

# Imagification技術とDeep Learningによるブレード非破壊検査支援：製造現場への適用のためのDigital Co-creation

## Imagification Technology and Deep Learning Supporting Non-Destructive Inspection of Blades: Digital Co-creation for Manufacturing Site Applications

● 古屋 早知子      ● Ali Sanaee      ● Serban Georgescu      ● Joseph Townsend  
● Peter Chow      ● Bjarne Rasmussen      ● David Snelling      ● 後藤 正智

### あらまし

風力発電は再生可能エネルギーの中でも期待が大きく、急速に成長している。発電の最重要部品であるブレードには非常に大きな荷重がかかるため、製造工程における品質検査基準は厳しい。品質検査では超音波による非破壊検査を実施しており、例えば全長75mの画像から数cmの欠陥可能性箇所を検出するために、検査技師が細かく分析している。これは長い時間を要する作業であり、ヒューマンエラーが発生する懸念もあった。欧州富士通研究所では、独自開発したImagification技術と画像認識用Deep Learningエンジンを組み合わせて、検査量の削減とヒューマンエラーを予防するための欠陥検知支援システムを開発した。更に、お客様が持つ画像データの知見・知識をデジタル化して統合し、品質検査支援ソリューションを構築した。

本稿では、欠陥検知支援システムの開発の概要と実用化に向けて行ったDigital Co-creation(デジタル共創)について述べる。

### Abstract

Wind power generation is a fast-growing type of renewable energy that is highly recognized for its potential. Turbine blades are a crucial part of power generation systems, and they bear substantial loads in operation. Therefore, quality inspection standards during production are extremely strict. Quality inspections include non-destructive ultrasound inspections, for instance, which involve an engineer's detailed examination of around 75-meter-long image data to identify possibly defective sections of a few centimeters. This is a time-consuming process, and there are always risks of human errors. Fujitsu Laboratories of Europe has developed the unique Imagification technology and combined it with an image-recognition deep learning engine to develop a system for assisting defect detection, helping to reduce the inspection load and prevent human errors. We have further developed the system by digitizing and integrating customer knowledge and expertise from their visual data to build a new quality inspection solution. This paper explains the developed defect detection system and describes the process of digital co-creation with customers to realize commercial applications of the technology.

## まえがき

風力発電は再生可能エネルギーの一つであり、最も急速な成長を遂げている。CO<sub>2</sub>を排出しない無限のエネルギーとして、世界中で需要がある<sup>(1)</sup>

風力発電機は巨大かつ複雑なシステムであり、中でもブレードは発電の最重要部品である。その長さは数十m～100mに及び、湾曲した形状で板厚も場所により異なる。ブレードには発電時に非常に大きな荷重がかかることから、設置後の破損や故障を防ぐために高い構造強度が要求される。また品質検査には、わずかな傷や埃、製造上の欠陥も検出できる先進的な手法が求められる。そのため、外観検査のほかに目視できないブレード内部の検査には、非破壊検査（NDT：Non-Destructive Testing）の一検査法である、超音波深傷試験（UT：Ultrasonic Testing）が重要な役割を果たしている。

その方法は、超音波でブレードをスキャンして内部の欠陥を画像化し、検査技師が読影する。その作業は、全長75mのブレードの画像から数cmの欠陥可能性箇所を見つけ出すことであるため、読影には専門知識と相応の経験が必要とされる。また、欠陥画像は複雑でパターンによる分類が困難であるため、AI（人工知能）技術を用いた効率化が検討されていた。

富士通では、2015年にFUJITSU Human Centric AI Zinraiを発表<sup>(2)</sup>以来、AI技術をAPI（Application Programming Interface）やクラウドサービスとして提供してきた<sup>(3)</sup>。欧州富士通研究所（以下、FLE）も、設計・製造分野から金融、リテール分野などでAI技術の社会実装を進めている。FLEは、非画像データを画像化するImagification技術の開発に成功し、画像認識用Deep Learning（深層学習）エンジン（以下、DLエンジン）を利用した特徴認識を可能にした<sup>(4)</sup>。

本稿では、Digital Co-creation（デジタル共創）で実現した、AI技術を活用したNDTの効率化について述べる。

## ブレード製造における品質管理の課題

前章で述べたとおり、ブレードの品質検査には、超音波によるNDTが導入されている。撮影した画

像を細部にわたって分析し、欠陥の可能性がある箇所、例えば材料の積層方向に平行したシワ、異種材料間に発生する空隙や異物といった製造上の欠陥や外部起因の塵や傷などを見極める。このようにして検出された箇所は、その後の工程で補修される。風車ブレードの製造メーカー各社は、品質向上のための技術開発が活発で、これらの欠陥が発生する可能性は極めて少ない。しかし、ブレード内に欠陥が一つ残るだけでも設置後の破損や故障のリスクは高くなる。そのため、全ての検査画像を検査技師が画面上で読影し、分析する必要がある。

この画像の検査量を削減するために、あらかじめ欠陥の可能性がある箇所を絞り込む支援システムを開発する必要があった。そのシステムが欠陥の可能性のある箇所を全体の20%まで絞り込み、残りの80%は無視することで、検査員は欠陥の可能性のある箇所にだけ注目すればよい。このような支援システムを開発することで、画像の検査量を削減してヒューマンエラーの発生を抑制できる。

## Imagification技術とブレードの非破壊検査への適用

Imagificationとは、image（画像）と接尾辞-ification（～化すること）から成る造語で、画像化を意味する。本章では、Imagification技術とDLエンジンの関係、およびNDTへの適用について述べる。

### ● Deep Learning適用の課題

Deep Learningを実用レベルで運用するためには、数十から数百万以上のデータを用いて、対象の特徴を学習させる必要がある。しかし、お客様側でこうした大規模なデータを準備できることはまれであり、十分な学習に基づいた実用的性能の実現は困難である。

また、学習に用いるデータの質も重要であり、特にデータの分類（Labelling）は精度に大きく影響する。超音波画像の読影には専門的な知識が必要になるため、データに関する専門的知見などの情報交換が重要になる。これについては次章で述べる。

### ● Imagification技術

Imagification技術は、少ないデータ量でもDLエンジンの学習効果を高めることを目的としており、

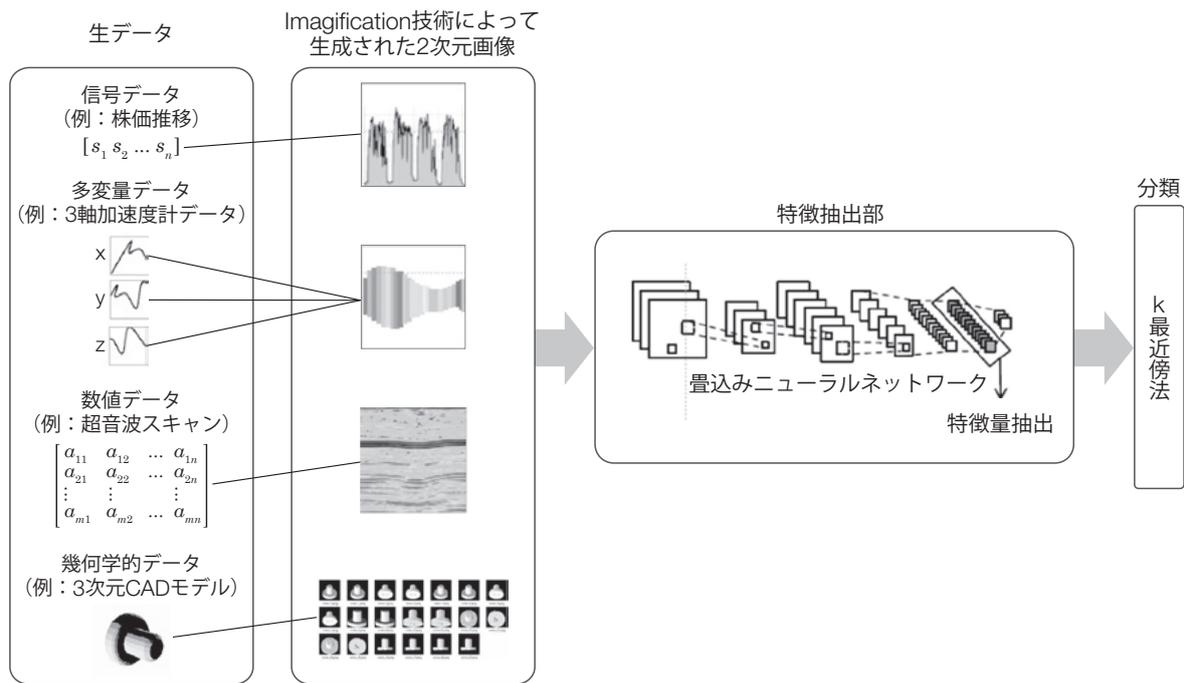


図-1 Imagification技術による画像化と汎用DLエンジンによる特徴分類

次の二つの特長がある。

(1) 非画像データの画像化

Imagification技術に適用可能なデータの種類の、2次元画像データのほか、3次元CADモデル、株価推移や3軸加速度計などのデータ、レジスタのシステムログに代表される時系列データなど多岐にわたる。図-1に示すように、センサーやCADモデルなどの生データにImagification技術を適用し、DLエンジンに入力して、学習モデルを作成する。

(2) 効果的な学習を実現するための前処理

(1) で画像化したデータに対して、学習効率が最大になるようなパラメーター調整を行う。例えば、画像の明るさやコントラストなどもパラメーターの一つである。より実践的な例として、3次元CADモデルを用いた自動部品検出<sup>(5)</sup>では、特徴量を用いて類似部品の抽出を行った。図-1左下に示す3次元CADモデルの2次元画像化において、カメラ角度をパラメーターとして用い、更なる精度向上のために部品サイズや面積などの情報を取り入れた。Imagification技術では、画像処理や信号処理の手法を組み合わせることで特徴を抽出することで、効率的な学習用データの作成を実現した。

● NDTへのImagification技術の適用

本事例における入力データは次の2種類である。

(1) 生データ

超音波により撮影されたブレードの数値データ

(2) メタデータ (CSVファイル)

(1) とリンクした付帯情報、欠陥可能性箇所の座標位置やデータ番号など

図-2は、NDTデータ用に構築したImagification技術とDLエンジンを用いた一連の処理の流れである。初めに、生データを画像化するScan Plottingと、75 mに及ぶブレードの画像を適度な長さに切断するImage Patchingを行う。前準備として、データを学習用とテスト用に分け、学習用データはメタデータを基に分類する。この学習用データをDLエンジンに入力し、欠陥可能性箇所とそれ以外の画像パターンを学習する。次にテスト用のデータを用いて、学習モデルの妥当性を評価する。十分な性能が得られない場合には、パラメーターを調整して再学習させる。

この一連の処理の有効性を確認するために、新規のデータセットを用いて評価した結果を以下に示す。

- ・ 欠陥可能性箇所検出率<sup>(注1)</sup>：89.5%
- ・ 1ブレードあたりの検査量<sup>(注2)</sup>：28.4%

(注1) 欠陥部分をDLエンジンで正しく欠陥と検出した割合。

(注2) 画像全体を100%とした場合、DLエンジンが欠陥と指摘した部分の割合。

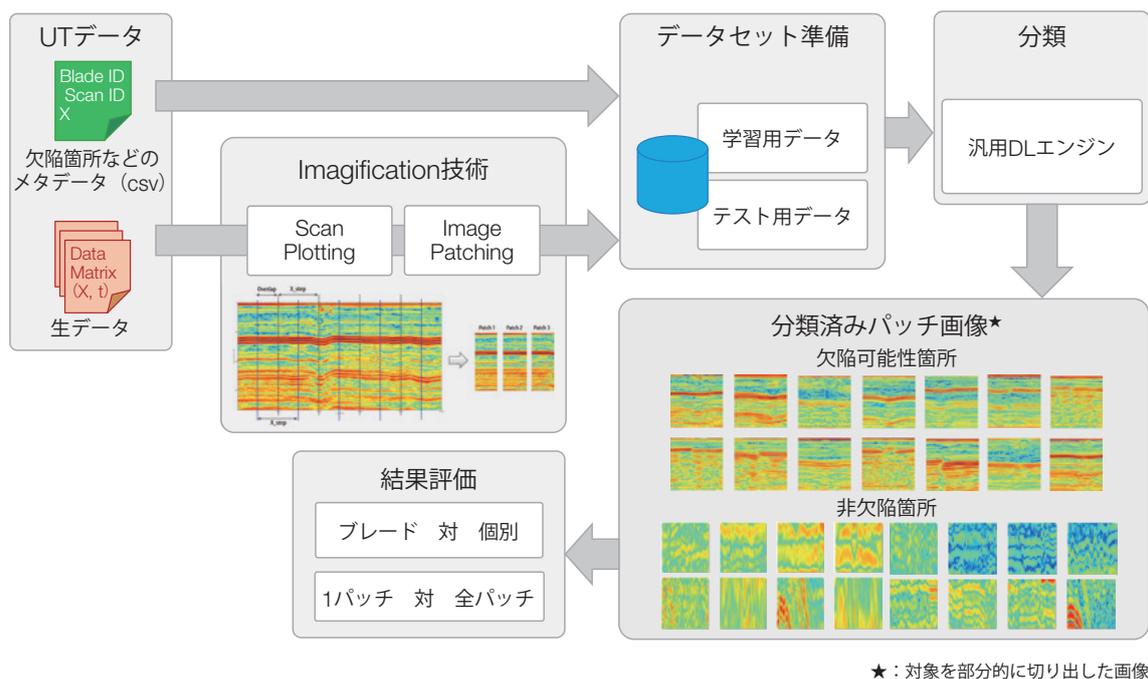


図-2 UTデータ用Imagification技術と処理の流れ

### 製造現場適用のためのDigital Co-creation

本章では、前章で有効性を確認したシステムを製造ラインに適用するためのソリューション構築について述べる。

本プロジェクトでは、評価基準の設定とビジネスに適した技術要求から始まり、製造ラインへの適用要件を以下のように定めた。

- ・欠陥可能性箇所検出率：95%以上
- ・1ブレードあたりの検査量：20%以下

前述したように、ブレード製造手法は既に各社が試行錯誤を重ねており、欠陥そのものの発生数が少ない。そのため、予想した以上に限られた学習用データサンプルから上記要件を満足しなればならなかった。

#### ● Digital Co-creationの実践

前章で述べたように、学習用データの質が最終的なシステムの精度に大きく影響することから、検査工程や超音波検査の専門知識を踏まえた上でデータを理解することが重要である。プロジェクトの実行に当たり、NDTの品質管理技術者から以下の専門的な知識などがFLEに提供された。

- ・ブレードの設計や構造に関する知識
- ・NDTのプロセス

- ・超音波画像による検査と最終検査工程の知見・知識

課題解決に必要な要素は、データとそれに関連する知識・知見である。実用レベルの性能を満たすためには、製造手順や日常的に検査技師が暗黙知としているノウハウのデジタル化が必要である。そのために、品質管理グループのメンバーとの会話を繰り返した。彼らはNDTにおける長年の経験から、画像の分析と評価、そして抽出したデータから導かれた欠陥の種類とその発生確率などを細かく分類し、FLEに提供した。FLEが構築したシステムに対する理解と認識結果の整合性を確認するために、特徴的な画像パターンとブレード材料の分析を行うなど、画像の専門知識を提供する側にとっても複雑なタスクであった。

FLEでは、提供されたデータから作成した学習モデルの精度を向上させるために、次の三つの手順の有効性を繰り返し確認した。

- ・技術適用上の課題抽出
- ・Imagification技術の機能拡張
- ・拡張後のImagification技術とDLエンジンの最適化

更に、ワークショップを数回開催し、システムの実行能力とこのソリューションにおけるゴール

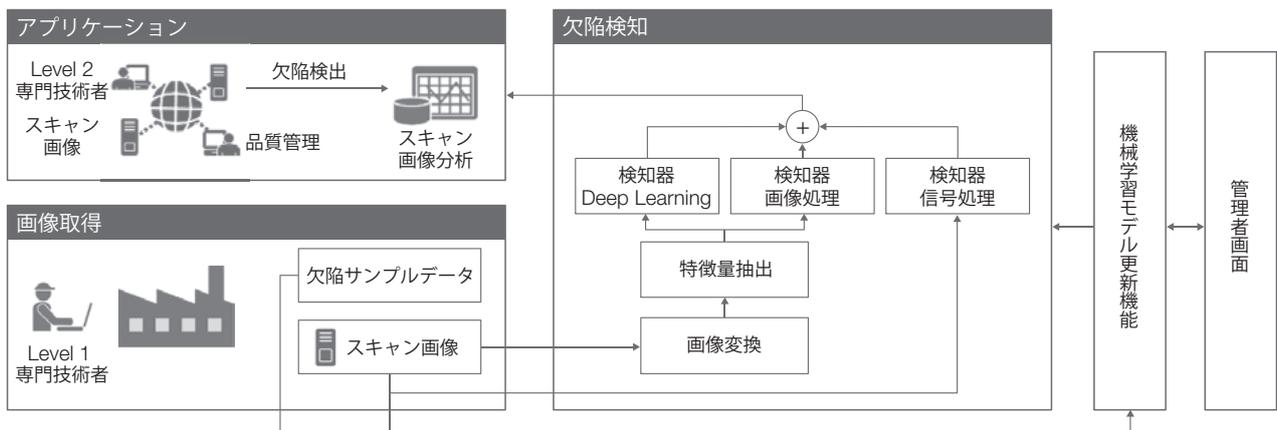


図-3 欠陥検知支援ソリューションの構成

の合意形成を行った。実データや知識・知見を含めて欠陥を判定するノウハウ、およびFLEが持つImagification技術とDLエンジンによって構築されたものが、図-3に示す欠陥検知支援ソリューションである。これは超音波によるNDTが持つ課題解決に特化したオーダーメイドソリューションである。<sup>(6)</sup>

3か月という短期間で開発したシステムの最終評価では以下の結果が得られ、製造ラインへの適用要件を満たした。

- ・欠陥可能性箇所検出率：95%
- ・1ブレードあたりの検査量：18%

Digital Co-creationでは、現場の専門知識とノウハウの抽出、およびお客様との会話が必須であるが、場合によっては現場の日常業務にも支障を来しかねない。そのため、信頼関係の構築とタイムマネジメントが求められることから、常に効率的な会話を意識して開発を進めた。Sprintsと名付けて2週間ごとの電話会議で進捗状況の共有と試行錯誤を繰り返し、更に対面でのWorkshopを2度開催し、最終的に要件を満足できた。

### 今後の課題と展望

これまでの取り組みで実用レベルの欠陥検出精度を達成できたが、今後実用化するためには、更に完成度を高める必要がある。例えば、1秒以内に描画する高速表示やカラープロファイルの充実などがある。

また、Deep Learningを運用する上で注意しなければならない点は、新しい種類の欠陥に対しては

検出精度が低くなることである。ブレードは複合材から成る積層構造であり、製造工程のほとんどは手作業である。このため、欠陥の画像パターンは複雑で分類が難しい。したがって、品質検査の精度を維持するためには、定期的な学習モデルの更新が必要になる。

再学習には新たな欠陥画像を収集する必要もあるため、運用側の負担を最小限にする再学習環境が求められる。更に、大きさの異なるブレードに適用する場合は、現状の学習モデルを再評価する必要がある、アフターサービスの体系化が課題である。

ここまで紹介した取り組みは、国と部門を越えたプロジェクトである。Fujitsu A/SとドイツのFujitsu Technology Solutionsの営業部門を通じて、あるブレード製造メーカーからFLEへの問い合わせがきっかけで始まり、日本の富士通研究所の支援を受けながらFLEが技術開発を行った。ビジネス化は、Fujitsu A/Sと日本の富士通アドバンステクノロジーが牽引した。

Imagification技術には、NDTをはじめとして幅広く他産業に活用できる可能性がある。現在、イギリスのFujitsu Servicesでは本事例を基にしたFujitsu Advanced Image Recognition Solutionを構築中であり、更に業界を越えた実用化を目指している。

### む す び

本稿では、ブレード製造における品質検査の効率化のために、Imagification技術とDeep

Learningを活用したソリューション構築におけるDigital Co-creationの事例を紹介した。

今後は、追加学習モジュールの開発によって更なるソリューションとしての価値向上を目指すとともに、Fujitsu Advanced Image Recognition solutionとして他産業にも展開していく。

## 参考文献

- (1) 自然エネルギー世界白書2017.  
<http://www.ren21.net/status-of-renewables/global-status-report/>
- (2) 富士通：当社が培ったAI技術を「Human Centric AI Zinrai」として体系化。  
<http://pr.fujitsu.com/jp/news/2015/11/2.html>
- (3) 富士通：Fujitsu Human Centric AI Zinrai.  
<http://www.fujitsu.com/jp/solutions/business-technology/ai/ai-zinrai/>
- (4) Fujitsu EMEA : Fujitsu Advances AI for Social Innovation, Aiding Safer Driving with New Deep Learning Solution.  
<http://www.fujitsu.com/fts/about/resources/news/press-releases/2016/emeai-160609-fujitsu-advances-ai-for-social-innovation.html>
- (5) 野崎直行ほか：製品設計における人工知能技術の応用. FUJITSU, Vol.67, No.3, p.58-65 (2016).  
<http://www.fujitsu.com/jp/documents/about/resources/publications/magazine/backnumber/vol67-3/paper10.pdf>
- (6) Fujitsu Laboratories of Europe : Fujitsu Develops State-of-the-Art AI Solution to Revolutionize Non-Destructive Testing Manufacturing Inspection.  
<http://www.fujitsu.com/fts/about/resources/news/press-releases/2017/emeai-20171002-fujitsu-develops-state-of-the-art-ai.html>

## 著者紹介



**古屋 早知子** (ふるや さちこ)

欧州富士通研究所  
Business Support & Development Group  
富士通アドバンステクノロジー(株)より出向。欧州市場への製品展開とAIを用いた設計製造技術のビジネス化に従事。



**Ali Sanaee**

品質管理技術者として、風車ブレード製造におけるNDTおよびUT技術の開発プロジェクトを牽引。高効率かつ効果的な品質管理工程の実用化に従事。



**Serban Georgescu**

欧州富士通研究所  
Artificial Intelligence Research Division  
テクニカルリーダーとして、Imagificationの機能拡張やDeep Learning応用技術の研究開発に従事。



**Joseph Townsend**

欧州富士通研究所  
Artificial Intelligence Research Division  
Imagificationの機能拡張やDeep Learning応用技術の研究開発に従事。



**Peter Chow**

欧州富士通研究所  
Business Support & Development Group  
エンジニアリングクラウドの欧州展開ならびにAIを用いた設計製造技術のビジネス化に従事。



**Bjarne Rasmussen**

Fujitsu A/S  
Head of Digital Technology Services (DTS) CSM in Denmark  
デンマークおよびEMEA市場における顧客満足度、価値向上のための新規技術、自社ソリューションやアプリケーションサービスの拡販・ビジネス化に従事。



### David Snelling

Fujitsu Services Ltd.

CTO Office EMEA

EMEAのAIビジネス戦略（技術・市場展開）の立案や量子コンピュータなど新規技術のビジネス化に従事。



### 後藤 正智 (ごとう まさと)

(株) 富士通研究所

AI社会実装プロジェクト

プロジェクトを統括。