

業務シナリオセッション B

AI装い現場改革

On-site reform accompanied by AI

IVIシンポジウム2020 -Spring-

2020年3月13日

堅実型

AIによる製造ラインの生産性向上 ～検査工程 Part3



市本 秀則 (マツダ (株))



久保田 進也 ((株) シーイーシー)



瀬戸 大樹 ((株) ニコン)



小森 悠一 (マツダ (株))

大塚 広晃 ((株) ディー・オー・エス)

片田 博之 ((株) ヒロテック)

劔持 真弘 (トヨタ自動車 (株))

近藤 修 (コマツ)

中川 智晴 ((株) ジェイテクト)

中村 嘉克 (中村留精密工業 (株))

本田 昌弘 ((株) ニコン)

山口 武彦 (三菱電機 (株))

発表者： 瀬戸 大樹



Industrial Value Chain Initiative



ファシリテータ



エディター

5C02

1. 現状課題と目指す姿


1 - 1. テーマ設定

① 困りごとチャート



【困りごと】

- 検査を自動化したものの設定や誤判定処理に手間がかかっている。
- また、不良要因解析に時間が掛かり要因の抑え込みが進まず検査に頼っている。



【テーマ設定】


AIの活用で、自動化：検査判定率の100%化
不良要因分析、不良抑え込みの早期化

堅実型

1. 現状課題と目指す姿


1 - 2. 現状の業務 (AS-IS)

<対象工場 マツダ カムシャフト加工ライン>




<やり取りチャート (AS-IS) >

【不良 (ビバリ) 要因分析】



研削不良 (ビバリ) が発生、要因分析に時間が掛かる

【画像検査】



画像検査で自動化しているが、誤判定処理や初期設定に手間が掛かる


1. 現状課題と目指す姿

1 - 2. 目指す姿の検討


②なぜなぜチャート



なぜなぜチャート_要因分析



なぜなぜチャート_画像検査




1. 現状課題と目指す姿

1 - 3. あるべき姿／ありたい姿 (TO-BE)


<対象工場 マツダ カムシャフト加工ライン>

素材投入 → 両端穴 → オイル通路 → 荒加工 → 研削




ラップ 検査

研削面 画像検査




<やり取りチャート (TO-BE) >

【 要因分析+AI (機械学習) 活用 】



【 画像検査 + AI (Deep Learning) 】



Step1: 製造データから不良要因を分析して特定する
Step2: AIによる監視 (予防保全)
Step3: 加工条件を制御し、不良発生ゼロ

Deep Learningで判定率100%。
機種追加時の設定時間の短縮化。

1. 現状課題と目指す姿

1 - 4. あるべき姿／ありたい姿（まとめ）


目指す姿

対象：加工工程、検査工程

概要：①工作機械のセンシングデータを解析、特定不良の発生要因を判定

②ワーク画像をDeepLearningで判定、良品/不良品に仕分け

構成：



2. 実証実験シナリオ # 1、# 2

対象概要

実証実験
1

実証実験
2




①対象部品
カムシャフト



カムシャフト (CM)
鋳造品

②対象工場
マツダ株式会社 カムシャフト加工ライン

③対象工程



2. 実証実験シナリオ # 1、# 2

対象概要

実証実験
1

実証実験
2



研削設備

実証実験#1



課題

ビバリ不良が発生する
不良要因の分析に時間がかかる

外観検査設備



実証実験#2




課題

判定率 100 % 未達成
立ち上げ時の設定に時間がかかる

検査画像例



検出困難



(1) 実証実験の狙い

実証実験 # 1 不良要因分析へのAI導入

● 狙い


カムシャフトのビビリ不良を抑制

不良要因分析、予知手法の習得

● 概要

基本方針：フリーソフトを使った安価なシステム構成

- Step1：製造データから不良要因を分析して特定する
- Step2：AIによる監視（予防保全）
- Step3：加工条件を制御し、不良発生ゼロ




(2) 実証実験の手順・進め方

● Step1 : 製造データから不良要因を分析して特定する

製造データの収集




エッジ型解析モジュール TOYOPUC-AAA



ビビり要因系統図

- クーラント流量(1種類) 1Hz
- サーボ系データ(7種類) 80Hz
- 振動データ(2種類) 1000Hz



TOYOPUC、TOYOPUC-AAAは株式会社ジェイテクトの登録商標です



(2) 実証実験の手順・進め方

● Step1 : 製造データから不良要因を分析して特定する


➤ ビビリ要因の時系列データの分析手法検討

分析対象のサンプル総数(2,710ヶ)

良品 : 2,690ヶ / 不良 : 20ヶ

1 サンプル (204,881データ)

10波形 (1Hz, 80Hz, 1000Hz)



総数(2,710ヶ)

不良： 20ヶ

1データ)

Hz, 1000Hz)

		データの前処理						
		特徴量			時系列→標本化			
要因分析アプローチ		統計量	周波数	クラスタリング	加工区間	スライド窓	スペクトル変換法	ガードバンド
1	機械学習モデル化	◎	◎		◎			
2	統計手法	◎		◎	◎	◎		◎
3	波形分析（閾値）		◎	◎			◎	◎

機械学習モデル用に時系列データを説明変数として扱えるよう加工区間で分割し、特徴量は統計量で標本化
データ処理にはフリーソフトのKNIMEを利用し自動処理

2 - 1. 実証実験シナリオ # 1

実証実験

1



(2) 実証実験の手順・進め方

● Step1 : 製造データから不良要因を分析して特定する

➤ ビビリ要因の時系列データの分析手法検討


時系列データを分割 (204,881データ)
(加工 8 区と未加工 9 区、合計17区間)

区間ごとに統計量算出

統計データ書き出し (1365データ)



切り出しワークフロー
(KNIME)



統計量 (8種類)
最小値、最大値、平均、
標準偏差、分散、歪度、尖度、総計

切り出した結果 (例)

	1	2	3	4	5	6	7	8	9	10	11	1360	1361	1362	1363	1364	1365	1366
1	OKNG	ワークID	1+移動	1+1+移動	1+1+移動	1+1+移動	1+1+移動	1+1+移動	1+1+移動	1+1+移動	1+1+移動	移動_5+9+移動	移動_5+9+移動	移動_5+9+移動	計測終了時 filename	外気温℃	湿度%	床高
2	OK	K1K753231	1	29	18.2	13.953494	194.7	-0.651257	-3.056031			0.024	2.513	-2037.058	*****	K1K753231	11.6	32
3	OK	K1K753231	1	29	18.2	13.953494	194.7	-0.651257	-3.056031			0.024	2.513	-2037.058	*****	K1K753231	11.6	32
4	OK	K1M753010	1	59	28.4	20.659138	426.8	0.3779039	1.88691			-0.008	0.831	-4671.961	*****	K1M753010	11.9	30
5	OK	K1M753010	1	59	28.4	20.659138	426.8	0.3779039	1.88691			-0.008	0.831	-4671.961	*****	K1M753010	11.9	30
6	OK	K1M753043	1	34	21.4	13.649176	186.3	-0.985866	-0.506525			-0.128	2.041	-3190.616	*****	K1M753043	11.9	30
7	OK	K1M753043	1	34	21.4	13.649176	186.3	-0.985866	-0.506525			-0.128	2.041	-3190.616	*****	K1M753043	11.9	30
8	OK	K1M753050	1	51	26.4	17.910891	320.8	-0.112412	1.5094764			-0.105	1.658	-2853.447	*****	K1M753050	12.1	27
9	OK	K1M753050	1	51	26.4	17.910891	320.8	-0.112412	1.5094764			-0.105	1.658	-2853.447	*****	K1M753050	12.1	27
10	OK	K1M753070	7	70	32.2	23.036927	530.7	1.2849738	2.8583887			0.042	1.2	-5320.773	*****	K1M753070	10.9	31
11	OK	K1M753070	7	70	32.2	23.036927	530.7	1.2849738	2.8583887			0.042	1.2	-5320.773	*****	K1M753070	10.9	31
12	OK	K1M753083	13	70	33.8	31.347131	455.7	1.6285061	3.4766077			-0.114	5.136	-1201.8	*****	K1M753083	10.9	31
13	OK	K1M753083	13	70	33.8	31.347131	455.7	1.6285061	3.4766077			-0.114	5.136	-1201.8	*****	K1M753083	10.9	31
14	OK	K1M753083	13	70	33.8	31.347131	455.7	1.6285061	3.4766077			-0.114	5.136	-1201.8	*****	K1M753083	10.9	31
15	OK	K1M753083	13	70	33.8	31.347131	455.7	1.6285061	3.4766077			-0.114	5.136	-1201.8	*****	K1M753083	10.9	31

1 サンプル約20万データを1365の特徴量に変換。

1 サンプル約20万データを1365の特徴量に変換。
KNIMEでワークフローを作り、2710サンプルすべて自動実行

2710サンプル

(2) 実証実験の手順・進め方

● Step1 : 製造データから不良要因を分析して特定する

➤ 分析・予測モデルの作成

① 勾配ブースティング木

(Rapid Miner Auto Modelを使用)

Rapid miner Auto Model

- ① 重要度の低い特徴量を事前に除外(欠損値や同一値が多い等)
- ② データを学習用と評価用のデータセットに分割
- ③ 学習用データセットを使用してk-交差検証を行いながら追加特徴量の自動生成を行う
- ④ ③で追加された特徴量を含めて学習を実施
- ⑤ ④で作成されたモデルで評価用データセットの評価を行う

<評価指標の結果>

	勾配ブースティング木	ナイーブベイズ
Accuracy	1.0000	0.9948
Recall	1.0000	0.9961
Precision	1.0000	0.9987
F1	1.0000	0.9974
AUC	1.0000	0.9000

Accuracy正解率、Recall再現率、Precision適合率


<混同行列>

勾配ブースティング木		実測	
		OK	NG
予測	OK	769	0
	NG	0	6

ナイーブベイズ		実測	
		OK	NG
予測	OK	766	1
	NG	3	5

モデル構造

勾配ブースティングとランダムフォレストを組み合わせた決定木のアンサンブル学習



モデルイメージ

変数重要度 (大きいものから一部リストアップ)

Attribute	Weight
13+移動_7+実効電流(X:といし台切込 %)+歪度	0.162
16+Cam_8+実効電流(X:といし台切込 %)+総計	0.158
9+移動_5+実効電流(C:工作主軸 %)+分散	0.154
3+移動_2+実効速度(X:といし台切込 mm/min)+最小	0.149
8+Cam_4+実効位置(C:工作主軸 度)+最大	0.144
16+Cam_8+実効位置(X:といし台切込 mm)+標準偏差	
17+移動_9+実効速度(C:工作主軸 min-1)+分散	

Cam : 加工中のデータ
移動 : 未加工時のデータ

変数の解釈

- ・要因として加工中だけでなく、未加工中のデータも出てきた。
- ・未加工時、砥石は無負荷状態で空転し次の加工部位へ移動状態。
- ・砥石のアンバランスは空転中はその影響が出やすい
- ・その結果として機械学習が未加工時を重要度の高い変数として選んだと解釈。
- ・未加工中のデータを除き再学習すると予測精度が低下したことから未加工のデータの重要性を確認した。

勾配ブースティング木では正解率、再現率、適合率ともに1.0で100%ビビリ不良を予測できる結果となった。
ナイーブベイズも若干劣るが高い精度の結果が出た。

Rapid Minerは、Rapid Miner, Inc.の商標または登録商標です。

(2) 実証実験の手順・進め方

● Step1 : 製造データから不良要因を分析して特定する

➤ 分析・予測モデルの作成

② ロジスティック回帰

(Pythonでの堅実実装の結果)

K-交差検証でモデルの評価

- ① 全データを複数(K)個のサブサンプルに分割
- ② 分割したサブサンプルのうち、1つを評価用データ、残りを学習用データとして、学習用データでモデルを作成する
- ③ 評価用データを新たなデータと見立てて、評価指標を算出する
- ④ ②と③をデータを分割した回数分繰り返す
- ⑤ 分割した回数分の評価指標算出が完了したら、モデル評価を行う

評価指標結果

	XGBoost + 閾値最適化	ランダムフォ レスト	ロジスティック回帰 + 閾値最適化
Accuracy 正解率	0.99410	0.98968	0.99558
Recall 再現率	0.80000	0.20000	0.80000
Precision 適合率	0.57143	0.25000	0.66667
F1	0.66667	0.22222	0.72727
AUC	0.89777	0.59777	0.99316
MCC	0.67336	0.21846	0.72813

MCC : マシューズ相関係数は、2値分類モデルの評価に有用

MCCの高いロジスティック回帰は正解率0.99、再現率0.80
適合率0.66 だった

ロジスティック回帰モデル式

x が入力で、pが確率（出力）、αとβがパラメータ。


$$\text{logit}(p_i) = \ln\left(\frac{p_i}{1-p_i}\right) = \alpha + \beta_1 x_{1,i} + \dots + \beta_k x_{k,i},$$

$$i = 1, \dots, n,$$

シグモイド関数を用い、データが2値のどちらに属するかの確率を
計算する手法を用いた分析方法

出典 : Wikipedia

変数重要度 (大きいものから一部リストアップ)



変数の解釈

勾配ブースティング木と同様と考えられる。

Pythonは、Python Software Foundationの登録商標です。

2 - 1. 実証実験シナリオ # 1

(4) 検証結果 (代表モデル例)

実証実験
1



● 結果

➤ 実証実験用データ：121サンプル (すべて良品)

➤ 実証実験データの結果

OKのみの判定では予測モデルの検証できた

誤判定はなかった

(誤判定：OK品をNGと判定すること)

① 勾配ブースティング木

(RapidMinerのAutoModelの結果)

a) 混同行列
(2モデルとも)

実績値	予測値			計
	OK	NG	計	
	OK	NG	計	
OK	121	0	121	121
NG	0	0	0	0
計	121	0	121	121

b) 評価指標

	勾配ブースティング木	ナイーブベイズ
Accuracy 正解率	1.0000	1.0000
Recall 再現率	1.0000	1.0000
Precision 適合率	1.0000	1.0000
F1	1.0000	1.0000
AUC	1.0000	1.0000
MCC	1.0000	1.0000

② ロジスティック回帰

(Pythonでの堅実実装モデルの結果)

a) 混同行列
(3モデルとも)

実績値	予測値			計
	OK	NG	計	
	OK	NG	計	
OK	121	0	121	121
NG	0	0	0	0
計	121	0	121	121

b) 評価指標

	XGBoost	ランダムフォレスト	ロジスティック回帰 + 閾値最適化
Accuracy 正解率	1.0000	1.0000	1.0000
Recall 再現率	1.0000	1.0000	1.0000
Precision 適合率	1.0000	1.0000	1.0000
F1	1.0000	1.0000	1.0000
AUC	1.0000	1.0000	1.0000
MCC	1.0000	1.0000	1.0000

●成果

- 機械学習を用いて製造データから不良要因を分析、特定した。
複数の手法で分析予測モデルを作成、比較した
- KNIME等を用いたデータ処理、クレンジングのノウハウ
- 要因分析や良否判定のモデルを構築するノウハウ

●今後の課題

- Step2：再学習（データn増し精度UP）→ 実装
- Step3：加工条件を制御し、不良発生ゼロ

2 - 2. 実証実験シナリオ # 2

(1) 実証実験の狙い

実証実験
2



実証実験 # 2 加工外観検査工程へのAI導入

● 狙い

外観検査工程でのビバリ不良判定率100%化
学習用NGデータが少ない中で学習モデル作成する

● 概要




昨年度の経験を踏まえて以下の方針とした

- 現行画像検査と併用し、Deep Learningの対象は現場ニーズの高いカム面ビバリに的を絞る
- 全カム面共通の教師有学習とする




フリーソフトでディープラーニング勉強会を実施する


AI画像判別 学習モデル



● 学習データ収集



良品画像 : 2,685枚
(画像n増し含む)





ビブリNG画像 : 233枚
(7サンプル 画像n増し)

● モデル作成

- WiseImagingの欠陥位置指定学習を使用
- 教師有り学習
- フルスクラッチによる、モデル作成

工夫点：検査部位を固定し、データを複数の時期に収集し、過検出のデータを分ける等、収集時、学習時のデータのバラツキを抑えることが出来るようにした。



2 - 2. 実証実験シナリオ # 2



(2) 実証実験の手順・進め方

実証実験
2




ネットワーク

オンラインデータ取得 (8月~11月)



実証実験Deep Learning判定 (2月10日~)



2 - 2 .実証実験シナリオ # 2


(3) システムの構成

実証実験
2

IVI

全体構成像

WiseImaging®



WiseImaging、WiseImagingのロゴは株式会社シーイーシーの登録商標です。
イラスト出典：株式会社シーイーシー
SMBは通信プロトコルServer Message Blockの略称です。

● 結果

➤ 事前検証結果

【分類】

2種分類(OK・NG)

【使用画像枚数】

学習 OK : 270枚、NG : 105枚

検証 OK : 2,415枚、NG : 128枚



【Step数 (学習回数)】

300step

【テスト画像それぞれの精度(300step)】

OK $2,272/2,415 = 94.08$ [%]

NG $128/128 = 100$ [%]



➤ 実証実験でのテスト結果

2020年2月10日より実証実験開始。現在検証中



●成果

➤教師有り学習

- 学習用NGデータが少ない中で学習モデル作成できた。
- カム全体ではなく、部分で学習させる手法を学んだ
- ルールベースの検査設備に、AI（ディープラーニング）を実装できた。

●今後の課題

- ビビリ学習モデルの精度向上
- ビビリ以外の不良画像に対しても同様の取り組みを展開する



3. 終わりに

Special Thanks

- 三菱電機株式会社
別所様、奥川様、村中様、輝岡様、森田様、柳生様
- 株式会社シーイーシー
大和田様

メンバーより一言

- ・機械学習の勉強から実装まで経験できてありがたかった！
- ・要因分析の絞り込みに役立った！
- ・自社で取り組む際のやり口を勉強できた！
- ・オープンソースの概要は分かったが、まだ、使いこなすレベルには至っていない。
- ・他業界の方と交流出来、工場見学もでき、知見が広がった！
- ・IoT、AIという中で、皆、同じ課題がある。
- ・どう着手すればいいのかということが共通理解として得られた。
- ・普段システムの仕事しかしていないが、今回、モノ造りの場に立ち会うことが出来
今後の業務に役立てることが出来そう！ 等々

- 株式会社ジェイテクト
杉本様

