

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2013-161476

(P2013-161476A)

(43) 公開日 平成25年8月19日(2013.8.19)

(51) Int.Cl.

G06F 3/06 (2006.01)

F 1

G06F 3/06 306Z
 G06F 3/06 540
 G06F 3/06 301Z
 G06F 3/06 305C
 G06F 3/06 304R

テーマコード (参考)

審査請求 未請求 請求項の数 20 O L (全 21 頁)

(21) 出願番号 特願2013-2710 (P2013-2710)
 (22) 出願日 平成25年1月10日 (2013.1.10)
 (31) 優先権主張番号 13/368,725
 (32) 優先日 平成24年2月8日 (2012.2.8)
 (33) 優先権主張国 米国(US)

(71) 出願人 591007686
 エルエスアイ コーポレーション
 アメリカ合衆国カリフォルニア州9503
 5, ミルピタス, バーバー・レーン 16
 21
 (74) 代理人 100140109
 弁理士 小野 新次郎
 (74) 代理人 100075270
 弁理士 小林 泰
 (74) 代理人 100096013
 弁理士 富田 博行
 (74) 代理人 100092967
 弁理士 星野 修
 (74) 代理人 100096068
 弁理士 大塚 住江

最終頁に続く

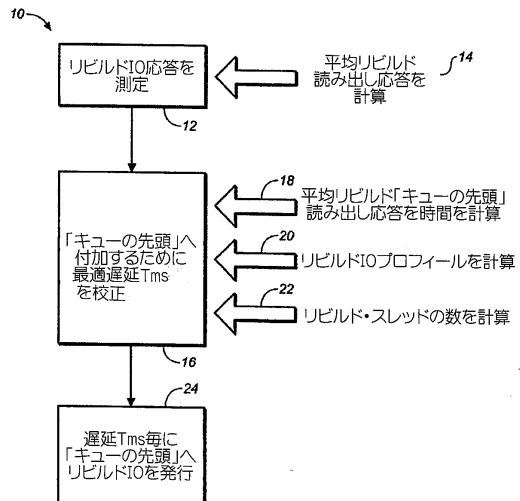
(54) 【発明の名称】 RAIDの再構築を改善するシステム及び方法

(57) 【要約】

【課題】 RAIDシステムにおけるディスクのリビルドの処理を改善する。

【解決手段】 ホストIOの処理が優先して行われる処理において、ストレージ・システムのドライブのリビルドIO応答を測定して、応答の平均時間を計算し（ステップ12）、「キューの先頭」に付加すべき遅延時間である最適遅延時間を校正し（ステップ16）、該最適遅延時間毎に、「キューの先頭」に対してリビルドIO要求を発行する（ステップ24）。ドライブのキューの先頭へ向けてリビルドIO要求を発行することにより、リビルドIOの処理が優先的に行われる。遅延時間は、ディスク・ヘッドの応答時間、リビルドに割り当てる時間、リビルド・スレッドの数、ドライブの挙動、リビルドIOのプロフィール、作業負荷及び局所性を含むホストIOのプロファイル、一連のイベントのタイムラインなどに基づいて計算される。

【選択図】 図1



【特許請求の範囲】**【請求項 1】**

複数のドライブを有し、ホスト I/O 条件のもとでの RAID のリビルド処理を改善するストレージ・システムであって、

前記ストレージ・システムの 1 つのドライブのリビルド I/O 応答を測定するファームウェアと、

前記 1 つのドライブのキューであって、リビルド I/O 要求及びホスト I/O 要求を含むキューと、

前記キューに対するリビルド I/O の発行を遅延させるファームウェアと
を備えることを特徴とするストレージ・システム。

10

【請求項 2】

請求項 1 に記載のストレージ・システムにおいて、該システムはさらに、

前記リビルド I/O の発行の遅延を較正するファームウェア
を備えるストレージ・システム。

【請求項 3】

請求項 2 に記載のストレージ・システムにおいて、前記遅延を較正するファームウェアは、前記キューからの平均リビルド応答時間、全時間のうちのリビルドに割り当たられる時間、及びリビルド・スレッドの数のパラメータに従って、遅延を較正するよう構成されていることを特徴とするストレージ・システム。

20

【請求項 4】

請求項 2 に記載のストレージ・システムにおいて、該システムはさらに、前記ファームウェアがどれだけ速くリビルドを行うかを示すリビルド・レートを有するファームウェアを備え、前記リビルド・レートは、最大値及び最小値を有し、前記最小値の場合は、前記最大値の場合と比べて、ホスト I/O がリビルド I/O よりも優先されることを特徴とするストレージ・システム。

【請求項 5】

請求項 4 に記載のストレージ・システムにおいて、前記リビルド・レートを有するファームウェアにおける前記リビルド・レートはコンフィギュレーション可能であり、前記リビルド・レートを有するファームウェアが、前記最小値から前記最大値までの範囲で幾つかの所定の値をとることができるリビルド・レートを有することができるよう構成されていることを特徴とするストレージ・システム。

30

【請求項 6】

請求項 2 に記載のストレージ・システムにおいて、前記遅延を較正するファームウェアは、読み出し応答時間、リビルドに割り当たられる時間、ユーザ選択のリビルド I/O プロファイル、コンフィギュレーション可能なリビルド I/O プロファイル、及びリビルド・スレッドの数を含むグループから選択されたパラメータに従って、前記遅延を較正するよう構成されていることを特徴とするストレージ・システム。

【請求項 7】

請求項 6 に記載のストレージ・システムにおいて、該システムはさらに、周期的に前記キューの先頭へ向けてリビルド I/O を発行するファームウェアを備え、該ハードウェアにより行われる処理は、1 つの周期を構成する複数のステージを有し、前記複数のステージは、

リビルド I/O へ遅延を付加せずにリビルド I/O をキューへ向けて発行し、リビルドを行う第 1 のステージと、

リビルド・レートと応答時間とのうちの少なくとも一方が、それぞれに対応して設定された所定の値よりも大きい場合に実行される第 2 のステージであって、前記遅延の時間である T ミリ秒を計算する第 2 のステージと、

前記 T ミリ秒毎に前記キューの先頭へ向けてリビルド I/O を発行する第 3 のステージとからなることを特徴とするストレージ・システム。

40

【請求項 8】

50

請求項 7 に記載のストレージ・システムであって、

前記第 2 のステージにおいて、前記遅延の時間である T ミリ秒は、下記の式

$$T = C / nR - resp$$

により計算されるものであり、

ただし、上記の式において、

$$nR = rIOPS / (\text{リビルド・スレッドの数}) ,$$

$$rIOPS = rt / resp$$

であり、

前記リビルド・スレッドの数は、前記 RAID システムにおけるリビルド・スレッドの数であり、

10

前記 r_t は、全時間 C のうちのリビルドに割り当てる時間であり、

前記 $resp$ は、キューの先頭での平均「キューの先頭」リビルド読み出し応答時間であり、

前記 C は時間の定数であり、前記全時間であることを特徴とするストレージ・システム。

【請求項 9】

請求項 7 に記載のストレージ・システムにおいて、前記ファームウェアは、RAID1、RAID2、RAID3、RAID4、RAID5、RAID6、RAID0 を含むハイブリッド RAID レベル 1 ~ 6、コピーバック・オペレーションを行うストレージ・システム、及び消失訂正符号を用いるストレージを含むグループから選択されるストレージ・システムにおいて動作するよう構成されていることを特徴とするストレージ・システム。

20

【請求項 10】

ストレージ・システムの複数のドライブに対しての RAID リビルドの方法であって、

ホスト I/O 条件のもとでリビルドを行う RAID システムにおけるリビルド I/O 応答を測定するステップと、

前記 RAID システムのドライブのキューの先頭へ向けてのリビルド I/O の発行を遅延させる遅延時間を計算するステップと、

前記キューの先頭へ向けてのリビルド I/O を発行するステップであって、前記遅延時間により前記リビルド I/O の発行を遅延させるステップと
を含んでいることを特徴とする方法。

30

【請求項 11】

請求項 10 に記載の方法において、該方法はさらに、

読み出し応答時間、リビルドに割り当てる時間、ユーザ選択のリビルド I/O プロファイル、コンフィギュレーション可能なリビルド I/O プロファイル、及びリビルド・スレッドの数を含むグループから選択されたパラメータに従って、前記遅延時間を計算するステップ

を含んでいることを特徴とする方法。

【請求項 12】

請求項 11 に記載の方法において、該方法はさらに、

前記リビルドに割り当てる遅延時間を、最小リビルド・レートから最大リビルド・レートまでの間から選択するステップ

を含んでいることを特徴とする方法。

40

【請求項 13】

請求項 12 に記載の方法において、該方法はさらに、

前記リビルドに割り当てる時間を、コンフィギュレーション可能なリビルド・プロフィールから選択するステップ

を備え、前記リビルド・プロフィールにおいてリビルドに割り当てる前記時間の選択肢は、最小リビルド・レートから最大リビルド・レートまでの間の複数のリビルド・レートを含むことを特徴とする方法。

50

【請求項 14】

請求項 13 に記載の方法において、該方法はさらに、周期的に前記キューの先頭へ向けてリビルド I/O を発行するステップを含み、該ステップは、

リビルド I/O へ遅延を付加せずにリビルド I/O をキューへ向けて発行し、RAID システムのリビルドを行う第 1 のステージと、

リビルド・レートと応答時間とのうちの少なくとも一方が、それぞれに対応して設定された所定の値よりも高い場合に行われる第 2 のステージであって、前記遅延時間である T ミリ秒を計算する第 2 のステージと、

前記 T ミリ秒毎に前記キューへ向けてリビルド I/O を発行する第 3 のステージとを含むことを特徴とする方法。

【請求項 15】

請求項 10 に記載の方法において、前記遅延時間は、読み出し応答時間、リビルドに割り当てる時間、ユーザ選択のリビルド I/O プロファイル、コンフィギュレーション可能なリビルド I/O プロフィール、及びリビルド・スレッドの数を含むパラメータに従って計算されることを特徴とする方法。

【請求項 16】

請求項 15 に記載の方法において、前記リビルド I/O 応答を測定するステップと、前記キューに関する遅延時間を計算するステップと、前記キューに対してリビルド I/O を発行するステップとは、前記 RAID システムにおいて周期的に行われることを特徴とする方法。

【請求項 17】

請求項 16 に記載の方法において、周期的に行われるステップは、

リビルド I/O をライブのキューの先頭へ向けて発行せずに、リビルド I/O をキューへ向けて発行し、RAID システムのリビルドを行う第 1 のステージと、

リビルド・レートと応答時間とのうちの少なくとも一方が、それぞれに対応して設定された所定の値よりも高い場合に行われる第 2 のステージであって、遅延時間である T ミリ秒を計算する第 2 のステージと、

前記 T ミリ秒毎に前記ライブのキューの先頭へ向けてリビルド I/O を発行する第 3 のステージと

を含むことを特徴とする方法。

【請求項 18】

請求項 17 に記載の方法において、該方法は、RAID 1、RAID 2、RAID 3、RAID 4、RAID 5、RAID 6、RAID 0 を含むハイブリッド RAID レベル 1 ~ 6、コピーバック・オペレーションを行うストレージ・システム、消失訂正符号を用いるストレージ、I/O を物理デバイスへ向けて発行するオペレーションを行うストレージ・システム、メディア・スキャンを行うストレージ・システム、整合性の検査を行うストレージ・システム、初期設定を行うストレージ・システム、及びフォーマッティングを行うストレージ・システムを含むグループから選択されるストレージ・システムにおいて実行されることを特徴とする方法。

【請求項 19】

ホスト I/O 条件のもとでの RAID のリビルド処理のための装置であって、

RAID ストレージ・システムにおけるリビルド I/O 応答を測定する手段と、

前記 RAID ストレージ・システムに対するリビルド I/O 要求及びホスト I/O 要求を記憶するためのキューを形成する手段と、

前記キューの先頭へ向けての前記リビルド I/O 要求の発行を遅延させるためのミリ秒単位の遅延時間を計算する手段と、

前記キューの先頭へ向けてのリビルド I/O を発行する手段であって、前記遅延時間だけ前記リビルド I/O の実行を遅延させる手段と、

前記 RAID ストレージ・システムに対するリビルド・レートを設定する手段とを備え、

前記 RAID ストレージ・システムの、前記リビルド I/O 応答を測定する手段と、前記

10

20

30

40

50

遅延時間を計算する手段と、前記リビルド I/O を発行する手段とは、周期的に動作するものであり、

前記リビルド I/O 応答を測定する手段は、第 1 の時間間隔において、従来の様式で動作しているときに平均リビルド応答時間を計算するものであり、この計算は、前記 RAIDストレージ・システムのリビルド・レートと応答時間とのうちの少なくとも一方が、それに対応して設定された所定の値よりも高い値となる時まで行われるものであり、

前記遅延時間を計算する手段は、第 2 の時間間隔において、前記 RAIDストレージ・システムが、前記ドライブのキューの先頭へ向けて発行されるリビルド I/O 要求に関して発する前記遅延の命令を用いて動作しているときの平均リビルド応答時間と、前記リビルド・レートを設定する手段から得られるリビルド・レートと、前記 RAIDストレージ・システムにおけるスレッドの数とを用いて計算を行うことにより、最適な遅延時間を求めるものであり、

前記リビルド I/O を発行する手段は、第 3 の時間間隔において、前記第 2 の時間間隔において計算された前記最適な遅延時間だけ、前記ドライブのキューの先頭へ向けてのリビルド I/O 要求の発行を遅延させる

よう構成されていることを特徴とする装置。

【請求項 20】

請求項 19 に記載の装置であって、前記第 2 の時間間隔において遅延時間を計算する手段は、前記最適な遅延時間である T を、下記の式

$$T = C / nR - resp$$

により計算するものであり、上記の式において、

$$nR = rIOPS / (\text{リビルド・スレッドの数}),$$

$$rIOPS = rt / resp$$

であり、

前記リビルド・スレッドの数は、前記 RAIDストレージ・システムにおけるリビルド・スレッドの数であり、

前記 rt は、全時間 C のうちのリビルドに割り当てられる時間であり、

前記 resp は、キューの先頭での平均「キューの先頭」リビルド読み出し応答時間であり、

前記 C は時間の定数であり、前記全時間である

ことを特徴とする装置。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、RAID (Redundant Array of Independent Disks) の分野における再構築 (リビルド : rebuild) に関する。

【背景技術】

【0002】

本発明は、RAID に関し、RAID は、特にネットワークにおいて、複数のディスク・ドライブ・コンポーネントを仮想化形態の論理ユニットへと組み合わせる記憶技術であり、主に、ディスクの障害により発生するエラーを低減するためのものである。データは、複数のブロックへと分割されてシーケンシャルに幾つかのディスクへ記憶され、この様式はデータ・ストライピングとして知られている。パリティ・ブロックは、通常、エラー検査のための手段、及びディスク・ドライブの 1 つに障害が生じた際のデータの再構築のための手段を形成し、パリティ冗長性を形成する。

【0003】

RAID は、適切に構成された場合には幾つかの利点を有する。RAID の利点として、冗長性を通じてデータ・セキュリティが高くなること (セーブ RAID 0 コンフィギュレーション (save RAID 0 configuration)) 、障害を許容すること、データへのアクセスが改善されること (データ・アベラビリティ) 、大量の隣接したディスク空間を作るた

10

20

30

40

50

めの統合された容量が増加すること、及び性能が改善されること等をあげることができる。R A I D に関するコストには、より高価なハードウェアと、必要となる特別なメンテナンスとが含まれる。

【 0 0 0 4 】

特に、ハイブリッド（ネスト型）R A I D システムを含めた場合には、多種のR A I D が存在するが、R A I D レベル0～6を用いれば、ディスク・ベースのストレージ・システムに関する全ての典型的なデータ・マッピング及び保護のスキームを定義することができる。R A I D に関するシステムの他の分類としては、障害耐性（ドライブ障害に起因するデータの喪失に対する保護を行うシステム）、障害許容性（1又は複数のコンポーネントに起因するデータ・アクセスの喪失に対する保護を行うシステム）、及び災害許容（2以上の独立の地域（ゾーン）を用いる構成を備え、何れのゾーンも記憶されたデータに対するアクセスを提供するシステム）などがある。

10

【 0 0 0 5 】

通常用いられるR A I D レベルは、R A I D 0、R A I D 5、及びR A I D 6である。R A I D 0 は、パリティやミラーリングを用いず、冗長性ゼロでのブロック・レベルのストライピングを行う。R A I D 0 は、性能を向上させ且ストレージを増加させるが、障害許容性ではない。R A I D 0 では、ブロックは、個々のドライブへ同じセクタ上で同時に書き込まれ、小さいセクションのデータは各ドライブから並列に読み出され、それにより帯域幅が増大される。R A I D 0 は誤り検出を実行しないので、エラーは修正されない。R A I D 0 は、ハイブリッドR A I D システムで、性能を向上させるために使用されることが多い。R A I D 5 は、データと共にパリティが分散される分散型パリティを用いるブロック・レベルのストライピングを行うものであり、1つのドライブ以外の全てのドライブが使用され、その1つのドライブは、1ドライブ障害（single drive failure、1つのドライブの障害）が発生したときに使用するリザーブ用である。1ドライブ障害が発生した場合、アレイは破壊されず、後続のデータ読み出しは、分散型パリティに基づいて計算され行われるので、エンド・ユーザにはドライブ障害を認識させない。しかし、1ドライブ障害は、障害したドライブを取り替えて関連するデータをリビルド（再構築）するまで、アレイ全体の性能を低下させる。R A I D 6 は、二つの分散型パリティを用いるブロック・レベルのストライピングを行うものであり、2ドライブ障害に対する障害許容性を提供する。アレイは、2個のドライブが障害するまで動作を継続できる。R A I D 6 の利点は、大きいR A I D グループを、より好適に作動するようにできることであり、この利点が重要なのは、大きい容量のドライブは、リビルドするため及び1つのドライブの障害から回復するために必要とする時間が長くなることと関連する。

20

【 0 0 0 6 】

コピーバックは、機能しているアレイ・メンバのディスクの内容を置換用ディスクへコピーすることにより、そのアレイ・メンバのディスクを別のアレイ・メンバのディスクに入れ替えることである。コピーバックは、障害しかけているコンポーネントが完全に障害してアレイの性能を低下させる前に置換するためや、アレイの特定の物理的コンフィギュレーションをレストア（復帰）するために用いられることが多い。

30

【 0 0 0 7 】

従来のスピンドル・ベースのハード・ドライブに格納される二次メモリは、アーマチュアにより保持される磁気ヘッドにより読み出されるデータを記憶する複数の回転ディスク（プラッター）を有する。現在のドライブは、通常、幾つかのヘッド及びプラッターを有する。1つのI O オペレーションを完了するために、アーマチュアは、ヘッドを、データを保持するプラッターのトラックのセクタへと移動させる必要がある。このプロセスはシーキング（シーク）と呼ばれるものであり、シーク時間と呼ばれる時間を必要とする。次に、このI O オペレーションでは、プラッターが回転されてセクタがヘッドの下へ来るまで待つ必要がある。この待ち時間は回転遅延（rotational latency）と呼ばれる。これらの時間及びその他の遅延は、ファームウェアや、ソフトウェアや、ドライブの応答に関連する他のハードウェアに起因するものである。

40

50

【0008】

IOPS（「アイオプス」：1秒当たりのI/Oオペレーションの回数）は、ハード・ディスク・ドライブ（HDD）やストレージ・エリア・ネットワーク（SAN）等のコンピュータ・ストレージ・デバイスのベンチマークのために使用される一般的な性能尺度である。ストレージ・デバイスの製造者が発表しているIOPSの数値は、Iometer（当初はインテル（登録商標）社により開発されたソフトウェア）などのようなアプリケーションを用いて測定できる実際の応用での性能を保証するものではない。システム構成におけるIOPSの考えられる数値は、様々な変量（変数）に依存して大きく変わるものである。様々な変量としては、例えば、読み出し動作及び書き込み動作のバランス、シーケンシャル・アクセスとランダム・アクセスとのパターンの混合、ワーカー・スレッド（worker thread）の数及びキューの深さ、データ・ブロックのサイズ、そして、システム構成における他のファクタ、ストレージ・デバイス、OSのバックグラウンドのオペレーションなどの要因が含まれる。

10

【0009】

RAIDアレイの中の1以上のハード・ドライブが障害した場合、その障害が生じたハード・ドライブをリビルドする必要がある。リビルドを行うためのI/Oオペレーションは、リビルドI/Oと呼ばれ、リビルド用ではない通常のI/Oオペレーション、例えば、RAIDグループのハード・ドライブの通常動作用のI/Oオペレーションなどは、ホストI/Oと呼ばれる。RAIDシステムでは、リビルド性能は、ホストI/O状態のもとでは強い影響を受ける。これは、リビルド動作では、ディスク・グループ中の残りの全てのディスクの読み出しを行う必要があり、各ディスクに対してシークを行う必要があるからである。それに加えて、それぞれのドライブ・モデルは、I/Oキューを最適化するための個々の方法を有し（その方法はプロプライエタリである場合が多い）、その方法によりI/Oキューを整理し直してドライブのシークを最小化する。その結果、リビルドI/Oは、大きい影響を受け、大きい遅延（レイテンシ）に苦しむこととなる。なぜなら、通常、リビルドI/Oは最も整理し直されやすい（順序変更されやすい）I/Oだからである。これは、リビルド性能に直接的に影響するものであり、システムは、例えば1TBのデータをリビルドするために8～30日という時間を必要とし得る。このようにリビルド時間が長くなると、RAIDグループは、ホストI/Oの性能が低下した状態のもとに長い期間置かれることになり、これは、RAIDグループ全体をオフラインとしてしまうようなデータ喪失をさせ得る第2や第3のドライブ障害を生じさせ得る機会を与えることになる。

20

【0010】

全てのRAIDシステムは、通常、多くのI/Oキューをコントローラにより管理及び制御しており、それぞれのドライブはそれ自体のI/Oキューも有する。本発明は、後者の方、即ち、個々のドライブ内のキューを考慮するものであり、それは32コマンド又は64コマンドの深さである。リビルドI/Oは、大きい遅延や応答時間に苦しめられることが多い。これは、リビルドI/Oは、通常、ドライブのキュー内のホストI/Oと局所性が同じではなく、同じ箇所に存在していないからである。局所性に関しては、ディスク上のグループ化されたセクタの共通の領域又はクラスタという定義があり、従って、局所性がある場合、ドライブのヘッドは、1つのLBA（論理ブロック・アドレス）を得てから次のLBAを得る際に、大きく離れた位置をシークする必要はない。従って、リビルドI/Oに関する動作の際に悪影響を及ぼす可能性がある。リビルド動作では、データを再構築するためにドライブ全体の読み出しを行うので、殆どのリビルド動作では、リビルドI/Oは、ホストI/Oと局所性を共有しない。典型的に、全てのシステムは、ドライブに対するリビルドI/OとホストI/Oとのレートを制御するが、それらがドライブへ渡されると、ドライブはそれらを引き継いで、ここで説明したように、RAIDコントローラにより計算されたレートを変え得るので、リビルドI/Oが枯渇させられる結果となる。

30

【0011】

ドライブは、一連の1又は複数の同時のスレッド又はプロセスでリビルドすることができ、それらは、インプリメンテーションに依存するものであり、RAIDシステムのファ

40

50

ームウェアにより決定されるものであり、使用可能なシステム資源や、ディスク・グループの I/O サイズの粒度（細分性）、例えば、リビルドされる仮想グループのストライプのサイズなどに基づくものである。

【 0 0 1 2 】

本発明は、ホスト I/O 動作の処理を行いつつリビルドを行うための新規でヒューリスティック（発見的）な方法であり、それにより、リビルド I/O に関する遅延が大きいことでリビルド時間が長くなるという問題に対処するものである。

【 発明の概要 】

【 0 0 1 3 】

従って、本発明の 1 つの態様は、決定性の様式でリビルド時間を大幅に改善するための方法であり、該方法においては、或る RAID レベルのストレージ・システムがホスト I/O の状態のもとでリビルドを行っているときに、リビルド I/O の長い遅延が起こらないようにし、この方法により、システムが、リビルドを行うと同時に、リビルドが行われていないときに行われる通常（従来）の動作を行うようにする。

10

【 0 0 1 4 】

本発明の別の態様では、ホスト I/O の状態のもとで、head-of-queue（キューの先頭） SCSI タグを用いて、リビルド動作と関連する I/O を発行する。

【 0 0 1 5 】

本発明の別の態様では、リビルドのレートを制御して、ホスト I/O の窮乏(starvation)が起きないようにする（ホスト I/O の実行を極度に妨げないようにする）。この方法は、リビルドのレートが正しく制御され継続的に調節されて、最適なリビルドのレートが提供されることを保証し、かつ、ユーザの要求に応じてホスト I/O の処理が行われて、I/O ホストの窮乏が生じないことを保証する。

20

【 0 0 1 6 】

本発明の更に別の態様では、RAIDストレージ・システムで用いるファームウェアにより、リビルド・キューに対して遅延を故意にもたらすようとする。これはリビルドのレートを制御するものである。遅延は、ディスク・ヘッドの応答時間、リビルドに割り当たられる時間、リビルド・スレッドの数、及び一連のイベントのタイムライン（time line、時間線、スケジュール）の発見的な関数として計算することができる。1つの実施形態では、一連のイベントのタイムラインは 70 秒毎のサイクルとなる。ドライブの挙動と、ホスト I/O 及びリビルド I/O の作業負荷及び局所性を含むホスト I/O プロフィールとは、ドライブの順序変更アルゴリズムに影響を及ぼす重要なファクタ（要因）であり、リビルド I/O の遅延の原因ともなる。これらは、リビルド I/O の平均遅延を測定することにより、発見的なアルゴリズムへ組み入れられる。

30

【 0 0 1 7 】

本発明の別の態様は、ユーザによる選択又はユーザによるコンフィギュレーション（環境設定）が可能なりビルド・レートに関するものであり、このリビルド・レートは、オプションとしてオペレーション・メニューで提示することができる。メニューのオプションは、ホスト I/O と相対してどの程度速くリビルドが行われるかに関してや、ホスト I/O 動作に対してリビルドがどの程度の影響（インパクト）を及ぼすかに関して、例えば、「無インパクト（no impact、無影響）」、「低インパクト（低影響）」、「高インパクト（高影響）」、「最大インパクト（最大影響）」などとすることができます。

40

【 0 0 1 8 】

本発明の更に別の態様は、発見的なリビルドを行うものであり、この発見的なリビルドは、何れのハードウェアをも適応させるために絶えず再較正（再校正）を行う。1つの好適な実施形態では、この方法は 70 秒毎に反復して行われる。

【 0 0 1 9 】

即ち、本発明は、ホスト I/O の状態のもとでの RAID のリビルドを改善するシステム及び方法であり、リビルド時間を大幅に改善し、且つホスト I/O が窮乏しないようにする（ホスト I/O が極度に妨げられないようにする）。RAID の一部であるドライブにおける

50

るキューは、リビルド I/O 及びホスト I/O のリクエスト（要求）を記憶するために用いられ、リビルド I/O は、ライブのキューの先頭に向けて発行される。ライブにおけるリビルドの要求は、遅延時間により遅延される。この遅延は、R A I D システムにホスト I/O の窮乏（ホスト I/O 要求が処理されない状態）をもたらすような、本発明の意図しない副作用が無いことを保証する。遅延は、複数の変数から導き出された関数として計算され、変数は、例えば、ディスク・ヘッドの応答時間、リビルドに割り当てられる時間、リビルド・スレッドの数、ライブの挙動、リビルド I/O プロフィール、作業負荷及び局所性を含むホスト I/O プロフィール、及び一連のイベントのタイムラインなどである。一連のイベントのタイムラインは、1つの実施形態では 70 秒毎のサイクルである。リビルド I/O プロフィールは、複数のオプションとして表されるリビルド・レートを有し、それらのオプションは、ホスト I/O と関連してどの程度速くリビルドが行われるかに関してや、ホスト I/O 動作に対してリビルドがどの程度の影響（インパクト）を及ぼすかに関しての、例えば、「無インパクト（無影響）」、「低インパクト（低影響）」、「高インパクト（高影響）」、「最大インパクト（最大影響）」などである。

10

【0020】

ホスト I/O による負荷が大きい状態で、或る構成では、本発明の方法及び装置を用いた場合のリビルド時間は、10 倍まで改善することができる。

上記の全ての利点を足し合わせて得られる利点や、本願で開示された様々な他の利点や本発明に内在する利点は、従来技術を超える改善をもたらす。

20

本発明の上記及び他の多くの特徴及び利点は、以下の詳細な説明を添付の図面とともに考慮すれば明らかになるであろう。

【0021】

本発明の好適な実施形態の詳細な説明は、添付の図面を参照しつつ行われる。ここでは、本発明を実施するための現在において最適と考えられる様式を詳細に説明する。以下の説明は、発明を制限するものと判断すべきではない。以下の説明は、単に、本発明の一般的な原理を例示する目的でなされるものである。この説明における各章の名称や全体的な編成は利便性を考慮してのものであり、本発明を限定するためのものではない。

20

【0022】

当業者であれば、本発明の教示を用いて、図面に示す実施形態を、本発明の精神から外れることなく変更することが可能であり得ることを、理解すべきである。図面では、1つの図面におけるエレメントに付された参照番号と同様の参照番号が、別の図面におけるエレメントに付されている場合、その別の図面のエレメントは、先の図面のエレメントと同様のエレメントである。

30

【図面の簡単な説明】

【0023】

【図 1】本発明の一般的な全体の流れを示すフローチャートである。

【図 2】リビルド I/O 対ホスト I/O の、ユーザにより定義可能又はコンフィギュレーション可能なリビルド・レートを示す。

30

【図 3】動作中の本発明の好適な実施形態を示す更に詳細なフローチャートである。

【発明を実施するための形態】

【0024】

本発明の方法及び装置は、ここで述べた機能を実施する有線又はソフトウェアでプログラマされるデバイス（例えば、A S I C や、F P G A などのようなプログラマブル論理デバイス（P L D）など）や、ファームウェアを実行するハードウェアや、ソフトウェアを実行するハードウェアなどにより構成することができ、ソフトウェアはメモリに記憶される。また、ここで用いる「ファームウェア」という用語は一般的な表現であり、類義語に置き換えることができ、又はドウェアやソフトウェアの組み合わせとして表すことができる。このハードウェアやソフトウェアは、例えば、A S I C 、P L D 、コントローラ、プロセッサ、コンピュータ・システムなどであり、それらは、コンピュータ・プログラムを記憶するコンピュータ読取可能な記憶媒体を含み、コンピュータ・プログラムは、コンピ

40

50

ユータやソフトウェア・プログラマブル・デバイスと組み合わせて用いられるものであり、それらを動作させるための命令を含む。本発明の実施に用いるコンピュータ・システムは、典型的には、1以上のプロセッサと、プロセッサと共に働く一次メモリ及び二次メモリ（プロセッサはこれらのメモリに記憶された命令を実行する）と、モニタやマウスやキー・ボードなどのような入力／出力手段と、他の必要とされる別のハードウェアやファームウェアとを有する。本発明を構成するために使用されるソフトウェアは、そのソース・コードや機械語の中に、幾つかのクラス、機能、サブルーチン、オブジェクト、変数、テンプレート、モジュール、コードの行、コードの一部、及び本発明をここで説明し教示する連続するステージ（段）で実行するための構成（ここでは集合的に又は一般的に構成と記載したが、この説明に関連するフローチャートでは「プロセス・ステップ」、「ステップ」、「プロセス」、「ブロック」、「ブロック・ステップ」、「アプリケーション」、「命令」、「プログラム命令」、「モジュール」などのように示されている）を有することができ、このソフトウェアは、スタンダードのソフトウェア・アプリケーションとすることも、別のソフトウェア・アプリケーションの内部で用いるもとすることも、別のソフトウェア・アプリケーションにより呼び出されるものとすることもできる。

10

【0025】

発明の詳細な説明の一部は、プロセス、プロシージャ（手順）、論理ブロック、機能ブロック、及び、他の象徴的な表現、例えば、コンピュータやプロセッサやコントローラやメモリの中のデータ・ビットやデータ・ストリームや波形に対するオペレーションの象徴的な表現に関するものである。ここで説明するプロセス、プロシージャ、ボックス、論理ブロック、機能ブロック、オペレーション（動作、演算）などは、一般に、物理量の物理的操作を含むものと考えられ、その物理量は、例えば、電気的信号、磁気的信号、光学的信号、そして、コンピュータやデータ処理システムや論理回路において記憶、転送、組み合わせ、比較、及び他の操作が可能なその他の信号などの形態である。これらの信号は、一般的な用法を考慮した場合、ビット、波、波形、ストリーム、値、エレメント、記号／符号、特徴、項、数などと呼ぶことが好都合である。

20

【0026】

以下で更に説明するが、本発明に関して、前述のように、従来から考えられているリビルトは、ドライブのキューの順序変更（re-ordering）に起因する大きい遅延（レイテンシ）が問題である。ここで教示する解法は、リビルトIOに、SCSI IOタグ「キューの先頭（Head-of-Q）」を発行することであり、これは、そのIOをドライブのキューの先頭へ置き、そのIOを強制的に実行させる。これにより、リビルトの遅延を大幅に減少させ、リビルト性能を劇的に改善させることができる。IO（リビルトIO）を発行する際には、SCSI IOタグ「キューの先頭」を用いるようにし、そのIOを、好ましくはキューの前部（先頭）以外の場所ではなくキューの前部（先頭）に置くようにする。この解法は、大きい遅延の問題を解決するが、二次的な問題を生じさせる。その第1の問題は、キューの先頭でリビルトの要求を強力に推し進めると、リビルトは速い速度で行われるが、システムの他の部分に関する命令／要求が欠乏（窮乏）して作動しない状態となることである。この第1の問題を解決するために、ここで教示するように、キューに対して遅延を適用する。しかしながら、この遅延も問題を生じさせ得る。例えば、固定の静的な遅延を用いた場合、全ての状態のもとにおいて最適の結果を得ることができず、状態が変わると結果も変わり、リビルトに1～2日を要する結果となる場合もある。従って、固定の静的な遅延の値に頼るのではなく、ここで教示するように、最適な遅延の値を計算する必要がある。ここで教示するように、最適な遅延は、発見的な方法に基づくものであり、様々な状態における多くの変数や作業に対応できる。RAIDのユーザは、単に、ホストIOのインパクト（影響）について、性能を快適と感じるレベル（許容できる影響のレベル）をシステムへ入力するだけでよく、ここで教示するように、その入力に対応する残りの処理はシステムが行う。遅延は、性能を向上させるものではないが、システムが許容できる最低限の性能を有しつつリビルトが十分速く行われるようにするために、必要なものである。ここで教示する遅延を用いない場合、リビルトは速い速度で行われるが、以下

30

40

50

でも説明するようにシステムの性能は低下する。

【0027】

ここで図1を参照する。図1は、RAIDシステムがホストIO状態のもとでリビルドされるときに用いられる本発明に係るRAIDシステムに関する、本発明の全体の流れを概略的に示すフローチャートを示す。本発明に係るシステムは、発見的な様式でリビルドを行う。概略的には、本発明を実現するプログラム10の流れは3つの段階(ステップ)を備える。本発明は、ファームウェア、ハードウェア、ソフトウェア、又はこれらを組み合わせたもの(以下では、単に「ファームウェア」という)に備えられることができる。

【0028】

第1ステップ12において、「リビルドIO応答を測定」と記載されたボックスでは、プログラムは、解法の基礎となる平均リビルドIO応答時間を計算する。例えば、プログラムは、本発明を含まない従来の技術を用いる通常のリビルド、即ち、「従来の」リビルドが行われる間にデータを読み出すハード・ドライブのヘッドの応答時間を読み出し、ミリ秒(ms)単位で平均応答時間を計算する。入力14は、「平均リビルド読み出し応答を計算」と示されている。平均リビルド応答時間は、事実上、任意の時点におけるホストIOの作業負荷、局所性、及びドライブのキューマネージメント効率を測定するものである。ここで説明するように、平均リビルド応答時間が、特定の経験的に決定された閾値よりも下である場合、従来技術によるリビルド機構が、リビルドに関して十分に速く動作していると判断できる。しかし、平均リビルド応答時間が閾値よりも大きい場合、リビルド・コマンドをRAIDデバイスのキューリストック(前部)へと動かし、それが即座に処理されるようにして、リビルド性能を向上させる。

【0029】

第2ステップ14、すなわち、「『キューリストック』へ付加するために最適遅延Tmsを校正」と記載されたボックスでは、プログラムは、発見的な様式で、ミリ秒(ms)単位で最適遅延Tを計算し、この遅延時間により、ドライブのキューリストックへのリビルドIOの発生発行を遅延する。この「キューリストック」キューリストックは、ドライブのベンダにより実装された個々のドライブのファームウェアにおける個々のドライブに関するキューリストックである。このステップでは、RAIDシステムは、ここで教示するように、とりわけキューリストックに関連する従来とは異なる様式でリビルドを行う。RAIDシステムに対して、キューリストックは、何れのIOプロセスを処理するか、及び、何れの処理のシーケンス(キューリストックの形)で処理するかを示すものであり、処理のシーケンスとは、例えば、ホストIOに続いてリビルドIO、リビルドIOに続いてホストIO、2つのリビルドIOに続いてホストIOなどのようなものである。「キューリストック」とタグ付されたリビルドIOは、そのリビルドIOを即座に処理すべきこと、即ち、ドライブがキューリストックに対する処理や順序変更の動作に戻る前に処理すべきことを、ドライブに対して示す。遅延Tは、ドライブのキューリストックに対するリビルドIO(リビルドIO要求)が発行される前に遅延(ミリ秒単位)される時間である。この遅延(休止)の間、キューリストック(前部)に対してリビルドIOは発行されない。この休止期間があることにより、ドライブはそのキューリストック(既にキューリストックに含まれているIO要求)を実行でき、そのキューリストックに残った部分を実行すべきときに、「キューリストック」リビルドIOが発行されてドライブがそれに占有されることを防止する。

【0030】

図1のステップ16におけるファクタ、即ち、リビルドIOコマンド(又はリビルドIO)をドライブのキューリストック(前部)へ発行することを遅延するための、必要とされる最適遅延時間の計算、又は遅延の校正(較正)に用いられるファクタには、幾つかのファクタが含まれる。

第1のファクタは、キューリストックと関連する「キューリストック」リビルド(即ち、リビルドIOをキューリストックへ置いて行う処理)が行われている間にデータを読み出すハード・ドライブのヘッドの平均リビルド読み出し応答時間である。これは、入力18において「平均リビルド『キューリストック』読み出し応答時間計算」と示されている。

10

20

30

40

50

【0031】

ステップ16の遅延の校正に用いる第2のファクタは、ユーザ選択の又はコンフィギュレーション可能なりビルドIOプロフィールからリビルトへ割り当てられる時間の計算であり、入力20において「リビルトIOプロフィールを計算」と示されている。リビルト・プロフィールは複数のリビルト・レートを含み、これは、どの程度積極的にリビルトを行うかを決定する。リビルト・プロフィールは、また、合計時間と比較しての、リビルトに割り当てられる時間として見ることもできる。ここで教示する1つの実施形態では、ユーザは、メニュー中の一連の選択肢からプロフィールを選択することができ、その選択肢には、リビルトIOに対して十分な優先度が与えられずホストIOに対して比較的高い優先度が与えられる低インパクト・リビルト（「低」）のような最小リビルト・レート、リビルトIO要求に対してもホストIO要求と同じ優先度が与えられる高インパクト・リビルト（「高」）、ホストIOに勝る最高の優先度がリビルトIOに対して与えられる最大インパクト・リビルト（「最大」）などがある。この選択は、自動的に行うこともできる。なお、このような等級（選択肢におけるインパクトの段階）は実施の様様に依存するものであり、リビルト・プロフィールにおいて、任意の数の等級を設定することが可能であり、また、ゼロ又は最小値から最大値までの連続的で平滑な関数を用いることも可能である。更に、リビルト・プロフィールのレート及び割り当てられる時間を、ユーザ入力なしで自動的に決定する構成や、ユーザ入力と関連して自動的に決定する構成とすることも可能である。例えば、リビルト・プロフィールのレート及び割り当てられる時間を、エキスペート・システムの場合のように、履歴データを用いてルックアップ・テーブルから自動的に選択するように構成でき、この場合、様々な類似のストレージ・システム及び／又は特定のハード・ドライブ製造者から収集した履歴データに基づいてプロフィールを決定するように構成できる。

10

20

30

【0032】

ステップ16の遅延の校正において遅延を決定するために用いる第3のファクタは、リビルト・スレッドの数の計算であり、リビルト・スレッドの数は、ハード・ドライブ製造者の実施の形態に依存するものであり、図1の入力22において「リビルト・スレッドの数を計算」と示されている。デバイスは、使用可能なシステム・リソース及びディスク・グループのIOサイズの粒度（細分性）、例えば、リビルトされている仮想グループのストライプのサイズ、に基づいて、RAIDシステムのファームウェアで決定されたよう、データの1以上の一連のスレッドでリビルトすることができる。例えば、ストライプ・サイズが1メガの仮想ドライブに対しては、ディスクに対しての各IOに対してキャッシュを使用する必要があるので、一度に1つのスレッドのみが発行される。しかし、ストライプ・サイズが64キロの仮想ドライブは8個のスレッドを実行することができる。なぜなら、8個のそのようなIOが使用するのは、ディスクあたり512キロの量のキャッシュのみだからである。これらは本質的に知られていることであり、実施の形態により変わる。

30

【0033】

ステップ16の遅延の校正に用いる第4のファクタは、リビルトに許される時間の長さに関する1以上の時間定数の使用である。1つの実施形態では、その時間定数は1つのIO応答に対して1000msであるが、一般に、特定の実施の形態に応じて適宜に決定した値とすることができる。更に、本発明の方法の全てを行うために要する期間もまた別の時間定数であり、1つの実施形態では、後に説明するように70秒であるが、一般に、その時間長は、普遍性を喪失しない範囲で適宜に決定した長さとすることができます。

40

【0034】

最後である第3ステップ24については、そのボックスに「遅延Tms毎に『キューの先頭』ヘリビルトIOを発行」と記載されており、このステップにおいて、本発明のプログラムは、先行するステップで計算された遅延を実際に実施する。この処理では、本発明を用いるファームウェアにより、キューの前部（キューの先頭）へのリビルトIOコマンドの発行を、第2ステップ16で決定された時間Tミリ秒（ms）だけ遅延する。この遅

50

延時間の間、キューへリビルド I/O が送られない。

【0035】

本発明を用いる RAID システムでは、図 1 に示す技術を用いると、リビルド処理の間の性能が顕著に向かう。その有効性を示すために、以下の表 A 及び表 B にシミュレーションの結果を示す。幾つかの場合においては、性能における 10 倍の向上が見られる。表 A は、本発明に従って行ったリビルドに関するものであり、表 B は、従来のリビルド手法のもので行ったリビルドに関するものである。

【0036】

【表 1】

表 A ー 本発明を用いるリビルド キューの先頭リビルド IOPS および応答時間 (ms) 64K				
番号	ホスト I/O	IOPS	平均応答 (ms)	MB/S
1	I/O 無し	220	2~40	13.74
2	1 QD 近	156	4	9.74
3	1 QD 遠	146	9	9.12
4	16 QD 近	140	10	8.74
5	16 QD 遠	130	17	8.12
6	256 QD 近	128	16	7.99
7	256 QD 遠	123	20	7.68

10

20

30

【表 2】

表 B ー 本発明を用いないリビルド リビルド IOPS および応答時間 (ms) 64K				
番号	ホスト I/O	IOPS	平均応答 (ms)	MB/S
1	I/O 無し	1398	0	87.29
2	1 QD 近	540	4	33.72
3	1 QD 遠	422	12	26.35
4	16 QD 近	102	77	6.37
5	16 QD 遠	106	80	6.62
6	256 QD 近	11	1200	0.69
7	256 QD 遠	90	97	5.62

【0037】

上記の表の用語について説明する。第 1 コラムの「番号」は、考慮している例におけるケース番号であり、表 A 及び表 B にはそれぞれ 7 個の例が示されている。第 2 コラムの「ホスト I/O」に関して、「近」は、リビルド領域がホスト領域に近いことを表す。ホスト I/O の作業負荷が大きい場合において、リビルド領域がホスト領域に近い場合には、遠い場合よりも、その処理に関する遅延が長くなることが知られており、表 B の行 6 (番号 6 の行) はその一例である。第 2 コラムでは、リビルド領域がホスト領域から遠いこと「遠」と示している。多くの製造業者は、ファームウェアに依存する I/O キューを最適化するためのプロプライエタリの方法を有するので、この「近」及び「遠」に関する現象についての共通する理由付けはできないが、その現象が観察されていることは事実である。第 2 コラムの「ホスト I/O」は、I/O 要求に応答する指定されたホスト I/O を表す。このコラムにおいて、「QD」はキューの深さ (Queue Depth) を表し、キューの深さとは、ホスト

40

50

I/O要求の間に存在する（ホストI/O要求に応じての）ホストI/Oの数を測定したものである。「1QD」では、非常に軽いホストI/Oドライブ順序変更スキームとなり、システム全体に対するインパクトを実質的には与えない。1QDでは、ドライブのI/Oキューに含まれるホストI/Oは1個のみであるので、そのI/Oキューへ多くのリビルドI/Oを含ませることができる。それに対して、16QDは、比較的典型的なホストI/O作業負荷であり、或る時点で16個の処理されるべきI/Oが存在することを示す。1QDと対極にあるのは256QDであり、これは、或る時点で多数の処理されるべきI/Oが存在することを示すものであり、これは重い作業負荷である。最大が256QDというのは典型的ではないが、この例では最も長いリビルド時間を生じさせている。

【0038】

10

第3コラムの「IOPS」は、1秒あたりの入力／出力リビルド・オペレーションの数である。第4コラムの「平均応答」は、リビルドI/Oに対するドライブの平均応答の時間をミリ秒単位で示す。最後のコラムの「MB/S」は、リビルドI/Oに関するデータ転送レート（スループット）であり、「メガバイト／1秒」という単位で表している。

【0039】

表Aと表Bとを比較すると分かるように、本発明を用いることにより、従来のリビルド処理と比較してシステムの性能が顕著に向かう。例えば、番号「5」の行の例では、作業負荷は16QDという中程度のものであるが、従来のリビルドでの平均応答時間は長く、80msである。しかし、本発明の技術を用いた場合、番号「5」の行の例での平均応答時間は17msであり、80msと比較して79%短くなっている。IOPSは106から130へ、スループット(MB/S)は6.62MB/sから8.12MB/sへと向上している。

20

【0040】

同様に、重い作業負荷、例えば、番号「7」の行の例で示される「256QD遠」の場合にも、本発明の技術を用いると、従来のリビルド処理の場合よりも性能が改善されている。この場合、IOPSでは90から123へと37%の向上が見られ、スループット(MB/S)では5.62MB/sから7.68MB/sへと上昇し、更に、平均応答時間は97msから20msへと79%低下しており、この20msという値は97msという値と比べてかなり好適なものである。

30

【0041】

I/O作業負荷が軽い場合には、本発明を用いても利益は得られない。このことは認識されており、本発明の方法でも織り込み済みである。例えば、表Aと表Bとの番号「1」の行の例を比較すると、「I/O無し」の場合では本発明による利益はなく、本発明を用いることにより性能は低下している。番号「2」の行の例を比較すると、「1QD近」の場合でも、従来のリビルド処理と比較しての本発明の利益はない。（なお、表Aの場合において、番号「2」の行の例に関しては、1つの「キューの先頭」リビルドI/O要求と別の「キューの先頭」リビルドI/O要求との間に50msの最小遅延時間が付加されている。）しかし、番号「3」の行の例では、「1QD遠」の場合に関して、本発明を用いた場合には、平均応答時間において12msから9msへと低下しており、少しではあるが改善が見られる。しかし、この例では、本発明を用いてもスループット(MB/S)に関して利益は得られず、従来のリビルド処理でのスループットは26.35MB/sであり、これは、本発明を用いた場合のスループットである9.12MB/sよりも高い。また、表から理解できるように、一般には「近」の状態のほうが「遠」の状態よりも処理が速くなるが、例外もある。従来のリビルド処理に関する表Bにおいて、番号「6」の行、即ち、重い負荷の例である「256QD近」で長い遅延が発生しており、これは、番号「7」の行の「256QD遠」と比較すると差が明確に理解できる。この例では、「近」のI/O要求における通常の場合のような速い応答がなされず、反対に応答が遅くなってしまい、「遠」の平均応答時間は97msであるが「近」の平均応答時間は1200msであり、「遠」のほうの平均応答時間のほうが12倍以上速くなっている。この逆転現象は、本発明により対処され解決される1つの問題の例であり、表Aにおける番号「6」の例と番号「7」

40

50

の例とを比較すると本発明の効果が理解できる。表Aと表Bとのそれぞれの「256QD近」に関する性能を比較すると、平均応答時間は16msと1200msであり、本発明を用いた場合には平均応答時間が98.7%減少しており（即ち、75倍速く（1200/16））、表Aに示す処理の性能が表Bに示す従来の処理の性能に勝っていることが理解できる。スループットに関しても、0.69MB/s（表B）から7.99MB/s（表A）へと劇的に増加しており、これは1桁異なる増加であり、より正確には11倍以上の向上である。また、表Aの番号「7」の例と、表Bの番号「5」の例とを比較すると、表Aの番号「7」の例（本発明を用いた場合）の平均応答時間は20msであり、表Bの番号「5」の例（従来のリビルド処理を用いた場合）の平均応答時間は80msであり、表Aの番号「7」の例では、その作業負荷が表Aの番号「5」の例の作業負荷よりも重いにもかかわらず、平均応答時間が良好に（短く）なっている。

10

【0042】

作業負荷が軽く又は無く、キューの深さが浅い状態では、従来のリビルドの方法と比較して本発明の方法が利益をもたらさないことが、表A及び表Bから理解できる。従って、以下に説明するように、本発明では、リビルドを行っているときに、リビルド・レートと応答時間とを考慮し、1つの実施形態では、遅延を伴う「キューの先頭」リビルド方法（リビルドIOをキューの先頭へ向けて発行する方法）のみを実施するが、この方法は、リビルド・レートがベースライン（基準値）の33%を超える大きさの場合、又は応答時間が45msよりも長い場合に実行する。これにより、本発明では、表Aにおける「番号」の大書きで示す例、例えば、番号「4」から番号「7」の行に示す例の範囲の状態において、本発明の処理が行われるようにする。

20

【0043】

次に、図2を参照する。図2はユーザ定義可能なわちコンフィギュレーション可能なリビルド・レートを示す。図2では、グラフィカル・ユーザ・インターフェース（GUI）200を用いてリビルド・レートを選択する方法を示すが、本発明では、ユーザにより操作されるGUIは必ずしも必要ではない。従って、GUIと関連する説明は、コンフィギュレーション可能かつ変更可能な様式でのリビルド・レートの操作を説明するために用いる概念的なツールの説明と理解すべきである。なぜなら、リビルド・レートは、実際には、GUIや人間の操作者により選択及び変更するのではなく、自動的に選択及び変更することが可能であり、また、固定のシーケンスで選択することも可能であるからである。GUI200は、本発明によると、ユーザが望むRAIDシステムのリビルド処理を選択するために、様々な強度の度合いに対応する複数のボタン210、215、220、225を備える。その度合いは、例えば、「低」、「高」、「最大」、「無し」であり、それぞれ、低い値/低インパクト、高い値/高インパクト、最大値/最大インパクト、リビルド無し/インパクト無し、というリビルド・レートに対応する。例えば、1つの好適な実施形態では、「無インパクト」、「低インパクト」、「高インパクト」、「最大インパクト」という4個のレベルのリビルド・レートがユーザに提示される。なお、インパクトとは、ホストIOがリビルドにより受けける影響を意味する。

30

【0044】

「無インパクト」の場合、本発明のRAIDシステムは、従来のリビルド処理を行う。このオプション（「無インパクト」）の場合、本発明の処理は行われないので、ホストIOに関する性能に対するインパクトは最小限となる。また、このオプションの場合、ユーザにとって、リビルド時間は問題にはならない。

40

【0045】

他の3個のオプションでは、本発明に従ったリビルドの動作を行う。図2に示す実施形態では、「低インパクト」を選択した場合、ホストIOに関する性能は、「無インパクト」の場合と比べて3分の1が影響を受ける。より詳細には、図2の棒グラフで示す「『キューの先頭』リビルドIO」において、低インパクトの場合は、割り当てられた1000msのうちの333msを使っている。図2の240で示すように、キューの先頭へ向けて発行されるリビルドIO（従って、「『キューの先頭』リビルドIO」と示している）

50

には、動作のために 1 0 0 0 m s のうちの 3 3 3 m s が与えられる。残りの 6 7 7 m s は本発明のファームウェアに与えられ、ホスト I O 要求を処理するために使用されるので、この部分に関して図 2 では「ホスト I O」と示している。「高インパクト」を選択した場合、リビルド I O がキューの先頭へ向けて発行され、図 2 の 2 5 0 で示すように、本発明におけるリビルド I O 処理は 5 0 0 m s (これは 1 0 0 0 m s のうちの 5 0 0 m s であり、半分の時間) にわたって行われる。半分の残った時間は、ホスト I O に関する処理に対して与えられる。「最大インパクト」を選択した場合、リビルド I O がキューの先頭へ向けて発行され、図 2 の 2 6 0 で示すように、本発明におけるリビルド I O 処理は 6 6 6 m s (1 0 0 0 m s のうちの 6 6 6 m s であり、約 6 7 %) にわたって行われる。約 3 3 % の残った時間は、ホスト I O に関する処理に対して与えられる。特定の時間間隔の間に、リビルド I O が全く発行されないが、ホスト I O の間には散在している。リビルド I O は、望まれるリビルド・レートを提供するため、及び効果的なサービス時間を達成するために、適切な遅延を伴って発行される。

10

【 0 0 4 6 】

図 2 では、性能に関する個別の段階的な等級を選択可能とする 4 個のオプション・ボタンのみを示しているが、任意の数の選択可能なオプションを設定できる。例えば、ユーザは、スライダ 2 3 0 として示すスライダ・バーを用いてリビルド・レートを設定することができ、また、0 % ~ 最大 % までの間のパーセンテージを設定することによりリビルド・レートを決定することもできる。更に、人工知能手段を用いて、時刻、リビルド動作の過去の経験、製造者のデータなどのような履歴データに基づいて、リビルド・レートを自動的に設定することもできる。

20

【 0 0 4 7 】

次に、本発明の好適な実施形態の更に詳細なフローチャートを示す図 3 を参照する。図 3 のフローチャートは、0 秒 ~ 7 0 秒までのタイムラインに沿ったサイクルで、校正、再校正、及びリビルドの作業の行われる様子を示す。タイムラインは T 0 ~ T 7 0 までのものとして示され、第 1 のステージは T 0 ~ T 5 、第 2 のステージは T 5 ~ T 1 0 、第 3 のステージは T 1 0 ~ T 7 0 の間となっている。図 3 に示す本発明の方法は、3 ステージに分割されており、処理に要する時間は 7 0 秒であるが、これに限らず、この処理に要する時間はここで教示に従って任意に設定することができる。「通常のリビルド I O を発行」と示された第 1 のステージは、T 0 ~ T 5 の 5 秒で終了する測定段階である。「『キューの先頭』ヘリビルド I O を発行」と示された第 2 のステージは、T 5 ~ T 1 0 の 5 秒で終了する段階であり、リビルド I O 要求をキューの先頭へ向けて発行する間ににおいて必要とされる遅延 (すなわち、遅延 T) をミリ秒単位で計算する。この遅延は、前述のようにリビルドに関する遅延を軽減するためのものである。この遅延は、ヘッド応答時間、リビルドに割り当てられる時間、リビルド・スレッドの数などのパラメータを考慮したものである。「遅延 (m s) 毎に『キューの先頭』ヘリビルド I O を発行」と示された最後の段階である第 3 のステージは、T 1 0 ~ T 7 0 の 6 0 秒で終了する段階であり、ミリ秒毎に「キューの先頭」へ向けてリビルド I O を発行することにより、第 2 のステージで計算された遅延を導入する。計算された遅延 T は、キューの先頭へ向けてのリビルド I O の発行を遅らせる時間である。第 3 のステージが完了するとサイクルが反復される。このようにして、本発明の方法は、発見的な様式で与えられるパラメータに従って、I O の再発行を動的に再校正する。

30

【 0 0 4 8 】

第 1 のステージは、T 0 ~ T 5 の間の 5 秒間 (7 0 秒のうちの 5 秒、即ち、全時間の約 7 %) であり、この第 1 のステージにおいて、本発明に従って R A I D システムのドライブを動作させるファームウェア、ハードウェア、及び / 又はソフトウェア (単に「ファームウェア」という) は、「平均リビルド読み出し応答時間を計算」と示された図 3 のボックス 3 2 5 に示すように、平均リビルド読み出し応答時間を計算する。このリビルドが従来の方法により行われる場合、即ち、本発明を用いず従来技術を用いるリビルド (通常リビルド I O と言う) が行われる場合、ボックス 3 1 0 に示すように「通常のリビルド I O

40

50

を発行」となる。次に、「リビルド・レート < 33% || 応答時間 < 45ms?」と示された判断ボックス330において、ファームウェアは、この従来のリビルドにおいて、リビルド・レートが33%未満であるか（即ち、ホストI/Oに対してインパクトが無いことを、ユーザが要求していることを示すか）、リビルドに関する応答時間が45ms未満であるか（即ち、システムに対して従来のリビルド方法が最適であることを示しているか）を検査する。判断ボックス330におけるこの条件が満たされた場合、ファームウェアは、「YES」と記載された経路をたどり第1のステージの処理を反復する。この処理は、判断ボックス330において条件が満たされなくなる時（「NO」の状態）まで反復される。「NO」の状態となった時点で、処理はT5～T10の第2のステージへ移る。

【0049】

第2のステージは、T5～T10の間の5秒間（70秒のうちの5秒、即ち全時間の約7%）であり、この第2のステージにおいて、ファームウェアは、キューにおける1つのリビルドI/Oコマンドと別のリビルドI/Oコマンドとの間に必要な最適の遅延を計算する。この遅延は、上記で説明したように、ホストI/Oの窮乏及びリビルドI/Oの大きい遅延を避けるためのものである。この最適の遅延を求めるために、図3のボックス340に示すように、ファームウェアは、実際の環境から様々なパラメータを計算し、第2のステージの時間間隔全体にわたってリビルド「キューの先頭」読み出し応答時間の平均値を計算し、第2のステージの最後にこの平均値を用いる。上述のように、この計算には様々なファクタが組み込まれる。

【0050】

最初に、システムがキューの先頭へリビルドI/Oを発行して、それがパラメータとしてファームウェアにより読みとられると、5秒間に、ハード・ドライブのヘッドの読み出し応答時間の平均値が計算される。キューは、この分野の技術では知られた技術であり、RAIDシステムの特定のドライブに対するキューには、リビルドI/O及びホストI/Oが記憶される。本発明ではリビルドI/Oをキューの先頭に配置するので、図3では「キューの先頭」と示している。リビルドI/O要求は、ホストI/O要求とともにキューへ送られ、1つのリビルドI/O要求と別のリビルドI/O要求との間には遅延時間が与えられる。この遅延時間は、初期的にデフォルトで100ミリ秒とすることができ、また、前の70秒サイクルにおいて処理が行われていた場合には、そのサイクルで計算された遅延時間を用いることができる。ハード・ドライブのヘッドの読み出し応答時間は、ファームウェアにより読み出され、このステージ中にその平均が求められる。この処理に関して、図3のボックス340では「平均リビルド『キューの先頭』読み出し応答時間（resp）を計算」と示し、この平均をとられたパラメータを「resp」と表す。

【0051】

次に、リビルド・プロファイルが決定され、リビルドに割り当てられる時間が確かめられる。リビルドに割り当てられる時間は、ホストI/O要求及びリビルドI/O要求の双方を含むリビルドの全時間と相対して求められたものである。前述のように、リビルド・レートが33%～65%のリビルド・レートで、ユーザ及び/又はシステムが「低」を選択した場合、そのパラメータが、変数「リビルドに割り当てられる時間（rt）」に関して選択される。様々なリビルド・プロファイルの選択肢（オプション）に対しての「rt」（ミリ秒で表す）は、（1）33%～65%のリビルド・レートで333ms（低のオプション）、（2）66%～98%のリビルド・レートで500ms（高のオプション）、（3）99%～100%のリビルド・レートで666ms（最大のオプション）である。これらのオプションの数は実施形態に依存するものであり、3個のみではなく任意の数のオプションを設けることができ、段階的な等級として設定することも、最小値から最大値まで連続的なものとすることもできる。

【0052】

そして、図3のボックス340に示されるように、リビルドIOPS(rtIOPS)が

$$\text{リビルドIOPS(rtIOPS)} = rt / resp$$

10

20

30

40

50

に従って計算される。上記の式において、「*r t*」は、リビルドに割り当てられる時間であり、前の計算ステップで得られたものである。「*r e s p*」は、前述のように、「平均リビルド『キューの先頭』読み出し応答時間」、すなわち、キュー先頭読み出し応答時間の平均値である。

【0053】

そしてさらに、パラメータ「*n u m R e b u i l d s*」すなわち「*n R*」が計算される。「*n R*」は、リビルドIOPS(*r IOPS*)を、対象となっているRAIDシステムにおけるリビルド・スレッドの数(図3のボックス340における「リビルド・スレッドの数」)で割ったものである。「*n R*」の値は、

$$\begin{aligned} n u m R e b u i l d s (n R) \\ = r I O P S / (\text{リビルド・スレッドの数}) \end{aligned}$$

により計算される。

【0054】

最後に、T5～T10の間の第2のステージの最終処理で、リビルドIO間で用いる実際の遅延が、

$$\text{リビルドIO間の遅延} = 1000 / n R - r e s p$$

に従って計算される。遅延は 又はTと表す場合もある。上記の式において、1000は時間定数であり、単位はミリ秒である。この時間定数は任意の値とすることができます。なお、IOPSは1秒あたりの値なので、使用に好適な定数は、1秒に対応する1000msである。しかし、この定数が変えられた場合、*r IOPS*も変更する必要がある。このことは、当業者であれば、ここでの教示から理解できる。従って、図3に示すT5からT10の間の第2のステージの計算は、この時間間隔以外の任意の時間定数を用いて行うことができる。なお、上記の式において、前述のように「*n R*」は「*n u m R e b u i l d s*」であり、「*r e s p*」は「平均リビルド『キューの先頭』読み出し応答時間」である。

【0055】

遅延時間(又はT)が計算されると、本発明の方法は第3のステージへ進む。この第3のステージはT10～T70までであり、60秒である。この第3のステージで、RAIDシステムの個々のドライブのキューの先頭へ向けて発行されるリビルドIOを遅延させるために、前のステージで計算した実際の遅延が用いられる。なお、キューは、リビルドIO及びホストIOを含むものである。それぞれのリビルドIOは、そのリビルドIO要求がドライブへ向けて発行される前に、遅延だけ、ファームウェアにより遅延される。このような遅延をキューにおいて用いることにより、上述のように、ホストIOを窮乏しないようにする効果がある。この期間の最後である時点T70で、即ち、時点T0で、校正が新たに開始され、処理が反復される。このように、本発明は発見的及び日和見的であり、ハードウェアの実際の状態を考慮に入れるものである。その理由は、遅延を計算する際にも、ハードウェアの状態は時間とともに変化するからである。

【0056】

ここで説明した本発明の方法及び装置は、RAID2、3、及び4を含めてのRAID1～6までの任意のRAIDレベルで使用可能であり、又はハイブリッドRAIDシステムや、消失訂正符号(erasure code)などを用いる新しいタイプのフェイルセーフ型及び冗長型のストレージでも使用可能である。更に、本発明の方法及び装置は、コピーバック・オペレーションや、RAIDコントローラで用いる必要のある任務で重要なプロセスなどにおいて、用いることができる。この重要なプロセスとは、物理デバイスへIOを発行する必要があり、かつ、ホストIOに対する管理可能なインパクトで、予測可能に完了せねばならないプロセスであり、例えば、メディアのスキャン、整合性の検査、初期設定、フォーマッティングなどであるが、これらに限定されるものではない。

【0057】

本発明の実施形態の構成に関して、当業者であれば、本発明の精神から離れることなく、変更、構成の部分的な削除、別の構成の付加などを行うことができる。更に、ここでは

10

20

30

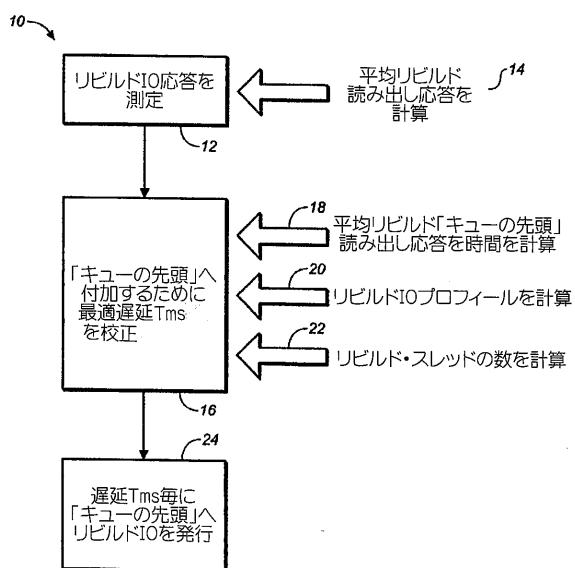
40

50

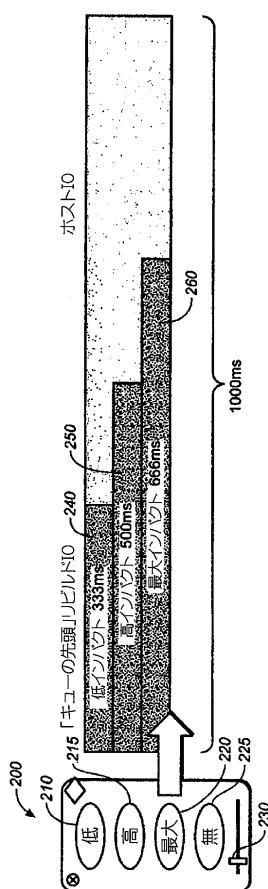
本発明の様々な構成について記載したが、これらの構成の組み合わせを、本発明を解体して構成できる実施形態において用いることもできる。本発明の範囲は、特許請求の範囲により定められる。

本発明の範囲は、変更や付加などがなされた構成の全てにわたることを意図しており、本発明の範囲は、特許請求の範囲によってのみ制限される。

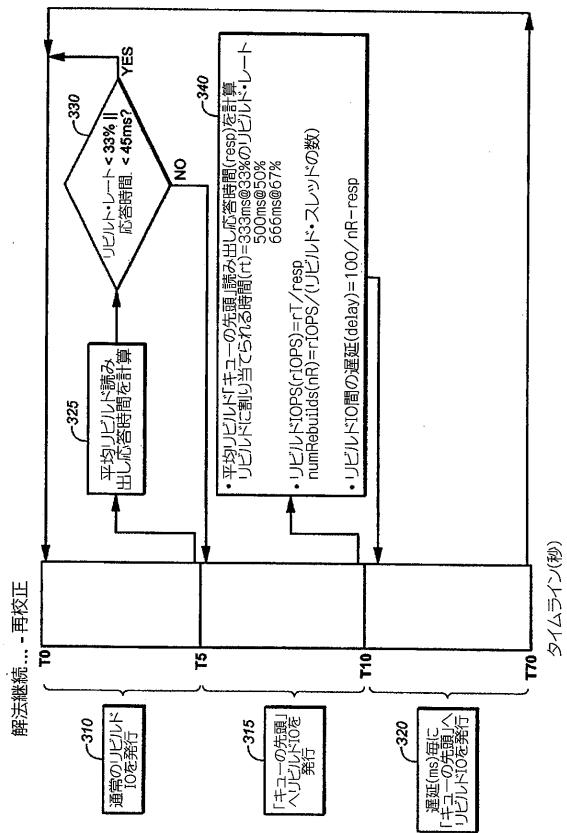
【図1】



【図2】



【図3】



フロントページの続き

(72)発明者 ナマン・ネア

アメリカ合衆国カリフォルニア州 95035 , ミルピタス , バーバー・レイン 1621 , エイデ
イー 800

(72)発明者 カイ・エム・レ

アメリカ合衆国ジョージア州 30093 , ノークロス , シャックルフォード・ロード 4165 ,
エイベヌオーアールシー