مشترک را تشخیص دهند.

مسأله اصلی این است: چگونه می توان این توالی SNPها را به تعدادی بلوک تقسیم بندی کرد به طوری که تعداد SNPهای نماینده مینیمم باشد.

برای حل مسأله چند شرط را باید در نظر گرفت. هاپلوتیپهای مشترک، هاپلوتیپهایی هستند که بیشتر از یک بار در یک بلوک دیده شوند. بنابراین ما نیاز داریم که در نتیجه نهایی تقسیم بندی، بخش قابل توجهی از هاپلوتیپها در هر بلوک، هاپلوتیپهای مشترک باشند (مثلاً ۸۰٪). فرض کنید که  $k$  هاپلوتیپ (از  $k$  فرد مختلف) با  $n$  SNP متوالی داریم.  $r_i, i = 1, 2, \dots, n$  یک بردار  $k$  بعدی است که  $r_i(k) = 0, 1, 2$  آلل  $k$  امین هاپلوتیپ در موقعیت SNP،  $i$  است که  $1$  و  $2$  دو آلل مختلف است و صفر به معنای آن است که وضعیت آلل در آن موقعیت مشخص نشده است (به دلایل تجربی ممکن است نتوان نوکلئوتید قرار گرفته در یک موقعیت را تشخیص داد).

یک بلوک با ترتیب  $r_1, \dots, r_j$  تعریف می شود. دو هاپلوتیپ  $k$  و  $k'$  با هم سازگار گفته می شوند اگر آللها در دو هاپلوتیپ در موقعیت هایی که صفر نباشند، یکسان باشند. به عبارت دیگر: به ازای هر  $l, l \leq j$ ، به طوری که  $r_i(k) = r_i(k')$ ،  $r_j(k)r_l(k) \neq 0$ . یک هاپلوتیپ در یک بلوک «مبهم» است اگر با دو هاپلوتیپی که با هم ناسازگار هستند سازگار باشد. با در نظر گرفتن شرط سازگار بودن، ما می توانیم هاپلوتیپ «نامبهم» را به گروه های مجزا یا بلوکها تقسیم کنیم. دو هاپلوتیپ در یک گروه خواهند بود اگر با هم سازگار باشند. با تعریف ذکر شده درباره هاپلوتیپهای نامبهم می توان تابع  $\text{block}(r_1, \dots, r_j) = 1$  را تعریف کرد، اگر حداقل  $\alpha$  درصد (مثلاً ۸۰ درصد) از هاپلوتیپهای نامبهم در بلوک بیشتر از یک بار ظاهر شده باشند. بنابراین بلوکهای به دست آمده در تقسیم بندی نهایی باید این شرایط ذکر شده را داشته باشند. همانگونه که قبلاً ذکر شد، می خواهیم تقسیم بندی اپتیمم بلوکها را پیدا کنیم (مثلاً  $B_1, \dots, B_r$ ) به طوری که تعداد کل SNPهای نماینده  $(f(B_1) + \dots + f(B_r))$  مینیمم باشد.

در طول دو روز برگزاری این نشست، الگوریتمهای متعددی که توسط دانشجویان مطرح، پیاده سازی و بررسی شد که متأسفانه هیچ کدام از آنها به حل درستی از مسأله منجر نشد. پس از آن تعدادی از دانشجویان کار

در روزهای ۲۲ و ۲۳ دی ماه ۸۴ یک دوره دو روزه حل مسأله به پیشنهاد رئیس پژوهشکده علوم کامپیوتر، دکتر حمید سربازی آزاد و به سرپرستی دکتر روزه توسرکانی در پژوهشگاه دانشهای بنیادی برگزار شد که هدف از آن، کسب یک تجربه جدید در استفاده از توان دانشجویان برجسته علوم ریاضی و کامپیوتر برای حل یک مسأله باز و مهم روز بود. با توجه به اهمیت زیاد بیوانفورماتیک به عنوان یک رشته جدید و در حال رشد و همچنین ماهیت بین رشته ای آن که به علوم ریاضی و کامپیوتر وابسته است، بررسی یک مسأله بیوانفورماتیک و تلاش برای حل آن به عنوان موضوع فعالیت انتخاب شد. بدین منظور از دکتر مهدی صادقی از پژوهشگاه ملی مهندسی ژنتیک و دکتر چنگیز اصلاحچی از دانشکده ریاضی دانشگاه شهید بهشتی که در این زمینه فعالیت می کنند، دعوت شد تا با طرح یک مسأله، با این دانشجویان در جهت پیدا کردن راه حل آن همکاری کنند. مسأله ای با عنوان بخش بندی بلوکهای هاپلوتیپی (Haplotype Block Partitioning) برای دانشجویان مطرح شد که می توان آن را به طور خلاصه به شرح زیر بیان کرد.

ماده ژنتیکی یا DNA را می توان به صورت یک رشته پیوسته از چهار مولکول متفاوت (نوکلئوتید) که با نمادهای A, C, G, T مشخص می شوند تعریف کرد. طول این رشته در انسان حدود ۳ میلیارد است که در ۲۳ جفت کروموزوم با اندازه های مختلف تقسیم شده است. در واقع هر کروموزوم یک زنجیره بسیار طویل با اندازه متوسط حدود ۱۵۰ میلیون نوکلئوتید است.

نشان داده شده است که در افراد مختلف حدود سه میلیون موقعیت در رشته DNA وجود دارد که در این موقعیتها، نوع نوکلئوتید قرار گرفته در انسانها متفاوت است و در بقیه موقعیتها (۹۹/۹٪) نوکلئوتیدها شبیه به هم هستند. همچنین نشان داده شده است که در هر کدام از این موقعیتها فقط دو نوکلئوتید از چهار نوکلئوتید می توانند قرار گیرند. این موقعیتها چندریختی تک نوکلئوتیدی (Single Nucleotide Polymorphism) یا به اختصار SNP نامیده می شوند و دو نوکلئوتید قرار گرفته در این موقعیتها آلل (Allele) نام دارند. بنابراین، چنانچه ترتیب سه میلیارد نوکلئوتید در یک فرد شناخته شده باشد در افراد دیگر فقط با دانستن نوکلئوتید قرار گرفته در موقعیت های ترتیب کل توالی نوکلئوتیدها شناخته خواهد شد. از آنجایی که در هر فرد در موقعیت های SNP یکی از دو نوکلئوتید می تواند قرار گیرد، تعداد کل توالی های متفاوت ممکن در انسان  $2^n$  است که  $n$  تعداد این موقعیت های SNP است. ترتیب نوکلئوتیدها در این موقعیتها در یک فرد، هاپلوتیپ آن فرد نامیده می شود. از راه های تجربی و نظری نشان داده شده است که در بین انسانها همه این  $2^n$  تنوع

نرم افزار مناسب توسط امین صادقی، دانشجوی کارشناسی مهندسی کامپیوتر، دانشگاه صنعتی شریف در حال انجام است که انتظار می رود به زودی تکمیل شود.

بر روی حل مسأله را ادامه دادند که نهایتاً یک فرمول بندی بر اساس نظریه اطلاعات به نتایج قابل توجهی منجر شد که کار بر روی آن و استخراج اطلاعات از یک پایگاه داده واقعی مربوط به ژنوم انسان و نهایتاً تهیه یک



## چه کشوری سریعترین رشد را در تولیدات علمی دارد؟

ممکن است بگوئید چین؛ ولی اشتباه می کنید. طبق تحقیقی که اخیراً مؤسسه بازرگانی و صنعت بریتانیا (DTI) درباره رتبه بندی کشورها از لحاظ علمی انجام داده، کشور دیگری حائز این رتبه است. در این بررسی، انواع شاخص های ورودی و خروجی برای به دست آوردن تصویر نسبتاً کاملی از توزیع فعالیت و تأثیر علمی در سراسر جهان مورد توجه قرار گرفته است. علی رغم پاسخ تعجب آوری که عنوان این نوشته دارد (و در پایان مطلب آن را افشا خواهیم کرد)، این گزارش رشد سریع چین را به مثابه یک قدرت علمی که برتری سابقاً بی چون و چرای آمریکا را به چالش طلبیده، تأیید می کند و نیز (در چشم انداز محدود ملی) مؤید عملکرد نسبتاً قوی بریتانیاست که نسبت به رقابیش پول کمتری صرف تحقیق می کند و پژوهشگران کمتری دارد ولی در مقایسه، دانش بیشتری با تأثیر زیاد تولید می کند.

در زمینه بودجه تحقیقات علمی، صعود چین بیش از هر کشوری چشمگیر است. بودجه پژوهشی چین (با در نظر گرفتن ملاحظات مربوط به قدرت خرید) طی دهه گذشته چهار برابر شده و اکنون بیشتر از هر کشوری در جهان بجز آمریکا و ژاپن است و به نصف کل بودجه تحقیقات در اتحادیه اروپا رسیده است. از لحاظ میزان انتشارات علمی، سهم چین ۵٪ کل جهان است و در دهه گذشته سه برابر شده و امروز بیشتر از فرانسه است. اگر هر کشوری جداگانه در نظر گرفته شود، ایالات متحده آمریکا هنوز هم در صدر قرار دارد و تقریباً یک سوم کل محصول علمی جهان را تولید می کند، ولی اتحادیه اروپا در مجموع از آمریکا پیشی گرفته و سهم آن ۳۷/۹٪ از کل انتشارات است. بریتانیا با حدود ۹٪ مقام دوم را در بین تک تک کشورها دارد و اخیراً ژاپن را پشت سر نهاده است. گروه کشورهای آسیلپاسیفیک (چین، کره، تایوان، و سنگاپور) روی هم رفته ۱۰٪ از تولید علمی جهان را در دست دارند. و اما درباره کیفیت و تأثیر. در این مورد آمریکا هنوز به وضوح پیشگام است؛ اگر سهم هر کشور از پرارجاع ترین مقاله ها (با در نظر گرفتن ۱٪ بالا در هر رشته) به عنوان شاخصی از تأثیر جهانی قلمداد شود، آمریکا با ۶۱٪ در رأس قرار دارد. بریتانیا سهم خود را از مقاله های پرارجاع افزایش داده و به ۱۳٪ رسانده است. چین از این لحاظ هنوز نسبت به صدرنشینان عقبتر است ولی فاصله اش از آنها در حال کم شدن است به خصوص که شمار ارجاعات، یک شاخص تأخیری است یعنی مدتی طول می کشد تا ثمره صرف بودجه در تحقیقات به صورت انتشار مقاله ها ظاهر شود و پس از آن، پژوهشگران دیگر به آن مقاله ها استناد کنند.

کشوری که رشد انتشارات علمی آن طی دهه گذشته بیش از همه بوده، ایران است که میزان تولید آن ده برابر شده است (هرچند نسبت به میرانی اندک در آغاز دهه). باید دید که آیا با توجه به تحولات سیاسی اخیر، ایران می تواند همچنان به عملکرد خوب خود در این زمینه ادامه دهد یا خیر.

منبع:

<http://www.softmachines.org/wordpress/>