

リアルタイムストリームデータ解析フレームワークにおける センサ・クラウド間負荷分散の実装と性能評価

理学専攻・情報科学コース 黒崎 裕子

1 はじめに

一般家庭でカメラやセンサ等によりライフログを取得して、防犯対策やセキュリティ、お年寄りや子供のための安全サービスを目的としたライフログ解析アプリケーションが数多く開発されている。それらのアプリケーションを一般家庭で採用する場合、サーバやストレージを設置して解析までを行うことは難しいため、クラウドでの処理が必要となる。しかし、センサとクラウド間のネットワーク帯域やクラウド側の資源の制限により、クラウドに動画画像を含む多数のセンサデータを送信し、特徴量抽出等の前処理から解析までの全ての工程をクラウド側でリアルタイムに行うことは困難である。本論文は、前処理をセンサ側とクラウド側で負荷分散させることで、動画画像解析処理全体の高速化を図る。負荷分散機能をもつ Apache Storm(以降、Storm と呼ぶ)[1] を導入し、動画画像データ解析フレームワークを実装した。大規模クラスター環境においてネットワーク帯域を考慮した実験を行い、低帯域環境においてセンサ・クラウド間の負荷分散が有効であることがわかった。また、提案フレームワークの性能について、使用している Apache Storm に焦点を当ててより詳しく解析する。解析結果より、スレッド数が多い環境において、スレッドの再起動の際の sleep 時間を短縮することによって、性能が向上することがわかった。

2 ライフログ解析アプリケーションフレームワークの設計

本論文が提案する動画画像データ解析アプリケーションフレームワークの処理は、基本的に (1) 画像の取得、(2) 特徴量抽出 (前処理)、(3) 機械学習処理の 3 つのステップからなる。(1) では、OpenCV[2] を用いて WEB カメラから画像を取得、構造体に格納し、(2) のプロセスに構造体を渡す。(2) では、(1) で取得した画像を OpenCV[2] を用いて特徴抽出し、Bag-of-Features[3] による画像データのベクトル化を行い、ベクトル化したデータを (3) のプロセスに転送する。(3) では、(2) から受け取ったベクトルデータをもとにオンライン機械学習フレームワーク Jubatus[4] を用いて解析を行う。

動画画像データ解析をリアルタイムに処理するには、負荷の高い処理を適宜並行実行して高速化を図る必要があるため、分散型リアルタイム計算システムの Storm を導入し、図 1 に示すように、センサ側およびクラウド側で前処理を負荷分散処理するフレームワークを実装した。本節で説明した (1) はセンサ側、(2) はセンサ側とクラウド側で処理される。また、(3) の処理はクラウド側で行われるようにした。(2) の処理を全てセンサ側で行う場合は、クラウドへの通信量は少なくなるものの、前処理の負荷が大きくなる。(2) の処理を全てクラウド側で行う場合、前処理の負荷がクラウド側で分散できるものの、クラウドへの通信量が大きくなり、そのオーバーヘッドによる性能劣化が懸念さ




図 1: 提案するフレームワークの概要

れる。

3 提案フレームワークの性能解析

提案フレームワークの有効性を示すため、以下の 2 点に関して性能解析を行った。

1. ネットワーク帯域を考慮したセンサ・クラウド間負荷分散の評価実験
2. スレッド再起動時の sleep 時間の変化に伴う性能解析

Spout とはストリームデータを流し始める処理の起点となるプロセスで、Bolt は流れてくるデータの変換処理を行うプロセスを指す。各実験では経過時間あたりに完了した総ジョブ数を比較する。

3.1 実験概要

実験では、実装したフレームワークを用いて 2 種類の人の行動を判別する。予め 320×240 ピクセルの画像を 100 枚を用いて「ドアを開けた」状態と「イスに座った」状態を学習させる。次に、画像データを Spout で定義するストリーム生成時間毎にランダムに選出し、選出された画像データの特徴量抽出を行う。特徴量抽出における特徴ベクトル長である Visual Words 数は 100 に設定した。

構築した Storm クラスターは図 2 のような構成をとる。センサ側計算機、クラウド側計算機ともに、Intel Xeon W5590(3.33GHz, 4 コア) $\times$ 2 ソケット) を使用した。Supervisor ノードを 4 台用意し、1 台がセンサ側、3 台がクラウド側計算機であると想定する。Supervisor ノードには worker をコア数に合わせて 8 つずつもたせ、Supervisor ノードの 4 台のうち 1 台は Nimbus ノードとしても機能させ、クラウド側に配置する。また、クラウド側に Zookeeper を稼働させた計算機を 1 台用意した。

3.2 ネットワーク帯域を考慮したセンサ・クラウド間負荷分散の評価実験

センサ・クラウド間の負荷分散の有無による性能比較を、ネットワーク帯域を考慮して行った。Spout スレッド数を 2、ストリーム生成速度を 10ms/tuple とし、Bolt スレッド数を 16 と設定した。計測結果は図 3、図 4 に示す。縦軸は処理したジョブ数の合計を表




図 2: 実験環境

し、横軸は経過時間を秒で表す。センサ・クラウド間の帯域が 1Gbps と 100Mbps の場合の処理ジョブ数を比較すると、帯域を制限することによってジョブ数の大幅な減少がみられた。一方、センサ・クラウド間での分散処理の有無の比較では、1Gbps ではセンサ・クラウド間での分散処理の有無による性能差は見られなかったのに対し、100Mbps では、センサ・クラウド間での分散処理を行うことによる処理できるジョブ数の増加がみられた。よってネットワーク帯域が低い場合、センサ・クラウド間での負荷分散処理が効果的であることが示された。




図 3: 帯域を考慮した経過時間あたりの処理ジョブ数の比較 (1Gbps, 100Mbps)




図 4: 帯域を考慮した経過時間あたりの処理ジョブ数の比較 (50Mbps, 10Mbps)

3.3 スレッド再起動時の sleep 時間の変化に伴う性能解析

スレッド再起動時の sleep 時間の変化に伴う性能解析を行った。Storm ではスレッドが落ちて再起動を行




図 5: 経過時間あたりの処理ジョブ数の比較

う際、Topology が active かどうか定期的に判断し、active になればスレッド処理を開始する実装になっている。この時間を default 時の 100ms から 1ms に短縮させた場合、どのような性能差が出るかを解析した。Spout スレッド数を 4、ストリームデータの生成速度は 10ms/tuple とし、Bolt スレッド数を 16, 24 と変化した。sleep 時間は default の 100ms と 1ms の場合で計測を行った。

実験結果は図 5 に示す。縦軸は処理した総ジョブ数を表し、横軸は経過時間を秒で表している。Bolt 数 16 の場合は、ジョブ数の変化は見られなかったが、Bolt 数が 24 の場合、性能向上がみられた。これは、スレッド数が増えることによって、スレッドの停止、再起動が増えるため、sleep 時間を短縮することによって処理した総ジョブ数が増加したと考えられる。

4 まとめと今後の予定

本論文では、動画データ解析アプリケーションのリアルタイム処理を実現させるため、Storm を導入し、センサ側およびクラウド側で負荷分散処理する動画データ解析フレームワークを設計、実装している。実験より、大規模クラスター環境においてネットワーク帯域を考慮した実験を行い、低帯域環境においてセンサ・クラウド間の負荷分散が有効であることがわかった。また、提案フレームワークにおける Storm 部分の性能解析を行い、スレッド数が多い環境において、スレッドの再起動の際の sleep 時間を短縮することによって、性能が向上することがわかった。

本研究では、一定速度のストリームデータを対象に実験を行ってきたが、実環境では、動体検知した時に動画解析を行うため、ストリームデータ量が変動することが考えられる。今後は、このような大きく変動するストリームデータに対応できるよう、適切な負荷分散手法を開発する。

参考文献

- [1] Apache Storm, <https://storm.apache.org/>
- [2] 画像ライブラリ OpenCV, <http://opencv.org/>
- [3] Tomoyuki Nagahashi, Hironobu Fujiyoshi, “Object Category Recognition by Bag-of-Features using Co-occurrence Representation by Foreground and Background Information”, Machine Vision Applications, pp.413, 2011.
- [4] Jubatus, <http://jubat.us/ja/>