

分散型リアルタイムオペレーティングシステム ; DIROS

谷口 秀夫 遠城 秀和 井村 佳弘 境 孝之

NTTデータ通信（株）開発本部

DIROSは、バス／LAN／SCSIの各通信路で結合された分散プロセッサ環境においてのトランザクション処理を可能にする分散型リアルタイムオペレーティングシステムである。DIROSは、リクエスト制御と呼ばれるプログラム構築方式に基づいて作成されており、非完了システムコール機能やリモートファイルアクセス／リモートデバイスアクセス／マルチプロセス生成／リモートプロセス間通信の各機能を実現している。また、UNIXとの協調処理を可能にするため、UNIXシステムコール機能とDIROS-UNIXマシン間の分散ファイルシステム機能を実現している。

A Distributed Real-time Operating System ; DIROS

Hideo TANIGUCHI, Hidekazu ENJO, Yoshihiro IMURA, Takayuki SAKAI

Development Headquarters

NTT DATA COMMUNICATIONS SYSTEMS CORPORATION

Kowa Kawasaki Nishi Bldg. 66-2 Horikawa-cho, Saiwai-ku,
Kawasaki-shi, Kanagawa 210, Japan

DIROS is a real-time operating system for transaction processings. It supports a distributed environment where one hardware internal bus connects up to 8 processors to one computer. Processors on different computers are connected by a local area network(LAN) or small computer system interface(SCSI). Because the DIROS program is based on a facility called request control, it realizes the following functions: (1) remote-file access, (2) remote-device access, (3) multi-process creation, and (4) remote inter-process communication. DIROS has two characteristics for coordinating work between DIROS machines and UNIX workstations. One is that application programs can mix unique DIROS system-calls and UNIX system-calls. The another is that one distributed file system is constructed between DIROS machines and UNIX workstations.

1. まえがき

LSI技術の進歩に伴い、マルチマイクロプロセッサシステムはメインフレームに匹敵するコスト/パフォーマンスを実現している。分散型リアルタイムオペレーティングシステム(Distributed Real-time Operating System:DIROS)は、複数のプロセッサを搭載した計算機を高速通信路で結合した分散環境におけるトランザクション処理をサポートするOSである。

分散環境でのトランザクション処理をサポートするOSを実現するには、以下の問題がある。

(1) 分散処理OSは、大きく3つに分類できる。1つはUNIXシステムコールインターフェースを持つ新OSであり、LOCUS^[1]やMach^[2]がある。もう1つは、独自のシステムコールインターフェースを持つ新OSであり、CHORUS^[3]やSprite^[4]がある。最後は、UNIXを拡張したOSであり、Newcastle-Connection^[5]、COCANET^[6]、NFS^[7]、DPE^[8]、RFS^[9]、MOSIX^[10]がある。これらのOSは、分散ファイルシステムを持ち、リモートプロシージャコールやプロセスマイグレーションの機能を持つものもある。しかし、トランザクション処理を行なうには、次の問題がある。(A) 非完了システムコール機能が充分でない、(B) ファイル操作関連の信頼性が低い。

(2) TRON^[11]のようなリアルタイムOSは、リアルタイム性を確保するため、複雑なプログラム構成になっていることが多い。そのため、分散環境をサポートするように改造することは難しい。単に、各OS間をメッセージ通信で結んだだけでは、分散環境でのトランザクション処理をサポートすることはできない。

本稿では、トランザクション処理をサポートする分散OSへの要求条件を示すとともに、DIROSにおける解決策について述べる。

2. 要求条件

分散環境においてトランザクション処理を実現す

るOSには、非完了システムコール機能、ネットワーク透過性、ヘテロ環境サポート、が求められる。各々について、以下に説明する。

2.1 非完了システムコール機能

非完了システムコール機能とは、3つのタイプのシステムコール(ジョブ受付、ジョブ結果取得、ジョブ取消し)を応用プログラム(以降、APと略す)に提供する。この機能により、APは1つのプロセスで多くの処理を並列的に行なうことができ、サービス実現時のAPプロセス数を最適化できる。

非完了システムコール機能を実現するには、各ジョブについて、ジョブの受取り/ジョブの実行/ジョブ結果の格納の処理を行なうOSプログラムを分離するとともに、ジョブの取消しメカニズムを持つことが必要である。

2.2 ネットワーク透過性

ネットワーク透過性とは、スタンドアロン環境と同様なインターフェースを分散環境でも提供することである。このことは、OSがAPに提供するシステムコールとOSプログラム間のインターフェース(以降、内部コールと呼ぶ)の両方に求められる。

システムコールのネットワーク透過性としては、ファイル管理とプロセス管理のシステムコールについて2つのことが求められる。1つは、装置やファイルやプロセスの資源が全プロセッサから一意の名前で管理されていることである。もう1つは、資源アクセスのセマンティクスがスタンドアロン環境と分散環境で同じであることである。これらの条件を満足することにより、APプロセスを任意のプロセッサで走行させることができる。

内部コールのネットワーク透過性としては、プロセス管理やファイル管理やディスク制御などのOS基本処理プログラム間で直接通信でき、そのインターフェースは通信方式に影響されない必要がある。その結果、いろいろな分散環境をサポートするOSを構築できる。

2.3 ヘテロ環境サポート

トランザクション処理とTSS処理やバッチ処理の間での協調処理を可能にするため、ファイルやプログラムを共用できるヘテロ環境のサポートが必要である。

プログラムを共用できるため、OSは独自のシステムコールとともにTSSのシステムコールを実現する必要がある。また、そのインターフェースはマシン語レベルでTSSマシン上のものと同じでなくてはならない。これにより、例えば、TSSコマンドをトランザクションマシン上でもそのまま利用できる。

ファイルを共用できるため、ヘテロ分散ファイルシステムを構築しなくてはならない。この実現時の主な問題は、システムコール処理の変換とエラー値変換である。

3. ハードウェア環境

分散環境は、いろいろな通信路でプロセッサ間が結合される。DIROSがサポートするハードウェア環境について、プロセッサ間の結合状態を以下に説明し、様子を図1に示す。

(1) DIROSマシン内のプロセッサは、1つのバスで結合されている。プロセッサ間の通信は、プロセッサ割込みと共有メモリを介して行なう。共有メモリは、各プロセッサからアクセスできるが、周辺装置とのデータ転送を制御するDMAコントローラからはアクセスできない。

(2) 各プロセッサは、他プロセッサからアクセスできないローカルメモリを持

つ。

(3) DIROSマシンは、LANやSCSIで結合されている。

(4) 同一のLANでDIROSマシンとUNIXマシンを結合している。

4. オペレーティングシステム構造

DIROSは、非完了システムコール機能とネットワーク透過性を実現するため、そのプログラムは、リクエスト制御^[12]の方式に基づいて作成されている。

4.1 リクエスト制御

リクエスト制御は、OSの各機能を実現しているプログラム間の処理のやりとりについての制御方式である。リクエスト制御方式を以下に説明するとともに、処理フローを図2に示す。

(1) システムコールに対応する機能を実現していく




図1 ハードウェア環境




図2 リクエスト制御の処理フロー

る処理単位にプログラムを分割し、処理モジュールと呼ぶ。これには、ディスク制御、H D L C通信制御、ファイル管理、メッセージ制御などがある。

(2) 処理モジュールは、分散環境で一意の識別子(以降、処理モジュール識別子と呼ぶ)を持つ。識別子は、処理装置番号、プロセッサ番号、モジュール番号の情報を持つ。様子を図3に示す。




図3 処理モジュール識別子

(3) 処理モジュール間は、4つのインターフェース(ジョブの依頼／結果取得／取消しおよび結果応答)を持つ。これらのインターフェースは、6つのルーチン(以降、ユニットと呼ぶ)、アクションユニット／レスポンスユニット／リザルトユニット／クリーンユニット／キャンセルユニット／キャンセルアクションユニット、で制御する。

(4) 処理モジュール間は、リクエストブロックと呼ぶ制御ブロックを送受信することで情報をやりとりする。リクエストブロックは、ジョブの依頼先と依頼元の処理モジュール識別子、ジョブの内容とそのデータ、ジョブ結果、を持つ。

(5) 処理モジュール間のインターフェースが、共有メモリ／L A N／S C S Iの各通信方式の違いに影響されないように、リクエスト制御内の通信制御部が、この違いを吸収している。

上記の項目（3）が非完了システムコール機能の実現を可能にし、項目（2）と（5）がネットワーク透過性の実現を可能にしている。

4.2 非完了システムコール機能

D I R O S は、リクエスト制御方式に基づいて作成されているため、全てのシステムコールを非完了システムコールとして A P に提供することができる。実際は、A P 利用上で有効な機能を非完了システムコールとして提供している。

A P に提供している非完了システムコールのインターフェースを図4に示すとともに、以下に説明する。

(1) A P からのジョブを受け付けるシステムコールは、各プロセスに一意な値であるリクエスト識別子 (r d : request descriptor) を返却する。

(2) ジョブ結果を受取るシステムコールは、パラメータに r d を持ち、次の3タイプがある。
(タイプ1：最初に処理が終了したジョブの結果を返却する)、
(タイプ2：r d に対応する非完了システム

コールのジョブ結果を返却する)、(タイプ3：r d に対応する非完了システムコールのジョブが終了していればその結果を返却し、そうでなければ、最初に終了したジョブの結果を返却する)。いずれの処理も、パラメータ l i m i t で指定された時間だけ処理の終了を待つ。

(3) ジョブの実行を取消すシステムコールは、パラメータで指定された r d に対応する非完了システムコールのジョブの実行を取消す。

A P からのジョブを受け付けるシステムコールとして14個ある。9個はファイル管理のシステムコールであり、5個はプロセス間通信やタイマ制御のシステムコールである。D I R O S は、入出力装置や通信回線を外部記憶装置内のファイルと同様にアクセスできるため、9個のファイル管理システムコールで大半のファイル制御処理ができる。ファイル管理機能の詳細については、4.3.1節で述べる。

4.3 ネットワーク透過性のための機能

ネットワーク透過性のための機能として、リモートファイルアクセス機能、リモートデバイスアクセス機能、マルチプロセス生成機能、リモートプロセス間通信機能、を実現した。これらの機能は、リクエスト制御方式を利用し、システムコールや内部コールをジョブとして転送することで実現している。

4.3.1 ファイル管理機能

D I R O S のファイル管理^[13] は、ディレクトリによりファイルを木構造で管理し、ファイルとして通常ファイルと特殊ファイルの2種類を持つ。通常ファイルとは外部記憶装置内にあるデータやプログラムのことであり、特殊ファイルとは入出力装置や通信回線を仮想化したファイルである。

これらのファイルを複数のプロセッサ間で共用できるために、リモートファイルアクセス機能とリモートデバイスアクセス機能がある。アクセスインターフェースは、ローカルファイルにアクセスする場合と同じである。リモートファイルアクセスはリモートの通常ファイル／特殊ファイルとディレクトリに

```
rd = asyn_syscall_job( ... , ... , ... );
long rd; /* 返却値 */
(A) ジョブを受け付けるシステムコール

rt = get_first_result(rd, limit);
rt = get_named_result(rd, limit);
rt = get_named_result_first(rd, limit);
long rt; /* 返却値 */
long rd; /* リクエスト識別子 */
int limit; /* 制限時間 */
(B) ジョブ結果を返却するシステムコール

rt = cancel(rd);
long rt; /* 返却値 */
long rd; /* リクエスト識別子 */
(C) ジョブの実行を取消すシステムコール
```

図4 非完了システムコールのA P インタフェース

ついてアクセス可能であるが、リモートデバイスアクセスはリモートの特殊ファイルへのアクセスのみである。しかし、リモートの特殊ファイルへのアクセス速度は、リモートデバイスアクセスが速い。

〈〈リモートファイルアクセス〉〉

異なるプロセッサのファイル管理間でファイル管理システムコールを転送することにより、リモートファイルアクセスが実現できる。各プロセッサは、自プロセッサのファイル管理の処理モジュール識別子情報を持つネットワークディレクトリを有する。

ファイル管理は、システムコールで指定されたファイルパス名を解析し、ネットワークディレクトリを発見するとその内容に基づいて残ったファイルパス名を該当ファイル管理に送る。ファイルパス名の途中にネットワークディレクトリがない場合は、ローカルファイルへのアクセスとして処理を実行する。このような処理フローになっているので、ファイルパス名の中に2つ以上のネットワークディレクトリが存在すると、1つのシステムコールからリモートファイルアクセスが多重に発生する。

〈〈リモートデバイスアクセス〉〉

ファイルアクセスの内部コールをファイル管理と各入出力制御あるいはファイル管理と各通信制御の間で転送することにより、デバイスにアクセスできる。特殊ファイルは、次の情報を持つ。

・周辺装置を制御しているプロセッサを有する計算機番号

- ・周辺装置を制御しているプロセッサ番号
- ・周辺装置を制御しているプログラムのモジュール番号

・同一プロセッサ内の周辺装置番号

システムコールで指定された特殊ファイルの情報が他プロセッサの場合、そのアクセスはリモートデバイスアクセスであり、自プロセッサの場合はローカルデバイスアクセスである。このような処理フローになっているので、アクセス処理系はローカル／リモートを全く意識しない。また、1つのシステムコールからリモートデバイスアクセスが多重に発生することはない。。

4. 3. 2 マルチプロセス生成機能

プロセス生成の内部コールを転送することでリモートにプロセスを生成する。プロセス識別子を以下の情報を持つ形で規定し、ネットワーク透過なプロセス生成環境を実現している。

- ・プロセスが走行するプロセッサを有する計算機番号

- ・プロセスが走行するプロセッサ番号

- ・プロセスを制御するプログラムのモジュール番号

- ・同一プロセッサ内のプロセス番号

各プロセッサ上のAP負荷分散をスムーズに行なうためには、各プロセッサ上へのプロセス生成を高速にできる必要がある。1プロセス生成をくり返して多数のプロセスを生成すると、過大なディスクアクセスやデータコピーやCPU負荷が発生する。このため、DIROSは、1つのプログラムから複数のプロセッサ上に多数のプロセスを一度に生成できるマルチプロセス生成機能^[14]を実現した。

以下の点を並列化して、処理を効率的に実現している。

(1) ディスクから共有メモリへのプロセスデータの転送、と共有メモリから各プロセス生成プロセッサのローカルメモリへのプロセスデータの転送、の並列化

(2) 各プロセス生成プロセッサでのプロセス生成の並列化

さらに、マルチプロセス生成システムコールの内容通知やプロセス生成終了通知の処理が、全プロセッサを対象としているため、プロセス生成依頼処理が生成プロセスの数や場所に影響されないというメリットがある。このような特徴により、マルチプロセス生成の処理時間は、生成プロセッサ数や生成プロセス数にほとんど影響されず、プログラムサイズで決定される。

4. 3. 3 リモートプロセス間通信機能

プロセス間通信のシステムコールを転送すること

により、リモートプロセス間の通信を実現した。通信媒体には、メイルボックス、セマフォ、共用メモリ、があり、プロセスへの直接通信もできる。プロセス識別子は4.3.2項で述べたような情報を持ち、通信媒体は以下の情報を持つ。

・ 媒体を管理しているプロセッサを有する計算機番号

・ 媒体を管理しているプロセッサ番号

・ 媒体を制御するプログラムのモジュール番号

・ 同一プロセッサ内の媒体番号

通信媒体の位置情報に基づいてローカル／リモートを判別することにより、ネットワーク透過性を実現している。26個のシステムコールが計算機内のリモートプロセス間通信をサポートしており、以下の6つのグループに分けられる。メッセージ／セマフォ／イベント／共用メモリ／バッファプール／プロセス制御。SCSIで結ばれた計算機間ではメッセージ送信ができる。

5. ヘテロ環境をサポートする機能

UNIXとの協調処理を可能にするため、DIROS上にUNIXシステムコールを実現するとともに、DIROSマシンとUNIXマシン間のヘテロ分散ファイルシステムを構築した。

5.1 UNIXシミュレート

OSが別のOSインタフェースを実現する方式は、大きく以下の3つに分類できる。

[方式1] プロセスとしてシミュレート

[方式2] OS核内にシミュレート

[方式3] 仮想マシン機能を実現し利用

[方式1] は、最も作成が易しい。[方式2] は、作成が[方式1]に比べ難しい。[方式3] は、独立な2つのOS環境を生むことができる。DIROSは、UNIX環境との協調処理を可能にするため、以下の要求を満足する必要がある。

[要求1] APプロセスは、同時にDIROSとUNIXの両システムコールを使える。

[要求2] APプロセスは、両OS上のファイルを

共有できる。

[要求3] DIROSマシンと同種のプロセッサを持つUNIXマシン上で走行するプログラムは、そのままDIROSのUNIX環境上で走行する。

[方式1] は[要求3]を満足せず、[方式3]は[要求1]を満足しない。そのため、DIROSは、[方式2]によりUNIXシステムコールをシミュレートし、各要求を満足する環境をAPに提供した。

APに提供しているUNIX環境は、以下のようにになっている。

(1) 3つのシステムコール(profile, plock, ptrace)を除く全てのシステムコールを、UNIXマシンと同じAPバイナリインタフェースで提供する。

(2) DIROSプロセス管理は、DIROSプロセスにUNIXプロセスより高い権限を与える。

(3) DIROSプロセスは8つのUNIXシステムコールを利用でき、UNIXプロセスは42個のDIROSシステムコールを利用できる。但し、DIROSシステムコールを利用できるUNIXプロセスは、ユーザidが特定値より小さくなくてはならない。

特に、(1)の特徴は、大変有効である。例えば、UNIXマシン上のコマンドをDIROSマシン上で走行させてDIROSファイルを操作できる。また、シェルをDIROSマシン上で走行させることで、ユーザフレンドリなインタフェースをDIROS上に実現できる。

5.2 ヘテロ分散ファイルシステム

ファイルの共有を可能にするため、同一LANで結合されたDIROSマシンとUNIXマシン間に分散ファイルシステム^[15]を構築した。これは、UNIXマシン間の分散ファイルシステム^[8]をベースにしている。

以下にファイルシステムの特徴を示す。

(1) DIROSは、UNIXシミュレート機能を利用してこの機能を実現しているため、全ファイル管理システムコールについてUNIXマシンからDIROSマシンへのアクセスを可能にしている。こ

れにより、例えば、UNIXマシンからDIROSマシン上のファイルをエディタで変更できる。

(2) 8つの基本的なDIROSファイル管理システムコールにより、UNIXマシン上のファイルにアクセスできる。

(3) リクエスト制御方式や非完了システムコール機能やUNIXシミュレート機能を利用するにより、非常に効率的なプログラム構造を持つ。

(4) 機能の大半をOS核外に実現することにより、複数タイプの分散ファイルシステム構築を容易にしている。

6. あとがき

分散したマルチプロセッサ環境においてトランザクション処理を実現するためには、非完了システムコール機能／ネットワーク透過性／ヘテロ環境サポート、がOSに求められる。

DIROSは、上記の要求を満足し、分散環境でのトランザクション処理を実現した。具体的には、

- (1) 14個の非完了システムコールを提供し、
- (2) リモートファイルアクセス／リモートデバイスアクセス／マルチプロセス生成／リモートプロセス間通信の機能を実現し、

(3) DIROSシステムコールとUNIXシステムコールの同時利用、とDIROSマシンとUNIXマシン間の分散ファイルシステムの構築、を行なった。これらの機能は、「リクエスト制御」と呼ぶプログラム間インターフェース方式に基づいて作成された。

DIROSは、既に研究開発を終え、商用システムに導入されている。

〈参考文献〉

- [1] B. Walker, et.al., "The LOCUS Distributed Operating System," Proc. of 9th ACM Sym. on Operating Principle, 1983, pp. 49-70.
- [2] M. Accetta, et.al., "Mach:A New Kernel Foundation For UNIX Development," Proc. of USENIX Summer Conf., 1986, pp. 93-112.
- [3] M. Rozier, et.al., "CHORUS Distributed Operating System," Computing systems, Vol. 1, No. 4, 1983, pp. 305-370.
- [4] J. Ousterhout, et.al., "An Overview of the Sprite Project," ;login:, Vol. 12, No. 1, 1987, pp. 13-17.
- [5] D. R. Brownbridge, L. F. Marshall and B. Randell, "The Newcastle Connection or UNIXes of the World Unite!," Software-Practice and Experience, Vol. 12, 1982, pp. 1147-1162.
- [6] L. A. Rowe and K. P. Birman, "A Local Network Based on the UNIX Operating System," IEEE Trans. Soft. Eng., Vol. SE-8, No. 2, 1982, pp. 137-146.
- [7] D. Walsh, et.al., "Overview of the Sun Network File System," Proc. of USENIX Winter Conf., 1985, pp. 117-124.
- [8] 谷口, 鈴木, 瀬々, "ファイル管理機能のネットワーク化による分散処理OSの構成法", 情処学論, Vol. 27, No. 1, 1986, pp. 56-63.
- [9] A. P. Rifkin, et.al., "RFS Architectural Overview," Proc. of USENIX Summer Conf., 1986, pp. 248-259.
- [10] A. Barak and R. Wheeler, "MOSIX:An Integrated Multiprocessor UNIX," Proc. of USENIX Winter Conf., 1989, pp. 101-112.
- [11] K. Sakamura, "The TRON Project," IEEE Micro, Vol. 7, No. 2, Apr. 1987, pp. 8-14.
- [12] 谷口, "OS機能の分散を可能にするOS構成法", 信学論, Vol. J72-D-I, No. 3, 1989, pp. 168-174.
- [13] 井村, 谷口, 遠城, "マルチプロセッサにおける分散ファイル管理方式", 情処研報, 89-OS-43-6, 1989.
- [14] 谷口, 境, "プロセス生成の高速化と並列化に関する検討", 信学技報, CPSY89-28, 1989.
- [15] 谷口, 遠城, 箱守, "異種OSを結ぶ分散ファイルシステム", 情処研報, 89-OS-43-7, 1989.

・UNIXはAT&Tのベル研究所が開発したOSです。