

「富岳」成果創出加速プログラム
 防災・減災に資する新時代の大アンサンブル気象・大気環境予測
 2021年度成果発表会

「深層学習を使った気象シミュレーション代理モデルの可能性」

	データ同化 w/ 物理モデル	深層学習
理論的根拠	ベイズ統計学に基づいた最尤推定	ベイズ統計学に基づいた最尤推定
主な計算方法	アンサンブルによる誤差推定、あるいは勾配法による最適化	勾配法による最適化(気象学でいう4次元変分法とほぼ同じ)
やってくれること	ビッグデータの内挿・外挿	ビッグデータの内挿・外挿
解を収束させる方法	支配方程式(物理学)による拘束	膨大な入力データによる力業
観測データの充足度	推定する変数に比べて極めて疎	推定する変数よりもずっと密
利点	物理モデル・ドリブンの予測	予測計算がとにかく速い
欠点	物理モデルを作り、動かさないと何もできない	予測や推定の根拠が分かりにくい

関山剛 (気象研究所)

2022年3月11日オンライン開催

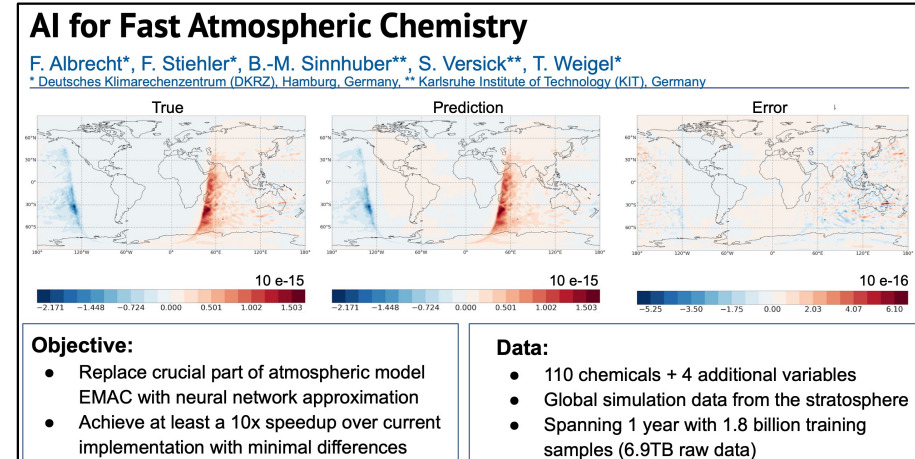
気象学と深層学習

気象学における深層学習の利用法

- 観測データの処理 (人力を超えるビッグデータ処理)
- 衛星画像・レーダー画像・AMeDAS降水量の内挿/外挿
- 衛星画像で台風の強度推定 (=全自動ドボラック法)
- 衛星画像から台風の種を抽出
- レーダー画像から風速場アノマリーの検出
- 観測データの分類・品質管理
- マニュアル化された作業の代替
- 気象電文の全自動作成
- 天気図への前線記入自動化
- 客観解析値の分類・アノマリー抽出・未知の相関の発見

気象予報に使える深層学習


- ナウキャスト
- 数時間程度なら観測データの外挿で天気予報は可能
- 予報ガイダンスの高精度化
- 現状の予報ガイダンスも地点固定の機械学習ダウンスケーリングといえる
- **代理モデル (Surrogate Modeling)**
 - 物理モデルの代わりに深層学習で物理プロセスを計算
 - 物理モデルに比べて深層学習は予測計算が軽いことを利用
例：放射伝達、雲物理、化学反応系の代理計算
 - アンサンブル予報の代理で予報誤差を推定



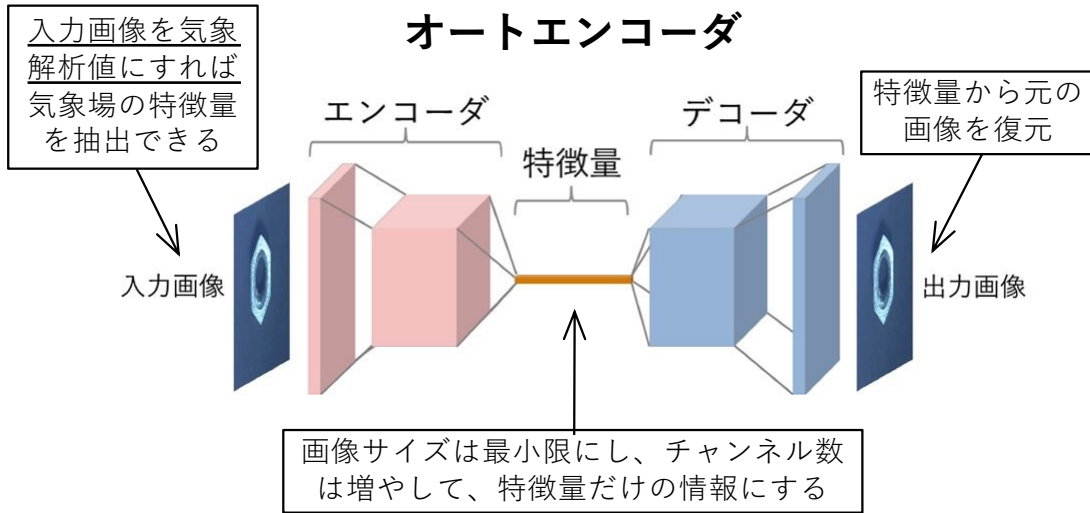
MetNet: A Neural Weather Model for Precipitation Forecasting

Casper Kaae Sønderby*
 Lasse Espenholt
 Jonathan Heek
 Mostafa Dehghani
 Avital Oliver

GOOGLE RESEARCH




物理モデルの出力を教師にする



<https://jp.mathworks.com/discovery/autoencoder.html>

オートエンコーダの処理例

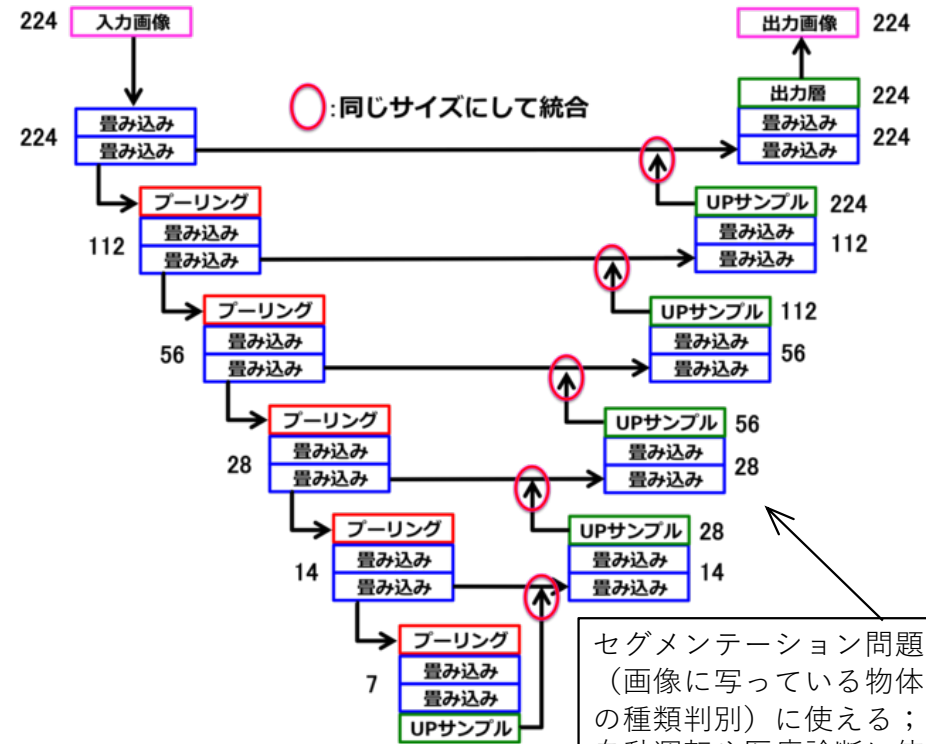


https://sinyblog.com/deaplearning/auto_encoder_001/

差分を取ればアノマリー検出に使える

U-net

- オートエンコーダの一種だが、エンコード過程からデコード過程へ同じ解像度の情報を流して結合させる
- 特徴量の位置情報をエンコーダに渡すことができる




セグメンテーション問題 (画像に写っている物体の種類判別) に使える; 自動運転や医療診断に使われているが、物理モデルを教師にすれば気象場の地域特性を学習できる

<https://lp-tech.net/articles/5Mleh>

物理モデルの出力を教師にする

超解像技術

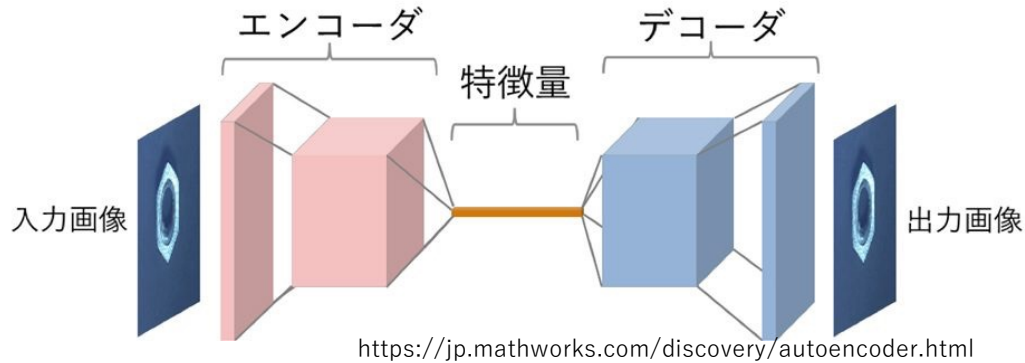


↑ (上図) 超解像のモデル構造


↓ (下図) オートエンコーダの構造

} ほぼ同じ


違いは入力画像の解像度を超えて出力画像をデコードすること



超解像技術の例



<https://arxiv.org/abs/2002.00580>



from FSRNet: End-to-End Learning Face Super-Resolution with Facial Priors

この技術は気象場のダウンスケーリングに利用可能；地形依存の細かな大気の構造は大量の物理モデル出力で学習させる

例えば、超解像で気象場をダウンスケーリングしてみる

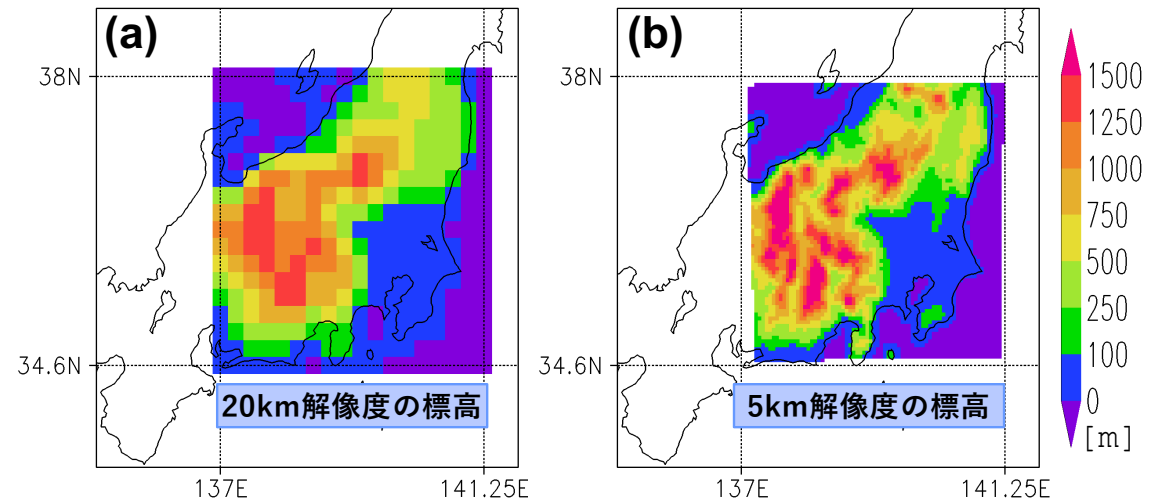
代理モデルによる気象場ダウンスケーリング

目指すのは物理モデルを教師にしたダウンスケーリング用代理モデル

- 気象現象は数千kmから数mまで階層構造を成す
 - 再現したい現象スケールに合わせた解像度のモデルが必要
 - しかし高解像度モデルはとにかく計算が重い
 - CFL条件の下では計算負荷は水平解像度比の3乗で増加
- どうしても解像度を高くしたい時は領域モデルを使う
 - 計算領域（ドメイン）を限定する
 - ドメインの外枠部分の気象場は低解像度モデルから時々刻々受け取って計算を進める
 - この入れ子構造的な計算手法が**力学的ダウンスケーリング**
 - ドメインは狭くとも、物理モデルを動かすのでやはり重い
 - 地形依存の気象現象を再現したいがために需要は大きい
- あるいは統計的な方法でなんとかする
 - これが**統計的ダウンスケーリング**
 - 重回帰法やそれに類する手法が多い → 計算が軽い
 - 観測地点毎の統計だから、広範囲の変換は苦手
 - 広範囲な格子点情報も欲しい
- 超解像で代用できないか（**深層学習ダウンスケーリング**）
 - 超解像：本来は不鮮明な画像の修復（補間）技術
 - 2種類の水平解像度のモデル出力をペアにして教師データとすれば、学習後に全格子点の値をダウンスケーリング可能
 - 一度学習してしまえば変換計算はとても速い
 - ただし学習プロセス計算はとてつもなく重い

実験設定

- 気象庁全球GPV(水平解像度20km)を気象庁メソGPV(水平解像度5km)に変換してみる
- ドメインは以下の範囲（富岳ではなく普通のゲーム用GPUを利用したのでこの広さが限界）
 - 18×18グリッドを72×72グリッドに変換
- 学習期間は3年、テスト期間は1年（時間間隔は6時間）



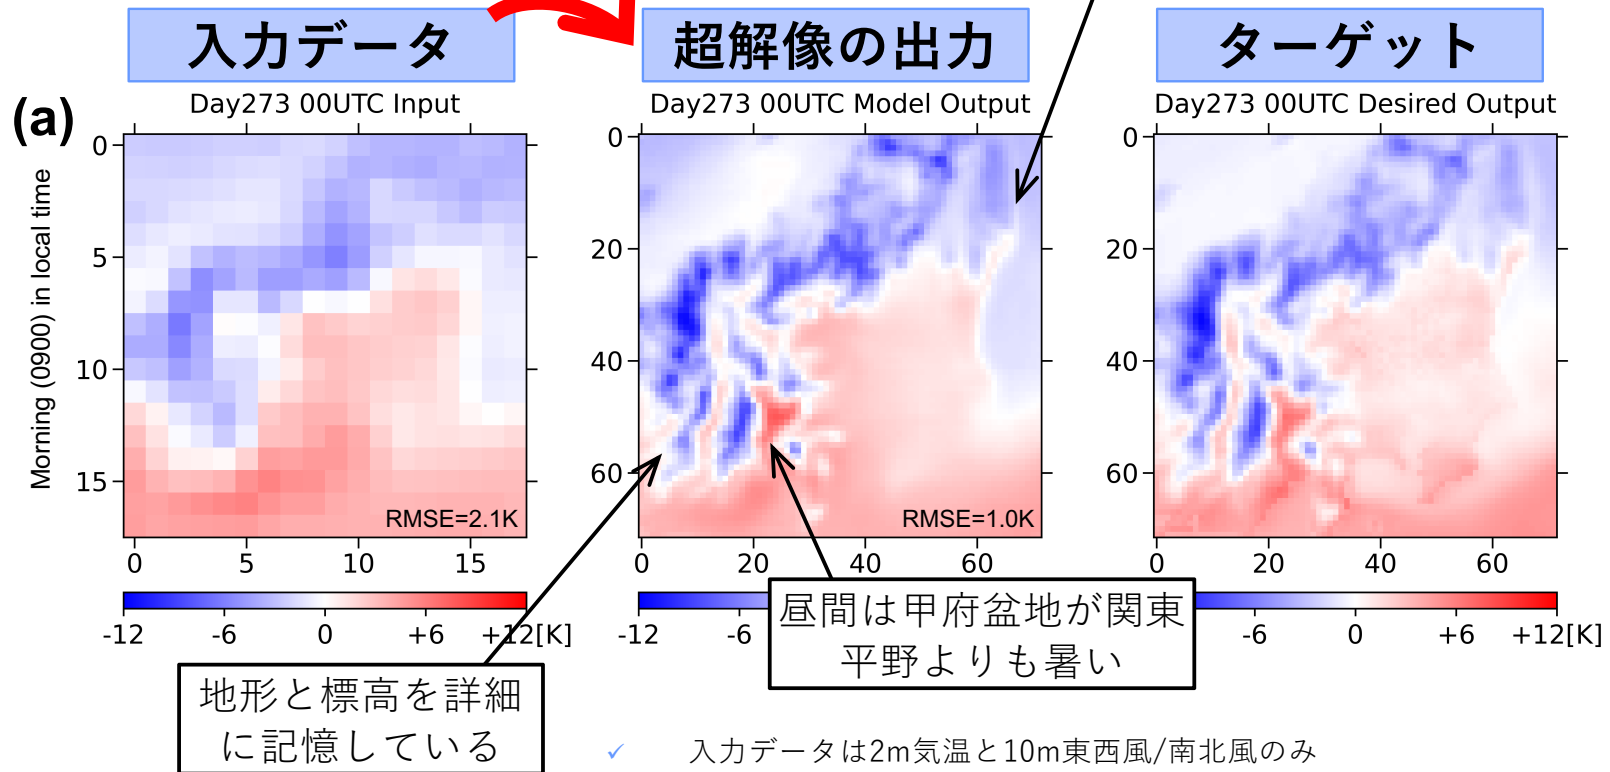
Sekiyama, T. T. (2020): Statistical Downscaling of Temperature Distributions from the Synoptic Scale to the Mesoscale Using Deep Convolutional Neural Networks, *arXiv:2007.10839*.

代理モデルによる気象場ダウンスケーリング：気温場の場合

昼間(9AM)の場合

使ったニューラルネットワークはノーマルな14層モデル

海面の位置を正確に記憶




- ✓ 入力データは2m気温と10m東西風/南北風のみ
- ✓ 気温は領域平均(GSM側)からの偏差に変換
- ✓ 上図は訓練データではなくテストデータの変換結果なので、深層学習システムはターゲット(正解)を知らない

代理モデルによる気象場ダウンスケーリング：気温場の場合

夜間(9PM)の場合

使ったニューラルネットワークはノーマルな14層モデル

海陸の気温傾度や風速傾度で昼と夜を判別してる模様



- ✓ 入力データは2m気温と10m東西風/南北風のみ
- ✓ 気温は領域平均(GSM側)からの偏差に変換
- ✓ 上図は訓練データではなくテストデータの変換結果なので、深層学習システムはターゲット(正解)を知らない

まとめ

物理モデルの代理を務められたか

- 気温場のダウンスケーリング
 - 比較的簡易な構造の深層学習モデルで実現可能
 - ➔ 学習の計算機負荷が小さい
 - 海岸線や標高を正確に学習可能
 - RMSEはGSMの線形内挿に比べて半分以下に
 - 昼／夜の判別もいつの間にか学習した
 - Kudo (2022, 気象集誌) によると関東平野の局地前線の位置も深層学習で補正できたとのこと
 - 代理モデルによる変換計算はほぼ一瞬
- 風速場のダウンスケーリング
 - 気温場に比べると複雑な構造の深層学習モデルが必要
 - ➔ 学習の計算機負荷が大きい
 - 海岸線・標高・時刻は教えてしまった方がスコアが良い
 - 風速バイアスはほぼ消えるが、尾根沿いの風向補正がまだ苦手
 - 代理モデルによる変換計算はほぼ一瞬

深層学習ダウンスケーリング：実用上の問題点

- 学習プロセスの計算機負荷
 - ゲーム用GPUの流用では計算速度だけでなくメモリ容量に制限が大きい（一般にGPUは搭載メモリが少ない）
 - GPUメモリが少ないとモデルドメインを広く取れない
 - 深層学習モデルが複雑になると学習計算に時間がかかり、広いモデルドメインや大規模な学習を諦めざるえない

将来的な可能性

代理モデルとして有望な分野

- 計算が重すぎて予報モデルや気候モデルで著しく簡易化されてしまっているプロセス
 - 化学反応モデル
 - 雲微物理モデル
 - 放射伝達モデル
 } 世界的には既に代理モデル開発が始まっている
- **簡易物理モデルを超える精度を出せるかどうか**が鍵
- アンサンブル予報やデータ同化の補助
 - 物理モデルの計算回数を減らすことができるかも
 - 物理モデルの解像度を抑えることができるかも

富岳のような大規模計算機で期待すること

- 実用的な規模での代理モデル学習計算
 - 動作テスト段階ならばゲーム用GPUレベルで学習計算可能だが、モデルドメインを高層／全球／多変数へ広げていくには大規模な並列計算システムが必要
 - ➔ 入力データや出力データが他分野に比べて巨大なことが気象学の不利な点
- 教師データを作るための物理モデル計算
 - 学習には大量の教師データが必要
 - その教師データは物理モデルで計算しなければならない
 - 機械学習は習ったことしか再現できないので、多種多様な条件で教師データを用意する必要あり
 - よって準備段階では重い計算を地道に実施する必要がある