

آرثر م. ليسك

مقدمة في

البيو معلوماتية

عرض: د. محمد باسم عاشور

كتاب
البيو
معلوماتية

أبحاثات جديدة حول العلم والمستقبل



المكتبة الأكاديمية

شركة مساهمة مصرية - القاهرة

EBSCO Publishing : eBook Arabic Collection Trial - printed on 4/9/2020 6:30 AM via MINISTÈRE DE L'EDUCATION NATIONALE, DE LA FORMATION PROFESSIONNELLE

AN: 844665 ; Lesk, Arthur M., .; : Introduction to bioinformatics

Account: ns063387

مقدمة في البيو معلوماتية

Introduction to Bioinformatics

تأليف

Arther M. Lesk

الناشر

Oxford Univ. Press, 2002

عرض

د. محمد باسم عاشور

أستاذ علم السمسمية - جامعة الزقازيق

الناشر



المكتبة الأكاديمية

ش.م.م

٢٠٠٦

هذه الكراسة تقدم عرضاً تفصيلياً لكتاب :

Introduction to Bioinformatics

Arther M. Lesk

Oxford Univ. Press, 2002

حقوق النشر

الطبعة الأولى - م ٢٠٠٦ هـ ١٤٢٥

حقوق الطبع والنشر © جميع الحقوق محفوظة للناشر :

المكتبة الأكاديمية

شركة مساعدة مصرية

رأس المال المصدر والمدفوع ١٦,٢٨٥,٠٠ جنية مصرى

١٢١ شارع التحرير - الدقى - الجيزة

القاهرة - جمهورية مصر العربية

تليفون : ٣٣٦٨٢٨٨ - ٧٤٨٥٢٨٢ (٢٠٢)

فاكس : ٧٤٩١٨٩٠ (٢٠٢)

لا يجوز استنساخ أى جزء من هذا الكتاب بأى طريقة
كانت إلا بعد الحصول على تصريح كتابي من الناشر .

هذه السلسلة

هي الثالثة في مشروع "الكراسات"، الذي تصدره "المكتبة الأكاديمية". والكراسات تعنى بمحورين كبيرين: العلم والمستقبل. لذلك فقد حملت السلسلة الأولى عنوان "كراسات مستقبلية"، وقد بدأ ظهورها عام ١٩٩٧. وفي عام ١٩٩٨ ظهرت السلسلة الثانية تحت اسم "كراسات علمية". وقد فكرنا في البداية أن تضم السلسلتين، بجانب التأليف والترجمة، عروض مطولة لبعض الإصدارات المهمة، التي لا تلافقها حركة الترجمة. إلا أن أنشطأعضاء أسرة الكراسات، وللكراسات أسرة متعددة ترحب دائمًا بالأعضاء الجدد، أقول أن أنشط الأعضاء الصديق الدكتور محمد رؤوف حامد، الأستاذ بهيئة الرقابة الدوائية، اقترح أن تصدر العروض في سلسلة خاصة بها. وقد كان اقتراحًا موفقاً كما أرجو أن يوافقني القارئ.

والكتب المختارة للعرض في السلسلة لاتأتى فقط من اقتراحات هيئة التحرير، حيث قدم أعضاء الأسرة مقترحتهم التي حظيت بالترحيب، والباب مفتوح لكل من يرغب في المشاركة. وإذا كانت السلسلة قد بدأت بمجموعة من الكتب الصادرة بالإنجليزية، فإننا نطمح أن تشمل العروض القادمة كتاباً تصدر في لغات أخرى، لتشملها عادة خطط الترجمة كالإسبانية والروسية والصينية، بالإضافة إلى الفرنسية والألمانية. فرغم أن الأخيرتين أكثر حظاً نسبياً، إلا أن كم المترجم والمعرض لا يقارن بما يتم بالنسبة للإنجليزية.

والحديث عن "العروض" يذكرنا بالجهود السابقة، التي لانتكرها، بل نحاول أن نكمل مسيرتها. وبالنسبة للعروض الموسعة، تذكر جهود الهيئة العامة للإستعلامات بالنسبة للمجالات التي تهمها. كما أن العروض المتوسطة، التي أصدرتها هيئة الكتاب في التسعينيات، ضمن سلسلة "تراث الإنسانية" لا يمكن إغفالها. وهما مثلث يقصد بهما الإعتراف بفضل السبق، دون أن ندعى الحصر. وإن كنا، في الوقت نفسه، نظن أن السلسلة الحالية هي الأولى التي تعنى بالعرض التفصيلي للكتب.

هذه الكراسة

هي الأولى التي يمكن للقارئ المتخصص أن يطالعها وهو متصل بالإنترنت ليمارس بعض تطبيقات البيومعلوماتية الموضحة بها. لكنها أيضاً موجهة للقارئ العام، الذي يريد أن يلم بهذا المجال الجديد، الذي ذكر أنه قد حول البيولوجيا (علم الحياة) إلى علم معلوماتي. ولأن المجال يجمع بين البيولوجيا والمعلوماتية فالبيولوجي المهتم بتطبيقاته يحتاج إلى الإلمام بالقاعدة المعرفية والمهارات المعلوماتية التي تمكن من ذلك. والمشتغل بالمعلومات يحتاج بدوره إلى مزيد من المعرفة عن البيولوجيا التي سيوظف تخصصه فيها. والقارئ العام، الذي يسعى إلى تنقيف نفسه علمياً، يهمه أن يفهم كيف تساهم البيومعلوماتية في تشكيل صورة المستقبل في الطب والزراعة والبيئة... إلخ. لذلك رحبت السلسلة بالعرض المتميز لكتاب أثر ليسك "مقدمة في البيومعلوماتية"، الذي أعده الدكتور محمد باسم عاشور، أستاذ علم السمسمية ووكيل كلية الزراعة جامعة الزقازيق، الذي سبق أن قدمنا له كراسة مستقبلية عن التكنولوجيا الحيوية الزراعية.

أ. د. أحمد شوقي

يناير ٢٠٠٦

تقديم

البيومعلوماتية مجال علمي تطبيقي جديد، زادت أهميته وال الحاجة اليه مع توفر الكم الهائل من المعلومات والتى نتجت عن مشروع الجينوم البشرى، وغيره من جينوم كائنات عديدة، وكذلك ضرورة تشخيص فيروسات تسبب أمراض خطيرة فى الكائنات وما يتطلبه من تحديد تتابعات والتعرف على تركيب، وانتاج أ虺صال، وتصميم دواء، وحلول لمشاكل المقاومة للمضادات الحيوية والدواء والمبيدات.

تقدم البيومعلوماتية مجموعة من المهارات المتعلقة بأدوات جمع المعلومات والتنقيب عن البيانات وبناء المعرفة فى البحوث الجارية والتطبيقات الصناعية والأكاديمية وغيرها. وذلك باستخدام برامج كمبيوتر لعمل استنتاجات من أرشيف بيانات البيولوجيا الجزيئية الحديثة، والربط بينها والوصول الى تنبؤات مفيدة. ويتحقق ذلك ليس فقط عن طريق تطوير وزيادة السعة التخزينية ولكن أيضا بابتكار النماذج الحسابية والصور التقديرية لمعالجة البيانات.

ومجال البيومعلوماتية هو نتاج التزاوج بين علوم البيولوجيا وعلوم الكمبيوتر وهندستها ويعظمى باهتمام المشغلين بذلك العلوم. لذلك من المهم بالنسبة لعلماء البيولوجيا دراسة الكمبيوتر وكذلك تدريس البيولوجيا للمتخصصين فى علوم الكمبيوتر. حيث يتطلب هذا المجال تكامل وفهم للخلفية البيولوجية مع اكتساب مهارات ضرورية فى مجال الكمبيوتر.

ويهدف كتاب "مقدمة فى البيومعلوماتية الى بناء وتطوير خلفية عن مجال البيومعلوماتية بدون الاعتماد على طرق معقدة فى علوم الكمبيوتر أو مهارات برمجة متقدمة. وذلك بدعم وتشجيع استخدام الأدوات الحسابية والصور التقديرية بطريقة مرضية وشيقه. وكذلك يتيح الكتاب لقارئه التفاعل مع موضوع الدراسة، وتطويع المادة العلمية طبقاً للحاجة مع توفير مصادر لمواقع الكترونية متنوعة.

دكتور محمد باسم عاشور

الفصل الأول

مقدمة

علم البيولوجي من العلوم التي تعتمد على المشاهدة وحديثاً أصبح من العلوم الاستنتاجية حيث تغيرت طبيعة النتائج. ومن المعروف للجميع أن جميع المشاهدات البيولوجية الأساسية تشتمل على سرد لروايات بدرجات متفاوتة من الدقة. إلا أنه في الفترة الأخيرة أصبحت البيانات ليست فقط أكثر كما ودقة، ولكن متحفظة وحكيمة كما هو الحال في بيانات تتابعات النيكلويونيدات في الأحماض النووية.

ومن الممكن الآن تقدير تتابع الجينوم لكتائين منفرد أو نسخة منه ليس فقط كاملاً بل على نحو صحيح ودقيق. ومع أنه ليس من الممكن تجنب الخطأ التجريبي إلا أنه منخفض للغاية بالنسبة للتتابع الجينومي.

وكذلك من الخصائص الواضحة لبيانات البيومعلوماتية أنها ذات كم هائل جداً. فمثلاً يحتوى بنك البيانات لتتابع النيكلويونيد على 9×10^{16} من القواعد (16 Gbp). لو استخدم الحجم التقريري للجينوم البشري (٣,٢) 10^9 حرفاً) كوحدة فإن ذلك يعادل (٢ bugs, an apt name). وللمقارنة المرجعية فإن bug يقابل عدد الحروف التي ظهرت في اعداد نيويورك تايمز لمدة ٦ سنوات. تحتوى قاعدة البيانات لstrukib الجزيئات الكبيرة Macro molecules (الأبعاد الثلاثية للبروتينات بمتوسط طول ٤٠٠ حمض أميني) على ١٦٠٠٠ قيد.

شجع الكم الهائل المتاح من البيانات العلماء إلى السعي نحو أهداف قياسية وطموحة مثل:

- التأكيد على قدرة العلماء على الرؤية الواضحة وال الكاملة للحياة. بمعنى الفهم المتكامل لبيولوجيا الكائنات كأنظمة مترابطة و معقّدة.

- إيجاد وربط علاقة التتابع والتركيب ثلاثي الأبعاد والتدخلات والوظيفة لبروتينات وأحماض نوية منفردة وكذلك لمعدن البروتين - الحامض النووي.
- استخدام بيانات لكائنات معاصرة كأساس للحركة الزمنية للخلف والأمام للاستدلال الزمني على وقائع منذ تاريخ النشوء ووصولاً دراسات العلماء المتألقة لتطور الأنظمة البيولوجية.
- دعم التطبيقات في مجال الطب والزراعة وغيرها من المجالات العلمية.

سيناريو A Scenario

كلمة سريعة دور طرق الحساب الآلي في البيولوجيا الجزيئية، دعنا نتخيل أن هناك مأساة في المستقبل حيث ظهور فيروس جديد يسبب مرضًا وبائيًا للإنسان أو الحيوان. في هذه الحالة سوف يقوم العلماء بعزل المادة الوراثية معملياً وتحديد التتابع وحينئذ تستخدم برامج الكمبيوتر.

وباستعراض هذا الجينوم الجديد ومضاهاته بالبيانات الوراثية المعروفة والموجودة في بنك البيانات سوف يتم تعريف وتشخيص ذلك الفيروس وكذلك تحديد علاقته بالفيروسات التي سبق دراستها (١٠). تستمر بعد ذلك الدراسات بهدف إنتاج علاج مضاد للفيروس. وبما أن الفيروسات تحتوى على جزيئات بروتين والتى تعتبر كأهداف مناسبة للعقاقير التي تتدخل مع تركيب ووظيفة الفيروس وأن تتابع الأحماض الأمينية للبروتينات عبارة عن رسائل مكونة من ٢٠ حرفاً من الحروف الهجائية، لذا باستخدام تتابع الحمض النووي دنا DNA يمكن بالاستعانة ببرامج الحاسوب الآلي استنتاج تتابعات الحمض الأميني في واحد أو أكثر من بروتينات الفيروس والتى لها دوراً حاسماً في التكرار والمضاهاة (١٠).

ومن خلال تتابع الحمض الأميني سوف تقوم البرامج بالحساب الآلي لتركيب تلك البروتينات على أساس أن تتابع الأحماض الأمينية يحدد التركيب ثلاثي الأبعاد لها وبالتالي خصائصها الوظيفية. في بداية الأمر

سوف يتم مراجعة البيانات الموجودة في بنك المعلومات الخاصة بالبروتينات قريبة الصلة والمعروفة تركيبيها (١٥). اذا تم التعرف على أحد التراكيب فان مشكلة التنبؤ بالتركيب الجديد سوف تختزل الى اذنی درجة ممكنة (التنبؤ بالغيرات في التابع) وهذا يمكن التنبؤ بتركيب الأماكن المستهدفة للبروتين باستخدام نماذج التماثل Homology modeling (٢٥). أما في حالة عدم وجود تركيب ذات علاقة ويبدو أن بروتين الفيروس جديد تماماً فان عملية التنبؤ بالتركيب يجب أن تجرى بالكامل *ab initio* (٥٥). وسوف يقل في المستقبل تكرار مثل هذه الحالات حيث أنه بمرور الوقت سيحدث نمو في حجم البيانات التي يمكن تزويد البنك بها وبالتالي تزداد المقدرة على الكشف عن تراكيب عديدة.

بمعرفة تركيب بروتين الفيروس يصبح من الممكن تصميم مادة للعلاج. وحيث تمتلك البروتينات أماكن على سطح الجزيء تتناسب مع وظيفة البروتين والتي يمكن تعطيلها، فإنه من الممكن تعريف وتصميم جزيء صغير متواافق من حيث الشكل والشحنة مع المكان المستهدف على سطح البروتين ليعمل كدواء مضاد للفيروس (٥٠). وهناك طريقة بديلة تعتمد على تصميم أجسام مضادة لبروتين الفيروس ثم تصنيعها واستخدامها لمعادلة الفيروس (٥٠).

يقوم هذا السيناريو على أساس ثابتة وليس هناك مجالاً للشك أنه في يوم ما سوف يطبق كما هو.

هناك سبب وحيد يحول دون تطبيق ذلك السيناريو لموجة الفيروس المسبب لمرض الايدز وهو أن تلك الفيروسات تمتلك قدرة ما على الحماية الذاتية. وعلماء الكمبيوتر عند قراءتهم لهذا الكتاب يدركون أن الأرقام المذكورة بين أقواس في هذا الكتاب لم تستخدم للاستدلال على مراجع ولكنها تتبع نظام D. E. Knuth لفهرسة درجة صعوبة مشكلة تحت البحث كما ورد في كتابه *The art of computer programming* الآلي

programming حيث تدل الأرقام أقل من ٣٠ على مشاكل ذات حلول موجودة بالفعل أما الأرقام الأعلى تدل على موضوعات قيد البحث.

وأخيرا فانه يجب أن يكون من المعلوم أن الطرق التجريبية البحتة لا يجد مواد مضادة للفيروس سوف تظل ولسنوات عديدةقادمة أكثر نجاحا من التوجهات النظرية.

الدوجما: مركزاً وطرياً **Dogmas: Central & Peripheral**

تعتبر مادة الوراثة دنا DNA وفي بعض الفيروسات رنا RNA هي سجل المعلومات في الكائنات (طبيعة التطور والنشاط لكل فرد). وكما هو معروف فان جزيئات دنا عبارة عن سلسلة طويلة خطية تحتوى على رسالة مكونة من أربعة حروف هجائية. والرسالة طويلة حتى في الكائنات الدقيقة تتكون من ٦١٠ حرفا تماما. ويتضمن تركيب الدنا على آليات للنسخ الذاتي وتكون البروتينات. يؤدى التركيب الحذرونى المزدوج والمتماثل داخليا الى نسخ دقيق. ومع أن النسخ الدقيق ضروري لثبات الصفة الوراثية إلا أن بعض عمليات النسخ غير الدقيق أو آليات نقل مادة وراثية غريبة تكون أحيانا ضرورية لحدوث النشوء في الكائنات اللاجنسيه.

شرائط الحذرون المزدوج تكون في وضع متوازياً وعكضاً ويعرف بالاتجاه ٣-٥ وذلك بالنسبة لأماكن حلقة الداي أوكسى ريبوز وعند ترجمتها إلى بروتين يقرأ تتابع الحمض النووي في الاتجاه ٣-٥. ويتم تنفيذ المعلومة الوراثية من خلال تخليق الرنا والبروتينات. والبروتينات هي الجزيئات المسئولة عن غالبية التركيب والأنشطة في الكائنات. فالشعر والعضلات والإنزيمات والمستقبلات والأجسام المضادة جميعها بروتينات وكل من الأحماض النوويه والبروتينات جزيئات تتكون من سلسلة طويلة خطية. تتكون الشفرة الوراثية من ثلاثة حروف متتالية من تتابع الدنا تحدد أحماض أمينية متتالية وبامتداد تتابعات الدنا يشفّر تتابعات

الأحماض الأمينية في البروتينات. كذلك تكون البروتينات من ٢٠٠ - ٤٠٠ حمض - أميني تتطلب من ٦٠٠ - ١٢٠٠ حرفاً من رسائل الدنا لتحديد ها. تخليق جزيئات الرنا أيضاً يتحكم فيه تتابعات الدنا بالرغم من أنه في معظم الكائنات ليس كل الدنا يترجم إلى بروتينات ورنا. بعض المناطق في تتابع الدنا يختص بالتحكم في آليات محددة كما توجد كميات كبيرة من الجينوم في كائنات راقية يبدو أنه لا فائدة منها Junk بمعنى أنه حتى الآن لم يتم التعرف أو فهم وظائفها.

في جزيئات الدنا التمايل في الحروف الهجائية يؤدي إلى التشابه الكيميائي والتوحد في الشكل. وعلى العكس - تظهر البروتينات اختلافات كبيرة في التوزيع ثلاثي الأبعاد. وذلك ضروري لدعم التنوع التركيبى والوظيفى الكبيرين لها. يحدد تتابع الحمض الأميني في البروتين التركيب ثلاثي الأبعاد له. يوجد لكل تتابع طبيعي للحمض الأميني حالة فطرية ثابتة مميزة والمتأقلمة تلقائياً تحت الظروف المناسبة. عندما يتم تسخين بروتين منقى أو يتعرض لظروف مغايرة للبيئة الفسيولوجية الطبيعية ينتج تركيب غير حلزوني ذو تركيب مختلف وغير نشط بيولوجيا. لذلك تمتلك الثدييات آليات للحفاظ على ثبات درجة الحرارة داخل أجسامها. وتستعيد جزيئات البروتين تركيبها الفطري عند العودة للظروف الطبيعية وبصورة مماثلة للحالة الأصلية.

الطي التلقائي في جزيئات البروتينات لتكوين حالتها الفطرية هي النقطة التي عندها تقوم الطبيعة بالقفزة الضخمة من بعد الأحادي لعالم تتابعات الوراثة والبروتين إلى العالم ثلاثي الأبعاد الذي نعيش. وهذا يوجد تناقض ظاهري فترجمة تتابعات الدنا إلى تتابعات حمض أميني من السهل أن توصف منطقياً بواسطة الكود الوراثي بينما من الصعب جداً الوصف المنطقي للاتفاق الدقيق للسلسلة متعددة الببتيدات إلى تركيب ثلاثي الأبعاد. بينما تتطلب عملية الترجمة الآلية الضخمة المركبة للريبوسوم

- الرنا الناقل وجزئيات مصاحبة - الا أن عملية طى البروتين تحدث تلقائيا.

تعتمد وظائف البروتينات على التركيب الثلاثي الأبعاد الفطري. على سبيل المثال يحتوى تركيب أي إنزيم على تجويف على سطح الجزيء يقوم بالارتباط بجزء صغير ليجاور أحماض أمينية حفارة. لذلك نذكر النموذج التالي:

- يحدد تتابع الدنا تتابع البروتين
- يحدد تتابع البروتين تركيب البروتين
- يحدد تركيب البروتين وظيفة البروتين

تركز معظم أنشطة المعلوماتية الحيوية المنظمة على تحليل البيانات ذات الصلة بتلك العمليات.

إلى هذا الحد لم يتضمن هذا النموذج على مستويات أعلى من المستوى الجزيئي للتركيب والتنظيم وتشتمل على سبيل المثال على أسئلة كتلك المتعلقة بكيفية تخصص الأنسجة أثناء التطور أو أكثر تعقيراً ككيف تمارس التأثيرات البيئية تحكمها في الأحداث الوراثية. في بعض الحالات البسيطة يكون من المفهوم على المستوى الجزيئي كيف أن زيادة كمية مادة تفاعله تسبب زيادة إنتاج الإنزيم المحفز لتحوله. والأكثر تعقيداً هي برامج التطور خلال فترة حياة الكائن. تلك المشكلات الساحرة المتعلقة بتدفق المعلومات في الكائن والتحكم فيها أصبحت الآن تأتي من خلال مجال البيو-معلوماتية.

يتضمن بنك البيانات على سجل للمعلومات وتنظيم أو كيان منطقي لتلك المعلومات وأدوات للاتصال به. يغطي بنك البيانات للبيولوجيا الجزيئية تتابعات الحمض النووي والبروتين وتركيب ووظائف الجزيئات الكبيرة. وتشتمل على:

الشهادات وسجلات البيانات Observables and Data Archives

- بنك بيانات سجلية للمعلومات البيولوجية:
 - تتابعات الدنا والبروتين متضمنة الشرح والتفسير.
 - تراكيب الحمض النووي والبروتين وشرحها. بنوك بيانات لطرز تعبير البروتين.
- بنوك بيانات فرعية: تحتوى على المعلومات المجمعة من بنوك البيانات السجلية والناجحة عن تحليل محتواها. فعلى سبيل المثال:
 - بواسعه تتابع (خصائص عائلات البروتينات)
 - الطفرات والاختلافات في تتابعات الدنا والبروتين
 - تصنيف أو علاقات (الصلات والخصائص المشتركة للمدخلات في السجلات. مثل بنك بيانات لمجموعة من عائلات تتابع البروتين أو تصنيف متسلسل لطرز التفاف البروتين.
- بنوك بيانات مرجعية
- بنوك بيانات لموقع الوب
- بنوك بيانات لبنوك البيانات المحتوية على معلومات بيولوجية
 - روابط بين بنوك البيانات

تساؤلات قاعدة البيانات تبحث تعريف مجموعة من المدخلات (على سبيل المثال: تتابعات أو تراكيب) على أساس صفات محددة أو على أساس التشابه مع محس للتتابع أو التركيب. أكثر التساؤلات شيوعا هو: عند تقدير تتابع أو تركيب جديد ما هو درجة التشابه بينه وبين المجدود في بنوك البيانات؟ بمجرد التوصل إلى مجموعة من التتابعات أو التراكيب من قاعدة بيانات ملائمة تتشابه مع المحس يصبح الباحث قادرًا على تعريف وبحث خصائصها العامة.

آليات الاتصال بينك للبيانات هي مجموعة من الأدوات للإجابة على الأسئلة الآتية:

- هل يحتوى بنك البيانات على المعلومات المطلوبة؟ (مثال: في أي من بنوك البيانات يمكن الحصول على تتابعات الحمض الأميني للكحول ديهيدروجينيز؟)
- كيف يمكن جمع معلومات منقاة من بنك البيانات في صورة مفيدة؟ (مثال: كيف يصنف قائمة لتتابعات الجلوبين أو جدول لمصفوفة تتابعات الجلوبين؟)
- فهرس بنوك البيانات تفيد عند التساؤل: أين يمكن أن يوجد بعض المعلومات المحددة؟ (مثال: ما هي بنوك البيانات التي تحتوى تتابع الحمض النووي لتربيتين بوركيوبين؟) وبالتالي اذا تم معرفة وتحديد ما هو المطلوب بدقة عندئذ تبدأ خطوات حل المشكلة.

وبنك البيانات بدون طرق فعالة للاتصال والتعامل تكون بمثابة مقبرة للبيانات. كيف تتحقق اتصال فعال مع قاعدة بيانات مصممة على أن تظل محجوبة عن المستفيدين. أصبح من الواضح أن الاتصال الفعال لا يمكن تزويده بنظام تسلّفات في أرشيف غير مشبع. بدلاً من ذلك يجب أن يضم التنظيم المنطقي لتخزين المعلومات مع وجود تصور لطرق الاتصال والتعامل - ماهي نوعية الأسئلة التي يريد المستخدم طرحها - كما ينبغي أن ينسجم تركيب الأرشيف بسلسة مع برامج استدعاء المعلومات.

تتضمن مختلف أنواع استعلام قاعدة البيانات الممكنة في مجال البيومعلوماتية الآتي:

١) تتابع مفترض، أو جزء من تتابع، وإيجاد تتابعات في قاعدة البيانات مماثلة له. هذه مشكلة مرکزية في البيومعلوماتية. يشارك المعلوماتية الحيوية مجالات عديدة من علم الحاسوب في سلسلة من المشاكل المتماثلة. على سبيل المثال، برامج معالجة الكلمات والتحرير التي تدعم سلسلة من وظائف البحث.

(٢) تركيب بروتين مفترض، أو جزء منه ، وإجاد تراكيب مماثلة في قاعدة البيانات. ذلك هو التعميم لسلسلة المشاكل المتشابهة للأبعاد الثلاثية.

(٣) تتابع مفترض لبروتين غير معروف تركيبه، إيجاد تراكيب في قاعدة البيانات والتي تتبنى تراكيب ثلاثة الأبعاد مشابهة. يحث ذلك على البحث في بنوك بيانات التتابع عن بروتينات لها تتابعات مماثلة لتتابع المجرس: من المتوقع في حالة وجود اثنان من البروتينات لهما تتابعات متماثلة درجة كافية فسوف يكون لهما تراكيب متشابهة. إلا أن هذا القول غير حقيقي. ونأمل في الوصول إلى تقنيات بحث أكثر قوة والتي تستطيع التعرف على بروتينات متشابهة التركيب حتى ولو كان تتابع كل منها ينحرف عن النقطة التي تقر التشابه بينهما على أساس مقارنة التتابع.

(٤) تركيب مفترض لبروتين لايجاد تتابعات في بنك البيانات والتي تقابل تراكيب مماثلة. مرة أخرى يمكن استخدام هذا التركيب كمجرس لتركيز في بنك البيانات لكن ذلك سوف يحقق فقط نجاحاً محدوداً لأن هناك العديد من التتابعات المعروفة أكثر من التراكيب. ولذا فإنه من المرغوب فيه وجود طريقة يمكنها التقاط التركيب من التتابع.

أرقام (١) و (٢) عبارة عن أمثلة محلولة لعمليات بحث تجرى آلاف المرات كل يوم. بينما (٣) و (٤) عبارة عن مجالات نشطة للبحث.

تتأتى أهداف غاية في الرقة عند الرغبة في دراسة العلاقات بين معلومات بنوك بيانات منفصلة. حيث يتطلب ذلك وجود روابط تسهل الاتصال المتزامن مع عدة بنوك بيانات. مثال على ذلك: هل يوجد في الخميرة بروتين مماثل لذلك البروتين معلوم التركيب والذي يساهم في حدوث أمراض تخليق البيورين في الإنسان؟ والخلفية هنا يحددها: تركيب معلوم ووظيفة معينة واكتشاف الصلة والارتباط بالمرض ونوع معين من

الكائنات. أدى الاهتمام بالنمو المتزايد بطرق الاتصال المتزامن ببنوك البيانات إلى بحث التفاعل داخل بيانات البنك بمعنى - كيف يتم تبادل البيانات بين بنك وآخر بدون تضحية كبيرة في حرية كل بنك في بناء بياناته بطرق تلائم الصفات الفردية المميزة للمادة التي تحتويها تلك البيانات.

وال المشكلة التي لم تظهر بعد في مجال البيولوجيا الجزيئية هي عملية تحدث السجلات. ففي نظام قاعدة البيانات للحجز بشركات الطيران يمنع حدوث بيع المكان الواحد لأكثر من مسافر مع وجود منافذ للحجز متعددة. في مجال المعلوماتية الحيوية يمكن المستخدم قراءة واستخلاص المعلومات من سجلات بنوك البيانات أو تقديم مواد يتم معالجتها بواسطة القائمين بالعمل في سجل ما ولكنه لا يستطيع إضافة أو تغيير المدخلات مباشرة. قد يتغير هذا الوضع. من منظور عمل تزايد كمية البيانات الناتجة بسرعة كبيرة لدرجة تعيق قدرة مشروعات السجلات على استيعابها. ويوجد بالفعل تحرك نحو مشاركة أكبر للعلماء في المعامل لتجهيز بيانات للسجلات.

بالرغم من جدل بخصوص تحكم متميز للسجلات إلا أن هناك حاجة إلى الحد من الطرق العامة (غير المتخصصة) للتعامل معها - تصميم front ends . ويمكن لمجتمعات المستخدم المتخصص أن تستخلص تحت مجموعات من البيانات أو دمج بيانات من مصادر مختلفة والوصول إلى طرق متخصصة للاتصال والتعامل. وتعتمد مثل - داكيين قواعد البيانات هذه - على السجلات الأولية كمصدر للمعلومات التي تحتويها ولكن مع إعادة تصميم التنظيم والعرض بالطريقة التي يرونها أكثر ملاءمة. وفي الحقيقة يمكن لمختلف قواعد البيانات الفرعية أن تصنف ذات المعلومة. يقترح الاستقراء المعقول مفهوم قواعد البيانات الواقعية المتخصصة virtual data bases المبني على السجلات وفي نفس الوقت يقدم مفهوما ووظيفة فردية فصلت لتلبى احتياجات مجموعات البحث الفردية أو حتى علماء منفردين.

تعتمد المجتمعات العلمية والطبية على جودة بنوك البيانات. ومؤشرات الجودة حتى وإن كانت لا تسمح بتصحيح الأخطاء إلا أنها قد تتجنب التوصل إلى استنتاجات خاطئة.

تضمن مدخلات بنك البيانات النتائج التجريبية الخام ومعلومات معاونة أو تفسيرات. ومتلك كل واحدة من تلك مصادرها الخاصة من الخطأ.

من أهم المحددات لجودة البيانات ذاتها هو مدى دقة التجارب. البيانات القديمة محدودة بتقنيات قديمة. على سبيل المثال: تتبعات الحمض الأميني للبروتينات التي تم تقديرها بواسطة تحديد التتابع البيني يتم الآن ترجمتها جميعاً من تتبعات الدنا. أحد عواقب انفجار البيانات هو أن غالبية البيانات جديدة وتم الحصول عليها بتكنولوجيا حديثة والتي في معظم الحالات تؤدي عملاً جيداً.

تشتمل التفسيرات معلومات حول مصادر البيانات والطرق المستخدمة في تقديرها. كما أنها تقدم روابط مع المعلومات ذات الصلة في بنوك المعلومات الأخرى. في بنوك بيانات التتابع تتضمن التفسيرات جداول توصيف: قوائم بأجزاء التتابعات التي لها معنوية بيولوجية - على سبيل المثال مناطق من تتابع الدنا الخاصة بشفرة البروتينات. يظهر ذلك في تصميم مناسب للتعامل مع الحاسب الآلي ويكون محتوياتها مقيدة بمفردات لغوية محكومة. حتى وقت قريب ادخل تتابع نمطي لدنا يتم بواسطة مجموعة بحثية منفردة تبحث الجين ونواتجه بطريقة مترابطة منطقياً. تستند التفسيرات على البيانات التجريبية والمكتوبة بواسطة متخصصون. على النقيض، لا تقدم مشروعات تتابع الجينوم تأكيد تجريبي للتعبير في معظم الجينات المفترضة ولا تشخيص نواتجها. يقيم الأمانة في بنوك البيانات تفسيراتهم على أساس تحليل التتابعات بواسطة برامج الحاسب الآلي.

التفسيرات هي أضعف مكون في مؤسسة الجينوم وميكانة التفسيرات تكون ممكناً فقط بدرجة محدودة. وللحصول عليها بطريقة صحيحة تكون كثيفة

الرعاية والتفسير والتحكم في الجودة:

Curation Annotation, and Quality Control:

العملة وتقسيم المصادر يكون غير كافيا. ولكن لا يمكن الاستخفاف بالتفسيرات الصحيحة. وقد علق بورك بأن تلك الأخطاء في دراسة الجنين تقضي جودة بيانات التابع. سوف يؤدي نمو بيانات الجنين إلى تحسين جودة التفسير كما أن الطرق الإحصائية تزيد من الدقة وتسمح باعادة محسنة لتقدير المدخلات. التحسن في التفسيرات شيء جيد ولكن التلازم الحتمي - التفسير سيكون متذبذبا - سيكون مزعجا. هل يجب الاطلاع دوريا على البحوث المكتملة والأخذ في الاعتبار خلاصة ما توصلت له من نتائج؟ وقد تفاقمت المشكلة بوجود العديد من مواقع الويب مع تزايد شبكات الربط الكثيفة. وينتج ذلك طرق مفيدة للتطبيقات المتنوعة. والويب أيضا ناقل لعدوى تضم الأخطاء في البيانات الخام والتفسيرات المختلفة ويتم تباعا تصويب الأخطاء في البيانات في صورتها الأولية ولكن الحاجة إلى التصويب لا نهاية لها.

والحل الوحيد الممكن هو تصويب موزع ديناميكي لمعالجة الخطأ والتفسير. سوف يقوم الأخصائيون الموزعون بدور الأمانة حيث أن العاملين بينك البيانات ليس لديهم لا الوقت ولا الخبرة ل القيام بذلك المهمة. كما تسمح ديناميكية التقدم في ميكنة تعريف وتصحيح الخطأ والتفسير باعادة التفسير لبنوك البيانات. ولسوف نضطر أن نسلم بالفكرة الآمنة لبنك بيانات مستقر يتكون من مدخلات سليمة من بداية توزيعها وتظل كذلك. وسوف تصبح بنوك البيانات مصدر غال وثمين للمعلومات والتي تنمو في الحجم وتزداد نضجا ونأمل أن تكون بجودة مناسبة.

تستخدم الشبكة العنكبوتية للحصول على مواد مرجعية وأخبار للتعامل مع قواعد البيانات في البيولوجيا الجزيئية أو لمجرد التصفح. وتعتبر الويب الآن وسيلة من وسائل الاتصال بين الأشخاص وبين الحاسوبات عبر الشبكات. وهي بمثابة قرية عالمية تشمل على ما يقابل المكتبة ومكتب البريد والأسواق والمدارس وغيرها.

الشبكة العنكبوتية العالمية واسعة الانتشار The World Wide : Web (www)

ويجرى المستخدم برنامج للتصفح على الحاسوب الخاص به. ومن برامج التصفح الشائعة:

ويمكن بواسطه تلك البرامج قراءة Netscape and Internet Explorer وعرض مواد من أي مكان في العالم. تقدم برامج التصفح معلومات للتحكم كما تتيح نقل المعلومات إلى حاسب محلي. ومن الأشياء الرئيسية لبدء استخدام الشبكة بفاعلية إيجاد نقاط دخول مفيدة حيث تأخذك روابط الوصل (links) إلى المكان الذي تريده بمجرد بدء التشغيل. ومن بين أكثر الواقع أهمية تلك الخاصة ببرامج البحث والتقطيب search engines والتي تفهرس الويب بأكمله وتتيح استرجاع المعلومات باستخدام كلمات رئيسية key words. ومن الممكن إدخال واحداً أو أكثر من المصطلحات مثل 'phosphorylase', 'H osteric change', 'rys tal structurre' برنامج البحث قائمة بروابط الوصل لموقع على الويب تحتوى على تلك المصطلحات وعندئذ يمكن التعرف على الموقع محل الاهتمام.

أثناء جلسة تصفح الويب يمكن الاحتفاظ بالمستندات التي تحتاج الرجوع إليها في جلسات تصفح قادمة وذلك بحفظ روابط الوصل الخاصة بها في ملف bookmarks أو favourites ومن ثم يمكنك في جلسات لاحقة الرجوع إلى أي موقع مباشر دون الحاجة إلى اتباع محاولات روابط الوصل المستخدمة في أول مرة.

الويب ليس طريقة ذو اتجاه واحد بمعنى أن العديد من مستندات الويب تتضمن نماذج يمكن إدخال معلومات فيها وإجراء برنامج للحصول على النتائج خلال نفس الجلسة. وتعتبر برامج البحث والتقطيب خير مثال على ذلك. وتنطلق الآن العديد من العمليات الحسابية في البيومعلوماتية عبر أجهزة الخدمة servers. وفي حالة العمليات الحسابية الطويلة ربما لا تتأتى النتائج أثناء نفس الجلسة ولكن ترسل بالبريد الإلكتروني e-mail.

The hURLy-bURLy (Uniform Resource Locators)

تحدد تلك الحروف شكل المادة ومكانها حيث ينبغي أن يكون لكل مستند على الويب ملف في مكان ما على حاسب معين. مثال لـ URL:

<http://www.lib.berkeley.edu/TeachingLib/Guides/Internet/FindInfo.html>

وهو موقع لدرس حول كيفية الحصول على معلومات من الإنترنط. ويشير مختصر http:// إلى أن المستند في صيغة بروتوكول نقل النص المحوري hypertext transfer protocol أما www.lib.berkely.edu فهو اسم الحاسب: المكتبة المركزية في جامعة كاليفورنيا بيركيلي. وباقية الأجزاء تشير إلى مكان واسم الملف في الحاسب.

النشر الإلكتروني :Electronic publication

هناك العديد والعديد من المواد المنشورة على صفحات الويب. وفي المجالات العلمية قد ينشر جدول المحتويات فقط أو جدول المحتويات مع ملخصات المقالات أو المقالات كاملة. والآن يظهر العديد من المطبوعات المؤسسية والنشرات الدورية والتقارير الفنية على الويب. كما يحتوى الكثير من المطبوعات على مراجع لروابط وصل تحتوى على مواد مساعدة لا يمكن ظهورها على ورق. كما أن المواد المطبوعة على ورق يمكن أن تتضمن عناوين لمواقع على الويب وللبريد الإلكتروني.

الحاسبات وعلم الحاسب :Computers and computer science

لم يكن من المحتمل ظهور مجال البيومعلوماتية بدون التقدم الذى تحقق فى المكونات المادية Hardware وبرامج software للحاسبات. كما أن وسائل الحفظ السريعة ذات الكفاءة العالية ضرورية للإبقاء على السجلات. وتتطلب عملية استرجاع وتحليل المعلومات برامج بعضها بسيطة وسلسة وبعض الآخر متقدمة ومتقدمة. كما يتطلب توزيع

المعلومات توافر إمكانيات من شبكات الحاسب computer networks وكذلك بالنسبة للشبكة العنكبوتية العالمية www.

علوم الحاسوب مجال صغير ومزدهر يستهدف تعظيم الاستخدام الفعال لمكونات تكنولوجيا المعلومات. مناطق معينة من علم الحاسوب تمس البيومعلوماتية مسا وثيقاً و مباشرةً. دعنا نتصور مشكلة بيولوجية مثل استرجاع كل التتابعات المماثلة لمجس التتابع probe sequence من قاعدة بيانات سيكون الحل الصواب هو اللجوء إلى علم الحاسوب في:

• **التحليل العددى (الخوارزميات)** Analysis of algorithms

وهو الوصف الكامل والدقيق لطريقة حل المشكلة. بالنسبة لاسترجاع تتابعات مماثلة نحتاج قياس مدى شابه تتابع المجس لكل تتابع موجود في قاعدة البيانات. ومن المحتمل أن يكون ذلك أفضل بكثير من تلك الاتجاه الساذج لفحص كل زوج من الأماكن في كل تجاور محتمل وهي طريقة حتى بدون السماح بفراغات فإنها تحتاج إلى وقت يتناسب مع ناتج ضرب عدد حروف مجس التتابع في عدد حروف تتابعات قاعدة البيانات. ويركز تخصص الحاسوب المعروف عامه 'stringology' على إيجاد طرقاً ذات كفاءة للتعامل مع هذا النوع من المشاكل وتحليل فاعليتها أدائها.

• **ترانكيب البيانات واسترجاع المعلومات** Data structures, and information retrieval

كيف يتم تنظيم البيانات بطريقة تتيح استجابة كفاءة للتساؤلات؟. على سبيل المثال: هل هناك طرق لفهرسة أو اعداد معالجة للبيانات لجعل بحث تمايل التتابع أكثر كفاءة؟ كيف يمكننا تقديم حدوداً مشتركة من شأنها مساعدة المستخدم على تصميم وتنفيذ التساؤلات؟.

• **هندسة البرامج** Software engineering

لم يعد من الصعب بناء كتابة برامج بلغة الحاسوب الأصلية. يعمل المتخصصون في عمل البرامج بلغات عالية المستوى مثل

C, C++, PERL ('Practical Extraction and Report Language')

أو حتى لغة FORTRAN. يعتمد اختيار لغة البرمجة على طبيعة الحساب وتركيب البيانات المصاحبة. وبالطبع فمعظم البرامج المعقدة المستخدمة في البيومعلوماتية تكتب بواسطة متخصصون.

البرمجة :Programming

البرمجة بالنسبة لعلم الحاسوب كالقائم بالبناء في فن العمارة كلاهما مبدع أحدهما فن والأخر حرفة.

يستفسر العديد من طلاب البيومعلوماتية هل من الضروري أن يتعمدوا كتابة برامج حاسب معقدة ؟ والاجابة أنه ليس من الضروري ذلك إلا إذا كانت هناك رغبة في التخصص في هذا المجال. ويطلب العمل في مجال البيومعلوماتية اكتساب خبرات في استخدام الأدوات المتاحة على صفحات الويب. كما أنه من الأشياء الأساسية هو تعلم كيفية إنشاء موقعًا على الويب وكذلك البقاء عليه وبالتالي حاجة إلى إمكانيات لاستخدام نظام تشغيل الحاسوب الشخصي. ومهارة كتابة نصوص بسيطة بلغة مثل PERL تعتبر من ضمن أساسيات نظام التشغيل.

وحيث يجب أن يؤخذ في الاعتبار حجم سجلات البيانات والنمو المتزايد في درجة التعقيد في التساؤلات المطروحة لذلك من الأفضل أن يترك الإبداع الحقيقي للبرمجة في هذا المجال للمتخصصين ذى الخبرة الجيدة في علم الحاسوب.

وينصح بتعلم المهارات الأساسية لغة PERL لأنها أداة قوية تجعل من السهل جدا القيام بالعديد من العمليات البسيطة والمفيدة. وتمتاز لغة PERL بأنها متاحة في غالبية أنظمة الحاسوب.

كيف يمكنك تعلم PERL بدرجة كافية لاستخدامها في البيومعلوماتية ؟ تقدم العديد من المعاهد دروسا لهذه اللغة كما يمكن تعلمها بمساعدة

الزملاء وكذلك بالرجوع الى الكتب المتوفرة. ومن الطرق المفيدة أيضاً البحث عن دروس على صفحات الويب بالاستعانة ببرامج البحث حيث يوجد مواقع لذلك. يمكن الرجوع الى موقع مشروع بيوبريرل Bioperl PERL (http://bio.perl.org/) : project ومكوناته المستخدمة في مجال البيومعلوماتية.

قوة PERL فيتناول سلسلة الحروف جعلها تلائم عمليات تحليل التتابع في علم البيولوجى. وفيما يلى مثال لاستخدام برنامج PERL بسيط لترجمة تتابع نيكليونيدية الى تتابع حمض نوى طبقاً لكود وراثي قياسي. السطر الأول: #!/usr/bin/perl هو اشارة الى نظام تشغيل UNIX (LINUX) وما يليه هو برنامج PERL. خلل البرنامج جميع النصوص التي تبدأ ب# ليست الا تعليق. ويشير السطر-END_ الى انتهاء البرنامج وأن ما يليه هو عبارة عن بيانات تم ادخالها. (يمكن الحصول على المواد والبرامج بالرجوع الى موقع الكتاب على الويب وهو:

<http://www.oup.com/uk/lesk/bioinf>

ويعرض هذا المثال البسيط صور عديدة للغة PERL. ويحتوى هذا الملف على بيانات مصاحبة (جدول ترجمة الكود الوراثى)، وعبارات تخبر الحاسب لعمل شىء معين بالمدخلات (مثل التتابع المطلوب ترجمته)، والبيانات التي يتم ادخالها (وهي تظهر بعد سطر-END_). كما تلخص التعليقات أقسام من البرنامج وتوصف تأثير كل عبارة.

يتركب البرنامج كbloکات داخل أقواس متعرجة : { ... } مما يفيد فى انسياپ الأداء. وداخل bloکات عبارات فردية (كل منها تنتهى ب;) . والبلوك الخارجى عبارة عن لوپ:

while (\$line = <DATA> {

...

}

تشير <DATA> إلى سطور ادخال البيانات (والتي تظهر بعد _END_). ويتم اجراء البlok مرة واحدة لكل سطر من المدخلات ويستمر ذلك حتى نهاية كل السطور.

ويظهر في البرنامج ثلاثة أنواع من تركيب البيانات. سطر ادخال البيانات ويشار إليه \$line وهو سلسلة من الحروف البسيطة والتي تجزأ إلى منظومة متعددة البيانات array أو حامل لثلاثيات triplets. وتخزن المنظومة بيانات لموضوعات عديدة في ترتيب خطى. ويمكن استرجاع بيانات كل موضوع على حدي من أماكنها في المنظومة. لتسهيل التقاط الكود الثلاثي لحامض أميني فإنه يتم تخزين الكود الوراثي كمنظومة ترتيب. ومنظومة الترتيب أو جدول التكرار عبارة عن تعميم لمنظومة بسيطة أو تسلسلية. إذا كانت عناصر المنظومة البسيطة مفهرسة بواسطة أرقام متتابعة فإن عناصر منظومة الترتيب تفهرس باستخدام سلاسل من حروف وهي في هذه الحالة تكون ٦٤ ثلاثية. يتم معالجة الثلاثيات المدخلة طبقاً للترتيب ظهورهم في تتبع النيكليوتيدية مع الاستعانة بعناصر جدول الكود الوراثي بترتيب تحكمي كما يقرأ في الثلاثيات المتتالية. المنظومة البسيطة أو حامل سلاسل الحروف يكون مناسباً لمعالجة ثلاثيات متتالية بينما تلائم المنظومة التسلسلية التقاط الأحماض الأمينية المقابلة للثلاثيات.

مثال : برنامج بيرل لترجمة تتبع حامض نووي إلى تتبع حامض أميني

```
Translate.pl - PERL program to translate nucleic acid
sequence to amino acid sequence:

#!/usr/bin/perl
#translate.pl -- translate nucleic acid sequence to protein
               sequence
#           according to standard genetic code

# set up table of standard genetic code

%standardgeneticcode = (
    "ttt"=> "Phe",   "tct"=> "Ser",   "tat"=> "Tyr",      "tgt"=> "Cys",
    "ttc"=> "Phe",   "tcc"=> "Ser",   "tac"=> "Tyr",      "tgc"=> "Cys",
    "tta"=> "Leu",   "tca"=> "Ser",   "taa"=> "TER",      "tga"=> "TER",
    "ttg"=> "Leu",   "tcg"=> "Ser",   "tag"=> "TER",      "tgg"=> "Trp",
    "ctt"=> "Leu",   "cct"=> "Pro",   "cat"=> "His",     "cgt"=> "Arg",
    "ctc"=> "Leu",   "ccc"=> "Pro",   "cac"=> "His",     "cgc"=> "Arg",
```

كراسات "عروض"

```
"cta"=> "Leu",    "cca"=> "Pro",  "caa"=> "Gln",    "cga"=> "Arg",
"ctg"=> "Leu",    "ccg"=> "Pro",  "cag"=> "Gln",    "cgg"=> "Arg",
'att"=> "Ile",    "act"=> "Thr",   "aat"=> "Asn",    "agt"=> "Ser",
'atc"=> "Ile",    "acc"=> "Thr",   "aac"=> "Asn",    "agc"=> "Ser",
'ata"=> "Ile",    "aca"=> "Thr",   "aaa"=> "Lys",    "aga"=> "Arg",
'atg"=> "Met",    "acg"=> "Thr",   "aag"=> "Lys",    "agg"=> "Arg",
"gtt"=> "Val",    "gct"=> "Ala",   "gat"=> "Asp",    "ggt"=> "Gly",
"gtc"=> "Val",    "gcc"=> "Ala",   "gac"=> "Asp",    "ggc"=> "Gly",
"gtt"=> "Val",    "gca"=> "Ala",   "gaa"=> "Glu",    "gga"=> "Gly",
"gtg"=> "Val",    "gcg"=> "Ala",   "gag"=> "Glu",    "ggg"=> "Gly"
}

# process input data

while ($line = <DATA>) {                                # read in
line of input
    print "$line";                                     #
transcribe to output
    chop();                                         # remove
end-of-line character
    @triplets = unpack("a3" x (length($line)/3), $line); # pull out
successive triplets
    foreach $codon (@triplets) {                      # loop
over triplets
        print "$standardgeneticcode($codon)";          # print
out translation of each
    }
on triplets
    print "\n\n";                                       # skip
line on output
}
on input lines

# what follows is input data
```

```
--END--
atgcatcccttaat
tctgtctga
```

Assemble.pl - PERL program to assemble overlapping fragments of strings:

```
#!/usr/bin/perl
#assemble.pl -- assemble overlapping fragments of strings

# input of fragments
while ($line = <DATA>) {                                # read in fragments, 1
per line
    chop($line);                                         # remove trailing
carriage return
    push(@fragments,$line);                             # copy each fragment
into array
}
# now array @fragments contains fragments

# we need two relationships between fragments:
# (1) which fragment shares no prefix with suffix of another
fragment
#      * This tells us which fragment comes first
```

```

# (2) which fragment shares longest suffix with a prefix of
another
#      * This tells us which fragment follows any fragment

# First set array of prefixes to the default value
"noprefixfound".
#      Later, change this default value when a prefix is found.
#      The one fragment that retains the default value must be come
first.

# Then loop over pairs of fragments to determine maximal overlap.
#      This determines successor of each fragment
#      Note in passing that if a fragment has a successor then the
#      successor must have a prefix

foreach $i (@fragments) {           # initially set prefix
of each fragment
    $prefix{$i} = "noprefixfound";   #      to
"noprefixfound"
}                                     #      this will be
overwritten when a prefix is found

# for each pair, find longest overlap of suffix of one with prefix
of the other
#      This tells us which fragment FOLLOWS any fragment

foreach $i (@fragments) {           #      loop over fragments
    $longestsuffix = "";            #      initialize longest
suffix to null

    foreach $j (@fragments) {       #      loop over fragment
pairs
        unless ($i eq $j) {         #      don't check fragment
against itself

            $combine = $i . "XXX" . $j; #      concatenate fragments,
with fence XXX
            $combine =~ /([\S]{2,})XXX\1/; #      check for
repeated sequence
            if (length($1) > length($longestsuffix)) { #      keep
longest overlap
                $longestsuffix = $1;      #      retain longest suffix
                $successor{$i} = $j;      #      record that $j follows
$i
            }
        }
    }
    $prefix{$successor{$i}} = "found"; #      if $j follows $i then
$j must have a prefix
}

foreach (@fragments) {               #      find fragment that has
no prefix; that's the start
    if ($prefix{$_} eq "noprefixfound") {$outstring = $_;}
}

```

كراسات "عروض"

```
$test = $outstring;                      # start with fragment
without prefix
while ($successor($test)) {                # append fragments in
order
    $test = $successor($test);             # choose next fragment
    $outstring = $outstring."XXX". $test; # append to string
    $outstring =~ s/((\S )+)XXX\1/\1/;   # remove overlapping
segment
}

$cutstring =~ s/\n/n/g;                   # change signal \n to
real carriage return
print "$outstring\n";                    # print final result
```

the men and women merely players;\none man in his time
All the world's
their entrances,\nand one man
stage,\nAnd all the men and women
They have their exits and their entrances,\nworld's a stage,\nAnd all
their entrances,\nand one man
in his time plays many parts.
merely players;\nThey have

وهنالك اصدار بديل من البرنامج لمضاهاة الأجزاء المتداخلة
assemble : overlapping fragments

```
# /usr/bin/perl

$. = "";
@fragments = split("\n",<DATA>);

foreach (@fragments) { $firstfragment{$_.} = $_; }

foreach $i (@fragments) {
    foreach $j (@fragments) { unless ($i eq $j) {
        ($combine = $i . "XXX" . $j) =~ /((\S ){2,})XXX\1/;
        (length($1) <= length($successor($i))) || { $successor{$i}
= $j };
    }
    undef $firstfragment{$successor{$i}};
}

$test = $outstring = join "", values(%firstfragment);
while ($test = $successor($test)) { ($outstring .= "XXX" . $test)
=~ s/((\S )+)XXX\1/\1/;

$outstring =~ s/\n/n/g; print "$outstring\n";

_____
the men and women merely players;\n
one man in his time
```

All the world's
their entrances, \nand one man
stage, \nAnd all the men and women
They have their exits and their entrances, \n
world's a stage, \nAnd all
their entrances, \nand one man
in his time plays many parts.
merely players; \nThey have

تعتمد التسمية البيولوجية على تقسيم الكائنات الحية إلى مملكة وقبيلة وأقسام وأجناس وأنواع وذلك على أساس أوجه التشابه المشاهدة. وتقديم نتائج تحليل التتابع دلائل قاطعة على العلاقات بين الأنواع.

استخدام التتابع لتحديد علاقات القرابة: Use of sequence to determine phylogenetic

توضح الأمثلة التالية تطبيقات استرجاع التتابعات من بنوك المعلومات ومقارنات التتابع في تحليل العلاقات البيولوجية:

المثال الأول: استرجاع تتابع الحمض الأميني لأنزيم الريبونيوكليز في بنكرياس الحصان باستخدام ExPASY server في المعهد السويسري للبيومعلوماتية وعنوانه:

<http://www.expasy.ch/cgi-bin/sport-search-fu!>.

١- اكتب في المكان المخصص ل key words
ribonuclease

٢- ثم اضغط على مفتاح ENTER

٣- اختار RNP_HORSE ثم FASTA format ثم تحصل على التالي:

```
>sp|P00674|RNP_HORSE RIBONUCLEASE PANCREATIC (EC 3.1.27.5) (RNASE  
1) ...  
KESPAMKFERQHMDSGTSSSNPTYCNQMMKRRNMTQGWCKPVNTFVHEP  
LADVQAICLQKNITCKNGQSNCYQSSSSMHTDCRLTSGSKYPNCAYQTS  
QKERHIIIVACEGNPYVPVHFDASVEVST
```

وهنا يمكنك أن تقوم بعملية قص ولصق إلى برامج أخرى حيث يمكن استرجاع عدة تتابعات وعمل sequence alignment وهذا يفيد في تقدير درجة القرابة والعلاقات.

التصنيف والتسمية البيولوجية

Biological Classification and nomenclature:

المثال الثاني: حدد باستخدام تتابعات إنزيم الريبيونيوكلسيز البكترياسي للحصان والحوت والكنجر النوعين الأكثر قرابة:

Pancreatic ribonuclease sequences from horse (*Equus caballus*), minke whale (*Balaenoptera acutorostrata*) and red kangaroo (*Macropus rufus*):

```
>RNP_HORSE
KESPAMKFERQHMDSGTSSSNPTYCNQMMKRRNMTQGWCKPVNTFVHEP
LADVQAICLQKNITCKNGQSNCYQSSSSMHITDCRLTSGSKYPNCAYQTS
QKERHIIIVACEGNPYVPVHFDADEVST
>RNP_BALAC
RESPAMKFQRQHMDSGNSPGNNPNYCNCQMMMRKMTQGRCKPVNTFVHES
LEDVKAVCSQKNVLCKNGRTNCYESNSTMHITDCRQTGSSKYPNCAKTS
QKEKHIIVACEGNPYVPVHFDSV
>RNP_MACRU
ETPAEKFQRQHMDTEHSTASSSNYCNCNLMKKARDMTSGRCKPLNTFIHEPK
SVVDAVCHQENVTKNGRTNCYKSNSRLSITNCRQTGASKYPNCQYETSN
LNKQIIVACEGQYVPVHFDAYV
```

يستخدم برنامج CLUSTAL W: و عنوانه:

<http://www.ebi.ac.uk/clustalw/>

:T-coffee: وهذا بديل آخر وهو

<http://www.ch.embnet.org/software/TCoffee.html>

وسوف تصل إلى تطابق م الواقع في تتابعات كلا من الحصان والحوت.

من أشهر الأمثلة هو البحث عن قاعدة بيانات لموضوعات تتشابه مع جنس. ففي حالة تحديد تتابع جين جديد أو التعرف من خلال الجينوم البشري على جين مسؤول عن مرض معين يكون هناك رغبة لمعرفة وجود جينات مماثلة في أنواع أخرى. والطريقة المثلث لتحقيق ذلك يجب أن تكون حساسة بحيث تتعرف على كل العلاقات و اختيارية بأن تكون تلك العلاقات حقيقة.

وتشتمل طرق البحث في قواعد البيانات التناوب بين الحساسية والاختيارية. هل تستطيع الطريقة إيجاد كل أو معظم التطابقات الموجودة بالفعل أم أنها تفقد أجزاء كبيرة؟. وعلى النقيض كم من التطابقات الواردة

البحث عن التتابعات المتماثلة باستخدام قواعد بيانات PSI-BLAST

تكون غير صحيحة؟. بافتراض أن قاعدة بيانات تحتوى على ١٠٠ تتابع جلوبين وأن عملية البحث فى تلك القاعدة للجلوبين أعطت ٩٠٠ تتابع، وكان منها ٧٠٠ جلوبين حقيقى و ٢٠٠ خطأ. اذا يمكن القول أن هذه النتائج تحتوى على ٣٠٠ مفقودة (نتيجة خادعة سلبية) و ٢٠٠ نتيجة خادعة ايجابية. وسيترتب عن تخفيض الحد الحرج للأمان زيادة لكتلا النوعين. وهذا يكون الحرص على العمل بحدود حرجة منخفضة للتأكد من عدم فقد أى شيء ويطلب ذلك فحص دقيق للنتائج للتخلص من النتائج الخادعة الايجابية.

من الأدوات الفاعلة للبحث في قواعد بيانات التتابع بالاستعانة بمجلس التتابع استخدام PSI-BLAST

(Position Sensitive Iterated - Basic Linear Alignment Sequence Tool)

وهو برنامج من المركز القومى الأمريكى لمعلومات التكنولوجيا الحيوية (NCBI). ويعمل برنامج BLAST على التعرف على مناطق التشابه بدون فراغات ثم ضمها معا. ويشير PSI إلى تحسين وتهذيب نمط التعرف داخل التتابع في المراحل الأولية للبحث في قاعدة البيانات. يؤدي اقرار انماط متحفظة إلى تعظيم كل من حساسية و اختيارية البحث. ويتضمن PSI-BLAST عمليات متكررة حيث يتحسن تعريف الأنماط الناشئة من خلال المراحل المتتالية للبحث.

مثال: تماثل الجين البشرى PAX-6 وهى جينات تحكم فى تطور العين فى أنواع عديدة من الكائنات. وقد وجد تماثل هذا الجين فى الإنسان وذبابة الدrosophila.

ويمكن اجراء البحث عن التماثل كما يلى:

١- الحصول على تتابع الحمض الأمينى للبروتين بالرجوع إلى SWISS-PROT entry P26367

٢- اجراء PSI-BLAST من خلال الموقع:

<http://www.ncbi.nlm.nih.gov/blast/psiblast.cgi>.

٣- ادخل التابع واستخدم الخيارات لتحديد قاعدة بيانات للبحث وجدول التشابه المستخدم.

سوف يظهر البرنامج قائمة مشابهة لتابع المنس ومرتبة تنازلياً طبقاً لدرجة المعنوية الاحصائية. وفيما يلى نموذج طبق الأصل لأحد الأسطر في القائمة:

Pir 11 I 45557 eyeless, long form - fruit fly (Drosophila melano
255 7e-67

حيث Pir عبارة عن مصدر تعريف البروتين وهو entry 145557 وهو التماثل لعين الدروسفيلا. والرقم ٢٥٥ مقياس لدرجة التطابق. و 7e-67 تدل على مدى معنوية التطابق.

كما يمكن استخلاص أسماء الأنواع من نتائج PSI-BLAST وذلك باستخدام برنامج PERL كما يلى:

PERL program for extraction of species names from PSI-BLAST output:

```
#!/usr/bin/perl
#extract species from psiblast output

# Method:
#   For each line of input, check for a pattern of form [Drosophila
# melanogaster]
#   Use each pattern found as the index in an associative array
#   The value corresponding to this index is irrelevant
#   By using an associative array, subsequent instances of the same
#       species will overwrite the first instance, keeping only a
unique set
#   After processing of input complete, sort results and print.

while (<>) {
    if    (/^([A-Z][a-z]+ [a-z]+)\|/) {      # read line of input
        # select lines containing
        # strings of form
        #               [Drosophila
melanogaster]
        $species{$1} = 1;                      # make or overwrite entry
in
    }                                         # associative
array
}

foreach (sort(keys(%species))) {           # in alphabetical order,
    print "$_\n";                         # print species names
}
```

وقد وجد أن هناك تماثل مع ٥٢ نوعاً.

التتبؤ بتركيب البروتينات وهندستها : Protein structure and engineering

يحدد تتابع الحمض الأميني لبروتين ما التركيب ثلاثي الأبعاد له. باحتواء تتابعات الحمض الأميني على معلومات كافية لتحديد التراكيب ثلاثية الأبعاد للبروتينات يصبح من الممكن استبطاط نظام حسابي للتتبؤ بتركيب بروتين من تتابع الحمض الأميني. بالإضافة إلى التتبؤ بالتركيب فقد حدد العلماء عدداً من الأهداف أقل طموحاً يمكن تحقيقها:

١ - التتبؤ بالتركيب الثانوي : Secondary structure prediction

تحديد ما هي أجزاء التتابع التي تكون الشكل اللولبي والأخرى التي تكون الشرائط.

٢ - تمييز الطى : Fold recognition

يعمل مكتبة لتركيب بروتينات معروفة ولتابعات الحمض الأميني لها هل يصبح في استطاعتنا الحصول من تلك المكتبة على تركيب يشابه لدرجة كبيرة نظام طى لبروتين المطلوب معرفة تركيبه؟.

٣ - نماذج التمايز : Homology modeling

نفترض أن هناك بروتين معروف تتابع الحمض الأميني له وغير معروف التركيب ولكنه متماثل مع واحد أو أكثر من البروتينات المعروفة تركيبها. هنا يمكننا أن نتوقع أن البروتين الأكثر تماثلاً يمكن استخدامه كأساس لنموذج لبروتين المجهول التركيب. ويعتمد كمال ودقة النتائج على مدى تشابه التتابع. وعموماً وجد أنه في حالة ما إذا كان في اثنين من البروتينات قريبة الصلة تطابق ٥٠% في التتابع عند عمل المحازاة يكون هناك تماثل ٩٠% في تركيبهما.

فيما يلى التتابعات المصنفة والتركيب المتطابقة لاثنين من البروتينات قريبة الصلة وهم ليسوا زيم الأبيض في بيض الدجاج وألفا لاكتواليومين

في البابون. والتتابعات فيما شديدة التقارب (٣٧% تطابق كامل في التتابعات المترادفة) كما أن هناك تماثل في التركيب. وكل بروتين يمكن استخدامه كنموذج جيد للبروتين الآخر:

Chicken lysozyme :

KVFGRCLEAAAMKRHGLDNYRGYSLGNWVCAAKFESNFNTQATNRNT
DGS

Baboon ? - lactalbumin :

KQFTKCELSQNLY- -DIDGYGRIALPELICTMFHTSGYDTQAIVEND - ES

Chicken lysozyme :

TDYGILQINSRWWCNDGRTPGSRNLCNIPCSALLSSDITASVNCAKKIVS

Baboon ? - lactalbumin :

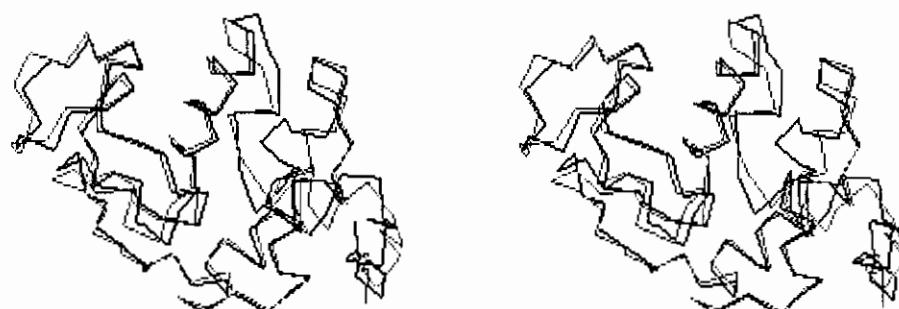
TEYGLFQISNALWCKSSQSPQRNICDITCDKFLDDITDDIMCAKKILD

Chicken lysozyme :

DGN- GMNAWVAWRNRCKGTDVQA- WIRGCRL-

Baboon ? - lactalbumin :

I - - KGIDYWIAHKALC - TEKL - EQWL - - CE - K



التفوييم الحرج للتبؤ بالتركيب :Structure Prediction (CASP)

يتطلب الحكم على تقانات التبؤ بستراكيب البروتينات الى استخدام اختبارات مصمته blind tests. لهذا الغرض صمم جائى مولت برامج CASP. العلماء المنشغلون بتقدير تركيب البروتين باستخدام طرق الفيسلس الباللورى والرنين النووي المغناطيسى مدعاوون الى: (١) نشر تتابع الحمض الأمينى عدة شهور قبل التاريخ المتوقع الى اكمال التجارب، (٢) الاحتفاظ بسرية النتائج حتى تاريخ منتق عليه. يقدم القائمون بالتبؤ بنماذج تبؤ يحفظ بها حتى التاريخ المنفق عليه لاعلان النتائج التجريبية. وهنا يتم مقارنة نتائج التبؤ والتجربة. ولقد سجلت نتائج التقييم باستخدام برامج CASP تقدما فى فاعلية التبؤ والذى يرجع الى نمو بنوك المعلومات وأيضا بسبب التحسن فى الطرق المستخدمة. والباب الخامس من الكتاب يناقش التبؤ بتركيب البروتين.

هندسة البروتينات :Protein engineering

كان هناك تشابه بين طبيعة عمل كلا من علماء البيولوجيا الجزيئية وعلماء الفلك من حيث القدرة على ملاحظة الأشياء دون اجراء تعديلات عليها. الا أن هذا لم يعد حقيقة الان. ففى المعمل يمكننا عمل تعديل فى الأحماض النووية والبروتين واحداث طفرات لمعرفة التأثير على وظائفهم. فمن الممكن أن يصبح لبروتين قديم وظيفة جديدة مثل انتاج أجسام مضادة لفازة ومحاولة تحضير بروتينات جديدة.

تشق العديد من قواعد تركيب البروتينات من ملاحظات للبروتين الطبيعي. وليس ضروريا تطبيق تلك القواعد فى البروتينات الم الهندسة. تمثل البروتينات الطبيعية صفات مرتبطة بالأسس العامة للكيمياء الطبيعية وآليات نشوء البروتين. ويجب أن تخضع البروتينات الم الهندسة

لقوانين الكيمياء الطبيعية وليس لقيود النشوء. وتسطيع هندسة البروتينات أن تستكشف آفاق و مجالات جديدة.

التطبيقات الـاكلينيكية:

هناك اجماع في الرأى على أن معرفة التتابعات في الجينوم البشري وجينوم العديد من الكائنات الأخرى سوف يؤدي إلى تحسن كبير في صحة البشر. وتطبيقات ذلك يمكن أن تتضمن الآتى:

١- تشخيص الأمراض ومخاطرها:

يمكن أن يكشف تتابع الدنا عن غياب جين معين، أو طفرة. يؤدي تعريف تتابعات جين محدد مصاحباً لمرض ما إلى سرعة ودقة تشخيص الحالة.

غالباً ما تكون العلاقة بين طبيعة الجين ومخاطر المرض من الصعوبة تحديدها. تعتمد بعض الأمراض مثل الحساسية على تداخلات بين جينات عديدة بالإضافة إلى عوامل بيئية. وفي حالات أخرى يكون الجين موجوداً وسليناً إلا أن حدوث طفرة في مكان ما قد يغير من تعبير ذلك الجين وتوزيعه بين الأنسجة. مثل تلك الأشياء غير السوية يجب اكتشافها بواسطة قياسات نشاط البروتين. كما أن قياس طرز تعبير البروتين تعتبر وسيلة هامة لقياس مدى الاستجابة للعلاج.

٢- وراثة الاستجابة إلى العلاج المتخصص:

نظراً لاختلاف الناس في قدرتها على تمثيل الأدوية فإن المرضى المختلفة قد تحتاج إلى جرعات مختلفة لعلاج نفس الحالة. يسمح تحليق التتابع اختيار الدواء والجرعة التي تتناسب مع كل مريض وذلك في إطار مجال ينمو بسرعة يعرف باسم Pharmacogenomics. ويصبح في استطاعة الأطباء تقادى تجرب طرق علاجية مختلفة والتي لها آثار جانبية خطيرة بالإضافة إلى التكلفة الباهظة.

٣-تعريف الأماكن المستهدفة للدواء:

المكان المستهدف قد يكون بروتين يتم تعديل وظيفته بالتدخل مع الدواء للتأثير على أعراض المرض ومسبياته. ويلقى التعرف على المكان المستهدف الضوء على الخطوات المتتالية لتصميم الدواء. والأماكن المستهدفة لمعظم الأدوية المستخدمة الآن نصفها مستقبلات وحوالى الربع انزيمات والربع المتبقى هرمونات وحوالى ٧% تعمل على أهداف غير معلومة.

أدى التزايد في ظاهرة مقاومة البكتيريا للمضادات الحيوية إلى خلق مأساة بخصوص علاج الأمراض. والحاجة الماسة لابتكار أدوية جديدة مرهونة بقاعدة البيانات اللازمة لانتاجها. ونتائج دراسة الجينوم قد تؤدي إلى اقتراح أماكن مستهدفة. الاختلافات في الجينوم ومقارنة طرز تعبير البروتين بين سلالات مسببات الأمراض الحساسة والمقاومة للأدوية يمكن أن تحدد البروتين المسؤول عن مقاومة الدواء. ويأمل استطاعة دراسة الاختلافات الوراثية بين الخلايا السرطانية والعاديّة في التعرف على تعبير بروتينات مختلفة تستخدم كأهداف لأدوية مضادة للسرطان.

٤- العلاج بالجينات:

وهو امكانية استبدال جين - أو على الأقل مد الجسم بناتجه - محل جين غائب أو مصاب بخلل. كما يتضمن العلاج بالجينات العمل على خفض النشاط الزائد لجين ما. وهناك بعض الحالات المرضية في الإنسان والتي أظهرت نتائج مشجعة بالعلاج الجيني.

ومن التوجهات التي تستخدم لايقاف تعبير الجين هو ما يطلق عليه "antisense therapy". وهو عبارة عن انتاج شريط قصير من الدنا أو الرنا والذي يرتبط بأسلوب تتبع متخصص بمنطقة بالجين. وهذا الارتباط يتدخل على التوالى مع عمليات النسخ والانتقال. لقد أظهر

هذا النوع من العلاج كفاءة ضد بعض المراض مثل cytomegalovirus; and Crohn disease تتبع المستهدف الى اختصار مراحل عديدة من عمليات تصميم الدواء.

المستقبل :The future

سوف يشهد القرن الحالي تطويراً مذهلاً في انتاج وتوزيع وسائل العلاج والرعاية بصحة البشر وتتلاشى الحواجز بين قلاع البحث والممارسة الاكلينيكية. ويصبح بامكان قارئ هذا الكتاب أن يتوصّل إلى علاج لمرض قاتل. كما يمكن اكتشاف عقاقير ووسائل من شأنها منع حدوث الأورام السرطانية وليس فقط العمل على التحكم في نموها وانتشارها.

مصادر على الانترنت يمكن الرجوع اليها :Web Resources

Human Genome Project Information :

<http://www.ncbi.nlm.nih.gov/hgmis/project/info.html>

Genome Statistics:

<http://bioinformatics.weizmann.ac.il/mb/statistics.html>

Taxonomy Sites :

Species : <http://www.sp2000.org>

Tree of life : <http://phylogeny.arizona.edu/tree>

Database of genetics of disease :

<http://www.ncbi.nlm.nih.gov/omim/>

<http://www.geneclinics.org/profiles/all.html>

Lists of databases :

<http://www.infobiogen.fr/services/dbcat/>

<http://www.ebi.ac.uk/biocat/>

List of tools for analysis :

<http://www.ebi.ac.uk/Tools/index.html>

Debate on electronic access to the scientific literature :

<http://www.nature.com/debates/e-access/>

تمرينات محلولة :Solved Problems

Problem 1. For what of following sets of fragment strings does the PERL program mentioned before work correctly ?

(a) Would it correctly recover :

Kate, when France is mine and I am yours, then yours is France and you are mine .

From :

Kate, when France
France is mine
is mine and
and I am\nyours
yours then
Then yours is France
France and you are mine\n

Sample input strings for assembly:

(a) Input data:

Kate, when France
France is mine
is mine and
and I am\nyours
yours then
Then yours is France
France and you are mine\n

(a) Correct answer:

Kate, when France is mine and I am
yours, then yours is France and you are mine.

(b) Would it correctly recover :

One women is fair , yet I am well; another is wise, yet I am well; another virtuous, yet I am well; but till all graces be in one woman, one woman shall not come in my grace .

from :

One woman is
woman is fair,
is fair, yet I am
yet I am well;
I am well; another
another is wise, yet I am well;
yet I am well; another virtuous,
another virtuous, yet I am well;
well; but till all
all graces be

be in one woman,
one woman, one
one woman shall
Shall not come in my grace.

(b) Input data:

One woman is
wo nan is fair,
is f air, yet I am
yet I am well;
I am well; another
anc ther is wise, yet I am well;
yet I am well; another virtuous,
another virtuous, yet I am well;
we l; but till all
all graces be
be in one woman,
one woman, one
one woman shall
Shall not come in my grace.

(b) Correct answer:

One woman is fair, yet I am well;
another is wise, yet I am well;
another virtuous, yet I am well;
but till all graces be in one woman,
one woman shall not come in my grace.

(c) Would it correctly recover :

That he is made, "tis true: "tis true "tis pity; And pity "tis "tis true.

from :

That he is
is mad, 'tis
'tis true
true: 'tis true 'tis
true 'tis
'tis pity;\npity 'tis
'tis 'tis
'tis true.\n

(c) Input data:

That he is
is mad, 'tis
'tis true
true: 'tis true 'tis
true 'tis

'tis pity;\n
pity;\nAnd pity
pity 'tis
'tis 'tis
'tis true.\n

(c) Correct answer:

That he is mad, 'tis true: 'tis true 'tis pity;
And pity 'tis 'tis true.

الفصل الثاني

نشوء وتنظيم الجينوم

Genome organization and evolution

الجينوم البكتيري يتتأتى من جزئى دنا منفرد والذى يصل طوله عند فردہ الى نحو ٢ ملليمتر (يبلغ قطر الخلية حوالي ١٠٠٠ ملليمتر). وينظم الدنا فى الكائنات الراقية على كروموسومات حيث تحتوى الخلية العادية فى الانسان على ٢٣ زوجا من الكروموسومات. والكمية الكلية للمعلومات الوراثية لكل خلية - تتبع النيكلويونيدات فى الدنا - تكون ثابتة لدرجة كبيرة لكل أفراد النوع الواحد بينما تختلف بصورة واسعة بين الأنواع المختلفة. وبم أن ليس كل الدنا يشفر الى بروتينات فان كم معلومات تتبع البروتين فى الخلية لا يمكن تقديره بسهولة من حجم الجينوم.

الجينوم والبروتوميك Genomics and Proteomics:

البروتوم: Proteomes

يقدم جينوم الكائن مجموعة كاملة لصفات الفرد. وتعتمد حالة تطور الكائن ونشاطه على المستوى الجزيئي في أي لحظة على كميات وتوزيع البروتينات. ويعتبر برنامج مشروع البروتوم من البرامج الضخمة التي تعنى - باسلوب تكاملى - بطرز تعبير البروتينات في الأنظمة البيولوجية بشكل ينطابق مع مشروعات الجينوم ويعظمها.

تمييز الجينات في الجينوم:

تعرف برامج الكمبيوتر لتحليل الجينوم على إطار القراءة مفتوحة open reading frames (ORFs) . ويعرف ORF بأنه منطقة من تتبع الدنا تبدأ

بكود بادئ (ATG) وينتهي بكود ايقاف. وهى منطقة فاعلة لشفير البروتين.

و عمليات التعريف على شفير البروتين تتم بواسطة واحد أو الجمع بين اثنان من التوجهات المحتملة التالية:

١ - الكشف عن مناطق مشابهة لمناطق شفير من كائنات أخرى. وتقوم تلك المناطق بشفير تتابعات حمض أميني مماثل لبروتين معروف أو مماثل علامات تتابعات ناتج الجين Expressed Sequence Tags (ESTs) وبم أن ESTs تشقق من الرنا الرسول فانها تتاظر جينات معروفة. ومن الضروري أن يتم تحديد التتابع لعدة مئات فقط من قواعد cDNA لتعطى معلومات كافية للتعرف على الجين. ويشابه تحديد الجينات بواسطة ESTs عملية فهرسة القصائد الشعرية والأغانى بالاستعانة بأول بيت فيها.

٢ - طرق *Ab initio* والتي تسعى الى التعرف على الجينات من خلال خصائص تتابعات الدنا.

مصادر على الانترنت :Web Resources

HUMAN GENOME INFORMATION

Interactive access to DNA and protein sequences :

<http://www.ensemble.org/>

Images of chromosomes, maps, loci :

<http://www.ncbi.nlm.nih.gov/genome/guide/>

Gene map 99 :

<http://www.ncbi.nlm.nih.gov/genemap99/>

Overview of human genome structure :

<http://hgrep.ims.u-tokyo.ac.jp>

Single-nucleotide polymorphisms :

<http://snp.cshl.org/>

Human genetic disease :

<http://www.ncbi.nlm.nih.gov/Omim/>
<http://www.geneclincs.org/profiles/all.htm>

Ethical, legal, social issues :

<http://www.nhgri.nih.gov/ELSI/>

DATABASES OF ALIGNED GENE FAMILIES

Pfam: protein families database :

<http://www.sanger.ac.uk/software/pfam/>

COG: Clusters of orthologous groups :

<http://www.ncbi.nlm.nih.gov/COG/>

HBAGENE : Homologous Bacterial Genes Database :

<http://pbil.univ-lyon1.fr/databases/hobacgen.html>

HOVERGEN: Homologous Vertebrate Genes Database :

<http://pbil.univ-lyon1.fr/databases/hoyergen.html>

TAED: The Adaptive Evolution Database :

<http://www.sbc.su.se/~liberles/TAED.html>

GENOME DATABASES

List of completed genomes :

<http://www.ncbi.nlm.nih.gov/PMGifs/Genomes/allorg.html>
<http://www.ebi.ac.uk/genomes/mot/index.html>
<http://pir.georgetown.edu/pirwww/search/genome.html>

Organism-specific databases :

<http://www.unl.edu/stc-95/ResTools/biotools/biotools10.html>
<http://www.-fp.mcs.anl.gov/~gaasterland/genomes.html>
<http://www.hgmp.mrc.ac.uk/GenomeWeb/genome-db.html>
http://www.bioinformatik.de/cgi-bin/browse/Catalog/Databases/Genome_projects/

الفصل الثالث

السجلات واسترجاع المعلومات

يتناول هذا الفصل من الكتاب مهارات استرجاع المعلومات والتي تتيح الاستخدام الفعال لبنوك البيانات.

فهرسة قواعد البيانات وخصائص مصطلحات

البحث:

الفهرس عبارة عن مجموعة من المؤشرات للمعلومات في قواعد البيانات. عند البحث على شبكة المعلومات الدولية أو من خلال قاعدة بيانات للبيولوجيا الجزيئية يتم إدخال واحد أو أكثر من مصطلحات البحث ويقوم برنامج بالبحث عنها في جداول الفهارس. وهنا يتعرف برنامج الاسترجاع على الموضوعات ذات المحتويات المتعلقة بمجال الاهتمام. على سبيل المثال عند إدخال الكلمة حصان horse سوف تحصل على معلومات تختص بموضوعات عديدة تتعلق بالحصان مثل البيولوجيا الجزيئية والتربية والسلالات والقصائد الشعرية حول الحصان وغيرها. وللتركيز على موضوع محدد يسمح نظام استرجاع المعلومات باستخدام كلمات استرشادية. فمثلاً بالبحث عن إنزيم ديهييدروجينيز للكحول في كبد الحصان horse liver alcohol dehydrogenase سوف يتم التعرف فقط على الموضوعات المحتوية على الكلمات الاسترشادية الأربع التي تم إدخالها وهي horse و alcohol و liver و dehydrogenase.

لذلك من المهم استخدام قواعد بيانات متخصصة بما في ذلك قواعد بيانات البيولوجيا الجزيئية والتي تفرض تركيب معين على المعلومات لفصل فئات مختلفة من المعلومات.

تحليل البيانات المسترجعة: أحياناً يكون هناك حاجة إلى الحصول على برنامج يسمح باستخدام النتائج المسترجعة من عمليات بحث في قواعد البيانات - كمدخلات. على سبيل المثال، تستخدم نتائج تتابع بروتين ما كمدخلات للتقريب بواسطة برنامج PSI-BLAST. وفي هذه الحالة يجب تغذية البرنامج بنتيجة التتابع يدوياً. إلا أنه كما هو الحال في التقريب في قواعد البيانات المتعددة، تتيح نظم المعلومات المسترجعة - في البيولوجيا الجزيئية - تسهيلات لبدء تلك العمليات.

السجلات: Archives

بالرغم من أن معرفتنا ببيانات التتابع والتركيب البيولوجي لم تكتمل بعد، إلا أن حجم تلك البيانات ينمو سريعاً. ويعمل العديد من العلماء على توفير البيانات أو تنفيذ مشاريع بحثية لتحليل النتائج. كما تقوم هيئات معنية بقواعد البيانات بأرشفة وتوزيع البيانات.

وتجرى عمليات أرشفة البيانات المتعلقة بالمعلوماتية الحيوية بواسطة مجتمع بحثية مهتمة بالعلوم ذات الصلة.

وتتضمن عملية الجمع الأولى للبيانات المتعلقة بالجزئيات البيولوجية الكبيرة ما يلى:

- تتابعات الحمض النووي بما في ذلك مشاريع الجينوم.
- تتابعات الحمض الأميني للبروتينات.
- تراكيب البروتين والحمض النووي.
- التراكيب البلورية للجزئيات الصغيرة.
- وظائف البروتين.
- طرز تعبير الجينات.
- المراجع والمؤلفات.

قواعد بيانات تتبع الحمض النووي:

يتكون الأرشيف العالمي لتابع الحمض النووي من شراكة ثلاثة وهي: المركز القومي لمعلومات التكنولوجيا الحيوية بالولايات المتحدة الأمريكية، ومكتبة البيانات لمعهد البيو معلوماتية الأوروبي بالمملكة المتحدة (EMBL)، وبنك اليابان لمعلومات الدنا (المعهد القومي للوراثة اليابان). ويتم تبادل البيانات بين المجموعة يومياً. ولذلك فإن البيانات الأولية تكون متطابقة بالرغم من اختلاف نماذج تخزين البيانات وطبيعة تفسيرها. وتقوم قواعد البيانات هذه بمعالجة وأرشفة وتوزيع تتابعات الدنا والرنا المجمعة من مشروعات الجينوم والمنشورات العلمية وتطبيقات براءات الاختراع. وتحتاج المجلات العلمية لإدارات جديدة لتتابعات جديدة للنيكلويونيدات في قاعدة البيانات كشرط لنشر المقالة وذلك للتأكد من حرية توفير تلك البيانات الأساسية. وكذلك الحال بالنسبة لتتابعات الحمض الأميني ونراكيب الحمض النووي والبروتين.

تكون قواعد بيانات تتبع الحمض النووي من مجموعات من المدخلات. لكل مدخل ملف نص يحتوى على البيانات والتفسيرات لكل تتابع مجلور. العديد من المدخلات تكون مجمعة من عدة أوراق علمية منشورة تقرر أجزاء متداخلة لتتابع كامل.

فيما يلى مثال لمدخلات تتبع دنا من مكتبة بيانات EMBL متضمنة تفسيرات وبيانات تتبع جين مثبط التربسين البنكرياسي:

The EMBL Data Library entry for the Bovine pancreatic trypsin inhibitor gene.

```
ID  BTBPTIG    standard; DNA; MAM; 3998 BP.  
XX  
AC  X03365; K00966;  
XX  
CV  X03365.1  
XX  
LT  18-NOV-1986 (Rel. 10, Created)  
LT  20-MAY-1992 (Rel. 31, Last updated, Version 3)  
XX  
DE  Bovine pancreatic trypsin inhibitor (BPTI) gene  
XX  
KW  Alu-like repetitive sequence; protease inhibitor; trypsin inhibitor.  
XX  
OS  Bos taurus (cow)
```

OC Eukaryota; Metazoa; Chordata; Craniata; Vertebrata;
Euteleostomi; Mammalia;
OC Eutheria; Cetartiodactyla; Ruminantia; Pecora; Bovoidea;
Bovidae; Bovinae;
OC Bos.
XX
RN [1]
RP 1-3998
RX MEDLINE; 86158754.
RA Kingston I.B., Anderson S.;
RT "Sequences encoding two trypsin inhibitors occur in strikingly
similar
RT genomic environments";
RL Biochem. J. 233:443-450(1986).
XX
RN [2]
RX MEDLINE; 84070725.
RA Anderson S., Kingston I.B.;
RT "Isolation of a genomic clone for bovine pancreatic trypsin
inhibitor by
RT using a unique-sequence synthetic dna probe";
RL Proc. Natl. Acad. Sci. U.S.A. 80:6838-6842(1983).
XX
DR SWISS-PROT; P00974; BPT1_BOVIN.
XX
CC Data kindly reviewed (08-DEC-1987) by Kingston I.B.
XX
FH Key Location/Qualifiers
FH
FT source 1..3998
FT /db_xref="taxon:9913"
FT /organism="Bos taurus"
FT misc_feature 795..800
FT /note="pot. polyA signal"
FT misc_feature 835..839
FT /note="pot. polyA signal"
FT repeat_region 837..847
FT /note="direct repeat"
FT misc_feature 930..945
FT /note="sequence homologous to Alu-like
consensus seq."
FT repeat_region 1035..1045
FT /note="direct repeat"
FT misc_feature 2456..2461
FT /note="pot. splice signal"
FT CDS 2470..2736
FT /db_xref="SWISS-PROT:P00974"
FT /note="put. precursor"
FT /protein_id="CAA27062.1"
FT
/translation="PSLFNRDPPIPAQQRPDFCLEPPYTGPCKARIIRYFYNAKAGLCQ
FT TFVYGGCRAKRNNFKSAEDCMRTCGGAIGPWGKTGGRAEGEGKG"
FT misc_feature 2488..2489
FT /note="pot. intron/exon splice junction"
FT misc_feature 2506..2507
FT /note="pot. intron/exon splice junction"
FT CDS 2512..2685
FT /db_xref="SWISS-PROT:P00974"
FT /note="trypsin inhibitor (aa 1-58)"
FT /protein_id="CAA27063.1"
FT
/translation="RPDFCLEPPYTGPCKARIIRYFYNAKAGLCQTFVYGGCRAKRNNF
FT KSAEDCMRTCGGA"
FT misc_feature 2698..2699
FT /note="pot. exon/intron splice junction"
FT misc_feature 3690..3695
FT /note="pot. polyA signal"

كراسات "عرض"

```
FT misc_feature 3729..3733
FT          /note="pot. polyA signal"
XX
SQ Sequence 3998 BP; 1053 A; 902 C; 892 G; 1151 T; 0 other;
aattctgata atgcagagaa ctggtaagga gtctgattt ttctgcttga
ttaaatgggt 60
tgtaacagga tagtgtcttgc tcctgatcct agcattcata tggtgtgtt
tcggggcaa 120
gtcatctgca gtttcttcac ctgaacaggg ggaccaggaa acatgagttt
cttaaaagat 180
taccagtcat gagtatgaag agtttacact ttccctgatca atgacgtcca
ttccccatca 240
aaatattttt gtc当地aaaga ctc当地tatac taatgttagat cattttctca
ccacccctct 300
aaaaaaattn tcttcagat atgatcattt ctcttattat aaattaatca
gagagttgag 360
tgacagctga gtttccc tccaaaggca actgcaggaa gagcaagaaa
tgcaatactt 420
ttctatgagt ttgtctcggtt ggccaagact gcttttcca ggctggtaca
atagtaatca 480
aatctcaaag atattcttct ttccctcggtt ccagactattt atttttatttt
cctatcaaga 540
tatagaaaatg tagaaagtaga ctc当地atta tataaggcagg cctcatcatc
aaatagacta 600
acaagaattn tattttatct gcctttcaa tgactgtca cttggcatga
ggatgaaatg 660
ggagatttat tcccttgata aatattcatg aaatacttat gcttttgc
cctaaaaagc 720
atatttcttg atataggaaa acagctgtaa acaaaggta gtaaaataat
atgccttcta 780
agagggatac agacaataaa gacggggcg gattcctata ccaggtcatg
atgagtgta 840
tgaggaaggt 900
gaggagacat taagcagaag ctgccaaaaa ggagcctggt gtgttgagc
a<=cagccagg 960
accagggtgg 1020
geagcagaga 1080
ggccatgggg 1140
aatttgactc 1200
tgagagagct 1260
ggactggagt 1320
tttaacaggg 1380
aaagcagggg 1440
acagggggcc 1500
aqaatata 1560
cctgtgttgt 1620
c1tgctatat 1680
g1.catttgta 1740
attgattcaa 1800
aaagaagtag 1860
atccccatc
ttggcttgc
actccccctt
gctctcatct
tggatgcag
accaagttaa
tcttattatt
ccttctcca
tttatggcat
cctatcaacc
atgggctggc
gcaacccttg
```

gtggtccagt	tcagccattg	ccactgtcgt	agccacagtg	ggctcttcgc
cctcccgttc	1920	aaggaacagg	aatttatact	gtggaaagat
ttttgtataa				ggtttcttg
agacagtagc	1980	atgcgtatcat	ctccgtgggc	ccaatttcca
ttccagcaac	2040	tcttctccgg	attattggct	ggccctgagg
tcagtgtatgc	2100	tttcttaacg	gtggaaagttt	tgagcagaat
ttaaaaaaagc	2160	cgtggatcca	ttgtccagct	ccaccacaca
tatatgtgc	2220	cctcttttgt	gttacttttg	catacataga
gcataaacat	2280	tcatacatgg	catgttaatta	aaactcatca
taacaacatt	2340	aataataatg	tcctggaaag	gtacgtatcc
cacttctgcc	2400	caccccccatt	caactcttat	aaaggcctt
gtagactgag	2460	ctgtgtatgc	cttcccttctt	tggttttagt
gcggccgtac	2520	ttctgtcttag	agectccata	tgccctgtca
atacttctac	2580	aacgccaagg	ctgggctctg	tttataatat
taaaagaaac	2640	aatttcaaga	gcccgtggjt	tgccctgtca
gcacccatgg	2700	aagacagggg	2700	ttgttcacacc
gcgcctcaga	2760	ggccacacac	gcagggcaga	aaactcatcc
gagaagttgc	2820	agaagccctg	ctttccaaaa	ctccatccat
gccacccct	2880	agaagtatcc	gtggatttag	tttcccttgc
gatggaaaca	2940	ctgagtcagt	tcatcataat	atggaccgc
cctcagcctg	3000	tcagagatgt	ctgactgcag	tttcccttgc
aaaaactccc		cattcagcaa	ttgttatttgc	tttcccttgc
ttgcgcattt	3060	ctgggatgt	cttagacctg	tttcccttgc
tcagagatgt	3120	gaagtatgag	tcagggtgga	tttcccttgc
atttcagct	3180	atccatgcct	catgtccat	tttcccttgc
ccitccctca	3240	cttttttattt	cttctcaacc	tttcccttgc
ccatccatca	3300	caggccact	ctatctcata	tttcccttgc
gaaagcaaat	3360	cttcccttttgc	ctatctcata	tttcccttgc
tccagaaata	3420	tttcccttgc	ctatctcata	tttcccttgc
ttggagaaag	3480	tttcccttgc	ctatctcata	tttcccttgc
ctgagatttt	3540	aatctggattt	cttgccttaa	tttcccttgc
ttttcagctc	3600	accatcaactg	cttgccttaa	tttcccttgc
tgaggctctg	3660	agtggggata	cttgccttaa	tttcccttgc
aactaactgg	3720	tgcttcaaa	gaggtttttt	tttcccttgc
aaacgtgtgt	3780	atgggattgt	gttggggca	tttcccttgc
gactcagccc	3840	ctttctcattt	ttatgcagat	tttcccttgc

```
taccaagtag    aaggagccaa    ccccttacac    tgacatctac    ctcttatggc  
cgtgccatg    3900  
tacatgaaaa    actggatgag    agacacaccta    acaagaaaac    ttttgtcatt  
caattttgg    3960  
ggcaggtaa    actttgggtt    gtgttatttc    cctgaatt    3998  
//
```

السطور التي تبدأ ب FT هي عبارة عن مكون لتفسير المدخل الذي يقرر صفات مناطق متخصصة (تابعات كودية CDS) بحيث تقرأ بواسطة برامج كمبيوتر. على سبيل المثال: لترجمة كود منطقة إلى تتابع حمض الأميني، توجد نماذج متحكم فيها بعنایة ومفردات مقيدة. ويكون من المهم وجود مفردات لغوية محكمة وقواميس وكلمات استرشادية وجداول مميزة حتى يمكن إنشاء روابط بين قواعد بيانات مختلفة.

قواعد بيانات الجينوم:

بالرغم من أن تتابعات الجينوم تشكل مدخلات الأرشيفات المرجعية للتتابع الحمض النووي، فإن العديد من الأنواع لها قواعد بيانات خاصة والتي تجمع تتابع الجينوم وتفسيره مع باقي البيانات ذات العلاقة بالنوع.

مصادر على الانترنت Web Resources لروابط قواعد بيانات للكائنات:

<http://www.unl.edu/stc-95/ResTools/biotools/biotools10.html>

<http://www.-fp.mcs.anal.gov/~gaasterland/genomes.html>

<http://www.hgmp.mrc.ac.uk/GenomeWeb/genome-db.html>

http://www.bioinformatik.de/cgi-bin/browse/Catalog/Database/Genome_projects/

قواعد بيانات تتبع البروتين:

تتأتى بيانات تتبع الحمض الأميني من ترجمة تتابعات الحمض النووي. يتعاون المعهد السويسرى للبيومعلوماتية مع مكتبة بيانات EMBL لتنزود قاعدة بيانات تفسيرية للتتابعات الحمض الأميني تسمى SWISS-PROT. كما توجد قاعدة بيانات للتتابع البروتين تنتجها The PIR International والتي تشكل مجموعات فى المؤسسة القومية للبحوث الطبية بجامعة جورجتاون واشنطن - الولايات المتحدة الأمريكية، ومركز معلومات

ميونيخ للتبعات البروتين (MPIS) بألمانيا، وقاعدة بيانات اليابان الدولية لمعلومات البروتين.

وفيمالي نموذج لمدخلات تتبع الحمض الأميني لبروتين لمثبط التربسين البنكرياسي في قاعدة بيانات PIR:

PIR entry for the amino-acid sequence of Bovine pancreatic trypsin inhibitor

```
ENTRY          TIBO #type complete iProClass View of TIBO
TITLE          basic proteinase inhibitor precursor - bovine
ALTERNATE_NAMES aprotinin; basic pancreatic trypsin inhibitor;
BPTI;
ORGANISM       cationic kallikrein inhibitor; inhibitor IV
#formal_name Bos primigenius taurus #common_name
cattle
#cross-references taxon:9913
DATE           24-Apr-1984 #sequence_revision 22-Jul-1994
#text_change
ACCESSIONS     S00277; A30333; S10546; S02486; S28197; A90162;
A92023;
REFERENCE      S00274
#authors       Creighton, T.E.; Charles, I.G.
#journal       J. Mol. Biol. (1987) 194:11-22
#title         Sequences of the genes and polypeptide precursors
for two
bovine protease inhibitors.
#cross-references MUID:87283904
#accession     S00277
##molecule_type DNA; mRNA
##residues 1-100 ##label CR2
##cross-references GB:M20934; GB:X05274; NID:g162767;
PIDN:AAD13685.1; PID:g162769
REFERENCE      A90926
#authors       Creighton, T.E.; Charles, I.G.
#journal       Cold Spring Harb. Symp. Quant. Biol. (1987) 52:511-
519
#title         Biosynthesis, processing, and evolution of bovine
pancreatic trypsin inhibitor.
#cross-references MUID:88295740
#accession     A30333
##molecule_type DNA
##residues 1-100 ##label CRE
##cross-references GB:M20934; GB:X05274; NID:g162767;
PIDN:AAD13685.1; PID:g162769
REFERENCE      S10546
#authors       Kingston, I.B.; Anderson, S.
#journal       Biochem. J. (1986) 233:443-450
#title         Sequences encoding two trypsin inhibitors occur in
strikingly similar genomic environments.
#cross-references MUID:86158754
#accession     S10546
##molecule_type DNA
##residues 34-97 ##label KIN
REFERENCE      S02485
#authors       Fioretti, E.; Angeletti, M.; Fiorucci, L.; Barra,
D. ;
Bossa, F.; Ascoli, F.
#journal       Biol. Chem. Hoppe-Seyler (1988) 369(Suppl.):37-42
```

```
#title Aprotinin-like isoInhibitors in bovine organs.
#cross-references MUID:89076531
#accession S02486
##molecule_type protein
##residues 36-93 ##label FIO
REFERENCE S28197
#authors Ikekita, M.; Jone, C.S.; Kamo, M.; Tsugita, A.; Kizuki, K.; Moriya, H.
#journal Protein Seq. Data Anal. (1992) 5:7-11
#title Purification and characterization of the major cationic kallikrein inhibitor in bovine pituitary gland.
#cross-references MUID:93150003
#accession S28197
##molecule_type protein
##residues 36-93 ##label IKE
REFERENCE A90162
#authors Kassell, B.; Laskowski, M.
#journal Biochem. Biophys. Res. Commun. (1965) 20:463-468
#title The basic trypsin inhibitor of bovine pancreas. V.
The disulfide linkages.
#cross-references MUID:66083012
#contents annotation; disulfide bonds
#accession A90162
##molecule_type protein
##residues 36-93 ##label KAS
REFERENCE A92023
#authors Anderer, F.A.; Hornle, S.
#journal J. Biol. Chem. (1966) 241:1568-1572
#title The disulfide linkages in kallikrein inactivator of bovine lung.
#cross-references MUID:66171231
#contents annotation; disulfide bonds
#accession A92023
##molecule_type protein
##residues 36-93 ##label AN2
REFERENCE A90736
#authors Chauvet, J.; Acher, R.
#journal Bull. Soc. Chim. Biol. (1967) 49:985-1000
#title La structure covalente d'un inhibiteur polypeptidique de la trypsine (inhibiteur de Kunitz et Northrop).
#cross-references MUID:68012003
#contents annotation; disulfide bonds
#accession A90736
##molecule_type protein
##residues 36-93 ##label CHA
REFERENCE A90927
#authors Dlouha, V.; Pospisilova, D.; Meloun, B.; Sorm, F.
#journal Collect. Czech. Chem. Commun. (1968) 33:1363-1365
#title Sequence of residues 18-20 in pancreatic trypsin inhibitor.
#accession A90927
##molecule_type protein
##residues 36-93 ##label DLO
REFERENCE A93410
#authors Huber, R.; Kukla, D.; Ruhlmann, A.; Epp, O.; Formanek, H.
#journal Naturwissenschaften (1970) 57:389-392
#title The basic trypsin inhibitor of bovine pancreas. I. Structure analysis and conformation of the polypeptide chain.
#cross-references MUID:70255230
```

#contents annotation; X-ray crystallography of basic protease inhibitor, 2.5 angstroms

REFERENCE A34658
 #authors Lewis, R.V.; Ray, P.; Coguill, R.; Kruggel, W.
 #journal Biochem. Biophys. Res. Commun. (1990) 167:543-547
 #title Presence of pancreatic trypsin inhibitor in adrenal medullary chromaffin cells.
 #cross-references MUID:90211226
 #accession A34658
 ##molecule_type protein
 ##residues 36-53,55-81.##label LEW

REFERENCE A93977
 #authors Anderson, S.; Kingston, I.B.
 #journal Proc. Natl. Acad. Sci. U.S.A. (1983) 80:6838-6842
 #title Isolation of a genomic clone for bovine pancreatic trypsin inhibitor by using a unique-sequence synthetic DNA probe.
 #cross-references MUID:84070725
 #accession A93977
 ##molecule_type DNA
 ##residues 'PSLFNRDPPPIPA',34-97,'GKTGGRAEGERK' ##label AND
 ##cross-references GB:X03365; GB:K00966; NID:g142;
 PIDN:CAA27062.1;
 PID:g1364183

REFERENCE S00371
 #authors Siekmann, J.; Wenzel, H.R.; Schroeder, W.;
 Tschesche, H.
 #journal Biol. Chem. Hoppe-Seyler (1988) 369:157-163
 #title Characterization and sequence determination of six aprotinin homologues from bovine lungs.
 #cross-references MUID:88221840
 #accession S10062
 ##molecule_type protein
 ##residues 36-66,'P',68-82,'S',84-93 ##label SIE
 ##experimental_source lung
 ##note the authors designated this protein as isoaprotinin 2

COMMENT Basic proteinase inhibitor is an intracellular polypeptide found in many tissues, probably located in granules of connective tissue mast cells.

GENETICS #introns 34/1; 98/1

CLASSIFICATION #superfamily basic proteinase inhibitor; animal Kunitz-type proteinase inhibitor homology

KEYWORDS serine proteinase inhibitor

FEATURE 1-20 #domain signal sequence #status predicted
 #label SIG\

21-35 #domain propeptide #status predicted

#label PRO\
 36-100 #product basic proteinase inhibitor

#status experimental #label MAT\
 40-90 #domain animal Kunitz-type proteinase inhibitor

homology #label BPI\
 40-90,49-73,65-86 #disulfide_bonds #status experimental\
 50 #inhibitory_site Lys (trypsin,

chymotrypsin, kallikrein, plasmin) #status experimental

SUMMARY #length 100 #molecular_weight 10903

SEQUENCE

5	10	15	20	25	30
1 M K M S R L C L S V A L L V L L G T L A A S T P G C D T S N					
31 Q A K A Q R P D F C L E P P Y T G P C K A R I I R Y F Y N A					
61 K A G L C Q T F V Y G G C R A K R N N F K S A E D C M R T C					
91 G G A I G P W E N L					

in the PIR1 section of the Protein Sequence Database, release
71.00,
31-Dec-2001, assembled and annotated by the PIR-International.
Copyright 2000 PIR-International.

PDB structures most related to TIBO:

1CBWD (36-93) 100.0%; 1BZ5E (36-93) 100.0%; 9PTI (36-91)
100.0%
1BZXI (36-93) 100.0%; 1B0CB (36-93) 100.0%; 1CBWI (36-93)
100.0%
1B0CD (36-93) 100.0%; 1B0CE (36-93) 100.0%; 6PTI (36-93)
100.0%
1BHCA (36-93) 100.0%; 1BHCC (36-93) 100.0%; 1MTND (36-93)
100.0%
1BHCE (36-93) 100.0%; 1MTNH (36-93) 100.0%; 1BHCG (36-93)
100.0%
1PIT (36-93) 100.0%; 1BHCI (36-93) 100.0%; 1TPAI (36-93)
100.0%
1BPI (36-93) 100.0%; 2HEXA (36-93) 100.0%; 1BTHQ (36-93)
100.0%
2HEXB (36-93) 100.0%; 1BZ5B (36-93) 100.0%; 2HEXC (36-93)
100.0%
1BZ5D (36-93) 100.0%; 2HEXD (36-93) 100.0%; 1B0CC (36-93)
100.0%
2HEXE (36-93) 100.0%; 1BHCD (36-93) 100.0%; 2KAI (36-93)
100.0%
1BHCH (36-93) 100.0%; 2PTCI (36-93) 100.0%; 1BTHP (36-93)
100.0%
2TGPI (36-93) 100.0%; 1BZ5C (36-93) 100.0%; 2TPII (36-93)
100.0%
1BHCB (36-93) 100.0%; 3TGII (36-100) 100.0%; 1BHCJ (36-93)
100.0%
3TGJI (36-100) 100.0%; 1B0CA (36-93) 100.0%; 3TPII (36-93)
100.0%
1BZ5A (36-93) 100.0%; 4PTI (36-93) 100.0%; 1BHCF (36-93)
100.0%
5PTI (36-93) 100.0%; 1FAN (36-93) 98.3%; 1BPT (36-93) 98.3%
1NAG (36-93) 98.3%; 1BTI (36-93) 98.3%; 4TPII (36-93) 98.3%
8PTI (36-93) 98.3%; 1AALA (36-93) 96.6%; 1AALB (36-93) 96.6%
7PTI (36-93) 96.6%; 1BRBI (36-93) 94.8%; 1QLQA (36-93) 93.1%

SCOP: 1CBW ; 1BZ5 ; 9PTI ; 1BZX ; 1B0C ; 6PTI ; 1BHC ; 1MTN ;
1PIT ; 1TPA ;
; 1BPI ; 2HEX ; 1BTH ; 2KAI ; 2PTC ; 2TGP ; 2TPI ; 3TGI ; 3TGJ ;
3TPI ; 4PTI ;
; 5PTI ; 1FAN ; 1BPT ; 1NAG ; 1BTI ; 4TPI ; 8PTI ; 1AAL ; 7PTI ;
1BRB ; 1QLQ

CATH: 1CBW ; 1BZ5 ; 9PTI ; 1BZX ; 1B0C ; 6PTI ; 1BHC ; 1MTN ;
1PIT ; 1TPA ;
; 1BPI ; 2HEX ; 1BTH ; 2KAI ; 2PTC ; 2TGP ; 2TPI ; 3TGI ; 3TGJ ;
3TPI ; 4PTI ;
; 5PTI ; 1FAN ; 1BPT ; 1NAG ; 1BTI ; 4TPI ; 8PTI ; 1AAL ; 7PTI ;
1BRB ; 1QLQ

FSSP: 1CBW ; 1BZ5 ; 9PTI ; 1BZX ; 1B0C ; 6PTI ; 1BHC ; 1MTN ;
1PIT ; 1TPA
; 1BPI ; 2HEX ; 1BTH ; 2KAI ; 2PTC ; 2TGP ; 2TPI ; 3TGI ; 3TGJ ;
3TPI ; 4PTI
; 5PTI ; 1FAN ; 1BPT ; 1NAG ; 1BTI ; 4TPI ; 8PTI ; 1AAL ; 7PTI ;
1BRB ; 1QLQ

MMDB: 1CBW ; 1BZ5 ; 9PTI ; 1BZX ; 1B0C ; 6PTI ; 1BHC ; 1MTN ;
1PIT ; 1TPA
; 1BPI ; 2HEX ; 1BTH ; 2KAI ; 2PTC ; 2TGP ; 2TPI ; 3TGI ; 3TGJ ;
3TPI ; 4PTI
; 5PTI ; 1FAN ; 1BPT ; 1NAG ; 1BTI ; 4TPI ; 8PTI ; 1AAL ; 7PTI ;
1BRB ; 1QLQ

ALIGNMENTS containing TIBO:

FA2061 basic proteinase inhibitor - 328.8 1.0
SA0572 basic proteinase inhibitor superfamily 328.8
M01603 basic proteinase inhibitor - 1561.0 1.0

Associated Alignments:

DA1053 animal Kunitz-type proteinase inhibitor homology

قواعد البيانات المشاركة لـ SWISS-PROT

يوجد اثنان من قواعد البيانات المشاركة لـ SWISS-PROT وهما

. ENZYME DB & PROSITE

يقوم ENZYME DB بتخزين المعلومات التالية عن الانزيمات:

- EC Number وهو وسيلة تعريف رقمية تم اقرارها بواسطة مفوضية الانزيمات المنبثقة من الاتحاد الدولي للكيمياء الحيوية والبيولوجيا الجزيئية، يمكن الرجوع إلى الموقع التالي:
[\(http://www.chem.qmw.ac.uk/iubmb/enzyme/\)](http://www.chem.qmw.ac.uk/iubmb/enzyme/)
- الاسم الموصى به.
- الاسم البديل، إن وجد.
- النشاط المحفز.
- المرافق.
- مؤشرات إلى SWISS-PROT وبنوك المعلومات الأخرى.
- مؤشرات إلى الأمراض المصاحبة للخلل في النشاط الانزيمي.

والمثال التالي يوضح المدخلات في ENZYME DB حيث:

التعريف	=	ID
الوصف	=	اسم الرسمى
الاسم البديل	=	AN
النشاط التحفيزى	=	CA
المرافق	=	CF
التعليقات	=	CC
مرجع قاعدة البيانات (SWISS-PROT)	=	DR

A Sample Entry in ENZYME DB

ID 1.14.17.3
DE PEPTIDYLGLYCINE MONOOXYGENASE.
AN PEPTIDYL ALPHA-AMIDATING ENZYME.
AN PEPTIDYLGLYCINE 2-HYDROXYLASE.
CA PEPTIDYLGLYCINE + ASCORBATE + O(2) = PEPTIDYL(2-HYDROXYGLYCINE)+
CA DEHYDROASCORBATE + H(2)O.
CF COPPER.
CC -!- PEPTIDYLGLYCINES WITH A NEUTRAL AMINO ACID RESIDUE IN THE
CC PENULTIMATE POSITION ARE THE BEST SUBSTRATES FOR THE ENZYME.
CC -!- THE ENZYME ALSO CATALYZES THE DISMUTATATION OF THE PRODUCT TO
CC GLYOXYLATE AND THE CORRESPONDING DESGLYCINE PEPTIDE AMIDE.
DR P10731, AMD_BOVIN ; P19021, AMD_HUMAN ; P14925, AMD_RAT ;
DR P08478, AMD1_XENLA; P12890, AMD2_XENLA;

: PROSITE

تحتوى على طرز لمتبقيات مجاميع البروتينات مثل الطراز (ال بصمة أو القالب) الذى يظهر عادة فى عائلة من البروتينات القريبة بسبب متطلبات أماكن الارتباط والتى تحد من التحول فى عائلة بروتين ما.

قواعد البيانات المشاركة: PIR

يدبر PIR عدة قواعد بيانات خاصة بالبروتينات مثل:

- PIR-PSD : وهى قاعدة البيانات الأساسية لتابع البروتين.
- iProClass : تقسيم البروتينات طبقاً للتركيب والوظيفة.

- ASDB : قاعدة بيانات التفسير والمماثلة، وكل مدخل متصل بقائمة من التتابعات المماثلة.
- P/R-NREF : تجميع لأكثر من ٨٠٠٠٠ تتابع بروتين من مصادر متاحة.
- NRL3D : قاعدة بيانات لتابعات وتقسيرات لبروتينات معروفة التركيب وموجودة بينك معلومات البروتين.
- ALN : قاعدة بيانات لمحازاة تتابع البروتين.
- RESID : قاعدة بيانات لتحولات التركيب التساهمي للبروتين.

وقد أنشأ PIR موقع Integrated Environment for Sequence (IESA) (Analysis لاسترجاع المعلومات والمعاملة الحسابية لها. ويمكن الرجوع إلى موقع PIR على الويب:

<http://pir.georgetown.edu>

قواعد بيانات التراكيب:

يقوم أرشيف قواعد بيانات التركيب بتفصيل وتوزيع مجاميع من المنسقات الذرية. ويعتبر بنك بيانات البروتين (PDB) Protein Data Bank من أفضل قواعد البيانات الخاصة بـ تراكيب الجزيئات البيولوجية الكبيرة. ويحتوى البنك على تراكيب بروتينات وأحماض نووية وقليل من الكربوهيدرات. ويدار البنك بواسطة the Research Collaboratory for Structural Bioinformatics (RCSB).

والموقع الإلكتروني الأساسي لبنك بيانات البروتين هو: <http://www.rcsb.org>. وهناك موقع رسمية للبنك لأماكن عديدة حول العالم منها أوروبا، سنغافورة، اليابان، والبرازيل.

وتحتوى الصفحة الأساسية للبنك على روابط اتصال ملفات البيانات ذاتها، ومواد تعليمية، أخبار، نشرات دورية وبرامج بحث متخصصة لمعالجة التراكيب.

مثال: يمكن الحصول على بيانات بروتين ثيوردوكسين في بكتيريا *E. coli* (Protein data bank entry 2trx, *E. coli* thioredoxin)

التالي:

<http://www.rcsb.org/pdb/cgi/explore.cgi?job=download;pdBld=2TRX;page=0;pid=197301010382789&opt=show&format=PDB>

وتتضمن المدخلات البيانات التالية:

- نوع البروتين ومصدره.
- مراجعة لوصف طرق تحديد التركيب.
- بيانات تصصيلية لتجارب تحديد التركيب متضمنة نتائج الأشعة السينية واحصائيات للشكل الفراغي للتركيب.
- تابع الحمض الأميني.
- الجزيئات الإضافية مثل المرافق، المثبتات، جزيئات الماء.
- التركيب الثانوي: الشكل المطوى، المنفرد.
- الموقع ثنائية الكبريت.
- المنسقات الذرية.

وقد حدد بنك بيانات البروتين كود تعرف رباعي لكل تركيب موجود بالبنك، يبدأ برقم (من ١ إلى ٩). وأصبح من السهل استرجاع تركيب ما وذلك باستخدام كود التعريف الخاص به. حيث يمكن إدخال الكود على الصفحة الرئيسية لموقع RCSB ثم اختيار Explorer للحصول على ملخص لبيانات التركيب من صفحة واحدة كما هو مبين:

Protein data bank entry Structure Explorer - 2trx, *E. coli* thioredoxin

<http://www.rcsb.org/pdb/cgi/explore.cgi?pid=197301010382789&page=0&pdBld=2TRX>



Structure Explorer - 2TRX



Summary Information

[Summary Information](#)

Title: Crystal structure of thioredoxin from Escherichia coli at 1.68 Å resolution.

[View Structure](#)

Compound: Thioredoxin

[Download/Display File](#)

Authors: S. K. Katti, D. M. LeMaster, H. Eklund

[Structural Neighbors](#)

Exp. Method: X-ray Diffraction

[Geometry](#)

Classification: Electron Transport

[Other Sources](#)

Source: Escherichia coli

[Sequence Details](#)

Primary Citation: Katti, S. K., LeMaster, D. M., Eklund, H.: Crystal structure of thioredoxin from Escherichia coli at 1.68 Å resolution. *J Mol Biol* 212 pp. 167 (1990)

[Crystallization Info](#)

Deposition Date: 19-Mar-1990 *Release Date:* 15-Oct-1991

Top of Form

Resolution [Å]: 1.68

R-Value: 0.165

Explore

Space Group: C 2

[SearchLite](#) [SearchFields](#)

Bottom of Form

<i>Unit Cell dim [Å]:</i>	<i>a</i> 89.50	<i>B</i> 51.06	<i>c</i> 60.45
	<i>alpha</i> 90.00	<i>Beta</i> 113.50	<i>gamma</i> 90.00

Polymer Chains: A, B

Residues: 216

Atoms: 1842

Chemical Components:

("HET" groups) ID

(needs Rasmol)

Name

Formula

Retrieve All
PDB IDs
Containing

CU

CU COPPER (II) ION

MPD 2-METHYL-2,4-

PENTANEDIOL

7(C₆H₁₄O₂)

MPD

[CATH: Structural Classification](#)

[PDBSum: Summary of PDB Structure](#)

[SCOP: Structural Classification](#)

RCSB

والصفحة السابقة بها روابط اتصال للمعلومات التالية:

- مراجع للبيانات الموجودة من خلال قاعدة بيانات المراجع PubMed.
- صور للتراكيب ويحتاج ذلك وجود برنامج لاظهار الصور.
- مداخل لملفات البيانات.
- قوائم بالتراكيب الأخرى ذات الصلة طبقاً لتصنيف تراكيب البروتين.
- التحليل الكيميائي الفراغي، وتوزيع أطوال الروابط والزوايا.
- مصادر لمعلومات حول المدخلات.
- التتابع والتراكيب الثانوية.
- تفاصيل حول الشكل البلوري وطرق انتاج البلورت.

وفي حالة عدم معرفة كود التعرف يمكن استخدام أداة بسيطة من على الصفحة الرئيسية لبنك بيانات البروتين وهي Search Lite والتي تسمح باستخدام كلمات استرشادية key words.

مصادر على الانترنت Web Resources لتراكيب البروتين والحمض النووي:

الصفحة الرئيسية لبنك بيانات البروتين:

<http://www.rcsb.org>

الصفحة الرئيسية لقاعدة بيانات EBI التركيب الجزيئي المакرو:

<http://msd.ebi.ac.uk/>

الصفحة الرئيسية ل BioMagResBank :

<http://www.bmrb.wisc.edu/>

للبحث في بنك بيانات البروتين:

الصفحة الرئيسية ل SCOP (Structural Classification of Protein)

<http://scop.mrc-lmb.cam.ac.uk/scop/>

قائمة باماكن التصفح:

http://pdp-browsers.ebi.ac.uk/browse_it.shtml

أداة البحث : OCA

<http://oca.ebi.ac.uk/oca-bin/ocamain>

قاعدة بيانات التركيب الرباعي للبروتين:

<http://pqs.ebi.ac.uk/>

تقارير جودة التركيب:

<http://www.cmbi.kun.nl/gv/pdbreport>

مصادر على الانترنت Web Resources لقواعد بيانات لعائلات معينة

من بروتين:

Protein kinase :

<http://www.sdsc.edu/kinases/>

HIV proteases

<http://www-fbsc.ncifcrf.gov/HIVdb/>

Icosahedral viruses :

<http://mmtsb.scripps.edu/viper/main.html>

: Immunology قاعدة بيانات علم المناعة

IGMT : (International ImMunoGene Tics database):

<http://imgt.cines.fr>

وهي قاعدة بيانات متكاملة عالية الجودة، ومتخصصة في:

T-Cell receptors (TcR)، و (Ig) Immunoglobulins

Histocompatibility Complex (MHC) molecules of all vertebrate species.

KABAT : <http://immuno.bme.nwu.edu/>

وهي قاعدة بيانات لتابعات البروتينات ذات الأهمية المناعية.

MHCPEP : <http://wehih.wehi.edu.au/mhcpep/>

وهي قاعدة بيانات لمعقد البيبيتيدات الرئيسية المرتبطة والمتواقة
هستولوجيا.

مجموعات من روابط الاتصال لقواعد بيانات لعائلات معينة من
البروتين:

<http://www2.ebi.ac.uk/msd/Links?family.shtml>

قواعد بيانات ناتج تعبير الجين والبروتومكس :proteomics databases

من المعرف أن الدنا يصنع الرنا ويقوم الرنا بصنع البروتين. وتحتوى
قواعد بيانات الجينوم على تتابعات الدنا. كما تسجل قواعد بيانات
التعبير الجيني مقاييس مستويات الرنا الرسول mRNA وذلك عبر (short
terminal sequences of cDNA synthesized from mRNA) ESTs
وصف طرز نسخ الجين. بينما تسجل قواعد بيانات البروتومكس
مقاييس للبروتينات مع وصف طرز ترجمة الجين.

تقديم مقارنات طرز التعبير الجيني معلومات موثقة عن:

(١) وظيفة وآلية فعل نواتج الجين.

(٢) كيف تنسق الكائنات عملية التحكم في العمليات الأيضية تحت
ظروف مختلفة. على سبيل المثال: الخميرة تحت ظروف هوائية
ولاهوائية.

(٣) الاختلافات في تعبئة الجين أثناء مراحل مختلفة من دورة الخلية
وتطور الكائن.

(٤) آليات المقاومة للمضادات الحيوية في البكتيريا وبالتالي اقتراح
أماكن مستهدفة لاستحداث أدوية.

(٥) الاستجابة لتحدي طفيل ما.

(٦) الاستجابة لأنواع وجرعات مختلفة من الأدوية للوصول إلى علاج فعال.

وهناك عدة قواعد بيانات لESTs، تحتوى مدخلات معظمها على مجالات تشير إلى موقع نسيج و/أو مكون تحت خلوى، حالة التطور، ظروف النمو، والمستوى الكمى للتعبير. حالياً تحتوى dbEST من خلال بنك الجين على ما يقرب من تسعة ملايين مدخل من ٣٤٨ نوع.

بعضمجموعات EST متخصصة في أنسجة معينة (عضلات، أسنان) أو أنواع. كما توجد جهود لربط طرز التعبير بمعلومات أخرى حول الكائن. فعلى سبيل المثال ينسق مشروع تطور الجرذان بين بيانات تعبير الجين والتشريح التطورى.

تتيح العديد من قواعد البيانات وسائل للربط بين ESTs في أنواع مختلفة مثل ربط التمايز في الإنسان والجرذان، أو العلاقات بين جينات أمراض الإنسان وبروتينات الخميره. وهناك مجموعات أخرى متخصصة في نوع من البروتين مثل سيتوكتينات. كما يوجد جهداً هائلاً للتركيز على السرطان من حيث تكامل المعلومات عن الطفرات واعادة التنظيم للクロموسومات والتغيرات في طرز التعبير وذلك للتعرف على التغيرات الوراثية أثناء تكوين الأورام ونموها.

بالرغم من العلاقة الشديدة بين طرز النسخ وطرز الترجمة، إلا أن القياسات المباشرة للمحتوى البروتيني للخلايا والأنسجة - البروتومكس proteomics تتيح معلومات إضافية قيمة. وبسبب عدالت النسخ المختلفة لمختلف الرنا الرسول فإن قياسات البروتينات تعطي مباشرة وصفاً أكثر دقة لطرز تعبير الجين بالمقارنة بقياسات النسخ. ويمكن اكتشاف تحورات ما بعد الترجمة فقط عن طريق فحص البروتينات.

يتضمن تحليل البروتوم الفصل والتعريف والتقدير الكمى لبروتينات العينة. ويعتمد ذلك على فرد البروتين بواسطة الجيل ثنائى الأبعاد

وتعريف كل مكون بواسطة مطياف الكتلة. وتقوم قواعد بيانات البروتين بتخزين صور الجيل وتقديراتها على هيئة طرز بروتين. كما تظهر بعض قواعد البيانات صوراً وتسمح باختيار تفاعلٍ للنقطة. وباختيار نقطة معينة تفتح نافذة لمدخلات البيانات المتطابقة. ويوجد مدخل بيانات لكل بروتين يسجل المعلومات التالية:

- تعريف البروتين.
- الكمية.
- الوظيفة.
- آلية الفعل.
- طراز التعبير.
- مكان التواجد تحت الخلوي.
- البروتينات ذات الصلة.
- تحورات ما بعد الترجمة.
- التفاعلات مع البروتينات الأخرى.
- روابط اتصال بقواعد بيانات أخرى.

وقد ساهمت البيومعلوماتية في إنشاء وتطوير قواعد البيانات هذه، وكذلك إيجاد نظم خوارزمية لمقارنة وتحليل طرز البروتينات المحتوية عليها تلك القواعد.

قواعد بيانات المسارات الأيضية :Databases of metabolic pathways

تقوم قاعدة Kyoto Encyclopedia of Genes and Genomes (KEGG) بجمع الجينوم، ونواتج الجين ووظائفها، وعمل تكامل بين المعلومات البيوكيميائية والوراثية. وتركز KEGG على تفاعلات شبكات التجميع الجزيئي والشبكات الأيضية والمنظمة.

1) وتنظم KEGG خمسة أنواع من البيانات من خلال نظام شامل وهي:

٢) كتالوج للجينات يحتوى على جزيئات وتنابعات معينة.
٣) خرائط الجينوم. حيث يتم التكامل بين الجينات طبقاً لظهورهم على الكروموسومات.

٤) خرائط المسارات والتى تصف شبكات الأشط الأيضية والمنظمة للجزيئات. وتساهم فى امكانية ايجاد مسار اىضى حقيقى فى كائن معين عن طريق مضاهاة بروتينات هذا الكائن مع انزيمات مسارات مرجعية.

٥) جداول أرثولوج. تستخد ببيانات تلك الجداول لربط انزيم فى كائن ما بالانزيمات ذات الصلة فى كائنات أخرى. ويتبع ذلك تحليل العلاقات بين المسارات الأيضية فى كائنات مختلفة.

تتيح KEGG امكانية أخذ مجموعة من الانزيمات من كائن واختبار مدى تكاملها مع مسارات أىضية معروفة. وفي حالة ظهور فراغ فى مسار ما فان ذلك قد يرجع الى غياب انزيم او مسار اىضى غير متوقع.

مداخل الى السجلات :

تمتلك قواعد بيانات الحمض النووي وتنابعات البروتين امكانات هائلة لاسترجاع المعلومات وتحليلها من خلال عديد من العمليات والتى تتضمن:

١. استرجاع التنابعات من قاعدة البيانات.
 ٢. مقارنة التنابع.
 ٣. ترجمة تنابعات الدنا الى تنابعات بروتين.
 ٤. تحليل التركيب والتنبؤ.
 ٥. طرز التعرف.
٦. الأشكال الجزيئية. وتستخدم تلك الأشكال فى:

- خرطنة الأجزاء التي يعتقد أن لها وظيفة ما إلى إطار ثلثي الأبعاد لبروتين.
- تقسيم ومقارنة طرز الطى في البروتينات.
- تحليل الاختلافات بين التراكيب شديدة القرابة أو بين الأوضاع الفراغية لجزء ما.
- دراسة تفاعل جزئ بسيط مع بروتين كمحاولة لتحديد وظيفة أو لاكتشاف دواء.
- الحصول على نموذج تفاعلي لتحسين جودة صور الأشعة السينية لمقاييس تراكيب البروتين.
- تصميم ونمذجة تراكيب جديدة.

ENTREZ هي نقطة البداية لاسترجاع تتابعات وتراتيب من على الموقع التالي:

<http://www.ncbi.nlm.nih.gov/ENTREZ/>

طرق الدخول إلى قواعد بيانات البيولوجيا الجزيئية:

وتقديم ENTREZ طرق دخول عبر الأقسام الآتية لقواعد البيانات:

- Protein
- Peptide
- Nucleotide
- Structure
- Genome
- Popset- information about populations
- OMIM- Online Mendelian Inheritance in Man

فمثلا للبحث في قاعدة البروتين: ادخل على موقع ENTREZ، ثم اختر بروتين، ثم ادخل نوع البروتين المطلوب البحث عنه، ثم اضغط على GO وسيقوم البرنامج باظهار الاجابات.

وللبحث في قاعدة بيانات النيكلويوتيدات: اختر نيكليوتيد من على موقع INDEX واضغط على ENTREZ ثم اختر الكائن من القائمة وادخل اسم الموضوع في صندوق البحث، ثم اضغط على AND ثم اتبع التعليمات من القائمة.

:OMIM

وهي قاعدة بيانات للجينات البشرية والعيوب الوراثية. وتعمل بتكميل تام مع ENTREZ.

نظام استرجاع التتابع (SRS) :The Sequence Retrieval System (SRS) يستطيع نظام SRS البحث في ١٤١ من قواعد بيانات البروتين، وتتابعت النيكليوتيد، والمسارات الأيضية، والتركيب ثلاثية الأبعاد، والوظائف، والجينوم، والأمراض.

مصدر تعريف البروتين (PIR) :The Protein Identification Resource

يمكن البحث باستخدام SRS من على الموقع التالية :
فى الولايات المتحدة الأمريكية :

<http://www-nbrf.georgetown.edu/pirwww/search/textpsd.html>

فى أوروبا: <http://www.mips.gsf.de>

: ExPASY-Expert Protein Analysis System

وهو نظام استرجاع وتحليل المعلومات لمعهد البيو معلوماتية السويسرى بالتعاون مع معهد البيو معلوماتية الأوروبي والذى ينتج قواعد بيانات تتابع البروتين SWISS-PROT وقاعدة TrEMBL التى تحتوى على ترجم تتابعات النيكلوتيد. وفتح الصفحة الرئيسية ل ExPASY

يعطى TrEMBL و اختصار SWISS-PROT (<http://www.expasy.ch>)

مدخل توصل الى أدوات استرجاع المعلومات.

ENSEMBL

وهو عبارة عن مصدر معلومات شامل للجينوم البشري (<http://www.ensemble.org>). وتهدف الى جمع وتقسیر كل المعلومات المتاحة عن تتابعات الدنا البشري، وروابط اتصال الى تتابع جينوم قياسي، واتاحة هذه المعلومات لعديد من العلماء. ويمكن للمستخدم تعريف مناطق في التتابع عبر عدة أدوات بحث:

- BLAST ويستخدم للبحث عن تتابع او جزء منه.
- التصفح، ويبدا على مستوى الكروموسوم ثم يتعمق داخله.
- العلاقة بالأمراض بواسطة OMIM.
- ENSEMBL ID •
- أداة بحث عامة للنصوص.

الفصل الرابع

المحازاة والأشجار العرقية

محازاة التتابع:

في حالة وجود اثنان من التتابعات يتم عمل الآتي:

- قياس درجة التشابه بينهما.
- تحديد تقابل الأجزاء.
- ملاحظة طرز التحفظ والاختلاف.
- علاقات النشوء.

:The dotplot

وهي صورة بسيطة تعطي رؤية عامة للتشابه بين اثنان من التتابعات. يتكون dotplot من جدول أو مصفوفة. تشير الصفوف إلى أجزاء أحد التتابعات بينما تدل الأعمدة على التتابع الآخر. وتظهر بقئع في حالة التمايز، بينما لا توجد استجابة في حالة الاختلاف.

مصادر DOTPLOTS على الانترنت (web Resources)

يتيح برنامج E.L. Sonnhammer's Dotter للمس تخدم التحكم وطرق الحساب وتعديل مظهر العرض بواسطة ضبط معايير تفاعلية والذي يجب تجهيزه في الكمبيوتر من على الموقع التالي:

<http://www.cgr.ki.se/cgr/groups/sonnhammer/Dotter.html>

يقدم الموقع التالي إمكانية اجراء dotplotting تفاعلياً:
<http://www.isrec.isb-sib.ch/java/dotlet/exonintron.html>

A PERL program to draw dotplots.

```

#!/usr/bin/perl
#dotplot.pl -- reads two sequences and prints dotplot
# read input
$/ = "";
$_ = <DATA> $_ =~ s/(.*)\n/\n/g;
$_ = ~^(.*)\n\s*(\d+)\s+(\d+)\s*\n(.*)\n([A-Z\n]*)\*\s*\n(.*)\n([A-Z\n]*)\*\*/s;
$title = $1; $nwind = $2; $thresh = $3;
$seqt1 = $4; $seq1 = $5; $seqt2 = $6; $seq2 = $7;
$seq1 =~ s/\n//g; $seq2 =~ s/\n//g; $n = length($seq1); $m =
length($seq2);
# postscript header
print << EOF setfont scalefont 20 findfont Helvetica translate 30
setlinewidth 1.75 def load fill f closepath c newpath n rlineto r
moveto m lineto l stroke s %!PS-Adobe->

#print matrix

$dx = 500.0/$n; $mdx = -$dx; $dy = 500.0/$m;
if ($dy < $dx) { $dx = $dy; } $dy = $dx; $xmx = $n*$dx; $ymx =
$m*$dx;
print "0 510 m ($title NWIND = $nwind) show\n";
printf "0 0 m 0 %9.2f 1 %9.2f %9.2f 1 %9.2f 0 1 c s\n",
$ymx,$xmx,$ymx;
for ($k = $nwind - $m + 1; $k < $n - $nwind; $k++) {
    $i = $k; $j = 1; if ($k < 1) { $i = 1; $j = 2 - $k; }
    while ($i <= $n - $nwind && $j <= $m - $nwind) {
        $_ = (substr($seq1,$i -1,$nwind)) ^ substr($seq2,$j -
1,$nwind));
        $mismatch = ($_ =~ s/[^x0]//g);
        if ($mismatch < $thresh) {
            $xl = ($i - 1)*$dx; $yb = ($m - $j)*$dy;
            printf "n %9.2f %9.2f m %9.2f 0 r 0 %9.2f r %9.2f 0 r c
f\n",
                $xl,$yb,$dx,$dy,$mdx;
        }
        $i++; $j++;
    }
}
print "showpage\n";

-END_
ATPases lamprey / dogfish          #TITLE
15 6                                #WINDOW, THRESHOLD
Petromyzon marinus mitochondrion   #SEQUENCE 1
ATGACACTAGATATCTTGACCAATTACCTCCCCAAC
ATATTTGGCCTTCCACTAGCTGTATAGCTATACTAGCCCCTAGCTTA
ATATTAGTTTCACAAACACAAAATTATCAAATCTCGTTACACACTA
CTTACACCCATCTAACATCTATTGCCAAACAACTCTTCTTCCAATAAAC
CAACAAGGGATAATGAGCCTTAATTGTATAGCCTCTATAATATTATC
TTAATAATTAAATCTTAGGATTATACCATATACTTACACCAACTACC
CAATTATCAATAAACATAGGGATTAGCAGTGCCTAGTACTAGCTACTGTC
CTCATTGGGTTACAAAAAAACCAACAGAAGGCCCTAGCCCCACTTATTACCA
GAAGGTACCCAGCAGCACTATTCCCATATTAAATTATCATTGAAACTATT
AGTCTTTTATCCGACCTATGCCCTAGGAGTCGACTAACCGCTAATTAA
ACAGCTGGTCACTTACTTACAAACTAGTTCTATAACAACCTTGTAAATA
ATTCCCTGTCAATTCAATTATTACCTCACTACTTCTTCTTATT
CTAACAAATTCTGGAGTTAGCTGTGCTGAATCCAGGCATATGTATTATT
CTACTTTAACTCTTATCTGCAAGAAAACGTTT*
Scyliorhinus canicula mitochondrion #SEQUENCE 2
ATGATTATAAGCTTTTGATCAATTCTAACGCCCCCTTTCTAGGA
ATCCCACATAATTGCCCTAGCTATTCAATTCCATGATTAATATTCCAACACCAAC
AATCGTTGACTTAATAATCGATTATAACTCTCAAGCATGATTATTAACCGATTAT
TATCAACTAATACAACCCATAAATTAGGAGGACATAAATGAGCTATCTTACAC
CTAATATTATTTTAATTACCATCAATCTCTAGGTCTCCCTTCCATATACTTTACGCT
ACAACTCAACTTCTCTTAATATAGCCTTGGCCCTTATGGCTACAACTGTATT

```

ATGGTATTTAATCAACCAACCATTGCCCTAGGGCACTTATTACCTGAAGGTACCCCA
ACCCCTTAGTACCACTAATCATTATCGAAACCACAGTTTATTGACCATTA
GCCTTAGGAGTCCGATTAACAGCCAACCTAACAGCTGACATCTCCCTTATAAATC
GCAACTGCGGCTTGTCTTTAACTATAATACCAACCGTGGCCTACTAACCTCCCTA
GTCCTGTTCTATTGACTATTAGAAGTGGCTGTAGCTATAATTCAAGCATACTATT
GTCCTCTTTAAGCTTATCTACAAGAAAACGTATAA*

محازاة التتابع بواسطة Dotplots

لا يقدم **Dotplots** فقط صورة شاملة لتشابه اثنان من التتابعات ولكن أيضاً يعطى مجموعة متكاملة ذات جودة نسبية للمجازاة المحتملة وذلك بالمرور على الصورة من الجانب الأيسر العلوي الى الجانب الأيمن السفلي.

محازاة التتابع المتعدد : Multiple sequence alignment

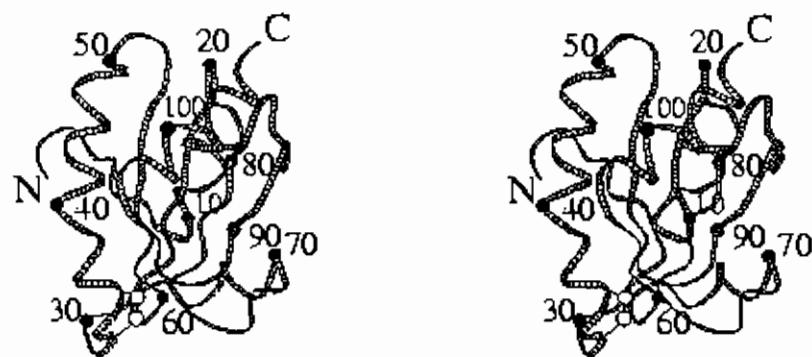
تكون نتائج الكشف عن العلاقات البعيدة بين التتابعات أكثر واقعية في حالة تعدد التتابعات. وأيضاً تعطى أدوات التنبؤ بالتركيب نتائج أفضل عندما تعتمد على محازاة تتابعات متعددة وذلك بالمقارنة بالتتابعات المنفردة. ولذلك يجب أن تحتوى محازاة التتابع المتعدد على توزيع من التتابعات قريبة وبعيدة الصلة.

الاستدلال التركيبى بواسطة محازاة التتابع المتعدد:

يمكن التعرف على الملامح التركيبية والوظيفية بواسطة المحازاة للتتابعات المتعددة من خلال موقع الخادم التالي:

<http://www.bio.cam.ac.uk/cgi-bin/seqlogo/logo.cgi>

ومثال ذلك التعرف على الملامح التركيبية لعدد 16 ثيوريدوكسينات (أنزيمات موجودة في كل الخلايا وتساهم في مدى واسع من العمليات الбиولوجية):



The structure of *E. coli* thioredoxin [2TRX] contains a central five-stranded β -sheet flanked on either side by α -helices. Residue numbers correspond to those in the multiple sequence alignment table. The N- and C-termini are also marked. Spheres indicate positions of the $C\alpha$ atoms of every tenth residue. The reactive disulphide bridge between Cys32 and Cys35 appears between the numberals 30 and 60.

Hiden Markov Models (HMMS) :

وهي نماذج تركيب حسابية لوصف طرز عائلات التتابعات المتماثلة. كما أنها تعتبر من الأدوات القوية للكشف عن القرابة البعيدة والتبؤ بطرز طى البروتين.

مصادر على الانترنت : Web Resources

<http://cse.ucsc.edu/research/compbio/sam.html>
<http://cse.ucsc.edu/research/compbio/HMM-apps/HMM-applications.html>
<http://www.sanger.ac.uk/Software/Pfam>.
<http://stash.mrc-lmb.cam.ac.uk/SUPERFAMILY/>

النشوء النوعي : Phylogeny

هناك العديد من الأمثلة للتطور في البروتينات والجينوم. ويفهد هذا المجال العمل على التوصل إلى العلاقات بين الأنواع والعشائر والأفراد والجينات وذلك باستخدام الخصائص الجزيئية.

أشجار القرابة الوراثية:

وتمثل الشجرة في علم الحاسوب شكلًا خاصًا يتكون من نقط nodes يتم توصيلها بعض عن طريق خطوط edges. والشجرة قد تكون rooted أو unrooted. والشكل الأخير لا يظهر النسب بينما في الشكل الأول ينحدر من كل نقطة أصلان ويسمى binary tree ويستخدم برنامج PERL لرسم الشجرة كما يلى:

```
drawtree.pl - PERL

program to draw binary trees.

#!/usr/bin/perl
#drawtree.pl -- draws binary trees (root at top)
#usage: echo '(A((BC)D)(EF))' | drawtree.pl > output.ps

print <; chop($tree); $_= reverse($tree); s/{}//g;

$x = 0; $y = 0;
while ($nd = chop()) {
    print "$x $y m ($nd) stringwidth pop -0.5 mul 0 rm ($nd)
show\n";
    $xx($nd) = $x; $x+=20; $yy($nd) = 10;
}

while ($tree =~ s/(?([A-Z])([A-Z]))?/ /) {
    print "n $xx($1) $yy($1) m\n";
    ($yy($1) > $yy($2)) || ($yy($1) = $yy($2)); $yy($1) += 20;
    print "$xx($1) $yy($1) l $xx($2) $yy($1) l $xx($2) $yy($2) l
s\n";
    $xx($1) = 0.5*($xx($1) + $xx($2));
}print "n $xx($tree) $yy($tree) m 0 20 rl s showpage\n";

$rx = 2*$x + 30; $yt = 2*$yy($tree) + 146;
print "%BBox: 40 95 $rx $yt\n";
```

مصادر على الانترنت لأدوات الوراثة العرقية :

<http://evolution.genetics.washington.edu/phylip/software.html>

الفصل الخامس

تركيب البروتين واكتشاف الدواء

يتضمن هذا الفصل من الكتاب تركيب البروتينات من حيث:

يستخدم تحليل hydrophobicity profile للتنبؤ بأماكن التقاف العناصر في التركيب الثانوي، الوحدات الظاهرية والمخفية، امتداد أجزاء الغشاء، وموقع الأنتيجين. وفيما يلى مثال لاستخدام برنامج PERL لرسم مايسى بـ The helical wheel التي تعتمد على دراسة تتبع الوحدات من حيث التبادل ما بين محب وكاره للماء وذلك فى

:protiens

ثبات وطى البروتين وتطبية

:Hydrophobicity

```
helwheel.pl - program to draw helical wheels.

#!/usr/bin/perl
#helwheel.pl -- draw helical wheel
#usage: echo DVAGHGQDILIRLFKSH | helwheel.prl > output.ps
# or      echo 20DVAGHGQDILIRLFKSH | helwheel.prl > output.ps
#           the numerical prefix sets the first residue number

# The output of this program is in PostScript (TM),
#           a general-purpose graphical language

# The next section prints a header for the PostScript file

print <;
chop();$_ =~ s/\s//g;                                # read line of input
carriage return and blanks                           # remove terminal

if ($_ =~ s/^(\d+)/)                                 # if input begins with
integer                                              # extract it as
($resno = $1);                                      # if not, set initial
initial residue number                               # residue number = 1
else ($resno = 1);

$radius = 50;                                         # initialize values
for radius,
$x = 0; $y = -50; $theta = -90;                      # x, y and angle theta
```

```

#   print light gray spiral arc as succession of line segments, 10
per residue

$npoints = 10*(length($_) - 1);
print "0.8 0.8 0.8 setrgbcolor\n";          #  set colour to light
gray
print "newpath\n";                         #  draw spiral arc
printf("%8.3f %8.3f moveto\n", $x, $y);
foreach $d (1 .. $npoints) {                #  10 points per
residue
    $theta += 10; $radius += 0.6;           #  increase radius and
theta
    $x = $radius*cos($theta*0.01747737);  #  calculate new value
of x
    $y = $radius*sin($theta*0.01747737); #  and y
    printf("%8.3f %8.3f lineto\n", $x, $y);
}
print "stroke\n";

#  print residues and residue numbers

$radius = 50;                                #  reinitialize values
for radius,
$x = 0; $y = -50; $theta = -90;               #  x, y and angle theta
print '0 setgray\n'                           #  set colour to black

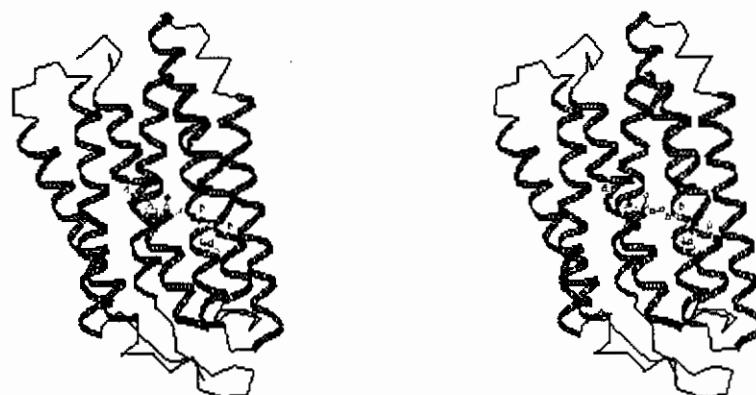
foreach (split ("", $_)) {                    #  loop over characters
from input line
    print "/$font($_) findfont";             #  set font appropriate
    print "20 scalefont setfont\n";          #  for this amino acid
    printf("%8.3f %8.3f moveto\n", $x, $y); #  move to current
point
    print " ($resno$_) stringwidth";        #  adjust position to
center residue
    print " pop -0.5 mul -7 rmoveto\n";     #  identification on
point on spiral
    print " ($resno$_) show\n";            #  print residue number
and id
    print "% $theta $resno$_\n";
    $theta += 100; $radius += 6;            #  set new values of
angle, radius
    $x = $radius*cos($theta*0.01747737); #  compute new values
of x
    $y = $radius*sin($theta*0.01747737); #  and y
    $resno++;                            #  increase residue
number
}

print "showpage\n";                          #  postscript signals
to
print "%&BoundingBox:";                   #  print
$x1 = 297.5 - 1.05*$radius;              #  x
$xr = 297.5 + 1.05*$radius;              #  and
$yb = 421. - 1.05*$radius;                #  y
$yt = 421. + 1.05*$radius;                #  limits
printf("%8.3f %8.3f %8.3f %8.3f\n", $x1, $xr, $yb, $yt);

print "showpage\n";
print "%&EOF\n";                         #  and wind up

```

المثال الثاني: التنبؤ بالتركيب اللولبي لبروتينات الأغشية، حيث أن العديد من بروتينات الأغشية تتركب من سبع أشكال لولبية متصلة مع بعضها بواسطة عقد كما هو الحال في **bacteriorhodopsin** :



Bacteriorhodopsin membrane from the bacterium *Halobacterium salinarum*. The ligand shown in ball-and-stick representation is the chromophore, retinal .

Web Resources : Transmembrane Helix Prediction :

TMHMM (A.Krogh and E. Sonnhammer)

Markov Model :

<http://www.cbs.dtu.dk/krogh/TMHMM/>

PHDhtm (B.Rost) :

<http://dodo.bioc.columbia.edu/predictprotein>

Membrane protein explorer (S. White) :

<http://blanco.biomol.uci.edu/mpex/>

Web Resources :

matrix Alignment) :

<http://www2.ebi.ac.uk/dali/>

Classifications of Protein Structure :

<http://www2.ebi.ac.uk/msd/Links/fold.shtml>.

<http://www.bioscience.org/urllists/protdb.htm>
<http://scop.mrc-lmb.cam.ac.uk/scop>

Protein Structure Prediction and modelling :

<http://cubic.bioc.columbia.edu/eva>

Homology Modelling :

SWISS-MODEL (automatic homology modelling) :

<http://www.expasy.ch/swissmod/SWISS-MODEL.html>

MODBASE, a database of comparative models of protein from complete genomes:

<http://guitar.rockefeller.edu/modbase/>

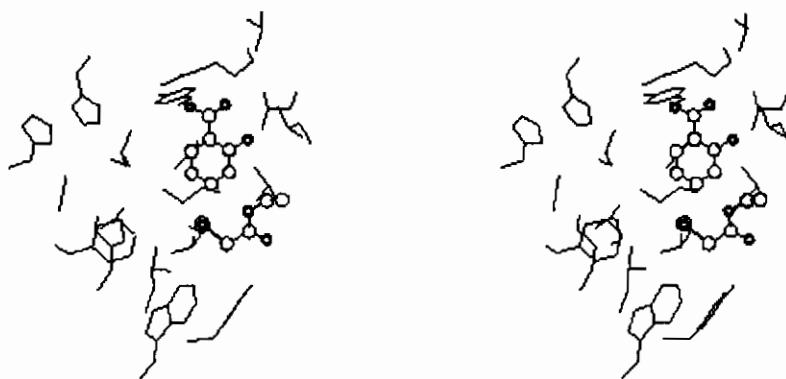
اكتشاف وتطوير الدواء:

تم استعراض الموصفات التي يجب توافرها في المركب الكيميائي المؤهلة لاستخدامه كدواء. وكذلك مرافق انتاج دواء جديد. واستخدام الكمبيوتر في حصر مركبات عديدة للوصول إلى مركب واحد مؤهل، ثم إجراء تحسين للمركب المرشح من خلال تحديد العلاقة الكمية بين التركيب والفعالية QSAR والتي تتيح طرق للتبؤ بالنشاط الدوائي لمجموعة من المركبات بواسطة العلاقة بين الملامع الجزيئية والنشاط الدوائي. وكذلك الاستعانة بمعلومات عن الجينوم.

تصميم الدواء بمساعدة الكمبيوتر:

مثال: تصميم مثبطات 2 prostaglandin cyclo-oxygenase. ومن المعروف أن مركب الأسبرين ومركبات أخرى من NSAID تربط اثنان من COX- COX-1 قريري الصلة تسمى prostaglandin cyclo-oxygenase

: 2



The binding site in COX-1 for an aspirin analog, 2- bromoacetoxybenzoic acid . The ligand has reacted with the protein, transferring the bromoacetyl group to the sidechain of serine 530 . The protein is shown in skeletalrepresentation . The aspirin analog is shown in ball-and-stick representation .

والمزيد من المعلومات يمكن الرجوع الى الموقع الالكتروني للكتاب:

<http://www.oup.com/uk/lesk/bioinf>

الخاتمة

استقراء الحاله الراهنه لتطبيقات البيومعلوماتيه تمكنا من استشراف أهمية مجال البيومعلوماتيه في المستقبل. فمن الواضح أن عمليات جمع البيانات ستستمر في الزيادة وبسرعة. كذلك التوجه نحو زيادة كفاءة وقدرة أجهزة الكمبيوتر من حيث التخزين، والتوزيع، وتحليل النتائج. وسوف يؤدي ابتكار طرق خوارزمية محسنة الى تحليل وتفسير المعلومات المتاحة لنا وتحويلها من مجرد صور بيانات الى معرفة ثم حكمة.

وسوف نصل الى الكتلة الحرجية عندما تصبح معرفتنا بالمتتابعات والترانكيب أكثر قربا من الاكمال، بمعنى جمع مجموعات غير منحازة من البيانات المتاحة عن أشكال الحياة المعاصرة. وسوف نتعرف على ذلك عندما يؤدي التعمق العشوائي في جينوم ما أو معرفة تركيب بروتين ما إلى تغيير شيئاً موجوداً بالفعل بدلاً من الكشف عن شيئاً جديداً. وبعد كل ذلك، تكون الطبيعة من نظام غير محدود الاحتمالات ولكن مع اختيارات لانهائيه.

ستصبح التطبيقات أكثر وضوحاً، ونضجاً وستمر بسرعة من مراحل البحث إلى الممارسات الصناعية والأكاديمية القياسية. ونقل بعض المعلومات البيولوجية عالية المستوى مثل برامج التطور أثناء فترة حياة الأفراد، وأنشطة العقل البشري ودخولها في عمليات معالجة البيانات، سوف يمكننا من الوصف الكمي والتحليل على مستوى الجزيئات وتفاعلها.

رقم الإيداع: ٢٠٠٦/٢١٩١
ISBN: 977-281-297-5

