

# 一種依據連線緩衝區使用率的流量控制演算法

朱延平 黃一泓 曾晞凌

國立中興大學應用數學所

台中市國光路250號

E-mail:ypchu@flower.amath.nchu.edu.tw

## 摘要


本篇文章提出一種新的流量控制演算法,經由在封包中加入兩個位元,做為回饋訊息。發送端送出封包後,交換節點依連線緩衝區使用率來設定位元值,封包到達目的端後,此二位元被複製到回應中,隨回應傳回發送端,發送端根據所得回饋訊息調整流量。模擬實驗結果顯示,本文方法不僅有效控制網路中的交通流量,並且不需借助交換節點的排程演算法便能維持公平性。

## 1. 簡介

在這個科技進步的時代,資訊的流通日趨頻繁,資料的傳遞一日千里,愈來愈多的資訊透過網路相互傳遞,導致Internet的交通流量急遽增加,網路擁塞情形日趨嚴重,所以解決Internet擁塞情形的流量控制演算法(flow control algorithm)便格外重要。

流量控制演算法包含兩部分:回饋策略(feedback strategy)與控制策略(Control strategy)[1、2]。兩者之間的關係可用圖一表示。回饋策略包含了擁塞偵測(congestion detection)及回饋產生(feedback generation)。擁塞偵測依據輸出線使用率(output link utilization)或緩衝區使用率(buffer utilization)來決定網路是否發生擁塞;回饋產生根據偵測結果來設定回饋訊息(feedback information)。控制策略則包括決策函數(decision function)與流量調整(load adaption)。發送端收到回饋訊息後,決策函數參考回饋訊息決定增加或減少流量,流量調整再決定增減量。簡言之,網路透過回饋策略將交通狀況回饋給發送端,發送端再參考回饋訊息作為調整流量的依據。發送端可以速率(rate-based)(例如:秒/封包)或視窗大小(window-based)(即網路中所允許的最多封包數)的方式送出封包。

當網路的交通流量超過所能承擔的負荷量時,便會造成擁塞。依據調整時機的不同,流量控制演算法分為被動的(reactive)與主動的(preventive)兩類[1、3]。被動式的流量控制演算法是等到網路已經發生擁塞,造成封包流失,這時才減少交通流量,使網路脫離擁塞狀態,例如TCP Tahoe[4]與CUTE[5]等便屬於



圖一 流量控制演算法組成要件

此種流量控制演算法;主動式的流量控制演算法是透過控制交通流量,避免網路造成擁塞,例如DECbit[6、7]便是一種主動的流量控制演算法。

在TCP Tahoe演算法中,回饋策略將網路分為擁塞狀態與非擁塞狀態。它並不使用明確的回饋訊息,而是以發送端發現封包流失,導致計時器(timer)中斷作為間接的回饋訊息,表示網路處於擁塞狀態,此時將視窗大小設為1;否則便認為網路並未發生擁塞。每當收到回應(acknowledgement)時便增加視窗大小。DECbit演算法在封包中加入一個擁塞指示位元(congestion indication bit)作為回饋訊息。此位元初值為0,發送端送出封包後,若網路任何一個交換節點的平均佇列長度(queue length)大於或等於1,便將擁塞指示位元設為1,封包到達目的端後,此位元被複製到回應中,隨回應傳回發送端,發送端收集兩個視窗大小的封包後,若超過一半的擁塞指示位元值為1,便降低視窗;否則便增加視窗長度。

近年來有不少探討關於TCP Tahoe演算法的論文發表[8、9、10]。我們發現,由於TCP Tahoe演算法的調整策略,導致計時器週期性的發生中斷,使視窗大小、佇列長度週期性的振盪,造成整體產能(throughput)下降及封包間的來回旅行時間(Round Trip Time, RTT)過長。因此我們提出新的流量控制演算法,讓交換節點緩衝區維持一定的使用率,達到充分利用網路資源,獲致最大的整體產能,且維持合理的來回旅程時間。

在本篇文章第二節裡,將介紹我們所提出的演算法。第三節中我們透過模擬實驗將本文方法與TCP Tahoe作一比較。最後我們提出結論。

## 2. 演算法模型

我們希望藉由使交換節點始終處於忙碌狀態，達到充分利用網路資源，獲致最大的整體產能(maximal global throughput)，因此必須讓交換節點緩衝區保持封包存在的狀態；同時控制交換節點緩衝區的使用率，令緩衝區內封包數不致過多，使得封包的來回旅行時間太長，甚至發生封包因交換節點緩衝區溢滿(overflow)而流失，造成產能的下降，所以必須將緩衝區的使用率控制在一定的範圍內，如此便能維持良好的網路傳輸效能及合理的來回旅行時間，並避免網路因擁塞而造成封包流失。

我們提出的演算法主要分成兩部分：交換節點的回饋策略及發送端的控制策略。我們在封包中加入兩個擁塞位元，藉以作為網路交通狀況的參考依據。我們希望網路中的每位使用者都能公平的使用頻寬，所以將交換節點緩衝區虛擬地平均分給每條連線(實際上緩衝區是所有連線共享的)。在發送端與目的端建立連線(connection)後，每當封包流經交換節點時，交換節點便依據連線緩衝區(per-connection buffer)的使用率來設定擁塞位元。在封包到達目的端後，目的端便將擁塞位元複製到回應封包送回發送端，發送端便以擁塞位元來作為調整視窗大小的依據(如圖二)。所以當交通流量過多時，網路會通知超用頻寬的使用者減少流量，而不影響其它使用者，達到選擇性回饋(selective feedback)的效果。接著先介紹交換節點的回饋策略，再介紹發送端的控制策略。

依據連線緩衝區使用率的高低，將其由高至低區分成4個階段來設定擁塞位元值。由於n個位元最多可表示 $2^n$ 種狀態，因此利用兩個位元來表示交換節點緩衝區的使用率。我們以C語言演算法來說明回饋策略及控制策略：

```
發送端送出封包時，封包的擁塞位元初始化設定
pkt->venbiti = 0;
每當封包流經交換節點時：
if(bytes_in_qi ≥ aver_conv_sizei * S1)
    pkt->venbiti = 3;
else
    if(bytes_in_qi ≥ aver_conv_sizei * S2)
```


```
    pkt->venbiti = 2;
else
    if(bytes_in_qi ≥ aver_conv_sizei * S1)
        pkt->vnebiti = 1;
```

其中， $\text{pkt} \rightarrow \text{vnebit}_i$  連線  $i$  封包的擁塞位元， $\text{bytes\_in\_q}_i$  為連線  $i$  緩衝區內所存位元組數， $\text{aver\_conv\_size}_i$  為連線  $i$  所配置緩衝區大小， $S_1$ 、 $S_2$  及  $S_3$  為連線緩衝區使用率。


當目的端將擁塞位元拷貝至回應封包送回發送端後，發送端依據擁塞位元值作視窗大小調整(如圖三)：

```
if(pkt->venbit==0)
    /* window = window + 1 */
    {window+=1;
    counter1=0;
    counter2=0;}
else
    if(pkt->venbit==1)
    /* window = window + 1/window */
    if(++counter1 ≥ window)
    {window+=1;
    counter1=0;
    counter2=0;}
    else
    if(pkt->venbit==2)
    /* window size unchanged: operating region */
    {window=window;
    counter1=0;
    counter2=0;}
    else
    if(pkt->venbit==3)
    /* window = window - 1/window */
    if(++counter2 ≥ window)
    if(window>1)
    {window-=1;
    counter1=0;
    counter2=0;}
```

其中， $\text{window}$  為視窗大小， $\text{counter1}$ 、 $\text{counter2}$  分別為記錄視窗增加及減少的參數，當  $\text{counter1}$  或



圖二 交換節點的回饋訊息



counter2等於視窗大小時，分別將視窗大小加1或減1。此外，每次調整視窗時，便將counter1及counter2重設為0，避免過度累積，產生不適當的調整。

增加的調整策略類似 TCP Tahoe，我們可以看出，當連線緩衝區使用率低時（擁塞位元=0），發送端每收到回應時便將視窗大小加1，讓視窗呈指數增加，連線緩衝區使用率較高時（擁塞位元=1），我們便減緩增加的速度，讓視窗呈線性增加；當連線緩衝區使用率到達某一階段時（擁塞位元=3），我們便減少視窗大小。因網路傳輸延遲的緣故，擁塞位元所傳回的網路訊息並非目前的狀況，所以調整視窗長度的策略除了增加與減少之外，還包含一部分不作任何調整（擁塞位元=2），這部分是作為緩衝地帶，使連線緩衝區內封包維持在合理的範圍內，避免視窗因過度調整而造成擁塞或未充分利用頻寬。如此便能減小視窗振盪幅度，甚至維持不變，使網路處於穩定狀態，獲致較佳的產能及來回旅行時間。

### 3. 模擬結果與比較


為了能較為清楚的觀察本文方法與 TCP Tahoe 兩者之間的差異，我們透過模擬實驗將本文所提出的演算法與 TCP Tahoe 演算法作一比較。本文以 U.C. Berkeley 所發展出的 REAL 4.0[11]作為網路模擬實驗的軟體。透過單一連線實驗 (single connection experiment)，我們可以更加瞭解演算法運作的行為；公平性實驗可測試演算法在不同路徑時，是否能達到公平性；而橫截交通實驗 (cross-traffic connection experiment) 則較能模擬真實網路中的交通行為模式，因此在本節中，我們分別設計了這三種網路模擬實驗。實驗中假設只有當交換節點緩衝區溢滿的時候，封包才會流失，而刪除封包時選擇最後一個封包刪除。交換節點緩衝區的排班策略為先到先服務 (FCFS)。當封包的到達速率 (input rate) 大於輸出速率 (output rate) 時，節點便會發生擁塞，我們稱此節

點為瓶頸 (bottleneck)。為了評估演算法的效率，在每個實驗中均有瓶頸存在。此外，對於連線緩衝區使用率  $S_1$ 、 $S_2$  與  $S_3$  的設定分別為  $1/10$ 、 $1/5$  及  $1/3$ ，這是因為當交換節點緩衝區較小時，設定太高容易造成緩衝區溢滿，設定太低則無法充分利用頻寬，且模擬實驗顯示，我們的設定甚為適當。基本上， $S_1$ 、 $S_2$ 、 $S_3$  值的設定與交換節點緩衝區大小及連線個數有關，因此我們認為應由系統管理者決定，在何種情況下的設定會有較好的效果。

圖四為單一連線網路拓模圖形，節點1為發送端，節點2與3為交換節點，節點4為目的端。發送端與交換節點及交換節點與目的端之間傳輸線的頻寬為每秒2M位元，傳輸延遲為10微秒；交換節點間的頻寬為每秒40K位元，傳輸延遲為1秒，為本實驗的瓶頸，每個交換節點緩衝區大小為5000位元組。本實驗發送端將傳送500K位元組，每個資料封包大小均為500位元組，回應封包大小為40位元組，實驗模擬時間為300秒。

圖五是 TCP Tahoe 與本文方法瓶頸佇列 (queue) 的變化狀況。由圖五(a)可看出封包因緩衝區週期性的溢滿而被刪除，佇列呈現週期性振盪。在圖五(b)中，因緩衝區的使用率被控制在一定的範圍內，佇列則呈現較小振盪。圖六則是視窗大小的變化情形。圖六(a)為 TCP Tahoe 的視窗變化，由此圖可知，因封包被刪除，使計時器週期性的發生中斷，視窗降低為1並重新開始運作，導致視窗呈現週期性的振盪。在圖六(b)中，因緩衝區的使用率控制在一定的範圍內，所以視窗大小逐漸趨於一固定值，最後當資料即將傳送完畢時，視窗長度隨著瓶頸佇列長度減少而增加。圖七為本文方法與 TCP Tahoe 的產能比較。我們每隔20秒統計封包傳輸量。由於瓶頸的頻寬為每秒40K位元，因此連線每20秒最多可傳送200個封包。我們可以看出，TCP Tahoe 因計時器週期性的發生中斷，視窗呈現巨幅振盪，傳輸量並不穩定，並且未能充分利用網路資源。本文方法由於緩衝區內始終存有封包，穩定的維持每20秒傳送200個封包的最大傳輸量，因此在120秒時就已經傳輸完成，而 TCP Tahoe 在160秒時才傳完。







第二個模擬實驗測試當連線間的距離不同時，演算法能否達到公平。實驗模型如圖八。圖九為本文方法的視窗變化。最初連線1的視窗持續增加，連線2加入後，連線1因連線緩衝區長度減半，連線緩衝區使用率相對增加，隨後的擁塞位元均被設定為3，視窗長度因而降低，將頻寬分給連線2，此一現象為選擇性回饋的效果。當緩衝區使用率穩定後，兩者視窗均維持不變，因連線2的延遲-頻寬乘積 (delay-bandwidth product) 較大，所以視窗比連線1大。TCP Tahoe 的視窗變化如圖十。在圖中可看出，兩者視窗均巨幅振



盪,且長度差距頗大,連線2因為視窗較大,由於FCFS的結果,使得它的封包比連線1較易被服務,而佔用大部分頻寬,因此300秒前便傳送完畢。圖十一為每20秒統計連線間的產能比較圖。瓶頸的頻寬為每秒20K位元,因此連線每20秒最多可傳送100個封包。從圖十一(a)可知本文方法不但達到最大整體產能,並且維持公平性;圖十一(b)中顯示兩者傳輸量極不公平。








為了模擬真實網路中的交通流量,我們令整體橫截交通的資料量呈現逐漸增加後再逐漸減少,來觀察當連線個數增加及減少時,演算法是否能如單一連線般的運作。圖十二為橫截交通連線網路拓模圖形。此實驗是當主連線(primary connection)1開始傳送資料後,橫截交通連線隨後加入。連線1在0秒時開始傳送,資料量為750K位元組。橫截交通連線2至8則從

5秒開始,每隔5秒陸續加入傳送。每條橫截交通連線所傳送的資料量均為250K位元組。每個交換節點緩









衝區大小為40000位元組，實驗模擬時間為1100秒，其餘實驗環境設定如單一連線實驗。

圖十三為連線1的瓶頸佇列變化情形。TCP Tahoe連線1的佇列變化如圖十三(a)，由於剛開始時



只有少數橫截交通流量加入，瓶頸緩衝區幾乎均被連線1所佔用，因此連線1的佇列最多高達70個封包，隨後因封包被刪除，視窗降為1及橫截交通陸續加入，佇列長度減小，並呈現週期性的振盪，直到830秒後，橫截交通流量逐漸減少，佇列長度才逐漸增加。圖十三(b)則是本文方法連線1的瓶頸佇列變化。因擁塞位元的設定是依據連線緩衝區的使用率，當連線個數增加時，每條連線的緩衝區相對變小，減少視窗長度的機率隨之提高。一開始受到橫截交通陸續加入的影響，發送端減少視窗長度，佔用瓶頸緩衝區的封包數逐漸減少，等到連線個數不再增加，佇列長度便被控制在一定的範圍內，當橫截交通離開後，佇列長度才又增加。連線1的視窗變化如圖十四。圖十四(a)是TCP Tahoe連線1視窗變化情形，由圖可看出，連線1的視窗長度最初高達147，隨後呈週期性劇烈振盪，待橫截交通離開後，此時因緩慢啟動門檻值(slow-start threshold)很小，視窗以線性的方式遞增。本文連線

1的視窗變化如圖十四(b)，最初因為只有少數橫截交通連線，視窗便快速增加，而後其視窗長度始終維持為10，期間雖仍有部分封包的擁塞位元被設定為3，但由於演算法中的counter2尚未累積到足以降低視窗時便被歸零(代表回饋訊息不足以反應網路的擁塞)，因而視窗大小保持不變。連線6的瓶頸佇列變化情形如圖十五所示。圖十五(a)是TCP Tahoe的瓶頸佇列變化，當連線6加入時，網路交通呈現極度擁塞，交換節點緩衝區已被填滿，封包因此被刪除，而後佇列長度逐漸增加，並呈週期性振盪。相對的，本文方法有效控制連線緩衝區使用率，所以交換節點緩衝區仍有空間容納封包。圖十五(b)顯示本文方法瓶頸佇列很快的趨於穩定。圖十六是連線6視窗調整的變化情形。在圖十六(a)中，我們可明顯的看出，連線6一加入後便因封包流失，導致計時器中斷，緩慢啟動門檻值被設定為1，所以視窗以線性的方式遞增，並呈週期性劇烈振盪。圖十六(b)為本文方法視窗調整的變



化情形。由於瓶頸佇列長度便被控制在一定的範圍內，因此視窗長度逐漸趨於穩定，與連線1有相同的大小，達到公平使用網路資源。圖十七為每隔100秒統計的整體產能比較圖。瓶頸的頻寬為每秒20K位元，因此連線每100秒最多可傳送500個封包。由圖中我們可以看出，本文方法的產能明顯的優於TCP Tahoe。

#### 4. 結論

在本文中，我們提出了一個新的流量控制演算法，經由在封包中加入兩個擁塞位元，將網路的交通狀況區分成四種狀態。交換節點根據連線緩衝區使用率的高低來設定擁塞位元值，當此一訊息隨回應傳回發送端後，發送端便依據回饋訊息調整視窗長度。

經由模擬實驗結果顯示，本文方法藉由控制連線緩衝區使用率，使其維持在一定的範圍內，如此不僅

在傳輸過程中較TCP Tahoe有較高的產能、能夠充分利用網路資源、傳輸量較穩定外，同時不需借助交換節點的排程(queueing scheduling)演算法亦能達到公平性(fairness)，公平的分配網路上的資源。

#### 參考文獻：

- [1] O. Rose, "The Q-bit Scheme," *ACM SIGCOMM* Vol. 22, No. 2, April, 1992.
- [2] Raj Jain and K. K. Ramakrishnan, "Congestion Avoidance in Computer Networks with a Connectionless Network Layer: Concepts, Goals and Methodology," *Proc. Computer Networking Symposium, Washington, DC, 1988*;
- [3] Yannis A. Korilis and aurel A. Lazar, "Why is Flow Control Hard: Optimality, Fairness, Partial and Delayed Information," *IEEE INFOCOM'93*.
- [4] V. Jacobson, "Congestion Avoidance and Control," *Proc. of ACM SIGCOMM'88, Stanford, CA*, pp. 314-329, Aug. 1988.
- [5] R. Jain, "A Timeout-Based Congestion Control Scheme for Window Flow-Controlled Networks," *IEEE Journal on Selected Areas of Communication*, Vol. SAC-4, No. 7, pp. 1162-1167, Oct. 1986.
- [6] D. M. Chiu and Raj Jain, "Analysis of the Increase and Decrease Algorithms for Congestion Avoidance in Computer Networks," *Comp. Networks and ISDN Syst.*, Vol. 17, pp. 1-14, 1989.
- [7] K. K. Ramakrishnan and R. Jain, "A Binary Feedback Scheme for Congestion Avoidance in Computer Networks," *ACM TOCS* Vol. 8, No. 2, pp. 158-181. May, 1990.
- [8] S. Shenker, L. Zhang and D. Clark, "Some Observations on the Dynamics of a Congestion Control Algorithm," *ACM Computer Communication Review*, Vol. 20, No. 5, Oct. 1990.
- [9] Z. Wang and J. Crowcroft, "Eliminating Periodic Packet Losses in the 4.3-Tahoe BSD TCP Congestion Control Algorithm," *ACM SIGCOMM*, April, 1992.
- [10] A. Mankin and K. Thompson, "Limiting factors in the performance of the slow-start TCP algorithms," *Proc. of USENIX Win. Conference'89*, pp. 219-228, Jan. 1989.
- [11] S. Keshav, "REAL: A Network Simulator," Computer Science Dept. TR 88/472. Uni. of California, Berkeley, Dec. 1988.

