



Title	機械学習を用いたプレス加工における加工状態認識とバリ高さ推定に関する研究
Author(s)	鶴谷, 知洋
Citation	北海道大学. 博士(工学) 甲第13992号
Issue Date	2020-03-25
DOI	10.14943/doctoral.k13992
Doc URL	http://hdl.handle.net/2115/78299
Type	theses (doctoral)
File Information	Tomohiro_Tsuruya_.pdf



[Instructions for use](#)

機械学習を用いたプレス加工における加工状態認識と
バリ高さ推定に関する研究

Study on forming state recognition and burr height estimation in
press working using machine learning

令和 2 年 3 月

鶴谷 知洋

目次

第1章 序論

1.1	研究背景	1
1.2	加工状態認識に関する従来の研究.....	4
1.3	バリ高さ推定に関する従来の研究.....	6
1.4	本研究の目的および論文の構成.....	8

第2章 機械学習について

2.1	緒言	10
2.2	機械学習の分類.....	11
2.3	機械学習の変遷.....	16
2.4	機械学習の現状.....	16
2.5	機械学習の手法.....	17
2.6	結言	23

第3章 引張試験における AE 測定とデータ解析

3.1	緒言	24
3.2	引張試験	25
3.2.1	試験装置.....	25
3.2.2	試験条件.....	26
3.2.3	試験結果および考察.....	27
3.3	引張試験における AE 測定	28
3.3.1	実験装置.....	28
3.3.2	実験条件.....	31
3.3.3	実験結果および考察.....	31
3.4	測定データの解析.....	35
3.4.1	データ解析方法.....	35
3.4.2	データ解析結果と考察.....	35
3.5	結言	37

第4章 深絞りにおける AE 測定と加工状態認識実験

4.1	緒言	39
4.2	深絞り加工	40
4.2.1	実験装置.....	40
4.2.2	実験条件.....	43

目 次

4.2.3	実験結果および考察.....	45
4.3	深絞りにおける AE 測定	49
4.3.1	実験装置.....	49
4.3.2	実験条件.....	49
4.3.3	実験結果および考察.....	49
4.4	深絞りにおける測定データ解析方法.....	54
4.4.1	データ解析方法.....	54
4.4.2	データ解析結果と考察.....	54
4.5	機械学習による加工状態認識実験.....	56
4.5.1	実験環境.....	56
4.5.2	実験条件.....	57
4.5.3	使用データ.....	60
4.5.4	実験方法.....	60
4.5.5	実験結果と考察.....	61
4.6	結言	71
第 5 章 打抜きにおけるバリ高さ推定実験		
5.1	緒言	72
5.2	打抜き加工	73
5.2.1	実験装置.....	73
5.2.2	実験条件.....	75
5.2.3	実験結果および考察.....	77
5.3	バリ測定	79
5.3.1	測定装置.....	79
5.3.2	測定方法.....	80
5.3.3	測定結果と考察.....	81
5.3.4	残留応力との相関.....	87
5.3.5	金型摩耗との相関.....	90
5.4	打抜きにおけるデータ測定.....	95
5.4.1	実験装置.....	95
5.4.2	実験条件.....	97
5.4.3	実験結果および考察.....	97
5.5	打抜きにおける測定データの解析.....	101
5.5.1	データ解析方法.....	101
5.5.2	データ解析結果と考察.....	101
5.6	機械学習によるバリ高さ推定実験.....	104
5.6.1	実験環境.....	104

5.6.2	実験条件.....	105
5.6.3	使用データ.....	106
5.6.4	実験方法.....	106
5.6.5	実験結果と考察.....	108
5.7	結言	112
第6章 総括		
6.1	結論	113
6.2	展望	116
文献		117
図表一覧		122
謝辞		125

第1章

序論

1.1 研究背景

プレス加工は金型を用いた加工であることから、他の機械加工法と比較して加工速度が大きく、均一な製品を大量に生産できる[1]。加工コストが安く、材料歩留まりも良いため、自動車を中心に電気製品、住宅関連製品、日用品などの分野において量産加工技術として広く普及している。プレス加工における品質検査では、加工速度が大きいことやコスト等の問題から全数検査ではなく、目視検査や治具検査等の抜取り検査で行われるのが一般的である。抜取り検査では全ての製品の検査ができないことから、不良品の見逃しの可能性がある。不良品の発生を見逃した場合、加工速度が大きいことから大量の不良品が継続的に生産される恐れがある。このような不良品の大量発生を防止するには、不良の発生そのものを回避すること、抜取りではなく全数に対して加工中に不良が発生した時点で瞬時に加工を停止することなどが重要である。不良発生そのものの回避のため、プレスモーション制御[2-4]、ブランク保持力制御[5-12]、シミュレーションによる欠陥発生の予測[13-22]などの研究、製品の品質評価[23]、製品の品質予測と成形条件の最適化[24,25]の研究が報告されている。しかし不良の原因は多くの要因が複雑に関係していることから、不良の発生を完全に抑制することは困難であり、不良が発生した時点で瞬時に加工を停止することが理想的である[26]。そのためには加工中の状態を監視するシステムが必要であり、インプロセスで加工状態を認識することが求められる。

インプロセスで加工状態を認識するには、被加工材の状態を直接認識するのが最良であるが、プレス加工は金型内部で行われるため直接のセンシングは困難である。そこで被加工材に接している金型から被加工材の状態に関する情報を得るため、金型のセンシングが行われている[27]。金型のセンシングを行うには金型に直接センサを取り付ける

第1章 序論

ことになるが、取り付けに追加加工が必要な場合は金型の剛性や構造を考慮する必要があり、金型の設計見直しや追加加工によるコスト上昇や金型製作期間の増加が課題となる。

プレス加工はせん断加工、曲げ加工、絞り加工、成形加工、圧縮加工に分類される[1]。絞り加工に分類される深絞りは、カップ形状の物体である缶、シェル、圧力容器など多数の用途がある普及した金属成形法である。深絞りの加工は被加工材の部位により伸びや縮みの方向が異なっており、複雑な応力が発生している。また、製品の品質は材料の特性だけではなく、応力やひずみ、ひずみ速度、温度などにも依存しており[28]、不良は複雑な要因で発生すると言える。深絞りにおける不良は、割れ、しわなどがある。深絞りはシームレスな一体成形物が求められていることから、特に図 1.1 に示すような割れに類する不良は重大であり、不良品の流出は許されない。また打抜きは、切削加工などの加工法と比較して特に加工速度が大きく、多数個取りも可能で大量生産に向くことから、あらゆる分野で使用されている。そのため、不良発生時に瞬時に検知できなければ大量の不良品が生産される恐れがある。打抜きにおける不良品としては、金型摩耗に起因するバリの発生、カス上がりによる 2 枚打ちが原因の圧痕などがあるが、最も影響が大きく、発生頻度が高いのはバリである[29]。不良品の大量発生を防止するためには金型の状態を把握することが有効であるが、金型の構造が複雑で加工中の金型内の状態を判断することは困難である。そのため、金型に起因する不良品の対策として金型の定期的なメンテナンスを行うのが一般的であるが、割れや欠け、急激な摩耗など突発的な金型の不具合の対応ができないほか、過剰な頻度のメンテナンスは生産コストの増加を招く。

近年、機械学習に基づく画像認識技術が急速に発展しており、さまざまな分野に応用され成果が表れている。たとえば、荷重センサによるベッド上の人間の姿勢の認識[30]、超音波によるコウモリの種類の識別[31]、地滑りの空間予測[32]、振動信号を介したスピンドルベアリングの故障診断[33]などの適用例がある。しかし、プレス加工における

加工状態の認識に機械学習を用いた研究はほとんどない[34,35].

プレス加工におけるインプロセスでの加工状態認識において、被加工材の直接的なセンシングではない金型のセンシングによる、複雑な要因で発生する深絞りの割れに類する不良の認識や、主に金型の摩耗に起因する打抜きの変形の認識に、閾値などの単純な手法を適用するには精度に不安がある。そのため、機械学習を用いることにより、深絞りにおける割れ発生の高精度な把握と、打抜きにおける変形高さの高精度な把握が実現できれば、量産加工における品質向上や生産コスト低減に大きく寄与すると考えられる。



Fig. 1.1 Cracked product.

1.2 加工状態認識に関する従来の研究

これまで、プレス加工における加工状態認識に関して、超音波、金型の変形・成形荷重、および AE(Acoustic Emission)を用いた研究が行われている。超音波では、柿木らは超音波探触子を埋め込んだ金型を用いて深絞り加工を行い、フランジしわ発生による加工中の超音波反射特性の変化や、フランジしわ形状と超音波反射特性との関係を調べ、超音波の相対反射強度により深絞り加工で生じるしわのインプロセス検知を行っている[27]。萩野らは、超音波を用いたインプロセス計測システムの構築、超音波の反射・透過特性に対する被加工材の影響の調査、数値シミュレーションを用いた金型・被加工材内における超音波伝播の可視化技術の開発など、超音波を用いてプレス加工における被加工材と金型の接触状態をインプロセスで計測するシステムの開発を行っている[36,37]。Keitmann-Curdes らは超音波の反射波を用いて高反射の鋼板のハイドロフォーミングにおける金型内の材料形状の可視化を行っており、配置がまばらなトランスデューサーから得られた情報を基に高精度な輪郭形状を得ることに成功している[38]。超音波を用いた場合、割れが認識対象となる加工状態ではないこと、センサの取り付け時に金型への追加工が必要であり金型の剛性や製品の加工精度に問題が発生する恐れがあることなどが課題である。

金型の変形・成形荷重では、小山らは、半導体加工技術を利用して複数の半導体ゲージから構成されるマイクロセンサーを製作し、それを金型の適切な箇所に内蔵させた新しいセンシングシステムを提案しており、金型のひずみ測定による曲げ加工時の材料変形抵抗や曲げ角度の測定手法を示している[39]。Garcia らは、金型に組み込んだセンサから得られるパンチ荷重とブランクホルダー荷重、および、カメラで撮像した画像とニューラルネットワークを用いた深絞り加工における割れやしわの有無の検知を行っている[40]。Mahayotsanun らは、材料の引き込み量、金型と材料の接触圧の測定による薄板成形時のオンラインプロセスモニタリングを行っている[41]。金型の変形・成形荷重

を用いた場合、超音波を用いた場合と同様にセンサの取り付け時に金型への追加工が必要であり、金型の剛性や製品の加工精度に問題が発生する恐れがあること、他のセンサとの複合利用が必要であることなどが課題である。

AE では、Behrens らは、AE 信号と割れの相関を分析し、最大振幅や発生数を用いた深絞り加工における割れの発生や潤滑状態、材料の違いの認識を行っている[42]。Yoo らは、加工中の AE 信号の解析により不良の認識に最適な AE 信号処理方法として持続時間を選択し、自動車用パネル成形における割れの検知を行っている[43]。Hao らは、AE 信号により被加工材の変形状態の把握について検討し AE 信号の振幅の二乗平均平方根を用いることでカップ絞りにおける材料の初期の変形状態の監視を行っている[44]。AE 信号を用いた場合、センサの取り付けが容易で金型への追加工が不要であり、材料の変化に応じた有益な情報を含むデータが得られる。しかし、AE 信号はノイズに弱くかつ再現性に問題があること、対象とする信号の周波数が高く特徴を逃さないためには扱うデータ数が膨大となることなどから、データの処理方法と認識率の向上が課題と言える。また、絞り加工を対象とした DC06(SPCC 相当)など延性のある材料の割れの認識が困難とされている。

1.3 バリ高さ推定に関する従来の研究

バリ高さ推定について、AE 測定、加工後の製品のバリ測定、有限要素法を用いた研究が行われている。AE 測定では、西本らはバリの発生により放出される AE の特徴を明らかにし、バリ発生検知装置の製作と実機試験により AE 信号の最大振幅を用いた打抜き加工におけるバリ発生の検知を行っている[29]。村尾らは、AE 波形の包絡線から算出した面積とバリ高さの相関を検証し、試作したシステムを用いた生産ラインでの実証試験によりバリ高さ推定の有効性を確認している[45]。AE 信号を用いた場合、加工状態の認識の場合と同様にセンサの取り付けが容易で金型への追加工が不要である。しかし、AE 信号はノイズに弱くかつ再現性に問題があること、対象とする信号の周波数が高く特徴を逃さないためには扱うデータ数が膨大となることなどから、データの処理方法が課題と言える。また、対象とするブランク形状が円であることから、実際の製品で想定される非線対称形状が対象ではないことも課題と言える。製品の測定では、徳永らは、空間周波数フィルタリングによる寸法およびバリのインライン計測・検査方法を提案し、その有効性を示している[46]。

加工後の製品のバリ測定における課題として、プレス加工ラインは油性、水性を問わず潤滑剤が使用されていることから、インラインでの処理速度や後工程での防錆効果などを考慮すると測定前の洗浄は困難であり、潤滑剤が物理的な測定に影響を及ぼす可能性が高く、ロバストな測定が困難なことが挙げられる。

有限要素法では、Al-Momani らは、実験計画法により導出した最適パラメータと有限要素法によりバリ高さを推定している[47]。Celik らは、ニューラルネットワークを用いて、真鍮を対象に荷重やクリアランスからバリ高さを推定している[34]。Hambli は、有限要素法で得られる情報とニューラルネットワークを用いて、クリアランスからバリ高さを推定している[35]。また、工具摩耗を考慮した有限要素法によるバリ高さの推定とソフトウェアの開発も行っている[48,49]。Hatanaka らは、開発した剛塑性有限要素コー

ドを用いてバリ高さを推定している[50]. Rachik らは, ALE (Arbitrary Lagrangian and Eularian) 法に基づいた有限要素法により, パンチ荷重やバリ高さを推定している[51]. 有限要素法を用いた場合, 推定時のクリアランスが既知である必要や, 工具摩耗などでクリアランスが変化した場合を考慮していても, 対象とするブランク形状が円であり, 実際の製品で想定される非線対称形状が対象ではないことが課題と言える.

1.4 本研究の目的および論文の構成

本論文の目的は、大きく分けて2つある。1つ目は、深絞り加工を対象として、加工中の金型のデータ測定により、割れに類する不良の発生をインプロセスで認識する手法を検討し、プレス加工工程の自動化や低コスト化、製品品質向上に繋げることである。2つ目は、打抜き加工を対象として、加工中の金型のデータ測定により、製品のバリ高さを推定する手法を検討し、金型メンテナンスにおける回数やコストの低減、製品品質向上に繋げることである。

深絞り加工を対象とした加工状態の認識では、金型のセンシングを行うにあたり、金型構造に影響を与えず、単一のセンサで割れの認識ができ、かつ延性のある被加工材を対象とした研究はほとんどない。本研究では、センサの取り付けが簡便で金型構造に影響を与えない AE を測定対象とし、データ処理速度向上につながる AE 特徴量の選択と、ノイズおよび再現性の課題をクリアするため機械学習を用いて、延性のある SPCC の深絞り加工における加工状態認識を行う。

打抜き加工を対象とした製品のバリ高さ推定では、複数の測定データを多次元的に用いた推定精度向上や、ブランク形状として非線対称形状を対象にした研究はほとんどない。本研究では、金型のデータ測定対象として AE、加工荷重、ひずみの3種類を用い、複数のコーナ部を有する非線対称形状をブランク形状とし、機械学習により多次元データからバリ高さ推定を行う。

本論文は、全6章で構成されており、以下に各章の概要を述べる。

第1章では、本研究の背景と近年の研究動向、本研究の目的および本論文の構成について述べる。プレス加工工程の自動化や低コスト化、製品品質の向上のため、深絞りにおける加工状態認識と、打抜きにおけるバリ高さ推定における課題を示し、本論文の目

的を明確にする.

第2章では, 本研究で適用する機械学習について, 分類と特徴, これまでの変遷, 現在の状況, 手法の概要について述べる.

第3章では, 引張試験における AE を測定し, 応力ひずみ線図と得られた AE 信号から, 塑性変形時および破断時の波形データと周波数領域の特徴について明らかにするとともに, 試験片の状態判別の可能性について検討する.

第4章では, 深絞りにおける AE を測定し, 得られた AE 信号から波形データと周波数領域の特徴を明らかにし, 引張試験時の特徴と比較する. また, 引張試験と深絞りの AE データの比較結果を基に, 機械学習を用いた深絞りにおける加工状態認識実験を行い, その有効性を示す.

第5章では, 打抜きにおける AE, 加工荷重, ひずみのデータ測定と製品のバリ高さを測定し, ショット数の増加と測定データおよびバリ高さについて分析する. また, 測定データとバリ高さの分析結果を基に機械学習を用いた打抜きにおけるバリ高さ推定実験を行い, その有効性を示す.

第6章では, 全体の総括と本研究により得られた結論について述べる.

第2章

機械学習について

2.1 緒言

近年、機械学習が注目され、その適用事例が増加している。特に人工知能を支える技術として機械学習が用いられ、工業のみならず、医療、農業、水産業、林業、金融、ゲームなど適用分野は非常に広い。機械学習の適用事例が増加している背景として、オープンソースのフレームワークの存在、プログラムの直接的な記述が不要なGUI(Graphical User Interface)ツールの存在、高機能なハードウェアの価格下落など、開発環境が充実していることもその理由として挙げられる。開発の敷居が下がったことで、機械学習の適用が広がり、その広がりがさらなる広がりを生んでいる。本章では、機械学習について、分類と特徴、これまでの変遷、現在の状況、手法について述べる。

2.2 機械学習の分類

機械学習は人工知能に包含される技術であり、機械学習もまた複数のアルゴリズムを包含している。機械学習は次の8種類に分類される[52]。

1) 教師あり学習

教師あり学習は、教師となる正解データを与える必要があるアルゴリズムである。入力データセットは正解ラベルと紐づけられて対になり、学習に用いる学習データセットと評価に用いるテストデータセットに分けられる。学習データセットには、予測または分類が必要な出力変数がある。学習データセットからある種のパターンを学習し、予測または分類のためテストデータセットに適用し評価する。教師あり学習のアルゴリズムのうち、主要な3種類について下記に述べる。

i) 決定木

決定木とは、値に基づいて属性を並べ替えることにより属性をグループ化するツリーである。決定木は主に分類の目的で使用される。各ツリーはノードとブランチで構成され、各ノードは分類されるグループ内の属性を表す。各ブランチはノードが取ることができる値を表す。

ii) 単純ベイズ

単純ベイズは主にテキスト分類を対象とし、クラスタリングと分類の目的で使用されることが多い。単純ベイズの基礎となるモデルは条件付き確率に依存しており、発生する確率に基づいてツリーを作成する。これらのツリーはベイジアンネットワークとも呼ばれる。

第2章 機械学習について

iii) サポートベクターマシン

サポートベクターマシン (SVM) は主に分類に使用される。SVM はマージン最大化の原理で動作し、クラス間に識別線を描画する。識別線はクラス間のマージンが最大になるように描画されるため、分類誤差が最小限に抑えられる。

2) 教師なし学習

教師なし学習は、正解ラベルを用いず、わずかな特徴をデータから学習するアルゴリズムである。新しいデータに対して、それまで学習した特徴によりそのデータのクラスを認識する。主にクラスタリングと特徴量の削減に使用される。教師なし学習のアルゴリズムのうち、主要な2種類について下記に述べる。

i) k 平均法

k 平均法は、開始時に自動的にランダムなクラスタリングを行う。各クラスタの値の平均をそのクラスタの中心とし、同様の特性を持つ点を同じクラスタに配置していくことを繰り返す。このアルゴリズムは、k 個の異なるクラスタを作成するため k 平均法と呼ばれる。

ii) 主成分分析

主成分分析はデータの次元を削減するため、計算がより高速かつ簡単になる。2D データの場合、グラフにプロットされているときは2つの軸を占有するが、主成分分析がデータに適用されるとデータは 1D になる。

3) 半教師あり学習

半教師あり学習は、教師あり学習と教師なし学習の両方の機能を組み合わせた手法である。正解ラベルが紐づけされていないデータが既に存在し、正解ラベルが紐づけされたデータを取得するのが困難な、機械学習とデータマイニングの分野において有効である。半教師あり学習には多くのカテゴリがあり、以下にその一部を述べる。

i) 生成モデル

生成モデルは、最も古い半教師あり学習方法の1つである。正解ラベルの紐づけがあるデータとないデータの混合データの学習により識別ができる。混合データにおける正解ラベルの紐づけがあるデータとないデータの割合としては、正解ラベルの紐づけがされたデータが1つ以上であれば学習ができる。構造は以下の式で定義される。 $p(x|y)$ は混合ガウスモデルである。

$$p(x,y) = p(y) p(x|y) \quad (2.1)$$

ii) 自己学習

自己学習では、初めに正解ラベルと紐づけがあるデータの一部で学習を行う。次に正解ラベルの紐づけがないデータが与えられる。正解ラベルの紐づけがないデータと予測された正解ラベルがセットになり、学習セットデータとして追加される。この一連の処理の繰り返しにより学習が進む。

iii) トランスダクティブ SVM

トランスダクティブ SVM (TSVM)は、機能を拡張した SVM である。TSVM では、正解ラベルの紐づけがあるデータとないデータの両方が考慮される。正解ラベ

第2章 機械学習について

ルの紐づけがあるデータとないデータとの間のマージンが最大になるように、正解ラベルの紐づけがないデータにラベルを付ける

4) 強化学習

強化学習は、より良い結果が得られるにはどの行動をとるのが良いかに基づいて決定を下すタイプの学習である。学習者は環境が与えられるまでどの行動をとるべきかを知らない。学習者がとる行動は環境に影響を与える可能性がある。環境から、現在の状態、状態遷移、および入力関数を受け取り、これらの入力に基づいてより良い結果が得られる行動を決定し実行する。

5) マルチタスク学習

マルチタスク学習は、他の学習器のパフォーマンスを向上させるという単純な目標を持つ。マルチタスク学習のアルゴリズムがタスクに適用されると、問題をどのように解決したか、または特定の結論に至るまでの手順を覚える。次に、アルゴリズムはこれらの手順を使用して、他の同様の問題またはタスクの解決策を見つける。これは転移学習と呼ばれる。学習器が互いの学習経験を共有している場合に同時学習が可能となる。

6) アンサンブル学習

様々な学習器を組み合わせて1つの学習器を形成する場合、その学習はアンサンブル学習と呼ばれる。個々の学習器としては、単純ベイズ、決定木、ニューラルネットワークなどがある。アンサンブル学習は1990年代から注目されており、学習器の集合は個々の学習器よりも常に優れていることが確認されている。代表的な2つの手法を以下に述べる。

i) ブースティング

ブースティングはバイアスと分散を減らすために使用される。ブースティングは、弱い学習器の集合を作成し、それらを1つの強い学習器にする。弱い学習器とは真の分類結果とほとんど相関しない分類器である。強い学習器はと真の分類と強く相関する分類器である。

ii) バギング

機械学習アルゴリズムの精度と安定性を高める必要がある場合、バギングが適用される。バギングは分類と回帰に適用できる。バギングは分散を減らし、過学習の対策に役立つ。

7) ニューラルネットワーク

ニューラルネットワークは、ニューロンの生物学的概念に由来する。ニューロンは、脳の構造のような細胞であり、樹状突起、核、細胞体、軸索の主に4つの部分からなる。樹状突起は電気信号を受け取り、細胞体は電気信号を処理する。樹状突起が受け取った電気信号は細胞体から軸索を通り次のニューロンに運ばれる。核はニューロンの心臓部である。ニューロンの相互接続はニューラルネットワークと呼ばれ、電気信号が脳の周りを移動している。人工ニューラルネットワークも同じように動作し、3種類の層で構成されている。樹状突起に似ている入力層は入力を受け取り、隠れ層は細胞体や軸索のように入力を処理する。出力層は樹状突起のように演算結果を出力する。

8) 事例ベース学習

事例ベース学習では、学習器はあるパターンを学習し、新しいデータに同じパターンの適用を試みる。事例ベース学習は、テストデータが到着してから学習データと一緒に

処理を行う怠惰な学習器と言える。学習アルゴリズムの複雑さは、データのサイズとともに増加する。事例ベース学習としては、最近傍法が良く知られている。

2.3 機械学習の変遷

機械学習は人工知能の一分野であり、その中でも特に学習に焦点を合わせた方法論である[53]。機械学習は、1950年代に Hebb 則で学習するニューラルネットワークや、現在でも使用されているパーセプトロンが提案され、第1次ニューラルネットワークブームが起こった。同時期に線形の SVM も提案されているが、線形学習器の限界が指摘されブームが終焉している。1980年代に入り、誤差逆伝播法の再発見により深層学習が実現され、第2次ニューラルネットワークブームが起こった。しかし、深層学習は定式化されず局所最適解しか得られない課題があり、カーネル法による SVM が提案された。1990年代から2000年代にかけて、データから学習する統計的学習が発展し、ビッグデータの解析に機械学習が用いられるようになった。また、規模の大きなデータに対して高速な学習を実現させるための確率的最適化手法も発展した。一方で深層学習の研究も継続されていたがメインストリームから外れていた。しかし畳み込みネットワークを用いたことで大幅に精度が向上し、第3次ニューラルネットワークブームが起こり現在に至っている。

2.4 機械学習の現状

機械学習において、現在に至る2010年代は深層学習が注目されている[54]。深層学習の特徴は、既存のニューラルネットと比べて層数が多いことである。超多層のニューラルネットはその学習が困難と考えられていたためこれまで用いられてこなかった。しかし、超多層の方が実際には学習が容易であり、またその実験的な予測精度も優れている

ことが発見された。その他、ネットワーク内で行う処理や、新たな活性化関数、最適化関数の改良などにより、超多層なネットワークを扱えるようになっている。さらに、GPUと呼ばれる元来はコンピュータグラフィックス用に開発された装置を数値計算に利用する GPGPU が急速に広まっており、反復計算の多い深層学習には欠かせないものとなっている。最近の機械学習の応用分野として、コンピュータープログラミング、チェスなどのゲームプレイ、画像認識、音声認識、医療診断、農業、物理学、メール管理、ロボティクス、音楽、数学、自然言語処理などが示されている。しかし、機械学習の応用および研究はいまだ未熟であり、多くの問題をさらに研究し解決する必要がある[55]。学習アルゴリズムはいくつかの古典的なアルゴリズムからの選択が多く、アルゴリズム同士の比較分析と新しいアルゴリズムの提案が不足している。さらに、現在の研究はほとんどが既に収集されたデータを用いており、サンプリングの問題を考慮することがほとんどない。データセットが大きすぎる場合、データを収集して処理するため非常に多くの時間が必要となる。今後は、既存アルゴリズムの最適な組み合わせ、新規アルゴリズム、データサンプリング手法についての提案が重要と言える。

2.5 機械学習の手法

機械学習において、近年大幅に認識精度が向上し適用範囲が広がっている多層ニューラルネットワーク[56]について述べる。深層学習（ディープラーニング）は多層ニューラルネットワークであり、神経細胞であるニューロンをモデル化したユニットを層状に並べ、層間に結合を持たせたものである。ユニットの入出力を図 2.1 に示す。ユニットは複数の入力を受け取り、1つの出力を計算する。入力が4つの場合、ユニットが受け取る総入力 u は、各入力にそれぞれ異なる重み w_1, w_2, w_3, w_4 をかけたものを全て加算し、これにバイアスと呼ばれる1つの値 b を足したものとなる（式 2.2）。ユニットの出力 z は総入力 u に対する関数 f の出力である（式 2.3）。

$$u = w_1x_1 + w_2x_2 + w_3x_3 + w_4x_4 + b \quad (2.2)$$

$$z = f(u) \quad (2.3)$$

この関数 f は、活性化関数と呼ばれる。

次に、ユニットを重ねた2層のニューラルネットワークを図2.2に示す。3つのユニットが受け取る入力はそれぞれ式2.4、式2.5、式2.6のように計算される。

$$u_1 = w_{11}x_1 + w_{12}x_2 + w_{13}x_3 + w_{14}x_4 + b_1 \quad (2.4)$$

$$u_2 = w_{21}x_1 + w_{22}x_2 + w_{23}x_3 + w_{24}x_4 + b_2 \quad (2.5)$$

$$u_3 = w_{31}x_1 + w_{32}x_2 + w_{33}x_3 + w_{34}x_4 + b_3 \quad (2.6)$$

第1層のユニットを $i = 1, \dots, I$ 、第2層のユニットを $j = 1, \dots, J$ で表すと、第1層のユニットの出力から第2層のユニットの出力が決まるまでの計算は、式2.7および式2.8のように一般化される。

$$u_j = \sum_{i=1}^I w_{ji}x_i + b_j \quad (2.7)$$

$$z_j = f(u_j) \quad (2.8)$$

下記のようにベクトルと行列を定義すると、式2.7および式2.8は、式2.9および式2.10のように表現することもできる。

$$\mathbf{u} = \begin{bmatrix} u_1 \\ \vdots \\ u_j \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_l \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} b_1 \\ \vdots \\ b_j \end{bmatrix}, \quad \mathbf{z} = \begin{bmatrix} z_1 \\ \vdots \\ z_j \end{bmatrix},$$

$$\mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1l} \\ \vdots & \ddots & \vdots \\ w_{j1} & \cdots & w_{jl} \end{bmatrix}, \quad \mathbf{f}(\mathbf{u}) = \begin{bmatrix} f(u_1) \\ \vdots \\ f(u_j) \end{bmatrix}$$

$$\mathbf{u} = \mathbf{W}\mathbf{x} + \mathbf{b} \tag{2.9}$$

$$\mathbf{z} = \mathbf{f}(\mathbf{u}) \tag{2.10}$$

さらにユニットを重ね、3層からなる多層構造にしたニューラルネットワークの例を図2.3に示す。情報は左から右へ一方向に伝わり、この順に各層を $l=1,2,3$ で表す。なお、 $l=1$ を入力層、 $l=2$ を隠れ層、 $l=3$ を出力層と呼ぶ。 $l=2$ の隠れ層のユニットの出力は式2.11および式2.12のように計算される。右肩の括弧内番号は層の番号 (l) を表す。

$$\mathbf{u}^{(2)} = \mathbf{W}^{(2)}\mathbf{x} + \mathbf{b}^{(2)} \tag{2.11}$$

$$\mathbf{z}^{(2)} = \mathbf{f}(\mathbf{u}^{(2)}) \tag{2.12}$$

同様に、 $l=3$ の出力層のユニットの出力は \mathbf{x} を隠れ層の出力 $\mathbf{z}^{(2)}$ に置き換えることで、式2.13および式2.14のように計算される。

$$\mathbf{u}^{(3)} = \mathbf{W}^{(3)}\mathbf{z}^{(2)} + \mathbf{b}^{(3)} \tag{2.13}$$

$$\mathbf{z}^{(3)} = \mathbf{f}(\mathbf{u}^{(3)}) \tag{2.14}$$

以上から、任意の層数 L のネットワークに一般化すると、層 $l+1$ のユニットの出力 $\mathbf{z}^{(l+1)}$ は、1つ下の層 l のユニットの出力 $\mathbf{z}^{(l)}$ から式 2.15 および式 2.16 のように計算される。

$$\mathbf{u}^{(l+1)} = \mathbf{W}^{(l+1)}\mathbf{z}^{(l)} + \mathbf{b}^{(l+1)} \quad (2.15)$$

$$\mathbf{z}^{(l+1)} = \mathbf{f}(\mathbf{u}^{(l+1)}) \quad (2.16)$$

したがって、ネットワークに対する入力 \mathbf{x} が与えられた時、各層の出力を順に決定していくことができ、最終的な出力は式 2.17 で表すことができる。

$$\mathbf{y} \equiv \mathbf{z}^{(L)} \quad (2.17)$$

ネットワークが表現する関数は、パラメータ w を変えると変化する。良い w を選ぶことでネットワークが望みの関数を与えるようになる。関数の入力と出力のペアが複数与えられた時、1つの入力 x に対する望ましい出力を d と書くと $\{(x_1, d_1), (x_2, d_2), \dots, (x_n, d_n)\}$ が与えられる。ペア1つずつを学習サンプルと呼び、集合を学習データと呼ぶ。どのペアに対しても入力 x_n の時のネットワークの出力が d_n に近くなるよう w を調整することを学習と呼ぶ。このとき、ネットワークが表す関数と学習データの近さの尺度のことを誤差関数と呼ぶ。誤差関数は、回帰やクラス分類などネットワークの目的に応じて選択する。

学習のゴールは、選択した誤差関数に対して最小値を与える w を求めることであるが、誤差関数は一般的に凸関数ではなく、大域的な最小解を直接得るのはほぼ不可能である。そこで、代わりに局所的な極小点求める手法が最適化手法である。




Fig. 2.1 One unit input / output.




Fig. 2.2 Neural network of 2-layers.




Fig. 2.3 Neural network of 3-layers.

2.6 結言

本章では、機械学習について、分類と特徴、これまでの変遷、現在の状況、手法について述べた。AI の適用範囲拡大に伴い機械学習の適用も広がっており、手法の改良や提案も活発になされ、適用結果の向上も著しい。短時間で材料や金型の状況が変化し、複雑な状態の中で加工が行われるプレス加工において、加工状態認識やバリ高さ推定に機械学習を適用することで精度の向上が期待できる。

第3章

引張試験における AE 測定とデータ解析

3.1 緒言

プレス加工における品質検査では、加工速度が大きいことやコスト等の問題から全数検査ではなく、抜取り検査で行われるのが一般的である。不良品の発生を見逃した場合、加工速度が大きいことから大量の不良品が継続的に生産される恐れがある。このような不良品の大量発生を防止するには、抜取り検査ではなく全数を対象として、加工中に不良が発生した時点で瞬時に加工を停止することが重要である。このような製品品質向上と、工程の自動化および低コスト化などを目的として、インプロセスで加工状態を認識することが求められている。特に深絞り加工で発生する割れに類する不良を認識することは、深絞りの製品で求められるシームレスな一体成形物の機能を確保する上からも重要である。割れは被加工材が塑性変形中に一部が破断したものであり、物体が変形あるいは破断した際に AE が発生することは良く知られている。

本章では、材料に AE センサを取り付けて引張試験を行い、応力ピーク付近での塑性変形時と破断時の AE 信号を測定し、得られたデータについて解析した。この実験により塑性変形時と破断時の AE 信号の特徴を把握し、次章で行う深絞りにおける AE 信号の測定と解析結果から得られる特徴と比較することで、加工状態の認識における AE の有効性を検証する。

3.2 引張試験

3.2.1 試験装置

使用した万能材料試験機 AG-100kNXplus（株式会社 島津製作所）を図 3.1 に示す。測定対象の AE は 0.1~1MHz の高周波領域の信号であることから[57]，AE 信号と引張試験中の材料の状態を比較するためには，応力とひずみの状況を高い分解能で把握する必要があり，超高速サンプリングが可能な本機を選定した。



Fig. 3.1 Tensile testing machine.

3.2.2 試験条件

本試験で使用した試験片形状を図 3.2 に示す。材質は SPCC (公称板厚 1.0 mm)、サイズは AE センサを直接取り付けるためセンサのホルダサイズにあわせて短冊状の $40 \times 300 \times t_{1.0}$ とした。試験速度は 30 mm/min で行い、サンプリングタイム 0.01 sec にてストロークと試験力を収録した。弾性変形時、初期塑性変形時、応力ピーク付近での塑性変形時および破断時の AE 信号を測定するため、試験は一般的な引張試験と同様に破断まで行った。



Fig. 3.2 Geometry of tensile test specimen.

3.2.3 試験結果および考察

試験により得られた応力-ひずみ関係を図 3.3 に示す。縦軸は公称応力、横軸は公称ひずみである。試験片である SPCC は冷間圧延材であることから上降伏点と下降伏点の差が小さく、降伏点伸びも小さい。なお、最大応力は 298 MPa であった。本試験の応力-ひずみ関係において、応力ピーク付近での塑性変形時および破断時が明確に区別できることから、塑性変形時と破断時の AE 信号を測定できることが確認できた。次節にて引張試験における AE 測定を行い、材料の状態と AE 信号の関係について明らかにする。

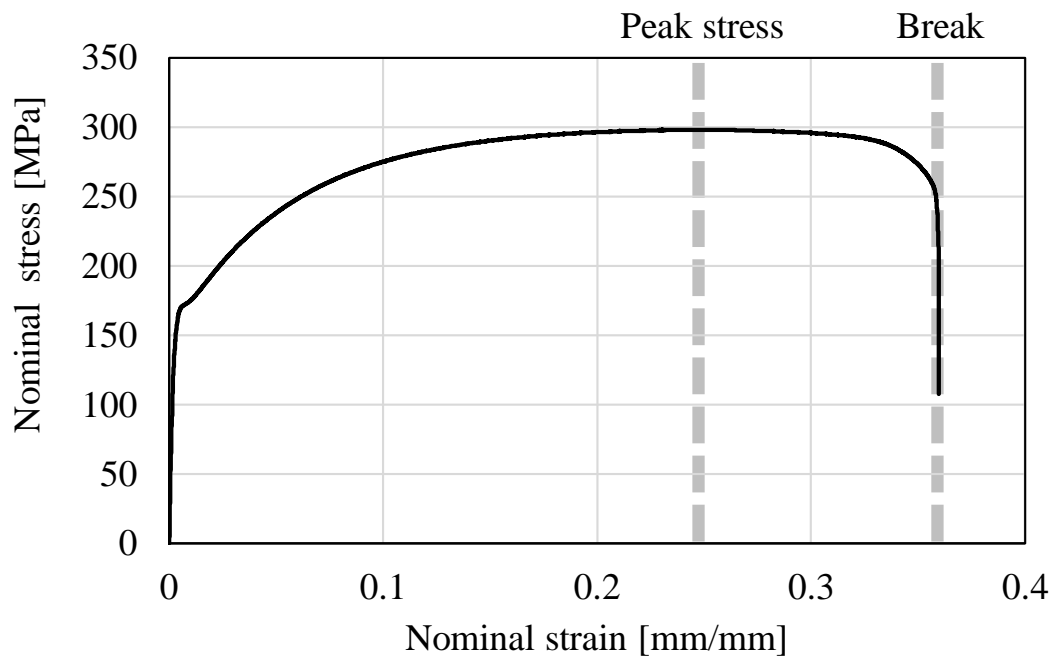


Fig. 3.3 Stress-strain relationships obtained from tensile tests.

3.3 引張試験における AE 測定

3.3.1 実験装置

AE 信号の測定にあたり，AE センサは引張試験機の可動する上部ではなく，静止したままの下部のチャック付近の試験片表面に，マグネットホルダにより取り付けられた．AE 信号は，テストとアナログ入力デバイスを経由して PC に収録した．AE 信号をそのまま扱うには 1 加工当たりのデータ数が多いこと，インプロセスでは高速な処理が求められることから，AE 信号の測定のほか，破断時の AE 信号で観測される波形の特徴に対する使用パラメータとして一般的な単位時間当たりの AE 波形の発生数をカウントしたデータ(カウントレート)を測定した[58]．実験装置の概要を図 3.4 に，AE 信号測定システムの概要を図 3.5 に示す．AE センサは AE-901S (株式会社 エヌエフ回路設計ブロック)，AE テスタは AE9501A (株式会社 エヌエフ回路設計ブロック) を用いた．またアナログ入力デバイスとして，AE 信号の測定に AI-1204Z-PCI (株式会社 コンテック)，カウントレートの測定に AIO-121602LN-USB (株式会社 コンテック) を使用した．




Fig. 3.4 Experimental set-up to analyze and measure the AE.

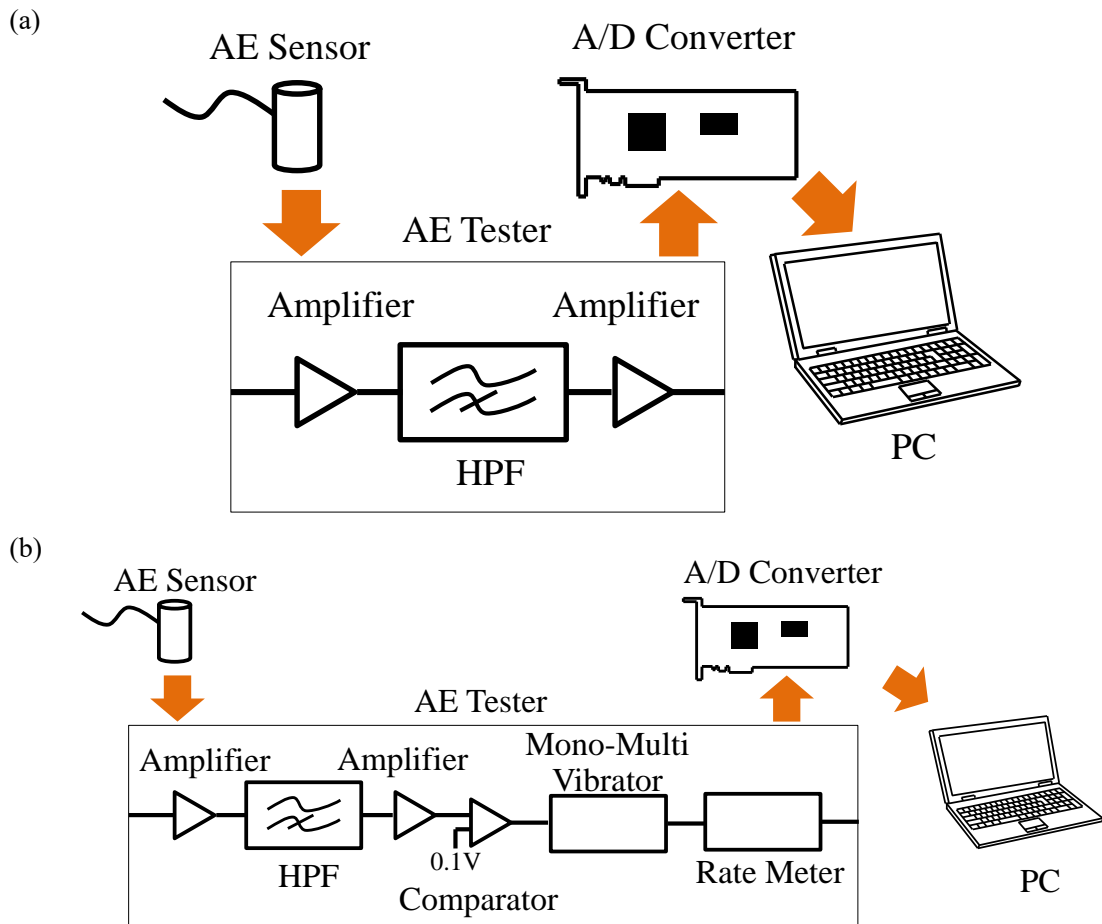


Fig. 3.5 Schematic illustration of the data acquisition system for AE.

(a)For waveform of AE signals. (b)For count rate of AE signals.

3.3.2 実験条件

AE センサは共振周波数 70kHz のものを用いた。使用した AE センサの周波数特性を図 3.6 に示す。信号は 70kHz で最も減衰が小さくなるが、測定対象となる範囲は 30Hz から 1000kHz である。AE 信号は、AE テスタで入力信号の 20 倍のゲインの増幅と 100 kHz を閾値とするハイパスフィルタ処理を行い、サンプリングタイム 3 μ sec にて PC にデータを収録した。カウントレートは、AE テスタで入力信号を 20 倍のゲインの増幅と 100 kHz を閾値とするハイパスフィルタ処理を行った後、0.1 V を閾値としてカウントレートをコンパレータによってカウントし、サンプリングタイム 10 msec にて PC にデータを収録した。

3.3.3 実験結果および考察

5 回の引張試験で得られたネッキング直前の応力ピーク周辺の塑性変形時および破断発生時に得られた AE 信号の例を図 3.7 に示す。縦軸は出力電圧、横軸は時間である。図 3.7 (a) は応力ピーク周辺の塑性変形時に得られた AE 信号であり、応力がピークに達する 6 msec 付近において 3mV 程度のわずかな振幅の増加が発生している。図 3.7 (b) は破断発生時に得られた AE 信号であり、対照的に破断発生の前後である 2.5 msec から 5 msec の間に、約 1000 mV の非常に大きく急激な振幅の増加が発生している。5 回の引張試験ではそれぞれ同様の傾向が確認できた。過去の研究報告の通り [59]、塑性変形時に観測される AE 信号は連続型 AE が支配的であり、き裂が進展する破断発生時に観測される AE 信号は突発型 AE が多いことが確認できた。

次に、引張試験中の全範囲と応力ピーク周辺の塑性変形時、および、破断発生時に得られたカウントレートのデータを図 3.8 に示す。図 3.8 (a) の縦軸はカウントレート、横軸は公称ひずみである。図 3.8 (a) は引張試験中の全範囲で得られたカウントレートであり、弾性変形から塑性変形への移行時のカウントレートが比較的大きく、応力のピ

ーク付近で小さくなり、破断時に再び大きくなっている。図 3.8 (b) および(c)の縦軸はカウントレート、横軸は時間である。図 3.8 (b) は図 3.8 (a) の応力ピーク周辺の塑性変形時に得られたカウントレートであり、多くのピークが存在している。図 3.8 (c) は図 3.8 (a) の破断発生時に得られたカウントレートであり、大きなピークが1つだけ存在している。AE 信号は、塑性変形中に継続的に発生し、破断時に集中的に発生する。AE 信号と同様に、カウントレートにおいても塑性変形時に観測される AE 信号は連続型 AE が支配的であり、き裂が進展する破断発生時に観測される AE 信号は突発型 AE が多いことが確認できた。プレス加工で多用される SPCC においても、塑性変形時と破断時でそれぞれ連続型 AE, 突発型 AE という異なる特徴を持つ AE 信号が観測されたことから、AE 信号による加工状態認識の可能性が示された。




Fig. 3.6 Frequency response curve.

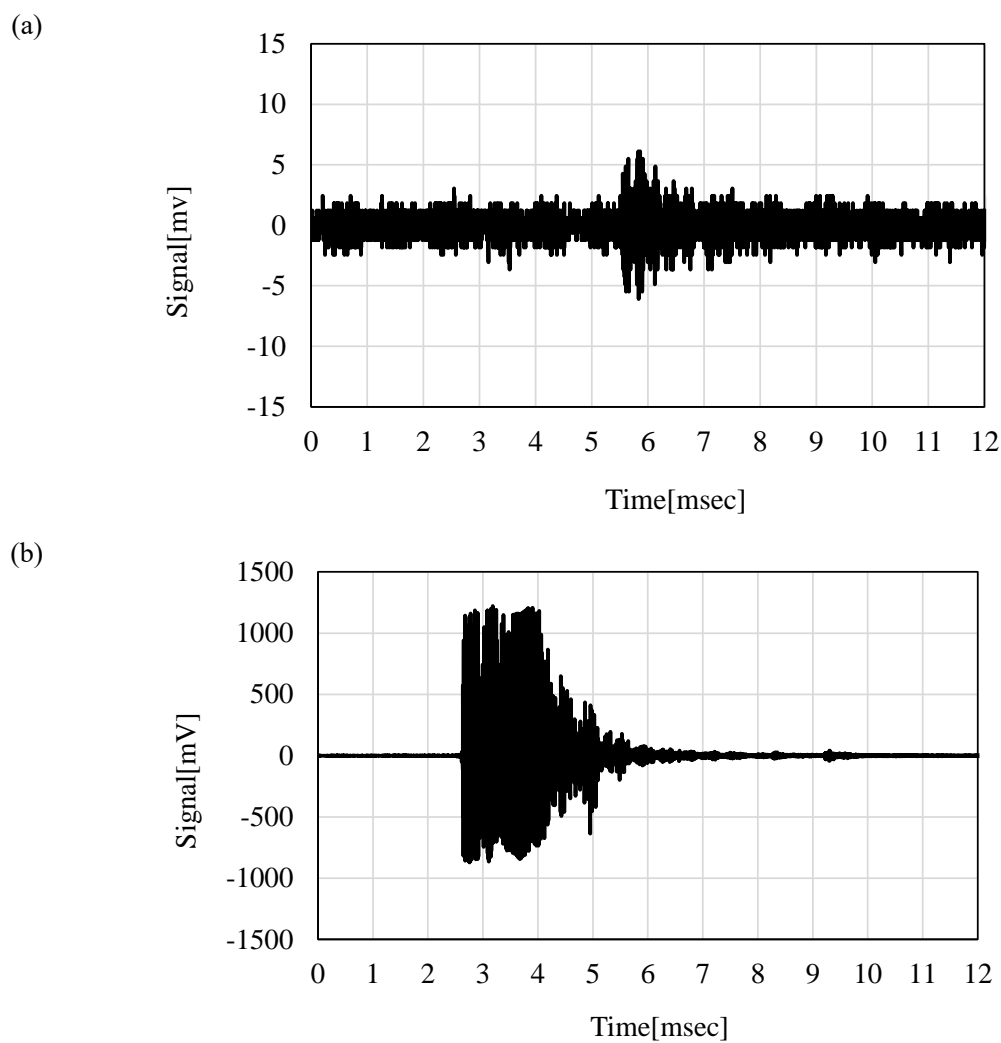


Fig. 3.7 Waveform of AE signals.

(a) Data at the time of plastic deformation around the peak stress. (b) Data at the point of break.

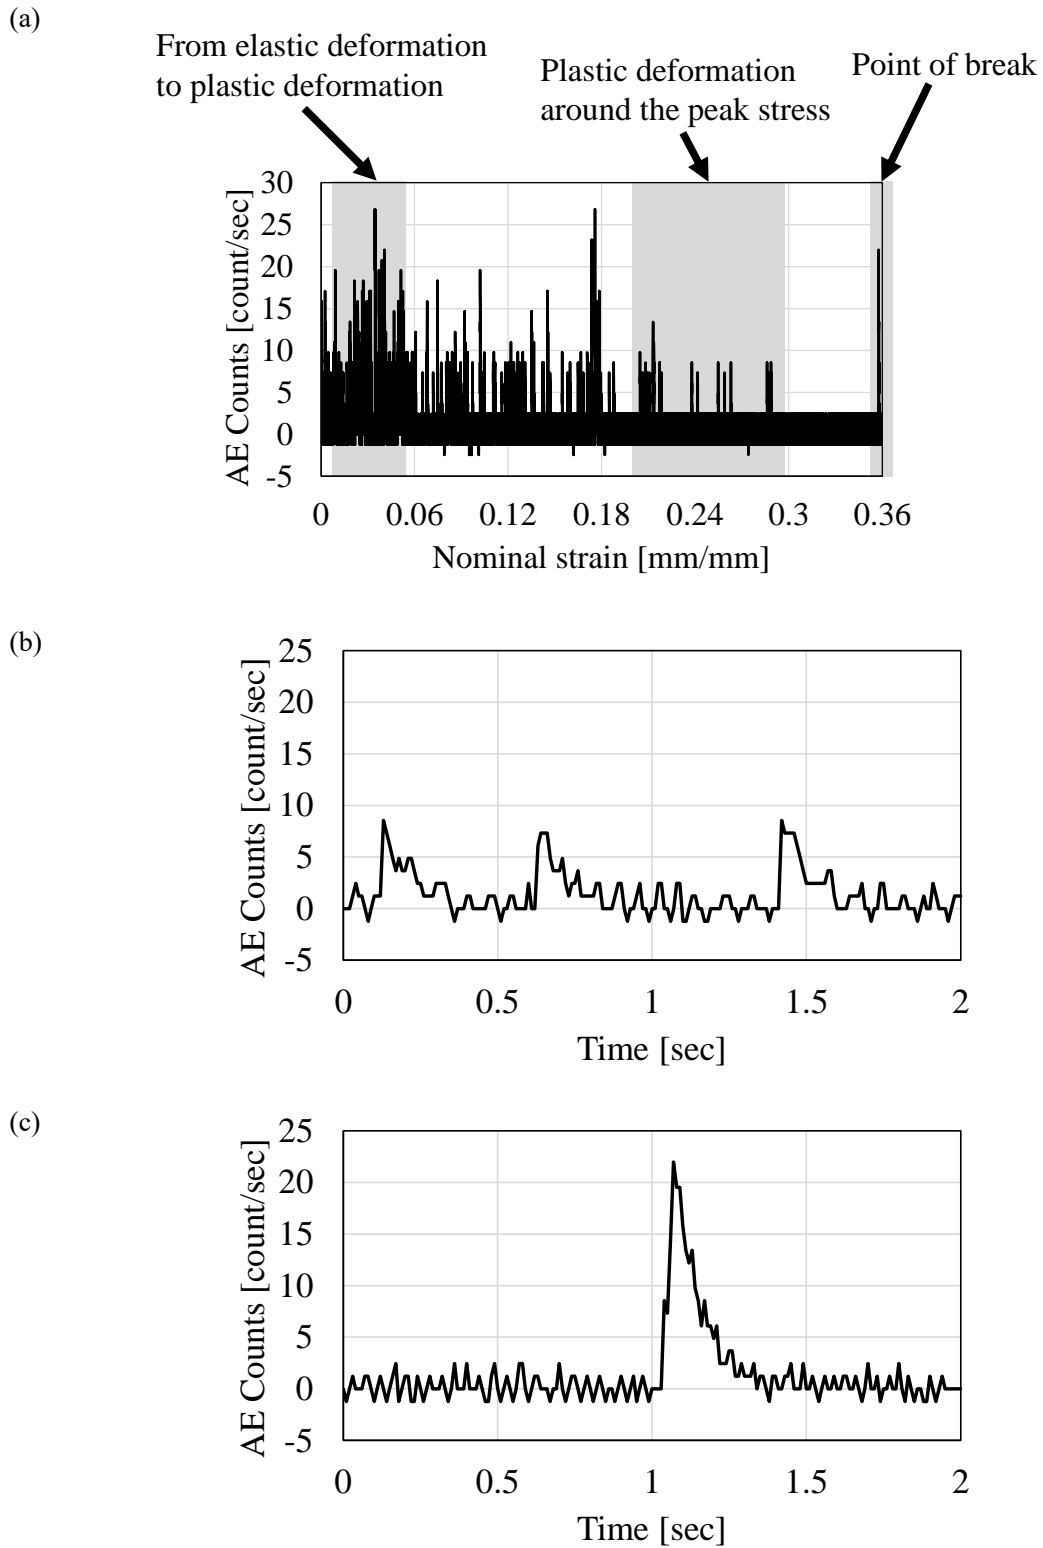


Fig. 3.8 AE count rate.

(a) Overall data. (b) Data at the time of plastic deformation around the peak stress. (c) Data at the point of break.

3.4 測定データの解析

3.4.1 データ解析方法

応力ピーク周辺の塑性変形時に得られた AE 信号 (図 3.8 (b)) では、振幅の増大部分が 3 ヶ所、破断時に得られた AE 信号 (図 3.8 (c)) では、振幅の増大部分が 1 ヶ所存在した。そこで、振幅増大部分について周波数分析を行い、材料の状態変化と構成周波数の関係について調べた。周波数分析は、Microsoft Excel の分析ツールを用いて、2 の累乗である 4,096 点を対象に振幅増大部に FFT (高速フーリエ変換) を行った。

3.4.2 データ解析結果と考察

AE 信号の振幅の増大部分について周波数分析を行い、材料の状態変化と構成周波数の関係について調べた結果を図 3.9 に示す。図 3.9 (a) は応力ピーク周辺の塑性変形時、(b) は破断発生時の結果である。縦軸はスペクトル強度、横軸は周波数を表す。元の信号は AE テスタにより 100 kHz のハイパスフィルタ処理が行われている。また、AE センサの共振周波数は 70 kHz であるため、共振周波数の 2 倍まで測定できるようサンプリング定理[60]からサンプリング周期を $3\mu\text{s}$ に設定している。したがって、分析可能な周波数の範囲は約 167 kHz となる。応力ピーク周辺の塑性変形時である図 3.9 (a) では、60 kHz と 160 kHz 付近に 2 つの鋭いピークが確認できる。一方、破断発生時である図 3.9 (b) では 60 kHz, 90 kHz, 160 kHz 付近に顕著なピークが確認できる。AE センサから得られた信号は、ハイパスフィルタにより 100 kHz 未満がカットされているため、材料の状態変化により現れる周波数は 160 kHz 近傍と言える。なお、カウントレートは AE テスタ内で演算されており AE センサと HPF の仕様により 100kHz から 1000kHz の信号が対象になっている。以上の結果から、塑性変形時および破断発生時に発生する AE 信号の周波数領域の特徴を明らかにし、両者の強度の違いが明確となった。したがって、深絞り加工など塑性加工中の AE 信号が得られれば、AE 信号を使用して加工中

に製品の割れなどの認識が可能であると考えられる。

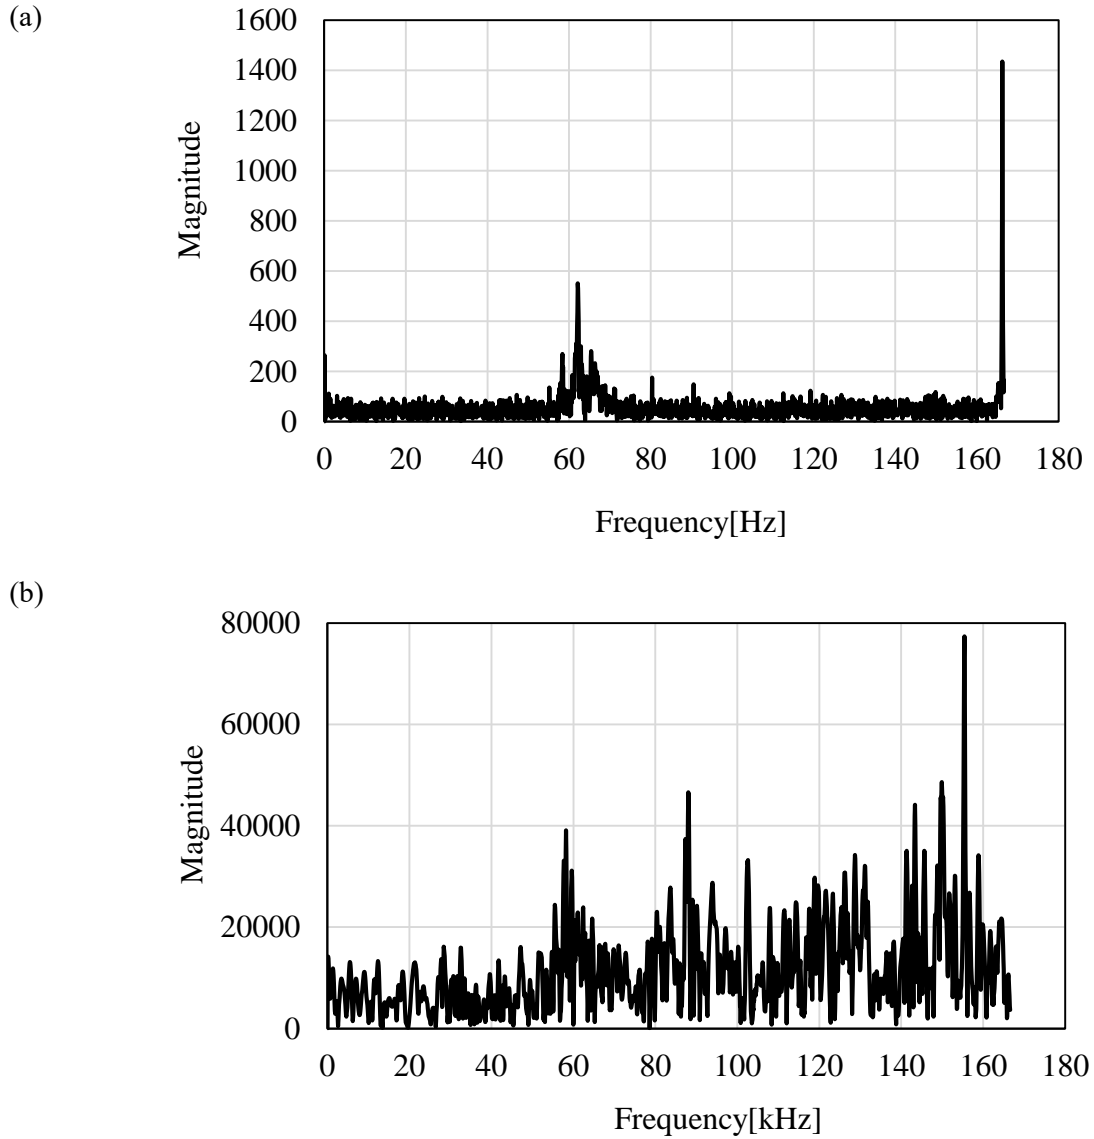


Fig. 3.9 Frequency spectra of the AE signals.

(a) Peak stress. (b) Break.

3.5 結言

本章では、材料にAEセンサを取り付けて引張試験を行い、応力ピーク付近での塑性変形時および破断時のAE信号とカウントレートを測定し、得られたデータについて信号の波形とカウントレート、および周波数スペクトルについて解析した。その結果、以下の結論を得た。

- (1) 応力ピーク周辺の塑性変形時、AE信号ではわずかな振幅の増加が発生しており、塑性変形時に特有な連続型AEが確認できた。
- (2) 破断発生時、AE信号では非常に大きく急激な振幅の増加が発生しており、材料のき裂進展時に特有な突発型AEが確認できた。
- (3) 引張試験中、弾性変形から塑性変形への移行時のカウントレートが比較的大きく、応力のピーク付近で小さくなり、破断時に再び大きくなっている。
- (4) カウントレートにおいても、塑性変形時に観測されるAE信号は連続型AEが支配的であり、き裂が進展する破断発生時に観測されるAE信号は突発型AEが多いことが確認できた。
- (5) プレス加工で多用されるSPCCにおいても、塑性変形時と破断時でそれぞれ連続型AE、突発型AEという異なる特徴を持つAE信号が観測されたことから、AE信号による加工状態認識の可能性が示された。
- (6) AE信号の周波数領域での特徴として、応力ピーク周辺の塑性変形時は60 kHzと160 kHz付近、破断発生時は60 kHz、90 kHz、160 kHz付近に顕著なピークが確認できた。しかし、AEセンサから得られた信号は、ハイパスフィルタにより100 kHz未満がカットされているため、材料の状態変化に直接関係する周波数は160 kHz近傍に現れるピークと考えられる。

- (7) 塑性変形時および破断発生時に発生する AE 信号の周波数領域での違いが明確となったことから、塑性加工中の AE 信号が得られれば、AE 信号を使用して加工中に製品の割れなどの認識ができる可能性がある。

第4章

深絞りにおける AE 測定と加工状態認識実験

4.1 緒言

前章では、材料に AE センサを取り付けて引張試験を行い、応力ピーク付近での塑性変形時および破断時の AE 信号とカウントレートの測定および得られたデータの解析により、AE 信号とカウントレートおよび周波数領域における特徴を把握し、プレス加工中の加工状態の認識における AE の有効性を明らかにした。深絞り中に測定する AE 信号には、被加工材と金型間の接触や摩擦に起因する特徴も含まれることが予想される。これは、深絞り中に得られた AE 信号が、引張試験中に得られた AE 信号の特徴のほかに異なる特徴もあわせて持つ可能性があることを意味する。したがって、深絞りにおける AE 信号の測定とカウントレートおよび解析を行い、引張試験中に得られた測定結果と比較する必要がある。本章では、深絞りにおける AE 信号とカウントレートの測定とデータ解析を行い、引張試験で得られた結果と比較し、深絞りの加工状態の認識における AE の有効性を確認した上で、認識精度向上が期待できる機械学習手法を用いて深絞りにおける加工状態認識実験を行い、本手法の有効性を検証した。

第4章 深絞りにおける AE 測定と加工状態認識実験

4.2 深絞り加工

4.2.1 実験装置

実験に用いたプレス機と金型および AE センサの取り付け位置を図 4.1 に、金型の概略図を図 4.2 に示す。プレス機はサーボプレス NC1-800(D) (株式会社 アイダエンジニアリング)、金型はパンチとダイの位置関係が反転している倒置式を使用した。被加工材はブランクホルダーにより拘束され、中央部をパンチでダイに押し込むことで加工が行われる。本試験で使用したパンチ速度曲線を図 4.3 に示す。プレス機は機械式サーボプレスを用いており、横軸はクランク角を表している。クランク角 180° は下死点、クランク角 0° と 360° は上死点である。下死点付近ではパンチ速度は 0 であり、クランク角 90° 付近および 270° 付近においてパンチ速度は最大となる。




Fig. 4.1 Forming machine and mounting location of the AE sensor.




Fig. 4.2 Schematic illustration of the experimental setup.




Fig. 4.3 Punch speed curves used in this study.

4.2.2 実験条件

深絞りの実験条件を表 4.1 に、金型の詳細仕様を図 4.4 に示す。被加工材は引張試験と同じ SPCC（公称板厚 1.0mm）を用いた。正常な加工品と割れが発生した加工品は、加工中の潤滑油量を変えることで得た。実験では、刷毛を使用して最初の試験片に潤滑油を塗布し、き裂が生じるまで潤滑油の塗布なしで次の試験片の加工を続ける。き裂の発生後、次の試験片には再び刷毛で潤滑油を塗布し、再度き裂が発生するまで試験片に潤滑油の塗布なしで加工を続ける。この過程を 100 個の加工品が得られるまで繰り返した。

Table. 4.1 Experimental conditions for the deep drawing test.

Apparatus	Mechanical servo press
Nominal capacity	800 kN
Stroke	160 mm
Blank holder force	6 kN
Shape of drawing	Circular cup
Blank diameter	110 mm
Punch diameter	52 mm
Depth of draw	37 mm
Clearance	1 mm
Lubricant	Curtagil 60NEAT




Fig. 4.4 Schematic illustration of the deep drawing process.

4.2.3 実験結果および考察

深絞りで得られた加工品を図 4.5 に、深絞り中の加工荷重曲線を図 4.6 に、深絞りの工程の模式図を図 4.7 に示す。正常な加工品では、側壁に変形やくびれは発生していないが、割れた加工品では側壁が途中から破断している。加工品のフランジ部分の面積を比較すると、割れた加工品のフランジ面積は正常な加工品のフランジ面積よりも大きい。よって、加工の初期の段階で割れが発生していることが確認できる。図 4.6 において、縦軸は加工荷重、横軸はクランク角度を示す。図 4.6 の領域 A では、図 4.7(2)で示すように下降した上型が被加工材に接触している。領域 A'では、図 4.7(3)で示すように上型がさらに下降し加工が進行している。図 4.6 の領域 A''では、図 4.7(4)で示すように加工が終了し上型が下降から上昇に転じている。図 4.6 の領域 B では、図 4.7(5)で示すように上型が下降している間に離脱していたパンチプレートとクッションプレートが再び接触している。深絞りでは、被加工材および金型の状態の変化が大きくわけて 4 種類あることから、これらの発生時の特徴が加工状態の認識に重要だと考えられる。

(a)



(b)




Fig. 4.5 The processed product obtained by the deep drawing testing.

(a) Normal product. (b) Cracked product.

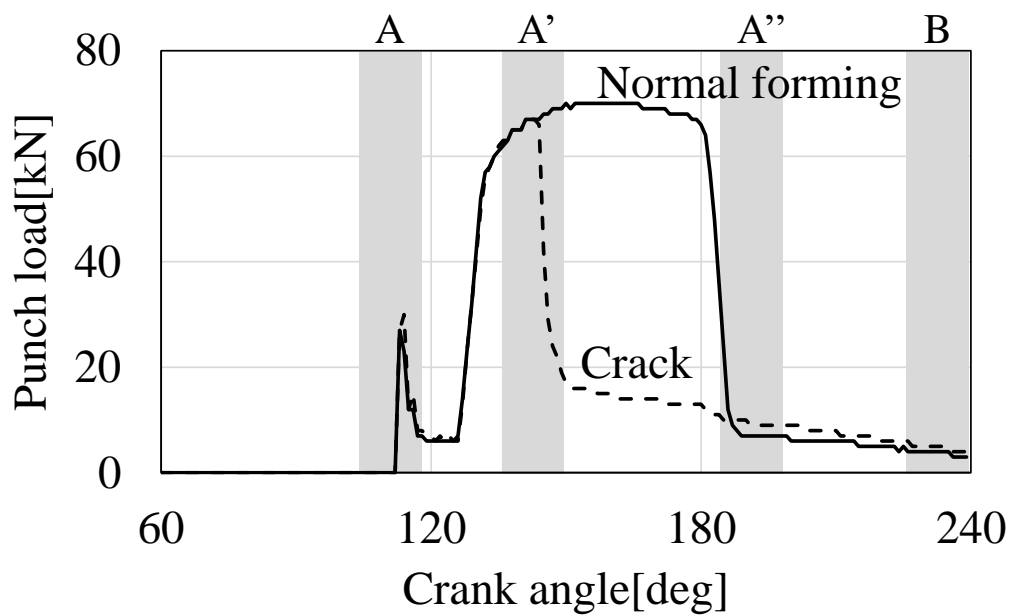


Fig. 4.6 Load curves during deep drawing.

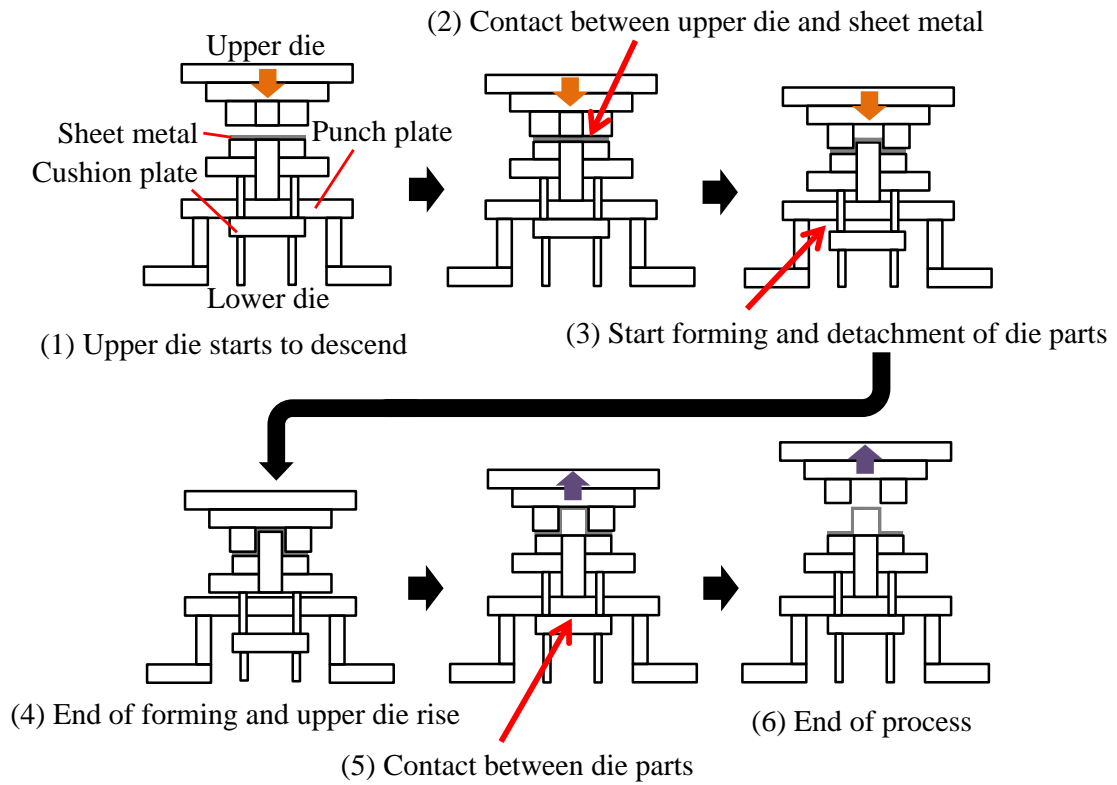


Fig. 4.7 Schematic illustration of the deep drawing.

4.3 深絞りにおける AE 測定

4.3.1 実験装置

実験に用いた AE センサの取り付け位置は、前節の図 4.1 に示した通りである。AE センサは、深絞り中の AE 信号をより正確に測定するため、材料との接触面積が大きいパンチの取り付け先であるパンチプレートに、マグネットホルダを用いて取り付けた。AE 信号測定システムおよび AE センサは前章と同じものを用いた。

4.3.2 実験条件

AE センサは前章と同様に共振周波数 70 kHz のものを用いた。AE テスタにおいても前章と同様であり、AE 信号の場合は入力信号に 20 倍のゲインの増幅と 100 kHz を閾値とするハイパスフィルタ処理を行い、サンプリングタイム 3 μsec にて PC にデータを収録した。カウントレートの場合も AE 信号の場合と同様に、入力信号に 20 倍のゲインの増幅と 100 kHz を閾値とするハイパスフィルタ処理を行った後、0.1 V を閾値としてカウントレートをコンパレータによってカウントし、サンプリングタイム 10 msec にて PC にデータを収録した。

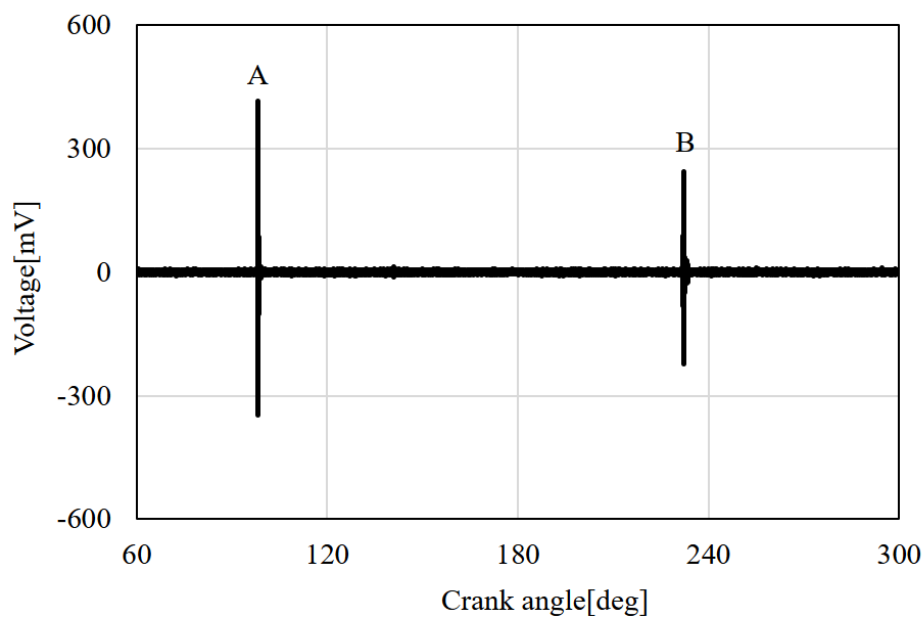
4.3.3 実験結果および考察

AE 信号の測定結果を図 4.8 に示す。縦軸は出力電圧、横軸はクランク角度である。図 4.8 (a)は正常な加工、(b)は割れが発生した加工である。正常な加工および割れともに、A と B で示す振幅の増大部分が見られる。A はダイと材料の接触、B はパンチプレートとクッションプレートの接触に起因する瞬間的な変形によるものと言える。また割れが発生した加工については、A'および A''においても、振幅の大きい部分が見られる。A'は潤滑不足による高摩擦、A''は材料の破断による振幅の増大が原因と考えられる。こ

れらは正常な加工では見られないことから、加工状態を反映している特徴と言え、深絞りにおいて加工状態の認識の可能性が示された。

次に、得られたカウントレートのデータを図 4.9 および図 4.10 に示す。縦軸はカウントレート、横軸はクランク角である。図 4.9 は正常な加工、図 4.10 は割れが発生した加工でのカウントレートのデータであり、それぞれ代表的な 2 例について示している。すべての加工例に対して、正常な加工と割れが発生した加工の両方に 2 つのピーク A と B が存在する。それぞれのピークについて、A はダイと被加工材の接触によるものであり、B はパンチプレートとクッションプレート同士の接触による瞬間的な変形によるものであると考えられる。割れが発生した加工である図 4.10(a)にはさらにピーク A' および A'' があるが、図 4.9 の正常な加工のデータには存在しない。これは、図 4.10(a)の A' および A'' のピークが、割れの発生によって引き起こされていることを示している。図 4.6 の荷重の変化から、A' は被加工材のき裂によるものと考えられる。さらに A'' は、金型を強くこすりながら割れによって変形した製品がロックアウト（図 4.2 参照）に押し出された事に起因すると考えられる。ピーク A' および A'' は、不十分な潤滑による高摩擦状態と被加工材のき裂が原因と推測される。したがって、本実験で使用した AE 信号測定システムを使用することにより、加工状態を認識することが可能である。しかしながら、図 4.9(b)のように正常な加工でも A と B の間にピークが現れる場合（61 個中 6 個）や、図 4.10(b)のように割れが発生しても A と B の間にピークが現れない場合（39 個中 10 個）がある。したがって、カウントレートには加工状態を認識するのに有効な情報が含まれているが、従来の方法では割れを識別するのに十分ではないと言える。

(a)



(b)

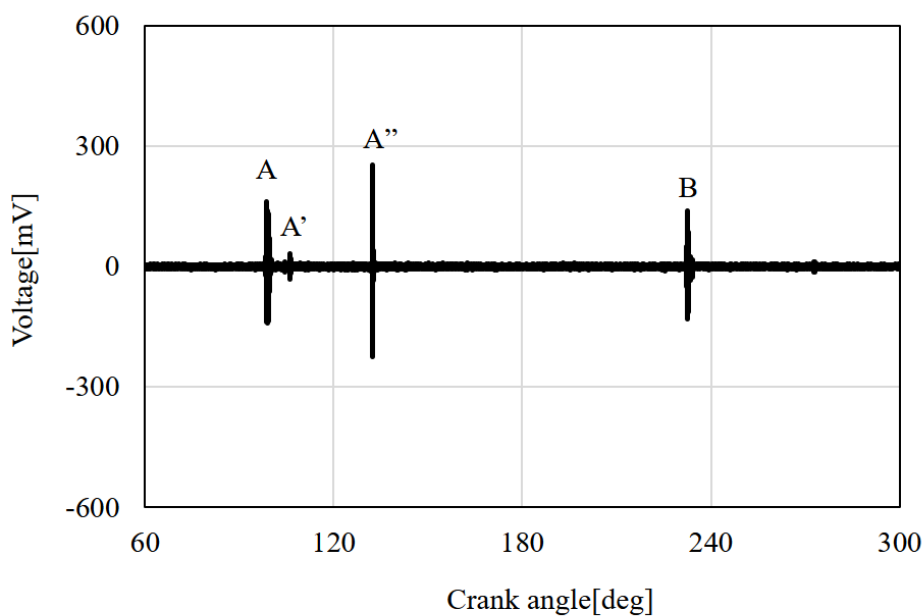



Fig. 4.8 Waveform of AE signals.

(a) Normal forming. (b) Crack.

(a)



(b)

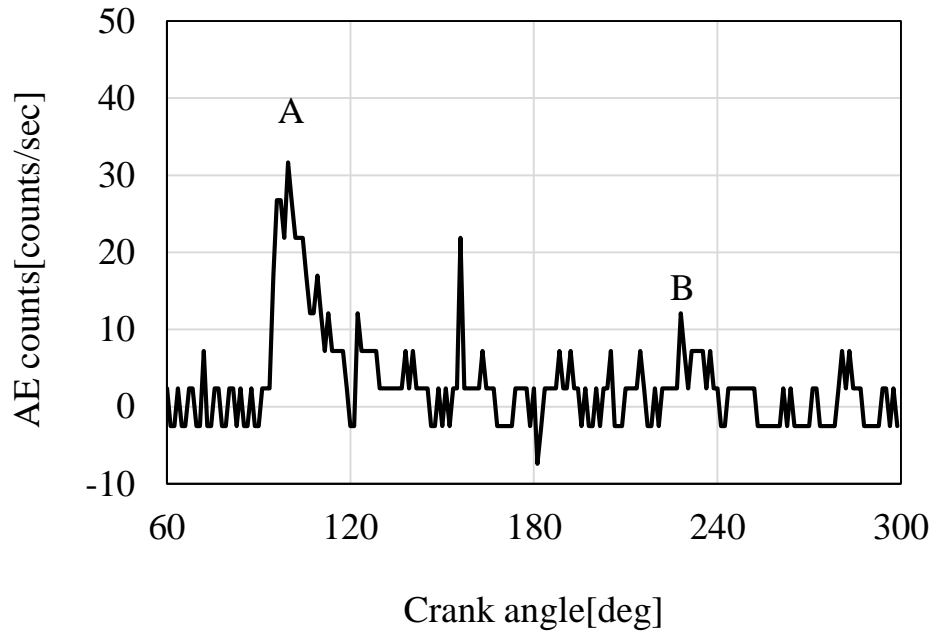


Fig. 4.9 AE count rate of normal forming.

(a)Sample1. (b)Sample2

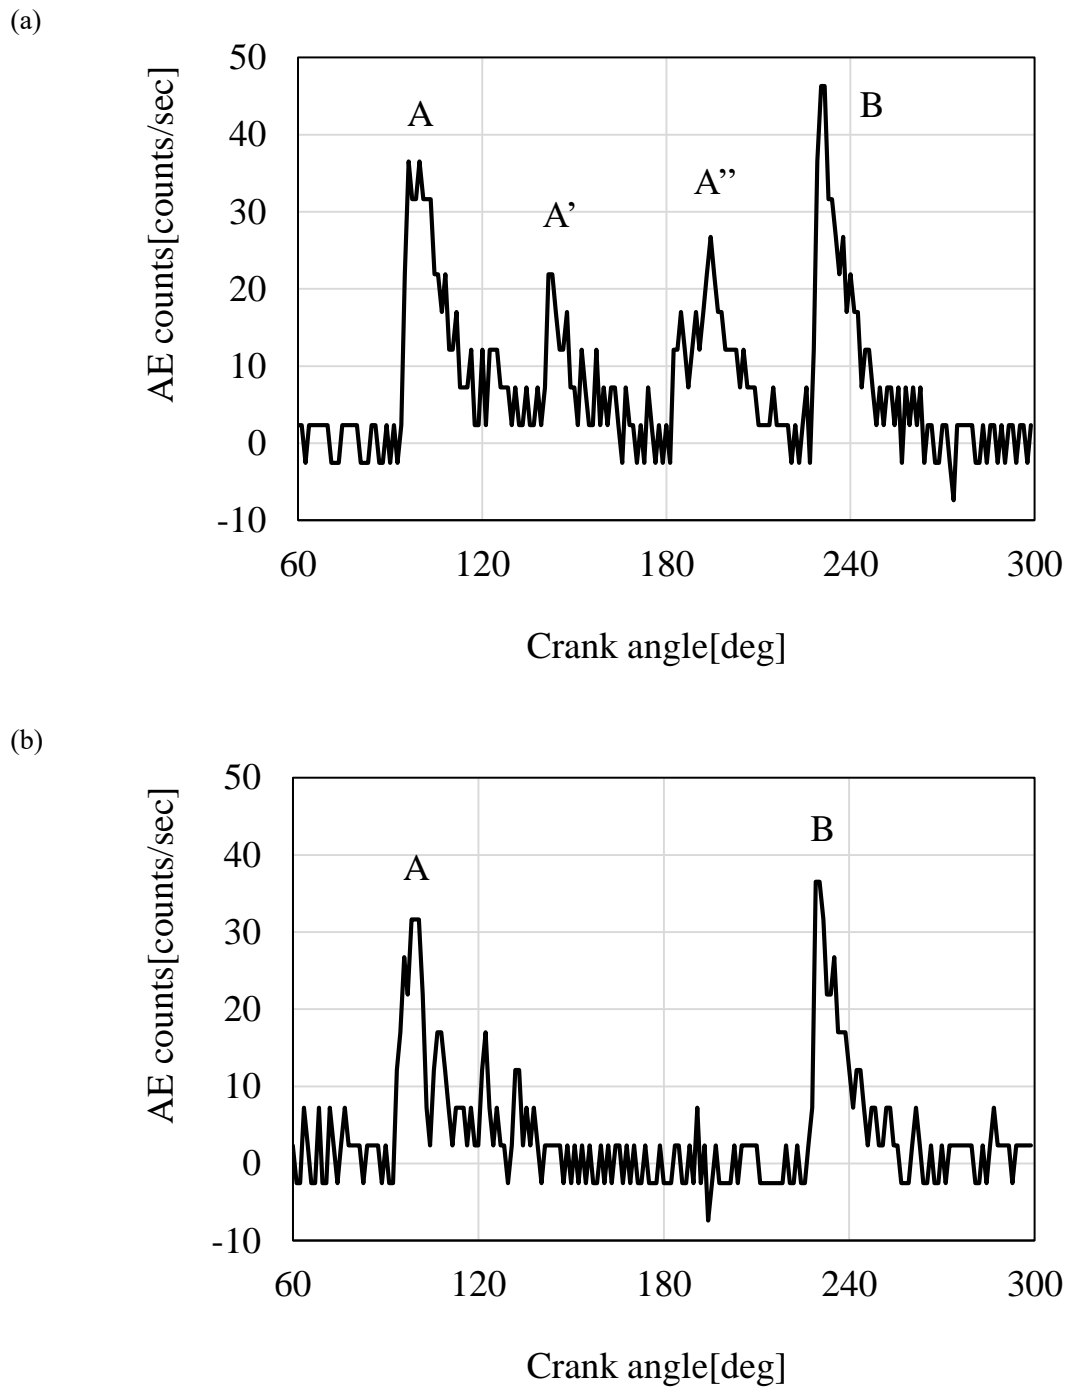


Fig. 4.10 AE count rate of crack.

(a)Sample1. (b)Sample2

4.4 深絞りにおける測定データ解析方法

4.4.1 データ解析方法

前節のAE信号の測定結果から、加工状態を反映していると言えるA'およびA''において周波数分析を行い、前章の引張試験におけるAE測定とデータ解析結果から得られた周波数領域での特徴と比較した。周波数分析は前章と同様に、Microsoft Excelの分析ツールを用いて、解析可能なデータ数である2の累乗の4096点を対象にFFT（高速フーリエ変換）を行った。

4.4.2 データ解析結果と考察

加工状態を反映していると言えるA'およびA''において特徴が明確な1ショットを選んで周波数分析を行い、構成周波数の関係について調べた結果を図4.11に示す。図4.11で(a)はA'、(b)はA''の結果である。縦軸はスペクトル強度、横軸は周波数を表す。A'については、40、50、60、100、160 kHz近傍に、A''については、40および100~165 kHz近傍にピークが見られた。AE信号測定システムでは100 kHzを閾値とするハイパスフィルタ処理を行っていることから、40、50、60 kHz近傍のピークはノイズによるものと考えられる。周波数分析の結果、引張試験における塑性変形時や破断発生時の主要構成周波数である160 kHz近傍のピークが含まれることを確認した。よって、深絞り加工においても構築したAE信号測定システムにより加工状態を反映した160 kHz近傍のピークを含むデータを得ることができるため、得られたAE信号データやカウントレートを用いた加工状態認識の可能性がある。

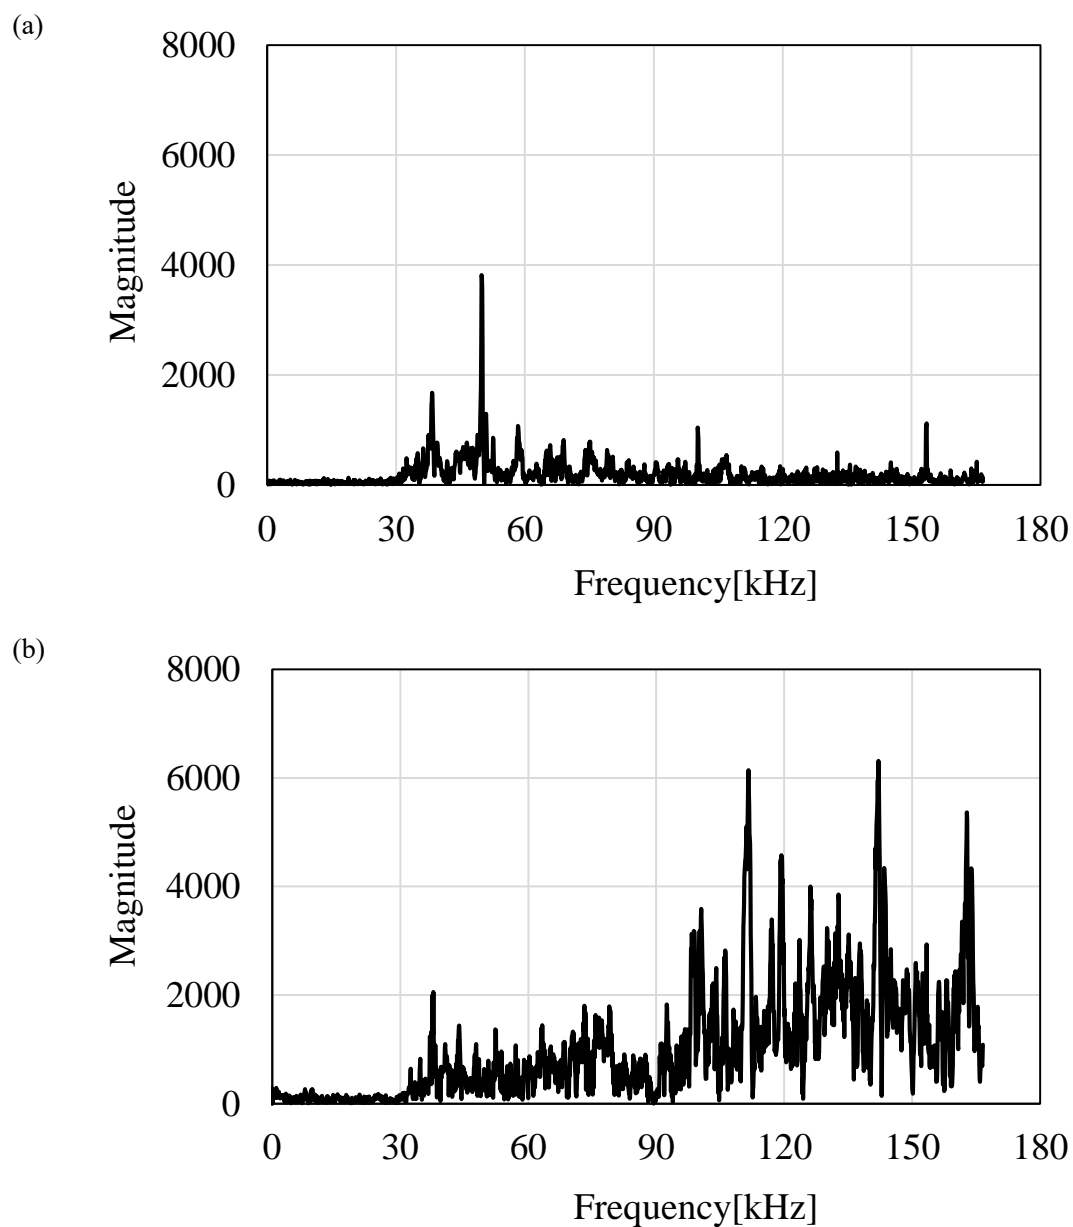


Fig. 4.11 Frequency spectra of AE signals.

(a) The FFT result of point A'. (b) The FFT result of point A''

4.5 機械学習による加工状態認識実験

4.5.1 実験環境

前節では、構築した AE 信号測定システムにより深絞り加工において引張試験の場合と同様に 160 kHz 近傍のピークを含んだ加工状態を反映したデータを得ることができたことから、AE カウントレートを用いた加工状態認識の可能性を示した。しかしながら、加工状態を認識するのに有効な情報が含まれているものの、従来の方法では割れを識別するのに十分ではない。そこでカウントレートを用いた加工状態認識実験を行うにあたり、認識精度向上を期待し機械学習を用いた。加工状態認識実験は、Chainer を用いた加工状態認識システムを構築して行った。構築した実験環境を表 4.2 に示す。Chainer は、(株)Preferred Networks 社により提供されている Python ベースで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。ネットワークの構築と評価の同時実行や GPU の使用により高速な計算が可能で、様々な損失関数や最適化手法が利用でき、多層や複雑なネットワークを簡単に柔軟に記述できるなどの特徴を持つ。

Table. 4.2 Computer specifications, software version.

CPU	Intel Xeon E3-1241 V3 3.50 GHz, 4 cores 8 threads
Memory size	16 GB DDR3, Non-ECC
GPU	NVIDIA Quadro K620, 2 GB DDR3
OS	Ubuntu 14.04.5 LTS
Versions of Chainer	V1

4.5.2 実験条件

実験に使用したネットワークの構成を図 4.12 に示す。入力層、隠れ層、出力層の各層は全結合、入力層のノード数は 200、出力層のノード数は正常な加工の確率と割れの確率をそれぞれ出力するため 2 とした。最適化手法は SGD, RMSprop, Adam の 3 種類、活性化関数は sigmoid, tanh, ReLU の 3 種類を用いた。

SGD(Stochastic Gradient Descent)は、データの中からランダムに選択したデータを用いた最適化、RMSprop は、過去の情報の影響を徐々に減らす指数移動平均による最適化、Adam(Adaptive moment estimation)は、RMSprop で発生する指数移動平均によるバイアスを打ち消した最適化を行う手法である。

Sigmoid は、式(4.1)および図 4.13(a)で示すように、入力値 x が大きくなると出力値 y が 0 から 1 に近づいていく。tanh は、式(4.2)および図 4.13(b)で示すように、入力値 x が大きくなると出力値が -1 から 1 に近づいていく。ReLU(Rectified Linear Unit)は、式(4.3)および図 4.13(c)で示すように、入力値 x が負であれば出力値は 0、入力値 x が正であれば出力値 y は線形に増加する。従来のニューラルネットワークでは、Sigmoid と tanh が主に使用されているが、計算負荷が高く層が多いと計算が不可能になる場合がある。ReLU が使用されるのは計算速度が大きくレイヤーが多くても効果的なためである。

$$y = \frac{1}{1 + \exp(-x)} \quad (4.1)$$

$$y = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (4.2)$$

$$y = \max(0, x) \quad (4.3)$$

本実験では 3 つの活性化関数 (Sigmoid, tanh, ReLU) と 3 つの最適化手法 (SGD, RMSprop, Adam) の 9 つの組み合わせを認識に使用した。

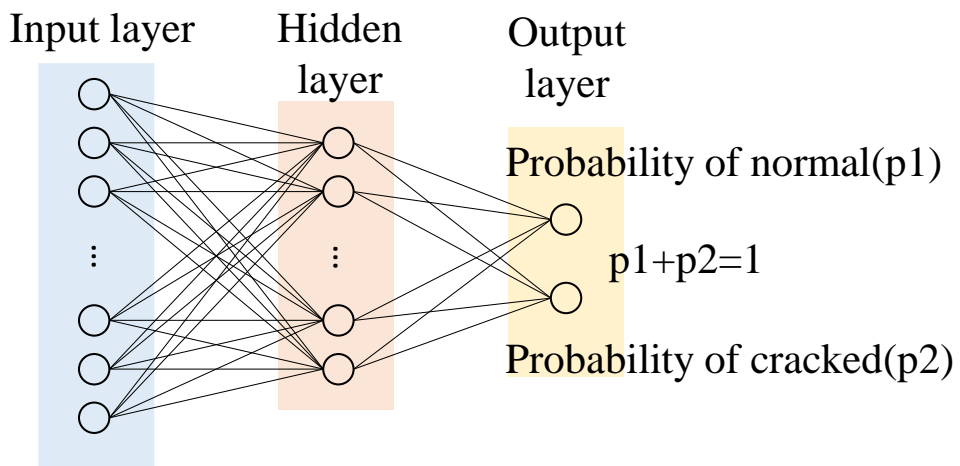


Fig. 4.12 The configuration of the network.

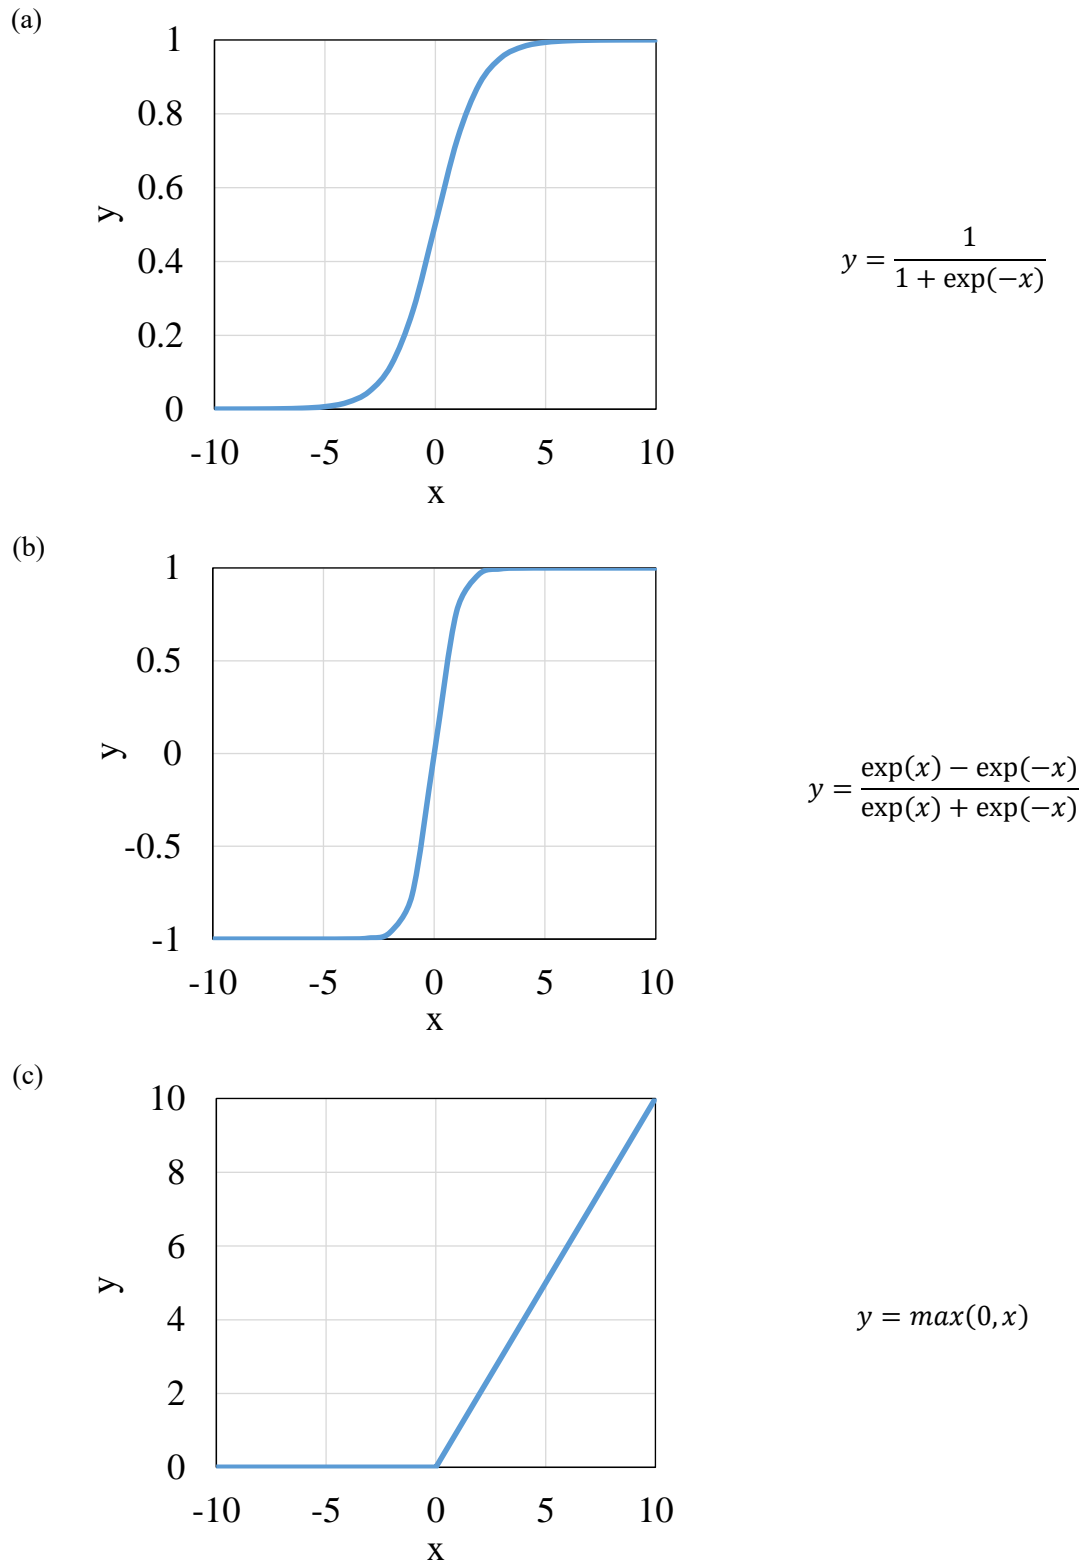


Fig. 4.13 Activation functions. (a) Sigmoid. (b) tanh. (c) ReLU.

4.5.3 使用データ

引張試験と深絞り中の AE 信号の解析により、AE 信号を利用した加工状態認識の可能性を示した。しかし、AE 信号をそのまま扱うには 1 加工当たりのデータ数が多いこと、インプロセスでは高速な処理が求められること、AE 信号で観測された波形の特徴は連続型ではなく突発型であることから、突発型に対する使用パラメータとして一般的でデータ処理が容易な、単位時間当たりの AE 波形の発生数をカウントしたカウントレートをを用いた[58]。データは、深絞りの 1 工程が全て測定できるよう、200 点、2 sec 分を収録した。なお、近接スイッチによりプレス機のスライドが所定の位置に降下したことをトリガとし、データ収集開始のタイミングを揃えた。

4.5.4 実験方法

加工状態の認識は、入力層の 200 個のノードに 1 工程分のカウントレートのデータ 200 点を入力し、出力層の正常な加工の確率と割れの確率を比較し、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する。正常な加工のカウントレートのデータ 61 個、割れのカウントレートのデータ 39 個、合計 100 個のデータを用意し、その中からランダムに選んだ 80 個を学習用データに振り分け、学習用データの中からランダムに選んだ 10 個を用いた学習を 30 回繰り返した。最後に、学習済みモデルを用いて、100 個のデータ全てに対して隠れ層のノード数、最適化手法、活性化関数を変えた加工状態認識実験を行い、認識率を比較した。

また、学習データ数が認識率の精度に与える影響を調べるため、さらに深絞り加工実験を行い新たに得られた正常な加工のデータ 790 個、割れのデータ 286 個、合計 1076 個のデータを用いた加工状態認識実験についても行った。学習データはランダムに選んだ 800 個とし、学習データの中からランダムに選んだ 50 個を用いた学習を 350 回繰り返した。

4.5.5 実験結果と考察


100 個のデータに対する加工状態認識実験の結果を図 4.14 に示す。最適化手法と活性化関数の組み合わせ別の認識率であり、認識率は 3 回実施した平均値を用いた。グラフは横軸が隠れ層のノード数、縦軸が認識率である。認識率は、加工状態を正しく認識した割合と定義した。最適化手法は Adam を用いた場合に認識率が高い傾向があり、最高値は活性化関数 tanh との組み合わせによる 97.3 %であった。tanh は、入力データをマッピングし直した際、0 付近のデータが多ければ分類の成績が向上する。よって、今回のデータは 0 付近が多かったため認識率が良好だったと考えられる。SGD は全ての活性化関数との組み合わせにおいて認識率が低かった。SGD は一般的な最適化手法であるものの、収束が不安定であることから機械学習としては少ない 100 個のデータ数では認識率が低くなったと考えられる。活性化関数は sigmoid を用いた場合に認識率が低かった。sigmoid は収束が遅いため、SGD の場合と同様に、100 個のデータ数では認識率が低くなったと考えられる。

図 4.15 は、隠れ層の数が 1 である場合の認識率に対する隠れ層のノード数の影響を示している。認識率は、隠れ層のノード数が 200 まで増加するが、200 を超えると認識率はほぼ一定になる。データの特徴がそれほど複雑ではないため、ノード数を増やしても効果が得られず頭打ちになっていると考えられる。図 4.16 は、認識率に対する隠れ層の数の影響を示している。図 4.16 (a)は隠れ層の数が 3、(b)は隠れ層の数が 4、(c)は隠れ層の数が 5 の結果である。隠れ層の数が 3 でノード数が 800 のときに認識率は最も高くなる。また、認識率は隠れ層の数が増えると低下する傾向がある。データの特徴がそれほど複雑ではないため、特徴を複雑に表現しようとする局所解におちいるなど、目標の解に到達できていないためと考えられる。


1076 個のデータに対して機械学習を用いた加工状態認識実験の結果を図 4.17 に示す。図 4.17 は最適化手法と活性化関数の組み合わせ別の認識率を示しており、隠れ層の数

は2, 認識率は10回実施した平均値を用いた。グラフは横軸が隠れ層のノード数, 縦軸が認識率である。最適化手法はRMSprop, Adamで高い認識率であったが, Adamの方が安定して高い認識率を示し, 最高値はReLU-Adamの組み合わせによる95.59%であった。最高値は100個のデータを用いた場合の方が高かったが, 全体的には1076個のデータを用いた場合の方が認識率は高くなっており安定した認識が行われた。SGDは他の最適化関数と比べて認識率は低いが, 100個のデータを用いた実験結果より認識率が高くなっている。これより適切な学習回数であれば, 層数を増やさなくても学習がうまく進むと考えられる。なお, SGD-sigmoidの組み合わせでは認識率が上がることはなかった。これはsigmoidの収束が遅いことや, 勾配消失問題により学習が上手く進まなかったことが原因だと考えられる。現在の認識率は100%に達していないが, 本手法を量産現場に適用し, より多くのデータを蓄積することで学習が進み, 認識率が安定化することでさらなる改善が期待できる。

(a)
Sigmoid-SGD



(b)
Sigmoid-Adam



(c)
Sigmoid-RMSprop






Fig. 4.14 Recognition rate of forming state using 100 data.
(a) Sigmoid-SGD. (b) Sigmoid-Adam. (c) Sigmoid-RMSprop.

(d)
tanh-SGD



(e)
tanh-Adam



(f)
tanh-RMSprop





Fig. 4.14 (continued)

(d) tanh-SGD. (e) tanh-Adam. (f) tanh-RMSprop.


(g)

ReLU-SGD



(h)

ReLU-Adam



(i)

ReLU-RMSprop




Fig. 4.14 (continued)

(g) ReLU-SGD. (h) ReLU-Adam. (i) ReLU-RMSprop.

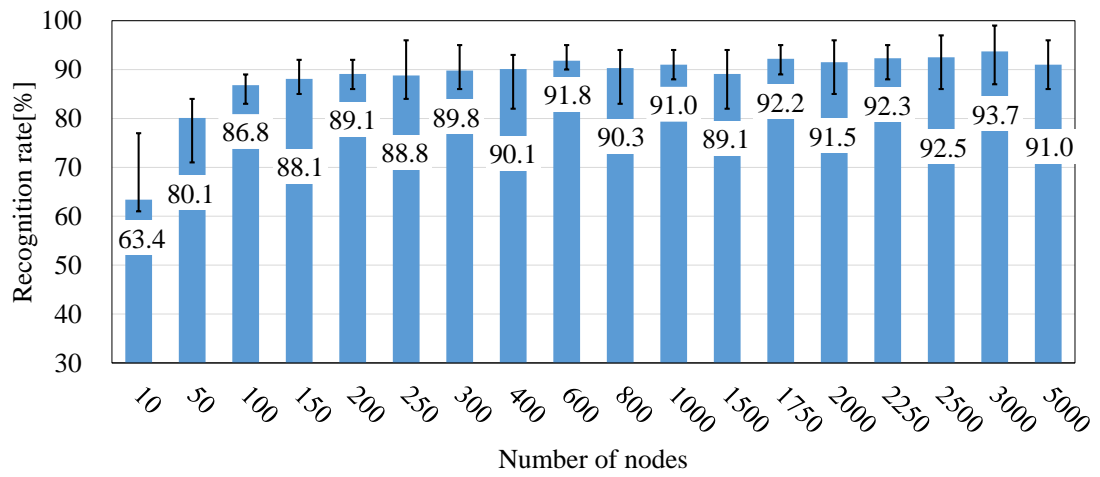



Fig. 4.15 Recognition rate of tanh-Adam with different nodes.


(a)

Hidden layers three



(b)

Hidden layers four



(c)

Hidden layers five






Fig. 4.16 Recognition rate of tanh-Adam with hidden layers.
 (a) Hidden layers three. (b) Hidden layers four. (c) Hidden layers five.

(a)
Sigmoid-SGD



(b)
Sigmoid-Adam



(c)
Sigmoid-RMSprop






Fig. 4.17 Recognition rate of forming state using 1076 data.
(a) Sigmoid-SGD. (b) Sigmoid-Adam. (c) Sigmoid-RMSprop.

(d)
tanh-SGD



(e)
tanh-Adam



(f)
tanh-RMSprop






Fig. 4.17 (continued)

(d) tanh-SGD. (e) tanh-Adam. (f) tanh-RMSprop.

(g)
ReLU-SGD



(h)
ReLU-Adam



(i)
ReLU-RMSprop




Fig. 4.17 (continued)

(g) ReLU-SGD. (h) ReLU-Adam. (i) ReLU-RMSprop.

4.6 結言

本章では、深絞りにおける AE 信号とカウントレートの測定とデータ解析を行い、引張試験で得られた結果と比較し、深絞りの加工状態の認識における AE の有効性を確認した上で、認識精度向上が期待できる機械学習を用いて深絞りにおける加工状態認識実験を行い、手法の有効性を検証した。その結果、以下の結論を得た。

- (1) 深絞り中の AE 信号の測定と解析により、引張試験中の AE 信号の周波数領域の特徴と同じ 160 kHz 付近にピークがあることが示された。したがって、AE 信号を測定することにより、深絞り中の加工状態を認識することができると思う。
- (2) AE データを用いたニューラルネットワークによる加工形状認識実験を行ったところ、 \tanh -Adam の組み合わせにおいて認識率は最大で 97.3%であった。
- (3) 深絞り中の AE データのニューラルネットワークのパラメータを調べると、隠れ層の数が増えると認識率がわずかに増加する傾向があり、隠れ層のノード数が大きくなりすぎると認識率が低下することが明らかになった。データの特徴がそれほど複雑ではないため、特徴を複雑に表現しようとする局所解におちいるなど、目標の解に到達できていないためと考えられる。
- (4) 使用データ数を 100 個から 1076 個に増やしたことで認識率は安定した。今後、現場への適用によりさらに多くのデータを蓄積することで認識率の改善が期待できる。

第5章

打抜きにおけるバリ高さ推定実験

5.1 緒言

打抜きは、切削加工などの加工法と比較して特に加工速度が大きく、多数個取りも可能で大量生産に向くことから、あらゆる分野で使用されている。そのため、不良発生時に瞬時に検知できなければ大量の不良品が生産される恐れがある。打抜きにおける不良品としては、金型摩耗によるバリの発生、カス上がりによる圧痕などがあるが、もっとも影響が大きく、発生頻度が高いのはバリである[29]。許容されるバリ高さをこえるような不良発生を防止するためには金型の状態の把握が有効であるが、金型の構造が複雑で加工中の金型の状態を判断することは困難である。

本章では、打抜きにおける AE、加工荷重、ひずみのデータ測定と製品のバリ高さを測定し、ショット数の増加と測定データおよびバリ高さについて分析した。また、測定データとバリ高さの分析結果を基に機械学習を用いた打抜きにおけるバリ高さ推定実験を行い、その有効性を検証した。

5.2 打抜き加工

5.2.1 実験装置

実験に用いたプレス機と金型およびセンサの取り付け位置を図 5.1 に、金型の概略図を図 5.2 に示す。プレス機は前章までと同様にサーボプレス NC1-800(D) (株式会社 アイダエンジニアリング) を用いた。打抜き加工では、被加工材はストリップにより押さえられ、パンチで被加工材の中央部をダイ側に押し込むことで加工が行われる。金型材はプラスチックの加工に多用される AISIP21 を用いた。AISIP21 は熱処理をしない状態で HRC40 程度と柔らかい材料であり、生材で使用するにより少ないショット数でも摩耗が進行しバリ高さが増加するよう工夫した。

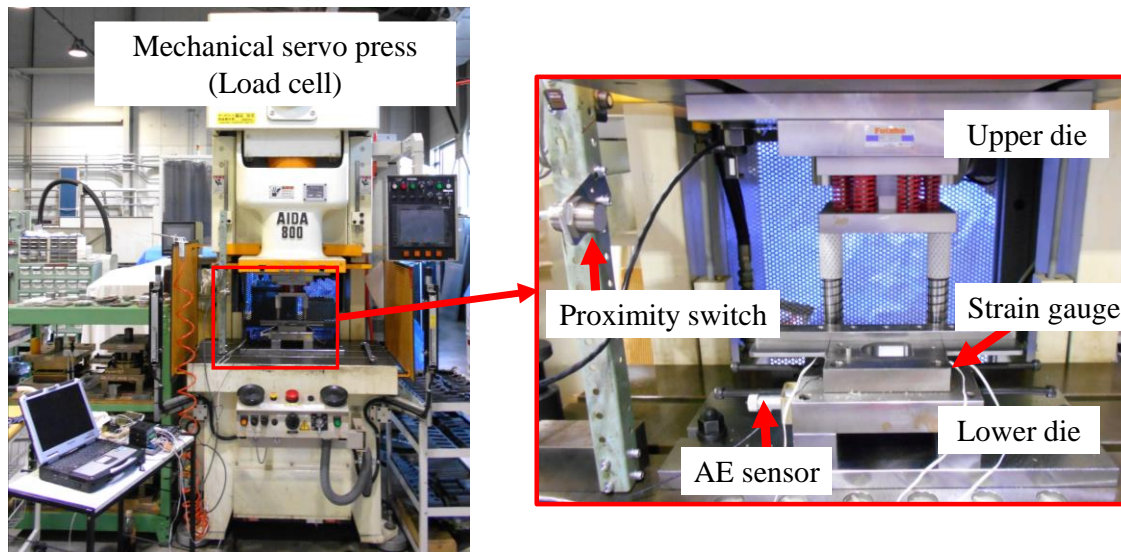


Fig. 5.1 Blanking machine and mounting location of the sensors.





Fig. 5.2 Schematic illustration of the experimental setup.

5.2.2 実験条件

打抜きの実験条件を表 5.1 に、打抜き形状を図 5.3 に示す。被加工材は前章までと同じ SPCC で公称板厚 1.2 mm のものを用いた。実験では、スプレータイプの汎用潤滑油をショットごとに被加工材に塗布した。加工は金型の摩耗が進行しバリが発生するよう 1500 ショットまで行った。

Table. 5.1 Experimental conditions for the blanking test.

Apparatus	Mechanical servo press
Nominal capacity	800 kN
Stroke	160 mm
Punch speed	20SPM (Crank motion)
Die material	AISIP21 (Raw material)
Clearance	0.12 mm
Lubricant	General lubricant



Dimensions in mm

Fig. 5.3 Geometry of blank.

5.2.3 実験結果および考察

打抜きで得られた加工品を図 5.4 に、拡大図を図 5.5 に示す。一般的な打抜きで見られるダレ、バリが発生し、加工面においては破断面とせん断面が確認できた。1500 ショットの加工初期と終盤のそれぞれにおいてバリに触れると高さが増加しており、金型材に柔らかい材質を使用することで摩耗が進行しバリが増加したと考えられる。



Fig. 5.4 The processed product obtained by the blanking testing.




Fig. 5.5 Enlarged view of the product obtained by the blanking testing.

(a) Punch side. (b) Die side. (c) Side of product.

5.3 バリ測定

5.3.1 測定装置

バリ測定に使用したレーザ顕微鏡 VK-X200 (株式会社 キーエンス)を図 5.6 に示す。オートフォーカス、レーザ受光感度の自動調整、対象物の上限と下限を自動で認識し測定レンジを設定する自動上下限設定の機能のほか、エリアを指定することで1視野では測定できない広範囲を自動で複数回に分割して測定し、最後にデータを連結する機能を有する。



Fig. 5.6 Laser microscope.

5.3.2 測定方法

初めに、1500ショット分の加工の初期、中期、終期から1枚を選び、それぞれ加工品全周を12の領域に分割してバリが高い場所を調べ、バリ部を含む高さの測定と近傍の母材部の高さの測定を行い、その差をバリ高さとした。加工品全周の領域分割を図5.7に示す。次に、加工品全周の中でバリが高い領域を特定し、1500ショット分の加工から加工品を20枚ごとに抽出し、一定の長さでバリ部を含む高さの平均値の測定と同じ長さでの母材部の測定を行い、その差を平均バリ高さとした。




Fig. 5.7 Divided measurement area.

5.3.3 測定結果と考察

1500 ショット分の加工の初期として選んだ 2 ショット目の加工品全周の高さ測定結果を図 5.8 に、中期として選んだ 819 ショット目の加工品全周の高さ測定結果を図 5.9 に、終期として選んだ 1498 ショット目の加工品全周の高さ測定結果を図 5.10 に示す。高さはレーザ顕微鏡の絶対的な高さであり、青→水色→黄緑→黄色→赤の変化にしたがって高くなる。加工部のバリは、一様ではなく突発的に発生する場合も多く、バリ高さの定義が困難と言える。

次に、バリ高さと測定領域について整理したデータを図 5.11 に示す。測定領域の番号は、図 5.7 で示した番号を表す。直線部である 02 部、04 部、06 部においてバリが高い傾向にあることがわかった。凸コーナ部では材料不足により 2 軸引張となり、き裂が入りやすくなる[61]。そのため、R 部と直線部を比較すると R 部の方が先にき裂が発生するため、き裂の発生が遅い直線部ではパンチ側とダイ側の材料のき裂の会合のずれが大きくなり、発生するバリが高くなると考えられる。バリが高い領域である 02 部、04 部、06 部について 38.3 mm の区間について平均バリ高さを測定した結果を図 5.12 に示す。図 5.12 (a)は 02 部、(b)は 04 部、(c)は 06 部の測定結果であり、横軸はショット数、縦軸はバリ高さを表す。02 部および 04 部の領域については、ばらつきはあるもののショット数の増加にともないバリ高さが顕著に増加した。06 部についてもばらつきはあり、ショット数の増加にともなうバリ高さの増加は小さい結果であった。これは、06 部がコーナ R の最も小さい 05 部に隣接しているため、き裂が入りやすくなり、き裂の会合のずれが 02 部および 04 部と比較して小さくなったためと考えられる。以上の結果から、ショット数の増加にともなうバリ高さの増加が確認できた。

第5章 打抜きにおけるバリ高さ推定実験

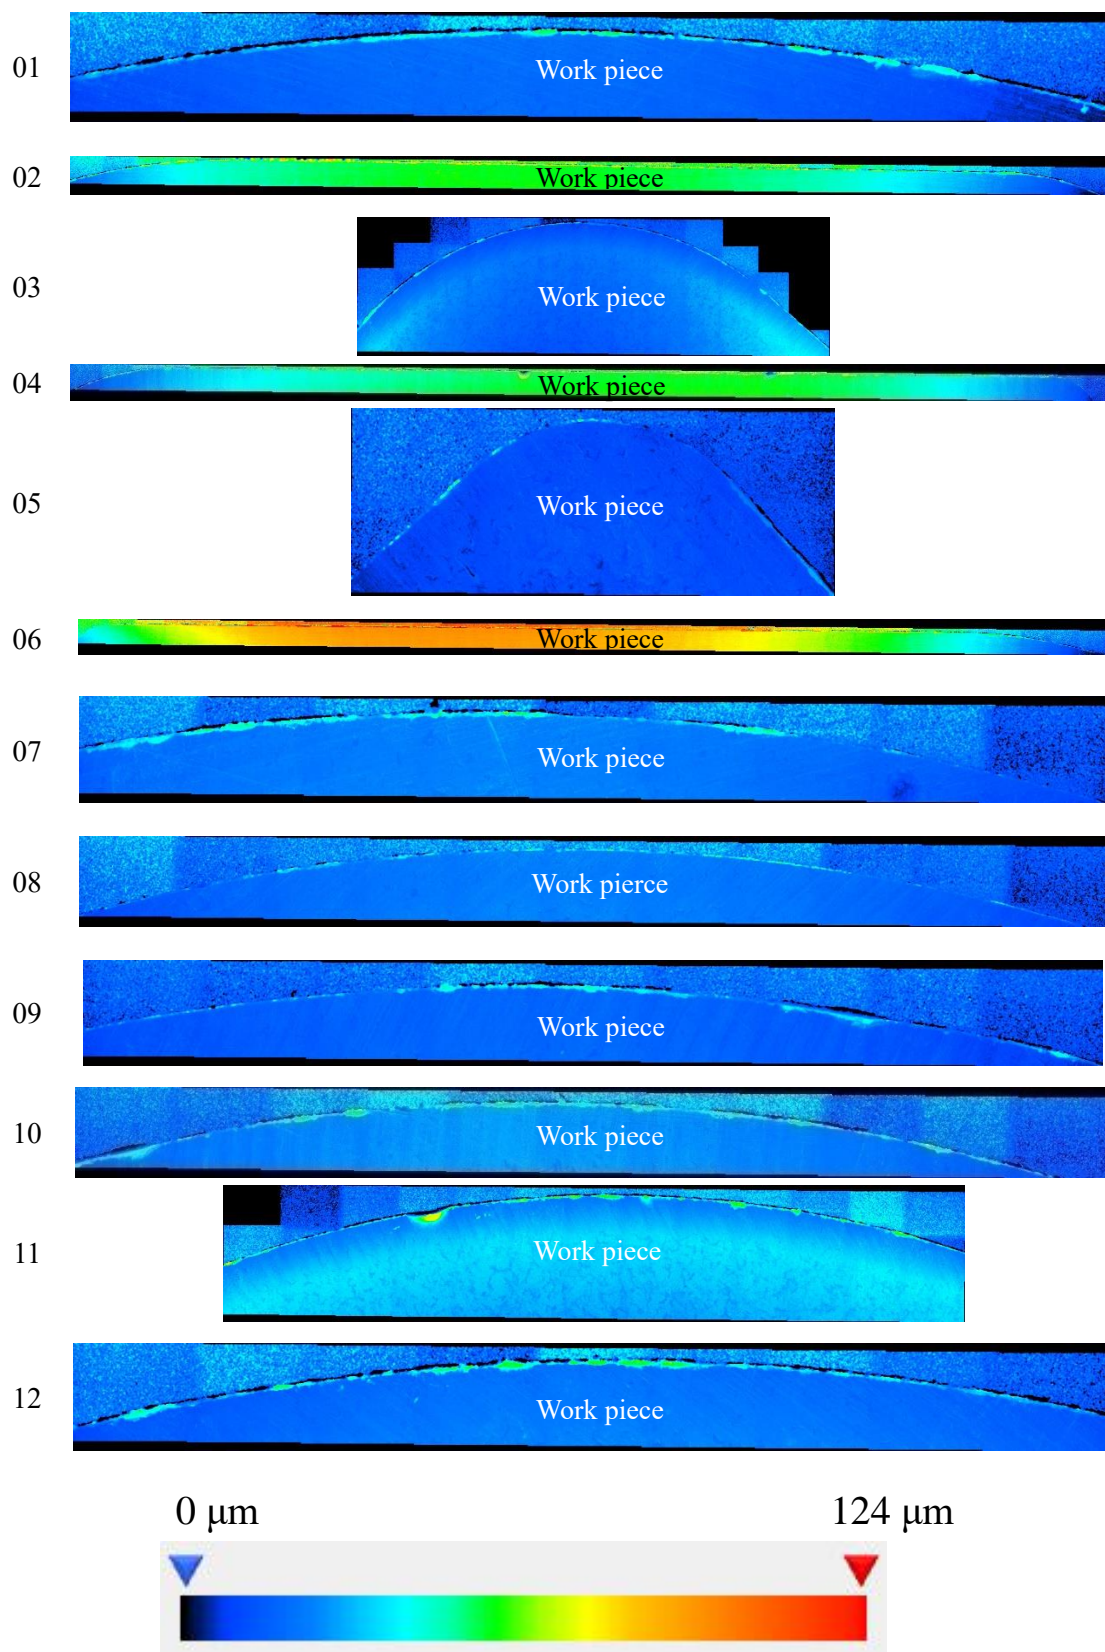


Fig. 5.8 Height data of shot2.

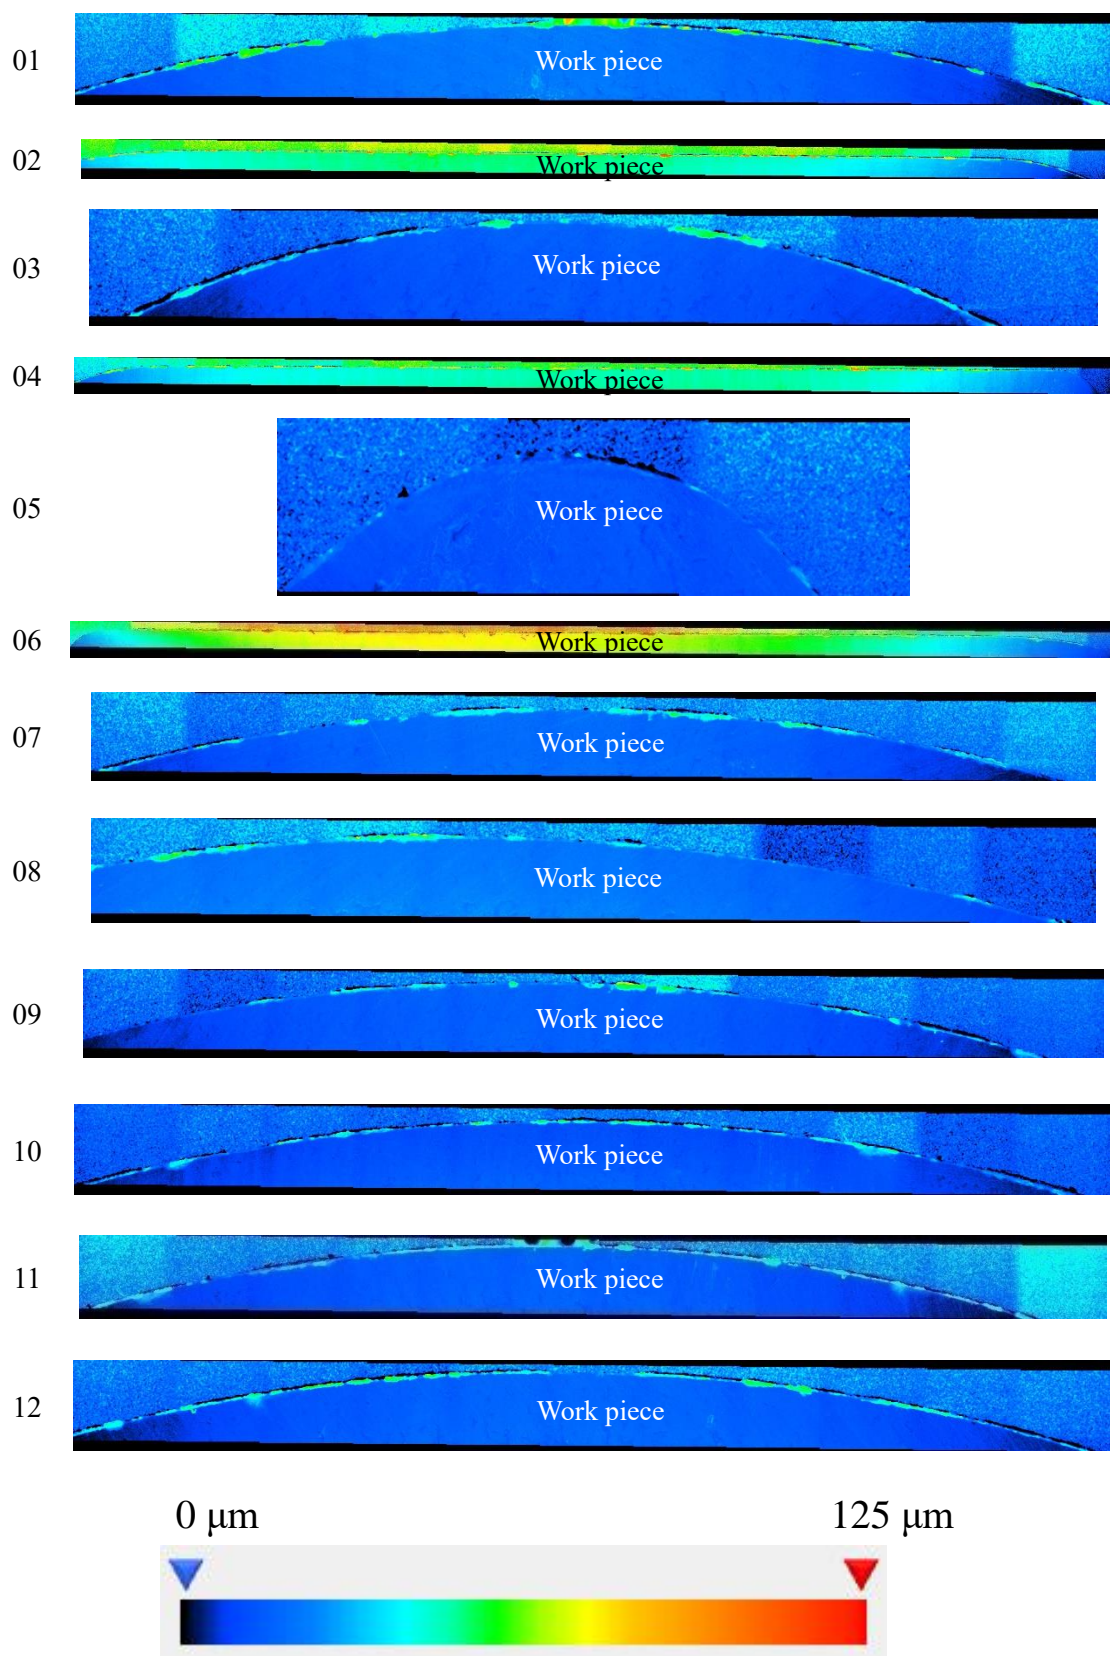


Fig. 5.9 Height data of shot819.

第5章 打抜きにおけるバリ高さ推定実験

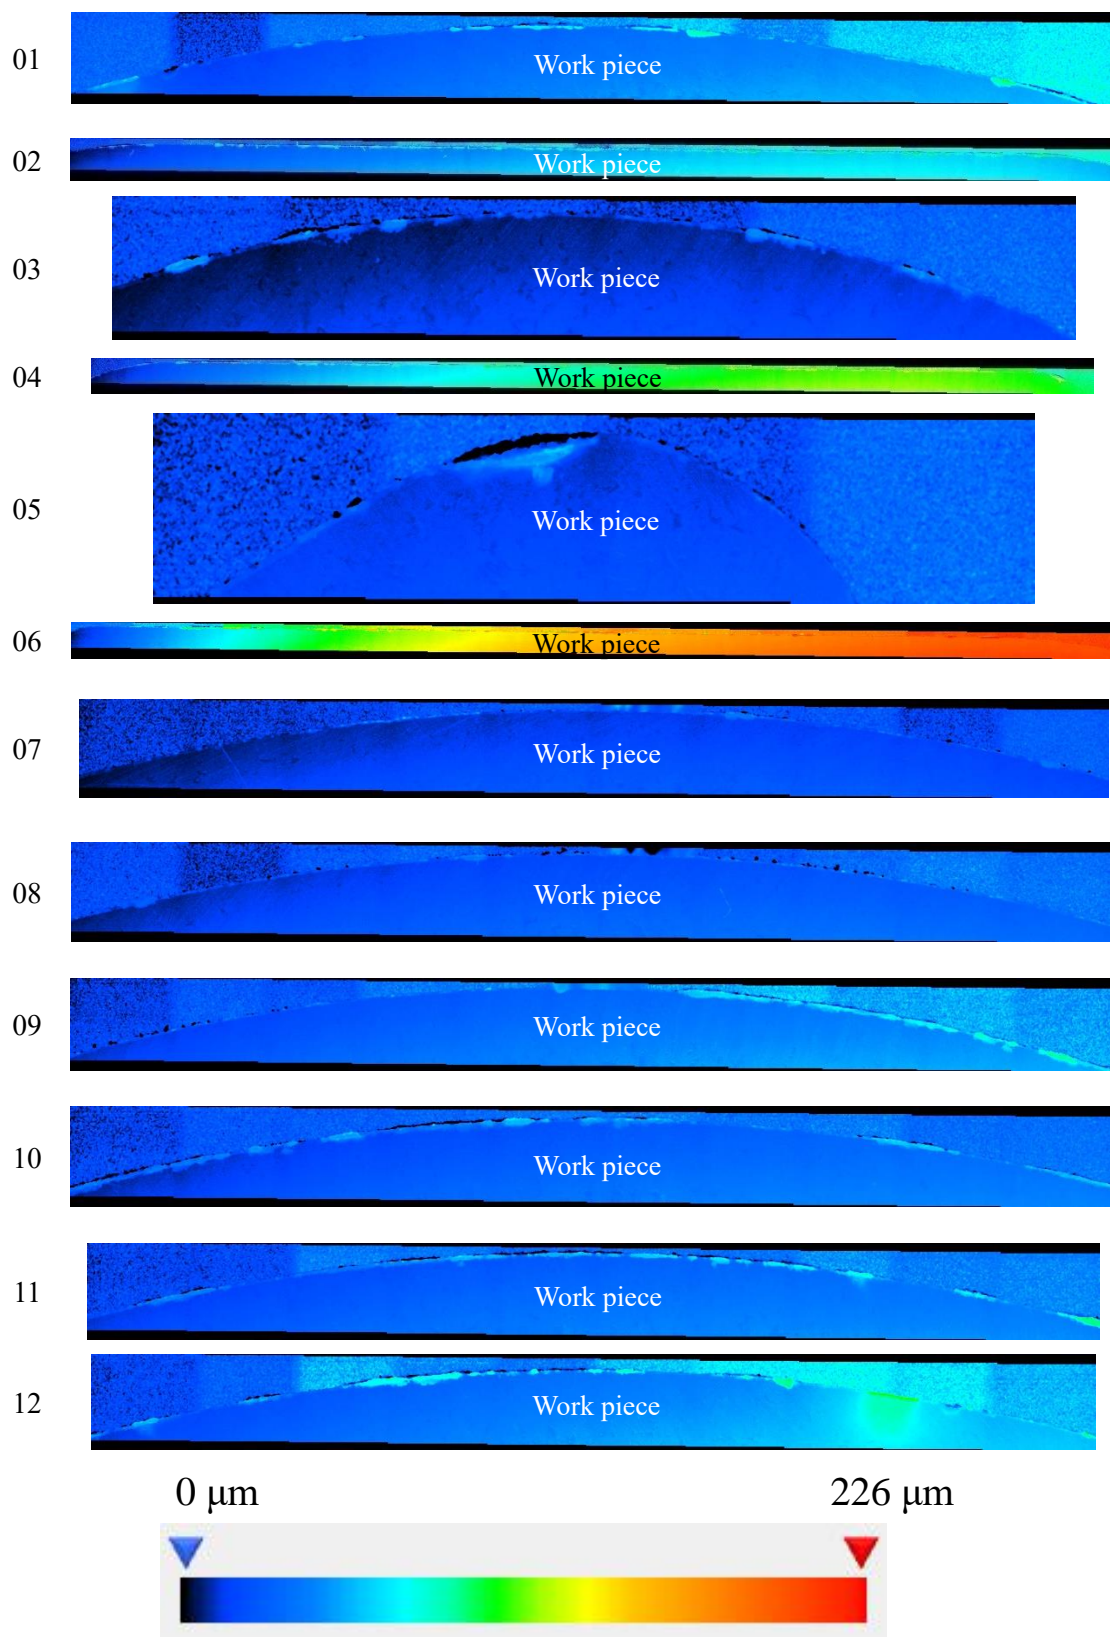


Fig. 5.10 Height data of shot1498.




Fig. 5.11 Burr height data for each region.

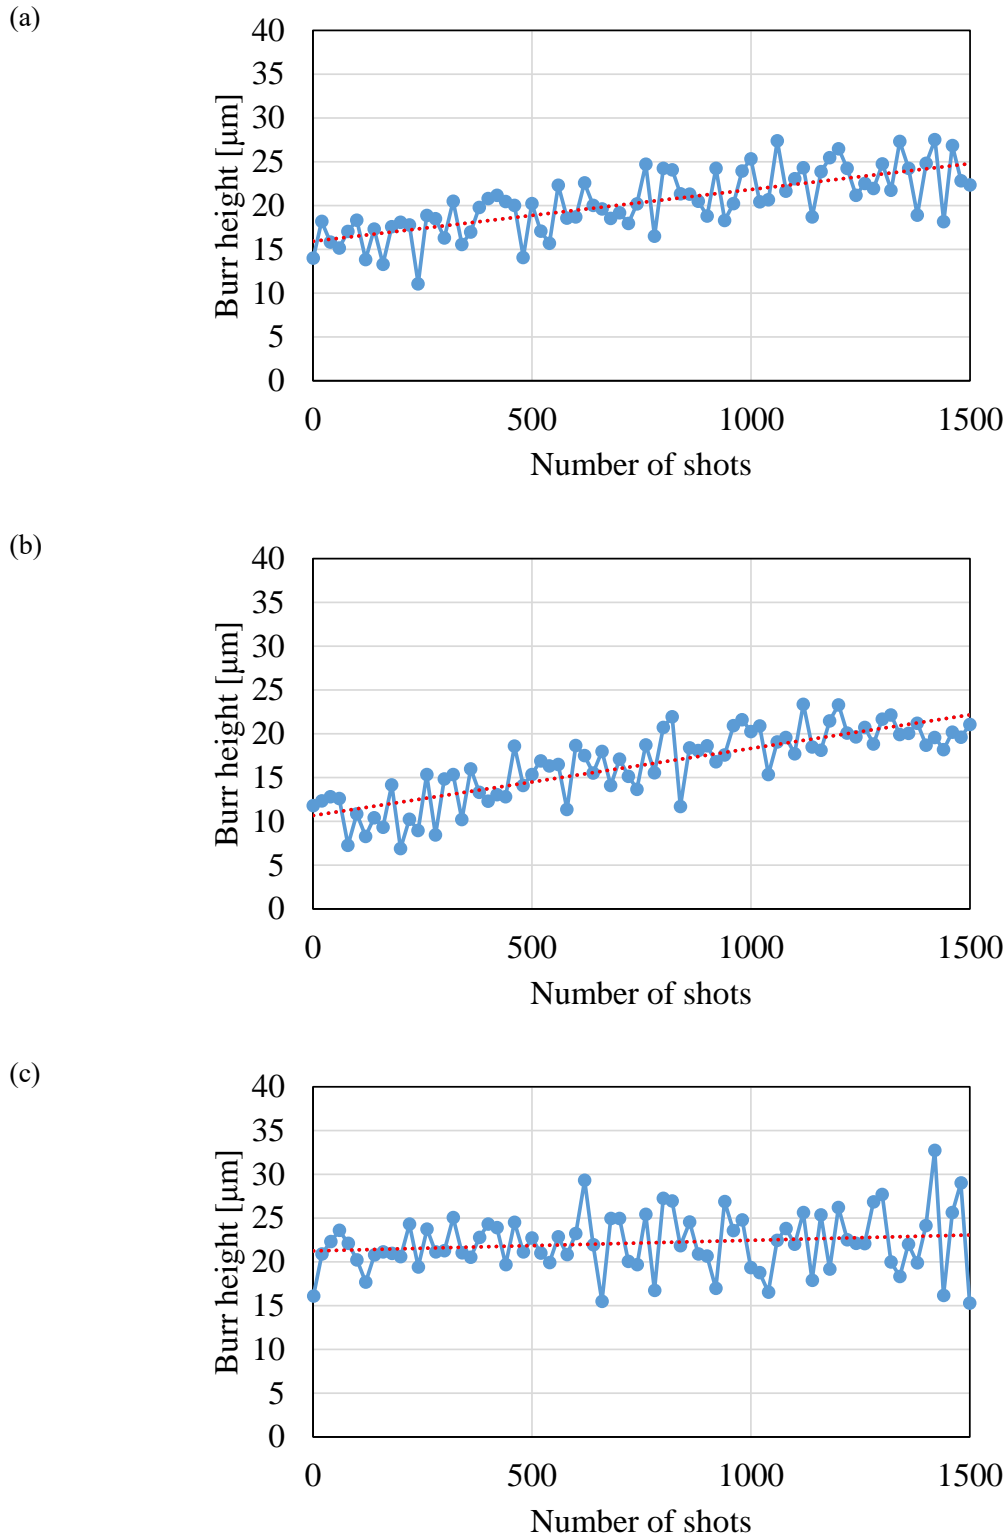


Fig. 5.12 Average data of burr height.

(a) Region 02. (b) Region 04. (c) Region 06.

5.3.4 残留応力との相関

バリについて更なる検討を行うため、加工品のバリ高さと残留応力の相関について調査した。残留応力の測定に使用したポータブル型 X 線残留応力測定装置 μ -X360n (パルステック工業 株式会社) を図 5.13 に示す。測定は、加工品のバリ側の角部に垂直方向にて、X 線照射角 35° 、X 線照射径 2 mm、深さ 10 μm 、 $\cos \alpha$ 法にて行った。測定した残留応力とバリ高さについてまとめた結果を図 5.14 に示す。図 5.14 (a)は 2 ショット、(b)は 819 ショット、(c)は 1498 ショットの加工品の結果である。加工品の内周に配置した値はバリ高さの測定結果で単位は μm 、加工品の外周に配置した値は残留応力の測定結果で単位は MPa である。赤字で示した値がそのショットでの最大値を表す。2 ショットの残留応力の最大値となった場所と、819 ショットの残留応力の最大値となった場所、1498 ショットの残留応力の最大値となった場所は一致しなかったが、加工品の上部の直線部かその周辺となる傾向であった。また、2 ショットのバリ高さの最大値となった場所と、819 ショットのバリ高さの最大値となった場所、1498 ショットのバリ高さの最大値となった場所についても一致しなかったが、直線部となる傾向であった。2 ショット、819 ショット、1498 ショットにおいて、バリ高さの最大値の位置と残留応力の最大値の位置も一致しなかった。残留応力のみでバリ高さを判断することは困難と言えるが、残留応力の最大値は直線部かその周辺で確認されており、加工品の全周におけるバリ高さの最大値の傾向が直線部であることと概ね一致した。これらのことから、残留応力によりバリ高さの傾向を把握できる可能性がある。




Fig. 5.13 Portable X-ray residual stress measuring device.

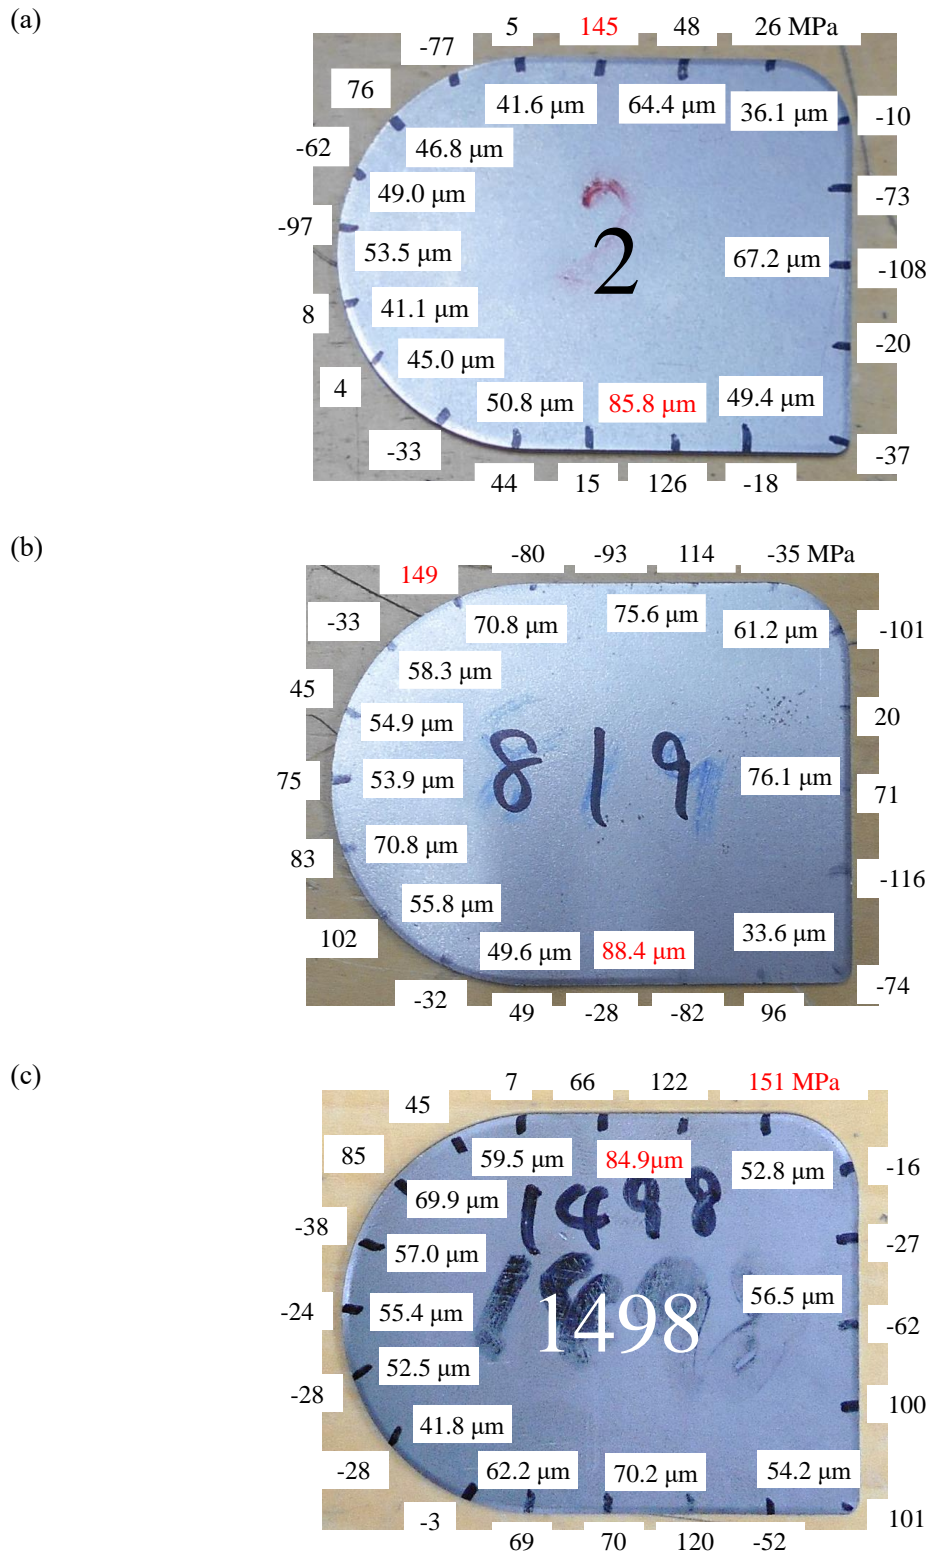


Fig. 5.14 Residual stress and burr height.

(a) Shot2. (b) Shot819. (c) Shot1498.


5.3.5 金型摩耗との相関

バリと金型摩耗の相関について調べるため、前節で使用したレーザ顕微鏡を用いて加工前と 1500 ショット加工後のパンチ表面の高さを測定し、金型摩耗量を算出した。加工前のパンチ表面を図 5.15 に、1500 ショット加工後のパンチ表面を図 5.16 に示す。図 5.15 と図 5.16 とともに (a)は加工前のパンチの天面、(b)は加工前のパンチの R10 方向、(c)は加工前のパンチの R2 方向から観察した写真である。加工前と加工後を比較すると、角部に外観上の変化が確認できる。また、R 部においてはパンチの上下方向においても外観上の変化が確認できる。これらは加工により表面が摩耗したためと考えられる。次に、加工前のパンチ表面の高さ測定結果を図 5.17 に、1500 ショット加工後のパンチ表面の高さ測定結果を図 5.18 に示す。上部の写真はレーザ顕微鏡によりパンチ表面を撮像した写真、下部のグラフはレーザ顕微鏡により測定した上部の写真の破線上の高さであり、加工前後で外観上の変化があった領域に分割したセクション A と B についてそれぞれ算出した区間平均値も示している。なお、セクション B の幅は 1.8 mm である。加工前のセクション A と B の区間平均値の差は 3.1 μm 、加工後のセクション A と B の区間平均値の差は 12.8 μm であり、加工後の差が増大した。この結果より、1500 ショットの加工によりパンチの摩耗が進行したことがわかる。

(a)



(b)



(c)




Fig. 5.15 Die before blanking.

(a) Top. (b) R10 direction. (c) R2 direction.




Fig. 5.16 Die after blanking 1500 shot.

(a) Top. (b) R10 direction. (c) R2 direction.

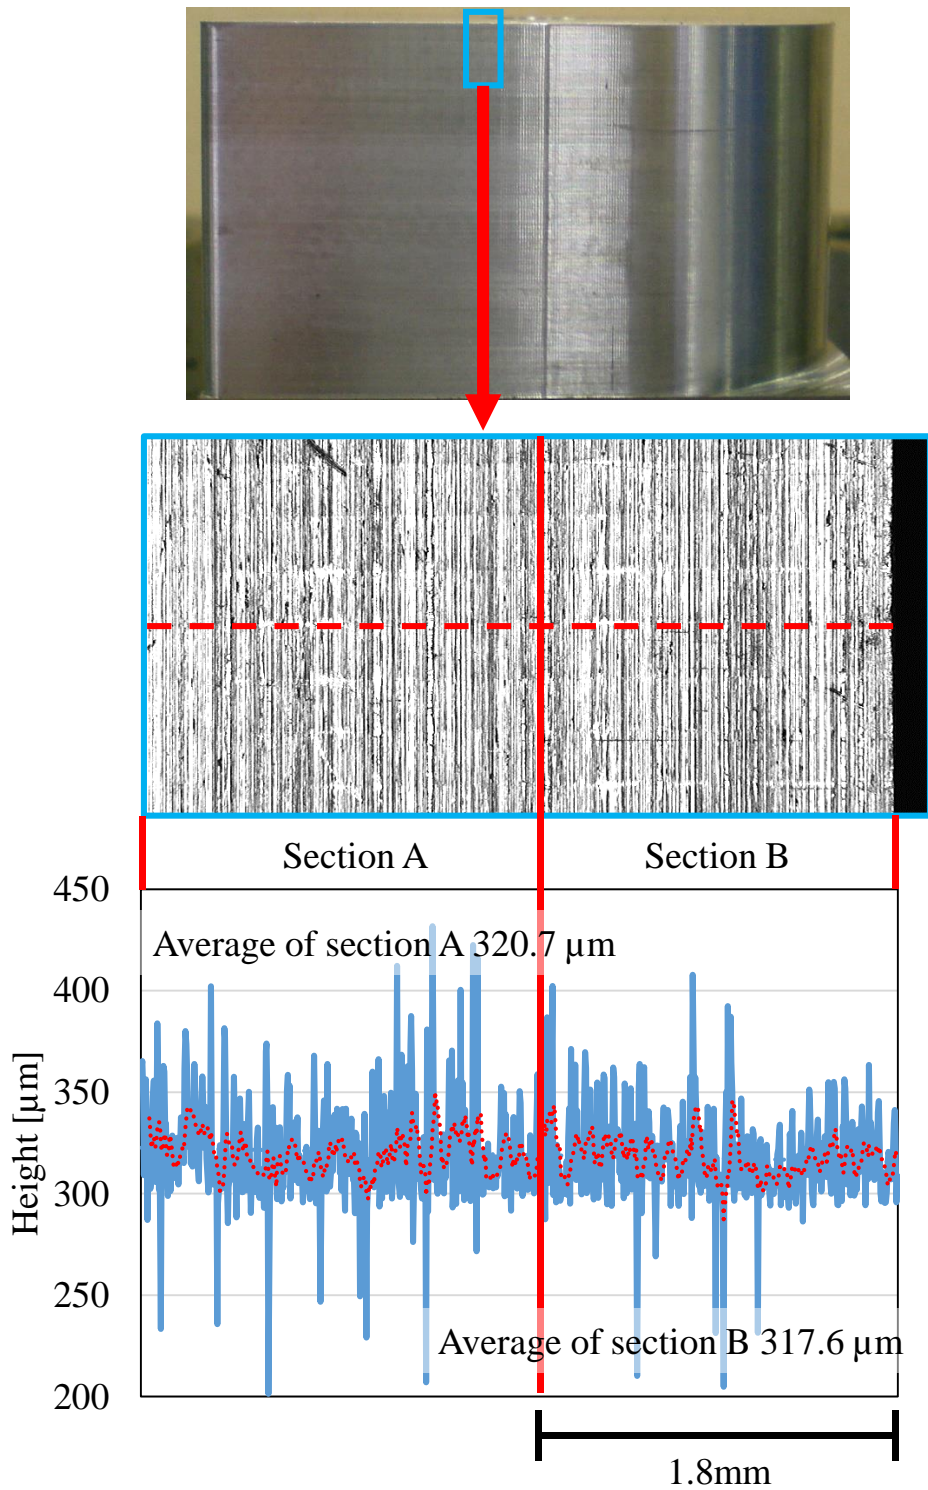


Fig. 5.17 Height data of die before blanking.

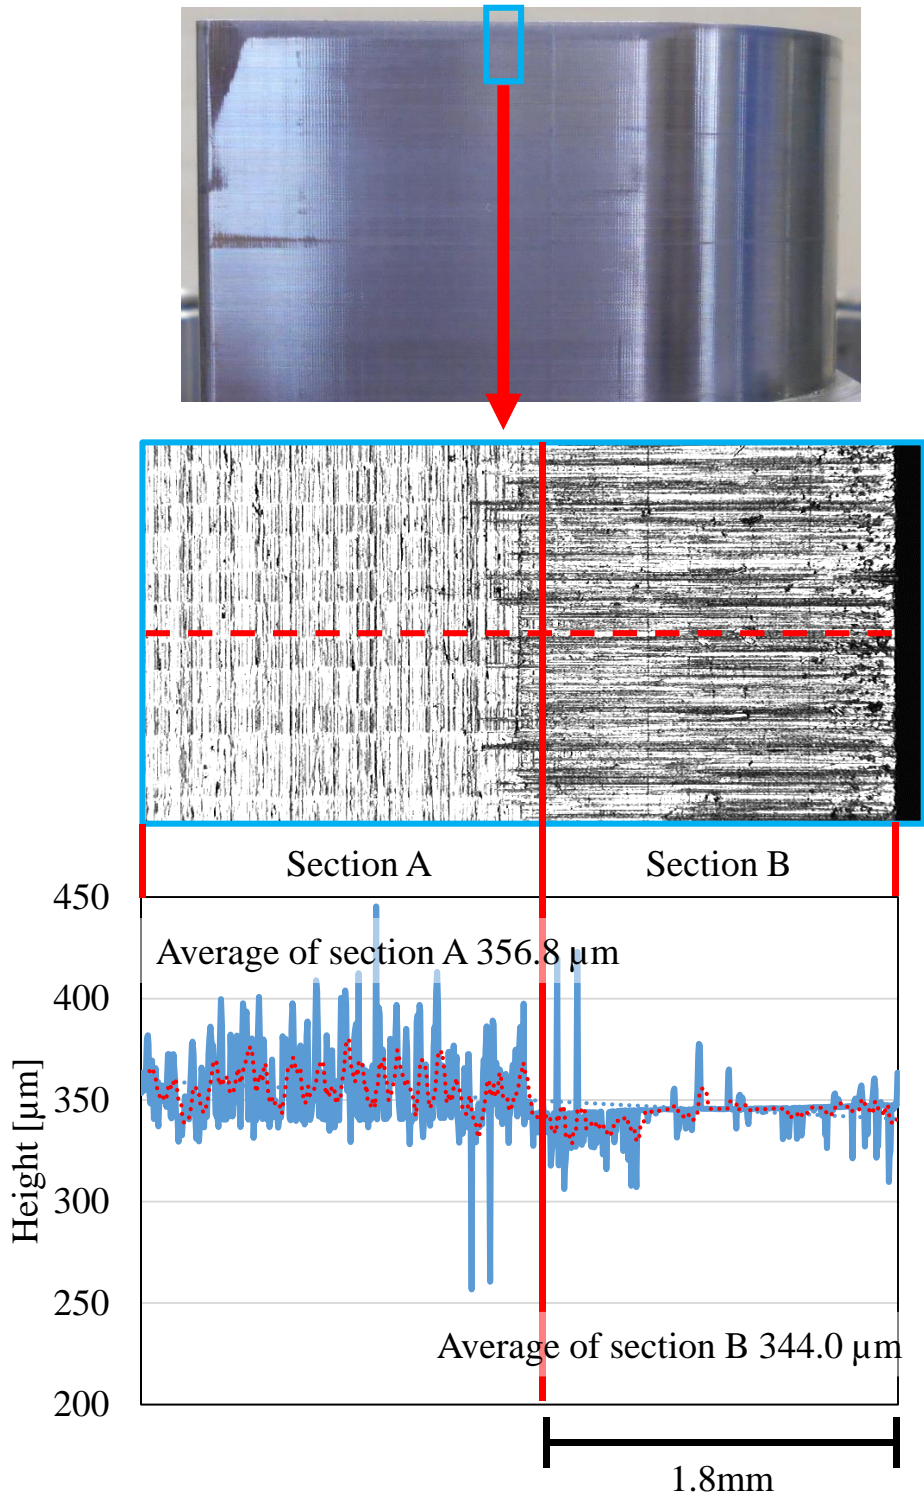


Fig. 5.18 Height data of die after 1500 shot.

5.4 打抜きにおけるデータ測定

5.4.1 実験装置

実験装置の概要を図 5.19 に示す。AE センサは前章までと同じもの、アナログ入力装置は EDX-10B (協和電業 株式会社)、ひずみゲージは KFG-2-120-C1-11LL3M3R (協和電業 株式会社)、加工荷重計はサーボプレスに付属のものを使用した。ひずみゲージの貼り付け位置を図 5.20 に示す。ひずみゲージは、金型の構造や剛性に影響を与えないよう、ダイの裏側に幅 5 mm、深さ 5 mm のサイズに加工した溝へ専用接着剤を用いて貼り付けた。なお、貼り付け場所は R2, R10, R25 の中心部のダイ側壁より 5 mm 離れた位置とした。

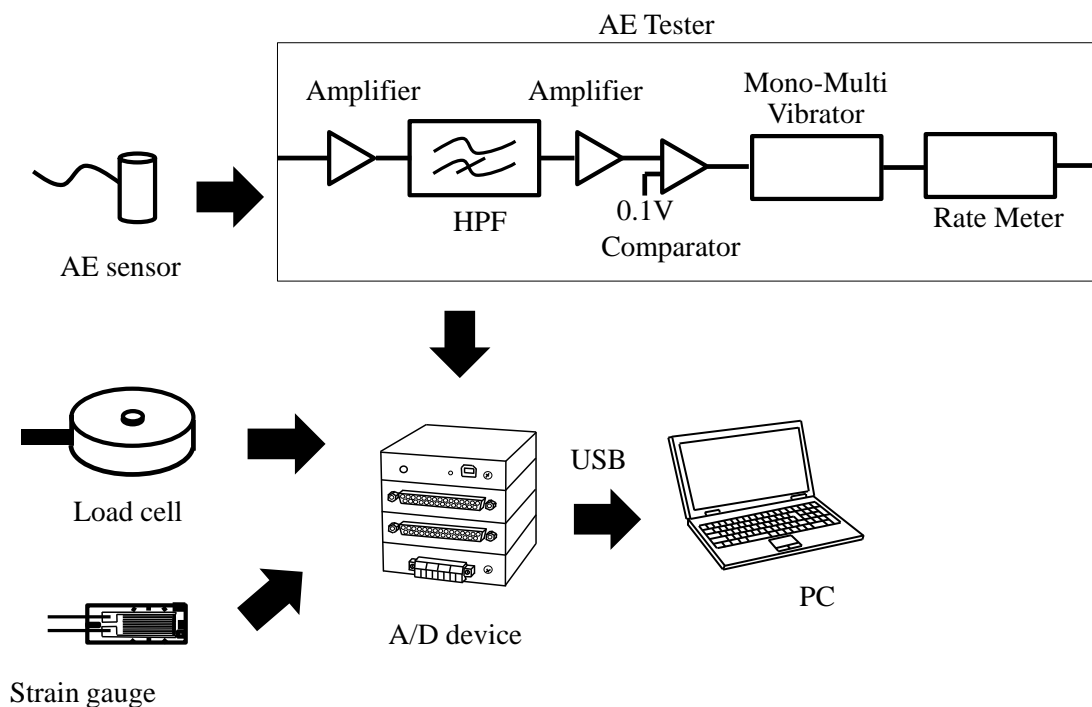


Fig. 5.19 Schematic illustration of the data acquisition system.




Fig. 5.20 Strain gauge attachment position.

5.4.2 実験条件

AE センサは前章と同様に共振周波数 70 kHz のものを用いた。AE テスタにおいても前章と同様であり、AE 信号は、入力信号に 20 倍のゲインの増幅と 100 kHz を閾値とするハイパスフィルタ処理を行った後、0.1 V を閾値としてカウントレートをコンパレータによってカウントした。AE 信号は AE テスタを介してアナログ入力デバイスへ入力し、加工荷重、ひずみは直接アナログ入力デバイスへ入力した。アナログ入力デバイスからは 2 msec のサンプリングタイムにて AE データ、加工荷重データ、ひずみデータを PC に収録した。

5.4.3 実験結果および考察

打抜きで得られた AE データを図 5.21 に示す。横軸は時間、縦軸は単位時間当たりの AE 波形発生数のカウントレートである。データは 1 ショット分の時間を収録している。1500 ショット分のデータのうち、1 ショット、300 ショット、600 ショット、900 ショット、1200 ショット、1500 ショットのデータを抜粋して示している。200 msec 周辺にピークがあり、ばらつきはあるものの概ねショット数の増加にともない最大値も増加している。このことから、加工状態の変化が AE データに表れていると言える。次に、加工荷重データを図 5.22 に示す。横軸は時間、縦軸は荷重である。AE データと同様に 1 ショット分の時間を収録しており、抜粋したショットのデータを示している。図 5.22 (a) はデータの全体、(b) はピーク周辺の拡大である。150 msec 周辺にピークがあり、データの全体ではショット数の違いによるピークの最大値の違いは確認できないが、200 msec 付近の波形に違いがあるように見える。ピーク周辺を拡大したデータを見ると、ばらつきはあるがショット数の増加にともない最大値が増加傾向にある。以上から、加工状態の変化が加工荷重データに表れていると言える。最後に、ひずみデータを図 5.23 に示す。横軸は時間、縦軸はひずみ値である。AE データ、加工荷重データと同様に 1 ショ

ット分の時間を収録しており、抜粋したショットのデータを示している。図 5.23 (a)は R2, (b)は R10, (c)は R25 付近のひずみデータである。150 msec 付近に下向きのピークがあり、R2 と R25 ではショットの違いによる変化が確認できる。また、R2, R10, R25 に共通して、150 msec から 250 msec の範囲でショットの違いによる変化が確認できる。以上から、加工状態の変化がひずみデータに表れていると言える。これらの結果から、AE データ、加工荷重データ、ひずみデータには、加工状態の変化を表すデータが含まれていると言えるが、単純な閾値などの手法ではその区別は困難と考えられる。




Fig. 5.21 AE count rate data of blanking.

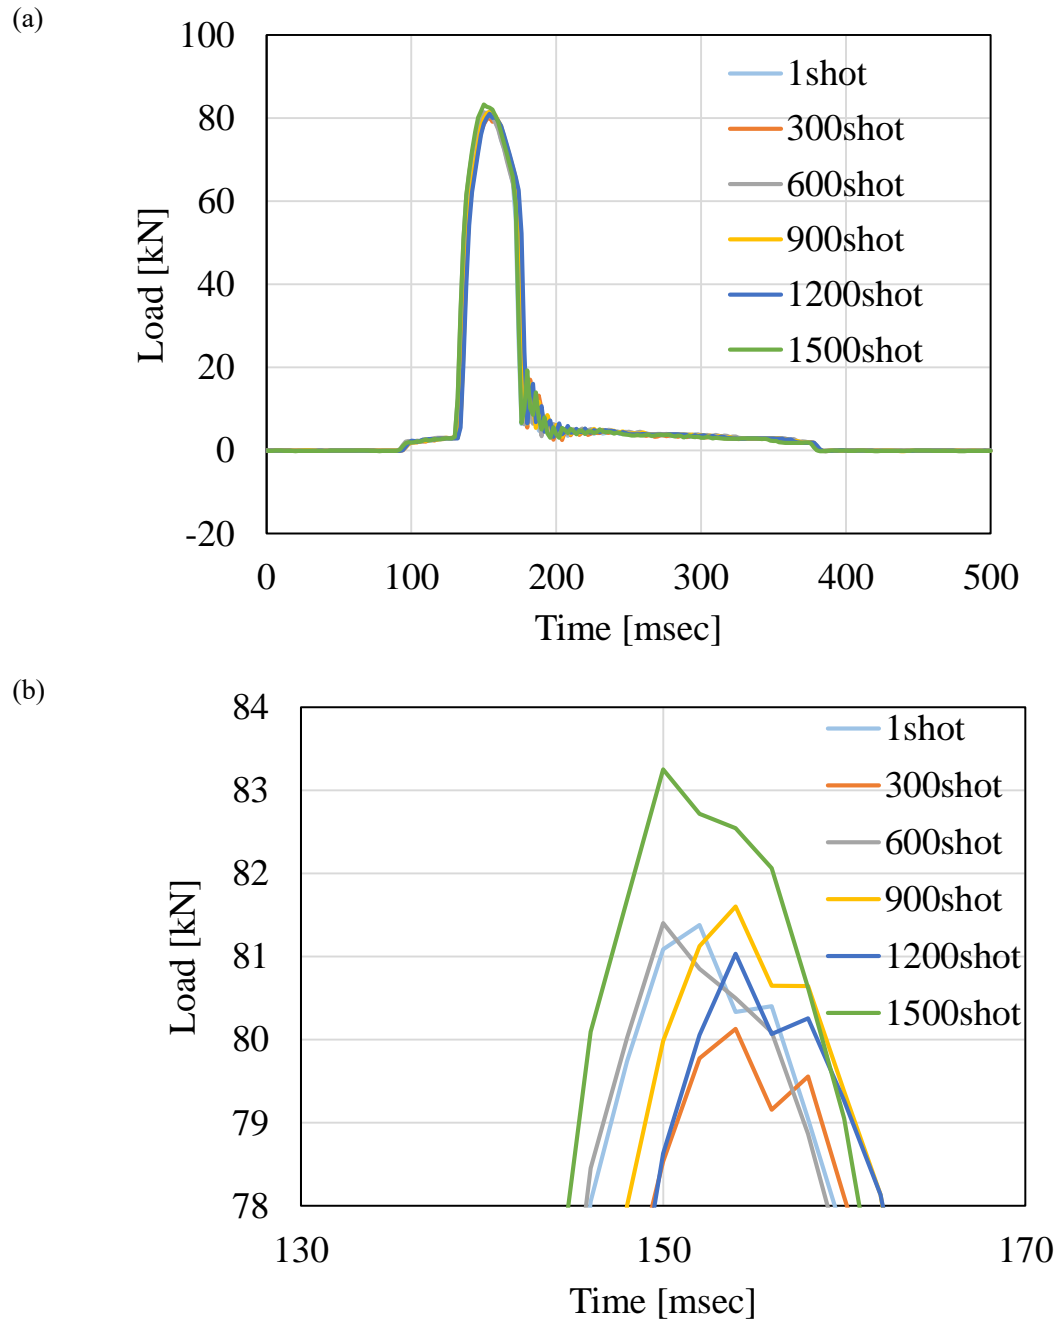


Fig. 5.22 Blanking load data of blanking.
 (a) Overall. (b) Enlarged view of the peak.

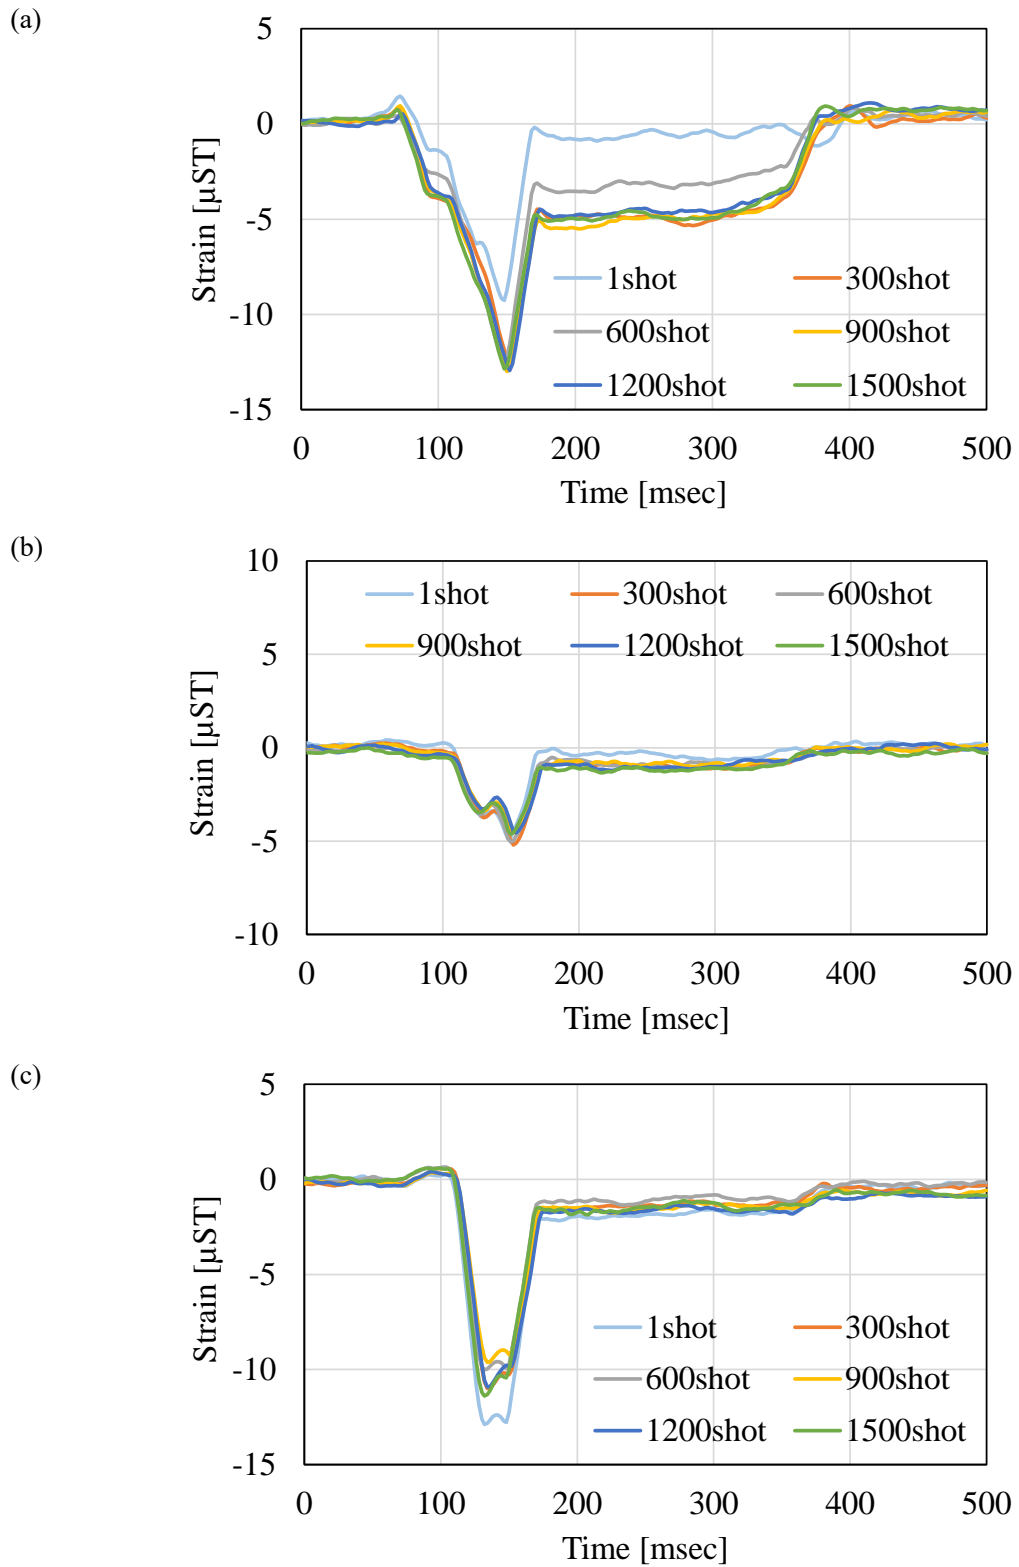


Fig. 5.23 Strain data of blanking.

(a) R2. (b) R10. (c) R25.

5.5 打抜きにおける測定データの解析

5.5.1 データ解析方法

前節の測定データから、1ショット中のデータの変化や1500ショットから間引いて抽出したデータではあるがショットの違いによるデータの変化が確認できた。そこで次に、各測定データにおいて、全ショット数を対象にデータの変化を解析した。AEデータおよび加工荷重データについてはピーク部分における最大値、ひずみデータについては下向きのピーク部分における最小値について、それぞれショット数の増加との関係を解析した。

5.5.2 データ解析結果と考察

データの解析結果を図5.24に示す。図5.24(a)はAEデータで横軸はショット数、縦軸は単位時間当たりのAE波形発生数のカウントレートの最大値、(b)は加工荷重データで横軸はショット数、縦軸は荷重の最大値、(c)はひずみデータであり、各図の横軸はショット数、縦軸はひずみ値の最小値である。AEデータおよび荷重データについては、落ち込みによる大きな変化はあるものの、概ねショット数の増加にともない最大値も増加傾向と言える。この落ち込み部分については、荷重が変化していることからパンチの切れ味に大きな変化が発生していると考えられる。ひずみデータについては、加工初期で落ち込み部分はあるもののR10とR25では概ねショット数の増加にともない最小値が大きくなる傾向がある。R2については、勾配がやや増加傾向にある。加工初期の落ち込みについては、温度変化などの外乱が主な原因と推察されるが、ショット数が増加するにつれて金型自体の温度が上昇し外乱の影響が限定的となり最大値の変化が比較的安定していると考えられる。以上の結果から、測定データを1ショットごとに解析することで、ショット数の増加に対する測定データの変化を確認することができ、加工状態の変化すなわちバリ高さの変化を把握できる可能性を見出した。しかしながら、単純

な閾値などの手法の適用は困難であり、かつ、最大値や最小値の単一な特徴量だけではなく、1ショット中の全ての変化を活用する必要がある。

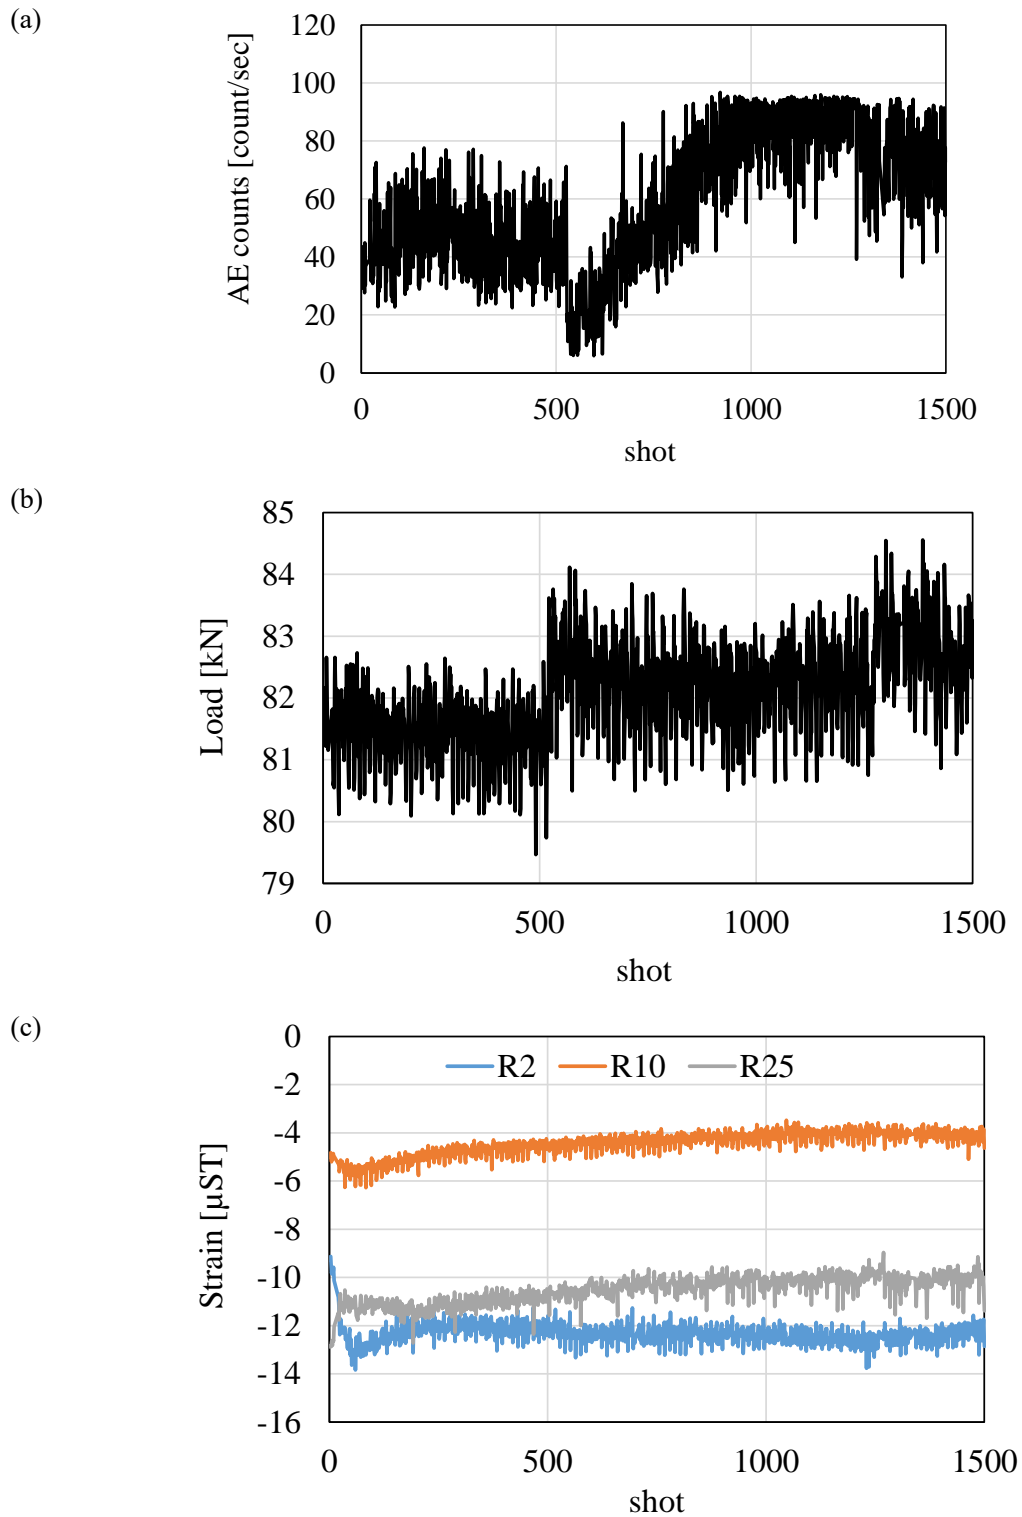


Fig. 5.24 Result of data analysis.

(a) Maximum value of AE count rate. (b) Maximum value of blanking load.

(c) Minimum value of strain.

5.6 機械学習によるバリ高さ推定実験

5.6.1 実験環境

前節では構築したデータ測定システムにより、ショット数の増加を反映したデータを得ることができ、データを用いたバリ高さ推定の可能性を示した。しかしながら、バリ高さの推定に有効な情報が含まれているものの、ばらつきや突発的な変化などがあり、近似直線などの従来の方法では推定が不十分と言える。そこで測定データを用いたバリ高さ推定実験を行うにあたり、認識精度向上を期待し機械学習を用いた。バリ高さ推定実験は、Chainer を用いたバリ高さ推定システムを構築して行った。構築した実験環境を表 5.1 に示す。Chainer については、前章で述べた通りニューラルネットワークの構築と評価の同時実行や GPU の使用により高速な計算が可能で、様々な損失関数や最適化手法が利用でき、多層や複雑なネットワークを簡単に柔軟に記述できるなどの特徴を持つ。

Table. 5.1 Computer specifications, software version.

CPU	Intel Core i7-6700K 4.00 GHz, 4 cores 8 threads
Memory size	16 GB DDR3, Non-ECC
GPU	NVIDIA GeForce GTX980Ti, 6 GB GDDR5
OS	Ubuntu 16.04.6 LTS
Versions of Chainer	5.3.0

5.6.2 実験条件

実験に使用したネットワークの構成を図 5.25 に示す。各層は全結合、入力層のノード数 251、隠れ層のノード数 500、出力層のノード数はバリ高さを出力するため 1 とした。最適化手法は Adam、活性化関数は ReLU を用いた。前章に述べた通り、Adam は RMSprop で発生する指数移動平均によるバイアスを打ち消した最適化を行う手法、ReLU は入力値 x が負であれば出力値は 0、入力値 x が正であれば出力値 y は線形に増加する活性化関数である。また、学習データの前処理として外れ値に強い標準化と、標準化よりもさらに外れ値に強いロバスト z スコアを行った。標準化は、平均を原点、各軸の標準偏差を 1 とする処理であり、ロバスト z スコアは平均を中央値、四分位範囲を 1 とする処理である。




Fig. 5.25 The configuration of the network.

5.6.3 使用データ

打抜き中に得られたデータの解析により、AE データ、加工荷重データ、ひずみデータの全てにおいてショット数増加にともなう傾向が確認でき、バリ高さ推定の可能性を示した。そこで、バリ高さ推定には AE データ、加工荷重データ、ひずみデータの全てを用いる。データは、打抜きの 1 ショットが全て測定できるよう、251 点、500 msec を収録した。なお、近接スイッチによりプレス機のスライドが所定の位置に降下した事をトリガとし、データ収集開始のタイミングを揃えた。バリ高さのデータについては、02 部を対象とし 1500 ショット分のデータの近似直線を求め、近似直線からの差を用いた。

5.6.4 実験方法

バリ高さの推定は、図 5.26 に示すように入力層の 251 個のノードに 1 ショット分 251 点の AE データ、加工荷重データ、ひずみデータ (3 種)、計 5 種類のそれぞれのデータを 5 次元データとしてノードそれぞれに入力し、入力データに対するバリ高さを入力する。1 ショットから 1500 ショットまでの 20 個おきのデータ 76 個に対して、85%相当の 1300 ショットまでの 66 個を学習データとし、学習用データの中からランダムに選んだ 20 個を用いた学習を 1000 回繰り返した。最後に、学習済みモデルを用いて 76 個のデータ全てに対してバリ高さ推定実験を行い、学習に用いていない未知部分の推定値の誤差を比較した。

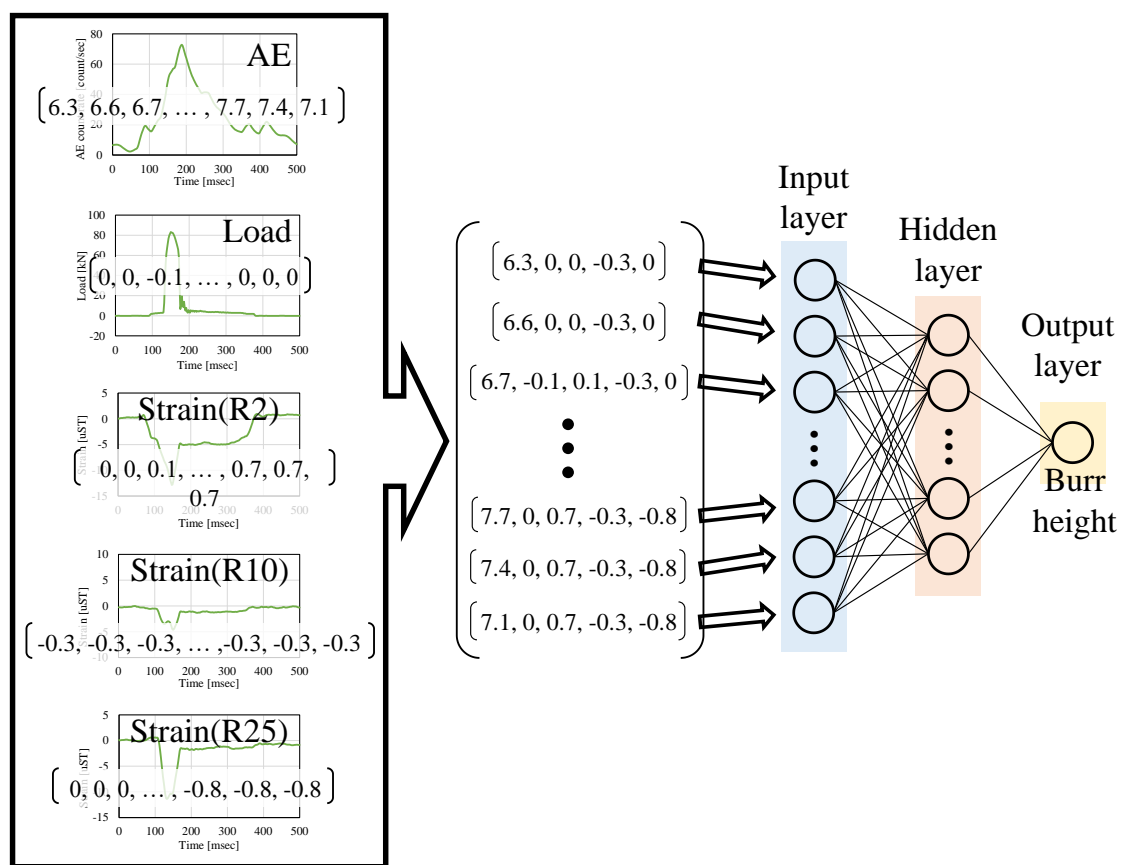


Fig. 5.26 Input data.

5.6.5 実験結果と考察

バリ高さの推定実験結果を図 5.27 に示す。横軸は実験条件を示し、縦軸は測定値と推定値の誤差を示す。誤差はそれぞれ 5 回の推定実験の平均値である。A は隠れ層 1 層で前処理なし、B は隠れ層 10 層で前処理なし、C は隠れ層 10 層で標準化、D は隠れ層 10 層でロバスト z スコアを行った結果であり、図中の数値は測定値と推定値の誤差絶対値の平均値を示している。隠れ層の数は多い方が誤差は小さいことがわかったが、隠れ層数 50 および 100 で同条件の推定実験を行ったところ、パラメータが収束せず、推定値を得られなかった。そのため、隠れ層の数は多いほど良好な結果が得られるわけではなく、適正な数があると言える。また、前処理の効果であるが、標準化は処理なしと比べるとわずかではあるが誤差は拡大した。一方、ロバスト z スコアは処理なしと比べて誤差が減少しており、外れ値の処理が推定精度に影響すると考えられる。

次に、A のバリ高さの推定例を図 5.28 に B のバリ高さの推定例を図 5.29 に、C のバリ高さの推定例を図 5.30 に、D のバリ高さの推定例を図 5.31 に示す。横軸はショット数、縦軸はバリ高さで、バリ高さの推定値と測定値を示している。また、学習に使用した 1300 ショットまでのデータと学習に使用していない未知のデータとの境界を赤線で示している。A では学習に使用したデータにおいても推定誤差が見られる。これは、隠れ層が少ないと、パラメータの合わせこみが不十分になるためと考えられる。B、C、D では、学習に使用したデータにおいて推定誤差はほとんどないことから、適切な隠れ層の数を設定することにより、学習データに対するパラメータの設定が良好に行えることが確認できた。B は、学習に使用していない未知のデータに対する推定で測定値のばらつきの傾向に近いが差がある。C、D では、まだ誤差はあるものの、測定値のばらつきの傾向と一致しており差も小さくなっている。以上のことから、機械学習の前処理は、推定精度向上に有効と考えられる。




Fig. 5.27 Results of burr height estimation experiment.

A: The number of hidden layers is 1, and no preprocessing.

B: The number of hidden layers is 10, and no preprocessing.

C: The number of hidden layers is 10, and the preprocessing is the standardization.

D: The number of hidden layers is 10, and the preprocessing is the Robust z-score.




Fig. 5.28 Results of burr height estimation experiment A.
(The number of hidden layers is 1, with no preprocessing.)




Fig. 5.29 Results of burr height estimation experiment B.
(The number of hidden layers is 10, with no preprocessing.)




Fig. 5.30 Results of burr height estimation experiment C.
(The number of hidden layers is 10, with the standardization preprocessing.)




Fig. 5.31 Results of burr height estimation experiment D.
(The number of hidden layers is 10, with the Robust z-score preprocessing.)

5.7 結言

本章では、打抜きにおける AE、加工荷重、ひずみのデータ測定と製品のバリ高さを測定し、ショット数の増加と測定データおよびバリ高さについて解析した。また、測定データとバリ高さの分析結果を基に機械学習を用いた打抜きにおけるバリ高さ推定実験を行った。その結果、以下の結論を得た。

- (1) 金型材質として硬度の低い AISIP21 を選択し 1500 ショットの打抜き加工実験を行った結果、加工初期と終期の比較によりバリ高さが増加していることが確認できた。
- (2) 1500 ショット分の加工品のバリ測定を行った結果、R 部よりも直線部でバリ高さが大きい傾向を確認した。R 部と比較して直線部ではき裂の発生が遅く、き裂の会合のずれが大きくなるためと考えられる。
- (3) ばらつきが大きいものの、ショット数の増加に伴いバリ高さも大きくなった。これは、金型摩耗の進行に伴うと推察される。
- (4) パンチ表面の状態の観察と摩耗量の測定を行った結果、1500 ショットの加工の初期と末期で $9.7 \mu\text{m}$ の変化が確認でき、摩耗が進行していることがわかった。
- (5) 打抜き中の AE、加工荷重、ひずみのデータ測定と得られたデータの解析を行った結果、ショット数の増加に伴うデータの変化が確認できたことから、取得したすべてのデータは加工状態の情報を含むと考えられ、バリ高さ推定の可能性を確認した。
- (6) 打抜き中の測定で得られた AE、加工荷重、ひずみのすべてのデータによるバリ高さ推定実験を行った結果、隠れ層の数は適切な数があること、また前処理により精度が向上することが明らかになった。バリ高さは、最高で $2.61 \mu\text{m}$ の精度で推定ができた。データ数の積み上げや測定データのさらなる多次元化により推定精度の向上が期待できる。

第6章

総括

6.1 結論

本研究では、量産加工における品質向上や生産コスト低減を目的に、機械学習を用いた深絞りにおける加工状態認識と、打抜きにおけるバリ高さ推定について検討した。

機械学習を用いた深絞りにおける加工状態認識では、はじめに引張試験における AE 信号の測定と得られた AE データの特徴を明らかにし、試験片の状態判別の可能性を示した。次に、深絞りにおける AE 信号を測定し、得られたデータの特徴と引張試験時の特徴を比較した上で、機械学習を用いた深絞りにおける加工状態認識実験を行い、その有効性を示した。

機械学習を用いた打抜きにおけるバリ高さ推定では、はじめに打抜きにおける AE、加工荷重、ひずみのデータ測定と加工品のバリ高さを測定し、ショット数の増加と測定データおよびバリ高さについて解析し特徴を明らかにした。次に、測定データとバリ高さの解析結果を基に機械学習を用いた打抜きにおけるバリ高さ推定実験を行い、その有効性を示した。

以上の検討を行い、本研究で得られた結論を各章毎に以下で述べる。

第1章では、プレス加工において不良品の大量発生を防止するには、インプロセスで加工状態を認識することが求められることを示した。しかし、プレス加工は金型内部で行われるため直接のセンシングは困難であり、金型のセンシングが行われていることを示した。金型のセンシングでは、閾値などの単純な手法の適用は加工状態の認識精度に不安があり、機械学習を用いることにより高精度化が期待できることを示した。

総 括

第2章では、本研究で適用する機械学習について、アルゴリズムの分類とそれぞれの特徴、幾度か現れたブームと現在に至るまでの変遷、適用範囲や目的などの現在の状況、本研究で適用を図る手法の概要について述べた。

第3章では、引張試験における AE 信号を測定し、応力ひずみ線図と得られた AE 信号から、塑性変形時および破断時の波形データと周波数領域の特徴について明らかにするとともに、試験片の状態判別の可能性について検討した。その結果、塑性変形時は連続型 AE を、破断発生時は突発型 AE を確認した。また、塑性変形時および破断時に周波数領域での顕著なピークの存在を確認した。カウントレートにおいても塑性変形時は連続型 AE を、破断発生時は突発型 AE を確認できたことで、高速な処理で加工中に製品の割れなどの認識ができる可能性があることを明らかにした。

第4章では、深絞りにおける AE 信号とカウントレートの測定とデータ解析を行い、引張試験で得られた結果と比較し、深絞りの加工状態の認識における AE の有効性を確認した。その上で、機械学習を用いて深絞りにおける加工状態認識実験を行い、手法の有効性を検証した。その結果、深絞り中の AE 信号の測定と解析により、引張試験中の AE 信号の周波数領域と同じ特徴を確認し、深絞り中の加工状態認識の可能性を示した。さらに、AE データを用いたニューラルネットワークによる加工形状認識実験を行い、認識率は最大で 97.3% となり、本手法の有効性を明らかにした。

第5章では、打抜きにおける AE、加工荷重、ひずみのデータ測定と製品のバリ高さを測定し、ショット数の増加と測定データおよびバリ高さについて解析した。また、機械学習を用いた打抜きにおけるバリ高さ推定実験を行い、本手法の有効性を検証した。その結果、ショット数の増加にともないバリ高さが変化していることを確認した。さら

に、加工品の周囲のバリ高さの発生状況を解析し、R部よりも直線部でバリ高さが大きくなる傾向があることを明らかにした。また、加工実験前後のパンチ表面の観察と摩耗量の測定を行い、摩耗が進行していることを確認した。打抜き中のAE、加工荷重、ひずみのデータ測定と得られたデータの解析を行った結果、ショット数の増加にともなうデータの変化が確認でき、バリ高さ推定の可能性を示した。最後に、打抜き加工中の測定で得られたデータによるバリ高さ推定実験を行い、最高で $2.61\ \mu\text{m}$ の精度で推定ができ、本手法の有効性を明らかにした。

6.2 展望

深絞り加工を対象としたインプロセスでの加工状態認識に関し、本研究では、引張試験における AE の測定および解析、深絞りにおける AE の測定および解析を行い、得られた AE 信号から波形データと周波数領域の特徴を明らかにし、機械学習を用いた深絞りにおける加工状態認識実験により有効性を示した。しかしながら、認識率は 100%に到達しておらず、現状で現場適用した場合には不良品流出の危険性もある。そのため、認識率 100%を目指し、収録データ数の積み上げ、機械学習手法やパラメータの検討などが今後の課題である。

打抜き加工を対象としたバリ高さ推定に関し、本研究では、打抜きにおける AE、加工荷重、ひずみのデータ測定と製品のバリ高さを測定し、ショット数の増加にともなうバリ高さやデータの変化を確認した上でバリ高さ推定実験を行い、最高で 2.61 μm の推定精度が得られた。しかしながら、ショットによっては推定精度が悪い結果もあり、バリによる不良品を認識できない可能性もある。したがって、推定精度向上のため個々の加工品の代表値とするバリ高さの定義や測定方法の見直し、データ前処理手法や機械学習パラメータの検討などが今後の課題である。

文 献

- (1) 吉田弘美 著, プレス加工大全 (2015), 日刊工業新聞社
- (2) 玉井良清, 稲積透, 真鍋健一, FEM 成形解析による薄鋼板の絞り成形性向上に有効なプレスモーショントリプル制御の予測, 塑性と加工, Vol.55, No.636 (2014), pp. 34-38.
- (3) 四宮徳明, 白川信彦, 深絞り加工におけるサーボプレスモーシントリプル制御の評価-板厚および限界絞り比の測定と NC ダイクッションを用いた TZIP 試験-, 塑性と加工, Vol.54, No.629 (2013), pp. 542-546.
- (4) 古閑伸裕, 浅賀将義, クラチャートジュンラペン, 1050 アルミニウム板の NC サーボプレスを用いた振動深絞り加工としごき加工, 軽金属, Vol.57, No.6 (2007), pp. 240-244.
- (5) 久保達男, 北山哲士, 濱野智史, 西川輝, 木下洋, 山崎光悦, 可変ブランクホルダー力による角筒深絞り加工, 日本機械学会論文集 C 編, Vol. 76, No. 766 (2010), pp. 1617-1626.
- (6) 横山眞樹, 北山哲士, 河本基一郎, 野田拓也, 宮坂卓嗣, 越後雄斗, 薄板材成形における可変ブランクホルダー力とスライド速度の最適設計法, 日本機械学会論文集, Vol. 84, No. 863 (2018), pp. 2693-2703.
- (7) Yossifon, S., Messerly, D., Kropp, E., Shivpuri, R., Altan., A SERVO MOTOR DRIVEN MULTI-ACTION PRESS FOR SHEET METAL FORMING, International Journal of Machine Tools and Manufacture, Vol. 31, No. 3 (1991), pp. 345-359.
- (8) Obermeyer, E.J., Majlessi, S.A., A review of recent advances in the application of blank-holder force towards improving the forming limits of sheet metal parts, Journal of Materials Processing Technology, Vol. 75, No. 1-3 (1998), pp. 222-234.
- (9) 北山哲士, 濱野智史, 山崎光悦, 久保達男, 西川輝, 木下洋, 可変ブランクホルダー力による角筒深絞り加工, 日本機械学会論文集 C 編, Vol. 76, No. 766 (2010), pp. 1617-1626.
- (10) Koyama, H., Wagoner, R.H., Manabe, K., Blank holding force control in panel stamping process using a database and FEM-assisted intelligent press control system, Journal of Materials Processing Technology, Vol. 152, No. 2 (2004), pp. 190-196.
- (11) Osakada, K., Wang, C.C., Mori, K., Controlled FEM Simulation for Determining History of Blank Holding Force in Deep Drawing, CIRP Annals, Vol. 44, No. 1 (1995), pp. 243-246.

- (12) Tommerup, S., Endelt, B., Experimental verification of a deep drawing tool system for adaptive blank holder pressure distribution, *Journal of Materials Processing Technology*, Vol. 212, No. 11 (2012), pp. 2529-2540.
- (13) Lal, R.K., Choubey, V.K., Dwivedi, J.P., Kumar, S., Study of factors affecting Springback in Sheet Metal Forming and Deep Drawing Process, *Materials Today: Proceedings*, Vol. 5 (2018), pp. 4353-4358.
- (14) Chalal, H., Abed-Meraim, F., Numerical Predictions of the Occurrence of Necking in Deep Drawing Processes, *metals*, Vol. 7, No. 455 (2017).
- (15) Gorji, M.B., Mohr, D., Predicting shear fracture of aluminum 6016-T4 during deep drawing: Combining Yld-2000 plasticity with Hosford–Coulomb fracture model, *International Journal of Mechanical Sciences*, Vol. 137 (2018), pp. 105-120.
- (16) Bohm, T., Meurer, T., Trajectory planning and tracking control for the temperature distribution in a deep drawing tool, *Control Engineering Practice*, Vol. 64 (2017), pp. 127-139.
- (17) Greco, F., Deckers, E., Stroobants, J., Poppel, S.V., Linck, K., Desmet, W., Finite element simulation of the dynamic behaviour of deep drawn components with accurate thickness description. *Finite Elements in Analysis and Design*, Vol. 138 (2018), pp. 12-20.
- (18) Karupannasamy, D.K., Hol, J., de Rooij, M.B., Meinders, T., Schipper, D.J., A friction model for loading and reloading effects in deep drawing processes, *Wear*, Vol. 318 (2014), pp. 27-39.
- (19) Gallee, S., Pilvin, P., Deep drawing simulation of a metastable austenitic stainless steel using a two-phase model, *Journal of Materials Processing Technology*, Vol. 210 (2010), pp. 835-843.
- (20) Karupannasamy, D.K., Hol, J., de Rooij, M.B., Meinders, T., Schipper, D.J., Modelling mixed lubrication for deep drawing processes, *Wear*, Vol. 294-295 (2012), pp. 296-304.
- (21) Salehinia, I., Shahani, A.R., Effect of sheet anisotropy on the wear in deep-drawing process of a cylindrical cup, *International Journal of Mechanical Sciences*, Vol.51 (2009), pp. 856-868.
- (22) Khelifa, M., Oudjene, M, Numerical damage prediction in deep-drawing of sheet metals, *Journal of Materials Processing Technology*, Vol. 200 (2008), pp. 71-76.
- (23) Muller, T., Meyer, M., Lenske, A., Hauptmann, M., Majschaket, J.-P., Optical inline quality assessment of deep-drawn paperboard containers, *Journal of Materials Processing Technology*, Vol. 262 (2018), pp. 615-621.
- (24) Rodrigues, D.M., Leitao, C., Menezes, L.F., A multi-step analysis for determining admissible blank-holder forces in deep-drawing operations, *Materials and Design*, Vol. 31 (2010), pp. 1475-1481.

- (25) 守屋岳志, 高橋進, 桑原利彦, 自動車パネル絞り成形工程の成形条件自動最適化技術の開発, 塑性と加工, Vol. 49, No. 574 (2008), pp. 1081-1085.
- (26) Tsuruya, T., Danseko, M., Sasaki, K., Honda, S., Takeda, R., Forming state recognition in deep drawing process with machine learning, Journal of Advanced Mechanical Design, Systems, and Manufacturing, Vol.13, No.3 (2019).
- (27) 柿木亮太, 瀬川裕二, 丸茂康男, 今村康博, 野中智博, 坂田豊, 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, 塑性と加工, Vol. 58, No. 676 (2017), pp. 49-53.
- (28) Radha, K L., Vikas, K C., J. P., D., Shravan, K., Study of factors affecting Springback in Sheet Metal Forming and Deep Drawing Process, Materials Today: Proceedings, Vol. 5, No.2 (2018), pp. 4353-4358.
- (29) 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 (2005), pp. 557-561.
- (30) 間所洋和, 下井信浩, 佐藤和人, 徐粒, フィルム荷重センサによる睡眠を見守るヒューマンセンシング, 知能と情報, Vol.28 (2016), pp. 963-973.
- (31) 増田圭祐, 松井孝典, 福井大, 福井健一, 町村尚, 機械学習法を用いたエコーロケーションコールによるコウモリの種判別, 哺乳類科学, Vol. 57, No. 1 (2017), pp. 19-33.
- (32) Pham, B.T., Prakash, I., Tien, B.D., Spatial prediction of landslides using a hybrid machine learning approach based on Random Subspace and Classification and Regression Trees, Geomorphology, Vol.303 (2018), pp. 256-270.
- (33) Ding, X., He, Q., Energy-Fluctuated Multiscale Feature Learning with Deep ConvNet for Intelligent Spindle Bearing Fault Diagnosis, IEEE Transactions on Instrumentation and Measurement, Vol. 66, No.8 (2017), pp. 1926-1935.
- (34) Celiki, E., Cavusoglu, O., Gurun, H., Ozturk, N., Estimation of the Clearance Effect in the Blanking Process of CuZn30 Sheet Metal Using Neural Network—A Comparative Study, International Journal of Informatics Technologies Vol. 11, No. 2 (2018), pp. 187-193.
- (35) Hambli, R., Prediction of burr height formation in blanking processes using neural network, International Journal of Mechanical Sciences, Vol. 44 (2002), pp. 2089-2102.
- (36) 萩野直人, 遠藤順一, 加藤俊二, 石濱正男, 平面金型における超音波の反射・透過特性 —プレス加工中の金型内部における材料接触状態の可視化 第 1 報—, 塑性と加工, Vol. 54, No. 632 (2013), pp. 826-830.
- (37) 萩野直人, 小宮聖司, 遠藤順一, 石濱正男, プレス加工における金型と被加工材の接触状態のインプロセスモニタリング, 塑性と加工, Vol. 57, No. 669 (2016), pp. 983-990.

-
- (38) Keitmann-Curdes, O., Hansen, C., Knoll, P., Meier, H., and Ermert, H., Ultrasonic imaging of sheet metal forming, *Ultrasonics*, Vol. 42 (2004), pp. 989-992.
- (39) 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, 塑性と加工, Vol. 51, No. 596 (2010), pp. 60-64.
- (40) Garcia, C., Artificial intelligence applied to automatic supervision, diagnosis and control in sheet metal stamping processes, *Journal of Materials Processing Technology*, Vol. 164-165 (2005), pp. 1351-1357.
- (41) Mahayotsanun, N., Sah, S., Cao, J., Peshkin, M., Gao, R. and Wang, C., Tooling-integrated sensing systems for stamping process monitoring, *International Journal of Machine Tools & Manufacture*, Vol. 49 (2009), pp. 634-644.
- (42) Behrens, B., Hubner, S., and Wolki, K., Acoustic emission—A promising and challenging technique for process monitoring in sheet metal forming, *Journal of Manufacturing Processes*, Vol. 29 (2017), pp. 281-288.
- (43) Yoo, H., Liu, Z., Quang, N., Kim, S., and Bien, F., Implementation of Nondestructive Crack Detection System for Automotive Press Panel, *IEEE Sensors Journal*, Vol. 16, No. 2 (2016), pp. 383-389.
- (44) Hao, S., Ramalingam, S., and Klamecki, B.E., Acoustic emission monitoring of sheet metal forming: characterization of the transducer, the work material and the process, *Journal of Materials Processing Technology*, Vol. 101 (2000), pp. 124-136.
- (45) 村尾昭, 榎原誠, 鈴木春夫, 横川敦俊, AE 法によるプレス加工状態監視技術の開発, *デンスーテクニカルレビュー*, Vol. 9, No. 1 (2004), pp. 92-99.
徳永啓樹, 矢澤孝哲, 山田玲子, 松尾幸祐, 松本哲也, 宮本侑弥, 大坪樹, 濱園和久, バリと寸法のインライン全数検査の研究, 2016 年度精密工学会春季大会学術講演会講演論文集 (2016), pp. 989-990.
- (47) Al-Momani, E., Rawabdeh, I., An Application of Finite Element Method and Design of Experiments in the Optimization of Sheet Metal Blanking Process, *Jordan Journal of Mechanical and Industrial Engineering*, Vol. 2, No.1 (2008), pp. 53-63.
- (48) Hambli, R., Blanking tool wear modeling using the finite element method, *International Journal of Machine Tools & Manufacture*, Vol. 41 (2001), pp. 1815-1829.
- (49) Hambli, R., BLANKSOFT: a code for sheet metal blanking processes optimization, *Journal of Materials Processing Technology*, Vol. 141 (2003), pp. 234-242.
- (50) Hatanaka, N., Yamaguchi, K., Takakura, N., Iizuka, T., Simulation of sheared edge formation process in blanking of sheet metals, *Journal of Materials Processing Technology*, Vol. 140 (2003), pp. 628-634.

-
- (51) Rachik, M., Roelandt, J.M., Maillard, A., Some phenomenological and computational aspects of sheet metal blanking simulation, *Journal of Materials Processing Technology*, Vol. 128 (2002), pp. 256-265.
- (52) Dey, A., Machine Learning Algorithms: A Review, *Journal of Materials Processing Technology, International Journal of Computer Science and Information Technologies*, Vol. 7, No. 3 (2016), pp. 1174-1179.
- (53) 鈴木大慈, 機械学習の概要, *応用数学会論文誌*, Vol. 28, No. 1 (2018), pp. 32-37.
- (54) 神寫敏弘, 変わりゆく機械学習と変わらない機械学習, *日本物理学会誌*, Vol. 74, No.1 (2019), pp. 5-13.
- (55) Hua, W., Lijuan, Z., Cuiqin, M., A Brief Review of Machine Learning and its Application, *2009 International Conference on Information Engineering and Computer Science*, (2009), pp. 1-4.
- (56) 岡谷貴之, 深層学習, (2015), 株式会社 講談社.
- (57) 北川英夫, 大平壽昭, AE (アコースティックエミッション) によるき裂の追跡と検出の展望, *生産研究*, Vol. 29, No. 11 (1977), pp. 76-81.
- (58) 羽田野甫, アコースティック・エミッション, *応用物理学会誌*, Vol. 44, No. 6 (1975), pp. 564-576.
- (59) 岸輝雄, 加藤明, 栗林和彦, 堀内良, 塑性変形における AE の振幅分布, *日本金属学会誌*, Vol. 41, No. 9 (1977), pp. 897-904.
- (60) 石井泰, パワースペクトル測定におけるウインドウの働き, *計測と制御*, Vol. 5, No. 9 (1966), pp. 667-674.
- (61) 中川威雄, 阿部邦雄, 林豊 共著, 薄板のプレス加工 (1977), 実教出版 株式会社.

図表一覧

Fig. 1.1	Cracked product.
Fig. 2.1	One unit input / output.
Fig. 2.2	Neural network of 2-layers.
Fig. 2.3	Neural network of 3-layers.
Fig. 3.1	Tensile testing machine.
Fig. 3.2	Geometry of tensile test specimen.
Fig. 3.3	Stress-strain relationships obtained from tensile tests.
Fig. 3.4	Experimental set-up to analyze and measure the AE.
Fig. 3.5	Schematic illustration of the data acquisition system for AE. (a) For waveform of AE signals. (b) For count rate of AE signals.
Fig. 3.6	Frequency response curve.
Fig. 3.7	Waveform of AE signals. (a) Data at the time of plastic deformation around the peak stress. (b) Data at the point of break.
Fig. 3.8	AE count rate. (a) Overall data. (b) Data at the time of plastic deformation around the peak stress. (c) Data at the point of break.
Fig. 3.9	Frequency spectra of the AE signals. (a) Peak stress. (b) Break.
Fig. 4.1	Forming machine and mounting location of the AE sensor.
Fig. 4.2	Schematic illustration of the experimental setup.
Fig. 4.3	Punch speed curves used in this study.
Table. 4.1	Experimental conditions for the deep drawing test.
Fig. 4.4	Schematic illustration of the deep drawing process.
Fig. 4.5	The processed product obtained by the deep drawing testing. (a) Normal product. (b) Cracked product.
Fig. 4.6	Load curves during deep drawing.
Fig. 4.7	Schematic illustration of the deep drawing.
Fig. 4.8	Waveform of AE signals. (a) Normal forming. (b) Crack.
Fig. 4.9	AE count rate of normal forming. (a) Sample1. (b) Sample2

-
- Fig. 4.10 AE count rate of crack.
(a)Sample1. (b)Sample2
- Fig. 4.11 Frequency spectra of AE signals.
(a) The FFT result of point A'. (b) The FFT result of point A''.
- Table. 4.2 Computer specifications, software version.
- Fig. 4.12 The configuration of the network.
- Fig. 4.13 Activation functions. (a) Sigmoid. (b) tanh. (c) ReLU.
- Fig. 4.14 Recognition rate of forming state using 100 data.
(a) Sigmoid-SGD. (b) Sigmoid-Adam. (c) Sigmoid-RMSprop.
(d) tanh-SGD. (e) tanh-Adam. (f) tanh-RMSprop.
(g) ReLU-SGD. (h) ReLU-Adam. (i) ReLU-RMSprop.
- Fig. 4.15 Recognition rate of tanh-Adam with different nodes.
- Fig. 4.16 Recognition rate of tanh-Adam with hidden layers.
(a) Hidden layers three. (b) Hidden layers four. (c) Hidden layers five.
- Fig. 4.17 Recognition rate of forming state using 1076 data.
(a) Sigmoid-SGD. (b) Sigmoid-Adam. (c) Sigmoid-RMSprop.
(d) tanh-SGD. (e) tanh-Adam. (f) tanh-RMSprop.
(g) ReLU-SGD. (h) ReLU-Adam. (i) ReLU-RMSprop.
- Fig. 5.1 Blanking machine and mounting location of the sensors.
- Fig. 5.2 Schematic illustration of the experimental setup.
- Table. 5.1 Experimental conditions for the blanking test.
- Fig. 5.3 Geometry of blank.
- Fig. 5.4 The processed product obtained by the blanking testing.
- Fig. 5.5 Enlarged view of the product obtained by the blanking testing.
(a) Punch side. (b) Die side. (c) Side of product.
- Fig. 5.6 Laser microscope.
- Fig. 5.7 Divided measurement area.
- Fig. 5.8 Height data of shot2.
- Fig. 5.9 Height data of shot819.
- Fig. 5.10 Height data of shot1498.
- Fig. 5.11 Burr height data for each region.
- Fig. 5.12 Average data of burr height.
(a) Region 02. (b) Region 04. (c) Region 06.
- Fig. 5.13 Portable X-ray residual stress measuring device.
- Fig. 5.14 Residual stress and burr height.
(a) Shot2. (b) Shot819. (c)Shot1498.

図表一覧

Fig. 5.15	Die before blanking. (a) Top. (b) R10 direction. (c) R2 direction.
Fig. 5.16	Die after blanking 1500 shot. (a) Top. (b) R10 direction. (c) R2 direction.
Fig. 5.17	Height data of die before blanking.
Fig. 5.18	Height data of die after 1500 shot.
Fig. 5.19	Schematic illustration of the data acquisition system.
Fig. 5.20	Strain gauge attachment position.
Fig. 5.21	AE count rate data of blanking.
Fig. 5.22	Blanking load data of blanking. (a) Overall. (b) Enlarged view of the peak.
Fig. 5.23	Strain data of blanking. (a) R2. (b) R10. (c) R25.
Fig. 5.24	Result of data analysis. (a) Maximum value of AE count rate. (b) Maximum value of blanking load. (c) Minimum value of strain.
Table. 5.1	Computer specifications, software version.
Fig. 5.25	The configuration of the network.
Fig. 5.26	Input data.
Fig. 5.27	Results of burr height estimation experiment.
Fig. 5.28	Results of burr height estimation experiment A. (The number of hidden layers is 1, with no preprocessing.)
Fig. 5.29	Results of burr height estimation experiment B. (The number of hidden layers is 10, with no preprocessing.)
Fig. 5.30	Results of burr height estimation experiment C. (The number of hidden layers is 10, with the standardization preprocessing.)
Fig. 5.31	Results of burr height estimation experiment D. (The number of hidden layers is 10, with the Robust z-score preprocessing.)

謝 辞

本研究を遂行し、学位論文を執筆するにあたり、非常に多くの方々のご指導、ご支援、ご協力をいただきました。心より感謝申し上げます。

北海道大学大学院工学研究院 佐々木克彦教授には、社会人博士課程入学の相談に始まり、研究内容、研究計画、投稿論文、学会発表、学位論文と、研究の全てにおいて的確なご指導をいただきました。博士課程と仕事と家庭が並立でき、学位に辿り着けたのは佐々木克彦教授のおかげであり、感謝の念に堪えません。研究の進め方や考え方など、今後の仕事に活用できる多くの財産も築くことができました。

北海道大学大学院工学研究院 本田真也准教授には、研究の方向性の決定が重要な局面において非常に有意義な提案やアドバイスをいただき、また、研究全般におけるご指導、ご助言も多くいただきました。深く感謝申し上げます。

北海道大学大学院工学研究院 武田量助教には、レーザ顕微鏡での測定についてご教示いただき、また、研究についてのご助言のみならず英語の論文や英語の学会発表に関して多くのご指導をいただきました。深く感謝申し上げます。研究室卒業生 團迫武蔵氏にも、プレス加工実験のデータ取得や機械学習実験に関し、多大なる協力をいただきました。本当にありがとうございました。

北海道立総合研究機構 産業技術研究本部 工業試験場 片山直樹場長、北海道立総合研究機構 産業技術研究本部 ものづくり支援センター 飯田憲一センター長、北海道立総合研究機構 産業技術研究本部 工業試験場 製品技術部 田中大之部長、中西洋介研究主幹、戸羽篤也主査には、仕事と学位取得の両立に対して多大なる配慮をいただき、研究を進めることができました。深く感謝致します。また、北海道立総合研究機構 産業技術研究本部 工業試験場 材料技術部 坂村喬史研究主任には、残留応力の測定やレーザ顕微鏡での測定に関してご協力いただきました。北海道立総合研究機構 産業

謝 辞

技術研究本部 工業試験場 製品技術部 鈴木逸人研究職員には，職場の後輩でありながら博士課程の先輩として，心構えや研究の進め方のアドバイスをいただきました．感謝致します．

最後に，社会人博士後期課程への進学を応援し，毎日の生活と家計を支えてくれた妻と，何だかよくわからないけれど大変そうなので協力してくれた二人の娘，両親や家族に感謝の意を表し，謝辞と致します．

令和 2 年 3 月

鶴谷知洋