

Flow Imaging Microscope(FlowCam)을 이용한 유해 조류 자동 식별 및 계수 기술 개발

Hirofumi Nakanishi ^{*1}

Tomoya Itou ^{*1}

^{*1} DX Business Development Department, Innovation Center, Marketing Headquarters

수질 및 해양 환경 모니터링 분야에서 수중 미세조류의 종 식별 및 개체 수 측정은 숙련된 작업자의 수작업에 크게 의존하고 있어 정확성과 효율성 측면에서 어려움을 겪고 있다. 본 연구에서는 Yokogawa사의 flow imaging microscope인 FlowCam을 활용한 자동 식별 및 계수 기술을 개발하였다. 원수 및 해수 시료에는 종종 수많은 비표적 조류와 이물질이 포함되어 있으며, 이는 오분류의 주된 원인이다. 이 문제를 해결하기 위해 비표적 데이터의 오분류를 억제하는 분류 지원 모듈을 도입하여 정확도를 향상시켰다. 해조류 양식 지역의 유해 조류인 *Coscinodiscus wailesii*를 대상으로 한 검증 결과, 95% 이상의 종 식별 정확도와 $\pm 10\%$ 이내로 나타났다. 이 기술은 기존 방법에 비해 매우 정확하고 효율적인 조류 모니터링을 가능하게 하며, 수질 관리 및 적조 예측과 같은 분야에 기여할 것으로 기대한다.

서론

저수지는 식수 공급원으로서 중요한 역할을 한다. 그러나 미세조류의 대량 증식은 여과기 막힘, 악취 발생, 맛의 저하와 같은 문제를 야기할 수 있다⁽¹⁾. 또한, 해양 지역에서 유해 조류가 발생하면 양식업에 피해를 주고 수산물 섭취를 통해 인체 건강에 위험을 초래할 수 있다⁽²⁾. 이러한 이유로 해당 수역의 수질은 정기적으로 모니터링하며, 유해 조류 대발생 및 독소 생성 위험을 조기에 파악하여 피해를 최소화하기 위한 조치를 시행한다.

현재의 생물학적 수질 조사에서는 원수 및 해수 시료를 실험실에서 현미경으로 관찰하고, 형태학적 특성에 따라 미세조류를 분류 및 계수한 뒤, 종별 세포 밀도를 산출하는 방법을 사용하고 있다. 구체적인 예로, 일정 부피의 시료를 1mm 격자가 장착된 플랑크톤 계수 챔버에 주입한 후, 현미경을 통해 각 격자 셀 내의 미세조류를 종별로 식별하고, 계수기를 사용하여 종별 세포 수를 집계한다. 그런 다음 모든 격자 셀의 총 계수치를 시료 부피로 나누어 세포 밀도를 산출한다⁽³⁾. 그러나 이러한 방법은 상당한 노력과 긴 측정 시간이 소요된다. 또한 전문 지식을 갖춘 숙련된 기술자만이 수행할 수 있으며, 측정 정확도는 기술자의 판단에 따라 달라질 수 있다.

이러한 문제점을 해결하기 위해, 본 연구에서는 Yokogawa의 flow imaging microscope인 'FlowCam'을 이용하여 미세조류를 종별로 자동적이고 신속하게 식별 및 계수하는 방법을 개발하였다. FlowCam은 Flow cell을 통과하는 액체 시료 내의 입자를 지속적으로 촬영하고, 그 결과 이미지를 기록 및 분석한다. 그림 1은 FlowCam 8000의 외관을 보여준다. FlowCam 8000은 획득한 이미지를 통해 입자의 크기, 모양 및 기타 매개변수를 분석할 수 있지만, 종 식별 기능이 내장되어 있지는 않다. 따라서 본 연구에서는 획득한 이미지를 바탕으로 학습 모델을 구축하고, 인공지능 기반의 종 식별 기술을 개발하였다. 원수 및 해수 시료에는 비표적 조류와 이물질이 다량 포함되어 있어 오분류의 주된 원인이 되므로, 비표적 데이터의 오분류를 억제하고 정확도를 향상시키기 위해 분류 지원 모듈을 도입하였다. 본 논문에서는 이 기술의 개발 과정과, 해조류 양식 지역에서 유해 조류인 *Coscinodiscus wailesii*의 세포를 식별하고 계수하기 위해 이 기술을 활용한 검증 시험 결과를 보고한다.



그림1 Flowcam8000

방법

시스템 개요

본 연구에서 개발된 시스템은 FlowCam 8000을 이용한 포괄적인 입자 이미지 획득 및 형태학적 매개변수 계산을 시작으로, 표적 조류 종을 식별하고 세포 밀도를 추정하는 것을 목표로 한다(그림 2). FlowCam 8000은 2배에서 20배에 이르는 대물렌즈를 지원하지만, *C. wailesii*(직경이 수백 μm 인 원통형 미세조류)의 이미지를 선명하게 촬영하고 높은 이미지 획득 처리량을 달성하기 위해 4배 대물렌즈를 사용했다.

구체적으로, FlowCam을 사용하여 각 입자에 대해 크로핑(개별 입자를 감지하고 추출하는 과정) 및 마스크 생성(입자의 모양에 부합하는 영역을 추출하는 과정)을 수행한 후, 형태학적 매개변수를 계산하고 종 식별을 진행했다. 이번 검증 연구에서는 대상 종인 *C. wailesii*를 식별하기 위해 두 가지 방법이 사용되었다. 하나는 FlowCam으로 계산된 형태학적 매개변수를 단일 클래스 분류와 결합하는 형태학적 매개변수 방법이고, 다른 하나는 크롭된 입자 이미지를 직접 학습시키는 딥러닝 방법이다. 현장 시료에는 비대상 종의 입자가 포함될 수 있으므로, 두 방법 모두 비대상 입자를 배제하기 위해 분포 외(OD) 탐지 메커니즘을 통합했다. 여기서 OD는 학습된 분포로부터의 편차를 의미하며, 대상 종 이외의 종에 속하는 데이터 샘플이 OD로 탐지될 것으로 예상되었다. 식별 후, 세포 밀도 C 는 다음과 같이 추정되었다.

$$C = \frac{N_{acc}}{V \times \eta \times \alpha}, \quad (1)$$

여기서 N_{acc} 는 표적 종으로 식별된 입자의 수, V 는 처리된 시료의 부피(mL), η 는 유효 이미징 속도(FlowCam 소프트웨어에서 출력되는 "효율(Efficiency)" 값으로 간주), α 는 이미징 중 시야 가장자리에서 입자의 부분적 클리핑과 같은 요인으로 인한 기기별 변동을 보정하는 보정 계수이다. 본 연구에서는 $\eta = 0.356$ 및 $\alpha = 0.760$ 을 사용하였으며, 세포 밀도는 세포/ mL 단위로 표기하였다. α 는 예비 검증 연구에서 현미경 검사를 통해 얻은 세포 밀도와 FlowCam 데이터로부터 계산된 세포 밀도 간의 일치도를 분석하여 결정되었으며, 해당 결과를 바탕으로 계산되었다.

형태학적 매개변수 측정법

형태학적 매개변수 방법의 경우, Flow Cam 전용 분석 소프트웨어인 VisualSpreadsheet로 계산된 수많은 형태학적 매개변수 중에서 분포, 상관관계 및 다중공선성을 검토하는 탐색적 데이터 분석을 통해 유효한 매개변수 집합을 선정하였다(표 1). 이러한 매개변수들은 크기, 모양, 질감과 같은 정보를 요약하여, 노이즈를 억제하면서도 식별에 유용한 정보를 통합한다. 매개변수 간의 척도 차이 영향을 제거하기 위해, 학습 전에 표준화 처리를 적용하였다.

부정 예제 데이터 없이도 학습이 가능한 1-클래스 서포트 벡터 머신⁽⁴⁾(방사형 기저 함수 [RBF] 커널)을 모델로 채택하였다. 이 프레임워크는 *C. wailesii*의 양성 예제 데이터로부터 이 종에 전형적인 특성 범위(정상 영역)를 학습하며, 해당 범위 밖의 표본을 비표적(non-target)으로 처리한다. RBF 커널을 사용함으로써 모델은 선형으로 표현하기 어려운 경계도 수용할 수 있다.




그림 2 시스템 개요

하이퍼파라미터는 베이지안 최적화⁽⁵⁾를 통해 결정되었다. 구체적으로, 각각 이상치 허용 오차와 경계 세분성을 제어하는 두 가지 주요 파라미터인 ν 와 γ 에 대해 검색이 수행되었으며 검증 데이터에서 F1 점수를 최적화하는 것을 목표로 한다. 이 검증 연구는 *C. wailesii*라는 단일 종만을 대상으로 하므로, One-Class SVM만으로 프로세스가 완료된다. 여러 종을 대상으로 할 경우, 이 방법을 1단계로 사용하여 이상치 탐지 및 후보 제외하는 데 이 접근법을 첫 번째 단계로 사용하는 2단계 구성으로 확장될 수 있다. 추출 단계에 이어 두 번째 단계에서 다중 클래스 분류 모델을 적용함으로써, 여러 대상 종을 식별할 수 있게 한다.

표 1 형태학적 매개변수 기법에 사용된 매개변수

매개변수 이름	간략한 설명
Aspect Ratio	입자를 타원으로 가정했을 때, 단축과 장축의 비율; 값이 1에 가까울수록 원형에 가까운 모양을 나타냄
Compactness	입자의 복잡성을 나타내며, 값이 높을수록 복잡성이 더 큼
Geodesic Length	입자를 직사각형으로 가정했을 때 긴 변의 길이
Geodesic Thickness	입자를 직사각형으로 가정했을 때의 짧은 변의 길이

딤러닝 방법

이 방법의 목표는 다층 신경망을 통해 개별 입자의 잘린 이미지에서 고수준의 특징을 추출함으로써, 형태학적 매개변수만으로는 특성화하기 어려운 국소적인 모양과 복잡한 질감을 포착하여, 시료에 밀접하게 관련된 종이나 미지의 입자(비표적 종)가 존재할 때 식별의 견고성을 높이는 것이었다. 계산 속도와 인식 정확도 간의 균형을 고려하여 기본 모델로 EfficientNet-V2-Small⁽⁶⁾을 채택했다. 전처리 단계에서는 크기 조정, 패딩(여백 추가), 회전, 명암/밝기 조절 등 FlowCam 이미지의 특성에 맞춘 이미지 증강 기법을 적용했다.

학습은 두 단계로 구성되었다. 첫째, 시각적 표현의 대조적 학습을 위한 단순 프레임워크(SimCLR)⁽⁷⁾를 따르는 자기 지도 학습을 통해 타겟 클래스와 독립적인 고품질 초기 표현을 획득했다. 이어서 지도 대조적 학습(SupCon)⁽⁸⁾과 유사한 방법을 적용하여, 타겟 중 분류 학습과 함께 클래스 내 밀집도와 클래스 간 분리를 동시에 강화했다. 이 과정을 통해 근연종과 같이 시각적으로 유사한 입자 이미지에 대한 결정 경계가 명확해졌으며, 안정적인 분리가 가능한 특징 공간이 도출되었다. 주요 하이퍼파라미터(에포크 수, 학습률, 배치 크기 등)는 지정된 하이퍼파라미터 후보들의 모든 조합을 테스트하는 그리드 검색을 통해 선정되었다.

OOD 탐지를 위해, SupCon 인코더가 학습한 특징의 근접성을 활용하는 k-최근접 이웃 기반 OOD 탐지(k NN-OOD)⁽⁹⁾가 채택되었다. 여기서 인코더 f_θ 는 특징 추출 구성 요소를 제외하는 데 이 접근법을 첫 번째 단계로 사용하는 2단계 구성으로 확장될 수 있다. 입자 이미지 x 는 특징 벡터 $z = f(x) \in R^d$ 로 매핑되며, 훈련 특징 집합 Z_{train} 에 대한 유클리드 거리를 기반으로 한 k-최근접 이웃 집합 $N(z)$ 가 계산된다. OOD 점수 $s(x)$ 는 이웃 거리의 평균으로 정의된다:

$$s(x) = \frac{1}{k} \sum_{z_i \in N_k(z)} \|z - z_i\|_2$$

임계값 τ 는 검증 데이터에 대한 점수 분포 $\{s(x_{val})\}$ 의 95번째 백분위수에 계수 α (본 연구에서는 $\alpha = 1.2$)를 곱하여 설정하였으며, OOD 판정은 다음 규칙에 따라 이루어졌다:

$$\tau = \alpha \cdot P_{95}(\{s(x_j^{val})\})$$

$$Decision(x) = \begin{cases} in\ distribution & if\ s(x) \leq \tau \\ out\ of\ distribution & if\ s(x) > \tau \end{cases}$$

여기서는 $k = 3$ 을 사용했으며, 모든 훈련 데이터에 대해 최근접 이웃 검색을 수행했다. 이러한 접근 방식을 통해 분류기의 확률 출력이 아닌 훈련 데이터 분포와의 근접성에 기반한 OOD 탐지 메커니즘을 구현함으로써, 알려지지 않은 입자가 존재할 때 발생하는 오분류를 억제할 수 있었다.

평가 방법

데이터셋

정확하게 라벨링된 학습 데이터를 활용하기 위해, 분리 배양된 샘플을 사용하여 모델을 구축하고 현장 해수 샘플을 사용하여 평가를 수행했다(표 2, 그림 3). 배양은 두 차례 수행되었으며, 매번 $N = 3$ (샘플 수)으로 15일 이상 배양하고 2~3일 간격으로 FlowCam을 사용하여 데이터를 수집했다. 첫 번째와 두 번째 배양 시료 간의 세포 크기 차이가 큰 것은, 재배양 및 사전 배양 기간이 서로 다른 *C. wailesii* 균주를 사용했기 때문이다. 해양 시료는 2024년 9월부터 10월 사이에 효고현 Harimanada의 30개 지점에서 채집되었다. Harimanada에서 채집된 시료는 배양 시료에 비해 세포 면적이 더 작은 경향을 보였다. 표지 작업은 현미경 검사관 또는 해당 검사관의 감독 하에 근무하는 담당자가 수행했다. 또한 모델의 견고성을 평가하기 위해 효고현 Tajima 해안에서 추가로 채집한 해양 시료를 사용했다. 딤러닝 모델에서 대조군을 포함하면 특징 공간을 보다 안정적으로 구축할 수 있다. 이러한

이유로 본 연구에서는 *아나바에나*(*Anabaena*) 및 *카레니아*(*Karenia*)와 같이 *C. wailesii*와 형태학적으로 구별되는 여러 미세조류 종을 대조군으로 학습 데이터에 포함시켰다. 단, 평가는 *C. wailesii*의 분류 정확도로만 한정되었음을 유의해야 한다.

표 2 각 데이터 세트의 이미지 수

	배양 배치 1	배양 배치 2	Harima-Nada	Tajima 해안
<i>C. wailesii</i>	2147	4178	582	5
<i>C. wailesii</i> 일부	30	141	—	—
<i>C. wailesii</i> 피각(껍질)	338	2372	—	—
<i>C. wailesii</i> 와 밀접한 관련이 있는 종	—	—	193	—
기타 (미세조류, 부유물 등)	4528	18176	58247	20245

그림 3 각 데이터셋의 예시 이미지



평가 프레임워크

Harimanada의 30개 지점에서 해수 시료를 채취하고, 세포 밀도에 따라 10~200 mL의 원수를 농축한 후 FlowCam을 사용하여 이미징을 수행했다. 세포 밀도는 식 (1)을 사용하여 추정하였으며, Tajima 연안에서 채취한 시료도 동일한 방법으로 평가했다.

분류 정확도를 평가하기 위해 일반적으로 사용되는 지표인 정밀도(Precision), 재현율(Recall), F1 점수(정밀도와 재현율의 조화평균)를 사용했다. 또한, 세포 밀도 추정치의 정확성을 검증하기 위해 기존의 현미경 기반 세포 밀도 계산 방법을 비교 기준(참조)으로 사용했다. 이를 위해 추정값과 기준값 간의 일치 정도를 평가하기 위해 결정계수(R^2)를 계산하였고, 오차의 크기를 평가하기 위해 평균절대오차(MAE)를 계산하였다. 회귀 문제에 대한 이러한 대표적인 평가 지표를 사용하여, 본 방법과 기존 방법 간의 차이를 정량적으로 평가하였다.

결과

모델 방법 간 비교

형태학적 매개변수 방법의 F1 점수는 84.1%였습니다(표 3). *C. wailesii* 이미지보다 비타겟 입자 이미지가 약 100배 더 많았음에도 불구하고, 비타겟 종의 오분류는 약 0.25%로 억제되어 정밀도(Precision)의 현저한 저하를 방지할 수 있었다(표 4). 오분류 사례에는 학습 데이터에 포함되지 않은 비정상적으로 밀집된 색소 침착을 보이는 *C. wailesii* 세포, 밀접하게 관련된 종, 빈 피각(껍질) 및 세포 파편(Debris) 등이 있었으며, 이 중 일부는 전문가조차 구별하기 어려운 사례들이었다(그림 4).

딥러닝 방법의 F1 점수는 93.0% (표 3)이었다. 비타겟 종의 오분류는 약 0.05%로 억제되었으며, 정밀도는 형태학적 매개변수 방법보다 약 15% 높았고, F1 점수는 약 10% 더 높았다(표 5). 이는 SimCLR/SupCon을 통해 OOD 탐지에 적합한 특징 공간이 형성되었고, kNN-OOD 탐지를 통해 OOD 경계 부근의 오분류를 억제했기 때문으로 볼 수 있다.

표 3 두 방법의 정확도 지표

	정밀도	재현율	F1 점수
형태학적 매개변수 방법	79.1%	89.9%	84.1%
딥러닝 방법	94.3%	91.8%	93.0%

표 4 형태학적 매개변수 기법의 혼동 행렬

		예측	
		<i>C. wailesii</i>	<i>not C. wailesii</i>
실제	<i>C. wailesii</i>	523	59
	<i>not C. wailesii</i>	138	58302
	세부 분류		
	유사 종	25	168
	기타	113	58134




	형태학적 매개변수 방법	딥러닝 방법
라벨: <i>C. wailesii</i> 예측: 기타		
라벨: <i>C. wailesii</i> 와 밀접하게 관련된 종 예측: <i>C. wailesii</i>		
라벨: 기타 예측: <i>C. wailesii</i>		

그림 4 각 방법에서 잘못 분류된 이미지의 대표적인 예

이번 검증 연구에서, *C. wailesii*의 크기는 학습에 사용된 배양 데이터와 평가에 사용된 Harimanada 데이터 간에 상당한 차이를 보였으며, 세포 형태에도 뚜렷한 차이가 나타났다. 그럼에도 불구하고 두 방법 모두 실용적인 사용에 충분한 높은 정확도를 달성했으며, 이는 두 접근법 모두 *C. wailesii*의 핵심적 특성을 성공적으로 모델링한 것으로 보였다.

두 방법 모두 현미경 계수를 통해 측정된 세포 밀도 값에 비해 높은 예측 정확도($R^2 \geq 0.9$)와 낮은 오차(MAE ≈ 1.5)를 보여주었다(그림 5). 이는 *C. wailesii*와 같이 뚜렷한 형태학적 특징을 가진 종의 경우, 형태학적 매개변수 방법만으로도 실용적인 수준의 정확도를 달성하기에 충분할 수 있음을 시사한다. 반면, 복잡한 패턴, 미세 구조 또는 국소적 특징에 의존하는 종이나 작업의 경우, 딥러닝 방법의 장점이 더욱 두드러질 것으로 예상된다. 따라서 요구되는 정확도, 대상 종의 특성, 처리 속도 및 계산 자원에 대한 제약 조건에 따라 두 방법 중 하나를 선택하는 것이 중요하다.

표 5 딥러닝 방식의 혼동 행렬

		예측	
		<i>C. wailesii</i>	<i>C. wailesii</i> 아님
실제	<i>C. wailesii</i>	534	48
	<i>C. wailesii</i> 아님	32	58408
	세부 분류 유사		
	중	21	172
	기타	11	58236




그림 5 각 방법에 대한 측정된 세포 밀도와 예측된 세포 밀도 비교 (30개 측정 지점)

표 6 Tajima 해안 데이터에 대한 혼동 행렬

		예측	
		<i>C. wailesii</i>	<i>C. wailesii</i> 아님
실제	<i>C. wailesii</i>	5	0
	<i>C. wailesii</i> 아님	1	20244




그림 6 Tajima 해안 데이터에서 잘못 분류된 *C. wailesii*

Tajima 연안 외곽에서 채취한 시료를 이용한 딥러닝 방법의 견고성 검증

Tajima 연안에서 채집된 *C. wailesii*가 포함된 표본을 사용하여 딥러닝 방식의 정확도와 두 방법 중 어느 것이 더 우수한 성능을 보였는지 검증하고, 그 견고성을 평가하였다. 그 결과, 한 개를 제외한 모든 입자가 정확하게 식별되었다(표 6, 그림 6). 오분류 사례는 밀접하게 관련된 종이 *C. wailesii*로 식별된 경우였으며, 전문가라도 구별하기 어려운 이미지였다. 이러한 결과는 본 방법이 모델 구축에 사용된 해역과 다른 해역의 표본도 분류할 수 있음을 보여줌으로써, 그 견고성을 입증한다.

딥러닝 방법에서의 OOD 점수 시각화 및 활용

딥러닝 방법에서는 모델의 임베딩 공간 내 평균 kNN 거리를 기반으로 한 OOD 점수를 사용하여 OOD 탐지를 수행한다. SupCon은 동일한 클래스에 속한 샘플은 서로 가깝게, 서로 다른 클래스의 샘플은 멀리 떨어지도록 임베딩 공간을 학습시키기 때문에, OOD 점수는 알려진 클래스로부터의 분리 정도를 정량화한다. *C. wailesii*로 추정된 이미지의 OOD 점수 분포를 실제로 관찰한 결과, 점수가 높아질수록 비표적 종 이미지의 비율이 증가했으며, 이 추세에서 급격한 변화가 나타났다. 설정된 임계값 주변(그림 7 및 8). 또한, 임계값 근처의 사례에는 밀접하게 관련된 종이 자주 포함되었기 때문에, 다음의 워크플로우를 적용함으로써 실무에서 높은 정확도, 안정성 및 투명성을 달성할 수 있다. 이 방법은 임계값 근처의 데이터만 수동으로 검토함으로써, 비표적 종의 오분류를 억제한다. 또한, 임계값 근처 사례에 대한 전문가의 판단 결과를 축적하여 재훈련에 활용함으로써 모델의 지속적인 개선이 가능해진다.




그림 7 다양한 OOD 점수를 나타내는 예시 이미지




그림 8 설정된 임계값 주변 OOD 이미지

토론

본 연구에서는 FlowCam을 이용하여 특정 미세조류 종을 식별하기 위한 두 가지 방법, 즉 형태학적 매개변수법과 딥러닝법을 개발하고 평가하였다. 딥러닝법이 더 높은 정확도를 보였으나, 두 방법 모두 실제 적용에 충분한 정확도를 보여주었다. 각 방법은 정확도와 계산 부하 측면에서 뚜렷한 장점을 가지고 있으므로, 현장 요구 사항에 따라 두 방법을 상호 보완적으로 활용하는 것이 효과적인 접근 방식이 될 것이다. 계산 자원이나 구현 용이성이 제한 요인이 되는 상황에서는 형태학적 매개변수 방법이 더 유리한 반면, 밀접하게 관련된 종이 빈번하게 출현하거나 계절 또는 지리적 영역에 따른 분포 변동성이 크며, 미확인 입자가 자주 관찰되는 환경에서는 딥러닝 방법이 유리하다. 또한, 딥러닝 방법은 OOD 점수를 활용한 부분적인 인간 개입을 통해 매우 높은 정확도와 지속적인 모델 개선을 동시에 달성할 수 있다. 향후 여러 종을 동시에 식별해야 하거나 군집성 종으로 적용 범위를 확장해야 하는 상황에서는 딥러닝 방식의 장점이 더욱 두드러질 것으로 예상된다.

결론

본 연구에서는 flow imaging microscope FlowCam을 활용하여 미세조류의 자동 종 식별 및 계수 기술을 개발하였으며, 숙련된 기술자의 현미경 관찰에 기반한 기존 방법보다 더 빠르고 정확한 조류 모니터링을 실현할 수 있는 잠재력을 입증하였다. 향후, 이 기술을 다른 여러 종에 적용할 때의 정확성과 견고성을 검증하고, 군집성 종을 위한 세포 식별 및 계수 기술을 개발할 계획이다.

감사의 말

본 연구는 효고현 농림수산기술센터 산하 수산기술연구소와의 협력을 통해 수행되었다. 협력해 주신 모든 분께 깊은 감사를 드립니다.

참고문헌

- (1) Ministry of Land, Infrastructure, Transport and Tourism, Guidelines for Improving Water Quality in Dam Reservoirs, 2018 (in Japanese)
- (2) K. Kohata, "Basic Knowledge on Environmental Issues: Red Tide," National Institute for Environmental Studies News, Vol. 23, No. 4, 2004, pp. 8-9 (in Japanese)
- (3) Japan Water Works Association, Standard Methods for Examination of Water, 2011 Edition, Part VI: Biology, 2011 (in Japanese)
- (4) B. Schölkopf, R. C. Williamson, et al., "Support Vector Method for Novelty Detection," Proc. Advances in Neural Information Processing Systems (NeurIPS), Vol. 12, 2000, pp. 582-588
- (5) J. Snoek, H. Larochelle, et al., "Practical Bayesian optimization of machine learning algorithms," Proc. Advances in Neural Information Processing Systems (NeurIPS), Vol. 25, 2012, pp. 2951-2959
- (6) M. Tan, Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," Proc. 38th Int. Conf. Machine Learning (ICML), Vol. 139, pp. 10096-10106
- (7) T. Chen, S. Kornblith, et al., "A Simple Framework for Contrastive Learning of Visual Representations," Proc. 37th Int. Conf. Machine Learning (ICML), Vol. 119, 2020, pp. 1597-1607
- (8) P. Khosla, P. Teterwak, et al., "Supervised Contrastive Learning," Proc. Advances in Neural Information Processing Systems (NeurIPS), Vol. 33, 2020, pp. 18661-18673
- (9) Y. Sun, Y. Ming, et al., "Out-of-Distribution Detection with Deep Nearest Neighbors," Proc. 39th Int. Conf. Machine Learning (ICML), Vol. 162, 2022, pp. 20827-20840

* FlowCam 은 Yokogawa Electric Corporation 의 등록상표이다.

* 본 논문에 등장하는 기타 모든 회사명, 조직명, 제품명, 서비스명 및 로고는 Yokogawa Electric Corporation 또는 각 소유권자의 등록상표 또는 상표이다.