

# Elementy Modelowania Matematycznego

## Wykład 7

### Modele Markova



---

# Spis treści

---

- ◆ Wstęp
- ◆ Łańcuch i procesy Markova
- ◆ Przykłady procesów Markova

# Wstęp

- ◆ Andrey Andreyevich Markov (14 czerwca 1856 – 20 czerwca 1922) wybitny rosyjski matematyk.
- ◆ Znany jest przede wszystkim ze swych prac na temat procesów stochastycznych, zwanych później łańcuchami Markova.
- ◆ On i jego młodszy brat Vladimir Andreevich Markov (1871-1897) udowodnili tzw. Nierówność Markova.

# Wstęp

- ◆ Procesy Markowa w reprezentacji dyskretnej lub ciągłej, jako wyodrębniona grupa procesów przypadkowych (losowych), są dziś najlepiej zbadaną dziedziną procesów losowych i znalazły zastosowanie w modelowaniu wielu zjawisk z życia codziennego

# Wstęp

- ◆ Prognozowanie cen akcji giełdowych
- ◆ Niemal wszystkie akcje zmieniają swoje ceny codziennie, a duża ich część w sposób niemal ciągły.
- ◆ Wykresy cen przedstawiają, w zależności od nastawienia obserwatora, efekt równoważenia się popytu i podaży, dyskontowanie przyszłych zdarzeń, reakcje na wydarzenia historyczne, efekt manipulacji akcjami, wpływ kosmosu bądź też całkowicie przypadkowe ruchy Browna.

# Wstęp

- ◆ Te bądź jeszcze inne przyczyny zmian cen usiłuje się wykorzystać w analizie historycznych przebiegów i próbie prognozowania przyszłego zachowania cen.
- ◆ Zachowanie poszczególnych akcji zapisane w postaci kolejnych cen i przekształcone do postaci graficznej to dla każdego inwestora wykres ceny.
- ◆ Bardzo podobne przebiegi i szeregi liczb są znane i używane w wielu dziedzinach nauki

# Wstęp

- ◆ Jako że szeregi te opisują za pomocą kolejnych liczb zachowanie pewnego zjawiska w czasie, bardzo często określa się je mianem szeregów czasowych.
- ◆ Kolejne zdarzenia występujące w szeregach czasowych tworzą pewien proces.
- ◆ Tak więc to, co dla inwestora jest wykresem cen, dla specjalisty zajmującego się na przykład teorią informacji, jest graniczną interpretacją szeregu czasowego opisującego proces zmian cen.

# Wstęp

- ◆ Proces stochastyczny jest to takie zjawisko (reprezentowane liczbowo przez szereg czasowy), w którym przyszła wartość opisująca stan zjawiska nie jest pewna (przyszłe liczby opisujące je mogą przyjmować różne wartości, przy czym żadna z nich nie pojawi się z prawdopodobieństwem równym 1).



# Wstęp

- ◆ Klasycznymi przypadkami procesów stochastycznych są przyszłe wartości zmiennych opisujących pogodę
  - temperatura,
  - ciśnienia ,
  - kierunek bądź siła wiatru).
- ◆ Dobrym przykładem może być wypełnianie się nizu.

# Wstęp

- ◆ Można nawet w pewien sposób oszacować drogę, którą się przesunie i czas potrzebny na podniesienie się ciśnienia wewnątrz niżu do wartości średniej.
- ◆ Nie da się tego jednak zrobić w sposób dokładny.
- ◆ Czyli mimo pewnych ściśle określonych ram zachowania, dokładne zachowanie nie jest znane.
- ◆ Podobnie jest ze zmianami cen na giełdzie.
- ◆ Jakkolwiek każdy silny spadek kiedyś musi się skończyć, nigdy nie mamy pewności kiedy to nastąpi.

# Łańcuch Markowa

- ◆ Ciąg Markowa to taki proces stochastyczny, w którym określone są związki probabilistyczne przyszłych zdarzeń w zależności od wcześniej występujących.

# Ciąg Markowa

- ◆ ciąg Markova pierwszego rzędu - jutrzejsze zachowanie zależy (w sensie statystycznym) tylko i wyłącznie od dzisiejszej zmiany
- ◆ ciąg Markova drugiego rzędu - prawdopodobieństwo jutrzejszego zachowania zależy od dzisiejszej i wczorajszej zmiany
- ◆ ciąg Markova zerowego rzędu - jutrzejsze zachowanie jest całkowicie niezależne od wcześniejszych notowań (bez względu jakie było zachowanie historyczne przyszłe zmiany będą określone takimi samymi związkami prawdopodobieństw);
- ◆ właśnie takie założenie jest wykorzystywane w analizie portfelowej czyli fakt, że przyszłość nie zależy od przeszłości może być w jakiś sposób wykorzystany w procesie inwestycyjnym.

# Proces Markowa

- ◆ Proces Markowa bazuje wyłącznie na rozkładzie prawdopodobieństw warunkowych.
- ◆ Może się więc zdarzyć, że mamy do czynienia z deterministycznym procesem chaotycznym, w którym jutrzejsze zachowanie określone jest ścisłym wzorem, a mimo to proces będzie sprawiał wrażenie, że jest zerowego rzędu (to znaczy zupełnie nie zależy od przeszłości).

# Proces Markowa

- ◆ Wynika to z faktu, że bardzo podobne, niemal identyczne zachowanie historyczne może skutkować zupełnie różnym zachowaniem w przyszłości.
- ◆ Tak więc mimo tego, że proces chaotyczny oznacza się istnieniem tak zwanej długoterminowej pamięci zachowania wykrycie tej zależności może być trudne bądź niemożliwe.

# Proces Markowa

- ◆ Najważniejszym problemem w prognozowaniu cen jest brak stacjonarności procesu.
- ◆ Niestacjonarność to zjawisko, które jest źródłem większości niepowodzeń inwestorów giełdowych, próbujących wyznaczyć przyszłe ceny akcji na giełdzie.

# Proces Markowa

- ◆ Proces stacjonarny to taki proces, w którym związki probabilistyczne są stałe i nie zależą od zmiennej niezależnej, czyli prawdopodobieństwo wystąpienia pewnej sytuacji nie zmienia się w miarę upływu czasu.



# Proces Markowa

- ◆ Gdyby przyjąć, że zachowanie cen akcji jest procesem niestacjonarnym o nieznanej zmianie sposobu zachowania oznaczałoby to, że do prognozowania przyszłych cen potrzebna byłaby wiedza o przyszłym charakterze tego procesu, natomiast zupełnie nieprzydatna byłaby wiedza o wcześniejszym zachowaniu.

# Proces Markowa

- ◆ W skrócie oznacza to, że wyłącznie osoby manipulujące rynkiem (przy założeniu, że jest to możliwe na większą skalę) mogłyby posiadać wiedzę jak zarobić na inwestycjach giełdowych.

# Proces Markowa

- ◆ Należy rozróżnić niestacjonarność procesu od efektywności rynku.
- ◆ Rynek efektywny, jest skutkiem tego, że zmiany cen są procesem Markowa zerowego rzędu.
- ◆ Dodatkowo, charakteryzuje go tak zwana słaba stacjonarność, która cechuje się stałością średniej i wariancji.
- ◆ Czyli ostatecznie na rynku efektywnym ceny nie zależą od wcześniejszych.
- ◆ Natomiast w przypadku braku stacjonarności ceny zależą od poprzednich, lecz nie ma pewności, że wiemy w jaki sposób.

# Proces Markowa

- ◆ W praktyce sprawa nie jest taka beznadziejna.
- ◆ Zmiany cen nie są procesem stacjonarnym, jednak zmienność zależności jest bardzo powolna.
- ◆ To znaczy system, który był dobry wczoraj będzie dobry jeszcze dzisiaj, a jutro będzie tylko trochę gorszy.
- ◆ Kiedyś oczywiście może utracić swoje właściwości. Ponadto można podejrzewać, że zmiany cen składają się z kilku (zapewne trzech) procesów o różnych charakterach.
- ◆ Bardzo prawdopodobne, że przynajmniej jeden z nich jest stacjonarny, czyli jego parametry ustalone w przeszłości będą w przyszłości takie same.


# Proces Markowa

- ◆ Niech układ  $\Omega$  może przyjmować stany  $\omega_1, \omega_2, \dots$  - zbiór skończony lub przeliczalny i niech w pewnej jednostce czasu może przejść z jednego stanu do innego z pewnym prawdopodobieństwem, to

$$P(\omega_j^{(n)} | \omega_i^{(n-1)})$$

- ◆ prawdopodobieństwo warunkowe, że układ znajdujący się w chwili  $n-1$  w stanie  $\omega_i$  przejdzie do stanu  $\omega_j$  w chwili  $n$ .

# Proces Markowa



# Łańcuch jednorodny

- ◆ Jeśli prawdopodobieństwo nie zależy od czasu, tzn.:

$$P(\omega_j^{(n)} | \omega_i^{(n-1)}) = P(\omega_j^{(n+1)} | \omega_i^{(n)})$$

- ◆ to łańcuch Markowa jest jednorodny, a macierz złożona z elementów

$$p_{ij} = P(\omega_j^{(n)} | \omega_i^{(n-1)})$$

- ◆ to macierz przejścia.

- ◆ Mamy  $p_{ij} \geq 0, \sum_j p_{ij} = 1.$

# Łańcuch jednorodny

Prawdopodobieństwo, że w  $n$  przejściach układ przejdzie ze stanu  $\omega_i$  do stanu  $\omega_j$  wynosi

$$p_{ij}(n) = \sum_k p_{ik}(m) p_{kj}(n - m)$$

$m$  – liczba całkowita,  $1 \leq m < n$ .

Przykład łańcucha Markova: proces urodzin i śmierci — zmiana liczebności populacji na skutek narodzin i śmierci.



# Łańcuch Pochłaniający

- ◆ Łańcuch Markowa nazywamy pochłaniającym, jeśli istnieje taki stan  $i$ , z którego nie można wyjść, czyli:

$$p_{ii} = 1 \quad \wedge \quad \forall_{i \neq j} p_{ij} = 0$$

- ◆ Stan taki nazywamy stanem pochłaniającym (ang. absorbing state).
- ◆ Stan nie będący stanem pochłaniającym nazywamy stanem przejściowym (ang. transient state).

# Postać kanoniczna łańcucha pochłaniającego

$$P = \begin{bmatrix} Q & R \\ 0 & I \end{bmatrix}$$

$Q$  – macierz tranzytywna

$0$  – macierz zerowa

$I$  – macierz identycznościowa

$R$  – macierz przejścia do stanów pochłaniających

# Łańcuch Markowa

- ◆ Łańcuch Markowa nazywamy ergodycznym, jeśli z dowolnego stanu można przejść do dowolnego innego (niekoniecznie w jednym kroku).

# Procesy ergodyczne

- ◆ Centralnym zagadnieniem teorii procesów stochastycznych jest znalezienie rozkładu prawdopodobieństwa zmiennej losowej  $y(t)$  w pewnej chwili  $t$  na podstawie znajomości realizacji  $y(s)$  tej zmiennej losowej w pewnych innych chwilach  $s$  (na ogół chwila  $t$  odnosi się do przyszłości).

# Procesy ergodyczne

- ◆ Jedną z podstawowych własności, dzięki którym można ocenić rozkład prawdopodobieństwa zmiennej losowej  $y(t)$  na podstawie obserwacji aktualnych przebiegów danego procesu stochastycznego, jest tzw. własność ergodyczności

# Procesy ergodyczne

- ◆ Można powiedzieć, że proces stochastyczny jest ergodyczny, jeżeli prawdopodobieństwo zaobserwowania wartości  $y(t)$  należącej do jakiegoś zbioru  $A$  da się oszacować przez średni czas pobytu każdej realizacji w tym zbiorze podczas długiego czasu obserwacji

# Procesy ergodyczne

- ◆ Tak więc w procesach stochastycznych ergodycznych można oszacować ich rozkład prawdopodobieństwa na podstawie obserwacji jednego przebiegu w dostatecznie długim czasie, czyli otrzymane wyniki są średnią po czasie.

# Procesy ergodyczne

- ◆ Hipoteza ergodyczna
- ◆ Ewolucja klasycznego złożonego układu dynamicznego zachodzi z jednakowym prawdopodobieństwem przez wszystkie stany, które są dostępne z punktu początkowego i które podlegają ograniczeniom narzuconym przez zasadę zachowania energii.



# Procesy Markowa


- ◆ Przykładem procesu niemarkovskiego może być np. proces zmian poziomu wody w rzece w pewnym ustalonym jej miejscu, gdzie informacja o tym, że w pewnej chwili  $t$  poziom wody wynosił  $y$  i bezpośrednio przedtem obserwowano np. tendencję obniżania się poziomu wody, pozwala na lepsze przewidywania niż sama informacja o tym, że w chwili  $t$  poziom wody wynosił  $y$ .

# Procesy Markowa

- ◆ Przykłady procesów Markowa
  - Proces emisji cząstek wypromieniowanych przez substancję radioaktywną.
  - Ruch cząstki zawieszonyj w cieczy tzw. ruch Browna.
  - Proces zajmowania i zwalniania łączy w centrali telefonicznej.
  - Dynamika kolejki w serwerach WWW.

# Procesy Markowa

Błądzenie losowe: prawdopodobieństwo znalezienia układu w  $n$ -tym stanie zależy tylko od stanu poprzedniego  $n - 1$ .



Rys. 2: Losowe błądzenie pijaka:  $p$  - prawdopodobieństwo, że pijak pójdzie w lewo;  $q = 1 - p$  - prawdopodobieństwo, że pijak pójdzie w prawo;  $x = m l$  - lokalizacja pijaka wzdłuż osi  $x$

# Procesy Markowa

- ◆ Pytanie: jakie jest prawdopodobieństwo, że po wykonaniu  $N$  kroków znajdziemy pijaka w położeniu  $x = m$ ?
- ◆ Niech po  $n$  krokach pijak będzie w położeniu  $x = m$ ,  $m \leq N$ .
- ◆ Niech  $n_r$  - liczba kroków w prawo;  $n_l$  - liczba kroków w lewo.
- ◆ Mamy więc

$$N = n_r + n_l$$

$$m = n_r - n_l = n_r - (n - n_r) = 2n_r - N$$

# Procesy Markowa

**Przypomnienie:** rozkład dwumianowy

Prawdopodobieństwo, że pijak pokonał pewną drogę wynosi

$$p \dots p q \dots q = p^{n_r} q^{n_l}$$

Liczba realizacji takich dróg wynosi

$$\frac{N!}{n_r! n_l!}$$

więc prawdopodobieństwo wykonania  $n_r$  kroków w prawo i  $n_l$  kroków w lewo wynosi

$$P_N = \frac{N!}{n_r! n_l!} p^{n_r} q^{n_l}$$

# Procesy Markowa

Przyjmijmy

$$n_r = \frac{1}{2}(N + m), \quad n_l = \frac{1}{2}(N - m)$$

i wstawmy do wzoru na  $P_N$

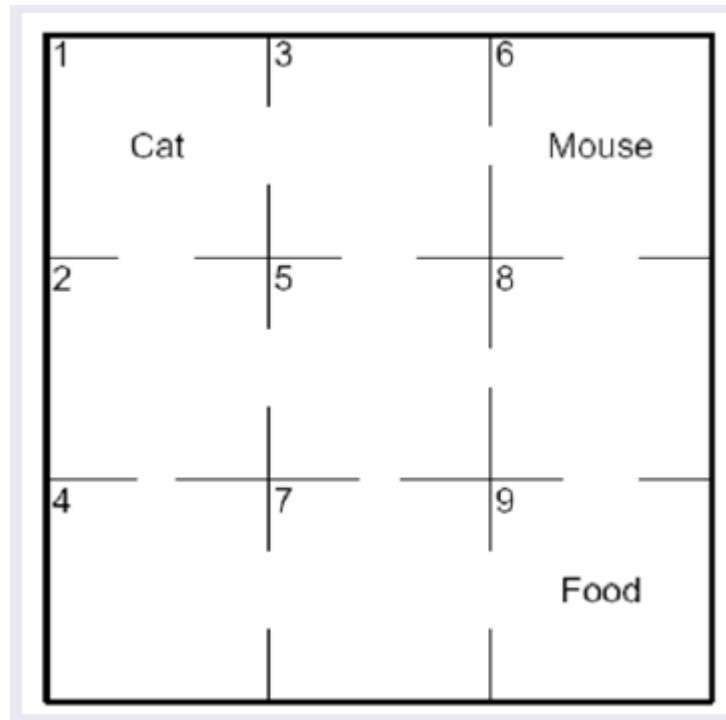
$$P_N(m) = \frac{N!}{\frac{1}{2}(N + m)! \frac{1}{2}(N - m)!} p^{(N+m)/2} q^{(N-m)/2}$$

Szczególny przypadek  $p = q = 1/2$ :

$$P_N(m) = \frac{N!}{\frac{1}{2}(N + m)! \frac{1}{2}(N - m)!} \left(\frac{1}{2}\right)^N$$

# Procesy Markowa

- ◆ Mysz w labiryncie



# Procesy Markowa

- ◆ Mysz w labiryncie
- ◆ Mamy kilka możliwości:
  - Kot zawsze siedzi w swojej komórce i czeka na ofiarę
  - Kot może wchodzić tylko do pomieszczeń 1,2,3 i 5, gdyż wszystkie inne otwory są dla niego za małe; do każdego sąsiedniego dopuszczalnego pomieszczenia wchodzi z jednakowym prawdopodobieństwem
  - To samo co powyżej, ale prawdopodobieństwo, że zostanie w swej komórce wynosi  $1/2$ , a wchodzi do sąsiednich pomieszczeń z prawdopodobieństwem  $1/4$



# Procesy Markowa


- ◆ Procesy gałązkowe (Galtona-Watsona)
- ◆ Procesy gałązkowe modelują rozwój populacji (jednopłciowej, rozmnażającej się przez podział, np. bakterii, ameb, monet czy innych mikroorganizmów).
- ◆ Zmienne losowe  $y(n)$  (przyjmujące nieujemne wartości) określają liczbę osobników w  $n$ -tym pokoleniu.
- ◆ Przyjmujemy zawsze, że jest jeden protoplasta rodu, czyli  $y(0) = 1$ .
- ◆ Zmienne losowe opisujące, ile dzieci ma każdy osobnik, są niezależne o jednakowym rozkładzie.
- ◆ Główne pytanie, jakie się pojawia, to: jakie są szanse, że dana populacja przeżyje?

# Procesy Markowa

## Procesy gałązkowe (Galtona-Watsona)

Założmy, iż osobnik może mieć 0, 1 lub 2 potomków, a przez  $p_0$ ,  $p_1$  i  $p_2$  oznaczmy prawdopodobieństwa tych zdarzeń ( $p_0 + p_1 + p_2 = 1$ ).

pokolenie



# Procesy Markowa

## Procesy gałązkowe (Galtona-Watsona)

Niech  $x_k$  – liczba osobników  $k$ -tej generacji. Wtedy prawdopodobieństwo pojawienia się określonej liczby osobników danej generacji można zapisać:

$$p(x_0 = 1) = 1$$

$$p(x_1 = 0) = p_0$$

$$p(x_1 = 2) = p_2$$

$$p(x_2 = 0) = p_0 + p_0 p_1 + p_2 p_0^2$$

$$p(x_2 = 2) = p_1 p_2 + p_2 (2 p_0 p_2 + p_1^2)$$

$$p(x_2 = 4) = p_2^3$$

$$p(x_1 = 1) = p_1$$

$$p(x_2 = 1) = p_0 + 2 p_2 p_1 p_0$$

$$p(x_2 = 3) = 2 p_2^2 p_1$$

Jeśli potraktujemy  $x_k$  jako zmienną losową, to możemy wyznaczyć jej wartość oczekiwaną ( $E(X_k) = \mu$ ).

# Błądzenie losowe

$$B(t + 1) = B(t) + z(t + 1), \quad B(0) = B_0$$

$z(t)$  – zakłócenie losowe opisane ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie normalnym o średniej 0 i wariancji 1

$t$  – czas mierzony w jednakowych dyskretnych odstępach

Gdy  $t = 0$  – teraźniejszość. Niech  $B(0) = 0$ , a przyrost czasu

$\Delta = \frac{1}{n}$ ,  $n$  – dowolna liczba naturalna.

# Błądzenie losowe

Dla nowych jednostek czasu

$$B(t + \Delta) = B(t) + z(t + \Delta), \quad B(0) = B_0$$

Zmieniła się wariancja (zmiennosc) zakłócenia losowego  $z(t)$ , a mianowicie  $z(t)$  jest teraz ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie  $N(0, \Delta)$ . Nowy proces ma takie samo średnie przesunięcie (dryf) i wariancję na przedziale o długości  $n$  odstępów (okresów), jak i wyjściowe błądzenie losowe obserwowane na jednostkowym przedziale.

Co się stanie, gdy  $\Delta$  staje się nieskończenie małą wielkością, czyli  $dt$ ?

# Ruch Browna

- ◆ Proces stochastyczny  $B(t)$  nazywamy standardowym ruchem Browna (Brownian motion).
- ◆ Jest to jeden z ważniejszych modeli teoretycznych w rachunku prawdopodobieństwa.
- ◆ Nazwa pochodzi od dobrze znanego w fizyce procesu opisującego położenie cząstki w klasycznym ruchu Browna.

# Ruch Browna

- ◆ Możemy go przedstawić w następującej postaci całkowej:

$$B(t) = B_0 + \int_0^t dB(s)$$

# Ruch Browna

Podstawowe właściwości procesu ruchu Browna:

- prawie wszystkie realizacje  $B(t)$  są ciągłe
- $B(t)$  jest procesem o przyrostach stacjonarnych i niezależnych
- przyrosty procesu  $B(t)$  mają rozkład normalny  $N(0, dt)$
- rozkłady warunkowe  $B(u)$  przy danym  $B(t)$  są normalne o rozkładzie  $N(b(t), u - t)$ , dla  $u > t$
- wariancja  $\text{Var}[B(u)] \rightarrow \infty$ , gdy  $u \rightarrow \infty$



# Ruch Browna

- ◆ Ruch Browna był po raz pierwszy wykorzystany do modelowania procesów finansowych przez Louisa Bacheliera, który w swojej pionierskiej pracy doktorskiej *Théorie de la spéculation*, obronionej 29 marca 1900 r. w Paryżu, zaproponował pierwszy teoretyczny model procesu ceny akcji z paryskiej giełdy.

# Przykład

- ◆ Czy możemy liczyć na kawę ?
- ◆ Maszyna z kawą może być czynna (stan 0) lub zepsuta (stan 1).
- ◆ Załóżmy, że jeśli maszyna jest czynna w danym dniu, to prawdopodobieństwo zepsucia w dniu następnym jest  $d$ , a jeśli jest zepsuta w danym dniu, to prawdopodobieństwo jej naprawienia na dzień następny jest  $g$ .
- ◆ Jakie jest prawdopodobieństwo dostania kawy z maszyny?

# Przykład

- ◆ maszyna jest czynna, wczoraj też była czynna:  
 $p(0, t_n / 0, t_n-1) = 1 - d,$
- ◆ maszyna jest nieczynna, wczoraj była czynna:  
 $p(1, t_n / 0, t_n-1) = d,$
- ◆ maszyna jest czynna, wczoraj była nieczynna:  
 $p(0, t_n / 1, t_n-1) = g,$
- ◆ maszyna jest nieczynna, wczoraj też była nieczynna:  $p(1, t_n / 1, t_n-1) = 1 - g,$

# Przykład

- ◆ Dobra i dobrze serwisowana maszyna powinna mieć **d** bliskie 0 i **g** bliskie 1 !)
- ◆ Prawdopodobieństwo dostania kawy z maszyny będzie zależało od proporcji czasu, gdy maszyna jest czynna, do całego czasu pomiaru.

# Przykład

- ◆ Symulacja dla  $d=0.2$  i  $g = 0.9$

|            | LICZBA SYMULACJI (DNI) |      |      |      |      |
|------------|------------------------|------|------|------|------|
|            | 10                     | 50   | 100  | 500  | 1000 |
| 0 W DNIU 0 | 0.90                   | 0.82 | 0.84 | 0.84 | 0.82 |
| 1 W DNIU 0 | 0.50                   | 0.86 | 0.80 | 0.80 | 0.81 |

- ◆ Zauważmy, że uśredniając po długim czasie, prawdopodobieństwo kupienia kawy stabilizuje się na poziomie 80%, praktycznie niezależnie od stanu maszyny w dniu początkowym.

# Przykład

- ◆ Brawurowa gra
- ◆ Mamy 1 zł i chcemy wygrać 5 zł.
- ◆ Krupier oferuje nam grę, w której prawdopodobieństwo naszej wygranej wynosi  $p$  w każdej rundzie z wypłatą podwójnej stawki w razie wygranej oraz jej stratą w razie przegranej, przy czym stawki są w całkowitych wielokrotnościach złotówki.

# Przykład


- ◆ Wybieramy następującą strategię
- ◆ brawurowa: w każdej grze stawiamy wszystko co mamy, jeśli ewentualna wygrana pozwoli osiągnąć cel (osiągnąć 5 zł), lub mniej niż cel.
- ◆ W przeciwnym razie, stawiamy tyle aby ewentualnie wygrać 5 zł.
- ◆ Jaka jest szansa wygrania w  $k$  lub mniejszej liczbie gier?

# Przykład

- ◆ Ponumerujmy stany liczbą posiadanych przez nas złotych.
- ◆ Zaczynamy grę od stanu nr 1.
- ◆ Wygrać grę – znaczy przejść od stanu 1 do stanu 5.
- ◆ Stan 0 oznacza przegraną.
- ◆ Prawdopodobieństwo wygrania lub przegrania gry nie zależy od historii wygranych i przegranych w poprzednich grach – własność Markowa jest zatem spełniona.
- ◆ Prawdopodobieństwo wygranej w stanie  $i$  nie zależy od czasu, więc proces ten jest jednorodny w czasie.



# Przykład



# Przykład

- ◆ Interesują nas tylko ścieżki, które kończą się w stanie 5. Nazwiemy je istotnymi.
- ◆ Prawdopodobieństwo każdej ścieżki jest iloczynem prawdopodobieństw przejść jednokrotnych.
- ◆ Istotna ścieżka o długości 3 o prawdopodobieństwie  $p^3$  S: (1)  $\rightarrow$  (2)  $\rightarrow$  (4)  $\rightarrow$  (5)
- ◆ Zatem prawdopodobieństwo wygrania w trzech grach wynosi  $p^3$

# Przykład

- ◆ Istotna ścieżka o długości 4
- ◆ R: (1)  $\rightarrow$  (2)  $\rightarrow$  (3)  $\rightarrow$  (5)
- ◆ ma prawdopodobieństwo  $p^3q$ .
- ◆ Zatem prawdopodobieństwo wygrania w 4 lub mniej grach wynosi  $p^3(1+q)$ .

# Przykład

- ◆ Nie ma istotnych ścieżek o długości 6.
- ◆ Istotna ścieżka o długości 7 ma jedna pętle
- ◆ L:  $(1) \rightarrow (2) \rightarrow (4) \rightarrow (3) \rightarrow (1)$ ,
- ◆ po czym następuje ścieżka S.

# Przykład

- ◆ Prawdopodobieństwo pętli  $L$  wynosi  $\lambda = p^2q^2$ , zatem prawdopodobieństwo dla ścieżki  $L^*S$  wynosi  $\lambda q^3$ .
- ◆ Zatem prawdopodobieństwo wygrania w 7 lub mniej grach wynosi
- ◆  $p^3(1 + \lambda) + p^3q$ .


# Przykład

- ◆ Istnieje jedna ścieżka o długości 8:  $L^*R$ , dla której prawdopodobieństwo wynosi  $\lambda p^3q$ .
- ◆ Zatem prawdopodobieństwo wygrania w 8 lub mniej grach wynosi  $p^3(1+q)(1+\lambda)$ .
- ◆ Zauważmy ogólną prawidłowość, że wszystkie dłuższe ścieżki są typu  $L^* \dots * L^*S$  lub  $L^* \dots * L^*R$ .
- ◆ Ich prawdopodobieństwa przy  $n$  pętlach wynoszą
- ◆  $\lambda^n p^3$  i  $\lambda^n p^3 q$ .

# Przykład

- ◆ Prawdopodobieństwo wygranej przy nieograniczonej liczbie prób wynosi

$$p^3(1+q)(1+\lambda+\lambda^2+\dots) = \frac{p^3(1+q)}{1-\lambda}$$



**Koniec**