

令和7年度 卒業論文

# ソーラーパネル画像を用いた 深層回帰による電流損失推定

宮崎大学 工学部 工学科 情報通信工学プログラム  
60221320

小林 泰斗  
指導教員 棕木雅之 教授

令和8年2月6日

## 概要

本研究では、ソーラーパネル画像から電流損失を連続値として直接推定する「深層回帰」モデルを構築し、その有効性を検証する。特に、推定精度の鍵となるバックボーンネットワークのアーキテクチャ（CNN、Transformer、およびハイブリッド系モデル）の違いが、データ規模や画像の背景情報の有無に応じてどのような回帰特性を示すか比較する。

実験では、ResNet、EfficientNetV2、ViT、Swin Transformer、ConvNext、MaxViT を含む計 11 種類のモデルを選定した。評価には、独自に撮影・測定を行った小規模、中規模のデータセットと、既存の大規模データセットの 3 種類を用いた。

実験の結果、データ数が限られる小規模データセットでは、帰納バイアスと広域的な文脈把握を両立した Swin Transformer や ConvNext が高い汎化性能を示した。背景情報を含む中規模データセットにおいては、局所的な特徴と大域的な情報を統合する MaxViT が最も高い精度（平均絶対誤差 MAE: 0.017）を達成した。また、大規模データセットにおいては、提案手法が先行研究（DGImnet）の精度を大幅に上回る結果（MAE: 0.031）を示した。

本研究により、適切なバックボーンを選定することで、画像情報のみから極めて高精度な電流損失推定が可能であることが実証された。これは、追加のセンサーを必要としない、安価かつ実用的な次世代太陽光発電監視システムの実現に寄与するものである。

# 目次

第1章 はじめに .....	1
第2章 ソーラーパネルの電流損失推定.....	3
2.1 ソーラーパネル .....	3
2.2 ソーラーパネル画像を用いた発電監視.....	4
2.3 深層回帰 .....	5
第3章 ソーラーパネル画像からの深層回帰による電流損失推定.....	7
3.1 深層回帰モデルの構造.....	7
3.2 バックボーンとデータの重要性.....	8
3.3 バックボーンの選定 .....	9
第4章 データセット .....	11
4.1 小規模データセット .....	11
4.2 中規模データセット .....	13
4.3 大規模データセット .....	14
第5章 実験 .....	16
5.1 実験設定 .....	16
5.2 実験結果と分析 .....	17
5.3 考察.....	23
第6章 おわりに .....	25
謝辞 .....	26
参考文献.....	26

# 第1章

## はじめに

太陽光発電は、温室効果ガスの排出を伴わないクリーンで持続可能なエネルギー源として急速に普及しており、2012年から2022年間に累積導入量は1.6 TWに達している[1]。ソーラーパネルは、電圧  $V$  と電流  $I$  の積である電力  $P$  によって評価される。本研究では、この因子の中から特に電力損失への影響を与え、直列接続時に複雑な非線形挙動を示す「電流損失」に着目する。屋外に設置されるソーラーパネルは、塵埃、花粉、鳥の糞などの堆積物による「汚れ (Soiling)」の影響を強く受け、これが発電効率を大幅に低下するという課題がある[2]。乾燥地域や塵埃汚染の激しい地域では、この汚れによる発電損失が1日あたり15%から最大30%に達することもあり、電力網への安定した統合を妨げる障壁となっている[2]。そこで、電流損失の原因を早期発見するためにソーラーパネルの発電監視が重要である。

発電監視の手法として、物理的な手法やソーラーパネル画像を用いた手法がある。物理的な手法では、透過率を利用して損失を算出する方法[3]やきれいなセルと汚れたセルの比較で損失を監視する方法[4]がある。これらの物理的手法は数値としての信頼性が極めて高い。一方で、広大な面積を持つメガソーラー等の発電所においては、各所に精密機器を設置するコストや、定期的に人の手で計測・清掃を行う手間が膨大となり、運用継続が困難である。

ソーラーパネル画像を用いた手法では監視カメラやドローン画像を用いることで非接触かつ低コストな監視が可能である。近年では、高次元な入力であるソーラーパネル画像から自動的に特徴を抽出することができる深層学習が注目されている。従来研究では、発電損失を分類問題として扱う研究がされてきた。例えば、**ImpactNet** [5] は、ソーラーパネル画像から発電損失を4段階と16段階の離散的なカテゴリとして予測している。**DGImNet** [6] では、ソーラーパネル画像と時系列情報を用いた手法で精度の向上が証明されている。このように従来研究では、発電損失の推定を分類問題として扱ってきた。しかし、電流値のような連続値の推定において、分類手法ではクラス境界での不連続な「量子化誤差」や多クラス分類による精度低下が生じる。一方で、数値を直接出力する深層回帰は、物理現象の滑らかな変化をより正確にモデル化することが可能である。

本研究では、連続値の予測に適している深層回帰の有効性を追求し、ソーラーパネル画像から電流損失を推定するモデルを構築する。**DGImNet** [6]は、評価実験の一部で深層回帰を扱っていたが、電流損失推定の問題への深層回帰の適用に関する検討はまだまだ不十分である。深層回帰においてはバックボーンとデータの質が重要であることが、先行研究 [7,8] において指摘されている。しかし、**DGImNet** [6]ではその各要素を考慮できていない。本研究では、電流損失推定におけるバックボーンのパフォーマンスを評価する。具体的には、CNNの**ResNet**[9]、**EfficientNetV2** [10]に加え、Transformer系の**ViT** [11]、**Swin Transformer** [12]、さらには大

域的な情報を捉える **ConvNext**[13]、**MaxViT**[14]といった計 11 種類のモデルを用い、電流損失推定における各アーキテクチャの回帰特性を系統的に比較する。これにより、局所的な汚れのテクスチャを抽出する CNN の能力と、ソーラーパネル全体の状態を把握する Transformer の大域的な依存関係把握能力のどちらが電流損失推定において優位であるかを結果から考察をする。また、深層回帰ではデータ数の多様性や総数も重要である。しかし、実設置環境で多様なデータを取得するためには、数年単位の長期間データ収集が必要となる。また、実験室レベルで多様なデータ作成・取得するにも多くの手間がかかる。そのため、深層回帰の学習に使用できるデータ数が限られる場合も多い。そこで、本研究では実際に撮影した小規模データセット、中規模データセット、そして大規模のデータセットの 3 種類でデータと深層回帰との関係を調査する。

本論文の構成として、第 2 章では、関連研究を整理し、分類から回帰へとシフトする技術的根拠を詳述する。第 3 章では、本研究で採用する深層回帰手法とそのバックボーンとして利用する 11 種類の深層学習モデルについて述べる。第 4 章では、使用する 3 種類のデータセットを説明する。第 5 章で、各モデルの精度比較、およびアーキテクチャごとの性能差異に関する実験と考察を行う。最後に第 6 章にて本研究の成果と今後の展望を総括する。

## 第2章

# ソーラーパネルの電流損失推定

### 2.1 ソーラーパネル

今日、地球規模の気候変動対策として脱炭素社会の実現が急務となる中で、太陽光発電は温室効果ガスの排出を伴わないクリーンかつ持続可能なエネルギー源として中心的な役割を担っている。技術革新によるコスト低減や各国政府の普及促進策を背景に、太陽光発電の導入は世界的に急速な進展を見せており、2012年から2022年までの10年間における累積導入量は1.6 TWという莫大な規模に達している[1]。

ソーラーパネルは、光エネルギーを直接電気エネルギーに変換する「光起電力効果」を利用した発電デバイスである。その基本構造はp型とn型の半導体を接合したp-n接合から成り、太陽光を構成する光子が半導体内に吸収されることで、負の電荷を持つ「電子」と正の電荷を持つ「正孔」が発生する[15]。これらの電荷は接合部の内部電界によって分離され、それぞれ異なる電極へと引き寄せられることで、パネルの両端に電位差が生じ、外部回路を接続することで電流が取り出される仕組みとなっている[16]。

太陽電池から得られるエネルギーは、電圧Vと電流Iの積である電力Pによって評価される。効率的な発電のためには、日射強度や温度の変化に応じて変動する「最大電力点」を追従し、電力を最大化する制御が一般的である。しかし、実際のシステム運用においては、生成された電力がすべて負荷に供給されるわけではなく、様々な要因による損失が発生する[17]。

本研究では、これら諸因子のうち、特に「電流損失」に着目して解析を行う。電流損失とは、きれいな状態のセルの電流値を1とした時の汚れた状態のセルの電流値のことを示す。電流損失を採用する理由は主に二点ある。第一に、電気回路における電力損失（ジュール熱）は  $P_{loss} = I^2R$  で定義される通り、電流値の2乗に比例して増大するため、電流の微小な変動がシステム全体の効率に影響を与えるためである[18]。第二に、ソーラーパネルの直列接続時において、一部に汚れや影がある場合にソーラーパネル全体の電流を制限する。そのため電圧の変化よりも複雑かつ非線形な挙動を示す電流値に着目する必要がある[19]。

太陽光発電システムの運用面においては、屋外設置という特性に起因する課題が顕在化している。ソーラーパネルは長期間にわたり外気にさらされるため、その表面には周囲の環境に応じた様々な物質が堆積する。具体的には、塵埃や花粉、さらには鳥の糞といった堆積物による「汚れ」が挙げられる。これらは太陽光の透過を物理的に阻害することで、発電効率を大幅に低下させる要因となっている[2]。

この「汚れ」による悪影響は、設置環境によっては極めて深刻である。特に降水量の少ない乾燥地域や、産業活動や交通量の影響で塵埃汚染が激しい地域においては、「汚れ」の蓄積が極めて短期間に進行する。こうした地域では、「汚れ」に起因する発電損失が1日あたり15%から、

最大では30%という甚大な数値に達する事例も報告されている[2]。このような予測不能な出力の低下は、発電事業者にとっての経済的損失のみならず、電力網への安定した統合を妨げる技術的な障壁としても作用する。

したがって、太陽光発電を効率的かつ安定的に運用し続けるためには、パネルの表面状態や発電状況を常時把握し、電流損失の原因を早期に発見するための発電監視体制を構築することが極めて重要となっている。

## 2.2 ソーラーパネル画像を用いた発電監視

ソーラーパネルの発電監視におけるアプローチは、大きく分けて物理的な計測に基づく手法と、パネルの外観を捉えた画像データに基づく評価法の2種類に大別される。

物理的な計測に基づく手法では、透過率測定器を用いてパネル表面の汚れによる光の遮蔽率を直接測定する手法[3]や、基準セル（日射計）を設置して理論的な発電期待値と実発電量を比較する手法[4]がある。これらの手法は数値としての信頼性が極めて高いが、広大な面積を持つメガソーラー等の発電所においては、各所に精密機器を設置するコストや、定期的に人の手で計測・清掃を行う手間が膨大となり、運用継続が困難であるという課題がある。

これに対し、ソーラーパネル画像を用いた手法では、監視カメラやドローン画像を用いることで非接触かつ低コストな監視が可能となる。画像処理を用いた手法のひとつとして、線形回帰に基づくモデルが存在する。具体的には、ソーラーパネル表面の「青さ（色度）」の特徴量を取り出して電流損失との相関を求める手法[20]や、パネル領域の輝度変化から汚れの堆積量を推定する手法[21]がある。これらの手法は計算負荷が低く、単純なデータ分布では有効であるが、特徴量を人の手で編集・加工をする点において非線形な要因を十分に考慮できず、正確な予測には限界がある。

こうした複雑な状況に対応する手法として、近年では深層学習（Deep Learning）が大きな注目を集めている。深層学習では、多数のデータを用いることで、判定に有効な特徴量自体を自動的に学習し、抽出することができる。この性質により、様々な問題に対して高い性能を示している。深層学習を用いて発電監視を行う従来研究の多くは、発電損失を離散的なカテゴリとして扱う分類問題として検討している。例えば ImpactNet[5]は損失を4段階と16段階のカテゴリとして電力損失の分類を行っている。また、DGImNet[6]では画像と時系列情報を組み合わせることで精度を向上できることを示している。

しかし、電流値のような本来連続的な物理量を推定する場合、分類手法ではクラスの境界付近で予測が不連続になる「量子化誤差」が生じるという問題がある。Lathuilièreら[22]は、連続値の予測において分類モデルを用いると、クラス数を増やすほど学習が困難になり、逆にクラス数が少ないと精度の高い推定が不可能になるというジレンマを指摘している。これに対し、深層回帰（Deep Regression）は連続的な数値を直接出力するため、物理現象の滑らかな変化をより忠実にモデル化することが可能である。本研究では、この深層回帰の有効性を追求し、予測精度に大きく寄与するバックボーンの設定や、データの多様性がモデルの回帰特性に与える影響について系統的に比較・検討を行う。

## 2.3 深層回帰

深層回帰 (Deep Regression) とは、多層構造を持つ深層ニューラルネットワーク (DNN) を用いて、入力データから連続的な実数値を直接予測する手法である。従来の回帰モデルは、独立変数と従属変数の間に線形・多項式などの事前に設定したな関係(関数形式)を想定し、解析者がドメイン知識に基づいて最適な変数を選択・加工することに強く依存していた。これに対し、深層回帰は、高次元かつ非構造的なデータから予測に最適な特徴表現を自動的に獲得することができる。さらに、従来の回帰モデルが解析者による関数形式の厳密な定義を必要とするのに対し、深層回帰は多層的な非線形活性化関数を介することで、任意の関数形式を近似できるため、データに潜む複雑な依存関係を柔軟に表現することを可能にしている。

機械学習における一般的な「分類問題」が、入力を離散的なカテゴリ (クラス) のいずれかに割り当てることを目的とするのに対し、回帰問題は無限の解を持つ連続的な数値空間へのマッピングを行う点に本質的な違いがある。例えば、電流値を推定する場合、推定する値はアンペア (A) で表される連続値である。分類では「10A」や「11A」といった段階的な予測しかできないが、深層回帰を用いることで「10.52A」といった精緻な数値を導き出すことが可能となる。このように、対象となる物理量や統計的な指標を連続値として正確に捉える必要がある場面において、深層回帰は極めて強力なツールとなる。

深層回帰モデルの基本構造は、入力画像から高度な視覚的特徴を抽出する「バックボーン (Backbone)」と、その特徴を最終的な数値出力へと変換する「回帰ヘッド (Regression Head)」の2つの主要な要素で構成されている。バックボーンで抽出された高次元の特徴量は、全結合層 (Fully Connected Layer) などで構成される回帰ヘッドへと渡され、最終的に1次元の連続値として出力される。

深層回帰の精度を決定づける要素としてはバックボーンとデータが挙げられる[7,8]。バックボーンは、入力される高次元な画像情報を、ターゲットである電流値と相関の強い低次元な表現へと変換する役割を担う。このプロセスにおいて、局所的なテクスチャと大域的なコンテキストを同時に捉える能力が重要となる。一方で、データの総数と多様性は、モデルの学習過程における探索空間の広さを規定する。スケーリング則によれば、大規模なモデルほどデータ量の増大に対する精度の恩恵を強く受けることが示されている[8]。実環境の多様な気象条件や汚れの分布を網羅したデータセットを用いることで初めて、回帰モデル特有の鋭敏な数値予測が可能となる。

深層回帰の応用範囲は極めて広範であり、コンピュータビジョンにおける物体検出時のバウンディングボックス座標推定[23]や、顔画像からの年齢・感情強度の推定[24]、さらには医療分野における眼底画像からの血圧予測[25]といった、画像から「量」を導き出す必要がある多くの先端領域で基盤技術として確立されている。エネルギー分野においては、気象衛星画像を用いた降水量予測や風力発電の出力推定[26]などに利用されてきた。しかし、ソーラーパネル画像を用いた電流損失予測の領域においては、ImpactNet [6] や DGImNet [5] に代表されるように、依

然として損失を段階的なカテゴリとして扱う分類手法が主流である。そのため、本来は連続値である電流値を直接推定する深層回帰の有効性や、採用するバックボーンのアーキテクチャが回帰特性に与える影響を系統的に調査することは、この分野においていまだ不十分な検討事項であり、本研究の核となる議論である。

## 第 3 章

# ソーラーパネル画像からの深層回帰による電流損失推定

### 3.1 深層回帰モデルの構造

本研究の目的は、撮影されたソーラーパネルの表面画像から、その時点における電流損失を推定することである。この課題は、入力画像という高次元データから、電流値という連続的な実数値を導き出す深層回帰タスクとして定義される。電流損失は汚れのない状態での電流量と汚れた状態の電流量との差として定義される。本研究では、汚れのない状態の電流量が 1、発電していない状態の電流量が 0 となるように正規化した電流値を推定することで、電流損失を推定する。

本研究では、入力画像から電流損失を推定するために深層回帰モデルを構築した。本モデルは図 3.1 に示すように、バックボーンと回帰ヘッドで構成される。まず、入力されたソーラーパネル画像はバックボーンに入力される。バックボーンはソーラーパネル画像中に含まれる汚れの分布や濃淡といった視覚的特徴を抽出する役割を担う。バックボーンでは特徴抽出を目的として深層ニューラルネットワークを用いる。本研究では、後述する 11 種類のニューラルネットワークを用いて性能比較を行う。これにより、電流損失推定に適した特徴表現を学習できるバックボーン構造の検討を行う。

バックボーンから得られた出力は高次元の特徴ベクトルとして表現され、回帰ヘッドに入力される。回帰ヘッドでは、この特徴量を基に電流損失を推定する。回帰ヘッドは回帰タスクに特化した構造を持つ。本研究では、単層の全結合層によって構成される単純な回帰ヘッドを用いる。

回帰ヘッドの最終層では、連続値として電流損失を出力する。最終層の出力関数(活性化関数)として、深層回帰では値をそのまま出力する線形関数を用いることが多いが、本研究では Sigmoid 関数を採用する。Sigmoid 関数は、入力を 0 から 1 の範囲で出力する活性化関数であり、次式で定義される。

$$f(x) = \frac{1}{1 + e^{-x}}$$

本研究では以下の理由から Sigmoid 関数を選択した。

- **値の正規化:**推定する電流損失を  $[0, 1]$  の範囲に正規化しているため、出力層に Sigmoid 関数を適用することで、モデルの出力値の定義域を推定値の範囲と一致させることが可能となる。

- **外れ値への対策:** 入力データに含まれるノイズや外れ値に対して、出力が極端な値を取ることを抑制し、モデルの安定性を高める効果がある。

このように、本モデルは画像から特徴を抽出するバックボーンと、抽出された特徴量から電流損失を推定する回帰ヘッドを分離した構成とすることで、バックボーンの違いが回帰性能に与える影響を体系的に評価できる。

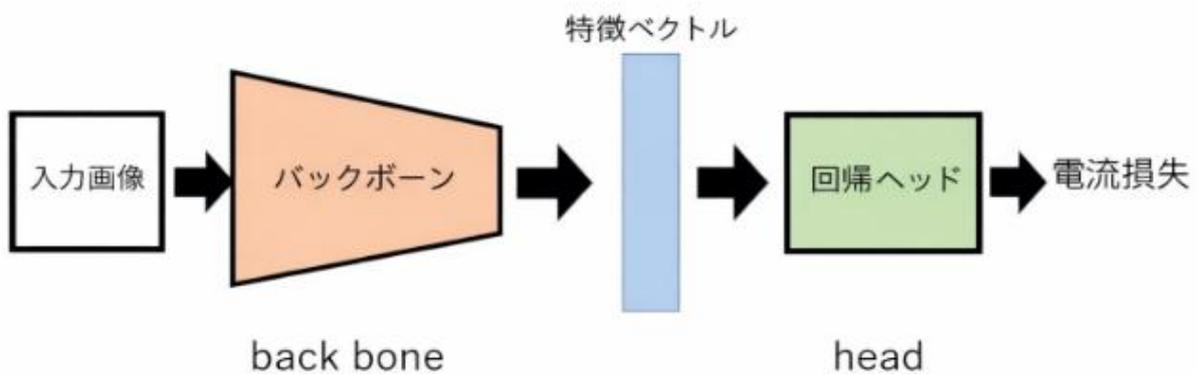


図 3.1 深層回帰モデル

## 3.2 バックボーンとデータの重要性

深層回帰において、予測精度の向上を決定づける中核的な要素はバックボーンのパフォーマンスと学習データの質および量である[7,8]。バックボーンは入力されたソーラーパネル画像から回帰に不可欠な視覚的特徴を抽出する役割を担っており、その性能が推定結果に極めて大きく寄与する。具体的には、局所的な汚れのテクスチャを抽出する能力に長けた CNN（畳み込みニューラルネットワーク）と、ソーラーパネル全体の状態や大域的な依存関係を把握する能力に長けた Transformer とでは、電流値の推定において示す回帰特性が本質的に異なる。そのため、どのアーキテクチャが適しているかを系統的に比較・評価することは、高精度な推定モデルを構築する上で極めて重要である。

同時に、深層回帰におけるモデルの汎化性能や推定の安定性は、学習に用いるデータの総数や多様性に依存している。一般に、深層学習では膨大なデータが必要とされるが、ソーラーパネルの設置現場における実測データの収集は困難を伴う場面が多く、データセットの規模が回帰精度に与える影響を無視することはできない。そのため、小規模なデータセットから既存のデータセットまで、異なる規模のデータと深層回帰モデルとの相関関係を詳細に調査すること

は、限られた観測データ条件下においても実用的な予測精度を確保するために不可欠なプロセスであると言える。

### 3.3 バックボーンの設定

本研究では、ソーラーパネル画像からの電流値推定において、どのような内部構造（アーキテクチャ）が回帰精度に寄与するのかを明らかにするため、近年のコンピュータビジョン分野で高い成果を上げている計 11 種類のモデルを選定した。これらのモデルは、局所的な特徴抽出に長けた CNN 系、広域的な情報の統合に長けた Transformer 系、そしてその両方の特性を併せ持つハイブリッド系の 3 つのカテゴリに分類される。

#### 3.3.1 CNN 系モデル

畳み込みニューラルネットワーク（CNN）は、画像内の局所的なパターンを捉える能力に優れており、ソーラーパネル表面に付着した微細な汚れや堆積物のテクスチャを抽出するのに適している。本研究では以下の 2 つの系列を採用する。

- **ResNet (18, 50, 152)**: 残差接続（Residual Connection）を導入することで層を深くしても学習を安定させた、CNN の標準的なモデルである [9]。Resnet18,50,152 の 3 種類のモデルを評価に用いる。数字はネットワークの層の数を表しており、層数が多いほど大規模なモデルとなる。
- **EfficientNetV2 (b0, b1, b2, b3)**: 学習速度とパラメータ効率を最適化したモデルであり、回帰タスクにおける効率的な特徴抽出が期待される [10]。EfficientNetV2\_b0, b1, b2, b3 の 4 種類のモデルを評価に用いる。数字はモデルの規模の違いを表しており、数が大きいほど大規模なモデルとなる。

#### 3.3.2 Transformer 系モデル

自然言語処理から発展した Transformer を画像に応用した手法は、画像全体のピクセル間の依存関係を直接モデル化できるため、ソーラーパネル全体の状態や影の影響といった大域的な情報の把握に優れている。

- **Vision Transformer (ViT)**: 画像をパッチに分割し、それぞれの関連性を自己注意機構（Self-Attention）で計算することで、画像全体の特徴を捉える [11]。
- **Swin Transformer**: 階層的な構造と移動窓（Shifted Window）を用いることで、ViT の計算効率を改善しつつ、多スケールの特徴を抽出可能にしたアーキテクチャである [12]。

ViT 及び Swin Transformer には規模の異なる複数のモデルが存在するが、本研究では比較的小規模な ViT\_tiny 及び Swin\_tiny を評価に用いる。

### 3.3.3 ハイブリッド系モデル

局所的な特徴抽出に長けた **CNN** と、大域的な依存関係を捉える **Transformer** の長所を高度に融合させた手法である。ソーラーパネルの微細な汚れと全体的な発電状態の両方を同時に捉える能力を検証するために採用する。

- **ConvNext**: Transformer の設計思想を CNN に逆輸入し、畳み込みの枠組みを維持しながらも近代的なアーキテクチャへと進化させたモデルである [13]。
- **MaxViT**: CNN の局所的な演算と Transformer の大域的な演算を高度に組み合わせたモデルである [14]。

ConvNext 及び MaxViT には規模の異なる複数のモデルが存在するが、本研究では比較的小規模な ConvNext\_tiny 及び MaxViT\_tiny を評価に用いる。

## 第4章

### データセット

本章では、本研究における深層回帰モデルの学習および評価に用いる3種類のデータセットについて詳述する。本研究では、自ら撮影を行った小規模、中規模の2種類のオリジナルデータセットと、既存の大規模データセットで、データ規模や背景情報の差異が回帰精度に与える影響を検証する。

#### 4.1 小規模データセット

本研究の主要な解析対象として、実際にソーラーパネルを撮影し、撮影時の電流値を測定して対応付けたデータセットを作成した。小規模データセットでは、単一セルである自作のモジュール(図4.1)と人工光源を使用して屋内でのデータ収集を実施した。データ収集は光量を固定した人工光源下で実施した。また、人工光源とモジュールの位置関係を固定し、実験期間を通じて同一の照射条件を保った。なお、人工光源の有効照射面積は約  $10\text{ cm} \times 10\text{ cm}$  ( $100\text{ cm}^2$ ) であるため、照射範囲を一定に保つ目的で測定用マスクをモジュール上に重ねて測定した。

本研究では、汚れの試料として泥を使用する。泥は、粒径の小さいシルトと粘土が混ざり合ったやわらかい堆積物である。汚し方としては、計測した泥を人工光源に照らされる自作モジュールの  $10\text{ cm} \times 10\text{ cm}$  部分にのせ、素手で自作モジュール全体にならして汚れを作り出した。汚し方は、泥の重さで  $0.0\text{g}$ ,  $0.1\text{g}$ ,  $0.5\text{g}$ ,  $1.0\text{g}$ ,  $1.5\text{g}$ ,  $5.0\text{g}$  の計6パターンである。

画像取得については、画像に多様性を与えるために角度を変えた5種類の取り方を行った。一つは、一眼レフのカメラを使用して人工光源に対して正面から撮影した。残りの4種類は、スマートフォンを使用して、人工光源に対して左右から、自作モジュールの表面に対して浅い角度と上からの緩やかな角度で撮影を行った。

正解のデータとなる電流損失の測定は、モジュール温度で電流損失のずれが出ることを考えモジュールの温度をソーラーパネルにおける標準温度  $25^\circ\text{C}$  で設定した。この温度を保ったまま、汚した状態の自作モジュールの撮影とその際の電流値を計測する。電流損失のずれを平均化するために、同じ汚し方に対して、この試行を3回行う。

本データセットは、深層学習において極めて少量とされる90枚(6パターン $\times$ 5方向 $\times$ 3回)の画像で構成されている。図4.2に6パターンの汚れの画像例を示す。また、図4.3に各汚れパターンで測定した電流値分布を示す。横軸は泥の重さ(g)、縦軸は測定した電流値(A)を表す。泥の重さが増えるにつれ、測定した電流値が小さくなる傾向が表れている。

本データセットでは、画像処理によって背景情報を除去している。屋外での撮影では周囲の建物や地面といった背景情報が学習時の「ノイズ」として作用する可能性があるため、ソーラーパネルの領域のみを切り抜いた画像を用いる。

測定した電流値は、汚れのない泥 0.0g で最大 2.6(A)であった。これを基に、測定した電流値を 0 から 1 の範囲に正規化することで、正解となる電流損失を求めた。

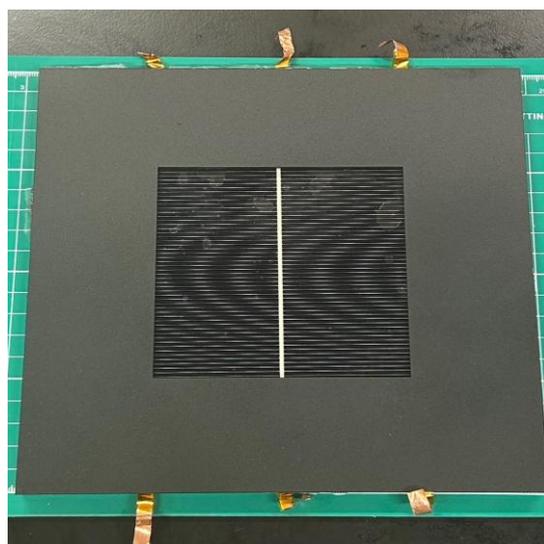


図 4.1 自作モジュール

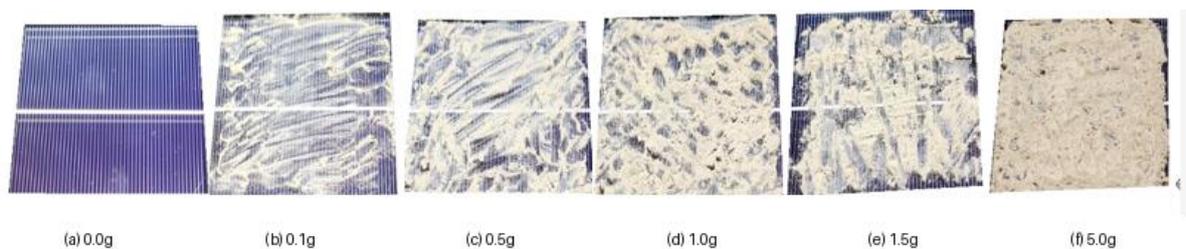


図 4.2 小規模データセットの画像例(6 パターン)

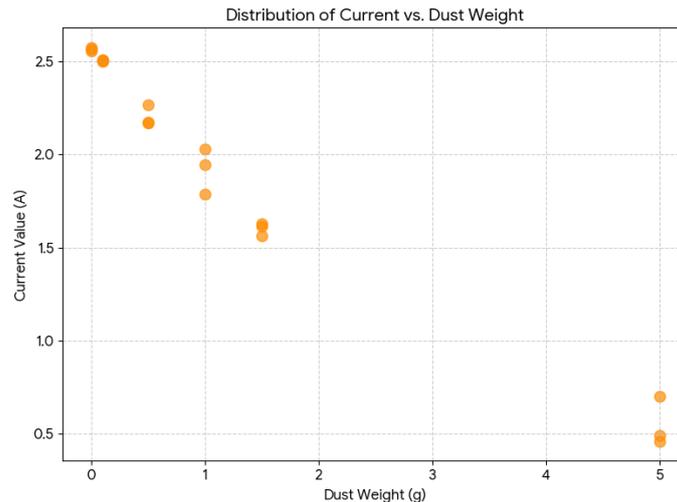


図 4.3 測定した電流値の分布(小規模データセット)

## 4.2 中規模データセット

中規模データセットは、小規模データセット用に取得した 90 枚の画像に加えて、汚れを 15 段階に細分して測定したデータ 350 枚を追加した計 440 枚の画像で構成される。撮影対象は、小規模データセットと同じ自作モジュールで、撮影時の光源環境などの条件も同一である。

汚れの与え方としては、濃度に基づく手法を採用した。小規模データセットの汚し方である「素手で一面に泥を広げる方法」では泥の量を細かく制御するには限界があった。本データセットでは、泥を水に溶かした水溶液を作成し、この水溶液を、自作モジュールの 10 cm × 10 cm で乾燥させ、一面の汚れを再現した。汚し方は、水溶液の濃度が、0%から 2.5%の範囲を 15 分割で作成した。また、各濃度において、そのままの汚れに加えて、刷毛で縦、横、斜めの縞模様を順次追加した計 4 通りの汚れを作成した。各汚れのパターンにおいて 1 回から 2 回の撮影を行い、計 350 枚の画像を取得した。同時に、各汚れパターンでの電流値を測定した。

小規模データセットと異なり、背景の切り抜きを行わず、撮影時の背景情報をそのまま保持した状態で学習及び電流損失推定を行う。図 4.4 に中規模データセットの画像例を示す。また、図 4.5 に各汚れパターンで計測した電流値の分布を示す。横軸は泥水溶液の濃度(%)、縦軸は測定した電流値(A)を表す。同じ泥濃度でも、4 通りの模様をつけているため、測定した電流値に差が表れている。

測定した電流値は、汚れのない状態で最大 2.8(A)であった。これを基に、測定した電流値を 0 から 1 の範囲に正規化することで、正解となる電流損失を求めた。

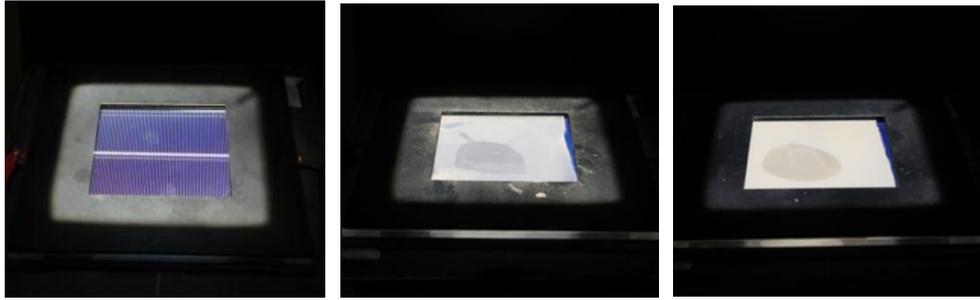


図 4.4 中規模データセットの画像例

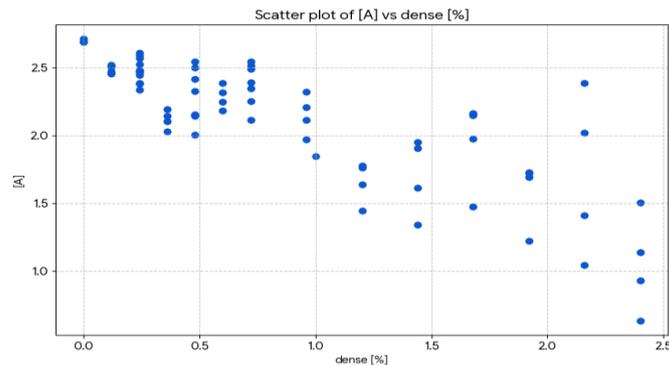


図 4.5 測定した電流値の分布(中規模データセットの追加データ)

### 4.3 大規模データセット

大規模データセットとして、既存の公開データセットである「Solar Panel Soiling Image Dataset」[27]を使用する。本データセットは、論文[5,6]においても使用されており、ソーラーパネルの汚れに起因する発電損失の解析において標準的なベンチマークの一つとして広く認知されている。

本データセットは合計で 45,754 枚という膨大な画像数で構成されている。本データセットは屋外環境で固定カメラを使用して 5 秒間隔で撮影されたものである。実際の画像例を図 4.6 に示す。画像には、塵埃、鳥の糞、砂の堆積といった実環境下における多様な汚れの形態が記録されている。一方で、連続撮影という特性上、汚れの状態が実質的に変化したタイミングに着目すると、ユニークな汚れのパターンを持つ画像は 84 枚程度に集約されるという側面も併せ持っている。大規模データセットの正解となるデータは、すでに正規化されている電力量を使用する。また、固定カメラでの撮影のため中規模データセットと同様にソーラーパネル画像は背景をつけたまま使用する。

自身で撮影した独自のデータセット (90 枚および 440 枚) に加え、これら先行研究で実績のある膨大な既存データセットを評価対象に含めることで、11 種類のネットワークアーキテクチ

ヤが、データの背景情報や分布、そしてデータ総数の差異に対してどのような回帰特性を示すのかを、より広範かつ多角的に考察することが可能となる。



図 4.6 Solar Panel Soiling Image Dataset の画像例

## 第5章

### 実験

#### 5.1 実験設定

##### 5.1.1 使用したバックボーン

本研究は、公開ライブラリである torchvision[27]や timm[28]が提供する深層学習モデルを使用する。使用する深層学習モデルは、ImageNet 画像データセットを用いて 1000 種類の画像分類を事前学習したものである。これらの深層学習モデルから最終層のクラス分類ヘッドを除去したものをバックボーンとして利用する。事前学習済みのモデルを使用し、第4章で述べたデータセットを追加学習することで、少ないデータ量でも高い精度が期待できる。

##### 5.1.2 データ拡張および前処理

本研究では、深層回帰モデルの汎化性能を向上させ、過学習を効果的に抑制するために、入力画像に対して以下の前処理およびデータ拡張 (Data Augmentation) を適用する。

- ネットワーク入力用の標準リサイズ
- 学習時のデータ多様性を確保するための左右反転
- ImageNet 統計量に基づく正規化

本研究では、計算速度や管理のしやすさからデータセットを  $256 \times 256$  画素へリサイズする。そして、入力画像に対しては事前学習時の設定に合わせて  **$224 \times 224$  画素**になるように中央部分を切り抜き(クリッピング)する。これに加えて限られデータセットにおける過学習を抑制し、撮影角度や向きの差異に対するロバスト性を向上させるための**確率 50%でのランダムな左右反転**を行う。最後に、学習時の設定に合わせて ImageNet の統計量に基づく正規化 (Normalize) を施す。これにより、入力画像のデータ分布をモデルが学習しやすい形式へと最適化している。

##### 5.1.3 損失関数

モデルの学習において、予測値と正解値の差異を定量化し、ネットワークの重みを更新するための指標として損失関数を定義する。本研究では、損失関数として**平均絶対誤差 (MAE: Mean Absolute Error)**を採用する。

MAE は予測値と正解値の差の絶対値を算出する手法である。回帰モデルで標準的に利用される平均二乗誤差に比べて、外れ値に対して過剰なペナルティを与えないという特性を持つ。MAE を損失関数に採用することで、特定の異常なデータに引きずられることなく、モデルの頑

健性を維持しながら汎化性能の高い電流損失推定モデルを構築する。MAE は以下の式で計算する。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

ここで、 $n$ はデータ数、 $y_i$ は正規化された正解の電流値、 $\hat{y}_i$ はモデルによる予測値を示す。この MAE を最小化するようにバックプロパゲーション（誤差逆伝播法）を行うことで、ソーラーパネルの電流損失推定モデルを構築する。

### 5.1.3 学習設定

本研究では、学習時に以下のハイパーパラメータを設定する。

- ・エポック数: 50
- ・バッチサイズ: 小規模、中規模データセット 8、大規模データセットは 32
- ・最適化アルゴリズム: RADAM
- ・最適化パラメータ ( $\beta_1, \beta_2$ ): (0.9, 0.999)
- ・初期学習率: 0.0005
- ・学習スケジューラ: 9 エポックごとに学習率を 0.5 倍するステップスケジューラ

### 5.1.4 評価手法

本研究における評価のプロセスは、データセットの規模や特性に応じて最適な戦略を適用している。まず、90 枚の小規模データセットに対しては、データの有効活用と評価の客観性を両立させるため、全データから 1 枚を評価用として抽出し、残りの画像をさらに 8:2 の比率で学習用と検証用に分割してモデル構築を行う Leave-One-Out (LOO) 交差検証を採用する。この LOO 実施時には、検証データにおける MAE の閾値を 0.05 に設定する。50 エポックの学習の中で、検証データに対する MAE の最小値が閾値以下となった場合、そのエポックでのモデルを用いて、評価用の 1 枚のデータに対する電流損失を推定する。閾値に達しない場合は、学習を最初から再度やり直す。この試行を最大 20 回繰り返しても MAE が閾値以下にならない場合は、それまでの最小 MAE のモデルを用いて、評価用のデータに対する電流損失を推定する。得られた推定結果と、測定により得られた電流損失との絶対値誤差を求める。最終的に、90 枚の各データを評価用とした推定結果の平均絶対誤差により、精度を評価する。

一方で、440 枚の中規模データセットおよび既存の大規模データセットについては、計算コストと評価の妥当性を考慮し、全データを 8:2 の比率で学習用と評価用に分割している。そして、評価用データに対する平均絶対誤差により精度を評価する。

## 5.2 実験結果と分析

本節では、5.1 節で述べた実験設定に基づき、各データセットにおける深層回帰モデルの推定精度を評価する。

### 5.2.1 小規模データセットの結果

90 枚という極めて限定的なデータ環境下において、LOO 法を用いて算出した各モデルの平均絶対誤差 (MAE) を表 5.1 および図 5.1 に示す。

表 5.1 小規模データセットにおける各モデルの MAE 測定結果

推定モデル (Backbone)	MAE (平均絶対誤差)
<b>Swin_tiny</b>	<b>0.044488</b>
ConvNext_tiny	0.049494
ViT_tiny	0.052346
EfficientNetV2_b2	0.052741
EfficientNetV2_b1	0.056879
MaxViT_tiny	0.057131
EfficientNetV2_b0	0.057993
EfficientNetV2_b3	0.064693
ResNet18	0.076541
ResNet50	0.084718
ResNet152	0.112833

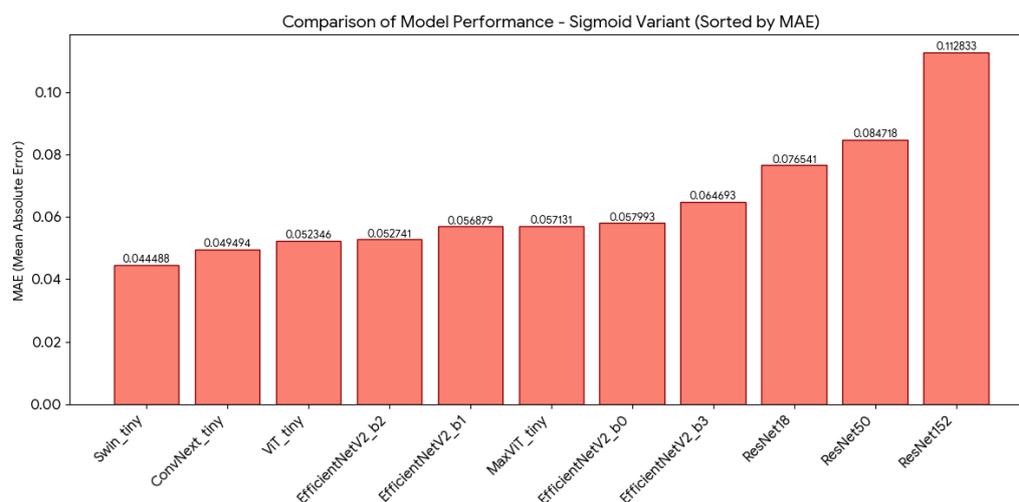


図 5.1 小規模データセットにおけるモデル間精度の比較

90 枚という極めて限定的なデータ環境下における実験結果から、アーキテクチャごとの特性が顕著に現れることが明らかとなった。本データセットにおいて最も高い精度を示したのは **Swin\_tiny** であり、次いで **ConvNext\_tiny** や **ViT\_tiny** が良好な結果を記録した。これは、データ数が少ない場合でも、事前学習済みの重みを活用することで、Transformer ベースの大域的な依存関係把握能力や、ConvNext のような近代的な CNN 構造が、ソーラーパネル表面のわずかな変化を捉えるのに有効であることを示唆している。一方で、ResNet 系列は他のモデルと比較して誤差が大きく、特に層が最も深い **ResNet152** において誤差が最大となった。これは、データ数が極端に少ない条件下では、純粋な CNN 構造を持つ深いモデルほど複雑な特徴空間の学習において過学習に陥りやすく、回帰タスクに必要な収束が困難であることを示している。また、EfficientNetV2 系列は中規模なモデルである **b2** が最も高い性能を示した。少量データ環境においてはモデルの巨大化が必ずしも精度向上に直結しないという、効率的なネットワーク選定の重要性が浮き彫りとなった。以上の通り、背景を切り抜きパネル表面の状態に特化させた環境においては、Transformer 系モデルが CNN 系モデルを凌駕する推定精度を発揮することが確認された。

### 5.2.2 中規模データセットの結果

440 枚の背景情報を残した中規模データセットを用いて、各バックボーンのパフォーマンスを評価した。得られた各モデルの MAE (平均絶対誤差) を表 5.2 および図 5.2 に示す。

表 5.2 中規模データセットにおける各モデルの MAE 測定結果

推定モデル (Backbone)	MAE (平均絶対誤差)
MaxViT_tiny	0.017130
ConvNext_tiny	0.017914
Swin Transformer	0.021330
EfficientNetV2_b3	0.025491
EfficientNetV2_b2	0.028499
EfficientNetV2_b0	0.029140
EfficientNetV2_b1	0.029810
ResNet18	0.039917
ViT_tiny	0.039997
ResNet50	0.047250
ResNet152	0.057050

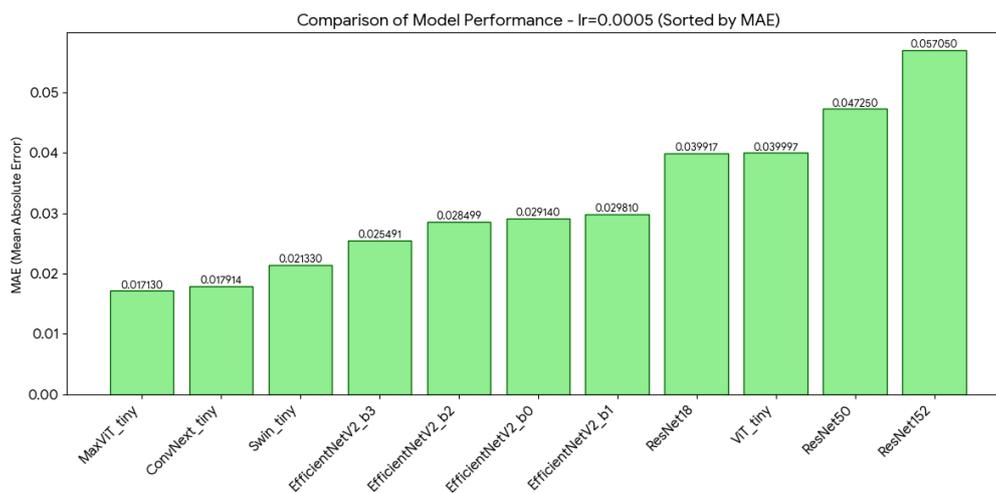


図 5.2 中規模データセットにおけるモデル間精度の比較

データ数を 440 枚に拡充し、背景情報を保持した条件下での解析では、全てのモデルにおいて MAE が大幅に改善される結果となった。特に注目すべきは、CNN の局所的な特徴抽出と Transformer の大域的な情報統合を組み合わせた **MaxViT\_tiny** が最良の精度(MAE=0.017130)を記録した点である。これは、背景情報が含まれる複雑な画像環境において、ハイブリッド構造が「パネルの汚れ」という局所情報と「周囲の環境」という大域情報を最も効率的に峻別・統合できたことを裏付けている。また、背景を切り抜いていないにもかかわらず、ConvNeXt や Swin Transformer が高い精度を維持している点は、近代的なアーキテクチャが優れたアテンション機構や広い受容野を備えることで、背景を「ノイズ」ではなく「設置環境のコンテキスト」として適切に処理できている可能性を示している。対照的に、ResNet 系列はデータ増加後も最新モデルに及ばず、特に深い層を持つモデルほど回帰タスクにおける特徴抽出の濃縮が不十分であるという傾向が継続して見られた。以上の通り、MaxViT や ConvNext といった最新アーキテクチャの採用により、極めて高精度な電流損失推定が可能であることが実証された。

### 5.2.3 大規模データセット (Solar Panel Soiling Image Dataset) の結果

最後に、45,754 枚という膨大な画像数を持つ「Solar Panel Soiling Image Dataset」[5]を用いた実験結果について述べる。本データセットは、先行研究で ImpactNet[5]や DGIImnet[6]でも使用されている。本研究ではこれらを「回帰タスク」として解いた際の各アーキテクチャの性能を調査した。得られた各モデルの MAE (平均絶対誤差) を表 5.3 および図 5.3 に示す。

表 5.3 大規模データセットにおける学習率別の MAE 比較

推定モデル (Backbone)	MAE (平均絶対誤差)
<b>ResNet50</b>	<b>0.031576</b>
ResNet152	0.031780
MaxViT_tiny	0.032343
ConvNext_tiny	0.032448
EfficientNetV2_b2	0.033030
EfficientNetV2_b3	0.033240
Swin_tiny	0.033370
ViT_tiny	0.033590
EfficientNetV2_b1	0.033603
ResNet18	0.033898
EfficientNetV2_b0	0.034321

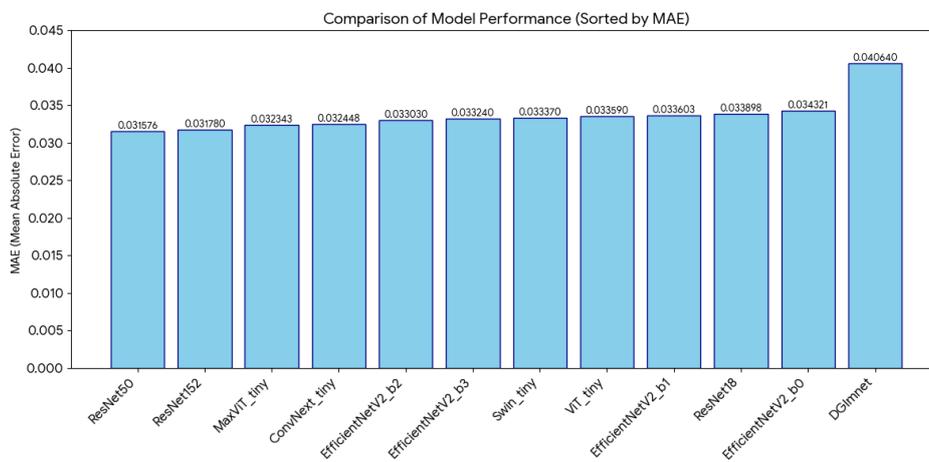


図 5.3 大規模データセットにおけるモデル間精度の比較

45,754 枚という膨大なデータを持つ大規模データセットの解析においては、小規模データセットで見られたようなモデル間の性能差が大幅に縮小し、MAE が 0.031 から 0.034 の範囲で拮抗する結果となった。特筆すべきは、少量データでは振るわなかった ResNet50 や ResNet152 が最良のスコアを記録した点である。これはデータ規模が十分に大きい場合には、標準的な CNN 構造でも膨大なサンプルから汚れのパターンと発電損失の相関を高度に一般化できることを示している。

しかし、どのモデルを採用しても MAE 0.03 付近で精度が頭打ちになる現象（プラトー）が確認されている。これは 5 秒間隔の連続撮影というデータの特性上、画像間の視覚的变化が極めて微細であるため、モデルの構造以上に「データのユニークな変化量」が物理的な精度の限界を決定づけていると考えられる。

先行研究である DGI<sub>net</sub> や ImpactNet などは、主に「汚れの分類」や「時系列融合の有効性」に焦点を当てており、電流損失の推定精度に直結するバックボーン自体のアーキテクチャ検討が不十分であった。実際、先行研究では標準的な CNN 構造の使用に限定されていたが、本研究では Transformer 系、ハイブリッド系、および近代化された CNN (ConvNext) で検証を行い、それぞれの回帰特性を比較した。先行研究である DGI<sub>net</sub> との比較においては、画像情報のみを用いた本手法が全 11 種類のバックボーンにおいて DGI<sub>net</sub> の MAE (0.04064) を大きく上回る 0.031~0.034 という結果を達成した。この優位性は、先行研究で不十分であったバックボーン群 (Transformer 系やハイブリッド系) の検証によるものであり、ソーラーパネル画像のみからでも物理量を極めて精密に推定できることを実証した。

### 5.3 考察

本研究で行った 3 つの異なるデータセットに対する実験結果を総合すると、ソーラーパネル画像を用いた電流値推定におけるアーキテクチャの有効性は、データの規模や背景情報の有無に密接に依存していることが明らかとなった。まず、90 枚という極めて少量なデータ環境においては、Swin Transformer や ConvNext といった、帰納バイアスと広域的な関係把握能力を高度に両立させたアーキテクチャが圧倒的な優位性を示したのに対し、ResNet152 のような純粹かつ深層な CNN が精度を落とした点は、限られたサンプルから回帰に必要な特徴を濃縮する際の構造的な得手不得手を浮き彫りにしている。

データ数を 440 枚に拡充し背景情報を保持した条件下では、背景を切り抜いた 90 枚データよりも精度の向上が見られ、特に局所と大域の情報を統合的に処理する MaxViT が最良の数値を記録した。この事実は、アーキテクチャが備える空間的な注意機構や広い受容野によって、背景が単なるノイズではなく、パネルの設置環境を補完する「コンテキスト」として機能、あるいはパネル領域と高度に峻別して学習に寄与している可能性を示唆している。これは、実運用における画像切り抜き工程の省略という実用的なメリットを裏付けている。

また、大規模データセットにおいてはモデル間の性能差が収束し、ResNet 系列が最良スコアを記録したが、すべてのモデルが MAE 0.031 付近で落ち着いたことは、データ総量よりもユニークな汚れパターンのバリエーションが物理的な推定精度の限界を規定していることが考えられる。先行研究である DGIInet との比較においては、画像情報のみを用いた本手法が全 11 種類のバックボーンにおいて先行研究の MAE (約 0.038~0.045) を大きく上回る 0.031~0.034 という結果を達成した。この優位性は、先行研究で不十分であったバックボーン群 (Transformer 系やハイブリッド系) の検証によるものであり、画像のみからでも物理量を極めて精密に推定できることを実証した。

総じて、本研究で得られた MAE 0.01~0.03 という誤差水準は、安価な監視カメラ画像のみを用いた次世代の太陽光発電モニタリングシステムが、実環境下で高度に実現可能であることを強く示唆するものである。

## 第6章

### おわりに

本研究では、ソーラーパネル画像から電流損失を推定する手法として、CNN、Transformer、およびそれらを融合させたハイブリッド系を含む計 11 種類の深層回帰モデルを検討し、実際に撮影した小規模および中規模のデータセット、ならびに公開されている大規模データセットを用いてその有効性を多角的に検証した。

実験の結果、90 枚の小規模データセットにおいては **Swin Transformer** や **ConvNext** といった帰納バイアスと広域的コンテキストの把握に長けたモデルが優れた汎化性能を示した。440 枚の中規模データセットにおいて背景情報を保持した場合には、局所・大域情報を高度に統合する **MaxViT** が最高精度を達成することを明らかにした。また、大規模データセットを用いた比較検証においては、先行研究である DGI<sub>net</sub> の精度を全ての検証モデルにおいて大幅に上回る **MAE 0.031** という極めて低い誤差を記録し、適切なバックボーンアーキテクチャの選定と学習率の最適化が、追加の環境センサーに依存しない画像のみによる精密な物理量推定において決定的な役割を果たすことを示した。

本研究で得られた知見は、安価な監視カメラ画像を利用した高精度かつ低コストな太陽光発電モニタリングシステムの実現可能性を強く示唆するものである。今後は気象条件の変動に対するさらなる頑健性の向上や、エッジデバイスへの実装によるリアルタイム監視体制の構築といった実地応用へ向けた発展が期待される。

## 謝辞

本論文の作成にあたり、丁寧な対応とご指導をして下さった椋木雅之教授に深く感謝申し上げます。実験やデータセットの調査などでも助力して頂きありがとうございました。先生の多角的な視点からのご助言とご鞭撻がなければ、本論文を完成させることはできませんでした。そして、データ収集や共同研究に協力していただいた西岡教授と馬渡さんにも心から感謝申し上げます。

また、本研究の評価実験において貴重なデータを提供して下さった「DeepSolarEye」プロジェクトの S. Mehta 氏、A. P. Azad 氏をはじめとする研究チームの皆様には厚く御礼申し上げます。公開された詳細なデータセットは、本研究における深層回帰モデルの検証において不可欠なものでした。

お互いの研究を進めるにあたって助言し合うことで切磋琢磨した椋木研究室の皆様には感謝申し上げます。これからのご活躍をお祈り申し上げます。

## 参考文献

- [1] International Renewable Energy Agency (IRENA), "Renewable Capacity Statistics 2023," Abu Dhabi: International Renewable Energy Agency, 2023.
- [2] T. Sarver, A. Al-Qaraghuli, and L. L. Kazmerski, "A comprehensive review of solar photovoltaic soiling: Characterization, measurements, challenges and solutions," *Renewable and Sustainable Energy Reviews*, vol. 28, 2013, pp. 699-727.
- [3] M. Mani and R. Pillai, "Impact of dust on solar photovoltaic (PV) performance: Research status, challenges and solutions," *Renewable and Sustainable Energy Reviews*, vol. 14, no. 9, 2010, pp. 3124-3131.
- [4] C. R. Osterwald, "Aniso-thermal error-free solar cell performance measurements," *Solar Cells*, vol. 18, no. 3-4, 1986, pp. 269-279.
- [5] J. S. Mehta, A. P. Azad, S. A. Chemmengath, V. Raykar, and S. Kalyanaraman, "DeepSolarEye: Power loss prediction and weakly supervised soiling localization via fully convolutional networks for solar panels," in *Proceedings of the IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2018, pp. 333-342.
- [6] M. Fang, W. Qian, T. Qian, Q. Bao, H. Zhang, and X. Qiu, "DGIImNet: A deep learning model for photovoltaic soiling loss estimation," *Applied Energy*, vol. 376, 124335, 2024.
- [7] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proceedings of the International Conference on Machine Learning (ICML)*, 2019.

- [8] Chen Sun, Abhinav Shrivastava, Saurabh Singh, and Abhinav Gupta. Revisiting unreasonable effectiveness of data in deep learning era. in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pp. 843–852, 2017.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [10] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," in *Proceedings of the 38th International Conference on Machine Learning*, 2021, pp. 10096–10106.
- [11] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, and N. Houlsby, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," in *Proceedings of International Conference on Learning Representations (ICLR)*, 2021.
- [12] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, and B. Guo, "Swin Transformer: Hierarchical Vision Transformer using Shifted Windows," in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 2021, pp. 10012–10022.
- [13] Z. Liu, H. Mao, C. Y. Wu, C. Feichtenhofer, T. Darrell, and S. Xie, "A ConvNet for the 2020s," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 11976–11986.
- [14] Z. Tu, H. Talebi, H. Zhang, F. Yang, P. Milanfar, A. Bovik, and Y. Li, "MaxViT: Multi-Axis Vision Transformer," in *Proceedings of European Conference on Computer Vision (ECCV)*, 2022, pp. 459–479.
- [15] W. Shockley and H. J. Queisser, "Detailed Balance Limit of Efficiency of p-n Junction Solar Cells," *Journal of Applied Physics*, vol. 32, no. 3, 1961, pp. 510-519.
- [16] R. A. Messenger and A. Abtahi, *Photovoltaic Systems Engineering*, 4th ed. Boca Raton, FL, USA: CRC Press, 2017.
- [17] M. A. Green, *Third Generation Photovoltaics: Advanced Solar Energy Conversion*. Berlin, Germany: Springer, 2003.
- [18] E. Lorenzo, *Solar Electricity: Engineering of Photovoltaic Systems*. London, UK: Earthscan Publications Ltd., 1994.
- [19] V. Quaschnig and R. Hanitsch, "Numerical simulation of current-voltage characteristics of photovoltaic systems with shaded solar cells," *Solar Energy*, vol. 56, no. 6, 1996, pp. 513-520.
- [20] Mahmoud Hammad, Mohammed Abdulla, and Ahmed M. T. Ibraheem Al-Naib, "Detection of dust on solar panels using image processing techniques," *International Journal of Computer Applications*, vol. 175, no. 6, pp. 31–36, 2017.
- [21] V. Sumathi, V. Jayashree, and R. Hemalatha, "Automatic detection of dust on solar panels using image processing," in *Proceedings of the 2017 International Conference on Computer Communication and Informatics (ICCCI)*, 2017, pp. 1-4.

- [22] S. Lathuilière, P. Mesejo, X. Alameda-Pineda, and R. Horaud, "A Comprehensive Analysis of Deep Regression," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 42, no. 9, 2019, pp. 2065-2081.
- [23] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," in *Proceedings of Neural Information Processing Systems (NIPS)*, pp. 91–99, 2015.
- [24] R. Rothe, R. Timofte, and L. Van Gool, "Deep expectation of real and apparent age from a single image without facial landmarks," *International Journal of Computer Vision (IJCV)*, vol. 126, no. 2, 2018, pp. 144–157.
- [25] R. Poplin, A. V. Varadarajan, K. Blumer, Y. Liu, M. V. McConnell, G. S. Corrado, L. Peng, and D. R. Webster, "Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning," *Nature Biomedical Engineering*, vol. 2, no. 3, 2018, pp. 158–164.
- [26] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W.-C. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," in *Proceedings of Neural Information Processing Systems (NIPS)*, 2015, pp. 802–810.
- [27] The PyTorch Team, "Torchvision," [Online]. Available: <https://github.com/pytorch/vision>, 2016.
- [28] R. Wightman, "PyTorch Image Models," [Online]. Available: <https://github.com/huggingface/pytorch-image-models>, 2019.