

第4章

移動空間分析

4.1 シミュレーションモデルの構成

4.1.1 四段階推定法とアクティビティベース手法

古典的な四段階推定法は、発生・集中交通量、分布交通量、分担交通量、配分交通量をそれぞれの段階にわけて予測する方法であり、これまで交通需要の予測や交通ネットワークの設計で大きな役割を果たしてきた。四段階推定法では、移動に焦点が当てられ、トリップ単位の分析でそれらの移動目的・目的地・交通手段・経路などが推定の対象となっていた。交通行動調査も四段階推定法に合わせて、我が国ではゾーン単位の OD 表を作成することを目標に、大規模なパーソントリップ調査が約 10 年おきに各都市圏で実施されてきた。

しかしながら、非集計な交通行動理論ができつつあり、また個人の細かな活動の観測が可能となった 1990 年代以降、移動は個人の活動の派生需要であるという立場に立ったアクティビティベースモデルが展開されてきている。アクティビティベース手法では、世帯または個人が無数の活動可能性の中からどのように活動内容や活動時間を決定し、さまざまな個人属性や制約条件を考慮した上で行動しているかを分析する。四段階推定法と同様の移動目的・目的地・交通手段・経路はアクティビティベースモデルにおいても推定対象となるが、推定が非集計レベルの意思決定理論に立脚していることが大きな特徴である。

四段階推定法とアクティビティベースモデルの違いを挙げると、各モデルの統合性や一貫性、時空間の解像度、時間の概念、行動理論との整合など

がある。

従前の四段階推定法では発生集中、分布、分担、配分の各モデルが独立して下位のモデルが上位のモデルに影響を及ぼすことはなく、交通政策を実施時に誘発交通が考慮できないことが課題とされてきた。アクティビティベーストモデルでは活動発生、交通手段選択、目的地選択などの各ステップが統合されており、一つの要素に関する意思決定が他の意思決定に影響するといった作用を考慮することができる。

時空間の解像度についても、四段階推定法では集計された OD 表が基本となり、空間的にはゾーン単位、時間的にも日ごとまたは時間帯ごとに集約した流動の分析となる。アクティビティベーストモデルは世帯や個人単位での意思決定の分析が基本となり、非集計のデータを扱うことから細かな表現が可能となり、選択肢に関する時空間的な制約条件の反映や、個人間の相互作用の考慮などが可能となる。

時空間の細かな表現ができることにより、アクティビティモデルを用いた分析では動的な交通状況が表現できるメリットもある。四段階推定法では時間の概念は存在せず、交通需要やネットワーク上の交通流の動的側面は無視されていた。アクティビティベースのアプローチでは、マイクロ交通シミュレーションと組み合わせることで交通状況に応じた動的な交通需要予測が可能となる。

アクティビティベーストモデルの非集計での分析では、行動理論と整合した記述ができ、行動論的根拠を持った推定であることも特徴である。観測データ如何では、物理学的・生物情報科学的な理論を援用した行動理論の適用ができ、モデル推定を行う研究も行われつつある。

4.1.2 全体の構成

移動計画理論の全体像を整理する。表 4.1 は、対象とするスケールごとに適用理論、使用データ、推定パラメータを整理したものである。それぞれのスケールは必ずしも厳密にわけられる訳ではないが、各々のスケールで観測手法からモデルによる記述がそれぞれ対応していると考えることができる。

表 4.1 スケールレベル別モデルの概要

	アクティビティレベル	ネットワークレベル	2次元レベル
理論モデル	活動内容選択 目的地選択 交通手段選択	均衡配分 最短経路探索 追従理論	経路選択 構造推定アプローチ
インプット データ	PT、PP データ 交通センサス	PP データ、検知器 DRM、VN、交通フロー	図面、動画データ 交通フロー
アウトプット データ	活動場所 OD 交通量	経路、経路交通量 時系列位置座標	時系列位置座標
パラメータ	交通ネットワーク 居住/従業人口分布	所要時間、料金 割引因子、学習	目的地、進行角度 相互作用

4.1.3 各レベルにおけるモデルの概説

(a) 世帯、個人の発生

都市圏単位を対象としたシミュレーションモデルでは、まずはじめに人口構成や社会経済属性の設定が必要となる。国勢調査や PT データなどで直接取得されているデータや、従業地分布等のデータにより、都市圏での人口分布や土地利用分布を表す。既存のデータをそのまま適用するほか、自動車保有モデルや住宅保有モデル、また職業選択モデルを個人属性や社会条件設定から推定し、各世帯や個人の設定を推定するアプローチもとられる。推定したモデルでは、この後の活動や交通行動に関するモデルの説明変数とすべき変数を考慮する。この段階により、非集計モデルを適用する母集団が設定される。

(b) アクティビティレベル

主として活動の発生に関する推定モデルである。離散選択モデルや重力モデルを用いた活動内容、活動場所、交通手段などが推定対象となる。

都市圏を対象としたシミュレーションを考える場合、このスケールでは非集計モデルで推計した交通行動を、母集団全体に拡大して、時空間的に分布する交通需要量を予測するため、PP データなどの小サンプルの非集計データと、PT データや道路交通センサスなどの母集団分布への拡大が担保された集計データとのデータフュージョン手法が必要となる。

また、モデルで用いる説明変数に交通のサービスレベル等のデータが用いられる場合、次ステップ以降の交通量配分や交通流シミュレーションによる結果をフィードバックし、交通需要が収束するまで計算を繰り返すことにより、四段階推定法の欠点であった誘発需要の考慮や、意思決定間の相互依存

の影響の考慮を行うことができる。

この段階で活動に伴う交通行動からなる OD 交通量と、出発時刻の分布を求めることができる。

(c) ネットワークレベル

主にグラフ表現されたネットワーク上における交通量配分を扱う。ネットワーク上での均衡配分理論に必要な交通フローは、アクティビティモデルから受け渡される。ネットワークデータや交通フローが分析には必要となり、ネットワークデータの作成や処理方法自体も計算上の過程において検討対象となる。配分方法も静的・準動的・動的など、多くの方法が適用されている。

動的な交通流の再現のためには、追従理論を用いたマイクロ交通流シミュレーションが用いられる。近年の計算機処理速度の向上により、交通現象を個々の車両の挙動単位で再現することが可能となりつつある。個々の車両挙動とそれらの相互作用の記述により、道路混雑渋滞の正確な再現や、車線変更挙動の影響などが評価する。シミュレーションアプローチによる交通流の再現では、車線変更や車間距離に関する加減速モデルを設定する。

また、経路の選択についても、従来得ることが難しかった経路の観測が、GPS 機器や携帯端末技術の向上により、可能となっている。プローブパーソンデータなどの移動軌跡データとネットワークデータを組み合わせることにより、オンライン/オフラインでの通行経路の同定や、確率的な推定が可能となる。

(d) 2次元レベル

発生した活動のデータをもとにして、広場や街路空間などの歩行者の挙動の再現を行うことが考えられる。歩行者の挙動については、エージェントモデルとしての行動選択や相互作用表現方法が提案されている。実際の歩行者の挙動を動画データにより観測し、画像解析手法を用いて進行方向や加減速の選択モデルの推定を行うことで、個々の位置座標の再現が可能となる。

4.1.4 シミュレーションモデル構成例

ここでは都市圏のシミュレーションモデルの構成例を2つ取り上げる。

- PCATS/DEBNetS モデル




図 4.1 PCATS と DEBNetS によるマイクロシミュレーション (飯田ら, 2000)

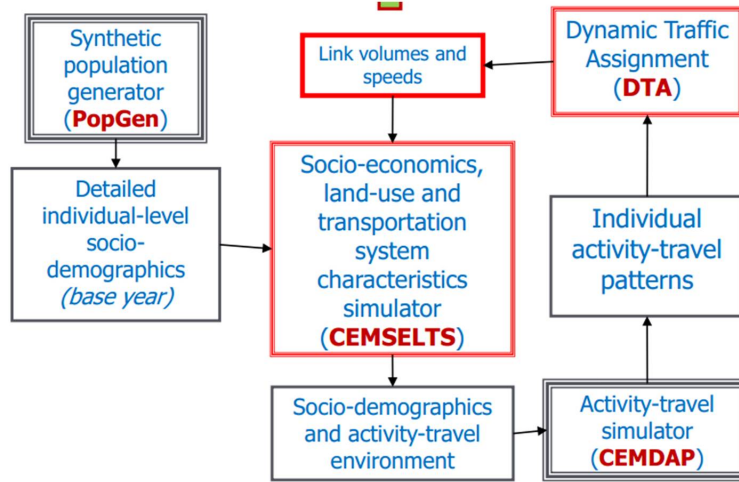


図 4.2 マイクロシミュレーション SimAGENT (Goulias et al., 2012)

生活行動シミュレータ PCATS と動的交通流シミュレータ DEBNetS を組み合わせたマイクロシミュレーションは京都大学で開発された手法である。シミュレーションのシステムを図 4.1 に示す。シミュレーションでは、入力データとして、交通サービスの LOS データとパーソントリップ調査データを入力し、アウトプットデータとして、対象地域での自動車の個々の車両の挙動を再現する。

まず、PCATS 部分で個人の 1 日について睡眠、仕事、学校を固定活動として、それ以外の時間を自由時間として逐次的に活動内容と活動継続時間、目的地と交通機関を推定する。PCATS で推定された交通需要は、PT 調査の拡大計数によって都市圏全体に拡大され、DEBNetS を用いて時間軸上での車両挙動が再現される。

シミュレーションシステムでは、動的交通流シミュレータを回すことで得られた自動車の LOS データを更新して PCATS に入力することで、交通渋滞等が個々人の交通行動に及ぼす影響を考慮されている。

(a) SimAGENT モデル

SimAGENT は、中長期的な意思決定の選択モデル CEMSELTS と、活動-移動シミュレータ CEMDAP、そして動的交通量配分を組み合わせたマイクロシミュレーションモデルである。シミュレーションのシステムを図 4.2 に示す。シミュレーションは交通需要予測と都市圏の自動車による排出ガスの予測を目的としており、ベースとなる年のデータから 1 年ごとの将来時点の状況を予想できるような動的なモデルとなっている。シミュレーションでは、入力データとして、初年度の人口や従業地分布と社会経済状況データを入力し、アウトプットデータとして、対象地域での個人の年間及び日ごとの交通行動を再現する。

まず、人口生成モデル PopGen によって人口分布および社会経済属性データが作成され、それらを用いて CEMSELTS で労働参加、自動車保有、住宅保有などの設定が行われる。次に、活動シミュレータ CEMDAP により、複数選択可能な離散選択モデルの形である MDCEV モデルを用いて、1 日の活動が再現される。生成された交通行動は動的交通配分によりネットワーク上に流され、配分結果のリンク交通量とリンク旅行測度は空間的な所要時間として CEMSELTS にフィードバックされる。

シミュレーションでは、混雑の影響が長期的な意思決定に与える影響を考慮しているほか、1 年単位で人口や世帯分布の更新を行うことで、動的な社会的作用を考慮している。

4.2 活動選択のモデリング

4.2.1 アクティビティモデルの発展経緯

四段階推定法に見られるように、従前の交通行動分析で用いられてきたアプローチは OD 表を所与としたトリップベース (trip-based) の分析であった。1970 年代に入ると、トリップの連結性が重要視されてトリップチェーン (trip-chain, tour-based) 研究が進んだ。一方でアクティビティモデル (activity-based approach) は「すべての移動は活動の派生需要である」という考えのもと、個人・世帯の活動・移動パターンを予測し、再現するモデルとして開発されてきた。移動を発生させる活動の発生そのものを予測す

ることで、交通政策のより正確な評価を可能にするものとして期待されている。アクティビティモデルは、Hagerstrand(1970)[8]の時空間プリズム(図4.3)の考え方を基盤とし、時空間軸上での活動順序や活動時間に着目するスケジューリングモデル(scheduling model)として展開された。また、Chapin(1974)[6]による「すべての活動は個人の基本的欲求から生じる」という考え方から、活動発生モデル(activity generation model)の展開も見られる(Arentze and Timmermans, 2011[3]; Nijland et al., 2013[14])。Kitamura(1988)[10]は、1981年にOxfordで開催された“The Conference on Travel Demand Analysis: Activity-based and Other New Approach”(Carpenter and Jones, 1983[5])がアクティビティモデル発展の試金石となったことに言及し、研究課題による分類をしている。ここでは近年の発展も踏まえ、手法の違いによる類型化を行なう。

アクティビティモデルを分類すると、アクティビティパターンを選択肢集合として列挙する離散選択型モデルと、一定のルールに従ってパターンを生成するルールベースドモデル、そして時空間制約下で実行可能な活動列を探索するネットワーク探索型モデルの3つに大別できる。以下、各類型についての詳細な説明を行なう。

4.2.2 離散選択型モデル

離散選択モデルを用いたアクティビティモデルは、ランダム効用最大化理論(RUM: Randon Utility Maximization)に従って個人の効用に誤差項を仮定し、1日の活動パターンを確率的に選択するモデルである。活動パタンの要素としては、活動開始時刻、活動場所、活動時間、交通手段などが考慮される。それぞれの意思決定には選択肢集合が設定され、個人は自身の効用を最大化させるように選択を行なう。

(a) pre-trip 型モデル

Bowman and Ben-Akiva(2001)[4]は活動パターンと、パターンを構成する主活動の開始時刻、場所と交通手段をネスト構造にして、Nested Logit モデルで一日の活動パタンの生成を定式化した(図4.4)。pre-trip 型の離散選択モデルは一日の活動が自宅を出発する前にすべて決定されることを仮定している。これは基本的な一日の予定と活動パターンについての意志決定は、ツアー




図 4.3 時空間プリズム

内の詳細な意思決定よりも優先されるという概念に基づいている。Bowman and Ben-Akiva(2001)では、一日の活動パターン（スケジュール）が選択される確率 $p(\text{schedule})$ は以下のように表される。

$$p(\text{schedule}) = p(\text{pattern})p(\text{tours}|\text{pattern}) \quad (4.1)$$

ここで、パターン確率とは特定の活動パターンを選択する確率のことを指し、条件付ツアー確率とはパタンの選択から与えられる特定のツアーの集合の確率である。しかし、パタンの選択と条件付きツアーの決定は互いに独立ではない。むしろパタンの相対的な魅力や効用は、パターンと関連しているツアーによって得られる最大効用の期待値に依存している。この期待効用を含めて、パタンの選択確率は全ての選択可能なツアーの選択肢に属する関数である。この関係は、空間的な特性と交通システムのサービスレベルによるパターン選択の感度を表現しており、このモデルシステムの最大の特徴でもある。パターンは以下の項目によって特徴付けられる。

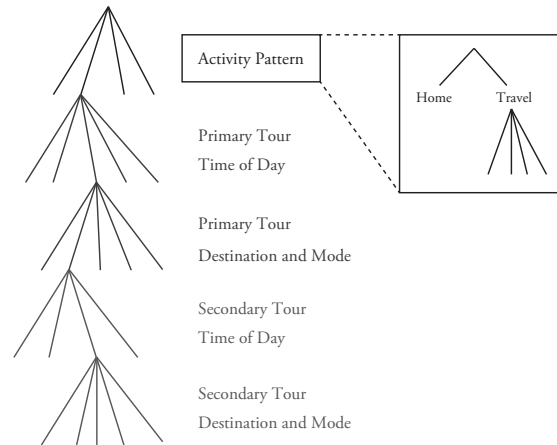


図 4.4 離散選択モデルによる活動パタン生成 (Bowman and Ben-Akiva, 2001[4] をもとに作成)

- (a) 一日中家にいるという選択肢も含む一日の活動の主要な活動
- (b) 回数・目的・一連の活動停止を含むその日の代表活動ツアーのタイプ
- (c) 二次ツアーの回数と目的

アクティビティパタン選択モデルは、図 4.4 に示すようなネスト構造が仮定されており、最下層から推定を行う。また、ツアーの意志決定に関する時刻、交通機関選択と各ツアーにおける活動場所の選択も下位層に含まれており、下層は上層の意思決定によって条件付けられる。このモデルにおける活動は、home(H),work(W),school(S),other(O) の 4 種類のみで構成される。最上部の層であるアクティビティパタンの選択においても Nested Logit モデルを用いて推定を行う。ここでは、上層は一日中家にいるか、または外出するかの二項選択となっており、下層ではアクティビティパタンの組み合わせ、二次ツアーの回数と目的により分類した活動パタンのデータセットにより構成された選択肢を仮定している。全ての旅行は、主要ツアーと 0 回以上

の二次ツアーによって構成されており、二次ツアーの目的地と交通手段選択モデルは目的地と主要ツアーの交通手段によって決定される。二次ツアーは主要ツアーの結果に依存する条件付き確率で表されるため、ツアーの選択確率は、主要ツアーの選択確率と、二次ツアーの条件付き確率を用いて式 4.3 で表される。

$$p(\text{tours}|\text{pattern}) = \quad (4.2)$$

$$p(\text{primary tours}|\text{pattern}) \times$$

$$p(\text{secondary tours}|\text{primary tours})$$

二次ツアーは互いに独立だと仮定することで、二次ツアーの条件付き確率は (3) 式によって表すことができる。

$$p(\text{secondary tours}|\text{primary tours}) = \quad (4.3)$$

$$\prod_{t=1}^T p(\text{secondary tours}_t|\text{primary tours})$$

ここで、 T は二次ツアーの回数を表している。全ての二次ツアーを式 4.4 を用いて計算するため、二次ツアーの相関関係を考慮できないという欠点を有する。式 4.3、式 4.4 を式 4.1 に代入することで、活動スケジュールの選択確率を求めることが出来る。

$$p(\text{schedule}) = \quad (4.4)$$

$$p(\text{pattern})p(\text{primary tours}|\text{pattern}) \times$$

$$\prod_{t=1}^T p(\text{secondary tours}_t|\text{primary tours})$$

図 4.4 に示すネスト構造の第二段階では、主要ツアー、二次ツアーそれぞれに対して、time of day モデルを適用し、1 日を複数の時間帯に分割したものを選択肢として推定を行う。ネストの第三段階では、ツアーを行う際の

交通手段と目的地を選択肢として、Tour destination and mode choice モデルを適用して推定を行う。二次ツアーについても、主要ツアーと同様のモデルを用いて推定を行う。全ての階層での推定結果をもとに、アクティビティパターンが決定される。一般に活動の選択肢は活動場所や活動時間など膨大なデータを扱うため、離散選択モデルでは選択肢集合の生成方法がポイントであり、課題となっている。

(b) 逐次選択型モデル

逐次選択型モデルは自宅出発前に一日のスケジュールを決定する pre-trip 型とは異なり、ツアー中の1つずつの活動について、活動内容（開始時刻や場所など）を順次決定していくモデルである。藤井ら(1997)[18]が開発したPCATS(Prism-Constrained Activity-Travel Simulator)では、個人の一日は自由時間帯と固定時間帯に分類されると仮定し、自由時間帯の活動について、活動時間、活動内容・場所、交通手段を段階的に選択していくモデルを構築した。

PCATSでは、個人は活動実行に要する時間を予め想定し、それに基づいた活動要素を決定するものとした。その際の想定活動時間 y は、ワイブル分布を仮定した以下の Duration Model によって定式化した。

$$y = Y_0 \exp(BX) \quad (4.5)$$

ここで、 Y_0 は標準個人の想定活動時間、 X は説明変数ベクトル、 B はパラメータベクトルである。この想定活動時間をもとに選択肢集合の限定を行い、活動内容選択モデル、交通機関・目的地選択モデルをそれぞれネスティッドロジットモデルとして構築した。図4.5はPCATS内の仮想個人のある自由時間帯 j における意思決定過程を示している。この逐次型の意思決定によって、最終的な1日の活動が生成される。

また、Root and Recker (1981)では、モデルの最初のモジュールで活動の実行の前に pre-travel phase として活動プログラムを決定し、その後活動プログラムに基づいて逐次的に活動を決定していくモデルを定式化した。

離散選択型モデルは、選択構造が明確でモデルの構築が容易である。また、

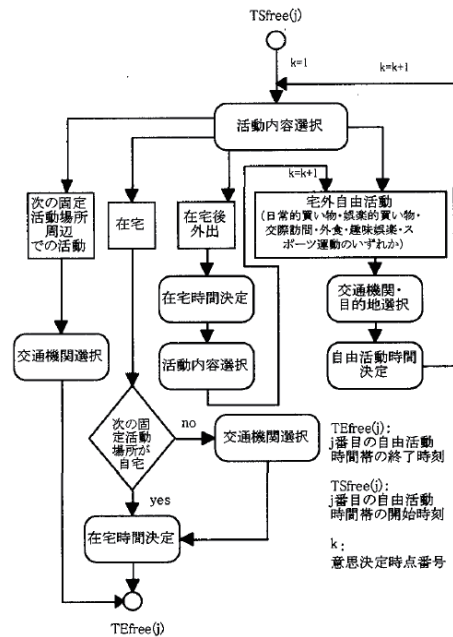


図 4.5 PCATS における逐次選択過程 (藤井ら, 1997[18] より引用)

個人の選択に誤差項を仮定することでパラメータ推定が可能となり、実データとの整合性がとれる。一方で選択肢集合の特定が必要であり、同時的な意思決定を仮定した行動モデルを構築することは選択肢集合の観点からも極めて困難である。

4.2.3 ルールベースドモデル

ルールベースドモデルは、決められたルールの下で活動列を作成していくモデルであり、コンピュータプロセスモデル (CPM: Computational Process Model) とも呼ばれる。Arentze and Timmermans(2004b)[2] の ALBA-TROSS(A Learning-based Transportation Oriented imulation System) では、義務的活動をスケルトンとして事前に決定し、観測データに基づいて活動を付加していくアルゴリズムを開発している。




図 4.6 スケジュールの調整例 (Miller and Roorda(2003)[13] をもとに作成)

また, Miller and Roorda(2003)[13] はデータオリエンテッドなシミュレーションモデルである TASHA(Travel/Activity Scheduler for Household Agents) を提案している. TASHA ではまず, データから属性ごとに生成された活動頻度・活動開始時刻・活動時間の分布に基づいて活動を発生させる. 次に活動場所の選択を行なう. 活動場所はゾーン単位で, 魅力度と移動コストを考慮したロジット型の式で選択確率が定式化される.

活動場所が決定されたあと, 決められたルールに従って活動のスケジューリングを行なう. TASHA ではそれぞれの活動は, 共通の目的を持った活動群である「プロジェクト」に入れられる. プロジェクトには例えば, 仕事関連の活動 (the work project) などがある. そこから, 事前に定められた優先順位に基づいて活動が 1 つずつスケジュール上に配置されていく. 活動時間が重なってしまうなどの齟齬が生じた場合は, 活動内容や活動開始時刻の変更・活動時間の短縮がスケジュール上で適宜行われる. スケジュール調整の例を図 4.6 に示す. ここでは, 既に決定されている活動 1,2 からなるスケジュールに対して活動 3 が挿入されたことで, 活動 1 から 2 への移動が削除される. その後, 活動 1, 2 の開始時刻が変更され, 活動 1 から 3, 3 から 2 の新しいトリップが発生する. このようにあらかじめ定められたルールに従い, 最適なスケジューリングが行われる.

Roorda et al.(2008)[16] では TASHA を用いて, トロント都市圏を対象としたシミュレーション計算を行い, その内容について検証している. こうしたモデルは, 活動の頻度・開始時刻・活動時間が作成した分布に左右されるため, データの収集に課題がある.

4.2.4 ネットワーク探索型モデル

アクティビティモデルでは Hagerstrand(1970)[8] によって時空間プリズムが提唱されたように、時空間軸上の活動表現が重要となる。時空間を 3 次元のネットワークとみなしたとき、活動時間を含めた活動場所間の移動経路が時空間パスによって描かれる。時空間制約下での実行可能パスを探索し、目的関数を最適化する 1 日の活動パターンを生成する手法をここでは「ネットワーク探索型モデル」と呼ぶ。

ネットワーク探索型モデルは時空間制約との整合性が高く、Recker(1995)[15] を端緒としてアクティビティモデルで考慮されてきた。Recker(1995) は活動場所・活動時間に関する時空間制約の下、生成された活動列の目的関数を最適化するように 1 日の活動パターンを決定する HAPP(Household Activity Pattern Problem) を提案した。HAPP は物流計画における PDPTW(Pickup and Delivery Problem with Time Windows: 時間窓付き集荷配送問題) の拡張であり、混合線形整数問題として以下のように記述される。

$$\text{Minimize } Z(\mathbf{X}_i) = \mathbf{B}'_i \mathbf{X}_i \quad (4.6)$$

$$\text{subject to } \mathbf{A} \mathbf{X}_i \leq \mathbf{0}, \quad (4.7)$$

where

$$\mathbf{X}_i = \begin{bmatrix} \mathbf{X} \\ \mathbf{H} \\ \mathbf{T} \end{bmatrix} \quad (4.8)$$

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_{uv}^v = \begin{cases} 0 \\ 1 \end{cases} \end{bmatrix} \quad (4.9)$$

$$\mathbf{H} = \begin{bmatrix} \mathbf{H}_{uv}^\alpha = \begin{cases} 0 \\ 1 \end{cases} \end{bmatrix} \quad (4.10)$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{T}_u \gg \mathbf{0} \end{bmatrix} \quad (4.11)$$

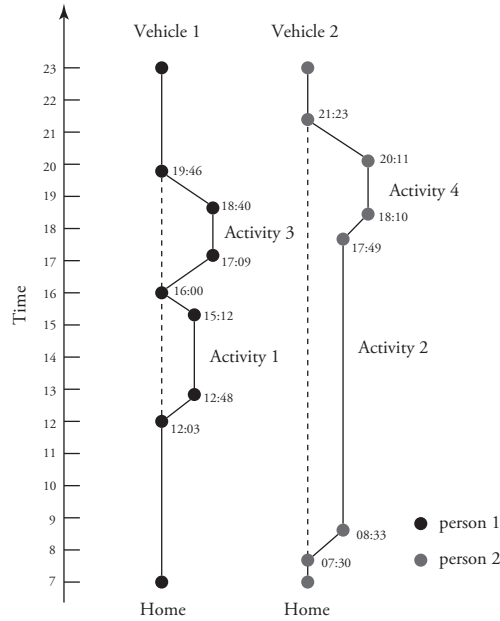


図 4.7 世帯の最適活動パターン例 (Gan and Recker, 2008[7] をもとに作成)

ここで、 \mathbf{B}'_i は交通行動に伴うコストを決定する各変数の係数 (パラメータ) ベクトルであり、 $\mathbf{A}\mathbf{X}_i \ll \mathbf{0}$ は線形計画問題に伴う制約条件を表している。最終的に求めるものは目的関数 $\mathbf{Z}(\mathbf{X}_i)$ を最小にする活動列 \mathbf{X}_i であり、以下の変数によって特定化される。

\mathbf{X}_{uw}^v : 活動 u から活動 w への移動に際して車両 v (世帯が保持している自動車や自転車) が用いられれば 1, それ以外で 0

H_{uw}^α : 世帯構成員 α が活動 u から活動 w へ移動すれば 1, それ以外で 0

T_u : 活動 u の開始時間

この結果、出発時刻や移動手段、世帯構成員との関係を考慮した「最適な」1日の活動パターンが求められる。その例を図4.7に示す。個人ごとに、行われる活動の順序、活動に用いる移動手段、そして個々の活動の開始・終了時刻が算出される。HAPPは以後も発展研究がなされており、活動の変更や時間調整を考慮したGan and Recker(2008)[7]のHARP(Household Activity Rescheduling Problem)や、活動場所選択を考慮したKang and Recker(2013)[9]のLSP(Location Selection Problem)-HAPPなどがある。

また、Arentze and Timmermans(2004a)[1]は1)交通手段、2)活動場所、3)活動実行状況の3つから決まる状態のネットワークであるMultistate supernetworkを提案し、状態間を移動する経路を一日の活動として定義した。近年では、他人とのスケジュール調整を考慮したモデル(Liao et al., 2013a[11])、活動場所選択に関する時空間制約が明示的に考慮されたモデル(Liao et al., 2013b[12])として展開された。

こうしたネットワーク探索型のアクティビティモデルは、時間窓(出勤時間や店舗の営業時間)などの時空間制約を明示的に組み込める点、選択肢集合の取り扱いが離散選択モデルに比べて比較的安易な点で優れている。一方で、誤差項を扱わないことによる推定の難しさや、解法による計算負荷への対処などに課題があると指摘されている。

参考文献

- [1] Arentze, T.A. and Timmermans, H.J.P.: Multistate supernetwork approach to modelling multi-activity, multimodal trip chains, *International Journal of Geographical Information Science*, 18(7), 631-651, 2004a.
- [2] Arentze, T.A. and Timmermans, H.J.P.: A learning-based transportation oriented simulation system, *Transportation Research. Part B: Methodological*, 38(7), 613-633, 2004b.
- [3] Arentze, T., Eetema, D., Timmermans, H.: Estimating a model of dynamic activity generation based on one-day observations: method and results, *Transportation Research Part B*, Vol.45, pp.447-460, 2011.
- [4] Bowman, J. L., Ben-Akiva, M. E.: Activity-based disaggregate travel demand model system with activity schedules, *Transportation Research A*, Vol. 35, No, 1, pp. 1-28, 2001.

- [5] Carpenter, S. and Jones, P.: Recent Advances in Travel Demand Analysis. Gower, Aldershot, England.
- [6] Chapin, F.S.: Human Activity Patterns in the City. Wiley, New York, 1974.
- [7] Gan, L.P. and Recker, W.: A mathematical programming formulation of the household activity rescheduling problem, *Transportation Research Part B*, 42, 571-606, 2008.
- [8] Hagerstrand, T.: What about people in regional science? *Papers of the Regional Science Association*, Vol. 24, No. 1, pp. 6-21, 1970.
- [9] Kang, J. E., Chow, J. Y. J., Recker, W. W.: On activity-based network design problems, *Procedia Social and Behavioral Sciences*, Vol. 80, pp. 157-185, 2013.
- [10] Kitamura, R.: An evaluation of activity-based travel analysis, *Transportation*, 15, 9-34, 1988.
- [11] Liao, F., Arentze, T., Timmermans, H.: Multi-state supernetwork framework for the two-person joint travel problem, *Transportation*, 2013a.
- [12] Liao, F., Arentze, T., Timmermans, H.: Incorporating space-time constraints and activity-travel time profiles in a multi-state supernetwork approach to individual activity-travel scheduling, *Transportation Research Part B*, Vol.55, pp.41-58, 2013b.
- [13] Miller, E. J., Roorda, M. J.: Prototype model of household activity/travel scheduling, *Transportation Research Record*, No. 1831, pp. 114-121, 2003.
- [14] Nijland, L., Arentze, T., Timmermans, H.: Representing and estimating interactions between activities in a need-based model of activity generation, *Transportation*, Vol.40, pp.413-430, 2013.
- [15] Recker, W.: The household activity pattern problem: general formulation and solution, *Transportation Research B*, Vol. 29, No. 1, pp. 61-77, 1995.
- [16] Roorda, M. J., Miller, E. J., Habib, M. N. K.: Validation of TASHA: A 24-h activity scheduling microsimulation model, *Transportation Research Part A*, Vol.42, pp.360-375, 2008.
- [17] 西井和夫：時空間制約下における2ストップチェーンのバス選択モデル，土木学会論文集，No.470，pp.105-114，1993.
- [18] 藤井聡，大塚祐一郎，北村隆一，門間俊幸：時間的空間的制約を考慮した生活行動軌跡を再現するための行動シミュレーションの構築，土木計画学研究・論文集，No. 14，pp. 643-652，1997.

4.2.5 選択肢集合限定のモデリング

本章では，選択肢集合を考慮した行動モデルについて，概説する．人が意思決定をする際には，まず選ぶべき選択肢（選択肢集合）を想定し，その中から選択を決定する．選択肢の選択過程を定式化し，行動モデルを記述することにより，選択肢集合の記述原理をモデル化する．

(a) 基本モデル

個人 q の選択行動は、次の 2 段階の選択の結果であると仮定する。

step1 選択肢集合の選択 全選択肢集合 G の中から個人 q が選択する可能性のある選択肢集合 S を選択する。

step2 選択肢の選択 選択肢集合 S の中から個人 q が最も望ましい選択肢 i を選択する。

これまでのモデルと比べて、選択肢集合の選択過程である *step1* が追加されている。人が意思決定する際に想定する選択肢数には上限 (多くてもせいぜい 10 以下か) があり、全選択肢集合 G の数が多い場合には *step1* は特に有効となる。Manski(1977)[1] では、選択肢 i の全選択肢集合 G からの選択確率を条件付き確率を用いて、式 4.12 と定式化している。

$$P_q(i|G) = \sum_{S \in G} P_q(i|S)P_q(S|G) \quad (4.12)$$

式 4.12 のように記述できるものの個人の選択肢集合の観測は困難であり、選択肢集合のモデル化は難しい。そこで、観測可能な選択結果を用いた尤度関数の設定により、選択肢集合の選択確率をモデル化している。

PCMNL モデル

Basar and Bhat(2004)[3] では probabilistic choice set multinomial logit(PCMNL) モデルを提案している。選択肢 i の選択肢集合効用が一定の閾値を超えていれば、個人 q の選択肢集合 G に含まれると仮定する。しかし、ここで閾値は観測不能であり、選択肢集合に含まれる確率はロジスティック分布を用いて、次で表す。

$$M_{qi} = \frac{1}{1 + \exp(-\gamma w_{qi})} \quad (4.13)$$

選択肢をここでは、選択肢 i の効用を U_{qi} である。なお、 w_{qi} は個人 q の選択肢 i に関する属性、 γ は効用算出のための係数である。選択肢集合 G の選択確率は次となる。

$$P_q(G) = \frac{\prod_{i \in G} M_{qi} \prod_{j \notin G} (1 - M_{qj})}{1 - \prod_{i=1}^I (1 - M_{qi})} \quad (4.14)$$

分母は選択肢集合が空となる確率を除外している。選択肢集合 G から選択肢 i を選ぶ確率は MNL モデルと同様に定式化する。

$$P_{qi}|G = \frac{\exp(\beta'x_qi)}{\sum_{j \in G} \exp(\beta'x_qj)} \quad \text{if } i \in G \quad (4.15)$$

$$= 0 \quad \text{if } i \notin G \quad (4.16)$$

x は外生変数、 β は係数である。選択肢 i の選択確率は次となる。

$$P_{qi} = \sum_G (P_{qi}|G) \cdot P_q(G) \quad (4.17)$$

ここで、全選択肢数を I とすると、 G は $(2^I - 1)$ 個となる。対数尤度関数は次で定義され、パラメータ β と γ を推定する。 y_{qi} は選択結果である。

$$L(\beta, \gamma) = \sum_q \sum_i y_{qi} \cdot \log P_{qi}(\beta, \gamma) \quad (4.18)$$

参考文献

- [1] Manski, C.: The structure of random utility models, *Theory and decision*, vol. 8, pp. 229-254, 1977.
- [2] Kaplan, S., Shifan, Y., Bekhor, S.: Development and estimation of a semi-compensatory model with a flexible error structure, *Transportation Research Part B*, Vol. 46, Issue. 2, pp. 291-304, 2012.
- [3] Basar, G., Bhat, C.: A parameterized consideration set model for airport choice: an application to the San Francisco Bay Area, *Transportation Research Part B*, Vol. 38, Issue. 10, pp. 889-904, 2004.

4.3 経路選択モデル

4.3.1 確定的に経路選択肢を列挙する方法

OD 交通量をネットワークあるいは経路集合に対して配分するとき、その OD に関して経路の設定が必要となる。大規模なネットワーク上の経路選択

を考えると、OD間で考えられる経路は膨大であり、その中から適切な経路を抽出し、フローを流す手法が求められる。配分に関する経路選択のモデリングについてはさまざまなアプローチがこれまでとられてきた。ここでは、明示的に経路を列挙する方法、確率的に経路を列挙する方法、経路を列挙しない方法に分けて解説する。

まず、明示的に経路を扱って選択するアプローチを取り上げる。ここでは、経路の列挙方法として、以下の方法を紹介する。

- ダイクストラ法
- K 番目最短経路探索
- ラベリング法
- ペナルティ法
- Gateway Shortest Paths

ダイクストラ法

1 つ目は、経路を具体的に各 OD について確定的に明示して経路選択肢を定める方法である。ネットワーク上で経路を探索して列挙する方法の多くは Dijkstra (1959)[?] による最短経路探索アルゴリズム (ダイクストラ法) が経路探索のベースとなっている。ダイクストラ法はネットワーク上の起点・終点間の最短経路を求めるアルゴリズムであり、各リンクのコストが非負で設定されるとき、ある起点ノードから終点ノードまでの最小コストとなる経路を求めることができる。以下にダイクストラ法のアルゴリズムを述べる。なお簡単のため、コストはリンクの距離のみにより決定されることとして、最短経路は経路長距離が最小となる経路を表すこととする。リンクの距離は明らかに非負となる。

ネットワーク上の起点ノードを r 、終点ノードを s とすると、 rs 間の最短経路は次のステップにより求めることができる。ここで、ノード i についての起点からの最短距離を d_i 、 ri 間の最短経路上でのノード i の 1 つ前のノードを π_i とする。また、リンクにより結ばれたノード ij 間の距離を c_{ij} とする。ステップごとのイメージを図 4.8 に示す。




図 4.8 ダイクストラ法アルゴリズム

ステップ1 初期化

起点ノード r について $d_r = 0$ 、その他のノードについて $d_i = \infty$ を設定する。このとき、起点ノード r を最短距離確定済ノード集合 V に入れ、その他のノードを未確定ノード集合 U に入れる。 $i = r$ とする。

ステップ2 最短距離確定点から隣接ノードを探索

最短距離を確定させたノード i からリンクにより隣接する全てのノード j に対して、最短距離を計算する。 $d_j > d_i + c_{ij}$ であれば $d_j = d_i + c_{ij}$ としてノード j の最短距離 d_j を更新し、 $\pi_j = i$ とする。

ステップ3 ノードまでの最短距離の確定

未確定ノード集合 U に含まれるノードのうち最短距離が最も小さいノードについて、値を確定させて未確定ノード集合 U から確定済ノード集合 V に移す。このノードをノード i とする。

ステップ4 全ノードが V に入るまで繰り返し計算


全てのノードが確定済ノード集合 V に含まれるまで、ステップ2とステップ3を繰り返す。全てノードの最短距離が確定したら、終点ノード s から π_i を辿っていくことによって、 rs 間の最短経路を求められる。

ダイクストラ法のアルゴリズムについては、隣接行列を用いて全ての OD ペアの最短経路を求める Floyd (1962)[?] と Warshall (1962)[?] による Floyd-Warshall 法や、最短距離を確定させるノードを暫定的な最短距離が最小となるノードでなく空間的に目的地に近いノードから優先的に探索する A*法 (Hart et al., 1968[?]) が提案されている。加藤 (1994) は行政区域単位で探索範囲を限定する方法を提案している。


K 番目最短経路探索

最短経路探索を拡張して複数経路を求める方法として K 番目最短経路探索 (Yen, 1971[?], Katoh et al., 1982[?] など) を紹介する。K 番目最短経路探索では、同一のコスト、同一の評価観点によって複数の経路を求める経路を求め、2 番目、3 番目と K 番目に短い経路を順に列挙する。図 4.9 に K 番目最短経路の探索例を示す。経路の探索では、それまでに既に列挙されている


1番目最短経路



2番目最短経路



3番目最短経路



4番目最短経路




図 4.9 K 番目最短経路の探索結果例

経路と重複しない経路の中で、起点から終点までの距離が最短となる経路が列挙される。K 番目最短経路探索のアルゴリズムを以下に述べる。

ネットワーク上の起点ノードを r 、終点ノードを s とすると、 rs 間の K 番目最短経路は次のステップにより求めることができる。ここで、 K は列挙する経路数、 P は rs 間の K 番目最短経路集合、 P_i は起点ノード r からノード i までの経路、 B は計算上で暫定的な経路を格納する集合、 $count_i$ をノード i における最短経路数、 c_{ij} をリンクにより結ばれたノード ij 間の距離とする。

ステップ1 初期化

rs 間の K 番目最短経路集合 P を空集合とし、全てのノード i について $count_i = 0$ とする。 $P_r = \{r\}$ を B に入れる。

ステップ2 最短経路の探索

ノード i について、 B に含まれる ri 間経路の中で最短経路となる経路を P_i とする。 B から P_i を除き ($B = B - \{P_i\}$)、 $count_i = count_i + 1$ とする。

ステップ3 最短経路の格納

ノード i が終点ノードのとき ($i = s$)、最短経路集合 P に P_s を加える。

ステップ4 最短経路の更新

$count_i < K$ のとき、ノード i からリンクにより隣接する全てのノード j に対して P_i に j を加えた経路を P_j とし、 B に P_j を加える。

ステップ2～ステップ4を全てのノードについて実行する。

ステップ5 終了判定

B が空集合となるか、 $count_s = K$ となれば、アルゴリズムを終了する。

K 番目経路探索では、最短経路から1ブロック分迂回しただけの経路など、最短経路と殆どの区間重複する経路が生成されてしまう問題がある。天目(2000)[?]ではK番目経路探索において経路重複率と分岐・合流の回数を考慮した列挙アルゴリズムを用いて実用的な代替経路を探索する工夫をしている。

ラベリング法

多数の評価観点に従って複数経路を列挙する方法として、ラベリング法 (Ben-Akiva et al., 1984[?]) が挙げられる。Ben-Akiva et al. (1984) は、経路選択に影響を与える属性を、所要時間、距離、良景観道路長、信号数、混雑、高速道路長、交通容量、商業地区を通る道路長、舗装状態、道路の階層、の10の要素挙げて、それぞれについて最適となる経路を最短経路探索のアルゴリズムを利用することで抽出し、経路選択肢集合としている。山川・羽藤(2008)[?]ではラベリング法のリンク属性をプローブデータから設定することでプローブパーソン調査から経路選択モデルを構築している。

ペナルティ法

ペナルティ法は、計算された最短経路上のリンクについて抵抗となるペナルティを与えた上で再び最短経路探索を行うことにより、異なる経路を列挙




図 4.10 菱形を用いた GSP の適用 (Yamakawa and Hato, (2008) より)

する方法である。ペナルティ法は、1) ペナルティの付加方法の決定、2) 最短経路の探索、3) 最短経路上のリンクにペナルティを付加、4) 探索された最短経路を経路集合に加えて列挙経路数に達するまで 2)~4) を繰り返す、という手順で経路の探索を行う。ペナルティの付加方法は、予め定めた定数をリンクのコストに加える方法と、リンクのコストを一定の率で増加させる方法とが考えられる。Bekhor and Prato (2006) では、最短経路とされた経路上でのリンクについて、リンクの所要時間に 5% の抵抗をペナルティとして加えて、15 回計算を繰り返している。

Gateway Shortest Paths

Gateway Shortest Paths (GSP) は、OD 間の特定の箇所を Gateway として列挙し、その Gateway を通過する条件のもとでの最短経路の探索を行う方法である。木下ら (2004)[?] は、起終点を結ぶ線分の垂直二等分線上を通過するリンクを Gateway として設定し、各リンクについて、リンクの一方の端のノードと起点ノードを結ぶ最短経路ともう一方の端のノードと終点ノードを結ぶ最短経路を結合させることにより経路を生成している。経路の列挙は、最短経路と比較した経路長が基準値以下であり、かつ経路上にループを持たない経路を全て列挙している。また、Yamakawa and Hato (2008)[?] も、起終点間において OD 間を結ぶ線分に対してなす角 θ となる直線により生成される菱形の中心線を通るリンクをプローブデータを用いた経路選択モデルの経路選択枝列挙に適用し、最適となる角度 θ について考察を行っている。(図 4.10)

4.3.2 確率的に経路選択肢を列挙する方法

シミュレーション法

シミュレーション法は、計算機による乱数発生を用いたモンテカルロ法によって、確率的に経路を抽出し、経路列挙を行う方法である。シミュレーション法では、ネットワーク上の各リンクのコストが独立な確率分布に従う条件下で、最小コストとなる経路の抽出を繰り返す方法である。シミュレーション法では、確率分布型、確率分布のパラメータ、乱数発生による抽出回数を事前に決定する。Bekhor et al. (2006)[?] では、リンクコストが平均及び標準偏差にリンク所要時間を仮定した正規分布に従うものとしてランダムサンプリングを行い、経路抽出を行っている。

リンクのコストに正規分布を仮定した配分モデルはプロビット配分モデルと呼ばれる。プロビット配分モデルでは旅行者の知覚旅行時間が確率的であるとするランダム効用理論を基本とし、導出される。シミュレーションによるプロビット配分モデルでは、経路選択モデルにおいて誤差項にガンベル分布を仮定して導かれるロジットモデルが持つ IIA 特性がなく、重複区間を持つ複数経路を持つ誤差の相関を考慮でき、プロビット選択モデルと理論的に整合性を持つ。OD ペア間で経路の重複が多く生じると考えられる鉄道経路選択モデルにおいて適用例が見られる。(屋井ら (1993)[?], Yai et al. (1997)[?], 円山ら (2001)[?])

Daganzo and Sheffi (1977) [?] は旅行者が持つリンクの知覚旅行時間が正規分布に従うと仮定している。

$$T_a = N(t_a, \beta t_a) \quad (4.19)$$

$$C_k^{rs} = \sum_a T_a \delta_{a,k}^{rs} \quad (4.20)$$

ここで、 T_a はリンク a の旅行者の知覚旅行時間、 t_a はリンク a の知覚旅行時間の期待値、 β は知覚旅行時間の分散パラメータ、 C_k^{rs} は OD ペア rs 間の経路 k の知覚旅行時間、 $\delta_{a,k}^{rs}$ はリンク a が OD ペア rs 間の経路 k に含まれるかどうかを表す指示変数である。

OD ペア rs の交通量は、乱数発生サンプリングにより得られた経路へ全て配分される。経路の抽出を複数回繰り返すことにより、各試行回において配分される交通量が求まり、各リンクに配分される交通量は各試行回で配分された交通量を平均することにより求まる。 l 回サンプリングを終えた時点でリンク a の配分交通量 $x_a^{(l)}$ は、 l 回目のサンプリングによりリンク a に配分された交通量 $X_a^{(l)}$ を用いて、以下のように表される。

$$x_a^l = \frac{(l-1)x_a^{l-1} + X_a^l}{l} \quad (4.21)$$

プロビット配分モデルはモンテカルロ法による方法以外にも、Maher and Hughes (1997)[?] が内挿法近似による効率解法を提案している。

ランダムウォーク

経路選択枝の確率的な抽出方法として、Frejinger et al. (2009)[?] は重み付きのランダムウォークにより、ネットワーク上で起点ノードから終点ノードに至るまでの経路を抽出する方法を提案している。経路はネットワーク上のノードごとに確率的に次のリンクを選択する方法により生成され、起点を出発点として終点に到達するまで、乱数発生による確率的なリンクの選択を繰り返す。経路は、リンクの選択確率は迂回度を用いた重みによって抽出される。

ネットワーク上での起点ノードを r から終点ノード s までの経路のサンプリングアルゴリズムを以下に示す。なお、 $SP(i, j)$ はノード i からノード j までの最短経路、 c_l はリンク l のコスト、 ϵ_i はノード i を起点とするリンクの集合である。

ステップ1 初期化

現在のリンク i を r とする。

ステップ2 リンクの相対的迂回度の計算

ノード i を起点とするリンク $l = (i, j) \in \epsilon_i$ について、相対的迂回度 x_l を以下の式で計算する。

$$x_l = \frac{SP(i, s)}{c_l + SP(j, s)} \quad (4.22)$$

ステップ3 リンクの重みの計算

ノード i を起点とするリンク $l = (i, j) \in \epsilon_i$ について、重み $\omega(l|b_1, b_2)$ を以下の式で計算する。ただし、 b_1 と b_2 はパラメータである。

$$\omega(l|b_1, b_2) = 1 - (1 - x_l^{b_1})^{b_2} \quad (4.23)$$

ステップ4 リンクを選択確率の計算

ノード i を起点とするリンク $l = (i, j) \in \epsilon_i$ について、選択確率 $q(l|\epsilon_i, b_1, b_2)$ を以下の式で計算し、乱数発生により確率的にリンクを選択する。選択されたリンク $l = (i, j)$ について、 $i = j$ とする。

$$q(l|\epsilon_i, b_1, b_2) = \frac{\omega(l|b_1, b_2)}{\sum_{m \in \epsilon_i} \omega(m|b_1, b_2)} \quad (4.24)$$

ステップ5 経路の生成

ステップ2～ステップ4を $i = s$ となるまで繰り返し計算し、経路を生成する。

経路の一部置換による代替選択枝生成

Flotterod and Bierlaire (2013)[?] は、ネットワーク上での起終点間の経路列挙について、最短経路の一部をメトロポリス・ヘイスティングス法 (MH法) を用いて確率的に置換することで抽出する方法を提案している。図 4.11 に MH 法による代替選択枝生成の概念図を示す。MH 法による経路抽出では、最短経路上でノードを 3 点ランダムに選択し、起点から順に 3 点並べたときに中間となるノードを確率的に他のノードに置き換え、各点を結ぶ最短経路を結合させた経路が生成される。生成経路は重複区間や周回を持つ場合は代替経路の候補を満たさない。生成された経路に対しては選択確率が定義され、選択確率に応じた採択率によって生成経路を採択するか棄却するかを決定する。




図 4.11 メトロポリス・ヘイスティングス法による代替選択枝生成の概念図 (Flotterod and Bierlaire (2013) より)

4.3.3 経路を明示しない方法

Dial アルゴリズム

ここでは、有効経路を考慮して明示的に経路を挙げずに交通量を配分する方法を扱う。現実の交通ネットワーク上で OD 交通量の配分を行う場合、想定される経路選択枝集合は膨大になり、全てを列挙することは困難である。経路を明示しない交通量の配分方法では、困難な経路の列挙を回避することができる利点がある。

経路の列挙を必要としない方法として、Dial (1971) によるロジット型経路選択を仮定した交通量配分が挙げられる。Dial (1971) はネットワーク上で交通量の配分の対象となる経路集合を *efficient paths* と呼び、*efficient paths* に交通量を配分するアルゴリズムを提案している。

マルコフ連鎖

経路を限定的に明示しない方法として、通行するノード或いはリンクを確率過程として捉えたマルコフ連鎖による記述アプローチがある。交通量の流れを巨視的にマルコフ連鎖と考えて定式化したモデルが佐佐木のマルコフモデルである。マルコフモデルでは、交通流は交差点で確率的に方向を変えて次の交差点へ向かうように観察する。対象とする交通の経路はノードまたはリンクの遷移確率に従って表され、各時点で逐次的に選択を行っていることを仮定してモデル化される。佐佐木 (1965)[?] は自動車の交通流に、佐佐木・




図 4.12 マルコフ連鎖による推移確率設定例

松井 (1968)[?] は歩行者の流動にそれぞれマルコフ連鎖を用いてモデルを提案している。

ネットワーク上での経路選択行動にマルコフ連鎖を仮定したときの推移確率設定例を図 4.12 に示す。推移確率行列 P の i 行 j 列の要素を $p(i, j)$ と表すと、 $p(i, j)$ はノード i からノード j への推移確率とする。例えば、2 行目 3 列目の $2/3$ は、現在ノード 2 にいるとき次のノードがノード 3 となる確率が $2/3$ であることを表している。ここでマルコフ連鎖の推移確率行列を満たすべき条件として、全ての i, j において $p(i, j) \geq 0$ 、 $\sum_j p(i, j) = 1$ である。

マルコフ連鎖での推移状態を吸収源、発生源、過渡状態の 3 つに分類する。吸収源は交通流が吸収される状態であり、経路の終点となり、推移確率行列では $p(i, i) = 1$ となる状態 i である。図 4.12 の例では、ノード 1 が該当する。発生源は交通流が発生する起点となる状態であり、全ての i について $p(i, j) = 1$ となる状態 j である。図 4.12 の例では、ノード 5 が該当する。交通流の発生も吸収も起こらない状態は過渡状態である。図 4.12 の例では、ノード 2, 3, 4 が該当する。

発生源、吸収源の個数をともに r 、過渡状態の個数を m とすると、吸収マルコフ連鎖モデルにおける推移確率行列は以下のような配置により定義されることとする。

$$P = \begin{pmatrix} \overbrace{\begin{matrix} I & 0 & 0 \end{matrix}}^{r \text{ 吸収源}} \\ \overbrace{\begin{matrix} 0 & 0 & Q_1 \end{matrix}}^{r \text{ 発生源}} \\ \overbrace{\begin{matrix} R & 0 & Q_2 \end{matrix}}^{m \text{ 過渡状態}} \end{pmatrix} \quad (4.25)$$

I は $r \times r$ の単位行列、 Q_1 、 Q_2 はそれぞれ $r \times m$ 、 $m \times m$ の過渡状態への遷移確率を表す行列、 R は $m \times r$ の過渡状態から吸収源への遷移確率を表す行列である。マルコフ性の仮定から、各行の行和は 1 となる必要がある。

吸収マルコフ連鎖では状態間の遷移が連鎖的に繰り返され、 Q_2 は 1 回のステップでの過渡状態間の遷移確率を表す。考慮する経路において周回経路を含むことを許すとき、現在の状態から無限回までの遷移状態を経た状態を考慮した遷移確率の合計は、行列計算より以下の式で表すことができる。

$$I + Q_2 + Q_2^2 + \dots = (I - Q_2)^{-1} \quad (4.26)$$

これを吸収マルコフ連鎖の基本行列と呼ぶ。ここで各発生源で発生する交通量を行ベクトルで、

$$U = (u_1, u_2, \dots, u_r) \quad (4.27)$$

と表し、各過渡状態を通過する交通量を行ベクトルで、

$$X = (x_1, x_2, \dots, x_m) \quad (4.28)$$

表すとすると、通過交通量 X はネットワーク内で発生した車両がいずれかの吸収源に吸収されるまでに、各過渡状態を通過した回数として定義することができる、以下のように表される。

$$X = UQ_1(I - Q_2)^{-1} \quad (4.29)$$

図 4.13 にネットワーク上での周回経路の例を示す。




図 4.13 周回経路の例

4.3.4 歩行者の経路探索モデル

空間を2次元平面として捉えたとき、移動可能な経路集合は無数に存在する。本項では歩行者の経路探索モデルとして、障害物や他者の影響を受けて微視的な2次元平面上のODを動く歩行者の挙動を記述するための方法を紹介する。

歩行者の経路探索モデルは、主に混雑状況下における群集行動や避難行動の再現に用いられ、様々な分析手法がとられてきた。交通分野では交差点や駅構内の群衆流において適用事例が見られる。(※参考文献) こうした手法は微視的な空間設計における直接的なインプリケーションを得られる面でも注目を集めている。

本項では、各歩行者をエージェントベースで捉え、各時点で次の一步を予測することで全体としての歩行者の経路・フローを再現し、予測するモデルを紹介する。中でも、ニュートンの運動方程式を援用した力学的モデル、セル・オートマトン法を用いたモデル、ポテンシャル関数を導入したモデル、離散選択モデルが代表的である。さらに近年では、歩行者同士の譲歩・回避行動に着目し、ゲーム理論を援用したモデルなども見られる。

(a) Social Force モデル

Social Force モデルは物理法則を基にした力学的モデルである。各歩行者を物体とみなし、設定した運動方程式を解くことによって得られる加速度ベクトルから次の時刻における歩行者の位置を実座標上で表現する。

$$F_{\alpha}(t) = F_{\alpha}^0(v_{\alpha}, v_{\alpha}^0 e_{\alpha}) + \sigma_{\beta} F_{\alpha\beta}(e_{\alpha}, r_{\alpha} - r_{\beta}) \\ + \sigma_{\beta} F_{\alpha\beta}(e_{\alpha}, r_{\alpha} - r_{\beta}^{\alpha}) + \sigma_i F_{\alpha i}(e_{\alpha}, r_{\alpha} - r_i(t)) \quad (4.30)$$

次の時点における進行方向と速度を決めるベクトルは、式 4.30 によって求められる。右辺第 1 項は目的地指向性を表すベクトル、第 2 項は他の歩行者からの反発ベクトル、第 3 項は障害物から受ける反発ベクトル、そして第 4 項は同行者や魅力的なものの吸引ベクトルを示し、これらの足しあわせによって次時点までの加速度ベクトルを決定する。計算のステップを以下に示す。

ステップ 1

式 4.30 に基づき、周囲の状況から受ける力（加速度ベクトル）を計算。

ステップ 2

算出した加速度ベクトルから現在の速度、進行方向を更新。

ステップ 3

速度ベクトルと離散化された時間ステップ幅 Δt から、現在地を更新。

ステップ 4

ステップ 1~3 をすべての歩行者に対して行なう。

Social Force モデルの概念を図 4.14 に示す。歩行者は他者や障害物（壁）から反発ベクトルを受けてそこから遠ざかるように動く一方、目的地に向かおうとする力が働く。これらのベクトルの総和から次時点の進行方向、速度が求められ、現在地が逐次的に更新されていく。




図 4.14 Social Force モデル

(b) セル・オートマトン法

セル・オートマトン法は空間を均一なセル状に分割し、歩行者がセル間を推移すると仮定して歩行者の挙動を表現するモデルである。各セルには歩行者密度や障害物の存在といった時刻ごとに更新される状態量が与えられる。歩行者はセルの状態量に基づく遷移ルールに従い、隣接セル間を遷移する。遷移ルールの違いによってさまざまなモデル考案されており、前歩行者の速度を一定としてセル間を移動させるもの、移動先のそれぞれのセルに進む確率が現在速度に基づくとしたもの (Schadscheider, 2002) など、研究に多くの蓄積が存在する。以下、セル・オートマトン法を用いた歩行者モデルの移動先決定のステップを示す。

ステップ 1

隣接するセル (フォン・ノイマン近傍, ムーア近傍など) について、歩行者密度、障害物の存在といった情報から各セルの状態量を計算。

ステップ 2

隣接セルの状態量をもとに、あらかじめ設定された遷移ルールに基づいて移動先を決定。

ステップ 3

現在地（移動先のセル），およびセルの状態量を更新．

ステップ 4

ステップ 1~3 をすべての歩行者に対して行なう．

図 4.15 にセル・オートマトン法を用いた場合の概念図を示す．空間はセル状に離散化され，個人は遷移ルールに従って隣接するセルのいずれかに移動する．




図 4.15 セル・オートマトンモデル

セル・オートマトン法はモデル自体がシンプルで理解しやすく，かつ動的な歩行者の挙動を少ない時間で計算可能にする点で優れている．一方で，セル上の動きに簡素化されて状態量の変化や歩行者の軌跡が自然な形で表現出来ない点や，セルの大きさによってモデルの精度，評価が左右されるという欠点もある．

(c) ポテンシャル関数

ポテンシャル関数を用いたモデルは，2次元上の空間に対して障害物や他の歩行者などの影響による経路コスト（ポテンシャル）を設定することで，ほぼ無限に存在する経路選択肢の中からコストを最小とするように移動軌跡を

決定するモデルである。歩行者は選択された経路にしたがって次時点の現在位置を更新する。

ステップ 1

歩行者が移動する空間を離散化し、それぞれについて障害物や他の歩行者などの影響からポテンシャルを計算。

ステップ 2

計算したポテンシャルに従い、目的地までのコストが最小になるような経路が決定される。

ステップ 3

決定した経路に従い、次時点の現在地を更新。

ステップ 4

ステップ 1~3 をすべての歩行者に対して行なう。

図 4.15 にポテンシャル関数を用いた場合の概念図を示す。現在地から目的地までの経路が、障害物や他の歩行者によって形成される不効用のポテンシャルによって一意に決定される。




図 4.16 ポテンシャル関数

(d) 離散選択モデル

離散選択モデルは、個人が確率的意思決定に基づき、最も効用の高い選択肢（次時点の移動先）を選択すると仮定したモデルである。選択肢集合は現時点の歩行者の進行方向・速度をもとにした歩行平面上を離散的に分割したものである。Antonini(2006)は歩行平面を進行方向を軸にした 170° の扇型として設定し、11の角度、3の速度（加速/速度保持/原則）からなる33の選択肢を考えている。単純な歩行傾向を示す方向維持性、目的地指向性、速度維持性に加え、他の歩行者の影響も考慮して効用関数を設定することで、混雑状況下の挙動も再現した。離散選択モデルでは、各選択肢の効用は以下の式で表される。

$$U_{ni} = V_{ni} + \epsilon_{ni} \quad (4.31)$$

$$V_{ni} = \sum_k \beta_{ni,k} X_{ni,k} \quad (4.32)$$

ここで $X_{ni,k}$ は個人 n の選択肢 i に対する k 番目の説明変数を差し、 $\beta_{ni,k}$ はそのパラメータを表す。説明変数は目的地との距離や目的地方向角度、障害物や他者との距離、希望速度と現在速度の比など、評価したい内容や目的に応じて設定される。離散選択モデルを用いた移動経路予測における計算ステップは以下のようなになる。

ステップ0

式4.31, 4.32に基づく離散選択モデルから、パラメータベクトル β を推定。

ステップ1

現在の進行方向、速度をもとに扇型の歩行平面（選択肢集合）を作成。

ステップ2

ステップ0で算出したパラメータ β と説明変数を用いて各選択肢の効用を計算し、最も効用の高い選択肢（速度、角度）を決定。

ステップ 3

選択された速度ベクトルに基づき、現在地を更新.

ステップ 4

ステップ 1~3 をすべての歩行者に対して行なう.




図 4.17 離散選択モデル

(e) 相互作用を考慮した歩行者経路探索

従来の歩行者行動分析の多くは、意思決定者は他者の行動と独立して行動選択しているとする仮説に基づいていた。しかし現実には、意思決定者が他者の選択する行動を考慮していると考えられる。そこで、意思決定者の行動と他者の行動が相互に依存する状況を主たる分析対象とするゲーム理論を援用したモデルについて説明する。交通主体同士のやり取りは、行動内容を事前に協議しない非協力ゲーム状況下での意思決定だと推測できる。

Draganska(2008)[5] は、表に示すような利得行列を持つ非協力 2 人ゲームを定式化した。プレイヤー (a_1, a_2) は期待利得を考慮した後に 2 つの選択肢 (0: 市場参入しない, 1: 市場参入する) から 1 つの行動を選択する。

表-4.2 から、プレイヤー i ($i=1,2$) が市場参入する ($a_i=1$) 確率は、以下の式で表される。

表 4.2 Draganska の利得行列

	$a_2 = 0$	$a_2 = 1$
$a_1 = 0$	(Π_{00}^1, Π_{00}^2)	$(\Pi_{00}^1, \Pi_{00}^2 + \Delta_{01}^2)$
$a_1 = 1$	$(\Pi_{00}^1 + \Delta_{10}^1, \Pi_{00}^2)$	$(\Pi_{00}^1 + \Delta_{10}^1 + \Delta_{11}^1), (\Pi_{00}^2 + \Delta_{01}^2 + \Delta_{11}^2)$

$$P(a_1 = 1) = P(\Delta_{10}^1 + P(a_2 = 1)\Delta_{11}^1 + \epsilon_1 \geq 0) \quad (4.33)$$

$$P(a_2 = 1) = P(\Delta_{01}^2 + P(a_1 = 1)\Delta_{11}^2 + \epsilon_2 \geq 0) \quad (4.34)$$

上式においては一方のプレーヤーのパラメータを変化させると相手のプレーヤーの確率項も変化するため、両者のパラメータを同時に推定する必要がある。そこでゲームの結果に観測させたプレーヤー i の選択行動の組み合わせを $Y_i (= \mathbf{0}, \mathbf{1})$ とすると、最大化する尤度関数 L は以下の式で表される。

$$L = \prod_{i \in \{1, 2\}} P(a_i = 1)^{Y_i} (1 - P(a_i = 1))^{1 - Y_i} \quad (4.35)$$

北川 (2009)[6] は歩行者と自動車 that 交錯する空間において、意思決定に相互依存性が存在する場合のモデルを定式化した。相互作用行動の分析を目的として、歩行者と自動車の選択行動の組み合わせに着目し、ゲーム的視点から出現頻度や戦略行動の推移を分析している。2つのプレーヤー (歩行者, 自動車) はそれぞれ2つの選択肢 (非減速, 減速) を持つと仮定する。意思決定に相互依存が生じる相互作用モデルの効用関数の確定項は、以下の様に定式化される。ここでは簡略化のため、意思決定者が歩行者 (ped) であり、相手プレーヤーが自動車 (car) である状況のみ記述する。

$$I_{v, dec}(V_{S_{ped}}^{ped} + \lambda_{ped}^{notdec} P_{car}(notdec) + \lambda_{ped}^{dec} P_{car}(dec)) \quad (4.36)$$

ここで、 $I_{v, dec}$ は歩行者の減速の選択肢に対してのみ1となる指示関数である。 $v_{S_{ped}}^{ped}$ は歩行者が速度 $S_{ped} \in (notdec, dec)$ を選択した場合に得られる独立項であり、ゲームの結果に得られる利得は自動車の選択行動とは独立している。また λ_{ped}^{dec} , λ_{ped}^{notdec} は自動車の選択確率に依存する効用のパラメータであり、 $P_{car}(dec)$, $P_{car}(notdec)$ はそれぞれ自動車が非減速, 減速を選択する確率を表す。上式で定式化された他者の影響を表す項を用いると、相互作用モデルのペイオフマトリクスは以下の表の様に表される。

このとき、歩行者の行動選択確率は以下の様に定式化される。

表 4.3 利得行列

		自動車	
		非減速 (not dec)	減速 (dec)
歩行者	非減速 (not dec)	V_{notdec}^{ped}	V_{notdec}^{ped}
	減速 (dec)	$V_{dec}^{ped} + \lambda_{ped}^{notdec}$	$V_{dec}^{ped} + \lambda_{ped}^{dec}$

$$P_{ped}(notdec) = P(V_{notdec}^{ped} \geq V_{dec}^{ped} + \lambda_{ped}^{notdec} P_{car}(notdec) + \lambda_{ped}^{dec} P_{car}(dec))$$

$$P_{ped}(dec) = P(V_{notdec}^{ped} \leq V_{dec}^{ped} + \lambda_{ped}^{notdec} P_{car}(notdec) + \lambda_{ped}^{dec} P_{car}(dec)) \quad (4.38)$$

ここでは、行動ゲーム理論の歩行者 2 次元空間への適用を考える。行動ゲーム理論とは限定合理性の中での行動を解明する理論であり、時間の流れを考慮しない静学的ゲームと、過去の結果から学習を行う動的ゲームに分類される。前者の交通挙動への適用に関しては、Kita(1999)[7] に詳しい。また、後者に関して、北川(2009)[6] は複数の自動車が存在する空間において、歩行者が最も衝突の危険性が高い自動車(相手プレイヤー)を選定し、1対1の繰り返しゲームを行うと仮定して、動的ゲームの定式化を行った。

一般にゲーム的状况における意思決定を表現する要素として、(1) プレーヤーの集合、(2) 選択肢集合、(3) 利得関数が挙げられる。歩行者行動の分析において、特に複数の歩行者が相互に衝突を回避する場面では、特定のゲームが繰り返し実施される「動的ゲーム」の意思決定方策が考えられる。このとき、上記 3 つのゲーム要素に加え、プレーヤーが過去の両者の選択行動を踏まえた「学習プロセス」の特定が重要な要素となる。学習プロセスには様々なタイプが提案されている。

強化学習

強化学習は、プレーヤーが様々な戦略を試し、得られた結果が良かった戦略を高い確率で選択するよう行動を変容させる学習過程である。強化学習が他の学習則と異なる特徴は、正しい行動を学ぶことなく取った行動を評価することで、学習を行う点である。学習ルールは式(4.39)に与えられる(Harley(1981)ito-harley1981, Roth and Erev(1995)ito-roth1995)。

$$R_j^i(t) = \phi R_i^j(t-1) + I(S_i^j, S_i(t)) \pi_i(S_i^j, S_{-i}(t)) \quad (4.39)$$

ここで、 $R_i^j(t)$ はプレーヤー i の t 期における戦略 j の強化、 S_i^j はプレーヤー i の選択 j 、 $I(S_i^j, S_i(t))$ は t 期の戦略結果の指示関数であり、プレー

ヤー i が戦略 j を選択したときに 1 となり、選択しなかった戦略に対しては効用が得られず 0 となる. $\pi_i(S_i^j, S_{-i}(t))$ は t 期にプレイヤー i が戦略 j によって得た利得である. ϕ は、過去に経験した強化の割引率である. パラメータとして、プレイヤー i の戦略 j に対する初期強化 $R_i^j(0)$ を定める必要がある.

信念学習

信念学習は、プレイヤーが経験的に他者の選択行動を予測し、それに対する自分の期待利得が最大となるような戦略を選ぶ学習過程である. 強化学習では自身の過去の戦略結果を参照したのに対し、信念学習では相手の過去の戦略結果から学習を行う. 学習ルールは式 (4.40)~(4.42) に与えられる (Fudenberg and Levine(1995)[10]).

$$N(t) = \rho N(t-1) + 1 \quad (4.40)$$

$$B_{-i}^k(t) = \frac{\rho N_{-1}^k(t-1) + I(S_{-i}^k, S_{-i}(t))}{N(t)} \quad (4.41)$$

$$E_i^j(t) = \sum_{k=1}^{m-i} \pi(S_i^j, S_{-i}^k) B_{-i}^k(t) \quad (4.42)$$

ここで、 $N(t)$ は i が t 期に持つ、相手の行動に対するゲームの経験数、 $B_{-i}^k(t)$ は i が t 期に持つ“相手が戦略 k を選択する”確信の確率、 $E_i^j(t)$ は i が t 期に戦略 j を選択する期待効用を表す. パラメータとして、 i が持つ“相手が戦略 k を選択する”初期確率と経験数 $B_{-i}^k(0)$ 、 $N(0)$ ならびに過去に経験した強化の割引率 ρ を与える必要がある.

EWA 学習

Camerer and Ho(1999)[11] は、強化学習と信念学習を統合した EWA 学習を提案している. t 期において、プレイヤー i の戦略 j に対する選好 (効用) $A(t)$ は、式 (4.43)~(4.45) で表される.

$$A_j^i(t) = \phi \frac{N(t-1)}{N(t)} A_i^j(t-1) + \frac{|\delta + (1-\delta)I(S_i^j, S_i^j(t))| \pi(S_i, S_{-i})}{N(t)} \quad (4.43)$$

$$\pi(S_i, S_{-i}) = \beta_0 + \sum_{m=1}^M \beta_m x_m(S_i^j, S_i^j(t)) \quad (4.44)$$

$$P_i^j(t+1) = \frac{\exp(A_i^j(t))}{\sum_k \exp(A_k^j(t))} \quad (4.45)$$

$\pi(S_i, S_{-i})$ は信念学習で得られる効用を表す。これは強化学習で得られる効用と異なり、実際には選択されることがなかったが、相手プレイヤーが選択した戦略に対して得られたであろう利得も含む。 $\delta (\delta \in (0, 1))$ は学習種別を表すパラメータである。 $\delta = 0$ ならば学習プロセスが強化学習であることを表し、相手プレイヤーが選択した行動を考慮せず、自身が実際に選んだ戦略と得られた利得のみに依存する学習プロセスであることを表す。一方 $\delta = 1$ ならば信念学習であることを表し、相手プレイヤーが多く選択した行動に対する期待効用が高い戦略を選択するような学習プロセスを記述する。

また $A(t)$ を用いて、 $t+1$ 期における各戦略の選択確率 P_j^i をロジット選択確率により算出する。この EWA モデルの援用によって意思決定の合理性を仮定し、利得関数 $\pi(S_i, S_{-i})$ に内生される説明変数 $x(S_i, S_{-i})$ のパラメータ β_0, β_m と学習プロセス ρ, ϕ, δ を最尤推定法により同時に推定する。例えば北川 (2009) では、歩行者と自動車 that 交錯する空間において、歩行者、自動車の選択肢集合を $S_i = (\text{減速}, \text{一定}, \text{加速})$ ($i = \text{ped, car}$) と設定している。

参考文献

- [1] Helbing, D., Molnar, P.: Social force model for pedestrian dynamics, Physical Review E, Vol.51, No.5, pp.4282-4286, 1995.
- [2] Antonini, G., Bierlaire, M., Weber, M.: Discrete choice models of pedestrian walking behavior, Transportation Research Part B, Vol.40 No.8, pp.667-687, 2006.

- [3] Hoogendoorn, S.P., Bovy, P.H.L.: Pedestrian route-choice and activity scheduling theory and models, *Transportation Research Part B*, Vol.38, No.2, pp.169-190, 2004.
- [4] Blue, V.J., Adler, J.L.: Cellular automata microsimulation for modeling bi-directional pedestrian walkways, *Transportation Research Part B*, Vol.35, No.3, pp.293-312, 2001.
- [5] M.Draganska, S.Misra, V.Aguirregabiria, P.Bajari, L.Einav, P.Ellickson, D.Horsky, S.Narayanan, Y.Orhun, P.Reiss, K.Seim, V.Singh, R.Thomadsen, T.Zhu: Discrete choice models of firms' strategic decisions, *Marketing Letters*, 19(3-4), pp.399-416, 2008.
- [6] 北川直樹:移動空間の更新に伴う歩行者と自動車の相互規範の変化, 東京大学大学院工学系研究科都市工学専攻修士論文,2009.
- [7] H.Kita:A Merging-Giveway Interaction Model of Cars in a Merging Section:A Game Theoretic Analysis,*Transportation Research Part A*,Vol.33,No.314,pp.305-312,1999.
- [8] Harley, Calvin B.:Learning the evolutionarily stable strategy,*Journal of theoretical biology*,Vol.89,4,pp.611-633,1981.
- [9] Roth,Alvin E.,and Ido Erev:Learning in extensive-form games:Experimental data and simple dynamic models in the intermediate term,*Games and economic behavior*,Vol.8,1,pp.164-212,1995.
- [10] Fudenberg,Drew,and David K.Levine.:Consistency and cautious fictitious play,*Journal of Economic Dynamics and Control*Vol.19,5,pp.1065-1089,1995.
- [11] Camerer,Colin, and Teck Hua Ho: Experience - weighted Attraction Learning in Normal Form Games,*Econometrica*,Vol.67.4,pp.827-874,1999.

4.4 サンプリング理論/融合推定法

非集計行動モデルの推定においては、調査方法やデータに由来するバイアスが存在し、複数時点のデータからなるパネルデータを扱う場合や、異なる調査方法のデータを融合的に扱う場合はバイアスの考慮が必要となる。また、行動原理は実現選択肢ごとのサンプルや、外生的な属性により異なることが想定され、行動モデルで仮定する確率的な誤差項について、要因ごとに分離することや、選択肢間での相互依存を考慮することで、現象の理解に迫ることができるようになっている。本項ではデータごとのバイアスや特性を取り扱う手法を説明する。

消耗バイアス

交通調査において、同一個人を対象として長期間にわたり繰り返しデータを取得する調査がパネル調査と呼ばれる。パネル調査では、調査期間の途中

における参加の脱落が発生し、参加の脱落が交通行動と相関を持つことがある。調査参加の脱落による系統的なバイアスを消耗バイアス (attrition bias) と呼ぶ。消耗バイアスはデータの標本抽出において、選択性バイアスと同様の問題として捉えることができる。

4.4.1 系統的バイアスを補正する推定量

内生変数である選択結果に基づく標本抽出データを用いたモデル推定においては、標本抽出のバイアスを補正する推定量の選択が必要となる。離散選択モデルにおいて、無作為抽出のときの最尤法の最尤推定量である尤度は次のようになる。

$$\prod_{i=1}^n P(j_i | x_i, \theta) \quad (4.46)$$

$P(j | x, \beta)$: 外生変数が x のとき選択結果が j である確率

β : モデルのパラメータ

内生的な選択性バイアスを持つデータに対してモデル推定を行うとき、いくつかの推定量が提案されている。WESML (weighted exogenous sample maximum likelihood) 推定量は Manski and Lerman (1977) により提案された推定量であり、漸近正規性と一致性を有することが Cosslett (1981) により示されている。抽出率が既知のときに有効で、標本内比率と母集団内比率の比で重み付けする方法である。推定量は対数尤度として以下のように表される。

$$\ln L = \sum_{i=1}^n \hat{\omega}(j_i) \ln P(j_i | x_i, \theta) \quad (4.47)$$

$$\hat{\omega}(j_i) = \frac{H(j_i)}{Q(j_i | \theta)} \quad (4.48)$$

$H(x)$: 標本の中で選択結果が j である確率

$Q(x)$: 母集団の中で選択結果が j である確率

$P(j | x, \beta)$: 外生変数が x のとき選択結果が j である確率

$\omega(j_i)$ は標本抽出に伴う重み付けである。このとき、分散共分散行列の推定量は、

$$\Sigma = \frac{1}{N} \Omega^{-1} \Lambda \Omega^{-1} \quad (4.49)$$

となり、

$$\hat{\Omega} = \frac{1}{N} \sum_{i=1}^N \left\{ \left[\frac{\partial \ln P(j_i | x_i, \theta)}{\partial \theta} \right] \left[\frac{\partial \ln P(j_i | x_i, \theta)}{\partial \theta'} \right] \right\} \quad (4.50)$$

$$\hat{\Lambda} = \frac{1}{N} \sum_{i=1}^N \left\{ \hat{\omega}(j_i) \left[\frac{\partial \ln P(j_i | x_i, \theta)}{\partial \theta} \right] \left[\frac{\partial \ln P(j_i | x_i, \theta)}{\partial \theta'} \right] \right\} \quad (4.51)$$

を適用する。推定では、上記の推定量を最大化する θ を母集団に対するパラメータの最尤推定値とする。

CML(conditional maximum likelihood) は Manski and McFadden (1981) により提案された推定量であり、外生変数・モデルが与えられた時の条件付尤度を最大化する方法である。

$$\ln L = \sum_{i=1}^n \frac{H(j_i)}{Q(j_i | \theta)} \ln P(j_i | x_i) - \ln \sum_{j=1}^C \frac{H(j_i)}{Q(j_i | \theta)} \ln P(j_i | x_i) \quad (4.52)$$

選択肢別標本抽出データを用いた推定として、森地・屋井 (1984) の交通手段選択モデルにおける WESML 推定量と CML 推定量の比較や、北村ら (2001) の京都観光調査による自動車利用二項ロジットモデルで、入浴地点・来訪地・宿泊施設別の多次元の標本抽出に適用した例、また Bierlaire et al. (2008) の GEV モデルに対して一致性を持つ推定量として拡張してネスト構造での選択モデルに適用した例などが存在する。

4.4.2 複数データの融合推定法

複数のデータを用いてモデル推定を行う例として、RP(Revealed Preference) データと SP(Stated Preference) データの同時推定がある。SP 調査は

仮想の状況下での選好意思を観測する調査であり、現存しない交通サービスの需要分析や、新規の施策の検討などに用いられる。実際の行動結果を観測した RP データと異なり、SP データでは仮想の状況や選択肢集合を自由に設定できることから、調査の操作性が高い。一方で、仮想状況下での意思決定であり実際に行われるであろう行動と異なる観測結果が出ることや、選択肢の属性値が明示的に示されるために測定誤差が存在しないことなど、選好の顕在化が異なる。SP データと RP データの持つバイアスの修正方法として、森川・山田 (1993) m p RP/SP 同時推定モデルがある。森川・山田 (1993) は、RP データと SP データを融合した MNL モデルの推定において、誤差項のスケールを統一するスケールパラメータを導入する手法を提案している。

RP データと SP データの双方について、それぞれ効用関数は設定される。個人 n の選択肢 i に対する効用関数は、以下のように表される。

$$U_{in}^{RP} = \beta X_{in}^{RP} + \alpha W_{in}^{RP} + \epsilon_{in}^{RP} = V_{in}^{RP} + \epsilon_{in}^{RP} \quad (i = 1, \dots, J_n^{RP}, n = 1, \dots, N^{RP}) \quad (4.53)$$

$$U_{in}^{SP} = \beta X_{in}^{SP} + \gamma Z_{in}^{SP} + \epsilon_{in}^{SP} = V_{in}^{SP} + \epsilon_{in}^{SP} \quad (i = 1, \dots, J_n^{SP}, n = 1, \dots, N^{SP}) \quad (4.54)$$

ここで、 α, β, γ は未知のパラメータベクトル、 X は RP モデルと SP モデルで共通のパラメータを持つ説明変数ベクトル、 Y は RP モデル固有のパラメータを持つ説明変数ベクトル、 Z は SP モデル固有のパラメータを持つ説明変数ベクトル、 J_n は個人 n の選択肢集合に含まれる選択肢数、 N はデータの観測数である。また、RP モデルと SP モデルの誤差項の分散の関係は、全ての個人 n 及び選択肢 i について以下の式で表す。

$$\text{Var}(\epsilon_{in}^{RP}) = \mu^2 \text{Var}(\epsilon_{in}^{SP}) \quad (4.55)$$

パラメータの推定では、まず RP モデルと SP モデルのそれぞれの対数尤度関数を求める。

$$\ln L^{RP}(\alpha, \beta) = \sum_{n=1}^{N^{RP}} \sum_{i=1}^{J_n^{RP}} d_{in}^{RP} \ln P_n^{RP}(i) \quad (4.56)$$

$$\ln L^{RP}(\beta, \gamma, \mu) = \sum_{n=1}^{N^{SP}} \sum_{i=1}^{J_n^{SP}} d_{in}^{SP} \ln P_n^{SP}(i) \quad (4.57)$$

ここで、RP モデルと SP モデルの確率項が独立で、相互依存性を持たないならば、それぞれの対数尤度関数の足し合わせによって一致性と漸近性を持つパラメータ推定量を求めることができる。

$$\ln L^{RP+SP}(\alpha, \beta, \gamma, \mu) = \ln L^{RP}(\alpha, \beta) + \ln L^{RP}(\beta, \gamma, \mu) \quad (4.58)$$

4.4.3 Mixed Logit モデル

Mixed Logit モデルは、(i) で前述したとおり、プロビットモデルに代表される正規分布を誤差項に仮定したモデルと、MNL モデルに代表されるガンベル分布を誤差項に仮定したモデルを組み合わせたモデルである。MNL モデルを誤差項操作により、変数の系列相関や分散を表現できるように拡張したモデルであるといえる。

Mixed Logit モデルの特徴は、母集団に対してパラメータを、確率分布により期待値と分散を用いて扱うことにより、母集団内でのばらつきを表現できることである。選好や価値観のばらつきの表現は、個人内、個人間の変動を考慮したモデルに適用できる。例えば、パネルデータの分析では、時系列上での同一個人にたいしてモデルを適用することで、個人内のパラメータのばらつきを考慮できる。また、複数人の行動データへの適用では、個人間でのパラメータのばらつきを表現でき、誤差項の構造化や仕分けによって、個人間、個人内、世帯間、地域間など、変動をもたらす要因ごとに分散の大きさを考察することも可能となる。

モデル構造については、(i) で示しているため、ここでは計算例のみを示す。

ここでは行動データについて、交通手段選択モデルを例として推定する。行動データ、及び実選択行動に関しての代替選択肢のサービスレベルデータとして表 4.4 のデータが得られているとする。

個人 n の選択肢 i を選択したときの所要時間を $time_{in}$ 、料金を $cost_{in}$ として、効用関数を以下のように表す。

表 4.4 推定データ

ID	選択結果	所要時間 (徒歩)	所要時間 (鉄道)	費用 (鉄道)	所要時間 (自動車)	費用 (自動車)	...
1	自転車	3	5	400	6	700	...
2	自動車	45	30	400	10	150	...
3	徒歩	15	10	160	5	150	...
:	:	:	:	:	:	:	:

$$U_{in} = \beta_1 time_{in} + \beta_2 cost_{in} + \epsilon_{in} \quad (4.59)$$

パラメータベクトル β は、平均 $\bar{\beta}$ 、標準偏差 σ に従うとする。なお、簡単のため、変数間での誤差相関は考慮しない。分散共分散行列 Ω を用いて表現すると、以下のように表すことができる。

$$\Omega = \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{pmatrix} \quad (4.60)$$

表 4.5 MXL モデル推定結果

	パラメータ	t 値
定数項 (鉄道)	1.672	6.27
定数項 (バス)	-0.358	-1.03
定数項 (自動車)	-0.203	-0.90
定数項 (自転車)	-0.573	-2.45
所要時間 [100 分] - 平均	-7.324	-9.46
所要時間 [100 分] - 標準偏差	2.658	6.86
料金 [100 円] - 平均	-0.093	-2.09
料金 [100 円] - 標準偏差	0.032	1.13
サンプル数	400	
初期尤度	-564.18	
最終尤度	-384.72	
修正済み尤度比	0.304	

推定では、各パラメータの期待値 $\bar{\beta}$ と標準偏差 σ 、及び各選択肢の定数項を推定する。

パラメータ推定を行った結果は表 4.5 に示す。推定結果から、所要時間や料金に関するパラメータの期待値と標準偏差が求められていることがわかる。符号も所要時間と料金ともに効用に関して負の影響を与えており、妥当といえる。

ここでこの結果から、母集団の時間価値の分布を所要時間のパラメータ値を料金のパラメータ値で除することで求める。MNL モデルでは時間価値は母集団について画一的に仮定が置かれるが、Mixed Logit モデルでは個人間のばらつきが求めることができる。得られた時間価値の分布を図で示すと、図 4.18 のようになる。

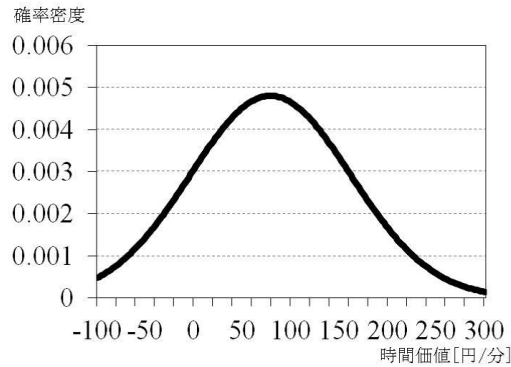


図 4.18 時間価値分布推定結果

推定データでは、時間価値の期待値は 78.8 円/分、標準偏差は 83.1 円/分となった。

プログラム例

プログラムのフローを図 4.19 に示す。

4.4.4 潜在クラスモデル

モデル概要

個人間の異質性を考慮したモデルとして、潜在クラスモデルによる分析が行われる。潜在クラスモデルは対象集団内で観測できない異質性があることを前提として、母集団を複数の集団（潜在クラスと呼ぶ）に分け、混合分布モデルとしてモデルの推定を行う手法である。集団内の個人の特徴ある嗜好を選択的に表すことができ、マーケティング等の分野で用いられてきた。

潜在クラスモデルでは、母集団内のクラスごとにパラメータが推定され、パラメータ値の違いによりクラス間の嗜好の異質性を示すことができることで

ある。交通行動においても、通勤通学時の行動と余暇時の行動では意思決定が異なることが想定でき、また就業者と非就業者も交通行動選択の嗜好は異なると考えることができよう。このような個人内や個人間での行動文脈の違いを明示的に示すことができることが特徴である。

モデルでは、通常モデルでは母集団に対して単一に推定されるパラメータを、クラスごとに推定することによって説明力を向上させることができる。一方で、モデルのクラス数を事前に決定する必要があるという恣意性があることや、クラスの数を増やすとモデルの構築や推定が困難になるという問題が存在する。

モデル構造

潜在クラスモデルでは個人 n が選択肢 i を選ぶ確率は以下のように表される。

$$P_n(i) = \sum_{s=1}^S P_n(i|s)Q_n(s) \quad (4.61)$$

ただし、 $P_n(i|s)$ はクラス s に属する個人 n が選択肢 i を選択する確率、 $Q_n(s)$ は個人 n が潜在クラス $s (s=1, \dots, S)$ に帰属する確率である。

潜在クラスへの帰属確率がロジット型の確率式で表されると仮定すると、個人 n の潜在クラスへの帰属確率 $Q_n(s)$ は個人属性を用いて表すことがで

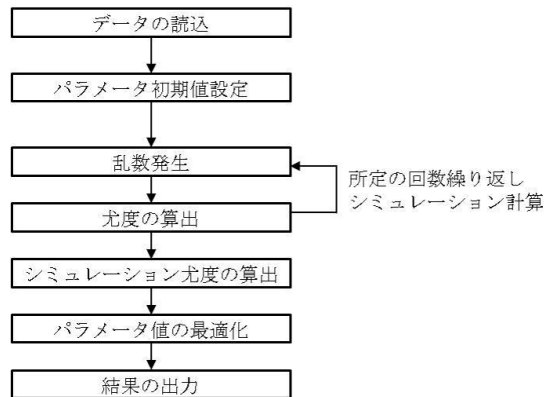


図 4.19 プログラムコードのフロー

きる。

$$Q_n(s) = \frac{\exp(\delta_s z_n)}{\sum_{s=1}^S \exp(\delta_s z_n)} \quad (4.62)$$

ここで、 δ_s はクラス s に関するメンバーシップパラメータベクトル、 z_n は個人 n の個人属性ベクトルである。

このとき、観測データに対する尤度関数は、対数尤度を用いて表す。

$$\ln L = \sum_{n=1}^N \sum_{s=1}^S \delta_{ns} P_n(i|s) Q_n(s) \quad (4.63)$$

ここで、 δ_{ns} は個人 n がクラス s に属する時に 1 となる指示変数であるが、この変数は観測することができない。そこで、推定では EM アルゴリズムを用いて個人 n がクラス s に属する事後確率 w_{ns} を更新して推定する方法がとられる。事後確率はベイズの定理から以下のように計算される。

$$w_{ns} = \frac{Q_n(s) P_n(i|s)}{\sum_{s=1}^S Q_n(s) P_n(i|s)} \quad (4.64)$$