

# インプロセス管理システム開発について

## In-Process Management System Development

木下裕次\*

Yuji Kinoshita

従来の生産工程において「加工」→「検査」→「完成」という工程が一般的であるが、生産する機械においては「加工」と「検査」との間に時間差があるために多くの不良品が発生する可能性が高くなる。インプロセス管理とは、「加工」のプロセスにおいて「検査」を同時に行うシステムである。

当社で製造している切断機は切断速度が速いため、より早く不良品を確認できることは不良率を大幅に下げることになる。そこで、ECU（エッジコンピュータユニット）で金属部品加工（切断）時の AE（アコースティックエミッション）波を測定して解析し、「加工」と同時に「検査」が可能かどうか AE 波形のデータを解析した。

実生産機での検証のために不良品データを得ることができなかったが、量産時のデータをモデル化して分析した結果、刃物条件が変化する傾向が AE 波により確認できたので、この内容を報告する。

In conventional production processes, the process of *machining* → *inspection* → *completion* is generally used, but in production machinery, since there are long gaps of time between *machining* and *inspection*, defective products are more likely to occur. In-process management is a system that simultaneously performs *inspection* in the *processing* process.

Since the cutting machine manufactured by our company has a high cutting speed, sooner detection of defective products greatly leads to the reduce of the defect rate. We measured the AE (acoustic emission) waves using the ECU (edge computer unit) during the machining (cutting) of a metal part, and analyzed the AE waveform data to determine whether *inspection* is possible at the same time as *processing*.

Although we could not obtain defective product data for verification with an actual production machine, the tendency for blade conditions to change could be confirmed by the AE waves, as a result of modeling and analyzing the data during mass production. The details are reported in this paper.

### 1 はじめに

2015年頃から世の中がIoT（Internet of Things）の略で「モノがインターネットでつながる」に関心が高まった。当初は、クラウドに全てデータを上げて分析という流れであったが、実際にはデータ量の多さによるクラウドとの通信費用とクラウド利用費用の問題や処理時間の問題が判明し、障壁となっている。そこでクラウドには必要最小限のデータのみを上げ、データの処理はエッジコンピュータで行うという流れになってきている。

現在IoTという言葉は一般的になり、モノからセンシングを通じて得られるデータを情報化し、AI（Artificial Intelligence）化により情報データから付加価値を生出すことが今後の機械メーカーに必要と思われる。

当社の機械で生産される部品は主に自動車部品であり、金属加工となる。その加工プロセスにおいて良否判定が可能になれば、図1のように「加工」→「検査」→「完成」における「検査」を「加工」工程に入込むことができ、生産の効率化とコストダウンが可能になる。そこで金属加工時に発生する AE 波からの良否判定について検討を行った。



図1 インプロセス管理システム概要

### 2 AE（アコースティックエミッション）

AEとは、振動周波数より高い領域の周波数（60 kHz～1 MHz）であり、材料が変形あるいは亀裂が発生する際に、材料に蓄えられていた歪エネルギーを弾性波として放出する現象である。この弾性波を材料の表面に設置した変換子すなわち AE センサで検出し、信号処理を行うことにより材料の破壊過程を評価する手法が AE 法である。圧力容器、ダム、建物、道路、飛行機、自動車など、さまざまな構造物、設備の亀裂や摩擦摩耗の進行を破壊することなく評価することができ、また、

\*株式会社ケイエステック

漏洩、腐食、放電などの現象でも AE 波が発生し、これを検出することにより配管の漏洩や腐食、変圧器の部分放電などを評価できる。

材料により発生する周波数が異なり、鉄の場合 60 ~ 150 kHz 程度の AE 波が発生する。AE 波を測定することは 30 年以上前から知られている技術であるが、測定機器が非常に高価であったためになかなか浸透しなかった。

AE 波を測定するためには、高速サンプリング (10 MHz) ができる測定器が必要であったが、近年の FPGA (Field Programmable Gate Array: 製造後に購入者や設計者が構成を設定できる集積回路であり、現場でプログラム可能なゲートアレイである。) の発展によって測定できる ECU の開発が可能になったため AE 波の測定が身近になった。また、波形解析や AI 化のソフトウェアの進歩もあり、インプロセス管理システムの開発が進んできたので合わせて現状について説明する。

### 3 実施内容

#### 3.1 事前テスト

当社では、切断機・板金プレスを設計・製作しているが、精密鍛造素材切断機「MACS」<sup>1)</sup> (図 2) においては切断速度が速く、約 1 秒に 1 個ピレット (図 3) が生産されるために不良が発生すると不良数が多くなる問題がある。そのため不良などの異常が発生したときに即座に異常発生を表示する要望があった。今まで生産状態を検知する方法が無かったが、ECU にて AE 波を測定して波形解析を行い、検知できる可能性を確認した。



図 2 精密鍛造素材切断機「MACS」



図 3 ピレット

切断機でバー材からピレットが生産され、そのピレットを 800 ~ 1200 °C に加熱して温間または熱間鍛造プレスで部品を生産している。ピレットの切断面不良や曲がりなどが発生するとその影響で鍛造品が不良になるため、AE 波形により切断プロセスでの良品・不良品判定を検証する目的でテストを実施した。

事前テストにて評価するため、材質 S45C で研磨直後の鋭利な刃物条件での切断と、刃物コーナに R0.5 を付け刃物条件を悪くした場合の比較を行った。図 4 にその比較波形を示す。

研磨直後の刃物切断より刃物コーナ R0.5 で切断した方は、AE 波形の発生時間が長いことがわかる。なお色の違いは、データ転送パケットによる色分けでデータに関係無い。波形の横軸は時間、縦軸は AE 値 ± 10 V アナログデータをデジタルデータの 16 ビットのバイナリ値 (± 32,768) で表した値である。

AE 波の発生時間が長いということは、刃物の切れ味が低下したために金属組織を多く潰していくために発生エネルギーが多くなったと考えられる。切れ味が良い包丁であると力が少なく切断することが可能であるが、切れ味が悪いと潰す力が余分に発生するのと同じである。測定においては AE 波のアナログ信号をデジタル信号に変換する場合、サンプリング定理より倍以上のサンプリング周波数が必要であるが、鉄の場合 60 ~ 150 kHz 程度の AE 波に対して ECU は 10 MHz のサンプリング周波数なので十分である。




図 4 切断時の AE 波形

### 3.2. 実機テストおよび解析

#### 3.2.1 実機テスト

事前テストで AE 波形による違いが明確になったので、次に納入機の MACS3000 の実機生産における切断機で測定した。AE 波測定において、弾性波の減衰を考慮すると近くに取付けなくても測定が可能であるため、刃物から少し離れたところに AE センサを取付けている(図5)。データ収集の ECU を図6に示す。




図5 MACS3000へのAEセンサー取付位置




図6 ECUおよびECUコントロールPCなど

材質は SCM822H で行い、実生産のため事前テストと異なり良品だけのデータ測定になった。測定中に不良品が発生すれば、異常データとして測定でき「教師あり」学習が可能であったが、良品のデータしか測定することができなかったため「教師なし」のデータになった。多品種少量生産で測定データ 4,500 個の「教師なし」データになるため生産スタート時と生産終了付近でのデータに変化などの傾向が発生しているかどうか解析を行った。

波形の解析手法は多くあるが、まずは時系列データから波形解析が容易に行えることから東京エレクトロデバイス株式会社製の異常判別プログラム自動生成マシン「CX-M」<sup>2)</sup>(図7)を用いて解析を行った。CX-Mは、データファイルをクレンジング・特徴抽出・機械学習・モデ



図7 CX-M (旧型モデル)

ル作成までの分析作業が自動化されているため使い勝手が良い。

生産スタート時の 50 個のデータファイル + 4,500 個手前のデータファイル 21 個 = 71 個のデータファイルを CX-M に入力してグループ分けを wavelet 変換(時間と周波数にかかわる信号情報を同時に抽出)で行った。その結果 67 個のデータファイルは同じグループに分類され、残り 4 個のデータファイルは別々の 4 つのグループに分類できた(図8)。分類された 67 個のグループの wavelet 変換波形例が図9の⑤~⑧であり、その他のグループの wavelet 変換波形は、①~④である。

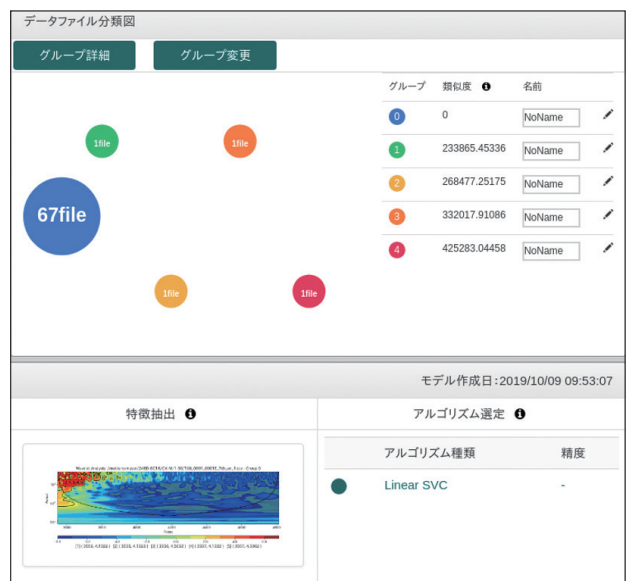


図8 CX-Mでのクラス分類結果

#### 3.2.2 CX-Mでのモデル化による検証

3.2.1 で得られた 67 個を良品モデル、4 個を不良モデルとして推論モデル化を行った。作成したモデルの精度確認のために 67 個のうち良品 50 個のデータファイルと分類された不良品 4 個のデータファイルで入力判定を行った結果が図10である。

作成したモデルで良品は良品、不良品は不良品と 100% の判定結果である。なお実際は全て良品であるが、分類のために良品・不良品という表現にしている。

図11は、モデル化により良品判定になった wavelet 変換波形例が⑤~⑧で不良品判定とした wavelet 変換波形が①~④である。よって、CX-Mにおいて、生産スタートと 4,500 個生産付近における分類は可能となり、推論モデル化により精度高く良否判定ができた。

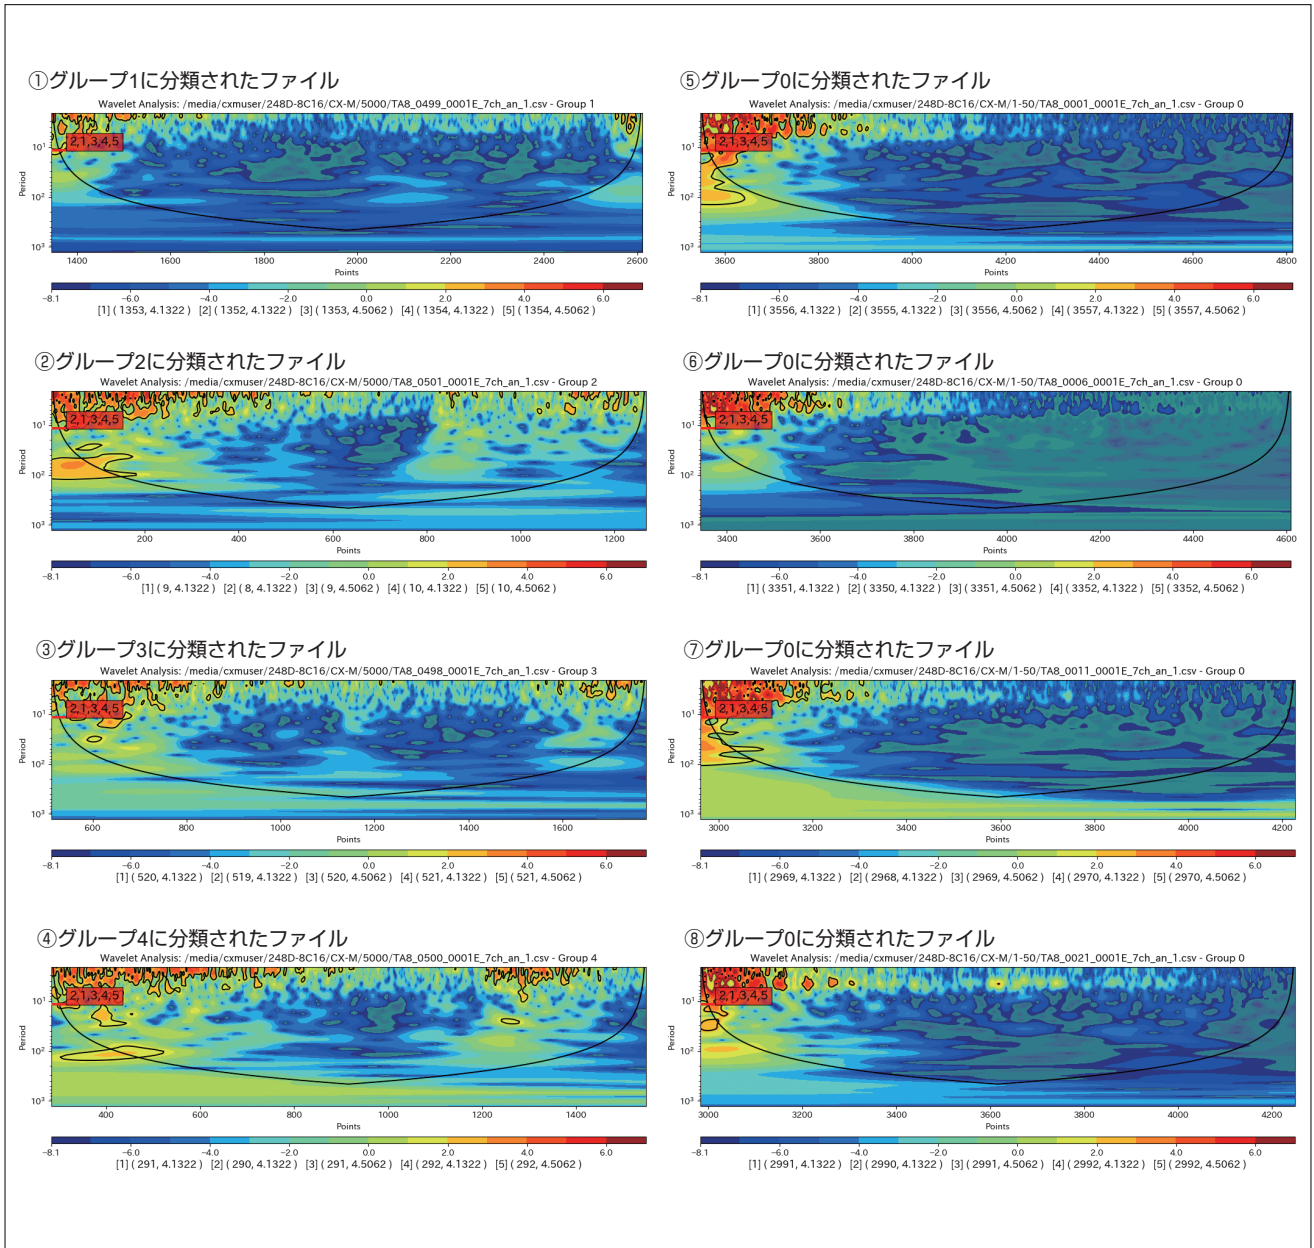


図9 クラス分け詳細 (wavelet)



図10 モデルでのクラス分類結果

しかし、CX-Mの学習できる容量がメモリ量で決まるために学習できる容量に制限がある。今回使用したCX-Mは旧型のため、メモリ量が16GBと容量が不足していた。

「教師なし」学習では、データ数が多いほど機械学習の容量も増え精度も上がるが、データファイルの入力容量制限があると機械学習の容量が決まるので、「教師なし」学習でのモデル化作成は、CX-Mでは難しいと判断した。なお、最新型モデルでは、メモリ容量が64GBに改善されている。

良品・不良品の明確なデータで学習できる「教師あり」学習では、データファイル容量が少なくなるので効果はあると思われる。推論モデル化作成においては、作成したモデルにデータを追加して再モデル化ができないために一から全てのデータ学習をしなければならず、その点も機械学習の問題点である。

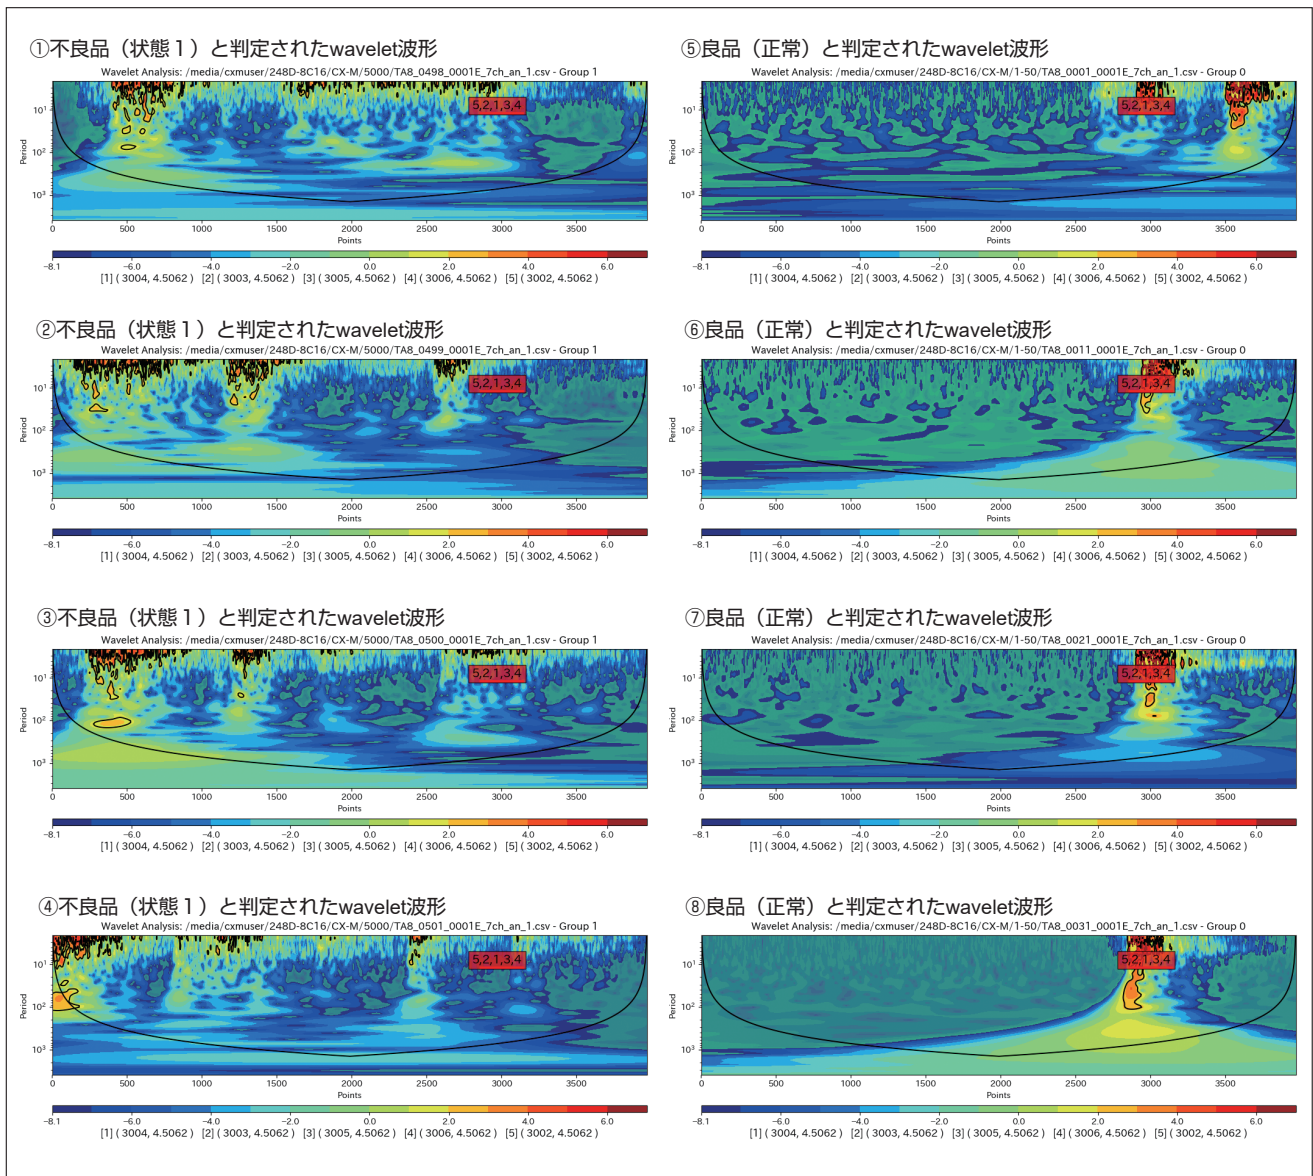


図11 モデルでの良否判定詳細(wavelet)

### 3.2.3 MATLABでの分析

次に推論モデル化するためには、適正なデータ内の特徴量を見つけることができれば精度が大きく向上するのでMathWorks社の数値解析ソフト「MATLAB」で特徴量を見出せないか検討した。

波形をFFT分析(高速フーリエ変換による周波数分析)を行ったが、良好な結果を得ることができなかった。そこでAE波形にRMS(平方根平均二乗レベル)処理を行った。

図12-aの青色の波形がAE波の生波形でありオレンジ色の波形がRMS波形である。RMS波形の図形重心(x,y)では、特徴量を見出せなかった(図12-bの赤印)。しかし、RMS波形の面積においては、切断個数が増えると大きくなる傾向が見られ、RMS波形の面積の標準偏差も大きくなり、平均値も大きくなっていることが分かった。

すなわち切断個数が増えるとAE実効値(RMS波形の面積)も増えることになり切断エネルギーが増加していることになる。この結果は、切断個数が増えると刃物の切れ味が悪くなってきているということになる。




図12-a 切断時のAE波形




図12-b RMS波形の図形重心

### 3.2.4 500個からのモデル化

推論モデル化作成のために富山に本社がある株式会社インテック／先端技術研究所殿の協力を得て特徴量の分析を行い、AE実効値とAE波形における±の符号反転数2つの特徴量により傾向が把握できるとの結果を得た。図13は横軸がAE実効値、縦軸が波形の符号反転数のグラフであり、左から1から1,500回のグラフ、1,501から3,000回のグラフ、3,001から4,500回のグラフである。ある程度集合体に分類できており、切断回数が増えるにしたがいAE実効値と符号反転数も増加する傾向が見られた。AE実効値が高いということは、切断エネルギーが大きいということであり刃物の摩耗などによる影響と考えられる。刃物に微小なダレが発生したとき刃物から60～150kHz程度のAE波が発生するので符号反転数が増えたと考えられる。

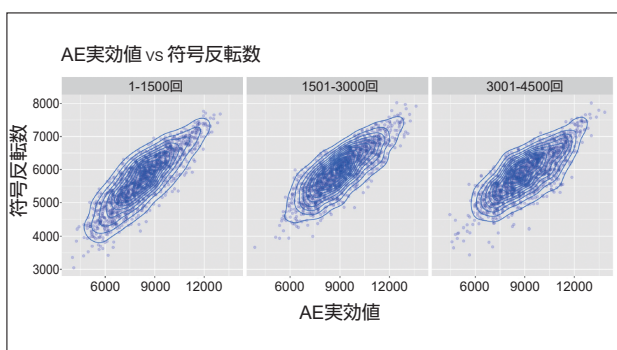


図13 AE実効値と符号反転数のグラフ

「教師なし」学習においては良品であるAE実効値と符号反転数からKDE(カーネル密分布)等高線を求めて、その範囲を基準にしきい値を決め、範囲内なら良品、それ以外であれば不良品の可能性が高いという推論モデル化が作成できた。

切断回数1～500回目の特徴量(AE実効値と符号反転数)を学習データとして推論モデル化を行った。全データ(1～4,500回)を対象に異常スコアを計算するとしきい値を超えた回数は、501～1,500回で0、1,501～3,000回で2回、3,001～4,500回で4回であった。

結果として、AE実効値と符号反転数からの推論モデル化でインプロセス管理が可能と考える。

## 4 まとめと課題

- 1) しきい値を超える回数が増加することで刃物交換の目安になるため、刃物交換が実態に合った交換になる。これにより不良品発生を抑えられ、効率のよいメンテナンスが可能になる。一方で、実運用においては、しきい値の決め方が今後の課題になってくる。
- 2) 今回は測定がAE波形だけであったが、例えば荷重などの他の要素も取り入れて多次元で解析することで、より精度の高い推論モデル化の作成が可能と思われる。また「教師なし」学習は難しく、特徴量が見出せるかどうか大きなポイントである。最近では「教師なし」学習においては、オートエンコーダ(自己符号化器)というニューラルネットワークを利用した方法もあり、現在確認中である。
- 3) 機械で生産される製品は、機械の精度にも大きな影響を及ぼすのでインプロセス管理システムを搭載すれば生産される製品の良否判定と機械本体の故障する前兆も把握でき、予知保全につながると思う。波形そのものやwavelet変換処理して時間軸での比較という手法も行われているが、機械の場合機械部品のバックラッシュや電気部品の応答性の問題があり、測定スタート位置がずれるという要素があるので、今回行ったような時間軸の要素を無くした特徴量で行う推論モデル化が現実的であると考えられる。

## 5 今後

### 5.1 今後の開発

現在、AE波形の測定と他の波形を同時に入力できる8CHの独自のECUを開発中である。AE波は、高い周波数の弾性波であるので測定位置が離れていても測定はできるが、距離が長くなると高い周波数は減衰していくので測定場所とゲインの問題が発生する。そのため開発中のECUでは、ECU側でAE波のゲイン調整機能がある。つまりAEセンサのゲインを調整することが可能で、他のセンサ値やモータ電流などが取込め、8CH同時でも最大10MHzサンプリング周波数のECUである。

また、製作中のサーボプレスに開発中のECUを搭載し、AE波形・サーボ電流値・荷重などのデータを測定し、多次元での解析による推論モデル化を行い検証する予定である(図14)。

最近の傾向としてGPU(Graphics Processing Unit)の発展に伴い、画像による機械学習が主流になってきている。そこで製品や波形処理したグラフを画像処理して機械学習や画像と波形処理を連携させた学習で推論モデル化の作成という手法も検討していく予定である。

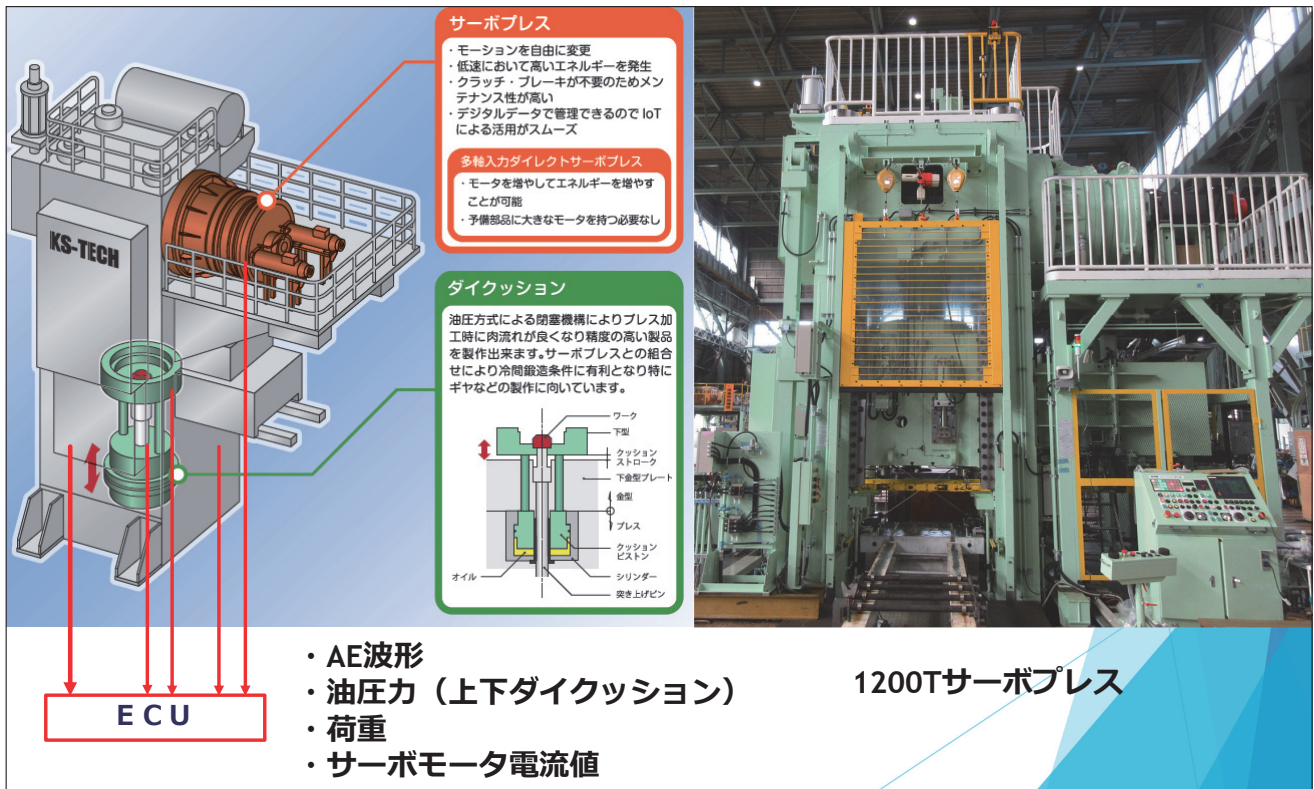


図14 サーボプレス+ECU

## 5.2 今後の展望

IoTすなわちモノからセンシングを通じて得られるデータを情報化し、AI化などにより情報データから今まで感覚でしかできなかったことが、数値化あるいは見える化を行うことができる時代になってきたので、インプロセス管理システムも今後さまざまな業界で発展していくと予想される。

### 謝辞：

当社でインプロセス管理システム開発を行える環境になったのは、IVI (Industrial Value Chain Initiative) のセンサデータ活用技術研究分科会のご協力によるものである。また、実証実験にご協力頂いた川崎鍛工株式会社殿、分析にご協力頂いた株式会社インテック／先端技術研究所の関係者の方々にこの場でお礼を申し上げます。

### 参考文献：

- 1) 精密鍛造素材切断機「MACS」のURL  
<https://premium.ipros.jp/ks-tech/catalog/detail/491283/?hub=165&categoryId=47004>
- 2) 東京エレクトロニクス(株)製CX-MのURL  
<https://www.inrevium.com/product/cxm/>

### 執筆者：

木下裕次

1985年  
 株式会社栗本鐵工所入社  
 鍛压机の設計に従事  
 2016年  
 株式会社ケイエステック  
 代表取締役社長就任

