

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第6233086号
(P6233086)

(45) 発行日 平成29年11月22日(2017.11.22)

(24) 登録日 平成29年11月2日(2017.11.2)

(51) Int.Cl.

G06F 3/06 (2006.01)

F 1

G 0 6 F	3/06	3 0 6 Z
G 0 6 F	3/06	5 4 0
G 0 6 F	3/06	3 0 5 C
G 0 6 F	3/06	3 0 4 F

請求項の数 8 (全 31 頁)

(21) 出願番号	特願2014-30390 (P2014-30390)
(22) 出願日	平成26年2月20日 (2014.2.20)
(65) 公開番号	特開2015-156081 (P2015-156081A)
(43) 公開日	平成27年8月27日 (2015.8.27)
審査請求日	平成28年11月2日 (2016.11.2)

(73) 特許権者	000005223 富士通株式会社 神奈川県川崎市中原区上小田中4丁目1番 1号
(74) 代理人	100092978 弁理士 真田 有
(74) 代理人	100112678 弁理士 山本 雅久
(72) 発明者	小嵐 弘 神奈川県川崎市中原区上小田中4丁目1番 1号 富士通株式会社内
審査官	桜井 茂行

最終頁に続く

(54) 【発明の名称】ストレージ制御装置、ストレージシステム及び制御プログラム

(57) 【特許請求の範囲】

【請求項 1】

冗長構成がなされた複数の記憶装置及び複数の予備記憶装置と通信路を介して通信可能に接続されるストレージ制御装置であって、

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第1の予備記憶装置に再構成する再構成処理部と、

前記再構成処理部による再構成を行なう際に、前記再構成処理部が前記冗長用記憶装置から読み出したデータを利用して、前記複数の予備記憶装置における、当該データを読み出した前記冗長用記憶装置に対応する第2の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう複製処理部と

を備えることを特徴とする、ストレージ制御装置。

【請求項 2】

リード要求受信時には、前記冗長用記憶装置と、当該冗長用記憶装置のデータを格納する前記第2の予備記憶装置とを併用することを特徴とする、請求項1記載のストレージ制御装置。

【請求項 3】

ライト要求受信時には、前記冗長用記憶装置及び当該冗長用記憶装置のデータを格納する前記予備記憶装置の双方に書き込みを行なうことを特徴とする、請求項1又は2記載のストレージ制御装置。

【請求項 4】

前記記憶装置に対して前記予備記憶装置を割り当てる割当処理部を備え、

前記複製処理部が、前記冗長用記憶装置から読み出したデータを、前記割当処理部が割り当てた前記予備記憶装置に格納することを特徴とする、請求項 1～3 のいずれか 1 項に記載のストレージ制御装置。

【請求項 5】

前記記憶装置に割り当て可能な前記予備記憶装置の数が前記記憶装置の数よりも少ない場合に、

前記割当処理部が、

前記予備記憶装置を、安定度の低い前記記憶装置から優先して割り当てる特徴とする、請求項 4 記載のストレージ制御装置。 10

【請求項 6】

前記再構成処理部による再構成の完了後に、安定度の低い前記冗長用記憶装置に代えて、当該安定度の低い前記冗長用記憶装置の複製がされた前記予備記憶装置を用いて、前記冗長構成を変更する冗長構成変更部を備えることを特徴とする、請求項 1～請求項 5 のいずれか 1 項に記載のストレージ制御装置。

【請求項 7】

冗長構成がなされた複数の記憶装置と、

複数の予備記憶装置と、

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第 1 の予備記憶装置に再構成する再構成処理部と、 20

前記再構成処理部による再構成を行なう際に、前記再構成処理部が前記冗長用記憶装置から読み出したデータを利用して、前記複数の予備記憶装置における、当該データを読み出した前記冗長用記憶装置に対応する第 2 の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう複製処理部と
を備えることを特徴とする、ストレージシステム。

【請求項 8】

冗長構成がなされた複数の記憶装置及び複数の予備記憶装置と通信路を介して通信可能に接続されるコンピュータに、 30

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第 1 の予備記憶装置に再構成し、

前記再構成を行なう際に前記冗長用記憶装置から読み出したデータを利用して、前記複数の予備記憶装置における、当該データを読み出した前記冗長用記憶装置に対応する第 2 の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう処理を実行させることを特徴とする、制御プログラム。

【発明の詳細な説明】**【技術分野】****【0001】**

本発明は、ストレージ制御装置、ストレージシステム及び制御プログラムに関する。 40

【背景技術】**【0002】**

情報通信技術 (Information and Communication Technology ; I C T) システムの普及に伴い、近年、Hard Disk Drive (HDD) に代表される記憶装置（以下、「ディスク」と総称する）を複数使用するディスクアレイ装置が広く用いられるようになっている。このようなディスクアレイ装置では、一般に、Redundant Arrays of Inexpensive Disks (RAID) 技術を用いて、データが 2 台以上のディスクに冗長化されて記録されることにより、データの安全性が担保されている。

【0003】

10

20

30

40

50

ここで、RAIDとは、複数のディスクを組合せて、仮想的な1台のディスク（RAIDグループ）として管理する技術を指す。RAIDには、各ディスクへのデータ配置及び冗長性に応じて、RAID0～RAID6のレベルが存在する。

RAID装置では、RAIDを構成する複数ディスクにまたがるストライプ内にパリティデータを入れてRAIDを構成するディスクの故障に対してデータを保護する。そして、このRAID構成上にLUN（Logical Unit Number）を割り当ててサーバにディスク領域として見せて使用させている。

【0004】

データが冗長化されたディスクアレイ装置において、ディスクが故障すると、故障したディスクに記憶されていたデータが再構築されて、予備ディスクなどの代替ディスクに格納される。このような処理は、一般にリビルド処理と呼ばれる。リビルド処理が実行されることで、データの冗長性が回復する。10

【先行技術文献】

【特許文献】

【0005】

【特許文献1】特開平10-293658号公報

【特許文献2】特開2005-78430号公報

【発明の概要】

【発明が解決しようとする課題】

【0006】

しかしながら、このような従来のディスクアレイ装置において、例えば、RAID上に複数のLUNがある場合に、リビルド処理により一部のLUNの復元が完了していても、RAID内で更にもう1本ディスクが故障した場合には、RAID内の全データがロストし、復元されていたLUNのデータも失われてしまう。20

また、RAID装置上に複数のLUNがある場合に、復元が完了しているLUNであっても、リビルドの全処理が終わるまでは、このリビルド処理による性能劣化の影響を受ける。

【0007】

1つの側面では、本発明は、記憶装置の故障時における信頼性を向上させることを目的とする。30

なお、前記目的に限らず、後述する発明を実施するための形態に示す各構成により導かれる作用効果であって、従来の技術によっては得られない作用効果を奏することも本発明の他の目的の1つとして位置付けることができる。

【課題を解決するための手段】

【0008】

このため、このストレージ制御装置は、冗長構成がなされた複数の記憶装置及び複数の予備記憶装置と通信路を介して通信可能に接続されるストレージ制御装置であって、前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第1の予備記憶装置に再構成する再構成処理部と、前記再構成処理部による再構成を行なう際に、前記再構成処理部が前記冗長用記憶装置から読み出したデータを利用して、前記複数の予備記憶装置における、当該データを読み出した前記冗長用記憶装置に対応する第2の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう複製処理部とを備える。40

【発明の効果】

【0009】

一実施形態によれば、記憶装置の故障時における信頼性を向上させることができる。

【図面の簡単な説明】

【0010】

【図1】実施形態の一例としてのストレージ装置を備えるストレージシステムのハードウェア構成を模式的に示す図である。50

【図2】実施形態の一例としてのストレージ装置の機能構成を示す図である。

【図3】実施形態の一例としてのストレージ装置におけるLUN管理テーブルの構成を例示する図である。

【図4】実施形態の一例としてのストレージ装置におけるリビルド処理を説明する図である。

【図5】実施形態の一例としてのストレージ装置におけるリビルド処理を説明する図である。

【図6】実施形態の一例としてのストレージ装置におけるリビルド処理を説明する図である。

【図7】実施形態の一例としてのストレージ装置におけるRAID構成変更部によるRAID構成変更方法を示す図である。 10

【図8】実施形態の一例としてのストレージ装置におけるリビルド処理の概要を説明するフローチャートである。

【図9】実施形態の一例としてのストレージ装置におけるストレージ構成の決定方法をフローチャートである。

【図10】実施形態の一例としてのストレージ装置におけるリビルド処理を説明するフローチャートである。

【図11】実施形態の一例としてのストレージ装置における予備ディスクの解放要求の有無の確認処理の詳細を説明するフローチャートである。

【図12】実施形態の一例としてのストレージ装置におけるリビルド処理後の処理を説明するフローチャートである。 20

【図13】実施形態の一例としてのストレージ装置におけるリード受信時の処理を説明するフローチャートである。

【図14】実施形態の一例としてのストレージ装置におけるライト受信時の処理を説明するフローチャートである。

【発明を実施するための形態】

【0011】

以下、図面を参照して本ストレージ制御装置、ストレージシステム及び制御プログラムに係る実施の形態を説明する。ただし、以下に示す実施形態はあくまでも例示に過ぎず、実施形態で明示しない種々の変形例や技術の適用を排除する意図はない。すなわち、本実施形態を、その趣旨を逸脱しない範囲で種々変形して実施することができる。又、各図は、図中に示す構成要素のみを備えるという趣旨ではなく、他の機能等を含むことができる。

【0012】

図1は実施形態の一例としてのストレージ装置1を備えるストレージシステム4のハードウェア構成を模式的に示す図である。

ストレージシステム4においては、ストレージ装置1と1つ以上(図1に示す例では2つ)のホスト装置2a, 2bとが冗長化された複数のパスを介して接続されている。

ストレージ装置1は、ドライブエンクロージャ(D E : Drive Enclosure)30に格納された記憶装置31を仮想化して、仮想ストレージ環境を形成する。そしてストレージ装置1は、仮想ボリュームを上位装置であるホスト装置2a, 2bに提供する。 40

【0013】

ホスト装置2a, 2bは、例えば、サーバ機能をそなえた情報処理装置であり、本ストレージ装置1との間において、NAS(Network Attached Storage)やSAN(Storage Area Network)のコマンドを送受信する。これらのホスト装置2a, 2bは、同様の構成を有している。

以下、ホスト装置を示す符号としては、複数のホスト装置のうち1つを特定する必要があるときには符号2a, 2bを用いるが、任意のホスト装置を指すときには符号2を用いる。

【0014】

ホスト装置 2 は、図示しない C P U (Central Processing Unit) やメモリを備え、C P U がメモリ等に格納された O S (Operating System) やプログラムを実行することで、種々の機能を実行する。

ホスト装置 2 は、例えば、ストレージ装置 1 に対して N A S におけるリード / ライト等のディスクアクセスコマンドを送信することにより、ストレージ装置 1 が提供するボリュームにデータの書き込みや読み出しを行なう。

【 0 0 1 5 】

そして、本ストレージ装置 1 は、ホスト装置 2 からボリュームに対して行なわれる入出力要求（例えば、リードコマンドやライトコマンド）に応じて、このボリュームに対応する実ストレージに対して、データの読み出しや書き込み等の処理を行なう。なお、ホスト装置 2 からの入出力要求のことを I O コマンドという場合がある。10

スイッチ 3 a , 3 b は、ホスト装置 2 a , 2 b とストレージ装置 1 のコントローラ 1 0 0 との通信を中継する中継装置である。各スイッチ 3 a , 3 b は、それぞれホスト装置 2 a , 2 b に接続されるとともに、コントローラ 1 0 0 に接続されている。

【 0 0 1 6 】

図 1 に示す例においては、コントローラ 1 0 0 に 2 つのポート 1 0 1 a , 1 0 1 b が備えられている。そして、ポート 1 0 1 a にスイッチ 3 a が、又、ポート 1 0 1 b にスイッチ 3 b が、それぞれ接続され、更に、各スイッチ 3 a , 3 b にそれぞれホスト装置 2 a , 2 b が接続されている。

ストレージ装置 1 は、図 1 に示すように、1 つ以上（本実施形態では 1 つ）のコントローラ 1 0 0 及び 1 つ以上（図 1 に示す例では 1 つ）のドライブエンクロージャ（Drive Enclosure : D E ）3 0 をそなえる。20

【 0 0 1 7 】

ドライブエンクロージャ 3 0 には、1 以上（図 1 に示す例では 8 つ）の記憶装置（物理ディスク）3 1 a - 1 ~ 3 1 a - 4 , 3 1 b - 1 ~ 3 1 b - 4 が搭載され、これらの記憶装置 3 1 a - 1 ~ 3 1 a - 4 , 3 1 b - 1 ~ 3 1 b - 4 の記憶領域（実ボリューム、実ストレージ）を、本ストレージ装置 1 に対して提供する。

以下、記憶装置を示す符号としては、複数の記憶装置のうち 1 つを特定する必要があるときには符号 3 1 a - 1 ~ 3 1 a - 4 , 3 1 b - 1 ~ 3 1 b - 4 を用いるが、任意の記憶装置を指すときには符号 3 1 を用いる。又、記憶装置 3 1 をディスク 3 1 という場合がある。30

【 0 0 1 8 】

また、以下、記憶装置 3 1 a - 1 , 3 1 a - 2 , 3 1 a - 3 , 3 1 a - 4 を、disk1 , disk2 , disk3 , disk4 とそれぞれ表す場合がある。更に、以下、記憶装置 3 1 b - 1 , 3 1 b - 2 , 3 1 b - 3 , 3 1 b - 4 を、disk1' , disk2' , disk3' , disk4' とそれぞれ表す場合がある。

記憶装置 3 1 は、ハードディスクドライブ（Hard disk drive : H D D ）、S S D （Solid State Drive）等の記憶装置であって、種々のデータを格納するものである。

【 0 0 1 9 】

ドライブエンクロージャ 3 0 は、例えば複数段のスロット（図示省略）を備えて構成され、これらのスロットに記憶装置 3 1 を挿入することにより、実ボリューム容量を隨時変更することができる。40

また、ドライブエンクロージャ 3 0 に備えられた複数の記憶装置 3 1 を用いて R A I D （Redundant Arrays of Inexpensive Disks）が構成される。図 1 に示す例においては、記憶装置 3 1 a - 1 ~ 3 1 a - 4 を用いて R A I D が構成されており、これらの記憶装置 3 1 a - 1 ~ 3 1 a - 4 が R A I D グループ 3 0 a を構成している。

【 0 0 2 0 】

この R A I D グループ 3 0 a を構成する記憶装置 3 1 a - 1 ~ 3 1 a - 4 を R A I D 構成ディスク 3 1 a という場合がある。

記憶装置 3 1 b - 1 ~ 3 1 b - 4 は、R A I D ディスクグループ内のディスク故障にそ50

なえて予備的に設けられた予備ディスクであり、ホットスペア (Hot spare ; H S) として用いられる。これらの記憶装置 3 1 b - 1 ~ 3 1 b - 4 が予備ディスクグループ 3 0 b を構成している。以下、記憶装置 3 1 b を予備ディスク 3 1 b という場合がある。

【 0 0 2 1 】

ドライブエンクロージャ 3 0 は、コントローラ 1 0 0 のデバイスアダプタ (Device Adapter : D A) 1 0 3 , 1 0 3 とそれぞれ接続されている。

コントローラエンクロージャ 4 0 は、1 以上 (図 1 に示す例では 1 つ) のコントローラ 1 0 0 を備える。

コントローラ 1 0 0 は、ストレージ装置 1 内の動作を制御するストレージ制御装置であり、ホスト装置 2 から送信される I O コマンドに従って、ドライブエンクロージャ 3 0 の記憶装置 3 1 へのアクセス制御等、各種制御を行なう。10

【 0 0 2 2 】

なお、図 1 に示す例においては、ストレージ装置 1 に 1 つのコントローラ 1 0 0 が備えられているが、これに限定されるものではなく、2 つ以上のコントローラ 1 0 0 を備えてもよい。すなわち、複数のコントローラ 1 0 0 により冗長化を行ない、通常は、いずれかのコントローラ 1 0 0 がプライマリとして各種制御を行ない、このプライマリコントローラ 1 0 0 の故障時には、セカンダリのコントローラ 1 0 0 がプライマリとしての動作を引き継いでもよい。

【 0 0 2 3 】

コントローラ 1 0 0 はポート 1 0 1 a , 1 0 1 b を介してホスト装置 2 に接続される。20
そして、コントローラ 1 0 0 は、ホスト装置 2 から送信されるリード / ライト等の I O コマンドを受信し、D A 1 0 3 等を介して記憶装置 3 1 の制御を行なう。

コントローラ 1 0 0 は、図 1 に示すように、ポート 1 0 1 a , 1 0 1 b と複数 (図 1 に示す例では 2 つ) の D A 1 0 3 , 1 0 3 とをそなえるとともに、C P U 1 1 0 , メモリ 1 0 6 , S S D 1 0 7 及び I O C (Input Output Controller) 1 0 8 をそなえる。

【 0 0 2 4 】

以下、ポートを示す符号としては、複数のポートのうち 1 つを特定する必要があるときには符号 1 0 1 a , 1 0 1 b を用いるが、任意のポートを指すときには符号 1 0 1 を用いる。

ポート 1 0 1 は、ホスト装置 2 等から送信されたデータを受信したり、コントローラ 1 0 0 から出力するデータをホスト装置 2 等に送信する。すなわち、ポート 1 0 1 は、ホスト装置等の外部装置との間でのデータの入出力 (I / O) を制御する。30

【 0 0 2 5 】

ポート 1 0 1 a は、S A N を介してホスト装置 2 と通信可能に接続され、例えば、F C (Fibre Channel) インタフェース等のネットワークアダプタに備えられる F C ポートである。

ポート 1 0 1 b は、N A S を介してホスト装置 2 と通信可能に接続され、例えば、L A N (Local Area Network) インタフェースの N I C ポートである。コントローラ 1 0 0 は、これらのポート 1 0 1 により通信回線を介してホスト装置 2 等と接続され、I / O コマンドの受信やデータの送受信等を行なう。40

【 0 0 2 6 】

そして、ポート 1 0 1 a にスイッチ 3 a が、又、ポート 1 0 1 b にスイッチ 3 b が、それぞれ接続され、更に、各スイッチ 3 a , 3 b にそれぞれホスト装置 2 a , 2 b が接続されている。

すなわち、ホスト装置 2 a , 2 b は、それぞれスイッチ 3 a を介してポート 1 0 1 a に接続されるとともに、スイッチ 3 b を介してポート 1 0 1 b に接続されている。

【 0 0 2 7 】

なお、図 1 に示す例においてはコントローラ 1 0 0 に 2 つのポート 1 0 1 a , 1 0 1 b が備えられているが、これに限定されるものではなく、1 つもしくは 3 つ以上のポートを備えてもよい。

D A 1 0 3 は、ドライブエンクロージャ 3 0 や記憶装置 3 1 等と通信可能に接続するためのインターフェースである。D A 1 0 3 にはドライブエンクロージャ 3 0 の記憶装置 3 1 が接続され、コントローラ 1 0 0 は、ホスト装置 2 から受信した I O コマンドに基づき、これらの記憶装置 3 1 に対するアクセス制御を行なう。

【 0 0 2 8 】

コントローラ 1 0 0 は、これらの D A 1 0 3 を介して、記憶装置 3 1 に対するデータの書き込みや読み出しを行なう。又、図 1 に示す例においては、コントローラ 1 0 0 に 2 つの D A 1 0 3 がそなえられている。そして、コントローラ 1 0 0 において、各 D A 1 0 3 にドライブエンクロージャ 3 0 が接続されている。これにより、ドライブエンクロージャ 3 0 の記憶装置 3 1 には、コントローラ 1 0 0 からデータの書き込みや読み出しを行なうことができる。10

【 0 0 2 9 】

S S D 1 0 7 は、C P U 1 1 0 が実行するプログラムや種々のデータ等を格納する記憶装置である。

メモリ 1 0 6 は、種々のデータやプログラムを一時的に格納する記憶装置であり、図示しないメモリ領域とキャッシュ領域とをそなえる。キャッシュ領域は、ホスト装置 2 から受信したデータや、ホスト装置 2 に対して送信するデータを一時的に格納する。メモリ領域には、C P U 1 1 0 がプログラムを実行する際に、データやプログラムを一時的に格納・展開して用いる。

【 0 0 3 0 】

このメモリ 1 0 6 には、後述する R A I D 制御部 1 2 による R A I D 制御に用いられる、仮 / 実ボリューム変換テーブル 6 2 やディスク構成情報 6 3 , R A I D 構成テーブル 6 4 等が格納される。仮 / 実ボリューム変換テーブル 6 2 は、ホスト装置 2 に提供する仮想ボリュームのアドレスを、記憶装置 3 1 の物理アドレス（実アドレス）にマッピングしているテーブルである。20

【 0 0 3 1 】

ディスク構成情報 6 3 は、本ストレージ装置 1 に備えられる記憶装置 3 1 を管理する情報である。ディスク構成情報 6 3 において、例えば、各記憶装置 3 1 のディスク種別や、各記憶装置 3 1 がライブエンクロージャ 3 0 のどのスロットに取り付けられているか、又、どの記憶装置 3 1 が予備ディスク 3 1 であるか等の情報が管理される。30

R A I D 構成テーブル 6 4 は、後述する R A I D 制御部 1 2 が R A I D の管理を行なうために用いる情報であり、例えば、R A I D 種別や、R A I D グループ 3 0 a を構成する記憶装置 3 1 a を特定する情報等が格納される。

【 0 0 3 2 】

なお、これらの仮 / 実ボリューム変換テーブル 6 2 やディスク構成情報 6 3 , R A I D 構成テーブル 6 4 は既知であるので、その詳細な説明は省略する。

また、メモリ 1 0 6 には、後述するリビルド処理部 1 3 がリビルド処理を行なう際に、各リビルド元ディスク 3 1 a から読み出されたデータが一時的に格納される。

さらに、メモリ 1 0 6 には、後述する、L U N 管理テーブル 6 1 が格納される。L U N 管理テーブル 6 1 の詳細は後述する。40

【 0 0 3 3 】

I O C 1 0 8 は、コントローラ 1 0 0 内におけるデータ転送を制御する制御装置であり、例えば、メモリ 1 0 6 に格納されたデータを C P U 1 1 0 を介すことなく転送させる D M A 転送 (Direct Memory Access) を実現する。

C P U 1 1 0 は、種々の制御や演算を行なう処理装置であり、例えばマルチコアプロセッサ（マルチ C P U ）である。C P U 1 1 0 は、S S D 1 0 7 等に格納された O S やプログラムを実行することにより、種々の機能を実現する。

【 0 0 3 4 】

図 2 は実施形態の一例としてのストレージ装置 1 の機能構成を示す図である。

この図 2 に示すように、ストレージ装置 1 は、I O 制御部 1 1 , R A I D 制御部 1 2 ,

50

リビルド処理部 13，割当処理部 14，ミラーリング処理部 15 及び RAID 構成変更部 16 として機能する。

そして、コントローラ 100 の CPU110 が、制御プログラムを実行することにより、これらの I/O 制御部 11，RAID 制御部 12，リビルド処理部 13，割当処理部 14，ミラーリング処理部 15 及び RAID 構成変更部 16 として機能する。

【0035】

なお、これらの I/O 制御部 11，RAID 制御部 12，リビルド処理部 13，割当処理部 14，ミラーリング処理部 15 及び RAID 構成変更部 16 としての機能を実現するためのプログラム（制御プログラム）は、例えばフレキシブルディスク，CD (CD-ROM, CD-R, CD-RW 等)，DVD (DVD-ROM, DVD-RAM, DVD-R, DVD+R, DVD-RW, DVD+RW, HD DVD 等)，ブルーレイディスク，磁気ディスク，光ディスク，光磁気ディスク等の、コンピュータ読取可能な記録媒体に記録された形態で提供される。そして、コンピュータはその記録媒体からプログラムを読み取って内部記憶装置または外部記憶装置に転送し格納して用いる。又、そのプログラムを、例えば磁気ディスク，光ディスク，光磁気ディスク等の記憶装置（記録媒体）に記録しておき、その記憶装置から通信経路を介してコンピュータに提供するようにしてもよい。

【0036】

I/O 制御部 11，RAID 制御部 12，リビルド処理部 13，割当処理部 14，ミラーリング処理部 15 及び RAID 構成変更部 16 としての機能を実現する際には、内部記憶装置（本実施形態では SSD107 やメモリ 106）に格納されたプログラムがコンピュータのマイクロプロセッサ（本実施形態では CPU110）によって実行される。このとき、記録媒体に記録されたプログラムをコンピュータが読み取って実行するようにしてもよい。

【0037】

RAID 制御部 12 は、記憶装置 31a を用いて RAID を実現し、RAID を構成する記憶装置 31 の制御を行なう。すなわち、RAID 制御部 12 は、複数の記憶装置 31a を用いた冗長構成を設定する。

この RAID 制御部 12 は、上述した RAID 構成テーブル 64 を作成・管理して、RAID 構成ディスク 31a を用いて RAID グループ 30a を設定し、各種 RAID 制御を行なう。なお、RAID 制御部 12 による RAID の管理は既知の手法で実現することができ、その説明は省略する。

【0038】

また、RAID 制御部 12 は、記憶装置 31 を用いて LUN の設定・管理を行ない、ホスト装置 2 はこの設定された LUN に対してデータアクセスを行なう。RAID 制御部 12 は、LUN 管理テーブル 61 を用いて、LUN の管理を行なう。

図 3 は実施形態の一例としてのストレージ装置 1 における LUN 管理テーブル 61 の構成を例示する図である。

【0039】

LUN 管理テーブル 61 は LUN 每に備えられる管理情報であり、この図 3 に例示する LUN 管理テーブル 61 は LUN 1 についての情報を示す。

LUN 管理テーブル 61 は、項目と内容と備考とを関連付けて構成されている。図 3 に示す例においては、LUN 管理テーブル 61 に 12 個の項目が登録されており、これらの項目を特定するための項番 1 ~ 12 が設定されている。

【0040】

具体的には、項目として、LUN 名，構成ディスク名リスト，各ディスク上の位置、サイズ，故障ディスク名，LUN の状態，利用予備ディスク名リスト，ディスクの安定度リスト，リビルド済サイズ，元ディスクのリード / ライト中カウンタ，予備ディスクのリード / ライト中カウンタ，元ディスクの I/O 禁止フラグ及び予備ディスクの I/O 禁止フラグが登録されており、これらに対して 1 ~ 12 の項（項番）が設定されている。

【0041】

10

20

30

40

50

項 1 の LUN 名には、LUN を特定する識別情報が登録され、図 3 に示す例においては “LUN1” が登録されている。項 2 の構成ディスク名リストは、その LUN を構成する記憶装置 31 を示す情報が登録される。すなわち、構成ディスク名リストには、RAID 構成ディスク 31a を示す情報が格納される。図 3 に示す例においては、構成ディスク名リストに disk1, disk2, disk3, disk4 が登録されている。

【0042】

項 3 の各ディスク上の位置、サイズは、その LUN を構成する RAID 構成ディスク 31a 上における、当該 LUN のデータの格納位置とサイズを示す情報が登録される。なお、位置としては、例えばオフセット (Offset) 値が登録される。

項 4 の故障ディスク名は、その LUN を構成する RAID 構成ディスク 31a において、故障の発生が検知された記憶装置 31a を示す情報が登録され、図 3 に示す例においては “disk2” が登録されている。

【0043】

項 5 の LUN の状態は、その LUN の状態を示す情報が格納され、図 3 に示す例においては、正常な状態であることを示す “正常”、リビルド中であることを示す “rebuild 中” 及び、リビルド済みであることを示す “rebuild 済” のいずれかが格納される。

項 6 の利用予備ディスク名リストは、各 RAID 構成ディスク 31a に対応付けられている予備ディスク 31b を示す情報が格納される。なお、この RAID 構成ディスク 31a に対応づけられる予備ディスク 31b は、後述する割当処理部 14 によって設定される。

【0044】

図 3 に示す例においては、項 2 の構成ディスク名リストの disk1, disk2, disk3 及び disk4 に対して、disk1', disk2', disk3' 及び disk4' が対応付けられている。すなわち、disk1 と disk1' とが対をなし、同様に、disk2, disk3 及び disk4 が disk2', disk3' 及び disk4' とそれぞれ対をなす。

また、RAID 構成ディスク 31a の数に対して割り当て可能な予備ディスク 31b の数（本数）が少ない場合には、後述の如く、一部の RAID 構成ディスク 31a に対してのみ予備ディスク 31b が割り当てられる。図 3 においては、このように予備ディスク 31b の数が少ない場合の例も表示されており、割り当てられた予備ディスク 31b のみが示され、割り当てられる予備ディスク 31b がない部分には、横線（-）を記している。

【0045】

項 7 のディスクの安定度リストには、その LUN を構成する RAID 構成ディスク 31a を示す情報が、その安定度が高い順に登録される。図 3 に示す例においては、RAID 構成ディスク 31a が、disk1, disk4, disk3 の順で登録されている。なお、disk2 は故障中であるので、このディスクの安定度リストには登録されない。

項 8 のリビルド済サイズには、項 2 の故障ディスクに関するリビルド処理が実行された場合に、その復元されたデータの合計値（データサイズ）が進捗状況として登録される。このリビルド済みサイズの初期値は 0 であり、リビルド処理の進行に伴い、その値が大きくなる。

【0046】

項 9 の元ディスクのリード / ライト中カウンタには、その LUN を構成する各 RAID 構成ディスク（元ディスク）31a のそれについて、実行中のリードアクセス及びライトアクセスの数が格納される。すなわち、各 RAID 構成ディスク 31a への I/O アクセス状態をリアルタイム表す。

図 3 に示す例においては、各 RAID 構成ディスク 31a のそれに対して、リード中カウンタの値 n とライト中カウンタの値 n とを、(n, n) の形式で示している。

【0047】

ホスト装置 2 から LUN に対するリード要求もしくはライト要求の I/O コマンドを受信すると、例えば、後述する I/O 制御部 11 が、そのアクセス先の RAID 構成ディスク 31a についてのリード中カウンタもしくはライト中カウンタの値をインクリメントする。

10

20

30

40

50

又、I/O制御部11は、リードアクセスもしくはライトアクセスが完了すると、対応するカウンタの値をデクリメントする。

【0048】

この元ディスクのリード／ライト中カウンタの値を参照することで、各RAID構成ディスク31aがI/O処理を実行中であるか否かを判断することができる。

項10の予備ディスクのリード／ライト中カウンタには、各予備ディスク31bのそれについて、実行中のリードアクセス及びライトアクセスの数が格納される。すなわち、各予備ディスク31bへのI/Oアクセス状態を示す。

【0049】

図3に示す例においては、各予備ディスク31bのそれに対して、リード中カウンタの値nとライト中カウンタの値nとを、(n, n)の形式で示している。10

例えば、後述するミラーリング処理部15が、その予備ディスク31bに対してデータのライトを行なう際にライト中カウンタの値をインクリメントする。又、ミラーリング処理部15は、ライト処理が完了すると、対応するカウンタの値をデクリメントする。

【0050】

この予備ディスクのリード／ライト中カウンタの値を参照することで、各予備ディスク31bがI/O処理を実行中であるか否かを判断することができる。

項11の元ディスクのI/O禁止フラグは、そのLUNを構成する各RAID構成ディスク31aのそれについて、I/O処理が禁止されているか否かを示す情報が格納される。20 図3に示す例においては、“0”もしくは“1”が格納され、“1”がフラグとして設定されている場合には、そのRAID構成ディスク31aへのI/Oが禁止されていることを示す。

【0051】

項12の予備ディスクのI/O禁止フラグは、予備ディスク31bのそれについて、I/O処理が禁止されているか否かを示す情報が格納される。図3に示す例においては、“0”もしくは“1”が格納され、“1”がフラグとして設定されている場合には、その予備ディスク31bへのI/Oが禁止されていることを示す。

リビルド処理部13は、例えば、いずれかのディスク31aの故障を検出した場合に、リビルド処理を実行制御する。以下、故障が検出されたディスク31aを故障ディスク31aという場合がある。この故障ディスク31aが復元対象記憶装置に相当する。なお、ディスク31aの故障は、例えば媒体エラー等の所定のエラーが閾値として設定された頻度以上で生じる場合に発生したと判断される。30

【0052】

リビルド処理は、RAIDグループの冗長性を自動回復する処理であり、RAIDグループに属する記憶装置31aが故障した際に、代理として用いられる予備ディスク（代理ディスク、第1の予備記憶装置）31bに対し、故障ディスク31aのデータを、同一RAIDグループにおける故障ディスク31a以外の記憶装置31aのデータを用いて再構築する処理である。以下、同一RAIDグループにおける故障ディスク31a以外の記憶装置（冗長用記憶装置）31aをリビルド元ディスク31aという場合がある。又、このリビルド元ディスクを単に元ディスクという場合もある。40

【0053】

つまり、リビルド処理部13は、故障ディスク31aの発生を検出すると、故障ディスク31a以外のリビルド元ディスク31aのデータを用いて、故障ディスク31aに代わる代理ディスク（リビルド先ディスク）31bに故障ディスク31aのデータを再構築する。

このように、リビルド処理部13は、複数のRAID構成ディスク31aのうち故障ディスク（復元対象記憶装置）31a以外のリビルド元ディスク（冗長用記憶装置）31aから読み出した冗長データを用いて、故障ディスク31aのデータを、予備ディスク（第1の予備記憶装置）に再構成する再構成処理部として機能する。

【0054】

50

リビルド処理部（データ復元部）13による故障ディスク31aのデータの復元は、既知の手法で実現することができる。

同一のRAIDグループ30aを構成する複数の記憶装置31aは、各記憶装置31aのデータが他の複数の記憶装置（冗長用記憶装置）31aに分散してコピーされることにより、冗長化されている。

【0055】

リビルド処理部13は、故障ディスク31aと同じRAIDグループを構成する複数の記憶装置（冗長用記憶装置）31aにそれぞれ格納されたデータを読み出して、代替ディスク31bに格納することで、故障ディスク31aのデータを代替ディスク31bに復元（データディスク構築）する。10

例えば、メモリ106の所定の領域に、格納した故障ディスク31a以外の各リビルド元ディスク31aから読み出したデータを格納し、このデータに対してパリティを用いたXOR（排他的論理和）演算を行なうことで、故障ディスク31aのデータの復元を行なう。

【0056】

図4は実施形態の一例としてのストレージ装置1におけるリビルド処理を説明する図である。この図4に示す例においては、RAIDグループ30aは、4本（3本+1本）のRAID構成ディスク31a-1~31a-4によりRAID5を実現している。又、これらのRAID構成ディスク31a-1~31a-4のうち、ディスク31a-2の故障が検知された場合を示す。20

【0057】

また、この図4に示す例においては、RAIDグループ30aのディスク31a-1~31a-4を用いて3つのLUN1~3が形成されており、これらのうちLUN1のデータ（Data1-2）を復元する例を示している。

リビルド処理部13は、ディスク31a-2の故障を検出すると、同一RAIDグループ30a内のリビルド元ディスク31a-1, 31a-3, 31a-4のデータ（Data1-1, 1-3, 1-4）を用いて、故障ディスク31a-2のデータ（復元Date1-2）を作成する（図4中の破線参照）。

【0058】

そして、この作成した故障ディスク31a-2のデータ（復元Date1-2）を、故障ディスク31a-2に代わる代替ディスク（リビルド先ディスク）31b-2に格納することで、故障ディスク31a-2を再構築する。30

RAIDグループ30aにおいて、複数のLUNが形成されている場合には、リビルド処理部13はLUN毎にリビルド処理を行なう。又、リビルド処理部13は、複数のLUNについてリビルドを行なう場合には、これらの複数のLUNの一覧（図示省略）と、当該一覧においてリビルド処理の進捗を示すポインタとを用いて、リビルド処理の進捗状況を管理する。

【0059】

ミラーリング処理部（複製処理部）15は、リビルド処理部13によるリビルド処理中に、RAIDグループ30a内のリビルド元ディスク（冗長用記憶装置）31aからそれぞれ読み出したデータを、各リビルド元ディスク31aに割り当てられた予備ディスク（第2の予備記憶装置）31bに格納する。これにより、ミラーリング処理部15は、各リビルド元ディスク31aを予備ディスク31bに複製する。40

【0060】

図4に示す例においては、リビルド元ディスク31a-1に対して予備ディスク31b-1が対応付けられており、同様に、リビルド元ディスク31a-3に対して予備ディスク31b-3が、リビルド元ディスク31a-4に対して予備ディスク31b-4が、それぞれ対応付けられている。なお、このようなリビルド元ディスク31aへの予備ディスク31bの対応付けは、後述する割当処理部14が行なう。

【0061】

10

20

30

40

50

ミラーリング処理部 15 は、リビルド処理部 13 によるリビルド処理中に、RAID グループ 30a 内のリビルド元ディスク（冗長用記憶装置）31a から読み出されメモリ 106 に格納されたデータを、対応する予備ディスク 31b に格納（デッドコピー）することで、予備ディスク 31b へのリビルド元ディスク 31a の複製を行なう。

すなわち、図 4 に示す例においては、リビルド元ディスク 31a - 1, 31a - 3, 31a - 4 の LUN 1 の各データ (Data1-1, 1-3, 1-4) が、予備ディスク 31b - 1, 31b - 3, 31b - 4 にそれぞれコピーされる（矢印 P1 ~ P3 参照）。

【0062】

割当処理部 14 は、リビルド元ディスク 31a に対して予備ディスク 31b を対応付ける。以下、リビルド元ディスク 31a に対して予備ディスク 31b を対応付けることを、「割り当てる」と表現する場合がある。
10

また、予備ディスク 31b のうち、RAID 構成ディスク 31a に対応付けられていないディスク 31b を特に未割当予備ディスク 31b という。

【0063】

図 4 に示した例においては、リビルド元ディスク 31a のそれぞれに予備ディスク 31b が対応付けられている。

しかしながら、使用可能な予備ディスク 31b の数がリビルド元ディスク 31a の数に足りず、予備ディスク 31b を全てのリビルド元ディスク 31a に対応付けることができない場合もある。このような場合に、割当処理部 14 は、一部のリビルド元ディスク 31a に対してだけ予備ディスク 31b を割り当てる。
20

【0064】

割当処理部 14 は、RAID サイズ (P) とスペア disk 数 (m) と制限値 (L) とを参照することで、リビルド時に使用する予備ディスク 31b の数を決定する。

ここで、RAID サイズ (P) は、RAID グループ 30a において実現される RAID を構成する記憶装置 31a の数（本数）であり、RAID 種類により決定される。例えば、RAID 5 の場合は 4 本（3 本 + 1 本）である（P=4）。この RAID サイズは、RAID 構成ディスク 31a の数でもある。

【0065】

スペア disk 数 (m) は、使用可能な予備ディスク 31b の数であり、例えば、ディスク構成情報 63 を参照することで確認することができる。制限値 (L) は、例えば予備ディスク 31b の数 (m) が RAID サイズ (P) 未満の場合に、リビルド時に使用する最低限の予備ディスク 31b の数である。例えば、制限値 L = 2 の場合には、リビルド時に 2 本の予備ディスク 31b が用いられる事を示す。制限値 (L) は、管理者等によって予め設定される。
30

【0066】

また、割当処理部 14 は、予備ディスク数 (m) が RAID サイズ (P) に満たない場合に、リビルド元ディスク 31a のうち、安定度が低い、すなわち、不安定なリビルド元ディスク 31a に対して予備ディスク 31b を優先して割り当てる。割当処理部 14 は、例えば、LUN 管理テーブル 61 の項 7 のディスクの安定度リストを参照することで、安定度の低い、すなわち、最も不安定なリビルド元ディスク 31a を知ることができる。
40

【0067】

図 5 は実施形態の一例としてのストレージ装置 1 におけるリビルド処理を説明する図であり、予備ディスク 31b が一部のリビルド元ディスク 31a にだけ対応付けられた例を示す。

この図 5 に示す例においては、RAID 構成ディスク 31a - 2 が故障し、この RAID 構成ディスク 31a - 2 のデータがリビルド処理により代理ディスク 31b - 2 に復元されている（図 5 中の破線参照）。

【0068】

そして、リビルド元ディスク 31a - 1, 31a - 3, 31a - 4 のうち、リビルド元ディスク 31a - 3 に対してだけ予備ディスク 31b - 3 が対応付けられており、他のリ
50

ビルド元ディスク 3 1 a - 1 , 3 1 a - 4 に対しては予備ディスク 3 1 b が対応付けられていない。

全てのリビルト元ディスク 3 1 a に対して予備ディスク 3 1 b を割り当てることができない場合には、割当処理部 1 4 は安定度の低い一部のリビルト元ディスク 3 1 a に対してだけ予備ディスク 3 1 b が割り当てる。

【 0 0 6 9 】

このように、安定度の低い一部のリビルト元ディスク 3 1 a に対してだけ予備ディスク 3 1 b が割り当てられた場合には、ミラーリング処理部 1 5 は、この予備ディスク 3 1 b が割り当てられているリビルト元ディスク 3 1 a のデータを、当該リビルト元ディスク 3 1 a に対して割り当てられた予備ディスク 3 1 b にコピーする。 10

図 5 に示す例においては、リビルト元ディスク 3 1 a - 3 の LUN 1 のデータ (Data1-3) が、予備ディスク 3 1 b - 3 にコピーされる (矢印 P 4 参照)。

【 0 0 7 0 】

すなわち、ミラーリング処理部 1 5 は、リビルト処理部 1 3 によるリビルト処理中に、リビルト元ディスク 3 1 a - 3 から読み出されメモリ 1 0 6 に格納されたデータを、対応する予備ディスク 3 1 b - 3 に格納 (デッドコピー) する。これにより、予備ディスク 3 1 b - 3 にリビルト元ディスク 3 1 のデータの複製が行なわれる。

余分に割り当てた予備ディスク 3 1 b は、システム内で別の RAID に故障が発生して予備ディスク 3 1 b が不足となった場合に、リビルト処理が完了していないくとも、対をなす RAID 構成ディスク 3 1 a が安定している予備ディスク 3 1 b から順番に、割り当てを解除することで未割当予備ディスク 3 1 b として利用する。 20

【 0 0 7 1 】

I/O 制御部 1 1 は LUN に対する I/O 制御を行なう。この I/O 制御部 1 1 は、例えば、LUN に対して FCP (Fibre Channel Protocol) もしくは NAS の I/O 制御を行なう。

I/O 制御部 1 1 は、上述した仮 / 実ボリューム変換テーブル 6 2 を用いて、ホスト装置 2 からの I/O 要求に応じて実ボリュームである記憶装置 3 1 に対する I/O 処理を行なう。I/O 制御部 1 1 は、ホスト装置 2 から送信された I/O 要求に応じて、LUN を構成する記憶装置 3 1 に対して、データのリードやライトを行なう。

【 0 0 7 2 】

図 6 は実施形態の一例としてのストレージ装置 1 におけるリビルト処理を説明する図である。この図 6 に示す例においては、図 4 と同様に、RAID グループ 3 0 a は 4 本の RAID 構成ディスク 3 1 a - 1 ~ 3 1 a - 4 により RAID 5 を実現しており、代理ディスク 3 1 b - 2 に故障ディスク 3 1 a - 2 のデータを再構築している。特にこの図 6 においては、図 4 に示した状態の後、LUN 1 のリビルト処理が完了し、LUN 2 のリビルト処理中の状態を示す。 30

【 0 0 7 3 】

リビルト処理部 1 3 は、リビルト元ディスク 3 1 a - 1 , 3 1 a - 3 , 3 1 a - 4 の LUN 2 のデータ (Data2-1 , 2-3 , 2-4) を用いて、故障ディスク 3 1 a - 2 の LUN 2 のデータ (復元 Date2-2) を作成する。そして、この作成した故障ディスク 3 1 a - 2 の LUN 2 のデータ (復元 Date2-2) を、故障ディスク 3 1 a - 2 に代わる代替ディスク 3 1 b - 2 に格納している (図 6 中の破線参照)。 40

【 0 0 7 4 】

また、これに伴い、ミラーリング処理部 1 5 が、リビルト元ディスク (冗長用記憶装置) 3 1 a - 1 , 3 1 a - 3 , 3 1 a - 4 の LUN 2 の各データ (Data2-1 , 2-3 , 2-4) を、予備ディスク 3 1 b - 1 , 3 1 b - 3 , 3 1 b - 4 にそれぞれコピーしている。

この図 6 に示す状態において、リビルト済みの LUN 1 に対してホスト装置 2 から I/O 要求が行なわれると、I/O 制御部 1 1 は、RAID グループ 3 0 a の RAID 構成ディスク 3 1 a と、予備ディスクグループ 3 0 b の予備ディスク 3 1 b との両方のディスクデータ域を用いて I/O 処理を行なう。

【 0 0 7 5 】

具体的には、LUN 1 のデータに対するリードアクセスが行なわれると、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b を併用してリード処理を行なう。例えば、IO 制御部 11 は、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b をラウンドロビンで交互に選択してリード処理を行なう。

【0076】

リビルド済みの LUN 1 のデータは RAID グループ 30a と予備ディスクグループ 30b との両方に存在し、二重化されている。

リード処理については、これらのデータは RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b のいずれか一方から行なえばよい。本ストレージ装置 1においては、ホスト装置 2 からのリード要求に対して、これらの RAID グループ 30a と予備ディスクグループ 30b との両方を用いてデータリードを行なう。すなわち、複数のデータリードを並列して実行できるようすることでデータリードのパフォーマンスを向上させるとともに、ディスクアクセス負荷を分散させることで、記憶装置 31 の寿命を延ばすことができる。10

【0077】

具体的には、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b をラウンドロビンで交互に選択してリード処理を行なうことで、リビルド中であっても高いストレージアクセス性能を実現することができる。20

一方、LUN 1 のデータに対するライトアクセスが行なわれると、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b との両方に対してライト処理を行なう。

【0078】

このように、ライト処理については、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b とで重複して行なう必要がある。しかしながら、一般に、ストレージ装置においては、ライト処理に比べてリード処理の割合が多く、リード : ライト = 2 : 1 程度であると言われているので、全体的にはライト処理を重複して行なうことによるストレージアクセス性能への影響は少ないと考えられる。30

【0079】

なお、図 6 に示す状態において、リビルドが完了していない LUN 2, 3 に対してホスト装置 2 から IO コマンドが発行されると、IO 制御部 11 は、RAID グループ 30a の RAID 構成ディスク 31a のディスクデータ域を用いて IO 処理を行なう。

例えば、LUN 2 のデータに対するリードアクセスが行なわれると、IO 制御部 11 は、RAID グループ 30a の RAID 構成ディスク 31a からリード処理を行なう。又、故障ディスク 31a - 2 に対するリード処理は、この故障ディスク 31a - 2 以外の各リビルド元ディスク（冗長用記憶装置）31a - 1, 31a - 3, 31a - 4 のデータに対して、パリティを用いた XOR 演算を行なって故障ディスク 31a - 2 のデータの復元を行なって対応する。40

【0080】

また、LUN 2 のデータに対するライトアクセスが行なわれると、IO 制御部 11 は、RAID グループ 30a の RAID 構成ディスク 31a に対してライト処理を行なう。又、故障ディスク 31a - 2 に対するライト処理は、この故障ディスク 31a - 2 以外の各リビルド元ディスク（冗長用記憶装置）31a - 1, 31a - 3, 31a - 4 のデータに対して、パリティを用いた XOR 演算を行なって故障ディスク 31a - 2 のデータの復元を行ない、この復元したデータを用いて、予備ディスクグループ 30b の代理ディスク 31b - 2 に対してライト処理を行なう。

【0081】

RAID 構成変更部 16 は、リビルド処理部 13 によるリビルド処理の完了後に、RA

50

I D グループ 3 0 aにおいて不安定なリビルド元ディスク 3 1 aがある場合には、その不安定なリビルド元ディスク 3 1 aに代えて予備ディスク 3 1 bを用いて R A I D 構成を組み直す。

すなわち、R A I D 構成変更部 1 6は、リビルド処理部 1 3によるリビルド処理の完了後に、安定度の低いリビルド元ディスク 3 1 aに代えて、当該リビルド元ディスク 3 1 aの複製がされた予備ディスク 3 1 bを用いて、R A I D 構成を変更する冗長構成変更部として機能する。

【 0 0 8 2 】

リビルド元ディスク 3 1 aが不安定であるか否かの判断は、例えば、ストレージ統計情報（ログ情報）に基づいて行なう。ストレージ統計情報において所定のエラーが閾値以上検知された場合に、不安定であると判断することができる。10

ストレージ統計情報としては、例えば、各 R A I D 構成ディスク 3 1 aにおける媒体エラーの発生数やシークエラーの発生数を用いることができる。このようなストレージ統計情報は、例えば、各ディスク 3 1 aのファーム等を参照することにより取得することができる。

【 0 0 8 3 】

R A I D 構成変更部 1 6は、リビルド処理部 1 3によりすべての L U N のリビルド処理が完了したら、障害が検知された障害 R A I D を構成する R A I D 構成ディスク 3 1 aと、それに対をなす予備ディスク 3 1 bの信頼性を確認して、より安定な R A I D 構成となるように構成を組みなおす。20

なお、元の R A I D を構成するディスク群の各搭載位置を維持する必要がある場合には、元の R A I D の R A I D 構成ディスク 3 1 aを問題がなければ使用し続けてよい。

【 0 0 8 4 】

図 7 は実施形態の一例としてのストレージ装置 1 における R A I D 構成変更部 1 6による R A I D 構成変更方法を示す図である。

この図 7 に示す例においても、図 4 と同様に、R A I D グループ 3 0 a は 4 本の R A I D 構成ディスク 3 1 a - 1 ~ 3 1 a - 4 により R A I D 5 を実現しており、又、故障ディスク 3 1 a - 2 が代理ディスク 3 1 b - 2 に再構築されている。特にこの図 7 においては、図 6 に示した状態の後、L U N 2 , 3 のリビルド処理が完了した状態を示す。

【 0 0 8 5 】

すなわち、予備ディスク 3 1 b - 1 , 3 1 b - 3 , 3 1 b - 4 には、ミラーリング処理部 1 5 により R A I D 構成ディスク 3 1 a - 1 , 3 1 a - 3 , 3 1 a - 4 のデータがそれぞれ複写されている。30

そして、この図 7 に示す例においては、R A I D 構成ディスク 3 1 a - 3 が不安定であると判断された状態を示す。

【 0 0 8 6 】

リビルド処理の完了後に、R A I D 構成ディスク 3 1 a - 3 が不安定であると判断された場合に、R A I D 構成変更部 1 6 は、この R A I D 構成ディスク 3 1 a - 3 に代えて、R A I D 構成ディスク 3 1 a - 3 のデータが複製された予備ディスク 3 1 b - 3 を用いて R A I D を構成し直す。40

なお、R A I D 構成ディスク 3 1 a - 3 から予備ディスク 3 1 b - 3への切り替えは既知の種々の手法を用いて実現することができる。例えば、R A I D 構成変更部 1 6 は、不安定であると判断された R A I D 構成ディスク 3 1 a - 3 を fail 状態に設定するコマンドを発行することで、R A I D 構成ディスク 3 1 a - 3 を予備ディスク 3 1 b - 3 に切り替える。

【 0 0 8 7 】

また、不安定であると判断された R A I D 構成ディスク 3 1 a が複数ある場合には、これらの複数の R A I D 構成ディスク 3 1 a についても同様に予備ディスク 3 1 b に切り替える。

また、R A I D 構成変更部 1 6 は、リビルド処理の完了後、不安定であると判断されて50

いない R A I D 構成ディスク 3 1 a に対応する予備ディスク 3 1 b を未割当予備ディスク 3 1 b に戻す。これにより、ドライブエンクロージャ 3 0 のスロットに予備ディスク 3 1 b として取り付けられた記憶装置 3 1 を、積極的に予備ディスク 3 1 b として使用することができ、管理が容易になる。図 7 に示す例においては、予備ディスク 3 1 b - 1 , 3 1 b - 4 がフリーの未割当予備ディスク 3 1 b に戻され、R A I D 構成ディスク 3 1 a との対応付けが解除される。

【 0 0 8 8 】

上述の如く構成された実施形態の一例としてのストレージ装置 1 におけるリビルド処理の概要を、図 8 に示すフローチャート（ステップ A 1 ~ A 3 ）に従って説明する。

ステップ A 1 において、割当処理部 1 4 は使用可能な予備ディスク 3 1 b の本数を確認して、ストレージ構成を決定する。なお、このストレージ構成の決定手法の詳細は、図 9 を用いて後述する。

【 0 0 8 9 】

ステップ A 2 において、リビルド処理部 1 3 が故障ディスク 3 1 のリビルド処理を行なう。先ず、ステップ A 2 1 において、R A I D グループ 3 0 a に構成されている全ての L U N についてのリビルドが完了したかを確認する。全 L U N のリビルドが完了していない場合には（ステップ A 2 1 の N O ルート参照）、ステップ A 2 2 において、リビルド処理部 1 3 が、故障ディスク 3 1 のデータを復元する。又、このリビルド処理中に、ミラーリング処理部 1 5 が、リビルド元ディスク 3 1 a から読み出されたデータを対応する予備ディスク 3 1 b にデッドコピーする。これにより、予備ディスク 3 1 b へのリビルド元ディスク 3 1 a の複製が行なわれる。

【 0 0 9 0 】

ステップ A 2 3 において、処理中の L U N のリビルドが完了すると、対になる R A I D 構成ディスク 3 1 a と予備ディスク 3 1 b とを二重化して利用可能にする。例えば、ホスト装置 2 からリード要求を受信した場合には、対を形成する R A I D 構成ディスク 3 1 a と予備ディスク 3 1 b とからラウンドロビンで交互にリードされるようとする。又、ホスト装置 2 からライト処理を受信した場合には、対を形成する R A I D 構成ディスク 3 1 a と予備ディスク 3 1 b との両方にライト処理が行なわれるようとする。その後、ステップ A 2 1 に戻る。

【 0 0 9 1 】

なお、このリビルド処理の詳細は、図 1 0 及び図 1 1 を用いて後述する。

ステップ A 2 1 において全ての L U N についての処理が完了すると（ステップ A 2 1 の Y E S ルート参照）、リビルド処理後の処理、すなわち後処理（ステップ A 3 ）に移行する。

この後処理においては、ステップ A 3 1 において、R A I D 構成変更部 1 6 が、故障が検知された R A I D 構成ディスク 3 1 a に代えて予備ディスク 3 1 b を用いて R A I D 構成を組み直す。

【 0 0 9 2 】

また、R A I D グループ 3 0 a において不安定な R A I D 構成ディスク 3 1 a がある場合には、R A I D 構成変更部 1 6 は、その不安定な R A I D 構成ディスク 3 1 a に代えて、当該 R A I D 構成ディスク 3 1 a に対応する予備ディスク 3 1 b を用いて R A I D 構成を組み直す。

その後、ステップ A 3 2 において、ステップ A 3 1 で使用されなかった予備ディスク 3 1 b を解放して、未割当予備ディスク 3 1 b に戻し、処理を終了する。

【 0 0 9 3 】

なお、故障ディスク 3 1 a や、ステップ A 3 2 において不安定であると判断された R A I D 構成ディスク 3 1 a は、保守作業により当該ストレージ装置 1 から取り外され、新しい記憶装置 3 1 と交換される。

なお、この後処理の詳細は、図 1 2 を用いて後述する。

次に、実施形態の一例としてのストレージ装置 1 におけるストレージ構成の決定方法を

10

20

30

40

50

、図9に示すフローチャート（ステップB1～B8）に従って説明する。

【0094】

ステップB1において、割当処理部14が、RAIDサイズ（P）、予備ディスク数（m）及び制限値（L）を確認する。

ステップB2において、割当処理部14は、“RAIDサイズP = 2”，“予備ディスク数m = 1”及び“制限値L = 1”的3つの条件のうち、少なくともいずれか1つが満たされるか否かを確認する。

【0095】

確認の結果、これらの3つの条件のうち、少なくともいずれか1つが満たされる場合には（ステップB2のYESルート参照）、リビルド処理部13は、従来手法によるリビルド処理を行なう。すなわち、故障ディスク31aのデータを、同一RAIDグループにおける故障ディスク31a以外のリビルド元ディスク31aのデータを用いて再構築する。又、この際、割当処理部14によるリビルド元ディスク31aに対する予備ディスク31bを割り当てや、ミラーリング処理部15によるリビルド元ディスク31aのデータの対応する代理ディスク31bへの複製は行なわれない。10

【0096】

ここでRAIDサイズPは、RAIDにより必要とされる記憶装置31の数を示す。従って、“RAIDサイズP = 2”は、RAIDグループ30aのRAID種類がRAID1の二重化（ミラーリング）であり、リビルド処理が不要であることを意味する。又、“予備ディスク数m = 1”及び“制限値L = 1”は、いずれも予備ディスク31bが1つもしくは0であり、割当処理部14によりRAID構成ディスク31aに割り当て可能な予備ディスク31bがないことを意味する。20

【0097】

一方、確認の結果、上述した3つの条件のいずれも満たされない場合には（ステップB2のNOルート参照）、ステップB3において、“RAIDサイズP > 制限値L”であるか否かが確認される。

RAIDサイズP > 制限値Lである場合（ステップB3のYESルート参照）、ステップB4において、L（例えば、図5に示したようにL = 2）本の予備ディスク31bがリビルド処理及びミラーリング処理に使用される。

【0098】

一方、RAIDサイズP > 制限値Lでない場合（ステップB3のNOルート参照）、ステップB5において、P（例えば、図4等に示したようにL = 4）本の予備ディスク31bがリビルド処理及びミラーリング処理に使用される。30

その後、ステップB6において、RAID制御部12は、記憶装置31aに故障が生じたRAIDグループ30a（故障RAID）において生き残っているRAID構成ディスク31aのストレージ統計情報を確認する。そしてRAID制御部12は、LUN管理テーブル61の項7のディスクの安定度リストとして格納する情報を作成し、LUN管理テーブル61に登録する。ストレージ統計情報として取得した各RAID構成ディスク31aのエラーの発生数に基づき、エラーの発生数に従ってRAID構成ディスク31aをソートすることで、ディスクの安定度リストを作成する。40

【0099】

また、ステップB7において、割当処理部14は、故障が検知されたRAID構成ディスク31aを含む不安定なRAID構成ディスク31aを優先して、RAID構成ディスク31aに予備ディスク31bを割り当てる。RAID制御部12は、LUN管理テーブル61の項6の利用予備ディスク名リストとして格納する情報を作成し、LUN管理テーブル61に登録する。

【0100】

ステップB8において、RAID制御部12は、LUN管理テーブル61の項4～12の各内容を初期化し、又、LUN管理テーブル61の項5のLUNの状態に“リビルド中”を登録して、処理を終了する。50

次に、実施形態の一例としてのストレージ装置1におけるリビルド処理を、図10に示すフローチャート（ステップC1～C10）に従って説明する。

【0101】

ステップC1において、リビルド処理部13は、LUN管理テーブル61を参照することでLUN数を取得する。LUN管理テーブル61はLUN毎に作成されるので、例えばLUN管理テーブル61の数を参照することで、RAIDグループ30aに形成されているLUNの数を把握することができる。又、リビルド処理部13は、処理中のLUNを示す図示しない処理中ポインタに、最初のLUN（LUN域）を示す情報を記憶する。この処理中ポインタを参照することで、リビルド処理の進捗状況を把握することができる。

【0102】

ステップC2において、リビルド処理部13は、処理中ポインタを参照して、未処理のLUN数を確認する。

未処理のLUN数が1つ以上ある場合には（ステップC2のN0ルート参照）、ステップC3において、処理中LUNの情報に基づき、生き残っている各リビルド元ディスク31aを調べ、この生き残っているリビルド元ディスク31aから、RAIDストライプ分のデータを読み出し、メモリ106の所定の領域に格納する。

【0103】

ステップC4において、リビルド処理部13は、各リビルド元ディスク31aから読み出したデータを用いて故障ディスク31aの復元を行なう（復元データ作成）。

ステップC5において、リビルド処理部13は、故障ディスク31に対してもアサインされた予備ディスク31bの所定位置（元と同じ位置）へ復元データを書き出す。又、同時に、ミラーリング処理部15は、生き残っているリビルド元ディスク31から読み出したデータを、各リビルド元ディスク31に対応付けた（アサインした）予備ディスク31bの同じ位置へデッドコピーする。

【0104】

ステップC6において、リビルド処理部13は、LUN管理テーブル61の項8のリビルド済サイズに、リビルドが完了したデータサイズ（リビルド済サイズ）を加算（up）する。

ステップC7において、リビルド処理部13は、他のRAIDの故障による予備ディスクの解放要求があるか否かを確認する。

【0105】

ここで、このステップC7にかかる、予備ディスクの解放要求の有無の確認処理の詳細を、図11に示すフローチャート（ステップC71～C77）に従って説明する。

ステップC71において、他RAIDの故障による予備ディスク31の解放要求があるか否かを確認する。他のRAIDから予備ディスク31bの解放要求がない場合には（ステップC71のN0ルート参照）、処理を終了し、図10のステップC8に移行する。

【0106】

他のRAIDから予備ディスク31bの解放要求がある場合には（ステップC71のYESルート参照）、ステップC72において、リビルド処理部13は、LUN管理テーブル61の項7のディスクの安定度リストを参照して、解放できる予備ディスク31bがあるか否かを確認する。対応するRAID構成ディスク31aが安定していれば予備ディスク31bが代理ディスク31bとして使用される可能性は低い。従って、LUN管理テーブル61の項7のディスクの安定度リストにおいて、安定度が高いRAID構成ディスク31aに対応付けられている予備ディスク31bは、解放して他の記憶装置31aの予備ディスク31bとして使用しても問題ないと考えられる。

【0107】

そこで、例えば、LUN管理テーブル61の項7のディスクの安定度リストに、一つでもRAID構成ディスク31aが登録されれば、解放できる予備ディスク31bがあると判断することができる。

確認の結果（ステップC73）、解放できる予備ディスク31bがある場合には（ステ

10

20

30

40

50

ツップC 7 3 の Y E S ルート参照) 、ステップC 7 4 において、リビルド処理部1 3 は、L U N 管理テーブル6 1 の項1 2 の予備ディスクのI O 禁止フラグに、当該解放対象の予備ディスク3 1 b のI O を禁止にするフラグを設定する。このI O 禁止フラグが設定される予備ディスク3 1 b は、L U N 管理テーブル6 1 の項7 のディスクの安定度リストにおいて先頭に登録されているR A I D 構成ディスク3 1 a に対応する予備ディスク3 1 b であることが望ましい。

【 0 1 0 8 】

これにより、当該予備ディスク3 1 b に対するI O 処理が禁止され、最終的にI O アクセスが無くなるので、当該予備ディスク3 1 b を使用することができるようになる。

その後、ステップC 7 5 において、リビルド処理部1 3 は、L U N 管理テーブル6 1 の項1 0 の予備ディスクのリード / ライト中カウンタにおいて、解放対象の予備ディスク3 1 b のカウンタ値を確認する。

【 0 1 0 9 】

確認の結果(ステップC 7 6)、解放予定の予備ディスク3 1 b がリード中でなく、且つ、ライト中(R W 中)でもない場合、すなわち、解放対象の予備ディスク3 1 b についてリード中カウンタもしくはライト中カウンタのいずれにおいても1以上の値が格納されていない場合には(ステップC 7 6 のN O ルート参照)、ステップC 7 7 に移行する。

このステップC 7 7 において、リビルド処理部1 3 は、L U N 管理テーブル6 1 の項6 の利用予備ディスク名リストから、当該予備ディスク3 1 b を削除してL U N 管理テーブル6 1 を更新する。これにより、リビルド処理部1 3 は、その予備ディスク3 1 b を割り当て可能な予備ディスク3 1 b としてシステムに返却して、処理を終了し、図1 0 のステップC 8 に移行する。

【 0 1 1 0 】

また、ステップC 7 3 における確認の結果、解放できる予備ディスク3 1 b がない場合(ステップC 7 3 のN O ルート参照)や、ステップC 7 6 における確認の結果、解放予定の予備ディスク3 1 b がリード中もしくはライト中(R W 中)である場合にも(ステップC 7 6 のY E S ルート参照)、処理を終了し、図1 0 のステップC 8 に移行する。

ステップC 8 において、リビルド処理部1 3 は、処理中のL U N のリビルド処理が完了したか否かを確認する。この確認の結果(ステップC 9)、リビルド処理が完了していない場合には(ステップC 9 のN O ルート参照)、ステップC 3 に戻る。

【 0 1 1 1 】

一方、リビルド処理が完了した場合には(ステップC 9 のY E S ルート参照)、ステップC 1 0 に移行する。

ステップC 1 0 において、リビルド処理部1 3 は、L U N 管理テーブル6 1 の項5 のL U N の状態に“リビルド済”を設定する。又、リビルド処理部1 3 は、未処理のL U N 数をダウンして、次のL U N 管理テーブル1 0 0 を処理中ポインタに記憶する。その後、ステップC 2 に戻る。

【 0 1 1 2 】

ステップC 2 において、未処理のL U N 数が0である場合には(ステップC 2 のY E S ルート参照)、処理を終了する。

次に、実施形態の一例としてのストレージ装置1におけるリビルド処理後の処理(後処理)を、図1 2 に示すフローチャート(ステップD 1 ~ D 9)に従って説明する。

ステップD 1 において、R A I D 構成変更部1 6 は、上述したリビルド処理を行なった故障ディスク3 1 a 以外のR A I D 構成ディスク3 1 a について、その統計情報を確認することで、これらのR A I D 構成ディスク3 1 a に異常がないかを確認する。

【 0 1 1 3 】

ステップD 2 において、R A I D 構成変更部1 6 は、R A I D 構成ディスク3 1 a に問題の有無を確認する。この問題の有無の確認は、例えば、媒体エラーやシークエラー等の所定のエラーの発生数と閾値とを比較することで行なう。所定のエラーの発生数が閾値を越えている場合に問題があると判断することができる。

10

20

30

40

50

確認の結果、問題があると判断された場合には（ステップD 2のN Oルート参照）、ステップD 3において、その問題があると判断されたR A I D構成ディスク3 1 aを、failさせるリビルダ元ディスク（元ディスク）としてメモリ1 0 6等に記憶して、ステップD 4に移行する。

【0 1 1 4】

また、ステップD 2における確認の結果、問題がないと判断された場合には（ステップD 2のY E Sルート参照）、ステップD 3をスキップしてステップD 4に移行する。

ステップD 4において、R A I D構成変更部1 6は、failさせるディスク3 1 aと解放する予備ディスク3 1 bとにI O禁止フラグを設定する。具体的には、L U N管理テーブル6 1の項1 1において、該当する記憶装置3 1 aにI O禁止フラグを設定する。又、R A I D構成変更部1 6は、L U N管理テーブル6 1の項1 2において、該当する予備ディスク3 1 bにI O禁止フラグを設定する。
10

【0 1 1 5】

ステップD 5において、R A I D構成変更部1 6は、L U N管理テーブル6 1の項9及び項1 0を参照して、failさせる元ディスク及び解放する予備ディスクの各リード／ライト中カウンタの値を確認する。すなわち、これらのfailさせる元ディスク及び解放する予備ディスクが使用されておらずI Oアクセスがないことを確認する。

確認の結果（ステップD 6）、failさせる元ディスク及び解放する予備ディスクの各リード／ライト中カウンタの値が0でない場合には（ステップD 6のN Oルート参照）、ステップD 7において所定の時間（例えば1秒）待った後、ステップD 5に戻る。
20

【0 1 1 6】

ステップD 4において、failさせる元ディスク及び解放する予備ディスクに対してI O禁止フラグを設定することにより、これらのディスク3 1への新規のディスクアクセスがなくなり、最終的には各リード／ライト中カウンタの値が0となる。

failさせる元ディスク及び解放する予備ディスクの各リード／ライト中カウンタの値が0である場合には（ステップD 6のY E Sルート参照）、ステップD 8に移行する。

【0 1 1 7】

ステップD 8において、R A I D構成変更部1 6は、R A I D構成テーブル6 4及びL U N管理テーブル6 1を変更して、R A I D構成を変更する。

例えば、R A I D構成変更部1 6は、R A I D構成テーブル6 4及びL U N管理テーブル6 1において、failさせる元ディスク3 1 aに代えて、ミラーリング処理部1 5により、当該failさせる元ディスクのデータを複製した予備ディスク3 1 bを登録する。これにより、R A I D構成変更部1 6は、R A I Dグループ3 0 aにおいて不安定なリビルダ元ディスク3 1 aに代えて予備ディスク3 1 bを用いてR A I D構成を組み直す。
30

【0 1 1 8】

また、R A I D構成変更部1 6は、L U N管理テーブル6 1の項6の利用予備ディスク名リストから、解放する予備ディスク3 1 bを削除する。

ステップD 9において、R A I D構成変更部1 6は、failさせる元ディスク3 1 aをfail状態に設定するコマンドを発行することでfailさせる。これにより、不要になった予備ディスク3 1 bがシステムに返却（解放）されることになる。
40

【0 1 1 9】

なお、上述したステップD 2において、R A I D構成変更部1 6は、failさせる元ディスクがないと判断された場合には、ステップD 4以降の処理において、failさせる元ディスクに対して行なわれる処理が省略される。

次に、実施形態の一例としてのストレージ装置1におけるリード受信時の処理を図1 3に示すフローチャート（ステップE 1～E 1 3）に従って説明する。

【0 1 2 0】

ステップE 1において、I O制御部1 1は、受信したリード要求がリビルド処理中のR A I Dへのリードであるか否かを確認する。確認の結果（ステップE 2）、リードの要求先のR A I Dグループ3 0 aがリビルド中である場合には（ステップE 2のY E Sルート
50

参照)、ステップE3において、IO制御部11は、受信したリード要求がリビルド処理が完了したLUN領域へのリードであるか否かを確認する。確認の結果(ステップE4)、リードの要求先が未リビルドのLUN領域である場合や(ステップE4のNOルート参照)、リードの要求先のRAIDグループ30aがリビルド中でない場合には(ステップE2のNOルート参照)、従来手法によるリード処理を行なう。

【0121】

すなわち、IO制御部11は、リード要求先の記憶装置31aにアクセスして、要求されたデータを読み出し、ホスト装置2へ送信する。又、リード要求先が故障ディスク31aである場合には、この故障ディスク31a以外の各リビルド元ディスク31aのデータに対して、パリティを用いたXOR演算を行なって故障ディスク31aのデータの復元を行なってホスト装置2へ送信する。10

【0122】

一方、リードの要求先がリビルド済のLUN領域である場合には(ステップE4のYESルート参照)、ステップE5において、IO制御部11は、アクセス対象のRAID構成ディスク31aが二重化されているかを確認する。すなわち、アクセス対象のRAID構成ディスク31aに対して予備ディスク31bが割り当てられ、この予備ディスク31bにRAID構成ディスク31aのデータの複製が格納されているかを確認する。

【0123】

確認の結果(ステップE6)、二重化されている場合には(ステップE6のYESルート参照)、ステップE7において、LUN管理テーブル61の項11及び項12のIO禁止フラグを確認する。すなわち、リード対象のRAID構成ディスク31a及びその対応する予備ディスク31bの両方のIO禁止フラグが“0(off)”であるかを確認する。20

【0124】

確認の結果(ステップE8)、リード対象のRAID構成ディスク31a及びその対応する予備ディスク31bの各IO禁止フラグが共にoffの場合には(ステップE8のYESルート参照)、ステップE9において、IO制御部11は、RAID構成ディスク31aと対応する予備ディスク31bとのうちの一方をラウンドロビンにより交互に選択して、リード対象ディスク31を選択する。このように、RAID構成ディスク31aのデータが予備ディスク31bにより二重化されている場合に、これらのRAID構成ディスク31aと予備ディスク31bとを交互に選択してリードを行なう。これにより、各ディスク31に対するアクセスを分散し、負荷を軽減することで寿命を延ばし、信頼性を向上させることができる。30

【0125】

一方、ステップE7における確認の結果、禁止フラグが共にoffではない場合、すなわち、RAID構成ディスク31a及び対応する予備ディスク31bの一方に、禁止フラグにonが設定されている場合には(ステップE8のNOルート参照)、ステップE10に移行する。

ステップE10において、IO制御部11は、RAID構成ディスク31a及び対応する予備ディスク31bのうち、IO禁止フラグにoffが設定されている方をリード対象ディスク31として選択する。40

【0126】

その後、ステップE11において、IO制御部11は、選択されたリード対象ディスク31について、LUN管理テーブル61の項9もしくは項10のリード/ライト中カウンタをカウントアップする。これにより、選択されたリード対象ディスク31がfailされたりフリーにされることを阻止することができ、信頼性が向上する。

また、ステップE5における確認の結果、二重化がされていない場合にも(ステップE6のNOルート参照)、このステップE11に移行する。

【0127】

ステップE12において、IO制御部11は、リード対象ディスク31へリードを実行50

し、このリードが完了すると、ステップE 1 3において、当該リード対象ディスク3 1について、L U N管理テーブル6 1の項9もしくは項1 0のリード／ライト中カウンタをカウントダウンして、処理を終了する。

次に、実施形態の実施形態の一例としてのストレージ装置1におけるライト受信時の処理を図1 4に示すフローチャート（ステップF 1～F 1 4）に従って説明する。

【0 1 2 8】

ステップF 1において、I O制御部1 1は、受信したライト要求がリビルド処理中のR A I Dへのライトであるか否かを確認する。確認の結果（ステップF 2）、ライトの要求先のR A I Dグループ3 0 aがリビルド中である場合には（ステップF 2のY E Sルート参照）、ステップF 3において、I O制御部1 1は、受信したライト要求がリビルド処理が完了したL U N領域へのライトであるか否かを確認する。確認の結果（ステップF 4）、ライトの要求先が未リビルドのL U N領域である場合や（ステップF 4のN Oルート参照）、ライトの要求先のR A I Dグループ3 0 aがリビルド中でない場合には（ステップF 2のN Oルート参照）、従来手法によるライト処理を行なう。10

【0 1 2 9】

すなわち、I O制御部1 1は、ライト要求先の記憶装置3 1 aにアクセスして、要求されたデータを書き込む。又、ライト要求先が故障ディスク3 1 aである場合には、この故障ディスク3 1 a以外の各リビルド元ディスク3 1 aのデータに対して、パリティを用いたX O R演算を行なって故障ディスク3 1 aのデータの復元を行ない、この復元したデータとつき合わせをしながらデータのライトを行なう。20

【0 1 3 0】

一方、ライトの要求先がリビルド済のL U N領域である場合には（ステップF 4のY E Sルート参照）、ステップF 5において、I O制御部1 1は、ライトデータとR A I Dメンバディスクのデータからパリティデータを生成する。

その後、ステップF 6において、I O制御部1 1は、書き出し対象のR A I D構成ディスク3 1 aが二重化されているかを確認する。すなわち、アクセス対象のR A I D構成ディスク3 1 aに対して予備ディスク3 1 bが割り当てられ、この予備ディスク3 1 bにR A I D構成ディスク3 1 aのデータの複製が格納されているかを確認する。

【0 1 3 1】

確認の結果（ステップF 7）、二重化されている場合には（ステップF 7のY E Sルート参照）、ステップF 8において、L U N管理テーブル6 1の項1 1及び項1 2のI O禁止フラグを確認する。すなわち、ライト対象のR A I D構成ディスク3 1 a及びその対応する予備ディスク3 1 bの両方のI O禁止フラグが“0 (o f f)”であるかを確認する。30

【0 1 3 2】

確認の結果（ステップF 9）、ライト対象のR A I D構成ディスク3 1 a及びその対応する予備ディスク3 1 bの各I O禁止フラグが共にo f fの場合には（ステップF 9のY E Sルート参照）、ステップF 1 0において、I O制御部1 1は、R A I D構成ディスク3 1 aと対応する予備ディスク3 1 bとを二重書きの対象ディスク3 1として選択する。

一方、ステップF 8における確認の結果、禁止フラグが共にo f fではない場合、すなわち、R A I D構成ディスク3 1 a及び対応する予備ディスク3 1 bの一方に、禁止フラグにo nが設定されている場合には（ステップF 9のN Oルート参照）、ステップF 1 1に移行する。40

【0 1 3 3】

ステップF 1 1において、I O制御部1 1は、R A I D構成ディスク3 1 a及び対応する予備ディスク3 1 bのうち、I O禁止フラグにo f fが設定されている方をライト対象ディスク3 1として選択する。

その後、ステップF 1 2において、I O制御部1 1は、選択されたライト対象ディスク3 1について、L U N管理テーブル6 1の項9もしくは項1 0のリード／ライト中カウンタをカウントアップする。これにより、選択されたライト対象ディスク3 1がfailされた50

リフリーにされることを阻止することができ、信頼性が向上する。

【0134】

また、ステップF6における確認の結果、二重化がされていない場合にも（ステップF7のN0ルート参照）、このステップF12に移行する。

ステップF13において、IO制御部11は、ライト対象ディスク31へライトを実行し、このライトが完了すると、ステップF14において、当該ライト対象ディスク31について、LUN管理テーブル61の項9もしくは項10のリード／ライト中カウンタをカウントダウンして、処理を終了する。

【0135】

このように、実施形態の一例としてのストレージ装置1によれば、ミラーリング処理部15がRAID構成ディスク31aの複製を、当該RAID構成ディスク31aに対応する予備ディスク31bに作成することで、各RAID構成ディスク31aのデータを冗長化することができる。これにより、複数のRAID構成ディスク31aが故障した場合でも、予備ディスク31bを用いてRAIDを構成しなおすことにより、RAID内の全データのロストの発生を阻止することができる。これにより信頼性を向上させることができる。10

【0136】

また、リビルド処理が完了したLUNは、リビルド処理による性能劣化の影響が緩和され、データ保護状態に速やかに戻ることができる。

リード時において、冗長化されたRAID構成ディスク31aのデータと予備ディスク31bのデータとをラウンドロビンで交互に選択してリード処理を行なうことで、リビルド中であっても高いストレージアクセス性能を実現することができる。更に、リード時に、冗長化されたRAID構成ディスク31aと予備ディスク31bとを均等に用いることで負荷を分散させることができる。20

【0137】

RAID構成変更部16が、リビルド処理の完了時点で、RAIDグループ30a内に不安定なRAID構成ディスク31aを検知した場合に、この不安定なRAID構成ディスク31aに代えて対応する予備ディスク31bを用いてRAIDを構成し直す。これにより、RAID構成ディスク31aの故障を未然に阻止することができ、信頼性を向上させることができる。30

【0138】

ミラーリング処理部15が、リビルド時にリビルド元ディスク31aからメモリ106に読み出されたデータを、当該リビルド元ディスク31aに対応する予備ディスク31bにデッドコピーすることで、リビルド元ディスク31aの複製を予備ディスク31bに容易に作成することができる。この際、コントローラ100のCPU110等による特別な制御が不要であり、コントローラ100の負荷の増大や処理速度の低下が発生するがない。

【0139】

そして、開示の技術は上述した実施形態に限定されるものではなく、本実施形態の趣旨を逸脱しない範囲で種々変形して実施することができる。本実施形態の各構成及び各処理は、必要に応じて取捨選択することができ、あるいは適宜組み合わせてもよい。40

例えば、上述した実施形態においては、リビルド処理部13がいずれかの記憶装置31aの故障を検知した場合にリビルド処理を行なっている例を示しているが、これに限定されるものではない。例えば、いずれかの記憶装置31a故障の発生が予測される場合に、この故障の発生が予測される記憶装置31aを故障ディスク31aとしてリビルド処理を行なってもよく、又、予防保守の観点等から、異常のない記憶装置31aを故障ディスク31aとしてリビルド処理を行なってもよい。

【0140】

また、上述した実施形態においては、RAIDグループ30aが4本（3本+1本）のRAID構成ディスク31aによりRAID5を実現している例を示しているが、これに50

限定されるものではない。例えば、RAID 2～4 や RAID 50 (5+0)、RAID 6、RAID 10 等、種々変形して実施することができる。

上述した実施形態においては、IO 制御部 11 が、RAID グループ 30a の RAID 構成ディスク 31a と、予備ディスクグループ 30b の予備ディスク 31b とをラウンドロビンで交互に選択してリード処理を行なっているが、これに限定されるものではない。すなわち、RAID 構成ディスク 31a と、この RAID 構成ディスク 31a の複製が格納された予備ディスク 31b とから必ずしも交互にデータリードを行なう必要はなく、結果として均等にデータのリードを行なうことで負荷が分散できればよい。

【0141】

また、上述した開示により本実施形態を当業者によって実施・製造することが可能である。10

以上の実施形態に関し、更に以下の付記を開示する。

(付記 1)

冗長構成がなされた複数の記憶装置及び複数の予備記憶装置と通信路を介して通信可能に接続されるストレージ制御装置であって、

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第 1 の予備記憶装置に再構成する再構成処理部と、

前記再構成処理部による再構成を行なう際に前記冗長用記憶装置から読み出したデータを、前記複数の予備記憶装置のうちの前記冗長用記憶装置に対応する第 2 の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう複製処理部とを備えることを特徴とする、ストレージ制御装置。20

【0142】

(付記 2)

リード要求受信時には、前記冗長用記憶装置と、当該冗長用記憶装置のデータを格納する前記第 2 の予備記憶装置とを併用することを特徴とする、付記 1 記載のストレージ制御装置。

(付記 3)

ライト要求受信時には、前記冗長用記憶装置及び当該冗長用記憶装置のデータを格納する前記予備記憶装置の双方に書き込みを行なうことを特徴とする、付記 1 又は 2 記載のストレージ制御装置。30

【0143】

(付記 4)

前記記憶装置に対して前記予備記憶装置を割り当てる割当処理部を備え、

前記複製処理部が、前記冗長用記憶装置から読み出したデータを、前記割当処理部が割り当てる前記予備記憶装置に格納することを特徴とする、付記 1～3 のいずれか 1 項に記載のストレージ制御装置。

【0144】

(付記 5)

前記記憶装置に割り当てる可能な前記予備記憶装置の数が前記記憶装置の数よりも少ない場合に、40

前記割当処理部が、

前記予備記憶装置を、安定度の低い前記記憶装置から優先して割り当てる特徴とする、付記 4 記載のストレージ制御装置。

【0145】

(付記 6)

前記再構成処理部による再構成の完了後に、安定度の低い前記冗長用記憶装置に代えて、当該安定度の低い前記冗長用記憶装置の複製がされた前記予備記憶装置を用いて、前記冗長構成を変更する冗長構成変更部を備えることを特徴とする、付記 1～付記 5 のいずれか 1 項に記載のストレージ制御装置。50

【0146】

(付記7)

冗長構成がなされた複数の記憶装置と、

複数の予備記憶装置と、

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第1の予備記憶装置に再構成する再構成処理部と、

前記再構成処理部による再構成を行なう際に前記記憶装置から読み出したデータを、前記複数の予備記憶装置のうちの前記冗長用記憶装置に対応する第2の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう複製処理部と
10
を備えることを特徴とする、ストレージシステム。

【0147】

(付記8)

リード要求受信時には、前記冗長用記憶装置と、当該冗長用記憶装置のデータを格納する前記第2の予備記憶装置とを併用することを特徴とする、付記7記載のストレージシステム。

(付記9)

ライト要求受信時には、前記冗長用記憶装置及び当該冗長用記憶装置のデータを格納する前記予備記憶装置の双方に書き込みを行なうことを特徴とする、付記7又は8記載のストレージシステム。
20

【0148】

(付記10)

前記記憶装置に対して前記予備記憶装置を割り当てる割当処理部を備え、

前記複製処理部が、前記冗長用記憶装置から読み出したデータを、前記割当処理部が割り当てる前記予備記憶装置に格納することを特徴とする、付記7～9のいずれか1項に記載のストレージシステム。

【0149】

(付記11)

前記記憶装置に割り当て可能な前記予備記憶装置の数が前記記憶装置の数よりも少ない場合に、
30

前記割当処理部が、

前記予備記憶装置を、安定度の低い前記記憶装置から優先して割り当てる特徴とする、付記10記載のストレージシステム。

【0150】

(付記12)

前記再構成処理部による再構成の完了後に、安定度の低い前記冗長用記憶装置に代えて、当該安定度の低い前記冗長用記憶装置の複製がされた前記予備記憶装置を用いて、前記冗長構成を変更する冗長構成変更部を備えることを特徴とする、付記7～付記11のいずれか1項に記載のストレージシステム。

【0151】

(付記13)

冗長構成がなされた複数の記憶装置及び複数の予備記憶装置と通信路を介して通信可能に接続されるコンピュータに、

前記複数の記憶装置のうち復元対象記憶装置以外の冗長用記憶装置から読み出した冗長データを用いて、前記復元対象記憶装置のデータを、前記複数の予備記憶装置のうちの第1の予備記憶装置に再構成し、
40

前記再構成を行なう際に前記冗長用記憶装置から読み出したデータを、前記複数の予備記憶装置のうちの前記冗長用記憶装置に対応する第2の予備記憶装置に格納することで、前記冗長用記憶装置の複製を行なう

処理を実行させることを特徴とする、制御プログラム。
50

【0152】

(付記14)

リード要求受信時には、前記冗長用記憶装置と、当該冗長用記憶装置のデータを格納する前記第2の予備記憶装置とを併用する

処理を前記コンピュータに実行させることを特徴とする、付記13記載の制御プログラム。

【0153】

(付記15)

ライト要求受信時には、前記冗長用記憶装置及び当該冗長用記憶装置のデータを格納する前記予備記憶装置の双方に書き込みを行なう

10

処理を前記コンピュータに実行させることを特徴とする、付記13又は14記載の制御プログラム。

【0154】

(付記16)

前記記憶装置に対して前記予備記憶装置を割り当て、

前記冗長用記憶装置から読み出したデータを、前記割当処理部が割り当てた前記予備記憶装置に格納する

処理を前記コンピュータに実行させることを特徴とする、付記13～15のいずれか1項に記載の制御プログラム。

【0155】

20

(付記17)

前記記憶装置に割り当て可能な前記予備記憶装置の数が前記記憶装置の数よりも少ない場合に、

前記予備記憶装置を、安定度の低い前記記憶装置から優先して割り当てる

処理を前記コンピュータに実行させることを特徴とする、付記16記載の制御プログラム。

【0156】

(付記18)

前記再構成の完了後に、安定度の低い前記冗長用記憶装置に代えて、当該安定度の低い前記冗長用記憶装置の複製がされた前記予備記憶装置を用いて、前記冗長構成を変更する処理を前記コンピュータに実行させることを特徴とする、付記13～付記17のいずれか1項に記載の制御プログラム。

30

【符号の説明】

【0157】

1 ストレージ装置

2 ホスト装置

3 a , 3 b スイッチ

4 ストレージシステム

1 1 I O 制御部

1 2 R A I D 制御部

1 3 リビルド処理部

1 4 割当処理部

1 5 ミラーリング処理部

1 6 R A I D 構成変更部

3 0 ドライブエンクロージャ

3 0 a R A I D グループ

3 0 b 予備ディスクグループ

3 1 記憶装置

3 1 a , 3 1 a - 1 ~ 3 1 a - 4 記憶装置 (R A I D 構成ディスク , リビルド元ディスク)

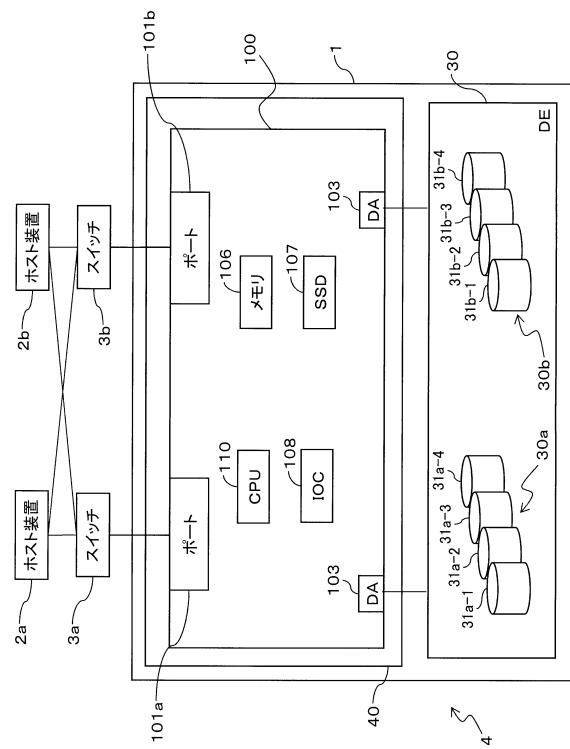
40

50

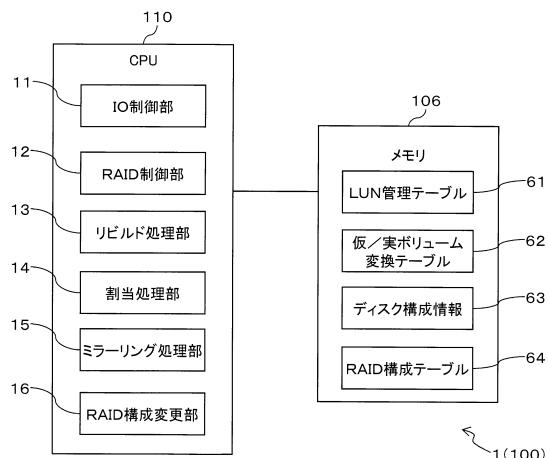
3 1 b , 3 1 b - 1 ~ 3 1 b - 4 予備ディスク
 4 0 コントローラエンクロージャ
 6 1 LUN 管理テーブル
 6 2 仮 / 実ボリューム変換テーブル
 6 3 ディスク構成情報
 6 4 RAID 構成テーブル
 1 0 0 コントローラ (ストレージ制御装置)
 1 0 1 a , 1 0 1 b ポート
 1 0 3 DA
 1 0 6 メモリ
 1 0 7 SSD
 1 0 8 IOC
 1 1 0 CPU

10

【図1】



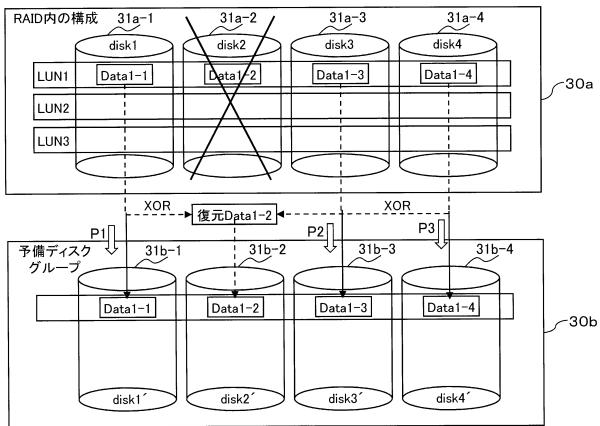
【図2】



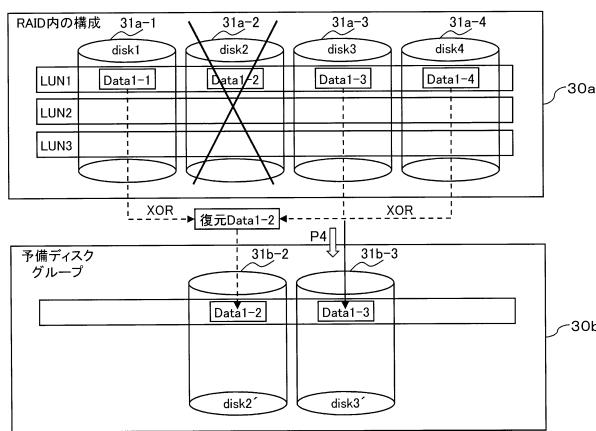
【図3】

項目	内容	備考
1 LUN名	LUN1	
2 構成ディスク名リスト	(disk1, disk2, disk3, disk4)	
3 各ディスク上の位置、サイズ	Offset値、+サイズ	
4 故障ディスク名	disk2	
5 LUNの状態	正常 or rebuild中 or rebuild済	
6 利用予備ディスク名リスト	(disk1', disk2', disk3', disk4') or (-, disk2', disk3', -)	予備ディスクが少ない時
7 ディスクの安定度リスト	disk1, disk4, disk3	高い順
8 リビルド済サイズ	サイズ	初期値=0
9 元ディスクのリード/ライト中カウンタ	((0, 0, 0, 0), (0, 0, 0, 0))	(リード=n, ライト=n)
10 予備ディスクのリード/ライト中カウンタ	((0, 0, 0, 0), (0, 0, 0, 0))	RAID構成の変更同期用
11 元ディスクのIO禁止フラグ	(0, 0, 0, 0)	ディスク毎のフラグ(1:禁止、0:許可)
12 予備ディスクのIO禁止フラグ	(0, 0, 0, 0)	RAID構成の変更同期用

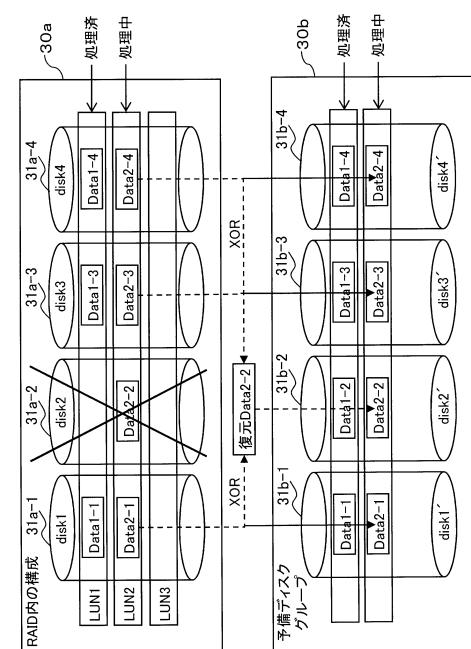
【図4】



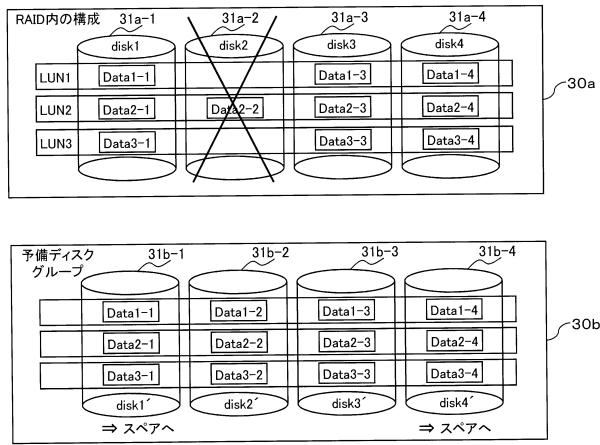
【図5】



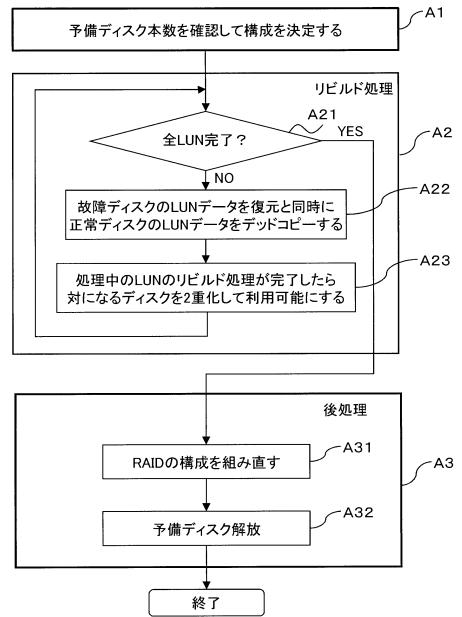
【図6】



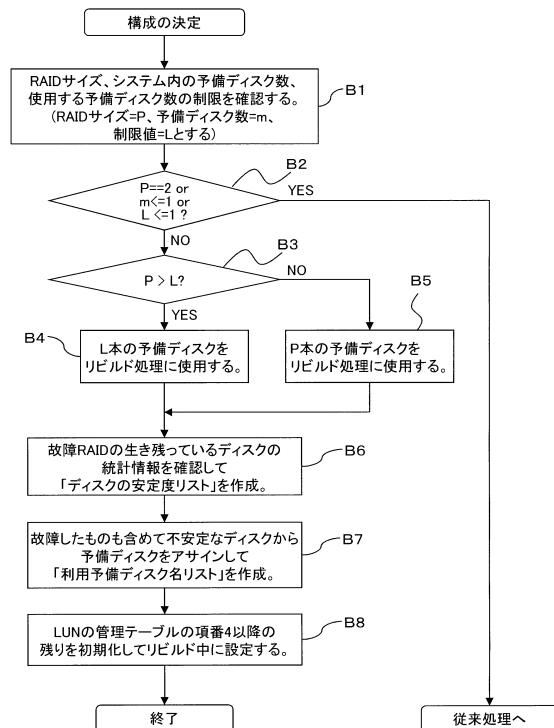
【図7】



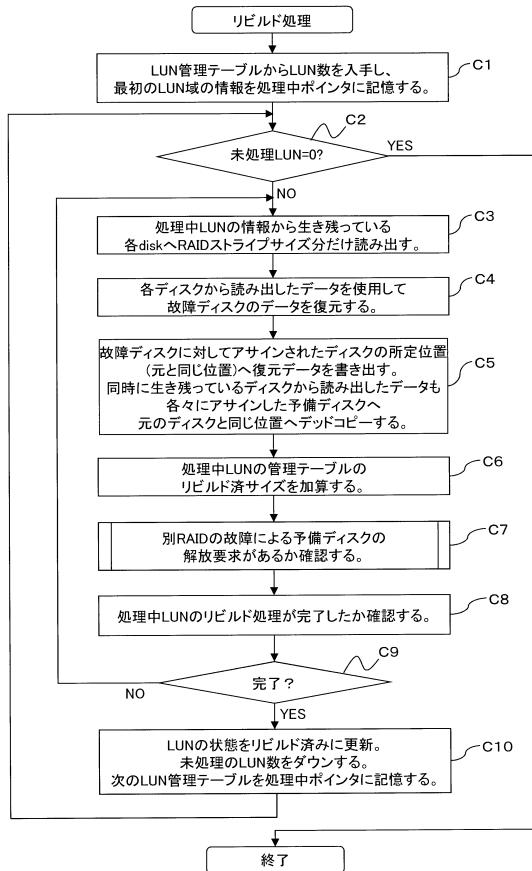
【図8】



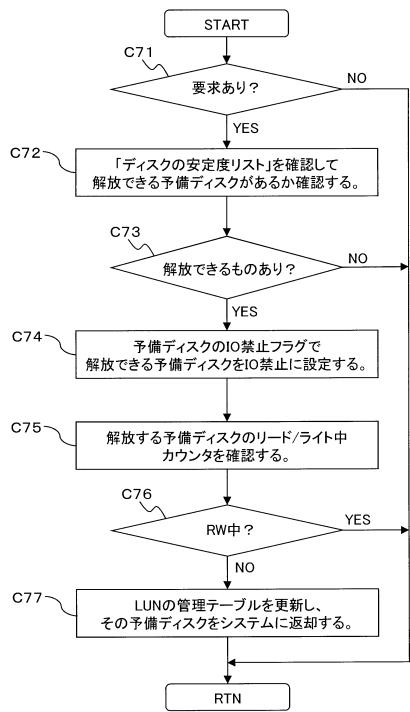
【図9】



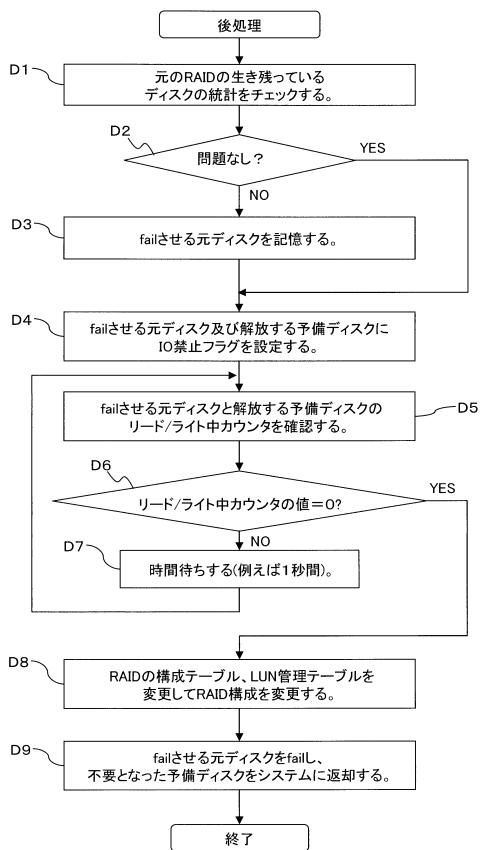
【図10】



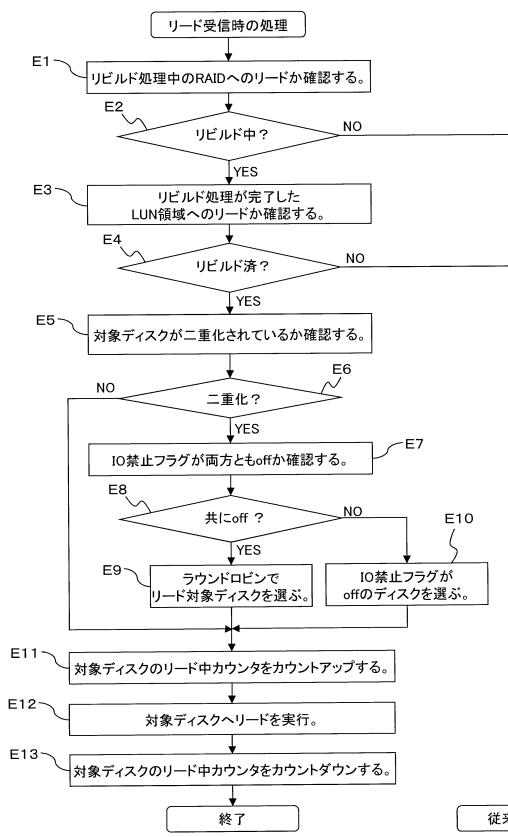
【図11】



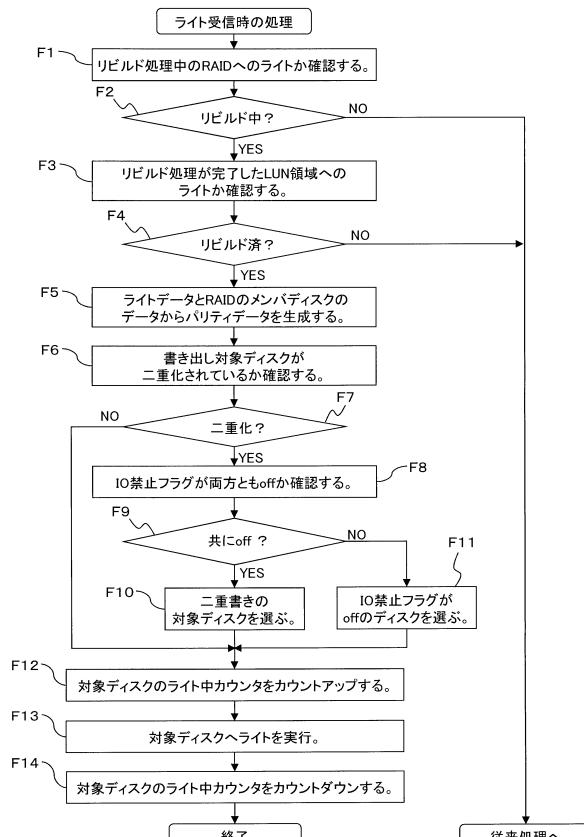
【図12】



【図13】



【図14】



フロントページの続き

(56)参考文献 特開2007-233903(JP,A)
米国特許出願公開第2007/0220313(US,A1)
特開平11-085410(JP,A)
特開平09-305324(JP,A)
特開2006-164304(JP,A)
米国特許出願公開第2008/0126839(US,A1)
米国特許第7685463(US,B1)
米国特許出願公開第2007/0294567(US,A1)

(58)調査した分野(Int.Cl., DB名)

G 06 F 3 / 06 - 3 / 08
G 06 F 13 / 10 - 13 / 14
G 06 F 12 / 16