

PS-15 Deep Learning を用いた輸出入海上コンテナ貨物輸送経路推 定のための学習データ作成

知識・データシステム系 * 松倉 洋史

1. はじめに

海上コンテナによる貨物の輸出入は社会・経済活動にとって極めて重要であり、効果的に輸送を改善していく必要がある。そのためには時間・費用その他の多様な輸送属性が輸送経路の選択に及ぼす影響について定量的かつ詳細な分析を行う手法の開発が求められる。当所では AI で中心的な技術となっている Deep Learning を用いて輸出入海上コンテナ貨物の経路推定手法の開発を試みている^{詳細は 1) 参照}。ここでは学習データの作成が極めて重要であり、殆どの研究資源はその構築及び試行錯誤に用いられる。本稿では本取組みにおける学習データ作成に関し、主たる論点について述べる。

2. 貨物輸送経路推定システムの概要

2.1 推定計算機構

従来の経路推定ではロジックモデル、犠牲量モデル等の利用が殆どで、少数の因子間の比較的単純な関係による分析に止まっている。一方、Deep Learning を用いれば多変数間の複雑な関係も適切に扱って高精度の推定を行える可能性がある。しかし上記では固定数の選択肢から 1 つの正解を出すモデルが通常である。本課題では貨物発着地 (OD: Origin-Destination) のペアに対して候補となる経路の数は多数かつ不定数であることから、図-1 のように定数 (実装では $n=4$ 本と設定) の経路選択肢に対する多クラス分類問題として学習済みモデルを作成し、それを図-2 のようにトーナメント方式で適用することで輸送経路の推定を可能とした。

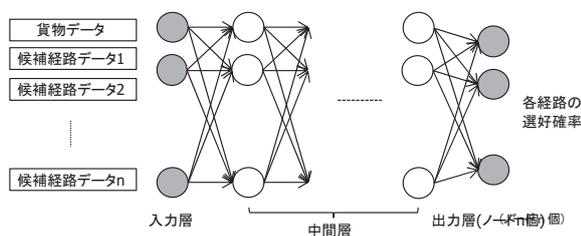


図-1 経路推定モデル(学習済みモデル)の作成

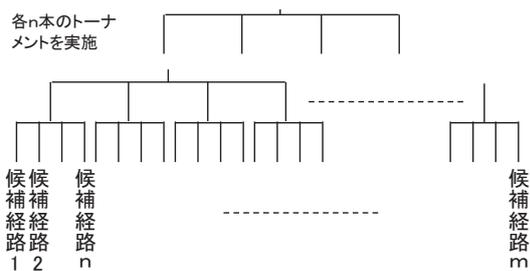


図-2 トーナメントの実施(候補経路数 m 本の例)

なお、図-1 では n 本の候補経路の入力順に、対応する n 個の出力層ノードに当該経路の選好確率が出力される。

2.2 学習データ

経路推定モデルの生成に用いる学習用データの作成について述べる。元となるのは国土交通省の作成する全国輸出入コンテナ貨物流動調査²⁾の非集計データである。

学習データとして利用する貨物属性は、国内発着地の(1)生活圏名、(2)都道府県名、(3)施設区分(コンテナ詰め/取り出し場所の荷主/業者/公共/その他施設の別)、(4)施設種別(コンテナ詰め/取り出し場所の恒温/冷凍・冷蔵/その他倉庫の別)、(5)海外発着港名、(6)州名(海外港のアジア/大洋/ヨーロッパ/北アメリカ/アフリカ/南アメリカ州の別)、(7)海外港の国名、(8)品目名(81 分類)、(9)品類名(8 分類)、(10)混載の有無(FCL/LCL)、(11)コンテナの種類(ドライ/リーファー/その他)、(12)フレートトン、(13)申告価格の計 13 種類である。

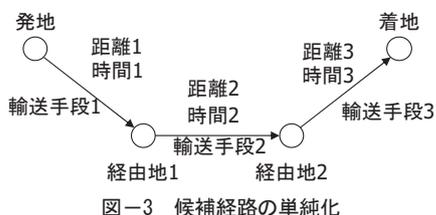
一方、利用する経路属性は、後述する図-3 の各パスについて発地から経由地 1 までにつき(1)輸送手段名 1(外航船/内航船/トレーラ)、(2)距離 1、(3)時間 1、(4)経由地名 1。経由地 1 から経由地 2 までにつき(5)輸送手段名 2、(6)距離 2、(7)時間 2、(8)経由地名 2。経由地 2 から着地までにつき(9)輸送手段名 3、(10)距離 3、(11)時間 3。更に共通項目として(12)ドライバ総休憩時間、(13)ドライバ総休憩時間、(14)ドライバ総拘束時間、(15)総時間(運行計画加味)、(16)総時間(運行計画加味せず)、(17)総費用(運行計画加味)、(18)総費用(運行計画加味せず)の 18 種である。ただし、上記は候補経路 1 本あたりの属性であり、学習データには図-1 の候補経路数に相当する n 倍の入力数を含むこととなる。

3. 候補経路の作成

国内外の貨物発着地及びその組合せである発着地ペアは膨大にあるため、そのまま用いられれば複雑すぎて計算機で扱うことは極めて困難である。また各発着地ペアを用いる貨物の数も少数となって十分な学習用データを用意できない。そこで国内の貨物発着地は国内を 207 の生活圏²⁾に分類し、その中核自治体の主たる役所所在地と見做した。海外については最初の船積みまたは船降し港を発着地と見做し、日本に関する輸出入経路を考える際の重要性を鑑みて世界を 24 地域に分類して代表港を定めるとともに、うち 6 港にはフィーダー機能を設定した。国内の輸出入港については文献 2) に出現する港を省略せず全て用いることとした。

上記を輸送経路の発着及び経由地点とし、図-3 のように3つのパスからなる候補経路で表現した(単純ではあるが、主要パターンの殆どをカバーすることが可能である)。これらを用い、輸出入の発着ペアに対して、組合せ可能な輸送パターンを全てをあらかじめ計算して候補経路データベースを作成した。ただし、内航フィーダー航路については元データ²⁾に出現した航路のみを用いている。計算の結果、各発着地ペアに対して数十から300本弱の候補経路が得られた。

これにより外航航路においては存在しない航路も候補経路として設定することとなるが、Deep Learningによる学習が進む過程ではそのような経路は“使われない”経路として学習されていくため、悪影響は少ないと期待できる。国内輸送経路、ひいては(海上輸送を検討する観点から)国内輸出入港を推定するために、このように単純化すべき要素と精密に扱うべき要素を適切に区別してデータ及び全体システムを構築していくことが肝要である。



4. トラックドライバーの労働条件の加味

近年は人手不足からトラックドライバーの労働条件の改善への取り組みが進んでいる。そのため輸送所要時間は単純に輸送距離を走行速度で割ったものとはならず、必要な休憩・休息等の時間を加味したより長時間のものとなる。それに伴い、輸送費用についても増加した人件費や車両利用時間を加味したものとなる。従来は単純な割算により輸送時間や費用を求めているものが殆どであったが、ここではトラックドライバーの労働条件も加味した所要時間・費用を用いる。

トラック運送業界の労働時間等に関する基準としては厚生労働省の定めた「自動車運転者の労働時間等の改善のための基準」⁴⁾、いわゆる改善基準告示がある。これにはドライバーの拘束時間、休息期間、休憩時間、運転時間等についての様々なルールが記載されており、それに従い運行を行った場合の輸送時間及び輸送費用をコンピュータプログラムにより計算して用いることとする。概要を表-1に示す。

表-1 トラックの運行計画作成規則

項目	内容
拘束時間	1ヶ月293時間(労使協定がある時は、一定の条件下で320時間まで延長可) 1日13時間 最大16時間(ただし、15時間超は1週2回以内)
休息期間	継続8時間以上 業務の必要上やむを得ない場合に限り、1回4時間以上の分割休息で合計10時間以上でも可(ただし、一定期間における全勤務回数の2分の1が限度)
運転時間	2日平均で1日あたり9時間以内 2週平均で1週間あたり44時間以内
連続運転時間	4時間以内(運転の中断には1回連続10分以上、かつ、合計30分以上の運転離脱が必要)

5. 発着地分類による過学習の回避

3章に述べたように、本研究では単純化及び必要数の学習データを得るために、発着地をエリアでまとめた上で輸送経路を求めている。それは国内207か所、海外24か所と、輸出入ともに5千弱の組合せ数となる。

そのうち、多くの貨物が人口の多い発着ペアのものであり、また、学習に用いる貨物データは数万件あるため、単に全貨物をランダムにDeep Learningの訓練データ・検証データ・テスト(本件ではトーナメントに相当)データに振り分けた場合、主要な発着地の組合せの経路が正解となる貨物が各データに共通して含まれる可能性が高い。そのまま訓練・検証を行うと過学習となる恐れがあり、また、テストでも正しく性能を評価することができないと考えられる。

そこで、訓練・検証・テストにおいて、図-4のように共通の発着地(OD)ペアが無いよう、すなわち3者がお互いに未知のODを扱うよう振り分けることとした。これにより訓練結果の汎用性が検証段階でチェックされ、暗記に依らない貨物の経路性能に基づく経路選択ロジックが学習されると共に、テストでは適切に推定性能を評価可能と期待できる。

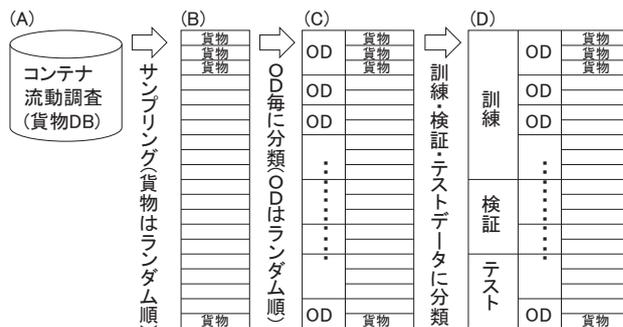


図-4 発着地(OD)分類と訓練・検証・テストの関係

6. 結果とまとめ

Deep Learningを用いて輸出入海上コンテナ貨物の経路推定手法を開発するにあたって必要となる学習データの作成の重要点について述べた。本稿で述べた学習データを用いて貨物輸送経路推定モデルを作成することにより、輸出入ともに9割程度の輸送経路正答率を得ることができている¹⁾。今後は本手法の応用事例を増やすとともに引き続き改良に努めていきたい。

参考文献

- 1) 松倉洋史: Deep Learning 手法による輸出入海上コンテナ貨物の輸送経路推定, 日本船舶海洋工学会論文集, vol135, 2020(投稿中)。
- 2) 国土交通省: 全国輸出入コンテナ貨物流動調査, 2014。
- 3) 国土交通省: 第4回(2005年)全国幹線旅客純流動調査 207生活圏ゾーン, 2007。
- 4) 厚生労働省: トラック運転者の労働時間等の改善基準のポイント, 2016年, 2017.3。