


PURSKETASON TARKASTELUT

Ylivuototodennäköisyys puskurittomassa systeemissä

- Tarkastellaan ATM-kytkimen lähtöporttia
- Oletetaan:
 - puskuri riittää vain solutason puskurointiin
 - lähtöväylän kapasiteetti C
- Useita VC-yhteyksiä kulkee saman lähtöväylän kautta
 - yhteyksien yhteenlaskettu nopeus X
- Kapasiteetin C ylittävä osuus vuotaa yli
- Ylivuotovirta $(X - C)^+$
 - missä $(\cdot)^+ = \max(0, \cdot)$



Ylivuoto- ja saturaatiotodennäköisyys

- Ylivuototodennäköisyys

- ylivuotavan virran suhde saapuvaan virtaan

$$P_{\text{loss}} = \frac{E[(X - C)^+]}{E[X]} = \frac{\int_C^\infty (x - C)f(x)dx}{\int_0^\infty xf(x)dx}$$

- Saturaatiotodennäköisyys

$$P_{\text{sat}} = P\{X \geq C\}$$

- todennäköisyys, että kapasiteetti ylittyy

- usein hiukan helpompi laskea kuin P_{loss}

- karkea yläraja P_{loss} :lle

- yleensä pari dekadia suurempi kuin P_{loss}

- ero ei ratkaiseva mitoituksen kannalta

- häviöt riippuvat jyrkästi kapasiteetista

- kapasiteetti muuttuu hitaasti häviötason mukana

Alkeellinen tarkastelu – normaaliapproksimaatio

- Linkillä kulkee n virtuaalikanavayhteyttä
 - samanlaiset, riippumattomat liikennevirrat

$$X = X_1 + \dots + X_n$$

- Merkitään

$$\begin{cases} m = \text{yhden virran keskinopeus, } E[X_1], \\ \sigma^2 = \text{yhden virran nopeuden varianssi, } V[X_1]. \end{cases}$$

- Vastaavasti


$$\begin{cases} M = n \cdot m = \text{koko liikennevirran keskinopeus, } E[X], \\ \Sigma^2 = n \cdot \sigma^2 = \text{koko liikennevirran nopeuden varianssi, } V[X] \end{cases}$$

- Jos n on suuri, pätee likimain $X \sim N(M, \Sigma^2)$
- Saturaatiotodennäköisyys on tällöin

$$P_{\text{sat}} = Q\left(\frac{C - M}{\Sigma}\right)$$

missä

$$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty e^{-y^2/2} dy = \frac{1}{2} \operatorname{erfc}\left(\frac{x}{\sqrt{2}}\right)$$



Normaaliapproksimaatio – efektiivinen kaista

- Taso P_{sat} edellyttää vähintään kapasiteettia C

$$C \geq M + Q^{-1}(P_{\text{sat}}) \cdot \Sigma$$

- Merkitään todennäköisyyttä $1 - P_{\text{sat}}$ vastaava $N(0,1)$ -jakauman fraktilipistettä η :lla

$$\eta = Q^{-1}(P_{\text{sat}})$$


- M :n ja Σ^2 :n määritelmiä käyttäen

$$C \geq n \cdot m + \eta \sqrt{n} \cdot \sigma$$

- Tarvittava kaista yhtä virtaa kohti eli efektiivinen kaista

$$B_{\text{eff}} = m + \frac{\eta \cdot \sigma}{\sqrt{n}}$$

- Efektiivinen kaista lähenee keskinopeutta n :n kasvaessa



Momenttien generoiva funktio

- Satunnaismuuttujan X momenttien generoiva funktio

$$M(\beta) = \mathbb{E}[e^{\beta X}] = \int e^{\beta x} f(x) dx$$

- Logaritminen momenttien generoiva funktio

$$\varphi(\beta) = \log M(\beta)$$

- Momentit voidaan laskea näiden avulla

$$\begin{cases} m = \mathbb{E}[X] = M'(0) & = \varphi'(0) \\ \mathbb{E}[X^2] = M''(0) \\ \sigma^2 = \mathbb{V}[X^2] = M''(0) - M'(0)^2 = \varphi''(0) \end{cases}$$

- Additiivisuus: Jos $X = X_1 + X_2 + \dots + X_n$, missä X_1, X_2, \dots, X_n ovat riippumattomia satunnaismuuttujia, joiden lmgf:t ovat $\varphi_1(\beta), \varphi_2(\beta), \dots, \varphi_n(\beta)$, niin

$$\begin{aligned} \varphi(\beta) &= \log \mathbb{E}[e^{\beta X}] \\ &= \log \mathbb{E}[e^{\beta(X_1+X_2+\dots+X_n)}] \\ &= \log \mathbb{E}[e^{\beta X_1} e^{\beta X_2} \dots e^{\beta X_n}] \\ &= \log(\mathbb{E}[e^{\beta X_1}] \cdot \mathbb{E}[e^{\beta X_2}] \dots \mathbb{E}[e^{\beta X_n}]) \\ &= \log \mathbb{E}[e^{\beta X_1}] + \log \mathbb{E}[e^{\beta X_2}] + \dots + \log \mathbb{E}[e^{\beta X_n}] \\ &= \varphi_1(\beta) + \varphi_2(\beta) + \dots + \varphi_n(\beta) \end{aligned}$$

Arvot origossa:

$$\begin{cases} M(0) = 1 \\ \varphi(0) = 0 \end{cases}$$

Vinoutettu jakauma

- Olkoon X :n tiheysfunktio $f(x)$
- Vinoutettu l. siirretty jakauma $f_\beta(x)$

$$f_\beta(x) = \frac{e^{\beta x} f(x)}{M(\beta)} = e^{\beta x - \varphi(\beta)} f(x)$$

- X :n suuret arvot tulevat todennäköisemmiksi
- jakauman massa siirtyy kohti suurempia arvoja
- momenttien generoiva funktio $M(\beta)$ toimii normitustekijänä


- Kääntäen $f(x)$ voidaan lausua $f_\beta(x)$:n avulla

$$f(x) = e^{-\beta x + \varphi(\beta)} f_\beta(x)$$

- Vinoutus voidaan määritellä olettamatta jatkuvuutta
- Todennäköisyysmitan vinoutus

$$dP_\beta(x) = e^{\beta x - \varphi(\beta)} dP(x)$$

- Merkitään $E_\beta[\cdot] =$ odotusarvo mitan P_β suhteen



Vinoutettu jakauma – jatkoa

- Vinoutetun jakauman momentit

$$\begin{cases} E_{\beta}[X] &= \frac{E[Xe^{\beta X}]}{M(\beta)} = \frac{M'(\beta)}{M(\beta)} = \varphi'(\beta) \\ E_{\beta}[X^2] &= \frac{E[X^2e^{\beta X}]}{M(\beta)} = \frac{M''(\beta)}{M(\beta)} \\ V_{\beta}[X] &= \frac{M''(\beta)}{M(\beta)} - \frac{M'(\beta)^2}{M(\beta)^2} = \varphi''(\beta) \end{cases}$$

$$\begin{cases} m(\beta) &= \varphi'(\beta) \\ \sigma^2(\beta) &= \varphi''(\beta) \end{cases}$$

Vinoutettu jakauma – jatkoa

- Vinoutettujen momenttien additiivisuus: Jos $X = X_1 + X_2 + \dots + X_n$, missä X_1, X_2, \dots, X_n ovat riippumattomia, niin lmgf-funktioiden additiivisuudesta seuraa

$$\begin{cases} m(\beta) &= m_1(\beta) + m_2(\beta) + \dots + m_n(\beta) \\ \sigma_1^2(\beta) &= \sigma_1^2(\beta) + \sigma_2^2(\beta) + \dots + \sigma_n^2(\beta) \end{cases}$$

missä $m_i(\beta)$ ja $\sigma_i^2(\beta)$ ovat muuttujan X_i odotusarvo ja varianssi vinoutetun jakauman suhteen

- Pätee enemmänkin:

Riippumattomien satunnaismuuttujien summan X vinoutettu jakauma on sama kuin kyseisten muuttujien X_i vinoutettuja jakaumia noudattavien riippumattomien satunnaismuuttujien summan jakauma:

$$\begin{array}{ccc} & \text{summa} & \\ & \implies & \\ \text{vinoutus} \Downarrow & & \Downarrow \text{vinoutus} \\ & \implies & \\ & \text{summa} & \end{array}$$

Vinoutettu jakauma – esimerkki 1

- Eksponenttijakauma $X \sim \text{Exp}(\lambda)$
- Tiheysfunktio $f(x) = \lambda e^{-\lambda x}$

$$\begin{cases} M(\beta) = \mathbb{E}[e^{\beta X}] = \int_0^\infty \lambda e^{-(\lambda-\beta)x} dx = \frac{\lambda}{\lambda-\beta}, \\ \varphi(\beta) = \log M(\beta) = \log \lambda - \log(\lambda - \beta) \end{cases}$$

$$\begin{cases} m(\beta) = \varphi'(\beta) = \frac{1}{\lambda-\beta} \\ \sigma^2(\beta) = \varphi''(\beta) = \frac{1}{(\lambda-\beta)^2} \end{cases}$$

- Vinoutettu jakauma

$$f_\beta(x) = (\lambda - \beta)e^{-(\lambda-\beta)x}$$

- on myös eksponentiaalinen
- parametri $\lambda - \beta$


Vinoutettu jakauma – esimerkki 2

- X on n :n riippumattoman eksponenttijakautuneen muuttujan summa
- $X \sim \text{Erlang}(n, \lambda)$
- Tiheysfunktio on

$$f(x) = \lambda \frac{(\lambda x)^{n-1}}{(n-1)!} e^{-(\lambda x)}$$

- Vinoutettu jakauma:
 n :n vinoutetun $\text{Exp}(\lambda - \beta)$ -jakautuneen muuttujan summan jakauma
- $\text{Erlang}(n, \lambda - \beta)$ -jakautuma
- Keskiarvo ja varianssi

$$\begin{cases} m(\beta) = \frac{n}{\lambda - \beta} \\ \sigma^2(\beta) = \frac{n}{(\lambda - \beta)^2} \end{cases}$$



Viiden $\text{Exp}(1)$ -jakautuneen muuttujan summan jakauma ja vastaava vinoutettu jakauma vinoutusparametrilla $\beta = \frac{2}{3}$.

Vinoutettu jakauma – Yhteenvetotaulukko

- Tavallisissa jakaumaperheissä vinoutettu jakauma kuuluu samaan perheeseen
- Vinoutetun jakauman keskiarvo ja varianssi noudattavat kyseisen perheen tunnettuja kaavoja

Jakauma	Vinoutettu	$m(\beta)$	$\sigma^2(\beta)$
$\text{Bin}(n, p)$	$\text{Bin}(n, \frac{pe^\beta}{1-p+pe^\beta})$	$\frac{npe^\beta}{1-p+pe^\beta}$	$\frac{n(1-p)pe^\beta}{(1-p+pe^\beta)^2}$
$\text{Erlang}(n, \lambda)$	$\text{Erlang}(n, \lambda - \beta)$	$\frac{n}{\lambda - \beta}$	$\frac{n}{(\lambda - \beta)^2}$
$\text{Poisson}(a)$	$\text{Poisson}(ae^\beta)$	ae^β	ae^β
$\text{N}(m, \sigma^2)$	$\text{N}(m + \sigma^2\beta, \sigma^2)$	$m + \sigma^2\beta$	σ^2


Taulukko 1: Eräiden jakaumien siirretyt jakaumat ja näiden parametrit.

- Bernoulli-jakauma on erikoistapaus binomijakaumasta: $\text{Bernoulli}(p) \sim \text{Bin}(1, p)$
- Eksponenttijakauma on erikoistapaus Erlang-jakaumasta: $\text{Exp}(\lambda) \sim \text{Erlang}(1, \lambda)$
- χ^2 -jakauma on erikoistapaus Erlang-jakaumasta: $\chi^2(n) \sim \text{Erlang}(\frac{n}{2}, \frac{1}{2})$

Chernoffin raja

- Kaikilla arvoilla $\beta \geq 0$ pätee

$$\begin{aligned} P\{X \geq x\} &= E[1_{\{X \geq x\}}] \\ &\leq E[e^{\beta(X-x)}] \\ &= e^{-\beta x} E[e^{\beta X}] \\ &= e^{\varphi(\beta) - \beta x} \end{aligned}$$



sillä $e^{\beta(X-x)} \geq 1_{\{X \geq x\}}$.

- Tällöin pätee myös $P\{X \geq x\} \leq \inf_{\beta} e^{-\beta x + \varphi(\beta)}$
- Merkitään β_x :llä sitä β :n arvoa, jolla minimi saavutetaan.
- Chernoffin yläraja

$$P\{X \geq x\} \leq e^{-\beta_x x + \varphi(\beta_x)}$$

- Arvo β_x löydetään minimoimalla eksponentti.

$$\varphi'(\beta_x) = x \quad \text{eli} \quad m(\beta_x) = x$$

- Vinoutetun jakauman keskiarvo siirretään pisteeseen x .

Cramérin teoreema

- Olkoon $X = X_1 + X_2 + \dots + X_n$
 - X_i :t riippumattomia ja samoinjakautuneita
 - komponenttimuuttujien yhteinen lmgf on $\varphi(\beta)$
 - X :n lmgf on $n \varphi(\beta)$
- Tutkitaan keskiarvon $\frac{1}{n}X$:n ylitystodennäköisyyttä

$$P\left\{\frac{1}{n}(X_1 + X_2 + \dots + X_n) \geq x\right\}$$

- Sovelletaan Chernoffin rajaa

$$P\left\{\frac{1}{n}(X_1 + X_2 + \dots + X_n) \geq x\right\} = P\{X \geq n x\} \leq e^{-n(\beta_x x - \varphi(\beta_x))}$$

- β_x määräytyy ehdosta $n \varphi'(\beta_x) = n x$ eli $\varphi'(\beta_x) = x$.
- Vauhtifunktio $I(x) = \sup_{\beta}(\beta x - \varphi(\beta)) = \beta_x x - \varphi(\beta_x)$.
- Keskiarvon ylitystodennäköisyys

$$P\left\{\frac{1}{n}(X_1 + X_2 + \dots + X_n) \geq x\right\} \leq e^{-nI(x)}$$

- Cramérin teoreema: yläraja on asympotoottisesti tarkka

$$\lim_{n \rightarrow \infty} \frac{1}{n} \log P\left\{\frac{1}{n}(X_1 + X_2 + \dots + X_n) \geq x\right\} = -I(x)$$

Yhteenvetotaulukko

- Taulukkoon on valmiiksi laskettu
 - tasoa x vastaava vinoutusparametri
 - vinoutetun jakauman varianssi vinoutuksella β_x
 - vauhtifunktio $I(x)$

Jakauma	β_x	$\sigma^2(\beta_x)$	$I(x)$
Bin(n, p)	$\log \frac{\frac{x}{n}(1-p)}{(1-\frac{x}{n})p}$	$x(1 - \frac{x}{n})$	$x \log \frac{\frac{x}{n}(1-p)}{(1-\frac{x}{n})p} + n \log \frac{1-\frac{x}{n}}{1-p}$
Erlang(n, λ)	$\lambda - \frac{n}{x}$	$\frac{x^2}{n}$	$x\lambda - n - n \log(\frac{x\lambda}{n})$
Poisson(a)	$\log \frac{x}{a}$	x	$x \log \frac{x}{a} + a - x$
N(m, σ^2)	$\frac{x-m}{\sigma^2}$	σ^2	$\frac{1}{2} \left(\frac{x-m}{\sigma}\right)^2$

Tarkempi approksimaatio

- Chernoffin raja vinoutetun jakauman avulla

$$\begin{aligned} P\{X \geq x\} &= \int_x^\infty f(y)dy \\ &= \int_x^\infty e^{-\beta y + \varphi(\beta)} f_\beta(y)dy \\ &= e^{-\beta x + \varphi(\beta)} \int_x^\infty e^{-\beta(y-x)} f_\beta(y)dy \end{aligned}$$

- Integroimisalueessa pätee $e^{-\beta(y-x)} \leq 1$
 \Rightarrow koko integraali ≤ 1
 $\Rightarrow P\{X \geq x\} \leq e^{-\beta x + \varphi(\beta)}$
 \Rightarrow Chernoffin raja $e^{-\beta_x x + \varphi(\beta_x)}$ saadaan minimoimalla β :n suhteen
- Tiukin raja saavutetaan arvolla β_x , jolla $m(\beta_x) = x$
 – jakauman $f_{\beta_x}(\cdot)$ keskiarvo sijaitsee pisteessä x
- Keskiarvon lähellä normaalijakauma $N(x, \sigma^2(\beta_x))$ on kohtuullinen approksimaatio

$$f_{\beta_x}(y) \approx \frac{e^{-\frac{1}{2}(y-x)^2/\sigma^2(\beta_x)}}{\sqrt{2\pi}\sigma(\beta_x)}$$

Tarkempi approksimaatio (jatkoa)

- Tällöin (olettaen $\beta_x \sigma(\beta_x) \gg 1$)

$$\begin{aligned} \int_x^\infty e^{-\beta_x(y-x)} f_{\beta_x}(y) dy &\approx \frac{1}{\sqrt{2\pi}\sigma(\beta_x)} \int_x^\infty e^{-\beta_x(y-x)} e^{-\frac{1}{2}(y-x)^2/\sigma^2(\beta_x)} dy \\ &\approx \frac{1}{\sqrt{2\pi}\beta_x\sigma(\beta_x)} \end{aligned}$$

- Saadaan (melko tarkka) likiarvo – ei enää yläraja

$$\boxed{P\{X \geq x\} \approx \frac{e^{-I(x)}}{\sqrt{2\pi}\beta_x\sigma(\beta_x)}}$$

Keskiarvon ylitystodennäköisyys ja menetystodennäköisyys

- Keskiarvolle pätee tarkemman approksimaation mukaisesti

$$P\left\{\frac{1}{n}(X_1 + X_2 + \dots + X_n) \geq x\right\} \approx \frac{e^{-nI(x)}}{\sqrt{2\pi n} \beta_x \sigma(\beta_x)}$$

- $I(x)$ on yhden komponenttimuuttujan vauhtifunktio
- $\sigma(\beta_x)$ on yhden komponentin vinoutettu hajonta
- summan vinoutetun jakauman hajonta on \sqrt{n} -kertainen
- tästä johtuu nimittäjään ilmestynyt n

- P_{loss} voidaan arvioida seuraavasti

$$P_{\text{loss}} = \frac{1}{m} E[(X - x)^+] = \frac{1}{m} e^{-\beta x + \varphi(\beta)} \int_x^\infty (y - x) e^{-\beta(y-x)} f_\beta(y) dy$$

- Valitaan β :lle arvo β_x

$$\int_x^\infty (y - x) e^{-\beta(y-x)} f_\beta(y) dy \approx \frac{1}{\sqrt{2\pi} \sigma(\beta_x)} \int_x^\infty (y - x) e^{-\beta_x(y-x)} e^{-\frac{1}{2}(y-x)^2/\sigma^2(\beta_x)} dy \approx \frac{1}{\sqrt{2\pi} \beta_x^2 \sigma(\beta_x)}$$

josta seuraa

$$P_{\text{loss}} = \frac{1}{m} E[(X - x)^+] \approx \frac{e^{-I(x)}}{\sqrt{2\pi m} \beta_x^2 \sigma(\beta_x)}$$

Esimerkki: Ylitystodennäköisyyden laskeminen

- Millä todennäköisyydellä viiden $\text{Exp}(1)$ -jakautuneen sm:n summa ylittää arvon $x = 15$?
- $X \sim \text{Erlang}(5, 1)$
- Tarkka tulos: $P\{X \geq 15\} = 22403e^{-15}/8 \approx 8.566 \cdot 10^{-4}$
- Tiedetään $E[X] = V[X] = 5$
- Normaaliapproksimaatio, $X \sim N(5, 5)$: $P_{\text{sat}} \approx Q\left(\frac{15-5}{\sqrt{5}}\right) \approx 3.87 \cdot 10^{-6}$
- Chernoffin raja: $P_{\text{sat}} \leq e^{-5I(15/5)} \approx 1.10 \cdot 10^{-2}$
missä $I(x) = x - 1 - \log x$ on yhden komponentin vauhtifunktio
- Tarkennettu approksimaatio: $P_{\text{sat}} \approx \frac{e^{-5I(15/5)}}{\sqrt{2\pi 5(2/3)}(15/5)} \approx 9.84 \cdot 10^{-4}$

$$\text{missä } \begin{cases} I(x) = x - 1 - \log x \text{ on yhden komponentin vauhtifunktio} \\ \beta_x = 1 - 1/3 = 2/3 \\ \sigma^2(\beta_x) = x^2 \end{cases}$$

- normaaliapproksimaatio on liian optimistinen
- Chernoffin yläraja on hyvin konservatiivinen
- tarkennettu approksimaatio on kohtuullisen tarkka

Kutsujen hyväksyminen – efektiivinen kaista

$$\left\{ \begin{array}{l} K = \text{lähdetyyppien lukumäärä; lähdeindeksi } k = 1, \dots, K \\ \varphi_k(\beta) = \text{lähdetyypin } k \text{ logaritminen momenttien generoiva funktio (oletetaan tunnetuksi)} \\ n_k = \text{tyypin } k \text{ lähteiden lukumäärä} \\ c = \text{linkin kapasiteetti} \end{array} \right.$$

Hyväksymisehto ylivuotokriteerin mukaan: $P_{\text{loss}} \leq \epsilon$ (ϵ on annettu suurin sallittu arvo)

Ylivuototodennäköisyys voidaan arvioida edellä esitetyn mukaisesti

$$P_{\text{loss}} \approx \frac{e^{-I(c)}}{\sqrt{2\pi m \beta^2 \sigma(\beta)}}$$

missä

$$\left\{ \begin{array}{l} I(c) = \beta c - \sum_k n_k \varphi_k(\beta) \\ \sigma^2(\beta) = \sum_k n_k \sigma_k^2(\beta) = \sum_k n_k \varphi_k''(\beta) \end{array} \right.$$

ja β määräytyy ehdosta

$$m(\beta) = c \quad \text{eli} \quad \sum_k n_k \varphi_k'(\beta) = c$$

Ylivuototodennäköisyyden arvioimiseksi tarvitsee ainoastaan ratkaista tämä yhtälö (numeerisesti) ja sijoittaa saatu β edellisiin lausekkeisiin. – Tämä on huomattavan helppoa verrattuna tarkan laskennan edellyttämään jakaumien konvoluointiin ($\sum_k n_k - 1$ konvoluutiota).

Kutsujen hyväksyminen – efektiivinen kaista (jatkoa)

Yhteyksien lukumäärävektori $\mathbf{n} = (n_1, \dots, n_K)$ määrää liikennesekoituksen (liikenneprofilii).

Annetulla sekoituksella \mathbf{n} ja kapasiteetilla c voidaan laskea P_{loss} ,


$$P_{\text{loss}} = P_{\text{loss}}(\mathbf{n}, c)$$

Tämän avulla voidaan kääntäen selvittää
hyväksymisalue A (yleensä konkaavi)

$$A = \{\mathbf{n} : P_{\text{loss}}(\mathbf{n}, c) \leq \epsilon\}$$

eli kaikki hyväksyttävissä olevat liikennesekoitukset \mathbf{n} ,
joilla $P_{\text{loss}} \leq \epsilon$.

Järjestelmään voidaan ottaa kuljetettavaksi uusia
yhteyksiä niin kauan kuin \mathbf{n} pysyy alueessa A .



Kutsujen hyväksyminen – efektiivinen kaista (jatkoa)

Jos liikennetyypit eivät eroa toisistaan liian paljon, hyväksymisalueen reuna on likimain suora (hypertaso)

$$\sum_k n_k B_k \leq c, \quad \text{missä efektiivinen kaista } B_k \text{ on } B_k = \frac{c}{n_k(c)}$$

ja $n_k(c)$ ilmoittaa, kuinka monta tyyppin k yhteyttä yksinään linkille c mahtuu siten, että $P_{\text{loss}} \leq \epsilon$.


Jos liikennetyypit ovat hyvin erilaiset, tasoapproksimaatio ei ole kovin tarkka.

Hyväksymisalueen reunan mielivaltainen tangenttitaso määrittelee turvallisen hyväksymisalueen.

Efektiivisenä kaistana voidaan pitää arvoa

$$B_k = c/n_k^*$$

missä n_k^* on arvo, jossa asetettu tangenttitaso leikkaa n_k -akselin.



Efektiivisen kaistan karkea likiarvokaava

Suuruusluokkalaskelmissa voidaan käyttää Lindbergerin likiarvokaavaa

$$B_k = 1.2m_k + 60\sigma_k^2/c$$

Jos lähteestä tunnetaan vain keskinopeus m_k ja huippunopeus h_k , voidaan vielä tehdä pahimman tapauksen arvio:

- Lähteen oletetaan olevan “on/off”-tyyppinen lähde
 - lähde on välillä päällä huippunopeudella h_k
 - välillä pois päältä siten, että keskinopeus on m_k

Tällöin on helppo osoittaa, että


$$\sigma_k^2 = m_k(h_k - m_k)$$

Efektiivinen kaista on/off-lähteiden tapauksessa

Edellä esitetty suurten poikkeamien teoriaan perustuva menetelmä antaa varsin tarkan keinon ylivuototodennäköisyyden arvioimiseksi mielivaltaisella liikennesekoituksella.

Joissakin tapauksissa ylivuototodennäköisyys voidaan laskea eksaktisti. Tärkein näistä on keskenään samanaisten “on/off”-lähteiden tapaus.

- n keskenään tilastollisesti identtistä lähettä
- lähteen nopeus “on”-tilassa h (huippunopeus)
- “on”-tilan todennäköisyys α
- “off”-tilan todennäköisyys $1 - \alpha$
- lähteen keskinopeus $m = \alpha h$



Huippunopeuden mukaan allokoitaessa, voidaan sallia n_0 lähettä: $n_0 = c/h$

Kun lähteitä on paljon eikä α ole aivan lähellä ykköstä, on hyvin epätodennäköistä, että kaikki lähteet olisivat yhtäaikaisesti päällä.

- Lähteet limittyvät tilastollisesti keskenään.
- Kun sallitaan pieni ylivuodon mahdollisuus, sallittua yhteyksien määrää voidaan merkittävästi kasvattaa (ns. tilastollisen multipleksoinnin hyöty eli limityshyöty G).

Efektiivinen kaista on/off-lähteiden tapauksessa (jatkoa)

Todennäköisyys p_i , että i lähettä n :stä on samanaikaisesti aktiivitulassa

$$p_i = \binom{n}{i} \alpha^i (1 - \alpha)^{n-i}$$

Ylivuototodennäköisyys on siten

$$P_{\text{loss}}(n, n_0, \alpha) = \frac{1}{nm} \sum_{i=[n_0]}^n p_i \cdot (i - n_0)h = \frac{1}{n\alpha} \sum_{i=[n_0]}^n p_i \cdot (i - n_0)$$

Suurin hyväksyttävä määrä yhteyksiä $n_\epsilon(n_0, \alpha)$ määräytyy ehdosta

$$P_{\text{loss}}(n_\epsilon, n_0, \alpha) \leq \epsilon$$

Yhden yhteyden efektiivinen kaista B_{eff} ($m \leq B_{\text{eff}} \leq h$)


$$B_{\text{eff}} = \frac{c}{n_\epsilon} = \frac{n_0}{n_\epsilon} \cdot h$$

- Limityshyöty (multiplexointihyöty) $G = n_\epsilon/n_0 = h/B_{\text{eff}}$
- Sallittu kuormitus $\rho = n_\epsilon m/c = n_\epsilon \alpha h/c = \alpha n_\epsilon/n_0 = \alpha G$

Efektiivinen kaista on/off-lähteiden tapauksessa (jatkoa)

Tilastollisen multipleksoinnin tehokkuutta voidaan mitata joko limityshyödyn G tai sallitun kuorman $\rho = \alpha G$ avulla (kumpaankin sisältyy sama informaatio).

- Alla olevissa kuvissa nähdään G ja ρ riippuvuus α :sta arvolla $\epsilon = 10^{-9}$.
- Käyräparametrina on $n_0 = c/h$ (alhaalta lukien arvot 10, 15, 30, 100).



- Pienillä arvoilla α (purskeinen liikenne) limityshyöty voi olla suuri.
- Sallittu kuormitus kuitenkin riippuu lähinnä vain käyräparametrin c/h .
- Kohtuullisen käyttöasteen saavuttaminen puskurittomassa systeemissä edellyttää, että yksittäisen lähteen huippunopeus on vain pieni osa linkin nopeudesta (1% tai alle).