

並列計算機システム FOLON の通信ライブラリの設計と評価

上田 學[†] 菊地 賢太郎[†] 土山 了士^{††}
小林 一成^{††} 大原 拓三^{††}
外山 孝伸^{††} 上田 和紀^{††}

FOLON は安価な PC を PE とした共有メモリを持つ並列計算機システムである。共有バスには VME バスを利用し、ハードウェア工作をまったく行うことなく並列計算機を実現している。既存のハードウェアが持たないタイムアウト処理や排他制御についてはソフトウェアで実現している。FOLON では、共有メモリ機能、メッセージパッキング型プロセス間通信機能をライブラリの形で提供している。本稿ではこれらのライブラリの設計と通信性能について述べる。

Design and evaluation of the communication libraries of the parallel computer system FOLON

GAKU UEDA,[†] KENTARO KIKUCHI,[†] RYOJI TSUCHIYAMA,^{††}
KAZUNARI KOBAYASHI,^{††} TAKUZO OHARA,^{††}
TAKANOBU TOYAMA^{††} and KAZUNORI UEDA^{††}

FOLON is a shared memory parallel computer system which uses high cost-performance PCs as processing elements. FOLON employed VMEbus and no dedicated hardware was developed to make the whole FOLON system. Functions not supported by the hardware, such as time-out and mutual exclusion management, and the interprocess communication capabilities are provided as libraries. This paper describes the design and communication performance of these libraries.

1. FOLON とは

FOLON は共有メモリを持つ並列計算機システムであり、記号処理をはじめとする均質でない細粒度並列処理に向いたシステムを目指している。

FOLON の設計方針は以下の通りである。

- 価格性能比の高いパソコンを PE (processing element) として使うことにより、システム全体を安価に仕上げる。
- 既存のハードウェアを使い、新規のハードウェア製作を行なわない。
- 並列計算機として動作するために必要であり、ハードウェアが持たない機能は OS やライブラリレベルで実現する。

- 細粒度並列処理に向いたプラットホームを実現するため Ethernet で構成されたワークステーションクラスタよりもはるかに高い通信性能を発揮させる必要がある。特に少量のデータ転送の高速化を図る。インターネットネクションネットワークの製作を行わず、既存のハードウェアを利用した並列計算機システムの研究には文献 2 があるが、本研究では上記の方針にしたがって、実際には次のように実装されている。

- PE として IBM-PC 互換機 (以降 PC と呼ぶ)、Pentium 120 マシンを使う。
- 外部に VME バスを用意し、これを共有バスとして使う。PE と VME バスとの接続は PCI-VME バス変換アダプタを利用する。
- PCI-VME バス変換アダプタは BiT3 社製 PCI-VME バスアダプタ Model 617 を採用している。
- OS は、FreeBSD 2.1.0-RELEASE を用い、カーネルレベルに組み込むデバイスドライバおよびユーザーレベルのライブラリによって、VME バス上のメモリを共有メモリとしたシステムを構築する。
- 共有メモリアクセスの高速化を図るために、OS のババパス、DMA 転送の利用を行う。

本稿ではまず FOLON の構成について述べ、各レベ

[†] 早稲田大学大学院理工学研究科

Department of Information and Computer Science,
Graduate School of Science and Engineering, WASEDA
University

^{††} 早稲田大学理工学部情報学科

Department of Information and Computer Sci-
ence, School of Science and Engineering, WASEDA
University

ルにおける通信性能の測定とその結果について述べる。

2. ハードウェア構成

FOLON は IBM PC/AT 互換アーキテクチャのパーソナルコンピュータ(以降 PC と記述する)を PE としている。1996年1月現在、FOLON は6台のPC(Pentium 120MHz)から構成される。

外部にVMEバスを用意しこれを共有バスとして利用している。VMEバスシャーシには各PEとケーブルで接続されたバス変換アダプタカード(VME側)が接続されている。このバス変換アダプタカード上にはデュアルポートメモリがそれぞれ128KBずつ、計896KB[☆]が実装されている(図1)。




図1 FOLON のハードウェアシステム構成図

VMEバスに接続されたバス変換アダプタカードは、PC内部のPCIバスに接続されたPCI側のカードに接続されている。このほかに、各PEはEthernetにより接続されている^{☆☆}。

各PE上ではFreeBSD^{☆☆☆}が動作しており、共有メモリを使わず、Ethernet経由でアクセスすれば通常のUNIXマシンとして利用できる。

VMEバス上には、各PEのメモリアドレス空間とは別にVMEメモリアドレス空間が存在する。VMEバスは32bitアドレスのメモリ空間を持ち、4GBまでのアドレッシングが可能である。FOLONではVMEバスを共有バスとして利用する。VMEバス上のデュアルポートメモリと、各PEのメインメモリの一部をVME空間にマップした部分を、共有メモリとして使うことができる(図2)。

VME空間でアドレッシング可能なメモリ領域は、




図2 VME アドレス空間

PCIメモリ空間にもマップさせ、Test & Set命令が使えないことを除けば通常のメモリアクセスと同じ方法でアクセスすることができる。

また、大量のデータに対してはDMA転送を用い、より高速な処理を行なう。これにより共有メモリを通信路として使い、Ethernetよりもレイテンシが小さくスループットが大きい通信を実現している。

3. ソフトウェア構成

3.1 ライブライアリ階層

FOLONのPEはBSD系UNIXであるFreeBSDで動作する。FOLONの並列計算機システムとしての機能はFreeBSD上に構築されたデバイスドライバ、ユーザーアプリケーションにリンクするライブラリで実現されている。FOLONのハードウェアおよびOSは本来並列計算機用途に開発されたものではなく、不足している機能は既存の機能の組み合わせあるいはソフトウェアアルゴリズムによって補う必要がある。

並列計算機システムとしての機能を、FOLONでは大きく3つの階層に分けインプリメントしている。

デバイスドライバ PE間を接続しているVMEバスおよびバスを操作するハードウェアの制御を可能にするドライバ

VCL(VME Control Library) VME資源のコントロールおよび共有メモリアクセス機能を実現するライブラリ

FCP(FOLON Control Protocol) ライブラリ マルチプロセス対応プロセス間通信を実現するプロトコルライブラリ

階層構造を図に表わすと図3のようになる。VCLは、VME上の共有メモリに対するアクセスをOS/カーネルをバイパスさせ直接操作することで高速化(主にレイ

[☆] PE6台と監視用の1枚

^{☆☆} FOLONでは最大20台のPEで稼働することができる。

^{☆☆☆} FreeBSD 2.1.0-RELEASE




図3 FOLON のライブラリ階層

テンシ性能の向上)を図っている。

3.2 デバイスドライバ

デバイスドライバはVMEバスアダプタのコントロールの他、メモリマッピング、FOLONプロセスの管理、割り込み処理、DMA転送を担当している。

3.2.1 メモリマッピング

FOLONでは、各PEのメモリ空間上の空き領域にデュアルポートメモリのメモリイメージをマップすることで、共有メモリを実現している。2つのPEがこの領域をアクセスすることにより、VMEバス経由での通信が実現されている。さらにPEのPCIメモリの一部をVME空間にマップすることで、VMEメモリ空間を増やしている。このメモリをマップドPCIメモリと呼び、ローカルなPEからは、通常のメモリと同じ速度でアクセスできるという特性を持つ。

3.2.2 VMEバスアダプタのコントロール

VMEバスアダプタの状態はI/Oポートを経由して取得することができる。またVMEバスアダプタの制御もI/Oポートを操作することで行う。VMEバスの初期化などVMEバスを操作する処理は、実際はドライバがI/Oポートを操作することで実現している。

3.2.3 DMA転送の実現

VMEバスアダプタはDMA転送機能を持っている。この機能をドライバを経由して使うことで、大量のデータ転送の効率をあげることができる。DMA転送は以下のような理由でドライバ内部で実現されている。

- I/Oポートのうち多くのレジスタを使って初期設定を行う必要がある。
- DMA転送中はPEの転送データの含まれる物理メモリのスワップアウトを禁止する必要がある。
- 1PE内で同時に見えるDMA転送は1つであり、共有メモリにアクセスするプロセス間での調停が必要となる。

3.2.4 FOLONプロセスの管理

VMEバスアダプタ自体は複数プロセスの同時使用を考えて設計されているわけではない。そのためI/Oポートやメモリマップ情報など、FOLONとしての動作に関わる共有資源はデバイスドライバで一括して管理している。さらにFOLONを使用するプロセスに関する

情報を管理しており、ソフトウェア割り込み処理のためには使用している。

3.2.5 割り込み処理

VMEバスで発生する割り込みはPEのバスアダプタによって、一般割り込みとエラー割り込みの二種類の割り込みとして、PEのデバイスドライバに伝えられる。現在は一般割り込みのうちDMA Done割り込みとエラー割り込みを監視している。

3.2.5.1 エラー割り込み

VMEバスへのアクセス時にエラーが発生した場合、VMEバスアダプタはPEにエラー割り込みをかける。この割り込みはドライバ内で処理され、必要ならばプロセスに通知される。

現在のドライバでは

- インターフェースバリティエラー
- リモートバスエラー
- インターフェースタイムアウト

の3種類のエラーを検出している。発生したエラーの識別は割り込みハンドラがステータスレジスタを参照することを行っている。

3.2.5.2 DMA Done割り込み

この割り込みはDMA転送の成功、失敗にかかわらず終了時に発生する。DMA転送中はPE上の他のプロセスはVME資源のアクセスを禁止されているのでアクセスできずに待っている。ドライバはこの割り込みを確認するとDMA転送の後処理を行った後、他のプロセスに使用許可をソフトウェア割り込みを使って通知する。

3.2.5.3 タイムアウト対策

後述するVCLライブラリで説明する通り、VMEアクセス時に30μs以上の遅延があった場合、VMEバスはタイムアウトエラーによる割り込みを発生させる。現在の仕様ではタイムアウトエラーの場合は再送を行うことになっており、ドライバがタイムアウトエラーを確認した場合には、FOLONを使用中のユーザープロセスに対してドライバはソフトウェア割り込みを使って通知する。実際に再送する機能は後述するVCLライブラリ内で実現されている。

3.3 VCL (VME制御ライブラリ)

VCL(VME Control Library)は、FOLONの持つ共有メモリ機能を実装するライブラリである。VMEバス上の共有メモリに対するアクセスはすべてこのライブラリを通して行われる。

VME上の共有メモリに対するアクセス速度の向上のため、共有メモリアクセスはOSのバイパスによってユーザープロセスから直接行う。デバイス利用の競合の解決をVCLレベルで行う。

このライブラリでは次の機能を実装している。

- 共有メモリに対するさまざまな種類のアクセス
- デバイスドライバで実現されている機能のインターフェース(DMA転送など)
- 共有メモリに対するTest & Set機能

● ユーザーからのシステムの保護

共有メモリに対するアクセスの種類は限られており、それらすべてのアクセスを VCL でインプリメントする。上位プログラムは必然的にこれらのいずれかの機能を利用するため、中間にライブラリが存在することによるオーバーヘッドは問題にならない。

3.3.1 VCL が提供する共有メモリ空間

FOLON で利用できる共有メモリには、VME バス上のデュアルポートメモリと VME メモリ空間上にマップされた他の PE の PCI メモリがある。

自 PE の PCI メモリ空間の一部にはデュアルポートメモリ、他の PE のマップド PCI メモリがまとめられている。自 PE のマップド PCI メモリ（他からアクセスできる領域）は、マップされたメモリとは別の領域にカーネルが確保しページングの対象外となっている。

VCL は、個々の PE ごとに異なる PCI アドレス空間を、すべての PE から同じ共有メモリアドレス体系でアクセスできるよう FOLON アドレス空間を提供し、ライブラリ内でアドレス変換を行っている（図 4）。




図4 各メモリ空間の間の関係 (PE5 の例)

3.3.2 共有メモリに対する Test & Set の提供

VCL は PE 内の複数のプロセスから同時に利用することが可能なマルチプロセス対応型ライブラリである。FOLON ではレイテンシ改善のため、共有メモリへのアクセスを OS(デバイスドライバ)を経由させず、直接ユーザープロセスからアクセスできるようにしている。このためバス変換アダプタが複数のプロセスから同時に操作されることがあるため、Test & Set の実現には次のような方法をとっている。

Test & Set を実現するには、同一プロセスが処理を掌握しなければならない。同一プロセスによる処理を保証するために、まず PE 内のプロセス排他を行い、成功すれば VME バスにバスロックをかけ PE 間の排他を行うことで、Test & Set が実現できる（図 5）。




図5 排他制御の流れ

3.3.3 タイムアウト処理

VME バスアダプタ経由のメモリ読み込み / 書き込みが一定時間実行できなければ VME バスアダプタのインターフェースタイムアウトエラーが発生し、タイムアウトを発生させた PE に割り込みがかかる。

割り込みがカーネルに通知され、割り込み処理が開始されるまでに、VCL のメモリ操作処理が先に進んでしまうという問題が発生する。

この問題は PE(PCI バス)において Posted Write⁵⁾という手法が取られていることが原因であり、FOLON で利用しているマザーボードでは 5 ダブルワード分のバッファが設定されている。

割り込みは VME デバイスドライバに捕捉され、PE 内の VCL を利用するすべてのプロセスに通知される。VCL では、メモリ操作関数に対し 5 命令分の時間を待ってから処理を終了することにより、割り込みを確実にメモリ操作関数内で捕捉することを可能にし、割り込みがかかつてた時点でメモリ操作を行っていれば、現在の書き込みを中止し最初から再度書き込みを行うことによりタイムアウトの処理を実現している（図 6）。




図6 タイムアウト処理

3.4 FCP 通信ライブラリ

FCP(FOLON Control Protocol) ライブラリは、VCL 上に構築されたメッセージパッシングモデルの通

* 最大 4 ダブルワード先まで書き込まれる場合がある

信ライブラリである。FCP はマルチプロセスに対応したことが最大の特徴である。

FCP の設計方針は以下の通りである。

- UDP と同等の通信をより高速に行う方式を実装。
- PE 内のマルチプロセスに対応。
- バスの混雑ができるだけ軽減。
- 今後の FOLON の拡張に対する移植性の確保。

3.4.1 高速な通信の実現

FCP では VCL を利用し OS を介さず共有メモリを経由した通信が可能になるため、Ethernet 経由の通信に比べレイテンシの小さい通信が可能となる。FCP は、メッセージの大きさによって最適なメモリアクセス方法を選択し、大きなメッセージに対しては DMA を利用することにより最適化を図っている。

3.4.2 PE 内マルチプロセスへの対応

FCP では同一 PE 内のプロセスが同時に PE 間通信に参加することが可能となっている。FOLON の通信に参加するプロセスは初期化時に VME 空間の共有メモリ上にそのプロセスの受信バッファが割り当てられる。送信プロセスがそのバッファに書き込むことにより通信が成立する。共有メモリアクセスをクリティカルセクションにせずに、FCP のプロトコルレベルで同時アクセスに対しても動作することを理論的に保証し、排他制御を最低限に押さえている。

3.4.3 バスの混雑の緩和

FOLON に利用している共有メモリは、デュアルポートメモリ、マップド PCI メモリとも PE がローカルに持つメモリに対しては共有バスを経由せずにアクセスができる。この特性を活かすため FCP では受信側のポーリングがバス上に出ていかないよう受信バッファをローカルにある共有メモリに用意し、書き込み側のメモリアクセスのみがバス上に現れるようになっている。

3.4.4 移植性の向上

FCP は、PVM や MPI などの並列ライブラリや低レベルでの操作の必要な並列アプリケーションから利用することを主眼におき、UDP と同等の通信を実装し、これらを利用するアプリケーションの移植が容易なよう設計されている。FCP を利用する場合は共有メモリ空間に対する考慮は不要となる。

FCP は、FCP を利用するアプリケーションから FOLON のハードウェアに依存する部分を取り除き、ハードウェア構成や共有メモリマップの変更、さらにより高速な転送方法が実装された場合にもアプリケーションのソースコードに変更を加えることなくそのメリットを享受できるようになっている。

4. 性能評価

FOLON の通信性能を評価するため、ハードウェアレベル、VCL レベルでベンチマークテストを行った。

4.1 FOLON の基本性能

まずハードウェアの持つ基本性能を測定した。各種ライブラリではこの性能に対し、ソフトウェアオーバーヘッドが加算されるため、最大限この値に近づけるようインプリメントすることを目標としている。

レイテンシは、4 バイトのデータを PE のユーザー メモリ空間から別 PE の共有メモリへ転送し、転送の命令を終了した時間までを測定した。スループットは 4096 バイト転送の場合の値である(表 1 および表 2)。

送信先	アクセス	レイテンシ	スループット
デュアルポート RAM (ローカル)	read	1	1.89
	write	2	1.91
デュアルポート RAM (リモート)	read	1	1.75
	write	1	1.74
マップド PCI メモリ (リモートのみ)	read	6	0.87
	write	1	0.93

表 1 PIO 性能(レイテンシ単位 μs 、スループット単位 MB/s)

送信先	アクセス	レイテンシ	スループット
デュアルポート RAM (ローカル)	read	136	8.70
	write	134	8.77
デュアルポート RAM (リモート)	read	137	7.55
	write	134	7.50
マップド PCI メモリ (リモートのみ)	read	142	8.79
	write	145	7.46

表 2 DMA 性能(レイテンシ単位 μs 、スループット単位 MB/s)

4.2 VCL レベルのベンチマーク

共有メモリアクセスを提供する VCL レベルでのベンチマークテストは、データが送信側 PE のプロセスから受信側 PE のプロセスに到達するまでの時間を、往復にかかる時間から算出する。通信に利用するメモリがマップド PCI メモリの場合とデュアルポートメモリの場合について測定した。

4.2.1 PIO 転送

まず、共有メモリに対するアクセスを PIO で行う性能について測定した。表 3 の値は、PE のユーザー メモリ空間から別の PE のユーザー メモリ空間までの片道の転送時間を往復の転送時間から算出した値である。データの経由する経路は、クライアントプロセス → サーバのバッファ (PCI またはデュアルポートメモリ) → サーバプロセス → クライアントのバッファ (PCI またはデュアルポートメモリ) → クライアントプロセスである(図 7、図 8)。レイテンシは 1 バイト転送、スループットは 4096 バイト転送の場合の値である。今回の測定ではタイムアウト処理は行っていない。

PIO 転送では、Ethernet 経由の通信に比べレイテンシ性能を 50 倍程度向上させることができるがスループットに関しては Ethernet 経由 UDP と同等の転送速度しか得られない。




図7 マップド PCI メモリ経由の通信の経路




図8 デュアルポートメモリ経由の通信の経路

経路	レイテンシ	スループット
マップド PCI メモリ経由	5	0.43
デュアルポートメモリ経由	6	0.38
Ethernet 経由 UDP/IP	320	0.39

表3 VCL レベルにおける通信性能(レイテンシ単位 μs , スループット単位 MB/s)

4.2.2 DMA 転送

PIO 転送の欠点である大量のデータ転送の遅さを解決するため, FOLON ではバスアダプタの持つ DMA 転送を利用したメモリアクセス関数をサポートしている。ベンチマークは, PE のユーザーメモリ空間→別 PE のマップド PCI メモリ→別 PE のユーザーメモリ空間→PE のマップド PCI メモリ→PE のユーザーメモリ空間の転送時間を測定し, その片道の通信のレイテンシを最小の通信である 4 バイトの通信, スループットを 4096 バイトの通信から算出した。

経路	レイテンシ	スループット
マップド PCI メモリ経由	480	1.00
Ethernet 経由 UDP/IP	320	0.39

表4 VCL レベルにおける DMA 転送性能(レイテンシ単位 μs , スループット単位 MB/s)

DMA 転送の場合は DMA 転送用のレジスタ設定などのオーバーヘッドのため, レイテンシ性能は Ethernet 経由 UDP に比べて悪いが, 160 ダブルワード(640




図9 VCL レベルにおける通信性能

バイト)以上の転送で PIO アクセスよりも早くデータ転送ができるようになり, スループットも 2.5 倍程度あり, メッセージ長の増加に対する通信時間の増加幅を PIO 転送に比べ大幅に押さええることができる。

5. まとめ

FOLON は, PE として PC を使いデバイスドライバ, VCL, FCP で PE 間通信を実現している。FOLON の VCL レベルでは, レイテンシ性能で UDP の 50 倍程度を実現している。また, 大量のデータに関しては DMA 転送を用い, スループット性能で UDP の 2.5 倍程度の性能を発揮する。

プロセス間通信を実現する FCP 上への PVM の移植は現在進行中であり, KL1 言語処理系であり PVM を利用する並列版 KLIC を動作させる予定である。

また今回通信性能の測定ができなかった FCP レベルでの転送性能の測定, VCL にタイムアウト処理を追加した場合の転送性能の測定を行うとともに割り込みなどを活用し, 既存の VCL, FCP のパフォーマンスチューニングを行う予定である。

参考文献

- BIT3 Computer Corporation: "Bus-to-Bus Adaptor Model 617 Adaptor Hardware Manual", BIT3 Computer Corporation, Minneapolis, Minnesota, 1994.
- 瀧和男, 小倉毅, 小西健三: "ワークステーション複合体による並列処理システム", 情報処理学会研究報告, 93-PRG-13, pp. 49–56, 1993.
- Janet I. Egan Thomas J. Teixeira, 野中浩一, 大西照代(訳): "改訂版 UNIX デバイスドライバ", アスキー出版局, 1989.
- Samuel J. Leffler: "The Design and Implementation of the 4.3BSD UNIX Operating System", Addison-Wesley, 1988.
- 滝誠一: "PCI バスの詳細と応用へのステップ", OpenDesign, No. 7, CQ 出版社, 1995.