熟練技能継承を目的としたLSTMを用いた技能データの永久保存と再現性の検証

香川高等専門学校　電気情報工学科
教授　漆原　史朗
（2021年度 一般研究開発助成 AF-2021026-B3）

キーワード：熟練技能獲得，LSTM，データ圧縮

１．研究の目的と背景

近年，人工知能(AI)をはじめとする自動化技術の進展により，複雑な作業工程の自動化が多様な分野で実現されつつある[1,2]．これらの技術は，生産品質の安定，生産性の向上，省人化を可能にし，深刻化する人手不足に直面する製造業において極めて重要な役割を果たしている[3]．

一方で，自動車，医療，航空宇宙，情報通信といった分野における精密部品の製造では，依然として熟練技能者の手作業が不可欠である．μm 単位の加工精度が要求される工程では，先端ロボット技術を持ってしても，長年の経験と繊細な感覚による熟練技能に及ばないのが現状である[4~9]．そのため，今後いかに自動化が進展しようとも，熟練技能は依然として現場の根幹を支える要素であり続ける可能性が高い．しかしながら，少子高齢化に伴う技能継承者の減少，熟練作業者の高齢化，手作業に起因する大量生産の難しさなど，技能の継承と現場の維持には多くの課題が山積している．特に，技能の可視化や形式知化が進まなければ，熟練技能の喪失が現実のものとなりかねない．このような課題に対し，近年の IoT 技術やクラウドシステムを活用する第 4 次産業革命の流れに乗り，作業データの収集・蓄積・分析によって，技能の再現や継承を可能にする「スマート技能継承システム」の構築が求められている．

本研究では，熟練技能の再現に必要な時系列データの圧縮技術に焦点を当て，技能データの効率的な管理と活用を実現するための手法を提案する．熟練作業における工具位置や加工力のデータは，高時間分解能かつ膨大な量となるため，そのままでは通信や保存においてハードウェア上の制約を受ける．したがって，技能の特徴を損なうことなくデータを圧縮する技術が必要である．従来研究では，ニューラルネットワークを用いたスピニング加工における最適工具経路パラメータの算出などが報告されているが[10)~13)]，熟練技能そのものの獲得や再現に焦点を当てた研究は限られている．

そこで本研究では，深層学習[14~18)]の一手法である Long Short-Term Memory(LSTM)を用い，熟練技能データの特徴を抽出・圧縮する方法を提案する．具体的には，作業中の工具位置と加工力の時系列データに加え，材料の厚みといった作業条件情報を学習データとして過去の位置情報 LSTM モデルに入力し，次時刻の力指令を予測するモデルを構築する．学習済みモデルの重み係数には，技能データの特徴が圧縮された形で保持されるため，省メモリかつ高速な再現が可能となる．本稿では，卓上スピニング加工機を試作し，3 種のアルミ板（0.3mm・0.4mm・0.5mm 厚）を対象とした実加工により技能データを取得し，提案手法の有効性を検証する．加えて，LSTM の学習条件（厚み情報の有無など）と再現性の関係を評価し，最適な学習方法を明らかにする．

２．熟練技能データの獲得

2・1　へら絞りの概論

本研究では，図 1 に示すへら絞り加工に着目した．へら絞りとは，塑性加工の一種であるスピニング加工に分類され，その中でも機械ではなく熟練作業者の手作業によって行われる加工法を指す．スピニング加工は，回転させた金属素板に対して棒状の工具（へら）を押し当てることで，金属の塑性を利用して型に沿った成形を行う技術である．このとき，素材は型に沿って徐々に変形し，最終的には滑らかで均一な形状に仕上げられる．特にへら絞り加工では，成形物の表面品質や寸法精度に作業者の技能が直接反映されるため，熟練度の違いが結果に大きく現れる．高度な技能を有する作業者であれば，機械加工を上回る精度や仕上がりを実現することも可能である．

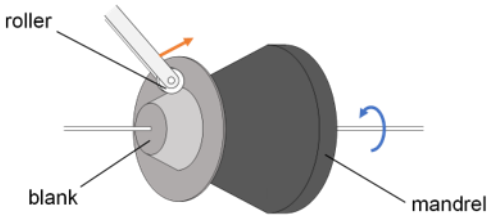

図 1　へら絞りの概略

2・2　技能データ計測システム[19)]

本研究では，へら絞り加工における工具に加えられる力および工具の回転位置の時系列データを取得し，技能データとして用いた．これらのデータは，市販の卓上旋盤を改造して製作した卓上スピニング加工機により取得されたものである．加工機は，東洋アソシエイツ製の Compact3 66500 型卓上旋盤を基台としており，これに加えて，先端にローラを有するへら工具，工具を支持する構造体，および成形型を独自に設計・製作して構成している．試作した

卓上スピニング加工機の外観を図 2 に，使用した卓上旋盤の仕様を表 1 に示す．

技能データの計測に用いたシステム構成を図 3 に示す．へら工具には，ひずみゲージ式の力センサとインクリメンタル型ロータリーエンコーダを搭載しており，これにより加工中の力と位置を同時に計測できる．力センサのアナログ出力は，計装用コンディショナによって増幅され，FPGA に搭載された A/D コンバータによりディジタル化される．これにより，へらに対して平行方向に加わる力が正確に取得可能となる．一方，ロータリーエンコーダからのパルス信号は，FPGA 内のカウンタボードによって読み取られ，ローラの回転位置が角度情報として記録される．各々の仕様を表 2～4 に示す．

また，本システムを用いて厚さ 3mm のアルミ円盤を加工した際に取得した工具位置および加工力に関する 50 回分の時系列データを取得した結果を図 4 に示す．この結果から，工具位置は時間とともにほぼ直線的に増加する傾向を示し，一方で加工力は初動時にピークを示したのち，徐々に減衰する傾向が見られた．ただし，加工条件や操作方法により，加工力には振動成分や，減衰・増加のパターンの違いが確認されており，作業者の技能に係わる要素だと考えられる．

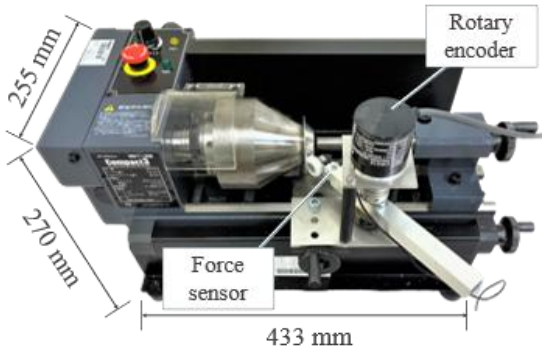

図 2　試作した卓上スピニング加工機

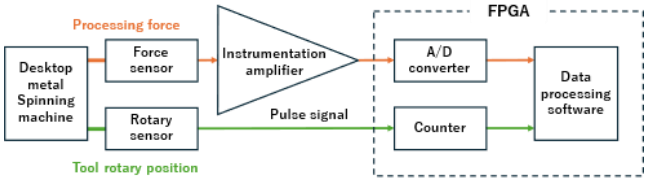

図 3　技能測定システムのハードウェア構成

表 1　卓上スピニング加工機に使用した卓上旋盤の仕様

回転速度	無段変速 0～3800min^{-1}
電源	100V，50/60Hz，150W
本体寸法	W433×D255×H230mm
自重	13.5kg

表 2　卓上スピニング加工機の工具に搭載した力センサの仕様

定格容量	200N
定格出力	1.4mV/V(2800 × 10^{-6}ひずみ)以上
許容印加電圧	7V AC または DC
ケーブル	0.035mm^2，外径 1.8 mm 4 心シールドふっ素樹脂 2m
本体材質	ステンレス鋼
本体質量	約 1.5g

表 3　工具に加わる力の計測に使用した計装用コンディショナの仕様

A/D 分解能	24bit
測定範囲	−3.2～3.2mV/V
精度	±0.1%FS 以内
サンプリング周波数	4000Hz
寸法	W96×H96×D126mm
質量	約 750g

表 4　卓上スピニング加工機の工具に搭載したロータリーエンコーダの仕様

分解能	2000R/P
出力形式	ラインドライバ出力
許容回転数	6000min^{-1}
最大消費電流	160mA

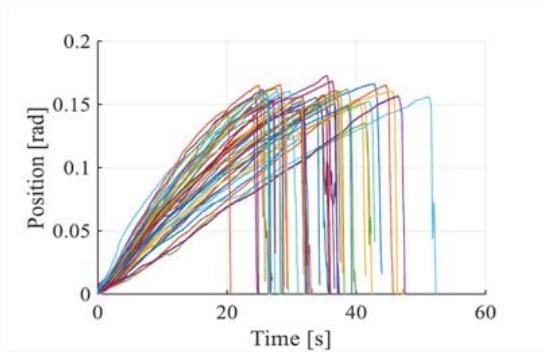

(a) 工具の回転位置の時系列データ

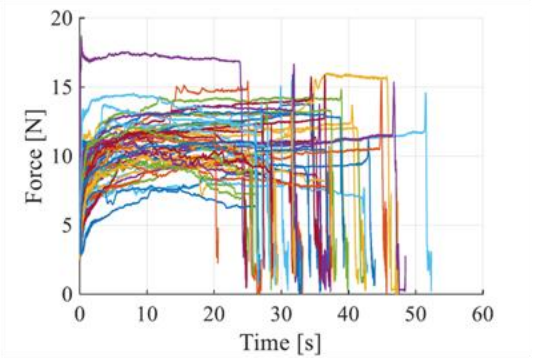

(b) 工具に加わる力の時系列データ

図 4　作業データ(0.3mm)

３．LSTM を用いた熟練技能の獲得 [20~22)]

3・1　深層学習モデルの LSTM

本研究では，Long Short-Term Memory（以降 LSTM）という図 5 に示すような深層学習モデルを用いた．LSTM には CEC(Constant Error Carousel)と呼ばれる記憶セルが存在し，重みを 1 とすることで過去の情報を減衰させない記憶形態を実現している．また，忘却ゲートの自動判別に基づいて CEC の記憶状態をリセットすることで，長期的なデータを正しく記憶し続けることが可能である．各ゲートと CEC による出力は式(1)から(5)のように表せる．添え字は，その変数にかかわる構造部分を入力ゲート(i)，忘却ゲート(f)，出力ゲート(o)および CEC(c)として表している．

$$i = \sigma(w_i x^t + v_i y^{(t-1)} + u_i c^{(t-1)} + b_i) \quad \cdots\cdots (1)$$

$$f = \sigma(w_f x^t + v_f y^{(t-1)} + u_f c^{(t-1)} + b_f) \quad \cdots\cdots (2)$$

$$c^t = i \odot \sigma_c(w_c x^t + v_c y^{(t-1)} + b_c) + f \odot c^{(t-1)} \quad \cdots\cdots (3)$$

$$o = \sigma(w_o x^t + v_o y^{(t-1)} + u_o c^t + b_o) \quad \cdots\cdots (4)$$

$$y^{(t-1)} = o \odot \sigma_c(c^t) \quad \cdots\cdots (5)$$

ここで，i：入力ゲートの活性化出力，f ：忘却ゲートの活性化出力，o ：出力ゲートの活性化出力，c^t：現時刻 tにおける CEC の状態，w:現時刻の入力x^tに対する重み，v：前時刻からの再起入力y^{t-1}に対する重み，u：Peephole connection の重み，v：バイアスである．

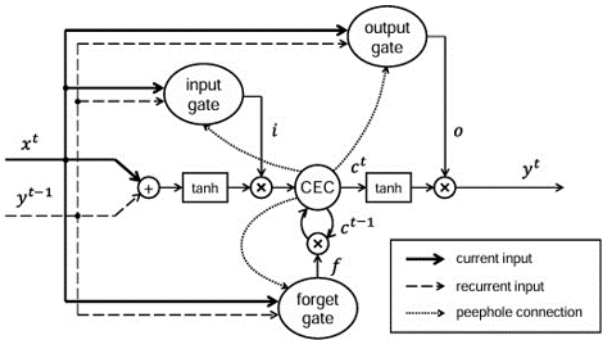

図 5　LSTM の構造

3・2　熟練技能データを用いた深層学習

本研究では，板厚ごとに 50 回の成形実験を行い，計 50 個の作業データを取得した．LSTM がこれらの作業データの特徴を適切に学習できるよう，データに対して間引き処理および標準化処理を施した．作業データは，サンプリング周波数 5 kHz で計測されたが，人間の動作は一般に 10 Hz 以下の周波数帯で行われると想定される．そのため，1/100 の間引きを行い，実質的なサンプリング周波数を 50 Hz に設定することで，学習に用いるデータ量を抑えつつも必要な運動情報を保持した．LSTM の出力が人間の動作特性をどの程度再現しているかを評価するために，Short-Time Fourier Transform(STFT)を用いた周波数解析を実施し，その結果を図 6 に示す．LSTM から出力

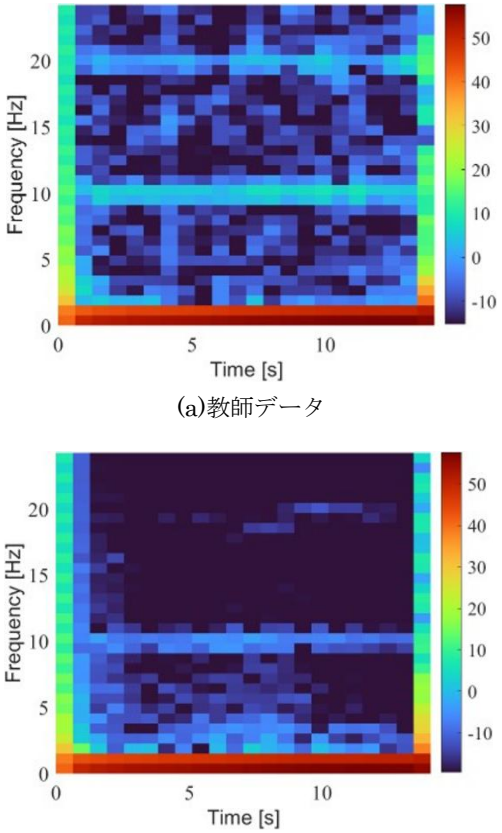

(a)教師データ

(b)LSTM の出力

図 6　教師データと LSTM 出力の STFT 結果

された推定加工力は，10 Hz 以下の周波数帯において，教師データと同様のスペクトル特性を示しており，本モデルが技能データの主要な周波数成分を適切に学習していることが確認された．一方で，標準化処理については，工具に加わる力と工具の回転位置という異なる単位・スケールを持つ複数のデータを同等に扱うために実施した．

LSTM モデルは，MATLAB の Deep Learning Toolbox を用いて実装し，設定したハイパーパラメータは表 5 に示す．なお，LSTM の学習には Adam 最適化手法を採用しており，これは損失関数の勾配の指数移動平均およびその 2 乗の移動平均を用いて学習率を動的に調整する手法である．Adam による重み更新の数式は，式(6)～(10)に示す通りである．

$$m_t = \beta_1 m_{t-1} + (1-\beta_1)\frac{\partial E}{\partial w} \quad \cdots\cdots (6)$$

$$v_t = \beta_2 m_{t-1} + (1-\beta_2)\left(\frac{\partial E}{\partial w}\right)^2 \quad \cdots\cdots (7)$$

$$\hat{m}_t = \frac{m_t}{1-\beta_1^t} \quad \cdots\cdots (8)$$

$$\hat{v}_t = \frac{v_t}{1-\beta_2^t} \quad \cdots\cdots (9)$$

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v}_t}+\epsilon}\hat{m}_t \quad \cdots\cdots (10)$$

ただし，η ：学習率の初期値，m_t：損失関数 E のw_tに対する勾配の指数移動平均，v_t：勾配の 2 乗の指数移動平

均，β：指数移動平均における平滑化係数，$\hat{m}_t$：m_tのバイアス補正項，$\hat{v}_t$：v_tのバイアス補正項である．

学習過程における損失関数の値の推移を図 7 に示す．学習反復回数の増加とともに損失関数の値が減少しており，円滑に学習が進行したことを表している．まず，学習終了時の LSTM モデルの出力性能を確認すべく，既学習である厚みが 0.5 mm の作業データによる試験結果を図 8 に示す．力の立ち上がりにて若干の時間的なずれがあるものの，教師信号に対する LSTM モデルの出力の誤差はほとんどないことが確認できる．

さらに，本研究では，3 種の異なる厚み(0.3 mm, 0.4 mm, 0.5 mm)のアルミ板を対象に，それぞれの作業データに基づいた深層学習を行った．ここでは，各板厚の情報を一定のバイアス信号として LSTM モデルの入力に加えることで，厚みの違いに対応可能なモデル構築を試みた．構築した LSTM モデルに対し，学習に用いていないテスト用作業データを入力し，その出力結果を図 9 に示す．出力結果より，作業の序盤における加工力の推定値が教師データと良好に一致している．一方で，作業全体を通じてみると，各板厚に対して一定の推定誤差が存在している．

表 5　ハイパーパラメータ

損失関数	Mean Squared Error
最適化アルゴリズム	Adam
バッチサイズ	64
学習初期値	0.005
過去の工具位置の時系列値	10
学習反復回数（epoch 数）	100
隠れ層の LSTM ユニット数	50
隠れ層の数	1

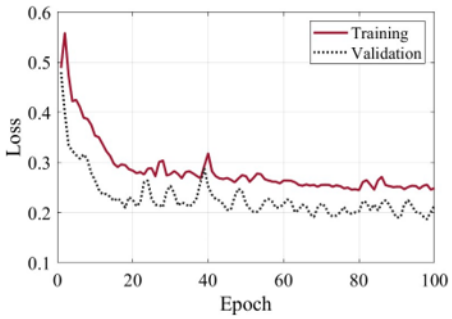

図 7　学習反復回数に対する損失関数の推移

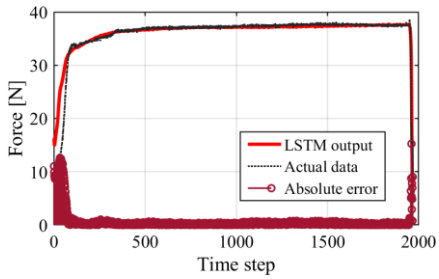

図 8　既学習の厚み 0.5 mm に対する LSTM の出力

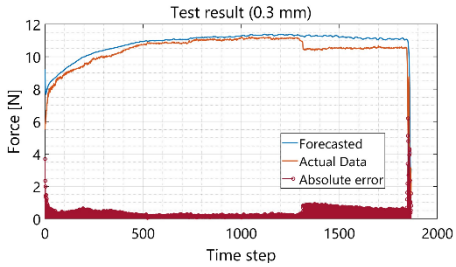

(a)素材厚み 0.3mm

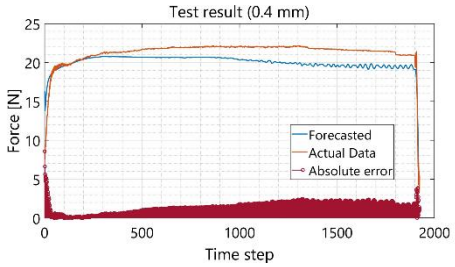

(b) 素材厚み 0.4mm

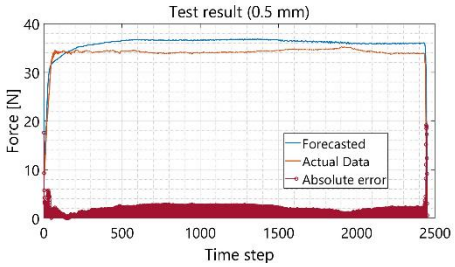

(c) 素材厚み 0.5mm

図 9　LSTM の出力

4．熟練技能獲得法の検証

4・1　厚み情報が深層学習に与える影響

へら絞り作業における技能の獲得状況を評価するために，LSTM(Long Short-Term Memory)を用いた深層学習による実験を実施した．評価には，テスト用工具に加わる力の実測データと，工具の回転位置から予測された力の時系列データとの間の平均絶対誤差(Mean Absolute Error : MAE)を用いた．これは，予測の精度を示す損失関数であり，値が小さいほど予測精度（＝学習精度）が高いことを意味する．LSTM の出力に偏りが出ないように，同一の学習条件に対して 30 回の学習を実施し，その平均値を学習精度として採用した．次に，学習条件を変更し，それぞれの条件下での学習精度の変化を評価した．

そこで，1 種類の厚みの作業データのみを用いて学習を行った場合における「厚み情報」の影響について検証を行った．この条件において，厚み情報を入力変数として与えると，MAE の平均値には一定の変動が見られたものの，分散はいずれの厚みにおいても小さくなる傾向が確認された．これは，厚み情報がモデルの出力安定性に寄与している可能性を示唆している．そこで，この傾向の妥当性を

確認するために，30 回の学習を 1 セットとし，それを 4 回繰り返す（合計 120 回）ことでデータ取得回数を増やし，ばらつきの縮小が一時的なものではないかを検証した．素材の厚みが 0.3，0.4，0.5mm の場合の検証結果を図 10 に示す．これらの結果から，いずれの厚みにおいても，厚み情報を入力した場合に MAE の分散が明確に小さくなる傾向が見られた．具体的には，分散の縮小率は最小で 7%，最大で 52%に達し，学習の安定性が大きく向上していることが確認された．

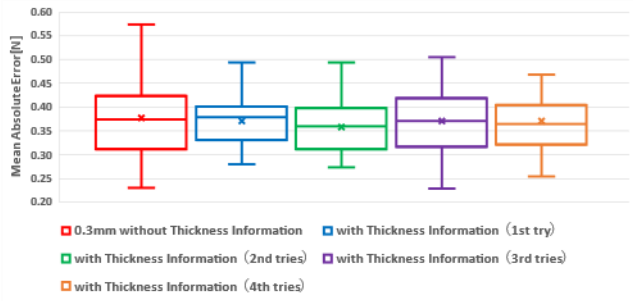

(a) 素材厚み 0.3mm

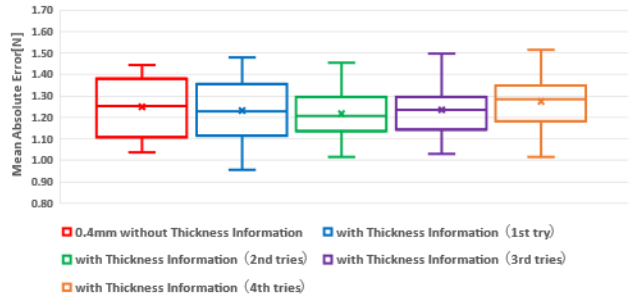

(b) 素材厚み 0.4mm

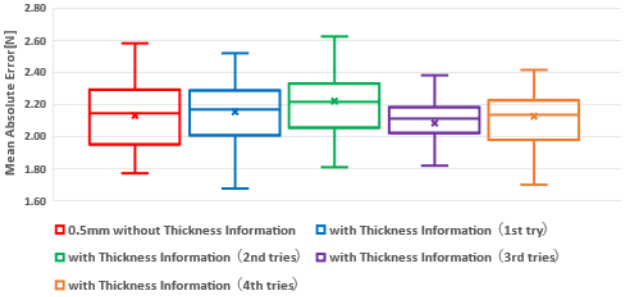

(c) 素材厚み 0.5mm

図 10　MAE のばらつき

4・2　学習反復回数の影響

学習の反復回数（epoch 数）と学習精度の関係を評価するため，素材の厚みが 0.3mm，0.4mm，0.5mm の場合における，さまざまな学習条件下での epoch 数と平均絶対誤差(MAE)の変化を調査した．その結果を図 11 に示す．全体的に，どの厚みにおいても，epoch 数が 300 回までは MAE の変化は比較的小さい傾向が見られた．しかしながら，厚み 0.3mm および 0.4mm では，epoch 数が 700 回を超える時，厚み 0.5mm では 400 回を超えた時，MAE に大きな変動が見られた．特に，厚み 0.3mm および 0.5mm においては，epoch 数の増加に伴い MAE が大きくなる現象が確認され，これは過学習(overfitting)によるものと考えられる．一方で，厚み 0.4mm の場合は，全体的に MAE が減少する傾向が見られた．この違いは，0.4mm のデータにおいては前処理によるデータ削減が比較的少なく，他の厚みと比べて学習データの量が多かったことが，過学習を回避する一因となっている可能性がある．

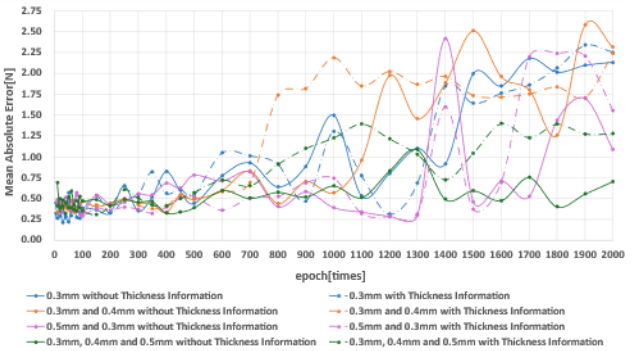

(a) 素材厚み 0.3mm

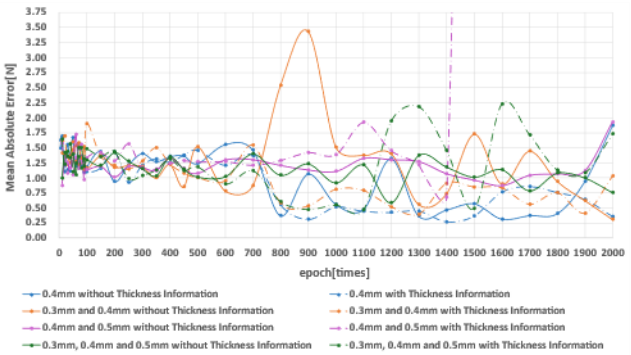

(b) 素材厚み 0.4mm

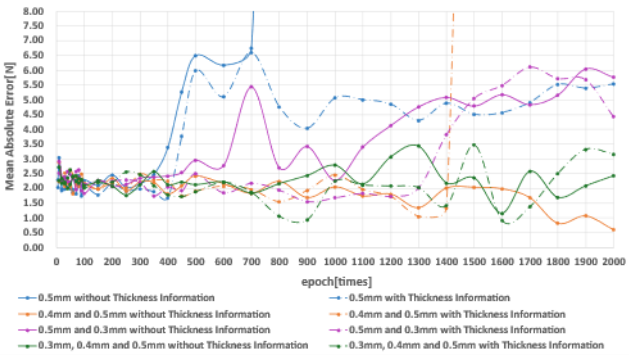

(c) 素材厚み 0.5mm

図 11　epoch 数による学習精度の変化

5．まとめ

本研究の目的は，熟練技能再現システムにおいて，①技能の獲得効率を向上させる学習手法の最適化，②技能の獲得状況を可視化する手法の構築である．そのために，実際

の加工データを用い，LSTM による深層学習に基づいた技能データの獲得方法を検討した．

卓上スピニング加工機から得られた作業データに基づいて検証を行った．その結果，技能獲得手法の最適化に関しては，学習回数（epoch 数）を 300 回以下とし，1 種類の厚みデータに対して厚み情報を付加して学習を行うことで，LSTM の学習精度および出力の安定性の向上が確認された．

今後の課題としては，実作業データと熟練技能データを比較・検証することで，技能評価を可能とする評価システムの構築を進める必要がある．

謝　辞

本研究は，公益財団法人天田財団研究助成（一般研究開発助成，AF-2021026-B3）ならびに JSPS 科研費 JP 22K04160 の支援を受けて実施したものである．ここに記して深甚なる謝意を表する．また，本研究の遂行にあたりご協力を賜った香川高専の高橋洋一先生ならびに吉岡崇先生に厚く御礼申し上げる．さらに，本研究の実験データ収集や分析に多大なご協力をいただいた専攻科生（当時）の久米駿弥氏ならびに本科生（当時）の山口翔大氏，岡田大和氏に心より感謝の意を表する．

参考文献

1) 足立大輔，海沼修平，川口大司，齊藤有希子，“自動化技術の導入と労働代替”，*RIETI Policy Discussion Paper Series,* 19-P-010, pp. 1–29, 2019.
2) 村上弘記，“自動化システムの最近の動向と今後の展開”，計測と制御，Vol. 54, No. 12, pp. 889–894, 2015.
3) 総務省，“平成 29 年版情報通信白書”，2017.
4) 森山祐樹，前田雄介，“産業用ロボットによるマニピュレーションのためのビューベースト教示再生”，日本機械学会論文集（C 編），Vol. 79, No. 806, pp. 3597–3608, 2013.
5) 荒井裕彦，“ロボットによるへら絞り−ものづくりとロボット技術”，精密工学会誌，Vol. 72, No. 1, pp. 41–45, 2006.
6) 関口明生，荒井裕彦，“傾斜しごきスピニング加工による肉厚分布の制御”，塑性と加工，Vol. 51, No. 597, pp. 984–989, 2010.
7) 荒井裕彦，“ロボット技術を用いたスピニング加工（へら絞り）−手作りの現場密着型ものづくり”，*Synthesiology*, Vol. 5, No. 2, pp. 126–134, 2012.
8) 太陽パーツ株式会社．“へら絞り加工の方法と製造品の用途”https://www.taiyoparts.co.jp/blog/1903/
9) 今野絞製作所．“へら絞り加工”，https://www.konnosibori.com/what
10) N. P. Belfiore, F. Ianniello, D. Stocchi, F. Casadei, D. Bazzoni, A. Finzi, S. Carrara, J. R. González, J. M. Llanos, I. Heikkila, F. Peñalba, X. Gómez, A hybrid approach to the development of a multilayer neural network for wear and fatigue prediction in metal forming, Tribology International 40 (2007) 1705–1717.
11) S. Jiang, Z. Ren, K. Xue, C. Li, Application of BPANN for prediction of backward ball spinning of thin-walled tubular part with longitudinal inner ribs, J. Mater. Process. Technol. 196 (2008) 190–196.
12) S. Gondo, H. Arai, Data-driven metal spinning using neural network for obtaining desired dimensions of formed cup, CIRP Annals 71.1 (2022): 229-232.
13) S. Gondo, H. Arai, Effect and control of path parameters on thickness distribution of cylindrical cups formed via multi-pass conventional spinning, Journal of Intelligent Manufacturing 33 (2022) 617–635.
14) Azevedo,A.C.F., Carvalho,R.B.L., Grinberg,T.L., et al., “equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain”. *Journal of Comparative Neurology,* Vol. 513, No. 5, pp. 532–541, 2009.
15) McCulloch,W.S. and W.Pitts, “A Logical Calculus of the Ideas Immanent in Nervous Activity”, *Bulletin of Mathematical Biophysics*, Vol. 5, pp. 115–133, 1943.
16) Rumelhart,D.E., Hinton,G.E. and Williams,R.J., “Learning representations by back-propagating errors”, *Nature*, Vol. 323, No. 9, pp. 533–536, 1986.
17) Hochreiter,S., and Schmidhuber,J., “Long Short-Term Memory”, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
18) Kingma,D. and Ba,J., “Adam: A Method for Stochastic Optimization”, Proceedings of International Conference on Learning Representations, 2015.
19) 山口翔太，松本怜士，漆原史朗，高橋洋一，吉岡崇：「熟練技能再現のための加工精度を含んだスピニング加工データの獲得と評価」，第 40 回センシングフォーラム計測部門大会，2P1-21，2023 年 8 月 31 日−9 月 1 日（高知工科大学，高知）
20) 久米駿弥，漆原史朗，吉岡崇：「LSTM を用いたへら絞り技能再現システムの加工対象の厚みに対する汎化性能評価」，令和 5 年電気学会全国大会，4-173，2023 年 3 月 15−17 日（名古屋大学　東山キャンパス）

21) 岡田大和，山口翔大，漆原 史朗，吉岡 崇，高橋 洋一：「LSTM を用いたスピニング加工技能獲得における素材厚み情報入力による学習効率」，2024 年電気学会産業応用部門大会，Y-100，2024 年 8 月 28 日－8 月 30 日（水戸市民会館，茨木）

22) 大喜多隼人，岡田大和，漆原 史朗，吉岡 崇，高橋 洋一：「LSTM を用いたスピニング加工技能獲得における最適化と技能獲得状況の見える化」，2025 年電気学会産業応用部門大会，Y-104，2025 年 8 月 19 日－8 月 21 日（徳島大学理工学部）