

AIによる鍛造設備故障診断システムの実用化

村野 正和* 平久 稔男* 遠藤 徹* 高橋 元*

抄 録

近年、鍛造設備は全自動生産が進み制御方式が複雑となり、設備故障時の原因特定に時間を要していた。そこでAIを用いてベテラン保全員が持つ暗黙知を形式知化し、設備故障診断システムの開発に取り組んだ。

その結果、故障原因の診断時間を削減するシステムの実用化に至ったので、ここに紹介する。

1. はじめに

近年、鍛造設備は搬送装置の全自動化が進み、高効率生産となっている。そのため、従来の設備に比べ制御方式が複雑になり、故障が発生した際の故障真因の特定が難しい。故障を修理する保全員が実施する故障診断の手順やそれに掛かる時間は、その保全員個々の知識・技能によって差が生じる。

今回、AIを使いベテラン保全員が持つスキル=暗黙知を織り込んだ設備故障診断システムを作成しMTTR (Mean Time To Repair : 平均復旧時間) 短縮の効果が得られたので紹介する。

2. 現状について

2.1 鍛造設備の現状

組立、鋳造、加工、鍛造設備のMTTR(平均復旧時間)をFig. 1に示す。鍛造設備は組立、鋳造、加工と比べ故障から復旧に要する時間が長い。

鍛造設備の故障復旧時間の作業割合をFig. 2に示す。鍛造設備の故障復旧時間の作業割合をみると修復時間の次に診断時間が長いことがわかる。

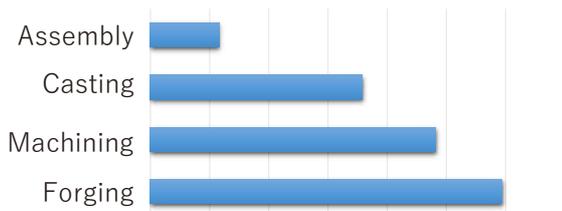


Fig. 1 Analysis of mean time to repair (MTTR)

組立設備は1990年代から自動化が進み設備構成が確立、蓄積したデータと技能が確実に伝承されており診断時間も短い。

一方、鍛造設備はここ10数年で急激に自動化が進み、既存の大型鍛造設備間を自動化、搬送装置で接続ラインが構成されている。制御方式の複雑化とあわせ故障原因も多岐にわたるため診断時間に保全員の熟練度の差が顕著に表れることが故障復旧時間を長くする要因となっている。

2.2 故障復旧方法

保全員が行っている故障復旧方法のフローをFig. 3に示す。ベテラン保全員と若手保全員の故障復旧に掛る時間を分析した結果、診断時間に40分の差があることがわかった。

このベテラン保全員と若手保全員との診断時間の差を明確にするため、ベテラン保全員に故障診断の手順の聞き取りを行いながら、下の3つの視点で比較し、何が違うのかの調査を行った。

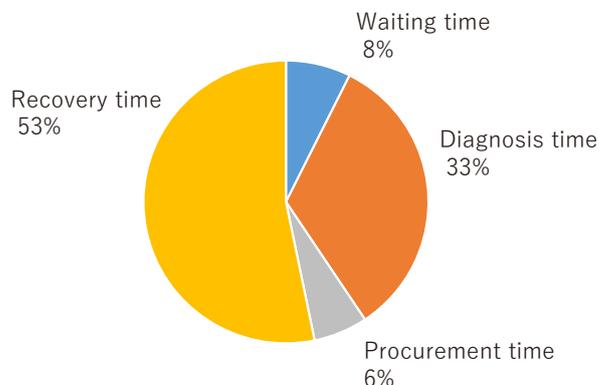


Fig. 2 Percentage breakdown by task of MTTR for forging equipment

* 工務部

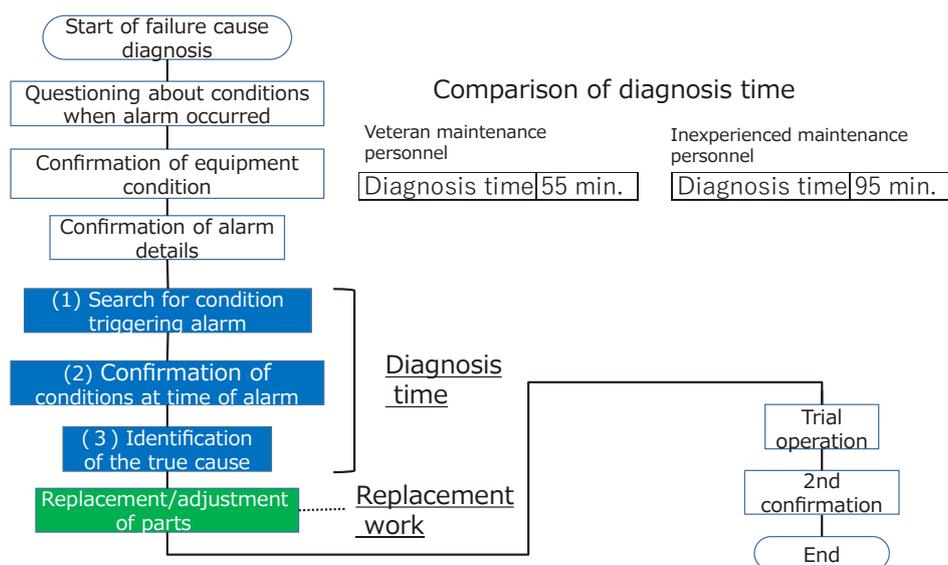


Fig. 3 Flow of failure recovery

(1) アラーム発生条件の探索

ベテラン保全員は現場に到着すると設備の状態とアラーム内容から、以前同じようなことが無かったかを考え、故障原因のいくつかの候補をあげる。

この候補の数が若手保全員との差となっていた。

(2) アラーム発生時の状態を確認

ベテラン保全員は日頃から正常に稼働している設備の状態をよく観察し記憶している。そして故障診断時はアラーム発生時の状況を再現させたり、設備を操作したりして、その動作や信号を正常時と比較することにより故障原因候補を絞り込んでいた。

この絞り込む時間の差が若手保全員との差となっていた。

(3) 故障原因の特定

ベテラン保全員は(1)や(2)の手法を使いながら頭の中でなぜなぜ分析を行い、原理原則に基づいて素早く故障の原因を特定していることがわかった。

この原因特定の正確さが若手保全員との差となっていた。

そこで、保全員の熟練度による診断時間の差を埋めるためモデルラインを設定し設備故障診断システムを開発することとした。

3. 設備故障診断システムの開発

3.1 開発のねらい

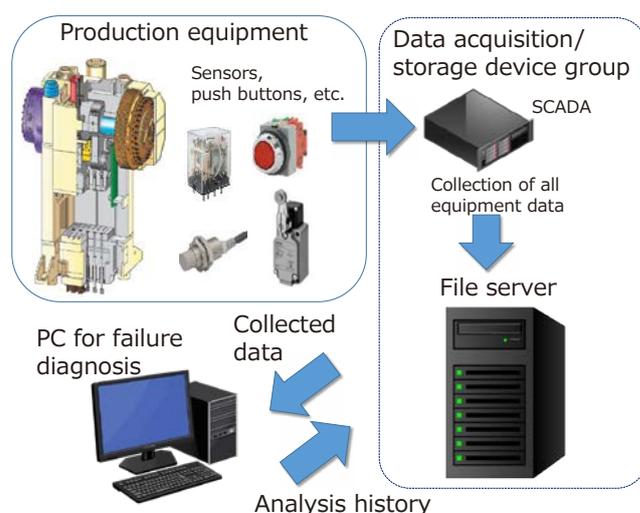
本設備故障診断システムの目的は、誰でも最短でベテラン保全員と同じ故障診断を行なえるようにすることであ

る。したがって、このシステムを活用することにより、ベテラン保全員の持っている知識技能が効率よく習得できるようになる。

3.2 システム構成

このシステムは設備の正常な状態を、AIに学習させ、アラームが発生した時に自動で故障原因を特定するものである。

システム構成図をFig. 4に示す。そのシステム構成は大きく2つからできており、設備に設置されたセンサや押しボ



SCADA (Supervisory Control and Data Acquisition)
This computer system provides remote centralized monitoring and control at one location of various production machines at the plant and elsewhere. It collects and centrally records data from sensors and other devices.

Fig. 4 System configuration

タンなどのデバイスの状態データをリアルタイムで収集するSCADAとそのデータを保存するファイルサーバから構成されるデータ取得装置群と、もう一つはサーバへ蓄積されたデータを使って故障分析をおこなうAIを搭載したPCである。このPCは、データのやり取りや学習、分析を行っている。

3.3 正常稼働データの学習方法

設備の正常な状態を学習させるため、ファイルサーバから設備のアラームが発生していない時の稼働データを、AIを搭載した故障分析PCに読み込む。

多量のデバイスデータを毎回計算して学習することは、故障分析PCのCPU負荷が大きくなるため、平均と分散の計算には「Welfordの方法」とよばれる方法を使った。その計算方法は前回の差分を算出して偏差としてサイクル線図に反映を繰り返す。学習したサイクル線図例をFig. 5に示す。サイクル線図の学習はセンサや押しボタンなど約8,000個の全てデバイスを1サイクル分、時系列データやタイミングを学習して標準偏差と現在のデータを波形として記録する。

なお、例として平均の「Welfordの方法」の計算式は以下のとおり。

$$\mu_n = \frac{1}{n} \sum_{i=1}^n x_i$$

上記の漸化式は以下のとおり。

$$\mu_{n+1} = \frac{1}{n+1} (x_{n+1} - \mu_n) + \mu_n$$

μ_{n+1} : 更新された平均

μ_n : 前回計算した平均

x_{n+1} : 新しく得られた収集データ

n : 収集データ数

3.4 故障原因別データベース

故障原因特定をより早く、正確におこなうために、これまでに発生した故障原因のデータベースを作成しておくことが重要となる。

故障履歴をリスト化し、アラームが発生したタイミングや故障毎の原因デバイスなどをまとめ、故障原因別データベースを作成した。

3.5 故障診断の仕組み

設備のアラームが発生した瞬間に“現在のサイクル線図”を輪切りにする。輪切りした“現在のサイクル線図”と“学習したサイクル線図”を比較して全てのデバイスデータから平均 $\pm 3\sigma$ を超えるデバイスを故障原因候補として絞り込む。

絞り込んだ故障原因候補と故障原因別データベースの原因と突き合わせ、マッチングしたデバイスを故障原因として特定する。マッチングしたデバイスが複数ある場合は、アラームが発生したタイミングをデータベースと突き合わせ、一致するデバイスを故障原因として特定する。

3.6 AI故障診断システムの効果

正常に稼働している状態を学習し、アラーム発生時にサイクル線図を比較することにより、故障原因候補の絞り込みが可能となった⁽¹⁾。またベテラン保全員の知見を活用することにより原因特定の判定精度を向上させた。

診断時間は保全員の熟練度に左右されることなく、最短で故障要因を探索できるシステムとなり、実用化に至った。システム導入後の診断時間改善結果をFig. 6に示す。

今回のシステムではベテラン保全員が持つ故障原因候補を絞り込む技能をAIで自動化することによりアラーム発

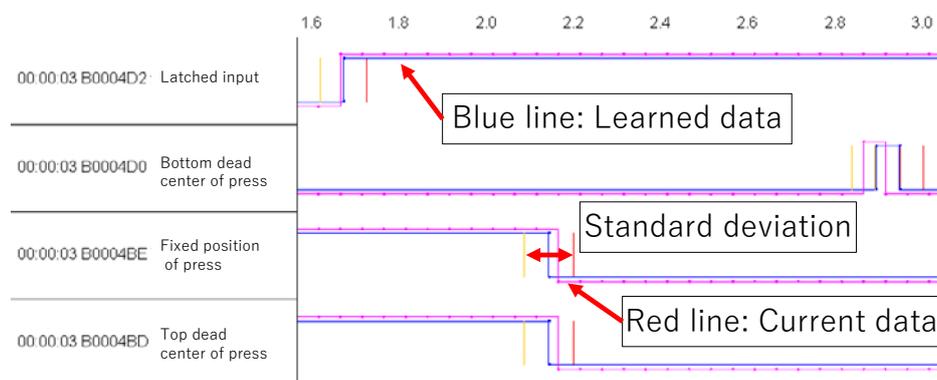


Fig. 5 Learning screen of a cycle diagram

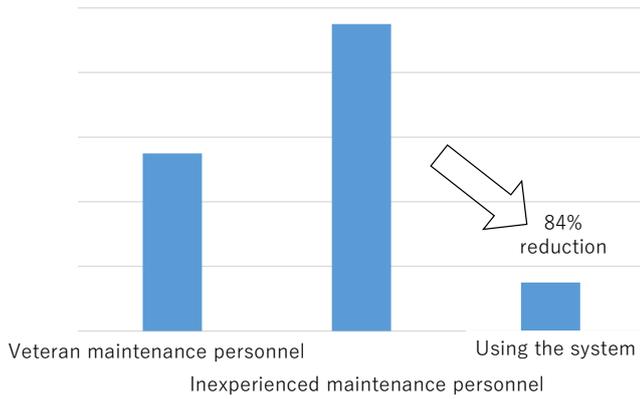


Fig. 6 Effect on improving diagnosis time

生時の状況再現や設備操作を省略でき、原因特定に辿り着く時間が大幅に短縮できた。

その結果、AI故障診断システムを使うことで故障診断時間を84%削減することができた。

4. 今後の課題

ベテラン保全員の故障診断方法の分析により、従来、保全員がどのようなロジックで故障原因の診断を行っているのかが分かりベテラン保全員が持つ暗黙知を形式知にすることができた。

今後は他の生産ラインにも水平展開を進め、このシステムを活用しながら従来、行なってきた教育方法についても改善していきたい。

5. 参考文献

- (1) 佐野容士他：ICTミリ秒分析による圧延条件の最適化，プラントエンジニア，日本プラントメンテナンス協会，第53巻 第12号

■ 著者 ■



村野 正和



平久 稔男



遠藤 徹



高橋 元