

施策検討での活用事例②

CARATS Open Dataを用いた 機械学習による軌道予測

国立研究開発法人 海上・港湾・航空技術研究所
電子航法研究所

岡 恵



本日の発表

背景

分析方法

分析結果

予測誤差の比較

誤差要因の考察

改善した便の特徴

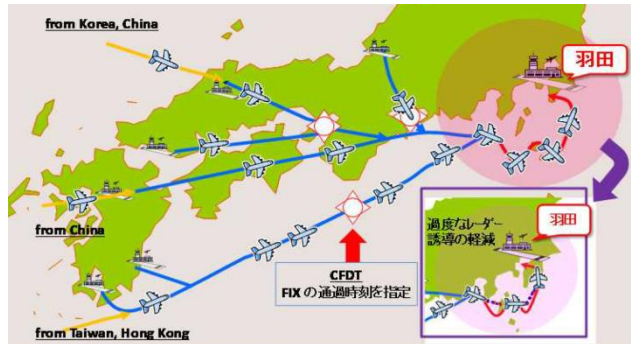
入力の重要度解析

季節による改善量の比較

まとめ

背景

- 軌道ベース運用の導入、初期的CFDTによる時間管理



CFDT: Calculated Fix Departure Time

飛行中の航空機に経路上の特定地点における通過時刻を指定することにより、目的空港近傍等の特定の空域における航空機の集中を緩和する交通流制御手法

航空交通流時間管理検討WG 設置

- 人工知能(機械学習)技術の発展
 - ✓ 出発から、空港周辺の順序・間隔付けが行われる空域に入るまでの飛行時間を**精度良く予測**できれば、**効率の良い運用**が可能になる
 - ✓ 機械学習で予測精度の向上の可能性

実施内容

羽田空港 南西方面 到着機 を対象

出発から空港周辺空域に入るまでの飛行時間を予測

実運用データを教師データとする機械学習

➡ 予測精度の向上を図る



分析方法

学習データの作成

使用したデータ

CARATS Open Data 2012


出発・到着空港、
巡航高度を推定

BADA

(Base of Aircraft Data)

航空機の軌道予測

ニューラルネットワークの
設定



機械学習のモデル

ニューラルネットワーク

隠れ層: 1層

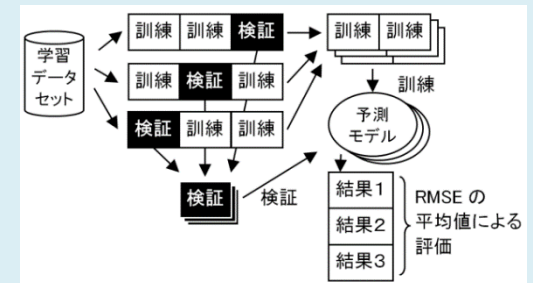
重みの更新: 正則化項を入れた
逆誤差伝搬法

隠れ層のノード数: 17個

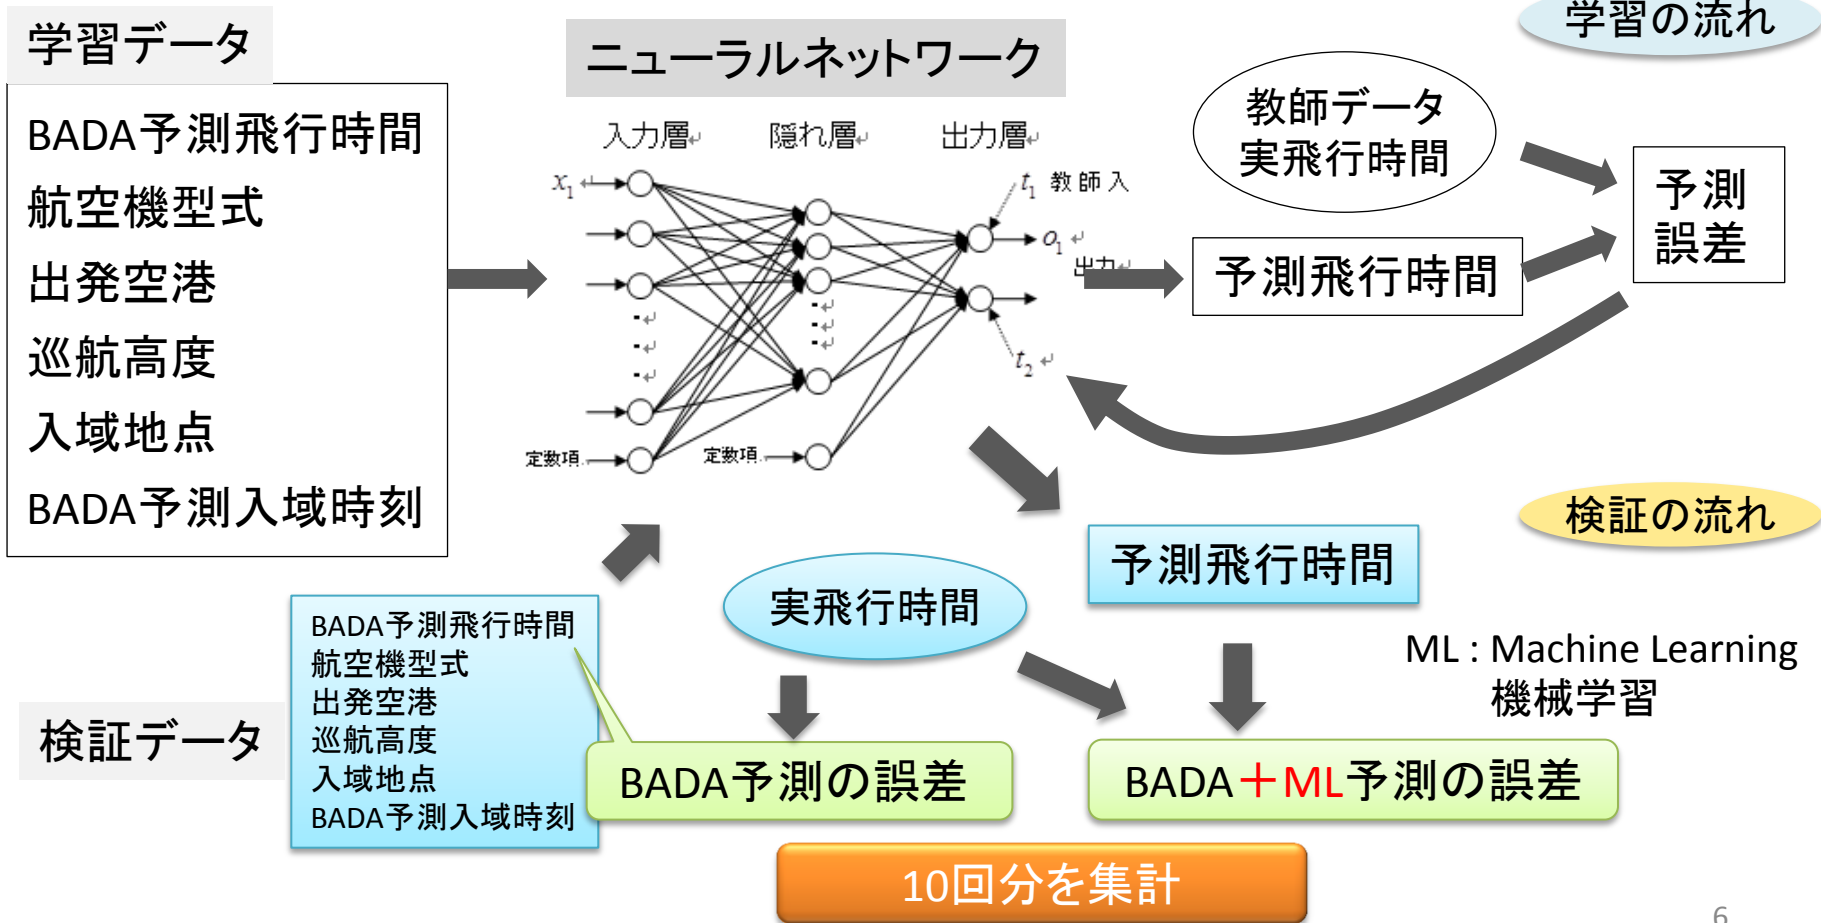
検証データによる
性能評価

航跡から算出した飛行時間
→ 真値

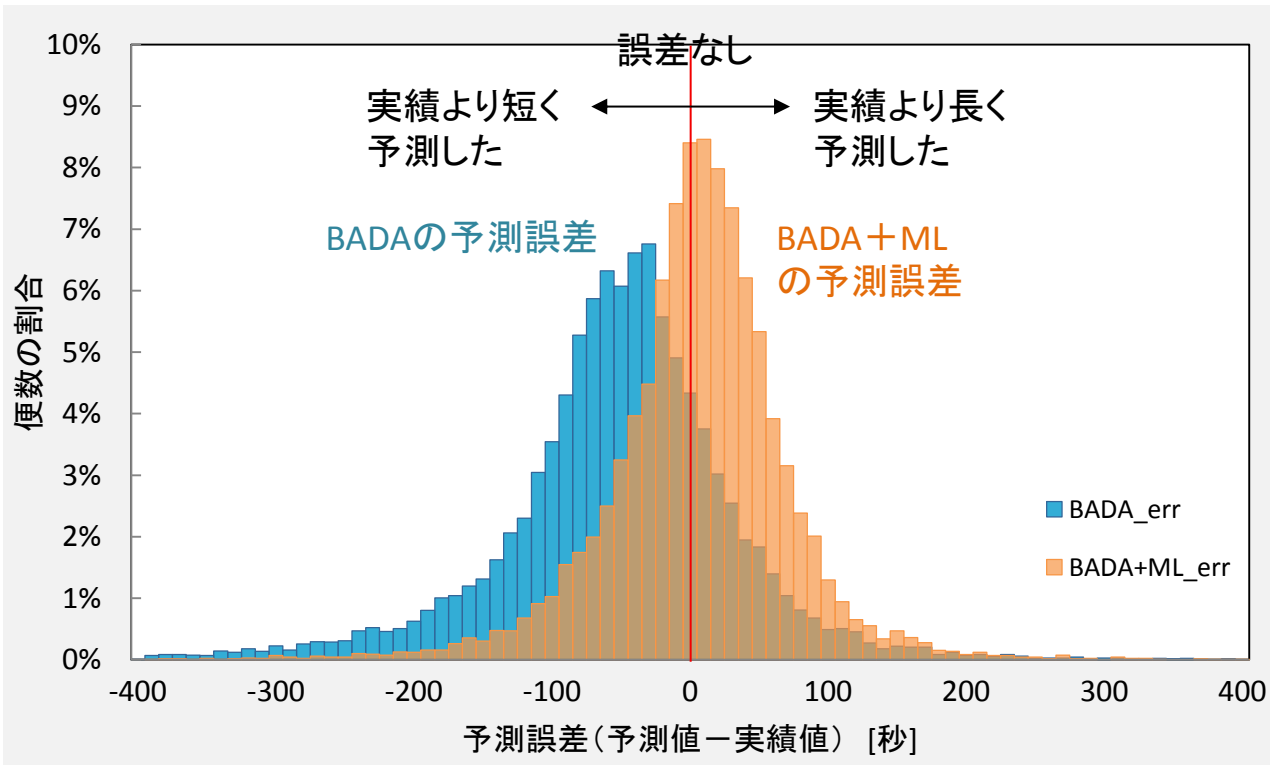
データを10分割して交差検証



学習と検証の流れ



予測誤差の分布



BADAの予測と
BADA+ML予測の
誤差分布

二乗平均平方根誤差
(RMSE)が約2/3に改善

バイアス誤差(ME)がほ
ぼ0に改善

平均絶対誤差(MAE)が
約32秒改善

標準偏差が約22秒改善

予測方法	RMSE	ME	MAE	標準偏差
BADA予測	106.9	-57.0	79.1	90.4
BADA+ML予測	68.1	0.23	47.4	68.1

RMSE: Root Mean Squared Error

$$\sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}$$

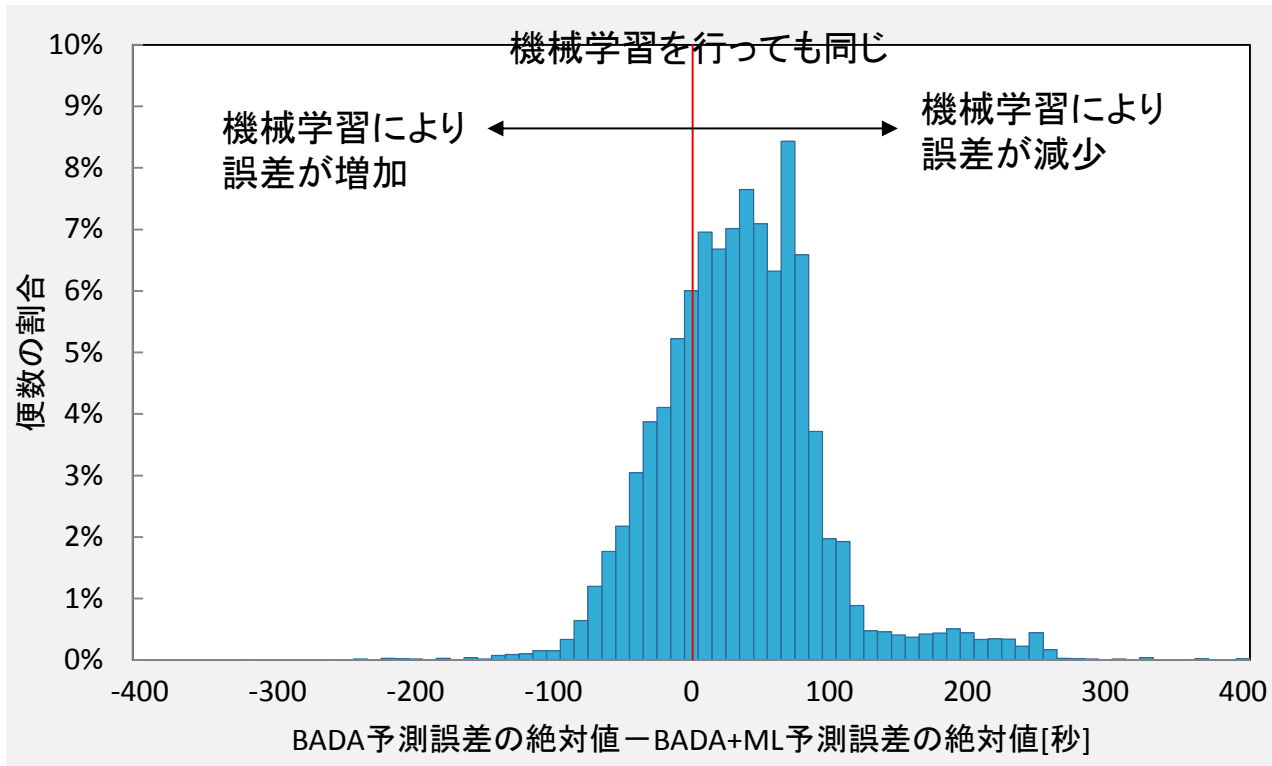
ME: Mean Error

$$\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)$$

MAE: Mean Absolute Error

$$\frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|$$

誤差変化量の分布



誤差が増加した便もあるか？
誤差変化量の分布は？

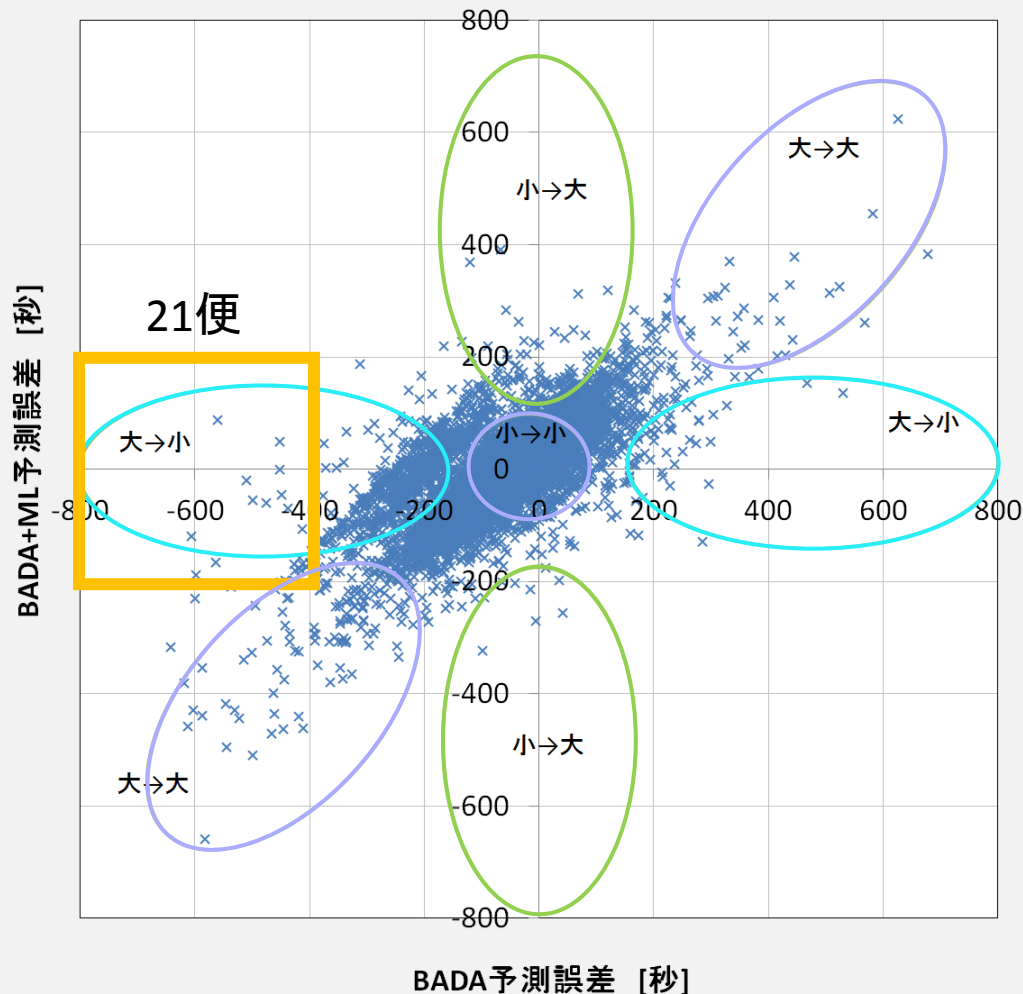
誤差が増加した便もあった
0秒から100秒まで
線形的に減少
→ 変化量は小さい便が多い

誤差が減少した便は0秒から
80秒まで約7%
それ以上は少なくなるが
250秒程度まで約0.5%あった

変化量の平均値は誤差が
減少した便の方が大きかった

誤差の変化量	便数の割合	変化量の平均値
減少	70.9%	58.9
増加	29.1%	34.3

誤差改善の傾向



誤差が増加/減少した便の
元々のBADA予測誤差は？

BADA	BADA+ML	変化	エリア
小	小	なし	紫色
	大	増加	緑色
大	小	減少	水色
	大	なし	紫色




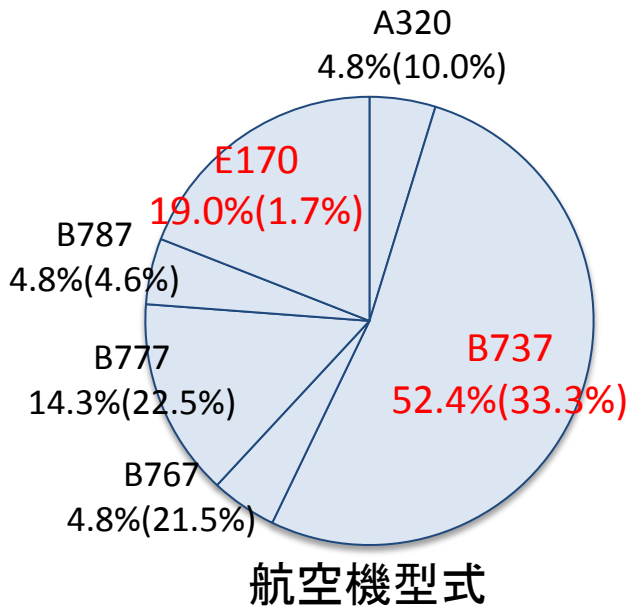
誤差が増加した便 少数
最大誤差増加量 325秒

誤差が減少した便
最大誤差減少量 489秒
大きく誤差が減少した便は
BADA予測誤差が負の値の部分に
多かった

改善した便の特徴

誤差が大きく改善された便は、どのような特徴があるか？

X%(Y%)
 X%・・・大きく改善した便に占める割合
 Y%・・・元のデータに占める割合



航空機型式・・・B737,E170
 出発空港・・・神戸、南紀白浜
 入域地点・・・1
 が多く含まれていた

出発空港では比較的短距離である関西・四国エリアの出発便が2/3を占めた

日付、巡航高度は顕著な傾向は見られなかった

入域地点

ま と め

羽田空港 南西方面 到着機を対象に、出発から空港周辺空域に入域するまでの飛行時間を予測する機械学習のモデルの構築を行った。

予測結果はバイアス誤差がほぼ0となり、誤差のばらつきであるRMSEが大きく改善した。

今後はデータ量を増やして更なる精度の改善を行う。また、予測精度の改善が航空交通流管理に与える影響の評価を行う。