

# Procesy stochastyczne

## WYKŁAD 2 - 3

### Łańcuchy Markowa

Łańcuchy Markowa to procesy "bez pamięci" w których czas i stany są zbiorami dyskretnymi.



Andrei A. Markov 1856 - 1922

Rosyjski matematyk.

## Przykład.

$A_1, \dots, A_n$  - wierzchołki  $n$ -kąta foremnego. Punkt losowo porusza się po tych wierzchołkach.

Czy jest łańcuchem Markowa ciąg położenia punktu gdy

- a) punkt porusza się w sposób zdeterminowany zgodnie z ruchem wskazówek zegara, (tak)
- b) punkt losowo wybiera kierunek i dalej porusza się w wybranym kierunku, (nie)

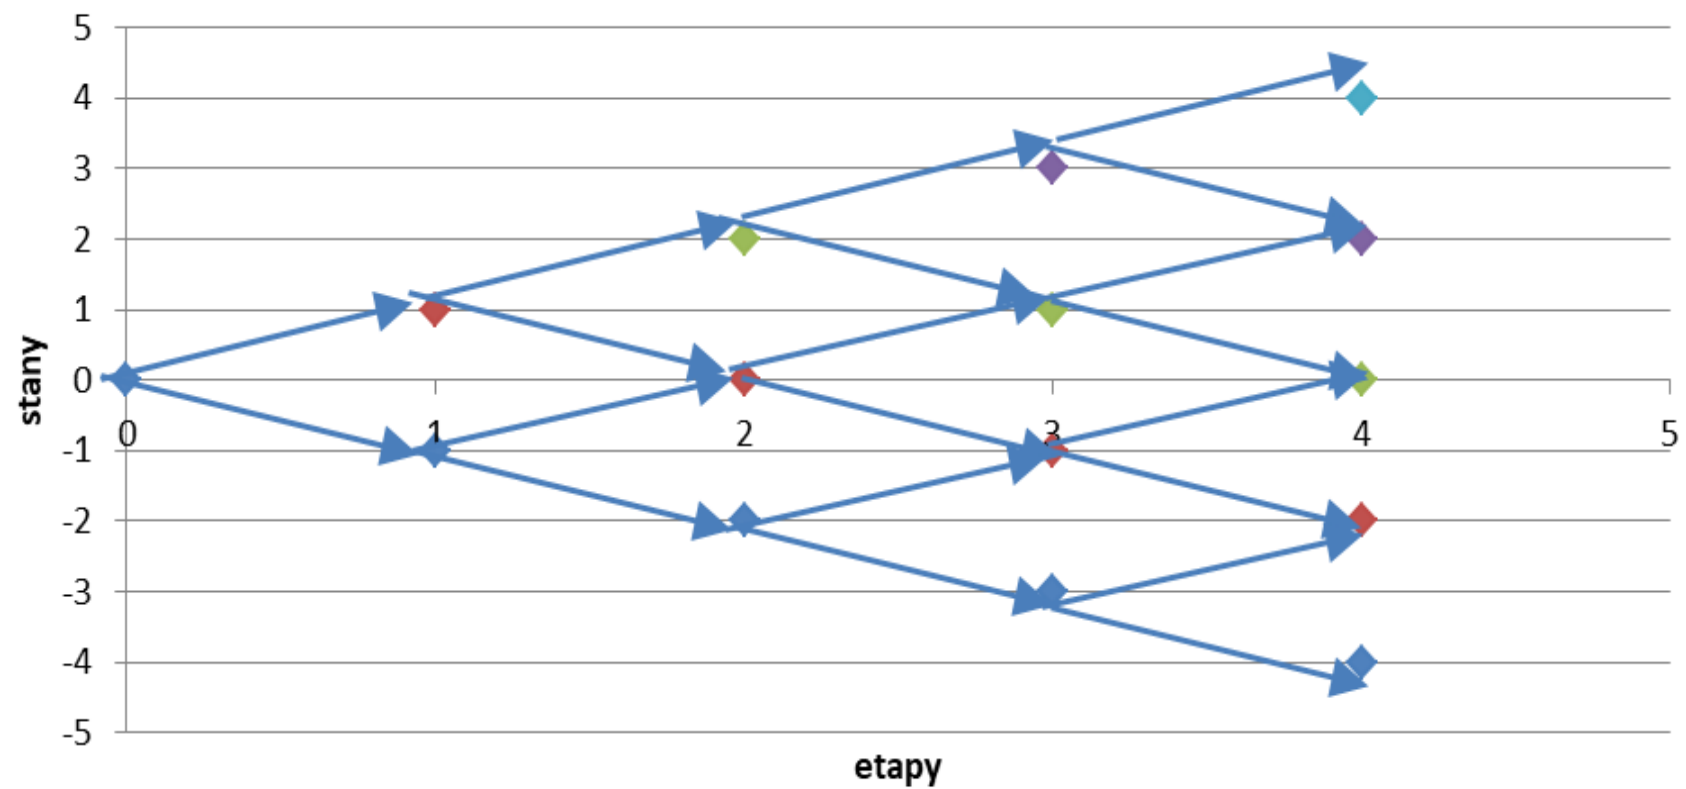
## **Przykład**

Symetryczne błądzenie przypadkowe na prostej.

Stan początkowy to 0.

Rzucamy symetryczną monetą, jeśli wypadł „orzeł” to przechodzimy o jedną jednostkę w prawo, jeśli wypadła „reszka” to przechodzimy o jedną jednostkę w lewo.


# Błądzenie symetryczne



Przykładowa realizacja:

(0, 1, 2, 1, 0, -1, 0, 1, 2, 3, 2, 3, 2, 1, 0, -1, 0, -1, -2, .....)

i jej obraz graficzny



Zauważmy, realizacji jest nieskończenie wiele.

Jest to proces  $X = (X_0, X_1, X_2, X_3, X_4, \dots)$

Jakie są rozkłady jednowymiarowe tego procesu?

Jaka jest przestrzeń stanów tego procesu?

$X_0$  ma rozkład jednopunktowy.

$X_1$  ma rozkład:

<b>-1</b>	<b>1</b>
<b>1/2</b>	<b>1/2</b>

$X_2$  ma rozkład:

<b>-2</b>	<b>0</b>	<b>2</b>

$X_3$  ma rozkład:

<b>-3</b>	<b>-1</b>	<b>1</b>	<b>3</b>

$X_4$  ma rozkład:

<b>-4</b>	<b>-2</b>	<b>0</b>	<b>2</b>	<b>4</b>



$X_1$  ma rozkład:

<b>-1</b>	<b>1</b>
<b>1/2</b>	<b>1/2</b>

$X_2$  ma rozkład:

<b>-2</b>	<b>0</b>	<b>2</b>
<b>1/4</b>	<b>1/2</b>	<b>1/4</b>

$X_3$  ma rozkład:

<b>-3</b>	<b>-1</b>	<b>1</b>	<b>3</b>
<b>1/8</b>	<b>3/8</b>	<b>3/8</b>	<b>1/8</b>

$X_4$  ma rozkład:

<b>-4</b>	<b>-2</b>	<b>0</b>	<b>2</b>	<b>4</b>
<b>1/16</b>	<b>4/16</b>	<b>6/16</b>	<b>4/16</b>	<b>1/16</b>

Zauważmy, że prawdopodobieństwa wynikają z rozkładu dwumianowego.

**Łańcuchem Markowa** nazywamy proces będący ciągiem zmiennych losowych

$$X_0, X_1, \dots$$

Określonych na wspólnej przestrzeni probabilistycznej, przyjmujących wartości całkowite ze zbioru  $S$  i spełniające warunek

$$\begin{aligned} P(X_n = j_n | X_0 = i_0, X_1 = i_1, \dots, X_{n-1} = i_{n-1}) = \\ = P(X_n = j_n | X_{n-1} = i_{n-1}) \quad \bigwedge_n \quad \bigwedge_{i_0, \dots, i_{n-1}, j_n \in S} \end{aligned}$$

Zatem dla łańcucha Markowa rozkład prawdopodobieństwa warunkowego położenia w  $n$ -tym kroku zależy tylko od prawdopodobieństwa warunkowego położenia w kroku poprzednim a nie od wcześniejszych punktów trajektorii (historia).

Niech

$$p_{ij}^{(n)} = P(X_n = j | X_{n-1} = i)$$

oznacza prawdopodobieństwo przejścia w n-tym kroku ze stanu i do stanu j.

Jeśli  $p_{ij}^{(n)}$  nie zależą od n to łańcuch nazywamy **jednorodnym** i stosujemy

zapis  $p_{ij}$ .

$$P(X_n = j | X_{n-1} = i) = P(X_1 = j | X_0 = i) = p_{ij}$$

Zakładając, że numery stanów są całkowite, nieujemne można prawdopodobieństwa przejść zapisać w macierzy

$$P^{(n)} = \begin{bmatrix} P_{00}^{(n)} & P_{01}^{(n)} & \dots \\ P_{10}^{(n)} & P_{11}^{(n)} & \dots \\ \dots & \dots & \dots \end{bmatrix}$$

Dla łańcuchów jednorodnych powyższą macierz oznaczamy  $P$ .

Dla łańcuchów **jednorodnych** i stanów

**0, 1, 2, ..., N**

macierz  $P$  ma postać:

$$P = \begin{bmatrix} p_{00} & p_{01} & \cdots & p_{0N} \\ p_{10} & p_{11} & \cdots & p_{1N} \\ \cdots & \cdots & \cdots & \cdots \\ p_{N0} & p_{N1} & \cdots & p_{NN} \end{bmatrix}$$

**Dalej rozpatrujemy tylko łańcuchy jednorodne.**

Własności macierzy prawdopodobieństw przejść:

a)  $p_{ij} \geq 0$

b) suma **każdego** wiersza jest równa 1.


tzn.  $\forall i \quad \sum_j p_{ij} = 1$

Każdą macierz spełniającą warunki a), b) nazywamy **macierzą stochastyczną**.

Każdej macierzy stochastycznej odpowiada graf łańcucha Markowa i odwrotnie.

Przykład

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



### Uwaga (prawdopodobieństwo trajektorii)

$$\begin{aligned} P(X_n = i_n, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0) &= \\ &= P(X_n = i_n | X_{n-1} = i_{n-1}) P(X_{n-1} = i_{n-1} | X_{n-2} = i_{n-2}) \dots P(X_1 = i_1 | X_0 = i_0) P(X_0 = i_0) = \\ &= p_{i_{n-1}i_n} p_{i_{n-2}i_{n-1}} \dots p_{i_0i_1} p_{i_0} \\ &\quad \bigwedge_n \quad \bigwedge_{i_0, \dots, i_{n-1}, i_n \in S} \end{aligned}$$



Wniosek (z tw. o prawdopodobieństwie całkowitym)

$$\begin{aligned} P(X_1 = i) &= \sum_{j \in S} P(X_1 = i, X_0 = j) = \sum_{j \in S} P(X_1 = i | X_0 = j) P(X_0 = j) = \\ &= \sum_{j \in S} p_{ji} P(X_0 = j) \\ &\quad \bigwedge_{i \in S} \end{aligned}$$

Co oznacza, że rozkład łańcucha po pierwszym kroku uzyskamy mnożąc rozkład początkowy przez macierz P.

$$p(1) = p(0)P$$

gdzie  $p(1) = (p_0(1), p_1(1), \dots, p_N(1))$ ,  $p(0) = (p_0(0), p_1(0), \dots, p_N(0))$

Własność tą uogólnimy w dalszej części wykładu.

**Uwaga.**

Macierz stochastyczna (lub odpowiadający jej graf) i rozkład zmiennej losowej  $X_0$  określają pewien łańcuch Markowa.

Własności macierzy stochastycznych są zatem ściśle związane z własnościami łańcuchów Markowa.

## Własności macierzy stochastycznych.

A - dowolna macierz kwadratowa stopnia r.

**Wielomianem charakterystycznym** tej macierzy nazywamy wielomian

$$W(\lambda) = \det(\lambda I - A)$$

Równanie  $W(\lambda) = 0$  nazywamy **równaniem charakterystycznym**.

Pierwiastki tego równania to **wartości własne** lub pierwiastki charakterystyczne tej macierzy.

Niech  $\lambda_1, \dots, \lambda_k$  - wartości własne macierzy

A o krotnościach  $\alpha_1, \dots, \alpha_k$  ( $k \leq r$ ).

Równanie charakterystyczne ma r rozwiązań (mogą być zespolone, mogą być wielokrotne).

## **Własność:**

- I) suma wartości własnych (z krotnościami) jest równa śladowi macierzy tzn. sumie elementów jej przekątnej.
- II) Macierz jest osobliwa wtedy i tylko wtedy, gdy zero jest jej wartością własną

Przykład.

Macierz  $P = \begin{bmatrix} \frac{1}{4} & \frac{3}{4} \\ \frac{2}{3} & \frac{1}{3} \end{bmatrix}$  ma równanie charakterystyczne

$$W(\lambda) = \det \begin{bmatrix} \lambda - \frac{1}{4} & -\frac{3}{4} \\ -\frac{2}{3} & \lambda - \frac{1}{3} \end{bmatrix} = \lambda^2 - \lambda \frac{7}{12} - \frac{5}{12} = 0$$

i wartości własne:

$$\lambda_1 = 1, \quad \lambda_2 = \frac{-5}{12}.$$

## Własności macierzy stochastycznych:

a) Wartością własną każdej macierzy stochastycznej jest  $\lambda = 1$  (oznaczamy  $\lambda_1 = 1$ ),

b) Moduły wszystkich wartości własnych dowolnej macierzy stochastycznej są mniejsze lub równe 1,

c) Średnia arytmetyczna i iloczyn dwóch macierzy stochastycznych tego samego stopnia są także macierzami stochastycznymi.

d) (tw. Dooba ) istnieje granica  $\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n P^k = A$ ,

Macierz  $A$  ma własność  $PA = AP = A = A^2$  (macierz idempotentna),

## Klasyfikacja macierzy stochastycznych.

	$\alpha_1 = 1$	$\alpha_1 > 1$
$\bigwedge_{i>1}  \lambda_i  \neq 1$	<b>Regularne</b> (tzn. nierozkładalne i niecykliczne)	rozkładalne niecykliczne
$\bigvee_{i>1}  \lambda_i  = 1$	nierozkładalne cykliczne	rozkładalne cykliczne



## Uwaga

W macierzy **rozkładalnej** występują diagonalne podmacierze stochastyczne (ich ilość wynosi  $\alpha_1$ ).

W macierzy **cyklicznej** w kolejnych potęgach okresowo (długość cyklu) pojawiają się bloki zerowe i dodatnie.

Łańcuchy Markowa, których macierz P jest **regularna** nazywamy **ergodycznymi**.

## **Tw. Frecheta (tw. Dooba dla macierzy nierozkładalnych)**

Dla każdej nierozkładalnej macierzy stochastycznej  $P$  istnieje granica

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n P^k = E, \quad (\text{ergodyczność w sensie Cesaro})$$

$$E = \begin{bmatrix} e_1 & e_2 & \cdots & e_r \\ e_1 & e_2 & \cdots & e_r \\ \cdots & \cdots & \cdots & \cdots \\ e_1 & e_2 & \cdots & e_r \end{bmatrix} \quad (\text{macierz ergodyczna})$$

Macierz E ma własność

$$PE = EP = E = E^2$$

i spełnia warunki a), b) definicji macierzy stochastycznej.

Macierz E ma jednokrotną wartość własną równą 1 wartość własną 0 o krotności r-1.

Elementy macierzy E możemy wyznaczyć z warunków:

$$(P^T - I)e^T = 0, \quad \sum_{i=1}^r e_i = 1, \quad \text{gdzie } e = (e_1, \dots, e_r)$$

lub

$$e(P - I) = 0, \quad \sum_{i=1}^r e_i = 1,$$

Powyższe układy równań są oznaczone.


Dla macierzy **regularnych** tw. Dooba ma postać:

**Twierdzenie.**

Jeśli macierz stochastyczna  $P$  jest regularna to istnieje granica

$$\lim_{n \rightarrow \infty} P^n = E, \quad (\text{ergodyczność})$$

gdzie  $E$  - macierz ergodyczna.



Joseph Doob, amerykański matematyk 1910-2004

Stochastyczne macierze regularne charakteryzuje też tzw. twierdzenie ergodyczne:

### **Twierdzenie.**

Jeśli macierz stochastyczna  $P$  jest **regularna** to istnieje taka jej potęga  $w$  której co najmniej jedna kolumna ma wszystkie elementy dodatnie.

## Przykład.

Macierz  $P = \begin{bmatrix} 0,5 & 0 & 0,5 \\ 0 & 0,25 & 0,75 \\ 0,5 & 0,5 & 0 \end{bmatrix}$

ma wartości własne  $\lambda_1 = 1$ ,  $\lambda_2 = \frac{-1 + \sqrt{17}}{8}$ ,  $\lambda_3 = \frac{-1 - \sqrt{17}}{8}$



Do której klasy należy ta macierz?

Jest to macierz **regularna**.

Zauważmy też, że już jej kwadrat ma dodatnie kolumny.

$$P^2 = \begin{bmatrix} 0,5 & 0,25 & 0,25 \\ 0,375 & 0,438 & 0,188 \\ 0,25 & 0,125 & 0,625 \end{bmatrix}$$

eigenvalues {{0.5,0,0.5},{0,0.25,0.75},{0.5,0.5,0}}

 Extended Keyboard  Upload

 Examples  Random

Input:

eigenvalues	$\begin{pmatrix} 0.5 & 0 & 0.5 \\ 0 & 0.25 & 0.75 \\ 0.5 & 0.5 & 0 \end{pmatrix}$
-------------	---

Results:

[Approximate forms](#)

[Step-by-step solution](#)

$$\lambda_1 = 1$$

$$\lambda_2 = \frac{1}{8}(-1 - \sqrt{17})$$

$$\lambda_3 = \frac{1}{8}(\sqrt{17} - 1)$$

Corresponding eigenvectors:

[Approximate forms](#)

[Step-by-step solution](#)

$$v_1 = (1, 1, 1)$$

$$v_2 = \left( -\frac{-1 + \sqrt{17}}{3 + \sqrt{17}}, -\frac{6}{3 + \sqrt{17}}, 1 \right)$$

$$v_3 = \left( -\frac{1 + \sqrt{17}}{-3 + \sqrt{17}}, \frac{6}{-3 + \sqrt{17}}, 1 \right)$$



Dla macierzy **regularnej** wysokie potęgi są zbliżone do macierzy ergodycznej  
(tw. Dooba)



`{{0.5,0,0.5},{0,0.25,0.75},{0.5,0.5,0}}^100`

[Extended Keyboard](#)

[Upload](#)

[Examples](#)

[Random](#)

Input:

$$\begin{pmatrix} 0.5 & 0 & 0.5 \\ 0 & 0.25 & 0.75 \\ 0.5 & 0.5 & 0 \end{pmatrix}^{100}$$

Result:

$$\begin{pmatrix} 0.375 & 0.25 & 0.375 \\ 0.375 & 0.25 & 0.375 \\ 0.375 & 0.25 & 0.375 \end{pmatrix}$$

Prawdopodobieństwa przejścia po  $n$  krokach wyznaczamy obliczając  $P^n$ .

Niekiedy dobrym sposobem jest wykorzystanie **diagonalizacji** macierzy  $P$ .

Jeśli macierz  $P$  ma różne wartości własne to da się przedstawić w postaci

$$P = SJS^{-1}$$

gdzie  $J$  jest macierzą diagonalną złożoną z wartości własnych, kolumny macierzy  $S$  zbudowane są z wektorów własnych.

Wtedy  $P^n = SJ^nS^{-1}$ . Macierz  $J^n$  wyznaczamy obliczając  $n$ -te potęgi wartości własnych.

## Przykład.

System pakietowego przesyłania zdigitalizowanej mowy pracuje w dwóch stanach 0 – cisza, 1 – rozmowa. Pakiety są generowane tylko w stanie 0.

Kontrola stanów odbywa się co 0,01 s.

Proces ma macierz  $P = \begin{bmatrix} 0,95 & 0,05 \\ 0,01 & 0,99 \end{bmatrix}$  i startuje ze stanu 0.

P ma wartości własne  $\lambda_1 = 1$ ,  $\lambda_2 = 0,94$ , więc jest macierzą regularną.

Jakie jest prawdopodobieństwo przejścia ze stanu 0 do 1 po 1s?

## Sposób I (bezpośrednie obliczenie $P^{100}$ )



`{{0.95, 0.05}, {0.01, 0.99}}^100`

Extended Keyboard Upload Examples Random

Input:

$$\begin{pmatrix} 0.95 & 0.05 \\ 0.01 & 0.99 \end{pmatrix}^{100}$$

Result:

$$\begin{pmatrix} 0.168379 & 0.831621 \\ 0.166324 & 0.833676 \end{pmatrix}$$

Zatem  $p_{01}(100) = 0,831621$ .

# Sposób II (wykorzystanie diagonalizacji macierzy P)

## Diagonalizacja



diagonalize {{0.95, 0.05}, {0.01, 0.99}}

Extended Keyboard Upload Examples Random

Input interpretation:

diagonalize	$\begin{pmatrix} 0.95 & 0.05 \\ 0.01 & 0.99 \end{pmatrix}$
-------------	--

Result:

$$M = S.J.S^{-1}$$



where

$$M = \begin{pmatrix} 0.95 & 0.05 \\ 0.01 & 0.99 \end{pmatrix}$$
$$S = \begin{pmatrix} -5 & 1 \\ 1 & 1 \end{pmatrix}$$
$$J = \begin{pmatrix} 0.94 & 0 \\ 0 & 1 \end{pmatrix}$$
$$S^{-1} = \begin{pmatrix} -0.166667 & 0.166667 \\ 0.166667 & 0.833333 \end{pmatrix}$$

Obliczenie  $P^{100}$



$\{\{-5, 1\}, \{1, 1\}\} * \{\{0.94, 0\}, \{0, 1\}\}^{100} * \{\{-5, 1\}, \{1, 1\}\}^{-1}$

 Extended Keyboard    Upload

Input:

$$\begin{pmatrix} -5 & 1 \\ 1 & 1 \end{pmatrix} \cdot \begin{pmatrix} 0.94 & 0 \\ 0 & 1 \end{pmatrix}^{100} \cdot \begin{pmatrix} -5 & 1 \\ 1 & 1 \end{pmatrix}^{-1}$$

Result:

$$\begin{pmatrix} 0.168379 & 0.831621 \\ 0.166324 & 0.833676 \end{pmatrix}$$

Zatem  $p_{01}(100) = 0,831621$ .

### Przykład.

Macierz  $P = \begin{bmatrix} 0 & 0 & 0,5 & 0,5 \\ 0 & 0 & 0,5 & 0,5 \\ 0,5 & 0,5 & 0 & 0 \\ 0,5 & 0,5 & 0 & 0 \end{bmatrix}$

ma wartości własne

$$\lambda_1 = 1, \lambda_2 = -1, \lambda_3 = 0 \text{ o krotności } 2,$$

Do której klasy należy ta macierz?

Jest to macierz cykliczna nierozkładalna.

Macierz ta ma własność  $P^n = \begin{cases} P & \text{gdy } n \text{ nieparzyste} \\ P^2 & \text{gdy } n \text{ parzyste} \end{cases} .$

$$P^2 = \begin{bmatrix} 0,5 & 0,5 & 0 & 0 \\ 0,5 & 0,5 & 0 & 0 \\ 0 & 0 & 0,5 & 0,5 \\ 0 & 0 & 0,5 & 0,5 \end{bmatrix}$$



## Przykład.

Macierz  $P = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{3} & \frac{2}{3} \\ 0 & 0 & 0 & \frac{1}{3} & \frac{2}{3} \\ 0 & 0 & 0 & \frac{1}{4} & \frac{3}{4} \end{bmatrix}$  ma wartości własne  $\lambda_1 = 1$  o krotności 3,  $\lambda_2 = 0$ ,

$\lambda_3 = \frac{1}{12}$ , więc jest macierzą niecykliczną rozkładalną.

Macierz stochastyczna rozkładalna (po ewentualnym przestawieniu wierszy i kolumn) ma bloki diagonalne, które są macierzami stochastycznymi. Wartościami własnymi macierzy  $P$  są wartości własne poszczególnych bloków. W powyższym przykładzie są trzy bloki diagonalne.

## Przykład.

Macierz  $P = \begin{bmatrix} 0,5 & 0,5 & 0 & 0 \\ 0,5 & 0,5 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$  ma wartości własne

$\lambda_1 = 1$  o krotności 2,  $\lambda_2 = 0$ ,  $\lambda_3 = -1$ , więc jest macierzą cykliczną rozkładalną.

## **Macierz przywiedlna.**

Macierz kwadratowa  $A$  (nie musi być stochastyczna) stopnia  $n$  nazywa się **przywiedlna**, jeśli przez odpowiednie permutacje wierszy i kolumn można przekształcić  $P$  do postaci

$$\begin{bmatrix} B & 0 \\ C & D \end{bmatrix}$$

gdzie  $B, D$  są kwadratowe.

W przeciwnym przypadku macierz  $A$  nazywa się **nieprzywiedlna**.

## **Własność**

Macierz dodatnia jest nieprzywiedlna,

Jeśli macierz ma zerowy wiersz lub kolumnę zerową to jest przywiedlna.

Macierz diagonalna lub trójkątna jest przywiedlna.

Jeśli  $A$  jest przywiedlna to  $A^T$  też jest przywiedlna.

Własności LM zależne od własności macierzy P.

**P - regularna, nieprzywiedlna.**



Ł. ergodyczny, rozkład gr. nie zależy od r. początkowego, jeden dodatni r. stacjonarny.

**P - regularna, przywiedlna.**



Ł. ergodyczny, rozkład gr. nie zależy od r. początkowego, jeden nieujemny r. stacjonarny.

**P - nierozkładalna, cykliczna, nieprzywiedlna.**



Ł. ergodyczny w sensie Cesaro,  
jeden dodatni rozkład stacjonarny.

**P - nierozkładalna, cykliczna, przywiedlna.**



Ł. ergodyczny w sensie Cesaro,  
jeden nieujemny rozkład stacjonarny.



**P - rozkładalna, niecykliczna.**



Ł. nieergodyczny, rozkład gr. **zależy** od rozkładu początkowego, wiele rozkładów stacjonarnych.

**P - rozkładalna, cykliczna.**



Ł. nieergodyczny, rozkład gr. **zależy** od rozkładu początkowego, wiele rozkładów stacjonarnych.

## **Łańcuchy Markowa (jednorodne).**

$p_i(n)$  - prawdopodobieństwo znalezienia się w stanie  $i$  po  $n$  krokach (rozkład zmiennej losowej  $X_n$ ).

$p_i(0)$  - prawdopodobieństwo znalezienia się w stanie  $i$  w chwili początkowej (rozkład zmiennej losowej

$X_0$  - rozkład początkowy).

$$\mathbf{p}(n) = (p_0(n), p_1(n), \dots, p_N(n))$$

$$\mathbf{p}(0) = (p_0(0), p_1(0), \dots, p_N(0))$$

## Przykład.

Błądzenie przypadkowe z odbiciem.


$$[0] \begin{array}{c} \xrightarrow{1} \\ \xleftarrow{q} \end{array} [1] \begin{array}{c} \xrightarrow{p} \\ \xleftarrow{q} \end{array} [2] \begin{array}{c} \xrightarrow{p} \\ \xleftarrow{q} \end{array} [3] \begin{array}{c} \xrightarrow{p} \\ \xleftarrow{1} \end{array} [4]$$

Jaką postać ma P?

$$P = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ q & 0 & p & 0 & 0 \\ 0 & q & 0 & p & 0 \\ 0 & 0 & q & 0 & p \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

## Przykład.

Zapisz macierz P dla łańcuch a Markowa przedstawionego grafem



$P(n) = P^n = [p_{ij}(n)]$  - macierz prawdopodobieństw przejść od stanu  $i$  do stanu  $j$  w  $n$  krokach,


## Równanie Chapmana, - Kołmogorowa:

$$p_{ij}(k+l) = \sum_m p_{im}(k) p_{mj}(l)$$

Zapis w postaci macierzowej

$$P(k+l) = P(k) P(l) \quad \text{czyli} \quad P^{k+l} = P^k P^l$$





**Sydney Chapman** (1888 – 1970) brytyjski matematyk i geofizyk.



**Andriej Kołmogorow (1903-1987)** – rosyjski matematyk, m.in. sformułował aksjomaty prawdopodobieństwa.

## **Własność:**

Znając rozkład początkowy i macierz  $P$  możemy wyznaczyć rozkład zmiennej losowej  $X_n$  czyli prawdopodobieństwo znalezienia się w poszczególnych stanach po  $n$  krokach:

$$(\mathbf{p}_0(\mathbf{n}), \mathbf{p}_1(\mathbf{n}), \dots) = (\mathbf{p}_0(\mathbf{0}), \mathbf{p}_1(\mathbf{0}), \dots)\mathbf{P}^n.$$

czyli 
$$\mathbf{p}(\mathbf{n}) = \mathbf{p}(\mathbf{0})\mathbf{P}^n$$

Uzasadnienie

Wiemy, że  $\mathbf{p}(1)=\mathbf{p}(0)\mathbf{P}$  zatem  $\mathbf{p}(2)=\mathbf{p}(1)\mathbf{P}=\mathbf{p}(0)\mathbf{P}^2$  itd

Mamy też własność: 
$$\mathbf{p}(\mathbf{m} + \mathbf{n}) = \mathbf{p}(\mathbf{m})\mathbf{P}^n$$

## Przykład.

Rozpatrzmy łańcuch Markowa o macierzy

$$P = \begin{bmatrix} 0,5 & 0 & 0,5 \\ 0 & 0,25 & 0,75 \\ 0,5 & 0,5 & 0 \end{bmatrix}$$

i rozkładzie początkowym  $p(0) = (1, 0, 0)$ .

Po pierwszym kroku prawdopodobieństwa znalezienia się w poszczególnych stanach są równe

$$p(1) = p(0)P = [1,0,0] \begin{bmatrix} 0,5 & 0 & 0,5 \\ 0 & 0,25 & 0,75 \\ 0,5 & 0,5 & 0 \end{bmatrix} = [0,5;0;0,5]$$

Po drugim kroku prawdopodobieństwa znalezienia się w poszczególnych stanach są równe


$$p(2) = p(0)P^2 = [1,0,0] \begin{bmatrix} 0,5 & 0,25 & 0,25 \\ 0,375 & 0,438 & 0,188 \\ 0,25 & 0,125 & 0,625 \end{bmatrix} = [0,5;0,25;0,25]$$

Po trzecim kroku prawdopodobieństwa znalezienia się w poszczególnych stanach są równe

$$p(3) = p(0)P^3 = [1,0,0] \begin{bmatrix} 0,375 & 0,188 & 0,438 \\ 0,281 & 0,203 & 0,516 \\ 0,438 & 0,344 & 0,219 \end{bmatrix} = [0,375; 0,188; 0,438]$$

Obliczając kolejne potęgi macierzy  $P$  możemy wyliczone wartości  $p(n)$  zestawić dla  $n = 1, \dots, 12$  w następującej tabeli i przedstawić na wykresie.

krok	Stan 0	Stan 1	Stan 2
1	0,5	0	0,5
2	0,5	0,25	0,25
3	0,375	0,188	0,438
4	0,406	0,266	0,328
5	0,367	0,23	0,402
6	0,385	0,259	0,356
7	0,371	0,243	0,386
8	0,379	0,254	0,367
9	0,373	0,247	0,38
10	0,376	0,252	0,372
11	0,374	0,249	0,377
12	0,376	0,251	0,374



Zauważmy, że rozpatrywane prawdopodobieństwa stabilizują się na określonym poziomie i dążą do pewnych granic, co związane jest z regularności rozpatrywanej macierzy stochastycznej.

Jak pokażemy wkrótce, istnieją sposoby wyznaczania tych granicznych prawdopodobieństw bez obliczania potęg macierzy  $P$ .

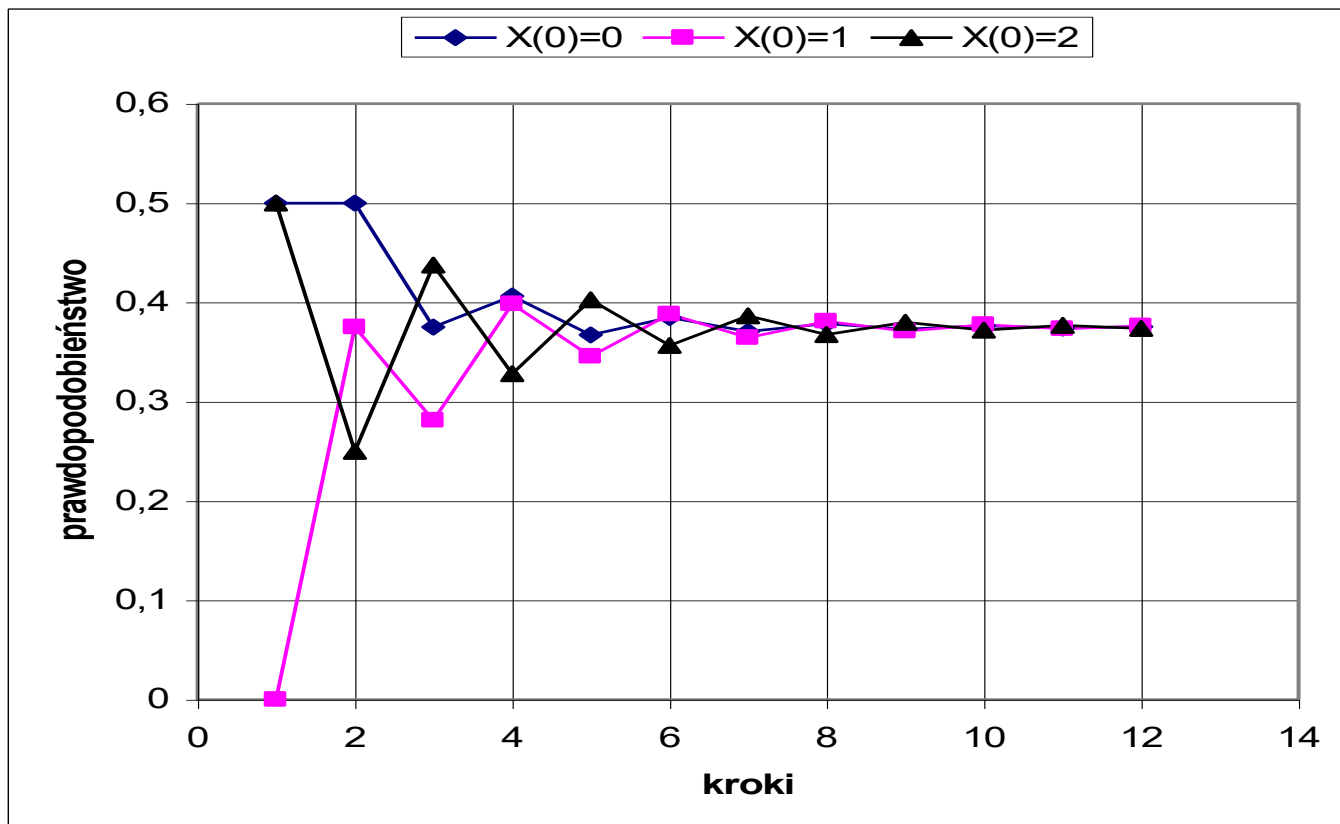
Zobaczmy teraz jak zmienia się prawdopodobieństwo znalezienia się w ustalonym stanie w poszczególnych krokach, gdy zmienia się rozkład początkowy.

**Rozpatrzmy stan 0** i rozkłady początkowe  $p(0) = (1, 0, 0)$ ,  $p(0) = (0, 1, 0)$ ,  $p(0) = (0, 0, 1)$ .

Obliczone prawdopodobieństwa (w podobny sposób jak wyżej) zestawiono w tabeli i przedstawiono na wykresie dla  $n = 1, \dots, 12$ .

$p(0) \setminus$ krok	1	2	3	4	5	6	7	8	9	10	11	12
$p(0) =$ $(1, 0, 0)$	0,5	0,5	0,375	0,406	0,367	0,385	0,371	0,379	0,373	0,376	0,374	0,376
$p(0) =$ $(0, 1, 0)$	0	0,375	0,281	0,398	0,346	0,388	0,364	0,381	0,371	0,378	0,373	0,376
$p(0) =$ $(0, 0, 1)$	0,5	0,25	0,438	0,328	0,402	0,356	0,386	0,367	0,38	0,372	0,377	0,374





Zauważmy, że rozpatrywane prawdopodobieństwo dla dużych  $n$  nie zależy od rozkładu początkowego.

Granice  $\Pi = p(\infty) = \lim_{n \rightarrow \infty} p(n)$  (o ile istnieje)

nazywamy **rozkładem granicznym** łańcucha Markowa.

Uwaga dla macierzy regularnej

$\Pi = \lim p(n) = \lim p(0)P^n = p(0)P^\infty = p(0)E$  gdzie E to macierz ergodyczna.

Łańcuch Markowa dla którego istnieje rozkład graniczny **niezależny od rozkładu początkowego**  $p(0)$  nazywamy **łańcuchem ergodycznym** a rozkład graniczny nazywamy **rozkładem ergodycznym**.

## **Twierdzenie.**

Rozkład graniczny nie zależy od rozkładu początkowego  $p(0)$  wtedy i tylko wtedy, gdy wiersze macierzy granicznej

$$\lim_{n \rightarrow \infty} P^n = E$$

są takie same (równe rozkładowi granicznemu  $\Pi$ ).

Warunek ten jest spełniony dla macierzy  $P$  **regularnej** (jednokrotna wartość własna równa 1 i brak innych wartości własnych o module 1).

## **Twierdzenie.**

Jeśli macierz stochastyczna  $P$  lub dowolna jej potęga ma **wszystkie elementy dodatnie** to odpowiadający jej łańcuch Markowa **jest ergodyczny**.

## Sposoby wyznaczania rozkładu granicznego:

Sposób I.

Rozkład graniczny  $\Pi$  jest jedynym niezerowym rozwiązaniem układu

$$(\mathbf{P}^T - \mathbf{I}) \Pi^T = \mathbf{0},$$

(równoważnie  $\Pi\mathbf{P}=\Pi$ )

spełniającym warunek  $\sum_{i=1} \Pi_i = 1$ ,

Uzasadnienie

$$\mathbf{p}(n+1) = \mathbf{p}(n)\mathbf{P}$$

$$\mathbf{p}(n+1) \rightarrow \Pi, \quad \mathbf{p}(n) \rightarrow \Pi$$

stąd  $\Pi\mathbf{P}=\Pi$

**Przykład.**

Wyznaczyć rozkład ergodyczny łańcucha Markowa o macierzy

$$P = \begin{bmatrix} 0,3 & 0,5 & 0,2 \\ 0,6 & 0 & 0,4 \\ 0 & 0,4 & 0,6 \end{bmatrix}$$

Przybliżony rozkład graniczny możemy odczytać wyznaczając wysoką potęgę macierzy P.



`{{0.3,0.5,0.2},{0.6,0,0.4},{0,0.4,0.6}}^100`

Extended Keyboard Upload Examples Random

Input:

$$\begin{pmatrix} 0.3 & 0.5 & 0.2 \\ 0.6 & 0 & 0.4 \\ 0 & 0.4 & 0.6 \end{pmatrix}^{100}$$

Result:

$$\begin{pmatrix} 0.26087 & 0.304348 & 0.434783 \\ 0.26087 & 0.304348 & 0.434783 \\ 0.26087 & 0.304348 & 0.434783 \end{pmatrix}$$

Zatem  $\Pi \approx [0,26087, 0,304348, 0,434783]$ .

Należy rozwiązać równanie jednorodne

$$\begin{bmatrix} -0,7 & 0,6 & 0 \\ 0,5 & -1 & 0,4 \\ 0,2 & 0,4 & -0,4 \end{bmatrix} \begin{bmatrix} \Pi_0 \\ \Pi_1 \\ \Pi_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$



Jest to **układ nieoznaczony z jednym parametrem**. Przyjmijmy np.  $\Pi_0 = 1$ ,

Wtedy  $\Pi_1 = 28/24, \Pi_2 = 40/24$ .

Dzieląc te rozwiązania przez ich sumę otrzymamy rozwiązanie unormowane

$$\Pi = [6/23, 7/23, 10/23].$$

Sprawdzenie



solve {-0.7\*x+0.6\*y=0,0.5\*x-y+0.4\*z=0,0.2\*x+0.4\*y-0.4\*z=0, x+y+z=1}

Extended Keyboard Upload

Examples Random

Input interpretation:

solve

$$-0.7x + 0.6y = 0$$

$$0.5x - y + 0.4z = 0$$

$$0.2x + 0.4y - 0.4z = 0$$

$$x + y + z = 1$$

Result:

Approximate form

$$x = \frac{6}{23} \wedge y = \frac{7}{23} \wedge z = \frac{10}{23}$$

$e_1 \wedge e_2 \wedge \dots$  is the logical AND function

Sposób II.

$$\Pi_j = \frac{A_{jj}}{\sum_k A_{kk}}$$

gdzie  $A_{kk}$  to **dopełnienia algebraiczne** macierzy  $I - P$  (wyznacznik podmacierzy otrzymanej przez skreślenie  $k$ -tego wiersza i  $k$ -tej kolumny macierzy  $I - P$ ).

## **Przykład.**

Wyznaczyć drugim sposobem rozkład ergodyczny łańcucha z poprzedniego przykładu.



			A <sub>ii</sub>		π <sub>i</sub>	
	1	-0,4	0,24		0,26087	6/23
	-0,4	0,4				
0,7	-0,2		0,28		0,304348	7/23
0	0,4					
0,7	-0,5					
-0,6	1		0,4		0,434783	10/23
			0,92		1	

## Klasyfikacja stanów.

Będziemy utożsamiać stan  $s_k$  z liczbą  $k$ .

Stan  $s_k$  jest **osiągalny** ze stanu  $s_j$  jeśli  $p_{jk}(n) > 0$  dla pewnego  $n$ ,

Stany  $s_k$  i  $s_j$  nazywamy **wzajemnie komunikującymi się** jeśli stan  $s_k$  jest osiągalny ze stanu  $s_j$ , i odwrotnie.


Stan  $s_k$  jest **stanem nieistotnym** gdy istnieje stan  $s_j$  osiągalny ze stanu  $s_k$  a stan  $s_k$  nie jest osiągalny ze stanu  $s_j$ ,

Relacja wzajemnej komunikacji jest relacją równoważności, zatem dzieli zbiór stanów na klasy rozłączne.

Zbiór stanów  $C$  nazywamy **zamkniętym**, jeżeli żaden stan spoza  $C$  nie da się osiągnąć wychodząc z dowolnego stanu w  $C$ .

## Przykład.

Rozpatrzmy łańcuch Markowa



Jego macierz P ma postać

$$p = \begin{bmatrix} 0 & 0,25 & 0 & 0,5 & 0,25 \\ 0 & 0,5 & 0,5 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0,75 & 0,25 & 0 & 0 \\ 0 & 0 & 0 & 0,5 & 0,5 \end{bmatrix}$$

Stany 0 i 4 są nieistotne.

Stany 1, 2 i 3 są istotne.

Zbiór stanów  $\{1, 2, 3\}$  jest zamknięty.



Pojedynczy stan zamknięty (musi być  $p_{kk} = 1$ ) nazywamy stanem **pochlaniającym**.

Łańcuch Markowa jest **nieprzywiedlny**, gdy wszystkie jego stany wzajemnie komunikują się.

Przy badaniu ewolucji łańcucha Markowa w czasie chcemy wiedzieć, do których stanów łańcuch powraca nieskończenie wiele razy, a które po pewnym czasie opuszcza bezpowrotnie.

Niech  $F_{kj}$  będzie prawdopodobieństwem, że łańcuch wychodząc ze stanu  $k$  dotrze kiedykolwiek do stanu  $j$ .

$$F_{kj} = P\left(\bigcup_n (X_n = j \mid X_0 = k)\right)$$

Jeśli  $f_{kj}(n)$  - prawdopodobieństwo, że wychodząc ze stanu  $k$  łańcuch dojdzie po raz pierwszy do stanu  $j$  w  $n$ -tym kroku

$$f_{kj}(n) = P(X_1 \neq j, \dots, X_{n-1} \neq j, X_n = j \mid X_0 = k)$$

to

$$F_{kj} = \sum_n f_{kj}(n)$$

Stan  $j$  nazywamy:

a) **powracającym**, gdy  $F_{jj} = 1$ .

b) **chwilowym** gdy  $F_{jj} < 1$ .

## **Twierdzenie.**

W nieprzywiedlnym łańcuchu Markowa wszystkie stany są tego samego typu: jeżeli jeden jest powracający (chwilowy) to wszystkie są powracające (chwilowe).

Dlatego możemy mówić, że łańcuch jest np. powracający.

## **Twierdzenie.**

Przestrzeń stanów  $S$  łańcucha Markowa można jednoznacznie przedstawić w postaci sumy:

$$S = T \cup S_1 \cup S_2 \cup \dots$$

gdzie  $T$  - zbiór stanów chwilowych,

$S_i$  - nieprzywiedlne zamknięte zbiory stanów powracających.

## Łańcuchy okresowe.

**Okresem stanu**  $j$  nazywamy liczbę:

$$o(j) = \text{NWD}(n: p_{jj}(n) > 0)$$

jest to **największy wspólny dzielnik** takich liczb  $n$ , że powrót do stanu  $j$  może nastąpić po  $n$  krokach.

Stan  $j$  nazywamy **okresowym** gdy ma okres większy od 1 i **nieokresowym** gdy ma okres 1.



## **Twierdzenie.**

W nieprzywiedlnym łańcuchu Markowa wszystkie stany mają ten sam okres.

Zatem nieprzywiedlny łańcuch Markowa nazywamy **okresowym**, gdy jego stany mają okres większy od 1, w przeciwnym przypadku łańcuch nazywamy **nieokresowym**.

Przykład

Proces ma stany  $\{0, 1, 2, 3\}$ .

$$P = \begin{bmatrix} 0 & 0,1 & 0,9 & 0 \\ 0,3 & 0,5 & 0 & 0,2 \\ 0,5 & 0 & 0 & 0,5 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Wskaż podzbiory wzajemnie komunikujące się.

Czy ten łańcuch jest nieprzywiedlny?

Wskaż stan pochłaniający.

$\{0, 1, 2\}, \{3\}$ .

Łańcuch jest przywiedlny.

Stan pochłaniający to 3.

Przykład

Proces ma stany  $\{0, 1, 2, 3\}$ .

$$P = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0,3 & 0 & 0 & 0,7 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Wskaż stany okresowe.

Wszystkie stany mają okres 2

Przykład

Proces ma stany  $\{0, 1, 2, 3\}$ .

$$P = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0,3 & 0,2 & 0 & 0,5 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Wskaż stany okresowe.

Brak stanów okresowych.

## Łańcuch ergodyczny.

Łańcuch jest ergodyczny jeśli istnieje

$$\lim_{n \rightarrow \infty} p_{ij}(n) = \pi_j \quad \sum \pi_j = 1$$

Rozkład  $\Pi$  nazywamy rozkładem **ergodycznym** (granicznym).



## **Łańcuch stacjonarny.**

Łańcuch jest **stacjonarny**, gdy istnieje rozkład  $\Pi$  zwany rozkładem stacjonarnym, że

$$\Pi P = \Pi$$

W łańcuchu ergodycznym rozkład stacjonarny (graniczny) nie zależy od rozkładu początkowego.


**Uwaga.**

**ergodyczny  $\Rightarrow$  stacjonarny**

Każdy łańcuch o skończonej liczbie stanów jest stacjonarny.

### Przykład.

Rozpatrzmy łańcuch Markowa



Jego macierz P ma postać

$$P = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}$$

Wszystkie stany mają okres 3.

Zauważmy, że wielomian charakterystyczny tej macierzy ma postać

$$W(\lambda) = \lambda^3 - 1$$

i jej wartości własne są równe:  $\lambda_1 = 1$ ,  $\lambda_2 = \frac{-1-i\sqrt{3}}{2}$ ,  $\lambda_3 = \frac{-1+i\sqrt{3}}{2}$ .

Ponieważ wszystkie wartości własne mają moduł 1 i  $\lambda_1 = 1$  jest jednokrotną wartością własną to rozpatrywana macierz jest nierozkładalna i cykliczna.

Łańcuch ten jest stacjonarny, jego rozkładem stacjonarnym jest  $(1/3, 1/3, 1/3)$ .

Rozkład ten można wyznaczyć I lub II sposobem obliczania rozkładów granicznych.

Kolejne potęgi macierzy  $P$  są równe

$$P^2 = P^{3n+2} = \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix}, \quad P^3 = P^{3n+3} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad P^4 = P = P^{3n+1} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}$$


dla  $n = 0, 1, 2, \dots$

Zauważmy, że żadna kolumna  $P^n$  nie składa się wyłącznie z elementów dodatnich.

Rozkład graniczny nie istnieje.

Weźmy np. rozkład początkowy  $p(0) = (1, 0, 0)$ .

Obliczone prawdopodobieństwa  $p(n)$  zestawiono w tabeli i przedstawiono na wykresie dla



$n = 0, \dots, 8$ .

$p(n) \setminus n$	0	1	2	3	4	5	6	7	8
Stan 0	1	0	0	1	0	0	1	0	0
Stan 1	0	1	0	0	1	0	0	1	0
Stan 2	0	0	1	0	0	1	0	0	1

Jak widać  $\lim_{n \rightarrow \infty} p(n)$  nie istnieje dla żadnej współrzędnej (dla żadnego stanu).

### Wniosek.

Istnienie rozkładu stacjonarnego nie implikuje, że łańcuch jest ergodyczny. Każdy łańcuch o skończonej liczbie stanów jest stacjonarny.

## Twierdzenie.

Dla nieprzywiedlnego, nieokresowego łańcucha Markowa  $(X_n)$  dla którego istnieje rozkład stacjonarny  $\Pi$  mamy:

- a) łańcuch  $(X_n)$  jest powracający,
- b) łańcuch  $(X_n)$  jest ergodyczny,
- c) rozkład stacjonarny jest jedyny oraz  $\pi_j = 1/\mu_j$ , gdzie  $\mu_j$  jest średnim czasem powrotu łańcucha do stanu  $j$ .