

استخدام سلاسل ماركوف المخفية في تمييز حروف العلة في اللغة الإنجليزية

رنا بشار حسين*

د.حسن محمد الياس*

الملخص

تمت في هذا البحث دراسة نماذج ماركوف المخفية التي هي مجموعة منتهية من الحالات ، كل حالة تقرن بتوزيع احتمالي ، أما الانتقالات ما بين الحالات فتُحدَّد بوساطة مجموعة من الاحتمالات وتُسمى الاحتمالات الانتقالية ، وبشكل عام ، تتولد الحالة الناتجة (المشاهدة) طبقاً لتوزيع الاحتمالية المقترنة ، إذ توجد احتمالية ناتجة فقط ولا توجد حالة ظاهرة يمكن أن تُشاهد ولهاذا فإن الحالات تكون مخفية .

تم عرض المسائل الأساسية لـنماذج ماركوف المخفية (Hidden Markov Models) وهي :

حساب الإمكان لمتسلسلة المشاهدات (O) عندما يكون المعطى هو النموذج

$\lambda = (A, B, \pi)$ ، أي إيجاد $P(O|\lambda)$ ، حيث أن :

A = مصفوفة احتمالات انتقال الحالة .

B = مصفوفة احتمالية المشاهدات .

π = توزيع الحالة الابتدائية .

- اختيار متسلسلة الحالة المثلث لعملية ماركوف المخفية .

- إيجاد النموذج $(\lambda = (A, B, \pi))$ الذي يكون فيه الإمكان أعظم ما يمكن ،

أي إعادة تقدير معلمات النموذج لتعظيم $P(O|\lambda)$.

* استاذ مساعد/ قسم الاحصاء/ كلية علوم الحاسوبات والرياضيات/ جامعة الموصل

** مدرس مساعد/ كلية الادارة والاقتصاد/ جامعة الموصل

فضلاً عن حلولها .

Using Hidden Markov Chains in Recognition of Vowel Letters in English Language

ABSTRACT

This study deals with hidden Markov models . These models consist of sets of finite states , each one of them is associated with a probability distribution . The transition among the states is governed by a set of probabilities namely “ Transition probabilities ” . In general , the final observation produced according to the associated probability , where there is only probability production instead of a clear visible states . Therefore , these states are described as hidden

The basic problems for hidden Markov models (HMMs) are :

- The probability account for the observation sequence (O) when the model is given $\lambda = (A, B, \pi)$, i.e. $P(O|\lambda)$ Where :
 - A = The state transition probabilities .
 - B = The observation probability matrix .
 - π = The initial state distribution .
- Choosing the optimal state of the sequence for hidden Markov process.
- Finding the model $\lambda = (A, B, \pi)$ which has the greatest probability , i.e. re-estimating the model to maximiz $P(O|\lambda)$. in addition to its results .

- مقدمة 1

هناك بعض الاختيارات الممكنة حول أي نوع من نماذج الإشارة هو المستخدم لتمييز خواص الإشارة ، وبشكل موسع استطاع العلماء تقسيم أنواع نماذج الإشارة إلى : نماذج التحديد والنماذج الإحصائية ، إذ إن نماذج التحديد (بشكل عام) تستخدم بعض الخواص المحددة المعروفة للإشارة ، مثلًا تمثل موجة الجيب ، وفي هذه الحالة يكون التحديد لنموذج الإشارة (بشكل عام) واضحًا ومبشرًا ، وهذا مطلوب في تحديد (أو تقدير) قيم المعلومات لنموذج الإشارة (مثل : المدى ، التردد ، شكل (أو صورة) موجة الجيب) . أما الصنف الثاني لنماذج الإشارة فهو مجموعة

من النماذج الإحصائية التي تُستخدم فقط لتمييز الخواص الإحصائية للإشارة ، ومن الأمثلة على هذه النماذج ، العمليات الكاوسيّة ، عمليات بواسون وعمليات ماركوف وعمليات ماركوف المخفية ... الخ .

تُعرف عملية ماركوف المخفية على أنها عملية تصادفية مخفية مركبة وذلك لأنها عملية ضمنية لا يمكن مشاهدتها ، ولكن يمكن مشاهدتها من خلال عملية تصادفية أخرى إذ إن الأخيرة تعطي متسلسلة من المشاهدات ، فهي عملية مزدوجة ذات فضاء حالة منتهي مع عملية ماركوفية مخفية تحكم باختيار الحالات . (Rabiner,1989)

درست (HMMs) ، التي هي من النماذج التصادفية ، في أواخر السبعينيات وبداية الثمانينيات من القرن العشرين وقد بدت المسألة صعبة جداً في بادئ الأمر ولكن بمرور الزمن ونتيجةً للبحوث والدراسات التي جرت حول الموضوع فقد تم تسهيله نظرياً وتطبيقياً في مجالات كثيرة من مجالات الحياة .

في عام (1989) قدم الباحث (Rabiner) بحثاً موسعاً حول (HMMs) حاول من خلاله (وبشكل دقيق ومنظّم) استعراض الجوانب النظرية لهذا النوع من الصياغة الإحصائية وإظهار كيفية تطبيقها في مسائل تمييز الكلام ، وقد عدّ هذا البحث المصدر الأساسي للعديد من البحوث الأخرى المختصة بنموذج ماركوف المخفية (Rabiner , 1989).

في عام (1999) ألقى (Parker) محاضرة بعنوان (ملف نماذج ماركوف المخفية) تضمنت المقدمة لـ(HMMs) وكيفية بنائها (Parker , 1999) .

كذلك في عام (2001) قدم (Ellis) بحثاً بعنوان (تمييز المتسلسلة) أوضح فيه كيفية تمييز المتسلسلات الإحصائية فضلاً عن نماذج ماركوف المخفية وحالاتها وطرائق حسابها . (Ellis , 2001)

كذلك في عام (2003) قام (Zhai) بتقديم بحثٍ حول الملاحظات المختصرة والمفيدة جداً في نماذج ماركوف المخفية (Zhai , 2003) .

كذلك في عام (2003) قدم (Stamp) دراسة بعنوان (مقدمة الكشف عن نماذج ماركوف المخفية) ، إذ إنه من خلال مثال بسيط عن درجات الحرارة ، أعطى فكرة موجزة حول مفهوم نماذج ماركوف المخفية وحالاتها المخفية ومسائلها الأساسية وطرائق حلها فضلاً عن طريقة البرمجة الحركية وكيفية تقييس (Scaling) نموذج ماركوف المخفي (Stamp, 2003).

(2) هدف الرسالة :

تهدف هذه الرسالة إلى عرض النظرية الأساسية لـ(HMMs) والتي تعود لـ(L.E. Baum) وكذلك التعرف على أهم المسائل المتعلقة بها فضلاً عن وصف بعض التطبيقات حول النظرية ، وتطبيقها على التمييز بين الحروف الصحيحة والعلة في اللغة الإنجليزية .

(3) العملية التصادفية (Stochastic Process) :

إن أية ظاهرة حقيقة تجري في حيز المعلومة المدروسة (كالزمن مثلاً) هي عملية تصادفية إذا كانت حالات تلك الظاهرة في أي جزء من حيزها (في أي وقت مثلاً) تمثل نتائج تجربة عشوائية تخضع لقوانين الاحتمالات ، هذا وتعرف العملية التصادفية أيضاً بالعملية العشوائية (Random Process) أو عملية الفرصة (Chance Process) .

تعريف: العملية التصادفية $\{X(t), t \in T\}$ هي العملية المكونة من خلال قيم مختلفة تأخذها متغيرات عشوائية معينة ، معرفة على تجربة ما ، عند قيم مختلفة من فضاء المعلومة المدروسة (عند أزمان مختلفة مثلاً) حيث إن (T) تمثل مجموعة المعلمات وتشير إلى فضاء المعلومة (Parameter Space) .

(4) فضاء الحالة : (The State Space)

تعريف : وهو مجموعة من القيم المتعلقة بـ $X(t)$.

ويكون فضاء الحالة متقطعاً (Discrete) إذا احتوى على نقاط منتهية أو نقاط غير منتهية قابلة للعد ، أما في الحالات الأخرى فهو مستمر (Continuous) . (Cox & Miller , 1965 , P.14)

(5) سلاسل ماركوف (Markov Chains)

معظم النظم الشائعة الاستخدام في التطبيقات العملية تتمتع بخاصية كون أن حالة الظاهر قيد التحليل في الزمن الحاضر والزمن الماضي هي التي تحدد حالتها في المستقبل ، ولربما قد تدخل في ذلك عوامل أخرى وذلك حسب المسألة الم دروسه .

أما ما يخصنا فهو تلك النظم والظواهر التي تتميز بخاصية أنه إذا علمت حالة الظاهرة في الزمن الماضي ، فإنه سوف لن يكون هناك أي تأثير لحالات الظاهرة في الزمن الماضي على ما سيجري لها في المستقبل ، وتلك النظم التي تمتلك هذه الخاصية تُعرف بسلاسل ماركوف ، وإن الخاصية نفسها تُدعى بالخاصية الماركوفية (Markovian property) (الربيعي وعبد، 2000 ، ص 15) .

(6) المصفوفة الاحتمالية الانتقالية :

(The Transition Probability Matrix)

إن المصفوفة العشوائية (التصادفية) هي مصفوفة ذات عناصر عشوائية(غير سالبة) منتهية أو غير منتهية بحيث إن مجموع عناصر كل صف يساوي (1) ، فإذا كانت المصفوفتان $[a_{ij}]$ و $[b_{ij}] = B$ تصادفيتين فإن المصفوفة الناتجة عن حاصل ضربهما هي أيضًا مصفوفة تصادفية . (Srinivasan & Mehata , 1976 , P.35)

أما $p(i,j)$ فهي تمثل احتمالية الانتقال من الحالة (i) في الخطوة (n) إلى الحالة (j) في الخطوة (n+1) حيث يتم وضع العناصر $p(i,j)$ (كل $i, j \in E$) على شكل مصفوفة مربعة مثلاً (P) وبافتراض أن (E) هي $\{0, 1, 2, \dots\}$ ، فإنه يمكن كتابة المصفوفة (P) بالشكل الآتي :

$$P = \begin{bmatrix} p(0,0) & p(0,1) & p(0,2) & \cdots & p(0,N) \\ p(1,0) & p(1,1) & p(1,2) & \cdots & p(1,N) \\ p(2,0) & p(2,1) & p(2,2) & \cdots & p(2,N) \\ \vdots & \vdots & \vdots & & \ddots \\ p(N,0) & p(N,1) & p(N,2) & & p(N,N) \end{bmatrix}$$

تعريف : يُقال للمصفوفة المربعة (P) (المعرفة أعلاه) بأنها مصفوفة ماركوف (أو مصفوفة الانتقال) الممثلة للعملية $\{X_n, n \in N\}$ ، على فضاء الحالة ، إذا تحقق الشرطان الآتيان (الربيعي وعبد، 2000، ص17) :

1. لكل قيم $(i, j \in E)$ تكون $p(i, j) \geq 0$.
2. لكل قيم $(i \in E)$ يكون $\sum_{j \in E} p(i, j) = 1$.

(7) نماذج ماركوف المخفية :

نماذج ماركوف المخفية هي مجموعة منتهية من الحالات كل حالة تقترن بتوزيع احتمالي ، إما الانتقالات ما بين الحالات فتحدد بوساطة مجموعة من الاحتمالات وتسمى الاحتمالات الانتقالية . بشكل عام ، تتولد الحالة الناتجة (أي المشاهدة) طبقاً لتوزيع الاحتمالية المقترنة ، حيث توجد احتمالية ناتجة فقط ولا توجد حالة ظاهرة يمكن أن تُشاهد ، ولهذا فإن الحالات تكون مخفية ؛ هذا هو معنى نماذج ماركوف المخفية بشكل عام (Rabiner , 1989) .

وهناك تعاريف لمفهوم نماذج ماركوف المخفية منها :

تعريف: وهي تمثل متسلسلات تصادفية (كما في سلاسل ماركوف) حيث إن الحالات لا تُشاهد بشكل مباشر ولكنها تقترن بدالة كثافة احتمالية (pdf) ، وبشكل أوضح فإن متسلسلة الحالة $\{Q = \{q_n\}$ (أي Q) متسلسلة الحالات المخفية) لا يمكن مشاهتها ولكن المشاهدات (O) تعتمد على (Q) ، أي $P(O | Q)$ (Ellis , 2001)

تُعد نماذج ماركوف المخفية إحدى الوسائل المفيدة لدراسة النماذج الاحتمالية في السلسل الزمنية، إذ إن معلومات (HMMs) حول الماضي تُنقل على شكل متغير متقطع منفرد (وهي تمثل الحالة المخفية) .

إن نماذج ماركوف المخفية هي نماذج إحصائية تُستخدم لنمذجة البيانات حيث إنها تُستخدم وبنجاح في العديد من المجالات منها تمييز وفهم الكلام وسيطرة الرجل الآلي (Zhai , 2003) .

في الآونة الأخيرة ، حازت (HMMs) على اهتمام كبير في مجتمع Bioinformatic (أي مجتمع المعلوماتية الحياتية) ، إذ إنها تُستخدم في حل المسائل الخاصة بتبني التركيب الثنائي البروتيني (Protein Secondary Structure Prediction) وإيجاد الجينة ، وتصنيف عائلة البروتين وتشكيل خرائط ارتباط الجينات لعلم الوراثة وخرائط فيزيائية (Parker , 1999) .

(8) عناصر نماذج ماركوف المخفية : (Elements of HMMs)

ويمكن تلخيص عناصر (HMMs) بالآتي :

T = طول متسلسلة المشاهدات .

N = عدد الحالات المخفية في النموذج .

M = عدد رموز المشاهدات .

$\{q_0, q_1, \dots, q_{N-1}\} = Q$ = الحالات لعملية ماركوف (أي الحالات المخفية) .

$\{0, 1, \dots, M-1\} = V$ = مجموعة رموز المشاهدات .

A = مصفوفة احتمالات انتقال الحالة .

B = مصفوفة احتمالية رابطة بين الحالات المخفية والمشاهدات .

π = متجه توزيع الحالة الابتدائية .

$\{O_0, O_1, \dots, O_{T-1}\} = O$ = متسلسلة المشاهدات .

وللهولة يمكن استخدام العبارة المركبة $(A, B, \pi) = \lambda$ للإشارة إلى مجموعة معلمات النموذج (Rabiner , 1989) .

(9) أنواع نماذج ماركوف المخفية (Types of HMMs)

يمكن تصنيف (HMMs) إلى نوعين وذلك حسب الانتقالات بين حالاتها وكما يأتي :

1. النموذج الثبوتي (Ergodic Model) : وهو النموذج الذي تكون فيه كل الحالات انتقالية.

2. نموذج الأيسر-الأيمن (Left-Right Model) : وهو النموذج الذي تكون فيه بعض الحالات انتقالية ، بحيث إن :

$$a_{ij} = 0 \quad , \quad \forall j < i$$

أي أنها مصفوفة مثلية علية ، وهذا النوع من النماذج يستخدم وبشكل واسع في نمذجة متسلسلات الإشارات (Rabiner , 1989).

(10) المسائل الأساسية لنماذج ماركوف المخفية :

(The Basic Problems for HMMs)

المسألة (1) :

إذا كان المعطى هو النموذج $(A, B, \pi) = \lambda$ ومتسلسلة المشاهدات $O = O_1 O_2 \dots O_T$ ، أوجد $P(O | \lambda)$ ، أي تحديد الإمكان لمتسلسلة المشاهدات (O) عندما يكون المعطى هو النموذج .

المسألة (2) :

إذا كان المعطى هو النموذج $(A, B, \pi) = \lambda$ ومتسلسلة المشاهدات $O = O_1 O_2 \dots O_T$ ، أوجد متسلسلة الحالة المثلثى (The Optimal State Sequence) لعملية ماركوف المخفية ، والتي تمثل أفضل توضيح للمشاهدات .

المسألة (3) :

إذا كان المعطى هو متسلسلة المشاهدات $O = O_1 \ O_2 \ ... \ O_T$ والأبعاد (N) و (M) ، أوجد النموذج $P(O | \lambda) = P(O | \lambda, A, B, \pi)$ الذي تكون فيه λ عظمى ، أي إعادة تقدير معلمات النموذج $\lambda = \lambda(A, B, \pi)$ لتعظيم (Stamp,2003).

(11) حل المسائل الأساسية لنماذج ماركوف المخفية :

(Solutions to the Basic Problems of HMMs)

11.1 حل المسألة (1) :

إن الطريقة المباشرة لحسابها تكون من خلال سرد متسلسلة حالة ذات طول T (حيث إن T تمثل عدد المشاهدات) ولنتأمل المتسلسلة الثابتة للحالة :

$$Q = q_1 \ q_2 \ ... \ q_T \quad \dots(1)$$

حيث إن (q_t) تمثل الحالة الابتدائية ، أما الاحتمالية لمتسلسلة المشاهدات (O) بالنسبة لمتسلسلة الحالة في المعادلة (1) فهي (Rabiner , 1989) :

$$P(O | Q, \lambda) = \prod_{t=1}^T P(O_t | q_t, \lambda) \quad \dots(2 a)$$

وذلك بافتراض الاستقلال الإحصائي للمشاهدات ، أي إن :

$$P(O | Q, \lambda) = P(O_1 | q_1, \lambda) * P(O_2 | q_2, \lambda) * \dots * P(O_T | q_T, \lambda)$$

$$= \prod_{t=1}^T P(O_t | q_t, \lambda) \quad \dots(2 b)$$

$$= \prod_{t=1}^T b q_t(O_t) \quad \dots(2 b)$$

وأن الاحتمالية لمتسلسلة الحالة (Q) هي :

$$\begin{aligned}
 P(Q | \lambda) &= P(q_1, q_2, \dots, q_T | \lambda) \\
 &= P(q_1; \lambda) \prod_{t=2}^T P(q_t | q_{t-1}; \lambda) \\
 &= \pi q_1 \prod_{t=2}^T a q_{t-1}, q_t
 \end{aligned} \quad ... (3)$$

وذلك حسب الخاصية الماركوفية (Ellis 2001 ، حيث إن π) تشير إلى احتمالية .
الحالة الابتدائية للحالة (q_1) .

أما الاحتمالية المشتركة لـ (O) و (Q) ، أي احتمالية ورود (O) و (Q) في الوقت نفسه ، فهي تمثل النتيجة للمعادلتين (2.5 b) و (2.6) ، أي إن :

$$P(O, Q | \lambda) = P(O | Q, \lambda) * P(Q | \lambda) \quad ... (4)$$

ومن هنا يمكن الحصول على الاحتمالية لـ (O) عندما يكون المعطى هو
النموذج (λ) وذلك عن طريق جمع هذه الاحتمالية المشتركة لكل متسلسلات الحالة
 (q) ، حيث إن :

$$P(O | \lambda) = \sum_{\text{all } Q} P(O | Q, \lambda) * P(Q | \lambda) \quad ... (5)$$

$$\pi_{q1} * b_{q1}(O_1) * a_{q1q2} * b_{q2}(O_2) * \dots * a_{qT-1qT} * b_{qT}(O_T) \sum_{q_1, q_2, \dots, q_T} = \quad ... (6)$$

إن هذه الحسابات تكون غير عملية وإن كانت قيم (N) و (T) صغيرة ، فمثلاً إذا
كانت $(N = 5)$ (وهي تمثل عدد الحالات المخفية) وكانت $(T = 100)$ (وهي تمثل
عدد المشاهدات) ، فيجب القيام بـ $5^{100} \approx 10^{72}$ عملية حسابية ، ومن
ذلك يتضح بأن هذه الحسابات تتطلب جهداً كبيراً لحل المسألة (1) ، ولذلك استخدم
الباحثون الخوارزميات الأمامية - الخفية (Forward-Backward)
لحل تلك المسألة (Rabiner , 1989) ، وفيما يأتي توضيح لهذه
الخوارزميات :

أولاً : الخوارزميات الأمامية :

تُعرَّف الاحتمالية الأمامية (α_t) على أنها الاحتمالية لمتسلسلة مشاهدات جزئية والحالة ($q_t = S_i$) عندما يكون المعطى هو النموذج (λ) ، أي :

$$\alpha_t(i) = P(O_1 O_2 \dots O_t, q_t = S_i | \lambda) \quad \dots(7)$$

حيث إن الاحتمالية المطلوب إيجادها هي :

$$P(O | \lambda) = \sum_{i=0}^{N-1} \alpha_{T-1}(i)$$

وهذه الاحتمالية يمكن إيجادها بشكل متتالي (Recursion) وكما الآتي :

1. البداية (Initialization) :

$$\alpha_0(i) = \pi_i b_i(O_0), \quad i = 0, \dots, N-1 \quad \dots(8)$$

2. التعاقب (Recursion) :

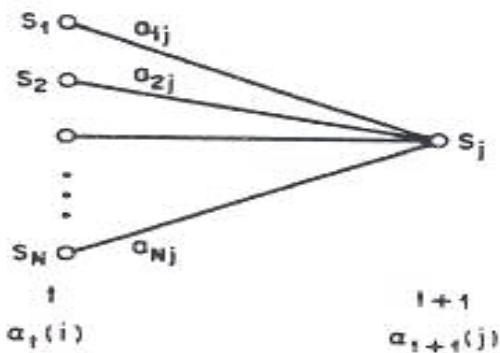
$$\alpha_t(j) = \left[\sum_{i=0}^{N-1} \alpha_{t-1}(i) a_{ij} \right] * b_j(O_t), \quad t = 1, \dots, T-1 \quad \dots(9)$$

$$, j = 0, \dots, N-1$$

3. النهاية (Termination) :

$$P(O | \lambda) = \sum_{i=0}^{N-1} \alpha_{T-1}(i) \quad \dots(10)$$

ومن هنا تُحسب $P [O_1 O_2 \dots O_T]$. (Parker ,1999)
ويمكن توضيح الخوارزميات الأمامية من خلال الشكل (1) .



الشكل (1) : سلسلة العمليات المطلوبة لحساب الاحتمالية الأمامية α_{t+1}^j

إن حسابات α_t^j تتطلب $N(N-1)(T-1)+N$ عملية ضرب و $N(N+1)(T-1)$ عملية جمع وهي أفضل من الحسابات المباشرة والتي تتطلب $(2T * N^T)$ عملية حسابية (Rabiner, 1989) و (Stamp, 2003).

ثانياً : الخوارزميات الخلفية :

تُعرف الاحتمالية الخلفية على أنها الاحتمالية لمتسلسلة المشاهدات الجزئية (λ) عندما يكون المعطى هو الحالة $(q_t = S_i)$ والنموذج $(O_{t+1}, O_{t+2}, \dots, O_T)$ وكما يأتي :

$$\beta_t(i) = P(O_{t+1} O_{t+2} \dots O_T | q_t = S_i, \lambda) \quad \dots(11)$$

وهذه الاحتمالية يمكن إيجادها أيضاً بشكل متsequab (Recursion) وكالآتي (Stamp, 2003) :

$$\beta_{T-1}(i) = 1, \quad i = 0, \dots, N-1 \quad \dots(12)$$

2. التعاقب :

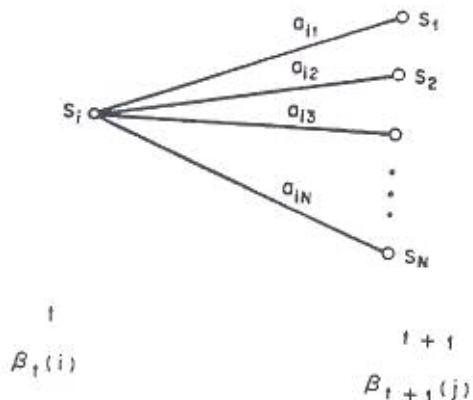
$$\beta_t(i) = \sum_{j=0}^{N-1} a_{ij} * b_j(O_{t+1}) * \beta_{t+1}(j), \quad t = 0, \dots, T-2 \quad \dots(13)$$

$, i = 0, \dots, N-1$

3. النهاية :

$$P(O | \lambda) = \sum_{i=0}^{N-1} \alpha_t(i) * \beta_t(i), \text{ for any } t \quad \dots(14)$$

والشكل (2) يوضح العمليات المطلوبة لحساب الاحتمالية الخلفية .



الشكل(2) : سلسلة العمليات المطلوبة لحساب الاحتمالية الخلفية $\beta_t(i)$

1.21 حل المسألة (2) :

هناك بعض الطرق الممكنة لحل المسألة (2) ، أي لإيجاد متسلسلة الحالة

المُتّلِى المقتربة بمتسلسلة المشاهدات المعطاة منها :

خوارزمية (Viterbi)

هي طريقة البرمجة الحركية المستخدمة لحساب مسار الحالة الانتقالية الأكثر احتمالاً عندما يكون المعطى هو متسلسلة المشاهدات للرموز ، وهي مشابهة للخوارزمية الأمامية ما عدا كون استخدام الـ " أكبر " Max " بدلاً من الـ " مجموع " Σ . (Zhai , 2003)

ولإيجاد أفضل متسلسلة حالة وحيدة $Q = [q_0 \ q_1 \ \dots \ q_{T-1}]$ بالنسبة لمتسلسلة المشاهدات المعطاة $O = [O_0 \ O_1 \ \dots \ O_{T-1}]$ يجب تعريف المقدار :

$$\delta_t(i) = \max_{q_0 \dots q_{t-2}} P[q_0 q_1 \dots q_{t-1} = S_i, O_0 O_1 \dots O_{t-1} | \lambda] \quad \dots(15)$$

إذ إن (i) δ_t تمثل أعلى احتمالية على طول المسار الوحيد خلال الزمن (t) والمحسوبة بالنسبة لمشاهدات (t) الأولى والمنتهية في الحالة (S_i) ، فضلاً عن استخدام $(i)_t \psi$ والتي تساعد في حفظ تتبع الأثر (Keep Track) للمسار الفعلي ، أي إن $(i)_t \psi$ ستوضح أية حالة خلال الزمن $(t-1)$ تقود لاحتمالية (i) δ_t أعلى خلال الزمن (t) (Parker, 1999).

أما خطوات خوارزمية (Viterbi) فهي كالتالي :

1. البداية :

$$\delta_0(i) = \pi_i * b_i(O_0), i = 0, \dots, N-1 \quad \dots(16\ a)$$

$$\psi_0(i) = 0 \quad \dots(16\ b)$$

2. التعاقب :

$$\delta_t(j) = \max_{0 \leq i \leq N-1} [\delta_{t-1}(i) * a_{ij}] * b_j(O_t), t = 1, \dots, T-1 \quad \dots(17\ a)$$

$$, j = 0, \dots, N-1$$

$$\psi_t(j) = \arg \max_{0 \leq i \leq N-1} [\delta_{t-1}(i) * a_{ij}], t = 1, \dots, T-1 \quad \dots(17\ b)$$

$$, j = 0, \dots, N-1$$

3. النهاية :

$$P^* = \max_{0 \leq i \leq N-1} [\delta_{T-1}(i)] \quad \dots(18\ a)$$

$$q^*_{T-1} = \arg \max_{0 \leq i \leq N-1} [\delta_{T-1}(i)] \quad \dots(18\ b)$$

4. التتابع المعاكس : (Back Tracking)

$$Q^* = \{q^*_0, \dots, q^*_{T-1}\}$$

$$q^*_t = \psi_{t+1}(q^*_{t+1}), t = T-2, T-3, \dots, 0 \quad \dots(19)$$

ثم تقرأ المتسلسلة الأفضل للحالات من متجهات ψ_t .

:(11.3) حل المسألة

المطلوب في المسألة (3) هو إعادة تقدير معلمات النموذج (π , B , A) وذلك لتعظيم الاحتمالية لمتسلسلة المشاهدات عندما يكون المعطى هو النموذج ويمكن حل هذه المسألة باستخدام خوارزمية (Rabiner , 1989) (Baum-Welch)

خوارزمية (Baum-Welch)

هذه الخوارزمية تُناقش خطوات التكرار بالاعتماد وبشكل ابتدائي على العمل الكلاسيكي للعالم (L.E. Baum) وزملائه وذلك لاختيار معلمات النموذج . ولوصف خطوات إعادة تقدير (Re-estimate) معلمات (HMM) ، يتم تعريف المتغيرين الآتيين :

المتغير الأول هو :

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=0}^{N-1} \alpha_t(i)\beta_t(i)}$$

أما المتغير الثاني فهو :

$$\begin{aligned} \gamma_t(i,j) &= \frac{\alpha_t(i)a_{ij}b_j(O_{t+1})\beta_{t+1}(j)}{P(O|\lambda)} \\ &= \frac{\alpha_t(i)a_{ij}b_j(O_{t+1})\beta_{t+1}(j)}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \alpha_t(i)a_{ij}b_j(O_{t+1})\beta_{t+1}(j)} , t = 0, \dots, T-2 \quad \dots(20) \end{aligned}$$

وباستخدام الصيغ أعلاه ، يمكن إدراج الصيغ الآتية وذلك لإعادة تقدير معلمات : (Stamp ,2003) (A , B , π) (HMM)

$$\bar{\pi}_i = \gamma_0(i) , i = 0, \dots, N-1 \quad \dots(21 \text{ a})$$

$$\bar{a}_{ij} = \frac{\sum_{t=0}^{T-2} \xi_t(i, j)}{\sum_{t=0}^{T-2} \gamma_t(i)}, \quad i, j = 0, \dots, N-1 \quad \dots(21\ b)$$

$$\bar{b}_j(k) = \frac{\sum_{\substack{t \in (0, 1, \dots, T-2) \\ O_t = v^k}} \gamma_t(j)}{\sum_{t=0}^{T-2} \gamma_t(j)}, \quad j = 0, \dots, N-1 \quad \dots(21\ c)$$

بالاعتماد على الخطوات السابقة وباستخدام (وبشكل متكرر) (λ)
بدلاً من (A, π, B) و تكرار حسابات إعادة التقدير فسوف تُعَدَّ
الاحتمالية لـ(O) المشاهدة من النموذج إلى أن يتم التوصل إلى بعض النقاط
المُحددة ، والنتيجة النهائية لخطوات إعادة التقدير هذه تُعرف بـ(تقدير الإمكان
الأعظم لـ (HMM) .

إن الجانب المهم من خطوات إعادة التقدير هو شرط (أو قيد) التصادفية
لمعلمات الـ(HMM)، وبالذات المتحقق في كل تكرار، أي إن (Rabiner, 1989)

$$\sum_{i=0}^{N-1} \bar{\pi}_i = 1$$

$$\sum_{j=0}^{N-1} \bar{a}_{ij} = 1, \quad i = 0, \dots, N-1$$

$$\sum_{k=0}^{M-1} \bar{b}_j(k) = 1, \quad j = 0, \dots, N-1$$

إن عملية إعادة التقدير التي تمثل عملية التكرار بدأت من اختيار أفضل
قيم تخمينية (أو تقديرية) لـ(A, π, B) ، وإذا لم تتوافر هذه القيم فسوف
يتم اختيار قيم عشوائية بحيث إن :

$$\pi_i \approx 1/N$$

$$a_{ij} \approx 1/N$$

$$b_j(k) \approx 1/M$$

مع التأكيد على أن تكون (A, B, π) دائمًا ذات صفات تصادفي ، وأن لا تكون قيم عناصر المصفوفة متساوية .

ويمكن تلخيص العملية بالخطوات الآتية :

1. البداية ، اختيار قيم عشوائية ابتدائية للنموذج (A, B, π)
 2. حساب $\alpha_t(i)$ ، $\beta_t(i)$ ، $\gamma_t(i, j)$ ، $\lambda = (A, B, \pi)$
 3. إعادة تقدير النموذج λ
 4. إذا كانت $P(\lambda | O)$ تزايدية ، فيجب الذهاب إلى (2).
- وبالطبع يجب التوقف إذا لم تكن $P(\lambda | O)$ تزايدية (Stamp, 2003) .

(12) تقدير نماذج ماركوف المخفية : (Scaling HMMs)

يمكن تنفيذ الصيغ المعطاة في المباحث السابقة كما هي ولكنها تكون مفيدة في حالة كون المتسلسلات قصيرة جدًا ، أما عندما تكون المتسلسلة طويلة فإن عدة مقادير تصغر وبشكل حاد وحل هذه المشكلة هناك طريقتان :

الأولى ، العمل على مجال اللوغاريتم ، أيأخذ اللوغاريتم الذي يقرب الناتج للكميات الصغيرة .

الثانية ، طريقةScaling أي التقسيس (وهي الطريقة المفضلة) والقصد منها تقسيس $\alpha_t(i)$ و $\beta_t(i)$ ، حيث يرمز لهما بـ $\hat{\alpha}_t(i)$ و $\hat{\beta}_t(i)$ (على التوالي) ، على أن تكون $\hat{\alpha}_t(i)$ متناسبة مع $\alpha_t(i)$ ويكون المجموع يساوي (1) لكل الحالات الممكنة (أي لجميع قيم i) وكالآتي (Zhai , 2003) و(Stamp , 2003) :

$$\sum_{i=0}^{N-1} \hat{\alpha}_t(i) = 1$$

هذا وأن :

$$\hat{\alpha}_t(i) = \prod_{k=0}^t \eta_k \alpha_t(i) , i = 0, \dots, N-1 ; t = 0, \dots, T-1 \quad \dots (22)$$

وكذلك فإن :

$$\prod_{k=0}^{T-1} \eta_k = \frac{1}{\sum_{i=0}^{N-1} \alpha_{T-i}(i)} = \frac{1}{P(O | \lambda)}$$

أو :

$$\log[P(O | \lambda)] = - \sum_{k=0}^{T-1} \log(\eta_k) \quad ... (23)$$

حيث يمكن حساب لوغاريثم (P) وليس (P) ، هذا وأن التقييس سيمر بعدة خطوات كما هي مبينة أدناه .

أولاً: خوارزمية تقييس الاحتمالية الأمامية (α) :

(The Scaling Forward Algorithm)

يتم حساب ($\hat{\alpha}$) بنفس خوارزمية (α) إجراء بعض التغييرات عند كل خطوة وكالآتي (Zhai , 2003)

$$1. \hat{\alpha}_0(i) = \frac{\pi_i b_i(O_0)}{\sum_{k=0}^{N-1} \pi_k b_k(O_0)} \quad , i = 0, \dots, N-1 \quad ... (24 \text{ a})$$

$$2. \hat{\alpha}_t(i) = \frac{b_i(O_t) \sum_{j=0}^{N-1} \hat{\alpha}_{t-1}(j) a_{ji}}{\sum_{k=0}^{N-1} b_k(O_t) \sum_{j=0}^{N-1} \hat{\alpha}_{t-1}(j) a_{jk}} \quad , i = 0, \dots, N-1 \quad ... (24 \text{ b})$$

$, t = 1, \dots, T-1$

ثانياً : خوارزمية تقييس الاحتمالية الخلفية (β) :

(The Scaling Backward Algorithm)

يمكن تقييس الاحتمالية الخلفية (β) بالطريقة المستخدمة نفسها لتقييس الاحتمالية الأمامية (α) ذلك إن :

$$\hat{\beta}_t(i) = \beta_t(i) \prod_{k=t+1}^{T-1} \eta_k \quad ... (25)$$

حيث إن ($\hat{\beta}_T(i) = \beta_T(i)$) ، وأن :

$$\hat{\alpha}_t(i)\hat{\beta}_t(i) = \prod_{k=0}^{T-1} \eta_k \alpha_t(i)\beta_t(i) = \frac{\alpha_t(i)\beta_t(i)}{P(O|\lambda)}$$

حيث يتم حساب الاحتمالية الخلفية $(\hat{\beta})$ بطريقة حساب الاحتمالية الخلفية (β) نفسها مع إدخال (η) (المحسوبة سابقاً من خوارزمية تقدير الاحتمالية الأمامية في القانون وكالآتي (Zhai , 2003) :

$$1. \hat{\beta}_{T-1}(i) = \beta_{T-1}(i) = 1 \quad , i = 0, \dots, N-1 \quad \dots(26 \text{ a})$$

$$2. \hat{\beta}_t(i) = \eta_{t+1} \sum_{j=0}^{N-1} \hat{\beta}_{t+1}(j) a_{ij} b_j(O_{t+1}) \quad , t = 0, \dots, T-1 \quad \dots(26 \text{ b})$$

ثالثاً: صيغ التحديث باستخدام $(\hat{\alpha})$ و $(\hat{\beta})$:

(The Updating Formulas Using Scaled α 's and β 's)

يمكن حساب (γ) باستخدام $(\hat{\alpha})$ و $(\hat{\beta})$ وكالآتي :

$$\gamma_t(i) = \frac{\hat{\alpha}_t(i)\hat{\beta}_t(i)}{\sum_{j=0}^{N-1} \hat{\alpha}_t(j)\hat{\beta}_t(j)} \quad , i = 0, \dots, N-1 ; t = 0, \dots, T-2 \quad \dots(27)$$

وحساب (ξ) بصيغ مختلفة وكالآتي :

$$\xi_t(i,j) = \frac{\hat{\alpha}_t(i)a_{ij}b_j(O_{t+1})\eta_{t+1}\hat{\beta}_{t+1}(j)}{\sum_{j=0}^{N-1} \hat{\alpha}_t(j)\hat{\beta}_t(j)} \quad \dots(28)$$

أو :

$$\xi_t(i,j) = \frac{\gamma_t(i)a_{ij}b_j(O_{t+1})\eta_{t+1}\hat{\beta}_{t+1}(j)}{\hat{\beta}_t(i)} \quad \dots(29)$$

وباستخدام (γ) و (ξ) المحسوبتين أعلاه ، يمكن حساب (a, b, π) المعدلة [والتي

: (Stamp ,2003) وكالآتي (Zhai , 2003) و $(\bar{\pi}, \bar{b}, \bar{a})$ يرمز لها بـ]

$$\bar{\pi}_i = \gamma_0(i) \quad , i = 0, \dots, N-1 \quad \dots(30 \text{ a})$$

$$\bar{a}_{ij} = \frac{\sum_{t=0}^{T-2} \xi_t(i, j)}{\sum_{t=0}^{T-2} \gamma_t(i)}, \quad i, j = 0, \dots, N-1 \quad \dots(30\ b)$$

$$\bar{b}_j(k) = \frac{\sum_{\substack{t \in (0, 1, \dots, T-2) \\ O_t = v_k}} \gamma_t(j)}{\sum_{t=0}^{T-2} \gamma_t(j)}, \quad j = 0, \dots, N-1 \quad \dots(30\ c)$$

رابعاً: خوارزمية تقييس الاحتمالية (δ) :

أما عند استخدام خوارزمية (Viterbi) لإعطاء الإمكان لمتسلسلة الحالة ،
فليس من الضروري عمل (Scaling) إذا استخدمت اللوغاريتمات بالطريقة الآتية،
حيث يُعرف المقدار ($\delta_t(i)$) كالتالي :

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_t} \{ \log P[q_1 q_2 \dots q_t, O_1 O_2 \dots O_t | \lambda] \} \quad \dots(31)$$

و هذه الاحتمالية يمكن إيجادها بشكل تعاقبى وكالآتى :

1. البداية :

$$\delta_0(i) = \log(\pi_i) + \log[b_i(O_0)], \quad i = 0, \dots, N-1 \quad \dots(32\ a)$$

$$\psi_0(i) = 0 \quad \dots(32\ b)$$

2. التعاقب :

$$\delta_t(j) = \max_{0 \leq i \leq N-1} [\delta_{t-1}(i) + \log(a_{ij})] + \log[b_j(O_t)], \quad t=1, \dots, T-1 \quad \dots(33\ a)$$

$$, j=0, \dots, N-1$$

$$\psi_t(j) = \arg \max_{0 \leq i \leq N-1} [\delta_{t-1}(i) + \log(a_{ij})] \quad \dots(33\ b)$$

3. النهاية :

$$\log P^* = \max_{0 \leq i \leq N-1} [\delta_{T-1}(i)] \\ \dots (34\text{ a})$$

$$q^*_{T-1} = \arg \max_{0 \leq i \leq N-1} [\delta_{T-1}(i)] \dots (34\text{ b})$$

4. التابع المعاكس :

$$Q^* = \{q_0^*, \dots, q_{T-1}^*\} \\ q_t^* = \psi_{t+1}(q_{t+1}^*) \quad , t = T-2, T-3, \dots, 0 \dots (35)$$

. (Stamp, 2003) و (Rabiner, 1989)

الجانب التطبيقي :

تم في هذا البحث تطبيق نماذج ماركوف المخفية للتمييز بين الحروف الصحيحة وحروف العلة في نصوص اللغة الإنجليزية .

(13.1) خطوات العمل :

الخطوة الأولى :

ترتيب الحروف الإنجليزية بشكل متسلسل حيث يقابل كل حرف رقمًا يمثله، وكذلك وضع رقم للفراغ (Space) بين كلمة وأخرى .

الخطوة الثانية :

تؤخذ سلسلة من المشاهدات التي هي حروف مرتبة حسب النص الذي أخذت منه ، وتكون كما يأتي :

إذا كان الحرف في الكلمة هو (a) فيرمز له بـ(0) وإذا كان الحرف هو (b) فيرمز له بـ(1) وهكذا لبقية الحروف .

الخطوة الثالثة :

هي عملية اختيار قيم ابتدائية للمعلمات، ليست هناك طريقة مباشرة لاختيار التقديرات الابتدائية، ولعمل ذلك تم اختيار القيم بشكل عشوائي أو تخميني .

الخطوة الرابعة :

هي عملية حساب المتغيرات الأمامية (أي حساب قيم α وقيم α المعدلة) .

الخطوة الخامسة :

هي حساب المتغير (η) ويكون بالاعتماد على قيم كل من (α) و ($\hat{\alpha}$) فضلاً عن إيجاد $\log P(O|\lambda)$.

الخطوة السادسة :

وهي حساب المتغيرات الخلفية (أي حساب β) وبسبب طول متسلسلة المشاهدات أيضاً فسوف يتم تقدير قيم (β).

الخطوة السابعة :

وتتمثل في حساب كل من (i) و (j) وذلك حسب صيغ التحديث باستخدام ($\hat{\alpha}$) و ($\hat{\beta}$).

الخطوة الثامنة :

إعادة حساب المعلمات (A , B , π) لتعظيم الاحتمالية لمتسلسلة المشاهدات إذا كان المعطى هو النموذج مع التأكيد على أن تكون المصفوفات تصادفية ، ومن هذه المصفوفات الناتجة يُعاد حساب $\log P(O|\lambda)$ فإذا كانت تزايدية تُعاد الخطوات السابقة (من الخطوة الرابعة) وذلك باستخدام المصفوفات الجديدة الناتجة لـ (A), (B) و (π) كمصفوفات داخلة .

(13.2) النتائج :

بعد حساب المتغيرات المطلوبة وإجراء التكرار الابتدائي لوحظ بأن :

$$\log P(O|\lambda) = -634.433173$$

وبعد التكرار ($q = 284$) :

$$\log P(O|\lambda) = -512.467179$$

وهذا يؤكد أن النموذج قد تحسن وبشكل واضح ، إذ إن النموذج (π , A , B) بعد التكرار (284) تحول إلى :

$$\begin{aligned} \pi &= [1.000000 \quad 0.000000] \\ A &= \begin{bmatrix} 0.452615 & 0.547385 \\ 0.960543 & 0.039457 \end{bmatrix} \end{aligned}$$

فضلاً عن مبدلة المصفوفة (\bar{B}) الموضحة في الجدول .

إن الجزء الأكثر أهمية في هذه النتيجة هو المصفوفة (B) ، وبشكل واضح وبدون أي افتراض حول الحالتين المخفيتين فإن المصفوفة (B) تُظهر بأن هناك حالة واحدة مخفية تحتوي على حروف العلة في حين إنّ الحالة المخفية الأخرى تحتوي على الحروف الصحيحة ، ذلك أن العمود الأول في الجدول (1) قد أعطى أعلى قيم لحروف العلة (وهي a , e , i , o وu) أما بقية الحروف (أي الحروف الصحيحة) فقد كانت صفرية أو مقاربة للصفر، لذا فإن العمود الأول يمثل نسبة احتمالية حروف العلة ، أما في العمود الثاني فقد كانت قيم حروف العلة مساوية للصفر، أي أن العمود الثاني يمثل نسبة احتمالية الحروف الصحيحة ، مع ملاحظة أن الحرف (y) يُعامل أحياناً كحرف علة .

(14) الاستنتاجات والتوصيات :

تم التوصل من خلال هذه الدراسة إلى ما يأتي :

في ما يخص الجانب التطبيقي لهذه الدراسة يُلاحظ أنه يمكن معرفة الحروف الصحيحة وحروف العلة دون معرفة سابقة بقواعد اللغة الإنكليزية ، وقد تبين من الجدول (1) أن حروف العلة هي (a , e , i , o وu).

ويمكن التوصية بما يأتي :

1. من خلال مقابلة الباحثة لأستاذة اللغة الإنكليزية في كلية الآداب أوضحاوا ان هناك فرقاً بين النصوص العلمية والنصوص الأدبية لذا نوصي بتطبيق هذه النماذج للحالتين ومقارنة النتائج .
2. أكد المختصون أن هناك فرقاً بين حروف العلة وأصوات العلة والتي هي صوتاً ، لذا نوصي بأخذ (12) حالة مخفية وملاحظة النتائج لها .

الجدول (1): قيم عناصر مبدلة المصفوفة (\bar{B}) عند التكرار الأخير (284)

	القيمة	
a	0.128153	0.000000
b	0.000000	0.018740
c	0.008775	0.019412
d	0.007727	0.068840
e	0.181550	0.000000
f	0.000000	0.031233
g	0.008478	0.004421
h	0.000000	0.187400
i	0.075755	0.000000
j	0.000000	0.003204
k	0.000000	0.018740
l	0.004951	0.048724
m	0.000000	0.062467
n	0.000000	0.181154
o	0.188995	0.000000
p	0.000000	0.031233
q	0.000000	0.001026
r	0.000000	0.118687
s	0.000516	0.100233
t	0.013922	0.021395
u	0.045919	0.000000
v	0.000000	0.024987
w	0.000000	0.054220
x	0.000000	0.000245
y	0.000665	0.001202
z	0.000000	0.001104
space	0.334594	0.001333

(المصادر : 15)

1. الربيعي، فاضل محسن وعبد، صلاح حمزة (2000). "مقدمة في العمليات التصادفية " ، دار الكتب – بغداد ، العراق .
2. Cox,D.R. and Miller, H.D. (1965). " The Theory of Stochastic Processes ", John Wiley & Sons , Inc. , New York , USA .
3. Ellis,D. (2001) " Sequence Recognition " , Computer, Speech, and Language, Vol. 1, no. 2, pp. 167-197
4. Parker,J. (1999). " Profile Hidden Markov Models " , Biophysical Journal , Vol. 17 , P. 1335 – 1348 .
5. Rabiner,L.R. (1989). " A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition " , Proceedings of IEEE , Vol. 77 , No. 2 , P. 257 – 286 .
6. Srinivasan,S.K. & Mehata, K.M. (1976). " Stochastic Processes " , Tata McGraw – Hill Publishing Company Limited , New Delhi .
7. Stamp,M. (2003). " A Revealing Introduction to Hidden Markov Models " , IEEE , Vol. 51 , No. 7 , P. 347 – 356 .
8. Zhai,C. (2003). " A Brief Note on the Hidden Markov Models " , IEEE Transactions on PAMI , Vol. PAMI –18 , No.3 , P.475–4 79. <http://hanoi.cs.uiuc.edu/cs397/hmm>.