

本研究では機械学習を用いて作成したニューラルネットワークにより太陽内部などの観測が困難な領域の物理量の推定を行うことを目的としている。その前段階として太陽表面において観測が困難な水平方向の流れ場を推定するためのニューラルネットワークを開発する。機械学習には太陽の内部を含む正確なデータが必要となるが、観測により得ることが困難であるため、太陽内部を再現した輻射磁気流体計算を行うことで学習のためのデータを用意する。

太陽を構成するプラズマは太陽表面付近で熱対流運動をおこなっている。この対流のより磁場の生成やコロナでの加熱などを発生させると考えられており、対流運動の観測は重要な意味を持つ。そのため現在までの多くの太陽の光学観測が行われており、その精度は年々向上している。しかしながら、太陽の光学観測には限界があり、得ることができる情報には限りがある。太陽の熱対流の直接的な情報である対流速度場のうち視線方向成分はドップラー効果により観測することが可能であるが、視線方向に垂直な速度場ではこの方法は使えない。太陽の見た目の動きなどから太陽表面での水平方向の運動を推定する手法などが存在するが十分な性能ではない。

そこで本研究では機械学習を用いてニューラルネットワークの学習を行い太陽表面での水平速度場の推定をする。機械学習を行うには正確な放射強度などの観測が容易な量と水平速度場の組み合わせが必要となるが観測では得ることができないため、太陽光球を再現した数値シミュレーションを行って用意したものを使用する。本研究で用いたニューラルネットワークは複雑な構造を持ちネットワークパラメータが 3×10^7 個あり、効率的な学習、推定を行うには高性能な GPU の存在が不可欠である。

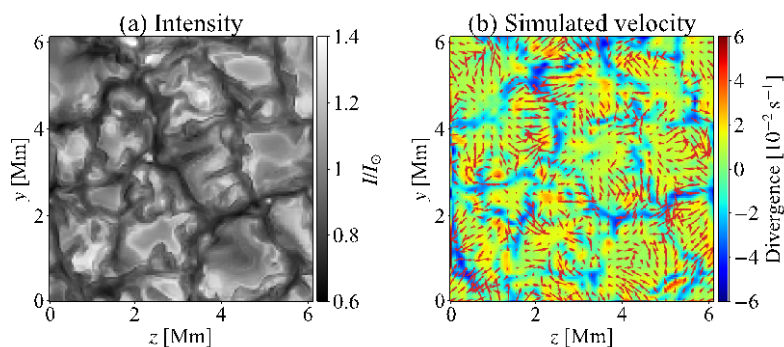


図 1 数値シミュレーションの結果。入力の放射強度(a)出力の水平速度(b)

研究の第一段階としてシミュレーションデータをそのまま用いてネットワークの機械学習を行い、観測データに適用する。シミュレーションデータに対しては正常に推定できるものの観測データに適用した際に正常な推定が行えないことが確認された。そこで学習用シミュレーションデータと観測データを比較して解析したところ観測機器の精度などの理由で二つのデータは小規模な構造が一致していないことがわかった。

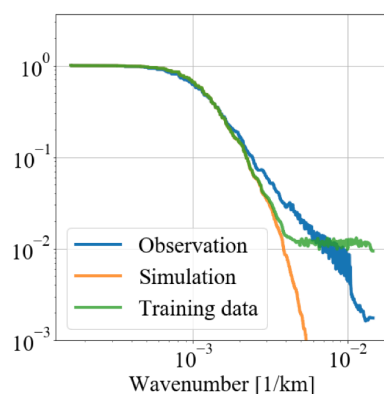


図 2 放射強度の観測データ(青線)とシミュレーションデータ(オレンジ線)の波数分布。緑の線は修正後のシミュレーションデータ。

学習に使用するシミュレーションデータに小規模構造を打ち消すランダムノイズを加えて、大局的な構造に狙いを絞ることで学習に成功し、ネットワークを用いて観測と対応した水平速度場の推定に成功した。シミュレーションデータに対してネットワークを適用し正解とネットワークの推定した速度場との相関係数は 0.7 であった。




図 3 ネットワークに入力した観測データ(a)とネットワークによって推定した速度場(b)