

解説 高速プロセッシングデータベース技術

6. テクニカルサーバ Exemplar における高速データプロセッシング技術

A High Speed Data Processing Technology on Technical Server Exemplar by Ichizo KITAGAWA (Advanced Technology Center, Product Marketing, Technical Computing Marketing Center).

北川 一三¹

1 日本ヒューレット・パッカード(株)

1. はじめに

はじめに今回題材にしている Exemplar S/X の簡単な紹介をします。

Exemplar S/X クラスは、旧 CONVEX 社の SPP シリーズの第二世代として Hewlett-Packard と CONVEX の合併後に初めてリリースされた計算機です。この S/X クラスは、ピーク性能 720Mflops という性能を引き出す 64bit プロセッサ PA8000 (180MHz 版)、高速 15.3GB の 8 × 8 ノン・ブロッキング・クロスバー・スイッチなどの高速演算を能力を支える技術を採用した S クラス、さらに S クラスのマルチノード仕様として X クラスに分けられています。それぞれの最大構成として、S クラスでは PA8000 を 16 プロセッサ、メモリを 16GB までの構成ができます。X クラスでは 64 プロセッサ、64GB となります。この余裕の計算リソースから S/X クラスは Exemplar ファミリーにおいて、高速演算性能、スループット性能や大規模な計算リソースを必要とするユーザ向けのハイエンド・マシンとして位置づけられています。

この S/X クラスの高速演算性能を支える技術として S/X クラス共通の PA8000 からメモリまでのアーキテクチャ、および X クラスのマルチ・ノード間におけるデータバス技術の概要を述べます。

2. PA8000 のプロセッサ・アーキテクチャ

PA8000 プロセッサは、すべてのレジスタを 64 ビット幅とした完全 64 ビット・アドレッシングの RISC プロセッサです。プロセッサ内部の並列化を大幅に進め、10 個の演算ユニット中、クロックごとに最大 4 命令が並列して稼動する 4-

Way スーパースカラ技術を採用し、きわめて高い性能 (720 Mflops) を発揮します。

PA8000 の特長としては、

- 1MB 命令用キャッシュと 1MB データ用キャッシュをサポート。(アーキテクチャ的には、さらに大容量のキャッシュにも対応できるようデザインされています。)
 - 浮動小数点の積算／加算、除算／平方根計算、整数演算、シフト／マージ演算用に、それぞれ 2 つの演算器が用意されています。
 - 2 つのロード／ストア・ユニット (PA8000 独自)
 - 56 個のエントリをもつ命令リオーダ・バッファ
 - 12 個のメモリ・リクエストの同時処理機能
 - スペキュレーティブ実行
 - プリフェッチ機能
 - スタティック、およびダイナミックな分岐予測
 - キャッシュ・アクセスのレイテンシは最大 2 クロック (連続したアドレスへのアクセスは 1 クロック)
 - デュアル・ポート・キャッシュ
 - 64bit アドレッシング
- などがあげられます。

PA8000 は、PA-RISC 2.0 命令セットアーキテクチャを実装した最初のチップです。従来の PA-RISC とも完全バイナリ互換を保っています。2.0 アーキテクチャの目的は、64bit の整数と 64bit のアドレッシングをサポートすることです。性能の向上とともに、新しい命令セット・アーキテクチャに重要で不可欠な新しい機能も追加されました。

新しい特徴として、可変サイズのページ、新しい浮動小数点オペレーション、置換と予測の両方




図1 PA8000 の概観

の手法を使った効果ある分岐処理などがあげられます。PA8000は、64bit整数がそのまま使える完全な64bitチップで、また、フラットな64bit仮想アドレス空間をサポートしていますが、チップ自体が出力するのは40bitの物理アドレスです。これは、直接1TBのメモリにアクセスすることが可能であることを意味します。PA-RISCの製品ラインの既存チップとの互換性を保つために、PA8000は、narrowとwideという2つのモードから1つを選択するコントロールbitをサポートしています。narrowアドレス・モードでは、32bitの物理アドレスだけがサポートされます。

PA8000は、分離アーキテクチャを採用しています。つまり、命令デコード・ロジックは、演算・ユニットのパイプライン・ロジックとは異なります。これにより、プロセッサは、演算・ユニットで命令が実際に実行されるよりも早く、命令をデコードすることができます。デコードされた命令は、チップ内のキューに入れられます。

PA8000は、実行中に最大56命令をもつことが可能で、クロック・サイクルごとに4命令を発行することができます。スーパースカラ性能をできるだけ高いレベルで保つために、PA8000は、独立した浮動小数点ファンクション・ユニット、独立した除算／平方根演算・ユニット、独立した64bit整数ALU、シフト／マージ・ユニット、そして独立したロード／ストア・ユニットをそれぞれ2個ずつ、計10個の演算ユニットをもっています。なお、クロックごとに発行できる4命令のうち、浮動小数点ファンクション・ユニット、除算／平方根ファンクション・ユニット、64bit整数ALU、シフト／マージ・ユニット用の命令は2個です。ここで重要なポイント

は、2個の浮動小数点演算・ユニット用に、2個のFloatingPointMultiplyAndAccumulate(FMAC演算)命令をクロックごとに発行できるというです。つまり、ピークの浮動小数点演算性能は、4×動作周波数180MHzで計算できます。FMAC命令は、複合命令です。1つの命令で2つの浮動小数点演算が実行されます。また、FMAC命令のレイテンシは3サイクルですが、浮動小数点演算・ユニットは、クロックごとに命令を受け付けることができますので、演算結果もクロックごとに出力されます。

PA8000のキャッシュ・アーキテクチャは、PA-RISC製品ラインの既存製品と同じです。命令データとも1次キャッシュの1階層です。容量としては1MBから4MBのキャッシュ・サイズが構成できます。Sクラス、Xクラスでは、命令、データ各1MBのサイズで、ライト・バック処理のダイレクト・マップ方式を採用しています。キャッシュは、オフチップ上にSSRAM(Synchronous SRAM)で構成します。データ・キャッシュは、2クロックでデータを転送しますが、パイプライン処理およびout-of-order実行により、通常、レイテンシがないのと同じになります。命令キャッシュは、プロセッサにクロックごとに4命令を供給します。

豊富な演算・ユニットを十分に使うために、プロセッサは、56エントリのIRB(Instruction Reorder Buffer)、デュアル・ポート・データ・キャッシュ、クロックごとに4命令が命令キャッシュからフェッチできる能力を備えています。プロセッサは、IRBに最大56個の命令を保持することができ、必要なデータとファンクション・ユニットの準備ができた時に命令を発行します。IRBの中で、命令のデータ依存性はチェックされ、データと必要なファンクション・ユニットが利用可能になった時、その命令が演算・ユニットに送られます。分離アーキテクチャを採用した結果、PA8000は、out-of-order実行が可能になりました。IRBの中に命令があれば、レジスタ、データ、演算・ユニットが利用可能になった時に発行されます。プログラムに書かれた順序どおりに命令を実行する必要はありません。しかし、命令は、必ずプログラムに書かれた順序で完了しなければなりません。このように、次々と




図-2 プロセッシング・サブシステムとクロスバー

ロード・リクエストを同時処理できるという機能に加えて、プロセッサは命令レベルでのスケジューリングを行うことができるということは非常に重要なポイントです。これは、X クラス・システムのような cc-NUMA(cache coherent Non-Uniform Memory Access)アーキテクチャを補完する機能です。つまり、PA8000 は、ローカル・キャッシュやメモリ内に配置されたデータへのリクエストと、プロセッサ・インターフェクトにわたったリクエストを同時にサポートします。その結果、非常に多くのレイテンシを隠してしまう、つまり、実際には、レイテンシは存在しますが、プロセッサはその影響を受けずに、実行を続けることができます。PA8000 のもう 1 つの優れた機能は、スペキュレーティブ(speculative)実行を行うことです。スペキュレーティブ実行とは、実行のパスをプロセッサに予測させ、予測したパス上の命令を実行させることです。予測が正しくなければ、その予測で実行された命令は排除されます。スペキュレーティブ実行が行われるケースとして、まず分岐のケースがあげられます。これは最も重要なケースです。PA8000 は、分岐によってどちらのパスがとられるかということを予測するための優れたメカニズムをもっています。分岐予測では実行されるべき命令の流れ、すなわち、

分岐で選択されると予測されるパスを示します。そして、このパス上にある命令がスペキュレーティブ実行されます。もし分岐が誤って予測された場合実行された命令は単に排除されます。

3. 高速メモリ・データバス技術

Exemplar のアーキテクチャは大きくわけてクロスバー・スイッチ、プロセッシング・サブシステム、メモリ・サブシステム、I/O サブシステムから成り立っています。S クラス 1 台には、最大で 16 個までのプロセッサ、8 枚のメモリ・ボード、8 本の I/O チャネル(この時、24 個の PCI I/O コントローラが接続可能)を搭載することができます。(この S クラス 1 台分に相当するノードを Exemplar ではハイパノードと呼んでいます。)

3.1 クロスバー・スイッチ

S/X クラスのメモリ・サブシステムは、クロスバー・テクノロジをベースとして、15.3GB /秒という高いデータ転送性能を実現しています。

クロスバーのポート数は、8 ポート × 8 ポートで、プロセッサ側の各ポートはエージェントに接続され、各エージェントには、2 個の PA8000 プロセッサ、240MB/s の I/O チャネル、および、データマウバが接続されています。一方メモリ側の各ポートには、4-way インタリープのメモリ・ボードが接続されています。クロスバーは、120MHz(8.33ns)で動作し、エージェントとメモリ・コントローラ・チップ間のデータ幅は 64bit です。クロスバーのバンド幅は、ポートあたり単方向で 960MB /秒ですが、入力と出力の 2 つのクロスバーが組み込まれ、8 個のエージェントと 8 個のメモリ・コントローラは、入力用と出力用クロスバーの 2 つの接続路をもっています。したがってクロスバーの総バンド幅は、15.36GB/s になります。さらに、クロスバーはノンロックング・アクセスが可能なため、すべてのポートが最大限のバンド幅でデータを転送することができます。したがってプロセッサや I/O チャネルからメモリ・サブシステムへのアクセスを、クロスバーがブロックすることができないため、データ転送にバスを使用する場合に避けられない性能の低下を防ぐことができます。

3.2 メモリ・サブシステム

S クラスは、256MB から 16GB の SDRAM を

サポートしています。実際には、メモリは、2枚から8枚のメモリ・ボードに分散して配置されますが、SDRAMを使用することにより、メモリ・サブシステムを普通のDRAMより高いクロック周波数で動作させ、より高いバンド幅を得ることができます。メモリは、DIMM(Double In-line Memory Module)の形で、システムに実装されます。DIMMを使うことにより、メモリを偶数枚ずつシステムに増やすことによって、メモリ・インタ・リープ性能の向上が可能になります。実際には、DIMMの数ではなくて、メモリ・コントローラの数によってメモリ・インタ・リープは決まります。それぞれのメモリ・コントローラは、4-Wayのインタ・リープをサポートしていますので、8個のメモリ・コントローラをすべて実装した場合は、搭載されているメモリの量に関係なく、32-Wayのインタリープがサポートされることになります。

3.3 プロセッシング・サブシステム

2個のPA-8000プロセッサ、I/Oサブシステム、DATA MOVERから構成されています。

- DataMover

I/OとDMAの性能をさらに高めるために、Sクラス、Xクラスは、ハイパノード内、およびハイパノード間の高速なデータ転送を行うことを目的としたハードウェアが実装されています。

このハードウェアは、データムーバと呼ばれ、プロセッシング・エージェントの一部分として、それぞれのプロセッシング・サブシステム内に含まれます。データムーバは、シングル・スレッドによるデータ転送を、450MB/秒の実効転送速度で行います。データムーバは、メッセージ・パッシング・ライブラリを用いるプログラミング環境での性能を向上するという重要な役割も担っています。

- I/Oサブシステム

Exemplar Sクラス、Xクラスは、ハイパノードあたり24PCIコントローラを接続可能な、非常にI/Oの接続性が高いシステムです。さらに、XクラスのI/Oサブシステムは、高いスケーラビリティを発揮し、システム内のハイパノードに分散して配置することができます。ハイパノード上の1組のプロセッサごとに、32bit PCIサブシステムへのI/Oチャネル(バンド幅：240MB/秒)

があります。実装には32bit PCI規格を使用し、120MB/秒のバンド幅を実現しています。しかし実際には、Sクラス、XクラスのI/Oチャネルは、将来の64bit PCI規格も取り扱える設計になっているため、そのI/Oスループットは、将来的に現在の倍の240Mbytes/秒になります。

PCIコントローラはI/Oチャンネルごとに3枚あり、ハイパノードあたり最大24PCIコントローラが接続可能です。インテリジェント化されたI/Oポートは、システム内のハイパノードに分散して配置された各メモリと直接DMA(Direct Memory Access)転送を行うことが可能です。これにより、CPUはデータ転送にほとんど介在することなく、本来の演算処理などユーザのための作業を行うことができます。また、大きなブロック・サイズを使うディスクのアクセスや高速なネットワークでの効率的なデータ転送を可能にします。これらのI/Oオペレーションは、データムーバにより大幅に性能が向上しています。XクラスのI/Oサブシステムは、物理的にはシステム内にあるハイパノードのすべてに、あるいはいずれかに分散して配置することができます。しかも、システム内のすべての周辺装置、ネットワーク・インターフェースは、ノード内の接続を司るクロスバー・スイッチ、およびノード間を接続するインタコネクトを介して、システム内のどのメモリにもアクセスすることができます。同様に、すべてのプロセッサは、システム内のハイパノードに接続されているいずれのデバイスやディスクにもアクセスすることができます。たとえ、プロセッサとディスクが異なるハイパノードに接続されていても問題は起きません。

4. ノード間データバス技術

ここではXクラスのものマルチ・ノード・システムを実現する技術を紹介します。

Xクラスのノード自体は、Sクラスのハイパノードと同じですが、複数のハイパノードに分散配置されたメモリをどのプロセッサからも共有できようにして、さらにシステム全体にわたってキャッシュ・コヒーレンシをとるためのインターフェクト・ハードウェアが、ハイパノードを接続しています。特徴として(1)階層化されたccNUMAアーキテクチャ、(2)ノード間を結ぶCTI、(3)ハ




図-3

ードウェアでサポートされた GSM(Global Shared Memory)を紹介します。(※ Exemplar ではハイパノードと呼びますが、以下ノードと記述します。)

・階層化メモリ・アーキテクチャ

ccNUMA アーキテクチャ採用により、メモリ・サブシステムのどの階層も、データ共有が最適に行えるようにデザインされています。この共有メモリ構造は 2 つの階層にわけられています。

第 1 階層は基本的に SMP のメモリ・プロセッサ構造と同じです。この階層では 16 個までのプロセッサ、および I/O サブシステムと、物理メモリが、クロスバーによって接続され、複数のプロセッサ、I/O サブシステムは、メモリへ同時にアクセスできます。

第 2 階層は複数のノードを CTI(Coherent Toroidal Interconnect)と呼ばれるインタコネクトによって、それぞれの第 1 階層のメモリを結合することによって構築されています。CTI は 2 方向(X 方向、Y 方向)にそれぞれ複数のリングで構成されバンド幅を高めています。CTI によってノードが接続されることによって SMP 型の複数ノードが、1 つのシステムとして動作します。その結果、システム全体のメモリが 1 つの共有メモリとして使えるマルチ・プロセッサ・システムのように機能します。

・インタコネクト(CTI)

複数のノードを接続しているのは、IEEE1596-1992 SCI(Scalable Coherent Interface)に準拠した、低レイテンシのインタコネクトリングです。

このインタコネクトは、共有メモリへコヒーレントなアクセスができるように、高 bandwidth と低 latency という性能を提供します。CTI は、Point-To-Point 接続の単方向リンクが集まつたもので、X 方向の 1 つのインタコネクションはリングとしてみなすことができます。このリングは、ノードに対し 8 個のインターフェース・コントローラをもち、インターフェース・コントローラからそれぞれ独立に出る 8 本のデータ・パスから構成されます。つまり、2 つのノード間のリンクは、8 本の完全に独立したバスであるインタコネクトをもっていることになります。8 個のインタコネクトのデータは、リング上を單一方向かつすべて同じ方向に動くため、あるノードから、データの流れとは逆鱗のノードにデータを送る場合、そのデータはリングを 1 周することになります。

CTI コントローラは、1 つのリクエスト処理が完了する前に、次のリクエストの受付処理を開始することができます。多くのデータを高速に転送する上でこの機能は重要です。2 つのノードが同じリング上にあるものと仮定した場合、ノード間のデータ転送は次のように行われます。(1) データを要求する側のノードが 1 キャッシュライン分のデータを応答側のノードに要求した場合、最初は、インタコネクトを通じてリクエスト・パケットが送られます。その時、リクエスト・パケットはそのバス上にあるターゲットでないノード上の CTI コントローラを通過します。(2) ターゲットとなる応答側のノードはそのリクエスト・パケットをみつけ、インタコネクトからそれを取り除きます。(3) そして、応答側のノード上のメモリ・サブシステムは、ローカルメモリから必要なキャッシュラインを引き出すための処理を開始します。(4) この時、応答側ノードは、ローカルのメモリ・サブシステムにアクセスすると同時に、要求側ノードに、ACK(acknowledge)パケットを送ります。(5) 応答側ノードは、キャッシュラインを引き出すと、これを含めたレスポンス・パケットを作ります。(6) このレスポンス・パケットが、インタコネクトに置かれ、要求側ノードに送られます。(7) 要求側ノードから応答側ノードに ACK のパケットが送られデータ転送処理が完了します。

CTI は SCI と同じように分割処理プロトコルを




図4 CTI リング

使っています。CTI の分割(split)とは、リクエスト・パケットとレスポンス・パケットとがまったく別のものであることを意味します。この分割処理プロトコルと ACK パケットの同時処理という観点から、「一番近いノード」とか「ホップリクエスト」という考え方は存在しません。もし、要求側ノードと応答側ノードがリング上のデータの流れに沿った方向で物理的に近く配置されているならば、リクエスト・パケットは短いパス、そして、レスポンス・パケットは、長いパスを通ります。逆に 2 つのノードが離れている場合は、リクエスト・パケットは長いパス、そして、レスポンス・パケットは、短いパスを通ります。結局、リクエスト・パケットとレスポンス・パケットが通るパスの長さの合計は、リング 1 周分になります。

• CTI キャッシュ

CTI のレイテンシを最少限にするために、各ノードは CTI キャッシュと呼ばれる、ローカルなキャッシュを備えています。インタコネクトを介してほかのノードのメモリから参照されたデータが、一時的にここに格納されます。CTI を介してアクセスしたデータは、すべていったん CTI キャッシュに入れられ、そのデータがノード内のどこかの CPU キャッシュにあるかぎり、CTI キャッシュに存在します。CTI キャッシュのディレクトリ情報から、その CTI キャッシュに入れられたグローバルデータが、現在どの CPU キャッシュに存在するかを知ることができます。CTI キャッシュは、グローバル物理アドレスをタグとしてもち、ソフトウェアのサポートを必要とせず、ハードウェアだけによるアドレッシングが行われます。S クラス、X クラスは、複数のハイパノード間でのキャッシュのコピーレンジを保証しています。つまり、同じグローバル・アドレスを参照している複数のハイパノードは、常に同じ値をみる

ことができます。これは、キャッシングラインを共有しているノードや、単独でキャッシングラインをもっているノードの情報をもっているリンクリストを使うことによって実現されています。また、どのプロセッサが CTI キャッシュ内のどのラインをもっているかについても記録しているため、ほかのノードから送られてきたコピーレンジの要求は、適切なプロセッサへ転送されます。


• ハードウェア GSM(Global Shared Memory)

X クラス・システムは、ハードウェアで GSM をサポートしています。ノード間を跨いで共有メモリを実現する場合の重要な機能になっています。もしこの機能がなければソフトウェア・コントロールでノードからノードへページを動かして共有メモリをエミュレーションする必要があり、大きなオーバーヘッドが生じることになります。このハードウェア制御によりオーバーヘッドが削減され、効率よくパラレル・アプリケーションを実行することができ分散共有型計算機のメリットを受けることができます。

5. おわりに

本文は昨年 HP で配布した冊子「Exemplar Technical Server ファミリ」の紹介記事および以下のサイト情報を参考にして本特集の趣旨に合うように加筆再構成をしたものです。この冊子にはソフトウェア関連も含めて総合的に紹介されていますので Exemplar にご興味をもたれましたらお問い合わせください。また Exemplar S/X クラスの最新情報は U.S の公開サイト <http://www.convex.com> でも紹介されています。

(平成 9 年 3 月 31 日受付)



北川 一三

1962 年生。1986 年日本大学工学部建築工学科卒業。卒業後リアルタイム計測アプリケーションソフトウェアの開発に携わる。1991 年コンカレント日本(株)に入社。引き続き建築、自動車関連を中心にリアルタイム実験計測アプリケーションを開発。1996 年に日本コンベックスコンピュータ(株)に入社。同年合併により日本 Hewlett Packard(株)へ移籍し、現在 TCBU Advanced Technology Center 所属。