外観検査画像処理プログラム自動生成における 検出失敗時の追探索*

坂井 舜** 長田 基 ** 鈴木航平*** 青木公也†

Functionally Enhancement of IPNP(Image Processing Network Programming)
for Modifying Appearance Inspection Program

Shun SAKAI, Hajime OSADA, Kohei SUZUKI and Kimiya AOKI

In this paper, we discuss a method for automatic programming of inspection image processing. Generally, an automatic appearance inspection in a manufacturing process has been expected from a viewpoint of reliability and efficiency of the inspection. However, the automation of the appearance inspection using image processing technology is not always easy. This is because building the system requires proficiency in selecting the image processing logic and tuning the parameters. Therefore, we had proposed a method for automatic programming of inspection image processing system called "Image Processing Network Programming (IPNP)". In this study, we extend the functionality of IPNP. Concretely, that function is modifying an appearance inspection program automatically when it fails to detect a defect region. It is verified from experiments that the proposed method can modify inspection image processing programs.

Key words: appearance inspection, evolutionary computation, artificial intelligence, image processing

1. 緒 言

製造工程における外観検査は、原材料の選別から最終製品の良否判定に至る検査によって不良の流出を防ぎ、製品の品質を保証する役割を果たしている。従って、検査の信頼・効率性の観点から、画像処理技術による自動化が進められてきた¹⁾。しかし、必ずしも外観検査の自動化は容易ではない。結果的には画像処理の基本技能だけで自動化が達成された場合でも、その処理ロジックやセンサ選定・照明条件は、対象に応じた調整・設計が必要となる。つまり、外観検査装置は検査対象・項目毎にワンオフ開発になりがちである。しかしモノづくり企業からは、少量多品種、多種多様な検査項目、検査仕様・基準の変化へ対応可能な汎用性・融通性が求められている。そこで著者らの研究グループでは、検査装置における画像処理ソフトウェアを自動で生成する手法を提案してきた^{2)~4)}。

2. 研究背景と目的

外観検査の自動化が進まない現場では、そもそも良否判定の規格・基準が定性的で曖昧な場合が多い。そのためそういった現場では、熟練者(検査員)によって、限度見本や経験、ノウハウに基づいて外観検査が行われる。一方、それほど検査難度が高くなるとも、自動化のために画像処理コマンドを選択し、パラメータチューニングを行うことには習熟が必要である。また、運用時の装置の調整も同様である。そこで、画像処理エンジニアでなくて

もロジックの修正・再構築が可能な、汎用性・融通性の高い外観検査システムが必要とされている。

それに対して、AI技術を活用した手法が盛んに研究開発されている。AI技術(本稿では、深層学習に基づく手法を狭義にAI技術と記述する)は、データさえ収集すれば学習(と呼ばれるロジック)によって、自動的に感度設定が達成されるが、一般的には装置導入前に多量の学習データを準備する必要がある。また、誤検出に対する再学習が課題である。

前述の課題は、現状のAI技術が「純然たるパターン認識を実行し、局所的な一般化を達成するモデル⁵⁾」であることが原因の一つである。つまりAI技術によって得られる識別モデルは「抽象化と推論機能を持ち、極端な一般化を達成できるモデル⁶⁾」ではない。一方、検査員や画像処理エンジニアによって構築された検査画像処理プログラムは、与えられたタスク(外観検査)を適切に抽象化・モデル化している。例えば、検査画像から欠陥候補領域を前景としたセグメンテーションタスクに対して構築されたシステムは、設計時に参照された画像から良品・欠陥特徴に比較的大きな変化があったとしても対応可能である。

そこで、人の画像処理プログラムの生成過程に学び、その過程を画像処理ロジックやパラメータチューニングの組み合わせ最適化問題として、進化的探索によって解く方法^{7)~9)}が古くから提案されている。著者らの研究グループでもIPNP(Image Processing Network Programming)^{2)~4)}と呼ぶ、遺伝的ネットワークプログラミングを基本とする手法を提案している。

本研究では外観検査の課題の内、素形材に発生する不定形の欠陥領域抽出を目的とする。素形材とは、素材に熱や力に加えられ形が与えられた部品や部材のことであり、具体的な加工方法としては、鋳造、鍛造、粉末冶金、プレス加工、プラスチック加工、セラミック加工等多岐に渡る。図1は欠陥を含む素形材表面を模擬した画像であるが、一般的に

* 原稿受付 令和2年5月22日

掲載決定 令和2年10月16日

** 中京大学大学院工学研究科 (愛知県名古屋市中区八事本町101-2)

*** 中京大学工学部 (愛知県名古屋市中区八事本町101-2)

† 正 会 員 中京大学工学部

Fig.1 Inspection Image

Fig.2 Image Processing Network Programming

は加工方法や材料によって様々なテクスチャを有し、欠陥はこの背景に紛れる不定形領域として存在する。図 1(b)のように被検査画像から背景テクスチャと分離して欠陥領域を抽出することができれば、欠陥のサイズ、密度、個数等を定量的に計測することができる。この画像処理課題に対する IPNP を使った画像処理プログラムの自動生成において、AI 技術による自動化課題でもある誤検出に対する再学習(追探索)に着目し、IPNP の機能拡張として追探索法を提案する。

3. IPNP の概要 2)9)

IPNP では、図 2 に示すように、画像処理プログラムを処理ノードと判断ノードからなるネットワーク状の有向グラフで表現する。処理ノードには画像処理コマンドが、判断ノードには画像特徴抽出コマンドが設定される。処理はスタートノードから開始され、処理ノードの場合は設定された画像処理が実行され、その際の結果を専用バッファに保存しつつ、次のノードに遷移する。判断ノードの場合は専用バッファに保存されたいずれかの画像の画像特徴が計測され、それによって遷移先が選択される。従って、順接・反復・分岐の三つの制御構造から成る一般的な構造化プログラムが記述される。

このネットワークを進化的計算手法によって探索する。模式図を図 3 に示す。初めに、各ノードの関数や接続先、スタートノードがランダムに選択された画像処理プログラムが個体数分生成される。個体群が用意されたら、画像処理プログラムを表す個体にトレーニングデータを入力し、設計した評価関数を用いて適応度の算出を行う。最適化における評価関数はタスクによって様々考えられる。本研究で取り上げる、被検査画像中から欠

Fig.3 Evolutionary Computation

陥領域を前景として抽出するセグメンテーションタスクにおいては、構築されるロジックに被検査画像を入力した際の出力と理想的な出力(欠陥領域が抽出された画像)との一致度を評価する。そして評価された結果を基に個体群を順位付けする。この初期個体群に対して、順位に基づいて選択された個体間で部分的にネットワークをスワップする交差や、ノードの関数や接続先などをランダムに変更する突然変異などの遺伝的操作を適用し、次世代の個体群が生成される。以上の処理を終了条件が満たされるまで繰り返し、最終世代において適応度が最も高い画像処理プログラムが採用される。

IPNP では、検査画像処理プログラムの表現を抽象度の異なる三つのカテゴリに分類し、探索効率を向上し、かつ自動生成されるプログラムの規模を適切に抑制している。具体的には、ノードに設定される画像処理コマンド・パラメータを予め「理論」、「表現」、「実装」のレベル¹⁰⁾に入れ子状に分類する(具体例は、後述の表 1 に示す)。図 4 に、これらの抽象度の異なる表現関係を用いた画像処理プログラム生成の流れを示す。初めに(i)に示すように、画像のノイズをキャンセルする平滑化処理、欠陥のみを抽出する 2 値化処理、2 値画像の補正処理といったプログラムの一連の流れを構成する「理論」の検討を行う。次に(ii)に示すように、「理論」レベルにおける平滑化処理には具体的にはガウシアンフィルタを用いるといった、「表現」の探索を行う。最後に(iii)に示すように、「表現」レベルにおいて選択された手法について、「実装」レベルとしてパラメータの調整を行う。ただし、この関係性は必ずしも抽象度の高いレベルから低いレベル(「理論」→「表現」→「実装」)にのみ遷移するのではなく、「実装」の選択段階で実用解が見つからなければ、「表現」の探索をもう一度行うなど、それぞれのレベルは互いに影響し合う。

IPNP で実際に生成される検査画像処理プログラムの例を図 5 に示す。生成される検査画像処理プログラムは「平滑化→プロブ面積特徴→プロブ面積特徴」の「理論」、「平滑化: ガウシアンフィルタ→プロブ面積特徴: 領域面積特徴最大値→プロブ面積特徴: 特定ラベルの領域面積」の「表現」、加えて各種パラメータまで含めた「実装」のように、3 種類の抽象度の異なるレベルで表現することが可能である。この抽象度の異なるプログラム表現は、現状の AI 技術に基づく外観検査システムでは困難な再学習(IPNP では追探索)を可能にすると考えられる。

Fig.4 Relations of Abstraction

Fig.5 Expression Style

4. 提案手法

4.1 概要

教師あり学習では一般的に、サンプルデータセットを少なくともトレーニングデータとテストデータの二つに分割する。ここで、テストにおいて判別に失敗したデータへの対応が重要である。本研究における素材上の不定形欠陥領域の抽出で考えると、トレーニングデータに基づいて背景テクスチャと前景欠陥領域にセグメンテーションできたとしても、テストデータにおいて未検出や虚報(過検出)領域があった場合は、なんらかの修正が必要となる。本質的には、予め実際に発生し得る被検査画像を網羅した十分な量のデータセットを準備する必要があるが、製造現場では困難である。この点において IPNP は、AI 技術と比較して少量のデータセットでも目的とする画像処理プログラムを自動生成し得ると考えられる。一方、IPNP による欠陥検出プログラムの自動生成において、その探索の効率性や収束性を考えれば、発生し得る被検査画像を網羅した最小枚数をトレーニングデータとするのが理想的であるが、その選択は困難である。

以上のことは、外観検査システムの運用前にかかる話であるが、運用後に誤判定が発生した際も速やかに検出感度

を再設定する必要がある。しかし 2 章で述べた通り、AI 技術を用いたシステムは局所的な一般化を達成したシステムであることから、学習済みのモデルの部分的な修正は困難であり、このことが導入の阻害要因の一つとなっている¹¹⁾。例えば、単に誤検出した画像をトレーニングデータに追加する方法ではうまくいかない。一方、IPNP ではこの単純な方法が可能である。つまり、誤検出した被検査画像に対応できるよう、既存のプログラムの「実装」レベルのパラメータをチューニングしたり、「表現」レベルの処理コマンドを変更したり、判定ノードを追加して新たな処理経路を生成する等に対応でき得る。

以上、予め準備したサンプルデータを使った運用前のシステム構築と、運用後の誤判定への対応のいずれにおいても、追探索・再学習の方法は重要であると考えられる。そこで本研究では、自動生成される画像処理プログラムが異なる抽象度で表現でき、かつ解釈性が高いという特長に着目し、IPNP に追探索の機能を付加する。まず、テストデータにおいて誤検出した場合に追探索する際のトレーニングデータの追加・更新方法を提案する。さらに、更新されたトレーニングデータを使って IPNP によって画像処理プログラムを追探索する際の既存のプログラムの再利用方法について提案する。

4.2 追探索におけるデータ選択

IPNP で生成されるプログラムでは、処理ノードの画像処理による画像特徴抽出や判断ノードによる画像特徴計測によって、各トレーニングデータに合った処理経路が生成される。トレーニングデータ内で類似した画像はグループ化され、グループ毎に画像処理手順(処理経路)が生成される。逆にいえば、テストデータを入力した場合、その処理経路によって画像を分類することができる。処理経路は画像の特徴を表すと考えられる。

そこで本研究では、誤検出した被検査画像を検査画像処理プログラムの処理経路の類似性から分類し、代表的な画像をトレーニングデータに追加する方法を提案する。そうすることで、サンプルデータを網羅したトレーニングデータを用意することができると考えられる。模式図を図 6 に示す。処理の流れは次の通りである。

Fig.6 Update of Training Data

Fig.7 Program Reuse

Fig.8 Sample data

- ① トレーニングデータを用いて検査画像処理プログラムを生成する
- ② テストデータにおいて、欠陥領域となる前景をうまく検出できない場合、自動生成されたプログラムにおける処理経路を追跡し、経路が同じ画像をそれぞれの画像群に分類する
- ③ 分類後、それぞれの画像群から画像を一枚以上選択し、それらをトレーニングデータに加えて追探索する

4.3 検査画像処理プログラムの再利用

追探索において追加トレーニングデータを割り出した既存の画像処理プログラムを再利用する手法を提案する。検出に失敗する要因として、学習不足と過学習が考えられる。IPNPにおける学習不足は、トレーニングデータに検出に失敗したテストデータに類する画像がなく、適切な経路が構築されなかったことを表す。また、過学習という観点では、より抽象度の低いレベルでの問題であると考えられる。つまり、例えば「実装」レベルでのパラメータがトレーニングデータに過剰に適合していること等が考えられる。以上を踏まえることを前提に、テストデータにおいて検出に失敗した画像があったロジックを再利用する手法を提案する。

再利用の具体的な方法は様々考えられるが、進化的探索において検出に失敗した画像があったプログラムを初期個体群に加

える手法を提案する。既存の画像処理プログラムをどのレベルの抽象度まで再利用するかが重要である。ただし、前述の学習不足と過学習の観点から、それを明に決定することは困難である。従って、既存プログラムについて、図7のように異なる三つの抽象度で表現されたものを使用した。既存プログラムの「理論」のみ採用し、「表現」、「実装」をランダムに設定する個体と、「理論」、「表現」まで採用し、「実装」はランダムに設定する個体を、それぞれある比率で準備する。また、プログラムの再利用による過学習抑制のため、「理論」もランダムに設定する個体も初期個体群に加える。以上より、欠陥検出可能であったデータに対する処理経路は担保されつつ、検出に失敗したデータに対しては新しくグループ化され、それに応じた処理経路が追加されると考えられる。

4.4 探索における評価関数(適応度)

本研究では、2種類の評価関数を組み合わせる。具体的には、目標画像と出力画像の黒画素(欠陥領域)と白画素(背景領域)の重なり度と、黒画素領域のエッジ画素の重なり度をそれぞれ算出し、加重平均をとる。適応度は0.0~1.0の値で出力される。

具体的には目標画像と出力画像との重なり度と、エッジマッチによって算出するものを組み合わせた評価関数を用いる。以下の式によって適応度(Fitness)を算出する。

$$Fitness_A = \frac{Match_B}{Train_B} * Weight_B + \frac{Match_W}{Train_W} * Weight_W \quad (1)$$

$$Fitness_E = \frac{Match_E}{Output_E} \quad (2)$$

$$Fitness = Fitness_A * Weight_A + Fitness_E * Weight_E \quad (3)$$

$Fitness_A$ は目標画像と出力画像の重なり度である。 $Train_B$ は目標画像の黒画素(欠陥候補部)の数、 $Train_W$ は目標画像の白画素(背景部)の数を表し、 $Match_B$ は画素(i,j)で目標画像、出力画像が共に黒画素であった場合の数、 $Match_W$ は同様に白画素であった場合の数を表す。 $Weight_B$ と $Weight_W$ は黒画素、白画素、それぞれの重なり度の重みを表す。 $Fitness_E$ がエッジマッチによる評価値である。なお、エッジ画像はラプラシアンフィルタを適用後、2値化したものを使用する。 $Output_E$ は出力エッジ画像のエッジ部の画素数、 $Match_E$ は出力エッジ画像のエッジ部と目標エッジ画像のエッジ部の重なっている画素数を表す。式3が最終的な適応度であり、 $Weight_A$ と $Weight_E$ は欠陥領域の重なり度とエッジの重なり度、それぞれの重みである。

5. 実験と考察

5.1 概要

本実験では、提案手法(追探索)の有用性を示す。初めに被検査画像のサンプルデータをトレーニングデータとテストデータに分割し、IPNPを用いて画像処理プログラムを生成する。生成されたプログラムはテストデータにおいては誤検出があり得るが、提案手法の追探索を適用することによってリカバリー(性能向上)できるかを確認する。

5.2 実験で使用するデータセット、評価関数、パラメータ

本研究で検査対象とする素素材は、その加工方法や材料

Table1 Process Function・Judge Function・Parameter

(a) Process Function			(b) Judge Function			(c) Parameter	
Theory	Representation	Implementation	Theory	Representation	Implementation		
Binarize	Adaptive Threshold	None	Edge	Laplacian	Filter Size	Number of Judge node	10
	Otsu	None		Canny	None	Number of Process node	20
	Thresh Binary	Threshold		Sobel(X)	Number	Population	10
	Thresh Binary(INV)	Threshold		Sobel(Y)	Number	Number of Theory(Judge)	3
						Number of Theory(Process)	7
Figure Correction	Dilation	Number	Logical Operation	AND	Number	Number of Expression(Judge)	4
	Erosion	Number		OR	Number	Number of Expression(Process)	4
	Opening	Number		NOT	Number	Blanch	4
	Closing	Number		EOR	Number	Generation	1000
Morphology	Morphology	Number	Gradation Conversion	Tone Curve (+)	f	Crossover value	0.5
	Morphology	Number		Tone Curve (-)	f	Mutation rate	0.05
	Top hat	Number		Tone Curve (S)	f	Limit	15
	Black hat	Number		Nega Posi	f		
Smoothing	Gaussian	Filter Size					
	Blur	Filter Size					
	Median	Filter Size					
	Bilateral	Filter Size					

によって様々なテクスチャを持つ。欠陥像は、そのテクスチャを背景とする不定形領域として存在する。そこで本実験では、図 8 に示す工業用部品の表面欠陥を模擬した公開データセット¹²⁾を用いる。(a)は背景に干渉縞のような模様の良品特徴上に擦れてその背景が潰れたような欠陥がある画像、(b)は背景に線状の良品特徴を有し、それとは異なる方向を持つ線状の欠陥がある画像、(c)は背景に斑模様の良品特徴を有し、シミのような欠陥がある画像、(d)は背景の粗い斑模様の良品特徴上に黒い帯状の欠陥がある画像、(e)は背景の雨柄の良品特徴上にしわのような欠陥がある画像、(f)は背景の帯状の良品特徴上に線状の欠陥を持つ画像、(g)は斑模様の良品特徴上のそれと粒度が同等の円状の欠陥がある画像である。また本実験で使用する目標画像は黒画素を欠陥領域、白画素を背景領域とする。

本タスクは欠陥部抽出(黒画素領域)であるため、 $Fitness_A$ における加重は $Weight_B:Weight_W=6:4$ とした。また、 $Fitness$ における加重を $Weight_A:Weight_E=8:2$ とし、欠陥部の重なり度をエッジマッチで補正することにした。

IPNP に使用する処理関数・判断関数、および進化的探索に使用したパラメータを表 1 に示す。処理関数は「理論」、「表現」、「実装」に、判断関数は「理論」、「表現」の各抽象度に分けられたものを使用する。

5.3 検査画像処理プログラムの生成

提案する追探索法の有用性を示すため、まず IPNP を用いて検査画像処理プログラムの自動生成を行う。以降の実験は図 8 に示した(a)~(g)のデータセットのそれぞれに対して実施する。プログラム生成は各サンプルについて 50 回ずつ行った。また、追探索の効果を実証するため、あえてトレーニングデータは少量の 4 枚とした。生成された 50 個のプログラムの中、トレーニングデータにおいて検出性能が良好であったプログラム一つに、テストデータ(146 枚)を入力した際の結果の一例を図 9 に示す。出力画像には、虚報や未検出が多数存在している場合がある。そこで、このプログラムに追探索を適用する。

5.4 追探索

前述の実験で生成されたプログラムを用いて、追探索を行った。追探索では、提案手法によって選択されたデータを追加したトレーニングデータを使用する。本実験では、元々の 4 枚に選択された 4 枚を追加した 8 枚をトレーニングデータとした。そのため、テストデータにおいて誤検出したデータを分類する際、グループが 4 つ未満の場合は各グループから複数枚を選択する。

ここで、データセット(a)について具体例を説明する。まず、図 9 で検出例を示したプログラムにテストデータ 146

枚を入力した際、検出に失敗したのは 15 枚であった。その 15 枚について処理経路を追跡し、処理経路に基づいて分類する。今回の場合、2 通りの処理経路に分類され、各経路を通る画像は 14 枚と 1 枚であった。従って、1 つ目の経路の 14 枚から 3 枚、2 つ目の経路から 1 枚を選択する。

また、プログラムを再利用する際の抽象度毎の初期個体群における割合は、「理論」を採用したものを 20%、「理論」、「表現」を採用したものを 60%、全てランダムに設定されたものを 20%とした。追探索前のプログラムは、「実装」レベルにおけるパラメータがトレーニングデータへ過剰適合(過学習)し、テストデータにおいて検出に失敗する場合があると考えられる。それを踏まえて、既存プログラムの抽象度レベル毎の採用割合を実験的に設定した。

探索は追探索前と同様、各サンプルについて 50 回ずつ行った。生成された 50 個のプログラムの中、トレーニングデータにおいて検出性能が良好であったプログラム一つに、前節の実験で使ったテストデータを入力した際の一例を図 10 に示す。出力された画像は、追探索前に比べ虚報や未検出が減少する結果となった。

また、図 9、図 10 で検出例を示したプログラムに、テストデータ 146 枚を入力した際の各画像の検出評価値(IPNP の評価関数によって出力される適応度を使用する)の平均値を表 2 示す。追探索することで、適応度の観点からも概ね適切なプログラムへ調整・再設計されたことが分かる。このことから、提案手法のデータ選択では、元のトレーニングデータには足りなかった検査画像が追加され、サンプルデータの傾向を網羅できていると考えられる。ただし、(f)については平均適応度が下がっている。これは、本研究で使用している評価関数の性質によるもので、欠陥部を抽出できた場合でも、虚報プロブによって低い適応度を出力する結果となった。しかし、図 9、図 10 に示した検出結果の一例から分かるように、欠陥領域の検出については他のサンプル同様、問題ないことを確認した。

本研究では、誤検出したテストデータをトレーニングデータに追加する手法を提案した。前述の通り、元のトレーニングデータには足りなかった検査画像を追加することができることを確認した。それに対し、データの追加・変更によりタスク難度が向上し、最適なプログラム生成が困難になるデメリットが考えられる。そこで、本実験で生成された追探索前後の各 50 個のプログラムの内、トレーニングデータにおいて検出性能が良好であったプログラムの個数を確認した。表 3 に結果を示す。上段に追探索前のプログラムの数、下段に追探索後の値を示す。追探索

Fig.9 Result (before additional search)

Fig.10 Result (after additional search)

Table2 Improvement of evaluation value

	(a)	(b)	(c)	(d)	(e)	(f)	(g)
Before	0.977	0.759	0.904	0.905	0.932	0.894	0.974
After	0.985	0.973	0.935	0.952	0.936	0.681	0.985

Table3 Improvement of the generation rate

	(a)	(b)	(c)	(d)	(e)	(f)	(g)
Before	17	10	10	43	4	5	35
After	33	14	18	48	1	0	47

の実験時のほうが適切なプログラムが生成される割合が高い。したがって、トレーニングデータの追加によってタスク難度が高くなっても適切なプログラムの生成が可能であることが分かる。これは追探索時に異なる抽象度で表現されたプログラムを再利用したことで、利用可能な部分はそのままに、足りない部分に関しては更新する、所謂モデル化・抽象化が適切に行われたからであると考えられる。ただし、(e)、(f)についてはその割合が減少している。これについては前述の表 2 についての考察と同様である。実運用においては、微小な虚報プロブを除去する等、自動生成されたプログラムに後処理を追加することは容易である。

また、サンプル(a)の追探索について、検出に失敗したデータ全てをトレーニングデータに追加し生成したプログラムとの比較も行った。提案手法によって 15 枚から 4 枚のみを追加した場合と追加枚数とプログラムの再利用の適用以外は同様の条件で、追探索を 50 回試行した。トレーニングデータにおいて良好な結果を示すプログラムが生成されたのは 6 回であった。それに対して、提案手法では 50 回試行中の 33 回(表 3)であり、提案する追探索手法を適用した方が良好な結果を示すプログラムが多く生成された。これは、単純にトレーニングデータを増やした場合は画像処理タスクの難度が向上し、良好なプログラム生成が困難になるためであると考えられる。一方、追探索のデータ選択・プログラム

の再利用を適用することにより、探索の効率性と収束性が担保されると考えられる。

提案手法である追探索法は、実運用前の検査画像処理プログラム構築での適用と、プログラム導入後のメンテナンスの両方で使用可能である。ただし後者においては運用中に誤検出したかを判断するシステムが必要である。これについては、出力される検査結果画像を定期的にモニタリングすることで導入が可能であると考えられる。検査画像処理は不良品流出防止の観点から、一般的に未検出よりも過検出が発生するように感度調整される。よって設備保全において出力画像をモニタリングすることで、過大に過検出している画像と欠陥領域が検出不足となっている画像を発見し、そのデータを基に追探索を適用することにより検出性能を維持できると考えられる。

6. 結 言

本研究では AI 技術を用いた外観検査自動化の課題の内、誤検出に対する再学習(追探索)に着目し、著者らの研究グループが提案する IPNP の機能拡張を実現した。

誤検出したプログラムに対して提案手法である追探索を適用することで、実験に使用したサンプルデータ 7 種類の内、6 つについては明確に検出性能が向上した。ただし、検出性能が低下した 1 つについても、本研究で使用する評価関数の性質上の問題であり、欠陥検出に関しては問題ないことを確認した。

また、良好なプログラムが生成される割合は、概ね追探索後のほうが多い結果となった。このことからトレーニングデータの追加によって画像処理タスクの難度が高くなったとしても、プログラムの再利用法を適用することにより、適切にモデル化・抽象化され、対応できたと考えられる。

今後はプログラムそのものを再利用するだけでなく、処理経路のまとまりを新しいロジックとしてストックする手法について検討する。つまり、IPNP における画像処理コマンド群の組み合わせから、自動的に任意のタスクに対応する「理論」を生成する。また、IPNP におけるハイパーパラメータ(個体数, 世代数,

トレーニング・テストへのデータ分割)の設計方法について明確化する。

謝 辞

本研究の一部は、JSPS 科研費 JP19K12055 の助成を受けたものです。また、IPNP の開発に尽力された元 CVSLab.(著者らの研究グループ)、現富山大学の吉村裕一郎先生に敬意を表します。

参 考 文 献

- 1) 公益財団法人ちゅうごく産業創造センター：ものづくり企業の生産現場における検査の自動化促進可能性調査報告書，(2016)。
- 2) 吉村，他：画像処理ネットワークプログラミングにより検査画像処理自動生成手法の検討，精密工学会誌，**81**，12，(2015)，1193。
- 3) 伊藤，他：外観検査システム設計における撮像系と画像処理系の相互最適化手法，ビジョン技術の実利用ワークショップ，(2019)。
- 4) 鈴木，他：画像処理プログラム自動生成における Loose Annotation の検討，動的画像処理実利用化ワークショップ，(2020)。
- 5) Francois Chollet, 株式会社クイープ(訳)：Python と Keras によるディープラーニング，マイナビ出版，(2018)。
- 6) 依田育士，山本和彦，山田博三：GA による構造的モルフロジー手順の獲得，電子情報通信学会論文誌 D，**78**，12，(1995)，1758。
- 7) 青木神也，長尾智晴：木構造状画像変換の自動構築法 ACTIT，映像メディア学会誌，**53**，6，(1999)，888。
- 8) 前薮正宜，小野智司，中山茂：遺伝的プログラミングを用いた画像フィルタ設計におけるパラメータ調整とブロード抑制，日本計算工学会，2006，(1996)，20060021。
- 9) 吉村，他：人の実装プロセスに学ぶ検査画像処理ソフト自動生成手法，電気学会論文誌 C，**137**，9，(2017)，1201。
- 10) デビッド・マー：ビジョナー視覚の計算理論と脳内表現一，産業図書，(1987)。
- 11) 橋本大樹，玉垣勇樹，永田毅：外観検査の実務と AI 活用最前線～目視検査のコツから自動化のポイント・人口知能の導入まで～，情報機構，(2018)。
- 12) <https://resources.mpi-inf.mpg.de/conference/dagm/2007/prizes.html> (2020/5/22 確認)