Monitorování vysokorychlostních počítačových sítí

Úkolem monitorování počítačových sítí je poskytnout provozovateli sítě a náročným uživatelům se specifickými požadavky informace o operačním stavu sítě, o výkonnostních charakteristikách a o možných bezpečnostních problémech. V tomto článku se zaměříme na současné trendy v monitorování vysokorychlostních sítí zejména s ohledem na sledování výkonnostních charakteristik pro náročné aplikace.

Aktivní a pasivní monitorování

Většinu monitorovacích metod lze rozdělit na aktivní a pasivní. Při aktivním monitorování posíláme do sítě testovací pakety, které opět přijímáme v jiném místě sítě. Tímto způsobem můžeme měřit například zpoždění při průchodu sítí, ztrátovost nebo dosažitelnou propustnost. Nevýhodou aktivního monitorování je přidaná zátěž do sítě (zejména při měření propustnosti „hrubou silou“ intenzivním datovým tokem), možné ovlivnění provozu uživatelů a to, že měříme charakteristiky našich testovacích paketů, nikoliv charakteristiky provozu uživatelů, které mohou být velmi odlišné. Je například obtížné měřit aktivně ztrátovost paketů v síti, protože ta velmi závisí na objemu a dynamice provozu, jež jsou u skutečného provozu uživatelů velmi odlišné od testovacích paketů, které si můžeme dovolit do sítě posílat.

Při pasivním monitorování neposíláme do sítě testovací pakety, ale vyhodnocujeme časové a objemové charakteristiky uživatelského provozu. Pasivní monitorování neovlivňuje uživatelský provoz a může sledovat charakteristiky, které jsou aktivním monitorováním nezjistitelné. Například jaký je objem a dynamika volné kapacity v síti, které aplikace uživatelů mají největší nároky na kapacitu sítě nebo zda v síti dochází k bezpečnostním útokům. Aktivní monitorování si lze tedy představit jako testovací sondu poslanou jednorázově nebo opakovaně do sítě, zatímco pasivní monitorování je zpravidla trvale běžící pozorovatel dění na síti.

Kromě čistě aktivního nebo pasivního monitorování jsou i metody využívající kombinace obou přístupů (vhodné například pro měření ztrátovosti), metody zpracovávající data získaná z komponentů síťové infrastruktury (např. pomocí SNMP nebo protokolu Netflow) a měření sledující stav koncové stanice (např. pomocí rozhraní PAPI). V tomo článku se soustředíme na možnosti pasivního monitorování, které se pro řadu aplikací jeví jako velmi atraktivní.

Hardwarová akcelerace

Problémem pasivního monitorování je potřeba zpracování velkého objemu dat v reálném čase. Páteřní linky současných sítí mají standardně kapacitu 10 Gb/s. Monitorování tak velkého objemu dat je potřeba rozdělit mezi hardware a software. Specializované hardwarové monitorovací adaptéry provádějí operace na nižších vrstvách komunikace v síti, jako je sledování časových a objemových charakteristik paketů a jejich klasifikace podle protokolů nebo jiných údajů. Potom následuje zpracování již menšího objemu dat na vyšších úrovních komunikace. Tím může být výpočet dlouhodobých statistik nebo rozpoznávání aplikací nebo možných bezpečnostních útoků podle obsahu vybraných filtrovaných paketů.

Potřebné monitorovací adaptéry lze dnes získat od několika výrobců. Několik typů programovatelných monitorovacích adaptérů bylo také vyvinuto v projektu Liberouter sdružení CESNET a v mezinárodním projektu SCAMPI. Adaptéry jsou standardně osazeny programovatelným hradlovým polem (FPGA), ve kterém jsou implementovány monitorovací funkce adaptéru. Adaptéry se liší zejména v typu síťového rozhraní (ethernet od 10 Mb/s do 10 Gb/s, ATM, PoS) a v monitorovacích funkcích implementovaných v hardware. Většina adaptérů umí rozdělovat pakety do tříd podle obsahu jejich hlaviček, přidělovat paketům přesné časové značky z vnějšího zdroje času a počítat statistiky pro jednotlivé třídy. Základní srovnání dostupných adaptérů je v *tabulce 1*. Obecně lze říci, že karty od firem Endace a Force10 kladou důraz na stoprocentní propustnost na dané linkové technologii při všech délkách paketů včetně hardwarové klasifikace paketů. Karty Napatech a COMBO naproti tomu kladou důraz na větší rozsah monitorovacích funkcí implementovaných přímo na kartě s možností jejich programování.

Tabulka 1 Srovnání monitorovacích adaptérů

	Endace (karty DAG)	Force10 (P-Series)	Napatech	COMBO
rozhraní	2x 1 Gb, 1x 10 Gb, 1x OC-48 a další	2x 1 Gb, 2x 10 Gb	4x 1 Gb, 8x 1 Gb, 1x 10 Gb	4x 1 Gb (počet využitých portů závisí na typu firmware)
transceivery	výměnné SFP a pevné TX pro 1 Gb, pevné 10GBaseLX pro 10 Gb	výměnné SFP pro 1 Gb, výměnné XPAK pro 10 Gb	výměnné SFP pro 1 Gb, pevné 10GBaseLX pro 10 Gb	výměnné SFP a pevné TX pro 1 Gb
sběrnice	PCI-X 64-bit/133 MHz	dodáváno jako celé zařízení pro montáž do racku	PCI-X 64-bit/133 MHz	PCI-X 64-bit/64 MHz
funkce v hardware	filtrace a klasifikace paketů, podrobná u karet 1 Gb s koprocesorem, jednodušší u karet 10 Gb	filtrace a klasifikace paketů, prohledávání payloadu	k dispozici jsou dva druhy karet: "protocol and traffic analysis adapter" a "programmable adapter", přesný popis monitorovacích funkcí není k dispozici	filtrace a klasifikace paketů, samplování, statistiky a generování Netflow záznamů
informace	www.endace.com	www.force10networks.com	www.napatech.com	www.liberouter.org

Monitorovací adaptér lze připojit k monitorované lince buď pomocí optického rozbočovače (splitteru), nebo pomocí portu na paketovém přepínači nebo směrovači, který je nastaven pro kopírování všech paketů (port mirroring) z monitorované linky. Optický rozbočovač je levnější a zaručeně zachová původní časové charakteristiky provozu. Vyžaduje ale rozpojení monitorované linky, vkládá do ní další útlum a musíme použít monitorovací adaptér s rozhraním odpovídajícím fyzické vrstvě dané linky. Monitorovací port

umožňuje použít jiný typ rozhraní monitorovacího adaptéru (například Gigabit Ethernet pro méně zatíženou linku PoS 2,5 Gb/s), ale směrovače mají obvykle omezení na počet a typ portů, pro které lze kopírování paketů nastavit.

Integrace infrastruktury – architektura Lobster

V síti obvykle potřebujeme nasadit několik různých monitorovacích aplikací pracujících s různými typy monitorovacích adaptérů zahrnujícími různý stupeň hardwarové podpory monitorování. Aby monitorovací infrastruktura pracovala v tomto heterogenním prostředí a byla snadno rozšiřitelná, bylo v rámci projektu SCAMPI [1] vytvořeno prostředí MAPI (Monitoring Application Programming Interface) pro snadnou tvorbu přenositelných monitorovacích aplikací. V následném projektu Lobster [2] bylo toto prostředí rozšířeno o podporu distribuovaného monitorování v DiMAPI (Distributed MAPI). Architektura Lobster je znázorněna na *obr. 1*.

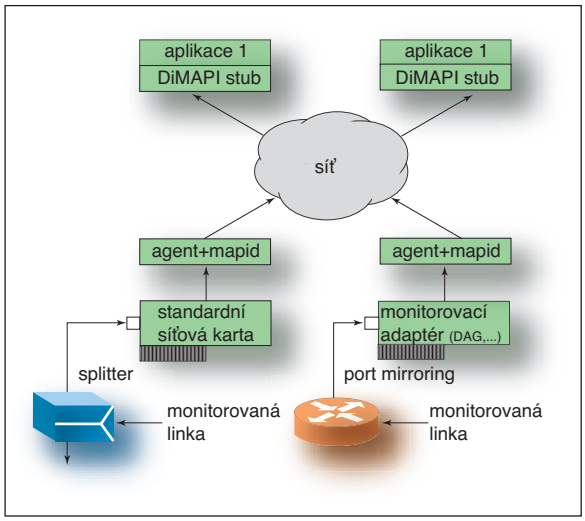

Obr. 1 Architektura Lobster

Každá aplikace je přeložena s knihovnou DiMAPI-stub. Více aplikací může běžet současně na stejném nebo na různých počítačích a mohou při tom sdílet monitorovací adaptéry, které mohou být instalovány na vzdálených monitorovacích stanicích v různých uzlech sítě. Knihovna DiMAPI-stub předává přes síť v rámci spojení TCP požadavky na monitorovací funkce do vlastní implementace DiMAPI v démonu mapid. Síťovou komunikaci zprostředkovává démon agent. Je kladen důraz na to, aby ze vzdálených uzlů s monitorovacími adaptéry byly přenášeny již pouze výsledky monitorovacích funkcí, nikoliv vlastní pakety. Prostředí DiMAPI je k dispozici na Internetu [3] a je možné jej začít používat s běžnými síťovými kartami, speciální monitorovací adaptéry lze nasadit později.

Monitorovací funkce

Aplikace vždy nejprve otevře jeden nebo více toků dat (flow). Každý tok zpočátku představuje všechny pakety přicházející do zadané množiny monitorovacích adaptérů (scope). Potom aplikace nasadí na každý tok posloupnost monitorovacích funkcí. Tyto funkce mohou provádět například klasifikaci paketů do tříd, samplování, vyhledávání řetězců v paketech, anonymizaci údajů v hlavičkách, výpočet objemových a časových statistik, atd. DiMAPI automaticky využije podporu monitorovacích funkcí zabudovanou v jednotlivých použitých hardwarových monitorovacích adaptérech. Pokud potřebné funkce nejsou v daných adaptérech k dispozici nebo je nelze použít vzhledem k pořadí nebo počtu monitorovacích funkcí nasazených na toky dat, potom DiMAPI implementuje příslušné funkce softwarově. Pro aplikaci je tento proces zcela transparentní. Uživatel může definovat svoje vlastní monitorovací funkce a rovněž může přidat podporu pro nový typ monitorovacího adaptéru s určitou zabudovanou hardwarovou podporou. Fragment kódu v *tabulce 2* vytvoří tok dat ze dvou vzdálených monitorovacích adaptérů (běžné síťové karty a karty DAG) a pomocí dvou monitorovacích funkcí sleduje počet paketů přicházejících do zadané subsítě.

Tabulka 2 Vytvoření toku dat ze dvou vzdálených monitorovacích adaptérů

```
fd=mapi_create_flow("pc1:eth1, pc2:/dev/dag0");
fid0=mapi_apply_function(fd, "BPF_FILTER", "dst net 10.0.2.0/24");
fid1=mapi_apply_function(fd,"PKT_COUNTER");
```

Inspekce paketů

Jedním ze žádaných úkolů monitorování je detekce aplikací, které používají dynamicky volené porty (nikoliv pevně přidělená čísla portů). Tento úkol vyžaduje použít kombinaci hlavičkové filtrace s hledáním řetězců v paketech. Za tímto účelem obsahuje prostředí DiMAPI samostatnou knihovnu tracklib pro detekci aplikačních protokolů. K dispozici je detekce známých aplikací pro sdílení souborů jako Gnutella, BitTorent, atd. DiMAPI se opět snaží využít hardwarové podpory v monitorovacích adaptérech, je-li to možné. Uživatel může přidat svoje vlastní funkce do knihovny tracklib pro detekci dalších aplikací. Fragment kódu, který sleduje objem dat šířených aplikací Gnutella ze zadané subsítě, je uveden v *tabulce 3*.

Tabulka 3 Fragment kódu pro hlídání objemu dat šířených aplikací Gnutella

```
fd=mapi_create_flow("pc3:/dev/dag0");
fid0=mapi_apply_function(fd, "BPF_FILTER", "src net 10.0.3.0/24");
fid1=mapi_apply_function(fd, "TRACK_GNUTELLA");
fid2=mapi_apply_function(fd,"BYTE_COUNTER");
```

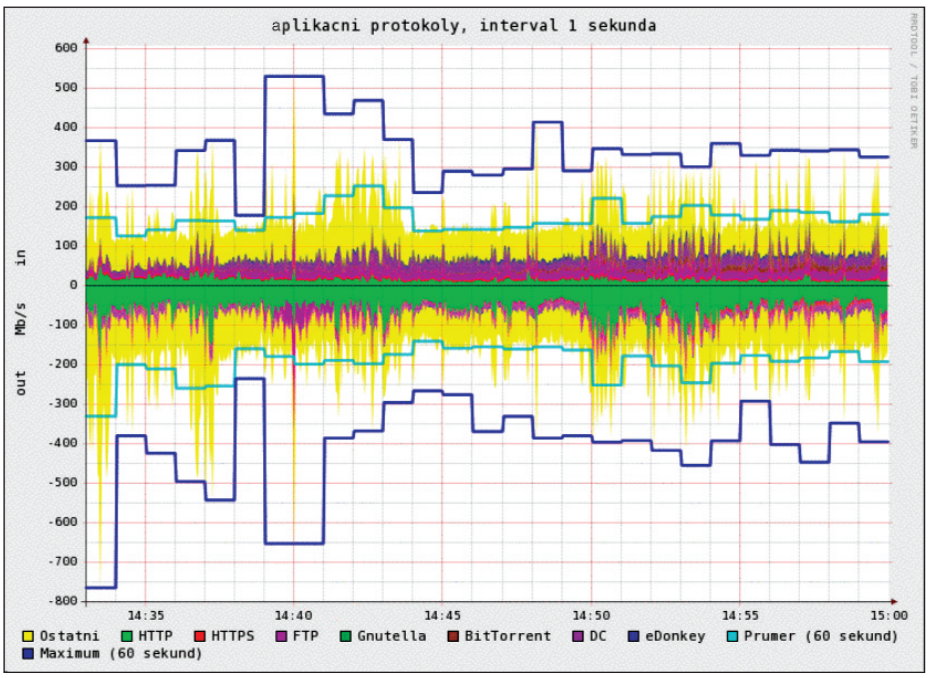

Obr. 2 Vzdálené monitorování objemu dat jednotlivých protokolů

Sledování zátěže linky

Jedním z nejdůležitějších výkonnostních parametrů linky, resp. trasy v síti je její aktuální zátěž nebo naopak volná kapacita.

Tuto informaci potřebujeme při hledání příčin nízké propustnosti, pro plánování infrastruktury sítě a případně pro tarifikaci uživatelů.

Aktivní zátěžové testy například programem *iperf* měří dosažitelnou propustnost. To je užitečná charakteristika, je však třeba si uvědomit, že měřením dochází k ovlivnění provozu uživatelů, který je dnes převážně přenášen protokolem TCP, který je tzv. elastický, tj. jednotlivé toky spolu soupeří o instalovanou kapacitu trasy. Je to tedy metoda intruzivní a měří odlišnou charakteristiku od volné kapacity sítě, která je doplňkem využité kapacity trasy do instalované kapacity.

Aktivní nezátěžové testy například programy *pathrate* nebo *pathload* se snaží odhadnout instalovanou nebo volnou kapacitu trasy pomocí malého počtu paketů odeslaných v přesných časových rozestupech, kde změna těchto rozestupů po průchodu trasou je analyzována. Existuje řada programů tohoto typu, většinou však poskytují nepřesné výsledky ve vysokorychlostních sítích s bohatou dynamikou uživatelského provozu.

Často používanou metodou sledování využité kapacity linky je periodické čtení čítačů odeslaných a přijatých bajtů na jednotlivých rozhraních směrovačů protokolem SNMP. Tato metoda je spolehlivá, umožňuje však sledovat jen celkový objem provozu bez rozdělení na protokoly a aplikace a neumožňuje detekci krátkodobých špiček. Směrovače totiž standardně aktualizují svoje čítače s periodou několika sekund. Nejkratší rozumný interval, přes který můžeme počítat průměrnou zátěž linky, je tak v řádu desítek sekund.

Pasivní monitorování umožňuje sledovat, jak je kapacita linky využívána jednotlivými protokoly a aplikacemi, a to i ve velmi krátkých intervalech. Příklad grafického znázornění využití kapacity linky různými aplikacemi s periodou jedna sekunda a celkovým průměrným a maximálním zatížením s periodou 60 sekund je na *obr. 2*.

Další aplikace, které lze realizovat pasivním monitorováním v prostředí DiMAPI, zahrnují například měření ztrátovosti paketů, detekci šíření virů, detekci různých druhů síťových útoků a anomálií v provozu.

Integrace měření – architektura perfSONAR

Při řešení výkonnostních problémů je často potřeba provést měření řady různých charakteristik ve více sítích, přes které probíhá komunikace, a provést korelaci těchto měření. Evropské národní sítě pro výzkum a vzdělávání (NREN – National Research and Educational Network) jsou propojeny společnou sítí GÉANT2. V České republice provozuje síť NREN sdružení CESNET. V rámci projektu GN2, který buduje síť GÉANT2, se vytváří systém perfSONAR (performance-focused service-oriented network monitoring architecture) [4] pro integraci různých měření výkonnostních charakteristik. Systém je založen na principu web services, jde tedy o množinu nezávisle běžících služeb komunikujících posíláním zpráv ve formátu XML. Jsou k dispozici následující služby:

- Measurement Point (MP) – provádí měření určité charakteristiky v určitém místě,
- Measurement Archive (MA) – ukládá výsledky měření,
- perfSONAR UI – uživatelské rozhraní pro prezentaci výsledků,
- Lookup Service (LS) – registruje umístění ostatních služeb,
- Authentication Service (AS) - ověřuje identitu uživatelů.

Tabulka 4 Zpráva XML systému perfSONAR

```
<nmwg:metadata id="meta1">
  <netutil:subject id="iusub1">
    <nmwgt:interface>
      <nmwgt:ifAddress type="ipv4">192.168.1.1</nmwgt:ifAddress>
      <nmwgt:ifName>Te1/1</nmwgt:ifName>
      <nmwgt:direction>in</nmwgt:direction>
    </nmwgt:interface>
  </netutil:subject>
  <nmwg:eventType>utilization</nmwg:eventType>
</nmwg:metadata>

<nmwg:metadata id="meta2">
  <select:subject id="iusub2" metadataIdRef="meta1"/>
  <select:parameters id="param1">
    <nmwg:parameter name="startTime">1124250480</nmwg:parameter>
    <nmwg:parameter name="endTime">1124250840</nmwg:parameter>
    <nmwg:parameter name="consolidationFunction">AVERAGE</nmwg:parameter>
    <nmwg:parameter name="resolution">60</nmwg:parameter>
  </select:parameters>
  <nmwg:eventType>select</nmwg:eventType>
</nmwg:metadata>

<nmwg:data id="data1" metadataIdRef="meta2">
  <nmwg:datum value="12345" timeValue="1124250481" timeType="unix" />
  <nmwg:datum value="12349" timeValue="1124250482" timeType="unix" />
  <!-- ... -->
  <nmwg:datum value="32345" timeValue="1124250839" timeType="unix" />
</nmwg:data>
```

Jednoduchou komunikaci části služeb znázorňuje *obr. 3*. Služba MP provádí měření a ukládá výsledky do databáze pomocí služby MA, která se registruje u služby LS. Služba perfSONAR UI zjistí u služby LS umístění služby MA, ze které přečte požadované výsledky a prezentuje je uživateli. Zprávy ve formátu XML posílané mezi službami jsou většinou tvořeny ze dvou částí. První částí jsou tzv. metadata, která popisují, jaká data jsou požadována nebo jaká data jsou naopak posílána. Druhou volitelnou částí jsou vlastní data. Metadata sestávají ze subjektu, který určuje místo monitorování (monitorovací stanice a její rozhraní), a z parametrů, které určují podmínky platné pro data, například časové období monitorování, sledované subsítě, argumenty volaných monitorovacích nástrojů a podobně. Základní struktura zpráv odpovídá doporučení pracovní skupiny NMWG (Network Measurements Working Group) sdružení GGF (Global Grid Forum) [5]. Příklad části XML zprávy zahrnující metadata a data je v *tabulce 4*. Systém perfSONAR je k dispozici na Internetu [4], protože ale projekt GN2 ještě probíhá, implementace není dosud úplná.

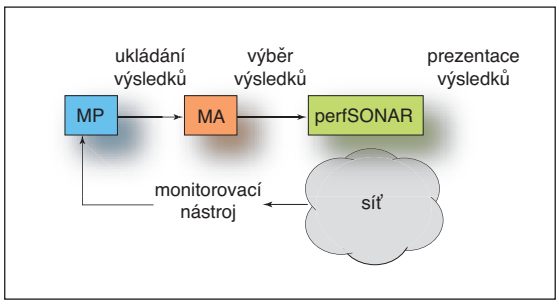

Obr. 3 Komunikace v systému perfSONAR

Dr. Ing. Sven Ubik, CESNET,
ubik@cesnet.cz

LITERATURA

[1] Projekt SCAMPI – http://www.ist-scampi.org
[2] Projekt Lobster – http://www.ist-lobster.org
[3] DiMAPI – http://mapi.uninett.no
[4] perfSONAR – http://www.perfsonar.net
[5] GGF (Global Grid Forum) - http://www.gridforum.org