

プローブカーデータを用いた 道路ネットワーク上の交通行動分析

三 輪 富 生

要旨

近年の道路交通計画においては、厳しい予算制約の下で如何に効果的かつ効率的な代替案を選定するかが重要なテーマとなっており、分析対象となる交通行動や交通施策も多様化している。ハード的な交通施策に対する厳密で精緻な評価はもとより、ソフト的な交通施策による既存ストックの有効活用を前提とした TDM 施策や、ドライバーへのリアルタイム情報提供等の ITS 技術の開発・導入に関する分析が盛んに進められている。このため、より詳細な交通流の調査が、今後検討されるべき交通計画において重要な項目の一つとして注目を集めている。

ソフト的な交通施策に向けた分析を行うにあたっては、実際の道路ネットワーク上を流れる交通流を、より精緻に表現することが可能なデータの収集とモデルの構築が必要不可欠である。しかし、道路ネットワーク上を移動する自動車や歩行者は、各々の持つ起終点、利用経路や移動者の個人属性など、そのほとんどが把握されていない。このような交通行動をすべて把握し、モデルによって完全に再現することは困難であるものの、管理者側からの適切な交通情報提供によりネットワーク利用者各々の交通行動を誘導することで、利用者全体にとって最適なネットワーク交通流の実現を目指すシステムを構築することは、今日の交通工学の主要な課題の 1 つといえる。

このような背景の下、より詳細な交通行動を調査することが可能で、かつハード的な設備投資を必要としない調査手法が求められ始めた。プローブカー (Probe-Car) システムは、GPS 車載機を搭載した車両を現実の道路ネットワーク上を移動するセンサーとして捉え、走行速度や位置情報等を収集することにより、交通流動等の道路交通情報を生成するシステムである。従来の OD データが平均的な 1 日を対象とし、トラフィックカウンターデータ等の断面交通量データが道路ネットワーク上の主要区間を対象としているのに対して、プローブカーシステムでは、実験期間中に車両が走行したすべての道路区間で経験した走行速度や停止回数など、時間的、空間的な制約の少ない、より動的な情報を収集することができる。さらに、プローブカーの走行軌跡は、ドライバーが選択した経路に関する情報を直接的に分析者に伝えることができ、これまでは収集が困難であった経路選択実績データを、容易にしかも十分なデータ量を確保することが可能となる。

しかし、プローブカーが提供する車両の走行軌跡は連続する位置座標情報であり、これを交通行動分析に用いるためには走行経路を特定する作業が必要となる。連続する車両位置座標から走行経路を特定する作業はマップマッチングと呼ばれ、これにより経路上に存在する全ての道路区間の旅行時間情報を利用することが可能となり、また経路選択行動分析用データとしての利用も可能となる。そこで本研究では、プローブカーの走行軌跡情報を道路ネットワーク上の走行経路情報へと変換する技術の開発を行うことを目的の一つとする。本研究で開発されたマップマッチングアルゴリズムでは、車両位置座標のみからでは走行経路特定が困難な、都市高速道路と一般道路が立体的に配置した区間を有する OD ペアにおいても、車両の走行速度情

報を用いることにより，94%程度の精度で走行経路を正しく特定することが可能となることが示された．

マップマッチング処理により走行経路データへと変換されたプローブカーデータは，従来の交通データよりも広範囲にわたる旅行時間情報として利用可能である．このため本研究では，従来の交通データからは困難であった，より柔軟な旅行時間予測手法を開発する．ここで開発される手法は，起点において出発後の交通状況の変化を考慮した最適経路を提供するものである．出発時刻の交通状況のみを用いる予測手法では，交通状況の変化の激しい時間帯において予測された旅行時間や経路に含まれる予測誤差が大きく，交通状況の変化をあらかじめ予測することで，予測旅行時間の精度が大きく向上することが示された．

しかし，予測された旅行時間情報は，トリップ開始後の交通状況が平均的に変化することを前提としており，さらには，情報提供の対象となるドライバーが平均的な走行を示すことをも前提としている．しかし，日々の交通状況は平均的な交通状況のまわりを変動しており，またすべてのドライバーが平均的な走行速度を示すとは限らない．プローブカーデータは，トリップ開始後にドライバーが経験した交通状況や，ドライバーが示す走行特性に関する詳細な情報を有している．そこで本研究では，トリップ中にドライバーが経験した交通状況の平均とは異なる変化や，ドライバーの平均とは異なる走行特性を考慮して，適切に残り区間の旅行時間を更新するための手法を開発する．本研究で開発された予測旅行時間更新手法は4種類であるが，それらは蓄積されたプローブカーデータを非集計的に扱う手法と集計的に扱う手法に大別される．前者は，蓄積データに含まれる各データと対象トリップの走行データを一対比較することで，類似度の高い蓄積データを抽出して残り区間の予測旅行時間を更新する手法であり，後者は蓄積データを集計し，統計的手法を用いて残り区間の予測旅行時間を更新する手法である．本研究における分析により，前者と後者では予測更新精度が異なることを示し，特に蓄積データ数が少ない場合においては，蓄積データの非集計的な取り扱いがより高い予測更新精度を導くことを示した．

またプローブカーデータが提供する走行軌跡は，ドライバーの経路選択行動に関する情報であり，この情報を用いれば現在一般的に用いられている経路選択モデルや，これまでに開発された様々なモデルについてその再現性を検証することが可能となる．そこで本研究では，現実の交通状況を記述する概念として最も一般的な交通均衡状態について，その成立の可否についての検証を行った．この結果，現実のドライバーは交通状況に関する十分な知識を有しておらず，現実の交通状況は交通均衡状態に達していない可能性を示した．

さらに，より詳細な経路選択行動を分析するために，これまでに開発された経路選択モデルについて概説した後，プローブカーデータに対して大規模な経路選択肢集合に対しても適用可能な幾つかのモデルを適用した．この結果，ドライバーの認知する旅行時間情報は非常に精度が低く，出発後の交通状況の変化を考慮していない可能性や，複数経路の重複による経路間の相関を考慮することでモデル適合度が上昇することを示した．また，終点までの距離の変化に

よる経路選択行動の変化を表現するための方法として、トリップ距離が短くなるほどドライバーの経路効用に対する認知誤差が小さくなると捉え、経路効用の誤差項の標準偏差が OD 間距離に比例するとしてスケールパラメータを構造化することで、トリップ長によらず同一のモデルを適用する従来の経路選択モデルと比較して大きく適合度が向上することを示した。

また、これまで一般的に行われてきた経路選択行動分析は、ドライバーは OD 間距離がどれほど長い状況下でも起点において終点までの詳細な経路を一度に決定するとしている。そこで、名古屋都心部の交通混雑の激しいエリアを対象として、トリップ中の意思決定発生の可能性を分析した結果、ドライバーはトリップ中の停止回数やネットワーク形状により意思決定を発生させ、また走行中に経験した速度が高いほど意思決定を発生させにくいことを示した。この結果を踏まえ、動的な経路選択行動を適切に表現可能な意思決定時点内生モデルを開発し、名古屋都心部の主要経路に適用した。この結果、起点のみもしくは到着交差点ごとに意思決定を行うと仮定した従来の経路選択モデルが、より現実的な枠組みを背景として大きく改善可能であることを示した。

最後に今後の課題として、プローブカーデータのより効率的な利用を目指したリアルタイムマップマッチングアルゴリズムの開発が必要であり、さらには経路選択に際して有用な情報を提供するための、適切な代替経路探索方法の開発が必要であること、また動的な経路選択行動を内包した交通シミュレータの開発を行い、交通全体をより最適な状態へと導くための情報提供タイミングや、交通情報提供の効果について分析を行う必要があることを述べた。

目次

第 1 章 序論	1
1.1 研究の背景と目的	1
1.2 本論文の構成	3
第 1 章 参考文献	7
第 2 章 プローブカーデータを用いた交通行動分析の位置づけ	9
2.1 従来の交通データとプローブカーデータ	9
2.1.1 従来の交通データとその問題点	9
2.1.2 プローブカーシステムの概要	12
2.1.3 プローブカーデータの利点と欠点	15
2.2 本研究で使用するプローブカーデータ	16
2.2.1 データの概要	16
2.2.2 交通データとしての特徴	20
2.3 本研究の方針	25
第 2 章 参考文献	27
第 3 章 プローブカーデータ利用技術の開発	29
3.1 交通行動分析用データへの変換	29
3.1.1 近接リンク法	29
3.1.2 より詳細なマップマッチング手法の必要性	31
3.2 マップマッチングアルゴリズムの開発	33
3.2.1 既存のマップマッチングアルゴリズム	34
3.2.2 アルゴリズムの開発と精度検証	36
3.3 データ蓄積方法の提案	41
3.3.1 マップマッチング処理の概要	41
3.3.2 データ蓄積方法	47
3.4 本章のまとめ	50
第 3 章 参考文献	52
第 4 章 旅行時間予測手法の開発	55
4.1 既存の旅行時間予測手法	57
4.1.1 従来の旅行時間情報	57

4.1.2 既存の旅行時間予測手法	57
4.2 蓄積データベースを用いた旅行時間予測手法の開発	58
4.2.1 旅行時間予測計算の基本的な考え方	59
4.2.2 計算アルゴリズム	59
4.2.3 予測精度・予測経路に関する考察	63
4.3 トリップ中の予測旅行時間更新手法の開発	68
4.3.1 プローブカーデータによる旅行時間予測手法の開発	69
4.3.2 分析対象経路とデータの概要	74
4.3.3 予測旅行時間更新精度の検証	77
4.4 本章のまとめ	79
第4章 参考文献	82
第5章 経路選択行動分析	85
5.1 経路選択行動分析データとしてのプローブカーデータ	86
5.1.1 既存の経路選択データとの違い	86
5.1.2 プローブカーデータの有する問題点	87
5.2 経路選択行動の基礎分析	89
5.3 既存の経路選択モデルの概要	92
5.3.1 経路選択モデルの適用場面	92
5.3.2 既存の経路選択モデル	93
5.4 経路選択モデルへの適用	100
5.4.1 分析用データの整理	101
5.4.2 旅行時間認知に関する分析	102
5.4.3 経路認知に関する分析	103
5.4.4 経路選択モデルへの適用	104
5.4.5 トリップ距離が経路選択行動に与える影響	107
5.5 より動的な枠組みに向けた分析	116
5.5.1 トリップ中における意思決定に関する分析	117
5.5.2 トリップ中の意思決定を考慮した経路選択モデル	124
5.6 本章のまとめ	131
第5章 参考文献	133
第6章 結論	137
6.1 本研究の成果	137

6.2 今後の課題と展望	140
第 6 章 参考文献	144
謝辞	145

第1章 序論

1.1 研究の背景と目的

道路交通は社会全体に与える影響力が大きく、交通環境の変化により人々の生活も大きく変化する。国土軸を形成するような高規格自動車道路の整備により、沿道地域に居住する人々の交流圏は大きく変化するであろうし、都市内で発生する交通渋滞や交通事故による経済損失や環境汚染は、沿道で営まれる社会活動に大きな影響を与えている。道路ネットワーク上の交通行動分析の目的は、このような道路ネットワーク整備による社会活動の変化を予測したり、道路ネットワーク上で発生する様々な問題を解決するために、現状における交通行動を調査したデータと対象を適切に表現する分析モデルによって交通環境を再現し、新たな道路インフラ整備をはじめとする交通施策導入の影響を予測・評価するための基礎資料を提供することであり、道路交通計画において重要な役割を担っている。

交通行動はこれまでも多くの方法で調査され、収集されたデータを用いた様々なモデルにより分析されてきた。例えば、広域道路ネットワークにおける新規路線整備の必要性を評価したい場合には、対象地域周辺の自動車起終点調査データを用いて、ネットワーク配分モデルによって一日あたりの平均利用交通量と、それに伴うネットワーク全体への負荷軽減を予測する。また、交通渋滞が慢性化している交差点における最適な改良案を選定したい場合には、対象交差点における方向別交通量、滞留長や渋滞長、通過時間等を調査し、動的交通流シミュレータによってピーク時刻における渋滞緩和効果をすべての代替案について予測する。このように、道路ネットワーク上の交通行動分析は、分析者が評価すべき対象の特性に応じて適切な調査データと分析モデルを組み合わせることで行われている。

近年の道路交通計画においては、厳しい予算制約の下で如何に効果的かつ効率的な代替案を評価・選定するかが重要なテーマとなっており、分析対象となる交通行動や交通施策も多様化している。ハード的な交通施策に対する厳密で精緻な評価はもとより、ソフト的な交通施策による既存ストックの有効活用を前提とした、高速道路の時間帯料金割引のような TDM (Transportation Demand Management) 施策や、ドライバーへのリアルタイム情報提供サービスや輸送トラックの最適な運行管理などの ITS (Intelligent Transport Systems) 技術の開発・導入に関わる分析が盛んに進められている(森地ら, 2000)。新規路線や新規交通機関の整備のような大規模でハード的な交通施策の評価に対して、パーソントリップ調査や自動車起終点調査が数年に一度、平均的な1日を対象として調査され、これにより収集されたデータが分析に用いられてきた。これに対して、近年では比較的小規模で多大な設備投資の必要がないソフト的な交通施策の検討に向けて、トラフィックカウンターデータや AVI (Automated Vehicle Identification) システムが、年間を通じて途切れることのない時間軸上の交通状況の詳細な変化

を監視するために用いられ始めた．このようなより詳細な交通流の調査が，今後検討されるべき交通計画において重要な項目の一つとして注目を集めている．

ソフト的な交通施策に向けた分析を行うにあたっては，実際の道路ネットワーク上を流れる交通流をより精緻に表現することが可能なデータの収集とモデルの構築が必要不可欠である．しかし，道路ネットワーク上の交通流は多くの人々が毎日接しているにもかかわらず，これを正確に把握し適切に表現することは非常に困難である．例えば，航空管制システムや列車運行管理システム（COMTRAC：Computer aided Traffic Control）のように，航空機や電車はすべての個体に対してその管理者が存在し，すべての個体の起終点や運行経路について把握されている（宮島，2003）．その一方で，道路ネットワーク上を移動する自動車や歩行者は，各々の持つ起終点や利用経路，移動者の個人属性など，そのほとんどが把握されていない．これは，大容量で決められた経路と一定の間隔を保って運行される飛行機や電車などのマストランジットに対して，自動車・歩行者は個々がばらばらの属性を持ち，各々の意思で出発時刻や利用経路を選択しているためである．このような交行動をすべて把握し，モデルによって完全に再現することは困難であるものの，管理者側からの適切な交通情報提供によりネットワーク利用者各々の交行動を誘導することで，利用者全体にとって最適なネットワーク交通流の実現を目指すシステムを構築することは，今日の交通工学の主要な課題の 1 つといえる．

このような背景の下，より詳細な交行動を調査することが可能で，かつハード的な設備投資を必要としない調査手法が求められ始めた．プローブカー（Probe-Car）はプローブビークル（Probe-Vehicle），フローティングカー（Floating-Car）とも呼ばれ，これを用いたシステムは，GPS（Global Position System）車載機を搭載した車両を現実の道路ネットワーク上を移動するセンサーとして捉え，走行速度情報や位置情報等を収集することにより，交通流動等の道路交通情報を生成するシステムである（国土交通省道路局，2003）．自動車起終点調査が平均的な 1 日を対象とし，トラフィックカウンターデータや AVI データが道路ネットワーク上の主要区間を対象としているのに対して，プローブカーシステムを用いれば，車両が走行したすべての道路区間で経験した走行速度や停止回数，停止時間など，道路区間の断面的な情報にとらわれず，より動的な情報を収集することができる．また，プローブカーシステムがカバーするエリアは従来の交通データと比較して飛躍的に拡大し，任意の時刻における情報を収集することが可能である．さらに，プローブカーの走行軌跡はドライバーが選択した経路に関する情報を直接的に分析者に伝えることができ，これまでは収集が困難であった経路選択実績データを容易に，しかも十分なデータ量を確保することが可能となる．

しかし，プローブカーが提供する情報は車両の位置座標や走行速度など車両自体に関するものであり，これを分析に用いるためには走行経路を特定する作業が必要となる．現在，様々な地域でプローブカーを用いた交通状況を解明するための調査，分析が進められているものの，これを用いるための統一された手法は開発されるに至っていない．このため本研究では，プローブカーデータの走行軌跡を，道路ネットワーク上の走行経路データへと変換する技術を開発

することを目的の一つとする．また，走行経路データへと変換されたプローブカーデータを集計することで，従来の交通データより広範囲にわたるリンク旅行時間情報を有するデータベースを作成することが可能となる．これにより本研究では，従来の交通データからは取り組むことが困難であった，より柔軟な旅行時間予測手法を開発する．ここで開発される手法は，起点において出発後の交通状況の変化を考慮した最適経路を提供しうるものである．さらに，プローブカーデータは，トリップ開始後にドライバーが経験した交通状況や，ドライバーが示す走行特性に関する情報を提供することができる．これらの情報は，対象車両がトリップを開始する以前には分析者は知ることのできない情報であり，トリップ開始後の時間経過とともに変化する情報である．このように，プローブカーはより動的な情報を提供する．そこで本研究では，トリップ中にドライバーが経験した交通状況の平均とは異なる変化やドライバーの走行特性を考慮して，残り区間の旅行時間を適切に更新するための手法を開発する．

また，プローブカーシステムは交通状況に関する情報を収集することが最も大きな目的ではあるものの，プローブカーデータの与える走行軌跡はドライバーの経路選択行動に関する情報である．この情報を用いれば，現在一般的に用いられている経路選択モデルや，これまでに開発されたさまざまなモデルについてその再現性を検証することができる．さらには，トリップ距離により変化する経路選択行動を表現するための分析や，トリップ中における意思決定の発生を考慮したより動的な経路選択行動モデルを提案する．

このように，本研究では新しい交通データであるプローブカーデータを用いて，トリップの起点における終点までの情報を取り扱う静的な分析と，ドライバーのトリップ中の行動を取り扱う動的な分析に着目し，これまでは分析や開発が困難であったより詳細な交通管理に向けた技術を開発・分析することを目的とする．

1.2 本論文の構成

本論文は，図 1-1 に示すように 6 章から構成される．第 1 章では本研究の背景と目的について既に述べた．第 2 章では，パーソントリップ調査データを代表とする OD データや，道路交通センサス一般交通量調査を代表とする断面交通データなど，これまで一般的に用いられてきた交通データについて，その使用場面やそれぞれのデータの持つ問題点を整理する．その上で，プローブカーシステムについてその概要を示し，すでに世界各地で始められているプローブカーシステムによる主な実験についてまとめ，データ収集方法の概要やプローブカーデータの持つ利点と欠点を整理する．さらに，本研究で使用するプローブカーデータについて，そのデータの概要を従来の交通データから得られる情報と比較を行いながら整理する．最後に，これらにより明らかにされたプローブカーデータの特徴を踏まえた上で，本研究の基本方針について述べる．

第 3 章では，プローブカーデータが連続する車両位置座標により走行軌跡を表現しているこ

とから、走行路線を特定するための簡単な手法について、その利点や欠点を踏まえながら述べ、より詳細な交通行動分析データへと変換するための走行経路特定手法の必要性を述べる。次いで、既存の走行経路特定手法について特徴を踏まえながら概説し、本研究で使用するデータが持つ走行経路特定上の問題点を整理する。さらに、これにより明らかとなった問題点を有するプローブカーデータを対象として、精度よく走行経路を特定する手法を開発し、特定精度を検証するとともに更なる精度向上のための改善策について述べる。また、開発された手法を用いて膨大なデータ量进行处理するための効率的な処理フローを示し、道路ネットワーク上の各リンクの時刻別平均旅行時間を蓄積するための方法を示す。

第4章では、プローブカーデータから作成された蓄積データベースを用いた旅行時間予測手法を開発する。これまでに開発された旅行時間予測手法の問題点を整理した上で、トリップ開始後に発生する交通状況の変化に対応しうる、より柔軟な経路探索・旅行時間予測手法を開発する。また、開発された手法の計算速度を分析した上で、その実用可能性について検証を行う。さらに、プローブカーデータがドライバーのトリップ中の走行状況について、詳細な情報を提供しうる点に着目し、トリップ中における予測旅行時間更新手法について複数の手法を開発する。最後に、提案された旅行時間更新手法についてそれぞれの予測更新精度を検証し、蓄積データ量と適切な予測旅行時間更新手法の関係について考察を行う。

第5章では、ドライバーの経路選択行動を分析する。これまでの経路選択行動の基本概念であった交通均衡の成立の可否について分析を行った上で、プローブカーデータをこれまでに提案された幾つかの経路選択モデルに適用し、現実のドライバーの経路選択行動についてより詳細な分析を行う。また、従来の経路選択モデルは、起点において終点までの詳細な経路を一度に決定する枠組みを用いてきた。しかし、現実のドライバーはトリップ中においても経路変更・選択行動を繰り返していると考えられる。そこで、プローブカーデータを用いてトリップ中の経路選択行動についての検証を行うとともに、より動的な枠組みの経路選択モデルを適用するための基礎的な分析を行う。最後に、トリップ中の意思決定発生確率を内生的に取り扱った、動的な経路選択行動を記述する新たな経路選択モデルを提案し、簡単なネットワークを対象としてその適用可能性を検証する。

最後に第6章では、本研究を通じて得られた知見をまとめるとともに、今後の研究の方向性やさらなる分析に向けた課題の整理を行いながら今後の展望について述べる。

ここで、第4章前半において議論される旅行時間予測手法は起点から終点までを一度に取り扱うものである。本研究では、このように交通行動やその分析の枠組みが、トリップの起点から終点までを一度に捉える場合を“静的”な分析の枠組みと呼ぶ。一方、第4章後半で議論される予測旅行時間更新手法はドライバーの走行位置にとらわれないものであり、トリップ中の任意の地点における“動的”な分析の枠組みである。前述のように、プローブカーデータはドライバーがトリップ中に経験した交通状況や、ドライバーの示す走行特性を分析者に提供することができる。つまり、トリップ開始後には開始前では得られない多くの情報を提供すること

ができ、これらの情報を有効に用いることで、従来の交通データを用いることでは取り組むことが困難であった、より動的な視点から交通行動を分析することが可能である（図 1-2）。

第 4 章と同様に、第 5 章前半において議論される経路選択行動の分析は、起点から終点までを一度に取り扱う静的な枠組みであり、経路選択行動分析においてこれまで最も一般的に取り組まれてきた分析の枠組みである。一方、第 5 章後半で議論されるトリップ中の意思決定発生の有無を考慮した経路選択行動分析は、トリップ中の走行状況を有効に用いることで分析が可能となったより動的な分析の枠組みであるといえる。第 4 章と第 5 章における、静的な分析と動的な分析の関係を図 1-3 に示す。

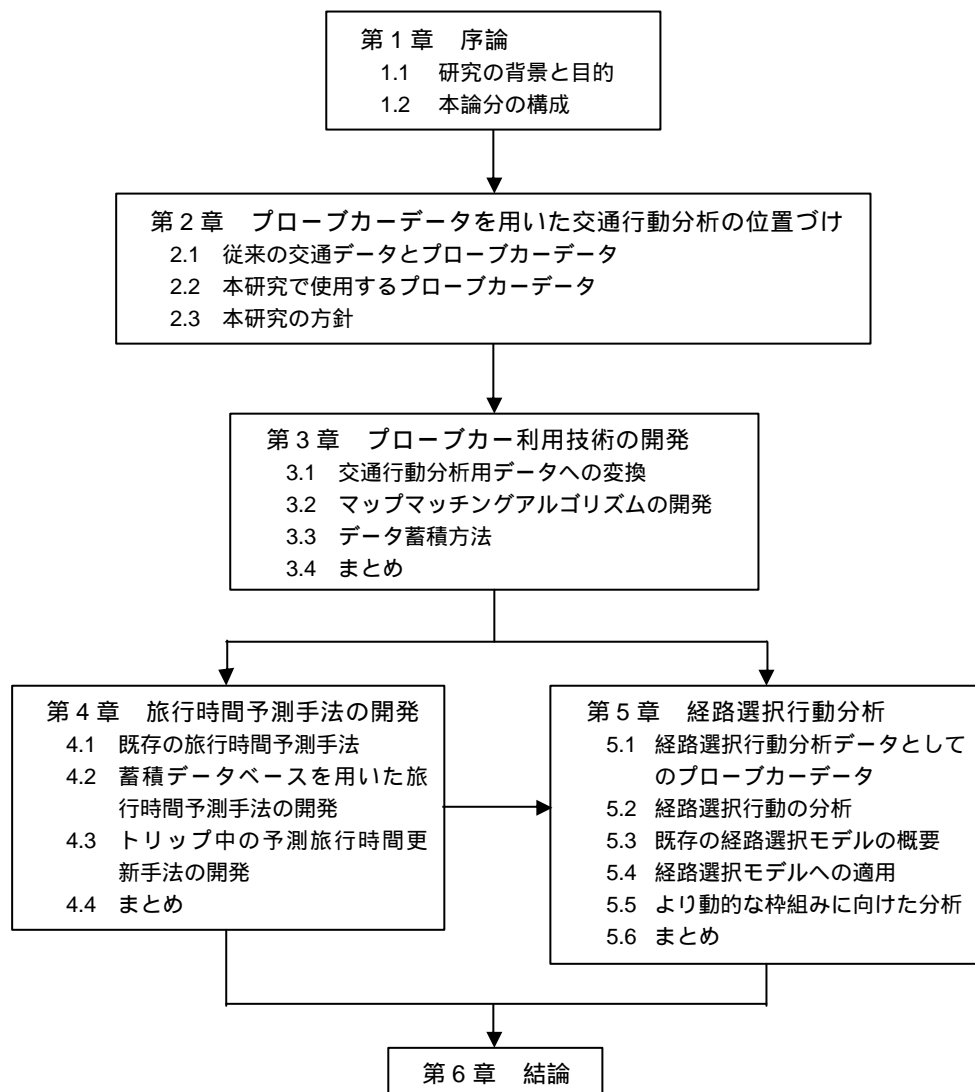


図 1-1 本論文の構成

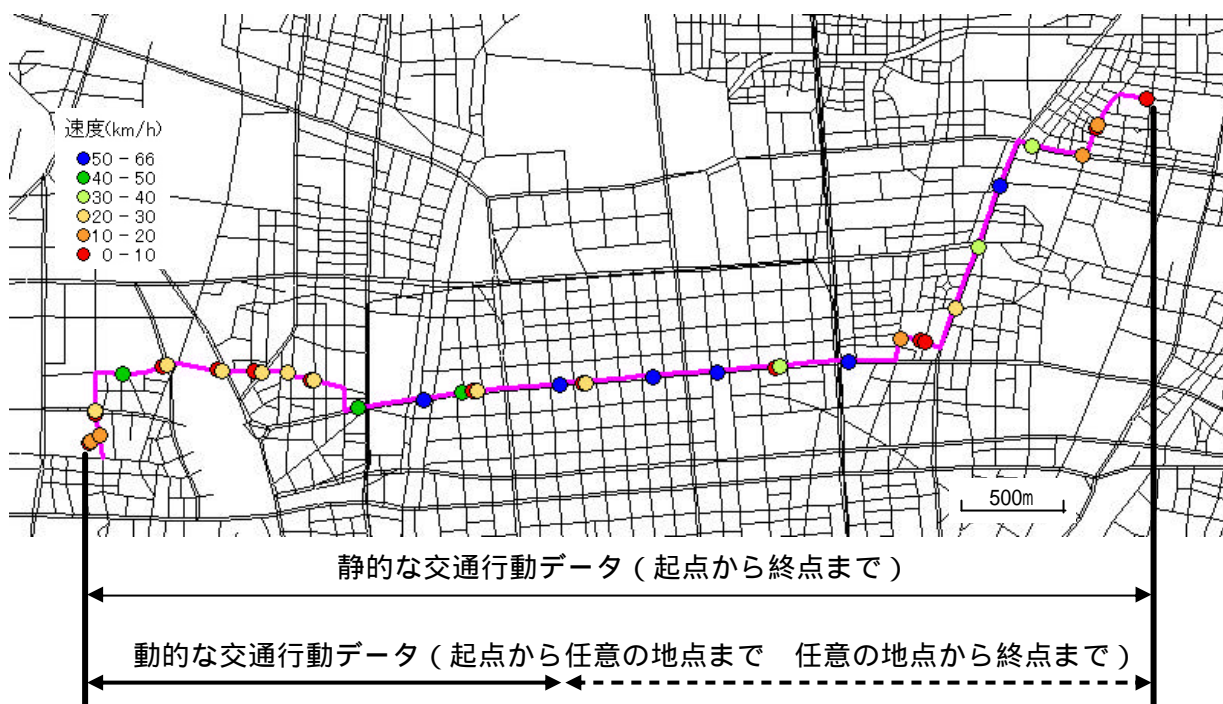


図 1-2 交通行動に関する静的なデータと動的なデータ

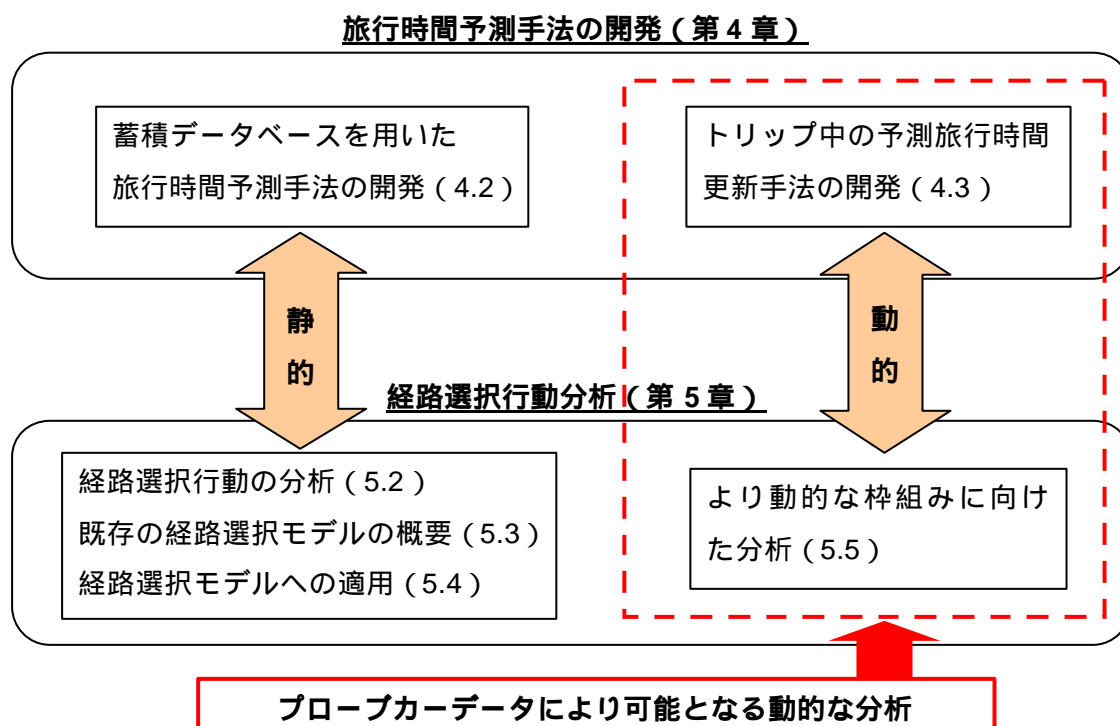


図 1-3 本研究における静的な分析と動的な分析

第 1 章 参考文献

森地茂，川島弘尚，奥野卓司（2000）ITS とは何か 情報革命と車社会 ，岩波書店．

宮島弘志（2003）運行管理システムの変革，JR EAST Technical Review, No.5, Autumn2003,
pp.12-20.

国土交通省道路局（2003）ITS handbook 2003-2004.

第2章 プローブカーデータを用いた交通行動分析の位置づけ

本章では、従来用いられてきた交通データとプローブカーデータの違いを、それぞれの利点や欠点、分析手法に沿ってまとめるとともに、本研究で用いるプローブカーデータの概要を述べる。そして最後に、本研究の基本的な方針について述べる。

2.1 従来の交通データとプローブカーデータ

2.1.1 従来の交通データとその問題点

トリップメーカーである個人の交通行動を分析するために、これまで最も用いられてきたデータはパーソントリップ調査データ（以降、PT データと称す）である。PT データは、50 万人以上の人口規模を持つ都市圏を対象として、抽出された個人の年齢や性別、家族構成などの個人属性や、平均的な一日に行われたすべてのトリップについて調査するものであり、都市圏ごとに 10 年に一度、平日を対象として実施されている。これにより、調査対象圏域全域における一日の交通行動を把握しようとするものであり、自動車交通のみでなく公共交通機関も含めたすべての交通機関の需要予測や、通勤・通学などの交通流を把握するために多く用いられてきた。また、PT データは従来の交通需要予測において実行されてきた四段階推定法のほぼすべての段階（ただし、配分段階には必ずしも適用可能とはいえない）に対して、基礎情報を提供しているものである。しかし、PT 調査はアンケートを用いているため、調査対象者の負担が大きく、また数日前に行った 1 日の交通行動について記憶に基づいて回答するものであるため、回答結果から完全な情報を期待することは難しいといった問題点もある。特に、各トリップに要した旅行時間やその出発時刻が 15 分・30 分単位で丸められるケースがしばしば見られ、さらには、短いトリップや徒歩・自転車トリップなどの報告漏れの存在も指摘されている（北村，2002）。また、道路交通の分析に用いるためには、10 年に 1 度といった長いスパンでの調査では交通状況の変化に関する詳細な分析は困難である（石田ら，1998）。さらには、道路ネットワーク上の交通需要予測において重要となる、自動車を用いた場合の利用経路については、被験者の記憶に基づいて正確な経路を調査することは困難である。

PT データが個人を対象として調査されたものであるのに対して、道路交通センサス自動車起終点調査データ（以降、センサス OD データと称す）は、道路ネットワーク上を走行する自動車を対象としている。調査はおおよそ 5 年に一度行われ、自動車保有者に調査票を配布したり、実際に道路ネットワーク上を走行中する車両のドライバーに路側上でアンケートを配布することで、PT 調査と同様に 1 日の自動車を利用したトリップについて調査している（道路交通センサスホームページ）。また、PT 調査とは異なり全国で一斉に実施されるため、特定の都市圏

だけでなくより広域的な自動車の交通行動を、車種や目的別に詳細に把握することが可能となる。このように作成されたセンサス OD データは、PT データよりも自動車交通に関して正確な情報を提供するものとして、四段階推定法の最終段階である交通量配分における OD 交通量として用いられている。しかし、センサス OD データも PT データと同様に、被験者が利用した経路については正確な情報を得ることは難しい。調査内容には主な利用路線や利用した IC などの情報は含まれるものの、それらへのアクセス・イグレス経路については不明であり、また調査対象者の記憶に基づくものであるため、必ずしも正確な情報を収集できる保証はない。また、調査実施間隔についても PT 調査よりは短い間隔で実施されているものの、交通状況の変化に関する詳細な分析に用いることは難しい。

前章でも述べたように、道路交通ネットワーク上の交通流は、事故や渋滞などの交通問題や排ガスや騒音などによる沿道地域への環境影響が大きい。これらの問題を解決するためには、道路ネットワーク上のどの区間を取り上げ、分析すべきかを把握する必要がある。このような分析に用いられるデータとして、主要道路区間の断面交通量や通過速度等を把握するための調査が行われている。最も代表的な断面交通量調査は、道路交通センサス一般交通量調査である（国土交通省道路局，1999）。これは 2 年ないしは 3 年に一度行われ、道路ネットワーク上の交通状況を把握するための情報として現在最も利用されている。調査にあたっては、道路ネットワークを交通流の均質な区間に分割し、各区間の代表地点に調査員を配置して車種別交通量を目視により調査している。また、調査された交通量データとともに、道路構造（車線数や中央帯設置延長など）や沿道状況（駐車車両数や市街化延長）、ピーク時における平均旅行速度なども合わせてデータベース化されているため非常に用途が広く、これまでにさまざまな分析に用いられてきた。しかし、現実の道路ネットワークは膨大な道路区間により構成されているため、調査には多額の費用を要し、調査地点数もある程度集約する必要がある。さらには、実施される時間的なスパンもおのずと拡大せざるをえない。

日々の詳細な交通変動を調査することを目的とするデータとして、トラフィックカウンターデータがある。これは路側に設置されたセンサーにより、そこを通過する車両数を 5 分ごとに集計しデータ化するものであり、調査はすべて自動化されている。また、トラフィックカウンターには超音波式や埋設されたループコイルからの信号を利用するループディテクターなどがあり、調査される項目は交通量や占有率、各車両の地点速度などである。さらには、通過車両の車両番号を読み取ることで、区間旅行速度を調査することを主目的とする AVI システムも導入されている。これらのデータの特徴は、時間的に途切れることなく情報を収集し続けることにあり、詳細な交通状況の変化を把握するための情報を提供する点にある。これらセンサーの設置箇所は愛知県内に 200 箇所以上あるが、それらはいずれも幹線道路上の主要箇所のみである。さらに、高速自動車国道については日本道路公団が、都市高速道路についてはそれぞれの管理公団（公社）が、一般道路についてはそれぞれの所轄県警が管理しているため、分析に際しては管理者の許可を得なければデータを利用することができない。さらに、これらのデータ

により道路ネットワーク上の各断面における詳細な交通流を観測することが可能となるものの、運転者についての属性や起終点、利用経路について観測することは難しい。

以上が従来の主な交通データであるが、ここまでにまとめた以外にも、例えば、物資流動調査（物資や貨物車などの流動を調査）や大都市交通センサス調査（大都市圏における鉄道やバスなどの大量公共交通機関の利用実態を調査）などもある。このように、従来の交通データにはいろいろな種類があり、それぞれの持つ問題点も様々である。表 2-1 は、従来の主な交通データについて、本研究に関連のある特徴と問題点をまとめたものである。

表 2-1 従来の交通データの特徴と問題点

主な交通データ	特徴	問題点
パーソントリップ調査データ	<ul style="list-style-type: none"> ・ 50 万人以上の人口規模の都市で実施 ・ 個人の 1 日の行動を収集 ・ 性別、年齢、世帯構成など個人属性情報が詳細 ・ 都市圏全域の交通行動データ ・ 都市圏の都市計画・交通計画で用いられる 	<ul style="list-style-type: none"> ・ 抽出率が 3%程度と低い ・ アンケート調査であり、報告漏れの可能性 ・ 調査対象者の記憶に基づくため旅行時間情報の精度が低い ・ 10 年に 1 度の調査 ・ 経路情報は得られない ・ 詳細な交通状況変化に関する情報は得られない
道路交通センサス自動車起終点調査データ	<ul style="list-style-type: none"> ・ 全国規模で実施 ・ 自動車利用トリップのみを対象 ・ 車種、運行目的、乗車人員など詳細な情報 ・ 物資の運搬状況についての情報 ・ 四段階推定法の配分段階で用いられる ・ 自動車の利用状況についての情報 	<ul style="list-style-type: none"> ・ アンケート調査であり、報告漏れの可能性 ・ 5 年に 1 度の調査 ・ 詳細な経路情報は得られない ・ 詳細な交通状況変化に関する情報は得られない
道路交通センサス一般交通量調査データ	<ul style="list-style-type: none"> ・ 全国規模で実施（起終点調査と同年、および中間年に実施） ・ 主要道路区間の車種別通過交通量についての情報 ・ 沿道状況についての情報 ・ ピーク時の旅行速度情報 ・ 交通計画における基礎データとして用いられる 	<ul style="list-style-type: none"> ・ 調査員による直接観測であるため莫大な調査費用 ・ 観測地点数が限られる ・ 2～3 年に 1 度の調査 ・ 速度情報はピーク時のみ ・ OD 情報や経路情報は得られない
トラフィックカウンタデータ	<ul style="list-style-type: none"> ・ 自動観測が可能 ・ 通過車両数、地点速度を観測 ・ 常時観測であるため詳細な交通状況変化についての情報 ・ 加工後に混雑情報として配信される 	<ul style="list-style-type: none"> ・ 収集データ自体は一般に公開されていない ・ 観測地点数が限られる ・ 高速道路、都市高速道路、一般道路などによって管理者が異なる ・ OD 情報や経路情報は得られない

2.1.2 プローブカーシステムの概要

a) プローブカーシステム

プローブカーシステムは車両をセンサーとしてとらえ、走行速度情報や位置情報等を収集することにより交通流動等の道路交通情報を生成するシステムである。名古屋において実施されたプローブカーシステムの基本的な構成を図 2-1 に示す。GPS を搭載した車両(プローブカー)が、実験主体によりあらかじめ設定された間隔で車両の走行位置座標や速度などの動態情報を、既存の通信網を用いて情報センターへ送信するか、もしくは車載機内に蓄積する。プローブカーが走行した走行軌跡や走行速度などの情報を収集することで、分析者は道路ネットワーク上の交通状況についての情報を得ることができる。図 2-2 はプローブカーの走行軌跡と走行速度情報収集のイメージを示している。このように、プローブカーデータを用いれば交通状況を分析することが可能となり、現状を把握もしくは交通施策の立案に役立てることができる。ただし、プローブカーシステムに関する統一的な調査方法はなく、これまでのところ実験の実施主体ごとに調査の目的に適したデータ収集方法を用いている。また、これまでに行われた主な実験や、データ収集方法についての詳細は後述する。

道路ネットワーク上における各道路区間の走行速度や渋滞に関する情報は、これまでは主要幹線道路の限られた地点における感知器や調査員により収集されてきた。これに対して、実際に走行する車両から送信される速度データなどのプローブ情報を用いることで、計測対象となる道路区間は飛躍的に拡大する。また、PT 調査やセンサス OD 調査により取得されてきた、調査対象者の記憶に基づく誤差を含んだ出発・到着時刻や、別途アンケート調査でしか得られなかった走行経路についての情報は、プローブカーを用いることで常時かつ詳細に収集することが可能になる。さらには、ワイパー情報を用いた天候データの取得など、新しく有用な情報の収集・提供も可能となる。以降にプローブカーを用いた実験例、データ取得方法やプローブカーデータの利点、欠点について述べる。




図 2-1 名古屋におけるプローブカーシステムの概要

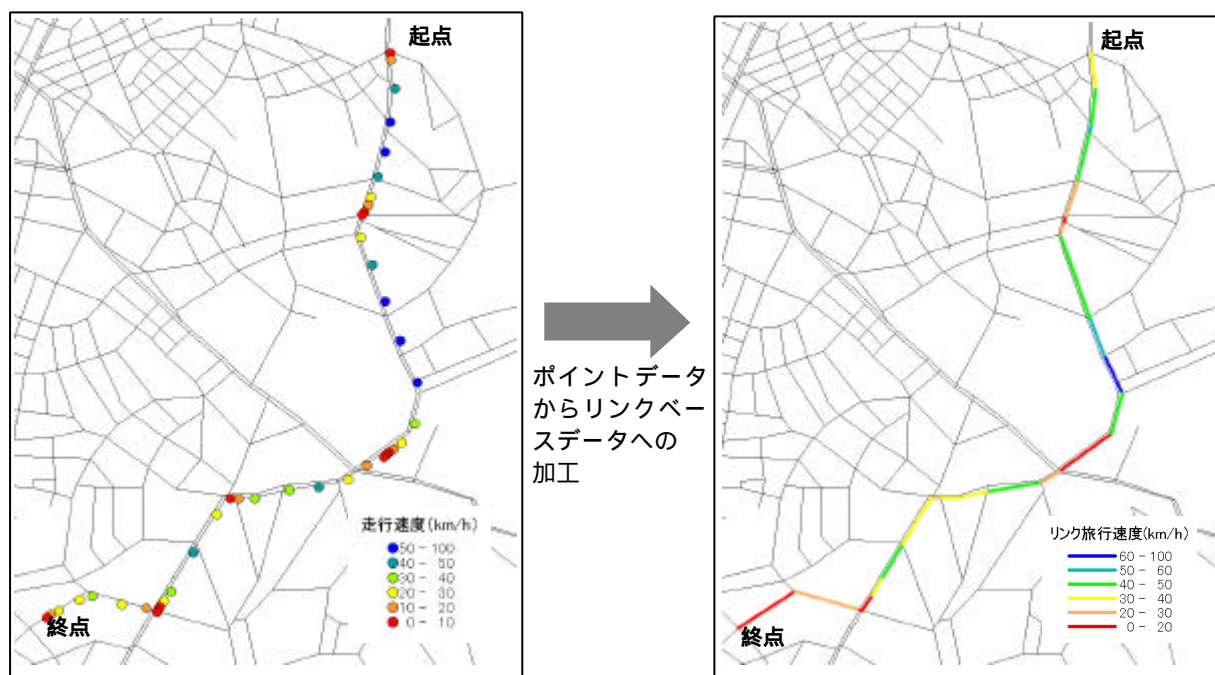


図 2-2 プローブカーによるデータ収集イメージ

b) プローブカーを用いた実験事例

現在世界各地で利用され始めているプローブカーシステムには、車載機の統一された規格やデータ送信・蓄積方式はなく、実験方法も各実施主体が予算や分析対象を踏まえ、GPS 車載機を対象車両に搭載することで行われている。表 2-2 はこれまでに行われたプローブカーを用いた実験において、比較的大規模な実験におけるその対象エリア、プローブカーとされた車種、実験期間等をまとめたものである。

表に示す以外にも、研究主体ごとに少数のプローブカーを準備し、目的に応じたデータ収集が行われている。交通事故発生時における緊急通報 (Funke et al., 2002) や加速度情報による対象地域内の危険地点の抽出 (古屋ら, 2003) 、加速度・速度パターンによる燃料消費量の推定 (Ding and Rakha, 2002) 、交通行動調査としての利用可能性評価 (藤原ら, 2001; Wolf et al., 2002) 、バスロケーションシステムとしての利用 (Schelin and Kronborg, 2002; Tanaka and Tanigawa, 2002) 、トラックの運行管理システムの運用効果 (Odani et al., 2002) など、すでに世界中でさまざまな実験が行われている。

表 2-2 世界の大規模なプローブカー実験*

実施主体	対象エリア	利用車両	車両数	実験期間	概要
シンガポール政府	シンガポール都心部	タクシー	7000	1998 年 4 月 ~	ロードプライシングの料金設定のための走行速度計測
国土交通省	東京 23 区	タクシー	20	2000 年 5 月 ~ 2002 年 6 月	マップマッチング手法の開発と旅行速度・燃料消費量などアウトカム指標の計測可能性評価
		トラック	20		
トヨタ, デンソー, NEC, 経済産業省, 国土交通省, 名古屋大学など	名古屋市	タクシー	1570	2002 年 1 月 ~ 3 月, 2002 年 10 月 ~ 2003 年 3 月, 2003 年 10 月 ~ 2004 年 10 月	インターネットによる交通情報配信とタクシー利用者へのコンテンツ配信などによる事業化評価およびデータ利用技術の開発
いすゞ自動車	全国	トラック	800	2004 年 2 月 ~	運転挙動や燃料消費の分析・評価や危険挙動による緊急通報

*参考文献（中条潮，2001；測量編集委員会・GPS 小委員会編，2002；中部経済産業局，2003；いすゞ自動車 HP）

c) データ収集方法

分析者はプローブカーシステムを通じて、実験目的に応じたデータ項目を収集することができる。しかし、いずれの実験においてもデータ送信時刻とその時点における車両位置座標については少なくとも必要であり、追加的に、速度や加速度、ワイパー作動状況、ウインカー作動状況などの情報を収集することが多い。

データ収集方法には、主に以下に示す 2 つの方法がある。

車載装置にメモリ機能を持たせることでデータを車載機に蓄積し、一定期間データを収集した後に調査員により回収

既存の通信ネットワーク（携帯電話ネットワークの packet 通信など）を利用して、センターサーバへリアルタイムにデータを送信

は車載機のメモリ容量により、データ回収までの期間や取得項目、データ取得間隔などが異なるものの、一般的に実験費用が安価となる。しかしその一方で、リアルタイムなデータの利用が不可能となる。は本研究で用いるデータとも一致するが、データ利用のリアルタイム性は確保されるものの、データ送信費用が高価となる。

データ取得間隔は実験主体ごとに任意に設定できる場合が多く、各実験により異なっているものの大きく分類すれば以下の通り。

一定時間間隔（1 秒間隔など）、または一定距離間隔（100m 間隔など）で取得
車両が停止、発進した場合など、イベント発生ごとに取得

一般に、GPS 車載機は任意の間隔（通常は 1 秒間隔）で、その位置情報や進行角などを測定することが可能である。詳細なデータ収集は詳細な分析を可能にするため、より短い間隔でデータ収集を行う方が多様な分析に用いることができる。しかし、データ量が多すぎると分析に要する時間が長くなり、十分な分析が行えなくなる恐れもある（羽藤，2004）。また、既存の通信ネットワークを利用してリアルタイムにデータ収集を行う場合は、データ送信量に応じて通信費用が発生するため、なるべく少ない通信量で必要なデータを収集する必要がある。したがって、現在各地で行われている実験では、車載機にメモリ機能を持たせる場合には一定間隔で、データ利用のリアルタイム性を確保したい場合はイベントベースで収集する方法が採用されていることが多い。このように、プローブカーから得られるデータの利用方法を十分計画した後、どのような間隔でデータを収集すべきか決定することが必要となる。

2.1.3 プローブカーデータの利点と欠点

プローブカーシステムは、各車両の走行軌跡や走行速度、走行中の加減速、停止回数など、走行動態に関する詳細な情報を収集することが可能である。また、実際に走行する車両をセンサーと捉えることから、トラフィックカウンターや AVI システムなどの固定された観測機器よりも、広い範囲で交通データを収集することが可能となる。さらに、タクシーやバスなど日常的に使用される車両をプローブカーとすることで、効率的にデータを収集することも可能である。したがって、一定の調査期間を経れば、非常に広い範囲でトラフィックカウンターデータと同様の交通状況の変化に関する情報を取得でき、これまでは認知されていなかった、もしくは観測が困難であった渋滞箇所のような道路ネットワーク上の問題点を、広い範囲から抽出することが可能となる。さらに、走行軌跡をドライバーの選択経路と捉えれば、従来のデータからは取得が困難であった利用経路情報を収集することが可能であり、経路走行中の停止回数や走行速度の変化などの情報も合わせて取得できる。このように、プローブカーデータの利点は、これまでは困難であった空間的に広範囲にわたる交通データの取得や、ドライバーの選択経路やトリップ中の経験（停止回数や走行速度など）の詳細な情報を取得することにある。

しかし、表 2-2 にも示した通り、これまでの大規模な実験で使用されたプローブカーはタクシーやバス等の公共車両がほとんどであり、一般車をプローブカーとした大規模な実験はほとんど行われていない。プローブカーは車両の走行軌跡を詳細に取得するものであり、調査対象車両のトリップや経路に関する情報を取得することができる。したがって、一般車をプローブカーとすることにより保有者または運転者のプライバシーを侵害してしまう恐れがある。一般のドライバーの交通行動を分析するためには、調査対象者を募り十分な説明を行った上で実験

を行うことになるが、長期間にわたる実験を行うことや、多くのドライバーに協力を依頼することは困難である。また、タクシーなどの公共車両をプローブカーとする場合にも、運転するドライバーに関する情報を取得することは困難である。このように、プローブカーデータは運転者に関する個人属性等の情報を得ることが困難である。

また、収集されるデータの空間的な密度がばらつくという欠点もある。これは、プローブカーが稀にしか走行しない路線についての情報は非常に少なく、頻繁に走行する路線についての情報は非常に多いといった、データ収集エリアにむらが生じることも欠点の一つである。しかし、このようなプローブカーデータの欠点を克服するために、最適な車両配置の検討（堀口，2002）や、VICS データなど従来の交通データからの補間を試みる研究も行われている（姜ら，2004）。表 2-3 は、プローブカーデータの有する利点や欠点についてまとめたものである。

表 2-3 プローブカーデータの利点と欠点

プローブカーデータの利点	プローブカーデータの欠点
<ul style="list-style-type: none"> ・ 走行状態（走行速度、停止回数など）に関する詳細な情報を収集できる ・ 走行軌跡を正確に取得できる ・ 調査範囲が広く、またプローブカーが通過する区間であればどこでも情報を収集できる ・ 大規模なインフラ設備を必要としない ・ 目的に応じて車種を選定可能 	<ul style="list-style-type: none"> ・ 同一地点における時間的に連続したデータ収集が困難 ・ 分析に時間がかかる ・ 運転者属性などの情報を取得することが困難 ・ プローブカーとする車両の選定や配置によりデータが収集される路線や地域にむらが生じる

2.2 本研究で使用するプローブカーデータ

2.2.1 データの概要

本研究で使用するデータは、トヨタ、デンソー、NEC、経済産業省、国土交通省、名古屋大学などが、名古屋市周辺地域で行った実験（以降、名古屋実証実験と称す）により収集されたデータである（慶應義塾大学インターネット ITS 共同研究グループ，2002）。実験は名古屋市周辺の 32 のタクシー営業所に協力を依頼し、1570 台のタクシーをプローブカーとして収集された。実験期間は 2002 年 1 月～3 月（以降、第 1 期と称す）、2002 年 10 月～2003 年 3 月（以降、第 2 期と称す）の計 9 ヶ月間であるが、第 1 期の最初の 1 ヶ月間はタクシーに車載システムを設置する作業期間であったため、必ずしも全台数がプローブカーとして運用されていない。実験の目的は、収集されたデータをタクシー営業所へ送信することによる運行管理用データとしての利用や、インターネット上での渋滞情報や降雨情報の配信、タクシー車内での乗客に向けた Push 型広告の提供などプローブ情報の利用方法の検討、さらには交通基礎データとしての利

用技術の開発などである（中部経済産業局，2003；総務省，2004）。したがって，プローブカーからのデータ収集にはリアルタイム性の確保が必要となる。名古屋実証実験では，データ収集に携帯電話通信におけるパケット通信を用いており，通信費用は約 5,000 円/月・台となっている。表 2-4 に本研究で使用するプローブカーデータの概要を示す。

表 2-4 本研究で使用するプローブカーデータの概要

項目	説明
対象エリア	名古屋市周辺
プローブカー(台数)	タクシー (1570)
実験期間	9 ヶ月間 (第 1 期: 2002 年 1 月 ~ 3 月, 第 2 期: 2002 年 10 月 ~ 2003 年 3 月)
データ送信方法	携帯電話通信網を利用したパケット通信
データ取得間隔	イベントベース (表 2-5 参照)
データ項目	時刻, 車両位置座標, 速度, 加速度, 乗客の有無など (表 2-6 参照)
データ蓄積方法	走行路線などの情報付加の後, センターサーバに蓄積
車載機	655 台にはカーナビゲーションシステムが装備 (表 2-7 参照)
通信費用	約 5,000 円 / 月・台
その他	タクシー営業所での運用管理データとして利用 渋滞情報や降雨情報のリアルタイム配信

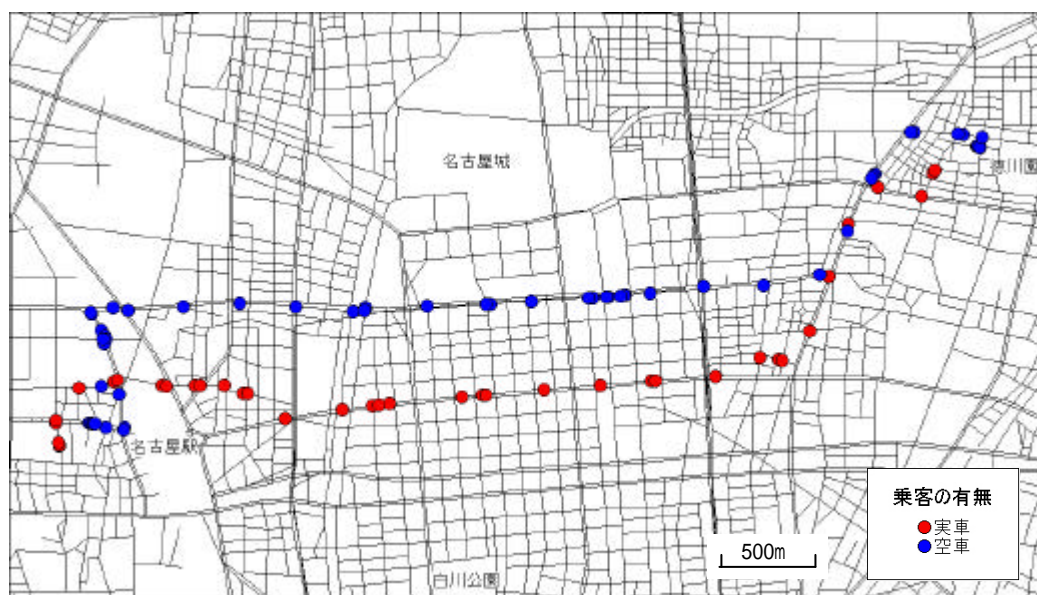
また前述の通り，既存通信網を利用したリアルタイムデータ収集は頻繁なデータ送信を行うと通信コストが高価となる。このため，データ送信タイミングとその頻度，それにより発生する通信コストを十分検討した上で，表 2-5 に示すイベントをデータ送信トリガとして行われた。

表 2-5 名古屋実証実験でのデータ送信イベントとその構成比

イベント名	備考	構成比*
距離周期	300m 走行中に他のイベントが発生しない時	35.1%
SS (Short Stop)	車両発進時	31.3%
ST (Short Trip)	車両停止時	29.8%
時間周期	550 秒間に他のイベントが発生しない時	3.8%
実車 / 空車変化時	タクシーの実車 / 空車変化時	
エンジン始動 / 終了時	エンジンを始動 / 終了した時	
危険挙動発生時	速度超過: 80km/h で 120 秒以上走行したとき 急加速: 0.3G 以上の加速度が発生したとき 急減速: 0.3G 以上の減速度が発生したとき	

*第 1 期実験データより集計

2002 年 3 月 28 日（木）にはプローブカー稼働台数が 1,557 台であり，1 台当りの平均データ送信回数は 1,521 回，平均走行距離は 208.3km であった．一方，2001 年における乗用車（ただし，営業用車両を含む）の平均走行距離は約 23km/日であることから（（財）道路経済研究会，道路交通経済研究会，2004），タクシーをプローブカーとして情報を収集することは，一般車をプローブカーとすることよりも詳細で広範囲な道路交通情報を入手できるといえる．また上表から，距離周期（300m），SS，ST がそれぞれ 30～35% 程度であり，それら 3 種類で全体の 96% 以上を占めており，本研究で使用するデータの大半がこれら 3 つのイベントデータにより構成されていることが分かる．表 2-6 に本研究で使用するプローブカーデータのデータフォーマットを示す．本研究で用いるプローブカーデータは，各車両から送信される時刻や車両位置座標（緯度，経度），走行速度，加速度，各フラグ（SS フラグ，ST フラグ，実車／空車フラグ）などに関する情報に，センターサーバに蓄積する直前に，電子道路地図（Digital Road Map 以降，DRM と称す）基本道路網（県道・指定市市道以上の全ての幹線道路と幅員 5.5m 以上のその他の道路）を参照し近接リンクに関する情報を付加した上で蓄積している．これにより，位置座標を参照しなくても，走行路線や車両走行位置に関する情報を得ることが可能である．本研究では，このように近接リンクを用いたリンク情報の付加方法を“近接リンク法”と呼ぶ．しかしこの処理では，送信される連続した車両位置座標を独立に扱い近接リンクに対応付けるため，特定された走行リンクを繋げても走行経路とはならないことがしばしば発生する．この問題とその対策については第 3 章で詳細に議論される．参考として，図 2-3 にプローブカーデータを DRM 上に表示したものを示す．名古屋実証実験ではタクシーをプローブカーとしているため，乗客の乗車位置や降車位置までの走行経路，空車中の走行軌跡などが情報として得られる．



*車両 ID：1001 2002/1/1 0:58:44 - 1:54:46

図 2-3 タクシーをプローブカーとしたときの取得データ例

表 2-6 センターサーバに蓄積されるデータフォーマット

項目	備考
車両 ID	
車載機 UNIX 時刻	データ取得時刻（日本標準時）”YYYYMMDDhhmmssmm”形式
業態種別	1: タクシー事業者（固定）
速度	0～255 単位(km/h)
加速度	-128～127 単位（0.01G）
積算走行距離	単位(m)
GPS 緯度	車両から送信される緯度（Type1:WGS-84 系，Type2: 日本測地系）
GPS 経度	車両から送信される経度（Type1:WGS-84 系，Type2: 日本測地系）
オンラインマッチング結果*2	0=正常，1=マップマッチング異常
オリジナル緯度*1	測地系変換後の緯度 1LSB=1/256（度） GPS 異常時:0
オリジナル経度*1	測地系変換後の経度 1LSB=1/256（度） GPS 異常時:0
オリジナル進行方向*1	測地系変換後の進行方向（1 6 方位） 01h=北、02h=北北東、03h=北東、04h=東北東、05h=東、06h=東南東、07h=南東、08h=南南東、09h=南、0Ah=南南西、0Bh=南西、0Ch=西南西、0Dh=西、0Eh=西北西、0Fh=北西、10h=北北西、00h=不明
処理後緯度*2	マップマッチング不可の時はオリジナル緯度 1LSB=1/256（度） GPS 異常時:0
処理後経度*2	マップマッチング不可の時はオリジナル経度 1LSB=1/256（度） GPS 異常時:0
処理後進行方向*2	オリジナル進行方向と同じ
2 次メッシュ番号*2	0=マップマッチング不可
リンク番号*2	0=マップマッチング不可
リンク方向*2	0=正，1=逆，9=不明
リンク位置*2	始点からの位置（リンク基準端点からの位置）
リンク長*2	DRMDB のリンク長(m)
道路種別*2	1：高速自動車国道，2：都市高速道路，3：一般国道，4：主要地方道（都道府県道），5：主要地方道（指定市道），6：一般都道府県道，7：指定市の一般道，9：その他の道路，0：未調査，-1: マップマッチング不可
路線番号*2	路線番号 -1=マップマッチング不可
パーキングブレーキ	0=検出せず，1=検出
ワイパー	0=動作無し，1=動作有り
SS フラグ	0=検出せず，1=検出
ST フラグ	0=検出せず，1=検出
速度超過フラグ	0=検出せず，1=検出
急加速フラグ	0=検出せず，1=検出
急減速フラグ	0=検出せず，1=検出
緊急通知スイッチ	0=検出せず，1=検出
実車 / 空車フラグ	0=空車，1=実車

*1 プローブ車両から送信されたデータを統一するための変換により作成されたデータ

*2 DRM への近接リンク法（第 3 章参照）により追加されたデータ

プローブカーに搭載される車載機には、表 2-7 に示すように Type1 ～ 3 の 3 種類の機器が用いられた。ここで、Type1 および Type3 はモバイルタイプの簡易な GPS 車載機であるのに対して、Type2 車載機はカーナビゲーションシステムが接続されている。したがって、Type2 車載機から送信されるデータは、カーナビゲーション内で使用されている地図データ上へ車両位置座標が補正されており、さらには GPS による車両位置補正エラーが発生しても、自律航法システムにより車両位置座標を推測することも可能であることが知られている（Makimura et al., 2002）。図 2-4 に車載機タイプ別の位置測位ミス発生比率を示す。ここで、位置測位ミスとは GPS の位置測位が不能であった場合を指し、カーナビの装備された Type2 は位置測位ミスがほとんど発生しないのに対して、Type1、Type3 は比較的多く発生している。このため本研究では、ほとんどの分析において Type2 車載機によって収集されたデータを分析に用いている。

表 2-7 使用された車載機タイプと使用台数

車載機タイプ	搭載車両数	備 考
Type1	845 台	モバイルタイプの車載機であり、パケット通信機と GPS 機器のみであるため、位置動態情報にエラーが多い。
Type2	655 台	Type1 車載機にカーナビゲーションシステムが合わせて用いられている。カーナビゲーションシステムにより位置動態情報を補正しているため高精度の情報が取得可能。
Type3	70 台	Type1 車載機に DSRC 無線機や広告表示用のタッチパネルが接続されている。位置動態情報にエラーが多い。




図 2-4 車載機タイプ別位置測位ミス発生比率

2.2.2 交通データとしての特徴

a) タクシーの走行速度

タクシーをプローブカーとして利用する場合には、その走行特性に十分注意する必要がある。特に、実車中（乗客が乗車してから降車するまで）のタクシーと空車中のタクシーでは、その

走行特性に大きな違いがある．図 2-5 は，2002 年 3 月 28 日に名古屋市都心部桜通を走行するプローブカーデータのうち，距離周期データの走行速度を集計したものである．この図より，実車中のタクシーは空車中より平均で 4km 程度走行速度が高く，また分散も大きくなっている．空車中のタクシーは乗客を探しながら走行する，いわゆる“ながし”走行を行うため速度が低くなると考えられる．また，走行経路についても空車中のタクシーは明確な目的地を持たないため同じ地点を何度も走行するなど，経路選択行動データとしては利用しにくい特徴がある．このため本研究では，この点を踏まえて実車中のデータを抽出して分析するものとする．





図 2-5 実車空車別走行速度

b) トリップ発生状況

図 2-6 に第 1 期実験期間におけるプローブカーデータより集計されたタクシートリップの発生状況，および，1991 年に実施された第 3 回中京都市圏 PT 調査（中京都市圏総合都市計画協議会，1993）による，名古屋市内で発生した自家用乗用車利用トリップの発生状況を示す．ただし，図中のプローブカーデータのトリップ数は第 1 実験期間を通じて観測されたものであり，第 1 実験期間には全てのプローブカーが稼動していたわけではないため，ここではタクシートリップ発生分布の特徴のみを考察する．

タクシートリップは深夜から明け方を除けば平日の発生トリップ数が休日を大きく上回っている．また，平日・休日ともに 9 時～23 時まで発生トリップ数に大きな変化はなく，午前 0 時から減少し始め午前 5 時に最も少なくなる．一方，PT データによる自家用車利用トリップは，7～8 時，17 時～18 時に多く，それ以外の時間帯に発生するトリップ数が相対的に少ないことが分かる．これにより，タクシートリップは，最も交通量の多い時間帯が 2 時間程度後ろにずれることや，9 時～23 時まで発生トリップ数がそれほど減少しないことなどが一般的な自動車交通と大きく異なっている．したがって，取得されるデータは昼間～深夜までのデータが多く，交通データとしては重要な時間帯である朝ピーク時のデータ量が少なくなるため，十分なデータ収集期間を設定するなどして必要なデータ量を確保しなければならないといえる．



タクシートリップ：第1期実験データより集計 自家用車トリップ：第3回中京都市圏 PT データより集計

図 2-6 タクシートリップの発生分布

図 2-7 は、名古屋市内で発生したトリップの分布交通量を示している。図より、中区や中村区、千種区、東区など、タクシー利用トリップ発集量の多い商業地域において多くのトリップが観測されていることが分かる。このような都心エリアは交通渋滞も激しく交通計画上重要な地域であるため、多くの観測データが得られることは重要ではあるものの、週末の深夜などでは多くのタクシーが都心部に集中するため幅広いデータ収集の面では問題もある。本研究では取り扱わないが、最適なプローブ配車手法の検討など実験以前に行うべき問題も見られる。

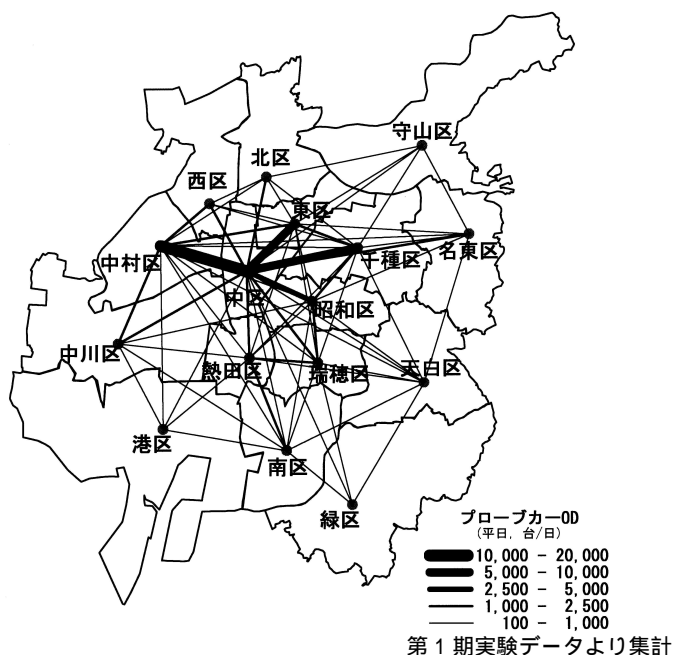


図 2-7 タクシートリップの分布

c) トリップ長分布

図 2-8 にタクシートリップの距離帯別構成比を示す．この図より，タクシートリップのうち 70% 程度が 4km 未満のトリップであり，非常に短い距離のトリップにより構成されていることが分かる．また，タクシートリップの平休別時刻別平均トリップ長を示す図 2-9 より，タクシートリップは 7 時から 20 時までは 3km から 4km 程度のトリップ距離であり，深夜から明け方にかけてトリップ長が長くなることが分かる．また，平日よりも休日の方がトリップの距離が長くなる傾向も見られる．




図 2-8 タクシートリップの距離帯別構成比




図 2-9 タクシートリップの平休別時刻別平均トリップ長

d) 旅行時間情報の精度

ここでは，交通計画策定上重要なサービス水準の一つである OD 間旅行時間を取り上げる．

プローブデータの精度を検証するため、第3回中京都市圏 PT 調査の自動車利用小ゾーン間旅行時間を用いた。ただし、この PT 調査データは 1991 年に実施されており、プローブカーデータとは調査年度が異なる。また、ネットワークの整備状況も異なるため、OD 間旅行時間を直接比較することは行わない。ここでは、プローブカーデータによる旅行時間情報が、従来データと比較して有利となる点について明らかにすることを目的とする。表 2-8 に名古屋駅から名古屋市内の各区役所（16 区役所）のある PT 小ゾーンまでの旅行時間を、4 つのピーク・オフピーク時間帯ごとに集計したものを示す。

表 2-8 OD 間自動車旅行時間情報の違い（名古屋駅小ゾーン 各区役所小ゾーン）

< 朝ピーク（7:00～9:00）>

		H3PT調査			プローブカーデータ		
起点	終点	サンプル数	平均旅行時間(分)	分散	サンプル数	平均旅行時間(分)	分散
名古屋駅	千種区	0	-	-	11	20.5	16.7
	東区	2	15.0	0.0	56	12.6	5.5
	北区	0	-	-	8	13.5	15.2
	西区	0	-	-	60	7.1	4.9
	中村区	1	10.0	0.0	45	7.2	34.8
	中区	1	15.0	0.0	138	10.2	5.7
	昭和区	0	-	-	4	17.1	3.8
	瑞穂区	0	-	-	2	22.5	17.1
	熱田区	0	-	-	1	18.4	0.0
	中川区	0	-	-	5	15.2	4.9
	港区	1	25.0	0.0	2	30.6	26.9
	南区	0	-	-	1	23.8	0.0
	守山区	0	-	-	0	-	-
	緑区	0	-	-	0	-	-
	名東区	0	-	-	1	27.5	0.0
	天白区	1	60.0	0.0	0	-	-

< 昼オフピーク（9:00～17:00）>

		H3PT調査			プローブカーデータ		
起点	終点	サンプル数	平均旅行時間(分)	分散	サンプル数	平均旅行時間(分)	分散
名古屋駅	千種区	2	12.5	6.3	118	23.5	36.6
	東区	3	30.0	66.7	257	15.0	18.9
	北区	2	70.0	2500.0	79	16.4	21.0
	西区	1	10.0	0.0	167	9.1	14.8
	中村区	4	9.8	0.2	443	7.7	55.7
	中区	8	26.3	67.2	868	13.0	25.7
	昭和区	0	-	-	25	21.0	56.3
	瑞穂区	3	26.7	22.2	41	27.3	21.2
	熱田区	4	37.5	256.3	72	22.4	42.4
	中川区	4	37.5	631.3	21	17.5	43.0
	港区	2	30.0	0.0	11	26.6	31.8
	南区	0	-	-	10	28.1	76.6
	守山区	3	50.0	66.7	5	33.3	6.3
	緑区	0	-	-	2	36.1	30.5
	名東区	0	-	-	3	42.5	9.0
	天白区	0	-	-	3	37.1	35.0

< タピーク（17:00～19:00）>

		H3PT調査			プローブカーデータ		
起点	終点	サンプル数	平均旅行時間(分)	分散	サンプル数	平均旅行時間(分)	分散
名古屋駅	千種区	0	-	-	62	24.4	20.2
	東区	1	19.0	0.0	57	17.3	21.0
	北区	2	20.0	0.0	53	15.4	9.4
	西区	0	-	-	30	9.2	15.1
	中村区	1	10.0	0.0	86	9.2	242.0
	中区	3	16.7	22.2	528	13.7	16.1
	昭和区	0	-	-	5	20.1	23.3
	瑞穂区	2	35.0	0.0	14	27.6	18.5
	熱田区	0	-	-	16	28.0	477.0
	中川区	0	-	-	8	17.3	21.7
	港区	0	-	-	3	23.3	14.7
	南区	0	-	-	2	24.7	159.4
	守山区	0	-	-	2	35.8	9.7
	緑区	0	-	-	0	-	-
	名東区	0	-	-	0	-	-
	天白区	0	-	-	2	38.7	7.6

< 夜オフピーク（19:00～7:00）>

		H3PT調査			プローブカーデータ		
起点	終点	サンプル数	平均旅行時間(分)	分散	サンプル数	平均旅行時間(分)	分散
名古屋駅	千種区	1	90.0	0.0	327	20.3	20.1
	東区	0	-	-	214	13.6	15.0
	北区	1	30.0	0.0	136	12.7	14.7
	西区	1	20.0	0.0	102	6.9	8.8
	中村区	0	-	-	251	5.9	12.2
	中区	6	16.7	5.6	1,749	11.7	15.0
	昭和区	1	50.0	0.0	59	15.5	18.8
	瑞穂区	0	-	-	95	21.5	18.7
	熱田区	0	-	-	78	16.0	16.0
	中川区	0	-	-	46	13.1	25.0
	港区	0	-	-	17	18.7	21.6
	南区	0	-	-	23	23.7	83.6
	守山区	1	40.0	0.0	37	29.4	32.5
	緑区	0	-	-	8.5	28.6	31.1
	名東区	1	60.0	0.0	74	33.3	39.9
	天白区	0	-	-	14	32.8	37.9

第1期実験データより集計

これにより、PT 調査ではサンプル数が少ないために、旅行時間情報の得られないゾーンが多く存在している。また 2.1.1 でも示したが、被験者のあいまいな記憶により調査票に記入され

る旅行時間は 15 分,30 分単位が多く,被験者の知覚旅行時間のばらつきも大きくなっている。プローブカーデータではサンプル数も多く,また分散も比較的小さくなっており,従来の調査方法によるデータに比べて信頼性の高い旅行時間情報が得られることが分かる。

2.3 本研究の方針

本研究では,自動車を運転するドライバーに関する交通行動を分析することを主眼とする。自動車が走行する道路ネットワークは渋滞や事故など社会的な影響が大きく,これまでもこれらを解決するための調査・研究が多く行われてきた。プローブカーデータは道路網上を実際に走行する車両から得られるものであり,すなわち道路ネットワーク上の自動車交通に関する情報である。したがって,プローブカーデータは本研究において非常に重要な分析データとなりうる。移動する人に GPS 機能付携帯電話や PHS などを携帯させ,これにより個人の 1 日の行動そのものを観測,分析しようとする試みや(Asakura et al, 1999; 朝倉ら, 2000; Asakura and Hato, 2001; Asakura and Iryo, 2004) 利用交通機関を特定しようとする試みも行われているが(井料ら, 2002),これらの最終的な目的は,PT 調査データを代替しうるデータを収集することである。つまり,滞在地点や滞在時間,トリップの報告漏れなどにおいてより精度の高いデータを収集しようとするものであり,本研究の主眼とするところとは外れる。

プローブカーを用いた実験が世界各地で行われ始めるにつれ,これにより収集されるデータを用いて交通現象を分析しようとする研究が近年次第に蓄積され始めた。しかし,これら既存研究の多くがプローブカーデータを実際に使うものではなく,交通シミュレータを用いた仮想的な交通状況下において,全 OD 交通量のうち設定した構成比率でプローブカーを混入した場合を想定するものが多い。これは,これまでにプローブカーを利用した実験がそれほど多くは行われておらず,誰もが容易にデータを使用できる環境にはないことや,プローブカーが提供する情報は連続する車両の走行位置を表す座標データであり,このデータを分析に使用するためには走行路線を特定する作業が必要となるためであると考えられる。交通シミュレータによる仮想的な環境は,実際にフィールド実験を行うよりも設定変更やデータの取り扱いが容易であり,またこれにより基礎的で有用な知見も得られる。しかし,現実の交通状況やドライバーの経路選択行動において未知な部分は多く,これらについて仮定をおいて実行された交通シミュレーションの結果は現実の交通現象とは一致しない場合も多い。したがって本研究では,名古屋実証実験によって実際に収集されたプローブカーデータを用いることで,これまでは計測が難しかった,また,これまでは取り組まれてこなかった領域についてプローブカーデータの特性を活かしつつ分析を進める。

しかし 2.1.3 においてまとめたように,プローブカーデータは多くの利点を持つ反面,多くの欠点も併せ持っている。本研究で用いるプローブカーデータは 9 ヶ月間という比較的長い実験期間によって収集されているものの,タクシートリップの少ない郊外部などでは収集される

データ量が非常に少ない．しかし，より長期間に渡って実験を行うことでこの問題点はある程度解決できるものと考えられ，本研究では分析時において十分なデータ量が確保できる地域や路線について分析を進める．また 2.2.2 でも示したように，タクシートリップはそのほとんどが 4km 程度と短い距離のトリップにより構成されている．このような短距離のトリップと都市間のような長距離のトリップでは，経路選択行動は異なると考えられる．この点についても，より長期間の実験を行うことで克服可能である．したがって，本研究では十分なデータ量が確保できる OD ペアについて分析を進めるものとする．

2.2.1 でも述べたように，本研究で使用するプローブカー（タクシー）には，カーナビゲーションシステムを搭載するものも含まれており，これにより車両の位置動態情報を精度良く収集することが可能となる．しかし，タクシードライバーの経路選択に関する意思決定には，カーナビゲーションシステムによる推奨経路情報を参照することはほとんどないと考えられる．これは，走行経験が豊富なタクシードライバーは，道路ネットワークや交通状況に関して経験的に蓄積された情報が多いためであり，走行経験による認知旅行時間や経路選択行動の変化を扱った幾つかの既存の研究で報告された知見とも一致する（藤井ら，1999；rinivasan and Mahmassani, 2001）．また，乗客を乗せたタクシーの経路選択に関する意思決定者は誰かという問題もある．この問題に対して，本研究では基本的にはタクシードライバーが経路を選択していると考え．ただし，高速道路を利用するかどうかなどの特別な意思決定に際しては，乗客の意向を踏まえた上で決定していると考え．

最後に，本研究の多くの分析において 様々なドライバーについてその個人属性を用いれば，より有用な知見が得られると考えられるものが多い．特に，同一個人が繰り返し行う経路選択行動を分析する際には，連続する選択行動間の相関が考慮されるべきである（Srinivasan and Mahmassani, 2003）．しかし，すでにプローブカーデータからは得ることのできない情報として，これを運転するドライバーに関する情報があることを述べた．さらに，一般的にタクシーは同一車両を複数人で使用するため，車両 ID などを選択者固有の属性として使用することは困難である．また，一般車をプローブカーとして多くのデータを収集することも現段階では困難であることもすでに述べた．一般にタクシードライバーは通常のドライバーよりも運転頻度が極めて高く，道路交通状況や道路ネットワークに関する認知も高いと考えられる．このため，本研究で得られる知見は，必ずしもそれらすべてが一般のドライバーの交通行動に適用可能であるとはいえない．しかし，現実のドライバーの選択経路や走行特性について，本研究で行うような非常に多くのデータを用いてこれを分析した例は極めて少なく，得られる知見も少なからず有用であると考えられる．したがって，本研究ではドライバーの個人属性については取り扱わないものとし，収集された経路選択結果は全て独立した交通行動として取り扱う．

第 2 章 参考文献

- 朝倉康夫，羽藤英二，大藤武彦，田名部淳（2000）PHS による位置情報を用いた交通行動調査手法，土木学会論文集，No.653，-48，pp.95-104．
- 石田東生，森川高行，永野光三，毛利雄一，中野敦（1998），パーソントリップ調査の現状と課題，土木計画学研究・講演集，No.21(1)，pp.601-608．
- いすゞ自動車ホームページ，<http://www.isuzu.co.jp/cv/cost/mimamori/online.html>．
- 井料隆雅，小根山裕之，Edward Chung，桑原雅夫（2003）個人位置情報を用いた利用経路および交通機関の推定手法に関する研究，土木計画学研究・講演集，Vol.27，CD-ROM．
- 北村隆一（2002），交通行動調査の展開，北村隆一・森川高行編著「交通行動の分析とモデリング」，pp.53-68，技報堂．
- 慶應義塾大学インターネット ITS 共同研究グループ（2002）インターネット ITS 研究開発報告書，<http://www.internetits.org/ja/report.html>．
- 国土交通省道路局（1999），平成 11 年度道路交通センサス，CD-ROM．
- 姜美蘭，王立暁，三輪富生，山本俊行，森川高行（2004）VICS データとプローブデータの旅行時間情報に関する比較分析，土木計画学研究・講演集，Vol.29，CD-ROM．
- 総務省（2004）プローブ情報を活用した動的経路誘導システムの研究開発，平成 15 年度戦略的情報通信研究開発推進制度における研究主体育成型研究開発報告書．
- 中京都市圏総合都市計画協議会（1993），第 3 回中京都市圏パーソントリップ調査報告書．
- 中部経済産業局（2003）車のインターネット接続による新たなコンテンツ事業の研究開発，平成 13 年度即効型地域新生コンソーシアム研究開発事業成果報告書．
- 道路交通センサスホームページ，<http://www.cgr.mlit.go.jp/chiki/doyroj/sensasu/index.htm>．
- （財）道路経済研究会，道路交通経済研究会（2004）国土交通省道路局監修「平成 15 年度版道路交通経済要覧
- 中条潮（2001）車社会の IT 革命，ITS 産業・経済 2001．
- 「測量」編集委員会・GPS 小委員会編（2002）GPS が交通調査を変える～プローブカーによるパラダイムシフト～，GPS フロンティア，pp.13-20．
- 羽藤英二（2004）交通を測る新技術 ヒト，モノ，環境 第 4 回 人の行動を測る プローブ調査の実施と展望，交通工学，Vol.39，No.2，pp.89-95．
- 古屋秀樹，牧村和彦，川崎茂信，赤羽弘和（2003）車載型センサーを用いた車両挙動特異地点抽出に関する基礎的研究，土木計画学研究・論文集，Vol.21，No.4，pp.787-795．
- 藤井聡，中野雅也，北村隆一，杉山守久（1999）認知所要時間の形成プロセスに関する実証的研究，土木計画学研究・講演集，No.22(1)，pp.393-396．
- 藤原章正，杉恵頼寧，岡村敏之，山田敏久（2001）GPS を用いた観光周遊行動調査の適用可能性，土木計画学研究・講演集，Vol.24，CD-ROM．

- 堀口良太 (2002) 効率的な交通情報提供サービスのためのタクシープローブ配備計画手法の理論と実証, 第1回 ITS シンポジウム Proceedings, pp.677-683.
- Asakura, Y., E. Hato, Y. Nishibe, T. Daito, J. Tanabe and H. Koshima (1999) Monitoring Travel Behaviour using PHS based Location Positioning Service System. Proceedings of the 6th World Congress on Intelligent Transport Systems, CD-ROM.
- Asakura, Y. and E. Hato (2001) Rethinking Urban Travel Measurement, Asia GIS, CD-ROM.
- Asakura, Y. and T. Iryo (2004) Tracking Individual Travel Behaviour using Mobile Phone, Proceedings of International Workshop on Behavior in Networks, pp.191-200.
- Ding, Y. and H. Rakha (2002) Trip-Based Explanatory Variables for Estimating Hot-Stabilized Light-Duty Gasoline Vehicle Fuel Consumption and Emission Rates, 81st Transportation Research Board, CD-ROM.
- Makimura, K., H. Kikuchi, S. Tada, Y. Nakajima, H. Ishida and T. Hyodo (2002) Performance Indicator Measurement Using Car Navigation Systems, 81th Transportation Research Board, CD-ROM.
- Odani, M., S. Kinoshita, M. Yoshii and T. Hirai (2002) Development of Truck Operations Management System and ITS Evaluation through Field Experiment, Proceedings of 9th World Congress on Intelligent Transport Systems, CD-ROM.
- Funke, D., J. Ort, C. Thielman and E. Mark (2002) IIMS, A Multi-Agency System for Coordinating Incident Responses – A Phase 2 Update and Initial Test Results, Proceedings of 9th World Congress on Intelligent Transport Systems, CD-ROM.
- Schelin, E. and P. Kronborg (2001) ITS in Practice in Sweden, Proceedings of 9th World Congress on Intelligent Transport Systems, CD-ROM.
- Srinivasan, K.K. and H.S. Mahmassani (2001) Trip time perception and judgment process in Tripmaker decisions under real-time traffic information, Transportation Research Board 81st Annual Meeting, CD-ROM.
- Srinivasan, K.K. and H.S. Mahmassani (2003) Analyzing heterogeneity and unobserved structural effects in route-switching behavior under ATIS: a dynamic kernel logit formulation, *Transportation Research Part B* 37, pp.793-814.
- Tanaka, T. and M. Tanigawa (2002) Highway Express Bus Location System, Proceedings of 9th World Congress on Intelligent Transport Systems, CD-ROM.
- Wolf, J., R. Guensler and W. Bachman (2002) Elimination of the Travel Diary: An Experiment to Derive Trip Purpose From GPS Travel Data, 80th Transportation Research Board, CD-ROM.

第3章 プローブカーデータ利用技術の開発

3.1 交通行動分析用データへの変換

プローブカーデータが提供する車両走行軌跡は緯度・経度などの座標情報であり、この情報のみでは車両がどの路線を走行しているかを判断することはできない。もちろん、正確な走行ルート情報を用いなくても、ゾーン内で発生する急発進・急加速データの集計や、前章で示したようなゾーン間旅行時間など分析可能な項目は多い。しかし、プローブカーデータの優位性である“時々刻々と変化する交通状況の把握”や、調査対象者の記憶に基づかない“詳細な走行経路に関する情報の取得”などには、走行経路特定作業は必要不可欠である。つまり、プローブカーデータを詳細な交通行動分析用データとして利用するためには、DRM データ上におけるプローブカーの走行位置を特定する作業が必要となる。本節ではこのようなデータ変換方法について説明を行う。

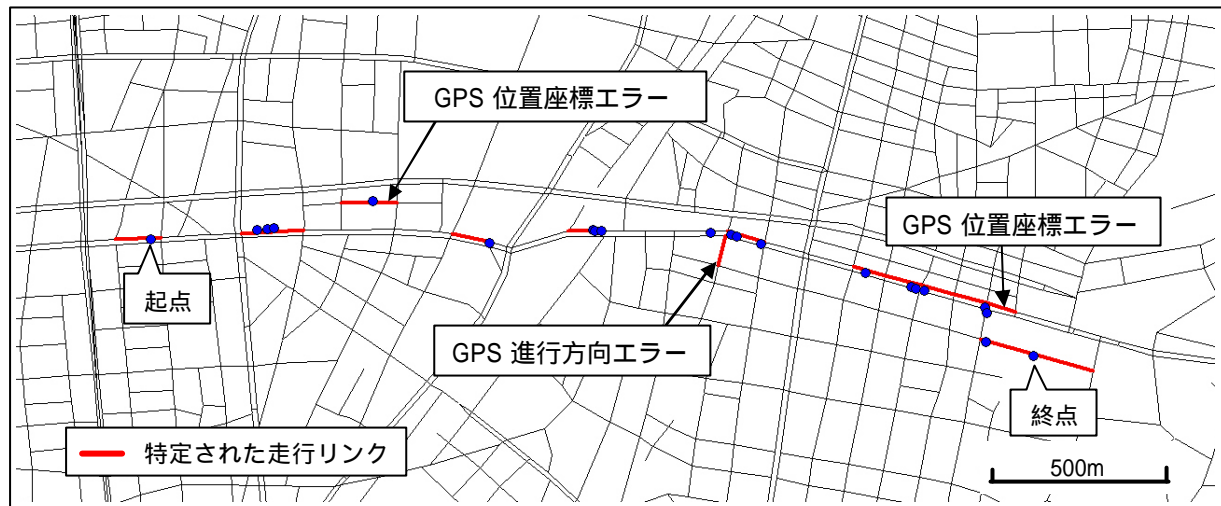
3.1.1 近接リンク法

前章でも述べたが、本研究で使用するプローブカーデータは、センターサーバにデータを蓄積する際に走行路線を特定する作業を行っている。ここで用いられる手法は非常に簡単なものであり、処理に要する時間が非常に少ない反面、問題点も多い。この手法を本研究では“近接リンク法”と呼び、以降にその特徴や問題点を述べる。

近接リンク法は車両の走行経路を特定するわけではない。プローブカーが提供する車両位置座標と進行方向の情報を用いて、DRM リンクの中から最も近いリンクを抽出し、抽出されたリンク上に走行位置を暫定的に特定するものである。しかし、GPS により測定された位置座標は数 m ～ 十数 m 程度の誤差を含み、また進行方向についても必ずしも正確ではないことが知られている（機械システム振興協会，2000）。このため、この手法で特定された走行路線は特定ミスを含むことが多い。図 3-1 は、近接リンク法により特定されたプローブカーの走行路線を示しているが、走行路線の特定ミスが多く発生しており、特定された走行リンクをつなぎ合わせても走行経路とはならないことが容易に分かる。

近接リンク法の利点としては、処理速度が速いことが挙げられる。これは、プローブカーからデータが送信される毎に、その位置座標や進行方向を用いて即座に、かつ各データを独立に扱って走行リンクを特定するため、リアルタイムにデータ処理を行うことが可能である。また、本研究で使用するプローブカー車載機にも含まれるように、車載機にカーナビゲーションシステムが装備されている場合は、車両位置座標が DRM リンク近くに補正されている（ただし、カーナビゲーションシステムで用いられる DRM データに関する情報は公開されておらず、また、必ずしも分析者が使用する DRM データとは同一ではないため、カーナビゲーションシス

テムによる補正によっても，分析者が使用する DRM リンク上にプローブカーの車両位置座標が重なるとは限らない)．このため，カーナビゲーションシステムにより車両位置座標を補正することが可能な場合は，近接リンク法によっても走行路線を比較的正しく特定できる．



(車両 ID1002，トリップ：2002/1/3 13:27:59～13:35:41)

図 3-1 近接リンク法による走行リンクの特定

走行路線が特定されれば，走行経路を特定することが困難であっても主要交差点間旅行時間など，ある一定の距離を持つ主要道路区間の通過旅行時間を算出することは可能である．図 3-2 は，近接リンク法により特定された走行リンク情報を用いる場合の主要道路区間の旅行時間算出方法を示している．プローブカーデータは必ずしも交差点通過時刻を提供しないため，上流側交差点への流入前後のプローブカー位置情報とその時刻，そして下流側交差点への流出前後の位置座標とその時刻を用いて，上流側・下流側交差点通過時刻を算出する必要がある．

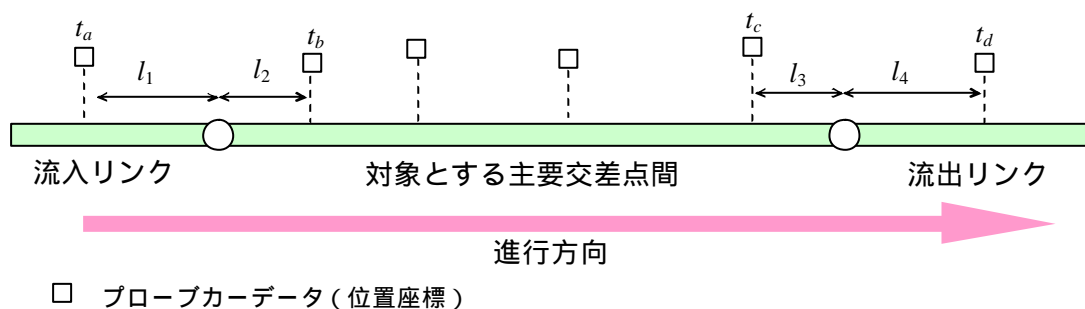


図 3-2 近接リンク法による走行リンクの特定

このとき流入時刻 T_{in} ，流出時刻 T_{out} はそれぞれ以下の式で表される．

$$T_{in} = (t_a * l_2 + t_b * l_1) / (l_1 + l_2) \quad (3.1)$$

$$T_{out} = (t_c * l_4 + t_d * l_3) / (l_3 + l_4) \quad (3.2)$$

ここに、 t_a (t_b) は上流側交差点への流入直前 (直後) のデータ送信時刻、 t_c (t_d) は下流側交差点への流入直前 (直後) のデータ送信時刻、 l_1 (l_2) は t_a (t_b) のデータの上流側交差点までの距離、 l_3 (l_4) は t_c (t_d) のデータの下流側交差点までの距離である。

したがって、対象交差点間の通過旅行時間は式(3.1)、(3.2)の差分として算出できる。

ここで、図 3-3 に名古屋市内の主要交差点間における通過旅行時間の算出例を示す。近接リンク法に用いた DRM データは、(財)デジタル道路地図協会の基本道路網 ver.1200 (平成 12 年 3 月出版) である。この DRM データには、すべての幹線道路 (県道・指定市市道以上) と 5.5m 以上の幅員をもつその他の道路が含まれる。また、旅行時間の変化を交通量の変化と比較するため、トラフィックカウンターデータより集計された時刻別交通量を同時に示す。トラフィックカウンターデータは愛知県警より借用した 2002 年 1 月～3 月のデータであり、5 分間隔の断面交通量 (単一車種) である。ここでは、比較のプロブカーデータの通行回数が多く、また名古屋市中心部の幹線道路である桜通線 (桜通大津交差点～丸の内交差点) を対象とした。この図より、早朝ではプロブカーから得られる旅行時間は若干ばらついているものの、その他の時間帯では交通量の変化に応じて旅行時間が変化していることが見て取れる。

近接リンク法では走行リンク特定ミスが多く発生するものの、比較的長い実験期間にわたってデータ収集を行い、また主要幹線道路の通過旅行時間等であれば比較的精度よく算出することが可能であることを示した。しかし、これは主要道路区間を対象とする場合のみである。次項では、近接リンク法による分析の限界や、より詳細なマップマッチング手法の必要性について述べる。




図 3-3 プロブカーデータより得られる旅行時間

3.1.2 より詳細なマップマッチング手法の必要性

近接リンク法では、都心に位置する幹線道路区間であれば旅行時間情報を比較的多く、また

比較的精度良く収集することが可能である．ここで，対象道路区間が都心部に位置する必要性はプローブカーの通過回数による．近接リンク法により特定された走行リンク情報は，前述のように特定ミスが多く含まれる．対象道路区間通過中に他の区間への特定ミスが発生すると，旅行時間情報を算出することができない．したがって，走行リンク特定ミスの発生を考慮して，十分な走行回数が確保できる道路区間でのみ旅行時間情報を収集できる．また，プローブカーが対象区間を一度に通過する必要がある．これは，対象区間を部分的に通過する車両については，流入（出）時刻を算出できないためである．さらに，近接リンク法の情報からは経路情報を取得することはできない．

以上のような理由により，プローブカーデータを有効に利用するための走行経路特定手法が必要となる．プローブカーが提供する走行軌跡を連続する通過リンクからなる走行経路情報へと変換することができれば，経路上に存在するすべてのリンクについてその通過旅行時間を算出することが可能となる．本研究では，このように改めてプローブカーの走行経路を特定する作業を“マップマッチング”と呼ぶ．ここで，近接リンク法もプローブカーの走行路線を DRM 上に特定する点においてはマップマッチングと呼ぶことができる．したがって本来であれば，近接リンク法もマップマッチング手法の 1 つとして定義し，走行経路を正しく特定する作業は別の名称で呼称されるべきである．しかし，走行経路の特定は交通行動分析において特に重要であり，また呼び名による混乱を避けるため，本研究では“マップマッチング”を“走行経路の特定”と定義する．

図 3-4 にマップマッチング処理により特定された走行経路情報を示す．前項で示した図 3-1 と比較して，トリップ中に通過したすべてのリンクについて正しく特定されていることが分かる．このように，マップマッチングによりプローブカーが走行した経路が把握可能となり，トリップ中に経験した右左折回数や走行距離，幹線道路利用率なども算出可能となる．




図 3-4 マップマッチングによる走行リンクの特定

このような走行経路の特定作業は、交通工学分野以外にもカーナビゲーションに関する研究領域や GIS に関連した研究領域においてもマップマッチングと呼ばれ、これまでも多くの研究が行われてきた。交通工学以外の研究分野におけるマップマッチングは、GPS と一体的に DRM へとリアルタイムに行われることが多く、これらの技術はすでにカーナビゲーションシステムにおいて実用化されている。名古屋実証実験で用いられたプローブカー車載機のうち Type2 車載機は、カーナビゲーションシステムを用いてその位置情報の精度を向上させている。したがって、データ送信時においてカーナビゲーションシステム内では、既にその走行路線や路線上の走行位置は把握されている。しかし、カーナビゲーションシステム内で使用しているデータやシステムに関する情報は一般には公開されておらず、車両が走行する路線についての情報のみならず、使用している電子地図データについてさえ分析者は知ることはできない (White et al., 2000)。このような背景の下、交通工学の分野においてもプローブカーによる実験が行われ始めた当初よりその必要性が高まり、これまでもプローブカーデータを対象としたマップマッチング手法の提案が行われている。これらの詳細は次節で示す。

第 2 章で示したように、情報のリアルタイム性を確保するために既存の通信ネットワークを介して情報を伝達する場合、頻繁な通信は実験費用を高額にしてしまう。このため、名古屋実証実験のようにイベントベースの通信方式を採用するか、もしくは比較的間隔の長い一定時間周期にするなどして通信回数を削減する必要がある。このようにして取得された車両の位置座標は、走行中であれば位置座標間の距離が長くなってしまい、走行経路を特定する際にカーナビゲーションシステム内で行われている手法をそのまま用いることができない。名古屋実証実験で取得されたデータでもその送信位置間の距離は最大で 300m と長く、信号などによる停止が発生しない場合は 300m 間隔で連続したデータが取得されることになる。さらに、走行中に送信エラーが発生すればその間隔は 600m 以上離れてしまうことになる。このように、イベントベースでデータ送信を行うプローブカーの走行軌跡は、走行経路を特定する際のデータ密度の観点からも問題が生じる。また、名古屋都市圏のように都市高速道路の整備された都市においては、一般道路上に立体的に配置された都市高速道路は位置座標が一般道路とほぼ一致しており、プローブカーにより得られる車両位置座標のみからではどちらの路線を走行しているかを判別することが難しい。そこで次節において、本研究で用いるプローブデータからその走行経路を DRM データ上に特定する手法を開発する。

3.2 マップマッチングアルゴリズムの開発

ここでは、本研究で用いるプローブカーデータをマップマッチングするための手法を開発する。そこで、既存のマッチング手法についてレビューすることでそれらの問題点を明確にした後、本研究で適用可能なマップマッチング手法についての検討を行う。

3.2.1 既存のマップマッチングアルゴリズム

前述の通り、マップマッチングとはプローブカーが GPS を用いて取得した車両位置座標を用いて、DRM 上にその走行経路や路線上の車両位置を特定する作業である。一般に GPS は使用者が任意に位置座標取得間隔を設定でき、カーナビゲーションシステムで使用されるマップマッチング手法は 1 秒間隔の位置動態情報を用いてマップマッチングを行っている。さらに、カーナビゲーションシステム内には自立航法システム (Dead Reckoning System) が装備されており、車両の進行角や前輪ホイールの回転速度などを基に、たとえ GPS が位置測位エラーを起こしても車両走行位置を特定し続けることができる (White, 2000; Greenfeld, 2002; Quddus, 2003)。しかし、カーナビゲーション内で適用されているマップマッチング手法や DRM データなどの詳細な情報は外部から閲覧することが難しい。

交通工学の分野で行われるマップマッチングは、プローブカーなどの走行軌跡を求めるために適用されており、リアルタイムな状況下でのマップマッチング手法についてはそれほど行われていない (小島・羽藤, 2004)。これまでに交通工学の分野で開発された代表的なマップマッチング手法には、国土交通省により開発された PROLIMAS (Makimura et al., 2002)、および朝倉らの手法 (朝倉ら, 2000; Asakra and Hato, 2001) がある。ここではそれぞれの目的や使用データ、マッチング手法についてレビューした後、本研究で用いるプローブカーデータへの適用上の問題点を整理する。

a) PROLIMAS

国土交通省により開発されたマップマッチング手法として、PROLIMAS (Probe car Link Matching System) がある。プローブカーとして使用された車両は 20 台のタクシーと 20 台のトラックであり、実験期間は平成 12 年 5 月～平成 13 年 8 月である (「測量」編集委員会・GPS 小委員会編, 2002)。カーナビゲーションシステムに接続した車載システム内にメモリ機能を搭載し、これに車両の 1 秒間隔の時刻や位置座標、走行速度、進行方法を蓄積している。これにより取得されたデータを、DRM 全道路網 (すべての幹線道路と幅員 3.0m 以上のその他の道路) 上に以下の手順によりマップマッチングを行っている。

- <Step 1> プローブカーデータから、車両進行方向に急な変化が生じる間のデータをマップマッチング対象データとして抽出する
- <Step 2> 抽出されたマップマッチング対象データにおいて、進行方向が変化した座標間を直線で結び、これを仮ルートとする
- <Step 3> 仮ルートから半径 30m に含まれる DRM リンクを抽出する
- <Step 4> 抽出されたリンク集合内で最短経路探索 (最短距離経路探索) により走行経路を特定する

Makimura et al. (2002) はこの手法により処理されたプローブカーデータからリンク通過旅行

時間を算出することで、都市圏レベルの走行速度の変化や渋滞損失、燃料消費等を空間的に分析している。ここで、2 分以上の走行停止が発生した場合は、その地点前後でそれぞれマップマッチング処理を行っている。

ただし、この手法では経路特定の際の最短経路は距離によって行われており、都市高速道路のオンランプからオフランプまでの経路と一般道路経路が完全に並行する区間で、かつ、ランプ通過により距離的に遠回りする区間では一般道路に特定されてしまうといった欠点がある。また、使用されたデータは 1 秒間隔で取得されており、本研究で使用するデータのようにデータ送信間隔が最大 300m と長い場合には、30m 範囲のリンク集合からは正確な車両軌跡が特定できない。さらには、この手法ではタクシーをプローブカーとしていながら、実車時と空車時の区別をしていない。これは、データ取得間隔が 1 秒と短く、また <Step 1> において進行方向が大きく変化する地点を抽出することで、走行経路を部分的にマップマッチングしているためである。空車時のタクシーは明確な目的地を持たず、乗客を探しながら走行する、いわゆる“ながし”走行を行い、同一地点を比較的短い時間に何度も走行する場合は発生する。数十秒や数百メートル間隔のデータ取得からは何度も通過する地点に多くの位置座標が発生し、特定された経路が実際の走行経路とは異なる場合は発生してしまうことも、本研究で使用するプローブカーデータに用いる場合の問題の 1 つとして挙げられる。

b) 朝倉ら (2000) の方法

朝倉ら (2000) は PHS による位置座標特定システムを利用して、2 分間隔でデータ取得を行っている。このシステムにより個人の位置座標情報やデータ取得時刻を収集し、センター側システムに蓄積される。実験期間は 1998 年 11 月 3 日～16 日の 14 日間であり、10 名の被験者により収集された。朝倉らはこのデータより対象個人のトリップデータを抽出し、その利用経路の特定を試みている。マップマッチングに関する基本的な手順は以下の通り。

<Step 1> トリップデータを抽出する

<Step 2> 各データ送信位置から一定距離 (閾値 D) に含まれるリンクを抽出する

<Step 3> 抽出されたリンク集合内において、起点・終点間で最短経路探索を行う

<Step 4> Screening 法により複数の経路を抽出し、個人の位置座標と経路との距離が許容範囲内にある経路のうち、OD 間の距離が最短となる経路を利用経路として特定する

ここで、Screening 法とは OD 間においてコストの小さい順に経路を列挙する方法である (D'Este, 1997; 大草ら, 1999)。この方法では、 $k+1$ 番目の経路を探索する際に k 番目経路から逸れるリンクに着目し、逸れたリンクから終点までをつなぎ合わせることで $k+1$ 番目経路を探索する。また、位置座標と経路のずれは式(3.3)で表される。

$$\sum_i^I d_i / I \quad (3.3)$$

ここに、 d_i は位置座標と経路の距離、 I は位置座標数である。

朝倉らの研究では、利用経路を特定するとともに個人の1日の活動データを取得することを目的としている。論文内においては特に滞在位置や滞在時間の特定に焦点が当てられており、経路特定精度については十分な検証を行っていない。しかし、データ取得間隔が長いという点においては本研究で用いるデータと共通しており、また候補となる経路集合を複数探索した後尤もらしい経路を利用経路として特定する考え方は、都市高速道路と一般道路が立体的に並行する場合にも適用可能であると考えられる。ただし、立体的に並行する路線からどちらかを走行路線として特定する際には、位置座標のみを用いるのではなく何らかの修正が必要である。また、朝倉らは <Step 2> で用いられた閾値 D を小さく設定するとトリップを結ぶ経路が抽出されなくなり、大きく設定すると特定精度が下がるため、滞在地点特定方法（連続する位置座標が D 以内であれば、“滞在”と見なす）とも整合する値を設定する必要があると述べている。したがって、閾値 D の設定方法についても、何らかの修正が必要であると考えられる。

3.2.2 アルゴリズムの開発と精度検証

a) アルゴリズムの開発

ここでは、名古屋実証実験で収集されたデータをマップマッチングするための手法についての検討を行う。そこで、名古屋実証実験でのプローブカーデータをマップマッチングする際に問題となる点を以下にまとめる。

- ・データ送信間隔が最大で 300m と長い
- ・都市高速道路と一般道路が立体的に配置された区間が主要区間を形成している（図 3-5）
- ・走行経路は必ずしも距離的に最短であるとは限らない。例えばループ状の都市高速ランプや一般道路についても距離的に遠回りする経路を走行する場合がある

本研究では、マップマッチング後のデータを経路選択行動分析用データとしても使用することを前提としているため、実車中のデータを極力分割せずに処理することを念頭に置く。しかし、トリップ中に5分以上の走行停止が発生した場合は、そこで何らかの目的を果たしたと見なしてトリップを分割した。また、マップマッチングに使用した DRM データは、都市高速道路（名古屋高速道路2号東山線）の延伸に対応するため、前章とは異なり（財）日本デジタル地図協会出版の DRM 基本道路網 ver.1500（平成15年3月出版）を用いた。



図 3-5 名古屋高速道路と国道 41 号の立体配置区間

本研究では、これらの特徴を持つデータを対象とした場合のマップマッチング手法として、朝倉らのマッチング手法を基本とし、これを立体路線区間に対応可能な手法へと改良する。これは、Screening 法を用いることで複数の探索経路を対象とするためより車両走行軌跡に近い経路を特定でき、またデータ送信間隔が長い場合も適用しやすいためである。


複数経路を探索する手法は、Screening 法以外にも幾つか提案されている。各リンクとそこへ流入するリンクの組み合わせを考慮して最短経路以外の経路を探索する手法（杉本・加藤，1985；大西・加藤，1992）や、遺伝的アルゴリズムを用いて複数経路を探索する手法（稲垣ら，1999；井上，2001）が提案されている。経路探索手法として現在最もよく用いられ、また最も効率的である手法は Dijkstra 法（ラベル確定法）である（土木学会，1998）。この手法は計算速度が速く、大規模で複雑なネットワーク上でも高速度で最短経路の探索が可能である。しかし、最短経路のみが抽出され、それ以外の経路については抽出されない。各リンクとその流入リンクの組み合わせを用いる方法では、膨大なネットワークを対象とする本研究では、計算に必要なメモリ容量が足りなくなる恐れがある。また、遺伝的アルゴリズムを用いる方法は、計算時間が長くなり膨大なトリップを扱うことは困難である。Screening 法は Dijkstra 法により探索された最短経路から分岐するリンクと終点ノードをつなぐ手法であるが、Dijkstra 法の特性により（起点ノードを探索開始ノードとした場合）起点からすべてのノードへの最短コストと最短経路を記憶することが可能である。したがって、終点ノードを探索開始ノードとして進行方向とは逆向きに探索計算を行えば、起点から終点までの最短経路とともに、すべてのノードから終点までの最短経路が算出できる。したがって、Screening 法では Dijkstra 法による探索計算は 1 度だけであり、その後は既に計算されたすべてのノードから終点までの最短経路情報を組み合

わせることで複数経路を探索することができる。


このとき、本研究で提案するマップマッチングアルゴリズムの基本手順は以下のようになる。

- <Step 1> トリップデータ（乗客が乗車してから降車するまでのデータ）を抽出する
- <Step 2> 抽出した車両位置座標について、位置座標と前後遠いほうの位置座標間の距離を半径とする円に含まれるリンクを抽出し、対象リンク集合とする
- <Step 3> 対象リンク集合内で経路探索を行う
- <Step 4> 探索された経路に対して Screening 法を行い、複数経路を抽出する
- <Step 5> 最も位置座標に近い経路を利用経路として特定する


図 3-6 は、ここで示したマップマッチングの基本的な流れを示している。<Step5> の経路特定指標は朝倉らと同様に式(3.3)で表され、特定される経路は式(3.3)により算出される値が最も小さい経路としている。また、<Step2> において抽出範囲を前後車両位置座標間隔により変更している。これは、サブネットワークとして抽出されるリンク数を減らすことで計算負荷を軽減するためである。また、都市高速道路の高架下では頻繁に位置測位エラーが起き、データ取得間隔が広がる。このような場合は、前後の位置座標の midpoint を仮位置座標として補間している。



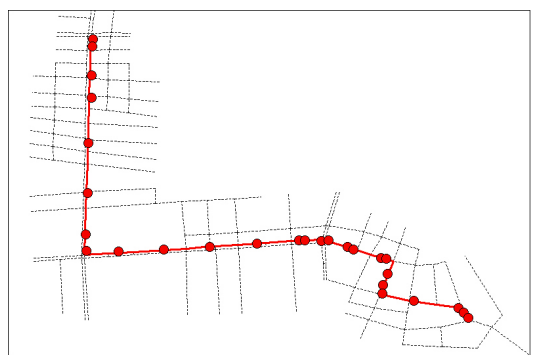
<Step 1> トリップデータの抽出



<Step 2> 対象リンク集合の抽出



<Step 3> 経路探索



<Step 4> Screening 法による経路抽出

<Step 5> 走行経路の特定

図 3-6 マップマッチングの基本的な流れ

また，<Step3> と <Step4> で用いるリンクコストは，マップマッチング精度の変化を分析するため，車両位置座標，リンク長，走行速度について，以下のように 3 通りの組み合わせにより設定した．

リンクコスト ：リンク長

$$\text{探索経路} = \min \sum_i \text{link}_i \quad (3.4)$$

ここに， link_i はリンク i のリンク長である．

リンクコスト ：リンク長 × 位置座標距離

$$\text{探索経路} = \min \sum_i (\text{link}_i \times \bar{d}_i) \quad (3.5)$$

ここに， \bar{d}_i はリンク i から最も近い車両位置座標までの距離とする．

リンクコスト ：リンク長 × 位置座標距離 × 速度ウェイト

$$\text{探索経路} = \min \sum_i (\text{link}_i \times \bar{d}_i \times w_i) \quad (3.6)$$

ここに， w_i は速度ウェイトとする．

リンクコスト を用いる場合は通常の最短経路探索と同じであり，朝倉らの手法とほぼ同様の探索手法となる．リンクコスト の \bar{d}_i は各リンクから最も近い車両位置座標までの距離であり，車両位置座標から垂線が引けないリンクについては車両位置座標に近いノードまでの距離としている．リンクコスト の速度ウェイトは，表 3-1 に示す立体区間の各路線（名古屋都市高速道路 1 号楠線，国道 41 号）の時間帯別走行速度（データ送信時における走行速度）を基に，trial-and-error により最もマッチング精度が高くなる値に定めた．

表 3-1 に示された各道路区間の走行速度は，立体区間を通過したプローブカーデータを抽出し，目視によりどちらの道路区間を走行しているかを特定した上で作成している．これにより，16～18 時台で名古屋駅 名古屋空港方向の名古屋高速道路で速度低下が見られる．また，名古屋高速道路上の走行速度の変化は一般道路と比較して大きく，特に夕方のピーク時には大きく低下する．このため表 3-2 に示すように，設定した速度ウェイト w_i は夕方のピーク時とその他の時間帯や，またプローブカーの走行速度を考慮して高速道路リンクのコストを増減するように設定された．

表 3-1 名古屋高速道路と国道 41 号における走行速度の変化

道路種別	トリップの方向	指標	6時	7時	8時	9時	10時	11時	12時	13時	14時	15時	16時	17時	18時	19時	20時	21時	22時	総計
名古屋高速道路	名古屋駅 空港	平均速度 (km)	71.2	72.3	72.4	79.7	78.0	75.0	75.0	76.0	78.0	75.7	59.3	61.0	55.0	80.0	0.0	0.0	0.0	72.2
		最高速度 (km)	75	83	82	89	78	75	80	83	78	80	64	61	55	80	0	0	0	89
		最低速度 (km)	68	66	66	67	78	75	71	69	78	72	52	61	55	80	0	0	0	52
		サンプル数	5	12	11	3	1	1	6	2	1	3	4	1	1	1	0	0	0	52
	空港 名古屋駅	平均速度 (km)	0.0	0.0	64.0	76.0	0.0	72.0	0.0	73.0	72.5	74.0	0.0	78.5	72.5	77.5	74.7	80.6	0.0	75.9
		最高速度 (km)	0	0	64	86	0	72	0	75	87	83	0	100	86	83	89	97	0	100
		最低速度 (km)	0	0	64	66	0	72	0	72	58	66	0	64	66	69	65	69	0	58
		サンプル数	0	0	1	2	0	2	0	3	2	4	0	4	4	4	6	10	0	42
	R 41 号	平均速度 (km)	51.1	33.7	36.3	12.3	20.6	8.0	22.9	35.3	24.2	11.3	9.5	0.0	9.5	0.0	0.0	45.0	0.0	31.6
		最高速度 (km)	72	58	58	14	44	8	30	61	25	11	10	0	10	0	0	45	0	72
		最低速度 (km)	13	11	7	11	8	8	16	20	24	11	10	0	10	0	0	45	0	7
		サンプル数	8	7	8	2	5	1	5	5	2	1	1	0	1	0	0	1	0	47
R 41 号	名古屋駅 空港	平均速度 (km)	0.0	0.0	11.0	0.0	0.0	52.3	53.0	56.5	54.8	49.0	36.0	45.8	47.0	56.0	57.8	49.3	64.0	51.9
		最高速度 (km)	0	0	11	0	0	58	53	58	58	50	36	52	47	61	75	62	64	75
		最低速度 (km)	0	0	11	0	0	47	53	55	51	47	36	36	47	52	27	12	64	11
		サンプル数	0	0	1	0	0	3	1	2	4	3	1	5	1	4	12	9	1	47
	空港 名古屋駅	平均速度 (km)	0.0	0.0	11.0	0.0	0.0	52.3	53.0	56.5	54.8	49.0	36.0	45.8	47.0	56.0	57.8	49.3	64.0	51.9
		最高速度 (km)	0	0	11	0	0	58	53	58	58	50	36	52	47	61	75	62	64	75
		最低速度 (km)	0	0	11	0	0	47	53	55	51	47	36	36	47	52	27	12	64	11
		サンプル数	0	0	1	0	0	3	1	2	4	3	1	5	1	4	12	9	1	47

表 3-2 設定した速度ウェイト w_i

タピーク時間帯 (16:00 ~ 19:00)

対応するプローブカーの走行速度が 50km 以上の下り方向，都心環状高速道路リンク	0.1
対応するプローブカーの走行速度が 30km 未満の高速道路リンク	10.0
その他	1.0

それ以外の時間帯

対応するプローブカーの走行速度が 80km 以上の高速道路リンク	0.1
対応するプローブカーの走行速度が 60km 未満の高速道路リンク	10.0
その他	1.0

b) マッチング精度の検証

ここでは，リンクコスト c を用いた場合のマッチング精度について，以下に示す 2 式で算出される指標を用いて検証を行う．

$$\text{リンク正解率 (\%)} = \{ \text{マッチング結果の正解リンク数} / \text{現実経路リンク数} \} \times 100 \quad (3.7)$$

$$\text{距離正解率 (\%)} = \{ \text{マッチング結果の正解リンク距離} / \text{現実経路距離} \} \times 100 \quad (3.8)$$

精度検証のための現実経路は，対象 OD ペアにおける任意の 200 トリップについて，それぞれ手作業により利用経路として尤もらしいと思われるリンク列を作成している．リンクコスト c を用いた場合の走行経路特定精度を表 3-3 に示す．この結果から，リンク長のみをコス

トとした手法と比較して、車両位置座標からの距離をリンクコストに組み込んだ場合の方が走行経路の特定精度が30%程度高くなり、さらに混雑時の速度低下を考慮してリンクウェイトを導入した場合のほうがさらに10%以上高くなることが分かる。ここで、リンクコストではリンク正解率の方が距離正解率よりも高いのに対して、リンクコストでは距離正解率の方が高くなっている。これは、ここでの分析が名古屋空港と名古屋駅間のトリップを対象としており、名古屋高速道路を利用するトリップが多く含まれるためである。名古屋高速道路を構成するリンクは1つのリンク長が一般道路リンクよりも長いいため、リンクコストを用いることにより、高速利用トリップが適切に高速道路経路にマッチングされ、リンク正解率の向上率よりも距離正解率の向上が大きくなっているものと考えられる。なお、ここで検証の対象としたODペアは都市高速道路の立体区間をもち、また利用可能経路集合も多いため、対象エリア内でも最も走行経路特定が困難なODペアである。従って、その他のODペアにおいては、より特定精度が高くなると考えられる。

表 3-3 リンクコスト別マッチング精度

	リンクコスト	リンクコスト	リンクコスト
リンク正解率	53.0%	80.3%	92.5%
距離正解率	47.2%	84.0%	94.2%

ここで示した手法のマッチング精度が100%に達しない理由には、以下の原因が挙げられる。

- ・ 曲り角付近でデータ送信がなく、車両がどこで曲がったかの判別が難しい場合
- ・ 車両が幅員 5.5m 未満の細街路を走行した場合
- ・ 高速道路上で、車両が完全に停止するような渋滞が発生した場合

これらの問題は、仮に目視によりデータをチェックしても、プローブカーがどの経路を走行したかを特定することが難しい。このため、このような問題を解決するためには以下のようなハード的な変更についても検討すべきである。

- ・ 方向指示器作動時をデータ送信トリガとする
- ・ 全道路網上でマッチングを行う
- ・ 高速道路走行中フラグをデータに追加する

3.3 データ蓄積方法の提案

3.3.1 マップマッチング処理の概要

前節ではプローブカーデータのマップマッチング手法を提案し、データ送信間隔が長い場合でも比較的高精度にマップマッチングが可能であることを示した。マップマッチング処理によ

り，それまでは車両位置座標の連続データであったプローブカーデータを，走行経路データおよび経路上の車両走行位置情報へと変換することが可能となる．ここで，車両走行位置情報は，特定された経路上に各車両位置座標から垂線を引くことで特定可能となる．本研究で作成したマップマッチングシステムでは，車両走行位置特定作業に合わせて 3.1.1 における近接リンク法でのリンク旅行時間算出方法として示した式(3.1)，(3.2)と同様の方法により，特定された走行経路上にあるすべてのリンクについて流入時刻および流出時刻を算出し，各リンク旅行時間を出力している．

マップマッチング処理後に出力されるデータフォーマットを表 3-4 に示す．出力データには，経路データとトリップデータがあり，前者は主に走行経路やリンク通過旅行時間情報を，後者は主に車両 ID 番号やトリップ開始・終了時刻についての情報が含まれる．分析にその他の情報が必要な場合は，車両 ID 番号，プロット時刻を用いてマップマッチング処理前のデータを参照することで取得可能である．

表 3-4a マッチング処理後のプローブカーデータ（経路データ）

トリップ SQno.	構成 リンク数	node1	node2	方向 *1	リンク 長(m)	路線情 報*2	通過旅行 時間 (sec)	送信 回数	送信時刻 (× 送信回数)	
1	58	4700304	4700409	0	63	9000	12.86	3	20020121040806	...
1	58	4700361	4700409	1	105	5050	25.43	0		
1	58	4700361	4700562	0	62	5050	10.11	1	20020121040847	
...										

*1 方向=0 のとき node1 → node2 に通過，方向=1 の時 node2 → node1 に通過 *2 道路種別番号 × 1000+路線番号

表 3-4b マッチング処理後のプローブカーデータ（トリップデータ）

トリップ SQno.	車両 ID 番号	出発時刻	到着時刻
1	1025	20020121040806	20020121042501
2	1032	20020201220239	20020201221505
...			

表 3-5 に，全実験期間中（9 ヶ月間）に観測されたトリップ数を車載機タイプ別に示す．Type2 車載機を搭載したプローブカーから収集されたトリップは約 341 万トリップであるのに対し，Type1 および Type3 車載機を搭載した車両から収集されたトリップは約 256 万トリップであった．ここで，Type1,3 車載機を搭載した車両台数（915 台）は，Type2 車載機を搭載した車両数（655 台）より多いにもかかわらず，観測されたトリップ数が少なくなっている．これは，トリップの集計に際して，実車フラグにより乗客が乗車中である情報が得られる場合であっても，

途中連続して4プロット以上のデータ異常の発生により車両位置情報が欠損している場合はそこでトリップを分割していることや、また5プロット以上連続して実車フラグが観測されなければマップマッチングの対象としなかったためである。第2章でも示したように、Type1,3車載機からは位置測位エラーが多く発生しているため、トリップ数が少なく観測される結果になっている。

表 3-5 実験期間（9ヶ月間）に観測されたトリップ数

車載機 Type	観測トリップ数
Type1, 3	2,558,135
Type2	3,412,952

このような非常に多くのトリップに対してマップマッチング処理を行うためには、効率よく処理する必要がある。このため本研究では、第3回PT調査小ゾーンを用い、図3-7に示すフローに沿ってマッチング処理を行っている。

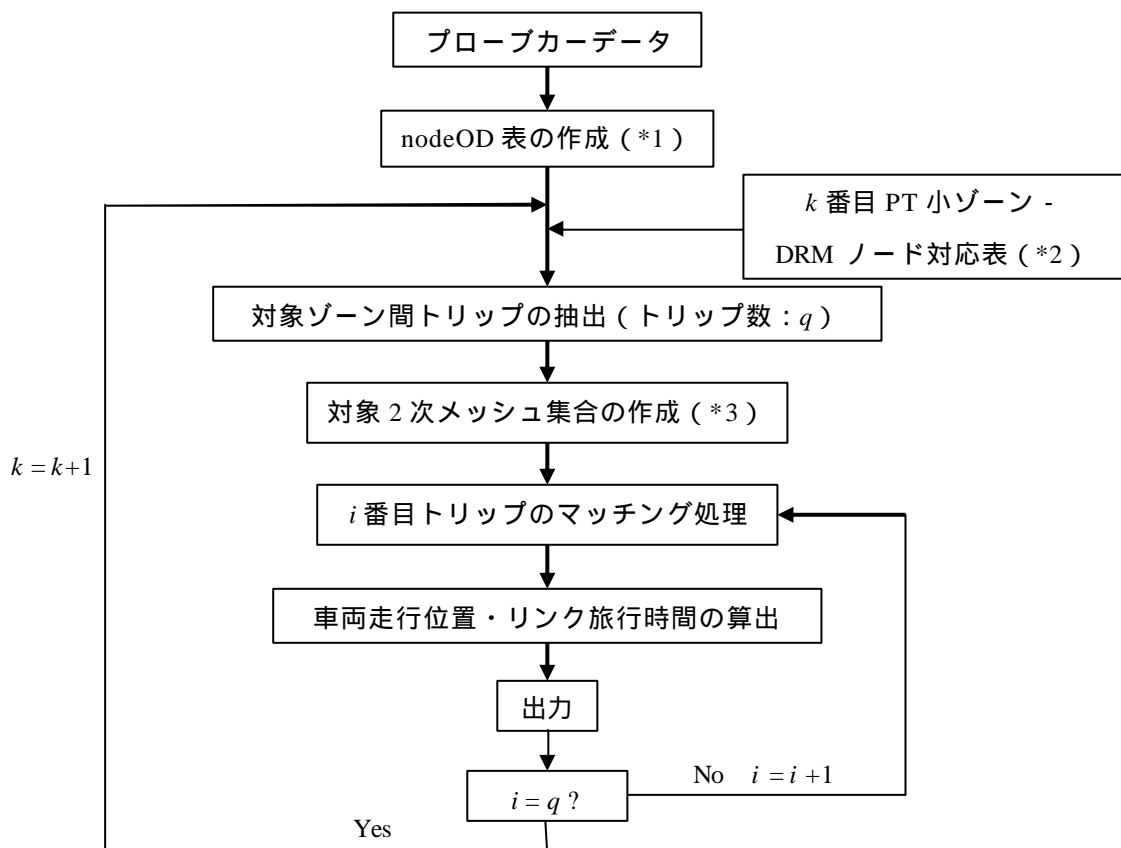


図 3-7 マップマッチング処理フロー

ここで nodeOD 表（図中*1）とは，プローブデータより観測されたトリップについて，その起点，終点を DRM ノードで表現するデータベースである．この際，トリップの起点座標および終点座標に最も近いノード番号を，便宜的に起点ノードおよび終点ノードとしている．このノード番号はマップマッチング処理を効率的に行うために用いられ，実際の走行ルートの起終点ノードとは必ずしも一致しない．nodeOD 表にはこれら以外にも，プローブカーの車両 ID やトリップの出発，到着時刻，プロット数，トリップが通過する 2 次メッシュ番号等が情報として蓄積されている．また，PT 小ゾーン - DRM ノード対応表（図中*2）は，各 PT 小ゾーン内に位置する DRM ノードを集計したものであり，これを用いて nodeOD 表に含まれるトリップが，どの小ゾーン間のトリップであるかを確認することが可能となる．対象 2 次メッシュ集合（図中*3）は，マップマッチング対象となるサブネットワーク作成を効率的に行うために作成されるものであり，対象ゾーン間トリップで出現するすべての 2 次メッシュ番号（オンラインによる近接リンク法により付加された情報）を集計しリストアップするものである．この処理フローにより，観測されたすべてのトリップの内，同じような起終点を持つトリップごとに処理を行っていくことが可能となる．同じような起終点を持つトリップは利用するリンク集合が重なり合っているため，マップマッチング処理に必要なリンク集合を抽出する作業に要する時間を短縮することができ，全体としての処理速度を向上させることが可能となる．

Makimura et al. (2002) では PROLIMAS の処理速度について，1 ヶ月分のデータを 4 枚の 2 次メッシュ（リンク数：84,946）を対象とし，4 台の PC（CPU：Pentium ，メモリ 512MB）を使用して約 1 週間要するとある．本研究では，図 3-8 に示す 24 枚の 2 次メッシュ（往復合計リンク数：149,042（片方向リンク数：83,159），ノード数：57,827）を対象とし，3 台の PC（CPU：Pentium 3.2GHz，メモリ 2GB）を用いてマップマッチング処理に要した時間はおおよそ 3 ヶ月であった．ただし，PROLIMAS では 40 台のプローブカーの内タクシーとトラックがそれぞれ 20 台であり，タクシーに対しては，実車と空車の区別なく処理している．また Makimura et al. (2002) では，タクシーは 1 日に約 300km 走行し，トラックは約 40km 走行するとある．仮に 40 台すべてがタクシーとし，実車時と空車時の走行距離の割合が同じとした時，プローブカーを 655 台，実験期間を 9 ヶ月に拡大すると，実車データのみを処理するために必要な期間は約 74 週間となる．一方，本研究で開発したシステムでは，655 台・9 ヶ月のタクシーについて実車データのみを処理に約 12 週間で要したことから，使用した PC の能力を割り引いても，本研究で開発したシステムの処理効率はかなり高いものであることが分かる．

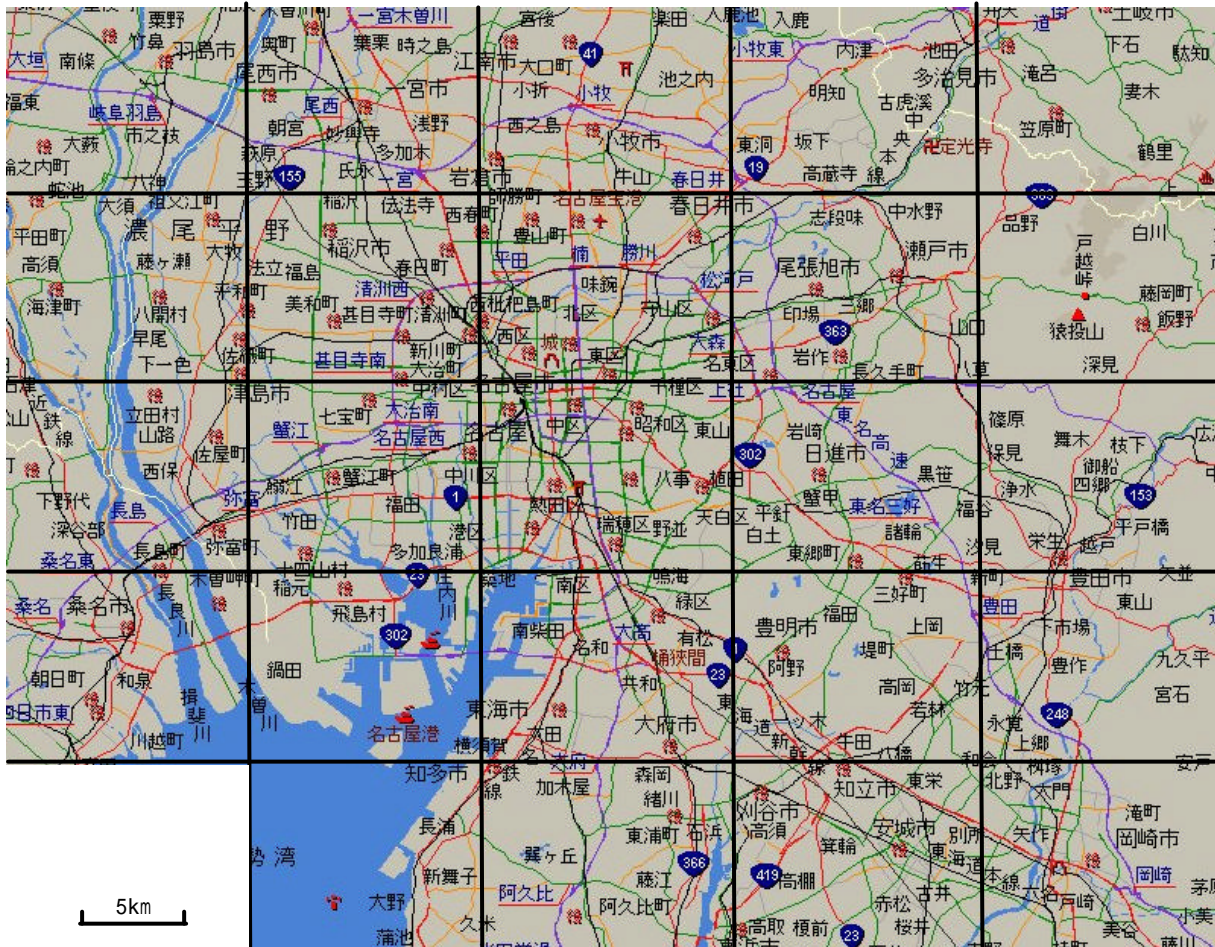


図 3-8 マップマッチング対象エリア

2002 年 11 月に Type2 車載機を搭載したプローブカーにより収集されたデータのうち、実車中のデータについて、近接リンク法を用いた場合の各リンクの通過回数とマップマッチング処理による通過回数を集計した。図 3-9 に名古屋市周辺での通過回数を示す。ここで、近接リンク法による処理後のデータからは、1 回以上連続して同じリンクが特定された場合に 1 回の通過として集計した。また、マップマッチング処理後のデータからは、各リンクが期間中に発生したトリップによる通行回数が集計されている。

図より、マップマッチング後のデータからは各リンクの通過回数が連続的に集計されているのに対して、近接リンク法によるデータの通過回数は郊外部で断続的に観測されていることが分かる。これ以外にも、3.1 で示したように近接リンク法を用いる場合は、対象区間のみならず流入・流出リンク上での観測が必要であり、実際には図に示すほどのリンク旅行時間情報を取得することは不可能である。このことから、マップマッチング処理により、プローブカーデータを有効に利用することが可能となるといえる。




図 3-9a 近接リンク法による観測通過回数




図 3-9b マップマッチングデータによる観測通過回数

3.3.2 データ蓄積方法

ここでは、マップマッチング処理後のプローブカーデータの蓄積方法について提案を行う。表 3-5 に示したように、マップマッチング処理されたプローブカーデータには経路データとトリップデータがある。これらのファイルは、PT 調査小ゾーンペアの内トリップが確認されたゾーンペアごとに出力されており、ファイル数、データサイズは表 3-6 に示すとおりである。

表 3-6 マップマッチング処理後のプローブカーデータの概要

実験期間	トリップデータ		経路データ	
	ファイル数	データサイズ	ファイル数	データサイズ
第 1 期 (3 ヶ月)	41,463	64.5MB	41,463	2.43GB
第 2 期 (6 ヶ月)	51,817	126MB	51,817	5.18GB

これらのデータは、このままの状態でもドライバーが選択した経路についての情報であり、経路選択行動分析には有用なデータ形式である。しかし、交通状況の変化など断面交通データとして用いるためには、リンク単位に通過回数や時刻別平均旅行時間などを集計し直す必要がある。膨大なデータを集計するには多くの時間が必要であり、4 章で説明する旅行時間予測や、5 章で説明する経路選択行動分析における、任意の経路の旅行時間を算出するためのデータベースとして用いるには、より適切なデータ形式により蓄積する必要がある。そこで本研究では、表 3-7 に示すようなデータ形式に集計し直すことで断面交通データとして蓄積する。この蓄積データベースを、以降“リンクコストテーブル”と呼ぶ。この蓄積方法は、マップマッチング処理後のプローブカーデータを蓄積する方法の 1 つの考え方である。

表 3-7 断面交通データとしての蓄積データベースイメージ（リンクコストテーブル）

2 次メッシュ No.	node1	node2	道路種別	リンク長 (m)	交通規制コード *1	リンク方向	時間帯 1 *2 (0:00 0:05)		時間帯 2 (0:05 0:10)		...
							通過回数	平均旅行時間 (sec)	通過回数	平均旅行時間 (sec)	
523657	29001	29025	9	17	0	0	101	4.45	81	3.32	...
523657	29001	29025	7	112	0	1	18	7.58	4	6.82	...
523657	29003	29012	4	200	4	0	98	12.58	48	11.44	...
523657	29006	29028	3	136	5	0	42	8.22	21	8.08	...
...											
523667	14001	14013	4	68	0	0	9	20.39	12	23.11	...

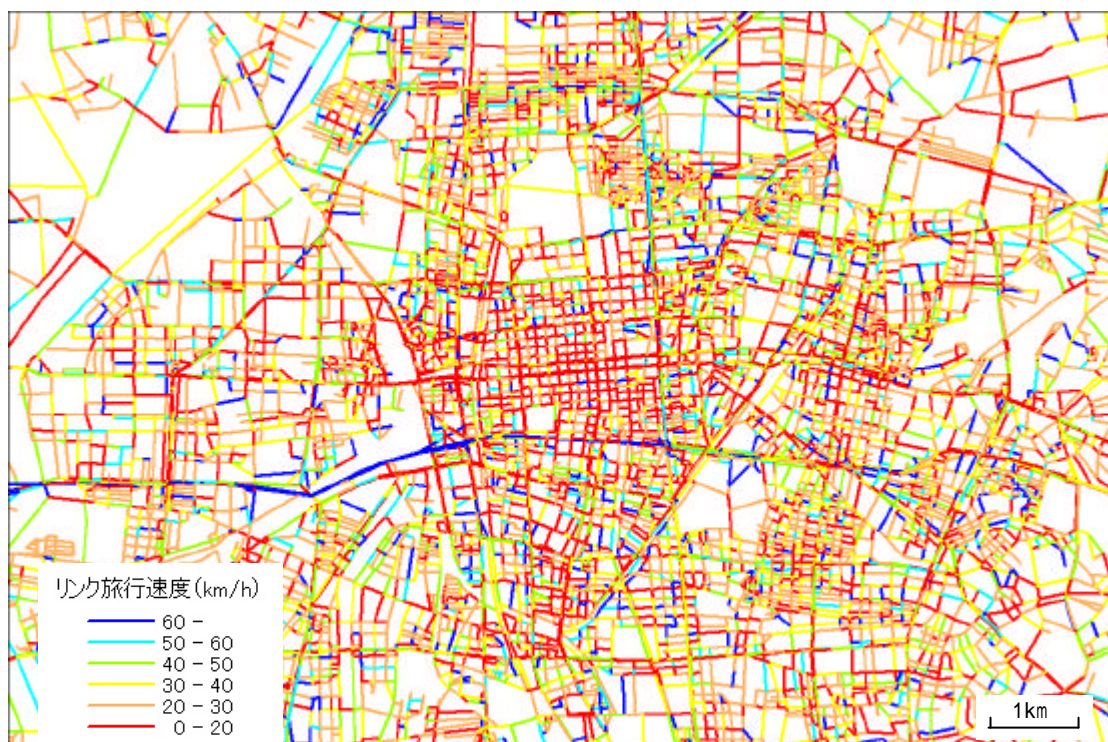
*1 規制種別コードとは、リンクの通行規制情報（一方通行情報など）を示す

*2 時間帯は 1 日を 5 分間隔に分割し、時間帯 1～時間帯 288 まで設定した


ここで、リンクコストテーブルは各リンクの 5 分間隔平均旅行時間情報を蓄積しており、観測されたプローブカーの通過回数や通過旅行時間の分散値(表 3-7 には示していない)を含む。テーブルの種類は、曜日別(月、火、・・・、日&祝)、天候別(降水量 1mm 以上、未満)として 14 種類を作成した。

蓄積データベースは、対象エリア内の断面交通データとして利用可能である。2.1.1 でも述べたように、道路交通センサスやトラフィックカウンターデータなど従来の断面データは幹線道路のみを対象とし、ごく限られた地点でのみデータ収集を行っている。ここで、これら従来データでは幹線道路網を均質な区間(主要交差点間など均質であると考えられる区間)に分割し、各区間上の代表地点のみにおいてデータ収集を行っている。したがって幹線道路網上のほぼすべての区間で交通量や通過旅行速度などの断面交通データが得られるが、すべてを網羅的に観測しているわけではない。これに対してプローブカーデータは各断面の観測回数は従来データより少ないものの、広いエリアでの旅行時間情報を利用することが可能となる。図 3-9b にも示したように、プローブカーを用いることで対象エリア内のほぼすべての交通情報を取得可能であることが分かる。ただし、断面データとは異なり時間的に連続しておらず、また非常に稀にしかプローブカーが通過しないリンクにおいては観測データ数が少なくなるといった問題点もある。もちろん実験を長く行えば、交通量の少ない郊外のリンクにおいてもある程度の通過回数を得られ、比較的安定した旅行時間情報を得ることは可能である。

ここで、前節で作成した蓄積データベースを基に、マップマッチング処理されたプローブカーデータが断面交通データとして利用可能であることを示す。図 3-10 は、名古屋市中北部における各リンクの通過旅行時間を示している。ここで、晴天時・金曜日のリンクコストテーブルから 18:00～18:05、0:00～0:05 のカラムを使用した。もちろんすべてのリンクにおいて、この時間帯にプローブカーの通過が観測されるわけではないため、欠損データについては隣接する時間帯から旅行時間データを補間している。この図から、夕方のピーク時間帯である 18:00 では旅行速度が低く、また深夜 0:00 では高くなっている様子が見て取れ、交通混雑が時刻によって変化している状況が把握できる。このように、任意の時刻、任意のリンクにおける交通状況の変化に関する情報を、蓄積データから取得することが可能であることが分かる。



金曜日，晴天時，18:00 のリンク旅行速度



金曜日，晴天時，0:00 のリンク旅行速度

図 3-10 蓄積データによる旅行時間変化情報

3.4 本章のまとめ

本章では、プローブカーの車両位置座標と DRM の近接リンク情報のみを用いる近接リンク法によるデータ利用上の非効率性を問題意識として、さらに走行速度とトリップの起終点情報を用いることで走行経路を精度良く特定するマップマッチング手法を開発した。そして、マップマッチング処理により出力されたプローブカーデータの交通データとしての蓄積方法を提案した。

プローブカーデータは車両の走行軌跡や、データ送信時の走行速度や加速度、ワイパー作動状況などの情報を有しており、これだけでも有用な分析が可能である。前章で示したように、ゾーン間の旅行時間情報を収集することが可能であるし、例えば、路線バスや走行路線が決められた試験車両などをプローブカーとする場合には走行経路を特定する必要はなく、また走行位置は車両位置座標から走行経路に垂線を引くことで確認することができる。しかしこのような場合は、プローブカーの利点であるより広範囲にわたるエリアでのデータ収集や、ドライバーの経路選択データの収集が行えないばかりか、利用可能なデータ量自体も少なくなってしまう。本研究で使用するプローブカーデータのように、日常的なトリップを繰り返すタクシーや、もしくはトラックや商用車をプローブカーとした方が多くの面で効率的であり、この場合はプローブカーの走行軌跡を特定するためのマップマッチング処理が必要となる。

これまでに、多くのマップマッチング手法がカーナビゲーションや GIS の分野で研究されているが、これらはいずれも車載機内に適用されるものであり、車両位置情報も 1 秒間隔のデータを利用することが多い。しかし、交通工学の分野で用いられるプローブカーデータはカーナビゲーション内で使用しているデータ情報を付加することが難しい上、通信コストや収集データ量の点で頻繁なデータ送信が行えない場合が多く、これによりデータ送信間隔が長くなるといった問題もある。提案した手法は、送信エラーや GPS エラーによりデータ送信間隔が 1km 程度まで広がっても、走行経路を特定することができる。また、走行速度情報を用いた速度ウェイトをリンクコストとして導入することや、Screening 法により特定される走行経路を修正することで、走行経路特定が困難な道路区間を有する OD ペアにおいても 94% 程度の経路特定精度があることを示した。さらに、提案する手法では完全に正確な経路を特定できない理由について考察し、高速道路走行フラグや右左折フラグなど車載機側のハード的な改良の必要性を論じた。また、提案したマップマッチング手法のデータ処理速度はこれまでに提案された手法と比較しても十分な処理速度を有しており、膨大なプローブカーデータに対しても十分実用的なシステムとして利用することができる。またこれにより、交通状況の変化に関する情報やドライバーの経路選択行動の分析用データを作成することが可能である。このように、マップマッチング処理を行うことで、プローブカーデータを有効に活用することができる。本研究では交通行動分析を対象とするため行わないが、急加速・急減速情報を用いて道路ネットワーク上の危険箇所を抽出したり、交通渋滞発生要因の分析や交通渋滞による経済的な損失額の計測を行

うことも可能となり，すでにこのような取り組みも行われつつある（Ueta, 2003）．

しかし，本研究で開発したマップマッチング手法において用いられる速度ウェイト w_i は，trial-and-error により定められた ad hoc な値であり，より整合性の高いウェイト値の検証が必要である．さらに，本研究で提案したマップマッチング手法はセンターサーバに蓄積されたデータを用いることを前提としており，トリップの起終点情報が与件の場合にのみ適用可能である．しかし，近接リンク法がデータをセンターサーバへの蓄積と同時に行われているように，オンラインによる走行経路特定手法は，より多くのデータ処理や効率的なデータ利用に際しては必要であると考えられる．これまでに，プローブカーデータを用いたオンラインによるマップマッチング手法の研究は著者の知る限り行われていないが，今後はより効率的なデータ処理と利用価値の高いデータ作成を目指して，オンラインでの処理が可能な手法を開発する必要がある．

第3章 参考文献

- 朝倉康夫，羽藤英二，大藤武彦，田名部淳（2000）PHS による位置情報を用いた交通行動調査手法，土木学会論文集，No.653，-48，pp.95-104．
- 稲垣潤，長谷川美紀，北島秀夫（1999）遺伝的アルゴリズムを用いた経路探索における複数経路候補の決定法，電子情報通信学会論文誌，D-，Vol. J82-D-，No.8，pp.1102-1111．
- 井上祐介（2001）遺伝的アルゴリズムを用いた複数経路探索法，高知工科大学学士学位論文．
- 大草裕二郎，朝倉康夫，羽藤英二（1999）Screening 法による観光周遊ルート集合の抽出，土木計画学研究・講演集，No.22（1），pp.397-400．
- 大西啓介，加藤誠巳（1992）交差点内コストを考慮した道路網における経路探索の手法とそのマルチメディア型経路案内システムへの応用，情報処理学会論文誌，Vol.33，No.7，pp.970-979．
- 機械システム振興協会（2000）ITS プローブカーシステムの開発に関するフィージビリティスタディ報告書．
- 小島英史，羽藤英二（2004）プローブパーソンデータによるオンラインマッチングアルゴリズム，土木計画学研究・講演集，Vol.29，CD-ROM．
- 杉本克行，加藤誠巳（1985）有向ネットワークにおいて閉路を含まない k 個の最短経路を求めるための手法，情報処理学会論文誌，Vol.26，No.2，pp.356-364．
- 「測量」編集委員会・GPS 小委員会編（2002）GPS が交通調査を変える～プローブカーによるパラダイムシフト～，GPS フロンティア，pp.13-20．
- 中京都市圏総合都市計画協議会（1993），第3回中京都市圏パーソントリップ調査報告書
- 土木学会編（1998）交通ネットワークの均衡分析 最新の理論と解法，丸善．
- Asakura, Y. and E. Hato (2001) Rethinking Urban Travel Measurement, Asia GIS, CD-ROM.
- D'Este, G (1997) Hybrid Route Choice Procedures in a Transport Network Context. *Journal of Eastern Asia Society for Transportation Studies*, Vol.2, No.3, pp.735-752.
- Greenfeld, J.S. (2002) Matching GPS Observations to Locations on A Digital Map, Proceedings of the 81st Annual Meeting of the Transportation Research Board, CD-ROM.
- Makimura, K., H. Kikuchi, S. Tada, Y Nakajima, H. Ishida and T. Hyodo (2002) Performance Indicator Measurement Using Car Navigation Systems, 81th Transportation Research Board, CD-ROM.
- Quddus, M.A. , W.Y. Ochieng, L. Zhao and R.B. Noland (2003) A general map matching algorithm for transport telematics applications", *GPS Solutions Journal*, 7 (3), pp.157-167.
- Ueta, M. (2003) Road Management Practice Utilizing Probe Vehicles, Proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM.
- White, C.E., D. Bernstein and A.L. Kornhauser (2000) Some Map Matching Algorithms for Personal

Navigation Assistants, *Transportation Research Part C* 8, pp.91-108.

第4章 旅行時間予測手法の開発

予測旅行時間情報はドライバーの交通行動に与える影響が極めて大きい。与えられた旅行時間情報を利用して、これからトリップを行おうとするドライバーは出発時刻や利用経路に関する意思決定を行うであろうし、トリップ中のドライバーでさえも走行する経路の変更に関して意思決定を行うであろう。もちろん、ドライバーが得られた情報を完全に信頼し、これを利用するとは限らない。つまり、ドライバーにとって与えられた情報が参考値としかならない場合も多いと考えられる。これまでに、提供された旅行時間情報とドライバーが認知する旅行時間との関係を分析した研究は多い（飯田ら 1990；飯田ら 1991；小林・井川，1993；林ら，1998；小川，1999；藤井ら，2000）。これらの研究に共通した知見は、ドライバーは提供された旅行時間情報を参照することで認知旅行時間の不確実性を減少させるということである。一方で、Verplanken et al.（1997）は、十分な走行経験を持つドライバーは日々の運転により蓄積された経験から得られる情報の影響が強く、新たに提供される情報を参照しても利用しない傾向があるとしている。それまでの走行経験が認知旅行時間の不確実性を減少させることを示す研究成果も多く（山下・萩山，1996；久保田ら，1999；田中ら，2000），走行経験を繰り返すうちに提供された情報の精度をドライバーが検証することで、現在の予測旅行時間精度に対して「信用するに値しない」といった先入観が確立されている場合も考えられる。

また、完全に正確な旅行時間を予測することは非常に難しい。例えば、毎日変動し続ける交通状況に関する膨大なデータを収集・解析し、極めて精度の高い旅行時間予測値を算出することが可能であったとする。この情報をドライバーに提供し、その情報精度の高さがドライバー間で認知されれば、情報を参照した多くのドライバーがこれに従って出発時刻や選択経路に関する意思決定を行うであろう。しかしこの場合、精度の高い情報を提供したことによって交通状況がそれまでの状況とは一変し、新たな状況へと変化するであろう。結果として、新たな交通状況を考慮しないで予測された情報が、誤った情報となってしまうことは容易に推察される。これはハンチング現象（hunting phenomenon）と呼ばれ、高速道路上の旅行時間情報により実際に観測される現象である（大口ら，2002；Ogutchi et al., 2003）。

この問題を解決するためには、ドライバーの情報参照行動や経路選択・変更行動をあらかじめ分析・モデル化し、これから提供しようとする情報が交通状況にどのような影響を与えるかを予測した上で、より円滑な交通状況へ向けた適切な情報提供のあり方についての研究が重要となるであろう。しかし、本研究では上記のような情報提供とドライバーの情報参照行動・経路選択行動の関係には言及しない。次節で詳細に述べるが、現在すでに提供されている旅行時間情報の多くは、交通状況の変化の激しい時間帯においては誤った情報となってしまう場合が少なくない。したがって、より高精度の予測旅行時間情報を提供することは、現段階においては十分に重要な研究課題であると考えられる。

トラフィックカウンターデータや AVI データは、今日の旅行時間予測において最も利用されるデータである。しかし、これらのデータ収集システムはハード面での大規模な設備投資が必要である上、収集機器を設置した区間においてしか情報を入手できない。一方、前章でも示したように、プローブカーシステムから得られる区間旅行時間データは、収集可能な情報量は固定システムより少なく、また時間的に連続した情報収集は困難であるものの、広範囲にわたる任意の道路区間で情報を収集することが可能である。さらに、プローブカーシステムでは車両がトリップ中に経験した走行速度の変化に関する情報も入手できる。つまり、これは対象区間の通過に要する旅行時間のみではなく、その区間を通過するに際して途中でどのような速度変化を経験したかについての情報であり、最終的な旅行時間がどのようなメカニズムにより発生しているかについての重要な資料となる。

旅行時間予測についてこれまで行われてきた多く手法は、固定された観測機器から収集される特定区間の通過に要した旅行時間のデータ、もしくはその蓄積データを用いて、近い将来に同区間を通過するために要する旅行時間を予測するものである。したがって、予測された旅行時間情報は、対象区間に流入する前のドライバーにのみ提供可能である。一方、プローブカーデータを用いる場合は、リンクコストテーブルのように任意のリンクについての情報を蓄積しておけば、情報提供区間をあらかじめ設定する必要はない。

また、短い区間の旅行時間は提供されるまでもなくドライバー自身がある程度正確に予測できるため、予測対象とする区間は走行距離、旅行時間ともにある程度長い区間が適していると考えられる。しかし、予測される区間が長距離になるほど予測旅行時間の誤差は大きくなり、誤った情報の提供がドライバーに与える不利益も大きなものとなってしまう。さらには、ドライバーの走行特性は個人によって異なっていると考えられ、平均的な旅行速度より遅く走行するドライバーや速く走行するドライバーが存在する。この場合も、予測対象区間が長いほど平均値として算出された予測旅行時間と、実際の走行に要する旅行時間との乖離は大きくなる。このため、長距離に渡る区間の旅行時間情報を与える場合には、対象区間に流入する以前に与える情報のみではなく、その区間を通過しているドライバーに対して、更新された残り区間の予測旅行時間情報が与えられるべきである。プローブカーシステムでは走行中の情報提供車両の走行状況を収集することが可能であることから、より動的な旅行時間更新手法について取り組むことが可能である。

そこで本章では、マップマッチング処理後のプローブカーデータを用いて、旅行時間予測手法の開発を行う。開発される予測手法は、起点においてドライバーに提供される情報を予測する手法とともに、トリップ中の交通状況の変化に対応して残り区間の旅行時間を更新する手法である。

4.1 既存の旅行時間予測手法

4.1.1 従来の旅行時間情報

現在最も一般的に提供されている旅行時間情報の算出手法は、AVI システムによる現在時間法である。この手法は、道路上に設置された AVI システムによって予測対象区間の旅行時間を実際に観測し、これを提供するものである。例えば、ある対象とする道路区間を x 分で通過した車両が存在したとする。このシステムは x 分で通過したこの車両を観測した後、それ以降に対象区間に流入する車両に対して情報を提供する。したがって、提供される情報は少なくとも x 分前の情報になる。当然、対象区間が長いほど情報の鮮度は低くなり、交通状況の変化が激しければ誤差も大きくなる。

また、トラフィックカウンターを用いて区間の平均速度を割り出すことで、旅行時間を算出する場合もある。対象区間内に n 個のトラフィックカウンターが存在する区間では、旅行時間 T は次式で計算される。

$$T = \sum_{i=1}^n \frac{L_i}{V_i} \quad (4.1)$$

ここに、 T は現在の旅行時間の推定値、 L_i は区間 i のトラフィックカウンターの勢力長、 V_i は区間 i の平均走行速度である。

これらの手法は旅行時間を“予測”しているわけではなく、最新の実現値を提供しているに過ぎない。予測対象区間にとらわれず、OD 間の最短旅行時間となる経路を VICS 情報等を利用して探索するシステムにおいても、各リンク旅行時間は現在時間法のように出発時点での最新情報であり、トリップ開始後の交通状況の変化を考慮しているわけではない。

4.1.2 既存の旅行時間予測手法

このような出発後の交通状況の変化に関する問題を解決するために、これまでも旅行時間を予測しようとする研究は多く行われてきた。例えば、回帰モデルを用いることで、ある区間の現在の旅行時間と将来の旅行時間の関係をモデル化することで予測する方法や (Zhang and Rice, 2003; Wu et al., 2003; Sun et al., 2003)、パターンマッチングにより過去の旅行時間変動パターンから現在の旅行時間変動パターンと最も類似したデータを抽出することで、将来の交通状況を予測する方法 (舟橋ら, 2003; 割田ら, 2003; Bajwa et al., 2003)、同様にカルマンフィルタを用いて未来の旅行時間変動パターンを予測する方法 (若尾ら, 1997; Chen and Chien, 2001)、また、ある上流側道路区間の旅行時間や交通量を与件として、下流側の道路区間の旅行時間をカルマンフィルタにより算出する方法 (安井ら, 1993)、対象区間への流出入交通量の変動パターンを用いる方法 (上野ら, 2002; Bajwa et al., 2002)、さらには、交通シミュレーションを用

いる手法（井上・湯川，1996；巻上ら，1997）などがある．

これらの研究では，高速道路（都市高速道路を含む）を予測対象区間とするものが多い．これは，高速道路上にはトラフィックカウンターデータや AVI カメラが 500 m 間隔に設置されていることが多く，一般道路に比べて密に配置されているためである．また高速道路の交通量は，出入り口で流入・流出交通量を観測することで対象区間に存在する交通量を観測することが容易である点や，インターチェンジペアにおいて利用経路が非常に限られるため予測区間を設定しやすい点も，高速道路を対象とした旅行時間予測が取り組まれてきた主な要因であろう．さらには，少ない対象区間において多くの車両に情報を配信できることや，有料道路であるため旅行時間に関する情報が重要視されやすいなどの要因も挙げられる．このように，高速道路を対象とする場合は交通変動を捉えやすく，また情報提供を行い易いといえよう．

これに対して，一般道路を対象とした研究は非常に少なく，これまでの一般道路を対象にした旅行時間予測研究の多くは幹線道路のある単一路線に関するものである．これは，一般道路網を対象とする場合には各 OD ペア間に膨大な数の利用可能経路が存在するため，効率的な予測対象区間を設定することが困難であることや，多くの従来研究で用いられるトラフィックカウンターも一般道路網上での設置数は交差点間数に対して少なく，正確な旅行時間予測を行うことが困難であることも原因として挙げられる．プローブカーデータの大きな利点の 1 つである，より広範囲に渡る交通データ収集はこれらの問題点を解決し得る．そこで，以降においてプローブカーデータによる旅行時間予測手法の開発を行う．

4.2 蓄積データベースを用いた旅行時間予測手法の開発

ここでは，マップマッチング処理後のプローブカーデータにより作成された，蓄積データベースであるリンクコストテーブルを用いて，任意の OD ペアにおける旅行時間予測手法を開発する．リンクコストテーブルは各リンクの 5 分間隔平均旅行時間情報が蓄積されており，任意の時刻における各リンクの旅行時間情報を得ることができる．つまり，対象エリア内のすべての道路区間を対象とし，いかなる出発時刻にも対応した旅行時間や最短経路の予測が可能である．

カーナビゲーションシステムでは，（機種にもよっても異なるが）任意の起終点に対応して最適な経路とその旅行時間情報を提供することができる．このシステムではリンクの旅行時間情報を用いて最短経路探索を行っているが，システム内で用いられているリンク旅行時間情報は道路種別によって平均走行速度を設定し，これによって予測旅行時間を算出するものである．つまり，同じ道路種別であれば道路区間が異なっていようと同一旅行速度で走行することになるため，いかなる時刻に出発しても同じ経路，同じ旅行時間を算出することになる．VICS 情報に対応したカーナビゲーションシステムでは，現在の交通状況に応じて異なる交通情報を提

供可能であるが、旅行時間情報を提供する VICS 対象区間はごく一部の幹線道路のみであり、名古屋市域における VICS リンク数は全ての道路リンク(DRM 基本道路網に含まれるリンク数)に対してわずか 3%程度であることが知られている(小出ら, 2004)。

4.2.1 旅行時間予測計算の基本的な考え方

ここでは、開発する経路探索アルゴリズムの基本的な考え方を示す。

図 4-1 は、リンクコストテーブルを用いた場合の旅行時間予測方法の基本的な考え方を示している。出発地点に繋がるリンクには出発時刻を含むカラムのリンク旅行時間を用い、これがリンクコストテーブルの区分時刻(5 分)を越えるたびに、以降のリンク旅行時間を参照するカラムを更新する。このように、出発時刻以降の交通状況変化を考慮すれば、対象トリップ中の交通状況を出発から到着まで適切に捉えることができ、逆にこれを用いない場合は出発以降の交通状況を誤って捉えているともいえる。

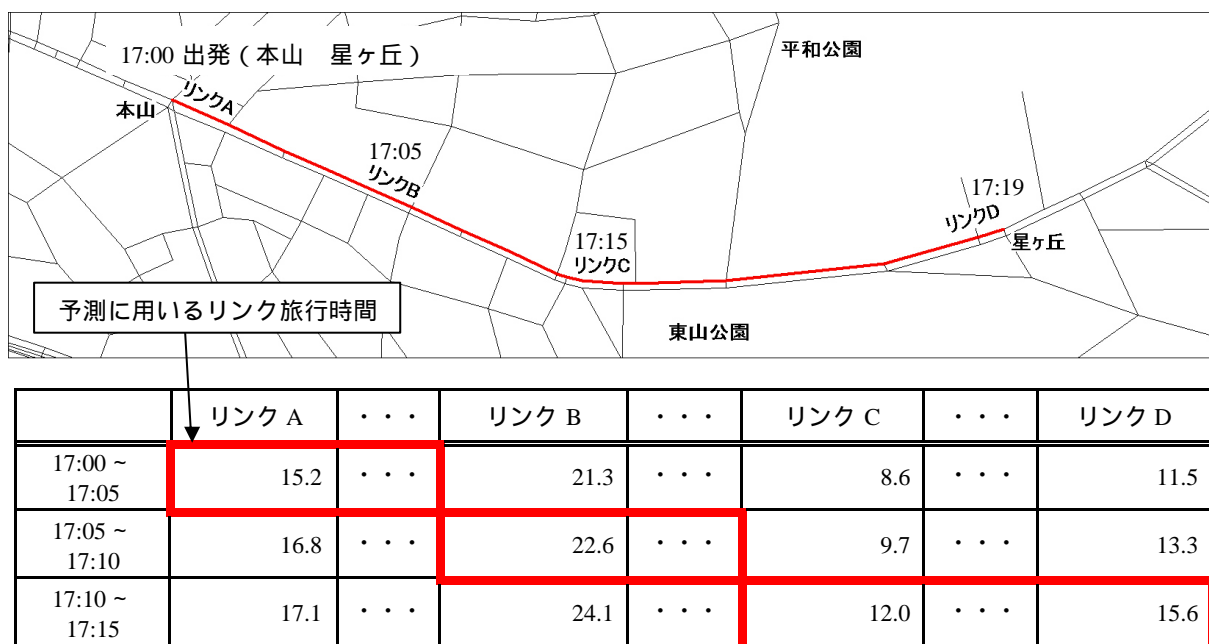


図 4-1 リンクコストテーブルを用いた旅行時間予測の考え方

4.2.2 計算アルゴリズム

ネットワーク理論に基づく最短経路探索アルゴリズムは、Dijkstra 法、Ford-Fulkerson 法、Yen 法、Warshal-Floyd 法、Bellman-Ford 法、Moore 法など多くが提案されている。リンクコストが非負であり、また 1 つのノードから発生するリンク数が多い複雑なネットワークを対象とする場合は、Dijkstra 法や Warshal-Floyd 法が最も計算効率が良いことが知られている(志水, 1976; 林ら, 1983)。ただし前項で説明したような、探索過程でリンクコストを更新する考え方に対して適用可能な方法としては Dijkstra 法が挙げられる。したがって、ここでは図 4-1 で示した考

え方に基づく最適経路・旅行時間探索アルゴリズムを，Dijkstra 法を基本として開発する．

トリップ中の交通状況の変化を考慮するためにはリンク旅行時間の修正を行う必要があり，本研究ではこの探索手法を“リンクコスト更新型 Dijkstra 法”と呼ぶこととする．図 4-2 にこのアルゴリズムの計算フローを示す．

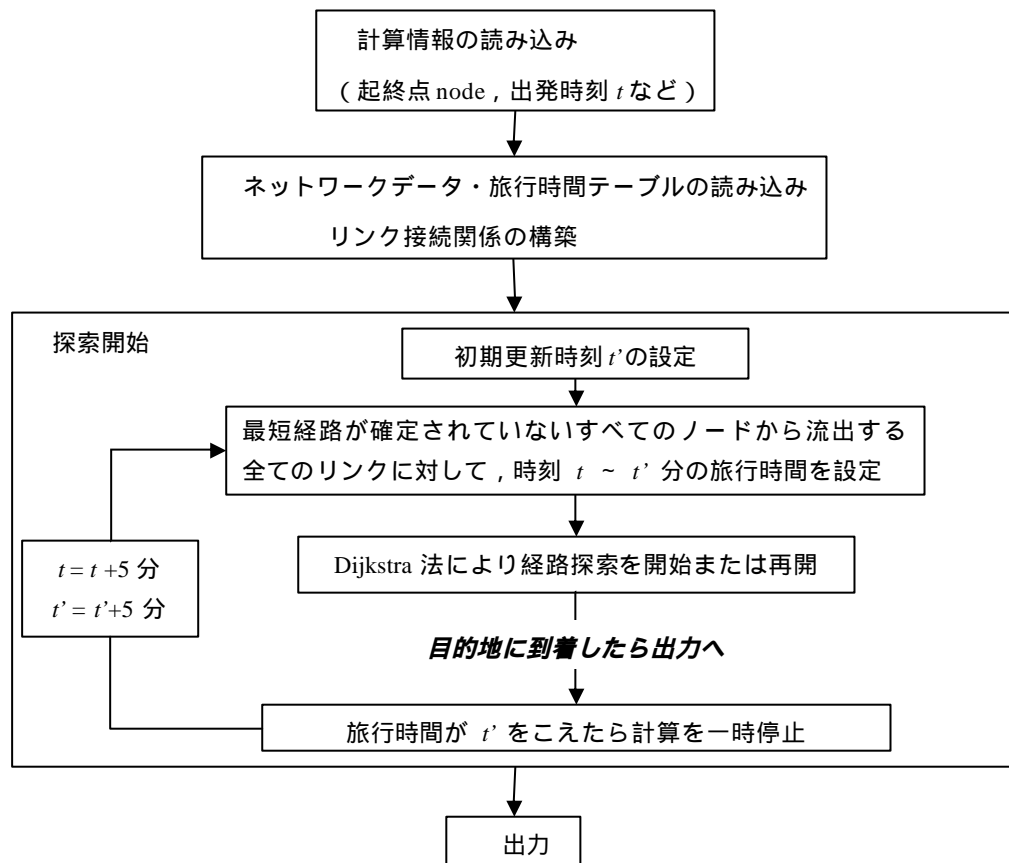


図 4-2 リンクコスト更新型 Dijkstra 法の計算フロー

この計算フローに従えば，出発後の交通状況の変化を考慮した上での最短旅行時間経路を探索することが可能となる．したがって，探索される経路および旅行時間は事後的にも（到着後に考えても）最短な経路，旅行時間となる．ただし，これは交通状況の変化が平常時における変化であるとみなせる場合のみ成り立つ．つまり，出発時点ですでに平常時とは異なる交通状況である場合（事故や路上工事などによる車線規制など）は，これらを考慮したうえで探索されるべきである．このため，出発時点での交通状況に関する情報は VICS 情報などを利用する必要がある．プローブカーデータのリアルタイム情報による旅行時間予測手法もすでに開発されつつあるが（Nakata and Takeuchi, 2004），各道路区間における通過旅行時間情報を断片的にし取得することができないためそれほど効率的であるとはいえない．本研究では，あくまで平常時に適用可能な基礎技術に関する知見を深めることを目的とするため，リアルタイム情報を

併用した旅行時間予測は行わないものとする。

これまでも幾つかの研究で，出発後の交通状況の変化を考慮した旅行時間予測手法は提案されている（中村・王，2003；Wang and Nakamura, 2003；岸野ら，2003）。しかしいずれも，対象経路を特定した上で，この経路上の旅行時間を算出しているに過ぎない。一般道路における利用可能経路は無数に存在する。あらかじめ対象経路を特定した上で交通状況の変化を考慮して旅行時間を算出しても，対象経路が最短経路とはならないことは自明である。

リンクコスト更新型 Dijkstra 法は，対象ネットワーク上の各リンクの旅行時間を更新しながら探索計算を行うことになるが，探索中の予測旅行時間が更新時刻を超えた場合は探索計算を一時停止して未到達リンクのコストを更新した上で探索計算を続行するため，計算ステップ（ネットワーク上に存在する各ノードへの最短経路確定作業）は通常の Dijkstra 法と同じである。したがって，計算時間（CPU 時間）はリンクコストを更新するための時間が通常の Dijkstra 法より余分に必要となるものの，通常の Dijkstra 法とそれほど変わらないと考えられる。しかし，この手法では，少なくとも出発時刻から到着するであろう時刻までの各リンクの旅行時間情報を利用するため，計算に必要な情報量は通常の Dijkstra 法よりも明らかに多く，必要な記憶領域も大きくなってしまう。そこで，リンクコスト更新型 Dijkstra 法の計算速度を検証するため，図 4-3 に示すネットワークを用いて計算速度を検証した。ここで，検証に用いる起点を JR 名古屋駅桜通口タクシーターミナルとし，終点を星ヶ丘交差点とした。

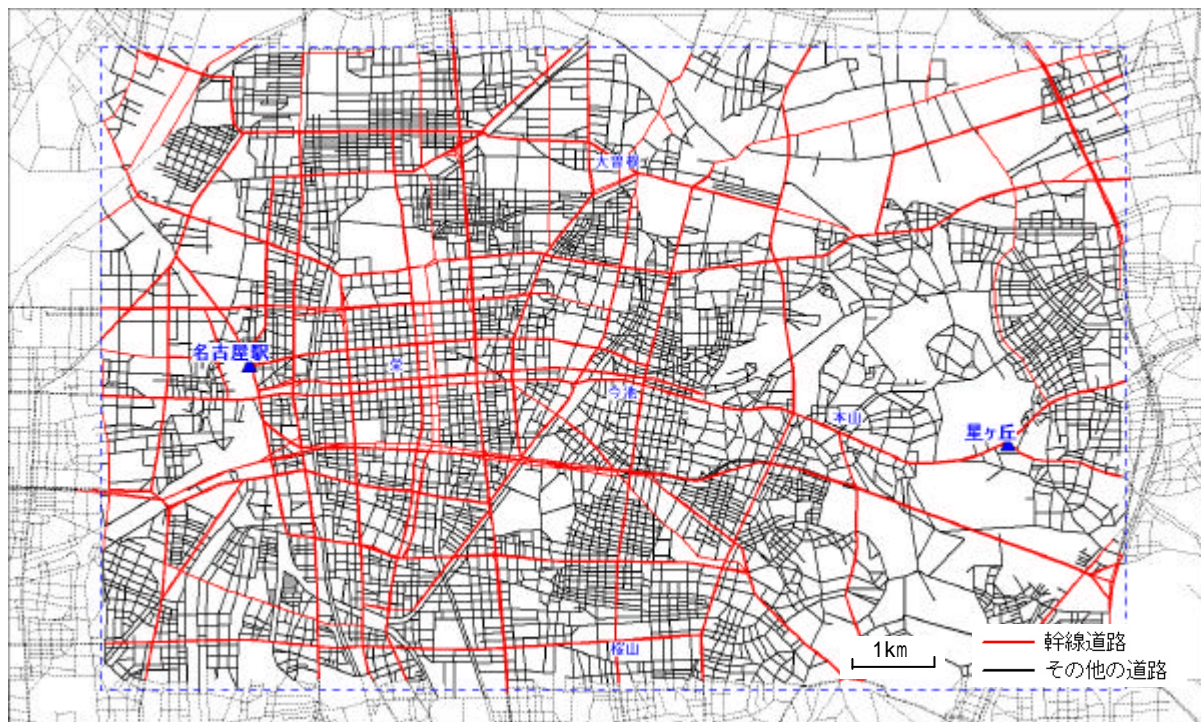


図 4-3 検証用ネットワーク

対象ネットワークは往復合計リンク数 26,412，ノード数 9,433 である．まず，設定した出発時刻と探索結果を表 4-1 に示し，各リンクに適用されたリンクコストの状況を図 4-4 に示す．リンクコストの更新回数は 6 回であった．図 4-4 からわかるように，起点から遠ざかるほど適用されるリンクコストの時刻が大きく更新されていることが分かる．

表 4-1 リンクコスト更新型 Dijkstra 法の適用結果

対象リンク数	26,412
対象ノード数	9,433
出発時刻	15:32:19
予測到着時刻	16:02:47
予測旅行時間	30 分 28 秒



図 4-4 適用されたリンクコスト

次に，リンクコスト更新型 Dijkstra 法の探索に要する計算時間（CPU 時間）を検証した．探索計算には市販の PC（Pentium4，2GB；メモリ 512MB）を用い，プログラム言語は Fortran である．ただし，計算に要する CPU 時間はプログラムの実行毎にばらつくため，ここでは同じ条件で探索計算を 5 回繰り返しその平均値を示す（表 4-2）．

ここで，リンクコストを更新しない場合は，これまでのカーナビゲーションシステムで行われている探索計算と同じであるとみなせる．この結果より，計算時間に大きな影響を与えてい

るのはネットワークデータの読み込み，およびリンク接続条件の設定である．中でも，旅行時間情報（時間区分）が大きいほど読み込みに時間を要する．また経路探索に要する時間は，リンク数が2万～3万程度でも0.02秒程度と非常に小さいことが分かる．ここで示した探索アルゴリズムを実際に使用するためには，カーナビゲーションシステムのような専用端末，もしくは探索専用センターサーバにより計算が行われると考えられる．このような専用システムを用いる場合は，システム起動時にネットワークの読み込みや接続条件設定が行われる．このため，表4-1で示す程度のネットワークを対象とする場合は，ユーザが起終点情報や出発時刻，天候情報などをシステムに入力すれば，最大でも0.03秒程度の極めて短い時間で最短経路を計算できることになる．

表 4-2 探索に要する計算時間

< 計算機性能 > CPU：Pentium4 – 2GHz メモリ：0.512GB (単位：秒)				
	リンクコスト更新なし		リンクコスト更新あり	
ネットワークデータ (リンク数)	幹線ネットワーク (9,433)	全ネットワーク (26,412)	幹線ネットワーク (9,433)	全ネットワーク (26,412)
リンクコスト更新回数	-		6	
計算情報の読み込み	0.016	0.016	0.019	0.019
ネットワークデータの読み込み&設定	0.294	2.425	1.944	8.906
旅行時間テーブル更新&経路探索	0.000	0.016	0.003	0.022
出力	0.003	0.000	0.006	0.006
総計算時間	0.312	2.456	1.972	8.953

旅行時間情報を持たないネットワークデータを使用し，探索には経路長を用いた

4.2.3 予測精度・予測経路に関する考察

a) 予測手法の有効性の検証

ここでは，開発した予測手法の有効性を検証する．検証には図4-5に示す経路を対象として，リンクコストを更新する場合と更新しない場合の旅行時間予測値を比較する．開発したリンクコスト更新型 Dijkstra 法は，起終点を与件としてすべての利用可能経路から事後的にも最短旅行時間となる経路を探索することができるが，特定の経路を対象としたほうが探索手法自体の有効性が明確になると考えられる．対象とする経路は，東名高速道路名古屋 IC から中区錦通久屋交差点に至る 9.2km の経路であり，全区間が幹線道路のみにより構成されている．

プローブカーデータから対象経路を完全に通過したトリップを抽出したところ，実験期間中

に 84 トリップが観測された。これらトリップの概要を表 4-3 に示す。平日と休日では、平日のほうが観測されたトリップ数が多いもののこれらの差は小さく、対象経路においては曜日による旅行時間の違いはほとんどないことが分かる。また、昼間(7:00 ~ 19:00)と夜間(19:00 ~ 7:00)において同数のトリップが観測されているが、その差は平均で 8 分以上も昼間時の方が大きくなっている。



図 4-5 予測精度検証用経路

表 4-3 検証用データの概要

	トリップ数			平均旅行時間 (分)		
	昼間	夜間	計	昼間	夜間	計
平日	21	33	61	26.16	17.88	21.68
休日	14	9	23	25.79	17.18	22.42
計	42	42	84	26.03	17.73	21.88

昼間：7:00 ~ 19:00，夜間：19:00 ~ 7:00

リンクコストを更新した場合の予測旅行時間と更新しない場合の予測旅行時間のそれぞれについて、実測値との相関係数，RMS 誤差を表 4-4 に示す。

表 4-4 リンクコスト更新の有効性

	相関係数			RMS 誤差 (秒)		
	昼間	夜間	計	昼間	夜間	計
リンクコスト更新なし	0.593	0.778	0.826	255.25	168.08	216.11
リンクコスト更新あり	0.705	0.757	0.863	224.93	164.35	193.57

この結果より，夜間の相関係数を除けば相関係数，RMS 誤差ともに，リンクコストを更新して予測された旅行時間の方が予測精度が高くなっていることが分かる．ここで使用した観測データは夜間のトリップが半数を占めているが，夜間は交通状況の変化が小さく，リンクコストを更新することによる予測精度の向上が小さいことも見て取れる．しかし，交通状況変化の大きな昼間時においては，相関係数，RMS 誤差ともに大きく向上しており，出発後の交通状況の変化を考慮した予測手法の有効性が示された．

b) 予測経路に関する考察

ここでは，リンクコスト更新型 Dijkstra 法（ここでは手法 Ⅱ と呼ぶ）と，出発時刻の交通状況のみを利用する通常の Dijkstra 法（ここでは手法 Ⅰ と呼ぶ）の予測経路とその予測特性について分析を行う．対象とする OD ペアは名古屋空港 名古屋駅とし，情報提供の対象となるトリップが 16:00～19:00 にわたって 10 分間隔に出発するものとする．この OD ペアでは，名古屋高速道路の供用形態により，高速道路を利用した方が 5km 程度長い走行距離となる．さらに，この時間帯は名古屋高速道路上の交通混雑が非常に激しく，名古屋高速道路の利用による時間短縮が非常に小さいため，一般道路利用した方が旅行時間が短くなる場合がある．図 4-6a～d に，手法 Ⅰ，Ⅱ により予測される経路長の違い，予測旅行時間の違い，手法 Ⅱ の予測誤差，そして各手法により予測された経路に従った場合に実際に要する旅行時間の違いを示す．

図 4-6a は，各手法により予測される経路長の違いを示している．前述の通り，名古屋高速道路を利用する経路は一般道経路と比較して長くなる．各手法により予測された最短経路の経路長から，名古屋高速道路を利用する時刻がほとんどの出発時刻において異なっていることが分かる．このように，交通状況の変化の激しい時間帯では考慮する交通状況の違いにより予測経路が明らかに異なる．また，図 4-6b に各手法により予測される旅行時間の違いを示す．予測旅行時間についても経路長と同様に，すべての時刻において異なっていることが分かる．

図 4-6c に手法 Ⅱ（出発時刻の交通状況のみを考慮）の予測旅行時間と，予測された経路の実際の旅行時間を示す．ここで，実際の旅行時間はリンクコストテーブルにより作成されるため，5 分間隔の交通状況により再現された平均的な旅行時間である．手法 Ⅱ では，ほぼすべての出発時刻で予測誤差が発生しており，実際に要する旅行時間より予測旅行時間が小さくなっている場合が多く見られる．特に，交通状況が混雑し始める 17:30 以降においては予測旅行時間が常に過小になっていることが分かる．このように，出発後に交通混雑が激しくなる時間帯では出発後の交通状況の変化をあらかじめ評価することが重要であるといえる．

図 4-6d は，各手法により予測された最短経路が実際に要する旅行時間である．手法 Ⅱ では，実際に要する旅行時間が予測旅行時間と一致する値になる．また，手法 Ⅰ により予測された最短経路の実際の旅行時間は，手法 Ⅱ の実際の旅行時間より常に大きくなる．これは出発後の交通状況の変化により，手法 Ⅰ で予測される経路は最短経路ではなくなってしまうためである．




図 4-6a 予測経路長の違い




図 4-6b 予測旅行時間の違い




図 4-6c 出発時刻の交通状況のみを用いる場合の予測誤差




図 4-6d 予測経路が実際に要する旅行時間の違い

このように、リンクコスト更新型 Dijkstra 法の予測特性を幾つかの点で分析を行った結果、上述のようにより適切な予測を行えることが分かった。しかし、同じ曜日の同じ時刻を取り上げても現実の交通状況は変動しており、5 分間隔という詳細な時間間隔で各リンクの平均旅行時間を蓄積しても必ずしも適切に表現できるとは限らない。さらには、ドライバーの走行特性も個人間で異なっている。このように、平均的な交通状況や走行を前提とした予測旅行時間は、必ずしも情報を提供されるドライバーにとって適切であるとは限らない。そこで次節では、プローブカーデータの重要な特徴の 1 つである、トリップ中の走行状況に関する情報を用いた旅行時間更新手法の開発を行う。

4.3 トリップ中の予測旅行時間更新手法の開発

前節で示した旅行時間予測手法は、出発後の交通状況の変化を考慮して、起終点間に存在する経路の中から事後的にも最短となる経路を探索するものであった。しかし、ここで用いられたデータベースは、曜日別、天候別、5 分間隔の各リンクの平均旅行時間という詳細な情報について蓄積しているものの、いずれの情報も平均的な交通状況に関する情報である。すなわち、予測される旅行時間や経路は平均的な交通状況の変化を前提としている。さらに言えば、予測された旅行時間は、情報提供の対象となるドライバーが平均的な走行を示すことをも前提としている。しかし、日々の交通状況は平均的な交通状況に対して変動していると考えられるし、すべてのドライバーが平均的な走行速度で走行するわけではない。したがって、ドライバーが提供された経路を走行しても、交通状況が平均的でなければ、またドライバーが平均的な走行を示さなければ、旅行時間を正確に予測することはできない。トリップ開始以前に出発時刻における交通状況が平均的であるかどうかを知るためには、VICS などリアルタイム交通情報を収集する必要があるが、出発時刻の交通状況が出発後も継続するわけではない。また、膨大な道路ネットワーク上で、近い将来にどのような交通状況が実現するかを正確に予測することは困難である。さらには、情報提供対象となるドライバーが平均的な走行を行うかどうかを、ドライバーがトリップを開始する前に分析者や情報提供者は知ることは困難である。したがって、予測旅行時間情報はトリップ開始後に何らかの情報をを用いて更新されるべきである。

4.1 で示したように、従来の旅行時間予測手法はトラフィックカウンターデータや AVI データなど、道路ネットワーク上の固定された区間を対象としているものがほとんどである。したがってこれらの方法では、対象区間にすでに流入した車両が流出するまでに要する旅行時間を、再度予測し提供することはできない。これまでに開発された旅行時間予測手法の中で予測区間を任意に扱うことの手法としては、カルマンフィルタを用いて下流区間の交通状況を予測する手法（安井ら，1993；Nanthawichit et al., 2003）や、交通シミュレーションを用いる手法（井上・湯川，1996；巻上ら，1997）が挙げられる。しかし、これらは近い将来における下流区間の交通状況を予測してはいるものの、情報提供対象となるドライバーの走行特性を考慮していない。またこれらの研究では、高速道路ネットワークや固定観測機器の設置された主要幹線道路を対象としており、広いエリアにおける任意の経路に対して適用可能であるとはいえない。

プローブカーデータは、ドライバーが出発後に経験した走行状況についての情報を提供することができる。この情報は交通状況の変化やドライバーの走行特性に応じて変化する、より動的な情報である。したがって、予測旅行時間の更新には情報提供の対象となるドライバーが予測経路を走行し始めてから、経路上のある地点に到達するまでに経験した速度分布情報を用いることで更新精度の向上を図ることができると考えられる。このような情報を用いることは、非集計分析が集計分析とは対照的に、トリップ対象者の個人属性や選択肢のサービスレベル変数などの非集計データを用いるのと同様のアプローチである。そこで、マップマッチング処理

後のプローブカーデータから、過去に予測対象経路を通過したデータを抽出し、過去のデータが示す速度変化情報と情報提供対象車両の示す速度変化情報とともに用いることで、残された区間に対する予測旅行時間の更新手法を開発する。

4.3.1 プローブカーデータによる予測旅行時間更新手法の開発

ここではまず、プローブカーデータを用いた旅行時間更新手法の基本概念について述べる。任意の予測対象経路（起点において出発後の平均的な交通状況の変化を仮定して予測された最短経路）において、過去にこの経路を走行した走行履歴から作成される、旅行時間 - 旅行距離関係を“蓄積データ”とする。さらに、予測対象経路が K 個の等間隔な区間に分割されるとし、予測対象車両が対象経路上の第 k 区間まで走行したとき、起点から第 k 区間までに経験した速度変化を“経験データ”と呼ぶ。このとき、蓄積データと経験データをともに用いることで、対象トリップが第 $k+1$ 区間以降に経験するであろう走行状況を予測することができると考える。図 4-7 は、以上の考え方を示している。




図 4-7 予測旅行時間更新の考え方

過去のある時間帯において、対象経路を通過した N 個の蓄積データがあるとき、蓄積データに含まれる過去の旅行時間をそれぞれ $\{\tilde{t}^1, \dots, \tilde{t}^n, \dots, \tilde{t}^N\}$ と表す。すなわち、 \tilde{t}^n は蓄積データ n の旅行時間とする。さらに、予測対象経路が等間隔な K 区間に分割されている場合には、蓄積データ n における各区間の旅行時間 $\{\tilde{t}_1^n, \dots, \tilde{t}_k^n, \tilde{t}_{k+1}^n, \dots, \tilde{t}_K^n\}$ を用いて次式が成り立つ。

$$\tilde{T}^n = \sum_{k=1}^K \tilde{t}_k^n \quad (4.2)$$

また，経験データにおける各区間の旅行時間を $\{t_1, \dots, t_k, t_{k+1}, \dots, t_N\}$ と表す．ここで，ある車両が第 1 ～ k 区間まで通過した時，蓄積データと経験データの関係を用いて，第 $k+1$ 区間から終点までの旅行時間を予測する手法として，以下に示す手法 A ～ D を考える．

a) 経験速度の自乗誤差を用いる手法（手法 A）

旅行時間と同様に，蓄積データ n の各区間の旅行速度を $\{\tilde{v}_1^n, \dots, \tilde{v}_k^n, \tilde{v}_{k+1}^n, \dots, \tilde{v}_K^n\}$ と表す．第 1 ～ k 区間における蓄積データ n と経験データ $\{v_1 \dots v_k\}$ の走行特性の違いは，各区間の走行速度の自乗誤差により次式で表される．

$$Err^n = \frac{1}{k} \sum_{i=1}^k (v_i - \tilde{v}_i^n)^2 \quad (4.3.a)$$

ここに Err^n は第 1 区間から第 k 区間における蓄積データと経験データの違いを表す．これは，経験データとある蓄積データの類似度が高いほど小さな値をとる．

このとき，第 $k+1$ 区間目以降の更新された予測旅行時間 \hat{t}_{k+1+} は，自乗誤差の小さな N' 個の蓄積データの平均値として式(4.3.b)により算出される．

$$\hat{T}_{k+1+} = \frac{1}{N'} \sum_{n=1}^N T_{k+1+}^n d_{N'}^n \quad (4.3.b)$$

ここに， $d_{N'}^n$ は蓄積データ n について式(4.3.a)により算出される値が小さい N' 個に含まれるとき 1，そうでないとき 0 をとるダミー変数とする．

b) 類似度の重み付け関数を用いる手法（手法 B）

ここで，第 i 区間における蓄積データ n の速度 \tilde{v}_i^n と経験データの速度 v_i の類似度を表現する関数 $f_w(\tilde{v}_i^n, v_i)$ を以下の式で定義する．

$$f_w(\tilde{v}_i^n, v_i) = \exp(-g|\tilde{v}_i^n - v_i|) \quad (4.4.a)$$

この関数により算出される値は常に正である．また，2 つの速度 (\tilde{v}_i^n, v_i) が近いほど大きな値をとり，最大で 1 となる．この手法では， g の値によって速度差についての感度を調節することができる．この関数を用いると，第 1 ～ k 区間における蓄積データ n と経験データの類似度は式(4.4.b)により表される．

$$W^n = \sum_{i=1}^k f_w(\tilde{v}_i^n, v_i) \quad (4.4.b)$$

ここに、 W^n は第 1 区間から第 k 区間における蓄積データと経験データの類似度を表し、2 つのデータの類似度が高いほど大きな値をとる。

このとき、第 $k+1$ 区間目以降の更新された予測旅行時間 \hat{T}_{k+1+} は、式(4.4.b)により算出される類似度の大きい N'' 個のみを取り出し、以下の式で表すようにその値を重みとした重み付平均により算出される。

$$\hat{T}_{k+1+} = \frac{\sum_{n=1}^N (\tilde{T}_{k+1+}^n W^n d_{N''}^n)}{\sum_{n=1}^N (W^n d_{N''}^n)} \quad (4.4.c)$$

ここに、 $d_{N''}^n$ は蓄積データ n について式(4.4.b)により算出される値が大きい N'' 個に含まれるとき 1、そうでないとき 0 をとるダミー変数とする。なお、本研究では $N''=1$ とした。

以上の手法 A、B は、経験データと蓄積データの類似度の算出方法、および予測旅行時間の算出方法が異なる。手法 A では速度の自乗誤差を用いて類似度の高いデータを単純に平均する。一方、手法 B は指数関数である重み付け関数を用いて類似度を算出し、類似度による重み付平均により予測値を算出している。これらの手法は、蓄積データに含まれる過去の走行履歴データを 1 つ 1 つ経験データと比較し、類似度の高いデータのみを用いて現在地点以降の旅行時間や走行状況を予測するものである。

これらに対して、以降に示す手法 C、D は蓄積データと経験データを直接比較せず、蓄積データを集計し走行パターンを統計的に解析することで、経験データを条件とした場合の予測旅行時間（条件付平均値）を算出するものである。

c) 2 区間の統計的指標を用いる手法（手法 C）

蓄積データ n において、第 1 区間、 \dots 、第 k 区間の旅行時間の合計値を \tilde{T}_{-k}^n と表し、第 $k+1$ 区間、 \dots 、第 K 区間の旅行時間の合計値を \tilde{T}_{k+1+}^n と表す。これらが正規分布に従うとき、これらの関係は 2 次元正規分布で表される。さらに、あるトリップが第 k 区間までを旅行時間 T_{-k} で走行したとき、第 $k+1$ 区間目以降の更新された旅行時間は式(4.5)で表される。

$$\hat{T}_{k+1+} = \bar{T}_{k+1+} + \tilde{r}_{-k, k+1+} \times \frac{\tilde{s}_{k+1+}}{\tilde{s}_{-k}} \times (T_{-k} - \bar{T}_{-k}) \quad (4.5)$$

ここに、 \bar{T}_{k+1+} は蓄積データによる第 $k+1$ 区間以降の旅行時間の平均値、 $\tilde{r}_{-k, k+1+}$ は第 k 区間以前と第 $k+1$ 区間以降の旅行時間の相関係数、 \tilde{s}_{-k} (\tilde{s}_{k+1+}) は蓄積データによる第 k 区間以前 ($k+1$ 以降) の標準偏差である。

この手法は、提案する 4 つの手法のうちで唯一対象経路を予測更新地点前後の 2 つの区間に分割している。したがって、分割区間数が K であれば $K-1$ 種類の蓄積データを用意する必要がある。

d) 全区間の統計的指標を用いる手法（手法 D）

この手法では、 K 個の各区間旅行時間が正規分布に従うものとする。このとき、各区間の旅行時間は K 次元正規分布に従うことになる。ここで、 K 次元正規分布の確率密度関数は式(4.6.a)で表される。

$$f_{x_1, \dots, x_K}(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^K \det \mathbf{V}}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}) \mathbf{V}^{-1} (\mathbf{x} - \boldsymbol{\mu})^T \right\} \quad (4.6.a)$$

ここに、 \mathbf{x} を確率変数ベクトル（ K 次元横ベクトル）、 $\boldsymbol{\mu}$ を平均値ベクトル（ K 次元横ベクトル）、 \mathbf{V} を共分散行列（ $K \times K$ 次元正方行列）とし、それぞれ以下の式で表される。

$$\mathbf{x} = (x_1, x_2, \dots, x_K) \quad (4.6.b)$$

$$\boldsymbol{\mu} = (\boldsymbol{m}_1, \boldsymbol{m}_2, \dots, \boldsymbol{m}_K) \quad (4.6.c)$$

$$\mathbf{V} = \begin{pmatrix} v_{11} & v_{12} & \cdots & v_{1K} \\ v_{21} & v_{22} & \cdots & v_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ v_{K1} & v_{K2} & \cdots & v_{KK} \end{pmatrix} \quad (4.6.d)$$

このとき、予測対象車両が第 1 区間を t_1 で走行したとすると、 $x_1=t_1$ なる条件が与えられるので、第 2 区間以降の確率密度関数は式(4.6.e)となる。

$$f_{x_2, \dots, x_K}(x_2, \dots, x_K) = \frac{f_{x_1, \dots, x_K}(t_1, x_2, \dots, x_K)}{f_{x_1}(t_1)} \quad (4.6.e)$$

式(4.6.e)の x_2, \dots, x_K の平均値、すなわち式(4.6.e)を最大とする x_2, \dots, x_K を求めれば、これが更新された予測旅行時間となる。これはすなわち、式(4.6.a)に含まれる

$$(\mathbf{x} - \boldsymbol{\mu}) \mathbf{V}^{-1} (\mathbf{x} - \boldsymbol{\mu})^T \quad (4.6.f)$$

を、与えられた条件の下で最小とすることと同値である。

ここで、

$$\mathbf{V}^{-1} = \mathbf{W} = \begin{pmatrix} w_{11} & w_{12} & \cdots & w_{1K} \\ w_{21} & w_{22} & \cdots & w_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ w_{K1} & w_{K2} & \cdots & w_{KK} \end{pmatrix} \quad (4.6.g)$$

とすると，式(4.6.f)は $x_1=t_1$ なる条件により，式(4.6.h)に書き換えられる

$$\sum_{i \neq 1, j \neq 1} (x_i - \mathbf{m}_i) w_{ij} (x_j - \mathbf{m}_j) + 2 \sum_{j \neq 1} (t_1 - \mathbf{m}_1) w_{1j} (x_j - \mathbf{m}_j) + w_{11} (t_1 - \mathbf{m}_1)^2 \quad (4.6.h)$$

ここで，さらに以下の4式を定義する．

$$\mathbf{x}' = (x_2, \cdots, x_K) \quad (4.6.i)$$

$$\mathbf{\mu}' = (\mathbf{m}_2, \cdots, \mathbf{m}_K) \quad (4.6.j)$$

$$\mathbf{b} = (t_1 - \mathbf{m}_1) (w_{12}, w_{13}, \cdots, w_{1K}) \quad (4.6.k)$$

$$\mathbf{U} = \begin{pmatrix} w_{22} & \cdots & w_{2K} \\ \vdots & \ddots & \vdots \\ w_{K2} & \cdots & w_{KK} \end{pmatrix} \quad (4.6.l)$$

式(4.6.i)～(4.6.l)を利用して，式(4.6.h)の定数でない項(第1,2項)を平方完成すると，以下の式になる．

$$(\mathbf{x}' - \mathbf{\mu}' + \mathbf{bU}^{-1}) \mathbf{U} (\mathbf{x}' - \mathbf{\mu}' + \mathbf{bU}^{-1})^T - \mathbf{bU}^{-1} \mathbf{U} (\mathbf{bU}^{-1})^T \quad (4.6.m)$$

したがって， $x_1=t_1$ なる条件下での x_2, \cdots, x_K の平均値は式(4.6.n)で表されるベクトルとなり，この各要素の和が第2区間目以降の更新された予測旅行時間となる．

$$\bar{\mathbf{\mu}} = \mathbf{\mu}' - \mathbf{bU}^{-1} \quad (4.6.n)$$

これを，対象車両が各区間を通過するごとに計算することで，経験データと蓄積データを利用した予測旅行時間の更新が可能となる．なお第2区間目以降は， \mathbf{U}^{-1} を新たな共分散行列として計算することが可能である．これは，式(4.6.f)と式(4.6.m)を比較すると， \mathbf{V}^{-1} が \mathbf{U} に相当していることから分かる．

以上の手法A～Dに加え，これら提案手法の精度向上を検証するため，以下の手法E～Gを

定義する．

e) 対象トリップの経験速度のみを用いる手法（手法 E）

蓄積データを使用せず，対象トリップが対象経路流入後に経験した速度の平均値を，残りの区間に当てはめることで予測値を更新する方法である．予測更新旅行時間は次式で表される．

$$\hat{T}_{k+1+} = \frac{L-l}{l} \sum_{i=1}^k t_i \quad (4.7)$$

ここに， l は予測経路内をすでに通過した距離， L は予測経路長である．

f) 蓄積データの平均値のみを用いる手法（手法 F）

対象トリップが予測地点までに経験した情報を用いず，常に蓄積情報のみを用いて予測更新を行う場合，更新された予測旅行時間は式(4.8)で表される．

$$\hat{T}_{k+1+} = \frac{1}{N} \sum_{n=1}^N \tilde{T}_{k+1+}^n \quad (4.8)$$

g) 更新を行わない手法（手法 G）

これは，予測対象経路流入前の予測旅行時間をトリップ中に更新しない手法であり，トリップ中の残り旅行時間は，対象経路の起点における予測旅行時間と既に走行した旅行時間の差分として式(4.9)で表される．

$$\hat{T}_{k+1+} = \hat{T} - T_{-k} \quad (4.9)$$

4.3.2 分析対象経路とデータの概要

分析の対象とする経路は，名古屋空港から名古屋駅へ向かう OD ペアで利用される代表的な 2 経路とする．これらの経路は，必ずしも名古屋空港前や名古屋駅前の同一地点（ノード）に発着しているわけではない．通常すべてのトリップが必ず同じ起終点ノードを持つとは限らないため，多くのトリップが利用する区間を経路として扱うことで分析を進める．対象とする 2 経路はそれぞれ高速道路，一般道路のみにより構成される（図 4-8）．

高速道路経路は名古屋高速道路楠 JCT を起点とし，錦橋出口に至る全長 12.5km の経路である．起点に流入後すぐに楠料金所があり，順に黒川出入口，東片端 JCT，東新町出入口，丸田町 JCT，鶴舞南 JCT，東別院出入口，新洲崎 JCT という 3 つの出入口と 4 つのジャンクションを通過する．名古屋高速道路を利用して名古屋空港から名古屋駅に向かう車両は，大半がこのルートを利用している．

一般道路経路は，名古屋市北区大我麻町交差点を起点とし，国道 41 号線，環状線，大津通，出来町通，国道 22 号を経由して中区愛知県図書館前に至る全長 7.1km の経路であり，経路上には 4 度の右左折が存在する．一般道を経由して名古屋空港から名古屋駅に向かう経路はかなり多彩であるが，プローブカーが走行する一般道経路の中で最も多く利用されていたためこの経路を採用した．

各経路の走行距離 - 累積旅行時間推移のサンプルを図 4-9 に示す．サンプルは実験期間中の平日に収集されたそれぞれ 10 サンプルである．高速道路経路と比較して，一般道路経路では速度変化が激しいことが分かる．



図 4-8 分析対象経路




図 4-9 走行距離 - 旅行時間の関係

各経路の走行データは，実験期間中の平日を通して高速道路経路が 915 トリップ，一般道路経路が 207 トリップであった．図 4-10 は，観測されたトリップ数と平均旅行時間を対象経路への流入時刻別に示している．平均旅行時間は 9:00 ~ 17:00 において，どちらの経路もそれほど大きな変化はなく，また 18:00 ~ 23:00 の旅行時間もそれほど大きな変化は見られない．しかし，トリップ数に関しては，本研究で用いたプローブカーデータがタクシーから取得され，また対象とする経路が主に名古屋空港から名古屋駅に向かうトリップに利用されるため，夜間のトリップが多くなっていることが分かる．




図 4-10 時刻別トリップ数と平均旅行時間（平日）

道路ネットワーク上の交通状況の変化（走行速度の変化など）は，時刻によって特徴づけられる．例えば，上流区間は 1 日を通じて走行速度の変化が非常に少なく，下流区間は朝のピーク時と夕方のピーク時では交通の重方向率が逆転し，走行速度が著しく変化する場合を考える．このとき，上流区間を通過した際の走行状況に関する情報のみからでは，下流区間でどのような交通状況に遭遇するかを予測することは困難である．したがって，対象経路上で観測されたデータすべてを用いるよりも，ある程度同様の交通状況変化が発生する時間帯に観測されたデータのみを用いる方が予測精度が高くなると考えられる．




図 4-11 高速道路経路における区間別平均旅行速度

図 4-11 は，高速道路経路（経路長：12.5km）を 1km 間隔で区切った 13 区間（最後の 1 区間は 0.5km とする）について，時刻別の旅行速度を示している．高速道路経路は起点から約 8km 以降において都心環状線に合流するため，ジャンクションの分合流により速度変化が著しいこ

とが分かる．しかし，19 時台から 23 時台の各区分における平均速度の推移は比較的類似している．つまり，この 5 時間帯を 1 つの時間帯として扱うことで，より精度の高い分析が可能となると考えられる．また図 4-10 より，19 時～23 時台は観測トリップ数も多く，分析を行うためには適した時間帯であるといえる．同様に，一般道路経路では 18 時台から 22 時台までに観測されたデータを用いるものとする．

表 4-5 に，対象とする時間帯に観測されたデータ数を示す．

表 4-5 分析用データの概要

	観測データ数	対象時間帯	分析用データ数
高速道路経路	915	19:00 0:00	456
一般道路経路	207	18:00 23:00	131

4.3.3 予測旅行時間更新精度の検証

ここでは，4.3.1 で示した本研究で提案する旅行時間更新手法 A～D と比較のための手法 E～G を用いて，その予測更新精度を検証する．予測更新シミュレーションは，分析用データから 1 サンプルを抽出してこれを情報提供対象トリップとし，残りのデータを蓄積データとして分析データ数だけ予測更新計算を繰り返すことで行った．ここで，分析用データのサンプル数を $N+1$ と表す．

検証にあたって，精度指標を定める必要がある．本研究では，Chen (2001) が旅行時間予測において用いた $MARE$ (Mean Absolute Relative Error) を用いる．ここで k 区間走行後の $MARE_k$ は次式で算出される．

$$MARE_k = \frac{1}{N+1} \sum_{n=1}^{N+1} \frac{|T_{k+1+}^{(n)} - \hat{T}_{k+1+}^{(n)}|}{T_{k+1+}^{(n)}} \quad (5.10)$$

ここに，添え字 k は各予測更新を行う地点を， (n) は抽出したトリップのサンプル番号を表す．

ここで，手法 A および手法 B において類似度の高いデータを抽出する際に使用する， N' および N'' を決定する必要がある．そこで，高速道路経路における起点から 4000m 地点において，手法 A を用いて $N'=1, 10, 20, 30, 40, 455$ (全て) とし，それぞれの $MARE$ を算出した．算出した結果を表 4-6 に示す．

この結果より N' が 30 のときの $MARE$ が小さく，予測更新精度が高くなっていることが分かる．つまり，予測地点前の速度の類似性から旅行時間予測をするには，より類似している 30

データを使用することでより精度よく残り区間の旅行時間を更新できることを示している。これは、類似度上位 30 位を境にして、その先の旅行時間の似ている / 似ていないが分かれ、旅行時間予測にとってより良い取捨ができたためである。しかし、予測更新精度は N' が 10~40 においてそれほど変化は見られない。これは、蓄積データに含まれるトリップ数がそれほど多くはないことや、類似したサンプルが蓄積データ内に多く含まれているためであると考えられる。手法 B による予測も蓄積データから類似度の高いデータを抽出する点では手法 A と同じであり、ここでは簡単のため N' 、 N'' とともに 30 として分析を進める。

表 4-6 N の違いによる MARE の変化

N'	1	10	20	30	40	455
MARE	0.0428	0.0334	0.0326	0.0323	0.0325	0.0682

予測更新を行う地点は、対象経路を等間隔に分割した際の分割地点とする。対象経路の区間数は、高速道路経路は 12 (区間距離: 1km)、一般道路経路が 13 (区間距離: 0.5km) とした。表 4-7 に、高速道路経路、一般道路経路での予測更新結果を示す。

蓄積データと経験データをともに用いる手法 A~D は、ほとんどの場合においてどちらかしが用いない、もしくはどちらも用いない手法 E~G より精度が高くなっている。したがって、経験データと蓄積データをともに用いることで、トリップ途中で行う予測更新の精度が向上することが分かる。また、一般道路での予測更新精度は高速道路での予測更新精度より低くなっており、一般道路のような速度変化が多様な区間では精度向上が難しいことが分かる。

統計的指標を用いた手法 C、D は、蓄積データを個別に扱う手法 A、B より精度が低くなっている。したがって、蓄積データを集計することで各区間前後の相関関係を用いるよりも、集計せず非集計的に蓄積データを扱う方がより高い精度で予測更新を行うことができる。これは、手法 C、D は集計された蓄積データを用いるのに対して、手法 A、B は蓄積データから経験データとの類似性の高い、限られた数のデータのみを予測に用いるためであると考えられる。例えば、事故や激しい渋滞などの異常時では、そのようなデータが十分に蓄積されていない場合には統計的手法では予測更新精度が高くならないと考えられる。

また、統計的指標を用いる場合は区間の分割位置がその関係に大きく影響を与えられ、より適切な区間設定を検討する必要がある。本研究では、対象経路を等間隔に分割することで予測計算や予測更新地点を決定しているが、特に一般道路経路上では、主要な信号交差点位置などを考慮した分割地点の設定が、より予測更新精度を高めるものと考えられる。さらに、手法 D は予測区間を部分的に通過したデータから蓄積データを作成することも可能であり、手法 C よりも詳細にデータを扱うことから、蓄積データをさらに増加させることで精度向上が見込めると考えられる。

表 4-7a 予測精度 $MARE_k$ の変化（高速道路経路）

予測更新地点（経路長：12.5km，区間数：12）							
手法	流入前	1km (k=1)	3km (k=3)	5km (k=5)	7km (k=7)	9km (k=9)	11km (k=11)
A	0.0731	0.0412	0.0347	0.0342	0.0378	0.0406	0.0530
B	0.0731	0.0419	0.0367	0.0343	0.0391	0.0436	0.0544
C	0.0731	0.0426	0.0406	0.0397	0.0398	0.0450	0.0560
D	0.0731	0.1200	0.0616	0.0563	0.0548	0.0423	0.1012
E	0.0731	0.1164	0.0631	0.0515	0.0548	0.0533	0.0619
F	0.0731	0.0729	0.0706	0.0662	0.0650	0.0696	0.0732
G	0.0731	0.0806	0.0978	0.1233	0.1640	0.2577	0.6091

サンプル数：456

表 4-7b 予測精度 $MARE_k$ の変化（一般道路経路）

予測更新地点（経路長：7.1km，区間数：13）							
手法	流入前	1km (k=2)	2km (k=4)	3km (k=6)	4km (k=8)	5km (k=10)	6km (k=12)
A	0.0710	0.0713	0.0776	0.0934	0.1252	0.1887	0.2192
B	0.0710	0.0685	0.0769	0.0923	0.1273	0.1926	0.2187
C	0.0710	0.0747	0.0790	0.0938	0.1270	0.1948	0.2210
D	0.0710	0.0729	0.0856	0.1008	0.1273	0.2100	0.2706
E	0.0710	0.2192	0.2556	0.2328	0.1677	0.2463	0.3697
F	0.0710	0.0743	0.0787	0.0931	0.1273	0.1932	0.2193
G	0.0710	0.0829	0.0940	0.1145	0.1653	0.2852	0.6170

サンプル数：131

4.4 本章のまとめ

本章では，プローブカーデータを用いた旅行時間予測手法の開発を行い，また予測された経路上を走行する車両の走行状況データを用いて，残り区間の通過に要する旅行時間の修正手法を開発した．

起点における旅行時間予測手法については，蓄積されたプローブカーデータであるリンクコストテーブルを有効に用いることで事後的にも最短となる経路の探索アルゴリズムを開発し，さらにはその有効性の検証を行った．この結果，開発されたアルゴリズムはリンクコストテーブルの読み込みにおいて比較的長い計算時間を要するものの，2～3 万リンクを含む大規模なネ

ットワークを用いる場合においても，探索計算には通常の Dijkstra 法と比較してほぼ同様の計算時間（CPU 時間）であることを示した．また，開発した予測手法は出発時刻の交通状況のみを考慮した場合よりも，交通状況の変化の激しい昼間時において予測精度が高くなることを示した．さらに，出発後の交通状況の変化を考慮しない予測旅行時間は，特に交通状況の変化が激しい場合には予測誤差が大きく，提供される情報としては適切ではないことを示した．

しかし，リンクコストテーブルを用いた予測手法では，交通状況の平均的な変化とドライバーの平均的な走行を仮定した場合にのみ適用可能である．実際の交通状況は平均的な変化の回りを分布しており，またドライバーの走行特性も個人ごとにばらついている．したがって，起点においてドライバーに一旦は提供された予測旅行時間は，走行中の交通状況の変化やドライバーの走行特性により，長距離の経路では誤差が大きくなってしまう．プローブカーデータは，走行中の走行速度や停止回数などを分析者に提供し，またこれらは交通状況やドライバーの走行特性を示す情報でもある．そこで，これらの情報を用いることでトリップ中に残り区間の走行に要する予測旅行時間を更新するための手法を開発し，その有効性を検証した．蓄積されたデータを非集計的に用いる手法と集計的に用いる手法では，蓄積データ数がそれほど多くない段階においては，特異な交通状況の発生を的確に予測に反映しうる非集計的な蓄積データの扱いが高い予測更新精度を示すことが明らかとなった．

しかし，ここで開発した手法により探索される経路は，細街路を多く通過したり，右左折が非常に多い経路を探索するなど問題点も多い．このためには，右左折コストを考慮したり，起点と終点付近においては細街路を利用し，それ以外においては幹線道路を利用するなど階層的なネットワークの取り扱いが必要となる．丹羽ら（1990）らは同様の考え方に基づいた階層的な経路探索アルゴリズムを示しているし，大西・加藤（1992）は右左折コストを用いた経路探索手法を提案している．今後は，旅行時間情報として実際に提供可能な経路，旅行時間を算出するための探索アルゴリズムを開発する必要がある．

また，起点における旅行時間予測においては，リアルタイム情報を用いたより精度の高い予測手法の開発が挙げられる．例えば，路上工事などにより平常時よりも通過旅行時間が大きな区間は毎日どこかに存在しており，これらを考慮することでより実用性の高い予測が行えると考えられる．さらに，道路ネットワーク上に存在する信号のオフセットの影響を考慮することで，より精度の高い予測が可能となると考えられる．また，経路途上での予測更新においては，信号交差点位置やジャンクション位置などを考慮して，経路の分割位置をより適切に設定することで予測精度が向上すると考えられる．さらに，Zhang and Rice (2003) は旅行時間予測計算において明示的にタイムラグを考慮している．この場合のタイムラグとはデータ収集から予測旅行時間提供までの分析に要する時間のことを指し，予測値計算中に車両が走行する距離や時間を考慮することでより汎用性の高い予測手法となると考えられる．

本章で示した旅行時間予測手法やトリップ中の走行状況の取り扱いは，次章での経路選択行動分析と大きな係わりを持つ．経路選択モデルにより経路選択行動を分析する際には，ドライ

パーが実際に選択した経路のみではなく、選択されなかった経路の旅行時間情報を作成する必要がある。本章で示した旅行時間予測手法は、このような経路選択分析における LOS (level of service) データ作成段階で利用可能である。また、トリップ中の交通状況の取り扱いは、動的な経路選択モデルの分析において有用な技術となる。

第 4 章 参考文献

- 飯田恭敬，内田敬，宇野伸宏（1990）通勤者の旅行時間予測機構に関する実験分析，土木計画学研究・講演集，No.13，pp.335-341．
- 飯田恭敬，内田敬，山本政博，村田重雄（1991）実験アプローチによる動的経路選択行動のモデル化，土木計画学研究・講演集，No.14（1），pp.271-278．
- 井上博司，湯川亮達（1996）高速道路の旅行時間予測に関する研究，土木学会第 51 回年次学術講演会講演概要集，pp.696-697．
- 上野秀樹，大場義和，桑原雅夫（2002）料金所データを用いた所要時間予測方法の比較，第 1 回 ITS シンポジウム 2002 Proceedings，pp.515-520．
- 大口敬，佐藤貴行，片倉正彦，鹿田成則（2002）交通情報にもとづく代替経路選択行動と交通渋滞の実態解析，第 1 回 ITS シンポジウム Proceedings，pp.585-590．
- 小川圭一（1999）交通情報の提供精度による経路選択行動への影響，第 3 回 ITS 研究ワークショップ．
- 岸野清孝，石田康，伏木匠，横田孝義（2003）トラックの運行管理のプロブカー情報を利用した所要時間予測，第 23 回交通工学研究発表会論文報告集，pp.141-144．
- 久保田尚，福山剛男，坂本邦宏（1999）くり返し走行実験による自動車運転者の経路選択機構とその変容に関する研究，土木計画学研究・論文集，No.16，pp.643-650．
- 小出勝亮，宮崎要，堀口良太，赤羽弘和（2004）VICS 情報とプローブ情報の融合手法の研究，土木計画学研究・講演集，Vol.30，CD-ROM．
- 小林潔司，井川修（1993）交通情報によるドライバーの経路誘導効果に関する研究，土木学会論文集，No.470 / -20，pp.185-194．
- 志水清孝（1976）システム最適化理論，コロナ社．
- 田中俊祐，小川圭一，宮城俊彦（2000）所要時間情報の不確実性による経路選択行動への影響に関する研究，土木計画学研究・論文集，No.17，pp.559-566．
- 中村英樹，王 鋭（2003）車両感知器とプローブデータを組み合わせた旅行時間推定手法の実証分析，第 2 回 ITS シンポジウム Proceedings，pp.283-288．
- 丹羽寿男，吉田雄二，福村晃夫（1990）道路網の階層的表現にもとづく経路探索アルゴリズムと地図情報システムへの応用，情報処理学会論文誌，Vol.31，No.5，pp.659-666．
- 林成卓，藤井聡，北村隆一，大窪剛文（1998）ドライバーの認知所要時間の確率構造に関する実証的研究，土木学会第 53 回年次学術講演会講演概要集，pp.652-653．
- 林良嗣，槇谷博光，大島邦彦，中村英夫（1983）大規模ネットワークにおける経路探索の簡略化手法に関する研究，土木学会論文報告集，第 338 号．
- 藤井聡，中野雅也，北村隆一，杉山守久（2000）認知旅行時間の環境適応プロセスに関する理論実証研究，土木計画学研究・論文集，No.17，pp.589-597．

- 舟橋賢二，西村茂樹，堀口良太，赤羽弘和，桑原雅夫，小根山裕之（2003）VICS 蓄積データを用いた旅行時間短期予測手法に関する研究，土木計画学研究・講演集，Vol.27，CD-ROM.
- 巻上安爾，竹上直輝，大塚浩司（1997）高速道路渋滞シミュレーションモデルを用いた旅行時間予測の基礎的研究，土木計画学研究・講演集，No.20（1），pp.473-476.
- 安井一彦，池之上慶一郎，深井靖史（1993）街路における旅行時間予測，土木計画学研究・論文集，No.11，pp.137-144.
- 山下智志，萩山実（1996）所要時間分布の学習過程を内包した経路選択モデル，土木計画学研究・講演集，No.19（2），pp.757-748.
- 若尾将徳，谷口綾子，中辻隆（1997）高速道路における旅行時間予測に関する研究，土木計画学研究・講演集，No.20（1），pp.477-480.
- 割田博，森田綽之，桑原雅夫，田中淳（2003）統計的手法による所要時間情報提供に関する研究，第2回 ITS シンポジウム 2003 proceedings, pp.215-220.
- Bajwa, S., E. Chung, M. Kuwahara (2002) Travel Time Prediction on Expressways using Traffic Detectors, Proceedings of Infrastructure Planning, Vol.26, CD-ROM.
- Bajwa, S., E. Chung and M. Kuwahara (2003) Sensitivity Analysis of short-term travel time prediction model's parameters, Proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM.
- Chen, M. and S. Chien (2001) Dynamic Freeway Travel Time Prediction Using Probe Vehicle Data: Link-based vs. Path-based, Transportation Research Board 80th Annual Meeting, CD-ROM.
- Nakata, T. and J. Takeuchi (2004) Mining traffic data from probe-car system for travel time prediction, Proceedings of the 2004 ACM SIGKDD international conference on Knowledge discovery and data mining, pp.817-822.
- Nanthawichit, C., T. Nakatsuji and H. Suzuki (2003) Dynamic estimation of traffic states on a freeway using probe vehicle data, *J. Infrastructure Plan. And Man.*, No. 730 / -59, pp.43-54.
- Oguchi, T., T. Satoh, M. Katakura and S. Shikata (2003): Analysis of traffic congestion and route choice behavior influenced by traffic information, *International Journal of ITS Research*, Vol.1, No.1, pp.75-82.
- Sun, H., H.X. Liu, H. Xiao and B. Ran, (2003), Short Term Traffic Forecasting Using the Local Linear Regression Model, Transportation Research Board 82nd Annual Meeting, CD-ROM.
- Verplanken, B., H. Aarts and A. V. Knippenberg (1997) Habit, Information Acquisition, and the Process of Making Travel Mode Choices, *European Journal of Social Psychology*, No.27, pp539-560.
- Wang, R. and H. Nakamura (2003) Expressway Travel Time Estimation by Using the Combination of Detector and Probe Vehicle Data, proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM.
- Wu, C.H., C.C. Wei, D.C. Su, M.H. Chang and J.M. Ho, (2003) Travel Time Prediction with Support

Vector Regression , Proceedings of IEEE 6th International Conference on Intelligent Transportation Systems

Zhang, X. and J.A. Rice (2003) Short-term travel time prediction, *Transportation Research C* 11, pp. 187-210.

第5章 経路選択行動分析

ドライバーの経路選択行動の分析は、道路ネットワーク分析において重要な鍵となる作業であり、詳細な交通需要予測においては必要不可欠である。しかし、従来の経路選択行動分析の基本的なアプローチは、アンケート形式により収集された RP データ（Revealed Preference）や SP（Stated Preference）データを用いて経路選択モデルを作成するか（例えば、矢部ら，1994；Abdel-Aty et al., 1995；羽藤ら，1997；Bekhor et al., 2002），もしくはあらかじめ仮定した経路選択モデルを組み込んだ交通量配分手法や交通シミュレーションの予測結果が，現実ネットワーク上で観測されたリンク交通量にどの程度近づいたかにより評価され（例えば，桑原，1989；宮城ら，1989；溝上・松井，1990；溝上・松井，1993），現実の経路選択行動を観測・分析する作業はほとんど行われてこなかった。これは，ドライバーが実際に行っている経路選択行動を観測することは，極めて大きな費用と労力を要するためである。このため，経路選択実績や経路選択状況に関するデータも蓄積されておらず，詳細な経路選択行動や，さらにはこれまで需

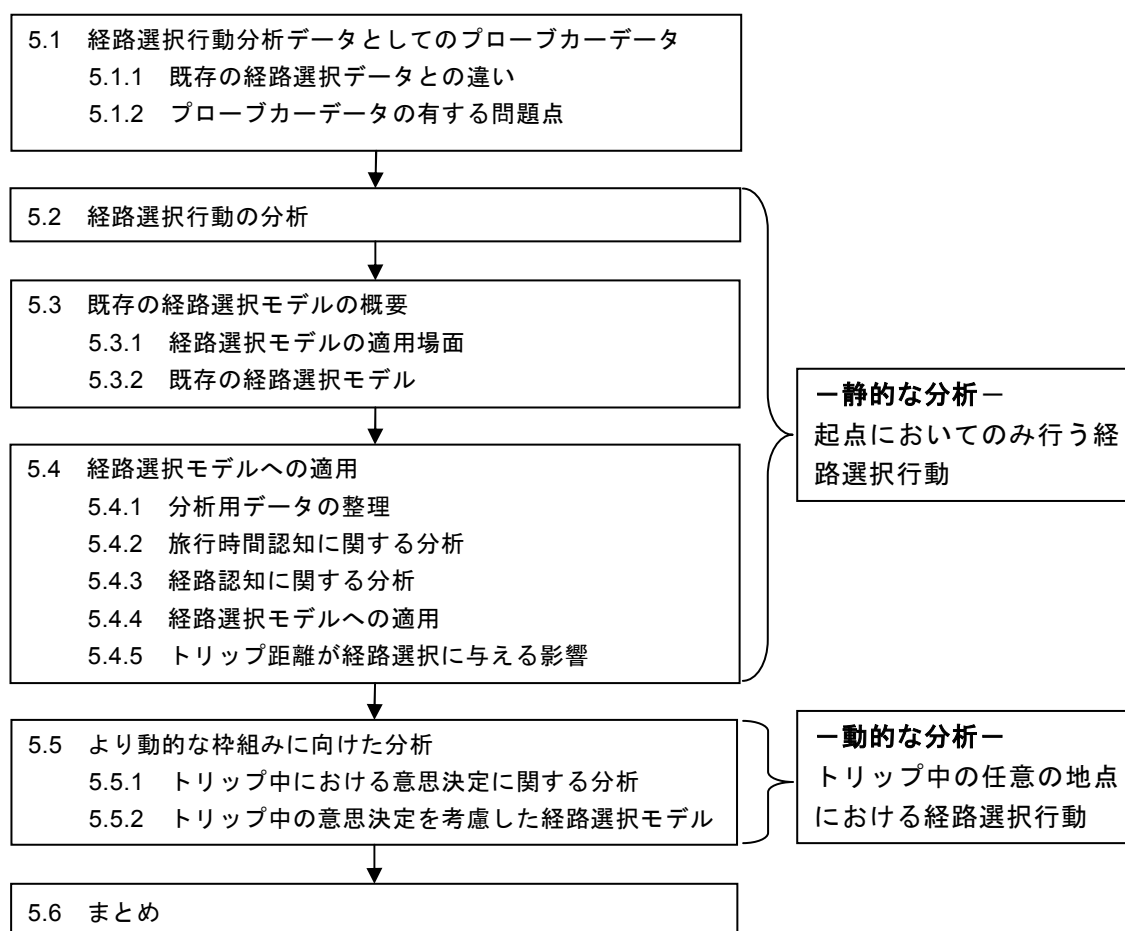


図 5-1 本章における経路選択行動の分析フロー

要予測ツールに組み込まれてきた経路選択モデルを、観測データから検証した例はほとんどない。プローブカーデータは、ドライバーが選択した経路とその経路上で経験した走行状況について、詳細な情報を分析者に提供することができる。そこで本章では、これまでは分析が困難であったより現実的なドライバーの経路選択行動を、プローブカーデータを用いて分析することを目的とする。

図 5-1 は、本章における経路選択行動分析の分析フローである。5.1 においては、プローブカーデータが経路選択行動分析用データとして使用される際の既存データとの違いをまとめ、プローブカーデータが有する問題点について述べる。5.2 では、交通状況を記述するための最も一般的な概念である Wordrop 均衡について、その成立の可否についての分析を行う。5.3 では、これまでに開発された多くの経路選択モデルについて、そのモデル構造や理論的背景について概説する。5.4 では、プローブカーデータを既存の経路選択モデルに適用し、それらの再現性やドライバーの経路選択行動について分析を行い、さらにトリップ距離の変化が経路選択行動に与える影響を分析する。5.5 では、トリップ中の意思決定発生について検証を行い、意思決定発生時点を内生化した経路選択モデルを提案する。ここで、5.2 から 5.4 までの分析では従来の交通需要予測ツールで一般的に用いられてきた静的な分析、すなわち起点において終点までの詳細な経路を一度に選択する行動を取り扱い、5.5 では動的な分析、すなわちドライバーの走行位置を固定しない経路選択行動を取り扱う。

5.1 経路選択行動分析データとしてのプローブカーデータ

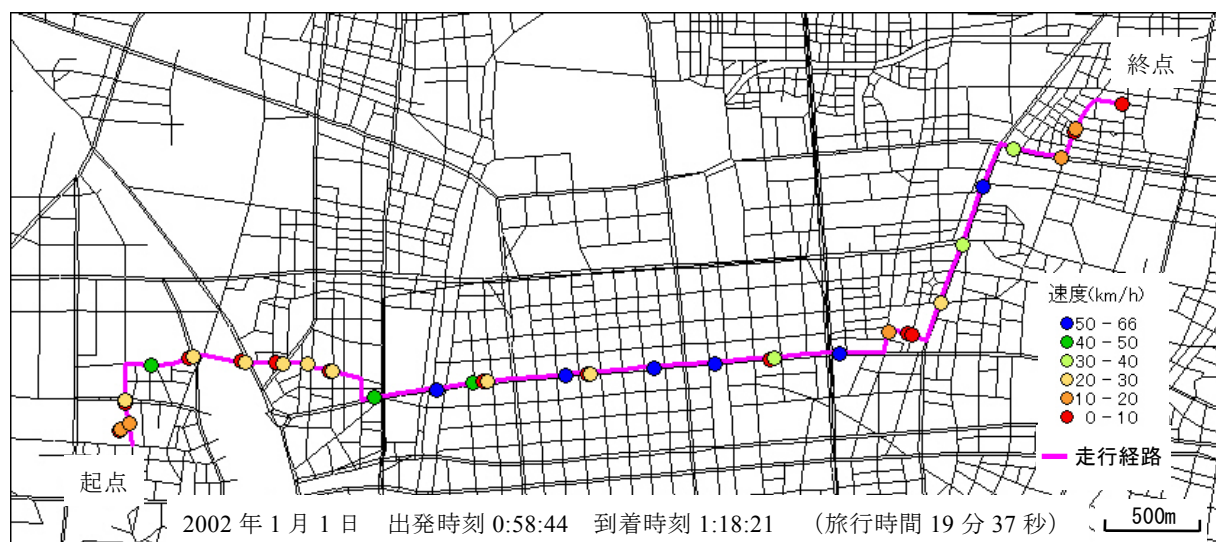
5.1.1 既存の経路選択データとの違い

これまでの道路ネットワーク上の経路選択行動分析は、アンケート形式により収集された RP データや SP データを用いるものが多い。しかし、このようにして収集されたデータは、普段利用している経路やその代替経路に関する情報、もしくは想定された交通状況下においてドライバーが走行するであろう経路についての情報のみを知ることができ、走行中に経験した情報（停止回数や走行速度など）については知ることができない。また、分析を行おうとする際に重要となる旅行時間情報や、さらには走行経路でさえも被験者の記憶に基づくあいまいな情報を用いるか、道路交通センサスなどの交通データを用いて平均的な交通状況を基に作成してきた。このような問題を解決するため、被験者となるドライバーが運転する車両に調査員が同乗し、走行中の情報を収集しようとする試みもなされている（久保田ら，1999）。確かに、このような方法を用いれば、走行経路や旅行時間、出発時刻等の情報を正確に収集でき、また走行中にドライバーが経験した情報についても収集可能となるが、多くの分析データを確保することは困難であり、収集されたデータを電子データに変換する際の労力が大きい。

図 5-2 は、プローブカーデータにより取得されたトリップデータである。このトリップでは

トリップ中に 11 回の停止を経験しており，最高で 66km/h の走行速度を経験している．このように，走行中にドライバーが経験した交通状況についても詳細な情報を得ることができる．さらに，プローブカーデータからは膨大なトリップデータを収集することが可能であり，これらを DRM 上に経路データとして変換するための技術も第 3 章で既に開発されている．また，第 3 章で提案したリンクコストテーブルや第 4 章で開発した旅行時間予測手法は，経路選択モデルを用いた分析に必要な代替経路の旅行時間情報を作成する際に用いることができる．これらの技術により，あらゆる OD ペア，時間帯において経路選択行動の分析が可能となる．

このように，プローブカーデータは膨大な経路選択実績データとして非常に有用であり，これまでの経路選択行動分析において使用されてきたデータからは得ることのできない，さまざまな新しい知見を与えられられる．



トリップ中の最高速度：66km/h 停止回数：11 回

図 5-2 プローブカーデータによる走行中の経験情報

5.1.2 プローブカーデータの有する問題点

一方で，プローブカーデータには経路選択行動を分析する上での問題点もある．経路選択行動の分析には，個人属性が重要な役割を果たす．これまでの研究でもドライバーの個人属性を分析に用いることで，経路選択行動における様々な有用な知見が得られている（例えば，矢部ら，1994；藤井ら，1998；Srinivasan and Mahmassani, 2001）．しかし第 2 章でも述べたように，プローブカーデータは実験期間中に発生したトリップについて詳細な起終点や走行経路の情報を得ることができる反面，ドライバーの個人情報を収集することはプライバシーの問題により一般的には難しい．このため，これまで行われてきた多くの実験がそうであるように，タクシーやバス，トラックなどの非一般車両をプローブカーとして利用せざるをえず，本研究で使用するデータもタクシーをプローブカーとしている．タクシードライバーは一般のドライバーと

はネットワーク認知や経路選択行動が異なっていると考えられ、汎用性のある経路選択モデルの作成が困難である。その一方で、一般のドライバー等に協力を得て交通行動データを収集する実験も行われているが（古屋ら，2003），長い実験期間を通じて多くのデータを収集することは困難である。

プローブカーデータにより経路選択行動を分析するに当たっての、もう一つの大きな問題としては利用可能経路集合の取り扱い方法が挙げられる。アンケート調査により経路選択行動を分析しようとする際には、代替経路についての質問を加えることが一般的である。しかし、プローブカーデータからは最終的に走行した経路についての情報しか得られないため、ドライバーがどのような利用可能経路集合を認知していたかについての情報は得られない。意思決定者が認知する選択肢集合の問題は、経路選択問題意外においても多く取り上げられており、各選択肢の属性や選択者の個人属性を用いて個人が認知する選択肢集合を内生的に扱う方法や（森川ら，1991；Ben-Akiva and Boccara, 1995; Horowitz and Louviere, 1995; Swait, 2001），個人の選択肢集合を選別するモデル（福田・森地，2002）などが提案されている。しかし、これらはいずれも交通機関選択や目的地選択など、選択肢の最大数が限られた問題に対して適用されている。経路選択問題では、利用可能経路が膨大な数に上る。この問題を解決するために、Screening 法を用いて選択肢集合を生成する方法（眞浦ら，1999；大草・朝倉，2000）や、リンク属性を用いて経路コストを修正した上で最短経路探索により生成する方法（Bekhor et al., 2002），経路認知確率を用いて経路効用を修正する方法（Cascetta et al., 2002），認知ネットワークを作成した上で利用可能経路を抽出する方法（羽藤・朝倉，1999）などが提案されている。しかし、いずれの方法においても個人属性を用いているか、もしくは選択肢集合の生成に大きな労力を費やすものである。また、OD ペアごとに利用可能経路は異なるため、分析対象とするすべての OD ペアごとに選択肢集合を作成する必要がある。この問題に対して、本研究では一貫して観測された経路を利用可能経路集合として扱うものとする。もちろん、各ドライバーが観測された全ての経路を認知しており、この集合から利用経路を選択しているとは考えにくい。しかし、均衡配分や交通シミュレーションでは、交通量をネットワーク上に負荷する際に Dial のアルゴリズムを用いることが多く、この方法における利用可能経路集合は、後戻りのない全ての経路を対象とすることになる（Dial, 1971）。したがって、本研究で得られる知見は、ごく一般的な交通需要予測ツールへの適用において十分に有用であると考えられる。

最後に、本研究で行う分析には実車中のデータのみを用いることは第2章で既に述べた。乗客を乗せたタクシーは明確な目的地を持ち到着時刻に対して敏感であると考えられ、経路選択行動を分析するデータとして適している。ここで、乗客を乗せたタクシーの経路選択に関する意思決定は基本的にはタクシードライバーが行うものとする。しかし、高速道路を利用するかどうかなどの特別な意思決定に際しては、乗客の意向を踏まえた上で決定していると考えられる。

このように、プローブカーデータにより経路選択行動を分析する際には、様々な点で注意が必要である。

5.2 経路選択行動の基礎分析

現実の交通状況を表現する最も一般的な概念は利用者均衡の概念であり，“Wardrop の第一原則”として広く知られている（土木学会編，1998）．これは，「利用される経路の旅行時間は皆等しく，利用されない経路の旅行時間よりも小さいか，せいぜい等しい」と定義されている（Wardrop, 1952）．プローブカーデータを用いれば，この概念を検証することが可能である．そこで，名古屋空港－名古屋駅間のトリップを対象として，利用経路とその旅行時間について分析を行った．分析対象エリアを図 5-3 に示す．



図 5-3 名古屋空港－名古屋駅間の選択可能経路（代表区間）

表 5-1 名古屋駅－名古屋空港間の利用可能経路（代表区間）

経路 No.	路線名	利用料金
1	枇杷島橋：（主）名古屋祖父江線	—
2	新名西橋：国道 22 号	—
3	庄内川橋：（主）名古屋江南線	—
4	新川中橋：国道 41 号	—
5	名古屋高速楠線	650 円
6	水分橋：（県）名古屋犬山線	—

OD 間距離は経路によっても異なるが，およそ 12～16km である．もちろん，OD 間には膨

大な利用可能経路が存在することは言うまでもないが、いずれの経路も表 5-1 に示す 6 つの橋のいずれかを通過しなければならない。このうちの 1 つは名古屋高速道路であり、通過するためには利用料金（650 円）が必要である。また、これらの橋はボトルネックを形成しており、全ての経路における代表区間として捉えることができる。したがってここでの分析は、ドライバーの時々刻々と変化する交通状況下における、ボトルネック選択であるとも捉えられる。

第 1 期実験期間中の平日に収集されたプローブカーデータより、これら経路（各代表区間を通過した経路集合）のピーク・オフピーク時間帯別（朝ピーク：7:00～9:00，昼オフピーク：9:00～17:00，タピーク：17:00～19:00，夜オフピーク：19:00～7:00）選択結果を表 5-2 に示す。表より、下り方向（名古屋駅→空港）の昼オフピーク，夜オフピーク時間帯を除けば、全ての時間帯で名古屋高速道路が最も利用されていることが分かる。下り方向においては、主に名古屋高速と国道 41 号が利用されている。これら 2 経路の所要時間差はいずれの時間帯においても約 7～11 分程度であり、名古屋高速の利用料金が 650 円であることから、下り方向における時間価値は 60～90 円/台分程度となる。これは実務において用いられる車種別時間価値（乗用車 54.3 円/台分，普通貨物車 97.29 円/台分，小型貨物 85.68 円/台分）（全国道路利用者会議，2002）と比較しても妥当な値といえる。その一方で上り方向（空港→名古屋駅）においては、高速道路利用経路が名古屋高速都心環状線の供用形態により迂回するような経路であるため、国道 41 号と比較して平均走行距離が 1～3km 程度長くなる。この結果、朝ピーク時間帯ではわずかではあるが国道 41 号より遅い経路となり、その他の時間帯においてもせいぜい 5 分程度の短縮しか起こらない。それにもかかわらず、名古屋高速を利用するルートは全ての時間帯において最も利用されており、下り方向とは異なった経路選択特性を示している。一般道において利用されているルートのみを見ると、ほとんどの車両が国道 41 号もしくは国道 22 号を利用しており、2 ルートの所要時間差はいずれの時間帯においてもそれほど大きくない。しかし、朝ピーク時間帯の庄内川橋ルートのように、トリップ数は少ないがそれらの所要時間が国道ルートより短い場合もみられる。これら結果より、現実のドライバーは上り方向では都市高速道路を過大評価する傾向がうかがわれ、上り方向と下り方向で異なる経路選択規範を使用しているか、もしくは交通状況の違いを十分には把握していないと考えられる。

平常時における交通状況は均衡状態にあると仮定される場合が多く、利用されるいずれの経路も同じ所要時間となると仮定されている。しかし以上の分析により、ドライバーは高速利用料金を支払い、より所要時間の要する名古屋高速ルートを利用している状況から、一般的に仮定されるような旅行時間に基づく利用者均衡状態が成立していない可能性があることが示された。しかし、現実の経路選択行動はさらに複雑な分析を必要とする。ここでは、代表区間のみに着目して分析を行ったが、同一の代表区間を通過する経路においても右左折回数や幹線道路構成比率は異なる。また、ここでの分析には近接リンク法によりプローブカーデータに付加された情報を用いた。以降の節では、マップマッチング処理されたデータを用いて、より詳細な経路選択行動の分析を行う。

表 5-2 経路選択結果と経路旅行時間

名古屋駅 → 名古屋空港

朝ピーク (7:00-9:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	0	--	--	--
2	0	--	--	--
3	2	25.9	1.1	12.2
4	66	34.3	7.7	13.0
5	122	23.7	5.4	13.6
6	0	--	--	--

昼オフピーク (9:00-17:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	1	35.3	0.0	13.2
2	0	--	--	--
3	6	33.1	3.3	13.0
4	181	34.4	4.4	13.3
5	160	23.1	5.5	13.6
6	1	50.2	0.0	13.4

タピーク (17:00-19:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	0	--	--	--
2	0	--	--	--
3	1	42.7	0.0	13.5
4	10	33.7	6.7	11.4
5	34	22.5	4.7	13.5
6	1	43.3	0.0	13.8

夜オフピーク (19:00-7:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	1	31.7	0.0	15.8
2	1	26.5	0.0	14.2
3	1	31.7	0.0	13.6
4	52	29.7	4.1	12.7
5	32	23.1	5.1	13.7
6	0	--	--	--

名古屋空港 → 名古屋駅

朝ピーク (7:00-9:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	0	--	--	--
2	4	29.2	5.2	14.3
3	0	--	--	--
4	12	29.5	4.2	13.4
5	22	29.7	6.9	15.9
6	0	--	--	--

昼オフピーク (9:00-17:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	1	32.1	0.0	13.5
2	63	32.6	4.2	14.2
3	3	35.1	4.0	13.6
4	243	34.7	5.0	13.5
5	304	28.9	5.8	16.5
6	0	--	--	--

タピーク (17:00-19:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	0	--	--	--
2	18	37.0	4.8	14.5
3	0	--	--	--
4	71	32.9	6.1	14.2
5	96	31.4	6.4	16.8
6	0	--	--	--

夜オフピーク (19:00-7:00)

No.	トリップ数	平均旅行時間(分)	標準偏差	平均経路長 (km)
1	0	--	--	--
2	100	30.7	4.1	14.3
3	2	24.6	1.5	12.9
4	282	31.6	4.6	13.7
5	371	26.2	4.8	16.8
6	2	43.0	9.8	15.8

5.3 既存の経路選択モデルの概要

5.3.1 経路選択モデルの適用場面

交通量配分などの道路ネットワーク上の需要予測において、経路選択モデルは道路ネットワーク上に存在する全てのリンクの交通量を、与えられた OD 交通量から算出するために用いられており、均衡配分や交通シミュレーションの枠組みで広く取り入れられてきた。均衡配分モデルは、全国規模や地方圏などの広域な道路ネットワークとそれに対応した OD 交通量を与件として、既存路線の改修や新規路線の建設に向けた検討のために用いられる。算出される交通量は、平均的な 1 日における各リンクの日交通量や時間帯別交通量である。特に、確率的均衡配分モデルは、ドライバーの認知誤差を伴う経路選択行動を前提として、ネットワーク上の全てのリンクに交通量を配分（割り当て）するものであり、近年では実務においても用いられ始めた。均衡配分モデルでは数万に及ぶリンクを対象とすることも多く、交通量負荷における効率的な計算アルゴリズムが必要である。Dial のアルゴリズムは、ドライバーの経路選択行動が Multinomial Logit モデルで表現できるとした場合に、非常に効率的に交通量負荷が可能であり、現在最も一般的に用いられている。さらに、均衡配分モデルでは高速利用選択モデル（高速転換率モデル）や機関選択モデルから分布・発生にいたるまでの各モデルを、理論的に統合したモデル化と配分計算が可能であるため、これらを統合したモデルを用いてさまざまな分析が行われている（例えば、Fernandez and Cea, 1995；宮城・水口，1995；円山ら，2002）。

均衡配分における経路選択行動モデルは、起点において終点までの詳細な経路を一度に選択する行動を表現するものであり、Dial のアルゴリズムを用いる多くの配分モデルでは、ドライバーは膨大な数に上るすべての利用可能経路から利用経路を選択すると仮定している。また、均衡配分モデルにおいて経路選択モデルに導入される説明変数は旅行時間のみ（もしくは一般化費用のみ）であることが多く、この場合に経路選択モデルに導入されるパラメータはスケールパラメータのみとなる。このスケールパラメータは現実の交通状況を最も精度良く再現する値に設定されることが多く、現実の経路選択行動を分析した上で設定されることはほとんどない。一方、交通シミュレーションは、地区レベルや高速道路ネットワークなど比較的小規模なネットワークを対象として、時々刻々と変化する交通状況を再現しようとするものである。モデルによって車両やその行動の取り扱いに違いはあるものの、経路選択行動を扱う上ではそれほど大きな違いは見られない。これらのモデルでは、起点において終点までの詳細な経路を選択するか、もしくは到着するノードごとや一定の時間間隔に、起点においてと同一の選択モデルにより終点までの経路選択を繰り返すことになる。交通シミュレーションが適用される場面では、対象とするネットワークの規模が比較的小さく、利用可能経路集合を後戻りのない全ての経路としてもそれほど多くはならない。また、到着ノードごとに経路選択を繰り返す場合においては、各ノードから全ての終点までの利用可能経路を設定することには大きな労力を要するため、Dial のアルゴリズムを援用して流出リンクの選択確率を算出し、モンテカルロシミュ

ュレーションを用いて経路選択行動を表現することになる（交通工学研究会編，2000）．

トリップ中の経路選択行動発生メカニズムを解明しようとする研究（森津・中島，1997；久保ら，1996；Srinivasan and Mahmassani, 2003）や，走行中の経験による交通状況や経路旅行時間認知の変化についての分析（林ら，1998），さらには提供された情報の獲得・参照過程を考慮した経路選択行動の分析（羽藤ら，1998；平井ら，1999；羽藤ら，2000）などが目指す，より詳細な記述を行う交通シミュレーションの役割は大きい．今後一般的に導入されるであろう，ATIS（Advanced Traveler Information Systems）の導入効果を分析するためには，より動的な枠組みで経路選択行動は分析されるべきである．しかしこれらの研究は，室内実験や簡易なネットワークを用いて分析される場合が多く，現実の経路選択データからシミュレーションに導入された例はほとんどない．

5.3.2 既存の経路選択モデル

ドライバーの経路選択行動を記述する最も基本的な概念は，「ドライバーは必ず最小一般化費用経路（最大の効用を与える経路）を選択する」というものである．大規模なネットワークを対象としても，経路効用がリンク効用の総和で表現できれば，最小一般化費用経路を探索することは Dijkstra 法を用いれば容易に実行可能である．このため，ドライバーの認知誤差の影響を考慮しない確定的均衡配分理論において広く用いられている．しかし，OD ペア間には膨大な数の利用可能経路が存在し，ドライバーが常に最短経路を選択できるとは考えにくい．このため，さまざまな経路選択モデルが開発されてきた．

これまでに開発された経路選択モデルは，Multinomial Logit モデル（以降，MNL モデルと称す）をはじめとする離散選択モデルが多い．これは意思決定者が自らの効用を最大化する，いわゆる効用最大化理論を背景とする一連のモデルである．これまでに経路選択モデルは数多く開発されており，すでにこれらを体系的にまとめた論文も発表されている（兵藤・室町，2001；羽藤，2002）．開発されたモデルの多くは，MNL モデルでは表現できない，いわゆる「赤バス・青バス」問題に代表される選択肢間の類似性の相違を表現するものである．ここでは，これまでに開発された離散選択モデルのうち，経路選択モデルへの適用可能である代表的なモデルについて，そのモデル構造や適用例を踏まえつつ概説する．ただし，本研究の目的はプローブカーデータを用いてドライバーの経路選択行動を分析することであるため，モデルについての詳細な考察は行わない．

a) Multinomial Logit モデル

MNL モデルは，現在の交通量配分において最も利用される経路選択モデルである．このモデルは式(5.1)により表される．

$$P_k = \frac{\exp(\mu V_k)}{\sum_{k' \in R} \exp(\mu V_{k'})} \quad (5.1.a)$$

$$V_k = \sum_i \beta_i x_{k,i} \quad (5.1.b)$$

ここに、 P_k は経路 k を選択する確率、 R は利用可能経路集合、 μ はスケールパラメータ、 V_k は経路 k の効用の確定項、 β は未知パラメータ、 x は説明変数である。なお、意思決定者である個人を表す添え字は省略した。

前項でも述べたが、MNL は Dial のアルゴリズムにより容易に適用可能であるため、非常に多くの研究で用いられてきた。しかし、このモデルは各選択可能経路の誤差項が同一の分布を持ち、互いに独立である (identically and independently distributed; i.i.d) ことを仮定している。この仮定により導かれる IIA (independence from irrelevant alternatives) 特性は、選択肢間の独立性を意味する。しかし、OD 間に存在する多くの利用可能経路はそれぞれが重なり合っており、それらが完全に独立であるとは考えにくい。Multinomial Probit モデル (以降、MNP モデルと称す) は、誤差項に選択肢数の次元をもつ多変量正規分布を仮定するためこの問題を解決しうる。しかし、膨大な数の選択肢を持つ経路選択問題への適用は選択肢数の数だけの多重積分か、もしくはシミュレーション法による推定が必要となり (Train, 2003)、現実的には適用は困難である。Yai et al. (1997) は鉄道ネットワークにおいて、利用可能な各経路の共有区間距離で経路間の共分散を表現した構造化プロビットモデルを適用している。しかし、道路ネットワークは鉄道ネットワークと比較して遥かに複雑であり、利用可能な経路すべてを列挙することすら大きな労力を要する。このため、道路ネットワーク上の経路選択への適用は容易ではないと考えられる。

このような背景の下、以降に示すような IIA 特性の緩和を図った Logit タイプの経路選択モデルが多く開発されている。

b) Nested Logit モデル

Nested Logit モデル (以降、NL モデルと称す) は、MNL モデルにおける IIA 特性を緩和するモデルとして、経路選択問題においても多く用いられてきている。類似性の大きいと考えられる選択肢を同一グループとしてツリー構造を用いて記述する NL モデルは、均衡配分モデルにおいて高速道路転換率モデルとして頻繁に用いられてきており、これを組み込んだ統合型均衡配分モデルもこれまでに開発されてきている (例えば、三輪・森川, 2000)。NL モデルは以下の式で表される。

$$P_k = P_n \times P_{k|n} \quad (5.2.a)$$

$$P_{k|n} = \frac{\exp(\mu V_{n,k})}{\sum_{k' \in R_n} \exp(\mu V_{n,k'})} \quad (5.2.b)$$

$$P_n = \frac{\exp(V_n + \theta S_n)}{\sum_{n' \in R^A} \exp(V_{n'} + \theta S_{n'})} \quad (5.2.c)$$

$$S_n = \frac{1}{\mu} \ln \sum_{k' \in R_n} \exp(\mu V_{n,k'}) \quad (5.2.d)$$

ここに、 P_n はネスト n を選択する確率、 $V_{n,k}$ はネスト n に含まれる経路 k を選択することにより得られる効用の確定項、 R_n はネスト n に含まれる経路数、 V_n はネスト n を選択することのみについて得られる効用の確定項、 R_A はネストの集合、 θ は未知パラメータであり、仮定するネスト構造が正しい場合は 0 から 1 の間のパラメータとして推定される。

c) Paired Combinatorial Logit モデル

Paired Combinatorial Logit モデル（以降、PCL モデルと称す）は Chu (1989) により提案され、経路選択モデルとしての推定特性について、詳しく分析した研究も多く発表されている (Prashker and Bekhor, 1998; Gliebe et al., 1999; Koppelman and Wen, 2000)。MNL モデルが全ての選択肢間で誤差項の相関がないものと仮定し、NL モデルが異なるネストに含まれる選択肢間での相関はなく、同一ネストに含まれる選択肢間の相関はすべて等しいと仮定しているのに対して、PCL モデルは全ての選択肢ペアごとに異なる相関を取り入れている。このモデルにおいて、経路 k を選択する確率 P_k は以下の式で表される。

$$P_k = \frac{\sum_{j \neq k} e^{\mu V_k / (1 - \sigma_{kj})} (e^{\mu V_k / (1 - \sigma_{kj})} + e^{\mu V_j / (1 - \sigma_{kj})})^{-\sigma_{kj}}}{\sum_{l=1}^{R-1} \sum_{m=l+1}^R (e^{\mu V_l / (1 - \sigma_{lm})} + e^{\mu V_m / (1 - \sigma_{lm})})^{1 - \sigma_{lm}}} \quad (5.3)$$

ここに、 σ_{kj} は経路 k と j の類似性を示すパラメータであり、NL モデルの θ と同様に 0 から 1 に推定される必要がある。

PCL モデルでは、 σ_{kj} を 0 とすると MNL モデルに分解される。また、PCL モデルは NL モデルとは異なり、特定のネスト構造を仮定する必要がないためより柔軟なモデル構造であるといえる。ここで、 σ_{kj} は推定されるべきであるが、この場合 $R*(R-1)/2$ の数の類似度パラメータを推定することになってしまう。仮に 10 の選択肢が存在したとしても、類似度パラメータ数は 45 である。経路選択問題における利用可能経路数はさらに大きいことが多いため、類似度パラメータの構造化を行うことで計算負荷を軽減する必要がある。Gliebe et al. (1999) は、この間

題に対処するため σ_{kj} を次式のように構造化している.

$$\sigma_{ij} = \frac{L_{ij}}{L_i + L_j - L_{ij}} \quad (5.4)$$

ここに, L_i は経路 i の経路長 (もしくは経路旅行時間), L_{ij} は経路 i と経路 j の共有区間長 (もしくは共有区間の旅行時間) である.

d) Cross-Nested Logit モデル

Cross Nested Logit モデル (以降, CNL モデルと称す) は Vovsha (1997) により機関選択モデルを背景に開発され, その後 Vovsha and Bekhor (1998) により Link-Nested Logit モデル (以降 LNL モデルと称す) として経路選択問題へと適用された. CNL モデルでは各選択肢の複数のネストへの帰属が考慮されており, NL モデルをより一般化したモデルと考えることができる. LNL モデルにおいては, 上位段階でリンクベースのネストを, 下位段階では経路選択モデルを考慮している. モデル式を以下に示す.

$$P_k = \sum_n P_n \times P_{k|n} \quad (5.5.a)$$

$$P_{k|n} = \frac{(\alpha_{nk} e^{V_k})^{1/\mu}}{\sum_m (\alpha_{nm} e^{V_m})^{1/\mu}} \quad (5.5.b)$$

$$P_n = \frac{\left(\sum_k (\alpha_{nk} e^{V_k})^{1/\mu} \right)^\mu}{\sum_l \left(\sum_k (\alpha_{lk} e^{V_k})^{1/\mu} \right)^\mu} \quad (5.5.c)$$

ここに, α_{kn} はアロケーションパラメータと呼ばれ 0 から 1 値をとる. またこのパラメータは, 上位段階の各ネスト (リンク) への帰属の程度を示し, 以下の式が成り立つ.

$$\sum_n \alpha_{nk} = 1 \quad (5.5.d)$$

α_{nk} は直接推定可能ではあるものの, ネットワーク規模が大きくなると (リンク数と経路数が多くなると) 膨大な数となり推定が困難となる. このため, Vovsha and Bekhor (1998) は以下のように構造化している.

$$\alpha_{nk} = \left(\frac{L_n}{L_k} \right) \delta_{nk} \quad (5.5.e)$$

ここに、 L_n はリンク n のリンク長（もしくはリンク旅行時間）、 L_k は経路 k の経路長（もしくは経路旅行時間）、 δ_{nk} は経路 k 上にリンク n があれば 1、そうでなければ 0 となる変数。

Prashker and Bekhor (1998) は PCL と CNL を前提として、均衡配分に適用するための要件である、最適化問題と交通量のネットワーク負荷アルゴリズムを示している。

以上のモデルは、一般に GEV モデルの特殊形であることが知られている (Ben-Akiva and Bierlaire, 1999; Koppelman and Wen, 2000)。これら以外にも GEV モデルにより導出可能なモデルは開発されているが、本研究では経路選択モデルとして適用可能、もしくは経路選択問題を背景として開発、分析されたモデルについてのみ取り扱う。

e) C-Logit モデル

C-Logit モデルは、経路選択問題を背景として Cascetta ら (1996) により提案されたモデルである。このモデルは、通常の MNL モデルと同様の構造を維持しているため適用が容易であり、各経路効用関数の確定項に式(5.6.b)で表される Commonality Factor と呼ばれる変数 CF_k を組み込むことで、各経路間の類似性を表現している。モデル式は以下の通り。

$$P_k = \frac{\exp(V_k - CF_k)}{\sum_{k' \in K} \exp(V_{k'} - CF_{k'})} \quad (5.6.a)$$

$$CF_k = \beta_{cf} \ln \sum_{l \in K} \left(\frac{L_{kl}}{\sqrt{L_k L_l}} \right)^\gamma \quad (5.6.b)$$

ここに、 V_k はこれまでと同様に経路 k の効用の確定項、 β_i , β_{cf} , γ は未知パラメータ、 L_{kl} は経路 k と経路 l 間の共有区間長（もしくは共有区間の旅行時間）であり、 L_k , L_l はそれぞれ経路 k と経路 l の経路長（もしくは経路旅行時間）、 K は利用可能経路集合である。

修正項 CF_k は上式以外にも提案されており (Cascetta, 2001)、利用可能経路集合内での各経路の認知に関わる度合いと解釈できる (Ben-Akiva and Bierlaire, 1999)。ただし C-Logit モデルは、その修正項についての理論的背景はなく、むしろ直感的に経路間の類似性を考慮するものである。

f) Path-Size Logit モデル

Path-Size Logit モデル (以降、PSL モデルと称す) は、集約された代替案 (aggregate alternatives)

に関する選択理論を背景として開発されたモデルであり，理論的背景は Ben-Akiva and Lerman (1985) によって示された．モデルには C-Logit モデルと同様に，式(5.7.b)で表される経路間のリンク共有の度合いを表現する修正項 PS_k が組み込まれる．モデル式を以下に示す．

$$P_k = \frac{\exp(V_k + \ln PS_k)}{\sum_{k' \in K} \exp(V_{k'} + \ln PS_{k'})} \quad (5.7.a)$$

$$PS_k = \sum_{a \in A_k} \left(\frac{l_a}{L_k} \right) \frac{1}{\sum_{k' \in K} \delta_{ak'} \frac{L_k^*}{L_{k'}}} \quad (5.7.b)$$

ここに， A_k は経路 k を構成するリンク集合， l_a はリンク a のリンク長（もしくはリンク旅行時間）， $\delta_{ak'}$ は経路 k' がリンク a を利用していれば 1，そうでなければ 0 のダミー変数， L_k^* は最短経路長（もしくは最短経路旅行時間）である．

PSL モデルは，C-Logit モデルとよく似たモデル構造をしている．どちらのモデルも MNL モデルと同様に，各経路を並列に扱う点や共有区間長により効用値を修正する点は同じである．そこで，それぞれのモデルに組み込まれる修正項についての簡単な比較を行うため，図 5-4 のような互いに重なり合う K 本の経路からなるネットワークを考える．




図 5-4 共有リンクを持つネットワーク

このとき， CF_k 内の β_{cf} , γ の値を便宜的にそれぞれ 1 とすると，式(5.6.b)，式(5.7.b)は以下のように変形できる．

$$CF_k = \ln \left(1 + \frac{d(K-1)}{L} \right) \quad (5.8)$$

$$PS_k = \ln \left(1 - \frac{d(K-1)}{LK} \right) \quad (5.9)$$

式(5.8), (5.9)の括弧内第2項は, $K=1$ のときどちらも0となる. また, $K>1$ のときどちらも正であるから, CF_k は正, PS_k は負の値が算出される. しかし, C-Logit モデルの効用関数では CF_k はマイナスの符号を持つので, 結果的にどちらも共有リンク長 d や重複経路数 K が大きいほど, その経路の効用を下げる働きをする. 図 5-5 にそれぞれの修正値 ($-CF_k$, PS_k の値) と共有リンク長の関係を示す. $-CF_k$ と PS_k は凹凸関係が逆となっており, C-Logit モデルの方が共有経路数や短い共有リンク長に対して敏感に効用値を修正することになる. さらに, $d=0$ または $d=L$ のときはどちらも同じ値となることから分かる.




図 5-5 共有リンク長と補正値の関係

g) Implicit Availability/Perception Logit モデル

Implicit Availability/Perception Logit モデル (以降, IAPL モデルと称す) は, 経路選択問題を背景として Cascetta ら (2002) により開発された. 経路選択問題における重大な課題である利用可能経路集合の問題は, 経路選択モデルとは別に選択肢集合生成モデル (choice set generation model) によって解決しようとされてきた. しかし, IAPL モデルでは, 各経路の認知度合いを明示的に選択モデルに組み込むことで, これを解決しようとするものである. IAPL モデルでは, 経路 k を選択する確率 P_k は以下の式で表される.

$$P_k = \frac{\exp(V_k + \alpha \ln PC_k)}{\sum_{k' \in K} \exp(V_{k'} + \alpha \ln PC_{k'})} \quad (5.10.a)$$

ここで, α は未知パラメータ, PC_k は以下の式で算出される値を平均値に持つ確率変数である.

$$PC_k = \frac{1}{1 + \exp(\gamma Y_k)} \quad (5.10.b)$$

ここに、 Y_k は経路 k の利用可能性や認知度合いを表す説明変数、 γ は未知パラメータベクトルである。

ここまでに示したモデル以外にも、Bekhor et al. (2002) は Logit Kernel モデル (Mixed Logit model) を経路選択問題に適用しているし、日比野ら (2003, 2004) は鉄道ネットワークを対象として C-Logit モデルと構造化プロビットモデル、Mixed Logit モデルの特性を比較した上で、同重複率・異旅行時間を表現しうる C*-Logit モデルを提案している。このように、現在までにさまざまなモデルが開発され、適用性について多くの分析が行われている。

5.4 経路選択行動モデルへの適用

ここでは、プローブカーデータを前節で示した経路選択モデルのうちの幾つかのモデルに適用する。これにより、現実のドライバーの経路選択行動における新たな知見を得ることを目的とし、また既存の経路選択モデルの適用可能性を検証する。

5.1.2 でも述べたが、プローブカーデータのみを用いることでは、ドライバーが起点から終点までに存在する膨大な数の経路のうち、どのような経路を利用可能経路として認知しているかを分析することは難しい。これまでの研究でも、選択結果のみから個人の選択肢集合生成過程と選択過程を同時に扱うモデルについての研究は多いが、いずれも交通機関選択など選択肢数の限られた場面への適用であり、経路選択問題への適用は行われていない。IAPL モデルを用いれば、選択結果のみから各経路の利用可能性・認知度に関して分析することは可能ではあるものの、プローブカーデータからはドライバーの個人属性が得られないため十分な結果が得られなかった。このため本研究で行う分析は、実験期間中に観測された全ての経路（もしくは数トリップ以上が利用した経路）を、全てのドライバーに共通した利用可能経路集合とする。

ただし、プローブカーデータにより観測される利用経路は、次項で示すが数百経路と膨大な経路集合となる。このため、そのような大規模な選択肢集合に対して経路選択モデルを適用しても、モデル適合度は十分な値が得られないと予想される。しかし、ここでは適合度以外の指標によるドライバーの経路選択行動の検証や、適合度の変化によるモデルの適用可能性に焦点を当てた分析を行う。これは、本研究で使用するプローブカーデータのドライバーがタクシードライバーのみである点や、経路選択モデルの適用場面での Dial のアルゴリズムにおける仮定を考えれば、本研究で得られる知見は十分有用なものであると考えられるためである。しかし、ドライバーの個人属性を考慮することでさらに多くの知見が得られると考えられ、この点についてはプローブカー実験の今後の展開に期待したい。

5.4.1 分析用データの整理

ここでは、プローブカーデータの経路選択モデルへの適用可能性を検証するためのデータ整理を行う。適用の対象は、名古屋空港⇄名古屋駅の OD ペアとする。第1期実験期間中にこの OD ペアにおいて観測された経路数、トリップ数について表 5-3 にまとめ、利用経路を図 5-6 に示す。なお、利用経路図はマップマッチング処理後のデータにより作成された。これらより、実際に利用された経路は非常に多岐にわたっており、特に名古屋駅周辺では、幹線道路以外の街路が頻繁に利用されていることが分かる。さらに名古屋空港→名古屋駅方向のトリップでは、利用経路数に対して最大利用経路の利用トリップ数が相対的に少なく、利用経路の多様性が著しいことが分かる。

表 5-3 名古屋駅—名古屋空港間のトリップデータ

	名古屋駅→名古屋空港			名古屋空港→名古屋駅		
	平日	休日	計	平日	休日	計
トリップ数	330	229	559	722	481	1203
利用経路数	216	144	328	445	322	677
最大利用経路*	27	18	42	37	24	61

*最大利用経路：最も利用された経路の利用トリップ数




図 5-6 名古屋駅⇄名古屋空港間の利用経路図

5.4.2 旅行時間認知に関する分析

現実のドライバーは経路を選択するに際して、その最も重要なサービスレベル変数である経路所要時間をどのように認知しているのだろうか。これまでも、走行経験の繰り返しによる旅行時間認知の変化について分析した研究や（飯田ら，1990；飯田ら，1991），鉄道路線を対象とした，利用者のサービスレベル認知についての研究は行われてきた（岩倉ら，2004）。しかし，実際の経路選択データから，ドライバーが認知する旅行時間について分析した例は少ない。

道路ネットワーク上の交通状況は時々刻々と変化しており，出発時点での交通状況がトリップ終了時点まで保たれることはほとんどない。ドライバーはこのような出発後の交通状況の変化を，出発前にある程度予測した上で選択を行っているのであろうか。そこで以下のような **A**～**D** の4つの旅行時間データを経路選択モデルに適用することで，ドライバーの情報認知について分析を行う。

- A.** 交通状況把握は詳細であり，出発後の交通状況の変化も考慮している
- B.** 交通状況把握は詳細であるが，出発後の交通状況の変化は考慮しない
- C.** 交通状況の把握はせいぜいピーク・オフピーク時間帯程度しか認知していないが，出発後の時間帯の変化は考慮している
- D.** 交通状況の把握はせいぜいピーク・オフピーク時間帯程度しか認知しておらず，出発後の時間帯の変化も考慮しない

ここで，**A**，**B**における詳細な交通状況とは，各ドライバーが利用可能経路集合に含まれる全経路上のすべてのリンクに対して，出発時刻におけるリンク旅行時間を把握していることを意味している。**C**，**D**で設定したピーク・オフピーク時間帯とは朝ピーク（7:00～9:00），昼オフピーク（9:00～17:00），タピーク（17:00～19:00），夜オフピーク（19:00～7:00）の4つの時間帯である。また**A**，**B**における交通状況の変化とは，終点に到着するまでに実際に要する旅行時間であり，トリップ中の交通状況の変化を意味する。**C**，**D**における時間帯の変化とは，出発時刻以降のピーク・オフピーク時間帯の変化である。**A**はドライバーの交通状況認知能力を非常に高いものであるとしており，**D**は低い能力しか持たないことを意味している。これら4つの経路旅行時間データは，それぞれ3章で示した，リンクコストテーブルを用い作成されている。

使用するモデルは，経路選択モデルとして最も一般的に用いられている MNL モデルとし，推定には名古屋空港→名古屋駅方向のトリップデータのうち平日トリップ（722 トリップ）を用いた。設定した利用可能経路集合は，実験期間中に同じ OD 間で観測されたすべての経路（677 経路）とする。

推定結果を表 5-4 に示す。この結果から，旅行時間に関する情報があいまいになるほど旅行時間パラメータの値が上昇しており，経路選択への影響が強くなっている。また，モデル適合度についても，その値は非常に小さいものの，あいまいな **D** の旅行時間を用いた場合が最も高くなっている。したがって，現実のドライバーはピーク・オフピーク時間帯程度の交通状況

しか認知しておらず、さらには出発前においてトリップ開始後の交通状況の変化までは考慮していないことを示唆している。この結果は、5.2 における“ドライバーは交通状況に対して十分な知識を有していない”との分析結果とも関連すると考えられる。ただし以上の結果では、推定されたモデル間やパラメータ間の差は非常に小さく有意な差は見られない。しかしこれらの結果から、ドライバーの情報認知能力が非常に低いものである可能性を示すことができた。

表 5-4 所要時間情報の精度を変化させた場合の MNL モデルの推定結果

説明変数	A	B	C	D
旅行時間 (分)	-0.0126 (-0.9)	-0.0155 (-1.1)	-0.0304 (-1.9)	-0.0315 (-2.0)
右折+U ターン数	-0.0808 (-1.8)	-0.0778 (-1.7)	-0.0662 (-1.4)	-0.0649 (-1.4)
高速道路定数項	0.386 (2.4)	0.386 (2.4)	0.416 (2.6)	0.415 (2.6)
初期尤度	-4705.759	-4705.759	-4705.759	-4705.759
最終尤度	-4662.467	-4662.257	-4661.052	-4660.885
修正 ρ^2	0.00856	0.00861	0.00886	0.00890
AIC	4665.467	4665.257	4664.052	4663.885

サンプル数：722 (t 値)

5.4.3 経路認知に関する分析

経路旅行時間以外の経路属性である右折回数や通過路線も、ドライバーの経路認知に影響を与えていると考えられる。つまり、高速道路を主に通過する経路は多くのドライバーに利用可能経路として認知されているが、右左折の多い経路や生活道路を通過する経路についてはそれほど認知されていないと考えられる。しかし前述の通り、プローブカーデータはドライバーが出発時点において利用可能経路集合として認知していた経路についての情報を得ることができない。このため、ここでは実験期間中に通過実績が得られた経路が利用可能な全経路集合とし、その中から 2 トリップ以上に利用された経路が、ドライバーに認知される経路とみなして経路認知モデルを作成する。つまり、ある経路に対するドライバーの認知度と利用トリップ数の間には強い関係があるとしている。このとき、モデル式は 2 トリップ以上に利用された経路か否かの 2 項ロジットモデルとして式(5.11)で表される。対象 OD ペアにおいて観測された全経路数は 1005 経路 (表 5-3)、その内 2 トリップ以上の利用実績が確認された経路は 190 経路であった。推定結果を表 5-5 に示す。

$$P_k = \frac{\exp(V_k)}{\exp(\lambda_{cong}) + \exp(V_k)} \quad (5.11.a)$$

$$V_k = \sum_i \beta_i x_i^k \quad (5.11.b)$$

ここに、 V_k は経路 k を認知することで得られる効用の確定項、 β_i は未知パラメータ、 x_i^k は経路 k の i 番目説明変数、 λ_{cong} は認知されるための閾値である。つまり、認知効用が閾値を超える経路は認知されやすい経路であるとしている。

表 5-5 経路認知モデルの推定結果

説明変数	パラメータ
閾値 λ_{cong}	4.34 (4.0)
右折数 (回/km)	-5.41 (-5.8)
高速利用距離/経路距離	4.88 (4.4)
国道利用距離/経路距離	4.45 (3.7)
主要道・県道利用距離/経路距離	4.59 (3.8)
初期尤度	-696.613
最終尤度	-435.513
修正 ρ^2 値	0.368
AIC	440.513

サンプル数：1005 (t 値)

推定結果より、高速道路がもっとも認知されやすく、国道と主要道・県道は同程度に認知される傾向があり、右折・U ターンの数が増加するほど認知されにくくなる傾向があることが分かる。このように旅行時間以外の経路属性によっても、ドライバーへの認知のされやすさは異なることが示された。

5.4.4 経路選択モデルへの適用

ここまでに、ドライバーが経路選択を行うに際して、どのような情報をもとに選択行動を行っているかについて分析を行った。しかし 5.4.2 の結果からは、利用可能経路集合が大きいこともあり、最も一般的に用いられている MNL モデルであるにも関わらず、その適合度は非常に低いことが分かる。5.3.2 でも示したように、これまでに多くの離散選択モデルが開発され、経路選択モデルとして適用されている。しかしこれら多くのモデルにおいて、本研究で分析対象としているような非常に大きな選択肢集合（677 経路）に適用できるモデルはそれほど多くない。これまで開発された経路選択モデルの中でも、大きな選択肢集合に対して比較的容易に適用可能なものとしては、NL モデル、C-Logit モデル、PSL モデルなど、モデル構造がそれほど複雑ではないものが挙げられる。さらに、PCL モデルについてもそのモデル構造は複雑ではあるものの、類似度パラメータの構造化により適用可能であると考えられる。ここではこれらのモデルを用いて、そのモデル適合度から経路選択行動モデル化の可能性について分析を行う。

a) NL モデル

ドライバーが利用経路を選択する際には、まず利用幹線道路を選択し、利用幹線に対するアクセス・イグレス経路は幹線ごとに独立した選択肢としてみなせると考える。このとき経路選択モデルは、利用幹線道路が同一である経路間の類似性を考慮した NL モデルにより表現でき、モデル構造は図 5-7 で表される。ここで利用幹線道路とは、各経路での最も長い距離で利用された県道以上の路線とする。




図 5-7 NL モデルの経路選択構造

推定には MNL モデルと同様に名古屋空港→名古屋駅の平日トリップデータを用い、利用可能経路集合は観測された全経路とする。なお、利用可能経路集合には幹線経路数が 11 路線存在する。また、経路旅行時間データは MNL モデルを用いた分析における旅行時間 **D** と同様に、4 時間帯、時間帯変化なしとした。表 5-6 に推定結果を示す。

表 5-6 NL モデルの推定結果

説明変数		パラメータ
幹線選択	ログサム変数	0.939 (19.8)
	高速道路定数項	0.617 (7.6)
経路選択	旅行時間 (分)	-0.0319 (-2.0)
初期尤度		-4705.759
最終尤度		-4661.000
修正 ρ^2		0.00887
AIC		4664.000

サンプル数：722 (t 値)

NL モデルの推定結果を MNL モデルの推定結果と比較する場合には、そのモデル構造の違いから、修正 ρ^2 値ではなく AIC (Akaike's Information Criteria) により比較されるべきである。それぞれのモデルの AIC を比較すると、NL モデルの方がその値が大きくモデル適合度が低いことが分かる。さらに、推定されたパラメータは適切な符号条件が得られているものの、幹線道

路選択段階でのログサム変数のパラメータ値が 1 から十分に離れていない．すなわち，帰無仮説 $=1$ に対する t 値が 1.4 となり，5%の有意水準で棄却できない．これは図 5-7 で仮定したネストの構造よりも，すべての経路が並列に並ぶ通常の MNL モデルで表現すべきであることを示唆している．したがって本研究で用いたデータでは，幹線道路を共有する複数経路間には，観測されない類似性（誤差項の相関）はないことが分かる．

b) C-Logit モデル，PSL モデル

表 5-7 に C-Logit モデルと PSL モデルの推定結果を示す．C-Logit モデルにおける修正項のパラメータ γ はモデル構造上推定しにくく，これまでの研究においてはあらかじめ適当な値に設定することが多いが（溝上，2003；日比野ら，2004），ここではより詳細にその適用性を検証するために，他のパラメータと同時に推定を行った．

表 5-7 C-Logit モデルと PSL モデルの推定結果

説明変数		パラメータ	
		C-Logit	PSL
旅行時間（分）		-0.0332 (-2.1)	-0.104 (-7.8)
高速道路定数項		0.652 (7.9)	0.945 (12.2)
CF_k	β_{cf}	0.310 (3.0)	--
	γ	2.13 (3.6)	--
初期尤度		-4705.759	-5031.170
最終尤度		-4638.732	-4900.084
修正 ρ^2		0.0134	0.0257
AIC		4642.732	4902.084

サンプル数：722 (t 値)

C-Logit モデルにおいて，Cascetta らは γ の値が 1 か 2 程度であるとしており，推定された γ の値は妥当な値であるといえる．この推定結果から，C-Logit モデルの AIC は MNL モデルのそれより低くなっており，経路選択行動への適合度は MNL モデルよりは幾分高くなっている．したがって，各経路間の共有区間の類似性を考慮することによりモデル適合度が向上することが示された．しかし，そのモデルの適合度は依然としてかなり低い値である．また，PSL モデルの AIC は，推定されたいずれのモデルより高くなり適合度が最も低くなっている．これは，PSL モデルではその補正項 PS_k にパラメータがつかず，モデルの自由度が低くなっているためであると考えられる．さらに PSL モデル内の旅行時間パラメータ値は，いずれのモデルよりも高くなっている．C-Logit モデルの補正項 CF_k が 0.3 程度のパラメータを持つのに対して，PSL モデルの補正項のスケールが大きすぎるためにモデル適合度を下げていることも分かる．

c) PCL モデル

表 5-8 に PCL モデルの推定結果を示す。なお、類似度パラメータ σ_{kj} は、式(5.4)のように構造化して推定を行った。推定結果より、旅行時間のパラメータが NL モデルや C-Logit モデルより大きく、その説明力が大きくなっていることが分かる。しかし、モデル適合度は C-Logit モデルより若干劣っている。PCL モデルは全ての経路の組み合わせごとにその類似性を表現でき、より柔軟な構造であるものの、 σ_{kj} を構造化して推定する場合はモデルの自由度が十分ではなく、結果としてパラメータ数の少ない PCL モデルの方が C-Logit モデルより適合度が下がるものと考えられる。

表 5-8 PCL モデルの推定結果

説明変数	パラメータ
旅行時間 (分)	-0.0564 (-3.9)
高速道路定数項	0.633 (7.8)
初期尤度	-4700.398
最終尤度	-4641.230
修正 ρ^2	0.0122
AIC	4643.230

サンプル数：722 (t 値)

ここまで、MNL モデル、NL モデル、C-Logit モデル、PSL モデル、PCL モデルについてプローブカーデータを用いて推定を行った。この結果 C-Logit モデルが最も適合度が高く、またその操作性の高さを考えれば、最も実用的な経路選択モデルであるといえる。

5.4.5 トリップ距離が経路選択行動に与える影響

これまでの経路選択モデルの多くは、OD 間距離にかかわらず同一のモデルを適用することが一般的である。例えば、均衡配分を適用する際には都市圏レベルや全国規模の道路ネットワークを対象としているにもかかわらず、全ての OD ペアに対して使用される経路選択モデルの構造やパラメータは同一であるとしている。そこで本項では、距離の異なる複数の OD ペアを対象として、トリップ長の変化に伴う経路選択行動の変化を分析することを目的とし、より適切に現実の行動を表現するための経路選択行動モデルについて考察を行う。

a) トリップ距離と経路選択行動の関係

ここでは、図 5-8 に示す 5 つの OD ペアを対象とする。これらの OD ペアは、全て名古屋駅桜通口タクシーターミナル前を終点に持つ OD ペアである。また、起点についてはトリップによってばらついているため、出発後 500m 以内に各起点側交差点を通過したデータを同一 OD

ペアとしている。ただし、ここでの分析では前項までとは異なり、観測された経路全てをそのまま用いず、ある程度集約した経路データを用いる。これは、マップマッチングエラーや DRM データの方向規制情報等のエラーにより、無意味に観測経路数が多くなるのを防ぐためである。また、ドライバーの経路選択行動についての本質的な分析を行うためには、ある程度の利用経路の整理が必要と考えた。分析に用いる利用可能経路集合は、OD ペアごとに観測されたトリップが 2 トリップ以上通過したリンクを抽出し、このリンク上のみを通過して終点まで到達できる経路により構成される。またトリップについては、分析経路を 90% 以上通過するもののみを集計した。表 5-9 に、対象 OD ペアで観測されたトリップについてまとめる。




図 5-8 分析対象エリア

ここで、表 5-9 における平均経路長は、利用可能な経路の経路長を利用トリップ数で重み付平均した値である。以上のデータを用いて OD ペアごとに経路選択モデルを推定することで、OD 間距離の違いが経路選択行動に与える影響について分析する。適用する経路選択モデルは MNL モデルを採用する。また、すべての OD ペアにおいて経路旅行時間データは 2 時間間隔、

交通状況の変化を考慮するとしている。これは、ピーク・オフピーク時間帯（4 区分）、2 時間、1 時間、30 分、15 分、5 分間隔の 6 種類のリンクコストテーブルを作成した上で、出発後の交通状況変化ありとなしについて MNL モデルを推定し、その適合度について分析した結果、モデル間に有意な差は見られず、また明確な傾向は見られなかったためである。OD ペアごとの推定結果を表 5-10 に示す。

表 5-9 対象 OD の起終点と観測されたトリップの概要

OD No.	起点 (交差点名)	終点	抽出トリ ップ数	分析経 路数	平均経路長 (km)
1	豊場	名古屋駅桜 通口タクシ ーターミナ ル	482	115	11.8
2	赤塚		257	21	4.5
3	東片端		316	25	3.3
4	県警本部西		284	23	2.3
5	明道町		270	8	1.3

*第 1 期，第 2 期実験期間データから作成

表 5-10 距離の異なる OD ペアごとの MNL モデルによる推定結果

モデル No.	1	2	3	4	5	6 ^{*1}
起点交差点名	豊場	赤塚	東片端	県警本部西	明道町	--
利用可能経路数	115	21	25	23	8	--
トリップ数	482	257	316	284	270	1609
平均経路長(km)	11.8	4.5	3.3	2.3	1.3	8.3
説明変数	パラメータ					
旅行時間（分）	-0.236 (-8.5)	-0.438 (-2.8)	-0.616 (-3.8)	-1.39 (-9.2)	-2.04 (-10.6)	-0.342 (-16.0)
右左折数	-0.0771 (-2.9)	-0.185 (-2.7)	-1.31 (-14.0)	-1.17 (-14.6)	-1.68 (-15.4)	-0.391 (-18.1)
高速比率 ^{*2}	3.01 (4.5)	--	--	--	--	5.46 (11.5)
国道比率 ^{*2}	4.94 (6.5)	17.9 (6.8)	11.3 (6.9)	6.42 (5.5)	--	8.58 (19.0)
県道比率 ^{*2}	1.72 (2.4)	15.2 (6.5)	11.2 (7.1)	2.43 (2.8)	--	6.26 (15.4)
初期尤度	-2287.057	-782.442	-1017.165	-890.480	-561.449	-5538.596
最終尤度	-2148.317	-619.278	-607.671	-546.763	-175.272	-4607.420
修正 ρ^2 値	0.0585	0.203	0.399	0.382	0.684	0.167

*¹ 全てのデータをプールして推定

(t 値)

*² 高速（国道，県道）比率：高速（国道，県道・主要道）利用距離／経路距離

推定結果より、OD 間距離が短くなるほど旅行時間や右左折数のパラメータ値が上昇する傾向がみられる。また、モデル No.2 から 4 においては、OD 間距離が短くなるほど国道比率や県道比率のパラメータ値が減少しており、距離の短いトリップにおいては幹線道路利用の重要性が減少する傾向がある。

表中のモデル No.6 は、対象とする 5 つの OD ペアについてプールしたデータによる推定結果である。通常、経路選択モデルにおけるパラメータは全ての OD 間で同一であるとしている。したがって、従来の枠組みで経路選択モデルを適用する場合、ここで取り扱うエリアを対象とすればモデル No.6 の推定結果を用いることになる。しかし、OD ペアごとに推定された各モデルで推定されたパラメータは、それぞれ大きく異なっている。特に旅行時間や右左折数のパラメータは、OD 間距離が短くなるほど大きな値になるといった明確な傾向がみられる。

b) 対数を用いた経路選択モデル

上記のようなトリップ距離による経路選択行動の変化を表現するためには、説明変数に対して対数をとる方法が有効であると考えられる。すなわち、旅行時間や費用に対して意思決定者がそれらの差を認知するための変化量は、旅行時間や費用の対数に比例して変化するという考えである。これは、ウェーバー・フェヒナーの法則としてよく知られている。ウェーバーは、感覚の強さに変化を起こすために必要な最小の刺激強度差を ΔS 、もとの刺激の大きさを S とすると、 $\Delta S / S$ が一定であることを示した。ここで、分析対象である経路選択行動において例を挙げると、100 分の旅行時間が 102 分に変化した時にその違いを認知した意思決定者は、200 分の旅行時間が 202 分に変化してもその違いを認知することはなく、204 分に変化して初めてその変化を認知することになる（これらの設定値は説明のために便宜的に設定）。さらに、フェヒナーはこれを以下の式で表した（Keats, 1971）。

$$E = k \log S + a \quad (5.12)$$

ここに、 E は感覚量、 S は刺激量、 k 、 a は定数である。

本項で対象とする 5 つの OD ペアは、OD 間距離が長くなれば旅行時間や右左折数も大きくなるため、これら説明変数に対数をとることでトリップ距離の違いを考慮した経路選択モデルを作成することができる。このように、旅行時間や費用の対数を説明変数とすることは、これまでの非集計モデル分析において頻繁に行われている。一般に、対数を用いた説明変数を導入する場合には自然対数を用いる場合が多いが、ここではウェーバー・フェヒナーの法則に従って常用対数を用いる。常用対数を用いても底の変換により自然対数に変換することが可能であり、常用対数を用いて推定されたパラメータ値を $\ln 10$ (≈ 2.3) で除せば、自然対数により推定されるパラメータとなる。また、モデル適合度や対数をとらない説明変数のパラメータは、自然対数を用いても常用対数を用いても同一である。

表 5-11 に推定結果を示す。この結果より、対数をとることで旅行時間、右左折数の t 値が上

昇しており，その説明力が上昇していることが分かる．また，表 5-10 におけるモデル No.6 と比較してモデル適合度も大きく上昇しており，OD 間距離が異なる場合の経路選択行動をより適切に表現していることが分かる．

表 5-11 対数を用いた推定結果

トリップ数	1609
説明変数	パラメータ
log（旅行時間（分））	-15.1 (-20.9)
log（右左折数（回））	-3.30 (-25.9)
高速比率	4.57 (9.5)
国道比率	6.51 (13.7)
県道比率	5.35 (12.4)
初期尤度	-5538.596
最終尤度	-4335.434
修正 ρ^2 値	0.216

(t 値)

c) スケールパラメータの構造化

対数を用いた説明変数を導入する以外にも，効用の誤差項が OD 間距離によって変化していると捉えることもできる．これは，目的地までの距離が短い場合は交通状況や道路ネットワークに対するドライバーの認知度が高く，逆に距離が長い場合はドライバーの認知度が低くなると考えられる．さらには，OD 間距離が長くなるに伴い増加する，観測された利用可能経路集合が，ドライバーが認知する利用可能経路集合と異なるためとも考えられる．

ここで前者については，図 5-9 に示すような OD 間距離の異なる 2 つの OD ペアを考えることで説明ができる．これらの OD ペアにはそれぞれ 2 本の経路が存在し，その差はどちらの OD ペアにおいても 5 分である．MNL モデルでは各経路の選択確率が効用差で決定されるため，全ての OD ペアにおいて同一のパラメータを適用する従来の枠組みでは，どちらのケースにおいても短い経路の選択確率は同じである．すなわち，経路選択行動を説明する変数が旅行時間のみでありスケールパラメータ μ が 1 であるとき，いずれのケースにおいても旅行時間の短い経路の選択確率は 0.993 となる．しかし一般的に考えれば，OD 間距離の短い Case A では多くのドライバーが旅行時間の短い経路を選択しても，OD 間距離の長い Case B では Case A ほど旅行時間の短い経路に選択が集中しないと考えられる．これは，全ての OD ペアにおいて同一のスケールパラメータを用いるために生じる現象である．実際には，OD 間距離が長くなれば各経路の効用に対するドライバーの認知誤差は大きくなり，経路間の効用の差を正確には判断でき

なくなる．すなわち，OD 間距離が長くなれば効用の誤差項の分散が大きくなり，モデルに含まれるスケールパラメータが小さくなると考えられる．例えば，Case B においてはスケールパラメータ μ が 0.1 であるとすれば，旅行時間 55 分の経路の選択確率は 0.622 となる．




図 5-9 距離の異なる OD ペアにおける経路選択

また後者については，本研究では実験期間中に観測された経路を利用可能経路集合とすることによるものである．つまり，観測された経路集合に含まれる，旅行時間が十分に短い，または右左折数が十分に少ない経路をドライバーが認知していない場合は，導入した説明変数のみではその選択構造を表現することができないため，モデル内では誤差項として表現されてしまうことになることを意味している．この問題は，Swait and Ben-Akiva (1986) により分析された選択肢集合の特定の問題とも類似しており，ドライバーが認知する利用可能経路集合に関する詳細な分析を必要とする．しかし本研究で使用するプローブカーデータからは，ドライバーの属性に関する情報を得ることが困難であり，さらには現状における経路選択モデルの適用場面を踏まえ，ここでは観測された全ての経路を利用可能経路集合として扱うものとする．

OD 間距離の変化によるスケールパラメータの変化を確認するため，5 つの OD ペアをプールしたデータにより，OD ペアごとのスケールパラメータを同時に推定した結果を表 5-12 に示す．ここで，全ての OD ペアにおいてスケールパラメータを未知とすることはできないため，OD No. 4（平均経路長 2.3）のスケールパラメータを 1 とした．

この結果から，OD ペアごとのスケールパラメータは，OD 間距離が短くなるほど大きな値となっていることが分かる．またモデル適合度についても，表 5-10 におけるモデル No.6 と比較して修正 ρ^2 値が大きく向上している．しかし，実際に経路選択モデルを適用する場面において，対象となる全ての OD についてそのスケールパラメータを推定することは困難である．そこで，スケールパラメータの構造化を試みる．

表 5-12 距離の異なる OD ペアごとのスケールパラメータ

トリップ数		1609
説明変数		パラメータ
旅行時間 (分)		-1.52 (-14.2)
右左折数 (回)		-1.28 (-17.7)
高速比率		4.61 (2.3)
国道比率		5.61 (7.9)
県道比率		5.03 (7.9)
スケール パラメータ μ	OD No.1	0.114 (8.3)
	OD No.2	0.426 (11.2)
	OD No.3	0.913 (14.7)
	OD No.4	1 (--)
	OD No.5	1.10 (13.8)
初期尤度		-5538.596
最終尤度		-4184.558
修正 ρ^2 値		0.243

(t 値)

経路選択を行う際に、ドライバーが認知する経路の効用には誤差が伴う。MNL モデルでは、この誤差項がガンベル分布であることを仮定しており、ガンベル分布の分散は以下の式で表される。

$$Var(\varepsilon_k^{rs}) = \frac{\pi^2}{6\mu_{rs}^2} \quad (5.13)$$

ここに、 ε_k^{rs} は OD ペア rs 間の経路 k を選択することで得られる効用の誤差項、 μ はスケールパラメータである。

このとき、スケールパラメータ μ が、OD 間距離により式 (5.14) のように、または利用可能経路数により式 (5.15) のように構造化可能であるとする。

$$\mu_{rs} = \frac{\pi}{\sqrt{6}} D_{rs}^{\alpha} \quad (5.14)$$

$$\mu_{rs} = \frac{\pi}{\sqrt{6}} R_{rs}^{\gamma} \quad (5.15)$$

ここに、 D_{rs} は OD ペア rs 間の距離 (km)、 R_{rs} は OD ペア rs 間で観測された経路集合、 α 、 γ は未知パラメータである。

2 式のように構造化されたスケールパラメータを用いて、再度 5 つの OD ペアをプールしたデータを用いて MNL モデルを推定した。表 5-13 に推定結果を示す。この結果から、構造化されたスケールパラメータを導入した 2 つのモデルは、構造化前のモデル(表 5-10 のモデル No.6)と比較して適合度が大きく向上している。さらには、旅行時間や右左折数に対数を用いたモデル(表 5-11)と比較しても、モデル適合度は向上していることが分かる。従って、スケールパラメータの構造化により、距離の異なる OD ペアを対象としても、より適切に経路選択行動を表現しうるモデルを作成することが可能となることが分かる。

また、利用可能経路数により構造化されたモデルよりも、OD 間距離により構造化されたモデルの方がその適合度は高い。これは、表 5-12 で示された OD ペアごとのスケールパラメータは、OD 間距離の増加により単調に減少しているのに対して、観測された利用可能経路集合は OD No.2~4 の間でほとんど同じであり、特に OD No.2 での利用可能経路数は OD No.3、4 より少ないためであると考えられる。また、利用可能経路集合により構造化されたモデルのパラメータが、OD 間距離により構造化されたモデルより 3~5 倍のスケール値を持つのは、経路数が OD 間距離よりも大きく、構造化後のスケールパラメータの値が小さくなるためである。

表 5-13 構造化スケールパラメータを用いた推定結果

トリップ数		1609	
説明変数		パラメータ	
		OD 間距離	利用可能経路数
旅行時間 (分)		-1.85 (-13.5)	-6.16 (-8.2)
右左折数 (回)		-1.79 (-16.8)	-5.46 (-9.0)
高速比率		3.76 (2.0)	19.0 (2.9)
国道比率		11.4 (9.9)	45.6 (8.5)
県道比率		6.98 (6.8)	34.4 (7.7)
構造化パラメータ	α	-0.951 (-25.1)	
	γ		-0.734 (-23.3)
初期尤度		-5538.596	-5538.596
最終尤度		-4242.853	-4302.836
修正 ρ^2 値		0.233	0.222

(t 値)

ここで、 α の値は -1 から有意に離れていない。すなわち、帰無仮説 = -1 に対する t 値が 1.3

となり，5%の有意水準で棄却できない．ここで $\alpha = -1$ とすると，式 (5.14) は以下の式に変形できる．

$$\sqrt{\frac{\pi^2}{6\mu_{rs}^2}} = SD(\varepsilon_k^{rs}) = D_{rs} \quad (5.16)$$

すなわち，誤差項の標準偏差は OD 間距離により表現可能であることが分かる．ここで参考として，図 5-10 に構造化されたスケールパラメータと，表 5-12 で推定された OD ペアごとのスケールパラメータを示す．ただし，表 5-12 で推定された OD ペアごとのスケールパラメータは，OD 間距離が約 2km のときに 1 としているため，図中に示す構造化されたスケールパラメータも，スケール軸方向にその値を修正している．




図 5-10 OD ペアごとのスケールパラメータと構造化スケールパラメータ

なお，OD 間距離の影響と利用可能経路集合の大きさの影響を同時に考慮すべく構造化を図ったモデルについても適用を行ったが，OD ペア数が 5 と少ないこともあり，正しい符号条件の推定結果を得ることはできなかった．

また，ここではドライバーの経路効用に対する認知は OD 間距離により変化し，これは経路効用の誤差項の標準偏差が OD 間距離に比例するとして表現できることを示したが，Gliebe ら (1998) はリンク旅行時間の分散はリンク旅行時間に比例していると仮定し，経路旅行時間の分散はリンク旅行時間の分散の合計で表現できるとして，スケールパラメータの構造化を図っている．しかし，リンク旅行時間は連続するリンク間で相関を持つと考えられ，必ずしも Gliebe らの仮定が正しいとはいえない．ただし，経路旅行時間を用いて構造化する考え方は，同じ OD

ペアの同じ経路に対しても、例えばピーク時とオフピーク時の交通状況の違いにより認知誤差が変化することを表現することができる。これは、5.2 でも検証したような交通状況の変化によるドライバーの経路選択行動の変化を表現可能であり、より一般的な表現方法であると考えられる。このようなより適合度の高い構造化手法については今後の課題として挙げられる。

本項では、トリップ距離の変化が経路選択行動に与える影響を分析し、スケールパラメータを構造化することでモデル適合度が向上し、より現実の経路選択行動を表現しうることが明らかとなった。ここで、経路選択モデルにおける説明変数に対数をとることは、経路選択モデルの再現性を大きく向上させる 1 つの方法ではあるが、交通量配分や交通シミュレータへのモデルの適用が困難となる場合があることに注意しなければならない。これは、経路選択モデルを容易に適用するために用いられる Dial のアルゴリズムでは、経路効用がリンク効用の総和となることが前提とされているためである。一方、スケールパラメータを構造化する方法であれば、すべての OD ペアの交通量をネットワーク上に同時に負荷することが困難となるものの、OD 間距離により全 OD ペアを幾つかのセグメントに分割すれば、Dial のアルゴリズムにより配分計算を行うことが可能である（岡田ら、2004）。このように、経路選択モデルの適用場面においても、スケールパラメータの構造化は有効な方法であるといえる。

しかし、ここまでに示した選択モデルは、起点において終点までの詳細な経路を選択するものであり、言い換えれば、ドライバーはどんなに OD 間距離が長くてもトリップ中に意思決定を行わないとしている。さらに、これまでの分析では、観測されたすべての経路を利用可能経路集合としている。もしドライバーがトリップ途中に経路を変更するのであれば、ここまでに使用した利用可能経路集合は、あくまで最終的な走行軌跡でしかない。このため、起点においてドライバーが認知する経路は（もしくは、交通量配分問題で設定する必要のある利用可能経路集合は）さらに少なくなると考えられる。そこで次節では、ドライバーのトリップ中の経路変更行動の可能性を検証し、より動的な経路選択行動のモデル化に向けた分析を行う。

5.5 より動的な枠組みに向けた分析

これまでに示した経路選択モデルの枠組みは、交通機関選択や目的地選択等と同様に、意思決定者がトリップにおいて 1 度だけ選択行動を行うというものであった。つまり、ドライバーは起点において終点までの詳細な経路を一度に決定するものである。しかし、経路選択行動は他の交通行動とは大きく異なる特徴を有している。例えば、道路ネットワーク上の交通状況は時々刻々と変化しているため、出発時点で期待した旅行時間がトリップ中に大きく変わってしまう点や、道路ネットワーク上には膨大な数の選択可能な経路が存在し、それらが互いに交差したり重なり合っているため、一旦どれかの経路を選択したとしても途中で走行中の経路の利用を取りやめ、現在の経路から分岐する、もしくは交差する経路へと転換することが容易に可

能である点などが挙げられる。このため、一度選択した経路上にあるドライバーが、交通状況の変化に応じて利用経路を変更することがしばしばあり、経路選択行動はより動的な枠組みで分析されるべきである。ここで述べる“動的”とは、出発地点での経路選択に加えて、トリップ中においても交通状況の変化に応じて選択経路を変更することを指す。静的な均衡配分のように、トリップ中の時間的変化を扱わない場合においても、現実を選択された経路のアウトプットは上記のような選択行動の繰り返しの結果であり、リンク交通量が各ドライバーの経路選択・変更行動の集積である点を考えれば、このような意思決定構造を明らかにすることは非常に重要であり、交通状況の解明につながるはずである。

これまでに、トリップ中の経路変更について取り扱った研究は多いが（久保ら，1996；森津・中島，1997；羽藤ら，1998；Srinivasan et al., 2003），いずれも高速道路など簡単なネットワークを対象とするものや室内実験によるものであり、現実の経路選択データを用いた詳細な検証は行われていない。また、林ら（1998）は、トリップ中の走行経験が走行経路における残り区間の認知旅行時間に影響を及ぼすとしているが、提案するモデルフレームワークを SP データにより検証したに過ぎず、現実の観測データによる検証には至っていない。

そこで本節では、より現実の経路選択行動を扱うためのフレームワークを提案するために、プローブカーデータを用いて動的な経路選択行動モデルへ向けた分析を行う。ここで、OD 間距離やドライバーの走行位置により、動的な経路選択行動は変化すると考えられる。すなわち、非常に長い距離のトリップを考える場合、起点や終点付近にドライバーが位置する場合と、終点までの十分な距離が残された中間区間に位置する場合とでは、経路変更行動が異なると考えられる。このような経路変更行動の変化に対する理由は多く考えられるが、最も直感的な理由としてはドライバーのネットワーク認知の変化が挙げられる。つまり、ドライバーは起終点付近のネットワークに関しては細街路を含めた詳細なネットワークを認知しているが、ある程度起点や終点から離れたネットワークに対しては、その認知度が低下するため経路の変更が起こりにくいと考えられる。しかし、プローブカーデータのみを用いる場合はネットワーク認知に関する分析を行うことが困難であることから、このような動的なネットワーク認知に関する分析も本研究では対象としない。また、本研究で用いるプローブカーデータはタクシートリップデータであり、また経路選択行動もタクシードライバーによるものである。2.2.2 でも示したようにタクシートリップは平均して 4km 程度と距離が短く、また、ドライバーは一般のドライバーと比較して道路ネットワークに対する認知度が高い。したがって、本研究ではこのようなネットワーク認知の動的な扱いは行わないものとする。

5.5.1 トリップ中における意思決定に関する分析

a) トリップ中の意思決定発生の可能性

通常、経路選択行動をモデル化する際には、出発地点において終点までの詳細な経路を一度に決定すると捉えることがほとんどである。動的シミュレーションのようにトリップ中の意思

決定を行う場合においても、出発地点では終点までの詳細な経路を選択しているし、トリップ中においても、出発地点での意思決定と同様の選択を到着ノードごとに単純に繰り返すものである。道路ネットワーク上の交通状況は時々刻々と変化しており、ドライバーも交通状況の変化に応じて一度選択した経路を変更する。しかし、実際に意思決定を行っていない状況下にもかかわらず経路選択行動モデルを適用すれば、再現されたドライバーの経路選択は、現実よりも交通状況認知能力の高い行動として再現されるであろう。

それではどのような状況で、ドライバーは経路変更を行うのであろうか。そこで、トリップ中の経路変更行動発生の可能性を検証するための分析を行った。分析対象エリアは、図 5-11 に示す名古屋駅－中区役所間の OD ペアである。

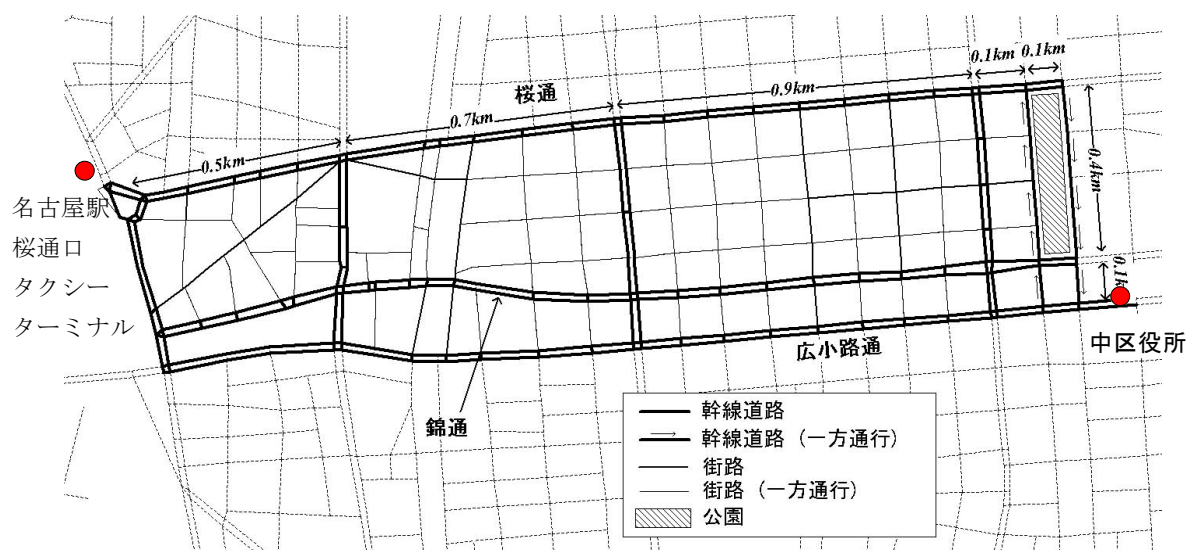


図 5-11 中区役所⇄JR 名古屋駅桜通口タクシーターミナル間のネットワーク

この OD ペアの大きな特徴として、利用可能な各経路の大部分を構成する 3 本の幹線道路(桜通、錦通、広小路通)の混雑度合いが挙げられる。桜通は 8 車線であり比較的スムーズな走行が可能であるのに対して、広小路通は沿線に商店やデパートが建ち並んでおり、駐車車両や歩行者が多いため、通過するためには何度も停止しなければならない。名古屋駅→中区役所のトリップでは、トリップの起点が桜通に接続しており、中区役所→名古屋駅では広小路通に接続している。表 5-14 は、第 1 期実験期間中に 3 つの幹線道路上で収集されたデータの内訳、および、距離周期データより集計された平均走行速度である。桜通で収集されたデータ内訳は、距離周期、発進、停止がそれぞれ約 30%であるのに対して、広小路通は発進、停止の割合が高くなっており、ストップ・アンド・ゴーが多く発生していることが分かる。またそれに伴い、広小路通では走行速度が低くなっている。

表 5-14 東西方向の幹線上で記録されたデータの内訳

	桜通	錦通	広小路通
距離周期 (300m)	31.1%	27.2%	22.4%
車両発進時	34.9%	37.1%	44.1%
車両停止時	33.9%	35.3%	36.1%
その他	0.1%	0.4%	0.4%
平均走行速度 (東向き, km/h)	40.4	34.5	29.9
平均走行速度 (西向き, km/h)	42.8	40.1	34.3

図 5-12 に平日における各リンクの通過交通量を示し、表 5-15 にトリップ方向別の細街路利用率を示す。図表より、トリップの起点が混雑した広小路通に位置する中区役所→名古屋駅方向の方が細街路を利用する割合が高く、比較的スムーズな走行が可能な桜通に起点が位置する反対方向のトリップでは、細街路を利用するトリップが少ないことが分かる。




図 5-12 トリップ方向別経路交通量 (第 1 期実験期間中の平日合計)
(上：名古屋駅→区役所，下：区役所→名古屋駅)

表 5-15 トリップ方向別トリップの細街路利用率

	トリップ数	利用経路数	街路利用率
中区役所→名古屋駅	249	45	14.5%
名古屋駅→中区役所	173	18	4.1%

*第 1 期実験期間のプロブカーデータより集計

以上の結果から、ドライバーは直面する交通混雑により経路変更についての意思決定が誘発されていることが予想される。そこで、式(5.17)に示すような右折行動発生モデルを作成することで、経路変更行動と交通混雑の関係を分析した。モデル作成に用いたデータは、中区役所（名古屋駅桜通口タクシーターミナル）を出発した後、広小路通（桜通）を走行中に右折可能な交差点を通過もしくは右折した際のデータである。

$$P_{turn} = \frac{\exp(V_{turn})}{\exp(V_{turn}) + \exp(\lambda_{turn})} \quad (5.17)$$

ここに、 P_{turn} はドライバーが右折行動を起こす確率、 V_{turn} は右折行動により得られる効用の確定項、 λ_{turn} は右折行動を起こすための効用の閾値である。

ここで、本研究で使用したプローブカーデータは最大で 300m のデータ間隔を持つことから、各起点である中区役所（名古屋駅桜通口タクシーターミナル）から広小路通（桜通）に沿って 500m 以上離れた交差点を対象とした。このとき、トリップの方向によらず各幹線上には 7 箇所の右折可能交差点が存在する。推定結果を表 5-16 に示す。幹線ダミーとは、目の交差路線が幹線道路であれば 1、そうでなければ 0 のダミー変数である。なお、説明変数として右折後や直進後の旅行時間を扱っていない。これは、右折後（直進後）の経路は複数存在し、これらすべてを考慮することで分析が複雑になることを避けるためであり、ここでは右折行動が発生するための状況を、ドライバーが経験した交通状況により説明しうるかを検証する。

表 5-16 右折行動発生モデルの推定結果

説明変数	パラメータ
過去1.0kmに経験した最高速度 (km/h)	-0.0461 (-2.8)
過去0.5kmに経験した停止回数 (回)	0.295 (2.9)
幹線ダミー	2.73 (7.3)
起点からの走行距離／OD間距離	4.53 (3.7)
閾値 λ_{turn}	4.00 (4.7)
初期尤度	-354.198
最終尤度	-137.712
修正 ρ^2	0.597
AIC	142.712

サンプル数：511 (t 値)

この結果から、ドライバーは過去 1.0km に経験した最高速度が高いほど走行する幹線（桜通・

広小路通)から逸れにくく、過去 0.5km に経験した停止回数が多いほど走行する幹線から逸れやすい。また、交差する路線が幹線である場合は逸れやすい傾向がうかがえる。このようなドライバーの経路変更行動については、幹線を走行する車両の細街路への迂回行動を扱った他の分析でも同様の結果を得ており (Kitamura et al., 2003), ドライバーはトリップ中であっても、直面した交通状況 (混雑の度合いやネットワーク状況) によって意思決定行動を繰り返しながら終点に向かっていることが確認された。

b) トリップ中の経路選択行動分析

トリップ中の意思決定が発生するとすれば、その際の経路選択行動を表現するモデルパラメータはどのように変化するであろうか。そこで、5.4.5 で対象とした複数の OD ペアのうち、豊場交差点から名古屋駅桜通口に向かう OD において、トリップ途中で通過する幾つかの交差点で意思決定が発生していると仮定して経路選択モデルを推定した。経路選択モデルはこれまでと同様に MNL モデルとし、各経路の旅行時間は 2 時間間隔、交通状況の変化を考慮するとして作成した。各通過交差点に関する推定データの概要を表 5-17 に示す。




図 5-13 トリップ中の経路選択行動分析用交差点

表 5-17 豊場→名古屋駅桜通口トリップの主要通過交差点と対象トリップの概要

通過交差点 No.	起点 (交差点名)	通過交差点名	終点	抽出トリップ数	分析経路数	平均経路長 (km)
1	豊場	黒川	名古屋駅桜 通口タクシ ーターミナ ル	197	70	5.5
2		城北橋		173	61	4.1
3		市役所		95	24	3.2
4		新御園橋		83	22	1.9

これらのデータを用いて、各交差点通過時のデータ、プールしたデータにより MNL モデルを推定した。ここで、プールしたデータには、同一のトリップが複数の通過交差点通過データとして用いられる場合がある。しかし、本研究では同一トリップの連続する意思決定はそれぞれ独立であると仮定して分析を進める。推定結果を表 5-18 に示す。

表 5-18 トリップ中の経路選択モデルの推定結果

モデル No.	1	2	3	4	5*	6*
通過交差点名	黒川	城北橋	市役所	新御園橋	--	--
利用可能経路数	70	61	24	22	--	--
トリップ数	197	173	95	83	548	548
平均経路長(km)	5.5	4.1	3.2	1.9	4.1	4.1

説明変数		パラメータ					
旅行時間 (分)		-0.487 (-5.0)	-0.469 (-3.3)	-0.914 (-3.2)	-0.697 (-1.8)	-0.570 (-8.1)	-0.956 (-4.1)
右左折数		-0.156 (-4.0)	-0.271 (5.2)	-0.266 (-2.6)	-0.703 (-3.5)	-0.208 (-7.3)	-0.378 (-3.4)
国道比率		0.916 (1.8)	2.02 (2.9)	6.90 (1.1)	--	1.10 (3.4)	1.86 (2.9)
県道比率		0.431 (1.2)	--	3.51 (0.5)	1.21 (0.8)	0.227 (1.0)	0.306 (0.7)
スケールパラメータ	No.1						0.458 (3.6)
	No.2						0.637 (3.4)
	No.3						0.856 (2.7)
	No.4						1.00 (--)
初期尤度		-836.954	-711.181	-301.915	-256.557	-2106.605	-2106.605
最終尤度		-806.437	-678.963	-286.026	-235.565	-2021.134	-2016.043
修正 ρ^2 値		0.0317	0.0397	0.0394	0.0623	0.0387	0.0397

*: 全てのデータをプールして推定

(t 値)

ここで、5.4.5 の表 5-12 でスケールパラメータを 1 とおいた OD 間距離が約 2km であったこ

とから、ここでの分析においても、終点までの距離が同様な通過交差点 No.4（御園橋交差点、終点までの距離 1.9km）のデータを適用する場合にスケールパラメータを 1 とした。その上で、通過交差点ごとにスケールパラメータを推定した結果（表中モデル No.6）より、トリップ中の走行位置が終点に近づくにつれスケールパラメータの値が大きくなっており、誤差項の分散が目的地までの距離に応じて小さくなっていることが分かる。図 5-14 に、上表で推定されたスケールパラメータを、5.4.5 で推定されたスケールパラメータや、誤差項の標準偏差が OD 間距離と比例するとして構造化したスケールパラメータとともにプロットした。これにより、トリップ中のスケールパラメータは、OD 間距離の変化に伴うスケールパラメータの変化とほぼ同様に変化していることが分かる。




図 5-14 トリップ中のスケールパラメータの変化

しかし、上表で示された各モデルは、いずれも適合度が非常に低い。同様の OD 間距離、利用可能経路数である、表 5-10 の東片端→名古屋駅桜通口（利用可能経路数：25、OD 間距離：3.3km）の修正 ρ^2 値が 0.399 であるのに対して、上表の市役所→名古屋駅桜通口（利用可能経路数：24、終点までの距離：3.2km）の修正 ρ^2 値は 0.0394 と非常に小さくなっている。この原因の一つとしては、対象とする交差点において必ずしもすべてのドライバーが意思決定を行っているわけではないためであると考えられる。この場合、ドライバーの走行する経路が対象とする通過交差点において最適であるとは限らないため、適合度が低くなってしまうと考えられる。また、上表で示された各通過交差点での旅行時間のパラメータがばらばらについている。これは、各経路の旅行時間にそれほど差がないためや、旅行時間以外の変数の説明力が小さくなったためなどが考えられる。

いずれにしても、通過交差点以前の意思決定ポイントにおいては、ドライバーにとっては最適であった経路でも、トリップ中の交通状況の変化により最適ではなくなってしまうのは当然

である。もし仮に、ドライバーが到着する交差点ごとに必ず意思決定を繰り返しながら終点に近づいているとすれば、さらに適合度が高くなると考えられる。したがって、ドライバーは一度選択した経路をすぐには変更せずそのまま走行しようとする、いわゆる“慣性”のような現象が起きていると考えられる。Mahmassani and Stephan (1988) や Mahmassani and Jayakrishnan (1991)は通勤交通を対象として、ドライバーは旅行時間のより短い経路に関する情報を与えられても即座には経路を変更せず、走行中の経路を引き続き走行する傾向があるとしている。本項で示された結果は、同様の傾向が運転経験の豊富なタクシードライバーでさえ見られることを示し、さらには交通状況の混雑に直面した場合に、経路選択に関する意思決定を行っていることを示している。

5.5.2 トリップ中の意思決定を考慮した経路選択モデル

本章におけるここまでの分析により、経路選択行動のモデル化に向けて得られた知見をまとめると以下のとおり。() 内は分析が行われた本文中の章.節.項)

- ①ドライバーは出発時刻における交通状況を十分には把握しておらず、現実の交通状況は均衡状態にはない可能性がある (5.2)
- ②ドライバーは出発後の交通状況の変化を詳細には把握していない傾向がある (5.4.2)
- ③重複する経路間の相関を考慮することでモデル適合度は向上する (5.4.4)
- ④各経路の効用に対するドライバーの認知度は OD 間距離によって変化し、これはドライバーが認知する経路効用の誤差項の標準偏差が、OD 間距離に比例して変化すると仮定することで表現できる (5.4.5)
- ⑤ドライバーは起点のみではなく、トリップ中においても経験した交通状況（信号停止や走行速度）やネットワーク形状に影響を受けて経路選択に関する意思決定を発生させる (5.5.1)
- ⑥トリップ中の意思決定は、必ずしもすべての交差点で（もしくは、すべての主要交差点で）発生するわけではなく、走行中の経路をそのまま走行しようとする傾向がある (5.5.1)

本項では、これらの知見を基により現実的な経路選択モデル、すなわちトリップ中の意思決定時点を内生化した経路選択モデルを開発する。ただし、上記③における経路間の重複に関しては、分析が過度に繁雑になることを避けるためここでは取り扱わない。

ここで、図 5-15 に示すような 12 リンク、9 ノードからなる格子状のネットワークを考える。利用可能経路集合には後戻りが発生する経路は含まれないものとする、起終点間には図中に示す 6 本の経路が存在することになる。また、トリップ中の意思決定は利用可能な経路が分岐または交差する地点（交差点）でのみ発生し、合流する地点や単路部では発生しないと仮定する。このとき、経路選択に関する意思決定が発生しうるノードを“意思決定ノード”と呼び、

図中に示すネットワーク上には、4つの意思決定ノードが存在することになる．ここで、ある経路上に意思決定ノードが N 個存在する場合、起点から近い順に第 n 意思決定ノード($n=1, \dots, N$)と呼ぶ．例えば、経路2上には意思決定ノードが3個存在し、それぞれを第1意思決定ノード～第3意思決定ノードと呼ぶ．




図 5-15 テストネットワークにおける意思決定ノードと利用可能経路集合

トリップ中の経路選択に関する意思決定の発生確率が、それまでに経験した情報やネットワーク形状などにより説明可能であるとき、意思決定発生モデルは式(5.18)のように二項ロジットモデルを用いて表現できる．

$$q^n = \frac{\exp(\lambda^n)}{\exp(\bar{\lambda}^n) + \exp(\lambda^n)} \quad (5.18.a)$$

$$\lambda^n = \sum_i \theta_i x_i^n \quad (5.18.b)$$

$$\bar{\lambda}^n = \alpha_0 + \alpha D_{rs}^n \quad (5.18.c)$$

ここに、 q^n は第 n 意思決定ノードで意思決定が発生する確率、 λ^n は第 n 意思決定ノードで意思

決定が発生するか否かを規定する関数、 $\bar{\lambda}^n$ は意思決定が発生するか否かを判定する閾値、 x_i^n は意思決定が発生するか否かに影響を及ぼす要因、 D_{rs} はトリップにおいてすでに走行した割合とし、起点からの走行距離 / OD 間距離とする。最後に、 θ_i , α_0 , α は未知パラメータである。

このとき、ドライバーが最終的に走行した経路を与件とすれば、テストネットワークにおける経路2を選択する確率は以下のように表される。

$$\begin{aligned}
P_2 = & p_1^1 \times p_2^2 q^2 \times (1 - q^3) + p_1^1 \times p_2^2 q^2 \times p_2^3 q^3 + p_1^1 \times p_3^2 q^2 \times p_2^3 q^3 + p_2^1 \times (1 - q^2) \times (1 - q^3) \\
& + p_2^1 \times (1 - q^2) \times p_2^3 q^3 + p_2^1 \times p_2^2 q^2 \times (1 - q^3) + p_2^1 \times p_2^2 q^2 \times p_2^3 q^3 + p_2^1 \times p_3^2 q^2 \times p_2^3 q^3 \\
& + p_3^1 \times (1 - q^2) \times p_2^3 q^3 + p_3^1 \times p_2^2 q^2 \times (1 - q^3) + p_3^1 \times p_2^2 q^2 \times p_2^3 q^3 + p_3^1 \times p_3^2 q^2 \times p_2^3 q^3
\end{aligned} \tag{5.19}$$

ここに、 p_k^n は第 n 意思決定ノードで経路 k を選択する確率、 $(1 - q^n)$ は第 n 意思決定ノードにおいて意思決定が発生しない確率である。

ここで、第3意思決定ノードにおける経路2と経路4や経路3と経路5は、終点までの全ての構成リンクが同じであり、ドライバーにとっては経路番号の違いを区別する必要がないため、このような場合はどちらか一方のみを選択可能な経路として扱えばよい。このとき、式(5.19)で示したトリップ中の意思決定発生を考慮した経路選択確率をより一般的に示すと、以下の式で表される。

$$P_k = \sum_{\bar{k}^{1,2}} p_{\bar{k}^{1,2}}^1 \left(\sum_{\bar{k}^{2,3}} \bar{p}_{\bar{k}^{2,3}}^2 \left(\cdots \sum_{\bar{k}^{N-1,N}} \bar{p}_{\bar{k}^{N-1,N}}^{N-1} \left(\bar{p}_{\bar{k}^{N,dest}}^N \right) \right) \right) \tag{5.20.a}$$

$$\bar{p}_{\bar{k}^{n,n+1}}^n = q^n \times p_{\bar{k}^{n,n+1}}^n + \delta_{\hat{k}^n = \bar{k}^{n,n+1}} \times (1 - q^n) \tag{5.20.b}$$

$$p_{\bar{k}^{n,n+1}}^n = \frac{\exp(V_{\bar{k}^{n,n+1}}^n)}{\sum_{\bar{k}^n \in R^n} \exp(V_{\bar{k}^n}^n)} \tag{5.20.c}$$

ここで、 R^n は第 n 意思決定ノードで選択可能な経路の集合、 \bar{k}^n は第 n 意思決定ノードで選択可能な経路、 $\bar{k}^{n,n+1}$ は第 n 意思決定ノードで選択可能な経路のうち、第 n 意思決定ノードと第 $n+1$ 意思決定ノードの間で経路 k （最終的に走行した経路）と重複する経路、 \hat{k}^n は意思決定ノード n に到達した時点ですでに選択していた経路、 $\delta_{\hat{k}^n = \bar{k}^{n,n+1}}$ は、 \hat{k}^n が第 n 意思決定ノードと第 $n+1$ 意思決定ノード間において経路 k と重複するとき 1、そうでないとき 0 をとるダミー変数である。

上式を用いれば、プローブカーデータのような最終的な走行経路や走行中にドライバーが経

験した情報から、より現実的な経路選択行動をモデル化することができる。さらに、推定されたモデルからは、ドライバーがどのような状況下で経路選択に関する意思決定を行っているかを検証することも可能となる。本研究では、上式で記述される経路選択モデルを“意思決定時点内生モデル”と呼ぶ。

意思決定時点内生モデルの有用性を検証するため、名古屋都心部の代表的な経路を対象として分析を行った。対象エリアは 5.5.2 において分析対象とした中区役所－名古屋駅桜通口タクシーターミナル間の OD ペアとし、対象トリップは中区役所前、名古屋駅前をともに通過したトリップとする。ただし、この OD ペア間にも多くの利用可能経路が存在するため、ここでは方向別に代表的な 3 経路を利用可能経路集合として分析を進める。対象経路を図 5-16 に示し、対象トリップの概要を表 5-19 に示す。




図 5-16 意思決定時点内生モデル検証用ネットワーク

表 5-19 検証用トリップデータの概要

経路	名古屋駅→中区役所	中区役所→名古屋駅
A	103	1147
B	153	183
C	99	37
計	1367	355

ここでまず、開発したモデルとの比較を行うため、これまでに用いられてきた経路選択モデルを適用する。すなわち“起点において終点までの経路を一度に決定する”，または“到着するノードごとに意思決定を繰り返す”ものであり、本研究では前者を“静的モデル”，後者を“動的モデル”と呼ぶ。一般に、静的モデルは均衡配分や交通シミュレータで、動的モデルは交通シミュレータや動的配分で用いられている。静的モデルのモデル式は通常の MNL モデルであり、式(5.1)で表される。動的モデルは、意思決定時点内生モデルにおける意思決定発生確率

を考慮しない以下の式で表される．

$$P_k = \sum_{\bar{k}^{1,2}} p_{\bar{k}^{1,2}}^1 \left(\sum_{\bar{k}^{2,3}} p_{\bar{k}^{2,3}}^2 \left(\cdots \sum_{\bar{k}^{n-1,n}} p_{\bar{k}^{n-1,n}}^{N-1} \left(p_{\bar{k}^N,dest}^N \right) \right) \right) \quad (5.21.a)$$

各経路の旅行時間は、ピーク・オフピーク時間帯（4 区分）、交通状況の変化なしとして作成した．静的モデルと動的モデルの推定結果を表 5-20 に示し、意思決定時点内生モデルの推定結果を表 5-21 に示す．

ここで、表 5-21 における意思決定ノードへの到着時刻の予測誤差は以下の式で算出される．

$$\begin{aligned} \text{意思決定ノードへの到着時刻予測誤差} &= \text{意思決定ノード } n \text{ への到着時刻} \\ &- \text{前回の意思決定で予測された意思決定ノード } n \text{ へ到着時刻} \end{aligned} \quad (5.21)$$

推定結果より、意思決定時点内生モデルの AIC は静的モデルや動的モデルより大きく減少しており、適合度が大きく上昇していることが分かる．ただし、ここで推定した意思決定時点内生モデルは、経路選択モデルを対象起点と経路上とに分離しているため、動的モデルとはモデル構造が異なる．このため、適合度の上昇にはモデル構造の違いによる影響も含まれていると考えられる．

ただし、意思決定発生モデルにおけるパラメータの符合は全て正しく、また統計的に有意な値であることから、トリップ中の意思決定発生機構については正しい解釈が可能である．推定結果より、走行中に経験した停止回数や想定していたより遅い走行状況が意思決定を誘発し、終点までの距離が短い場合や走行中に経験した速度が高い場合は、意思決定が発生しにくいことが分かる．この結果は、5.5.1 における右折行動発生モデルによる分析結果と同様の傾向を示している．

起点での右左折数パラメータが有意に正となっている．この点についての理由の 1 つとして、ここでの分析で扱ったデータは必ずしも対象起終点付近に出発・到着地を持つトリップばかりではないことから、ドライバーが対象起点流入以前の真の意思決定地点においては、利用可能経路集合内における選択経路の右左折数が少なかったにもかかわらず、分析対象経路においては利用可能経路集合がドライバーの認知する経路集合とは異なっており、右左折数が相対的に多くなってしまった可能性も考えられる．また、経路上での旅行時間パラメータ値は対象起点でのパラメータ値よりも小さく、また t 値も小さくなっている．前項までの分析により、目的地までの距離が短くなれば誤差項の標準偏差が残り距離に比例して小さくなるため、パラメータのスケールは大きくなるはずである．これに対しての理由としては、仮に使用した旅行時間データがドライバーの認知する旅行時間と類似している場合は、トリップ中の意思決定に際し

での旅行時間情報の重要性が低下していることを示唆する結果であり、ドライバーはトリップ中の意思決定には残り区間の旅行時間をそれほど重要視していない解釈できる。またその一方で、仮に使用した旅行時間データがドライバーの認知する旅行時間情報と大きく異なっている場合は、使用した説明変数の精度が低くその説明力が低いためであると解釈できる。いずれにしても、トリップ中のドライバーが認知する旅行時間情報については、本研究では十分に明らかにされておらず、今後の重要な課題の1つとして挙げられる。

本研究で開発した意思決定時点内生モデルは、複雑な潜在クラス構造であり高度に非線形であるため収束計算が非常に難しい。本研究でも多くの条件設定に対して意思決定時点内生モデルを適用したが、収束解が得られることは稀であった。このため、トリップ中の意思決定時点を考慮した場合の経路選択行動については、十分な分析を行うことができなかった。また上述した推定結果とも関連するが、さらなる分析が必要な項目として、トリップ中の経路選択における経路旅行時間の設定方法が挙げられる。ここで示した分析では、ピーク・オフピーク時間帯、交通状況の変化なしとして経路旅行時間を算出しているが、実際にはトリップを開始して交通状況を経験することで、経路旅行時間に関する認知が向上すると考えられる。しかしその一方で、表 5-21 に示した結果から、トリップ開始後においては旅行時間に関する重要性が低下することが示されている。このように、トリップ中におけるドライバーの旅行時間に対する認知や、その表現方法についての分析を行う必要がある。

表 5-20 静的モデルと動的モデルの推定結果

説明変数	静的モデル	動的モデル
旅行時間 (分)	-0.413 (-2.1)	-0.374 (-1.9)
右左折数 (回)	-1.18 (-23.8)	-1.13 (-23.9)
初期尤度	-1891.806	-2044.307
最終尤度	-1352.651	-1485.347
修正 ρ^2 値	0.284	0.272
AIC	1354.651	1487.347

サンプル数 : 1722 (t 値)

表 5-21 意思決定時点内生モデルの推定結果

説明変数			パラメータ
意思決定発生 モデル	$\bar{\lambda}^n$	定数項	2.46 (2.9)
		起点からの走行距離／OD 間距離	6.51 (4.9)
	λ^n	意思決定ノードへの到着時刻の予測誤差 (分)	4.53 (9.2)
		過去 500m での停止回数 (回)	1.78 (6.1)
		過去 1000m での最高速度 (km/h)	-0.0906 (-5.3)
経路選択モデル (起点)	旅行時間 (分)		-2.27 (-5.2)
	右左折数 (回)		1.93 (8.5)
経路選択モデル (経路上)	旅行時間 (分)		-0.571 (-1.4)
	右左折数 (回)		-2.38 (-20.5)
初期尤度			-1955.107
最終尤度			-1069.963
修正 ρ^2 値			0.448
AIC			1078.963

サンプル数 : 1722 (t 値)

5.6 本章のまとめ

本章では、プローブカーデータがドライバーの経路選択実績データとして従来の交通データよりも詳細な情報を提供する点に着目し、プローブカーデータに基づく経路選択行動の分析を行った。

5.1 においては、プローブカーデータを経路選択行動分析に用いる場合の有用性や問題点についてまとめた。

5.2 では、名古屋空港－名古屋駅間のトリップを用いて、経路上の代表区間別にトリップ数と平均旅行時間を用いて分析した。この結果、ドライバーは上り方向と下り方向では異なる経路選択行動を示しているか、方向別の交通状況を十分考慮しないで経路選択を行っていることを明らかにした。また、一般道路より旅行時間の大きい高速道路を利用するトリップが多いことや、一般道路においても最も早い経路のトリップ数が少ないことなどを明らかにした。この結果より、現実の交通状況は、これまで一般的に仮定されてきた交通均衡状態にはない可能性を示した。

5.3 では、経路選択モデルの適用場面において概説した後、これまでに開発された様々な経路選択モデルについて説明を行った。

5.4 では、プローブカーデータを用いてドライバーが認知する経路旅行時間について分析した結果、ドライバーは詳細な交通状況や、出発後の交通状況の変化までは考慮して経路選択行動を行っていない可能性があることを示し、また右左折数や道路種別構成比率により、経路の認知度が異なることを示した。また、MNL モデル、NL モデル、C-Logit モデル、PSL モデル、PCL モデルについて、プローブカーデータを用いて適用性の検証を行った。この結果、C-Logit モデルが適合度や操作性の面で、現実の経路選択行動を最も再現できる可能性を示した。また、利用可能経路集合の適切な設定や、経路選択行動の動的な扱いが必要であることを示した。さらに、OD 間距離が経路選択行動に与える影響について分析した結果、ドライバーの経路効用に対する認知は OD 間距離により変化し、これは経路効用の誤差項の標準偏差が OD 間距離に比例するとして表現できることを示した。

5.5 では、経路選択行動をより動的な交通行動として捉え、トリップ中に発生する経路選択行動を分析した。この結果、トリップ中の意思決定は到着ノードごとに発生するわけではなく、出発後に経験した走行状況やネットワーク形状によって誘発されることを示し、より動的な枠組みで経路選択を分析するための経路選択モデルを開発した。

以上のように、本章ではプローブカーデータがドライバーの走行経路に関する情報を非常に詳細に提供できることに着目し、現実の経路選択行動をさまざまな角度から分析した。このようにプローブカーデータを用いれば、これまでは困難であった多くの分析に取り組むことが可能となる。しかし、本研究で使用したプローブカーデータにおけるドライバーはタクシードライバーであることから、より汎用性のある経路選択行動の分析結果を得るためには、一般車を

プローブカーとして収集する必要性がある点や、ドライバーの個人属性や認知する利用可能経路集合についての分析が可能な情報が利用できれば、さらに有用な知見を得ることが可能であると考えられる。ただし、より詳細なトリップ属性を踏まえた経路選択行動の分析は今後取り組む必要がある。本研究で使用したプローブカーデータは、朝ピーク時間帯のデータが少なく、また実験期間には雨天時のデータが非常に少なかったため、詳細な分析を行うことができなかったが、このようなより詳細なトリップ属性を踏まえた分析により、現実の経路選択行動に対する新たな知見が得られると考えられる。

また、本章での分析の多くは MNL モデルを適用しており、利用可能経路集合に含まれる各経路間の相関を考慮していない。しかし、5.4.4 で示された結果からも、重複する経路間の相関を考慮することでモデル適合度は向上することが示されており、より現実的なモデルの適用についても取り組む必要がある。

さらには、トリップ中の経路選択行動に際しての、ドライバーが認知する経路旅行時間情報に関する分析は十分とはいえない。本研究では、意思決定内生モデルの推定結果から、トリップ中における旅行時間情報の重要性が低下する傾向を示したが、このような動的な旅行時間認知に関する分析を行うためには、より多くの OD ペアを対象としてより一般的な知見を得る必要がある。このような動的な認知行動の分析は、より現実的な経路選択モデルを交通シミュレータ等に適用する上で非常に重要であると考えられる。

第 5 章 参考文献

- 飯田恭敬, 内田敬, 宇野伸宏 (1990) 通勤者の旅行時間予測機構に関する実験分析, 土木計画学研究・講演集, No.13, pp.335-341.
- 飯田恭敬, 内田敬, 山本政博, 村田重雄 (1991) 実験アプローチによる動的経路選択行動のモデル化, 土木計画学研究・講演集, No.14 (1), pp.271-278.
- 岩倉成志, 新倉淳史, 高平剛 (2004) 経路選択行動におけるサービス水準の知覚誤差, 土木学会論文集, No.765/IV-64, pp.39-48.
- 大草裕二郎, 朝倉康夫 (2000) EBA を組み込んだ確率的利用者均衡問題の計算法, 土木計画学研究・講演集, No.23 (2), pp.743-746.
- 岡田良之, 三輪富生, 森川高行 (2004) 認知誤差を考慮したマルチクラス確率的利用者均衡配分モデルに関する研究, 第 24 回交通工学研究発表会論文報告集, pp.157-160.
- 久保篤史, 飯田恭敬, 宇野伸宏 (1996) 旅行時間情報提供下での逐次経路選択行動に関する実験分析, 土木計画学研究・講演集, No.19 (2), pp.749-750.
- 久保田尚, 福山剛男, 坂本邦宏 (1999) くり返し走行実験による自動車運転者の経路選択機構とその変容に関する研究, 土木計画学研究・論文集, No.16, pp.643-650.
- 桑原雅夫 (1989) 交通量配分手法の実証的検討, 交通工学, Vol.23, No.2, pp.17-25.
- 交通工学会編 (2000) やさしい交通シミュレーション, 丸善.
- 全国道路利用者会議 (2002) 道路行政平成 13 年度版.
- 土木学会編 (1998) 交通ネットワークの均衡分析—最新の理論と解法—, 丸善.
- 羽藤英二, 香月伸一, 杉恵頼寧 (1997) Intranet Survey による SP データを用いた交通情報獲得・経路選択行動分析, 土木計画学研究・講演集, No.21(1), pp.403-406.
- 羽藤英二, 朝倉康夫, 粕谷増男 (2000) 複数情報リソース下における行動的不均衡を考慮した経路変更モデル, 土木学会論文集, No.653/IV-48, pp.51-61.
- 羽藤英二, 朝倉康夫 (1999) 限定合理性を考慮した経路選択モデルと均衡配分手法, 土木計画学研究・講演集, No.22 (2), pp.191-194.
- 羽藤英二, 谷口正明, 杉恵頼寧, 桑原雅夫, 森田綽之 (1998) 複数交通情報リソース下における情報獲得・参照行動を考慮した経路選択モデル, 土木学会論文集, No.597/IV-40, pp.99-111.
- 羽藤英二 (2002) ネットワーク上の交通行動, 土木計画学研究・論文集, Vol.19-1, pp.13~27.
- 林成卓, 藤井聡, 北村隆一, 大窪剛文 (1998) ドライバーの認知所要時間の確率構造に関する実証的研究, 土木学会第 53 回年次学術講演会講演概要集, pp.652-653.
- 日比野直彦, 兵藤哲朗, 内山久雄 (2003) 高密度な鉄道ネットワークへの実適用に向けた C*-Logit モデルの検証, 土木計画学研究・講演集, Vol.28, CD-ROM.
- 日比野直彦, 兵藤哲朗, 内山久雄 (2004) 高密度な鉄道ネットワークへの実適用に向けた非 IIA

- 型経路選択モデルの特性分析—改良型 C-Logit モデルの提案—, 土木学会論文集, No.765 /IV-64, pp.131-142.
- 兵藤哲朗, 室町泰徳 (2001) 個人選択行動モデルの最近の開発動向に関するレビュー, 土木計画学研究・論文集, Vol.18, No.3, pp.517~522.
- 平井千智, 羽藤英二, 朝倉康夫 (1999) 経路選択の不確実性を考慮した逐次的な情報参照モデル, 土木計画学研究・講演集, No.22(1), pp.319-322.
- 福田大輔, 森地茂 (2002) 選択肢の選別過程に関する実証比較分析: 交通手段選択行動を対象として, 土木計画学研究・論文集, No.19, pp.375-381.
- 藤井聡, 守田武史, 北村隆一, 杉山守久 (1998) 不確実性に対する態度を考慮した交通需要予測のための経路選択モデル, 土木計画学研究・講演集, No.21 (1), pp.387-390.
- 古屋秀樹, 牧村和彦, 川崎茂信, 赤羽弘和 (2003) 車載型センサーを用いた車両挙動特異地点抽出に関する基礎的研究, 土木計画学研究・論文集, Vol.21, No.4, pp.787-795.
- 眞浦靖久, 朝倉康夫, 羽藤英二, 宗貞孝太郎 (1999) 選択経路集合生成アルゴリズムの提案と松山市道路網での検証, 土木計画学研究・講演集, No.22 (2), pp.187-190.
- 円山琢也, 原田昇, 太田勝敏 (2002) 大規模都市圏への交通需要統合型ネットワーク均衡モデルの適用, 土木計画学研究・論文集, Vol.19, No.3, pp.551-560.
- 溝上章志, 松井寛 (1990) 均衡交通量配分手法の推定特性に関する実証的分析, 交通工学, Vol.25, No.6, pp.33~43.
- 溝上章志, 松井寛 (1993) Fisk 型確率均衡配分モデルの未知パラメータ θ の推定に関する一手法, 交通工学, Vol.25, No.2, pp.21-29.
- 溝上章志 (2003) P&R 需要予測への GEV 型手段選択モデルの適用可能性, 日本都市計画学会論文集, No.38-1, pp.40-45.
- 宮城俊彦, 小川俊幸, 小嶋幸則 (1989) 均衡確率配分法に関する事例研究, 土木学会第 40 回年次学術講演会講演概要集, pp.503~504.
- 宮城俊彦, 水口晴男 (1995) 複合交通手段を考慮した交通ネットワーク均衡モデルに関する研究, 土木学会論文集, No.512/IV-27, pp.25-33.
- 三輪富生, 森川高行: (2000) 複数の高速道路経路を考慮した確率的均衡配分法に関する研究, 土木計画学研究・講演集, Vol.23, pp.739-742.
- 森川高行, 竹内博史, 加古裕二郎 (1991) 定量的観光魅力度と選択肢集合の不確実性を考慮した観光目的地選択分析, 土木計画学研究・論文集, No.9, pp.117-124.
- 森津秀夫, 中島正樹 (1997) 動的経路誘導のための経路選択行動モデルに関する一考察, 土木計画学研究・論文集, No.14, pp.621-630.
- 矢部義雄, 藤井聡, 北村隆一 (1994) 個人の経路選択決定要因を把握するための非集計モデルの構築, 土木学会第 49 回年次学術講演会講演概要集, pp.868-869.
- Abdel-Aty, M.A., R. Kitamura and P.P. Jovanis (1995) Exploring route choice behavior using

- geographic information system-based alternative routes and hypothetical travel time information input, *Transportation Research Record 1493*, pp.74-80.
- Bekhor, S., M.E. Ben-Akiva, and M.S. Ramming (2002) Adaptation of Logit Kernel to Route Choice Situation, Transportation Research Board 81st Annual Meeting, CD-ROM.
- Ben-Akiva, M. and B. Boccara (1995) Discrete choice models with latent choice sets, *International Journal of Research in Marketing*, 12, pp.9-24.
- Ben-Akiva, M. and M. Bierlaire (1999) Discrete choice methods and their applications to short term travel decisions, *Handbook of Transportation Science* ed R.W. Hall, pp.5-33. Kluwer Academic Publishers.
- Ben-Akiva, M. E. and S.R. Lerman (1985) Discrete choice Analysis: Theory and Application to Travel Demand, MIT Press, Cambridge, Ma.
- Cascetta, E., A. Nuzzolo, F. Russo and A. Vitetta (1996) A modified logit route choice model overcoming path overlapping problems. Specification and some calibration results for interurban networks, Proceedings of the 13th International Symposium on the Theory of Road Traffic Flow.
- Cascetta, E. (2001) Transportation systems engineering: theory and methods, Kluwer Academic Publishers.
- Cascetta, E., F. Russo, F.A. Viola, and A. Vitetta (2002) A Model of Route Perception in Urban Road Networks, *Transportation Research Part B* 36, pp.577-592.
- Chu, C. (1989) A paired combinatorial logit model for travel demand analysis, Transport Policy, Management & Technology Towards 2001: Selected Proceedings of the 5th World Conference on Transport Research, Vol. 4, pp. 295-309, Ventura, CA: Western Periodicals Co.
- Dial, R.B. (1971) A probabilistic multipath traffic assignment algorithm which obviates path enumeration, *Transportation Research*, 5, pp.83-111.
- Fernandez, E. and J.D. Cea (1995) Network Equilibrium Models with Combined Modes, *Transportation Science*, Vol.28, No.3, pp.182-192.
- Gliebe, J. P., Koppelman, F. S. and Ziliaskopoulos, A. (1999) Route choice using a paired combinatorial logit model, Transportation Research Board 78th Annual Meeting, CD-ROM.
- Horowitz, J.L. and J.J. Louviere (1995) What is the role of consideration sets in choice modeling, *Intern. J. of Research in Marketing*, 12, pp.39-54.
- Keats, J.A. (1971) AN INTRODUCTION TO QUANTITATIVE PSYCHOLOGY, John Wiley & Sons Australasia Pty Ltd. (島津一夫, 石井巖 訳 (1973) 計量心理学, 基礎心理学 4)
- Kitamura, S., T. Yamamoto, T. Yoshii and T. Miwa (2003) Descriptive Analysis of Detouring Traffic though Neighborhood Streets Using Probe Car Data, Proceedings of 10th World Congress on Intelligent Transport Systems, CD-ROM.
- Koppelman, F. S. and Wen, C. H (2000) The paired combinatorial logit model: properties, estimation

- and application, *Transportation Research Part B*, 34, pp. 75-89.
- Mahmassani, H.S. and D.G. Stephan (1988) Experimental Investigation of Route and Departure Time Choice Dynamics of Urban Commuters, *Transportation Research Record 1203*, pp.69-84.
- Mahmassani, H.S. and R. Jayakrishnan (1991) System performance and user response under real-time information in a congested traffic corridor, *Transportation Research Part A* 25, No.5, pp.293-307.
- Prashker, J. N. and S. Bekhor (1998) Investigation of stochastic network loading procedures, Transportation Research Board 77th Annual Meeting, CD-ROM.
- Srinivasan, K.K. and H.S. Mahmassani (2001) Trip time perception and judgment process in Tripmaker decisions under real-time traffic information, Transportation Research Board 81st Annual Meeting, CD-ROM.
- Srinivasan, K.K. and H.S. Mahmassani (2003) Analyzing heterogeneity and unobserved structural effects in route-switching behavior under ATIS: a dynamic kernel logit formulation, *Transportation Research Part B* 37, pp.793-814.
- Swait, J. and M. Ben-Akiva (1986) Analysis of the effects of captivity on travel time and cost elasticities, In Behavioral Research for Transport Policy, VNU Science Press, pp.119-134.
- Swait, J. (2001) Choice set generation within the generalized extreme value family of discrete choice models, *Transportation Research B* 35, pp643-666.
- Train, E.K. (2003) Discrete choice methods with simulation, Cambridge University Press.
- Yai, T., S. Iwakura and S. Morichi (1997) Multinomial probit with Structured covariance for route choice behavior, *Transportation Research Part B* 31, No.3, pp.195-207.
- Vovsha, P. (1997) Application of cross-nested logit model to mode choice in Tel Aviv, Israel, Metropolitan Area, *Transportation Research Record 1607*, pp.6-15.
- Vovsha, P. and S. Beckhor (1998) Link-nested logit model of route choice: overcoming route overlapping problem, *Transportation Research Record 1645*, pp.133-142.
- Wardrop, J.G. (1952) Some theoretical aspects of road traffic research, *Proceedings of the Institution of Civil Engineers, Part II*, pp. 325-362.

第 6 章 結論

6.1 本研究の成果

道路ネットワーク上の交通行動分析は、道路交通計画において重要な作業であり、これまでも多く研究が行われてきた。これまでの多くの研究は、都市圏レベルのゾーン間 OD 表と広域ネットワークを対象としたマクロ的な分析や、詳細な街路やその流入出交通量を与件とした信号交差点の運用計画などのミクロ的な分析である。しかし、ITS 技術の進展とその実用化が迫りつつある現在では、より詳細な、そしてより動的な交通行動分析に対する必要性が高まりつつある。すなわち、今後の ITS 技術の進展により実施可能となるソフト的な交通施策が交通状況に与えるインパクトを、ドライバーの交通行動の変化を踏まえてより詳細に分析する必要がある。プローブカーデータは、現実の道路ネットワークを実際に走行する車両の走行軌跡データであり、交通状況に関する情報や、時々刻々と変化する交通状況に対してドライバーが行う経路選択行動を分析することが可能である。このため、プローブカーデータは今後の交通行動分析において、重要な役割を果たすと期待されている。そこで本研究では、プローブカーデータを詳細な交通行動分析に用いるためのデータ変換技術を開発した上で、これから広く取り組まれるであろうより詳細かつ動的な交通行動分析へ向け、旅行時間予測・更新手法の開発、およびこの技術を援用した経路選択行動分析を行った。

第 1 章では、本研究の背景と目的を述べ、本論文の構成を示した。

第 2 章では、プローブカーデータを用いた交通行動分析の位置づけを示すことを目的とし、パーソントリップ調査データや道路交通センサスデータなど、従来の代表的な交通データとプローブカーデータの比較を行った上で、プローブカーシステムの概要や、その利点・欠点について論じた。

第 3 章では、プローブカーデータを交通行動分析に用いるために必要なデータ変換技術である、マップマッチングアルゴリズムの必要性を論じ、本研究で使用したプローブカーデータに対して、より正確に走行経路を特定することが可能なアルゴリズムの開発を行った。名古屋実証実験のようにプローブカーデータのリアルタイム性を重視する場合は、既存の通信ネットワークを利用する必要がある。この場合、データ送信量や送信回数に応じて実験費用が高価となるため、頻繁なデータ送信を行うことは難しく、このため送信間隔が比較的長くなる。その結果として、車両の走行軌跡を十分な精度で特定することが困難となる。特に名古屋都市圏やその他の大都市圏のように、都市内の一般道路上に都市高速道路が立体的に配置されている場合には、車両の走行位置座標のみからでは正確な走行経路を特定することが困難である。さらに、プローブカーの走行経路を特定するために開発された既存のマップマッチングアルゴリズムでは、これらの点を克服することが難しい。本研究では、車両の走行速度と走行路線の関係に着

目し，都市高速道路の立体的配置区間においても精度よく走行経路を特定するためのマップマッチングアルゴリズムを開発した．この結果，特に走行経路特定が困難な OD ペアに対しても，94%程度の精度で走行経路を正しく特定することができることを示した．しかし，データ送信間隔の長さから，右左折交差点を特定することが困難な場合や，都市高速道路上の極端な渋滞により走行路線を誤って特定する場合もみられ，この点については車載機の改良や新たな送信トリガの設定など，車載機側のハード的な改良の必要性を論じた．

さらに，膨大な量のトリップデータを効率的に処理するためのフローを示し，類似した起終点を持つトリップごとにマップマッチング処理を行うことで，既存の研究で示された処理速度と比較して十分な速度でデータ処理を行えることを示した．最後に，マップマッチング処理されたプローブカーデータを断面交通データとして蓄積するための方法を示し，これにより任意の時刻，道路区間における平均旅行時間情報が利用可能となることを示した．

第4章では，マップマッチング処理後のプローブカーデータから作成されるデータベースである，リンクコストテーブルを用いた最適経路探索アルゴリズムを開発した．ここで開発した手法は，出発後の交通状況の変化をリンクコストテーブルにより予測し，事後的にも（トリップ終了後に考えても）最短となる経路を探索するものである．これにより予測される旅行時間は，出発後の交通状況の変化を考慮しない場合と比較して予測精度が高く，特に交通状況の変化の激しい時間帯においては予測精度が大きく向上することや，予測される最短経路も大きく変化することを示した．また，このアルゴリズムは通常の Dijkstra 法と比較して多くの記憶領域を必要とするものの，探索計算速度はわずか 0.02 秒程度であり，最短経路探索システムとして実用に耐えうるものであることを示した．

しかし，ここで示したアルゴリズムにより探索される経路は，トリップ開始後の交通状況が平均的に変化する場合にのみ適用可能であり，さらには，ドライバーの走行特性をも平均的であることを前提としているため，いかなる時刻においても，またすべてのドライバーに対して必ずしも適切に旅行時間を予測可能であるとは限らない．この点を問題意識とし，より動的な視点からトリップ中における残り区間の予測旅行時間更新手法の開発を行った．ここでは，プローブカーデータがトリップ中の走行状況についての詳細な情報を提供する点に着目し，トリップ開始後のドライバーの走行特性と，過去に収集し，蓄積された同じ経路を走行したデータを用いて，残り区間の旅行時間更新手法を開発した．

開発した手法は4種類であるが，蓄積データを非集計的に扱う手法と集計的に扱う手法に大別される．前者は，蓄積データに含まれる各データと対象トリップの走行データを一対比較することで，類似度の高い蓄積データを抽出して残り区間の予測旅行時間を更新する手法であり，後者は蓄積データを集計し，統計的手法を用いて残り区間の予測旅行時間を更新する手法である．本研究で示された分析結果より，前者と後者では予測更新精度が異なることを示し，蓄積データ数が少ない場合は非集計的な取り扱いがより高い予測更新精度を導くことを示した．ただし，集計的に蓄積データを扱う場合は，対象経路を断片的に通過したデータを利用すること

が可能である。上杉ら（2003）はこの点に着目し、交通シミュレータを用いて、断片的に通過するプローブカーの全体交通量に占める割合と旅行時間予測精度を分析している。従って、より多くのプローブカーデータを蓄積しより詳細に分析することで、統計的な手法の有効性も検証可能となる。

第5章では、プローブカーデータが膨大な経路選択実績データとして利用可能である点に着目し、これまで最も一般的に交通状況を説明してきた交通均衡の概念について検証を行った。また、これまでに開発された経路選択モデルについて概説し、大規模な経路集合にも適用可能ないくつかの経路選択モデルへの適用を試みた。さらに、より現実的な経路選択行動についてさまざまな分析を行い、トリップ中における意思決定の発生を考慮した動的な経路選択モデルを開発した。

名古屋都市圏において最もタクシートリップの多いODペアの1つである、名古屋駅 - 名古屋空港間においてドライバーの利用経路を集計することにより、一般道路利用経路より旅行時間の大きな都市高速道路（有料道路）経路の利用や、一般道利用経路間においても十分に旅行時間の短い経路が存在することを明らかにした。この結果より、タクシードライバーのように交通状況や道路ネットワークに関する認知度の高いドライバーでさえ、必ずしも最短経路を的確に選択しているとは限らず、現実の交通状況は旅行時間や一般化費用に基づく均衡状態には達していない可能性を示した。また、これまでに開発された様々な経路選択モデルのうち、MNLモデル、NLモデル、C-Logitモデル、PSLモデル、PCLモデルに対して、プローブカーデータより収集された経路選択実績データを適用した結果、重複区間を持つ経路間の相関を考慮することで適合度が向上することを示し、本研究で得られたデータに対しては、理論的な背景は少ないものの、モデルの操作性や再現性の点においてC-Logitモデルが最も優れていることを示した。

さらに、距離の異なるいくつかのODペアを対象として、トリップ長の違いにより経路選択行動が異なることを示し、これをより適切に表現するためには、OD間距離が短くなるほどドライバーの経路効用に対する認知誤差が小さくなると説明することで、現実の経路選択行動をより適切に再現可能であることを示した。具体的には、経路効用の誤差項の標準偏差がOD間距離に比例するとして、スケールパラメータをOD間距離により構造化することで、トリップ長によらず同一のモデルを適用する従来の経路選択モデルと比較して大きく適合度が向上することを示した。

また、これまで一般的に行われてきた経路選択行動分析は、OD間距離がどれほど長い状況下でも、ドライバーは起点において終点までの詳細な経路を一度に決定するとしている。そこで、名古屋都心部の交通混雑の激しいエリアを対象として、トリップ中の意思決定発生の可能性を分析した結果、ドライバーはトリップ中の停止回数やネットワーク形状により意思決定を発生させ、また過去に経験した速度が高いほど意思決定を起こしにくい傾向があることを示した。さらに、トリップ中の経路選択行動を適切に表現するためには、距離の異なるOD間にお

ける分析と同様に，経路効用の誤差項の標準偏差が終点までの距離に比例するとしてスケールパラメータを構造化することで再現可能であることを示した．また，ドライバーは必ずしも全ての交差点で意思決定を行っているとはいえず，一旦選択した経路をそのまま走行しようとする“慣性”のような現象が存在することを示した．

これらの結果を踏まえ，経路選択行動をより動的に分析するための意思決定時点内生モデルを開発し，その有効性を検証するため名古屋都心部の主要経路に適用した．この結果，起点のみもしくは到着交差点ごとに意思決定を行うと仮定した従来の経路選択モデルが，より現実的な枠組みを背景として大きく改善可能であることを示した．

6.2 今後の課題と展望

前節で述べたように，プローブカーデータを用いることで，これまでは取り扱うことの難しかった様々な道路ネットワーク上の交通行動分析が可能となる．最後に，本研究で対象としたマップマッチングアルゴリズムの開発，旅行時間予測手法の開発，経路選択行動の分析，そして，本研究で分析された各項目の統合的な交通行動分析について，残された課題を踏まえつつ今後の展望を以下に示す．

a) マップマッチングアルゴリズムの開発

本研究で使用したプローブカーデータは，リアルタイム性を重視したデータであるにもかかわらず，マップマッチング処理はセンタサーバに蓄積されたデータをオフラインにより処理している．収集データをより有効に利用するためには，プローブカーの走行軌跡はリアルタイムにマップマッチング処理されるべきである．送信されたデータをリアルタイムに処理することで，別途必要となる処理時間を削減できることから，リアルタイムマップマッチングの必要性は高いといえよう．これまでは簡易的に近接リンクへのリアルタイムマッチングを行っているが，より正確で利用価値の高い情報をリアルタイムに分析に用いるための，走行経路特定精度の高いアルゴリズムが必要となる．

これまでに開発されたマップマッチング技術の多くは，交通工学分野以外の研究領域で組み込まれていることは第3章で既に述べた．これらの技術の多くが，1秒間隔の車両位置情報を用いるものであり，車両が通過した1本のDRMリンクに対して複数の車両位置情報がマッチングされることになる．しかし，名古屋実証実験により収集されたプローブカーデータは，送信エラーやGPSの位置測位エラーが発生しない場合でさえ車両位置座標の間隔は最大で300mとなり，そのようなエラーが発生すればデータ間隔はさらに長くなる．このような場合は，連続する2つの位置座標の間に多くの走行可能経路が存在することになり，走行状況や走行路線情報などを用いて，より適切な通過経路を特定するアルゴリズムが必要となる．

これを解決するための考え方としては，経路選択モデルを適用する方法が挙げられる．車両

がある地点まで走行した際の走行状況を条件として、それ以降に観測される車両位置座標までの区間を、車両がどのような経路を走行したかを特定するための経路選択モデルを作成する方法である。さらには、これまで文字列処理において頻繁に取り扱われている、隠れマルコフモデルを援用することも有効であると考えられる（北，1999）。つまり、連続する車両位置座標間の走行経路が未確定である場合に、走行経路を構成するリンク集合が最も高い状態遷移確率となるよう特定する考え方である。これらの方法は、システムを構築する以前に、対象エリアのネットワーク形状や交通状況を踏まえて、経路選択モデルや状態遷移確率行列などを詳細に分析する必要があるが、より精緻なリアルタイムマップマッチングアルゴリズムを開発するためには必要不可欠であり、既に膨大な量のプローブカーデータが蓄積されていることから今後取り組んでいくべき重要な研究課題である。

b) 旅行時間予測システムの開発

これまでに開発された旅行時間予測手法のほとんどが、高速道路や主要幹線道路を対象としているのに対して、本研究では一般道路を含めた全てのネットワークを対象としている。ネットワーク上に含まれる全てのリンクを扱う場合の注意点として、幹線と細街路の取り扱い方が挙げられる。出発後の交通状況の変化を考慮して、事後的にも最短となる経路を探索することの有効性を本研究では示したが、探索される経路は細街路を多く通過したり、右左折が非常に多い経路を探索するなど問題点も多い。このためには、右左折コストを考慮したり、起点と終点付近においては細街路を利用し、それ以外においては幹線道路を利用するなど、階層的なネットワークの取り扱いが必要となる。丹羽ら（1990）らは同様の考え方に基づいた階層的な経路探索アルゴリズムを示しているし、大西・加藤（1992）は右左折コストを用いた経路探索手法を提案している。さらに、Hellings and Fu (2002) は、交通シミュレーションを用いて、仮想のプローブカーデータに基づく幹線道路上の信号停止を考慮した旅行時間の算出方法を示している。今後のより実用的な最適経路の探索と旅行時間予測には、これらの技術を応用した最適経路探索手法を開発する必要がある。

また、実際に利用者に最適経路を提供する場合には、複数の代替経路を提供する必要がある。これまでも、代替経路算出方法が提案されていることは3章で既に述べたが、ドライバーが利用経路を選択する際に、情報として必要とする経路の特徴について調査・分析し、提供情報として適切な複数の経路を効率よく探索するための技術が必要となる。

ドライバーは毎日同じ経路を走行することが多い。通勤トリップや帰宅トリップがその典型的な例であるが、このような場合は同一経路の走行状況に関する情報を多く収集することが可能となる。本研究で示した予測旅行時間更新手法は、同一経路を過去に走行した履歴を蓄積データとし、対象トリップの走行状況（経験データ）との関係を用いることで残された区間の旅行時間を予測しようとするものであり、同一のドライバーが頻繁に走行する経路の情報が収集可能な状況であればより実行力の高い技術となりうる。

以上の点を踏まえ、本研究で開発した技術を発展させることで、走行経験が蓄積され、かつ

利用するほど精度が向上する予測型カーナビゲーションシステムの開発が可能となると考えられる。

c) 経路選択行動の分析

本研究では、道路ネットワーク上の需要予測ツールに適用するための経路選択モデルについての有用な知見を得ることを目的として、ドライバーの経路選択行動を分析した。ここでの分析は、大規模なネットワークを対象としても効率的な交通量負荷計算を可能とする Dial のアルゴリズムにも適用可能な知見を得るためである。すなわち、すべての利用可能経路集合を対象とした場合においても適用可能な分析結果を得るために、本研究では観測されたすべての経路を利用可能経路集合としている。しかし、このような大規模な経路集合においては各経路間に重複区間が多く存在し、誤差項の独立性を仮定することが必ずしも適切とはいえない。実際に本研究においても、誤差相関を考慮することでモデル適合度が向上することが示されている。従って、誤差相関を考慮した適切なモデルによる詳細な分析が必要となる。

また、大規模な選択肢集合の適用に関連して、不確実性状況下における意思決定の記述理論である、期待効用最大化理論に対する疑問も投げかけられているのも事実である (Tversky, 1972; Kahneman and Tversky, 1979)。しかし、本論文中において何度も記述したように、プローブカーデータからはドライバーの個人属性が得られない上、ドライバーが認知する利用可能経路集合に関する情報も得られない。従って、今後はアンケート調査などその他のデータを援用しつつ、ドライバーが認知する利用可能経路集合に関する分析が必要であり、さらには、意思決定基準についても十分な分析が必要であると考えられる。

また本研究では、トリップ中の意思決定の発生を内生化した動的な経路選択モデルを開発したが、トリップ中における経路選択には、トリップ中に経験した走行状況に関する情報のみならず、進行方向においてドライバーが目の当たりとする混雑状況も影響を与えていると考えられる。VICS データには渋滞度情報として幹線道路上の混雑状況も記録されていることから、これらのデータを用いたより現実的な意思決定発生構造の分析を試みる必要がある。

また、トリップ中の経路選択において、ドライバーが認知する経路旅行時間に関する分析を行う必要がある。直感的には、ドライバーはトリップを開始して実際に交通状況を体験することで、経路旅行時間に関する認知が向上すると考えられる。しかしその一方で、意思決定時点内生モデルの結果から、トリップ中における旅行時間に関する重要性が低下する可能性も示されている。経路選択行動の分析に際して、ドライバーが認知する旅行時間情報を用いず、実際の旅行時間など客観的に与えられた情報を用いて推定されたモデルは、現実の経路選択行動を適切に表現することはできない (Srinivasan and Mahmassani, 2001)。このように、トリップ中におけるドライバーの旅行時間に対する認知や、それを表現するためのモデルの記述方法などに関する分析を行う必要がある。

d) 情報提供効果を考慮した統合的な交通行動分析

最後に、第 4 章でも述べたが、より精度の高い旅行時間予測手法とドライバーの経路選択行

動モデルは、ドライバーの情報獲得・参照行動を介して密接な関わり合いを持つ。羽藤ら(1998)はこのようなドライバーの情報獲得行動を詳細に分析しているし、情報提供とその交通状況に与える影響を分析する必要性を述べた論文は多い(例えば、Mahmassani and Jayakrishnan, 1991; 小林ら, 1993)。さらには、Srinivasan and Mahmassani (2003) は、出発時刻や経路選択行動とトリップ中の経路変更行動には強い関係があることを示しており、予測旅行時間情報の提供は、トリップ開始時刻にも大きな影響を与えられらる。

本研究で得られた知見から、ドライバーは経験した交通状況により経路選択に関する意思決定を発生させることや、走行中の経路を引き続き走行しようとする傾向、さらには、トリップ中における経路旅行時間情報の重要性は低下している可能性などが示された。これらの結果は、トリップ中のドライバーは目的地への到着時刻に対して大きな関心を持つ一方で、経路変更行のための心理的抵抗の影響により頻繁な経路変更行動を行わないことや、交通混雑を回避することを重要視するあまり最適経路を選択しなくなることを示唆している。このような、客観的には必ずしも最適とはいえない経路選択行動についての十分な分析とモデル化を行った後、交通全体をより最適な状態へと導くための情報提供タイミングや情報提供効果について分析を行う必要がある。

つまり、ドライバーが意思決定を行うタイミングとその際の経路選択傾向を把握した上で、適切なタイミングで個々のドライバーに最適な情報を提供することで、情報提供効果を分析することができる。例えば、走行中の経路が最短経路であるにもかかわらず、直面する、もしくは経験した交通混雑により経路変更を行おうとするドライバーに対しては、走行経路の予測旅行時間や、代替経路と比較した走行経路の優位性を提供する。また逆に、走行する経路が最短ではないにもかかわらず引き続き走行しようとするドライバーには、代替経路の存在を示すなどである。このような、より円滑な交通状況の再現に向けた情報提供のあり方についての検討や、詳細な交通情報提供の効果を分析するためには、ドライバーの詳細な経路選択行動を内包した動的交通シミュレータを開発し、旅行時間予測手法や経路選択モデルを統合的に分析する必要がある。

第 6 章 参考文献

- 上杉友一，井料隆雅，小根山裕之，堀口良太，桑原雅夫（2003）断片的なプローブ軌跡の接合による区間旅行時間の期待値と分散の推定，土木計画学研究・論文集，Vol.20，pp.923-929．
- 大西啓介，加藤誠巳（1992）交差点内コストを考慮した道路網における経路探索の手法とそのマルチメディア型経路案内システムへの応用，情報処理学会論文誌，Vol.33，No.7，pp.970-979．
- 北研二（1999）言語と計算 - 4 確率的言語モデル，東京大学出版会．
- 小林潔司，井川修（1993）交通情報によるドライバーの経路誘導効果に関する研究，土木学会論文集，No.470 / -20，pp.185-194．
- 丹羽寿男，吉田雄二，福村晃夫（1990）道路網の階層的表現にもとづく経路探索アルゴリズムと地図情報システムへの応用，情報処理学会論文誌，Vol.31，No.5，pp.659-666．
- 羽藤英二，谷口正明，杉恵頼寧，桑原雅夫，森田綽之（1998）複数交通情報リソース下における情報獲得・参照行動を考慮した経路選択モデル，土木学会論文集，No.597 / -40，pp.99-111．
- Hellinga, B.R. and L. Fu (2002) Reducing bias in probe-based arterial link travel time estimates, *Transportation Research Part C* 10, pp.257-273.
- Kahneman, D. and A. Tversky (1979) Prospect theory: an analysis of decision under risk, *Econometrica*, pp.263-291.
- Mahmassani, H.S. and R. Jayakrishnan (1991) System performance and user response under real-time information in a congested traffic corridor, *Transportation Research Part A* 25, No.5, pp.293-307.
- Srinivasan, K.K. and Mahmassani (2001) Trip time perception and judgment processes in tripmaker decisions under real-time traffic information, Transportation Research Board 81st Annual Meeting, CD-ROM.
- Srinivasan, K.K. and H.S. Mahmassani (2003) Analyzing heterogeneity and unobserved structural effects in route-switching behavior under ATIS: a dynamic kernel logit formulation, *Transportation Research Part B* 37, pp.793-814.
- Tversky, A. (1972) Elimination by aspects: a theory of choice, *Psychological Review*, 79, pp.281-299.

謝辞

本研究を遂行するにあたり，多くの方のご指導とご協力を賜った．ここに記して感謝の意を表す次第である．

まず，本研究の遂行ならびに本論文を作成するにあたり，指導を賜った指導教員の森川高行先生（名古屋大学大学院 環境学研究科 教授）は，筆者が社会人から改めて大学院に入学するに際して，様々な相談や協力をして頂いた．また，入学後研究を始めるにあたって，プローブカーデータを用いた研究の方向性を示していただき，終始適切な指導を賜った．先生の指導なくして本研究を進めることはできなかった．ここに，森川高行先生に対して深甚たる感謝の意を表したい．

次に，山本俊行先生（副指導教員，名古屋大学大学院 工学研究科 助教授），倉内慎也先生（名古屋大学大学院 工学研究科 助手）には，非常に丁寧な指導とご助言を賜ったことに感謝の意を表したい．また，河上省吾先生（名古屋大学名誉教授，現関西大学工学部都市環境工学科教授），佐々木邦明先生（現山梨大学大学院工学研究科助教授），井ノ口弘昭先生（現関西大学工学部都市環境工学科助手）には，著者が学部生から大学院修士課程を修了するまでの3年間取り組んだ，均衡配分理論や非集計行動モデルに関して幾度となくご助言を頂いた．この期間に学んだネットワーク上の交通行動の考え方や非集計行動モデルに関する知識は，本研究に大きな影響を与えるものである．また，林良嗣先生（副指導教員，名古屋大学大学院環境学研究科教授）にも貴重なご意見をいただいた．ここに深く感謝の意を表したい．また，植原啓介先生（慶應義塾大学大学院政策・メディア研究科特別研究専任講師）をはじめとする，インターネット ITS アプリケーション開発ツール検討委員会の先生方には，本研究を進める上で経路選択の動的な考え方について，示唆に富んだ貴重なご意見を頂いた．ここに深く感謝いたします．

また，本研究を進めるにあたり，貴重なデータを提供していただいた（財）計量計画研究所の牧村和彦氏，中島康博氏に感謝の意を表したい．

本研究を進めるにあたって，森川・山本研究室の諸先輩，諸兄には多くの貴重なご意見をいただくとともに，研究遂行にご協力いただいた．特に，データ収集や分析にあたっては，岡田良之氏（（株）長大），境隆晃氏（パシフィックコンサルタンツ株式会社），北村清州氏（（財）計量計画研究所），多和田雄介氏（名古屋市役所）には多大なご協力を頂いた．ここに感謝の意を表します．

本研究は，ここに記しきれない多くの方々のご支援を得て成立していることを記し，深く感謝いたします．

最後に，苦楽をともにし，常に暖かく励ましてくれた家族にあらためて感謝します．

三輪 富生