

(19) 日本国特許庁 (JP)

(12) 特 許 公 報 (B2)

(11) 特許番号

特許第6248523号
(P6248523)

(45) 発行日 平成29年12月20日 (2017.12.20)

(24) 登録日 平成29年12月1日 (2017.12.1)

(51) Int.Cl. F I
G O 6 F 9/50 (2006.01) G O 6 F 9/46 4 6 5 Z

請求項の数 8 (全 34 頁)

(21) 出願番号	特願2013-209824 (P2013-209824)	(73) 特許権者	000005223
(22) 出願日	平成25年10月7日 (2013.10.7)		富士通株式会社
(65) 公開番号	特開2015-75803 (P2015-75803A)		神奈川県川崎市中原区上小田中4丁目1番1号
(43) 公開日	平成27年4月20日 (2015.4.20)	(74) 代理人	100092152
審査請求日	平成28年6月6日 (2016.6.6)		弁理士 服部 毅巖
		(72) 発明者	今村 信貴
			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	漆原 孝治

最終頁に続く

(54) 【発明の名称】 データ処理管理方法、情報処理装置およびデータ処理管理プログラム

(57) 【特許請求の範囲】

【請求項1】

第1のコンピュータおよび第2のコンピュータを有するシステムのデータ処理管理方法において、

前記第1のコンピュータが、

一連のイベントを示すパターンであって記憶部に記憶された前記パターンに対応する処理を、前記第1のコンピュータにより受信した到着済イベントに応じて実行し、前記到着済イベントの情報を前記記憶部に記録し、

前記処理の割当てを前記第2のコンピュータに変更する指示を受信し、

前記処理に対する前記到着済イベントを示す進捗情報の送信準備中に、前記パターンに属する第1のイベントを受信し、

前記進捗情報および前記第1のイベントを含む送信データを生成し、

前記進捗情報に代えて、前記送信データを前記第2のコンピュータに送信する、

データ処理管理方法。

【請求項2】

前記第2のコンピュータが、前記送信データが到着する前に前記処理に対応付けられた第2のイベントを受信すると、前記第2のイベントを保持する、請求項1記載のデータ処理管理方法。

【請求項3】

前記第2のコンピュータが、前記送信データを受信した際に、前記第2のイベントより

10

20

も前に発生し前記処理に対応付けられているが前記第2のコンピュータに未到着である第3のイベントがあっても、前記進捗情報および前記第2のイベントを用いて前記処理を実行する、請求項2記載のデータ処理管理方法。

【請求項4】

前記第2のコンピュータが、前記送信データを受信すると、前記進捗情報および前記第1のイベントを用いて前記処理を実行し、その後、前記第2のイベントを用いて前記処理を実行する、請求項2または3記載のデータ処理管理方法。

【請求項5】

前記第1のコンピュータが、前記進捗情報と前記第1のイベントとを連続して送信する、請求項1乃至4の何れか1項に記載のデータ処理管理方法。

10

【請求項6】

前記第1のコンピュータが、前記指示を受信すると前記処理の実行を停止し、前記第2のコンピュータが、前記進捗情報および前記第1のイベントを用いて前記処理を再開する、請求項1乃至5の何れか1項に記載のデータ処理管理方法。

【請求項7】

自装置で実行される処理に対応する一連のイベントのパターンを記憶する記憶部と、前記パターンに対応する前記処理を、受信した到着済イベントに応じて実行し、前記到着済イベントの情報を前記記憶部に記録し、前記処理の割当てを他の情報処理装置に変更する指示を受信し、前記処理に対する前記到着済イベントを示す進捗情報の送信準備中に、前記パターンに属する第1のイベントを受信し、前記進捗情報および前記第1のイベントを含む送信データを生成し、前記進捗情報に代えて、前記送信データを前記他の情報処理装置に送信する、演算部と、

20

を有する情報処理装置。

【請求項8】

コンピュータに、一連のイベントを示すパターンであって記憶部に記憶された前記パターンに対応する処理を、前記コンピュータにより受信した到着済イベントに応じて実行し、前記到着済イベントの情報を前記記憶部に記録し、前記処理の割当てを他のコンピュータに変更する指示を受信し、前記処理に対する前記到着済イベントを示す進捗情報の送信準備中に、前記パターンに属する第1のイベントを受信し、前記進捗情報および前記第1のイベントを含む送信データを生成し、前記進捗情報に代えて、前記送信データを前記他のコンピュータに送信する、処理を実行させるデータ処理管理プログラム。

30

【発明の詳細な説明】

【技術分野】

【0001】

本発明はデータ処理管理方法、情報処理装置およびデータ処理管理プログラムに関する。

40

【背景技術】

【0002】

複数のマシンを含む分散処理システムを用いてデータ処理を行うことがある。マシンには、物理的なコンピュータ（物理マシンや物理ホストということがある）や物理マシン上で動作する仮想的なコンピュータ（仮想マシンや論理ホストということがある）が含まれ得る。例えば、分散処理システムを用いて複合イベント処理（CEP：Complex Event Processing）を行うことがある。種々の装置により発行された複数のイベントを複数のマシンで並列に処理することで、複数のイベントを高速に処理し得る。

50

【0003】

分散処理システムでは、マシン毎の処理の割当てを変更することでマシン毎の負荷の平準化を図ることがある。そこで、処理の割当て変更を行う種々の方法が考えられている。例えば、第1の計算機で実行中のプロセスを第2の計算機に移動させる際に、複製した当該プロセスを第2の計算機に送信しながら、第1の計算機で当該プロセスの実行を継続することで、プロセス移動中のプロセス停止時間を短く抑える提案がある。

【0004】

また、自プロセッサで動作しているタスクを他のプロセッサに移動させる際、当該タスクを移動先に送り出す送り出しタスクを実行し、送り出す最中に移動対象タスクに対する割り込み要求が発生すると、送り出しタスクにより割り込み処理を起動する提案もある。

10

【0005】

更に、処理負荷が所定値を超える仮想マシンが検出された場合、複合イベント処理の関連度に基づいて、仮想マシンそれぞれに複合イベント処理を分散させる提案もある。

【先行技術文献】

【特許文献】

【0006】

【特許文献1】特開2004-78465号公報

【特許文献2】特開2010-272076号公報

【特許文献3】特開2012-79242号公報

【発明の概要】

20

【発明が解決しようとする課題】

【0007】

データ処理の割当てを変更する際に、変更前の処理経過を変更後も引き継ぎたいことがある。例えば、複数のイベントに対する処理を行う場合に、そのうち一部のイベントが発生済なら、一部のイベントの発生済の状態を割当て変更後も維持したいことがある。そこで、割当て変更前の第1のマシンから割当て変更後の第2のマシンに処理の進捗を提供し、第2のマシンに処理を途中から引き継がせることが考えられる。ところが、第1のマシンから第2のマシンへの進捗情報の送信中にも、割当て変更対象の処理に用いられるデータが第1のマシンに入力されることがある。このとき、当該データの扱いが問題となる。

【0008】

30

例えば、上記提案のように、入力されたデータを第1のマシン側で継続して処理することが考えられる。しかし、当該データが第1のマシンに到着し続けると第1のマシンで処理を終えられなくなり、第2のマシンに当該処理を開始させるまでに時間がかかり得る。一方、第1のマシンで当該処理を中断し、進捗情報の送信完了後に、第1のマシンに入力されたデータを第2のマシンに送信し、処理を再開させることも考えられる。しかし、進捗情報の送信完了を待ち、更に当該データを次に送信できるタイミングまで待っていると、第2のマシンへの当該データの到着が遅れ、第2のマシンでの処理再開が遅延し得る。

【0009】

1つの側面では、本発明は、割当て変更先での処理開始までの遅延を短縮できるデータ処理管理方法、情報処理装置およびデータ処理管理プログラムを提供することを目的とする。

40

【課題を解決するための手段】

【0010】

1つの態様では、第1のコンピュータおよび第2のコンピュータを有するシステムのデータ処理管理方法が提供される。このデータ処理管理方法では、第1のコンピュータが、一連のイベントを示すパターンであって記憶部に記憶されたパターンに対応する処理を、第1のコンピュータにより受信した到着済イベントに応じて実行し、到着済イベントの情報を記憶部に記録し、処理の割当てを第2のコンピュータに変更する指示を受信し、処理に対する到着済イベントを示す進捗情報の送信準備中に、パターンに属する第1のイベントを受信し、進捗情報および第1のイベントを含む送信データを生成し、進捗情報に代え

50

て、送信データを第2のコンピュータに送信する。

【0011】

また、1つの態様では、情報処理装置が提供される。この情報処理装置は、記憶部と演算部とを有する。記憶部は、自装置で実行される処理に対応する一連のイベントのパターンを記憶する。演算部は、パターンに対応する処理を、受信した到着済イベントに応じて実行し、到着済イベントの情報を記憶部に記録し、処理の割当てを他の情報処理装置に変更する指示を受信し、処理に対する到着済イベントを示す進捗情報の送信準備中に、パターンに属する第1のイベントを受信し、進捗情報および第1のイベントを含む送信データを生成し、進捗情報に代えて、送信データを他の情報処理装置に送信する。

【0012】

また、1つの態様では、データ処理管理プログラムが提供される。このデータ処理管理プログラムは、コンピュータに、一連のイベントを示すパターンであって記憶部に記憶されたパターンに対応する処理を、コンピュータにより受信した到着済イベントに応じて実行し、到着済イベントの情報を記憶部に記録し、処理の割当てを他のコンピュータに変更する指示を受信し、処理に対する到着済イベントを示す進捗情報の送信準備中に、パターンに属する第1のイベントを受信し、進捗情報および第1のイベントを含む送信データを生成し、進捗情報に代えて、送信データを他のコンピュータに送信する、処理を実行させる。

【発明の効果】

【0013】

1つの側面では、割当て変更先での処理開始までの遅延を短縮できる。

【図面の簡単な説明】

【0014】

【図1】第1の実施の形態の分散処理システムを示す図である。

【図2】第2の実施の形態の分散処理システムを示す図である。

【図3】ノードのハードウェア例を示す図である。

【図4】クエリの割当て変更例を示す図である。

【図5】分散処理システムのソフトウェア例を示す図である。

【図6】分散処理システムのソフトウェア例（続き）を示す図である。

【図7】イベントの例を示す図である。

【図8】クエリの例を示す図である。

【図9】クエリ状態の例を示す図である。

【図10】配置表の例（その1）を示す図である。

【図11】配置表の例（その2）を示す図である。

【図12】配置表の例（その3）を示す図である。

【図13】送信データ管理構造体の例を示す図である。

【図14】送信リストの例を示す図である。

【図15】クエリ状態送信管理の例を示すフローチャートである。

【図16】イベント受信管理（変更元）の例を示すフローチャートである。

【図17】クエリ状態受信管理の例を示すフローチャートである。

【図18】イベント受信管理（変更先）の例を示すフローチャートである。

【図19】イベント送信管理の例を示すフローチャートである。

【図20】クエリ状態の送信例（その1）を示す図である。

【図21】クエリ状態の送信例（その2）を示す図である。

【図22】クエリ割当て変更の例（その1）を示すシーケンス図である。

【図23】クエリ割当て変更の比較例（その1）を示すシーケンス図である。

【図24】クエリ割当て変更の例（その2）を示すシーケンス図である。

【図25】クエリ割当て変更の比較例（その2）を示すシーケンス図である。

【図26】分散処理システムの他の例を示す図である。

【発明を実施するための形態】

10

20

30

40

50

【0015】

以下、本実施の形態を図面を参照して説明する。

[第1の実施の形態]

図1は、第1の実施の形態の分散処理システムを示す図である。第1の実施の形態の分散処理システムはマシン1, 2を含む複数のマシンを有する。複数のマシンはネットワークに接続され、相互に通信可能である。この分散処理システムでは、複数の処理を複数のマシンにより分散して実行する。

【0016】

ここで、第1の実施の形態ではマシン1, 2として物理マシンを想定する。ただし、マシン1, 2は仮想マシンでもよい。例えば、マシン1, 2は異なる物理マシン上で動作する仮想マシンでもよいし、1台の物理マシン（記憶装置や演算処理を行う装置などを備えたコンピュータシステム）上で動作する仮想マシンでもよい。

10

【0017】

マシン1は、記憶部1aおよび演算部1bを有する。マシン2は、記憶部2aおよび演算部2bを有する。記憶部1a, 2aは、RAM (Random Access Memory) などの揮発性記憶装置でもよいし、HDD (Hard Disk Drive) やフラッシュメモリなどの不揮発性記憶装置でもよい。演算部1b, 2bは、CPU (Central Processing Unit)、DSP (Digital Signal Processor)、ASIC (Application Specific Integrated Circuit)、FPGA (Field Programmable Gate Array) などを含み得る。演算部1b, 2bはプログラムを実行するプロセッサであってもよい。ここでいう「プロセッサ」には、複数のプロセッサの集合（マルチプロセッサ）も含まれ得る。

20

【0018】

記憶部1aは、マシン1に割当てられた処理毎の進捗情報を記憶する。進捗情報3は、そのうちのある処理の進捗情報である。例えば、第1の実施の形態の分散処理システムが、複数の入力データに対して所定の処理を実行するシステムなら、記憶部1aは、複数の入力データのうち一部が到着済であることを進捗情報3として記憶する。一例として、CEPを実行するシステムが考えられる。その場合、記憶部1aは、一連のイベントのうちの一部のイベントが到着済であることを進捗情報3として記憶することが考えられる。

【0019】

演算部1bは、マシン1に割当てられた複数の処理を実行する。演算部1bは、各処理の実行状況を進捗情報として記録し、記憶部1aに格納する。例えば、演算部1bは、複数の入力データに対して当該処理を実行する。例えば、演算部1bは、複数の入力データの何れかを受信するたびに、当該入力データが到着済である（当該入力データを処理済である）ことを進捗情報3に記録してもよい。

30

【0020】

演算部1bは、マシン1で実行される処理の割当てをマシン2に変更する指示（変更指示4）を受信すると、当該指示で指定された処理に対応する進捗情報3をマシン2に送信する。例えば、演算部1bは、処理の割当てを管理する所定の装置から変更指示4を受け付けてもよい。あるいは、演算部1bは、マシン1に接続された所定の入力デバイスを用いたユーザの操作入力により、変更指示4を受け付けてもよい。

40

【0021】

ここで、各処理を実行するためのプログラムは、例えば記憶部1a, 2aに予め格納される。例えば、演算部1b, 2bは、ある処理が自身に割当てられた際に、HDDなどに格納された当該処理に対応するプログラムをRAMに格納し、実行することで、当該処理をデータ入力待ちの状態とすることができる。

【0022】

演算部1bは、割当て変更対象の処理の進捗情報3をマシン2に送信中に、当該処理に用いられるデータ5を受信すると、進捗情報3にデータ5を追加してマシン2に送信する。情報の送信中の期間は、ネットワーク上へ当該情報を送出するための準備（送信準備）期間を含む。例えば、準備期間はシリアライズやバッファリングなどに要する期間を含む

50

。シリアルライズは、進捗情報 3 をネットワークの転送形式に変換する処理である。バッファリングは、送信する情報を所定量まで蓄積する処理である。マシン 1 からマシン 2 へ進捗情報 3 を送信中の間、進捗情報 3 に対応する処理の実行は中断される。

【0023】

例えば、演算部 1 b は、変更指示 4 を受信すると、記憶部 1 a に記憶された進捗情報 3 のシリアルライズやバッファリングを行い、進捗情報 3 を含む送信データを生成する。演算部 1 b は、当該送信データの生成中にデータ 5 を受信すると、当該送信データにデータ 5 を含めた送信データ 6 を生成する。送信データ 6 には、進捗情報 3 およびデータ 5 以外の情報が含まれてもよい。演算部 1 b は、送信データ 6 をマシン 2 に送信する。

【0024】

マシン 2 は、送信データ 6 を受信すると、送信データ 6 から進捗情報 3 およびデータ 5 を取得する。マシン 2 は、進捗情報 3 およびデータ 5 を用いて、マシン 1 からマシン 2 に割当て変更された処理を再開する。

【0025】

第 1 の実施の形態の分散処理システムによれば、マシン 1 により、マシン 1 で実行される処理の割当てをマシン 2 に変更する変更指示 4 が受信される（ステップ S 1）。マシン 1 により、当該処理の進捗情報 3 のマシン 2 への送信中に、当該処理に用いられるデータ 5 が受信される（ステップ S 2）。すると、マシン 1 により、進捗情報 3 にデータ 5 が追加されてマシン 2 に送信される（ステップ S 3）。

【0026】

これにより、割当て変更先（上記の例ではマシン 2）での処理開始までの遅延を短縮できる。ここで、例えば、進捗情報 3 の送信中、割当て変更対象の処理をマシン 1 で継続することも考えられる。しかし、当該処理に対してデータ 5 を含む複数のデータがマシン 1 に入力され続けることがある。すると、マシン 1 での処理を終えられなくなり、マシン 2 への当該処理の割当て変更が完了するまでに時間がかかる。また、マシン 1 が高負荷であるために処理の割当て変更を行いたいにも関わらず、マシン 1 が高負荷である状況が継続してしまう。しかも、マシン 1 の負荷が高い程、このような状況が発生する可能性は高い。更に、マシン 1 で処理が行われると、進捗情報 3 にも更新による差分が生じる。このため、マシン 1 は、マシン 2 への進捗情報 3 の差分の提供も継続することになり、ネットワーク帯域を消費してしまうという問題もある。

【0027】

一方、マシン 1 による割当て変更対象の処理を中断し、進捗情報 3 の送信完了後にデータ 5 をマシン 2 に送信して、マシン 2 により当該処理を再開させることも考えられる。しかし、情報の送信にはシリアルライズやバッファリングなどの送信側での処理や、デシリアルライズなどの受信側での処理を要し、時間がかかる。このため、進捗情報 3 の送信完了を待ち、更にデータ 5 を次に送信できるタイミングまで待っていると、マシン 2 へのデータ 5 の到着が遅れ、マシン 2 での処理再開が遅延し得る。

【0028】

そこで、マシン 1 は、割当て変更対象の処理の進捗情報 3 のマシン 2 への送信中に、当該処理に用いられるデータ 5 を受信すると、進捗情報 3 にデータ 5 を追加してマシン 2 に送信する。例えば、マシン 1 へデータ 5 を含む複数のデータが継続的にマシン 1 に入力されても、進捗情報 3 とともに各データ（あるいは、そのうちの一部）をマシン 2 へ提供し得る。マシン 2 は、進捗情報 3 とともにデータ 5 を取得できるので、進捗情報 3 およびデータ 5 を用いて当該処理を迅速に開始できる。また、マシン 1 で当該処理を継続せずに済むので、進捗情報 3 の提供を継続して行わなくてもよい。よって、マシン 1 で処理を継続する場合よりも、マシン 1 の負荷を迅速に低減でき、また、ネットワーク帯域の利用量も低減できる。

【0029】

更に、進捗情報 3 とともにデータ 5 をマシン 2 に提供できるので、進捗情報 3 の送信完了を待機し、更に、次の送信タイミングまでデータ 5 の送信を待機しなくてよい。このた

10

20

30

40

50

め、マシン 2 ヘデータ 5 が到着するまでの時間を短縮化でき、マシン 2 で割当て変更対象の処理を再開するまでの遅延を短縮できる。

【0030】

〔第 2 の実施の形態〕

図 2 は、第 2 の実施の形態の分散処理システムを示す図である。第 2 の実施の形態の分散処理システムは、ノード 100、200、300 および管理ノード 400 を含む。ノード 100、200、300 および管理ノード 400 は、ネットワーク 10 に接続されている。ネットワーク 10 は、例えば LAN (Local Area Network) である。

【0031】

ネットワーク 10 は、ネットワーク 20 に接続されている。ネットワーク 20 は、WAN (Wide Area Network) やインターネットなどの広域ネットワークでもよい。ネットワーク 20 には、スマートシティ 21、物流センサ 22、気象衛星 23、携帯装置 24 およびスマートセンサ 25 が無線または有線で接続されている。ネットワーク 20 には、これらの装置以外にもイベントを発行する各種の装置が接続され得る。第 2 の実施の形態の分散処理システムは、ノード 100、200、300 を用いて CEP を実行する。

【0032】

ノード 100、200、300 は、イベントを処理するサーバコンピュータである。ノード 100、200、300 は、スマートシティ 21、物流センサ 22、気象衛星 23、携帯装置 24 およびスマートセンサ 25 などにより発行された種々のイベントを並列に処理する。ノード 100、200、300 は、複数のイベントの処理結果（新たなイベント）に対する所定の処理を行うこともある。

【0033】

ノード 100、200、300 は、CEP により次のような機能を実現することが考えられる。例えば、ネットワーク 20 に接続されたスマートシティ 21 やスマートセンサ 25 から取得された消費電力の情報を基にして、スマートシティ 21 の省電力化を制御する。また、ネットワーク 20 に接続された各種装置から取得した交通状況の情報を基にして、携帯装置 24 を所持するユーザや車などの状況に合わせた適切なナビゲーションを携帯装置 24 に提供する。また、気象衛星 23 やレーダーなどから取得されたイベントを基にして、天気予報を携帯装置 24 に提供する。更に、家屋への侵入有無の報告、家族（子供やお年寄り）の所在確認の報告などを行う。ノード 100、200、300 は、その他にも種々の情報をユーザに提供し得る。

【0034】

ここで、ノード 100、200、300 により、イベントに応じて実行される処理を以下ではクエリと称する。クエリの内容を記述したプログラムは、ノード 100、200、300 に予め与えられる。当該プログラムを、イベントに応じた処理を記述したルールまたはルール情報ということもできる。また、以下の説明では、ノード 100、200、300 それぞれを指す場合に、各ノードということがある。

【0035】

管理ノード 400 は、各クエリによるイベント処理を、何れのノードに担当させるかの割当て（クエリの割当て）を行うサーバコンピュータである。例えば、管理ノード 400 は、ノード 100、200、300 の負荷を分散する。管理ノード 400 は、ノード 100、200、300 の負荷に応じてクエリの割当てを変更を行うことで、ノード 100、200、300 の負荷の平準化を図る。

【0036】

図 3 は、ノードのハードウェア例を示す図である。ノード 100 は、プロセッサ 101、RAM 102、HDD 103、通信部 104、画像信号処理部 105、入力信号処理部 106、ディスクドライブ 107 および機器接続部 108 を有する。各ユニットがノード 100 のバスに接続されている。ノード 200、300 および管理ノード 400 もノード 100 と同様のユニットを用いて実現できる。

【0037】

10

20

30

40

50

プロセッサ101は、ノード100の情報処理を制御する。プロセッサ101は、マルチプロセッサであってもよい。プロセッサ101は、例えばCPU、DSP、ASICまたはFPGAなどである。プロセッサ101は、CPU、DSP、ASIC、FPGAなどのうちの2以上の要素の組み合わせであってもよい。

【0038】

RAM102は、ノード100の主記憶装置である。RAM102は、プロセッサ101に実行させるOS (Operating System) のプログラムやアプリケーションプログラムの少なくとも一部を一時的に記憶する。また、RAM102は、プロセッサ101による処理に用いる各種データを記憶する。

【0039】

HDD103は、ノード100の補助記憶装置である。HDD103は、内蔵した磁気ディスクに対して、磁氣的にデータの書き込みおよび読み出しを行う。HDD103には、OSのプログラム、アプリケーションプログラム、および各種データが格納される。ノード100は、フラッシュメモリやSSD (Solid State Drive) などの他の種類の補助記憶装置を備えてもよく、複数の補助記憶装置を備えてもよい。

【0040】

通信部104は、ネットワーク10を介して他のコンピュータと通信を行えるインタフェースである。通信部104は、有線インタフェースでもよいし、無線インタフェースでもよい。

【0041】

画像信号処理部105は、プロセッサ101からの命令に従って、ノード100に接続されたディスプレイ11に画像を出力する。ディスプレイ11としては、CRT (Cathode Ray Tube) ディスプレイや液晶ディスプレイなどを用いることができる。

【0042】

入力信号処理部106は、ノード100に接続された入力デバイス12から入力信号を取得し、プロセッサ101に出力する。入力デバイス12としては、例えば、マウスやタッチパネルなどのポインティングデバイス、キーボードなどを用いることができる。

【0043】

ディスクドライブ107は、レーザ光などを利用して、光ディスク13に記録されたプログラムやデータを読み取る駆動装置である。光ディスク13として、例えば、DVD (Digital Versatile Disc)、DVD-RAM、CD-ROM (Compact Disc Read Only Memory)、CD-R (Recordable) / RW (ReWritable) などを使用できる。ディスクドライブ107は、例えば、プロセッサ101からの命令に従って、光ディスク13から読み取ったプログラムやデータをRAM102またはHDD103に格納する。

【0044】

機器接続部108は、ノード100に周辺機器を接続するための通信インタフェースである。例えば、機器接続部108にはメモリ装置14やリーダライタ装置15を接続できる。メモリ装置14は、機器接続部108との通信機能を搭載した記録媒体である。リーダライタ装置15は、メモ리카ード16へのデータの書き込み、またはメモ리카ード16からのデータの読み出しを行う装置である。メモ리카ード16は、カード型の記録媒体である。機器接続部108は、例えば、プロセッサ101からの命令に従って、メモリ装置14またはメモ리카ード16から読み取ったプログラムやデータをRAM102またはHDD103に格納する。

【0045】

図4は、クエリの割当て変更例を示す図である。ノード100は、CEPエンジンE1を有する。ノード200は、CEPエンジンE2を有する。ノード300は、CEPエンジンE3を有する。CEPエンジンE1、E2、E3はCEPを実行する。例えば、CEPエンジンE1、E2、E3は、各ノードが備えるRAMに記憶されたプログラムを各ノードが備えるプロセッサが実行することで実現される。CEPエンジンE1、E2、E3は、各ノードが備える専用のハードウェアで実現されてもよい。

10

20

30

40

50

【0046】

例えば、CEPエンジンE1には、ノード100が担当するクエリに応じたイベントが入力される。CEPエンジンE1は当該クエリの結果として新たなイベントを生成し、出力する。出力されたイベントは、他ノードに送信されたり、ネットワーク20に接続された各種の装置に送信されたりする。これにより、CEPエンジンE1は、他ノードに別のイベント処理を行わせたり、ネットワーク20に接続された装置を制御したりする。CEPエンジンE2、E3もCEPエンジンE1と同様である。

【0047】

ここで、管理ノード400は、ノード100、200、300の負荷を監視する。例えば、ノード200の負荷がノード100よりも高く、ノード300の負荷がノード100よりも低い場合が考えられる。この場合、管理ノード400は、ノード200に割当てられた何れかのクエリをノード300に割当てると決定する。ノード200の負荷を軽減でき、かつ、ノード100、200、300の負荷の平準化を図れるからである。管理ノード400は、ノード300の負荷が比較的高まり、ノード200の負荷が比較的低くなったのであれば、ノード300に割当てられた何れかのクエリをノード200に割当てると決定することもできる。

【0048】

管理ノード400は、決定した割当て変更をノード100、200、300に指示する。ノード100、200、300は当該指示に応じて、クエリの割当て変更を行う。例えば、あるクエリの割当てがノード200からノード300へ変更になった場合、ノード100、200、300は、当該クエリの担当ノードをノード300に更新する。このように、第2の実施の形態では、スケーラブルなシステムを実現し得る。例えば、ノードの追加やノードの削減に対して、クエリの割当てを柔軟化できる。

【0049】

ここで、クエリは、複数のイベントの到着状況に応じた状態（クエリ状態）をもつ。第2の実施の形態では、クエリの割当て変更前後でクエリ状態を維持する。具体的には、割当て変更元のノードは、割当て変更先のノードへ、割当て変更対象のクエリのクエリ状態を提供することで、割当て変更先のノードへクエリの実行を引き継ぐ。ここで、クエリ状態は、第1の実施の形態の進捗情報の一例である。

【0050】

図5は、分散処理システムのソフトウェア例を示す図である。ノード100は、クエリ記憶部110、管理情報記憶部120、クエリ実行管理部130、クエリ状態送信管理部140、クエリ状態受信管理部150、イベント送信管理部160、イベント受信管理部170および通信部180を有する。クエリ記憶部110および管理情報記憶部120は、RAM102やHDD103に確保した記憶領域として実現できる。

【0051】

クエリ実行管理部130、クエリ状態送信管理部140、クエリ状態受信管理部150、イベント送信管理部160、イベント受信管理部170および通信部180は、プロセッサ101が実行するソフトウェアのモジュールとして実現できる。また、各部はCEPエンジンE1の機能の一部でもよい（ノード200、300も同様）。

【0052】

クエリ記憶部110は、クエリおよびクエリ状態を記憶する。クエリ記憶部110は、分散処理システムで用いられる全てのクエリを予め記憶する。また、クエリ記憶部110は、クエリ毎の現在のクエリ状態を記憶する。クエリ記憶部110は、イベントに含まれるストリーム名とそのイベントを処理するクエリの識別情報（クエリ名）との対応関係の情報を予め記憶する。

【0053】

管理情報記憶部120は、配置表および送信リストを記憶する。配置表は、各ノードへのクエリの割当て状況を示す。また、配置表は、クエリと当該クエリの現在のクエリ状態との対応を示す。送信リストは、送信対象のデータを格納したコンテナである。送信リス

10

20

30

40

50

トは、宛先毎に用意される。

【0054】

クエリ実行管理部130は、入力されたイベントに応じたクエリの実行を管理する。クエリ実行管理部130は、クエリの実行に伴って、クエリ記憶部110に記憶された当該クエリのクエリ状態を更新する。

【0055】

クエリ状態送信管理部140は、自ノード（ここでは、ノード100）に割当てられたクエリ他ノードへの割当て変更指示を管理ノード400から受信する。すると、クエリ状態送信管理部140は、クエリ記憶部110から当該クエリのクエリ状態を取得する。クエリ状態送信管理部140は、取得したクエリ状態をシリアルライズし、宛先ノードへの送信リストに追加する。シリアルライズとは、ネットワーク10に送出可能なデータ形式へ情報を変換する処理である。クエリ状態送信管理部140は、送信リストのデータサイズが所定サイズに達するまでバッファリングし、当該送信リストに含まれるデータを宛先ノードへ送信する。

10

【0056】

クエリ状態受信管理部150は、他ノードから自ノードへ割当て変更されたクエリのクエリ状態を、当該他ノードから受信する。クエリ状態受信管理部150は、割当て変更されたクエリとクエリ状態との対応を管理情報記憶部120に記憶された配置表に登録する。後述するように、クエリ状態受信管理部150が他ノードから受信するクエリ状態には、当該クエリに対するイベントが付加されていることもある。その場合、クエリ状態受信管理部150は当該イベントを用いたクエリ実行をクエリ実行管理部130に依頼する。

20

【0057】

イベント送信管理部160は、イベントの送信管理を行う。具体的には、イベント送信管理部160は、他ノードが担当するクエリのイベントを当該他ノードへ送信するため、当該イベントのシリアルライズや送信リストへの登録を行う。イベント送信管理部160は、送信リストに含まれるイベントを当該他ノードへ送信する。

【0058】

イベント受信管理部170は、イベントの受信管理を行う。具体的には、イベント受信管理部170は、次に示す（1）～（4）の各場合に応じた処理を実行する。

（1）取得したイベントが自ノードに割当てられたクエリに対応するものである場合。この場合、イベント受信管理部170は、当該イベントを用いたクエリ実行をクエリ実行管理部130に依頼する。

30

【0059】

（2）取得したイベントが自ノードから他ノードへの割当て変更対象のクエリに対応するものであり、当該クエリのクエリ状態が自ノードから他ノードへ送信中として管理されている場合。この場合、イベント受信管理部170は、当該クエリ状態の送信リストに当該イベントを追加する。

【0060】

（3）取得したイベントが他ノードから自ノードへの割当て変更対象のクエリに対応するものであり、当該クエリのクエリ状態が他ノードから自ノードへ送信中として管理されている場合。この場合、イベント受信管理部170は、当該クエリに対する待ちイベントとして、管理情報記憶部120に記憶された配置表に当該イベントを登録する。

40

【0061】

（4）取得したイベントが他ノードに割当てられたクエリに対応するものである場合。この場合、イベント受信管理部170は当該他ノードに当該イベントを転送する。

イベント受信管理部170は、管理情報記憶部120に記憶された配置表に基づいて上記（1）～（4）の場合を判断できる。なお、上記（2）、（3）において「クエリ状態が送信中である」と管理される期間には、クエリ状態をネットワーク上へ送出するための準備（送信準備）期間（シリアルライズやバッファリングなどを行う期間）を含む。

【0062】

50

通信部 180 は、ノード 200、300、管理ノード 400 およびネットワーク 20 に接続された各種の装置との間の通信を行う。上述したクエリ状態送信管理部 140、クエリ状態受信管理部 150、イベント送信管理部 160 およびイベント受信管理部 170 と他の装置との間のデータの送受信は、通信部 180 を介して行われる。

【0063】

管理ノード 400 は、管理情報記憶部 410 および配置制御部 420 を有する。管理情報記憶部 410 は、管理ノード 400 が備える RAM や HDD など に確保した記憶領域として実現できる。配置制御部 420 は、管理ノード 400 が備えるプロセッサが実行するソフトウェアのモジュールとして実現できる。

【0064】

管理情報記憶部 410 は、配置表を記憶する。配置制御部 420 は、ノード 100、200、300 の負荷を監視する。配置制御部 420 は、ノード 100、200、300 の負荷に応じて、各ノードに対するクエリの割当てを変更することで、各ノードの負荷の平準化を図る。配置制御部 420 は、クエリの割当て変更に伴って、管理情報記憶部 410 に記憶された配置表の更新も行う。

【0065】

配置制御部 420 は、クエリの割当てを変更する際、ノード 100、200、300 の全てに、その旨を指示する。この指示は、割当て変更対象のクエリ、変更元のノードおよび変更先のノードを示す識別情報を含む。また、この指示は、各ノードが保持する配置表の更新指示も含む。クエリの割当て変更の指示は、ユーザにより、管理ノード 400 に接続された所定の入力デバイスを用いて入力されてもよい。その場合、管理ノード 400 は、ユーザによる操作入力を契機としてクエリの割当て変更を各ノードに指示する。

【0066】

図 6 は、分散処理システムのソフトウェア例（続き）を示す図である。ノード 200 は、クエリ記憶部 210、管理情報記憶部 220、クエリ実行管理部 230、クエリ状態送信管理部 240、クエリ状態受信管理部 250、イベント送信管理部 260、イベント受信管理部 270 および通信部 280 を有する。

【0067】

ノード 300 は、クエリ記憶部 310、管理情報記憶部 320、クエリ実行管理部 330、クエリ状態送信管理部 340、クエリ状態受信管理部 350、イベント送信管理部 360、イベント受信管理部 370 および通信部 380 を有する。

【0068】

クエリ記憶部 210、310 および管理情報記憶部 220、320 は、ノード 200、300 が備える RAM や HDD など に確保した記憶領域として実現できる。クエリ実行管理部 230、330、クエリ状態送信管理部 240、340、クエリ状態受信管理部 250、350、イベント送信管理部 260、360、イベント受信管理部 270、370 および通信部 280、380 は、ノード 200、300 が備えるプロセッサが実行するソフトウェアのモジュールとして実現できる。ここで、ノード 200、300 が備える機能は、ノード 100 が備える同名の機能と同様であるため、説明を省略する。

【0069】

図 7 は、イベントの例を示す図である。イベント X は、イベントのフォーマットを例示している。イベント X は、イベント種別、ストリーム名および内容の項目を含む。イベント種別の項目にはイベントの種別が登録される。ストリーム名の項目には、当該イベントに対応するストリームの識別情報が登録される。内容の項目には、イベントの内容を示す情報が登録される。

【0070】

イベント X1 は、イベント X の一例である。例えば、イベント X1 には、イベント種別が“P”、ストリーム名が“Input Stream”、内容が“1000W”という情報が格納されている。これは、当該イベント種別が“P”であり、電力に関する情報であることを示す。また、イベント X1 に対応するストリーム名が“Input Stream

10

20

30

40

50

”であることを示す。また、イベントX1の内容が“1000W”の消費電力の検出であることを示す。

【0071】

図8は、クエリの例を示す図である。クエリ111は、クエリ記憶部110に格納される。クエリ111は、E s p e rと呼ばれるEPL(Event Processing Language)を想定した記述例である。クエリ111では、“A”、“B”、“C”という3種のストリームの順番でイベントが入力された場合に、データ(イベント)をデータストリームに出力する。各クエリでは、このように種々のイベントに対する条件を定めることができる。ここで、以下の説明では、ストリーム名“A”であるイベントを、イベント“A”、イベントAのように表記することがある。

10

【0072】

図9は、クエリ状態の例を示す図である。クエリ状態112は、クエリ111のクエリ状態の一例である。クエリ状態112は、クエリ記憶部110に格納される。クエリ状態112は、クエリ111に対して、イベントA、Bが到着済だが、イベントCが未到着である(イベントCの到着待ちの状態である)ことを示している。ノード100、200、300は、クエリ毎の現在のクエリ状態を保持する。クエリとクエリ状態との対応は、配置表により管理される。

【0073】

図10は、配置表の例(その1)を示す図である。配置表121は、管理情報記憶部120に格納される。図10の例では、テーブル形式で配置表121を表したが任意のデータ構造を利用できる。例えば、配置表121は、クエリ名をkeyとしたHashMapなどでもよい。配置表121は、クエリ名、配置ノード名、状況、クエリ状態への参照、ロックおよび待ちイベントの項目を含む。

20

【0074】

クエリ名の項目には、クエリの識別情報が登録される。配置ノード名の項目には、当該クエリを割当てられた(配置された)ノード(担当ノード)の名称が登録される。状況の項目には、当該クエリの現在の状況が登録される。

【0075】

クエリの状況は、次のような状態を含む。(1)稼働中の状態(担当ノードで当該クエリを実行可能である状態)。(2)他ノードに移動中の状態(クエリの割当て変更に伴い、変更元のノードから変更先の担当ノードへクエリ状態を送信中である状態)。(3)他ノードに移動済の状態(変更元のノードから変更先の担当ノードへクエリ状態の送信を終えた状態)。

30

【0076】

クエリ状態への参照の項目には、クエリ状態へのポインタが登録される。ただし、自ノードで当該クエリ状態を管理していない場合には、クエリ状態への参照の項目には“ノード内に無し”という情報が登録される。

【0077】

ロックの項目には、クエリ状態のロックの有無が登録される。待ちイベントの項目には、待ちイベントが登録される。待ちイベントは、割当て変更前の担当ノードから自ノードへ、割当て変更対象のクエリのクエリ状態の送信が完了する前に、当該クエリに対して自ノードが取得したイベントである。

40

【0078】

例えば、配置表121には、クエリ名が“Q u e r y 1”、配置ノード名が“ノード100”、状況が“ノード200へ移動中”、クエリ状態への参照が“&Q u e r y 1 S t a t e”、ロックが“無”、待ちイベントが“n u l l”という情報が登録されている。

【0079】

これは、“Q u e r y 1”で示されるクエリがノード100に現在割当てられていること、ノード100からノード200へ当該クエリを割当て変更中であることを示す。また、当該クエリのクエリ状態がポインタ“&Q u e r y 1 S t a t e”で示される状態であ

50

ること、クエリ状態がロックされていないこと、当該クエリに対する待ちイベントが存在しないことを示す。

【0080】

図11は、配置表の例（その2）を示す図である。配置表221は、管理情報記憶部220に格納される。配置表221は、配置表121と同じタイミングの登録内容を例示している。配置表221に含まれる項目は、配置表121と同様であるため、説明を省略する。

【0081】

例えば、配置表221では、“Query1”で示されるクエリに対して、クエリ状態への参照が“ノード内に無し”であり、待ちイベントが“α5, α6”である点が、配置表121と異なる。これは、当該クエリは、現在割当て変更中（クエリ状態をノード200へ移動中）であり、自ノード（ノード200）では、クエリ状態を保持していないことを示す。また、当該クエリに対して、既にイベント“α5, α6”を待ちイベントとして取得済であることを示す。

10

【0082】

また、配置表221では、“Query8”で示されるクエリに対して、クエリ状態への参照“&Query8State”が登録されている点が配置表121と異なる。これは、当該クエリの担当ノードがノード200であり、ノード200で当該クエリのクエリ状態を保持しているからである。

【0083】

20

図12は、配置表の例（その3）を示す図である。配置表321は、管理情報記憶部320に格納される。配置表321は、配置表121, 221と同じタイミングの登録内容を例示している。配置表321に含まれる項目は、配置表121と同様であるため、説明を省略する。

【0084】

例えば、配置表321では、“Query1”で示されるクエリに対して、配置ノード名が“ノード200”、状況が“稼働中”である点が配置表121, 221と異なる。これは、ノード300がクエリ名“Query1”のクエリの割当て変更に伴うクエリ状態の送受信に関与しないためである。すなわち、各ノードは、管理ノード400からクエリの割当て変更の指示を受け、自ノードが当該変更に伴うクエリ状態の送受信に関与しないと判断すると、直ちに配置ノード名の変更を行ってよい。

30

【0085】

また、配置表321では、“Query10”で示されるクエリに対して、クエリ状態への参照“&Query10State”が登録されている点が配置表121, 221と異なる。これは、当該クエリの担当ノードがノード300であり、ノード300で当該クエリのクエリ状態を保持しているからである。

【0086】

なお、管理ノード400も配置表121, 221, 321と同様に配置表を保持する。管理ノード400の配置表では、各ノードに対する各クエリの最新の割当て状況が登録される。ただし、管理ノード400が保持する配置表では、クエリ状態への参照、ロックおよび待ちイベントを管理しなくてよい。

40

【0087】

図13は、送信データ管理構造体の例を示す図である。送信データ管理構造体Dは、送信リストにおいて1つのクエリのクエリ状態を格納するための構造体である。ここで、送信リストとして、双方向リストを想定したデータ構造を例示するが、双方向リストでなくてもよい（例えば、単方向リストでもよい）。送信データ管理構造体Dは、Forward、Backward、Query StateおよびEventsの項目を含む。

【0088】

Forwardは、連結された次の送信データ管理構造体を示すポインタ（&SendBufStructure）である。Backwardは、連結された前の送信データ管

50

理構造体を示すポインタ (&SendBufStructure) である。Query State は、送信対象のクエリ状態を示すポインタ (&QueryState) である。Events は、イベントを格納した配列を示すポインタ (&Events []) である。

【0089】

図14は、送信リストの例を示す図である。送信リスト122は、管理情報記憶部120に格納される。送信リスト122は、ノード100からノード200への情報の送信に用いられる。送信リスト122は、第1の実施の形態の送信データ6の一例である。送信リストは、宛先毎に作成される。ノード100からノード200以外の他ノードへ情報を送信する際、ノード100は他の送信リストを作成する。

10

【0090】

送信リスト122は、送信データ管理構造体D (リスト要素ということがある) を複数連結可能な双方向リストである。送信リスト122は、リスト要素122a, 122b, 122cを含む。リスト要素122aは、送信リスト122の先頭 (Head) である。また、リスト要素122aは、送信リスト122がロックされているか否かを示す情報 (例えば、フラグ) を含む (Lockの項目に設定される)。

【0091】

リスト要素122bは、リスト要素122aの次のリスト要素である。リスト要素122cは、リスト要素122bの次のリスト要素である。リスト要素122b, 122cは、Forward、Backward、Query State、Eventsの項目を含む。具体的な設定内容は次の通りである。

20

【0092】

リスト要素122bには、次の情報が設定されている。Forwardには、リスト要素122cへのリンク (Forwardリンク) を示すポインタが設定される。Backwardには、リスト要素122aへのリンク (Backwardリンク) を示すポインタが設定される。Query Stateには、“Query1”で示されるクエリのクエリ状態 (Query1State) を示すポインタが設定される。当該クエリ状態は、“Query1”で示されるクエリのクエリ状態である旨の情報も含む。Eventsには、当該クエリに対して受信したイベントの配列 ([a1, a2, a3]) を示すポインタが設定される。

30

【0093】

リスト要素122cには、次の情報が設定されている。Forwardは、次のリスト要素が存在していないため、設定無し (null) となる。Backwardには、リスト要素122bへのリンクを示すポインタが設定される。Query Stateには、“Query13”で示されるクエリのクエリ状態 (Query13State) を示すポインタが設定される。当該クエリ状態は、“Query13”で示されるクエリのクエリ状態である旨の情報も含む。Eventsは、当該クエリに対して受信したイベントが存在していないため、設定無し (null) となる。

【0094】

次に、第2の実施の形態のクエリの割当て変更時の処理手順を説明する。以下の説明では、ノード100からノード200へクエリの割当てを変更する場合を想定する。ただし、他ノード間でクエリの割当てを変更する場合も同様の手順となる。

40

【0095】

図15は、クエリ状態送信管理の例を示すフローチャートである。以下、図15に示す処理をステップ番号に沿って説明する。以下の手順は、ノード100からノード200へクエリの割当てを変更する場合のノード100の手順である。

【0096】

(S11) クエリ状態送信管理部140は、ノード100が担当するクエリ (例えば、クエリ名“Query1”のクエリ) をノード200へ割当てに変更する指示を管理ノード400から受信する。クエリ状態送信管理部140は、配置表121を操作して、変更対

50

象のクエリのクエリ状態をロックする（ロック“無”から“有”に変更する）。

【0097】

（S12）クエリ状態送信管理部140は、配置表121を操作して、当該クエリに対応するエントリの状況の項目を“稼働中”から“ノード200へ移動中”に変更する（割当て変更先のノード200も同様の設定を行う）。以降、割当て変更が完了し、ノード200で当該クエリの実行が再開されるまで、当該クエリの実行は中断される。

【0098】

（S13）クエリ状態送信管理部140は、送信データ管理構造体Dを生成する。

（S14）クエリ状態送信管理部140は、配置表121を参照して、当該クエリに対応するエントリのクエリ状態への参照の項目に設定されたポインタを用いて、クエリ状態を取得する。クエリ状態送信管理部140は、配置表121を操作して、当該エントリのクエリ状態への参照の項目を、ステップS13で生成した送信データ管理構造体Dへのポインタに変更する。

10

【0099】

（S15）クエリ状態送信管理部140は、配置表121を操作して、変更対象のクエリのクエリ状態をアンロックする（ロック“有”から“無”に変更する）。

（S16）クエリ状態送信管理部140は、ステップS14で取得したクエリ状態のシリアルライズを実行する。

【0100】

（S17）クエリ状態送信管理部140は、シリアルライズ済のクエリ状態をステップS13で生成した送信データ管理構造体Dに登録する。具体的には、クエリ状態送信管理部140は、当該クエリ状態へのポインタを送信データ管理構造体Dに登録する。

20

【0101】

（S18）クエリ状態送信管理部140は、送信リスト122をロックする。

（S19）クエリ状態送信管理部140は、送信データ管理構造体D（クエリ状態登録済）を送信リスト122に連結する。

【0102】

（S20）クエリ状態送信管理部140は、送信リスト122の合計のデータサイズが閾値以上であるか否かを判定する。閾値以上である場合、処理をステップS21に進める。閾値未満である場合、処理をステップS24に進める。なお、当該閾値には、例えばユーザにより、通信環境に応じた任意の値が設定され得る。

30

【0103】

（S21）クエリ状態送信管理部140は、配置表121を操作して、送信リスト122に登録されているクエリ状態を全てロックする。配置表121において、状況の項目が“ノード200へ移動中”と設定されているエントリのクエリ状態が、送信リスト122に登録されているクエリ状態である。

【0104】

（S22）クエリ状態送信管理部140は、送信リスト122に登録されているクエリ状態をノード200宛で、ネットワーク10に送出する。クエリ状態送信管理部140は、配置表121を操作して、配置ノード名の項目を（“ノード100”から）“ノード200”に、当該クエリ状態に対応するエントリの状況の項目を“移動済”に、クエリ状態への参照の項目を“ノード内に無し”に変更する。クエリ状態送信管理部140は、配置表121を操作して、当該エントリのクエリ状態をアンロックする。

40

【0105】

（S23）クエリ状態送信管理部140は、送信リスト122を参照して、ステップS22で送信対象としたクエリ状態にイベントが付属していれば、当該イベントもノード200に送信する。なお、ステップS22、S23は、送信リスト122に登録されたクエリ状態毎に実行される。送信リスト122に登録されたクエリ状態が複数であれば、クエリ状態送信管理部140は、クエリ状態毎にステップS22、S23を繰り返す。

【0106】

50

(S 2 4) クエリ状態送信管理部 1 4 0 は、送信リスト 1 2 2 をアンロックする。

このように、ノード 1 0 0 は、割当て変更対象のクエリのクエリ状態をノード 2 0 0 に送信する際に、当該クエリに対するイベントが送信リスト 1 2 2 に含まれていれば、クエリ状態とともに、そのイベントも送信する。

【0 1 0 7】

その後、例えば、クエリ状態送信管理部 1 4 0 は管理ノード 4 0 0 からクエリの割当て変更が完了した旨の通知を受け付ける。例えば、クエリ状態送信管理部 1 4 0 は、当該通知を受けると、配置表 1 2 1 の対応するクエリの状況の項目を（“移動済”から）“稼働中”に変更する。

【0 1 0 8】

また、ステップ S 1 2 において、前述のようにクエリ状態の送受信に関与しないノード 3 0 0 では、ステップ S 1 1 の指示に対して、配置表 3 2 1 の配置ノード名の項目を“ノード 2 0 0”に変更してよい。管理ノード 4 0 0 でも同様に、割当て変更指示を行うとともに管理ノード 4 0 0 が保持する配置表の配置ノード名の項目を“ノード 2 0 0”に変更してよい。

【0 1 0 9】

図 1 6 は、イベント受信管理（変更元）の例を示すフローチャートである。以下、図 1 6 に示す処理をステップ番号に沿って説明する。ノード 1 0 0 を例示するが、他ノードでも同様の手順となる。

【0 1 1 0】

(S 3 1) イベント受信管理部 1 7 0 は、イベントを取得する。イベントの発行元は、ネットワーク 2 0 に接続された何れかの装置でもよいし、ノード 1 0 0, 2 0 0, 3 0 0 の何れかでもよい。イベント受信管理部 1 7 0 は、取得したイベントのデシリアライズを実行する（イベントの発行元がノード 1 0 0 ならデシリアライズを行わなくてもよい）。

【0 1 1 1】

(S 3 2) イベント受信管理部 1 7 0 は、当該イベントに含まれるストリーム名から、クエリの識別情報（クエリ名）を取得する。クエリ記憶部 1 1 0 は、ストリーム名と当該ストリーム名のイベントを処理するクエリのクエリ名との対応関係の情報を記憶している。よって、イベント受信管理部 1 7 0 は、当該情報を参照することで、ストリーム名からクエリ名を取得できる。イベント受信管理部 1 7 0 は、クエリ名をキーに配置表 1 2 1 から当該イベントに対応するエントリを検索する。

【0 1 1 2】

(S 3 3) イベント受信管理部 1 7 0 は、配置表 1 2 1 を操作して、当該エントリのクエリ状態をロックする。

(S 3 4) イベント受信管理部 1 7 0 は、配置表 1 2 1 を参照して、当該エントリで示されるクエリを実行可能であるか否かを判定する。クエリを実行可能である場合、処理をステップ S 3 5 に進める。クエリを実行可能でない場合、処理をステップ S 3 6 に進める。クエリを実行可能である場合とは、当該クエリを自ノードが担当しており、状況が“稼働中”である場合である。クエリを実行可能でない場合とは、当該クエリを自ノードが担当していない場合や、当該クエリを自ノードが担当しているが状況が“稼働中”でない場合である。

【0 1 1 3】

(S 3 5) クエリ実行管理部 1 3 0 は、取得したイベントを用いてクエリを実行し、実行結果に応じて当該クエリのクエリ状態を変更する。クエリ実行管理部 1 3 0 は、配置表 1 2 1 を操作して、当該クエリのクエリ状態をアンロックする。そして、処理を終了する。

【0 1 1 4】

(S 3 6) イベント受信管理部 1 7 0 は、配置表 1 2 1 を参照して、取得したイベントに対応するクエリのクエリ状態がバッファリング中であるか否かを判定する。クエリ状態がバッファリング中である場合、処理をステップ S 3 7 に進める。クエリ状態がバッファ

10

20

30

40

50

リング中でない場合、処理をステップ S 4 2 に進める。クエリ状態がバッファリング中であるか否かは、当該クエリに対応する配置表 1 2 1 のエントリの状況の項目を参照することで判定できる。当該クエリを自ノードが担当しており、状況が“他ノード（例えば、ノード 2 0 0）に移動中”であれば、当該クエリ状態はバッファリング中である。状況が“他ノードに移動中”以外であれば、当該クエリ状態はバッファリング中でない。

【0 1 1 5】

（S 3 7）イベント受信管理部 1 7 0 は、取得したイベントのシリアル化を実行する。

（S 3 8）イベント受信管理部 1 7 0 は、送信リストのうち、当該イベントに対応するクエリのクエリ状態を登録した送信データ管理構造体 D（リスト要素）のリンクをロックする。

10

【0 1 1 6】

（S 3 9）イベント受信管理部 1 7 0 は、当該送信データ管理構造体 D に、取得したイベントを登録する（イベント連結）。

（S 4 0）イベント受信管理部 1 7 0 は、当該送信データ管理構造体 D のリンクをアンロックする。

【0 1 1 7】

（S 4 1）イベント受信管理部 1 7 0 は、配置表 1 2 1 を操作して、着目するクエリのクエリ状態をアンロックする。そして、処理を終了する。

（S 4 2）イベント受信管理部 1 7 0 は、配置表 1 2 1 を操作して、着目するクエリのクエリ状態をアンロックする。

20

【0 1 1 8】

（S 4 3）イベント受信管理部 1 7 0 は、取得したイベントをイベント送信管理部 1 6 0 に送信させる。イベント送信管理部 1 6 0 による処理の詳細については後述する。

このように、イベント受信管理部 1 7 0 は、イベントを取得した際に、当該イベントを処理するクエリのクエリ状態が送信中の状態であれば、送信リスト内の当該クエリ状態を格納したリスト要素に、そのイベントを登録する（ステップ S 3 7 ～ S 4 0）。ここで、例えば gather と呼ばれる API（Application Programming Interface）を用いることで、上述したクエリ状態送信管理部 1 4 0 やイベント受信管理部 1 7 0 の送信リストの作成処理を低コストで実現できる。

30

【0 1 1 9】

また、自ノードが担当するクエリに対するイベントでクエリ状態が送信中の状態でなければ、通常通りクエリを実行する（ステップ S 3 5）。更に、他ノードが担当するクエリに対するイベントを取得した場合には、イベント送信管理部 1 6 0 により、他ノードに当該イベントを送信させる（ステップ S 4 3）。

【0 1 2 0】

図 1 7 は、クエリ状態受信管理の例を示すフローチャートである。以下、図 1 7 に示す処理をステップ番号に沿って説明する。以下の手順は、ノード 1 0 0 からノード 2 0 0 へクエリの割当てを変更する場合のノード 2 0 0 の手順である。なお、ノード 2 0 0 は、ステップ S 5 1 よりも前にノード 1 0 0 からノード 2 0 0 へのクエリの割当て変更指示を管理ノード 4 0 0 から受信している。ノード 2 0 0 は、配置表 2 2 1 において、当該変更指示で指定されたクエリの状況を“ノード 2 0 0 へ移動中”と設定している。

40

【0 1 2 1】

（S 5 1）クエリ状態受信管理部 2 5 0 は、ノード 1 0 0 から割当て変更対象のクエリ（例えば、クエリ名“Query 1”のクエリ）のクエリ状態を受信する。クエリ状態受信管理部 2 5 0 は、受信したクエリ状態のデシリアル化を実行し、クエリ記憶部 2 1 0 に格納する。

【0 1 2 2】

（S 5 2）クエリ状態受信管理部 2 5 0 は、受信したクエリ状態にイベントが付属しているか否かを判定する。イベントが付属している場合、処理をステップ S 5 3 に進める。

50

イベントが付属していない場合、処理をステップ S 5 5 に進める。

【0123】

(S 5 3) クエリ状態受信管理部 2 5 0 は、付属しているイベント（例えば、イベント α 1, α 2, α 3）のデシリアライズを実行し、クエリ実行管理部 2 3 0 に出力する。

(S 5 4) クエリ実行管理部 2 3 0 は、取得したイベントおよびクエリ状態により該当のクエリを実行し、クエリ記憶部 2 1 0 に記憶されたクエリ状態を変更する。

【0124】

(S 5 5) クエリ状態受信管理部 2 5 0 は、管理情報記憶部 2 2 0 に記憶された配置表 2 2 1 を参照して、当該クエリのエントリを検索する。

(S 5 6) クエリ状態受信管理部 2 5 0 は、当該エントリをロックする。

10

【0125】

(S 5 7) クエリ状態受信管理部 2 5 0 は、当該エントリのクエリ状態への参照の項目に、クエリ記憶部 2 1 0 に記憶されたクエリ状態へのポインタを登録する。当該ポインタで示されるクエリ状態は、ステップ S 5 4 を実行していなければ、ステップ S 5 1 で取得したクエリ状態である。一方、ステップ S 5 4 を実行していれば、ステップ S 5 4 の実行結果に応じたクエリ状態である。

【0126】

(S 5 8) クエリ状態受信管理部 2 5 0 は、当該エントリに待ちイベントがあるか否かを判定する。待ちイベントがある場合、処理をステップ S 5 9 に進める。待ちイベントがない場合、処理をステップ S 6 0 に進める。

20

【0127】

(S 5 9) クエリ実行管理部 2 3 0 は、待ちイベント（例えば、イベント α 5, α 6）および現在のクエリ状態により該当のクエリを実行し、クエリ状態を変更する。

(S 6 0) クエリ状態受信管理部 2 5 0 は、配置表 2 2 1 を操作して、ステップ S 5 5 で検索されたエントリの配置ノード名の項目を（“ノード 1 0 0”から）“ノード 2 0 0”に、状況の項目を“移動済”に変更する。

【0128】

(S 6 1) クエリ状態受信管理部 2 5 0 は、当該エントリをアンロックする。

このように、クエリ状態受信管理部 2 5 0 は、受信したクエリ状態にイベントが付属していれば、当該イベントおよびクエリ状態を用いてクエリを実行し、クエリ状態を更新する。更に、クエリ状態受信管理部 2 5 0 は、当該クエリに対して待ちイベントが存在する場合には、待ちイベントを用いて当該クエリを実行し、クエリ状態を更新する。

30

【0129】

このとき、待ちイベントよりも前に発生し当該クエリに用いられるがノード 2 0 0 に未到着である未到着イベントが存在することもある（後述する）。この場合でも、ノード 2 0 0 によるクエリ状態および待ちイベントを用いたクエリの実行を許容する。

【0130】

なお、ステップ S 5 1 の後の何れかのタイミングで、クエリ状態受信管理部 2 5 0 は、クエリ状態を適切に受信した旨を管理ノード 4 0 0 に通知する。例えば、クエリ状態受信管理部 2 5 0 は、当該通知に対する管理ノード 4 0 0 からの応答（割当て変更完了の通知）を受けると、配置表 2 2 1 の当該クエリの実況の項目を“稼働中”に変更する（ステップ S 6 0 よりも前に“稼働中”になっていればステップ S 6 0 では“移動済”に変更しなくてよい）。

40

【0131】

図 1 8 は、イベント受信管理（変更先）の例を示すフローチャートである。以下、図 1 8 に示す処理をステップ番号に沿って説明する。ノード 2 0 0 を例示するが、他ノードでも同様の手順となる。

【0132】

(S 7 1) イベント受信管理部 2 7 0 は、イベントを取得する。イベントの発行元は、ネットワーク 2 0 に接続された何れかの装置でもよいし、ノード 1 0 0, 2 0 0, 3 0 0

50

でもよい。イベント受信管理部 270 は、取得したイベントのデシリアライズを実行する（イベントの発行元がノード 200 ならデシリアライズを行わなくてもよい）。

【0133】

（S72）イベント受信管理部 270 は、当該イベントに含まれるストリーム名から、クエリの識別情報（クエリ名）を取得する。クエリ記憶部 210 は、ストリーム名と当該ストリーム名のイベントを処理するクエリのクエリ名との対応関係の情報を記憶している。よって、イベント受信管理部 270 は、当該情報を参照することで、ストリーム名からクエリ名を取得できる。イベント受信管理部 270 は、クエリ名をキーに配置表 221 から当該イベントに対応するエントリを検索する。

【0134】

（S73）イベント受信管理部 270 は、配置表 221 を操作して、当該クエリのクエリ状態をロックする。

（S74）イベント受信管理部 270 は、配置表 221 を参照して、当該エントリのクエリを実行可能であるか否かを判定する。クエリを実行可能である場合、処理をステップ S75 に進める。クエリを実行可能でない場合、処理をステップ S76 に進める。クエリを実行可能である場合とは、当該クエリを自ノードが担当しており、状況が“稼働中”または“移動済”である場合である。クエリを実行可能でない場合とは、当該クエリを自ノードが担当していない場合や、当該クエリを自ノードが担当しているが状況が“稼働中”または“移動済”でない場合である。

【0135】

（S75）クエリ実行管理部 230 は、取得したイベントを用いてクエリを実行し、クエリ記憶部 210 に記憶された当該クエリのクエリ状態を変更する。クエリ実行管理部 230 は、配置表 221 を操作して、クエリ状態をアンロックする。そして、処理を終了する。

【0136】

（S76）イベント受信管理部 270 は、配置表 221 を参照して、取得したイベントに対応するクエリについて、クエリ状態の到着待ちであるか否かを判定する。クエリ状態の到着待ちである場合、処理をステップ S77 に進める。クエリ状態の到着待ちでない場合、処理をステップ S79 に進める。クエリ状態の到着待ちである場合とは、当該クエリ状態のエントリの状況の項目に“自ノード（ここでは、ノード 200）へ移動中”と設定されている場合である。クエリ状態の到着待ちでない場合とは、当該クエリ状態のエントリの状況の項目に“自ノードへ移動中”以外の情報が設定されている場合である。

【0137】

（S77）イベント受信管理部 270 は、配置表 221 の当該エントリの待ちイベントの項目に、取得したイベント（例えば、イベント α5 やイベント α6）を登録する。

（S78）イベント受信管理部 270 は、配置表 221 を操作して、当該エントリのクエリ状態をアンロックする。そして、処理を終了する。

【0138】

（S79）イベント受信管理部 270 は、配置表 221 を操作して、取得したイベントに対応するクエリのクエリ状態をアンロックする。

（S80）イベント受信管理部 270 は、取得したイベントをイベント送信管理部 260 に送信させる。

【0139】

このように、イベント受信管理部 270 は、クエリ状態の到着待ちであるクエリに対するイベントを取得すると、当該イベントを待ちイベントとして配置表 221 に登録する（ステップ S76, S77）。それ以外のイベントで自ノードが担当するクエリに対するイベントを取得した場合には、通常通りクエリを実行する（ステップ S75）。また、他ノードが担当するクエリに対するイベントを取得した場合には、イベント送信管理部 260 により、他ノードに当該イベントを送信させる（ステップ S80）。

【0140】

次に、イベント送信管理部160、260、360によるイベント送信管理の手順を説明する。以下では、イベント送信管理部160を例示するが、イベント送信管理部260、360による手順も同様である。

【0141】

図19は、イベント送信管理の例を示すフローチャートである。以下、図19に示す処理をステップ番号に沿って説明する。

(S81) イベント送信管理部160は、イベントを取得する。イベントの発行元は、ネットワーク20に接続された何れかの装置でもよいし、ノード100、200、300の何れかでもよい。前述のように、イベント送信管理部160は、イベント受信管理部170から他ノードが担当するクエリのイベントを取得することもある。イベント送信管理部160は、イベントのシリアル化を実行する。

10

【0142】

(S82) イベント送信管理部160は、配置表121を参照して、当該イベントの送信先のノードを特定する。なお、図16のステップS32や図18のステップS72と同様に、イベント送信管理部160は、イベントに含まれるストリーム名から、当該イベントを処理するクエリのクエリ名を特定できる。当該クエリ名のクエリを担当するノードが当該イベントの送信先のノードである。イベント送信管理部160は、当該送信先に対応する送信リストをロックする。

【0143】

(S83) イベント送信管理部160は、シリアル化済のイベントを当該送信リストに追加する。

20

(S84) イベント送信管理部160は、当該送信リストの合計のデータサイズが閾値を超えたか否かを判定する。閾値以上である場合、処理をステップS85に進める。閾値未満である場合、処理をステップS86に進める。なお、当該閾値には、例えばユーザにより、通信環境に応じた任意の値が設定され得る。

【0144】

(S85) イベント送信管理部160は、当該送信リスト内のイベントを送信先のノードを宛先として、ネットワーク10に送出する。このとき、他のイベントなどのデータが当該送信リストに格納されていれば、そのデータも送出する。

【0145】

(S86) イベント送信管理部160は、当該送信リストをアンロックする。

30

このように、イベント送信管理部160は、担当ノードが自ノードでないクエリに対するイベントを取得すると、当該イベントを担当ノードに送信する。

【0146】

図20は、クエリ状態の送信例(その1)を示す図である。図20では、ノード100からノード200へ、クエリ名“Query1”のクエリの割当てを変更する場合を例示している。ノード100は、当該クエリのノード200への割当て変更指示を管理ノード400から受信すると、当該クエリのクエリ状態のシリアル化を実行し、送信リスト122に追加する。ノード100において、当該クエリ状態は送信中として管理される。ノード100は、送信リスト122が所定サイズに達するまで、送信対象のデータを送信リスト122に追加する(バッファリング)。

40

【0147】

(1) ノード100は、バッファリングの間に、イベントα1、α2、α3を順に取得する。ノード100は、イベントα1、α2、α3が割当て変更対象のクエリに対するイベントであることを特定する。

【0148】

(2) ノード100は、イベントα1、α2、α3のシリアル化を実行し、送信リスト122内の当該クエリのリスト要素に、順番に追加する。

図21は、クエリ状態の送信例(その2)を示す図である。図21では、図20の後の処理を例示している。なお、前述のイベントα1、α2、α3に加えて、イベントα4、

50

α 5, α 6, α 7 もクエリ名 “ Q u e r y 1 ” のクエリで用いられるイベントである。

【 0 1 4 9 】

(3) ノード 1 0 0 は、送信リスト 1 2 2 のデータサイズが閾値に達すると、送信リスト 1 2 2 の内容を、ノード 2 0 0 を宛先としてネットワーク 1 0 に送出する。これにより、クエリ名 “ Q u e r y 1 ” のクエリのクエリ状態とともに、イベント α 1, α 2, α 3 も送出される。

【 0 1 5 0 】

(4) 次に、ノード 1 0 0 はノード 3 0 0 からイベント α 4 を取得する。このような状況が発生するのは、割当て変更指示がノード 3 0 0 に到着する以前に、ノード 3 0 0 がイベント α 4 をネットワーク 1 0 に送出する場合である。ノード 3 0 0 の配置表 3 2 1 ではイベント α 4 を送出するタイミングで、イベント α 4 に対するクエリの担当ノードがノード 1 0 0 のままであったためである。ノード 1 0 0 はイベント α 4 を、イベント α 1, α 2, α 3 よりも後のタイミングでノード 2 0 0 に送信することになる。

【 0 1 5 1 】

(5) ノード 1 0 0 により送出された送信リスト 1 2 2 の内容がノード 2 0 0 に到着する前に、ノード 2 0 0 はイベント α 5, α 6 を取得する。この場合、ノード 2 0 0 は、イベント α 5, α 6 を待ちイベントとして保持する。

【 0 1 5 2 】

(6) ノード 2 0 0 は、ノード 3 0 0 からイベント α 7 を取得する。このような状況が発生するのは、割当て変更指示がノード 3 0 0 に到着した後にノード 3 0 0 がイベント α 7 をネットワーク 1 0 に送出する場合である (ノード 3 0 0 の配置表 3 2 1 ではイベント α 7 に対するクエリの担当ノードがノード 2 0 0 に変更されている) 。

【 0 1 5 3 】

上記の例では、ノード 2 0 0 は、ノード 1 0 0 からクエリ状態およびイベント α 1, α 2, α 3 を受信すると、当該クエリ状態およびイベント α 1, α 2, α 3 を用いてクエリ名 “ Q u e r y 1 ” のクエリを実行する。その後、ノード 2 0 0 は、待ちイベントであるイベント α 5, α 6 を用いて当該クエリを実行する。更に、ノード 2 0 0 は、イベント α 4, α 7 をノード 2 0 0 に到着した順に用いて、当該クエリを実行する。

【 0 1 5 4 】

このように、イベント α 1, α 2, α 3 の処理をクエリ状態とともにノード 2 0 0 に送信する。このため、当該クエリ状態を取得したノード 2 0 0 は、イベント α 1, α 2, α 3 を用いて、直ちにクエリ名 “ Q u e r y 1 ” のクエリを実行できる。すなわち、イベント α 1, α 2, α 3 を当該クエリ状態とともにノード 2 0 0 に送信しない場合よりも、ノード 2 0 0 によるクエリの実行再開を短縮化できる。

【 0 1 5 5 】

ここで、第 2 の実施の形態の方法を用いると、例えば、イベント α 1, α 2, α 3, α 5, α 6, α 4, α 7 をこの順番で用いて、クエリが実行されることもある。一方、クエリによってはイベントの発生順を重視するものもある。例えば、イベント α 1, α 2, α 3, α 4, α 5, α 6, α 7 がこの順番に発生したなら、当該発生順で各イベントを用いてクエリを実行したいこともある (例えば、イベントの時間差検出を厳密に行う科学的計測の場合など) 。そこで、イベントの発生順を厳密に維持してクエリ実行するか、イベントの発生順と異なる順番で各イベントを用いたクエリ実行を許容するかを指定する情報を、各クエリに含めてもよい。

【 0 1 5 6 】

例えば、イベントの発生順と異なる順番でのクエリ実行を許容するクエリには、その旨を示すアノテーション (注釈を示すメタデータ。例えば、“ @ X X X ” などの文字列。) を当該クエリ内に記述可能とすることが考えられる。例えば、クエリ内に当該アノテーションが記述されている場合には、上記の方法により、クエリ状態にイベントを追加して送信可能とする。クエリ内に当該アノテーションが記述されていない場合には、例えば、クエリ状態の送信が完了するまで、各ノードは対象のクエリに対する全てのイベントの担当

10

20

30

40

50

ノードへの送信を保留し、クエリ状態の送信完了後に発生順で担当ノードに各イベントを処理させる。

【0157】

このようにすれば、クエリ状態とともにイベントを送信してクエリ実行する方法と、イベントの発生順を厳守してクエリ実行する方法とを両立できる。特に、イベントの発生順に拘らずにイベント処理を行えるようにすれば、未到着のイベント（上記の例ではイベントα4）を待たずに、待ちイベント（上記の例ではイベントα5、α6）のイベント処理を行える。このため、割当て変更後の担当ノードによるイベント処理を高速に開始できる。

【0158】

また、クエリ状態にイベントが付属しているときは、付属する当該イベントを先に利用し、待ちイベントをその後で用いることで、（発生順を入れ替えた入力順でのイベント処理を許容するものの）イベント発生順をある程度保ってクエリ実行できる。クエリ状態に付属するイベントの方が、待ちイベントよりも早いタイミングで生成されたものである可能性が高いからである。イベント間の発生タイミングの時間差として、比較的小さな時間差のイベント間の入れ替わりを許容するが、比較的大きな時間差のイベント間の入れ替わりを許容しない場合に有用である。

【0159】

なお、図21の（4）の例において、送信リスト122に含まれる全情報のネットワーク10への送出が完了する前に、イベントα4の到着や送信準備が間に合えば、当該全情報の中にイベントα4の情報を割り込ませて送出してもよい。例えば、他の情報に代えて、イベントα4を優先して送出してもよい。すると、ノード100は、クエリ状態とともにイベントα1、α2、α3、α4をノード200に提供できる。

【0160】

図22は、クエリ割当て変更の例（その1）を示すシーケンス図である。以下、図22に示す処理をステップ番号に沿って説明する。

（ST11）管理ノード400は、ノード100からノード200へのクエリの割当て変更をノード100、200、300に指示する。当該指示は、この段階ではノード100、200、300に未だ到着していない。

【0161】

（ST12）ノード300は、新たなイベントを取得する（ノード300でイベント発生）。当該イベントは、割当て変更対象のクエリに対するイベントである。

（ST13）ノード300は、配置表321を参照し、当該クエリの担当ノードであるノード100を特定する。ノード300は、ノード100へ宛てて、取得したイベントを送出する。当該イベントは、この段階ではノード100に未だ到着していない。

【0162】

（ST14）ノード100、200、300は、ステップST11の指示を受信する。ノード100、200は、配置表121、221を操作して、当該クエリの状況を“ノード200へ移動中”とする。ノード300は、配置表321の当該クエリの担当ノード名を“ノード200”とする。ノード100は、指示されたクエリのクエリ状態のシリアルズを実行し、当該クエリ状態を登録したリスト要素を送信リスト122に追加する。その後、ノード100は、ノード300から当該クエリに対するイベントを受信する。ノード100は、当該イベントのシリアルズを実行し、上記クエリ状態のリスト要素に追加する。

【0163】

（ST15）ノード100は、送信リスト122のデータサイズが閾値以上になるまでバッファリングする。

（ST16）ノード100は、送信リスト122のデータサイズが閾値以上になると、送信リスト122の内容をノード200へ宛てて送出する。このとき、ノード100は、ステップST14で送信リスト122に登録したクエリ状態も送出する。

【0164】

(ST17) ノード100は、ステップST14で当該クエリ状態に付加したイベントも送出する。

(ST18) ノード200は、ノード100からクエリ状態を受信すると、当該クエリ状態のデシリアライズを実行する。ノード200は、ノード100からクエリ状態に付属するイベントを受信すると、当該イベントのデシリアライズを実行する。

【0165】

(ST19) ノード200は、クエリ状態の移動が完了した旨を管理ノード400に通知する。

(ST20) ノード200は、ステップST18で取得したクエリ状態およびイベントを用いて、ノード100からノード200へ割当て変更されたクエリを実行する。

10

【0166】

このように、クエリの割当て変更指示がノード300に到達する前に、ノード300からノード100へ当該クエリに対するイベントが送出され得る。この場合、新たな担当ノードであるノード200が当該イベントを用いて割当て変更対象のクエリを実行できるまでの遅延時間（イベント転送レイテンシと呼ぶ）は、ステップST12からステップST18の完了までとなる。

【0167】

なお、管理ノード400は、ステップST19の後、クエリの割当て変更が完了した旨をノード100、200、300に通知してもよい。

20

図23は、クエリ割当て変更の比較例（その1）を示すシーケンス図である。以下、図23に示す処理をステップ番号に沿って説明する。図23では、第2の実施の形態の方法を用いない場合を想定して図22に対する比較例を説明する。図23の説明では、便宜的に第2の実施の形態と同じ符号を用いて各ノードを示す。

【0168】

(ST21) 管理ノード400は、ノード100からノード200へのクエリの割当て変更をノード100、200、300に指示する。当該指示は、この段階ではノード100、200、300に未だ到着していない。

【0169】

(ST22) ノード300は、新たなイベントを取得する（ノード300でイベント発生）。当該イベントは、割当て変更対象のクエリに対するイベントである。

30

(ST23) ノード300は、当該クエリの担当ノードをノード100と特定する。ノード300は、ノード100へ宛てて、取得したイベントを送出する。当該イベントは、この段階ではノード100に未だ到着していない。

【0170】

(ST24) ノード100、200、300は、ステップST21の指示を受信する。ノード100は、指示されたクエリのクエリ状態のシリアライズを実行し、送信データに追加する。また、ノード100は、ノード300から当該クエリに対するイベントを受信する。

【0171】

(ST25) ノード100は、送信データのデータサイズが閾値以上になるまでバッファリングする。

40

(ST26) ノード100は、送信データのデータサイズが閾値以上になると、送信データの内容をノード200へ宛てて送出する。当該送信データは、割当て変更対象のクエリのクエリ状態を含む。一方、当該送信データは、ステップST24で受信したイベントを含んでいない。

【0172】

(ST27) ノード200は、ノード100からクエリ状態を受信すると、当該クエリ状態のデシリアライズを実行する。

(ST28) ノード200は、クエリ状態の移動が完了した旨を管理ノード400に通

50

知する。

【0173】

(ST29) 管理ノード400は、クエリの割当て変更が完了した旨をノード100, 200, 300に通知する。ノード100, 200, 300は、当該通知を受信する。

(ST30) ノード100は、ノード300から受信していたイベントを、割当て変更後の新たな担当ノードであるノード200に送信する(当該イベントに対してもシリアライズやバッファリングを行う)。ノード200は、ノード100からイベントを受信すると、当該イベントのデシリアライズを実行する。

【0174】

(ST31) ノード200は、ステップST27で取得したクエリ状態およびステップST30で取得したイベントを用いて、ノード100からノード200へ割当て変更されたクエリを実行する。

【0175】

上記比較例の場合、ノード300で発生したイベントをノード200が受信完了するまでのイベント転送レイテンシは、ステップST22からステップST30の完了までとなる。比較例では、図22のイベント転送レイテンシに比べて、ステップST28~ST30の時間が余計にかかる。特に、ステップST30では、図示を省略しているが、ステップST24~ST26と同様にロック待ち、バッファリング、転送、デシリアライズ、登録、アンロック待ちという複数段階のフェーズを含み、これら処理のレイテンシも含まれることになる。

【0176】

一方、図22の場合は、ステップST28~ST30の時間分の遅延を削減できる。よって、比較例に比べて、割当て変更対象のクエリをノード200により実行再開できるまでの遅延を短縮できる。

【0177】

なお、ステップST24, ST25で送信データのデータサイズが閾値に達していなければ、ステップST26でノード300から到着したイベントをクエリ状態とともにノード200に送信できる可能性もある。ただし、比較例の場合では、送信データを単にバッファリングするのみである。すなわち、第2の実施の形態の方法のように、送信データ管理構造体Dを用いてクエリ状態とイベントとを一塊として管理していない。したがって、ノード100からノード200へクエリ状態とイベントとが関連性なく送信されることになる。この場合、ノード200では、受信したデータの中からクエリ状態と当該クエリ状態に関係するイベントとを検索する演算コストや遅延も生じ得る。この演算コストや遅延も改善の余地がある。

【0178】

一方、図22の場合は、送信データ管理構造体Dを用いてクエリ状態とイベントとを一塊で管理する。これにより、クエリ状態とイベントとをノード100から連続して送信可能とする。ノード200では、受信データのデシリアライズの際に、クエリ状態の直後にイベントを抽出すれば、当該イベントを直前のクエリ状態に付属するイベントと判断できる。すなわち、クエリ状態とイベントとをノード200により効率的に取得させ、割当て変更対象のクエリの実行再開をより短縮できる(上記の演算コストや遅延を改善し得る)。このように、クエリ状態とイベントとをノード100から連続して送信する方が、より好ましい。

【0179】

図24は、クエリ割当て変更の例(その2)を示すシーケンス図である。以下、図24に示す処理をステップ番号に沿って説明する。

(ST41) 管理ノード400は、ノード100からノード200へのクエリの割当て変更をノード100, 200, 300に指示する。

【0180】

(ST42) ノード100, 200, 300は、ステップST41の指示を受信する。

ノード１００，２００は、配置表１２１，２２１を操作して、当該クエリの状態を“ノード２００へ移動中”とする。ノード３００は、配置表３２１の当該クエリの担当ノード名を“ノード２００”とする。ノード１００は、指示されたクエリのクエリ状態のシリアルライズを実行し、当該クエリ状態を送信リスト１２２に追加する。

【０１８１】

（ＳＴ４３）ノード３００は、新たなイベントを取得する（ノード３００でイベント発生）。当該イベントは、割当て変更対象のクエリに対するイベントである。

（ＳＴ４４）ノード３００は、配置表３２１を参照し、当該クエリの担当ノードであるノード２００を特定する。ノード３００は、ノード２００へ宛てて、取得したイベントを送出する。その後、ノード２００は当該イベントを受信し、受信したイベントのデシリアルライズを行う。ノード２００は、割当て変更対象のクエリの待ちイベントとして、当該イベントを配置表２２１に登録する。ノード２００の配置表２２１では、ノード３００から受信したイベントに対するクエリが“自ノード（ここでは、ノード２００）へ移動中”となっているためである。

10

【０１８２】

（ＳＴ４５）ノード１００は、送信リスト１２２のデータサイズが閾値以上になるまでバッファリングする。

（ＳＴ４６）ノード１００は、送信リスト１２２のデータサイズが閾値以上になると、送信リスト１２２の内容をノード２００へ宛てて送出的る。

【０１８３】

20

（ＳＴ４７）ノード２００は、ノード１００からクエリ状態を受信すると、当該クエリ状態のデシリアルライズを実行する。

（ＳＴ４８）ノード２００は、クエリ状態の移動が完了した旨を管理ノード４００に通知する。

【０１８４】

（ＳＴ４９）ノード２００は、ステップＳＴ４６で取得したクエリ状態およびステップＳＴ４４で取得したイベント（待ちイベント）を用いて、ノード１００からノード２００へ割当て変更されたクエリを実行する。

【０１８５】

このように、クエリの割当て変更指示がノード３００に到達した直後に、ノード３００からノード２００へ当該クエリに対するイベントが送出され得る。この場合、イベント転送レイテンシは、ステップＳＴ４３からステップＳＴ４７の完了までとなる。

30

【０１８６】

なお、管理ノード４００は、ステップＳＴ４８の後、クエリの割当て変更が完了した旨をノード１００，２００，３００に通知してもよい。

図２５は、クエリ割当て変更の比較例（その２）を示すシーケンス図である。以下、図２５に示す処理をステップ番号に沿って説明する。図２５では、第２の実施の形態の方法を用いない場合を想定して図２４に対する比較例を説明する。図２５の説明では、便宜的に第２の実施の形態と同じ符号を用いて各ノードを示す。

【０１８７】

40

（ＳＴ５１）管理ノード４００は、ノード１００からノード２００へのクエリの割当て変更をノード１００，２００，３００に指示する。

（ＳＴ５２）ノード１００，２００，３００は、ステップＳＴ５１の指示を受信する。ノード１００は、指示されたクエリのクエリ状態のシリアルライズを実行し、送信データに追加する。

【０１８８】

（ＳＴ５３）ノード３００は、新たなイベントを取得する（ノード３００でイベント発生）。当該イベントは、割当て変更対象のクエリに対するイベントである。ノード３００は、当該イベントが割当て変更対象のクエリに対するものであることを検出すると、当該イベントの担当ノードへの提供を保留する。

50

【0189】

(ST54) ノード100は、送信データのデータサイズが閾値以上になるまでバッファリングする。

(ST55) ノード100は、送信データのデータサイズが閾値以上になると、送信データの内容をノード200へ宛てて送出する。当該送信データには、クエリ状態が含まれる。

【0190】

(ST56) ノード200は、ノード100からクエリ状態を受信すると、当該クエリ状態のデシリアライズを実行する。

(ST57) ノード200は、クエリ状態の移動が完了した旨を管理ノード400に通知する。

10

【0191】

(ST58) 管理ノード400は、クエリの割当て変更が完了した旨をノード100, 200, 300に通知する。ノード100, 200, 300は、当該通知を受信する。

(ST59) ノード300は、ステップST53で取得したイベントの送信先をノード200と特定する。ノード300は、当該イベントをノード200に送信する(当該イベントに対してもシリアライズやバッファリングを行う)。ノード200は、ノード300からイベントを受信すると、当該イベントのデシリアライズを実行する。

【0192】

(ST60) ノード200は、ステップST56で取得したクエリ状態およびステップST59で取得したイベントを用いて、ノード100からノード200へ割当て変更されたクエリを実行する。

20

【0193】

上記比較例の場合、ノード300で発生したイベントをノード200が受信完了するまでのイベント転送レイテンシは、ステップST53からステップST59の完了までとなる。比較例では、図24のイベント転送レイテンシに比べて、ステップST57～ST59の時間が余計にかかる。特に、ステップST59では、図示を省略しているが、ステップST52～ST56と同様にロック待ち、バッファリング、転送、デシリアライズ、登録、アンロック待ちという複数段階のフェーズを含み、これら処理のレイテンシも含まれることになる。

30

【0194】

一方、図24の場合はステップST44において、ノード300からノード200へのイベントの送信を許容し、ノード200では当該イベントを待ちイベントとして管理する。このため、ステップST57～ST59の時間分の遅延を削減できる。すなわち、比較例に比べて、割当て変更対象のクエリをノード200により実行再開できるまでの遅延を短縮できる。

【0195】

図26は、分散処理システムの他の例を示す図である。図2では、サーバコンピュータ(物理マシン)を用いてノード100, 200, 300を実現する例を示した。一方、仮想マシンを用いて各ノードを実現してもよい。例えば、サーバ51, 52, 53をネットワーク10に接続する。ここで、図26ではネットワーク20および他の装置の図示を省略している。

40

【0196】

例えば、サーバ51, 52, 53は、ハイパーバイザや仮想マシンモニタなどと呼ばれる管理用のソフトウェアを実行し、サーバ51, 52, 53上の複数の仮想マシンに、サーバ51, 52, 53が備えるCPUやRAMなどのリソースを割当てる。例えば、サーバ51は、仮想マシン100a, 200a, 300aを有する。

【0197】

仮想マシン100a, 200a, 300aを、分散処理を行うノードとして用いることができる。例えば、仮想マシン100aは、ノード100と同一の機能を実現できる。仮

50

想マシン200aは、ノード200と同一の機能を実現できる。仮想マシン300aは、ノード300と同一の機能を実現できる。なお、物理マシンと仮想マシンとが分散処理を行うノードとして混在してもよい。このように、仮想マシン100a、200a、300aを用いて分散処理を行う場合も、クエリの割当て変更先で当該クエリ実行を再開するまでの遅延を短縮できる。

【0198】

すなわち、ノード100、200、300は、第1の実施の形態のマシン（物理マシン）の一例である。仮想マシン100a、200a、300aは、第1の実施の形態のマシン（仮想マシン）の一例である。

【0199】

また、上記の例では、クエリ毎に担当ノードを割当ててのものとした。一方、クエリおよび当該クエリに対するイベントに含まれる所定のキーに応じて、クエリの割当てを行うことも考えられる。同じクエリでも、キーに応じて担当ノードを別個にしたいこともあるからである。具体的には、複数の地域のうちの何れの地域で発生したイベントかを示す情報（キー）が、当該イベントに含まれる場合に、当該キーに応じて担当ノードを決定することが考えられる。その場合、配置表121、221、321では、クエリとキーとの組に応じて、配置ノード名を管理することができる。その場合でも、上記の説明において「クエリとキーとの組」に対して「クエリ名」が与えられると考えれば、上記と同様の方法を適用できる。

【0200】

なお、第1の実施の形態の情報処理は、演算部1bにプログラムを実行させることで実現できる。また、第2の実施の形態の情報処理は、プロセッサ101にプログラムを実行させることで実現できる。プログラムは、コンピュータ読み取り可能な記録媒体（例えば、光ディスク13、メモリ装置14およびメモリカード16など）に記録できる。

【0201】

例えば、プログラムを記録した記録媒体を配布することで、プログラムを流通させることができる。また、プログラムを他のコンピュータに格納しておき、ネットワーク経由でプログラムを配布してもよい。コンピュータは、例えば、記録媒体に記録されたプログラムまたは他のコンピュータから受信したプログラムを、RAM102やHDD103などの記憶装置に格納し（インストールし）、当該記憶装置からプログラムを読み込んで実行してもよい。

【符号の説明】

【0202】

- 1, 2 マシン
- 1a, 2a 記憶部
- 1b, 2b 演算部
- 3 進捗情報
- 4 変更指示
- 5 データ
- 6 送信データ


10

20


30

40


【図 1】




【図 2】




【図 3】




【図 4】



【図 5】



【図 6】




【図 7】


イベントの例

イベント種別	ストリーム名	内容
P	InputStream	1000W

【図 8】



【図 9】



【図 10】

配置表

クエリ名	配置ノード名	状況	クエリ状態への参照	ロック	待ちイベント
Query1	ノード100	ノード200へ移動中	&Query1State	無	null
Query8	ノード200	稼働中	ノード内に無し	無	null
Query10	ノード300	稼働中	ノード内に無し	無	null
...	...	...	...	...	...

【図 11】

配置表

クエリ名	配置ノード名	状況	クエリ状態への参照	ロック	待ちイベント
Query1	ノード100	ノード200へ移動中	ノード内に無し	無	$\alpha 5, \alpha 6$
Query8	ノード200	稼働中	&Query8State	無	null
Query10	ノード300	稼働中	ノード内に無し	無	null
...	...	...	...	...	...

【図 1 2】


配置表					
クエリ名	配置ノード名	状況	クエリ状態への参照	ロック	待ちイベント
Query1	ノード200	稼働中	ノード内に無し	無	null
Query8	ノード200	稼働中	ノード内に無し	無	null
Query10	ノード300	稼働中	&Query10State	無	null
...	...	...	...	...	...

【図 1 3】


送信データ管理構造体の例

Forward	&SendBufStructure
Backward	&SendBufStructure
Query State	&QueryState
Events	&Events []


【図 1 4】




【図 1 5】




【図 1 6】




【図 17】




【図 18】




【図 19】




【図 20】




【図 2 1】




【図 2 2】




【図 2 3】



【図 2 4】



【図 26】



フロントページの続き

(56)参考文献 特開2012-248169 (JP, A)

高橋 雅彦, データセンタ環境に適したTCP無切断プロセスマイグレーションの実現 (2004-O S-96), 情報処理学会研究報告, 日本, 社団法人情報処理学会, 2004年 6月18日, 第2004巻, 第63号, pp.29-36

(58)調査した分野(Int.Cl., DB名)

G06F 9/50