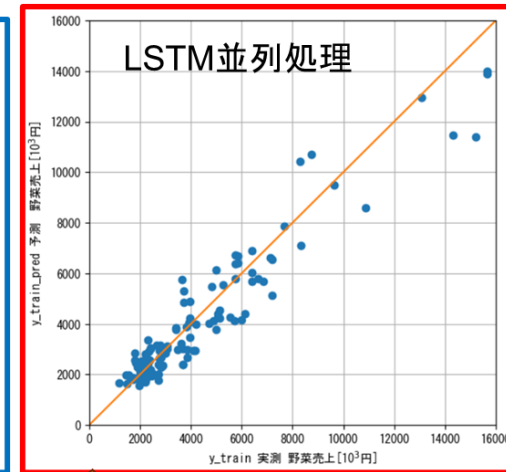




気温と各野菜数量のラグ相関





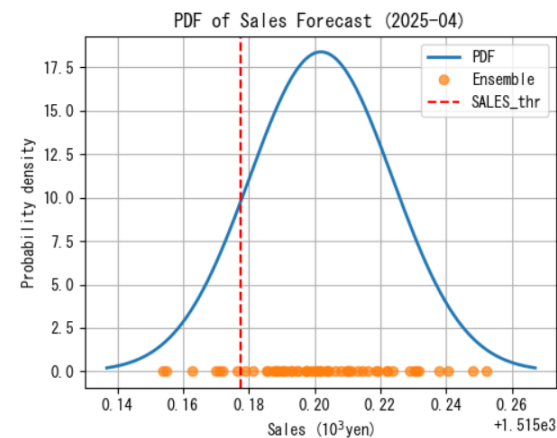
岐阜大学
気象データアナリスト育成講座

気象データ応用 PBL実習

～気象×農業の分析～

グループ名: Group5

氏名: 青木 裕司、大久保 綾子、近藤 蔵ノ助、
齋藤 弘明、杉浦 克尚



背景 ~農業を取り巻く課題~

近年の農業は、気候変動による不安定な生産環境、担い手不足による技術継承の困難さ、資材高騰や土壌劣化といった持続可能性への脅威など、複合的な課題に直面。

異常気象による農作物への影響

✓ 異常気象の頻発により、作物の生育不良や収穫量の不安定化が深刻化。

農業従事者の減少・高齢化の影響

✓ 経験と勘に頼る農業技術が継承困難で、新規就農者にとって高い参入障壁となっている。

農業資源と環境の持続可能性に関する課題

✓ 資材高騰と土壌劣化が収量・品質に影響し、持続可能な農業の障壁となっている。

目的

誰もが活用できる持続可能な農業支援の仕組みの構築

STEP 1 気象データと農業成果の相関把握

- ・気象データと農作物の収量・価格との相関を分析し、作物ごとの傾向を探る。

STEP 2 タイムラグを考慮した時系列予測モデルの構築

- ・STEP 1の結果を踏まえ、野菜品目ごとの気象要素に対するタイムラグを考慮した、数量・価格・売上の時系列予測モデルを構築する。

STEP 3 予測の不確実性の評価と最適な行動の提案

- ・STEP 2のLSTM学習済みモデルを利用して、気温のアンサンブル予報による野菜の売上を予測し、その不確実性を評価する。
- ・コスト／ロス構造を評価し、確率予報による意思決定を行う

目的

誰もが活用できる持続可能な農業支援の仕組みの構築

STEP 1 気象データと農業成果の相関把握

- ・気象データと農作物の収量・価格との相関を分析し、作物ごとの傾向を探る。

STEP 2 タイムラグを考慮した時系列予測モデルの構築

- ・STEP 1の結果を踏まえ、野菜品目ごとの気象要素に対するタイムラグを考慮した、数量・価格・売上の時系列予測モデルを構築する。

STEP 3 予測の不確実性の評価と最適な行動の提案

- ・STEP 2のLSTM学習済みモデルを利用して、気温のアンサンブル予報による野菜の売上を予測し、その不確実性を評価する。
- ・コスト／ロス構造を評価し、確率予報による意思決定を行う

使用したデータ (STEP1)

気象要素と野菜の数量 (※) ・価格の月別データを用いて、
102ケース (= $3 \times 2 \times 17$) に対して相関関係を調べた。

<u>気象要素</u>	月平均の「気温・降水量・日照時間」の3パターン (AMeDAS, 2010年1月~2024年12月)
<u>分析対象変数</u>	高知市中央卸売市場の野菜の「数量 (※) ・価格」の2パターン (農林水産省 青果物卸売市場調査, 2010年1月~2024年12月)
<u>野菜品目</u>	たけのこ、ほうれんそう、れんこん、ねぎ、しゅんぎく、アスパラガス、パセリ、ししとうがらし、さやえんどう、生しいたけ、なす、こまつな、キャベツ、レタス、きゅうり、トマト、ピーマンの17品目


※数量とは、卸売数量（卸売市場で取り扱われた数量）を指すが、ここでは、数量を疑似的に収量と同等と仮定している。

分析結果 (STEP1)


気象要素と野菜の相関係数の一覧

	たけのこ	ほうれんそう	れんこん	ねぎ	しゅんぎく	アスパラガス	パセリ	ししとうがらし	さやえんどう	生しいたけ	なす	こまつな	キャベツ	レタス	きゅうり	トマト	ピーマン	
気温	数量	0.198	-0.361	-0.456	-0.545	-0.741	0.63	0.22	0.428	-0.31	-0.127	0.213	0.365	0.741	0.844	-0.654	0.267	0.118
	価格	-0.319	0.414	0.325	0.062	0.343	-0.438	-0.022	-0.549	0.188	-0.581	-0.573	-0.365	-0.142	-0.307	-0.365	-0.162	-0.588
降水量	数量	0.063	-0.236	-0.277	-0.376	-0.463	0.463	0.168	0.142	-0.198	-0.177	0.114	0.233	0.375	0.517	-0.417	0.166	0.030
	価格	-0.252	0.308	0.233	0.093	0.348	-0.303	-0.132	-0.248	0.258	-0.342	-0.251	-0.135	-0.062	-0.155	-0.060	-0.100	-0.253
日照時間	数量	0.079	0.080	-0.020	-0.049	0.121	-0.050	0.000	-0.129	0.371	-0.083	0.191	-0.089	-0.016	-0.241	0.393	0.240	0.200
	価格	-0.112	-0.265	-0.053	-0.018	-0.336	0.272	-0.091	0.033	-0.242	0.125	-0.025	-0.007	0.100	-0.032	-0.274	0.136	0.049


分析結果



月平均気温 vs. しゅんぎく (オリジナル)

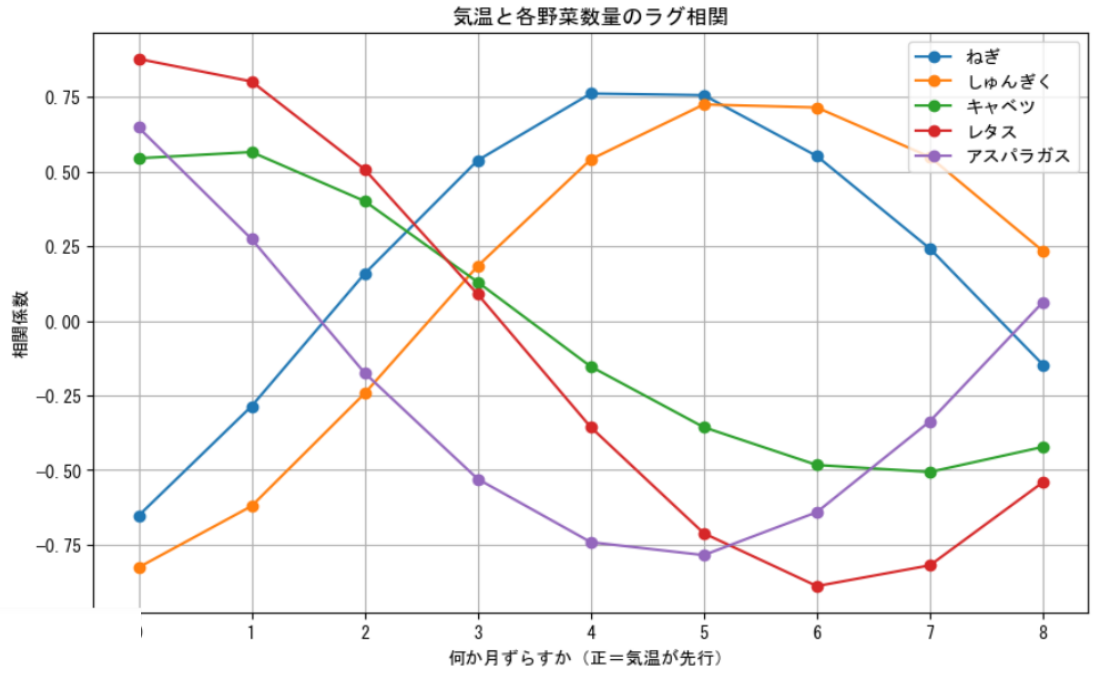


キャベツ, レタス, アスパラガスは位相をずらさない (0か月) 場合に, 相関が最も高いが, しゅんぎくは5か月ずらした場合に最も高くなる。
 → LSTMによるAI予測では, 入力として一定の時間幅のデータを用いる必要があるが, しゅんぎくの場合は気温データを5か月分多く入力する設定となる。



月平均気温 vs. しゅんぎく (shift-5mon)

- ねぎ: 最も相関が高いのは 4.0 か月のずれ (相関係数=0.761)
- しゅんぎく: 最も相関が高いのは 5.0 か月のずれ (相関係数=0.725)
- キャベツ: 最も相関が高いのは 1.0 か月のずれ (相関係数=0.565)
- レタス: 最も相関が高いのは 0.0 か月のずれ (相関係数=0.877)
- アスパラガス: 最も相関が高いのは 0.0 か月のずれ (相関係数=0.647)



位相ずらしのチューニングを自動化.

目的

誰もが活用できる持続可能な農業支援の仕組みの構築

STEP 1 気象データと農業成果の相関把握

- ・気象データと農作物の収量・価格との相関を分析し、作物ごとの傾向を探る。

STEP 2 タイムラグを考慮した時系列予測モデルの構築

- ・STEP 1の結果を踏まえ、野菜品目ごとの気象要素に対するタイムラグを考慮した、数量・価格・売上の時系列予測モデルを構築する。

STEP 3 予測の不確実性の評価と最適な行動の提案

- ・STEP 2のLSTM学習済みモデルを利用して、気温のアンサンブル予報による野菜の売上を予測し、その不確実性を評価する。
- ・コスト／ロス構造を評価し、確率予報による意思決定を行う

使用したデータ (STEP 2)

➤ 説明変数

- 気温 (2010年1月～2024年12月, 高知, 1か月毎): <https://www.data.jma.go.jp/risk/obsdl/index.php>
- 降水量 (2010年1月～2024年12月, 高知, 1か月毎): <https://www.data.jma.go.jp/risk/obsdl/index.php>

(注意) 説明変数として気象要素に加え、**目的変数の過去値を自己回帰的入力として組込む**

➤ 目的変数

- 2010年1月～2024年12月 高知市中央卸売市場の野菜の「**数量**」or「**価格**」or「**売上** (=数量 × 価格)」
(農林水産省 青果物卸売市場調査)

※ 単位は**数量**は[t], **価格**は[円/kg], **売上**は数量[t] × 価格[円/kg]なので, [1000kg × 円/kg]=[10³円]

※ 対象品目は、「**ほうれんそう**」「**ねぎ**」「**しゅんぎく**」「**アスパラガス**」「**キャベツ**」「**レタス**」
の6品目とした。(理由)分析で相関係数が比較的良かったため。

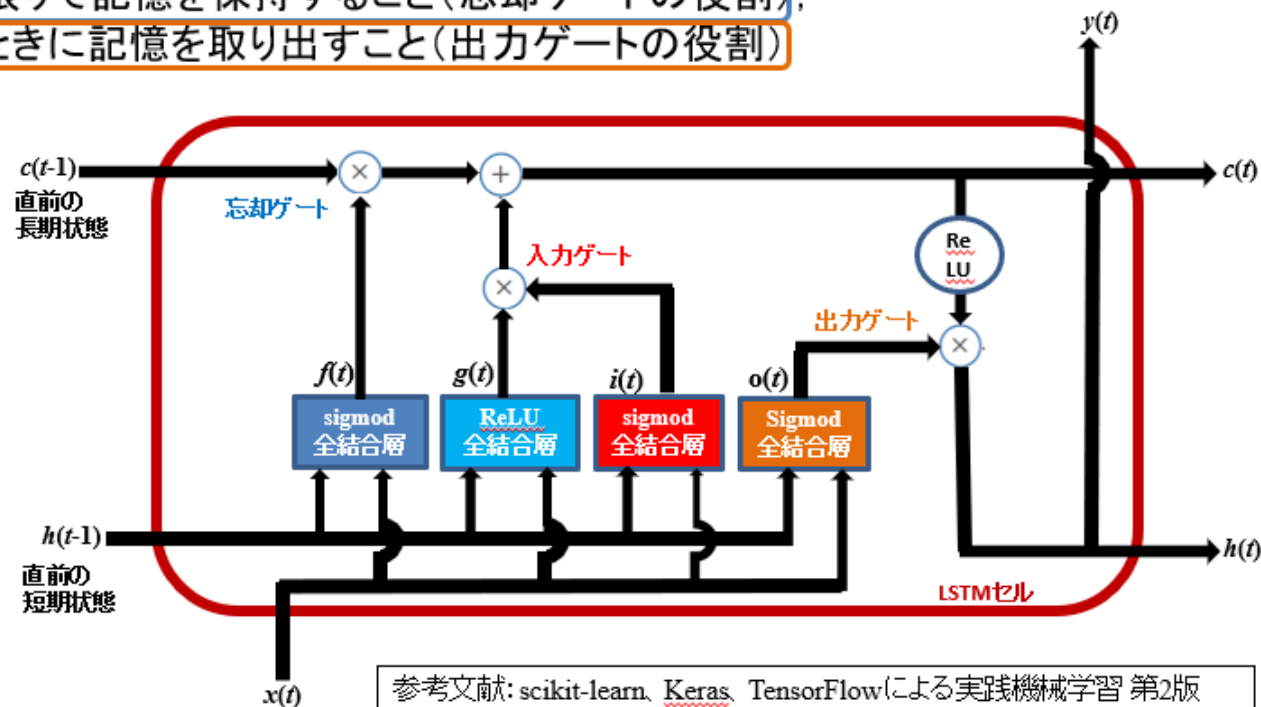
売上予測は、JAや農家の経営判断に直接活用できるため、数量予測や価格予測よりも実務上のニーズが高いと期待される。

予測手法：LSTM (Long Short-Term Memory)

野菜の売上・数量・価格は、**気温や降水量**、**生育状況**、**需要などの影響が時間を通じて累積・遅延して現れる**という特徴を持つ。LSTM は内部にメモリ機構を有し、過去の時系列情報や長期依存性を明示的にモデル化できるため、当該データの特性と親和性が高いと考えられる。

LSTMセルは、以下を学習する。

- ① **重要な入力を認識して(入力ゲートの役割)、それを長期状態に格納すること**
- ② **必要な限りで記憶を保持すること(忘却ゲートの役割)**
- ③ **必要なときに記憶を取り出すこと(出力ゲートの役割)**



LSTMは、時系列データから長期的なパターンを取り出すことに優れる。

LSTMモデルの概要(LSTM並列処理)

LSTM並列処理：CNNにより抽出された同一の時系列特徴を、表現能力の異なる複数のLSTMで同時に学習する。

学習パラメータ設定

項目	カテゴリ	入力数など
最適化アルゴリズム	学習設定	adam
損失関数	学習設定	平均2乗誤差 (MSE)
ミニバッチ数	学習設定	16
学習エポック数	学習設定	23 (過学習を考慮し、最適な回数として設定)

モデル構成に関するハイパーパラメータ

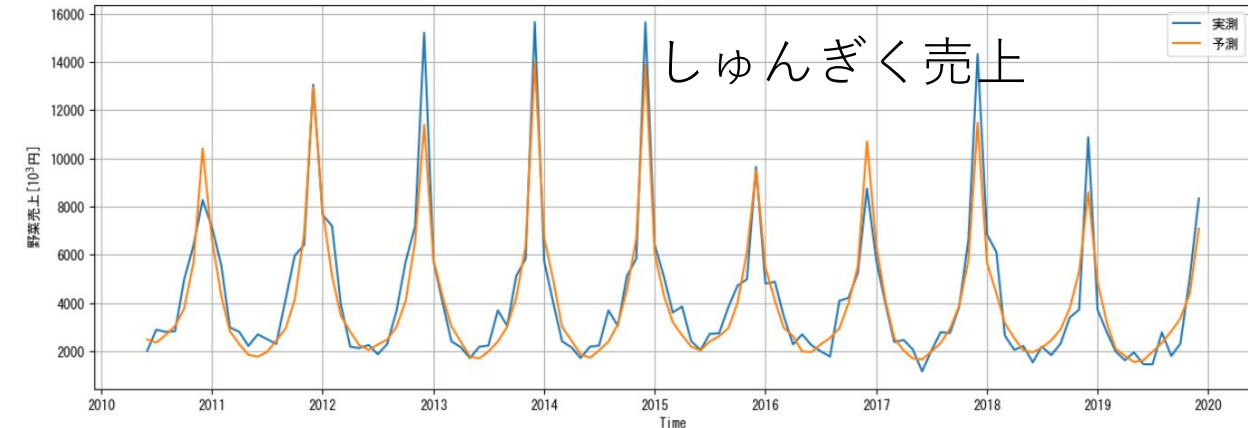

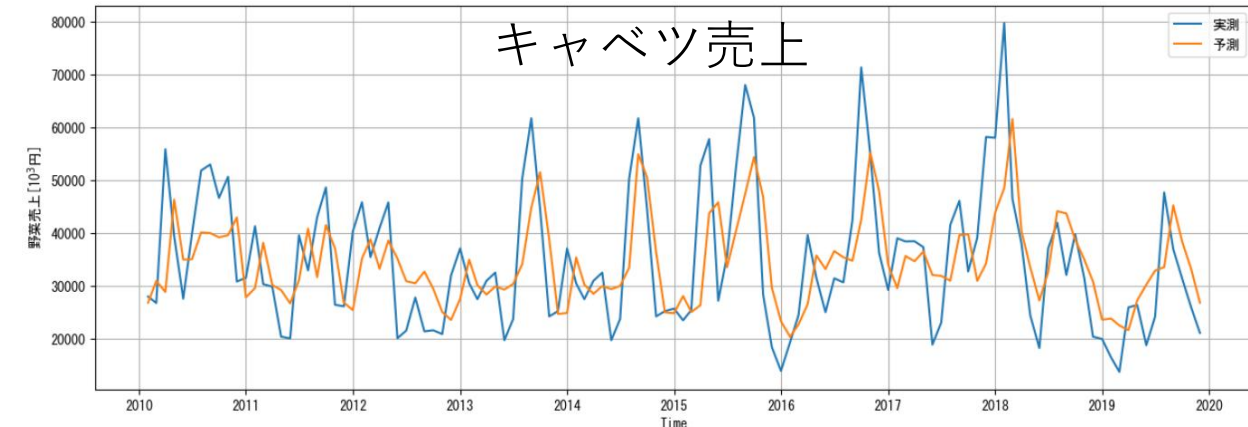


項目	ベースラインモデル	チューニング
中間層数	LSTM層 : 3 (直列)	Conv1D層:3 LSTM層:3(並列処理) Dense層:1
中間層のユニットセル数	LSTM層(直列):(128,64,32)	Conv1D : 32フィルタ, カーネルサイズ3 LSTM層 (並列処理) : (64,32,16) Dense層 : 32
中間層の活性化関数	LSTM : tanh	Conv1D : ReLU LSTM : tanh Dense : ReLU

学習・検証対象

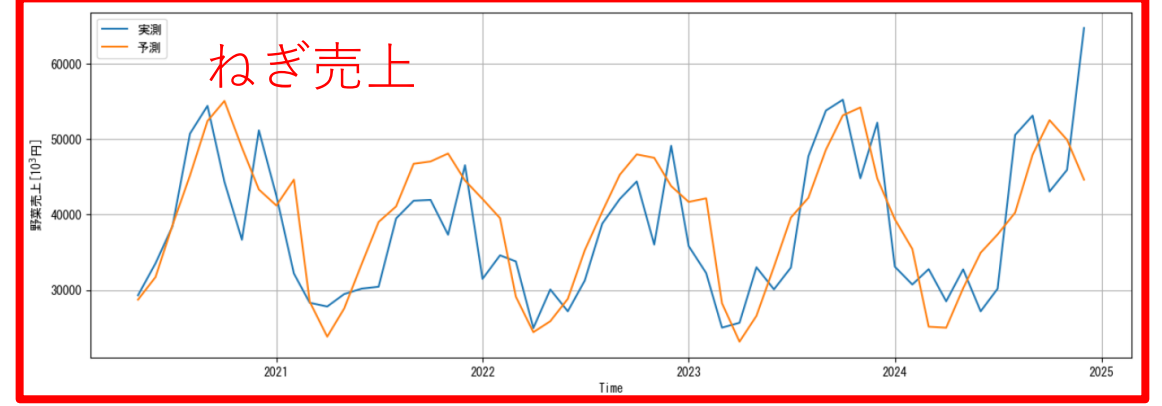
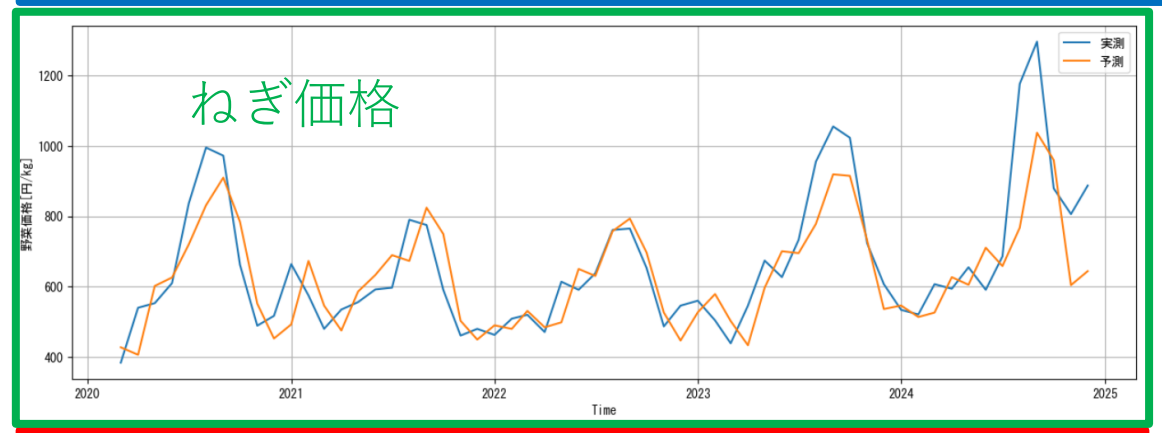
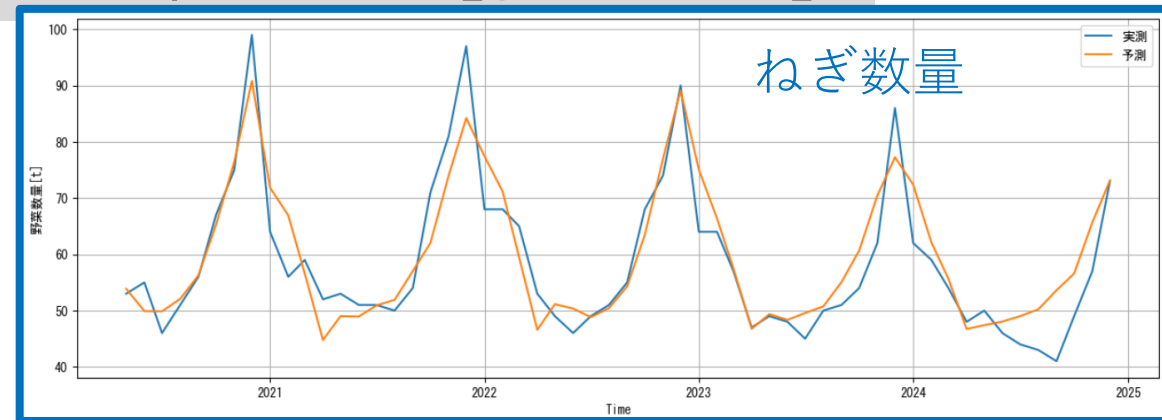
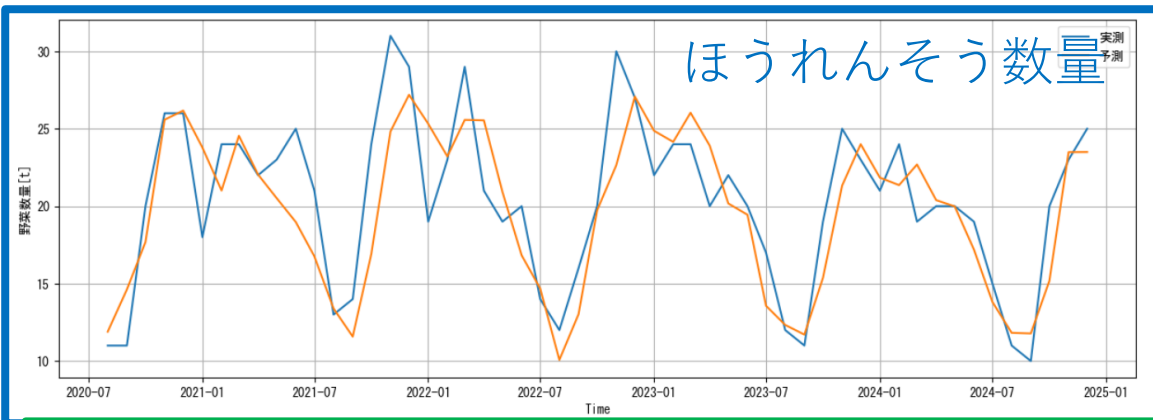
項目	対象期間
訓練 (学習) データ	2010年1月～2019年12月 (120か月)
検証データ	2020年1月～2024年12月 (60か月)

※ クロスバリデーションは適用していない。

他5品目のLSTM並列処理による売上予測【訓練(学習)データ】

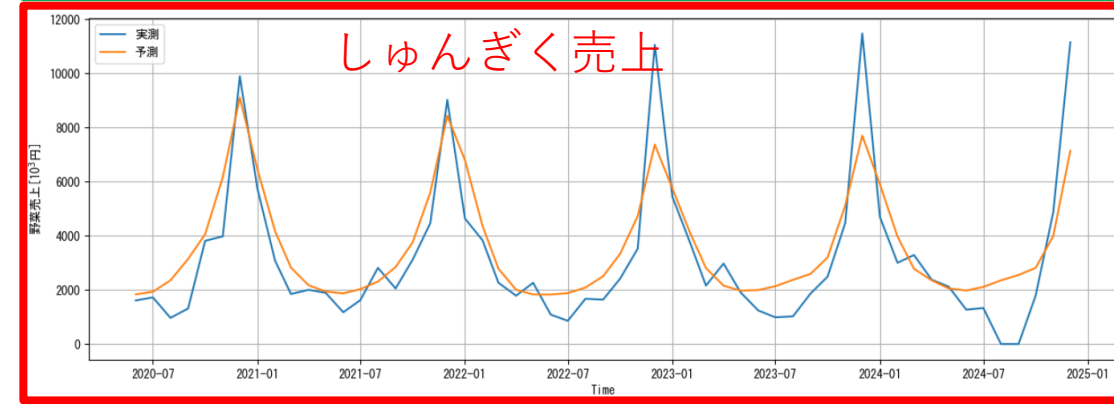
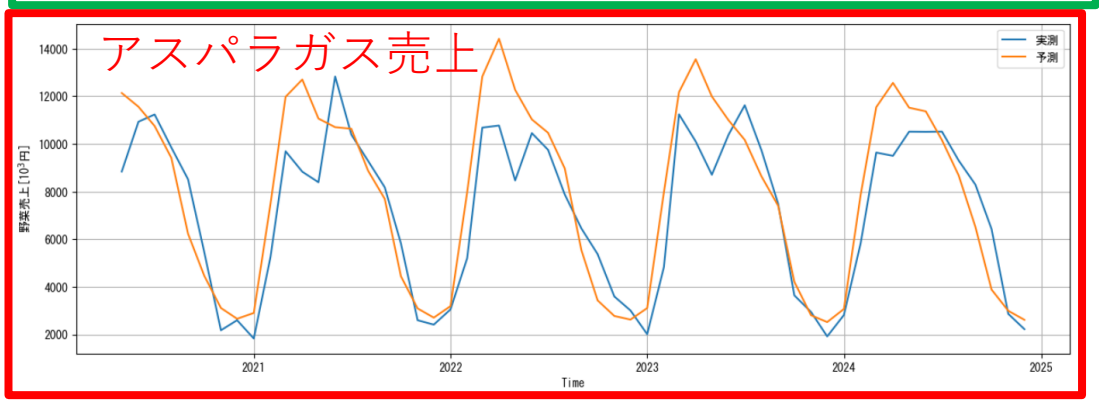
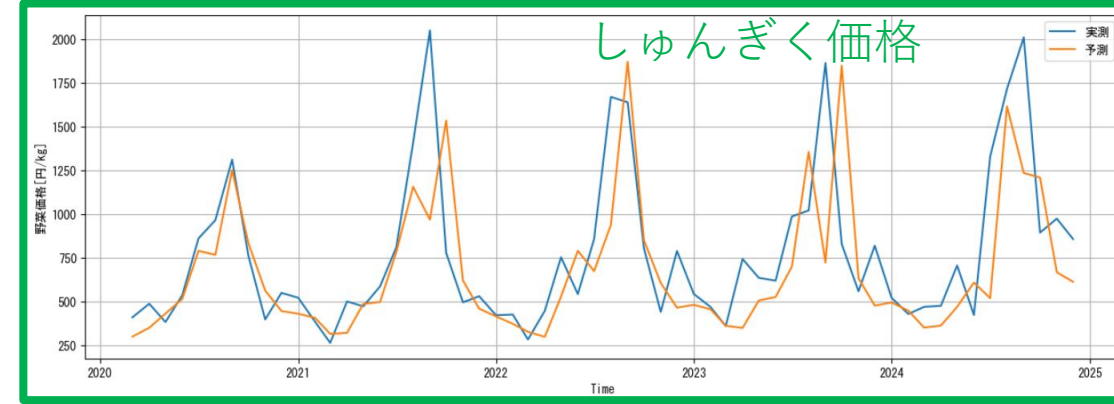

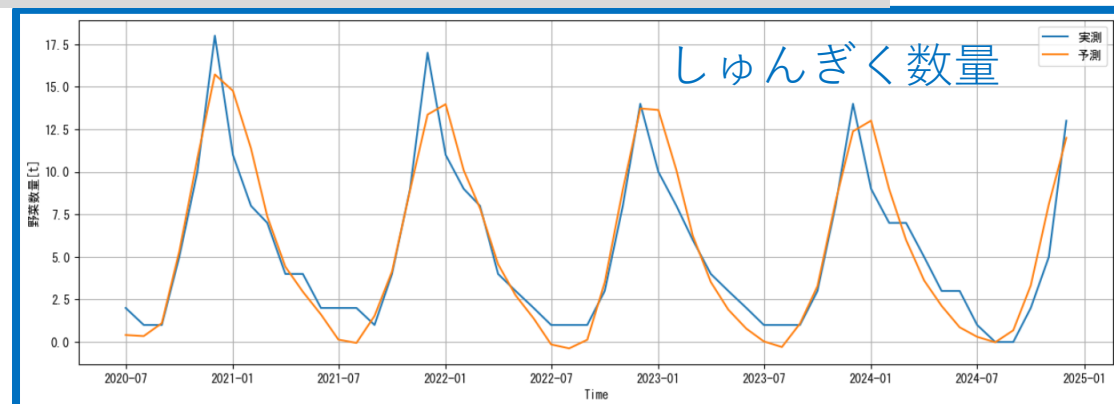
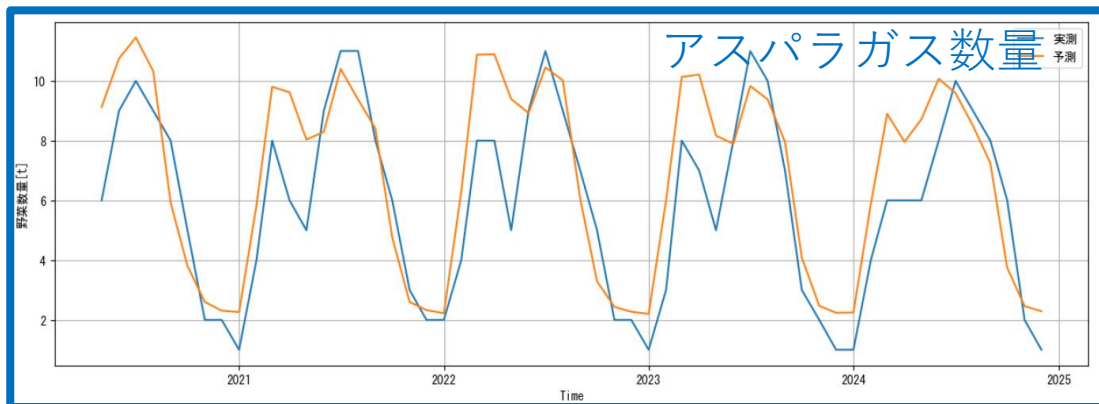


数量・価格・売上のLSTM並列処理による予測結果比較 1/3【検証データ】



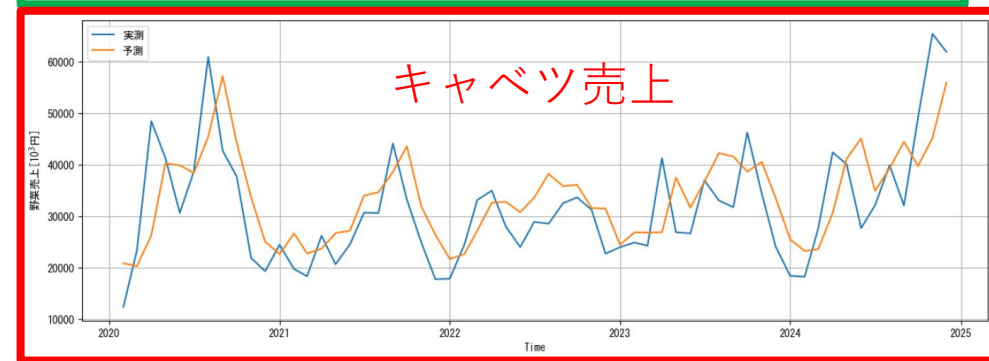
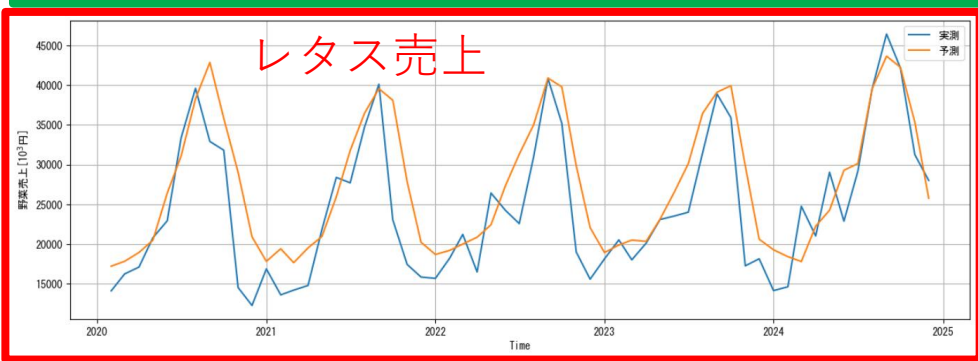
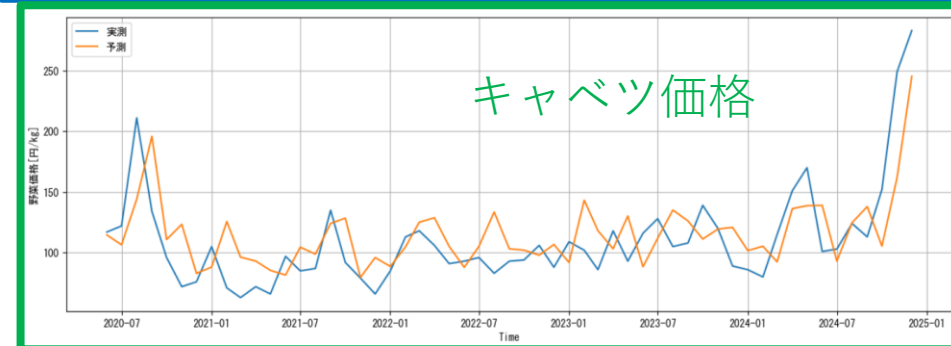

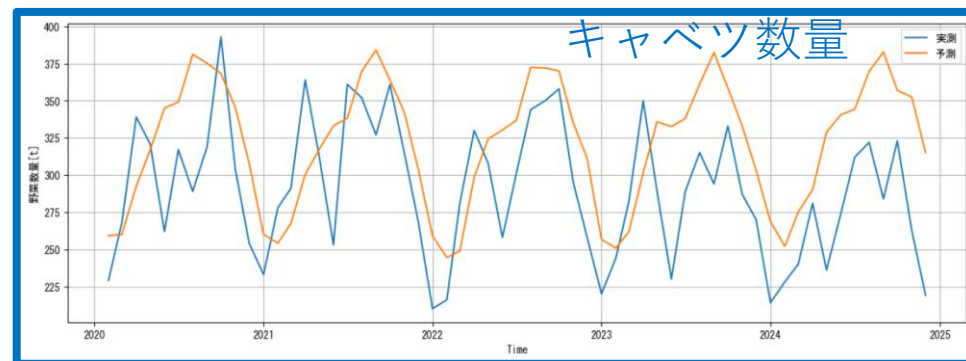
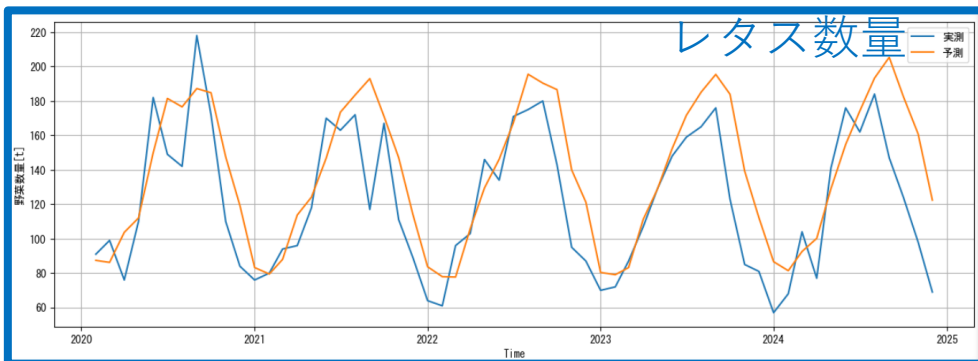
ほうれんそう・ねぎともに、数量・価格・売上の予測における波形の追従性は概ね良好

数量・価格・売上のLSTM並列処理による予測結果比較 2/3【検証データ】



アスパラガスとしゅんぎくともに、数量・価格・売上の予測における波形の追随性は概ね良好

数量・価格・売上のLSTM並列処理による予測結果比較 3/3【検証データ】



数量・価格の予測に比べると、売上の予測における波形の追従性は概ね良好。これは、数量と価格の時系列には不規則かつ急激な変動を含む波形が多く見られる一方、両者を乗じて得られる売上の時系列では、それらの変動が相互に相殺・平滑化されるため、結果としてLSTMによる予測に適した時系列特性を有したためと考えられる。

目的

誰もが活用できる持続可能な農業支援の仕組みの構築

STEP 1 気象データと農業成果の相関把握

- ・気象データと農作物の収量・価格との相関を分析し、作物ごとの傾向を探る。

STEP 2 タイムラグを考慮した時系列予測モデルの構築

- ・STEP 1の結果を踏まえ、野菜品目ごとの気象要素に対するタイムラグを考慮した、数量・価格・売上の時系列予測モデルを構築する。

STEP 3 予測の不確実性の評価と最適な行動の提案

- ・STEP 2のLSTM学習済みモデルを利用して、気温のアンサンブル予報による野菜の売上を予測し、その不確実性を評価する。
- ・コスト／ロス構造を評価し、確率予報による意思決定を行う

使用したデータ (STEP 3)

➤ 説明変数

- アメダス気温：(2024年8月～2024年12月, 高知, 1か月毎) : <https://www.data.jma.go.jp/risk/obsdl/index.php>
- アメダス降水量 (2024年8月～2025年8月, 高知, 1か月毎) : <https://www.data.jma.go.jp/risk/obsdl/index.php>
- **6ヶ月アンサンブル数値予報モデルGPV** (2025年1月～2025年8月, 高知を含む領域, 1か月毎) :

◎岐阜大学の気象データサーバの「jmaepscomgpvgl6m」から予報データ入手

◎1ファイルあたりの5メンバーであるため, 時間をずらすことで11ファイル分を結合し, **合計55メンバーのアンサンブル**とした.

➤ 目的変数

- 2024年8月～2024年12月 高知市中央卸売市場の「**売上**(=**数量**×**価格**)」

※ 対象品目は, 「ほうれんそう」「ねぎ」「しゅんぎく」「アスパラガス」「キャベツ」「レタス」の6品目

分析手法 (STEP 3)

① 利益マトリックス：

売上LSTM予測を利益マトリックスに取り入れ，数量と価格の因果関係やトレードオフ構造を売上に対する外付け係数で表現した。

② LSTMモデルの改良：

気温のアンサンブル予報を利用するために，LSTMで逐次予測できるようにモデル改良を行った。

◎気温のアンサンブル予報を活用するため，LSTM が将来に向かって逐次的に予測できる構造へ拡張した。

利益マトリックス (1/2)

影響・損失 (ロス)

現象

気温高い

数量過多

単価下落
廃棄ロス
売上は伸びない

気温低い

数量不足

高単価
売上は伸びない

対策 (コスト)

数量適正化 (対策B: 数量抑制型)

→ 価格下落回避のために以下のコストが必要

- ・ 作付抑制のための管理コスト：間引き，播種回数・面積の調整，生育途中での廃棄
- ・ 品質維持コスト：遮光資材，灌水頻度増加，高温障害対策

対策Bをとれば，
(例) 対策Aと比較して

数量:-15%

価格:+10%

売上:-2~4%

数量確保 (対策C: 数量確保型)

→ 高単価期を捉えて，以下のコストが必要

- ・ 加温コスト：ビニールハウス等による加温
- ・ 被覆資材コスト，労力コスト等

対策Cをとれば，
(例) 対策Aと比較して

数量:+20%

価格:-5%

売上:-7~10%

営農対策内容

営農対策A：通常作付

例年どおりの作付を行う，特に調整をしない基本的な方法。

営農対策B：数量抑制型

作りすぎによる値下がり为了避免するため，作付量を控えめにする方法。

営農対策C：数量確保型

多少値下がりしても，量を多く作って売上を確保しようとする方法。

利益マトリックス (2/2)

設定：

- ① 平年気温におけるLSTM売上予測モデルから出力される売上額を基準として、ここでは R_t とする。ただし、LSTM売上予測値「 R_t 」は「平年相当の条件下での売上応答」を学習しているものとする。
- ② 売上補正係数を「外付け」で定義し、 s を気温状態、 a を営農対策とすると、各条件下の実質売上 $R_t(s,a)$ を以下のように書く。

実質売上

$$R_t(s,a) = R_t \times \alpha_{\text{数量}}(s,a) \times \alpha_{\text{価格}}(s,a) \times (1 - c(a)) \times \beta(s,a)$$

ここで係数の意味は以下の通りであるが、野菜品目・季節に応じて下記4つの係数は適宜変更可能である。

- **数量補正係数「 $\alpha_{\text{数量}}(s,a)$ 」**：気温状態 s および営農対策 a の組合せによって生じる作物の生育量変化を表す係数
- **価格補正係数「 $\alpha_{\text{価格}}(s,a)$ 」**：気温状態 s および営農対策 a に起因する市場価格の変動を表す係数
- **コスト係数「 $1 - c(a)$ 」**： $c(a)$ は、営農対策 a の実施に伴って発生する追加的な管理コスト、労働コスト、資材費等を売上比率として表したものであり、「 $1 - c(a)$ 」は、対策実施後に売上として残存する割合を示す係数
- **適合係数「 $\beta(s,a)$ 」**：気温状態と対策との組合せに依存して生じる「不適合リスク」を明示的に表現するため、状態×対策ペナルティを表す係数。なお、 $\beta(s,a)$ は1以下とする。

	高温	平年並	低温
対策A：通常作付	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times \beta$	R_t	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times \beta$
対策B：数量抑制型	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$
対策C：数量確保型	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$	$R_t \times \alpha_{\text{数量}} \times \alpha_{\text{価格}} \times (1 - c) \times \beta$

分析結果 (STEP 3)

① 気温のアンサンブル予報を用いた売上のLSTM予測結果：

先述のアンサンブル予報を用いて、改良したLSTM逐次予測モデルにより、しゅんぎくの売上の変化をそのばらつき（不確実性）とともに示す。

② 意思決定分析結果：

先述の利益マトリックスと確率予報を組み合わせて、対策ごとに期待利益を算出し、顧客がどのような対策をとるべきかの意思決定分析の結果を示す。



③ 野菜6品目ごとの売上予測特性の違い：

しゅんぎく以外にも同様にLSTM逐次予測を行い、アンサンブル予報による6品目の売上予測特性の違いを示す。



LSTM売上予測 (1/3)

アンサンブル平均を基準にしたバラつき

アンサンブル平均
からの偏差(10³円)





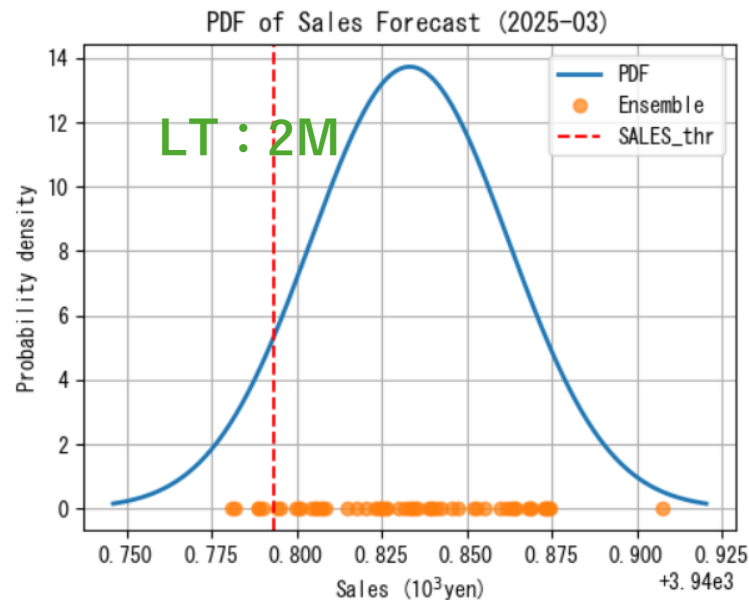

相対誤差 (%)



アンサンブル予測における売上予測値のバラつきは、売上水準そのものが月ごとに大きく異なるため、絶対値のみでは比較が難しい。そこで、各時刻におけるアンサンブル平均との差を、その時刻のアンサンブル平均で正規化し、相対誤差 (%) として評価した。

LSTM売上予測 (2/3)

しゅんぎくの売上の確率密度関数 (PDF) : リードタイム(LT)1~4か月



売上の閾値は、高知の前月の平年気温を入力した場合に、LSTMが予測した売上とする。なお、月ごとに平年気温や入力系列が異なるため、この閾値も月別に異なる値となる。

==== 2025-02 ====

mean = 4325.0254

std = 0.02131391

売上が 4324978.03 円を上回る確率 : 98.686%

売上が 4324978.03 円を下回る確率 : 1.314%

==== 2025-03 ====

mean = 3940.8333

std = 0.029052995

売上が 3940793.46 円を上回る確率 : 91.462%

売上が 3940793.46 円を下回る確率 : 8.538%

==== 2025-04 ====

mean = 1515.2019

std = 0.021717366

売上が 1515177.61 円を上回る確率 : 86.833%

売上が 1515177.61 円を下回る確率 : 13.167%

==== 2025-05 ====

mean = 726.70935





std = 0.01885907

売上が 726707.89 円を上回る確率 : 53.096%

売上が 726707.89 円を下回る確率 : 46.904%

LSTM売上予測 (3/3)

しゅんぎくの売上の確率密度関数 (PDF) : リードタイム(LT)5~8か月



売上の閾値は、高知の前月の平年気温を入力した場合に、LSTMが予測した売上とする。なお、月ごとに平年気温や入力系列が異なるため、この閾値も月別に異なる値となる。

==== 2025-06 ====

mean = 585.0954

std = 0.009731525

売上が 585100.10 円を上回る確率 : 31.457%

売上が 585100.10 円を下回る確率 : 68.543%

==== 2025-07 ====

mean = 1177.2214

std = 0.014060186

売上が 1177225.59 円を上回る確率 : 38.393%

売上が 1177225.59 円を下回る確率 : 61.607%

==== 2025-08 ====

mean = 2681.47

std = 0.018773273

売上が 2681471.92 円を上回る確率 : 45.857%

売上が 2681471.92 円を下回る確率 : 54.143%

==== 2025-09 ====

mean = 5592.3

std = 0.04904144

売上が 5592307.62 円を上回る確率 : 43.671%

売上が 5592307.62 円を下回る確率 : 56.329%

意思決定分析

利益マトリックスと確率予報による意思決定分析

$$Rt(s,a) = Rt \times \alpha_{\text{数量}(s,a)} \times \alpha_{\text{価格}(s,a)} \times (1 - c(a)) \times \beta(s,a)$$

	高温	平年並	低温
対策A: 通常作付	$Rt \times 1.20 \times 0.80 \times 0.75$	Rt	$Rt \times 0.75 \times 1.30 \times 0.7$
対策B: 数量抑制型	$Rt \times 1.02 \times 0.88 \times 0.97 \times 1.0$	$Rt \times 0.85 \times 1.10 \times 0.97 \times 0.85$	$Rt \times 0.64 \times 1.43 \times 0.97 \times 0.8$
対策C: 数量確保型	$Rt \times 1.44 \times 0.76 \times 0.93 \times 0.7$	$Rt \times 1.02 \times 0.95 \times 0.93 \times 0.7$	$Rt \times 0.90 \times 1.24 \times 0.93 \times 1.0$


	2025-01	2025-02	2025-03	2025-04	2025-05	2025-06	2025-07	2025-08
対策A	4259.5	3329.7	2899.9	1100.5	529.1	434.5	902.0	2031.4
対策B	5012.5	3564.1	3231.6	1179.5	553.6	455.7	896.1	2066.4
対策C	4136.4	3334.3	3140.9	1331.4	660.1	508.3	1046.6	2349.2

利益マトリックス作成のための係数は1月～8月の各月で本来は変更すべきだが，ここでは，モデル評価の簡略化のため，同一の係数とした。

期待利益が最大となる行動とそのときの期待利益

確率予報

確率予報



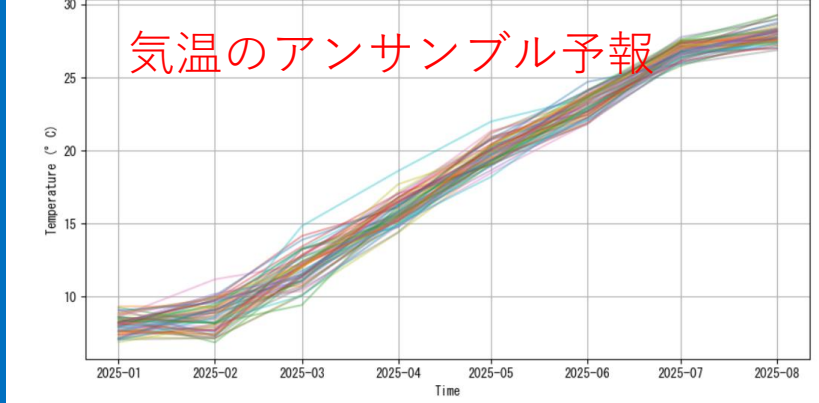






数量抑制型

数量確保型

月	best_strategy	expected_profit (10 ³ yen)
2025-01	対策B	5012.0
2025-02	対策B	3564.0
2025-03	対策B	3232.0
2025-04	対策C	1331.0
2025-05	対策C	660.0
2025-06	対策C	508.0
2025-07	対策C	1047.0
2025-08	対策C	2349.0

予測特性の違い(1/2)


野菜6品目ごとの売上予測値の相対的なバラつき アンサンブル平均との相対誤差 (%)



野菜の品目によって、アンサンブル予報における売上予測値の相対的なばらつきは異なっている。
 同一の気温アンサンブル予報を用いた場合でも、売上予測の相対的なばらつきの大きさやピークとなるリードタイムが品目ごとに異なることが確認された。これは、気温予報の不確実性そのものの違いではなく、気温と売上の関係性、特に生育期間や需給構造に起因する位相ずれの違いが、LSTM を通じて異なる形で売上予測に反映された結果と解釈できる。

予測特性の違い(2/2)

野菜6品目の超過確率の時系列の比較




確率予報では1~3月は平年より高温、4~8月は平年より低温の傾向にある。

売上の閾値は、高知の前月の平年気温を入力した場合に、LSTMが予測した売上とし、各野菜によって異なる。

- 平年より高温の1~3月は、2~4月の売上予測に影響し、超過確率は50%を超えている。
- 平年より低温の5月以降は、6月以降の売上予測に影響し、超過確率は50%を超えない品目が多い。

野菜の品目によって気温予報が売上予測に与える影響の大きさが異なり、売上予測や意思決定に対する影響が品目別に異なることが示唆される。

各野菜の売上の閾値に対する超過確率の時系列



結論

- 野菜の収量変動を説明する変数として、**月平均気温が最も有効な指標**であることが明らかになった。その影響の受け方は一様ではなく、**品目によって「タイムラグ」が存在**することが判明した。
- 「Conv1D層」による局所的な変動パターンの抽出と、「LSTM並列処理」の構造内アンサンブル効果を組み合わせることで、急峻かつ短期間のピークを含む**売上予測に成功**した。
- 売上のLSTM予測結果を利益マトリックスに組み込み、実質売上を4つの外付け係数として表現することで、**意思決定分析に応用できる可能性**が示唆された。

本モデルを活用すれば、品目特性を考慮した売上予測の高度化や意思決定支援に貢献でき、誰もが使える持続可能な農業支援の仕組みとして機能する。

参考資料

- 一般気象学（第2版），小倉義光著，東京大学出版会
- 気象データアナリスト養成プログラム教材，吉野純，小林智尚，玉川一郎，岐阜大学工学部附属応用気象研究センター，2025.
- scikit-learn、Keras、TensorFlowによる実践機械学習 第2版
- 気象庁ホームページ，<https://www.jma.go.jp/jma/index.html>
- 数値予報解説資料集(令和6年度)，
<https://www.jma.go.jp/jma/kishou/books/nwpkaisetu/nwpkaisetu.html>
- 農林水産省青果物卸売市場調査，
https://www.maff.go.jp/j/tokei/kouhyou/seika_orsu/