

ニューラルネットワークによるチ・カ・ホ人流推 定・予測モデルシステムの構築

2020年3月

公立大学法人 札幌市立大学

研究の概要

研究名称：

ニューラルネットワークによるチ・カ・ホ人流推定・予測モデルシステムの構築

研究目的及び内容：

チ・カ・ホに設置している人流センサーから収集したビッグデータの実績値に天気・曜日やチ・カ・ホや市内で開催されるイベントも考慮した人流の推定・予測モデルシステムを構築し、回遊性向上・にぎわい創出への活用手法や施設管理の最適化、また、災害避難のシミュレーションに活用するなどの防災支援の手法を検討することにより、エリアマネジメントに資することを目的とする。

研究期間： 契約締結日から 令和2年3月25日まで

研究代表者および共同研究者：

研究代表者：公立大学法人 札幌市立大学

地域連携研究センターAIラボ

特任准教授 高橋 尚人

共同研究者： 特任助教 吉田 彩乃

第1章 ニューラルネットワークによるチ・カ・ホ人流 推定・予測モデルシステムの構築

1.1. はじめに

札幌市では、都心部に広がる地下空間ネットワークを活用し、地上部と連動した ICT 活用の実証実験を展開しており、札幌駅前通地下歩行空間（以下、「チ・カ・ホ」と略す）には人流センサーを設置して、チ・カ・ホの通行人数を計測している。

本章では、人流センサーから収集したデータを用い、ニューラルネットワークによるチ・カ・ホ通行人数の推定モデルの構築を試みる。また、構築したニューラルネットワークモデルを用い、人流の推定・予測モデルシステムの構築を行った。

1.2. チ・カ・ホ人流センサーデータの概要

チ・カ・ホには5基（J1～J5）の人流センサーが設置されており（図 1.1）、人流センサーは、札幌駅から大通駅方向、大通駅から札幌駅方向の通行人数を計測し、計測データを15分間隔で集計している。本研究において、札幌市都心まちづくり推進室から提供のあった人流センサーデータの概要を表 1.1 に示す。



図 1.1 チ・カ・ホ人流センサー設置位置

表 1.1 チ・カ・ホ人流センサーデータの概要

アレイ	データ期間	計測時間	通過人数の計測
J1 - J4	2018年8月1日 - 2020年1月31日 (549日間)	5:45 - 0:45	札幌駅→大通駅方向
J5	2018年8月11日 - 2020年1月31日 (539日間)		大通駅→札幌駅方向

収集データは月ごとにCSVファイルに収録される。ファイル名の命名規則は「opendata_”年月”.csv」で、例えば、2018年8月分のデータは、opendata_201808.csv に収録される。表 1.2 にデータのサンプルを示す。

表 1.2 人流センサデータのサンプル (opendata_201808.csv から抜粋)

日時	アレイ	札幌→大通り	大通り→札幌	合計
2018-08-01T05:45:00+09:00	J1	250	243	493
2018-08-01T05:45:00+09:00	J2	267	274	541
2018-08-01T05:45:00+09:00	J3	242	173	415
2018-08-01T05:45:00+09:00	J4	220	229	449
2018-08-01T06:00:00+09:00	J1	290	276	566
2018-08-01T06:00:00+09:00	J2	155	168	323
2018-08-01T06:00:00+09:00	J3	261	215	476
2018-08-01T06:00:00+09:00	J4	215	190	405
2018-08-01T06:15:00+09:00	J1	317	299	616
2018-08-01T06:15:00+09:00	J2	155	173	328
2018-08-01T06:15:00+09:00	J3	289	229	518
2018-08-01T06:15:00+09:00	J4	218	205	423

(以降省略)

データ収録期間は、表 1.1 に示したように J1 から J4 は 549 日間、J5 は 539 日間だが、J5 には以下に示すデータ欠測期間があった。

- 2018 年 9 月 10 日 5:45 - 0:45 (1 日間)
- 2019 年 3 月 16 日 10:15 - 0:45
- 2019 年 3 月 17 日 5:45 - 0:45 (1 日間)
- 2019 年 9 月 6 日-10 月 4 日 5:45 - 0:45 (29 日間)

データ欠測が多い J5 を除き、J1～J4 の通過人数（札幌駅→大通駅、大通駅→札幌駅の通過人数の合計人数）を日別に集計したものを図 1.2 に示す。

なお、日々の人流計測は翌日の 0:45 まで行っている。0:00-0:45 のデータは前日の通過人数として日別の通過人数を求めた（例えば、8 月 2 日 0:00-0:45 のデータ

は8月1日の通過人数に含めた).

2018年9月6日, 7日には全てのアレイで通過人数が激減した. 2018年9月6日には北海道胆振東部地震が発生し, 翌7日まで北海道全域で停電が起こるなど大きな影響があったことがチ・カ・ホ通過人数に影響したと考えられる.




図 1.2 各アレイの日別通過人数の推移 (2018年8月1日~2020年1月31日)

図 1.2 を見ると, 夏期より冬期の方が, 通過人数が多くなっている. データ取得期間中の月別の平均通過人数を求めたものを図 1.3 に示す.




図 1.3 各アレイの月別の平均通過人数 (2018年9月は, 北海道東部地震のあった9月6日とその翌日の9月7日を除いて算出)

通過人数が最も多い J1 を例に説明すると、7月から9月にかけては平均通過人数が10万人を下回るが、冬に向けて徐々に通過人数が増え、3月から徐々に減少する傾向が見られる。夏期には自転車を利用する人や地上を歩く人が、冬期にチ・カ・ホを利用するケースが増えるためと考えられる。

次に、曜日別に平均通過人数を求めた結果を図 1.4 に示す。各アレイとも、月曜の通過人数が多いが、図 1.4 を見る限り、曜日と通過人数の関係は明確ではない。祝祭日や気象条件など、複数の要因が影響していると考えられる。




図 1.4 各アレイの曜日別の平均通過人数（北海道東部地震のあった 2018 年 9 月 6 日とその翌日の 9 月 7 日を除いて算出）

1.3. チ・カ・ホ通過人数の推定モデルの構築

本研究では、チ・カ・ホの1日当たり通過人数を、ニューラルネットワークを用いて推定する。前節で述べたように、欠測の多い J5 を対象から除外し、本研究では J1 から J4 を対象とする。

1.3.1. ニューラルネットワークの概要

ニューラルネットワークは、人間や動物の脳神経回路をモデルとしたアルゴリズムである。図 1.5 は、ニューラルネットワークを構成するニューロンの模式図である。入力 (x_1, x_2) にそれぞれ重み (w_1, w_2) を乗じた値 ($x_1 \cdot w_1 + x_2 \cdot w_2$)

が閾値 (θ) を超えるとある値を出力し、それ以下であれば値を出力しない。

ニューラルネットワークは、これらのニューロンが連なる入力層、隠れ層（中間層）、出力層から構成される（図 1.6）。多層のニューラルネットワーク(Deep Neural Network)による機械学習手法をディープラーニング（深層学習）という。




図 1.5 ニューロンの模式図

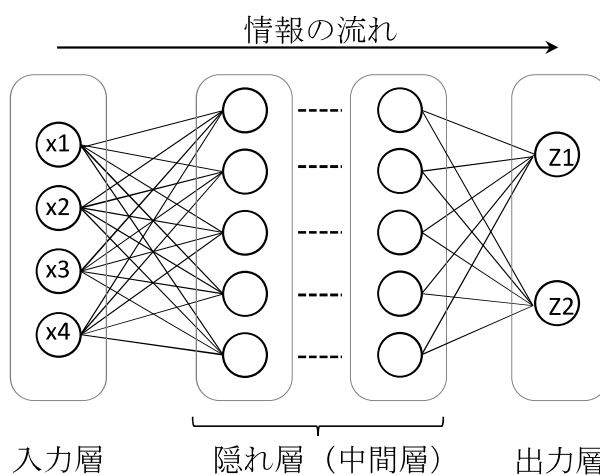


図 1.6 一般的なニューラルネットワークの模式図

1.3.2. 説明変数の設定

ニューラルネットワークモデルに投入する変数は、チ・カ・ホ通過人数に影響を与えると考えられる要因を変数として選定する。

チ・カ・ホ利用者は、通勤・通学・買い物・観光などの利用目的を持っていると考えられる。図 1.4 に示したように、曜日による通過人数の違いは明確ではなかったが、通勤、通学などがチ・カ・ホ通過人数に影響していると考えられることから、曜日、平日・土日・祝祭日であるかを変数として選定した。

また、図 1.3 に示したように、冬期にはチ・カ・ホ通過人数が増えること、同様に、雨天など悪天候時にもチ・カ・ホ通過人数が増えると考えられることから、気象の要素を変数として選定した。

本研究では、表 1.3 に示す曜日や気象に関する 20 の変数を説明変数として選定した。

表 1.3 ニューラルネットワークモデルに投入した変数

説明変数		備考	数
曜日		日曜～土曜を2値で表現	7
平日・土日		2値で表現	2
祝祭日		2値で表現	1
気 象 要 素	平均気温	当日	1
	最高気温	当日	1
	最低気温	当日	1
	降水量	当日	1
	日照時間	当日	1
	日射量	当日	1
	最深積雪	当日	1
	降雪量	当日	1
	平均風速	当日	1
	最大風速	当日	1
説明変数の合計			20

曜日などのカテゴリ変数は、one-hot エンコーディングを用いた。one-hot エンコーディングとは、カテゴリ変数を機械学習のアルゴリズムが学習しやすいように 0 と 1 で表現する処理で、たとえば、日曜日を[1, 0, 0, 0, 0, 0, 0]、月曜日を[0, 1, 0, 0, 0, 0, 0]と表現する。

また、2018 年度、2019 年度の祝祭日を表 1.4、表 1.5 に示す。

表 1.4 2018 年度の祝祭日

(オレンジ色に着色したセルはデータ期間中の祝祭日を表す)

日付	祝祭日
2018年4月29日(日)	昭和の日
2018年4月30日(月)	振替休日
2018年5月3日(木)	憲法記念日
2018年5月4日(金)	みどりの日
2018年5月5日(土)	こどもの日
2018年7月16日(月)	海の日
2018年8月11日(土)	山の日
2018年9月17日(月)	敬老の日
2018年9月24日(月)	秋分の日
2018年10月8日(月)	体育の日
2018年11月3日(土)	文化の日
2018年11月23日(金)	勤労感謝の日
2018年12月23日(日)	天皇誕生日
2018年12月24日(月)	振替休日
2019年1月1日(火)	元日
2019年1月14日(月)	成人の日
2019年2月11日(月)	建国記念の日
2019年3月21日(木)	春分の日

表 1.5 2019 年度の祝祭日

(オレンジ色に着色したセルはデータ期間中の祝祭日を表す)

日付	祝祭日
2019年4月29日(月)	昭和の日
2019年4月30日(火)	祝日
2019年5月1日(水)	天皇即位の日
2019年5月2日(木)	祝日
2019年5月3日(金)	憲法記念日
2019年5月4日(土)	みどりの日
2019年5月5日(日)	こどもの日
2019年5月6日(月)	こどもの日振替休日
2019年7月15日(月)	海の日
2019年8月11日(日)	山の日
2019年8月12日(月)	山の日振替休日
2019年9月16日(月)	敬老の日
2019年9月23日(月)	秋分の日
2019年10月14日(月)	体育の日
2019年10月22日(火)	即位礼正殿の儀
2019年11月3日(日)	文化の日
2019年11月4日(月)	文化の日振替休日
2019年11月23日(土)	勤労感謝の日
2020年1月1日(水)	元日
2020年1月13日(月)	成人の日
2020年2月11日(火)	建国記念の日
2020年2月23日(日)	天皇誕生日
2020年2月24日(月)	天皇誕生日振替休日
2020年3月20日(金)	春分の日

気象データは、国土交通省気象庁の“過去の気象データ・ダウンロードサイト” [1] (図 1.7) から、必要な気象データをダウンロードして使用した。



図 1.7 国土交通省気象庁の“過去の気象データ・ダウンロードサイト”

1.3.3. ニューラルネットワークモデルの構築

ニューラルネットワークモデルを構築するプログラミング言語として、本研究では Python(ver. 3.6.6)を使用した。

Python は、Guido van Rossum 氏が開発した動的プログラミング言語で、自由に使用・配布でき、商用利用も可能なオープンソースライセンスで提供されている [2]。Python は、多くのデベロッパーによって数多くのライブラリ開発が行われており、機械学習や AI 開発にも活用されている。

本研究では、ニューラルネットワークの実装に、以下のライブラリを使用した。

- ・ TensorFlow [3] :
Google の機械学習/ディープラーニング/多層ニューラルネットワークの開発用オープンソースのライブラリ。
- ・ TFLearn [4] :
Tensorflow 用のディープラーニングライブラリ
- ・ Keras [5] :
Python で書かれた, TensorFlow 上で実行可能なニューラルネットワークライブラリ

ライブラリのバージョンは, TensorFlow は ver. 1.16.0, TFLearn は ver. 0.3.2 および Keras は ver. 2.2.4 を使用した。

1.3.4. ニューラルネットワークモデルの学習

1 日当たりのチ・カ・ホ通過人数を目的変数, 表 1.3 に示した 20 変数を説明変数としてニューラルネットワークに学習させる。なお, 本研究で用いたデータ期間は 2018 年 8 月 1 日から 2020 年 1 月 31 日までの 549 日間であるが, 北海道胆振東部地震が発生した 2018 年 9 月 6 日とその翌日の 2 日間のデータを除外し, 547 日間のデータを用いることとした。

547 個のデータのうち, 85% (464 個) を学習に用いる教師データ, 15% (83 個) を検証データとした。教師データと検証データへの分割はデータをシャッフルして行った。学習回数 (エポック数) は最大 500 回とし, 過学習 (overfitting) を防ぐため, 検証データの損失関数の推移から学習を早期に終了する Early-stopping[6]を実装した。

1.3.5. ニューラルネットワークモデルのパラメータ・チューニング

ニューラルネットワークでは, 学習率などの学習に関するパラメータ, 隠れ層の層数などのモデル構造に関するパラメータのチューニング (調整) が重要になる。本節では, 隠れ層の構造に関するパラメータ・チューニングを例に紹介する。

1.3.5.1. 隠れ層の層数に関するチューニング

J1 を対象にチューニングを行う。隠れ層のニューロン数を 64 に固定し, 隠れ層の層数を 2 から 7 までとして, ニューラルネットワークモデルでアレイ J1 の通過人数を推定する。

なお、本検証の評価指標には、平均絶対誤差（Mean Absolute Error: MAE）（式（1））を用いた。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (1)$$

式(1)において、 n はデータ数、 f_i は予測値、そして y_i は実測値を表す。本検証においては、 n は検証用データ数の 83、 f_i は通過人数の推定値、そして y_i は通過人数の実測値となる。

隠れ層数と平均絶対誤差の関係を図 1.8 に示す。




図 1.8 隠れ層の層数と J1 の通過人数推定値の平均絶対誤差

隠れ層の層数が 4 の場合に、推定の平均絶対誤差が最も小さかったことから、本研究で構築するニューラルネットワークモデルの隠れ層の層数を 4 とする。

1.3.5.2. 隠れ層のニューロン数に関するチューニング

隠れ層の層数を 4 とし、隠れ層のニューロン数を 32, 64, 128, 256 とし、ニューラルネットワークモデルでアレイ J1 の通過人数を推定する。推定人数の誤差から適切なニューロン数を決定する（図 1.9）。

隠れ層のニューロン数を 64 とした場合、通過人数の推定誤差が最も小さい結果となった。本研究では、前節の検証より隠れ層の層数を 4、隠れ層のニューロン数を 64 と設定する。





図 1.9 隠れ層のニューロン数と J1 の通過人数推定値の平均絶対誤差


1.4. ニューラルネットワークモデルによるチ・カ・ホ通過人数の推定結果

図 1.10 に、ニューラルネットワークモデルによる J1～J4 の日通過人数の推定結果と実測値を示す。図 1.10 にプロットされているのは、検証データとしてランダムに抽出された 83 個の実測値と、学習モデルによる推定結果である。


(a)アレイ J1



(b)アレイ J2



(c)アレイ J3



(d)アレイ J4




図 1.10 チ・カ・ホ通過人数の推定結果

((a)アレイ J1, (b)アレイ J2, (c)アレイ J3, (d)アレイ J4)

次に、上記の推定の誤差を定量的に表す。誤差を評価する指標としては、前節で紹介した平均絶対誤差 (Mean Absolute Error: MAE) (式 (1)) に加え、誤差の最大値・最小値を知るために最大絶対誤差 (Maximum Absolute Error: MaxAE) (式 (2)) を用いた。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (1)$$

$$\text{MaxAE} = \max_{1 \leq i \leq n} |f_i - y_i| \quad (2)$$

式(1), 式(2)において, n はデータ数, f_i は予測値, そして y_i は実測値を表す。本検証において, n は検証用データ数の 83, f_i は通過人数の推定値, そして y_i は通過人数の実測値となる。

各アレイで MAE, MaxAE を計算した結果を表 1.6 に示す。平均絶対誤差 (MAE) は約 9,000 人から, 最大で約 11,000 人となった。

表 1.6 各アレイの推定誤差 (検証データを用いて計算)

誤差	J1	J2	J3	J4
MAE	10,743	8,954	9,700	10,865
MaxAE	38,807	32,365	51,787	46,288

図 1.2 に示したように, 各アレイの通過人数は大きく異なるため, 各アレイの通過人数の平均値と平均絶対誤差の比 (式 (3)) で推定の誤差を表す。

$$\text{推定誤差} = \frac{\text{平均絶対誤差}}{\text{平均通過人数}} \quad (3)$$

式(3)を用いて, 各アレイの平均通過人数に対する推定誤差の割合を計算した結果を表 1.7 に示す。

表 1.7 各アレイの推定誤差 (%)


	J1	J2	J3	J4
平均通過人数	125,556	83,183	115,576	112,087
平均絶対誤差	10,743	8,954	9,700	10,865
推定誤差	8.6%	10.8%	8.4%	9.7%

平均通過人数に対する推定誤差は, 8.4%から 10.8%となった。表 1.6 に示した

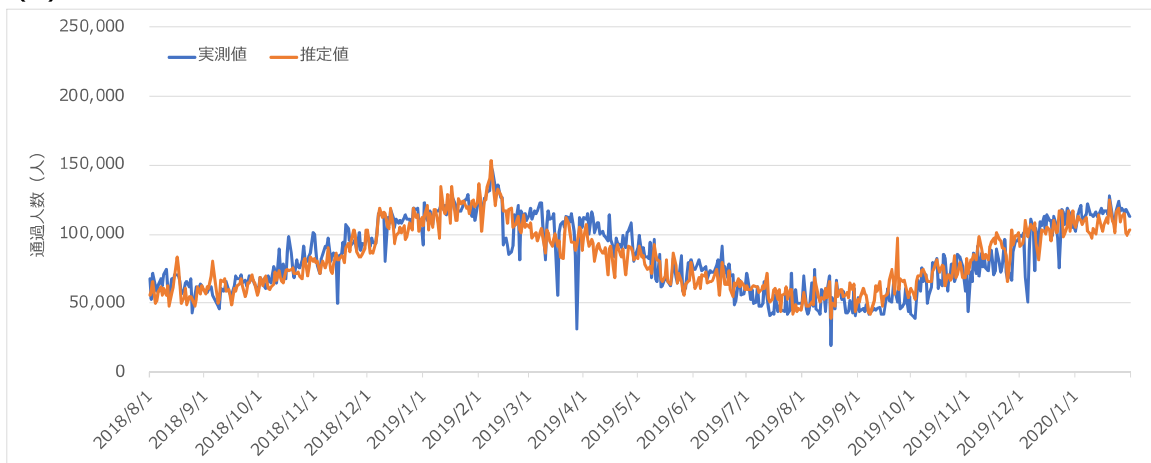
ように大きな誤差が生じる場合があるが、誤差は約 10%と高い推定精度を示した。

次に、学習結果を用いて、データ期間（2018年8月1日から2020年1月3日まで）のアレイの通過人数を再現した結果を図 1.11 に示す。


(a)アレイ J1



(b)アレイ J2



(c)アレイ J3






図 1.11 チ・カ・ホ通過人数の再現結果

((a)アレイ J1, (b)アレイ J2, (c)アレイ J3, (d)アレイ J4)

時折、実測値と推定値が大きく乖離する場合があるが、チ・カ・ホ通過人数の傾向をよく捉えている。

なお、実測値と推定値が大きく乖離した日のうち、実測値が極端に小さな値となっている日には、センサーの不調、一部で出入口をメンテナンス等で閉鎖したなど何かの原因があるかもしれない。これらについて原因を調べ、上記のような理由で実測値が適切でないと考えられる場合には、異常値として除外するなどの対応を検討する必要がある。

1.5. チ・カ・ホの人流推定・予測システムの構築（試作）

1.5.1. システムの基本構成検討

前章までで述べたように、チ・カ・ホの人流センサのデータ等からニューラルネットワーク（NN）モデルを構築し、一定の精度でチ・カ・ホの通過人数を推定できることを確認した。通過人数の推定には、①平日・土日・祝祭日のカレンダー情報、②気象要素の推定値、の大きく 2 種類の情報が必要になる（図 1.12）。




図 1.12 人流推定の基本的な流れ

学習により構築した NN モデルは、h5 ファイル形式で保存することができ、当該モデルをアレイごとに構築・保存すれば、各アレイの通過人数の推定が可能にな

る。さらに、将来のカレンダー情報、気象情報をモデルに投入すれば、将来の通過人数を得ることができる。構築した NN モデルを活用した通過人数予測の仕組みを図 1.13 に示す。

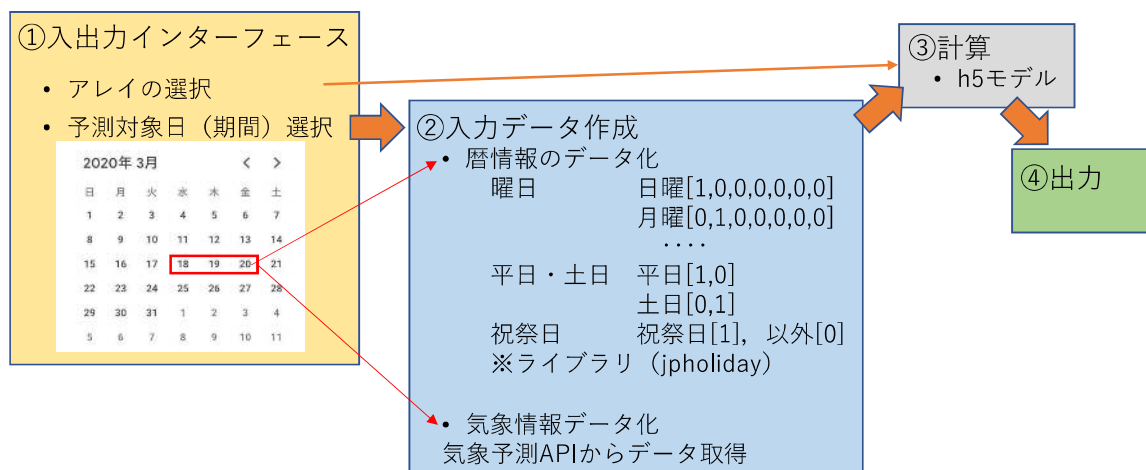


図 1.13 NN モデルを活用した通過人数の予測の仕組み

祝祭日と気象の将来値の取得について説明する。祝祭日については、内閣府のウェブサイト[7]で、2021 年までの国民の祝日を CSV ファイルで取得できるほか、Python のライブラリ jpholiday[8]を利用することができる。本研究では、プログラム実装の容易さを考慮して、jpholiday を採用する。

気象の将来値は、気象予測サービスを利用する必要がある。システムの利用しやすさ、将来的なシステムの実展性（人流センサーデータをオンライン（API）で取得できるようになる）を考え、気象 API から必要な予測情報を取得することが望ましいと考えられる。気象 API では、一部のサービスを無料で利用できる OpenWeather[9]があるが、無料で入手できる気象要素は少なく、予測期間（何日先までの予測情報が得られるか）が短いため、有料の気象 API サービスを利用する必要がある。

有料の気象 API サービスは、予測項目、期間、および費用が様々なため、さらに情報を収集し、システム構築の際に利用する気象 API サービスを検討する必要がある。

1.5.2. チ・カ・ホの人流推定・予測システムの構築（試作）

チ・カ・ホの人流推定・予測システムを試作する。システムは、将来的にインターネット経由で推定・予測に必要な情報を取得し、人流の推定・予測結果を発信す

ることを念頭に、ブラウザで表示・操作可能な Web アプリケーションを構築した。

Web アプリケーションの構築には、Django[10]を使用した。Django は、Python で実装された無料・オープンソースの Web アプリケーションフレームワークで、Web アプリ開発が容易である。

以下に、試作した Web アプリケーションの概要を説明する。

(1)プラットフォーム

ブラウザで表示可能な WEB 形式のユーザーインターフェースを構築する。対応ブラウザは、Edge, Chrome, FireFox および Safari とする。クラウドサーバー上に構築し、試作段階のため ID とパスワードを設定してアクセスを管理した。

(2)トップ画面

以下の画面を提供する。



図 1.14 チ・カ・ホ人流推定・予測システムのトップ画面

条件入力

- ・アレイ

予測対象のアレイを J1, J2, J3, J4 から選択する。

- ・予測対象日（開始／終了）

当日から 1 週間後の日付までの範囲で入力する。

開始のみを入力した場合は、入力した 1 日を範囲とする。

- ・通過人数予測ボタン

上記の条件を入力後，クリックすることで予測を行う。

(3)結果出力

結果出力画面を図 1.15 に示す。

予測日	通過人数	最高気温(°C)	最低気温(°C)	降水量(mm)	降雪量(cm)
2020/03/02 (月)	179,763	3.7	-2.4	0	1
2020/03/03 (火)	175,178	7	-4.1	0	0
2020/03/04 (水)	167,726	5.2	0.2	0	0
2020/03/05 (木)	167,598	4.4	-0.1	0	0
2020/03/06 (金)	147,814	8.3	0	0	0
2020/03/07 (土)	145,168	3.2	-2.9	0	0
2020/03/08 (日)	142,203	4.5	-4	0	1

図 1.15 チ・カ・ホ人流推定・予測システムの出力画面

出力

- ・予測日

条件入力された範囲の日付を表示する。

書式) YYYY/MM/DD (曜日)

例) 2020/03/04 (水)

- ・通過人数

予測プログラムによって予測した通過人数を表示する。

- ・最高気温(°C)，最低気温(°C)，降水量(mm)，降雪量(cm)

気象予測データを表示する。

本研究では，システムは試作段階のため有料の気象 API サービスを利用しなかった。ダミーで気象予測値のデータベースを構築し，予測対象期間のデータを読み込むことで予測を行う仕組みとした。

1.6. まとめと今後の課題

本章では、チ・カ・ホの人流センサのデータ等からニューラルネットワーク (NN) モデルを構築した。さらに、当該モデルを用いてチ・カ・ホの人流を推定・予測するシステムを試作した。

モデルの精度向上、システムの改善などの今後の研究課題、人流センサデータを活用した札幌都心部のエリアマネジメントについて以下に考察する。

(1)モデルの精度向上について

本研究では、2018年8月1日から2020年1月31日までの人流センサデータを用いてニューラルネットワークモデルを構築し、推定の誤差は8.4%-10.8%だった。推定精度が向上することで推定・予測情報の価値が高まると考えられ、以下にそのための検討・取り組みについて提言する。

①異常値の抽出

チ・カ・ホ人流センサのデータを見ると、通過人数が極端に少ない日がある。通過人数が少ない原因として、センサの異常や、出入口や通路の一部を工事等により閉鎖したなどが確認された場合は異常値として除外することが望ましい。

②説明変数の検討

本研究では、10の気象要素を説明変数として採用した。全て当日の値を採用したが、例えば、前日の天候が人の行動に影響する可能性も考えられるため、説明変数には検討の余地がある。なお、気象要素については、人流の推定・予測システムで気象API（有料）を利用する可能性があることから、気象APIの提供項目との整合、費用の面からの検討も必要となる。

(2)時間あたり通過人数の推定

本研究では、日あたり通過人数の推定モデル構築に取り組んだ。人流センサデータは15分間隔で集計していることから、1時間あたりの通過人数を推定することができたら推定情報の価値が高まると考えられる。

1時間あたり通過人数を推定するモデルを構築するには、時間のパラメータをone-hotエンコーディングで表現することから、14変数が追加される（データ取得時間が5:45~0:45のため、6時~0時まで14時間分の通過人数が得られる）。データ数が少ない割に説明変数が多くなることから、今のところ時間あたり通過人数

の推定は上手くいっていない。人流センサデータが蓄積されていくことで推定精度が高くなっていくと期待でき、今後の研究課題としたい。

(3)システムの改善等について

本研究では、チ・カ・ホの人流推定・予測システムとして、ブラウザで表示・操作可能な Web アプリケーションを試作した。チ・カ・ホ沿線の施設への予測情報の提供や、イベントスペースの利用を検討している者への情報提供等に活用可能である。今回試作した、気象予測情報が得られる範囲での予測のほか、以下のような活用も可能と考えられる。

①長期予測情報

気象 API を利用する場合、気象予測が得られる範囲での予測となるため、一ヶ月先などの長期予測ができないが、例えば、「気温が平年並みだった場合」や、「去年と同じ気象条件の場合」の通過人数のシミュレーションなどであれば、過去の気象データを活用し、向こう 1 年間の通過人数等の予測が可能である。このような長期予測情報は、例えば、翌年のイベントを検討している者にとって有益な情報となる可能性がある。

②シナリオ予測情報

入力側が任意の条件を入力し、人流の予測値を得る方法も考えられる。例えば、イベントを開催する際に、「最高気温が〇度くらいの場合」、「気温が低下し、強い雨が降った場合」などの状況に応じてどれくらいの人流が変動するか、気象のシナリオに応じた予測値を得ることで、イベントの準備や運営を効率的に行うことができると考えられる。

(3)人流センサデータの活用について

本研究では、人流センサデータの有効活用の一つの方法として、容易に入手できるデータであるカレンダー情報、気象情報と組み合わせて通過人数を推定・予測するモデルと当該モデルを内装した人流の推定・予測システムの構築に取り組んだ。

人流センサデータをさらに有効活用し、都心部のエリアマネジメントに活用していくためには、さらに多様なデータと組み合わせビッグデータ化していくことが必要となる。

①官民連携のデータプラットフォームの活用

ビッグデータとして活用可能なものとして、行政の有するデータ、企業等有するデータを併せて利用可能な、官民連携したオープンデータプラットフォームがあることが望ましい。現在、札幌では、DATA-SMART CITY SAPPORO [11]がオープンデータプラットフォームとして機能しており、これを活用するのが望ましい。

②地上の人流データとの統合

チ・カ・ホ通過人数は、夏より冬の方が多い。これは、気温の低下や降雪によりチ・カ・ホ利用者が増えるためと考えられる。札幌都心部のエリアマネジメントを考える場合には、チ・カ・ホに加えて地上の人の動きを可視化することが必要となる。地上の人の動きを可視化する取り組みの1つとして、携帯電話利用者の位置情報データを利用することが考えられ、本研究では、第2章にその取り組みを紹介する。

第1章参考文献

- [1] 過去の気象データ・ダウンロード, 国土交通省気象庁,
<https://www.data.jma.go.jp/gmd/risk/obsdl/index.php>
- [2] Python とは, Python Japan,
<https://www.python.jp/pages/about.html>
- [3] Tensorflow, <https://www.tensorflow.org>
- [4] TFlearn, <http://tflearn.org>
- [5] Keras, <https://keras.io/ja/>
- [6] Prechelt, Lutz. Automatic early stopping using cross validation: quantifying the criteria., *Neural Networks* 11.4, pp.761-767, 1998.
- [7] 国民の祝日について, 内閣府,
<https://www8.cao.go.jp/chosei/shukujitsu/gaiyou.html>
- [8] 日本の祝日を取得するライブラリ, Github,
<https://github.com/Lalcs/jpholiday>
- [9] OpenWeather, <https://openweathermap.org>
- [10] Django, <https://www.djangoproject.com>
- [11] DATA-SMART CITY SAPPORO, <https://data.pf-sapporo.jp>