

Computer Science Faculty
Damascus University
MS.c Software Engineering and Information Systems

Markov Chains

Amjad Y.Mahfoud and Mouhammad Wardeh

amjadoof@gmail.com

مقدمة

- جل دراستنا للاحتتمالات تعاملنا مع تجارب عشوائية مستقلة, تعتبر اساس نظرية الإحتتمالات الكلاسيكية والاحصاء.
- عندما تشكل سلسلة من التجارب إجرائية مستقلة يكون الخرج المتوقع لكل تجربة متماثلا, كما ان معرفة خرج تجربة لا يؤثر على التنبؤ بخرج التجربة التالية, يعتبر التوزيع الاحتمالي لتجربة واحدة كافيا وممثلا لكل التجارب الاخرى.
- تدرس نظرية الاحتمالات الحديثة تجارب الحظ حيث يؤثر خرج تجربة سابقة على خرج التجربة التالية, عندما نلاحظ سلسلة من التجارب , كل من النتائج الماضية يمكن أن تؤثر على توقعاتنا للتجربة المقبلة. على سبيل المثال, ينبغي أن يكون هذا هو الحال في التنبؤ بدرجات الطالب على سلسلة من الامتحانات في الدورة.
- في عام 1907, بدأ ماركوف دراسة نوع جديد مهم من التجارب. وفي هذه العملية, يمكن أن تؤثر نتيجة تجربة معينة على نتيجة التجربة التالية. ويسمى هذا النوع من العملية سلسلة ماركوف.
- . في عام 1907, بدأ ماركوف دراسة نوع جديد مهم من عملية الصدفة. وفي هذه العملية, يمكن أن تؤثر نتيجة تجربة معينة على نتيجة التجربة التالية. ويسمى هذا النوع من العملية سلسلة ماركوف.

إجرائية ماركوف:

نقول عن الـ stochastic process $\{X(t), t \in T\}$ انها إجرائية ماركوف عندما يكون من اجل كل مجموعة نقاط من $n+1$ عنصر بالشكل التالي $t_1 < t_2 < \dots < t_n < t_{n+1}$ (مجموعة الفهرس index set) ومجموعة الحالات states المكونة من $n+1$ عنصر كالتالي $\{X_1, X_2, \dots, X_{n+1}\}$

$$P[(X(t_{n+1}) = x_{n+1} | X(t_n) = x_n, X(t_{n-1}) = x_{n-1}, \dots, X(t_1) = x_1)] = P[(X(t_{n+1}) = x_{n+1} | X(t_n) = x_n)]$$

- يعتمد مستقبل الاجرائية على الحالة الحالية فقط دون النظر لتاريخ الاجرائية.
- تدعى إجرائية ماركوف بسلسلة ماركوف Markov chain في حال كان فضاء الحالة الخاص بها منتهياً.

سلاسل ماركوف المتقطعة في الزمن - Discrete-Time Markov Chains

هي stochastic process $\{X(t), t \in T\}$ بمجموعة فهرس N وفضاء حالة متقطع. ا.

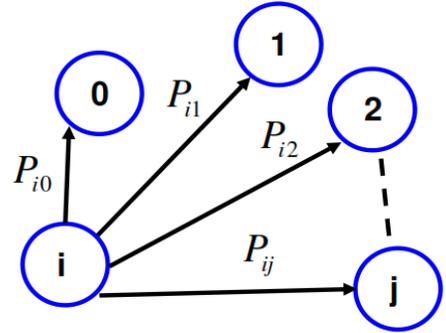
$$P[(X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0)] = P[X_{n+1} = j | X_n = i]$$

من المثير التفكير بالاجرائية كانتقال بين الحالات في الاوقات ($n=1, 2, 3, \dots$) من الممكن ان يكون الانتقال الى نفس الحالة).

احتمال الانتقال خطوة واحدة :

$$P[(X_{n+1} = j | X_n = i] \quad n, i, j = 0, 1, 2, \dots$$

سلاسل ماركوف المتجانسة زمنياً :homogeneous Markov Chains



$$P = \begin{bmatrix} P_{00} & P_{01} & P_{02} & P_{03} & \cdots \\ P_{10} & P_{11} & P_{12} & P_{13} & \cdots \\ P_{20} & P_{21} & P_{22} & P_{23} & \cdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ P_{i0} & P_{i1} & P_{i2} & P_{i3} & \cdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \end{bmatrix} \quad \sum_{j=0}^{\infty} P_{ij} = 1$$

- يقال ان سلاسل ماركوف ذات احتماليات انتقال ثابتة (متجانسة زمنياً) عندما يكون احتمال انتقال الخطوة الواحدة مستقل عن الزمن n .
- P_{ij} احتمال الانتقال من الحالة i الى الحالة j بخطوة واحدة:

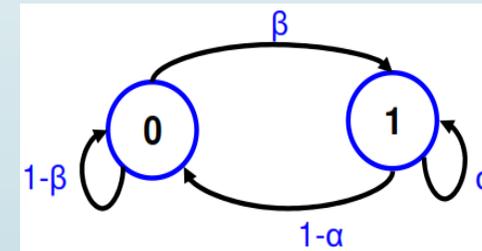
$$P[(X_{n+1} = j | X_n = i) = P_{ij}, n, i, j = 0, 1, 2, \dots]$$

- أو احتمالية كون النظام في الحالة j في اللحظة $n+1$ علماً انه كن في الحالة i في اللحظة n .
- في حال كان عدد حالات سلسلة ماركوف محدود n يوجد مصفوفة احتمالات الانتقالات من البعد $n \times n$.

مثال حالة الطقس:

- بفرض احتمال المطر غداً يعتمد على ظروف طقس سابقة فقط من خلال كونها تمطر اليوم أو لا بغض النظر عن الظروف السابقة.
- بفرض انها امطرت اليوم فستمطر غداً باحتمال α وفيما لو لم تمطر اليوم فإنها ستمطر غداً باحتمال β اوجد transition probability matrix:
- انها سلسلة ماركوف من حالتين 0 غير ممطرة و 1 ممطرة.

$$P = \begin{bmatrix} 1-\beta & \beta \\ 1-\alpha & \alpha \end{bmatrix}$$



مثال تحويل اجرائية إلى سلسلة ماركوف:

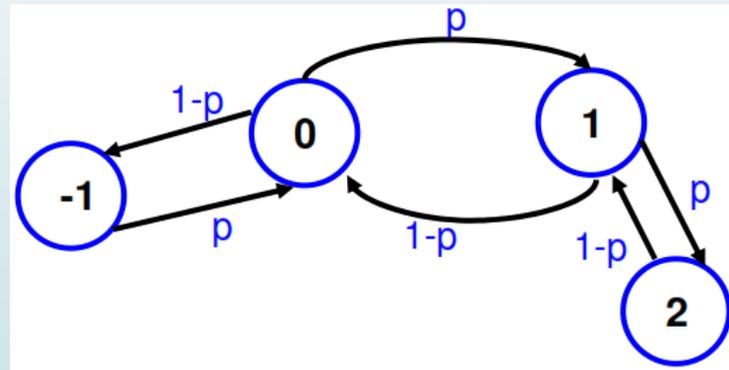
- بفرض انها امطرت في اليومين الماضيين فانها ستمطر غدا باحتمال 0.7
- إذا امطرت اليوم ولم تمطر بالامس فستمطر غدا باحتمال 0.5
- امطرت يالامس ولم تمطر اليوم فستمطر غدا باحتمال 0.4
- إذا لم تمطر في اليومين الماضيين فستمطر غدا باحتمال 0.2

- state 0 if it rained both today and yesterday,
- state 1 if it rained today but not yesterday,
- state 2 if it rained yesterday but not today,
- state 3 if it did not rain either yesterday or today.

$$P = \begin{pmatrix} 0.7 & 0 & 0.3 & 0 \\ 0.5 & 0 & 0.5 & 0 \\ 0 & 0.4 & 0 & 0.6 \\ 0 & 0.2 & 0 & 0.8 \end{pmatrix}$$

مثال Random Walk Model :

يقال عن سلسلة ماركوف بحالات $i = 0, \pm 1, \pm 2, \dots$ أنها random walk اذا وجد من اجل رقم $0 < p < 1$.



$$P_{ii+1} = p$$

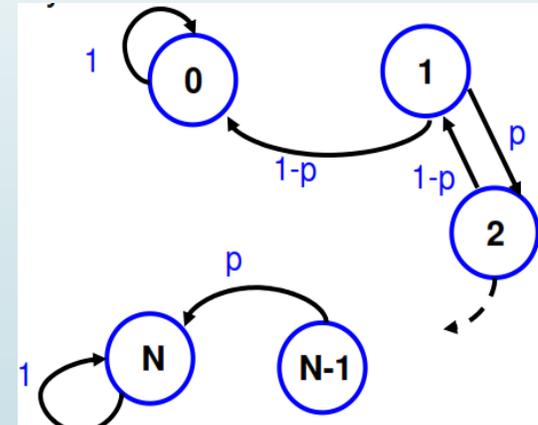
$$0, \pm 1, \pm 2, \dots$$

$$P_{ii-1} = 1 - p$$

مثال player Model:

- بفرض لاعب في كل مرحلة من اللعب يربح دولار واحد باحتمال p أو يخسر دولار باحتمال $1-p$.
 p غذا فرضنا ان اللاعب ينهى اللعب عندما بفلس أو يربح N دولار يمثل هذا الامر بسلسلة ماركوف لها مصفوفة الانتقال التالية:

$$P_{ii+1} = p \quad 1,2,\dots,N-1$$
$$P_{ii-1} = 1-p$$
$$P_{00} = P_{NN} = 1$$

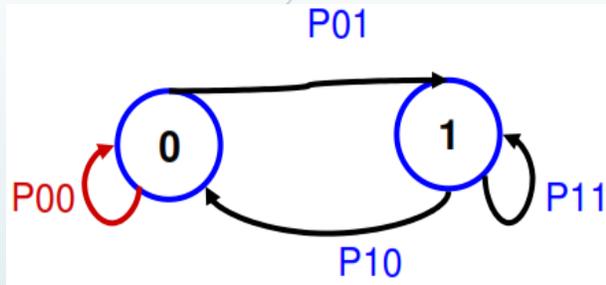


- تدعى الحالات 0 و N بالحالات الماصة اذ حالما يدخل اليها لا يمكن الخروج منها.

معادلات Chapman-Kolmogorov:

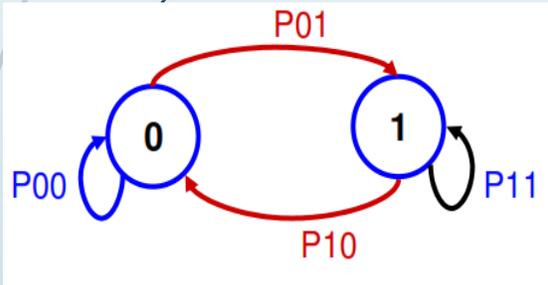
- عرفنا مسبقا احتمالات الانتقال بخطوة واحدة P_{ij} , بالعودة للمثال 2 ما هو احتمال الوصول من الحالة 0 لنفسها بعد حركتين

$$P_{00}^{(2)} = ?$$



$$P(X_2 = 0 | X_0 = 0) = P\left((X_1 = 0 | X_0 = 0 \cap X_2 = 0 | X_1 = 0) \cup (X_1 = 1 | X_0 = 0 \cap X_2 = 0 | X_1 = 1) \right)$$

$$= P_{00}P_{00} + P_{01}P_{10}$$



$$P^2 = \left(\begin{bmatrix} P_{00} & P_{01} \\ P_{10} & P_{11} \end{bmatrix} \right)^2 = \begin{bmatrix} P_{00}^2 + P_{01}P_{10} & P_{00}P_{01} + P_{01}P_{11} \\ P_{10}P_{00} + P_{11}P_{10} & P_{10}P_{01} + P_{11}^2 \end{bmatrix}$$

- احتمال الانتقال ب n خطوة هو احتمالية الانتقال من الحالة i للحالة j ب n خطوة.

$$P_{ij}^{(n)} = P(X_n = j | X_0 = i) \quad n, i, j = 0, 1, 2, \dots$$

- يمكن الحصول على مصفوفة الانتقال من المرتبة n عن طريق رفع مصفوفة الانتقال بخطوة واحدة للمرتبة n .

$$P^{(n)} = P^n$$

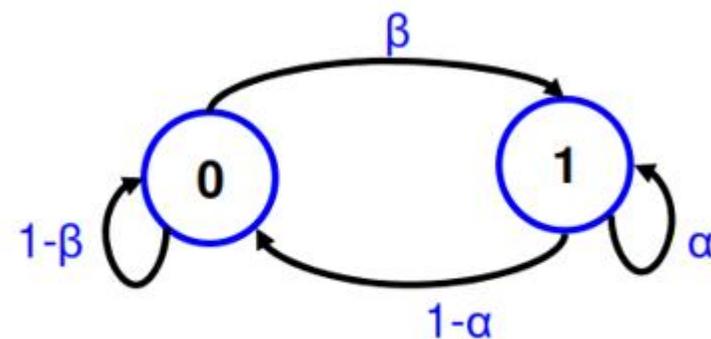
مثال:

بالعودة للمثال المتعلق بالطقس, وفي حال كانت $\alpha=0.7$ و $\beta=0.4$, ما احتمال عدم هطول المطر بعد اربعة ايام من الان مع العلم انها لا تمطر اليوم؟

$$P^{(4)} = P^4 = P^2 P^2$$

$$P^{(4)} = \begin{bmatrix} 0.4332 & 0.5668 \\ 0.4251 & 0.5749 \end{bmatrix}$$

$$P_{00}^{(4)} = 0.4332$$



التوزيع الاحتمالي غير المشروط Unconditional probability distribution

- لحد الان كنا نتعامل مع احتمالية مشروطة $P_{ij}^{(n)}$ كيف يمكن حساب احتمال كون النظام في الحالة زفي اللحظة n دون معرفة الحالة البدائية؟

$$P(X_n = j) = ?$$

- يجب تحديد التوزيع الاحتمالي الابتدائي للحالات كافة.

$$P(X_0 = i) = \pi_0(i)$$

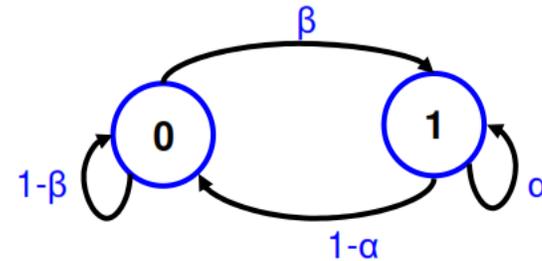
$$P(X_1 = j) = ?$$

$$P(X_1 = 1) = P(X_0 = 0).P(X_1 = 1 | X_0 = 0) + P(X_0 = 1).P(X_1 = 1 | X_0 = 1)$$

$$P(X_1 = 1) = \pi_0(0).P_{01} + \pi_0(1).P_{11}$$

$$P(X_1 = 1) = \sum_{i=0}^1 \pi_0(i).P_{i1}$$

$$P(X_1 = 1) = \pi_0(0).\beta + \pi_0(1).\alpha$$



التوزيع الاحتمالي غير المشروط 2: probability distribution

$$P(X_n = j) = ?$$

$$\begin{aligned} P(X_n = j) &= \sum_{i=0}^{\infty} P(X_0 = i) \cdot P(X_n = j | X_0 = i) \\ &= \sum_{i=0}^{\infty} \pi_0(i) P_{ij}^{(n)} \end{aligned}$$

$$P(X_n = j) = [\pi_0(0), \pi_0(1), \dots] \begin{bmatrix} P_{00} & P_{01} & \dots & P_{0j} & \dots \\ P_{10} & P_{11} & \dots & P_{1j} & \dots \\ \vdots & & & & \\ \vdots & & & & \\ P_{i0} & P_{i1} & \dots & P_{ij} & \dots \\ \vdots & & & & \\ \vdots & & & & \end{bmatrix}^n$$

يمكن الحصول على النتيجة بضرب الشعاع π بالعمود رقم j من المصفوفة $P^{(n)}$

تصنيف الحالات :Classification of States

حالات يمكن الوصول لها :Reachable (accessible) state

يقال عن الحالة z انها قابلة للوصول من الحالة i عندما:

$$P_{ij}^{(n)} > 0 \text{ for some } n > 0 \quad i \rightarrow j$$

عندما يمكن الوصول للحالات i و z من كل منهما يقال انهما على اتصال communicate أي $z \leftrightarrow i$

إذا لم يكن الوصول من i الى z يكون

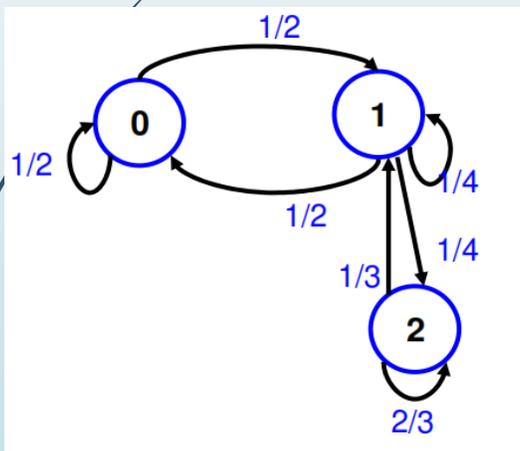
$$\sum_{n=1}^{\infty} P_{ij}^{(n)} = 0$$

يقال عن سلسلة ماركوف انها غير قابلة للتجزئ irreducible إذا كانت جميع حالاتها متصلة ببعضها.

الحالتان المتصلتان يكونان في صف واحد. وعليه تكون سلسلة ماركوف غير قابلة للتجزئ إذا شكلت جميع حالاتها صف واحد.

مثال:

$$P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{4} \\ 0 & \frac{1}{3} & \frac{2}{3} \end{bmatrix}$$



- ▶ لتكن سلسلة ماركوف المكونة من ثلاث حالات 0, 1, 2 ولها المصفوفة التالية.
- ▶ من الوهلة الاولى قد تعتقد انه لا يمكن الوصول من الحالة 0 للحالة 2.

$0 \rightarrow 1$ and $1 \rightarrow 2$ so $0 \rightarrow 2$

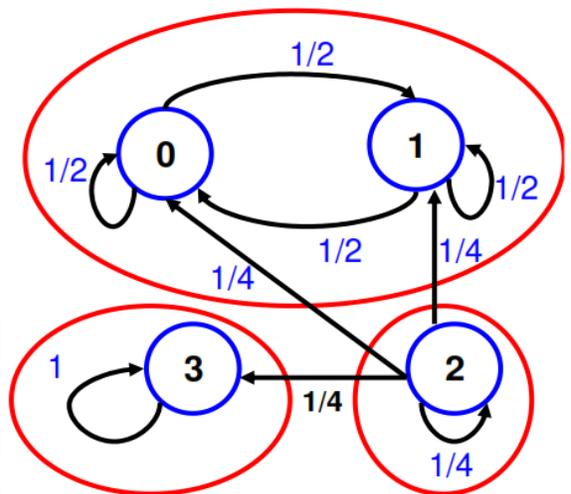
or:

$$P^{(2)} = P^2 = \begin{bmatrix} 0.5000 & 0.3750 & 0.1250 \\ 0.3750 & 0.3958 & 0.2292 \\ 0.1667 & 0.3056 & 0.5278 \end{bmatrix}$$

$P_{ij}^{(2)} > 0$ M.C. is irreducible

مثال :

$$P = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 & 0 \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \\ 0 & 0 & 0 & 1 \end{pmatrix}$$



► M.C. is not irreducible

► Class 1 $S_1 = \{0, 1\}$

► Class 2 $S_2 = \{3\}$

► Class 3 $S_3 = \{2\}$

► السلسلة هي سلسلة قابلة للتجزئ، والحالة 3 تدعى حالة ماصة إذ لا يمكن الانتقال منها لحالة أخرى.

تصنيف الحالات :Classification of States

2

➤ الحالات الماصة absorbing states:

➤ يقال عن الحالة زانها حالة ماصة عندما يكون $P_{jj} = 1$

➤ حالما يتم الوصول لها لا يمكن المغادرة.

➤ الحالات الدورية وغير الدورية periodic and aperiodic states:

➤ تعرف الحالة الدورية ز بكونها $d(j) = \gcd\{n \geq 1 : P_{jj}^{(n)} > 0\}$

➤ اذا كان $d(i) > 1$ فالحالة دورية periodic واذا كان $d(i) = 1$ فالحالة غير دورية aperiodic

➤ اذا كان $P_{ii} > 0$ فالحالة ز غير دورية إذ يمكن للنظام أن يبقى فيها فترة غير محددة

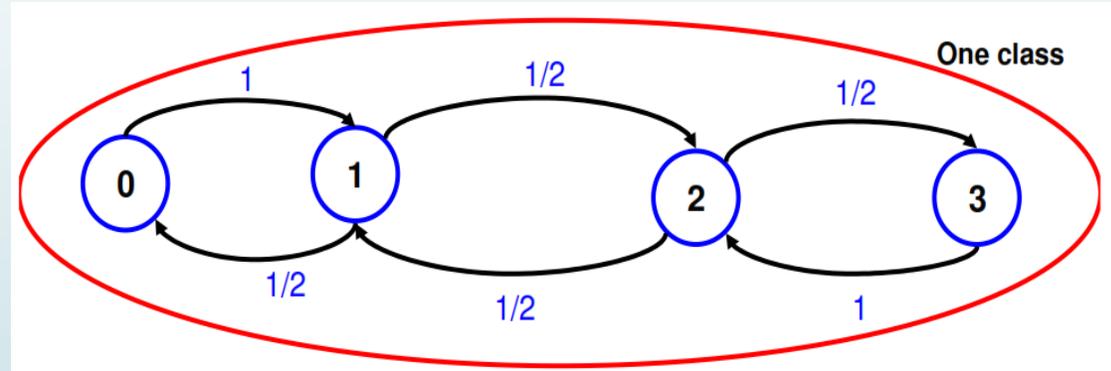
$$\text{if } P_{ii}^{(n)} = 0 \quad \forall n \Rightarrow d(i) = 0$$

➤ يقال عن سلسلة ماركوف انها غير دورية اذا كانت جميع حالاتها غير دورية

Symmetric random walk with reflecting boundaries (ver. 1):

يسير شخص على طول خط مستقيم وفي كل مرحلة يخطو خطوة لليمين باحتمال 0.5 ولليسار باحتمال 0.5, يبدأ هذا الشخص باحد المواقع التالية: 0, 1, 2, 3 عند وصوله للحالة 0 أو 3 توجه حركته تلقائيا للحالة 1 أو 2 باحتمال مكافئ لـ 1.

$$\begin{pmatrix} 0 & 1 & 0 & 0 \\ 1/2 & 0 & 1/2 & 0 \\ 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$



السلسلة متناظرة Symmetric كون احتمال الذهاب إلى أي اتجاه متساوي. ذات حدود انعكاسية Reflecting عند وصول المتحرك لأحد الحواف سوف يرتد مباشرة.

غير قابلة للتجزئ Irreducible كونه من الممكن الانتقال من أي حالة للأخرى خلال عدد محدود من النقلات. دورية Periodic بدور $\gcd\{2,4,6,8..\}=2$

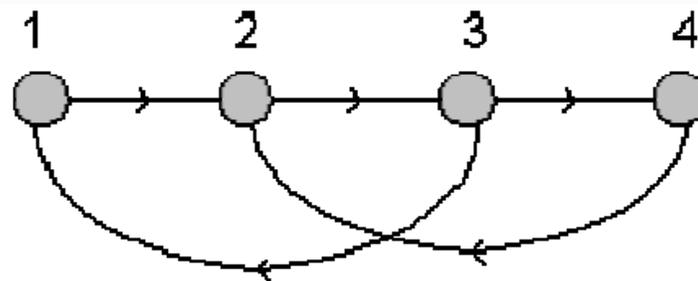
Symmetric random walk (ver. 2):

$$\begin{pmatrix} 1/2 & 1/2 & 0 & 0 \\ 1/2 & 0 & 1/2 & 0 \\ 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 1/2 & 1/2 \end{pmatrix}$$

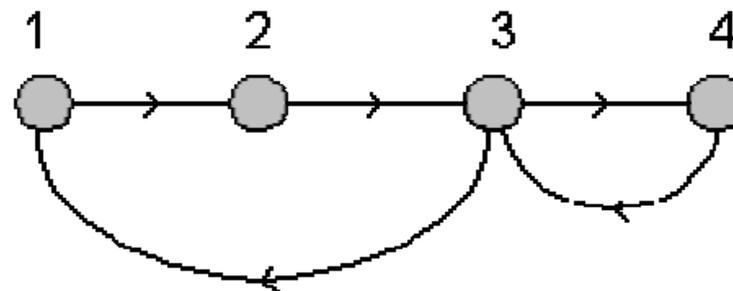
- غير قابلة للتجزئ.
- الحالة 0 غير دورية $P_{00} > 0$
- الحالة 1 غير دورية $d = \gcd\{2, 3, 4, \dots\} = 1$
- الحالة 2 غير دورية $d = \gcd\{2, 3, 4, \dots\} = 1$
- الحالة 3 غير دورية $P_{33} > 0$
- السلسلة قابلة للتجزئ، reducible و غير دورية aperiodic

مثال:

- كل حالة في سلسلة غير قابلة للتجزئ لها نفس الدور.
- سلسلة ماركوف غير القابلة للتجزئ غير دورية في حال كانت احد حالاتها غير دورية.



irreducible $d(1) = \text{g.c.d.}\{3, 6, 9, \dots\} = 3.$



irreducible $d(1) = \text{g.c.d.}\{3, 5, 7, 9, \dots\} = 1.$

مثال:

$$P = \begin{pmatrix} 1/2 & 1/4 & 1/4 \\ 0 & 1/2 & 1/2 \\ 1 & 0 & 0 \end{pmatrix}.$$

- ▶ السلسلة غير قابلة للتجزئ، كونه من الممكن الانتقال من اي حالة للاخرى في عدد محدد من الخطوات باحتمال غير صفري.
- ▶ بما ان $P_{00} > 0$ فالحالة 0 غير دورية
- ▶ بما ان السلسلة غير قابلة للتجزئ، هذا يعني ان كل الحالات غير دورية وبالتالي السلسلة غير دورية وغير قابلة للتجزئ.

تصنيف الحالات :Classification of States

3

الحالات المتكررة والعبارة :Recurrent and transient States

الحالات المتكررة والعبارة :Recurrent and transient States

لتكن $A(i)$ مجموعة الحالات الممكن الوصول لها من الحالة i . نقول عن i أنها حالة متكررة recurrent إذا كان من اجل كل حالة j ممكنة الوصول من i يمكن الوصول منها ايضا للحالة j .

من اجل كل j منتمية الى $A(i)$ يوجد $A(j)$ تتبع

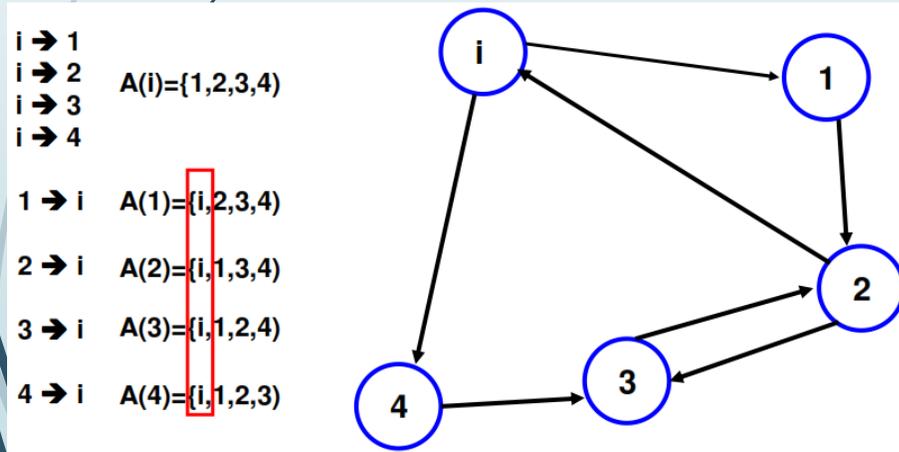
إذا تمت زيارة الحالة المتكررة recurrent مرة واحدة فسيتم

زيارتها عددا غير محدد من المرات.

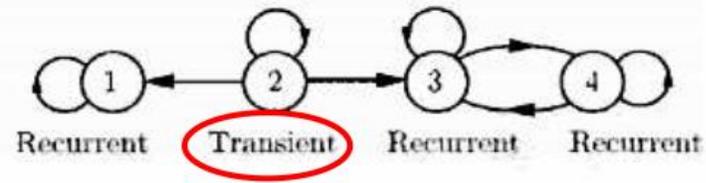
الحالة i حالة عبارة transient اذا وجدت حالة j تنتمي

إلى $A(i)$ لا يمكن منها الوصول للحالة i .

الحالة العبارة سيتم زيارتها عددا محددًا من المرات فحسب.



Examples:



Classification of states given the transition probability graph. Starting from state 1, the only accessible state is itself, and so 1 is a recurrent state. States 1, 3, and 4 are accessible from 2, but 2 is not accessible from any of them, so state 2 is transient. States 3 and 4 are accessible from each other, and they are both recurrent.

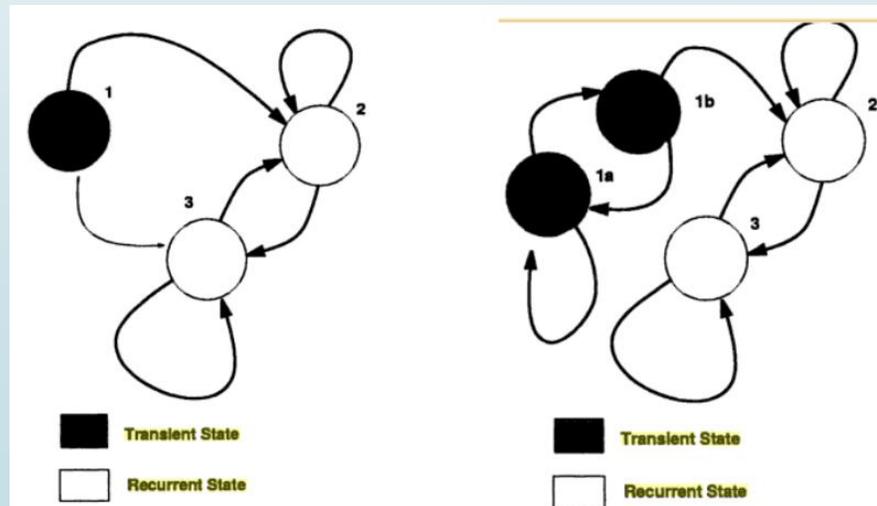
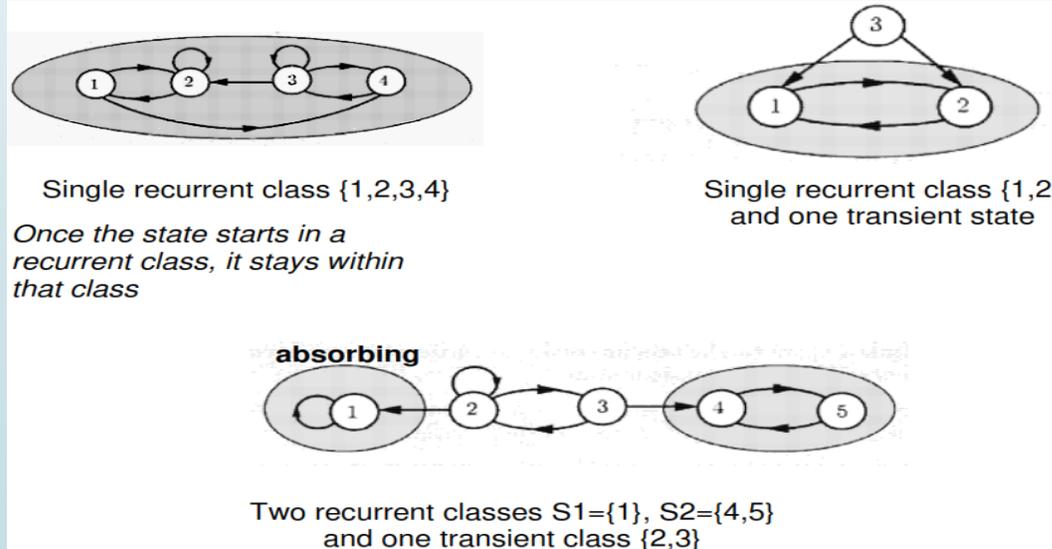


Figure 8.7. A Markov chain with one transient state

Figure 8.8. A Markov chain with two transient states

تفكيك سلاسل ماركوف Markov chains decomposition

- يمكن تفكيك سلسلة ماركوف إلى صف واحد متكرر على الأقل ومجموعة من الصفوف العابرة
- الحالة المتكررة يمكن الوصول لها من جميع الحالات في صفها لكن لا يمكن الوصول لها من الحالات المتكررة خارج صفها.
- الحالة العابرة لا يمكن الوصول لها من اي حالة متكررة.
- حالة متكررة واحدة على الأقل وربما اكثر يمكن الوصول لها من حالة عابرة.



التوزيع المستقر Stationary Distribution:

► احتمال كون سلسلة ماركوف في الحالة z في الخطوة رقم n يعطى بالعلاقة:

$$P(X_n = j) = \pi_n(j)$$

► التوزيع الاولي للحالات $0, 1, 2, 3, \dots$

$$P(X_0 = j) = \pi_0(j), \quad j = 0, 1, 2$$

► يقال عن سلسلة ماركوف المتقطعة ان لها توزيعاً احتمالياً مستقراً $\pi = \{\pi_0, \pi_1, \dots\}$ اذا كانت المعادلة المصفوفية التالية محققة:

$$\pi = \pi P$$

بحيث

$$\pi_j \geq 0 \quad \pi_j = \sum_{i=0}^{\infty} \pi_i P_{ij}, \quad j \geq 0, \quad \sum_{j=0}^{\infty} \pi_j = 1$$

$$\pi_0(j) = \pi_n(j) = \pi_j \quad \text{for } j = 0, 1, 2, \dots$$

مثال:

► اوجد التوزيع الاحتمالي المستقر لسلسلة ماركوف ذات مصفوفة الانتقال التالية:

$$P = \begin{pmatrix} 0.8 & 0.2 \\ 0.6 & 0.4 \end{pmatrix}$$

$$\pi = \pi.P$$

$$[\pi_0 \quad \pi_1] = [\pi_0 \quad \pi_1] \begin{bmatrix} P_{00} & P_{01} \\ P_{10} & P_{11} \end{bmatrix}$$

$$[\pi_0 \quad \pi_1] = [\pi_0 \quad \pi_1] \begin{bmatrix} 0.8 & 0.2 \\ 0.6 & 0.4 \end{bmatrix}$$

$$\pi_0 = 0.8\pi_0 + 0.6\pi_1$$

$$\pi_1 = 0.2\pi_0 + 0.4\pi_1$$

$$\pi_0 + \pi_1 = 1$$

$$\pi_0 = \frac{3}{4}$$

$$\pi_1 = \frac{1}{4}$$

مثال Alice and probability class:

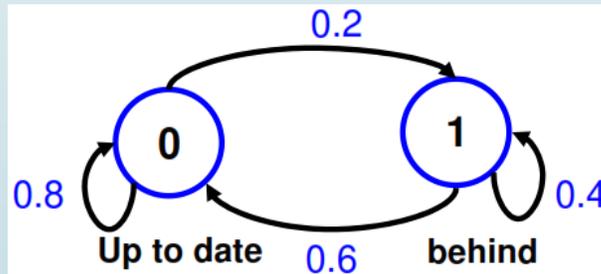
تحضر اليبس مقررا في الاحتمالات وفي كل اسبوع يمكن ان تكون متابعة up-to-date أو أن تكون متخلفة fallen behind اذا كانت متابعة في اسبوع ما فانها ستكون متابعة في الاسبوع التالي باحتمال 0.8 أو متخلفة باحتمال 0.2 واذا كانت متخلفة ستكون متابعة باحتمال 0.6 او متأخرة باحتمال 0.4.

بفرض ان الاحتمالات السابقة لا علاقة لها بالحالات في الاسبوع الماضية, لذلك للمشكلة خصائص سلسلة ماركوف المعتادة اعتماد المستقبل على الماضي فقط من خلال الحاضر.

State 0: up to date

State 1: behind

مصفوفة الانتقال:



$$P = \begin{pmatrix} 0.8 & 0.2 \\ 0.6 & 0.4 \end{pmatrix}$$

مثال Alice and probability class 2:

$$P^{(2)} = \begin{pmatrix} 0.76 & 0.24 \\ 0.72 & 0.28 \end{pmatrix}$$

$$P^{(3)} = \begin{pmatrix} 0.7520 & 0.2480 \\ 0.7440 & 0.2560 \end{pmatrix}$$

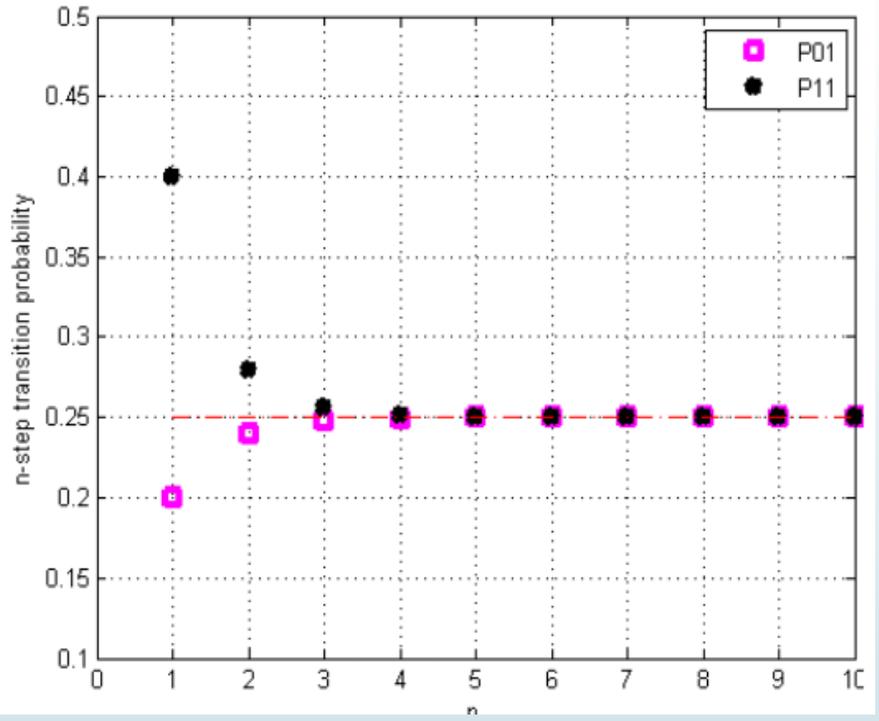
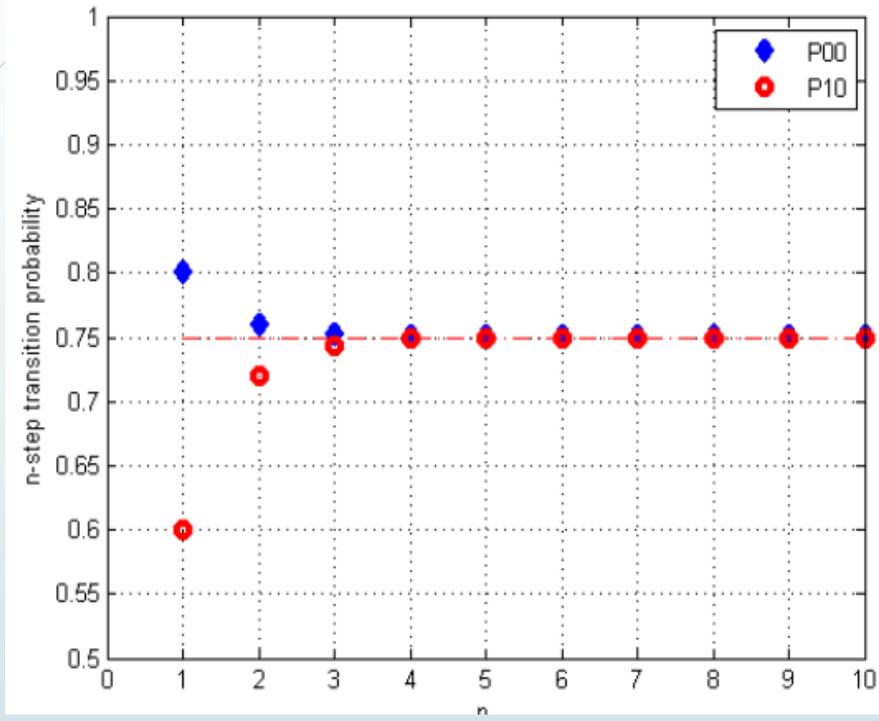
$$P^{(4)} = \begin{pmatrix} 0.7504 & 0.2496 \\ 0.7488 & 0.2512 \end{pmatrix}$$

$$P^{(5)} = \begin{pmatrix} 0.7501 & 0.2499 \\ 0.7498 & 0.2502 \end{pmatrix}$$

$$P^{(6)} = \begin{pmatrix} \boxed{0.7500} & \boxed{0.2500} \\ \boxed{0.7500} & \boxed{0.2500} \end{pmatrix}$$

$$P^{(\infty)} = \begin{pmatrix} \boxed{0.7500} & \boxed{0.2500} \\ \boxed{0.7500} & \boxed{0.2500} \end{pmatrix}$$

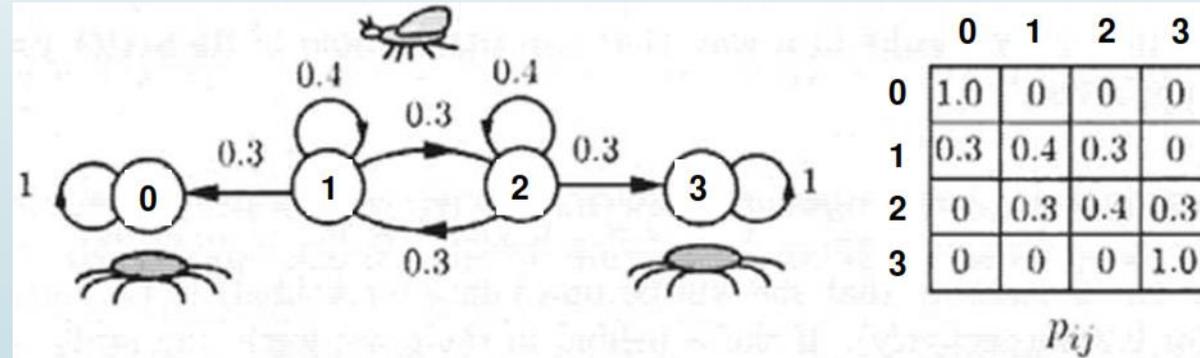
مثال Alice and probability class 3:



- تعمد الاحتمالية P_{ij} على الحالة البدائية عندما تكون n صغيرة
- خلال وقت طويل نسبيا, يصبح من الممكن التخلي عن تأثير الحالات البدائية
- عندما تسعي P للانهاية تتقارب إلى نهاية $P_{ij}^{(n)}$

مثال العناكب والذباب:

- تتحرك ذبابة على طول خط مستقيم في زيادات موحدة. في كل فترة زمنية تتحرك وحدة لليسار باحتمال 0.3 او وحدة لليمين باحتمال 0.3 وتبقى في مكانها باحتمال 0.4 بشكل مستقل عن تحركاتها السابقة. يوجد عنكبوت في كل من الموقعين 1 و m. في حال وصول الذبابة لاحدى الموقعين سوف تمسك من قبل العنكبوت وستنتهي الاجرائية كون سلسلة ماركوف على فرض الذبابة تبدأ في احد الموقعين 1 أو m.



مثال العناكب والذبابة 2:

$$P^{(2)} = \begin{pmatrix} 1.00 & 0 & 0 & 0 \\ 0.42 & 0.25 & 0.24 & 0.09 \\ 0.09 & 0.24 & 0.25 & 0.42 \\ 0 & 0 & 0 & 1.00 \end{pmatrix}$$

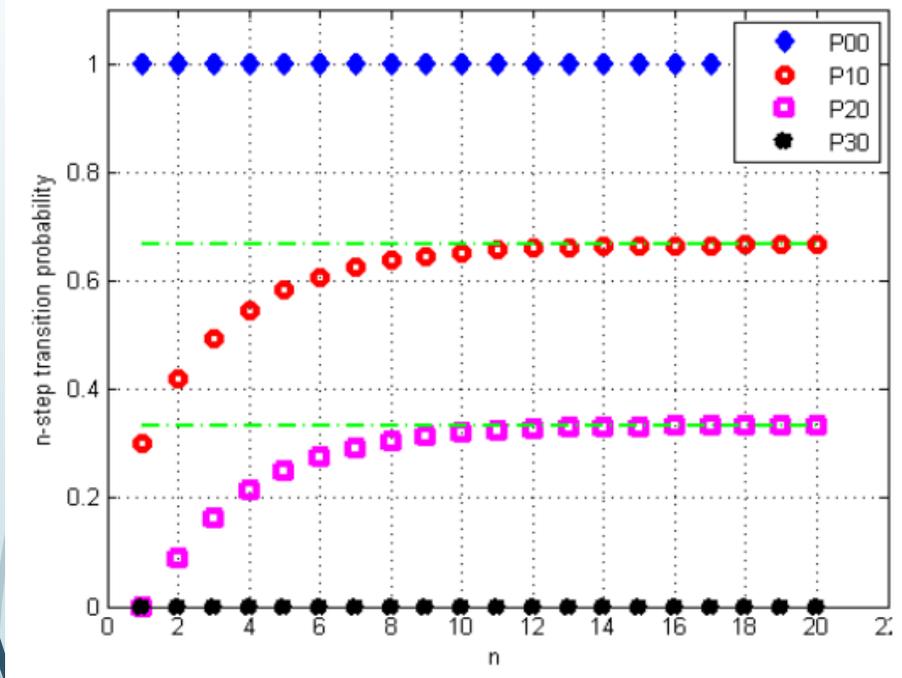
$$P^{(3)} = \begin{pmatrix} 1.00 & 0 & 0 & 0 \\ 0.49 & 0.17 & 0.17 & 0.16 \\ 0.16 & 0.17 & 0.17 & 0.49 \\ 0 & 0 & 0 & 1.00 \end{pmatrix}$$

$$P^{(4)} = \begin{pmatrix} 1.00 & 0 & 0 & 0 \\ 0.54 & 0.12 & 0.12 & 0.21 \\ 0.21 & 0.12 & 0.12 & 0.54 \\ 0 & 0 & 0 & 1.00 \end{pmatrix}$$

$$P^{(100)} = \begin{pmatrix} 1.00 & 0 & 0 & 0 \\ 0.6667 & 0 & 0 & 0.3333 \\ 0.3333 & 0 & 0 & 0.6667 \\ 0 & 0 & 0 & 1.00 \end{pmatrix}$$

$$P^{(\infty)} = \begin{pmatrix} 1.00 & 0 & 0 & 0 \\ 0.6667 & 0 & 0 & 0.3333 \\ 0.3333 & 0 & 0 & 0.6667 \\ 0 & 0 & 0 & 1.00 \end{pmatrix}$$

مثال العناكب والذبابة 3:



الحالات 0 و 3 هي حالات ماصة عند دخولها ستتكرر بشكل غير منتهي, عند الوصول للحالة 3 فان احتمال الوصول منها للحالة 0 هو 0.

عندما تسعى n للانهاية:

تتفارب الاحتمالية P_{ij} لنهاية معتمدة على الحالة البدائية.

احتمال الوصول الى حالة ماصة معينة تعتمد على مدى القرب منها في البداية, فمثلا الحالة 1 اقرب للحالة 0 من الحالة 2 وعليه $P_{10} > P_{20}$.

احتمالية الوجود في الحالات العابرة 1 و 2 تنتهي للصفر (العمودين 2 و 3)

مثال العناكب والذبابة:4

- تخبرنا نهاية الاحتمال $\lim_{n \rightarrow \infty} P_{ij}^{(n)}$ عن سلوك الحالة المستقرة steady-state أو (long-run) للاجرائية, تعرف احتمالية الحالة المستقرة للحالة i كالتالي:

$$\pi_j = \lim_{n \rightarrow \infty} P(X_n = j)$$

- تقدم لنا آلية للتنبؤ بعمل النظام الذي تتمذجة الاجرائية بالمعدل المتوسط.
- غذا كانت الحالة هي حالة عابرة فإن هذه النهاية هي المعامل الخاطئ لنسأل عنه لان هذه النهاية هي 0.
- في حال وجود صفين متكررين او اكثر يجب ان تعتمد قيمة $\lim_{n \rightarrow \infty} P_{ij}^{(n)}$ على الحالة البدائية (امكانية زيارة j في المستقبل تعتمد على كونها في نفس صف الحالة البدائية i).
- سلاسل ماركوف التي تتكون من صف متكرر وحيد قد لا تتقارب may fail to converge



Any Questions?