

交換研究員派遣研究成果  
総合情報学部 塩谷隆二

## 1. Introduction

派遣先の研究センター、CREWE (Centre for Research into Energy, Waste and the Environment) では、低炭素経済への移行中に効率的、信頼性の高い、熱および発電を提供することに焦点をあて、炭素回収技術または燃料供給の脱炭素化による炭素ベースの熱および発電システム(石炭、ガス、石油)の影響の緩和、海洋およびバイオマス由来の電力などの再生可能エネルギー源の開発と効率の向上を研究テーマとしている。水素やアンモニアなどの化学エネルギー貯蔵、および関連する研究も含まれ、従来の燃料の使用と新しいエネルギー技術の導入には、さまざまなリスクと慎重な管理が必要であり、エネルギーは供給/需要ベースで検討できるが、これは体系的な管理プロセスによって制御される必要がある。現在および将来のエネルギー使用が健康、安全、環境管理に与える影響を分析することが不可欠であり、研究センターでは、従来の燃料源と代替燃料源の危険特性、エネルギー需要の高いレジューセンターと病院のエネルギー調査と監査、および廃棄物からエネルギーへの計画を行っている。現在の推定では、英国の電力需要の最大 12% が都市固形廃棄物 (MSW) から生成される可能性があることが示唆されており、研究センターは、新しい燃料と推進技術を輸送部門、主に自動車産業と航空宇宙産業に適用することにも重点を置いている。輸送部門は、工業部門や住宅部門とは対照的に、現在 CO2 排出量が増加しているため、持続可能なエネルギー経済への移行において、おそらく最も困難な分野となっている。エネルギーシステムの理解を深めるために、新しい数学的手法と新しいレーザー診断および実験技術の開発を行い、基本的な流体力学と熱力学のプロセスを調査している。

研究センターで実施されているプロジェクトの 1 つに、ガスタービンによる炭素回収のための選択的排気ガス再循環プロジェクトがある。これは、UK-CCS コンソーシアムを通じて、排気ガス再循環がガスタービンの燃焼プロセスに与える影響を調査し、システム全体のパフォーマンスの最適化を目指すものである。このプロジェクトでは、非予混合燃料フレキシブルバーナーが高温環境下での可変スワール排出に与える影響について研究が行われ、低スワール/高圧条件下では NH<sub>3</sub>/H<sub>2</sub> 混合が純 H<sub>2</sub> よりも優れ、NO 濃度が低くなることを解明している。この問題は、スワール数、温度、ガス濃度などのパラメータ最適化問題であり、最適なパラメータ計算システムの開発が重要となる。

これまで電力配電システムにおいて送変電設備として重要な役割を果たす基幹機器である変圧器の内部故障を早期に検出するための油中ガス分析 AI 診断法を開発してきた。これらの技術を、ガスタービンの問題に適用し、その有効性を検証した。

## 2. Artificial Intelligence Method for Power Transformer Dissolved Gas Analysis [1]

油中ガス分析 AI 診断手法の概要は以下の通りである。油入変圧器は、電力システムにおいて最も重要な機器の一つである。電力変圧器の安全で安定した動作は、電力システム

の安全で信頼性の高い動作を促進する。停電を防ぐためには、変圧器の初期故障を早期に検出することが不可欠である。一方動作中の変圧器は、電氣的、熱的、機械的ストレスなど、さまざまな種類のストレスの影響を常に受けている。これらの内部ストレスが巻線やコアに負荷をかけると、損失が発生し熱に変わる。発熱により油や電気絶縁材が分解され、油入変圧器で絶縁破壊や局所過熱などの異常現象が発生し、分解効果が増大し、分解により「故障ガス」と呼ばれるさまざまな種類のガスが生成される。IEC規格によれば、通常最も一般的に測定される「故障ガス」はH<sub>2</sub>（水素）、CH<sub>4</sub>（メタン）、C<sub>2</sub>H<sub>4</sub>（エチレン）、C<sub>2</sub>H<sub>6</sub>（エタン）、C<sub>2</sub>H<sub>2</sub>（アセチレン）、CO（一酸化炭素）およびCO<sub>2</sub>（二酸化炭素）である。さらに、これらのガスの一部は、通常の運転状態でも発生する。実際、変圧器は使用される材料、製造プロセスおよび絶縁油の劣化または経年変化により、通常の条件下でも可燃性ガスとCO<sub>2</sub>を徐々に生成する。例えば、変圧器の耐用年数の初期段階では、かなりの量のH<sub>2</sub>とCOが検出されることがある。故障の原因となるプロセスが異なると、異なるガス混合物が生成されることがわかっており、さらに、同じ故障プロセスでも、内部熱エネルギーの違いにより、生成されるガスの量が異なる。

油中ガス分析法(DGA: Dissolved Gas Analysis)は、絶縁液で満たされた電気機器の故障を検出および評価するための最も広く使用されている診断手法である。ただし、DGAの結果の解釈は複雑な場合が多く、経験豊富な絶縁保守担当者が関与して常に慎重に行う必要がある。機器の種類やネットワークによって、運用方法（負荷レベル、気候など）に応じて標準値が異なるとされている。IEC規格を適用する場合、これに十分注意する必要がある。IEC国際規格(International Electrotechnical Commission International Standards)を使用して日本電気技術研究協会(ETRA: Electric Technology Research Association)データベースをテストし、ETRA方式を使用してIEC TC 10データベースをテストした。IEC規格は、世界中の15を超える個別のネットワークから収集されたIEC TC 10データベースに基づいており、ETRA方式は、日本の国内電力変圧器から収集されたETRAデータベースに基づいている。IEC規格で推奨されているように、各グリッドが独自のデータを収集できる場合、異なるネットワークは独自の標準値を確立する必要がある。これらすべてがDGA法の適用の難しさを増している。

この問題を解決するため、電力変圧器の障害のインテリジェント診断に、多層パーセプトロン(MLP)と呼ばれる人工知能(AI)技術を適用した。この方法は、それぞれIEC TC 10とETRAのデータベースに適用され、IECまたはETRAデータベースのみでトレーニングされた分析モデルが、別のデータベースに適用された場合でも予測の精度を維持できることを示しており、この方法の有効性を示した。

## 2.1 Traditional Diagnostic Technology

長期にわたる実践と統計に基づいて、変圧器の故障を分析する方法は以下の通りである。現在、電力変圧器の故障の診断には、油中ガス分析(DGA)が広く使用されている。油入変圧器の故障診断に使用される多くの診断方法は、IEEE C57.104 [1]、IEC 60599 [3]、および日本電気技術研究協会(ETRA)の方法 [2] など、DGAに基づいている。これらの標準と方法で使用されるDGA方法は、主に3つのカテゴリに分類される(表1)。表1に示すように、キーガス法とガスパターン法では、特定のガス濃度(ppm)を使用して電力変圧器

の故障を診断する。Doernenburg 比法，Roger 比法，IEC 比法および ETRA ガス比法では，さまざまな炭化水素ガス濃度比を使用して故障の種類を判断する。これらの特定のガスおよびガス比法とは異なり，デュバルトライアングル法では，3つのガス(C<sub>2</sub>H<sub>2</sub>, C<sub>2</sub>H<sub>4</sub>, CH<sub>4</sub>)の相対的な割合を観測値として使用する。DGA は電力変圧器の故障を診断するための比較的簡単でシンプルな方法だが，異なる手法では，通常，実際のデータで異なる結果が得られる。場合によっては特定のガスの組み合わせが，これらの方法ではカバーされていないこともある。故障の分析には高度な技術を備えた変圧器エンジニアリングが依然として必要となる。したがって，故障診断方法を向上させるにはさらなる研究が必要となる。

Table 1. Conventional DGA methods.

Categories	DGA methods	Collected and analyzed gases and gas ratios
Specific gas	Key gas technique (IEEE, IEC)	H <sub>2</sub> , CH <sub>4</sub> , C <sub>2</sub> H <sub>6</sub> , C <sub>2</sub> H <sub>4</sub> , C <sub>2</sub> H <sub>2</sub> , CO and CO <sub>2</sub>
	Gas pattern method (ETRA)	H <sub>2</sub> , CH <sub>4</sub> , C <sub>2</sub> H <sub>2</sub> , C <sub>2</sub> H <sub>4</sub> and C <sub>2</sub> H <sub>6</sub>
Gas ratio	Doernenburg ratio method (IEEE)	CH <sub>4</sub> /H <sub>2</sub> , C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub> , C <sub>2</sub> H <sub>2</sub> /CH <sub>4</sub> and C <sub>2</sub> H <sub>6</sub> / C <sub>2</sub> H <sub>2</sub>
	Roger ratio method (IEEE)	CH <sub>4</sub> /H <sub>2</sub> , C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub> and C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>6</sub>
	IEC ratio method (IEC)	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub> , CH <sub>4</sub> /H <sub>2</sub> and C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>
	ETRA gas ratio method Diagnostic chart A (ETRA)	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub> and C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>
	ETRA gas ratio method Diagnostic chart B (ETRA)	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub> and C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>6</sub>
Gas percentage	Duval triangle method	% C <sub>2</sub> H <sub>2</sub> , %C <sub>2</sub> H <sub>4</sub> and %CH <sub>4</sub>

日本では ETRA が現場で国内の変圧器の多くの DGA 診断を収集し評価をおこなっている。この研究に基づいて，ETRA は電力変圧器の故障を診断するための診断チャート A と B と呼ばれる 2 つの診断チャートを含む ETRA ガス比法を提案した。診断チャート A と B は，3つのガス (C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>6</sub>, C<sub>2</sub>H<sub>2</sub>)の濃度比に基づいて変圧器の故障を分類する。診断チャート A と B は，それぞれ C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> と C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub>, C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>6</sub> を使用している。ここでは，ETRA によって収集されたデータベースを使用し，診断チャート B の診断精度を判断した。診断結果は「過熱」「放電」「放電を伴う過熱」の 3 つの故障診断を行った。これらの故障診断はある程度区別できるが，各診断領域に重複部分が存在するため，診断精度を十分に判断することは容易ではない。

## 2.2 Using AI Technology for Dissolved Gas Analysis

従来の技術を 1 つだけ使用して障害診断を行うことは難しいため，障害の影響を解釈するには，複数の技術と人間の専門知識を組み合わせる必要がある。最近では AI の発展により，人工ニューラルネットワーク(ANN)，サポートベクターマシン(SVM)，ファジーロジックなど，DGA に基づくいくつかのインテリジェント診断方法が開発されている。これらの研究では，独自のコーディングを使用して障害を識別するために ANN を採用している。残念ながら，これらの研究の多くは公開データセットで利用可能なデータを使用しておらず，これらの手法を再現することは困難である。さらに，ほとんどの機械学習アプロ

ーチは、データの表現の1つまたは2つのレイヤーのみを学習することに焦点を当てる傾向があり、SVMや決定木などの浅い学習と呼ばれることもある。このようなアプローチでは、通常、機能エンジニアリングを使用してパフォーマンスを向上させる必要がある。ここで、機能エンジニアリングとは、データに固有の既存の生の特徴から関連する特徴を作成しようとするものである。一方深層学習は、浅い学習よりも連続するレイヤーの学習に重点を置いている。ディープラーニングでは、アーキテクチャの1つとして多層パーセプトロン(MLP)が知られている。MLPは多数の層を持つフィードフォワードANNの一種で、ディープニューラルネットワークの一種であり、分類や回帰の作業に使用されている。ディープラーニングライブラリ Keras のおかげで、強力なディープニューラルネットワークの構築は比較的簡単でシンプルになった。Keras は、Python で記述された高レベルのニューラルネットワークインターフェイスで、Tensorflow, CNTK または Theano 上で実行される。ライブラリは畳み込みネットワークと再帰ネットワーク、およびこの2つの組み合わせをサポートしている。モジュール性によりニューラルレイヤー、コスト関数、オプティマイザー、アクティブ関数などのすべてのスタンドアロンモジュールを組み合わせることで、新しいモデルを容易に作成できる。ここでは、トレーニングとテストに2つの公開データセットを使用し、MLPを適用して電力変圧器の障害を予測した結果を紹介する。

### 2.3 Comparison results of conventional DGA methods and AI technology for DGA

従来のDGA法とAI技術を搭載したDGA法の結果を比較するために、ETRA法とIECガス比法を使用して、2つのデータセットの障害タイプを識別した。データセットと手法の組み合わせとして、ETRAデータセットを用いてETRA法とIEC法を使用し、IEC TC 10データセットを用いてETRA法とIEC法を使用の2つの組み合わせを行った。各方法で、そのデータセットを使用すると良好な結果が得られることがわかった。これはIEC方式で最も顕著で、精度はETRAデータセットでは65.6%であったが、IEC TC 10データセットでは84.5%に達した。ただし、AI手法では、IEC TC 10データベースでトレーニングされたMLPモデルの精度は、IEC TC 10データセットで100%に達しており、ETRAデータセットでは96.7%となった。ETRA法の場合、ETRAデータセットで精度は98.4%、C<sub>2</sub>H<sub>2</sub>の0.5ppmなどのIECよりも低い厳しい値では91.4%であった。ETRA法によると、収集されたC<sub>2</sub>H<sub>2</sub>ガスの精度が向上し、特に提案された診断チャートBを使用すると、現象をよりよく理解できるようになる。また、データベースでテストされた方法を比較する観点から、AI手法の識別精度は従来のDGA方法の精度を上回る結果が得られた。

### 3. Variable Swirl on Emissions in a Non-Premixed Fuel-Flexible Burner [2]

将来のエネルギー需要を支えるために再生可能な方法で生成されたNH<sub>3</sub>の応用に対する関心が高まっているが、特にNO<sub>x</sub>排出量を削減するには、燃焼器の設計と戦略にかなりの開発が必要となっている。乱流スワールバーナーを使用して、予混合NH<sub>3</sub>/H<sub>2</sub>/空気炎による運用上のNO<sub>x</sub>削減の潜在的な経路を実験的かつ数値的に評価したデータが得られているので、このデータについてAI技術の応用について、検討を行った。

タービン内の反応物は圧力と湿度のパラメータ変更を行った高温下で供給される。排気ガス測定と反応器ネットワークモデルによる化学反応速度シミュレーションの間に好まし

い一致が実証されており，NO<sub>x</sub> 排出量は運用当量比に敏感で，実験範囲全体で数桁増加することが示されている．最も低い NO<sub>x</sub> 濃度は最も濃厚な条件で達成され，生成物ストリーム中の未燃焼燃料の割合が高くなっている．燃焼器圧力の上昇により，主に NH<sub>2</sub> 生成の増加とそれに続く炎後領域での NO 消費により，排気 NO<sub>x</sub> 濃度が大幅に減少している．この燃料で初めて反応物の加湿が詳細に分析され，拡張ゼルドビッチ機構により熱経路を制限する NO<sub>x</sub> 生成が低減することが示された．OH 生成 NH<sub>2</sub> の増加により後炎域での NO 消費も促進され，圧力と相まって排気 NH<sub>3</sub> 濃度の上昇をもたらしている．この影響は比較的小さいものであったが，NO<sub>x</sub> ペナルティなしで未燃燃料分率を低減するために，より希薄な加湿運転を使用できることを意味している．排出ガス性能は，燃料の燃焼を改善するために二次気流を使用する段階燃焼の適用によってさらに改善されている．湿度と圧力は段階構成で最適化され，全体的に希薄当量比で，サンプリングされた NO<sub>x</sub> および NH<sub>3</sub> 排気分率がそれぞれ 32 および 50ppmvd(15% O<sub>2</sub>)で動作している．二次空気の混合を改善し，周囲圧力を高めることで，システムをさらに最適化できる余地があり，これらのデータに対して AI 最適化の検討を行った．

### 3.1 Experimental specification

実験に用いたデータは次の通りである．NH<sub>3</sub>/H<sub>2</sub> 比率が 70/30% mol の燃料ブレンドを用いて代替比率が評価され，選択されたブレンドは，フラッシュバックの感受性(過剰な H<sub>2</sub> (> 40%))より濃い条件での吹き出し安定性の中で，最も安定したパフォーマンスを提供することが示された．この比率は，予混合 CH<sub>4</sub> 炎に類似した動作をすることも示されており，採用されたバーナーは CH<sub>4</sub>/空気混合物を使用して広範囲に特性評価されている．ベースライン条件は，燃焼器圧力 0.105MPaa (P1) で熱出力 25kWn，補助蒸気追加または二次空気流なしである．当量比は，NH<sub>3</sub>/H<sub>2</sub> 混合物の化学量論的燃料空気比 ( $\phi = \text{燃料空気} / \text{燃料空気化学量論}$ ,  $0.3 \text{ H}_2 + 0.7 \text{ NH}_3 + 0.675 \text{ O}_2 + 2.54 \text{ N}_2 \rightarrow 1.35 \text{ H}_2\text{O} + 2.89 \text{ N}_2$ ) を基準として計算され，最初は  $\phi = 1 \sim 1.4$  の範囲で追跡され，湿度，圧力，二次空気流量を個別に変更した詳細なパラメトリックスタディのために， $\phi = 1.2, 1.25$ ，および 1.3 (空気流量 6.56, 6.30, および 6.06g/sec) の値が選択されている．蒸気は，4 つの異なる加湿率で導入された(WL1=0, WL2=0.2, WL3=0.4, WL4=0.6g/sec)．これらは， $\phi = 1.2$  で全体の反応物分率が 0, 3.43, 6.63, 9.63% mol に相当し，空気流量の低下により  $\phi$  とともにわずかに上昇する．段階燃焼の二次空気負荷は，ベースライン燃焼器空気流量の約 50%と約 100%に指定された (SA1=0, SA2=3, SA3=6g/sec)．圧力は，P1=0.105, P2=0.131, P3=0.158, P4=0.184MPa の範囲で増加し，すべての流量は密度の変化に応じて調整され，同等のノズル出口速度と燃焼器内の滞留時間を維持している．最高圧力仕様は，最大持続可能 NH<sub>3</sub> 蒸気流量 1.8g/sec によって決まり，この時点で現在の動作が制限される．流量が増加すると，NH<sub>3</sub> の膨張によりドラム温度が低下し，供給蒸気圧が制限される．燃焼器入口温度は 423±5K に維持されている．

### 3.2 Results of experiment

先行研究[2]により得られた結果を以下に示す．圧力と水負荷のベースライン条件では，実験的範囲が 1~1.4 に広げられた  $\phi$  を横軸，NO<sub>x</sub> 濃度を縦軸に図示した結果を Fig. 1 に示す(NH<sub>3</sub> データは元の指定範囲内でのみ取得されている)．サンプルの NO<sub>x</sub> 濃度とモデ

ル化予測値(両方とも同等の条件に正規化)の間には良好な一致が見られる.  $\text{NH}_3$  データの場合は, 若干大きな差異があり, 濃い混合物で達成可能な低  $\text{NO}_x$  濃度では未燃焼燃料による効率の低下を招くことがわかった.  $\text{NO}_x$  の削減は, 火炎帯でのゼルドビッチ機構による熱生成の減少と, 火炎後帯での  $\text{NO}$  消費の組み合わせによって達成している. モデル化された入口温度は,  $\phi = 1.3$  条件では 515K まで上昇した( $\phi = 1.2$  の場合とほぼ同等の AFT が得られた). この熱効果により  $\text{NO}_x$  生成物の割合が約 2 倍になったが, それでも元の  $\phi = 1.2$  の場合の 10% 未満にとどまっている. より濃い  $\phi$  での  $\text{NH}_3$  の相対的增加は, 後炎領域での  $\text{NH}_2$  の大幅な増加にもつながり, 連鎖反応  $\text{NH}_2 + \text{NO} \leftrightarrow \text{NNH} + \text{OH}$  と終了反応  $\text{NH}_2 + \text{NO} \leftrightarrow \text{H}_2\text{O} + \text{N}_2$  によって  $\text{NO}$  消費が促進されている. 実験的  $\phi$  の範囲は, 過剰な未燃焼  $\text{H}_2$  および/または  $\text{NH}_3$  無しで好ましい  $\text{NO}_x$  濃度 (<500ppmvd) を生成する構成に焦点を当てた実験のために  $\phi = 1.2-1.3$  に制限している.

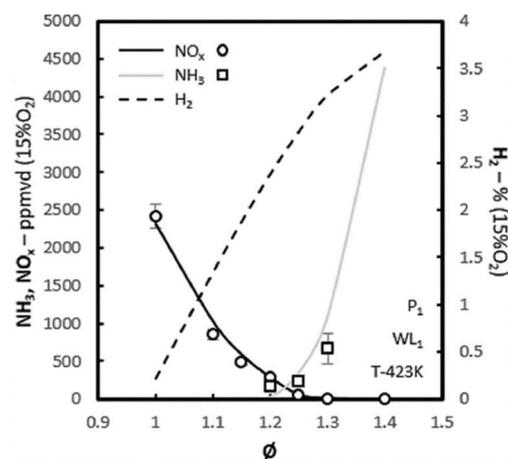


Fig. 1 Experimental (markers) and modelled (lines)  $\text{NO}_x$ ,  $\text{NH}_3$  and  $\text{H}_2$  concentrations against  $\phi$  at baseline conditions.

#### 4. Study of application of AI methods

上記実験に使用した, 湿度, 圧力, 二次空気流量を入力データとし,  $\text{NO}_x$  濃度を出力データとする MLP モデルを構築し, 実験データを用いて学習を行った. MLP モデルは Keras ライブラリを使用し構築し, Keras の各モデルは, レイヤーのシーケンスとして定義した. MLP モデルには, 1つの入力層, 1つの中間層および1つの出力層が含まれる. ReLU が中間層の活性化関数として使用し, 最終的な出力層は 2つの障害タイプを分類するためのソフトマックス関数を使用した.

ここで, 学習に使用可能なデータセットの数が 14 セットと, 極めて少ないことが判明し, 実験によるデータ取得が容易ではないため, 14 セット(12 セットを学習データ, 2 セットをテストデータ)を使用した. また, 比較検証用に, 模擬的にデータ拡張を行い, データセットを 10 倍に増加させ 140 セット(120 セットを学習データ, 20 セットをテストデータ)によるケースについても計算した. Fig.2 に 14 セット, Fig.3 に 140 セットの結果を示す. それぞれ青色が学習データを用いた検証結果の値, 橙色がテストデータによる結果, 左図が正解率, 右が収束モデルの収束性を示す loss 値を示している. 表 2 に収束値の値を示している. 学習データ数が不足している状況ではあるが, データ拡張を行うことにより,

テストデータでの検証では、正解率が 0.25 から 0.5 と 2 倍の精度向上が得られた。loss 値についても、15%程の改善が見られた。しかし、圧倒的にデータ数不足であり、十分な収束が得られていない。本プロジェクトでの実験は進行中のため、今後も実験データを取得し、データセット数の増加に伴い、精度改善は期待できる。しかし、実験の代わりとしての予測システム構築には、検討課題が残っているため、この点の解明を引き続き行っていく予定である。

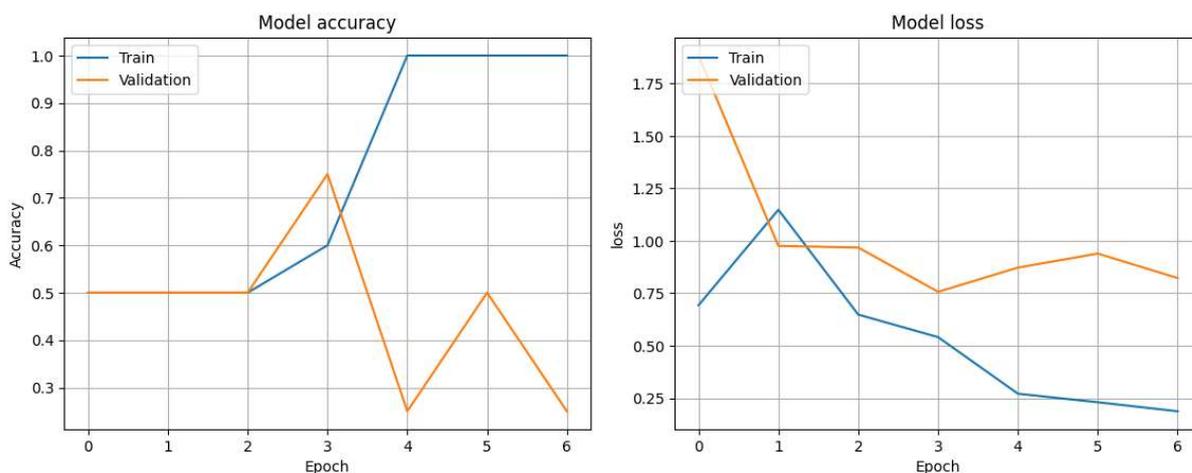


Fig. 2 Model Accuracy(left) and loss value(right) of 14 data set case.

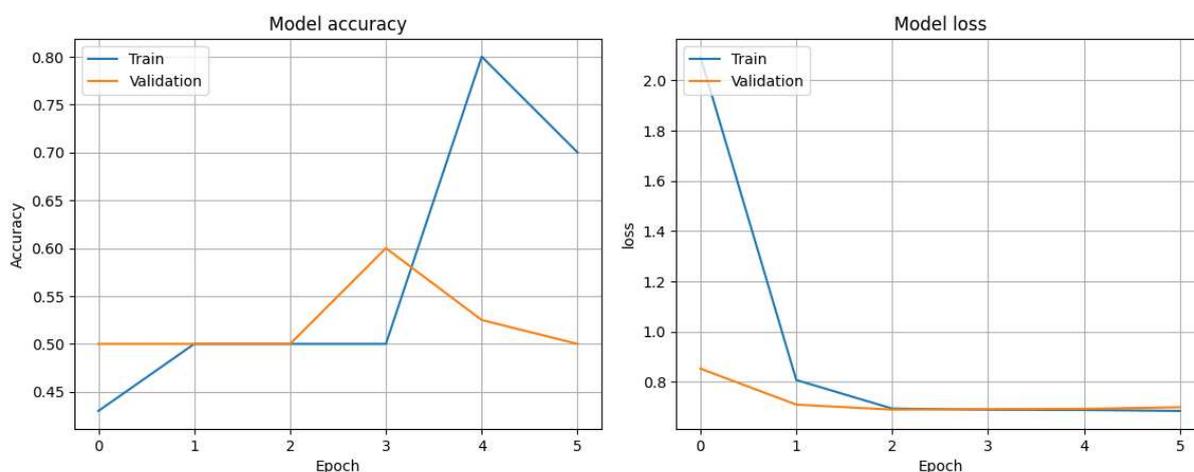


Fig. 3 Model Accuracy(left) and loss value(right) of 140 data set case.

Table 2. Comparison of 2 models.

Data set	14	140
Test loss	0.8223	0.6981
Test accuracy	0.25	0.5

## References

- [1] Hongjie Zheng, Ryuji Shioya, A Comparison between Artificial Intelligence Method and Standard Diagnosis

Methods for Power Transformer Dissolved Gas Analysis Using Two Public Databases, *IEEJ Trans* 2020, DOI:10.1002/tee.23197.

- [2] Pugh, D., Bowen, P., Valera-Medina, A., Giles, A., Runyon, J. and Marsh, R., Influence of steam addition and elevated ambient conditions on NO<sub>x</sub> reduction in a staged premixed swirling NH<sub>3</sub>/H<sub>2</sub> flame, *Proceedings of the Combustion Institute* 37(4), pp. 5401-5409,2019, DIO:10.1016/j.proci.2018.07.091.