

道路ネットワークデータ更新性能指標の 及び道路推論モデルの性能比較

鈴木 大樹¹・河内 大輝²

¹ 学生会員 東京大学大学院 工学系研究科社会基盤学専攻 (〒113-8654 東京都文京区本郷七丁目 3-1)
E-mail: suzuki@bin.t.u-tokyo.ac.jp(Corresponding Author)

² 学生会員 東京大学大学院 工学系研究科社会基盤学専攻 (〒113-8654 東京都文京区本郷七丁目 3-1)
E-mail: kawauchi@trip.t.u-tokyo.ac.jp

道路ネットワーク地図の更新は労働集約型の作業であり、衛星画像を用いた深層学習による自動化が期待されている。しかし、道路ネットワークの変化に対する更新性能を正当に評価する指標が確立されておらず、適切なモデルアーキテクチャが不明であった。本研究では、道路ネットワークの変化に対する更新性能を正当に評価する指標を提案し、また、計算負荷を増大させることなく提案指標を計算する手法を構築した。複数の既存モデルに対して提案指標を適用し、モデル間の比較を行った。その結果、小領域ごとの推論と深さ優先探索によるグラフ化を組み合わせたモデルアーキテクチャが有用であることが明らかになった。また、既存の手法では性能が不十分であることを確認し、更なるモデルアーキテクチャ研究の必要性が示された。

Key Words: road network data, road extraction, road map update, remote sensing, deep-learning

1. はじめに

道路ネットワーク地図は、ナビゲーションをはじめとして多様な用途で活用されているが、有効に活用されるためには、常に最新の情報を反映している必要がある。現状、道路ネットワーク地図の更新は人手による労働集約型の作業となっており、地図を最新に保つために多大なコストを要している。

一方、近年、都市を高頻度で撮影する高解像衛星画像が利用可能となっている。空間分解能は 1m 以下となっており、衛星画像から道路を検出することが可能なレベルにある。また、時間分解能は 1 日以下であることから、道路検出を毎日行うことが可能であるといえる。以上より、衛星画像の情報を用いて道路ネットワーク地図を自動更新することで、従来の労働集約型の作業の大幅な軽減や、それに伴うコストの大幅な削減を期待できる。

道路ネットワーク地図の更新において重要なのは、道路ネットワークが変化した部分を正しく更新することである。しかし、既往の研究では、道路ネットワーク全体を推論する手法の提案がほとんどであり、その評価手法についても、道路ネットワーク全体に対して行われるものが中心であった。そのため、道路ネットワークが変化

した部分に対する更新性能が正しく評価されず、道路ネットワーク地図の更新にあたって適切なモデルアーキテクチャが不明なままであった。そこで本研究では、道路ネットワークが変化した部分に対する更新性能を適切に評価する指標を提案し、複数のモデルに適用し、比較することで、道路ネットワーク地図の更新にあたって適切なモデルアーキテクチャを明らかにすることを試みる。

2. 既往研究と本研究の位置づけ

(1) 道路ネットワーク全体の推論モデル

航空写真や衛星画像から道路ネットワークを抽出するモデルは盛んに研究されているが、大きく分けて以下の 3 つのタイプに大別される。

- タイプ 1: 画像全体セグメンテーション+後処理
 - タイプ 2: 個別セグメンテーション+後処理の深さ優先探索反復処理
 - タイプ 3: グラフエンコードによる直接推論
- タイプ 1 は、画像全体から道路・非道路の 2 値のセグメンテーションを行い、それを後処理でグラフ化するというものである。タイプ 1 の代表的なモデルとしては、

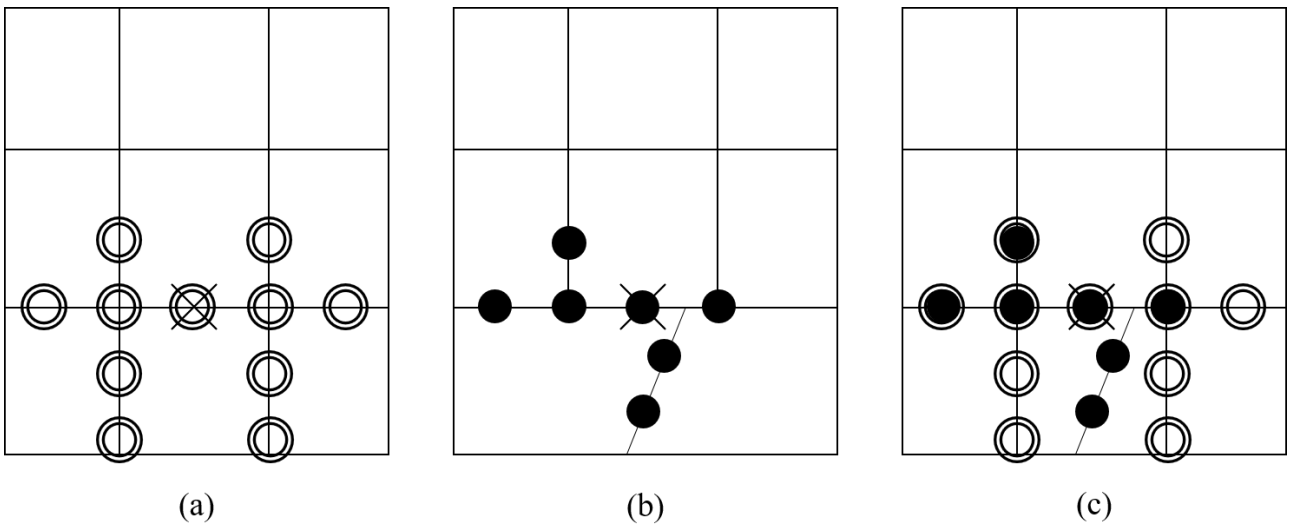


図-1 TOPO の計算プロセスのイメージ. ×印は開始点を示している. (a)現実の道路ネットワークに等間隔で「穴」を配置し, (b)推論した道路ネットワークに等間隔で「大理石」を配置し, (c)近傍に配置された「穴」を「大理石」とはマッチングしたとみなされる. Biaogini & Eriksson(2012)⁹⁾を参考に作成.

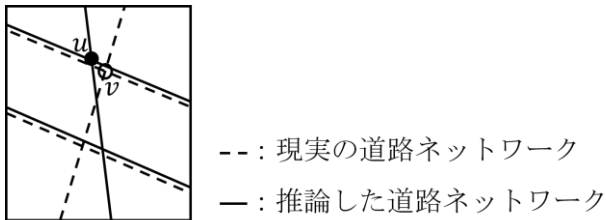


図-2 Junction Metric の計算プロセスのイメージ. 交差点 v に接続する 4 本のエッジのうち, 交差点 u の近傍を通るものは, 右向きに伸びるエッジ以外の 3 本なので, $f_{v,correct} = 3/4$ である.

RecurrentUNet¹⁾, MAiD²⁾, RoadConnect³⁾などがある. RecurrentUNetは U-Net 型の CNN ブロックを再帰的に組み合わせることで画像から詳細な道路特徴を抽出する. MAiD は各画素での道路の方向ベクトルを推論し, それを深さ優先探索で辿りグラフ化する. RoadConnect は, 2 値のセグメンテーションと方向ベクトルの両方をマルチタスクで推論し, さらに不要なグラフを除去する CNN を通すことで高精度化する. タイプ 2 の代表的なモデルとしては RoadTracer⁴⁾があり, これは画像中の小領域でセグメンテーションを行って後処理によりグラフ化し, その小領域グラフの接続方向をスタックに保持して, 次の小領域に移るといった処理を深さ優先探索によって探索する. タイプ 3 の代表的なモデルとしては Sat2Graph⁵⁾があり, これはグラフの接続情報をエンコードして扱い, 画像からこのエンコード情報を推論してグラフを直接推論する. 以上のモデルはすべて画像からネットワーク全体を抽出することを対象としており, 更新のための最適なモデルは不明である.

(2) 道路ネットワーク全体の推論に対する評価手法

Biagioni & Eriksson (2012)⁶⁾は, 道路ネットワークの推論モデルを統一的に評価する手法として, TOPO を提案した. TOPO の計算プロセスのイメージを図-1 に示す. まず, 現実の道路ネットワークから開始点を無作為に選択する. 開始点から d 以内の距離にある道路セグメントについて, 開始点から半径 r 以内の部分に一定の間隔で「穴」を配置する. 同様に, 推論した道路ネットワーク上にも, 「大理石」を配置していく. 「穴」と「大理石」が近傍に配置されていれば, 「穴」と「大理石」はマッチングされているとみなされる. このとき Precision, Recall を以下のように定義する.

$$\text{Precision} = \frac{M_m}{M_u + M_m} \quad (1)$$

$$\text{Recall} = \frac{H_m}{H_e + H_m} \quad (2)$$

ここで, M_m, M_u, H_m, H_e はそれぞれ, マッチングした「大理石」の数, マッチングしなかった「大理石」の数, マッチングした「穴」の数, マッチングしなかった「穴」の数を表す.

また, Bastani et al. (2018)⁷⁾は, 評価の解釈可能性向上と実用性の正当な評価のために, Junction Metric と呼ばれる指標を提案した. Junction Metric の計算プロセスのイメージを図-2 に示す. Junction Metric ではまず, 現実の道路ネットワークと推論した道路ネットワークとで, 対応する交差点の組 (v, u) を考える. ここで, $f_{v,correct}$ を, 交差点 v に接続するエッジのうち, 交差点 u の近傍を通過するものの割合と定義する. また, $f_{u,error}$ を, 交差点 u に

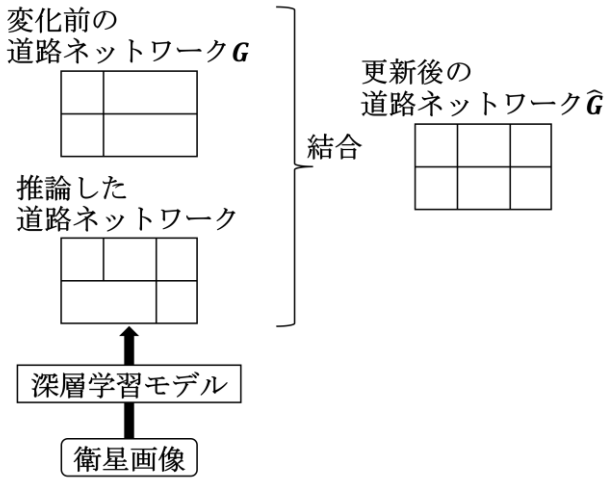


図-3 変化前のネットワークとの結合による道路ネットワークの更新プロセス (Bastani & Madden (2021)⁸⁾)

接続するエッジのうち、交差点 v の近傍を通過しないものの割合と定義する。2変数 $n_{\text{correct}}, n_{\text{error}}$ を

$$n_{\text{correct}} = \sum_v f_{v,\text{correct}} \quad (3)$$

$$n_{\text{error}} = \sum_u f_{u,\text{error}} \quad (4)$$

と定義し、正解率 F_{correct} および誤り率 F_{error} を以下のように求める。

$$F_{\text{correct}} = \frac{n_{\text{correct}}}{J} \quad (5)$$

$$F_{\text{error}} = \frac{n_{\text{error}}}{n_{\text{error}} + n_{\text{correct}}} \quad (6)$$

ここで、 J は実際の道路ネットワークに含まれる交差点の数である。

(3) 道路ネットワークの更新手法とその評価手法

以降では、各道路ネットワークを以下のように定義する。

- G : 変化前の現実の道路ネットワーク
- \hat{G} : 更新後の道路ネットワーク地図
- G^* : 変化後の現実の道路ネットワーク

Bastani & Madden (2021)⁸⁾は、2(1)で挙げた手法等で推論された道路ネットワークを、変化前の道路ネットワーク G に結合することで、道路ネットワークが変化した部分のみ更新を行う手法を提案した。更新の流れは図-3に示した通りである。この手法では、推論された道路ネットワーク内のあるエッジ e_0 から深さ優先探索を行う。探索される各エッジ (u, v) について、以下の処理を行う。

- ノード v が G のエッジから閾値 D 以上離れている場合は、エッジ (u, v) を G に追加し、ノード v から探




図-4 既往評価手法の問題点。ネットワークに変化が生じた部分のみに注目すれば、シナリオ1・2は等価である。しかし、道路ネットワーク全体に対する評価指標を用いると、シナリオ1の方が高い性能評価となる。

索を続ける。

- ノード v が G のエッジから閾値 D 以内に位置する場合で、かつノード v が探索済みでない場合、エッジ $e \in G$ 内の点でノード v に最も近い点 p を探索する。エッジ e を点 p で分割し、新しいノード v_{split} を作成した上で、エッジ (u, v_{split}) を追加する。新しく作成したノードに対するマッピング M を保持し、 $M[v] = v_{\text{split}}$ とする。
- ノード v が G のエッジから閾値 D 以内に位置する場合で、かつノード v が探索済みの場合、エッジ $(u, M[v])$ を追加する。

また、以下の2つの条件のうち一方でも満たすエッジは削除する。

- 探索中、 G に近いノードが1つも発見されなかった場合、
- 全長が50m以下である場合。

G に以上の処理が施したものを、更新後の道路ネットワーク地図 \hat{G} として出力する。

Bastani & Madden (2021)⁸⁾は、上述の更新手法のPrecisionおよびRecallを定義した。Precisionは、現実の道路ネットワークに変化がなかった場合に、変化がなかったと正しく推論できた割合、すなわち、 $G = G^*$ のときに、 $\hat{G} = G = G^*$ となる割合として定義している。また、Recallは、以下のように定義している。

$$\text{Recall} = \max\left(\frac{S(\hat{G}, G^*) - S(G, G^*)}{1 - S(G, G^*)}, 0\right) \quad (7)$$

ここで、 $S(G_1, G_2)$ は道路ネットワーク G_1, G_2 の類似度を表し、APLSを用いて計算される。これは、 G が更新され \hat{G} になることで G^* との類似度が高まった度合いを表している。2(2)で挙げた評価指標と異なり、道路ネットワークが変化した部分のみに注目しており、変化に応じた更新性能の評価を目指している点が特徴といえる。

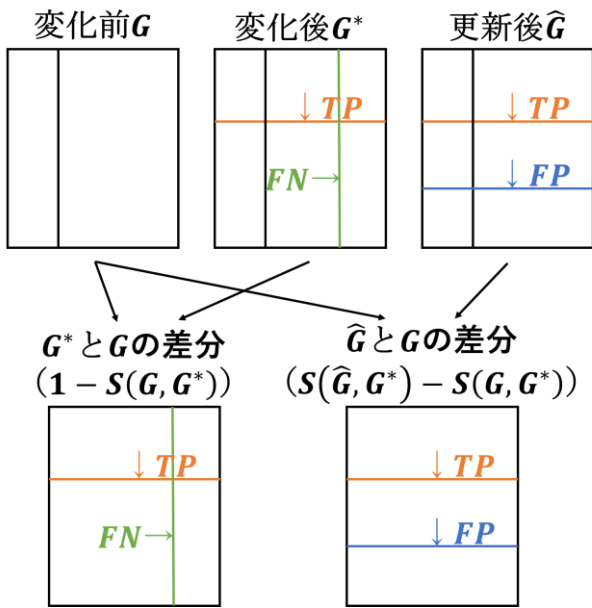


図-5 Bastani & Madden (2021)⁸⁾の評価手法の問題点. \hat{G} と G の差分を考えることで, FP を余分に評価している.

(4) 既往評価手法の問題点と本研究の位置づけ

道路ネットワーク地図の更新においては, 道路ネットワークに変化が生じた部分について, 正しく更新を行うことが重要である. しかし, 既往の研究では, 2(2)に挙げたような, 推論した道路ネットワーク全体に対する評価指標が提案されてきた. このような手法は, 道路ネットワーク全体のうち変化が生じた部分の割合によって評価が変動するため, 変化に対する更新の性能を正しく評価することができない (図-4). 道路ネットワークの変化に応じた更新性能を適切に評価するためには, 実際に変化が生じた部分のみを評価対象とすることが必要である.

道路ネットワークの変化に応じた更新性能を適切に評価しようとする試みは, 管見の限りでは, 2(3)に挙げた Bastani & Madden (2021)⁸⁾のみである. しかし, Bastani & Madden (2021)⁸⁾の定義した評価指標も, Precision や Recall の定義と一致したものとはなっていない. その理由について, Precision と Recall とに分けて説明する. なお, 以下では,

- TP : True Positive. 変化があり, かつ更新した部分.
- FP : False Positive. 変化がないにもかかわらず更新をした部分.
- TN : True Negative. 変化がなく, かつ更新を行わなかった部分.
- FN : False Negative. 変化があったにもかかわらず更新を行わなかった部分.

とする.

まず, Precision の一般的な定義は, 以下の通りである.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (8)$$

一方, Bastani & Madden (2021)⁸⁾の定義した Precision は, 変化がなかった部分 ($FP + TN$) のうち, 更新を行わなかった部分 (TN) の割合である. これは, 以下のように表すことができる.

$$\frac{TN}{FP + TN} \quad (9)$$

式(8)と式(9)を比べると, Bastani & Madden (2021)⁸⁾の定義した Precision は, 明らかに定義に反していることが分かる.

続いて, Recall の一般的な定義は, 以下の通りである.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (10)$$

これに対し, 式(7)に示した, Bastani & Madden (2021)⁸⁾の定義した Recall を考える. 概要を図-5 に示した. 式(7)の分母は, $1 - S(G, G^*) = S(G^*, G^*) - S(G, G^*)$ であることから, 変化後の道路ネットワーク G^* と変化前の道路ネットワーク G との差分, すなわち, 現実に変化があった部分 ($TP + FN$) を表している. 同様に, 分子は, 更新後の道路ネットワーク地図 \hat{G} と変化前の道路ネットワーク G との差分, すなわち, 更新を行った部分 ($TP + FP$) を表している. 以上を踏まえると,

$$\frac{S(\hat{G}, G^*) - S(G, G^*)}{1 - S(G, G^*)} = \frac{TP + FP}{TP + FN} \quad (11)$$

と表せる. 式(10)と式(11)を比べると, Bastani & Madden (2021)⁸⁾の提案した指標は FP を余分に評価しており, Recall を正しく評価できていないことが分かる.

以上より, Bastani & Madden (2021)⁸⁾の評価指標も, 適切な指標とは言えない. そのため, 道路ネットワークの変化に応じた更新性能を正しく評価する指標がなく, 複数のモデルを正当に比較し, 道路ネットワークの更新にあたって適切なモデルアーキテクチャを検討することが困難である. 本研究では, 道路ネットワークの変化に応じた更新性能を正しく評価する指標を提案し, 複数のモデルを比較することで, 道路ネットワークの更新にあたって適切なモデルアーキテクチャを得ることを目指す.

3. 更新性能の評価指標

道路ネットワークの変化は, エッジの追加・エッジの削除の2つに大別できる. 本章では, それぞれの変化に対する更新性能の評価指標を構築した上で, 評価指標を

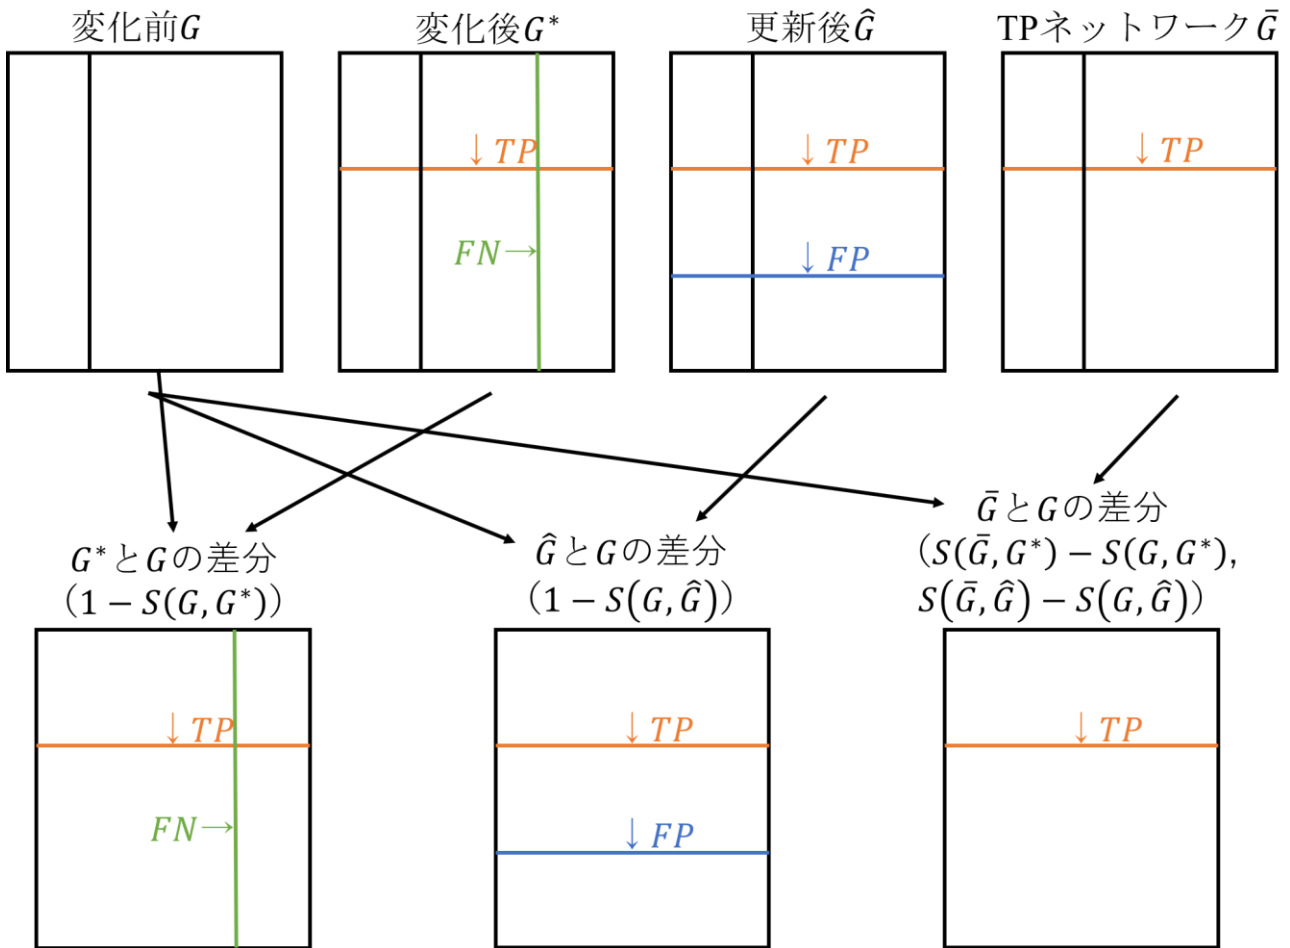


図-6 道路ネットワーク更新の新評価手法. TPネットワークを用いることで, TPのみを取り出すことが可能になる.

求めるアルゴリズムを提案する.

(1) エッジの追加に対する更新性能の評価指標

更新性能の評価指標構築にあたって, 更新後の道路ネットワーク地図 \hat{G} と変化後の現実の道路ネットワーク G^* との積集合 \bar{G} を考え, 「エッジの追加に対する TP ネットワーク」と名付ける. このとき, 各評価指標を以下のように定義する.

$$\text{Precision} = \max\left(\frac{S(\bar{G}, \hat{G}) - S(G, \hat{G})}{1 - S(G, \hat{G})}, 0\right) \quad (12)$$

$$\text{Recall} = \max\left(\frac{S(\bar{G}, G^*) - S(G, G^*)}{1 - S(G, G^*)}, 0\right) \quad (13)$$

それぞれの指標の正当性を説明する. 概要は図-6に示した通りである. まず, Precision の分母は, $1 - S(G, \hat{G}) = S(\hat{G}, \hat{G}) - S(G, \hat{G})$ であるため, 更新後の道路ネットワーク \hat{G} と変化前の道路ネットワーク G との差分, すなわち更新を行った部分 ($TP + FP$) を表している. 分子は, エッジの追加に対する TP ネットワーク \bar{G} と変化前の道路ネットワーク G との差分を表している. いま, 更新後の道路ネットワーク \hat{G} と変化前の道路ネットワー

ク G との差分は更新を行った部分 ($TP + FP$) を表し, 変化後の道路ネットワーク G^* と変化前の道路ネットワーク G との差分は変化が生じた部分 ($TP + FN$) を表す. これを踏まえると, エッジの追加に対する TP ネットワーク $\bar{G} = \hat{G} \cap G^*$ と変化前の道路ネットワーク G との差分は, 更新を行いつつ変化が生じた部分 ($(TP + FP) \cap (TP + FN) = TP$) を表している. 以上より, 以下の式が成り立つ.

$$\frac{S(\bar{G}, \hat{G}) - S(G, \hat{G})}{1 - S(G, \hat{G})} = \frac{TP}{TP + FP} \quad (14)$$

式(8)と式(14)を比べると, 式(12)で定義した Precision は, 定義に沿った指標になっていることが分かる.

続いて, Recall の分母は, $1 - S(G, G^*) = S(G^*, G^*) - S(G, G^*)$ であるため, 変化が生じた部分 ($TP + FN$) を表している. 分子は, エッジの追加に対する TP ネットワーク \bar{G} と変化前の道路ネットワーク G との差分であり, Precision のときと同様の議論で, 更新を行いつつ変化が生じた部分 (TP) を表している. 以上より, 以下の式が成り立つ.

$$\frac{S(\bar{G}, G^*) - S(G, G^*)}{1 - S(G, G^*)} = \frac{TP}{TP + FN} \quad (15)$$

式(10)と式(15)を比べると、式(15)で定義した Recall は、定義に沿った指標になっていることが分かる。

(2) エッジの削除に対する更新性能の評価指標

更新後の道路ネットワーク地図 \hat{G} と変化前の道路ネットワーク G との積集合 \bar{G} を考え、「エッジの削除に対する TP ネットワーク」と名付ける。このとき、各評価指標を以下のように定義する。

$$\text{Precision} = \max\left(\frac{S(\bar{G}', \hat{G}) - S(G, \hat{G})}{1 - S(G, \hat{G})}, 0\right) \quad (16)$$

$$\text{Recall} = \max\left(\frac{S(\bar{G}', G^*) - S(G, G^*)}{1 - S(G, G^*)}, 0\right) \quad (17)$$

指標の正当性は、3(1)と同様に示すことができる。

(3) アルゴリズム

3(1)で定義した指標を求めるためには、類似度 $S(G_1, G_2)$ の計算が必要である。本節では、TOPO を用いる場合と Junction Metric を用いる場合との2つについて、その計算手法を提案する。なお、3(2)で定義したエッジの削除に対する指標も同様に計算することが可能である。

a) TOPO を用いる場合

2 ネットワーク G_1, G_2 の類似度 $S(G_1, G_2)$ を以下のように定義する。

$$S(G_1, G_2) = \frac{2}{\frac{1}{T_1(G_1, G_2)} + \frac{1}{T_2(G_1, G_2)}} \quad (18)$$

ここで、

$$T_1(G_1, G_2) = \frac{1}{|S|} \sum_{s \in S} \frac{H_m^s}{H_e^s + H_m^s} \quad (19)$$

$$T_2(G_1, G_2) = \frac{1}{|S|} \sum_{s \in S} \frac{M_m^s}{M_u^s + M_m^s} \quad (20)$$

である。このとき、開始点を s とし、 G_2 に「穴」、 G_1 に「大理石」を配置したとき、マッチングした「穴」の数が H_m^s 、マッチングしなかった「穴」の数が H_e^s 、マッチングした「大理石」の数が M_m^s 、マッチングしなかった「大理石」の数が M_u^s である。

ここで、Precision や Recall の計算には $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ を求めることが必要だが、 \hat{G} や G^* から \bar{G} を求めるのには一定の計算負荷がかかる。そこで、 \bar{G} を直接求めずに $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ を計算する手法を以下の通り提案する。

$$S(\bar{G}, \hat{G}) = \frac{2}{\frac{1}{T_1(\bar{G}, \hat{G})} + 1} \quad (21)$$

$$S(\bar{G}, G^*) = \frac{2}{\frac{1}{T_1(\bar{G}, G^*)} + 1} \quad (22)$$

式(21)・(22)が成り立つ理由を説明する。まず、 $T_2(\bar{G}, G^*) = T_2(\bar{G}, \hat{G}) = 1$ である。これは、 \bar{G} の定義より、 \bar{G} 上に存在するノードやエッジは必ず G^* 、 \hat{G} 上にも存在し、 \bar{G} 上の「大理石」は必ずマッチングすることから明らかである。次に、 $T_1(\bar{G}, G^*) = T_1(\hat{G}, G^*)$ が成り立つ。 \bar{G} の定義より、 G^* 上に存在し、かつ \hat{G} 上には存在しない点は、 \bar{G} 上にも存在しない。また、 G^* 上に存在し、かつ \hat{G} 上にも存在する点は、 \bar{G} 上にも存在する。以上より、 $T_1(\hat{G}, G^*)$ を考えたときにマッチングする「穴」の割合は、 $T_1(\bar{G}, G^*)$ を考えたときにマッチングする「穴」の割合と等しくなるため、 $T_1(\bar{G}, G^*) = T_1(\hat{G}, G^*)$ と言うことができる。同様の議論で、 $T_1(\bar{G}, \hat{G}) = T_1(G^*, \hat{G})$ も成り立つ。

b) Junction Metric を用いる場合

2 ネットワーク G_1, G_2 の類似度 $S(G_1, G_2)$ を以下のように定義する。

$$S(G_1, G_2) = \frac{2n_{\text{correct}}}{J + n_{\text{correct}} + n_{\text{error}}} \quad (23)$$

ここで、 J は G_2 上の交差点の数であり、 $n_{\text{correct}}, n_{\text{error}}$ は

$$n_{\text{correct}} = \sum_v f_{v, \text{correct}} \quad (24)$$

$$n_{\text{error}} = \sum_u f_{u, \text{error}} \quad (25)$$

と定義する。なお、 G_2, G_1 上の対応する交差点の組を (v, u) とし、 $f_{v, \text{correct}}$ は交差点 v に接続するエッジのうち交差点 u の近傍を通過するものの割合、 $f_{u, \text{error}}$ は交差点 u に接続するエッジのうち交差点 v の近傍を通過しないものの割合である。なお、 v に対応する交差点が G_1 上に存在しない場合は、 $f_{v, \text{correct}} = 0$ である。

a)と同様、 \bar{G} を直接求めずに $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ を計算する手法を以下に提案する。まず、 $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ において、 $n_{\text{error}}^{\bar{G}} = 0$ である。これは、 \bar{G} の定義より、 \bar{G} 上に存在するノードやエッジは必ず \hat{G}, G^* 上にも存在することより明らかである。次に、 $S(\bar{G}, G^*)$ を考え、以下のように $n_{\text{correct}}^{\bar{G}}$ を計算する。

$$n_{\text{correct}}^{\bar{G}} = \sum_v \delta(f_{v, \text{correct}}) \cdot f_{v, \text{correct}} \quad (26)$$




図-7 各モデルに対する PR 曲線 (類似度計算に Junction Metric を用いた場合)。

ここで、 $\delta(f_{v,\text{correct}})$ は

$$\delta(f_{v,\text{correct}}) = \begin{cases} 0 & \text{if } f_{v,\text{correct}} < 1 \\ 1 & \text{otherwise} \end{cases} \quad (27)$$

を満たす指示関数である。このとき、

$$S(\bar{G}, \hat{G}) = \frac{2n_{\text{correct}}^{\hat{G}}}{J_{\hat{G}} + n_{\text{correct}}^{\hat{G}} + n_{\text{error}}^{\hat{G}}} = \frac{2n_{\text{correct}}^{\hat{G}}}{J_{\hat{G}} + n_{\text{correct}}^{\hat{G}}} \quad (28)$$

$$S(\bar{G}, G^*) = \frac{2n_{\text{correct}}^{\hat{G}}}{J_{G^*} + n_{\text{correct}}^{\hat{G}} + n_{\text{error}}^{\hat{G}}} = \frac{2n_{\text{correct}}^{\hat{G}}}{J_{G^*} + n_{\text{correct}}^{\hat{G}}} \quad (29)$$

により $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ を求めることができる。ここで、 $J_{\hat{G}}$ は \hat{G} 上の交差点数、 J_{G^*} は G^* 上の交差点数である。

式(26)~(29)が成り立つ理由を説明する。 $S(\hat{G}, G^*)$ を考えたときに、 $f_{v,\text{correct}} < 1$ となる交差点の組 (v, u) を考える。 $f_{v,\text{correct}} < 1$ より、交差点 v を構成する少なくとも1つのエッジが交差点 u の近傍を通過しないことから、2つの交差点 (v, u) は、一定の距離以上離れて位置している。そのため、2つのネットワーク \hat{G}, G^* の積集合 \bar{G} においては、交差点 v, u にあたる交差点は存在しない。ゆえに、 $S(\bar{G}, \hat{G})$ や $S(\bar{G}, G^*)$ を計算する際には $f_{v,\text{correct}} = 0$ として扱うことができ、式(26)~(29)が成立する。

4. モデルの評価と比較

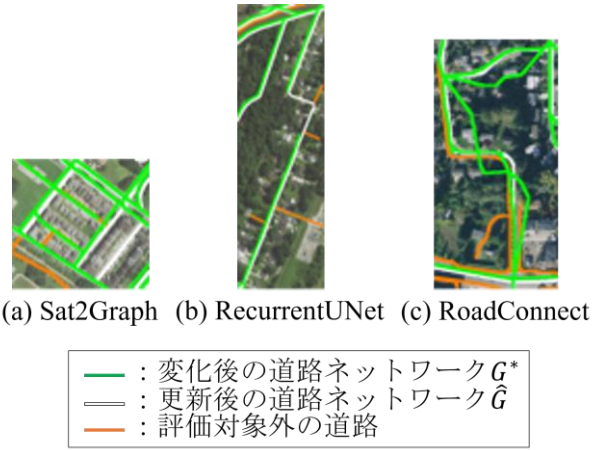


図-8 代表的な出力結果

3章で提案した指標を用いて、複数の道路ネットワークの更新手法の評価・比較を行った。データは、Bastani & Madden (2021)⁸⁾が作成した、アメリカの21都市の衛星画像と、Open Street Map から抽出した複数時点の道路ネットワークグラフから構成されるデータセットを使用した。道路が新規建設されたパターンや、道路が廃止されたパターンなど、複数の変化パターンのデータが含まれているが、本研究では、道路が新規建設されたパターンのみを扱った。3(3)で扱った Bastani & Madden (2021)⁸⁾が提案した手法を用い、2019年の衛星画像から道路ネットワーク全体を推論し、2013年の道路ネットワークと結合することで、道路ネットワークの更新を行った。道路ネットワーク全体の推論は、RoadTracer・RecurrentUNet・Sat2Graph・RoadConnect・MAiDの5手法を適用した。各手法に対して、式(12)・(13)により定義した評価手法を適用し、その結果を比較した。

まず、類似度 $S(G_1, G_2)$ の計算に Junction Metric を用いた場合の結果を示す。各手法に対する PR 曲線を図-7 と通りである。RoadTracer や MAiD は、他の手法と比較して Precision・Recall とともに相対的に高い性能を示した。RecurrentUNet は Precision・Recall とともに他の手法に比べて劣る結果となったが、特に Recall については、他の手法はほぼ同等の結果となっているのに対し、RecurrentUNet のみが相対的に低い性能を示している。図-8 に、RecurrentUNet の代表的な出力結果を示した。エッジが途中で途切れることで、現実には存在する道路を出力できていないことが分かる。2(1)で述べた通り、RecurrentUNet は衛星画像全体からセグメンテーションを通して道路ネットワークを得るため、道路の接続情報が利用されず、道路の接続状況が現実から乖離するケースが多くなると考えられる。Sat2Graph は、Recall は他の手法と同等の値となったが、Precision で大きく劣る結果となった。図-8に、Sat2Graph による代表的な出力結果を示し

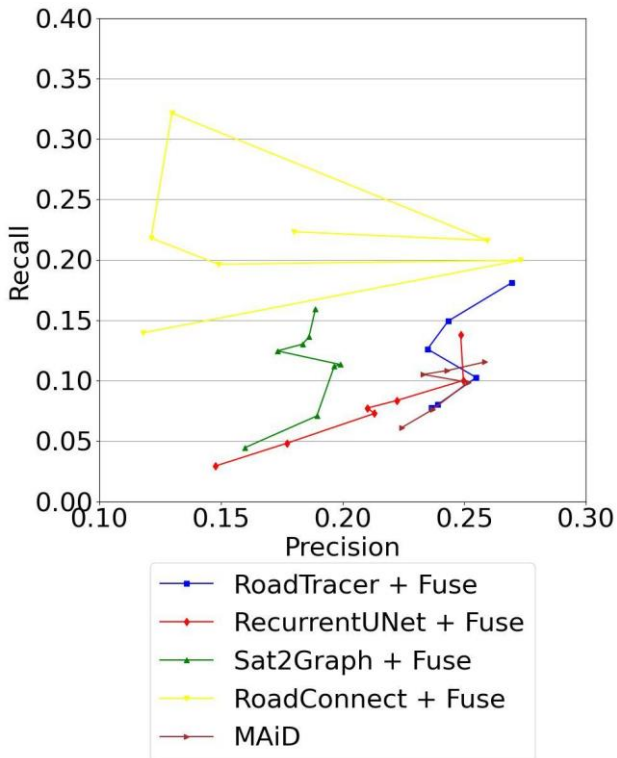


図-9 各モデルに対する PR 曲線 (類似度計算に TOPO を用いた場合)。

た。現実に道路が存在しない部分にエッジを出力していることが分かる。2(1)で述べた通り、Sat2Graph はノードの存在確率やエッジの接続方向の確率を推論するモデルであるため、実際には存在しないノードやエッジにも一定の存在確率が割り振られ、その結果、存在しない道路が出力される場合が多くなると考えることができる。RoadConnect は、Recall は安定して相対的に高い値を示したが、Precision は RoadTracer や MAiD と比べて不安定な結果となった。図-8 に、RoadConnect の代表的な出力を示した。現実に存在する道路と似た位置・形状だが、現実には存在しない道路を出力していることが分かる。2(1)で述べた通り、RoadConnect は衛星画像からセグメンテーションで道路ネットワークを抽出しつつ、方向ベクトルを学習し接続情報も利用するモデルである。そのため、現実の道路と類似しているが存在しない道路が出力されやすいと考えることができる。

続いて、類似度 $S(G_1, G_2)$ の計算に TOPO を用いた場合の PR 曲線を図-9 に示す。図-7 と比較すると、Junction Metric と同様の傾向になっていることが確認できる。RoadConnect の Recall や RecurrentUNet の Precision は、類似度に Junction Metric を用いた場合よりも相対的な評価が高くなっている部分もあるが、いずれのモデルも評価値が不安定であり、RoadTracer や MAiD の優位性に変化はないと考えられる。また、類似度計算に TOPO を用いた場合の方が、Junction Metric を用いた場合と比べて、全体的

な評価値が低くなっている。これは、Junction Metric では交差点のみに注目するのに対して、TOPO ではエッジ上の多数の点に注目しているため、ネットワーク間の差異に対する感度がより高くなっていることが原因として考えられる。

全体として高い性能を示した RoadTracer や MAiD は、画像を小領域に分けて推論を行い、深さ優先探索でネットワークを構築していく手法である。そのため、道路ネットワークの更新手法として、Bastani & Madden (2021)⁸⁾ が提案した手法を用いる場合、道路ネットワーク全体の推論には、小領域ごとの推論と深さ優先探索によるグラフ化を組み合わせたモデルアーキテクチャが有用であると言える。しかし、RoadTracer や MAiD についても、Precision は 65% 以下、Recall は 50% 以下に留まっていることから、既存の道路ネットワークの更新手法は、性能として不十分であると言えよう。

5. 結論

本研究の目的は、道路ネットワークの更新にあたって適切なモデルアーキテクチャを得ることであった。

変化後の道路ネットワークと変化前の道路ネットワークとの積集合を TP ネットワークと定義し、それを活用することで、Precision や Recall の定義に沿いつつ、道路ネットワークの変化に対する更新性能を正當に評価する指標を構築した。

また、評価指標の計算に必要な TP ネットワークと他の道路ネットワークとの類似度について、TP ネットワークを直接求めることなく計算する手法を構築した。これにより、TP ネットワーク導入による計算負荷の増大を回避した。

更に、提案した評価指標を用いて複数の既存手法を比較した。道路ネットワークの更新の際には、小領域ごとの推論と深さ優先探索によるグラフ化を組み合わせたモデルアーキテクチャが有用であることが明らかになった。また、既存の手法では性能が不十分であることを確認し、更なるモデルアーキテクチャ研究の必要性が示された。

参考文献

- 1) Yang, X., Li, X., Ye, Y., Lau, R. Y., Zhang, X. and Huang, X.: Road detection and centerline extraction via deep recurrent convolutional neural network U-Net. *IEEE Transactions on Geoscience and Remote Sensing*, vol.57, no.9, pp.7209-7220, 2019.
- 2) Bastani, F., He, S., Abbar, S., Alizadeh, M., Balakrishnan, H., Chawla, S. and Madden, S.: Machine-assisted map editing. *Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information*

- Systems*, pp. 23-32, 2018
- 3) Batra, A., Singh, S., Pang, G., Basu, S., Jawahar, C. V. and Paluri, M.: Improved road connectivity by joint learning of orientation and segmentation, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 10385-10393, 2019
 - 4) Bastani, F., He, S., Abbar, S., Alizadeh, M., Balakrishnan, H., Chawla, S., ... and DeWitt, D.: Roadtracer: Automatic extraction of road networks from aerial images. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 4720-4728, 2018.
 - 5) He, S., Bastani, F., Jagwani, S., Alizadeh, M., Balakrishnan, H., Chawla, S., ... and Sadeghi, M. A.: Sat2graph: Road graph extraction through graph-tensor encoding. *Proceedings of the European Conference on Computer Vision*, pp. 51-67, 2020.
 - 6) Biagioni, J. and Eriksson, J.: Inferring road maps from global positioning system traces, *Transportation Research Record*, Vol.2291, pp.61-71, 2012.
 - 7) Bastani, F., He, S., Abbar, S., Alizadeh, M., Balakrishnan, H., Chawla, S. and Madden, S.: Machine-assisted map editing. *GIS: Proceedings of the ACM International Symposium on Advances in Geographic Information Systems*, pp.23-32, 2018.
 - 8) Bastani, F. and Madden, S.: Beyond Road Extraction: A Dataset for Map Update using Aerial Images, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.11905-11914, 2021.

(?)
(?)

Road Network Data Update Performance Metrics and Performance Comparison of Road Inference Models

Taiki SUZUKI and Hiroki KAWAUCHI

This paper attempts to construct a metric for properly evaluating road map update models and to reveal what kind of model architecture is useful for road map update. Concept of TP network, which is intersection of ground truth network and updated network, is introduced and evaluation of road map update focusing only on where road network actually changed is made possible. Furthermore, algorithm for calculating the proposed metric without directly constructing TP network is proposed, thereby increasing computational cost by introducing TP network is avoided.

The proposed metric is applied to several existing map update models and results are compared. As a result, model architecture in which network segments are inferred for each small area and network is constructed by depth-first search is revealed to be useful for road map update. Moreover, insufficient performance of existing models and the necessity of further study on model architecture for road map update is suggested.