

# カーナビゲーションシステムの経路推奨機能における経路選好の学習に関する分析\*

## An Analysis of Learning on Driver's Preference by In-Vehicle Route Recommendation System\*

山本俊行\*\*・中山晶一郎\*\*\*・北村隆一\*\*\*\*

By Toshiyuki YAMAMOTO\*\*・Shoichiro NAKAYAMA\*\*\*・Ryuichi KITAMURA\*\*\*\*

### 1. はじめに

カーナビゲーションシステムは最も普及しているITS技術の一つである。経路推奨機能はカーナビゲーションシステムの主要な機能であり、推奨される経路の妥当性は運転者が推奨に従うか否かを決定する重要な要因である。わが国の都市部では道路網は密で代替経路は非常に膨大となることが多い。よって運転者が全ての代替経路を比較して最適な経路を選択することは限られた時間の中では不可能である。カーナビゲーションシステムは運転者の経路選択を支援する有用なものとなり得る。しかしながら、運転者は必ずしも推奨経路に満足するわけではない。これは、経路の選好は様々な要因が影響している上に、運転者によって選好が異なる一方で、通常のカーナビゲーションシステムの経路推奨機能が単純なルールに基づいて経路の選択を行っていることによる。個々の運転者に妥当な経路を推奨するためには、カーナビゲーションシステムが運転者の経路選好を学習する仕組みを持つことが得策であると思われる。

運転者毎にランダム効用理論に基づく離散選択モデルを構築するのは一つの方法である。しかしながら、通常、離散選択モデルは十分なデータを収集した後でパラメータが推定される。本研究では、学習という側面をより重要視し、オンライン学習に適したニューラルネットワークを用いて経路選好の推定を行う。ニューラルネットワークを用いた場合には、カーナビゲーションシステムを運転者が実際に使用し始めてから、自動的かつ継続的に運転者の経路選好を学習し続ける仕組みの構築が容易となる。さらに、ニューラルネットワークの特徴として、入力と出力の間の関係に関して高次の非線形性を考慮可能

であるという点が挙げられる。通常の離散選択モデルを用いる場合には経路の選好関数は線形を仮定することが多いが、実際には総距離や有料道路料金などが経路選好関数に与える影響は非線形であったり、交互作用を含む可能性が考えられる。ニューラルネットワークを適用することによって、このような選好関数の非線形性を内生的に学習することが可能となる。しかしながら、現実の道路ネットワークを対象として、何らかの一般化費用に基づく最短経路探索を行う場合、関数の線形性を仮定することによって、はじめてダイクストラ法<sup>1)</sup>を始めとする効率的な最短経路探索アルゴリズムの適用が可能となる。そこで本研究では、効率的な最短経路探索アルゴリズムの適用を保持しつつ選好関数の非線形を導入するための2段階の推奨経路決定構造を提案する。

これまで、ニューラルネットワークを始めとする学習モデルを適用する場合、従来の離散選択モデルとの比較において、同定されたパラメータの信頼性などの評価が統計的に出来ないという問題がある。中山ら<sup>2)</sup>は、ニューラルネットワーク型の効用関数を仮定しながらも最尤推定法を用いたパラメータの推定を行うことにより、非線形性を持つニューラルネットワークの特性を活かしたままで統計的なパラメータの信頼性(標準誤差)を推定している。しかしながら、このような推定方法はニューラルネットワークのもう一つの特徴であるオンライン学習を行う場合には適用することが出来ないという点、および、大域的な単峰性を持たないニューラルネットワークのパラメータは通常最尤推定法では局所解に陥る可能性が高いという点に問題があると考えられる。本研究では、バックプロパゲーション法によるオンライン学習に適用可能な方法としてブートストラップ法<sup>3)</sup>の適用を試みる。

### 2. 2段階経路推奨システム

#### (1) システムの概要

提案する2段階経路推奨システムの構造を図-1に示す。はじめに、運転者は目的地をカーナビゲーションシステムに入力する。出発地は、通常のカーナ

\*キーワード：経路選択, ITS

\*\*正員, 博(工), 名古屋大学工学研究科土木工学専攻  
(名古屋市千種区不老町, TEL:052-789-4636,  
E-mail:yamamoto@civil.nagoya-u.ac.jp)

\*\*\*正員, 博(工), 金沢大学工学部土木建設工学科  
(金沢市小立野2丁目40番20号, TEL: 076-234-4614,  
E-mail:snakayama@t.kanazawa-u.ac.jp)

\*\*\*\*正員, Ph.D., 京都大学工学研究科都市社会学専攻  
(京都市左京区吉田本町, TEL: 075-753-5134,  
E-mail:rkitamura@tem.kuciv.kyoto-u.ac.jp)

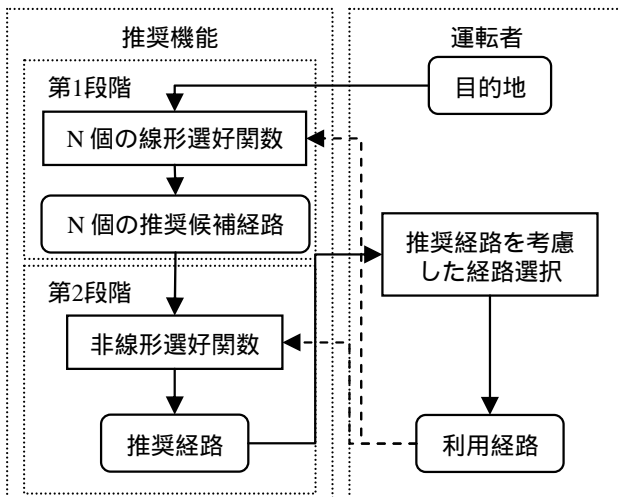


図-1 提案する経路推奨機能の構造

ビゲーションシステムと同様に、GPS等によって自動的にカーナビゲーションシステムが把握する。第1段階として、カーナビゲーションシステムは、N個の線形の選好関数に基づき出発地から目的地までの最短経路をN個それぞれ抽出する。ここでは、選好関数が線形に保たれているため、効率的な最短経路探索アルゴリズムの適用が可能である。抽出されたN個の最短経路を推奨候補経路とする。次に、第2段階として、第1段階で抽出されたN個の推奨候補経路から、最も望ましい経路を非線形の選好関数によって選択する。選択された経路は推奨経路として運転者に提供される。運転者は提供された推奨経路を考慮しつつ経路選択を行う。すなわち、もし提供された経路が妥当な経路であると判断した場合には当該経路を走行し、妥当でない判断した場合には、推奨された経路とは異なる経路を選択することになる。運転者によって選択された経路の属性は、GPS等によって走行中に自動的にカーナビゲーションシステムに把握される。最後に、実際に選択された経路が当該OD間の経路のうち、最も高い選好関数値を取るように、線形の選好関数と非線形の選好関数の両者について、パラメータの修正（運転者の経路選好の学習）を行う。

### (2) 第1段階

第1段階では、線形の選好関数を同定するために、中間層を含まず、入力層と出力層の2層のみからなるニューラルネットワークが用いられる。2層からなるニューラルネットワークの構造は、式(1)に示すように、ロジット型のシグモイド関数を仮定することによって、入力層を2選択肢の説明変数値の差、出力層を選択確率とした時の2項ロジットモデルの構造と一致する。

$$Y = \frac{1}{1 + \exp(\beta X)} \quad (1)$$

ただし、Yは出力値、Xは入力ベクトル値、 $\beta$ はウエイトを表す。すなわち、2層のニューラルネットワークによって同定したパラメータは、ロジットモデルにおける効用関数と同じ意味を持つ。本研究では、このような2層のニューラルネットワークの特徴を活かし、ニューラルネットワークによって線形の選好関数の学習を行い、同定されたウエイトを線形の選好関数として、最短経路探索に用いる。入力として、2選択肢の説明変数値の差を用いるため、実際に運転者が利用した経路と各推奨候補経路の説明変数値の差を入力、実際に利用した経路を出力とするN個の訓練データを用いて学習を行うこととなる。

### (3) 第2段階

第2段階では、選好関数の非線形性を考慮するため、中間層を含む3層からなるニューラルネットワークが適用される。各選択肢の説明変数の数をKとすると、 $N \times K$ 個の入力ノードと1つの出力ノードからなる構造をとるのが最も自然である。しかしながら、そのような構造を仮定した場合、パラメータ数が膨大となり、ニューラルネットワークの弱点の一つである過学習が起こる可能性が高くなる。実際に、 $N = 5, K = 8$ として、以下で述べるデータを用いてニューラルネットワークの構築を行ったところ、39の訓練事例のうち全ての事例についてのニューラルネットワークが同定されたが、10のテストケースに対して同定されたニューラルネットワークを適用したところ、5つの事例にしが正答しなかった。そこで、本研究では、N個の推奨候補経路から2つずつ全ての組み合わせからなる一対比較によってそれぞれ経路の優劣を決め、最も勝率の高い経路を推奨経路とするという方法を取る。この場合、入力ノード数は $2 \times K$ となり、 $N \times K$ に比べて少数となるため、過学習の問題は緩和されるものと考えられる。ただし、 $2 \times K$ としてもまだ過学習の問題が完全に除去できるかどうかは保障されない。そこで、本研究では、入力ノード数を減らしたネットワークも構築し、過学習について検討を行う。

第2段階において運転者の選好関数を学習する方法は第1段階と同様であり、実際に選択された経路と各推奨候補経路を対とするN個の事例を用いて、実際に選択された経路が出力されるように学習することとなる。

表-1 線形効用関数の推定結果

説明変数	ニューラルネット		ロジットモデル				
	ウエイト	標準偏差 <sup>†</sup>	推定値	標準誤差	t 値	標準偏差 <sup>†</sup>	t 値 <sup>*</sup>
総距離	-12.02	5.91	-13.61	2.97	-4.58	3.48	0.24
有料道路距離	62.15	6.46	45.39	10.73	4.23	11.14	1.34
幹線道路距離	2.74	2.76	1.19	1.75	0.68	1.61	0.47
細街路距離	-24.68	6.77	-8.82	3.14	-2.81	3.24	-2.12
右左折回数	-3.54	1.46	-3.66	1.19	-3.08	1.32	0.06
信号数	-2.35	1.80	-2.14	1.73	-1.24	1.79	-0.08
セグメント数	-26.38	4.31	-21.02	6.41	-3.28	5.85	-0.69
高速料金	-4.39	1.24	-2.49	1.05	-2.37	0.84	-1.17
サンプル数	245		245				
L(0)			-169.8				
L(β)			-109.5				
的中率	29/49		29/49				

<sup>†</sup>: ブートストラップ法による。

<sup>\*</sup>: ニューラルネットのウエイトとロジットモデルの推定値の差に関する t 検定。

### 3. 計算例

#### (1) データの概要

ニューラルネットワークの挙動を確認するために用いられたデータは、近畿地方の49のODを対象として、前もって定められた5種類の一般化費用関数を用いて最短経路探索によって抽出された5経路の妥当性を判断したものである。ここで、5種類の一般化費用関数は、それぞれ距離優先、有料道路優先、国道優先、広幅員道路優先、最小右左折優先、といった観点から前もって定められた選好関数である。また、5つの経路のうち、どの経路が妥当性が高いかの判断は、カーナビゲーションシステムの開発を行っている住友電工の複数の技術者の議論の結果によるものである。ここでは、この妥当性順位をある運転者の選好関数によるものと見なした分析を行う。

49のODはいずれも県庁や市役所等の地方自治体の所在地と駅を起終点に持ち、OD間の距離は10kmから400kmの範囲である。また、分析に用いた経路属性は、総距離、有料道路距離、幹線道路距離（幅員13m以上）、細街路距離（幅員5.5m以下）、右左折回数、信号数、セグメント数（経路途中で幅員が5.5m以下/5.5～13m/13m以上の間で何度変化するか）、高速料金の8つである。

#### (2) 第1段階

49のODから得られた245の選択肢対を訓練事例としてニューラルネットワークを構築した結果を表-1に示す。49のODで各ODにつき5経路が抽出されているとすると、選択肢対は490(= 49 ×  $_5C_2$ )となるはずであるが、実際に得られた選択肢数は245となっており490より少ない。この原因は、異なる選好関

数によって最短経路探索を行った場合でも結果的に同一の経路が抽出されたケースが多く見られたことによる。このような場合は妥当性の優劣をつける必要がないため、ここでは、これらのケースを除いた残りを訓練事例として用いた。このような処理は、ニューラルネットワークのモデル構造の検証を行う上では問題は少ないと考えられるが、図-1で示した経路推奨機能を実際に設計する上でどのように取り扱うかは今後の課題である。

前述したように、ニューラルネットワークは通常、パラメータの信頼性に関する指標を提供しないため、パラメータの推定結果に対する統計的な判断が不可能である。本研究ではブートストラップ法を適用することによって、パラメータの信頼性に関する目安を算出することを試みる。ブートストラップ法では、サンプルを母集団ととらえ、母集団から復元抽出によりサンプル数と同数の擬似サンプルを複数回抽出し、個々の擬似サンプルによるパラメータの推定結果のばらつきから標準偏差を算出する。算出された標準偏差を元のサンプルを用いて推定したモデルのパラメータの標準誤差の代理として用いる。表-1より、ブートストラップ法による標準偏差を標準偏差と見なした場合には、ほとんどの説明変数について有意なパラメータが同定されていることが分かる。

次に、ニューラルネットワークと比較を行うために同一のサンプルを用いて2項ロジットモデルを推定した。表より、ロジットモデルによる推定値は、ほぼニューラルネットワークと同様の値を持つことが分かる。また、ロジットモデルの推定値の標準誤差もニューラルネットワークの標準偏差と同様の傾向を示している。さらに、ロジットモデルについてもブートストラップ法による標準偏差を算出したが、

表-2 非線形選好関数の的中率（入力ノード数が16の場合）

中間ノード数	1	2	4	8	16
訓練事例(/49)	35	38	45	48	49
Leave-one-out 法(/49)	31	30	30	32	33

表-3 非線形選好関数の的中率（入力ノード数が4の場合）

中間ノード数	1	2	4	8	16
訓練事例(/49)	26	28	30	37	42
Leave-one-out 法(/49)	28	28	30	31	33

最尤推定法で算出される標準誤差とほぼ同様の値を示しており、ブートストラップ法の実用性を裏付ける結果となっている。

式(2)を用いてニューラルネットワークのウエイトとロジットモデルのパラメータ推定値の相違に関するt検定を行ったところ、表-1にt値を示すように、ほとんどの変数に対して統計的な相違は見られないという結果が得られた。この結果は、ロジットモデルとニューラルネットワークでパラメータの推定方法が異なるものの、式(1)で示される同一のモデル構造を持っているため、算出される選好関数に大きな違いはないことを示している。

$$t_i = \frac{w_i - \beta_i}{\sqrt{\sigma_{w_i}^2 + \sigma_{\beta_i}^2}} \quad (2)$$

ただし、 $w_i$ 、 $\sigma_{w_i}$ はニューラルネットワークの*i*番目の変数に対するウエイト、およびブートストラップによる標準偏差を表し、 $\beta_i$ 、 $\sigma_{\beta_i}$ はロジットモデルの*i*番目の変数に対する係数の推定値、および標準誤差を表す。

最後に、的中率についてはニューラルネットワークとロジットモデルが同一の値をとっており、線形の選好関数を仮定したニューラルネットワークの選択行動の再現性はロジットモデルと同等であることが示された。

### (3) 第2段階

第1段階と同様に、245の選択枝対を用いてニューラルネットワークを構築した。結果を表-2に示す。データには8つの経路属性が含まれているため、第2段階で構築するニューラルネットワークの入力ノード数は16となっている。ここでは、過学習について検証するために中間ノード数を1, 2, 4, 8, 16のそれぞれの場合について構築した。さらに、構築した各ネットワークについて、訓練事例を対象とした的

中率を算出した他に、予測力をより正確に判断できる指標として、Leave-one-out法による的中率についても算出した。Leave-one-out法は、サンプルから1ケースを取り出し、残りのサンプルで学習を行い、予め取り出しておいた1ケースの予測を行うという作業を全ケースについて繰り返す検証方法である。表より、中間ノード数が増加するほど訓練事例の的中率は向上するのに対して、Leave-one-out法による的中率はそれほど向上しない。すなわち、予測という観点からは中間ノード数の増加はそれほど効果がないことが分かる。

次に、入力ノード数の多さが過学習を引き起こしている可能性を検討するために、8つの経路属性のうち、総距離の和、総距離の差、有料道路距離の差、右左折回数差の4つの変数のみを入力とした場合のニューラルネットワークについても同様に構築した。表-3に示す結果より、訓練事例の的中率は入力ノードが16の場合よりも低いものの、Leave-one-out法による的中率はそれほど差が無く、特に中間ノード数が4の場合には的中率が一致している。これらの結果より、第2段階でのニューラルネットワークの構造に関しては、まだ検討の余地があるものと考えられる。

## 4. おわりに

本研究では、経路選好関数の非線形性を考慮しつつ、効率的な最短経路探索アルゴリズムの適用も可能な経路推奨機能として、2段階の経路推奨方法を提案した。運転者の経路選好関数を学習する仕組みとして、ニューラルネットワークの枠組みを適用したモデル化を行った結果、第1段階においてはロジットモデルと同等の精度で経路選好関数の学習が可能であることが確認されたものの、第2段階では、過学習を除去することが出来なかった。

最後に、本研究で用いたデータは住友電工より提供されたものである。住友電工との共同研究の中で、東京工業大学の藤井聡助教授、住友電工の土居陽一氏、長尾真伸氏から有益なコメントをいただいた。ここに記して感謝の意を表します。

### 参考文献

- 1) Dijkstra, E.W.: A note on two problems in connection with graphs, *Numerische Mathematik*, Vol. 1, pp. 269-271, 1959.
- 2) 中山晶一郎, 高山純一, 山下裕一郎: ニューラルネットワーク型非線形効用関数をもつロジットモデルの構築, *土木計画学研究・論文集* (投稿中)
- 3) Efron, B. and Tibshirani, R.J.: *An Introduction to the Bootstrap*, Chapman & Hall, London, 1993.