

スマート都市監視を実現する富士通の Deep Learning技術

Fujitsu Deep Learning Technology that Enables Smart City Monitoring

● 木下 修平 ● 若槻 政幸 ● 堀之内 省吾 ● 田辺 聡
● 東 明浩

あらまし

安価なIPカメラの普及により、世界中のあらゆる都市で監視カメラの台数が爆発的に増加している。これを有効活用するため、AI(人工知能)によるスマート都市監視が注目されている。富士通では、2018年3月にスマート都市監視用ソリューションFUJITSU Technical Computing Solution GREENAGES Citywide Surveillance V2の提供を開始した。Citywide Surveillanceを支える基盤技術はDeep Learningであり、これをビジネスに適用するには、基本性能となる解析精度、処理速度、および導入コストを満足することが重要である。更に、Deep Learningのみでは顧客に価値を提供することは難しいため、その周辺技術も併せて整備する必要がある。

本稿では、上記の精度、速度、コストを満足するための富士通の技術および顧客に価値を提供するための共創型の取り組みについて述べる。また、Citywide Surveillanceのビジネスへの活用事例を紹介する。

Abstract

With low-cost IP cameras readily available across the world, the number of monitoring cameras installed in major cities has seen a dramatic rise. Smart City Monitoring based on AI is garnering attention as a means of making efficient use of these cameras. In March 2018, Fujitsu launched its new smart city monitoring solution FUJITSU Technical Computing Solution GREENAGES Citywide Surveillance V2. Citywide Surveillance is based on deep learning technology, and in order to apply this suite to a business operation, there are challenges to address in terms of accuracy, speed, and cost as fundamental features. Furthermore, as deep learning alone cannot deliver the value customers want, it is necessary to develop auxiliary technologies at the same time. This paper explains the Fujitsu technologies that bring customers the needed accuracy, speed, and cost performance as well as our co-creation initiatives to deliver value to our customers. We will also describe a case in which Citywide Surveillance is applied in a business context.

まえがき

安価なIPカメラの普及により、街の至るところに監視カメラが設置されるようになってきた。矢野経済研究所の調査によると、世界の監視カメラ出荷台数は2018年には4,320万台に上り⁽¹⁾国内では国際的なスポーツイベント需要もあり、2020年に260万台に達すると予想されている⁽²⁾。このような状況の中、住民、建物、所有物の安心・安全を確保するために、監視カメラを有効活用するニーズがますます高まっている。

一方、安全確保の対策は、主に運用者によるビデオの目視確認に頼っているのが実情である。しかし、目視による監視はコストの低減が難しく、近年AI（人工知能）を活用したビデオ監視（以下、スマート都市監視）が注目されている。このスマート都市監視への期待として、街中の監視カメラを利用した特定の人物や車両の探索、不審者の監視などがある。また、最近ではスマート都市監視は安心・安全確保のための利用にとどまらず、マーケティングや交通などの分野にも活用されている。例えば、店頭でのお得意様の認識、交通量や混雑率・集客率の自動計測による動線の最適化、接客への活用が挙げられる。

このような状況の中、富士通はスマート都市監視用ソリューションFUJITSU Technical Computing Solution GREENAGES Citywide Surveillance V2の提供を開始した。

本稿では、Citywide Surveillanceを支える技術

および活用事例について述べる。

Citywide Surveillanceの概要

富士通は、Deep Learningに代表される機械学習を画像・映像解析に適用し、インテリジェントな監視を実現するCitywide SurveillanceパッケージV1を2016年10月にリリースした⁽³⁾。以後、国内外の公共機関や企業に提供してきた。更に、多くの顧客からの追加要望を実現するために、バージョン2（V2）を2018年4月にリリースした。

Citywide Surveillance V2は、監視カメラの映像あるいは静止画像を使用して、車両・人物に関する以下の認識・属性分類機能を有する（図-1）。

（1）車両

車両を認識し、車種、メーカー、車両の色の属性を分類できる。また、ナンバープレート解析機能、画面上で設定したエリアやラインに対するエリアごとの車両数カウント機能、ライン通過車両数カウント機能を有する。

（2）人物

人物を認識し、服装の種類・色、顔の属性を分類できる。また、画面上で設定したエリアやラインに対するエリアごとの人数カウント機能、ライン通過人数カウント機能、飲食店などにおける座席位置自動推定機能を有する。

Deep Learningのビジネス適用への課題

Citywide Surveillanceを支える技術の根幹は、Deep Learningである。2012年に発表されたDeep



図-1 Citywide Surveillanceの解析機能

CNN⁽⁴⁾を皮切りに、Deep Learningの研究は現在精力的に進められている。Deep Learningを活用するには、一般的にGPU（Graphics Processing Unit）を使用する。しかし、高価なGPUが必要なことや、Deep Learningのみでは結果を顧客に提供するのが難しいことから、実用例はまだ少ない。そこで、本章以降ではDeep Learningのビジネス適用に焦点を当てて述べる。

Deep Learningのビジネス適用において、筆者らが考える課題は二つある。一つ目は、Deep Learningの基本性能となる解析精度と処理速度、そして導入コストを満足することである。二つ目は、Deep Learning技術をソリューションにつなげるための周辺技術の整備・確立である。

(1) 精度、速度、コストの課題

Deep Learningで得られた結果の優劣を判断する際に、解析精度に注目することが多い。しかし、Deep Learningをビジネスに適用する上では、処理速度やGPUメモリ消費量も重要な要素となる。大容量メモリを搭載する高性能なGPUは非常に高価であり、顧客の導入コストが高くなってしまいうため、その対策が必要である。

(2) Deep Learning周辺技術の整備

Deep Learningを活用し、顧客にソリューションを提供するためには、Deep Learning単独では不十分であり、その周辺技術の整備・確立が重要となる。その候補は無数に存在するが、筆者らはよりビジネスに直結した技術を優先して整備・確立するため、顧客と共創型のアプローチに取り組んでいる。

精度、速度、コストを満足するための富士通の技術

富士通は長年培ってきた技術を基に、AIをビジネスに活用するために様々な取り組みを行っている。本章では、Deep Learningの精度、速度、コストを満足するための技術を紹介する。

● Deep Learningによる高精度な色識別の実現

Deep Learningの精度を高めるためには、二つのアプローチがある。一つ目は、モデルの階層をより多層構造とするなど、学習モデルを改良することである。二つ目は、高品質な学習データを数多く集めて学習させることである。筆者らは両方のアプローチに取り組み、学習モデルの改良と学習データの拡充に努めている。本章では、二つ目の

アプローチの例として、Deep Learningによる車両の色分類技術を紹介する。

色分類において問題となるのは、学習データ作成者の色覚に個人差があることである。例えば、同じ車両の画像でも青と分類する人もいれば、緑と分類する人もいる。このように学習データを用意する際に人によって基準が異なると、Deep Learningの学習時に発散してしまい、精度が上がらない一因となる。

そこで筆者らは、色の三属性⁽⁵⁾である、明度（Brightness）、彩度（Colorfulness、鮮やかさ）、色相（Hue、赤や緑などの色味）に着目し、人間の目の特性に基づき色判定ルールを整理した。例えば、明度が一定値より低く暗色である場合は、より明度の影響が強くなる。また、彩度が一定以上低い場合には色相は感じにくく、モノトーン（明度に応じて白、グレー、黒に分類可能）と識別される傾向が強くなり、彩度の影響が強くなることなどである。

更に、図-2に示すこれらの色判定ルールを用いて学習データ作成者向けのツールとして実装することで、個人の判断に依存しない高品質な学習データの作成に成功した。

● Deep Learningモデル軽量化による速度向上

GPUのメモリ消費量の削減と解析処理の高速化を両立するためには、Deep Learningモデルを軽量化することが重要である。Deep Learningにおいて計算の大部分を占めるのは畳み込み演算であり、その回数を減らすことでDeep Learningの解析処理を高速化できる。筆者らは、まず畳み込み演算の回数を減らすために、類似した計算を行っている畳み込み層を共通化した。これにより、特徴の抽出に必要な畳み込み演算の回数を約半分に削減できた⁽⁶⁾。

次に、演算回数の更なる削減のために、畳み込み演算自体の演算量を削減した。畳み込み演算は行列計算であるため、低ランクの行列に近似することによって演算量を削減できる⁽⁷⁾。筆者らは、畳み込み演算によるモデル（ベースモデル）で精度を確保した後に、近似した低ランク行列によるモデル（高速モデル）を用意した。そして、この両モデルの中間出力が一致するように、確率的勾配降下法による全体最適化のアプローチを採った。




図-2 色判定ルール

これらに代表されるモデル軽量化を行った結果、認識精度を落とさずに解析処理時間のみを半分にすることに成功している。

● Deep Learningモデル品質の確保と精度劣化防止

様々な手法を駆使して完成した学習モデルであるが、更なる高精度化や高速化、顧客のニーズに応じた解析対象の追加など、改良は日々行われている。しかし、処理がブラックボックスであるDeep Learningの特性上、予期せぬ精度劣化が発生する場合がある。例えば、ある車両メーカーの学習データを増やすと、そのメーカーの車両認識精度は向上するが、類似メーカーの精度が低下するといったことが起こり得る。

この問題を解決するため、学習データを追加した場合やモデル改良を行った際には、精度を再評価し予期せぬ精度劣化が生じていないことを検証する必要がある。しかし、これらの検証を人が行うと膨大なコストがかかる。そこで筆者らは、画像の解析から結果の評価・集計・可視化までを自動的に行うツールを開発した。このツールは、あらかじめ用意した正解データ付き画像とDeep Learning解析結果を比較することで正答率を自動で集計し、過去の結果からの改善や劣化を検出する機能を有する。また、正解データに付与されている車の向きなどの各属性値を集計・分析することで、Deep Learningモデル改良の加速につなげ




図-3 Citywide Surveillance精度評価

られた。

図-3は、富士通の従来技術とCitywide Surveillance V2の精度評価結果の比較である。この精度評価の正解とは、車両または人物を検出し、かつ各分類の認識が成功したものを指す。従来技術と比較して、V2では精度が顕著に向上していることが分かる。引き続き、モデルの改良や品質の高い学習データの拡充を進めていくことで、更なる精度の向上に取り組んでいく。

● コスト削減のための用途に応じたハードウェア導入

大容量メモリを搭載した高速なGPUは非常に高価なため、顧客の使用用途に応じて適切なハード

ウェアを選択することは重要な要素である。そこでCitywide Surveillanceでは、解析対象・解析頻度が異なる様々な用途に応じて最適なハードウェアの選択を可能としている。以下に、その機能の一部を紹介する。

- (1) 顧客が使用しない解析機能をOFFにすることや、同時解析処理数を減らすことが容易に設定できる。これにより、GPUのメモリ消費量を削減できる。
- (2) 解析頻度を下げること、複数のカメラからの入力を同一GPUに割り当て、適切にスケジューリングする機能を提供している。
- (3) 人数のエリアカウントや混雑検知など、リアルタイム性が低い用途向けでは、GPUを使用せずCPUだけでも解析を可能としている。

このように、顧客の使用用途によって最適なハードウェアを選択することで、最小限のハードウェア投資でシステム導入を可能とした。

Deep Learning周辺技術の整備

Deep Learningをビジネスに活用するためには、前述したDeep Learning技術の向上だけでは不十分である。Deep Learningによって得られる結果は人間にとって不親切なことも多く、顧客が求めている目的を達成するには、その結果を顧客価値へとつなげるための周辺技術の整備が欠かせない。例えば、侵入者検知においては、検知した結果をリアルタイムに通知・表示するために、高速な処理が必要である。

● リアルタイムスケジューリング

一般的なカメラ映像において、車両や人物のフレームインからフレームアウトまでに数秒程度の時間を要する。このことから、映像の全フレームに対して車両や人物の検知・分類を行う必要はなく、例えば毎秒1回程度の頻度で検知・分類を行えば十分なケースが多いと考えられる。また、映像の全フレームに対して、Deep Learningを使用して検知・分類を行うと処理時間が膨大となり、リアルタイムに追従できなくなる。そこで、Citywide Surveillanceでは、全フレームをDeep Learning処理するのではなく、検知した車両や人物を次の映像フレーム以降にわたって自動追尾（トラッキング）するリアルタイムスケジューリング機能を提

供している。処理時間の長いDeep Learningによる検知・分類と処理時間が比較的短いトラッキングを、GPU性能に応じた最適な間隔でスケジューリングすることで、全体の処理時間を短縮させリアルタイム解析を実現した。

● 座席位置の自動推定技術

筆者らは、大手外食チェーンの顧客と協働して、店内座席の空席状況を把握するための実証実験を行った。まず、Deep Learningを活用して人物を検出し、その結果をあらかじめ設定した座席位置と比較して店内の混雑率を求めた。顧客からは、競合他社に比べ解析精度が非常に高いという評価をいただいた一方で、多数の店舗に技術を導入する際の初期導入コストの削減を要求された。そこで、人物の滞留時間に着目し、滞留している部分に座席があると推定し、自動的に座席位置を算出する機能を開発した。この座席位置自動推定技術によって得られた座席情報と、空席状況を可視化した解析例を図-4に示す。

顧客にとって従来なかった業務が増えることは、システムの導入を判断する上で大きな障壁となる。しかし、筆者らが開発した座席位置自動推定技術を用いることで、何店舗もの座席情報を顧客の手を煩わせることなく自動的に算出できる。更に、レイアウト変更にも柔軟に対応できるようになった。このように、顧客のニーズに応じてAI技術の価値を顧客に提供することで、顧客から非常に高い評価をいただいた。

活 用 事 例

スマート都市監視は、より安全で快適な暮らしの実現や顧客体験の向上、企業の経営革新など、都市のあらゆるシーンで多大な貢献を果たすことが期待されている。本章では、実際にCitywide Surveillanceの運用を行っている国内外の活用事例を紹介する。

(1) 国内公的機関

駐車場などのセキュリティ強化、監視オペレーションの効率化を目的に、屋外に多数設置されているカメラ映像から容易に車種・メーカーを判別することで、効率的に犯罪車両を検出するシステムの運用を開始した。更に、人物検出機能の追加を計画している。



図-4 店内の空席状況解析結果

高速道路での活用事例

サービスエリア


- 混雑トレンド、顧客属性（年齢・性別）に応じた商品・サービス最適化
- 座席利用状況把握による店内スペース有効活用
- 駐車エリア空き情報の通知
- 顧客属性によるサービス最適化（車種・メーカー判別）
- ◎ 不正駐車検出アラート（駐車禁止、長時間駐車）

料金所ゲートエリア

- ◎ 車番・長期間停車検知による不審車アラート
- ◎ 料金所の不正通行アラート

道路エリア

- ◎ 道路への人侵入アラート
- ◎ 逆走車検知アラート
- 混雑情報のリアルタイム配信
- 混雑トレンドに基づく渋滞緩和施策の計画立案
- 顧客属性分析（車種・ブランド・LPR）によるサービスエリア最適化



- ◎ セキュリティ向上
- マーケティング強化

ガソリンスタンドでの活用事例

小売エリア

- 混雑トレンド、顧客属性（年齢・性別）に応じた商品・サービス最適化
- 座席利用状況把握による店内スペース有効活用
- ◎ 制限区域への侵入アラート

給油エリア

- 車番での常連客の通知
- 車両属性（車種・メーカー）に応じたサイネージ広告・サービス最適化
- ◎ 車番・長期間停車検知による不審車アラート

洗車エリア

- 車両属性（車種・メーカー）に応じた高利益率サービスの販推
- サービス混雑状況のリアルタイム配信

道路エリア

- 地域情報把握（交通混雑・車種分布）に基づく新規店舗展開検討




図-5 ビジネス活用事例

(2) 海外エネルギー企業

販売促進や接客サービスの充実を目的に、お得意様・要注意人物の来店検出や、店舗の混雑傾向分析を行うサービスの提供を開始した。その有用性が認められ、ある顧客から2017年に最も革新的な技術を提供した企業として表彰を受けた。

(3) 国内物流企業

トラック搬入出計画の最適化を目的に、物流センターに出入りするトラックの積載量ごとの入退場数カウント機能を評価中である。

(4) 国内環境調査団体

従来、目視でカウントしていた交通量調査を自動化することを目的に、道路上に設置したカメラの映像を用いた交通量調査（車種ごとの自動カウント）を実施中である。

(5) 国内交通機関

搭乗手続きや乗車の際の待ち行列は、交通機関利用者の満足度を低下させる主要な問題の一つである。そこで、監視カメラの映像を用いて、混雑状況をリアルタイムに把握し、混雑の原因を特定できることを実証した。

(6) 海外交通機関

公共交通機関にとって、混雑の可視化は利用者の満足度を向上させるために重要である。そこで、市街を走行する公共バス内に設置されたカメラ映像から、混雑状況を分析する実証実験に取り組んでいる。

また、上記活用事例のほかに様々な場所や分野でのビジネス活用事例が想定される。例えば、ハイウェイやガソリンスタンドなどに設置された監視カメラの映像を活用し、混雑・渋滞把握、広告の最適化といったマーケティング強化や、不正駐車・逆走検知といったセキュリティ向上など、様々な分野での活用が可能である（図-5）。

む す び

本稿では、Deep Learningを活用したCitywide Surveillanceをビジネスに活用するための取り組みについて述べた。

富士通は、Deep Learningをはじめとする機械学習を中核として、インフラからサービスまでを垂直統合したソリューションを提供していく。これによって、都市インフラ・セキュリティ・産業流通分野における幅広い社会の課題解決に取り組んでいく。

参考文献

- (1) 矢野経済研究所：監視カメラ世界市場に関する調査結果2015.
<http://www.yano.co.jp/press/pdf/1420.pdf>
- (2) 矢野経済研究所：IPカメラ国内市場に関する調査を実施（2016）.
<http://www.yano.co.jp/press/press.php/001599>
- (3) 富士通：AI技術を活用した都市監視や駐車管理のソリューションを販売開始.
<http://pr.fujitsu.com/jp/news/2016/10/3-1.html>
- (4) A. Krizhevsky et al. : Imagenet classification with deep convolutional neural networks. In: Adv. In Neural Information Processing Systems（2012）.
- (5) Colorfulness.
<https://en.wikipedia.org/wiki/Colorfulness>
- (6) S. Tanabe et al. :Real-Time Human Pose Estimation via Cascaded Neural Networks Embedded with Multi-task Learning. In: CAIP（2017）.
- (7) M. Jaderberg et al. : Speeding up Convolutional Neural Networks with Low Rank Expansions. arXiv preprint arXiv:1405.3866, 2015.

著者紹介



木下 修平 (きのした しゅうへい)

富士通（株）
テクニカルコンピューティングソリューション事業本部
GREENAGES Citywide Surveillance
パッケージの開発に従事。



若槻 政幸 (わかつき まさゆき)

富士通（株）
テクニカルコンピューティングソリューション事業本部
GREENAGES Citywide Surveillance
パッケージの開発に従事。



堀之内 省吾 (ほりのうち しょうご)

富士通（株）
テクニカルコンピューティングソリューション事業本部
GREENAGES Citywide Surveillance
パッケージの開発に従事。



田辺 聡 (たなべ さとし)

富士通（株）
テクニカルコンピューティングソ
リューション事業本部
Deep Learningなどの機械学習を活用
した映像解析技術の研究開発に従事。



東 明浩 (ひがし あきひろ)

富士通研究開発中心有限公司
メディアプラットフォーム技術研究部
Deep Learningなどの機械学習を活用
した映像解析技術の研究開発に従事。