

法人向け仕出し弁当の需要予測

～食品ロスの削減を目指して～

神奈川大学 工学部 経営工学科 経営システム工学研究室

出水 継 孫 一軒 北林 幸樹 岩田 康典 太田 和希

指導教員 片桐 英樹

食品製造業の現状と課題

近年、食品製造業の**生産性の低さ**が問題視^[1]されている

コンビニの普及,女性の社会進出,単身者・高齢者の増加が進む現代社会では,

食品製造業の中でも総菜や**弁当**を含む**中食産業**の市場が拡大^[2]した

～課題～

- ・中食産業を含む食品製造業の**食品ロスの量**は**126万**トン^[3]と食品を扱う業種の中で最も多いこと
- ・少子高齢化による**労働力人口の減少**, **技術継承**が**困難**であること



食品ロスの削減と**業務の自動化**の両方が求められている

食品製造業における法人向け仕出し弁当の需要予測と課題

仕出し弁当会社では、予測担当者の**経験**と**勘**による**需要予測**が行われている

- 高精度な予測は難しく、**発注・製造ロス**につながる
- 熟練者の**勘**と**経験**に**依存**しており、新人への**引継ぎ**が**困難**である

受注プロセス

- 顧客は、1企業や1組織の従業員や職員など
- 売上日当日の朝に電話やFAXなどで受注する

弁当製造会社

売上当日
電話・FAXなど



弁当の製造



昼頃までに配送

顧客



課題

見込み生産をしており、**需要予測の精度**が**食品ロス**に大きく影響する
マニュアルが存在しないため、**技術継承**が**困難**である

高精度な自動需要予測モデルが求められている

本研究における有意性

本研究では、**実データ**を用いて、
高精度な自動需要予測モデルを構築する

現状 需要予測の技術継承が困難であるのと同様に、
高精度な自動需要予測モデルを構築することも**困難**である









現場へのヒアリング、月に1度ある**打ち合わせ**により、
予測担当者の**予測方法**や**知見**、これまで**見えなかった特徴**を
明らかにし、考慮することが高精度な自動予測モデルを構築する
「**カギ**」となる

実データを用いた高精度な自動需要予測モデルの構築が可能であれば、
データを使用した企業だけでなく、**類似している企業**（競合他社）
にも応用することで、**食品製造業全体**の**生産性**を**向上**させる**可能性**
を秘めている

使用するデータの提供企業とその概要



本研究では法人向け仕出し弁当会社であるA社を対象とする

- ・ A社では、毎日約**13,000食**の仕出し弁当を製造
- ・ 毎日、**日替・丼・麺**の3種類の弁当を販売
- ・ 麺弁当は時期によって**冷麺**と**温麺**を販売
(**冷麺**提供期間：4月～10月頃、**温麺**提供期間：11月～3月頃)

売上日	日替	丼	麺
4/1	日替A 	丼B 	冷麺C 
...
11/1	日替D 	丼E 	温麺F 

法人向け仕出し弁当A社の商品の提供について

- ・ 日替弁当は日によって変わり，**周期がない**
- ・ 丼・麺弁当は**2週間周期**で同じ商品を提供

売上日	日替	丼	麺
4/1	日替A 	B丼 	C麺 
4/7	日替D 	E丼 	F麺 
4/15	日替G 	B丼 	C麺 
⋮	⋮	⋮	⋮
4/29	日替H 	B丼 	C麺 
⋮	⋮	⋮	⋮
5/13	日替I 	B丼 	C麺 

2週間周期

先行研究

弁当の需要予測に関する先行研究

太田の研究^[4]

- ・ 法人向け仕出し弁当会社であるA社の需要変動の要因分析の実施
- ・ 商品の人気と外部環境を考慮した状態空間モデルを用いて仕出し弁当の各商品の需要を予測

気象条件の重要性に関する先行研究

Tianらの研究^[5]

- ・ 気象条件が消費者の購入の多様性に与える影響を分析
- ・ 気温の変化が人の感情に影響を与えることで、人の購入行動にも影響を与えることを示した

気温を需要予測に考慮することが重要

弁当の需要が変動する要因







気温（外的要因）の影響

麺弁当の需要は気温に依存

例) 気温が20℃から30℃へ上昇

⇒ 冷麺の需要が高まる

⇒ 日替・丼の出数割合が下がる

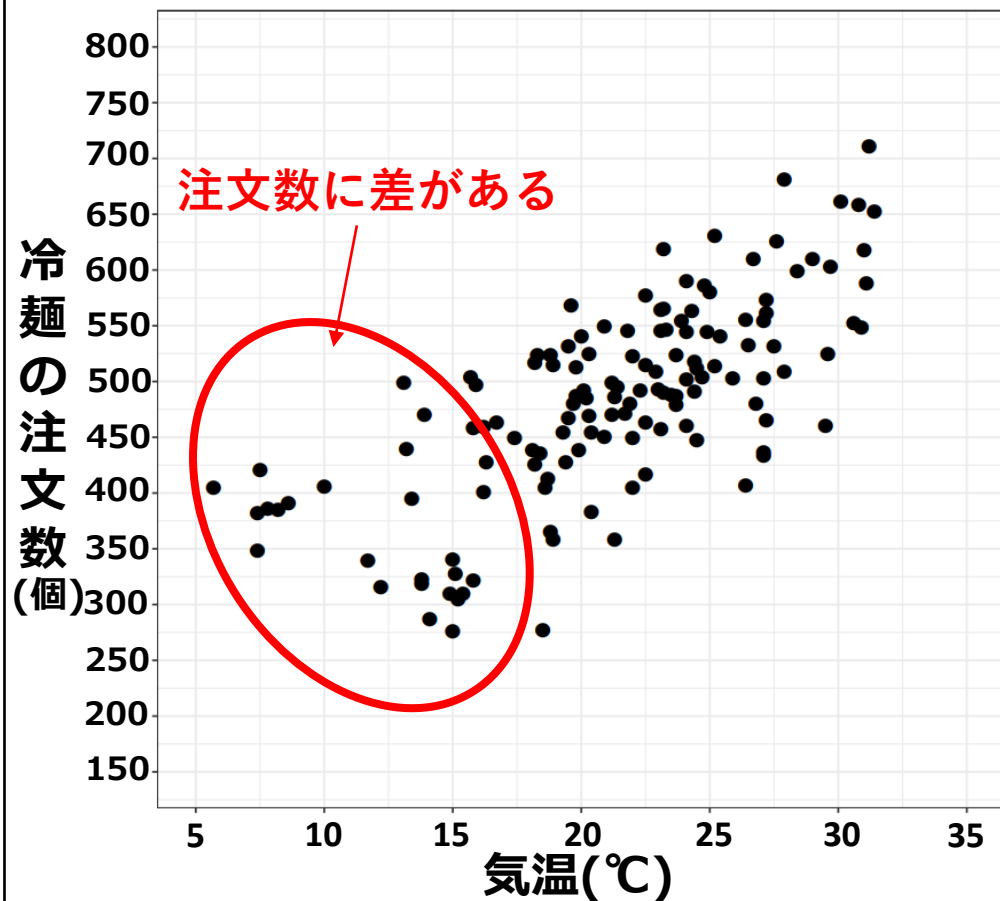
売上日	日替	丼	麺
8/1 20℃	日替A  70%	丼B  20%	冷麺C  10%
	↓ 10% ↓	↓ 10% ↓	↓ 20% ↑
8/2 30℃	日替D  60%	丼E  10%	冷麺F  30%

先行研究^[4]における課題とそこから生じた仮説

課題

気温が冷麺の需要変動に及ぼす影響の強さを全期間で一定にしている

2019年度における気温と注文数の関係



注文数に差がある気温帯(5~15°C)が存在する

考察

季節の変わり目で見られる温度であり、先入観(これから暑くなる, 寒くなる)で人間の気温の感じ方が変化

仮説

気温から受ける影響は一定ではなく、時期によって変化する

研究目的

本研究では以下の2点を目的とする

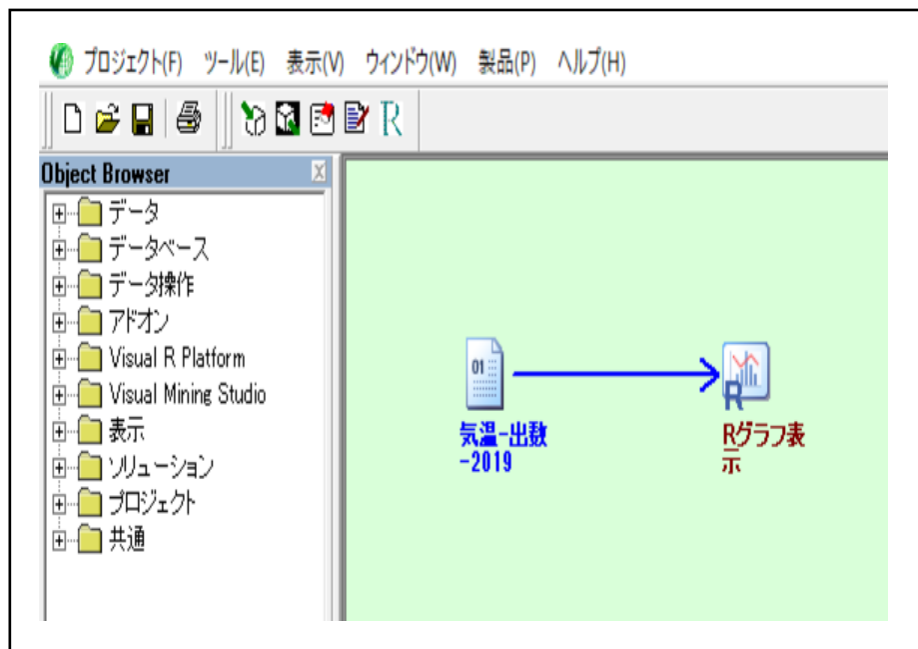
1. 時期によって変化する
**気温から受ける冷麺の注文数への影響を
明らかにする**
2. 時期によって変化する気温の影響を考慮した
冷麺の需要予測モデルを構築する

使用ソフト

Visual R Platform

(NTTデータ数理システム社製)

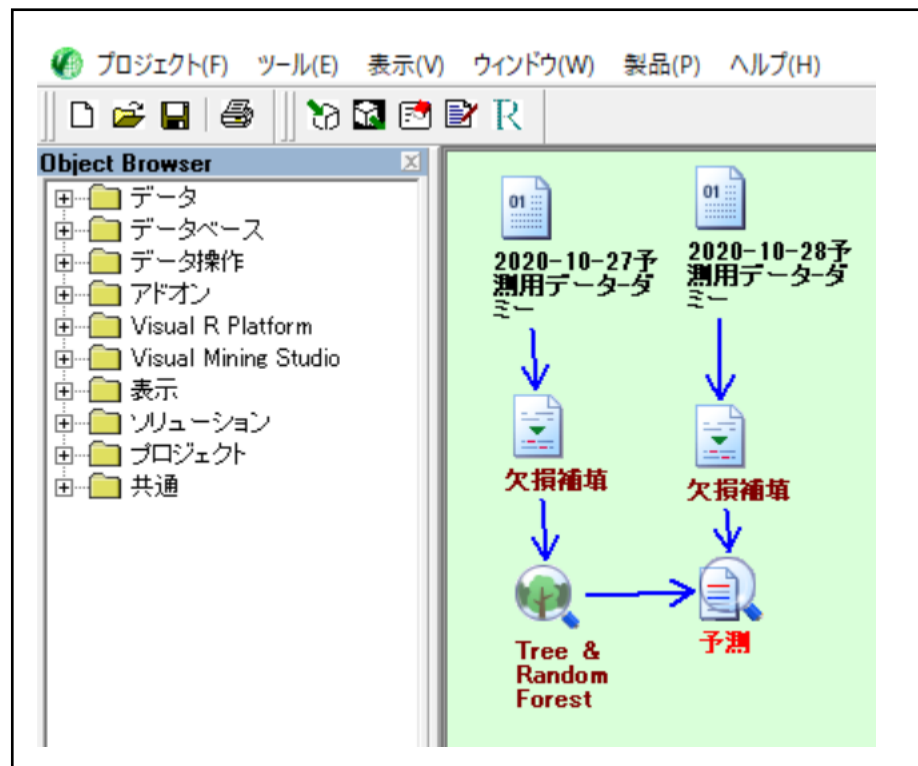
→分析・精度評価の際に、
グラフ作成を目的に使用



Visual Mining Studio

(NTTデータ数理システム社製)

→**需要予測**を目的に使用




研究内容

本研究では、以下の3点を行う

1. **気温と冷麺の注文数の関係**を分析し、**新たな特徴量**を提案
2. 提案した特徴量の効果を**Tree & Random Forest** (以下, TRF)と**Neural Network**(以下, NN)を用いて**検証**
3. 精度の良いモデルと勾配ブースティング決定木(以下, GBDT)で**精度を比較**
モデルの有用性を考察

気温から受ける影響の考察

2019年度における気温と注文数の関係



冷麺の注文数と気温は
比例関係にあるため、
気温帯が同じであれば、注文数は
同じになるはずである
しかし、
同じ気温帯 (例:5~15°C) で
注文数に差がある箇所が
存在する



時期によって、人間の気温の
感じ方が変化し、**気温の
影響度合い**が変化する


時期による気温の影響の違い（昇温期・降温期）

人間の温度の感じ方は2つの期間に分類できる

- (1) **昇温期**：春から夏にかけて
気温が上がる期間
(4月～8月)
- (2) **降温期**：夏から秋にかけて
気温が下がる期間
(8月～10月)

それぞれの期間で回帰直線を引くと傾きが異なる

昇温期：9.8 **降温期**：16.5



※赤線と青線はそれぞれの時期の回帰直線を表す

➡ 2つの期間で冷麺の注文数が気温から受ける影響度が異なる

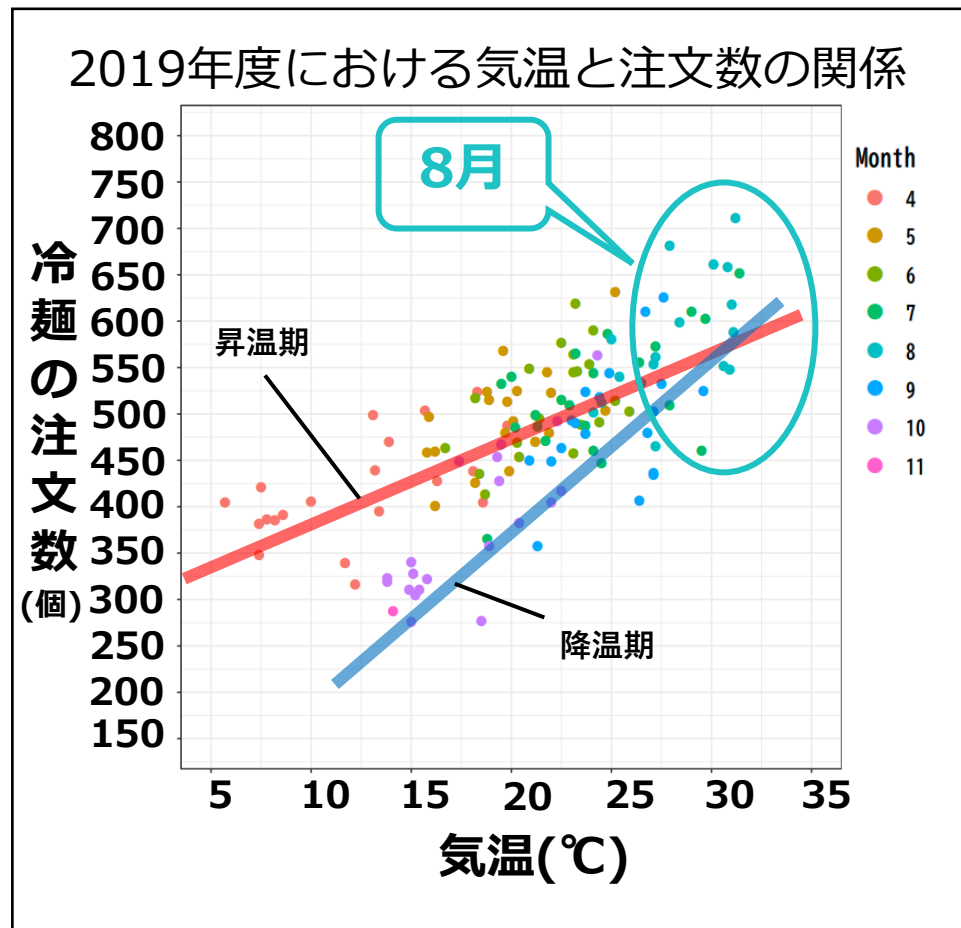
昇温期と降温期の境界の探索

8月は気温の変動が小さいが、冷麺の注文数にばらつきがある

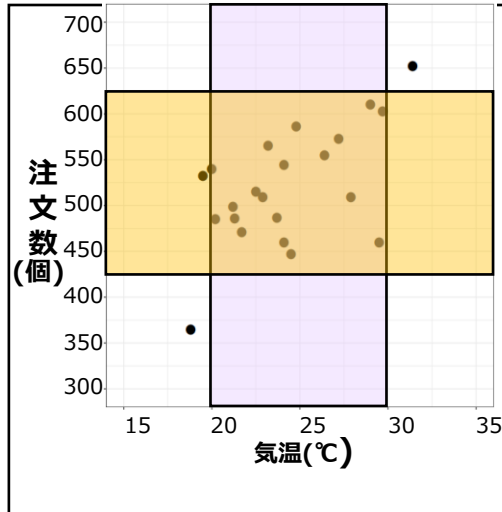
8月は気温が高い日が続き、暑さに慣れることで、気温と注文数の相関関係が弱まる



8月が昇温期と降温期を分ける境界になっている可能性がある

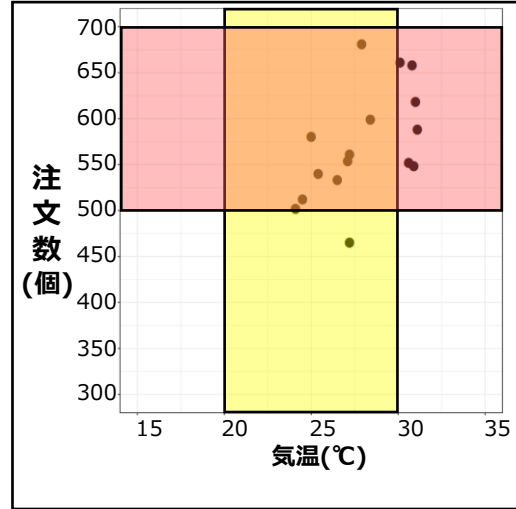


8月前後での気温帯と注文数の関係の違い



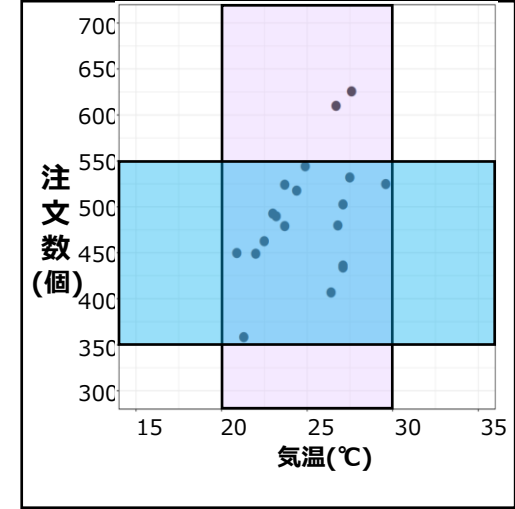
気温帯 : 20~30°C

7月



気温帯 : 23~33°C

8月 ↗



気温帯 : 20~30°C

9月 ↘

9月になると同じ気温帯でも注文数が変化している

→ **昇温期**から**降温期**に移り変わる

気温から受ける影響度に対応させた特徴量を
降温期である**9月**と**10月**に取り入れる必要がある

ここまでの分析のまとめ


分析結果より、

- ・ 冷麺の注文数が**気温に依存する**ことを再確認できた
- ・ 同じ気温帯でも**昇温期**か**降温期**かによって、
注文数が異なることが分かった

→ 9月で降温期に変わり気温と注文数の関係が
大きく変化する

気温から受ける影響度合いに対応させた**特徴量**を
降温期である9月と10月に**取り入れる必要がある**

昇温期と降温期の予測への影響



昇温期と降温期で
気温から受ける影響が異なる



降温期の予測を行うのに
昇温期の学習をそのまま
使用しては降温期の注文
数を高い精度でとらえる
ことができない




昇温期と降温期で
違いを考慮する必要がある

提案する特徴量

気温から受ける影響度合いが異なる
9月と10月に特徴量を加えるために
ダミー変数を与える

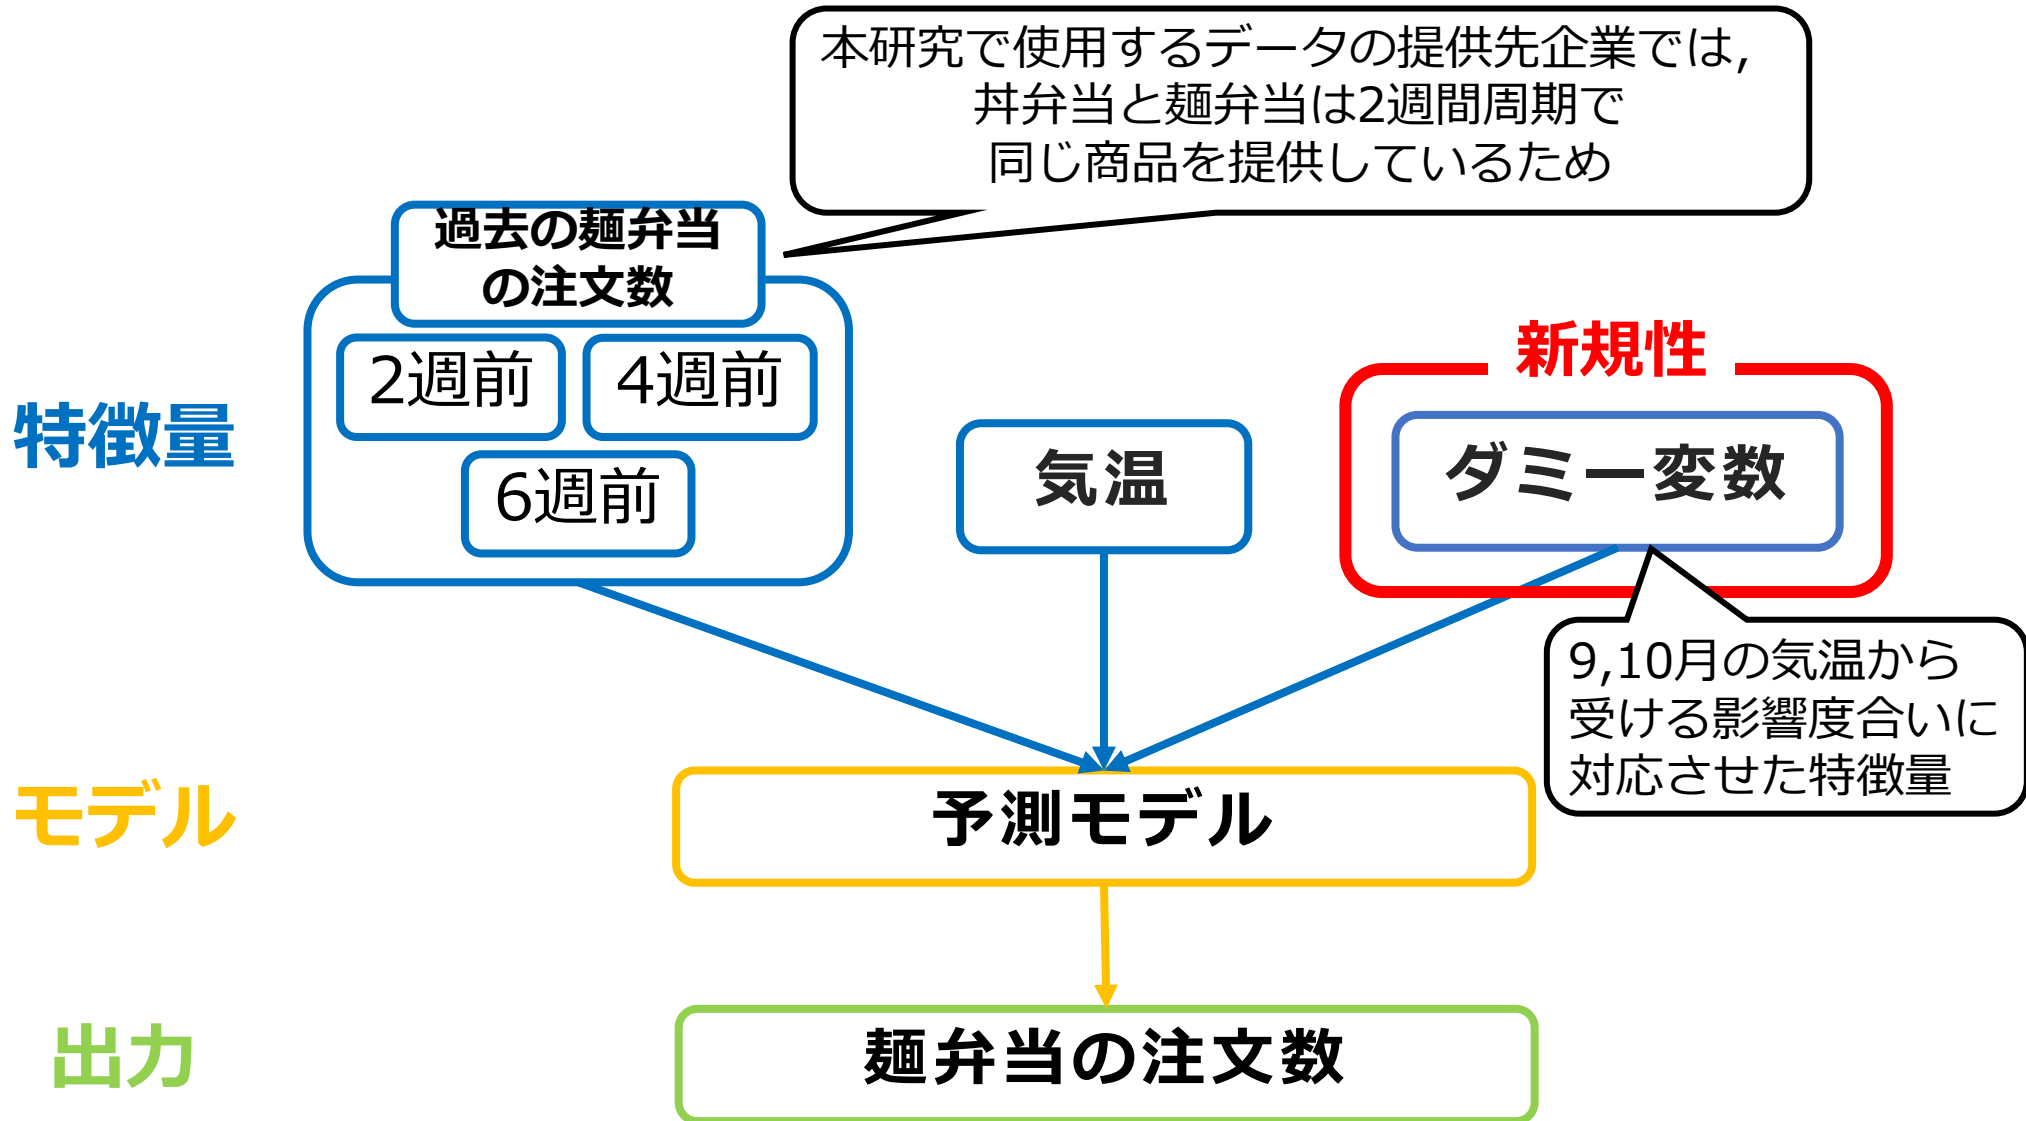


ダミー変数として**9月**と**10月**に**1**を,
それ以外の月には**0**を与える



月	4	5	6	7	8	9	10
ダミー変数	0	0	0	0	0	1	1

予測モデルの構築



使用モデルと検証方法及び学習・予測期間

《検証方法》

提案した特徴量を使用した場合と使用していない場合で精度を比較
提案モデルで精度の良かったモデルとGBDTで精度を比較

《使用モデル》

提案モデルでは、(1)Tree & Random Forest, (2)Neural Networkを採用
比較モデル^[4]として、GBDTを採用

比較モデルではすでに予測誤差が**3%弱**と**非常に高い精度を誇る**

《予測・学習期間》

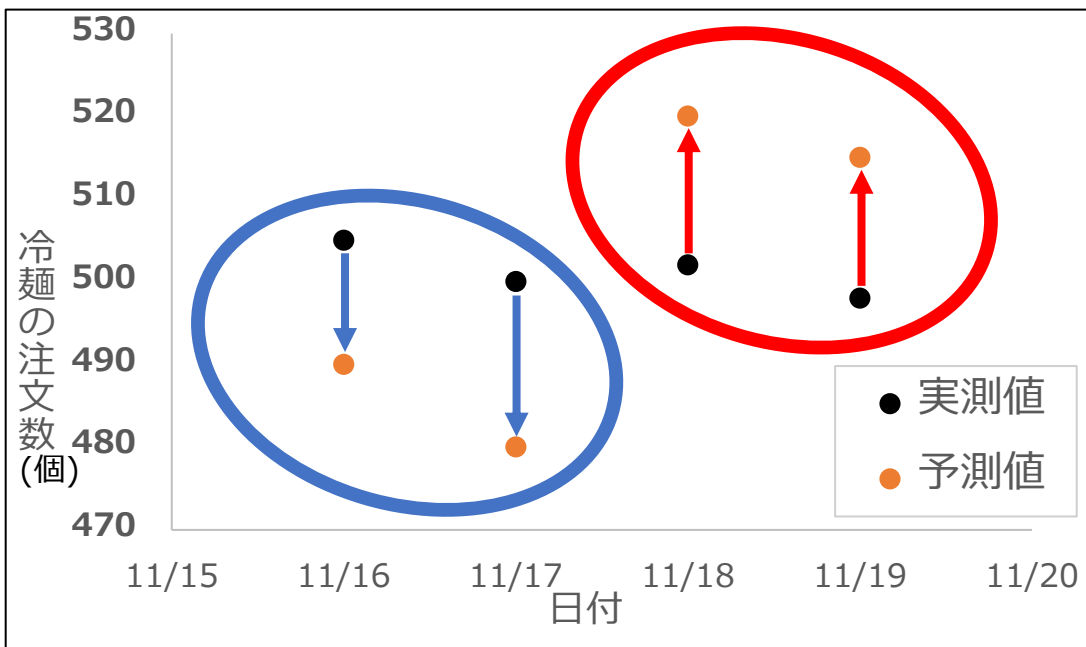
予測年度	学習期間
2018年度	2016年4月～2018年3月
2019年度	2017年4月～2019年3月
2020年度	2018年4月～2020年3月

評価指標

予測値が実測値を**上回ったとき**のME(Mean Error: 平均誤差) と
予測値が実測値を**下回ったとき**のMEを用いて、
提案モデルの精度評価を行う

$$ME = \frac{1}{n} \sum_{i=1}^n (f_i - y_i)$$

n : 全データ数
 f_i : i 番目の予測値
 y_i : i 番目の実測値



↑上に予測した予測誤差(ME+)

↓下に予測した予測誤差(ME-)

食料品製造業の予測精度評価

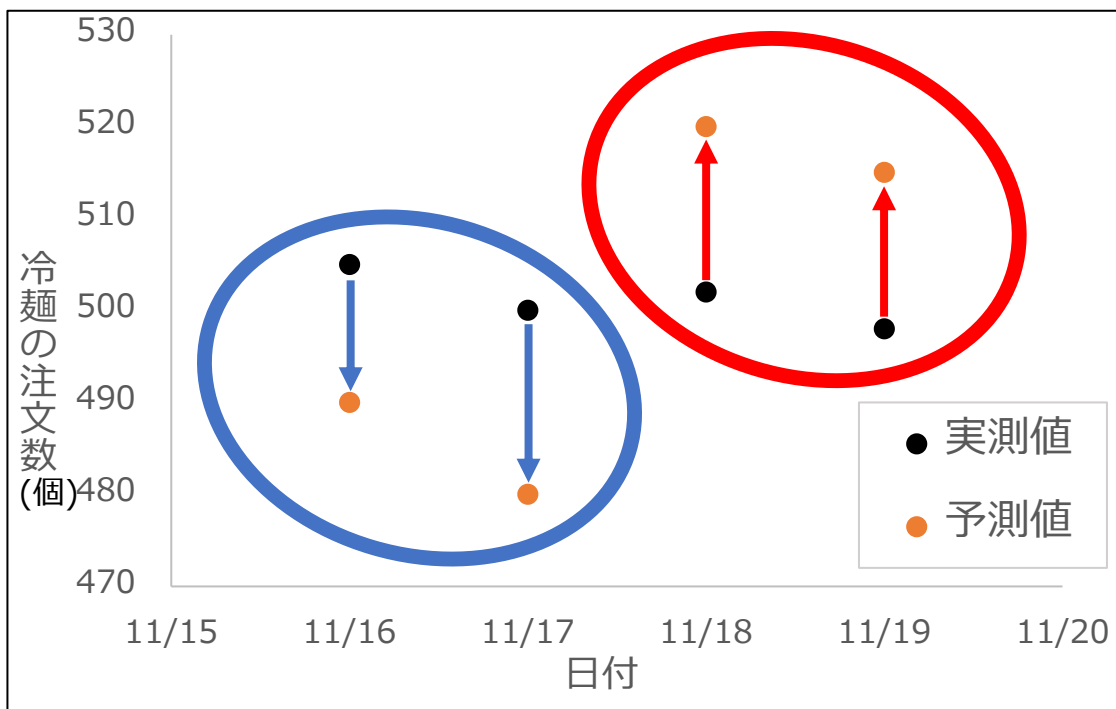
実測値よりも上に予測することと下に予測することでは意味が異なる

需要予測を行う際に、

上に予測した場合は、食品ロスの発生により**廃棄につながる**

下に予測した場合は、追加生産で補うことが可能である

→ **上**に予測した平均誤差を重視する




↑ 上に予測した予測誤差
→減らしたい

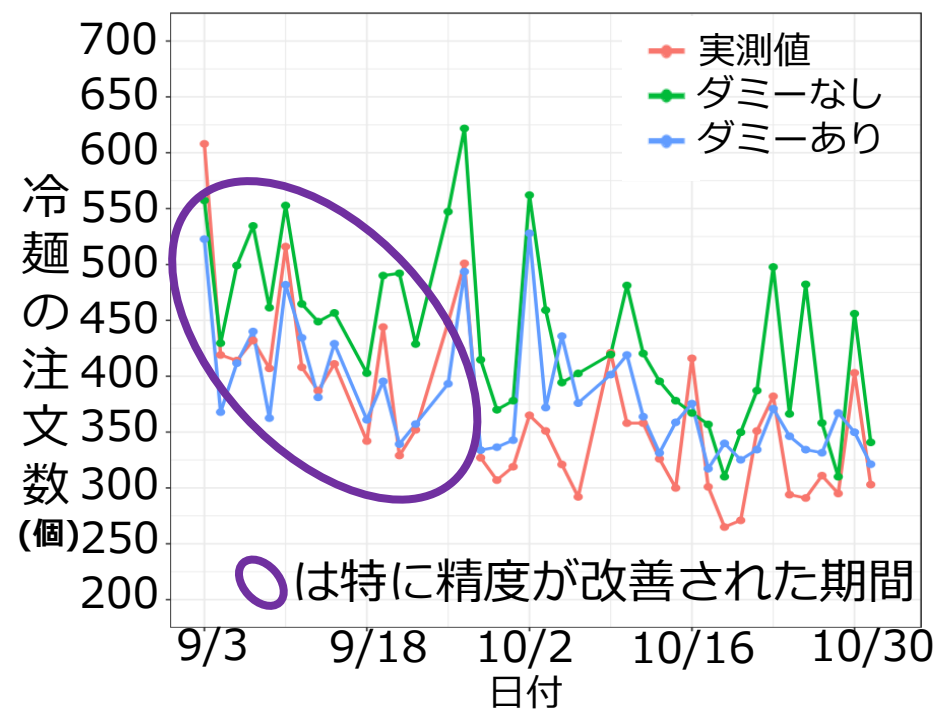
↓ 下に予測した予測誤差
→ある程度許容できる

ダミー変数効果検証(3年間)

2018年度 ランダムフォレスト 比較



2018年度 ニューラルネットワーク 比較



2018~2020年度の9月, 10月における
予測精度評価[個/日]

		ダミーなし	ダミーあり
Tree & Random Forest	ME+	57.7	49.7
	ME-	-23.3	-21.1
Neural Network	ME+	42.6	15.3
	ME-	-12.9	-31.8

※グラフは2018年度の1年分のみを示す

TRF, NNの両方でME+の値が小さくなったことから1日当たりの食品ロスの発生個数を減らすことができた

➡ **精度が改善された**

ダミー変数効果検証(月ごと)

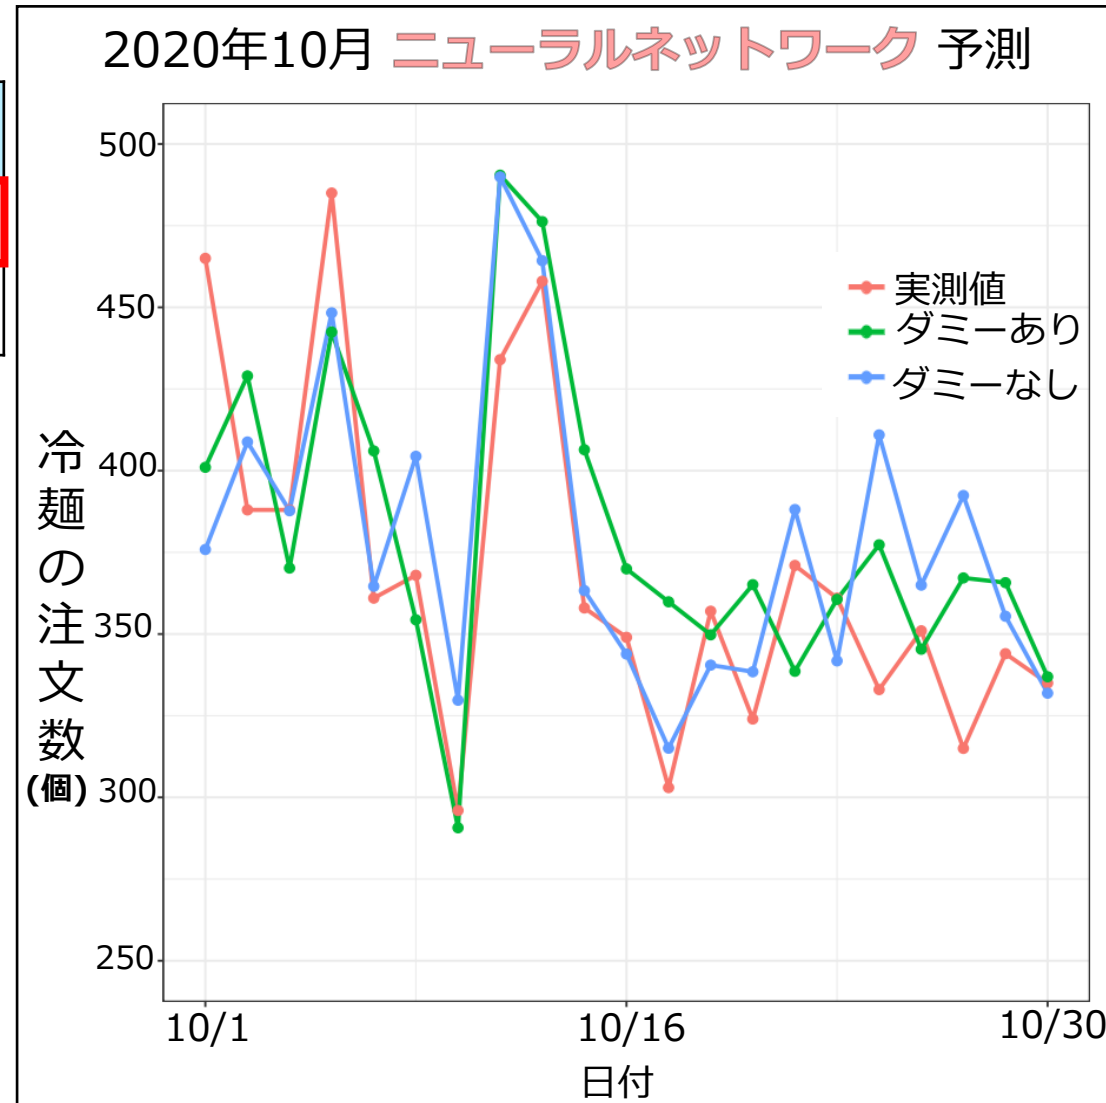
2020年10月の予測精度を上げる
2020年10月における予測精度評価

		ダミーなし	ダミーあり
Neural Network	ME+	21.3	18.4
	ME-	-9.0	-8.1

NNでは月別の予測でも
ダミー変数を取り入れたことで
ME+の値が小さくなり、
すべての期間で
予測精度が高くなった




特徴量としてダミー変数を
与えたことに**効果があった**



GBDTとの比較

ダミー変数の効果検証で予測精度が高かった**NN**と**GBDT**で比較を行う



2018~2020年度の9月, 10月における予測精度評価[個/日]

※グラフは2019年度の1年分のみを示す

	9月		10月	
	ME+	ME-	ME+	ME-
GBDT	32.3	-53.1	55.6	-31.5
NN	6.0	-55.2	22.7	-12.9

予測精度から, **NN**の方が**GBDT**よりも**予測精度が高い**

まとめ

本研究では冷麺の注文数が気温から受ける影響を分析し、**季節**によって、同じ気温帯でも注文数が受ける影響は**異なることが分かった**



分析から、新たな特徴量として**ダミー変数**を与えた結果、ダミー変数を与える前よりTRFでは**1か月**当たり**約130個**、NNでは**1か月**当たり**約430個**食品ロスを削減できた

2018~2020年度の9月、10月における予測精度評価[個/日]

		ダミーなし	ダミーあり
Tree & Random Forest	ME+	57.7	49.7
	ME-	-23.3	-21.1
Neural Network	ME+	42.6	15.3
	ME-	-12.9	-31.8



ダミー変数の効果を確認できた

まとめ

また, **Neural Network** では
GBDT(勾配ブースティング決定木)よりも
良い精度を示した

3年間における予測精度評価からNNの方がGBDTよりも
9月は**1か月当たり約430個**, 10月は**1か月当たり約530個**
食品ロスを削減できた



また, 10月においては
ME-の値がより0に近く,
現場の追加生産の負担を
減らすこともできた

2018~2020年度の9月, 10月における
予測精度評価[個/日]

	9月		10月	
	ME+	ME-	ME+	ME-
GBDT	32.3	-53.1	55.6	-31.5
NN	6.0	-55.2	22.7	-12.9

今後の課題

提案した特徴量を用いても、
9・10月で**増減を捉えきれていない**箇所が存在する




提案した特徴量の有無に関わらず予測が外れているため、
気温以外の要因の影響が考えられる



麺弁当以外で**人気の商品**が提供されていた



気温以外の**変動要因**の影響を明らかにし、
特徴量を考案する**必要**がある



参考文献

- [1] 経済産業省, 工業統計調査,
<https://www.meti.go.jp/statistics/tyo/kougyo/result-2/h30/kakuho/sangyo/index.html>(参照2021-11-28)
- [2] 農林水産省, 食品をめぐる情勢,
<https://www.maff.go.jp/j/council/seisaku/kikaku/bukai/attach/pdf/0520-1.pdf>
(参照2021-11-28)
- [3] 農林水産省, 食品ロス及びリサイクルをめぐる情勢,
https://www.maff.go.jp/j/shokusan/recycle/syoku_loss/attach/pdf/161227_4-194.pdf
(参照2021-12-2)
- [4] 太田和希, 狩野桜, 片桐英樹: 人気と外部環境を考慮した状態空間モデルによる
仕出し弁当の需要予測, 日本経営工学会2020春季大会予稿集, pp.2-3 (2020)
- [5] J.Tian, Y.Zhang, C.Zhang : Predicting consumer variety-seeking through weather
data analytics, Electronic Commerce Research and Applications, Elsevier, Vol.28,
pp.194-207 (2018)