車種別交通量調査における物体追跡法の改良

大久保　順一[1]・菅原　宏明[2]・藤井　純一郎[2]・小篠　耕平[2]

[1]非会員　八千代エンジニヤリング株式会社（〒111-8648 東京都台東区浅草橋 5-20-8）
E-mail: jn-okubo@yachiyo-eng.co.jp

[2]正会員　八千代エンジニヤリング株式会社（〒111-8648 東京都台東区浅草橋 5-20-8）

交通量観測に深層学習と物体追跡法を応用した安価なシステムを提案する．深層学習としては Caffe SSD を採用，国土交通省が実施している全国道路・街路交通情勢調査の 7 クラスの車種判別を行う．深層学習の出力を時系列で，物体追跡法を使い，通過カウントを行う．本手法にて目視に比較して 95%以上の精度を達成した．物体追跡法としては，セントロイドトラッキングを採用して，これに補助情報として方向，車種区別，存在区間を加えて判別するようにアルゴリズムを改良した．

Key Words: *deep learning, traffic counting, object tracking, classification*

1.　はじめに

交通量観測には道路管理者が設置している交通量常時観測装置の結果を用いる方法，簡易型トラカン（路面設置型，路側設置型など）を設置して交通量を観測する方法，人手により観測する方法，などが存在する．交通量の常時観測装置は支柱等の高さ 6m 程度に設置されており，超音波や光ビーコンにより計測するため機器設置の工事が必要となる．さらに，現在実用化されている交通量調査向け画像解析システムにおいても高所から撮影された映像の使用を想定しているものが多い．

本研究では車両カウントシステムを低価格化して汎用性を広げることを狙いとして，家庭用ビデオカメラと市販の三脚という入手と設置が容易な既存の装置を用いて録画した画像（動画）から，AI を用いて解析する．この中ではフレーム画像を追跡（トラッキング）して，車両を特定する技術について試行を行った．従来型の観測ではカウントは，カウント線を横切った時というような方式になり，そもそも物体追跡（オブジェクトトラッキング）は必要としない．

本提案の方式ではフレームトラッキングが，車両カウントの正確性にかなりのウエイトを占めている．

2.　既往研究と本研究

2.1　交通量調査への AI の応用に関する既往研究

交通調査に関する AI の応用については，例えば国土交通省は ETC2.0 の活用と AI カメラの活用について検討している．

また，星野ら[1]は ETC 車載器の製造時に割り当てられる固有の情報であるワイヤレスコールナンバー（以下，WCN）を用いた生活道路調査の適用可能性についての研究を行った．WCN 路側観測器を地上から高さ 6m に設置した場合の WCN の取得率は 61.7%，高さ 2m に設置した場合の取得率は 35.0%であり設置高さによって精度に大きく差が表れている．

岩﨑ら[2]の研究ではネットワークカメラを 6m の高さに設置し画像解析した結果，車両を囲む短形の面積から大型車両，小型車両の区別が可能であった．しかし，大型車両の誤認や車両の影の影響を受けるといった課題も明らかになった．

2.2　物体追跡についての既往研究

物体追跡についての既往手法としては背景差分法とフレーム間差分法がある．背景差分法は野外環境でのロバストネス性が低い傾向があるとされている[3]．

物体追跡についてはオプティカルフローが使われる場合が多い．

例えば，車両を対象とした物体追跡について，藤岡ら[4]の研究では，水平エッジについてヒストグラムを用いて，テンプレートマッチングを行うことで実装している．

また OpenCV のような汎用ライブラリでも，オプティカルフローによる物体トラッキングは実装されており，利用が可能となっている．

この手法は，画像をフレーム毎に光学的解析を行い，特徴量としてヒストグラムを算出し，フレームとフレームのヒストグラムを比較することで，一致箇所を求める方法である．

従って，フレームを処理する分の計算時間が必要となり，専用ハードウエアチップなどが必須となる場合が多い．

鈴木ら[5]は一般ビデオを用いて画像処理ライブラリを使用し光学的解析を実行することで，汎用コンピュータ上は 95%という精度を上げ，高い位置からの画像解析をおこなっている．

この高い位置からの画像解析は，後述する前方の車両に後方の車両が隠れてしまうオクルージョンの問題が起きにくいので有効であるが，設置に柱などが必要で，労力を必要とするため高額なものとなる．本研究では，三脚などで低い位置（1 m29 cm程度）からの撮影を前提とした．

2.3 本研究の提案手法

本研究では車種別交通量を検出する．そのためには車両クラスを判別する必要がある．そこで，深層学習の画像認識手法の一つである Single Shot MultiBox Detector[6]（以下，SSD）を車両クラス判別に適用した．

これは一般的なオブジェクト分類モデルとして多くの実績があること，また近年のグラフ共通化やグラフコンパイルの手法によりハードウエアに依存せず，エッジ機器での稼働が可能なことの理由から選定した．

図-1 に SSD による検出結果のフレーム画像を示す．赤線が教師領域で，緑線が検出領域となる．SSD ではこのようなフレーム画像が，1 秒間に 10 フレーム以上認識可能である．

図-2 に本研究での提案手法を示す．入力はビデオデータとしており，録画したデータもしくはリアルタイム入力を使うことができる．

SSD のオブジェクトクラスとしては，乗用車，バス，小型貨物，普通貨物，歩行者，自転車，その他二輪の 7 クラスを分類することとした．これは国土交通省が実施している全国道路・街路交通情勢調査のクラスわけに準拠している．

フレーム画像から車両カウントをおこなう為には，どのフレームからどのフレームの間出現しているかを追跡（トラッキング）する必要がある．

トラッキングをおこない車両が同一であることを判定して，そのオブジェクトを車両としてカウントする．

図-1　認識結果

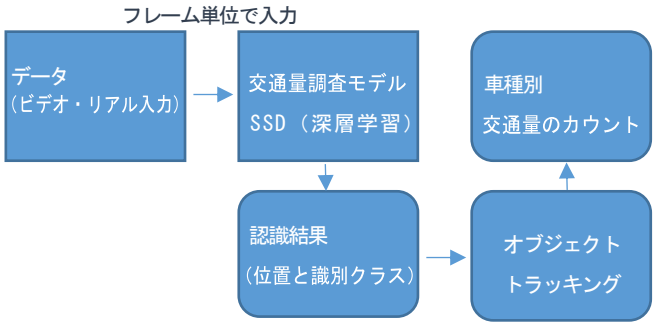

図-2　深層学習による交通量観測手法

これが本論で示すところのオブジェクトトラッキングの使い方である．オブジェクトトラッキングの前段の深層学習の結果で，すでに車両の領域（バウンディングボックス）の座標値が得られており，深層学習の結果の値を処理することで，オプティカルフローで利用されるようなフレーム単位での特徴量の抽出処理を行う必要がなく，演算のコストを下げ，かつ精度を維持していくことができると考えた．この新たに構築したシステムは TRAVIC と名付けた．

TRAVIC はグラフコンパイルの手法を用いることでインテル i7CPU を搭載したパソコンで動作する．またビデオ画像については汎用のビデオカメラで撮った画像を解析することが可能となっている．

3. 実証実験

実証実験は，令和 1 年度に千葉県習志野市と地方部の大学でおこなった．習志野市では 2 時間の撮影と人手でのカウントをやり，地方部の大学においては日中のビデオ撮影をした．

この実験で得られたビデオ及び人手でのカウントを基にして研究を進めた．

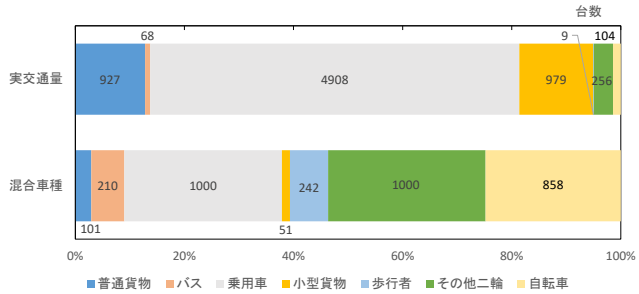

図-3　車種区分別割合

3.1 深層学習の構築

一般に SSD を用いる場合には COCO データセットを基にすることが多い．しかし本研究では，COCO データセットでは単に「車」と分類されているものをさらに細かく分類する必要があるため，あらたに今回の実験で得られたビデオから，データを作成した．（COCO データセットはフォーマットのみ利用し画像は利用していない）

深層学習の構築には 2 万枚の画像のアノテーションを行い，この中から 1 セット 2000 枚のデータセットを作成して，このデータセットを SSD で学習させることによって，深層学習モデルを作成した．

図-3 に示す学習セットを構築するときは，実際の交通流の車種別台数比に従った台数比にしたものと，深層学習でできるだけバリエーションの多い画像を学習させることにより精度がよくなる．そのため今回は，それぞれの車種比について，できるだけ均一になるような学習セットを構築してこれを比較した．

アノテーションはフレーム単位で行うため，1 枚のフレームに含まれる画像が実際の交通流の台数比に従う（フレーム単位にすると 1 台だけということは少なく通常数台の車両が映る）．そのためフレームは人手で選り分け，各車両が均一になるようなフレームの選定を行い，データセットを構築した．

3.2 深層学習の精度

次に今回採用した深層学習について単独での精度に触れる．

単独での精度とは，1 フレーム単位で予測した，オブジェクトと座標とクラス，あらかじめアノテーションを行ったオブジェクトの座標とクラスについての一致率を示す．

図-4 に示すように学習は 20 万回おこない，4 万毎に損失値を調べて学習の精度を確認した．

12 万回の学習で損失値が低く，この付近の学習結果の精度は高い．また混合車種と実交通量を比較すると，実交通量で早く損失が低下しており，過学習を起こしていた．

実交通量とは実際の交通量の車種割合からデータセットを作成したもので，混合車種とは，データセット中での 7 クラスの車種の数がなるべく等しくなるように作成したデータセットでの認識結果である．

このように混合車種の方が認識結果は良く，これは深層学習のデータ作成において，できるだけ同一でない画像を用いると精度が高くなるという，多くの論文結果と一致している．

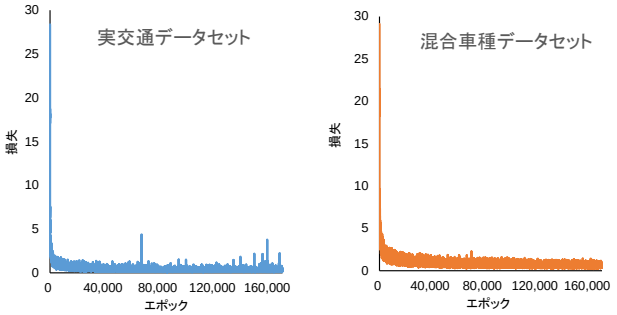

図-4　損失値

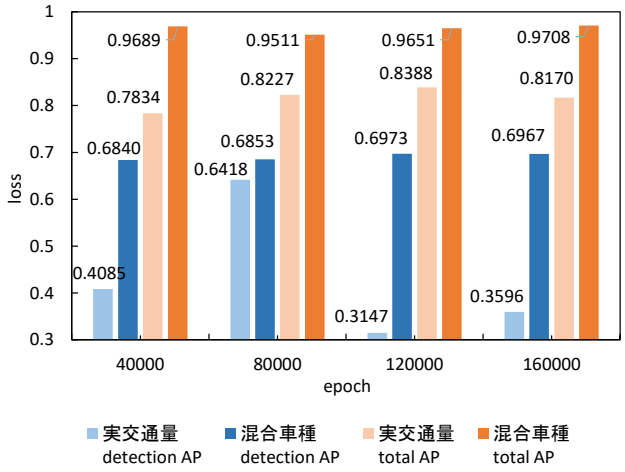

図-5　精度評価

図-5 に実際の精度について示す．12 万 epoch から 16 万 epoch で高い検出率を示す．detectionAP は車種区分と車両カウントの両方があっている場合を示し，totalAP は車両カウントのみあっている場合を示す．車両カウントはいずれも高い数値を示すが，車種区分を間違える場合が多くみられている．

車両区分は例えば小型貨物にみられるように，実際には形状は同じでも車両登録区分が異なることによって，車両区分が異なることになり，このような場合にはナンバープレートを見ないと正確な区わけができない．

4. 物体追跡法（トラッキングアルゴリズム）

本提案では，オブジェクトトラッキングアルゴリズムとしては Centroid Tracking[7]を用いてこれを改良していった．

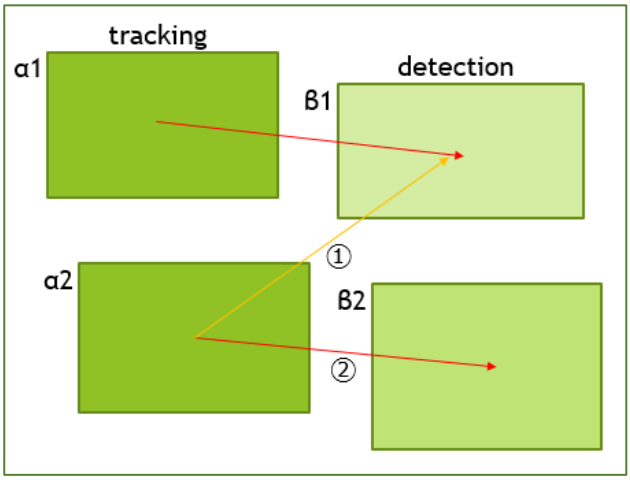

図-6　セントロイドトラッキング

4.1 セントロイドトラッキング

セントロイドトラッキングとは，あるフレームで認識されているトラッキングオブジェクト系列　$\alpha=\{\alpha1,\alpha2\cdots\}$ に対して，次のフレームで認識されているディテクションオブジェクト系列　$\beta=\{\beta1,\beta2\cdots\}$ との対応付けをして，オブジェクト間の同一性を特定していく手法である．通常，α 系列のエレメントをそれぞれ β 系列のエレメントに対応付けていく．

例えば図-6 に示すような α2 が β2 に，と順序付けて対応させていく場合，セントロイドトラッキングでは，α でのオブジェクトそれぞれの重心位置と β での各オブジェクトの重心位置とのユークリッド距離を計算して，このユークリッド距離が最短のものが，もとのオブジェクトに対応するという考え方である．

図-6 でいうと，α2 に対して①と②のユークリッド距離を計算し，短い方を採択する．

セントロイドトラッキングは，各オブジェクトの移動量が等しいか，あるいは一定のレンジに収まる場合に有効な手法である．

アルゴリズムの特徴として，フレーム毎のオブジェクトの個数の積の個数の距離の中から探索するので，探索空間が非常に小さくなることが特徴である．

セントロイドトラッキングは，方向を不定に変えていくような物体のトラッキングに有効なアルゴリズムであるが，計算量の少なさと，交通量調査に特化したアルゴリズムの改良を加えることで，十分実用に耐えるのではないか，という仮説の元に改良を開始した．

4.2 セントロイドトラッキングの改良

(1) 問題点

現実の交通量の動きでは，渋滞による停止，微速での移動などの状態がある．また停止している場合にも深層学習によって得られる座標は，常に微動するという特徴をもつ．このことを考慮に入れる必要もある．

また交通量トラッキングの大きな問題として，オクルージョンの問題がある．これはカメラ側を通過した車の背後に別の車が入ってしまうことにより，トラッキングができなくなる問題である．

本研究でのセントロイドトラッキングへの入力値は，画像認識の結果フレームの各オブジェクトの位置とクラスを使う．この座標値は，画像認識の予測値となるため精度が 95%となっている．しかし例えば，n フレームにおいて存在した車両が n+1 フレームでは消失して，n+2 でまた認識されるというようなケースも存在している．

深層学習の精度を高めて，前述のケースが少なくなるよう努力を続け，セントロイドトラッキングを改良し，このようなケースについてもトラッキングを続けることが必要になった．

(2) 付加的情報による一致度検出

今回のタスクでは，座標位置情報以外の特徴量を補助的な，オブジェクト特定手段として用いる．

オブジェクトクラスを出力できるので，オブジェクトクラスをオブジェクトの同一性の担保のためのひとつの条件とすることができる．

また道路交通では，2 車線の場合は上下線のように，各オブジェクトが移動する場合の方向性により，クラスタリングがおこなえるという特性もある．

このことから従来の重心の位置間のユークリッド距離だけを用いるものに加えて，同一性担保のためのオブジ

ェクトクラスと移動方向クラスターという条件を加味することで前述した，オブジェクト消失の問題を回避して，性能をあげることができると考えた．

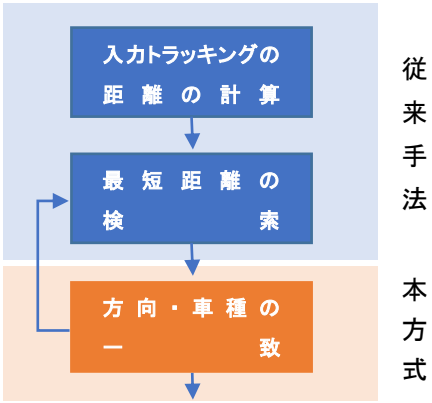

図-7　改良部分

図-7 は改良部分を示す．図のようにセントロイドトラキングアルゴリズムは，最初に入力フレームとトラッキングフレームの間でのユークリッド距離のマトリックスを作成する．次にこの距離マトリックスを探索して，それぞれの最短のものを採用していく．

本提案ではこの距離マトリックスの探索の直後に，先ほど述べた方向と車種の要素のマッチングをさらに行う．このマッチングではずれたものについては再探索を行い，別のオブジェクトとのマッチングを行う．

この再探索により間違った検出が減り，精度があがるというように考えた．

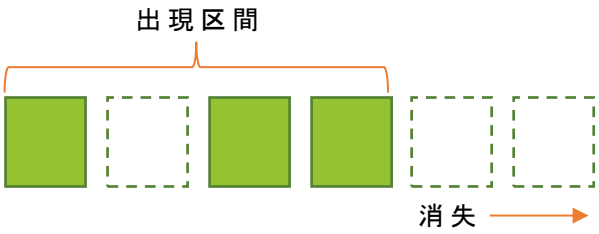

図-8　出現区間パラメータ

(3)　出現区間パラメータ

オクルージョンや先に述べた深層学習の特徴であるフレームミスなどに対応するために，図-8 のようなセントロイドトラッキングに出現区間パラメータを持たせた．これはオブジェクトの検出フレーム単位で見ていくと，一定区間続くことになる．

この区間は車両の速度に依存し，通常の交通の流れであれば短く，渋滞が発生した場合には長くなる．

出現区間パラメータは，この区間内ではセントロイドトラッキングの条件に一致しない場合でも仮想的にトラッキングを続けて、この区間を過ぎた場合に初めてトラッキング状態から離脱させるというアルゴリズムである．

このアルゴリズムによってオクルージョンが起きている場合でも，車両をカウントし続けることが可能になった．

データの中で実験の初期に低速度領域でのトラッキングの重なりなどの現象が発生したが，これについてはパラメータを調整していくことで解決した．

(4)　精度評価

精度評価は，実際の交通量調査の動画の中から，6 地点を取り，それぞれ 10 分間の交通量を，ビデオを目視でカウントしたものを正答として，本方式によって予測されたカウントとの比較によって評価を行った．

また正答とは，車両として認識されていて，かつクラスも正しく判定されているものを正答としている．

表-1　カウント比較

		成田街道 地点1	成田街道 地点2	成田街道 地点4	大学 東口出口	大学 南口出口	大学 北口出口
台数	目視	148	14	128	58	83	104
	TRAVIC	145	14	130	65	66	104

表-2　正答率比較

		改良前1	改良前2	改良後
台数	目視	145	145	145
	TRAVIC	194	176	145
正答率		74.7%	82.4%	100.0%

表-2 のように出現区間パラメータの改良アルゴリズムで 74.7%，改良後のアルゴリズムの平均で 82.4%となり，改良により向上していることがわかる．

図-5 の深層学習単体での detectionAP をいずれも上回る性能を出すことができた．

深層学習での精度はフレーム単位での精度であるが，トラッキングをおこなうと，複数フレームでの結果となるので，あるフレームでは消失したオブジェクトを別のフレームで検出し，結果としてカウントの精度は上がることになる．この事が深層学習での精度と比べてカウント精度が上がっている理由と考えられる．

精度としては図-9 に示す通り，目標とした 90%を各地点

で平均した数値で達成することができた．しかし細かく分析すると，地点により良い精度をあげているところとそうでないところがあることがわかった．

成田街道を使ったデータでは精度が良く，地方部の大学を使ったデータでは精度が悪い．

これは，一般の街道での，交通流の流れが一定方向であるのに対して，駐車場の出口では，一定方向ではない流れであることが影響していると思われる．

また今回の深層学習モデル構築に使ったアノテーション画像が成田街道のものだけから構築したために，深層学習の汎化性能が不足しているというようにも考えられる．

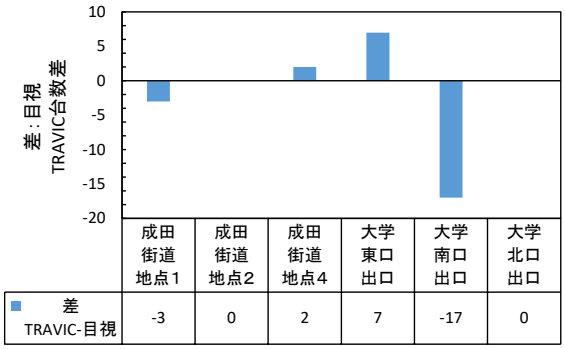

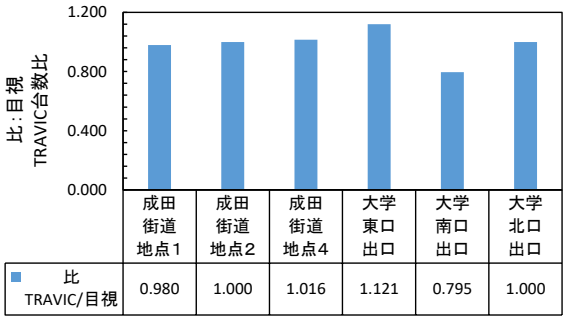

図-9　精度グラフ

5.　最後に

5.1　結論

本研究では，簡易な手法で撮影した画像を用いてAIによる車種別の交通量カウントのためのセントロイドトラッキングの改良について示した．この方式は有効な方式であることがわかった．

5.2　課題

本文でも述べたように，交通流の状態により精度が低下してしまう場合がある．低速度域についてダブルカウントが発生してしまうことが大きい．

今回は実験が 2 か所であったので，今後実験箇所を増やして，実際の交通流のさまざまなパターンに対応できるようにパラメータを調整していき，精度を高めていくようにすることが必要である．また深層学習側でのモデルの改良とトラッキングアルゴリズムの改良という２つの方向を合わせて精度をあげていかなくてはならない．

また車両分類を行う場合に，小型貨物と乗用車の分類において，同一車種で車両登録によって小型貨物か乗用車かがわかれてしまうような車種も存在する．このような車種については，深層学習における画像判定では判別することができないため，ナンバープレートについても認識をおこない，セントロイドトラッキングにおける今回付け加えた判別機能の中に加えて，より一層高い精度を目指す必要がある．

参考文献

1) 星野一輝，小嶋文，市本哲也，鈴木達也，上田透，片山賢治，久保田尚：WCNを用いた生活道路調査の適用可能性に関する研究，土木学会論文集 D3，Vol. 74，No. 5. pp. I_817-I_826，2018.

2) 岩﨑洋一郎，永村幸大，中宮俊幸，岩本祥二郎，宮田俊彦，倉本俊昌，北島俊孝，瀬戸口恵：交通量調査自動化のためのネットワークカメラを用いた交通流計測手法，電気関係学会九州支部連合大会講演論文集，pp.19-20，2015.

3) 堀武司，波通隆，飯島俊匡：実環境における移動体の検出・追跡技術に関する研究，北海道立工業試験場報告 No.305，pp.9-15，2006.

4) 藤岡明紘，中村靖：自動車運転支援システムのための単眼車載カメラによる前方車両検出，情報処理学会全国大会講演論文集，pp.179-180，2012.

5) 鈴木一史，中村英樹：交通解析のためのビデオ画像処理システム TrafficAnalyzer の開発と性能検証，土木学会論文集 D，Vol. 62，No. 3. pp. 276- 287，2006.

6) Wei Liu，Dragomir Anguelov，Dumitru Erhan，Christian Szegedy，Scott Reed，Cheng-Yang Fu，Alexander C. Berg: SSD:Single Shot MultiBox Detector，arXiv:1515.02325，2016.

7) J.C.Nascimento，A.J.Abrantes，J.S.Marques: An algorithm for centroid-based tracking of moving object，IEEE，1999.

(Received June 30,2020)
(Accepted July 31,2020)

OBJECT TRACKING ON TRAFFIC COUNTING IMPROVE METHOD

Junichi OKUBO, Hiroaki SUGAWARA and Junichiro FUJII and Kouhei OZASA

We propose using Centroid tracking for traffic counting. We use normal video camera instead of specially design for traffic counting system. We also design dataset for traffic counting by mixture picture for each category. We also en-hance COCO dataset tools to handle our dataset. Using mixture category dataset we can improve detection.