

## 欠測に対応可能な水稻収量予測ツールの開発

神生 直敏, 佐藤 博一\*

### Development of Paddy Rice Yield Prediction Tool that can Deal with Missing Data

Naotoshi KAMIO, Hirokazu SATOH\*

#### 抄 錄

北海道における稲作農業では、安定した収穫量を確保するために気象変動の影響を受けにくい品種の生育試験を実施し、その収穫量（収量）を把握しておく必要がある。しかし、生育試験の実施には制約が多いため、何らかの予測手法を使って収穫量の予測を行うことが求められている。収穫量を予測するには、土壌や気象などの過去の水稻栽培データが必要だが、品種・収集地点によってはデータが欠測しているため、統計解析や機械学習等の通常の予測ツールでは満足な結果が得られないケースが多い。そこで本研究では、品質工学のT法を応用して、データに欠測があっても解析可能な収量予測ツールを開発し、地域および気象別（低温・平年・高温）に水稻の収穫量の推定を行い、本ツールの有効性を検証した。

キーワード：水稻、収量予測、品質工学、T法、欠測

#### Abstract

In rice farming in Hokkaido, in order to secure the stable production, it is necessary to carry out surveys and growth tests of varieties that are not easily affected by climate change, and to grasp the amount of harvest(yield). However, there are a lot of restrictions in the implementation of growth tests, so it's required to predict the yield, using some forecasting methods. Growth data in the past of the soil and weather is necessary to predict the yield, but there are any missing data, there are a lot of cases from which a result satisfied with the usual predictive tool by which it's not obtained for statistical analysis and mechanical learning. Therefore, in this study, we applied the T method of Quality Engineering to create a yield forecasting tool that can be analyzed even if there are missing data, and conducted prediction model creation and yield estimation by region and weather (high temperature year, normal year, low temperature year.).

KEY-WORDS : paddy rice, yield prediction, Quality Engineering, T-method, missing

#### 1. はじめに

「日本の食糧基地」とも呼ばれる北海道は、かつての開拓時代には「稻作は不適地」と言っていたが、品種改良・栽培技術の改良が進み、現在では利尻島でも水稻が栽培されるなど、全国トップクラスの水稻の生産地となっている。

また、品種では、昭和63年に誕生した「きらら397」が、丼物の外食チェーンを中心に全国的に利用されるようになり、現在では「ななつぼし」や「ゆめぴりか」が、日本穀物検定

協会の食味ランキングで最高位「特A」を獲得するに至っている。

近年は温暖化の影響と見られる収量（収穫量）の鈍化傾向が見られ（図1）、気象変動の影響を受けにくい品種についての調査・生育試験が行われている。しかし、圃場試験の実施は制約が多いため、可能な限り予測モデルを使うことで、圃場試験を最低限にする品種選定の研究が求められている。

\* 道総研 中央農業試験場, \* HRO, Central agricultural experiment station

事業名：経常研究（理事長枠）「一次産業におけるビッグデータの取得技術と利活用解析技術に関する研究」

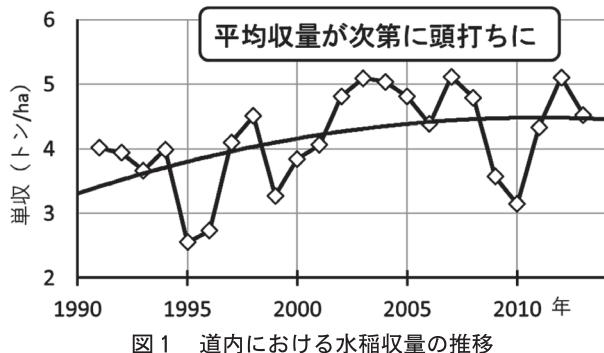


図1 道内における水稻収量の推移

水稻の収量を予測する作物モデルとしては、植物成長理論に基づく、堀江らのSIMRIW(Simulation Model for RIce-Weather relations)<sup>1)</sup>が知られている。SIMRIWは、品種パラメータと気温、日射量などの気象データから、収量を算出する予測モデルである。

しかし、SIMRIWはモデル構築から20年以上経過しており、かつモデル構築に使用した当時の品種がほぼ栽培されておらず、予測結果の適合性が問題となっている。加えて、品種情報を得るには相当な年数の圃場試験が必要で、品種開発が初期の場合、品種設計者が性能の見込みを早期に得るために、利用しにくいという問題がある。

また、過去に収集した水稻栽培・気象データには、欠測(欠損)が多数存在しており、収量の予測解析を進めるためには、欠測についての処理(補間)も必要となる。

そこで本研究では、比較的簡便な手法ながら、従来の統計手法などと異なる特徴を持つ、品質工学のT法を用いた予測モデルの確立を目的に、欠測処理方法の比較とともに、SIMRIWや一般的な統計解析手法である重回帰分析などとの性能比較を行うことで、T法の有効性を確認した。また、それらの知見を踏まえ、収量予測モデルを作成し、そのモデルにより地点別・気象別での水稻5品種の性能を比較した。

## 2. T法とは

多変量データによる予測手法としては、重回帰分析、機械学習が有名であるが、これらと比較して、簡便かつ異なる特徴を持つ予測手法としてT法が挙げられる。

T法は、開発技法である品質工学を体系化した田口玄一博士により提案された、簡便な予測・判別手法である<sup>2)</sup>。T法には3種類あるが、一般的に使用されるものがT法(1)(別名、両側T法)である。T法(1)は、目的値のある場合の予測値(総合推定値)を算出する方法であり、総合推定値の算出式は、品質工学におけるバラつきの指標値である「SN比」を使った式(a)で表される。なお、実際の計算手順は、文献<sup>3)</sup>等を参照されたい。

$$T = \frac{1}{\sum \eta} \left( \frac{\eta_1}{\beta_1} X_1 + \dots + \frac{\eta_k}{\beta_k} X_k \right) \quad (a)$$

$T$  : 総合推定値  $\eta$  : SN比  
 $\beta$  : 比例定数  $X$  : 変数(平均値で校正後)

またT法(1)を統計解析の重回帰分析と比較すると、予測式の構造が一次線型式という類似点がある一方、多重共線性などの解析制約がない<sup>4)</sup>などの相違点がある(表1)。特に、使用するデータに「欠測(欠損)」があっても、エネルギー比型SN比<sup>5)</sup>を用いて、欠測状態のままでも演算可能のように改良することで解析可能なことが、増田により報告<sup>6)</sup>されている。本研究では、増田により改良されたT法(1)を便宜的に「欠測対応T法(以下、欠測T法)」と呼び、水稻の収量予測に使用することとした。

表1 T法(1)と重回帰分析の比較

	重回帰	T法(1)
既知データ自身の推定	◎	○
未知データの推定	△	○
説明変数がデータ数より多い	×	○
多重共線性が存在	×	○
欠測が存在	△ (欠測処理)	○ (欠測T法)
手軽さ(使用ツール)	専用ソフトなど	Excel

## 3. 使用データと解析方法

### 3.1 使用データ

今回解析に使用したデータの全体概要を表2に示す。

表2 解析用データ概要

品種データの 総数と 収集地点	総数 624: 2005-2017年 (H17-H29) 【内訳】: ななつぼし 164 きらら397 151 ゆめぴりか(2008-) 133 そらゆき (2011-) 92 そらゆたか (2011-) 84 ※そらゆき(食用)、そらゆたか(飼料用)は多収性の新品種 収集地点: 道内 25地点	
	89個 【内訳】: 生育データ19(土壤等) ※変数毎の最大欠測率 0~52% ・気象データ70 平均気温、最高気温、最低気温、 積算日射量、積算日照時間の5種を、 14旬毎(5月中旬~9月下旬)に	
説明 変数	目的 変数	精玄米重 ( $g/m^2$ ) = ( $kg/10a$ ) ※総重より難易度高いが、一番知りたい値

解析用データは、平成17年~平成29年の5種類の品種について、北海道立総合研究機構(以下、道総研)農業試験場が栽培方法や品種改良の検討を行うために蓄積している、土壤、穂数など生育に関するデータと、農業・食品産業技術総合研究機構で提供している1kmメッシュ気象データから抽出したデータとを統合したものである。データ収集地点(図2)

は、道総研農業試験場3地点や協力農家の圃場22地点の計25地点である。説明変数は、研究当初、生育と気象の132種類で解析を実施したが、協力農家は、一部の品種しか栽培していないこともあり、農学的見地から、研究途中で改めて説明変数の見直しを行い、最終的には89種類で解析を実施した。



図2 データ収集地点（25地点）

なお、生育データについては、過去のデータ収集過程において、様々な事情により欠測が存在するデータとなっている（図3）。統計解析や、機械学習では予測を行うためには、補間による欠測処理が必要である。

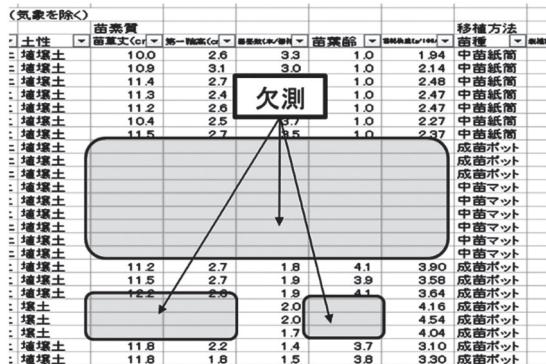


図3 欠測データの例

図4に精米過程における、過程毎の収量値名を示す。SIMRIWは、刈取り後に充分乾燥した地上部全重量である「総重」を目的変数として収量予測を行う。本研究では、精米過程の最終段階であり、不確定要素はあるものの、予測ニーズが高い「精玄米重」を目的変数として、収量予測を行った。

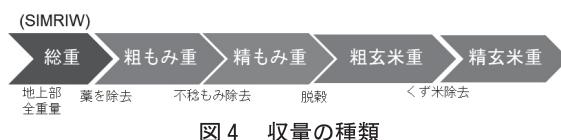


図4 収量の種類

### 3.2 解析方法

欠測T法の性能は、以下の3項目で評価した。

- ①欠測処理方法による予測性能比較
- ②予測モデルの性能
- ③ロバスト性評価

性能評価の指標として、実測値と予測値の相関係数R、RMSE（2乗平均平方根誤差）を使用した。相関係数は絶

対値にして0～1の値を取るが、1に近いほど良好で、またRMSEは、0に近いほど良好となる。

解析に使用したツールは、欠測補間の処理には「JMP」（SAS）や機械学習ツール「Weka」<sup>7)</sup>をそれぞれ使用した。

また、欠測T法での解析については、有）増田技術事務所の協力を得て、Microsoft Excel2013以降で動作する「欠測T法解析ツール」を研究を進める過程で作成し、解析を行った（図5）。

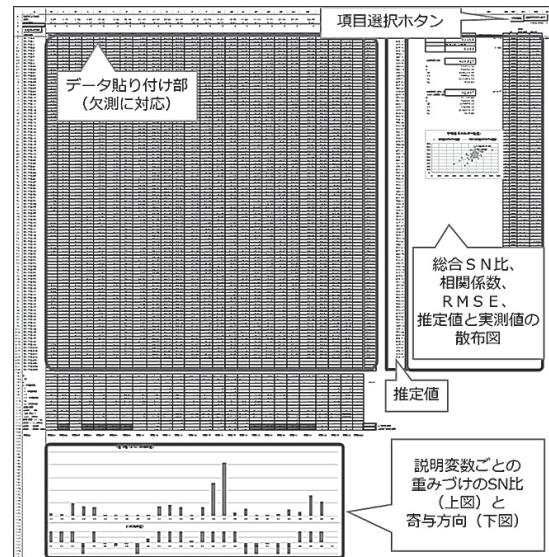


図5 欠測T法解析ツール画面

## 4. 欠測T法の性能評価

### 4.1 欠測処理方法の比較

重回帰分析などの統計解析では、欠測変数における残りデータの平均値で補間する「平均値補間」、目的変数との単回帰分析結果による予測を利用する「多変量正規分布補間」、多量データ処理得意とする「特異値分解補間」などの方法を使用してデータの欠測処理を行うのが一般的である。そこで、これらの欠測処理方法と、欠測が存在するままのデータを解析することができる欠測T法の予測性能を比較した。

欠測T法の性能評価結果の詳細については、文献<sup>8)</sup>に譲り、ここでは結果の概要のみを表3に記載する。

表3 T法における欠測処理方法の比較

欠測処理方法		きらら397	
		R	RMSE
補間	平均値補間	0.57	92.3
補間	多変量正規分布補間	0.58	90.9
補間	特異値分解補間	0.57	92.1
無処理	欠測T法	0.57	94.2

結果を総合的に比較すると、各方法の予測性能に大きな差異は見られなかった。なお、水稻の収量予測については、厳密な精度よりも、解析作業が簡単・効率的にできる方が、品種開発等の段階では有益であり、その点では、欠測T法は、欠測処理作業が不要という大きなメリットがある。

#### 4.2 既知データによる、SIMRIWとの性能比較

次に、欠測T法と既存予測モデルSIMRIWとの予測性能を比較した。結果を表4に示す。なお、SIMRIWの標準の出力は総重であること、また、欠測のままでは解析できることもあり、道総研農業試験場で標準的な値を使って、欠測補間や精玄米重に変換するなどの処理を事前にしている。

欠測T法は、予測モデル式として一次線形式(b)で表すことが可能である（係数値等は割愛）。

$$\text{予測値} = a_1(x_1 - b_1) + a_2(x_2 - b_2) + \cdots + T \quad (b)$$

$a_1$  : 係数,  $b_1$  : 解析に使用した変数データの平均値  
 $x_1$  : 変数,  $T$  : 解析に使用した目的値データの平均

さらに、欠測T法では、項目の重要度を算出し、モデル式の性能向上を目的に、重要度の高い変数を残した形での予測モデル式も作成可能である（項目選択）。項目選択は、重回帰分析での変数選択に相当するが、どの変数が目的値にどれだけ影響（寄与）を与えるかが、SN比の大きさで表現される。図6は、説明変数毎のSN比の表示例だが、この結果を見て、変数の絞り込みをする。絞り込み方法は、実験計画法で使用する直交表を使って分析する方法、モデル式から変数を1つずつ増減させてSN比の増減状況から判断する方法な

表4 既知データによる性能比較結果

予測手法	きらら397	
	R	RMSE
SIMRIW	0.37	162.2
欠測T法	0.61	93.0
欠測T法（項目選択後）	0.70	74.5

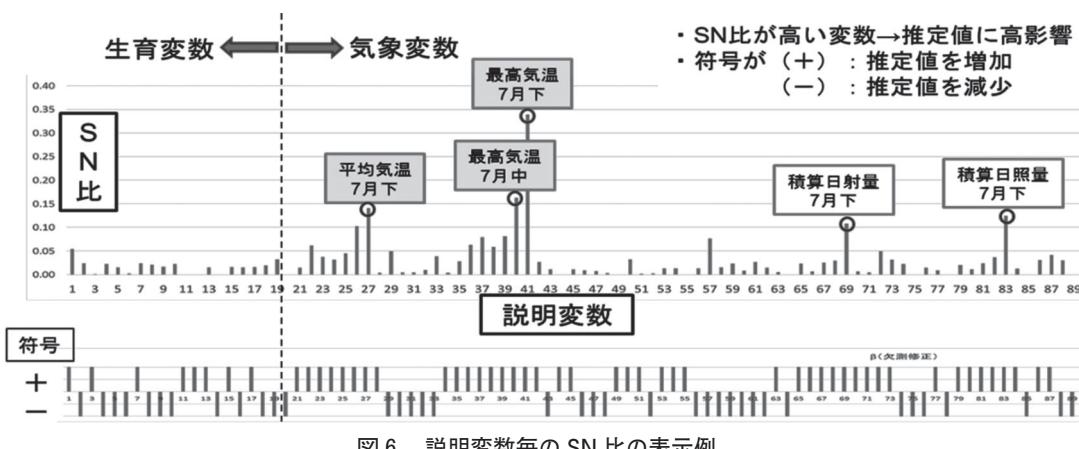


図6 説明変数毎のSN比の表示例

どが存在する。今回は、1変数ずつ行う方法を欠測T法解析ツールに追加して、項目選択の性能を評価した。

表4に説明変数を89個から44個に絞り込んで予測モデル式を作成し、解析した結果を示す。

解析した結果、欠測T法は、精玄米重の予測において、既存のSIMRIWよりも相関係数およびRMSEの点で良好な性能であり、また欠測T法は項目選択を行うことで、さらに予測性能が向上することが判明した。

#### 4.3 ロバスト性の比較

本来、予測モデルの良し悪しは、未知（将来）のデータによる予測性能で評価されるものである。予測モデルの作成に使用した既知データについての予測性能が良好でも、そのことが「未知データの予測性能（ロバスト性）」を担保しているものでないためである。そのため、予測モデルが未知のデータに対して、どの程度対応できるかを評価する必要がある。

予測手法の妥当性検証には、データ数が少ない場合に有効である交差検証法（Cross-validation）を研究の初期段階で利用していたが、その後、使用できるデータを一定程度確保できたこともあり、以後は、道総研農業試験場で、予測モデル作成用データとして、「データ多（5年：2009-2013）」と「データ少（3年：2011-2013）」の2パターンとした予測モデルを品種毎に作成し、未知データとして3年分（2014-2016）データからの精玄米重の予測精度を調査した。

調査結果を表5に示す。なお、新品種そらゆきとそらゆたかは、データが2011年からとなるため、「データ少」のみとなることに留意されたい。また、参考として品種の年数が一番長い、きらら397での重回帰分析とSIMRIWの結果も示すが、欠測処理等については4.2節と同じ処理を行っている。

調査の結果、データ数が多い方が、より予測性能が良好であること、欠測T法は重回帰分析やSIMRIWと比較しても、同等もしくはそれ以上の予測性能を有することがわかった。重回帰分析とSIMRIWの実施は、きらら397しか実施していないが、他品種でも欠測T法の有効性は同様と見込まれる。

表5 未知データの予測性能（中央農業試験場調査）

手法	品種名	予測モデル 作成データ	未知データ のRMSE
欠測T法	きらら397	2009-2013年	61.8
		2011-2013年	91.5
	ななつぼし	2009-2013年	64.0
		2011-2013年	82.1
	ゆめぴりか	2009-2013年	55.7
		2011-2013年	80.4
重回帰	そらゆき	2011-2013年	71.1
	そらゆたか	2011-2013年	78.2
	きらら397	2009-2013年	105.8
SIMRIW		2011-2013年	616.6
		—	94.2

## 5. 地点毎・気象毎の予測

これまでの結果を踏まえ、欠測T法を用いて、5品種の25地点別および気象別に精玄米重の収量予測を行った。図7から図11に品種毎の地点別・気象別（高温年、平年、低温年）の予測結果を示す。なお、図7から図11は、横軸にある地点名は低緯度からの番号としている。品種による地域特性も見られるが、多収性品種として開発された「そらゆき」の収量は、気温変動の影響を受けにくい傾向があることが解析結果から読み取れる。また、「そらゆき」と同じく多収性品種として開発された「そらゆたか」については、特に高緯度地域では、気象変動が収量に影響しやすい可能性を示唆する結果となった。

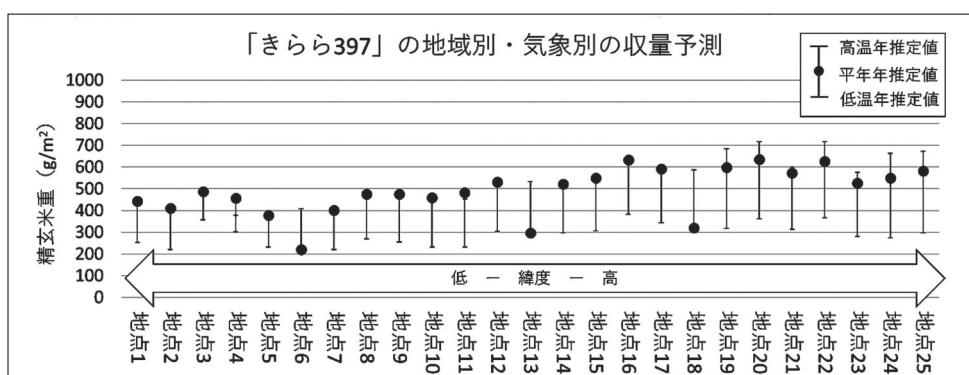


図7 きらら397の地点別・気象別の収量予測

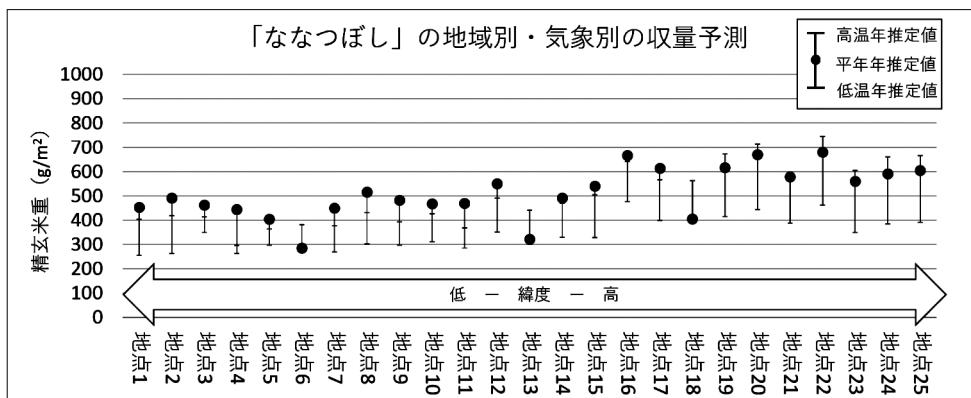


図8 ななつぼしの地点別・気象別の収量予測

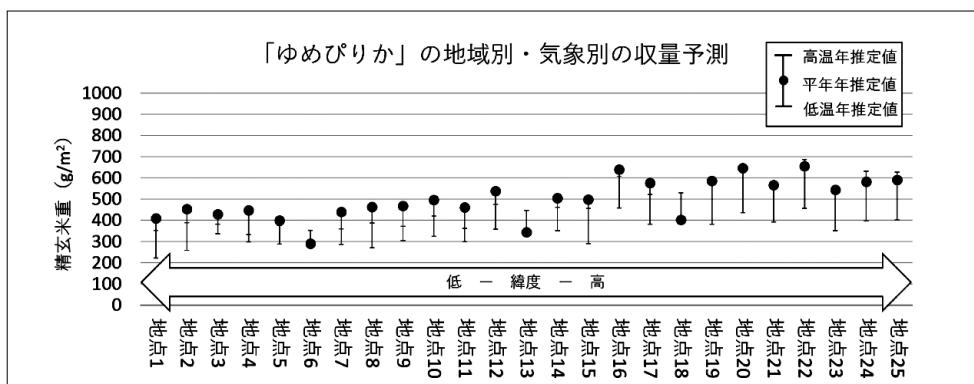


図9 ゆめぴりかの地点別・気象別の収量予測

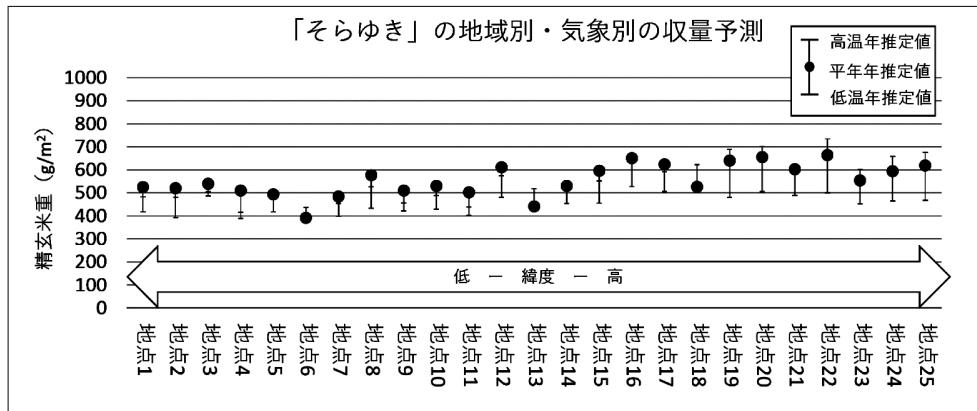


図10 そらゆきの地点別・気象別の収量予測

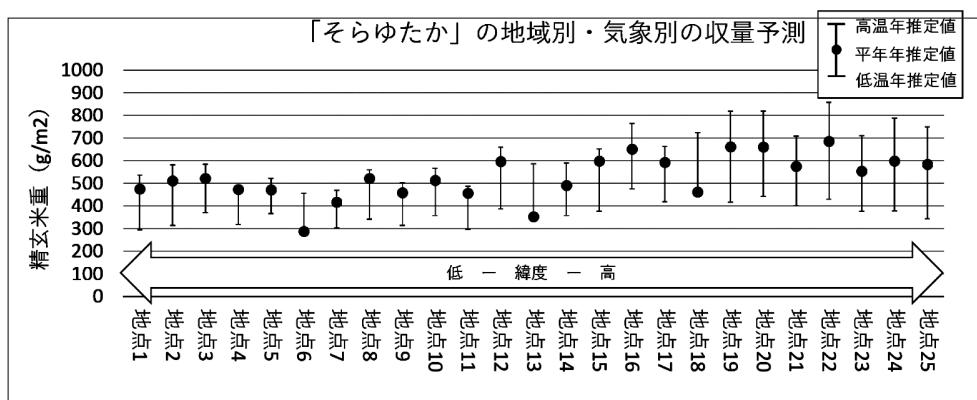


図11 そらゆたかの地点別・気象別の収量予測

一方で、全品種に共通して、地点6, 13, 18の平年の収量推定値がほかの地点の推定値と明らかに異なっていることがわかる。これは、今回の解析データに含まれていない要因（例えば地形、風データ）が影響したものと考えられる。また、欠測T法はどの程度の欠測率や欠測パターンに影響されるか、調査が必要な部分もあり、今後の検討課題としたい。

図12に、全地点平均の気象別予測結果を示す。そらゆきとそらゆたかは、気象変動があっても既存品種の予測収量をほ

ぼ上回る結果となった。また、そらゆきの方が、気象変動が収量に及ぼす影響を受けにくいことを示す結果となった。

## 6. おわりに

本研究では、欠測T法の解析ツールを作成し、生育・気象データを用いて、欠測処理方法の比較、ロバスト性の比較を行った。欠測T法を利用することで欠測処理作業が不要となり、その収量予測結果は、誤差精度やロバスト性において、既存の予測モデルでの予測結果と比較して、同程度もしくは良好であった。

また、水稻5品種の25地点における、気象変動を想定した収量予測を実施した結果、多収性として開発された新品種のそらゆき、そらゆたかについて、欠測T法を用いることで不完全かつ少ないデータ数でも精度良く収量が予測可能であり、その結果、これらの品種が多収性であることを確認することができた。

データ数が重回帰分析等では不十分な場合や、欠測が存在する不完全データの場合でも、欠測T法解析ツールを用いることで、精度良く収量が予測可能であり、品種特性の傾向を掴むことができることを確認した。欠測T法を使うことで、従来、専用ソフトによる予測システムの構築や解析作業に費

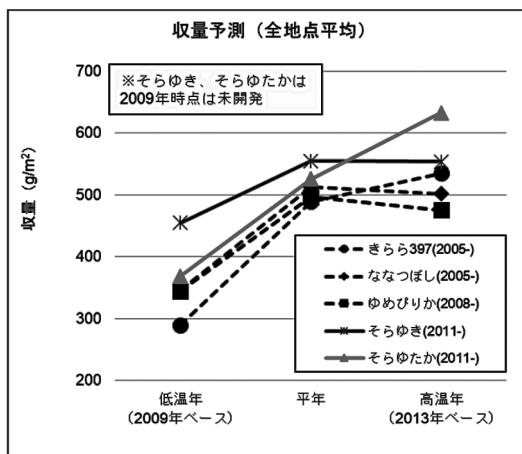


図12 気象別の収量予測（全地点平均）

やしていた労力・コストを新たな品種設計・開発に費やすことが可能となることから、欠測T法の利用については十分検討に資すると思われる。

本研究で作成した「欠測T法解析ツール」は、農業以外の分野でも活用可能であることから、今後の予定として、これまでデータの取り直しなどをしていた不完全データの有効活用のために、技術移転等を進める予定である。また、欠測T法の項目選択手法をさらに検討し、予測精度向上が可能かどうかを今後検討する。

## 謝辞

本研究を進めるにあたり、有限会社増田技術事務所 増田雪也氏、KTS & C 菊地富男氏、アマノ株式会社 鈴木真人氏にそれぞれ多くの助言を頂いた。記して感謝の意を表する。

## 参考文献

- 1) Horie et al : The Rice Crop Simulation Model SIMRIW and Its Testing in Modeling the Impact of Climate Change on Rice Production in Asia, R.B. Matthews,M.J. Kropff, D. Bachelet, and H.H. van Laar,Eds. CAB International, Wallingford, UK, ch.5, pp51-66,(1995a)
- 2) 田口玄一：目的機能と基本機能(6)－T法による総合予測，品質工学Vol.13.3, 品質工学会, pp 5 -10,(2005)
- 3) 鈴木真人：試して究める！品質工学 MTシステム解析法入門, 日刊工業新聞社 (2012)
- 4) 菊地富男：TS法, T法における推定精度の研究, 第14回品質工学研究発表大会論文集, 品質工学会, pp18-21, (2006)
- 5) 清水, 太田, 鶴田他：新SN比の研究(4), 第16回品質工学研究発表大会論文集, 品質工学会, pp422-425,(2008)
- 6) 増田雪也：T法における欠測データの活用に関する研究, 第20回品質工学研究発表大会論文集, 品質工学会, pp94 -97, (2012)
- 7) <http://www.cs.waikato.ac.nz/ml/weka/>
- 8) 神生, 飯田, 佐藤他：欠測データを用いたT法による水稻育種における収量予測, 第27回品質工学研究発表大会予稿集, 品質工学会, pp130-133, (2017)