


インタラクティブGAによるCNNの汎化性能に必要なとなる訓練画像の探索

永田研究室 EMM2507 邵 広生

背景と目的

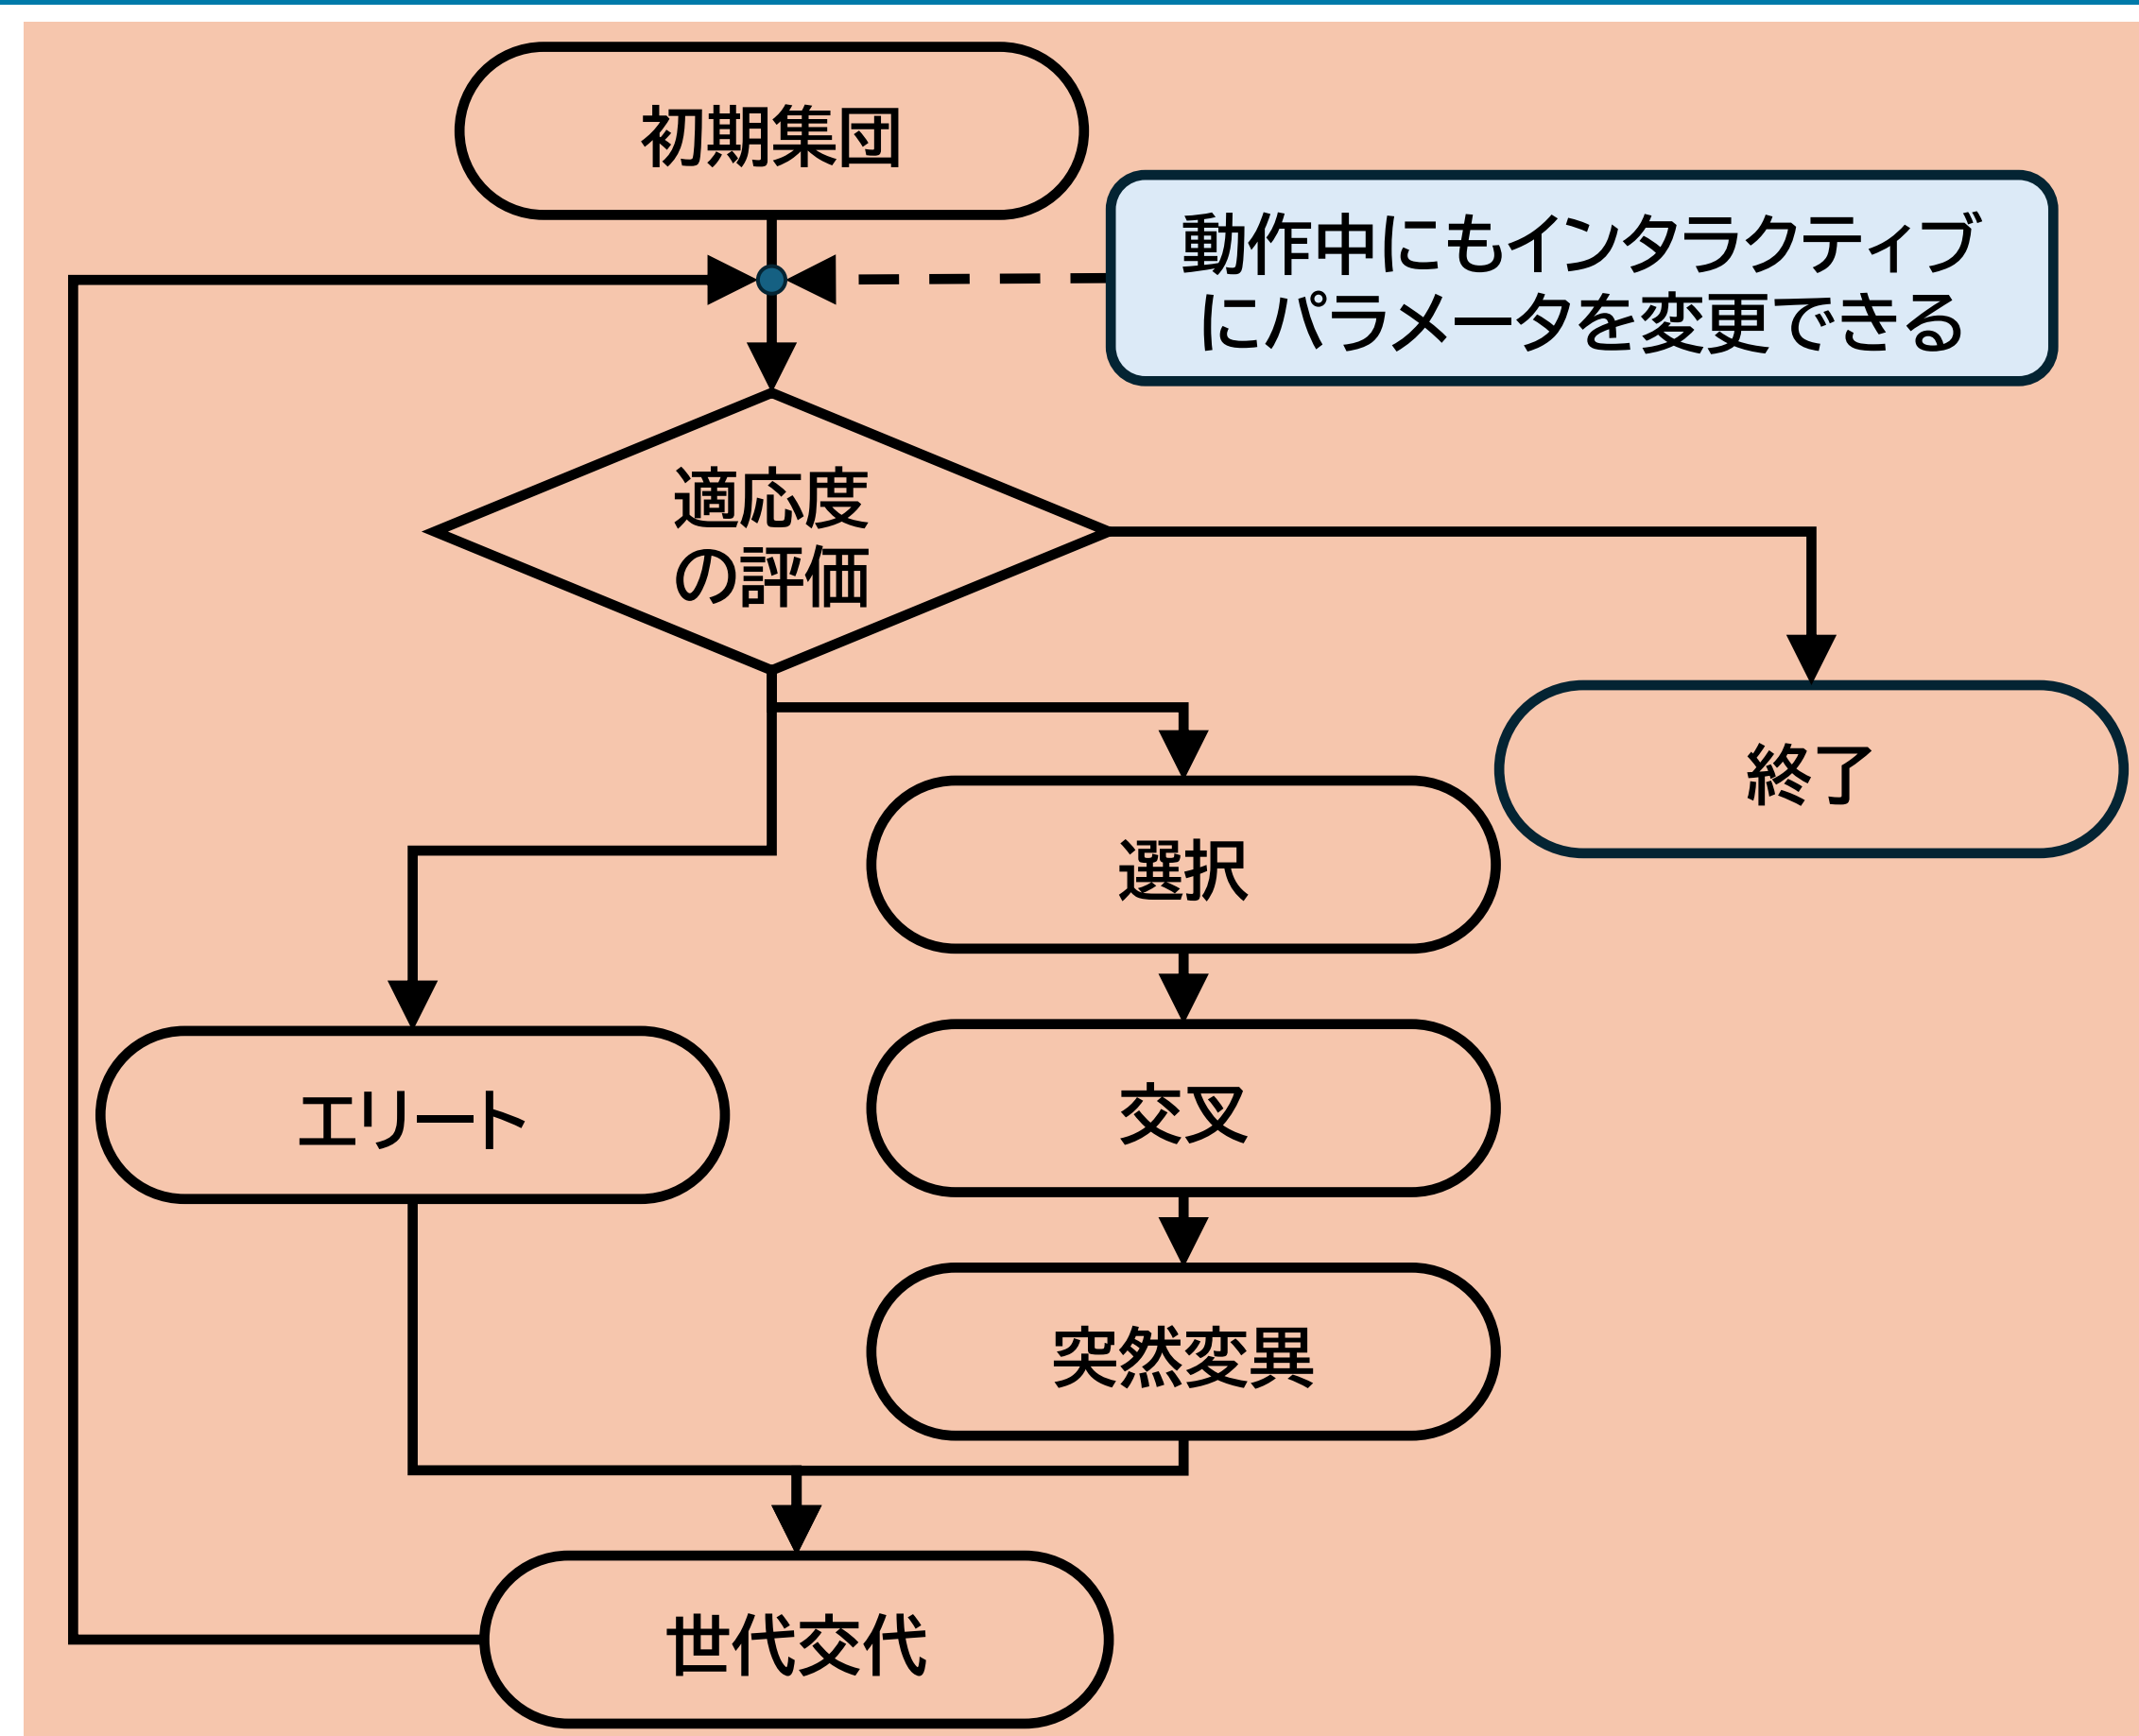
- 様々な工業製品や工業材料の生産現場では、完成した製品に欠陥が含まれていないかを確認するための検査工程が設けられている。検査工程における製品の検査は一部で自動化が進んでいるものの、現在でも熟練した検査員による目視検査に頼るところが大きい状況である。
近年、深層学習の技術を画像認識に特化させたCNNや、CNNを特徴抽出器としてSVMと融合させたAIモデルなどを製品の欠陥検出に応用しようとする試みが数多く報告されており、非常にホットな研究領域が形成され、日々新たな手法が公開されるなど高性能化に向け進化を続けているようである。
- 本研究では、インタラクティブGAを用いてそのようなパラメータの自動調整を試み、設計者が望ましいCNNモデルを構築していく上で、指針となる条件を提案できるシステムの構築を目指す。インタラクティブGAにより、ユーザとのインタラクションを通して、目標とするCNNモデルの構築が可能となる。

遺伝子コード



- 本研究でのGAによる探索パラメータは、最大エポック数（整数）、ミニバッチサイズ（整数）、学習率、蓄積した訓練用画像データセットから実際の訓練に用いた画像の抽出割合X [Image rate %]（整数）の4つであり、画像データセットからの抽出割合については、例えば100が設定された場合には訓練用データが全て用いられ、80が設定された場合はランダムに抽出された80%の画像が訓練に用いられる。
- これら4つの表現型は左図のように8ビットで二値化し、遺伝子コードに変換している。今回の実験では、集団を2つのエリート個体 ($E=2$) を含む12個体 ($N=12$) で構成し、1個体は32 (=8ビット×4) ビットの遺伝子長となる。

インタラクティブGAのフロー



- まず、初期集団に含まれる各個体の適応度を評価し、エリートの2個体はそのまま残し、残った10個体に遺伝子操作を行う。適応度とは、個体が集団内で生存する上での優位性を示す指標であり、本研究では訓練後のCNNの汎化性能（分類精度）で表現している。
- その後、トーナメント選択により、エリートを除く個体の中からランダムに3個の個体を選択し、その中で適応度の高いものを次世代に残していく。この操作を全個体数－エリート数の回数だけ実行し、次世代にも同数の個体を生成させている。選択の後には交叉処理を行う。今回は交叉確率50%の一様交叉を用いた。さらに、突然変異率は上図に示す遺伝子コードのビット長を考慮し、 $1/32 = 3.13\%$ としている。
- GAが動作中もインタラクティブに4つのパラメータの探索範囲を変更できるようにしている。

これまでに得られた結果

マニュアル設定によるパラメータ調整の場合

- 比較対象として、研究室の卒研7人がそれぞれ、試行錯誤的にパラメータを調整しながら手動操作でCNNの訓練とテスト画像による評価を行った。
- 下表には各学生が5回ずつ行った訓練で得られた5つのCNNモデル(sssNet)をそれぞれ、テスト画像で評価した結果（分類精度%）を示す。なお、テスト画像に対する十分な精度が得られるように40から100のエポック数の範囲で訓練を行っている。

Accuracy	Trial 1	Trial 2	Trial 3	Trial 4	Trial 5
Student 1	81.13%	80.90%	82.93%	80.93%	79.90%
Student 2	81.03%	81.30%	79.93%	78.27%	81.73%
Student 3	82.17%	81.07%	80.43%	78.57%	82.27%
Student 4	81.97%	80.80%	82.30%	78.53%	81.97%
Student 5	79.63%	81.53%	80.63%	80.93%	78.90%
Student 6	82.93%	80.23%	80.60%	80.46%	80.90%
Student 7	82.10%	80.23%	80.67%	81.20%	73.13%

インタラクティブGAによる自動調整の場合

- 下表には、提案手法であるインタラクティブGAを用いてCNNの自動訓練を行ったとき、ベストの個体が達成した分類精度を示している。この結果から、GAを用いることで高い分類精度が得られるようなパラメータを自動的に獲得できることが確認された。また、CNNの訓練で使用されたImage rate Xの値に示されるように、データセット内の限られたデータを使うだけで全てのデータを使ったときと同等の汎化性能が得られることも確認された。

Parameter	Trial 1	Trial 2	Trial 3	Trial 4	Trial 5
Generation	9	3	18	27	2
Accuracy	82.10%	82.23%	82.63%	82.80%	82.47%
Image rate	86%	93%	95%	97%	90%
Mini batch size	22	23	19	24	6
Max Epoch	39	33	42	48	31
Learning rate	0.0003	0.0004	0.0004	0.0004	0.0001

まとめと今後の展開

本研究ではインタラクティブGAを応用し、設計者が望ましいCNNモデルを構築していく上で指針となる学習条件を提案できるシステムの構築を目指した。インタラクティブGAにより、ユーザとのインタラクションを通して、設定した探索範囲内でパラメータを自動的に調整しながら目標とするCNNモデルの構築が可能となった。特に、目標とする汎化性能を獲得するために必要となる画像データセットのサイズのシステムティックな探索（特徴量の豊富な画像の探索）も可能となった。今後は、異なるタスクドメインでの有用性を検証するために、他の種類のデータセットを用いて検証実験を行う予定である。