GRU を用いた SMA アクチュエータのモデル化とセンサレス張力制御

伊藤 壮生^{*1}, 原田 宏幸^{*2}

Modeling and sensorless tension control of SMA actuator using GRU

Soki ITO^{*1} and Hiroyuki HARADA^{*2}^{*1} Graduate School of Engineering, Hokkaido University
Kita-13 Nishi-8, Kita-ku, Sapporo 060-8628, Japan^{*2} Faculty of Engineering, Hokkaido University
Kita-13 Nishi-8, Kita-ku, Sapporo 060-8628, Japan

Received: 29 March 2019; Revised: 19 September 2019; Accepted: 21 January 2020

Abstract

This paper proposes a method for sensorless tension control of shape memory alloy(SMA) actuators. Sensorless control has advantages in cost and size. Gated recurrent unit(GRU) was adopted to model complex characteristics of the SMA actuators. GRU is one of the machine learning technologies, which is evolved from the recurrent neural network. Modeling of SMA actuators are not easy due to their characteristics such as nonlinearity, hysteretic behavior, effects of temperature and stress. They are often responsible for control difficulties such as inaccuracy and instability. In this study, GRU is used to estimate the relation among the applied voltage(duty ratio), electrical-resistance, tension, displacement and room temperature. Two SMA models were created by GRU: the sensing model and the inverse model. Both models were trained with the original dataset obtained experimentally. A control framework for the sensorless tension control including the two SMA models was proposed. The sensing model which estimates the tension and displacement from the applied voltage, electrical-resistance and room temperature substituted for sensors. The inverse model which estimates the applied voltage canceled or reduced the effects of the hysteresis and nonlinearity as the feedforward controller. The results of experiments with the proposed control framework show that the actual tensions closely followed the target tensions without sensors.

Keywords : SMA, Sensorless control, Tension control, Force control, Machine learning, GRU

1. 緒 言

SMA (形状記憶合金) アクチュエータは、通電によるジュール発熱により相変態を起こし、収縮させることができるワイヤ状のアクチュエータである。軽量で重量に対して大きな発生力を得られることが特徴であり、さらに相変態に伴い電気抵抗値が変化することを利用し、電気抵抗値の計測に基づくフィードバック制御系を構成することができることから(本間, 2009), センサ機能をも備えたソフトかつスマートな材料アクチュエータとしてロボットのサーボ系などに応用されてきた(Ikuta et al., 1988)(田島他, 2011)(西田, 2013)。変位制御に関してはモデルベース(Pai et al., 2018)から機械学習(Song et al., 2003)(Ma et al., 2004)に至るまで様々な手法を適用した多くの研究が行われているが、更なる高機能化のためには、変位だけでなく、張力のセンシングや制御も行えることが望ましい。SMAの張力制御に関する研究例はこれまでもいくつか見られるが(Grant and Hayward, 2000)

No.19-00143 [DOI:10.1299/transjsme.19-00143], J-STAGE Advance Publication date : 30 January, 2020

^{*1} 正員, 北海道大学 大学院工学院 (〒060-8628 北海道札幌市北区北13条西8丁目) (現 北海道立総合研究機構 工業試験場)^{*2} 正員, 北海道大学 大学院工学研究院

E-mail of corresponding author: itousoki@frontier.hokudai.ac.jp

Fig. 1 Schematic of a major loop and minor loops in phase transformation of SMAs. SMAs have hysteretic and nonlinear characteristics in relations between the temperature and phase ratio.

Fig. 2 Schematic of phase transformation processes in SMAs. When the temperature is low, SMAs have martensite phases; the twinned-martensite easily transforms to the detwinned-martensite by applying a small load. When the temperature rises above the transformation point, phases transform to the austenite, and the strain is recovered.

(Pai et al.,2018), ロードセルなどのセンサを利用したものが多く、センサレスによる SMA の張力制御の実現例は示されていない。センサレス制御は、小型、軽量、シンプルな構造といった SMA アクチュエータの特徴を損なわずに機能強化ができるという点において大変有益であると考えられる。例えば SMA アクチュエータで駆動される小型軽量ロボットハンドの構造を全く変更せずに、応把持力調整機能を追加できるなどの応用が考えられる。

SMA は図 1 に模式的に示すように、温度-相比率などの関係に非線形の要素を持ち、かつその加熱・冷却過程間にヒステリシスが存在する。さらに、この関係は応力（アクチュエータの張力）によって影響を受け、また、実システムにおいては上記ヒステリシスループにおけるメジャーループばかりでなくマイナーループを経る過程を考慮する必要がある。既存の SMA モデルには応力などの負荷を考慮したものも多く（Brinson, 1993）（工藤, 原田, 2017）、張力のセンサレス制御が理論的には可能であることが推測できる。しかし、既存の SMA モデルの多くは SMA の温度測定を必要とするが、細い SMA ワイヤの温度を正確に計測することは難しく、さらに温度センサの応答性が制御性能に制約を与えるという問題点がある。また、入力電圧などを使用し、温度測定の不要なモデルを構築できたとしても、ヒステリシスなどの複雑な要素を含むモデルをもとに制御系を構築することは容易ではない。

そこで、本研究では Gated Recurrent Unit (GRU) (Cho et al.,2014) を使用する。GRU は時系列データを扱うリカレントニューラルネットワーク (RNN) から発展した手法の一つであり、株価予測分析や自然言語処理に応用されている。RNN は制御分野ではシステム同定 (Wang,2017) や制御器設計 (佐藤他, 2005) などに利用されており、SMA に対して電流-変位の関係のモデル化に使用された例 (Fathi and Mozaffari,2014) もあることから、張力を考慮した SMA モデルの構築にも適用が可能であると期待できる。また、GRU による SMA のモデル化には相比率や温度など測定困難な SMA の状態量を考慮することなく、ヒステリシスや非線形特性をモデル化できることから、モデル化を行う際の実験系を容易に構築できる利点がある。本研究では SMA の張力制御をセンサレスで行うために二つのモデルを使用する手法を提案する。一つはセンサによる測定値の代わりに SMA の張力や変位を推定するためのセンシングモデルである。もう一つは逆モデルであり、これは Song らによるフィードフォワードニューラルネットワーク制御器 (Song et al.,2003) を参考に、さらに、張力の入力を加えたフィードフォワード制御器を GRU によって作成したものであり、SMA のヒステリシスや非線形性の影響をフィードフォワード的に軽減させることを目的に使用する。提案手法による SMA アクチュエータのセンサレス張力制御について、実験的に検証する。

2. GRU による SMA のモデル化

2-1 SMA の特性

本研究で使用する SMA の特性について述べる。概要図を図 2 に示す。SMA の相変態は主に高温相である Austenite 相（以下 A 相）と、低温相である Martensite 相（以下 M 相）があり、M 相はさらに低応力相の Twinned-Martensite 相（以下 Twinned-M 相）と高応力相の Detwinned-Martensite 相（以下 Detwinned-M 相）に分けることができる。SMA は冷却された状態で M 相であり、加熱すると A 相へと逆マルテンサイト変態し、ひずみが減少する。そこから冷却を行うと A 相から M 相へと変態するマルテンサイト変態し、ひずみが増加する。これらの現象を形状記憶効果、増減するひずみを回復ひずみと呼ぶ。SMA アクチュエータはこの回復ひずみを利用して変位を得る。また、加熱した SMA に負荷をかけることによっても A 相から M 相へと変態し、そこから除荷すると M 相から A 相へと変態する。これらの変態を超弾性効果と呼ぶ。SMA は超弾性効果によって、ひずみを大きく与えても塑性変形せずに除荷でひずみが元に戻る。さらに低温の M 相でも応力変動によって変態が生じ、負荷によって Twinned-M 相から Detwinned-M 相へと変態する。しかし、除荷によって Detwinned-M 相から Twinned-M 相への変態は起きない。

2-2 GRU の概要

GRU はリカレントニューラルネットワークで学習を行う際に、時系列データが長くなると勾配が消失、もしくは発散し易くなり学習が困難になるという問題を解決するために提案された手法の一つである。同じ目的で提案された Long Short Term Memory (LSTM) と同等のモデルとしての表現力を持ちつつ、構造が簡単でパラメータ数が少ないという特徴がある。

本研究では SMA のヒステリシス効果を扱うためにこの GRU を使用している。GRU は GRU block をニューラルネットワークの中間層に複数個並べたものであり、ある時間 t の入力を $\mathbf{x}(t)$ リセットゲートの値を $r(t)$ 、更新ゲートの値を $z(t)$ 、活性化後の値を $\hat{h}(t)$ 、最終的な出力を $h(t)$ とすると j 番目の要素の GRU block は以下の合成関数で表される。

$$r_j(t) = \sigma([\mathbf{W}_r \mathbf{x}(t)]_j + [\mathbf{U}_r \mathbf{h}(t-1)]_j + [\mathbf{b}_r]_j) \quad (1)$$

$$z_j(t) = \sigma([\mathbf{W}_z \mathbf{x}(t)]_j + [\mathbf{U}_z \mathbf{h}(t-1)]_j + [\mathbf{b}_z]_j) \quad (2)$$

$$\hat{h}_j(t) = \tanh([\mathbf{W}_h \mathbf{x}(t)]_j + r_j(t)([\mathbf{U}_h \mathbf{h}(t-1)]_j + [\mathbf{b}_h]_j)) \quad (3)$$

$$h_j(t) = z_j(t)h_j(t-1) + (1 - z_j(t))\hat{h}_j(t) \quad (4)$$

ただし、 $\mathbf{W}_r$, $\mathbf{W}_z$, $\mathbf{W}_h$, $\mathbf{U}_r$, $\mathbf{U}_z$, $\mathbf{U}_h$, はそれぞれ入力、出力からの重み、 $\mathbf{b}_r$, $\mathbf{b}_z$, $\mathbf{b}_h$ はバイアスを表す。 σ はシグモイド関数である。

2-3 実験装置の概要

GRU によるモデルの学習に使用した教師データは実験により作成した。教師データ作成に使用した実験機構の概略図と一部を写した写真を図 3 に示す。センサなどの各要素はマイコン (Arduino) を通して PC に接続されており、PC 上にデータを記録できるようになっている。SMA は古河テクノマテリアル株式会社の NT-H7-TTR ϕ 0.1mm を用い、無負荷状態で完全に収縮した際の長さは 70.0mm であった。SMA への印加電圧や張力に変動を与え、そのときの変位、電気抵抗値を計測した。さらに、データ収集の間の室温変化の影響があることから、室温も同時に計測している。SMA への印加電圧はマイコンで出力した PWM 信号を増幅回路で増幅し、PWM のデューティ比を変化させることで行った。また、SMA に与える張力は SMA に滑車を通して直列につながれたバネの長さをサーボモータ (Dynamixel AX-12) によって変化させることで与えた。変位は LED 式変位センサによって計測を行った。電気抵抗値はホイートストーンブリッジ回路によって計測した。室温の計測は温度センサ (DS18B20+) を用いて行った。なお、リフレクタに接続されているバネは必ずしも必要ではないが、後述する制御用の実験構成 (図 10) と可能な限り条件を一致させるために取り付けられている。

Fig. 3 Experimental setup for dataset creation. The SMA actuator is energized by the amplified pwm voltage signal from the amplification circuit. The tension acting on the SMA actuator is varied by changing the spring length with the servo motor. The displacement is measured by the LED type displacement sensor. The electric resistance is measured by the wheatstone bridge circuit.

2.4 データセット作成手順

データセットは一定のサンプリング周期 0.2 秒の張力，デューティ比，電気抵抗値，変位の 20 秒間の計測データとし，上記の実験装置を使用して以下の手順を繰り返すことで取得した。

- (1) SMA の張力を 0.1N に保ち，30 秒間加熱した後，50 秒間冷却する。
- (2) 室温の計測を行う。
- (3) 乱数を用いて 100 項の数値を 2 つ作成し，それぞれ SMA の張力とデューティ比とする。
- (4) (3) で作成した数値に従い，サンプリング周期 0.2 秒で SMA に張力変動と温度変動を与え，そのときの電気抵抗値と変位を記録する。

SMA は低温時に応力を上昇させると Twinned-M 相から Detwinned-M 相への変態が起きるが，応力を減少させたときはその逆変態は起きない。よって同じ温度，応力であっても SMA の相比率は異なってしまうことから，正確なモデル化を行うためには，相比率を含めて初期条件を統一する必要がある。(1) の操作はこのために行った操作であり，SMA を加熱し一旦，完全に A 相にしたのちに室温に戻ることが目的である。次に，(3) の乱数を用いた数値の作成方法についてより詳しい手順を述べる。

図 4 に手順の概要を示す。 x は 0~99 までの整数であり，手順 (4) で使用する順番を表す。また y は張力とデューティ比の値である。まず，I では 1~20 の整数の乱数 N を定め， x から N 点をランダムで選び取り， X_n とする。II では X_n に対応する y 座標の値をそれぞれ乱数を用いて決める。III で図中の黒点である初期値を決める。SMA を冷却状態から開始することを前提としているため，デューティ比の初期値は常に 0 であり，張力の初期値は 0~1.0N の範囲の一樣乱数とした。IV では X_n, X_{n+1} 間の点を補完した。まず， y 座標の値を必要な個数だけ Y_n, Y_{n+1} の範囲内の乱数で求め， $Y_n < Y_{n+1}$ のときは昇順， $Y_n > Y_{n+1}$ のときは降順に並び替えた。また $n_x > X_{max}$ の範囲については一樣乱数で定めた。

荷重負荷の繰り返に伴う SMA の損傷を懸念することなく実行可能な実験回数を試行錯誤した結果，(1)~(4) の手順を合計 5800 回行いデータセットを作成することとした。またその際に記録された室温の範囲は 287.6K~301.3K の範囲にあった。室温は SMA の電気抵抗値などの値と比較してそれほど急激に変化するものではないため (2)~(4) の間は常に一定の値として記録した。SMA の加熱に使用した増幅回路の電源電圧は常に 1.65V で設定した。

2.5 GRU による SMA のモデル作成

先に述べたように SMA にはヒステリシスが存在し，これは張力（負荷条件）や電源電圧，室温などの多くの要因の影響を受ける。本研究ではこれらの関係をモデル化するために 2.2 で紹介した GRU を用いる。作成するモデルは以下の二つである。

Fig. 4 Dataset creation sequence. The x-coordinate of representative points are determined in I. In II, the y-coordinate of representative points are determined. In III, initial points are determined. Finally, points are connected with a smooth line.

- (1) SMA の電気抵抗値, デューティ比, 室温から張力と変位を計算するモデル. 以後センシングモデルと呼ぶ.
- (2) SMA の張力, 変位, 室温からデューティ比を計算するモデル. 以後逆モデルと呼ぶ.

まず, センシングモデルについて, モデルの概略図を図 5 に示す. このモデルは入力層と出力層の他に 100 個の GRU block からなる中間層を 2 層持っている. 図のように電気抵抗値, デューティ比, 室温を入力層に入力すると出力層のノードの値がそれぞれ張力と変位となるように学習させる. 本研究ではこれをセンサレス張力制御を行う際にセンサの代用としてセンシングを行うために使用する.

逆モデルについて, モデルの概略図を図 6 に示す. これは制御時に張力の目標値や変位の拘束条件などからフィードフォワード入力を算出し, センシングモデルからのフィードバックによって決定される入力と併用すること

Fig. 5 Schematic of the sensing model. It has three inputs of the electric resistance, duty ratio and room temperature. This model outputs the tension and displacement. Both of the two hidden layers consist of 100 GRU blocks.

Fig. 6 Schematic of the inverse model. It has three inputs of the tension, displacement and room temperature. This model outputs the duty ratio. Both of the two hidden layers consist of 100 GRU blocks.

よって SMA のヒステリシスによる影響を軽減させることを目的としている。

これら二つの GRU はともに 2.4 にて作成したデータセットを用いて学習を行い, GRU の内パラメータをまとめて θ とすると θ に関する評価関数は, センシングモデル, 及び逆モデルに対してそれぞれ

$$E_1(\theta) = \sum_{t=0}^{99} ((y_T(t) - T(t))^2 + (y_D(t) - D(t))^2) \quad (5)$$

$$E_2(\theta) = \sum_{t=0}^{99} (y_q(t) - q(t))^2 \quad (6)$$

とした。ただし, $y_T(t)$, $y_D(t)$, $y_q(t)$ はそれぞれ GRU による張力, 変位, デューティ比の推定値であり, $T(t)$, $D(t)$, $q(t)$ はそれぞれデータセットに記録されている実際の張力, 変位, デューティ比の値である。

データセットの 90% を学習用データセット, 残り 10% を検証用データセットとし, 学習用データセットを用いて誤差逆伝搬法による学習を行った。張力, デューティ比, 電気抵抗値, 変位, 室温の値はそれぞれ値域が $[-1, 1]$ の範囲となるように規格化を行った。また, Early stopping を適用し, 検証用データでの損失関数が 100 回連続で最小値を更新しなくなった時点で学習を打ち切った。その他の学習時の条件を表 1 に示す。センシングモデル, 逆モデルそれぞれについて学習を行った結果, センシングモデルでは張力, 変位それぞれの絶対値平均誤差は張力が 0.032N, 変位が 0.011mm であった。

Table 1 Learning conditions of GRU.

OS	Windows 10 Pro 64bit
CPU	Intel Core™ i5-3570K
GPU	NVIDIA GeForce GTX660
programming language	Python(Anaconda 3.6)
Framework	Chainer(version 4.2.0)
Optimizer	Adam
Minibatch-size	580
Max epoch	300

Fig. 7 Sample of the actual tension in the dataset and the estimated tension by GRU. In the entire dataset, the mean absolute error is 0.032N.

Fig. 8 Sample of the actual displacement in the dataset and the estimated displacement by GRU. In the entire dataset, the mean absolute error is 0.011mm.

Fig. 9 Sample of the actual duty ratio in the dataset and the estimated duty ratio by GRU. In the entire dataset, the mean absolute error is 0.032.

また、逆モデルについてはデューティ比の絶対値平均誤差は 0.032 となった。図 7, 図 8, 図 9 に張力, 変位, デューティ比それぞれについてのデータセットのサンプルと学習後の GRU で推定を行った結果を示す。黒線がデータセットの値, 赤線が GRU による推定値であり, いずれについても黒線と赤線が精度よく一致しており, GRU によって SMA の特性を再現できていることがわかる。なお, 推定対象によって精度にばらつきが見られるが, この原因は, 推定条件ごとの学習データ数のばらつき, 測定対象ごとに異なるセンサ精度の, 入出力関係に対する相対的な影響度の違い, SMA の非線形性に起因する, 入出力関係における応答性や感度の違い, などの複合的な影響であると推測される。

3. GRU を用いた張力のセンサレス制御

3.1 実験準備

次に 2.5 節にて作成した GRU を使用して SMA の張力のセンサレス制御を行う。実験機構の概略図を図 10 に示す。これは図 3 の実験機構で張力調節を行っていたサーボモータの代わりに, SMA の形状回復力による張力を測定するためのロードセルを, 滑車を介して, SMA と直列に接続したものである。このロードセルの出力は制御系内では使用せず, 制御性能の検証のみに使用した。さらに実験はワイヤに弛みを与えた状態から開始するが, その際 SMA の張力が 0 となることから, データセットに含まれる学習の範囲を超えてしまい, モデルの適用が困難になる。そのためばね定数の非常に小さいばねを用いて, SMA に常に微小な張力が加わるようにした。

まず, ロードセルの出力と GRU ネットワークの出力を一致させるために以下の手順で GRU の出力に対してキャリブレーションを行った。

- (1) SMA が収縮できるように SMA に取り付け付けたワイヤを十分に弛ませる。
- (2) 30 秒間加熱した後, 50 秒間冷却する。
- (3) 室温の計測を行う。
- (4) SMA が収縮した際に張力がロードセルまで伝わるようにワイヤの弛みを小さくする。
- (5) 三角波状のデューティ比を SMA に印加し, その間のロードセルの出力を記録する。
- (6) 電気抵抗値, デューティ比, 張力をそれぞれ以下の式で変換し, GRU に入力して張力の推定値を得る。

$$\hat{f}_i = a_i f_i + b_i \quad (7)$$

ただし, f_i は電気抵抗値, デューティ比, 張力の値で $\hat{f}_i$ は変換後の値を表す。

- (7) (6) で得られる張力の推定値とロードセルの出力との二乗誤差が最小となるように式 (7) の a_i , b_i 値を最適化した。

Fig. 10 Experimental setup for tension control. Unlike the experimental setup for dataset creation, there is no servomotor. The actual tension is measured by the wire-connected loadcell.

Fig. 11 Tension versus duty after the calibration. The estimated tension is close to the loadcell value. And it demonstrates the hysteresis.

Fig. 12 Block diagram of the designed control system. Estimated values by the sensing model are feedbacked instead of the measured value. The inverse model is used to reduce the hysteresis.

上記の操作によって得られたデューティ比と SMA 張力の関係と最適化後のセンシングモデルによる張力の推定値を図 11 に示す。センシングモデルによる張力の推定値を実線でロードセルの値を点線で示した。また、上記の手順 (5) の間での SMA の変位の最小値が 0.91mm だったときの結果を黒線、0.65mm であったときの結果を赤線で示す。図 11 からこの実験機構によって SMA に与えるデューティ比と張力の間にヒステリシスが存在していることがわかる。また、張力制御を行っている際の SMA の変位によってこのヒステリシス曲線が変化することがわかる。上記の手順でキャリブレーションを行うことで GRU による張力の推定値とロードセルの値がおおよそ一致することが確認できた。以降の実験ではセンシングモデル、逆モデルとともに電気抵抗値、デューティ比、張力の値は上記の手法でキャリブレーションを行った値を使用するものとする。

3.2 張力制御実験

張力制御の実験は以下の手順で行った。

- (1) SMA が収縮できるように SMA に取り付けられたワイヤを十分に弛ませる。
- (2) 30 秒間加熱した後、50 秒間冷却する。
- (3) 室温の計測を行う。
- (4) SMA が収縮した際に張力がロードセルまで伝わるようにワイヤの弛みを小さくする。
- (5) 後述する制御器に目標値を与え、ロードセルからの出力、電気抵抗値、変位、デューティ比、GRU ネットワークの出力を記録する。

提案する制御系のブロック線図を図 12 に示す。この制御器は PID 制御器に GRU によるフィードフォワード入力を組み合わせている。さらに、センシングモデルによる張力の推定値を目標値に収束させることができれば、実際の SMA の張力も目標値付近に制御することができると考え、ロードセルによる計測値を使用せずに構築されている。

まず、PID 制御器について、PID 制御器への偏差は以下のように計算する。

$$e(t) = y^d(t) - y_T(t) \quad (8)$$

ここで y^d は目標値であり、フィードバックさせる張力の信号はロードセルなどのセンサによって計測された値ではなくセンシングモデルによる張力の推定値を使用する。目標値に対して張力の推定値がずれた際に、PID 制御によってずれを修正する方向に入力が加わるようになっている。PID 制御器のゲインは試行錯誤的に決定した。

次に、逆モデルによるフィードフォワード入力について、これは SMA の持つヒステリシスや非線形性による影響を軽減することを目的としている。逆モデルは入力として室温の他、張力と変位を必要とするが、本研究では SMA の変位が未知であるため、あらかじめ SMA の変位を求めることはできない。そこで変位の入力にはセンシングモデルによる 1 ステップ前の変位の推定値を使用している。

実験開始時、SMA につながれたワイヤは弛んでおり、SMA へどのような入力を与えても、ロードセルの値が変化しないことによる不感帯がみられる。不感帯では SMA の変位が大きく変化するため逆モデルを用いて正しく

Table 2 Experimental conditions.

OS	Ubuntu 18.04 LTS 64bit
CPU	Intel Core™ i7-2600
programming language	Python(Anaconda 3.6)
Framework	Chainer(version 4.2.0)
Proportional gain	145 [1/N]
Differential gain	160 [s/N]
Integral gain	7.6 [1/Ns]

フィードフォワード入力を求めることができない．そのため，図 12 の制御はセンシングモデルによる張力の推定値が一定の値（本実験では 0.2N）に到達した時点から適用し，それまで一定のデューティ比によって SMA を加熱した．本実験での目標値は，以下の 2 通りで実験を行った．

$$y^d(t) = \begin{cases} y_T(t_0) + (1.4 - y_T(t_0))(1 - e^{-\frac{t}{T}}) & (t < 20s) \\ y_T(20) + (0.8 - y_T(20))(1 - e^{-\frac{t}{T}}) & (t > 20s) \end{cases} \quad (9)$$

$$y^d(t) = \begin{cases} 0.2 & (t < 20s) \\ -6 \sin \frac{2\pi t}{T} + 0.8 & (t > 20s) \end{cases} \quad (10)$$

ただし， t_0 はセンシングモデルによる張力の推定値が 0.2N に到達し，図 12 の制御を適用した時点の時刻， T は正弦波の周期である．今回の実験では正弦波の周期は 4 秒，8 秒とした．

そのほかの実験条件を表 2 に示す．

3.3 実験結果と考察

まず，式 (9) の目標値について，実験結果を図 13 に，逆モデルの出力と制御器全体の出力を図 14 に示す．図上側は SMA の張力がおおよそ収束した際の SMA のおおよその変位である．図 13 からどちらの場合においてもセンシングモデルによる張力の推定値を目標値に追従させることができていることがわかる．しかし，張力の推定値とロードセルの値に誤差があることから図 13 のように定常偏差を生じる場合がみられる．また，図 14 から逆モデルによるデューティ比と実際に制御器から出力されるデューティ比に誤差があり，目標値軌道に張力の推定値が完全には追従できていないことがわかる．

また，特に SMA の変位が小さくなる場合において制御器の出力が振動的になっていることがわかる．まず，フィードフォワードによる出力の振動について逆モデルにセンシングモデルの変位の推定値をフィードバックさせていることにより，推定値の誤差の影響を受けていると考えられる．さらに，実際の制御器の出力は逆モデルによるものよりも大きく振動しているが，これは PID ゲインを決める際に応答性を重視したためと考えられる．PID ゲインを小さくしていくとより滑らかな制御器の出力を得やすいが，ロードセルの値が SMA への入力や張力の推定値と比較し，それほど振動していないことから，実際にはデューティ比が振動的になることがそれほど問題になることは少ないと考えられる．これは SMA が温度変化によって駆動するアクチュエータであり，1 次遅れ要素を持つことから，細かい振動成分が抑制されるためと考えられる．

表 3 に目標値，張力推定値，ロードセルのそれぞれの絶対値平均誤差と誤差の最大値を，図 15 に目標値，張力推定値，ロードセルのそれぞれの誤差を示す．目標値とロードセルの計測値を一致させることが制御の目的であるが，実験結果では目標値-張力推定値間の誤差に比べて，張力推定値-ロードセル計測値間の誤差が大きいことから，さらなる制御性能の向上にはセンシングモデルの精度の向上が重要であると言える．本研究ではデータセット作成を自動化するために張力制御の実験とデータセット作成には異なる実験装置を使用した．表 3，図 15 から，張力制御実験での絶対値平均誤差がモデル作成時のデータセットに対する絶対値平均誤差よりもやや大きくなっていることから，本手法を応用したロボットなどにおいて，実機を用いて実際に作業を行わせることでデータの収集を行うことができれば SMA の張力制御に関してより高い性能を達成できる可能性があると考えられる．

次に，式 (10) の目標値に対する実験結果を図 16 に示す．動的な入力に対しても，目標値に良く追従できている

ことが分かる．参考として，逆モデルによるフィードフォワード入力なしの場合の実験結果を図 17 に示す．図 16 と比較すると，目標値に対し，センシングモデルによる推定値，ロードセルによる測定値ともに遅れや振幅の減少が見られる．また，推定値と測定値の間にも誤差が生じている．

図 18 は逆モデルによるフィードフォワード入力がある場合とない場合の制御器の出力である．図 11 に示すように SMA の張力とデューティ比の関係は全く線形ではないにもかかわらず，逆モデルを用いない場合は，目標値の正弦波に対し，より線形に近い出力となっている（青線）．これが図 17 の誤差の原因であると考えられる．これに対して，逆モデルを用いた場合は，正弦波とは大きく異なる出力となっており（赤線），これは，逆モデルから SMA の非線形性に対応した出力が発生した結果と考えられる．

Fig. 13 Control results of the tensions. The displacement of the SMA actuator converges to about 0.6mm(left) and 1.8mm(right) during the experiment. The actual tensions measured by the loadcell are close to the target tensions.

Fig. 14 Control results of the controller and inverse model outputs. The real duty ratios are different from the inverse model outputs because there are small errors between the estimated and target tensions.

Table 3 Errors among estimated tensions, loadcells values and target tensions.

Errors	0.62mm	1.8mm
MAE of estimated tension and loadcell value	0.058N	0.052N
MAE of estimated tension and target tension	0.026N	0.015N
MAE of loadcell value and target tension	0.059N	0.055N
Max error of estimated tension and loadcell value	0.50N	0.39N
Max error estimated tension and target tension	0.34N	0.34N
Max error of loadcell value and target tension	0.52N	0.62N

Fig. 15 Errors among the estimated tensions, actual tensions and target tensions. The errors between the estimated tensions and loadcell values are larger than the errors between the estimated and target tensions.

Fig. 16 Control results of the tensions with the inverse model. Periods of target sine waves are 4s(left) and 8s(right). The actual tensions measured by the loadcell follow target tensions well.

Fig. 17 Control results of the tensions without the inverse model. Periods of target sine waves are 4s(left) and 8s(right). The actual tensions measured by the loadcell are delayed and damped from the target tensions.

Fig. 18 Control results of the controller outputs. Periods of target sine waves are 4s(left) and 8s(right). The outputs with the inverse model have different shapes to the target sine waves(red lines), while the outputs without the inverse model have more linear shapes to the target tensions(blue lines).

4. 結 言

本研究では、SMA のセンサレス張力制御を行うことのできる GRU を用いた新しい手法を提案した。この手法には2つの GRU モデルを使用しており、一つはセンサの代用として SMA の張力や変位の推定を行うためのもの、もう一つはフィードフォワード入力によって SMA のヒステリシスや非線形性による影響を軽減するためのものである。実験により、張力と印加電圧を複雑に変化させた際の電気抵抗値、変位、室温を記録することでデータセットを作成し、GRU を用いてこれらの関係を表すモデルを高精度で構築できることを確認した。また、実験による提案手法の検証を行い、SMA の張力をセンサを用いずに目標値近傍に収束させることができることを示した。

謝 辞

SMA を提供いただいた古河テクノマテリアル株式会社に感謝の意を表す。

文 献

- Brinson, L. C., One-dimensional constitutive behavior of shape memory alloy: Thermomechanical derivation with non-constant material functions and redefined martensite internal variable, Journal of the Intelligent Material System and structure, Vol.4 (1993), pp.229-242.
- Cho, K., Van, B. M., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y., Learning phrase representations using rnn encoder decoder for statistical machine translation (2014), arXiv preprint arXiv:1406.1078.
- Fathi, A. and Mozaffari, A., Modeling a shape memory alloy actuator using an evolvable recursive black-box and hybrid heuristic algorithms inspired based on the annual migration of salmons in nature, Applied Soft Computing, Vol.14, Part B(2014), pp.229-251.
- Grant, D. and Hayward, V., Constrained force control of shape memory alloy actuators, Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No.00CH37065), Vol.2(2000), pp.1314-1320.
- 本間大, 機能異方性形状記憶合金の開発と応用, 精密工学会誌, Vol.75, No.6 (2009), pp.690-694.
- Ikuta, K., Tsukamoto, K. and Hirose, S., Shape memory alloy actuator system with electrical resistance feedback and application for active endoscope, Proceedings of the IEEE International Conference on Robotics and Automation(1988), pp.427-430.
- 工藤光輝, 原田宏幸, 負荷外乱に対応した SMA アクチュエータのモデル化および電気抵抗値フィードバック制御, 日本機械学会論文集, Vol.83, No.855 (2017), DOI:10.1299/transjsme.17-00139.
- Ma, N., Song, G. and Lee, H. J., Position control of shape memory alloy actuators with internal electrical resistance feedback using neural networks, Smart Materials and Structures, Vol.13 (2004), pp.777-783.

- 西田麻美, 爪を有する二脚式ソフトロボットの開発 (爪とストッパーを利用したソフトロボットの方向転換について), 日本機械学会論文集 C 編, Vol.79, No.808 (2013), pp.4831-4841.
- Pai, A., Riepold, M. and Ansgar, T., Model-based precision position and force control of SMA actuators with a clamping application, *Mechatronics*, Vol.50 (2018), pp.303-320.
- 佐藤哲平, 明愛国, 下条誠, ゴルフスイングロボットに関する研究-リカレントネットワークを用いた学習制御-, 第 48 回自動制御連合講演会講演論文集 (2005), pp.177-180.
- Song, G., Chaudhry, V. and Batur, C., Precision tracking control of shape memory alloy actuators using neural networks and a sliding-mode based robust controller, *Smart Materials and Structures*, Vol.12 (2003), pp.223-231.
- 田島悠介, 原田宏幸, 梶原逸朗, SMA の特性を利用した魚型ロボット・スマートひれの制御, 日本機械学会ロボティクス・メカトロニクス講演会 2011(2011), 1A2-L13.
- Wang, Y., A new concept using LSTM neural networks for dynamic system identification, *American Control Conference*(2017), pp.5324-5329.

References

- Brinson, L. C., One-dimensional constitutive behavior of shape memory alloy: Thermomechanical derivation with non-constant material functions and redefined Martensite internal variable, *Journal of the Intelligent Material System and structure*, Vol.4 (1993), pp.229-242.
- Cho, K., Van, B. M., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y., Learning phrase representations using rnn encoder decoder for statistical machine translation (2014), arXiv preprint arXiv:1406.1078.
- Fathi, A. and Mozaffari, A., Modeling a shape memory alloy actuator using an evolvable recursive black-box and hybrid heuristic algorithms inspired based on the annual migration of salmon in nature, *Applied Soft Computing*, Vol.14, Part B(2014), pp.229-251.
- Grant, D. and Hayward, V., Constrained force control of shape memory alloy actuators, *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No.00CH37065)*, Vol.2 (2000), pp.1314-1320.
- Homma, D., Development and application of function anisotropic shape memory alloy, *Journal of the Japan Society for Precision Engineering*, Vol.75, No.6 (2009), pp.690-694 (in Japanese).
- Ikuta, K., Tsukamoto, K. and Hirose, S., Shape memory alloy actuator system with electrical resistance feedback and application for active endoscope, *Proceedings of the IEEE International Conference on Robotics and Automation*(1988), pp.427-430.
- Kudo, K. and Harada, H., Modeling and electrical-resistance feedback control of SMA actuators adapting to load disturbance, *Transactions of the JSME(in Japanese)*, Vol.83, No855 (2017), DOI:10.1299/transjsme.17-00139.
- Ma, N., Song, G. and Lee, H. J., Position control of shape memory alloy actuators with internal electrical resistance feedback using neural networks, *Smart Materials and Structures*, Vol.13 (2004), pp.777-783.
- Nishida, M., Development of biped soft robot with nail (Turn using nail and stopper for biped soft robot), *Transactions of the Japan Society of Mechanical Engineers, Series C*, Vol.79, No.808 (2013), pp.4831-4841 (in Japanese).
- Pai, A., Riepold, M. and Ansgar Trächtler, Model-based precision position and force control of SMA actuators with a clamping application, *Mechatronics*, Vol.50 (2018), pp.303-320.
- Sato, T., Ming, A. and Shimojo, M., Study on Golf Swing Robot -Learning control using a recurrent neural network-, *Proceedings of the 48st Japan Joint Automatic Control Conference* (2005), pp.177-180(in Japanese).
- Song, G., Chaudhry, V. and Batur, C., Precision tracking control of shape memory alloy actuators using neural networks and a sliding-mode based robust controller, *Smart Materials and Structures*, Vol.12 (2003), pp.223-231.
- Tajima, Y., Harada, H. and Kajiwar, I., Control of fish robot and smart-tailfin by using SMA characteristic, *Proceedings of the 2011 JSME Conference on Robotics and Mechatronics* (2011), 1A2-L13 (in Japanese).
- Wang, Y., A new concept using LSTM neural networks for dynamic system identification, *American Control Conference*(2017), pp.5324-5329.