

交通運輸技術開発推進制度
令和4年度業務実績説明書

深層学習を用いた高時空間分解能の
地表面温度プロダクトの改良と
道路等の都市インフラ分野への実装

令和5年3月
(株式会社 天地人)

研究成果要約

作成年月	令和5年3月
研究課題名	深層学習を用いた高時空間分解能の地表面温度プロダクトの改良と道路等の都市インフラ分野への実装
研究代表者名	株式会社天地人 百束泰俊
研究期間	令和4年12月1日～令和5年3月31日
研究の目的	気候変動による影響は、農業、社会基盤、エネルギーなど、幅広い分野に及ぶ。農作物の生産性や都市インフラの健全性は、気候変動が要因となり引き起こされる地表面付近の温度変化に大きく左右され得る。従来、地表面温度（以下、LST）の観測には、赤外放射計を搭載した低軌道衛星が用いられてきたが、この手法でのLST観測は、2日に1回程度と低頻度であるという課題があった。 そこで本研究では、静止衛星ひまわりの観測データを用いて日本域を高頻度に観測する高時空間分解能のLSTプロダクトの開発を行うとともに、都市インフラ分野への実装を行った。
研究成果の要旨	はじめに、静止衛星ひまわりに適用可能なアルゴリズムであるsplit window法を用いてLSTの推定と推定精度の検証を行った。本来、LSTとともに同時推定することが望ましいとされる地表面射出率としては、JAXAが運用する気候変動観測衛星「しきさい」（GCOM-C）のSGLIセンサに由来するプロダクトを利用した。結果、検証データとの相関係数にして0.95程度という高い推定精度が得られ、LST観測の時間分解能の向上を実現した。 次に、複数のLSTプロダクトと気象データによって構築したマルチモーダルなLST推定モデルを用いて静止衛星ひまわり由来のLSTの雲域の除去および補完、超解像度化を行った。結果、異なるプラットフォームによって観測されたデータでの補完であっても、雲域が原因となって引き起こされる観測値の誤差を低減できる可能性を示した。また、同じ衛星画像プロダクト間の変換である、GCOM-C由来のLSTプロダクトを用いた静止衛星ひまわり由来のLSTの高解像度化に成功した。一方で地上センサや解析プロダクトを用いた気温分布との相関評価としては一定の課題が見られた。地表面温度の補完に既知の気温情報が使えるとすれば、より詳細な土地利用及び地表面応答特性がわかるため、今後もより高度な補完アルゴリズム改良を検討する予定である。 以上によって、高分解能化と独自プロダクトの精度向上が図られ、ひまわり衛星由来の地表面温度プロダクトの社会実装が進むことが期待できる。なお、弊社が事業化している天地人コンパスによる漏水評価システムにおいても本取組で作成した独自プロダクトの活用を進めているところである。
知的財産権 取得状況	特になし
研究成果発表実績	論文発表：国内 0件、海外 0件 口頭発表：国内 1件、海外 0件 その他：都市インフラ分野へのデータ実装のひとつとして、漏水リスク評価サービスを展開中。（環境要因データ群の一つに地表面温度がある： https://prt看mes.jp/main/html/rd/p/0000000075.000045963.html）

研究開発の目的と実施体制

研究開発の目的

気候変動による影響は、農業、社会基盤、エネルギーなど、幅広い分野に及ぶ。農作物の生産性や都市インフラの健全性は、気候変動が要因となり引き起こされる地表面付近の温度変化に大きく左右され得る。従来、地表面温度（以下、LST）の観測には、赤外放射計を搭載した低軌道衛星が用いられてきたが、この手法でのLST観測は、2日に1回程度と低頻度であるという課題があった。


そこで本研究では、静止衛星ひまわりの観測データを用いて日本域を高頻度に観測する高時空間分解能のLSTプロダクトの開発を行うとともに、都市インフラ分野への実装を行った。

研究実施体制

本研究は、株式会社天地人単独による研究開発体制により実施した。

研究課題名
「深層学習を用いた高時空間分解能の 地表面温度プロダクトの改良と道路等の 都市インフラ分野への実装」
機関名及び研究代表者氏名
株式会社 天地人 代表研究者 百東 泰俊

また、社内体制図は以下のとおりである。



研究開発成果

1. 序論

本書は、令和 4 年度交通運輸技術開発推進制度にて実施した「深層学習を用いた高時空間分解能の地表面温度プロダクトの改良と道路等の都市インフラ分野への実装」についての成果をまとめたものである。

交通運輸技術開発推進制度は、安全安心で快適な交通社会の実現や環境負荷軽減等に資するイノベティブな技術を発掘から社会実装まで支援するもので、SBIR フェーズ 2 に位置づけられている。令和 3 年度に行ったフェーズ 1 の成果を踏まえつつ、さらなる地表面温度の時間分解能の向上と深層学習等による独自プロダクトとしての価値向上を目指し、業務を実施した。

近年、地球温暖化と都市化に伴い、都市部においてヒートアイランド現象が顕在化してきている。都市化の進む大都市では気温が長期的に上昇し、東京における年平均気温の上昇率は $3.3^{\circ}\text{C}/100$ 年となっている。

このヒートアイランド現象の主な原因として、人間活動から排出される人工排熱の増加や地表面被覆の人工化、都市形態の高密度化などが挙げられる。国土交通省では「ヒートアイランド対策大綱」(2013)に基づき、各種ヒートアイランド対策に関する様々な施策を実施しており、こうした取り組みの効果や長期的な気温の変化傾向をモニタリングすることが、今後の取り組みの策定等を検討するうえで非常に重要と言える。

本研究では、静止衛星ひまわりが取得する多様な観測データを活用し、ヒートアイランド対策や環境負荷軽減に向けた取り組みの基礎データとして利用可能な「地表面温度(Land Surface Temperature: LST)プロダクト」の開発を行うことを目的とする。

株式会社天地人は、上記の課題に対し、国立研究開発法人新エネルギー・産業技術総合開発機構が行う「2021 年度 SBIR 推進プログラム/フェーズ1」において、①静止衛星ひまわりの観測データを用いることでLST の時間分解能を大幅に向上させるとともに深層学習により雲域を除去した独自の LST プロダクトを作成することに成功するとともに、②高解像度な商用衛星画像等を活用した超解像処理により空間分解能を 100 m 以下とする見通しを得ていた。

今回のフェーズ2では、上記フェーズ1において開発した LST プロダクトの改良及び精度向上と、LST プロダクトを提供するシステムの試作、都市インフラ分野へのデータ活用・実装を行った。

2. 研究内容

2.1. 静止衛星ひまわりを活用することによるLST 時間分解能の向上と、その推定精度向上

LST 推定精度への影響が大きい地表面射出率の設定方法の改良、GOES-16・17 向け LST 推定アルゴリズムおよび他の手法による LST 推定アルゴリズムの実装と検証を行い、LST プロダクトの精度向上を試みた。

①LST推定とは

衛星に搭載された熱赤外線センサのバンド*i*により観測される放射輝度 I_i は、地表面からの放射輝度成分 I_{si} と大気からの上向き放射輝度成分 I_{ai} の和として、以下のように放射伝達方程式でモデル化される。

$$I_i = \tau_i(\theta)I_{si} + I_{ai}(\theta)$$

ここで、 τ_i はバンド*i*における大気透過率、 θ は観測角である。さらに、上記モデルのうち地表面からの放射輝度成分 I_{si} は以下のように表現される。

$$I_{si} = \varepsilon_i B_i(T_s) + (1 - \varepsilon_i) \frac{F_i}{\pi}$$

ここで、 T_s が地表面温度を表し、 ε_i 、 B_i および F_i はそれぞれ、バンド*i*における地表面射出率、プランク関数および大気から地表面へ向かう下向き大気放射照度である。
衛星からの地表面温度 (Land Surface Temperature: LST) 推定とは、上記のモデルに基づいて熱赤外バ

ンドの衛星観測値から地表面温度 T_s を推定することであり、推定法には大きく分けて解析的な手法と統計的な手法がある。

②解析的LST推定とは

解析的手法では、複数の熱赤外バンドの観測値に対して上記モデルに基づいて連立方程式を立て、反復計算により解くことによって地表面温度 T_s を求める。この連立方程式の解法として種々の解析的アルゴリズムが提案されている。この連立方程式において、大気パラメータ (τ_i 、 I_{ai} 、 F_i) を、放射伝達コードによるシミュレーション結果や数値気象モデルのような外部データ等を利用して既知量とすれば、残る未知数は地表面温度 T_s と地表面射出率 ε_i となる。しかしながら、地表面射出率 ε_i は波長 i に依存するため、この連立方程式は式の本数より未知数が常に一つ多い劣決定問題となり解くことができない。各種解析的アルゴリズムでは、この連立方程式を求解可能とするために、様々な仮定や近似をもとにした式を追加する手法が取られており、この部分が各々の解析的アルゴリズムにおける独自性の一つとなっている。

③統計的手法とは

統計的手法では、複数の熱赤外バンドで観測された輝度温度やこれらの輝度温度差と地表面温度の間の統計的関係から構築された重回帰式によって地表面温度 T_s を求める。これは、一般的にsplit window法と呼ばれる手法であり、はじめに海面温度 (Sea Surface Temperature: SST) 推定において実績を上げたあと、LST推定への応用研究が進んだ。split window法を用いた精度の良いLST推定のためには、大気効果をよく表現できる重回帰式の構築およびその係数セットの導出と、妥当な地表面射出率の事前取得が重要である。

④本研究における技術的アプローチ

本研究におけるHimawari-8 LST推定では統計的手法であるsplit window法の適用を念頭に、既存のLST推定アルゴリズムの調査・選定とその実装を行っている。split window法の適用を念頭おいたのはその計算量の少なさが故である。静止気象衛星からは、広大な観測領域から膨大な量のデータが時々刻々と得られる。その静止気象衛星のデータから実時間でLSTを計算するためには計算量の少ないsplit window法が適していると考えられる。また、split window法が静止気象衛星のみならず極軌道衛星へ適用した先行研究や実運用実績が豊富であることも本研究においてsplit window法を採用する理由の一つである。

split windowアルゴリズムをHimawari-8に適用する場合、次の三つが候補となる。まずMoriyamaのアルゴリズム^[1]とYamamotoらのアルゴリズム^[2]である。これらは、Himawari-8向けLST推定への適用を目指して開発されたものであり、このうちMoriyamaのアルゴリズムは厳密には解析的アルゴリズムの分類であるが、アルゴリズムの一部としてsplit window法に基づく重回帰式を連立方程式に含んでいる。三つ目はGOES-16・17/ABIアルゴリズム^[3]であり、これは米国の静止気象衛星GOES-16号および17号向けに開発されたアルゴリズムである。Himawari-8向けではないがLST推定に用いる熱赤外バンドに関しては、GOES-16・17搭載のABIセンサとHimawari-8搭載のAHIセンサは同じであるためGOES-16・17/ABI LST推定アルゴリズムはHimawari-8への流用が可能であると考えられる。

今回、これらの三つのアルゴリズムのうちMoriyamaのアルゴリズムのsplit window法の重回帰式部分のみを用いることとした。この理由としては重回帰式が最もシンプル (パラメータ数および係数の切り替え基準が最少) であることと、必要とする外部データが最も少ないというアルゴリズムの単純さからである。

¹Masao Moriyama, GCOM-C1/SGLI Land Surface Temperature Product Algorithm Theoretical Basis Document, ver. 2, 2020.

² Yuhei Yamamoto, Hirohiko Ishikawa, Yuichiro Oku, Zeyong Hu, An Algorithm for Land Surface Temperature Retrieval Using Three Thermal Infrared Bands of Himawari-8, Journal of the Meteorological Society of Japan. Ser. II, 96B, 59-76, 2018.

³ Tim Schmit, Mat Gunshot, Gang Fu, Tom Rink, Kaba Bah, GOES-R Advanced Baseline Imager (ABI) Algorithm Theoretical Basis Document for Land Surface Temperature, ver.2.5, 2012.

⑤フェーズ1の結果

LST推定にはMoriyamaアルゴリズムを採用し、アルゴリズムの入力データの1つである地表面射出率には簡便に一律0.98の固定値を設定していた。地表面射出率0.98とは植生の射出率を想定したものであり湿潤な日本国内における非都市域においてHimawari-8の観測画素中（直下において2[km]分解能）に占める植生の割合が多いとの仮定に基づく。Moriyamaアルゴリズムの入力データのもう1つであるひまわりデータには、千葉大学環境リモートセンシング研究センター（the Center of Environmental Remote Sensing (CEReS), Chiba Univ.）により公開・配布されている、ひまわり8号精密幾何補正済みグリッドデータVer.2^[4]^[5]から取得したband13およびband15のデータを採用した。

LST推定精度の検証には米国NASAが運用する地球観測衛星Terra/MODISのLSTプロダクトであるMODIS Land Surface Temperature/Emissivity Daily L3 Global 1 km Ver.6.1プロダクト（MOD11A1）を用いた。以下、MOD11A1のLSTをMODIS LSTと表記。このうち2021年の雲域の少なかった、4/21、8/5、10/3のMOD11A1プロダクトを検証データとして採用しHimawari LSTとMODIS LSTを比較している。

Himawari-8 LSTとMODIS LSTの間の相関係数は0.95～0.98、RMS誤差は1.6[K]～2.2[K]、バイアス誤差は1.0[K]～1.7[K]であった。下図に一例として、4/21の検証セットに対する、Himawari-8 LSTとMODIS LSTの1対1プロットと精度評価指標の算出値、Himawari-8 LSTとMODIS LSTの差のヒストグラム、Himawari-8 LST画像、MODIS LST画像、および両者の差画像を示す。




図 2.1-1 フェーズ1におけるHimawari-8 LST推定精度の検証結果（4/21,2021）

⁴ Hideaki Takenaka, Taiyou. Sakashita, Atsushi Higuchi, Teruyuki Nakajima, Geolocation Correction for Geostationary Satellite Observation by a Phase-Only Correlation Method Using a Visible Channel, Remote Sensing, 12(15), 2472, 2020.

⁵ Yuhei Yamamoto, Kazuhito Ichii, Atsushi Higuchi, Hideaki Takenaka, Geolocation Accuracy Assessment of Himawari-8/AHI Imagery for Application to Terrestrial Monitoring, Remote Sensing, 12(9), 1372, 2020.

⑥フェーズ1の課題と、フェーズ2における解決方法

フェーズ1の解析において推定されたHimawari-8 LSTの傾向は、非常に簡便なアルゴリズムでのLST推定でありながら検証データのMODIS LSTとよく合っていることが確認された。しかしながら推定結果からは、Himawari-8 LSTがMODIS LSTに対して過大に推定される傾向が見られ、アルゴリズムには改良の必要性が生じた。具体的課題は、フェーズ1の検証でMoriyamaアルゴリズムの入力データとして、Himawari-8の輝度温度にはband13とband15それぞれの値を用いたのに対して、地表面射出率にはband13とband15に対して一律0.98の固定値を設定しており、これがHimawari-8データに基づくLSTの過大推定の原因の一つだと考えられた。

そこでフェーズ2では、Moriyamaアルゴリズムを用いたLST推定精度の向上を目指し、フェーズ1のアルゴリズム適用時に一律0.98の固定値を設定していた地表面射出率への外部データの適用を試みた。地表面射出率の外部データとしては、例えばTerra/MODISのMOD11A1プロダクト^[6]やJAXAが運用する気象変動観測衛星GCOM-C/SGLIのGCOM-C/SGLI L2 Land surface temperature Ver. 3^[7]などがある。これらのプロダクトについて地表面射出率推定の入力データとなるバンドの帯域と時空間分解能などの特徴を、Moriyamaアルゴリズムに用いるHimawari-8のバンド特性とともに下表に示す。

表 2.1-1 地表面射出率を含むLSTプロダクトを有する衛星とその特徴

衛星 センサ	バンド チャンネル	帯域 [μm]	空間分解能 [km]	時間分解能
Himawari-8/AHI	Band13	10.30 - 10.60	2.0	2.5 min
	Band15	12.20 - 12.50		
Terra/MODIS	Band31	10.78 - 11.28	1.0	1 day
	Band32	11.77 - 12.27		
GCOM-C/SGLI	T1	10.43 - 11.17	0.25	2 days
	T2	11.63 - 12.37		

地表面射出率は本来、独自のアルゴリズムを用いてLSTとともに同時推定することが理想的である。しかし今回、Himawari-8データを入力データとし、Moriyamaアルゴリズムを用いてLSTのみを推定することを目的としている。この場合より良いLSTの推定結果を得るためにはMoriyamaアルゴリズムの入力データに用いるHimawari-8のband13とband15の帯域と、地表面射出率外部データが生成されたバンドの帯域ができる限り一致していることが求められる。上表から明らかな通り、空間分解能が高くHimawari-8 LSTの推定に用いられるband13とband15と最も近い帯域を持つのはGCOM-C/SGLIのチャンネルT1とT2である。したがって、Moriyamaアルゴリズムの入力データとして用いる地表面射出率には、GCOM-C/SGLI由来のプロダクトを採用することとした。以下、SGLI地表面射出率と表記する。

⑦フェーズ2の実装と検証結果

SGLI地表面射出率データはJAXAが運用する地球観測衛星データ提供システムG-Portalからダウンロードし、データ詳細に従ってDN値から物理量に変換した。また同じくG-Portalで入手可能なツールキット、SGLI 地図投影・GeoTIFF出力ツール (Ver.1.2) を使い、EQA (Sinusoidal Equal Area) から緯度経度直交座標系へ再投影した。さらに、ひまわりグリッドとの重ね合わせのためにSGLI地表面射出率 (0.25[km]分解能) をHimawari-8画素相当 (2[km]分解能) に平均化した。

Moriyamaアルゴリズムの入力データは、Himawari-8のband13とband15の輝度温度、およびGCOM-C/SGLIのチャンネルT1およびT2の地表面射出率であり、チャンネルT1およびT2の地表面射出率をそれぞれband13とband15の地表面射出率として適用した。

⁶ Zhengming Wan, MODIS Land-Surface Temperature Algorithm Theoretical Basis Document (LST ATBD), ver. 3.3, 1999.

⁷ JAXA, GCOM-C “SHIKISAI” Data Users Handbook, 2018.

LST推定値はband13およびband15の輝度温度に基づき、画素ごとに低温・高温乾燥・高温湿潤の三つのcaseの判定を行い、split window法の重回帰式の係数セットをcaseごとに切り替えながら算出した。

Himawari-8 LSTの検証用データとしては、フェーズ1同様にTerra/MODISのMOD11A1プロダクトを用いた。ひまわりグリッドとの重ね合わせのために緯度経度直交座標系へ再投影した上で検証に利用。分解能の異なるMODISとHimawari-8の画素同士のマッチアップのためにMODIS LST (1[km]分解能)をHimawari-8画素相当 (2[km]分解能)に平均化した。

検証データは、2021年のMOD11A1プロダクトの中から雲域の少なかった4/21、8/5、10/3のMOD11A1プロダクトを用いた。Himawari-8 LSTの算出において用いるSGLI地表面射出率としては、検証データとして用いる4/21、8/5、10/3のMODIS LSTの観測時刻と近い昼間のデータを用いた。さらにHimawari-8 LSTとMODIS LSTの両者の観測時間差が±20分以内の画素をマッチアップ対象画素として選択し、比較・検証に用いた。

4/21、8/5、10/3 の各検証セットにおける、Himawari-8 LST と MODIS LST の1対1プロットと精度評価指標の算出値、Himawari-8 LST と MODIS LST の差のヒストグラム、Himawari-8 LST 画像、MODIS LST 画像、および両者の差画像を示す。




図 2.1-2 Himawari-8 LST推定精度の検証結果 (4/21,2021)




図 2.1-3 Himawari-8 LST推定精度の検証結果 (8/5,2021)




図 2.1-4 Himawari-8 LST推定精度の検証結果 (10/3,2021)

下表には、フェーズ1とフェーズ2でのLST推定における各精度評価指標の平均値の比較結果を示す。精度評価指標について MODIS LST と Himawari-8 LST 間の相関係数は 0.93～0.97、RMS 誤差は 1.7 [K]～2.4 [K]、バイアス誤差は -0.4 [K]～1.9 [K]であった。外部プロダクトであるGCOM-C/SGLI地表面射出率を利用した非常に簡便なアルゴリズムによって推定された Himawari-8 LSTは、フェーズ1よりも特に Biasにて顕著な精度向上が図られていることが確認できた。

表 2.1-2 フェーズ1とフェーズ2でのLST推定における各精度評価指標の平均値

	相関係数	RMSE [K]	Bias [K]
フェーズ 1	0.9472	2.0289	1.2554
フェーズ 2	0.9457 (フェーズ 1 と同程度)	2.0398 (フェーズ 1 と同程度)	0.7827 (顕著な精度 向上)

2.2. 深層学習等による独自プロダクトの開発

商用衛星画像からより詳細かつ高スペクトル分解能のデータを取得し、雲除去のさらなる精度向上および超解像処理を行い、実運用に耐えられるレベルの推定精度および分解能を試みた。

①フェーズ1の実施概要と課題

圃場におけるモニタリングや都市域での熱環境把握におけるLSTプロダクトの利活用を想定し、雲域の除去および補間、超解像、の二つの処理を行った。前項までで説明したHimawari-8から算出したLSTプロダクトを主に用いて、高時間分解能を持つデータ特性を生かす試みである。解析ではHimawari-8の近赤外線バンドの画像から作成された大量のLSTプロダクトから機械学習を用いたモデルを作成している。モデルの概要については以下の通りである。

雲域除去においては、二つの機械学習モデルを作成し比較検討および評価を行った。一つ目は敵対的生成ネットワーク (Generative Adversarial Network: GAN) 用いたモデルで、複数の画像から計算された長期的なLST分布特性を学習し、任意の画像における雲域から地表面温度分布の推定を行う。二つ目はAutoencoderを用いたモデルで、LST画像から特徴量を抽出しノイズとなる雲域を除去した画像を生成するものである。

超解像においては、低軌道衛星から得られた高空間分解能のLSTプロダクトを気候変動観測衛星しきさい (GCOM-C) より取得し、GANの機械学習モデルを作成した。機械学習により雲域を除去した高空間分解能のLSTプロダクトを作成できることを確認した。

これら方法の課題としては、このモデルで作成したプロダクトは対応する正解データ (Ground Truth: GT) が存在しないため、具体的にどの程度正確な予測を行ったかが不明瞭であることが挙げられる。また本モデルで推定したLST分布は過去の温度分布に基づいて推定を行っているため、気候変動や局所的な異常気象といった変化に対して強固なモデルとは言い難い。そこで今回のフェーズ2ではこれらの問題点を補うことが可能なよりロバストなモデルを作成することを目指した。




図 2.2-1 雲除去および高解像度化に用いた敵対的学習を用いた解析のフロー

②フェーズ2の実施概要

昨年の問題点であったLSTプロダクトの精度評価の実施とよりロバストなLST推定モデルの作成を行う。昨年度は機械学習を用いた統計的手法を用いて推定を行ったのに対して、フェーズ2はその他異なるデータソースを用いてマルチモーダルなモデルを構築することを目指した。本解析では異なるプラットフォームおよび解析手法で算出されたデータと比較することで、正確な雲域の補完および高解像度画像の作成を行った。解析の流れは以下の図に示すが、大きく3つのパート：データ取得、データ特性取得、モデリング、に分割される。昨年度はモデルの作成に重きを置いていたのに対して、今年度はLSTのデータ特性を異なるデータと比較することでより詳細に可視化及び数理的な理解を深める。




図 2.2-2 フェーズ2のデータ解析フロー

温度を取得する手段は、実際にセンシングを行う場合と、物理モデリングを用いて算出する2通りに大別される。ここでは前者は衛星から取得したデータ（GCOM-C）および地上から取得したデータ（Amedas）をセンシングデータとして用いた。また、解析プロダクトとしてGPVデータとSpireのデータを利用することとした。SpireはGPSの信号データと物理モデリングを用いているため2つのデータ特性を併せ持つデータと言える。それぞれのプロダクトの詳細な説明は割愛するが、それぞれ画像として扱えるラスタデータ（GCOM-C、GPV、商用衛星）とテーブルデータ（Spire、Amedas）があり、異なるデータ形式であるため、空間的なデータ補完と時系列データのデータ補完にそれぞれ用いることが可能となる。

- Spaceborne LST product（地表面温度）：GCOM-C（★）、商用衛星
- 解析プロダクト（気温）：GPV（★）、Spire
- 地上センサ（気温）
- Amedas（★）

本資料では紙面の都合上★印を付けた解析結果について示す。
なお、商用衛星については土地被覆の把握のために用いている。

③フェーズ2の実施結果（補完による雲除去：GPV）

GPVとは、気象庁の気象予測モデルから計算された予測値を指す。GPVには様々な種類があるが本解析では局地数値予報モデル(LFM)による予測値を使用した。また本解析ではLFMを、ひまわりLST画像の雲除去を目的として利用した。

探索的データ解析の結果からLSTデータにおいて雲がかかっている場所の温度が著しく低下していることがわかったため、LSTデータの雲がかかっている場所についてLFMのデータを埋め込む。対処エリアを2km四方のグリッドに分割し、予報雲量が80以上のグリッドについてLFMの気温データを埋め込んでいる。




図 2.2-3 補完前のHimawari画像




図 2.2-4 GPVを用いたHimawari画像補完結果

本手法の強みは、ひまわりの雲によって本来よりも低い温度で観測された地域の値を、GPVによって補完することで観測値の誤差を低減できることだと考えられる。また、GPVは30分ごとに予報画像があるため、30分ごとに観測しているひまわりとの相性も良い。上の結果はあくまでも2021/02/02/00:00時点の結果であるが、補完後の画像に不自然な温度分布は見られず本手法の実用性が示唆された。

④フェーズ2の実施結果（予測による雲除去：Amedas）

Amedasのデータ点は全国で1300点ほど存在するが、各観測所はおよそ17km間隔（温度は21km間隔）で設置しており、Himawari LSTの解像度 2km/pixよりも低い。しかし、地上センサのデータであり、10分おきのデータを24時間取得しており雨天時も利用可能なため、雲被覆によるLSTの補完に用いることができる。以下に示す図はHimawari LST mapに対して、Amedasの各観測所の値をプロットした後に空間的に値を補完して温度分布を取得したものである。これにより雲の影響を受けやすいHimawari LSTのデータに加えてAmedasの気温情報を用いることで空間的な分布を取得することができる。Amedasで利用している変数は気温データであるため地表面温度とは厳密には異なることに留意されたい。なお、気温データと地表面温度は非常に高い相関と一定の時定数による応答が知られているため、一方を取得することで他方の推定も容易にすることが可能となる。




図 2.2-5 AmedasデータとHimawari LST mapを利用した空間補完後のLSTマップ

下図はHimawari LSTの値とAmedasの過去12時間分のデータを取得し、線形回帰を行うことで温度分布の予測をした結果である。赤が予測の分布で青が実際の温度分布を表している。図に示す通り正確な予測を行うことが可能であることが分かった。一方で12月26日付近の温度分布変化のような急な天候不順による温度分布の乱れに関しては過去の時系列データを参照して予測をしている性質上、正確に予測を行うことは難しい。




図 2.2-6 AmedasデータとHimawari LST mapを利用した温度分布の予測結果

⑤フェーズ2の実施結果（高解像度化：GCOM-C）

GCOM-C画像を可視化すると下図のようになる。可視化において地表面温度分布を深紅から濃紺のグラデーションで表し、温度範囲は摂氏-21度以上35度以下の範囲とした。図中の濃紺の部分は河川や海洋である。




図 2.2-7 GCOM-C画像とその地表面温度分布及び2021年12月の最高最低気温の推移

GCOM-C画像はhimawari画像の64倍のピクセル数を持つ。そのため、生成元のhimawari画像の各ピクセルを64分割して、中央の4ピクセルは元の値を代入し、外側に向かって隣接するピクセルの値に近づくように線形補完を行った。具体的には下図のような操作である。




図 2.2-8 Himawari画像のピクセル数を増やす

生成した画像は以下の通りである。2021/12/31分は全領域が雲被覆により低温の分布であったため除外した。




図 2.2-9 線形補完した2021年12月の気温変化

Himawariの画像データを用いながら、線形補完によりGCOM-C相当の超解像化を行う基礎的なコードを作成した。比較的単純な処理を理解しやすい形で実装しており、より高度な方法を使う場合にカスタムしやすいコードとなった。線形補完をベースとする場合、LSTが連続的に変化し、上図の地表面温度変化にも見れるように輪郭がぼやけたような画像が生成される。これらを、各点の地表面温度が不連続なGCOM-CのLSTデータ群を用いた係数テーブルなどを別途作成し、補正することでより正確な地表面温度分布を得ることができる。さらに、フェーズ1で実施した機械学習（LST分布は過去の温度分布に基づいて推定を行っているので係数テーブルと実質的に似たような効果）も有効だと思われる。

2.3. LST データ提供システムの試作

①LST データ提供システムの試作の概要

LST プロダクト提供開始を見据え、天地人コンパスへの実装に向けた試作・設計を行った。加えて、インフラ事業者、エネルギー事業者、不動産土地取引業者、農業関連事業者(種苗メーカー、栽培支援ソリューション提供企業等)を対象としたサービス導入に向け、LST データの具体的な活用事例について調査した。なお、天地人コンパスとは、株式会社天地人が提供する「土地評価サービス」である。

データ取得から、天地人コンパス実装までの一連の流れを示す。雲除去には雲被覆部の温度取得ができるデータをもとに被覆部の同定及び補完を行う。高解像度化に関しては雲除去済みのデータから解像度が高いGCOM-Cを用いて高解像度画像の生成を行うという流れとなる。




図 2.3-1 Himawari LSTプロダクトの作成フローの概観図

②LST データ活用イメージ（LSTをそのまま閲覧する場合）

株式会社天地人が提供する「土地評価サービス」である天地人コンパスでLSTデータを表示するために、各種LSTデータ提供元からのLSTデータ取得を自動化するパイプライン化を行った。今後、取得したLSTデータを天地人コンパス上に表示する環境を構築していく予定であるが、現時点で想定する表示画面を下図に示す。




図 2.3-2 天地人コンパス上でのLSTデータ表示画面（仮）

③LST データ活用イメージ（LSTを高度に利用したサービス）

LSTを高度に活用したサービスとして、生態系修復、火事、都市部のヒートアイランド現象、道路整備とインフラモニタリング、道路の老朽化対策（アスファルト舗装の損傷原因と温度応力によるひび割れ）、水道管路の老朽化とリスク評価、再生可能エネルギー等を識別し調査を行った。紙面の都合上詳細は割愛するが、ここでは実際に事業化に結び付いている水道管路の漏水リスク評価について紹介する。




図 2.3-3 地表面温度情報を活用した漏水リスク評価サービス「天地人コンパス宇宙水道局」

「天地人コンパス 宇宙水道局」は、水道管の漏水リスク管理業務システムであり、複数の地球観測衛星から漏水に影響を及ぼす環境要因のデータ群（**地表面温度**、光学画像、気象データ、植生変化、SARなど）と、水道管の材質、使用年数、漏水履歴など水道事業者が保有する水道管路のデータを組み合わせ、天地人独自のアルゴリズムを基にAI技術で解析することで、約100m四方の地区ごとに漏水リスクを評価する。衛星観測に基づく、面的な地表面温度は、本サービスにおける重要なインプット情報となっている。

3. 結論

静止衛星ひまわりの観測データを用いて日本域を高頻度に観測する高時間分解能のLSTプロダクトを開発するとともに、静止衛星ひまわりの観測データと複数種類のLST、気象データを組み合わせることでLSTプロダクトの高空間分解能化を目指した。

本研究で開発した独自の地表面温度プロダクトは、高時空間分解能を必要とする多くの分野において社会実装が進むことが期待されている。弊社が事業化している天地人コンパスや天地人コンパス宇宙水道局においても本取組で作成した独自プロダクトの活用を進めていく。

4. 知的財産権取得状況 特許出願なし。

5. 研究成果発表実績

1) 論文発表

論文発表：国内 0件、海外 0件

2) 口頭発表

口頭発表：国内 1件（第7回交通運輸技術フォーラム）、海外 0件

3) その他（研究内容報告書、機関誌発表、プレス発表等）

天地人コンパスの公開：<https://prtimes.jp/main/html/rd/p/000000066.000045963.html>

6. 参考文献

概要ページ下部にそれぞれ示す。

以上