

استخدام سلاسل ماركوف في التعرف على تعاقبات الحامض النووي DNA

أ.د. علي عبد الرحمن الزعكاك
عميد معهد الهندسة الوراثية - جامعة بغداد

أ.د. ضوية سلمان حسن
قسم الاحصاء - جامعة بغداد

زينب هاتف عباس - ماجستير بحوث عمليات

الملخص

ان للحامض النووي DNA اهمية بالغة لكونه حاملاً للمعلومات الوراثية. وبالتالي فان دراسة تعاقبات الحامض النووي DNA سوف يعطي انطباعاً عن الصفات الوراثية للكائن الحي. ولاهمية الموضوع ارتأينا تقديم بحث يتضمن التعرف على سلاسل الحامض النووي DNA وحساب الاحتمالات الانتقالية الشرطية لعناصر هذه السلاسل، وبناء مصفوفات احتمالية انتقالية من الرتبة الاولى والثانية والثالثة والرابعة والخامسة وثم التجريب على اربعة تعاقبات لسلسلة الدنا لهرمون النمو البشري. وتم الاعتماد على نتائج الطرق البيولوجية ومميزات الجين في تعاقبات DNA للمفاضلة بين نتائج الطرق الثلاث التي ترشح السلسلة ذات الاحتمالية الاكبر لكي تمثل الجين.

وتم عمل برنامج تشفير وترجمة للنسق لثلاث نظم قراءة، بهدف المقارنة بين تعاقبات هرمون النمو البشري وسلاسل اخرى.

Abstract

The DNA has great importance because it is a hereditary information carrier. In view of the importance of markoves chains in explaining and analyzing many of the phenomena through succession, we apply it in our research to obtain the conditional probabilities of chains elements, for its great importance in finding the hereditary genetics from DNA compositions.

Markov chains has been implemented for the probable alignment of the first, second, third, fourth, and fifth orders.

A program was created to code and translate the three models of the ORF for DNA succession and the chains for the three program was written by visual basic language to carry out these operations and to yield sequence alignment between human and growth hormone gene and other chains.

The program implemented DNA chains in which the nucleotide number is less than 3000 bases exemplified by the human growths hormone, mouse, and chicken growth hormone.

المقدمة

بعد التطور المذهل الذي شهده علم بحوث العمليات والتأثير المتزايد له في الكثير من المجالات، أصبحت تطبيقاته واسعة ومتنوعة ولا سيما نتيجة استخدام الحاسوب وقد استخدم حقل OR في مجال الهندسة الوراثية، حيث استخدم الباحثين مواضيع مختلفة من OR مثلاً البرمجة الديناميكية وسلاسل ماركوف في بحث التعاقبات الجينية المختلفة لسلسلة الجينات المكونة للحامض النووي DNA، لما لهذه التكرارات من أهمية في إرجاع نقاط التشابه والاختلافات إلى مصادرها الأصلية وكذلك تكوين الشفرات الوراثية ودورها في عملية تكوين الأحماض الأمينية وعملية استنساخها إلى البروتين، ودور الحامض النووي في ذلك. تعتبر الاحتمالات الانتقالية الشرطية بعض الأدبيات الخاصة بسلاسل ماركوف، وتعتمد هذه الاحتمالات جنباً إلى جنب مع المعلومات الحياتية وكذلك مع نظم القراءة المفتوحة (Open Reading Frames) بهدف تفسير وتحليل سلاسل الحامض النووي وإيجاد مواقع التشابه بين سلسلتين وتسلسل النيوكليوتيدات في المناطق المتشابهة بين سلسلتين، ولذلك ارتأينا البحث في هذا الموضوع تحقيقاً للهدف التالي.

هدف البحث

يهدف البحث إلى اختيار أفضل الطرق المعتمدة على الاحتمالات الانتقالية لمصفوفة ماركوف في ترشيح السلسلة الجينية من السلاسل التي تبدأ بشفرة البداية (Start code) وتنتهي بشفرة النهاية (Stop code) والمتكونة من انساق النظم المفتوحة (ORF) لسلسلة الحامض النووي، وذلك من خلال تقدير الاحتمالات الانتقالية لسلاسل ماركوف وتقدير الاحتمالات الانتقالية بطريقة ماركوف التخمينية لأربعة سلاسل من سلاسل DNA لهرمون النمو البشري واختيار أفضل التقديرات. وتم إعداد برنامج بلغة فيجوال بيسك وهذا البرنامج هو خطوة أولية في عالم البرامج الجاهزة يساعد الباحثين البيولوجيين ويقوم بعملية تفسير وترجمة لصيغ القراءة المفتوحة للحامض النووي DNA وكذلك عملية المقارنة بين سلسلة النمو البشري مع سلسلة أخرى لهرمون النمو لحياء أخرى مثل الدجاج والفئران.

الجانب النظري

تتكون سلسلة الحامض النووي DNA من تكرار متسلسل لأربعة من القواعد الناتروجينية (A, T, G, C) وهي الأدينين (A) والثايمين (T) والسيتوسين (C) والكوانين (G). ويكون ارتباط القواعد الناتروجينية بواسطة أواصر هيدروجينية (Hydrogen Bonds) إذ يتصل الأدينين (A) لأحد السلسلتين مع الثايمين (T) للسلسلة الأخرى بأصرتين، في حين يتصل السيتوسين (C) في إحدى السلسلتين مع الكوانين (G) للسلسلة الأخرى بثلاث أواصر هيدروجينية، أي أن الأدينين (A) هو يقابل الثايمين (T) وأن الكوانين (G) يقابل السيتوسين (C) أينما ترد هذه في متسلسلة نيوكليوتيدات الحامض النووي DNA. وتعد هذه أهم الدلائل التي حولت الانتظار إلى الحامض الدنا باعتباره المادة الوراثية، بعد أن كان يعتقد أن كمية البروتين في الخلية تزداد بصورة مستمرة بينما كمية الدنا فهي ثابتة في الخلية تقريباً، ولكن من أهم صفات الدنا هي قدرة الدنا على التضاعف إذ تعتمد عملية التضاعف اعتماداً رئيسياً على طريقة اتصال القواعد النتروجينية مع بعضها في الحلزون المزدوج*، كما ذكرنا أن سلسلة الحامض النووي DNA تتكون من تكرار متسلسل لأربعة من القواعد الناتروجينية (A, T, G, C) والاختلاف الحاصل في

لاخر، اي ان الموديل الذي يمثل ترتيب هذه القواعد الاربعة والانتقال من نيوكليد الى الاخر يتمثل بالزمن، وافضل ما يعبر عن هذا الموديل بالعمليات التصادفية، والتي تمثل على شكل سلاسل ماركوف، لكي يسهل علينا حساب تكرارات القواعد لكل جين، وحساب الاحتمالات الانتقالية للانتقال من نيوكليد الى اخر، تكون بطريقة الامكان الاعظم.

تستخدم نماذج ماركوف التخمينية Interpolated Markov Models (IMM)

للزيادة في دقة المعلومات التي نريد الحصول عليها في نماذج ماركوف ذات الرتب العالية اذ ان هناك عدد كبير من الثوابت للرتب العالية (ان عدد ثوابت الرتبة يتناسب طردياً مع رتبة الموديل) وتعتمد هذه السلاسل على الوزن التخميني ويتم بواسطة IMM حساب القيمة المتوقعة التخمينية لكل سلسلة جزئية من السلسلة لكل عنصر من عناصر السلسلة كعلاقة رياضية خطية من الاحتمالات الانتقالية لرتب مختلفة من سلاسل ماركوف اذ ان :

$$E_X(X_i | X_{i-1}, X_{i-2}, \dots, X_{i-k}) = \sum \lambda_{j,i} \Pr(X_i | X_{i-1}, X_{i-2}, \dots, X_{i-k}) \quad (1)$$

حيث ان :

$$\lambda_{j,i} \Pr(X_i | X_{i-1}, X_{i-2}, \dots, X_{i-k})$$

ثابت يمثل الوزن لقيم الاحتمالات الانتقالية لموديل من الرتبة j_{th} .

ان الهدف من هذا الموديل، هو استعمال الاوزان في الموديلات ذات الرتب العالية اذ ان الموديل من الرتبة K_{th} يكون عدد الثوابت كبيراً فيه وتكون السلسلة طويلة لذلك فان تكراره يكون قليلاً وبالتالي وزن هذا الحد يكون اكبر مما يعطي فرصة اكبر للرتب العالية. تستعمل الاحتمالات من الرتب الدنيا التي تمتلك حدوث عالٍ (تكرار عالي) للمساعدة في تصحيح الاخطاء التي تقع عند تقدير القيمة الاحتمالية الانتقالية للرتب العليا من موديلات ماركوف. لذلك فان استعمال اعداد مختلفة من الثوابت يمكن السيطرة على حالات مختلفة لحساب الاحتمالات الانتقالية. وهناك معايير مختلفة لحساب قيم الثوابت او الاوزان التقديرية لموديل ماركوف منها طريقة ماركوف التخمينية IMM_k وطريقة X^2 والطريقة الافتراضية وغيرها (وقد فصلت هذه الطرائق في المصدر 4)* من المصادر العربية المشار اليها في نهاية البحث.

اضافة للطرق السابقة يوجد معيار اخر لحساب قيمة الوزن λ_i للسلسلة الجزئية في موديلات ماركوف التخمينية فتعتمد على طريقة افتراضية تتمثل باعطاء اوزان متساوية ($\sum \lambda_i = 1$) لجميع الرتب.

$$E_X(X_i | X_{i-1}, X_{i-2}, \dots, X_{i-n}) = \lambda_0 P(X_i) + \lambda_1 P(X_i | X_{i-1}) + \lambda_n P(X_i | X_{i-1}, \dots, X_{i-n}) \quad (2)$$

فعلى سبيل المثال لو كان لدينا موديل من الرتبة الرابعة ونريد ايجاد القيمة الاحتمالية التخمينية له، فان الوزن يقسم بالتساوي على عدد الحدود، لو كان عندنا السلسلة الجزئية

$$(atca) \text{ فان احتمال ان تأتي القاعدة } g \text{ بعد السلسلة الجزئية اي ان } |Pr(g|atca)$$

$$IMM_4 = \lambda_0 p(a) + \lambda_1 p(c|a) + \lambda_2 p(t|ca) + \lambda_3 p(a|tca) + \lambda_4 p(g|atca)$$

$$\lambda_0 = \lambda_1 = \lambda_2 = \lambda_3 = \lambda_4 = 1/5$$

ولكي نمثل سلسلة DNA بطريقة ماركوف نستخرج الاحتمال الانتقالي لكل قاعدة نيتروجينية وذلك بإيجاد التوقع الاحتمالي من الدرجة الاولى فمثلاً احتمال ان يأتي الادلين في الموقع الثالث من الشفرة فقط يعتمد على وجود الكوانيين في الموقع الثاني من الشفرة، ويعني ذلك رياضياً

$$Pr(a_3|g_2)$$

ولإيجاد القيمة الاحتمالية للسلاسل الجزئية المكونة لسلسلة الدنا (S) نطبق التعريف التالي

$$\begin{aligned} Pr(S) &= Pr(X_L, X_{L-1}, X_{L-2}, \dots, X_1) \\ &= Pr(X_L | X_{L-1}, X_{L-2}, \dots, X_1) Pr(X_{L-1} | X_{L-2}, \dots, X_1) Pr(X_1) \\ &= Pr(X_L | X_{L-1}, X_{L-2}) Pr(X_{L-1} | X_{L-2}, X_{L-3}) \dots Pr(X_3 | X_2, X_1) Pr(X_2 | X_1) Pr(X_1) \end{aligned} \quad (4)$$

ان مخرجات هذه السلسلة تعتمد على مجموعة الاحتمالات الانتقالية لسلسلة ماركوف .

الجانب التطبيقي

تم اعتماد هرمون النمو البشري كاساس في التطبيق العملي وقد اخذت امثلة من بدائية النواة بالاعتماد على تعاقبات (الذيفانات المعوية) Enterotoxins المنتجة من قبل بكتريا القولون الشيكلا والسالمونيلا وكذلك تم اعتماد متسلسلات هرمون النمو للدجاج، البقر والفئران لغرض التطبيق والمقارنة مع هرمون النمو البشري الذي تفرزه الغدة النخامية متوجهاً الى بقية الاعضاء معطياً الاشارة لافراز عوامل النمو الاخرى لتبدأ دورها في حث خلايا الجسم على الانقسام والتكاثر والتمايز.

ومن المعلوم ان الذيفانات المعوية هي انزيمات (سموم) تفرزها انواع عديدة من بكتريا مثل (E.coli, Shiglla, Salmonella) داخل الامعاء وهذه السموم المفرزة من البكتريا تمتصها الخلايا المبطنه للامعاء ، ولذا يكون تأثير هذه السموم موضعي وبعيد عن مصدر الافراز وهذا هو سبب انتقال السموم بواسطة الدم . وتختلف الذيفانات في تركيبها باختلاف الجينات المشفرة لها ولذلك اصبح من الضروري دراسة هذه الجينات لمعرفة الاساس الجيني للأمراض البكتيرية .

تضمن التطبيق العملي للبحث اولا كتابة برنامج بلغة في جوال بيسك يقوم بتشفير Coding لمتسلسلة الحامض النووي DNA وكذلك عملية ترجمة Translation للبروتين لمتسلسلة

DNA مع انساق القراءة المفتوحة ORF ، وكذلك مقارنة السلاسل (Sequence alignment) لسلسلتين من الحامض النووي الاولى لهرمون النمو البشري والاخرى لهرمون النمو من الحيوانات كالابقار والدجاج والفئران . وايجاد مناطق التشابه بين السلسلتين ولتمييز اكثر الكائنات تشابهاً مع الهرمون النمو البشري وتضمن التطبيق ثانياً حساب الاحتمالات الانتقالية الشرطية من سلسلة الحامض النووي DNA حيث تم تطبيق سلاسل ماركوف وبناء مصفوفة الاحتمالات الانتقالية من الرتبة الاولى والثانية والثالثة والرابعة والخامسة وفق خوارزمية اعدت لهذا الغرض ، فضلاً عن برنامج تشفير وترجمة لكل من متسلسلات الحامض النووي . وقد اضيفت للبرنامج واجهات مرئية تسهل بناء واجهة للبرنامج تتيح للباحث سهولة الاستعمال والذي يقوم بعمليتين الاولى تتمثل بعملية تشفير (Coding) والترجمة (Translation) لانساق (ORF) لـ DNA ، وذلك لتحديد مناطق التشابه وتسلسل الشفرات بين السلسلتين ويتم تحديدها من قبل المستخدم من السلاسل التي حمل بها البرنامج وقد تضمن برنامج Genetics الذي تم اعداده في هذا البحث سلاسل جينية لهرمون النمو لعدة كائنات حقيقية النواة مع السلاسل (الذيفانات) بدائية النواة والتي عدد القواعد الناتروجينية بها اقل من 3000 قاعدة ناتروجينية ، وقد حمل البرنامج بـ 22

وفي التطبيق العملي، حسبت الاحتمالات الانتقالية لمصفوفة ماركوف للتراكيب الجينية لسلاسل DNA لكل قاعدة نروجينية او لكل مقطع جزئي من السلسلة بطريقة الامكان الاعظم وتتمثل الرتبة Zero القيم الابتدائية للقواعد النانروجينية في السلسلة، اي مدى احتمالية وجود القاعدة النانروجينية في السلسلة لهرمون النمو البشري ووجد ان:

$$P_0(a) = 0.20281$$

$$P_0(c) = 0.26506$$

$$P_0(g) = 0.30723$$

$$P_0(t) = 0.22490$$

$$P(S) = P(t) * p(t) P(c) P(t) \dots P(a)P(g)P(g)$$

ووجد ان القيمة الاحتمالية الابتدائية لطريقة ماركوف الثابتة $FMM_0 = 7.98385 E^{-298}$

اما الرتبة الاولى والتي تتمثل باعتماد القاعدة النروجينية المراد ايجاد الاحتمالات الانتقالية لها على القاعدة التي تسبقها والمصفوفة التالية تمثل الاحتمالات الانتقالية لهرمون النمو من الرتبة الاولى:

	A	T	C	G
A	0.28712	0.11882	0.12872	0.46534
T	0.10715	0.26786	0.28571	0.33928
C	0.20455	0.34848	0.37128	0.07575
G	0.21568	0.15688	0.24836	0.37908

وبتطبيق القانون

$$Pr(S) = P(t)P(t | t) P(t | c) P(c | c) P(c | t) \dots P(t|g)$$

نحصل على القيمة الاحتمالية الكلية للسلسلة من الرتبة الاولى لطريقة ماركوف ذو الرتبة الثانية التي تساوي $9.9727E^{-280}$

اما الرتبة الثانية والتي تتمثل بمدى الاحتمال تاتي بها القاعدة النروجينية بعد القاعدتين التي تسبقها والتي تتمثل مثلاً (TT) وهكذا تم حساب الاحتمال الكلي لسلسلة هرمون النمو البشري باعتماد الاحتمالات الانتقالية من الرتبة الاولى والثانية والثالثة والرابعة والخامسة لطريقة (FMM) واوضحت جميع هذه النتائج في المصدر رقم 4 من المصادر العربية. وكذلك اعطيت نتائج المقارنة بين طريقة ماركوف التخمينية المستندة على الاوزان الثابتة وتلك المستندة على الاوزان المستخرجة بطريقة كاي سكوير كما هو مفصل في الرسالة.

الاستنتاجات

1. عند تطبيق برنامج Genetics وجد ان التركيب الجيني لهرمون النمو البشري يشابه الى حد كبير التركيب الجيني لهرمون النمو البشري للفئران.
2. وبتطبيق طرق ماركوف على السلاسل الجينية لوحظ انه كلما زادت رتبة الموديل (كلما كبرت السلسلة الجزئية) كلما زادت القيمة الاحتمالية للسلسلة مما يعني ان الرتب العليا هنا الخامسة هي الافضل في التطبيقات البيولوجية .
3. من التطبيقات العلمي للبرنامج نلاحظ ان عملية المقارنة (المطابقة) بين سلسلتين وعلى اساس حامضين امينيين (اي ستة من القواعد النيتروجينية) بان نسبة عالية من التشابه بين هرمون النمو البشري وسلاسل هرمون النمو الفئران وكذلك لسلاسل الـ E.coli المنتجة من قبل بكتيريا E.coli ، اما عندما تستند على ثلاث حوامض امينية فاكثرت فان عملية التشابه تقل كلما ازداد عدد الشفرات المستندة في اساس عملية التشابه .

النوصيات

1. ان التوسع في البرامج التطبيقية للتركيب الجينية بلغات متطورة لكي تكون سهلة المنال بالنسبة للباحث البيولوجي ولكون اكثر البرامج التطبيقية تتناول تطبيقات على سلاسل DNA من عمل الباحثين اجانب وهي ذات كلفة عالية.
2. نوصي بتوسع البرنامج لكي يلام تطبيقات هندسية اعتماداً على الاحماض الامينية صعوداً نحو اكتشاف الدنا المشفر لها.

المصادر العربية

1. البكري، غالب حمزة (1991)، مبادئ الهندسة الوراثية كتاب منشور عن وزارة التعليم العالي والبحث العلمي - جامعة البصرة - كلية العلوم .
2. الزبيدي، عمار الكوتي ناصر (2004) التحليل الطيفي لمتسلسلة الحامض النووي DNA - اطروحة دكتوراه مقدمة الى كلية الادارة والاقتصاد - الجامعة المستنصرية .
3. الشخيلي، فؤاد عبد الرزاق (2001)، "تنفيذ وتكوين النموذج قواعد معلومات الاستنباطية المستندة على جزيئات الحامض النووي DNA اطروحة دكتوراه مقدمة الى قسم علوم الحاسبات الجامعة التكنولوجية.
4. الركابي، زينب هاتف عباس (2005)، استخدام سلاسل ماركوف في التعرف على تعاقبات الحامض النووي DNA - رسالة ماجستير مقدمة الى قسم الاحصاء - جامعة بغداد.

المصادر الانكليزية

1. Burge , C.L . Karlin , S.(1997) " Prediction of Complete Gene Structures in Human Genomic DNA " J . Mol.Bio. Vol.268 , PP 78 – 94.
2. Delmas , J (2002) " An Introduction to DNA Analysis using Statistical Tolls" Bioinformatics , Vol.33, June . PP – 301-306 .
3. Irving Robent W.(2004) " Plagiarism and Collusion Delection using The Simth – Waterman Algorithm.