

分散型計算機システムの性能予測ツールの開発

本山博司, 大町一彦(日立システム開発研究所)

1. 序論

分散型計算機システムがいよいよ普及しようとしている。分散システムには大別して地理的分散システムと機能分散システムとがあるが、いずれにしても、分散システム設計者は複数のノードとそれを結ぶリンクをどのように構成するか、その構成によって所期の性能が出るか否かを決定し、判定しなければならない。しかしその判定は未だシステムが稼動しないうちに行なう必要がある。すなわちシステム設計者はどうしても性能予測をしなければならない。この事自体はシングルノードの計算機システムの設計者にとっても同様ではある。しかし分散システムはシングルノードのシステムに比べてノードの数は複数であり、しかもメッセージがノード間を渡り歩くなど従来に無い要素を加わって格段に複雑になってしまった。そこで性能評価ツールが必要になるのだが、分散システム用のしかるべき設計初期段階での性能評価ツールが、シングルノードの詳細を極めたシミュレータと同じ発想で造られてよいだろか。設計初期段階では、後期段階と異なり、回線バッファ長や、いまかな通信制御方式上の相違、CPU走行ステップ数の微細な変化等は不明である。設計初期段階ではノードとリンクの接続のしかたや、ノード内の各資源の基本性能が、これどよみのか否か知りにくく、もしよくないぞあれば、別のシステム構成はどうか等々、茫洋とした設計選択肢の中からどうぞうだけ早く、しかも誤またず正しい軸を見出したいのである。したがってこの設計段階で用いるべきツールは、少々精度は落ちること、少數の基本的設計データのみ入力すれば、素早く結果をユーザーに示せるよなどうなければならぬ。

筆者等は最近、以上のような段階における性能設計があり方を吟味し、それに適しいツールを開発し設計者の支援に供していきたい。ここに報告したい。なお本報告は、第22回大会の報告[ク]を發展させたものである。

この報告では、まず第2章で、分散システム性能評価における問題点を挙げ、その解決策について既存の研究成果を検討する。第3章で、既存成果が不十分な点に関する解決策を示し、その効果に言及する。第4章では、仮想的かつ現実的な分散システムに關し実際の評価例を示す。第5章では結論と今後の課題を記して全文を終る。

2. 分散型計算機システム評価の問題点と既存の研究成果

2.1 評価時間の長大化

性能予測の手法にはシミュレーションと解析手法の二種あるが、モデリング能力が高い点から、従来多くシミュレーションが行なわれてきた。シングルノードの計算機システムをシミュレートする際、応答時間とか他の評価項目の値が十分安定するまでには、通常数10分のCPU時間を要する。従ってこれと同程度の時間がかかる分散システムをモデル化し、シミュレーションを実行すると、少なくとも、このノード数倍は時間かかる。ちなみには、ノードあたり20分を要するモデルで、10ノードある分散システムを評価するには、少なくとも3時間20分のCPU時間必要である。

この長さは、評価を 1 ケースだけ行なう場合では、禁止的ではない。しかし設計時には、多数のシステム構成代替案を評価したいのが実情であり、この場合は評価時間を十分短かくしておかなければならぬ。

シミュレーション時間の短縮する方法として、モデルの分解(decomposition)がある。分解の考え方には COURTOIS [1] により提出された。[1] では分解を解析的手法について適用しているが、基本的にはシミュレーションモデルを分解してよい。分解し、上下二段階としたモデルをさらに高速化するため、一方を解析モデルで評価する方式、いわゆるハイブリッド方式がある。SCHWETMAN [2] は、単純なハイブリッドモデルについて、その方式の有効性を示し、CHIU and CHOW [3]、木下 [8] は、具体システムについて、ハイブリッド方式で評価し、容量計画(capacity planning)に適用し効果を上げた。しかし分散システム性能評価を行なうには、さらに高速化が必要であり、本報告ではこの点につき新しい工夫を示す。

2.2 分散システム特有のトランザクション動作のモデル化

分散システムでは、あるノードに入ってきたトランザクションを全て同一ノード内で処理するとは限らない。処理の一一部は、他のノードで行なわれ、その結果を用いて、後の処理を行なう。このような動作は地理的分散システム、機能分散システム双方に見られるが、集中システムには無い。この点が自由にモデル化できるしくみを、設計者に提供しなければならない。またノードとリンクの接続法(ネットワークトポロジー)も、簡単に定義をうなぐことはならない。

以上の点を考慮したコンピュータネットワーク専用のシミュレータには、田中、中村 [4], [5] および CHIU and CHOW [3] がある。これらは、性能評価の力点を通信系に置き、各通信割り当て方式個別の動作について十分な精度でモデル化している。この「ネットワーク定義」は十分に表現できるが、ノード内部の処理については大半に簡略化している。本報告では力点をネットワークからノード内処理の方に移し、通信系を上記方式より簡略化し、ノード内処理及び、トランザクション内部でのノード間渡り処理について、より詳細化した。

3. 問題点の解決法とその効果

3.1 評価時間の短縮

(1) 利用率の事前チェック

システム内に 1 個でも利用率が 100% を超えるものが有れば、シミュレーションは安定せず、待ち行列内のトランザクション数は次第に増加する。従って特にこのよくな状態における過度応答を知りたいのが本題であり、シミュレーションを行なう意味は無い。このよくなムダを避けるため、シミュレーションに入る前に、利用率の計算を行なう。利用率は、トランザクションの到着率入と、トランザクション当たりの資源使用量が与えられればネットワークについては、原理的に簡単に求まる。しかしながら、後述するようにトランザクションの内部が複数個の処理に分かれ、その各々につれて資源使用量を指す場合には、利用率の計算は、まず各々の処理毎に行ない、次にそれらの総計を行なうといふ手順を経なければならないので、複雑である。従って利用率の計算をツール内で自


動的に行な)事例は意味がある。

3.2 モデルの階層化、ハイブリッド化、静的インターフェース化

モデルの分解により、上下2段階に階層化する事が有効である事は、SWETMAN[2]で示されていふ事は既に述べた。[2]ではシステム資源を主メモリ、磁気テープ装置等の「長期間資源 (long-term resource)」と、CPU、チャネル等の「短期間資源 (short-term resource)」とに分け、前者をシミュレーションで、後者を解析的に評価してある。その理由は短期間資源は時間当たりの使用回数が多く、これを解析化すればより評価時間短縮効果が高いからである。我々も基本的にはこの方式を取る事例となる。CHIU and CHOW [3]も同じくこの方式を実施している。

しかしながら、[2]、[3]とともに階層間の情報の授受が動的である点が、報告者等の静的インターフェース方式と異なる。以下この点について説明しよう。

(a) 動的インターフェース




上位モデルと下位モデルの動的インターフェースとは、上位モデル中でトランザクションが主メモリの占有/解放毎に下位モデルを動作させ、その後の処理終了時刻を予測し、その予測時刻でタスク終了事象を発生させるよ)上位モデルがシミュレートする方式を言)。すなはち主メモリ占有時間を、トランザクション毎に評価するわけであるから、上位モデルと下位モデルは交互に頻繁に動作する。下位モデルの機能を数式で書けば、次のようになる。

$$\pi = R(N) \quad \dots \dots \quad (1)$$


但し $\pi = (T_1, T_2, \dots, T_i, \dots, T_m)$
 T_i : トランザクションタイプ i の処理終了時刻
 $N = (N_1, N_2, \dots, N_j, \dots, N_m)$
 N_j : トランザクションタイプ j のメモリ内消費度
 R : N より π を評価する機能

(b) 静的インターフェース



静的インターフェースとは①式の $\pi = R(N)$ を、毎回計算するかわりに、左図のよ)に計算結果をテーブルの形で持つておく方式と言)。次って下位モデルは、このテーブルを作成したのを、1回だけ動作すればよく、上位モデルはこのテーブルと引くのみで、タスク終了時刻が予測できる。

静的インターフェースを取る事により、下位モデルの走行回数は、次のようになります。下位モデルとして BUZEN [6] のセントラルサーバモデルを用いた場合、I/O 台数 12 ~ 50、多密度 2 ~ 50 における CPU 处理ステップ数実測値を図 3 に示す。



これはトランザクションタイプが 1 種類のみの場合である。但し、値は I/O 50 台、多密度 12 の時の走行ステップ数を 1 単位として表わした。以下 I/O 50 台、多密度 12 のケースについて考えるとする。いま、シミュレーションを行い、全部で 1 回トランザクションが、主メモリを占有したとすれば、X モリの解放と同様に 1 回だから計 21 回確保／解放される。動的インターフェース方式では、この場合


$2 \times 2 \times 1.0$ 単位

の走行ステップ数が下位モデルで費されるのは、静的インターフェース方式で費されるのは、

I/O 単位

のみであり、通常これは $10^3 \sim 10^5$ であるので、この差は 21 単位としてよい。すなはち静的の方が、動的よりも単位ステップ数だけ走行ステップ数が短かくなる。しかし静的インターフェース方式はテーブルサイズに限界があるため、トランザクションタイプが増え、各タイプ内の多密度が大きくなると、実施できない。

次に上下モデル間のインターフェースは上記と同じように静的ではあるが、下位モデルがセントラルサーバモデルのような解析手法ではなく、GPSS で組んだシミュレーションモデルとした場合を想定し、下位モデルの走行ステップ数を予測してみよう。モデルは上記の場合同様 I/O 50 台、多密度 12 とする。1 トランザクション当たり平均 1 回の I/O 要求を出すとする。CPU は 1 回使用する事になるので計 $(2P+1)$ 回資源を使用する。一般にシミュレーションでは資源の利用率により、資源当たりシミュレーションに要する走行ステップ数は異なる。GPSS による M/M/1 待行列の走行ステップ数を実測すると、図 4 のようになる。



いま、CPU と I/O の利用率がともに 60% であると仮定すると、図 4 より走行ステップ数は 0.02 単位である。また、シミュレーションは m 個のトランザクションにつき 2 行なうとする。結果、下位モデルのシミュレーションに要する走行ステップ数は、

$$(2P+1) \times 0.02 \times m \quad \text{単位ステップ数}$$

となる。

ミニマム上位シミュレーションモデルの評価に要する走行ステップ数を、トランザクション当たり、S単位ステップとして、以上の結果を図5にまとめる。

上位モデル		VS(単位ステップ)	
下位モデル	位相	手法	
		解析	シミュレーション
ミニマム	静	方式I 1.0	方式III $(2P+1) \times 0.02 \times m$
	動	方式II 2N	—

単位：「単位ステップ」すなはち下位モデル
のステップ数を1.0として時の比
V：全完了トランザクション数
S：上位モデルの1トランザクション
当たりの走行ステップ数

図5. 各方式の走行ステップ数比較

ミニマム上位シミュレーション、S≈1.0となると、(3)は $10/12 = 83\%$ となり、両者の差は1/2となる。
したがる、常にIの方がIIより速い。

(b) 方式IIと方式III


上記(1)における比較と同様にして、

$$(III)/(II) = (VS + (2P+1) \times 0.02 \times m) / (VS + 2N) \\ = (S + (2P+1) \times 0.02 \times m/V) / (S+2) \quad \dots \dots (4)$$

ミニマム上位シミュレーション、下位シミュレーションが安定するに要するトランザクション量N、mが、ほとんど同程度(通常 $10^3 \sim 10^4$)とすると、

$$(4) = (S + (2P+1) \times 0.02) / (S+2) \quad \dots \dots (5)$$

となり、トランザクション当たり/0使用回数 P=24.5 を境界にして、Pより小まければ方式IIIの方が走行ステップ数が遅くなる。方式IIIをつかって、下位モデルを、さらに複雑にしていいと、1トランザクション当たりの走行ステップ数が、2単位を超えれば、方式IIよりも方が走行時間が長くなる(?)が、それかわりシミュレータの高いモーデリング能力をひき出す事ができる。




(3), (4)式を、上位シミュレーションモデルの1トランザクション当たりステップ数 Sについてプロットしたものを図6に示す。図6は方式II(従来のハイブリッド方式)を1.0として、他の方式を比較したもので、1.0より上にあれば従来方式より遅く、下にあれば従来方式より速い事を意味する。

3.3 分散特有動作のモデル化支援機能


(1) Service Request = Function + Message (図9)

端末から入力されるオンラインランザクション、あるいはTSSのコマンドあるいはバッチジョブ等、システムに対する処理要求は様々な名で呼ばれる。これらを以後Service Request、SRと総称する。ツール内で「あつか」処理要求は、全てSRであり、他の形式はない。分散システムでは、1個のSR内で、複数個のノードにまたがりて処理するものが必ずある。(そしていわば、分散システムではなく孤立してシステムが単純複数個あるにすぎない) つまりSRの性格をモデル化しやすくなるため、「Function」を作った。FunctionはSRの内部に複数個あってよく、各Functionは、必ずしも1個のノード内で処理される。1個のFunctionのうち一部があるノードで処理され、他の部分が他のノードで処理されるような事はない。しかし、SR内の複数のFunctionが、別ノードで処理されるとよい。Functionは入力されたり、Functionが出力したりする情報をMessageと呼び、Functionは必ずしもMessageを入力し、必ずしも出力する。




(2) Function Class / Region

分散システムを構成する多くのノードは、システムに入ってきた処理要求の全てを処理できるわけではない。個々のノードで処理できる業務内容は決まっている。この事をモデル化しやすくなるため、各ノードを「グループ」に分け、それらのグループ内のノードはどれも、共通のFunctionを処理できるが、それ以外のFunctionは処理できないとした。これが「Functional Class」と呼ぶこと。(図8)




また、ファイルが分散している場合など、その SR が入って来たノード内のファイルを多く参照し、他ノードのファイルは少ししか参照しないといった事がある。例えば、全国に分散したデータベースで、大阪で作った検索のトランザクションは、ほとんど関西圏内のファイル参照で済み、少數が東京のファイルを参照するであろう。このような「ファイル参照の地域性」をモデル化するため "Region" の考え方を導入した。1つの Region は、ノードの集合で、全ノードは必ずどちらかのノードに属するものとする。各 SR 内の Function や、SR が到着したノード内で処理される率(ローカル率)、SR が到着したノード以外だが同一 Region 内のノードで処理される率(Region 率)を指定しておく。シミュレーターは、この率に従って、Function の処理を各ノードに配分していく。ここで、この処理すべきノードは、当然どの Function を処理できる Functional Class に属しているければならぬ。



4. 評価例

以上述べた手法を用いて、仮想的な分散システムについて、性能評価を行なってみよう。システムは図 8 のように、本社、事務管理センター、工場とから成っている。本社ではオーダエントリーのトランザクションを受けつけ、それに応じてマクロ生産計画を立て、工場に生産を指令する。工場は指令はどとずつミクロ生産計画を立て、部品発注をし、生産を開始する。また、製品が完成に到るまで、その状態管理を行うため、工場は独自の製品トラッキングを行なう。

SR は全体で 12 種類あり (SR1 ~ SR12) のうち、「オーダエントリ」と呼ばれる SR5 は、次のように内訳となっている。



さらに、SR5 内の Message, Function の定義である。

<u>Function;</u>
F3 ; マロセイシナカツ, 处理ノードの Functional class = 本社 使用資源 = CPU. 1個, 300 Kstep, 1点分布 DISK1, 10個, 10回アクセス, 1点分布. XZU 256 KB
F5 ; ジムカンリセンターレポート, 处理ノードの Functional Class = 事務管理セント 使用資源 = CPU 1個, 500 K step, 指数分布 DISK2, 15個, 30回アクセス, 1点分布. XZU 512 KB
<u>Message;</u>
M5 ; メッセージ長 200 バイト, 1点分布
M3 ; メッセージ長 4K バイト, 1点分布.


図11 SR 5 内 a Function, Message 定義

次に、各ノード内にある資源の定義及 Functional class の定義を行なう。

1-F1 ; ホンヤ, Functional Class = 本社, 1-F Region=1, CPU 6MIPS, メモリ処理 CPU 負荷 = 3 Kstep. DISK1, 30台, 30 msec / access DISK2, 5台 50 msec / access

図12 1-F1 (本社) の定義

最後にネットワーク定義を行なう)



以上のよきを入力データにすることで、以下のよきな結果を得た。(全CPU時間 8分10秒)

■ 2. LINK UTILIZATION (%)

(ORIGIN NODE)

IDS.NI	1	2	3	4	5	6	7
1	0.0	4.179	2.480	1.380	1.412	1.708	1.566
2	13.901	0.0	4.118	3.980	3.840	3.261	3.095
3	23.170	34.804	0.0	0.0	0.0	0.0	0.0
4	26.169	28.775	0.0	0.0	0.0	0.0	0.0
5	16.461	14.168	0.0	0.0	0.0	0.0	0.0
6	16.456	28.733	0.0	0.0	0.0	0.0	0.0
7	17.613	32.017	0.0	0.0	0.0	0.0	0.0

表1

DYNAMIC MODEL (上位モデル)

I=53

回線利用率

平均回線結果

表2 STATIC MODEL I=53

利用率事前 check (100%以下)OK

3. RESOURCE UTILIZATION BY RESOURCE CLASS

RESOURCE CLASS (%)

NODE	1	2	3	4	5	6
1	10.514	33.808	2.917	36.808	0.039	
2	1.897	13.250	0.0	0.0	0.007	
3	60.331	0.810	48.276	71.425	1.169	
4	60.331	0.810	48.276	71.425	1.169	
5	60.331	0.810	48.276	71.425	1.169	
6	60.331	0.810	48.276	71.425	1.169	
7	60.331	0.810	48.276	71.425	1.169	

表3 DYNAMIC MODEL I=53

利用率評価結果

1. RESOURCE UTILIZATION BY NODE (%)

(RESOURCE CLASS)

INODE	1	2	3	4	5	6
1	15.372	34.800	4.500	70.500	3.636	
2	2.016	14.400	0.0	0.0	0.322	
3	57.075	1.200	53.100	59.850	28.312	
4	55.500	0.750	47.700	62.550	28.186	
5	56.925	1.050	48.450	64.350	23.119	
6	60.375	0.750	46.950	73.050	27.591	
7	58.200	1.050	46.950	68.400	27.451	

CPU

DISK

完了個数



平均応答時間



応答時間標準偏差

表4

3. SERVICE REQUEST PERFORMANCE DATA

SR.#	SERVICE REQUEST DESCRIPTION	a		MEAN		VARIANCE OF TIMES
		NUMBER COMPLETED	TURNAROUND TIME (SEC)	MEAN	VARIANCE	
1	セイビン ハッシュ	41	0.474	0.474	0.088	
2	ハント イトケイ ハント イタカク	41	0.474	0.474	0.088	
3	セイリク カイカク	41	1.440	1.440	0.325	
4	クミタテ シュニシヨウ カイカク	41	1.804	1.804	0.318	
5	フヒン ハッシュ	131	4.304	4.304	0.912	
6	セイビン スタータス	241	2.114	2.114	1.424	
7	ヒヂテ	2191	3.924	3.924	4.132	
8	シユラカ シラカ	15561	0.968	0.968	0.032	
9	セカイ テータベイク	41	1.609	1.609	0.232	
10	ケンカシテイセイテイ/ホカ	22141	0.504	0.504	0.024	
11	ケンカシテイセイテイ/ホカ	531	4.106	4.106	1.070	
12	フヒン ハント メンテナス	241	2.133	2.133	0.914	

DYNAMIC MODEL (=上位モデル)

I=53 SR応答時間

平均結果

5. 結論

分散型計算機システムの性能評価ツールを開発した。この種ツールの課題は性能評価時間の短縮と、分散専用のモデリング機能支援の充実にある事から発し、時間短縮のために SCHWETMAN のハイブリッド方式をさらに高速化した方式を採用した。モデリング支援のため、トランザクションを複数の「ファンクション」と「メッセージ」で構成し、さらにノードを Functional class と呼ばれるグループに分け、各々の Functional Class 内のノードが共通のファンクションを処理できるように定義する機能を設けた。これにより、トランザクション内の処理を、複数ノードで行なうようなモデルが簡単にできるようになつた。

現在のところ、実稼動の分散システムの実測値により、本方式の結果の検証をさせていたま。また、ここで採用したハイブリッド方式の評価時間の測定と組織的に行なつていたま。今後この二点を課題としている。

6. 参考文献

- [1] Courtois, P. Decomposability, instabilities, and saturation in multiprogramming systems. Comm. ACM 18, 7 (July 1975), 371-377
- [2] Schwetman, H.D.. Hybrid Simulation Models of Computer Systems. Comm. ACM 21, 9 (Sept. 1978) 718-723
- [3] Chiu, W. and Chow, W.M., A performance models of MVS. IBM Sys. J. 17, 4 (1978) 444-463
- [4] 田中, 通信ネットワーク計画性能設計支援ツール SPACNET-P の開発
第23回情報処理大會(予定)
- [5] 中村, 通信ネットワーク性能設計 — SPACNET-P のプロセス
第23回情報処理大會(予定)
- [6] BUZEN, J. Computational algorithm for closed queueing networks with exponential servers. Comm. ACM 16, 9 (Sept. 1973) 527-531
- [7] 木山, 大町 ハイブリット手法を用いた分散システム性能評価手法
第22回情報処理大會
- [8] 木下, 吉沢 解析手法を取り入れた計算機性能評価シミュレータの開発
第22回情報処理大會