

第4章 計画・設計

第1節 導入計画

§ 16 計画の手順

本技術の導入計画にあたっては、導入対象の下水処理場の現状および課題等を把握した上で、設計計算や設備計画の検討を行い、その結果に基づいた導入効果の検証を行う。

【解説】

本手順は、既存施設への導入を前提としている。導入計画にあたっては、対象となる下水処理場の基本事項を検討した後、運転操作方法の対象を設定し必要なデータ量からハードウェア構成を定める。続いて設備計画の検討を実施し、導入効果の検証を行う。




図 4-1 導入手順

§ 17 基本事項の把握

本技術の計画、設計に必要な情報を入手し、基本事項を定める。

(1) 水量（日最大、日平均、日間変動、年間変動）

現在の季節変動を含む流入汚水量と、各下水道計画に基づく将来予測

(2) 実績水質、水温

導入にあたって求められる水質

(3) 水質基準、規制値、目標値

法令に基づく規制値、総量規制値、運転管理目標、その他規制値

(4) 既存施設の仕様

水処理フローや系列数、制御方法、設定項目、その他の仕様

(5) 運用方法の確認

設定変更に対する考え方

【解 説】

(1) 水量（日最大、日平均、日間変動、年間変動）

運転範囲を明確にするため、過去の流入汚水量を把握する。日間変動は本システムの安定運転に必要な情報である。また、流入汚水量の将来予測は、AI 推論の維持管理計画に必要な情報である。

(2) 実績水質、水温

水質の対応範囲を明確にするため、水質制御目標である BOD、SS、T-N、T-P を中心に pH、NH₄-N、PO₄-P、SV 等も把握することが望ましい。生物処理は水温の影響を受けるため、年間の水温変化を把握し、最低水温となる月の運転状況には特に注意する。

(3) 水質基準、規制値、目標値

法令に基づく規制値、総量規制値、運転管理目標、その他規制値等を確認する。特に運転管理目標については、経年的に変更されている場合があるため、留意する。

(4) 既存施設の仕様

水処理フローや系列数、DO や送風量、返送汚泥量等の制御（自動又は手動調整を含む）方法、設定項目及びそれらの変更頻度に加え、既存水処理施設の寸法についても考慮する。省エネを指向する場合、ブロワ台数の運転停止となる条件（送風量等）や送風機制御方法についても把握し、実質的な電力量削減効果が得られるよう留意する。

画像を考慮した運転を実施する場合、カメラの設置箇所（既存設備がある場合には流用することを含め）について把握する。

(5) 運用方法の確認

水質の維持について目標値を達成すればよいか、季節毎に目標が変わるのかを把握する。法令順守は最優先事項として、水質目標達成の優先順位についても把握する。

§ 18 AI 推論対象

AI 推論の対象は、電力量や薬品使用量を削減し処理水質を維持するための熟練技術者のノウハウとして残したい項目を選定する。

【解 説】

本技術を適用する目的は、熟練技術者がノウハウとして有する水質の維持、電力量や薬品使用量の削減に関する運転技術を AI で提示することであるため、その目的を達成する中で重要と思われる項目を選定する。

例えば、AI 推論の対象としては、運転決定に多くの判断材料を必要とする DO 設定や送風量設定が代表的である。水質を維持するためには返送汚泥量や余剰汚泥量、次亜塩素酸ナトリウム注入率を操作する。リン除去については、生物学的リン除去を行うこともあれば凝集剤注入で対応する場合もあるため、必要に応じて選定する。

§ 19 AI 推論に必要な情報

AI 推論に必要な情報としては、通常の水処理運転判断で使用している観測データや過去の設定変更履歴、施設データ、運転目標を標準とする。

【解説】

AI 推論を実施するためには、当該処理場の運用状況を把握する必要がある。具体的には、以下の項目のデータを使用する。なお、対象とする下水処理場の運転判断時に使用しているデータが含まれていればよく、以下に示すデータが全て必要ということではない。既存のデータ及びそれらの取得頻度で安定して運用できていれば、AI 構築のためにデータ収集量や頻度を変更する必要はない。

(1) 水処理の運転判断で使用している観測データ

- ・水量関係：流入水量、処理水量、返送汚泥量、余剰汚泥量 等
- ・空気量関係：送風量
- ・流入水質関係：BOD、SS、pH、T-N、T-P 等
- ・処理水質：BOD、SS、透視度、COD、T-N、T-P、大腸菌群数、NH₄-N、NO₂-N、NO₃-N、PO₄-P 等
- ・その他：反応タンク SV、MLSS、終沈汚泥界面、画像 等
- ・オンラインデータは運転操作の迅速性や測定結果の安定性に寄与するため、ある方がよい。

(2) 過去の設定変更履歴

- ・AI 推論で導出したい項目の操作履歴として、DO 設定、送風量設定、返送汚泥量設定、余剰汚泥量設定、次亜塩素酸ナトリウム注入率設定、PAC 注入率設定、攪拌機運転設定 等
- ・上記以外の設定変更履歴

例えば、BOD を目標とした AI 運転では、空気量や送風量を AI 推論する場合、返送汚泥量や余剰汚泥量、消毒剤注入率も併せて変更する場合があるため、処理場の運転方針に応じて必要な項目を選定する。

(3) 施設データ

- ・HRT や SRT 等を参考にして運転する場合には、池の容量や施設の運用停止等の情報が必要。

(4) 運転目標

- ・法令で定められている BOD や SS 等の他、独自の運転目標を定めている場合には、それらの目標値
- ・AI 推論で設定可能な目標値は、AI が学習した過去の運転実績の範囲を原則とする。
- ・必要空気量や処理水質目標の余裕等から設定値の変更でも水質の維持が可能と見込まれる場合には、それらの値を目標値として設定する。

目標値は経年で変更する場合があるため、学習データ作成時には、特に留意する。

§ 20 データの取り扱い

データの取り扱いについては、次の点について留意する。

- (1) 監視装置からデータを取得する場合には、監視装置内のデータを破損しないこと**
- (2) 各種データが外部に漏れないよう必要な策を講じること**
- (3) AI 推論に適した前処理を行うこと**

【解 説】

AI 推論においては、収集したデータや運用データを大量に扱うことから、次の点に留意する必要がある。

(1) 監視装置からデータを取得する場合には、監視装置内のデータを破損しないこと

AI 推論システムでは、監視装置からデータを連続的に取得することが必須条件ではないが、運用上では監視装置で把握しているプロセスデータを扱うことが多くなると想定される。また、AI 推論システムに投入するためには、熟練技術者のデータの見方に合わせ適切に加工することになる。監視装置内のデータは日報や月報等各種報告資料の元データとなることから、AI 推論装置からデータを適切に取得（コピー、伝送等）し、AI 推論に適した加工は監視装置外で行うことが望ましい。

(2) 各種データが外部に漏れないよう必要な策を講じること

下水処理場で監視するデータは設備構成の詳細を含め安易に公開すべきではない性質である。オンプレミス型で下水処理場外部とのやり取りがない場合を除き、外部から AI 推論システムを監視する場合やクラウド型を採用する場合には、下水処理場外にデータが出ることになる。そのため、関係者以外が閲覧、アクセスできないようなセキュリティ対策を講じるべきである。

(3) AI 推論に適した前処理を行うこと

カメラで撮影したデータ、画像監視装置から取得したデータ、分析結果等のデータは、AI 推論アルゴリズムに応じた前処理を行う。対応判断 AI や運転操作 AI でデータを扱うため、24 時間平均処理、前時間との差分処理、数値データの二値化・三値化・四値化処理等を行っている。また、画像処理 AI に対応するため、画像のトリミング処理を行っている。

§ 21 AI アルゴリズム概説

熟練技術者の運用ノウハウを表現できるよう AI アルゴリズムを選定する。

【解 説】

画像処理 AI、対応判断 AI、運転操作 AI、水質予測 AI で採用したアルゴリズムについて以下に概説する。なお、AI アルゴリズムは日進月歩に進化し、精度が向上することがあることから、新たに提案されたアルゴリズムを用いてもよい。

（１）画像処理 AI

画像処理 AI では、ネットワークカメラで撮影した画像により、反応タンクや最終沈殿池の状態の判定を行う。判定モデルは 2019 年に Google より発表された DeeplabV3+ と呼ばれる深層学習モデルを用いる。判定モデルは 2018 年に Google が発表した、セマンティックセグメンテーションの分野で最も高い精度のアルゴリズムの一つである。DeeplabV3+ では、Atrous 畳み込みと呼ばれる通常の畳み込み処理とは異なった畳み込み処理を行う。セマンティックセグメンテーションは、画像をピクセル単位で分類し、各ピクセルに対してラベルを割り当てる技術であり、物体検出や画像処理などの分野で広く利用されている。DeeplabV3+ は、エンコーダとデコーダ二つの部分から構成される。エンコーダは、学習済みの深層畳み込みニューラルネットワーク（DCNN）を用いて、入力画像を多数の畳み込み層を通過させ、複数の空間的スケールでの特徴表現を組み合わせる。Atrous 畳み込みは、畳み込みを行う際に、フィルタの間隔を変えて処理を行うため、より広範囲の特徴を捉えることができるようになる。また、ASPP（Atrous Spatial Pyramid Pooling）と呼ばれる手法を用いて、異なる解像度での特徴表現を融合させ、より広範囲の特徴を捉えることができる同時に計算量も削減する。デコーダは、畳み込み層による特徴量マップを元に、画像のサイズに合わせてアップサンプリングする。DeeplabV3+ の概念図を図 4-2 に示す。




図 4-2 画像処理 AI の概念図

出典：Encoder-Decoder with Atrous Separable Convolution for Semantic Image

DeeplabV3+は、セマンティックセグメンテーションの深層学習モデルである。過学習（統計学や機械学習において、訓練データに対して学習されているが、未知データ（テストデータ）に対しては適合できていない状態）を防止および汎化性能（訓練データ以外の未知データ（テストデータ）に対する性能や予測能力）を向上するために、学習データとして異常箇所をラベリングした大量の画像を用意する必要がある。しかし、最終沈殿池の異常発生が極めて稀であるため、学習処理に必要な量の異常画像を確保することは困難である。そこで、異常画像のフロク浮遊およびスカム浮上の異常部分を切り出してアフィン変換（2つの画像における座標の線形変換）を行い、正常時の画像とランダムに組み合わせることで大量な異常画像を生成した。学習データ生成の流れを表す概念図を図 4-3 に示す。このように異常画像を生成することで大量の学習データを確保する同時にデータセットのバランスも改善することができ、高い精度で異常を検出することが可能になる。




図 4-3 画像処理 AI における学習データ生成の流れ

(2) 対応判断 AI

対応判断 AI では、ベイジアンネットワークにより、状況に合わせた対応判断の導出とその判断根拠の見える化を行う。ベイジアンネットワークは、事象間の因果関係を有向グラフにより表現する確率モデルの 1 つである。

本実証研究では、広島市西部水資源再生センターの「DO・風量の増減」「返送汚泥量の増減」「次亜塩素酸ナトリウム注入率の増減」「返流水 PAC 注入率の増減」の 5 つの対応内容を導出候補とした因果関係モデルを構築した。船橋市高瀬下水処理場では、1～5 系の PAC 注入率を導出対象とした。

ベイジアンネットワークは、操作対応や原因と観測可能な現象（水質や池の状態変化）の関係を有向ネットワークで示したものである。操作対応と観測可能な現象がそれぞれ線でつながれた状態のことをネットワークと表現する。矢印の方向は「操作対応」から「観測可能な現象」へと向かっている。一つの対応を一つのノードに示す。ノードは、「事前確率」と「尤度」というパラメータを持っており、それぞれの内容は以下の通りである。

- ・事前確率 : 「経験上、おそらくこれくらいの確率で発生する」という情報
- ・尤度 : 「実際、観測されたデータから推測すると、これくらいの発生確率である可能性が高そう」という値

観測可能な事象についても、事象 1 つに対して 1 つのノードで表現する。観測可能な事象のノードも事前確率と尤度というパラメータを持つ。尤度は「条件付き確率」であり、原因層が発生した時（又は発生しなかった時）に、観測可能な事象が発生する（又は発生しない）確率という表現になる。

ベイズの定理では、原因が発生した時（A と示す）ことを事象が発生したこと（B と示す）を以下のように関連付ける。

$$B \text{ が起きた時に } A \text{ の起こる確率} = \frac{A \text{ が起きた時に } B \text{ の起こる確率} \times A \text{ の起こる確率}}{B \text{ の起こる確率}}$$

$$= \frac{\text{尤度} \times A \text{ の事前確率}}{B \text{ の事前確率}}$$

「B が起きたとき」は実際には水質がある範囲に収まったとき（水質データを分割する）とし、「A の起こる確率」は目的変数の操作方法とすれば、ある範囲の水質になったときに目的変数をどのように操作したかを、確率で計算することが出来る。

複数の事象が関係する場合も計算方法は同じである。

A の事前確率、B の事前確率はそれぞれのデータの発生頻度から計算することが出来る。尤度も同様である。目的変数と説明変数のつながりが変わらなければ、逐次データを溜めていくことで自動的に計算根拠のデータを更新することができる。

下水処理場における異常原因とその結果観測される事象について、簡易なモデルを図 4-4 に例示した。これは「散気管の目詰まり」という異常が発生すると、「ブロワの回転数」に変化が起きるとともに、「反応タンクの DO」が低下することを示している。また、「ブロワの吐出圧力」という異常が発生すると、「反応槽への送風量」が低下するとともに、やはり「反応タンクの DO」も低下するということを示したものである。ここでは簡易に示すため、5 つのノードの関係を示しているが、実際には、この原因と観測可能な事象が膨大かつ階層をもつものになることが想定される。

「反応タンクの DO が著しく減少した」という現象を観測できた時、このノードに紐付いている複数の条件付き確率表から、可能性のある原因が推測される。取得できた情報がこれだけであれば、単に最も条件付き確率の高いものが原因として高い可能性を持つということになるが、現実には観測できる複数の現象が確認できる。図 4-4 では、条件付き確率で言えば「ブロワの吐出圧力が減少」した原因による DO 減少の方が高い確率であるが、同時にブロワの回転数が増加したという現象も確認できていれば、散気管が目詰まりした原因である確率が高くなる。図 4-4 ではノードの数が少ないので非常に単純に思えるが、ノードが多数かつ階層的なつながりを持ち、かつ観測可能な現象も都度異なる時、その可能性の計算量は膨大に膨れ上がる。これを前記のように予め定められた事前確率と尤度から、最も可能性の高い原因とその確率（事後確率）を導くアルゴリズムがベイジアンネットワークである。

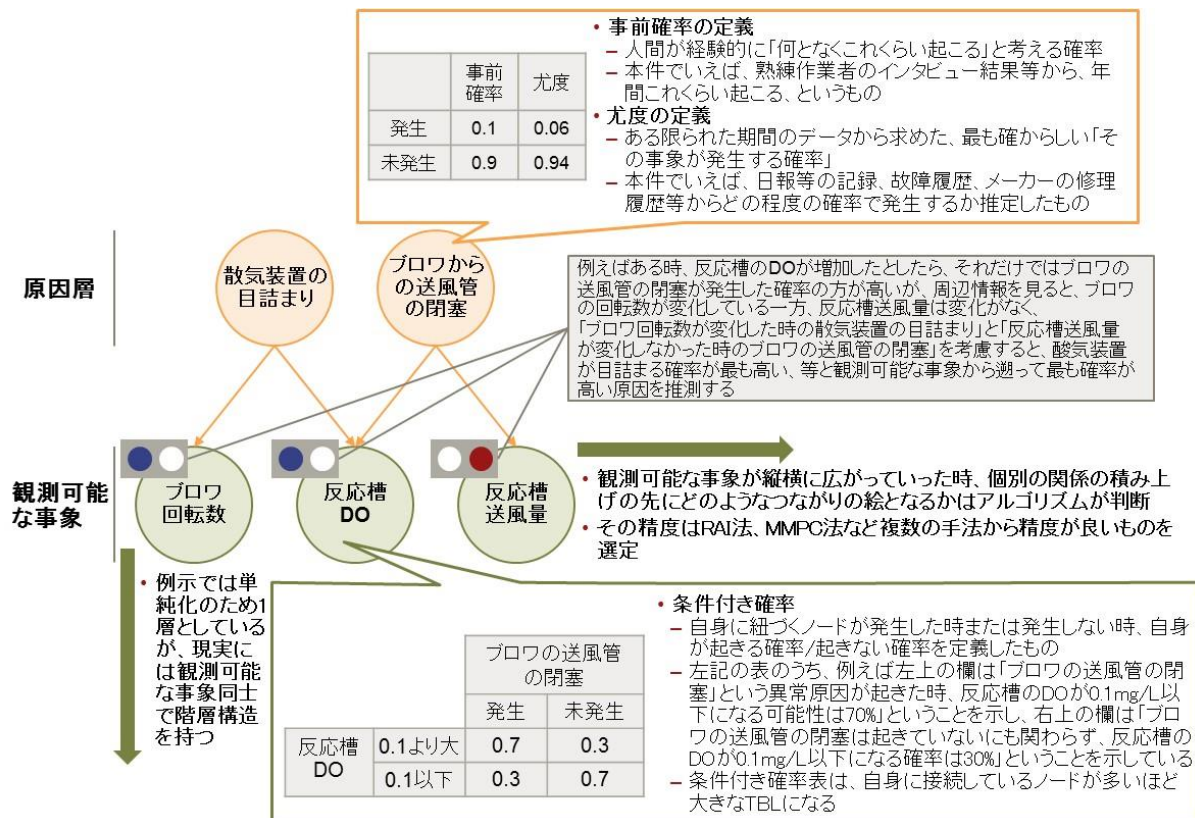


図 4-4 反応タンクに関する機器トラブルと観測可能な事象をベイジアンネットワークで示した例

本技術で用いたベイジアンネットワークで構成される各層の説明を図 4-5 に示す。ベイジアンネットワークは、①対応判断層、②判断根拠層、③観測可能事象層の 3 層より構成され、下記に示す機能を有している。

- ①対応判断層：判断根拠として想定される各要素の確率を用いて、目的とする操作対象について操作判断を示す層。
- ②判断根拠層：現在の環境から観測可能な事象を用いて操作判断に必要と想定される各根拠の確率推定を行う層。
- ③観測可能事象層：現在の下水処理場の環境や日時などから数値として表現可能な各事象の値を取得する層。判断根拠として使用するモデルの入力値として扱うためにモデルに適した形式に符号化する場合がある。

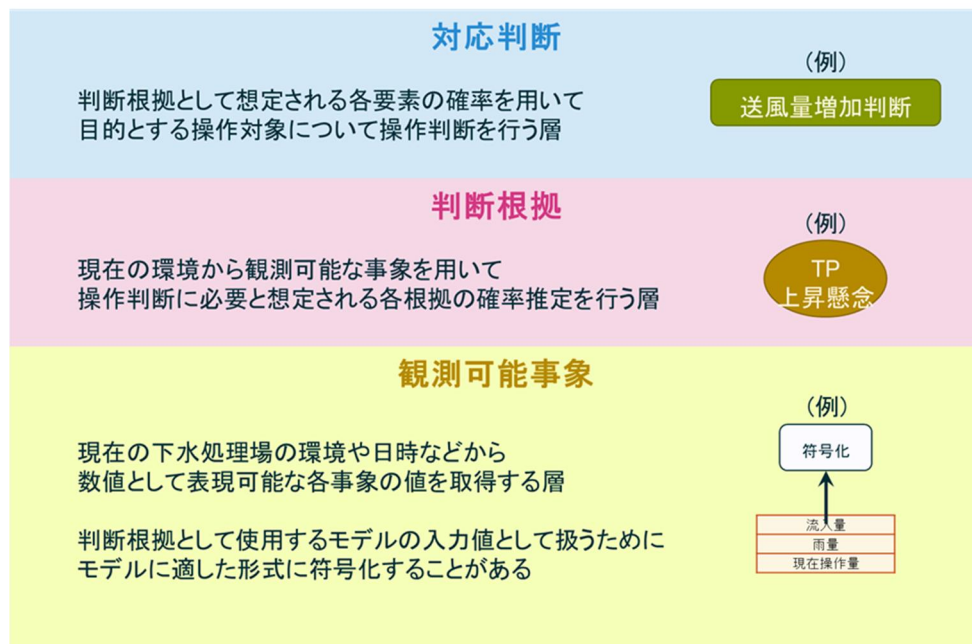


図 4-5 対応判断層、判断根拠層、観測可能事象層の考え方

（3）運転操作 AI

運転操作 AI には機械学習手法として決定木ベースのアンサンブル手法（集団学習手法）を使用する。

決定木とは、水質等の各入力項目の一定水準（閾値）に対する大小関係の組み合わせにより結果を導く手法である。決定木のイメージを図 4-6 に示す。熟練技術者は運転操作量を変更する場合、水質等の注目すべき特定の項目が一定水準以上もしくは一定水準未満であることを判断根拠としている。したがって、入力した各項目の閾値に対する大小関係の繰り返しにより結論を導出する決定木を運転操作の導出に用いることは、熟練技術者の運転判断の思考経路を再現する上で適した手法であると言える。

またアンサンブル手法とは単純な複数の推論の多数決により結果を導出する手法である。アンサンブル手法のイメージを図 4-7 に示す。熟練技術者と同じように、状況に応じて複数の項目を総合的に判断しながらの結論を導出しようとした場合、1つのルールで表現することは原理的に不可能であり、複数の単純な推論結果の多数決として結論を導出するアンサンブル手法を用いることは合理的である。

決定木ベースの機械学習手法はいくつか提案されているが、中でも 2016 年に Tianqi Chen らにより提案された XGBoost（eXtreme Gradient Boost）は性能がよいことで知られており、データ分析のコンペティションにおいても頻繁に使用される。

XGBoost は、簡単にいうとランダムフォレストとブースティングを組合せたアンサンブル学習手法である。ランダムフォレストは少ない変数で構成した決定木を複数用意し、それらの結果の総和で結論を導出する機械学習手法である。ブースティングとは、推論の精度に合わせて、学習データに対する重み付けを変化させながら分類器の調整を進めていく手法である。

XGBoost の場合、決定木を徐々に増やして行きながら、各決定木に含まれる葉に対する重み係数を誤差が最小になるように更新していく。




図 4-6 決定木による分類イメージ




図 4-7 アンサンブル手法のイメージ図

(4) 水質予測 AI

水質予測 AI では、Transformer を使用する。Transformer は、もともとは言語処理分野で提案された手法で、Encoder と Decoder により構成される、いわゆる Encoder-Decoder モデルである。Attention と呼ばれる、予測する上で注視すべき箇所を特徴量化する機構を持つことが大きな特徴である。例えば、Transformer により、日本語から英語に翻訳する場合、

- ・ Encoder によって日本語文自身を Attention により特徴量化
(入力した日本語文自身の Attention という意味で Self-Attention と呼ぶ)
- ・ Decoder 内で英文を Attention で特徴量化(英文の Self-Attention)
- ・ 上記 2 つの日本語文および英文の Self-Attention の関係を、さらに Attention で特徴量化
(入力と予測対象間の Attention ということで Source-Target Attention と呼ぶ)

の手順により特徴量を学習結果として保持しておくことで、予測時に Encoder へ日本語が入力されると Decoder から 1 語ずつ日本語に対応する英単語が出力される。

Attention 以外に、Transformer のもう一つの大きな特徴は、Positional Encoding という機構を持つ点である。リカレントニューラルネットなどの従来の手法では、単語の並び順をネットワーク構造で表現していたが、Transformer では単語の位置情報を特徴量化しネットワーク構造の外に出して扱う。これにより、入力と予測対象の間の単語間の位置関係を柔軟に対応付けすることが可能となる。Attention のイメージと Transformer の概要を図 4-8 に示す。




図 4-8 Attention のイメージと Transformer の概要

但し、運転操作量変更前後の水質の挙動の変化を予測結果に明確に反映できるよう、現在値からの相対値への変換し、さらに正規化処理を施してから Transformer モデルに入力する。予測処理の流れを図 4-9 に示す。



図 4-9 水質予測の処理の流れ

§ 22 AI エンジンの学習

AI エンジンの作成に必要なデータを準備し、AI に求める精度を達成するよう、AI エンジンを学習させる。

【解説】

画像処理 AI、対応判断 AI、運転操作 AI、水質予測 AI のそれぞれで学習方法が異なっている。それぞれの AI の学習方法について以下に概説する。

画像やプラント、日報、水質、運用結果等の過去データを準備し、教師データを構成する。教師データは目的変数（推論対象）と説明変数（推論対象との関係を説明する要素）で構成される。説明変数がある状態のときに目的変数がどのような値をとるかを推論するアルゴリズムが機械学習を含む AI と考えてよい。

教師データは、原則として以下のステージで分ける。学習及び運用に関する概念図を図 4-10 に示す。

- ・ 訓練 (training) …… 学習モデルを生成するためのデータ
- ・ 検証 (validation) …… 学習結果を評価するためのデータ
- ・ テスト (testing) …… 上記 2 つのデータで構築した最終的な推定モデルを評価するためのデータ

訓練期間のデータで AI エンジンを学習し、検証を行い、AI エンジンの学習を完了する。学習した AI エンジンをテスト期間のデータを与えて精度を確認する。目標精度を達成できれば、その AI エンジンを実運用に供し、AI 導入後の本格運用を開始する。




図 4-10 学習及び運用のイメージ

AI の学習時と実行時には異なるプログラムとなることから、実運用で使用する AI 推論装置とは別に学習用のシステムが必要となる。AI の学習を導入事業体側で実施する場合、学習環境の整備が追加が必要となることに留意する。

（１）画像処理 AI

設置するカメラと同一画角で撮影した画像を教師データとすることが望ましい。

広島市西部水資源再生センターにおける教師データについて、表 4-1、表 4-2 に示す。

表 4-1 広島市西部水資源再生センター東系の画像構成（学習用データセット）

項目		2 系最終沈殿池	3 系最終沈殿池
期間		2022.3.1～2022.3.31	2022.2.1～2022.3.31
数量	正常画像（生データ）	128	90
	異常画像（生データ） （フロック浮遊/スカム浮上）	83	67
	学習用生成画像（加工データ）	850	400

表 4-2 広島市西部水資源再生センター東系の画像構成（評価用データセット）

項目			2 系最終沈殿池	3 系最終沈殿池
期間			2022.11.26～2023.1.25	2022.11.26～2023.1.25
数量	正常画像		913	90
	異常画像	フロック浮遊	326	1048
		スカム浮上	0	37
	合計		1239	1175

画像処理 AI の精度の目標となる真陽性率、偽陽性率は以下のように定義される。

- ・真陽性率（True Positive Rate） …異常を異常と判定
- ・偽陽性率（False Positive Rate） …異常なしを異常と判定

目標精度は真陽性率 90%以上、偽陽性率 10%未満を目安とする。関係式は図 4-11 のようになる。

実画像 \ AI 推定	正常と推定	異常と推定
	正常な実画像	異常な実画像
正常な実画像	A	B
異常な実画像	C	D

$$\text{真陽性率} = \frac{D}{C + D} \geq 0.9$$

$$\text{偽陽性率} = \frac{B}{A + B} < 0.1$$

図 4-11 真陽性率、偽陽性率の考え方

（２）対応判断 AI

プロセスデータや水質分析結果等から運転判断を実施しているため、これらのデータを収集する。

広島市西部水資源再生センターでは、教師データの元として、以下の項目が挙げられる。これらを精査し、処理状況、水質、設備の稼働状況を勘案し最終的に運転判断に必要な項目を選定して教師データとして用いる。

- ・ 水処理運転日報
- ・ 水処理引継簿
- ・ 汚泥処理運転日報
- ・ 汚泥処理引継簿
- ・ 返流水日報
- ・ 運転日報
- ・ 日常試験成績表
- ・ 平常試験成績表
- ・ 通日試験成績表
- ・ 機械設備フローシート
- ・ 電気・計装設備フローシート
- ・ 計装タグリスト
- ・ 監視制御装置トレンドデータ
- ・ 設備概略

船橋市からは以下のデータを提供頂き、精査することで最終的にモデルに組み込む項目を決定した。データ取得期間は、2017 年 4 月から 2023 年 12 月までの期間の内、処理状況、水質、設備の稼働状況から適宜判断した。

- ・ 水質日報
- ・ 帳票日報
- ・ 臨時分析データ
- ・ 機械設備フローシート
- ・ 電気・計装設備フローシート
- ・ 計装タグリスト
- ・ 監視制御装置トレンドデータ

なお、これらの名称は下水処理場毎に異なっていることがあるため、各機場の管理データを確認する。

トレンドデータは監視制御装置から 1 分間隔で取得可能であるが、日常・平常試験の水質データの取得頻度は週に数回の程度である。また、DO 設定などの操作量の変更も通常、数日に 1 回と、トレンドデータと比べて長周期で変更が行われる。したがって、運転員と同等の対応判断を導出するためには、平均化するなどによりトレンドデータの周期もそれに合わせた形に加工する必要がある。また、加工時には異常値（外れ値）を除外しておく必要もある。

一般に、ベイジアンネットワークにより因果関係ネットワークを構築する場合、ネットワーク内に現れる変数は離散化（連続した値を非連続な状態の値（離散値）に変換すること。二つの離散値に変換することを二値化という）して扱うことが多い。データ加工の一例を図 4-12 に示す。対応判断 AI における導

出対象である 5 つの対応内容のうち、「DO・風量の増減」「返送汚泥量の増減」「次亜塩素酸ナトリウム注入量の増減」「返流水 PAC 注入量の増減」の判断根拠となる水質等の説明変数に対しては、データの解析によって得られた閾値に対し観測値が以上か未満によって二値化を行う。「返送汚泥量の増減」「次亜塩素酸ナトリウム注入量の増減」においては、返送汚泥量および次亜塩素酸注入率の現在設定値に対し、増加相当時または減少相当時によって二値化を行う。「経過観察」については、水質変化の周期性を考慮して判断根拠層において現在の日時情報をもとに昼夜（昼：9 時～19 時、夜：20 時～8 時）および曜日（月～日）の複数の説明変数にて二値化を行う。また、AI 推論結果による過度な運転変更の防止を目的に、対応判断による変更操作からの経過時間から確率相当値の直接算出を行う。例として二値化処理の手法を示しているが、説明変数によっては四値化を行うこともある。

省エネルギー化等のため、過去に設定変更を行わず一定運転した実績そのものを学習するのではなく、以下の考えで過去の設定を変更しても問題がないと判断される場合には、その値を目的変数に設定することを検討する。例えば、DO 設定の変更に対する考え方を以下にまとめる。

①必要空気量の算出

「下水道施設設計指針と解説」に基づき、流量、水質、MLSS 等から必要空気量を算出する。送風量実績と必要空気量が最も近くなるパラメータ（S-BOD に対する汚泥転換率、除去 BOD あたりに必要な酸素量等）を評価指標 RMSE/値幅として決定する。

②決定したパラメータを用い、学習対象の年度の必要空気量を算出。

③送風量の余裕分の算出

送風量余裕分（必要空気量と送風量実績との差）、DO 管理値、放流水質の観点から、以下の 4 つの条件に当てはまる期間は送風量を下げられる可能性があるとして判断する。

- ・必要空気量に対し送風量実績が 2 日以上、上回っている
- ・DO の手分析値が DO 目標値を上回っている
- ・放流水 T-N 計の平均値が目標値を 2 日以上、下回っている
- ・処理水、放流水アンモニア性窒素が 1.5 mg/L 未満

④送風量低減可能性の判断

送風量を下げられる可能性があるとして判断された期間では、送風量は算出された必要空気量で運用できると仮定し、送風量実績－必要空気量を集計する。

観測値と閾値の比較により二値化

■ 例: 流入量



個別の観測値から二値化

■ 現在設定値 (返送汚泥量と次垂注入率のそれぞれについて)



現在日時の情報に応じて複数の説明変数群に二値化

■ 昼夜



■ 曜日



個別の観測値から確率相当値を直接計算

■ 送風量変更からの経過時間



図 4-12 データ加工方法

(3) 運転操作 AI

広島市西部水資源再生センターおよび船橋市高瀬下水処理場の運転操作 AI の学習・検証に使用したデータセットの概要を表 4-3、表 4-4 に示す。

運転操作 AI は過去の運転操作の履歴を教師データとし、機械学習手法により運転操作を導出できるよう AI を学習させる。教師データとは、AI を学習するときに目標となる数値のことである。熟練技術者は常に正しい運転をしていたとするなら、この方法で AI が学習した結果を使えば、熟練技術者の運転操作をトレースするよう AI が判断を導出することになる。運転操作履歴を確認したところ、広島市西部水資源再生センターの 2 系返送汚泥量設定や東系次亜注入率設定などの項目は、一日に複数回設定変更することはほとんどない。一方、船橋市高瀬下水処理場の各系 PAC 注入量設定は、一日に複数回周期的に設定変更する傾向があった。また、説明変数となる水質データについても、週 3 回程度の日常試験や平常試験による結果を用いるため、MLSS 等の連続計測データ等の説明変数も日平均処理して学習データとした。現地実証前の性能確認での評価指標としては、運転操作 AI による操作量導出の現地実証前の性能確認期間での評価は以下で定義される RMSE (Root Mean Square Error : 平均二乗誤差平方根) により行う。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}$$

但し、ここで y_t , $\hat{y}_t$ はそれぞれ実際の操作量、推定操作量である。

目標精度としては、運転操作量の値幅に対して誤差 20% とする。すなわち、以下の数式で表される条件を目標精度とする。

$$\frac{\text{RMSE}}{\frac{\max_{1 \leq t \leq N}(y_t) - \min_{1 \leq t \leq N}(y_t)}{2}} < 0.2$$

但し、ここで $y_t (1 \leq t \leq N)$ は推定対象の操作量である。

運転操作 AI による操作量導出の現地での妥当性評価は、対応判断 AI と連動させて評価することとし、熟練技術者の対応判断と比較し一致率 80% 以上とした。評価は対応判断 AI とまとめて行った。

表 4-3 広島市西部水資源再生センターの対応判断 AI、運転操作 AI の学習・評価に使用したデータセット概要

No	導出項目	学習データ	評価データ
1	2 系 DO 設定	6 ヶ月 [2021/4/9～2021/10/29]	1 ヶ月 [2022/2/17～2022/3/22]
2	3 系 DO 設定	6 ヶ月 [2021/4/9～2021/10/29]	1 ヶ月 [2022/2/17～2022/3/22]
3	2 系返送汚泥量設定	6 ヶ月 [2021/4/9～2021/10/29]	1 ヶ月 [2022/2/17～2022/3/22]
4	3 系返送汚泥量設定	6 ヶ月 [2021/4/9～2021/10/29]	1 ヶ月 [2022/2/17～2022/3/22]
5	東系次亜注入率設定	6 ヶ月 [2021/4/9～2021/10/29]	1 ヶ月 [2022/2/17～2022/3/22]
6	分配槽 PAC 注入量設定	15 ヶ月 [2020/3/20～2021/12/19]	12 ヶ月 [2021/3/16～2022/3/16]
7	再曝気槽 PAC 注入量設定	15 ヶ月 [2020/3/20～2021/12/19]	7 ヶ月 [2021/3/16～2021/10/27]
8	4 系送風量設定	28 ヶ月 [2019/5/1～2021/9/1]	6 ヶ月 [2021/7/15～2022/1/10]
9	5 系送風量設定	28 ヶ月 [2019/5/1～2021/9/1]	6 ヶ月 [2021/7/15～2022/1/10]
10	4 系返送汚泥量設定	28 ヶ月 [2019/5/1～2021/9/1]	4 ヶ月 [2021/7/1～2022/10/31]
11	5 系返送汚泥量設定	28 ヶ月 [2019/5/1～2021/9/1]	4 ヶ月 [2021/7/1～2022/10/31]
12	西系次亜注入率設定	24 ヶ月 [2019/5/1～2021/5/1]	8 ヶ月 [2021/5/7～2022/12/31]

表 4-4 船橋市高瀬下水処理場の対応判断 AI、運転操作 AI の学習・評価に使用したデータセット概要

No	導出項目	学習データ	評価データ
1	1 系 PAC 注入量設定	3 ヶ月 [2023/1/1～2023/3/31]	2 ヶ月 [2023/4/1～2023/5/31]
2	2 系 PAC 注入量設定	3 ヶ月 [2023/1/1～2023/3/31]	2 ヶ月 [2023/4/1～2023/5/31]
3	3 系 PAC 注入量設定	3 ヶ月 [2023/1/1～2023/3/31]	2 ヶ月 [2023/4/1～2023/5/31]
4	4 系 PAC 注入量設定	3 ヶ月 [2023/1/1～2023/3/31]	2 ヶ月 [2023/4/1～2023/5/31]
5	5 系 PAC 注入量設定	3 ヶ月 [2023/1/1～2023/3/31]	2 ヶ月 [2023/4/1～2023/5/31]

A 処理場においては、次亜塩注入比率設定値を目的変数（予測対象）とした AI 構築を検討した。次亜塩注入比率設定値の変更の要否について、減少・維持・増加の 3 値に分けて出力する。モデルは上げ変化点・下げ変化点のみで学習させた。予測出力は 1 回/時間とした。モデル構築における学習期間と、評価に用いた期間を表 4-5 に示す。

表 4-5 A 処理場対応判断 AI、運転操作 AI の学習・評価に使用したデータセット概要

No	導出項目	学習データ	評価データ
1	次亜塩注入比率設定	22 ヶ月 [2020/6/27～2021/2/28、 2021/5/1～2022/7/1]	10 ヶ月 [2022/7/1～2023/5/19]

B 処理場では反応タンク曝気装置の運転が pH を基準に行われているが、その目標 pH は熟練技術者が経験に基づいて設定している。この pH の値を AI 推論することで、実際の曝気装置運転を再現することが可能であると考え。反応タンク曝気装置の運転操作 AI では、曝気装置を ON にする場合・OFF にする場合の判断基準となる反応タンク pH の値を入力データから推定する「操作判断時 pH 推論」を行い、pH のオンライントレンド値がその値に達したとき運転判断を行う。モデルの検証に使用した学習データおよび評価データを表 4-6 に示す。

表 4-6 pH 閾値推論のデータセット

導出項目	学習データ	評価データ
1/2 系 ON 時 pH 閾値	推論時が午前（3～14 時）の場合 3～14 時の 1 系 ON 判断時データ 推論時が午後（15～翌 2 時）の場合 15～翌 2 時の 1 系 ON 判断時データ [2020 年から 2022 年の 11、12 月]	11 ヶ月 [2021/7/1 – 2022/5/31]
3/4 系 ON 時 pH 閾値	3 系 ON 判断時データ [2020 年から 2022 年の 10～12 月]	
1/2 系 OFF 時 pH 閾値	1 系 OFF 判断時データ [2020 年から 2022 年の 11、12 月]	
3/4 系 OFF 時 pH 閾値	3 系 OFF 判断時データ [2020 年から 2022 年の 10～12 月]	

（４）水質予測 AI

運転方針を決定する上で重要な項目を目的変数に設定する。広島市西部水資源再生センターにおいて重要となるのは、以下の３つの水質である。

- ・ T-N [放流水]
- ・ T-P [放流水]
- ・ BOD[放流水]

但し、ここで BOD については採水してから 5 日後にしか結果が得られないため、運転判断時に参考にできるのは最新のものでも 5 日前の数値となる。また、T-N、T-P が監視装置よりリアルタイムに取得可能である一方で、BOD が得られるのは週に数回の採水による手分析値のみである。このことから、BOD の予測については、BOD の手分析値を直接予測対象として予測モデルを構築することはせず、まずは、BOD の挙動に大きな影響を与えかつ監視装置よりリアルタイムに取得可能である pH を対象に予測を行い、導出した pH 予測値に基づいて BOD 値を導出するという 2 段階の処理により BOD の予測値を導出する。

広島市西部水資源再生センターにおける T-N[放流水]、T-P[放流水]、pH[東系処理水]の予測について、入力項目をそれぞれ表 4-7、表 4-8、表 4-9 に示す。入力項目は監視装置より取得したトレンドデータであり、直近 48 時間分を入力とした。入力項目として使用する流入水量については、T-N[放流水]予測および T-P[放流水]予測については東系と西系の流入水量の合計値を使用するが、pH[東系処理水]予測の入力項目として使用する流入水量については、pH 計測器の実際の設置場所が東系終沈であることから、東系への流入水量のみを使用した。

表 4-7 T-N(放流水)予測の入力項目

No	項目
1	T-N[放流水]監視トレンド（直近 48 時間分）
2	T-N 変化量（3 時間前との差分）（直近 48 時間分）
3	流入水量監視トレンド（東系+西系）（直近 48 時間分）

表 4-8 T-P(放流水)予測の入力項目

No	項目
1	T-P[放流水]監視トレンド（直近 48 時間分）
2	T-P 変化量（3 時間前との差分）（直近 48 時間分）
3	流入水量監視トレンド（東系+西系）（直近 48 時間分）

表 4-9 pH(東系処理水)予測の入力項目

No	項目
1	pH[放流水]監視トレンド（直近 48 時間分）
2	pH 変化量（3 時間前との差分）（直近 48 時間分）
3	流入水量監視トレンド（東系）（直近 48 時間分）

水質予測に使用した検証データの概要を表 4-10 に示す。学習モデルは、操作量変更有無とその後の水質の挙動変化の違いを明確に表現するため、硝化促進時、硝化抑制時、現状維持時の 3 つに分けて生成した。また、評価についても同様に 3 つの場面に分けて行った。

表 4-10 広島市西部水資源再生センター 水質予測検証用データセット

項目	期間	数量			
		硝化促進	硝化抑制	現状維持	合計
学習データ	2017.1.11 ～2021.10.29	147	152	1490	1789
評価データ	2022.1.16 ～ 2023.1.22	39	31	277	347

評価指標は、実測値と予測値の間の RMSE が、各水質の変動幅に対してどの程度の割合かにより行った。すなわち、

$$\text{評価指標} = 100 \times (1 - \text{RMSE} \div \text{値幅}) [\%]$$

目標精度としては、上記評価指標 $\geq 80\%$ （誤差 $\leq 20\%$ ）と設定した。

§ 23 AI 推論結果の評価

学習した AI の精度を **§ 22 AI エンジンの学習**に従い評価し、実運転の適否について判断する。

【解 説】

画像処理 AI、対応判断 AI、運転操作 AI、水質予測 AI のそれぞれを学習した後、**§ 22 AI エンジンの学習**に従い評価し、実運転の適否について判断する。

目標となる精度が達成できれば、それぞれの AI を実運転に適用してよい。一方で、各 AI が目標となる精度を達成できない場合、以下の対策を講じる。

- 1) それぞれのアルゴリズムに応じたパラメータを調整する。
- 2) 教師データを見直す。対応判断 AI においては、二値化の処理を三値化に変更する、閾値を変更する等の対策がある。
- 3) 教師データの背景となる運用情報などを再確認する。
- 4) 目標を見直す。

§ 24 導入効果の検証

AI 技術に関する結果を評価実施後、導入検討段階に行った概略効果（事業性）に対し、想定通りの導入効果が得られるかどうかの検証を実施する。

【解 説】

導入検討段階では、設定した基準年度と評価年度を設定し、AI 推論の実現有無に依らず、**§ 14 導入効果の検討**において、概略の導入効果を算出した。

ここでは、**§ 23 AI 推論結果の評価**で得られたより精度の高い条件に基づいて導入効果を再検討する。本技術の導入における建設費、維持管理費を算出し、導入検討段階で期待していた効果が得られるか検証する。

第 2 節 設備設計

§ 25 設備設計の考え方

本設備設計にあたっては、AI 推論で導出したい操作項目や数、及びそれらの推定に必要なデータが収納されている装置又は資料から、データの取得から AI 推論した結果表示までできるだけ短時間、かつ少ない機器構成で表示できるよう構成する。

【解 説】

設備の設計時に考慮すべき事項は以下の通りである。

(1) AI 推論システムを現地に設置（オンプレミス型）する場合

既設監視設備の装置構成やデータ管理状況を考慮するとともに、監視設備近傍に AI 推論システムを設置する場合には、AI 推論を実施したい内容や項目数を元に、次の項目を考慮して AI 推論システムを構成する。

①監視装置データの伝送

既設の監視制御システムからリアルタイムにデータを伝送する場合、監視装置側からデータ収集装置側に一定周期でデータを直接伝送する。

なお、直接の伝送が困難な場合、必要に応じて監視装置からデータ収集装置の経路間にデータ変換装置を導入し、データ収集装置からデータ変換装置にデータ取得を可能とする。

②カメラ画像データの伝送

カメラと AI 推論システムとの伝送距離が離れている場合、ケーブル工事費用や通信費等を考慮し、有線での伝送又は無線での伝送を選定する。無線での伝送にあたっては、通信回線速度やセキュリティの確保に留意する。

③データ収集装置の構成

データの保存項目数や保存期間を考慮し、データ記録容量を選定する。運用開始後に AI を再学習する場合を考慮し、最低 3 年程度のデータを保存できることが望ましい。

④AI 推論装置の構成

AI 推論項目数や計算負荷の大きい画像処理 AI の有無、AI 推論頻度から、AI 推論装置の数を選定する。AI 推論装置は通常 1 台程度であるが、画像処理 AI の数が増え、AI 推論項目数が増える場合、2 台程度に増やすことが望ましい。

⑤運転ガイダンス装置の構成

AI 推論装置の負荷が高い場合、ガイダンス装置を 1 台設置することが望ましい。一方で、AI 推論装置の負荷が低い場合には、AI 推論装置にガイダンス機能を統合することを考慮する。

⑥装置類の設置

監視室の運転員が AI 推論の結果を確認しやすいよう、通常の監視操作を行う画面のそばに設置した方がよい。また、各装置が瞬停等でシャットダウンしないよう、UPS（無停電電源装置）を経由して給電することが望ましい。通常は、既設の監視制御システム等と UPS を共用することになるため、事前の容量計算を行い、通常の監視業務の妨げにならないよう配慮する必要がある。

監視装置のデータを活用するには、データ収集装置と情報系 LAN で接続することが望ましい。AI 推論には多くのデータが必要であること、1 時間の頻度で 24 時間推論を繰り返すことから、データ取得のプロセスは極力自動化することが望ましい。

（２）クラウド上のデータ収集機能や AI 推論機能を構成（クラウド型）する場合

クラウド上へのデータをアップロード可能な通信環境を準備するとともに、クラウド上でのデータ加工や AI 推論、ガイダンス表示を可能とする。

§ 26 システム構成

本技術は、オンプレミス型においては、AI 推論装置を核とし、データを収集するデータ収集装置、画像を撮影し加工するカメラシステム、AI 推論結果を表示する運転ガイダンス装置で構成され、処理場内の配線で完結することが可能である。

クラウド型においてもオンプレミス型と同じ機能を有するが、AI 推論機能やクラウドや運転ガイダンス機能がクラウド上に搭載されるため、VPN 接続を前提とした Web 回線経由の構築が別途必要となる、

【解 説】

§ 6 技術の構成と機能で技術の構成として記したが、ハードウェア一覧として改めて記す。

1) ハードウェア要素技術 1 : カメラシステム

沈殿池等に設置したカメラ画像を伝送し、AI 推論に必要な形式に加工するためのシステムである。

2) ハードウェア要素技術 2 : データ収集装置

沈殿池等に設置したカメラ画像、監視装置で収集したデータ、日報、水質分析結果を取り込み、AI 推論に必要な情報として加工する装置である。

3) ハードウェア要素技術 3 : AI 推論装置

画像処理 AI、対応判断 AI、運転操作 AI、水質予測 AI を実行するための装置である。

4) ハードウェア要素技術 4 : 運転ガイダンス装置

AI 推論結果を表示するための装置である。




図 4-13 本技術「AI 推論システム」(オンプレミス型) の構成

クラウド型においては、**3) ハードウェア要素技術 3 : AI 推論装置**や**4) ハードウェア要素技術 4 : 運転ガイダンス装置**がクラウド上に搭載されるとともに、**2) ハードウェア要素技術 2 : データ収集装置**のデータ保存機能もクラウド上で行うこととなる。そのため、クラウド型では必要となるハードウェアが減少し、導入コストが安価となる。一方で、通信費用やクラウドサービス料が別途必要となる。




図 4-14 本技術「AI 推論システム」(クラウド型) の構成

§ 27 AI 推論装置

AI 推論装置は、データ収集装置で作成したデータから AI 推論を実行し、AI 推論結果を運転ガイダンス装置で表示するための機能を有する。これらの機能を実現するための演算装置、記録装置、OS、AI 実行環境ソフトウェア等で構成される。

【解 説】

水処理に関する運転判断は逐次行いが、判断の周期は雨水や揚水ポンプの運転判断を除きそれほど短くはない。最終沈殿池の状況判断は日に数回、運転判断は毎正時に 1 回程度である。このことから、AI 推論の周期は、画像処理 AI で最短 30 分、その他の AI で最短 1 時間に設定した。画像データの伝送は 100 kB の画像が 10 秒周期で 6 枚送付されるのが最大、最短である。監視データの収集は毎正時、手分析による水質データは日に数回実施する。

（１）演算装置

AI 推論を演算する装置としては、特別高速な CPU を必要としない。メモリは多くのデータを一度に扱うことから、8 GB 以上であることが望ましい。実証実験では、CPU として、Intel Xeon E3-1268L v3 2.3 GHz、メモリとして 16 GB を採用した。

（２）記録装置

AI 演算用のデータを一時保存するための装置であり、必ずしも大容量を必要としない。実証実験では、500 GB 容量のハードディスクをミラーリング形式で採用した。

（３）OS・AI 実行環境ソフトウェア

AI 推論が実行できる環境であれば特に制限はない。AI は Python 言語で開発したソースコードを用いた。実証実験では、AI 用の演算ライブラリが豊富な Linux 系 OS として Red Hat Enterprise Linux 7.3 を採用した。

§ 28 データ収集装置

データ収集装置は、AI 推論に必要なデータを集約し各 AI に入力データを与えると同時に、AI 推論結果を保存する機能を有する。これらの機能を実現するための入力装置、伝送装置、記録装置等で構成される。

【解 説】

データを収集、伝送、記録するためのハードウェアであるため、高いスペックは要求しない。

（１）入力装置

水質分析データを読み込むための DVD ドライブの設置を標準とする。

（２）伝送装置

プロセスデータを取得する場合には、伝送装置としてルータを設置し、監視装置からデータ読み込みに対応する。また、AI 推論装置にデータを送るためにもルータが必要となる。

（３）記録装置

プロセスデータ、水質分析結果、AI 推論結果等を一元的に保存するための装置である。データ保護のため、ハードディスクはミラーリング（二重化）されていることが望ましい。

また、画像や監視、水質等の多量のデータをバックアップするためのハードウェアとして、NAS（Network Attached Storage）を AI 推論システムと同一 LAN 上に接続し、画像や水質、AI 推論結果等のデータを 5 年分保存可能な容量を準備することも推奨する。

画像 1 枚は JPG 形式で約 120 kB、1 回の AI 推論で使用する数値データとして 100 kB を目安とし、ハードディスクや NAS の容量を選定する。

§ 29 運転ガイダンス装置

AI 推論結果の表示にあたっては、熟練技術者のノウハウをできるだけシンプルに表現できるように配慮する。

【解 説】

運転ガイダンス装置は AI 推論結果を表示する装置である。熟練技術者のノウハウ等や設定変更値をわかりやすく表現するよう留意する。

(1) 画像処理 AI

AI 推論結果の表示にあたっては、必要な情報を表示できるようにする。

実施例では、最終沈殿池のスカムやフロックの数や専有面積を AI 推論で導出した例を図 4-15 に示す。




図 4-15 画像処理 AI の画面表示例

(2) 対応判断 AI

熟練技術者のノウハウを表現するため AI 推論結果、結果の導出に至った観測項目、観測項目と AI 推論結果の寄与について表現する。関係が複雑な場合には、観測項目と AI 推論結果を線で結ぶことが望ましい。また、観測項目から要因として整理して判断根拠としてまとめることも有効である。

対応判断 AI としてベイジアンネットワークを採用した場合には、観測値や計算結果、寄与が数値として表現できるため、観測項目からどのような判断根拠で AI 推論するに至ったかが尤度(もってもらしさ)とともに理解する手助けとなる。

観測事象に含まれる水質データについては、どの日時で得られた数値かわかるよう表現することが望ましい。例えば、計測値と併せて日時を画面表示する、マウスクリック若しくはマウスオーバー(マウスポイントを対象となる項目に重ねること)による日時がポップアップ表示する、等の機能を実装する。

一方で、観測項目と AI 推論項目をシンプルな関係で表現した場合、必ずしもこの表現にこだわる必要はない。



図 4-16 ベイジアンネットワークをアルゴリズムとした場合の対応判断 AI の画面表示例

(3) 運転操作 AI


運転操作 AI では、AI 推論結果による運転変更を数値として指示する。そのため、運転変更前（現状）の設定値、AI が推論した設定値（推奨値）を比較表示できることが望ましい。



図 4-17 運転操作 AI による運転操作の画面表示例

(4) 水質予測 AI

水質予測 AI では、現状の運転を継続した場合と、AI 推論結果による運転変更した場合の水質予測をそれぞれ示すことで、運転変更の効果を確認する。そのため、運転変更前（現状）の設定値、AI が推論した設定値（推奨値）による水質予測結果を比較表示できることが望ましい。



§ 30 カメラシステム

カメラシステムは、画像を撮影し、その画像を伝送し、画像処理 AI で異常診断するためのデータを準備するための装置である。以下の機器及び機能で構成される。

- (1) ネットワークカメラ
- (2) 照明
- (3) 制御機能
- (4) 画像データ保存機能
- (5) データトリミング機能

【解 説】

カメラシステムは、画像を撮影し、その画像を伝送し、画像処理 AI で異常診断するためのデータを準備するための装置である。

(1) ネットワークカメラ

ネットワークカメラは 100 万画素程度の静止画を撮影できる機種を選定する。下水処理場は屋内であっても湿気があるため、屋外型を選定する。定期的な撮影および情報取得が可能なよう、ネットワーク機能を有し FTP 等で遠隔のカメラシステムに画像を自動伝送できることが望ましい。

スカムやフロックを撮影するためには、池の水面にある程度近づけた方がよい。池上から支柱等でカメラを池の水面に近づける。ただしカメラの汚れや蜘蛛の巣を取り除く清掃を行う必要があるため、支柱はカメラを引き上げやすい構造とすることが望ましい。

カメラには LAN ケーブルを取り付けることができる。PoE 給電が可能なカメラを採用すれば、配線を減らすことが可能である。また、遠隔でカメラ設定の変更、撮影画像の伝送を LAN ケーブル経由で行うことができる。

カメラ設置場所と AI 推論システムが遠隔地である場合、有線方式を採用する場合には、LAN ケーブルと光ファイバーを接続するメディアコンバータが必要となる。無線方式を採用する場合には、VPN 接続としデータが不正に外部からアクセスされないよう留意する。




図 4-19 ネットワークカメラ（左）及び照明（右）の設置例

実証では、表 4-11 に示すネットワークカメラ及び光源を使用した。

表 4-11 ネットワークカメラ及び光源の仕様

機器	仕様	サイズ (mm)
ネットワークカメラ	機種：Panasonic BB-SW175A 撮影頻度：0.1-30 fps（設定 0.1 fps） 画素数：1280×960 dot 撮影画像：JPEG 圧縮 電源：AC アダプタ又は PoE 給電 記録方式：SD カード保存、LAN ケーブル経由の FTP 伝送等 消費電力：5 W	110×110×高さ 235
光源 【テープ型 LED】	型式：SunnyNight 5M ホワイト SMD5050 長さ（1 か所当たり）：1.6 m 消費電力：48W（AC アダプタ給電）	—

（２）照明

池面に十分な明るさを与える照明を準備する。実証では、50 W 程度のテープ型 LED 照明を池の水面から 1 m 程度の距離に設置し、テープ長として 1.6 m 程度を要した。照明光を水面に直射した場合、光散乱でブロックやスカムが見えにくくなるため、照明の当て方について注意する。照明は常時点灯する必要はなく、カメラシステム等から点灯及び消灯をタイマー等で自動的に指示することが望ましい。

（３）制御機能

カメラや照明を制御する機能を有する。通常の Windows PC 等でよい。

（４）画像データ保存機能

撮影した画像を保存する。データ保護のため、ハードディスクはミラーリング（二重化）されていることが望ましい。

（５）データトリミング機能

画像処理 AI により異常を診断するため、撮影した元画像を必要な大きさにトリミング（切り出す）する機能である。

§ 31 リモートアクセス

AI 推論システムの稼働状況や AI 推論結果の確認のため、遠隔地からの監視が有効である。

【解 説】

リモートアクセス機能を導入することで、AI 推論システムの稼働状況や AI 推論結果の確認、遠隔地からのリモートメンテナンスや AI エンジンの更新等の機能を付加することができる。そのため、オンプレミス型の装置であれば、それらに VPN 接続が可能なルータを設置することが有効である。