

# 携帯電話通信履歴を用いた地下鉄乗車路線推定手法の提案

石塚宏紀<sup>†1</sup> 黒川茂莉<sup>†1</sup> 小林亜令<sup>†1</sup>

**概要:** 近年、第4世代移動通信システムの普及に伴う高速で大容量の通信インフラの整備によって、ユーザは、移動中にスマートフォンを用いたデータ通信を気軽に利用できるようになった。移動体通信事業者は、高速移動中においても安定した通信品質を確保するため、日々無線環境やネットワーク容量を監視及び運用を実施している。一方で、都市部では、地下鉄網が充実し、ユーザは日々の通勤や通学をはじめとした移動手段として、地下鉄を利用している。地下鉄走行中における移動体通信網との接続品質は、地下共同溝に対する無線アンテナ整備によって、一部路線にて改善されてはいるものの、通信品質が不安定な箇所も多々存在する。そのため、移動体通信事業者にとって、地下鉄乗車中の移動体通信網利用者への安定した通信サービスの提供は喫緊の課題である。これまで、移動体通信事業者は、地下鉄走行中の無線環境調査において、試験用端末を所持した調査員を当該車両に乗車させ、切断箇所や品質情報の測定をしていた。そのため、都市部の全地下鉄路線を網羅的に且つ高頻度に調査することは困難であり、無線品質の調査に膨大な時間を要していた。そこで、本研究では、日々移動体通信事業者が無線環境の品質情報の分析などを目的に収集している無線基地局側で取得された携帯電話通信履歴の中から、地下鉄乗車者の履歴のみを抽出する手法を提案することで、容易に地下鉄乗車中における無線環境情報の収集を目指す。既存の携帯電話通信履歴を用いた移動経路や乗り物判定技術では、携帯電話通信履歴内の接続基地局の遷移パターンを利用する手法があるが、本提案においては、基地局遷移パターンに加えて、無線セクター情報、遷移時間、各基地局との通信遅延時間などの新たな特徴量を追加してさらなる判定精度の向上を目指す。本論では、地下鉄乗車中の携帯電話通信履歴同定に向けた正解ラベル付与、特徴量生成、機械学習による路線判定技術について述べ、個別許諾を得られている一部顧客の携帯電話通信履歴を用いた評価にて本提案の有効性を示す。

**キーワード:** 位置情報, 行動分析, 携帯電話通信履歴

## Estimating Underground Trains using Cellular Handoff in Call Detail Records

HIROKI ISHIZUKA<sup>†1</sup> MORI KUROKAWA<sup>†1</sup> AREI KOBAYASHI<sup>†1</sup>

**Abstract:** Recently, according to developing high-speed and large-capacity communication infrastructure accompanying the spread of the fourth generation mobile communication system, users can easily utilize wireless communication using smartphones while moving states. A mobile communication carrier monitors and operates wireless environment and network capacity in order to ensure stable communication quality even during high-speed movement. In urban area, the underground train network has been fully equipped. then, users utilize the train as a transport of daily commuting. Although the quality of mobile communication network during the underground train is running has been improved in some routes which developed wireless antennas into the underground tunnel, there are also many points where the wireless communication quality is unstable. For this reason, it is an urgent task for mobile communication carriers to provide stable communication services to users who ride underground trains for commuting. Nowadays, for a survey of the radio environment while the underground train is traveling, a tester who has a testing device rides on the vehicle and measures wireless quality information. Therefore, it is difficult to survey all underground lines in urban areas frequently, and it takes a huge amount of time to survey wireless quality in all lines. In this research, using Call Detail Records(CDRs) acquired from radio base stations that mobile communication carriers collect daily to analyze the network quality information in the wireless environment, we propose a method to extract the records of users who got on underground trains. There are conventional works using handoff patterns of cell towers in CDRs to estimate traveling routes and a type of transportation. In this proposal, however, in addition to the base station transition pattern, we aim to improve estimation accuracy by adding new features such as wireless sector information, handoff time, network delay. Finally, we show the effectiveness of our proposal using CDRs of some customers who have been licensed individually.

**Keywords:** Location Information, Behavior Analysis, Call Detail Records

### 1. はじめに

近年、第4世代移動通信システムの普及に伴う高速で大容量の通信インフラの整備によって、ユーザは、移動中にスマートフォンを用いたデータ通信を気軽に利用できるようになった。移動体通信事業者は、高速移動中においても安定した通信品質を確保するため、日々無線環境やネット

ワーク容量を監視及び運用を実施している。一方で、都市部では、地下鉄網が充実し、ユーザは日々の通勤や通学をはじめとした移動手段として、地下鉄を利用している。地下鉄走行中における移動体通信網との接続品質は、地下共同溝に対する無線アンテナ整備によって、一部路線にて改善されてはいるものの、通信品質が不安定な箇所も多々存在する。東京メトロ及び、都営地下鉄では、2013年3月よ

<sup>†1</sup>(株)KDDI 総合研究所  
KDDI Research, Inc.

り KDDI(au), NTT ドコモ, ソフトバンク, ワイモバイル(当時はイーアクセス)の 4 社と共同で全線トンネル内での携帯電話利用について宣言している[1][2]. 顧客にとって, 通勤中における通信品質は, 移動体通信事業者の選択に大きく影響する. そのため, 移動体通信事業者にとって, 地下鉄乗車中の移動体通信網利用者への安定した通信サービスの提供は喫緊の課題である. 地下共同溝へのアンテナ敷設については, 莫大な設備投資を必要とするため, 国内で移動体通信事業者を提供する 3 社が共同で実施しており, 品質の差別化要素は, 各社のアンテナにおける無線パラメータの設定にあると考えられ, 顧客の利用実態に合わせたパラメータ設定に向けた無線環境の調査が必要であった.

これまで, 移動体通信事業者は, 地下鉄走行中の無線環境調査において, 試験用端末を所持した調査員を当該車両に乗車させ, 乗車中における通信の切断箇所や品質情報の連続的な測定を実施してきた. そのため, 都市部の全地下鉄路線を網羅的に且つ高頻度に調査することは, コスト及び人員確保の面で困難であり, 無線品質の調査に膨大な時間を要していた. 我々は, 品質改善の速度向上と維持に向けて, 調査時間の短縮及び, 永続的な調査実施に向けた技術が必要であった. そこで, 本研究では, 日々移動体通信事業者が無線環境の品質情報の分析などを目的に収集している無線基地局側で取得された携帯電話通信履歴である Call Detail Records(CDRs)の中から, 地下鉄乗車中の顧客における通信履歴のみを抽出する手法を提案することで, 容易に地下鉄乗車中における無線環境情報を収集可能なシステムの構築を目指している.

既存の携帯電話通信履歴を用いた移動経路や乗り物判定技術では, 携帯電話通信履歴内の接続基地局の遷移パターンを利用する手法が提案されている. 特に都心部においては, 人口密度を加味して, 過密に基地局が配備されており, 基地局の遷移パターンによって路線判別が可能になってきている. しかしながら, 地下鉄トンネル内における無線通信環境の配備は, 地上とは異なり, 密に基地局を配備することは叶わないため, 基地局の遷移パターンのみでの路線判別は困難となる. そこで, 本提案においては, 基地局遷移パターンに加えて, 無線セクター情報, 遷移時間, 各基地局との通信遅延時間などの新たな特徴量を追加してさらなる判定精度の向上を目指す. 本論では, 一部発着駅のみで取得可能な GPS 情報と時刻情報を用いた地下鉄乗車判定による正解ラベル付与手法及び, CDRs から得られた情報を加工した特徴量生成手法, CDRs のみから得られた特徴量のみで地下鉄乗車路線を判定する機械学習による分類器について解説する. 最後に, GPS 情報と CDR の双方について個別に利用許諾を得たデータを用いて, 本提案手法の評価を実施し, 有効性を検証する.

## 2. 関連研究

本章では, 屋内移動手段である地下鉄網を想定した乗車判定技術の既存手法について整理するとともに, 既存手法に対する本論文の位置付けと方針について述べる. 既存手法は大きく分けて移動機内部のセンサを用いたセンサ位置推定手法と位置情報のアンカーとなる無線アクセスポイントを用いる無線相対位置推定手法の 2 つ大別される. 以下では, 2 つの代表的な手法について既存研究を整理するとともに, 本提案の位置付けについて明確化する.

### 2.1 センサ位置推定手法

現在, スマートフォンには多数のセンサが搭載されており, これらのセンサを活用することで, 地下鉄内における位置を推定する研究も進められている. Kuife 等は, 地下鉄乗車者が所持するスマートフォンにおける 3 軸加速度センサのデータを分析することで, 地下鉄車両の発着を分析し, 乗車判定を試みている. 一方, 米田等[5]は, 気圧センサが搭載されたスマートフォンにて, 地下における走行中の上下運動の特徴を学習することで地下鉄走行の検知を試みている. また, 渡邊等[4]は気圧センサによる地下鉄駅の同定手法を提案し, 日向等[6]もまた, 気圧センサの値を用いた走行及び停車判定を行い, その後, 停車時の気圧から駅を推定している. センサ位置推定手法において, 地下鉄乗車路線判定は, 気圧センサを用いることで高精度に判定可能な場合があるようだが, 気圧センサを搭載した端末はまだ十分に普及していない.

### 2.2 無線相対位置推定手法

WiFi アクセスポイントや携帯電話の基地局との電波強度を用いて相対的に位置を同定する手法も盛んに研究されている. 暦本等[3]は, 既設の Wi-Fi アクセスポイントの固有情報と位置座標情報のマッチングテーブルを集合知により作成し, 電波強度を利用した三点測位により, 屋内等でのおよその位置を把握する手法を提案している. また, Google 社がスマートフォン OS として提供されている Android では, 移動体通信事業者が設置している基地局セル ID から位置座標を推定する API[8]を提供している. また, 鉄道事業者各社によって提供されている位置情報提供サービス[7]もあり, JR 東日本では, 車両内の情報端末から音波ビーコンを発信し, 位置同定に利用されている. 前川等[?]は, 乗客の保持する移動機が受信した近隣の Bluetooth シグナルである RSSI をサーバへ集約し, 端末間で捕捉された RSSI から同一車両確率及び, 乗車車両確率を算出している. 無線相対位置推定手法において, 超音波や Bluetooth を利用する手法は, 車両に直接装置を配備する必要があり, 同車両内に Bluetooth を発信する移動機がないと機能しないため, 網羅性の視点において, 困難である.

### 2.3 本論の位置付け

本論の目的は、地下鉄に乗車中の顧客 CDR を高精度で特定し、地下鉄内における各路線の品質情報を網羅的に収集する必要がある。そのため、顧客のスマートフォンに対して、データ収集や分析を実施するためのアプリケーションをインストールするような手法は、網羅性の観点から許容できない。推定精度と網羅性の両面に対応するため、本提案では、日々移動体通信事業者が無線環境の品質情報の分析などを目的に収集している無線基地局側で取得された全顧客の携帯電話通信履歴である CDRs(Call Detail Record) を分析対象とすることで、網羅性を確保する。また、推定精度の向上に向けて、松原等[11]は、基地局のセル ID と各地下鉄駅の対応表を作成し、地下鉄利用時の利用駅を推定しているが、本提案では、停車駅だけでなく、路線全体における乗車中の基地局遷移パターン[12]及び、その他無線環境で得られる特徴量を追加して分析することで推定精度向上を試みる。本論の位置付けを下記にまとめる。

- 全顧客の通信時における接続無線基地局の環境情報が掲載された CDRs のみを用いることで網羅性を確保
- 乗降者駅における状態だけでなく、走行中の接続基地局情報やその他無線環境の情報を特徴量とした高精度分類器生成

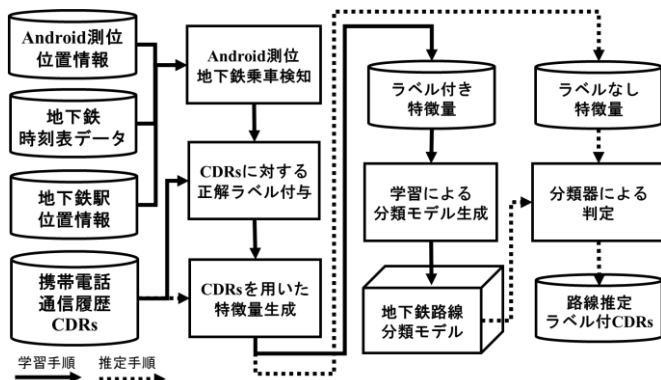


図 1 提案システムの処理手順

Figure 1 The processing procedure of the proposed system.

### 3. 提案手法

本提案は、CDRs のみから生成した特徴量を用いて乗車地下鉄路線を分類することを目的とする。分類モデルを生成するため、各顧客の CDRs に対して、乗車した地下鉄路線を正解として付与し、分類モデルを学習する必要がある。本提案システムは、正解ラベル付与を自動化した学習処理と CDRs のみから生成した特徴量を用いた推定処理の 2 つから構成される。図 1 に提案システムの処理手順を示す。図における実線が、学習処理の手順を示し、点線が、推定処理の手順を示している。本章は、まず本システムに用いるデータセットについて解説し、その後、学習処理と推定処理の設計と実装についてそれぞれ述べる。

### 3.1 データセット

提案システムにおける入力データセットは、図 1 の左側に示すように携帯電話位置情報、地下鉄時刻表データ、CDRs の 3 種類存在する。各データセットについて以下で詳細に解説する。

#### (1) Android 測位位置情報

Android OS を搭載したスマートフォンをご利用の一部の顧客に対して、定期的に Android OS による API を利用した位置情報測位を実施し、位置情報を収集するアプリケーションを配布した。本アプリケーションは、GPS 衛星が捕捉可能な範囲では GPS による位置情報取得を実施し、GPS 衛星が捕捉できない環境下では、WiFi や携帯基地局のセル情報を利用したネットワーク測位による位置情報取得を実施する仕様となっている。測位契機は、加速度センサが一定量の加速を感知し、推定で約 400m 以上移動した場合と、前の測位から数分経過した場合の 2 種である。Android 測位位置情報は、 $P(u_i \text{ lat, lon, } t)$  で表現され、顧客識別子  $u_i$ 、緯度経度情報  $\text{lat, lon}$  と測位時間  $t$  の 4 組で構成される。本データセットは学習処理における Android 測位地下鉄乗車検知で利用する。

#### (2) 地下鉄時刻表データ

地下鉄時刻表データは、推定対象路線の時刻表データセットであり、学習処理における Android 測位地下鉄乗車検知の精度向上に寄与する。地下鉄時刻表は、インターネット上に記載された東京メトロと営団地下鉄の時刻表を目視で確認し、 $TT_{ij}(at, dt, st_k)$  で表現され、 $i$  路線における  $j$  番目の列車における  $k$  番目の乗降者駅  $st_k$  の到着時刻  $at$  と発車時刻  $dt$  によって構成される。地下鉄乗車検知においてネットワーク測位による位置情報誤差の補正利用する。

#### (3) 地下鉄駅位置情報

顧客の Android 測位位置情報である  $P(u_i \text{ lat, lon, } t)$  が地下鉄駅であるかを検知するために、駅の位置情報と比較する必要がある。そこで、我々は、昭文社の PoI 情報データ[]から推定対象である地下鉄駅の位置情報を取得し、 $S_{ij}(\text{lat, lon, st})$  で表現した。地下鉄駅位置情報  $S_{ij}$  は  $i$  路線における  $j$  番目の駅である  $st$  の緯度経度情報  $\text{lat, lon}$  で構成されている。

#### (4) Call Detail Record (CDR)

CDR は移動機と基地局間における無線通信時の様々な情報を記録した情報であり、発生契機も多岐に及ぶ。データ生成の主な契機は、移動機によるデータ通信、通話、SMS 発信などの通信開始時と終了時、基地局やセクターのハンドオーバー発生時、移動機と基地局間の無線通信におけるエラー発生時がある。CDR における記録される本論に関係

する情報について表 1 にまとめる。

我々の推定対象である地下鉄を利用する一般顧客における CDRs の発生間隔について、詳細に調査した。地下鉄乗車者の CDR 抽出は、次章で説明する学習処理と同じ手法で抽出している。対象路線は東京メトロ有楽町線とし、126 名顧客における 2017 年 11 月における地下鉄移動時の CDR として 202 パターンを分析した。本分析では、CDR の発生間隔の特性を捉えるために、通信切断時刻から次の切断時刻までの通信間隔平均と通信間隔の不偏標準偏差で移動中 CDR を k-means 法でクラスタリング(k=5)し、地下鉄の通信間隔パターンを調査した。図 2 にクラスタリング結果を示す。結果から移動中における CDR の 93.6%がクラスタ 0 及び 1 に属しており、クラスタ 0 及び、クラスタ 1 の通信間隔平均の平均は、それぞれ 12.4 秒、27.7 秒となり、1 分未満間隔でログが発生していることがわかった。

表 1 本論に関する CDR 情報

Table 1 A part of CDRs related to the proposed system.

カラム名	意味
UserID	顧客識別子
ConnectionDateTime	データ通信、通話、SMS発信などの通信開始時刻
DisconnectionDateTime	データ通信、通話、SMS発信などの通信終了時刻
ConnectionBaseStationID	通信開始時接続基地局識別子
DisconnectionBaseStationID	通信終了時接続基地局識別子
ConnectionSectorID	通信開始時接続セクター識別子
DisconnectionSectorID	通信終了時接続セクター識別子
ConnectionRoundTripTime	通信開始時基地局との無線通信遅延時間
DisconnectionRoundTripTime	通信終了時基地局との無線通信遅延時間




図 2 CDR 発生間隔でのクラスタリング結果

Figure 2 A result of clustering with generation patterns of CDRs.

### 3.2 学習処理

学習処理では、Android 測位位置情報、地下鉄時刻表データ及び、地下鉄駅位置情報を用いて Android 測位地下鉄乗車検知を実施し、その結果を用いて、乗車時間における CDR に対して地下鉄路線の正解ラベルを付与し、特徴量生成を行った後、学習を行い地下鉄路線分類のモデルを生成するという、4 つの処理手順から構成される。図 3 に学習処理の処理手順を示す。以下に各処理について詳細に説明する。

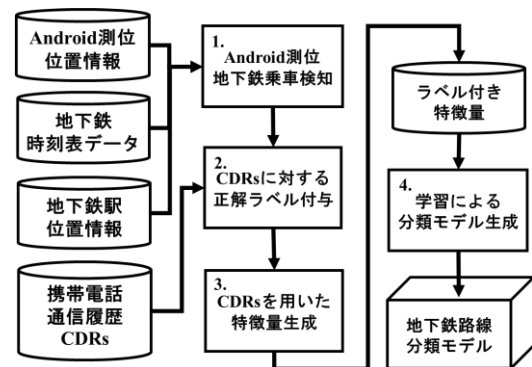


図 3 学習処理の手順

Figure 3 The processing procedure for the learning process.

#### (1) Android 測位地下鉄乗車検知

各地下鉄路線の地下鉄駅情報である  $S_i$  における始点・終点となる駅の緯度経度情報を重心として 1 辺 150m の正方形のジオフェンスを生成し、ジオフェンス内の  $P$  を探索する。探索に該当する  $P$  を保持するユーザと日付の全  $P$  データ ( $P_{all}$ ) を収集する。収集したデータに対して、路線  $i$  における全駅情報の  $S_{ij}$  と  $P_{all}$  も同様に範囲探索し、該当した  $P_{all}$  内の  $P$  に対して駅情報を付与する。選出されたログ情報を下記にします。

(出力例)

5,2017-11-27,('13:22:31', '有楽町線\_和光市),('13:45:19', '有楽町線\_東池袋),('13:46:55', '有楽町線\_護国寺)

上記例は、5 番のユーザにおける 2017 年 11 月 27 日におけるログが、有楽町線の始点である和光市駅のジオフェンスに該当し、その日の他のログにおいても有楽町線における東池袋駅と護国寺駅にも該当していることが記録されている。上記出力例に対して、さらに地下鉄時刻表データを用いて、該当する乗車列車を特定する。出力例のデータでは、13 時 22 分に和光市駅発車し、東池袋駅に 13 時 45 分前後の到着し、13 時 46 分前後に護国寺駅に到着する列車を時刻表から探索し、時刻表との誤差 5 分以内であるデータのみを正解データとして選出した。

## (2) CDRs に対する正解ラベル付与

Android 測位地下鉄乗車検知にて算出した地下鉄路線に乗車していた時間を割り出し、当該時間帯における同ユーザの CDR を抽出し、正解ラベルとして地下鉄路線 ID を末尾に追加する。

## (3) CDRs を用いた特徴量生成

本提案における特徴量は、地下鉄乗車中の連続する  $n$  個の CDR を集約して 1 つのデータを生成する。特徴量としては、連続する  $n$  個の基地局及び、セクターの遷移情報とそれぞれの基地局間の Round Trip Time 及び、 $n$  個のログの開始から終了時刻までの時間窓を示す time window の  $2n+1$  を特徴量として採用した。既存手法は、基地局の遷移情報のみを利用しているのに対して、本提案では、特徴量に対して新規に Round Trip Time と time window を設けた。

## (4) 学習による分類モデル生成

生成した特徴量に対して、正解ラベルを付与し、機械学習にて分類モデルの学習を行う。本提案システムでは、Wide and Deep 手法[9]を用いて学習を行った。Wide and Deep 手法は、線形モデルと深層ニューラルネットワークを一緒に学習することを可能にする。本提案では、線形モデルで学習する Wide 側にて、基地局とセクターの遷移状態を学習し、深層ニューラルネットワークで学習する Deep 側にて time window を学習させてモデルを生成した。実装においては TensorFlow1.5.0[10]を利用した。

### 3.3 推定処理

推定処理では、学習時に生成したモデルに対して、ラベルなし特徴量を入力し、路線判定ラベル付きの CDR を出力として得る。

## 4. 評価

本論では、提案システムの有効性を評価するため、提案システムのプロトタイプを実装し、判定精度について評価を実施した。本章では、評価データセットについて述べた後、各種モデル生成のパラメータ変更による精度への影響について評価結果を示す。

### 4.1 評価データセット

本評価実験の対象路線は、東京都市圏にて運行する地下鉄 16 路線とする。対象路線については表 2 にまとめる。評価用データは、各路線において約 30MB 程度の特徴量化したデータを用いた。全体のユーザ数としては、1308 名であり、トリップ数では、2067 であった。表 2 に各路線におけるデータセット数について示す。評価においては、 $k$ -分割交差検証( $k=4$ )にて学習データと評価データを分割して評価し、

各路線に対する Precision 値, Recall 値を算出している。

表 2 評価対象の地下鉄路線

Table 2 A list of Underground train routes for our evaluation

路線名	ユーザ数	トリップ数
千代田線	88	111
銀座線	73	127
半蔵門線	78	97
日比谷線	50	62
副都心線	73	110
丸の内線	91	105
南北線	47	119
埼玉高速鉄道	86	159
浅草線	83	144
三田線	52	121
大江戸放射線	189	325
大江戸環状線	110	209
新宿線	69	100
東急田園都市線	114	140
東西線	50	59
有楽町線	55	79

### 4.2 ステップ数における評価

学習におけるステップ数を変化させてモデルの精度を検証した。評価したステップ数は 20,000 と 40,000 の 2 種類である。また、他パラメータ値については、 $n$  を 5 個として設定した。評価結果として、20,000 ステップにおける平均 Precision 値及び平均 Recall 値がそれぞれ、0.967, 0.967 に対して、40000 ステップでのそれぞれの値は、0.973, 0.973 であった。ステップ数増加によって多少の精度向上はあるものの大きな変化は生じなかった。

### 4.3 連続する基地局特徴量における評価

CDRs を用いた特徴量生成にて解説したように、我々は、 $n$  個の連続する CDRs の情報を集約して 1 つの特徴量を生成している。地下鉄移動を表現しやすい集約する CDRs 数を評価するために、我々は  $n$  を 5 と 10 の 2 種で変化させた上で性能評価を実施した。CDR の発生間隔は 1 分未満であるため、5 個と 10 個では、time window 値において数分の差が生じる。仮説として、CDR 数が増えて、走行距離が延びるほど、基地局/セクター遷移に特徴が現れ、判定精度が向上する可能性がある。評価結果として、 $n=5$  の場合において、平均 Precision 値及び平均 Recall 値がそれぞれ、0.968 であり、 $n=10$  の場合においてそれぞれの値は、0.970 であった。図 4 に各路線における F 値平均のグラフを示す。差異は小さいが、日比谷線において  $n=10$  における精度向上が見受けられる。




図 4 特徴量内の CDR 数の違いによる各路線推定 F 値  
Figure 4 F-measures of estimation with difference of number of CDRs in a feature data set.

#### 4.4 Round Trip Time に追加における評価

CDRs に含まれる基地局/セクターの遷移情報のみを特徴量化するのに加え、我々は、移動体通信事業者ならではのデータとして、端末と基地局間の Round Trip Time を特徴量に追加した。地下鉄走行中に基地局/セクターの遷移は、一部路線の一部区間において、共通のインフラを利用している箇所があり、特徴量として差異がないため、誤判定の要因になりえる。しかしながら、基地局/セクター遷移が類似している路線間においても物理的な内部構造の違いから Round Trip Time に揺らぎが生じる可能性がある。評価結果として、Round Trip Time の有無では、推定精度に差異はなかった。図 5 に Round Trip Time 有無における各路線における F 値平均のグラフを示す。差異は小さいが、日比谷線及び、丸の内線において Round Trip Time を有した特徴量を用いた方が、精度向上している。




図 5 特徴量内の Round Trip Time を追加したことによる各路線推定 F 値  
Figure 5 F-measures of estimation according to adding Round Trip Time to feature data.

### 5. 考察

評価実験の結果から、高頻度に出力される CDR から基地局/セクターの遷移パターンを学習することで高精度に顧客の利用路線を推定可能であることがわかった。現状のモ

デルにおいては、ステップ数 40,000, n=10, Round Trip Time を含める特徴量において平均 Precision 値及び平均 Recall 値がそれぞれ 0.975 を示している。一方で、日比谷線など精度が不十分な路線が存在する。原因として、路線単位の学習用データセットの不足や、地下での並走による基地局/セクター遷移の類似による誤判定が考えられる。

### 6. まとめ

本論では、地下鉄乗車中の移動体通信網利用者への安定した通信サービスの提供に向けた効率的な通信品質調査に向けて、顧客の携帯電話通信履歴である CDR を用いた地下鉄乗車路線推定を提案し、判定後の CDR から各路線における無線環境の調査を目的とした。学習から推定までをシステム化することによって、CDR による地下鉄乗車路線推定を容易に実施するプロトタイプを実装し、評価を実施した。今後は、学習用データセットを増加させた上で、現状において低精度の路線について原因を調査し改善していく。

### 参考文献

- [1] “東京メトロの全線で携帯電話が利用可能に!”  
[http://www.kddi.com/corporate/news\\_release/2013/0318/](http://www.kddi.com/corporate/news_release/2013/0318/), (参照 2018-04-16).
- [2] “都営地下鉄の全区間で携帯電話サービスの利用が可能に!”  
[http://www.kddi.com/corporate/news\\_release/2013/0326a/](http://www.kddi.com/corporate/news_release/2013/0326a/), (参照 2018-04-16).
- [3] 厩本純一, 塩野崎敦, 末吉隆彦, 末吉隆彦, 末吉隆彦, 味八木崇 : PlaceEngine: 実世界集合知に基づく WiFi 位置情報基盤, インターネット コンファレンス論文集 2006/
- [4] Watanabe, T., Kamisaka, D., Muramatsu, S., et al.: At which station am I?: Identifying subway stations using only a pressure sensor. In: International Symposium on Wearable Computers (ISWC), pp. 110–111 (2012)
- [5] 米田 圭祐, 望月 祐洋, 西尾 信彦, “気圧センシング技術を用いた行動認識手法”, 情報処理学会論文誌, 56(1), pp.260-272, 2015 年 1 月.
- [6] S. Hyuga, M. Ito, M. Iwai, and K. Sezaki: Estimate a User’s Location Using Smartphone’s Barometer on a Subway, 5th International Workshop on Mobile Entity Localization and Tracking in GPS-less Environments (MELT 2015), 2015.
- [7] “「JR 東日本アプリ」での列車位置情報サービスがさらに進化します”. <https://www.jreast.co.jp/press/2015/20160203.pdf>, (参照 2018-04-16).
- [8] Google : Google Maps Geolocation API, 入手先 <<https://developers.google.com/maps/documentation/geolocation/intro>>
- [9] H.-T. Cheng, L. Koc, J. Harmsen, T. Shaked, T. Chandra, H. Aradhye, G. Anderson, G. Corrado, W. Chai, M. Ispir, et al. Wide & deep learning for recommender systems. arXiv preprint arXiv:1606.07792, 2016
- [10] Google : TensorFlow, 入手先 <https://www.tensorflow.org/>
- [11] 松原 剛, 金杉 洋, 熊谷 潤, 柴崎亮介, “携帯基地局情報を用いた地下鉄内測位システムの検討”, 情報処理学会 DICO2016, pp1550-1555
- [12] Hiroki Ishizuka, Nao Kobayashi, Shigeki Muramatsu, Chihiro Ono, Takahiro Hara, “Traffic Analysis of Railways using Call Detail Records”, NetMob2017, Italy, 2017