


Optimalizace využití kapacity sítí na unixových systémech



Plánování provozu

prioritní FIFO: Oba systémy ve standardním nastavení respektují IPv4 bajt *Type of Service* a upřednostňují například provoz označený *lowdelay*.
OpenBSD navíc priorizuje BPDU, LACPDU, CARP announcementy a prázdné TCP pakety s flagem ACK, což pomáhá zejména ucpaným asymetrickým DSL připojením udržet rychlost i interaktivitu.

DRR: Každá fronta má *kvantum* bajtů, standardně MTU, o které se zvyšuje její *deficit*. Při odbavení paketu se deficit sníží o jeho délku.

fq_codel: Návrh na výchozí algoritmus pro masové používání k zajištění nízké doby odezvy v interaktivních aplikacích za všech okolností. Minimální variantu SFQ následuje DRR, za níž je CoDel. Standardně nepodporuje priority, nutno použít *prio* nad ním.

SFQ: Hashovací funkce nastavitelná filtrem flow řadí toky do divisor front, standardně 1024. Periodická změna této funkce přeuspořádává pakety v rámci spojení, standardní funkce hashuje i čísla portů, pročež plánovač nerozezná více spojení téhož programu a tedy není spravedlivý.

QFQ: Třída k patří do skupiny i podle váhy Φ_k a jejího nejdelšího paketu L_k , tak, že $i = \lceil \log_2(L_k/\Phi_k) \rceil$. Tedy pro pakety mezi 64 B a 16 kB je méně než 32).
 skupiny. Číslo skupiny je index do bitových polí, podle kterých se plánuje.
 Bitové pole (*eligible*, *ready*) obsahuje pakety, které již měly odejít a nejsou blokovány těmi s vyšším indexem skupiny, které již měly dojít. Pole (*eligible*, *blocked*) obsahuje bity u skupin, před nimiž je důležitější provoz.
Ineligible varianty jsou udržovány, aby mohly být včas povýšeny na *eligible*.
 V rámci skupiny jsou pakety bucket-sortem seřazené podle času odchodu, algoritmus funguje s asymptoticky konstantní složitostí.

HHF: *k* hashovacích funkcí klasifikuje paket přičtením jeho velikosti do *k* příhrádek filtru. Toky s velkým objemem dat přetěcou admit_bytes ve všech svých příhrádkách a jdou na seznam hh_limit toků, dokud se po evict_timeout sekund neuklidní. Plánovač je vážený round-robin, váhy 1 resp. non hh weight. Zřejmě nemá false-positiva.

Akce k filtrům

Generické akce (gact) jako **drop/pass/reclassify/pipe/continue** se umějí pohybovat po subsystému, akce **ipt** umí spustit na právě klasifikovaný paket daný cíl systému Netfilter, akce **mirred** umí paket duplikovat či přeměrovat na jiné rozhraní, což se hodí třeba při omezování rychlosti příchodících dat (*ingress shaping*). Akce **nat** přepisuje bezstavové IPv4 adresy, akce **pedir**, **skbedit** a **csum** umějí upravit paket, změnit metadata na něj přepočítat kontrolní součet. Původně jediná akce **police** umí omezovat rychlost parametry `rate` a `burst`; jelikož se jedná o policer, nevyhovující provoz se nezdrží, ale aplikuje se na něj jedna ze specifikovaných akcí.

Rozdělování kapacity linky

CBQ: Strom tříd omezením rychlosti, prioritou a možností půjčovat kapacitu ostatním nebo od ostatních. Plánovač měří, jak dlouho byla linka v klidu, a pamatuje si EWMA limitovaný maxburst pakety o průměrné velikosti avpkt. Odesílá minburst paketů najednou, kvůli kompenzaci rozlišení časovače. Tříd jsou plánovány váženým *round-robin* a provoz je pouze v listech. Vnitřní uzly slouží k půjčování kapacity mezi podstromy.

HFSC: Strom tříd s po dvou částech lineárními křivkami omezujícími dobu, za kterou bude nejdříve možné data odeslat. Provoz je pouze v listech. Real-time plánovač obsluhuje třídu s nejbližším možným časem odeslání, zbytek je rozdělen podle nejmenšího virtuálního času na dané úrovni. Úroveň uzlu při plánování nehraje roli, pouze virtuální čas spočtený z křivek.

HTB: Strom tříd se zaručenou a maximální rychlostí, prioritou na dané úrovni a kvantem k půjčování třídám níže. Uzel je zelený, má-li připravená data k odeslání a tehdy je na *globálním seznamu* v poli indexovaném prioritou a úrovní. Žlutý uzel má půjčenou kapacitu od svého rodiče a je na jeho *interním seznamu*. Červený uzel přečerpal dostupnou kapacitu a čeká ve frontě na dané úrovni na čas nejbližší změny barvy. Úroveň uzlu tedy při plánování hraje roli; uzly výše mají přednost.

Klasifikace

basic: Klasifikuje pouze pomocí *extended matches*, což jsou jednoduché klasifikátory s logickými spojkami schopné kromě porovnávání obsahu několika způsobů též používat metadata poskytovaná jádrem. Původně měly sloužit k nahrazení jednodušších klasifikátorů a jako doplněk složitých.

bpf: Berkeley Packet Filter jádro na některých architekturách umí přeložit JIT do nativního kódu a výpočetní omezení jazyka zaručuje bezpečnost takového programu. Čtení ze záporných adres obsahuje užitečná metadata, ale filtr zatím bohužel není plnou náhradou za všechny ostatní.

flow: Vrací třídu jako výsledek `baseclass + x % divisor`, kde `x` je buď hash zadaných klíčů nebo mapování aritmetického výrazu nad některým.

Active Queue Management

IEEE 802.3x Flow Control: Zahlícená strana pošle *pause frame* s dobou, po kterou nechce být rušena. Fronta u úzkého hrdla zůstane malá, ale na tranzitním portu se zdrží i interaktivní provoz. Globální synchronizace.

RED: Je-li EWMA délky fronty větší než $\min_{th}$ paketů, s pravděpodobností p_a zahazuje algoritmus provoz; p_a se časem zvyšuje. Váha průměru se nastavuje pomocí odhadu burstu paketů *zadané průměrné velikosti*. Frontě s příliš velkým průměrem se zahazuje vše. Nic neříkající problémová magie.

SFB: Délka fronty nehraje roli, stavy jsou *prázdná* a *plná*. Pravděpodobnost zahození paketů se zvyšuje při zahození a snižuje v klidu. Varianta SFB umí stochasticky zohlednit datové toky Bloomovým filtrem.

CoDel, vysl. [kodl]: Maximální tolerovaná doba zpoždění vzniklá na daném stroji, target, je standardně 5 ms. Pokud má po interval (100 ms) všechen provoz zpoždění větší než target, algoritmus stále více zahazuje. Pomalému připojení algoritmus target posune podle MTU. Je třeba měřit dostatečně přesně čas všem zpracovaným pakety.

PIE: Odhaduje zpoždění po blocích a uvažuje i jeho tendenci růst. Krátkodobé bursty nemají zásadní vliv, neboť pravděpodobnost zahazování se mění po malých krocích; přesto je povolen `burst_time` (100 ms) upravovaný jako deficit u DRR. Měření času je tedy třeba méně často.

rewall pf. Linux kromě cílů systému Netfilter (např. CONNMARK, MARK, ém *filtrů*. Vyhoví-li, mohou kromě přiřazení čísla třídy navíc vykonávat akce.

fw: Mapuje značku systému Netfilter na konkrétní třídu/qdisc.

route: Klasifikace na základě rozhraní či realmu zdrojové/cílové cesty.

tcindex: Původně navržen jako doplněk disciplíny **dsmark** umí použít dříve uložená data do proměnné `skb->tcindex`, například hodnotu ToS či DSCP. Nepodporuje žádné akce kromě **police**, současná verze jádra spadne na validaci akcí. Plně nahraditelný např. filtrem **basic** s akcí **skbedit**.

u32: Klíči jsou 32bitové hodnoty z klasifikovaného paketu. Kombinací klíčů lze vytvořit víceúrovňovou hashovací tabulku, ve které filtr najde požadované číslo třídy. Možnost nepřímého adresování.