

特集記事・8

鉄鋼業におけるAI・IoT技術の最前線

冷間圧延機のAI制御技術

AI Control Technology of Cold Rolling Mill

(株) 日立製作所
制御プラットフォーム統括本部
電機制御システム設計部 技師

高田敬規
Keiki Takata

(株) 日立製作所
制御プラットフォーム統括本部
電機制御システム設計部 主任技師

服部 哲
Satoshi Hattori

1 緒言

圧延設備においては、製品品質の高精度化、操業の安定化のため、種々の制御が導入され成果を上げている。適用されている制御技術についても、古典制御から最適制御、ファジィ理論やニューラルネットを用いたものまで多種多様である^{1,3)}。弊社においても、特に、板厚制御、形状制御の分野にて制御技術の開発を行ってきており、形状制御においては、AI技術を活用した制御技術を開発し、実機への適用を実施してきた。

制御技術の比較を図1に示す。新しい制御を考える場合には、制御精度の向上のみではなく、試運転時およびその後の調整作業の容易度、新しい鋼種が入ってきた場合の対応、オペレータノウハウが考慮可能か、制御系自体が学習していく自己調整能力の有無等も考慮する必要がある。

制御モデルを用いて制御対象の状態が最良となるように予測して制御する最適制御は、モデルの確立した対象に対しては、非常に有効であり、制御精度も高い。反面、モデルの作成が困難な対象の場合、不正確なモデルを用いて制御対象の動作を予測するため、制御精度は悪化する。また、最適制御を適用した場合、試運転時およびその後の調整が理論を良く理解

した人でないと困難であり、保守性が悪いという問題もある。

ファジィ制御を用いた場合、オペレータの操作方法を模擬して制御を実施するため、一定の制御精度が期待できる。また、制御ルールという形で制御方法が決められているので、保守が容易である。弊社が開発・実用化した、ファジィ制御とニューラルネットを組み合わせ、制御対象のパターン認識をニューラルネットで、認識結果を用いた推論をファジィ制御で行うニューロ・ファジィ制御は、通常のファジィ制御より更に理解しやすい制御方式となっている。

冷間圧延機の形状制御は、正確な制御モデルの作成が困難であり、元々はオペレータが手動操作で制御していた。従って、ファジィ制御やニューロ・ファジィ制御の適用対象として最適であると考え、ファジィ制御を適用したクーラント形状制御、およびニューロ・ファジィ制御とそれを適用したセンデミア圧延機の形状制御を実現してきた。

さらに近年、Deep Learning を適用したプラント制御技術を開発し、センデミアミルの形状制御において実機へ適用した。本制御は、制御系自体が操業の実績データより自動で学習していくため、自己調整力、ノウハウの導入に優れ、高い制御精度を実現することができる。

AI技術を用いた制御を実機に適用するには、上記の内容に加えて、制御の信頼性の確保が重要な課題となる。ここでは、冷間圧延機のAI技術として、ファジィ制御の概要とそれを適用したクーラント形状制御、およびニューロ・ファジィ制御とそれを適用したセンデミア圧延機の形状制御、さらにニューロ・ファジィ制御を発展させたDeep Learning適用プラント制御について、概要を説明し、それぞれの制御の信頼性を確保する為の方法について紹介する。

制御技術比較

制御方式	制御精度	調整容易度	新材料対応	ノウハウの導入	自己調整力	備考
古典制御	△	○	△	×	×	従来制御
最適制御	◎*	△	△	×	△	モデルの確立した対象用
ファジィ制御	○	○	△	○	×	定性的な制御用
ニューロファジィ制御	○	△	○	◎	△	パターン制御に最適
Deep Learning適用プラント制御	◎	○	○	◎	◎	複雑な制御も可能

*: モデル精度により×～◎となる

図1 制御技術の比較

2 ファジィ制御の概要と ファジィクーラント制御

ファジィ推論は、人間の行う定性的な推論を、定量的に扱う手法であり、これを用いて制御系を構成したファジィ制御は、圧延機の制御においては、セットアップ、板厚・張力干渉防止、形状制御等に用いられてきている。ファジィ制御はメンバーシップ関数により定量的な量を定性的な量に変換する部分（クラス分け）、定性的なルールから推論を行う部分（推論）、および複数の結論を統合して1つの結論を求め、定性的な量を定量的な量に変換する部分（評価）から構成される。

ファジィクーラント制御は、スポットクーラントを備えた圧延機で、圧延中に発生する圧延発熱で熱膨張したワークロールを冷却してワークロールの表面形状を変化させることで、出側形状を修正する。スポットクーラントは、通常形状検出器の検出器ピッチと同じ間隔（50mm ピッチ程度）で設置される。

スポットクーラントを噴射することによる冷却効果は、隣のゾーンまで影響するため、制御モデルとしては板幅方向の空間的变化を考える必要がある。また、一般的にスポットクーラントは、バルブのON/OFF制御となるので、オーバーシュートしないように形状の時間的变化も考慮する必要がある。

出側板形状が伸びているということは、その部分の圧下率が大きいという事であり、形状をよくするためにはその部分のクーラントを噴射し、ワークロールの表面形状を凹にしていれば伸びを抑制することができる。

ファジィクーラント制御では、各スポットクーラントのノズル位置における「クーラントを出したい度合い」（＝「クーラントを噴射したい方向に形状の悪い度合い」）を定量化する過程において、ファジィ推論を利用している。図2に示したように、各ノズル位置の形状検出値を元に「クーラントを

出したい度合い」を定量化することで各ゾーンを比較することができ、度合いの大きなものからスポットクーラントをONするノズルを決定する。

このファジィクーラント制御を実機に適用するにあたって、制御の開始時と収束間際には、全体的な形状偏差の発生量が異なっており、一定のメンバーシップ関数を用いた場合、クラス分けが不適当になる状況が発生しうる。この為、本制御においては、クラス分けされた結果に基づき、メンバーシップ関数を自動調整する機能を持たせ、常に安定したクラス分けを実現することで、制御機能の信頼性を確保している。

本方式を用いた形状制御は、制御操作端としてスポットクーラントが設置された冷間圧延機に適用され、成果を上げている。

3 ニューロ・ファジィ制御 (センデミア圧延機形状制御)

ニューロ・ファジィ制御は、ファジィ推論における前件部の主要な機能である定量的な量を定性的な量に変換する部分を、ニューラルネットを用いて行うものである。

ニューラルネットは、生物の神経細胞（ニューロン）を模倣したニューロンモデルを複雑に結合することによって、パターン認識や学習等の高度な機能を実現する。形状制御においては、形状のパターン認識を行うために多層型ニューロンを結合させたRumelhart型のニューラルネットを用いている²⁾。

図3に形状認識用のニューラルネットの一例を示す。形状検出器の出力が6ゾーン、認識したい形状パターンが4パターンの場合の例である。この場合、入力層が6個、出力層が4個のニューラルネット構成となる。ニューラルネットでパターン認識するには、まず学習を行う必要が有る。入力として認識させたいパターン、対応するパターンNoを設定し、ニューラルネットの出力が教師データと一致するように各層




図2 ファジィクーラント制御方法の概略

の間の重み係数を修正する。各パターンの入力に対して、出力の誤差が予め設定した範囲になるまでこの学習を繰り返す。

学習完了後のニューラルネットは、入力として認識したいパターンに類似したものが入ってきた場合、どのパターンに類似しているかを出力する。図3のようなパターンが入ってきた場合、パターン1が1.0に近い出力となり、他のパターンの出力はほぼ0となる。

ニューロ・ファジィ制御方法は、予め設定してある形状パターンに実形状がどの程度適合しているかをニューラルネットで認識する。次に、認識結果に基づき、ファジィ推論でどの操作端を操作すべきか推論を行い、操作端を決定する。最後に、圧延速度等の条件から、実際の操作端への制御出力量を決定する。

ニューロ・ファジィ制御における推論ルールの表現を図4に示す。前件部が基準形状と呼ばれる形状パターン、後件部が前件部の形状パターンが発生した場合の制御操作端の操作方法となる。オペレータの経験やノウハウ等を制御ルールに反映することで、オペレータの感覚と非常に合致した制御とすることができる。制御ルールは、オペレータにとって容易に理解可能な形であるため、調整作業が容易であるという特長もある。

ニューロ・ファジィ制御は、ニューラルネットでの演算を形状パターンの認識のみに限定することで、制御の信頼性を確保している。制御中は、ニューラルネットによる形状パターンの認識結果を監視することができ、制御の演算がオペレータの感覚に合致していることを確認できる。また、圧延中の形状は、0-1に正規化した値を入力とすることで、形状




図3 形状認識用のニューラルネットの学習

偏差の大小に関わらず、同じ制御ルールに基づく制御精度を実現している。

オペレータの経験・知識から制御ルールを設定する本ニューロ・ファジィ制御により、モデル化が困難な為の実施できなかったセンザミア圧延機の形状制御が実用化でき、これまで多数の納入実績がある。

4 Deep Learning 適用プラント制御

Deep Learning 適用プラント制御は、前述のニューロ・ファジィ制御における形状のパターン認識と制御ルールに基づく操作量演算とをDeep Learning で学習したネットワークで行うものである。図5にニューロ・ファジィ制御とDeep Learning 適用プラント制御の制御時における制御フローチャートを示す。ニューロ・ファジィ制御では、ニューラルネットでパターン認識させる形状パターンと、認識した形状パターンに対する制御操作端の制御方法（制御ルール）とを、予め設定しておく必要があった。ニューロ・ファジィ制御で制御できる形状は、設定した形状パターンに対してのみであり、設定外の形状に対しては、手動操作による細かな微調整が必要となり、オペレータの操作負担に加え、熟練度の差によって形状にばらつきが出るなどの課題があった。

Deep Learning 適用プラント制御は、形状パターンとそれに対する適切な操作方法（制御ルール）を、操業の実績データから自動で学習する。操業の実績データから、形状の修正に効果のあった操作量とその時の形状パターンとを学習用データとして抽出し、この学習用データの蓄積をDeep Learning に学習させることにより、多様な形状パターンとそれに対する操作方法（制御ルール）を学習する。これにより、Deep Learning 適用プラント制御は、圧延中の任意の形状パターンに対して、適切な操作方法を出力可能となり、形状制御の制御精度向上を実現できる。また、Deep Learning 適用




図4 ニューロ・ファジィ制御方式における推論ルールの表現

プラント制御では、入力する形状パターンをあえて正規化せず、検出値をそのまま入力値とすることで、全体的な形状偏差の大きな場合や小さな場合、それぞれで適切な操作方法を学習し、制御を実行させることが可能となっている。

Deep Learningは中間層の層数を多層化したニューラルネットを用いており、ニューロ・ファジィ制御で用いた従来のニューラルネットと比較して、より複雑な関係の学習が可能である。Deep Learningに関係を学習させたいデータ（学習用データ）を与え、Deep Learningはネットワーク内のパラメータ調整を繰り返し、自動で入出力データの関係性を学習する。図6に示すように、Deep Learning適用プラント制御では、学習時は、実績データから抽出した学習用データを用いて、形状パターンとそれに対する操作量の関係をネットワークに学習させる。制御時は、この学習済みのネットワークに現在発生している形状パターンを入力することで、ネットワークは学習した制御ルールに基づく操作量を出力するので、これに基づいて機器の操作を行う。学習済みのネットワークを用いた演算は短時間で実行可能であり、制御時の演算は従来のニューロ・ファジィ制御と同様の周期で実行可能である。

図7にDeep Learning適用プラント制御の学習機能と制御機能を含めた制御サイクルを示す。Deep Learning適用プラント制御の実用性を高めるために、重要な要素として、評価機能、トライアル操作機能、プラント保護機能がある。以下、それぞれについて説明する。

評価機能は、学習機能において、形状偏差と機器の操作量および、操作後の形状変化から評価を行い、学習用データとして抽出する。実績データから制御操作がより効果的なデータを取り出して学習に使用することにより、Deep Learning適用プラント制御の制御精度を向上させる。形状評価関数を変更することによって、圧延機ごとの操業の優先度や他工程との兼ね合いにおける制約条件などを反映し、各圧延機の操業条件に合う制御方法を実現することが可能である。

トライアル操作機能は、制御ルールが固定化するのを防ぎ、制御精度を向上させていくための機能である。一度、学習した制御を繰り返し出力するのみでは、ネットワークは新たな制御ルールを獲得できず、継続的に制御精度を向上させることができない。このような場合に対応するため、制御機能にはトライアル操作機能を有する。一定確率で、プラントに対してランダムな操作を与える事で、効果的であった場合




図5 ニューロ・ファジィ制御とDeep Learning適用プラント制御




図6 Deep Learningを用いた学習時と制御時のデータの流れ




図7 Deep Learning適用プラント制御の制御サイクル

には新たな制御ルールとして獲得し、ネットワークの制御精度を向上することができる。

プラント保護機能は、このAI技術を用いた制御技術を実機に適用するにあたって、信頼性を確保するために必要となる機能である。学習に使用する実績データの数が少なく、多くの形状パターンに対応した学習用データが揃っていない場合、ネットワークは未学習の形状パターンに対して、誤った操作を出力する可能性が考えられる。このような場合に対応するため、Deep Learning適用プラント制御の制御機能には、プラント保護機能が必要となる。これは、ネットワークの出力をプラントに出力する前に、物理モデルによるシミュレーションを行い、悪影響を与えるような場合には出力を遮断する機能である。これにより、教師データの蓄積が不十分な初期段階においても、プラントへの悪影響のリスクを最小にした状態で、Deep Learning適用プラント制御の適用ができ、実用の中で精度を高めて行くことが可能となる。

Deep Learning適用プラント制御を、センデミア圧延機の形状制御に適用し、制御精度の向上を確認している。

5 結言

以上、弊社で冷間圧延機の制御に用いたAI技術であるファジィ制御、ニューロ・ファジィ制御、Deep Learning適用プラント制御について説明した。冷間圧延機の形状制御は、制御モデルの作成が困難であり、かつオペレータが必要に応じて操作しているという点で、ファジィ制御、ニューロ・ファジィ制御等のAI技術を適用するには、最適の対象であり、これまでも長く使用されてきている。

今回、さらにDeep Learning適用プラント制御を開発し、実績データから制御ルールの自動学習が可能となり、従来のニューロ・ファジィ制御に比較して制御精度を更に向上させることができた。人による定量的・定性的な制御ルールの設定では制御精度が不十分な分野では、Deep Learning適用プラント制御の適用により更なる精度向上が期待できる。

参考文献

- 1) 片山恭紀, 服部哲, 岡田隆: 第147回塑性加工シンポジウム, 日本塑性加工学会, (1992), 1.
- 2) D.E.Rumelhart, G.E.Hinton and R.J.Williams: Nature, 323 (1986), 533.
- 3) 前田英樹, 堺俊夫, 服部哲, 中島正明: 塑性と加工, 32 (1991) 361, 136.

(2018年9月4日受付)