

計算機資源の流通および 集約のための P2P ミドルウェア

首藤一幸 大西丈治
田中良夫 関口智嗣


産業技術総合研究所 グリッド研究センター



Personal
Power
Plant



Grid
Technology
Research
Center
AIST



背景

◆ 計算機資源の流通に向けた動きが活発化

- ◆ 資源: CPU能力、ストレージ、デバイス等
- ASP (アプリケーションサービスプロバイダ) の出現
- ユーティリティコンピューティングの提唱
 - ◆ 電気、水道のように、利用料に応じた課金
- Globus Toolkitの認証、認可機能を利用した、PCクラスタ等の組織間での融通
 - ◆ スパコンのグリッドによる大規模な科学技術計算
 - 他組織へのジョブ投入や、MPICH-G2, Ninf-Gを用いた組織をまたいだ分散実行

動機

◆PCをはじめとする個人情報機器では...

- インターネット上分散処理プロジェクト
 - ◆ i.e. SETI@home, distributed.net, GIMPS, ...
 - ◆ 運営者だけがアプリケーションプログラムを用意できる。
参加者は一方的に計算能力を提供する。
- アカウントの発行
 - ◆ 計算機資源 提供側の手間が大きい。
 - ◆ 単一目的に機器群を関係させることは難しい。
 - i.e. 並列処理, センサーからのデータを別計算機で処理

計算機資源 授受のための ミドルウェア



◆ P3: Personal Power Plant

- 個人情報機器の資源を容易に授受し、
- 自由な並列プログラミングでそれらを連係、集約して活用するためのミドルウェア。
- 資源提供者は、自らの意志で、どういった処理に資源を提供するのかを決めることができる。
 - ◆ 授受における重要な要件であり、P3 の特徴。
- 応用例
 - ◆ 計算してくれる人、ストレージを貸してくれる人、カメラ等センサーを使わせてくれる人 (資源提供者) の募集
 - ◆ インターネット上分散処理プロジェクトの運営
 - ◆ 組織内遊休 PC の cycle harvesting
- 当面のターゲットは、PC 群を用いた並列・分散処理

オーバーレイネットワークの利用

◆ 自由な並列プログラミングのために...

- 昨今の IPv4 インターネットには、通信の相手や方向に制約がある。
 - ◆ Private アドレス, DHCP: インターネット側から計算機を識別できない。NAT, NAPT ゲートウェイがあっても、通信開始の方向は一方向。
 - ◆ ファイアウォール: IPv6 だろうと必要。
- 通信には、P2P 通信ライブラリが提供するオーバーレイネットワークを利用。
 - ◆ 下位通信網 (TCP/IP, Bluetooth 等) の差異、混在や、通信相手、方向の制約を吸収する。
 - ◆ 任意の計算機 (ピア) 間の双方向通信機能を提供する。
- 本発表では、P2P 通信ライブラリが提供する各種の概念を、本ミドルウェアの目的に対していかに適用するかを提案する。

P2P 通信ライブラリ JXTA


◆ JXTA (じゃくすた) を採用

- P2P ソフトウェアに共通の機能を提供するプロトコル、参照実装 (Java, C)、プロジェクト。
- Sun Microsystems 社が 2001年に公開した。
- 比較的) 安心して使える理由：
 - ◆ API が、2001年末の時点ではほぼ固定されている。
 - ◆ 利用者が多い。
 - jxta.org でのユーザ登録は15,000 以上。
 - ◆ PCから携帯電話器まで、様々な規模の計算機で稼動する。
 - ◆ ライセンスが緩い :BSD由来である Apache と同じ内容。

JXTA の提供する オーバーレイネットワーク

“Project JXTA 2.0 Super-Peer
Virtual Network” 中の図

- ◆ 計算機はピアIDで識別される。
 - JXTAの実装は通信にTCPやHTTP, IPマルチキャストなどを用いるが、JXTAの利用者はそれを意識せずに、任意のピアを相手に通信を行う。
- ◆ ピアはピアグループを作成でき、複数のピアグループに参加できる。



JXTAの諸概念の適用法

- ◆ JXTAが提供する諸概念を、いかに本ミドルウェアの目的に適用するかを提案する。

- ◆ ピアグループ、発見

◆ 「ピアグループ」

- 並列処理には同報通信が欠かせない。
- ジョブごとにピアグループを作成し、計算中のブロードキャストや、実行制御を、ピアグループ内同報通信によって行う。
 - ◆ cf. JNGI: 計算機を集合的に管理する目的にピアグループを使用。
- また、このピアグループ内で、アプリケーションプログラムの配布を行う。
 - ◆ JXTA のファイル共有サービス CMS (Content Management Service) を使用。
 - ◆ そのピアグループが、ファイルの配布範囲となる。
→ ファイルを必要とする計算機と一致。

JXTAの諸概念の適用法

◆ 発見

■ 資源提供者による、ジョブの発見

- ◆ 計算機資源提供者は、資源の使用目的を決めることができるべき。
- ◆ 資源利用者（ジョブ投入者）が作成、広報したジョブのピアグループを、資源提供者が発見する。
- ◆ ジョブのピアグループを発見した資源提供者は、自らの意志に基づいて、そのピアグループに参加するか否かを決定する。

■ 資源利用者（ジョブ投入者）による、提供されている計算機の発見

- ◆ メッセージパッシング型アプリケーションの起動先指定に使用。

■ 資源提供者による、資源利用者（ジョブ投入者）の発見

- ◆ 利用者のネットワーク上位置（IPアドレス等）を手で事前に設定しておく必要がなくなった。

ミドルウェアの設計

◆ ジョブ管理ソフトウェア

- Host : デーモン
- Controller : ジョブ投入ツール


◆ 並列プログラミング支援ライブラリ

- マスタ・ワーカ
- メッセージパッシング
- これらのエミュレータ

ジョブ管理ソフトウェア：Host

- ◆ 資源提供者が起動しておくデモン。
- ◆ ジョブのピアグループを発見し、提供者に提示する。
- ◆ 提供者は、シェルを用いて、ジョブを選択する。
 - [将来] ポリシー指定に従い、自動的にジョブを選択する。
特に、集中管理が求められる組織内利用で重要。

投入されている
ジョブ




Host のシェル

ジョブ管理ソフトウェア : Controller


- ◆ 資源利用者がジョブ投入に用いるツール。
- ◆ アプリケーションプログラムを指定し、ジョブとして投入する。
 - アプリ : Java で記述し、JAR 形式のアーカイブに格納しておく
[将来] C, C++, FORTRANで記述、コンパイルしたネイティブコードのアプリも投入可能とする。

投入された
アプリケーション



Controller のシェル

ピアグループの構成



◆ Net Peer Group

- JXTAで常に存在するグループ。


◆ Base Peer Group

- P3 既定のグループ。全 Host, Controller は起動直後に参加する。


◆ Job Peer Group

- ジョブの投入ごとに作成されるグループ。

Controller を用いた ジョブの投入



Host の ジョブへの参加



Controller を用いた ジョブの起動

◆ 続いて、Controller のシェルから、**ジョブの起動を指示**する。


- アプリが用いる支援ライブラリの種類によって、ジョブを起動できるタイミングが異なる：
- ジョブ実行中の Host 参加を許す支援ライブラリ (e. マスタ・ワーカ) を用いるアプリの場合、Controller を用いたジョブ投入直後に起動できる。
 - ◆ Host の参加を待つ必要はない。
- そうでない支援ライブラリ (e. メッセージパッシング) を用いるアプリの場合、ジョブ投入後、Host 群の参加を待ってから、起動する必要がある。

並列プログラミング 支援ライブラリ

◆ プログラムが直接利用するのは、**マスタ・ワーカAPI** と、**メッセージパッシング API**。

◆ **エミュレータ**

- 並列プログラムを計算機 1 台上で動作させる。
- アプリの効率的な開発、デバッグに非常に有効。
我々自身、マスタ・ワーカライブラリの開発に使った。そのまま実環境に載った。



並列プログラミング 支援ライブラリ

◆ オブジェクトパッシング

- (Java の) オブジェクトを送受信するライブラリ。
 - ◆ API: send(PeerID, Object), broadcast(Object), recv(PeerID), recv(), listenerの登録など
- 通信相手は、JXTA のピアIDで識別する。
- プログラマからは直接使わない。
- この上に他のライブラリを開発する場合、JXTA の知識は不要。


◆ メッセージパッシング - JXTA-MPI

- MPI にならった API。
- 通信相手は、JXTA のピアIDの代わりに整数値 rank で識別する。

◆ マスタ・ワーカ

- 後述

並列プログラミング 支援ライブラリ



◆ マスタ・ワーカ

- マスタ・ワーカ型並列処理に特化した API とその実装 (ライブラリ)。
- マスタは、部分問題 (ワークユニット) を投入する。
ワーカは、部分問題进行处理し、結果を返戻する。
- 部分問題は要求に応じてワーカに配布する。
 - ◆ 動的負荷分散
 - ◆ アプリは部分問題のスケジュールを意識する必要なし。
- 障害と妨害への対応
 - ◆ 悪意あるワーカの存在を前提としている。
 - voting (投票) により虚偽の結果を検出できる。アプリ非依存。
 - ◆ タイムアウトに基づく 部分問題の再割り当てを行う。

マスタ・ワーカ API 使用例

◆ アプリのマスタ側

```
class Amaster implements Master {  
    start() {  
        while (...) {  
            ProblemSet p = <a subproblem>;  
            // submit a subproblem  
            submitProblemSet(p);  
        }  
    }  
}
```

◆ アプリのワーカ側

```
class Aworker implements Worker {  
    ResultSet process(ProblemSet p) {  
        // process a subproblem and  
        // return the result  
    }  
}
```

支援ライブラリの 性能評価

◆ [Q] オーバレイネットワークの機能はいいけど、通信その他が遅いんじゃないの？

◆ 測定の内容

- 通信の遅延とスループット
- マスタによる部分問題処理スループット
 - ◆ 単位時間あたりに、いくつの部分問題をさばけるか？
- アプリケーションプログラムでの性能確認
 - ◆ 共通鍵暗号方式 RC5 の暗号化鍵総当り探索
 - ◆ 粒度の細かい部分問題への耐性を確認。

◆ 環境

- 2.4 GHz Xeon × 34台の PC クラスタ, Gigabit Ethernet
- Linux 2.4.19, Java 2 SDK 1.4.2, JXTA 2.1
- 現インターネットよりリッチだが、それだけに、ソフトウェアによるオーバヘッドを明確に測定できる。

通信遅延

◆ 1バイトのピンポンを 1000往復。片道あたり：

- ◆ TCP (C プログラム) 0.062 msec
- ◆ TCP (Java プログラム) 0.064 msec
- ◆ メッセージパッシング 4.5 msec


◆ やはり、遅延は小さくない。

- 送信：Java のオブジェクトをバイト列に変換し、JXTAメッセージに埋め込み、送信。
- 受信：JXTAから呼び出された支援ライブラリ側のlistenerがJXTAメッセージを取得、バイト列を取り出し、オブジェクトを復元。支援ライブラリ中のキューに投入し、アプリに知らせる。

◆ この比較的大きな遅延が、マスタの部分問題処理スループット（後述）に大きな影響を与えている。

メッセージパッシングの スループット

- ◆ $100 \times 10^{**6}$ bps くらいは出ている。
 - 家庭、小規模オフィスのインターネット線や、低速LANを埋められるくらい。
- ◆ 送信データサイズが大きい場合に低下が見られる。
JXTA の現実装の問題？
 - 分割して送ればよい。



[参考]

- TCP (C) 108.0 MB/s
- TCP (Java) 105.5 MB/s
(送受信サイズ 1MB)

[注] K = 1024


M = 1024 ** 2

マスタの 部分問題処理スループット

- ◆ 並列処理効率のためには、マスタに集中する部分問題の配布、回収処理が律速とならないようにすることが重要。
- ◆ 単位時間あたりにさばける部分問題数が、マスタの性能を表す重要な指標となる。

◆実験：

- アプリは、RC5 暗号化鍵総当たり探索。
 - ◆ 鍵空間を分割して部分問題とし、ワーカーに配布。
- 部分問題に含める鍵候補の数をゼロとした。
 - ◆ アプリ固有の処理にかかる時間を可能な限り小さくした。
- 200 の部分問題を配布、回収し、1つあたりの時間を求めた。



マスタの 部分問題処理スループット

◆ スループット

- Best: 13 msec/個 77 個/秒
- Worst: 27 msec/個 37 個/秒
- 通信遅延だけで片道 4.5 msec かかっている。これがネック。

◆ United Devices 社のインターネット上分散処理プロジェクトの場合

- UD社：抗ガン剤探索、インターネットサイトのストレステストのプロジェクトを運営。200万デバイスが登録されているとのこと。
- 120 個/秒
- Grid MP (ミドルウェア)に 4 CPU、DBに 4 CPU。
- ミドルウェア自体の許容量は、最低でもこの数倍はあるだろう。


◆ 数万台規模のワーカを単一ジョブに参加させるなら、10 倍から100 倍の性能向上が望まれる。

- また、複数のマスタでワーカ群を分担できるように、部分問題をマスタの外の DB に格納しやすいような設計をしている。

アプリケーションでの性能確認

◆ 暗号鍵探索アプリで、Hostの台数と、部分問題あたりの鍵数を変化させた。
部分問題数は 200。

■ 部分問題の粒度を細かくしていった場合の、並列化効率の鈍り方を観察。



部分問題あたりの
処理時間

■ 鍵数 0x8000

1.4 秒

■ 鍵数 0x4000

0.69 秒


■ 鍵数 0x2000

0.36 秒

アプリケーションでの性能確認

◆ Y軸を、性能向上率にしたグラフ：

- 0.69 秒という比較的細粒度の部分問題でも、32台で20倍以上の性能向上は得られている。
 - ◆ cf. インターネット上分散処理では数時間～数日。
- 粒度 0.36 秒では、24台で頭打ち。



部分問題あたりの
処理時間

■ 鍵数 0x8000
1.4 秒

■ 鍵数 0x4000
0.69 秒

■ 鍵数 0x2000
0.36 秒

関連研究

◆ JNGI (by Sunの人)

- JXTA を用いた分散処理フレームワーク
- 計算機群の効率的な管理のためにピアグループを利用。
 - ◆ cf. P3 は、ジョブのピアグループ。
- 2003年 7月現在、構想の主要部分がほとんど実装されていない。
 - ◆ ピアグループを活用しない。
 - ◆ 性能評価が信頼に足らない。Solaris, Windows, Linux を合わせて150台でリニアな性能向上 ???

◆ XtremWeb, GreenTea, Javelin, Bayanihan, Ninflet, ...

- 資源提供者がジョブを選択できない。
- プログラミングモデルは、マスタ・ワーカや分割統治に限定。
- ファイアウォール越えが考慮されていない。
 - ◆ JavaRMI, HORB, TCP などを使用。
- 悪意あるワーカ対策を打っていない or 不明。

まとめ

- ◆ 計算機資源を容易に授受し、自由な並列プログラミングでそれらを連係、集約して活用するためのミドルウェア P3 を開発している。
 - 資源提供者は、自らの意志で、こういった処理に資源を提供するのかが決めることができる。
- ◆ 自由なプログラミングのために P2P通信ライブラリ JXTAを採用し、P3 の目的に対してその諸概念をいかに適用するかを提案した。
 - ピアグループと発見

まとめ

◆懸念される性能を評価した。

- 通信遅延は大きく、マスタの部分問題処理スループットを制限している。
- 通信のスループットは、 $100 \times 10^{**} 6$ bps 程度は出る。
- マスタの部分問題処理スループットは数十/秒であり、改善が望まれる。
- LAN では、部分問題の粒度が比較的細かい (0.7 秒) 場合でも、32台で20倍以上の性能向上を得られた。

今後



Personal
Power
Plant

◆ 研究的

- 参加ジョブ選択ポリシー & Host の自動運転
- ジョブのチェックポイントニング


◆ 実用的な有用性、品質に向けて

- 容易なインストールや、ミドルウェアの自動更新
- ネイティブコードのアプリケーションへの対応
 - ◆ C, C++, FORTRAN アプリ
 - ◆ ネイティブコード用サンドボックスを使用して、資源提供者が安心してアプリを実行できるようにする。
- アプリの実装を通じて要件を抽出し、P3 側からの支援を検討していく。
 - ◆ 例：気象のアンサンブル予報：2XX MB の大きな固定データを使う。

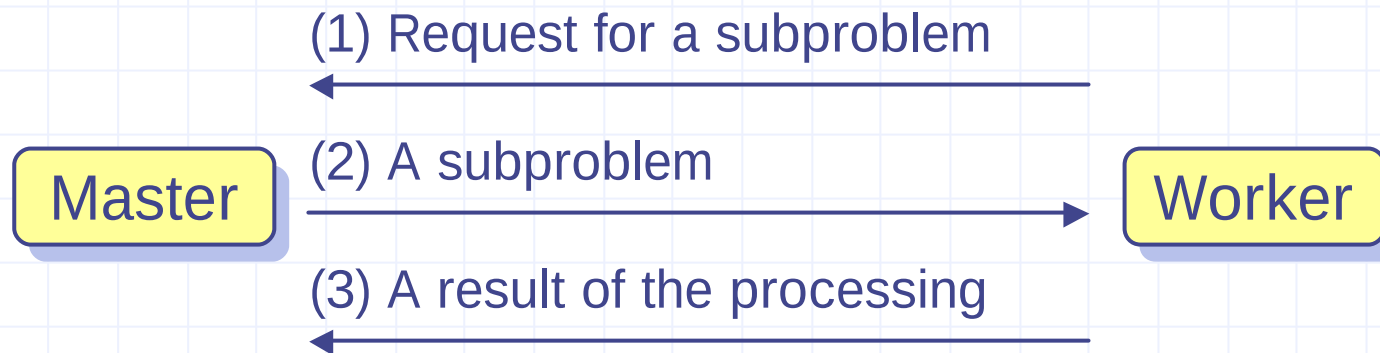
◆ その他たくさん

おまけ：TCP のスループット

◆ピンポン1000往復。



おまけ： マスタ・ワーカ間プロトコル



◆ 3-way


- (3) と (1) をまとめて 1メッセージで送ることで、2-way にはできる。
- しかしそれだけでは、10 ～ 100 倍の部分問題処理スループットは得られない。

P2P Supercomputing

2003年 5月の
IPA Spring 用資料

稼動環境

ソフトウェアとその機能



概要

遊休PCを用いた自由で容易な大規模分散処理を支援するミドルウェア。多量の計算やストレージを必要とする問題を抱えた利用者が、身のまわりやインターネット上のありあわせのPCを多数利用して、自分自身の手で、自由なプログラミングで分散処理を行うことを可能とする。

✓ テーマ名 組織内およびインターネット上の遊休PCを用いた大規模並列計算のためのミドルウェア

✓ 開発者 独)産業技術総合研究所