STUDIA INFORMATICA 2000
Volume 21 Number 1 (39)

Stanisław JĘDRUŚ
Instytut Informatyki Teoretycznej i Stosowanej PAN

PORÓWNANIE I OCENA DOKŁADNOŚCI METOD MODELOWANIA NATĘŻENIA RUCHU W SIECIACH KOMPUTEROWYCH[1]

Streszczenie. Artykuł prezentuje dwie najdokładniejsze ogólne metody modelowania natężenia ruchu w sieciach komputerowych, porównując ich dokładność na przykładzie przesyłów ruchomych obrazów w standardzie MPEG.

A COMPARISON AND EVALUATION OF COMPUTER NETWORK TRAFFIC MODELLING METHODS

Summary. Two most accurate general methods of network traffic modelling are presented. A comparison of them is performed on the basis of computation results obtained for an exemplary computer network model.

1. Wstęp

Wzrost popularności metod transmisji uwzględniających parametry jakości usług powoduje, że coraz istotniejsze stają się metody modelowania transmisji, pozwalające przewidzieć wpływ rozmaitych czynników na te parametry. Problem modelowania przesyłów można podzielić na dwa zasadniczo rozłączne problemy: modelowanie źródła oraz modelowanie mechanizmu przesyłającego. W niniejszej pracy skupiono się na modelach źródeł.

W artykule przedstawiono dwie najbardziej obiecujące ogólne metody modelowania źródeł: metodę MMPP (Markov modulated Poisson processes) oraz metodę MWM (multifractal wavelet models). Metody te pozwalają na uzyskanie rezultatów najbardziej

[1] Praca wykonana w ramach projektu badawczego 8 T11C 038 16

zbliżonych do rezultatów uzyskiwanych z wykorzystaniem doświadczalnie zebranych próbek natężenia ruchu. Opis metod poprzedzono wstępem teoretycznym na temat metod opisu charakteru natężenia ruchu. W ramach tego wstępu podjęto próbę definicji procesu o własnościach multifraktalnych.

Przedstawione metody zostały wykorzystane w zaprezentowanym na zakończenie przykładzie modelu fragmentu sieci oraz przesyłu ruchomych obrazów w standardzie MPEG. Przykład ten posłużył do porównania dokładności wyników uzyskiwanych za pomocą omówionych w artykule metod.

2. Charakterystyki opisujące natężenie ruchu

2.1. Reprezentacja natężenia ruchu

W niniejszej pracy natężenie ruchu będzie reprezentowane poprzez proces z czasem dyskretnym: ciąg wartości (próbek) natężenia ruchu x_i obserwowanych w stałych odstępach czasu Δt. Wartość pojedynczej próbki należy traktować jako uśrednioną wartość natężenia ruchu $x(t)$ obserwowanego w poprzedzającym odcinku czasu Δt:

$$x_i = \frac{1}{\Delta t} \int_{(i-1)\Delta t}^{i\Delta t} x(t)dt .$$

Natężenie ruchu określa ilość informacji (liczbę bitów), które przesłano przez dany punkt sieci w określonym kierunku w przeciągu jednostkowego odcinka czasu. Jeśli $N(t)$ oznacza liczbę bitów informacji przesłaną w czasie $[0;t]$, wówczas funkcję $x(t)$ należy rozumieć jako pochodną tej funkcji:

$$x(t) = \frac{dN(t)}{dt},$$

a proces x_i można zdefiniować również jako

$$x_i = \frac{N(t) - N(t-\Delta t)}{\Delta t}.$$

2.2. Skala czasu procesu natężenia ruchu

Poprzez skalę czasu procesu natężenia ruchu określa się odcinek czasu, podczas którego uśredniana jest wartość natężenia ruchu dla uzyskania pojedynczej próbki. Skala czasu może być określana w wartościach bezwzględnych i wówczas odpowiada ona wartości Δt. Częściej używane jest jednak względne określenie skali czasu procesu oznaczane przez m.

W takim wypadku dysponujemy pewnym procesem natężenia ruchu x_i, którego bezwzględna skala czasu to Δt. Proces ten następnie ulega przekształceniu w proces $x_i^{(m)}$

$$x_i^{(m)} = \frac{1}{m}\sum_{k=1}^{m} x_{(i-1)m+k}.$$

Zatem m, zgodnie z powyższym wzorem, oznacza liczbę kolejnych przedziałów Δt, dla których następuje uśrednienie wartości procesu x_i (a zatem również $x(t)$), aby otrzymać pojedynczą próbkę procesu $x_i^{(m)}$. Proces x_i może być rozumiany jako proces w skali $m = 1$.

2.3. Charakterystyki podstawowe

Podstawowe dwie charakterystyki używane do opisu natężenia ruchu to jego wartość średnia

$$\mu = \frac{1}{N}\sum_{i=1}^{N} x_i$$

oraz wariancja

$$\sigma^2 = \frac{1}{N}\sum_{i=1}^{N}(x_i - \mu).$$

W powyższych wzorach N oznacza liczbę próbek procesu.

Alternatywą dla tych dwóch statystyk jest histogram natężenia ruchu pakietów. Jednak w wypadku gdy rozkład natężenia ruchu jest nam znany lub też może być z wystarczającą dokładnością przybliżony jednym ze znanych rozkładów statystycznych, wartość średnia i wariancja zapewniają bardziej dokładny i wygodniejszy w użyciu opis natężenia ruchu pakietów.

2.4. Autokorelacja

Dla uzyskania wyników symulacji lub badań analitycznych lepiej odpowiadających rzeczywistości konieczne jest rozważanie procesów natężenia ruchu jako uogólnionych procesów statystycznych opisanych nie tylko rozkładem wartości takiego procesu, ale również jego funkcją autokorelacji. Funkcja ta dla procesu x_i wyrażona jest wzorem

$$R(k) = \frac{1}{N-|k|}\sum_{i=1}^{N-|k|} x_i x_{i+|k|}.$$

Powyższa formuła obowiązuje dla procesów słabo stacjonarnych, tj. takich, których momenty nie ulegają zmianom w czasie. Doświadczalne stwierdzenie stacjonarności procesu w wypadku pomiarów natężenia ruchu jest na ogół trudne i kłopotliwe do przeprowadzenia, gdyż dysponujemy pojedynczą realizacją badanego procesu. W praktyce, jeśli przedział czasu

trwania pomiaru jest wystarczająco krótki (maksymalnie rzędu kilkudziesięciu minut pracy sieci), stacjonarność można przyjąć w oparciu o założenie, że przyczyny wywołujące ruch w sieci są w tym czasie losowe i stałe. Dla dłuższych przedziałów czasu proces natężenia ruchu w sieci na ogół nie jest procesem stacjonarnym ze względu na dobowy oraz tygodniowy cykl aktywności człowieka.

Do opisu natężenia ruchu często zamiast funkcji autokorelacji używana jest funkcja autokowariancji

$$r(k)=\frac{1}{N-|k|}\sum_{i=1}^{N-|k|}(x_i-\mu)(x_{i+|k|}-\mu)=R(k)-(N-|k|)\mu^2$$

oraz funkcja współczynnika autokorelacji

$$c(k)=\frac{r(k)}{r(0)}.$$

Ta ostatnia funkcja umożliwia szybkie i czytelne porównanie zależności czasowych występujących w różnych procesach, gdyż jest niezależna od przesunięcia (wartości średniej) oraz skali (wariancji) badanego procesu.

Ponieważ wiele procesów odznacza się szczególnymi własnościami, ogólne metody opisu zwykle stanowią zbyt zgrubne narzędzie, aby czytelnie opisać badany proces (np. natężenie ruchu w sieci komputerowej). Jeśli jesteśmy w stanie zaklasyfikować proces do pewnej grupy o specjalnych własnościach, wówczas zwykle można określić parametry lepiej opisujące procesy z tej grupy, niż narzędzia stosowane w ogólnym przypadku. Prostym przykładem takiej sytuacji jest opis procesu za pomocą histogramu wartości. Histogram ten stanowi przybliżenie rozkładu wartości procesu. Jeżeli jednak znamy teoretyczny model tego rozkładu (np. wzór opisujący funkcję gęstości), to możemy określić parametry tego rozkładu i przez to stworzyć dokładniejszy model teoretyczny procesu niż opis za pomocą histogramu.

Podobna sytuacja występuje w wypadku funkcji autokorelacji procesu. Doświadczalne wyznaczenie funkcji autokorelacji daje nam podobną informację na temat zależności czasowych występujących w procesie, jak histogram w wypadku rozkładu wartości. Zaklasyfikowanie procesu do grupy o szczególnych własnościach czasowych pozwala na uzyskanie lepszych modeli teoretycznych niż modele opracowane na podstawie samej funkcji autokorelacji. Do tej pory wyróżniono dwie takie klasy procesów: procesy skalowalne statystycznie oraz procesy skalowalne multifraktalnie. Pierwsza grupa może być scharakteryzowana za pomocą wartości wykładnika Hursta, natomiast druga grupa jest charakteryzowana za pomocą widma multifraktalnego. Poniżej zostały przytoczone metody uzyskiwania tych charakterystyk. Przynależność procesu do pierwszej grupy nie wyklucza przynależności do drugiej i odwrotnie.

2.5. Wykładnik Hursta

Wykładnik Hursta jest parametrem charakteryzującym procesy skalowalne statystycznie. Własność skalowalności statystycznej oznacza, że istnieje pewien stały wykładnik β taki, że

$$\sigma_X^2 = m^\beta \sigma_{X^{(m)}}^2$$

niezależnie od przyjętej skali m. Wówczas wykładnik Hursta jest określony następującym wzorem:

$$H = 1 - \frac{\beta}{2}.$$

Wykładnik Hursta w ogólności może przyjmować wartości z przedziału $(0;1)$. Jak wynika z powyższych wzorów, wartość $H = 0{,}5$ oznacza, że wariancja jest dokładnie odwrotnie proporcjonalna do skali czasu, w jakiej obserwujemy badany proces. Ponieważ m wyraża liczbę próbek procesu w podstawowej skali czasu, które są uśredniane dla uzyskania pojedynczej próbki procesu w skali m, zatem spadek wariancji wraz ze wzrostem m jest w tym wypadku idealnie taki, jakiego należy oczekiwać dla procesów o niezależnych przyrostach. Jeśli wartość wykładnika Hursta jest niższa od 0,5, proces musi charakteryzować się ujemną autokorelacją. Natomiast jeżeli wartość wykładnika Hursta jest wyższa od 0,5, proces charakteryzuje się dodatnią korelacją, przy czym jego funkcja autokorelacji jest wówczas wyrażona wzorem:

$$r(k) \approx c \cdot k^{-\beta},$$

gdzie c oznacza pewien stały czynnik. Zależność ta jest prawdziwa dla dużych wartości k. Podobny charakter mają również funkcje autokorelacji tego procesu w większych skalach czasu (zachowana jest wartość wykładnika β).

2.6. Widmo multifraktalne

O procesie $x(t)$ mówimy, że jest on skalowalny multifraktalnie w pewnym ustalonym odcinku czasu $[0;T]$, jeśli dla każdej realizacji procesu w tym odcinku, traktowanej jako miara multifraktalna $\mu(u)$, zachodzi tzw. formalizm multifraktalny. Przekształcenie realizacji procesu w miarę multifraktalną należy rozumieć w sposób następujący. Tworzymy ciąg przedziałowych miar multifraktalnych $\{\mu_k(u)\}$ określonych wzorami:

$$\mu_k(u) = \frac{x_{k,i}}{S_k},$$

gdzie

$$x_{k,i} = \int_{(i-1)\cdot T\cdot 2^{-k}}^{i\cdot T\cdot 2^{-k}} x(t)dt,$$

$$S_k = \sum_{j=1}^{2^k} x_{k,j},$$

oraz

$$i = \lceil u \cdot 2^k \rceil.$$

Jako miarę multifraktalną odpowiadającą badanej realizacji procesu $x(t)$ przyjmujemy

$$\mu(u) = \lim_{k\to\infty} \mu_k(u).$$

Jak łatwo sprawdzić, każda z przedziałowych miar μ_k jest unormowana, zatem graniczna miara μ również jest miarą unormowaną, określoną dla $u \in (0;1]$.

Dla wprowadzenia pojęcia widma multifraktalnego konieczne jest uprzednie zdefiniowanie tzw. wykładnika Höldera. Parametr ten określa stopień nieciągłości miary w danym punkcie i jego wartość określona jest formułą

$$\alpha(u) = \lim_{k\to\infty} \alpha_k(u) = \lim_{k\to\infty} \frac{\log \mu_{k,i}}{\log 2^{-k}} = \lim_{k\to\infty} -\frac{1}{k} \log_2 \mu_{k,i},$$

gdzie $\alpha_k(u)$ oznacza wartość przedziałowego wykładnika Höldera w punkcie u.

Widmem multifraktalnym $f_H(\alpha)$ nazywamy funkcję opisującą zależność wymiaru Hausdorffa zbioru punktów dziedziny miary, których wykładnik Höldera zawiera się w infinitezymalnie małym przedziale $(\alpha - d\alpha; \alpha + d\alpha)$, od wartości wykładnika Höldera α, która charakteryzuje dany zbiór. Widmem multifraktalnym $f_G(\alpha)$ nazywamy granicę przeskalowanych histogramów wartości przedziałowego wykładnika Höldera, przy czym jeśli przez $Y_{k,i}$ oznaczymy liczbę wystąpień wykładnika Höldera $\alpha \in (\alpha_i - \Delta\alpha, \alpha_i + \Delta\alpha)$ w mierze μ_k, to wówczas wartość widma obliczamy jako

$$f_G(\alpha) = \lim_{k\to\infty} \frac{Y_{k,i}}{n \log 2},$$

przy czym

$$i : \alpha \in (\alpha_i - \Delta\alpha, \alpha_i + \Delta\alpha),$$

$$\Delta\alpha : \max_{\alpha} f_G(\alpha) = 1$$

oraz

$$\alpha_{i-1} + 2\Delta\alpha = \alpha_i = \alpha_{i+1} - 2\Delta\alpha.$$

Widmem multifraktalnym $f_L(\alpha)$ nazywamy transformatę Legendre'a tzw. funkcji podziału:

$$\tau(q)=\lim_{\delta\to 0}\frac{\log S_\delta(q)}{\log \delta},$$

gdzie

$$S_\delta(q)=\sum_{C\in G_\delta}\mu(C)^q .$$

W powyższym wyrażeniu C oznacza odcinek o długości δ, natomiast G_δ oznacza pokrycie dziedziny miary rozłącznymi odcinkami C. Transformatę Legendre'a obliczamy jako:

$$f_L(\alpha)=\tau^*(\alpha)=\inf_q(q\alpha-\tau(q)).$$

Ponieważ funkcja podziału obliczona na prawidłowo skonstruowanej mierze multifraktalnej jest funkcją wklęsłą, transformatę Legendre'a można obliczyć ze wzoru

$$f_L(\alpha)=\tau^*(\alpha(q))=q\tau'(q)-\tau(q),$$

gdzie $\alpha(q)=\tau'(q)$.

Jeżeli wymienione trzy widma istnieją i są sobie równe, to wówczas badany proces jest skalowalny multifraktalnie. Warunek równości trzech funkcji widma multifraktalnego

$$f_L(\alpha)=f_G(\alpha)=f_H(\alpha)$$

określa się mianem formalizmu multifraktalnego.

3. Metody modelowania natężenia ruchu

Modelem natężenia ruchu jest opis generatora wraz z odpowiednio dobranymi parametrami, który umożliwia wygenerowanie procesu o własnościach zbliżonych do modelowanego procesu natężenia ruchu. Dzięki temu, że znana jest konstrukcja takiego generatora, możliwe jest wykorzystanie takiego modelu praktycznie w symulacji lub w metodach analitycznych.

Niezbędna dokładność, z jaką generator powinien aproksymować modelowany proces, jest zależna od przewidywanego zastosowania. Właściwym kryterium jest porównanie wyników uzyskiwanych w określonym zastosowaniu z wykorzystaniem danej metody modelowania natężenia ruchu z wynikami uzyskanymi przy zastosowaniu przykładowej realizacji modelowanego procesu. Zakłada się, że tak uzyskana ocena dokładności może być uogólniona na inne realizacje modelowanego procesu bądź też na inne procesy o własnościach zbliżonych, ale różnych wartościach poszczególnych charakterystyk. O dwóch

procesach można powiedzieć, że posiadają zbliżone własności, jeżeli ta sama liczba i rodzaj charakterystyk wystarcza do ich opisania, tj. stworzenia na podstawie tego zestawu charakterystyk dobrego modelu (w odniesieniu do określonego zastosowania). Poniżej przedstawiono kilka popularnych koncepcji modeli natężenia ruchu konstruowanych w oparciu o proces poissonowski modulowany procesem markowowskim z czasem dyskretnym [1]. Modele te różnią się stopniem złożoności i dokładnością aproksymacji procesów natężenia ruchu.

Jako ostatni model zostanie zaprezentowana koncepcja multifraktalnych modeli falkowych [2], które zostały opracowane z myślą o prostym i dokładnym uwzględnieniu dwóch własności procesów natężenia ruchu: nieujemności oraz skalowalności statystycznej. Dodatkowo, przy konstrukcji tego rodzaju modeli użyteczne okazuje się widmo multifraktalne, którego znajomość pozwala w łatwy sposób zidentyfikować strukturę modelu.

3.1. Procesy MMPP aproksymujące histogram natężenia ruchu

Aby skonstruować model MMPP w oparciu o histogram natężenia ruchu, należy:

a) sklasyfikować zaobserwowane wartości natężenia ruchu,
b) obliczyć liczbę wystąpień wartości natężenia ruchu przynależących do poszczególnych klas,
c) na podstawie uzyskanych częstości obliczyć prawdopodobieństwo obserwacji wartości należących do poszczególnych klas,
d) skonstruować dyskretny proces markowowski o liczbie stanów równej liczbie klas natężenia ruchu oraz prawdopodobieństwach poszczególnych stanów równych prawdopodobieństwom odpowiadających im klas,
e) przypisać każdemu stanowi procesu markowowskiego intensywność procesu poissonowskiego równą średniemu natężeniu ruchu w odpowiedniej dla danego stanu klasie.

Działanie tak skonstruowanego modelu polega na tym, że proces markowowski przechodząc ze stanu do stanu zmienia intensywność procesu poissonowskiego używanego do generowania procesu natężenia ruchu. Proces poissonowski generuje co pewien czas, zgodnie ze swoją intensywnością, stałą porcję informacji (np. 1 bit). Otrzymany proces można przekształcić, zmieniając jego skalę czasu, do procesu reprezentującego liczbę bitów na jednostkę czasu.

Pewną trudnością przy konstruowaniu tego rodzaju modeli jest fakt, że istnieje około $n!(n-2)^n$ n-stanowych procesów Markowa, których prawdopodobieństwa stanów są równe, w tym przynajmniej $(n-2)^n$ należy uznać za istotnie różne (różnią się strukturą możliwych przejść pomiędzy stanami, a nie jedynie wartościami wag). Niemniej jednak przy

odpowiednio krótkim czasie trwania taktu wybór konkretnego rozwiązania nie powinien mieć znaczenia dla własności generowanego procesu. Najprostszym sposobem na skonstruowanie odpowiedniego procesu jest umożliwienie przejścia z każdego stanu i do każdego stanu j, przy czym j może być równe i. Wtedy prawdopodobieństwo przejścia ze stanu i do stanu j powinno być równe prawdopodobieństwu stanu j.

3.2. Procesy MMPP aproksymujące zależności krótkoterminowe

Model ten jest prostym rozwinięciem poprzedniego modelu. Aby skonstruować taki model należy:

a) sklasyfikować wartości natężenia ruchu x_i,

b) utworzyć ciąg numerów klas wartości natężenia ruchu $\{c_k\}$, przy czym $c_i : x_i \in C_{c_i}$, gdzie C_n oznacza n-tą klasę wartości natężenia ruchu,

c) utworzyć macierz $\mathbf{Q}$ prawdopodobieństw przejść pomiędzy stanami dla procesu markowowskiego modulującego proces poissonowski, przy czym element q_{ij} jest równy prawdopodobieństwu wystąpienia w ciągu $\{c_k\}$ pary i, j. Element q_{ij} określa prawdopodobieństwo przejścia ze stanu i do stanu j,

d) przypisać każdemu stanowi procesu markowowskiego intensywność procesu poissonowskiego równą średniemu natężeniu ruchu w odpowiedniej dla danego stanu klasie.

Tak skonstruowany model odzwierciedla pewne zależności czasowe występujące w modelowanym procesie, jednakże ich funkcja autokorelacji w ogólności jest funkcją wykładniczą i otrzymane za pomocą takiego generatora procesy nie charakteryzują się skalowalnością statystyczną.

3.3. Procesy MMPP aproksymujące zależności krótko- i długoterminowe

Prawidłowa aproksymacja zależności czasowych zarówno krótko-, jak i długoterminowych wymaga „hierarchicznego" złożenia kilku modeli MMPP aproksymujących zależności krótkoterminowe. Model taki jest konstruowany wieloetapowo. Podany niżej algorytm określa sposób tworzenia modelu złożonego z dwóch poziomów procesów MMPP, jakkolwiek może być w łatwy sposób rozszerzony na więcej poziomów, jeśli zachodzi taka potrzeba.

W pierwszym etapie tworzymy n-stanowy proces markowowski aproksymujący zależności długoterminowe. Postępujemy przy tym dokładnie tak, jak przy konstrukcji modelu z zależnościami krótkoterminowymi. Po utworzeniu macierzy prawdopodobieństw

przejść pomiędzy stanami dla tego modelu można przystąpić do drugiego etapu: tworzenia modeli aproksymujących zależności krótkoterminowe modelowanego procesu. W tym celu próbki procesu należące do klasy C_k należy połączyć w pojedynczy ciąg próbek (proces) $x_{k,j}$ (j - numer próbki w nowym procesie). W wyniku powstało n nowych procesów. Następnie, dla każdego z tych procesów wykonujemy normalny m-stanowy model aproksymujący zależności krótkoterminowe.

Działanie tak skonstruowanego generatora polega na tym, że stan n-stanowego procesu markowowskiego wyznacza nam aktywny m-stanowy model markowowski (tj. taki, którego stan ulegnie zmianie w następnym takcie i którego stan wyznacza intensywność procesu poissonowskiego reprezentującego proces natężenia ruchu). W chwili gdy dany proces podrzędny jest nieaktywny, jego stan ulega „zamrożeniu", pozostaje w tym samym stanie do chwili, w której proces nadrzędny przejdzie do stanu aktywującego dany proces podrzędny. Gdy proces nadrzędny wychodzi ze stanu odpowiadającego danemu procesowi podrzędnemu, stan procesu ponownie ulega „zamrożeniu" i proces podrzędny przestaje być aktywny.

3.4. Multifraktalne modele falkowe

Multifraktalne modele falkowe stanowią interesującą alternatywę dla złożonych, wielostanowych, a dodatkowo w praktyce trudno stosowalnych modeli markowowskich. W porównaniu z modelami markowowskimi wykazują kilka podstawowych zalet:

a) ich parametry wyznacza się na podstawie charakterystyk procesu, a nie jego realizacji,
b) generowane z wykorzystaniem tych modeli procesy z definicji wykazują pewne własności obserwowane dla natężenia ruchu: skalowalność statystyczną i multifraktalną.

Pierwsza zaleta umożliwia łatwe tworzenie procesów, których parametry znamy, a realizacji nie możemy uzyskać w sposób doświadczalny (np. jeśli chcemy sprawdzić własności sieci w warunkach obciążenia skrajnego typu).

Druga własność pokazuje wyraźną przewagę tej metody nad klasycznymi już metodami markowowskimi, gdyż procesy markowowskie stanowią z reguły jedynie lepszą lub gorszą aproksymację, natomiast ich graniczne własności (np. w dużych skalach czasu) odbiegają od obserwowanych w rzeczywistości. Natomiast modele multifraktalne pozwalają na uzyskanie skalowalności statystycznej zgodnie z jej definicją.

Generowanie procesu z wykorzystaniem multifraktalnego modelu falkowego polega na mnożeniu wielu specjalnie skonstruowanych, niezależnych procesów losowych. W ogólności próbkę x_i można wyrazić jako

$$x_i = \prod_{k=0}^{N-1} a_{k,i}$$

gdzie $a_{k,i}$ oznacza i-tą próbkę k-tego procesu. Próbki k-tego procesu powinny spełniać warunek

$$a_{k,j\cdot 2^k+1} = a_{k,j\cdot 2^k+2} = \ldots = a_{k,j\cdot 2^k+2^k}; \quad j \in \{0,1,2,\ldots\}.$$

Wariancja każdego procesu $a_{k,i}$ powinna być dobrana tak, aby spełniony był warunek skalowalności statystycznej procesu x_i.

Liczbę N procesów niezbędnych do prawidłowego zamodelowania danego procesu można oszacować [3] wykorzystując obliczone widmo multifraktalne:

$$N < \frac{\log\left(\dfrac{\mu^2+\sigma^2}{\mu^2}\right)}{\log\left(\alpha_{max}+\alpha_{min}-\alpha_{max}\alpha_{min}\right)}.$$

W powyższej nierówności α_{min} i α_{max} oznaczają odpowiednio minimalną i maksymalną wartość wykładnika Höldera występującą w widmie multifraktalnym modelowanego procesu.

4. Porównanie wyników symulacji dla modeli natężenia ruchu przy przesyłach MPEG-1

Poniżej zaprezentowano przykładowe wyniki modelowania pracy sieci komputerowej z wykorzystaniem różnych modeli natężenia ruchu dla przesyłów ruchomych obrazów kodowanych w standardzie MPEG-1. Oprócz wyników uzyskanych z wykorzystaniem różnych modeli zaprezentowano także, dla porównania, wyniki uzyskane przy użyciu danych o natężeniu ruchu przy przesyle filmu „Gwiezdne wojny" [4].

4.1. Opis modelowanego fragmentu sieci

Modelowany fragment sieci (rys. 1) składał się z następujących elementów:

- nadajnika MPEG-1 (A),
- mechanizmu dzielenia ramek na komórki (E),
- mechanizmu „cieknącego wiadra" (F,G,H,I),
- bufora wyjściowego stacji nadawczej o pojemności 10 000 komórek (J),
- linii przesyłowych (K,R,S),
- buforów węzła przełączającego o pojemności 5 000 komórek każdy (L,M,P,Q),

- dodatkowych użytkowników sieci (B,C,D,N),
- odbiorcy dla strumienia MPEG-1 oraz części dodatkowego ruchu (T),
- odbiorcy pozostałej części dodatkowego ruchu (U).

Źródła A,C oraz N transmitowały dane do odbiorcy T, natomiast źródło D transmitowało dane do odbiorcy U. Suma intensywności źródeł A, C i D określała obciążenie linii K, natomiast suma intensywności źródeł A, C i N określała obciążenie linii R. Zmieniając parametry źródeł C, D i N zmieniano obciążenie linii K i R zmieniając warunki dla strumienia nadawanego przez źródło A. Intensywności źródeł C, D i N były sobie równe. Parametry „cieknącego wiadra" dobrano tak, aby wychodzący z niego strumień charakteryzował się średnią intensywnością około 3Mbps oraz maksymalną intensywnością około 15Mbps.

Ze względu na ograniczone zasoby obliczeniowe przepustowość sieci została w tym przykładzie określona na 34 Mbps.

Wynikiem symulacji były parametry jakości usług dla strumienia MPEG-1 oraz średnie długości kolejek J i M w zależności od współczynnika całkowitego obciążenia sieci. Parametry dodatkowych źródeł dobrano tak, aby obciążenie na liniach K i R było równe.

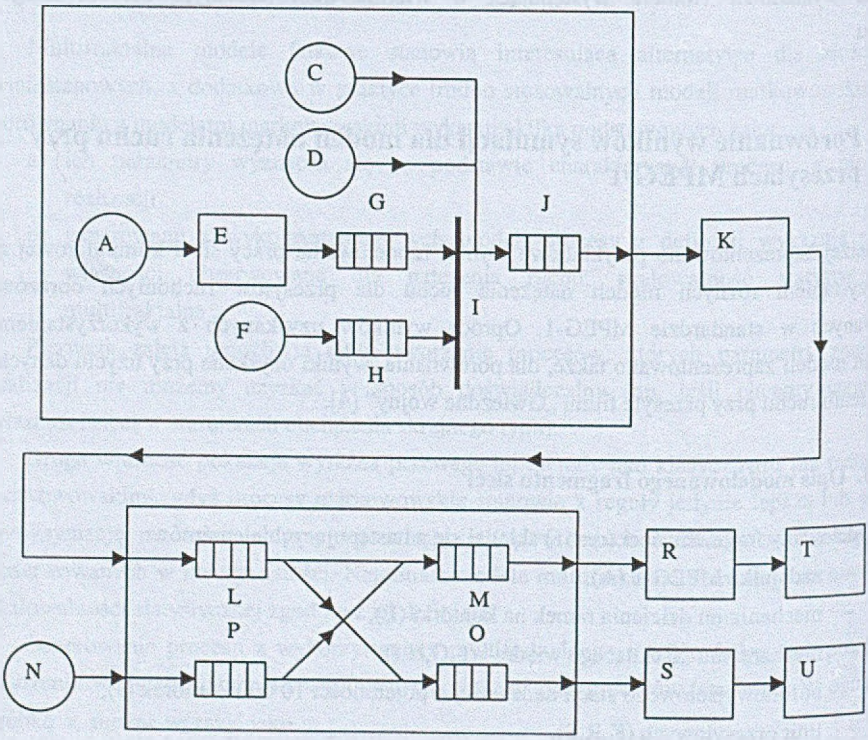

Rys. 1. Model sieci użyty w doświadczeniach
Fig. 1. A network model used in experiments

4.2. Omówienie uzyskanych wyników

Na rys. 2 przedstawiono porównanie średnich względnych odchyleń pomiędzy wynikami uzyskanymi za pomocą przedstawionych metod a wynikami uzyskanymi dla oryginalnego strumienia MPEG-1.

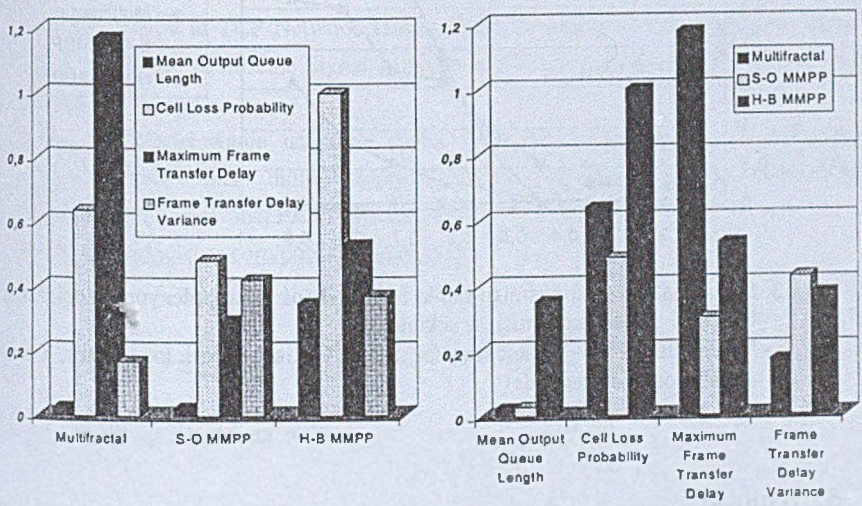

Rys. 2. Porównanie średnich względnych odchyleń wyników obliczeń
Fig. 2. A comparison of mean relative deviations of computation results

Wykresy te pokazują, że wyniki otrzymywane z wykorzystaniem modelu multifraktalnego (Multifractal) są w omówionym przykładzie porównywalne z wynikami otrzymanymi z wykorzystaniem modelu MMPP uwzględniającego długo- i krótkoterminowe zależności czasowe (S-O MMPP: scene-oriented Markov modulated Poisson process). Natomiast wyniki uzyskane z wykorzystaniem modelu MMPP aproksymującego histogram natężenia ruchu (H-B MMPP: histogram based Markov modulated Poisson process) dalece odbiegają od wyników uzyskiwanych z wykorzystaniem oryginalnej próbki. Dla modelu multifraktalnego w jednym wypadku (maksymalny czas transmisji ramki) otrzymano dużą wartość średniego względnego odchylenia. Pełny wykres uzyskanych w tym wypadku wyników zaprezentowano na rys. 3. Jak wynika z tego wykresu, duża wartość otrzymanego odchylenia wynika z dużych względnych różnic dla niskich obciążeń, podczas gdy dla współczynników obciążenia większych od 0,5 model ten dawał najlepsze rezultaty wśród porównywanych modeli.

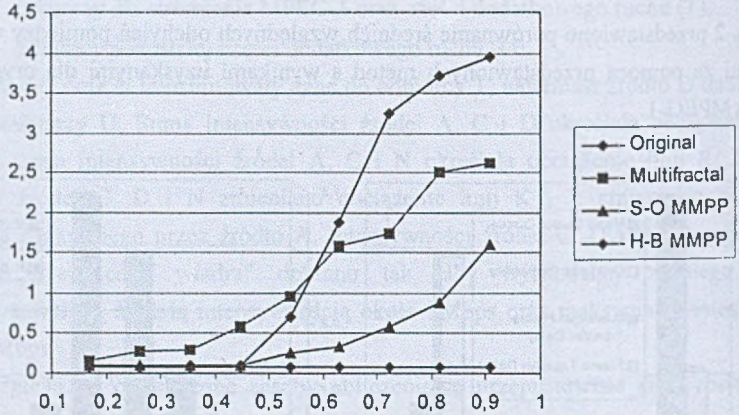

Rys. 3. Maksymalny czas transmisji ramki MPEG-1 (oś X: współczynnik obciążenia łącza, oś Y: czas transmisji w sekundach)
Fig. 3. Maximum MPEG-1 frame transfer delay (X axis: network load factor, Y axis: transfer delay in seconds)

5. Wnioski

W niniejszej pracy porównano dwie koncepcje modelowania natężenia ruchu w sieciach komputerowych: modele MMPP oraz modele multifraktalne. Modele MMPP opracowuje się na podstawie histogramu natężenia ruchu bądź też bezpośrednio na podstawie doświadczalnie uzyskanych sekwencji próbek. Natomiast modele multifraktalne opracowywane są na podstawie charakterystyk natężenia ruchu (wartości średniej, wariancji, wykładnika Hursta oraz skrajnych wartości wykładnika Höldera). Przeprowadzone przykładowe doświadczenie pokazuje, że przy modelowaniu natężenia ruchu przy przesyłach ruchomych obrazów kodowanych w standardzie MPEG, model MMPP aproksymujący histogram natężenia ruchu nie jest wystarczający, natomiast modele multifraktalny i MMPP uwzględniający długoterminowe zależności czasowe są praktycznie równoważne i można z ich pomocą uzyskać wyniki modelowania stosunkowo niewiele różniące się od wyników modelowania uzyskanych z pomocą oryginalnych sekwencji próbek.

LITERATURA

1. Roberts L., Mocci U., Virtamo J. (Eds.): Broadband Network Teletraffic, Performance Evaluation and Design of Broadband Multiservice Networks, Final Report of Action COST 242. Springer Verlag, Berlin, Heidelberg 1996.
2. Riedi R.H., Crouse M.S., Ribeiro V.J., Baraniuk R.G.: A Multifractal Wavelet Model with Application to TCP Network Traffic. IEEE Transactions on Information Theory (Special Issue on Multiscale Signal Analysis and Modeling), Kwiecień 1999, t. 45, s. 992-1018
3. Jędruś S.: Modelowanie natężenia ruchu pakietów w sieciach komputerowych z wykorzystaniem miar multifraktalnych. Praca doktorska. Instytut Informatyki Teoretycznej i Stosowanej PAN, Gliwice 1999.
4. ftp://thumper.bellcore.com/pub/vbr.video.trace

Recenzent: Dr inż. Ewa Starzewska-Karwan

Wpłynęło do Redakcji 3 kwietnia 2000 r.

Abstract

A paper briefly presents main methods of network traffic characterization. Next, two most accurate methods of network traffic modeling (namely scene-oriented MMPP and multifractal wavelet models) are described. These methods are compared against each other. A comparison is performed on exemplary simple network model computation results. The results consist of the mean output queue length, cell loss probability, maximum MPEG frame transfer delay and two-point MPEG frame transfer delay variation. A conclusion is that mentioned methods are approximately equivalent in respect to simulation results.