

M-010

## 超高遅延・ロス環境での遠隔物体検出のための確率的画像転送法

Stochastic Image Transmission for Object Detection over Ultra High Latency and Lossy Networks

坂口 朝陽<sup>1</sup> 丸田 一輝<sup>2</sup> 井上 文彰<sup>3</sup> 中原 睦貴<sup>3</sup> 久野 大介<sup>3</sup> 原 裕子<sup>2</sup> 中山 悠<sup>1</sup>  
Asahi Sakaguchi Kazuki Maruta Yoshiaki Inoue Mutsuki Nakahara Daisuke Hisano Yuko Hara Yu Nakayama

### 1. はじめに

近年, IoT デバイスおよび深層学習を用いた物体検出技術の普及により, 観測対象の遠隔モニタリングを安価に実施可能になっている[1]. ネットワークカメラの撮影画像をエッジサーバへ転送して物体検出処理を行うことで, 様々な環境を簡易にモニタできる. ただし, 深海をはじめとしたノイズの大きい極限環境や低速ネットワークを介した場合, すなわち超高遅延・ロス環境においては, 通信の信頼性が課題となる. データ通信の信頼性を担保する手法として, 誤り訂正符号や再送が一般に採用される. しかしながら, 超高遅延・ロス環境では, 通常の再送処理ではデータ転送効率が著しく低下する. エラー耐性を高めることを目的として, 様々な画像圧縮技術が開発されてきたが, 深層学習による物体検出に最適化した手法は未だ十分には検討されていない. この課題に対し我々は, ネットワーク越しの近似コンピューティング (AC) を検討している. AC とは, 計算機内でデータの誤りを許容して処理を行う技術である[2]. 本稿では, そのアプローチの一つとして, 超高遅延・ロス環境に向けた確率的画像転送法を提案する. 提案手法は, 画像内の対象物体の出現頻度の偏りを利用して不均一なデータ転送を行う. 超高ロス環境を模擬したオフライン実験により, 少ないデータ量で高い物体検出精度を実現可能なことを確認した.

### 2. 提案手法

提案手法の概要を図 1 に示す. 提案手法では, 検出対象となる物体の画像内での出現率に偏りがある状況を想定し, 画像を不均一に転送することで高出現領域の受信率を高める. 具体的には, 画像を複数のブロックに分割し, 各ブロックに対して物体の出現率に応じた価値を設定する. データ転送時には, 設定した価値を重みとして用いた反復試行としてブロック選択・転送を実行する. この手法により, 物体の出現率が高い領域ほど高頻度で送信され, それに伴って受信率が高まる. その結果として, 超高ロス環境においても物体検出精度を高めることができる. 特に高遅延環境においては, 従来の再送方式では再送要求の効率が低下するため, あらかじめロスを想定して反復試行として転送を行う確率的画像転送が有効である.

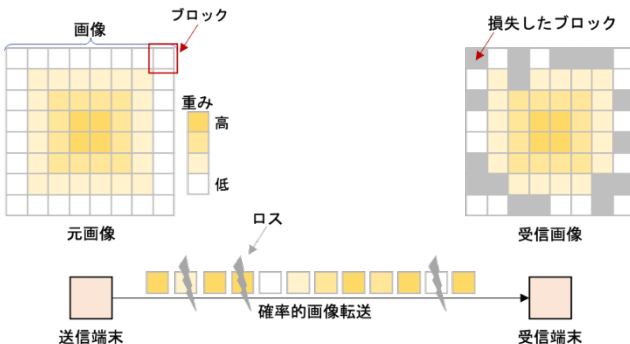


図 1: 確率的画像転送の概要

具体的な転送手法を以下に述べる. まず画像を構成するブロックの集合を  $J$  として, 各ブロックの識別子を  $i(\in J)$ ,  $i$  番目のブロックの価値を  $v_i$  とする. このとき,  $i$  番目のブロックの送信確率  $p_i$  は以下の式で与えられる.

$$p_i = \frac{v_i}{\sum_{i \in J} v_i} \quad (1)$$

総送信ブロック数を  $N$  とすると,  $i$  番目のブロックの期待送信回数  $e_i$  は以下の式で与えられる.

$$e_i = p_i N \quad (2)$$

ここで,  $L_{pkt}$  を伝送路でのロス率,  $K$  を 1 ブロックの送信に必要なパケット数とすると,  $i$  番目のブロックの到着確率  $\rho_i$  は, 総送信回数における不送信確率と未到達率の合計から以下の式で与えられる.

$$\rho_i = 1 - (1 - p_i) + p_i L_{pkt}^K \quad (3)$$

$i$  番目のデータに要求される受信確率を  $R_i$  と定義すると, 到着確率について以下の制約条件が得られる.

$$\rho_i \geq R_i \quad (4)$$

式 (1), (3) を用いて与えられる,  $p_i$  に関する条件式を以下に示す.

$$p_i = \frac{v_i}{\sum_{i \in J} v_i} \geq \frac{1 - (1 - R_i)^{\frac{1}{K}}}{1 - L_{pkt}^K} \quad (5)$$

画像を構成する全ブロック  $i \in J$  に関して, 式 (5) を合計すると, 以下のような受信確率を設定する上での制約式となる.

$$\sum_{i \in J} (1 - R_i)^{\frac{1}{K}} \geq |J| + 1 + L_{pkt}^K \quad (6)$$

### 3. オフライン実験

提案手法の有効性を確認するため, 表 1 のパラメータを用い, 高ロス環境を模擬したオフライン実験を行った.

#### 3.1. 検出対象の出現頻度の取得

検出対象となる緑色のボールをロボットに乗せてランダムに移動させ, その様子を地上に固定したカメラから撮影した (図 2/赤枠が検出対象). その画像 100 枚から, 画像内での検出対象の出現頻度分布を算出した (図 3).



図 2: 画像データの例


表 1: 実験に用いたパラメータ

画像サイズ[pixel]	256 × 144		
ブロックサイズ[pixel]	8 × 8	16 × 16	32 × 36
画像に含まれるブロック数	576	32	144
送信データ量 (元画像比)	1/8, 1/4, 1/2, 1, 1.5, 2, 2.5, 3		
ロス率[%]	0, 20, 40, 60, 80		

<sup>1</sup> 東京農工大学 Tokyo University of Agriculture and Technology

<sup>2</sup> 東京工業大学 Tokyo Institute of Technology

<sup>3</sup> 大阪大学 Osaka University




(a) ブロックサイズ8×8

(b) ブロックサイズ16×16

(c) ブロックサイズ32×36

図4: 受信画像の例

図3: 検出対象の画像内出現頻度分布




(a) ブロックサイズ8×8

(b) ブロックサイズ16×16

(c) ブロックサイズ32×36

図5: 対象の検出率



(a) ブロックサイズ8×8

(b) ブロックサイズ16×16

(c) ブロックサイズ32×36

図6: 画像完成率

### 3.2. データセットと学習モデルの作成

物体検出フレームワーク Darknet YOLOV3 を用いて、同条件で撮影した 1000 枚の画像を入力として 99%以上の検出率を持つ学習モデルを作成した。

### 3.3. データ転送の模擬

表1のパラメタを用いて提案手法によるデータ転送を模擬し、パラメタのセットごとに10000回の試行を行った。結果として得られた出力画像の例を図4に示す。

### 3.4. 検出率/画像完成率

3.3で得た出力画像において、3.2で作成したモデルを用いて対象の検出率を出力した。また、元画像に対する受信ピクセル数の比率を画像完成率として出力した。

## 4. 結果

対象物体の検出率を図5に、画像完成率を図6に示す。なお送信データ量は元画像のデータ量で正規化して表した。パラメタの設定次第では、正規化データ量1.0で画像完成率が40%未満と低くても、50%~90%の高い検出率を達成した。これは超高ロス環境において、画像内の物体出現率の偏りを利用した効果だと言える。なお正規化データ量3.0では、多くの条件で100%近い検出率を得た。この結果から、通常の再送制御が困難な高遅延環境でも、提案手法を用いることで高い認識精度を達成できる。なお、出現頻度の分布によっては、ブロックサイズが大きすぎても精度が低下することが予想され、さらなる検証が必要だと考えられる。

## 5. まとめ

本稿では、データの誤りを許容して処理を行う通信方式の一つとして、超高遅延・ロス環境に向けた確率的画像転送法を提案した。提案手法により、画像をブロックに分割し、重要度の高いブロックを高確率で複数回転送することで、少ないデータ量で高い認識率を達成できることを確認した。今後の課題として、多様な環境における検証、ブロックサイズ等のパラメタ最適化に向けた検討が挙げられる。また、今回はパケット転送を模擬したオフライン実験であったため、今後は実際に高ロス・遅延環境におけるパケット転送を行うオンライン実験に取り組んでいきたい。

### 謝辞

本研究は、JST ACT-I (JPMJPR18UL), JSPS 科研費 JP20K21789 の支援を受けて行われた。

### 参考文献

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, 2012, pp. 1097-1105.
- [2] J. Han and M. Orshansky, "Approximate computing: An emerging paradigm for energy-efficient design," in 2013 18th IEEE European Test Symposium (ETS). IEEE, 2013, pp. 1-6.