DEIM Forum 2019 XX-Y

並列データベース問合せ処理における動的対ノード故障耐性に関する検討

別所祐太朗[†]　早水　悠登[††]　合田　和生[††]　喜連川　優[††,†††]

† 東京大学 大学院情報理工学系研究科 〒 113-8656 東京都文京区本郷 7–3–1
†† 東京大学 生産技術研究所 〒 153–8505 東京都目黒区駒場 4–6–1
††† 国立情報学研究所 〒 101–8430 東京都千代田区一ツ橋 2–1–2
E-mail: †{bessho,haya,kgoda,kitsure}@tkl.iis.u-tokyo.ac.jp

あらまし　データ分析アプリケーションの取り扱うデータベースの容量は年々増加し, クエリの実行は長時間に渡ることがある. このようなワークロードに対しては並列処理環境の利用が一つの有効な手法であるが, 処理ノードの増加に従い障害が発生する確率が無視できなくなる恐れがある. 既存の並列データベースシステムでは障害発生後にクエリ全体を再実行するのが一般的であり, ユーザに大きく時間的ペナルティを課することとなる. 本研究は, 共有ストレージアーキテクチャの並列データベースシステムを対象とし, クエリの進捗を追跡することにより, 障害発生時に他ノードが処理を引き継ぐ手法を検討するものである. 本稿では, 共有ストレージ上のテーブルの並列フルスキャンに関する進捗の追跡手法を提案する.

キーワード　並列データベース, 耐故障性

1 は じ め に

データマイニングや BI ツールによる意思決定など, データの統計的分析を行うシステムは多様な場面で利用される. 日々蓄積されるデータを対象として構築されるデータベースは容量が増加する傾向にあり, 近年ではペタバイトオーダーのものも珍しくない.

大規模なテーブルに対する統計的クエリ処理は長時間を要することがあるため [1], 多数のノードを利用してテーブルに対して並列に処理を行う並列データベースシステムの利用は, Hadoop システムの利用 [2] と並び, 一般的なアプローチの一つとなっている.

多数の並列ノードを擁する計算機環境においては, クエリの実行中にいずれかのノードが故障する確率が無視できなくなる可能性が高い. 特に, 並列データベースの処理は通常パイプライン化されているため, それまでの進捗に関わらず, ノード故障の後にクエリ全体を初めから再実行するのが一般的である. 大規模なデータベースを構築することでクエリが長時間化する場合, クエリの完全な再実行に伴うユーザへの時間的ペナルティはアプリケーションの利便性を損ねる恐れがある.

ノードの故障に際してクエリを続行する研究は, ストリームデータ処理システム [3], [4] やグリッド環境 [5] の他に, 並列データベースシステムを対象としたものも存在する [6], [7], [8]. しかし, いずれも非共有ストレージ環境を前提としており, 共有ストレージ環境を取り扱った研究は筆者の知る限りなされていない.

本研究は, 共有ストレージアーキテクチャの環境において, クエリ処理の進捗を追跡することで, 故障ノードの処理を他ノードが引き継ぐ手法を提案する. 本稿では, 共有ストレージ上のテーブルに対する並列のフルスキャンを追跡する手法を提案する.

本稿の構成は次の通りである. まず, 第 2 章では現在主流の並列データベースアーキテクチャを紹介し, 本研究が対象とする共有ストレージ方式におけるテーブル読み出し方式について説明する. 続いて, 第 3 章では, 本稿で提案する並列フルスキャンの進捗の追跡手法を, テーブルの読み出し方式別に述べる. 第 4 章で現在の課題を示し, 第 5 章で本稿を総括する.

2 並列データベースシステムと故障

本章では, 本研究が対象とする共有ストレージ方式の並列データベースアーキテクチャとその特徴について説明したのち, ノード障害が発生した際の既存のシステムにおける問題点について述べる.

2.1 共有ストレージ方式と非共有ストレージ方式

現在の並列データベースシステムアーキテクチャとしては通常, 非共有ストレージ (Shared nothing) 方式, あるいは共有ストレージ (Shared storage) 方式の 2 種類が用いられる.

非共有ストレージ方式においては，各ノードに独立したストレージが接続される (図 1(a))．共有ストレージ方式のように Storage Area Network (SAN) を用意する必要がなく，安価に構築が可能である．また, 各ノードのデータアクセスが直接接続されたストレージに集中するため, DBMS はノード間のアクセスの衝突を調停する必要がなく, 実装が単純であるという利点も存在する.

共有ストレージ方式においては，複数のノードが単一のストレージに接続される (図 1(b))．全てのノードがストレージの

全空間にアクセスできるため, ストレージ領域の利用効率が高い. また, アプリケーション開発においてストレージ上のテーブルの配置を考える必要がないという利便性や, 負荷分散の柔軟性 [9] も利点として挙げられる.

本研究は, 共有ストレージ方式の並列データベースを対象とする.

2.2 共有ストレージ方式における並列読み込み

並列データベースシステムのクエリ処理においては, 複数ノードが単一のファイル (ここではテーブル) を並行して読み込むことが多い. 共有ストレージ方式において用いられる読み込みの方法は，partitioned read と on-demand read の 2 種類に大別される.

Partitioned read 方式 (図 2(a)) では, ファイル全体が連続した領域の断片 (パーティション) に分割され，各処理ノードが各領域を先頭から順番に読み出す．読み出しオフセット (ファイルオフセット, あるいはテーブルのキー) は，各パーティションごとに管理される．この方式では, 各処理ノードのワークロードが静的に決定されている. 非共有ストレージ方式における読み出しは，各ストレージをパーティションとみなした時, partitioned read 方式とみなすことができる.

On-demand read 方式 (図 2(b)) では, 全処理ノードが読み出しオフセットを共有し, 各処理ノードが発行する読み出しリクエストに応じて，未読み出しの領域がノードに与えられる. この方式では, 各処理ノードが読み出す領域は動的に決定する. すなわち, 試行ごとに各ノードが読み出す領域は必ずしも同じにはならない.

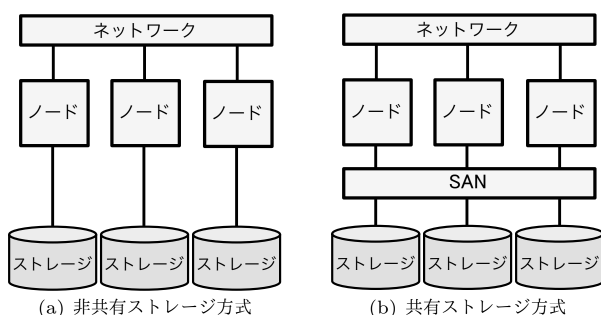

(a) 非共有ストレージ方式　(b) 共有ストレージ方式

図 1　並列処理データベースアーキテクチャの比較

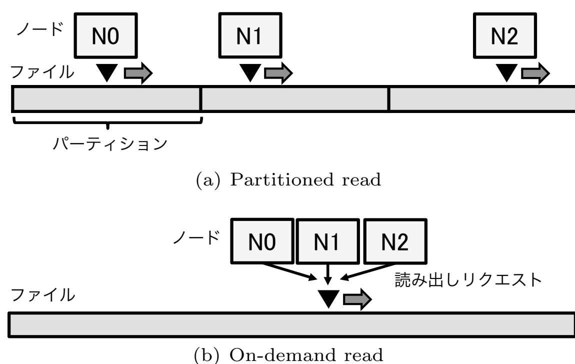

(a) Partitioned read

(b) On-demand read

図 2　並列データベースシステムにおけるファイル読み出し

2.3 ノード故障による問題

並列データベースシステムは多数の処理ノードを擁するため, クエリ処理の実行中に一部のノードが故障する可能性が無視できない. 故障したノードはファイルの読み出しおよび処理済データの出力を停止するので, 実行を続けると得られる処理結果は誤ったものになってしまう.

一つの方法として, クエリの処理中にノードの故障が見られた場合はクエリを最初から再実行するというものがある. しかし, 大規模データを取り扱う分析的クエリは処理時間が長く, 再実行による時間的コストが許容できない場合がある. 他の方法として, ノードが故障した際の進捗状況を始点としてクエリの実行を再開するものが考えられる. そのためには, 故障したノードが処理できなかったワークロードを他の何らかのノードが正確に特定し, 代替ノードに担当させる必要がある. 本研究は, 共有ストレージ方式においてクエリ実行の進捗状況を追跡する手法を提案するものである.

3 共有ストレージ方式における耐故障クエリ実行方式の検討

本章では, 共有ストレージ環境における並列データベースシステムにおいて, クエリ実行の進捗状況を追跡する手法を検討する. これによって, ノードが故障した場合においても, 他の idle なノード, あるいは事前に設定された代替ノードが故障ノードが行えなかったワークロードを特定して実行することができる.

本稿では, 共有ストレージ上に保存されたテーブルを入力とする並列フルスキャン処理の進捗を追跡する手法を取り扱う. 読み出しの方法として paritioned read を適用した場合について, 次に on-demand read を適用した場合について述べる. ストリーミングされたレコード群を入力とする処理については今後の検討課題とする.

3.1 Partitioned read における並列フルスキャンの追跡

並列データベースにおいて, 共有ストレージ上のテーブル全体を paritioned read 方式でスキャンしてから, 集計を行うワークロードについて考える. スキャンと集計は同じノード群で行うこととする. 各ノードでは, スキャンプロセス (scanner) によってスキャンされたレコードが中間バッファを経て, 下流のプロセス, ここでは集計プロセス (aggregator) に渡される.

処理対象のテーブルの各レコードの状態は次のように 3 つに分類できる. 故障ノードのワークロードを他のノードに代替させるには, 各レコードがどの状態であるかを把握することが必要である.

- 未要求状態 (unrequested). どの処理ノードにも読み出しが要求されていない.
- 未承認状態 (unacknowledged). 処理ノードに読み出しリクエストされたが, ノードに読み出され処理されていない, あるいは処理結果が下流処理ノードへの入力として確定するに至っていない.
- 承認状態 (acknowledged). 処理が既に終了し, 処理結果

が下流処理ノードへの入力として確定した.

Partitioned read 方式におけるレコードの要求・承認プロトコルは以下の通りである. 図 4(a) に図解する.

（1） 処理ノードがストレージコントローラにスキャン処理の開始を通知する. すると, 全レコードは未要求状態から未承認状態になる. ストレージコントローラは, 各パーティションの分割アドレスを設定し, その情報を処理ノードに送信する. 以下, 各処理ノードが (2) から (7) を繰り返す.

（2） スキャンプロセスが, パーティションの分割情報を利用して, 共有ストレージにレコードのデータを要求する. 共有ストレージが, 対象のレコードを処理ノードに返す.

（3） スキャンプロセスが, 処理後のデータを下流処理ノード (ここでは集計プロセス) との中間バッファに送信する.

（4） ある程度の数のレコードを送信したら, 集計プロセスに送信データを入力として承認することを要求する.

（5） 集計プロセスが要求されたデータを入力として取り込む.

（6） 集計プロセスがスキャンプロセスに承認を通知する.

（7） 送信したレコードの承認の通知を受け取ったスキャンプロセスが, ストレージコントローラの管理表における対象レコードの状態を未承認から承認に管理表を更新するよう通知する.

レコードの状態遷移を図 3(a) に示す. 全レコードに対して状態を管理する方法例として次のようなものが考えられる. レコードは番号順に下流の処理プロセスに送られるという仮定を置くと, 何番目のレコードまでが承認状態であるかを常に記録しておけば, ノードの障害発生時, 代替ノードが未承認状態のレコードを順番に読み出すことで処理を再開できる.

例えば, レコード数 1000 のテーブルを 3 つのノードでスキャンする場合を考える. まず, テーブルは 3 つのパーティションに分割される. このとき, ストレージのコントローラに図 5(a) のような管理表を用意すればよい. partition head は, 各パーティションの先頭のレコード番号, last ACKed は最後に承認されたレコード, すなわち, 承認状態と未承認状態のレコードの境界を示している. 例えば図 5(a) の状態で node id が 1 のノードが故障したら, 代替ノードは 453 番目のタプルから読み出しを行えばよい.

3.2 On-demand read における並列フルスキャンの追跡

次に, 共有ストレージ上のテーブル全体に対し on-demand read 方式でスキャン及び集計を行うワークロードについて考える. 処理ノードの構成は前章と同じであるとする.

Paritioned read 方式では, レコードがどのノードに読み出されるかは静的に確定し, 他のノードに読み出されることは最後までない. したがって, テーブルのスキャン処理開始後は, 全てのレコードには既に読み出し要求がなされたものとみなせ, 未要求状態と未承認状態のみを管理すればよい. 一方, レコードを読み出すノードが事前に決定しない on-demand read 方式の場合, ノードが故障したら, 故障ノードが処理できなかったレコードを他のノードが読み出して処理できるようにする必要がある. そのために, 故障ノードの要求したレコードのうち未承認状態のものは未要求状態に戻すようにプロトコルを設定する. レコードの状態遷移を示した図を図 3(b) に示す.

On-demand 方式におけるレコードの要求・承認プロトコルは以下の通りである. 図 4(b) に図解する. 各処理ノードが以下の動作を繰り返す.

（1） 処理ノードのスキャンプロセスがレコードの読み出し要求をストレージコントローラに送信する. ストレージコントローラは管理表を参照し, 未承認状態のレコードから処理ノードが読み出すべきレコードのリストを選択し, ノードに返答する.

（2） 処理ノードは返答に従い, 共有ストレージに読み出し要求を送信する. 共有ストレージが, 対象レコードを読み出す.

（3） 処理ノードは対象レコードの読み出し完了をストレージコントローラに通知し, 対象レコードの状態を未要求から未承認に更新させる.

（4） スキャンプロセスによる処理が完了したデータを下流処理ノード (ここでは集計プロセス) との中間バッファに送信する.

（5） ある程度の数のレコードを送信したら, 集計プロセスに送信データを入力として承認することを要求する.

（6） 集計プロセスが要求されたデータを入力として取り込む.

（7） 集計プロセスがスキャンプロセスに承認を通知する.

（8） スキャンプロセスがストレージコントローラに, 管理表における対象レコードの状態を未承認から承認に更新するよう通知する.

テーブル上の全レコードに対して 3 状態を管理する方法として考えられる例を図 5(b) に示す. node id を処理ノードの番号として, requested ranges に各処理ノードが要求したレコードの集合を可変長セグメントのリストとして保存している. # of acks は, requested ranges のリストの先頭から数えて何個のレコードが承認状態にあるかを示す. requested list はテーブルの未承認レコードの一覧で, 読み出し要求可能なレコードを示す. 図では, 丁度 node id が 1 の処理ノードの故障が検知された状況を例示している. この時点で, requested ranges のリストのうち承認されているのは先頭 55 個のレコード (0-55) であり, 未承認のレコード (56-99, 300-399) を unrequested list に返却している. また, node id が 2 の処理ノードは番号 250-299 のレコードの承認を得たため, リストから 250-299 を削除し, 続いて 450-499 に対して処理および承認を要求する.

4 本研究の課題

目前の課題は大きく分けて 2 つある.

1 つ目は実験による仮説検証の必要性であり, 本稿で提案した並列フルスキャン追跡システムを実装し, 実際の計算機上の動作を観察して性能上の課題を探ることである.

中でも重要な検証事項は, on-demand read 方式におけるレコードの処理の粒度による性能トレードオフである. 処理ノードが一度に要求するレコード数を少なくすれば, 処理完了 (承

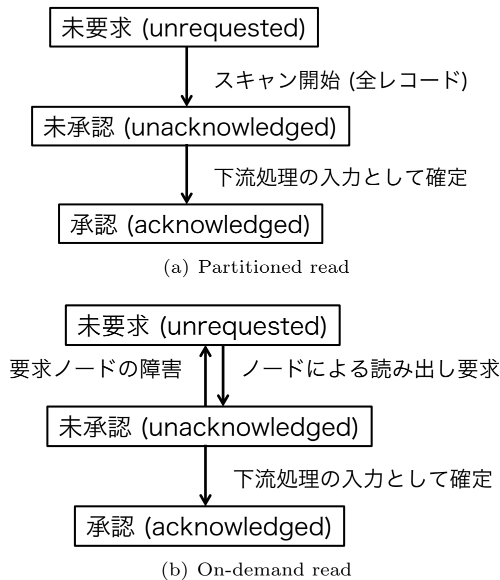

(b) On-demand read

図 3　耐ノード障害性のために管理するレコードの状態遷移

認) までの時間が短いためにすぐに次のレコードを要求できる．すると，ノードの性能のばらつきや配分されるワークロードの計算コストが違っても，処理時間が均等になるようレコードが配分されやすい．一方で，ストレージコントローラとの通信量が増加することや，I/O サイズが小さくなることによる効率低下が懸念される．

2 つ目は，手法の拡張の考察である．本稿で検討した手法は，select, nested loop join, index join など，中間データを生成しない処理に適用できるが，hash join などの中間データを生成する処理に対応する手法は未検討である．また，上流処理ノードからストリーミングされたテーブルを追跡する手法も考案する必要がある．

現在は並列フルスキャン追跡のプロトタイプ実装について実験を進めているところである．今回の DEIM では，その結果を含めて，提案手法の有効性を検証する予定である．

5　お わ り に

本研究は，共有ストレージアーキテクチャの並列データベースシステムにおいて，クエリの進捗をストレージコントローラで追跡させることで，障害発生時に他ノードに処理を引き継がせる手法を検討するものである．本稿では，共有ストレージ上のテーブルの並列フルスキャンに関する進捗を追跡する手法を提案した．

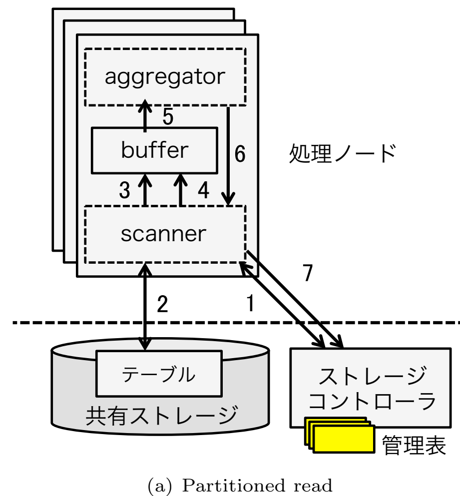

(a) Partitioned read

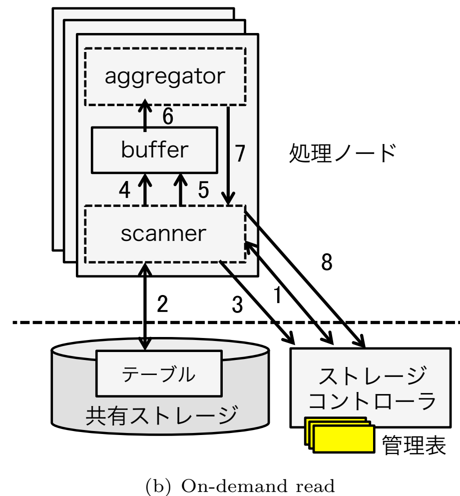

(b) On-demand read

図 4　共有ストレージ上の並列フルスキャンにおけるレコード状態の更新プロトコル

node id	partition head	last ACKed
0	0	100
1	334	452
2	667	80

(a) Partitioned read

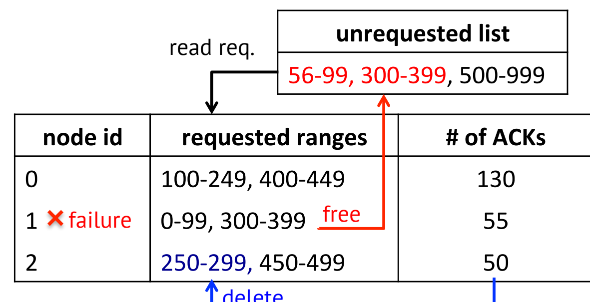

(b) On-demand read

図 5　進行中の並列フルスキャンにおける各レコードの状態管理の例

文　　献

[1] David Taniar. High performance database processing. In *Advanced Information Networking and Applications (AINA), 2012 IEEE 26th International Conference on*, pp. 5–6. IEEE, 2012.

[2] Paul Zikopoulos, Chris Eaton, et al. *Understanding big data: Analytics for enterprise class hadoop and streaming data*. McGraw-Hill Osborne Media, 2011.

[3] Mehul A Shah, Joseph M Hellerstein, and Eric Brewer. Highly available, fault-tolerant, parallel dataflows. In *Proceedings of the 2004 ACM SIGMOD international conference on Management of data*, pp. 827–838. ACM, 2004.

[4] J-H Hwang, Magdalena Balazinska, Alex Rasin, Ugur Cetintemel, Michael Stonebraker, and Stan Zdonik. High-availability algorithms for distributed stream processing. In *Data Engineering, 2005. ICDE 2005. Proceedings. 21st International Conference on*, pp. 779–790. IEEE, 2005.

[5] M Nedim Alpdemir, Arijit Mukherjee, Anastasios Gounaris, Norman W Paton, Paul Watson, Alvaro AA Fernandes, and Desmond J Fitzgerald. Ogsa-dqp: A service for distributed querying on the grid. In *International Conference on Extending Database Technology*, pp. 858–861. Springer, 2004.

[6] Stanislaw Bartkowski, Ciaran De Buitlear, Adrian Kalicki, Michael Loster, Marcin Marczewski, Anas Mosaad, Jan Nelken, Mohamed Soliman, Klaus Subtil, Marko Vrhovnik, et al. *High availability and disaster recovery options for DB2 for Linux, UNIX, and Windows*. IBM Redbooks, 2012.

[7] Jim Smith and Paul Watson. Fault-tolerance in distributed query processing. In *Database Engineering and Application Symposium, 2005. IDEAS 2005. 9th International*, pp. 329–338. IEEE, 2005.

[8] Binh Han, Edward Omiecinski, Leo Mark, and Ling Liu. Otpm: Failure handling in data-intensive analytical processing. In *Collaborative Computing: Networking, Applications and Worksharing (CollaborateCom), 2011 7th International Conference on*, pp. 35–44. IEEE, 2011.

[9] 合田和生, 田村孝之, 小口正人, 喜連川優. San 結合 pc クラスタにおけるストレージ仮想化機構を用いた動的負荷分散並びに動的資源調整の提案とその評価. 電子情報通信学会論文誌 D, Vol. 87, No. 6, pp. 661–674, 2004.