

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第4224077号
(P4224077)

(45) 発行日 平成21年2月12日(2009.2.12)

(24) 登録日 平成20年11月28日(2008.11.28)

(51) Int.Cl.

G06F 3/06 (2006.01)

F 1

G06F 3/06 301Z

請求項の数 7 (全 30 頁)

(21) 出願番号 特願2006-103256 (P2006-103256)
 (22) 出願日 平成18年4月4日 (2006.4.4)
 (65) 公開番号 特開2007-279898 (P2007-279898A)
 (43) 公開日 平成19年10月25日 (2007.10.25)
 審査請求日 平成18年4月4日 (2006.4.4)

(73) 特許権者 000003078
 株式会社東芝
 東京都港区芝浦一丁目1番1号
 (73) 特許権者 301063496
 東芝ソリューション株式会社
 東京都港区芝浦一丁目1番1号
 (74) 代理人 100058479
 弁理士 鈴江 武彦
 (74) 代理人 100091351
 弁理士 河野 哲
 (74) 代理人 100088683
 弁理士 中村 誠
 (74) 代理人 100108855
 弁理士 蔵田 昌俊

最終頁に続く

(54) 【発明の名称】ストレージシステム

(57) 【特許請求の範囲】

【請求項 1】

物理ボリュームを有する少なくとも2つのノードを含む複数のノードから構成され、前記少なくとも2つのノードが有する物理ボリュームを利用して、ホストに対して複数の論理工クスティントから構成される論理ボリュームを提供するストレージシステムにおいて、

前記複数のノードの少なくとも2つは、前記ホストに対して前記論理ボリュームを提供し、当該ホストからのアクセスを受け付けるコントローラを有し、

前記少なくとも2つのノードは、前記論理ボリュームを構成する論理工クスティントを物理工クスティントにマッピングして前記物理ボリューム内に格納するストレージを有し、

前記複数のノードの少なくとも2つは、前記論理ボリュームを構成する論理工クスティントのうち、自身が担当すべき論理工クスティントを格納しているストレージの所在に関する前記コントローラからの問い合わせに対して回答する所在管理サービスを実行する所在管理サーバを有し、

前記コントローラは、前記論理ボリュームを構成する論理工クスティントに対応する所在管理サーバを示す第1のマッピングテーブルを有し、

前記所在管理サーバは、前記論理ボリュームを構成する論理工クスティントのうち、当該サーバが担当すべき論理工クスティントについて、その論理工クスティントがどのノードのストレージに格納されているかを示す第2のマッピングテーブルを有し、

前記ストレージは、論理工クスティントを、当該ストレージが有する物理ボリュームのどの物理工クスティントに対応させて格納したかを示す第3のマッピングテーブルを有し、

10

20

前記コントローラは、前記ホストから前記論理ボリューム内の任意の論理工エクステントをアクセス先として指定するアクセス要求が与えられた場合、当該コントローラが有する前記第1のマッピングテーブルを参照することにより当該アクセス先の論理工エクステントに対応する所在管理サーバを特定し、特定された所在管理サーバに対して、当該論理工エクステントがどのストレージに格納されているかを問い合わせ、

前記所在管理サーバは前記コントローラから問い合わせを受けた場合、当該サーバが有する前記第2のマッピングテーブルを参照することにより問い合わせられたストレージを特定して、当該ストレージを示す情報を前記問い合わせに対する回答として問い合わせ元の前記コントローラに通知し、

前記コントローラは、前記所在管理サーバから前記問い合わせに対する回答として通知された情報の示すストレージに対して前記ホストから要求された論理工エクステントへのアクセスを要求し、10

前記ストレージは、前記コントローラから論理工エクステントへのアクセスが要求された場合、当該ストレージが有する前記第3のマッピングテーブルを参照することにより、当該ストレージが有する前記物理ボリューム内で前記要求された論理工エクステントに対応させられている物理エクステントを特定して、当該特定された物理エクステントに対してアクセスしてアクセス要求元の前記コントローラに応答し、

論理工エクステントを構成する物理エクステント内のデータを前記ストレージをまたがって別の物理エクステントに移動またはコピーするエクステント移動またはコピーが発生した場合、移動元及び移動先またはコピー先のストレージが有する前記第3のマッピングテーブルは当該エクステント移動またはコピーが反映されるように更新され、当該論理工エクステントを格納しているストレージの所在の問い合わせに対して回答する所在管理サーバが有する前記第2のマッピングテーブルは、当該論理工エクステントを格納しているストレージとして移動先のストレージ、またはコピー元及びコピー先のストレージを示すように更新される20

ことを特徴とするストレージシステム。

【請求項2】

前記所在管理サーバが有する前記第2のマッピングテーブルによって示されている、ある論理工エクステントがどのノードのストレージに格納されているかを示す情報を別の所在管理サーバが有する前記第2のマッピングテーブルに移動する所在管理サービス移動が発生した場合、移動元及び移動先の前記第2のマッピングテーブル、及び全ての前記コントローラが有する前記第1のマッピングテーブルは、当該所在管理サービス移動が反映されるように更新される30

ことを特徴とする請求項1記載のストレージシステム。

【請求項3】

前記所在管理サーバが有する前記第2のマッピングテーブルによって示されている、ある論理工エクステントがどのノードのストレージに格納されているかを示す情報を別の所在管理サーバが有する前記第2のマッピングテーブルにコピーする所在管理サービスコピーが発生した場合、コピー先の前記第2のマッピングテーブル、及び全ての前記コントローラが有する前記第1のマッピングテーブルは、当該所在管理サービスコピーが反映されるように更新される40

ことを特徴とする請求項1記載のストレージシステム。

【請求項4】

前記第3のテーブルは、前記論理ボリュームの作成時の初期状態において当該論理ボリュームを構成する論理工エクステントが格納される物理ボリュームのみを示し、

前記ストレージは、前記コントローラから論理工エクステントへのアクセスが要求されて、当該ストレージが有する前記第3のマッピングテーブルを参照した結果、当該ストレージが有する前記物理ボリューム内で前記要求された論理ボリュームに物理エクステントが対応付けられていないことが判別された場合、前記物理ボリューム内の空き物理エクステントを当該論理工エクステントに割り付けて前記第3のマッピングテーブルを更新する50

ことを特徴とする請求項 1 記載のストレージシステム。

【請求項 5】

前記第 2 のテーブルは、前記論理ボリュームの作成時の初期状態において、当該サーバに対応する論理工クステントに対してストレージの未割り付けの状態にあることを示し、

前記第 3 のテーブルは、前記論理ボリュームの作成時の初期状態において、当該論理ボリュームを構成する論理工クステントに対して物理ボリューム及び物理エクステントの未割り付けの状態にあることを示し、

前記所在管理サーバは、前記コントローラからの問い合わせに応じて当該サーバが有する前記第 2 のマッピングテーブルを参照した結果、前記アクセス先の論理工クステントに対してストレージの未割り付けの状態にあることが判別された場合、空き物理エクステントを有するストレージを当該論理工クステントに割り付けて、前記第 2 のマッピングテーブルを更新し、

前記ストレージは、前記コントローラから論理工クステントへのアクセスが要求されて、当該ストレージが有する前記第 3 のマッピングテーブルを参照した結果、当該ストレージが有する前記物理ボリューム内で前記要求された論理ボリュームに物理エクステントが対応付けられていないことが判別された場合、当該ストレージの前記物理ボリューム内の空き物理エクステントを当該論理工クステントに割り付けて、前記第 3 のマッピングテーブルを更新する

ことを特徴とする請求項 1 記載のストレージシステム。

【請求項 6】

前記コントローラは、前記問い合わせ及び当該問い合わせに対する前記所在管理サーバからの回答に関する情報を格納するキャッシュを有し、

前記コントローラは、前記所在管理サーバに論理工クステントがどのストレージに格納されているかを問い合わせる前に当該問い合わせに対する回答に関する情報が前記キャッシュに格納されているかを調べ、格納されている場合には当該キャッシュに格納されている回答に関する情報の示すストレージに対して前記ホストから要求された論理工クステントへのアクセスを要求する

ことを特徴とする請求項 1 記載のストレージシステム。

【請求項 7】

前記所在管理サーバが有する前記第 2 のマッピングテーブルの示す論理工クステントが格納されているストレージと、当該所在管理サーバが有するキャッシュに格納されている回答に関する情報の示す当該論理工クステントが格納されているストレージとが一致しているかを調べて、不一致の場合に当該キャッシュに格納されている当該情報を無効化する無効化手段を更に有することを特徴とする請求項 6 記載のストレージシステム。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、物理ボリュームを有する少なくとも 1 つのノードを含む複数のノードから構成されるストレージシステムに関する。

【背景技術】

【0002】

近年、相互に接続された複数のストレージ装置（例えばディスクストレージ装置）を有するストレージシステムが開発されている。この種のストレージシステムの 1 つとして、ストレージクラスタ（ストレージクラスタシステム）が知られている。

【0003】

ストレージクラスタの特徴は、複数のストレージ装置（以下、ノードと称する）の各々に存在する記憶領域（以下、物理ボリュームと称する）を、当該ノードを超えて統合する（束ねる）ことで、ノード間にまたがった横断的・仮想的な少なくとも 1 つの記憶領域（以下、論理ボリュームと称する）をホストに提供することにある。ここでのボリュームは、ブロック単位でアクセスされるブロックボリュームであるとする。

10

20

30

40

50

【0004】

ストレージクラスタを構成するノードは、常時稼動のストレージ装置である。つまり、ノードの参加・離脱は、運用中の計画的参加・離脱や、故障による突然の離脱による程度である。このためストレージクラスタでは、例えば毎日の電源ON/OFFによるような、頻繁なノードの参加・離脱はない。

【0005】

ストレージクラスタにおいては、データ（の断片）を物理ボリューム内や、別のノードの物理ボリュームをまたがって、（自動／手動を問わず）適切に移動／コピーすることは、頻繁に起きる。これは、ホストからの論理ボリュームへのアクセス透過性を保障しながら、ストレージクラスタを構成するノードの突発的停止やディスク故障などに備えたデータの冗長化や、アクセス性能・信頼性の向上などの目的による。10

【0006】

一方、ホストは、ストレージクラスタ内の任意の1つのノードに対してパスを張ってアクセスするだけで、複数のノードをまたがって構成された論理ボリューム全体に対してアクセスすることができる。ここで、ホストがパスを張っているノードで障害が発生して、当該障害が発生したノード（障害ノード）が停止したものとする。この場合でも、障害ノードに格納されているデータがストレージクラスタ内の他のノード（生存ノード）に冗長化されれば、ホストは任意の生存ノードに対してパスを張り直すことで、論理ボリュームに対するアクセスを継続することができる。

【0007】

このようなストレージクラスタを構築するには、論理ボリューム上のデータが、どのノードのどの物理ボリューム上の、どの位置に配置されているかを管理するための仕組みが必要になる。20

【0008】

一般に、ストレージクラスタのノードは、機能的にコントローラとストレージとから構成される。コントローラはホストとのパスを管理しアクセスを受け付ける。ホストはどのコントローラに対してパスを張っても、同じ論理ボリュームにアクセスすることができる。ストレージはデータを蓄える物理ボリュームを有する。

【0009】

ボリューム（ブロックボリューム）は、エクステントと呼ばれる、固定長のブロックの集合により構成される。各ノードのストレージは1つの物理ボリュームを管理する。一方、各ノードのコントローラは、物理ボリュームを構成する物理エクステントと、論理ボリュームの論理エクステントとをマッピングテーブルにより対応付けて管理する。これにより、論理ボリューム（論理ボリューム空間）が構成される。このようなマッピングテーブルによる物理エクステントと論理エクステントとの対応付けは、例えば特許文献1にも記載されている。30

【0010】

上述のマッピングテーブルを、論理エクステント - 物理エクステントマッピングテーブル（L P M T : Logical Extent to Physical Extent Mapping Table）と呼ぶ。L P M Tは、論理ボリュームの論理エクステントが、どのノード（ストレージ）の物理ボリュームの、どの物理エクステントから構成されているか、その対応付けを管理するのに用いられる。40

【0011】

ストレージクラスタ内の全てのノードのコントローラは、それぞれ同一内容のL P M Tを保持する。また各ノードは、L P M Tにより全論理ボリューム分を管理する。これらの理由は、ホストからコントローラへのパスが、別のコントローラに切り替わった際に、直ちに同一の論理ボリュームへのアクセスを継続可能とするためである。

【特許文献1】特開平9-62452号公報**【発明の開示】****【発明が解決しようとする課題】**

10

20

30

40

50

【0012】

上記したように従来のストレージクラスタ（ストレージシステム）では、当該クラスタ内の各ノードは、L P M T（論理工クステント・物理エクステントマッピングテーブル）により全論理ボリューム分を管理する必要がある。ところが、L P M Tのサイズは物理ボリュームの数と、その物理ボリュームを構成するエクステントの量によってはとても大きくなり、コントローラ上の大量のメモリを消費することになる。

【0013】

ストレージクラスタでは、当該クラスタ内のあるノード（以下、第1のノードと称する）の例えは第1の物理エクステントに格納されていた第1の論理工クステントを、別のノード（以下、第2のノードと称する）の例えは第2の物理エクステントにマイグレーション（移動）することが発生する。このようなマイグレーションは、第1のノードのストレージの負荷を軽減するなどの目的で行われる。また、上記特許文献1に記載されているように、あるノードのストレージに対するアクセス性能を向上させるために、当該ノードのある物理エクステントに格納されていた第1の論理工クステントを、当該ノードの別の物理エクステントにマイグレーションすることもある。このマイグレーションにより、ストレージクラスタのアクセス性能及び信頼性を向上することが可能となる。10

【0014】

このようにストレージクラスタでは、ストレージクラスタのアクセス性能・信頼性向上のために、論理工クステントを同じストレージ内の別の物理エクステントへ、また別のストレージの物理エクステントへの移動／コピーが発生する。この場合、ストレージクラスタの各コントローラは互いに同期をとって、自身が管理するL P M Tを一斉（同時）に更新する必要がある。しかし、各コントローラのL P M Tが同一となるように同時に更新することは、L P M T管理の処理の複雑さを招き、アクセス性能に悪影響を及ぼす。20

【0015】

本発明は上記事情を考慮してなされたものでその目的は、各ノードが管理する情報の更新作業量を抑えてアクセス性能を向上させることができるストレージシステムを提供することにある。

【課題を解決するための手段】**【0016】**

本発明の1つの観点によれば、物理ボリュームを有する少なくとも1つのノードを含む複数のノードから構成され、前記少なくとも1つのノードが有する物理ボリュームを利用して、ホストに対して複数の論理工クステントから構成される論理ボリュームを提供するストレージシステムが提供される。このシステムにおいて、前記複数のノードの少なくとも2つは、前記ホストに対して前記論理ボリュームを提供し、当該ホストからのアクセスを受け付けるコントローラを有する。また、前記少なくとも1つのノードは、前記論理ボリュームを構成する論理工クステントを物理エクステントにマッピングして前記物理ボリューム内に格納するストレージを有し、前記複数のノードの少なくとも1つは、前記論理ボリュームを構成する論理工クステントを格納しているストレージの所在に関する前記コントローラからの問い合わせに対して回答する所在管理サービスを実行する所在管理サーバを有する。また、前記コントローラは、前記論理ボリュームを構成する論理工クステントに対応する所在管理サーバを示す第1のマッピングテーブルを有する。前記所在管理サーバは、当該サーバに対応する論理工クステントについて、その論理工クステントがどのノードのストレージに格納されているかを示す第2のマッピングテーブルを有し、前記ストレージは、論理工クステントを、当該ストレージが有する物理ボリュームのどの物理エクステントに対応させて格納したかを示す第3のマッピングテーブルを有する。前記コントローラは、前記ホストから前記論理ボリューム内の任意の論理工クステントをアクセス先として指定するアクセス要求が与えられた場合、当該コントローラが有する前記第1のマッピングテーブルを参照することにより当該アクセス先の論理工クステントに対応する所在管理サーバを特定し、特定された所在管理サーバに対して、当該論理工クステントがどのストレージに格納されているかを問い合わせる。前記所在管理サーバは前記コントローラ304050

ーラから問い合わせを受けた場合、当該サーバが有する前記第2のマッピングテーブルを参照することにより問い合わせられたストレージを特定して、当該ストレージを示す情報を前記問い合わせに対する回答として問い合わせ元の前記コントローラに通知する。前記コントローラは、前記所在管理サーバから前記問い合わせに対する回答として通知された情報の示すストレージに対して前記ホストから要求された論理工クステントへのアクセスを要求する。前記ストレージは、前記コントローラから論理工クステントへのアクセスが要求された場合、当該ストレージが有する前記第3のマッピングテーブルを参照することにより、当該ストレージが有する前記物理ボリューム内で前記要求された論理工クステントに対応させられている物理工クステントを特定して、当該特定された物理工クステントに対してアクセスしてアクセス要求元の前記コントローラに応答する。

10

【発明の効果】

【0017】

本発明によれば、第1乃至第3のマッピングテーブルを用いることにより、ノード（コントローラ）が管理する情報の更新作業量を抑えてアクセス性能を向上させることができる。

【発明を実施するための最良の形態】

【0018】

以下、本発明の実施の形態につき図面を参照して説明する。

〔第1の実施形態〕

図1は本発明の第1の実施形態に係るストレージクラスタ構成のストレージシステムの概略構成を示すブロック図である。図1のストレージシステム（以下、ストレージクラスタと称する）は、複数、例えば3台のストレージ装置（以下、ノードと称する）1-1, 1-2及び1-3（#1, #2及び#3）から構成される。ノード1-1, 1-2及び1-3は、ファイバチャネル、或いはiSCSI（Small Computer System Interface）のようなインターフェイス2によって、ストレージクラスタを利用するホスト（ホストコンピュータ）と接続されている。

20

【0019】

ノード1-1, 1-2及び1-3は、それぞれ、コントローラ11-1, 11-2及び11-3と、所在管理サーバ12-1, 12-2及び12-3と、ストレージ13-1, 13-2及び13-3とから構成される。

30

【0020】

コントローラ11-i（i=1, 2, 3）はホストに対して論理ボリュームを提供する。ここでは、ストレージ13-1, 13-2及び13-3の後述する物理ボリュームを統合することで、論理ボリュームLVOL=1がホストに提供されるものとする。コントローラ11-iはホストからのアクセス要求を受け付ける。アクセス要求は、アクセスされるべき論理ボリューム内の論理ブロックを示すアドレス（論理ブロックアドレス）LBAを含む。コントローラ11-iは、要求された論理ブロックを含む論理工クステントがどのノードのストレージに格納されているか、後述するLMMT112aを参照して所在管理サーバ12-j（j=1, 2, 3）に問い合わせる。コントローラ11-iは、問い合わせに対して所在管理サーバ12-jから通知されたノードのストレージに対してアクセスを行う。

40

【0021】

図2は、コントローラ11-iの構成を示すブロック図である。コントローラ11-iは、ターゲットインタフェイス111、サーバ特定部112及び入出力マネージャ（I/Oマネージャ）113を含む。

【0022】

ターゲットインタフェイス111は、ホストからのアクセス要求を受け付け、要求された論理ボリュームの論理ブロックアドレスLBA（の示す論理ブロック）が位置する論理工クステントを特定する。ここでは、論理工クステントを識別する論理工クステントID（LEID）が、（LEID=LBA/エクステントサイズ）の演算によって特定される。ターゲットインタフェイス111は、特定された論理ボリューム内の論理工クステント

50

がどのストレージに格納されているかをサーバ特定部112を介して所在管理サーバ12-jに問い合わせる。この問い合わせは、論理ボリューム／論理工クステントを識別する論理ボリュームID(LV01)／論理工クステントID(LEID)を含む。ターゲットインターフェイス111は、所在管理サーバ12-iに対する問い合わせに応じてサーバ特定部112を介して通知されたストレージに対してIOMネージャ113を介してアクセスし、ホストに対して応答する。

【0023】

サーバ特定部112は、ターゲットインターフェイス111からの問い合わせを受け渡す所在管理サーバ12-jを特定する。以下の説明では、ターゲットインターフェイス111からの問い合わせに含まれている論理ボリュームID及び論理工クステントIDで示される論理工クステントをターゲット論理工クステントと呼ぶこともある。所在管理サーバ12-jは、このターゲット論理工クステントを格納するストレージの所在を管理するサーバとして特定される。10

【0024】

サーバ特定部112は、ターゲット論理工クステントの所在を管理する所在管理サーバを特定するために、第1のマッピングテーブルとしての論理工クステント-所在管理サーバマッピングテーブル(LMMT:LogicalExtent to ManagementServer Mapping Table)112aを有する。LMMT112aは、論理工クステントをどのストレージが格納しているか、その所在に関して責任を負う(つまり所在を管理する)所在管理サーバを提供するノードのID(MS)を保持する。サーバ特定部112は、コントローラ11-1からの問い合わせを特定された所在管理サーバに受け渡す。サーバ特定部112は、ターゲットインターフェイス111からの上記問い合わせに対する所在管理サーバ12-jからの応答(ターゲット論理工クステントが格納されているストレージのノードID(PV01)を当該ターゲットインターフェイス111に受け渡す。サーバ特定部112はまた、キャッシュ112bを有する。このキャッシュ112bについては、後述する第5の実施形態で説明する。20

【0025】

IOMネージャ113は、コントローラ11-iとストレージ13-jとの間のインターフェイスを提供する。30

【0026】

再び図1を参照すると、所在管理サーバ12-i(i=1,2,3)は、コントローラ11-j(j=1,2,3)によって問い合わせられた論理工クステントを格納しているストレージのノードIDを調べて、そのノードIDを当該コントローラ11-jに通知する。所在管理サーバ12-iは、自身が担当する論理工クステントについて、その論理工クステントがどのノードIDのストレージ(物理ボリューム)に格納されているかを管理するための、第2のマッピングテーブルとしての論理工クステント-ストレージマッピングテーブル(LSTM:Logical Extent to Storage Mapping Table)LSTM120-iを有する。つまり所在管理サーバ12-1,12-2及び12-3は、それぞれLSTM120-1,120-2及び120-3を有する。40

【0027】

ストレージ13-1,13-2及び13-3は、それぞれ物理ボリューム130-1,130-2及び130-3(PV01=1,PV01=2及びPV01=3)を有する。ストレージ13-i(i=1,2,3)は論理工クステントを物理エクステントにマッピングして物理ボリューム130-i内に格納する。ストレージ13-iは、コントローラ11-iからの入出力要求(I/O要求)を受け付ける。このI/O要求は、アクセスされるべき論理ボリューム内の論理工クステントのID(LEID)を含む。ストレージ13-iは、この論理工クステントと対応付けられている物理エクステントを調べる。ストレージ13-iは、この物理エクステントに対してI/Oを行い、コントローラ11-iに対して応答する。

【0028】

図3は、ストレージ13-iの構成を示す。ストレージ13-iは、I/Oドライバ131、50

論理工クステント - 物理工クステント管理部 (L P 管理部) 1 3 2 及びディスク 1 3 3 を含む。

【 0 0 2 9 】

I O ドライバ 1 3 1 は、ストレージ 1 3 -i とコントローラ 1 1 -i とのインターフェイスを提供する。

【 0 0 3 0 】

L P 管理部 1 3 2 は、論理工クステントと物理工クステントとの対応を管理する。L P 管理部 1 3 2 は、論理工クステントが、自身の物理ボリューム 1 3 0 -i のどの物理工クステントに対応させて格納されているかを示す、第 3 のマッピングテーブルとしての論理工クステント - 物理工クステントマッピングテーブル (L P M T : LogicalExtent to PhysicalExtent Mapping Table) 1 3 2 a を保持する。このように、本実施形態で適用される L P M T 1 3 2 a は、[背景技術] で述べた L P M T と異なり、全論理ボリューム分のマッピング情報を持たないことに注意されたい。また、L P M T 1 3 2 a の内容は、各ストレージ 1 3 -i 毎に異なることにも注意されたい。10

【 0 0 3 1 】

ディスク 1 3 3 は、物理ボリューム 1 3 0 -i (P V o l = i) を有する。物理ボリューム 1 3 0 -i は物理工クステント単位で管理される。また、物理ボリューム 1 3 0 -i へのアクセスの単位はブロックであり、物理工クステントは、複数のブロックから構成される。

【 0 0 3 2 】

また、図 1 のストレージクラスタは、当該クラスタの構成の計画・管理を司る構成管理部 (図示せぬ) を有する。この構成管理部は、ボリューム作成時に、論理ボリューム / 論理工クステントの格納先となる物理ボリューム / 物理工クステントを決定する。構成管理部はまた、エクステントや後述する所在管理サービスの移動 / コピー (冗長化) のための移動元 / 移動先を決定する。構成管理部は更に、オンデマンドでエクステント割り付けの割り付け先を決定する。この構成管理部が、ノード 1 -1 ~ 1 -3 から独立に設けられても、当該ノード 1 -1 ~ 1 -3 のいずれかに設けられても構わない。20

【 0 0 3 3 】

本実施形態において、構成管理部は、以下の手順で論理ボリュームを作成する。

(a) 構成管理部は、論理ボリュームを構成する論理工クステントの各々を、どのノード I D のストレージに格納するか決定する。構成管理部は、論理工クステントの各々に、決定されたストレージの物理工クステントを割り付ける。構成管理部は、ストレージ 1 3 -1 ~ 1 3 -3 毎に、そのストレージの物理工クステントと当該物理工クステントが割り付けられた論理工クステントとの対応を示す L P M T 1 3 2 a を生成して、そのストレージに保持する。30

【 0 0 3 4 】

(b) 構成管理部は、論理工クステントが割り付けられた物理工クステントを格納するストレージ (物理ボリューム) から、その論理工クステントの所在を管理するサービス (所在管理サービス) をノード 1 -1 ~ 1 -3 のうちのいずれのノードの所在管理サーバに担当させるかを決定する。構成管理部は、所在管理サーバ 1 2 -1 ~ 1 2 -3 每に、その所在管理サーバが担当する論理工クステントと物理ボリュームとの対応を示す L S M T 1 2 0 -1 ~ 1 2 0 -3 を生成して、その所在管理サーバ 1 2 -1 ~ 1 2 -3 内に設定する。なお、後述する第 2 の実施形態のように、ストレージクラスタ内の中の全ての所在管理サーバ 1 2 -1 ~ 1 2 0 -3 に L S M T が設定される必要はない。40

【 0 0 3 5 】

(c) 構成管理部は、L M M T 1 1 2 a を生成して全コントローラ 1 1 -1 ~ 1 1 -3 に配布する。L M M T 1 1 2 a は先に述べたように、論理ボリュームを構成する論理工クステント毎に、その論理工クステントが割り付けられている物理工クステントを格納するストレージ (物理ボリューム) をどの所在管理サーバに問い合わせればよいかを示す。

【 0 0 3 6 】

このようにして、論理ボリュームが作成される。すると、作成された論理ボリュームに50

対してホストからアクセスすることが可能となる。ホストからの論理ボリュームに対するアクセスは、ホストからノード 1-1~1-3のうちの任意のノード 1-i のコントローラ 11-i に対してパスを張ることで行われる。

【0037】

以下、例えばホストからノード 1-1 (i = 1 の場合) に対してパスが張られた後に、当該ホストからアクセス要求が発行された場合の処理の流れについて、図 4 及び図 5 を参照して説明する。図 4 は処理の手順を示すフローチャート、図 5 は情報の流れを示す図である。図 5 における矢印 A 1 ~ A 8 は、図 4 のフローチャートにおけるステップ S 1 ~ S 8 にそれぞれ対応する。

【0038】

まず、ホストからノード 1-1 のコントローラ 11-1 に含まれているターゲットインターフェイス 111 に対してアクセス要求 (IO 要求) が発行されたものとする。また、このアクセス要求が、ある論理ボリューム $L V o l = L V o l x$ (例えば $L V o l = 1$) のある論理ブロックアドレス $L B A = L B A x$ に対するアクセスを要求しているものとする。

【0039】

ターゲットインターフェイス 111 は、ホストからのアクセス要求を受け付ける (ステップ S 0)。するとターゲットインターフェイス 111 は、ホストからのアクセス要求で指定されるアクセスされるべき論理ボリューム $L V o l = L V o l x$ 上の $L B A = L B A x$ から、当該 $L B A x$ が位置する論理工エクステントの $I D = L E I D x$ を次式

$$L E I D x = L B A x / \text{エクステントサイズ}$$

により求める (ステップ S 1)。ここで、論理ボリューム $L V o l = L V o l x = 1$ 上の論理工エクステント $I D$ が $L E I D x$ の論理工エクステントを、論理工エクステント ($L V o l x, L E I D x$) と表現する。

【0040】

ターゲットインターフェイス 111 は、論理ボリューム名 ($I D : L V o l = L V o l x = 1$) 及び求められた論理工エクステント $I D = L E I D x$ をサーバ特定部 112 に渡すことにより、当該論理工エクステント $I D = L E I D x$ の論理工エクステント ($L V o l x, L E I D x$) が、どのノードのストレージに格納されているかを問い合わせる (ステップ S 2)。

【0041】

サーバ特定部 112 は、ターゲットインターフェイス 111 によって渡された論理工エクステント $I D = L E I D x$ の論理工エクステント ($L V o l x, L E I D x$) がどのノードのストレージに格納されているかを管理している所在管理サーバを提供するノードの $I D$ ($M S = M I D x$) を、 $L M M T 112 a$ に基づいて特定する (ステップ S 3)。ここでは、サーバ特定部 112 と同じノード 1-1、つまり所在管理サーバ 12-1 を提供するノード 1-1 の $I D$ ($M S = M I D x = 1$) が特定されたものとする。本実施形態において、ノード 1-1~1-3 のストレージ 13-1~13-3 は物理ボリューム 130-1~130-3 を有する。つまり、ノード 1-1~1-3 のストレージ 13-1~13-3 は、それぞれ 1 つの物理ボリュームを有する。このため本実施形態では、所在管理サーバ 12-1~12-3 を提供するノード 1-1~1-3 の $I D$ ($M S$) と当該ノード 1-1~1-3 のストレージ 13-1~13-3 が有する物理ボリューム 130-1~130-3 の $I D$ ($P V o l$) とは一致し、1~3 である。

【0042】

サーバ特定部 112 は、特定されたノード 1-1 の所在管理サーバ 12-1 に対して、ターゲットインターフェイス 111 からの問い合わせを受け渡す (ステップ S 4)。即ち、サーバ特定部 112 は所在管理サーバ 12-1 に対して、論理工エクステント $I D = L E I D x$ の論理工エクステント (ターゲット論理工エクステント) ($L V o l x, L E I D x$) に対応する物理エクステントを格納しているストレージのノード $I D$ ($P V o l$) = $S I D x$ を問い合わせる。

【0043】

所在管理サーバ 12-1 は、どのノード $I D = S I D x$ のストレージが、論理工エクステン

10

20

30

40

50

ト($L V o l x$, $L E I D x$)に対応する物理エクステントを格納しているかを、 $L S M T 1 2 0 -1$ に基づいて調べて、そのノード $I D = S I D x$ を、問い合わせ元のサーバ特定部112に対して通知する(ステップS5)。

【0044】

サーバ特定部112は、所在管理サーバ12-1から通知されたノード $I D = S I D x$ を、ターゲットインターフェイス111からの問い合わせに対する回答として当該ターゲットインターフェイス111に渡す(ステップS6)。ここでは、ストレージ13-1のノード $I D = S I D x$ がターゲットインターフェイス111に渡されたものとする。

【0045】

ターゲットインターフェイス111は、サーバ特定部112によって渡されたノード $I D = S I D x$ で示されるノード1-1のストレージ13-1に対し、論理工エクステント($L V o l x$, $L E I D x$)に対応する物理エクステントへのアクセスをIOMネージャ113を介して要求する(ステップS7)。

【0046】

ストレージ13-1のIODライバ131は、要求された論理工エクステント($L V o l x$, $L E I D x$)に、当該ストレージ13-1(物理ボリューム130-1)内のどのID(= $P E I D x$)の物理エクステント(以下、物理エクステント $P E I D x$ と表現する)が対応付けられているかを、 $L P M T 1 3 2 a$ に基づいて調べる(ステップS8)。このステップS8において、IODライバ131は、論理工エクステント($L V o l x$, $L E I D x$)に対応する物理エクステント $P E I D x$ に対してアクセスし、コントローラ11-1のIOMネージャ113に対して応答する。ターゲットインターフェイス111は、ストレージ13-1のIODライバ131からの応答をIOMネージャ113から受け取って、ホストに返す(ステップS9)。

【0047】

以上の説明では、ホストからのアクセス要求を受け付けたターゲットインターフェイスと、ターゲット論理工エクステントがどのストレージに格納されているかを管理している所在管理サーバと、当該ターゲット論理工エクステントを物理エクステント内に格納しているストレージとが、いずれも同一のノード1-1に属する場合を想定している。

【0048】

図6は、上述のターゲットインターフェイス、所在管理サーバ及びストレージが、それぞれ別々のノードに属する場合の情報の流れを示す。図6における矢印B1～B8は、図4のフローチャートにおけるステップS1～S8にそれぞれ対応する。

【0049】

図7は、図1のシステムにおいて、論理ボリューム $L V o l$ が $L V o l = 1$ であって、当該論理ボリューム $L V o l = 1$ を、 $L E I D$ が $L E I D = 1 \sim L E I D = 4$ の4つの論理工エクステントから構成した場合のシステム構成を示す。また、図8は図7の状態における $L M M T 1 1 2 a$ のデータ構造例を、図9は図7の状態における $L S M T 1 2 0 -i$ 、例えばノード1-1の $L S M T 1 2 0 -1$ のデータ構造例を、図10は図7の状態における例えばノード1-1の $L P M T 1 3 2 a$ のデータ構造例を示す。

【0050】

$L M M T 1 1 2 a$ は、論理ボリューム $L V o l = 1$ を構成する論理工エクステントの数に一致するエントリを有する。 $L M M T 1 1 2 a$ の各エントリは、論理ボリュームのID(論理ボリューム番号 $L V o l$)と、当該 $L V o l$ で示される論理ボリュームに含まれる論理工エクステントのID($L E I D$)と、当該 $L V o l$ 及び $L E I D$ で示される論理工エクステント($L V o l$, $L E I D$)をどのストレージ(物理ボリューム)が格納しているか、その所在を管理する所在管理サーバ12-jを提供するノードのID(MS)とを保持する。図8の例では、論理ボリューム $L V o l = 1$ を構成する論理工エクステントが、 $L E I D = 1 \sim L E I D = 4$ の4つであることが示されている。

【0051】

$L S M T 1 2 0 -i$ (120-1)は、所在管理サーバ12-i(12-1)が管理する論理工

10

20

30

40

50

クステントの数に一致するエントリを有する。LSMT120-i(120-1)の各エントリは、論理ボリュームのID(LV01)と、当該LV01で示される論理ボリュームに含まれる論理工クステントのID(LEID)と、当該LV01及びLEIDで示される論理工クステントが格納されているストレージ(物理ボリューム)のノードID(物理ボリューム番号PV01)とを保持する。

【0052】

LPMT132aは、物理ボリューム130-i(130-1)を構成する物理エクステントの数に一致するエントリを有する。LPMT132aの各エントリは、物理ボリューム130-iを構成する物理エクステントのID(PEID)と、当該PEIDで示される物理エクステントが割り付けられる論理工クステントを含む論理ボリュームのID(LV01)と、当該論理工クステントのID(LEID)と、当該論理工クステントをどのストレージ(物理ボリューム)が格納しているか、その所在を管理する所在管理サービス(所在管理サーバ12-j)を提供するノードのID(MS)とを保持する。このLPMT132a内のエントリのMSは、所在管理サービスの逆引きに用いられる。図10の例では、物理ボリューム130-i(130-1)を構成する物理エクステントが、PEID=1~PEID=3の3つであることが示されている。

【0053】

図7において、コントローラ11-1のLMMT112aのエントリから所在管理サーバ12-1~12-3のLSMT120-1~120-3へ向かう一点鎖線の矢印は、LMMT112aのエントリの情報によって参照されるLSMT120-1~120-3のエントリを指す。同様に、LSMT120-1~120-3のエントリからストレージ13-1~13-2のLPMT132aへ向かう一点鎖線の矢印は、LSMT120-1~120-3のエントリの情報によって参照されるLPMT132aのエントリを指す。同様に、ストレージ13-1~13-2のLPMT132aのエントリからストレージ13-1~13-2の物理ボリューム130-1~130-3へ向かう一点鎖線の矢印は、LPMT132aの情報に基づいてアクセスされる物理エクステントを指す。

【0054】

次に、図7を参照して、ホストからノード1-1に対してバスが張られた後に、当該ホストからの、論理ボリュームLV01=1/論理工クステントLEID=1で指定されるブロックに対するアクセスの流について説明する。

【0055】

まず、図7において矢印B1で示されるように、ホストからノード1-1に対して、論理ボリュームLV01=1内のあるブロックへのアクセス要求が発行されたものとする。ノード1-1のコントローラ11-1(に含まれているターゲットインターフェイス111)は、アクセスされるべきブロックがLEID=1の論理工クステント(論理工クステントLEID=1)に格納されていることを求める。

【0056】

コントローラ11-1のターゲットインターフェイス111は、論理工クステントLEID=1がどのノードのストレージに格納されているかを、当該コントローラ11-1内のサーバ特定部112に問い合わせる。サーバ特定部112は、自身のLMMT112a内のLEID=1が保持されているエントリ(図8の例では、1行目のエントリ)を参照する。これによりサーバ特定部112は、論理ボリュームLV01=1/論理工クステントLEID=1に対応する所在管理サーバがノード1-1に存在することを認識する。

【0057】

コントローラ11-1のサーバ特定部112は、図7において矢印B2で示されるように、ノード1-1に存在する所在管理サーバ12-1に対して、論理ボリュームLV01=1/論理工クステントLEID=1がどのノードのストレージ(物理ボリューム)に格納されているかを問い合わせる。

【0058】

所在管理サーバ12-1は、自身のLSMT120-1内でLV01=1/LEID=1が

10

20

30

40

50

保持されているエントリ（図9の例では、1行目のエントリ）を参照して、論理ボリューム $L V o l = 1$ / 論理エクステント $L E I D = 1$ の実体がノード1-1のストレージ（物理ボリューム）に格納されていることを認識する。所在管理サーバ12-1は、ノード1-1の $I D (S I D x = P V o l = 1)$ を、図7において矢印B3で示されるように、コントローラ11-1のサーバ特定部112に回答する（ステップB3）。これを受けたサーバ特定部112は、ノード1-1の $I D (S I D x = P V o l = 1)$ をターゲットインターフェイス111に通知する。

【0059】

ターゲットインターフェイス111（コントローラ11-1のターゲットインターフェイス111）は、図7において矢印B4で示されるように、サーバ特定部112によって通知されたノードIDで指定されるストレージ、即ちノード1-1のストレージ13-1に対して、論理ボリューム $L V o l = 1$ / 論理エクステント $L E I D = 1$ へのアクセスをI/Oマネージャ113を介して要求する。

【0060】

ノード1-1のストレージ13-1は、自身の $L P M T 1 3 2 a$ 内の論理ボリューム $L V o l = 1$ / 論理エクステント $L E I D = 1$ が保持されているエントリ（図10の例では、1行目のエントリ）を参照する。これによりストレージ13-1は、論理ボリューム $L V o l = 1$ / 論理エクステント $L E I D = 1$ に対応する物理エクステントの $P E I D$ が $P E I D = 1$ であることを認識する。ストレージ13-1は、この $P E I D = 1$ の物理エクステント（物理エクステント $P E I D = 1$ ）にアクセスして、図7において矢印B5で示されるように、コントローラ11-1に対して応答する。

【0061】

本実施形態において、各ノード1-1～1-3のコントローラ11-1～11-3が有する $L M M T 1 1 2 a$ は同一の内容である。つまり各ノード1-1～1-3（コントローラ11-1～11-3）は $L M M T 1 1 2 a$ を共有する。このためホストは、ストレージクラスタを構成するノード1-1～1-3のいずれのノード（のコントローラ）に対してもパスを張ることができる。例えば、ホストがパスを張っている先のコントローラが異常停止した場合、或いは当該コントローラの負荷が高まったときなどは、ホストは別のコントローラに対してパスを張り替えることができる。

【0062】

$L M M T 1 1 2 a$ など、全ノード1-1～1-3が共有する情報（共有情報）は、当該ノード1-1～1-3のコントローラ11-1～11-3が有する不揮発性メモリの記憶領域、当該ノード1-1～1-3のストレージ13-1～13-3の記憶領域、或いはストレージ13-1～13-3のうちの任意のストレージの記憶領域に格納される。コントローラ11-1～11-3は、この記憶領域を参照することにより共有情報を管理する。この管理のために、コントローラ11-1～11-3は上記記憶領域のアドレスを共有する。共有情報は $L M M T 1 1 2 a$ の他に、論理ボリューム構成情報を含む。論理ボリューム構成情報は、図1のストレージクラスタがホストに対してどのような論理ボリュームを提供するかを示す。上述した各ノード1-1～1-3が情報を共有する構成により、従来技術と比較して、当該各ノード1-1～1-3が管理しなければならない情報量を減らすことができる。

【0063】

次に、論理エクステントを構成する物理エクステントのデータを、ストレージをまたがって別の物理エクステントにマイグレート（移動）する場合の動作について、図11を参照して説明する。

【0064】

まず、例えば構成管理部によってデータの移動元及び移動先が決定される。ここでは、図1のストレージクラスタが図10に示す状態にあるときに、データの移動元として、論理エクステント $L E I D = 4$ に対応付けられている、ノード1-1のストレージ13-1内の物理ボリューム $P V o l = 1$ (130-1) / 物理エクステント $P E I D = 2$ が、移動先として、ノード1-2のストレージ13-2内の物理ボリューム $P V o l = 2$ (130-2) / 物

10

20

30

40

50

理工クステント P E I D = 1 が、それぞれ決定されたものとする。

【 0 0 6 5 】

この場合、ノード 1-1 のストレージ 13-1 内の物理ボリューム P V o l = 1 / 物理工クステント P E I D = 2 に格納されているデータが、図 11 において矢印 C 1 で示されるように、ノード 1-2 のストレージ 13-2 内の物理ボリューム P V o l = 2 / 物理工クステント P E I D = 1 に移動される。

【 0 0 6 6 】

また、移動元のストレージ 13-1 及び移動先のストレージ 13-2 の各々の L P M T 13 2 a が書き換えられる。ここでは、ストレージ 13-1 の L P M T 13 2 a 内の P E I D = 2 が保持されているエントリの L V o l , L E I D , M S がそれぞれ「1」、「N U L L」、「4」、「N U L L」、「1」、「N U L L」に書き換えられ、ストレージ 13-2 の L P M T 13 2 a 内の P E I D = 1 が保持されているエントリの L V o l , L E I D , M S が、図 11 において矢印 C 2 で示されるように、それぞれ「N U L L」、「1」、「N U L L」、「4」、「N U L L」、「1」に書き換えられる。

【 0 0 6 7 】

また、論理工クステント L E I D = 4 を参照していた（つまり論理工クステント L E I D = 4 に関する所在管理サービスを担当している）所在管理サーバ 12-1 の L S M T 12 0-1 が書き換えられる。ここでは、L S M T 12 0-1 内の L E I D = 4 が保持されているエントリの P V o l が、図 11 において矢印 C 3 で示されるように、「1」、「2」に書き換えられる。

10

20

【 0 0 6 8 】

このように本実施形態において、論理工クステント（L E I D = 4）のマイグレーションに係わる通知（更新）は、その論理工クステント（L E I D = 4）を管理する所在管理サーバ（12-1）に対して行われるだけで良い。つまり、上記の通知はストレージクラスタを構成する全てのノード 1-1 ~ 1-3 に対して行われる必要がない。このため、通知コストを小さくすることができる。

【 0 0 6 9 】

次に、論理工クステントを構成する物理工クステントのデータを、ストレージをまたがって別の物理工クステントにコピーする場合の動作について、図 12 を参照して説明する。このようなコピー処理は、論理工クステントを構成する物理工クステントを冗長化し、耐障害性を高め、また並列処理によりリードアクセスを高速化するために行われる。

30

【 0 0 7 0 】

まず、例えば構成管理部によってコピー元及びコピー先が決定される。ここでは、図 1 のストレージクラスタが図 11 に示す状態にあるときに、データのコピー元として、論理工クステント L E I D = 4 に対応付けられている、ノード 1-2 のストレージ 13-2 内の物理ボリューム P V o l = 2 (130-2) / 物理工クステント P E I D = 1 が、コピー先として、ノード 1-3 のストレージ 13-3 内の物理ボリューム P V o l = 1 (130-3) / 物理工クステント P E I D = 2 が、それぞれ決定されたものとする。

【 0 0 7 1 】

この場合、ノード 1-2 のストレージ 13-2 内の物理ボリューム P V o l = 2 / 物理工クステント P E I D = 1 に格納されている論理工ボリューム L V o l = 1 / 論理工クステント L E I D = 4 のデータが、図 12 において矢印 D 1 で示されるように、ノード 1-3 のストレージ 13-3 内の物理ボリューム P V o l = 1 / 物理工クステント P E I D = 2 にコピーされる。このコピーは、例えばストレージ 13-2 及び 13-3 の I O ドライバ 131 によって行われる。

40

【 0 0 7 2 】

また、コピー先のストレージ 13-3 の L P M T 13 2 a が書き換えられる。ここでは、ストレージ 13-2 の L P M T 13 2 a 内の P E I D = 1 が保持されているエントリの L V o l = 1 , L E I D = 4 , M S = 1 が、図 12 において矢印 D 2 で示されるように、ストレージ 13-3 の L P M T 13 2 a 内の P E I D = 2 が保持されているエントリの L V o l

50

, L E I D , M S にコピーされる。

【0073】

また、論理工エクステント L E I D = 4 を参照していた所在管理サーバ 1 2 -1 の L S M T 1 2 0 -1 が、例えばストレージ 1 3 -1 の I O ドライバ 1 3 1 によって書き換えられる。ここでは、ノード 1 -1 の所在管理サーバ 1 2 -1 が管理する L S M T 1 2 0 -1 内の、 L E I D = 4 が保持されているエントリの P V o 1 に、図 1 2 において矢印 D 3 で示されるように、「3」が追加される。この L S M T 1 2 0 -1 内のエントリの書き換えにより、論理工エクステント L E I D = 4 が、ノード 1 -2 の物理ボリューム P V o 1 = 2 に加えて、新たにノード 1 -3 の物理ボリューム P V o 1 = 3 にも対応付けられる。つまり、論理工エクステント L E I D = 4 を構成する物理エクステントが、ノード 1 -2 の物理ボリューム P V o 1 = 2 及びノード 1 -3 の物理ボリューム P V o 1 = 3 に冗長化される。10

【0074】

論理工エクステントを構成する物理エクステントの冗長化構成後に、ホストからコントローラ 1 1 -i に対して、当該論理工エクステントへのライトアクセスの要求が発生したものとする。この場合、コントローラ 1 1 -i は、上記論理工エクステントに対応する複数の物理エクステントの全てに対してライトを行う。したがって、論理工エクステント L E I D = 4 へのライトアクセスが発生した場合であれば、ノード 1 -2 の物理ボリューム P V o 1 = 2 / 物理エクステント P E I D = 1 及びノード 1 -3 の物理ボリューム P V o 1 = 3 / 物理エクステント P E I D = 2 に対してデータライトが行われる。リードの場合はこの限りではない。つまり、物理ボリューム P V o 1 = 2 / 物理エクステント P E I D = 1 または物理ボリューム P V o 1 = 3 / 物理エクステント P E I D = 2 の一方からのデータリードが行われる。20

【0075】

次に、論理工エクステントに関する所在管理サービスを、ノードをまたがってマイグレーション（移動）する場合の動作について、図 1 3 を参照して説明する。この所在管理サービスのマイグレーションは、当該所在管理サービスの負荷分散、或いはノードを構成するハードウェアの交換 / 更新などのために行われる。

【0076】

論理工エクステントに関する所在管理サービスのマイグレーションに際し、例えば構成管理部により移動元及び移動先が決定される。ここでは、図 1 のストレージクラスタが図 1 2 に示す状態にあるときに、所在管理サービスの移動元として、論理ボリューム L V o 1 = 1 / 論理工エクステント L E I D = 4 に関するネームサービスを担当する、ノード 1 -1 の所在管理サーバ 1 2 -1 が決定されたものとする。また、そのネームサービスの移動先として、ノード 1 -2 の所在管理サーバ 1 2 -2 が決定されたものとする。30

【0077】

すると、移動元ノード 1 -1 の論理ボリューム L V o 1 = 1 / 論理工エクステント L E I D = 4 に関する L S M T 1 2 0 -1 内エントリの情報が、図 1 3 において矢印 E 1 で示されるように、移動先ノード 1 -2 の L S M T 1 2 0 -2 にコピーされる。

【0078】

移動元ノード 1 -1 の例えば所在管理サーバ 1 2 -1 または移動先ノード 1 -2 の例えば所在管理サーバ 1 2 -2 は、論理ボリューム L V o 1 = 1 / 論理工エクステント L E I D = 4 に関する所在管理サービスがノード 1 -2 に移動されたことを、全てのコントローラ 1 1 -1 ~ 1 -3 に通知する。40

【0079】

コントローラ 1 1 -1 ~ 1 1 -3 の各々は、論理ボリューム L V o 1 = 1 / 論理工エクステント L E I D = 4 に関する L M M T 1 1 2 a 内のエントリの M S を、図 1 3 において矢印 E 2 で示されるように、ノード 1 -1 (の所在管理サーバ 1 2 -1) の I D (M S = 1) からノード 1 -2 (の所在管理サーバ 1 2 -2) の I D (M S = 2) に書き換える（張り替える）。

【0080】

また、論理ボリューム L V o 1 = 1 / 論理工エクステント L E I D = 4 を管理するノード50

1 -2及び1 -3のストレージ1 3 -2及び1 3 -3は、自身のL P M T 1 3 2 a中の論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関する所在管理サービスの逆引きを、図1 3において矢印E 3で示されるように、ノード1 -1(の所在管理サーバ1 2 -1)のI D (M S = 1)からノード1 -2(の所在管理サーバ1 2 -2)のI D (M S = 2)に変更する。ストレージ1 3 -2及び1 3 -3は、この変更を所在管理サービス移動の通知元ノードに応答する。

【0 0 8 1】

ここで、全コントローラ1 1 -1~1 1 -3がL M M T 1 1 2 aを書き換えるには、A) 所在管理サーバ(ここでは所在管理サーバ1 2 -1または1 2 -2)によるブロードキャスト(一斉通知)による方法、B) コントローラのサーバ特定部(ここではコントローラ1 1 -1または1 1 -2のサーバ特定部1 1 2)によるブロードキャストによる方法、C) 移動元からコントローラ1 1 -1~1 1 -3の各自に対する個々の更新通知による方法などが適用可能である。

【0 0 8 2】

ノード1 -1の例えは所在管理サーバ1 2 -1は、全ノード1 -1~1 -3からの応答を確認して、当該所在管理サーバ1 2 -1の論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関するL S M T 1 2 0 -1内のエントリを削除する。これにより、移動元ノード1 -1の論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関するL S M T 1 2 0 -1内エントリのデータが、移動先ノード1 -2のL S M T 1 2 0 -2に移動されたことになる。つまり、論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関する移動元ノード1 -1のL S M T 1 2 0 -1及び移動先ノード1 -2のL S M T 1 2 0 -2内のエントリが、それぞれ書き換えられたことになる。

【0 0 8 3】

次に、論理工エクステントに関する所在管理サービスを、ノードをまたがってコピーする場合の動作について、図1 4を参照して説明する。

【0 0 8 4】

所在管理サービスの多重化がなされていない状態では、当該所在管理サービスを担当するあるノードが故障した場合、ホストからのアクセス要求が実行できなくなる。そこで、所在管理サービスをノードをまたがってコピーして当該所在管理サービスを多重化(冗長化)することにより、耐障害性向上及び負荷分散を図ることが必要となる。

【0 0 8 5】

所在管理サービスをノードをまたがってコピー(冗長化)するに際し、例えば構成管理部によりコピー元及びコピー先が決定される。ここでは、図1のストレージクラスタが図1 3に示す状態にあるときに、所在管理サービスのコピー元として、論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関するネームサービスを担当する、ノード1 -2の所在管理サーバ1 2 -2が決定されたものとする。また、そのネームサービスのコピー先として、ノード1 -3の所在管理サーバ1 2 -3が決定されたものとする。

【0 0 8 6】

すると、コピー元ノード1 -2の論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関するL S M T 1 2 0 -2内エントリの情報が、図1 4において矢印F 1で示されるように、コピー先ノード1 -3のL S M T 1 2 0 -3にコピーされる。

【0 0 8 7】

コピー元ノード1 -2の例えは所在管理サーバ1 2 -2またはコピー先ノード1 -3の例えは所在管理サーバ1 2 -3は、論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関する所在管理サービスがノード1 -2からノード1 -3にも機能分担されたことを、全てのコントローラ1 1 -1~1 1 -3に通知する。

【0 0 8 8】

コントローラ1 1 -1~1 1 -3の各自は、論理ボリュームL V o 1 = 1 / 論理工エクステントL E I D = 4に関するL M M T 1 1 2 a内のエントリのM S、つまりノード1 -2(の所在管理サーバ1 2 -2)のI D (M S = 2)が設定されているM Sに、図1 4において矢印F

10

20

30

40

50

2で示されるように、ノード1-3(の所在管理サーバ12-3)のID(MS=3)を加える。これにより、論理ボリュームLV01=1/論理工エクステントLEID=4に関するLMMT112a内のエントリが、ノード1-2だけでなくノード1-3にも向けられる。

【0089】

また、論理ボリュームLV01=1/論理工エクステントLEID=4を新たに管理するノード1-3のストレージ13-3は、自身のLPMT132a中の論理ボリュームLV01=1/論理工エクステントLEID=4に関する所在管理サービスの逆引き(MS)を、図14において矢印F3で示されるように、ノード1-2(の所在管理サーバ12-2)だけでなく、ノード1-3(の所在管理サーバ12-3)にも向ける。ストレージ13-3は、この変更を所在管理サービスコピーの通知元ノードに応答する。全コントローラ11-1~11-3がLMMT112aを書き換えるには、前述した所在管理サービスの移動の場合と同様の方法A), B)またはC)が適用可能である。10

【0090】

以上、複数のノード(ストレージ)にまたがるエクステント移動/コピー及び所在管理サービス移動/コピーについて説明した。しかし、エクステント移動/コピーは1つのノード(ストレージ)の物理ボリューム内でも行うことができる。この場合、そのノード(ストレージ)のLPMT132aを更新するだけで良い。また、例えば所在管理サーバ12-iのLSMT120-i及びストレージ13-iのLPMT132aを冗長化のためにコピーすることも可能である。

【0091】

次に、図1のストレージクラスタに、新たにノードを参加させる(追加する)場合の動作について説明する。この場合、既にストレージクラスタを構成しているノード1-1~1-1のいずれかから、当該ストレージクラスタに新たに追加されるノード(新たなノード)に対して、少なくともLMMT112aをコピーする。これにより、新たなノードはIOを実行することができる。20

【0092】

新たなノードにノード1-1~1-1のいずれかの所在管理サーバの処理(所在管理サービス)を分担させるには、例えば構成管理部と連携して、前述の所在管理サービスをマイグレートする処理を行えば良い。ノードの参加で新たに増えたストレージ内の物理ボリューム/物理エクステントも、構成管理部と連携して、適宜分散して利用することができる。30

【0093】

上述したように本実施形態(第1の実施形態)においては、複数のノード(実施形態では3つのノード)を用いてストレージクラスタを構成したとき、各々のノードが管理しなければならない情報量を減らすことができる。また本実施形態においては、あるノード(のストレージ)の物理ボリューム内で、或いは複数のノード(のストレージ)の物理ボリュームをまたがって、論理工エクステントに対応する物理エクステントを移動/コピーする場合に、ストレージクラスタに含まれる全てのコントローラが情報を書き換える必要はないため(所在管理サーバの情報を書き換えるだけで良いため)、コントローラ間での同期更新処理が必要なく、エクステント移動/コピー時の処理を簡単にし、総じて性能を向上させることができる。40

【0094】

[第2の実施形態]

前記第1の実施形態では、ストレージクラスタを構成する各ノード1-1~1-3は、それぞれコントローラ11-1~1-3、所在管理サーバ12-1~12-3及びストレージ13-1~13-3を備えている。しかし、各ノードが、コントローラ、所在管理サーバ及びストレージの全てを必ずしも備える必要はない。そこで、ストレージクラスタを構成するノードの幾つかが、コントローラ、所在管理サーバ及びストレージの1つまたは2つのみを備える本発明の第2の実施形態について説明する。

【0095】

図15は本発明の第2の実施形態に係るストレージクラスタ構成のストレージシステム50

の構成を示すブロック図である。図15において、図7と同様の要素には便宜的に同一参照符号を付してある。図15のストレージシステム（ストレージクラスタ）は、前記第1の実施形態と同様に、3つのノード1-1～1-3から構成される。図15のストレージクラスタが第1の実施形態と異なるのは、ノード1-1～1-3のうちノード1-2及び1-3がコントローラ、所在管理サーバ及びストレージの1つまたは2つのみを備える点にある。ここでは、ノード1-1は、第1の実施形態と同様に、コントローラ11-1、所在管理サーバ12-1及びストレージ13-1を備える。これに対し、ノード1-2はコントローラ11-2のみを備え、ノード1-3はコントローラを除く所在管理サーバ12-3及びストレージ13-3を備えている。この図15に示すストレージクラスタの動作自体は、第1の実施形態と同様である。

10

【0096】

本実施形態では、ストレージクラスタが3つのノードから構成されているものの、コントローラ、所在管理サーバ及びストレージの数が2つである場合を想定している。しかし、所在管理サーバ及びストレージの数はストレージクラスタ全体で1つであっても構わない。つまり複数のノードから構成されるストレージクラスタにおいて、コントローラの数は少なくとも2つであれば良く、所在管理サーバ及びストレージの数は少なくとも1つであれば良い。この制約のもとで、コントローラ、所在管理サーバ及びストレージの数は適宜増減可能である。つまり本実施形態においては、ストレージクラスタを構成するとき、状況に応じて、必要な機能のみを拡張することができる。

【0097】

20

[第3の実施形態]

次に、本発明の第3の実施形態について説明する。この第3の実施形態の特徴は、実際にホストからある論理工エクステントへの初回のアクセスが要求されるまで、ストレージ側で当該論理工エクステントに対応する物理エクステントの割り付けを行わず、ディスクの有効利用を図ることにある。

【0098】

30

図16は、本発明の第3の実施形態に係るストレージクラスタ構成のストレージシステムの構成を示すブロック図である。図16において、図7と同様の要素には便宜的に同一参照符号を付してある。図16のストレージシステム（ストレージクラスタ）は、前記第1の実施形態と同様に、3つのノード1-1～1-3から構成される。図16のストレージクラスタが第1の実施形態と異なるのは、ホストから論理工エクステントへの初回のアクセス、例えばライトアクセスが要求されるまで、ストレージ13-i側で当該論理工エクステントに対応する物理エクステントの割り付けを行わない点にある。

【0099】

図16の例では、論理ボリュームLV01=1/論理工エクステントLEID=1及び論理ボリュームLV01=1/論理工エクステントLEID=4に対して、ノード1-1における物理ボリューム130-1の物理エクステントの割り付けが行われていない状態が、ストレージ13-1のLPMT132aによって示されている。同様に、論理ボリュームLV01=1/論理工エクステントLEID=2に対して、ノード1-2内の物理ボリューム130-2の物理エクステントの割り付けが行われていない状態が、ストレージ13-2のLPMT132aによって示されている。また、論理ボリュームLV01=1/論理工エクステントLEID=3に対して、ノード1-3内の物理ボリューム130-3の物理エクステントの割り付けが行われていない状態が、ストレージ13-3のLPMT132aによって示されている。

40

【0100】

ここでは、未割り付けの状態は、LPMT132a内で列項目PEIDに“NA(Not Assignment)”が設定されているエントリにより示される。但し、LPMT132a内で列項目PEIDに“NA”が設定されているエントリの他の列項目LV01, LEID及びMSには、それぞれ論理ボリューム、論理工エクステント及びノードを指定する情報が設定されている。このことは、論理ボリューム/論理工エクステントに対するストレージ（物

50

理ボリューム)の割り付けは行われていることを示す。換言するならば、論理ボリューム/論理工クステントに対する L P M T 1 3 2 a 内のエントリ (L V o l , L E I D) で指定される論理ボリューム/論理工クステントに必要な領域が、当該エントリの列項目 M S で指定されるノード上で予約されていることを示す。なお、図 1 6 では、L P M T 1 3 2 a 内のエントリにおける各列項目の並びが便宜的に変更されている点に注意されたい。

【 0 1 0 1 】

L P M T 1 3 2 a 内のエントリ (L V o l , L E I D) で指定される論理ボリューム/論理工クステントに対して物理エクステントの割り付けが行われると、当該エントリ中の列項目 P E I D が、“ N A ” から当該割り付けられた物理エクステントの I D で書き換えられる。

10

【 0 1 0 2 】

この図 1 6 に示すストレージクラスタの基本的な動作は、第 1 の実施形態と同様である。但し、論理ボリューム作成時と、論理工クステントへの初回のアクセス (ライトアクセス) 時の挙動は、第 1 の実施形態と異なる。

【 0 1 0 3 】

そこで、論理ボリューム作成時において第 1 の実施形態と異なる点について説明する。第 1 の実施形態では、前述した (a) , (b) , (c) の手順で論理ボリュームが作成される。これに対して第 3 の実施形態では、論理工クステントへの初回のライトアクセス時に当該論理工クステントに対する物理エクステントの割り付けが行われるため、上記 (a) の動作が次の (a 1) のようになる。

20

【 0 1 0 4 】

(a 1) 構成管理部は、作成されるべき論理ボリュームの容量を確保するために、当該論理ボリュームを構成する論理工クステントの各々を、どのノード I D (P V o l) のストレージ (物理ボリューム) に格納するか決定する。但し、上記 (a) とは異なり、各論理工クステントへの物理エクステントの割り付けは行われない。構成管理部は、ストレージ 1 3 -1 ~ 1 3 -3 毎に、各論理工クステントに対して物理エクステントが未割り付け状態にあることを示す L P M T 1 3 2 a を生成して、そのストレージに保持する。

【 0 1 0 5 】

次に、図 1 6 のストレージクラスタにおける、ホストから論理工クステントへのライトアクセス時の動作について、図 1 乃至 図 3 を援用しながら、図 1 7 のフローチャートを参照して説明する。図 1 7 において、図 4 のフローチャートと同様の部分には同一符号を付してある。

30

【 0 1 0 6 】

図 1 7 のフローチャートが、図 4 のフローチャートと異なるのは、ある論理工クステントへの初回のアクセスがライトアクセスの場合に、当該論理工クステントに物理エクステントが割り付けられていないため、割り付け先の物理エクステント先を決定する処理 (ステップ S 1 8) が追加されている点である。

【 0 1 0 7 】

今、第 1 の実施形態と同様に、ホストからノード 1 -1 のコントローラ 1 1 -1 に含まれているターゲットインターフェイス 1 1 1 に対してアクセス (ライトアクセス) が要求されたものとする。この場合、図 4 のフローチャートと同様に、まずステップ S 0 ~ S 7 が実行される。但し図 1 7 では、ステップ S 0 ~ S 7 のうちのステップ S 1 ~ S 6 が省略されている。ステップ S 7 では、ノード I D = S I D x で示されるノードのストレージ、例えばノード 1 -1 のストレージ 1 3 -1 に対し、論理工クステント (L V o l x , L E I D x) に対応する物理エクステントへのアクセスが要求される。するとストレージ 1 3 -1 では、ステップ S 1 8 が次のように実行される。

40

【 0 1 0 8 】

まず、ストレージ 1 3 -1 の I O ドライバ 1 3 1 は、論理工クステント (L V o l x , L E I D x) に対応付けられている L P M T 1 3 2 a 内のエントリの列項目 P E I D を参照する (ステップ S 1 8 a)。ストレージ 1 3 -1 は、この P E I D が非 N A であるか否かに

50

より、論理工エクステント (LVOLX, LEIDX) に物理エクステントが割り付けられているか否かを判定する (ステップ S18b)。

【0109】

もし、論理工エクステント (LVOLX, LEIDX) に物理エクステントが割り付けられていないならば、I/O ドライバ 131 は構成管理部と連携して、論理工エクステント (LVOLX, LEIDX) にストレージ 13-1 (物理ボリューム 130-1) 内の適当な物理エクステント PEIDX を割り付ける (ステップ S18c)。このステップ S18c において、I/O ドライバ 131 は、論理工エクステント (LVOLX, LEIDX) に対応付けられている LPMT132a 内のエントリの列項目 PEID を、“NA” から物理エクステント PEIDX の ID (=PEIDX) に更新する。そして I/O ドライバ 131 は、物理エクステント PEIDX に対してアクセスし、コントローラ 11-1 の I/O マネージャ 113 に対して応答する (ステップ S18d)。10

【0110】

一方、論理工エクステント (LVOLX, LEIDX) に物理エクステント (例えば物理エクステント PEIDX) が既に割り付けられているならば (ステップ S18b)、I/O ドライバ 131 はステップ S18c をスキップしてステップ S18d を実行する。

【0111】

このように第 3 の実施形態においては、ある論理工エクステントに対する初回のアクセスがライトアクセスの場合に、当該論理工エクステントに物理エクステントが割り付けられる。これに対し、ある論理工エクステントに対する初回のアクセスがリードアクセスの場合、つまりデータがライトされていない論理工エクステントに対してリードアクセスが発生した場合には、当該論理工エクステントに物理エクステントを割り付けることも、割り付けないことも可能である。割り付ける場合は、I/O ドライバ 131 によって上記ステップ S18 が実行されれば良い。いずれの場合にも、リード要求に対する応答として、全てゼロなどの適切なデータが返されるようにすれば良い。なお、本実施形態 (第 3 の実施形態) で適用される物理エクステントの割り付け方法は、第 2 の実施形態にも同様に適用可能である。本実施形態においては、各ストレージにおいて、ホストからアクセスが要求された際の状態に応じて、最適な物理エクステントの割り付けが可能になる。20

【0112】

[第 4 の実施形態]

次に本発明の第 4 の実施形態について説明する。この第 4 の実施形態の特徴は、実際にホストからある論理工エクステントへの初回のアクセスが要求されるまで、当該論理工エクステントの領域の予約が行われない点にある。30

【0113】

図 18 は、本発明の第 4 の実施形態に係るストレージクラスタ構成のストレージシステムの構成を示すブロック図である。図 18 において、図 7 と同様の要素には便宜的に同一参照符号を付してある。図 18 のストレージシステム (ストレージクラスタ) は、前記第 1 の実施形態と同様に、3 つのノード 1-1~1-3 から構成される。図 18 のストレージクラスタが第 1 の実施形態と異なるのは、実際にホストからある論理工エクステントへの初回のアクセスが要求されるまで、当該論理工エクステントへの物理エクステントの割り付けだけでなく、当該論理工エクステントへのストレージ (物理ボリューム) の割り付け (予約) も行われない点にある。40

【0114】

このように、図 18 のストレージクラスタでは、ある論理工エクステントへの初回のアクセスが要求されるまで、当該論理工エクステントの領域の予約が行われないため、論理ボリューム作成時には、ストレージ 13-1~13-3 の LPMT132a のエントリを予約する必要もない。論理工エクステントに対するストレージ (物理ボリューム) 及び物理エクステントの割り付けは、コントローラ 11-i (i = 1, 2, 3) からの所在管理サーバ 12-j に対する問い合わせに応じて当該所在管理サーバ 12-j (j = 1, 2, 3) によって行われる。この物理エクステントの割り付け計画は、例えば構成管理部により行われる。50

【0115】

図18の例では、論理ボリュームを構成する各論理工エクステントに対するストレージ（物理ボリューム）の割り付けが未だ行われていない状態が示されている。つまり図18の例では、論理ボリュームLV01=1 / 論理工エクステントLEID=1及び論理ボリュームLV01=1 / 論理工エクステントLEID=4に対して、ストレージ（物理ボリューム）の割り付けが行われていない状態が、所在管理サーバ12-1のLSMT120-1によって示されている。同様に、論理ボリュームLV01=1 / 論理工エクステントLEID=2に対して、ストレージ（物理ボリューム）の割り付けが行われていない状態が、所在管理サーバ12-2のLSMT120-2によって示されている。また、論理ボリュームLV01=1 / 論理工エクステントLEID=3に対して、ストレージ（物理ボリューム）の割り付けが行われていない状態が、所在管理サーバ12-3のLSMT120-3によって示されている。ここでは、ストレージ（物理ボリューム）の未割り付けの状態は、LSMT120-1~120-3内で列項目PV01に“NA”が設定されているエントリにより示される。図18において、LSMT120-1~120-3のエントリから、ストレージ13-1~13-3のLPMT132aのエントリに向かう矢印が描かれていないと注意されたい。

【0116】

この図18に示すストレージクラスタの基本的な動作は、第1の実施形態と同様である。但し、論理ボリューム作成時と、論理工エクステントへの初回のアクセス時の挙動は、第1の実施形態と異なる。

【0117】

そこで、論理ボリューム作成時において第1の実施形態と異なる点について説明する。第1の実施形態では、前述した(a),(b),(c)の手順で論理ボリュームが作成される。これに対して第4の実施形態では、論理工エクステントへの初回アクセス時に当該論理工エクステントを格納するストレージ（物理ボリューム）が決定され、この決定されたストレージ（物理ボリューム）内で当該論理工エクステントに対して物理エクステントが割り付けられる。このため、上記(a),(b)の動作が次の(a2),(b2)のようになる。

【0118】

(a2)構成管理部は、作成されるべき論理ボリュームを構成する論理工エクステントの各々を、どのノードID(PV01)のストレージ（物理ボリューム）に格納するか決定しない。このため構成管理部は、ストレージ13-1~13-3毎に、図18に示されるように空の状態のLPMT132aを生成して、そのストレージに保持する。

【0119】

(b2)構成管理部は、どのノードの所在管理サーバに論理工エクステントの所在管理サービスを担当させるかを決定する。但し、その論理工エクステントをどのストレージ（物理ボリューム）に格納するかは決定しない。このため構成管理部は、所在管理サーバ12-1~12-3毎に、その所在管理サーバが担当する論理工エクステントについてのエントリ情報をあって、列項目PV01が“NA”的エントリの情報を含むLSMT120-1~120-3を生成して、その所在管理サーバ12-1~12-3内に設定する。なお、第2の実施形態と同様に、ストレージクラスタ内の全てのノード1-1~1-3に所在管理サーバ(LSMT)が設けられる必要はない。

【0120】

次に、図18のストレージクラスタにおける、ホストから論理工エクステントへのライトアクセス時の動作について、図1乃至図3を援用しながら、図19のフローチャートを参照して説明する。図19において、図4または図17のフローチャートと同様の部分には同一符号を付してある。

【0121】

今、第1の実施形態と同様に、ホストからノード1-1のコントローラ11-1に含まれているターゲットインターフェイス111に対してアクセスが要求されたものとする。この場合、図4のフローチャートと同様に、まずステップS0~S4が実行される。図19では

10

20

30

40

50

、ステップS0～S4のうちのステップS1～S3が省略されている。ステップS4では、例えばコントローラ11-1のサーバ特定部112が例えば所在管理サーバ12-1に対して、論理工クステント(ターゲット論理工クステント)(LVOLX, LEIDX)に対応する物理エクステントを格納しているストレージのノードID=SIDXを問い合わせる。すると所在管理サーバ12-1では、ステップS25が次のように実行される。

【0122】

まず、所在管理サーバ12-1は、どのノードID=SIDXのストレージ(物理ボリューム)が、論理工クステント(LVOLX, LEIDX)に対応する物理エクステントを格納しているかを調べるために、当該論理工クステント(LVOLX, LEIDX)に対応付けられているLSMT120-1内のエントリの列項目PVOL(=SIDX)を参照する(ステップS25a)。10

【0123】

所在管理サーバ12-1は、このPVOLが非NAであるか否かにより、論理工クステント(LVOLX, LEIDX)にストレージ(物理ボリューム)が割り付けられているか否かを判定する(ステップS25b)。

【0124】

もし、論理工クステント(LVOLX, LEIDX)にストレージ(物理ボリューム)が割り付けられていないならば、所在管理サーバ12-1は、ストレージ13-1～13-3(の物理ボリューム130-1～130-3)における物理エクステントの空きを確認する(ステップS25c)。この確認処理は、例えば所在管理サーバ12-1がストレージ13-1～13-3のI/Oドライバ131と通信を行うことにより実現される。20

【0125】

もし、ストレージ13-1～13-3のいずれにも物理エクステントの空きがない(または要求に応えられない)場合には、I/Oエラーとなる(ステップS25d)。この場合、ホストからのアクセス要求に対する応答として、エラーが返される(ステップS9)。

【0126】

一方、ストレージ13-1～13-3のいずれかに物理エクステントの空きがあるならば、所在管理サーバ12-1は物理エクステントに空きのあるストレージ(例えばストレージ13-1)を選択して、論理工クステント(LVOLX, LEIDX)に当該ストレージを割り付ける(ステップS25e)。このステップS25eにおいて、所在管理サーバ12-1は、論理工クステント(LVOLX, LEIDX)へのストレージの割り付けがLSMT120-1内の対応するエントリに反映されるように、当該エントリを更新する。ここでは、論理工クステント(LVOLX, LEIDX)に対応付けられているLSMT120-1内のエントリの列項目PVOLが、“NA”から当該論理工クステント(LVOLX, LEIDX)に割り付けられるストレージ13-1のノードID(物理ボリューム130-1のノードID=PVOLOL=1)に更新される。30

【0127】

ステップS25eにおいてLSMT120-1が更新されると、第1の実施形態で図4のフローチャートのステップS4が実行された場合と同様に、ステップS5, S6が実行される。これにより、所在管理サーバ12-1からコントローラ11-1に対し、論理工クステント(LVOLX, LEIDX)に割り付けられるストレージ13-1のノードID(物理ボリューム130-1のノードID=PVOLOL=1)が問い合わせ元のサーバ特定部112を介して通知される。なお、論理工クステント(LVOLX, LEIDX)にストレージ(物理ボリューム)が割り付けられている場合には(ステップS25b)、直ちにステップS5, S6が実行される。40

【0128】

ターゲットインターフェイス111は、サーバ特定部112を介して通知されたノードID=SIDX=1を受け取ると、第1及び第3の実施形態と同様に、ノードID=SIDX=1で示されるノード1-1のストレージ13-1に対し、論理工クステント(LVOLX, LEIDX)に対応する物理エクステントへのアクセスをI/Oマネージャ113を介し50

て要求する（ステップS7）。このステップS7以降の動作は、第3の実施形態と同様であり、ステップS18a～S18dからなるステップS18がストレージ13-1において実行される。これにより、論理工エクステント（LVOLX, LEIDX）に物理エクステントが割り付けられていない場合には、物理ボリューム130-1内の空き物理エクステントが当該論理工エクステント（LVOLX, LEIDX）に割り付けられる。ここでは、そして、物理エクステントPEIDXが割り付けられたものとする。この場合、論理工エクステント（LVOLX, LEIDX）に対応付けられているLPMT132a内のエントリの列項目PEIDを、“NA”から物理エクステントPEIDXのID（=PEIDX）に更新される。

【0129】

10

本実施形態においては、各ストレージにおいて、ホストからアクセスが要求された際の状態に応じて、最適な物理エクステントの割り付けが可能になるだけでなく、総物理ボリューム容量の上限値を超える容量の論理ボリュームを作成することができる。

【0130】

[第5の実施形態]

次に本発明の第5の実施形態について説明する。この第5の実施形態の特徴は、コントローラ11-i（i=1, 2, 3）のサーバ特定部112から所在管理サーバ12-j（j=1, 2, 3）への問い合わせと当該問い合わせに対する回答（結果）とに関する情報をキャッシュ112bに保持することにある。この情報は、論理ボリュームLVOLX/論理工エクステントLEIDX、つまり論理工エクステント（LVOLX, LEIDX）を示す情報（LVOLX, LEIDX）と、当該論理工エクステント（LVOLX, LEIDX）に対応している物理エクステントを格納しているストレージのノードID=SIDXとを含む。このキャッシュ112bを利用することで、再度の問い合わせが必要となった場合に、当該問い合わせに対する回答に相当する情報をキャッシュ112bから速やかに取得することが可能となる。

20

【0131】

次に、第5の実施形態における、ホストから論理工エクステントへのアクセス時の動作について、図1乃至図3及び図7を援用しながら、図20のフローチャートを参照して説明する。

【0132】

30

今、第1の実施形態と同様に、ホストからノード1-1のコントローラ11-1に含まれているターゲットインターフェイス111に対してアクセスが要求されたものとする。この場合、図4のフローチャートと同様に、まずステップS0～S2が実行される。図20では、ステップS0～S2のうちのステップS0, S1が省略されている。ステップS2では、コントローラ11-1のターゲットインターフェイス111からコントローラ11-1のサーバ特定部112に対して、論理工エクステント（LVOLX, LEIDX）が、どのノードのストレージに格納されているかが問い合わせられる。

【0133】

するとサーバ特定部112は、第1の実施形態とは異なって、自身が管理しているキャッシュ112bを参照して、論理工エクステント（LVOLX, LEIDX）に対応している物理エクステントを格納しているストレージのノードID=SIDXを調べる（ステップS31）。

40

【0134】

もし、目的のノードID=SIDXが（LVOLX, LEIDX）と対応付けてキャッシュ112bに格納されていないならば、つまりミスヒットならば、サーバ特定部112は、第1の実施形態におけるターゲットインターフェイス111からの問い合わせ（ステップS2）に対するのと同様に、ステップS3及びS4を実行する。

【0135】

本実施形態では、論理工エクステント（LVOLX, LEIDX）に対応している物理エクステントが格納されているストレージの所在が、第1の実施形態と同様にノード1-1の

50

所在管理サーバ12-1によって管理され、当該ストレージのノードID(=PV01)がSIDx=1であるものとする。このノードIDはLSMT120-1に基づいて求められる。この場合、所在管理サーバ12-1は、論理工エクステント(LV01x, LEIDx)に対応している物理エクステントが格納されているストレージのノードID=SIDxと、LSMT120-1のシリアル番号(LSMTシリアル番号)SNとを、問い合わせ元のサーバ特定部112に対して通知する(ステップS5a)。第1の実施形態のステップS5との違いは、ノードIDに加えて、当該ノードIDを求めるのに用いられたLSMT120-1のシリアル番号SNが通知される点である。このシリアル番号SNは、LSMT120-1が更新される毎に、所在管理サーバ12-1によって例えばインクリメントされる。このことは、LSMT120-2, 120-3についても同様である。

10

【0136】

サーバ特定部112は、所在管理サーバ12-1からの通知を受けて、キャッシュ112bに、{(LV01x, LEIDx), SIDx, SN}を含む情報(つまり、問い合わせと回答に関する情報)を格納する(ステップSS5b)。これにより、サーバ特定部112は、論理工エクステント(LV01x, LEIDx)がどのノードのストレージに格納されているかをターゲットインターフェイス111によって再び問い合わせられた場合に、当該問い合わせに対する回答に相当する情報を上記ステップS31の処理で速やかに取得することができる。つまり、サーバ特定部112から所在管理サーバへの問い合わせの回数を減らして、アクセス速度を向上させることができる。

【0137】

但し、所在管理サーバ12-1~120-3上のLSMT120-1~120-3が変更された場合、その変更がキャッシュ112bに反映される必要がある。その理由は、例えば第1の実施形態のように、ストレージ間で物理エクステントのコピー(冗長構成)を管理する場合(図12参照)、LSMT120-1~120-3の更新がキャッシュ112bに反映されないと、ライトアクセスによって一方の物理エクステントのみが書き換えられてしまい、冗長構成が崩れてしまうからである。そのため、本実施形態では、以下のようなキャッシュ更新の仕組みが用いられる。

20

【0138】

まず、LSMT120-1~120-3の各々にシリアル番号SNが付与される。このシリアル番号SNは、ストレージ13-1~13-3のI/Oドライバ131によってLSMT120-1~120-3が更新される都度、例えば当該I/Oドライバ131によってインクリメント(更新)される。

30

【0139】

また、ステップS5aにおいてノードID=SIDxを求めるのに用いられたLSMT120-j(j=1, 2, 3)のシリアル番号SNが、(LV01x, LEIDx), SIDxと組をなしてキャッシュ112bに格納される(ステップS5b)。

【0140】

コントローラ11-i(i=1, 2, 3)は、ストレージ13-jへのアクセスを行うときに、このシリアル番号SNを受け渡す。ストレージ13-jのI/Oドライバ131は、このシリアル番号SNと自身が認識しているLSMT120-jの最新のシリアル番号SNとを比較する。I/Oドライバ131は、両シリアル番号SNが一致していないならば、コントローラ11-iのサーバ特定部112が管理するキャッシュ112bには、LSMT120-jの最新の更新内容が反映されていないと判定する。この場合、ストレージ13-jのI/Oドライバ131はコントローラ11-iに対してキャッシュ112bの該当する情報の無効化を通知する。つまりI/Oドライバ131は、キャッシュ無効化手段として機能する。コントローラ11-iのサーバ特定部112は、この通知に応じて、ステップS32でミスヒットが判定された場合と同様に、所在管理サーバ12-jに対して再度の問い合わせを行う(ステップS3, S4)。これによりサーバ特定部112は、所在管理サーバ12-jからLSMT120-jの最新の情報を取得して、キャッシュ112bに反映させることができる。

40

50

【0141】

なお、以下に述べるように、所在管理サーバ12-jがキャッシング無効化手段として機能しても良い。つまり、所在管理サーバ12-jがコントローラ11-jのサーバ特定部112上のキャッシング112bを監視して、自身が管理するLSMT120-jとの不整合が生じているかを判別する構成とすることも可能である。もし不整合を判別した場合、所在管理サーバ12-jからコントローラ11-jのサーバ特定部112に、キャッシング112bの該当するエントリ情報の破棄・更新が必要なことを通知すれば良い。

【0142】

なお、本発明は、上記各実施形態そのままで限定されるものではなく、実施段階ではその要旨を逸脱しない範囲で構成要素を変形して具体化できる。また、上記各実施形態に開示されている複数の構成要素の適宜な組み合せにより種々の発明を形成できる。例えば、各実施形態に示される全構成要素から幾つかの構成要素を削除してもよい。

10

【図面の簡単な説明】**【0143】**

【図1】本発明の第1の実施形態に係るストレージクラスタ構成のストレージシステムの概略構成を示すブロック図。

【図2】図1に示されるコントローラの構成を示すブロック図。

【図3】図1に示されるストレージの構成を示すブロック図。

【図4】同第1の実施形態においてホストからアクセス要求が発行された場合の処理の手順を示すフローチャート。

20

【図5】同第1の実施形態においてホストからアクセス要求が発行された場合の情報の流れを示す図。

【図6】同第1の実施形態においてホストからアクセス要求が発行された場合の情報の流れの変形例を示す図。

【図7】図1のシステムにおいて、論理ボリュームLV01がLV01=1であって、当該論理ボリュームLV01=1を、LEIDがLEID=1～LEID=4の4つの論理エクステントから構成した場合のシステム構成を示す図。

【図8】図7の状態におけるLMMTのデータ構造例を示す図。

【図9】図7の状態におけるLSMTのデータ構造例を示す図。

【図10】図7の状態におけるLPMTのデータ構造例を示す図。

30

【図11】同第1の実施形態において、論理工エクステントを構成する物理エクステントのデータを、ストレージをまたがって別の物理エクステントにマイグレートする場合の動作を説明するための図。

【図12】同第1の実施形態において、論理工エクステントを構成する物理エクステントのデータを、ストレージをまたがって別の物理エクステントにコピーする場合の動作を説明するための図。

【図13】同第1の実施形態において、論理工エクステントに関する所在管理サービスを、ノードをまたがってマイグレートする場合の動作を説明するための図。

【図14】同第1の実施形態において、論理工エクステントに関する所在管理サービスを、ノードをまたがってコピーする場合の動作を説明するための図。

40

【図15】本発明の第2の実施形態に係るストレージクラスタ構成のストレージシステムの構成を示すブロック図。

【図16】本発明の第3の実施形態に係るストレージクラスタ構成のストレージシステムの構成を示すブロック図。

【図17】同第3の実施形態においてホストからアクセス要求が発行された場合の処理の手順を示すフローチャート。

【図18】本発明の第4の実施形態に係るストレージクラスタ構成のストレージシステムの構成を示すブロック図。

【図19】同第4の実施形態においてホストからアクセス要求が発行された場合の処理の手順を示すフローチャート。

50

【図20】本発明の第5の実施形態においてホストからアクセス要求が発行された場合の処理の手順を示すフロー・チャート。


【符号の説明】

【0144】


1-1～1-3…ノード、11-1～11-3、11-i…コントローラ、12-1～12-3…所在管理サーバ、13-1～13-3、13-i…ストレージ、112a…LMMT（論理工エクステント - 所在管理サーバマッピングテーブル、第1のマッピングテーブル）、112b…キャッシュ、120-1～120-3、120-i…LSMT（論理工エクステント - ストレージマッピングテーブル、第2のマッピングテーブル）、130-1～130-3、130-i…物理ボリューム、132a…LPMT（論理工エクステント - 物理エクステントマッピングテーブル、第3のマッピングテーブル）。

10


【図1】




【図2】




【図3】




【 図 4 】




【 図 5 】



【図6】



【図7】



【図8】

図8

LMMT		
LVol	LEID	MS
1	1	1
1	2	2
1	3	3
1	4	1

【図9】

図9

LSMT		
LVol	LEID	PVol
1	1	1
1	4	1


【図10】

図10

LPMT			
PEID	VVol	LEID	MS
1	1	1	1
2	1	4	1
3	NULL	NULL	NULL


【図11】

図11




【図12】

図12




【図13】


図13




【図 14】




【図 15】



【図 16】




【図 17】




【図18】

図18




【図19】

図19



【図20】

図20



フロントページの続き

(74)代理人 100075672
弁理士 峰 隆司
(74)代理人 100109830
弁理士 福原 淑弘
(74)代理人 100084618
弁理士 村松 貞男
(74)代理人 100092196
弁理士 橋本 良郎
(72)発明者 小原 誠
東京都港区芝浦一丁目1番1号 東芝ソリューション株式会社内

審査官 木村 雅也

(56)参考文献 特開平07-152491(JP,A)
特開2004-078398(JP,A)
特開2001-312372(JP,A)

(58)調査した分野(Int.Cl., DB名)

G 06 F 3 / 06