

画像処理を用いた汎用性の高い ネットワーク機器監視システムの提案

小川康一^{†1†2} 吉浦紀晃^{†1†2}

概要: 大学は、教育研究のために教職員や学生にネットワークを提供している。大学のネットワークは自由度が高く、利用者が自身の裁量でネットワーク機器を接続できる。このため、利用者がネットワーク障害を引き起こすことが多い。ネットワーク管理者は、障害が発生している利用者の居室で状況を把握しながら解決に当たる必要があり、大きな負担となっている。その上、利用者が使用するネットワーク機器は多種多様で管理機能が乏しい。そこで本論文では、利用者のネットワーク機器の状態を小型コンピュータに付随するカメラにより監視し、画像処理により正常状態か異常状態かを判断し、ネットワーク管理者の負荷を軽減するシステムを提案する。

キーワード: 監視システム, 画像処理, 機械学習

Versatile Monitoring System for Network Equipment by Image processing Technology

Kohichi Ogawa^{†1†2} Noriaki Yoshiura^{†1†2}

Abstract: Many universities provide a network to users such as faculty members and students for education and study. Users can freely connect network equipment to the network of the university by discretion of users. Therefore, many network troubles are caused by users. Network Administrators of the university has to confirm a status for a solution to network troubles on the room of users. The solution of network troubles is big burdens for network administrators. Besides, users have many kinds of network equipment, and management capability of network equipment is poor. This report suggests a system which reduces workloads of network administrators, by checking a status of the network equipment of users through a web camera in conjunction with a small computer and automatically determining whether the network equipment is normal status or abnormal status by image processing.

Keywords: Monitoring System, Image Processing, Machine Learning

1. はじめに

大学のように自由度の高いネットワーク利用環境では、ネットワークの利用者がネットワークの接続障害を引き起こすことが多い。利用者とは、主に大学の構成員である教職員、研究室の学生を指す。利用者は、大学の研究室や教員の居室で独自に用意したネットワーク機器を接続している。利用者の環境におけるネットワーク障害は、単にネットワークに繋がらなくなる場合や、極端にネットワークが遅くなるなどの事象によってはじめて利用者が障害に気づく。この障害は、イーサネットスイッチ内でのループ、ネットワーク機器の故障、LAN ケーブルの抜け、利用者の不注意によりネットワーク機器の電源抜けなどが原因であることが多い。しかし、利用者は障害がどのような原因で発生したか、どのように障害を解決したらよいか方法がわからないため、大学の情報センターに問い合わせる。このとき管理者は、大学の基幹ネットワークに異常がない場合、利

用者側に障害の原因があるものと判断する。結局、障害を放置するわけにも行かず、ネットワーク管理者が個別に利用者の部屋に出向き、障害対応に奔走することとなる。

通常、ネットワーク障害の検知は、管理ツールを用いた監視システムで行われる。監視システムとしては、オープンソースソフトウェアでは Nagios[1]や Zabbix[2]が、商用ソフトウェアでは JP1[3]や Tivoli[4]などがよく利用されている。監視システムでネットワーク機器を監視する場合、ネットワーク機器が備えた管理機能として、SNMP (Simple Network Management Protocol) といった監視プロトコルを用いて、機器の死活監視やネットワークの状態を確認する方法が用いられる。しかし、大学の利用者が用意するネットワーク機器は、機能が最小限であり、SNMP などの管理プロトコルを備えていない場合が多い。利用する機器は利用者の裁量で決まるため、メーカーや機器も多種多様でかつ頻繁に入れ替えが行われる。ネットワーク管理者が初めて目にするネットワーク機器も存在する。このため監視システムの利用は難しい。

そこで本研究では、ネットワーク機器を監視する場合に

^{†1} 埼玉大学情報メディア基盤センター
Information Technology Center, Saitama University

^{†2} 埼玉大学大学院理工学研究科
Graduate School of Science and Engineering, Saitama University

において、通常人間が機器の異常を調べる方法＝「目視」によって機器が正常か異常かをリアルタイムに判別する方法を提案する。埼玉大学は、光直収ネットワークを整備しており、利用者と管理を行うサーバ室の間でメディアコンバータを利用している。また、ネットワーク障害の多くを占めるイーサネットスイッチのループがある。画像処理技術を用い、メディアコンバータの LED 監視による状態把握、利用者のイーサネットスイッチの LED 監視による異常検知について検討を行った。

2. 関連研究

ネットワークの障害を検知する方法には、機器から収集したログを機械学習やデータマイニングの手法で分析する方法[5]があるが、機器のログ出力機能や SNMP などの監視プロトコルを備えた機器に限定され、利用者が普段使う簡易的な機器を網羅できない。また、端末から流れるパケットを分析することにより異常検知を行う方法[6]や、端末にエージェントを導入して監視する方法があるが、障害の原因が端末にある場合に限られ、利用者の持つ機器に起因する障害の把握は困難である。

機器監視への機械学習の適用例としては、産業機器の監視にデータマイニングや機械学習を用いる例[7]がある。画像認識技術を用いる具体例としては、アナログメータの値を確認する手法[8]やナンバープレートを特定する手法[9]、駐車場監視システム[10]など、目視に変わる研究やシステムがすでに存在する。しかし、ネットワーク障害の場合は、ネットワーク管理者が対象のネットワーク機器がどのような種類・性質のものをかを理解し、機器が正常状態か異常状態かを目視で判断する、といった特殊な能力が必要となる。大学には多くの研究室があり、監視すべきネットワーク機器も多く存在する。

本研究では、前提条件としてカメラは固定されており、また監視対象のネットワーク機器それ自体が移動する異常な動きをすることは考慮していない。監視カメラで検討されている人物の異常行動検知[11]とは目的が異なる。

3. 本学のネットワーク環境

本章では埼玉大学のネットワーク環境として FTTL と必要設備について述べる。

3.1 FTTL の導入背景（センターの説明）

本研究の背景として、大学で利用しているネットワーク設備の問題点が発端となっている。埼玉大学（以下、本学）は、学内ネットワークを構成するネットワーク機器の老朽化に伴い、2007 年から大学全体のネットワークを刷新する必要があった。新たな取り組みとして検討を進めた構想は、大学構内の各部屋とネットワーク機器を設置するサーバ室

とを光ファイバにより直接結ぶことであった。本学では、この取り組みを各家庭に光ファイバを敷設する“Fiber To The Home” (FTTH) になぞらえて、“Fiber To The Laboratory”（以下、FTTL）[12]と呼んでいる。

本学では、FTTL をはじめとした全学情報基盤システムを情報メディア基盤センター（以下、センター）が運用している。

FTTL を導入した狙いは、大学の情報基盤システムの運用スタッフが不足していることにある。多くの国公立大学では、運用スタッフである情報系センターの職員が不足している状況にある。少数の運用スタッフで管理を行うためには、障害が発生しにくいシステムの導入が前提である。障害が起きた場合でもトラブルシューティングが容易で、メンテナンスし易いことが重要である。利用者の端末がある部屋とネットワーク機器の途中に複数の機器が存在する場合、ループなどの障害自体が隠蔽され、発生要因が発見しにくくなる。一方、FTTL で必要となる機器は、光ファイバと LAN ケーブルとを変換するメディアコンバータだけであり、障害点となるネットワーク機器が途中に介在しない。このため障害箇所の特定が容易になっている。

しかし、利用者が引き起こすトラブルは後を絶たない。サーバ室で中央集中型になることによる管理上の利点はあるものの、これまでは建物ごとに独自に管理が行われ、利用者の居室での障害も建物内の管理者が行っていた。しかし、ネットワークの形態が光直収ネットワークになったことによって、これまで建物内で完結していたネットワークの不具合の相談や対応要請がセンターに頻繁に来るようになった。

3.2 光ファイバ直収ネットワーク（FTTL）

FTTL は本学の建物 44 棟にある部屋、約 1800 か所をシングルモード光ファイバで接続する光ファイバ直収ネットワークである。ネットワーク構造は、大学の中心に位置するサーバ室を中心としたスター型構成である。

光ファイバの配線は、ネットワーク機器が置かれたサーバ室と、建物内の光中継盤を経由し、サーバ室と各部屋が光ファイバにより直接結ばれている（図 1）。図中の「MC」はメディアコンバータ、「光」は光ファイバを表す。




図1 FTTLの概要

サーバ室は光ファイバ敷設にあわせて、講義室を改装し構築した。サーバ室には、各建物と接続する光ファイバケーブルが集線されている。



図2 各部屋の光パッチパネル（左）とメディアコンバータ（右）

利用者の各部屋には2心の光ファイバ1本が敷設されており、光パッチパネル（図2左）に收容している。各部屋には、LANケーブルをメディア変換するメディアコンバータ（図2右）を設置する。メディアコンバータは光パッチパネルと光パッチコードで接続して利用する。メディアコンバータは速度に応じて10/100M対応メディアコンバータ、もしくはギガビット対応メディアコンバータを用意している。

サーバ室には、各建物の中継盤に接続された光ファイバの幹線が4つの光パッチパネル収容ラックに集線されている。光パッチパネル収容ラックと集合メディアコンバータ間を光ファイバパッチケーブルで接続している。集合メディアコンバータとネットワーク機器とはLANケーブルで接続している。

利用者は、本学でネットワークを利用する場合にはメディアコンバータでの接続が必須となっている。利用者自身でメディアコンバータの電源確保やメディアコンバータと端末を接続するLANケーブルを準備している。利用者の不注意でメディアコンバータの電源抜け、光ファイバのパッチケーブルの接続抜けなど、利用者側の機器の使い方に

よる不具合が発生している。サーバ室に設置している集合メディアコンバータはSNMPの管理機能を持つが、1,800箇所あるMCの挙動から、利用者の状況を把握することは困難である。

4. 利用者へのサポートに対する課題

本章では本学の利用者に対するサポートの課題について述べる。

4.1 運用に関わるスタッフの不足

通常、ネットワーク管理は少数の技術者で行われるため、利用者のネットワーク環境を手厚く支援するまで手が行き届かないのが現状である。このような利用者に対する個別の障害対応は、ネットワーク管理者の大きな負担となっている。大学のインフラは、少数の管理者で運用されており、管理者の作業負担が増大するばかりである。

本学のネットワークの運用にあたるスタッフは、専任が1名で他数名のスタッフが専任スタッフを支援している。ひとたび障害が発生すると、同時に複数の障害対応は難しいため、順次対応していくことになる。

4.2 利用者環境のサポート

大学という教育研究機関の特性上、休日深夜においてもネットワークは当たり前利用される。対応にあたる職員勤務時間は定められており、対応にあたる企業に対する保守費用の財源も少なく、対応時間帯は限定されている。

このような背景から、利用者に対する個別の支援はおろそかになることが多い。しかし、利用者が抱えるトラブルを放置し、障害が継続することによって大学のネットワーク全体への悪影響を及ぼすこともある。ネットワークの不具合は教育研究への支障が大きいため、利用者への対応は課題となっている。




図3 利用者からの障害問い合わせ原因の内訳

2012年から2014年にかけて本学情報メディア基盤センターに寄せられた大学内の利用者からのネットワーク障害の相談、問合せに関して、その原因を集計したところ、全体の73%の障害が利用者起因であることがわかった。

った(図3)．主な障害の理由としては，研究室内のイーサネットスイッチのループ，ルータの故障，電源の抜けなどがあげられる．

5. 提案手法

本章では，本学でネットワークを利用する上で必須となっているメディアコンバータ，研究室でのネットワーク障害の原因となるイーサネットスイッチの監視手法について述べる．

5.1 LEDの状態把握による機器監視

前章で述べたとおり，利用者に対するサポートは対応する人員が限られているため，困難である．通常，ネットワーク管理者は障害の状況を把握する際に，問題がありそうなネットワーク機器を目視によって確認している．そこで，管理者の目の代わりとなる小型コンピュータのような機械に付随するカメラを用い，ネットワーク機器の状態を自動的に把握する方法を提案したい．

5.1.1 メディアコンバータの状態監視

本学で利用している利用者側のメディアコンバータには，4つのLEDが備わっている．それぞれ，電源ランプ，光のリンクアップ，イーサネットポートのリンクアップ，リンクスピードランプである．図4のようにすべてのLEDが点灯している状態が正常状態である．



図4. メディアコンバータの正常状態

一方で，図5に示すようにLEDが不完全な状態で点灯する場合がある．これらは利用者に故意に電源や，LANケーブルもしくは光ファイバを抜いたことに起因する．これらのLEDをオブジェクトとして識別して異常を検知する．



図5. メディアコンバータのLED表示パターン

(左上：電源断，左下：電源のみ，右上：光のみ，右下：LANのみ)

メディアコンバータは，LEDの点滅状態を把握することで5つのパターンに分けることができる(表1)．

表1. メディアコンバータの状態パターン

パターン	異常				正常
	1	2	3	4	
電源	×	○	○	○	○
光Link	×	×	○	×	○
LAN	×	×	×	○	○

5.1.2 イーサネットスイッチの状態監視

大学の研究室のネットワークでは多くの端末が接続しており，イーサネットスイッチがよく利用されている．イーサネットスイッチがどのような状態かを把握するために，情報を収集する必要がある．具体的には，LEDの点灯位置を把握するために，LEDのみを検出したい．二値化処理では，明るい部分は白く，暗い部分は黒く表示される．撮影した画像を白黒で表現する二値化処理を行い，LEDの位置を検出しやすくする．二値化処理後，LEDが白く一連の繋がった要素として表示されるようになる．この一連繋がった要素を「blob」(blob)という．blobの把握によって，物体の大きさや姿勢状態の把握が可能である．画像処理では，blobの形状を数値化で表現する．また，1つの画像内に複数のblobが存在するときは，各blobに一意の識別子をつけて個々のblobを識別するラベリング処理が行われる．このように，LEDをblobとして認識し，個々のLEDをラベリングによって識別可能であれば，イーサネットスイッチの状態を把握できる．図6はイーサネットスイッチのLED点灯位置を把握するための処理の流れを示したものである．




図6. LED点灯位置の把握処理

この手法では，監視の動画の一部分を利用する．これは信号処理で利用される「窓かけ」の手法である．窓かけとは長時間のデータから一部分の短時間のデータを抜き出すことである．この方法は，通信回線やCPU資源などを考慮した場合に有効であるが，データの一部分を抜き出して検知を行うため，異常の検知漏れが起きる可能性がある．大学のサービスレベルでは利用者対応の人的コストと比較して

も、問題のない程度であると考えられる。




図7 ラベリングによるLED検出の例
 (左:元画像, 右:LED検出後の画像)

図7にラベリングによってLED検出する例を示す。矩形によってLEDの範囲が正確にプロットされていることがわかる。

5.2 イーサネットスイッチのループ現象の把握

利用者の環境で多く発生するネットワーク障害の一つにネットワーク機器のループがある。この障害は、研究室のレイアウト変更や清掃などで端末に接続していないLANケーブルをイーサネットスイッチの空きポートに接続することが原因である。ループ時にはイーサネットスイッチのLEDが激しく点滅を繰り返す。この場合、LEDの状態を画像として複数枚連続で取得しても、見かけ上は常に同じ状態であり異常を認識できない。前節のメディアコンバータの監視手法やLEDの点灯位置の把握手法では対応できない。

そこで、LEDの点滅の頻度を把握するために、オプティカルフローにより、LEDの点滅動作を動作ベクトルとして抽出し、抽出した傾向を利用して機械学習によって異常を検知する方法をとる。図8は、イーサネットスイッチのLEDの点滅状態を撮影し、撮影した動画データにたいしてオプティカルフローを用いてベクトルの状態を描画したものである。




図8 LED点滅に対するオプティカルフロー描画の例

オプティカルフローとは、時間的に連続した画像列を用いて画像の速度場を求め、速度ベクトルによって物体運動の様子を検出する手法である。オプティカルフローの利用の前提条件として、動きによって画像間での対応点の輝度が

変わらないことが必要である。本研究では、イーサネットスイッチは移動しないため、対応点の輝度は変化せず採用可能であると考えられる。オプティカルフローの手法としては、勾配法[13]、Lucas-Kanade法[14]がある。

6. 実装

本章では、前章5.2で述べたイーサネットスイッチのループ現象の実装方法について述べる。

6.1 イーサネットスイッチ異常検知システム

提案手法を実装したシステムは、監視装置と画像認識サーバで構成される。システム構成は図9の通りである。監視装置にはWebカメラを接続し、監視対象のイーサネットスイッチの状態を動画で撮影する。データのノイズ除去や動画サイズの縮小などの前処理を行い、特徴量の抽出を行う。これらのデータはネットワークを通じて画像認識サーバに転送する。画像認識サーバでは、あらかじめ正常状態と異常状態を教師あり学習により学習させておく。あらかじめ学習した情報と、監視装置で取得した情報を比較することによって、正常状態か異常状態かを判断させる。




図9 イーサネットスイッチ異常検知システム構成図

実装には画像ライブラリとしてOpenCV[15]を用いた。OpenCVのバージョンは2.4.10である。実装に使用したプログラミング言語はPython 2.7、数値計算ライブラリNumpyを含むAnaconda2-2.5.0を用いた。

動きの特徴量の抽出については、Pekerの手法[16]を用い、動画のフレームごとの最大ベクトル量(Max0)を算出し利用する。実装は文献[17]を参考に実施した。算出にあたってはOpenCVの関数cvCalcOpticalFlowLKでLucas-Kanade法を用い疎な特徴集合に対するオプティカルフローを求める。これによりx方向の速度ベクトル v_x とy方向の速度ベクトル v_y が求まる。次にOpenCVの関数cvCartToPolarにより極座標変換を行い、先に求めたベクトル v_x , v_y を元に特徴量の大きさを算出する。

機械学習に用いる実装は、オンライン機械学習フレームワークであるJubatus[18]を用いる。採用した理由としては、あらかじめ機械学習のアルゴリズムが備わっており、実装

が容易な点とサーバを分散構築可能な点である。今回の事象は、平常時が継続的に続く中で異常な値が発見される「異常検知」ではなく、一定期間の LED 点滅の傾向を学習し、新たな状態との比較検証を行うので、Jubatus の機械学習アルゴリズムのうち「分類」を用いた。分類に使用するアルゴリズムは Jubatus に標準で利用可能な AROW (Adaptive Regularization of Weight vectors) [19]を用いた。学習に関する感度設定は 1.0 とした。監視装置およびサーバの仕様は表 2 の通りである。

表 2 監視装置、画像認識サーバの機器仕様

・ 監視装置		
PC		Intel NUC DN2820FYKH
	CPU	Intel Celeron 2.40GHz Dual Core
	メモリ	4 GB
	HDD	SSD120GB
	OS	Ubuntu 14.04.4 LTS
カメラ	Buffalo BSW20KM11BK	
・ 画像認識サーバ		
Server		HP ProLiant DL320G6
	CPU	Intel Xeon 2.53GHz Dual Core
	メモリ	8 GB
	HDD	SATA 600GB × 2 (RAID1)
	OS	Ubuntu Server 14.04.4

7. 実験

本章では前章で実装したシステムの検証として実験を行い、判別の正確さを確認する。

7.1 イーサネットスイッチ監視システムの検証

今回検証では、イーサネットスイッチとしてロジテック社製の 10/100Mbps, 5 ポート (型名: LAN-SW05/P) を用いた。実験の条件として、暗い室内でイーサネットスイッチのループ状態, 正常状態をそれぞれ 1 回あたり 30 秒間撮影する。これを 10 回ずつ繰り返し、取得した動画データから動きの特徴量を抽出する。結果の一部を図 10 に示す。

正常状態の際の特徴量は、小さい値で推移しているのに対し、ループした際の特徴量は中間部に多くの値が集まっていることがわかる。取得した他の動画データからも同様の傾向が現れていることから、機械学習器にこれらの特徴量を投入し学習させる。




図 10 動きの特徴量抽出例

(上: ループ状態, 下: 正常状態)

次に判別の検証に用いるテスト動画を準備する。ループ状態, 正常状態をそれぞれ 1 回あたり 30 秒間で 3 回ずつ、計 6 回分撮影した。このテスト動画から動きの特徴量を抽出し、訓練を行った機械学習器にかけ判定テストを行った。実験結果を表 3 に示す。Jubatus は、機械学習のフレームワークとして評価指標もあらかじめ定義されている。Jubatus の Client API[20]によれば、score とは、ラベルに対する確からしさの値で、score の値が大きいほど推定されたラベルの信頼性が高いことを意味している。テストデータのうち、1~3 が正常状態, 4~6 がループ状態である。いずれのテストでも当該の状態に対して score は高い値を示していることがわかった。

表 3 イーサネットスイッチ監視システム判定テスト結果

	1	2	3	4	5	6
正常	1.179227	1.009736	0.876641	0.121993	-0.0238	0.186229
ループ	-0.39924	-0.24146	-0.12336	0.932147	1.075903	0.758367

8. 課題

8.1 監視に利用するネットワーク

今回の実験では、監視に利用するネットワークを別途用意していない。監視に利用するネットワークは、監視ネットワークと別に用意する必要がある。コスト面から見ても必ずしも広帯域な回線を用意できるわけではない。このため、実際のシステムとして運用する際にはデータをクライアントやサーバそれぞれで処理しながら、相互で送受信す

るデータを最小限にするなどの工夫が必要と考えられる。

8.2 色に対する対応

今回の実装では、二値化した動画画像を用いて処理を行っているため、色の変化について対応がなされていない。イーサネットスイッチにおいて、色の変化は重要である。たとえば、通常時 100Base-T の機器が接続していて突然 LED の色が変わり 10Base-T の機器が接続されたよう表示がなされた場合、なんらかの異常があったと把握できる。色に対する対応については今後の課題である。

8.3 手法の組み合わせ

今回はイーサネットスイッチについてはどのポートが異常を示しているかを判別するまでに実装が至らなかった。メディアコンバータの状態判別で利用した BoF の手法とイーサネットポートの把握手法を組み合わせることで、詳細な状態判別が可能になると考えられる。また今回は試行ができなかったが、昨今研究が進められているディープラーニングの手法についても適用の可能性を検証したい。

8.4 環境変化への対応

今回は、一定の暗い部屋で固定化されたネットワーク機器の LED の形状分析にとどまっており、ネットワーク機器が実際に設置された環境を十分想定できていない。たとえば、太陽などの外乱光などの環境要因による画像の変化などが考えられる。特徴量の抽出方法の工夫や、他の機械学習アルゴリズムなどを利用して、環境に対しても堅牢な手法を検討する。

8.5 カメラのキャリブレーション

現状では、監視に入る前に監視対象の機器がどのような種類の機器かを把握する機能が備わっていない。たとえば、一般物体認識の分野で用いられる Bag-of-Keypoints[21]や Bag-of-Features といった手法を活用することで十分実装可能であると考えられる。機器の諸元が把握できれば、監視に必要な情報や最適な撮影箇所をネットワーク管理者に教示できる。また、ネットワーク機器の作りによっては、LED の表示部が他の LED と重なって見えるなど、角度によって見え方が異なってしまう場合がある。これには正しく一定の撮影箇所に合わせられるような治具などのアタッチメントの開発が必要であると考えている。

9. まとめ

本論文では、画像処理と機械学習によって、利用者のネットワーク環境にあるメディアコンバータ、イーサネットスイッチの LED を監視することで、その挙動を把握する手法を提案した。今後はより実用可能なシステムとなるよう実装を進め、課題の解決を念頭に実証実験により提案手法の有効性を証明したい。

参考文献

- [1] Nagios, <https://www.nagios.org/>
- [2] Zabbix, <http://www.zabbix.com/jp/>
- [3] JPl, <http://www.hitachi.co.jp/Prod/comp/soft1/jp1/index.html>
- [4] Tivoli, <http://www.ibm.com/software/tivoli>
- [5] 木村達明, “Syslog 分析による大規模ネットワーク故障診断技術-ネットワーク機器ログデータの活用-”, 電子情報学会会誌, Vol.98, No.9, pp.823-828, 2015.
- [6] 國吉賢吾, 森井昌克, “端末監視によるホームネットワーク異常検知システム”, 研究報告ユビキタスコンピューティングシステム (UBI), pp.39-46, 2009.
- [7] 鈴木英明, 内山宏樹, 湯田晋也, “産業安全を支える異常検知技術: データマイニングの活用による設備保守”, 電子情報通信学会誌 Vol.94 No.4, pp.305-309, 2011.
- [8] 藤田悠介, 浜本義彦, “画像処理によるアナログメータの読み取り”, 電気学会論文誌.C, 電子・情報・システム部門誌, pp.901-908, 2009.
- [9] 加藤武他, “自動ナンバープレート読取装置の開発”, 2012 年 7 月・SEI テクニカルレビュー, 第 181 号, pp.99-103, 2012.
- [10] 前佑樹, 波部齊, 柴田智広, “機械学習を用いた屋外カメラによる駐車場監視システムの開発”, 電子情報通信学会技術研究報告, pp.165-169, 2012.
- [11] 小川宏高, 中田秀基, 工藤知宏, “多数の動画画像を対象とするリアルタイム異常値検出の検討”, 情報処理学会研究会報告, 2013-HPC-139, pp.1-6, 2013.
- [12] 小川康一, 吉浦紀晃, “埼玉大学における光ファイバ直収型ネットワークの運用経験について”, 研究報告インターネットと運用技術 (IOT), 2015-IOT-30, pp. 1-8, 2015.
- [13] O.D. Faugeras, “Three-Dimensional Computer Vision”, A Geometric Viewpoint. MIT Press, Cambridge, MA, 1993.
- [14] B. D. Lucas and T. Kanade, “An Iterative image registration technique with an application to stereo vision”, Proc. Of imaging understanding workshop, pp.121-130, 1981.
- [15] 画像ライブラリ OpenCV, <http://opencv.org/>
- [16] K. A. Peker and A. Divakaran, “A novel pair-wise comparison based analytical framework for automatic measurement of intensity of motion activity of video segments,” Multimedia and Expo, 2001. ICME 2001. IEEE International Conference on, Tokyo, Japan, 2001, pp. 729-732.
- [17] デジタル映像分析 OpenCV による映像内容の解析, カットシステム, 2012.
- [18] オンライン機械学習向け分散処理フレームワーク Jubatus, <http://jubat.us/ja/>
- [19] Koby Crammer, Alex Kulesza, Mark Dredze, “Adaptive Regularization of Weight Vectors,” Advances in Neural Information Processing Systems 22, pp.414-422, 2009.
- [20] Jubatus References, Client API, http://jubat.us/ja/api_classifier.html
- [21] G. Csürka, C.R. Dance, L.Fan, J.Willamowski, and C.Bray, “Visual categorization with bags of keypoints,” Proc. ECCV2004 Workshop on Statistical Learning in Computer Vision, pp.1-22, May 2004.