

Politechnika Śląska
Wydział Automatyki, Elektroniki i Informatyki

Rozszerzone streszczenie pracy doktorskiej

Godlove Suila Kuaban

Modele stanów nieustalonych, oparte na aproksymacji dyfuzyjnej
i łańcuchach Markowa w analizie efektywności sieci
komputerowych i systemów magazynowania energii

Promotor: Prof. dr hab. inż. Tadeusza Czachórski

Gliwice 2023

1 Kontekst rozprawy

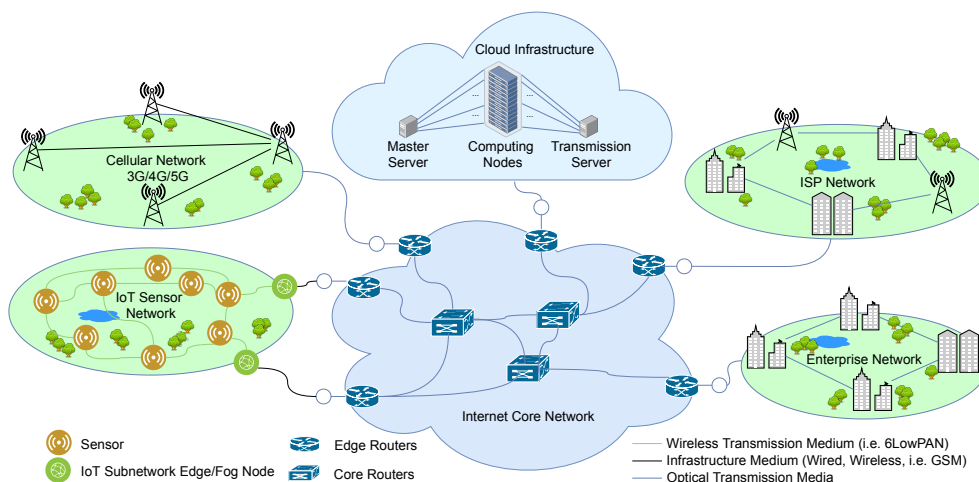
Tematyka rozprawy dotyczy modelowania i oceny efektywności systemów i sieci komputerowych za pomocą modeli kolejkowych. Zajęto się kilkoma problemami wymagającymi opisu stanów nieustalonych kolejki. Jako podstawową metodę analizy wybrano aproksymację dyfuzyjną, posiłkując się również modelami opartymi na łańcuchach Markowa rozwiązywanymi numerycznie.

W szczególności badano pracę mechanizmów agregacji pakietów, pracę nowoczesnych sieci komputerowych zdefiniowanych programowo (Software Defined Networks) oraz systemów magazynowania energii urządzeń sieci komputerowych. Pokazano, jak można zaadaptować metodę aproksymacji dyfuzyjnej w modelowaniu wymienionych problemów uzyskując bardzo dobre wyniki numeryczne. Teza pracy stwierdza użyteczność aproksymacji dyfuzyjnej w tym kontekście.

Rezultaty opisane w dysertacji zostały wcześniej opublikowane. Na końcu opracowania podano spis tych publikacji, oznaczonych (A1)-(A21). Prace były wykonywane częściowo w ramach trzech projektów europejskich typu H2020: *IoTAC -- Security By Design IoT Development and Certificate Framework with Front-end Access Control*, *SDK4ED – Software Development toolKit for Energy optimization and technical Debt elimination*, *SerIoT – Secure and Safe Internet of Things*. Dzięki m.in. tym publikacjom, doktorant otrzymał nagrodę dla najlepszego studenta zagranicznego w Polsce w kategorii studia doktoranckie *Interstudent 2020* (w załączniku).

Typowy model kolejkowy składa się z systemu obsługi i kolejki. Do kolejki nadchodzi *klienci*, czekając na obsługę. Na podstawie informacji o rytmie nadchodzenia klientów i czasu obsługi, model określa czas czekania, długość kolejki, a także prawdopodobieństwo przepełnienia kolejki, co daje prawdopodobieństwo odrzucenia klienta lub je przybliża. Zarówno dane, jak i wyniki modelu mają postać rozkładów prawdopodobieństwa lub są ograniczone do ich wartości średnich, czasem również wariancji. Często używana notacja Kendalla [33] klasyfikuje najczęściej używane modele kolejkowe pojedynczego stanowiska się za pomocą symboli określających kolejno: typ rozkładów czasu pomiędzy nadejściem klientów i czasu obsługi, liczbę pracujących równoległe kanałów obsługi i maksymalną liczbę klientów w systemie; np. $G/G/1/N$ oznacza, że rozkłady czasu pomiędzy nadejściem klientów i czasu obsługi są dowolne, jest jeden kanał obsługi i liczba klientów w systemie nie może przekroczyć N . W modelu typu $M/G/1/N$ rozkład odstępów czasów pomiędzy nadejściem klientów jest wykładniczy, t.zn. strumień wejściowy jest typu Poissona. Pojedyncze stanowiska można łączyć w sieć, podając reguły przechodzenia klientów między stanowiskami.

Teoria kolejek jest użytecznym narzędziem w projektowaniu sieci komputerowych i ocenie ich wydajności i towarzyszy rozwojowi systemów telekomunikacyjnych od czasów A.K. Erlanga i T.O. Engseta [14, 15, 13]. Na początku modelowano pracę central telefonicznych i telegraficznych, dzisiaj modele kolejkowe przedstawiają zazwyczaj w uproszczony sposób zachowanie sieci ruterów jako sieci kolejek, pomagając oszacować całkowity czas transmisji i jej jakość, zlokalizować wąskie gardła systemu. W tej interpretacji klientami są kolejki w ruterach pakiety, a czas obsługi to czas ich wysłania do następnego węzła sieci, proporcjonalny do rozmiaru pakietu. Modele umożliwiają dobór zasobów sprzętowych lub ich modernizację, tak by dostosować się do przewidywanego obciążenia sieci, spełnić oczekiwania użytkowników co do jakości usług i zmieścić



Rysunek 1: Model architektoniczny składający się z sieci dostępowych, internetowych sieci rdzeniowych oraz centrum danych w chmurze.

się w posiadanym budżecie. Modele są również wykorzystywane do badania wpływu parametrów sieci lub urządzeń sieciowych na metryki jakości usług sieci. Mogą też odzwierciedlać cechy protokołów transmisji, zasady unikania zatorów oraz zasady szeregowania pakietów w ruterach. Są wciąż rozwijane i dostosowywane do oceny wydajności nowych architektur i protokołów sieciowych, np. Software Defined Networks, Internet of Things, Cloud computing.

Większość modeli ogranicza się do analizy stanów ustalonych. Oznacza to, że wartości natężenia przepływu pakietów rozpatrywane w modelach są stałe, a uzyskane rozwiązania nie zależą od czasu. Pozostaje to w rażącej sprzeczności z przepływami obserwowanymi w sieciach rzeczywistych, gdzie nieustanne zmiany natężenia ruchu wynikają z charakteru użytkowników, przesyłających zmienne ilości danych, np. w ruchu multimedialnym, a także z działania algorytmów sterujących ruchem, które starają się unikać zatorów w sieciach, np. algorytmu okna zatłoczenia stosowanego w protokole TCP, który dostosowuje intensywność przesyłanego ruchu do obserwowanych strat lub opóźnień transmisji. Jednak analiza stanów nieustalonych jest znacznie trudniejsza i bardziej złożona.

Niniejsza praca dotyczy przypadków, w których rozpatrywanie stanów nieustalonych jest nieuniknione. Przy napełnianiu bufora agregacji pakietów i rozładowywaniu baterii wynika to z samej natury rozpatrywanego procesu, który jest funkcją czasu, w przypadku modelowania sieci SDN zmiany routingu wprowadzane przez kontroler i powodujące zmiany natężenia ruchu są na tyle częste, że w sieci panuje permanentny stan nieustalony. Potwierdzają to zawarte w pracy obliczenia numeryczne wykonane dla realistycznych parametrów sieci.

Modele kolejkowe użyteczne w analizie stanów nieustalonych, dostarczające wyników ilościowych, które są niezbędne w inżynierskim podejściu do modelowania, opierają się na łańcuchach Markowa, aproksymacji płynnej (fluid-flow approximation) lub aproksymacji dyfuzyjnej, por. [9, 7]. Alternatywą dla modeli analitycznych są modele oparte na symulacji zdarzeń dyskretnych, jednak w przypadku modelowania stanów nieustalonych są one bardzo czasochłonne: trzeba symulację powtórzyć wielokrotnie (rzędu setek tysięcy lub milionów razy,

by dla ustalonych momentów czasu uzyskać rozkład kolejki z dostateczną dokładnością).

Wykorzystanie łańcuchów Markowa z ciągłym czasem jest podejściem klasycznym, stosowanym od ponad stu lat. Rozpatruje się łańcuch Markowa, którego stany odpowiadają stanom badanego systemu, a rozwiązując układ równań wiążących prawdopodobieństwa stanu łańcucha (równania Chapmana-Kołmogorowa, w przypadku stanu nieustalonego są to równania różniczkowe liniowe pierwszego rzędu) uzyskuje się prawdopodobieństwa stanów modelowanego systemu. Dla stanu nieustalonego tylko w najprostszych przypadkach, typu stanowisk $M/M/1$, $M/M/1/N$, rozwiązanie ma postać jawną, np. [4], w innych trzeba go określić na drodze numerycznej. Jest to ograniczeniem tego podejścia, mimo rozwoju metod numerycznych, np. [36], ogromnego wzrostu mocy obliczeniowych i licznych pakietów dla tworzenia i rozwiązywania tego typu równań, np. [34], liczba stanów rośnie bardzo szybko wraz ze złożonością modelu, co uniemożliwia praktyczne zastosowanie tej metody w przypadku większych sieci. Innym ograniczeniem jest fakt, że czas pobytu w stanie łańcucha Markowa ma rozkład wykładniczy, co odpowiada wykładniczym rozkładom czasu między nadejściami klientów i czasu obsługi, To ograniczenie można jednak przewyciężyć (kosztem zwiększenia liczby stanów modelu) dobierając rozkłady będące liniową kombinacją faz o rozkładzie wykładniczym, którą można dopasować do dowolnego rozkładu, por. np. [38, 2].

Modele Markowa uwzględniają pojedyncze zdarzenia typu „nadejście pakietu”, „wysłanie pakietu”, co decyduje o ich złożoności. Bardziej efektywne są metody przybliżone, wykorzystujące natężenia strumieni wchodzących i wychodzących ze stanowiska oraz ich zmiany. Aproksymacja płynna bilansuje wartości średnie tych strumieni, wyznaczając zmiany średniej liczby klientów w stanowisku. Ze względu na swoją prostotę, metoda, w wersji opracowanej m.in. w [35] uwzględniającej regulację natężenia ruchu za pomocą okna zatłoczenia w protokołach TCP/IP, zdobyła popularność, powstała jej implementacja umożliwiająca modelowanie bardzo dużych sieci (100 tys węzłów, 50 tys, przepływów) [8].

W przypadku aproksymacji dyfuzyjnej, wprowadzonej do modelowania sieci komputerowych przez E. Gelenbe, [19, 28], bilans klientów w stanowisku uwzględnia, oprócz wartości średnich, także wariancję liczby klientów nadchodzących i wychodzących ze stanowiska, a wynikiem jest rozkład prawdopodobieństwa liczby klientów w stanowisku w funkcji czasu. Model jest więc bardziej szczegółowy niż w przypadku aproksymacji płynnej. Podejście to wykorzystuje analogię pomiędzy procesem $N(t)$ - liczbą klientów w systemie obsługi - a procesem dyfuzji $X(t)$. Oba procesy mają przyrosty (choć w innej skali czasu) o rozkładzie normalnym.

Niech $A(x)$, $B(x)$ oznaczają w systemie obsługi odpowiednio rozkład pomiędzy nadejściami klientów do systemu i rozkład czasu obsługi, a pierwsze dwa momenty tych rozkładów są oznaczone jako $E[A] = 1/\lambda$, $E[B] = 1/\mu$, $\text{Var}[A] = \sigma_A^2$, $\text{Var}[B] = \sigma_B^2$. Oznaczmy też kwadratowe współczynniki zmienności tych rozkładów jako $C_A^2 = \sigma_A^2 \lambda^2$, $C_B^2 = \sigma_B^2 \mu^2$. Jak można pokazać, por. [19, 5], liczba klientów nadeszłych do systemu w czasie Δ dąży do rozkładu normalnego o średniej $\lambda\Delta$ i wariancji $\sigma_A^2 \lambda^3 \Delta = C_A^2 \lambda \Delta$, a liczba klientów, którzy opuścili system w tym czasie (przy założeniu, że pracuje on bez przerwy) dąży do rozkładu normalnego o średniej $\mu\Delta$ i wariancji $\sigma_B^2 \mu^3 \Delta = C_B^2 \mu \Delta$. Zmiany liczby klientów w stanowisku, które są różnicą liczby klientów, którzy przyszli do systemu i którzy wyszli z systemu w rozpatrywanym okresie czasu, mają więc rozkład w przybliżeniu normalny o średniej $(\lambda - \mu)\Delta$ i wariancji $(C_A^2 \lambda + C_B^2 \mu)\Delta$.

Funkcja gęstości $f(x, t; x_0)$ procesu dyfuzji $X(t)$

$$f(x, t; x_0)dx = P[x \leq X(t) < x + dx \mid X(0) = x_0]$$

jest określona równaniem dyfuzji

$$\frac{\partial f(x, t; x_0)}{\partial t} = \frac{\alpha}{2} \frac{\partial^2 f(x, t; x_0)}{\partial x^2} - \beta \frac{\partial f(x, t; x_0)}{\partial x}. \quad (1)$$

Zmiany przyrostowe procesu $dX(t) = X(t + dt) - X(t)$ mają rozkład normalny, por. [5], ze średnią βdt i wariancją αdt , gdzie β, α są parametrami równania (1).

Oba procesy $X(t)$ i $N(t)$ mają więc zmiany o rozkładzie normalnym, a wybór $\beta = \lambda - \mu$, $\alpha = C_A^2 \lambda + C_B^2 \mu$ zapewnia, że oba momenty tych rozkładów zależą w ten sam sposób od czasu obserwacji zmian.

$X(t)$ jest procesem ciągłym, a $N(t)$ dyskretnym, zaś wielkości dt i Δ są różne. Mimo to, dobra jakość aproksymacji dyfuzyjnej, w której zastępujemy rozkład kolejki $p(n, t; n_0)$ funkcją gęstości procesu dyfuzji $f(n, t; n_0)$ została potwierdzona w bardzo wielu modelach, np. [10]. W teorii kolejek nie ma dokładnych analitycznych modeli typu $G/G/1$ i $G/G/1/N$, nawet dla stanu ustalonego, które można by wykorzystać do praktycznych obliczeń.

Parametry β, α określone powyżej odnoszą się do modelu $G/G/1$ (z nieograniczoną kolejką) - wtedy proces dyfuzji jest określony na przedziale $[0, \infty)$ oraz modelu $G/G/1/N$ - proces dyfuzji jest opisany na przedziale $[0, N]$. Metoda doczekała się różnych zastosowań, niektóre z nich omówiono w [10]. Fakt, że aproksymacja dyfuzyjna uwzględnia dowolne rozkłady $A(x), B(x)$, reprezentowane przez ich dwa pierwsze momenty, łatwe do zebrania w pomiarach ruchu sieciowego, ułatwia wykorzystanie w jej modelach rzeczywistych danych pomiarowych. Błędy wprowadzone przez tę przybliżoną metodę są znacznie mniejsze niż błędy popełnione w przypadku, gdy rozkłady nie-wykładnicze zastąpimy wykładniczymi o tej samej wartości średniej i zastosujemy model Markowa, [11].

Więcej szczegółów na temat metody podano poniżej, przy omawianiu poszczególnych modeli — każdy model wymaga dostosowania metody przez dobór odpowiednich parametrów i warunków brzegowych.

2 Teza

Praca stawia tezę, że aproksymacja dyfuzyjna jest metodą modelowania, która pokonuje ograniczenia innych technik teorii kolejek (jak łańcuchy Markowa i aproksymacja płynna) w przypadku analizy stanów nieustalonych, koniecznej w rozpatrywanych w pracy przypadkach, z których każdy odnosi się do problemów występujących we współczesnych sieciach telekomunikacyjnych. W szczególności pozwala ona na obliczanie zależnej od czasu jakości transmisji (QoS) w sieciach z dynamicznymi protokołami routingu (np. sieci rdzeniowe Software Defined Networking (SDN)), opóźnień wprowadzanych przez agregację pakietów na granicy dwu typów sieci, i analizę procesu wyczerpywania się energii w systemach magazynowania energii w infrastrukturze sieci komputerowych. Stwierdzenie to jest potwierdzone przez odpowiednie modele i analizę ich wyników. Gdy jest to możliwe, wyniki są porównane z rezultatami metod alternatywnych.

3 Przegląd treści pracy

Kolejne rozdziały rozprawy przedstawiają opracowane modele. **W niniejszym streszczeniu skupiono się na opisie zastosowania aproksymacji dyfuzyjnej w modelach, uzasadniając tezę pracy. W samej dysertacji opisano szerzej także mechanizmy działania sieci opisywane przez modele.**

Modelowanie mechanizmów agregacji pakietów, rozdział 2


Rezultaty przedstawione w tym rozdziale były opublikowane poprzednio w [A1,A5,A18,A19].

Architekturę sieci komputerowej/telekomunikacyjnej można w uproszczeniu przedstawić jak na rysunku 1; rozważane w pracy modele odnoszą się do niektórych elementów tej sieci. Składa się ona z sieci dostępowej, rdzeniowej i centrum danych. Użytkownicy uzyskują dostęp do usług operatorów telekomunikacyjnych lub dostawców usług internetowych poprzez sieci dostępne, takie jak cyfrowe linie abonenckie (DSL), sieci lokalne Ethernet (LAN), sieci Fiber-to-the-Home (FTTX), bezprzewodowe sieci LAN, sieci mobilne (np. 3G, 4G i 5G) oraz sieci dostępne Internetu rzeczy (IoT). Ruch generowany przez użytkowników podłączonych do danej sieci dostępowej jest transportowany przez sieci rdzeniowe do użytkowników podłączonych do innych sieci dostępowych lub centrów danych (dla użytkowników, którzy chcą uzyskać dostęp do usług w chmurze). Rozmiary pakietów generowanych przez różne sieci dostępne są bardzo zróżnicowane, od bardzo małych pakietów generowanych przez sieci dostępne IoT (o wielkości kilku bajtów) do pakietów IP (o wielkości ponad tysiąca bajtów). Ogromne liczby pakietów generowanych przez sieci dostępne są zwykle agregowane w większe pakiety w celu zwiększenia wydajności przepustowości i zmniejszenia kosztów przetwarzania.

Agregacja pakietów zapewnia korzyści na poziomie sieci rdzeniowych, takie jak zwiększona wydajność, efektywność energetyczna, lepsze wykorzystanie zasobów [1], uproszczone zarządzanie ruchem oraz znaczne zmniejszenie narzutu protokołu i sygnalizacji. Wpływa to znacząco na ogólną wydajność sieci w zakresie opóźnień pakietów i strat pakietów. Dlatego mechanizmy agregacji pakietów i zarządzania kolejką transmisyjną muszą być starannie zaprojektowane i sparametryzowane.

Natężenie ruchu transportowanego przez sieci komputerowe ma złożony charakter stochastyczny. Ponieważ czasy nadejścia pakietów do buforów w urządzeniach sieciowych oraz czas potrzebny na przetworzenie lub przesłanie pakietów są losowe, pakiety są kolejkowane w buforach. Czas, jaki pakiety spędzają czekając w buforach oraz czas wymagany do ich przetworzenia i wysłania opóźniają pakiety w drodze od źródła do miejsca przeznaczenia i pogarsza jakość usług (QoS) doświadczaną przez użytkowników sieci. Gdy opóźnienie pakietów zmienia się, wprowadza to *jitter*, który degraduje QoS doświadczaną przez użytkowników odbierających ruch multimedialny. Kolejowanie powoduje również straty pakietów z powodu odrzucania pakietów, gdy bufor węzłów pośredniczących są pełne lub gdy pakiety są odrzucane przez aktywny mechanizm zarządzania kolejką, aby zapobiec przepełnieniu buforów.

W procesie agregacji pakietów, małe pakiety są gromadzone w buforze (załóżmy, że jego rozmiar wynosi N bajtów). Następnie zawartość bufora tworzy jeden duży pakiet i jest wysyłana dalej. Może to następować po (i) określonym czasie T - wtedy duże pakiety są wysyłane regularnie, ale ich rozmiar jest zmienny (ii) po całkowitym wypełnieniu bufora - wtedy rozmiar



Rysunek 2: Rozkład rozmiaru zagregowanego pakietu w bajtach w przypadku, gdy czas napełniania bufora jest stały, porównanie dyfuzji i symulacji

pakietu jest w przybliżeniu stały i bliski N , lecz pakiety są wysyłane w różnych odstępach czasu, albo (iii) - biorąc pod uwagę oba kryteria.

Proces dyfuzji $X(t)$ rozpoczęty w $t = 0$ w $x = 0$ z barierą pochłaniającą w N modeluje bieżącą zawartość bufora w bajtach. Jeżeli $1/\lambda$, σ_A^2 to średnia i wariancja rozkładu odstępów czasu pomiędzy agregowanymi pakietami, a m i σ_m^2 są średnią i wariancją rozmiaru tych pakietów, to parametry procesu dyfuzji mają postać

$$\beta = \lambda m, \quad \alpha = \lambda^3 \sigma_A^2 \sigma_m^2 + \lambda^3 \sigma_A^2 m^2 + \sigma_m^2 \lambda^2.$$

Jego funkcja gęstości, por. np. [5] ma postać


$$\phi(x, t) = \frac{1}{\sqrt{2\pi\alpha t}} \left\{ \exp\left[-\frac{(x - \beta t)^2}{2\alpha t}\right] - \exp\left[\frac{2\beta N}{\alpha} - \frac{(x - 2N - \beta t)^2}{2\alpha t}\right] \right\}.$$

W przypadku (i), w którym wypełnienie całego bufora jest mało prawdopodobne, rozmiar wysyłanego pakietu bufora określa funkcja $\phi(x, t = T)$. Rysunek 2 ilustruje ten rozkład dla przykładowych wartości parametrów. Jednocześnie rozwiązanie dyfuzyjne jest porównane z wynikami symulacji zdarzeń dyskretnych.


W przypadku (ii), gdy o zakończeniu procesu agregacji decyduje wypełnienie całego bufora o rozmiarze N , czas wypełnienia bufora to czas pierwszego przejścia procesu dyfuzji z $x = 0$ do $x = N$; jego funkcję gęstości $\gamma_{0,N}(t)$ obliczamy jako

$$\gamma_{0,N}(t) = \lim_{x \rightarrow N} \left[\frac{\alpha}{2} \frac{\partial f(x, t; x_0)}{\partial x} - \beta f(x, t; x_0) \right] = \frac{N}{\sqrt{2\pi\alpha t^3}} \exp\left[-\frac{(N - \beta t)^2}{2\alpha t}\right]. \quad (2)$$


Widoczny zarówno w wynikach modelu symulacyjnego, jak i dyfuzyjnego pik blisko początku rozkładu na rys. 3 wynika z prawdopodobieństwa wystąpienia bardzo długich pakietów, o długości



Rysunek 3: Funkcja gęstości rozkładu czasu skompletowania bufora agregacji, przypadek (ii)



Rysunek 4: Funkcja gęstości rozkładu czasu, po którym kompletowanie bufora agregacji jest przerwane, przypadek kryterium hybrydowego (iii)



Rysunek 5: Schemat agregacji pakietów w sieci N-GREEN.

porównywalnej z rozmiarem bufora. W modelu analitycznym pole pod pikiem jest zdefiniowane przez prawdopodobieństwo $\int_0^{t_{min}} \gamma_{0,N}(t)dt$, że czas zapelnienia bufora jest mniejszy od $t_{min} = \frac{N-M_{max}}{\beta}$, gdzie M_{max} jest maksymalnym rozmiarem nadchodzących pakietów.

W przypadku algorytmu hybrydowego, pik na końcu rozkładu wynika z upływu maksymalnego czasu T przed całkowitym wypełnieniem bufora, co ma miejsce z prawdopodobieństwem

$$\int_T^\infty \gamma_{0,N}(t)dt = N \left\{ 2 - \operatorname{erfc} \left(\frac{N - T\beta}{\sqrt{2T\alpha}} \right) + e^{\frac{2N\beta}{\alpha}} \operatorname{erfc} \left(\frac{N - T\beta}{\sqrt{2T\alpha}} \right) \right\} \quad (3)$$

gdzie

$$\operatorname{erfc}(t) = 1 - \operatorname{erf}(t), \quad \operatorname{erf}(t) = \frac{2}{\sqrt{\pi}} \int_0^t e^{-\xi^2} d\xi.$$

Reguły opróżniania bufora mogą być bardziej złożone. Inny opracowany w rozprawie model dotyczy wypełniania bufora **agregacji pakietów na styku sieci dostępowych IP i pierścieniowej optycznej sieci metropolitalnej** opracowywanej w ramach projektu Next Generation of Routers for Energy Efficiency Networks (N-GREEN), w szczególności dla usług VoIP. System agregacji działa slotowo zgodnie ze schematem opisanym w [32, 31].

W węzłach pierścienia dochodzą do przewymiarowanych buforów (prawdopodobieństwo wypełnienia bufora jest pomijalne) elektroniczne pakiety zwane tu SDU (service data units). Po upływie szczeliny czasowej (slotu) Δ , pakiety zgromadzone w buforze są agregowane w większy pakiet optyczny PDU (Packet Data Unit) i gotowe do transmisji wzdłuż pierścienia optycznego, rys 5 – jeżeli tylko sieć jest dostępna, to znaczy jeśli przepływający przez węzeł kontener optyczny o pojemności L bajtów, obiegający pierścień nie został wcześniej wypełniony przez inny węzeł pierścienia. Załóżmy, że kontener jest dostępny z prawdopodobieństwem p .

Przybliżamy liczbę bajtów w buforze w czasie jednej szczeliny czasowej za pomocą procesu dyfuzji z barierą odbijającą w $x = 0$ (liczba zgromadzonych bajtów jest nieujemna); funkcja gęstości takiego procesu to [5]

$$f(x, t; x_0) = \frac{1}{\sqrt{2\pi\alpha t}} [a(t) - \exp(2\beta x/\alpha)b(t)], \quad (4)$$

gdzie

$$a(t) = \exp \left[-\frac{(x - x_0 - \beta t)^2}{2\alpha t} \right], \quad b(t) = \exp \left[-\frac{(-x - x_0 - \beta t)^2}{2\alpha t} \right].$$

Jeśli liczba bajtów x obecnych w buforze jest mniejsza lub równa L bajtów (czyli $x \leq L$), to cała zawartość bufora jest agregowana w PDU i wstawiana do kontenera. Proces dyfuzji, który

opisuje zawartość bufora wykonuje skok do zera. Jeśli liczba bajtów w buforze jest większa niż L bajtów ($x > L$), to SDU są agregowane w PDU o rozmiarze L i wstawiane do kontenera, a liczba bajtów w buforze zmniejsza się o L bajtów, co odpowiada skokowi wstecz do pozycji $x = x - L$. Jeżeli kontener jest zajęty, zawartość bufora nie zmienia się i nie ma skoku procesu. W modelu rozpatrujemy proces dyfuzji w każdej szczelinie czasowej Δ osobno, uwzględniając w warunku początkowym to, co zdarzyło się na końcu poprzedniej szczeliny.

Oznaczamy przez $f^{(i)}(x, \Delta; \psi(i))$ funkcję gęstości procesu w i -tym przedziale Δ . Na początku każdego przedziału czas jest ustawiony na zero, stąd zawsze $t \in [0, \Delta]$. Przyjmijmy, że w pierwszym przedziale wartością początkową procesu jest $x_0 = 0$, czyli bufor jest pusty. Na końcu tego przedziału położenie procesu, przed ewentualnym skokiem, jest dane przez $f^{(1)}(x, \Delta; 0)$. Skok następuje z prawdopodobieństwem p dając początkowy rozkład na następnym interwale

$$\psi^{(2)}(0) = \int_m^L f^{(1)}(x, \Delta; m) dx \quad (5)$$

oraz dla $\xi > 0$

$$\psi^{(2)}(\xi) = f^{(1)}(\xi + L, \Delta; 0), \quad (6)$$

lub z prawdopodobieństwem $1 - p$ nie ma skoku i nowy stan początkowy jest dany przez wartość procesu na końcu poprzedniego przedziału czasowego

$$\psi^{(2)}(\xi) = f^{(1)}(\xi, \Delta; 0), \quad (7)$$

a więc pełny warunek początkowy dla procesu w drugiej szczelinie czasowej to

$$\begin{aligned} \psi^{(2)}(0) &= p \int_m^L f^{(1)}(x, \Delta; m) dx, \\ \psi^{(2)}(\xi) &= p f^{(1)}(\xi + L, \Delta; 0) \\ &+ (1 - p) f^{(1)}(\xi, \Delta; 0), \quad \xi > 0, \end{aligned} \quad (8)$$

ogólnie

$$\begin{aligned} \psi^{(n+1)}(0) &= p \int_0^L f^{(n)}(x, \Delta; \psi^{(n)}) dx, \\ \psi^{(n+1)}(\xi) &= p f^{(n)}(\xi + L, \Delta; \psi^{(n)}) \\ &+ (1 - p) f^{(n)}(\xi, \Delta; \psi^{(n)}), \quad \xi > 0, \end{aligned} \quad (9)$$


aż do osiągnięcia zbieżności, gdy $\psi^{(n+1)}(\xi) \approx \psi^{(n)}(\xi)$ oraz $f^{(n+1)}(x, t; \psi^{(n+1)}) \approx f^{(n)}(x, t; \psi^{(n)})$. Proces osiągania zbieżności jest zilustrowany na rys. 6 dla przykładowych wartości parametrów, widać, że wystarczy ok. 25 iteracji.

Z algorytmu napelniania PDU wynika, że średnie rzeczywiste wypełnienie PDU jest mniejsze niż L , co obniża efektywną przepustowość sieci. Obliczamy średni efektywny rozmiar pakietu

$$L_{eff} = L \int_L^\infty f(x, \Delta; \psi) dx + \int_0^L f(x, \Delta; \psi) x dx. \quad (10)$$

oraz współczynnik agregacji

$$\epsilon = \frac{L_{eff}}{m} \quad (11)$$



Rysunek 6: Rozkład zawartości bufora w kolejnych szczelinach czasowych, $f^{(i)}(x, t; \psi^{(i)})$ dla $p = 0.25$ w kolejnych szczelinach czasowych, zgodnie z równaniem (10), $i = 1 \dots 25$

gdzie m jest średnią wielkością SDU. W dysertacji jest również rozważany wariant algorytmu, w którym pusty kontener jest napełniany tylko wtedy, gdy zawartość bufora przekroczy lub jest równa L bajtów.

Dla określenia **czasu czekania** w buforze, zauważmy, że przybywający w czasie $t \in (0, \Delta)$ SDU widzi rozkład kolejki $f(x, t; \psi)$. Z prawdopodobieństwem

$$p_1 = \int_0^L f(x, t, \psi) dx$$

liczba bajtów w buforze przed nim jest mniejsza niż L i pakiet zostanie załadowany do pierwszego pustego kontenera. Jego czas oczekiwania wyniesie $\Delta - t$ z prawdopodobieństwem p lub $\Delta - t + \Delta$ z prawdopodobieństwem $(1-p)p$, lub $\Delta - t + 2\Delta$ z prawdopodobieństwem $(1-p)^2p, \dots, \Delta - t + n\Delta$ z prawdopodobieństwem $(1-p)^{n-1}p$, w zależności od tego, kiedy pojawi się pierwszy pusty kontener. co daje funkcję gęstości prawdopodobieństwa

$$\begin{aligned} f_{W_1}(w, t) &= p\delta(w - (\Delta - t)) + (1-p)p\delta(w - (2\Delta - t)) \\ &\quad + (1-p)^2p\delta(w - (3\Delta - t)) + \dots \\ &\quad + (1-p)^n p\delta(w - ((n+1)\Delta - t)) + \dots \end{aligned} \tag{12}$$

gdzie $\delta(x)$ jest funkcją delta Diraca. Moment nadejścia SDU może się zdarzyć w każdym momencie slotu czasowego z tym samym natężeniem $1/\Delta$, więc

$$f_{W_1}(w) = \int_0^\Delta \frac{1}{\Delta} f_{W_1}(w, t) dt. \tag{13}$$

Podobnie, jeżeli rozmiar kolejki jest pomiędzy L i $2L$, co ma miejsce z prawdopodobieństwem

$$p_2 = \int_L^{2L} f(x, t; \psi) dx$$

rozważany pakiet zostanie załadowany do drugiego z kolei pustego kontenera. Rozkład dodatkowego opóźnienia to

$$\begin{aligned} f_\Delta(w) &= p\delta(w - \Delta) + (1-p)p\delta(w - 2\Delta) + \\ &\quad + (1-p)^2p\delta(w - 3\Delta) + \dots \\ &\quad + (1-p)^n p\delta(w - (n+1)\Delta) + \dots \end{aligned} \tag{14}$$

Dlatego rozkład czasu czekania w przypadku kolejki o rozmiarze pomiędzy L i $2L$ jest określony splotem


$$f_{W_2}(w) = f_{W_1}(w) * f_\Delta(w),$$

podobnie dla kolejki o rozmiarze pomiędzy $2L$ i $3L$ mamy

$$f_{W_3}(w) = f_{W_1}(w) * f_\Delta(w) * f_\Delta(w)$$

a w przypadku, gdy nadchodzący pakiet SDU widzi kolejkę o rozmiarze pomiędzy $(n-1)L$ i nL

$$f_{W_n}(w) = f_{W_1}(w) * f_\Delta(w)^{(n-1)} \tag{15}$$



Rysunek 7: $f_{W_n}(w)$ zdefiniowana w (15) – ilustracja wpływu liczby pustych optycznych kontenerów n potrzebnych do wysłania zawartości bufora na rozkład czasu czekania, $p = 0.25$

co ma miejsce z prawdopodobieństwem

$$p_n = \int_{(n-1)L}^{nL} f(x, t; \psi) dx \quad (16)$$

Rys. 7 przedstawia przykładowe wyniki numeryczne ilustrujące powyższy model.

Model przełącznika sieci SDN, rozdział 3

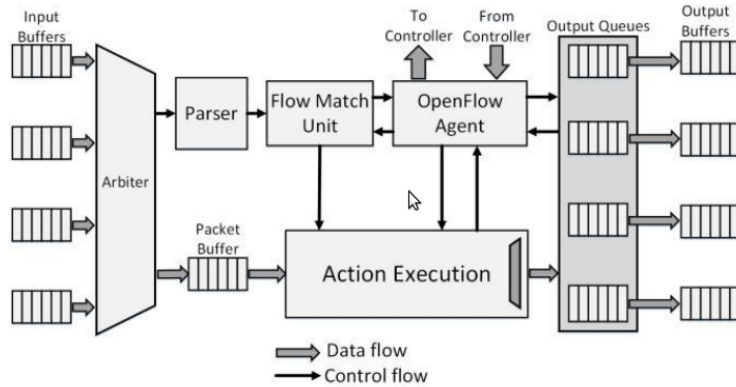
Razultaty tego rozdziału były poprzednio opublikowane w [A6].

W niedawno wprowadzonym paradygmacie SDN (Software Defined Networking) decyzja o routingu jest przeniesiona z rutera do scentralizowanego serwera zwanego kontrolerem, a ruter jest zredukowany do przełącznika, którego funkcją jest przekazywanie pakietów w oparciu o reguły podane przez kontroler.

Urządzenia płaszczyzny danych stale zbierają dane o bezpieczeństwie sieci, zużyciu energii i parametrach QoS i wysyłają je do kontrolera, który wykorzystuje te informacje do obliczenia tras zgodnie z założonymi kryteriami optymalizacji, a następnie aktualizuje reguły przekazywania pakietów w ruterach. Jeśli dzieje się to często, sieć jest stale w stanie przejściowym.

Rysunek 3 przedstawia architekturę przełącznika SDN zaproponowaną w [40]. Nadchodzące pakiety są tymczasowo kolejgowane w buforach wejściowych, a następnie umieszczane w buforze pakietów w oczekiwaniu na ich identyfikację. Jednocześnie Parser wyodrębnia pole nagłówka i przekazuje do jednostki Flow Match, tablicy przepływów zawierającej identyfikatory wszystkich przepływów przechodzących przez przełącznik i reguły ich routingu. Wpisy przepływów w tablicy przepływów są aktualizowane przez kontroler.

Wiersze tablicy odpowiadają poszczególnym przepływowi. Tablica jest przeszukiwana wiersz po wierszu, dopóki nie zostanie odnaleziony przepływ, do którego należy dany pakiet. Gdy



Rysunek 8: Architektura przełącznika SDN [40].

przeływ zostanie odnaleziony, pakiet może być wysłany dalej. W przypadku niepowodzenia (żaden wpis tabeli przepływów nie pasuje do nagłówka pakietu), pakiet jest przesłany do kontrolera dla identyfikacji i uzupełnienia tablicy przepływów. Jeśli nie ma odpowiedzi ze strony kontrolera, pakiet zostanie odrzucony. Głównym czasem przetwarzania pakietu jest czas przeszukiwania tabeli, a czas zwłoki to czas oczekiwania w kolejce bufora pakietów. Czas komunikacji z kontrolerem został w modelu pominięty.

Zaproponowany tutaj model przełącznika to model pojedynczego stanowiska obsługi. Rozważamy scenariusz, w którym tablice przepływów są przeszukiwane sekwencyjnie. Niech p jest prawdopodobieństwem, że reguła przepływu przychodzącego pakietu nie jest zainstalowana. Przełącznik wie to po zbadaniu wszystkich K wpisów przechowywanych w Flow Match Unit - tzn. w czasie KT , jeśli zbadanie każdego wpisu wymaga stałego czasu T . Czas obsługi jest więc stały z prawdopodobieństwem p , a z prawdopodobieństwem $(1 - p)$ przepływ, do którego należy pakiet zostaje znalezione w czasie, którego rozkład jest dyskretny i równomierny w przedziale $[T, KT]$, ze średnią $(K + 1)T/2$ i wariancją $(K^2 - 1)T^2/12$, co umożliwi nam wyznaczenie średniej i wariancji czasu obsługi w zastępczym stanowisku reprezentującym przełącznik bszępczym stanowisku reprezentującym przełącznik.

Bufor pakietów ma ograniczoną pojemność N pakietów, wykorzystujemy więc model stanowiska $G/G/1/N$ [20], gdzie proces dyfuzji jest ograniczony do przedziału $[0, N]$, na którego krańcach znajdują się bariery pochłaniające ze skokami. Pobyt w barierze w $x = 0$ odpowiada stanowi, gdy kolejka jest pusta (okres bezczynności stanowiska), skok z $x = 0$ do $x = 1$ modeluje nadejście klienta do pustego systemu, rozpoczynające następny okres czynny. Podobnie pobyt w barierze w $x = N$ odpowiada okresowi, gdy system jest przepełniony i nie może przyjąć następnych klientów, a skok do $x = N - 1$ do zakończenia obsługi klienta i uwolnienie jednego miejsca w systemie. Skoki odbywają się odpowiednio z intensywnością λ nadchodzenia klientów i intensywnością μ obsługi.

Prowadzi to do układu równań

$$\begin{aligned} \frac{\partial f(x, t; x_0)}{\partial t} &= \frac{\alpha}{2} \frac{\partial^2 f(x, t; x_0)}{\partial x^2} - \beta \frac{\partial f(x, t; x_0)}{\partial x} + \lambda p_0(t) \delta(x - 1) + \mu p_N(t) \delta(x - N + 1), (17) \\ \frac{dp_0(t)}{dt} &= \lim_{x \rightarrow 0} \left[\frac{\alpha}{2} \frac{\partial f(x, t; x_0)}{\partial x} - \beta f(x, t; x_0) \right] - \lambda p_0(t) \end{aligned}$$

$$\frac{dp_N(t)}{dt} = \lim_{x \rightarrow N} \left[\frac{\alpha}{2} \frac{\partial f(x, t; x_0)}{\partial x} - \beta f(x, t; x_0) \right] - \mu p_N(t), \quad (18)$$

gdzie $f(x, t; x_0)$ jest funkcją gęstości prawdopodobieństwa procesu dyfuzji z warunkiem początkowym x_0 ; $p_0(t)$ i $p_N(t)$ to odpowiednio prawdopodobieństwo pobytu procesu w barierze w $x = 0$ lub $x = N$ w chwili t , $\delta(x)$ jest funkcją delta Diraca. Równania odnoszą się do stanu nieustalonego, ale zakładają, że parametry dyfuzji są stałe.

W [20] przeprowadzono analizę stanu ustalonego tego modelu, gdy $f(x, t; x_0) \rightarrow f(x)$. Jednakże, ze względu na charakter pracy sieci SDN (częste zmiany routingu) musimy wziąć pod uwagę, że intensywność ruchu $\lambda(t)$ jest zmienna, co powoduje że również współczynniki równania dyfuzji są zmienne w czasie. Trzeba wziąć nie tylko pod uwagę stan nieustalony kolejki, ale też zmienne parametry równania dyfuzji. W modelu posłużono się metodą rozwiązywania równania 18 zaproponowaną [6], i stosowaną w krótkich przedziałach czasu, w których parametry są stałe. Rozwiązanie na końcu danego przedziału stanowi warunek początkowy w przedziale następnym.

W pierwszym etapie rozwiązuje się równanie dyfuzji z barierami pochłaniającymi, proces kończy się po dojściu do bariery. Jego rozwiązanie, funkcja gęstości $\phi(x, t; x_0)$ ma postać [5]

$$\phi(x, t; x_0) = \begin{cases} \delta(x - x_0) & \text{for } t = 0, \\ \frac{1}{\sqrt{2\pi\alpha t}} \sum_{n=-\infty}^{\infty} \{a(t) + b(t)\} & \text{for } t > 0, \end{cases} \quad (19)$$

gdzie

$$a(t) = \exp \left[\frac{\beta x'_n}{\alpha} - \frac{(x - x_0 - x'_n - \beta t)^2}{2\alpha t} \right],$$

$$b(t) = \exp \left[\frac{\beta x''_n}{\alpha} - \frac{(x - x_0 - x''_n - \beta t)^2}{2\alpha t} \right],$$

$$x'_n = 2nN, \quad x''_n = -2x_0 - x'_n.$$

Jeżeli warunek początkowy ma postać funkcji gęstości $\psi(\xi)$, $\xi \in (0, N)$, $\lim_{\xi \rightarrow 0} \psi(\xi) = \lim_{\xi \rightarrow N} \psi(\xi) = 0$, to

$$\phi(x, t; \psi) = \int_0^N \phi(x, t; \xi) \psi(\xi) d\xi. \quad (20)$$

W drugim etapie funkcja gęstości $f(x, t; x_0)$ jest wyrażona za pomocą funkcji $\phi(x, t; \psi)$

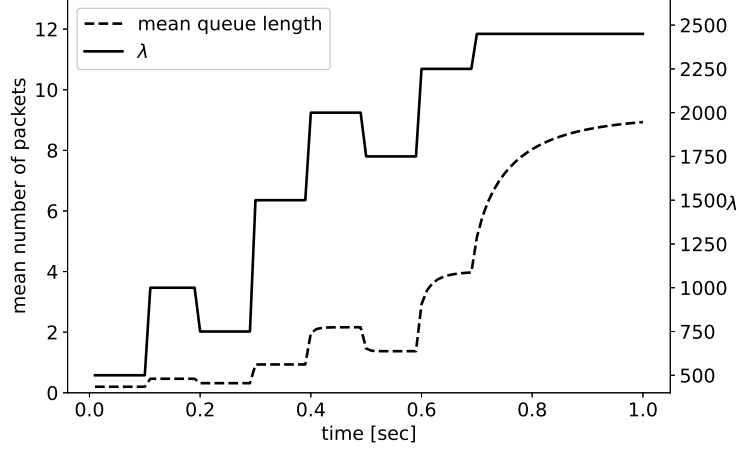
$$f(x, t; \psi) = \phi(x, t; \psi) + \int_0^t g_1(\tau) \phi(x, t - \tau; 1) d\tau$$

$$+ \int_0^t g_{N-1}(\tau) \phi(x, t - \tau; N - 1) d\tau. \quad (21)$$

intensywności $g_1(t)$ and $g_N(t)$ można wyrazić za pomocą funkcji $\gamma_0(t)$ and $\gamma_N(t)$:

$$g_1(\tau) = \int_0^\tau \gamma_0(t) l_0(\tau - t) dt$$

$$g_{N-1}(\tau) = \int_0^\tau \gamma_N(t) l_N(\tau - t) dt, \quad (22)$$



Rysunek 9: Wpływ zmian natężenia λ strumienia pakietów (linia ciągła) na średnią długość kolejki (linia przerywana) w przełączniku SDN.

gdzie $l_0(x)$, $l_N(x)$ są funkcjami gęstości czasu pobytu w barierach w $x = 0$ and $x = N$, a $\gamma_0(t)$ i $\gamma_N(t)$ są intensywnościami, z jaką w czasie t przechodzi do barier w $x = 0$ oraz $x = N$:

$$\begin{aligned}
\gamma_0(t) &= p_0(0)\delta(t) + [1 - p_0(0) - p_N(0)]\gamma_{\psi,0}(t) \\
&\quad + \int_0^t g_1(\tau)\gamma_{1,0}(t-\tau)d\tau + \int_0^t g_{N-1}(\tau)\gamma_{N-1,0}(t-\tau)d\tau, \\
\gamma_N(t) &= p_N(0)\delta(t) + [1 - p_0(0) - p_N(0)]\gamma_{\psi,N}(t) \\
&\quad + \int_0^t g_1(\tau)\gamma_{1,N}(t-\tau)d\tau + \int_0^t g_{N-1}(\tau)\gamma_{N-1,N}(t-\tau)d\tau, \tag{23}
\end{aligned}$$

gdzie $\gamma_{1,0}(t)$, $\gamma_{1,N}(t)$, $\gamma_{N-1,0}(t)$, $\gamma_{N-1,N}(t)$ są funkcjami gęstości czasu pierwszego przejścia procesu pomiędzy punktami podanymi w indeksach. np

$$\gamma_{1,0}(t) = \lim_{x \rightarrow 0} \left[\frac{\alpha}{2} \frac{\partial \phi(x, t; 1)}{\partial x} - \beta \phi(x, t; 1) \right]. \tag{24}$$

Powyższe rozwiązanie obowiązuje dla stanów ustalonych, ale stałych parametrów. W przypadku zmiany strumienia wejściowego w chwili t_1 , zmieniają się parametry dyfuzji. Końcowe rozwiązanie dla starych parametrów dla $t = t_1$ staje się warunkiem początkowym $\psi(\xi)$ w równaniach (20), (21) i obliczenia modelowe są kontynuowane dla nowych parametrów.

Rys. 3 przedstawia wyniki obliczeń modelowych – średnią długość kolejki w przełączniku SDN – dla przykładowych, ale zbliżonych do rzeczywistych wartości parametrów: natężenie ruchu λ zmienia się co 100 ms w granicach od 500 do 2500 pakietów na sekundę (każda zmiana λ pociąga za sobą zmianę parametrów α i β , średni czas przeszukiwania tablicy przepływów 0.038 ms ze średnim współczynnikiem zmienności 0.33, wielkość bufora $N = 100$ pakietów. Jak widać, przez większość rozpatrywanego okresu w kolejce panuje stan nieustalony, tym dłuższy im większe obciążenie stanowiska – co uzasadnia wybór modelu.

Model pracy sieci przełączników SDN, rozdział 4

Wyniki przedstawione w tutaj były opublikowane w [A2,A14].

Rozważmy sieć stacji M o dowolnej topologii z prawdopodobieństwami rutingu $r_{ij}(t)$, oznaczającym że w chwili t pakiet opuszczający stanowisko i skieruje się do stanowisko j . Zastosowano podejście przedstawione w [28], rozwinięte następnie dla stanów nieustalonych w [12], dodając tutaj zależny od czasu ruting, istotny w sieciach SDN.

Pierwszym krokiem jest dekompozycyjna sieci, tzn. wyznaczenie wejściowych parametrów ruchu λ_i , $C_{A_i}^2$ dla każdej stacji i , a następnie zastosowanie modelu pojedynczego serwera z poprzedniego rozdziału do każdej stacji osobno.

W stanie nieustalonym powinniśmy rozróżnić na każdej stacji i ruch wejściowy $\lambda_{i-in}(t)$ oraz natężenie ruchu wyjściowego $\lambda_{i-out}(t)$:

$$\lambda_{i-out}(t) = [1 - p_{0i}(t)]\mu_i,$$

$p_{0i}(t)$ oznacza prawdopodobieństwo, że stacja i jest beczynna w czasie t , tzn. proces dyfuzji związany z tą stacją znajduje się wewnątrz bariery w $x = 0$. Wartość $1 - p_{0i}(t) = \varrho_i(t)$ przedstawia prawdopodobieństwo, że stacja i pracuje, a klienci opuszczają ją z szybkością μ_i .

Równania ruchu bilansujące przepływy stacji to:

$$\lambda_{i-in}(t) = \lambda_{0i}(t) + \sum_{j=1}^M \lambda_{j-out}(t)r_{ji}(t), \quad i = 1, \dots, M, \quad (25)$$

gdzie λ_{0i} reprezentuje strumienie ruchu przychodzące z zewnątrz sieci bezpośrednio do stacji i .

Prawdopodobieństwa rutingu $r_{ji}(t)$ zmieniają się w każdym przedziale Δ w następstwie decyzji kontrolera, pozostając stałe wewnątrz przedziału, a parametry przepływu mogą zmieniać się w każdym przedziale $\delta < \Delta$; zakładamy $\Delta = n\delta$, w przykładach numerycznych prezentowanych poniżej $n = 10$. W ten sposób wszystkie parametry modelu są stałe w przedziałach δ wewnątrz których jest obliczane rozwiązanie (21).

Oznaczmy przez $f_{A_j}(x, t)$ i $f_{B_j}(x, t)$ funkcje gęstości czasów między nadejściem pakietów i czasów obsługi w stanowisku j w czasie t . Funkcja gęstości $f_{D_j}(x, t)$ czasów pomiędzy klientami opuszczającymi to stanowisko w czasie t można wyrazić jako:

$$f_{D_j}(x, t) = \varrho_j(t)f_{B_j}(x, t) + [1 - \varrho_j(t)]f_{A_j}(x, t) * f_{B_j}(x, t), \quad j = 1, \dots, M, \quad (26)$$

gdzie $*$ wyraża operację splotu w odniesieniu do x .

Pierwszy wyraz po prawej stronie równania odnosi się do sytuacji gdy węzeł j pracuje, a drugi gdy system jest beczynny. Wzór (26), znany jako twierdzenie Burke'a ([3]), jest dokładny dla Poissonowskiego strumienia wejściowego, gdy rozkład okres beczynności, który powinien tu występować jest tożsamy z rozkładem czasu pomiędzy nadejściami klientów, i przybliżony w innych przypadkach. Z (26) otrzymujemy:

$$C_{D_j}^2(t) = \varrho_j^2(t)C_{B_j}^2(t) + C_{A_j}^2(t)(1 - \varrho_j(t)) + \varrho_j(t)[1 - \varrho_j(t)]. \quad (27)$$

gdzie $C_{D_j}^2(t)$, $C_{B_j}^2(t)$, $C_{A_j}^2(t)$ są odpowiednio zależnymi od czasu współczynnikami zmienności rozkładu czasów między odejściami, obsługi i między nadejściami. Pakiety opuszczające

stanowisko j zgodnie z $f_{D_j}(x, t)$ wybierają stanowisko i z prawdopodobieństwem $r_{ji}(t)$, czyli czas pomiędzy kolejnymi pakietami przechodzącymi z j do i charakteryzującej $f_{ji}(x, t)$

$$f_{ji}(x, t) = f_{D_j}(x, t)r_{ji}(t) + f_{D_j}(x, t) * f_{D_j}(x, t)[1 - r_{ji}(t)]r_{ji}(t) + f_{D_j}(x, t) * f_{D_j}(x, t) * f_{D_j}(x, t)[1 - r_{ji}(t)]^2r_{ji} + \dots \quad (28)$$

o współczynniku zmienności

$$C_{ji}^2(t) = r_{ji}(t)[C_{D_j}^2(t) - 1] + 1.$$

Na tej podstawie obliczamy

$$C_{A_i}^2(t) = \frac{1}{\lambda_{i-in}(t)} \sum_{j=1}^M r_{ji}(t)\lambda_{i-out}(t)[(C_{D_j}^2(t) - 1)r_{ji}(t) + 1] + \frac{C_{0i}^2(t)\lambda_{0i}(t)}{\lambda_{i-in}(t)}, \quad (29)$$

gdzie λ_{0i} i C_{0i}^2 odnoszą się do strumienia dochodzącego do stacji i spoza sieci.

Parametry strumienia wejściowego stacji i są dane przez (25) and (29). Równania (27), (29) tworzą układ równań liniowych dających $C_{A_i}^2(t)$, a także parametry dyfuzji $\beta_i(t)$, $\alpha_i(t)$ dla każdego węzła i .

W każdym przedziale czasu δ obliczane są funkcje $f_i(x, t; \psi_i)$ określające rozkłady długości kolejek w każdej stacji i dla $t \in \delta$. Ich wartości na końcu przedziału dają m.in. aktualne wykorzystanie stacji ρ_i wykorzystywane do wyznaczenia parametrów przepływu i parametrów dyfuzji dla kolejnego interwału δ .

Funkcje $f_{R_i}(x, t)$ czasu odpowiedzi danego stanowiska i (czas oczekiwania plus obsługa) wyznaczana jest z wykorzystaniem czasu pierwszego przejścia od końca kolejki do zera. Funkcja gęstości $f_R(x, t)$ czasu odpowiedzi dla ścieżki $1, \dots, n$ dla stacji n to

$$f_R(x, t) = f_{R_1}(x, t) * f_{R_2}(x, t) * f_{R_3}(x, t) * \dots * f_{R_n}(x, t),$$

Prawdopodobieństwo $p_{loss}(t)$ utraty pakietu z powodu przepełnienia bufora w dowolnym węzle można obliczyć dla tej samej ścieżki jako:


$$1 - p_{loss}(t) = (1 - p_{N_1}(t))(1 - p_{N_2}(t))(1 - p_{N_3}(t)) \dots (1 - p_{N_n}(t)) \quad (30)$$

gdzie $p_{N_i}(t)$ jest prawdopodobieństwem, że stacja i jest przepełniona w chwili t , czyli że proces dyfuzji opisujący tę stację jest w barierze w $x = N_i$.


Poniższy **przykład numeryczny ilustruje właściwości tego rozwiązania.**

Rozważmy sieć składającą się z czterech przełączników SDN, $S1-S4$, rys. 10. Ich parametry to $\mu_1 = \mu_2 = \mu_3 = 2628.8$ pakietów/sek, $\mu_4 = 5257,6$ pakietów/sek. We wszystkich przełącznikach współczynnik kwadratowy zmienności czasu obsługi jest $C_{B_i}^2 = 0,33$.


Rozpatrujemy działanie sieci w przedziale o długości 1 sek. Host 1 nadaje pakiety do Hosta 2 ze zmienną intensywnością λ_{01} , podobnie Host 4 nadaje do Hosta 2 poprzez $S2 - S4$ pakiety z intensywnością λ_{02} . Przebieg obu intensywności w funkcji czasu jest przedstawiony na rys. 11. Łącze $S1-S4$ ma ograniczoną do 1000 pakietów na sekundę przepustowość. Jeżeli λ_{01} przekracza tę wartość, ruch jest kierowany również ścieżkami $S1 - S2 - S4$ oraz $S1 - S3 - S4$. Rozpatrujemy trzy warianty ruchu λ_{01} , różniące się wariancją rozkładu czasu między nadchodzącymi pakietami:




Rysunek 10: Przykład sieci SDN.



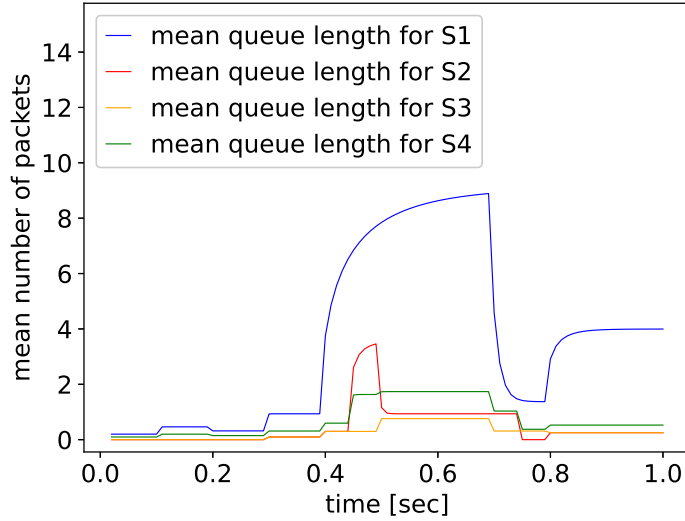
Rysunek 11: Przebieg intensywności wejściowej $\lambda_{01}(t)$, $\lambda_{02}(t)$ w czasie



Rysunek 12: Przebieg intensywności $\lambda_i(t)$ w stacjach $S1 \dots S4$.



Rysunek 13: Przebieg prawdopodobieństwa utraty pakietu w stacjach $S1, S2, S3, S4$: $p_N(t)$, w przypadku gdy $C_{A1}^2 = 1.02$.



Rysunek 14: Przebieg średniej długości kolejki w przełącznikach $S1, S2, S3, S4$; $C_{A1}^2 = 1.02$.

Współczynnik kwadratowy zmienności czasów między pakietami w strumieniu wejściowym w $S1$ wartość $C_{A1}^2 = C_{01}^2 = 1.02$ lub $C_{A1}^2 = 4.08$ lub $C_{A1}^2 = 8.16$. Ruch λ_{02} w $S2$ ma zawsze $C_{A2}^2 = C_{02}^2 = 1.02$.


Rys. 12, 13, 14 przedstawiają wybrane wyniki modelu. Pokazano rozplyw strumieni wewnątrz sieci w funkcji czasu, prawdopodobieństwo utraty pakietu w poszczególnych stanowiskach i zmiany średniej długości kolejki w stanowiskach, dobrze ilustrujące obecność stanu nieustalonego. Zwraca uwagę możliwość wyznaczenia bardzo małych wartości prawdopodobieństwa utraty pakietu, nieosiągalnych w przypadku modeli symulacyjnych.

Rozważmy **prosty przykład optymalizacji pracy sieci SDN**. Konfiguracja sieci i przebieg strumieni wejściowych $\lambda_{01}, \lambda_{02}$ pozostają jak poprzednio. Kontroler zmienia ruting co $\Delta = 100$ msec i musi wyznaczyć prawdopodobieństwa rutowania dla najbliższego Δ , znając aktualne parametry przepływów na początku interwału, a także aktualne rozkłady kolejek w $S1, S2$ i $S3$ wynikające z dotychczasowej pracy sieci.

Celem jest taki dobór rutowania w następnym przedziale Δ , aby łączna wartość średnia kolejek w $S2$ i $S3$ była minimalna, tj. minimalizacja funkcji celu Ψ :

$$\min_{r_{12}, r_{13}} \left\{ \Psi = \frac{1}{\Delta} \int_0^{\Delta} [E[N_2(t)] + E[N_3(t)]] dt \right\}.$$

Obliczamy za pomocą modelu przewidywane w następnym przedziale $E[N_2(t)], E[N_3(t)]$ for $t \in \Delta$ i minimalizujemy Ψ poprzez wybór $r_{12}, r_{13} = 1 - r_{12}$; rys. 15.




Rysunek 15: Wartość Ψ w przedziale czasu Δ jako funkcja prawdopodobieństw rutingu r_{12} , $r_{13} = 1 - r_{12}$, krzywe odpowiadają różnym wartościom λ_{02} wpływającym do S2.

Modelowanie zużycia energii w systemach magazynowania energii oraz ataków na urządzenia Internetu Rzeczy, zmierzających do pozbawienia ich energii, rozdziały 5 i 6

Rezultaty były opublikowane wcześniej w [A4,A15]. Rezultaty rozdz. 5 oddano do publikacji, [A22].

Ostatnio teoria kolejek jest adaptowana do modelowania systemów magazynowania energii dla systemów komputerowych, które są zasilane z baterii, np. [21, 22, 23, 27, 24, 26, 25, 17, 16, 30, 18, 29, 39]. Zużycie energii przez systemy komputerowe nie jest stałe. Zmienia się wraz z jego zapotrzebowaniem obliczeniowym oraz liczbą przetwarzanych lub przesyłanych pakietów. Jednym ze źródeł losowości zużycia energii przez niektóre systemy komputerowe jest fakt, że użytkownicy inicjują obliczenia, przetwarzanie lub transmisję danych w losowych momentach. Niektóre systemy komputerowe zasilane są z akumulatorów, które są stale doładowywane energią pozyskiwaną z odnawialnych źródeł energii. Ilość energii generowanej przez odnawialne źródła energii czasami ulega losowym wahaniom wraz z losowymi zmianami środowiska. Losowe fluktuacje ilości energii zbieranej i dostarczanej do akumulatora oraz ilości energii pobieranej z akumulatora do zasilania systemu komputerowego wywołują potrzebę stosowania modeli stochastycznych do analizy jej zmian w akumulatorze. Pozwala to m.in. na oszacowanie czasu, po którym energia w akumulatorze może zostać całkowicie wyczerpana.

W modelu baterii poziom energii w baterii jest opisany przez wartość procesu dyfuzji na przedziale $[0, B]$, gdzie B jest pojemnością baterii. Czas życia urządzenia IoT zasilanego z baterii jest czasem potrzebnym do całkowitego wyczerpania energii zgromadzonej w baterii. W przypadku braku ładowania baterii, czas życia to czas pierwszego przejścia procesu dyfuzji z $x = B$ (bateria jest w pełni naładowana) do $x = 0$ (energia całkowicie wyczerpana). Funkcja



Rysunek 16: Porównanie funkcji gęstości czasu życia baterii w modelu dyfuzyjnym $\gamma_{B,0}(t)$ i Markowa, dla $B = 100$ i $1/\mu = 0.2$.

gęstości tego czasu to

$$\gamma_{B,0}(t) = \lim_{x \rightarrow 0^+} \left[\frac{\alpha}{2} \frac{\partial \phi(x, t; B)}{\partial x} - \beta \phi(x, t; B) \right] = \frac{B}{\sqrt{2\pi\alpha t^3}} e^{-\frac{(B+\beta t)^2}{2\alpha t}} \quad (31)$$

gdzie

$$\phi(x, t; B) = \frac{1}{\sqrt{2\pi\alpha t}} \left\{ \exp \left[-\frac{(x - \beta t)^2}{2\alpha t} \right] - \exp \left[\frac{2\beta B}{\alpha} - \frac{(x - 2B - \beta t)^2}{2\alpha t} \right] \right\}.$$

Ponieważ nie ma dopływu energii, więc parametry dyfuzji to $\beta = -\mu$, $\alpha = \mu C_B^2$ odnoszą się do czasu zużycia jednostki energii. Przykładowe wyniki modelu przedstawia rys. 16. Są one porównane z wynikami modelu Markowa, w przypadku gdy czas zużycia jednostki energii ma rozkład wykładniczy. Oczywiście model dyfuzyjny jest ogólniejszy i dotyczy dowolnych rozkładów. Widać bardzo dobrą zgodność wyników obu modeli

Prawdopodobieństwo, że bateria jest całkowicie zużyta w chwili t to


$$\Gamma_{B,0}(t) = \int_0^t \gamma_{B,0}(\xi) d\xi = \frac{1}{2} \left(e^{-\frac{2\beta B}{\alpha}} \operatorname{erfc} \left[\frac{B - \beta t}{\sqrt{2\alpha t}} \right] + \operatorname{erfc} \left[\frac{B + \beta t}{\sqrt{2\alpha t}} \right] \right) \quad (32)$$

gdzie

$$\operatorname{erfc}(t) = 1 - \operatorname{erf}(t), \quad \text{and} \quad \operatorname{erf}(t) = \frac{2}{\sqrt{\pi}} \int_0^t e^{-\xi^2} d\xi.$$

Jeżeli $\beta > 0$, to prawdopodobieństwo, że bateria nigdy się nie rozładuje wynosi

$$1 - \int_0^\infty \gamma_{B,0}(t) dt = 1 - e^{-2\beta B/\alpha}.$$



Rysunek 17: Prawdopodobieństwo, że bateria nigdy nie zostanie wyczerpana w przypadku gdy intensywność poboru energii λ jest większa niż intensywność jej zużycia μ , przedstawione jako funkcja $\varrho = \lambda/\mu > 1$ dla różnych C_A^2 , ($C_B^2 = 1$)

Rys. 17 ilustruje powyższą zależność i pokazuje, jak stosunek $\varrho = \lambda/\mu$ oraz C_A^2 wpływają na prawdopodobieństwo, że bateria nigdy nie zostanie wyczerpana.

Jeżeli warunek początkowy czasu pierwszego przejścia jest dany w postaci funkcji gęstości ψ , to

$$\gamma_{\psi,0}(t) = \int_0^B \frac{\xi}{\sqrt{2\Pi\alpha t^3}} e^{-\frac{(\xi-\beta t)^2}{2\alpha t}} \psi(\xi) d\xi. \quad (33)$$

Przyjmijmy, że proces rozpoczyna się w $t = 0$ w punkcie $x_0 = B$ z parametrami dyfuzji α and β , a w chwili t_1 zmienia się zużycie energii i parametry dyfuzji przybierają nowe wartości α_1 i β_1 . Funkcja gęstości ϕ procesu w chwili t_1 jest dana przez (32) i po normalizacji – z prawdopodobieństwem $p(t_1) = \int_0^{t_1} \gamma_{B,0}(t) dt$ proces już doszedł wcześniej do bariery — staje się warunkiem początkowym dla dalszej ewolucji procesu: $\psi(\xi) = \phi(\xi, t_1; B)/(1 - p(t_1))$.


a trwa z prawdopodobieństwem $1 - p(t_1)$ i funkcja gęstości rozkładu jego trwania to

$$\gamma(t) = \begin{cases} \gamma_{B,0}(t) & \text{dla } t \leq t_1 \\ \gamma_{\psi,0}(t - t_1) & \text{dla } t > t_1. \end{cases} \quad (34)$$

Jeżeli bateria jest zasilana, to dopływ energii jest przedstawiony jako nadchodzące do baterii kwanty energii (klienci), ich strumień ma natężenie λ , a wariancja odstępów czasu pomiędzy ich nadejściem ot σ_A^2 .

Model przybiera postać stanowiska $G/G/1/B$, w którym klienci to obecne w baterii jednostki energii. Jest to ten sam model, który był stosowany do opisu pracy przełącznika SDN i pozwala wyznaczyć dla dowolnego momentu czasu rozkład energii w baterii $f(x;t;B)$ oraz prawdopodobieństwo, że bateria jest pusta $p_0(t)$ i że jest pełna $p_B(t)$.

Możemy też wyznaczyć dla dowolnego momentu czasu i dowolnego poziomu energii w baterii okres czasu, po którym bateria się opróżni lub zapełni. Wymaga to jednak określenia wpływu



Rysunek 18: Wpływ $\rho = \lambda/\mu$ na funkcję gęstości okresu czynnego $h_{i,0}(t)$ dla $i = 10$.

barier na te procesy. Jeżeli proces jest w położeniu $x_0 = i$, to zanim dojdzie do $x = 0$ może odwiedzić dowolną liczbę razy barierę w $x = B$, dlatego czas pierwszego przejścia z $x = i$ do $x = 0$ jest kombinacją czasów pierwszego przejścia z $x = i$ do $x = 0$, z $x = i$ do $x = B$ z $x = B$ do $x = 0$. Dla określenia prawdopodobieństwa tych sekwencji wyznaczmy najpierw prawdopodobieństwo $H(x_0, x_n)$, że proces dyfuzji rozpoczęty w x_0 i pochłonięty na końcu przez barierę w $x = 0$ nie dojdzie w swej drodze do punktu $x_n > x_0$. Pokazujemy, że jest ono dane przez

$$H(x_0, x_n) = \frac{1 - \exp\left[\frac{2\beta}{\alpha}(x_n - x_0)\right]}{1 - \exp\left[\frac{2\beta}{\alpha}x_n\right]}.$$

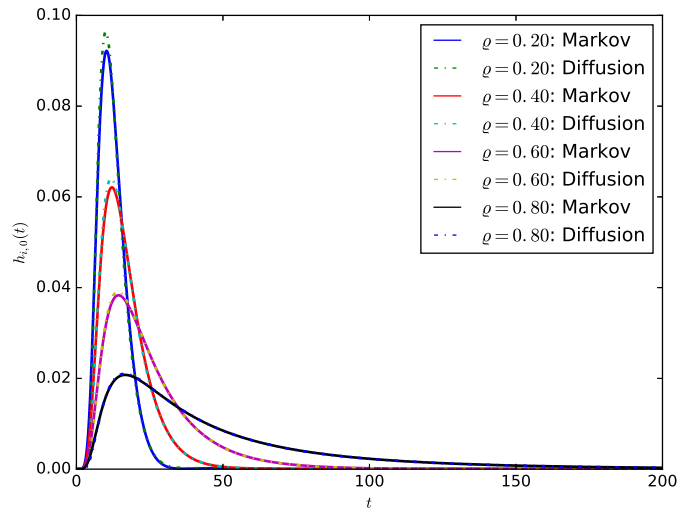
Wówczas funkcja gęstości okresu czynnego rozpoczętego w $x = i$ i zakończony w $x = 0$ może być wyrażona jako (wersja dla $\beta < 0$)

$$\begin{aligned} h_{i,0}(t) &= H(i, B)\gamma_{i,0}(t) + [1 - H(i, B)]\{H(B-1, B)\gamma'_{i,B}(t) * l_B(t) * \gamma_{B-1,0}(t) \\ &+ [1 - H(B-1, B)]H(B-1, B)\gamma'_{i,B}(t) * l_B(t)^{2*}\gamma'_{B-1,B}(t) * \gamma_{B-1,0}(t) \\ &+ [1 - H(B-1, B)]^2 H(B-1, B)\gamma'_{i,B}(t) * l_B(t)^{3*}\gamma'_{B-1,B}(t)^{2*} * \gamma_{B-1,0}(t) + \dots\} \end{aligned} \quad (35)$$

Funkcje gęstości oznaczone symbolem γ są znormalizowane (przy $\beta < 0$ prawdopodobieństwo dojścia z i do B lub z $i-1$ do B jest mniejsze od jedności). Rysunki przedstawiają przykładowe wyniki numeryczne.

Rezultat analogiczny do (36) był wcześniej znany dla przypadku stanowiska $M/M/1/B$ [37].


Rys. 20 przedstawia funkcję gęstości $h_{100,0}(t)$, uzyskaną z modelu dyfuzyjnego (linia przerywana i Markowa (linia ciągła) dla czasu rozładowania baterii o pojemności $B = 100$ jednostek energii, dla dwu przypadków: $\rho = 0.6$ i $\rho = 0.8$. W modelu dyfuzyjnym przyjęto $C_A^2 = C_B^2 = 1$, co odpowiada rozkładowi wykładniczemu, dla których jest ważny model Markowa.



Rysunek 19: Porównanie wyników modelu Markowa i dyfuzyjnego dla $h_{i,0}(t)$, w przypadku $i = 10$, $\mu = 1$, $C_A^2 = C_B^2 = 1$, $B = 100$.

Widać bardzo dobrą zgodność wyników uzyskanych przez oba modele. W wynikach modelu Markowa obserwujemy drobne odchylenia wynikające z błędów numerycznej inwersji transformaty Laplace'a; funkcja $h_{i,0}(t)$ jest podana w [37] w postaci transformaty Laplace'a.

Przedstawione wyniki stały się podstawą analizy ataków polegających na nadmiarowym poborze energii, [A22].



Rysunek 20: Funkcja gęstości $h_{B,0}(t)$ rozkładu czasu rozładowania baterii - porównanie wyników aproksymacji dyfuzyjnej i modelu Markowa, $\rho = 0.6$ i $\rho = 0.8$; $\mu = 1$, $C_A^2 = C_B^2 = 1$, $B = 100$.

4 Podsumowanie

Wśród znanych zalet aproksymacji dyfuzyjnej są wymieniane:

- możliwość uwzględnienia dowolnych rozkładów między nadejściami klientów i czasu obsługi, co często jest niemożliwe w analitycznych modelach teorii kolejek. Informacja dotycząca rozkładów jest ograniczona do dwu ich momentów, czyli danych, które łatwo pozyskać pomiarowo,

- Łatwość analizy stanów nieustalonych, analityczne modele teorii kolejek mają bardzo ograniczone możliwości w tym zakresie, a modele symulacyjne są bardzo czasochłonne, bo wymagają powtarzania symulacji tysiące razy, by uzyskać wiarogodne statystycznie wyniki jako funkcje czasu,

- łatwe wyznaczanie prawdopodobieństw zdarzeń rzadkich, w szczególności prawdopodobieństwa utraty pakietu z powodu przepełnienia bufora (symulacja wymaga bardzo długich przebiegów, by je wyznaczyć z dostateczną dokładnością),

- dekompozycja modeli sieciowych pozwala zastosować ją do analizy dużych topologii sieci, także o złożonej i hierarchicznej strukturze,

- ponieważ modele nie rozpatrują poszczególnych zdarzeń typu “nadejście klienta” “odejście klienta”, nie ma tutaj odgraniczeń wywołanych przez wzrost liczby stanów, które trzeba w modelu uwzględnić,

- modele są rozwiązywane w przedziałach czasowych, co pozwala na dowolny dobór parametrów ruchu, innych w każdym przedziale, z możliwością uwzględnienia ich korelacji.

Opracowane w rozprawie modele i analiza ich wyników potwierdzają te spostrzeżenia i świadczą, że aproksymacja dyfuzyjna jest narzędziem, które dobrze się nadaje do modelowania pracy elementów sieci komputerowej, szczególnie tam, gdzie niezbędna jest analiza stanów nieustalonych. Pozwala na analizę przypadków niedostępnych dla innych metod modelowania

i jest w stanie wyznaczyć prawdopodobieństw wypadków rzadkich, co też jest bardzo trudne w przypadku innych metod. Dokładność aproksymacji nie budzi zastrzeżeń. Wybrane modele znacznie poszerzają zakres zastosowania metody i pokazują, że jest ona użyteczna w modelowaniu aktualnych problemów sieci komputerowych (Internet Rzeczy, sieci zdefiniowane programowo, systemy magazynowania energii). Rozpatrywane modele pokazują elastyczność tej metody, którą można dostosować do opisu różnych, czasem złożonych mechanizmów działania. Wydaje się, że obiecujące będą dalsze prace dotyczące modelowania większych topologii sieci SDN i optymalizacji ich pracy zgodnie z założonymi przez centralny sterownik kryteriami.

Publikacje powstałe w trakcie pracy nad dysertacją

wyróżniono pozycje bezpośrednio związane z pracą

- (A1) Kuaban, G. S, T. Atmaca, A. Kamli, T. Czachórski, and P. Czekalski, *Performance Analysis of Packet Aggregation Mechanisms and Their Applications in Access (e.g., IoT, 4G/5G), Core, and Data Centre Networks*, *Sensors*, vol. 21, issue 3898, 2021, <https://doi.org/10.3390/s21113898>, IF: 3.847(2021), 100 punktów ministerialnych.
- (A2) Czachórski, T., E. Gelenbe, G. S. Kuaban, and D. Marek, *Time-Dependent Performance of a Multi-Hop Software Defined Network*, *Sensors*, vol. 21, issue 3898, 2021, <https://doi.org/10.3390/app11062469>, IF: 2.838(2021), 100 punktów ministerialnych.
- (A3) Kuaban, G.s., R. Kumar, B. Singh Soodan, and P. Czekalski, *A Multi-Server Queuing Model With Balking and Correlated Reneging With Application in Health Care Management*, *IEEE Access*, vol. 8, pp. 169623–169639, 2020, doi: 10.1109/ACCESS.2020.3024259, IF: 3.476, 100 punktów ministerialnych.
- (A4) Czachórski, T., E. Gelenbe, and G. S. Kuaban, *Modelling energy changes in the energy harvesting battery of an IoT device*, *Modelling, Analysis, and Simulation of Computer and Telecommunication Systems (MASCOTS)*, Nice, France, IEEE, 2023, (in press but I have copyright contract with the IEEE) 140 punktów ministerialnych.
- (A5) Atmaca, T., A. Kamli, G. S. Kuaban, and T. Czachórski, Atmaca, T., Kamli, A., Kuaban, G.S., Czachórski, T. *Performance Evaluation of the Packet Aggregation Mechanism of an N-GREEN Metro Network Node*, In: Calzarossa, M.C., Gelenbe, E., Grochla, K., Lent, R., Czachórski, T. (eds) *Modelling, Analysis, and Simulation of Computer and Telecommunication Systems. MASCOTS 2020. Lecture Notes in Computer Science()*, vol 12527. pp. 62-78, 2021, Springer, Cham, doi:10.1007/978-3-030-68110-4_4, 140 punktów ministerialnych.
- (A6) Czachórski, T., E. Gelenbe, G. S.Kuaban, and D. Marek, *Transient Behaviour of a Network Router*, in: *proceedings of the 2020 43rd International Conference on*

- Telecommunications and Signal Processing (TSP), Milan, Italy, 2020, pp. 246-251, IEEE doi: 10.1109/TSP49548.2020.9163477, 80 punktów ministerialnych.**
- (A7) Tokarz, K., P. Czekalski, G. Drabik, J. Paduch, S. Distefano, R. Di Pietro, G. Merlino, C. Scaffidi, R. Sell, and G. S. Kuaban, *Internet of Things Network Infrastructure for The Educational Purpose*, 2020 IEEE Frontiers in Education Conference (FIE), Uppsala, Sweden, 2020, pp. 1-9, IEEE doi: 10.1109/FIE44824.2020.9274040. 70 punktów ministerialnych.
- (A8) G. S. Kuaban, B. Singh Soodan, R. Kumar and P. Czekalski, *Analysis of the Performance of a Cloud Computing Processing Queue with Correlated Reneging of Tasks and Resubmission*, in proceedings of the 2021 International Conference on Electrical, Computer and Energy Technologies (ICECET), Cape Town, South Africa, 2021, pp. 1-8, IEEE, doi: 10.1109/ICECET52533.2021.9698583, 80 punktów ministerialnych.
- (A9) G. S. Kuaban et al., *An IoT Course Program to Foster the Adoption of IoT Driven Food and Agriculture in Sub-Saharan Africa (SSA)*, in: proceedings of the 2022 International Conference on Electrical, Computer and Energy Technologies (ICECET), Prague, Czech Republic, 2022, pp. 1-7, IEEE, doi: 10.1109/ICECET55527.2022.9872825, 80 punktów ministerialnych.
- (A10) G. S. Kuaban, B. S. Soodan, R. Kumar and P. Czekalski, *A Queueing-theoretic Analysis of the Performance of a Cloud Computing Infrastructure: Accounting for Task Reneging or Dropping*, in: proceedings of the 2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), Maldives, Maldives, 2022, pp. 1-7, IEEE, doi: 10.1109/ICECCME55909.2022.9988250, 80 punktów ministerialnych.
- (A11) Kumar, R., B. Singh Soodan, G. S. Kuaban, P. Czekalski, and S. Sharma, *Performance Analysis of a Cloud Computing System using Queuing Model with Correlated Task Reneging*, Journal of Physics: Conference Series, presented in 5th International Scientific Conference on Information, Control, and Communication Technologies (ICCT-2021) 4-7 October 2021, Astrakhan, Russian Federation, vol. 2091 , issue 012003, Institute of Physics (IoP), 2021, 10.1088/1742-6596/2091/1/012003, IF: 0.547, 40 punktów ministerialnych.
- (A12) Tangka, J. Kewir, J. Ngangsi Ngah, G. S. Kuaban, and M. N. W. Evina, *Comparative Analysis of the Vibrational Response of a Homemade Helicopter*, European Journal of Applied Sciences, vol. 10, issue 4, August 2022, doi: <https://doi.org/10.14738/aivp.104.12621>, 0 punktów ministerialnych.
- (A13) S. Sharma, R. Kumar, G. S. Kuaban, B. S. Soodan and P. Singh, *Performance and Cost Evaluation of an Adaptive Queuing System with Customer Reneging and Retention: Steady-state and Transient Analysis*, International Journal of Services, Economics and Management, Inderscience, 2023 (In Press but I have copyright contract with the Inderscience), 20 punktów ministerialnych.
- (A14) **Czachórski, T., E. Gelenbe, G. S. Kuaban, and D. Marek, *Time Dependent Diffusion Model for Security Driven Software Defined Networks, Time Dependent***

- Diffusion Model for Security Driven Software Defined Networks, in: proceedings of the Second International Workshop on Stochastic Modeling and Applied Research of Technology (SMARTY 2020), CEUR vol. 2792, pp. pp. 38-56, 2020, <https://ceur-ws.org/Vol-2792/>, <http://ceur-ws.org/Vol-2792/paper3.pdf>, 0 punktów ministerialnych.
- (A15) Kuaban, G.S., Soodan, B.S., Kumar, R., Czekalski, P. (2020), *Optimizing Energy Usage for an Electric Drone*, In: Gelenbe, E., Jankovic, M., Kehagias, D., Marton, A., Vilmos, A. (eds) Security in Computer and Information Sciences. EuroCybersec 2021. Communications in Computer and Information Science, vol 1596. pp. 61-75 2022, Springer, Cham, https://doi.org/10.1007/978-3-031-09357-9_6, 80 punktów ministerialnych.
- (A16) Kuaban, G.S., Soodan, B.S., Kumar, R., Czekalski, P. (2020), *Performance Evaluations of a Cloud Computing Physical Machine with Task Reneging and Task Resubmission (Feedback)*, In: Gaj, P., Gumiński, W., Kwiecień, A. (eds) Computer Networks. CN 2020. Communications in Computer and Information Science, vol 1231. pp. 185-198, Springer, Cham. https://doi.org/10.1007/978-3-030-50719-0_14, 80 punktów ministerialnych.
- (A17) Czachórski, T., Kuaban, G.S., Nycz, T. *Multichannel Diffusion Approximation Models for the Evaluation of Multichannel Communication Networks*, In: Vishnevskiy, V., Samouylov, K., Kozyrev, D. (eds) Distributed Computer and Communication Networks. DCCN 2019. Lecture Notes in Computer Science(), vol 11965., pp. 43–57, 2019, Springer, Cham, https://doi.org/10.1007/978-3-030-36614-8_4, 80 punktów ministerialnych.
- (A18) Kuaban, G.S., Anyam, E., Czachórski, T., Rataj, A., *Performance of a Buffer Between Electronic and All-Optical Networks, Diffusion Approximation Model*, In: Czachórski, T., Gelenbe, E., Grochla, K., Lent, R. (eds) Computer and Information Sciences. ISCIS 2018. Communications in Computer and Information Science, vol 935, pp. 68-75 2018. Springer, Cham, https://doi.org/10.1007/978-3-030-00840-6_8, 80 punktów ministerialnych.
- (A19) Kuaban, G.S., Czachórski, T., Rataj, A. (2018), *A Queueing Model of the Edge Node in IP over All-Optical Networks*, In: Gaj, P., Sawicki, M., Suchacka, G., Kwiecień, A. (eds) Computer Networks. CN 2018. Communications in Computer and Information Science, vol 860, pp. 258-271, 2018. Springer, Cham, https://doi.org/10.1007/978-3-319-92459-5_21, 80 punktów ministerialnych.
- (A20) Sell R., Kalm T., Malayjerdi M. R., Sell I., Nikitenko A., Ziravedska A., Berkolds K., Vitols K., Czekalski Piotr, Tokarz Krzysztof, Antemijczuk Oleg, Kuaban G.S., *Unmanned electrical vehicles and autonomous system simulation*, Riga : RTU Press, 2021, p-ISBN: 978-9934-22-667-0, e-ISBN: 978-9934-22-668-7, 0 punktów ministerialnych.
- (A21) Kuaban, G. S., E. L. Molua, P. Czekalski, and K. Grochla, *An Architectural Framework Proposal for IoT Driven Agriculture*, In: Gaj, P., Sawicki, M., Kwiecień, A. (eds) Computer

Networks. CN 2019. Communications in Computer and Information Science, vol 1039. pp. pp 18–33, 2019, Springer, Cham. https://doi.org/10.1007/978-3-030-21952-9_2, 80 punktów ministerialnych.

- (A22) **Kuaban G.S., Gelenbe E., Czachórski T., Czekalski P., Tangka J.K.**, *Modelling of the Energy Depletion Process and Battery Depletion Attacks for Battery-Powered Internet of Things (IoT) Devices*, **zgłoszone do Sensors**.

Bibliografia dotycząca całego tekstu streszczenia

Literatura

- [1] A. S. Akyurek and T. S. Rosing. Optimal packet aggregation scheduling in wireless networks. *IEEE Transactions on Mobile Computing*, 17(12):2835–2852, 2018.
- [2] F. Bause, P. Buchholz, and J. Kriege. Profido - the processes fitting toolkit dortmund, in proc. of the 7th international conference on quantitative evaluation of systems. *IEEE Computer Society*, 96(87), 2010.
- [3] P. J. Burke. The output of a queuing system. *Operations Research*, 4(6):699–704, 1956.
- [4] D. C. Champernowne. An elementary method of solution of the queueing problem with a single server and constant parameters. *J.R. Statist. Soc*, 3(4):263–266, 2000.
- [5] R. P. Cox and H. D. Miller. *The Theory of Stochastic Processes*. Chapman and Hall, London, UK, 1965.
- [6] T. Czachórski. A method to solve diffusion equation with instantaneous return processes acting as boundary conditions. *Bulletin of Polish Academy of Sciences, Technical Sciences*, 41(4), 1993.
- [7] T. Czachórski. Queueing models for performance evaluation of computer networks—transient state analysis. In V. Mityushew and M. Ruzhansky, editors, *Analytic Methods in Interdisciplinary Applications*, volume 116 of *Springer Proceedings in Mathematics & Statistics*, pages 51–80. Springer, 2015.
- [8] T. Czachórski, M. Nycz, and T. Nycz. Modelling transient states in queueing models of computer networks: A few practical issues. In V. Vishnevsky, editor, *Distributed Computer and Communication Networks. Communications in Computer and Information Science*, volume 279, pages 58–72. Springer International Publishing Switzerland, 2014.
- [9] T. Czachórski, M. Nycz, T. Nycz, and F. Pekergin. Analytical and numerical means to model transient states in computer networks. In A. Kwiecień, P. Gaj, and P. Stera, editors, *Computer Networks*, pages 426–435, Berlin, Heidelberg, 2013. Springer Berlin Heidelberg.
- [10] T. Czachórski and F. Pekergin. Diffusion approximation as a modelling tool. In D. D. Kouvatsos, editor, *Network Performance Engineering*, volume 5233, pages 447–476. Springer, 2011.

- [11] T. Czachórski. Przybliżone rozwiązania dokładnych modeli i dokładne rozwiązania modeli przybliżonych w ocenie efektywności złożonych układów komputerowych. *Podstawy Sterowania*, 7(1):11–24, 1977.
- [12] A. Duda. Diffusion approximations for time-dependent queueing systems. *IEEE Journal on Selected Areas in Communications*, 4:905–918, 1986.
- [13] T. O. Engset. Die wahrscheinlichkeitsrechnung zur bestimmung der wählerzahl in automatischen fernsprechämtern. *Elektrotechnische Zeitschrift*, 31, 1918.
- [14] A. K. Erlang. The theory of probabilities and telephone conversations. *Nyt Tidsskrift Matematik*, 20:33–39, 1909.
- [15] A. K. Erlang. Solutions of some problems in the theory of probabilities of significance in automatic telephone exchnges. *Electroteknikeren*, 13:5–13, 1917.
- [16] G. Erol and K. Y. Murat. Battery attacks on sensors: Wireless nodes with battery attacks. In *EuroCybersec 2018: International symposium on computer and information sciences, cybersecurity workshop*. Springer Cham, 2018.
- [17] G. Erol and K. Y. Murat. Energy life-time of wireless nodes with network attacks and mitigation. In *2018 IEEE International Conference on Communications Workshops (ICC Workshops)*, pages 1–6. IEEE, 2018.
- [18] A. Gautam and S. Dharmaraja. An analytical model driven by fluid queue for battery life time of a user equipment in LTE-A networks. *Physical Communication*, 30:213–219, 2018.
- [19] E. Gelenbe. On approximate computer systems models. *Journal of the ACM*, 22(2):261–269, 1975.
- [20] E. Gelenbe. Probabilistic models of computer systems part ii: Diffusion approximations, waiting times and batch arrivals. *Acta Informatica*, 12:285–303, 1979.
- [21] E. Gelenbe. Energy packet networks: Ict based energy allocation and storage. In *International Conference on Green Communications and Networking*, pages 186–195. Springer, 2011.
- [22] E. Gelenbe. Energy packet networks: adaptive energy management for the cloud. In *CloudCP'12: Proceedings of the 2nd International Workshop on Cloud Computing Platforms*, pages 1–5. ACM, <https://doi.org/10.1145/2168697.2168698>, 2012.
- [23] E. Gelenbe. Energy packet networks: smart electricity storage to meet surges in demand. In *SimuTools*, pages 1–7, 2012.
- [24] E. Gelenbe. Adaptive management of energy packets. In *COMPSAC Workshops*, pages 1–6. IEEE Computer Society, 2014.
- [25] E. Gelenbe. A sensor node with energy harvesting. *ACM SIGMETRICS Performance Evaluation Review*, 42(2):37–39, 2014.

- [26] E. Gelenbe and Y. M. Kadioglu. Energy loss through standby and leakage in energy harvesting wireless sensors. In *CAMAD*, pages 231–236. IEEE, 2015.
- [27] E. Gelenbe and C. Morfopoulou. A framework for energy-aware routing in packet networks. *Comput. J.*, 54(6):850–859, 2011.
- [28] E. Gelenbe and G. Pujolle. The behaviour of a single-queue in a general queueing network. *Acta Inf.*, 7:123–136, 1976.
- [29] G. L. Jones, P. G. Harrison, U. Harder, and T. Field. Fluid queue models of battery life. In *Proceeding of the 2011 IEEE 19th Annual International Symposium on Modelling, Analysis, and Simulation of Computer and Telecommunication Systems*, pages 278–285. IEEE, 2011.
- [30] J. M. Jornet and I. F. Akyildiz. Joint energy harvesting and communication analysis for perpetual wireless nanosensor networks in the terahertz band. *IEEE Transactions on Nanotechnology*, 11(3):570–580, 2012.
- [31] A. Kamli. *Analysis and Optimisation of a new futuristic optical network architecture*. PhD thesis, Ecole doctorale n=580 Sciences et technologies de l’information et de communication (STIC), Université Paris-Saclay, France, 2020.
- [32] A. Kamli, T. Atmaca, C. Lepers, A. Rataj, and D. Amar. Performance improvement of colored optical packet switching thanks to time slot sharing. In *Proceedings of the 14th Advanced International Conference on Telecommunications*, pages 12–31, Barcelona, Spain, 2018. IARIA.
- [33] D. G. Kendall. Stochastic processes occurring in the theory of queues and their analysis by the method of the imbedded markov chain. *The Annals of Mathematical Statistics*, 24(3):338–354, 1953.
- [34] M. Kwiatkowska, G. Norman, and D. Parker. Prism 4.0: Verification of probabilistic real-time systems. In *Proceeding of the 23rd International Conference on Computer Aided Verification (CAV’11)*, pages 585–591, 2011.
- [35] V. Misra, W.-B. Gongnad, and D. Towsley. A fluid-based analysis of a network of aqm routers supporting tcp flows with an application to red. In *Proceeding of the Conference on Applications, Technologies, Architectures and Protocols for Computer Communication (SIGCOMM 2000)*, pages 152–160. ACM, 2000.
- [36] R. Sidje. and W. J. Stewart. A numerical study of large sparse matrix exponentials arising in markov chains. *Computational Statistics & Data Analysis*, 29(012003):345–368, 1999.
- [37] H. Takagi and A. M. Tarabia. *Explicit Probability Density Function for the Length of a Busy Period in an M/M/1/K Queue*. Springer, Spring Street, New York, NY 10013, USA, 2009.
- [38] A. Thummler, P. Buchholz, and M. Telek. A novel approach for phase - type fitting with the em algorithm. *IEEE Trans DependableSerur. Comput.*, 3(3):245–258, 2006.

- [39] C. Tunc and N. Akar. Markov fluid queue model of an energy harvesting IoT device with adaptive sensing. *Performance Evaluation*, 111:1–16, 2017.
- [40] S. Wijeratne, A. Ekanayake, S. Jayaweera, D. Ravishan, and A. Pasqual. Scalable high performance router architecture on fpga for core networks. In *Proceeding of the 2019 ACM/SIGDA International Symposium*. ACM, 2019.