

適応機構を備えたオペレーティングシステムアーキテクチャ

石川 千秋，坂村 健，前川 守

(東京大学理学部情報科科学科)

1. はじめに

解こうとする問題の構造を計算機の構造に写像することは一般に難しい問題である。問題解決のためのアルゴリズムとコンピュータを作る電子回路、半導体構造の意味的な差は余りにも大きく、これは Gagliardini より「セマンティック・ギャップ」と呼ばれている⁽¹⁾が、との存在故に解くべき問題を計算機構造に写像することは、現在いくつかの階層構造を経て行われており、これが計算機システムの効率悪化の主要な要因となる。しかし、この階層的写像法を全くなくすることは、現在のところ考えにくい。そこでより効率の良い計算機構造の実現のためにには、問題のアルゴリズムと計算機間の構造のギャップを最小の手間でつなげるような階層構造を見つけることが重要である。これは一般に最適トレードオフの発見問題であり、これは計算機アーキテクチャの本質である。さて、最適トレードオフの発見は解くべき問題のアルゴリズムの検討から始まる。解析的(静的)な手法ですべて解明されればよい。ところが実際にはアルゴリズム、問題の構造の解析と静的に完全に行うこととは難しい。問題のほとんどは複雑すぎて静的な解析だけでは不十分で、動的な動作解析により初めてその性質がわかるものに属する。それにもかかわらず、現在の計算機の構造決定法には、このような静的方法しかとられなかつた。そのため、無駄が大きく、進歩したハードウェア・デバイスを最大限活用するに至つてしまつた。

ここに以上の議論をより現実的例を挙げ考察する。オペレーティングシステムは計算機上で走るプログラムの中でも、最も複雑なもののが一つであり、静的な

考察だけでは、最適な構造を決めることはできないように思われる。皮肉なことにオペレーティング・システムは計算機で我々が得た直接的な解を提供してくれる問題(プログラム)ではないが、計算機を必要とする最大の問題(プログラム)のひとつである。オペレーティング・システムはジョブの要求をシステムリソースに写像するための必要な中間構造があり、そこにオーバヘッドが入つてくる。

このような理由から、オペレーティング・システムの最適構造を考えることは、ユーザ・ジョブの要求をより直接、システムリソースに反映させて、最高性能を引き出すことに通じる。また、問題に適した最適オペレーティング・システムは VLSI ベースの高度にパッケナライズされたシステムにとどまることも必須である。以上のような概念にもとづき、本論文では、動的な情報をもとに、オペレーティング・システムの最適な構造を決定する方法について論ずる。これをオペレーティング・システムのダイナミック・チューニングと呼ぶ。従来このような観点からオペレーティング・システムについて述べた論文はないので、まず動的、即ち実行時におけると決定され得るよう因子たついてまとめる。またそこに適応性を持たせた場合の影響について検討する。個別ではあるがいくつかの例を挙げる。さらに個々の適応するための因子間の問題についても考察を行う。

このような異なる因子間にまたがる相乗チューニングにより、システ

ムの性能が静的情報だけをもとに設計された場合に比べて、大巾に向こうするというのが本論文の結論である。

2. チューニング

過去にあって、また現在でもとうごあるが、我々はシステムの設計、構築にあたっては多くの注意を払ってきた。しかし、ユーザがこれらのシステムをどのように使つているかとか、オペレーティング・システムの設計に限つていえば、ジョブがオペレーティング・システム、広くいえばコンピュータ・システムにどのような要求をしているかということを十分考慮して設計をすすめてきたとは思われない。コンピュータ・システム、オペレーティング・システムの性能が予想と大巾に違うことかしばしばあるのは、実際のジョブの要求をオペレーティング・システムの構築の際にうまく取り込めなかつたためである。

この論文ではオペレーティング・システムをユーザ・コミュニティーによつて種々の変化をするワーカロードに適応させることを考えていく。ジョブ(JOB)とはコンピュータ・システムが処理するユーザの問題の総称である。またオペレーティング・システムはこれらの中のジョブに対してサービスを与えるためのプログラム群である。

これらのジョブはシステムに対する“要求”によつて特徴付けることができる。システムをリソースのネットワークと考えてみよう。このリソースの典型的な分類としては、CPU、メモリ、システムを構成するメイン・メモリ、二次記憶用デバイス、I/Oシステムを構成するチャネル、ディスク、及びドラムなどがある。各ジョブは各リソースに対する要求量とあるリソースを使つて後他のリソースを要求する分歧確率によつて特徴付けられる。これ

をジョブ・パートンという。そしてこれは併せて訓練の理論により完全にモデル化される。(図1)

システムのコンフィギュレーションを変えることにより、ある特性を持つジョブ・パートンに対応を付けて目標性能を達成していくことをチューニングと定義することができる。システム・コンフィギュレーションとは、オペレーティング・システムで使うポリシー、アルゴリズム、種々のデータ表のサイズなどを我々が変えることができるもののすべてをいう。そしてこのように考えると、オペレーティング・システムのコンフィギュレーションがジョブ・パートンとうまく対応せずにリソース・ネットワーク中にボトルネックが生ずる時に必要なものがチューニングであるといえる。

リソース・サービスの要求量、リソースの要求頻度は、個々のジョブに本質的に必要なものと、オペレーティング・システムがジョブとコンピュータ・リソースの間に介在するが故に必要な部分とに分けられる。オペレーティング・システムによる部分はオペレーティング・システムの構造、アルゴリズムやパラメータの値、つまりシステムのコンフィギュレーションによつて変更できる。チューニングはこれらを変えて、目標達成を防げるボトルネックを取り除くのである。またこのようないくつかのチューニングを行う時には、ジョブをクラス分けして、優先すべきジョブ・クラスのパートンにマッチしたコンフィギュレーションを選び、他のジョブ・クラスの犠牲のもとで、優先ジョブのパフォーマンスを上げることが多い。

やっかいなことにチューニングによって、システム中のボトルネックは取り除かれるが、普通は新たにボトルネックとなるサブ・システムが登場することがある。(図2) しかし、その環境

ご目標性能が達成されといれば良いの
である。ところがなければ“チューニング”
とくり返して、顕著なボトルネックを
除去していくことになる。幾度もチュ
ーニングを行っても、効果が期待でき
ないことがある。それはジョブ・パター
ン、特にリソースの要求に大きなかた
よりがある場合である。ひとつはリソ
ースに過大な要求をしている場合には、
そのリソースの能力を大目に引き上げ
る他に性能改善の手はない。ハードウ
エアのアップグレーディングが必要と
される。

このようにチューニングの限界は常
に頭に置いておく必要がある。しかし実際にはコンピュータ・システムの運
営方法がまずく、その限界能力以前の
不完全性性能しか引き出していく場
合の方が圧倒的に多いようと思える。

チューニングの適用可能な場合をい
くつか挙げてみよう。チューニングが
大きなメリットを發揮するのは、ユーザーテンプトを処理して目標性能を達成
できるだけのリソースがあるにもかか
わらず、システムのコンフィギュレー
ションがジョブ・パターンとうまく対応
せずに復弱な性能しか引き出していくな
い場合がまた挙げられる。さらにこれを
発展させて、ワーカロードのジョブ・
パターンが安定している場合、あるいは
ユーザがジョブ・パターンを予測でき
る場合には、何の変更も加えない、現
在の一般的システムよりも高い性能を
引き出すようにすることができるこ
とも意味する。またワーカロードが急激
に変化した場合、自動化されたチュ
ーニングプロセスはシステム性能の急低下
を防いで、性能の安定化に役立つ。
またチューニングのためのモニタ・デー
タ、モデル化の方法は広い意味で新しい
コンピュータ・システムを考慮してい
く上でのデータの構組みと提供する。
次章ではコンピュータ・システムの各部

分ごとのようすをチューニングが可能か
についてみていく。

3. チューニングの方法と実例

システムを大きく、CPU、メモリ、
I/O、ファイルシステムとに分けて、
どれぞれがシステムの目標性能の達成、
のボトルネックとなっている時、どのような
チューニングが可能かを表1に
ついて示す。ここでは各サブシステム
を別々の“チューニング”的対象としてい
るが、実際にはサブシステムは他のサ
ブシステムにも影響を及ぼしているの
を考慮しなくてはならない。さらには高
いレベルでも考えたシステム全体の
チューニングについては、次章で
考える。以下、例を示しつつ、表に説
明を加えていく。

CPリカボトルネックとなるている
時、チューニングの対象となるのはオ
ペレーティングシステムのオーバヘッ
ドを減らすことである。これはジョブ
の要求に対して、システムが不要に
多くのスーパーバイザコール(SVC)
を行なうことから起り得る。例えば少
量のメモリ・ロックをフェッ
チするかわりに、大きなメモリ・ロック
を一度にフェッチするようにして必
要なSVC回数を減らすことができる。
さらにSVCの回数はシステム中の他の
部分のチューニングで影響を受ける。

例えばI/Oシステムで取り扱う転
送ブロック・サイズについて考えこみよ
う。ブロック・サイズを大きくすると、
同じ量のデータを送るのに必要な転送
回数は少くなる。それに応じて、S
VCの回数も減り、入出力に必要なサ
ーチ、シーケンス、チャネルの結合時間、
及びSVCに伴なうCPU時間も少す
くなる。ブロック・サイズとCPU時間
の関係の例を図3.1に示す。もちろん
むやみにブロック・サイズを大きくする

と、ブロック中の無駄な部分が大きく
なり、不要な部分までが転送される
ことになるので、最適の大至近距離
なければならない。いすれにせよ、S
VCを減らしCPUのロードを軽くす
ることは可能である。

I/Oシステムがボトルネックとな
る時にはボトルネックデバイスをなくすためにロード・バランスングの
手法が適用できる。Hughes & Moeはこ
れを取り扱いCPUの使用効率の12%
の向上を得た。⁽²⁾ さらにデバイスがいく
つものシリンドラに分かれている時、と
め中でのアームのシーク距離、アーム
に対する要求の衝突回数を減すことが
できる。Gurinらは、同一のディスク
上のファイルに連続してアクセスがな
されると、デバイス間の並列処理の可
能性が減り効率が落ちるというモデル
を考え、個別のファイルを個別のディ
スクに割り当てる、今述べたことが起
きる可能性を小さくするために手法を
論じている。ファイル毎に次にファイル
を参照する頻度 P_{ij} を測定して、

$$C = \sum_{\text{ディスク}} \sum_{i,j} P_{ij}$$

(同一のディスク)。

という指標を最小にすることを考え、
実際のデータとともに、Cの10~20%
程度の減少が得られている。⁽⁴⁾

I/Oシステムでの転送ブロックサイズの変更は先程CPUに觸れて述べ
たようにシステムのオーバヘッドを減
らすのに役立つ。

デバイストリコントロール・ポリシーを
変えることにより、システムのオーバ
ヘッドを減らすことができる。

例えばディスクのコントロールに、
FCFS (First Come First Served) と
SSTF (Shortest Seek Time First) の
二つの方法を使い分けることができる。
ディスクのロードが転い時にはFCFS
とSSTFの性能に大差はない。この時に
はログラムが短かく、Xモ

リ要求量が少なくて、CPU時間の要求
量も少ないのでFCFSを使うことによ
り、システムのオーバヘッドを少なく
できる。しかしディスクの負荷が大き
い時には、性能の良いSSTFを使う
ことにより、ディスクがボトルネック
とならぬようになることができる。
このようにして、コントロール・ポリシ
ーもチューニングの対象となり得る。

Xモリ、システムがボトルネックとな
る時には、表に挙げた手法がある。
ログラム再構成は、ログラム・
モジュール間の参照関係、それらの
大きさを考え、モジュールの結合順
序を変えて、参照の局所性を高めたり、
同一ページ中に閲覧する高頻度一チ
ンを入れてページングの必要量を減らすこ
とである。この方法は手間が比較的か
からず、しかもページング・システムの
もとでは有効な方法であることが知ら
れている。⁽³⁾ ローダーにこのような
インテリジェンスを持たせて、頻繁に
使われるログラムをワーカロードした
倉庫せて、再構成していくことは有効
であろう。

またページングシステムのコントロ
ールとログラムのページ参照列のハ
ッシュに合わせて、コントロールする
ことにより、良好な性能を引き出す
ことができる。例えばDenningのWS
ポリシーがある。

ここではページ活動をモニタして、
多度度を変えて、メモリの割り当てを
変えるスケジューラのシミュレーションを行
ったので、それにつけて述べ
る。

システムは図3.2のような閉じた待
ち行列網を使つたモデルである。ジョ
ブがページ・フォールトを起こすと、ペ
ージング用デバイスに移る。ジョブの
モデルはページ・フォールトの多い期間
と少ない期間の間を動くセミ・マルコフ
過程で記述され、それらの期間中で

は、ページフォーレトの間隔は、ライフタイム閾値の値で決定されるとした。ここで目標性能として、CPUの使用効率を高めることを考えた。このシステムではCPUの使用効率は、閉じた待ち行列網の理論により計算である。(付録A) と山によれば、ジョブに割り当てられるメモリサイズによって、CPUの使用効率は変化する。CPUの使用効率を下げないためには、スラッシュングが起きないように、しかも多密度を上げる必要がある。そこで解析結果をもとに最適多密度を求める。それとともに、ページング活動をモニタし、スケジューラがCPU待ちのジョブをロックあるいはリリースして多密度を変えるスケジューラを構成した。多密度を固定したシステムとスケジューラによると多密度を変更するシステムのCPUの使用効率の時間変化のシミュレーション結果の一例を図3.3に示す。

このようなスケジューラによるとスラッシュングも避けられるし、もしスラッシュングに陥っても、その状態から速やかに抜け出ることがわかる。

この例はチューニングの中でも比較的短期間にジョブの特性が大きく変わった場合に、システムの性能が大幅に低下することを防ぐためのダイナミックなチューニングといえる。

4. 因子の相関関係と広域チューニング

4.1 相関関係

前章でオペレーティング・システムの各部にどのようなチューニングを行うことができるかを示した。ここに挙げたいいくつかの例からもわかるように、オペレーティング・システムの一部に変更を加えるとそれは、他の部分にも影響を与える。オペレーティング・システムの一部のチューニングが他にどのよ

うな関係を持つかを図4.1に示した。

図4.1は、例えばデータ転送の際のロック、サイズを変更するとSVCの回数で、CPUにかける負荷が変わり、かつメモリ中のバッファ部分が大きくなったりロック中の無駄が生じたりして、メモリ・システムの負荷を変えるということを意味する。

図からわかるように、種々のパラメータ、アルゴリズム、あるいはポリシーの変更はシステムの各部に影響を及ぼしていく。チューニングによるとボトルネックを除こうとする場合には、この相関についての考察がなされていなければならぬ。

このようないオペレーティング・システムの各部の相関性、コンピュータ・システムの他の部分のチューニングにどういった効果を及ぼすかについて考えてみる。

計算機のインストラクションセットを応用に合わせて変化させる手段、インストラクション・チューニングを例にとれば、CPUの資源の有効利用を計算することによると、CPU時間の要求量が減ることが考えられる。これにより、CPUがボトルネックとなる場合に、それを取り除く可能性がある。また、インストラクション・チューニングはCPUばかりではなく、メモリ参照パターンを変える可能性もある。故に、もし、このメモリ・サブシステムへの影響を考えると、インストラクション・チューニングの持つ能力向上の可能性を最大限に取り出すことはできないだろう。相互に関連したオペレーティング・システムの一部に外部からの変更が加わる場合には、チューニングはその変更による能力向上を引き出さための必須の手順である。

もうと広く、コンピュータ・システムで走るプログラム・モジュールのチューニングを考えると、例えばページ

ゲ・システムの好むヤージ行動をプログラムにとらせるような方法がある。このようなチューニングは本来ならば、ユーザの要求をシステムに合ったものにすることができ、ユーザの存在すべきことであるが、ここでもプログラムのチューニングがオペレーティング・システム全体に与える効果は大きい。そしてシステムの相関を良く知ることが重要と思われる。

4.2 グローバルチューニング

チューニングに使われるワーカロードの特性のデータは当然のことながら、チューニングのみならず新システムの設計の際の基本データとなり得る。このデータはソフトウェアとハードウェアのトレードオフの決定、オペレーティング・システムの基本設計には欠かせない。⁽⁸⁾ 基本的な意味でシステムの構造を改めていくのに役に立つ。

チューニングの適用ができるオペレーティング・システム自身の構築については、チューニングの要求する処方を実行できるだけの柔軟性が必要とされる。柔軟性を高めるためオペレーティング・システムのファームウェア化の研究も重要なようだ。

ミニ、マイクロ・コンピュータの発展に応じて必要となる、またオペレーティング・システムの自動生成の際にも、このような自動チューニング機構を考えておくことが望まれる。

またオペレーティング・システム中のパラメータの変更の効果の評価を、量的パラメータのみならず、質的パラメータの場合につけても行えるように、システム・モデルとワーカロードのモデルを確立して、洗練されたものにしていくことが必要である。

5. 結論

本論文では適応機構を備えたオペレーティング・システムのアーキテクチャの構築を目指して、適応の可能性のある因子と適応可能性について論じた。適応可能性のある因子は多く、それらは互に影響を及ぼす。しかし、その関係を考慮しつつ、多様なチューニングをくり返すことによつて、静的に設計されたオペレーティング・システムに比べ性能を改善することができることが結論された。本文でも述べたように、このよう自働的オペレーティング・システム・アーキテクチャはレレSIIに代表されるパーソナルコンピュータにとて、パーソナライズ(適応)化技術として重要なばかりではなく、専用化されたオペレーティング・システムの自動生成とも深い関係がある。

このようにチューニングは単なる性能向上の手法としてだけではなく、将来のアーキテクチャと、それに沿つたソフトウェアの製作にも影響を与えるデータを提供する。

御討論いただいた藤田哲也君に感謝したい。

(参考文献)

1. U.D. Gagliardi
2. Hughes and Moe "A structural approach to computer performance analysis" NCC '73
3. R. Snyder "On a priori program resturucturing for virtual computer systems" in (5)
4. N.N. Gurin et al. "A heuristic approach to file allocation problems" in (5)
5. Proc. 2nd Int'l Symp. Operating Systems Theory and Practice. (ed.) D. Lanciaux
6. K. Sakamura et al. "Automatic tuning of computer architecture" NCC '79
7. 坂村健「超LSIベース・アキテクチャ」 bit 共立 1980.8.
8. Maekawa et al. "Performance adjustment of an APL interpreter" EUROMICRO '79
9. R.M. Shardt "An MVS tuning approach" IBM Syst. J., vol.19, no.1, 1980





图 2.1 (a) SYSTEM MODEL AS NETWORK OF RESOURCES.



(b) QUEUEING NETWORK MODEL EXAMPLE.




图 2.2 REMOVAL OF BOTTLENECK AND THE APPEARANCE OF NEW ONE

表 1. 平衡方法の可能性。

CPU

- reduce the number of SVCs (Supervisor calls) by increasing the data transfer block size, by decreasing paging activity and etc.

I/O subsystem

- balance the load by
 - reconfiguration of the connections of the channels, control units and devices
 - reallocation of files over devices to remove bottleneck device or to decrease the seek distance and arm contention.
- change the device control policy to strike the trade-off point among the program size, CPU time demand and the efficiency of the control.
- reduce I/O device request by using virtual I/O instead of real I/O, thus passing information inside the main memory.
- increase the transfer block size and reduce the number of I/O SVCs and overhead(search, seek, channel startup time.)
- make frequently used program modules , such as library, commands and etc., resident in main memory to decrease the I/O device usage for the linking process.


Memory subsystem

- reduce the number of swapping by making some programs or parts of programs non-swappable at the cost of free storage area.
- use page replacement algorithm which works well with the referencing pattern of the user job. Example. Working Set Policy.
- restructure programs
 - place the modules near the modules which they make reference to make reference to them.
 - place these modules in one page frame if possible.
 - make user jobs' referencing pattern to what paging system favors.
- regulate the degree of multiprogramming so that the programs can receive enough main memory to run with producing few page faults.
- make OS program module data area just as large as required by the workload, no more.


BLOCK SIZE	200	1,000	2,000	4,000	6,000
CPU TIME	73.6	21.6	14.3	10.6	9.3
CHANNEL TIME	95.2	46.9	38.4	36.5	33.3

(9)より。

3.1 Block size and processing time of same amount of data.



3.2 シミュレーションシステム



3.3 シミュレーション結果の一例。

(付録)

$$P(\vec{n}) = 1/g(N, M) * B_{CPU}(n_M) W_{CPU}^{n_M} \prod_{i=1}^p (W_i \tau_p)^{n_i} \prod_{j=p+1}^{p+f} (W_j \tau_f)^{n_j}$$

(システムの状態確率を与える式)

$$\vec{n} = (n_1, \dots, n_p, n_{p+1}, \dots, n_{p+f}, n_M)$$

n_1, \dots, n_p : # of jobs at paging devices.

n_{p+1}, \dots, n_{p+f} : # of jobs at file disks.

n_M : # of jobs at CPU

$$g(N, M) = \sum_{k=0}^N g(n-k, m-1) B_m(k) W_m^k$$

$$B_m(k) = B_{CPU}(k) = \prod_{i=1}^k 1/C_{CPU}(i)$$

$C_{CPU}(i)$: the processing speed of the CPU stations

when there are i jobs.

$$B_j(k) = (W_j \tau_f)^k \quad p+1 \leq j \leq p+f$$

$$B_i(k) = (W_i \tau_p)^k \quad 1 \leq i \leq p$$

W_j : the routing probability of the j -th disk.

τ_f : the mean service time of the file disk.

$$W_i = W_{CPU} / L \cdot f_i$$

W_{CPU} : the mean inter-I/O time.

f_i : the routing probability of the i -th paging device.

τ_p : the mean service time of the paging device.

图 4.1 $f_2 - f_1$ 因子的相互關係圖

TUNING THERAPY	I/O SUBSYSTEM	MEMORY SUBSYSTEM	CPU
file reallocation	decrease of arm contentions. load balancing of channels, control units and devices.		
reconfiguration of connections of channels, control units and devices.	same as above.		
making program modules memory resident.	decrease of channel, device utilization.	request for free storage.	
change of transfer block size.	decrease of I/O SVC overhead, (search, seek, channel start up time.)	change of the buffer area	frequency of I/O SVC.
Change of device control algorithm	yes.	change of program size.	change of CPU TIME request.
paging algorithm	swapping, paging frequency	yes.	paging, swapping SVC.
change of page frame size.	amount of data transferred at page fault time.	yes.	frequency of SVC
CPU scheduling, control of degree of multiprogramming	swapping, paging frequency.	memory partition.	frequency of swapping, paging, process switch SVC.
use of virtual I/O instead of real I/O	decrease of I/O device utilization and overhead.	virtual I/O area request.	decrease of I/O channel interrupts.
placing of program modules, program restructuring.	decrease of I/O activity due to paging.	yes.	frequency of paging SVC.
allocate to OS programs just as much data area as required by workload, no more.		yes.	
instruction tuning.		change of memory referenc- ing pattern.	decrease of load due to better utilization of CPU resources.
program module tuning. (program restructuring,	elimination of unnecessary I/O.	yes, probably.	elimination of unnecessary calculation, use of better algorithms, decrease of SVC, and et