

무인자동 양식어류 급이공급 시스템 개발 및 검증

(Operation of Unmanned Automated Aquaculture Feeding System)

전명재*, 신춘성**, 정희용*

(Myoungjae Jun, Choonsung Shin, Hieyong Jeong)

요약

육상 양식장의 자동화의 일환으로 무인자동 급이공급시스템의 보급이 활발히 이루어지고 있다. 현재 양식업의 사료공급은 주로 정해진 시기와 양에 기초하여, 운영자가 미리 설정한 사료량에 의존하고 있어서, 이는 어류의 역동적인 사료공급 요구를 고려하고 있지 않다. 사료의 과소 혹은 과잉 공급은 어류의 성장률에 영향을 미칠고, 양식 수질을 오염 시킬 수 있다. 따라서, 본 논문은 머신 비전을 기반으로 어류의 배고픔 정도를 파악하고, 추가 사료를 공급하더라도 수질 화악로 인하여 어류가 집단 폐사하지 않도록 용존 산소농도를 실시간으로 예측하는 방법을 제안하고, 그 성능을 검증하는 것을 목적으로 하였다. 우선, 어류의 배고픔 정도의 파악은 수조의 상단에 부착된 CCTV 영상 데이터를 이용하여 어류의 행동의 차이를 수치화 하여 판별할 수 있다는 것을 검증하였다. 다음으로, 어류의 크기는 어두운 환경에서도 발광 그리드와 카메라를 통하여 실제 길이를 추정할 수 있다는 것을 실험결과로 증명하였다. 마지막으로, 용존산소농도는 사료 공급에 의하여 크게 변화하기 때문에 새로운 인공지능 모델을 제안하며 3시간 후의 용존산소농도를 예측할 수 있다는 것을 보여주었다.

■ 중심어 : 무인자동 급이공급시스템 ; 용존산소농도 ; 배고픔정도 ; 시계열 데이터 분해 ; 선행학습모델

Abstract

Unmanned automatic feeding systems are being actively distributed to automate land-based aquaculture farms. Currently, feed supply in aquaculture is primarily based on a fixed period and amount, depending on the predetermined feed quantity set by the operator, which does not consider the dynamic feed supply needs of fish. This can lead to under- or oversupply of feed, affecting the fish growth rate and water quality in aquaculture. To address this, a method is proposed in this paper to identify fish hunger levels using machine vision and predict the dissolved oxygen concentration in real time to prevent mass fish mortality due to water quality deterioration, even with additional feed supply. The method aims to verify its performance. Firstly, based on the observation that aquaculture farm operators estimate fish hunger levels by feeding time, a method is proposed to estimate hunger levels using machine vision and feeding time. Next, a combination of time series data decomposition model and pre-trained deep learning model is used to predict the dissolved oxygen concentration in real time.

■ keywords : unmanned automated aquaculture feeding system ; dissolved oxygen concentration ; hunger state ; time-series decomposition ; pretrained model

I. 서론

사료는 어류의 생존을 위한 필수 영양분과 에

너지를 제공하여 양식업에서 중요하다. 데이터에 따르면 사료 비용은 전체 양식 비용의 60% 이상을 차지한다. 사료의 종류는 일반적으로 양

* 정/중심회원, 전남대학교 인공지능융합학과중심회원, 전남대학교 인공지능융합학과

** 중심회원, 전남대학교 문화전문대학원중심회원, 전남대학교 문화전문대학원

본 연구는 대한민국 정부(산업통상자원부 및 방위사업청) 재원으로 민군협력진흥원에서 수행하는 민군기술협력사업의 연구비 지원과(과제번호 23-CM-DI-11, 심해 잠수사 임무수행을 위한 정보증강 HUD 개발), 해양수산과학기술진흥원 재원으로 수산생명공학사업의 연구비 지원(과제번호 22-3063-02, 유수식 스마트양식 시스템 개발)으로 수행되었음.

접수일자 : 2024년 09월 23일

수정일자 : 2024년 10월 11일

게재확정일 : 2024년 10월 25일

교신저자 : 정희용 email: h.jeong@jnu.ac.kr h.jeong@jnu.ac.kr

식되는 어중에 따라 결정되기 때문에, 사료량을 적절하게 조절하는 것이 비용을 절감하고 이익을 극대화하는 주요 수단이다. 사료비를 줄일 수 있으면 양식업의 경제적 이익을 향상시킬 수 있게 된다.

양식에서 사료 공급을 결정하는 열쇠는 양식 어종의 특정 성장률에 대한 영양 요구 사항을 충족시키기 위해 주어진 기간에 적절한 양의 사료를 제공하는 것이다. 하지만, 일정 시간에 맞춰 정량 사료를 공급하는 방식은 현재 양식업에서 주로 사용되고 있는데, 이는 운영자가 미리 설정한 고정량의 사료에 의존하며, 이는 어류의 사료 요구에 적응할 수 없어서 과소 혹은 과잉 사료 공급의 문제를 초래할 수 있다. 어류가 적게 먹게 되면 성장률에 영향을 미치게 된다. 많이 먹게 되면 사료 낭비가 발생하여 양식 비용이 증가할 뿐만 아니라 양식 수질을 오염시키며, 남은 사료에서 생성되는 암모니아성 질소, 질산염 화합물 등 유해 물질이 발생한다[1]. 따라서, 사료 공급은 어류의 건강한 성장에 영향을 미칠 뿐만 아니라 양식업의 경제적 이익을 더 높게 결정한다고 할 수 있다[2].

자동 양식 공급 시스템의 대표적인 글로벌 제조 업체로는 AKVA 그룹[3], Steinsvik[4], LINN Geratebau[5], Fish Farm Feeder[6]로 알려져 있다. 각 제조 업체의 홈페이지를 통하여 제품의 사양을 살펴보면, 자동 양식 공급 시스템은 정해진 사료량을 정해진 시간에 투여하는 역할을 주로 수행한다. 이 기계장치를 사용하면, 카트로 복수 개의 양식 수조에 사료를 옮기면서 공급해야 할 필요가 없다. 단지, 운영자는 기계장치에 공급할 사료량과 시간을 제어장치에 설정하는 것이 필요하다. 사료 공급량은 어류의 종류 뿐만 아니라, 성장 단계에 따라 계속 변화하므로 시기에 따라 최적의 조건으로 변경 해주어야 한다. 어류의 배고픔 정도를 인식하여 무인으로 자동으로 사료 공급 기능이 필요하고, 추가적인 사료 공급 전 사료에 의한 사육 수질 문제로 인하여 집단

폐사의 문제를 미리 예측하는 것이 필요하다. 하지만, 현재 자동 양식 공급 시스템에 그러한 기능을 제공해 주고 있지는 않다.

사육 수질에 관한 정보는 다양한 센서 장치를 통하여 현재의 상태를 자동 사료 공급 시스템에 측정 정보를 전달해야만, 기계장치에 전달될 수 있다. 용존 산소 농도가 낮은 상태에서 사료까지 공급해 버리면 용존 산소 농도가 급락하여 어류가 집단 폐사할 위험성이 높아지기 때문에, 수조 환경을 고려하여 사료 공급 시점과 사료 공급량을 조절하는 것이 중요하다[7]. 현재는 작업자에 의하여 사료 공급을 비교적 규칙적이면서 매번 거의 유사한 양의 사료를 공급하기 때문에 통계 모델 혹은 대표적인 시계열 데이터 분석을 위한 인공지능 모델인 LSTM으로 쉽게 예측이 가능하다[8]. 하지만, 자동 사료 공급 시스템은 어류가 배고플 때마다 사료 공급할 필요가 있기 때문에 공급 시기가 랜덤하고, 공급량도 매번 상이하기 때문에, 불규칙한 패턴이 반드시 포함되기 때문에 통계모델과 일반적인 LSTM과 같은 단순한 모델로 쉽게 예측이 가능하지 않다. 물론, 다양한 인공지능 모델이 요즘 소개되고 있기 때문에 좀 더 복잡한 인공지능 모델로 예측하는 방법도 생각해 볼 수 있다. 하지만, LLM과 같은 모델을 적용할 경우 시스템의 가격 상승의 요인으로 작용할 수 있다. 또한, 용존 산소 농도와 같은 사육 수질의 결과는 거의 실시간으로 기계장치의 제어부분에 전달되어, 기계장치의 운영에 바로 반영이 되어야하기 때문에, 소형이면서 저가 컴퓨터에서도 동작 가능한 단순하면서 높은 정확도를 낼 수 있는 모델을 사용하는 것이 적합하다.

따라서, 본 논문은 머신 비전을 기반으로 어류의 배고픔 정도를 파악하고, 추가 사료를 공급하더라도 수질 악화로 인하여 어류가 집단 폐사하지 않도록 용존 산소 농도를 실시간으로 예측하는 방법을 제안하고, 그 성능을 검증하는 것을 목적으로 하였다. 우선, 경험적으로 양식장 운영




그림 1. 무인 자동 사료 공급 시스템의 개요: 기계장치((b)~(h))와 센서장치((a), (i), (j))로 구성되어 있으며, 분홍색 점선은 사료의 이동 경로를 표시.

자는 어류들의 배고픔 정도를 급이 공급 후 섭취 시간으로 추정하고 있다는 점에 착안하여, 머신 비전을 통하여 배고픔 정도를 섭취 시간으로 추정할 수 있는 방법을 제안하였다. 다음으로, 시계열 데이터 분해 모델과 선행 학습시킨 딥러닝 모델을 결합시켜 실시간으로 용존 산소 농도를 예측하였다. 본 연구가 양식업에 기여할 수 있는 점은 어류의 배고픔 정도를 추정하여 무인 자동 양식 사료 공급 시스템이 랜덤하게 사료를 공급하더라도, 용존 산소 농도의 부족으로 집단 폐사하는 위험성을 사전에 예방할 수 있다는 점이다.

II. 실험 환경 및 시스템

제안한 모델이 실질적으로 무인 자동 사료 공급 장치와 어떻게 연동되어 활용될 수 있는지를

이해하기 위해, 전체 시스템 구성 및 작업 흐름도를 설명하면서, 무인 자동 사료 공급 시스템의 운영에 필요한 정보를 수집하기 위한 센서 시스템과 제안한 용존 산소 농도 예측 모델의 역할을 살펴보도록 하겠다.

1. 시스템 구성

그림 1은 무인 자동 사료 공급 시스템의 일반적인 전체 구성을 보여주고 있다. 자동 사료 공급 시스템은 크게 기계장치[9]와 센서장치로 구성되어 있다. 그림 1에서 (b)~(h)는 기계장치를 나타내고 있고, (a), (i), 그리고 (j)는 센서장치를 나타내고 있다. 분홍색의 점선은 사료의 이동 경로를 표시하고 있다. 사료 공급은 한 곳에서 진행하고, 각 수조마다 그림 1과 같은 기계장치를




그림 2. 어류 크기 측정과 용존 산소 농도 예측, 섭취 시간 측정 정보 기반 무인 자동 사료 공급 시스템을 운영하기 위한 작업 흐름도: 파란색 박스는 기계장치의 역할을 나타내고 빨간색 박스는 센서장치의 역할을 나타냄.

이용한 사료 이송을 통하여 사료 공급이 이루어 지도록 공급라인이 설치되어 있다.

2. 작업 흐름도

그림 2는 어류 크기 측정과 용존 산소 농도 예측, 섭취 시간 측정 정보를 기반으로 무인 자동 사료 공급 시스템을 운영하기 위한 작업 흐름도를 나타내고 있다. 파란색 박스는 기계장치의 역할을 나타내고, 빨간색 박스는 센서장치의 역할을 나타내고 있다. 영어 소문자는 그림 1에서 나타낸 사료 이송 경로의 위치를 나타낸다. 기본적으로 시스템 운영은 자동 모드로 운영되지만, 유지보수 및 시스템 업그레이드 등과 같이 필요한 경우에는 수동 모드로 전환이 가능하다.

(a)에서 어류 크기의 측정 정보가 기계장치에 전달되고, (b)와 (c)에서 사료 저장 탱크에 있는 사료 중 사료 무게 측정 장치를 통하여 어류 크기를 기반으로 공급량을 결정하게 된다. 사료를 즉시 공급하는 것이 아니라, 현재의 측정한 용존 산소 농도와 공급될 사료량을 입력으로 가지는 인공지능 모델을 통해 용존 산소 농도를 예측하여 위험을 사전에 예방한다. 위험도가 낮다면 다음 단계로 진행하지만, 위험도가 높다면 다음 단

계로 진행하지 않고 대기를 하면서, 위험도가 다시 낮아지게 되는 것을 확인한 후, 다음 단계로 진행한다. (e)부터 (g)까지 결정된 공급량을 기계장치를 통하여 공급한다. (j)에서 공급된 사료를 어류가 잘 섭취하고 있는지 섭취 시간을 측정한다. 섭취 시간은 어류의 배고픔 상태를 의미하기 때문에 배고픔 상태가 강하다면 사료를 추가 공급한다. 그렇지 않다면 추가 사료를 공급하지 않는다. 이때, 추가 사료를 공급할 경우에도 용존 산소 농도를 예측한 후 위험도가 낮다면 공급하지만, 그렇지 않다면 바로 공급하지 않고 대기하고 있다가 위험도가 다시 낮아지면 공급한다. 이 작업 흐름도는 자동 모드를 통하여 무인 자동 사료 공급 시스템을 운영하는 방법을 보여주고 있지만, 필요한 경우에는 수동 모드로 전환하여 이 시스템을 운영하는 것도 가능하도록 제어장치 부분에 그 기능을 추가해 놓았다.

3. 센서장치

표 1. 수질 환경 측정을 위해 사용된 센서와 사양.

Sensor	Manufacturer	Range	Accuracy
DO	Oxyguard A/S	0~20 [mg/L]	± 1 [mg/L]
pH	Oxyguard A/S	0~14 [pH]	± 1 [pH]
CO2	Oxyguard A/S	0~50 [mg/L]	± 1 [mg/L]
ORP	Oxyguard A/S	-1,000~ +1,000 [mV]	± 1 [mg/L]
Flow	SENSIRION	0~20 [L/min]	± 3 [%]
Light	KIMO	0~10,000 [Lux]	± 2 [%]

실내 수조에서 영상 데이터, 센서 데이터, 관리 데이터를 수집하여 데이터셋을 구축하였다. 영상 데이터 수집을 위해서 카메라는 수조의 수면 위에 설치하였다. 센서 데이터는 양식장 내의 수질 및 환경에 대한 정보를 수조 내에 설치한 장치로 부터 획득하였다. 관리 데이터는 영상 및 센서 데이터 이외에 생산자가 수동으로 입력해서 생성한 데이터로 수질 분석, 사료 공급 관리, 어류 성장도, 현장 관리, 질병 분석 등을 의미한다. 영상과 센서 데이터와 샘플링 주기가 상이하다.

가. 배고픔 정도 예측 시스템

수조의 수면 위에 설치된 카메라를 통하여 사료 공급 전의 수면을 살펴보면, 파이프에서 나오는 해수의 영향으로 수면에 하얀 물거품이 발생하는 변화만 관찰할 수 있다. 하지만, 사료 공급 직전의 수조의 상태를 살펴보면, 어류들이 사료 공급자 주변으로 몰려들면서 수면으로 올라와서 파이프에서 나오는 해수의 물거품 영향 뿐만 아니라 어류에 의해서 수면에 하얀 물거품도 발생하고 있는 것을 관찰할 수 있다. 따라서, 카메라를 통하여 수집된 영상 정보를 분석하여 수조의

수면 변화를 통하여 어류들의 사료 공급 후 섭취 시간을 측정할 수 있다.

정해진 사료량을 경험적으로 사전에 알고 있던 섭취 시간 보다 빨리 섭취한다면 어류의 배고픔 정도가 강한 상태로 판단하여, 무인 자동 사료 공급 장치가 추가 사료를 공급하도록 설정한다. 반대로, 경험적으로 알고 있던 섭취 시간 보다 늦거나 공급한 사료가 수면 위로 떠다니다면, 어류의 배고픔 정도가 약한 상태로 판단하여, 자동 사료 공급 장치가 추가 사료를 공급할 필요가 없도록 설정한다.

나. 용존 산소 농도 측정 시스템

본 연구에서는 설치한 센서 장치를 통하여 수집된 데이터를 사용하여 수질 상태를 파악하였다. 센서 데이터를 수집하기 위한 장치는 5년 이상 상업용 양식장 현장에서 정상 구동되고 있는 센서를 채택하였다. 또한 자체 현장 테스트를 통하여 양식장의 학습용 데이터 구축 목적으로 사용하는데 문제가 없음을 검증하였다. 한 수조당 동일한 데이터를 측정하기 위하여 2개의 센서를 설치하여 평균값을 사용한다. 센서 데이터는 1분당 획득하여 자체 데이터베이스에 저장한 후 일별로 정리하였다. 학습 데이터 규모는 120만 세트 이상이다[10], [11].

표 1은 사용한 센서명과 제조사, 간략한 사양을 보여주고 있다. 센서로부터 들어오는 시계열 데이터에서 장비 오류나 네트워크 오류로 인해 데이터가 정해진 시간에 저장되지 않는 문제로 인하여 결측치가 발생하게 된다. 이를 해결하기 위해 결손 처리 알고리즘을 이용하여 처리하였다. 또한, 센서로부터 들어오는 데이터 중 현실에서 나올 수 없는 측정값들이 나올 경우가 발생하는데, 이런 이상치들은 학습 시 입력으로 들어가면 원치 않는 결과가 발생하기 때문에 이상치 제거 모듈을 이용하여 제거하였다.

다. 어류 크기 측정 시스템




그림 3. 어류 크기를 측정하기 위한 시스템 구성 및 설치 환경.

그림 3는 본 연구에서 제안하는 시스템의 전체 구성 요소 및 설치 환경을 나타내고 있다. 어류가 발광그리드 위를 지나가는 동안 수면 위 설치된 카메라를 통하여 수집된 어류의 이미지를 통하여 어류의 크기를 측정할 수 있는 시스템이다[12]~[15].

실제 양식 현장에서는 어류를 그물로 잡아서 마취시킨 후 저울과 줄자를 이용하여 어류의 무게와 크기를 측정하기 때문에 한 수조당 샘플로 몇 마리를 측정한 후 평균을 내어 한 수조의 어류 크기를 추정한다. 한 양식장에 많은 수조가 있기 때문에 이와 같은 방식으로 어류의 크기를 측정하는 방법은 작업자에게 육체적으로도 정신적으로도 매우 부담스러운 방법이다. 소비자 입장에서 마취제를 투여한 어류를 소비하기에는 꺼려지는 부분이 있다.

이에 제안한 시스템은 어두운 환경에서의 측정과 단위변환에 유용한 정보를 제공할 수 있다는 점이 큰 특징이다. 발광그리드의 그리드 간의 실질적 거리를 이용하여 픽셀 간의 차이를 실질적 거리로 단위 변환을 하는 데 사용한다. 또한, 양식 수조의 어류는 어두운 환경을 좋아하는데 측정할 때에만 발광그리드의 조명을 이용하여 전체적으로 어두운 환경에서도 어류의 크기를 측정할 수 있다.




그림 4. 사료 공급 전(a)과 사료 공급 직전(b)의 어류 행동의 차이로 발생한 수조 수면의 차이.

III. 방 법

1. 영상처리 기반 배고픔 정도 추정

현재 양식장에서는 공급된 사료량이 적절한지 판단은 작업자의 눈으로 직접 확인하고 판단한다. 사료량이 부족하다고 판단되면 추가로 사료를 공급하고, 양이 많다고 판단되면 다음 번에 공급 사료량을 줄이거나 한다. 여러 번의 시행착오를 거쳐 적절한 사료량을 경험을 통한 판단으로 결정한다. 즉, 그 경험을 통한 판단이라는 것은 사료를 공급하였을 때 어류가 일정 기준시간(2~3분 정도)보다 빠르게 양식 수조의 수면 위 사료를 섭취하였다면 사료량이 부족하다고 판단하고, 일정 기준시간보다도 더 느리게 사료를 섭취하였다면 사료량이 많다고 판단한다. 현장에 고가의 자동 사료 공급 장치를 설치하였다고 하더라도 결국 작업자가 장치를 수동으로 조절해서 사료를 공급해야 하기 때문에 육체적 노동은 줄겠지만 작업자는 현장에 머물면서 장치를 조작해야만 한다. 따라서, 사료 섭취 시간을 자동으로 도출할 수 있다면 사료 공급 장치에 이 정보

를 전달하여 사료량 조절을 자동으로 할 수 있게

류가 사료를 섭취하는 시간으로 간주할 수 있다.




그림 5. 시계열 데이터 분해 모델과 선행 학습 모델을 결합시킨 제안 모델의 구성.

된다는 점에 착안하였다.

그림 4은 사료 공급과 관련된 어류의 행동[16] 차이로 인하여 발생하는 수조 수면의 물결 차이를

보여주고 있다. 그림 4(a)는 사료 공급 전으로 사료 공급하는 작업자가 수조 근처에 없는 상황을 보여주고 있고, 그림 4(b)는 사료 공급 직전으로 사료 공급하는 작업자가 수조 옆으로 접근한 상황을 보여주고 있다. 작업자가 수조 근처로 접근하게 되면, 수조의 어류가 작업자 주변으로 몰려들면서, 수면의 하얀 물결이 발생하는 것을 알 수 있다. 사료 공급은 수면 위에 사료를 뿌려 줄 것이고, 수면에 떠 있는 사료를 수조 속의 어류는 수면 위로 접근하여 사료를 섭취하게 된다. 이때, 어류의 섭취 행동으로 인하여 수면에는 하얀 물결이 발생하게 된다는 특성을 발견할 수 있다. 그래서, 이전 프레임과 현재 프레임 간의 비교를 통해 변화된 부분이 발생한 시간 동안을 어

먼저, 촬영한 객체 영상 데이터를 로드하여 영상 내 각각의 프레임마다 이전 프레임과 비교를 통해 변화하지 않는 부분을 제거하는 차분 영상을 구한다. 다음으로, 차분 영상에서 변화된 부분을 인식하여 객체의 범위를 가산한다. 이때, 촬영한 영상에서 바람과 같은 여러 변수로 인하여 배경이 움직여 원하는 객체가 아닌 다른 부분을 가산하는 것을 사전에 방지하기 위하여 객체가 위치한 범위를 ROI(Region of Interest)로 지정하여 둔다. 또한, 차분 영상을 구할 때, 발생하는 잡음을 제거하기 위하여 여러 선택 인자를 추가하는데, 본 연구에서는 정확도 높은 객체 인식을 구현하기 위하여 Threshold 값을 이용한다.

2. 시계열 데이터 분해 기반 용존 산소 농도 예측

시계열 데이터가 가지고 있는 패턴을 여러 성

분의 부분 패턴으로 분해할 수 있다. 즉, 시계열 데이터를 추세요인(trend), 계절요인(seasonal), 순환요인(cyclical), 그리고 불규칙요인(irregularity)으로 나누어 분석하는 방법을 시계열 분해 방법이라고 한다. 여기서, 추세 요인은 시계열 데이터의 장기적 형태를 나타내며, 순환 요인은 경제 혹은 특정산업의 주기적 성쇠를 나타낸다. 계절요인은 요일마다 반복되거나, 일년 중의 각 월에 의한 변화, 사분기 시계열 데이터에서 각 분기에 의한 변화 등 고정된 주기에 의한 변동을 말하며, 불규칙요인은 위 세가지 요인으로 설명할 수 없는 오차(noise)로, 노이즈나 아웃라이어에 해당한다.

추세성분(T_t), 계절성분(S_t), 순환성분(C_t), 불규칙성분(R_t)에 대한 시계열 데이터 분해식은 다음과 같다.

$$y_t = f(T_t, S_t, C_t, R_t) = T_t + S_t + C_t + R_t. \quad (1)$$

시계열 데이터를 구성하는 요인들을 분석하는데 사용될 뿐만 아니라, 시계열 데이터 값을 예측하는 데도 유용하다. 그리고 시계열 데이터가 가지고 있는 각 성분들을 분석할 수 있으므로, 전체 시계열 데이터를 이해하는데 도움이 될 뿐만 아니라, 각 부분 패턴을 외삽하여(extrapolating) 예측 값들을 구한 후, 이 예측 값들을 더하여 데이터를 예측하는 방법에 사용한다. 본 연구에서는 앞서 언급한 시계열 데이터의 구성 요소 중 순환 요인은 사료 공급으로 인하여 발생하는 용존 산소 농도의 변화에 영향이 크지 않기 때문에, 추세성분과, 계절성분, 불규칙성분만을 사용한다.

그림 4는 본 연구에서 제안한 선행 학습된 LSTM과 전통적인 시계열 데이터 분해 모델을 결합시킨 제안 모델의 구성을 보여주고 있다. 제안 모델은 규칙적인 이벤트 발생을 예측할 수 있는 부분과 불규칙적인 이벤트 발생을 예측할 수 있는 부분을 결합시킨 모델이다. 규칙적인 이벤트의 경우에는 전통적인 시계열 데이터 분해 모

델과 동일한 방법을 통해 구할 수 있다. 불규칙 이벤트의 경우에는 발생 시점과 발생 후 최종 종속변수에 미친 영향도를 선행 학습 시킨 모델을 통하여 해결하는 방법을 본 논문에서 제안하였다.

우선, 독립변수가 연속적으로 측정 가능한 센서 데이터($X = [x_1, \dots, x_n]$)인 경우에는 기존 시계열 데이터 분해 방법과 동일하게 시계열 데이터 분해를 통하여 구해진 T, R, S 을 딥러닝 모델(LSTM-1, LSTM-2)로 학습시킨 후 최종 종속변수를 구할 수 있다. 즉, 추세요인인($T+R$)은 $T = f_{p1}(x_1, x_2, \dots, x_n)$ 을 통하여 구할 수 있다. 여기서, f_{p1} 는 딥러닝 모델을 의미하고, n 은 선택된 피쳐 개수를 의미한다. LSTM-1 모델을 통하여 독립변수를 입력으로 사용하여 종속변수인 T 를 구할 수 있다. 독립변수인 X 는 측정한 피쳐들 가운데 종속변수와 상관관계가 비교적 높은 피쳐로 선택할 수 있다. 이 종속변수는 용존 산소 농도의 긴 시간 동안의 변동을 예측한 결과에 해당한다.

다음으로, 독립변수가 연속적으로 측정할 수 없는 불규칙적인 이벤트 발생으로 측정할 수 있는 데이터에서 이벤트 발생 시점 정보를 취득할 수 있다. 또, 이벤트가 종속변수에 미치는 영향도는 이벤트에 따른 용존 산소 농도 변화량을 선행 학습시킨 모델(P-LSTM-1)을 통하여 취득할 수 있다. 최종 종속 변수는 이 두가지 예측 값을 합쳐서 구할 수 있다. 즉, 계절요소 중 하나 인 S 는 X 를 입력으로 사용하여 종속 변수인 S 를 딥러닝 모델(LSTM-2)을 학습시켜 구할 수 있다. 추가 계절요소 S_p 는 식 $S_p = f_{p2}(z_1, \dots, z_m)$ 을 통하여 구할 수 있게 된다. 여기서, f_{p2} 는 선행 학습시킨 딥러닝 모델을 의미하고, m 은 선택된 피쳐 개수를 의미한다. 데이터셋을 활용하여 S 를 정답 값으로 하고 Z 를 독립변수로 하여 딥러닝 모델을 학습시키면서 하이퍼파라미터를 사전에 설정한 모델이 P-LSTM-1모델이다. 이 사전 학습된 모델을 통하여 독립변수인 Z 를 입력으로 사용하여

종속변수인 ($S_p + R_p$)를 구할 수 있다. 독립변수인 Z 는 측정된 피치들 가운데 종속변수와 상관관계가 비교적 높은 피치로 선택할 수 있다. 이 종속변수는 용존 산소 농도의 짧은 시간 동안의 변동을 예측한 결과에 해당한다. 즉, 사료를 공급한 직후부터 급감하면서 변화하는 용존 산소 농도가 회복하기까지의 용존 산소 농도를 의미한다.

본 연구에서는 제안한 모델을 통하여 3시간 동안의 데이터 학습과 급이 이벤트 유무를 입력으로 받아서 출력으로 용존 산소 농도를 예측하는 것이다.

3. 어류 크기 측정

어류의 크기를 측정하기 위해 수조의 바닥에 설치한 발광 그리드의 크기는 가로 × 세로 = 900 × 600mm이고, 한 변의 길이가 10mm인 정사각형 모양의 그리드 형태이다. 발광 그리드 위를 지나가는 어류의 크기를 측정하기 위해 우선, 어류의 이미지를 수집하여 데이터셋을 구축한다. 다음으로, 이미지에서 어류의 객체를 발견한 후, 이미지에서 어류가 있는 위치, 해당 어류 모양의 정보 추출을 위해 이미지를 분할해 이미지의 각 픽셀에 레이블을 부여하는 이미지 세그멘테이션 기법을 적용한다.

이미지 세그멘테이션을 적용 여부의 판단은 IoU(Intersection of Union)의 수치를 보고 결정한다. IoU는 두 개의 Bounding Box에서 정의되는 개념으로 두 박스의 교집합을 두 박스의 합집합으로 나눈 값이다. IoU가 0이라는 것은 교집합이 없다는 것이고, 1이라는 것은 두 박스가 완전히 일치한다는 것이다. 본 연구에서는 IoU가 0.7 이상이면 객체 탐지가 성공하였다고 고려하여 이미지 세그멘테이션 기법을 적용한다.

이미지 세그멘테이션 기법의 결과물로 어류의 픽셀 면적을 도출할 수 있다. 픽셀 면적을 물리량으로 변경하기 위해 발광 그리드의 10mm와

픽셀 수 간의 관계를 파악하여, 이미지 세그멘테이션 결과물의 픽셀 면적을 실제 면적 단위로 환산하여 실제 면적을 구하면 된다. 어류의 길이




그림 6. 배고픔 정도 추정을 위해 영상처리를 통한 사료 섭취 시간 추정 결과.

정보는 발견한 객체를 직사각형 모양으로 바운딩 박스 처리하였을 때, 직사각형의 긴 변의 길이가 어류의 길이에 해당하고, 짧은 변의 길이가 어류의 폭의 길이에 해당한다.

IV. 결 과

1. 배고픔정도 추정결과

그림 6은 배고픔 정도 추정을 위해 수집된 영상을 처리하여 사료 섭취 시간을 추정한 결과를 보여주고 있다. 차분 영상에서 각 픽셀의 값을 가산한 결과이다. 수평축은 frame 번호를 나타내고, 수직축은 가산한 픽셀 값을 나타내고 있다. 500 frame 전까지는 거의 가산 값이 0에 근접해 있지만, 500 frame부터 3,000 frame까지 픽셀을 가산한 값이 급등한 것을 알 수 있다. 3,000 frame 이후에는 불규칙적인 시간 간격으로 가산 값이 0부터 최대 20,000까지 존재하기는 하지만, 연속적으로 발생하지 않다는 것을 알 수 있다. 500 frame부터 사료를 공급하여 어류가 섭취를

시작하였고, 3,000 frame에 사료 섭취가 완료하였다. 사료 섭취 시간은 $(3,000 / 500) [\text{frame}] / 30 [\text{frame/s}] = 83.3\text{s}$ 로 추정할 수 있다.




그림 7. 구축한 데이터셋의 피쳐들 간의 상관관계 분석 결과.

표 2. 전체 수조의 상관관계 계수의 평균처리 결과.

독립변수		변수		
		T	Sp	R
x1	DO	0.88	0.21	0.48
x2	Temp	-0.39	-0.01	0
x3	pH	-0.35	0	0
x4	ORP	0.46	0	0.01
x5	CO2	-0.22	-0.06	-0.07
z1	Feed quantity	-0.03	-0.33	0
z2	Water quantity	-0.03	-0.33	0

2. 용존산소농도 예측결과

가. 상관관계 분석결과

그림 7은 수조의 상관관계를 분석한 결과를 보여주고 있다. 상관관계 계수는 -1에서 +1사이의 값을 가지며 양수인 것은 양의 상관관계를 의미하고, 음수인 것은 음의 상관관계를 의미한다. 색깔이 진한 빨간색에 가까울 수록 양의 상관관계가 높다는 것을 의미하고, 색깔이 진한 파란색에 가까울 수록 음의 상관관계가 높다는 것을 의미한다. 가로축과 세로축에 상관관계 분석에 사용

한 피쳐들이고, 대각선이 진한 빨간색으로 +1인 것은 자기 자신이기 때문이다.




그림 8. 불규칙적인 급이 이벤트 조건에서 용존산소농도 예측결과: 녹색 점선 박스가 불규칙적인 급이 이벤트 발생 구간.

표 3. 용존산소농도 예측에 사용된 모델.

Model	Description
model-1	Only LSTM
model-2	LSTM with standard scaler
model-3	LSTM with minmax scaler
model-4	LSTM with robust scaler
model-5	Time-Series Decomposition model
new model	Proposed model




그림 9. 예측결과에 대한 모델 평가 비교 결과.

표 2는 모든 수조의 상관관계 분석결과를 통하여 독립변수와 종속변수의 관계를 정리한 것이다. 선행 학습 모델의 입력으로 사용될 독립변수를 선정하기 위해 종속변수에 영향을 미친 독립변수를 정리하였다. 본 연구에서 장기 변동 예측을 위해 사용한 변수인 $(T+R)$ 에 독립변수인 $x1 \sim x5$ 까지 의미 있는 영향을 미친 것으로 상관관계 분석을 통하여 확인되었고, 단기 변동 예측을 위해 사용한 변수인 Sp 에 독립변수인 $z1$ 과 $z2$ 가 의미 있는 영향을 미친 것으로 상관관계 분석

을 통하여 확인하였다.




그림 10. 어류크기 측정결과.

나. 불규칙적인 급이 이벤트 조건에서 용존 산소농도 예측결과

그림 8은 용존산소농도를 예측하기 위해 제안된 모델의 성능 검증하기 위해 다른 모델들과 결과를 비교한 것이다. 항상 규칙적으로 사료를 공급하는 것이 아닌 임의의 시점에 사료를 공급하였을 경우에 예측이 가능한지 확인하기 위해 실험을 진행하였다. 사료 공급은 하루 2번 4시 30분과 16시 30분에 이루어졌다. 2021년 8월 21일 데이터로 정기적으로 공급되는 사료 공급 시간을 피한 8시와 20시에 4시 30분과 16시 30분과 동일한 급이 이벤트를 발생시켜 예측을 진행하였다. 녹색 점선 박스가 임의로 공급한 사료의 구간을 나타낸다. 예측에 사용된 모델명과 자세한 설명은 표 3으로 정리하였다. LSTM모델의 다양한 스케일러를 조절한 모델과 시계열 데이터 분해 모델과 제안한 모델을 사용하였다.

현재 측정된 용존산소농도 3시간 데이터가 주어지고 이벤트의 유무가 주어지면 3시간 후의 용존산소농도를 예측하는 것이 모델의 결과물이다. 결과를 보면, 전체적으로 측정한 결과에 해당하는 검정색 실선에 가장 근접해 있는 모델은 제안한 빨간색 실선 모델인 것을 알 수 있다.

그림 9는 예측결과를 평가하기 위해 5일 데이터 전체를 두 가지 지표 MAE(Mean Absolute

Error)와 MSE(Mean Squared Error)로 평가 결과를 시각화한 것이다. 수평축은 수조 번호와 지표명을 나타내고, 수직축은 에러값을 나타낸다. 큰 에러 값일 수록 진리값과 차이가 많이 난다는 것을 의미한다. 결과를 보면, 수조 1번의 에러 값이 수조 2번의 에러 값보다 크다는 것을 알 수 있다. 이는 수조 1번의 용존산소농도를 예측하는 것이 더 어려운 상태라는 것을 나타낸다. 다른 모델에서는 에러 값의 변동이 크지만, 제안 모델의 에러값의 변동은 크지 않다는 것을 알 수 있다. 또한, 다른 모델에 비해 제안한 모델의 진리값에 근접하다는 것을 두 가지 평가 지표결과를 통해서 확인할 수 있다.

3. 어류 크기 측정결과

그림 10은 어류 크기를 측정한 결과를 보여주고 있다. 그림 10의 상기에 있는 결과물은 발광 그리드 위를 지나가는 어류를 검출하여 길이를 실시간으로 계산하고 있는 결과를 보여주고 있다. 어류의 전체가 그리드 위 내부로 들어오지 않았을 경우에는 검출 대상에서 제외시킬 수 있다. 그리드 위 내부로 완전히 어류가 진입한 상태에서만 검출 대상으로 판단하여 픽셀 넓이와 함께 단위 변환된 길이를 실시간으로 출력하게 된다[12], [13].

그림 10의 하부에 있는 결과물은 실제 수조에 서식하고 있는 어류의 길이가 36.0cm~50.0cm인 어류를 대상으로 제안한 센서 시스템으로 측정한 결과와 실제 결과를 비교한 것이다. 표준편차 $\pm 3.3\text{cm}$ ($R^2=0.994$)로 다양한 어류의 길이에 대하여서도 제안한 측정 시스템의 결과가 높은 신뢰성을 보장해 주는 것을 확인할 수 있다.

V. 결 론

본 논문에서는 개발한 무인자동 사료공급 시스템에서 센서장치를 중심으로 운영하는 방안

대하여 그 유효성을 검증하였다. 기 개발된 자동 사료 공급 시스템에서는 사료를 수레에 실어 나르는 육체적 노동에 대한 부담을 줄일 수 있었지만, 결국 작업자가 기계조작을 위해 현장에 반드시 있어야 하고 추가 사료 공급 등의 역할을 수행하여야 한다. 하지만, 개발한 무인자동 사료공급 시스템은 세가지 센서장치(배고픔정도, 용존 산소농도, 어류크기)를 통하여 작업자가 현장에 없어도 자동으로 시스템을 운영할 수 있다는 것을 실험을 통하여 검증하였다.

주요 결과로 우선, 어류의 배고픔정도의 파악은 수조의 상단에 부착된 CCTV 영상 데이터를 이용하여 어류의 행동의 차이를 수치화 하여 판별할 수 있다는 것을 검증하였다. 다음으로, 어류의 크기는 어두운 환경에서도 발광 그리드와 카메라를 통하여 실제 길이를 추정할 수 있다는 것을 실험결과로 증명하였다. 마지막으로, 용존 산소농도는 사료 공급에 의하여 크게 변화하기 때문에 새로운 인공지능 모델을 제안하며 3시간 후의 용존 산소농도를 예측할 수 있다는 것을 보여주었다.

기계장치의 구성은 기 개발된 시스템과 유사한 구성을 가지지만, 센서장치로 부터 수집된 데이터를 분석하여 기계장치에 필요한 정보를 제공하여 기 개발된 시스템과 크게 차별화시킬 수 있다는 점이 본 연구가 기여한 점이다.

본 연구의 한계점은 아직까지 양식장에 설치는 하였지만 운영하여 축적한 데이터가 아니라 초기 실험단계에서 구축한 데이터이기 때문에 향후 실질적으로 양식장에서 운영할 경우 발생할 수 있는 여러가지 변수에 대한 대책이 아직까지 미흡한 상태이다.

사 사

본 연구의 저자에는 포함되지 않았지만, 아낌 없이 필요한 현장 정보를 지원해 주신 (주)빌리언이십일의 조보현 대표님, 박진기 연구소장님, 이성규 부장님께 이 자리를 빌어서 감사의 뜻을

전달합니다. 또, 외국인 유학생으로 최선을 다해 수고하고 있는 Ngoc-Huynh Nguyen씨에게도 감사를 표현합니다.

REFERENCES

- [1] X. Yang, S. Zhang, J. Liu, Q. Gao, S. Dong, C. Zhou, "Deep learning for smart fish farming: applications, opportunities and challenges," *Reviews in Aquaculture*, vol. 13, no. 1, pp. 66-90, 2021.
- [2] D. Breitburg, L.A. Levin, A. Oschlies, M. Gregoire, "Declining oxygen in the global ocean and coastal waters," *Science*, vol. 359, no. 6371, 2018.
- [3] AKVA GROUP. (2024). <https://www.akvagroup.com/> (accessed Sep., 22, 2024).
- [4] STEINSVIK PRODUCTION. (2024). <https://sproduction.no/> (accessed Sep., 22, 2024).
- [5] LINN Geratebau. (2024). <https://www.linn.eu/de/> (accessed Sep., 22, 2024).
- [6] Fish Farm Feeder. (2024). <https://www.fishfarmfeeder.com/en/feeding-systems/> (accessed Sep., 22, 2024).
- [7] National Institute of Fisheries Science, "Standard guidelines for eel," 2017, (https://www.nifs.go.kr/distantwater/skin/doc.html?fn=20220209163834360_0.pdf&rs=/distantwater/preview/Board0027/).
- [8] W. Vazquez-Quispesivana, M. Inga, I. Betalleluz-Pallardel, "Artificial intelligence in aquaculture: basis, applications, and future perspectives," *Scientia Agropecuaria*, vol. 13, no. 1, pp.79-96, 2022.
- [9] 전명재, 신춘성, 정희용, 조보현, 박진기, 이성규, "인공지능 기반의 양식장 사료 공급 시스템 및 방법", *대한민국특허*, 출원번호 10-2024-0069308, 2024년
- [10] W. Kim, M. Jun, H. Jeong, "Real-time Prediction of Dissolved Oxygen Levels in Automated Aquaculture Feeding Systems Using a Combined Time Series Decomposition and Pretrained TCN Model," *BigDAS'24: Proceedings of the 2024 International Conference on Big Data Applications and Services*, 22-24 Aug, Jeju, South Korea.
- [11] 김우재, 정희용, "딥러닝 기반 시계열 분해를 통한 랜덤 이벤트를 포함한 데이터 예측 - 용존 산소량 예측 방법 제안 및 검증", *2024스마트미디어융계학술대회*, 2024년 5월 17일-18일, 광주실감콘텐츠큐브(GCC) 및 광주CGI센터.
- [12] N. Huynh, M. Jun, H. Jeong, "Effect of

light-emitting grid panel on indoor aquaculture for measuring fish growth," *Sensors*, vol. 24, no. 3, 2024.

- [13] H. Nguyen, M. Jun, H. Jeong, "Real-time estimation of Olive Flounder growth in indoor aquaculture using cameras combined with a grid," *Journal of the World Aquaculture Society*, 2024.
- [14] 전명재, 정희용, 김태호, "스마트양식을 위한 생물 성장 측정 시스템", *대한민국특허*, 출원번호 10-2022-0172688.
- [15] M. Jun, H. Jeong, C. Shin, T. Kim, "Development of Light-Emitting Grid Panel for Fish Growth in Indoor Aquaculture Farm," *OCEANS 2023 - Limerick*, Limerick, Ireland, 5-8 Jun. 2023.
- [16] D. Lee, J. Bae, K. Lee, "Development of an Edge Computing-Based Intelligent Feeding System for Observing Depth-Specific Feeding Behavior in Red Seabream," *Journal of Marine Science and Engineering*, vol. 11, no. 9, pp. 1767, 2023.

저 자 소 개



전명재(정회원)

2005년 한국산업기술대학교 전자공학과 학사 졸업.
2010년 한양대학교 지능형 로봇학과 석사 졸업.
2018년 한양대학교 메카트로닉스 공학과 박사 졸업.

2019-2021 Osaka University Post-doc 연구원.

2021-현재 전남대학교 인공지능융합학과 연구원

<주관심분야 : 생체모방로봇, 헬스케어시스템, 스마트 아쿠아팜 IoT시스템>



신춘성(종신회원)

2004년 숭실대학교 컴퓨터학부 학사 졸업.
2006년 광주과학기술원 정보통신공학과 석사 졸업.
2010년 광주과학기술원 정보통신공학과 박사 졸업.

2010-2012 카네기멜론대학 HCI연구소 박사후연구원

2013-2018 전자부품연구원 VR/AR연구센터 책임연구원

2018-2019 문화체육관광부 문화기술PD

2019-현재 전남대학교 문화전문대학원 미디어콘텐츠·컬처테크전공 교수

<주관심분야 : 문화기술, AR/VR, HCI >



정희용(종신회원)

2002년 부경대학교 제어계측공학과 학사 졸업.

2004년 Hiroshima University 로봇공학 석사 졸업.

2009년 Osaka University 기계공학과 박사 졸업.

2009-2013 삼성중공업 산업기술연구소 책임연구원

2014-2019 Osaka University 부교수

2019-현재 전남대학교 인공지능융합학과 교수

<주관심분야 : 인공지능, 헬스케어, IoT, HRI>