

プレス加工の不良判別手法に関する研究

鶴谷 知洋, 畑沢 賢一, 神生 直敏

Study on Defect Discrimination Method of Sheet Metal Stamping

Tomohiro TSURUYA, Kenichi HATAZAWA, Naotoshi KAMIO

抄 録

プレス加工は大量生産の方法として広く普及しているが、割れ・しわ等の不良品検査は加工後の検査工程でロット毎に行われることが多く、不良が発生した場合に大量の不良品が生産される可能性がある。そのため、不良品の発生を自動的に検知して瞬時に加工を停止し、不良品対策を行う必要がある。

本研究では、絞り加工を対象に加工中の不良品の発生を金型内で精度良く判別することを目的として、センシング方法と加工状態認識手法についての検討を行い、不良判別技術の確立を試みた。

キーワード：プレス加工, 検査, 絞り加工, 不良判別, センシング

Abstract

The press processing is widely used as a method of mass production. There is a fear that a large number of defectives will be manufactured in case of failure, since products are inspected for defects, such as cracks and wrinkles, in the inspection process by each lots. For that reason, it is necessary to take measures against defectives by detecting them automatically and stopping press processing instantly.

In this study, we aim to discriminate between complete and defective products for drawing process, we examined the methods of sensing and recognition of the processing state, and attempt to establish a defect discrimination method for press processing.

KEY-WORDS : Sheet Metal Stamping, Inspection, Drawing Process, Defect Discrimination, Sensing

1. はじめに

プレス加工は、他の機械加工法と比較して加工速度が大きく低コストであり、量産加工技術として広く普及している。しかし、品質検査は後工程でロット毎に抜き取りで行うことが多く、ロット内の不良を発見できずにそのまま製品を出荷する、あるいは検査工程で不良が発見されるまでの間に大量の不良品が発生する可能性がある。検査工程に進む前に加工工程内で全数の製品の加工状態を認識できれば、不良品の流出や大量発生防止など品質管理面の効果のほか、加工工程と検査工程を含めた工程の自動化も期待でき、メリットは大きい。そのため、加工工程内で加工状態を自動的に認識する試みがなされている。柿木らは、金型内に超音波センサを組

み込み、深絞り加工におけるしわの検知を行っている¹⁾。小山らは、半導体ひずみゲージを金型に組み込み、曲げ加工における曲げ角度の測定を行っている²⁾。西本らは、AE（アコースティックエミッション）の測定により、打抜き加工におけるバリ発生を検知を行っている³⁾。しかし、絞り加工を対象とした金型内での加工状態認識はほとんど行われていない。その理由として、絞り加工は正常な加工の範囲内では材料の分断がなく、割れの発生時も加工部分の一部の分断しか発生しないことから、不良発生時の信号変化が小さいことなどが挙げられる。

本研究では、プレス加工の中でも絞り加工を対象として、微小な信号変化をとらえる金型内センシングと、加工状態の認識率を高めるための学習型認識手法について検討し、不良判別技術の確立を試みた。

事業名：経常研究

課題名：プレス加工の不良判別手法に関する研究

2. 実験方法

2.1 加工条件

本研究の対象である絞り加工は、図1に示すサーボプレス機（アイダエンジニアリング(株)製NC1-800(D)）を用いて行った。サーボプレスの加圧能力は800 kN、ストローク160 mmで、エアダイクッションを備えている。材料はSPCC（板厚1.0 mm）を使用した。ブランク材を図2に、加工品を図3に示す。得られるデータの特徴を把握しやすいよう、加工方法は軸対称形状である円筒絞りを選択した。加工に使用した金型の概略図を図4に、加工条件を表1に示す。ダイクッション圧及び潤滑油の有無を変えることで、正常加工、割れ、フランジしわの3種類の加工状態を得た。



図3 加工品（円筒絞り）



図1 サーボプレス機




図4 金型概略図

表1 加工条件

絞り径	φ 54 mm
ブランク径	φ 110 mm
絞り深さ	37 mm
ダイハイト	310 mm
加工速度	20 SPM
クリアランス	1.2 mm
潤滑油	カータジル 60NEAT

※ SPM : Shots Per Minute (1分間当たりの加工数)




図2 ブランク材

2.2 ひずみの測定

加工中の材料の形状により金型に加わる力が変化すると考えられることから、金型のひずみの測定を行った。ひずみの測定は、材料との接触面積が大きく、かつ金型構造への影響が少ないことから、ダイを測定対象とした。測定にあたり、ダイの材料接触面の反対側に幅8 mm、深さ5 mmの溝を加工し、材料が引き込まれる中央の空間内壁から5 mmの位置にひずみゲージを貼り付けた。貼り付け位置の模式図を図5

に示す。ひずみゲージは(株)共和電業製KFG-2-120-C1を用い、ブリッジボックス、動ひずみ計、アナログ入力デバイスを経てPCにデータを収録した。サンプリングタイムは100 μ s、サンプリング点数は20,000点とした。




図5 ひずみゲージ貼り付け模式図

2.3 AE信号の測定

AE（アコースティックエミッション）は、材料の変形や、亀裂発生の際に弾性波が放出される現象であり、その周波数はおもに10 kHz～数 MHzの超音波領域である。材料の破壊時だけではなく、塑性変形時にも観測されることから、加工状態認識のため、AE信号の測定を行った。AEセンサは(株)エヌエフ回路設計ブロック製AE-901S（共振周波数：70 kHz）を用いた。センサの取付先は、AEをよりの確に測定するため、また、金型構造への影響を小さくするため、材料との接触面積が大きいパンチの組付け先であるパンチプレートに、マグネットホルダにより取り付けた。亀裂進展時のAEは突発型と呼ばれ、単位時間当たりのAE波形発生数（計数率）の観測が一般的であること、また、加工工程内での加工状態認識はリアルタイムの応答が求められるため、処理速度を考慮するとデータ点数の削減が重要であることから、ここではAEの生波形データではなく計数率を使用した。AEセンサからの信号は、AEテストのアンプによる増幅と、100 kHzを閾値とするハイパスフィルタ処理、波数のカウントを行い、計数率として出力した信号を、アナログ入力デバイスを経てPCに収録した。サンプリングタイム及びサンプリング点数は、ひずみ測定と同じ100 μ s、20,000点とした。金型へのセンサ取付位置を図6に示す。

2.4 金型間距離の測定

プレス加工中の下死点における金型間距離は、金型設計時に計算されているが、フランジしわや加工品の割れ部分の食い込みなどの要因で変化する可能性がある。そこで、下死点金型間距離を測定した。上型のベースプレートにレーザ変位

センサをマグネットにより固定し、下死点における上型と下型の距離を測定した。レーザ変位センサはパナソニック(株)製ANL1600Rを使用し、変位データをアナログ入力デバイスを経てPCに収録した。サンプリングタイム及びサンプリング点数は、ひずみ測定、AE測定と同じ100 μ s、20,000点とした。センサの取付位置を図6に示す。




図6 センサ取付位置

2.5 加工状態認識手法

金型内のセンシングデータを用いた加工状態認識は、量産現場での運用を目標としており、外乱の影響が少ないことが求められる。そこで、既知のデータに多く含まれる特徴をもとに加工状態を認識させることで、外乱の影響が小さくなり不良品の判別精度が向上することを期待し、学習型の認識手法を検討した。この手法の有効性を評価するため、既知のデータの平均値を学習データとして入力データとの一致度を計算した。一致度は、学習データと入力データの差分絶対値和により計算した。正常加工、割れ、フランジしわの3種類を認識対象とし、各12個、合計36個のデータを得た。次に3種類の加工状態それぞれ10個ずつのデータの平均値を学習データとし、入力データと正常加工、割れ、フランジしわのそれぞれの学習データの差分絶対値和を計算し、最も小さい差分絶対値和となった学習データの加工状態を、入力データの加工状態と判断した。入力データは36個のデータすべてを使用した。差分絶対値和の計算を式(1)に示す。

$$C_i = \sum_{j=1}^N |X_j - L_{C_j}| \quad (1)$$

X_j ：入力データ

L_{C_j} ：加工状態ごとの学習データ

C_i ：加工状態ごとの差分絶対値和

3. 実験結果と考察

3.1 加工結果

実験で得られた加工品を図7～9に示す。図7の正常加工はダイクッション圧6.25 kNで潤滑油あり、図8の割れはダイクッション圧12.5 kNで潤滑油無し、図9のフランジしわはダイクッション圧1.25 kNで潤滑油ありの加工条件で得た。加工品は各加工状態で12個ずつ、合計36個とした。クッション圧が強い場合及び潤滑不足の場合、材料が伸びきれずに割れが発生し、クッション圧が弱い場合は材料の押さえが効かずダイへの材料流入量が増加することでフランジにしわが発生していると考えられ、一般的な傾向と一致している。



図7 正常加工



図8 割れ



図9 フランジしわ

3.2 ひずみの測定

図10に正常加工のひずみデータ例、図11に割れのひずみデータ例、図12にフランジしわのひずみデータ例を示す。正值は引張ひずみ、負値は圧縮ひずみを表す。正常加工では、0.5 s付近で -8×10^{-6} 程度の小さい圧縮ひずみが検出され、その後大きくなり1.1 s付近で再び小さくなっている。割れでは、0.8 s付近までは正常加工と同様であるが、以後は上昇と下降が複雑に発生している。フランジしわでは、0.6 s付近まではほとんど変化はなく、その後は正常加工と似ているが、圧縮ひずみの値が小さくなる際は、正常加工と異なり一気にゼロへ近づいている。これらのことから、正常加工および割れでの0.5 s付近での小さい圧縮ひずみは、材料がダイの中心部方向に引き込まれる際に、ダイ肩部のRに力加わることにより発生していること、割れの発生時には一度圧縮ひずみは緩和されるが、変形した材料がダイに力を加え、大きな圧縮ひずみとなること、しわが発生する場合は材料押さえ力が弱いためダイ肩部のRに働く力が弱く圧縮ひずみ小さいことなどが推察される。なお、データの特徴が把握しやすい軸対称形状の円筒絞りのひずみデータであれば、単純な閾値により加工状態の判別が可能と考えられる。

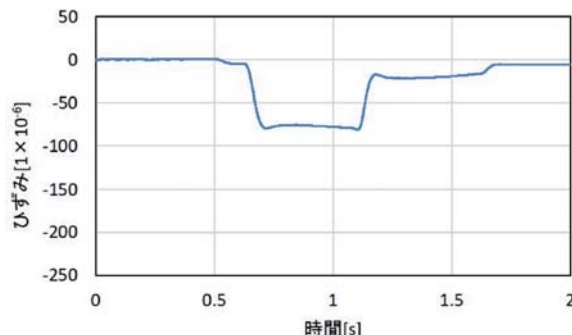


図10 正常加工のひずみデータ例

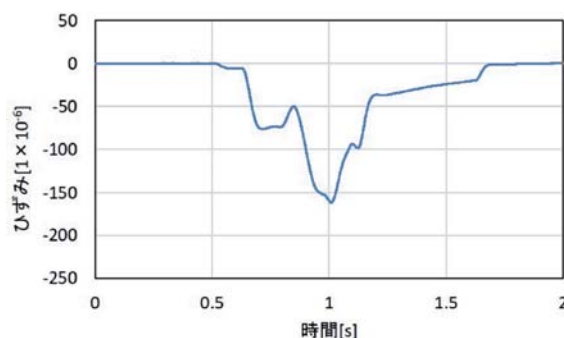


図11 割れのひずみデータ例




図12 フランジしわのひずみデータ例




図15 フランジしわのAEデータ例

3.3 AEの測定

図13に正常加工のAEデータ例、図14に割れのAEデータ例、図15にフランジしわのAEデータ例を示す。それぞれ、0.3s付近及び0.7s付近にピークが確認できる。0.3s付近の最初のピークは上型と材料の接触、0.7s付近の2つ目のピークは加工中の材料の変形により発生したAEである。正常加工の場合は塑性変形、割れの場合は破断、フランジしわの場合は正常加工よりも小さな塑性変形に起因するAEが発生していると考えられる。しかし、AEのピークの大きさや形に違いが見られるものの、単純な閾値による加工状態の認識は困難と思われ、より詳細な認識手法の検討が必要である。




図13 正常加工のAEデータ例

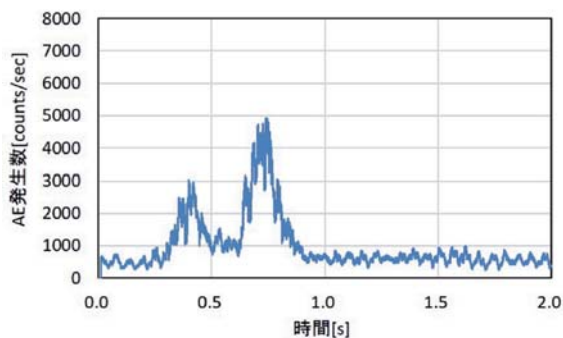


図14 割れのAEデータ例

3.4 金型間距離の測定

下死点における上型と下型の金型間距離について、図16に得られたデータの箱ひげ図を示す。箱ひげ図の箱の部分は、中央値を中心とした全データ数の50%（四分位範囲）を示している。正常加工の四分位範囲はフランジしわ及び割れの四分位範囲と異なっているが、データ全体の存在範囲が重複しているため、加工状態の判別は困難と考えられる。




図16 下死点における上型と下型の金型間距離の箱ひげ図

3.5 加工状態認識

得られたひずみ、AE、金型間距離のデータのうち、加工状態の判別が困難であると考えられる金型間距離以外のデータで加工状態認識実験を行った。正常加工、割れ、フランジしわ、それぞれ12個のデータに対して認識実験を行った結果を表2に示す。ひずみデータを使用した場合、3種類の加工状態すべてにおいて認識率は100%となった。しかしAEデータを使用した場合、正常加工の認識率は90%を超えたが、割れとフランジしわは70%前後であった。AEデータは特徴の差が小さいこと、データの再現性が悪いこと、ノイズの影響を受けやすいことなどが認識率が低い原因と考えられる。そのため、認識率が高かったひずみデータを用いた加工状態認識について、不良判別技術確立に向けたさらなる検討を行うこととした。

表 2 加工状態別認識率

	正常加工	割れ	フランジしわ
ひずみ	100%	100%	100%
AE	92%	75%	67%

4. 金型ひずみセンシングによる角筒絞りの不良判別

不良判別技術の確立に向け、軸対称で特徴が把握しやすい円筒絞りの形状から、より実製品に近い角筒絞りの形状を対象とし、認識手法も差分絶対値に加え機械学習を検討した。材料は円筒絞りと同じSPCCを使用した。ブランク形状を図17に、加工品を図18に、加工条件を表3に示す。




図 17 ブランク形状



図 18 加工品 (角筒絞り)

表 3 加工条件

加工品寸法	80 mm × 60 mm
絞り深さ	48 mm
パンチ	肩部 R 7 mm, コーナー R 7 mm
ダイ	肩部 R 5 mm, コーナー R 10 mm
ダイハイト	320 mm
加工速度	20 SPM
クリアランス	1.2 mm
潤滑油	カータジル 60NEAT

加工状態は、量産現場で発生する状況を想定し、潤滑油量のみを変えることで正常加工と不良を得た。得られた加工品を側面から観察した写真を図19～23に示す。くびれ、亀裂、小割れ、割れの4種類を不良として分類した。



図 19 加工品 (正常加工)



図 20 加工品 (不良: くびれ)



図 21 加工品 (不良: 亀裂)



図 22 加工品 (不良: 小割れ)



図 23 加工品（不良：割れ）

金型ひずみの測定は、円筒絞りと同様にダイの材料接触面の反対側に深さ 5 mm の溝を加工し、材料が引き込まれる中央空間の内壁から 5 mm の位置にひずみゲージを貼り付けた。図 24 にダイのひずみゲージ貼り付けの様子を示す。データ収録のシステム構成は 2.2 節と同じものを使用した。処理速度を考慮し、サンプリングタイムは 500 μ s、サンプリング点数は 4,096 点でデータを収録した。得られたデータを図 25～29 に示す。なお、ノイズ対策のためノイズの周波数から計算した 41 点の移動平均と 20 点おきの間引き処理を行い、204 点に圧縮している。正常加工のデータとくびれのデータは酷似しており単純な閾値での判別が困難であるが、亀裂→小割れ→割れと材料の分断度合いが増すにつれて正常加工との違いが大きくなり、閾値での単純な判別が可能と言える。また、ひずみはいずれの加工状態においても絶対値が 10×10^{-6} 未満であり、微小な変化であることが確認できた。なお、3.2 節のひずみデータと異なる正值であり、金型構造の変更により引張ひずみが検出されている。




図 24 ダイへのひずみゲージ貼り付け




図 25 ひずみデータ（正常加工）




図 26 ひずみデータ（不良：くびれ）




図 27 ひずみデータ（不良：亀裂）




図 28 ひずみデータ（不良：小割れ）




図 29 ひずみデータ (不良：割れ)

ひずみデータを用いて、差分絶対値和による不良判別を試みた。判別は、正常加工のデータ53個、くびれ・亀裂・小割れ・割れからなる不良のデータ44個、合計97個のデータを用意し、それぞれ20個のデータを選んで学習データを作成した。その他の条件は2.4節の内容を用い、判別実験を行った結果、97個のデータに対する認識率は89%であった。加工品によっては正常と不良の境界付近に位置するものがあり、得られるデータが似ているため、単純な手法である差分絶対値和では十分な認識率が得られなかったと考えられる。

次に、認識率の向上を目指し、機械学習による判別を試みた。まず、環境構築が容易で汎用のプログラム言語pythonによる演算処理も利用可能なChainerを用いた機械学習による加工状態認識システムを構築した。Chainerは、(株)Preferred Networks社が提供しているニューラルネットワークの設計・学習・評価を行うオープンソースのフレームワークである。認識システムは、Linux系のOSであるubuntu上に構築した。ネットワークの構成を図30に示す。ChainerはV1を使用し、機械学習の有効性を確認するため、層数は入力層が1、中間層が1、出力層が1の合計3層の最小構成とした。各層間は全結合、入力層のノード数は1加工あたりのデータ点数と同じ204で次元圧縮はせず、出力層のノード数は正常な加工の確率と不良の確率を出力するため2とした。出力層の正常な加工の確率と不良の確率を比較し、確率が大きい方の加工状態を入力データの加工状態と判定した。97個のデータの中からランダムに選んだ7割(68個)を用いて学習モデルを構築し、97個のデータ全てに対して学習モデルを用いた判別実験を行った。学習モデルの最適化手法はAdam、層間の活性化関数はReLUを用いた。Adamは一次微分の勾配法で適用例も多く評価が高い。またReLUは、派生型も含めて適用例が増加しており、認識率が高い。式(2)及び図31で示すように、ReLUは入力値が負であれば0、正であれば入力値を出力する関数である。機械学習による判別実験を行った結果、認識率は96%であった。単純な閾値で判別が困難な特徴を、機械学習により抽出できたことで高い認識率が得られたと考えられる。学習データ数が100程度と少ないにも関わらず高い認識率が得られていることから、データ数の積み上げにより認識率の向上が期待できる。




図 30 ネットワークの構成

$$y = \max(0, x)$$

$$\begin{cases} x : \text{入力} \\ y : \text{出力} \end{cases}$$




図 31 ReLU の出力

5. おわりに

- (1) 円筒の絞り加工を対象に、ひずみ、AE、金型間距離のセンシングを行い、加工状態と得られたデータの関係について精査した結果、ひずみは単純な閾値での判別が可能なこと、AEは認識手法の検討が必要なこと、金型間距離による加工状態の判別は困難なことがわかった。
- (2) 円筒絞りのひずみデータとAEデータにより、学習型認識手法として差分絶対値和を用いた加工状態認識実験を行った結果、ひずみデータでは高い認識率が得られたのに対し、AEデータでは十分な認識率が得られなかった。これは、再現性やノイズが認識率に影響を及ぼしたと考えられる。
- (3) 実製品環境に近い角筒絞りを対象に、差分絶対値和を用いた不良判別実験を行った結果、十分な認識率が得られなかった。そこで、認識率の向上を目指し、機械学習を用いた不良判別実験を行った結果、高い認識率が得ら

れた。これは、加工状態の特徴を抽出できた結果と考えられる。

今後は工程内での不良判別のため、認識に要する時間について検討を進めていきたい。

参考文献

- 1) 柿木亮太・瀬川裕二・丸茂康男他：金属板のプレス成形における超音波を利用したしわ発生状態のインプロセス評価，塑性加工学会誌，Vol.58，No.676，pp.49-53，(2017)
- 2) 小山純一・柳明：金型内蔵マイクロセンシングシステムの開発，塑性加工学会誌，Vol.51，No.596，pp.60-64，(2010)
- 3) 西本重人・新家昇：AE法による打抜き加工のバリ発生評価，非破壊検査，Vol.54，No.10，pp.557-561，(2005)