

DSMシステムにおける投機的コヒーレンス制御機構の提案と評価

古川 文人[†] 多田野 陽介[†] 乗 貞 由 華[†]
大津 金光[†] 馬場 敬信[†]

本稿では、ハードウェアによる Cache Coherent DSMシステムにおいて、新たな投機的コヒーレンス制御機構を提案する。本機構の目的は、readとwriteの両方の種類のメモリアクセスにより発生するコヒーレンス制御のオーバーヘッドを削減することである。本機構を備えたDSMシステムを評価した結果、従来の投機的コヒーレンス制御機構を備えたものに対して最大1.97倍の性能向上を得られることがわかった。

A Speculative Coherence Control Mechanism for DSM Systems

FUMIHITO FURUKAWA,[†] YOUSUKE TADANO,[†] YUKA NORISADA,[†]
KANEMITSU OOTSU[†] and TAKANOBU BABA[†]

In this paper, we propose a new speculative coherence control mechanism for hardware DSM systems. Our purpose is to reduce the overhead of coherence control caused by the both memory accesses of read and write. We have evaluated the performance of the DSM system that equips our mechanism. As a result, we have found that the DSM system can achieve up to 1.97 times better performance than that of the DSM system that equips the conventional speculative coherence control mechanism.

1. はじめに

分散共有メモリ（以下、DSM）は、1)ハードウェア構成の優れたスケーラビリティ、2)プログラミングが容易な共有メモリモデルの2つの特徴を持つメモリアーキテクチャである。このため、メモリアーキテクチャにDSMを採用した並列システム（以下、DSMシステム）の研究が数多く行われている。¹⁾

DSMシステムでは、リモートメモリへのアクセス（以下、リモートアクセス）が相互結合網を介した通信処理で実現される。このため、リモートアクセスが発行されてから完了するまでのレイテンシ（以下、リモートレイテンシ）はローカルメモリへのものと比較して格段に長い。そこで、現在では各ノードでリモートメモリ上のデータをキャッシュし、かつ各キャッシュ間でのデータの一貫性をディレクトリ法により維持するDSMシステム（以下、CC-DSMシステム）が提供されるようになった。しかし、真に共有しているデータへのアクセスでは相互結合網を介した通信は本質的に避けられず、リモートレイテンシはローカルメモリ上の非共有データへのものに対して3~9倍程度^{2),3)}と長い。これは、ノード内外の間に著しい動作速度の差が予測される将来ではより深刻な問題となる。この

問題解決へのアプローチは、リモートレイテンシの隠蔽と削減の2つに大別できる。

リモートレイテンシの隠蔽手法として、緩和されたメモリコンシステンシモデル⁴⁾によるメモリアクセスのバッファリングおよびバイライン処理がある。また、マルチスレッド処理^{5),6)}による演算と通信処理のオーバーラップが研究されている。これらの手法ではユーザへのAPIの提供とそれを用いた特別なプログラミングを要求し、それをサポートするコンパイラまたはランタイムライブラリの開発が必要となる。

一方、リモートレイテンシの削減手法として、ソフトウェアまたはハードウェアによるキャッシュラインのプリフェッチがある。しかし、いずれの実現方法においてもプログラムにおいてアクセスが可能になる時点（以下、同期点）より以前にプリフェッチを行うことはできない。そこで、ハードウェアによるCC-DSMシステムにおいて、同期点以前にコヒーレンス制御を行う投機的コヒーレンス制御に関する研究^{7)~11)}が行われている。この手法の目的は、コヒーレンス制御のオーバーヘッド（以下、コヒーレンスオーバーヘッド）を軽減することで、リモートレイテンシを削減することである。投機的コヒーレンス制御は、データの共有状態を動的に予測し、その予測情報を基に行われる。予測のための処理と投機的コヒーレンス制御はユーザには完全に透過な専用ハードウェアが行う。したがって、ユーザに提供するプログラミング環境への影響は

[†] 宇都宮大学工学部
Faculty of Engineering, Utsunomiya University

全くない。

本稿では、ハードウェアによる CC-DSM システムにおいて、新たな投機的コヒーレンス制御機構を提案する。この機構の目的は、read と write の両方の種類のメモリアクセスにより発生するコヒーレンスオーバーヘッドを完全に除去することである。なお、以降ではハードウェアによる CC-DSM システムのことを単に DSM システムと呼ぶ。

以下、2 章では、本研究の背景と新規性を述べる。3 章では、提案する投機的コヒーレンス制御機構について述べる。4 章では、評価を行い、5 章でまとめる。

2. 研究背景

投機的コヒーレンス制御によってコヒーレンスオーバーヘッドの軽減を目指す研究は、それらが対象にするメモリアクセスの種類で大きく分類することができる。本章では、これらの研究を分類して概要を述べたあと、本稿で提案する新たな投機的コヒーレンス制御機構の新規性を示す。なお、以降ではメモリアクセスを発行したプロセッサを持つノードをマスタ、マスタの要求したアドレスと対応するメモリを持つノードをホーム、キャッシュにそのコピーを持つノードをスレーブと呼ぶ。また、マスタ内のプロセッサが発行したメモリアクセスにおいて、read アクセスがミスヒットしたときに起きるホームへの要求を read 要求、write アクセスがミスヒットしたときに起きるホームへの要求を read-ex 要求、read 要求により既に保持しているコピーへ write アクセスしたときに起きるホームへの要求を upgrade 要求と呼ぶ。

read アクセスのみを対象にした投機的コヒーレンス制御に関する研究として、Self-Cleanup Cache⁷⁾ (以下、SCC) と Speculative Write-Invalidation⁸⁾ (以下、SWI) が挙げられる。SCC を持つノードで構成した DSM システムでは、ホームへ書き戻すスレーブ上のダーティなキャッシュライン (以下、ライン) と書き戻すタイミングをスレーブ自身が予測し、予測したラインをホームへ投機的に書き戻す。これにより、マスタの read 要求がホームに到着する以前に、この投機的な書き戻しが完了している場合、その read 要求のコヒーレンス処理内で書き戻しに要する時間が完全に除去される。また、SWI を行う DSM システムでは、ホームへ書き戻すスレーブ上のラインとそのタイミングをホームが予測し、スレーブに対して投機的に書き戻しの要求をする。さらに、この書き戻しが完了した後、ホームはそのラインを参照するマスタを予測し、投機的に送信する。これにより、マスタがホームへ read 要求をする以前に、この投機的なホームへの書き戻しとマスタへの送信が完了している場合、その read 要求の全てのコヒーレンス処理に要する時間が完全に除去される。

read と write の両方の種類のメモリアクセスを対象

にした投機的コヒーレンス制御に関する研究として、Self-Invalidation⁹⁾ (以下、SI) とメモリアクセス命令の履歴を基にした予測による機構¹⁰⁾ (以下、IBP) が挙げられる。SI は、スレーブ上の無効化するラインとそのタイミングをスレーブ自身が予測して無効化する。また、予測したラインがダーティな状態であるときは、ホームへ投機的に書き戻した後で無効化する。これにより、マスタの read 要求、read-ex 要求、upgrade 要求がホームに到着する以前に、この投機的な無効化およびホームへの書き戻しが完了している場合、その要求のコヒーレンス処理内で無効化および書き戻しに要する時間が完全に除去される。また、IBP は、producer-consumer sharing と migratory sharing の 2 つの共有状態 (以下、それぞれ PC 共有状態、M 共有状態) を予測することにより投機的コヒーレンス制御を行っている。PC 共有状態にあるデータは producer であるノード (以下、生産者) が検出し、生産者が consumer であるノード (以下、消費者) を予測する。生産者は共有データを更新した後、予測した消費者へ投機的に対応するラインを送信する。これにより、マスタが消費者、スレーブが生産者のとき、SWI と同様にコヒーレンス処理に要する時間が完全に除去される場合がある。すなわち、read アクセスを対象にしている。また、M 共有状態にあるデータへのアクセスはマスタが予測し、マスタ内のプロセッサがそのデータへの read アクセスを発行したとき、ホームに対して read 要求ではなく read-ex 要求を行う。これにより、read アクセスに続いて write アクセスを行った場合、write アクセスによるコヒーレンス処理が不要になる。

ここで、SCC、SWI、SI、IBP が対象にしているメモリアクセスについて以下の 4 つに分類できる。なお、以降では PC 共有状態にあるデータを PC 共有データ、M 共有状態にあるデータを M 共有データと呼ぶ。

- (1) PC 共有データへの消費者による read アクセス
- (2) PC 共有データへの生産者による write アクセス
- (3) M 共有データへの read アクセス
- (4) M 共有データへの write アクセス

(1) の SWI および IBP によるサポート、(3) の SWI によるサポート、(4) の IBP によるサポートは、それらのメモリアクセスのコヒーレンスオーバーヘッドを完全に除去できる可能性がある。しかし、(2) のコヒーレンスオーバーヘッドを完全に除去できるサポートは無い。以上をまとめると、read アクセスのコヒーレンスオーバーヘッドの完全な除去ができる投機的コヒーレンス制御機構として SWI が存在する。しかし、read と write の両方の種類のメモリアクセスを対象とし、それらのコヒーレンスオーバーヘッドの完全な除去を目指した研究は存在しない。

本稿で提案する投機的コヒーレンス制御機構は、read と write の両方の種類のメモリアクセスにより発生するコヒーレンスオーバーヘッドの完全な除去を目指す

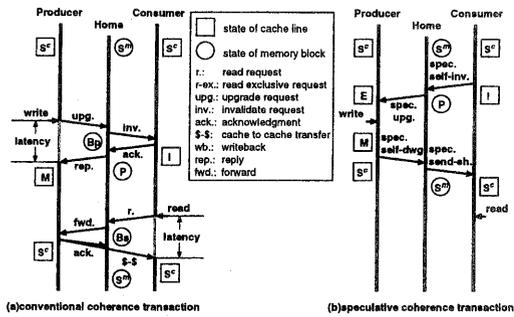


図4 PC共有状態における投機的コヒーレンス処理の例

ピーを既に保持するノードが自身のキャッシュに対して発行し、そのコピーの状態をS^cに遷移させる。その後、コピーの状態がS^cに遷移したことをホームに対して通知する。また、保持しているコピーの状態がMのときは、その内容をホームに対して書き戻す。

speculative self-invalidation (以下, spec.self-inv.) は、PC共有データへのwriteアクセス、およびM共有データへのreadとwriteの両方のメモリアクセスによって発生するコヒーレンスオーバーヘッドを軽減するための処理である。spec.self-inv.は、コピーを既に保持するノードが自身のキャッシュに対して発行し、そのコピーを無効化する。その後、コピーを無効化したことをホームに対して通知する。また、保持していたコピーの状態がMのときは、その内容をホームに対して書き戻す。

speculative send block in shared state (以下, spec.send-sh.) は、PC共有データへのreadアクセスによって発生するコヒーレンスオーバーヘッドを軽減するための処理である。spec.send-sh.は、ホームにおいてS^mの状態のメモリブロックに対してread要求を発行するノードを予測し、そのノードに対してS^cの状態のコピーを送信する。それと同時に、予測されたノードがS^cの状態のコピーを保持していることをDSMコントローラに対して通知する必要がある。

speculative send block in exclusive state (以下, spec.send-ex.) は、M共有データへのreadおよびwriteアクセスによって発生するコヒーレンスオーバーヘッドを軽減するための処理である。spec.send-ex.は、ホームにおいてUの状態のメモリブロックに対してread要求に引き続きread-ex要求を発行するノードを予測し、そのノードに対してEの状態のコピーを送信する。それと同時に、予測されたノードがコピーを専有し、その内容がメモリブロックと一致しない可能性があることをDSMコントローラに対して通知する。

speculative upgrade (以下, spec.upg.) は、PC共有データおよびM共有データへのwriteアクセスによって発生するコヒーレンスオーバーヘッドを軽減するための処理である。spec.upg.は、ホームにおいて

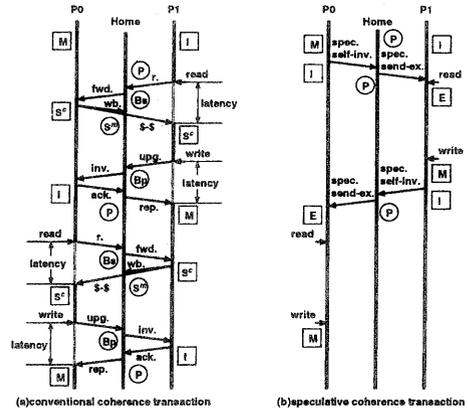


図5 M共有状態における投機的コヒーレンス処理の例

S^mの状態のメモリブロックに対してupgrade要求を発行するノードをS^cの状態のコピーを持つノードの中から予測し、そのノードに対してEの状態への遷移を許可したことを通知する。それと同時に、予測されたノードがコピーを専有し、その内容がメモリブロックと一致しない可能性があることをDSMコントローラに対して通知する。

図4, 図5は、コヒーレンス処理の流れを示したものである。図4(a), 図5(a)は、それぞれPC共有データおよびM共有データへのメモリアクセスを従来のコヒーレンス処理で解決する実行の例である。また、図4(b), 図5(b)は、いずれも上記の投機的コヒーレンス処理により、コヒーレンスオーバーヘッドを完全に除去できた実行の例である。

3.3 SCCMの概要

SCCMの構成を図6に示す。SCCMは、SDIG (Speculative self-Downgrade and self-Invalidation Generator), SSUG (Speculative Send block and Upgrade Generator), SRC (Speculative Remote Cache) および SCoC (Speculative Coherence Controller) から構成される。

3.3.1 SDIG

SDIGは、spec.self-dwg.およびspec.self-inv.の発行のタイミングと対象となるラインのアドレスを予測し、SCoCに対してそれを伝える。この予測器としてSCM⁷⁾およびLTP⁹⁾を応用することができる。本稿では、LTPの応用を想定している。LTPは、spec.self-dwg.もしくはspec.self-inv.のどちらか一方に関する予測器である。例えば、spec.self-inv.に関する予測は、無効化要求とそのラインへのメモリアクセス命令のトレース (以下, アクセストレース) を観測することで行う。また、予測の信頼性を確保するために、予測の成功/失敗を知らせる情報 (以下, 予測検証情報) から予測を行うか否かの判断を行う。LTPは、無効化要求のあったラインのアドレスをインデックスとして、そのラインに対する前回の無効化の直後から現在の無効化

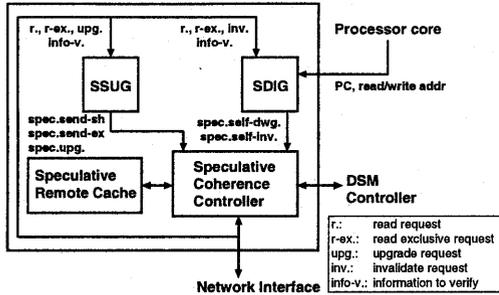


図6 SCCMの構成

の直前までのアクセスト्रेसを履歴として蓄積する。この履歴と現在観測しているアクセスト्रेसが一致したときをそのラインに対して spec.self-inv. を発行するタイミングと予測する。SDIGは、spec.self-dwg. と spec.self-inv. の両方に関して予測するため、履歴の各エントリにそのどちらかを識別するビットを持つ。

3.3.2 SSUG

SSUGは、spec.send-sh., spec.send-ex. および spec.upg. の発行のタイミングと対象となるメモリブロックのアドレスを予測し、SCoCに対してそれを伝える。この予測器にはCosmos¹¹⁾ およびMSP⁸⁾ を利用できる。本稿では、MSPの利用を想定している。MSPは、自ノードのメモリブロックに対する要求を監視し、そのアドレスをインデクスとして、要求の種類と発行元のノードの識別子を履歴として蓄積する。現在観測した要求とその対象であるアドレスからこの履歴を検索し、次に観測している要求の種類と発行元のノードの識別子を予測結果として出力する。SSUGは、この予測結果の要求の種類がread要求、read-ex要求、upgrade要求のときを、それぞれ対応するノードに対して spec.send-sh., spec.send-ex., spec.upg. を発行するタイミングと予測する。また、SDIGと同様に、予測検証情報を予測結果に反映する。

3.3.3 SRC

SRCは、spec.send-sh., spec.send-ex. によりホームから送信されたコピーを適切な状態で保持するキャッシュである。また、SRCは各コピーの参照の有無を管理し、そのコピーが無効化されたとき、予測検証情報としてホームに対して送信する。

3.3.4 SCoC

SCoCは、DSMコントローラに対して仮想的なNIとして動作し、SDIG、SSUGが予測した投機的コヒーレンス処理をDSMコントローラのサポートするプロトコルを用いて発行する。以下に、各投機的コヒーレンス処理におけるSCoCの動作を示す。

- spec.self-dwg., spec.self-inv.
自ノードのラインに対してそれぞれread要求、無効化要求を発行し、その応答をそれぞれspec.self-dwg., spec.self-inv. である情報を付加してホームへ転送する。これを受信したホームのSCoCは、そ

表1 シミュレーションパラメータ

ノード数	16
プロセッサコア	4-way スーパースカラ
キャッシュ	
ラインサイズ	64B
命令キャッシュ	完全ヒット
データキャッシュ	
サイズ	無制限
アクセスレイテンシ	1MC
最大未解決ミス数	8
メモリアクセスレイテンシ	40MC
ネットワーク	
メッセージヘッダサイズ	16B
トポロジ	2D-メッシュ
リンク幅	8B
1ホップ	4MC

のラインの置換の通知としてDSMコントローラに伝える。また、このホームのSCoCは、spec.self-dwg および spec.self-inv. が発行されたメモリブロックに関して、そのタイミングが早すぎたか否かの情報を管理し、予測検証情報としての発行元に送信する。

- spec.send-sh., spec.send-ex.
自ノードのメモリブロックに対して仮のノードからの要求としてそれぞれread要求、read-ex要求を発行し、その応答をそれぞれspec.send-sh., spec.send-ex. である情報を付加して予測されたノードへ転送する。これを受信したノードのSCoCは、そのコピーをSRCに保存する。
- spec.upg.
自ノードのメモリブロックに対して予測されたノードからの要求としてupgrade要求を発行する。
また、SCoCはDSMコントローラからのリモートノードへのread要求およびread-ex要求を観測した場合は、SRCが要求しているデータを既に保持しているかをチェックする。もし、保持していれば、そのデータを応答としてDSMコントローラに返し、保持していなければ、その要求をNIへ転送する。

4. 評価

本章では、readアクセスのみをサポートするSWIと比べて、readとwriteの両方をサポートするSCoCの性能向上がどの程度かを実験により明らかにする。

4.1 評価方法

評価は、表1に示すDSMシステムのモデル上でSPLASH-2¹²⁾のFFTの一部をCC-NUMA型並列計算機シミュレータRSIM¹³⁾でシミュレーションすることにより行った。

シミュレーションを行った部分は、FFT内の転置行列を作成するフェーズ（以下、転置行列作成フェーズ）である。このフェーズ内の大部分の処理は、PC共有データに対するreadおよびwriteアクセスである。こ

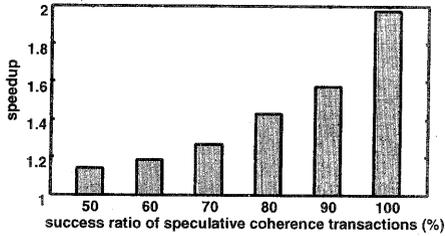


図7 FFT内の転置行列作成フェーズの性能向上比

のフェーズをSWIおよびSCCMでサポートしたときのそれぞれの実行時間を投機的コヒーレンス処理の成功率を50%から100%へ変化させて計測した。なお、投機的コヒーレンス処理の成功率 p は、以下の式で与えられる値である。

$$p = \frac{a-b}{a} \times 100 (\%)$$

ここで、 a は投機的コヒーレンス制御をしない場合にコヒーレンス処理を必要としたメモリアクセスの総数、 b は投機的コヒーレンス制御をした場合にコヒーレンス処理を必要としたメモリアクセスの総数である。

4.2 評価結果

図7に、転置行列作成フェーズのSCCMによる性能向上比を示す。この性能向上比は、SWIによる投機的コヒーレンス制御をした場合の実行速度を基準とした。この結果から、投機的コヒーレンス制御の成功率が50%以上の場合、SCCMを備えたDSMシステムがSWIを備えたものに対して1.14~1.97倍の性能向上を得られることがわかる。

5. まとめ

本稿では、ハードウェアによるCC-DSMシステムにおいて、新たな投機的コヒーレンス制御機構SCCMを提案した。また、本機構を備えたDSMシステムを評価した結果、SCCMを備えたDSMシステムがSWIを備えたものに対して1.14~1.97倍の性能向上を得られることがわかった。

今後は、提案した機構の詳細なシミュレーション環境を構築し、プログラム全体の実行を通して性能評価を行う予定である。

謝辞 本研究は、一部文部省科学研究費基盤研究(B)課題番号10558039、基盤研究(C)課題番号12680328の援助によるものである。

参考文献

- Keleher, P. J.: Distributed Shared Memory Home Pages. <http://www.cs.umd.edu/~keleher/dsm.html>.
- 細見岳生, 加納健, 中村真章, 広瀬哲也, 中田登志之: 並列計算機Cenju-4の分散共有メモリ機構, 並列処理シンポジウムJSP'99論文集, pp. 15-22 (1999).
- Laudon, J. and Lenoski, D.: The SGI Origin: A ccNUMA Highly Scalable Server, *Proceedings of the 24th Annual International Symposium on Computer Architecture* (1997).
- Adve, S. V. and Gharachorloo, K.: Shared Memory Consistency Models: A Tutorial, Technical Report 9512, Rice University ECE (1995).
- Fillo, M., Keckler, S. W., Dally, W. J., Carter, N. P., Chang, A., Gurevich, Y. and Lee, W. S.: The M-Machine multicomputer, *Proceedings of the 28th Annual International Symposium on Microarchitecture*, pp. 146-156 (1995).
- 佐藤三久, 児玉祐悦, 坂井修一, 山口喜教: 並列計算機EM-4の細粒度通信による共有メモリの実現とマルチスレッドによるレーテンシ隠蔽, 情報処理学会論文誌, Vol. 36, No. 7, pp. 1669-1679 (1995).
- 森眞一郎, 福島直人, 五島正裕, 中島浩, 富田眞治: Self-Cleanup Cacheの提案, 情報処理学会論文誌, Vol. 38, No. 2, pp. 321-331 (1997).
- Lai, A. and Falsafi, B.: Memory Sharing Predictor: The Key to a Speculative Coherent DSM, *Proceedings of the 26th Annual International Symposium on Computer Architecture* (1999).
- Lai, A. and Falsafi, B.: Selective, Accurate and Timely Self-Invalidation Using Last-Touch Prediction, *Proceedings of the 27th Annual International Symposium on Computer Architecture* (2000).
- Kaxiras, S. and Goodman, J. R.: Improving CC-NUMA Performance Using Instruction-Based Prediction, *Proceedings of the Fifth International Symposium on High-Performance Computer Architecture*, pp. 161-170 (1999).
- Mukherjee, S.S. and Hill, M.D.: Using Prediction to Accelerate Coherence Protocols, *Proceedings of the 25th Annual International Symposium on Computer Architecture*, pp. 179-190 (1998).
- Woo, S. C., Ohara, M., Torrie, E., Singh, J. P. and Gupta, A.: The SPLASH-2 Programs: Characterization and Methodological Considerations, *Proceedings of the 22th Annual International Symposium on Computer Architecture*, pp. 24-36 (1995).
- Pai, V. S., Ranganathan, P. and Adve, S. V.: RSIM: An Execution-Driven Simulator for ILP-Based Shared-Memory Multiprocessors and Uniprocessors, *Proceedings of the Third Workshop on Computer Architecture Education* (1997).