

スマートオーシャンに向けた 水産業の エレクトロニクス・ビジュアル モニタリング

ジェン ネン・ウォング 教授

ワシントン州シアトル ワシントン大学
電気コンピューター工科学科

hwang@uw.edu

EDF水産業のためのAIワークショップ、

日本、2021年9月





ワシントン大学 & NOAA エレクトロニック モニタリング イノベーション プロジェクト


2011-2026

ALASKA FISHERIES SCIENCE CENTER



W ELECTRICAL & COMPUTER
ENGINEERING

Northwest Fisheries Science Center



Farron Wallace
Craig Rose
Suzanne Romain
Paul Packer
Braden Moore
Kelsey Magrain
Graeme Lee-Son
Gaoang Wang
Tsung-Wei
Huang Jairui Cai
Jie Mei
Aotian Zheng

Collaborations



Galveston Laboratory

A laboratory of the Southeast Fisheries Science Center.



動機


- 水産業は**数十億ドル規模の世界적인産業**であり、長期的な持続性のためには**管理政策**が必要
- **カメラシステム**による**魚類資源**のモニタリングは、保全生態学や資源評価の分野では**一般的**になる






NOAAアラスカ漁業科学センター (AFSC) Cam-Trawl

- トロール網とステレオカメラシステムの組合せ
- サンプルング後に魚が無傷で通過できる



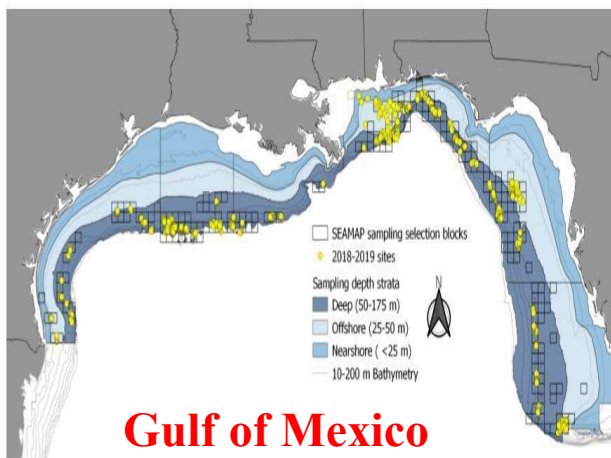
[K. Williams, et al, 2010]





NOAA東南地域モニタリング & アセスメントプログラム (SEAMAP)

- 1992年以降4,500万枚以上のファイル、167TB以上のデータ、年間約13TB増





漁業活動の エレクトロニックモニタリング

- 連邦漁業における電子モニタリング (EM) システム
 - 魚種とサイズをモニター
 - ほぼリアルタイムの報告 (衛星経由)、規制遵守




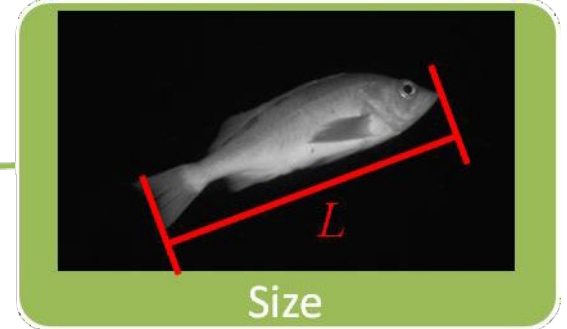

チュートベースの水揚げモニタリング



延縄漁水揚げモニタリング



スマートオーシャンのためのビッグ データ



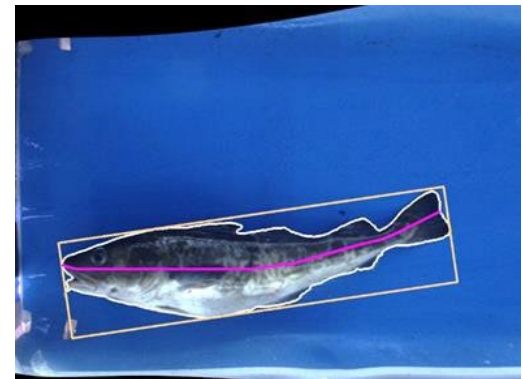







概要

- 漁業のエレクトロニック ビジュアル モニタリング
- シュートベースのエレクトロニック モニタリング
- 延縄漁水揚げの エレクトロニック モニタリング
- 結論

魚の体長測定

- 変形のバリエーションが多い → 形態的正中線





向きの違い

湾曲

分岐した尾




長さの計測例



11種の魚類 (3571サンプル) の絶対値誤差の平均値 - 1.49%

Tsung-Wei Huang, et al, IEEE ICASSP 2016



悪水質の状況 下での魚の数量 や長さの測定

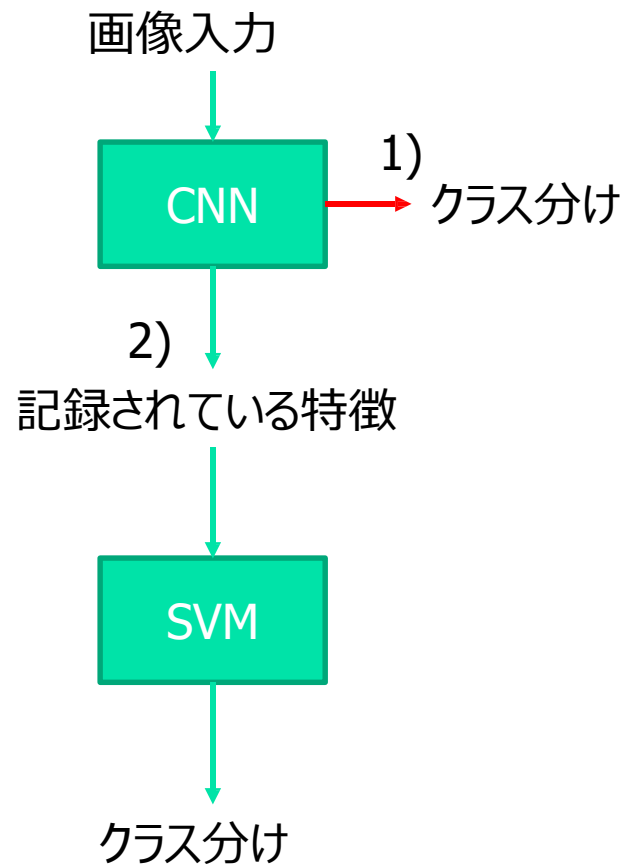




ディープラーニング (深層学習) による魚種判別

- トレーニングデータ (201クラス、2015+2016+2019年)
 - 11557 (x150 増加)
- 試験データ
 - 1412

手法	正確性 (201 クラス)
BoF (7168-dim) + SVM	89.1%
CNN (Inception ResNet v2)	91.7%
CNN (1536-dim) + SVM	92.9%





Fish ID作業の再確認

- データセット
 - 2015 シュートデータ (8835の画像 27 クラス)
 - 2016シュートデータ (5032の 画像 27 クラス)
- 同じデータセットをトレーニングとテストに分割

Training Data	Testing Data	Cross Validation	Accuracy (%)
2015	2015	10-fold	96.1
2016	2016	10-fold	98.5
2015+2016	2015+2016	10-fold	96.9

Training Data	Testing Data	Acc (%)
2015 dataset (5%)	2015 dataset (95%)	83.9
2016 dataset (5%)	2016 dataset (95%)	86.6
2015 dataset (100%)	2016 dataset (100%)	69.5
2015 dataset+2016 dataset (5%)	2016 dataset (95%)	88.1





管理指導学習の問題点

- トレーニングデータセットとテストデータセットの差異が大きい場合（ドメインやラベルの移動）

- 種のバリエーションが少ない
- カメラの色の反応が異なる
- 種の分布が異なる

種の分配

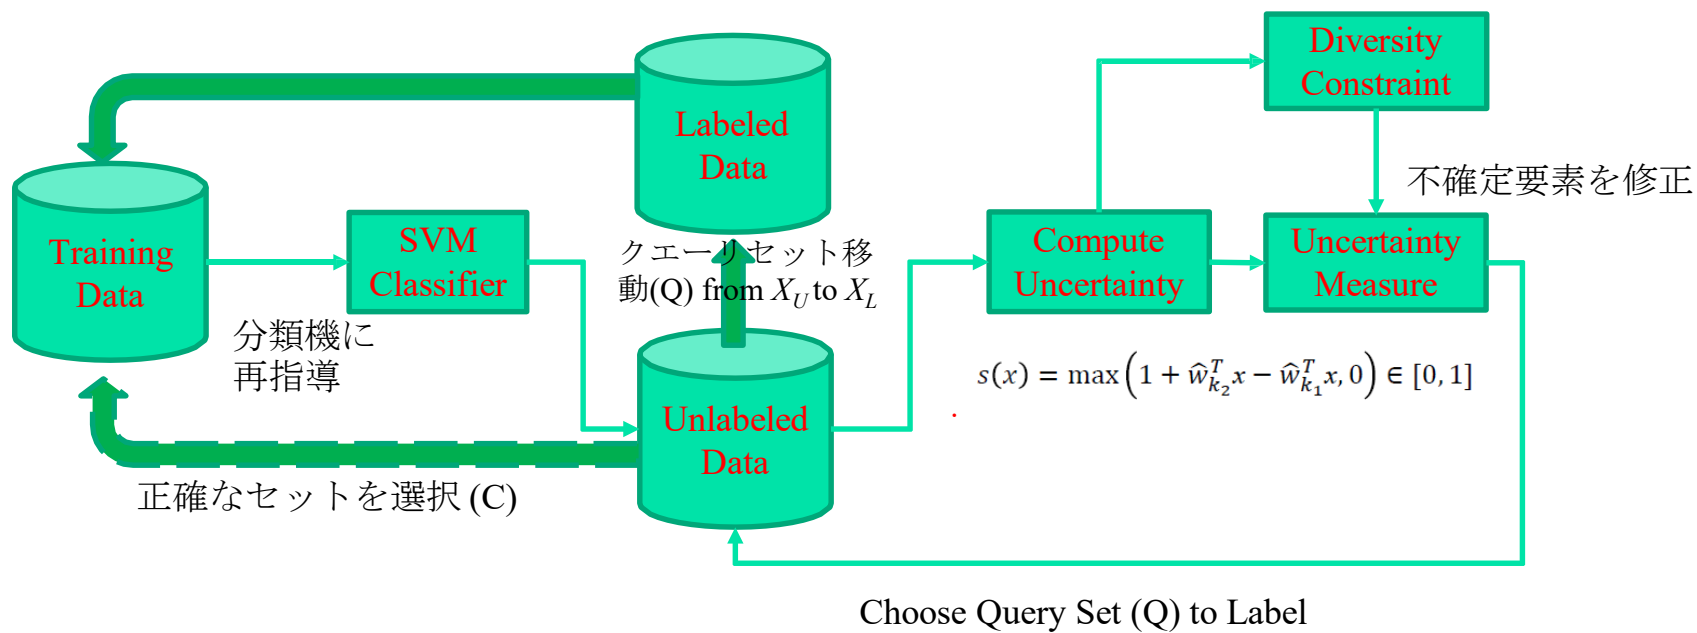


Fish ID	Fish Name
1	Arrowtooth Flounder
2	Atka Mackerel
3	Bathymaster Signatus
4	Berryteuthis Magister
5	Blackspotted Rockfish
6	Dover Sole
7	Dusky Rockfish
8	Flathead Sole
9	Giant Grenadier
10	Gorgonocephalus Eucnemis
11	Harlequin Rockfish
12	Northern Rock Sole
13	Northern Rockfish
14	Pacific Cod
15	Pacific Halibut
16	Pacific Ocean Perch
17	Pacific Octopus
18	Paragorgia Arborea
19	Prowfish
20	Rex Sole
21	Sablefish
22	Shortraker Rockfish
23	Shortspine Thornyhead
24	Strongylocentrotus sp
25	Sturgeon Poacher
26	Walleye Pollock
27	Yellow Irish Lord



ドメイン適合のための 能動的(クエリ)学習

- 目標：分類性能向上のため、人によるラベリングに有益なサンプルを繰り返し選択する。

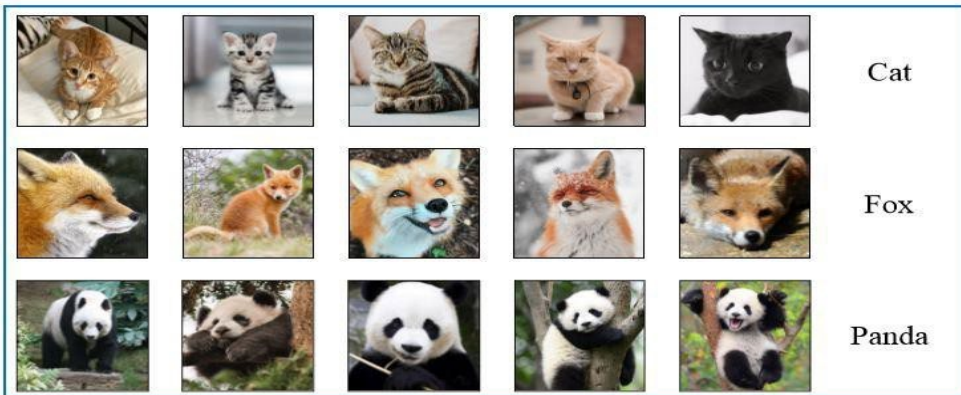


- 2015 データセット+2016 データセット (5%): **88.1% → 96.8%**



実世界での物体認識

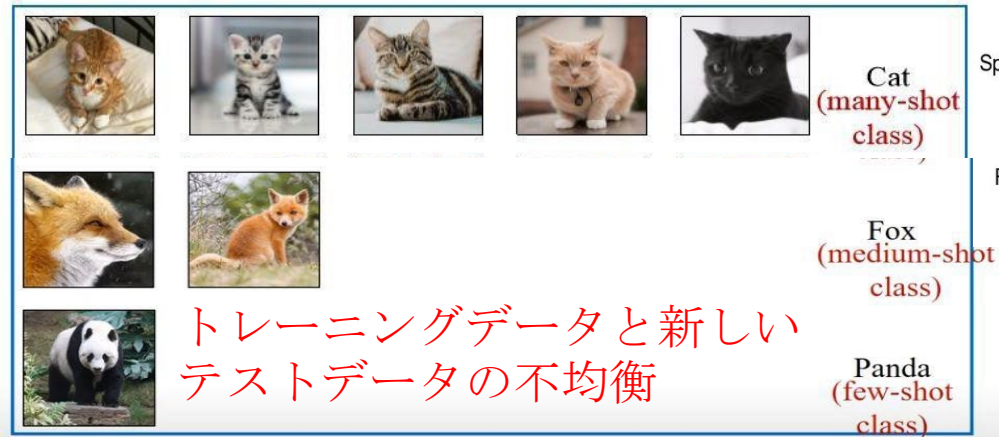
Train



Test



Train



Test



ロング テイルド認識 (LTR)
オープン セット認識 (OSR)

Spam/anomaly detection




Disease diagnosis

Species identification



Autonomous driving

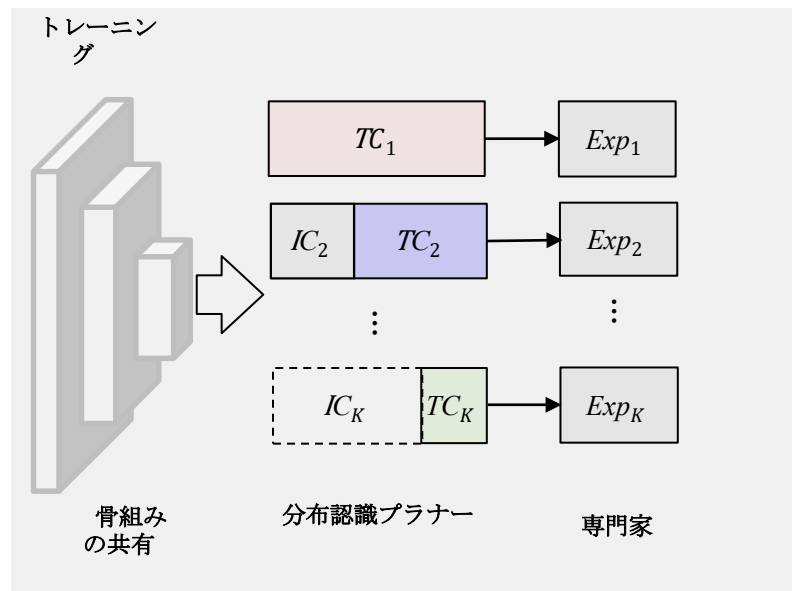
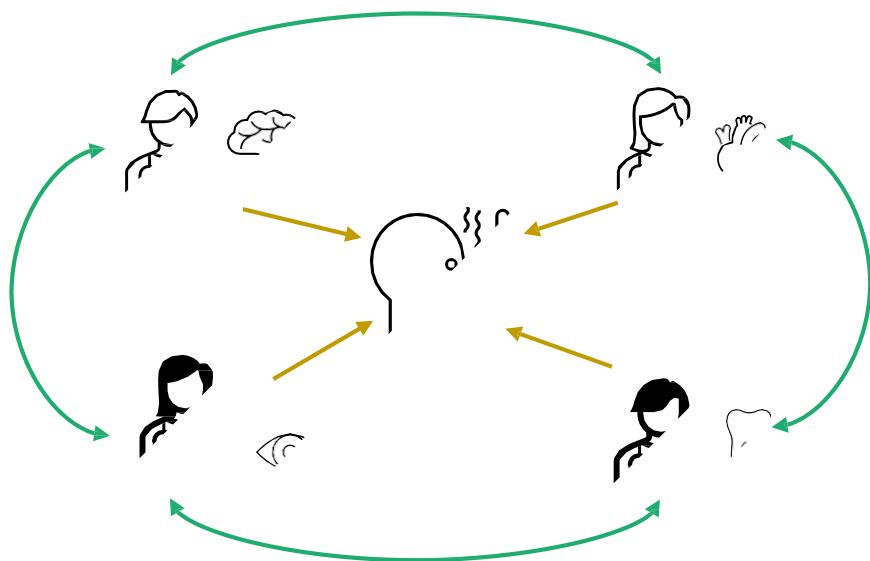
Recommendation system



Face recognition



ACE : LTRのための エキスパートを補完



TC: ターゲットカテゴリ

IC: 干渉カテゴリ

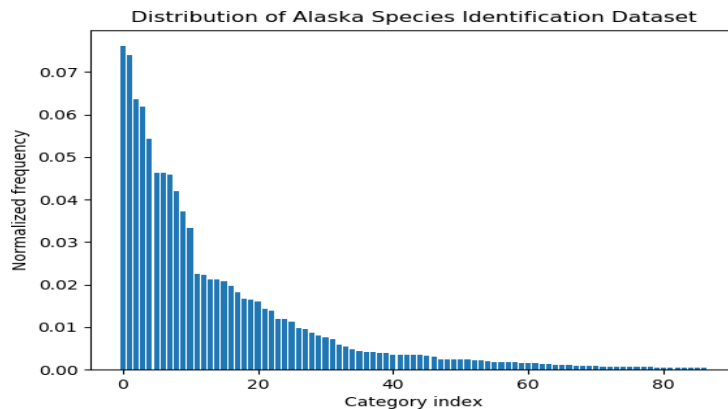
- 複数の専門家の意見を取り入れる
- 干渉する可能性のあるものを排除するためのパネル・ディスカッション

Jiarui Cai, et al., "ACE: Ally Complementary Experts for Solving Long-Tailed Recognition in One-Shot," ICCV 2021



Alaska Chute Fish データセット

- Alaska species ID データセット: 26.4k 画像で **87クラス**
- Many (多数) -ショット (>100 samples): **38 クラス**
- Medium (中間数) -ショット (>20 and <=100 samples): **33 クラス**
- Few (少数) -ショット (<= 20 samples): **16 クラス**



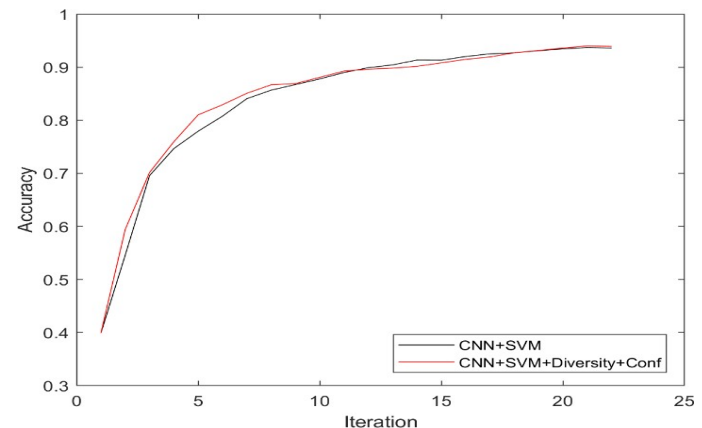
- Imbalance factor = $N_{\max}/N_{\min} = 193.5$

	Top1 acc	Top 2 acc	Top 3 acc	Many	Medium	Few
ACE	94.48%	97.70%	98.39%	98.42%	96.97%	80.00%



新クラス（分類）発見のための アクティブラーニング

- ノン・クエリー学習
- 43-クラス (42+その他 1)
 - トレーニング, 6042画像
 - テスト 698 画像
 - トレーニングでは**90%** サンプルを使用
 - 確度 = **94.5%**.
- 新クラスの発見
 - 27 から42 クラス
 - **5%** サンプルを
トレーニングで使用
 - 確度 = **93.9%**.







概要

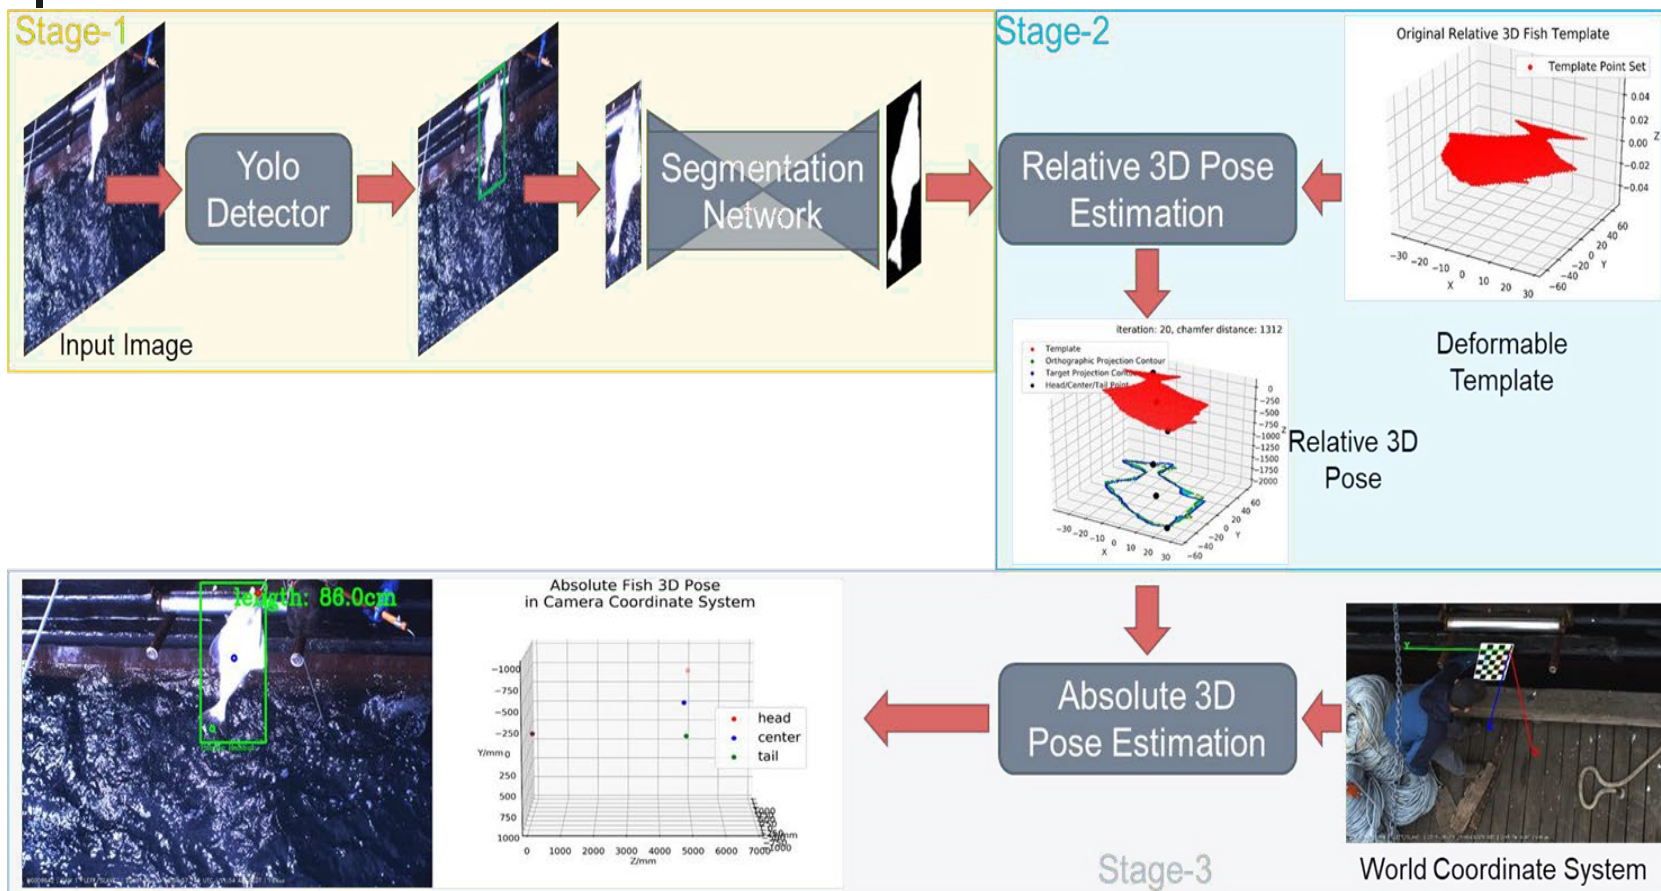
- 漁業のエレクトロニク ビジュアル モニタリング
- シュートベースのエレクトロニク モニタリング
- 延縄漁水揚げのエレクトロニク モニタリング
- 結論

延縄漁



- 延縄漁の単眼動画から、重度の変形魚の絶対的3次元姿勢推定と体長計測


魚の追跡（カウント）と体長測定




Jie Mei, et al., “Absolute 3D Pose Estimation and Length Measurement of Severely Deformed Fish from Monocular Videos in Longline Fishing,” IEEE ICASSP 2021, Toronto, Ontario, Canada, June 2021



絶対的3D姿勢推定からのトラッキングに基づいた体調測定

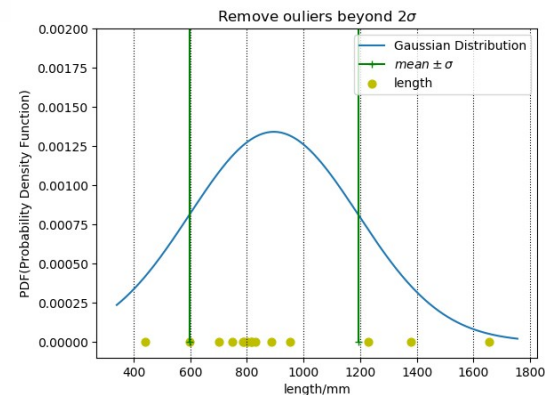


head, tail, center points in camera coordinate



Method	Bias(mm)	EMD(mm)	RMSD	KL
Stereo	-40.5	46.0	7.9%	0.26
BFS	-10.2	24.2	5.6%	0.11
BFS w/o Bending	-55.4	60.0	7.9%	0.28
Ours w/o Bending	-95.4	99.3	10.4%	0.53
Ours	-9.3	43.1	7.3%	0.23

Z=0 plane is image plane




738 魚サンプル

レールフィッシング種のID

- 特徴・機能の選択
 - 判別可能な特徴
 - 魚の変形や視野角の変化に強い
- 課題
 - 魚種間の視覚的類似性が高い
 - 姿勢や形状の変化によるクラス内変動が大きい




Pacific Halibut



Arrowtooth Flounder



Hard Snout Skates




Soft Snout Skates

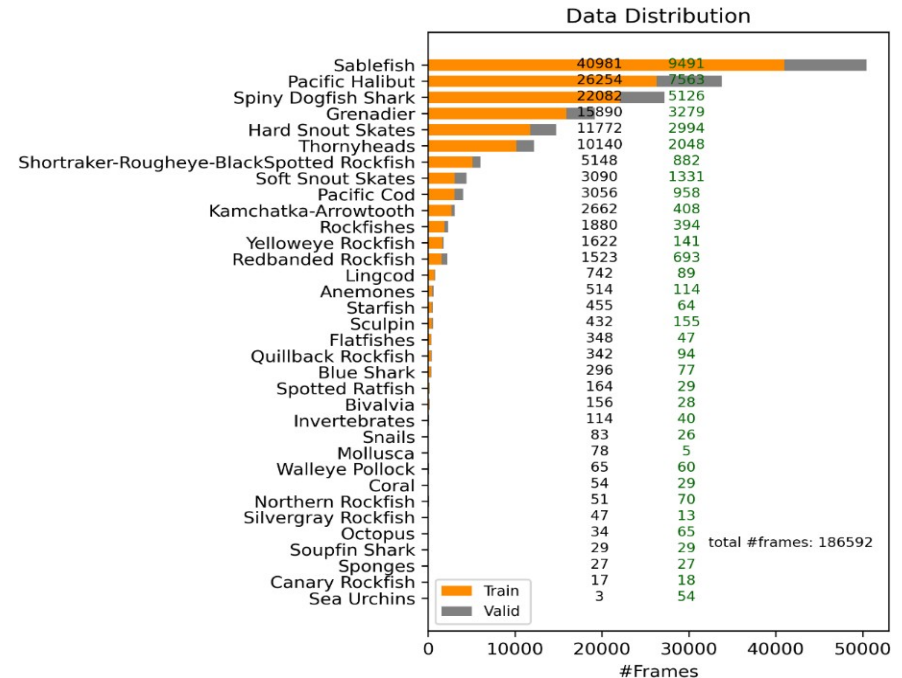


トラックベースの魚種 ID

- トラックベースデータをトレーニング/評価用に分割



Track #



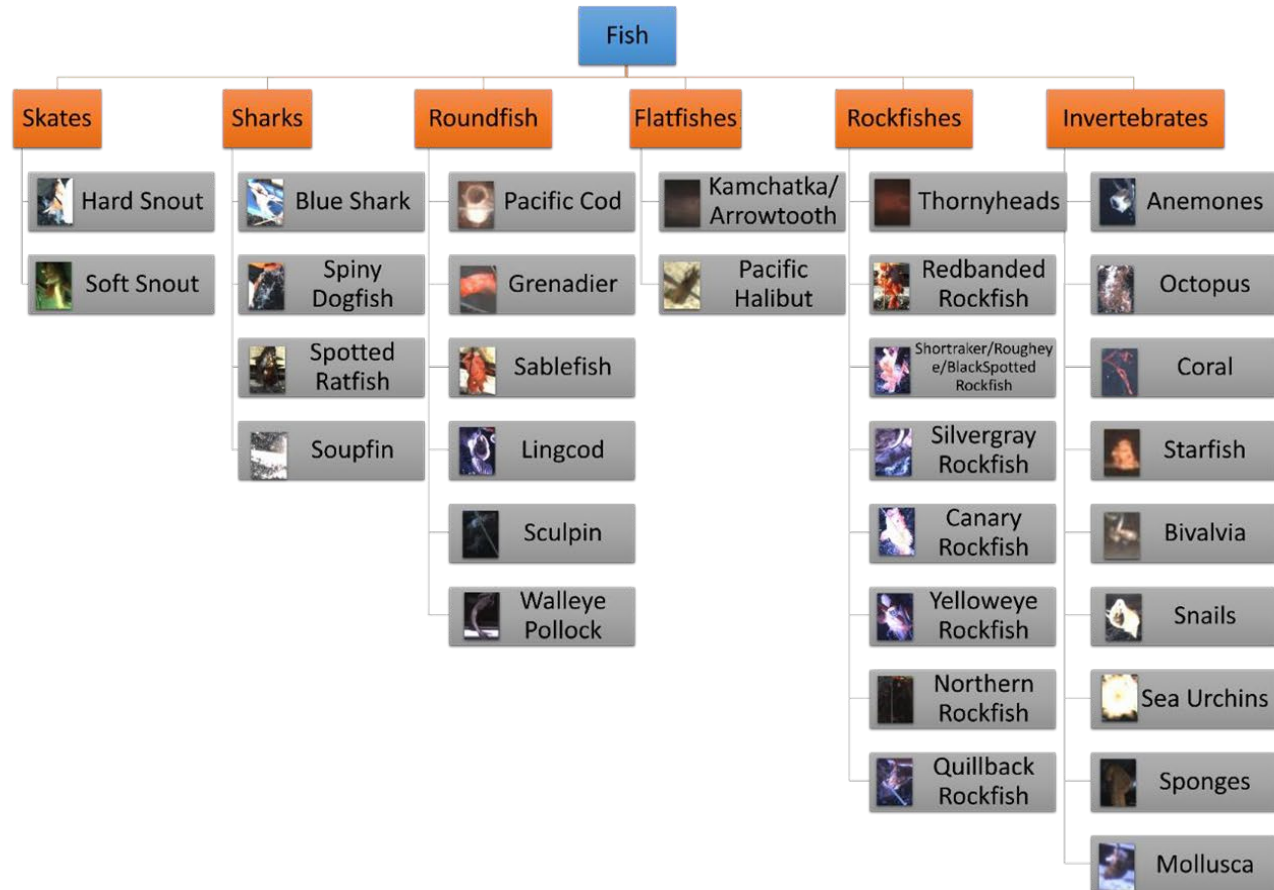
Frame #



階層化された魚種 ID

Level-1 (6 groups)

Level-2 (31 species)





実験結果

アブレーション研究

Model	Unit	Level-1	Level-2 A	Level-2 B	Level-2 C
Baseline	img	-	-	78.3	-
Scheme-1	img	86.3	77.4	77.4	82.0(8567, 27393)
	<i>video*</i>	93.2	86.5	86.6	93.2(298, 319)
	<i>video</i>	93.4	86.5	86.8	93.4(293, 324)
Scheme-2	img	88.4	79.9	80.0	84.6(8660, 27300)
	<i>video*</i>	94.3	88.6	88.9	94.3(329, 288)
	<i>video</i>	94.9	88.9	88.8	94.9(328, 289)
Scheme-3	img	91.0	82.3	82.3	86.3(5830, 30130)
	<i>video*</i>	96.3	90.6	90.3	96.3(286, 331)
	<i>video</i>	96.4	90.9	90.9	96.4(293, 324)

Scheme-1: 7 head, 乗算なし, Loss1
 Scheme-2: 7 head, 乗算あり, Loss1
 Scheme-3: 7 head, 乗算あり, Loss2

'*video*': 各トラックの予測種を1つ選ぶための31種の平均信頼度スコア。
 '*video**': 多数決で1つを選ぶ 各トラックの予測種

A: mレベル-1の最大スコアの後、レベル2の最大スコア
 B: 31点満点中の最高点
 C: 31点満点中の最高点、ただしレベル-1で停止可能(閾値0.91)



結論

- スマートシティ、スマートカー、インテリジェントハウス、スマート マニュファクチャリングなど、あらゆる場所でリアルタイムのセンシング、コミュニケーション、コンピューティング、コントロールが実現している。
- ビッグデータのおかげで機械学習やAIが効果的になり、強力な通信とコンピューティングにより、リアルタイムに対応できる可能性が高まっている。
- 海上のすべての漁船や水中カメラは、探査用のIoTセンサー – 漁業のビッグデータ
- 漁業のビッグデータを分析することで、スマート漁業、スマートオーシャンへの一歩