

2-2-1 AIによる画像処理技術を活用した微生物判別技術の開発

計画調整部 技術開発課 塩見 浩
(現 東部第二下水道事務所 葛西水再生センター)

1 はじめに

芝浦水再生センター（以下、「芝浦(セ)」という。）では、2010年頃から反応槽で大量のスカムを発生させる「放線菌」と呼ばれる細菌が増殖している。放線菌の増殖が進むと、異常発泡により発生したスカムが反応槽からあふれだす事象（図1）を生じ、悪臭や衛生面での悪化に加え、職員による日常の点検業務などの安全性に支障をきたすなど、様々な問題を引き起こしている。



図1 放線菌の異常発泡

これまでの放線菌対策として、他系列からの汚泥の転送や反応槽の送風量の増加により硝化処理を促進させる取組などを行ってきたが、固形物の管理や電力面での課題があるため、適切な実施時期を見極める必要がある。異常発泡を未然に防止するには、反応槽における放線菌の存在量と発泡の関係性を導き出し、増殖の兆候をいち早くつかむことが必要である。これまでは、放線菌の存在量職員が顕微鏡により把握していたが、迅速かつ簡便という訳にはいかなかった。

そこで、技術開発課と芝浦(セ)が連携し、放線菌の存在量を把握するための手法の開発に着手した。今回、この取組により、良好な成果が得られたので、以下のとおり報告する。

2 放線菌定量モデルの構築

2.1 定量手法の検討

2.1.1 定量技術の比較

放線菌を測定する手法としては、顕微鏡による観察（顕微鏡）、PCR法、培養法の三種類ある。各測定方法の概要は表1のとおりである。

表1 放線菌測定方法の概要

測定方法	測定方法	長所	短所	備考
顕微鏡	顕微鏡で活性汚泥を観察	即座に結果が得られる	実務経験を要する 測定者間の誤差が大きい	各水再生センターで実施可能
PCR法	PCRという装置で活性汚泥中の放線菌を測定	正確な結果が得られる	専用の装置・器具を必要とする 当局に装置がない	結果が出るまで約2日程度かかる
培養法	活性汚泥を専用の薬品（培地）で培養	ほぼ正確な結果が得られる	結果が出るまで2週間程度要する	放流水中の大腸菌群測定方法とほぼ同じ

これまで、芝浦(セ)では、活性汚泥を顕微鏡で観察し、放線菌を計数する方法を用いていた。一方で、表1に示すとおり、実務経験が少ない場合、放線菌とその他の細菌を区別することが困難であり、測定者間での誤差が大きいといった問題があった。

今回、新たに提案する放線菌の定量手法では、測定者間の誤差など実務経験に左右されることなく、迅速に、結果が得られることを目的とした。

顕微鏡による観察は、迅速性などの点で非常に有用な手法であるが、測定者間で誤差が生じることに課題がある。この点が解消できれば、より実用性を上げることができる。

そこで、AI画像処理技術を用いることを検討した。AI画像処理技術では、ベテラン職員が顕微鏡画像の中から放線菌と判別したものをラベリングし、その特徴を機械学習によって覚え込ませることで、「ベテラン職員の判別する技術を再現する」ことが可能となる。

2.1.2 定量方法の検討

写真2は、芝浦(セ)の反応槽より採取した放線菌の顕微鏡画像である(以下、放線菌の画像は、芝浦(セ)にて収集したものである。)物体検出による測定を想定した場合、左の図では、分散して存在していることから、問題なく一個体ごとを区分して判別し、数えることができる。一方、右の写真では、複数の放線菌が重なり合っているが、大きさや形状の違いから認識しない、あるいは大きな一個体として判別するおそれがある。特に、放線菌は密集して存在していることが多く、物体検出のアルゴリズムでは、満足な計数ができないことが想定される。

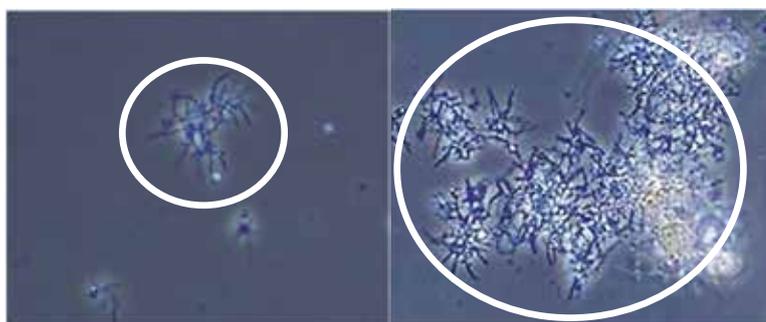


図2 放線菌の顕微鏡画像(左:分散 右:密)

そこで、発想を転換し、画像中の放線菌を個体数ではなく、量としてとらえることを検討した。具体的には、画像中の放線菌部分をぬりつぶし、その面積値を算出することで定量する方法である。測定イメージを図3に示す。この方法では、放線菌の一個体の面積がほぼ同程度であることを前提としている。

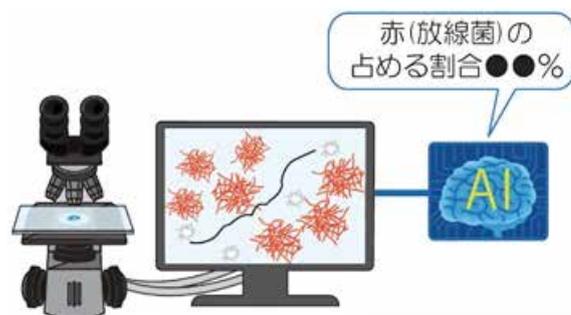


図3 放線菌の測定イメージ

2.2 画像処理モデルの構築

AIによる放線菌定量手法の開発は、放線菌を判別・定量化するモデルを機械学習により構築した。この開発の流れを図4に示す。アルゴリズムの決定から画像の収集・加工、モデルの構築、モデルの評価と進むが、各工程での取組を以下に紹介する。



図4 放線菌定量手法開発の流れ

2.2.1 アルゴリズムの決定

放線菌の定量方法に関するイメージから、画像処理モデルを構築する際の必要要件は、以下の2点である。

- (1) 放線菌の顕微鏡画像を入力画像とし、放線菌とそれ以外（微生物や活性汚泥フロック等）を画素のピクセルごとに判別した結果を出力すること
- (2) 放線菌部分のピクセル数が画像全体に占める割合を算出することで、放線菌を定量すること

アルゴリズムとは特定の問題を解くための手順や方法のことであるが、今回は放線菌だけを他と区別する画像処理のアルゴリズムを検討した。数種類ある画像処理のアルゴリズムの中で代表的な二例を図5に示す。中央の犬2匹の画像をそれぞれの画像処理のアルゴリズムで処理した結果を示す。左のセマンティック・セグメンテーションでは犬の部分のみを抽出しているが、右のインスタンス・セグメンテーションでは、それぞれの犬を分けて抽出している。今回、放線菌かそうでないかの判別であるので、アルゴリズムにはセマンティック・セグメンテーションを採用した。セマンティック・セグメンテーションは車の自動運転や医療画像の診断などに活用されている。



図5 画像処理のアルゴリズム処理

2.2.2 画像の収集・加工

芝浦(セ)反応槽の活性汚泥を対象とし、放線菌を含む顕微鏡画像を収集した。モデルの構築には、大量の画像が必要となることから、令和3年11月～12月に顕微鏡画像約500枚を収集した。この顕微鏡画像から、放線菌の部分にマーキングする。作成するモデルのコンセプトが「ベテラン職員の判別する技術を再現するもの」という考えであるため、マーキング作業は、芝浦(セ)において、日常的に放線菌を計数しているベテラン職員が実施した。この画像をもとに、教師画像や検証用画像を作成し、モデルの構築や評価に使用した。

AIの学習は、教師あり学習とした。教師あり学習とは、作成した教師画像をもとに学習する機械学習のことである。大量の教師画像を学習することにより、対象とするものの特徴を把握する。顕微鏡画像中の放線菌が存在するピクセル（図6左の赤丸）をラベリング処理し、教師画像とした（図6右）。教師画像では、黄色で示されている部分を放線菌とし、その他の菌などをピンク色、何も映っていない背景を黒色で領域分けしている。このように精度の高いモデルを構築するための工夫として、領域を3つに区分した。

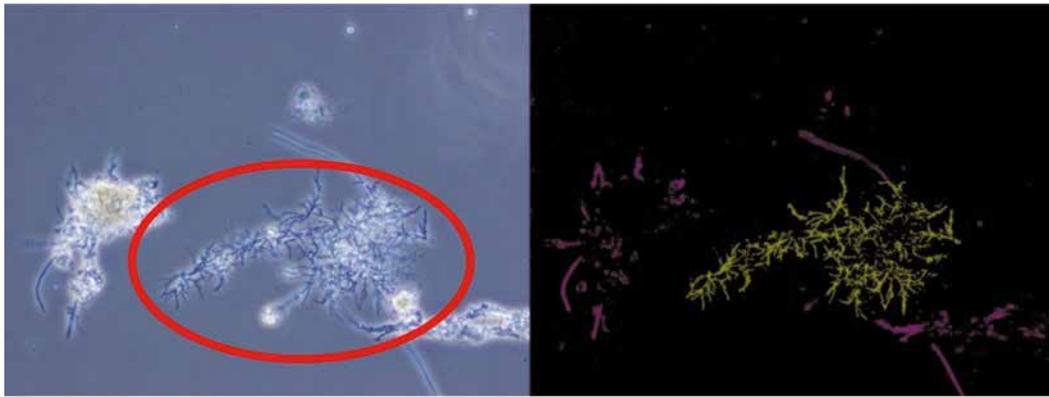


図6 教師画像の例（左：顕微鏡画像 右：教師画像に加工（正解情報を付与）
ラベル 黄色：放線菌、ピンク色：他の菌など 黒色：背景

2.2.3 モデルの構築

準備した教師画像を用いて機械学習によりモデルを構築した。機械学習には、様々な学習条件があるが、主なものとして学習枚数と学習回数がある。これらを検討した内容について、以下に示す。

(1) 学習枚数

学習枚数とは、機械学習に供される画像の枚数のことである。枚数が多くなると精度は向上するが、画像の収集や教師画像への加工に時間を要する。教師画像には 366 枚を使用し、モデルを構築した。

(2) 学習回数

学習回数とは、教師画像を用いて学習した回数である。学習回数を多くすることで特徴の把握が進み判別精度の向上が期待できるが、学習に係る処理時間が長くなる。

今回の構築では、500、3,000、9,000、27,000 回の学習回数で、判別精度を確認した。

学習回数 500 回では、放線菌の認識がまったくされず、3,000 回になるとわずかながら認識がされる程度であった。9,000 回及び 27,000 回の学習した結果を図 7 に示す。両者を比較すると、27,000 回の方が選択されている面積が大きく、多くの放線菌を判別できていることが分かる。学習回数を変化させて検討した結果、80,000 回で判別精度がほぼ上限になった。



図7 学習回数による認識状況の違い 黄色：認識した放線菌

モデル構築には、学習枚数や学習回数以外にも、放線菌を強調するような画像の前処理を行うなど、様々なサポートを人が行うことにより、精度向上を図ることが可能となる。

3 構築モデルの評価

3.1 構築モデルの評価方法

構築したモデルの評価には、学習用に使用していない 101 枚の評価画像に対してモデルが判別し、その結果を検証した。評価指標としては、(1) ベテラン職員による目視、(2) 面積割合の 2 手法で比較した。

3.1.1 目視による評価

モデルが判別した結果となる推論結果について、芝浦(セ)のベテラン職員による目視で評価した。具体的には、モデルが放線菌と異なるものを放線菌と認識していないか、また放線菌ではないと判別したものに放線菌が含まれていないか、をベテラン職員の目で確認し、その誤判別の状況から評価した。

3.1.2 面積割合

面積割合とは、画像中における放線菌の被覆面積割合を指し、以下の式により計算した。ベテラン職員が判別した正解画像とモデルによる推論結果の面積割合の関係性を確認することで評価した。

$$\text{面積割合 (\%)} = \text{放線菌が存在すると推測されるピクセル数} / \text{画像の総ピクセル数}$$

3.2 モデルの評価結果

3.2.1 モデルによる評価結果

検証用の顕微鏡画像をベテラン職員が確認し、放線菌の部分を黄色に着色して正解画像とした。モデルによる判別結果も放線菌と判別された部分を黄色で出力し、推論結果とした。正解画像と推論結果で差異が見られた 2 例を図 8 に示す。この図では、左から検証用の元画像、正解画像、モデルによる推論結果の順で並べている。

図 8①では、元画像(上左)の赤丸で示された範囲に対して、正解画像(上中)の放線菌の部分(黄色で着色)が少なく処理されている。モデルによる推論結果(上右)の白丸で示された部分は、元画像(左上)の赤丸の狭間に位置する部分であることから、正解画像の作成時に選択しなかった可能性が高い。そこで、今後の取組では、事前に正解画像を全て確認する必要があると示唆された。

図 8②では、正解画像(下中)よりモデルによる推論結果(下右)の面積割合が 40%ほど低くなっていた。これは、推論結果(下右)の白丸で囲まれている部分の選択が少なくなっていることによる。元画像(下左)を確認すると、活性汚泥が強く光を反射することで放線菌の見え方が変わっている。その結果、モデルが放線菌ではないと判別したと推測された。このように見え方が異なっているような画像では、漏れが生じる可能性がある。



図8 元画像、正解画像、推論結果の比較（上：①、下：②）

3.2.2 面積割合の評価結果

正解画像と推論結果の面積割合の相関を図9に示す。決定係数 (R^2) が 0.89 と高く、強い正の相関があった。回帰式の傾きは、1.33 であり、モデルの方が多めに判別していた。この要因として、「3.2.1 モデルによる評価結果」で述べた2点が考えられる。今回、構築したモデルでは、人が判別しないような細かな断片も選択していること、また正解画像を作成する際に放線菌の選択が不十分であったことである。両条件とも、推論結果の方が、面積が大きくなる。このような事象の出現率は、ある一定の値に収束するものと想定され、これが 30%程度であると仮定すると、構築したモデルは、人の判別を非常によく再現しているものと判断できる。

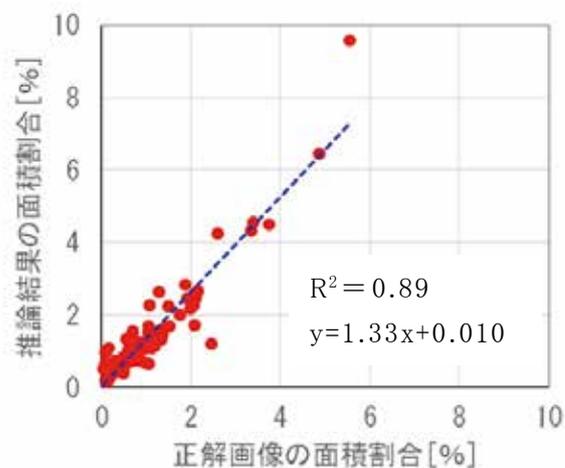


図9 面積割合の相関図

以上の結果より、構築したモデルは、「ベテラン職員の判別する技術を再現する」という当初の目的を達成できていると評価した。

測定 of 迅速性に関しても、モデルをインストールする PC の性能に依存し、定量的に判断することは困難であり、一概には言えないが、一般的なスペックの PC を使用した場合、1 画像あたりの測定時間は 5 分程度以下である。本モデルは PCR 法や培地法と比較して大幅な時間短縮が図られており、十分に迅速であると評価できる。

4 まとめ

今回、ベテラン職員が持つ「顕微鏡画像から放線菌を判別する技術」について、顕微鏡画像を機械学習させることにより、その再現が可能になった。モデルの使用環境に依存す

るが、迅速性についても概ね可能であると評価できた。顕微鏡を使用するための基礎的な知識さえあれば、本モデルにより誰でも迅速に放線菌を計数することが可能となり、測定結果の信頼性・連続性を維持することができる。加えて、構築したモデルは、若手職員が放線菌の判別スキルを習得するためのツールとしても活用できる。

今後の課題として、次の二点がある。第一に、モデルを検証した結果、推論結果の面積割合が正解画像の約 1.3 倍になっていた。そこで、推論結果の面積割合が高かった顕微鏡画像をベラン職員が再確認する必要がある。第二に、モデルの解析結果で放線菌と判断したものが、本に放線菌であるのか、PCR 法や培地法で確認していく必要がある。

放線菌画像の提供や画像中のマーキング作業など、芝浦(セ)職員の方々には多大なご協力をいただいた。この場を借りて感謝申し上げる。