

(19) 日本国特許庁(JP)

(12) 特許公報(B2)

(11) 特許番号

特許第6326062号
(P6326062)

(45) 発行日 平成30年5月16日(2018.5.16)

(24) 登録日 平成30年4月20日(2018.4.20)

(51) Int.Cl.

G06F 9/50 (2006.01)

F 1

G06F 9/46 465A
G06F 9/46 465C

請求項の数 18 (全 13 頁)

(21) 出願番号 特願2015-544196 (P2015-544196)
 (86) (22) 出願日 平成25年11月26日 (2013.11.26)
 (65) 公表番号 特表2016-506557 (P2016-506557A)
 (43) 公表日 平成28年3月3日 (2016.3.3)
 (86) 國際出願番号 PCT/US2013/072094
 (87) 國際公開番号 WO2014/082094
 (87) 國際公開日 平成26年5月30日 (2014.5.30)
 審査請求日 平成27年10月1日 (2015.10.1)
 (31) 優先権主張番号 61/729,930
 (32) 優先日 平成24年11月26日 (2012.11.26)
 (33) 優先権主張国 米国(US)

(73) 特許権者 514318459
 サイクル コンピューティング、エルエル
 シー
 アメリカ合衆国 O 6830 コネチカッ
 ト州、グリーンウィッチ、スイート 3エ
 フ、レイルロード アベニュー 151
 (74) 代理人 100140109
 弁理士 小野 新次郎
 (74) 代理人 100118902
 弁理士 山本 修
 (74) 代理人 100106208
 弁理士 宮前 徹
 (74) 代理人 100120112
 弁理士 中西 基晴

最終頁に続く

(54) 【発明の名称】異なる環境どうし間でのジョブ実行依頼のトランスペアレントなルーティング

(57) 【特許請求の範囲】

【請求項 1】

作業負荷を管理する方法であって、

(a) プロセッサによって、ルーティングするための作業負荷を受け取ること、
 (b) 前記プロセッサによって、ローカルコンピュータクラスタ及び外部コンピュータクラスタについての連続的に取得したリアルタイムのパフォーマンス及び使用データに基づいて前記作業負荷をどこへルーティングするかを決定し、それに応じて前記作業負荷をルーティングし、その際、作業負荷に関連する出力データを、(i)作業負荷実行中にシームレスに、又は、(ii)自動的に修正された作業負荷工程として、作業負荷がルーティングされた先に転送すること、

前記ローカルコンピュータクラスタに部分的に余裕がある場合に、前記外部コンピュータクラスタへ実行依頼された作業負荷の部分集合を、前記ローカルコンピュータクラスタへ戻すこと

を備えた方法。

【請求項 2】

請求項 1 に係る方法であって、受け取った前記作業負荷についての完了最終期限及びバッチ/非バッチ・タイプを確認すること、を更に備えた方法。

【請求項 3】

請求項 2 に係る方法であって、前記ルーティング工程が、前記完了最終期限までに前記作業負荷を完了するのに充分な容量を有するローカルコンピュータクラスタについての前

記連続的に取得したリアルタイムのパフォーマンス及び使用データに応じて、前記ローカルコンピュータクラスタへ前記ルーティングを行うことを含む、方法。

【請求項 4】

請求項 2 に係る方法であって、前記ルーティング工程が、実行依頼されたバッチタイプの作業負荷の第 1 部分を前記ローカルコンピュータクラスタへ、かつ前記バッチタイプの作業負荷の第 2 部分を少なくとも 1 つの外部コンピュータクラスタヘルーティングすることを含む、方法。

【請求項 5】

請求項 2 に係る方法であって、前記ルーティング工程が、完了最終期限が前記ローカルコンピュータクラスタの容量からみた完了時期よりも長い非バッチタイプの作業負荷については、前記外部コンピュータクラスタヘルーティングすることを含む、方法。

10

【請求項 6】

請求項 4 に係る方法であって、実行依頼された前記バッチタイプの作業負荷の前記第 1 及び前記第 2 部分をどこヘルーティングするかを、前記プロセッサによって調整すること、を更に備えた、方法。

【請求項 7】

(a) 少なくとも 1 つのプロセッサ、及びコンピュータープログラムを格納した少なくとも 1 つの記憶部を備えた装置であって、前記コンピュータープログラム付きの少なくとも 1 つの記憶部は、前記少なくとも 1 つのプロセッサとともに、前記装置を動作させ、少なくとも、

20

(b) ルーティングのための作業負荷を受け取り、

(c) ローカルコンピュータクラスタ及び外部コンピュータクラスタについての連続的に取得したリアルタイムのパフォーマンス及び使用データに基づいて、前記作業負荷をどこにルーティングするかを決定し、それに応じて作業負荷をルーティングし、その際、作業負荷に関連する出力データを、(i) 作業負荷実行中にシームレスに、又は、(ii) 自動的に修正された作業負荷工程として、作業負荷がルーティングされた先に転送し、

前記ローカルコンピュータクラスタに部分的に余裕がある場合に、前記外部コンピュータクラスタへ実行依頼された作業負荷の部分集合を、前記ローカルコンピュータクラスタへ戻す

ように構成されている装置。

30

【請求項 8】

請求項 7 に係る装置であって、前記装置が、受け取った前記作業負荷についての完了最終期限及びバッチ / 非バッチタイプを、前記少なくとも 1 つのプロセッサによって確認するように、前記コンピュータープログラム付きの前記少なくとも 1 つの記憶部が構成されている装置。

【請求項 9】

請求項 8 に係る装置であって、前記ルーティング動作が、前記完了最終期限までに前記作業負荷を完了するのに充分な容量を有するローカルコンピュータクラスタについての前記連続的に取得したリアルタイムのパフォーマンス及び使用データに応じて、前記ローカルコンピュータクラスタへ前記ルーティングを行うことを含む装置。

40

【請求項 10】

請求項 8 に係る装置であって、前記ルーティング動作が、実行依頼されたバッチタイプの作業負荷の第 1 部分を前記ローカルコンピュータクラスタへ、かつ前記バッチタイプの作業負荷の第 2 部分を少なくとも 1 つの外部コンピュータクラスタヘルーティングすることを含む装置。

【請求項 11】

請求項 8 に係る装置であって、前記ルーティング動作が、完了最終期限が前記ローカルコンピュータクラスタの容量からみた完了時期よりも長い非バッチタイプの作業負荷については、前記外部コンピュータクラスタヘルーティングすることを含む装置。

【請求項 12】

50

前記装置が、実行依頼された前記バッチタイプの作業負荷の前記第1及び前記第2部分をどこヘルーティングするかを、前記少なくとも1つのプロセッサによって調整するよう前記コンピュータープログラム付きの少なくとも1つの記憶部が構成されている、請求項10に係る装置。

【請求項13】

少なくとも1つのプロセッサによって実行可能なコンピュータープログラムを格納した非一時的コンピュータ読取可能記憶媒体であって、前記コンピュータープログラムが前記少なくとも1つのプロセッサによって、

(a) ルーティングのための作業負荷を受け取る動作、
 (b) ローカルコンピュータクラスタ及び外部コンピュータクラスタについての連続的に取得したリアルタイムのパフォーマンス及び使用データに基づいて、前記作業負荷をどこヘルーティングするか決定し、それに応じて前記作業負荷をルーティングし、その際、作業負荷に関連する出力データを、(i)作業負荷実行中にシームレスに、又は、(ii)自動的に修正された作業負荷工程として、作業負荷がルーティングされた後に転送する動作、
前記ローカルコンピュータクラスタに部分的に余裕がある場合に、前記外部コンピュータクラスタへ実行依頼された作業負荷の部分集合を、前記ローカルコンピュータクラスタへ戻す動作

を実行する非一時的コンピュータ読取可能記憶媒体。

【請求項14】

請求項13に係る非一時的コンピュータ読取可能記憶媒体であって、前記コンピュータープログラムによって、前記プロセッサが、受け取った前記作業負荷についての完了最終期限及びバッチ／非バッチ・タイプを確認する動作を、更に行う、非一時的コンピュータ読取可能記憶媒体。

【請求項15】

請求項14に係る非一時的コンピュータ読取可能記憶媒体であって、前記ルーティング動作が、前記完了最終期限までに前記作業負荷を完了するのに充分な容量を有する前記ローカルコンピュータクラスタについての前記連続的に取得したリアルタイムのパフォーマンス及び使用データに応じて、前記ローカルコンピュータクラスタへ前記ルーティングを行うことを含む、非一時的コンピュータ読取可能記憶媒体。

【請求項16】

請求項14に係る非一時的コンピュータ読取可能記憶媒体であって、前記ルーティング動作が、実行依頼されたバッチタイプの作業負荷の第1部分を前記ローカルコンピュータクラスタへ、かつ前記バッチタイプの作業負荷の第2部分を少なくとも1つの外部コンピュータクラスタヘルーティングすることを含む、非一時的コンピュータ読取可能記憶媒体。

【請求項17】

請求項14に係る非一時的コンピュータ読取可能記憶媒体であって、前記ルーティング動作が、完了最終期限が前記ローカルコンピュータクラスタの容量からみた完了時期よりも長い非バッチタイプの作業負荷については、前記外部コンピュータクラスタヘルーティングすることをさらに含む、非一時的コンピュータ読取可能記憶媒体。

【請求項18】

請求項16に係る非一時的コンピュータ読取可能記憶媒体であって、前記コンピュータープログラムが、実行依頼された前記バッチタイプの作業負荷の前記第1及び前記第2部分をどこヘルーティングするかを、前記プロセッサに調整させるように構成されている、非一時的コンピュータ読取可能記憶媒体。

【発明の詳細な説明】

【背景技術】

【0001】

本発明は、高パフォーマンス演算又はビッグデータ処理システムに関し、かつ負荷をビギー状態の分散コンピューティング環境から、余裕のある環境及び／又は動的に拡張可能

10

20

30

40

50

な環境へ自動送信する方法及びシステムに関する。

【0002】

ジョブスケジュールシステムは、異なるコンピュータ作業負荷を巨大コンピュータ環境に分散可能である。大企業内のコンピュータ環境は、以下の特徴を有する傾向がある：

- ・静的サイズ
 - ・一般的に物理的マシンによって構築
 - ・概略均一な構成
 - ・同じクラスタ内でしっかり接続
 - ・他の部署のクラスタとはゆるく接続
 - ・地理的に別の場所のクラスタとの接続は貧弱
 - ・クラスタどうし間では共有ストレージ部へのアクセスは一般に困難
 - ・あるクラスタは混み別のクラスタは余裕が有るとのホットスポットが出来るのが通例
- 10

【0003】

部署のクラスタの規模及び部署の作業負荷の要求量が変化した場合、他の部署や場所にジョブを流すようにすると魅力的である。しかし、作業負荷はネットワーク及びストレージにより強く制約されやすいから、これら高パフォーマンスコンピュータ、ネットワーク、及びストレージ源の領域間に作業負荷が機能的に跨るようにするには難しい。

【発明の概要】

【0004】

本発明の実施形態は、高パフォーマンスコンピュータ又は「ビッグデータ」又は「マップレデュース」ソフトウェアの開発者が、企業内部及び／又は複数の情報インフラサービス（イアースaaS）クラウド環境どうし間に跨るコンピュータ資源を切れ目無く使用するシステム及び方法を提供するものである。これは、パフォーマンス及び信頼性が不確実なゾーンの中にあって、周知のパフォーマンス特性を有するコンピュータ出力領域をなす、閉じた企業ネットワークの内部又は外部における、コンピュータ群からなる個々のクラスタを処理することによってなされる。このシステムは、データを転送し、作業負荷をあたかもそれが実在して手元で動作しているように遠隔のクラスタに移す。該システムは、バッチ・タイプの高パフォーマンスジョブのために、又は本発明の目的からして等価であるマップレデュースジョブにおける「マップ」処理のために、データを動かし、分離可能なジョブを分割して別のコンピューティング環境へ送り、完了した結果を戻す。以下に述べるすべての、実行依頼されたバッチタイプの作業負荷の一部分は、実行依頼されたマップレデュースタイプの作業負荷におけるマップ部分と等価である。このワークフローの決定動作及び実行は、開発者及びアプリケーションがまったく意識する必要のないプロセスとして行われる。開発者又はアプリケーションが、データ及びジョブを移動させるという煩雑さに見舞われることはない。開発者は、そのアプリケーションを一つの領域で作動させるだけでよく、それを本発明によって自動的に他の領域へ移すという複雑な作業が行われる。

20

30

【0005】

現行のアプローチでは、スケジューリング環境が同じで場所的には分離されたコンピュータ資源を用いて処理しており、かつローカル環境とリモート環境を等しく扱っている。現行アプローチには、本発明がその問題に対する優れた解決手段となるような2つのファクターがある。ファクター1：低レイテンシ及び高周波数帯域との仮定の下で実行する、不確かなWANリンク間の処理は、たいがい失敗する。ファクター2：全世界的に共有されたストレージ装置はパフォーマンス特性が一般的に遅いために、作業負荷内のジョブの進展速度の不足によって失敗に終わる。本発明によれば、これらの落し穴の両方とも避けることによって、確実にジョブがシステム環境間でより早く流れることができ、これらのジョブを実行することで、開発者が1つの地域にある内部クラスタ上で動いていると思うようなスピードと信頼性のある処理を続行することができる。本発明を使用した場合に生じる唯一の追加負担は、データをローカルからリモートのクラスタへ移動させてジョブ実行を補助してもらうことであり、このリモート領域で演算が完了後、データ結果が元

40

50

の領域へ返送される。

【0006】

本発明の実施形態では、詳細なパフォーマンス及び使用データをクラスタから連続的に集め、このデータを用いて、以下のパラメータに基づき、ジョブルーティングに関する決定をする：

セキュリティ、パフォーマンス、及び規制遵守上の問題から、内部環境でジョブをやらせたいというユーザー又は自動ワークロードの要望；

アマゾン・ウェブサービス（AWS）のような、外部のダイナミックなコンピューティング環境における耐ランニングコスト；

リモートクラスタの演算に要求されるデータ群における、すでに同期している部分又は区画の存在；

すべてのコンピューター分野にわたるすべてのコンピュータ資源の利用現況；

往復伝送される必要があるデータの量に関する情報で結び付き得る、データ転送のためのクラスタ間で利用可能な周波数帯域

【0007】

最終的なコンピュータジョブルーティングを決定するのに使われる仲介アルゴリズムは、種々の動特性に応じて設定変更可能である。本発明の実施形態では、実行依頼されているジョブ、及びジョブを実行出来たであろうポテンシャルクラスタに関して有するすべての知識を適用することによって、アプリケーション、開発者、またはエンドユーザの介在無しで、作業負荷のための補助スケジューリングを実行し、適切な領域にジョブを自動的にルーティングする。補助スケジューリングの決定は、実行依頼時又はその後定期的に行われる。そして、決定後直ちにジョブを、内部又は外部の、静的又は動的な特定領域のマシン上での仕事を受け持つスケジューラに送出する。

【0008】

本発明の実施形態では、スケジュールに入れられた複数クラスタ及び複数ジョブが、互いに完全に独立して動くのを許容し、常に必要な十分大きな安定性を与える。機能性環境を保つために低レイテンシ通信が求められることがない。本発明の実施形態では、これらクラスタが、当該アーキテクチャの範囲外でも完全に機能するのを許容し、完全にローカルの作業負荷と、本発明の補助スケジューリング・アルゴリズムを介して他のクラスタから入って来るジョブを混合する。これによって、セキュリティに関して、旧来の相互運用性及び柔軟性が確保される：スケジュールに入れられたジョブが本発明によって実行依頼された場所へ転送されるのが望ましくない場合、エンドユーザは、簡単にジョブを通常通りローカル領域で実行されるよう指示できる。本発明によれば、その補助スケジューリングアルゴリズムによって作業負荷をより多く実行依頼することで、コンピュータ資源の広く分散された共用部の使用率をも高め、全体的な利用度が多くなる。

【図面の簡単な説明】

【0009】

図1は、エンドユーザ、又はサイクル・サーバーのようなジョブ実行依頼ポータルによるジョブ実行依頼プロセスを示すブロック図である。

【0010】

図2は、SubmitOnceのルーティング・エンジン及び決定を操作可能な変数を示すプロック図である。

【0011】

図3は、リモートへの、データ転送及びスケジューラ・インタラクションを含むジョブ実行依頼のワークフローを示すブロック図である。

【0012】

図4は、リモートのクラスタへの実行依頼時、部分的に余裕がある内部クラスタへ作業を戻す処理を示すブロック図である。

【0013】

図5は、SubmitOnceの作業負荷のルーティングを示すフローチャートである。

10

20

30

40

50

【 0 0 1 4 】

図6は、SubmitOnceアプリケーションの作業負荷のルーティングの概念構造を示すフローチャートである。

【発明の詳細な説明】**【 0 0 1 5 】**

以下、本発明に係る処理及びシステムの実施形態を説明する。なお、いかなる場合も本開示が以下の実施形態に限定されるものでないことを注記する。下記実施形態は、本発明をここで実行するための非限定的な例示に過ぎない。

【 0 0 1 6 】

実施形態では、スケジューラ・ベースのジョブの実行依頼の動作を正確にまねたクラウド内において作業負荷を実行依頼するためのシステムを備えている。システムは、ジョブ・スケジューラの操作に関する知識を使って、実行依頼されている作業負荷についてできるだけ多くのメタデータを引き出す。 10

【 0 0 1 7 】

他の実施形態は、ジョブルーティングを集中的に決めるための変動可能な数の環境パラメータを決めるスケジューラ監視ソリューションと結合されたジョブルーティング機構を備えている。実施形態では、ジョブルーティングの決定がなされたとき、フレームワークが自動リモートアクセスを使うことで、データの継続伝送、リモートでのコマンド実行、及びジョブ監視を実行する。

【 0 0 1 8 】

実施形態では、異なるスケジューラ、又はマップレデュース、又は「ビッグデータ」のワークフレームを用いて、一組のジョブが、複数の異なる環境上で動くことができ、完了時には、気付かれることなく1つの統合されたエリアとなるアーキテクチャを備えている。実施形態では、クラウド・コンピューティング環境内で作業負荷を実行依頼するためのシステムを更に含む。このシステムは、ジョブ・スケジューラの操作に関する知識を使って、スケジューラ・ベースのジョブの実行依頼の動作を正確にまねる。このシステムは、実行依頼されている作業負荷に対応する有用なメタデータの少なくとも一部を引き出す。 20

【 0 0 1 9 】

この発明の実施形態は、複数のクラスタ環境内で、幾つかの又はすべての実行依頼があったことを周期的に確認する手段を使って、ジョブルーティングをリアルタイムに決定するための変動可能な個数の環境パラメータを決めるスケジューラ監視ソリューションと結合されたジョブルーティング機構を備えている。さらに他の実施形態は、ジョブルーティングの決定がなされたとき、データの継続伝送、リモートでのコマンド実行、及びジョブ監視を実行するための自動リモートアクセスを使うためのフレームワークを含む。更なる実施形態では、一組のジョブが、複数の異なる環境上で動くことができ、完了時には、気付かれることなく1つの統合されたエリアとなるアーキテクチャを備えている。ある実施形態では、分散コンピューティング環境どうし間で作業負荷を指定する方法を含む。前記方法は、複数のコンピュータクラスタの各々からパフォーマンス及び使用データを連続的に得ることを含み、前記複数のコンピュータクラスタの第1サブセットは第1領域に在り、前記複数のコンピュータクラスタの第2サブセットは第2領域に在り、各領域は、公知のパフォーマンス特性、パフォーマンスゾーン、及び信頼性ゾーンを有している。前記方法は、分散コンピューティング環境ヘルーティングするためのジョブを受け取ることを更に含む。前記方法は、得られたパフォーマンス及び使用データに応じて、ジョブを所定のコンピュータクラスタヘルーティングすることを更に含み、前記領域は、前記所定のコンピュータクラスタを包含する。 30

【 0 0 2 0 】

更なる実施形態は、分散コンピューティング環境どうし間で作業負荷を指定する方法を含む。前記方法は、電子的に実行依頼された作業負荷についての完了最終期限及びバッチ/非バッチ・タイプを確認することを含む。前記方法は、次のうち少なくとも1つによつて実行依頼された作業負荷を処理することを更に含む；(i) 完了最終期限までに処理を 40

10

20

30

40

50

完了するのに充分な容量を有するローカルコンピュータクラスタに応じて、実行依頼された作業負荷をローカルコンピュータクラスタヘルーティングすること；(i i) 実行依頼されたバッチ・タイプの作業負荷の第1部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップ部の部分を有効容量のローカルコンピュータクラスタヘルーティングすること、及び、実行依頼されたバッチ・タイプの作業負荷の第2部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップ部の第2部分を少なくとも1つのリモートコンピュータクラスタヘルーティングすること；及び(i i i) ローカルコンピュータクラスタの容量からみた完了時期よりも長い完了最終期限を有する非バッチタイプの実行依頼された作業負荷をリモートコンピュータクラスタヘルーティングすること。明確さのために、「マップレデュース」作業負荷は、バッチタイプの作業負荷であり、マップ部分及び個々のレデュースジョブを構成要素とする。同様に、いわゆる「はっきりしない」又は「はっきりとした」並列な作業負荷は、要するに、どんな作業負荷でも、多くの独立した演算を含んでいれば、たとえ個々が厳密に並列でなくても、バッチタイプの作業負荷である。

【0021】

他の実施形態は、分散コンピューティング環境どうし間で作業負荷を指示する方法を含む。前記方法は、アプリケーション作業負荷ルータで作業負荷の実行依頼を受け取ることを含む。前記方法は、以下のうち少なくとも1つの工程によって作業負荷の実行依頼をルーティングすることを更に含む。(i) 実行依頼された作業負荷の第1部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップ部の部分を、ローカルコンピュータクラスタヘルーティングし、実行依頼された作業負荷の前記第1部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップ部の前記第2部分は、ローカルコンピュータクラスタの有効満了パラメータ内にあり、実行依頼された作業負荷の第2部分をリモート(非ローカル)のコンピュータクラスタヘルーティングすること、及び(i i) ローカルコンピュータクラスタが無い場合、リモートコンピュータクラスタへ作業負荷の実行依頼をルーティングすること。

【0022】

本実施方法は、さらにワークフロー自動修正工程を含むことができる。この工程は、1又はそれ以上のリモート(非ローカル)コンピュータヘルーティングされた作業負荷の実行依頼に関連するデータのための、出力データ転送とその後の入力データ転送を含む。

【0023】

前記ジョブ実行依頼コマンド-ライン/A P I /ウェブページ/ウェブサービスは、ブロック106の環境情報、ブロック108のルーティング/実行依頼の試行から導き出された変数、及びブロック104のユーザー入力メタデータに蓄積する。ブロック112に在るサーバー環境が、利用できないか、応答が長くかかり過ぎる場合には、実行可能なジョブ実行依頼は、ブロック110の通り、常にローカルで前記実行依頼を実行する。このように、ジョブ実行依頼は、常に所定の時間間隔内で発生する。

【0024】

タスクが複数のクラスタ上で動作する場合には、出力は、そのシステムで定義されたクラスタ名によって示される接頭辞を用いたワークフローによって区別される。ジョブ実行依頼の出力は、生成場所のスケジューラ・コマンドによって作られた出力と同一でなければならない。このように、ユーザー、作業負荷、又はA P Iは、当該システムを活用することで、意識することなく当該システムと互いに連携することができる。前記出力は、ブロック114に在る一般的な処理中にサーバー環境によって返信される。

【0025】

図2は、本発明の他の実施形態を示す。図2においては、SubmitOnceのルーティング・エンジン、及び決定手順を操作可能な変数を表すブロック図が示されている。

【0026】

図2において、本システムの処理及び構成要素は、ブロック202で受け取られるジョブルーティング及び実行依頼動作を構成して管理してモニターするのに使用されるサーバ

10

20

30

40

50

一・アーキテクチャ内の G U I ダッシュボードを含む。当然に、前記システムを特定の方針及び予想に適合させために管理者によって使用することのできる初期環境設定の実行依頼をも含む。ブロック 204 では、利用可能な共有記憶場所、広告アプリケーション、現在の容量、予約超過閾値、及び動的実行ノード能力等（ただしこれらに限定されない）のスケジューリング環境のために定義可能なメタデータを取り込むことができる。前記メタデータは、環境設定中、及び / 又はブロック 212 に示すようにモニタリング環境によってリアルタイムに引き出されている時、入力可能である。ブロック 206、208、及び 210 に示すように、ジョブをローカルに送信することも、それが最も好都合であれば、選択可能である。ブロック 212 のように、ローカルルーティングがすぐに明らかにならない場合に、完全な仲介ルーチンに入る。ブロック 214 において、どんなクラスタ単位が選択されたとしても、最終的には実際の実行依頼プロセスのためにルーティングが決定される。

【 0027 】

図 3 は、本発明における他の実施形態を示す。図 3 は、データ転送及びスケジューラ・インタラクションを含むリモートジョブの実行依頼のワークフローを表したブロック図を示す。

【 0028 】

図 3 の実施形態におけるプロセス及び構成要素は、中央サーバがブロック 302 に在る 1 又はそれ以上のクラスタ単位と通信するハブ・アンド・スポークデザインを含む。実行依頼時のカギとなる決定事項は、ルーティングがローカルであるかリモートであるかである。なぜなら、それによって、データをブロック 304 とブロック 308 のどちらへ移動させる必要があるかが決まるからである。クラスタ単位は、コンピュータ資源における静的に割当られたか又は動的に割当られたリストで、マシンの内部クラスタとマシンの外部クラスタの両方を表し得る点に留意する必要がある。図 3 は、ブロック (310, 316) 及び (312, 314) において用いられているようにスケジュールベース又はオンデマンドベースで、内部に潜在するデータ及び外部に潜在するデータの両方を転送可能なチケット・ベースのデータ転送メカニズムを必要とする。このプロセスでも、ブロック (306, 318) のステップのためのコマンド実行のために、中央サーバとリモートノード間の安全な信頼できる通信を必要とする。また、委託されたジョブ実行依頼の前、指示中、又は指示後の何らかの潜在的不具合に対し適切にエラー処理する必要はある。エラーに遭遇したときは、前記システムは、ブロック 306 のように、フェイルセーフとして、ローカルでの実行を指示すべきある。

【 0029 】

図 4 は、本発明のさらに他の実施形態を示す。図 4 のブロック図は、リモートクラスタへ実行依頼するときは、部分的に余裕がある内部クラスタへ作業を戻すプロセスを表している。

【 0030 】

この実施形態のプロセス及び構成要素は、ジョブ実行依頼が特定のクラスタ単位に委託されるとき始まり、更なるロード・バランシングの機会がある。大半の作業負荷はリモートのクラスタ単位に指定されるが、作業負荷の部分集合を、すぐに利用できるローカル資源で動作させるために切り出してよい。そうすると、ブロック 402 のように全体のランタイムが減少する。この動作部分は、以下に該当する場合に採用される：(1) 実行依頼がきつく連結された並列ジョブではない (2) 実行依頼が、一列のジョブである (3) タスク列の分割作業は、システム内で行うことが出来る。前記システムは、利用可能な実行スロット数を数え、実行中のジョブを数え、ブロック 404 で利用可能なスロットを計算する。ブロック 406 では、ローカルのクラスタが先ず一杯になるように、ジョブ列が分割され、ジョブの残りは、ブロック 408 において、選択されたリモートのクラスタへ実行依頼される。これら二つ以上の実行依頼によって、ブロック 406 及びブロック 408 の処理が進められる、前述したように、ワークフローが進行する。

【 0031 】

10

20

30

40

50

図5は、本発明の他の実施形態を示す。図5は、SubmitOnceのワークフロールーティングのフローチャートを表す。ブロック502において、ユーザー／アプリケーションがジョブを実行依頼することで前記処理が開始する。ブロック504において、ジョブが「完了」最終期限を有するか判定する処理へ続く。「完了」最終期限が無ければ、ブロック506において、クラスタの空きは十分かどうかを判定する処理を行なう。イエスであれば、ブロック510において、ローカルクラスタヘルーティングする処理をする。ノーであれば、ブロック512において、バッチジョブかを判定する。イエスであれば、ブロック514において、ローカルの入り口を塞ぎ、外部ヘルーティングする。ノーであれば、ブロック516において、単に外部ヘルーティングする。一方、「完了」最終期限が有る場合、ブロック508において、ローカルへ行く時間は十分かどうかを判定する。イエスであれば、ブロック510において、ローカルクラスタヘルーティングされる。ノーであれば、ブロック512において、バッチジョブかどうかを判定し、その後、前述した処理へ続く。

【0032】

図6は、本発明の一実施形態を示す。図6は、SubmitOnceアプリケーションの作業負荷をルーティングするアーキテクチャを図示したものである。前記ルーティングアーキテクチャは、ブロック602において、ユーザー又はアプリケーションによるジョブの実行依頼から始まる。ブロック604において、アプリケーション・ワーカロード・ルータがジョブを受け取る。ローカル環境のクラスタが無ければ、ブロック608において、ジョブは、内部／外部のクラウドへ送られる。ローカルへのルーティングが可能であれば、ジョブがブロック606へ送られる。一方、必要ならば、ブロック608において、ジョブは、ローカルのクラスタから必要に応じてクラウドへ拡張できる。

【0033】

本発明の開示を実行する実施方法は、作業負荷を管理する方法を含む。前記方法は、プロセッサが、ルーティングのための作業負荷を受け取ること；並びに前記プロセッサが、ローカルコンピュータクラスタ及び外部コンピュータクラスタから連続的に取得したリアルタイムのパフォーマンス及び使用データに基づいて作業負荷をどこヘルーティングするかを決定し、それに応じて前記作業負荷をルーティングすることを備えている。前記方法は、受け取った作業負荷に関する完了最終期限、及びバッチ／非バッチ・タイプを確認することを更に含む。

【0034】

前記実施方法は、前記ルーティング工程が、完了最終期限までに作業負荷を完了するのに十分な容量を有するローカルコンピュータクラスタについての前記連続的に取得したリアルタイムのパフォーマンス及び使用データに応じて、前記ローカルコンピュータクラスタヘルーティングすることを、更に含む。前記方法は、前記ルーティング工程が、実行依頼されたバッチタイプの作業負荷の第1部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップ部をローカルコンピュータクラスタへ、かつバッチタイプの実行依頼作業負荷の第2部分、又は等価的にはマップレデュースタイプの実行依頼された作業負荷のマップの第2部分を、少なくとも1つの外部コンピュータクラスタヘルーティングすること、をも含む。

【0035】

前記実施方法は、前記ルーティング工程が、完了最終期限がローカルコンピュータクラスタの容量からみた完了時期よりも長い非バッチタイプの作業負荷については、外部のコンピュータ作業負荷へ送信することをも含む。前記方法は、実行依頼されたバッチタイプの作業負荷の前記第1及び第2部分をどこヘルーティングするかを、前記プロセッサによって調整すること、を更に含むことができる。

【0036】

前記実施方法は、結果的に、非一時的コンピュータ読取可能記憶媒体、例えば非一時的コンピュータ読取可能メモリに格納されたコンピュータープログラムを実行することであつてもよく、電子装置の構成要素によって前記電子装置を動作させるある特別な方法を実

10

20

30

40

50

行することであってもよい。前記実施方法は、コンピュータープログラム付きの1つの記憶部、及び1つのプロセッサを含む装置によって実行することであってもよい。前記コンピュータープログラム付きの前記記憶部は、前記装置が前記プロセッサによって前記実施方法を実行するように構成されている。

【0037】

まとめると、本発明の種々の実施形態は、プロセッサと記憶部を含むコンピュータのような種々の電子装置によって実行できる。

【0038】

大規模コンピュータ環境のユーザは、多くの別のコンピュータ環境を利用する能力を必要とする。その根っ子にあるスケジューラ、サーバ、ネットワークの構成については完全に理解する必要はない。

10

【0039】

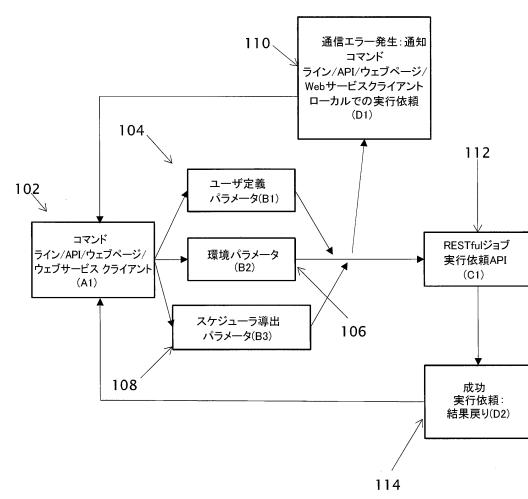
本発明開示手段は、ローカル及び外部のクラスタへジョブを自動送信している間、エンドユーザが典型的なジョブを実行依頼できるインターフェースを提供することを含む。これによって、複雑な構成及びプロセスによる負担をかけることなく、エンドユーザが出来る事が増える。アプリケーション・ワークロード・ルータ内の自動化によって、エンドユーザに過剰な複雑さを隠したまま、通常は1つの独立したクラスタに束縛されるはずの可能範囲を増やせる。

【0040】

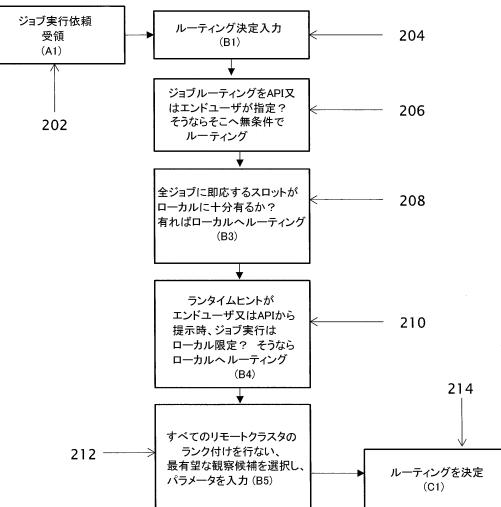
ひとたびこの自動ジョブルーティング環境が完全に構成されたときは、エンドユーザは、適切なルーティングのための自らの作業負荷をすべて記述する方法を必要とする。この記述の大部分は、スケジューリングレイヤを使ってなされる。エンドユーザにとって最も重要なパラメータは、実行信頼性を除くと、すべての作業負荷のための経過時間である。本発明開示内容によって、エンドユーザから更に2つの重要な情報の提供を受けられるジョブルーティング環境を実現できる。1つは、個々のタスクの平均実行時間である。もう1つは、作業負荷の全体的な所望実行時間である。この情報は、タスクの数、動的VMノードのスピンドル時間、データ転送時間、及びその作業負荷が全てのバッチなのか否か等の、既知のパラメータに沿って考慮される。この結果、ジョブを、複数のクラスタにわたるように分割でき、要求が満たされる間、内部クラスタを最大使用できる。

20

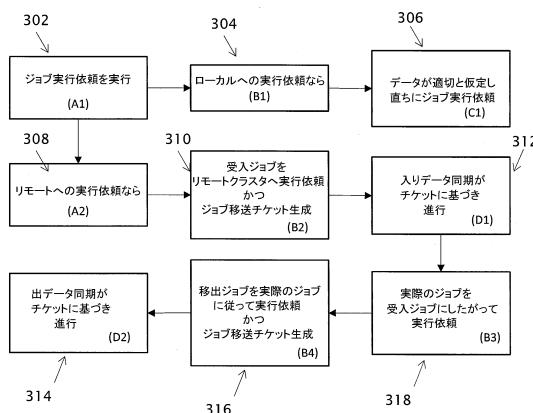
【図1】



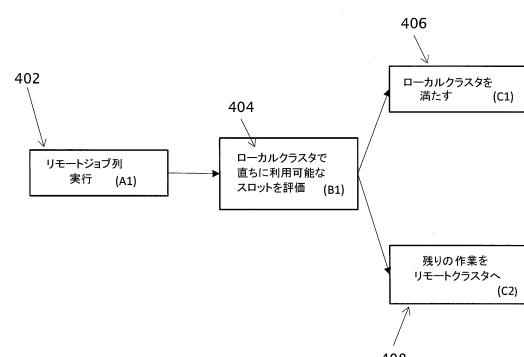
【図2】



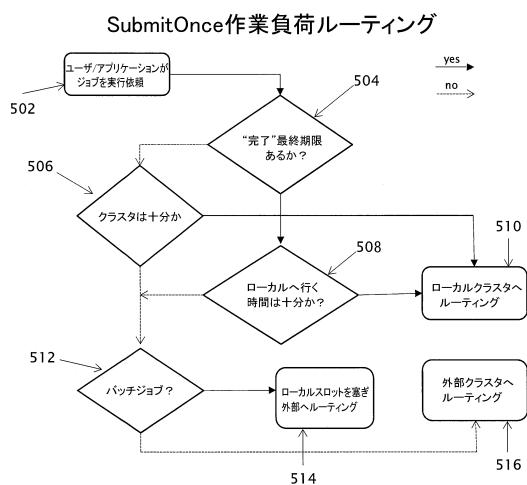
【図3】



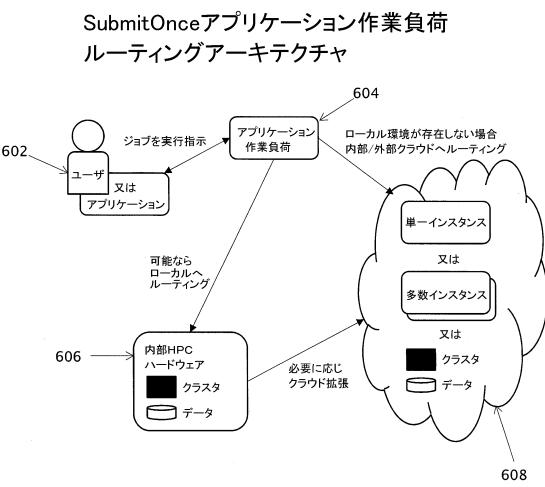
【図4】



【図5】



【図6】



フロントページの続き

(74)代理人 100162846

弁理士 大牧 綾子

(72)発明者 ストウ, ジェイソン, エー.

アメリカ合衆国 06830 コネティカット州, グリニッジ, 107番, グレン ストリート 5

(72)発明者 カクゾレック, アンドリュー

アメリカ合衆国 46032 インディアナ州, カーメル, グリーブ ストリート 2347

審査官 原 忠

(56)参考文献 米国特許出願公開第2012/0054771(US, A1)

特表2012-523038(JP, A)

特開2002-259353(JP, A)

特開2002-342098(JP, A)

米国特許出願公開第2008/0052712(US, A1)

米国特許出願公開第2004/0199918(US, A1)

(58)調査した分野(Int.Cl., DB名)

G06F 9/46 - 9/54