

WŁODARSKI Przemysław¹

MODELOWANIE RUCHU W SIECIACH TELEINFORMATYCZNYCH W OPARCIU O UŁAMKOWY PROCES AUTOREGRESJI

Modelowanie ruchu w sieciach teleinformatycznych, biorąc pod uwagę, że wykazuje on właściwości samopodobieństwa, prowadzi do bardziej dokładnych oszacowań parametrów efektywności, takich jak opóźnienie czy poziom strat pakietów, co w konsekwencji powoduje lepszą kontrolę poziomu usług (Quality of Service). Artykuł prezentuje metodę dopasowania ułamkowego procesu autoregresji do rzeczywistych danych natężenia ruchu, skupiając się na zależnościach krótkoterminowych. Ponieważ prezentowany model może zawierać w sobie zarówno zależności długo- jak i krótkoterminowe, wydaje się być lepszą propozycją niż modele oparte jedynie o własności autokorelacyjne procesu. W artykule przedstawiono metodę generowania ruchu, jak również różne kryteria wyboru rzędu dla zależności krótkoterminowych.

MODELING NETWORK TRAFFIC BASED ON FRACTIONAL AUTOREGRESSIVE PROCESS

Modeling ICT network traffic by taking into consideration self-similar behavior of the traffic leads to more accurate estimation of performance parameters, such as delay or packet loss rate, and hence better control of quality of service levels. This paper presents a method of fitting fractional autoregressive process into real network traffic data, focusing on short-range dependent properties. Since presented model can capture both short-range and long-range dependence, it seems to be a better approximation of network traffic than relying only on autocorrelation properties of the process. Method of generation as well as the model order selection and parameter estimation techniques are presented and discussed.

1. WSTĘP

Natężenie ruchu w sieciach teleinformatycznych wykazuje własności samopodobne [1,2]. Z tego powodu model opisujący ten ruch powinien być oparty o procesy posiadające zależności długoterminowe (long-range dependent), w przeciwieństwie do modeli: Poissona, Gaussa, AR, MA, ARMA czy też ARIMA [1,4,6]. Zależności długoterminowe

¹ Zachodniopomorski Uniwersytet Technologiczny, Wydział Elektryczny, Katedra Przetwarzania Sygnałów i Inżynierii Multimedialnej, 71-126 Szczecin, ul. 26 Kwietnia 10, tel.: +4891 449-5311, fax: +4891 449-5347, e-mail: Przemyslaw.Wlodarski@zut.edu.pl

obserwowane w natężeniu ruchu związane są z wolno opadającą wariancją dla zagregowanych szeregów czasowych, jak również z tym, że suma współczynników autokorelacji zmierza do nieskończoności. Taka natura ruchu mocno różni się od wspomnianych wcześniej modeli i sprawia wiele problemów w sterowaniu przeciążeniami oraz utrudnia zapewnienie odpowiedniego poziomu usług (QoS – Quality of Service). Dzieje się tak głównie z powodu mniej efektywnego działania systemów kolejkowych w porównaniu do modeli tradycyjnych [6].

Artykuł prezentuje metodę generowania ułamkowego autoregresyjnego szeregu czasowego (rozdział 2) jako modelu natężenia ruchu, który wykazuje nie tylko cechy samopodobne, ale również zawiera w sobie cechy modeli tradycyjnych. Prezentowany model zostanie użyty w rozdziale 3 w celu dopasowania do rzeczywistych danych otrzymanych z sieci komputerowej. Do oszacowania parametrów modelu zostanie użyta metoda periodogramu dla zależności długoterminowych oraz cztery różne kryteria do wyboru rzędu i parametrów części krótkoterminowej (short-range dependent).

2. GENEROWANIE UŁAMKOWEGO PROCESU AUTOREGRESJI

Ułamkowy proces autoregresji wywodzi się i jest uproszczeniem ułamkowego autoregresyjnego zintegrowanego procesu średniej ruchomej (FARIMA - Fractional Autoregressive Integrated Moving Average). Różnica polega na tym, że brak jest części odpowiedzialnej za średnią ruchomą. Z kolei proces FARIMA jest naturalnym rozszerzeniem modelu ARIMA, zaprezentowanego przez Boxa i Jenkinsa [3]. Dla $E(X_t) = 0$ proces ARIMA przybiera następującą postać:

$$\Phi(B)(1-B)^d X_t = \Psi(B)\varepsilon_t, \quad (1)$$

gdzie B oznacza operator przesunięcia wstecz oraz ε_t ($t = 1, 2, \dots$) jest zmienną losową o rozkładzie normalnym z zerową wartością oczekiwaną i wariancją σ^2 . $\Phi(B)$ oraz $\Psi(B)$ są wielomianami:

$$\Phi(x) = 1 - \sum_{j=1}^p \phi_j x^j, \quad \Psi(x) = 1 + \sum_{j=1}^q \psi_j x^j, \quad (2)$$

gdzie p i q to liczby całkowite dodatnie określające rząd odpowiednio części autoregresyjnej oraz średniej ruchomej. W klasycznym modelu ARIMA(p, d, q) parametr d jest liczbą całkowitą, podczas gdy dla procesu FARIMA(p, d, q) d jest nieujemną liczbą rzeczywistą. Uogólnienie wyrażenia $(1-B)^d$ dla rzeczywistego d może być zapisane w następujący sposób:

$$(1-B)^d = \sum_{k=0}^{\infty} \frac{\Gamma(d+1)(-1)^k B^k}{\Gamma(k+1)\Gamma(d-k+1)}. \quad (3)$$

Wynika z tego, że ułamkowy proces autoregresji oznaczony jako FAR(p,d), może być reprezentowany poprzez następujące równanie:

$$\Phi(B)(1-B)^d X_t = \varepsilon_t. \quad (4)$$

Dla $d \in (0;0.5)$ proces FAR(p,d) posiada zależności długoterminowe o określonym poziomie samopodobieństwa określanym za pomocą parametru H , zwanego wykładnikiem Hursta, którego wartości są większe od 0.5: $H = d + 0.5$. Jeżeli $d=0$ wtedy proces FAR(p,d) upraszcza się do klasycznego procesu autoregresji AR(p), który posiada jedynie zależności krótkoterminowe. W celu wygenerowania pełnego procesu FAR(p,d), proponuje się zacząć od procesu FAR($0,d$). W wyniku dekompozycji równania (4) otrzymuje się:

$$X_t = \Phi(B)^{-1} \tilde{X}_t, \quad (5)$$

gdzie \tilde{X}_t jest procesem FAR($0,d$):

$$\tilde{X}_t = (1-B)^{-d} \varepsilon_t. \quad (6)$$


X_t otrzymuje się przez „przepuszczenie” procesu FAR($0,d$) poprzez filtr AR(p). Z drugiej strony, można otrzymać czysty proces AR(p) (X'_t) poprzez „przepuszczenie” X_t poprzez filtr o nieskończonej odpowiedzi impulsowej (NOI), co odpowiada użyciu ułamkowego operatora różnicowania (3). Zatem do wygenerowania FAR($0,d$) wystarczy wykonać następujące obliczenia:

$$\tilde{X}_t = \sum_{k=0}^{\infty} \pi_k X_{t-k} + \varepsilon_t, \quad (7)$$

gdzie

$$\pi_0 = 1, \pi_1 = d, \pi_k = \frac{k-1-d}{k} \pi_{k-1}, \quad k = 2,3,\dots \quad (8)$$

Teraz, po wygenerowaniu procesu FAR($0,d$), można dodać część autoregresyjną AR(p) według równania (5). Rysunek 1 pokazuje przykładowe ścieżki dla FAR($2,d$) wygenerowane przy użyciu wyżej zaprezentowanej metody dla tego samego ε_t i tych samych parametrów autoregresji: $\phi = 0.2$, $\phi = 0.5$, ale dla różnych poziomów różnicowania d . Widać różnicę w zmienności na tych dwóch wykresach – im większy jest poziom różnicowania, tym większą zmienność można zaobserwować.



Rys. 1. Przykładowy proces FAR(0,d) dla $d=0.05$ (po lewej) oraz $d=0.45$ (po prawej)

3. DOPASOWANIE MODELU DO RZECZYWISTYCH DANYCH POCHODZĄCYCH Z POMIARU

W celu dopasowania proponowanego modelu opartego o proces FAR(p,d), trzeba najpierw wyestymować parametr różnicowania. Do realizacji tego zadania została użyta metoda bazująca na periodogramie, której rezultaty pokazane zostały w tabeli 1. Rzeczywisty pomiar został dokonany na głównym firewallu w Zachodniopomorskim Uniwersytecie Technologicznym w godzinach szczytu (13:00 – 15:00), kiedy ruch ma największą intensywność. Cztery wybrane szeregi czasowe (D1 – D4) utworzone na bazie pomiaru zostaną poddane głębszej analizie. Każdy szereg czasowy składa się z 2048 obserwacji natężenia ruchu dla równego odcinka czasu 10 ms, zatem każdy szereg czasowy odpowiada 20.48 sek. pomiaru. Następnie dane przepuszczane są przez filtr NOI zgodnie z równaniem (4), otrzymując proces AR(p). Poziom różnicowania d otrzymane po tej operacji powinien wahać się niewiele wokół wartości 0.

Tab. 1. Wyniki estymacji parametru d dla rzeczywistych danych pochodzących z pomiaru przed i po ułamkowym różnicowaniu

Dane	d dla rzeczywistych danych z pomiaru	d po różnicowaniu
D1	0.3408	0.0038
D2	0.2142	-0.0158
D3	0.2079	-0.0011
D4	0.2587	-0.0055

Po ułamkowym różnicowaniu, można przystąpić do wyznaczenia rzędu dla procesu autoregresji AR(p) – części modelu odpowiedzialnej za zależności krótkoterminowe, używając do tego celu następujących kryteriów [7]:

- Final Prediction Error (FPE)

$$FPE(M) = \frac{N+M}{N-M} \cdot Q_M \tag{9}$$

- Akaike Information Criterion (AIC)


$$AIC(M) = N \log(Q_M) + 2M \tag{10}$$

- Schwarz's method (SM)

$$SM(M) = N \log(Q_M) + M \log(N) \tag{11}$$

- Parzen's method – Criterion Autoregressive Transfer Function (CATF)

$$C_i = \frac{N}{N-i} \cdot Q_i, \quad i = 1, 2, \dots \quad CATF(M) = \frac{1}{N} \sum_{i=1}^M \frac{1}{C_i} - \frac{1}{C_M} \tag{12}$$



Rys. 2. Funkcje kryteriów dla czterech serii danych z pomiaru po procesie różnicowania

Wszystkie kryteria powinny określić optymalny rząd dla procesu AR(p) poprzez minimalizację ich funkcji (9)-(12) opartych o kryterium średniokwadratowe:

$$Q_M = \frac{1}{N} \sum_{n=M}^{N+M-1} \left(X'_{n+1} - \sum_{j=0}^{M-1} \phi_j X'_{n-j} \right)^2 \quad (13)$$

Rys. 2. Pokazuje zachowanie funkcji przedstawionych kryteriów dla czterech różnych serii danych otrzymanych podczas pomiaru po procesie różnicowania: D1 – linia ciągła, D2 – linia kropkowa, D3 – linia przerywana, D4 – linia kropkowo-przerywana. Zestawienie wyników estymacji rzędu p procesu autoregresji $AR(p)$ dla serii pomiarowych nieprzetworzonych oraz po procesie filtracji znajduje się poniżej w tabeli 2.

Tab. 2. Wyniki estymacji rzędu procesu autoregresji $AR(p)$ przy pomocy różnych kryteriów dla danych z pomiaru oraz danych po procesie różnicowania

	p dla danych z pomiarów				p po procesie różnicowania			
	D1	D2	D3	D4	D1	D2	D3	D4
FPE	11	18	19	18	2	2	3	3
AIC	11	18	16	9	2	2	3	3
SM	6	10	5	7	2	1	3	2
CATF	11	18	19	18	3	2	3	3

4. WNIOSKI

Wyniki estymacji rzędu p procesu autoregresji $AR(p)$ przed różnicowaniem są chaotyczne - wahają się między 5 a 19 sugerując odrzucenie klasycznego modelu $AR(p)$ jako procesu dobrze opisującego natężenie ruchu w sieci. Poprzez uwzględnienie zależności długoterminowych otrzymano stabilne rezultaty – wszystkie kryteria wskazały podobne wartości rzędu p między 1 a 3. Wskazuje to na silną obecność zależności długoterminowych. Proponowany model $FAR(p,d)$ będący syntezą klasycznych procesów krótkoterminowych, jak i ułamkowych długoterminowych może być z powodzeniem stosowany do symulacji ruchu w sieci zarówno przy jej projektowaniu, jak i analizie stanu bieżącego. Może również stanowić podstawę do budowy generatorów sieciowych do badania efektywności działania wszelkich pakietowych sieci teleinformatycznych.

5. BIBLIOGRAFIA

- [1] H. Elbiaze et al., "A new structure-preserving method of sampling for predicting self-similar traffic". *Telecommunication Systems* 43 265-277, 2010.
- [2] W. Leland, M. Taqqu, W. Willinger, D. Wilson. "On the Self-Similar Nature of Ethernet Traffic". *IEEE/ACM Transactions on Networking*, 2(1) 1-15, 1994.

- [3] G. E. P. Box, G. M. Jenkins "Time Series Analysis. Forecasting and Control", Holden-Day (1976), San Francisco.
- [4] M. Taqqu, W. Willinger, R. Scherman. "Proof of a Fundamental Result in Self-Similar Traffic Modeling". Computer Communication Review, 27 (1997) 5-23.
- [5] V. Paxson, S. Floyd. "Wide-Area Traffic: The Failure of Poisson Modeling". Proceedings of SIGCOMM'94, 1994.
- [6] Y. Shu, F. Xue, Z. Jin, O. Yang, "The Impact of Self-Similar Traffic on Network Delay", Journal of Computer Science and Technology, 585-589, 1999.
- [7] L. Rutkowski, "filtry adaptacyjne i adaptacyjne przetwarzanie sygnałów", WNT 1994.