

Supported by  日本 THE NIPPON
財団 FOUNDATION

2020年度

品質管理の高度化のためのシステム構築報告書
(品質管理の高度化に関するAI活用研究)

2021年3月

一般社団法人 日本船舶品質管理協会

品質管理の高度化に関するAI活用研究委員会 委員名簿（助成事業）

（敬称略）

担当	氏名	所属
委員長	荒木 勉	東京理科大学教授／上智大学名誉教授
委員	平方 勝	海上技術安全研究所
委員	島田 毅	一般財団法人 日本海事協会
委員	長谷川正則	株式会社IH原動機
委員	道本修司	ダイハツディーゼル株式会社
委員	辻 康之	株式会社三井E&Sマシナリー
委員	斉藤 央	三菱重工エンジン&ターボチャージャ株式会社
委員	山家正俊	ヤンマーパワーテクノロジー株式会社
関係官庁	佐藤将登	国土交通省 海事局 検査測度課
事務局	澤山健一 大谷雅実 中西孝志	一般社団法人 日本船舶品質管理協会

目 次

1. 事業目的	1
2. 事業目標	1
3. 研究委員会	1
4. 研究内容	2
5. まとめ	7
別添 1 2020 年度品質管理の高度化に関する AI 活用研究委員会名簿	9
別添 2 品質管理の高度化に関する AI 活用システムの開発研究報告書	11
別紙 3 AI 技術の活用による不適合未然防止 報告会スライド	59

1. 事業目的

2018年度～2019年度で実施してきた「品質管理の高度化に関する調査研究」(以下、「調査研究」という。)により、AIを使って、属性データや画像データから部品・部材の不適合予測や不適合検出を可能とするツールを確立することができた。本事業では、このツールの利用を希望する当協会の会員が直接当該技術にアクセスし、自社製品の適合予測や不適合検出を行えるシステムを構築し、船用工業界でのAI技術の活用と普及を促進することを目的とする。

2. 事業目標

本事業では、以下のツールをWeb上に乗せ、会員が自由にアクセスできるシステムを構築する。また、同システムについては、開発の主体となった内燃機メーカーだけではなく、船用産業の広い分野で使用できるシステムとする。

(1) 調達品の適合予測のためのツール

調達品に関する適合・不適合データとこれに対応した発注データとの関係をAIに学習させることにより開発されたツールであり、このツールを使用することにより、新たに発注する調達品の適合確率を予測できる。その他、集積したデータによる各分析にも応用できる。

(2) 画像による欠陥検出のためのツール

正常部品及び欠陥部品に関する多くの画像をAIに学習させることにより開発しつつあるツールであり、検査対象となる部品の画像をコンピュータに読み込ませることにより、自動的に欠陥を検出することが可能となる。

(3) 時系列データによる工作機械等の適合検出のためのツール

工作機械に流れる電流等の時系列データと工作精度との関係をAIに学習させることにより開発しつつあるツールであり、このツールにより工作機械の切削刃の磨耗度合い等の把握ができ、切削刃の交換時期に関する重要な情報を取得することが可能となる。

3. 研究委員会 (別添1参照)

(1) 本事業を進めるにあたり、品質管理の高度化に関するAI活用研究委員会を立ち上げた。同委員会の指導の下研究活動を進めた。内燃機関を製造する国内の主要な認定事業場5社と海上技術安全研究所及び一般財団法人日本海事協会より委員を派遣頂き、委員長は学識経験者をお願いし、また、オブザーバとして国土交通省海事局の出席を頂き活動を進めた。

(2) 委員会開催状況

- 2020年5月22日 2020年度第1回品質管理の高度化に関するAI活用研究委員会開催。書面審議の形で今年度活動内容を報告し承認された。
- 2020年11月4日 2020年度第2回同委員会をWeb会議として開催。助成事業進行報告書(案)について審議し承認された。
- 2021年3月23日 2020年度第3回同委員会をWeb会議として開催。2020年度年度事業報告書(案)について審議し承認された。

4. 研究内容(別添2参照)

研究の成果に基づき、会員が自由にアクセスできる「部品・部材の不適合予測・不適合検出システム」を海上技術安全研究所と共同でWeb上に構築した。システム名称を「品質管理Web AIシステム」としてクラウド上に配置し、会員企業がWeb経由で容易にアクセスできる仕組みとしている。

2項の事業目標に対応した具体的な実施内容は以下のとおりである。なお、海上技術安全研究所では、2019年度に続き2020年度は、上記2.(2),(3)項に関しWeb上で使用可能とする研究に取り組んだ。同研究内容を別添2に示す。

(1) 調達品の不適合予測のためのツール

調達品の不適合予測のためのツールを、Web上で会員が自由にアクセスでき、船用産業の広い分野で使用できるシステムとし、一般的な回帰問題や二項分類問題を解析できる「汎用機械学習アプリケーション」として完成させ、下記(2),(3)項のアプリケーションと統合し、「品質管理Web AIシステム」内で選択可能とした。

(2) 画像による欠陥検出のためのツール

同ツールでは、傷などの特徴を簡単に登録でき、AIはこれを学習し新しい画像に類似の特徴が無いかを判断する仕組みとした。同学習はクラウド上で行い、結果をメールで自動送信し、ユーザー側のソフトウェアで判定する使い易いシステムとし、「欠陥検出画像認識アプリケーション」として完成した。なお、判定用ソフトは、一般パソコン用と高機能グラフィック機能付パソコン用の2種類を開発し選択可能としている。

(3) 時系列データによる工作機械等の不適合検出のためのツール

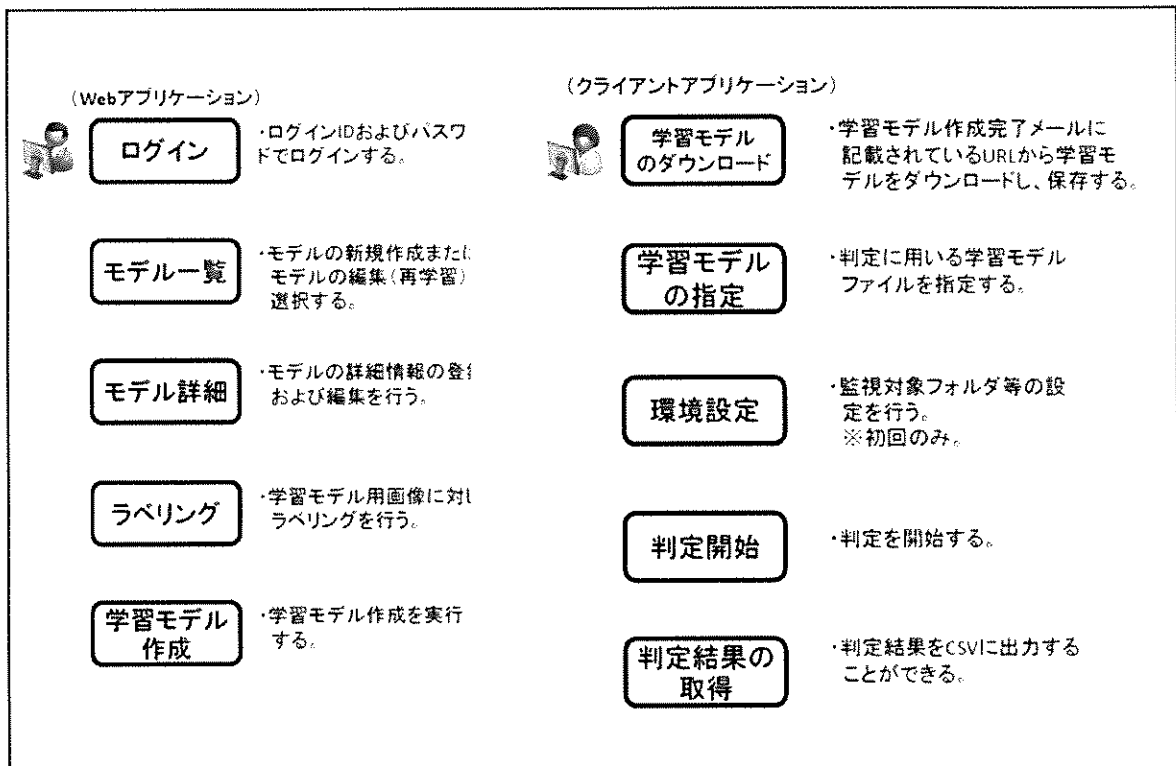
同ツールでは、電流値や振動値など時間で変化する時系列データの変化パターン等の特徴を、ユーザーの良否指定に基づき学習し、新しい時系列データの良否を容易に判定でき、かつ、不適合と判断された場合はアラームを発出する等、生産現場で使い易い「異常波形検出アプリケーション」として完成した。


(4) 品質管理 Web AI システム

上記(1)、(2)、(3)項に記した、汎用機械学習、欠陥検出画像認識、及び異常波形検出の3つのアプリケーションを統合し、「品質管理 Web AI システム」として完成し、2021年1月から運用を開始した。

下記に同システムの「欠陥検出画像認識アプリケーション」を例として流れを示す。

(ユーザー側の業務フロー)




品質管理WebAIシステム

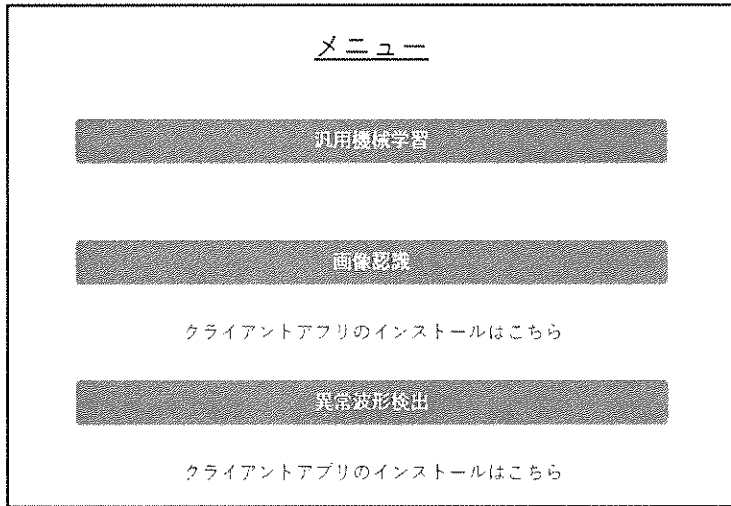
組織ID

ユーザID

パスワード

パスワードを忘れた方は[こちら](#)

ログイン画面 (例)



メニューで3つのアプリケーションを選択

学習モデル一覧（例）右上の「新規作成」ボタンでデータ入力へと進める。

画像認識

ユーザーID: nmriuser

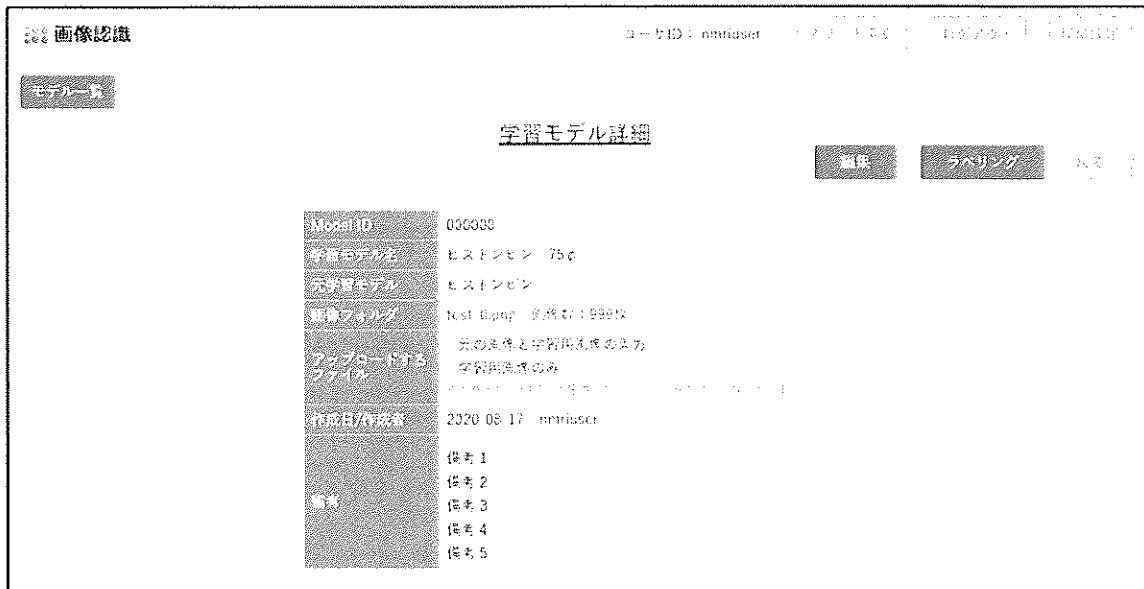
モデル一覧

新規作成


Model ID: モデル名: 検索

Model ID	モデル名	Ver	最終学習日時	状態
000001	インジェクションポンプ	1	2020/05/03 11:20	利用中
000002	インジェクションポンプ2	2	2020/05/04 11:20	利用中
000003	ピストンセン	1	2020/05/05 15:20	学習中
000004	ピストンセンサー50	1	2020/05/05 18:20	利用中
000005	ピストンセンサー80	1	2020/05/05 19:20	利用中
000006	シリンダーカマシ100	1	2020/05/06 10:30	利用中
000007	シリンダーカマシ1200	1	2020/05/06 11:30	利用中
000008	カムシャフト	1	2020/05/07 9:30	利用中

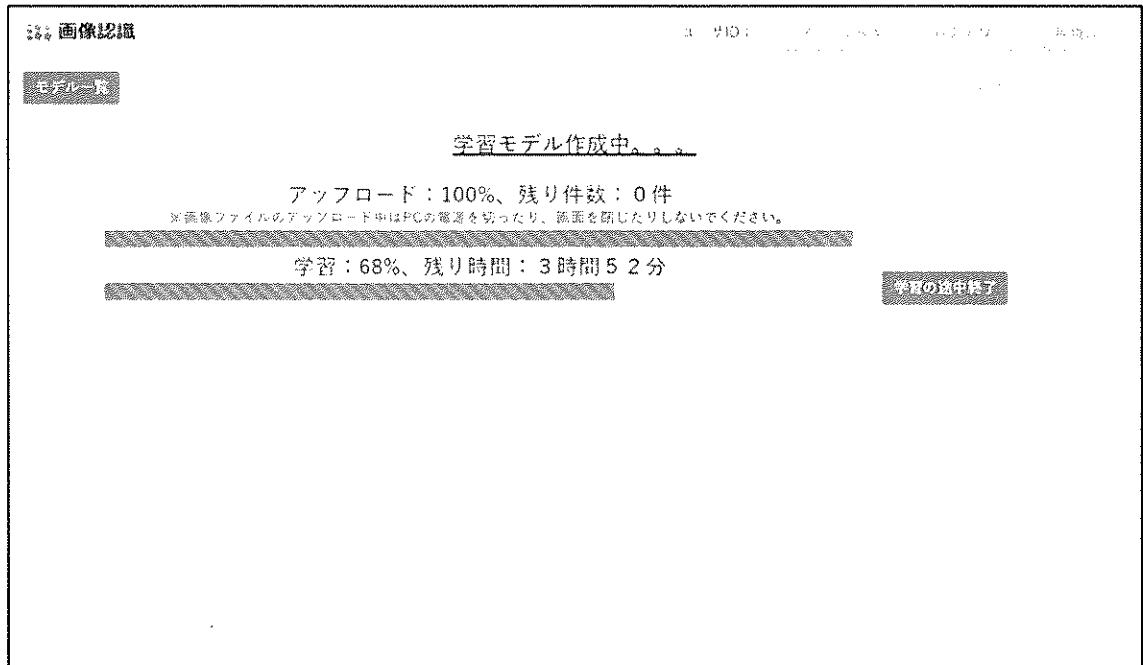
学習モデル名や学習用 画像フォルダを入力後「ラベリング」へと進む。



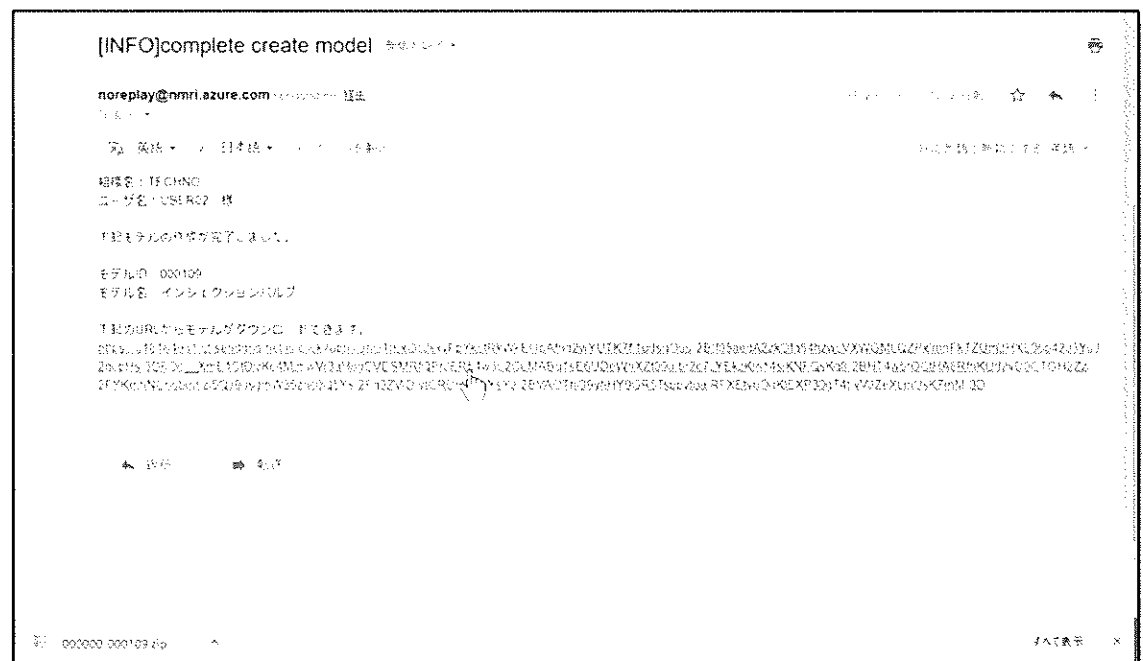
ラベリング画面 画像内の不適合箇所を赤枠で示し登録する。



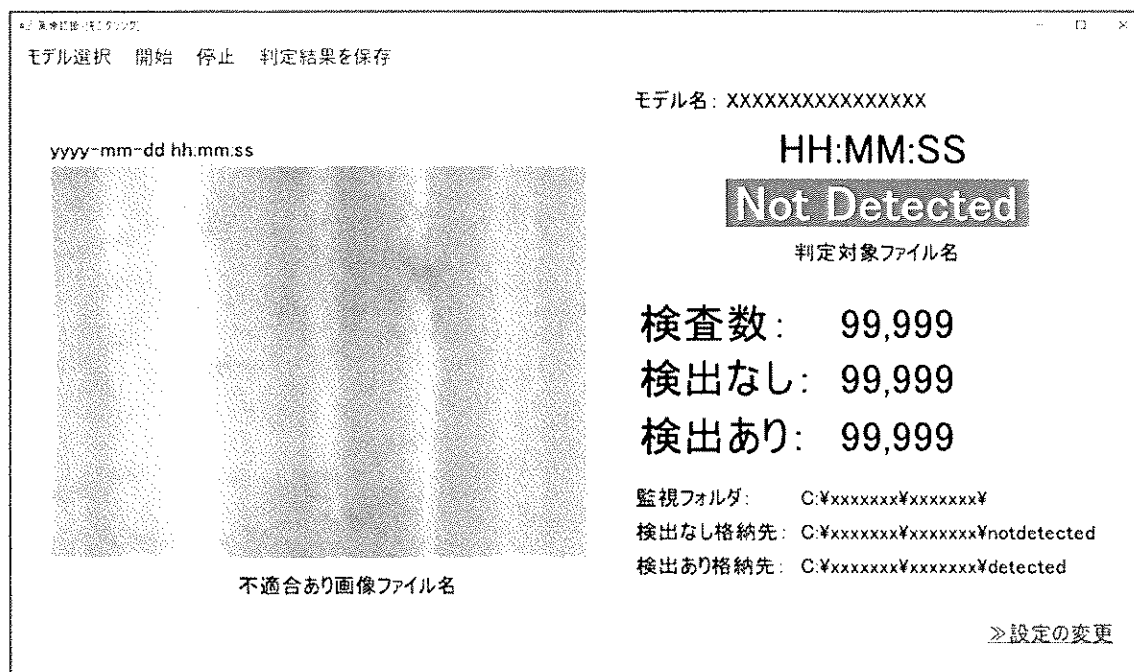
ラベリング後、画面指示に従い学習を開始する。棒グラフで学習進捗が表示される。



学習終了後、学習結果が登録アドレス宛にメールで自動送信される。



事前にインストールしたユーザー側の判定ソフトに学習結果を読み込み、新しい画像を判定する。



5. まとめ

(1) AI解析用 Web 化システム作成

「汎用機械学習」、「欠陥検出画像認識」、及び「異常波形検出」の3つのアプリケーションを作成し、「品質管理Web AIシステム」として統合した。会員企業に供するため、同システムを Web 経由で容易に使用可能とし、2021年1月から運用を開始した。

(2) 同システムの運用体制の確立

2021年1月からの本格運用のため、海上技術安全研究所と（一社）日本船舶品質管理協会が協力し、クラウドを使用した仕組みを設け、会員企業から容易に使用可能とした。

(3) 普及活動の実施（別添3参照）

会員企業には当協会機関誌「品管時報1月号」や2021年3月9日に開催した「品質管理の高度化に関する調査研究 成果報告会」等で紹介し、希望する会員企業にID、パスワードと使用要領及びサンプルデータを提供した。

6. 謝辞

最後になりましたが、本研究にあたり、日本財団をはじめ、国土交通省、海上技術安全研究所、並びにご協力頂きました多くの皆様に多大なご指導ご支援を賜りましたことを厚く御礼申し上げます。

以上

別添1

2020年度品質管理の高度化に関するAⅠ活用研究委員会 名簿

2021年3月15日

(一社)日本船舶品質管理協会

担当	氏名	所属	役職	備考
委員	荒木 勉	東京理科大学 上智大学	教授 名誉教授	
委員	平方 勝	海上技術安全研究所	産業システム系 情報システム研究グループ長	
委員	島田 毅	一般財団法人 日本海事協会	技術本部 機関部長	
委員	長谷川 正則	株式会社IHⅠ原動機	生産センター 品質管理部長	
委員	道本 修司	ダイハツディーゼル株式会社	生産購買統括本部 品質管理部 部長	
委員	辻 康之	株式会社三井E&Sマシナリー	R&Dセンター デジタル化推進 グループ グループ長	
委員	斉藤 央	三菱重工エンジン&ターボチャージャ株式会社	生産本部 品質保証部 次長	
委員	山家 正俊	ヤンマーパワーテクノロジー株式会社	特機事業部 品質管理部 検査第一グループ課長	
関係官庁	佐藤 将登	国土交通省 海事局 検査測度課	船舶検査官	
事務局	澤山 健一	一般社団法人 日本船舶品質管理協会	専務理事	
	大谷 雅実	同	常務理事	
	中西 孝志	同	上席技師	

NMRI

National Maritime Research Institute

日本船舶品質管理協会殿請負研究

品質管理高度化に関する AI 活用システムの開発研究 報告書

令和3年3月

国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所

目 次

1. まえがき	1
2. 品質管理における AI の活用	1
2.1 欠陥検出画像認識	1
2.1.1 畳み込みニューラルネットワーク	1
2.1.2 ネットワークの学習方法	3
2.1.3 欠陥検出に関する検討	4
2.1.4 欠陥検出システムの運用例の検討	11
2.2 AI による工作機械 IoT データによる不適合検出	12
2.2.1 全般	12
2.2.2 学習システム	13
2.2.3 判定システム	17
2.2.4 工作機械の時系列データから異常を検出するシステムの開発	17
2.2.5 工作機械の時系列データから異常を検出するシステムの運用の検討	18
3. システム設計・開発	21
3.1 全体システム	21
3.2 欠陥検出画像認識アプリケーション	25
3.3 異常波形検出アプリケーション	35
3.4 汎用機械学習	41
4. まとめ	43
参考文献	43

1. まえがき

本報告書は、国立研究開発法人 海上・港湾・航空技術研究所 海上技術安全研究所（海技研）が、一般社団法人日本船舶品質管理協会から、「品質管理の高度化に関する AI 活用システムの開発研究」として、受託して実施したものである。

本調査研究は、舶用品メーカーの要望を基に日本財団助成事業として、同協会が委員会を設置して進めている AI 活用研究（令和 2 年度）の一環である。本調査結果を踏まえ、日本財団助成事業では、クラウドサーバーを利用した Web アプリケーション及びそれに付随するシステムを構築する。このような全体計画の中で、本開発研究では、以下の研究を実施した。

令和元年度に実施した基礎的調査研究の結果を踏まえ、令和 2 年度は以下の検討を行う。

（1）AI による画像からの欠陥検出（欠陥検出画像認識）

AI による画像認識を活用した汎用的な欠陥検出 Web アプリケーションシステムの構築にむけて、欠陥検出画像認識のための学習及びシステムの仕様について検討を行う。

（2）AI による工作機械 IoT データによる不適合検出（異常波形検出）

工作機の IoT 出力などの時系列データの波形から不適合発生を検出する汎用的な Web アプリケーションシステムの構築にむけて、システムの仕様について検討を行う。

開発にあたっては、令和元年度の成果を踏まえて、海技研がシステムの基本仕様を検討し、株式会社テクノロジーソリューションが基本仕様を基に、詳細仕様の検討、システム開発を行った。

上記二つのアプリケーションに加え、令和元年度に実施した汎用機械学習の Web アプリケーションをこれらと同じ統合環境で処理できるように整備した。したがって、今年度製作した Web アプリケーションでは、以下の 3 つのアプリケーションが利用できるシステム環境を整備した。

- ① 汎用機械学習
- ② 欠陥検出画像認識
- ③ 異常波形検出

2. 品質管理における AI の活用

2.1 欠陥検出画像認識

2.1.1 畳み込みニューラルネットワーク

画像認識では、畳み込みニューラルネットワークが多く用いられる。畳み込みニューラルネットワークは、特定の形状を捉える畳み込み層とプーリング層を階層的に配置した構造になっている。図 2.1-1 に示すように、畳み込みニューラルネットワークはこれらの層と全結合層から構成されている。画像処理としては、畳み込み層はフィルタ処理に相当し、プーリング層は画像縮小に相当する。畳み込み層とプーリング層を重ねて層を深くし、最後は全結合層（パーセプトロン）で分類（識別）処理を行う。




図 2.1-1 畳み込みニューラルネットワーク

畳み込みニューラルネットワークの畳み込み層は、図 2.1-2 に示すように、入力に対して重みフィルタの内積を計算する。1 層目の畳み込み層では、入力サンプルに対して畳み込み処理を行い、特徴マップを求める。2 層目以降の畳み込み層では、前層の特徴マップを入力として同様に畳み込み処理を行う。畳み込み処理で得られた値は、そのまま特徴マップの値とはしない。畳み込み処理で得られた値を活性化関数に与えて、その出力を特徴マップの値とする。活性化関数には、シグモイド関数や ReLU などを使用される。

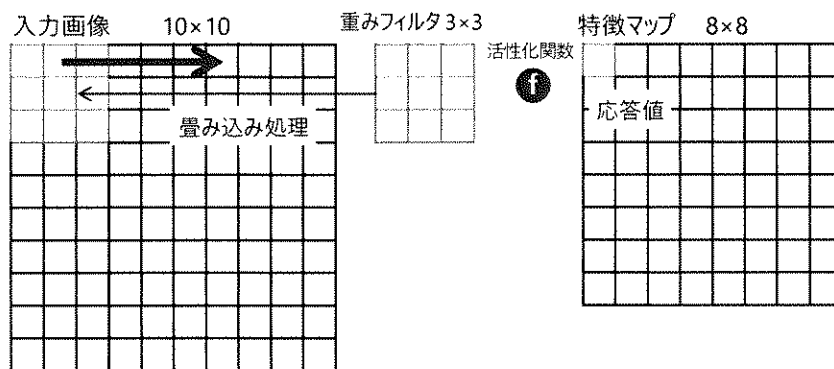


図 2.1-2 畳み込み層の処理

プーリング層は、畳み込み層から出力された特徴マップを縮小する処理である。その時、着目する領域を設定してその領域の特徴マップの値から新たな特徴マップの値を求める。これにより、幾何学変化などに対する不変性を獲得することができる。プーリング層の処理として最もよく使われるのは、最大値プーリングである。最大値プーリングは、注目領域の中の最大値を新たな特徴マップの値とする手法である。

全結合層は、多層パーセプトロンと同様にシナプスの重みを計算し、活性化関数によりユニットの値を求める。最初の全結合層の入力は、畳み込み層またはプーリング層の出力であり、2 次元の特徴マップを 1 次元に展開して与える。

識別層では、各クラスの尤度を求める。例えば、0 から 9 までの数字を認識する場合、出力層のユニット数は、10 個となる。各クラスに対応する尤度は、式(2.1-1)のように求める。

$$P(y^i) = \frac{\exp(h_i)}{\sum_{j=1}^M \exp(h_j)} \quad (2.1-1)$$

そして、尤度が最大となるクラスを分類クラスとして出力する。

2.1.2 ネットワークの学習方法

畳み込みニューラルネットワークを構成するパラメータは、畳み込み層の重みフィルタの値、全結合層のシナプス重みとバイアスである。これらは、誤差逆伝播法により学習を行う。図 2.1-3 に示すように、誤差逆伝播法による学習は、学習サンプルを順伝播させて認識を行う。次に出力と学習サンプルのラベルとを比較して誤差を求める。

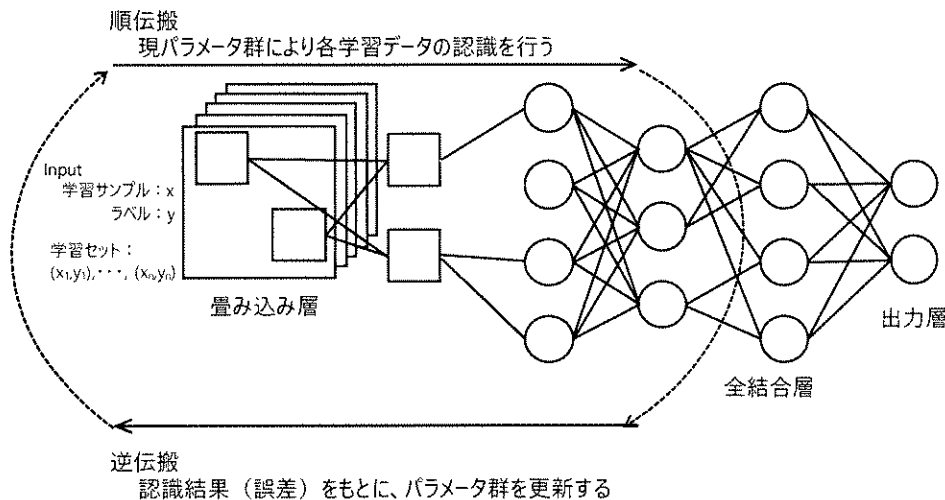


図 2.1-3 ネットワークの学習の流れ¹⁾

第三次人工知能ブームのブレイクスルーの一つに、2012年の画像認識が挙げられる。それは、2012年の一般物体認識のコンペティション ILSVRC (ImageNet Large Scale Visual Recognition Challenge)で、図 2.1-4 に示す AlexNet²⁾ が、他の機械学習のエラー率を大きく引き離したことによる。その後も、ILSVRC では新たなネットワーク構造が毎年提案されている。2014年に提案された VGG³⁾は、19層、GoogLeNet⁴⁾は、22層と畳み込み層を深くすることで分類性能の向上が図られた。




図 2.1-4 AlexNet のネットワーク構造²⁾

深層学習を利用した物体の識別技術の進歩の後に、深層学習を利用した物体検出技術が進歩した。物体検出では、R-CNN が利用されることが多い。R-CNN⁵⁾は Selective Search で検出した物体候補領域を AlexNet (または VGGNet) に入力して検出する手法である。Selective Search は、色の類似度に着目したセグメンテーション法であり、色の類似度の許容度を超えてグルーピングすることで様々な大きさの候補領域を抽出することができる。Selective Search で検出した物体候補領域を一定サイズにリサイズし、後段の CNN に入力する。物体候補領域の数だけ CNN で認識するため、計算コストが高いといわれる。

畳み込み処理の回数を大幅に削減することで計算コストを改善した Fast R-CNN⁶⁾が報告された。その後、Fast R-CNN をベースとし、Selective Search をやめ、Region Proposal Network で行うことで計算コストを削減した Faster R-CNN⁷⁾が報告された。現在では、Faster R-CNN が物体検出で広く使用される。本調査では、Faster R-CNN による検出を行った。

2.1.3 欠陥検出に関する検討

2.1.3.1 AI 画像認識モデル

本調査研究で使用した Faster R-CNN モデルを図 2.1-5 に示す。2.1.2 で述べたように、R-CNN を改良して計算速度を高めたところに特徴がある。また、精度よく検出できることから、広く利用されている。




図 2.1-5 Faster R-CNN モデル⁷⁾

2.1.3.2 データセット及び計算環境

欠陥を学習・認識させるために、欠陥が撮影された 133 枚の画像を用意した。学習時に学習を行う訓練画像、学習を行わない検証画像と、学習後の結果を用いて検証を行うテスト画像に分けた。

欠陥が撮影された画像の数が少なかったため、ここでは水増し作業（オリジナルの画像に加工を施す）を行って、訓練画像、検証画像の数を増やした。テスト画像の数も増やした。

水増し作業は、撮影された画像データに対し、周囲の明るさやピントのずれ等で環境条件を変化させた画像を模擬的に作成する作業になる。今次水増し作業では、①画像のコントラストを調整、②ガンマ補正、③平滑化をそれぞれ 3 水準で組み合わせを変えて、模擬的な画像を作成した。水増し後の画像枚数は、 $3^3=27$ 倍になった。この各水準で補正パラメータ及び 27 水準の組み合わせを表 2.1-1 に示す。コントラスト調整は、1 以上で画像の明度差を強くする。すなわち明るいところはより明るく、暗いところはより暗くなる。1 未満で明度差が弱くなる。表 2.1-2 は、全組み合わせ条件を示す。水増し作業の概要を図 2.1-6 に示す。

表 2.1-1 水増し作業対象パラメータの水準値

	水準値		
	-1	0	1
コントラスト調整	0.7 (弱くする)	1.0 (元画像のまま)	1.5 (強くする)
ガンマ補正	0.7 (暗くする)	1.0 (元画像のまま)	1.5 (明るくする)
平滑化	1 (元画像のまま)	3.0 (若干ぼかす)	5.0 (ぼかす)

表 2.1-2 全組み合わせ条件

ID	コントラスト調整	ガンマ補正	平滑化
#01	-1	-1	-1
#02	-1	-1	0
#03	-1	-1	1
#04	-1	0	-1
#05	-1	0	0
#06	-1	0	1
#07	-1	1	-1
#08	-1	1	0
#09	-1	1	1
#10	0	-1	-1
#11	0	-1	0
#12	0	-1	1
#13	0	0	-1
#14	0	0	0
#15	0	0	1
#16	0	1	-1
#17	0	1	0
#18	0	1	1
#19	1	-1	-1
#20	1	-1	0
#21	1	-1	1
#22	1	0	-1
#23	1	0	0
#24	1	0	1
#25	1	1	-1
#26	1	1	0
#27	1	1	1




図 2.1-6 水増し作業概要

水増し前のオリジナルの訓練画像を一例として図 2.1-7 に示す。訓練画像は、欠陥箇所をクローズアップして撮影した画像が多い。

水増し作業の結果、訓練画像は 4,779 枚、検証画像は 1,593 枚、テスト画像は 270 枚となった。なお、水増し加工を行っていないテスト画像は 10 枚である。

今回使用した画像の画素数は、約 2,000 万画素であったものの、学習・認識にあたっては、約 20 万画素に圧縮した後に行った。そのため、使用するカメラの解像度に関しては、20 万画素以上であれば、解像度によらず、同程度の精度となると思われる。一方、今回使用したカメラの解像度を活かすのであれば、例えば 2,000 万画素の原画像を 10×10 の 100 枚の 20 万画素の画像を分割し、分割後の各画像に対して、学習・認識を行う方法が考えられる。この方法は、画像の圧縮処理によるデータの損失がない一方、認識を行う画像が 100 倍に増えるため、

認識（計算）時間は100倍程度を必要とする。計算コストを問題にする場合、例えば、5×5の25枚の80万画素の画像を20万画素に圧縮することを検討するなど、データの損失を少なくしながら、計算コストの削減を行うことも可能である。

計算で使ったモデル、計算環境条件を表2.1-3に示す。OSは、LinuxのUBUNTUである。画像認識に要した時間は、1枚あたり0.07秒から0.1秒であった。

表 2.1-3 計算で使ったモデル等条件

機械学習理論モデル	Faster-RCNN
機械学習フレームワーク	CAFFE
CNN 構造	VGG16
学習アプローチ	END-TO-END
OS	UBUNTU
GPU	GTX2080Ti

2.1.3.3 欠陥検出結果

水増し加工していないテスト画像(10枚: Test01~Test10)について、元画像と認識結果の画像を図2.1-8(1)~図2.1-8(3)に示す。接近して撮影した画像に対しては、認識率は概ね1.0に近く、かつ誤認識もなく、確実に認識できていることが分かった。

クローズアップして撮影した欠陥の画像をもとに学習した結果を利用して、距離を置いて撮影した画像に対する認識の程度を確認した。認識結果を図2.1-9に示す。図2.1-9の#01から#02、#03の順番にシリンダに近づいて撮影している。#01のような距離からで、欠陥を十分認識できている。








図 2.1-7 オリジナルの訓練画像 (一例)



Test
01
認識率
0.999



Test
02
認識率
1.000



Test
03
認識率
0.998



Test
04
認識率
0.999









図 2.1-8(1) テスト画像の欠陥認識結果 (1)

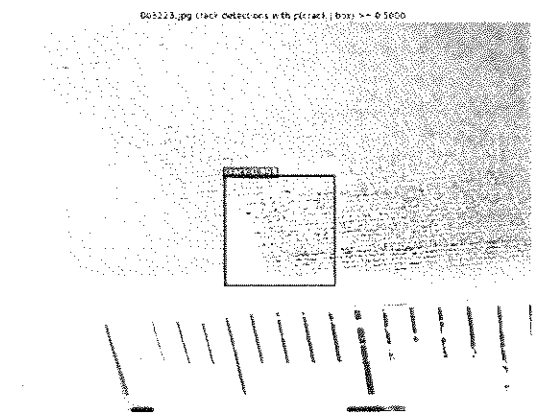

Test
05
認識率
0.998



Test
06
認識率
1.000



Test
07
認識率
0.999



Test
08
認識率
0.994






図 2.1-8(2) テスト画像の欠陥認識結果 (2)

Test
09
認識率
1.000



Test
10
認識率
0.999




図 2.1-8(3) テスト画像の欠陥認識結果 (3)




図 2.1-9 テスト画像の欠陥認識結果

2.1.4 欠陥検出システムの運用例の検討

欠陥検出画像認識システムの構成案として図 2.1-10、図 2.1-11 のように、二つの案を考える。いずれのケースも欠陥検出画像認識のための学習はサーバー上で行うことを想定する。

図 2.1-10 に示す、計測現場で使用するパソコンには、高性能の仕様を求めない点が利点である。図 2.1-10 のケースでは、サーバー上に AI 認識システムがあるため、欠陥の認識はサーバー上で行うことになる。そのため、撮影したコンテンツを、インターネットを介してサーバーに通信して、認識計算を行った後、認識結果を受信する必要がある。したがって、通信速度の制約を受けるため、Real Time での認識が困難である。また、現場でインターネット環境が必要である。

図 2.1-11 に示す通り、計測現場で欠陥検出画像認識を行うため、計測現場で使用するパソコンは、一定のスペックが必要である。計測現場では、動画・写真を圧縮して AI 認識システムに入力し、認識結果を計測現場で GUI

に表示する。そのため、インターネットが無くてもローカルで認識でき、結果を Real Time で見ることもできるのは利点である。

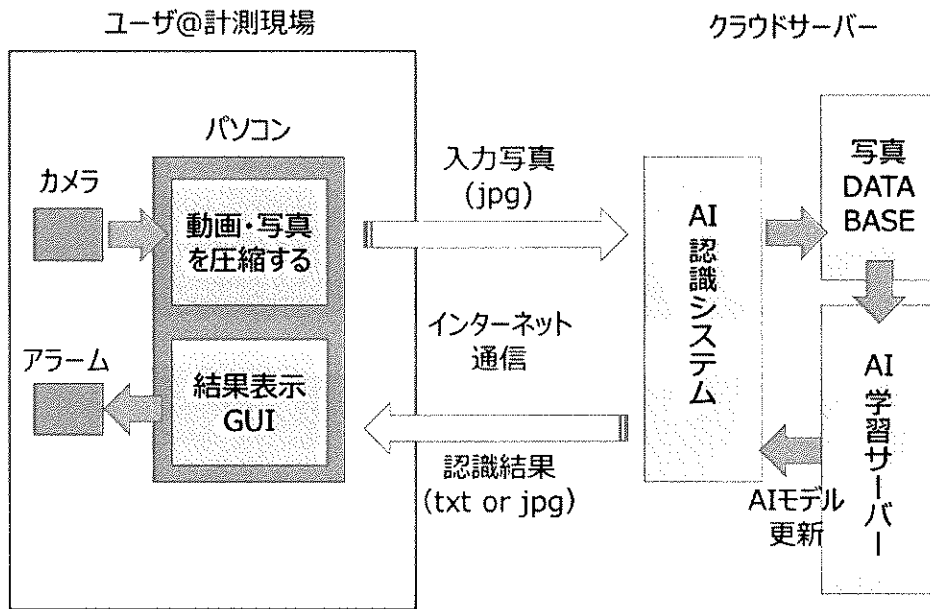


図 2.1-10 欠陥検出画像認識システム構成案（その1）

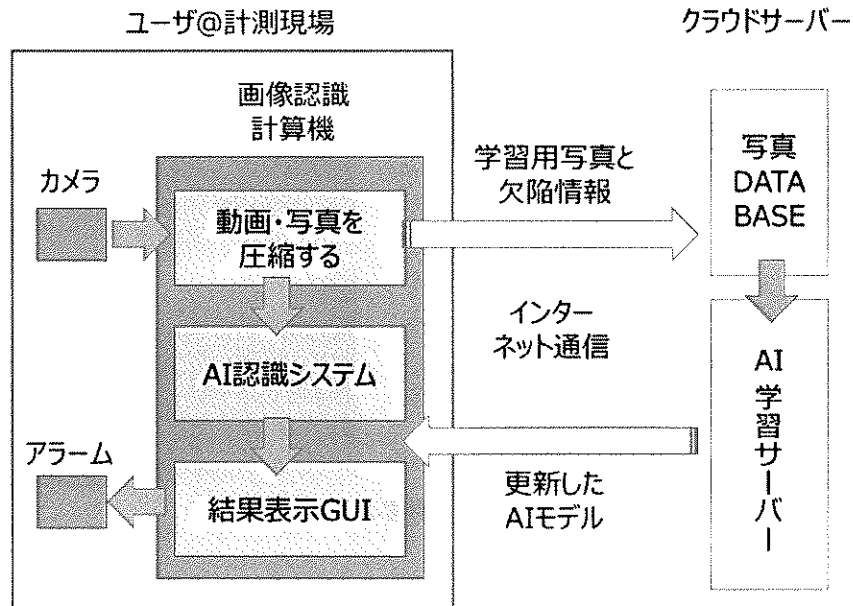


図 2.1-11 欠陥検出画像認識システム構成案（その2）

2.2 AI による工作機械 IoT データによる不適合検出

2.2.1 全般

工業製品の切削加工に使用されるドリルは、その劣化を踏まえて定期的に交換する必要がある。この判断は現場での目視で行われることが多いものの、ドリルに負荷されるトルク量などがモニターされている場合、その波形の変化から交換するタイミングを判断出来る可能性がある。

そこで過去の波形データから正常な波形と異常な波形を区別するための学習，及びその学習データに基づき波形の正常/異常を判断するシステムを構築したため，ここではそのアルゴリズムとアプリケーションの外観及び実際の運用例を示す。


2.2.2 学習システム

2.2.2.1 学習システム概要

ニューラルネットワークやサポートベクターマシン，ランダムフォレストなどの機械学習は汎用的であり，判断基準の定義が困難なものでも予測モデルを構築出来るといった長所の反面，高精度な学習に多くのデータが必要なこと，異常波形のデータも要することなどの課題がある．本調査研究では異常波形の判断は（突発的なピークが出現するなど），ある程度の合理的な定義が行えることや，異常波形を含め学習データが十分に集まらないケースでも運用可能とすることをより重視し，比較的古典的な機械学習を用いて正常/異常の判断を行うシステムの構築を試みた。


2.2.2.2 正常波の学習

図 2.2-1 に実際の工作用ドリルの出力波形に基づき本研究にて想定した波形形状を示す．学習に用いる正常波形は複数あり，個々の波形がある程度の固有のブレを有している．加えて切削対象の設置位置の誤差などから時間軸方向のずれの発生も想定する。



(a) 全体

図 2.2-1 (1) 想定する波形形状 (全体)



(b) $2480 < \text{Time} < 2520$

図 2.2-1(2) 想定する波形形状 (部分)

これら正常データに基づき、正常波形を代表する基準波形を構築する。基準波形は下記の手続きにより構築する。

Step 1: 正常波形の平均値により構成された波形を構築する。


Step 2: Step 1 で構築した波形との全時間域における誤差の累積値が最小となる正常波形を選択する。

Step 3: Step 2 で選択された正常波形との誤差が最小となるよう、他の正常波形を時間軸方向にオフセットする。


Step 4: オフセット後の正常波形の平均値により構成された波形を構築する。

Step 5: Step 4 で構築した波形との誤差が最小となる正常波形のデータを時間ごとに求め、その点を繋げたものを基準波形とする。


ここで誤差とは、同じ時間における出力の差の絶対値を示す。上記手続きを示したものを図 2.2-2 に示す。




(a) Step 1




(b) Step 2



(c) Step 3



(d) Step 4



(e) Step 5

図 2.2-2 基準波形の構築手続き

2.2.2.3 クライテリオンの設定

本調査研究では異常波形の検出において、検査する波形と前節で構築した基準波形間の統計量を使用する。また、より多角的な観点から判定するため、複数の統計量に基づき正常/異常を判定する。この統計量のクライテリオンの設定に関してここで述べる。

統計量には対象の波形と基準波形との①差の絶対値の最大/最小値、②差の平均値及び③差の標準偏差を用いる。また、統計量を求める際、**図 2.2-3**に示すとおり、波形を複数の区間に分割し、その区間ごとに統計量を求める。クライテリオンを求める手続きは次のとおりである。

- (1) 正常波形を一つ選び、基準波形との全時間域における誤差の累積値が最小となるよう、時間軸方向に正常波形をオフセットする。
- (2) オフセット後の波形に対して基準波形との統計量を区間ごとに求める。
- (3) (1)及び(2)を全ての正常波形に対して行う。
- (4) 統計量の最大/最小値をその区間における正常波形と判定するための上限/下限のクライテリオンとする。
- (5) もしあれば、異常波形に対して(1)-(3)の処理を行う。
- (6) (4)にて求めた正常波形の上限/下限の範囲から外れている場合、その中でクライテリオンと最も近い値を異常波形と判定するためのクライテリオンとする。ある統計量において異常波形が全て正常波形の上限/下限の範囲内にある場合、その範囲から微量外れた値を異常波形と判定するためのクライテリオンとする。

上記手続きを図に示したものを**図 2.2-4**に示す。




図 2.2-3 波形の分割




図 2.2-4 クライテリオンの決定方法

2.2.3 判定システム

2.2.2 にて構築した基準波形及びクライテリオンに基づき検査対象の波形の正常/異常を検出する。本研究では異常の判定を次の手続きにより行った。

- (1) 検査対象の波形と基準波形との全時間域における誤差の累積値が最小となるよう、検査対象の波形を時間軸方向にオフセットする。
- (2) 2.2.2.3 で定義した分割区間ごとに統計量を求める。
- (3) 統計量が正常範囲にある場合は異常度を 0、異常範囲にある場合は異常度を 1、正常範囲と異常範囲の間にある場合は線型補間した値(0~1)を異常度とする。
- (4) 全統計量、全区間ごとに異常度を求め、その最大値が既定値（ユーザーが決定する 0~1 の値）に達した場合、異常と判定する。

2.2.4 工作機械の時系列データから異常を検出するシステムの開発

2.2.2.2 及び 2.2.2.3 を自動で実行するアプリケーションを開発した。ここではそのアプリケーションの説明を行う。

2.2.2.2 を自動で行うアプリケーションとして OWL (Output Wave Learning app.) を開発した。アプリケーションの出力画面を図 2.2-5 に示す。正常波形及び異常波形を記載したテキストファイルを読み込んだ後、異常検出モデル構築ボタンを押すことにより、基準波形、分割区間の行番号及び分割区間ごとのクライテリオンをまとめたファイルを出力する。

2.2.3 を自動で行うアプリケーションとして CROW (Check and Read app. for Output Wave) を開発した。アプリケーションの出力画面を図 2.2-6 に示す。検査対象のファイルを定期的に取り、OWL にて構築した異常検出モデルに基づき異常の有無を判定する。異常と判定された場合、アラーム音を鳴らし、異常を周知させる。アラームを鳴らす異常度は図 2.2-6 左側の「閾値」トラックバーより設定する。閾値 0 は最も厳しい閾値であり、少しでもデータが正常の範囲を超えていれば「異常」と判定する。一方、閾値 1 は最も緩い閾値であり、データが異常の範囲に入っていたときに初めて「異常」と判定する。

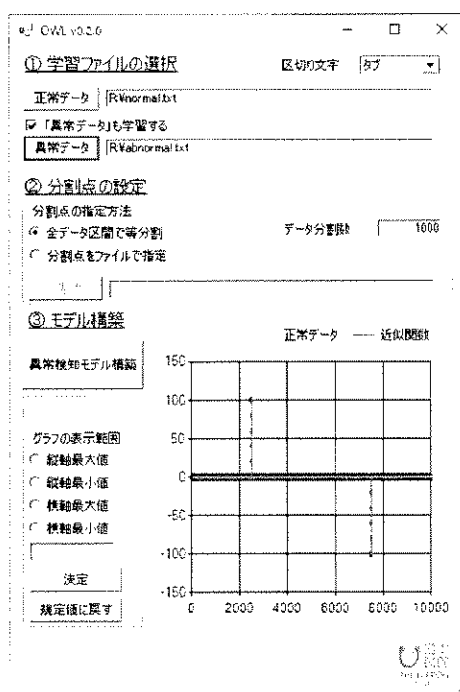


図 2.2-5 OWL の出力画面




図 2.2-6 CROW の出力画面

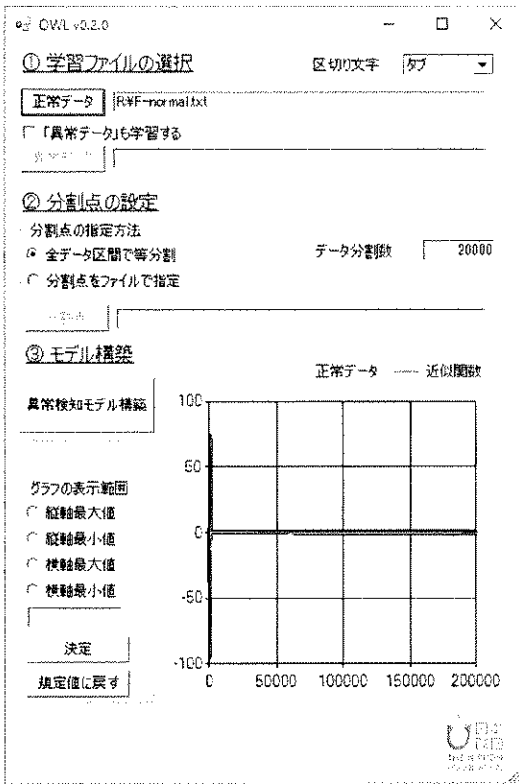
2.2.5 工作機械の時系列データから異常を検出するシステムの運用の検討

実際の現場で使用・計測された工作用ドリルの出力波形を用い、2.2.3 のアプリケーションを使用して学習及び異常波形の判定を行ったため、これに関してここに示す。


工作機のデータは 1msec ごとに記録された 200 秒間の出力データ (20 万行) であり、ドリルの使用回数 171 回目までのデータが得られている。本調査研究ではその内 155 回目と 166-171 回目を除いたドリルの出力を正常波形として学習し、169-171 回目を異常波形として学習した。

OWL の学習にて構築した基準波形 (図中では近似関数) を図 2.2-7 に示す。波形の出力は 0~1500msec 間に集中しており、黒点の正常波形を踏襲した基準波形の構築を確認した。

この学習結果を用い、150、155、167 及び 171 回目のドリルの出力波形を CROW にて検査し、異常の有無を判定した。結果を図 2.2-8 に示す。図 2.2-8 の横軸は時間、縦軸は異常度である。正常波形として学習に使用した 150 回目、及び学習には用いていないものの正常波形の範囲内にあると思われる 155 回目では異常度が 0 であり、正常と判定された。一方、正常と異常のデータの間である 167 回目、及び異常波形として学習に使用した 171 回目では出力が変動する時間帯で異常度が 1 となり、異常と判定された。おおよそ想定通りの動作であり、CROW が適切に波形の正常/異常を判定したと考える。




(a) 全体




(b) $0 < T < 1500$ msec


図 2.2-7 OWL の学習結果




(a) 150 回目



(b) 155 回目



(c) 167 回目



(d) 171 回目

図 2. 2-8 CROW での検査結果

3. システム設計・開発

3.1 全体システム

本システムは、「品質管理の高度化に関する AI 活用システムの開発研究」のなかで実施した①汎用機械学習、②欠陥検出画像認識、③異常波形検出のアプリケーションを統合したシステムである。それぞれのユーザーが必要なアプリケーションにアクセスして利用できることを目的とする。②欠陥検出画像認識アプリケーションは、2.1 で述べた技術と運用例をベースにし、③異常波形検出アプリケーションは、2.2 で述べた技術と運用例をベースにしてシステム設計を行った。ユーザーに提供する画面の順で、システム概要を以下に示す。

最近では、「資産、保守体制を社内に持つ必要がない」、「常に最新のアプリケーションを利用することができる」、「アプリケーションを短期間あるいは少量利用することができる」、「パソコンへのインストール等ユーザーによる環境構築が不要」等の理由で、クラウドサービスを利用するケースが増えている。海技研は、海事産業におけるオープンイノベーションを加速させるために、現在、海技研クラウドを整備しているところである。

一般社団法人日本船舶品質管理協会と協議して、本システムを海技研クラウドに展開することとした。したがって、サーバーは海技研クラウド上にあり、システムは、パソコンのウェブブラウザ上で動作する Web アプリケーションとし、インターネットと接続して利用できるようにシステムを構築した。

本システムは、①汎用機械学習、②欠陥検出画像認識、③異常波形検出のアプリケーションとそれら全体を管理する④マスタ管理機能からなるシステムとした。システム全体像を図 3.1-1 に示す。

マスタ管理は、ユーザーのユーザーアカウントの登録、編集する処理を行う。

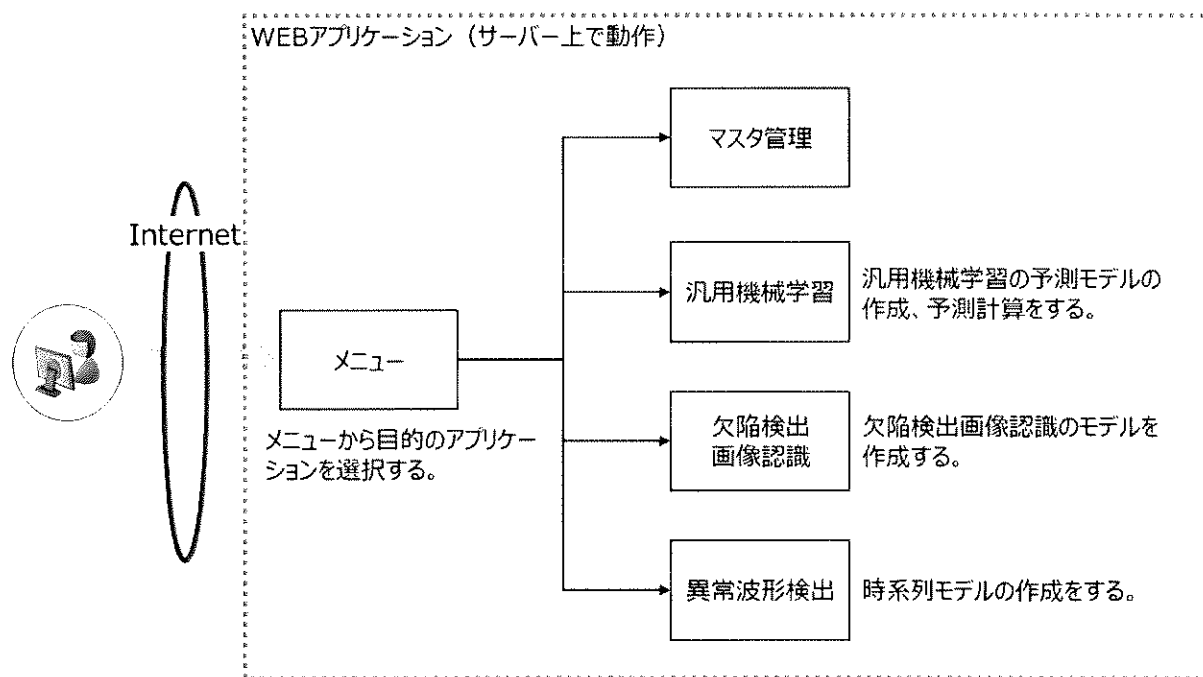


図 3.1-1 システム全体像

ユーザーは、本 Web アプリケーションを利用するにあたって、割り当てられた ID とパスワードからログインし、アプリケーションを利用する。ログインからログアウトまでの利用の一般的な流れは、図 3.1-2 に示すような業務フローとなる。マスタ管理は、組織管理者またはシステム管理者がユーザー登録等の処理を行う。システムによる自動処理とユーザーによる手動処理の流れは、図 3.1-2 に示す通りである。

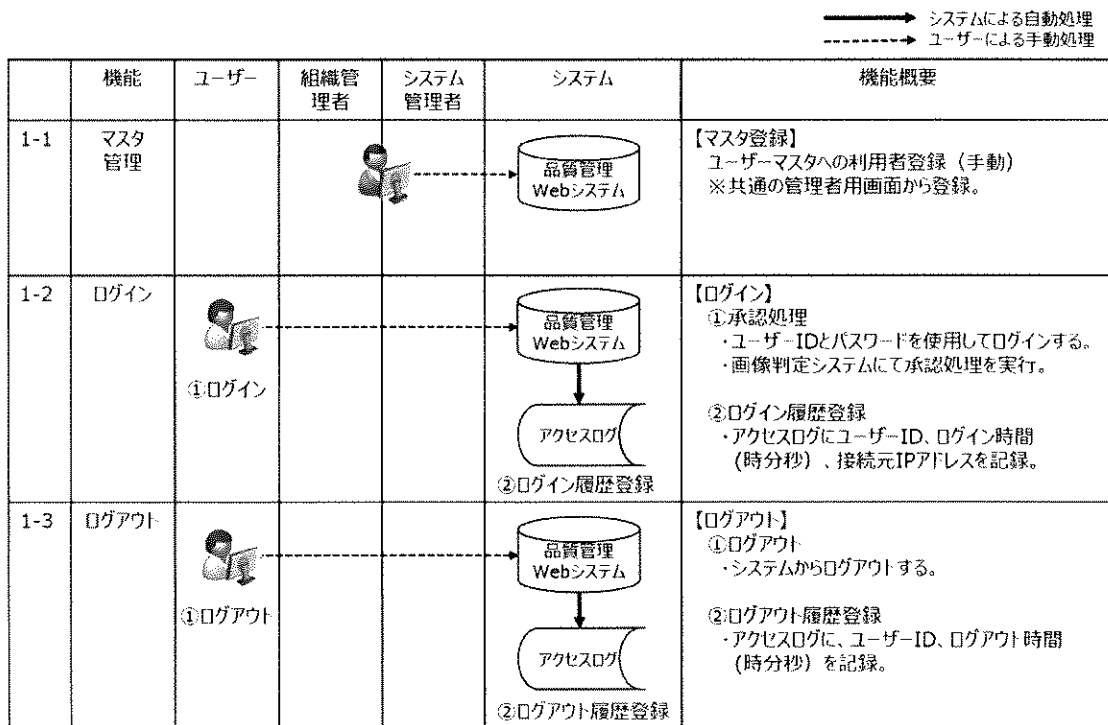


図 3.1-2 システム共通部分の業務フロー（ログインからログアウトまで）

図 3.1-3 は、ユーザーがメニュー画面から入って、アプリケーションを利用するところまでの流れを、システムによる自動処理とユーザーによる手動処理に分けて整理したものである。アプリケーションの利用時には、操作に応じて、結果を出力する自動処理と結果の通知を（計算終了後のお知らせメール等）自動で行うようにした。

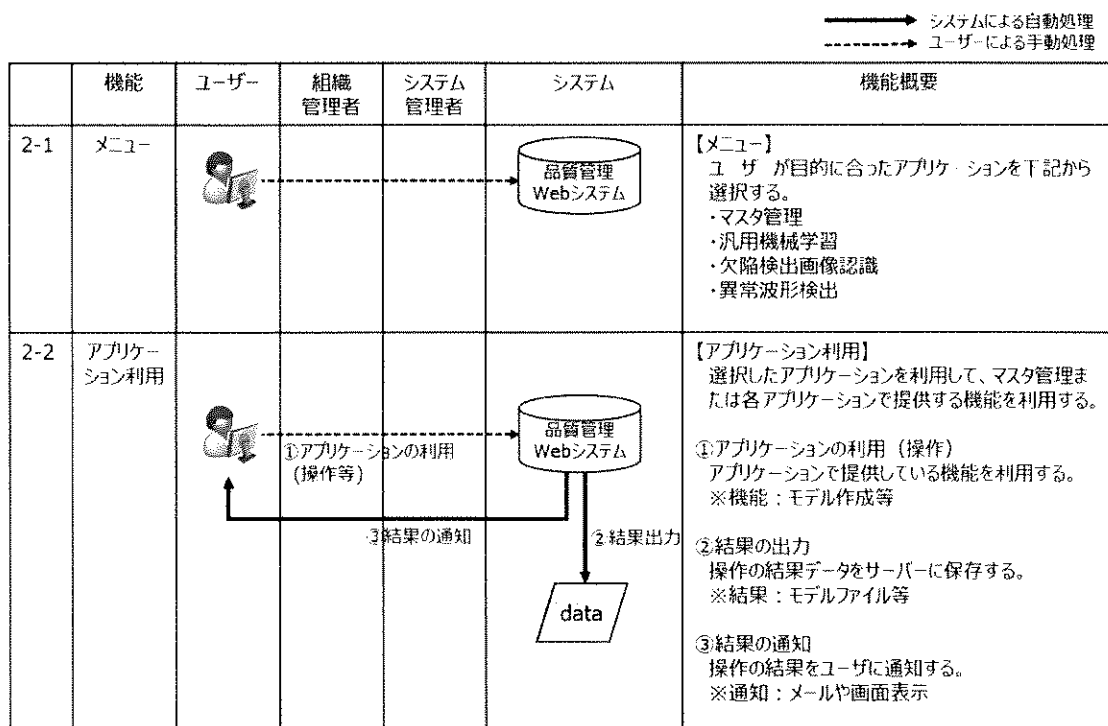


図 3.1-3 システム共通部分の業務フロー（メニューからアプリケーションの利用まで）

図 3.1-4 は、全体システムの論理構成を示す。ユーザーはクライアント PC からインターネットを経由してブラウザとサーバー間の通信を暗号化する SSL 通信でサーバーにアクセスする。本システムは、海技研クラウド（Microsoft Azure サービス）と海技研にあるオンプレミスサーバー（以下、AI サーバーと呼ぶ）にそれぞれアプリケーションを搭載し、それぞれのアプリケーションは、適宜データベースサーバー（MySQL を利用）とのデータの入出力を行うシステムとする。3つのアプリケーション全て、海技研クラウドサーバーにアクセスするものの、AI による画像認識のための学習には、GPU を搭載する等ハイスペックが要求されるため、AI の学習は AI サーバーで行い、結果は海技研クラウドサーバーを通じてユーザーに出力する形態とした。

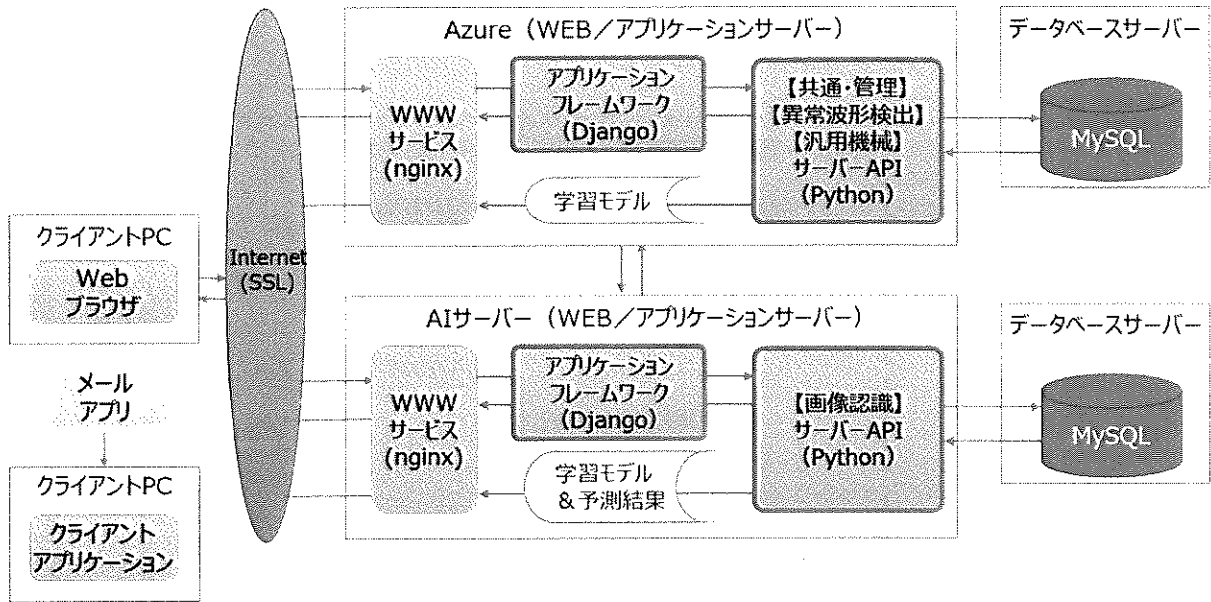


図 3.1-4 全体システム

本システムは Web アプリケーションであるため、ブラウザを利用する。表 3.1-1 は、対象ブラウザの仕様である。開発にあたっては、Google Chrome で動作することを前提にし、動作確認を行った。ユーザーのパソコンは Windows10 を想定した。

表 3.1-1 対象ブラウザの仕様

対象ブラウザ	Google Chrome
稼働 OS	Windows10
ハードウェア	SXGA (1280x1024 ピクセル) 以上の解像度のモニター

欠陥検出画像認識アプリケーションと異常波形検出アプリケーションは、機能の一部をクライアントアプリケーションによる操作とした。表 3.1-2 は、クライアントアプリケーションの仕様を示す。ユーザーのパソコンは Windows10 であるとし、システムの空きメモリが 2GB 以上あること、HDD 容量が 100MB を想定した。

表 3.1-2 クライアントアプリケーションの仕様

稼働 OS	Windows10
必要リソース	システムの空きメモリ：2GB 以上（標準搭載 8GB 以上推奨）
	HDD 容量（アプリケーション用）：100MB
フレームワーク	.NET Framework 4.7

本システムは、パソコンの Web ブラウザ上で動作するソフトウェア（Web アプリケーション）とパソコン上で動作するクライアント/サーバー方式のソフトウェア（クライアントアプリケーション）の2方式を採用した。Web アプリケーションは、サーバーとインターネット経由で接続するため、ネットワークに接続されている必要がある。一方、クライアントアプリケーションは、インターネットに接続することなく、オフラインで動作可能なアプリケーションである。欠陥検出画像認識アプリケーションと異常波形検出アプリケーションはクライアントアプリケーションも利用することとした。

Web アプリケーションは、ユーザーによる操作によって画面が切り替わる。ユーザーの利便性を考慮して、画面の設計、画面内の基本動作、画面遷移等の基本仕様を検討した。図 3.1-5 は、全体システムでトップページのログイン画面からメニュー画面へアクセスするログインとログアウト、さらにパスワード変更操作の画面にあたるアプリケーションを超えた共通部分を記述している。

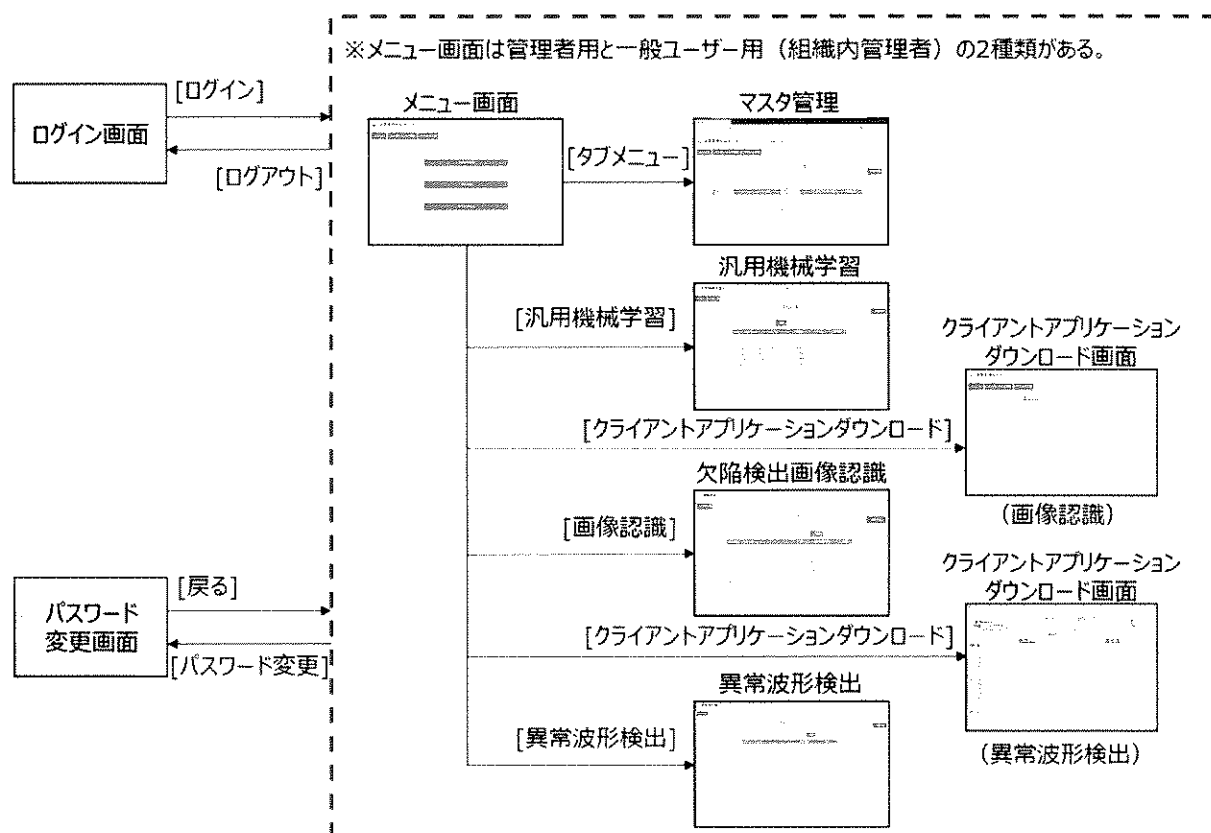


図 3.1-5 画面遷移（共通部分）

図 3.1-6 に示すログイン後のメニュー画面から、それぞれのアプリケーションにアクセスできるようになっている。欠陥検出画像認識アプリケーションと異常波形検出アプリケーションでは、クライアントアプリケーションが必要である。これらクライアントアプリケーションは、メニュー画面からそれぞれのアプリケーションにアクセスした後、ダウンロードできるようにした。組織管理者のマスタ管理は、組織内のユーザーアカウントの登録、編集を行う画面とする。

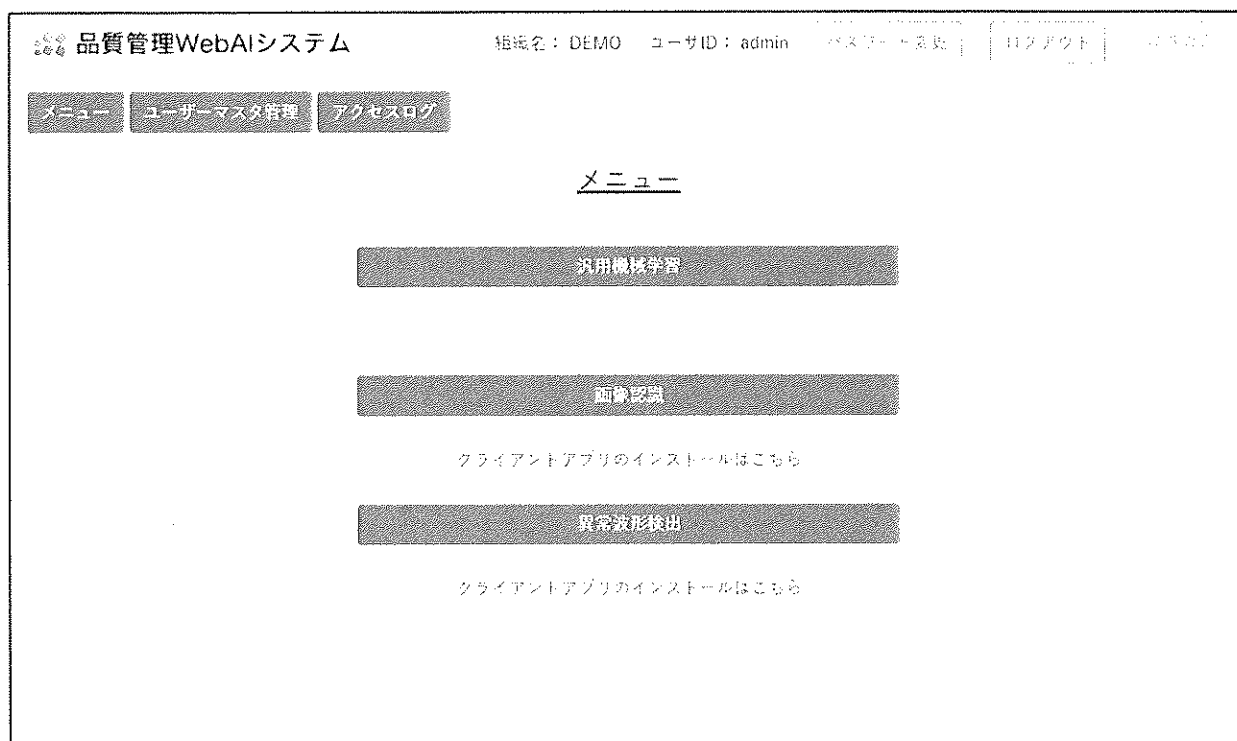


図 3.1-6 トップページ画面

本報告書は、今年度の調査研究対象である②欠陥検出画像認識アプリケーションと③異常波形検出アプリケーションを中心に、以下説明する。

3.2 欠陥検出画像認識アプリケーション

AI を用いて画像データから学習モデルを作成し、作成された学習モデルを用いて欠陥箇所の検出を行う。学習モデルを作成するために、学習用データとして素材となる画像と不適合範囲を示したラベリングデータを作成し、サーバーにアップロードするラベリングを行う。アプリケーションと、サーバーで作成された学習モデルを用いて画像内の欠陥箇所を検出するクライアントアプリケーションからなる。

図 3.2-1 に示したように、ユーザーによるラベリング作業のために、ラベリングアプリケーションを用意した。画像内の不適合箇所を指定（ラベリング）し、指定情報と画像をサーバーにアップロードする機能を有する。ウェブアプリケーションとして作成し、WWW ブラウザ上で動作するものとする。

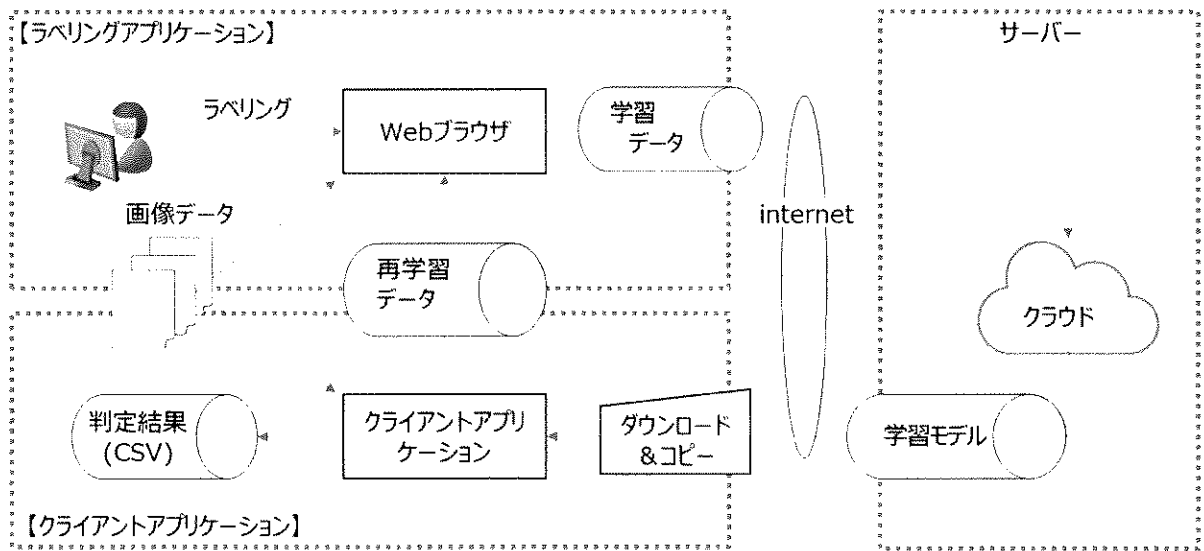


図 3.2-1 欠陥検出画像認識アプリケーション全体像

一方、ネットワークが使用できない現場での運用を想定しているため、スタンドアロンなアプリケーションとして作成するクライアントアプリケーションも用意した。判定結果はCSVに出力可能だが、サーバーには保存されない。

ラベリングアプリケーションからアップロードされた画像データ・ラベリング情報をもとにAIを用いて学習モデルは、サーバー上に作成される。

学習モデルは再学習が可能で、その場合はラベリングアプリケーションから再学習用の画像データとラベリングデータを追加アップロードする。

図 3.2-2 は、ユーザー登録等の管理、ユーザーのログインとログアウトの処理に関する業務フローであり、システムによる自動処理、管理者やユーザーの手動処理の流れを説明している。

図 3.2-3 は、ユーザーによるモデル作成処理、ラベリング処理、学習モデル作成処理の流れを説明している。学習モデル作成にあたっては、ブラウザ上で処理する場面と学習モデルをダウンロードして、オフラインで作業する流れを説明している。

図 3.2-4 は、学習処理は行わず欠陥検出のモニタリングを行う場面の流れを説明している。判定処理の開始、作業結果の保存はユーザーの手動処理で行うことになる。

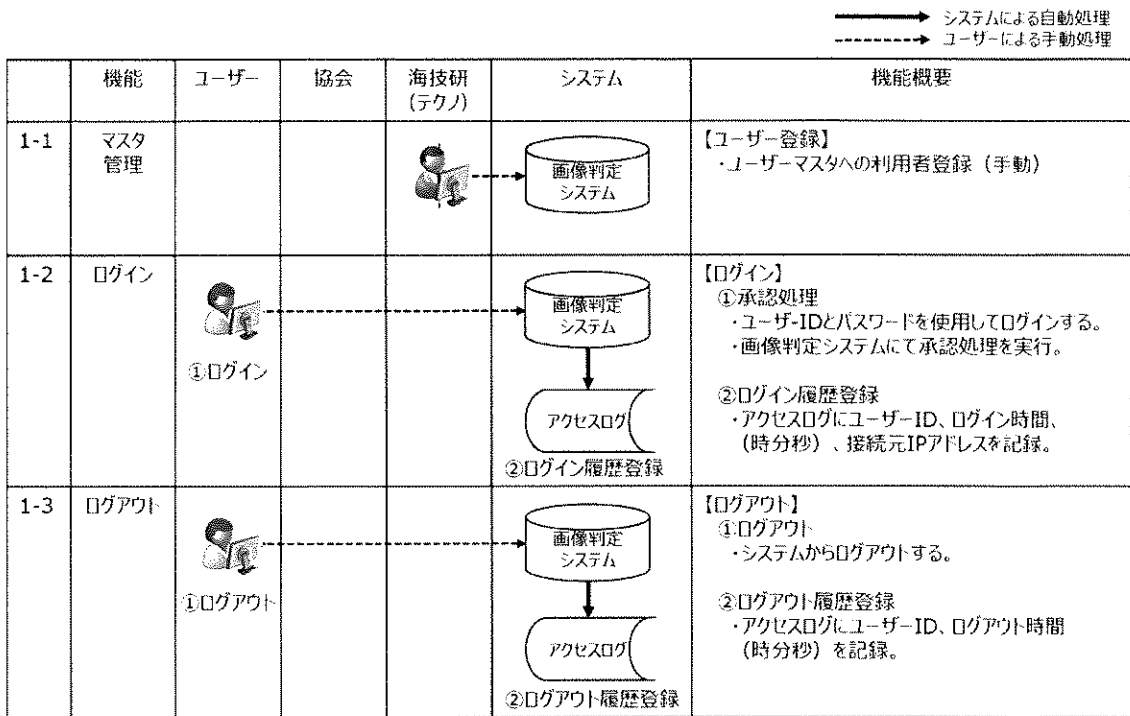


図 3.2-2 欠陥検出画像認識アプリケーションの業務フロー（ログインからログアウトまで）

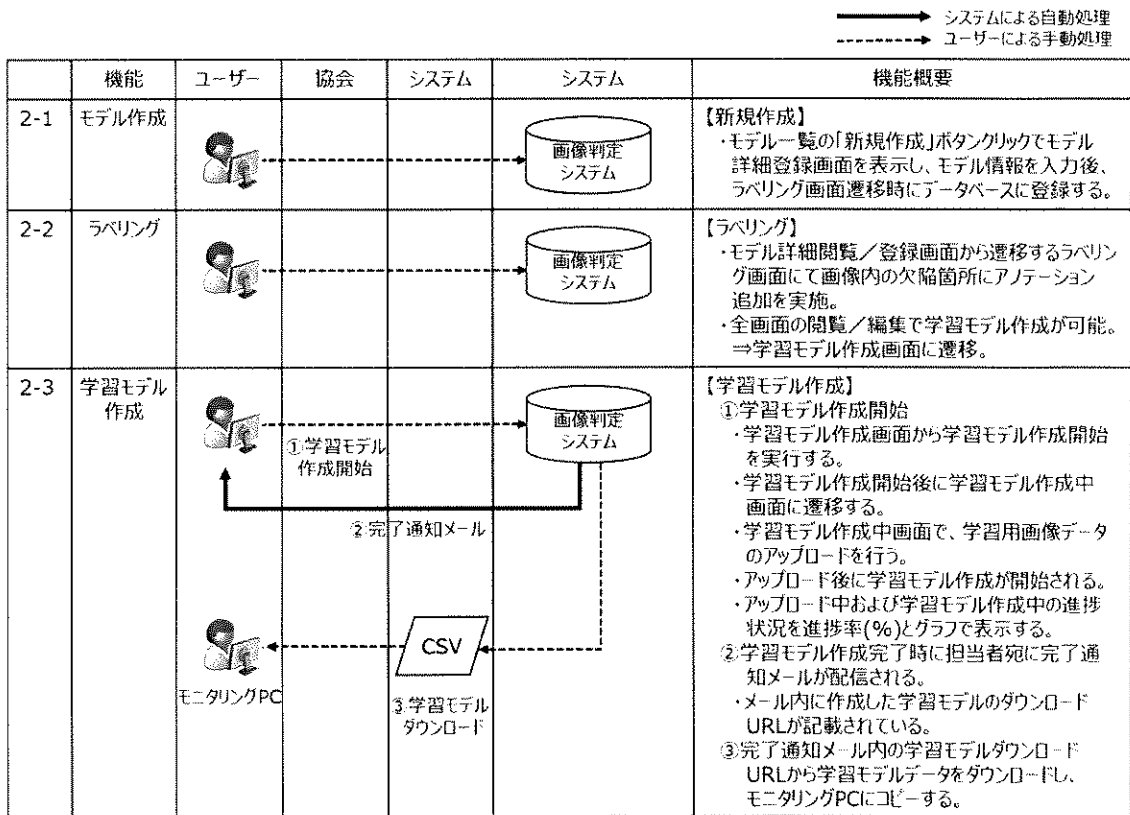


図 3.2-3 欠陥検出画像認識アプリケーションの業務フロー（モデル作成、ラベリング、学習モデル作成）




図 3. 2-4 欠陥検出画像認識アプリケーションの業務フロー（モニタリング）

欠陥検出画像認識アプリケーションは、Web アプリケーションとクライアントアプリケーションの2タイプの形態をとった。Web アプリケーションでは、AI 学習のための画像データに対して検出対象範囲を指定する作業（ラベリングと呼ぶ）を行う場面を想定する。一方、画像認識したい画像ファイルを自動で認識させる作業は、クライアントアプリケーションを利用する。本クライアントアプリケーションは、図 3.1-6 のトップページ画面でクライアントアプリケーションをサーバーからダウンロードしておくものとする。クライアントアプリケーションをパソコンにインストールした後は、オフラインで利用可能である。

Web アプリケーションの操作の流れを図 3.2-5 に示す。Web アプリケーションからアップロードされた画像から AI 学習のための学習モデルを作成する。学習が終了すると、作成された学習モデルのダウンロード先 URL を作成したユーザーにメールで通知することとした。画像を対象とした AI 学習は、GPU 等のハイスペックが要求されるため、今回は海技研のオンプレミスサーバー（AI サーバー）で学習させることにした。AI 学習が終了した後は、海技研クラウドサーバーを経由して、ユーザーに学習が完了した旨のメールが通知されることとなる。

画像データは、判定対象となる検査対象を撮影した BMP 形式/JPG 形式/PNG 形式のいずれかのフォーマットで作成された画像ファイルをさす。判定後の画像データは、学習用画像データとして再利用することができ、それらを基に学習モデルの再作成（再学習）を行うことができる。

ここでは、AI 学習は、新規学習と再学習という用語を用いる。新規学習は、用意した学習画像データを基に、新しく学習モデルを作成することである。再学習は、①新規の画像のみを追加して再学習する（既定）と②新規の画像及び既存の学習済みの画像を使用して再学習する2ケースを想定する。①がデフォルトになっている。



図 3. 2-5 欠陥検出画像認識 Web アプリケーションの流れ

システム側の流れを図 3.2-6 に示す。ユーザーは、Web アプリケーションを使用して画像データをクラウド上の所定のフォルダにアップロードするとともに、学習モデルをサーバー上に作成する。AI 学習はオンプレミスの AI サーバーで行い、AI 学習が完了したらメールでユーザーに通知される。

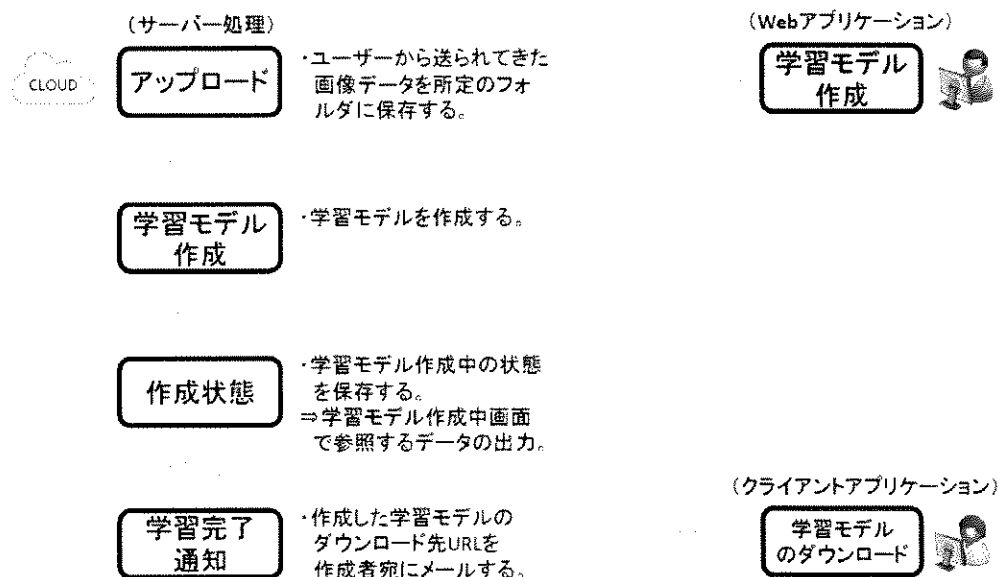


図 3.2-6 システム側の流れ

図 3.2-7 は、欠陥検出画像認識アプリケーションに入った後の画面遷移を示す。四角内には、画面内の機能とその記号を示す。各画面の仕様は、後述する。図 3.2-7 に示すように、欠陥検出画像認識アプリケーションを利用するにあたって必要となる環境設定画面で入力した後、学習モデルの登録、閲覧、画像学習のためのラベリング、AI による学習等にあたる画面の仕様を設定した。

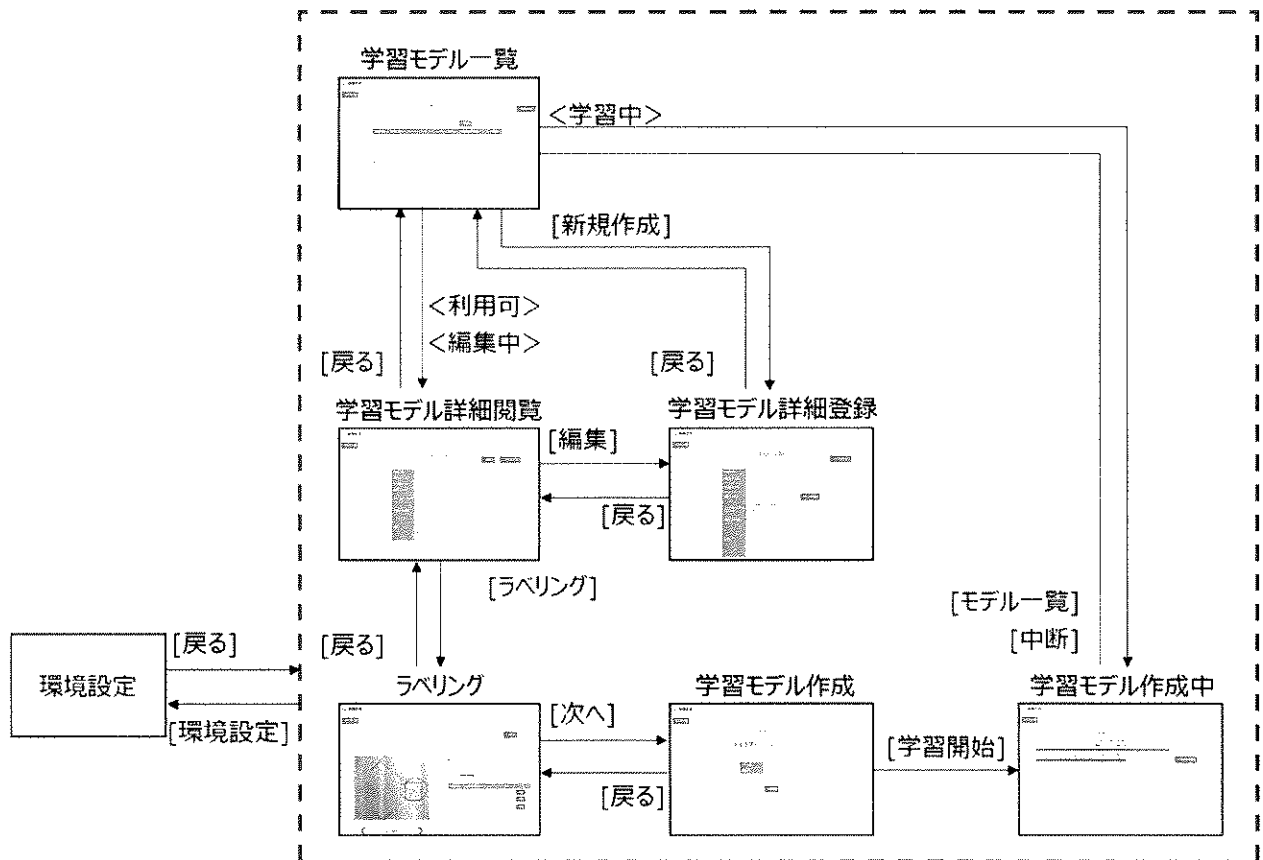


図 3.2-7 欠陥検出画像認識アプリケーション内の画面遷移

一方、クライアントアプリケーションの流れを図 3.1-8 に示す。クライアントアプリケーションでは、画面遷移はない。ユーザーは、学習モデルをダウンロードして、クライアントアプリケーション上で作業を行う。ここでは、検査対象の画像を読み込んで、欠陥があるか否かをこのクライアントアプリケーションを利用して検出することになる。図 3.1-9 は、クライアントアプリケーションをダウンロードする際に表示される画面である。

(クライアントアプリケーション)

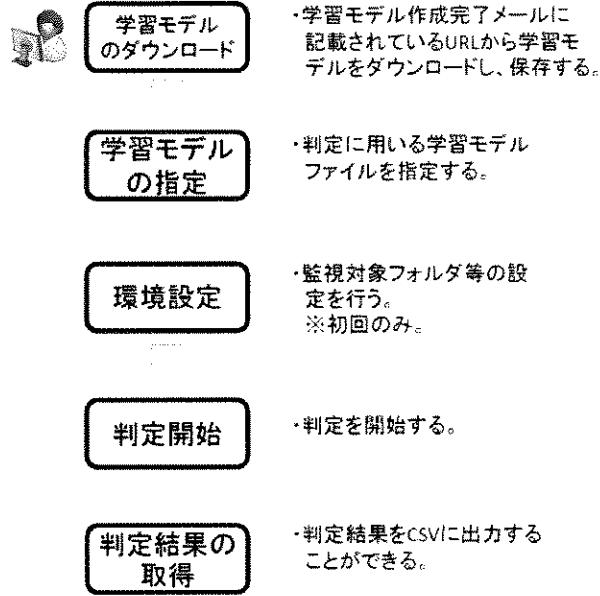


図 3.2-8 クライアントアプリケーションの流れ



図 3.2-9 欠陥検出画像認識クライアントアプリケーションダウンロード閲覧画面

学習を行う手続きとして、学習モデルを全く新規に作成する「新規学習」と、既存の学習モデルに対して追加で学習を行う「再学習」がある。「再学習」では、元となる学習データを指定し、新たに追加された学習データで学習モデルを作成する。この時、元の学習モデル作成時に使用した学習データを含めて再学習することもできる。

図 3.2-10 は、モデル一覧を表示する画面である。画面モデルの新規作成画面を呼び出すことができる。また、モデル名をクリックすることで、モデル名の編集を行うことができる。新規作成ボタンを押すと、図 3.2-11 に示すモデル詳細画面に遷移し、モデル詳細情報を入力することができる。

登録されたモデルを検索するために、検索ボタンを用意している。



図 3.2-10 欠陥検出画像認識アプリケーションのモデル一覧表示画面

図 3.2-11 は、学習モデルを作成するために用意された画面である。この画面からラベリング作業の画面に遷移するためのボタンが用意されている。ラベリングボタンを押すと、図 3.2-12 に遷移する。

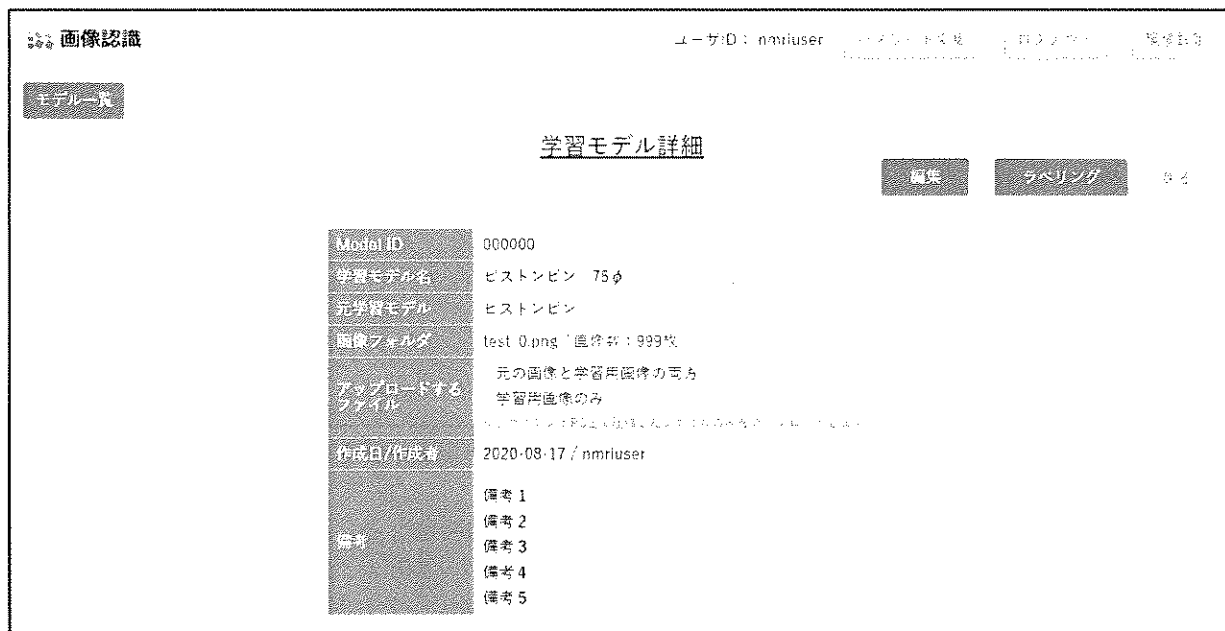


図 3.2-11 欠陥検出画像認識アプリケーションの学習モデル詳細画面

図 3.2-12 は、ラベリング作業を行う画面である。画面内画像で欠陥箇所を指定（ラベリング）し、サーバーにアップロードしてデータを作成する。図 3.2-12 に示すように、赤四角枠で指定する。赤四角枠は、画面画像内で移動可能であり、サイズ変更も可能である。赤四角枠で指定すると同時に、Crack 等ラベル名を Label Name の列に登録する。登録する際に、Label Name を入力した右側の「追加」ボタンを押す。すでに登録した Label Name で削除したいときは、「削除」ボタンを押す。次へのボタンを押すと、ラベリングしたい次の画像に移る。

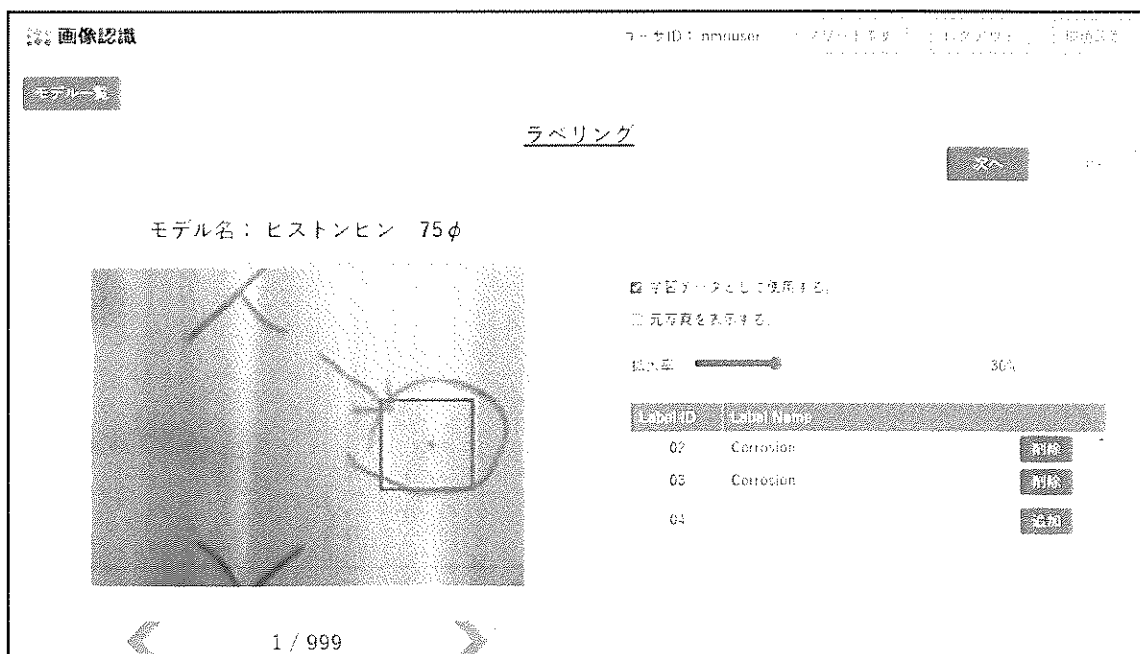


図 3.2-12 欠陥検出画像認識アプリケーションのラベリング画面

ラベリング作業が終了した後、図 3.2-13 の画面に遷移する。保存したラベリング情報と画像のアップロード、学習モデル作成が開始する。

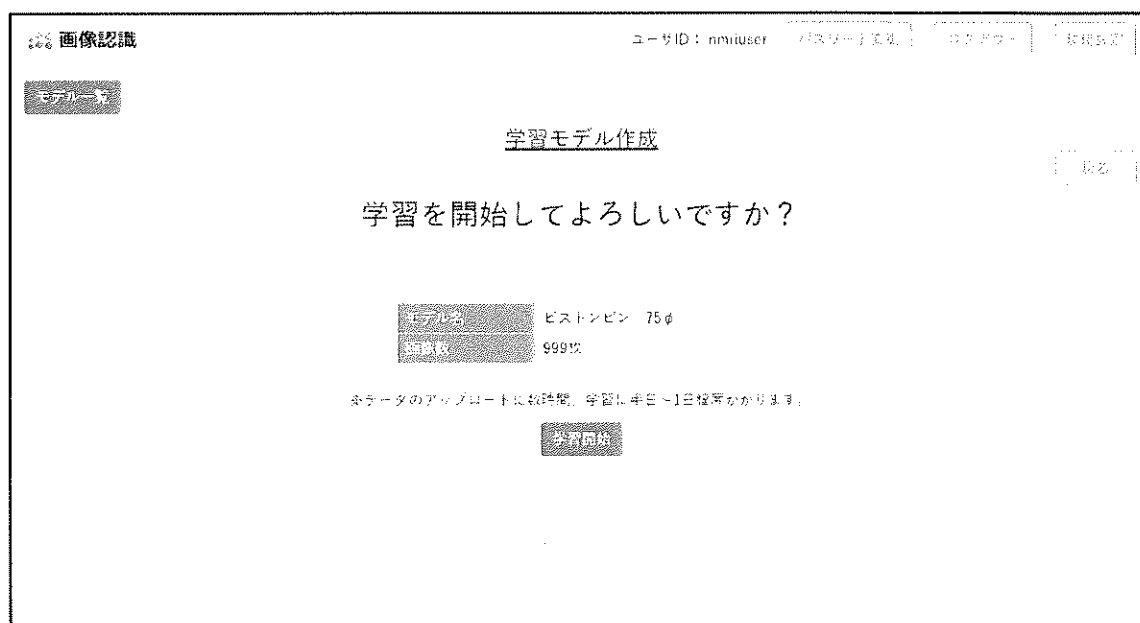


図 3.2-13 欠陥検出画像認識アプリケーションの学習モデル作成画面

図 3.2-14 は、AI 学習中の画面である。AI サーバーで計算する。学習には時間を要するため、進行状況（進捗率とアップロードの残り件数）を表示できるようにした。AI 学習を途中で終了するためのボタンも用意した。中断／再開ボタンも用意した。




図 3.2-14 欠陥検出画像認識アプリケーションの学習中表示画面

画像を対象とした AI の学習には学習する枚数に応じて、時間を要する場合がある。そのため、AI の学習が完了すると、図 3.2-15 に示すように学習完了通知メールがユーザーあてに届く機能を用意した。

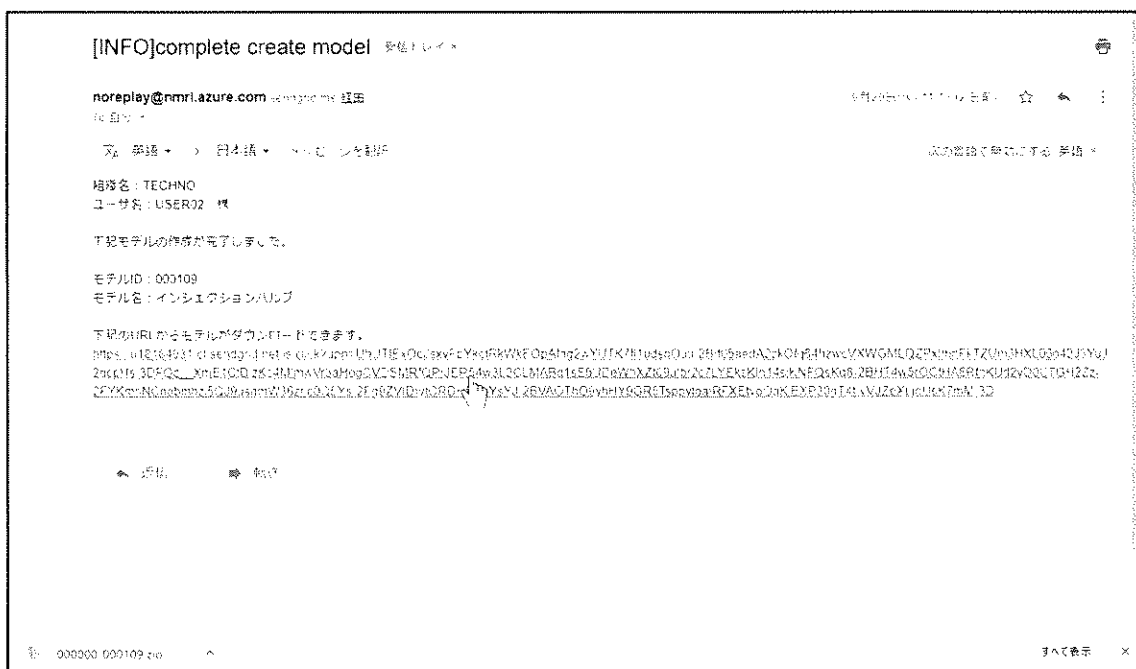


図 3.2-15 学習完了通知メール

AI 学習結果を用いて、欠陥検出画像認識を行うためのモニタリング画面を図 3.2-16 に示す。指定したフォルダ内に追加された画像を自動で取得し、設定された学習モデルを用いて判定を行う。判定結果は画面に表示され、直近の不適合（欠陥）箇所ありと判定された画像を画面に表示する。次の画像に不適合（欠陥）箇所がなくても変更しない。判定結果は CSV に出力することができる。使用する学習モデル、判定する画像の入ったフォルダ名はユーザーが自由に変更できるものとする。不適合（欠陥）箇所が見つかった場合は、画面に“Detected”と表示され、画像に赤枠が表示される。不適合（欠陥）箇所ありと判定された直近の画像を表示する。不適合画像のファイル名も表示される。“Not Detected”の場合は、画像は表示されない。検査した画像の件数が表示され、不適合（欠陥）箇所ありと判定された画像の件数、不適合（欠陥）箇所なしと判定された画像の件数も表示される。

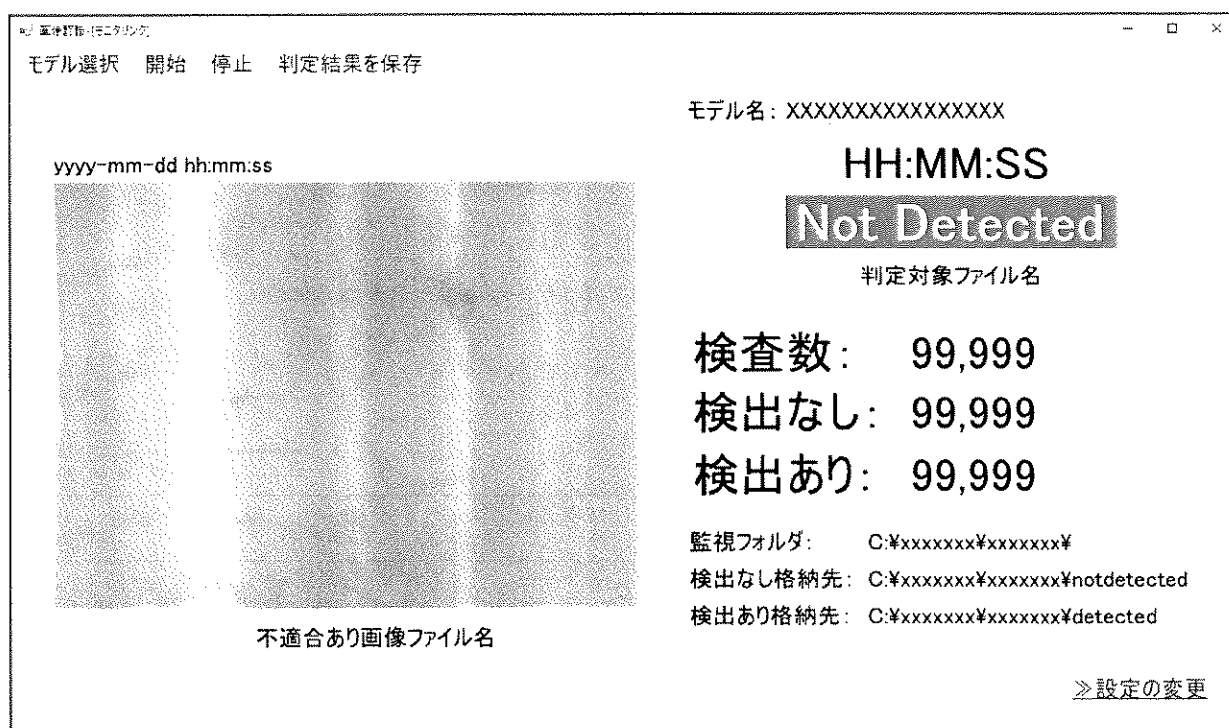


図 3.2-16 欠陥検出画像認識アプリケーションのモニタリング（欠陥検出画面）表示画面

3.3 異常波形検出アプリケーション

本アプリケーションは、工作機械から得られる IoT データ等時系列データを基に学習モデルを作成し、作成された学習モデルを用いて検査対象の正常／異常の判定を行うソフトである。画面では、時系列モデルと呼ぶこともある。

図 3.3-1 に、異常波形検出アプリケーションのシステム全体像を示す。

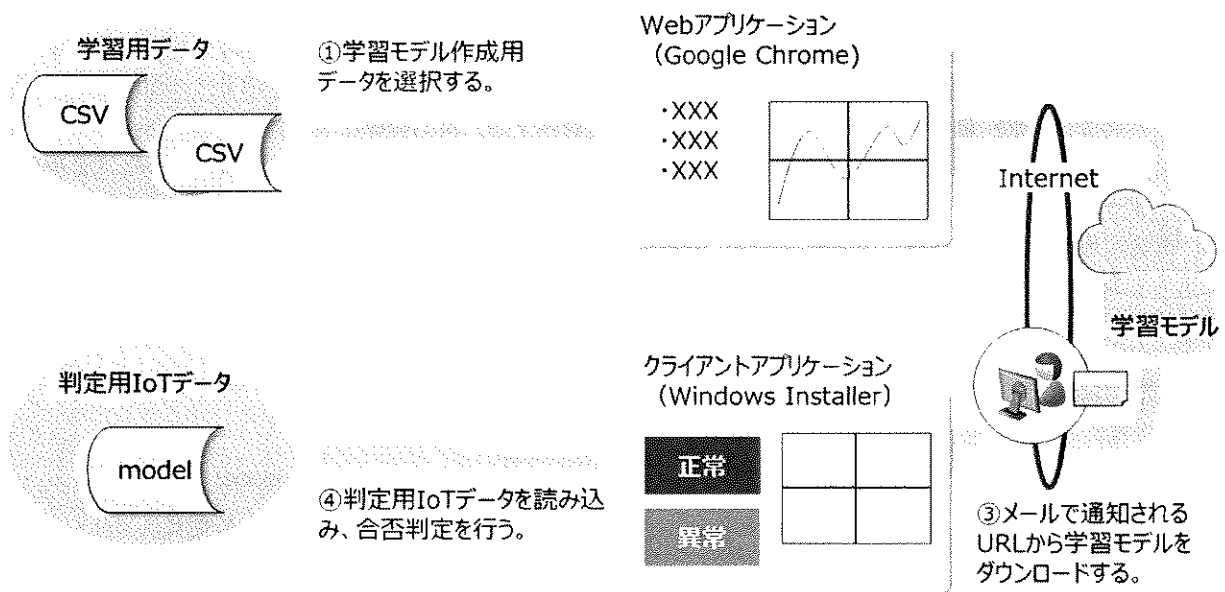


図 3.3-1 異常波形検出アプリケーションシステム全体像

図 3.3-2 は、異常波形検出アプリケーションを利用するにあたって、ログインからログアウトまでの利用の一般的な流れを示したものである。

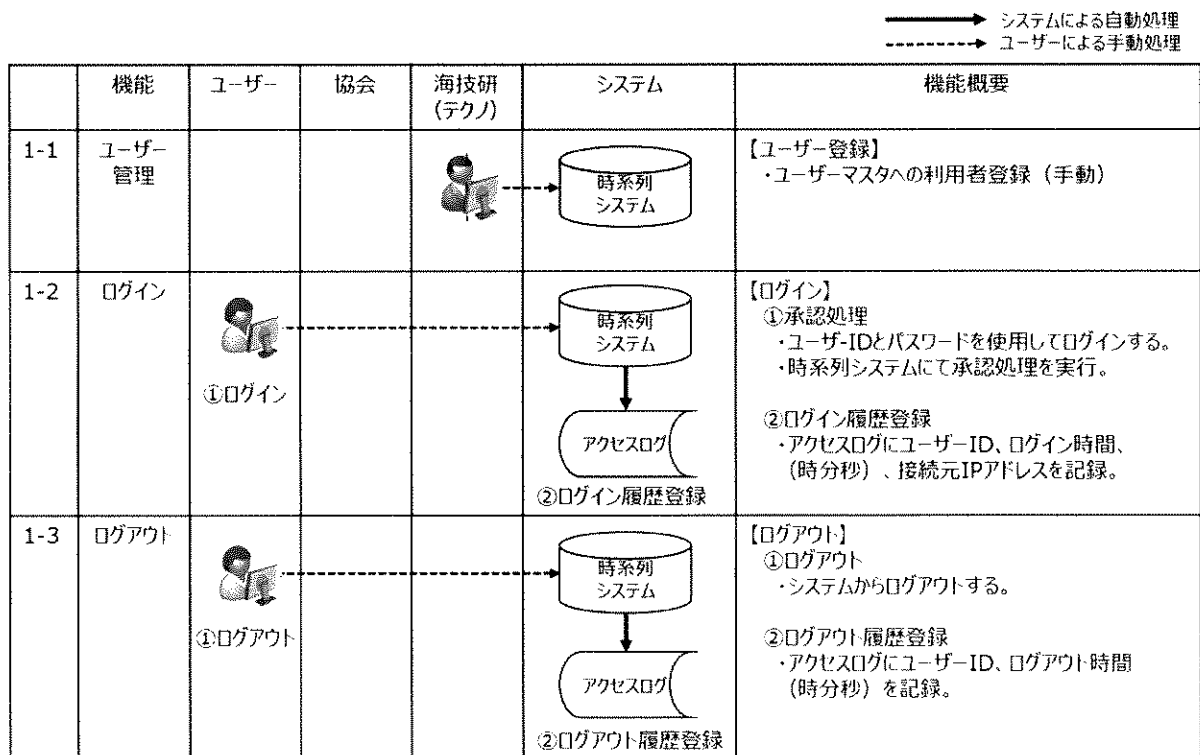


図 3.3-2 異常波形検出アプリケーション業務フロー（ログインからログアウト）

図 3.3-3 は、ユーザーが異常波形検出アプリケーションでモデル作成をする際の業務フローとなっている。システムによる自動処理とユーザーによる手動処理を区別して記載している。

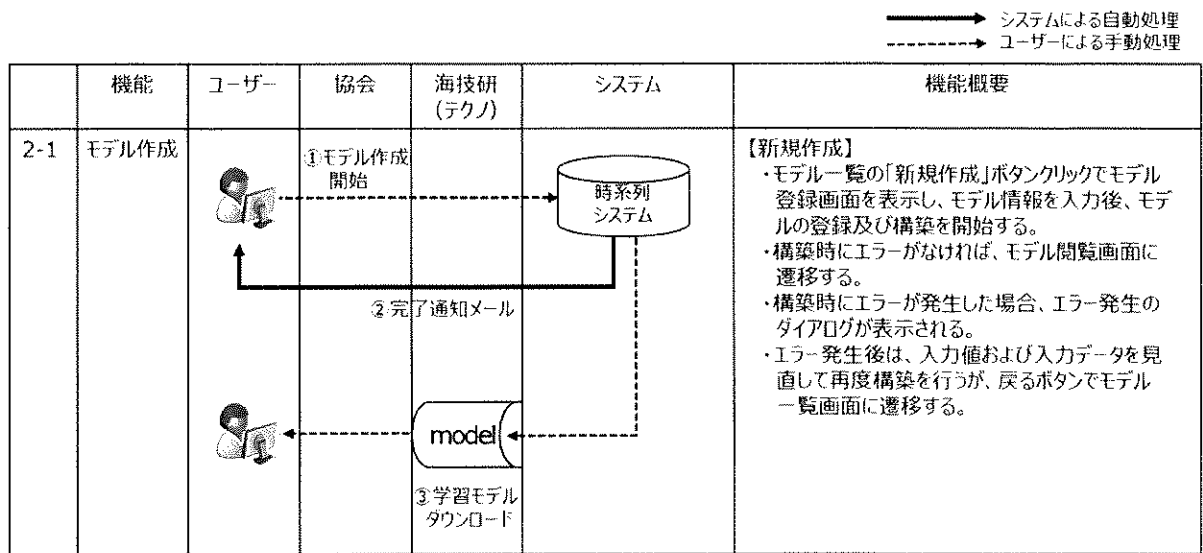


図 3.3-3 異常波形検出アプリケーション業務フロー（モデル作成）

図 3.3-4 は、クライアントアプリケーション上で、異常波形を検出（判定）する処理の業務フローを記載している。

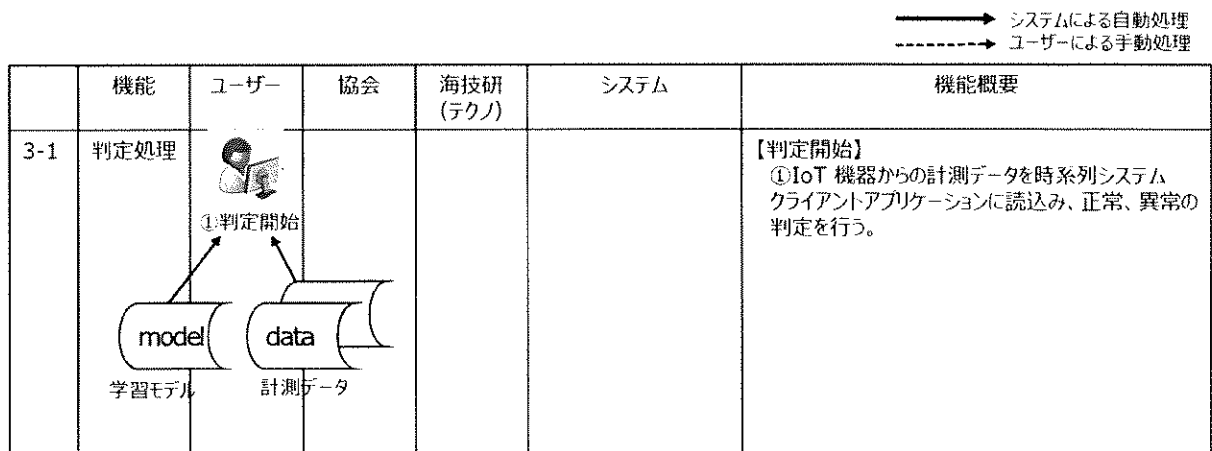


図 3.3-4 異常波形検出アプリケーション業務フロー（判定処理）

図 3.3-5 は、異常波形検出アプリケーションに入った後の画面遷移を示す。図 3.3-5 に示すように、異常波形検出アプリケーションを利用するにあたって必要となる環境設定画面で入力した後、モデルの登録、閲覧操作を行うように仕様を設定した。

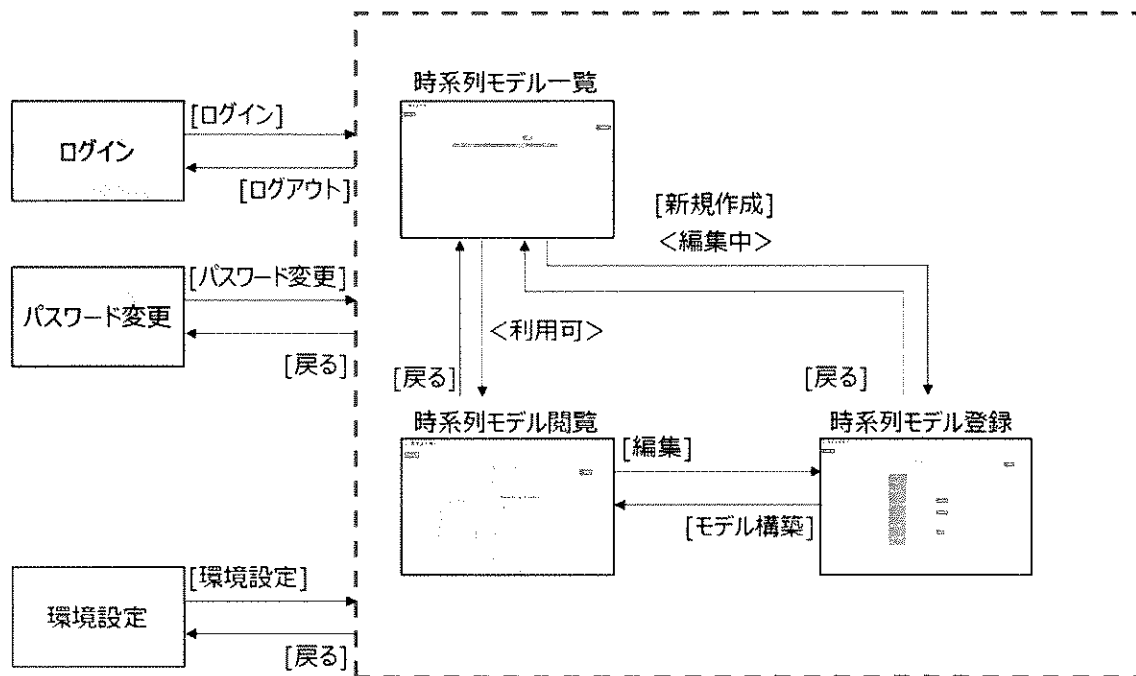


図 3.3-5 異常波形検出アプリケーション画面遷移

図 3.3-6 は、環境設定の画面である。この画面では、読み込む時系列データの項目区切り文字の設定（カンマ、スペース、タブ）とデータの分割数、オフセットの割合を設定する。

図 3.3-7 は、異常波形検出アプリケーションで使用するモデル一覧を閲覧する画面である。

異常波形検出

時系列モデル一覧

新規作成

モデルID: モデル名: 検索

モデルID	モデル名	登録日時	状態
000001	テスト01	2020/08/02 11:20	利用可
000002	テスト02	2020/08/04 11:20	利用可
000003	テスト03	2020/08/07 13:20	利用可
000004	テスト04	2020/08/09 18:20	利用可
000005	テスト05	2020/08/09 19:20	利用可
000006	テスト06	2020/08/09 10:20	利用可
000007	テスト07	2020/08/09 11:30	利用可
000008	テスト08	2020/08/09 09:10	利用可

図 3.3-6 異常波形検出アプリケーションモデル一覧閲覧画面

本アプリケーションでは、時系列データを取り扱っており、本アプリケーションの画面上は時系列モデルと呼ぶ。時系列モデルの呼び出し、新規作成、検索等を行う。図 3.3-7 は、異常波形検出（時系列モデル）を呼び込んだ詳細画面である。グラフの表示範囲の縦軸最大値、縦軸最小値入力、横軸最大値入力、横軸最小値入力を行う。データを読み込んでグラフ表示を行い、データを視覚的に確認することができる。

図 3.3-8 に移動して、設定した内容を確認することができる。




図 3.3-7 異常波形検出アプリケーションモデル閲覧画面

図 3.3-7 の画面で、編集ボタンを押すと図 3.3-8 の時系列モデル登録画面に遷移する。ここでは、2.2 で述べた正常データと異常データの AI 学習要領で処理が行われる。

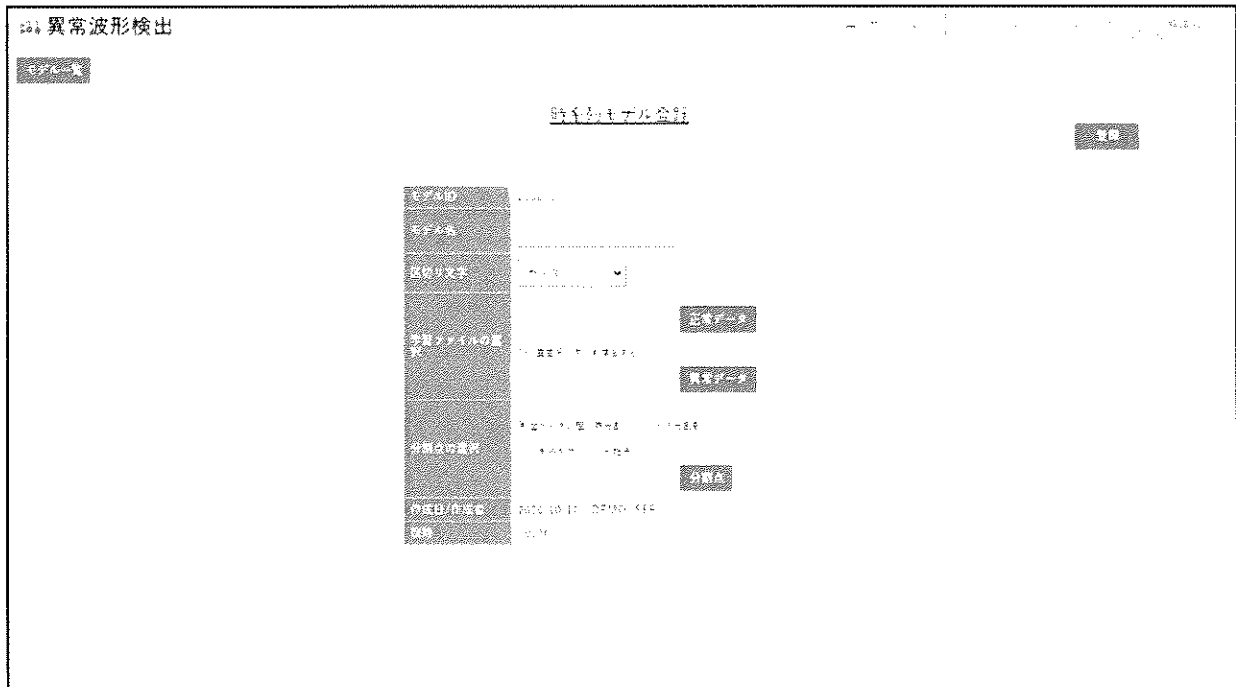


図 3.3-8 異常波形検出アプリケーションモデル登録画面




図 3.3-9 異常波形検出アプリケーションモデル詳細画面

図 3.1-6 のトップページ画面で、異常波形検出アプリケーションボタン下のクライアントアプリのダウンロードリンク(クライアントアプリケーションのインストールはこちら)をクリックすると、クライアントアプリケー

ションを起動する実行ファイルがダウンロードされる。実行すると、図 3.3-10 に示すクライアントアプリケーションが起動される。




図 3.3-10 異常波形検出クライアントアプリケーション初期画面

3.4 汎用機械学習

図 3.4-1 は、汎用機械学習アプリケーションに入った後の画面遷移を示す。図 3.4-1 に示すように、汎用機械学習アプリケーションを利用するにあたって必要となる環境設定画面で入力した後、モデルの登録、閲覧、予測モデルの作成、結果表示等の画面の仕様を設定する。

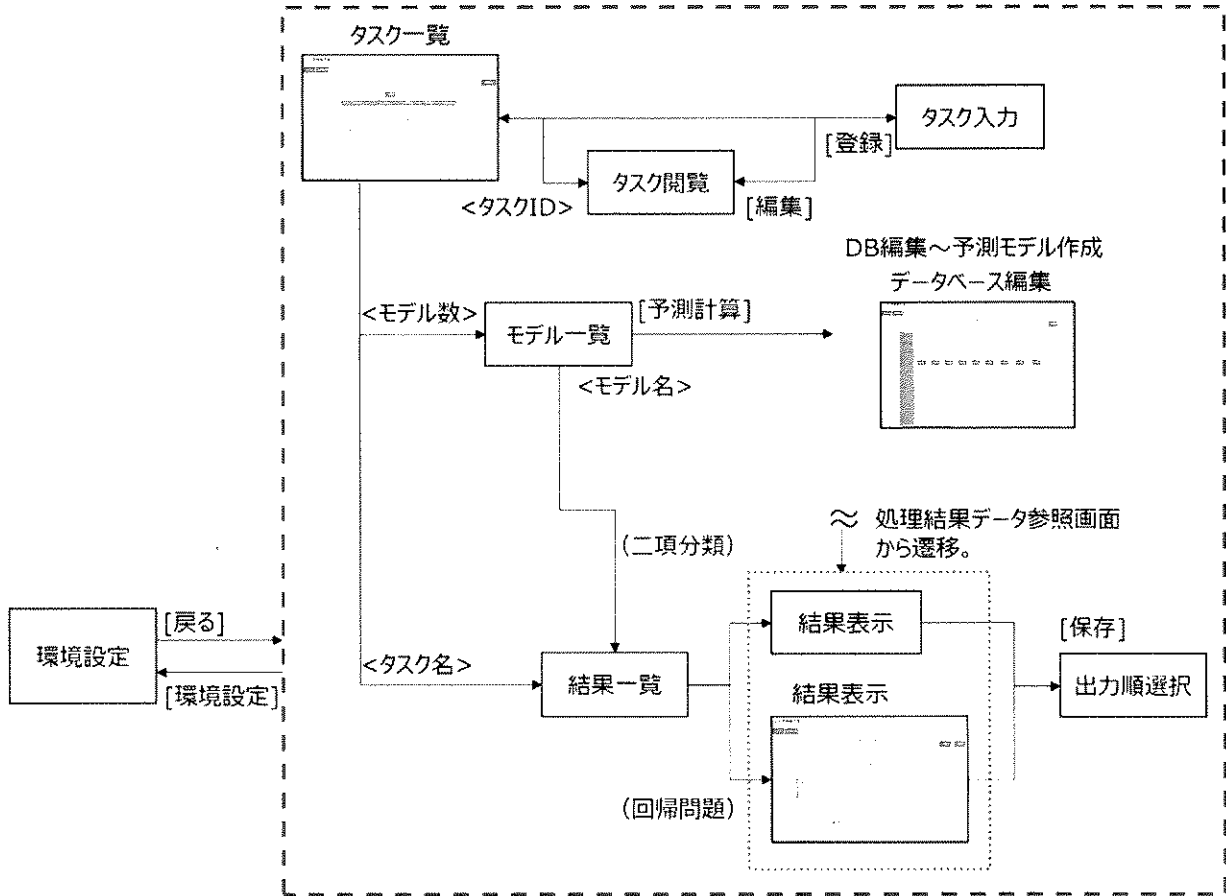


図 3.4-1 汎用機械学習アプリケーション内の画面遷移

図 3-4-2 は、汎用機械学習アプリケーション機能の中で、DB 編集から予測モデル作成までの画面遷移を示す。

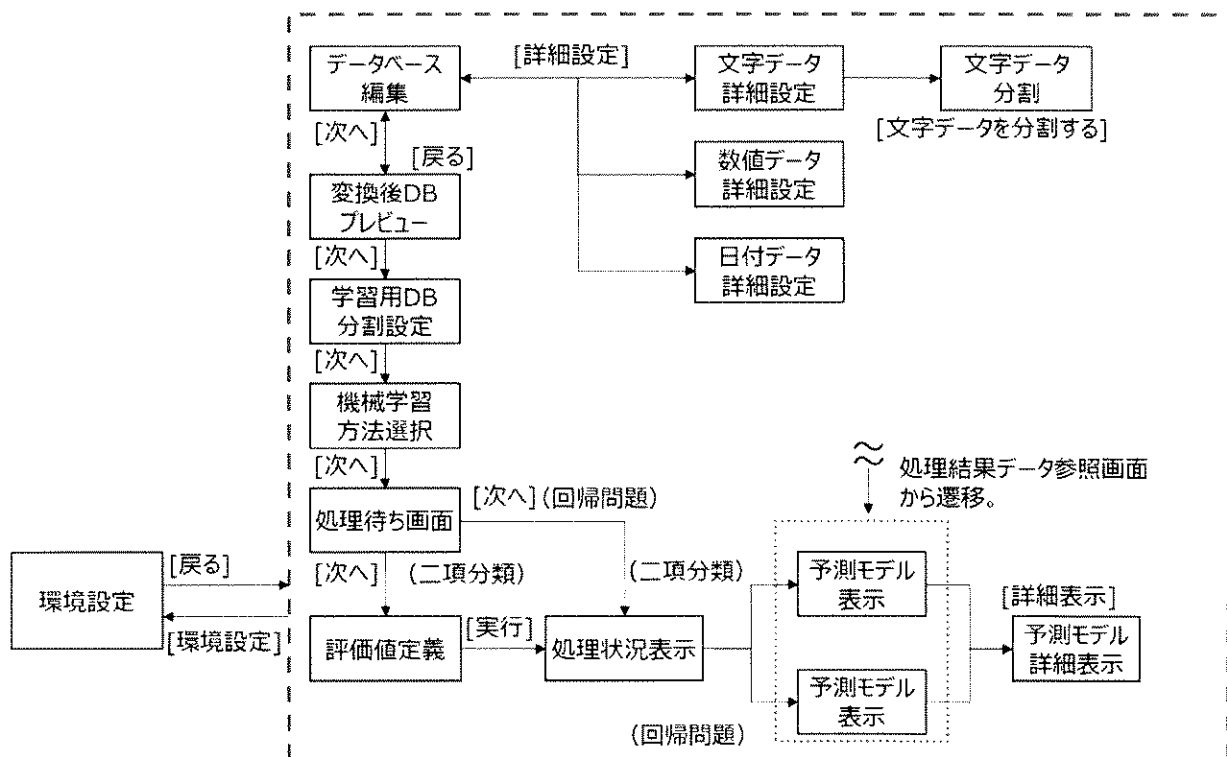


図 3.4-2 汎用機械学習アプリケーション内の画面遷移 (DB 編集から予測モデルの作成まで)

4. まとめ

「品質管理の高度化に関する AI 活用システムの開発研究」として、海技研が AI を活用した基礎的研究をベースに Web アプリケーションシステムの基本仕様を株式会社テクノソリューションと共同して制作した。基本仕様を基に、株式会社テクノソリューションが詳細仕様の検討、システムの開発を行った。

制作した Web アプリケーションシステムは、①汎用機械学習、②欠陥検出画像認識、③異常波形検出のアプリケーションを統合した海技研クラウド上で動作する Web アプリケーションである。委員会メンバーにユーザーID を付与して、本システムの動作検証を行った。

参考文献

- 1) 情報機構，機械学習・人工知能業務活用の手引き～導入の判断・具体的応用とその運用設計事例集～，情報機構
- 2) A. Krizhevsky, S. Ilya, and G. E. Hinton. Imagenet classification with deep convolutional neural networks. In Advances in Neural Information Systems (NIPS), pp.1097-1105, 2012
- 3) K. Simonyan, and Andrew Zisserman, Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, 2014
- 4) C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich, Going deeper with convolutions, IEEE Conference on Computer Vision and Pattern Recognition, 2015
- 5) R. Girshick, J. Donahue, T. Darrell, and J. Malik, Rich feature hierarchies for accurate object detection and semantic segmentation IEEE conference on computer vision and pattern recognition, pp.580-587, 2014.

- 6) J. R. R. Uijlings, K. E. A. Van De Sande, T. Gevers and A. W. M. Smeulders, Selective search for object recognition, *International journal of computer vision*, vol. 104, no. 2, pp.154-171, 2013
- 7) Shaoqing Ren et. al., Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks .2015

AI技術の活用による 不適合未然防止

国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所

間島 隆博、平方 勝
馬 沖、○小沢 匠

AI研究の流れ

ダートマス会議 (1956年)

第一次ブーム


第二次ブーム

第三次ブーム

ニューラルネットワーク (NN) の活用


2011年 音声認識 2012年 画像認識 2014年 LSTM (マルチモーダル)

< 深層NN >




Googleの猫

< マルチモーダル >



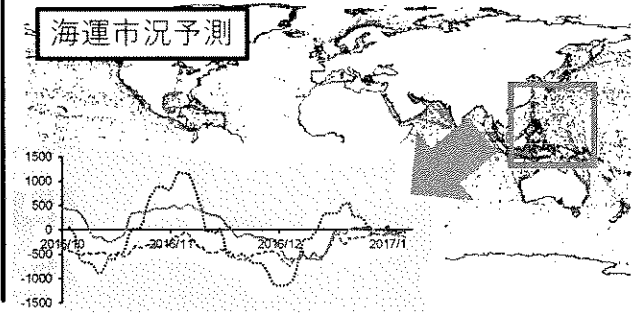

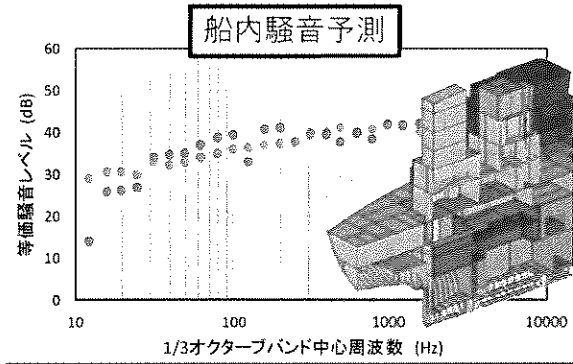
キャプション生成

< 深層強化学習 >



AlphaGo

海技研の取り組み



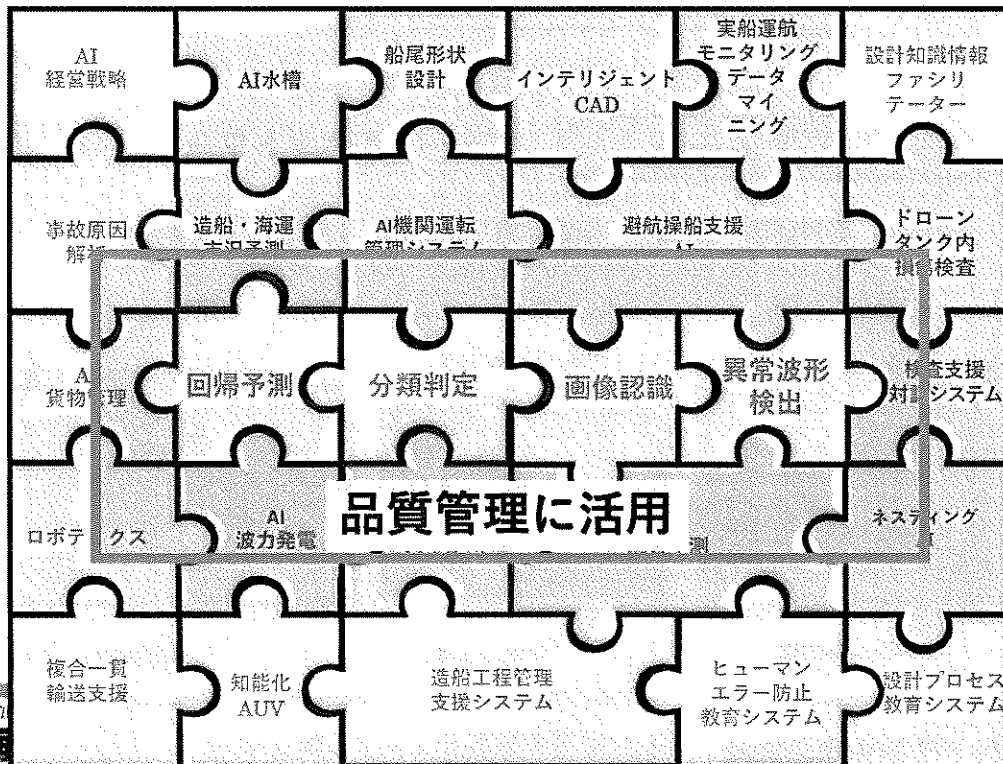
国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所
 National Maritime Research Institute.

品質管理の高度化に関する調査研究
 成果報告会
 2021/3/9

海技研の取り組み

海事分野におけるAI研究テーマビジョン

- 完了・実施中
- 今後のテーマ

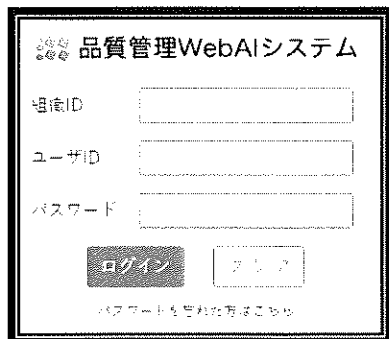


国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所
 National Maritime Research Institute.

成果報告会

2021/3/9

2020年度に開発したAIアプリの紹介



<https://quality-ai.nmri.go.jp/appco/COC0101/>

汎用機械学習

文字・数値の組み合わせから
結果を推定する人工知能



画像認識

傷や部品など、写真から特定の
画像を発見する人工知能



異常波形検出

正常な波形から逸脱していないか
波形を監視するシステム




汎用機械学習

文字・数値の組み合わせから
結果を推定する人工知能

STEP 1: 学習


この条件で発注した α 部品は異常なし、
短納期で発注した β 部品は傷があった、
国内A社さんの γ 部品は異常なし、



STEP 2: 予測

この条件で γ 部品を発注している。
A君、どう思う？

傷がある可能性が高いです。
検査を確りとやってください。

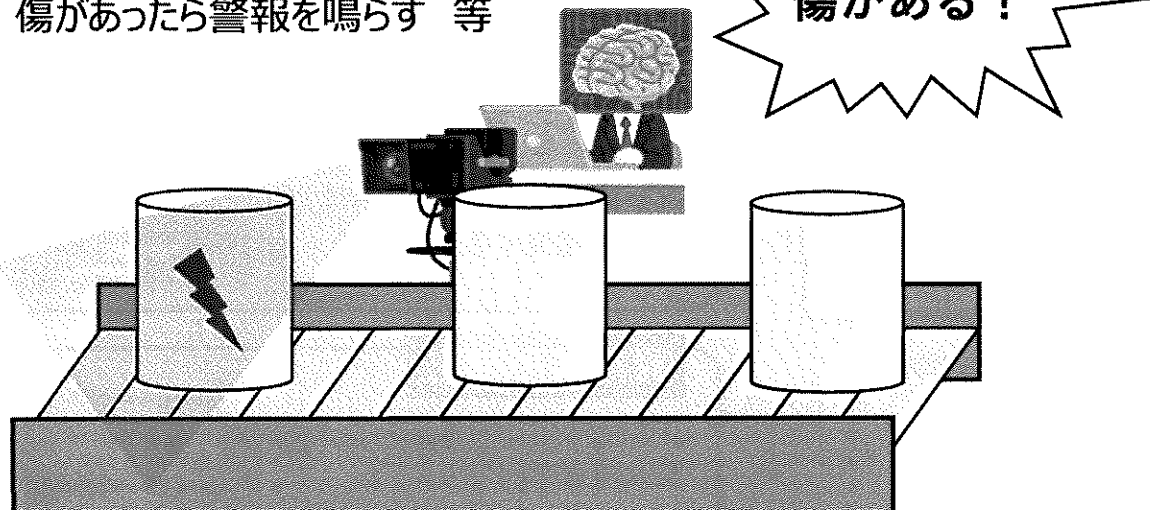


画像認識

傷や部品など、写真から特定の
画像を発見する人工知能

活用例：

製品をカメラで撮影し、
傷があったら警報を鳴らす 等



国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所
National Maritime Research Institute.

品質管理の高度化に関する調査研究
成果報告会 2021/3/9




7

異常波形検出

正常な波形から逸脱していないか
波形を監視するシステム

活用例：

工作機械のトルクを監視し、
(ドリルの摩耗等) 正常な波形から
逸脱したら、警報を鳴らす

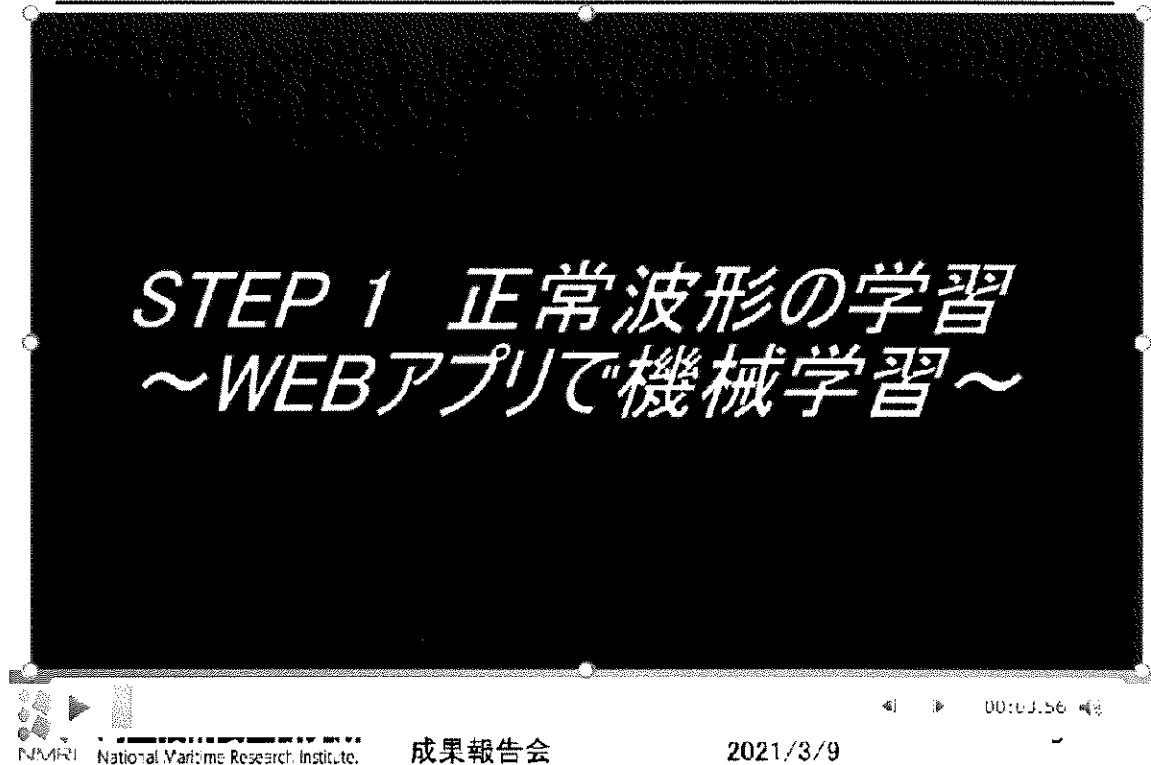


国立研究開発法人 海上・港湾・航空技術研究所
海上技術安全研究所
National Maritime Research Institute.

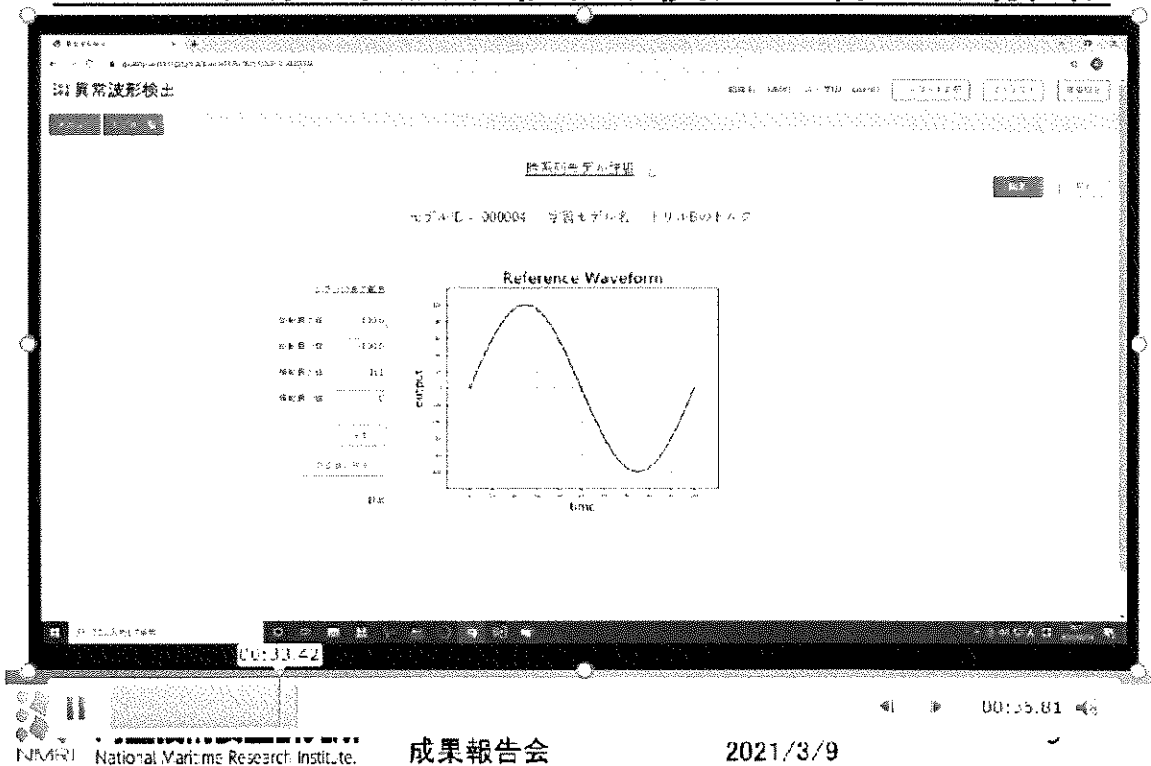
品質管理の高度化に関する調査研究
成果報告会 2021/3/9

8


AIアプリ(異常波形検出)使用の様子(動画)



AIアプリ(異常波形検出)使用の様子(動画)

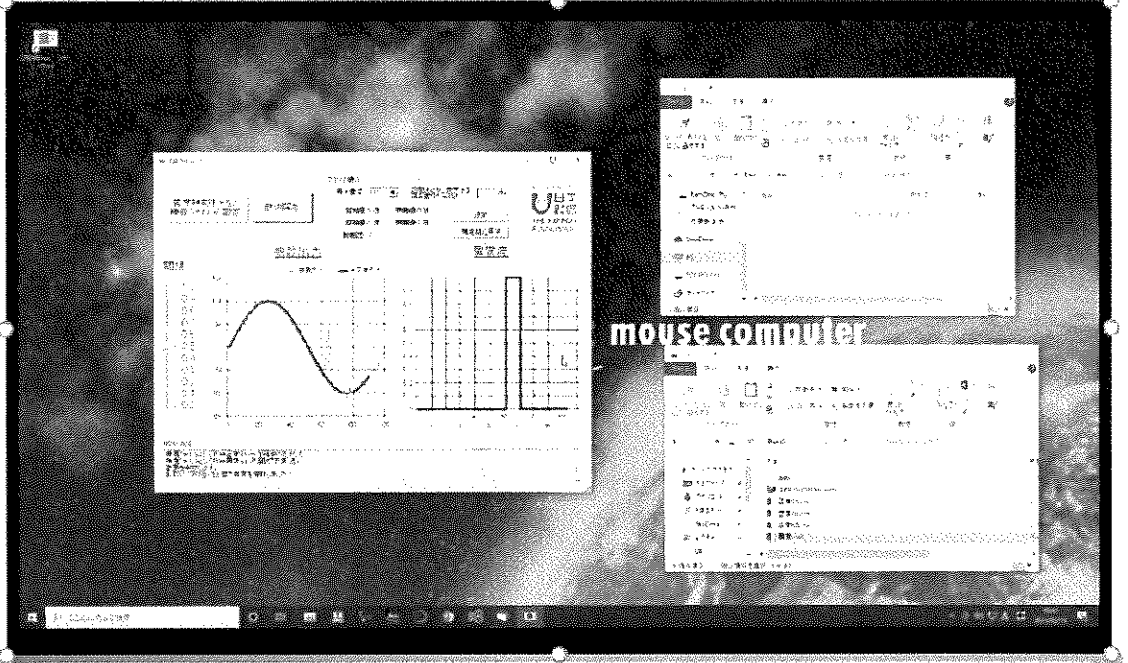


AIアプリ(異常波形検出)使用の様子(動画)



NMRI National Variome Research Institute. 成果報告会 2021/3/9 00:45.95

AIアプリ(異常波形検出)使用の様子(動画)



NMRI National Variome Research Institute. 成果報告会 2021/3/9 02:24.49

まとめ

- 海上技術安全研究所では世界的なAI技術の進化をフォローし、特に船舶分野でAI技術が活用できるよう、研究を続けております。
- 2020年度の成果として、日本船舶品質管理協会の要請に答え、日本財団の助成の下、品質管理WEB AIシステムを構築しました。このシステムでは3つのAIシステム（汎用機械学習・画像認識・異常波形検出）を使用でき、用途に合わせ様々な活用方法が考えられます。
- 今後も新しいAI技術の活用方法を研究し、皆様からの声をフィードバックし、より使いやすくなるよう、ブラッシュアップしていきます。皆様も是非ご活用ください。



ご清聴ありがとうございました

