

# 深層学習によるターニングセンターの 熱変位推定と抑制に関する研究

(A Study on Prediction and Compensation  
of Thermal Displacement of Turning Center  
Based on Deep Learning)

2021年9月

成松 宏一郎



博士論文 2021年度（令和3年度）

## 深層学習によるターニングセンタの 熱変位推定と抑制に関する研究

### 論文要旨

高齢化などによる生産年齢人口の減少により、先進国の製造業において自動化や省人化の需要が高まっている。工作機械による生産活動で省人化や自動化を達成するには、熟練工の知識や経験に基づいた加工条件の調整などを行わなくても、長い期間にわたって加工精度を維持することが重要である。工作機械の機械構造には、機械周辺の温度変化や機械要素からの発熱によって温度変化と熱変形が起こる。この熱変形は、安定した加工精度を阻害する代表的な要因とされている。工作機械の熱変形に対しては、様々な対策が提案されている。工作機械周辺の温度管理を実施し、機械内部の熱源の影響の排除や温度管理を実施することが根本的な対策といえるが、工場環境や様々な設計制約の中では容易でないことも多い。そこで、発生した熱変位を推定し、それらを打ち消すようにCNC装置による指令位置を制御することで、加工対象物の精度劣化を抑制する手法が、これまでに非常に多く研究され、市販機に搭載されたものも多い。本研究では、ターニングセンタの熱変位について、機械構造に取り付けた温度センサの値から、深層学習による熱変位推定モデルで熱変位を推定し、CNC装置で補正制御する手法について提案した。

熱変位補正のための温度センサを工作機械に取り付ける場合、温度センサを取り付けた場所の温度変化が、熱変位に与える影響が大きい箇所に取り付けることが望ましい。工作機械構造の熱変位と構造の温度変化の関係は、有限要素法などにより計算することができるが、機械構造全体について、温度変化と熱変位の間関係を一度に可視化することは難しい。そこで、工作機械構造の加工対象物-工具間の相対変位に及ぼす機械構造の温度変化の影響を評価する方法として、「熱感度」を提案した。実際の工作機械構造の熱感度を計算する方法として、有限要素法の計算を利用する方法を示した。

ケーススタディとして、ターニングセンタの熱感度を計算して可視化した。ターニングセ

ンタの熱感度は、ベッド上面の温度上昇で主軸とタレットが離れる方向の変位が生じ、ベッド背面の温度上昇で主軸とタレットが近づく方向の変位が生じることを示す結果であった。次に、熱感度の計算結果と実際の工作機械の主軸-タレット間の相対変位を比較するために実験を実施した。ターニングセンタの周辺温度を変化させた際の機械構造の温度と主軸-タレット間変位を計測した。機械座標系 X 軸方向の熱変位に着目すると、機械の周辺温度の上昇に伴って主軸とタレットが近づく方向へ変位し、その後主軸とタレットが離れる方向へ変化した。この変位は、主軸とタレットが近づく方向に作用する熱感度を持つベッド背面の温度上昇により、まず主軸とタレットが近づく変位が生じ、遅れて離れる方向に作用する熱感度を持つベッド上面の温度上昇により変位の緩和と変位方向の反転が発生するメカニズムである。温度変化、変位の関係と熱感度から、ターニングセンタの環境温度変化に対する変形メカニズムを説明することができた。

さらに、機械周辺の温度変化に対する熱変位を抑制する目的で、熱感度の計算ケーススタディを実施したターニングセンタに対してカバーとファンを取り付け、機械構造の温度分布を最適化する実験を実施した。温度変化の早いベッド背面は、空気との熱交換を阻害するカバーを取り付け、温度変化の遅いベッド上面は、空気との熱交換を促進するファンを取り付けた。カバーとファンの取り付けによって機械座標系 X 軸方向の熱変位を抑制することができた。熱感度の計算結果と熱変位の計測結果に基づいて、熱変位へ影響を与える機械構造の部位を特定し、対策を施すことで熱変位が抑制できる結果を得た。

本論文の第 3 章以降では、ターニングセンタの熱変位を推定するための、深層学習を用いた熱変位推定モデルの構築と、それを用いた熱変位補正に関して、新しい提案を行った。工作機械の熱変位推定のために、従来の研究で多く用いられてきた数式によるモデル化手法は、次数、静的・動的、線形・非線形など、設計者が対象に合わせて選択しなければならない要素が多い。そのような必要性が少なく、性能の良いモデル化手法として深層学習が挙げられる。そこで、CNN を用いた熱変位推定モデルを提案した。

深層学習では、多くのデータで学習すると精度が向上することが知られている。工作機械の熱変位推定モデルを学習するために、多数のターニングセンタの熱変位を測定する方法を示した。熱変位データとして、工作機械の機械構造に取り付けた温度センサと、主軸-タレット間の相対変位を非接触変位センサを用いて測定した。熱変位に影響する要因として、(1) クーラントの温度上昇、(2) 主軸運転、(3) 軸稼働、(4) 環境温度変化、の 4 つを挙げ、それぞれが熱変位に及ぼす影響を測定できるように測定条件を設定して熱変位データの収集方法を述べた。

深層学習による熱変位推定モデル学習のケーススタディとして、6 台の同一機種ター

ニングセンタについて、環境温度変化条件の熱変位データを収集し、提案した CNN による深層学習によって熱変位推定モデルを学習した。学習した熱変位推定モデルの誤差は、0.01 mm 程度以下であり、熱変位を高精度に推定することができた。また、L2 正則化による重回帰分析（リッジ回帰）による熱変位推定モデルと、提案した CNN による熱変位推定モデルの推定性能を比較し、CNN の方が良好な結果であった。

工作機械の熱変位推定や補正制御において、熱変位推定モデルや推定値の信頼性は非常に重要である。信頼性が低いと、本来適用されるべき補正量が適用されず、加工対象物の品質低下の原因になるばかりでなく、過大な補正量が適用されて機械の故障の原因になることも考えられる。そこで、「Bayesian dropout」を用いて熱変位推定モデルや推定値の信頼性を推定分布として計算する方法を提案した。

信頼性計算のケーススタディとして、6 台の同一機種ターニングセンタの、クーラント温度上昇、主軸運転、軸稼働、環境温度変化の各条件の熱変位データを収集し、3 台の機械のデータで CNN による熱変位推定モデルを学習した。学習データと、学習には使用しなかった評価用の 3 台の機械のデータで、熱変位の推定値と推定分布を計算した。学習データと評価データで、熱変位の推定精度と推定分布に大きな差はなく、熱変位推定モデルは、評価用データに対しても、十分な推定精度を示した。

熱変位推定モデルや推定値の信頼性を低下させる条件として、入力データである温度センサの故障を想定したシミュレーションを実施した。温度センサの種類として抵抗出力式と電圧出力式について、断線と接触不良の故障形態を仮定した。学習した熱変位推定モデルへ、温度センサの故障シミュレーション信号を入力し、推定精度と推定分布の変化を調べた。故障によって熱変位推定モデルへ入力される値の変化が相対的に大きくなる抵抗式温度センサの故障条件では、熱変位の推定誤差と推定分布が共に大きくなった。さらに、抵抗式温度センサの接触不良を考慮した条件では、熱変位の推定値と推定分布の時間変動も大きくなる結果であった。

計算した推定分布が大きい場合に、工作機械の熱変位制御に使用する補正量が大きく変動したり、過大な補正量が適用されることがないようにするために、熱変位推定モデルと工作機械の CNC 装置の間に移動平均フィルタを追加して補正量を修正する手法を提案した。移動平均フィルタは、推定分布の計算結果に応じて平均長を変更した。推定分布が大きい場合は平均長を大きくとって変動の影響が少なくなるようにし、分布が小さい場合は小さい平均長で推定値をそのまま採用するようにした。温度センサの故障シミュレーション信号を入力した場合、熱変位推定結果への影響が大きかった抵抗出力式温度センサの故障条件の場合には、補正量の修正が強く働いて異常な補正值が適用されることを防ぎ、熱変位推定結果への

影響が小さかった電圧出力式温度センサの故障条件の場合には、補正量はほとんど修正されずに高精度な補正値を維持することができた。

提案した熱変位推定モデルによる推定分布の計算機能と、推定分布の計算結果を使用した補正量の修正アルゴリズムを、熱変位推定モデルの学習用に熱変位データを収集したターニングセンタと同一機種 of 機械に搭載し、切削試験で効果を確認した。主軸運転条件と軸稼働条件を組み合わせた状態で切削試験を実施し、補正制御をしない場合の外径変化が 0.031 mm であったのに対し、提案手法で補正制御を実施した場合は 0.018 mm の外径変化であった。切削試験に使用した機械は、学習用の熱変位データを取得した機械ではないが、熱変位を抑制できる結果となり、推定分布の計算による信頼性評価と補正量の修正アルゴリズムで実際に加工対象物の加工精度を向上できることを確認できた。

深層学習による工作機械の熱変位推定において、熱変位推定モデルや推定値の信頼性に影響を与える代表的な要素として、センサの故障により生じる入力データの外乱が挙げられる。そこで、深層学習による熱変位推定モデルを学習する際に、あらかじめ想定できる温度センサの故障状態に基づいてシミュレーションした、温度センサの故障信号を正常信号と混合して学習することで、温度センサの故障に対してロバストな熱変位推定モデルが学習できる方法を提案した。

温度センサ故障を考慮した学習のケーススタディとして、CNN による熱変位推定モデルで温度センサの接触不良と断線を故障状態として考慮した学習を実施した。故障状態を考慮した学習によって、熱変位推定結果に生じる変動を抑制できることを示した。あらかじめ想定できる温度センサの故障パターンについて、故障により生じる外乱に対してロバストな熱変位推定モデルを構築することができた。

# 目次

<b>第 1 章</b>	<b>序論</b>	<b>1</b>
1.1	背景	1
1.2	先行研究	3
1.2.1	工作機械に係る熱源と熱変位	3
1.2.2	工作機械の熱源が熱変位に及ぼす影響を実際に低減する方法に関する先行研究	5
1.2.3	工作機械の熱変位の推定と補正による抑制に関する先行研究	6
1.3	工作機械の熱変位補正に関する課題と本研究の提案	7
1.4	本論文の構成	8
<b>第 2 章</b>	<b>工作機械の構造温度変化が主軸-タレット間の熱変位に及ぼす影響の可視化</b>	<b>11</b>
2.1	緒言	11
2.2	熱感度の定義	12
2.2.1	研究目的	12
2.2.2	熱感度の定義	13
2.3	有限要素モデルによる熱感度の計算と計算量削減	13
2.3.1	有限要素モデルによる熱感度の計算	13
2.3.2	熱感度の計算量削減	16
2.4	ケーススタディ：ターニングセンタの熱感度と熱変位抑制	18
2.4.1	ターニングセンタの熱感度	18
2.4.2	熱感度の実験による検証	22
2.4.3	ターニングセンタの熱感度に基づく熱変位抑制	24
2.5	結言	26
<b>第 3 章</b>	<b>深層学習によるターニングセンタの熱変位推定</b>	<b>29</b>

3.1	緒言	29
3.2	CNN による工作機械の熱変位推定	30
3.3	熱変位データの収集	34
3.3.1	熱変位データを収集したターニングセンタ	35
3.3.2	温度センサと変位センサの取り付け方法	36
3.3.3	熱変位データの測定条件	37
(1)	Test 1: クーラント加熱による切削熱の模擬条件	38
(2)	Test 2: 主軸運転条件	41
(3)	Test 3: 軸稼働条件	42
(4)	Test 4: 環境温度変化条件	43
3.4	ケーススタディ: ターニングセンタの熱変位推定モデルの学習	46
3.4.1	温度と主軸-タレット間相対変位の測定	46
3.4.2	学習した熱変位推定モデルの推定精度の検証	47
3.4.3	他の方式の熱変位推定モデルの推定精度との比較	48
3.5	結言	50
<b>第 4 章</b>	<b>深層学習による熱変位推定モデルの信頼性評価</b>	<b>53</b>
4.1	緒言	53
4.2	Bayesian dropout による熱変位推定モデルの信頼性の評価	54
4.3	ケーススタディ: ターニングセンタの熱変位推定分布の評価と補正量の修正	57
4.3.1	深層学習ネットワークによる熱変位の推定と Bayesian dropout による信頼性の評価	57
4.3.2	温度センサの故障をシミュレーションした信号を用いた場合の信頼性の評価	61
(1)	故障をシミュレーションした温度センサの信号	61
(2)	故障シミュレーション信号による熱変位推定分布の変動	64
4.3.3	熱変位推定分布に基づく熱変位補正量の修正	65
4.4	加工試験による熱変位補正機能の検証	68
4.5	結言	71
<b>第 5 章</b>	<b>深層学習による熱変位推定におけるセンサ故障に対するロバスト性向上</b>	<b>73</b>
5.1	緒言	73
5.2	深層学習による熱変位推定と温度センサ故障を考慮した学習	74

---

5.3 ケーススタディ：温度センサの故障を想定した学習による熱変位推定モデル の学習 . . . . .	76
5.3.1 センサ故障を考慮しない深層学習ネットワークによる予測 . . . . .	76
5.3.2 提案法を用いない場合にセンサ故障が予測に及ぼす影響の例 . . . . .	77
5.3.3 センサ故障を考慮した学習と熱変位推定モデルによる予測 . . . . .	79
5.3.4 センサ故障を考慮した学習の効果 . . . . .	82
5.4 結言 . . . . .	84
<b>第 6 章 結論</b>	<b>87</b>
6.1 まとめ . . . . .	87
6.2 今後の研究 . . . . .	91
<b>謝辞</b>	<b>92</b>
<b>参考文献</b>	<b>95</b>
<b>公表論文</b>	<b>101</b>

# 目次

1.1	G7 and BRICS working-age population trends and projections* <sup>1</sup> . . . . .	2
1.2	Thermal Effects Diagram [Bry90] . . . . .	4
2.1	Calculation of thermal sensitivity by FEM software . . . . .	14
2.2	An example of thermal sensitivity for simple model . . . . .	18
2.3	Machine structure of the turning center for thermal sensitivity analysis .	19
2.4	Calculated thermal sensitivity of the turning center (the influence of thermal change on mechanical structure on the displacement in X-direction of spindle to turret) . . . . .	20
2.5	Measured thermal displacement in X-direction under the change in ambient temperature . . . . .	22
2.6	Comparison of temperature between back and top part of bed . . . . .	23
2.7	Attached fan and cover . . . . .	24
2.8	Comparison of thermal displacement between condition with fan, cover and without fan, cover . . . . .	25
2.9	Temperature of back and top part of bed with fan and cover . . . . .	26
3.1	Conceptual diagram of the CNN used . . . . .	30
3.2	Structure of CNN and flow chart of model learning . . . . .	33
3.3	Machine structure of the turning center considered in this thesis . . . . .	35
3.4	Five displacement sensors to measure X, Y, Z displacements and orientations of spindle relative to turret . . . . .	37
3.5	Schematic diagram of coolant heating system . . . . .	39
3.6	Set amount of coolant temperature rise for heavy cutting . . . . .	39
3.7	Thermal displacement and temperatures data for coolant heating condition (Heavy) . . . . .	40

---

3.8	Thermal displacement and temperatures data for coolant heating condition (Light) . . . . .	41
3.9	Thermal displacement and temperatures data for spindle running condition . . . . .	42
3.10	Thermal displacement and temperatures data for axes moving condition	43
3.11	Movable temperature variable booth and air conditioner . . . . .	44
3.12	Set amount of ambient temperature . . . . .	45
3.13	Thermal displacement and temperatures data for ambient temperature change condition . . . . .	45
3.14	Temperature measurement results of 6 machines (CH1–CH10: temperature sensors) . . . . .	46
3.15	X-axis thermal displacement measurement results of 6 machines . . . . .	47
3.16	Predicted thermal displacement in X-axis direction with training data (four plots are from four different machines) . . . . .	48
3.17	Predicted thermal displacement in X-axis direction with evaluation data(two plots are from two different machines) . . . . .	49
3.18	Prediction result comparison between CNN and ridge regression . . . . .	50
3.19	Prediction error comparison between CNN and ridge regression . . . . .	51
4.1	Schematic diagram of dropout . . . . .	55
4.2	Structure of CNN and flow chart of model learning . . . . .	60
4.3	Prediction results of displacement in the X-direction (Test 4: the environmental temperature was changed by 8 °C from 0 hr to 9 hr. Test 2: the spindle rotated in 4,000 min <sup>-1</sup> from 0 hr to 8 hr) . . . . .	61
4.4	Simulated signals under sensor failure . . . . .	63
4.5	Predicted and measured displacement profiles under simulated sensor failures with the 2σ profile simulated by the Bayesian dropout. Sensors failures, Modes 1 to 4 in Table 4.2, occur at 10 hr. . . . .	64
4.6	Structure of CNN to modify the compensation commands to reduce the influence of sensor failure . . . . .	67

---

4.7	Predicted and measured displacement profiles under simulated sensor failures with the modification of the compensation commands to reduce the influence of sensor failure. Sensors failures, Modes 1 to 4 in Table 4.2, occur at 10 hr. . . . .	68
4.8	Machined workpiece and machine axes direction on a turning center . . .	69
4.9	Measured errors in the diameter of the machined workpiece with and without thermal displacement control system on a turning center . . . .	70
5.1	Structure of CNN and flow chart of model learning with simulated sensor signal profiles under sensor faults . . . . .	75
5.2	Measured and predicted spindle displacement profiles in X-direction . . .	77
5.3	Original and simulated faulty signal of a temperature sensor . . . . .	78
5.4	Measured and predicted spindle displacement profiles in X-direction . . .	79
5.5	Simulated signals under sensor failure . . . . .	80
5.6	Measured and predicted thermal displacement profiles in X-direction by the model learned with simulated sensor failure signals . . . . .	81
5.7	Contribution of temperature sensor to the error of thermal displacement prediction . . . . .	82
5.8	Predicted thermal displacement profiles when one to five temperature sensors are failed in Mode 1 (Table 4.2) . . . . .	83

# 表目次

2.1	Analysis conditions of turning center . . . . .	21
3.1	Machine specifications of the turning center considered in this thesis . .	36
3.2	Experimental thermal test conditions . . . . .	37
4.1	Number of measurement data for each condition . . . . .	58
4.2	Simulated sensor failure modes . . . . .	62
5.1	The maximum difference in measured and predicted thermal displacement profiles when one to five temperature sensors are failed . . . . .	84



# 使用記号一覧

記号	意味	単位	ページ番号
$z_l$	$l$ 層の 2 値ベクトル	—	56
$z_{l,j}$	$l$ 層の $j$ 番目の 2 値変数	—	56
$M_l$	$l$ 層の重み行列	—	56
$p_l$	$l$ 層のノードを切断する確率	—	55
$m_l$	$l$ 層のバイアスベクトル	—	55
$W_l$	$l$ 層のパラメータ行列	—	55
$K_l$	$l$ 層のパラメータ数	—	55
$T_0$	熱膨張の基準温度	K	16
$T$	温度	K	16
$N_S$	温度センサの数	—	30, 74
$c_q$	$q$ 番目の温度センサの寄与	—	82
$\hat{x}$	温度センサの故障を想定した入力データ	K	74
$q$	温度センサの番号	—	82
$N_L$	温度データのデータ長	—	30
$H$	温度変化-荷重変換行列	N/K	13
$p_r$	温度変化による荷重	N	13
$\mathbf{p}_r$	温度変化による荷重ベクトル	N	13
$\Delta T$	温度変化ベクトル	K	13
$W_{\text{tool}}$	工具熱感度行列	m/K	17
$\mathbf{u}_{\text{tool}}$	工具変位ベクトル	m	16
$k$	剛性	m/N	13
$K$	剛性行列	m/N	13

記号	意味	単位	ページ番号
$N_{\text{fail}}$	故障を想定する温度センサの数	—	74
$\lambda$	材料の線膨張係数	—	16
$X_i$	四面体要素の節点 X 座標	m	14
$Y_i$	四面体要素の節点 Y 座標	m	14
$Z_i$	四面体要素の節点 Z 座標	m	14
$\bar{y}$	深層学習ネットワークからの出力推定値	m	56
$\hat{y}$	深層学習ネットワークからの出力データ	m	31, 55, 56
$\sigma^2$	深層学習ネットワークからの出力分散値	m <sup>2</sup>	57
$\omega$	深層学習ネットワークの学習済みパラメータ	—	56
$y$	深層学習ネットワークの教師データ	m	31, 76
$J$	深層学習ネットワークの推論実行回数	—	57
$L$	深層学習ネットワークの層数	—	55
$l$	深層学習ネットワークの層番号	—	55
$x$	深層学習ネットワークへの入力データ	K	30, 55, 74
$G$	剪断弾性係数	N/m <sup>2</sup>	15
$B$	剪断弾性係数行列	N/m <sup>2</sup>	15
$E$	弾性係数	N/m <sup>2</sup>	15
$e_0$	基準二乗平均平方根推定誤差	m	82
$e_q$	故障信号を入力した場合の二乗平均平方根推定誤差	m	82
$W$	熱感度行列	m/K	13, 16
$N$	バッチサイズ	—	32, 74
$u$	変位	m	13
$N_D$	変位センサの数	—	31
$\mathbf{u}$	変位ベクトル	m	13
$\nu$	ポアソン比	—	15
$\hat{Y}$	ミニバッチでの深層学習ネットワークからの出力データ	m	32
$Y$	ミニバッチでの深層学習ネットワークの教師データ	m	32, 56
$X$	ミニバッチでの深層学習ネットワークへの入力データ	K	32, 56
$N_{\text{FEM}}$	有限要素モデルの自由度	—	13, 16
$W_{\text{rel}}$	加工対象物と工具の相対変位に対する熱感度	m/K	17

記号	意味	単位	ページ番号
$\mathbf{u}_{\text{rel}}$	加工対象物と工具の相対変位ベクトル	m	17
$\mathbf{u}_{\text{part}}$	加工対象物と工具の変位ベクトル	m	17
$\mathbf{W}_{\text{part}}$	加工対象物と工具の熱感度行列	m/K	17
$\mathbf{W}_{\text{work}}$	加工対象物熱感度行列	m/K	17
$\mathbf{u}_{\text{work}}$	加工対象物変位ベクトル	m	16



# 第 1 章

## 序論

高齢化などによる生産年齢人口の減少により，先進国の製造業において省人化や自動化の需要が高まっている．工作機械による生産活動で省人化や自動化を達成するには，熟練工の知識や経験に基づいた加工条件の調整などを行わなくても，長い期間にわたって加工精度を維持することが重要である．工作機械の機械構造には，機械周辺の温度変化や機械要素からの発熱によって温度変化が起こる．機械構造の熱変形は加工精度の劣化として現れ，安定的な生産活動を阻害する代表的な要素として対策が求められている．

### 1.1 背景

先進国では，生産年齢人口<sup>\*1</sup>が減少することが予測されている．図 1.1 に，主要先進国である G7（フランス，アメリカ，イギリス，ドイツ，日本，イタリア，カナダ）と開発途上国である BRICS（ブラジル，ロシア，インド，中国，南アフリカ）の人口推移および推計を示す．濃い青色の線が G7 の生産年齢人口，濃いオレンジ色の線が BRICS の生産年齢人口，薄い青色の線が G7 の総人口，薄いオレンジ色の線が BRICS の総人口を示す．G7 では，1950 年から 2010 年代に至るまで生産年齢人口は増加の傾向であったが，2020 年ごろを境に減少に転じていることがわかる．一方総人口は 1950 年から 2030 年頃にかけて増加し，その後も維持もしくは微増の推計である．このことから，各産業の生産規模は変わらないにもかかわらず，生産に従事する人材が不足することが予想できる．これに対応するためには製造業における生産性を向上させる必要がある．この状況は将来開発途上国においても発生すると予測できる．BRICS では 2030 年頃を境に生産年齢人口が減少する推計となっ

---

\*1 15 歳以上 65 歳未満；日本における定義

\*2 文献 [DES19] より著者作成

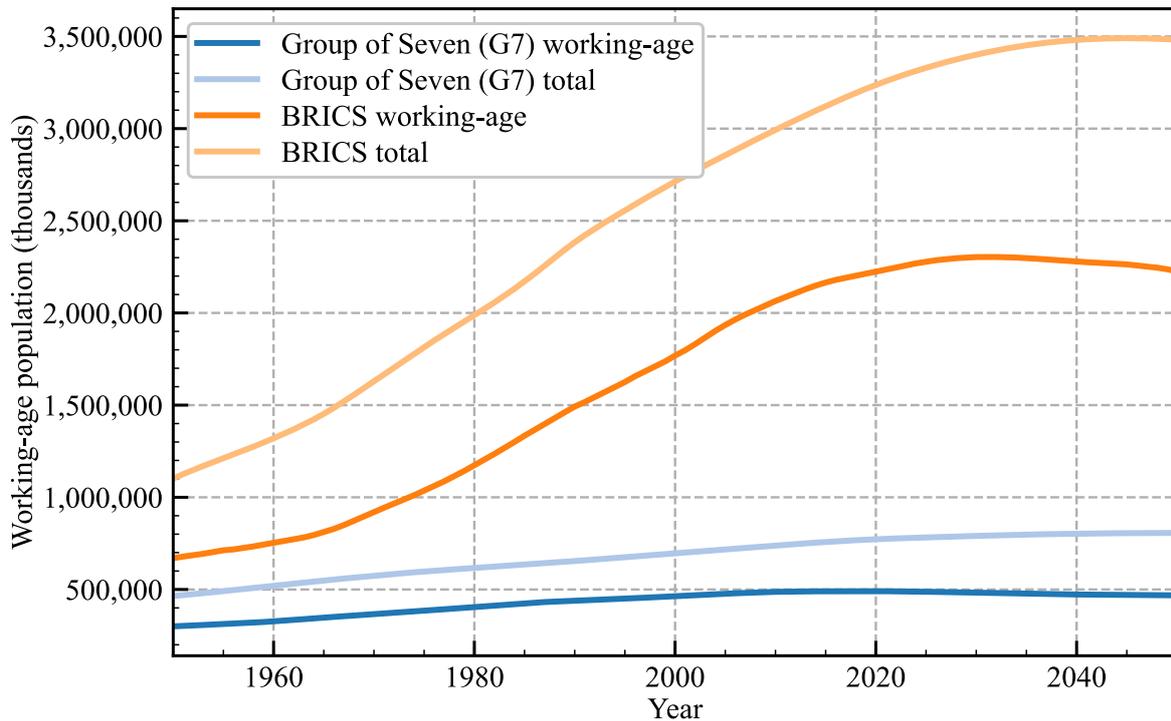


図 1.1: G7 and BRICS working-age population trends and projections\*<sup>2</sup>

ており、先進国と同様に生産性を上げる必要がある。

製造業では、生産に従事する人材が不足した状態でも生産量を維持するために、自動化・省人化の需要が高まっている。コンピュータ数値制御（computerized numerical control, CNC）工作機械は、NC プログラムに基づいてコンピュータによって加工対象物と工具の相対運動を数値制御することで、自動的に加工を実施して完成品を得ることができる。工作機械の CNC 化によって均一な品質の製品を大量に生産できるようになり、生産性は大きく向上した。しかし、たとえ同じものを大量に加工する場合でも、加工対象物の形状精度は常に同じとは限らない。時間の経過とともに、工作機械の精度は変わっていき、したがって、加工対象物の形状精度も変わっていくのが一般的である。その原因は、工作機械の部品の摩耗・案内部などの摺動状態の変化・設置されている地盤の変化など、比較的ゆっくりとした経時変化要因も存在する。しかし最も一般的なのは、熱の影響によって、工作機械の加工対象物-工具の位置・姿勢関係に変化が生じる、熱変位である。本論文では、熱的な要因により生じる、工作機械の加工対象物と工具の相対変位の変化を、「熱変位」と呼称する。一般に、工作機械が設置される工場は、正確に温度制御された環境であることはまれである。昼と夜、あるいは季節によって、かなり温度が変化する環境のなかで、安定した精度で加工す

るために、例えば加工条件などを「職人的」経験に基づいて調整することは決して珍しくない。しかし、生産年齢人口の減少とともに、工場に「職人」を確保することは徐々に難しくなり、工作機械はそのような調整を必要とせず、常に均一の精度で加工を行えることが要求されるようになるだろう。さらに、工作機械に投入する素材の搬送や完成品の搬送、計測など、自動化されていない生産工程が多く存在する。生産に従事する人材が不足した状態で生産性を高めるには、素材を用意すれば均一な品質の完成品が自動的に安定して生産できる状態にする必要がある。素材や完成品の運搬が自動化されても、品質不良の懸念があっては無人運転が実現できない。そこで、人手が介在しなくても均一な品質の維持できる、熱変位の小さい工作機械が求められている。

## 1.2 先行研究

### 1.2.1 工作機械に関係する熱源と熱変位

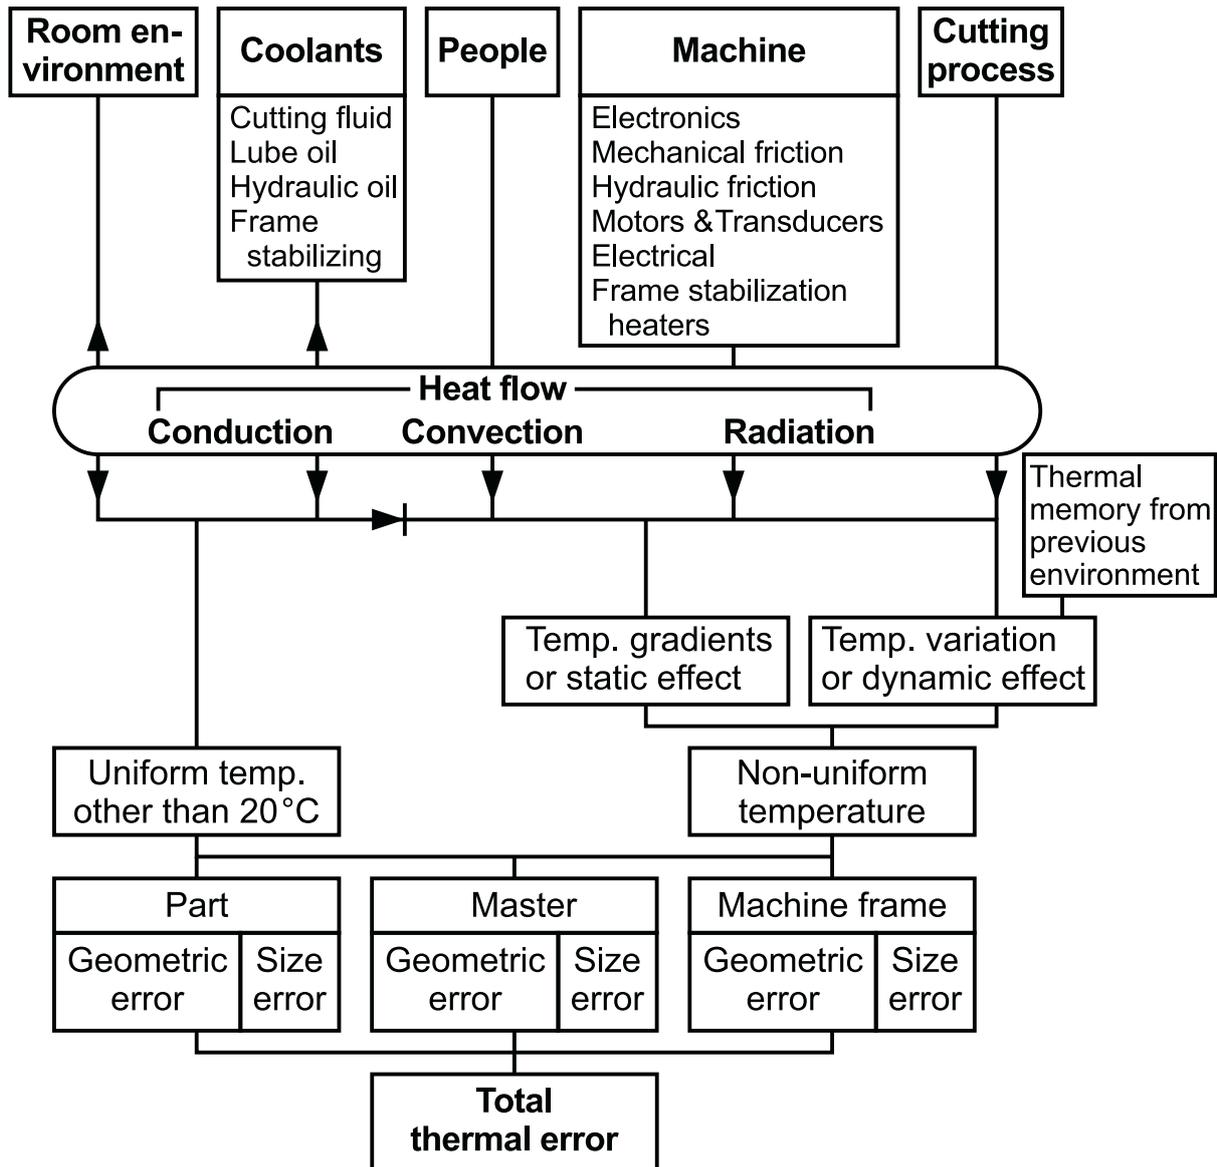
工作機械の熱変形が、工作機械による加工誤差の大きな要因となることが多いことは、工作機械のメーカ・ユーザ共によく理解している。そのため、その影響を低減するための取り組みは、長年にわたって研究され、その成果は市販の工作機械に搭載されたものも少なくない。工作機械の熱変形を低減するための機械設計や、機械構造の冷却方法、熱変形や熱変位を予測するためのモデル化、様々な補正方法は、文献 [Bry90, WMB+95, MJU+12] などでレビューされている。文献 [Bry90] では、図 1.2 に示すように工作機械に関係する熱源と熱現象をまとめている。温度変化の要因となる熱源としては、

- 加工プロセスからの発熱
- 機械からの発熱
- 温度制御機器による冷却や加熱の影響
- 周辺環境の温度変化による影響
- オペレータなどの人体による影響
- 温度履歴による影響

を挙げている。これらの熱源は、機械外部からの熱源と、機械内部からの熱源に大きく分類することができる [WMB+95]。熱源からは、

- 熱伝導
- 熱伝達

## Thermal effects diagram



☒ 1.2: Thermal Effects Diagram [Bry90]

- 輻射

の3つの形態による伝熱によって、最終的に、

- 機械構造
- 加工対象物
- ゲージなどの加工マスタ

の3つの要素の温度変化の要因になる。温度変化は、機械構造全体で均一であれば単純な膨張・収縮による寸法の変化に、不均一であれば直角度・真直度・平面度・角度偏差などを変化させる変形として現れる。工作機械の熱変位は、機械構造・加工対象物・加工マスタの3つの要素の寸法変化や変形の複合的な作用によって加工対象物の精度劣化として現れる。

本研究では、工作機械の熱変位として、機械構造の温度変化による機械構造の寸法変化と変形について扱う。

### 1.2.2 工作機械の熱源が熱変位に及ぼす影響を実際に低減する方法に関する先行研究

1.2.1 項の図 1.2 に示した工作機械に関係する熱源は、機械外部からのものと機械内部からのものに大きく分類できる。

工作機械外部からの熱源については、機械周辺の温度変化が工作機械へ与える影響を調査した例 [Mor97] などからもわかるように、熱変位へ与える影響が無視できない。機械周辺の温度管理を実施して熱変形を最小化することが根本的対策といえるが、工場環境では容易でないことが多い。そのため、機械構造の温度変化が加工対象物-工具間の相対変位に及ぼす影響を小さくできるよう、熱変形が最小化されるように機械構造を最適設計した例 [MMF<sup>+</sup>09]、断熱材により機械周辺の温度変化の影響を小さくすることを試みた例 [Kod05]、CFRP などの熱膨張の小さな材料で機械構造や機械要素を製作した例 [Kat18, Kat20] などが提案されている。

工作機械内部からの熱源については、クーラントが熱変位へ与える影響を体系化した例 [HBBM<sup>+</sup>17, MGM<sup>+</sup>14]、工作機械構造を循環する液体類が熱変位へ与える影響を調査した例 [Oku73] などが報告されている。工作機械内部からの熱源に対しては、機械の各部から発生する熱による機械構造の温度変化が最小限となるよう対策を実施する必要がある。具体的には、主軸やサーボモータなどの主要な熱源に対して冷却や温度制御を実施したり、クーラントの温度制御を実施したりすることで加工対象物や加工室内の温度を安定化させる設計

とすることが多い。冷却に関する提案としては、マシニングセンタの主軸と構造体について冷却の効果をモデル化し体系的にまとめた例 [Chi89]、機械構造を  $\text{CO}_2$  によって冷却した例 [PBW+16] などがある。また、機械内部からの熱源に対する対策として、機械の暖機運転を実施することは、製造現場において工作機械の熱変位が加工加工対象物へ与える影響を低減する方法として広く実施されている。暖機運転により加工を開始するまでの過渡的な熱変形を早期に安定させる方法を提案した例 [Sad75] などが提案されている。

### 1.2.3 工作機械の熱変位の推定と補正による抑制に関する先行研究

熱変位は、加工対象物と工具刃先 (tool center point, TCP) の相対位置の変化として起こる。加工対象物に対する工具刃先の相対変位を直接測定できれば熱変位による影響を打ち消すように指令位置を制御することは容易であるが、稼働中の工作機械の TCP 位置を高精度に測定することは困難なことが多い。そこで、1.2.2 項で述べたような実際に熱変位を低減するための手法とは別に、発生した熱変位を推定しそれらを打ち消すように CNC 装置による指令位置を制御することにより加工対象物の精度劣化を抑制する手法が、これまでに非常に多く研究され、市販機に搭載されたものも多い。

過去の研究を大きく分類すると、まず、機械の熱変形を予測するための入力情報は、機械の運転条件に基づくもの [Yab05]、CNC 内部情報に基づくもの [Sya03]、温度センサを利用するもの [Tak76, Mor88, MS98, Mor92, Mor95, Sas17, MBRHB18] に大きく分類することができる。次に、熱変形を予測するためのモデル化手法は、静的な多項式 [Ido16]、1 次遅れなどの動的な伝達関数 [Ima03]、ニューラルネットワークによる手法 [Mor92, Mor95]、有限要素法 (FEM) に基づく手法 [Sas17, Sas12, Sas13, Iwa13]、などに分類できる。予測した熱変位量は、CNC 装置で補正量として制御されることが多いが、機械構造に取り付けたアクチュエータを制御して変形量や姿勢を補正する例も提案されている。例えば、マシニングセンタのコラムに取り付けた熱アクチュエータでコラム姿勢を制御した例 [Mit95, Kod89]、流体軸受主軸の熱変位を刃物台に取り付けた圧電素子で補正した例 [Mor88] などが挙げられる。さらに、工作機械の熱変位は使用条件などの影響で変化し、熱変位量の推定が難しくなることがあるので、適応制御による自己学習で運転中に熱変位推定の精度を改善する提案 [MBRHB18, ZLBM20, ZBMW21] などもされている。

## 1.3 工作機械の熱変位補正に関する課題と本研究の提案

1.2.3 項でレビューしたとおり，工作機械の構造温度を測定し，それが熱変位へ及ぼす影響を推測し，補正を行う研究は数多く報告されている．そのような熱変位制御において，重要な設計要項は，機械構造のどこに，どの程度の数，温度センサを設置するか，ということである．実用的には，温度センサのコストや，センサが故障した時の損害の低減のために，温度センサの数は必要最低限であることが望ましい．また，温度変化した際に熱変位への影響が大きい部位に取り付けることが望ましい．そのため，多くの研究（例えば [Tat13]）では，温度の測定点の候補をある程度の数選び，その点の温度が熱変位に及ぼす影響を何らかの形で（実験で同定した多項式数理モデルや，FE モデルなど）モデル化して，最適な測定点の組み合わせを選ぶ，というアプローチが採られる．

しかし，温度と熱変位の関係のモデル化による最適化手法では，なぜその位置の温度を測定することが有効なのかを，本質的に理解することが難しいと考えた．そのため，機械構造の温度変化と熱変位の関係を「熱感度」として定義し，機械構造のどの部分が熱変位への影響が大きいかわ視化する手法を提案する（第2章）．

次に，1.2.3 項でレビューしたとおり，工作機械各部の温度から，熱変位を推定するものは，過去の研究で様々なものが提案されている．その中で補正に使われることが多いのは，静的あるいは動的な多項式（伝達関数）を用いるものである．しかし，そのような熱変位推定のためのモデル化手法は，静的・動的，線形・非線形，次数などを対象に合わせて設計者が適切に選択する必要がある．それに対して本研究では，Convolutional neural network (CNN) による深層学習を用いた熱変位推定モデルを提案する（第3章）．深層学習は，画像認識などの分野で顕著な性能が達成されており [KCH<sup>+</sup>07,SKP15,HZRS15]，学習データを用意すればデータに適応するネットワークパラメータが自動的に学習されるため，工作機械メーカーが多数の機種に対して熱変位推定モデルを開発する目的に適していると考えられる．

CNN による熱変位推定モデルを実際の工作機械に搭載して熱変位補正制御を実施する場合，熱変位推定モデルや推定値の信頼性が重要である．信頼性が低い状態で推定が実施されると，加工対象物の精度が低下するばかりでなく急激に大きな補正量が機械に入力され機械破損の原因になることも考えられる．深層学習による熱変位推定の信頼性を評価するために，「Bayesian dropout」[GG16b,GG16a,Gal16] と呼ばれる手法で熱変位推定モデルや推定値の信頼性を推定分布として評価する方法を提案する（第4章）．また，計算した推定分布に基づいて，熱変位推定の信頼性が低下した状態でも，工作機械に与える影響を最小限に抑

えたとえば機械の使用を続けられるよう、熱変位補正量を修正する手法について提案する。1.2.3 項でレビューしたとおり、ニューラルネットワークを用いて、工作機械の熱変位の補正を行った研究は近年いくつか報告されている。しかし、深層学習による熱変位推定モデルや推定値の信頼性の評価法は、本研究の新しい提案である。

熱変位推定モデルや推定値の信頼性を低下させる要因として、センサの故障により生じる入力データの外乱の影響が挙げられる。工作機械は長期間にわたって使用されることも珍しくないため、温度センサの値によって熱変位を推定する場合には、センサの故障を想定しなければならない。そこで、あらかじめ想定できる温度センサの故障形態として、断線と接触不良を挙げ、それらの故障の影響を考慮して深層学習による熱変位推定モデルを学習する手法を提案する（第5章）。これにより、例えば温度センサが故障しても、熱変位補正によって機械が想定外の大きな動きをして、機械自体や、高価な加工対象物を傷つけることを避けることができる。このような熱変位推定モデルの学習法も、本研究の新しい提案である。

## 1.4 本論文の構成

本論文は、以下の構成である。

第1章では、研究背景と目的、過去の研究のレビューと工作機械の熱変位補正に関する課題についてまとめた。

第2章では、熱変位に対する機械構造の温度変化の影響を可視化するために、「熱感度」を定義する。実際のターニングセンタの熱感度を計算したケーススタディについて、また、熱感度の計算結果に基づいてターニングセンタの機械構造にファンとカバーを取り付け、環境温度変化に対する熱変位を抑制した実験結果について述べる。

第3章では、深層学習による工作機械の熱変位推定モデルを提案する。熱変位推定モデルは、画像認識などの分野で顕著な性能を達成しているCNNで構築する。深層学習においては多数のデータを入手することが重要なため、ターニングセンタの熱変位データを複数の機械、複数の条件で収集する方法について述べる。ケーススタディとして、ターニングセンタの環境温度変化による熱変位データを収集し、CNNによる熱変位推定モデルを学習した結果について述べる。

第4章では、深層学習による熱変位推定モデルや推定値の信頼性を、「Bayesian dropout」によって推定分布として計算する手法を提案する。ケーススタディとして、熱変位推定モデルの入力データとして使用される温度センサの断線と接触不良を故障形態として想定した場合に、推定分布がどのように変化したかをまとめる。さらに、計算した推定分布に基づいて、

熱変位推定モデルや推定値の信頼性が低下した状態でも、工作機械に与える影響を最小限に抑え、機械の使用を続けられるよう、熱変位補正量を修正する手法について述べる。

第5章では、深層学習による熱変位推定モデルで入力データとして用いられる、温度センサの断線と接触不良の2つの故障形態について、故障が発生した状態でも熱変位の推定結果に与える影響を最小限に低減する手法を提案する。ケーススタディとして、ターニングセンタの熱変位推定モデルについて、温度センサの断線と接触不良を考慮した状態で深層学習による学習を実施し、熱変位推定モデルのロバスト性を高められることを、市販の工作機械を用いた実験で示す。

第6章では、結論として本研究をまとめ、今後の研究課題について述べる。



## 第 2 章

# 工作機械の構造温度変化が主軸-タレット間の熱変位に及ぼす影響の可視化

### 2.1 緒言

1.2.3 項でレビューしたとおり，工作機械の構造温度を測定し，それが加工対象物-工具間の相対変位へ及ぼす影響を推測し，補正を行う研究は数多く報告されている．また，そのような熱変位補正機能を搭載した市販の工作機械も多い．そのような熱変位制御において，重要な設計要項は，機械構造のどの点の温度を測定するか，ということである．実用的には，温度センサのコストや，センサが故障したときの損害の低減のために，温度センサの数は必要最低限であることが望ましいのはいうまでもない．多くの研究（例えば [Tat13]）では，温度の測定点の候補をある程度の数選び，その点の温度が加工対象物-工具間の相対変位に及ぼす影響を何らかの形でモデル化して，影響が大きい点を選ぶ，というアプローチが取られる．

一方で，経験ある工作機械の設計者であれば，機械の構造のどこがどの程度温度上昇し，機械構造全体がどのように変形するかは，少なくとも定性的には予想できることが多い．1.2 節でレビューしたとおり，機械の熱変形を小さく抑えるための設計手法や機械構造の温度管理手法は数多く報告され，実績をあげている．しかし，工作機械の構造によっては，温度分布の均一化が難しかったり，機械の温度上昇が加工対象物-工具間の相対変位に及ぼす影響を予測するのが難しい場合は少なくない．例えば，図 2.3 に示すターニングセンタは，台形

の断面を持つベッド（スラントベッド）を持ち、また、熱源である主軸のモータはZ軸方向の片側にしかないため、熱変形は機械構造に対して対称にはならず、経験ある設計者であっても予測が難しい。

そこで本研究では、機械構造の各部の温度上昇が、加工対象物-工具間の相対変位にどのような影響を及ぼすかを可視化することができれば、設計者が温度センサの設置位置を選択したり、機械の温度制御の方法を設計したりするのに極めて有効であると考えた。そのために、機械構造上の任意の位置における温度と、加工対象物-工具間の相対変位の関係を「熱感度」と呼び、市販の有限要素法（FEM）シミュレーションソフトを使って、熱感度を計算し、視覚化する方法を提案する。また、実際のターニングセンタを対象に、提案した方法で計算した熱感度をもとに、加工対象物-工具間に変位が生じるメカニズムを考察した。さらに、その考察をもとに、最も効果的な位置に、ファンとカバーを使って機械構造の温度分布を最適化する装置を設置することを目的とした、設計ケーススタディを示す。

## 2.2 熱感度の定義

### 2.2.1 研究目的

熱変位を抑制するための構造を実現したり補正制御によって加工対象物へ与える影響を抑制したりするには、温度変化と熱変位の関係を検討する必要がある。機械構造上のある点に熱を加えたとき、それがどのように機械構造を伝わり、どのように機械構造を変形させ、最終的に加工対象物-工具間の相対変位にどのような影響を及ぼすかは、有限要素法（finite element method, FEM）で計算することができる [Oku72, Yas78, TJM10, TOA+96]。しかし、機械構造上の任意の点の温度が、加工対象物-工具間の相対変位に及ぼす影響を評価するためには、機械構造上のすべての点に対して FEM 計算をせねばならず、計算資源の観点から現実的ではない。そこで、有限要素に分割された機械構造有限要素モデルの、剛性行列と、温度変化と荷重の関係を表す行列を用いて、機械構造上の任意の点の温度変化が、加工対象物-工具間の相対変位に及ぼす影響を評価する方法を提案する。機械構造上の多数の点の温度変化と、加工対象物-工具間の相対変位の関係を表す行列を本研究では「熱感度」と呼ぶ。

## 2.2.2 熱感度の定義

機械構造のある一点に、その点の温度変化による荷重  $p_r \in \mathbb{R}$  によって変位  $u \in \mathbb{R}$  が生じるとき、その関係は

$$ku = p_r \quad (2.1)$$

と記述できる。ここで  $k \in \mathbb{R}$  は構造の剛性である。機械構造全体の自由度が  $N_{\text{FEM}}$  の場合、変位  $\mathbf{u} \in \mathbb{R}^{N_{\text{FEM}}}$  は、式 (2.1) から、

$$\mathbf{K}\mathbf{u} = \mathbf{p}_r \quad (2.2)$$

と記述できる。 $\mathbf{K} \in \mathbb{R}^{N_{\text{FEM}} \times N_{\text{FEM}}}$  は構造の形状と材料から決まる剛性行列である。このとき、温度変化による荷重ベクトル  $\mathbf{p}_r \in \mathbb{R}^{N_{\text{FEM}}}$  と各点における温度変化を表すベクトル  $\Delta\mathbf{T} \in \mathbb{R}^{N_{\text{FEM}}}$  の関係は、温度変化-荷重変換行列  $\mathbf{H} \in \mathbb{R}^{N_{\text{FEM}} \times N_{\text{FEM}}}$  を用いて

$$\mathbf{p}_r = \mathbf{H}\Delta\mathbf{T} \quad (2.3)$$

と記述できるものとする。したがって、構造の温度変化ベクトル  $\Delta\mathbf{T}$  と構造の変位ベクトル  $\mathbf{u}$  の関係は式 (2.3) を式 (2.2) に代入して変形することにより、

$$\mathbf{u} = \mathbf{K}^{-1}\mathbf{H}\Delta\mathbf{T} \quad (2.4)$$

と記述できる。ここで、各点における変位と、温度変化の関係を表す行列  $\mathbf{W} \in \mathbb{R}^{N_{\text{FEM}} \times N_{\text{FEM}}}$  を以下のとおり定義し、本論文ではこれを「熱感度」と呼ぶ。

$$\mathbf{W} = \mathbf{K}^{-1}\mathbf{H} \quad (2.5)$$

したがって、温度変化と変位の関係は、

$$\mathbf{u} = \mathbf{W}\Delta\mathbf{T} \quad (2.6)$$

と記述できる。

## 2.3 有限要素モデルによる熱感度の計算と計算量削減

### 2.3.1 有限要素モデルによる熱感度の計算

熱感度  $\mathbf{W}$  は、式 (2.5) の関係から剛性行列  $\mathbf{K}$  と温度変化-荷重変換行列  $\mathbf{H}$  を用いて計算することができる。そこで、有限要素法を用いて熱感度を計算して、可視化する方法を示す。

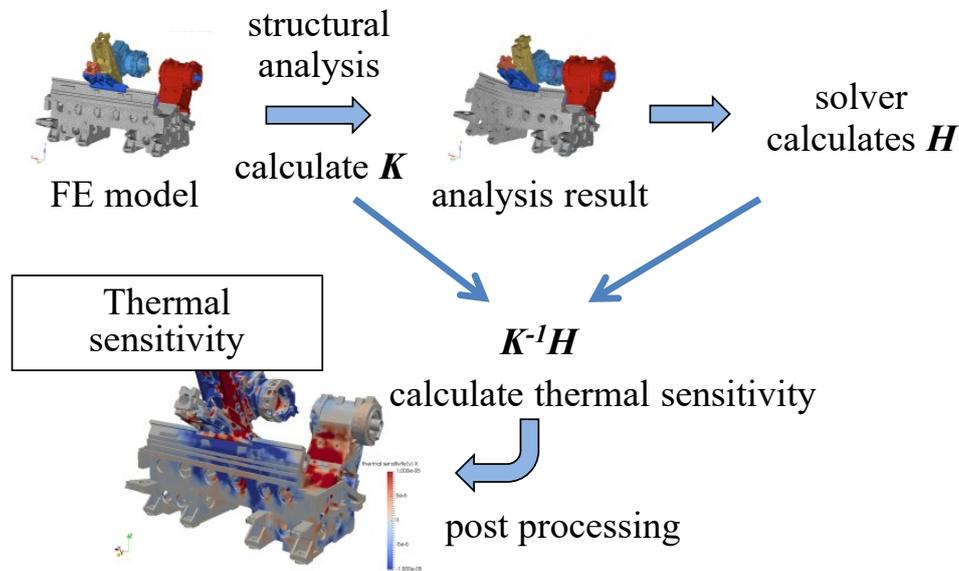


図 2.1: Calculation of thermal sensitivity by FEM software

有限要素法による熱感度計算のアルゴリズムの概要を図 2.1 に示す。熱感度を計算するための機械構造有限要素モデルとして、構造の温度変化を境界条件として設定し変位を求める構造解析の条件設定を使用する。剛性行列  $\mathbf{K}$  は、有限要素法による構造解析の過程で材料、形状、拘束条件などから計算される。温度変化ベクトル  $\Delta\mathbf{T}$  は、構造へ与えた温度条件から決定できる。

市販の有限要素解析ソルバの多くは、有限要素モデルから計算された様々な特性行列を出力する機能を提供している。例えば、市販の有限要素法構造解析ソルバである Simcenter Nastran (Siemens Digital Industries Software) には、計算過程における情報の入出力やユーザが定義した計算を解析計算中に実行することができる Direct Matrix Abstraction Program (DMAP) 機能が提供されている。熱感度の計算に必要なベクトルや行列、内部情報などを出力して利用するために Simcenter Nastran の DMAP 機能を使用した。

剛性行列  $\mathbf{K}$  は、構造解析の過程で計算されるものを DMAP を用いて出力した。温度変化-荷重変換行列  $\mathbf{H}$  は、計算に必要な各種情報を DMAP で出力し、Nastran の温度荷重生成アルゴリズム [Dou70, AA72] を使用して求めた。以下に温度荷重生成アルゴリズムの概要を説明する。温度荷重は有限要素モデルの要素全体について計算する必要があるが、ここでは任意の四面体要素の計算について説明する。

有限要素モデルの四面体要素を構成する節点の座標  $X_i, Y_i, Z_i (i = 1, 2, 3, 4)$  を 要素の座

標系に変換する行列  $\mathbf{H}_{qu} \in \mathbb{R}^{4 \times 4}$  は,

$$\mathbf{H}_{uq} = \begin{bmatrix} 1 & X_1 & Y_1 & Z_1 \\ 1 & X_2 & Y_2 & Z_2 \\ 1 & X_3 & Y_3 & Z_3 \\ 1 & X_4 & Y_4 & Z_4 \end{bmatrix} \quad (2.7)$$

を用いて  $\mathbf{H}_{qu} = \mathbf{H}_{uq}^{-1}$  の関係から求める。

節点における変位をひずみに変換する行列  $\mathbf{C}_i \in \mathbb{R}^{6 \times 3}$  は,  $\mathbf{H}_{qu}$  の  $j$  行  $i$  列の要素を  $H_{ji}$  と書くと,

$$\mathbf{C}_i = \begin{bmatrix} H_{2i} & 0 & 0 \\ 0 & H_{3i} & 0 \\ 0 & 0 & H_{4i} \\ 0 & H_{4i} & H_{3i} \\ H_{3i} & 0 & H_{1i} \\ H_{2i} & H_{1i} & 0 \end{bmatrix} \quad (2.8)$$

と表せる。

材料によって決まる弾性係数  $E \in \mathbb{R}$ , 剪断弾性係数  $G \in \mathbb{R}$  およびポアソン比  $\nu$  を用いて, 行列  $\mathbf{B} \in \mathbb{R}^{6 \times 6}$  を次のように表す。

$$\mathbf{B} = \begin{bmatrix} \frac{E(1-\nu)}{(1+\nu)(1-2\nu)} & \frac{E\nu}{(1+\nu)(1-2\nu)} & \frac{E\nu}{(1+\nu)(1-2\nu)} & 0 & 0 & 0 \\ \frac{E\nu}{(1+\nu)(1-2\nu)} & \frac{E(1-\nu)}{(1+\nu)(1-2\nu)} & \frac{E\nu}{(1+\nu)(1-2\nu)} & 0 & 0 & 0 \\ \frac{E\nu}{(1+\nu)(1-2\nu)} & \frac{E\nu}{(1+\nu)(1-2\nu)} & \frac{E(1-\nu)}{(1+\nu)(1-2\nu)} & 0 & 0 & 0 \\ 0 & 0 & 0 & G & 0 & 0 \\ 0 & 0 & 0 & 0 & G & 0 \\ 0 & 0 & 0 & 0 & 0 & G \end{bmatrix} \quad (2.9)$$

有限要素モデルの四面体要素の温度変化による荷重  $\mathbf{p}_i$  は, 式 (2.8) と式 (2.9) を用いて次のように求めることができる。

$$\mathbf{p}_i = \mathbf{A}_i^\top \mathbf{C}_i^\top \mathbf{B} \boldsymbol{\varepsilon}_t \quad (2.10)$$

ここで,  $\mathbf{A}_i$  は, 有限要素全体の座標系表記の変位  $\mathbf{u}_G$  と, 要素座標系表記の変位  $\mathbf{u}_i$  を以下の関係で記述する要素を持つ変換行列である。

$$\mathbf{u}_i = \mathbf{A}_i \mathbf{u}_G \quad (2.11)$$

また,

$$\boldsymbol{\varepsilon}_t = \begin{bmatrix} \lambda \\ \lambda \\ \lambda \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \Delta \bar{T} \quad (2.12)$$

であり, 四面体要素の節点 1, 2, 3, 4 の, 基準温度  $T_0$  に対する温度変化をそれぞれ  $\Delta T_1, \Delta T_2, \Delta T_3, \Delta T_4$  としたとき,  $\Delta \bar{T} = 1/4(\Delta T_1 + \Delta T_2 + \Delta T_3 + \Delta T_4)$  は基準温度  $T_0$  に対する四面体要素を構成する各節点の平均温度変化量,  $\lambda$  は材料の線膨張係数である.

有限要素モデルを構成するすべての要素について, 式 (2.10) に基づいて節点の温度変化量から温度変化による荷重を計算し, 節点座標系の荷重に割り当てることで有限要素モデル全体の荷重ベクトルを得ることができる. 有限要素モデルから熱感度  $\mathbf{W}$  を求めるには, 剛性行列  $\mathbf{K}$  から逆行列  $\mathbf{K}^{-1}$  を計算し, 式 (2.3) と式 (2.10) の関係から有限要素モデルの全節点の温度-荷重変換係数を求め, 式 (2.5) の温度変化-荷重変換行列  $\mathbf{H}$  を計算する. 式 (2.6) のとおり, 剛性行列の逆行列  $\mathbf{K}^{-1}$  に温度変化-荷重変換行列  $\mathbf{H}$  を右からかけることで熱感度  $\mathbf{W}$  を求めることができる. 求めた値を有限要素モデル上の全ての節点ごとに, 色として表示することで, 熱感度の大きさや位置を可視化することができる.

### 2.3.2 熱感度の計算量削減

熱感度  $\mathbf{W} \in \mathbb{R}^{N_{\text{FEM}} \times N_{\text{FEM}}}$  は, 機械構造全体を表現する有限要素モデルの自由度  $N_{\text{FEM}}$  に応じた大きさの正方行列である. 数万程度の自由度の有限要素モデルの場合, 熱感度  $\mathbf{W}$  の要素数は数億程度になる. しかし, 工作機械の加工精度は加工対象物と刃先の相対変位で決定されるため, 工作機械にとって重要な熱感度は,  $\mathbf{W}$  のうち加工対象物や工具に関する節点の自由度のみである. この特徴を用いて熱感度を求めるための計算量を削減することができる.

式 (2.6) における熱感度  $\mathbf{W}$  のうち, 加工対象物や工具に関する部分は, 変位ベクトル  $\mathbf{u}$  の部分ベクトルである加工対象物変位ベクトル  $\mathbf{u}_{\text{work}} \in \mathbb{R}^3$  および工具変位ベクトル  $\mathbf{u}_{\text{tool}} \in \mathbb{R}^3$  との対応関係から,

$$\begin{bmatrix} \vdots \\ \mathbf{u}_{\text{work}} \\ \vdots \\ \mathbf{u}_{\text{tool}} \\ \vdots \end{bmatrix} = \begin{bmatrix} \vdots \\ \mathbf{W}_{\text{work}} \\ \vdots \\ \mathbf{W}_{\text{tool}} \\ \vdots \end{bmatrix} \begin{bmatrix} \Delta T_1 \\ \vdots \\ \Delta T_i \\ \vdots \\ \Delta T_{N_{\text{FEM}}} \end{bmatrix} \quad (2.13)$$

のように熱感度  $\mathbf{W}$  の一部である加工対象物熱感度行列  $\mathbf{W}_{\text{work}} \in \mathbb{R}^{3 \times N_{\text{FEM}}}$  および工具熱感度行列  $\mathbf{W}_{\text{tool}} \in \mathbb{R}^{3 \times N_{\text{FEM}}}$  のみである。つまり、加工対象物と工具に関する変位成分のみを抜き出して、変位ベクトル  $\mathbf{u}_{\text{part}} \in \mathbb{R}^6$  を以下のように定義すると、

$$\mathbf{u}_{\text{part}} = \begin{bmatrix} \mathbf{u}_{\text{work}} \\ \mathbf{u}_{\text{tool}} \end{bmatrix} \quad (2.14)$$

加工対象物と工具に関する熱感度  $\mathbf{W}_{\text{part}} \in \mathbb{R}^{6 \times N_{\text{FEM}}}$  は、

$$\mathbf{W}_{\text{part}} = \begin{bmatrix} \mathbf{W}_{\text{work}} \\ \mathbf{W}_{\text{tool}} \end{bmatrix} \quad (2.15)$$

となる。式 (2.14) と式 (2.15) から式 (2.6) を再記述すると、

$$\mathbf{u}_{\text{part}} = \mathbf{W}_{\text{part}} \Delta \mathbf{T} \quad (2.16)$$

となる。 $\mathbf{W}_{\text{part}}$  の次元は  $6 \times N_{\text{FEM}}$  であり、全節点についての  $\mathbf{W}$  の次元  $N_{\text{FEM}} \times N_{\text{FEM}}$  と比較して大幅にサイズが小さい。 $\mathbf{W}_{\text{part}}$  を計算するための計算量は、 $\mathbf{W}$  全体を計算することと比較して大幅に削減することができる。ただし、温度変化ベクトル  $\Delta \mathbf{T}$  の自由度を削減することはできない。

ここで、加工対象物と工具の相対変位  $\mathbf{u}_{\text{rel}} \in \mathbb{R}^3$  を以下のように定義する。

$$\mathbf{u}_{\text{rel}} = \mathbf{u}_{\text{tool}} - \mathbf{u}_{\text{work}} = \mathbf{W}_{\text{tool}} \Delta \mathbf{T} - \mathbf{W}_{\text{work}} \Delta \mathbf{T} \quad (2.17)$$

$$= (\mathbf{W}_{\text{tool}} - \mathbf{W}_{\text{work}}) \Delta \mathbf{T} \quad (2.18)$$

$$= \mathbf{W}_{\text{rel}} \Delta \mathbf{T} \quad (2.19)$$

このように相対変位  $\mathbf{u}_{\text{rel}}$  は、熱感度  $\mathbf{W}_{\text{rel}} \in \mathbb{R}^{3 \times N_{\text{FEM}}} = \mathbf{W}_{\text{Tool}} - \mathbf{W}_{\text{Work}}$  から求めることができる。

熱感度からどのようなことがわかるのかを示すために、簡単な構造を使った計算例を示す。図 2.2 に示すような T 字型の部品について、熱感度  $\mathbf{W}_{\text{rel}}$  を計算し、分割された要素ごとに、熱感度を色で示したものが図 2.2 である。部品下部の底面を 6 自由度拘束し、図中に Point O として示した点に対して図中に Point A として示した点の X 軸方向相対変位に対

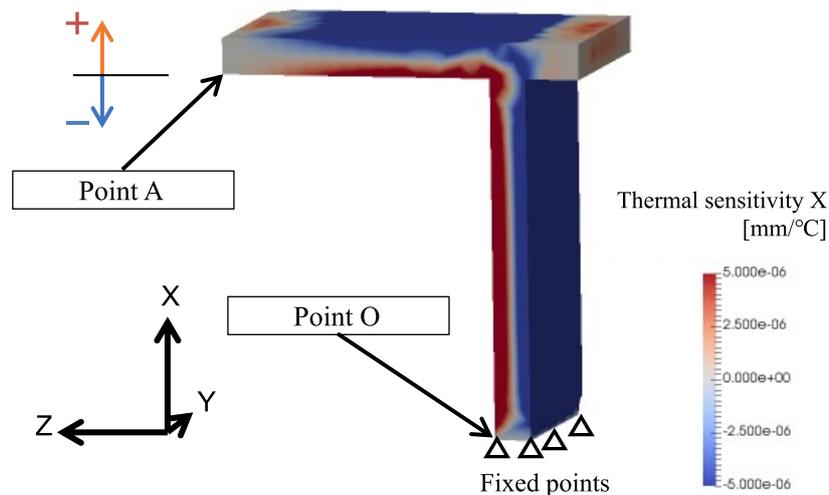


図 2.2: An example of thermal sensitivity for simple model

する熱感度を計算して図示した結果である。図中赤色部分は、その部分の温度上昇によって Point A がプラス方向へ変位することを示し、青色部分は、その部分の温度上昇によってマイナス方向へ変位することを示す。また、色の濃淡が熱感度の絶対値の大きさに対応する。検討したい相対変位に関する熱感度を視覚化することで、変位に対する温度変化の寄与を把握することができる。

## 2.4 ケーススタディ：ターニングセンタの熱感度と熱変位抑制

### 2.4.1 ターニングセンタの熱感度

ターニングセンタの機械構造に対して熱感度を計算し、その結果を可視化することで機械構造の温度変化と熱変位の関係を検討した。

熱感度の計算を実施したターニングセンタの機械構造概要と各部の名称を図 2.3 に示す。左右の図はそれぞれ同じ機械を正面から見た図と背面から見た図である。このターニングセンタのベッドは台形のベッド断面を持つスラント構造であり、ベッド上の機械座標系 Z 軸方向に沿って配置された Z 軸摺動面は、水平面内から手前側に 30° 傾斜している。サドルはこの摺動面上を Z 軸方向に往復運動する。サドル上には三角形の断面を持つ Y 軸ベースが配置されており、この Y 軸ベースが機械座標系の X 軸方向に沿って Z 軸方向と直交して往復運動する。Y 軸ベース上には Y 軸の横送り台が配置されている。この Y 軸は X 軸とは直交していないため、Y 軸の運動は、Y 軸と X 軸の同期制御により、Y 軸横送り台と Y 軸ベー

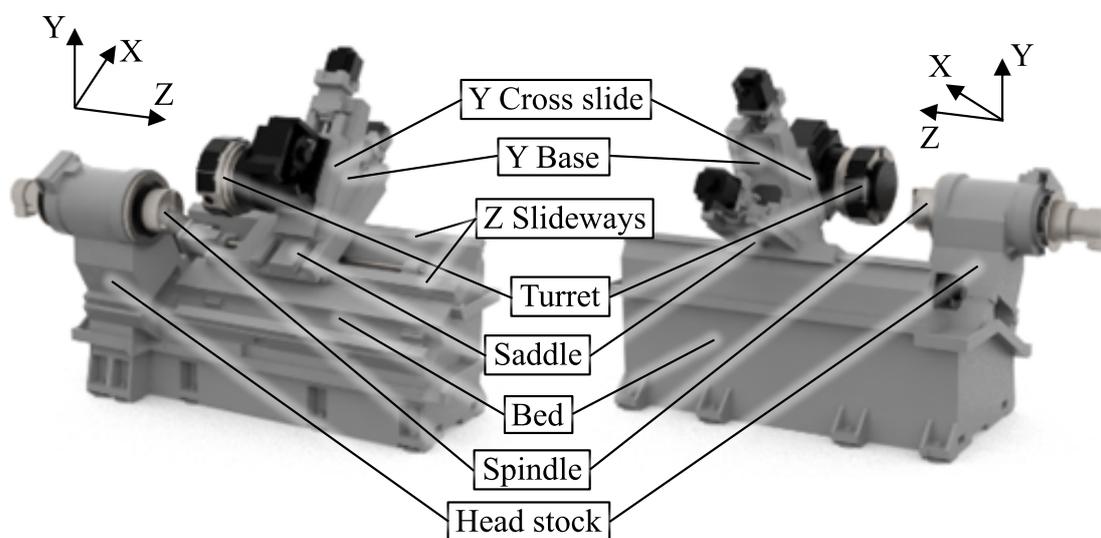
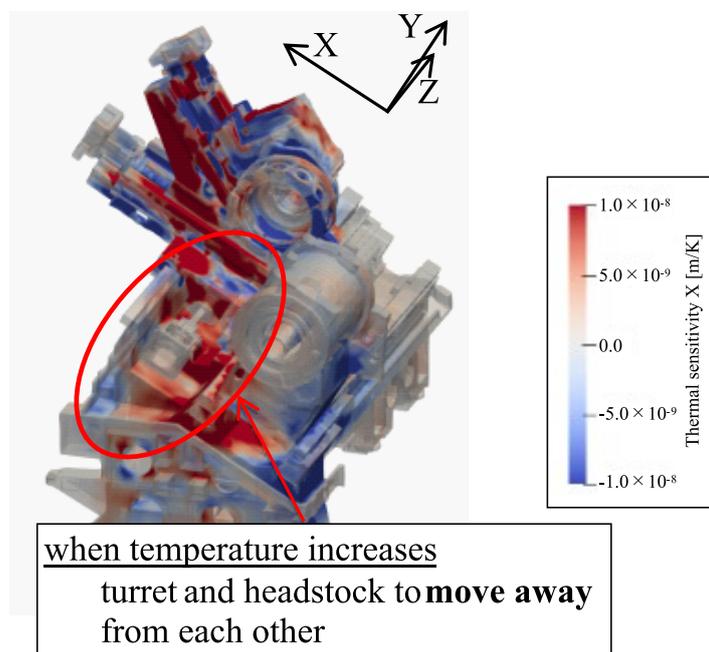


図 2.3: Machine structure of the turning center for thermal sensitivity analysis

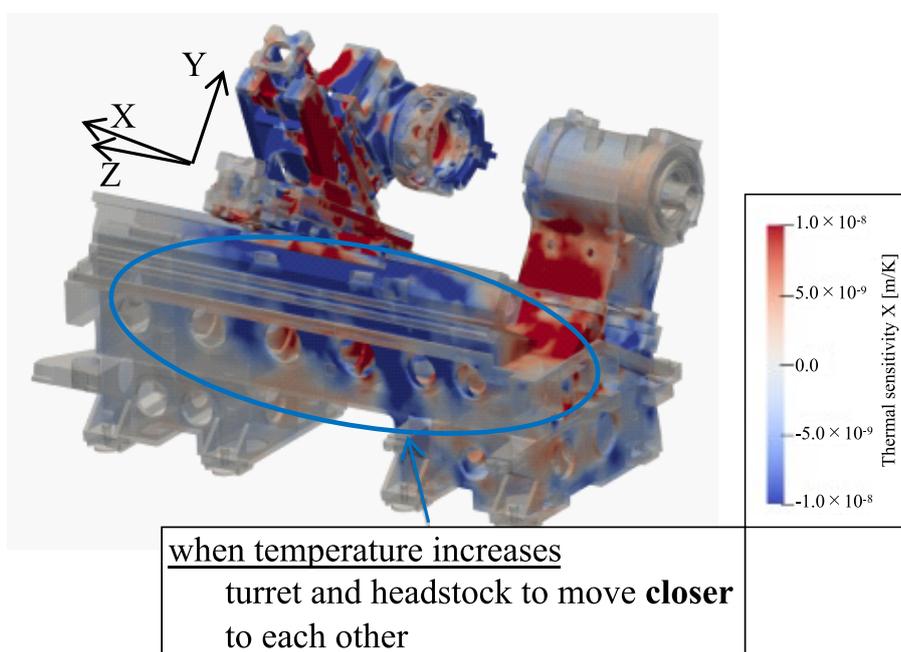
スが同時に運動することで X 軸および Z 軸運動と直交した運動が創成される構成である。Y 軸の横送り台にはタレットが配置されており、タレットに複数の工具を取り付けることで機械の自動運転中に工具交換が可能である。加工対象物は主軸に取り付けられ、主軸によって Z 軸方向を回転軸とした回転運動を与えられる。

有限要素モデルは、CAD ボディとして表現されたターニングセンタの形状から、カバー・配線類・配管類・ボルト類などを取り除き、主要構造を簡略化して作成した。有限要素モデルの設定条件を表 2.1 に示す。表中のカッコ内は Simcenter Nastran の要素種類を示す。体積要素は 1 次四面体要素で有限要素化し、機械構造部品間の接触部分については固着として扱った。軸受やボールねじ、リニアガイドなどの機械要素は線形ばねとして有限要素化した。摺動面は接触、機械構造と地面との接触部分は、ジャッキ部分に地面との間に線形ばねを定義することで有限要素化した。

熱感度計算の結果を図 2.4 に示す。図は、主軸とタレット刃先位置の相対変位に関する機械座標系 X 軸方向の熱感度計算結果である。図中の赤色の部分は、温度上昇によりタレットと主軸台が離れる変形が生じることを示し、青色の部分はタレットと主軸台が近づく変形が生じることを示している。また、色の濃さは、熱感度の絶対値の大きさに対応している。図 2.4 (a) に赤丸で示したベッド上面では、赤色のプラスの熱感度が濃く分布していることがわかる。これは、ベッド上面の温度上昇によって刃先と主軸が離れる変形が発生しやすいことを示している。つまり、ベッド上面が温度上昇によって熱膨張すると、主軸台の取り付



(a) Front side view



(b) Back side view

図 2.4: Calculated thermal sensitivity of the turning center (the influence of thermal change on mechanical structure on the displacement in X-direction of spindle to turret)

表 2.1: Analysis conditions of turning center

Model elements	Description (Simcenter Nastran's element name)
Volume elements	4-node tetra (CTETRA)
Fixing surfaces between parts	surface-to-surface completely gluing (Simcenter Nastran Glue)
Bearings	Designed stiffness valued linear spring (CBUSH) between shaft outer surface and housing inner surface with distributing applied loads rigid connection elements (RBE3)
Linear guides / Ball screws	Designed stiffness valued linear spring (CBUSH) between rail/screw surface and carriage/nut surface with distributing applied loads rigid connection elements (RBE3)
Slide ways	Contacting
Jacks	Connecting to fixed coordinate system with linear spring

け部とサドルが配置されている Z 軸摺動面が離れるために刃先と主軸が離れるということである。図 2.4 (b) に青丸で示したベッド背面では、青色のマイナスの熱感度が濃く分布していることがわかる。これは、ベッド背面の温度上昇によって刃先が主軸へ近づく変形が発生しやすいことを示している。つまり、ベッド背面は温度上昇に伴う熱膨張によってベッド後側の Z 軸摺動面を持ち上げる要素として作用し、これによってサドルが傾斜し刃先を主軸へ近づける要素として作用する。主軸台は、正面と背面で、それぞれ青、赤と逆の符号の熱感度となっている。これは、主軸台の正面もしくは背面が局所的に温度変化した場合には、主軸台が傾く変形をすることにより X 軸方向の熱変位が生じるが、主軸台が均一に温度変化する場合には、主軸台が機械座標系 Y 軸方向（上下方向）へ伸び縮みするため、X 軸方向の変位は少なくなることを示している。

熱変位量は、式 (2.6) の関係から熱感度と温度変化量の積で表すことができる。したがって熱感度の絶対値が大きく、温度変化量が大きい部分に着目することで、機械構造のどの部位の温度変化が熱変位量への寄与が高いかを判断することができる。スラントベッド型の

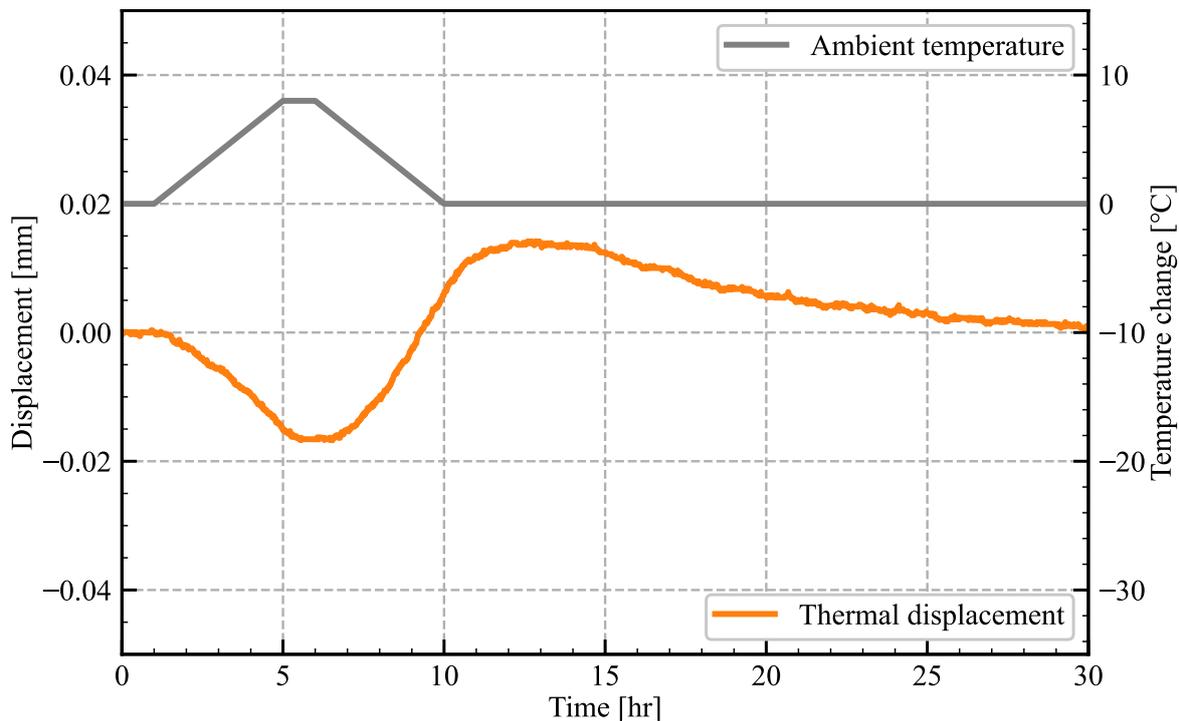


図 2.5: Measured thermal displacement in X-direction under the change in ambient temperature

ターニングセンタは、機械構造が非対称の形状であるため、熱変形の特徴を明らかにすることが困難であったが、熱感度の導入により熱変形のメカニズムを視覚的に理解できるようになった。

## 2.4.2 熱感度の実験による検証

2.4.1 項で示した、図 2.4 の熱感度から観察できる、熱変形によって主軸-タレット間相対変位が生じるメカニズムを実験によって確認することを目的として、ターニングセンタの周辺温度を変化させ、主軸-タレット間の相対変位を熱変位として計測した。対象としたターニングセンタと測定方法については 3.3 節で詳しく説明するのでここでは述べない。熱変位データの測定条件として、3.3 節で説明する環境温度変化条件（表 3.2 の Test 4）で機械周辺の温度を変化させた。図 2.5 に熱変位の測定結果のうち、機械座標系 X 軸方向の相対変位をオレンジ色の線で示す。変位のプラス方向は主軸とタレット間が離れる方向を示し、マイナス方向は近づく方向を示す。また、機械周辺の温度変化量として設定した値を灰色の線

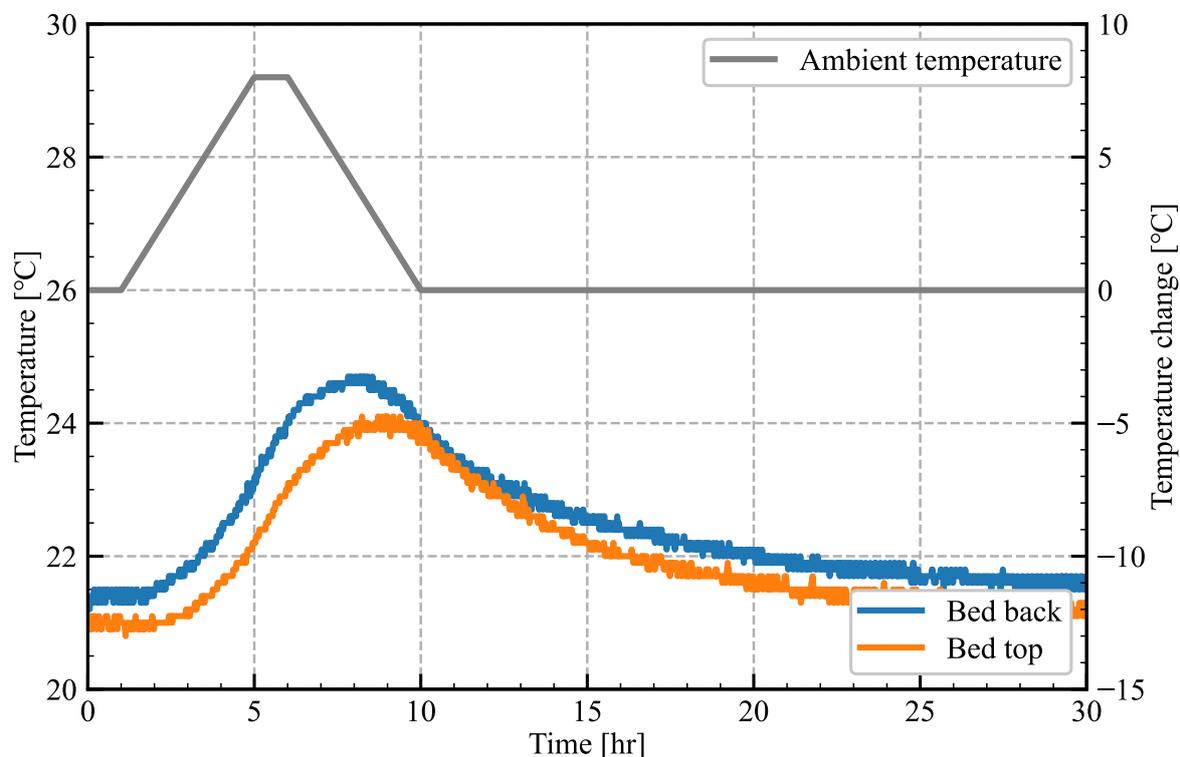


図 2.6: Comparison of temperature between back and top part of bed

で示す。機械周辺の温度は、測定開始から1時間初期温度を維持した後、4時間かけて8°C上昇させ、1時間維持した後4時間かけて8°C下降する変化を与えた。その際のベッド背面と上面の温度を図 2.6 に示す。ベッド背面の温度が青色の線、ベッド上面の温度がオレンジ色の線である。ベッド背面の温度変化は、ベッド上面と比較して温度上昇の際も、下降の際も早いことがわかる。

環境温度変化に対するターニングセンタの熱変形メカニズムは、熱感度計算結果から以下のように説明できる。

図 2.4 において、ベッド背面はマイナスの熱感度（青色）が優位である。つまり、温度上昇によってタレットと主軸台が近づく方向へ変形すると考えられる。一方、ベッド上面はプラスの熱感度（赤色）が優位である。つまり、温度上昇によってタレットと主軸台が互いに遠ざかる方向へ変形すると考えられる。先に述べたように、図 2.6 からわかるベッド背面と上面の温度変化の関係は、ベッド背面の温度変化が早い。機械周辺の環境温度が上昇すると、まずマイナスの熱感度を持つベッド背面の温度が上昇することで主軸とタレットが近づく方向の変形が生じ、遅れてプラスの熱感度を持つベッド上面の温度が上昇することで変形

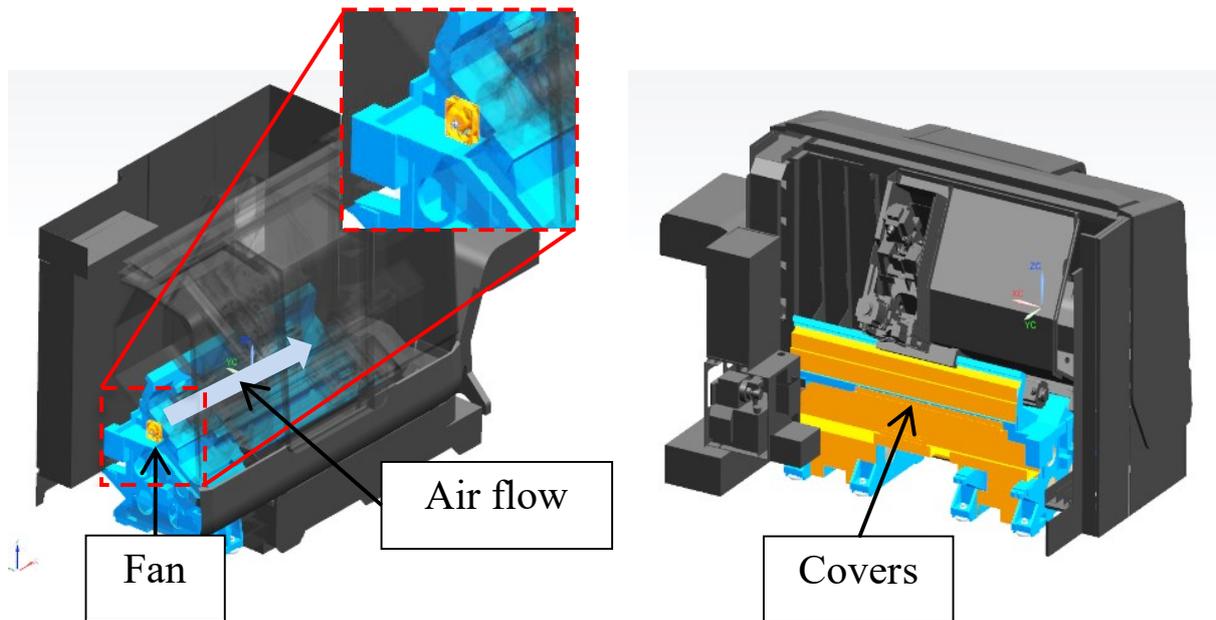


図 2.7: Attached fan and cover

量が緩和していく。周辺温度の下降が始まると上昇の場合と同様に、まずマイナスの熱感度を持つベッド背面の温度が下降し、主軸とタレットが離れる方向の変形が生じる。遅れてプラスの熱感度を持つベッド上面の温度が下降すると変形量の緩和が始まり、最終的に変形量が少なくなっていく。図 2.5 を見ると、主軸とタレットが近づく方向であるマイナス方向の変位が生じた後に、変位の向きが反転し主軸とタレットが離れる方向であるプラス方向の変位へ移行している。熱感度による変形メカニズムの解釈と温度変化、変位の関係は一致している。

### 2.4.3 ターニングセンタの熱感度に基づく熱変位抑制

環境温度変化に対するターニングセンタの熱変位を抑制するために、機械構造に熱対策を施し効果を確認した。構造の温度上昇とともにタレットと主軸台が近づく熱変形を低減するために、図 2.7 に示すようにベッドの上面付近にファンを取り付け、ベッドの背面にカバーを取り付け、取り付け前後の熱変位を比較した。

ベッド背面は、温度変化が早いためカバーを取り付けることで周辺の空気との熱交換を阻害し、温度変化を遅くすることをねらった。ベッド上面は、温度変化が遅いためファンを取り付けることで周辺の空気との熱交換を促し、温度変化を早くすることをねらった。

図 2.8 にファンとカバーの取り付け前後でのターニングセンタの熱変位のうち、機械座標

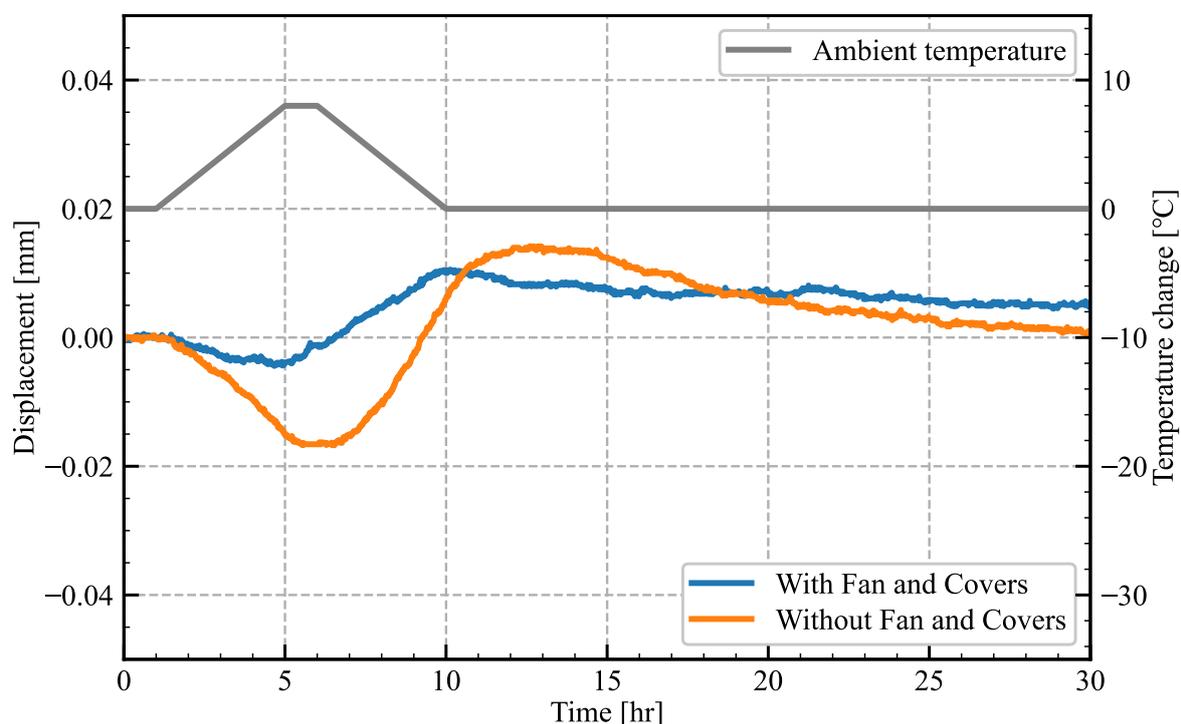


図 2.8: Comparison of thermal displacement between condition with fan, cover and without fan, cover

系 X 軸方向の主軸-タレット間の相対変位を示す。オレンジ色の線がファンとカバーの取り付け前、青色の線がファンとカバーを取り付けた後の機械座標系 X 軸方向の主軸とタレットの相対変位である。ファンとカバーを取り付ける前は、温度変化開始から 6 時間程度にかけて機械座標系 X 軸マイナス方向の変位、つまり主軸とタレットが近づく方向の変位が 0.017 mm 程度と顕著であったが、ファンとカバーを取り付けることにより 0.004 mm 程度まで抑制されている。また、プラス方向の変位も抑制されている。図 2.9 に、ファンとカバーを取り付けた後のベッド背面および上面の温度変化を示す。青色の線がベッド背面の温度変化、オレンジ色の線がベッド上面の温度変化を示す。図 2.6 と比較して、ベッド背面と上面の温度変化の速度差が小さくなっていることがわかる。

主軸-タレット間の機械座標系 X 軸方向の熱変位は、ファンとカバーの取り付けによってベッド背面と上面の温度変化の速度差が少なくなったことで抑制されたと考えられる。熱感度の計算結果と熱変位の計測結果に基づいて、熱変位へ影響を与える機械構造の部位を特定し、対策を施すことで熱変位が抑制できる結果を得た。

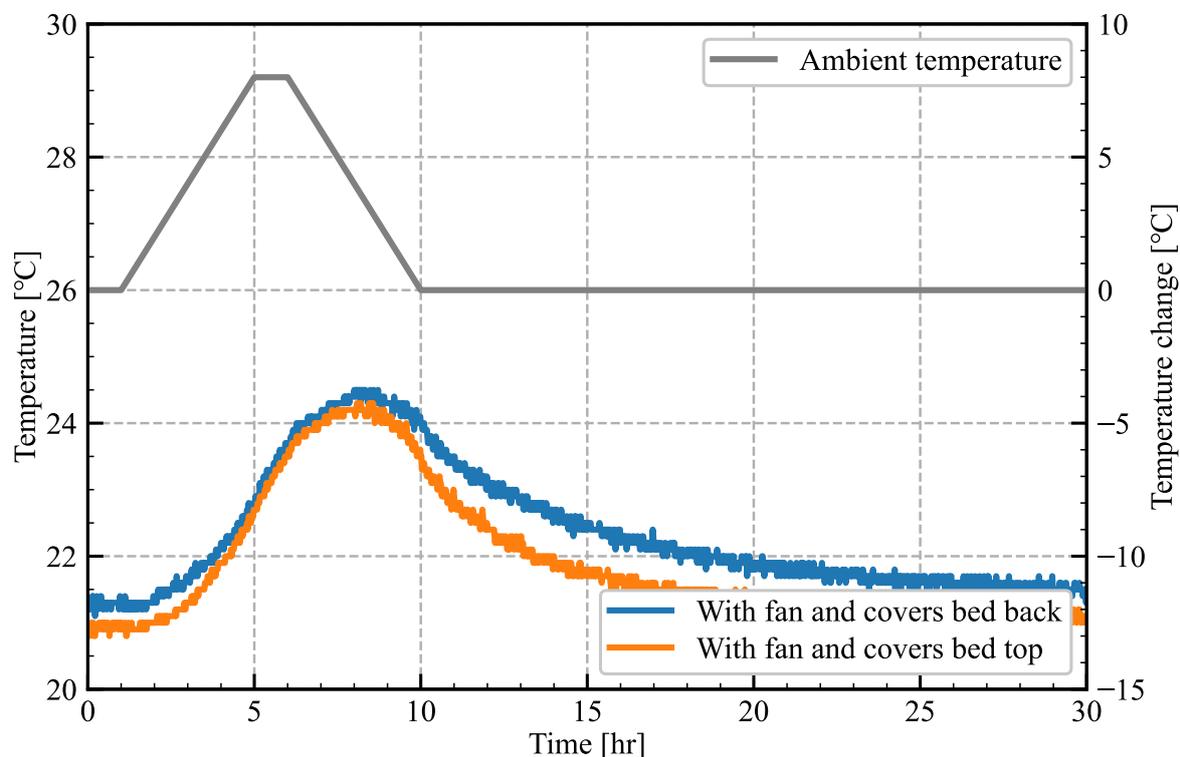


図 2.9: Temperature of back and top part of bed with fan and cover

## 2.5 結言

本章では、工作機械構造の温度変化と熱変位を検討するために熱感度を計算し、ターニングセンタの熱感度を可視化した。また、熱感度計算結果に基づいて機械構造の熱変形による熱変位に対して温度変化の影響が大きい部分について熱対策を施し、環境温度変化に対する熱変位を抑制する結果を得た。

本章で得られた主な結論は以下のとおりである。

1. 工作機械構造の温度変化が、加工対象物-工具間の相対変位に及ぼす影響を評価する方法として、「熱感度」を提案した。
2. 実際の工作機械構造の熱感度を計算する方法として、有限要素法（FEM）によって、有限要素モデルの熱感度を計算する方法を示した。熱感度は、加工対象物-工具間などの特定の相対変位について検討すれば十分なので、必要な自由度だけを抽出して計算量を削減する方法を示した。

3. ケーススタディとして、ターニングセンタの熱感度を計算した。ターニングセンタの熱感度は、ベッド上面の温度上昇で主軸とタレットが離れる方向の変位が生じ、ベッド背面の温度上昇で主軸とタレットが近づく方向の変位が生じることを示す結果であった。
4. 熱感度から観察できる主軸-タレット間相対変位の発生メカニズムを確認するために、実験を実施した。ターニングセンタの周辺温度を変化させた際の機械構造の温度と主軸-タレット間変位を計測した。機械座標系 X 軸方向の熱変位は、機械の周辺温度の上昇に伴って主軸とタレットが近づく方向へ生じ、その後主軸とタレットが離れる方向へ変化した。この変位は、主軸とタレットが近づく方向に作用するプラスの熱感度を持つベッド背面の温度上昇により、まず主軸とタレットが近づく変位が生じ、遅れてマイナスの熱感度を持つベッド上面の温度上昇により変位の緩和と変位方向の反転が発生するメカニズムである。温度変化、変位の関係と熱感度から、ターニングセンタの環境温度変化に対する変形メカニズムを説明した。
5. 熱変位を抑制する目的で、温度変化の早いベッド背面に空気との熱交換を阻害するカバーを取り付け、温度変化の遅いベッド上面に空気との熱交換を促進するファンを取り付けた。カバーとファンの取り付けによって機械座標系 X 軸方向の熱変位を抑制することができた。
6. 熱感度の計算結果と熱変位の計測結果に基づいて、熱変位へ影響を与える機械構造の部位を特定し、対策を施すことで熱変位が抑制できる結果を得た。



## 第3章

# 深層学習によるターニングセンタの熱変位推定

### 3.1 緒言

近年、深層学習に代表される人工知能技術分野において、計算機能力の向上により多層のニューラルネットワークでの学習を実現する技術が発展し、画像認識などの分野で人間の認識能力を超える顕著な性能が達成されている [KCH<sup>+</sup>07, SKP15, HZRS15]. 第1章でレビューしたように、工作機械の熱変形による熱変位を補正する方法に関する研究は、機械構造の温度や、運転条件などと、加工対象物-工具間の相対変位の関係を、何らかの数式を用いて予測するものが大半であった. そのような熱変位推定のためのモデル化手法は、静的・動的、線形・非線形、次数などを対象に合わせて設計者が適切に選択する必要がある. 一方深層学習では、学習データとして与えたデータに適応するネットワークパラメータが自動的に学習されるため、工作機械メーカーが多数の機種に対して熱変位推定モデルを開発する目的により適していると考えられる. このような観点から、工作機械の熱変位推定にニューラルネットワークを用いる研究がいくつか報告されている [Mor92, Mor95, BHW04].

本章では、ターニングセンタに取り付けた温度センサの値と熱変位の関係を、Convolutional neural network (CNN) を用いた深層学習により学習し、温度から熱変位を推定する熱変位推定モデルを提案する. また、提案した深層学習による熱変位推定モデルを学習するために、多数のターニングセンタの熱変位データを収集する方法について述べる. ケーススタディとして、収集した熱変位データを用いて熱変位推定モデルを学習した結果について述べる.

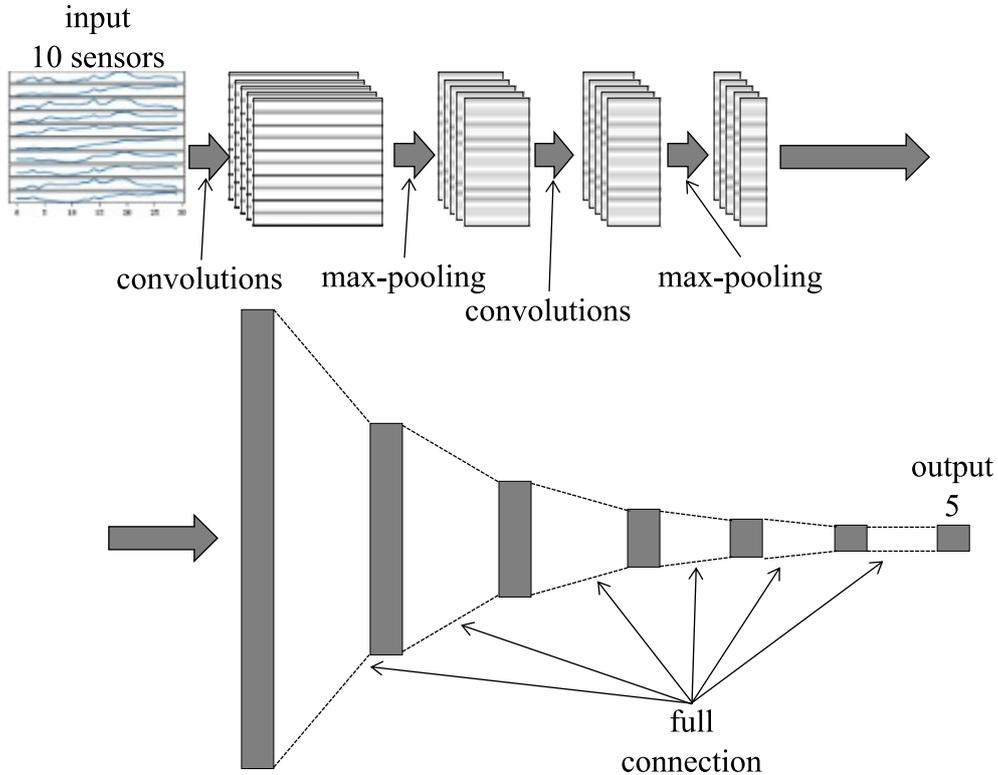


図 3.1: Conceptual diagram of the CNN used

## 3.2 CNN による工作機械の熱変位推定

深層学習による画像認識のタスクでは、Convolutional neural network (CNN) が広く用いられている。CNN は、畳み込み処理とプーリング処理によって情報を圧縮することによって画像の認識と抽象化を行う [Aso13]。この概念を温度データに対して適用すると、温度変動の認識や温度変化情報の特徴抽出ができると考えた。深層学習による工作機械の熱変位推定に用いた CNN 構造の概念図を図 3.1 に示す。

入力データ  $\mathbf{x} \in \mathbb{R}^{N_L \times N_S}$  は機械構造の各部の温度であり、

$$\mathbf{x} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1N_S} \\ x_{21} & x_{22} & \cdots & x_{2N_S} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N_L1} & x_{N_L2} & \cdots & x_{N_LN_S} \end{bmatrix} \quad (3.1)$$

の形式である。ここで  $N_S$  は温度センサの数、 $N_L$  は温度データのデータ長である。温度

データは、 $N_L \times N_S$  の形状の行列であり、 $j = 1, \dots, N_S$  番目の温度センサの、任意の時刻の測定値を  $x_{N_L j}$  として、固定長の時間だけ過去にさかのぼった測定値を  $x_{1j}$  とする。例えば、さかのぼる期間が 30 分間、サンプリングレートが 1 分、温度センサ数が 10 であれば、入力データの形状は  $30 \times 10$  となる。

教師データ  $\mathbf{y} \in \mathbb{R}^{N_D}$  は、機械構造の各部の変位であり、

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{N_D} \end{bmatrix} \quad (3.2)$$

の形式である。ここで  $N_D$  は変位センサの数であり、 $y_j$  は、任意の時刻における  $j = 1, \dots, N_D$  番目の変位センサの変位量である。温度データの最終時刻と、変位センサの値の時刻は一致するものとする。また、以降では、温度データ  $\mathbf{x}$  と変位データ  $\mathbf{y}$  の組み合わせを「熱変位データ」と呼ぶ。

入力された温度信号は CNN による深層学習ネットワークを構成する複数の畳み込み層およびプーリング層を介し、出力信号の数を調整するための 1 層以上の全結合層を通過した後に出される。出力データ  $\hat{\mathbf{y}} \in \mathbb{R}^{N_D}$  は、教師データである変位データ  $\mathbf{y}$  の数と一致しており、

$$\hat{\mathbf{y}} = \begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_{N_D} \end{bmatrix} \quad (3.3)$$

の形式である。深層学習ネットワークの学習は、任意の損失関数を介して  $\mathbf{y}$  と  $\hat{\mathbf{y}}$  の差を最小化する問題として扱うことができる。

深層学習により、熱変位推定モデルを同定するアルゴリズムの概要を以下の「熱変位推定モデルの学習フロー」に示す。図 3.2 は、これをフローチャートで説明したものである。

## 熱変位推定モデルの学習フロー

1. 熱変位データ（学習データ）群から温度データ（入力データ  $\mathbf{x}$ ）と変位データ（教師データ  $\mathbf{y}$ ）の組み合わせを  $N$  個選択して取り出す。
2. 選択したデータを結合し、入力データ  $\mathbf{X}$  と教師データ  $\mathbf{Y}$  とする。
3. 熱変位推定モデルに入力データ  $\mathbf{X}$  を入力し出力  $\hat{\mathbf{Y}}$  を計算する。
4. 出力  $\hat{\mathbf{Y}}$  と教師データ  $\mathbf{Y}$  を損失関数によって比較し誤差を計算する。
5. 計算した誤差に対する各ネットワークパラメータの偏微分値を計算する。
6. 計算した偏微分値に基づいて、各パラメータの更新量を調節しパラメータを更新する。
7. 以上の手順を繰り返し実施し、各ネットワークパラメータを学習データに適應させる。

教師データ  $\mathbf{y} \in \mathbb{R}^{N_D}$  は、式 (3.2) で述べた任意の時刻の変位量の値であり、サイズは変位センサの数  $N_D$  である。入力データは、式 (3.1) で述べた任意の時刻から一定時間さかのぼった期間の温度データであり、 $N_L \times N_S$  の形状の 2 次元データである。

熱変位推定モデルの学習は、ミニバッチ法 [Aso15, IS15] を用いて行った。ミニバッチ法では、熱変位データ（学習データ）から、温度データ（入力データ）と変位データ（教師データ）の組み合わせを  $N$  個抽出して、入力データ  $\mathbf{X} \in \mathbb{R}^{N \times N_L \times N_S} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  として一度に熱変位推定モデルに入力する。入力データは図 3.2 の「A. input」部に入力され、「B. output」部まで順に進み、最後に「loss function」部に到達する。「loss function」部には入力データの時刻に対応する教師データ  $\mathbf{Y} \in \mathbb{R}^{N \times N_D} = \{\mathbf{y}_1, \dots, \mathbf{y}_N\}$  が与えられ、出力  $\hat{\mathbf{Y}} \in \mathbb{R}^{N \times N_D} = \{\hat{\mathbf{y}}_1, \dots, \hat{\mathbf{y}}_N\}$  と教師データ  $\mathbf{Y}$  の誤差が計算される。計算された誤差は誤差逆伝播法（バックプロパゲーション）によって Prediction model 部を「B. output」部から「A. input」部に向かって逆に伝達され、その際「Prediction model」部の内部パラメータが更新される。これらの動作を繰り返し実施して内部パラメータの更新を行うことで、「B. output」部から出力される信号は、入力された温度データに対応する教師データ（変位データ）に近づいていく。

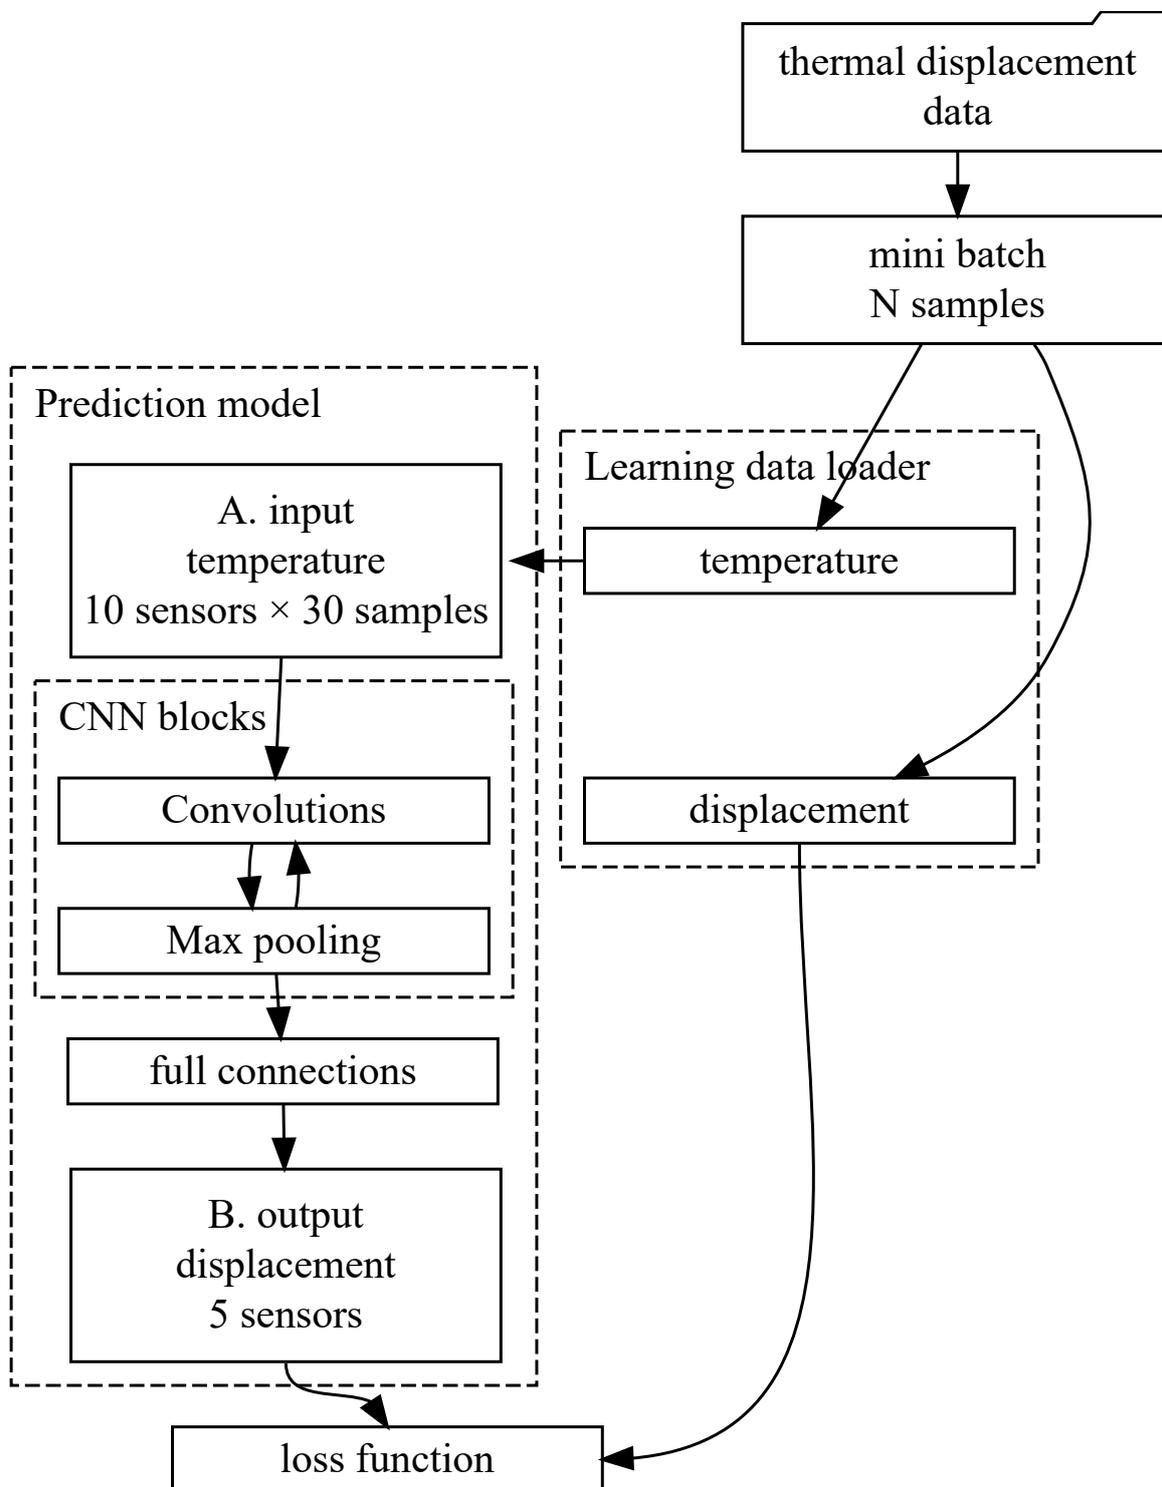


図 3.2: Structure of CNN and flow chart of model learning

### 3.3 熱変位データの収集

工作機械の熱変位特性を検討したり、熱変位データに基づいた熱変位推定モデルを構築したりするには多くの熱変位データが必要である。工作機械には、鋳物部品などの製作誤差、軸受などの組込予圧の差、各種ユニットの組立誤差などが存在するため、少なからず個体差がある。そのため、単一の機械に対して様々な条件で運転した場合だけでなく、複数の機械に対して運転を実施した場合の熱変位データを取得することが望ましい。その一方で、工作機械メーカーが製造するすべての機械について、個別に熱変位推定モデル学習のための実験を行うことは、製造効率の観点から現実的ではない。そのため、製造上の個体差をあらかじめ見込み、同一機種複数の機械を用いて熱変位推定モデルの学習を行うことで、同じ機種であれば、その後製造されるすべての機械に同じ熱変位補正システムを適用する、というのが現実的であると考えた。

そこで、同一機種複数のターニングセンタについて、機械構造各部の温度と主軸-刃先間相対変位のデータを熱変位データとして収集する方法について述べる。温度は、機械構造に取り付けた温度センサによって計測した。温度センサの取り付け位置は、第2章で述べた熱感度をもとに、主軸-刃先間相対変位への影響が大きいと考えられる箇所を選択して決定した。変位は、タレットに取り付けた非接触変位センサで、主軸に取り付けたテストバーを計測することにより計測した。

第1章でレビューしたように、工作機械構造の温度変化の原因になる熱源としては、機械内部によるものと、機械周辺の環境によるものに分類することができる [WMB+95]。機械周辺の環境によるものは、周辺温度の変化が代表的なものであるため、機械周辺の温度を変化させた条件で熱変位データを収集した。機械内部によるものは、加工プロセスからの発熱、機械的摩擦による発熱、モータやアクチュエータからの発熱、クーラントの温度変化、潤滑油や冷却油の温度変化など様々なものが挙げられる。しかし、いずれも加工や機械の稼働によるものであるため、クーラントの温度変化、主軸運転による主軸の発熱、移動軸の稼働によるモータやボールねじ、摺動面の発熱を考慮して熱変位データを収集した。本節では、対象とした工作機械（ターニングセンタ）、熱変位データを収集するためのセンサの配置などの実験のセットアップ、熱変位データを収集する測定条件、などについて述べる。これらのセットアップや測定条件で収集された熱変位データは、第3章～第5章で共通して用いられる。

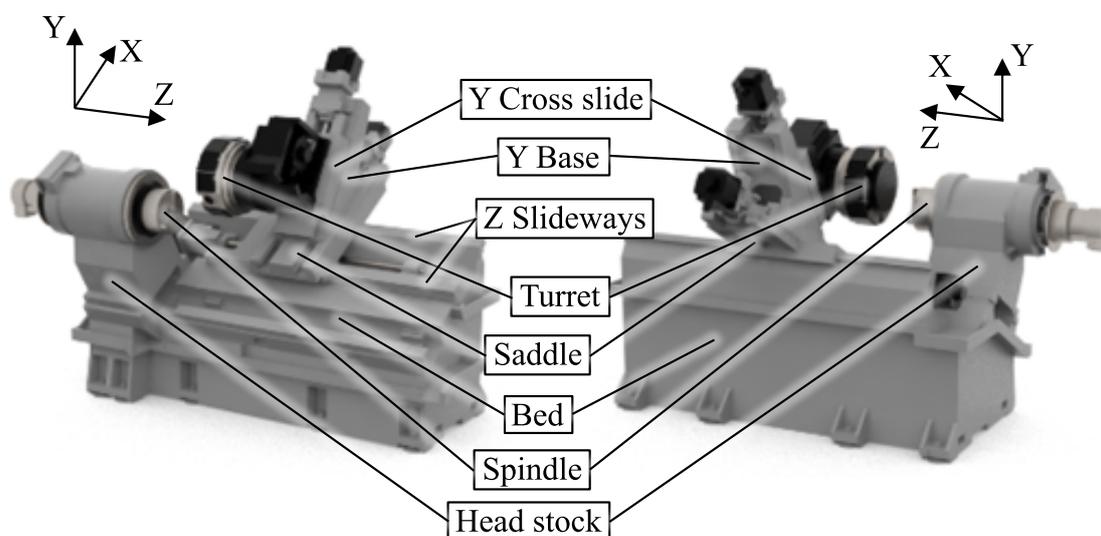


図 3.3: Machine structure of the turning center considered in this thesis

### 3.3.1 熱変位データを収集したターニングセンタ

熱変位データの収集対象としたターニングセンタの機械構造概要と各部の名称，機械座標系の向きを図 3.3 に示す．なお，「ターニングセンタ」とは一般に，加工対象物を把持して回転させる割り出し可能な主軸と，工具を回転させる回転工具主軸（タレットに内蔵されたものも多い）を持ち，工具の自動交換機能を持つ旋盤形の機械構造の CNC 工作機械を指す．

左右の図はそれぞれ同じ機械を正面から見た図と背面から見た図である．このターニングセンタのベッドは台形のベッド断面を持つスラント構造であり，ベッド上の機械座標系 Z 軸方向に沿って配置された Z 軸摺動面は，水平面内から手前側に  $30^\circ$  傾斜している．サドルはこの摺動面上を Z 軸方向に往復運動する．サドル上には三角形の断面を持つ Y 軸ベースが配置されており，この Y 軸ベースが機械座標系の X 軸方向に沿って Z 軸方向と直交して往復運動する．Y 軸ベース上には Y 軸の横送り台が配置されている．この Y 軸は X 軸とは直交していないため，Y 軸の運動は，Y 軸と X 軸の同期制御により，Y 軸横送り台と Y 軸ベースが同時に運動することで X 軸および Z 軸運動と直交した運動が創成される構成である．Y 軸の横送り台にはタレットが配置されており，タレットに複数の工具を取り付けることで機械の自動運転中に工具交換が可能である．加工対象物は主軸に取り付けられ，主軸によって Z 軸方向を回転軸とした回転運動を与えられる．表 3.1 には，対象としたターニングセンタの主要緒元を示す．

表 3.1: Machine specifications of the turning center considered in this thesis

Name	Unit	Specification
Swing over bed	mm	920
Max. turning length	mm	705
Travel	mm	X: 260, Y: $\pm 50$ , Z: 795
Max. spindle speed	$\text{min}^{-1}$	4,000
Rapid traverse rate	mm/min	X, Z: 30,000, Y: 10,000
Mass of machine	kg	6,140

### 3.3.2 温度センサと変位センサの取り付け方法

温度データは、図 3.3 のターニングセンタの機械構造に取り付けた温度センサによって測定した。温度センサの取付位置は、測定条件などによって適宜変更したが、基本的に 2.4.1 項で述べた熱感度の計算結果に基づいて、熱変位に対する影響が大きいと考えられる部位を選択した。熱感度は、熱変位に対する機械構造の任意の点の温度変化の寄与を示すので、熱感度の絶対値の大きい部分の温度変化は熱変位に与える影響が大きい。温度センサを熱感度の絶対値が大きい箇所に取り付けることで、熱変位に対する影響の大きい構造温度変化をとらえることができ、熱変形メカニズムの理解や熱変位推定モデルを構築する際の性能が向上することが期待できる。なお、本節では、機械構造温度 6 点、主軸温度 1 点、送り系温度 1 点、環境温度 2 点、切削油などの流体温度 2 点の合計 12 点の温度センサの測定例について、3.3.3 項で述べている。

変位データは、主軸-タレット間の相対変位を計測した。なお、「タレット」とは、複数の切削工具を放射状に取り付けることができる刃物台のことである（図 3.3, 図 3.4 参照）。本来、ターニングセンタで加工される加工対象物の形状精度は、主軸に取り付けた加工対象物と、タレットに取り付けた工具の先端（切削点）との、相対変位が決定する。そのため、以下のようなセットアップで、主軸-タレット間の相対変位を測定することとした。主軸-タレット間変位は、図 3.4 に示すように、主軸に取り付けたテストバー（図 3.4 内で「Measurement workpiece」と書かれた、測定対象の丸棒）に対し、タレットに非接触変位センサを取り付けることで計測した。変位センサは、主軸軸線（機械座標系 Z 軸方向）に沿って機械座標系 X 軸方向と Y 軸方向に 2 か所ずつ、Z 軸方向に 1 か所の計 5 か所に取り付け、テストバー

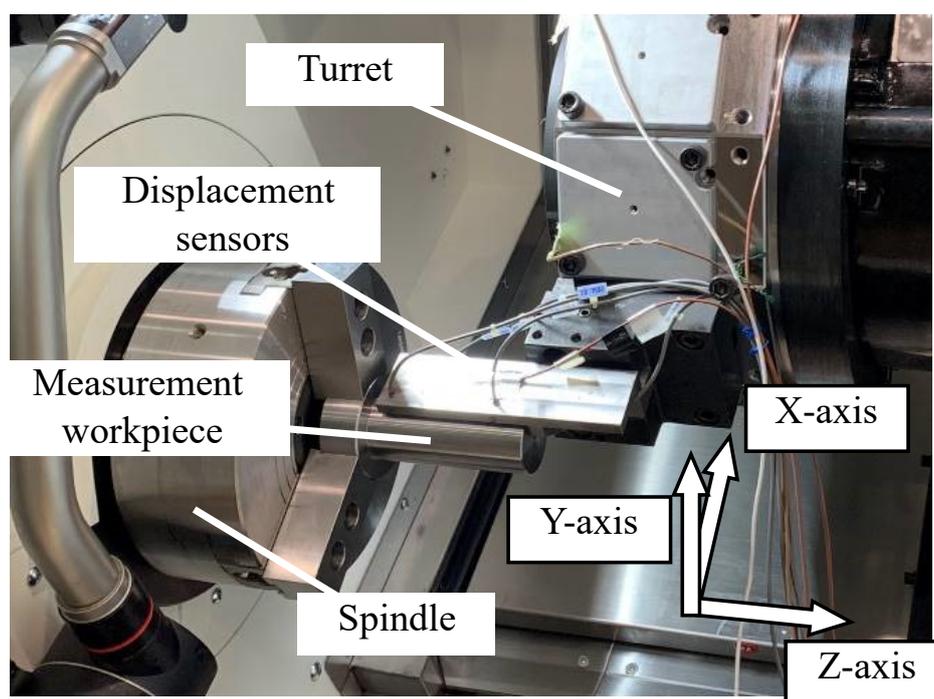


図 3.4: Five displacement sensors to measure X, Y, Z displacements and orientations of spindle relative to turret

表 3.2: Experimental thermal test conditions

Operating condition	Description
Test 1: Coolant	Coolant heated heavy or light (simulating the influence of cutting heat)
Test 2: Spindle	Spindle running for 8 hr at $2,000 \text{ min}^{-1}$ and $4,000 \text{ min}^{-1}$
Test 3: Moving axes	X and Z axes moving at $15,000 \text{ mm/min}$ and $30,000 \text{ mm/min}$ for 8 hr
Test 4: Ambient	Ambient temperature increasing and decreasing by 8 K in 9 hr

のタレットに対する位置・姿勢の変化を測定できるようにした。

### 3.3.3 熱変位データの測定条件

表 3.2 には、熱変位推定モデルの学習のために用いる、熱変位測定時の試験条件を示す。試験条件は、実際のターニングセンタの使用の際に、温度変化を生じやすい運転条件を模し

て、以下の4条件とした。(1) 加工熱による影響をクーラント加熱により模擬した条件およびクーラントを吐出した条件 (Test 1), (2) 主軸を  $2,000 \text{ min}^{-1}$  もしくは  $4,000 \text{ min}^{-1}$  の回転速度で8時間運転した条件 (Test 2), (3) X軸およびZ軸を  $15,000 \text{ mm/min}$  もしくは  $30,000 \text{ mm/min}$  の速度で8時間運転した条件 (Test 3), (4) 機械周辺の環境温度を9時間で8 K 上下させた条件 (Test 4) の4種である。なお, Test 1, 2 および 3 の条件について機械周辺温度はおおむね一定とした。また, 単一の条件だけではなく, 複数の条件の組み合わせ条件も設定した。組み合わせ条件とは, 環境温度を変化させながらクーラントを吐出する, 主軸運転しながら各軸を稼働するなど, 2つの条件を同時に実施した測定条件である。

### (1) Test 1: クーラント加熱による切削熱の模擬条件

ターニングセンタの加工によって発生する切削熱は, その多くが, クーラントによって奪われ [Bry90], クーラントの温度が上昇する。「クーラント」とは, 切削点とその周辺で発生する熱によって加工対象物や工具の温度が上昇することを防止するための冷却材のことを指す。表 3.2 の Test 1 の条件として, クーラントの温度変化に関係する重切削条件 (Heavy) と軽切削条件 (Light) の2種を考えた。

重切削加工の場合にはクーラントの温度上昇量が大きいため, 熱変位に与える影響も大きいと考えられる。そこで, 切削熱によってクーラントの温度が上昇した場合を再現するため, クーラントを加熱した。クーラント加熱装置の概要を図 3.5 に示す。使用したクーラントは水溶性クーラントであり, 機械に付随するクーラントタンク内部に水加熱用投げ込みヒータを据え付け, 加熱した。加熱用ヒータはソリッドステート・リレー (SSR) を介して温度制御装置と接続されており, タンク内に設置した温度センサで監視した温度が目標温度になるよう PID 制御でタンク内の温度を制御する。温度制御装置には, プログラム機能が搭載されており, あらかじめ設定した温度プロファイルを目標値としてタンク内のクーラント温度が制御できる。図 3.6 に設定した温度プロファイルを示す。この温度プロファイルは, 測定対象としたターニングセンタでターニング加工を実施した際のクーラント温度変化を測定することにより決定し, 重切削条件 (Heavy) とした。

重切削条件 (Heavy) でクーラントの温度を制御したとき, 主軸-タレット間の相対変位と, 機械構造の各部につけた温度センサの温度を測定した例を図 3.7 に示す。図 3.7 (a) は, 変位の測定結果であり, 濃い青色と薄い青色の2本の線が機械座標系 X 軸方向の変位センサの測定結果, 濃いオレンジ色と薄いオレンジ色の2本の線が Y 軸方向の測定結果, 緑色の線が Z 軸方向の測定結果を示す。図 3.7 (b) は, 温度の測定結果であり, 図中の各色が 1~12 番目の温度センサにそれぞれ対応する。測定開始時刻から8時間にかけて, クーラン

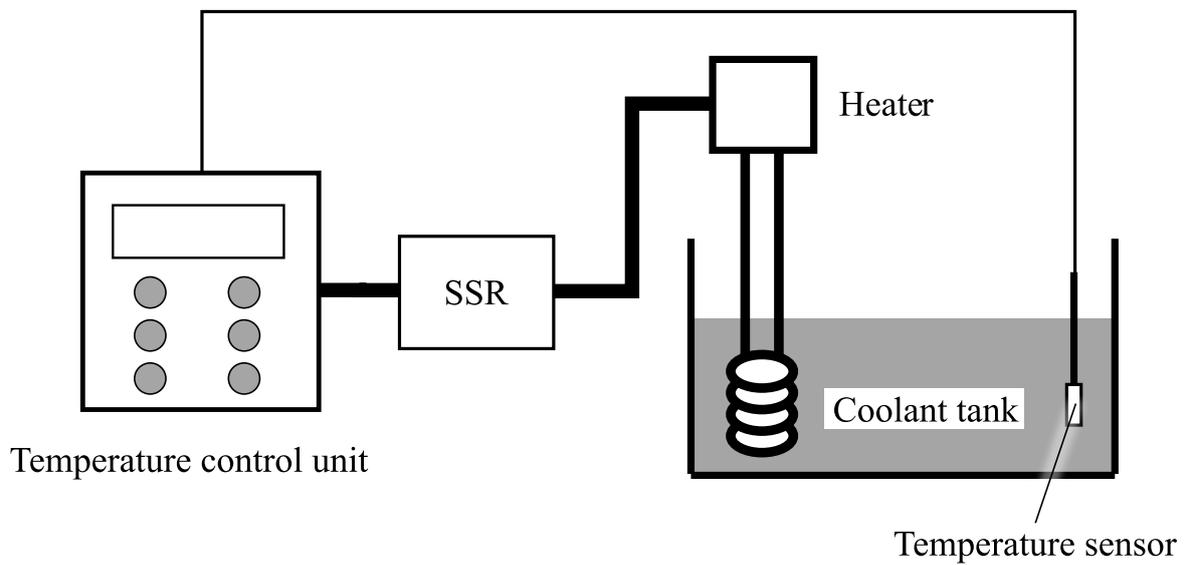


図 3.5: Schematic diagram of coolant heating system

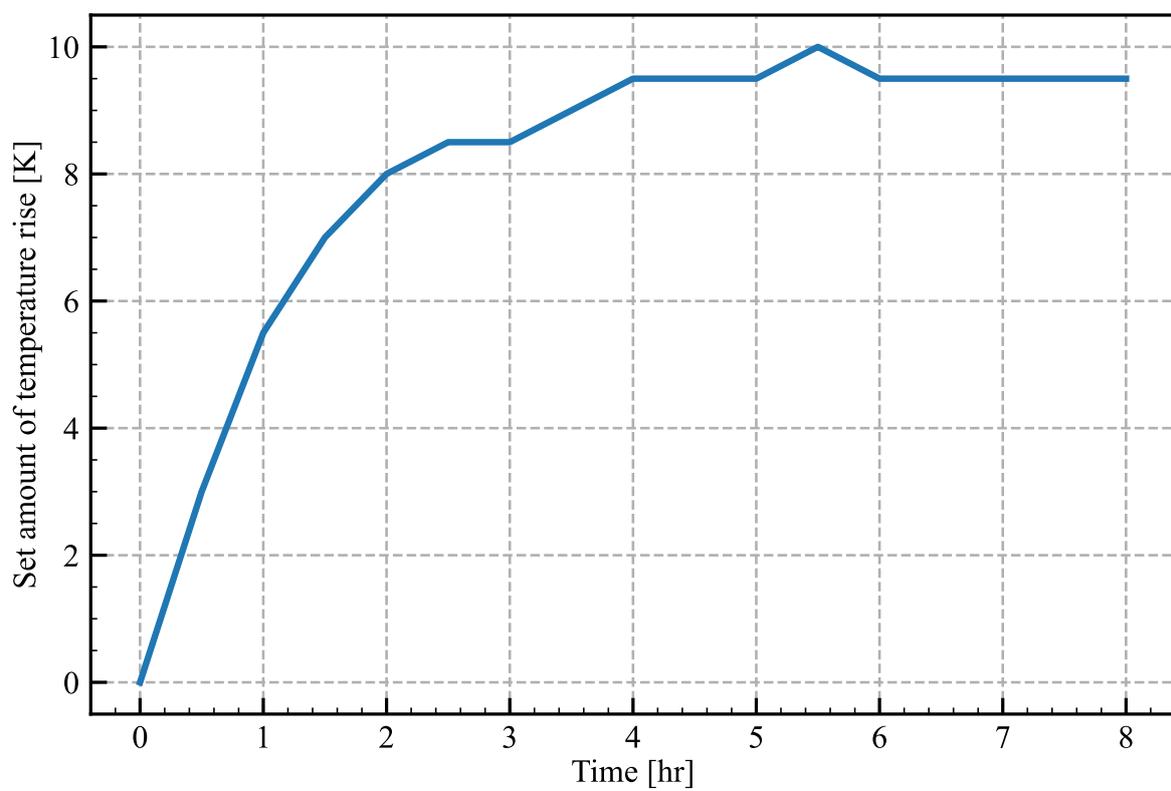
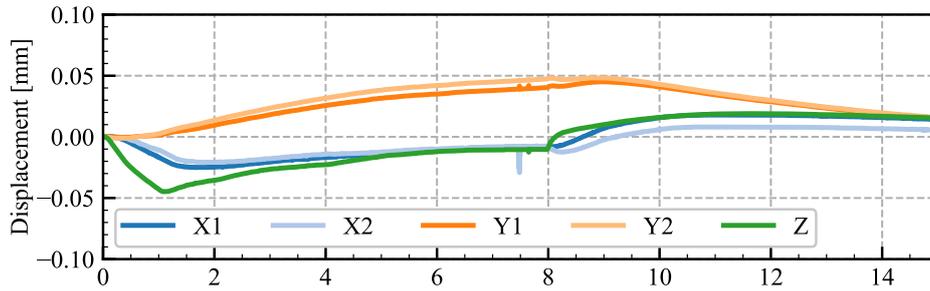
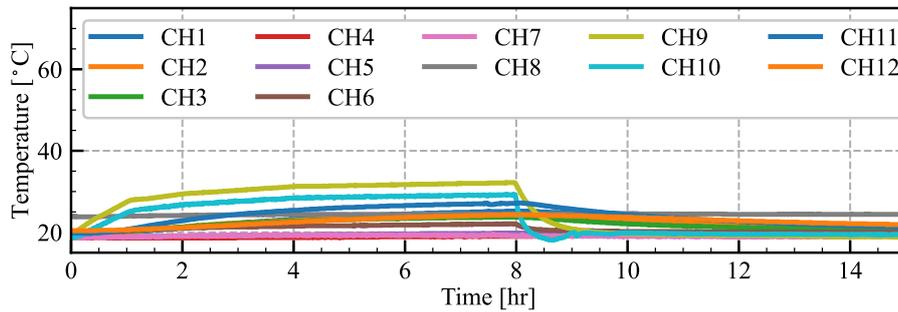


図 3.6: Set amount of coolant temperature rise for heavy cutting



(a) Displacement

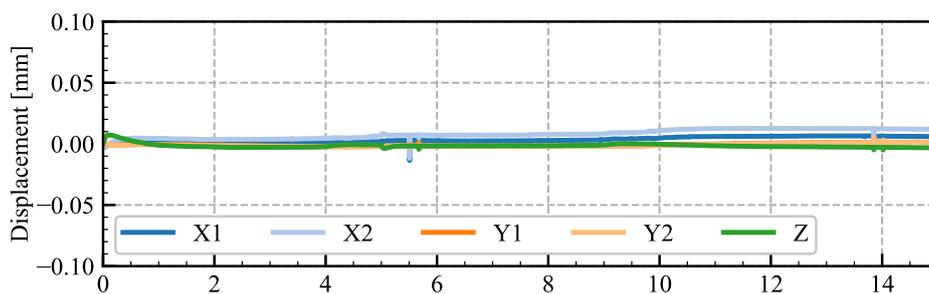


(b) Temperature

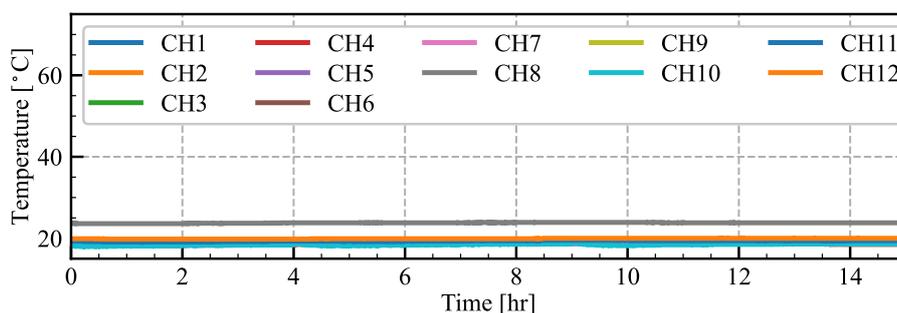
図 3.7: Thermal displacement and temperatures data for coolant heating condition (Heavy)

トを加熱し加工室内に吐出したため、8時間を境に変位、温度ともに現象が変化していることがわかる。

軽切削 (Light) 条件は、加熱は実施せずクーラントを加工室内に吐出した。これは、軽切削、つまり切削熱がほとんど発生しない使用条件では、切削熱によるクーラント温度上昇もほとんど発生しないと考えられるためである。主軸-タレット間変位、温度を測定した例を図 3.8 に示す。図 3.8 (a) は、変位の測定結果、図 3.8 (b) は、温度の測定結果であり、図中配色は図 3.7 と同様である。測定開始時刻から 8 時間にかけてクーラントを加工室内に吐出しているが、変位、温度とも明確な変動は見取れない。重切削条件と比較すると、軽切削を想定した条件では機械構造の温度は安定し、温度変化が小さいために熱変位の要因になる熱変形も小さなものであると考えられる。



(a) Displacement



(b) Temperature

図 3.8: Thermal displacement and temperatures data for coolant heating condition (Light)

## (2) Test 2: 主軸運転条件

測定対象としたターニングセンタの主軸は、ビルトイン構造を採用しており、主軸台内部に主軸シャフト、軸受、軸受箱などの構造部品と、主軸を回転させるためのモータが内蔵されている構造である。また、ビルトインモータのステータの外周には、冷却油が循環している。主軸の運転によってモータや軸受が発熱すると、主軸シャフトや主軸台構造の温度変化によって熱変位が発生すると考えられるため、表 3.2 の Test 2 に相当する条件として、主軸を  $2,000 \text{ min}^{-1}$  および  $4,000 \text{ min}^{-1}$  の 2 種で 8 時間運転した。

このときの主軸-タレット間変位、温度を測定した例を図 3.9 に示す。この測定結果は、主軸を  $4,000 \text{ min}^{-1}$  で 8 時間運転したものである。図 3.9 (a) は、変位の測定結果、図 3.9 (b) は、温度の測定結果であり、図中配色は図 3.7 と同様である。測定開始から 2 時間程度にかけて、X 軸方向と Y 軸方向に比較して Z 軸方向の変位が大きく変化していることがわかる。これは、主軸の伸びや主軸台の熱膨張に起因するものであると考えられる。主軸の運転

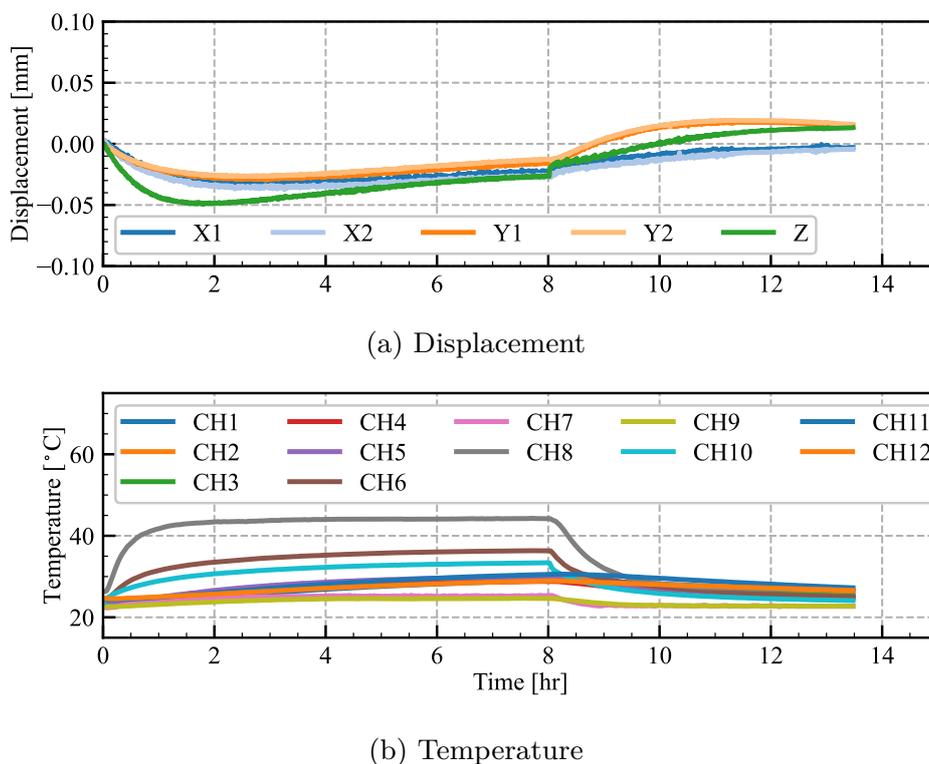


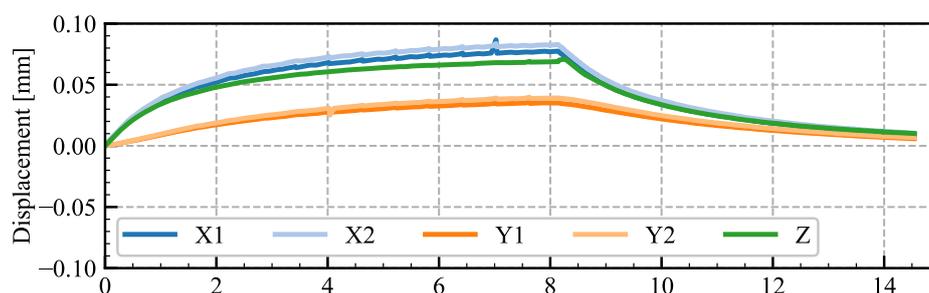
図 3.9: Thermal displacement and temperatures data for spindle running condition

によってモータや軸受が発熱すると、主軸シャフトや主軸台が温度上昇し、熱膨張の要因になる。

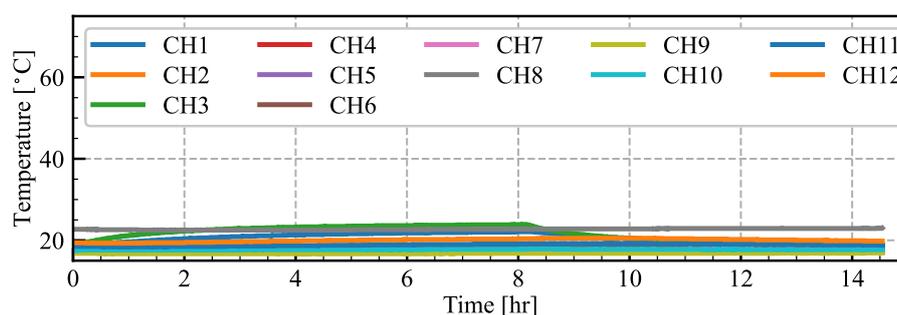
### (3) Test 3: 軸稼働条件

測定対象としたターニングセンタは、ボールねじによる駆動方式を採用しており、各軸はサーボモータ、ボールねじとボールねじを支持する軸受、摺動面で構成されている。各軸の稼働によりサーボモータとボールねじが回転し、摺動面に往復運動が発生すると、モータの発熱や、軸受・ボールねじの発熱、摺動面で発熱が起こる。表 3.2 の Test 3 に相当する条件として、軸稼働条件は、X 軸および Z 軸を 15,000 mm/min および 30,000 mm/min の 2 種で 8 時間運転する条件とした。各軸を動作させるためには、図 3.4 に示す主軸-タレット間の相対変位を測定するための測定位置からタレットを移動させる必要がある。主軸-タレット間の相対変位の測定と移動軸の動作を両立させるために、一定時間おきに図 3.4 に示す測定状態に復帰し、それ以外の時間帯は各移動軸を動作させることとした。

主軸-タレット間変位、温度を測定した例を図 3.10 に示す。この結果は、X 軸及び Z



(a) Displacement



(b) Temperature

図 3.10: Thermal displacement and temperatures data for axes moving condition

軸を 30,000 mm/min で 8 時間稼働させたものである。図 3.10 (a) は、変位の測定結果、図 3.10 (b) は、温度の測定結果であり、図中配色は図 3.7 と同様である。先に述べたように、図に示した変位の測定結果は、各移動軸が稼働しているタイミングを除外し、測定状態の変位だけを抜き出した。軸稼働条件では機械座標系の X 軸方向、Y 軸方向、Z 軸方向のすべてで、機械座標系のプラス方向に変位し、稼働が停止すると変位量が小さくなっていくことがわかる。

#### (4) Test 4: 環境温度変化条件

表 3.2 の Test 4 に相当する条件として、機械周辺の温度を変化させた。機械周辺の温度変化による熱変位への影響を測定するためには、温度制御が可能な室内に工作機械を設置すればよいが、工作機械の出し入れや据え付けの作業にかかる時間を考えると、多数の機械を対象とした測定には向かない。そこで、多数の機械に対して簡単に周辺温度を変化させるため、図 3.11 に示す移動式の温度可変ブース内に機械を設置して熱変位測定を実施した。温度可変ブースには空調装置が接続されており、機械周辺の温度を変化させたり一定温度に制



図 3.11: Movable temperature variable booth and air conditioner

御したりすることが可能である。ブース内の環境温度の指令温度プロファイルを図 3.12 に示す。測定開始から 4 時間かけて 8 K 上昇させ、1 時間温度を維持した後に 4 時間かけて 8 K 下降させ、測定開始時の温度に戻ってその温度を維持するパターンである。

主軸-タレット間変位、温度を測定した例を図 3.13 に示す。図 3.13 (a) は、変位の測定結果、図 3.13 (b) は、温度の測定結果であり、図中配色は図 3.7 と同様である。この測定結果のうち、機械座標系 X 軸方向の熱変位は、2.4.2 項の結果と同様に、測定開始からマイナス方向に変位したのちに変位の方向が変化してプラス方向に変位し、温度変化が終了すると熱変位が緩和している。変形メカニズムについては 2.4.2 項で述べたため再度説明しないが、熱変形の形態としては同様であると考えられる。

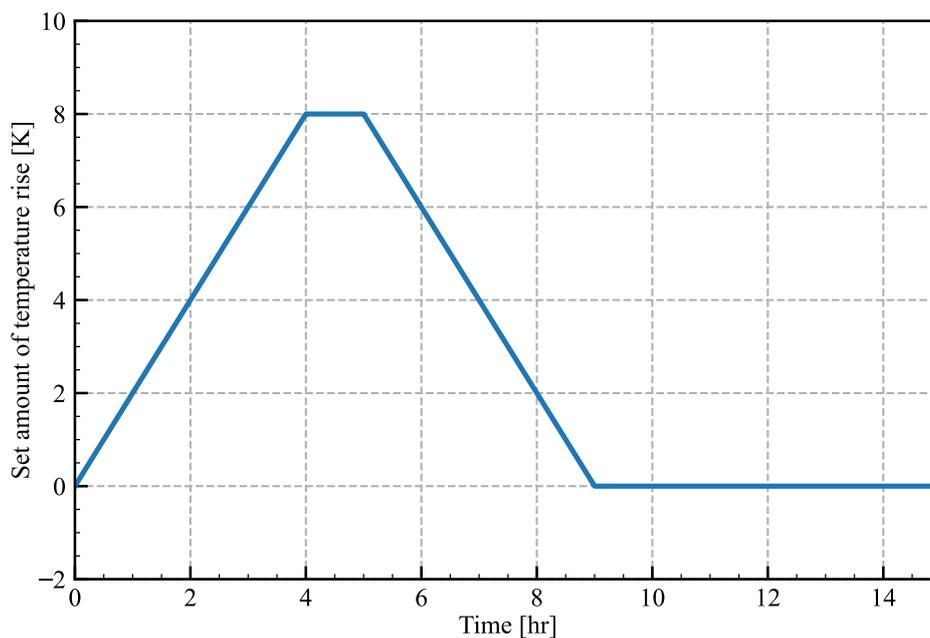
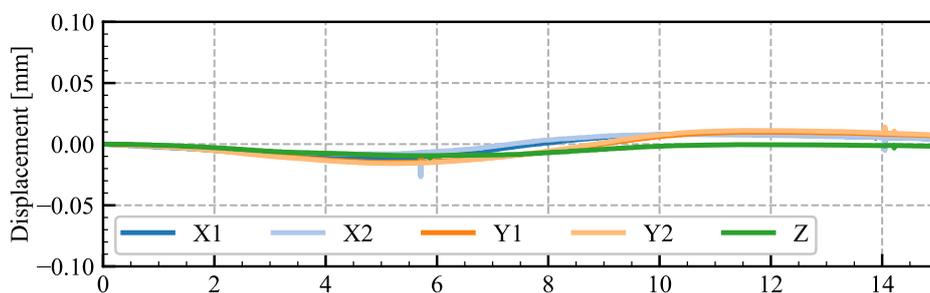
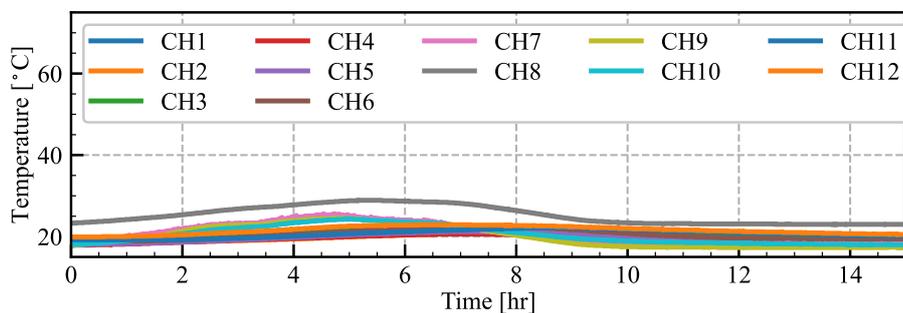


図 3.12: Set amount of ambient temperature



(a) Displacement



(b) Temperature

図 3.13: Thermal displacement and temperatures data for ambient temperature change condition

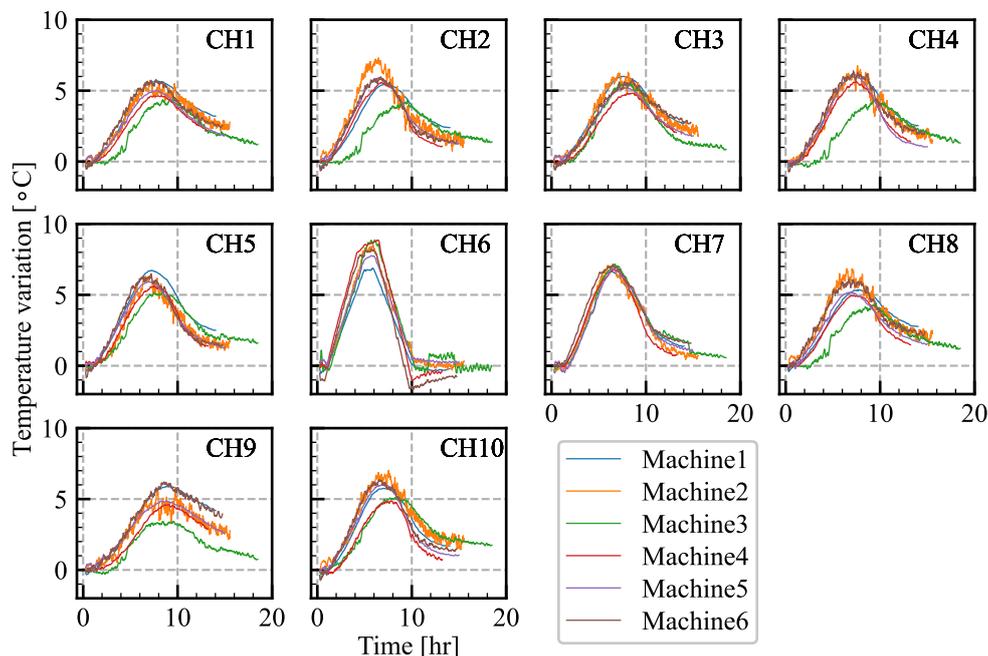


図 3.14: Temperature measurement results of 6 machines (CH1-CH10: temperature sensors)

## 3.4 ケーススタディ：ターニングセンタの熱変位推定モデルの学習

### 3.4.1 温度と主軸-タレット間相対変位の測定

3.3.1 項で述べたターニングセンタと同一機種 of ターニングセンタ 6 台について、熱変位データを収集した。温度センサは、機械構造 7 点、主軸温度 1 点、環境温度 2 点の合計 10 点を取り付けた。熱変位データの測定条件として、3.3.3 項で述べた環境温度変化条件（表 3.2 の Test 4）で機械周辺の温度を変化させた。測定した温度データを図 3.14 に示す。各図はターニングセンタの機械構造の温度センサ 1-10 の温度変化量の測定結果を示し、6 台それぞれの機械に対する測定結果が、同じ機械のものが同じ色になるように示した。この図では、機械周辺の温度変化開始時の値を 0 とし、温度変化量を示している。測定した主軸-タレット間相対変位を図 3.15 に示す。機械座標系 X 軸方向（図 3.4 参照）の変位であり、加工対象物の直径変化に相当する量である。6 台の機械それぞれの測定結果を別の色とし、図 3.14 と同じ機械のものが同じ色になるように示した。図中 Machine 3 の変位量は、他の機械の

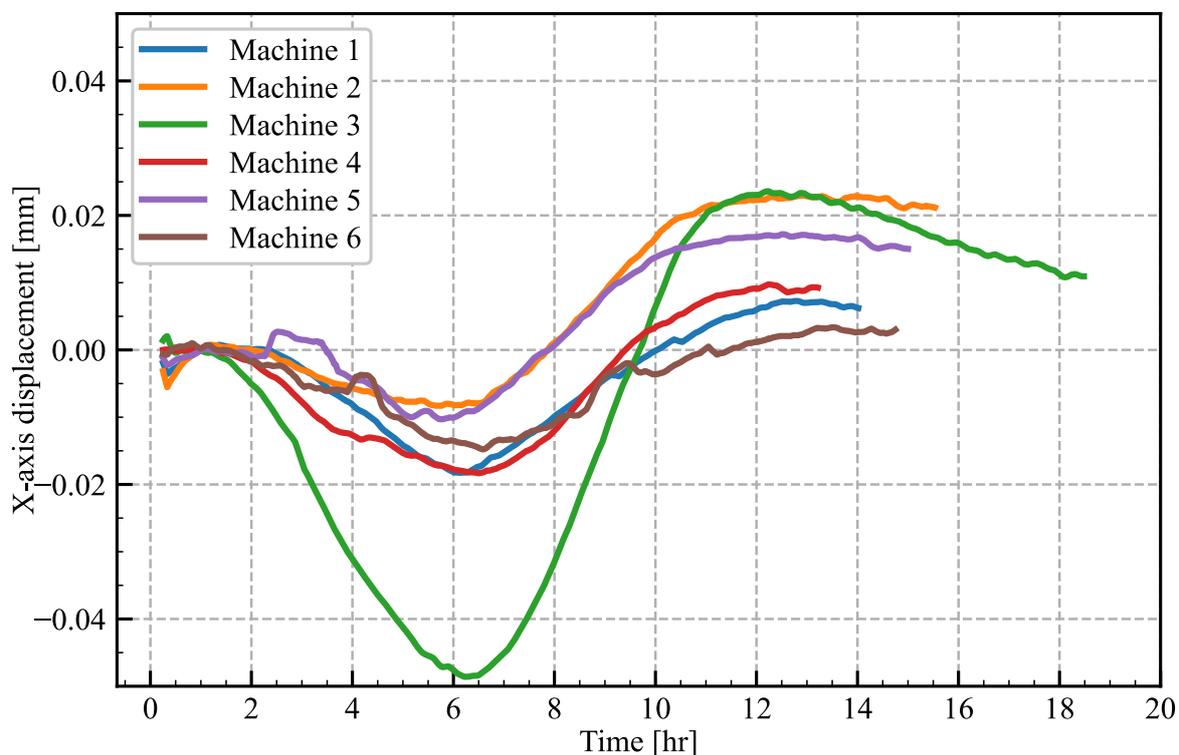


図 3.15: X-axis thermal displacement measurement results of 6 machines

変位量（Peak-to-Peak）が 0.04 mm 程度であるのに対して 0.07 mm 程度と大きいことがわかる。図 3.14 の温度データでは、Machine 3 を示す緑色の線が他の機械の温度変化データの傾向と一致していない部分（例えば、CH2、CH4、CH8）があり、この温度変化の違いが変位量の違いの要因であると考えられる。

### 3.4.2 学習した熱変位推定モデルの推定精度の検証

3.4.1 項で収集した熱変位データを使用して、深層学習による熱変位推定モデルを学習した。熱変位推定モデルは図 3.1 で示した構造のものを使用し、収集した 6 台の温度データと変位データの組み合わせからなる熱変位データのうち 4 台分を学習データとして、残りの 2 台分を評価データとして使用した。評価データは、熱変位推定モデルの性能を評価する目的で学習に使用せず、学習後の熱変位推定モデルに入力して推定結果を検証する目的で使用するデータである。

学習した熱変位推定モデルに対して、学習データを入力して熱変位推定を実施した結果のうち、機械座標系 X 軸方向の主軸-タレット間相対変位の推定結果を図 3.16 に示す。4 つ

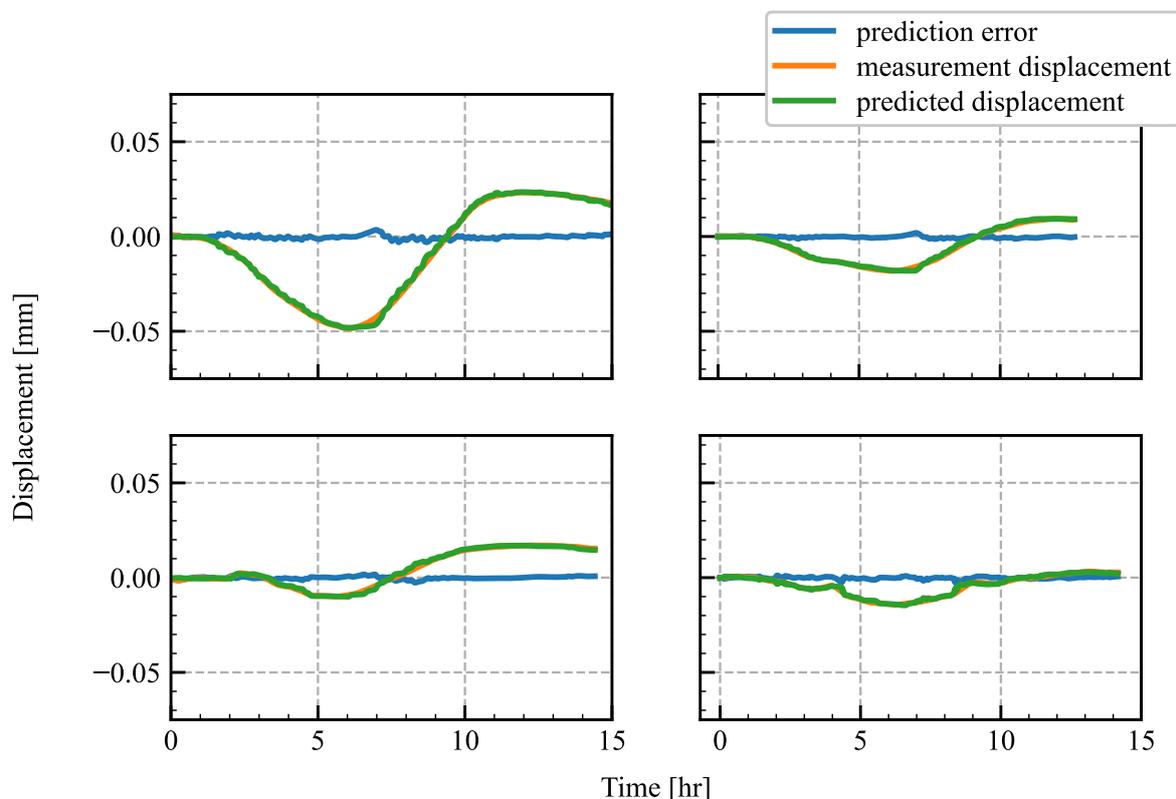


図 3.16: Predicted thermal displacement in X-axis direction with training data (four plots are from four different machines)

の図はそれぞれ同一機種 of ターニングセンタの別々の機械の推定結果であり、オレンジ色の線が測定結果、緑色の線が推定結果、青色の線が誤差を示す。いずれの結果も最大誤差 (Peak-to-Peak) は 0.01 mm 程度以下である。

次に、学習した熱変位推定モデルに対して、評価データを入力して熱変位推定を実施した結果を図 3.17 に示す。図 3.16 と同様に同一機種 of ターニングセンタの別々の機械の推定結果であり、オレンジ色の線が測定結果、緑色の線が推定結果、青色の線が誤差を示す。いずれの結果も最大誤差 (Peak-to-Peak) は 0.01 mm 程度以下である。

### 3.4.3 他の方式の熱変位推定モデルの推定精度との比較

CNN による熱変位推定の性能を線形重回帰と比較した。1 台の機械の 1 条件のデータを使用して、L2 正則化による重回帰分析 (リッジ回帰) [Ido16] で熱変位推定モデルを学習し、本章で提案した CNN を用いた深層学習ネットワークと同じデータについての推定精度を比

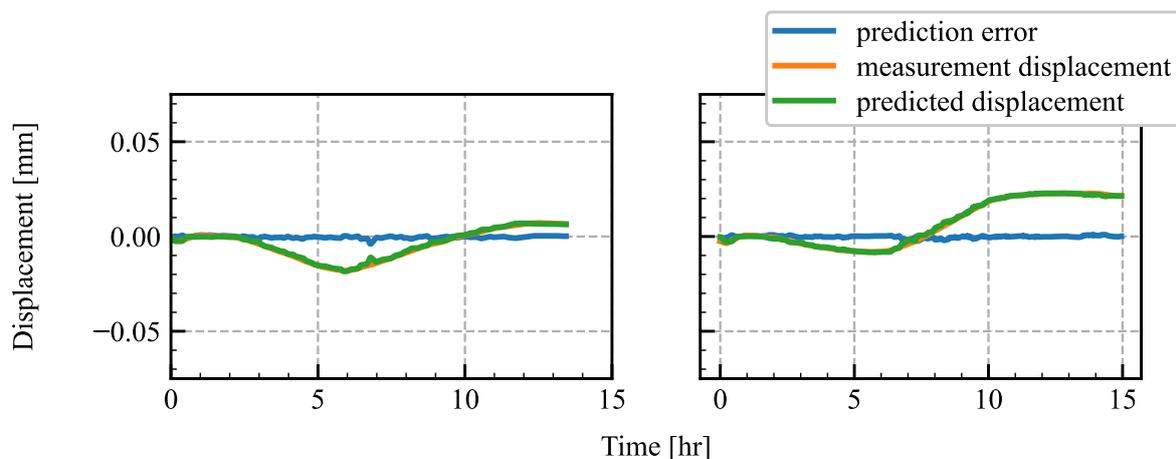


図 3.17: Predicted thermal displacement in X-axis direction with evaluation data (two plots are from two different machines)

較した。結果を図 3.18 に示す。青色の線がリッジ回帰による機械座標系 X 軸方向の熱変位推定結果，オレンジ色の線が CNN による推定結果，緑色の線が教師データとして用いた測定結果である。また，測定結果に対する推定結果の誤差を図 3.19 に示す。推定誤差は，推定結果から測定結果（教師データ）を減算することで計算した。青色の線がリッジ回帰による機械座標系 X 軸方向の熱変位推定結果の測定結果に対する誤差，オレンジ色の線が CNN による推定誤差である。

リッジ回帰と CNN の比較では，リッジ回帰の最大誤差（Peak-to-Peak 値）が 0.01 mm 程度であるのに対して，CNN の最大誤差（Peak-to-Peak 値）は 0.004 mm 程度と半分以下である。また，リッジ回帰の推定誤差には 0.005 mm 程度の周期の短い変動が認められるが，CNN の結果では変動が少なく，滑らかな波形である。リッジ回帰の結果に細かい変動が認められるのは，特定の温度センサの係数が過度に大きくなっていることなどが要因と考えられる。一方 CNN では，熱変位推定モデル内部に畳み込み演算が含まれることから，入力データの特定のセンサだけの変動や，ノイズのような細かい変動に対して，結果が安定する傾向があると考えられる。

リッジ回帰などの，重回帰分析による学習は，どのセンサを選択するか，あるいはどのデータで学習するかで，結果が大きく異なることがある [Nag99]。本項の結果は，単一のデータに対する検討であり，一般化した議論はできないが，使用するセンサの選択や熱変位推定モデルの学習パラメータのチューニングがほとんど必要なく，ある程度精度のよい結果が得られることは，CNN による熱変位推定モデル学習の利点である。

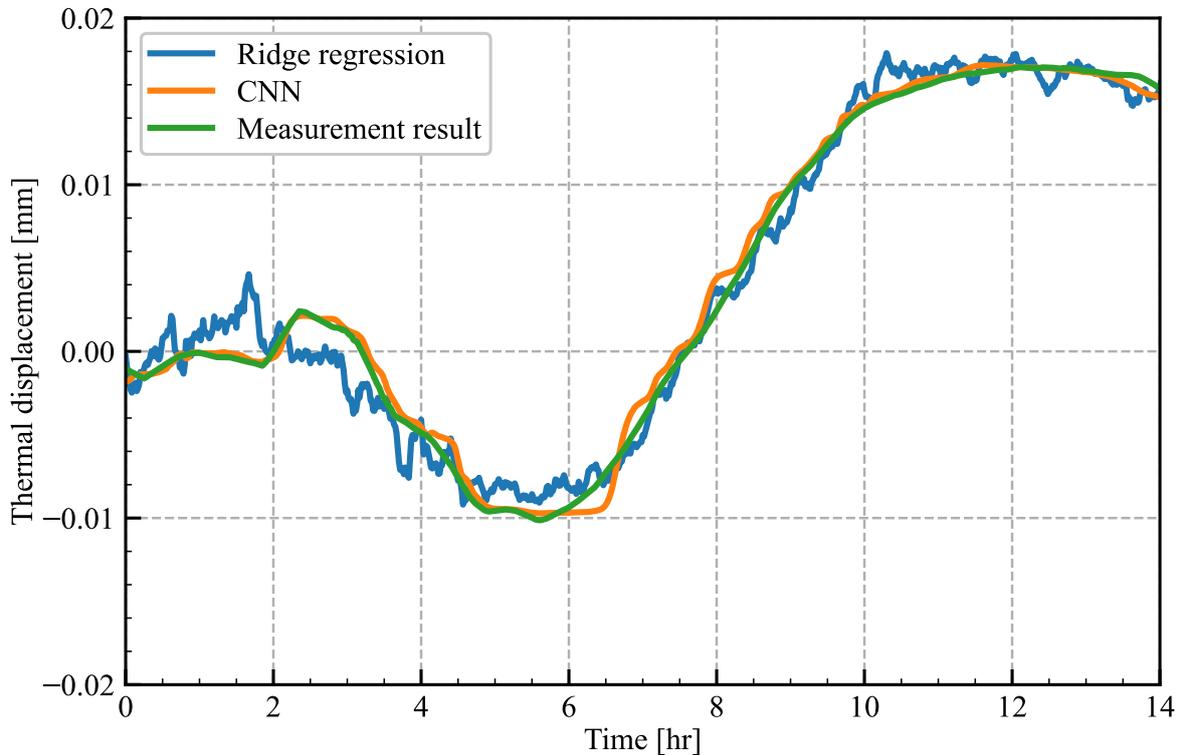


図 3.18: Prediction result comparison between CNN and ridge regression

### 3.5 結言

本章では、深層学習によって工作機械の熱変位を推定するために、CNN による熱変位推定モデルを提案し、多数のターニングセンタの熱変位データを測定する方法を述べ、収集した熱変位データで学習した CNN による深層学習ネットワークで熱変位が推定できることを示した。

本章での提案と、ケーススタディの結果まとめは以下のとおりである。

1. 工作機械の熱変位推定のために、従来の研究で多く用いられてきた数式による熱変位推定モデルは、次数、静的・動的、線形・非線形など、設計者が対象に合わせて選択しなければならない要素が多い。本章では、そのような必要性が少ない、CNN を用いた熱変位推定モデルを提案した。
2. 深層学習による工作機械の熱変位推定モデルを学習するために、多数のターニングセンタの熱変位を測定する方法を示した。熱変位データとして、工作機械の機械構造に

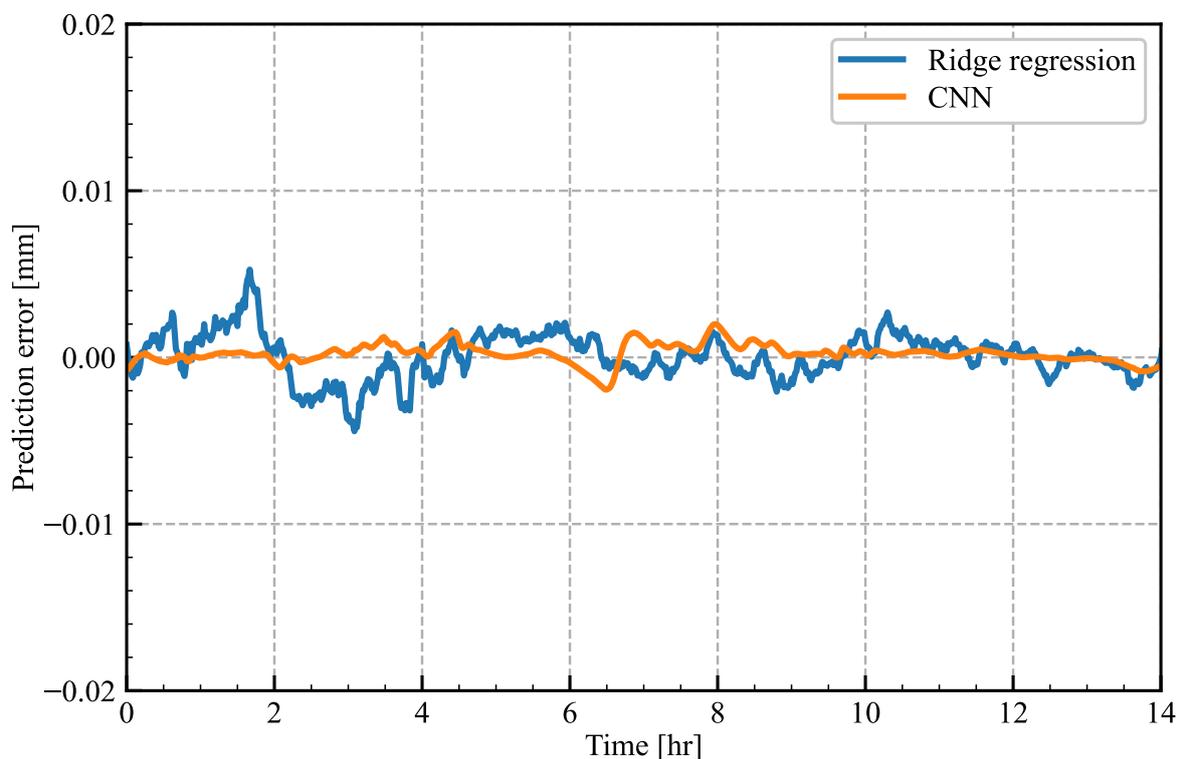


図 3.19: Prediction error comparison between CNN and ridge regression

取り付け温度センサと、主軸-タレット間の相対変位を非接触変位センサを用いて測定した。熱変位に影響する要因として、(1) クーラントの温度上昇、(2) 主軸運転、(3) 軸稼働、(4) 環境温度変化の4つを挙げ、それぞれについて測定条件を設定して熱変位データの収集方法を述べた。

3. ケーススタディとして、6台のターニングセンタの環境温度変化条件の熱変位データを測定し、提案したCNNによる深層学習によって熱変位推定モデルを学習した。学習した熱変位推定モデルの誤差は、0.01 mm程度以下であり、熱変位を高精度に推定することができた。また、L2正則化による重回帰分析(リッジ回帰)による熱変位推定モデルと本章で提案したCNNによる熱変位推定モデルの推定性能を比較し、CNNの方が良好な結果であった。
4. 本章の結果は同一機種別の機械のデータを使用したため、個体差の影響は考慮できている。しかし、測定条件は同じ設定プロファイルによる環境温度変化であるため、任意の測定条件や実際の加工条件での推定性能についてはさらに検討する必要がある。



## 第4章

# 深層学習による熱変位推定モデルの信頼性評価

### 4.1 緒言

熱変位推定モデルを実際の工作機械に搭載して加工精度が安定するよう補正制御を実施する場合、推定性能の信頼性が重要である。熱変位推定モデルは、実際の測定データを使用して学習するため、推定結果には少なからず誤差を含む。この誤差が大きくなると本来実施したい補正の量と実際の機械の移動量にずれが発生し、加工精度が安定しないばかりでなく、急激に大きな補正量が入力されて機械破損などの原因になることが考えられる。そこで、深層学習による熱変位推定において、推定結果に対する信頼性の評価手法を導入し、評価した信頼性に基づいて補正量を修正する補正制御システムを提案する。

熱変位推定モデルによる推定誤差が非常に大きくなるもっとも典型的な原因は、温度センサの故障である。実際の工作機械に熱変位補正制御機能を搭載する場合、センサ故障への対処が問題となる。工作機械は10年以上使用されることも珍しくないため、センサ故障は想定しなければならない。入力データとして使用するセンサが故障して故障信号が入力された場合、熱変位推定モデルはその信号が正しいものとして扱ってしまうために、推論結果が異常なものとなる。信頼性が不明の場合、正常な推論結果であるか異常なものであるかが判別できない。一方、熱変位推定モデルや推定値の信頼性がわかれば、信頼性に応じて対応を変えることもできる。例えば熱変位推定による補正制御の場合、信頼性が高い推定結果の場合には推定結果をそのまま補正制御に使用し、信頼性が低い場合には制御に使用せずに使用者に注意を促すことなどが考えられる。極端に信頼性が低い場合には補正制御機能を停止することもできる。ただし、本章の「信頼性」とは、温度センサの故障だけを考えるものではない。

い。本章で、熱変位推定モデルの「信頼性」とは、4.2節に示す「Bayesian dropout」の手法を用いて、深層学習ネットワークのノードの接続をランダムに切断したときの、出力値（熱変位の推定値）の変動と定義する。信頼性とは、学習した熱変位推定モデルについて、新規データを入力したときに出力データがどの程度信頼できるかということを表す。信頼性のより詳しい定義は、4.2節で述べる。

深層学習による分類タスク（例えば画像に写っているものが「犬」か「猫」か「猿」のうちどれかを判定するなど、入力データがあらかじめ与えられたカテゴリのどれに属するかを判定するタスク）では、入力データがどのクラスに属するかを推定する。出力関数として「softmax」などの正規化関数を用いることにより、出力の信頼性を確率として簡易的に評価することができる。一方深層学習による回帰タスク（例えば寝室数、立地、規模などの住宅の属性から住宅価格を予測するなど、入力データから何らかの数値を推定するタスク）では、入力データに対して連続性のある数値を推定する。数値そのものを推定するために、そのまま信頼性を評価することはできない。深層学習による熱変位の推定では、回帰タスクとして温度などのデータから変位量を推定する。したがって、深層学習による熱変位推定モデルで推定信頼性を評価することは難しかった。

本章では、「Bayesian dropout」[GG16b, GG16a, Gal16]と呼ばれる手法を用いて深層学習によって構築した熱変位推定モデルの推定分布を計算する。次に、ケーススタディとして、入力データとして使用する温度センサ信号の一部を断線と接触不良を想定した温度センサの故障シミュレーション信号に差し替え、推定分布の変化を調査した結果を示す。熱変位の推定分布が大きくなる状態は、推定の信頼性が低い状態であると考えられる。そこで、推定分布に応じて熱変位推定モデルからの出力に適用する移動平均フィルタの平均長パラメータを調整し、熱変位推定の信頼性が低い状態でも過大な補正量が機械に入力されない方法を提案し、実際の工作機械に搭載した加工試験でその効果を示す。

## 4.2 Bayesian dropout による熱変位推定モデルの信頼性の評価

ドロップアウトは、深層学習ネットワークの学習中にいくつかのノード間の接続をランダムに切断し、学習の反復ごとに接続するノードと切断するノードを切り替える手法である。深層学習では、ネットワークの汎化性能の向上や学習データの水増しなどの目的で、ドロップアウトが広く利用されている [HSK<sup>+</sup>12, SHK<sup>+</sup>14]。ドロップアウトの概要図を図4.1に示す。図4.1(a)はドロップアウトを用いず、すべてのノードが接続されている状態、図4.1(b)

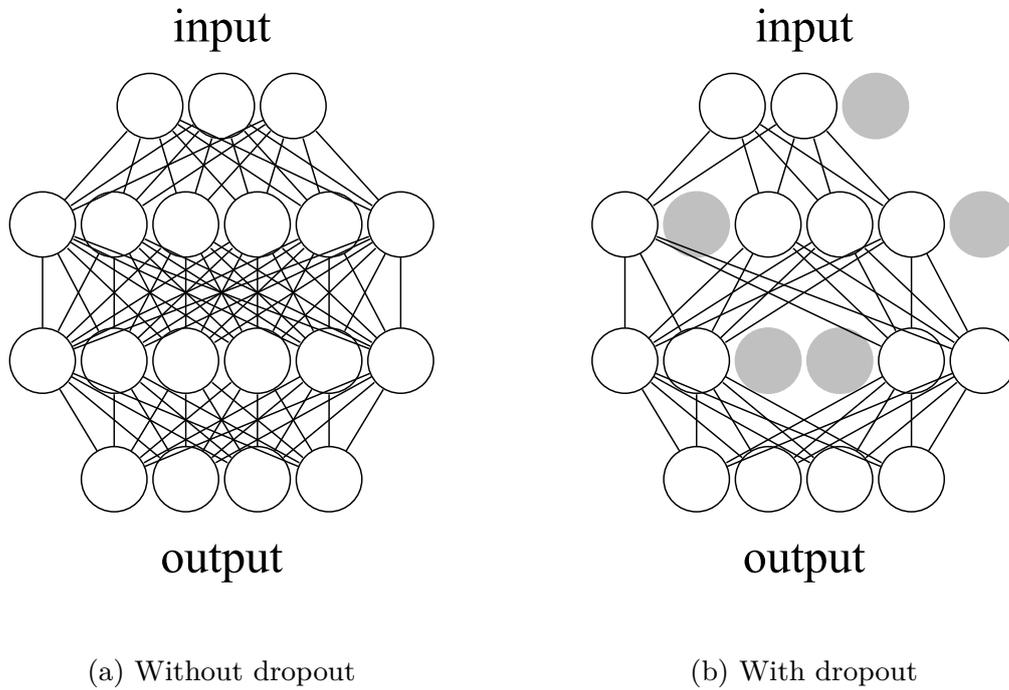


図 4.1: Schematic diagram of dropout

はドロップアウトを適用し、いくつかのノードの接続を切断した状態である。ドロップアウトは、深層学習ネットワークの学習時に推定ネットワークの  $l \in \mathbb{N}$  層に挿入し、1回の学習の試行ごとに確率  $p_l$  でランダムにノードを切断する。推論時には、すべてのノードを接続した状態で計算を実施する。

深層学習による回帰タスクでは、推定結果の信頼性を評価することが難しいことが一般的だった。文献 [GG16b, GG16a, Gal16] では、「Bayesian dropout」と呼ばれる手法でドロップアウトによって不確かさを計算し、信頼性を評価する方法が提案されているので、以下に簡単に紹介する。

深層学習で使用されるニューラルネットワークについて、 $l = 1, \dots, L$  層のパラメータ行列  $\mathbf{W}_l \in \mathbb{R}^{K_l \times K_{l-1}}$  とバイアスベクトル  $\mathbf{m}_l \in \mathbb{R}^{K_l}$  によって表されるネットワークの、入力  $\mathbf{x}$  に対する出力  $\hat{\mathbf{y}}$  は、

$$\hat{\mathbf{y}} = \mathbf{W}_L \sigma \left( \dots \mathbf{W}_2 \sigma (\mathbf{W}_1 \mathbf{x} + \mathbf{m}_1) \dots \right) \quad (4.1)$$

と表すことができる。  $\sigma(\cdot)$  はシグモイドや  $\tanh$  などの活性化関数である。

$l$  層に挿入されるドロップアウトは、各層のノードの、次の層のノードに対する接続状態

を切り替える役割をするので、2値変数  $\mathbf{z}_{l,j} = \{0, 1\}$  と重み行列から、 $l$  層のパラメータ  $\mathbf{W}_l$  を以下のように定義する.

$$\begin{aligned} \mathbf{W}_l &= \mathbf{M}_l \cdot \text{diag}([\mathbf{z}_{l,j}]_{j=1}^{K_l}) \\ \mathbf{z}_{l,j} &\sim \text{Bernoulli}(p_l) \text{ for } l = 1, \dots, L, j = 1, \dots, K_{l-1} \end{aligned} \quad (4.2)$$

これは、確率  $p_l$  と各層の重み行列  $\mathbf{M}_l \in \mathbb{R}^{K_l \times K_{l-1}}$  が与えられたとき、2値変数  $\mathbf{z}_{l,j} = \{0, 1\}$  によって、 $l-1$  層のユニット  $j$  が  $l$  層への入力から取り除かれることに対応するため、ドロップアウトの実装と同義である. 式 (4.1) は、式 (4.2) から、

$$\hat{\mathbf{y}} = \mathbf{M}_L \mathbf{z}_L \sigma \left( \dots (\mathbf{M}_2 \mathbf{z}_2) \sigma \left( (\mathbf{M}_1 \mathbf{z}_1) \mathbf{x} + \mathbf{m}_1 \right) \dots \right) \quad (4.3)$$

のように、2値ベクトル  $\mathbf{z}_l \in \{0, 1\}^{K_{l-1}} = \text{diag}([\mathbf{z}_{l,j}]_{j=1}^{K_{l-1}})$  によって表すことができる.

一方、深層学習ネットワークの予測分布は、ベイズ推定の考え方に基づき、学習データ群  $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ ,  $\mathbf{Y} = \{\mathbf{y}_1, \dots, \mathbf{y}_N\}$  によって学習したネットワークのパラメータを  $\boldsymbol{\omega} = \{\mathbf{W}_1, \dots, \mathbf{W}_L\}$  としたとき、未知のデータ  $\mathbf{x}$  に対する予測値  $\hat{\mathbf{y}}$  の分布として、次のように記述できるものとする.

$$p(\hat{\mathbf{y}}|\mathbf{x}, \mathbf{X}, \mathbf{Y}) = \int p(\hat{\mathbf{y}}|\mathbf{x}, \boldsymbol{\omega}) p(\boldsymbol{\omega}|\mathbf{X}, \mathbf{Y}) d\boldsymbol{\omega} \quad (4.4)$$

ここで、 $p(\hat{\mathbf{y}}|\mathbf{x}, \boldsymbol{\omega})$  は、以下の関係で求められる.

$$p(\hat{\mathbf{y}}|\mathbf{x}, \boldsymbol{\omega}) = \mathcal{N}(\mathbf{y}; \hat{\mathbf{y}}(\mathbf{x}, \boldsymbol{\omega}), \tau^{-1} \mathbf{I}_{N_D}) \quad (4.5)$$

$$\hat{\mathbf{y}}(\mathbf{x}, \boldsymbol{\omega} = \{\mathbf{W}_1, \dots, \mathbf{W}_L\}) = \mathbf{W}_L \sigma \left( \dots \mathbf{W}_2 \sigma(\mathbf{W}_1 \mathbf{x} + \mathbf{m}_1) \dots \right) \quad (4.6)$$

$\mathcal{N}(\mu, \sigma^2)$  は、平均を  $\mu$ 、分散を  $\sigma^2$  とするガウス分布を表し、 $\tau$  は、学習時のハイパーパラメータから決定できる精度ハイパーパラメータ、 $\mathbf{I}_{N_D} \in \{1\}^{N_D \times N_D}$  は単位行列である. 一方、式 (4.4) の事後分布  $p(\boldsymbol{\omega}|\mathbf{X}, \mathbf{Y})$  は複雑なモデルに対して計算が困難なので、文献 [GG16b, GG16a, Gal16] では、これを近似する分布  $q(\boldsymbol{\omega})$  を、式 (4.2) によってドロップアウトを用いた試行で表すことを提案している.

最終的な推定値  $\mathbb{E}(\mathbf{y}^*)$  は、ドロップアウトによって切断するノードを切り替えた  $J$  回の試行の平均値から、以下のように近似値  $\bar{\mathbf{y}}$  として求められる.

$$\mathbb{E}(\mathbf{y}^*) \approx \bar{\mathbf{y}} = \frac{1}{J} \sum_{j=1}^J \hat{\mathbf{y}}(\mathbf{x}, \mathbf{W}_1^j, \dots, \mathbf{W}_L^j) \quad (4.7)$$

また、予測分布  $\text{Variance}(\mathbf{y}^*)$  は、近似分散  $\sigma^2$  として、以下のように求められる。

$$\text{Variance}(\mathbf{y}^*) \approx \sigma^2 = \tau^{-1} \mathbf{I}_{N_D} + \frac{1}{J} \sum_{j=1}^J \hat{\mathbf{y}}(\mathbf{x}, \mathbf{W}_1^j, \dots, \mathbf{W}_L^j)^\top \hat{\mathbf{y}}(\mathbf{x}, \mathbf{W}_1^j, \dots, \mathbf{W}_L^j) \quad (4.8)$$

ドロップアウトは、ネットワークの学習結果を改善する手法であるため、通常はネットワークの学習時に使用し、推論時には使用しない。しかし「Bayesian dropout」では、ネットワークの推論時にもドロップアウトを使用する。通常の深層学習の推論では、1つの入力データ  $\mathbf{x}$  に対して1回の推論を実施して出力  $\hat{\mathbf{y}}$  を得るが、「Bayesian dropout」では、1つの入力データ  $\mathbf{x}$  に対して  $J$  回推論を実施する。その際、学習に使用したドロップアウトを適用し、1回ごとに切断するノードを切り替えながら出力  $\hat{\mathbf{y}}_1, \dots, \hat{\mathbf{y}}_J$  を得る。推定値は式 (4.7) から平均によって求め、推定分布は式 (4.8) から分散として求める。この手法の優れている点は、実装に際して特別な処理の追加や入力データに対する変更などが不要なく、最低限の変更で推定値と推定分布が得られることである。

熱変位推定モデルの信頼性は、式 (4.4) からわかるように、学習データ  $\mathbf{X}, \mathbf{Y}$  で構築した熱変位推定モデルについて、新規データ  $\mathbf{x}$  を入力したときに出力データがどの程度信頼できるかということを表す。これは、(1) 入力データに異常がある、(2) 学習データと入力データの特徴が異なる、(3) 学習データそのものの品質が悪い、などのいずれの場合でも、予測分布の増加として信頼性の低下を評価できることを表している。つまり、温度センサの故障などによる入力データの異常だけでなく、学習データ、学習結果としての熱変位推定モデルのいずれに原因がある場合でも信頼性を評価できるということである。本章では、熱変位推定モデルの信頼性を低下させるもっとも典型的な要素として、温度センサの故障による入力データの異常について扱うが、複数の熱変位推定モデルを信頼性で比較することや、学習データを変更したときの熱変位推定モデルの信頼性から、学習データの品質を評価することもできると考えられる。

## 4.3 ケーススタディ：深層学習によるターニングセンタの熱変位推定分布の評価と補正量の修正

### 4.3.1 深層学習ネットワークによる熱変位の推定と Bayesian dropout による信頼性の評価

本節の目的は、第3章と同様の実験によって、ターニングセンタの主軸-タレット間の熱変位を推定する熱変位推定モデルを深層学習によって学習するとともに、前節で示した

表 4.1: Number of measurement data for each condition

data / unit	Coolant		Spindle	Moving axes	Ambient
	Light	Heavy			
Test 1: Coolant	4 / 3	4 / 3	—	—	—
Test 2: Spindle	3 / 3		7 / 4	—	—
Test 3: Moving axes	2 / 2		2 / 2	6 / 3	—
Test 4: Ambient	4 / 3	1 / 1	4 / 2	4 / 2	8 / 4

Bayesian dropout を用いてその信頼性の評価を行うケーススタディを示すことである。対象としたターニングセンタと測定方法については 3.3 節に述べた。

同一機種のターニングセンタ 6 台について、熱変位データを収集した。温度センサは、機械構造温度 6 点、主軸温度 1 点、送り系温度 1 点、環境温度 2 点、切削油などの流体温度 2 点の合計 12 点を取り付けた。熱変位データの測定条件として、3.3 節で述べた加工熱による影響をクーラント加熱により模擬した条件（表 3.2 の Test 1）、主軸を  $4,000 \text{ min}^{-1}$  の回転速度で 8 時間運転した条件（表 3.2 の Test 2）、X 軸および Z 軸を  $30,000 \text{ mm/min}$  の速度で 8 時間運転した条件（表 3.2 の Test 3）、機械周辺の環境温度を 9 時間で 8 K 上下させた条件（表 3.2 の Test 4）と、それらの組み合わせ条件を選択し、合計 49 データを得た。

熱変位データの条件の組み合わせと取得したデータ数を表 4.1 に示す。表 4.1 は、行方向、列方向にそれぞれ表 3.2 の測定条件を示している。行方向と列方向の交差した箇所に、行方向と列方向の組み合わせ条件のデータ数を「データ数 / 台数」で示した。組み合わせ条件とは、環境温度を変化させながらクーラントを吐出する、主軸運転しながら各軸を稼働するなど、2 つの条件を同時に実施した測定条件である。例えば、表中左下の「4 / 3」の部分は、環境温度変化条件で機械周辺の温度を変化させ、クーラントを軽切削条件で吐出した条件の熱変位データが、3 台の機械について 4 データあるということを示す。なお、行方向と列方向で同じ条件の箇所は、組み合わせ条件ではなく単一の測定条件であることを示す。

収集した熱変位データを用いて、深層学習により熱変位推定モデルを学習する。概要を図 4.2 に示す。学習方法のおおまかな流れは 3.2 節及び 3.4.2 項に述べたものと同様であるため詳細は記載しない。熱変位推定モデル中には「dropout」部を設け、学習時・推論時どちらもドロップアウトを適用した。熱変位推定モデルの入力データは、12 個の温度センサの 30 分間（サンプルレート：1 分）の温度データである。教師データは、温度データの最終

時刻に対応する 5 つの主軸-タレット間の相対変位データである。熱変位推定モデルの学習には、3 台のターニングセンタの 41 個の熱変位データを使用し、別の 3 台の機械の 8 つのデータを評価用に使用した。

学習した熱変位推定モデルを用いて、熱変位の推定結果と推定分布を計算した結果を図 4.3 に示す。青色の線が機械座標系 X 軸方向の変位測定結果、太い赤色の線が変位推定結果、2 本の細い赤色の線の間が、推定分布 ( $\pm 2\sigma$ ) である。ここで  $\sigma$  とは、式 (4.8) の  $\text{Variance}(\mathbf{y}^*)$  の平方根 (標準偏差) を、各時刻において計算したものである。また、図の右軸に対して、推定分布量 (推定分布 ( $\pm\sigma$ ) の幅、つまり  $2\sigma$ ) を濃赤線で示した。また、緑色の分布は、式 (4.7) における平均を実施する前の各試行の推定結果を分布として表したものである。図 4.3 (a) と (b) は、学習に使用しなかった評価データであり、(c) と (d) は、学習データとして使用したデータの結果である。図 4.3 (a) と (c) は、時刻 0-9 hr において機械周辺の環境温度を  $8\text{ }^{\circ}\text{C}$  変化させた測定条件 (表 3.2 の Test 4)、図 4.3 (b) と (d) は、時刻 0-8 hr において主軸を  $4,000\text{ min}^{-1}$  で運転した測定条件 (表 3.2 の Test 2) の結果である。また、学習データと評価データは、同じ測定条件の結果であるが、異なる機械のものである。

学習データと評価データの推定精度や推定分布にほとんど差は認められないため、熱変位推定モデルは、学習に用いていない評価用データに対しても、十分な推定精度を示していると言える。環境温度変化条件である (a) と (c) の比較では、推定誤差や推定分布に大きな差は認められない。主軸運転条件である (b) と (d) の比較では、主軸運転中に対応する測定開始時点から 8 時間付近までの間について、学習データを示す (d) で、推定誤差に相当する青色の線と赤色の線の最大差が  $0.01\text{ mm}$  程度、推定分布に相当する赤色の細線間の最大幅が  $0.02\text{ mm}$  程度であるのに対し、評価データを示す (b) では最大推定誤差が  $0.02\text{ mm}$  程度、推定分布の最大幅が  $0.03\text{ mm}$  程度と大きい。さらに環境温度変化条件や、主軸停止時 (8 hr 以降) と比較しても推定誤差、推定分布ともに大きい傾向であるといえる。これは、例えば主軸軸受の組み込み予圧などの個体差によって、主軸運転時の発熱量や主軸伸びにばらつきがあり、主軸運転時の熱変位量の推定の信頼性が他の条件と比較して低いことを示していると考えられる。

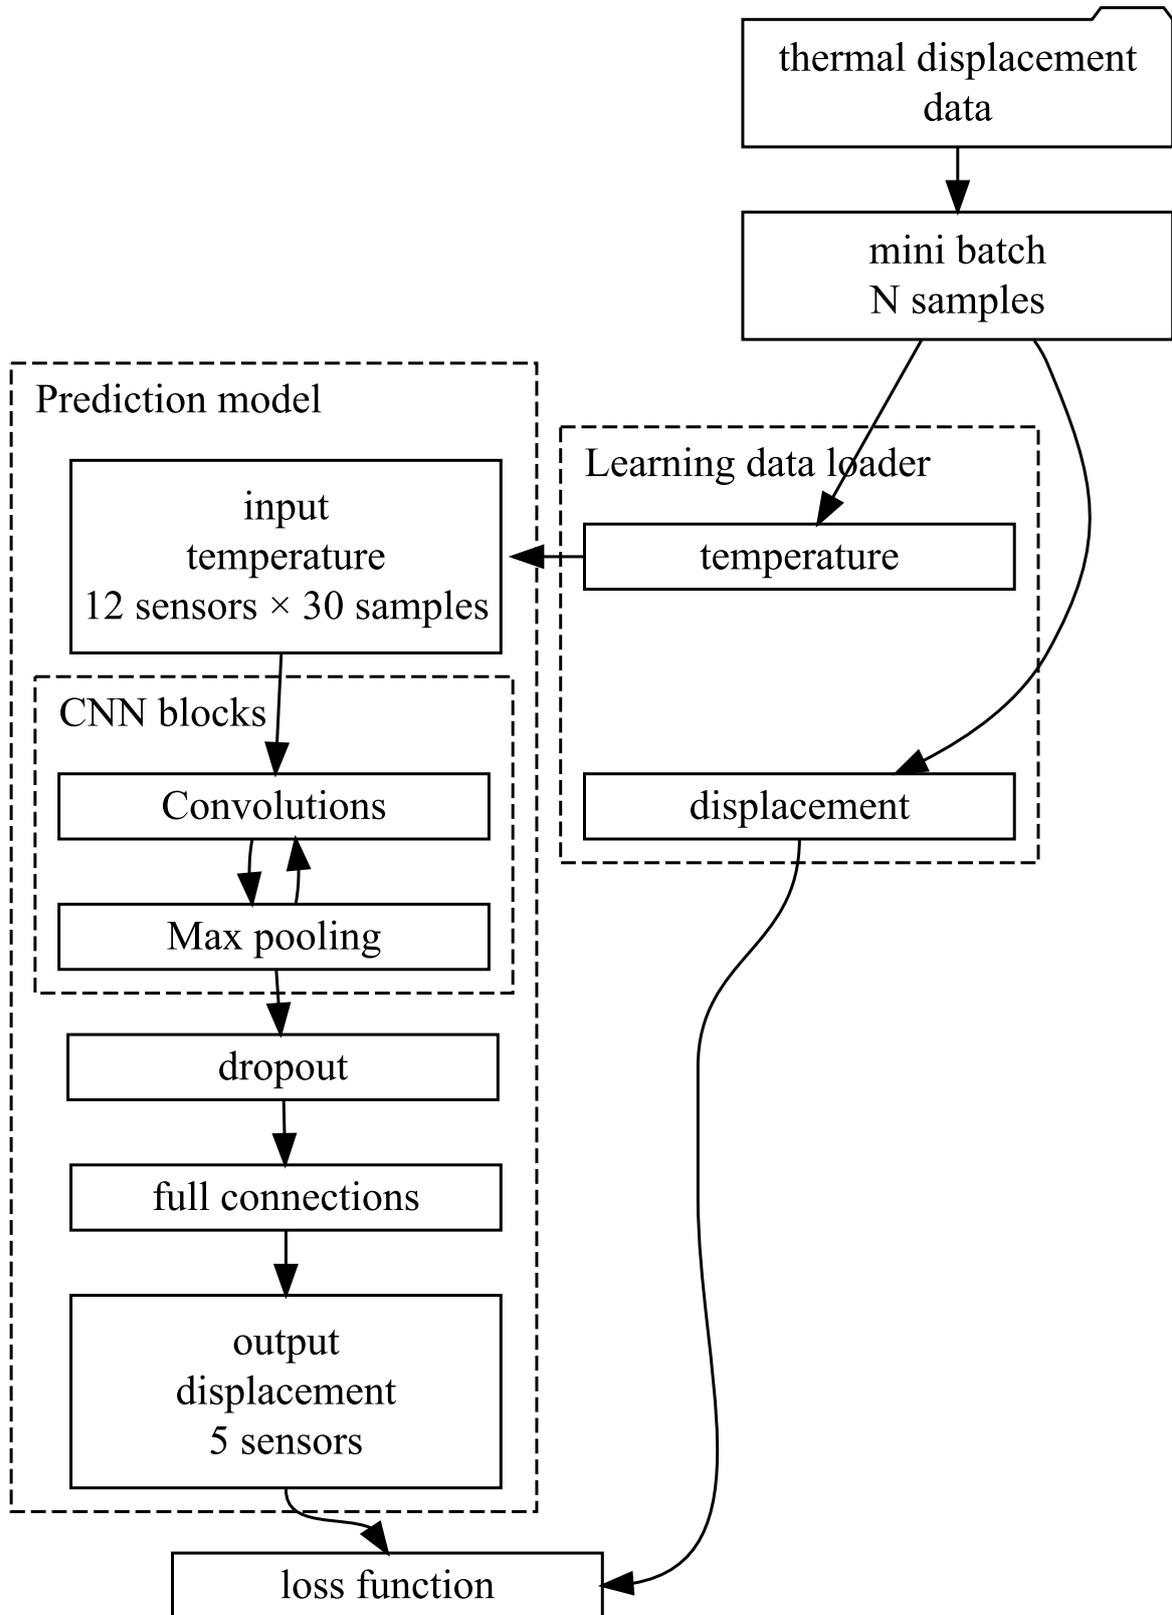


図 4.2: Structure of CNN and flow chart of model learning

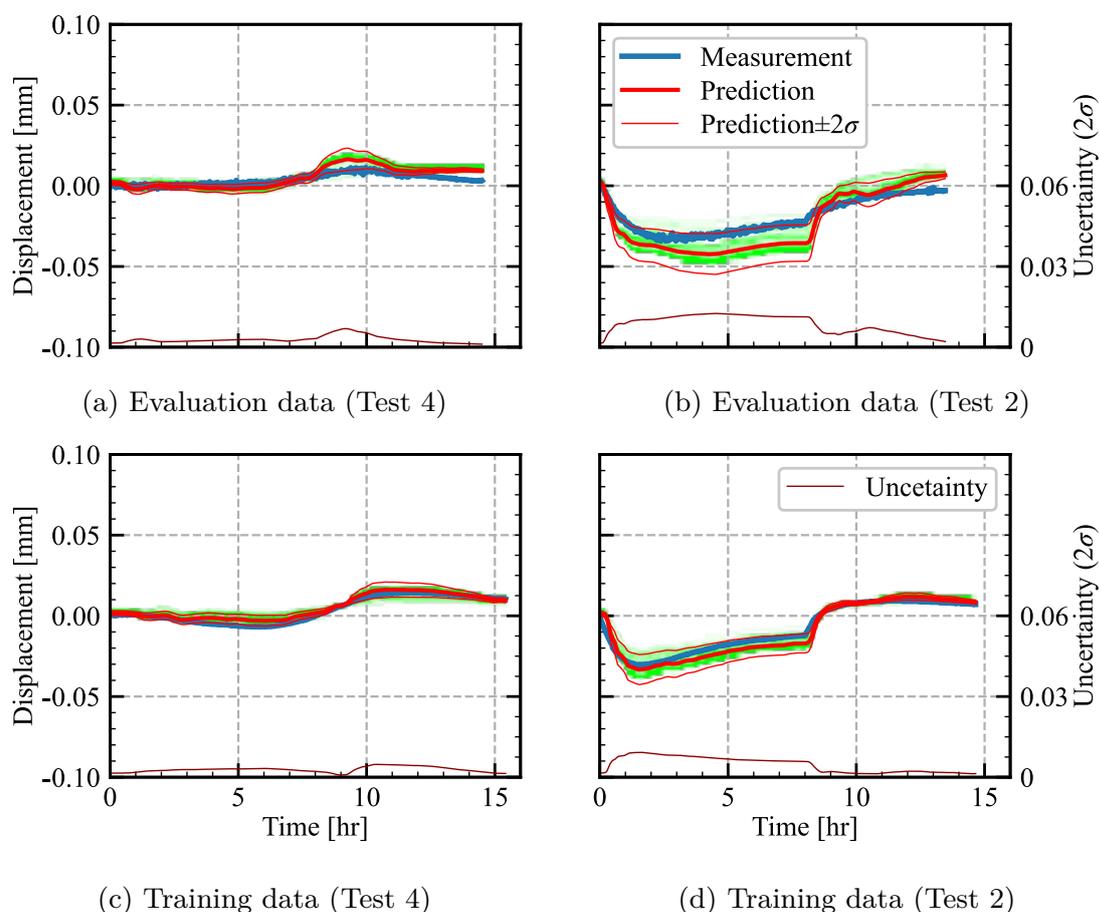


図 4.3: Prediction results of displacement in the X-direction (Test 4: the environmental temperature was changed by 8 °C from 0 hr to 9 hr. Test 2: the spindle rotated in 4,000 min<sup>-1</sup> from 0 hr to 8 hr)

### 4.3.2 温度センサの故障をシミュレーションした信号を用いた場合の信頼性の評価

#### (1) 故障をシミュレーションした温度センサの信号

入力データである温度センサの値に故障などに起因する意図しない変動が加わった場合に、4.2 節で示した Bayesian dropout を用いて求めた推定分布にどのような影響が出るのかを示すことを目的として、温度センサの故障信号をシミュレーションし、入力データとして学習済みの熱変位推定モデルに与えた。温度センサの故障シミュレーション状態を表 4.2 に示す。工作機械に取り付ける温度センサの故障形態としては、センサ素子そのものの故障

表 4.2: Simulated sensor failure modes

Failure cause	Value
Mode 1: Resistive sensor contact failure	Random switch between NV <sup>*1</sup> / OR <sup>*2</sup>
Mode 2: Voltage sensor disconnection	Always 0
Mode 3: Resistive sensor disconnection	Always OR
Mode 4: Voltage sensor contact failure	Random switch between NV / 0

\*1 NV: Normal value

\*2 OR: Over range

よりも、移動体に取り付けた温度センサのケーブルやコネクタなどが、工作機械の稼働による振動や加工による振動などで接触不良を起こしたり、断線を起こしたりする頻度が高いと考えられる。そこで、温度センサの故障形態として、接触不良と断線の2種を考える。また、温度センサの種類として、抵抗出力方式および電圧出力方式の2種の温度センサについて考え、合計4種の故障モードとした。

抵抗出力式温度センサ（表 4.2 の Mode 1 および Mode 3）の異常値は、 $-128\text{ }^{\circ}\text{C}$  とした。抵抗出力式温度センサの断線や接触不良により、センサとセンサ入力回路間の端子が解放されると、入力回路側から見れば温度センサの出力抵抗が極端に大きくなったと解釈される。今回検討した抵抗出力式温度センサは NTC (negative thermal coefficient) サーミスタであるため、センサ素子の温度上昇によって抵抗値が減少する。そのため入力回路側から見てセンサの出力抵抗が極端に大きくなった状態では、極端にセンサ素子の温度が低下したと解釈され、入力回路を構成する AD コンバータの下限值が取得される。今回検討した AD コンバータの下限値は  $-128\text{ }^{\circ}\text{C}$  である。したがって、抵抗出力式温度センサの異常値は、 $-128\text{ }^{\circ}\text{C}$  とした。次に、電圧出力式温度センサ（表 4.2 の Mode 2 および Mode 4）の異常値は、 $0\text{ }^{\circ}\text{C}$  とした。電圧出力式温度センサは、センサ素子近傍にプリアンプなどが配置され、センサに電源を接続すれば出力端子から温度の測定値に相当する電圧が出力される。電圧の出力が断線や接触不良によりセンサとセンサ入力回路間で端子が解放されると、入力回路から見ればセンサによって発生していた電位差がなくなり、 $0\text{ V}$  と解釈される。また、センサに接続している電源ラインに断線や接触不良が発生した場合も、同様に電位差がなくなり  $0\text{ V}$  と解釈される。今回検討した電圧出力式温度センサは、 $0\text{ V}$  に相当する温度測定値が  $0\text{ }^{\circ}\text{C}$  であるため、異常値は、 $0\text{ }^{\circ}\text{C}$  とした。

熱変位推定モデルに入力する温度センサ信号のうち、1つに表 4.2 の故障が発生したと想

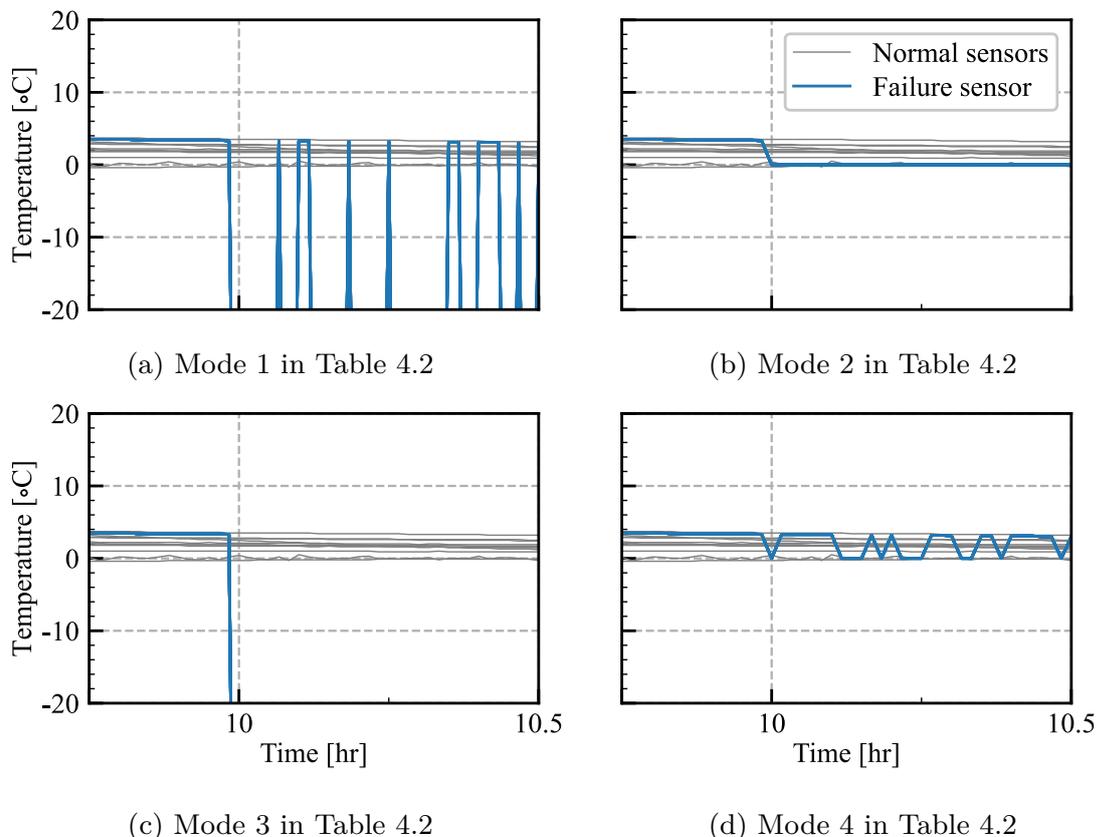


図 4.4: Simulated signals under sensor failure

定して、故障シミュレーション信号を作成した。故障シミュレーション信号の例を図 4.4 に示す。図は、それぞれ、(a) が抵抗出力式温度センサの接触不良（表 4.2 の Mode 1）、(b) が電圧出力式温度センサの断線（表 4.2 の Mode 2）、(c) が抵抗出力式温度センサの断線（表 4.2 の Mode 3）、(d) が電圧出力式温度センサの接触不良（表 4.2 の Mode 4）を想定した結果を示す。図には合計 12 本の線があり、3.3 節に示したように、機械各部に取り付けた 12 個の温度センサの測定値を表す。このうち故障したセンサに相当するセンサの信号が青色、他のセンサの信号を灰色で示す。図の横軸は信号全体のうち 10 時間付近を拡大しており、10 時間を境界として前後で正常状態と故障状態を切り替えた結果である。

抵抗出力式温度センサの接触不良状態を示す図 4.4 (a) を例に、具体的なシミュレーション信号について説明する。図は、10 時間以降の時間帯で、正常値と、異常値である  $-128^{\circ}\text{C}$  がランダムに切り替わる信号となっている。正常値と異常値の割合は 1:1 とし、時間方向に 50 % の割合でランダムに異常値が含まれるようにした。図 4.4 に示した故障信号はあくまで例で、実際のシミュレーションでは、故障後の信号はこの条件の下で、ランダムに生成

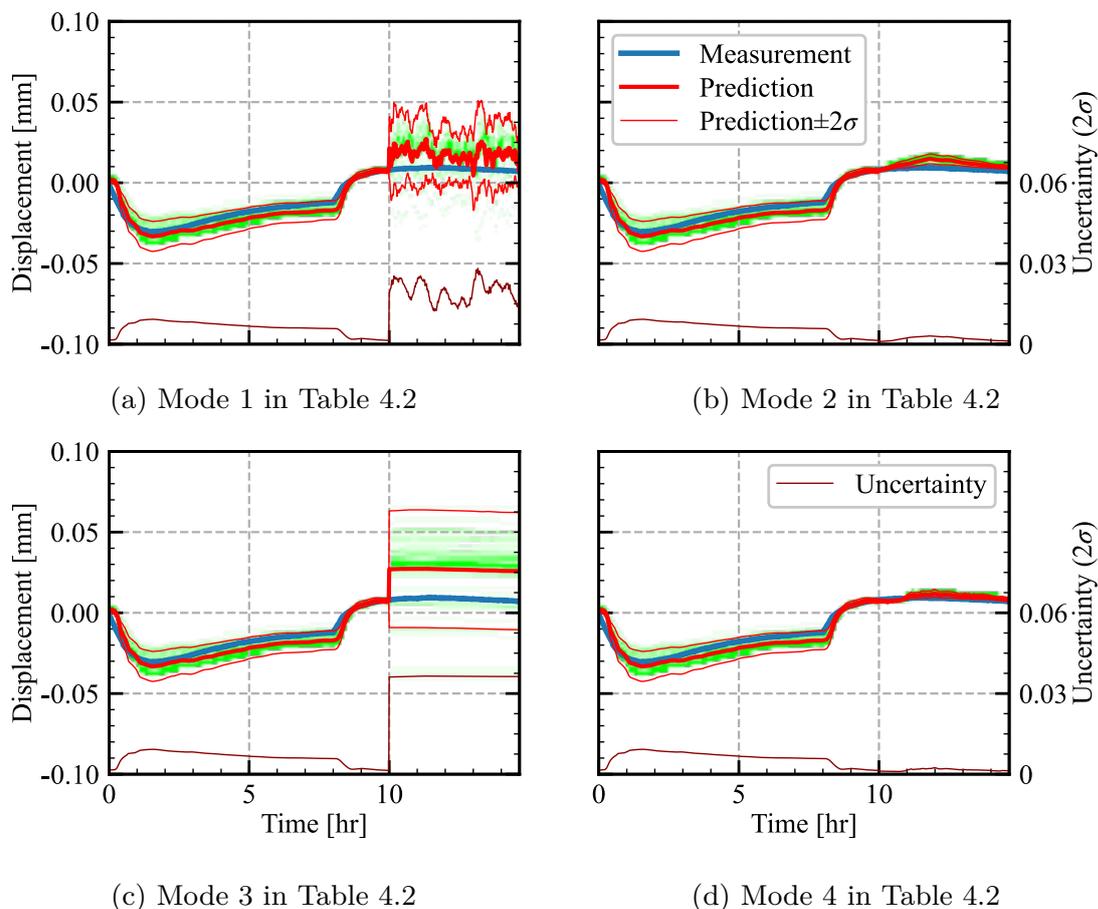


図 4.5: Predicted and measured displacement profiles under simulated sensor failures with the  $2\sigma$  profile simulated by the Bayesian dropout. Sensors failures, Modes 1 to 4 in Table 4.2, occur at 10 hr.

する。

## (2) 故障シミュレーション信号による熱変位推定分布の変動

生成した温度センサの故障シミュレーション信号を、学習済みの変位推定モデルに入力し、変位の推定値と推定分布の計算をした結果のうち、機械座標系 X 軸方向の結果を図 4.5 に示す。使用した熱変位データは、主軸運転条件（表 3.2 の Test 2）のものである。想定した温度センサの故障状態は、図 4.4 で示したものである。先に述べたとおり、測定開始から 10 時間後を境界として、正常状態と異常状態を切り替えた信号である。図 4.5 は、青色の線が測定結果、太い赤色の線が変位の推定結果、2 本の細い赤色の線の間隔が推定分布（推定

結果に  $\pm 2\sigma$  を足したもの、 $\sigma$  は式 (4.8) の  $\text{Variance}(\mathbf{y}^*)$  の平方根) を示す。図の右軸として、推定分布量 ( $2\sigma$ ) を濃赤線で示した。また、緑色の分布は、式 (4.7) における平均を実施する前の各試行の推定結果を分布として表したものである。

(a) Mode 1 と (c) Mode 3 の結果では、正常状態と異常状態の境界である 10 時間の前後で変位推定結果が測定値と乖離し、同時に推定分布が大きくなっている。また、推定結果の時間変動も大きい。一方、(b) Mode 2 と (d) Mode 4 の結果では、正常状態と異常状態の変化による推定結果と推定分布の変化はほとんど認められない。Mode 1 と Mode 3 の温度センサ故障シミュレーション信号は、それぞれ、抵抗出力式温度センサの接触不良状態 (Mode 1) と抵抗出力式温度センサの断線状態 (Mode 3) を想定している。このふたつの故障状態は、正常値と異常値の差が相対的に大きいため、温度センサの故障シミュレーションによる入力データの変動が、熱変位推定モデルからの出力に影響する度合いが大きかったと考えられる。さらに、接触不良状態は、温度センサの正常値と異常値がランダムに入れ替わるため、熱変位推定モデルに入力される温度信号の時間あたりの変動が大きく、この変動が推定値の変動と推定分布の増加に影響していると考えられる。推定結果と推定分布にほとんど変化が認められなかった Mode 2 と Mode 4 の結果は、それぞれ電圧出力式温度センサの、断線状態 (Mode 2) と接触不良状態 (Mode 4) を想定した結果である。このふたつの故障状態は、抵抗出力式温度センサの故障状態と比較すると、正常値と異常値の差が小さいため、推定結果に与える影響も小さかったと考えられる。

このように、「Bayesian dropout」の手法を用いて、式 (4.8) により評価した推定分布を見れば、温度センサの故障により熱変位推定の信頼性が低下しているのを判断することができる。また、推定分布に閾値を設定すれば、熱変位推定の信頼性低下を検出することができる。

### 4.3.3 熱変位推定分布に基づく熱変位補正量の修正

4.3.2 項で述べたとおり、熱変位推定モデルによって計算した推定分布が大きい状況では、推定の信頼性が低下していると考えられる。工作機械に対して熱変位補正制御を実施する場合、信頼性の低い推定結果をそのまま使用すると加工対象物に精度不良が発生したり、過大な補正量によって工作機械が意図せず動作して故障の原因になったりすることが考えられる。そこで、推定分布に応じて熱変位制御の補正量を修正し、過大な補正量が工作機械へ入力されない方法を提案する。本来、温度センサが故障して 4.2 節に示した方法でそれがわかった場合は、すぐに温度センサを交換して復旧すべきである。しかし、稼働中の工作機械を温度センサが故障した瞬間に停止して温度センサを交換することは困難である場合が多

い。また、温度センサの交換までの期間中、工作機械を使用することができなくなってしまうと、生産活動に重大な影響を与える。工作機械のメンテナンスは、あらかじめ計画され、生産活動への影響が出ないように生産計画を調整して実施されることが一般的なので、次のメンテナンスのタイミングまで工作機械を使用し続けられることが望ましい。つまり、温度センサの交換を実施するまでの期間も、最低限の性能低下で工作機械を継続して使用できることは、熱変位補正機能に求められる要件として重要なものといえる。

図 4.6 に、熱変位推定モデルで計算した推定分布に応じて工作機械の熱変位補正制御の補正量を修正するアルゴリズムの構成を示す。熱変位推定モデルで推定した変位推定量を、機械側の CNC 装置へ与える前に、計算した推定分布とともに移動平均フィルタへ入力する。移動平均フィルタは、推定分布に応じて内部パラメータを変更する。推定分布が大きい、すなわち信頼性が低い場合は移動平均フィルタの平均点数を増加させ、推定分布が小さい、すなわち信頼性が高い場合は移動平均フィルタの平均点数を減少させる。これによって、信頼性が高い場合は推定した変位がほとんどそのまま使用され、信頼性が低い場合は長期間の推定変位から補正量を計算し、急激な変動の発生を防止することができる。

図 4.7 に、推定分布に基づいて熱変位推定量の調整を実施したシミュレーション結果を示す。使用した熱変位データは、図 4.5 と同様に主軸運転条件（表 3.2 の Test 2）のもので、想定した温度センサの故障状態は、それぞれ、(a) が抵抗出力式温度センサの接触不良（表 4.2 の Mode 1）、(b) が電圧出力式温度センサの断線（表 4.2 の Mode 2）、(c) が抵抗出力式温度センサの断線（表 4.2 の Mode 3）、(d) が電圧出力式温度センサの接触不良（表 4.2 の Mode 4）である。すでに述べたとおり、測定開始から 10 時間後を境界として、正常状態と異常状態を切り替えた信号とした。図は、青色の線が測定結果、太い赤色の線が変位の推定結果、水色の線が推定分布に基づいて修正した変位の推定結果、右軸として示す濃い赤色の線が推定分布の幅（ $\pm 2\sigma$ ）である。

4.3.2 項で述べたとおり、(a) Mode 1 と (c) Mode 3 の結果では、正常状態と異常状態の境界である 10 時間の前後で変位推定結果が測定値と乖離し、推定分布が大きくなっている。しかし、移動平均フィルタによる修正結果は、修正しない推定結果と比較して時間変動が小さく、測定値との差も小さくなっていることがわかる。一方、(b) Mode 2 と (d) Mode 4 の結果では、センサ故障シミュレーション信号の入力による推定分布の変化は小さく、正常状態と異常状態の境界である 10 時間の前後で推定分布にほとんど差が認められない。したがって移動平均フィルタによる修正結果と、修正しない推定結果の差は小さい。この状態で熱変位制御を実施すれば、推定結果の精度がそのまま維持される。

このように、推定分布に基づいて熱変位制御に用いる補正量を修正することで、信頼性が

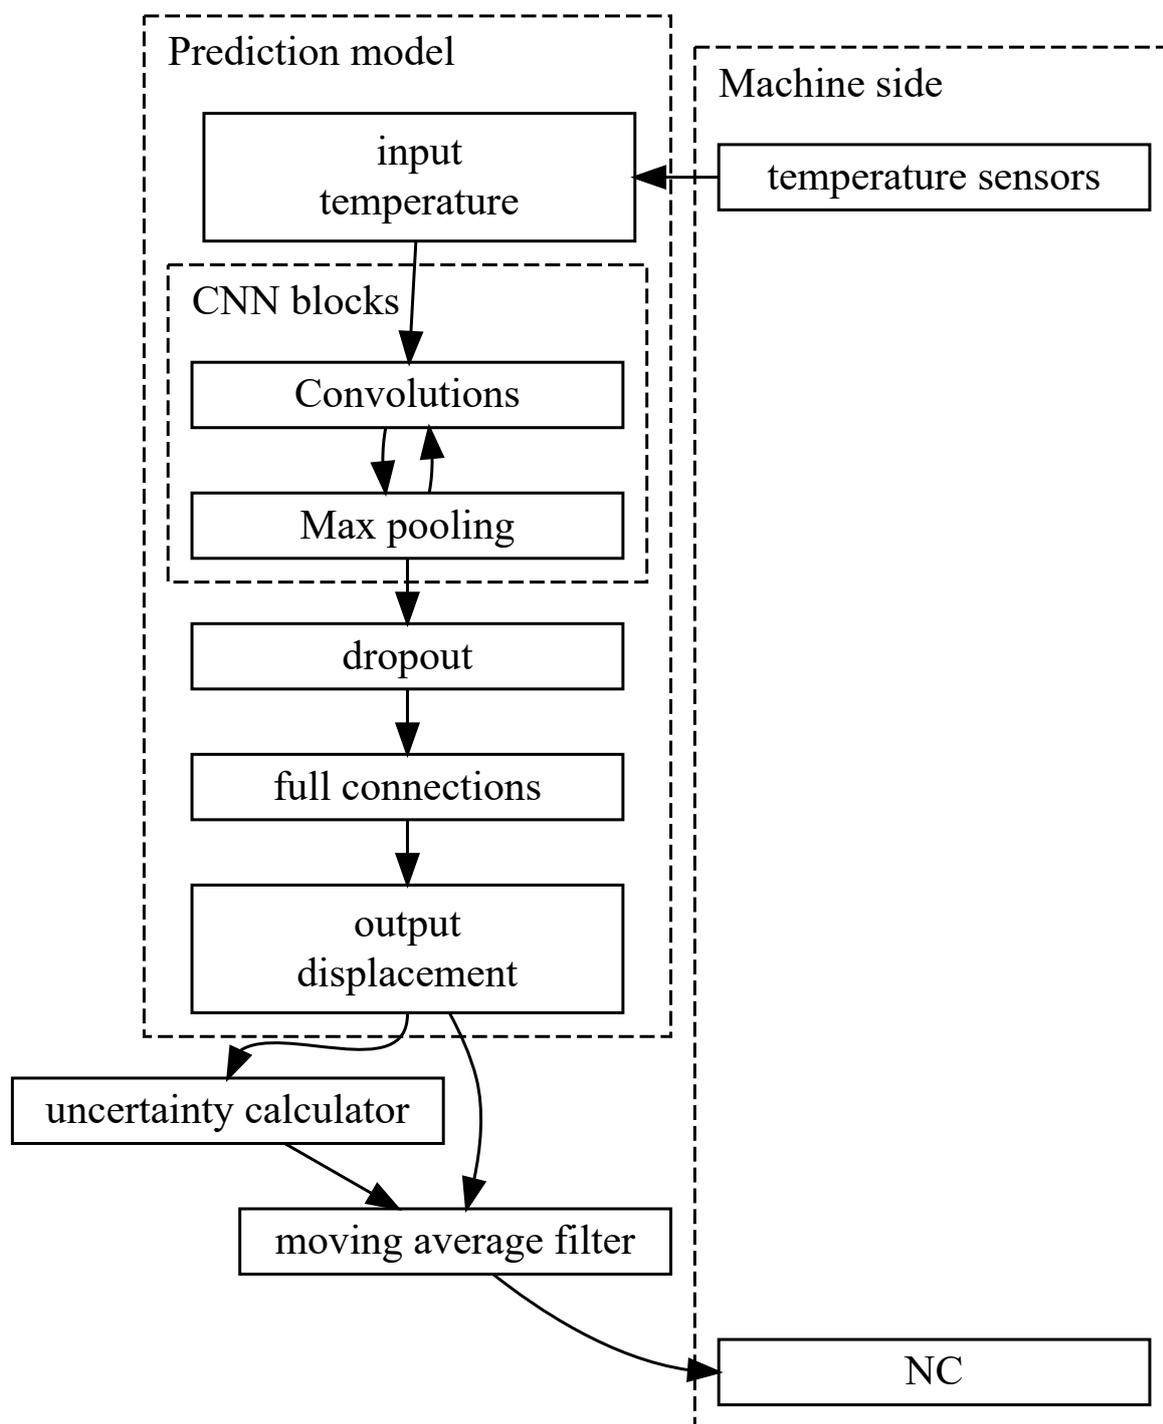


図 4.6: Structure of CNN to modify the compensation commands to reduce the influence of sensor failure

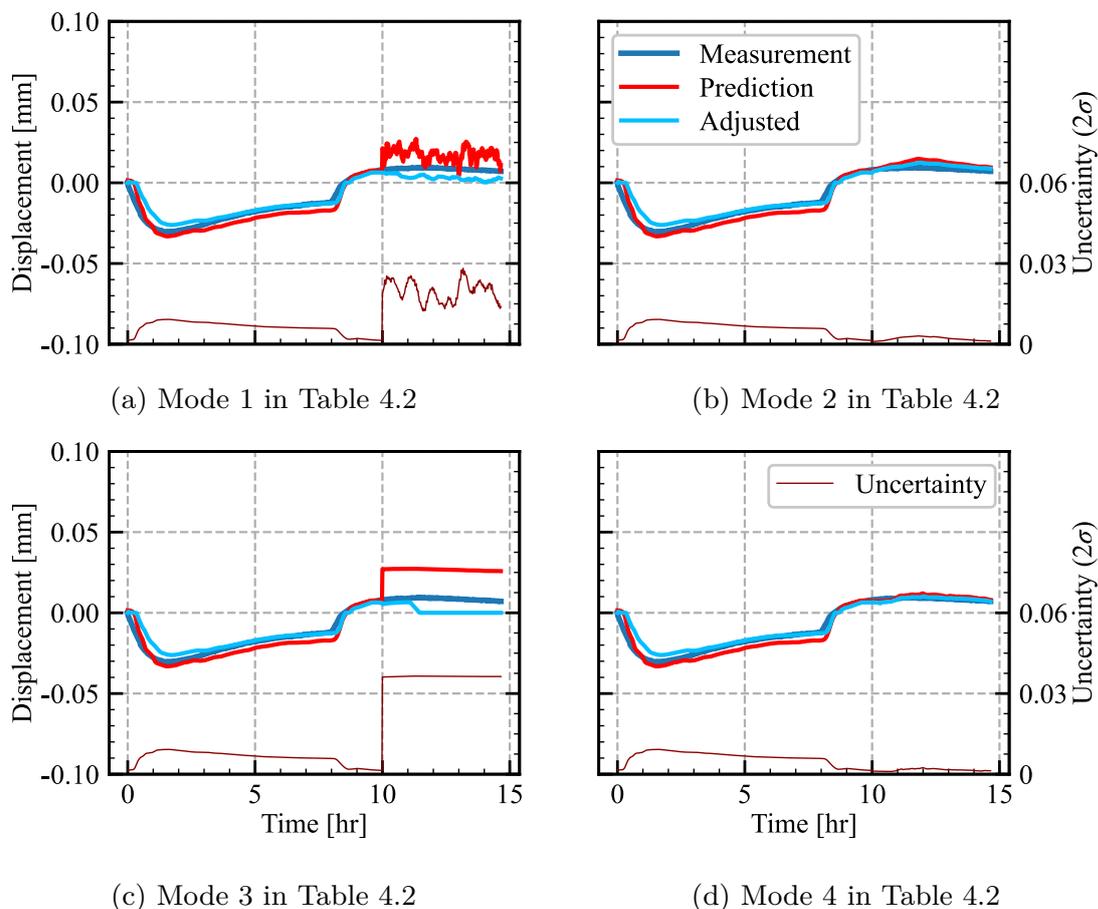


図 4.7: Predicted and measured displacement profiles under simulated sensor failures with the modification of the compensation commands to reduce the influence of sensor failure. Sensors failures, Modes 1 to 4 in Table 4.2, occur at 10 hr.

低い場合には本来入力したい補正量から乖離した補正量が適用されることを防止し、信頼性が高い場合には推定した補正量をそのまま使用し、高精度な補正制御を実現することができる。

#### 4.4 加工試験による熱変位補正機能の検証

学習した熱変位推定モデルの性能と、推定分布に基づく補正量の修正方法を実験で確かめるために、学習に用いた機械と同一機種ターニングセンタに熱変位制御機能を搭載し、切削試験を実施した。熱変位制御機能の基本構成は、図 4.6 に示したもので、ターニングセンタの Human-Machine interface (HMI) 用 PC に搭載した。切削試験は、ターニングセンタ

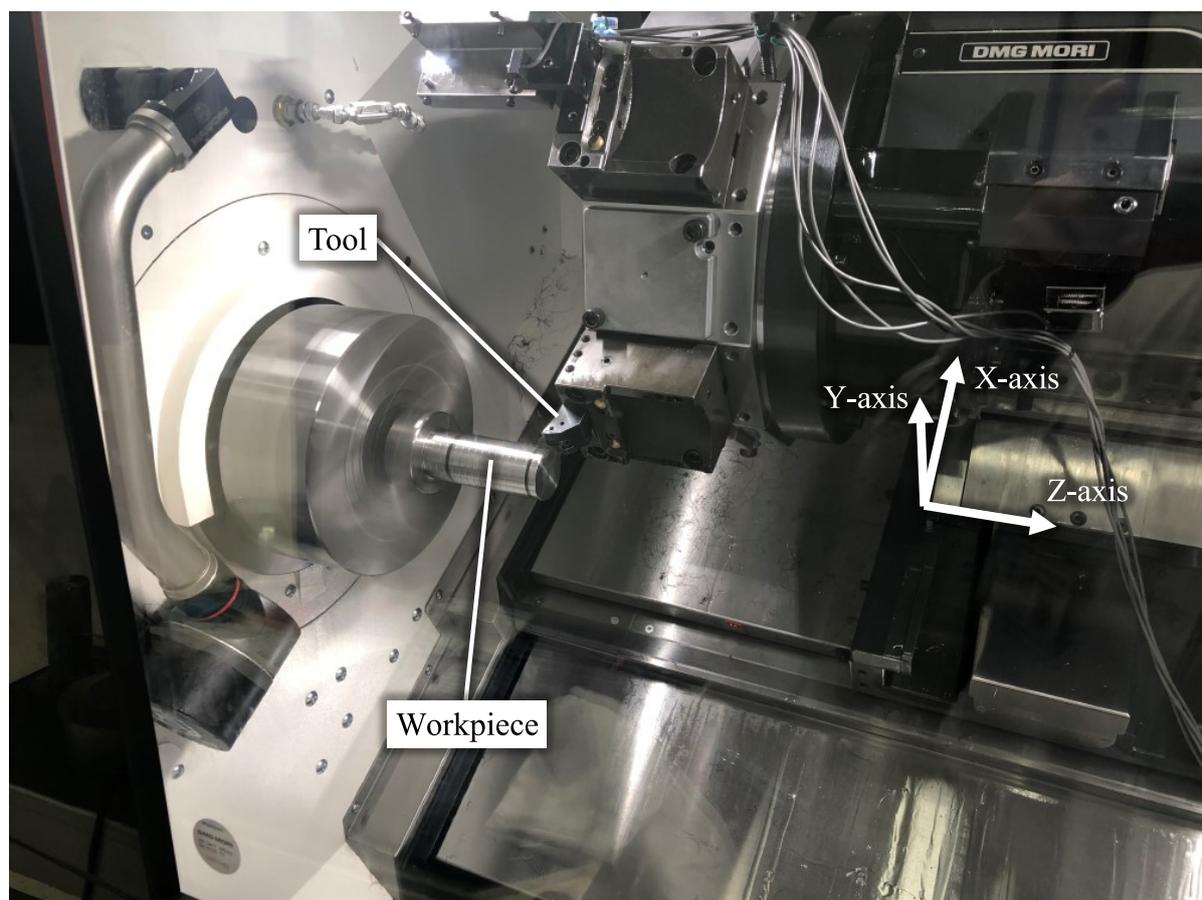


図 4.8: Machined workpiece and machine axes direction on a turning center

を表 3.2 の主軸稼働条件 (Test 2) および軸稼働条件 (Test 3) を組み合わせた条件で動作させ、単一の加工対象物に対して 6 時間で 10 回、Z 軸方向の旋削位置を変更しながら外径面の旋削加工を行った。すなわち、主軸を回転速度  $4,000 \text{ min}^{-1}$  で回転させながら (Test 2)、X 軸及び Z 軸を送り速度  $30,000 \text{ mm/min}$  で往復運動させる (Test 3) 運転を、6 時間実施する。そのなかで約 30 分に 1 回、計 10 回加工対象物の旋削加工を行う。図 4.8 に加工中の加工対象物と、ターニングセンタの各軸の方向を示す。外径面の旋削工具は、機械座標系の X 軸方向に沿って取り付けられているので、外径面の旋削加工結果の測定による熱変位測定は、3.3.2 項で述べた非接触変位センサによる X 軸方向の熱変位測定結果に相当する。

図 4.9 に、切削試験結果を示す。青色の線は熱変位補正制御をしない場合の加工対象物の外径の変化を、オレンジ色の線は熱変位補正制御をした場合の外径の変化を示す。なお、熱変位補正制御をしない場合の結果は、補正制御をした場合の外径の実測値と、推定変位量から計算によって求めたものであり、実際の加工試験は行わなかった。補正制御をしない場合

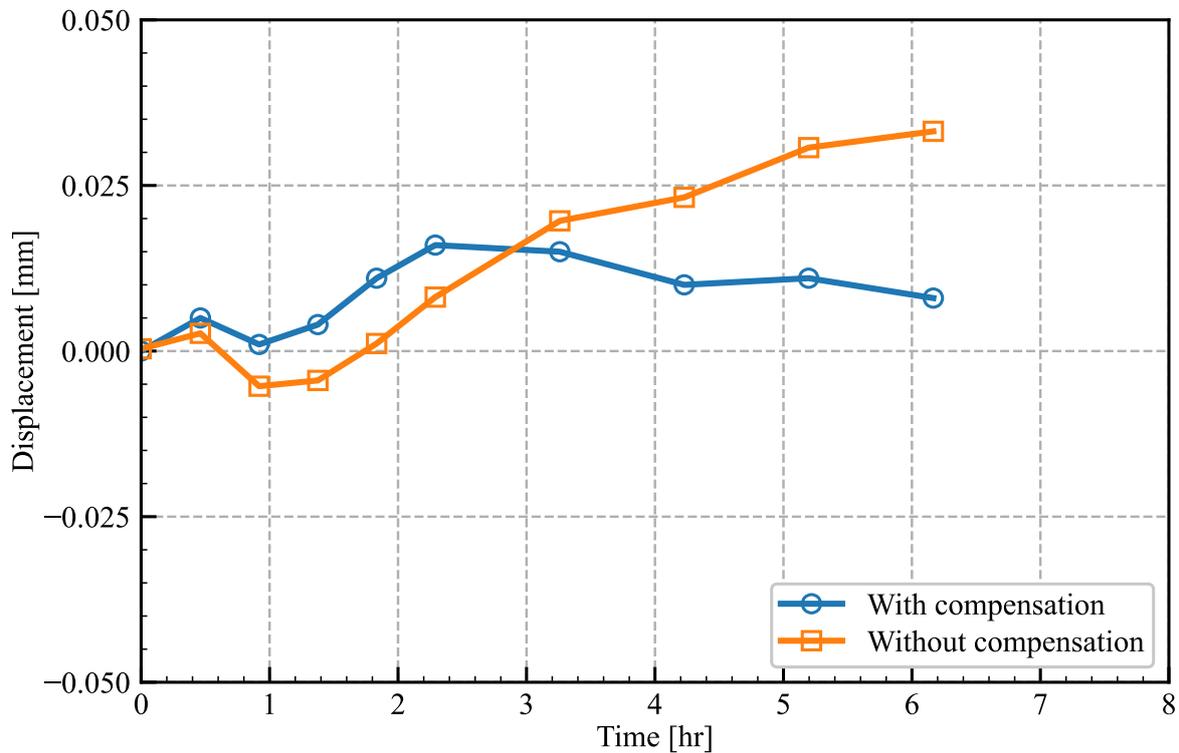


図 4.9: Measured errors in the diameter of the machined workpiece with and without thermal displacement control system on a turning center

の外径変化（推定値）が 0.031 mm であったのに対して、補正制御をした場合の外径変化は 0.018 mm であった。

切削試験を実施した機械の熱変位データは、学習データに含まれていないが、補正制御によって切削試験結果の熱変位が抑制できており、学習した熱変位推定モデルと補正量の修正アルゴリズムは、学習に用いていないデータに対しても、十分な推定精度を示していると言える。

この加工試験では、温度センサの故障は生じていない。したがって、図 4.5 で示したような温度センサの故障による熱変位推定値の信頼性低下や、図 4.7 で示したようなセンサが故障しても補正が実施できることを実証することは、本実験の目的ではない。第 3 章で構築した深層学習による熱変位推定モデルを用いた補正によって、実際に加工対象物の寸法精度が向上することを、実験で示すことができた。また、図 4.6 に示した補正システムの構造には、深層学習による熱変位推定とともに、本章で示した、Bayesian dropout を用いた信頼性の評価や、移動平均フィルタを使ってセンサが故障した時の影響を小さくする要素が加えられ

ているが、問題なく加工精度を向上できることを確認できた。

## 4.5 結言

本章では、深層学習による工作機械の熱変位推定モデルの学習について、推定分布の計算方法を提案し、実際の熱変位データによるケーススタディで推定分布に基づく熱変位補正制御量の推定アルゴリズムの効果を実験で確かめた。

本章で得られた主な結論は、以下のとおりである。

1. 工作機械の熱変位推定や補正制御において熱変位推定モデルや推定値の信頼性は非常に重要である。熱変位推定モデルや推定値の信頼性が低いと、本来適用されるべき補正量が適用されず、加工対象物の品質低下の原因になるばかりでなく、過大な補正量が適用されて機械の故障の原因になることも考えられる。しかし、深層学習による熱変位推定で、熱変位推定モデルや推定値の信頼性を評価することは難しかった。本章では、「Bayesian dropout」を用いて熱変位推定モデルや推定値の信頼性を推定分布として計算する方法を提案した。
2. ケーススタディとして、6 台の同一機種ターニングセンタの、クーラント温度上昇条件、主軸運転条件、軸稼働条件、環境温度変化条件の熱変位データを 49 データ収集し、3 台の機械の 41 データからなる学習データで CNN による熱変位推定モデルを学習した。学習データと、評価用の 3 台の機械の 8 つのデータで、熱変位の推定値と推定分布を計算した。学習データと評価データで、熱変位の推定精度と推定分布に大きな差はなく、熱変位推定モデルは、学習に用いていない評価用データに対しても、十分な推定精度を示した。
3. 熱変位推定モデルや推定値の信頼性を低下させる条件として、入力データである温度センサの故障を想定したシミュレーションを実施した。温度センサの種類として抵抗出力式と電圧出力式について、断線と接触不良を仮定した。  
学習した熱変位推定モデルへ、温度センサの故障シミュレーション信号を入力し、推定精度と推定分布の変化を調べた。故障によって熱変位推定モデルへ入力される値の変化が相対的に大きくなる抵抗式温度センサの故障条件では、熱変位の推定誤差が大きくなり、推定分布が大きくなった。さらに、抵抗式温度センサの接触不良を考慮した条件では、熱変位の推定値と推定分布の時間変動も大きくなる結果であった。
4. 計算した推定分布が大きい場合に、工作機械の熱変位制御に使用する補正量が大きく変動したり、過大な補正量が入力されることがないようにするために、熱変位推定

モデルと工作機械の CNC 装置の間に移動平均フィルタを追加して補正量を修正する手法を提案した。移動平均フィルタは、推定分布の計算結果に応じて平均長を変更した。推定分布が大きい場合は平均長を長くにとって大きな変動の影響が少なくなるようにし、推定分布が小さい場合は平均長を小さくにとって推定値をそのまま採用するようにした。温度センサの故障シミュレーション信号を入力した場合、熱変位推定結果への影響が大きかった抵抗出力式温度センサの故障条件の場合には、補正量の修正が強く働いて異常な補正值が適用されることを防ぎ、熱変位推定結果への影響が小さかった電圧出力式温度センサの故障条件の場合には、補正量はほとんど修正されずに高精度な補正値を維持することができた。

5. 提案した熱変位推定モデルによる推定分布の計算機能と、推定分布の計算結果を使用した補正量の修正アルゴリズムを、熱変位推定モデルの学習用に熱変位データを収集したターニングセンタと同一機種 of 機械に搭載し、切削試験で効果を確認した。主軸運転条件と軸稼働条件を組み合わせた状態で切削試験を実施し、補正制御をしない場合の外径変化が 0.031 mm であったのに対し、提案手法で補正制御を実施した場合は 0.018 mm の外径変化であった。切削試験に使用した機械は、学習用の熱変位データを取得した機械ではないが、熱変位を抑制できる結果となり、深層学習による熱変位推定モデルは学習に用いていないデータに対しても、十分な推定精度を示した。

この切削試験では温度センサに故障は生じていないため、推定分布の計算による推定値の信頼性評価や、移動平均フィルタによる推定値修正の実証をすることが目的ではない。しかし、それらの機能を組み込んだ状態で、問題なく加工精度を向上できることを確認できた。

## 第 5 章

# 深層学習による工作機械の熱変位推定におけるセンサの故障に対するロバスト性の向上

### 5.1 緒言

第 4 章では、深層学習による熱変位推定の信頼性を評価する方法を示し、信頼性を低下させる実際的な要因として、温度センサの故障を挙げた。実際の工作機械に熱変位補正制御機能を搭載する場合、センサ故障への対処が問題となる。工作機械は 10 年以上使用されることも珍しくないため、センサ故障は想定しなければならない。センサの故障に対して熱変位の推定値が大きく変動し、その結果、補正制御機能が急激に大きな補正值で機械を動かし、加工対象物や機械に損傷を与えることは許容できない。第 4 章で提案した熱変位推定モデルや推定値の信頼性を評価し熱変位補正の補正量を修正する手法 (4.3.3 項) は、加工対象物や機械に損傷を与える可能性を小さくできるが、推定値に対して修正を実施するいわば対症療法的な方法であるため、推定値自体の変動を小さくできるわけではない。しかし、熱変位推定モデルそのものが、センサ故障という外乱に対してロバストであれば、推定値自体の変動を小さくでき、加工対象物や機械に損傷を与える可能性をより小さくできると考えられる。

深層学習による画像認識において、一部をランダムに欠落 (cutout) させた画像を使用して学習することで汎化性能が向上した例 [DT17] や、ランダムにノイズを付加したり回転・変形などを施したりした画像を使用して学習することで推論性能が向上した例 [KSH17] が報告されている。これは、情報が欠落していたり、一部が改変されていたりする状態であっ

でも、入力された情報から正しく推論ができるネットワークを学習できることを示している。画像認識における情報の改変・欠落と熱変位推定におけるセンサ故障によるノイズ発生は、どちらも入力データに外乱が入るという点で同様であると考えた。そこで、熱変位推定モデルの学習時に、温度センサ故障状態をシミュレーションしたデータを正常データに混合して学習することにより、温度センサ故障時でも変位の推定値に大きな変動の生じない熱変位推定モデルを開発することを本章の目的とする。

温度センサの故障は接触不良や断線によるものがほとんどであるため、故障した際の信号は完全にランダムではなく数種のパターンに分類できると考えた (4.3.2 項)。本章ではこれらの故障信号をシミュレーションし、深層学習の熱変位推定モデル学習時に故障のない信号と混合して用いることで、温度センサの故障に対して熱変位推定結果の変動が小さい熱変位推定モデルを実現する方法を提案する。具体的には、深層学習による熱変位推定モデルを用いたターニングセンタの熱変位推定を対象として、想定される温度センサの故障状態を考慮した深層学習を実施することで、熱変位推定モデルのロバスト性を高められることを、市販の工作機械を用いた実験で示す。

## 5.2 深層学習による熱変位推定と温度センサ故障を考慮した学習

本章で用いる熱変位推定のための深層学習ネットワークの構成およびその学習法は、第3章および第4章で述べたものと同じである。対象の工作機械は、図 3.3 に示すターニングセンタとする。

センサ故障を考慮した深層学習による熱変位推定モデルの学習は、バッチサイズを  $N \in \mathbb{N}$  としたとき、 $N$  個の温度データと変位データの組み合わせをミニバッチ [Aso15, IS15] とし、同時に与え、熱変位推定モデルを介して誤差の勾配を計算し、ネットワークパラメータを更新することを繰り返して実施する。学習の概要を図 5.1 に示す。学習の際、入力データ  $\mathbf{x}$  について、温度センサの個数  $N_S$  のうち、ランダムに選択した  $N_{\text{fail}}$  個のセンサデータを故障状態をシミュレーションしたデータに差し替え、熱変位推定モデルに入力データ  $\hat{\mathbf{x}}$  とし、与える。故障状態として、接触不良と断線を考慮する。接触不良の故障信号は、元の入力信号の特徴が完全に失われることを防ぐため、入力信号を時間方向に見て、50% に相当する信号をランダムに置き換えて生成する。断線の故障信号は、選択したセンサの信号を一定の故障想定値で置き換える。この場合、特定のミニバッチにおいて入力信号の特徴が完全に失われるが、故障状態を考慮するセンサは繰り返し学習を進めるうちに切り替わっていくた

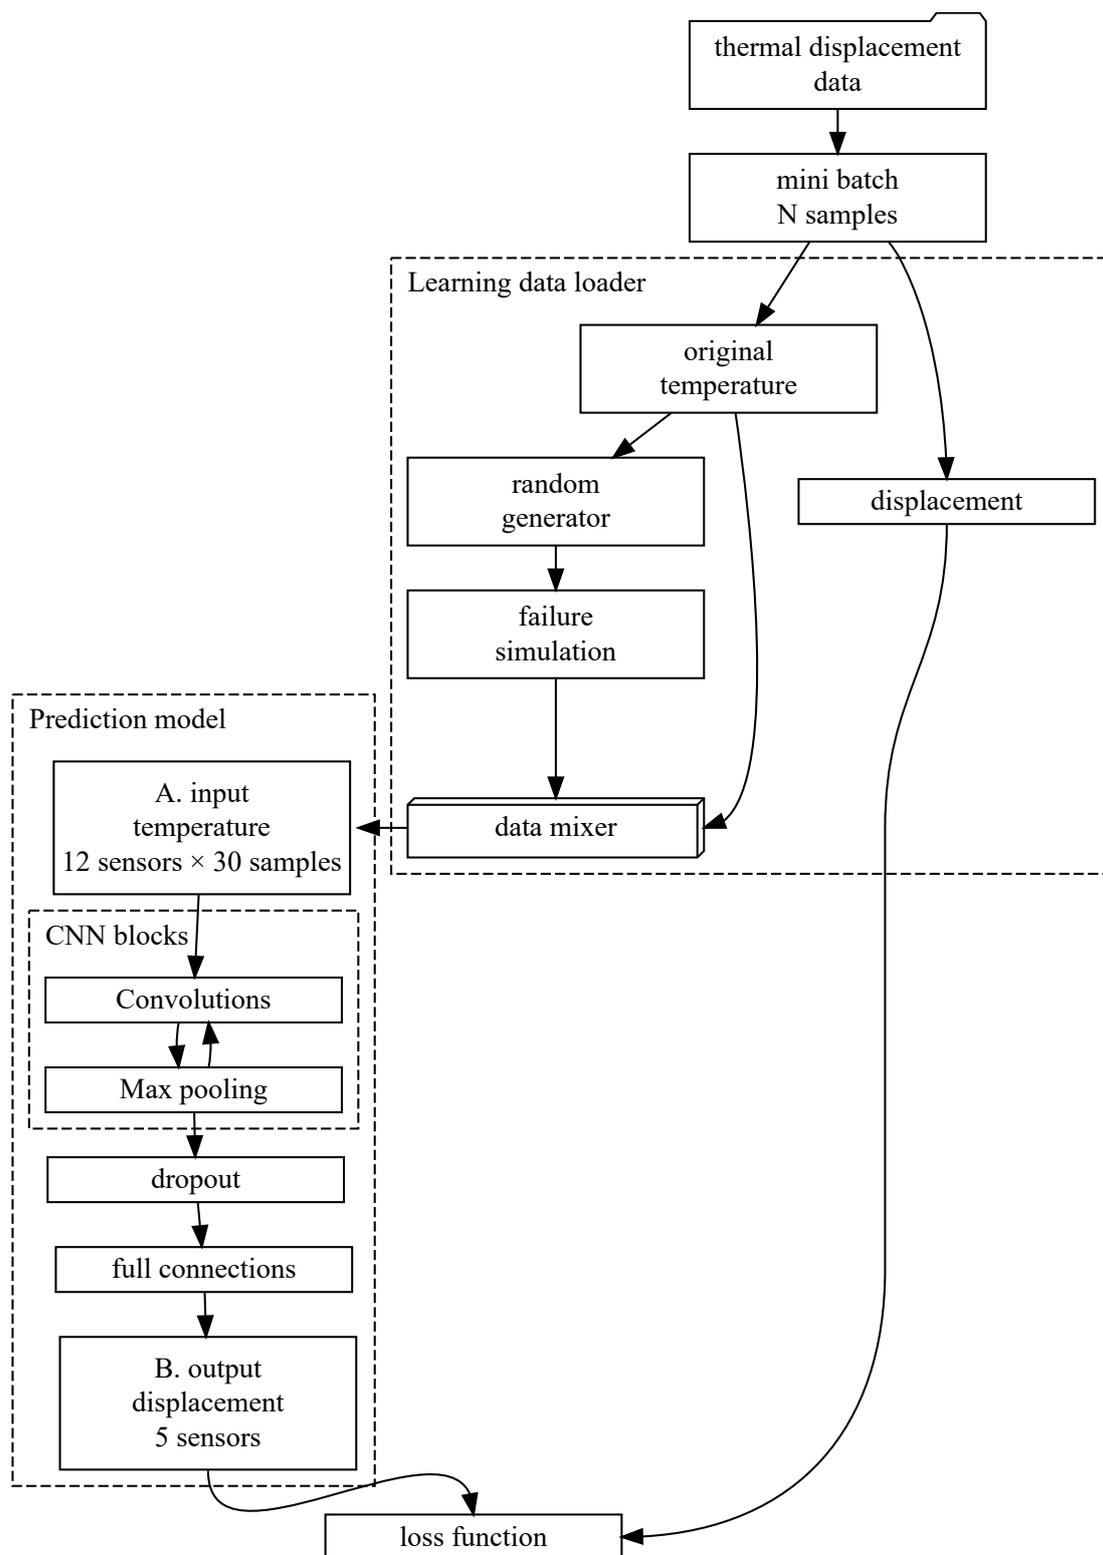


図 5.1: Structure of CNN and flow chart of model learning with simulated sensor signal profiles under sensor faults

め、結果としてセンサの入力信号がある場合も、ない場合も学習される。また、故障状態を想定する温度センサの個数と位置は、ミニバッチごとにランダムに変更し、特定のセンサの故障状態のみが学習されることを避ける。これにより温度データに故障状態が含まれる場合でも正常な変位の値が推定できるよう熱変位推定モデルを学習することができる。なお、変位データは加工せずに教師データ  $y$  として与える。結果として温度センサ故障に対して出力される値の変動が小さくなることが期待できる。

一般的な熱変位補正では、温度センサの故障を検知し、そのセンサの信号を除外するアプローチが取られることが多い。それに対し、故障したセンサからの信号を学習データに含めて学習することで、特別な故障検知のアルゴリズムなどを必要とせず、最小限の性能低下で同じ熱変位推定モデルで推論を続けることができる方法を示したことが、この提案の新規な点である。

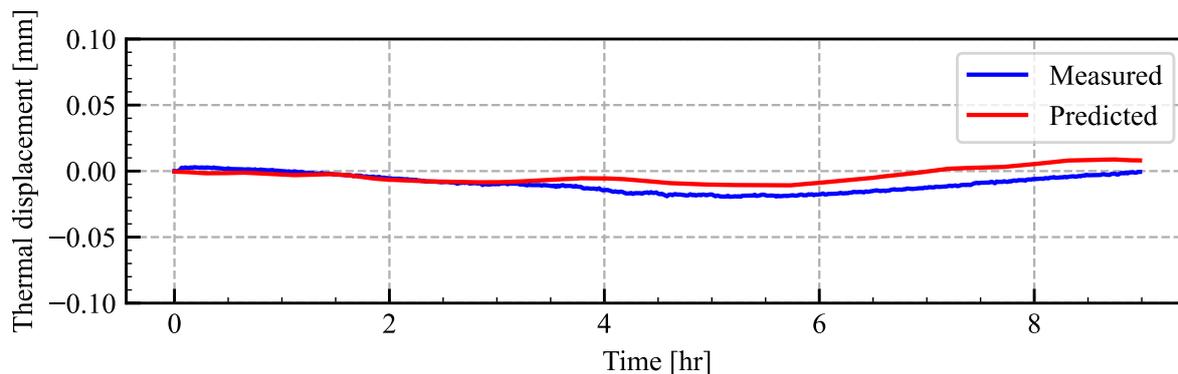
## 5.3 ケーススタディ：温度センサの故障を想定した学習による熱変位推定モデルの学習

### 5.3.1 センサ故障を考慮しない深層学習ネットワークによる予測

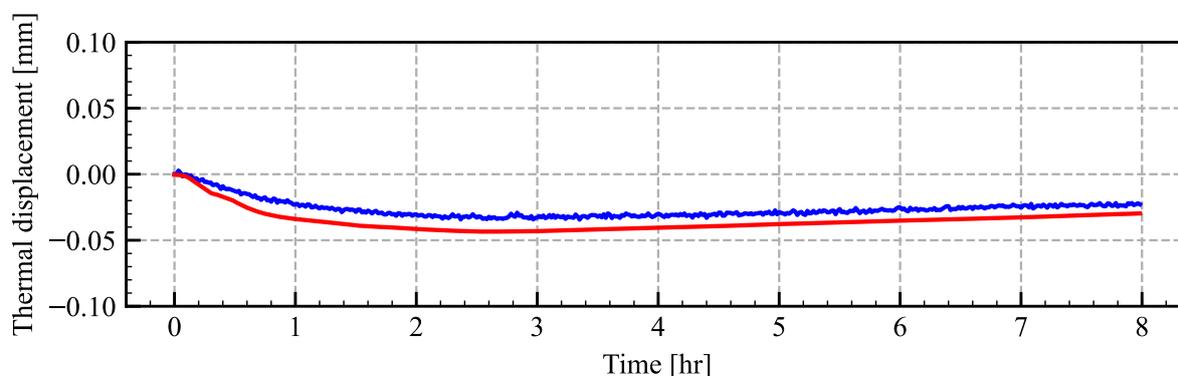
第3章で示した熱変位推定モデルを、3.3節に示した実験方法・条件で学習した。

収集した温度および主軸-タレット間変位のデータに対して、3.2節の熱変位推定モデルを用いて深層学習を実施した。入力データは、12個の温度センサの30分間（サンプルレート：1分）の温度データである。教師データは、温度データの最終時刻に対応する5つの主軸-タレット間変位データである。収集したデータのうち、あらかじめ学習に用いる測定データと推定だけに用いる評価用の測定データを分けた後、学習を実施した。

学習した熱変位推定モデルによる熱変位の推定精度を、評価用のデータを用いて実験で調べた結果は、すでに3.4.2項で示した。しかし、5.3.3項以降で、センサ故障が生じた場合と比較するために、3.4.2項で示した、熱変位の実測値と推定値の比較を、いくつかの実験条件について再び示す。なお、ひとつの熱変位推定モデルで、同一機種であれば異なる機械であっても同様に推定できることを示すため、同一機種の異なる2台（機械AおよびBと呼ぶ）での比較を示す。一例として、機械Aに対して、環境温度を表3.2のTest 4の条件で変化させた場合の、主軸-タレット間相対変位の測定値と推定値の比較結果を図5.2(a)に、機械Bに対して、主軸の運転条件を表3.2のTest 2の条件で変化させた場合の比較結果を図5.2(b)に示す。いずれも例として主軸-タレット間のX軸方向の変位のみを示す。青色の



(a) Machine A under Test 4



(b) Machine B under Test 2

図 5.2: Measured and predicted spindle displacement profiles in X-direction

線が実測結果，赤色の線が推定結果である．(a) の環境温度変化条件については 0.022 mm の X 軸方向熱変位を 0.013 mm 以内の誤差で，(b) の主軸運転条件については 0.034 mm の熱変位を 0.014 mm 以内の誤差で推定できている．

### 5.3.2 提案法を用いない場合にセンサ故障が予測に及ぼす影響の例

最初に，本章で提案する方法を使わず，5.3.1 項で学習した熱変位推定モデルだけを使った場合にセンサ故障が生じたと想定したとき，推定結果に及ぼす影響の例を示す．この例では，温度センサのひとつに接触不良を想定し，図 5.3 に示す故障シミュレーション信号を熱変位推定モデルに入力した．青色の線が変更前の温度信号，オレンジ色の線が故障をシミュレートした信号を示す．このセンサ故障は，図 4.4 の (a) Mode 1 に示した，抵抗出力式温度センサの接触不良と同じ形態である．図 5.3 は温度信号のうち測定開始から 1 時間までを拡大

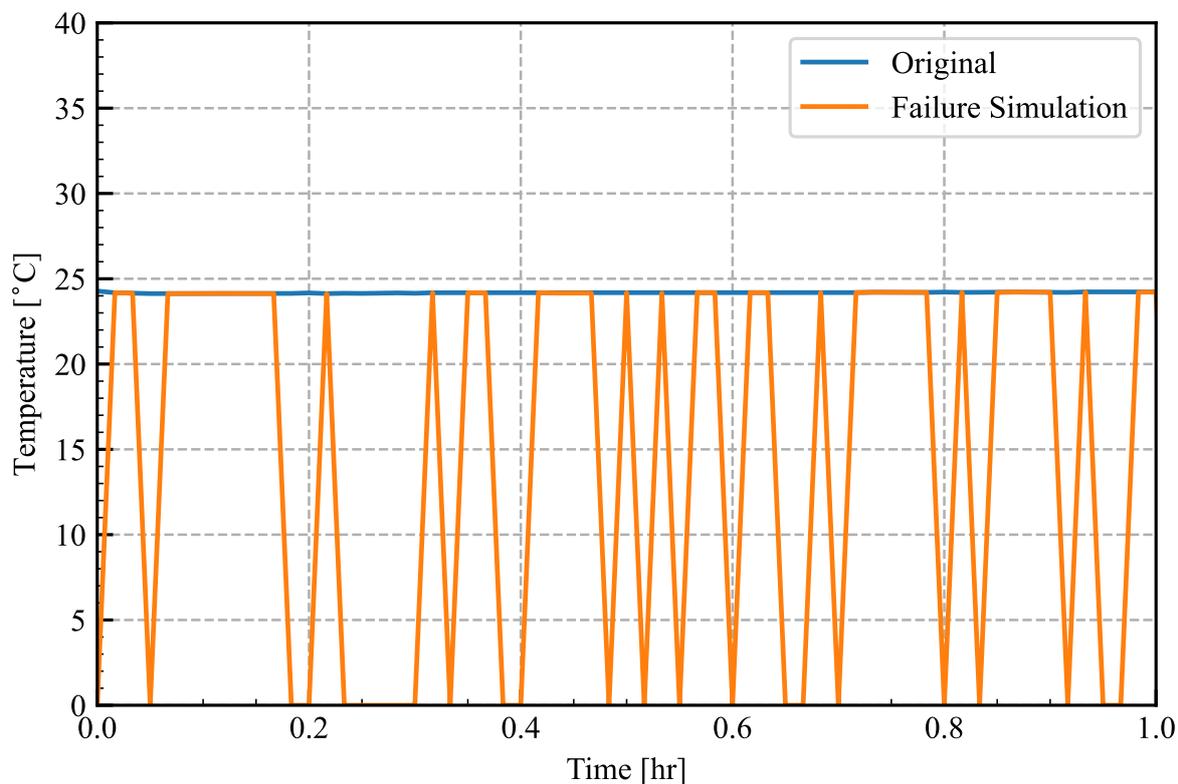
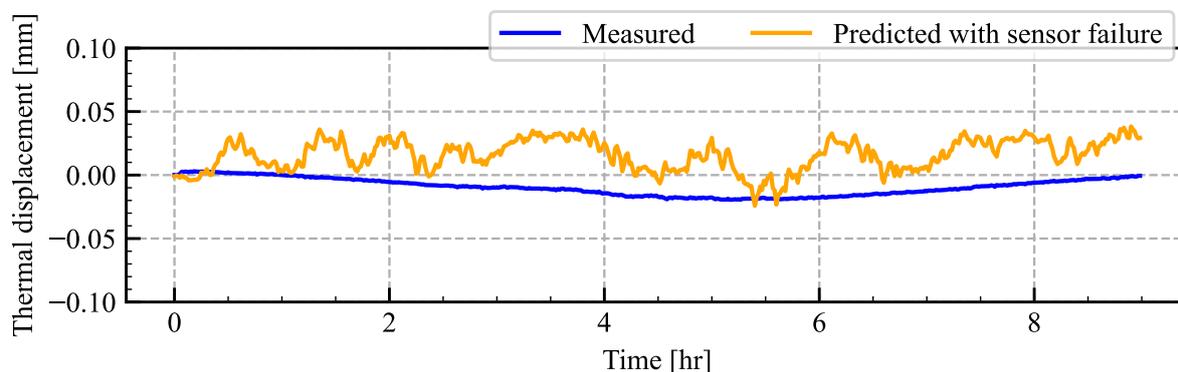
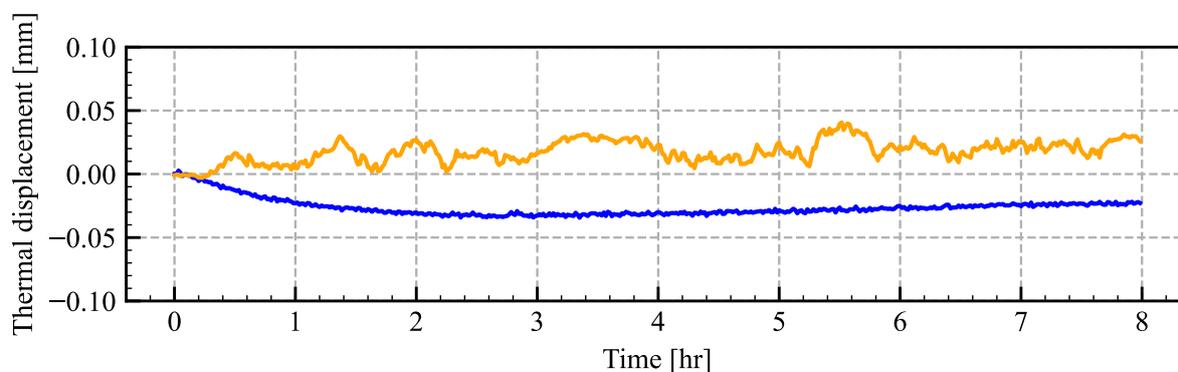


図 5.3: Original and simulated faulty signal of a temperature sensor

したものである。この信号は、時間あたりの正常信号と故障信号の割合が 1:1 になるようにランダムに正常信号と故障信号を切り替えることで作成した。この信号を入力データとして学習済みの熱変位推定モデルに入力した結果を図 5.4 に示す。図 5.2 同様、同一機種 of 機械 A および B での比較を示す。青色の線が主軸-タレット間の機械座標系 X 軸方向相対変位の実測結果（図 5.2 の青線と同じ）、オレンジ色の線が故障信号を入力した場合の推定結果である。機械 A の環境温度変化条件（表 3.2 の Test 4）、機械 B の主軸運転条件（表 3.2 の Test 2）のいずれについても、入力データの一部にセンサ故障を想定した信号が加わったことにより主軸-タレット間相対変位の推定値に最大（Peak-to-Peak 値）で 0.05 mm 程度の変動が発生していることがわかる。例えば、この推定値をもとに補正を行う場合、加工面や工作機械に損傷を与える可能性もある。



(a) Machine A under Test 4



(b) Machine B under Test 2

図 5.4: Measured and predicted spindle displacement profiles in X-direction

### 5.3.3 センサ故障を考慮した学習と熱変位推定モデルによる予測

4.3.2 項で述べたように、工作機械に搭載する温度センサの故障状態としては、センサ素子そのものの経年的な劣化による故障よりも移動体に取り付けたセンサやケーブルの断線やコネクタ部分の接触不良の発生頻度が高いと考えられる。それらの故障後の信号は、全くランダムになるのではなく、ある程度のパターンに分類できると仮定する。本章のケーススタディで想定する温度センサの故障形態は表 4.2 に示した 4 種の故障モードと同じである。図 5.5 に 4 種の故障モードにおける信号サンプルを示す。故障前のセンサの信号が青色、シミュレーションした故障信号がオレンジ色である。故障モードの (a) Mode 1 と (d) Mode 4 は、正常値と異常値をランダムに入れ替えることで接触不良の状態を再現した。(b) Mode 2 と (c) Mode 3 は、常時異常値を採用することで断線の状態を再現した。図 5.5 は、4.3.2 項

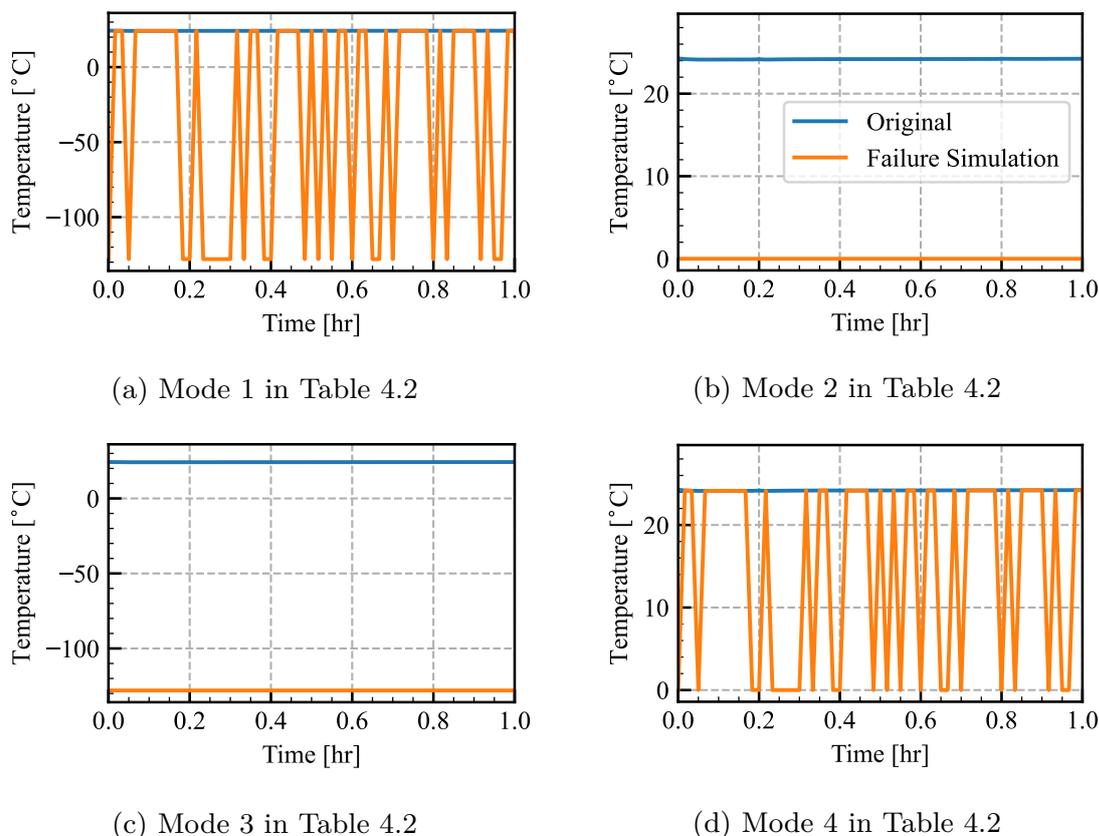
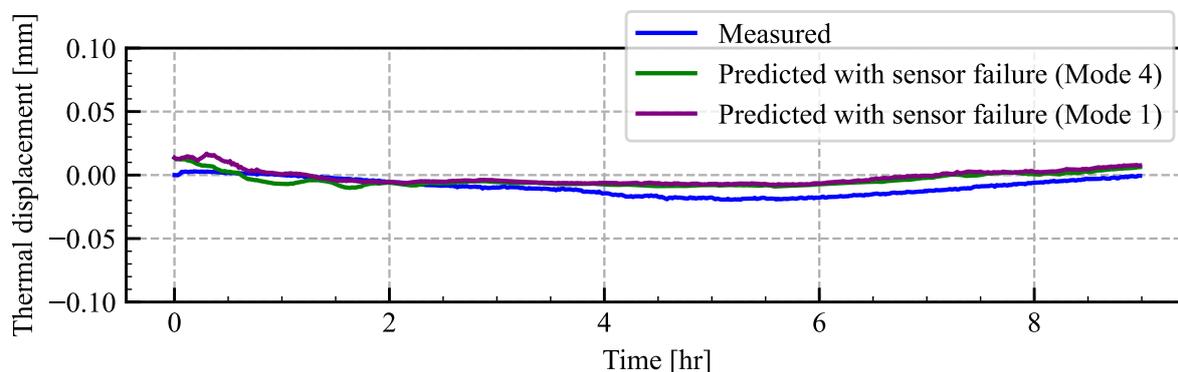


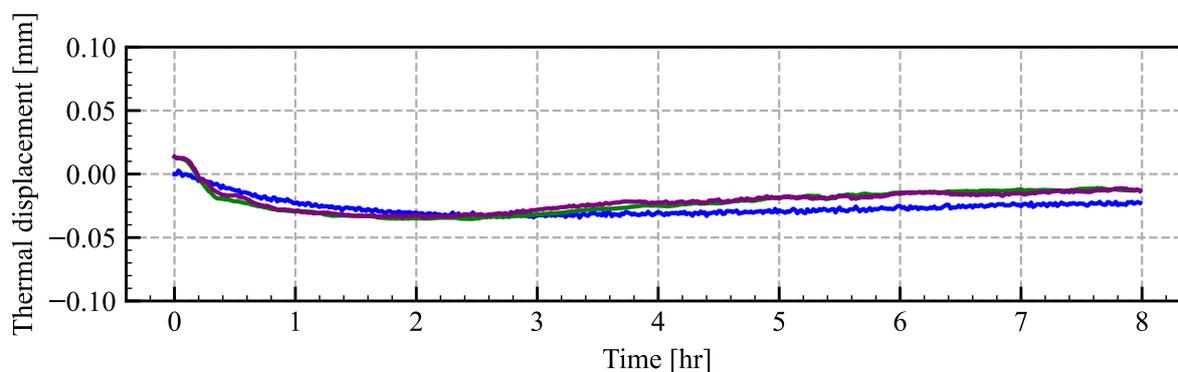
図 5.5: Simulated signals under sensor failure

の図 4.4 で示した故障シミュレーション信号と基本的には同じであるが、4.3.2 項では故障シミュレーションによる熱変位推定への影響を確かめるために途中（10 hr 時点）で正常状態と故障状態を切り替える信号としたが、本章では故障状態の信号を学習に使用すればよく、学習中に自動的に故障状態の信号が切り替わるので、全ての時間帯で故障状態を想定した信号としている。センサ故障を想定した学習は、5.2 節 で述べたとおり単一のミニバッチごとにランダムに選択した温度センサの信号をいずれかの故障モードの信号に変更して繰り返し学習を行った。

センサ故障を考慮して学習した熱変位推定モデルを用いて、故障信号が与えられた場合の熱変位を推定した結果の一例を図 5.6 に示す。図 5.2 同様、同一機種 of 機械 A および B での比較を示す。上側が機械 A の環境温度変化条件（表 3.2 の Test 4）、下側が機械 B の主軸運転条件（表 3.2 の Test 2）である。青色の線が主軸-タレット間の X 軸方向相対変位の実測結果（図 5.2 の青線と同じ）、緑色の線が電圧出力型温度センサの接触不良（表 4.2 の Mode 4）の故障シミュレーション信号を入力した際の推定結果、紫色の線が同じ熱変位推



(a) Machine A under Test 4



(b) Machine B under Test 2

図 5.6: Measured and predicted thermal displacement profiles in X-direction by the model learned with simulated sensor failure signals

定モデルに対して抵抗出力型温度センサの接触不良（表 4.2 の Mode 1）の故障シミュレーション信号を入力した際の推定結果である。なお、図 5.5 の故障モードの (a) Mode 1 と (d) Mode 4 は、正常値と異常値がランダムに入れ替わるので、図 5.6 の推定結果は学習に用いた図 5.5 とまったく同じ信号を入力したのではなく、ランダムに異なる信号を使っている。接触不良による故障シミュレーション信号は、正常値と異常値がランダムに入れ替わるため入力信号の時間変動が大きい。しかし、(a) 環境温度変化条件、(b) 主軸運転条件のいずれについても、推定結果の変動が小さく抑えられていることがわかる。測定結果との最大誤差（Peak-to-Peak 値）は (a) 環境温度変化条件で 0.014 mm 以内、(b) 主軸運転条件で 0.014 mm 以内であり、図 5.2 のセンサ故障状態を想定した信号を入力していない推定結果と同程度の推定性能を実現できている。センサの接触不良のような極端な故障状態を想定し

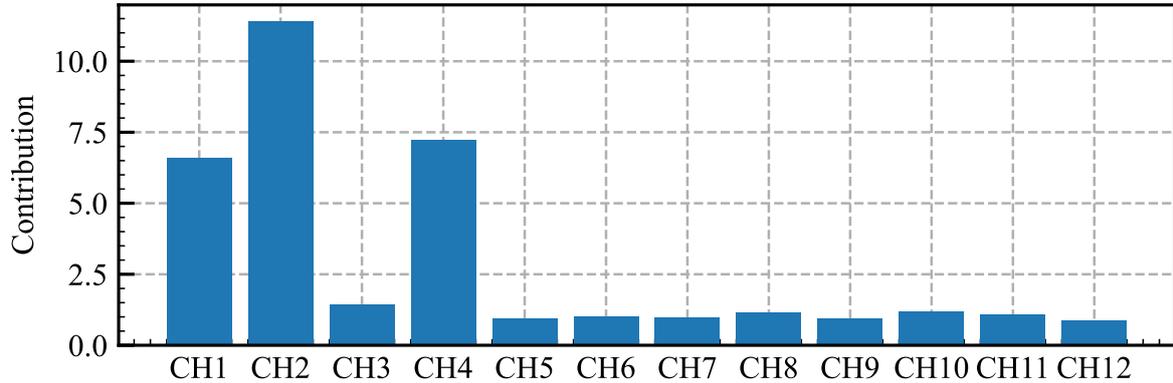


図 5.7: Contribution of temperature sensor to the error of thermal displacement prediction

た場合でも推定結果の変動を小さく抑えられることは、補正制御システムのロバスト性を高めるといって非常に重要である。センサ故障を考慮した学習による熱変位推定モデルは、センサが故障しても推定結果に与える変動が小さく、加工対象物や機械に対して損傷を与える可能性を小さくできると期待できる。

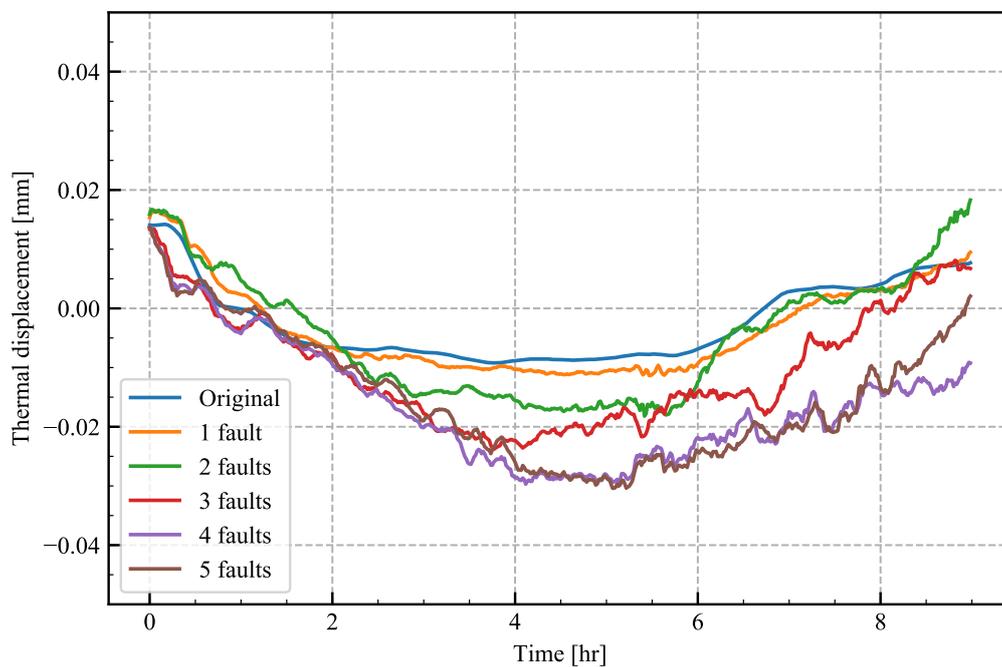
### 5.3.4 センサ故障を考慮した学習の効果

図 5.6 は、全部で 12 個ある温度センサのうちの一つ (CH 1) が故障した場合の、熱変位の推定値を示した。その他のセンサが故障した場合や、複数のセンサが同時に故障した場合に、熱変位の推定値に及ぼす影響を同様に調べた。提案法の効果を確認するために、ひとつずつ温度センサ信号を故障信号に置き換え、熱変位推定に与える影響を調査した。 $q$  番目の温度センサの寄与  $c_q$  は、故障信号を入力しない場合の主軸-タレット間の相対変位の推定結果の、実測結果に対する二乗平均平方根誤差  $e_0$  と、故障信号を入力した場合の二乗平均平方根誤差  $e_q$  から、

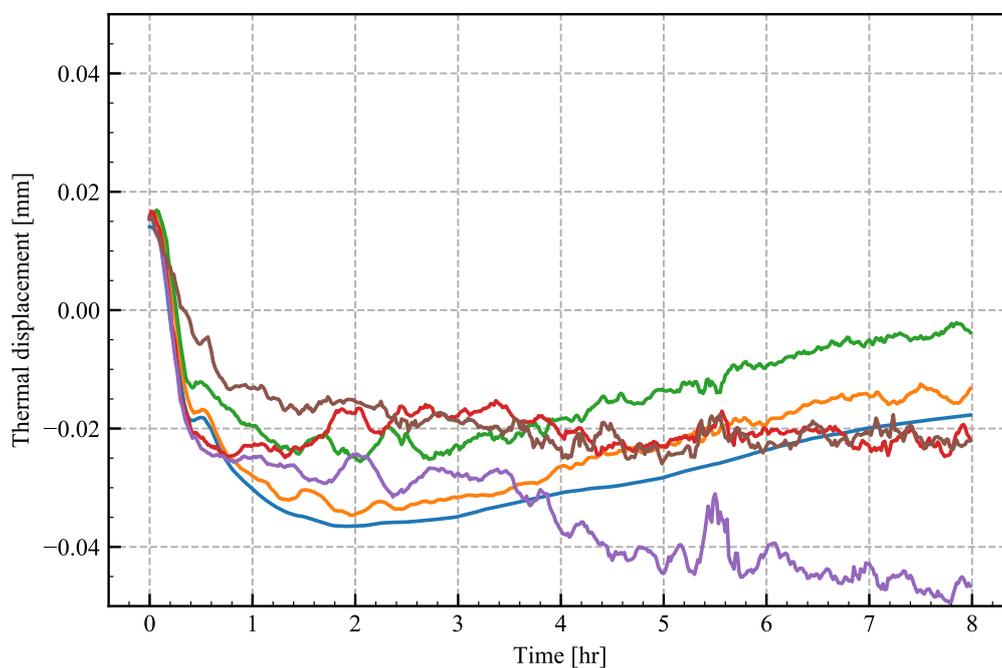
$$c_q = \frac{e_q}{e_0} \quad (5.1)$$

と定義する。提案法を用いて学習した熱変位推定モデルに対して、表 4.2 の Mode 1 の故障信号を用いて各温度センサの寄与を求めた結果を図 5.7 に示す。5.3.2 項および 5.3.3 項で故障を想定したセンサは CH 1 のセンサであり、このセンサの寄与は全体の 3 番目であった。

つぎに、寄与の高い順に温度センサ信号を表 4.2 の Mode 1 の故障信号に置き換え、故障信号の数を 1 個、2 個、3 個 ... と 5 個まで増加させた場合の推定結果を図 5.8 に示す。



(a) Machine A under Test 4



(b) Machine B under Test 2

図 5.8: Predicted thermal displacement profiles when one to five temperature sensors are failed in Mode 1 (Table 4.2)

表 5.1: The maximum difference in measured and predicted thermal displacement profiles when one to five temperature sensors are failed

Number of faults	Machine A Test 4	Machine B Test 2
1 fault	0.005 mm	0.007 mm
2 faults	0.011 mm	0.016 mm
3 faults	0.018 mm	0.020 mm
4 faults	0.024 mm	0.031 mm
5 faults	0.025 mm	0.022 mm

図 5.2 同様，同一機種 of 機械 A および B での比較を示す．故障信号を入力しない場合の推定結果と，故障信号を入力した場合の推定結果の最大差の絶対値を表 5.1 に示す．センサ 1 つの故障であれば最大 0.007 mm の誤差，センサ 5 つの故障の場合最大 0.025 mm の誤差であった．5.3.2 項で述べた，提案法を用いない場合のセンサ 1 つの故障での 0.05 mm 程度の変動と比較すると，センサ 5 つの故障状態でも熱変位の推定誤差の増加を抑制できていることがわかる．

## 5.4 結言

本章では，深層学習による工作機械の熱変位推定において，あらかじめ想定できる温度センサの故障状態をシミュレーションした信号を正常信号と混合して学習することにより，熱変位推定モデルの温度センサ故障に対するロバスト性を高められることを示した．

本章での提案とケーススタディの結果を以下にまとめる．

1. 深層学習による工作機械の熱変位推定において，熱変位推定モデルや推定値の信頼性は非常に重要である．例えば，入力データとして使用する温度センサの故障などの外乱に対して，熱変位推定結果が大きく変動した場合に，熱変位補正量が大きく変動すると，加工対象物や工作機械そのものに損傷を与えることも考えられる．そこで，深層学習による熱変位推定モデルを学習する際に，あらかじめ想定できる温度センサの故障状態に基づいてシミュレーションした温度センサの故障信号を正常信号と混合して学習することで，温度センサの故障に対してロバストな熱変位推定モデルが学習できる方法を提案した．

2. ケーススタディとして、ターニングセンタに取り付けた温度センサから熱変位量を推定する、深層学習による熱変位推定モデルにおいて、温度センサの接触不良と断線の故障状態を考慮した学習を実施した。故障状態を考慮しない学習による熱変位推定モデルでは、温度センサの故障を想定した故障信号を入力した際、熱変位推定結果に変動が発生したが、故障状態を考慮した学習による熱変位推定モデルでは、熱変位推定結果に生じる変動を抑制できることを示した。これによって、熱変位推定モデルによる工作機械の補正制御を実現する際問題となる、外乱に対する変動について、想定済みの温度センサ故障による変動を抑制することができる。一方、任意の外乱に対する変動については検討されていないが、あらかじめ想定できる特徴を有する外乱については温度センサの故障同様に学習の際考慮することで、同様の効果があることが期待できる。



## 第6章

# 結論

### 6.1 まとめ

本論文では、工作機械、特にターニングセンタの機械構造に取り付けた温度センサの値を使用して、深層学習による熱変位推定モデルで熱変位を推定し、補正制御する手法について述べた。工作機械で安定して加工対象物を生産するためには、機械外部からの熱源や機械内部からの熱源による機械構造の温度変化に対して、加工対象物と刃先の相対変位の変化（熱変位）が小さいことが必要である。工作機械の熱変位に対しては、様々な対策が提案されている。機械外部からの熱源に対しては機械周辺の温度を管理すること、機械内部からの熱源に対しては機械構造の温度変化の原因とならないよう熱源を排除して温度管理することが理想であるが、実際の使用環境や設計制約の中では困難なことが多い。そこで、発生した熱変位を推定し、それらを打ち消すように CNC 装置による補正制御を実施して加工対象物の精度劣化を抑制する手法が、これまでに多く研究され、市販機に搭載されたものも多い。本論文ではターニングセンタを対象として、温度センサの測定値から熱変位を推定して CNC 装置で補正量として制御する方法について述べた。本研究で得られた主な結論は以下のとおりである。

#### 第2章：

1. 熱変位補正のための温度センサを工作機械に取り付ける場合、温度センサを取り付けた場所の温度変化が、熱変位に与える影響が大きい箇所に取り付けることが望ましい。工作機械構造の熱変形・熱変位と構造の温度変化の関係は、有限要素法（FEM）などにより計算することができるが、機械構造全体について、熱変位に与える影響を一度に可視化することは難しい。そこで、工作機械構造の加工対象物-工具間の相対

変位に及ぼす機械構造の温度変化の影響を評価する方法として、「熱感度」を提案した。実際の工作機械構造の熱感度を計算する方法として、市販のシミュレーションソフトを用いた FEM によって有限要素モデルの熱感度を計算する方法を示した。熱感度は、加工対象物-工具間などの特定の相対変位について検討すれば十分なので、必要な自由度だけを抽出して計算量を削減する方法を示した。

2. ケーススタディとして、ターニングセンタの熱感度を計算して可視化した。ターニングセンタの熱感度は、ベッド上面の温度上昇で主軸とタレットが離れる方向の変位が生じ、ベッド背面の温度上昇で主軸とタレットが近づく方向の変位が生じることを示す結果であった。熱感度の計算結果と実際の工作機械の主軸-タレット間の相対変位を比較するために実験を実施した。ターニングセンタの周辺温度を変化させた際の機械構造の温度と主軸-タレット間変位を計測した。機械座標系 X 軸方向の熱変位に着目すると、機械の周辺温度の上昇に伴って主軸とタレットが近づく方向へ変位し、その後主軸とタレットが離れる方向へ変化した。この変位は、主軸とタレットが近づく方向に作用するプラスの熱感度を持つベッド背面の温度上昇により、まず主軸とタレットが近づく変位が生じ、遅れてマイナスの熱感度を持つベッド上面の温度上昇により変位の緩和と変位方向の反転が発生するメカニズムである。温度変化、変位の関係と熱感度から、ターニングセンタの環境温度変化に対する変形メカニズムを説明することができた。

さらに、機械周辺の温度変化に対する熱変位を抑制する目的で、熱感度の計算ケーススタディを実施したターニングセンタに対してカバーとファンを取り付け、機械構造の温度分布を最適化する実験を実施した。温度変化の早いベッド背面に空気との熱交換を阻害するカバーを取り付け、温度変化の遅いベッド上面に空気との熱交換を促進するファンを取り付けた。カバーとファンの取り付けによって機械座標系 X 軸方向の熱変位を抑制することができた。熱感度の計算結果と熱変位の計測結果に基づいて、熱変位へ影響を与える機械構造の部位を特定し、対策を施すことで熱変位が抑制できる結果を得た。

### 第3章：

3. 工作機械の熱変位推定のために、従来の研究で多く用いられてきた数式によるモデル化手法は、次数、静的・動的、線形・非線形など、設計者が対象に合わせて選択しなければならない要素が多い。そのような必要性が少なく、性能の良いモデル化手法と

して深層学習が挙げられる。そこで、CNN を用いた熱変位推定モデルを提案した。

4. 深層学習では、多くのデータで学習すると精度が向上することが知られている。深層学習による工作機械の熱変位推定モデルを学習するために、多数のターニングセンタの熱変位を測定する方法を示した。熱変位データとして、工作機械の機械構造に取り付けた温度センサと、主軸-タレット間の相対変位を非接触変位センサを用いて測定した。熱変位に影響する要因として、(1) クーラントの温度上昇、(2) 主軸運転、(3) 軸稼働、(4) 環境温度変化、の4つを挙げ、それぞれが熱変位に及ぼす影響を測定できるように測定条件を設定して熱変位データの収集方法を述べた。
5. ケーススタディとして、6 台の同一機種 of ターニングセンタの環境温度変化条件の熱変位データを収集し、提案した CNN による深層学習によって熱変位推定モデルを学習した。学習した熱変位推定モデルの誤差は、0.01 mm 程度以下であり、熱変位を高精度に推定することができた。また、L2 正則化による重回帰分析（リッジ回帰）による熱変位推定モデルと、提案した CNN による熱変位推定モデルの推定性能を比較し、CNN の方が良好な結果であった。

#### 第4章：

6. 工作機械の熱変位推定や補正制御において、熱変位推定モデルや推定値の信頼性は非常に重要である。本論文で信頼性とは、学習した熱変位推定モデルについて、新規データを入力したときに出力データがどの程度信頼できるかということを表す指標である。信頼性が低いと、本来適用されるべき補正量が適用されず、加工対象物の品質低下の原因になるばかりでなく、過大な補正量が適用されて機械の故障の原因になることも考えられる。そこで、「Bayesian dropout」を用いて熱変位推定モデルや推定値の信頼性を推定分布として計算する方法を提案した。
7. 熱変位推定モデルや推定値の信頼性を低下させる条件として、入力データである温度センサの故障を想定したシミュレーションを実施した。温度センサの種類として抵抗出力式と電圧出力式について、断線と接触不良の故障形態を仮定した。学習した熱変位推定モデルへ、温度センサの故障シミュレーション信号を入力し、推定精度と推定分布の変化を調べた。故障によって熱変位推定モデルへ入力される値の変化が相対的に大きくなる抵抗式温度センサの故障条件では、熱変位の推定誤差と推定分布が共に大きくなった。さらに、抵抗式温度センサの接触不良を考慮した条件では、熱変位の推定値と推定分布の時間変動も大きくなる結果であった。

8. 計算した推定分布が大きい場合に、工作機械の熱変位制御に使用する補正量が大きく変動したり、過大な補正量が適用されることがないようにするために、熱変位推定モデルと工作機械の CNC 装置の間に移動平均フィルタを追加して補正量を修正する手法を提案した。移動平均フィルタは、推定分布の計算結果に応じて平均長を変更した。推定分布が大きい場合は平均長を大きくとって変動の影響が少なくなるようにし、推定分布が小さい場合は平均長を小さくとって推定値をそのまま採用するようにした。温度センサの故障シミュレーション信号を入力した場合、熱変位推定結果への影響が大きかった抵抗出力式温度センサの故障条件の場合には、補正量の修正が強く働いて異常な補正値が適用されることを防ぎ、熱変位推定結果への影響が小さかった電圧出力式温度センサの故障条件の場合には、補正量はほとんど修正されずに高精度な補正値を維持することができた。
9. 提案した熱変位推定モデルによる推定分布の計算機能と、推定分布の計算結果を使用した補正量の修正アルゴリズムを、熱変位推定モデルの学習用に熱変位データを収集したターニングセンタと同一機種 of 機械に搭載し、切削試験で効果を確認した。主軸運転条件と軸稼働条件を組み合わせた状態で切削試験を実施し、補正制御をしない場合の外径変化が 0.031 mm であったのに対し、提案手法で補正制御を実施した場合は 0.018 mm の外径変化であった。切削試験に使用した機械は、学習用の熱変位データを取得した機械ではないが、熱変位を抑制できる結果となり、推定分布の計算による信頼性評価と補正量の修正アルゴリズムで実際に加工対象物の加工精度を向上できることを確認できた。

## 第5章：

10. 深層学習による工作機械の熱変位推定において、熱変位推定モデルや推定値の信頼性に影響を与える代表的な要素として、センサの故障により生じる入力データの外乱が挙げられる。そこで、深層学習による熱変位推定モデルを学習する際に、あらかじめ想定できる温度センサの故障状態に基づいてシミュレーションした、温度センサの故障信号を正常信号と混合して学習することで、温度センサの故障に対してロバストな熱変位推定モデルが学習できる方法を提案した。
11. ケーススタディとして、ターニングセンタに取り付けた温度センサから熱変位量を推定する CNN による熱変位推定モデルにおいて、温度センサの接触不良と断線を故障状態として考慮した学習を実施した。故障状態を考慮した学習によって、熱変位推定

結果に生じる変動を抑制できることを示した。これによって、センサ故障による外乱に対して、想定済みの温度センサ故障による熱変位推定結果の変動を抑制することができる。一方、任意の外乱に対する変動については検討されていないが、あらかじめ想定できる特徴を有する外乱については温度センサの故障同様に学習の際考慮することで、同様の効果があることが期待できる。

## 6.2 今後の研究

本研究に関する今後の研究課題を以下にまとめる。

1. 深層学習ネットワークは、設計者が内部パラメータの役割を理解していなくてもネットワークの構築・学習ができる反面、数式で表現できる他の手法と比較して、ネットワーク自体の解釈が難しく、ブラックボックス化しやすい。これはネットワークがどのような過程で推定値を計算しているかを説明することが難しいということでもある。計算過程が説明できないと、例えば実際には入力データに混入したノイズに対して推定値を判断してしまっている場合でも、それに気づくことができない。深層学習による熱変位推定モデルにおいて、入力データである温度情報のどの部分から推定値を判断して計算したかを可視化する手法が必要である。
2. 第4章で示した Bayesian dropout による信頼性計算の方法は、推定値と推定分布を得るために、1回あたり  $J$  回の計算を繰り返し、平均値と分散を計算する必要がある。一般的に  $J$  を大きくとり、試行回数を増やしたほうが信頼性の計算精度が向上すると考えられるが、熱変位推定モデルの規模によっては計算負荷が高くなることがある。計算量を増加させずに、あるいは最低限の計算量の増加で信頼性を計算できる手法が必要である。
3. 第5章の結果では、熱変位推定モデルへの入力データとして用いる温度センサのうち、いくつかのセンサの情報が欠落していても推定精度に与える影響が小さいことが示された。これは、そのセンサは熱変位を推定するためにあまり寄与していないと解釈することができる。一方、工作機械へ熱変位制御機能を搭載するために温度センサを取り付ける場合、できるだけ取り付けしやすく、メンテナンスのしやすい位置に、最小限の数の温度センサを取り付けることが望ましい。したがって、学習済みの熱変位推定モデルから、熱変位推定にとって寄与の大きいセンサと、除外しても問題ないセンサを体系的に判別できる手法が必要である。



# 謝辞

本研究を遂行するにあたり、非常に多くの方々にご協力をいただきました。ここに、謝辞を述べさせていただきます。

ご懇篤なるご指導を賜りました広島大学大学院先進理工系科学研究科機械工学プログラム教授 茨木創一博士に深甚なる謝意を表します。

本研究の機会を与えていただき、ご支援いただきました DMG 森精機株式会社 取締役社長 森雅彦博士，同社専務取締役 藤嶋誠博士，入野成弘博士，藤木正寛博士に心から感謝いたします。

研究遂行に際し、多大なるサポートをいただきました DMG 森精機株式会社の同僚諸氏に深く感謝いたします。

最後にここまで私を支えてくれた家族にも感謝の意を表したいと思います。



## 参考文献

- [AA72] National Aeronautics and Space Administration. NASTRAN-95. Web-Page, 1972. <https://code.nasa.gov>.
- [Aso13] 麻生英樹. 多層ニューラルネットワークによる深層表現の学習 (<連載解説> deep learning (深層学習) [第 2 回]). 人工知能, Vol. 28, No. 4, pp. 649–659, 2013.
- [Aso15] 麻生英樹, 神寫敏弘, 人工知能学会. 深層学習: Deep learning., 初版. 近代科学社, 2015.
- [BHW04] Christian Brecher, Peter Hirsch, and M Weck. Compensation of thermo-elastic machine tool deformation based on control internal data. CIRP Annals, Vol. 53, No. 1, pp. 299–304, 2004.
- [Bry90] Jim Bryan. International status of thermal error research (1990). CIRP annals, Vol. 39, No. 2, pp. 645–656, 1990.
- [Chi89] 千輝淳二, 垣野義昭. 工作機械の温度制御に関する研究 (第 5 報). 精密工学会誌, Vol. 55, No. 8, pp. 1397–1402, 1989.
- [DES19] UN DESA. World population prospects 2019. united nations. department of economic and social affairs. World Population Prospects 2019, 2019.
- [Dou70] Frank J Douglas. The NASTRAN programmer’s manual. NASA SP-223, Sept, 1970.
- [DT17] Terrance DeVries and Graham W Taylor. Improved regularization of convolutional neural networks with cutout. arXiv preprint arXiv:1708.04552, 2017.
- [Gal16] Yarin Gal. Uncertainty in deep learning. 2016.
- [GG16a] Y Gal and Z Ghahramani. Dropout as a bayesian approximation: Appendix 20 (2016). URL <http://arxiv.org/abs/1506.02157>, Vol. 1506, ,

- 2016.
- [GG16b] Yarin Gal and Zoubin Ghahramani. Dropout as a bayesian approximation: Representing model uncertainty in deep learning. In international conference on machine learning, pp. 1050–1059, 2016.
- [HBBM<sup>+</sup>17] Pablo Hernández-Becerro, Philip Blaser, Josef Mayr, Sascha Weikert, and Konrad Wegener. Measurement of the effect of the cutting fluid on the thermal response of a five-axis machine tool. Laser Metrology and Machine Performance XII, 2017.
- [HSK<sup>+</sup>12] Geoffrey E Hinton, Nitish Srivastava, Alex Krizhevsky, Ilya Sutskever, and Ruslan R Salakhutdinov. Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580, 2012.
- [HZRS15] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In Proceedings of the IEEE international conference on computer vision, pp. 1026–1034, 2015.
- [Ido16] 井戸悠, 松原厚, 高山直士, 中南成光. NC 旋盤の熱変位補正に関する研究. 生産加工・工作機械部門講演会: 生産と加工に関する学術講演会 2016.11, p. A29. 一般社団法人 日本機械学会, 2016.
- [Ima03] 今井登, 金子準平, 清水伸二. 主軸高速回転に伴う工作機械熱変位の評価法. 精密工学会学術講演会講演論文集 2003 年度精密工学会春季大会, pp. 233–233. 公益社団法人 精密工学会, 2003.
- [IS15] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In International conference on machine learning, pp. 448–456. PMLR, 2015.
- [Iwa13] 岩井英樹, 佐々木雄二, 桜井康匡, 若園賀生. 工作機械熱変位補償技術の研究 (第 3 報) リアルタイム熱変位補正による加工評価. 精密工学会学術講演会講演論文集 2013 年度精密工学会秋季大会, pp. 9–10. 公益社団法人 精密工学会, 2013.
- [Kat18] 加藤潤, 吉岡勇人, 新野秀憲, 朝倉和廣, 後藤俊輔, 白田敬介, 堀伸充. CFRP を適用した熱変形抑制ボールねじの性能評価. 精密工学会学術講演会講演論文集 2018 年度精密工学会秋季大会, pp. 145–146. 公益社団法人 精密工学会, 2018.
- [Kat20] 加藤慎, 河野大輔, 吉岡勇人, 杉田直彦, 浜口顕秀, 高野和雅, 飯島一憲, 柿沼康

- 弘. 新構造材料適用省エネ型工作機械の熱変位および省エネルギー性能評価. 日本機械学会論文集, Vol. 86, No. 884, pp. 1–16, 2020.
- [KCH<sup>+</sup>07] Yuan Kang, Chuan-Wei Chang, Yuanruey Huang, Chuag-Liang Hsu, and I-Fu Nieh. Modification of a neural network utilizing hybrid filters for the compensation of thermal deformation in machine tools. International Journal of Machine Tools and Manufacture, Vol. 47, No. 2, pp. 376–387, 2007.
- [Kod89] 幸田盛堂, 奥田長三, 村田悌二. レーザ光の反射光点変位検出による工作機械コラムの熱変位制御. 精密工学会誌, Vol. 55, No. 9, pp. 1706–1711, 1989.
- [Kod05] 幸田盛堂, 正本和則, 熊谷幹人. 工作機械の熱変形対策 (第3報) 周囲温度変化に対する断熱材の効果. 精密工学会学術講演会講演論文集 2005 年度精密工学会春季大会, pp. 450–450. 公益社団法人 精密工学会, 2005.
- [KSH17] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. Communications of the ACM, Vol. 60, No. 6, pp. 84–90, 2017.
- [MBRHB18] Josef Mayr, Philip Blaser, Adrian Ryser, and Pablo Hernandez-Becerro. An adaptive self-learning compensation approach for thermal errors on 5-axis machine tools handling an arbitrary set of sample rates. CIRP Annals, Vol. 67, No. 1, pp. 551–554, 2018.
- [MGM<sup>+</sup>14] Josef Mayr, Michael Gebhardt, Benjamin B Massow, Sascha Weikert, and Konrad Wegener. Cutting fluid influence on thermal behavior of 5-axis machine tools. Procedia CIRP, Vol. 14, pp. 395–400, 2014.
- [Mit95] 光石衛, 奥村努, 杉田直彦, 長尾高明, 畑村洋太郎. ニューラル・ネットワークと遺伝的アルゴリズムとを用いた高精度マシニングセンタの開発. 日本機械学会論文集 C 編, Vol. 61, No. 591, pp. 4517–4522, 1995.
- [MJU<sup>+</sup>12] Josef Mayr, Jerzy Jedrzejewski, Eckart Uhlmann, M Alkan Donmez, Wolfgang Knapp, Frank Härtig, Klaus Wendt, Toshimichi Moriwaki, Paul Shore, Robert Schmitt, et al. Thermal issues in machine tools. CIRP annals, Vol. 61, No. 2, pp. 771–791, 2012.
- [MMF<sup>+</sup>09] M Mori, H Mizuguchi, M Fujishima, Y Ido, N Mingkai, and K Konishi. Design optimization and development of CNC lathe headstock to minimize thermal deformation. CIRP annals, Vol. 58, No. 1, pp. 331–334, 2009.

- [Mor88] Toshimichi Moriwaki. Thermal deformation and its on-line compensation of hydrostatically supported precision spindle. *CIRP Annals*, Vol. 37, No. 1, pp. 393–396, 1988.
- [Mor92] 森脇俊道, 趙成和. ニューラルネットワークによるマシニングセンタの熱変形予測. 日本機械学会論文集 C 編, Vol. 58, No. 550, pp. 1932–1937, 1992.
- [Mor95] 森脇俊道, 社本英二, 河野昌弘. ニューラルネットワークによる工作機械の熱変形予測: 機械表面温度の時間履歴を考慮することによる予測精度の向上. 日本機械学会論文集 C 編, Vol. 61, No. 584, pp. 1691–1696, 1995.
- [Mor97] 森脇俊道, 社本英二, 徳永剛志. 周囲気温変化による超精密工作機械の熱変形: 伝達関数による熱変形特性の検討とたたみこみ積分による推定. 日本機械学会論文集 C 編, Vol. 63, No. 615, pp. 4025–4030, 1997.
- [MS98] Toshimichi Moriwaki and Eiji Shamoto. Analysis of thermal deformation of an ultraprecision air spindle system. *CIRP Annals*, Vol. 47, No. 1, pp. 315–319, 1998.
- [Nag99] 長島一男, 上田俊弘, 百地武. 熱と遠心力により生ずる工作機械主軸の変位とその補償方法. 日本機械学会論文集 C 編, Vol. 65, No. 636, pp. 3438–3443, 1999.
- [Oku72] 奥島啓式, 垣野義昭, 沢井浩次, 菊池敏彦. 工作機械の熱変形に関する研究 (第 1 報) コラムの定常熱変形. 精密機械, Vol. 38, No. 446, pp. 283–288, 1972.
- [Oku73] 奥島啓式, 垣野義昭, 菊池敏彦. 工作機械の熱変形に関する研究 (第 3 報) 液体の循環が熱変形に与える影響. 精密機械, Vol. 39, No. 457, pp. 230–236, 1973.
- [PBW<sup>+</sup>16] Florentina Pavliček, Yves Beer, Sascha Weikert, Josef Mayr, and Konrad Wegener. Design of a measurement setup and first experiments on the influence of co<sub>2</sub>-cooling on the thermal displacements on a machine tool. *Procedia CIRP*, Vol. 46, pp. 23–26, 2016.
- [Sad75] 佐田登志夫, 竹内芳美, 大久保信行, 佐藤和信. 工作機械の熱変形制御 (第 1 報) 加工開始前の早期安定化について. 精密機械, Vol. 41, No. 485, pp. 592–597, 1975.
- [Sas12] 佐々木雄二, 岩井英樹, 桜井康匡, 若園賀生. 工作機械熱変位補償技術の研究 (第 1 報) 熱変位推定方法の開発. 精密工学会学術講演会講演論文集 2012 年度精密工学会秋季大会, pp. 677–678. 公益社団法人 精密工学会, 2012.

- [Sas13] 佐々木雄二, 岩井英樹, 桜井康匡, 若園賀生. 工作機械熱変位補償技術の研究 (第2報) マシニングセンタ熱変位の評価. 精密工学会学術講演会講演論文集 2013年度精密工学会春季大会, pp. 729–730. 公益社団法人 精密工学会, 2013.
- [Sas17] 佐々木雄二, 岩井英樹, 若園賀生, 桜井康匡, 岡祐司. リアルタイム熱変位補正システムの開発. 精密工学会誌, Vol. 83, No. 2, pp. 121–124, 2017.
- [SHK<sup>+</sup>14] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. The journal of machine learning research, Vol. 15, No. 1, pp. 1929–1958, 2014.
- [SKP15] Florian Schroff, Dmitry Kalenichenko, and James Philbin. Facenet: A unified embedding for face recognition and clustering. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 815–823, 2015.
- [Sya03] 社本英二, 樋野励, 富江竜哉, 松原陽介, 森脇俊道. Cnc装置の内部情報を利用した工作機械の熱変形推定(機械要素, 潤滑, 工作, 生産管理など). 日本機械学会論文集 C 編, Vol. 69, No. 686, pp. 2775–2782, 2003.
- [Tak76] 竹内芳美, 大久保信行, 佐田登志夫. 温度分布測定による工作機械構造の実時間熱変形制御. 精密機械, Vol. 42, No. 503, pp. 1043–1048, 1976.
- [Tat13] 立矢宏, 平田紘規, 須摩貴嗣, 金子義幸, 中垣勝敬, 石野嘉章. 少数位置の温度測定による小型 CNC 旋盤の熱変形補正. 日本機械学会論文集 C 編, Vol. 79, No. 804, pp. 2960–2974, 2013.
- [TJM10] Paweł Turek, Jerzy Jędrzejewski, and Wojciech Modrzycki. Methods of machine tool error compensation. Journal of Machine Engineering, Vol. 10, No. 4, pp. 5–25, 2010.
- [TOA<sup>+</sup>96] Kiyoshi Takamasu, Satoshi Ozawa, Takayuki Asano, Akihiro Suzuki, Ryoshu Furutani, and Shigeo Ozono. Basic concepts of nano-CMM (coordinate measuring machine with nanometer resolution). In Jpn.-China Bilateral Symp. on Advanced Manufacturing Eng, Vol. 155, 1996.
- [WMB<sup>+</sup>95] M Weck, P McKeown, R Bonse, U Herbst, et al. Reduction and compensation of thermal errors in machine tools. CIRP annals, Vol. 44, No. 2, pp. 589–598, 1995.
- [Yab05] 矢生晋介, 清水伸二, 矢生晋介. 主軸パターン運転試験による工作機械熱変位

- の評価法. 精密工学会学術講演会講演論文集 2005 年度精密工学会秋季大会, pp. 29–30. 公益社団法人 精密工学会, 2005.
- [Yas78] 安井武司. 有限要素法による工作機械の剛性計算. 日本機械学会誌, Vol. 81, No. 713, pp. 336–341, 1978.
- [ZBMW21] Nico Zimmermann, Mario Breu, Josef Mayr, and Konrad Wegener. Autonomously triggered model updates for self-learning thermal error compensation. CIRP Annals, 2021.
- [ZLBM20] Nico Zimmermann, Sebastian Lang, Philip Blaser, and Josef Mayr. Adaptive input selection for thermal error compensation models. CIRP Annals, Vol. 69, No. 1, pp. 485–488, 2020.

# 公表論文

## 学術雑誌

- [1] Makoto Fujishima, Koichiro Narimatsu, Naruhiro Irino, Yutaka Ido. Thermal displacement reduction and compensation of a turning center, *CIRP Journal of Manufacturing Science and Technology*, Vol. 22, pp. 111–115, 2018.
- [2] Makoto Fujishima, Koichiro Narimatsu, Naruhiro Irino, Masahiko Mori, Soichi Ibaraki. Adaptive thermal displacement compensation method based on deep learning. *CIRP journal of manufacturing science and technology*, Vol. 25, pp. 22–25, 2019.
- [3] Makoto Fujishima, Masahiko Mori, Koichiro Narimatsu, Naruhiro Irino. Utilisation of IoT and sensing for machine tools, *Journal of Machine Engineering*, Vol. 19, No. 1, pp. 38–47, 2019.
- [4] 成松 宏一郎, 茨木 創一, 入野 成弘. 深層学習による工作機械の熱変位推定におけるセンサの故障に対するロバスト性の向上, *精密工学会誌*, Vol. 87, No. 8, pp. 698–703, 2021. Vol. 87, No. 8, 2021.

## 国際会議

- [5] Koichiro Narimatsu, Naruhiro Irino, Soichi Ibaraki. Adaptive thermal displacement compensation for turning center based on deep learning. The 8th International Conference of Asian Society for Precision Engineering and Nanotechnology (ASPEN), 2019.