

Title	航空オープンデータを用いたセクター間交通流のモデル化と混雑度予測
Author(s)	三島, 諒亮
Citation	
Issue Date	2021-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/17126
Rights	
Description	Supervisor: 平石邦彦, 先端科学技術研究科, 修士 (情報科学)

修士論文

航空オープンデータを用いた
セクター間交通流のモデル化と混雑度予測

1910204 三島 諒亮

主指導教員 平石邦彦

北陸先端科学技術大学院大学
先端科学技術研究科
情報科学

令和3年3月

概要

2015年に国土交通省がCARATS Open Dataという日本上空の過去の民間航空機の航跡データの提供を開始し、それを用いた航空システムの研究が進められている。航空機が運航する空域はセクターという単位で分割されており、航空管制官による交通流制御の最小単位となっている。航路は変更されることがあり、航空管制官がリアルタイムでモニターすることで予測と修正をしている。さらなる航空需要の増加が予測される中、遅延や空路の変更に柔軟に対応し、交通流の予測と制御を行えるモデルが求められている。

本稿では、実データであるCARATS Open Dataを用いて、空域交通流をモデル化する。さらに、状況に適したモデルの切り替えを行うAggregate Sector Flow Modelを元に、セクターの混雑度を予測する空域交通流モデルの構築と評価を行う。

目次

第1章	はじめに	1
1.1	背景	1
1.2	目的	1
1.3	構成	2
第2章	準備	3
2.1	CARATS Open Data	3
2.2	管制システムと日本上空のセクター	4
第3章	先行研究	6
3.1	セクター位置の決定	6
3.2	Aggregate Sector Flow Model	6
3.2.1	Sector Flow Model	7
3.2.2	Sector Demand Prediction Model	8
第4章	提案手法	10
4.1	概要	10
4.2	複数のLDSMモデルの構築	10
4.3	クラスタリングによる代表行列モデルの構築	11
4.4	混雑度予測	12
4.4.1	単一モデルによるセクター需要予測	12
4.4.2	複数のモデル切り替えによるセクター需要予測	13
第5章	評価実験	15
5.1	実験内容と評価基準	15
5.2	実験環境	15
5.3	実験結果と考察	15
5.3.1	状態遷移行列の生成結果	16
5.3.2	クラスタリングによるモデルの構築と分析	18
5.3.3	生成したモデルによる混雑度予測	21
第6章	おわりに	33

目 次

2.1	管制部管轄空域とセクター [4]	5
3.1	Sector Flow Diagram	7
5.1	15 分ごとのセクター需要予測の精度	23
5.2	30 分ごとのセクター需要予測の精度	23
5.3	1 時間ごとのセクター需要予測の精度	24
5.4	2 時間ごとのセクター需要予測の精度	24
5.5	福岡のセクター需要予測の精度 (2015 年度)	26
5.6	福岡のセクター需要予測の精度 (2016 年度)	26
5.7	東京のセクター需要予測の精度 (2015 年度)	27
5.8	東京のセクター需要予測の精度 (2016 年度)	27
5.9	那覇のセクター需要予測の精度 (2015 年度)	28
5.10	那覇のセクター需要予測の精度 (2016 年度)	28
5.11	札幌のセクター需要予測の精度 (2015 年度)	29
5.12	札幌のセクター需要予測の精度 (2016 年度)	29
5.13	ATM のセクター需要予測の精度 (2015 年度)	30
5.14	ATM のセクター需要予測の精度 (2016 年度)	30
5.15	1 時間ごとの予測精度	31

表 目 次

2.1	CARATS Open Data のデータ型式	4
4.1	セクター情報を付与した CARATS Open Data の一部	11
5.1	予測時間ごとに生成された状態遷移行列数	16
5.2	札幌センターで生成された状態遷移行列例	17
5.3	札幌センターの代表モデル例 1	18
5.4	札幌センターの代表モデル例 2	18
5.5	モデル数の精度比較 (福岡) [%]	19
5.6	モデル数の精度比較 (神戸) [%]	19
5.7	モデル数の精度比較 (札幌) [%]	19
5.8	モデル数の精度比較 (東京) [%]	19
5.9	モデル数の精度比較 (ATM) [%]	20
5.10	有効なモデル数	20
5.11	セクター需要の予測精度 [%]	21
5.12	2015 年 5 月 11 日の福岡センターの実測値と予測したセクター需要	22
6.1	那覇センターの実測値と予測したセクター需要	39
6.2	札幌センターの実測値と予測したセクター需要	39
6.3	ATM センターの実測値と予測したセクター需要	40

第1章 はじめに

1.1 背景

近年，発展途上国を中心に世界中で航空旅客輸送数は増加傾向にある．先進国でも同様に航空交通量が増加しており，日本も例外ではない．航空需要の増加に伴い，国内では空港の整備や空域の再編，空域全体を取り仕切る管制業務の工夫など，システムの高度化や業務の効率化により対応をとってきた．しかし，2013 年当時で，2025 年ごろには運航便数が管制処理能力の限界に達することが予測され，航空業界では研究が盛んに進められてきた．日本では，2015 年に国土交通省によって，将来の航空交通システムに関する長期ビジョンである Collaborative Actions for Renovation of Air Traffic Systems : CARATS が策定され，航空交通システムの変革を具体的に実現していく方針が固められた．また，CARATS Open Data という航空交通の航跡データの提供を開始し，大学や研究所などでも研究が行われるようになった [1]．

日本では，2006 年から ATM センターが福岡で運用開始され，航空交通流管理（Air Traffic Flow Management : ATFM）や協調的意思決定システムによる空域管理などの取り組みが実際に運用されており，今後もより効率化が期待されている．

航空機の飛行計画は，混雑度や天候に応じて，管制官や操縦士によって修正されることがある．補強航空交通管理システム（Enhanced Traffic Management System : ETMS）は，現在飛行中の便や気象情報などをリアルタイムでモニターし，最短 20 分から最高 15 時間先までの交通量予測も行うシステムである．予測の正確さは，増加する予測時間によって減少する．将来の交通量予測は時間の遅延を軽減するために重要である．

航空機が飛ぶ空域はセクターで分割されている．セクターとは，航空機を安全かつ効率的に航空交通管制部が管制できるよう，空港の位置や飛行経路の構成，交通量等を考慮して，適切な大きさ，範囲，形状を定めたもので，航空交通流制御の最小単位となっている．セクターの大きさや形の設計が適切ではないと，遅延や制御の効率の低下を招く．それによって，管制業務が非効率になり，全体的な遅延が発生する．それぞれのセクターには航空機の容量があり，人間が航空交通を制御する中で，安全に最小限の遅延を抑えるためには，セクター容量内での効率的な制御が求められる．さらなる航空需要の増加が予測される中で，遅延や空路の変更に柔軟に対応し，交通流の予測と制御を行える技術の開発が進められている．

1.2 目的

航空交通流の制御は航空管制官のスキルに頼っている．航空交通流のモデル化手法の 1 つに Linear Dynamic System Models : LDSM があり，セクター内の機体数の予測に用い

られている。LDSM は季節、曜日、気候などの違いで過去の運航データから複数のモデルの構築が可能で、航空交通の状況に応じて、最適なモデルへ切り替えることでセクターの機体数を予測する Aggregate Sector Flow Model の有用性が示されている。しかし、[2] では、必要なモデルの個数や切り替え条件について明確な指針が示されておらず、小規模なデータに対してのみ、評価実験が行われている。

今後、航空輸送の需要は大幅に増加すると予測されており、航空業界では安全かつ効率的な運航の実現のために、空域の交通流と状況を精度良く予測するためのモデルや交通流の最適化の手法が求められている。

本研究では、大量の航跡データである CARATS Open Data を用いて、実際の航空交通流からモデルの推定を行う。本研究でのモデルは、状態遷移行列によって表現される航空交通流から、代表的な状態遷移行列を推定することである。次にそれらのモデルから空域の交通流と状況に応じて最適なものを選択し、モデルの切り替えによって、安全かつ効率的な運航の制御が行えるような予測システムの開発を目指す。

1.3 構成

本論文は以下の構成とする。第 2 章では、航空交通業界と航空交通システムに関する予備知識について述べる。第 3 章では、本研究に関連する先行研究について述べる。第 4 章では、CARATS Open Data を用いて、代表となる状態遷移行列モデルを構築する方法と Aggregate Sector Flow Model により、センターごとの各セクターの機体数を表すセクター需要ベクトルを予測する手法を提案する。第 5 章では、前章で述べた手法の結果、及び考察を行う。第 6 章では、おわりに本研究のまとめと今後の課題について述べる。

第2章 準備

2.1 CARATS Open Data

1990年代にICAO（国際民間航空機関）により将来の航空法システムが策定された。それに伴い、国内では航空衛星システムの整備、航空交通管理（ATM）の導入や広域航法（RNAV）の導入で交通量の増加に対応してきた。現行のシステムでは処理容量を超過した交通量による遅延の発生や管制官やパイロットの業務負荷などの課題が顕在化しつつある。また、ICAOにより2025年及び、それ以降を見据えた統合的でシームレスかつ相互運用性のある全世界的な航空保安サービスに関する概念（ATM運用概念）が策定され、この指針に基づき、アメリカではNextGen、欧米ではSESARという将来の航空交通システムに関する長期計画が策定された。

日本でも同様に、航空交通量の増大や様々なニーズに対応し、かつ、世界的にシームレスで円滑な航空交通を実現するため、国土交通省により、CARATS（航空交通システムの変革に向けた協調的行動）が策定された。CARATSは国土交通省が運営し、2025年に向けて航空業界が目指すべき目標、変革の方向性などが示されている。このCARATSに基づいて、システムの変革は進められており、将来の航空交通システムの構築には、航空機関連メーカーや運航者などの民間企業、大学や研究所などの教育・研究機関、航空局や関係省庁などの国・地方公共団体に関わる産学官のステークホルダー同士での協調的行動が不可欠となる。

さらに、2015年2月から国土交通省航空局が将来の航空交通システムの構築、ならびに研究開発の促進を目的として、CARATS Open Dataという実際の航空交通の航跡データを元にした大規模な航跡データを公開することで研究開発の促進がされている。同様に航跡データを公開しているものにFlightradar24というサービスがあり、航跡データを利用することができる[3]。CARATS Open Dataはレーダーサイトからの距離と方位、または、ADS-Cという航空機が自動的に現在の位置などのフライト情報を送るシステムから、各管制機関へ送られた運航情報から生成される。データはそれぞれの管制機関・システムごとに記録され、緯度、経度、高度を算出したものが利用できる。表2.1は実際のCARATS Open Dataの一部で各奇数月の1週間分の航跡がそれぞれまとめられている。内容としては、仮想で割り振られた便名のフライトが各時間にどの緯度、経度、高度に存在しているかと航空機の型式が示されている。航跡データは2012年度のものから公開されているが、2012から2014年度の期間と2015年以降では公開されているデータの仕様が異なる。本研究では2015、2016年度の期間のデータのみを採用し、実際の航空交通流に準じた手法を提案する。

表 2.1: CARATS Open Data のデータ型式

時刻	便名	緯度	経度	高度 (ft)	型式
00:00:00.5	FLT0001	28.511030	126.502830	39000	A320
00:00:00.6	FLT0002	34.782596	138.170779	33977	B748
00:00:00.7	FLT0003	34.421903	138.493346	31113	B744
⋮	⋮	⋮	⋮	⋮	⋮
23:59:59.0	FLT0004	37.693676	140.954585	38000	B737

2.2 管制システムと日本上空のセクター

航空交通では航空路と呼ばれる飛行経路が定められており、様々な大きさや、安全性能の航空機が飛行できるように、それぞれが安全のための高度や速度を必要とする。通常、旅客機は計器飛行方式 (IFR) という常に地上にいる航空管制官からの指示で飛行する方式で運航しており、管制官は全体の航空機の位置情報を確認しつつ、操縦士へ指示をする。航空交通流の管制業務を円滑に実現するため、国ごとに Flight Information Region : FIR という飛行情報区が決められており、図 2.1 のようにセクターという単位で空域は分割されている。日本では福岡、神戸、東京、札幌にセンター (空港交通管制部) があり、制御をより円滑にするため、担当するセクターを割り当て、各センターで空域の管制業務を行っている。神戸の管制センターでは、沖縄上空のセクター、福岡の ATMC (航空交通管理センター) で太平洋上のセクターの管制業務を担当している。

セクターとは航空機を安全かつ効率的に制御できるよう、空港の位置、飛行経路の構成、交通量等を考慮して適切な範囲・形状を定めたものである。通常はひとつのセクターをレーダー管制官と調整管制官の各 1 名ずつで担当する。各セクターでは、セクター容量という単位を用いて、管制官が円滑に管制業務が出来る機体数が定められており、管制指示の意思決定に使われている。セクターの設計が適切でないと、遅延や管制制御の精度の低下を引き起こす原因となる。セクターが大きすぎると、管制官の処理能力を超過してしまう可能性が生じる。また、形状が適切でないと、管制業務の非効率化や意思決定に影響を与え、航空機の円滑な運航を妨げるような制限が必要になる場合が生まれる。これまでは航空交通量の増加に伴い、セクター面では再設計、細分化で対応を取ってきたが、さらに増加が見込まれる交通量に対して、セクターをさらに細分化することは、人手の増加やセクター間の航空機の遷移の複雑化により、制御が困難になることが考えられる。したがって、セクターの設計面以外の箇所での改良が進められている。

本研究では日本上空のセクター情報は先行研究と同様に、国土交通省航空局が運用している AIS Japan (航空情報センター) で提供されているデータを使用した。




図 2.1: 管制部管轄空域とセクター [4]

第3章 先行研究

3.1 セクター位置の決定

航空交通の制御には、セクター容量と運航状況が利用される。柔軟な予測の実現には、各航空機がどのセクターを運航しているか、また、各セクターを運航中の航空機の数を知る必要がある。各機体が運航しているセクターは座標から求めることが可能で、CARATS Open Data に記載されている機体の時刻ごとの座標データから、各機体が運航中のセクターを知ることが可能である。航空機は離着陸の際、安全の為に旋回することで目的地への軌道を調整することがある。逆に、その他の区間は高度や方向の転換が少なく、直線に近い軌道をとるため、軌道の予測がしやすい。また、セクター容量に準じたセクター需要の予測を考える際に重要となるのは、各飛行機の正確な位置ではなく、機体がいつセクターを移動し、現在どのセクターにいるかを高速に処理することである。

当研究室では CARATS Open Data へのセクター情報の付与にかかる時間を短縮する手法が提案されている。[5] では離着陸付近を非安定区間とし、高度の変化度合いや機体の高度から安定した飛行がされていると考えられる区間を安定区間と定義することで、安定区間内のセクター情報を付与する際の処理時間の短縮を実現している。

本研究の提案手法において、予測に用いる状態遷移行列を生成する際、それぞれのセクターに存在する機体数を知ることが必要となる。その際にこの手法を用いて、CARATS Open Data にセクター情報を付与したデータを用意する。

3.2 Aggregate Sector Flow Model

航空交通流を制御するモデル化には LDSM という手法が多く利用されている。LDSM は上空で隣接するセクター間の航空機の出入りする関係をモデル化した手法である。さらに、この LDSM によるモデル生成は運航データの違いから複数の異なるモデルを構築することが可能なことが示されている。

[2] では生成した複数の LDSM モデルから仮説検定を利用し、状況に応じた適切なモデルの選択・切り替えを行うことで、単一モデルよりも高い精度の交通流予測ができることが示されている。しかしながら、こちらの手法については必要なモデルの個数など明確な指針が示されているわけではなく、実証実験も小規模なデータに対してのみ行われている。以降では [2] で提案された Sector Flow Model とそれを用いた Sector Demand Prediction Model について述べる。

3.2.1 Sector Flow Model

Sector Flow Model は与えられたセクターの機体数からセクター需要の予測に使用できる。セクター需要とは、各ステップでセンター内のそれぞれのセクターの交通需要を表したもので、航空交通では各セクターの機体数を指す。Sector Flow Model は、Center Flow Model[6] に改良を加えたもので、状態空間形式で表現される。状態遷移行列は CARATS Open Data のフライトデータに先行研究を用いて、航空機の位置を特定し、セクター情報を付与したものから生成する。

Sector Flow Model では、セクターとセンター間の機体の移動を図 3.1 のように記述することができる。センター内の全てのセクターについて、ある時間ステップから次の時間ステップの間に移動してくる機体は、隣接するセクターから移動する機体とセクター内の空港から出発する機体が含まれる。他のセクターへ移動する機体は、隣接するセクターへ移動していく機体と、セクター内の空港に着陸する機体が含まれる。




図 3.1: Sector Flow Diagram

ここで、 $a_{i,j}$ の $i \neq j$ の要素は、次の時間ステップでセクター i からセクター j に移動する機体数を表している。また、 $i = j$ の要素は、次の時間ステップで変わらずセクター i に残る機体数を表している。 u はセンター間を移動する機体数を表しており、 $u_{i,out}$ は、次の時間ステップでセクター i の航空機が隣接するセンターへ移動、または着陸する機体数を表している。 $u_{i,in}$ は次の時間ステップで他のセンターからセクター i に移動してくる機体数である。これらを用いると、 N 個のセクターが存在する 1 つのセンターのある時間 k におけるセンターの Sector Flow Model は次の行列で定義される。

$$T(k) = \begin{bmatrix} a_{1,1}(k) & \cdots & a_{1,N}(k) & u_{1,out}(k) \\ \vdots & \ddots & \vdots & \vdots \\ a_{N,1}(k) & \cdots & a_{N,N}(k) & u_{N,out}(k) \\ u_{1,in}(k) & \cdots & u_{N,in}(k) & 0 \end{bmatrix} \quad (3.1)$$

時刻 k におけるセクター i の交通量の需要は、同一のセクターへ滞在する機体とそれ以降のセクター i へ移動してくる機体を表す行の合計によって求めることができる。すなわち、 $T(k)$ の i 行目は、 k から $k+1$ の間にセクター内を運航する機体数とセクターから移動するすべての航空機を表している。時刻 k におけるセクター i のセクター需要は定式化された行の合計によって求められる。 $T(k)$ の i 列目は、滞在している航空機と時刻 k から $k+1$ の時間間隔でセクター i へ移動してくる機体数を表す。時刻 k におけるセクター i のセクター需要は次のように定式化された列の合計によって求められる。

$$S_i(k) = \sum_{j=1}^N a_{i,j}(k) + u_{i,out}(k) \quad (3.2)$$

$$S_i(k+1) = \sum_{j=1}^N a_{j,i}(k) + u_{i,in}(k) \quad (3.3)$$

3.2 と 3.3 より、次の関係が成り立つ。

$$\sum_{j=1}^N a_{i,j}(k+1) + u_{i,out}(k+1) = \sum_{j=1}^N a_{j,i}(k) + u_{i,in}(k) \quad (3.4)$$

Sector Flow Model は状態空間形式で表せる。状態ベクトル $x(k)$ は、センターごとの全セクターのセクター需要 $[s_1(k), \dots, s_N(k)]^T$ によって形成される。入力項 $u(k)$ を持つ $x(k)$ を $x(k+1)$ に写す状態遷移行列 $A(k)$ は以下で定義される。行列 $A(k)$ の非対角要素の (i, j) 要素は、次の時間間隔でセクター i からセクター j へ移動する確率を表し、行列 $A(k)$ の対角要素 (i, i) は、次の時間間隔でセクター i に滞在する確率を表す。 $s_i(k) = 0$ の場合、 $a_{i,j} / s_i(k)$ は 0 で置き換える。

$$A(k) = \begin{bmatrix} a_{1,1}(k)/s_1(k) & \cdots & a_{N,1}(k)/s_N(k) \\ \vdots & \ddots & \vdots \\ a_{1,N}(k)/s_1(k) & \cdots & a_{N,N}(k)/s_N(k) \end{bmatrix} \quad (3.5)$$

状態空間方程式は次のように表され、これらを用いることで各セクターのセクター需要を取得できる。

$$x(k+1) = A(k)x(k) + u(k) \quad (3.6)$$

3.2.2 Sector Demand Prediction Model

各センターにおけるセクター需要の予測モデルは、Sector Flow Model により取得された状態遷移行列 A を利用する。各ステップにおける次のセクター需要の予測は以下の式で求められる。 $\hat{x}(k+1)$ は、時間ステップ $k+1$ のときのセクター需要の予測値で、時間ステップ k のときの実際のセクター需要 $x(k)$ と移動してくる機体数から予測する。

$$\hat{x}(k+1) = A(k)x(k) + \hat{u}(k) \quad (3.7)$$

各ステップでのモデルへの入力 $\hat{u}(k)$ には、過去のデータや周辺センターの航空機の運航計画や航空機の出発予定時刻が用いられ、連続した p ステップのセクター需要予測は次の順序で実行される．

$$\begin{aligned} \hat{x}(k+1) &= A(k)x(k) + \hat{u}(k) \\ \hat{x}(k+2) &= A(k+1)x(k+1) + \hat{u}(k+1) \\ &\vdots \\ \hat{x}(k+p) &= A(k+p-1)x(k+p-1) + \hat{u}(k+p-1) \end{aligned} \quad (3.8)$$

本研究の予測には CARATS Open Data を元に生成した状態遷移行列 $A(k)$ と $A(k)$ を生成する際に取得できる $\hat{u}(k)$ ，実際のセクター需要 $x(k)$ を用いて，各ステップで次のセクター需要を予測する．

第4章 提案手法

4.1 概要

各セクターのセクター需要の予測を行うシステムの構築を以下の手順で行う。はじめに CARATS Open Data の過去の航跡データを用いて、各航空状況の交通流ダイナミクスを LDSM モデルの形で構築する。構築した LDSM モデルはセクター間交通流のダイナミクスを状態遷移行列 A として保持しており、航空状況ごとに A は異なる値を持つ。モデルの構築とは、航空状況ごとに A の具体値を推定することである。過去の航跡データを用いることで多数の状況を表した状態遷移行列を取得でき、それらの行列を類似したグループに分類するためにクラスタリングを行うことで各クラスターの代表値を決定する。さらに、推定した行列を用いて、状況に応じてモデルの選択を行うシミュレーション環境を構築し、先行研究の Aggregate Sector Flow Model と同様にセクターの交通流をシミュレーションにより予測する。

4.2 複数の LDSM モデルの構築

はじめに過去の航跡データを用いて、各ステップにおける交通流ダイナミクスを LDSM モデルの形で構築する。今回は Sector Flow Model を航跡データに適用し、隣接するセクター、セクター間の関係を表す状態遷移行列 A を大量に取得する。航空状況ごとに A は異なる値を持ち、行列群にクラスタリングを用いることで特徴を分析する。状態遷移行列は日本上空のセクターごとに生成することができ、福岡、東京、札幌、神戸、ATM（太平洋上のセクター）の全てのセクターで生成する。また、状態遷移行列を生成する際の時間間隔を変化させ、複数のパターンの状態遷移行列を生成する。これにより、時間間隔ごとの状態遷移行列で生成される状態遷移行列に大きな差異が生じるのか、時間間隔に影響されない予測が行えるモデルを生成できるのかについても考察する。

入力には先行研究 [5] を用いて、各時間で航空機が飛行しているセクター情報を CARATS Open Data に付与し、各フライトの離陸から着陸までの時間とセクターの推移が分かるように成形したものをを用いた。以下に入力データの一部を記す。CARATS Open Data では奇数月ごとに1週間分のデータがあり、1年で42日分の航跡データが利用できる。

表 4.1: セクター情報を付与した CARATS Open Data の一部

便名	時間 (秒)	緯度	経度	高度 (ft)	セクター
FLT0237	20271	26.688813	124.00826	31000	begin
FLT0237	20271	26.688813	124.00826	31000	F15
FLT0237	22346	29.702255	128.224128	30975	N01-1
⋮	⋮	⋮	⋮	⋮	⋮
FLT0237	25876	34.163742	136.193007	11561	T24-1
FLT0237	26671	34.815295	136.801131	100	end
FLT0300	23802	34.815295	136.801131	100	begin
⋮	⋮	⋮	⋮	⋮	⋮
FLT0300	28671	80.815295	136.801131	100	end

4.3 クラスタリングによる代表行列モデルの構築

過去の航跡データから生成した状態遷移行列のデータ群からフライトの特徴を抽出し、代表となる状態遷移行列のモデルを生成するため、クラスタリングを行う。クラスタリングは機械学習における教師なし学習の1つで、データ間の類似度により、データをグループ分けする手法である。クラスタリングによってできた、類似したデータが集まるグループのことをクラスと呼ぶ。クラスタリングには取得できる状態遷移行列の数が多いこと、また、類似した航空状況から代表となる状態遷移行列を求めることから、非階層クラスタ分析手法の1つである k-means++ を採用した。

非階層クラスタリングは、クラスとデータとの類似度を測る評価関数を用いることでデータをクラスに分類する。この方法は階層型クラスタリングと比較し、計算コストが少ないため、大規模データのクラスタリングに適している。k-means 法は事前に最終的なクラス数 k を指定し、各データとの距離が最小になるようなクラスタの中心点を逐次的に決めることで、クラスタリングを行う手法である。したがって、センターごとの有効なクラス数を決定する必要がある。また、本研究では、予測を行う時間間隔ごとに代表となる状態遷移行列モデルを生成するため、それぞれの時間間隔でのクラス数を決定し、モデル数を決定する。

k-means 法は最初のクラスタの中心点がランダムに決定される。これにより、クラスタリングの結果が初期値に依存する問題がある。k-means++ は、ベクトルの距離が大きいものを確率的に選ばれやすくすることでランダムに次のクラスタの中心を決める方法で、重みつき確率分布を用いることで外れ値に対応したクラスタリングが行える。

step1: ランダムに1つベクトルを選択し、代表ベクトルとする。

step2: 代表ベクトルの数が k 個になったら終了。

step3: それぞれのベクトル x に関して、そのベクトルに最も近い代表ベクトルとの距離 $D(x)$ を求める。

step4: $\frac{D(x)^2}{\sum D(x)^2}$ を用いて、新たな代表ベクトルをランダムに選び、step2 へ。

kmeans++でのクラスタリングにおけるクラスタ数 k はシルエット分析の利用、クラスタ数を変更によるクラスター分析を行い、モデルの候補を複数パターン用意し、実際のセクター需要予測で最も精度が高くなるものを採用する。

[2] では、モデルの個数に明確な指針が立てられていないため、複数パターンのモデルを生成し、モデル数の違いによる精度の違いについても評価を行う。また、クラスタリングにより、クラスタごとに分けられた状態遷移行列のデータの日付や時間についても検証し、時間帯などによる特徴が大きく表れるかについての知見を得る。

4.4 混雑度予測

Sector Flow Model によって状態遷移行列を取得し、クラスタリングを用いて、航空交通流における特徴を分析することで、生成された状態遷移行列のモデル群と CARATS Open Data を利用した各セクターのセクター需要予測を行う。本項では、センターごとに生成した状態遷移行列のモデル群を用いて、各ステップでそれぞれのセクター需要ベクトルの予測を行う。はじめに、モデル群から状態遷移行列モデルを1つ選択し、そのモデルのみを用いた需要予測を行う。また、各ステップ時に代表モデルから最も適切なモデルの選択・切り替えによる複数のモデルを利用した予測を行い、予測精度とモデル切り替えの有効性についても評価する。CARATS Open Data の1ヶ月の運航データは連続した1週間のデータとして与えられている。本手法では、混雑度予測をそれぞれの日付ごとに行う。1つのモデルのみでの予測と複数のモデル切り替えによる予測はそれぞれ以下の手順で検証する。生成した状態遷移行列モデルはそれぞれ $A^1, \dots, A^n$ とし、各時点で次のステップに各セクターへ移動してくる機体数を $u(k)$ とする。また、各時点でのセクター需要ベクトルの予測値 $x'(k)$ と実測値 $x(k)$ の差の検証には、コサイン類似度を用いる。実測値は実際の予測間隔中にフライトで各セクターに存在した機体数の平均を用いる。

4.4.1 単一モデルによるセクター需要予測

生成した状態遷移行列モデルのうちの1つのみを用いて、日付ごとの各セクターの予測をそれぞれ以下の手順で行う。

$k = 0$ のとき

セクター需要ベクトルの初期値 $x(0)$ には実測値を用いる。代表となるモデルは各センターで生成した状態遷移行列モデル群のうち、最もそのクラスタに分類された状態遷移行列が多かったモデルを予測に用いる代表モデル A_{rep} とする。そして、次ステップに各セクターへ移動してくる航空機の入力 $u(0)$ を利用し、次のステップのセクター需要 $x'(1)$ を予測する。

$$x'(1) = A_{rep} x(0) + u(0) \quad (4.1)$$

$k \neq 0$ のとき

ステップごとにその時点でのセクター需要の実測値 $x(k)$ が与えられる．次のステップの予測に用いる状態遷移行列モデルは与えられた実測値に関わらず， $k = 0$ のときと同様の A_{rep} を採用し，1つのモデルによる予測を行う．式 4.2 のように，各ステップのセクター需要の実測値と次ステップに移動してくる機体数 $u(k)$ を用いて，同様のモデルを利用した予測を繰り返し行う．

$$\begin{aligned} x'(k+1) &= A_{rep} x(k) + u(k) \\ x'(k+2) &= A_{rep} x(k+1) + u(k+1) \\ &\vdots \\ x'(k+p) &= A_{rep} x(k+p-1) + u(k+p-1) \end{aligned} \tag{4.2}$$

4.4.2 複数のモデル切り替えによるセクター需要予測

生成した複数のモデルから各ステップで最も適したものを選択し，切り替えを行うことで，セクター需要ベクトルを予測する手法について示す．代表モデルから各ステップで適した状態遷移行列を決定する方法と，モデルの切り替えによる予測は以下の方法で行う．各時刻 k における $x(k+1)$ を予測する際に用いる行列 A を A_k とする．

$k = 0$ のとき

1つのモデルによる予測と同様に，セクター需要の初期値 $x(0)$ には実測値を用いる．初期値のモデル A_0 も同様に各センターで生成した状態遷移行列モデル群のうち，最もそのクラスに分類された状態遷移行列が多かったモデルを $k = 0$ のときの行列として採用し，次ステップに移動してくる航空機の入力 $u(0)$ を与え，式 4.3 によって，セクター需要ベクトルの予測値を計算する．

$$x'(1) = A_0 x(0) + u(0) \tag{4.3}$$

$k \neq 0$ のとき

以下の処理を繰り返すことにより，セクター需要を予測する．各ステップでは，その時点での実測値 $x(k)$ が与えられる．与えられた実測値に適した各ステップの状態遷移行列 A_k は式 4.4 により，用意したモデルごとの予測値をそれぞれ計算し，予測値 $x'(k)$ と与えられた $x(k)$ の差が最も小さくなるモデル A^j を採用する． j は生成した状態遷移行列のモデル数を表す．

$$x'(k) = A^j x(k-1) + u(k-1) \quad (j = 1, \dots, n) \tag{4.4}$$

式 4.4 により, k のときの状態遷移行列をモデルから 1 つ決定し, $x(k+1)$ のセクター需要の予測を繰り返す.

$$A_k := A^r \quad (4.5)$$

$$x'(k+1) = A_k x(k) + u(k) \quad (4.6)$$

CARATS Open Data の 1 ヶ月の運航データは連続した 1 週間のデータとして与えられている. 本手法では, 以上のステップでの予測をそれぞれの日付ごとに行う.

第5章 評価実験

5.1 実験内容と評価基準

実験の入力データには CARATS Open Data で公開されている 2015, 2016 年の全てのデータを用いて実装, 実験を行った. 実験では福岡, 札幌, 那覇, 東京, ATM, それぞれのセンターで状態遷移行列群を生成し, クラスタリングを利用することで代表モデルを生成する. 評価はセクターごとの混雑度を表すセクター需要ベクトルの誤差で評価する. 誤差による評価は実際の状態遷移行列を用いて状態ベクトルを求めたものと, 作成した状態遷移行列のモデル群を切り替えることで状態ベクトルを求めるもので行う.

2つの状態ベクトルの誤差率の計算にはコサイン類似度により, 評価を行う. コサイン類似度はベクトルの内積を用いて類似度を計算する手法で, 各セクターの混雑度をそれぞれ比較する. また, 状態遷移行列のモデル数や, 状態遷移行列を生成する時間間隔についての知見を得る. そして, 予測を行う時間間隔の違いにおける精度を比較し, 予測間隔に影響されない予測モデルが作成できたかについても評価する.

5.2 実験環境

本研究における開発, 及び実験環境は Intel[®] NUC Mini PC 上に VMware を用いて Ubuntu を導入し, vscode 上で python2.7 を用いて開発を行った.

Intel[®] NUC Mini PC の構成は, プロセッサ, 8th Generation Intel[®] Core i7-8565U processor, メモリは 8GB, コア数は 4 となっている.

5.3 実験結果と考察

4章で述べた提案手法を実装し, CARATS Open Data の実際のフライトデータを用いたセクターごとの各セクターの需要予測を行い, その精度を考察する. また, セクター需要の予測を行う時間間隔を複数のパターンで行い, 予測精度に影響があるかについても比較する. さらに, 各センターで予測する時間間隔ごとに代表となる状態遷移行列のモデル群を生成し, 適切なモデル数や状態遷移行列群の特徴を分析する.

5.3.1 状態遷移行列の生成結果

はじめに、Sector Flow Modelにより、福岡、札幌、那覇、東京、ATMのセンターごとの状態遷移行列を生成した。生成した状態遷移行列がセクター需要を予測する時間間隔の差により、精度に違いが生じるかについて検証するため、15分、30分、1時間、2時間の間隔でそれぞれデータを生成した。時間の間隔は先行研究の予測間隔の最小値である15分と最大値である2時間の間から採用した。センターごとのセクターは福岡では28個、東京では39個、神戸では6個、札幌では8個、ATMでは5個にそれぞれ分割されている。状態遷移行列は各センターの時間間隔ごとにそれぞれ生成した。CARATS Open Dataで利用できるデータは1年度ごとに42日分用意されており、本研究では2015年と2016年を採用したため、84日分のデータを利用した。生成する状態遷移行列は予測を行う時間間隔ごとに、以下の数の状態遷移行列を取得した。

表 5.1: 予測時間ごとに生成された状態遷移行列数

予測間隔	状態遷移行列数
15 分	8064
30 分	4032
1 時間	2016
2 時間	1018

また、状態遷移行列は表 5.2 のように表現され、セクター同士の関係を表したものとなっている。以下の表は2015年5月11日の10時と16時の航空交通流を表す札幌センターで生成された状態遷移行列で、表のように異なる値を持つ行列が取得できる。これらの行列をセンターごとに生成し、生成した行列は日付、時間帯で異なる値を持っており、センターごとに生成した状態遷移行列群に対して、クラスタリングを適用し、モデルを構築した。

表 5.2: 札幌センターで生成された状態遷移行列例

(a) 2015 年 5 月 11 日 10 時の状態遷移行列

	S01	S02	S03-1	S03-2	S04-1	S04-2	S31	S34
S01	0.4286	0.14929	0	0	0	0	0	0
S02	0	0.5714	0.0769	0	0	0	0	0
S03-1	0.1429	0.8571	0.3846	0	0	0	0	0
S03-2	0	0	0	0	0	0	0	0
S04-1	0	0.1538	0	0.25	0	0	0	0
S04-2	0	0	0	0	0	0	0	0
S31	0	0	0	0	0	0	1	0
S34	0	0	0	0	0	0	0	0

(b) 2015 年 5 月 11 日 16 時の状態遷移行列

	S01	S02	S03-1	S03-2	S04-1	S04-2	S31	S34
S01	0.5556	0.0909	0	0	0	0	0	0
S02	0	0.5455	0.0909	0	0.0833	0	0	0
S03-1	0.2222	0.2727	0.5455	0	0	0	0	0
S03-2	0	0	0	0	0	0	0	0
S04-1	0	0.0909	0.3636	0	0.3333	0	0	0
S04-2	0	0	0	0	0	0	0	0
S31	0	0	0	0	0	0	0	0
S34	0	0	0	0	0	0	0	0

5.3.2 クラスタリングによるモデルの構築と分析

表 5.2 のように、生成した状態遷移行列は日付、時間帯で異なる値を持っている。各センターでの航空交通流の特徴を分析し、状態遷移行列の代表モデルを構築するため、生成した状態遷移行列群に対して、クラスタリングを適用した。例として、札幌のセンターで 30 分間隔で生成した状態遷移行列群にクラスタリングを適用し、クラスタに分類された行列群から生成したモデルを 2 つ示す。

表 5.3: 札幌センターの代表モデル例 1

	S01	S02	S03-1	S03-2	S04-1	S04-2	S31	S34
S01	0.4935	0.0088	0.0078	0.0341	0	0	0.0553	0
S02	0.0169	0.6488	0.1162	0	0.0917	0	0.0037	0
S03-1	0.2177	0.1828	0.6257	0	0.0078	0	0.0883	0
S03-2	0	0	0.0051	0.0321	0	0	0	0
S04-1	0	0.1142	0.0933	0	0.5298	0	0	0
S04-2	0	0	0	0	0	0	0	0
S31	0.0223	0.0125	0.0122	0	0	0	0.4713	0
S34	0	0	0	0	0	0	0	0

表 5.4: 札幌センターの代表モデル例 2

	S01	S02	S03-1	S03-2	S04-1	S04-2	S31	S34
S01	0.1145	0.0006	0.0067	0.0061	0	0	0.002	0
S02	0.0064	0.4996	0.1605	0	0.0886	0	0	0
S03-1	0.0317	0.1573	0.3899	0	0.0126	0	0	0
S03-2	0	0	0.0201	0.0539	0	0	0	0
S04-1	0	0.1235	0.0262	0	0.1442	0	0	0
S04-2	0	0	0	0	0	0	0	0
S31	0.0004	0.0044	0.0021	0	0	0	0.0452	0
S34	0	0	0	0	0	0	0	0

代表となるモデルはそれぞれ類似度の高い状態遷移行列同士で分類され、要素ごとに異なる値を持つ行列群を生成することができる。クラスタ数の決定は k-means 法で有用とされるシルエット法を用いて、各センターの時間間隔ごとに有望なクラスタ数の候補を推測し、実際のセクター需要の予測を通して、最適なモデル数を判断した。各センター、時間間隔ごとの有望なモデル数の候補を 3 個決定し、それぞれでセクター需要の予測を行った結果を以下に示す。

表 5.5: モデル数の精度比較 (福岡) [%]

時間間隔	モデル数	予測精度
15 分	11	93.8
	14	95.3
	17	94.2
30 分	7	93.1
	18	95.1
	22	94.3
1 時間	10	94.3
	16	95.7
	18	94.6
2 時間	6	95.2
	11	97.1
	17	95.8

表 5.6: モデル数の精度比較 (神戸) [%]

時間間隔	モデル数	予測精度
15 分	8	95.1
	13	98.4
	17	97.4
30 分	8	96.6
	17	92.4
	22	97.5
1 時間	7	93.2
	10	96.4
	13	92.9
2 時間	13	98.6
	18	96.3
	19	95.5

表 5.7: モデル数の精度比較 (札幌) [%]

時間間隔	モデル数	予測精度
15 分	6	69.4
	13	70.8
	16	71.3
30 分	10	70.9
	12	70.1
	22	70.3
1 時間	7	69.5
	13	68.3
	21	67.7
2 時間	9	78.8
	12	80.5
	19	79.8

表 5.8: モデル数の精度比較 (東京) [%]

時間間隔	モデル数	予測精度
15 分	14	94.9
	16	96.3
	17	96.0
30 分	9	92.7
	13	96.3
	18	95.7
1 時間	7	91.5
	16	95.0
	19	96.1
2 時間	14	96.8
	16	97.6
	20	93.2

表 5.9: モデル数の精度比較 (ATM) [%]

時間間隔	モデル数	予測精度
15 分	6	94.2
	11	97.4
	21	96.5
30 分	13	97.6
	18	97.1
	21	95.3
1 時間	9	97.7
	14	97.2
	17	94.8
2 時間	6	94.8
	8	98.5
	20	97.4

条件ごとの有望なモデル数で混雑度予測を行い、最も精度が良くなったクラスタ数は以下となった。結果より、予測間隔が短い場合、長い場合に関わらず、必ずしもモデル数が多い、または少ない方が良いという傾向は得られなかった。無作為に決めたモデル数で状態遷移行列モデルを生成した場合は予測精度が低くなるが、時間帯ごとに有望なモデル数が複数存在することが言える。したがって、各センターの航空交通流に合わせたモデル数の設定が求められる。以降の実験では、有望なモデル数をもとに混雑度予測を行い、各センターの条件で最も精度の良くなった以下のモデル数を用いる。

[2] などでは複数の LDSM モデルの構築に、季節や天候を特徴として加えていた。本手法の状態遷移行列を用いたクラスタリングでは、それらの特徴がクラスタ分類結果には顕著には表れず、時間帯を中心に分類結果が得られた。

表 5.10: 有効なモデル数

	15 分	30 分	1 時間	2 時間
福岡	14	18	16	11
那覇	13	22	10	13
札幌	16	10	7	12
東京	16	13	19	16
ATM	11	13	9	8

5.3.3 生成したモデルによる混雑度予測

クラスタリングを用いて、複数のモデルを生成した。これらのモデルを用いた提案手法が、セクター需要の予測を行う間隔の違いにより、精度に差が生じるかを検証するため、15分、30分、1時間、2時間先のセクター需要の予測をそれぞれ行った。予測時間の間隔ごとに各センターのモデルは表5.10のモデル数を採用した。それぞれの条件でセクター需要の予測を行った結果を複数の観点から評価する。需要ベクトルの初期値 $x(0)$ には実測値を用いた。予測に用いる最初の状態遷移行列モデル A_0 は各センターで生成した状態遷移行列モデル群のうち、最もそのモデルに分類された状態遷移行列が多かったものを $k=0$ のときの行列モデルとして採用した。また、各ステップで次のステップに移動してくる航空機の入力 $u(k)$ は、CARATS Open Data から生成したものをを用いて予測を行った。

単一モデルと複数モデルによる予測の比較

1つのモデルのみを用いた予測と、航空状況に合わせて複数のモデルから選択・切り替えをする予測をそれぞれの時間間隔で行い、各センターでの予測精度を評価する。また、予測を行う時間間隔により、精度がどのように変化するかについて考察する。さらに、単一モデルと複数のモデルの予測精度を比較し、モデルの切り替えによる予測手法の有効性について検証する。単一モデルでの予測に用いたモデルは、生成した状態遷移行列のモデル群から最もそのモデルに分類されたものが多かったモデルを採用し、1日分の予測精度を求めた。また、各予測を行い、予測精度を求める際の福岡センターの実測値と予測値の一部を示す。その他のセンターの実測値と予測値は付録に記載する。各ステップでセンター内のそれぞれのセクター需要を予測し、実際の値と比較することで精度を求める。実測値の算出は予測を行う間隔でそれぞれのセクターで存在している機体数（離陸、着陸を含む）を5分ごとに取得し、その平均値を取ることで算出したものをを用いたため、小数点を含んでいる。

表 5.11: セクター需要の予測精度 [%]

	モデル数	15 分	30 分	1 時間	2 時間
福岡	単一	87.2	84.0	79.1	86.9
	複数	95.3	95.1	95.7	97.2
那覇	単一	91.1	86.1	84.9	89.2
	複数	98.4	97.5	96.4	98.6
札幌	単一	63.4	65.2	58.1	72.4
	複数	71.2	70.9	69.5	80.5
東京	単一	83.4	81.2	78.9	82.3
	複数	96.3	95.1	96.1	97.6
ATM	単一	85.3	90.2	81.9	87.6
	複数	97.4	97.6	97.7	98.5

表 5.12: 2015 年 5 月 11 日の福岡センターの実測値と予測したセクター需要

	14:00		18:00	
セクター名	実測値	予測値	実測値	予測値
F01-1	0.13	0.022	2.580	2.809
F01-2	0.018	0.012	0.334	0.241
F02-1	0.400	0.240	4.296	4.210
F02-2	0.035	0.066	1.667	1.498
F02-3	0	0.002	0	0
F02-4	0	0.004	0	0.001
F03-1	0.334	0.154	2.900	3.030
F03-2	0	0	3.900	3.908
F03-3	0	0	0	0
F05-1	0.167	0.079	2.834	2.622
F05-2	0	0	0	0.002
F05-3	0	0.005	0	0.
F06	0.128	0.133	1.112	0.913
F07-1	1.586	1.394	4.807	5.064
F07-2	2.897	3.071	8.333	8.616
F08-1	4.200	4.356	5.930	6.088
F08-2	0	0.003	0	0
F11-1	0	0	0	0
F11-2	5.995	5.695	11.10	11.41
F15	0.280	0.254	4.763	4.893
F16-1	7.600	6.927	1.636	1.719
F16-2	0	0.229	0	0.144
F16-3	0	0.003	0	0.008
F17	9.954	10.07	8.027	8.273




図 5.1: 15 分ごとのセクター需要予測の精度




図 5.2: 30 分ごとのセクター需要予測の精度




図 5.3: 1 時間ごとのセクター需要予測の精度




図 5.4: 2 時間ごとのセクター需要予測の精度

結果より、複数のモデルを用いたモデル切り替えによるセクター需要予測は、単一モデルによる予測より高い予測精度を実現できた。これはクラスタリングにより生成したそれぞれの状態遷移行列モデルが、ある特定の航空状況や時間帯の代表的な特徴のみを表現しており、単一のモデルのみの予測では、全ての航空状況を網羅できないためである。モデルを切り替えた場合では、交通状況ごとに最も有効であろうモデルを選択することで、単一モデルよりも高精度に予測を実現でき、モデル切り替えの有効性があると言える。

表 5.12 より、ステップごとに予測が行えており、セクター需要が高い箇所でも十分な予測が出来ていることがわかる。機体数が少ない、または存在しなかったセクターにおいては、状態遷移行列モデルから最も有望なモデルを選択しても、誤差が生じることがわかる。しかし、機体数が少ない場合のセクター需要予測は実際の制御が難しくなく、大きな影響がないため、問題ないと言える。福岡、那覇、東京、太平洋上の 4 箇所のセンターのすべての時間間隔において、94%以上の予測精度を得ることができた。結果から 4 つのセンター上空のフライトの交通流を表現する状態遷移行列のセンターごとでの特徴を抽出したモデルが生成できたことがわかる。札幌センターでのセクター需要予測の精度は予測する時間間隔に関わらず、平均は 70%～80%となった。

また、予測の時間間隔ごとでは、2 時間ごとに予測を行う精度が全て最も高くなった。これは、2 時間ごとのセクター間の航空機の移動パターンが、状態遷移行列の差として最も表れたことで、クラスタリングによって、より高精度なモデルが生成できたためと考える。次に札幌センターの予測精度の低さと、他センターで予測が上手くできていない箇所について、日付ごとと時間帯ごとの予測精度の分析を行うことで考察する。

センターごとの精度の比較

次に日付ごとのセクター需要の予測精度をまとめたものを元に、2015 年度と 2016 年度の日付ごとのフライトの特徴を分析する。各センターのセクター需要の予測精度を、15 分、30 分、1 時間、2 時間の間隔ごとに示す。




図 5.5: 福岡のセクター需要予測の精度 (2015 年度)




図 5.6: 福岡のセクター需要予測の精度 (2016 年度)




図 5.7: 東京のセクター需要予測の精度 (2015 年度)




図 5.8: 東京のセクター需要予測の精度 (2016 年度)




図 5.9: 那覇のセクター需要予測の精度（2015 年度）






図 5.10: 那覇のセクター需要予測の精度（2016 年度）






図 5.13: ATM のセクター需要予測の精度（2015 年度）




図 5.14: ATM のセクター需要予測の精度（2016 年度）

結果より、すべての時間間隔において、予測精度の良かった福岡、那覇、東京、ATM上の4箇所のセンターでは、特定の日付で精度が低くなっている。また、札幌のセンターの予測精度は時間間隔に関わらず、他のセンターより低い。精度が低くなったことは、ある時間帯の航空交通流の特徴を持つ状態遷移行列モデルが生成されていないためと考えられる。要因の1つとして、時間間隔によって1000~8000個以上生成される状態遷移行列から、10~20前後のモデルに類似度が近いものへと分類するときに、存在するイレギュラーな行列の数が少なかったため、特徴を反映したモデルが生成できなかったことがあげられる。予測結果を日付ごとに見ることで、モデルとして特徴を反映されなかった日付のフライトを分析し、より柔軟なモデルの構築が容易にできると言える。さらに、1時間ごとのセクター需要の予測精度を調べることで、特定の日付の精度の低さと札幌センターの精度の低さの原因について検証する。

1 時間ごとのセクター需要の予測精度

1時間ごとのセクター需要の予測の精度の平均の推移を示し、どの時間帯で予測が上手くできていないかについて考察する。以下に時間帯ごとの予測精度を示す。図5.15は1時間ごとに予測を用いたものを利用した。




図 5.15: 1 時間ごとの予測精度

時間帯ごとの予測精度は早朝、深夜の時間帯において低くなっている。札幌以外のセンターで精度の低い特定の日付について予測精度を確認すると、全体のグラフに表れているように、深夜、早朝の時間帯において全て精度低くなっていた。これはこの時間帯の外れ値のようなモデルが生成できていなかったためと考えられ、航空交通量が少ない時間帯において多く見られる。

また、札幌センターにおいても同様で、航空交通量の少ない時間帯において、精度が低くなっていることがわかる。これは北海道上空のセクターでは航空交通量が少ないことに加え、セクターに存在する機体数に差が生じず、センター内の隣接するセクターそれぞれ

が大きいことから状態遷移行列に大きな違いが生じず、代表行列のモデルとして、うまく表現できなかったと考えられる。しかしながら、早朝、深夜の精度が低くはなったが、実際の運用で予測が重要となる時間帯では、高い予測精度を持つモデルが生成できたと言える。

結果より、混雑度の予測が重要となる日中の時間帯において、有効な状態遷移行列モデルを生成し、適切なモデル選択を行う実際の航空交流の制御において、管制官の意思決定に役立てる十分有効な予測モデルを生成できた。

第6章 おわりに

本研究では、実際の航空交通データである CARATS Open Data を用いて、日本上空のセンターの航空交通流の特徴を分析し、センター内の各セクター需要を予測するモデルの提案を試みた。

はじめに、過去のフライトデータから航空機のセクター間の遷移を表現した状態遷移行列を生成し、航空交通流のモデルをクラスタリングによって構築した。さらに、これらの複数のモデル群を用いて、各時点の航空交通の状況から適切なモデルの選択・切り替えをすることでセクター需要を予測するモデルを開発した。セクター需要の予測は15分、30分、1時間、2時間の時間間隔で日本上空の5箇所のセンターでそれぞれ行った。各パターンで状態遷移行列の代表モデルの構築と、適切なモデル数の検証をシミュレーションと比較実験により行った。分類された結果から状態遷移行列は月や季節に大きな影響はされず、運航本数が多い時間帯とそうでない時間帯で大きく分類されることが分かった。最終的なモデルを用いた混雑度予測は、はじめにモデル切り替えの有効性について評価するため、単一モデルでのセクター需要予測と精度を比較し、複数のモデル切り替えによる予測の有効性を確認した。さらに、複数のモデルを用いた予測では、航空交通流の制御で最も必要とされる運航便数の多い時間帯において高精度な予測を実現した。札幌のセンターでの予測は早朝と深夜の時間帯で精度が低くなった。運航便数が少ないセクター、時間帯の観点から、状態遷移行列にフライトの特性が大きく現れない場合は、特徴をとらえたモデルを形成することが難しく、本手法は有効ではないと言える。しかし、航空交通量が少ない時間帯やセンター内のセクターが少なく、1つのセクターが大きな箇所では、管制官の航空交通の制御・予測の負担も大きくないため、制御において問題がないと考える。

過去の航空交通流を状態遷移行列として表現し、複数のモデルを構築後、最適なモデルの選択・切り替えによるセクター需要の予測が、十分な精度を持つことを示すことができた。モデルの選択・切り替えにかかる時間は少なく、実際の運用中に各セクターの機体数と次のステップにセクター間を遷移する機体数の取得は問題なく行える。したがって、リアルタイムでの運用も問題ないと考える。しかし、5つのセンターで、複数の時間間隔のモデルをそれぞれ構築したため、特定の時間帯やケースにおいて存在する、全てのイレギュラーな交通パターンを網羅するモデルの構築と実験までには至らなかった。また、先行研究では複数のモデルを季節や天候の状況を用いて構築していたが、本研究の状態遷移行列を用いたクラスタリングには、それらの特性が分類結果に大きく表れなかった。

本手法の過去のフライトデータから特徴を分析したものをモデル化し、その時点の航空交通流から用意したモデルを切り替えることでセクター需要を予測する有用性を示すことはできた。したがって、追加で公開される航跡データを加え、新たにモデルの改良を行うことでさらに柔軟な混雑度予測を可能とし、管制官の意思決定に役立てることができると考える。

今後の課題

国土交通省は CARATS Open Data を公開してから毎年データを追加している。本研究では、2 年度分のデータを用いてモデルの構築を行ったため、さらにデータを追加して状態遷移行列の代表モデル自体を再構築・追加をすることでより高精度な予測が可能になると考える。また、本研究では状態遷移行列のみでモデル生成を行い、良い精度でセクター需要の予測を行うことができたが、LDSM モデルは気候や季節を付与して複数のモデルを構築することも可能なため、航空需要密度の高いセンターのモデルの改良に効果があると考ええる。

謝辞

本論文の作成にあたり，主指導教員である平石邦彦教授には貴重な時間を割いていただき，丁寧な御指導と厚いご助言を賜りました．この場を借りまして心よりの感謝を申し上げます．大変ありがとうございました．また，インターン指導教員としてご指導いただきました鈴木正人准教授，審査委員として貴重なご意見をいただきました緒方和博教授，浅野文彦准教授の各先生方にも改めて感謝の意を表します．

研究業績

1. 三島 諒亮, 平石邦彦”航空オープンデータを用いたセクター間交通流のモデル化と混雑度予測”, システム数理と応用研究会 (MSS), 2021 年 3 月 16 日 (発表予定)

参考文献

- [1] Recent Models in the Analysis of Air Traffic Flow, Claus Gwiggner, Sakae Nakaoka, Electronic Navigation Research Institute
- [2] Banavar Sridhar, Neil Chen, Santa Cruz, Hok Ng, Santa Cruz, An Aggregate Sector Flow Model for Air Traffic Demand Forecasting, 9th ATIO, 2009
- [3] Flightradar24 <https://www.flightradar24.com/>
- [4] AIS JAPAN, Japan Aeronautical Information Service Center, <https://aisjapan.mlit.go.jp/>
- [5] 徳丸翔也, 平石邦彦, CARATS Open Data における航空機位置のセクター決定問題について, システム数理と応用研究会 (MSS) , pp.47-51 (2018-03-12)
- [6] Sridhar, B., Soni, T., Sheth, K., and Chatterji, G. B.,
- [7] Tokumaru, S., & Hiraishi, K. (2019). Sector Identification for a Large Amount of Airspace Traffic Data. IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences, 102(5), 755-756.
- [8] Menon, P.K., Sweriduk, G.D. and Bilimoria, K.D., 2004. New approach for modeling, analysis, and control of air traffic flow. Journal of guidance, control, and dynamics, 27(5), pp.737-744.
- [9] An Aggregate Flow Model for Air Traffic Management, AIAA Guidance, Navigation and Control Conference, Providence, RI, August 2004.
- [10] A New Model to Improve Aggregate Air Traffic Demand Predictions , ” AIAA Guidance, Navigation and Control Conference, Hilton Head, SC, August 2007.
- [11] 平田輝満, 米国における航空交通流管理の現状 – Ground Delay Program に焦点をあてて –, 第 42 回土木計画学研究発表会・講演集, 2010.
- [12] Quang Khai TRAN, Kunihiro HIRAISHI, An Improved Version of Cell-Transmission Model for Air Traffic Flow, TISDIC 2019, ISBN
- [13] 国土交通省, <http://www.mlit.go.jp> (2021/02/03)
- [14] Craig Wanke, Lixia Song, Stephen Zobell, Daniel Greenbaum, and Sandeep Mulgund, Probabilistic Congestion Management, The MITRE Corporation

- [15] James S. DeArmon, Craig R. Wanke, Daniel P. Greenbaum, Lixia Song, Sandeep Mulgund, Steve Zobell, Neera Sood, Solving Probabilistic Airspace Congestion: Preliminary Benefits Analysis, 6th ATIO, 2007

使用データ：国土交通省 CARATAS Open Data

付録

2015 年 5 月 11 日の 14:00 と 20:00 のセンターの各セクターのセクター需要ベクトルの実際の値と予測値を以下に示す.

表 6.1: 那覇センターの実測値と予測したセクター需要

セクター名	14:00		20:00	
	実測値	予測値	実測値	予測値
N01-1	20.480	21.141	15.522	15.93
N01-2	0	0	0	0
N02-1	12.803	12.480	9.0	8.842
N02-2	0	0	0	0
N16	8.021	7.212	4.5	4.283

表 6.2: 札幌センターの実測値と予測したセクター需要

セクター名	14:00		20:00	
	実測値	予測値	実測値	予測値
S01	6.25	6.463	0	0
S02	9.399	8.698	6.6	8.821
S03-1	6.7	5.707	5.125	5.923
S03-2	0	0.541	0	0
S04-1	0.167	0.745	0.667	1.96
S04-2	0	0	0	0
S31	1.333	0.146	1.0	1.0
S34	0	0	0	0

表 6.3: ATM センターの実測値と予測したセクター需要

セクター名	14:00		20:00	
	実測値	予測値	実測値	予測値
A01	23.610	22.806	4.334	5.101
A02	8.250	7.780	5.400	6.631
A03	5.150	5.061	2.582	3.239
A04	10.245	9.094	5.846	6.381
A05	4.900	4.282	2.030	2.271

表 6.4: 東京センターの実測値と予測したセクター需要

セクター名	14:00		20:00	
	実測値	予測値	実測値	予測値
T01	0.992	0.006	5.273	6.301
T02	4.167	3.542	12.39	12.62
T03-1	6.0	6.550	11.0	10.207
T03-2	7.12	9.391	0	0
T04-1	0	0	8.25	10.39
T04-2	6.2	6.269	0	0.012
T04-3	0	0	0	0.039
T05	0	0	0	0
T06	0	0	1.0	0.873
T07-1	6.0	5.259	1.0	0.547
T07-2	2.0	1.799	0	0
T09-1	0	0	4.0	4.226
T09-2	6.0	5.969	0	0
T09-3	0	0	1.0	0.163
T10-1	1.0	0.201	8.0	7.962
T10-2	11.0	10.567	0	0
T11	0	0	12.1	11.868
T12-1	8.334	8.611	20.0	20.708
T12-2	19.0	19.005	0	0
T12-3	0	0	0	0
T13	1.0	0.007	0	0
T14	0	0	1.0	1.326
T15	1.0	0.743	0	0.12
T17	1.0	0.683	14.0	14.277
T21-1	5.5	5.658	3.273	2.857

セクター名	14:00		20:00	
	実測値	予測値	実測値	予測値
T21-2	4.5	4.728	0	0
T22-1	0	0	2.85	3.334
T22-2	5.818	6.267	0	0
T23-1	0	0	2.286	1.985
T23-2	6.571	6.586	0	0
T24-1	0	0	13.166	14.879
T24-2	10.3	9.803	0	0
T26-1	0	0	6.125	6.440
T26-2	9.091	8.973	0	0.002
T26-3	0	0	0	0
T26-4	0	0	1.0	0.302
T27-1	0	0	3.0	4.098
T27-2	7.6	7.889	0	0
T28	0	0	6.0	5.1828