

스트레스 조건에 노출된 Angelfish *Pterophyllum scalare*의 행동 변화 분석 및 예측

김윤재 · 노혜민¹ · 김도형*

부경대학교 수산생명의학과, ¹부산대학교 전기전자컴퓨터공학부

Analysis and Prediction of Behavioral Changes in Angelfish *Pterophyllum scalare* Under Stress Conditions

Yoon-Jae Kim, Hea-Min NO¹ and Do-Hyung Kim*

Department of aquatic life medicine, Pukyong National University, Busan 48513, Korea

¹Department of Electrical and Computer Engineering, Pusan National University, Busan 46241, Korea

The behavior of angelfish *Pterophyllum scalare* exposed to low and high temperatures was monitored by video tracking, and information such as the initial speed, changes in speed, and locations of the fish in the tank were analyzed. The water temperature was raised from 26°C to 36°C or lowered from 26°C to 16°C for 4 h. The control group was maintained at 26°C for 8 h. The experiment was repeated five times for each group. Machine learning analysis comprising a long short-term memory model was used to train and test the behavioral data (80 s) after pre-processing. Results showed that when the water temperature changed to 36°C or 16°C, the average speed, changes in speed and fractal dimension value were significantly lower than those in the control group. Machine learning analysis revealed that the accuracy of 80-s video footage data was 87.4%. The machine learning used in this study could distinguish between the optimal temperature group and changing temperature groups with specificity and sensitivity percentages of 86.9% and 87.4%, respectively. Therefore, video tracking technology can be used to effectively analyze fish behavior. In addition, it can be used as an early warning system for fish health in aquariums and fish farms.

Keywords: Fish behavior, Angelfish, Temperature change, Video tracking

서 론

지난 20년 동안 동물의 행동과 움직임을 기록하고 감지하는 기술은 지속적으로 발전해왔다(Noldus et al., 2002). 특히 video tracking 기술은 많은 데이터를 수집할 수 있고 그 영상으로부터 행동패턴을 분석하여 육안으로 쉽게 관찰할 수 없는 미세한 이상 행동까지도 감지할 수 있는 장점이 있다(Noldus et al., 2002; Zum et al., 2005; Denoël et al., 2013). 지금까지 video tracking에 의한 행동 패턴 연구는 주로 설치류(Zum et al., 2005), 소(Chae and Cho, 2020), 돼지(Lind et al., 2005) 등의 육상동물에서 많이 이뤄지고 있다. 이런 연구의 대부분은 단일 카메라로부터 얻어진 2D 데이터를 이용하여 분석한다(Macri et al., 2017). 대부분의 동물 행동분석 연구는 개체 인식, 신경과

학, 독성 평가 및 신약 개발 분야에 집중되어 있다(Nimkerdphol and Nakagawa, 2008a; Burne et al., 2011; Cachat et al., 2011; Stewart et al., 2015; Rosa et al., 2018; Deakin et al., 2019). 예를 들어, 쥐의 행동분석을 통해 유전적 돌연변이나 정신적 장애에 대한 치료제 개발을 시도하였다(Zum et al., 2005; Hong et al., 2015). 돼지를 이용하여 아포몰핀(apomorphine)과 같은 약물의 작용 연구(Lind et al., 2005)뿐만 아니라, 최근에는 개체 인식과 행동 분석을 통해 돼지농장에 적용하는 연구까지 이뤄지고 있다(Yang et al., 2020). 그러나 육상동물과는 달리 어류의 행동은 3차원에서 표현되므로 최소 2대의 카메라를 이용하여 3D 데이터에 기반하여 행동패턴을 분석해야 하는 어려운 점이 있다. 이전 연구에서는 제브라피쉬(*Danio rerio*) 두 마리 사이의 상호 행동(Kato et al., 2004) 및 포식자에 대한 반응(Macri et

*Corresponding author: Tel: +82.51. 629. 5945 Fax: +82. 51. 629. 5938

E-mail address: dhkim@pknu.ac.kr



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

<https://doi.org/10.5657/KFAS.2021.0965>

Korean J Fish Aquat Sci 54(6), 965-973, December 2021

Received 12 August 2021; Revised 25 August 2021; Accepted 28 October 2021

저자 직위: 김윤재(대학원생), 노혜민(대학원생), 김도형(교수)

al., 2017)을 연구하였다. 또한 제브라피쉬의 행동분석을 통하여 마취제(tricaine methanesulfonate), 향정신성약물(e.g. PCP, nicotine and LSD), 카페인 등의 위험평가를 수행하였다(Kane et al., 2004; Stewart et al., 2015; Rosa et al., 2018). 차아염소산나트륨(Sodium hypochlorite)과 에탄올 노출에 대한 행동분석 연구에는 금붕어가 이용되었다(Zhu and Weng, 2007; Nimkerdphol and Nakagawa, 2008b). 양식어종인 틸라피아(*Oreochromis niloticus*)와 gilt-head sea bream (*Sparus aurata*)을 대상으로 용존산소 농도와 수용밀도에 따른 행동 변화를 분석한 연구도 있다(Xu et al., 2006; Papadakis et al., 2012). 그러나 지금까지 스트레스 환경이나 병원체에 감염된 어류의 행동 변화를 분석한 연구는 찾을 수 없다.

매년 4000종 이상의 담수어와 1400종의 해수어를 포함하여 10억마리 이상의 관상어가 국제적으로 거래되고 있다(Whittington et al., 2007). 관상어 사육은 제한된 수조 내에서 적정 환경을 유지하는 것이 매우 중요하다. 특히, 수온은 관상어 사육에 있어 가장 중요한 요소 중의 하나이며, 일반적으로 사용하는 히터, 냉각기 등 수온 조절장치의 고장으로 인한 급격한 수온의 변화는 어류 대사의 변화, 호흡 장애, 평형감각의 상실 등 여러 문제를 초래할 수 있다. 이처럼 관상어 사육 시에 발생할 수 있는 환경 변화에 의한 스트레스 유발을 어류 행동패턴 변화의 감지로 초기에 발견할 수 있다면 상황이 악화되기 전에 막을 수 있을 것이다. 따라서 본 연구에서는 시장가치가 높은 담수 관상용 어종인 angelfish *Pterophyllum scalare*를 이용하여 급격한 수온 변화에 의한 스트레스 조건에서 개체의 행동 변화를 video tracking 기술을 기반으로 속력 및 위치의 변화를 분석하고 머신러닝을 이용하여 육안 보다 빠리 이상 행동을 예측할 수 있는 방법을 찾고자 하였다.

재료 및 방법

실험어 순치 및 실험 환경

본 연구에서는 질병이 없는 건강한 angelfish 15마리(5.2 ± 0.4 cm, 2.7 ± 0.16 g)를 구입하여 26°C로 유지되는 수조(25 cm length \times 25 cm width \times 25 cm height)에 순치하였다. Video tracking을 위해 좌측면과 후면에 흰색 시트지가 부착된 26°C로 유지되는 유리 수조(45 cm length \times 45 cm width \times 45 cm height)에 한 마리의 angelfish를 넣어 실험을 수행하였다. 물 높이는 바닥으로부터 40 cm를 유지하였다. 카메라는 Intel RealSense D435 (Intel Corporation, Santa Clara, CA, USA) 2대를 각각 수조 정면과 우측면에서 50 cm 떨어진 곳에 설치하였다. 카메라는 video tracking software가 설치된 컴퓨터와 연결하였으며, software는 SoosangST (Busan, Korea)에서 개발한 smart aqua system software를 사용하였다(Fig. 1). Video tracking software는 수조 비율을 640 \times 640 \times 480 pixels로 조정하여 녹화하였으며, frame rate는 3-4 FPS (frame per sec-




Fig. 1. Experimental setup for angelfish *Pterophyllum scalare* using video tracking. Cameras were placed at the front (XZ) and side (YZ).

ond)였다. 녹화된 데이터에는 가로, 세로 및 높이의 좌표, 순각 속력, 촬영시간이 포함되어 있도록 했다.

일반 환경 및 온도 스트레스 조건

Angelfish의 행동 패턴 녹화는 10시부터 18시까지 수행되었으며, 불필요한 외부 자극을 줄이기 위해 실험 셋팅 이후 끝날 때 까지 해당 공간의 출입을 가급적 자제하였다. 대조그룹의 경우 녹화하는 8시간 동안 최적 사육 수온(27-30°C; Korzelecka-Orkisz et al., 2012)에 근접한 26°C로 유지하였으며, 이 구간을 “최적 수온 구간(optimal temperature, OT)”이라고 명명하였다. 이전 연구에서 angelfish에 대한 critical thermal limit가 각각 35.9-36.5°C, 12.82 ± 0.72 °C (Pérez et al., 2003; Yanar et al., 2019)인 것을 바탕으로 그와 근접한 온도인 36°C와 16°C에서 수온 스트레스를 유발할 수 있을 것으로 판단하여 다음과 같이 스트레스 유발 그룹을 설정하였다. 수온 상승에 의한 스트레스를 유발한 그룹의 경우 주변 공기 온도를 높이고 수중 히터를 이용하여 수온 26°C에서 4시간 동안 일정한 간격으로 10°C를 상승시켜 36°C에 도달하게 한 후 4시간을 지속하였다. 26°C에서 36°C로 수온의 변화과정을 “수온 상승 구간(increasing temperature, IT)”, 4시간 동안 36°C가 유지되는 과정을 “고수온 구간(high temperature, HT)”이라고 명명하였다. 수온 하강의 경우 주변 공기 온도를 낮추고 저온의 물로 실험 수조의 물을 교체하여 26°C에서 4시간 동안 일정한 간격으로 10°C 하강시켜 16°C에 도달하게 하였다. 이후 4시간 동안 16°C를 유지하였다. 따라서 26°C에서 16°C로 수온의 변화과정을 “수온 하강 구간(decreasing temperature, DT)”, 16°C로 유지하는 과정을 “저수온 구간(low temperature, LT)”이라고 명명하였다. 모든 수온 변화 시간 동안 수조 내 물을 섞어주기 위해 기포기를 좌측 하단에 설치하였으며, 행동 패턴을 연속적으로 녹화하여 각 그룹별로 5마리의 개체를 이용하여 반복 수행하였다(Fig. 2).

데이터 보정

본 연구에서는 2대의 카메라를 이용하여 획득한 video tracking의 angelfish 좌표값은 원근에 의해 왜곡된 좌표로 출력된다.

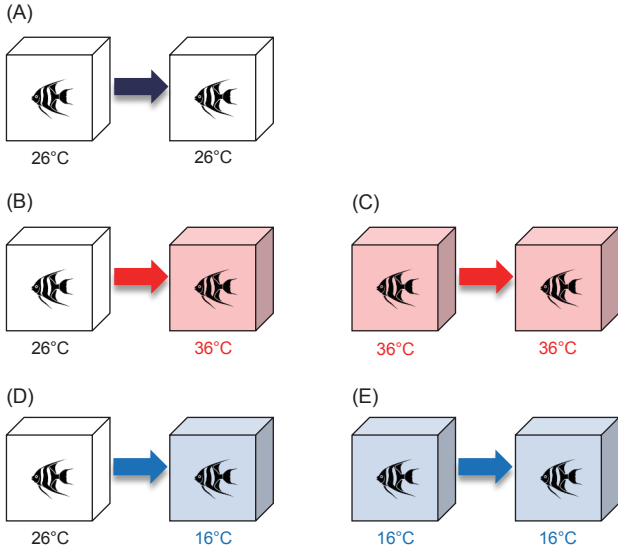


Fig. 2. Experimental setup for temperature changing. OT (26°C) (A), IT (26°C to 36°C) (B), HT (36°C) (C), DT (26°C to 16°C) (D) and LT (16°C) (E) groups. All groups were tracked for 4 h.

이를 해결하기 위해 Nimkerdphol and Nakagawa (2008a)의 방법을 일부 수정하여 Fig. 3에 표현된 모식도를 바탕으로 아래와 같은 방정식으로 실제 좌표로 변환하고자 하였다.

$$x' = x + \Delta x,$$

$$\Delta x = x_d \times \left(\frac{x - x_c}{x_{innerWidth}/2} \right) \times \left[\left(1 - \frac{x - x_{outerMin}}{x_{outerMin}} \right) \times \left(\frac{y - y_{innerMin}}{y_{innerWidth}} \right) + \left(\frac{x - x_{outerMin}}{x_{outerWidth}} \right) \times \left(\frac{y - y_{outerMin}}{y_{outerWidth}} \right) \right] \dots (1)$$

$$y' = y + \Delta y,$$

$$\Delta y = y_d \times \left(\frac{y - y_c}{y_{innerWidth}/2} \right) \times \left(1 - \frac{x'}{x_{outerWidth}} \right) \dots (2)$$

$$z' = z + \Delta z,$$

$$\Delta z = z_d \times \left(\frac{z - z_c}{z_{innerWidth}/2} \right) \times \left(\frac{y'}{y_{outerWidth}} \right) \dots (3)$$

여기서, x' , y' , z' 은 좌표 변환 방정식을 통해 계산된 실제 좌표이다. x , y , z 는 video tracking으로부터 출력된 x 축, y 축, z 축에 대응하는 어류의 좌표이다. Δx , Δy , Δz 는 각각 x 축, y 축, z 축으로부터 왜곡된 좌표를 실제 좌표로 계산된 결과이며, x_c , y_c , z_c 는 각각 x 축, y 축, z 축의 중앙 좌표이다. x_d , y_d , z_d 는 각각 x 축, y 축, z 축 사이 거리의 평균이다.

$x_{outerWidth}$, $x_{innerWidth}$, $x_{outerMin}$, $x_{outerMax}$, $x_{innerMin}$, $x_{innerMax}$ 는 각각 x 축의 외부 모서리 길이, 내부 모서리 길이, 외부 모서리에 대응하는 최소 좌표, 외부 모서리에 대응하는 최대 좌표, 내부 모서리에 대응하는 최소 좌표, 내부 모서리에 대응하는 최대 좌표이다.

다. 마찬가지로 y 축 및 z 축에 대응하는 값은 x 축과 동일하다.

속력 분석

수온 변화 스트레스 시험의 속력 데이터는 수온 상승(26°C to 36°C), 고수온(36°C), 수온 하강(26°C to 16°C), 저수온(16°C)으로 구분하여 분석하였다. 온도 변화 스트레스 시험의 속력 분석은 수온 변화 구간별 4시간 데이터를 이용하여 수행하였다. 최적 수온 구간은 실험 시간 중 4시간을 촬영하여 데이터를 분석한 후 온도 변화 그룹과 비교하였다. 속력 데이터는 5 mm/s 이하 속력 분포 비율, 평균 속력, 그리고 1초당 속력 변화량을 분석하였다.

위치 분석

위치 데이터는 angelfish가 분포한 위치에 따라 머문 시간과 fractal dimension 값을 분석하였다. 분포한 위치는 수조의 깊이 에 따라 하층부, 중층부, 상층부로 구분하였다. Fractal dimension 분석은 데이터의 복잡성을 확인하는 방법으로써 행동 분석에도 사용되고 있는 방법으로 최근에 Deakin et al. (2019)과 Nimkerdphol and Nakagawa (2008a)가 어류 행동 분석에 이 방법을 사용하였다. Fractal dimension 분석은 box-counting 방법을 사용하여 계산하였다. 정면인 XZ면과 우측면인 YZ면을 각각 0.625, 1.25, 2.5, 5, 10, 20, 44, 80, 160 pixel 크기의 정사각형 상자로 면적을 구분하였으며, angelfish의 행동 좌표를 포함하는 상자 개수를 counting하였다. Fractal dimension은 다음과 같은 식을 사용하여 계산하였다.

$$D = -\lim_{n \rightarrow \infty} \frac{\ln N}{\ln \epsilon} \dots (4)$$

여기서, N 은 box의 개수, ϵ 은 box size이다.

머신러닝을 이용한 행동 예측

Video tracking으로 도출된 데이터는 추가적인 분석을 통해 최적 수온 데이터와 비교해야 하며, 실시간으로 분석할 수 없는 한계가 있다. 따라서 본 연구에서는 머신러닝 기법을 활용하여 최적 수온 환경과 이상 수온 환경을 구분하고 예측하여 조기에 이상 행동을 발견하고자 하였다(Fig. 4). Video tracking으로 출력된 데이터는 (x, y, z)좌표로 이루어진 1,237,042개의 시계열 데이터로, 다섯가지 그룹별 데이터 개수 비율은 모두 약 20%이다. 즉, 최적 수온 그룹(OT)과 수온 스트레스 그룹(IT, HT, DT, LT)의 데이터 개수 비율은 각각 전체 데이터의 약 20%, 80%이다. 이 때, 최적 수온 그룹과 수온 스트레스 그룹은 유사한 데이터를 동시에 포함하면서 데이터 양의 차이가 크므로 스트레스 그룹을 무작위로 샘플링하여 75%의 샘플만 학습데이터로 활용하였다. 이러한 데이터를 머신러닝의 학습 데이터로 활용하기 위해 80초 단위(240개)의 sequence로 만드는 데이터 전처리(preprocessing) 과정을 수행하였다. 즉, 80초 단위의 3차원 좌




Fig. 3. Parameters used in equations for coordinate transformation.

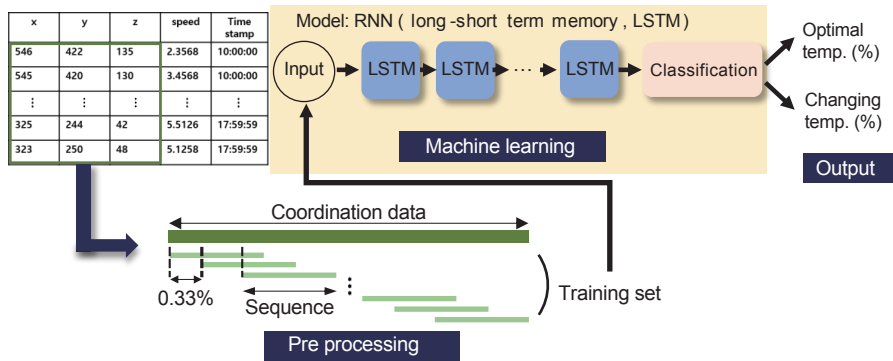


Fig. 4. The machine learning process.

표를 가지는 5,154개의 sequence 데이터를 학습데이터로 사용했다. 이 때, 길이는 실험적 방법을 통해 선정된 최적 길이이다. 정확도 향상을 위해 최초로 만든 sequence와 0.3의 비율로 겹치는 sequence 5,153개를 생성하였다. 총 10,207개의 학습데이터를 random sampling하여 60%는 training, 30%는 validation, 10%는 test 데이터로 사용하였다.

학습 모델은 시계열 데이터의 상관관계를 학습하는 순환신경망(recurrent neural network, RNN)으로 선정하였으며, 그 중에서도 기존 순환신경망의 수학적 한계인 기울기 소실 문제(vanishing gradient problem)를 해결하여 높은 성능을 보이는 LSTM (long short-term memory) 기법을 사용하였다(Kim and Kim, 2017). 또한, 학습 파라미터들은 실험적 방법을 통하여 다음과 같이 최적값으로 설정하였다(Number of layer in LSTM, 512; batch size, 128; learning rate, 0.001; number of epoch, 100). 최적 수온 환경 및 수온 스트레스 환경에서의 데이터를 기반으로 행동변화를 감지하는 학습을 진행하고 성능을 확인하였다. 이 때, 머신러닝의 학습 데이터는 랜덤 샘플링을 사용하기 때문에 데이터 편향(bias)이 나타나 학습이 제대로 이루어 질 수 없다는 문제점이 있다. 이러한 문제를 해결하기 위해 모든 데이터를 활용할 수 있도록 10번의 몬테카를로 시뮬레이션(Monte-Carlo simulation)방법을 통해 성능을 확인하였다.

통계분석

Video tracking으로부터 도출된 좌표의 개수와 속력 및 위치 분석으로 도출된 결과는 SPSS v20.0 (IBM, NY, USA)의 one-way analysis of variance (ANOVA) test로 확인하였으며, 사후 검정은 Duncan's multiple range test 방법을 이용하여 유의성을 검정하였다($P < 0.05$).

결과 및 고찰

Video tracking 데이터의 유의성 검증

Video tracking software를 이용하여 수온 변화에 따른 행동 데이터를 수집하였으며, 각 조건에 따른 데이터의 수를 Table 1에 나타내었다. 온도 변화에 따른 모든 데이터 개수는 평균 49,482개였으며 표준편차는 $\pm 35,457$ 개였다. 모든 온도 변화 조건에서 도출된 좌표의 개수에 대한 통계분석 결과 유의적인 차이는 없었다.

수온 변화에 따른 angelfish 속력 분석

Video tracking을 통해 도출된 속력 데이터의 분석결과를 그룹별로 히스토그램(Fig. 5)과 막대 그래프(Fig. 6)로 나타내었

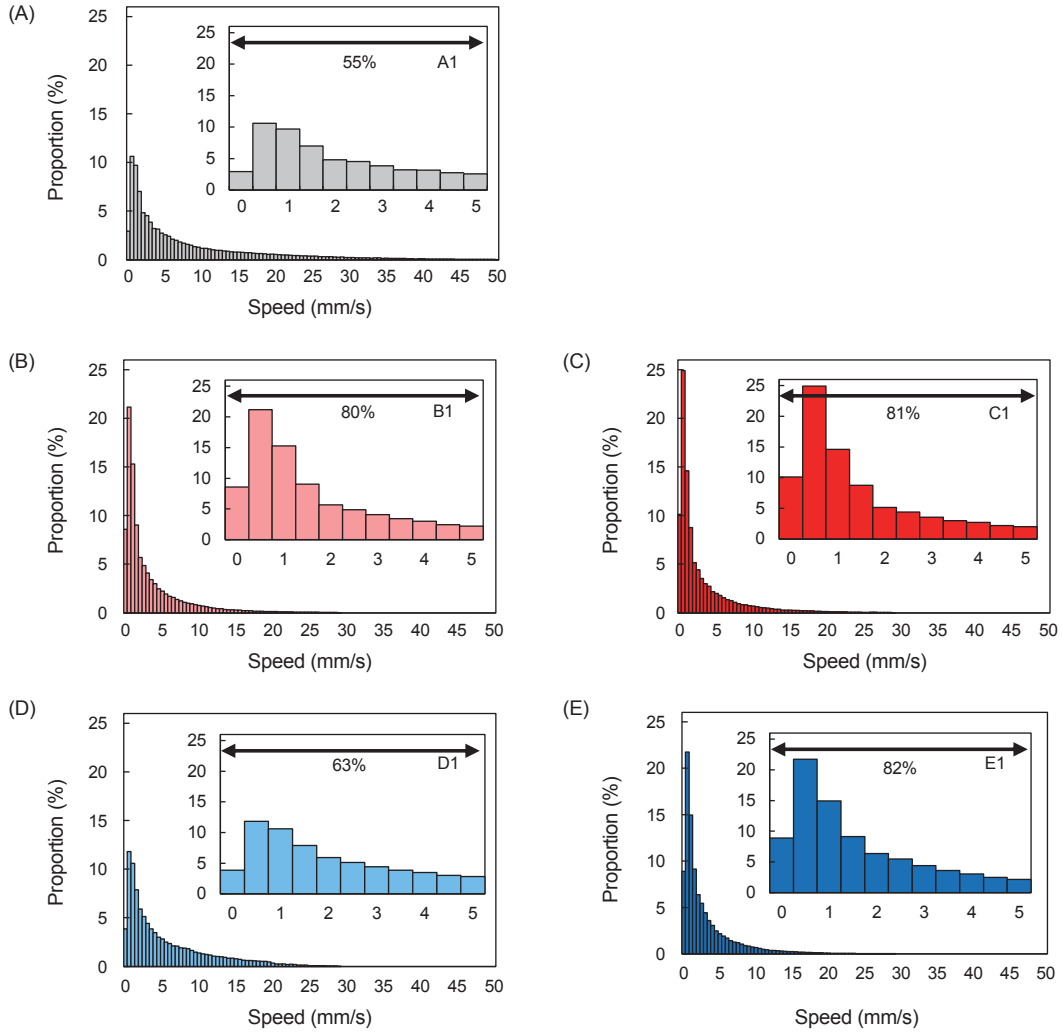


Fig. 5. Speed histograms according to water temperature changes. Speed distribution of angelfish in OT (26°C) (A), IT (26°C to 36°C) (B), HT (36°C) (C), DT (26°C to 16°C) (D), and LT (16°C) (E). A1, B1, C1, D1 and E1 indicate proportions at speeds below 5 mm/s.

다. 최적 수온(대조군), 수온 상승, 고수온, 수온 하강, 저수온 그룹에서 평균 속도, 5 mm/s 이하의 속도 분포 비율은 각각 8.47, 4.12, 3.9, 6.26, 3.68 mm/s와 55%, 80%, 81%, 63%, 82%였다. 이는 최적 수온과 비교하여 모든 수온 변화 구간에서 angelfish

의 속력이 떨어지는 것을 나타내고 있다. 또한 1초당 속도 변화량의 평균을 분석한 결과, 최적 수온, 수온 상승, 고수온, 수온 하강, 저수온 그룹은 각각 2.91 mm/s, 1.3 mm/s, 1.24 mm/s, 1.7 mm/s, 0.91 mm/s였다. 모든 수온 변화 그룹은 대조군에 비해

Table 1. Numbers of spatial coordinates based on the movement of angelfish *Pterophyllum scalare* under acute water temperature changes

Stress conditions	Trials				
	1	2	3	4	5
Optimal temperature (OT) (26°C)	54,798	50,523	44,983	51,980	54,891
Increasing temperature (IT) (26°C to 36°C)	56,001	46,922	47,531	50,366	49,233
High temperature (HT)	45,196	43,554	47,017	47,833	50,871
Decreasing temperature (DT) (26°C to 16°C)	51,717	52,447	47,045	49,665	48,893
Low temperature (LT) (16°C)	48,946	52,938	54,184	45,603	43,905




Fig. 6. Average speed (A) and changes in speed (per second) (B) of angelfish *Pterophyllum scalare* subjected to water temperature alterations. Different letters indicate statistically significant differences between the normal temperature group and other groups (analyzed using Duncan's multiple range test) ($P < 0.05$).

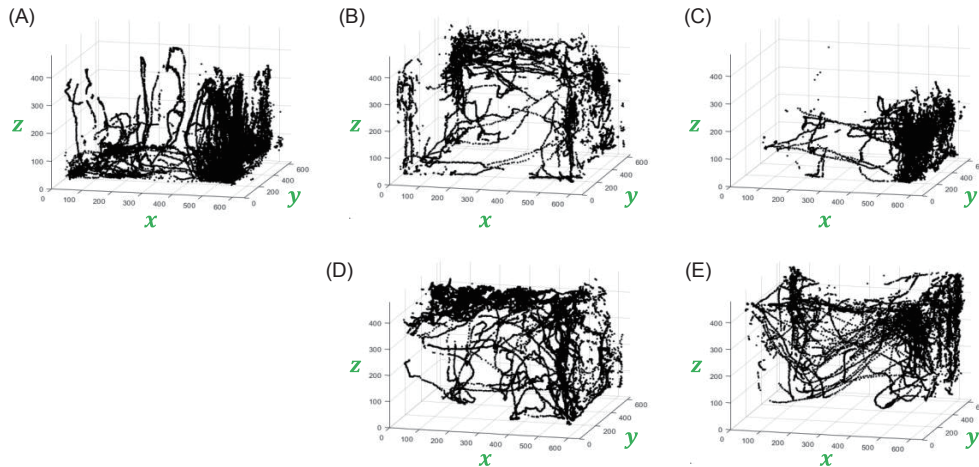


Fig. 7. Tracking results (3D scatter plot) of different groups over 4 h. OT (26°C) (A), IT (26°C to 36°C) (B), HT(36°C) (C), DT(26°C to 16°C) (D), and LT (16°C) (E).

유의적으로 낮은 속력 변화량을 나타내었다.

어류는 고수온 환경에 노출되면 자극에 대한 반응이 감소하고 움직임이 둔해져 활동성이 감소하는 경향이 나타나며 심한 경우 방향성을 잃어버리고 근육 경련이 일어나기도 한다(Lutterschmidt et al., 1997). 유사하게 어류는 저수온 환경에서도 움직임이 느려지고, 수영 능력이 저하되며 반응성의 감소와 평형 상태의 상실, 호흡의 곤란, 근육 수축 증상을 나타낸다고 알려져 있다(Wardle, 1980; Donaldson et al., 2008; Bartolini et al., 2015). 본 연구에서도 수온이 상승하거나 하강하는 환경에 노출된 angelfish는 대조그룹에 비해 유의적으로 속력이 감소하는 것으로 나타났다(Fig. 5, Fig. 6). 이는 고수온에서 유럽 농어(*Dicentrarchus labrax*)의 수영 능력이 증가하고 더 빨리 움직였다(Claireaux et al., 2006)는 이전 연구와 상반된 결과를 보였으나, 급성 저수온 스트레스 하에서 구피(*Poecilia reticulata*)와

brown trout *Salmo trutta*의 활동이 감소하였고(Colchen et al., 2017; Wiles et al., 2020), 대서양대구(*Gadus morhua*)의 경우 대사가 감소하는 등(Claireaux et al., 1995)의 결과와는 일치하는 것으로 나타났다. 따라서 급성적인 수온의 변화에 따른 스트레스로 angelfish의 수영 속력 변화를 video tracking 방법으로 감지할 수 있었다.

수온 변화에 따른 angelfish 위치 분석

Video tracking으로부터 도출된 좌표를 이용하여 수온 변화에 따른 angelfish의 위치를 분석하였다. 모든 그룹에서 4시간 동안의 angelfish의 위치 좌표를 무작위로 선정하여 3차원 공간에서 재구성하여 Fig. 7과 같이 나타내었다. 최적 수온 그룹과는 다르게 수온 변화에 의한 스트레스 발생 시 angelfish의 수영 패턴이 다양하게 나타나는 것을 확인할 수 있었다.

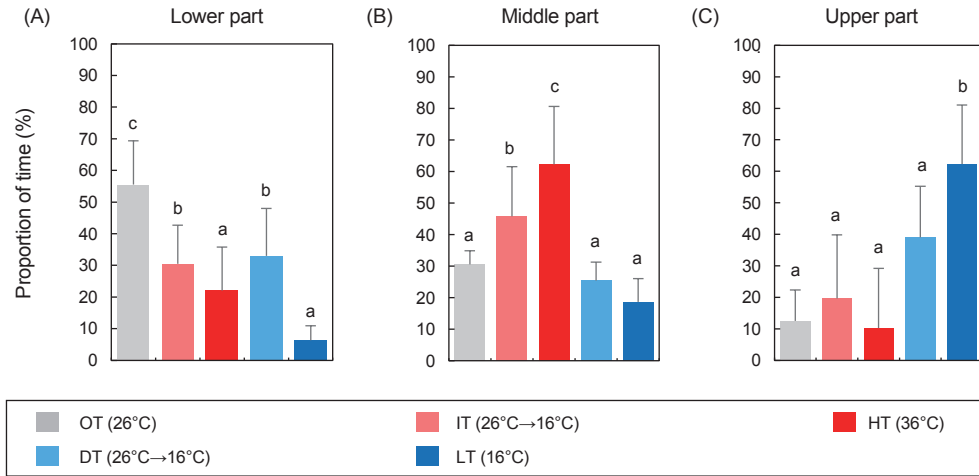


Fig. 8. The time that angelfish *Pterophyllum scalare* spent in the lower (A), middle (B), and upper (C) parts of the tank. Different letters indicate statistically significant differences ($P < 0.05$).




Fig. 9. Fractal dimension values of fish in different groups. XZ-side (Front) (A) and YZ-side (Side) (B). Different letters indicate statistically significant differences ($P < 0.05$).

수온 변화에 따른 angelfish의 수조 공간 분포 비율을 분석하기 위해 수심을 3등분으로 나눠 각 공간에 머무는 각 그룹의 비율을 Fig. 8에 나타내었다. 대조그룹의 angelfish는 하층, 중층 및 상층 부위에서 머무는 비율이 각각 약 56%, 31% 및 14%로 나타났다. 수온 상승 및 고수온 그룹에서는 대조구에 비해 하층부에 머무는 비율이 유의적으로 낮았고 주로 중층부에 위치하는 경향이 컸다. 수온 하강 및 저수온 그룹에서는 대조구에 비해 상층부에 머무는 경향이 나타났다. 특히 수온 하강 및 저수온 그룹의 경우 상층부에서 보다 오래 머무는 경향이 뚜렷이 나타났는데, 이는 물을 가열하고 냉각하면서 수조의 바닥과 위쪽의 수온이 상대적으로 1-2°C 차이났으며 그로 인해 angelfish가 수온

이 덜 변화된 곳으로 이동했을 가능성이 있는 것으로 보인다. 제브라피쉬 유생도 수온 변화가 나타나면 선호하는 온도로 이동하였던 결과(López-Olmeda and Sánchez-Vázquez, 2011)와 유사한 것으로 판단된다.

Fractal dimension 분석 결과, 정면인 XZ-side에서 최적 수온, 수온 상승, 고수온, 수온 하강, 저수온 그룹의 FD value는 각각 1.44, 1.33, 1.32, 1.37, 1.34였다(Fig. 9A). 측면인 YZ-side에 의 FD value는 각각 1.44, 1.31, 1.35, 1.38, 1.34였다(Fig. 9B). XZ-side와 YZ-side에서 모두 최적 수온과 비교하여 모든 온도 변화 그룹에서 유의적으로 낮은 FD value를 나타내었다. 본 연구에서는 최적 수온 대비 수온 변화 환경에서 유의적으로 더 낮

은 FD value를 나타내었으며, 이는 수온이 급격하게 변할 때 어류의 유명 패턴이 더욱 단순해진다는 것을 의미한다. 이는 video tracking을 이용한 다양한 분석 방법으로 이상 행동을 효과적으로 감지할 수 있음을 보여주고 있다.

머신러닝을 이용한 이상 행동 분석

10회의 몬테카를로 시뮬레이션의 결과, accuracy의 평균값은 각각 약 87.4%로 나타났다. 각 수온 변화 그룹에 대한 specificity와 sensitivity는 각각 86.9%, 87.4%으로 균형적(balanced)인 결과가 나타났다. 이러한 결과는 80초 길이의 행동 데이터 만으로도 최적 수온 또는 이상 수온 변화 환경을 구분 및 예측할 수 있다는 것을 의미한다. 머신러닝을 적용한 애완동물 행동 분석 선행 연구에서는 LSTM으로 반려묘의 행동 분류와 위치 식별 정확도 각각 평균 96.3%와 92.7%의 결과를 보이고 있다 (Choi et al., 2021). 본 연구의 결과는 선행 연구에 비해 다소 낮은 정확도를 보이지만 선행 연구와 대비하여 본 논문의 관찰 대상인 어류는 협소한 수조 환경에서 작은 운동량으로 3차원 공간을 완전히 이용한다는 측면으로 볼 때 약 87%의 정확도는 충분히 유의미하다고 판단된다. 따라서 수온 변화 발생 시 어류의 행동 변화를 머신러닝으로 감지하고 예측할 수 있으며 조기 경보시스템으로도 활용될 수 있음을 보여준다.

본 연구의 결과는 육안으로 신속하고 정확히 인지하기 어려운 어류의 이상 행동을 video tracking을 이용하여 속력 및 위치분석을 통해 감지 가능하다는 것을 보여주고 있다. 어류가 흔히 겪을 수 있는 수온 변화에서 나타나는 행동 변화를 속력과 분포하는 위치를 통해 최적 수온 그룹과의 차이를 확인 할 수 있었고 머신러닝의 적용도 충분히 가능하다는 것을 보여주고 있다. 본 연구의 머신러닝 결과를 바탕으로 관상어 사육자의 최종판단을 더한다면 문제 발생을 좀 더 빨리 인지하고 효과적인 대처가 가능할 것이다. 또한, 본 연구 결과는 향후 데이터베이스 구축 및 성능 개선을 통해 완전 자동화를 위한 연구의 기초자료로 활용될 수 있을 것이다. 궁극적으로, 추후 머신러닝을 포함하는 인공지능 기술의 활용으로 작은 수조에서부터 대형 아쿠아리움이나 양식장에 적용하는 후속 연구가 수행되어야 할 것이다.

사 사

이 논문은 부경대학교 자율창의학술연구비(2019년)에 의하여 연구되었음.

References

- Bartolini T, Butail S and Porfiri M. 2015. Temperature influences sociality and activity of freshwater fish. *Environ Biol Fish* 98, 825-832. <https://doi.org/10.1007/s10641-014-0318-8>.
- Burne T, Scott E, van Swinderen B, Hilliard M, Reinhard J, Claudianos C, Eyles D and McGrath J. 2011. Big ideas for small brains: what can psychiatry learn from worms, flies, bees and fish?. *Mol Psychiatry* 16, 7-16. <https://doi.org/10.1038/mp.2010.35>.
- Cachat J, Stewart A, Utterback E, Hart P, Gaikwad S, Wong K, Kyzar E, Wu N and Kalueff AV. 2011. Three-dimensional neurophenotyping of adult zebrafish behavior. *PLoS One* 6, e17597. <https://doi.org/10.1371/journal.pone.0017597>.
- Chae J and Cho H. 2020. Detecting abnormal behavior of cattle based on object detection algorithm. *Trans Korean Inst Electr Eng* 69, 468-473. <http://doi.org/10.5370/KIEE.2020.69.3.468>.
- Choi Y, Chae H, Lee J, Park D and Chung Y. 2021. Cat monitoring and disease diagnosis system based on deep learning. *J Korea Multimed Soc* 24, 233-244. <https://doi.org/10.9717/kmms.2020.24.2.233>.
- Claireaux G, Couturier C and Groison AL. 2006. Effect of temperature on maximum swimming speed and cost of transport in juvenile European sea bass *Dicentrarchus labrax*. *J Exp Biol* 209, 3420-3428. <https://doi.org/10.1242/jeb.02346>.
- Claireaux G, Webber D, Kerr S and Boutilier R. 1995. Physiology and behaviour of free-swimming Atlantic cod *Gadus morhua* facing fluctuating temperature conditions. *J Exp Biol* 198, 49-60. <https://doi.org/10.1242/jeb.198.1.49>.
- Colchen T, Teletchea F, Fontaine P and Pasquet A. 2017. Temperature modifies activity, inter-individual relationships and group structure in a fish. *Curr Zool* 63, 175-183. <https://doi.org/10.1093/cz/zow048>.
- Deakin AG, Spencer JW, Cossins AR, Young IS and Sneddon LU. 2019. Welfare challenges influence the complexity of movement: fractal analysis of behaviour in zebrafish. *Fishes* 4, 8. <https://doi.org/10.3390/fishes4010008>.
- Denoël M, Libon S, Kestemont P, Brasseur C, Focant JF and Pauw ED. 2013. Effects of a sublethal pesticide exposure on locomotor behavior: a video-tracking analysis in larval amphibians. *Chemosphere* 90, 945-951. <https://doi.org/10.1016/j.chemosphere.2012.06.037>.
- Donaldson MR, Cooke SJ, Patterson DA and Macdonald JS. 2008. Cold shock and fish. *J Fish Biol* 73, 1491-1530. <https://doi.org/10.1111/j.1095-8649.2008.02061.x>.
- Hong W, Kennedy A, Burgos-Artizzu XP, Zelikowsky M, Navonne SG, Perona P and Anderson DJ. 2015. Automated measurement of mouse social behaviors using depth sensing, video tracking, and machine learning. *Proc Natl Acad Sci* 112, E5351-E5360. <https://doi.org/10.1073/pnas.1515982112>.
- Kane AS, Salierno JD, Gipson GT, Molteno TC and Hunter C. 2004. A video-based movement analysis system to quantify behavioral stress responses of fish. *Water Res* 38, 3993-4001. <https://doi.org/10.1016/j.watres.2004.06.028>.
- Kato S, Nakagawa T, Ohkawa M, Muramoto K, Oyama O, Watanabe A, Nakashima H, Nemoto T and Sugitani K. 2004. A computer image processing system for quantification of zebrafish behavior. *J Neurosci Methods* 134, 1-7.

- <https://doi.org/10.1016/j.jneumeth.2003.09.028>.
- Kim J and Kim H. 2017. An effective intrusion detection classifier using long short-term memory with gradient descent optimization. In: 2017 International Conference on Platform Technology and Service (PlatCon). 1-6. <https://doi.org/10.1109/PlatCon.2017.7883684>.
- Korzelecka-Orkisz A, Szalast Z, Pawlos D, Smaruj I, Tański A, Szulc J and Formicki K. 2012. Early ontogenesis of the angelfish, *Pterophyllum scalare* Schultze, 1823 (Cichlidae). *Neotrop Ichthyol* 10, 567-576. <https://doi.org/10.1590/S1679-62252012005000017>.
- Lind NM, Vinther M, Hemmingsen RP and Hansen AK. 2005. Validation of a digital video tracking system for recording pig locomotor behaviour. *J Neurosci Methods* 143, 123-132. <https://doi.org/10.1016/j.jneumeth.2004.09.019>.
- López-Olmeda JF and Sánchez-Vázquez FJ. 2011. Thermal biology of zebrafish *Danio rerio*. *J Therm Biol* 36, 91-104. <https://doi.org/10.1016/j.jtherbio.2010.12.005>.
- Lutterschmidt WI and Hutchison VH. 1997. The critical thermal maximum: data to support the onset of spasms as the definitive end point. *Can J Zool* 75, 1553-1560. <https://doi.org/10.1139/z97-782>.
- Macri S, Neri D, Ruberto T, Mwaffo V, Butail S and Porfiri M. 2017. Three-dimensional scoring of zebrafish behavior unveils biological phenomena hidden by two-dimensional analyses. *Sci Rep* 7, 1-10. <https://doi.org/10.1038/s41598-017-01990-z>.
- Nimkerdphol K and Nakagawa M. 2008a. Effect of sodium hypochlorite on zebrafish swimming behavior estimated by fractal dimension analysis. *J Biosci Bioeng* 105, 486-492. <https://doi.org/10.1263/jbb.105.486>.
- Nimkerdphol K and Nakagawa M. 2008b. 3D locomotion and fractal analysis of goldfish for acute toxicity bioassay. *Inter J Bioeng Life Sci* 2, 38-43. <https://doi.org/10.5281/zenodo.1326718>.
- Noldus LP, Spink AJ and Tegelenbosch RA. 2002. Computerised video tracking, movement analysis and behaviour recognition in insects. *Comput Electron Agric* 35, 201-227. [https://doi.org/10.1016/S0168-1699\(02\)00019-4](https://doi.org/10.1016/S0168-1699(02)00019-4).
- Papadakis VM, Papadakis IE, Lamprianidou F, Glaropoulos A and Kentouri M. 2012. A computer-vision system and methodology for the analysis of fish behavior. *Aquac Eng* 46, 53-59. <https://doi.org/10.1016/j.aquaeng.2011.11.002>.
- Pérez E, Díaz F and Espina S. 2003. Thermoregulatory behavior and critical thermal limits of the angelfish *Pterophyllum scalare* (Lichtenstein) (Pisces: Cichlidae). *J Therm Biol* 28, 531-537. [https://doi.org/10.1016/S0306-4565\(03\)00055-X](https://doi.org/10.1016/S0306-4565(03)00055-X).
- Rosa LV, Ardais AP, Costa FV, Fontana BD, Quadros VA, Porciúncula LO and Rosemberg DB. 2018. Different effects of caffeine on behavioral neurophenotypes of two zebrafish populations. *Pharmacol Biochem Behav* 165, 1-8. <https://doi.org/10.1016/j.pbb.2017.12.002>.
- Stewart AM, Grieco F, Tegelenbosch RA, Kyzar EJ, Nguyen M, Kaluyeva A, Song C, Noldus LPJJ and Kalueff AV. 2015. A novel 3D method of locomotor analysis in adult zebrafish: Implications for automated detection of CNS drug-evoked phenotypes. *J Neurosci Methods* 255, 66-74. <https://doi.org/10.1016/j.jneumeth.2015.07.023>.
- Wardle CS. 1980. Effects of temperature on the maximum swimming speed of fishes. In: *Environmental physiology of fishes*. Springer, Boston, MA, U.S.A., 519-531. https://doi.org/10.1007/978-1-4899-3659-2_20.
- Whittington RJ and Chong R. 2007. Global trade in ornamental fish from an Australian perspective: the case for revised import risk analysis and management strategies. *Prev Vet Med* 81, 92-116. <https://doi.org/10.1016/j.prevetmed.2007.04.007>.
- Wiles SC, Bertram MG, Martin JM, Tan H, Lehtonen TK and Wong BB. 2020. Long-term pharmaceutical contamination and temperature stress disrupt fish behavior. *Environ Sci Technol* 54, 8072-8082. <https://doi.org/10.1021/acs.est.0c01625>.
- Xu J, Liu Y, Cui S and Miao X. 2006. Behavioral responses of tilapia *Oreochromis niloticus* to acute fluctuations in dissolved oxygen levels as monitored by computer vision. *Aquac Eng* 35, 207-217. <https://doi.org/10.1016/j.aquaeng.2006.02.004>.
- Yanar M, Erdoğan E and Kumlu M. 2019. Thermal tolerance of thirteen popular ornamental fish species. *Aquaculture* 501, 382-386. <https://doi.org/10.1016/j.aquaculture.2018.11.041>.
- Yang Q and Xiao D. 2020. A review of video-based pig behavior recognition. *Appl Anim Behav Sci* 233, 105146. <https://doi.org/10.1016/j.applanim.2020.105146>.
- Zhu L and Weng W. 2007. Catadioptric stereo-vision system for the real-time monitoring of 3D behavior in aquatic animals. *Physiol Behav* 91, 106-119. <https://doi.org/10.1016/j.physbeh.2007.01.023>.
- Zurn JB, Hohmann D, Dworkin SI and Motai Y. 2005. A real-time rodent tracking system for both light and dark cycle behavior analysis. In: 2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05)-Volume 1. Breckenridge, CO, U.S.A., 87-92. <https://doi.org/10.1109/ACVMOT.2005.9>.