

機械学習・深層学習の適用によるプレス打ち抜きにおける切断面の破壊開始因子の同定手法の開発

佐賀大学 理工学部
教授 萩原 世也

(2019 年度 一般研究開発助成 AF-2019022-B3)

キーワード：プレス打ち抜き加工，破壊開始点，機械学習

1. 研究の目的と背景

プレス打ち抜き加工は，自動車産業などにおいて，安価に大量に部品を製造するために広く用いられている。加えて近年では，部品・製品の切断面精度も要求されている。このとき金型設計製作にとって特に重要なのは，せん断面から破壊面への開始位置の予測である。

プレス打ち抜き加工による製品は，Fig. 1 の写真に示すように，切断面が滑らかなせん断面と破壊により生じた破壊面とに分かれている。Fig. 2 にはダイとパンチの金型で板の打ち抜き軸対称の模式図を示す。また，板の跳ね上りを抑えるためのダイ上部に板押さえを装備したものである。

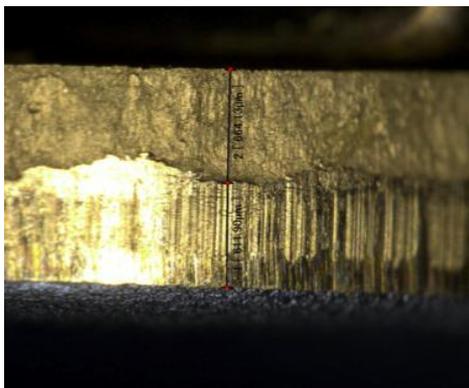


Fig. 1 Photograph of cut surface by press working

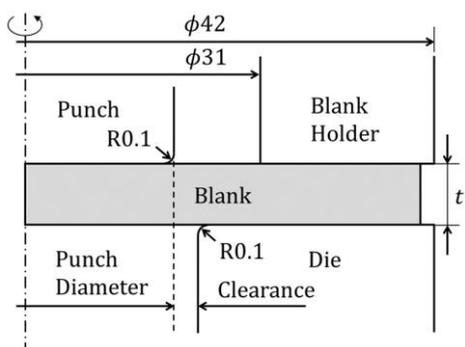


Fig. 2 Axisymmetric model for punching

せん断による切断面を大きくするためには，ファインブ

ランキングのように，金型のクリアランスを小さく取る必要があり，金型の精度を必要とする。ファインランキングのように板押さえ荷重を負荷し，ダイと板押さえにV字型突起を付けても，クリアランスが大きくなると一般のプレス打ち抜きと同様に破壊面の部分が大きくなることが分かっている[1][2][3]。

一般的には，構造物の過荷重や疲労によるき裂開始点を予測することは非常に困難であるとされている。また，連続体損傷力学等による理論により，損傷寿命の予測は行われているが，実際に設計に使用するためには，汎用有限要素法ソフトウェアに組み込まれている損傷理論を用いるか，そして，これらの物理モデルのパラメータ同定を行い，ユーザールーチンを作成し組み込むことになり，専門的な知識が必要になる。

一方，近年注目されている機械学習（マシンラーニング）は，入力値に対して，適切な出力値の学習を行うことにより，入力値としての変数を基にして適切な数値を得ることができる。近年の機械学習は，新たなアルゴリズムの開発とコンピュータの処理能力の向上により，大量のデータによる学習と深い階層による学習が可能となっている。この機械学習は，主にメールの分類，検索機能，金融，画像認識や文字認識などのパターン認識，ゲーム戦略など幅広い分野で用いられているが，現在のところ機械設計などに用いられている例は非常に少ない。

本研究では，簡便なプレス打ち抜き加工試験結果と有限要素法解析による種々の内部の状態変数をもとに，機械学習を用いることにより，物理的モデルを用いないで，打ち抜き加工の切断面におけるせん断面から破壊面への開始点を同定する新しい手法の提案を行う。これにより，打ち抜き加工金型に必要なダイとパンチの最適なクリアランスを予測する手法を開発することを目的とする。

プレス打ち抜き加工においては，延性破壊条件式，連続体損傷力学理論を用いた破壊開始点の予測に関する研究が行われている。それらを有限要素法解析により，事前に把握できるようになることは，製品精度に基づいた金型設計を行うことができ，それに伴い製品の精度管理に非常に有益である。しかし，延性破壊条件式および提案されている連続体損傷力学理論の物理的な意味の理解，これらの式に使用されている係数の同定等の適切な実験を行う必要がある。

ここで、提案する機械学習は、入力値に対して、適切な出力値の学習を行うことにより、入力値としての変数を基にして適切な数値を得ることができる。この入力値には、様々な設定ができる。それらの入力値の寄与は、ニューラルネットワークの重みにより、表現されることになる。したがって、延性破壊条件式、連続体損傷力学理論式におけるパラメータを複雑な過程で決定すること無く、様々な条件式に用いられている変数の入力により、破壊開始点へ影響を与える重要な変数の効果を取り入れることができる。

本研究での手法は、物理モデルを用いない手法であり、実験によるパラメータの設定等は必要としない。解析データと簡便な実験結果および、機械学習により破壊開始を決定する因子を同定し破壊開始点を探索する。

ここでは、延性破壊条件値と破壊開始点の同定をニューラルネットワークから試み、さらに Convolutional Neural Network; CNN により有限要素法(FEM)解析画像による破断点の探索には応力三軸度のコンター図から破断点の同定を試みた。

2. 解析方法

2.1 ニューラルネットワークの適用

階層型ニューラルネットワークは Fig. 3 の模式図のようにニューロンを並べたものである。階層型ニューラルネットワークの各層は入力層(Input Layer),中間層(Hidden Layer),出力層(Output Layer)に分類される。入力層は受け取った入力値を中間層へ渡す。中間層は入力層から値を受け取り、演算を行い次の階層のニューロンへ値を渡す。入力された情報を出力層へ伝えていく作業を順伝播(Forward propagation)という。

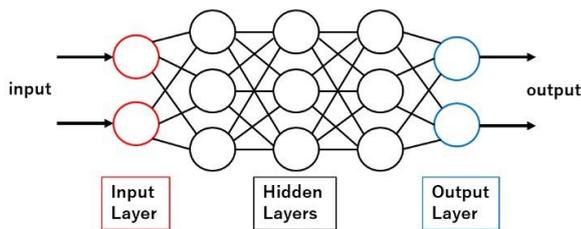


Fig. 3 Schematic figure of a neural network

ニューラルネットワークの学習は、学習データを入力し出力値を正解へ近づける学習あり学習と、学習データを必要としない学習なし学習に分けられる。今回は有限要素法による解析結果を学習データとしているため学習あり学習を行う。ニューラルネットワークにおける学習とは出力される結果が正解に近づくように重みやバイアスを修正することである。重みやバイアスを修正するアルゴリズムを誤差逆伝播法(Backward propagation)という。誤差逆伝播法は出力値が正解からどの方向にどのくらい外れているのかという情報を出力層へ伝え、出力層は中間層へと逆方向へ伝播させていく。情報を受け取った各ニューロンは

この情報をもとに自分の持っている重みとバイアスを更新する。今回構築するニューラルネットワークは入力層のニューロン数 2, 出力層のニューロン数 1 とし、複数層の中間層を導入する。活性化関数はシグモイド関数を使用する。入力値は文献[2][3]で用いた切断面評価位置(l/t)と板厚で無次元化したクリアランス値($\%t$)とし、出力値は有限要素法によるプレス打ち抜き加工の解析で得られた有限要素法解析結果より得られた Cockcroft-Latham の延性破壊条件値 C 値[2][3][4]を用いた。

$$\int_0^{\bar{\epsilon}_f} \left(\frac{\sigma_{max}}{\sigma_{eq}} \right) d\bar{\epsilon} = C_1$$

また、破壊開始点の決定は文献[2]による破壊開始点の式を用いた。

これらを用いてニューラルネットワークプログラムを作成し学習を行い、Cockcroft-Latham の延性破壊条件値 C を用いた破断開始点の同定を行った。

さらに画像による破壊開始の予測を行うために CNN のフリーソフトウェアである TensorFlow を用いて FEM 解析での分布図画像からの破壊の前後の判定を行う。

3. 結果と考察

ニューラルネットワークには学習を行う際に設定しておかなければいけないハイパーパラメータが存在する。これらには中間層の層数、中間層のニューロン数、学習係数、学習回数などが含まれる。ハイパーパラメータを決めるためにパラメータの条件を変えそれぞれ学習を行い、結果を比較しながら決定を行った。また重みの修正量を決定する際には勾配降下法を用いた。

Fig. 4 に中間層を 3 層各 6 ニューロンで構成したニューラルネットワークで学習回数は 20 万回で学習を行った結果を示す。また Fig. 5 には中間層を 3 層各 10 ニューロンで構成したニューラルネットワークで学習回数は 20 万回で学習を行った結果を示す。Fig. 6 には中間層を 3 層各 50 ニューロンで構成したニューラルネットワークによる 20 万回で学習を行った結果を示す。これらから中間層の各層のニューロン数を増やすことにより全体の誤差が小さくなっていることが分かる。なお Fig. 4 中に表示したクリアランス値は Fig. 5, Fig. 6 とともに同様の線を示している。

次に中間層を増やして 5 層 6 ニューロンで学習を行ったところ、ここでは結果を示していないが 3 層各 6 ニューロンよりも誤差の少ない結果が得られている。

重みの更新量を決定する学習係数についてはここまでの計算においては、最適値として試行錯誤により 0.25 に設定している。

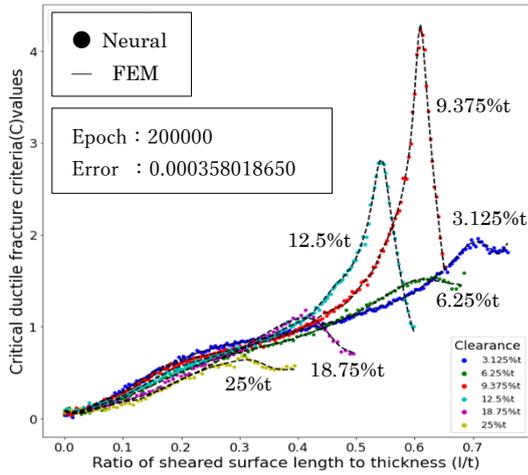


Fig. 4 Result of neural network 3 layers 6 neurons each at epoch 200000

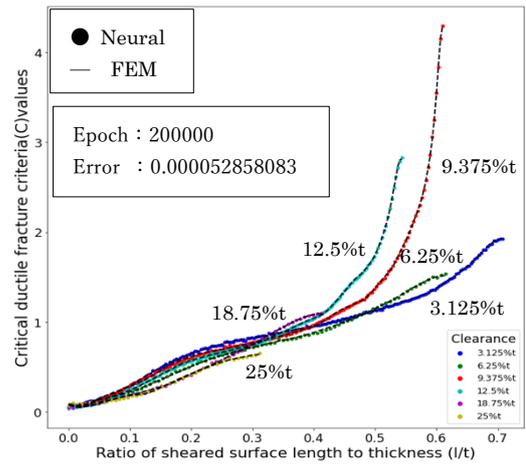


Fig. 7 Result for reduced data of neural network 3 layers 6 neurons each at epoch 200000

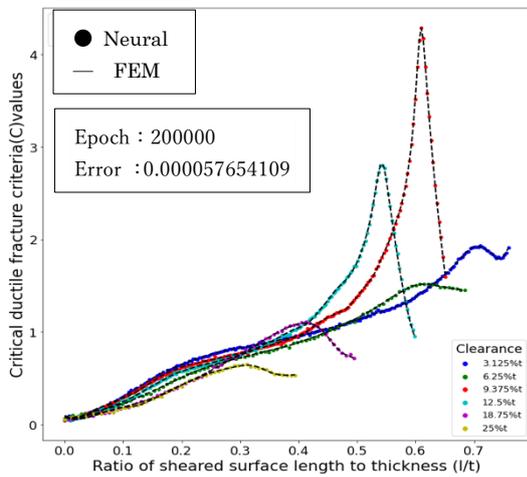


Fig. 5 Result of neural network 3 layers 10 neurons each at epoch 200000

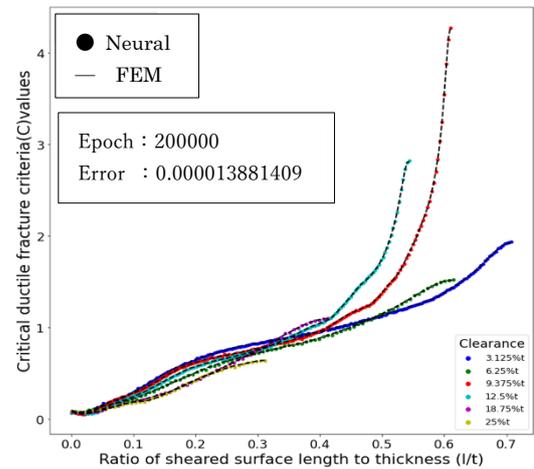


Fig. 8 Result for reduced data of neural network 3 layers 50 neurons each at epoch 200000

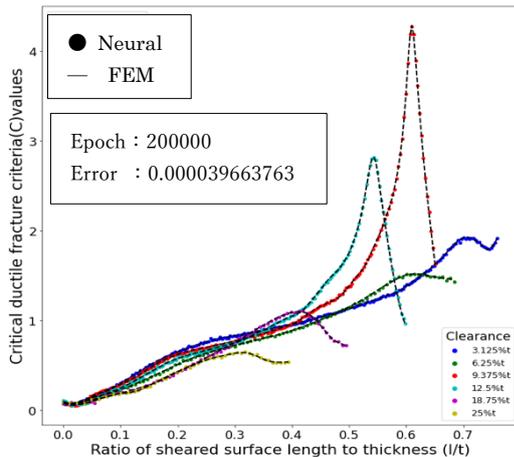


Fig. 6 Result of neural network 3 layers 50 neurons each at epoch 200000

次に学習データの調整を行い、それぞれのクリアランスにおいて破断開始点予測に影響しない学習データの部分を削除し、より良いニューラルネットワークの出力が得られるように調整した。3層各50ニューロン、5層各6ニューロンそれぞれ学習データを調整し20万回学習した結果をFig. 7, Fig. 8に示す。なおFig. 7中に表示したクリアランス値は以降Fig. 8, Fig. 9, Fig. 10ともに同様の線を示している。

結果を比較すると、学習データを調整する前とはどちらも誤差が小さくなっていることが見られる。中でも、5層各6ニューロンで学習したニューラルネットワークは調整する前と比べ良好な結果が得られている。

次に学習率を自動で調節するAdaGrad[5]と呼ばれるアルゴリズムを導入する。AdaGradは学習が進むと学習率を次第に小さくする仕組みであり、学習の初期段階は重みを大きく更新し、学習の終盤では重みを微調整できるため効率よく学習を行うことができる。

AdaGradは以下の式を用いて重み w を更新する。

$$h = h + \left(\frac{\partial E}{\partial w}\right)^2$$

$$w = w - \alpha \frac{1}{\sqrt{h}} \frac{\partial E}{\partial w}$$

E は誤差関数であり、 $\partial E/\partial w$ はその勾配であり、 h の値は重みを更新するたびに大きくなるため、重み w の更新量は次第に小さくなる。AdaGradは更新量が常に減少するため、途中で限りなくゼロに近くなり最適化が進まなくなることがあるケースがあることが報告されている。今回の解析ではAdaGradを導入し学習を行った結果をFig. 9, Fig. 10に示す。これらのグラフは学習回数が1/4の50000回終了した状態であるが、かなり良好な結果が得られており、効率よく学習ができていることが分かる。

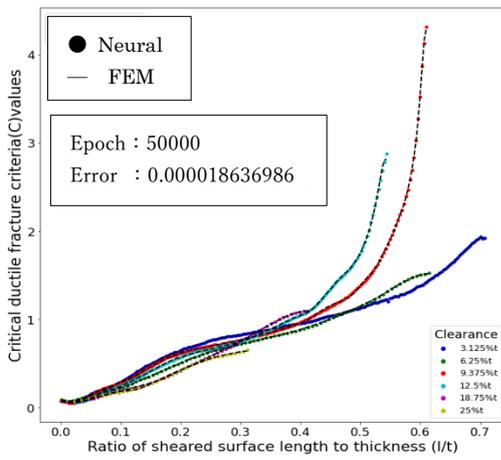


Fig. 9 Result for reduced data of neural network 3 layers 50 neurons each with AdaGrad at epoch 50000

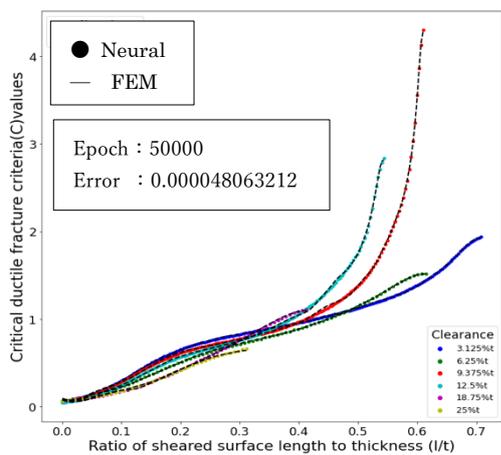


Fig. 10 Result for reduced data of neural network 5 layers 6 neurons each with AdaGrad at epoch 50000

そしてAdaGradを用いずに学習係数を0.25に定めたニューラルネットワークとAdaGradを用いたニューラルネットワークで破壊面への開始点予測を行った。

Fig. 11は中間層5層各6ニューロンの場合の結果である。Fig. 12は中間層5層各50ニューロンの場合の結果である。

これらの結果からFig. 11の中間層5層各6ニューロンの場合はAdaGradを用いても用いなくても学習データの無いクリアランスにおいても良好な結果が得られている。しかしFig. 12の中間層5層各50ニューロンの場合からはAdaGradを用いた場合は少し乱れた値が得られている。AdaGradを用いた学習と、AdaGradを用いない学習では、50000回学習と200000回学習の違いがあるが、この場合はニューロンの数が適切に設定されていないことが考えられる。すなわち各層のニューロン数を適切に設定することが必要であることが分かる。

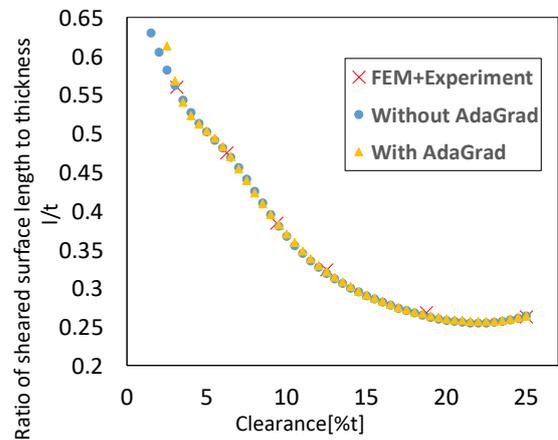


Fig. 11 Prediction of fracture initiation point of network 5 layers 6 neurons each

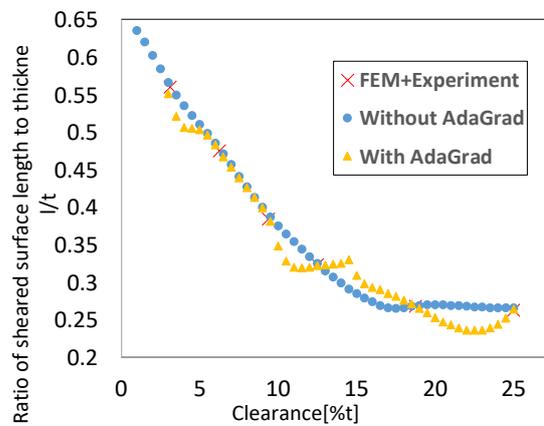


Fig. 12 Prediction of fracture initiation point of network 5 layers 50 neurons each

次に畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を用いて画像による破壊開始点の同定を試みた。ここでは詳しい説明は省くが、畳み込み層とプーリング層と呼ばれる2種類の層を、交互に積み重ねた構造を持つフィードフォワード型のニューラルネットワークである。CNNの特徴は、畳み込み層およびプーリング層と呼ぶ特殊な層を交互に接続した構造を持つことにある。

MSC. Marc2017によるFEM解析で得られた応力三軸度のコンター図の画像でオープンソースソフトウェアTensorFlow[6]を用いた画像分類を行った。せん断状態における応力三軸度コンター図、破断状態における応力三軸度コンター図の例をそれぞれFig. 13, Fig. 14にそれぞれ示す。このようなカラー画像をそれぞれ60枚用意し学習を行った。

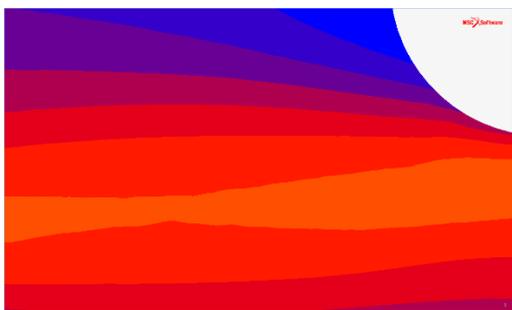


Fig. 13 Example of contour for stress triaxiality at fracture



Fig. 14 Example of contour for stress triaxiality before fracture

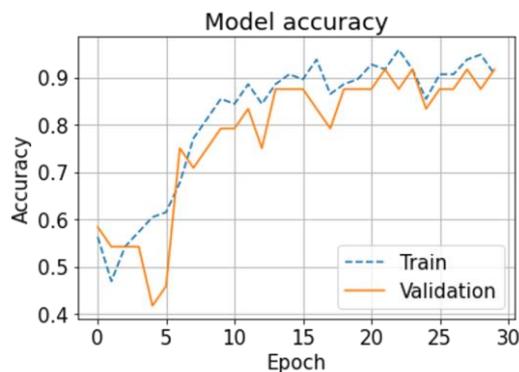


Fig. 15 Accuracy of training and validation data

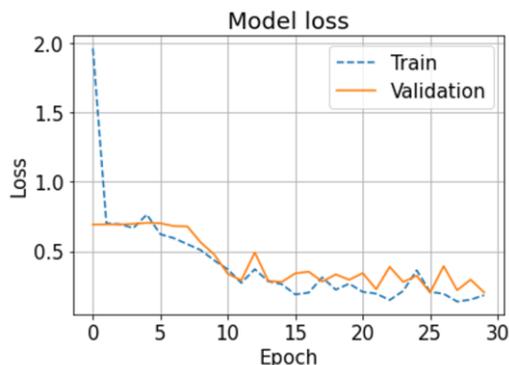


Fig. 16 Error of training and validation data

打ち抜き過程において、せん断状態と破断状態の応力三軸度のコンター図の画像をそれぞれ「sheared」「fracture」に分類して保存した。画像を読み込み、学習可能な配列に変換した。画像は学習データのうち8割を訓練用データに、2割を評価用のデータにした。10層の畳み込みニューラルネットワークモデルを作成し、カラー画像で30回の学習を行った。訓練データと評価データにおける学習過程における精度と学習誤差をFig. 15, Fig. 16にそれぞれ示す。30回学習が完了した時点で精度は約91.7%、誤差は約0.20を示した。精度は学習回数が多くなると上がっている。これらの結果より過学習は生じていないことが分かる。

次にテストデータを用いてこの学習をおこなったCNNにより画像の分類を行った。

テストデータに破断時の応力三軸度のコンター図を用いたところ破断を100%に判定を行った。次にせん断のテストデータを用いたところ87%でせん断の判定を行った。

これらの結果から、FEM画像を学習することによりその解析結果からどの位置で破断の開始を判定するか予測できる可能性があることを示した。

4. 結言

プレス打ち抜き加工について、物理モデルを用いない手法であり、実験によるパラメータの設定等は必要としない。解析データと簡便な実験結果および、機械学習により破壊開始を決定する因子により破壊開始点の同定を行った。

ここでは、延性破壊条件値と破壊開始点の同定をニューラルネットワークから試み、さらにConvolutional Neural Network: CNNにより有限要素法(FEM)解析画像による破断点の探索には応力三軸度のコンター図から破断点の同定を試みた。

その結果、ニューラルネットワークでは学習によりCockcroft-Lathamの延性破壊条件値C値から破壊開始点の予測を行うことができた。しかし、学習係数や学習回数設定により結果が良好でない場合があり、さらなる改良が望まれる。

また、TensorFlow を用いた CNN による有限要素法 (FEM) 解析画像による破断点の探索において、本研究では画像でえられた分布図が破断前 (せん断状態) なのか破断後 (破断状態) なのか判定できている。

これらから機械学習により破壊開始点の同定は様々なファクターを用いて可能であることを示した。

今後は本研究を更に発展させ、多くの機械学習の手法を取り入れて効率よく、そして精度良く判定できる手法を取り入れることを試みたい。

謝 辞

本研究は、公益財団法人天田財団の 2019 年度一般研究開発助成 (AF-2019022-B3) の援助により行われた。ここに記して深く感謝の意を表す。

本研究の遂行に当たり、ご協力をいただいた佐賀大学大学院理工学研究科博士前期課程 (当時) 新開拓未 氏、佐賀大学理工学部理工学科 (当時) 松海伸太郎 氏、山口光太郎 氏に深く感謝の意を表す。

参考文献

[1] Toru Tanaka, Seiya Hagihara, et al., Analysis of Finite Element Method to Analysis of Ductile

- Fracture Criteria for Punched Cutting Surface, *Materials Transactions*, Vol. 54, No. 9 (2013), 1697
- [2] Phyowai Myint, Seiya Hagihara, et al., Determination of the Values of Critical Ductile Fracture Criteria to Predict Fracture Initiation in Punching Processes, *Journal of Manufacturing and Materials Processing*, 1-12, (2017)
- [3] Phyowai Myint, Seiya Hagihara, et al., Application of Finite Element Method to Analyze the Influences of Process Parameters on the Cut Surface in Fine Blanking Processes by Using Clearance-Dependent Critical Fracture Criteria, *Journal of Manufacturing and Materials Processing*, 2-26, (2018).
- [4] Cockcroft, M.G., Latham, D.J. Ductility and workability of metals. *J. Inst. Metals*, 96, 33-39 (1968).
- [5] Duchi, J., et al., Adaptive Subgradient Methods for Online Learning and Stochastic Optimization *Journal of Machine Learning Research*, Vol.12, pp.2121-2159 (2011)
- [6] <https://www.tensorflow.org/?hl=ja>