

다중 퍼셉트론을 이용한 유해물질 유입에 따른 송사리의 행동 반응 분석 및 인식

김철기[†] · 김광백^{††} · 차의영^{†††}

요 약

본 논문에서는 자동 추적 시스템을 이용하여 반자연적인 조건에서 화학 약물의 아치사량 투여에 반응하는 수중 생물 중 하나인 물고기(송사리)의 행동을 관찰하였다. 결과의 분석을 위하여, 약물 투여 전의 대표적인 행동을 패턴 A로 정의하였으며, 약물 투여 후의 대표적인 행동을 패턴 B로 정의하였다. 실험 결과, 패턴 B가 약물 투여 후에 빈번하게 관찰되는 반면, 패턴 A는 약물 투여 전에 많이 관찰되었다. 또한, 물고기의 움직임 패턴을 자동으로 탐지하기 위하여 대표 패턴들을 인공신경망의 학습을 위하여 추출하였다. 독성 물질(다이아지논) 투여 후 패턴 B에 대한 평균 탐지율은 크게 증가하였으나, 패턴 A에 대한 탐지율은 크게 감소함을 볼 수 있었다. 본 논문에서는 지표종의 행동 모니터링을 통하여 환경에서 독성 물질의 존재를 탐지하는 방법으로 인공 신경망의 적용을 보여주고 있다.

Analysis and Recognition of Behavior of Medaka in Response to Toxic Chemical Inputs by using Multi-Layer Perceptron

Kim Cheol-Ki[†], Kim Kwang-Baek^{††} and Cha Eui-Young^{†††}

ABSTRACT

In this paper, we observe one of the aquatic insect, fish(Medaka)'s behavior which reacts to giving toxic chemicals until lethal conditions using automatic tracking system. For the result, we define the Pattern A is a normal movement of fish and Pattern B is after giving the chemicals. In order to detect the movement of fish automatically, these patterns are selected for the training data of the artificial neural networks. The average recognition rates of the pattern B are remarkably increased after inputs of toxic chemical(diazinon) while the Pattern A is decreased distinctively. This study demonstrates that artificial neural networks are useful method for detecting presence of toxicoid in environment as for an alternative of *in-situ* behavioral monitoring tool.

Key words: pattern recognition, neural network, environment monitoring

1. 서 론

현재 우리가 살고 있는 실세계는 많은 오염 물질에 노출되어 있는 상태이며 이러한 문제점들을 모르고 지나가는 경우가 허다하다. 각종 환경 오염 물질

이 인체에 미치는 영향을 알기 위하여 우선 이루어져야 할 연구는 현재 노출된 물질이 오염 물질인지 아닌지를 판가름할 수 있어야 하며, 또한 오염 물질로 결정되었을 경우 얼마나 치명적인 영향을 미치는 지의 여부 또한 중요한 문제라 할 수 있다. 근래에 들어 동물의 행동은 환경에 있어 독성 화학물질의 탐지를 위한 바이오 모니터링의 수단으로써 많은 관심을 받고 있다. 이러한 동물의 행동 반응은 다양한 화학 오염물질에 대하여 매우 민감하다고 그 동안의 연구를

접수일 : 2002년 9월 16일, 완료일 : 2003년 3월 25일

[†] 준희원, 밀양대학교 컴퓨터정보통신공학부 전임강사
^{††} 정희원, 신라대학교 컴퓨터정보공학부 부교수

^{†††} 종신희원, 부산대학교 정보컴퓨터공학부 교수

통하여 밝혀졌다. Dutta 등은 자신의 연구를 통하여 행동학적 생물 검정(behavioral bio-assay)이 다른 유형의 검사법보다 더욱 민감함을 검증하였다[1,2]. 그리고, 최근 들어 생물체에 있어 치사량에 가까운 독성 물질의 투여에 대한 연구가 다양한 생물군들에 대하여 빠르게 연구되고 있다. 그러나, 이러한 연구들은 대부분 반응 자체에 대해 초점을 맞추고 있으며, 언제 어떠한 형태로 관찰하고자하는 행동 반응이 이루어졌는가와 관련된 공간 및 시간 영역 상의 행동 반응 변화에 대한 수리적 분석과 관련된 연구가 이루어지지 않고 있다. 여기서 수리적 분석이란, 여러 가지 수학적, 통계적 방법을 통한 특징 추출 및 가버(Gabor) 변환이나 웨이블릿(Wavelet) 변환과 같은 시간 영역에서의 신호 분석 방법을 나타낸다.

생물체의 움직임 궤적에 대한 수리적 분석에 관하여 Alt와 Hoffman은 1989년에 상관도 함수를 등각류 동물들의 짹짓기 움직임 궤적을 모델링하는데 적용하였다[3]. 또한 Tourtellot 등은 바퀴벌레 행동에 있어서 움직임의 길이와 방향전환의 정의를 통하여 바퀴벌레의 귀소 본능을 분석하였다[4]. 최근 들어서는 생쥐에 대한 행동 분석을 위하여 통계적인 움직임 분석 방법과 동적인 분석 방법들이 고안되었다[5]. 이러한 수리적 방법들은 예를 들어, 상관계수 또는 프랙탈 차원 등과 같이 움직임 경로에 대한 데이터에 내재된 유사도들을 고려하여 분석이 이루어지게 된다. 그러나, 이러한 방법들에 의해 움직임의 수리적인 계산 방법들을 위한 매개 변수들이 획득되며, 본 논문에서는 이러한 매개 변수들에 기반하여 실험에 사용할 매개 변수들을 선택하였다. 본 논문에서는 환경 독성 물질에 노출된 국내 생물체들 중 송사리를 목표물로 하여 정상적인 상태와 오염물에 노출된 비정상적인 상태의 움직임을 카메라를 이용하여 추적하였다. 또한, 획득된 추적 좌표를 일종의 좌표 신호로 보고 몇 가지 매개 변수의 선택에 의한 수리적 분석 방법을 통하여 행동 패턴에 대한 특징값을 추출한다. 이렇게 추출된 특징값에 대하여 인공 신경망을 적용하여 학습을 거친 후 실제 관측 데이터가 입력되었을 때 오염 여부를 판단하는 방법을 제시함으로써, 수질 환경 모니터링 시스템의 설계를 위한 기반을 제공하고 있다.

본 논문의 구성을 살펴보면, 2장에서는 실험을 위하여 필요한 인공 신경망에 대한 간략한 이론을 살펴본 후 3장에서는 실험에서 사용한 행동 데이터들에

대하여 소개를 하고 있으며 4장에서는 유해 물질의 유입 전·후를 구분 짓기 위한 수리적 방법에 의한 특징값 추출 방법을 소개하고 있고, 5장과 6장에서는 실험 방법 및 결과와 결론을 내리고 있다.

2. 인공 신경망

일반적으로 인공 신경망은 컴퓨터 및 전자공학뿐만 아니라 다양한 응용 분야에서 복잡하고 비선형성을 띠고 있는 현상들을 해석하는데 폭넓게 사용되어 왔다[6,7]. 특히, 생태학 관련 분야에서 인공 신경망은 생물체의 그룹화, 변수들 사이의 복잡한 관계들의 유형화, 생물체 수의 예측법 개발 등과 관련하여 사용되어 왔다. 그러나, 그동안 생태학 분야에서는 생물체의 행동 유형 감시와 관련하여 신경망의 응용이 그다지 많이 이루어지지 않은 실정이다. 신경망의 여러 알고리즘들 중 역전파 퍼셉트론은 많은 연구자들이 패턴인식에 채택하는 방법인데, 사용하기 쉽다는 장점을 가지고 있다. 특히, 시간적 자료의 경우 공간적 양태로 변형할 수 있다. 기본 아이디어는 신경회로망의 입력층에 들어오는 시간적 자료의 연속을 동시에 나타내는 것이다. 그럼 1과 같이 오류 역전파 알고리즘에 의한 다중 퍼셉트론은 지도 학습의 일종으로 입력과 출력 쌍을 학습시키는데 사용된다[8]. 학습은 출력층에서의 실제 출력과 목표값 사이의 평균제곱오류를 최소화하는 방향으로 이루어진다. 즉, 입력층의 각 노드에 입력 패턴을 주면, 이 신호는 각 노드에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다[7,9]. 이 출력값과 기대값을 비교하여 차이를 줄여가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결 강도를 조정해 나간다. 이와 같이, 지도학습에서는 입력 및 원하는 출력 패턴이 네트워크에 제시된다. 네트워크는 입력층에

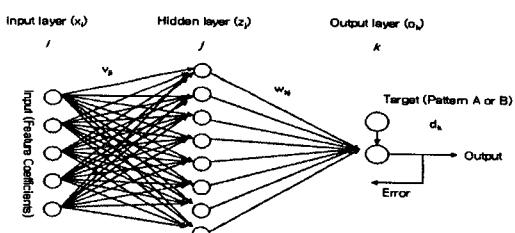


그림 1. 송사리의 움직임 궤적의 인식을 위한 다중 신경망

주어진 입력 패턴이 출력층에 전파되면서 변한 출력 패턴을 목표 패턴과 비교한다. 네트워크에서 출력된 패턴이 목표 패턴과 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우는 얻어진 출력 패턴과 목표 패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습을 한다.

본 논문에서는 움직임 케적을 특징화하는 매개변수들을 추출한 후 학습을 위한 입력 데이터로 주었으며, 최종 움직임 패턴의 결정은 이진 정보 형태로 하나의 출력 노드에서 생성하였다.

패턴 $p(NET_{p,i})$ 에 대한 은닉 층의 뉴런 j 의 입력은 각 입력층의 출력($x_{p,i}$: 매개변수의 입력 값)과 가중치($v_{p,j,i}$)의 곱들의 합에 의해 계산된다. 은닉층의 뉴런 j 의 출력($z_{p,j}$)과 출력층의 뉴런 k 의 출력($o_{p,k}$)을 계산하기 위하여 활성화 함수는 로지스틱-시그모이드(logistic-sigmoid) 함수를 사용하였다.

$$f(NET) = \frac{1}{1 + \exp(-\lambda NET)} \quad (1)$$

단, λ 는 활성화 함수 계수를 나타내며, NET 은 은닉층 또는 출력층의 뉴런의 출력의 계산을 위한 활성화 함수를 나타낸다.

$$z_{p,j} = f(\sum_i x_{p,i} v_{p,j,i}) \quad (2)$$

$$o_{p,k} = f(\sum_j z_{p,j} w_{p,kj}) \quad (3)$$

여기서, 패턴 p 에 대해 $v_{p,j,i}$ 는 입력층 뉴런 i 와 은닉층 뉴런 j 사이의 연결 가중치를 나타내며, $w_{p,kj}$ 는 은닉층 뉴런 j 와 출력층 뉴런 k 사이의 연결 가중치를 나타낸다.

일반적으로 오류역전파 알고리즘은 오류를 최소화하기 위한 방법으로 네트워크의 연결 강도들($v_{p,j,i}$, $w_{p,kj}$)을 변경한다. 패턴 p 에 대한 각 뉴런의 오류합(Err_p)은 식4와 같이 계산된다.

$$Err_p = \frac{1}{2} \sum_k (d_{p,k} - o_{p,k})^2 \quad (4)$$

여기서, $d_{p,k}$ 는 뉴런 k 에서 패턴 p 에 대응하는 목표값에 해당한다. 본 논문에서는 활성화 함수의 계수값 λ 에 1.0을 대입하였으며, 반복(iterative) 과정에서 가중치의 업데이트를 위하여 사용된 학습 계수를 0.01로 사용하였다. 또한, 오류 적용성(error tolerance)은 1.0으로 설정하였으며, 출력의 이진 레벨

을 결정하기 위한 임계치로 0.5를 사용하였다. 또한, 입력 노드는 5개로 구성하였으며 각각에 수리적 분석을 통하여 구한 특징 매개변수를 입력하였다. 은닉 노드는 모두 8로 구성하였으며, 출력노드는 패턴 A 또는 패턴 B를 결정짓기 위한 이진 상태이므로 1개를 할당하였다. 여기서, 패턴 A는 약물에 노출되기 전의 정상적인 패턴을 나타내며, 패턴 B는 약물에 노출된 후의 비정상적인 패턴을 나타낸다.

3. 패턴 추출 방법

본 논문에서 실험 데이터로 채택한 생물체인 송사리의 경우 독극물 투여 전 행동패턴은 전체 면에 걸쳐 자유롭게 움직이며 케적의 중간에 잦은 멈춤이나 짧은 거리의 방향 전환 또한 거의 없다는 전제 지식을 획득할 수 있었다. 그러나 독극물 중 다이아지논(Diazinon)¹⁾을 소량(0.1mg/l) 투여한 후 약 3시간 정도 흐른 후 움직임을 살펴보았더니 약물 투여전과 현격하게 다른 움직임을 보임을 알 수 있었다. 우선 본 논문에서 실험에 사용한 송사리는 25°C 상태에서 명기 10시간, 암기 14시간의 조건하에 어항 속에서 길러졌으며, CCD 카메라(Kukjae Electronics Co. Ltd. ; IVC-841®)에 의해 4일 동안(다이아지논 투여 전 2일, 투여 후 2일) 움직임 영상을 획득하였다. 송사리의 움직임 탐지를 위하여 CCD 카메라를 이용하여 영상을 획득한 후, 획득된 영상에서 차영상을 이용하여 생물체의 영역을 탐지한 후 이를 추적하여 움직임 좌표를 얻었다. 움직임 특성의 패턴은 약물 투여 전·후 송사리에서 모두 추출하였으며 신경망에서 학습을 위한 케적의 패턴을 특징화하는데 1분 단위로 움직임 케적을 분리하여 연속적으로 투여하였다. 또한 모델링의 단순화를 위하여, 약물 투여 전·후의 각각의 형태로부터 공통적으로 가장 많이 발생하는 패턴을 선택하여 학습을 위한 특징 데이터로 입력하였다. 그림 2는 학습을 위해 사용된 움직임 패턴의 유형을 나타내고 있다. 약물에 노출되지 않은 송사리의 경우 일반적으로 그림 2(a)와 같이 어항의 넓은 면적을 유영하며 움직이는 것을 자주 볼 수 있었으며, 움직임 케적은 끊기는 점이 명확하게 구분할 수

1) 1952년 스위스의 가이기사(社)에서 개발한 유기인제 살충제로서 파라티온보다 살충력이 약하고, 접촉제 또는 음독제로 사용한다.

없을 정도로 매우 선형적인 형태로 부드럽게 움직임을 알 수 있었다. 실험 결과 분석을 위한 패턴 식별의 용이성을 위하여, 본 논문에서는 이러한 형태의 움직임 궤적을 패턴 A로 정의하였다. 이와는 반대로, 다이아지논 ($0.1mg/l$)를 어항에 투여한 후 송사리의 움직임을 관찰하면 일반적으로 약물을 투여 전보다 훨씬 비활동적이며, 비정규적으로 앞뒤로 반복하여 움직이는 형태가 자주 나타남을 볼 수 있었으며, 수직 방향으로 움직이는 모습이 자주 나타났다(그림 2(b)). 본 논문에서는 이러한 유형의 패턴을 패턴 A와 대조되는 패턴으로 패턴 B로 정의하였다.

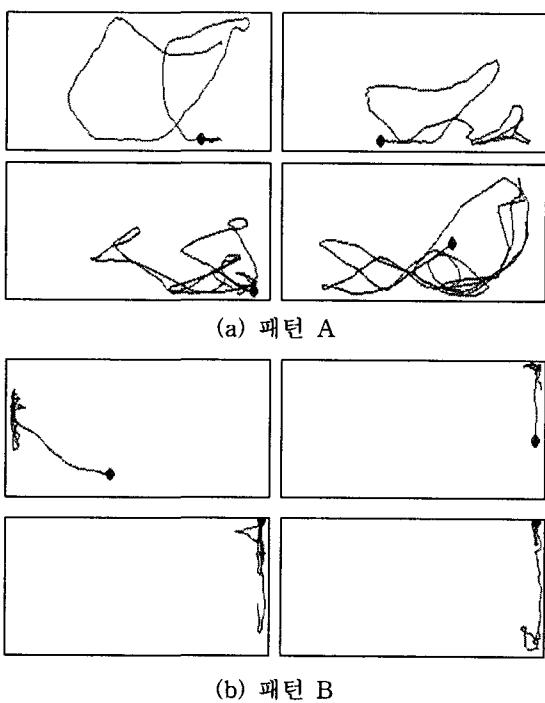


그림 2. 패턴 A, B의 대표적인 궤적들

4. 특징 매개변수 추출

본 논문에서는 송사리의 행동에 대해 1분 단위로 표 1과 같은 특징 매개변수들을 인공 신경망의 학습을 위한 입력 값으로 선택하였다. 표 1의 5가지 특징 중 두 번째 특징 값으로 선택한 역 방향 정도의 계산을 위하여 본 논문에서는 $160\sim180^\circ$ 사이의 각 변화를 사용하였다. 여기서 정확히 180° 를 사용하지 않은 이유는 역 방향 각도를 구하기 위해서는 세 개의 좌표 점이 필요한데 180° 의 경우 일직선 상에 세 점이

표 1. 특징 매개변수

특징 매개변수	단위
움직임 속도(speed)	mm/sec
역 방향 움직임 횟수(degree of backward movements)	sec
정지 주기(stop duration)	mm
꼬불꼬불한 움직임(total abstract angle changes divided by the total path length : meander)	radian/mm
수직 방향에 대한 최대 움직임 거리(maximum distance in y-axis)	mm

존재하므로 역 방향과 정방향을 구분하기 힘들기 때문에 $160\sim180^\circ$ 사이의 값을 사용하였다. 또한 3번 째 특징인 정지 주기의 계산 시 필요한 정지 시간의 계산은 샘플링 시간(0.25초)동안 생물체의 몸체 길이(3cm)보다 작은 거리를 정지하여 있는 시간으로 정의하였다.

입력 장치를 통하여 추적된 생물체의 움직임 데이터는 적개는 초당 2~3개의 움직임 좌표점에서 많게는 10여 개의 점으로 나타낼 수 있다. 본 논문에서는 이러한 점들을 표현하기 위하여 1초에 20프레임을 획득하여 사용하였으며, 움직임 데이터를 분석하였다. 본 논문에서 사용된 생물체의 움직임 궤적은 24시간 동안 관찰을 통하여 추적된 결과를 일정한 시간 윈도우 크기(60초)로 다시 분할하여 60초의 짧은 궤적을 분석하여 특징 매개변수를 추출하여 학습을 거친 후 최종 패턴 탐지를 위하여 사용하였다. 총 움직임 길이는 각 윈도우마다 움직인 거리의 합으로 계산되어지며, 방향 전환은 연속된 세 좌표 사이의 각도의 변화로 구하여 진다. 또한 본 논문에서 사용된 생물체의 성별 구별은 암놈과 수놈을 구별 없이 사용하였다.

4.1 움직임 속도(speed)

움직임 특성 분석에 있어서 가장 기본적으로 분석되는 항목 중 하나가 관찰 대상이 얼마나 빠른 속도로 움직이고 있느냐를 찾는 것이다. 약물을 투여했을 때 나타날 수 있는 반응으로 움직임이 급격히 빨라지거나 혹은 급격히 느려지는 현상들이 발생할 수 있다. 따라서, 이러한 현상들을 탐지하기 위하여 움직임 속도의 분석은 매우 중요하다 할 수 있다. 움직임 속도는 한 윈도우의 크기인 1분당 움직인 거리를 계

산하여 구하였다.

4.2 역 방향 움직임 정도(degree of backward movement)

움직이고 있던 방향에서 반대방향, 즉 180° 만큼 움직임 방향을 회전을 하여 다시 움직이는 횟수를 나타낸다. 갑작스런 역 방향 움직임의 측정은 움직임 특징의 분석에 있어서 매우 중요한 변수라 할 수 있다. 아래의 식 5는 각도의 변화를 계산하고 있다. 일반적으로 움직임에서 정확하게 180° 만큼 방향을 전환하는 경우는 불가능하다 할 수 있다. 따라서, 본 논문에서는 아래의 수식에 의해 나온 값이 $160^\circ \sim 180^\circ$ 정도 나왔을 경우(즉, $\pi - 20 \times \frac{\pi}{180}$ 보다 클 경우) 역 방향으로 간주하였다.

$$\left| \tan^{-1}\left(\frac{y_{k+1}-y_k}{x_{k+1}-x_k}\right) - \tan^{-1}\left(\frac{y_{k+2}-y_{k+1}}{x_{k+2}-x_{k+1}}\right) \right| \quad (5)$$

(단, x_k, y_k 는 각각 x 좌표와 y 좌표값을 나타내며, $k=0, \dots, N-1$, N 는 움직인 횟수를 나타냄)

4.3 정지 주기(stop duration)

송사리의 움직임 궤적에서 움직이지 않고 정지하여 있는 시간을 나타낸다. 이러한 정지 주기의 경우 일반적으로 약물 투여 전보다 약물 투여 후에 더욱 커지는 특징이 있다. 즉, 다이아지논의 투여 후 생물체의 신경계에 이상을 주어 움직임이 자유로이 이루어지지 않으므로, 정지 주기가 길어진다. 따라서, 이러한 특성을 이용하여 약물 투여 후의 패턴을 탐지하는데 사용할 수 있다.

4.4 꼬불꼬불한 움직임(Meander)

일반적으로 meander는 움직임의 궤적 중에서 꼬불꼬불하게 움직인 모양을 나타낸다. 즉, 주어진 단위 거리 당 얼마나 방향을 바꾸었는가와 관련이 있다 할 수 있다[10]. Meander의 경우 초당 움직인 거리와 초당 방향 전환의 횟수와 관련이 있다. 즉, 생물체의 행동을 분석할 때 테스트 생물체의 알려진 움직임 특성과 비교하여 주어진 시간동안 얼마나 많은 에너지를 소비하여 움직일 수 있는가와 비선형적인 움직임이 얼마나 많이 존재하는가를 분석하여 본다면 현재 생물체의 상태를 분석할 수 있을 것이다. 이를 수식

으로 나타내면 식 6과 같으며. 그림 3은 x 좌표와 y 좌표 점을 이용한 각도 계산 방법을 나타내고 있다.

Meander =

$$\sum_{k=1}^{N-2} \left| \tan^{-1}\left(\frac{y_{k+1}-y_k}{x_{k+1}-x_k}\right) - \tan^{-1}\left(\frac{y_{k+2}-y_{k+1}}{x_{k+2}-x_{k+1}}\right) \right| \sqrt{\sum_{k=1}^{N-3} ((x_{k+1}-x_k)^2 + (y_{k+1}-y_k)^2)} \quad (6)$$

(단, x_k, y_k 는 각각 x 좌표와 y 좌표값을 나타냄)

4.5 Y-축을 기준으로 한 최대 움직임 거리(maximum distance in Y-axis)

움직임 특성을 분석하기 위한 한 가지 방법으로써 X축을 제외하고 Y축을 기준으로 한 움직임 거리 중 최대 움직임 거리 값을 이상 움직임의 패턴들 중 하나로 추출하였다. 이는 깔파구 움직임 분석 결과 X좌표의 움직임보다 Y좌표의 움직임에 대하여 특징이 많이 나타남을 볼 수 있었음에 기인하였다.

$$\text{Max distance} = \text{Maximum}(y_{i+1} - y_i), \quad \text{단, } i=0, \dots, N-1 \text{ 이며, } y_i \text{ 는 } y \text{ 좌표를 나타냄} \quad (7)$$

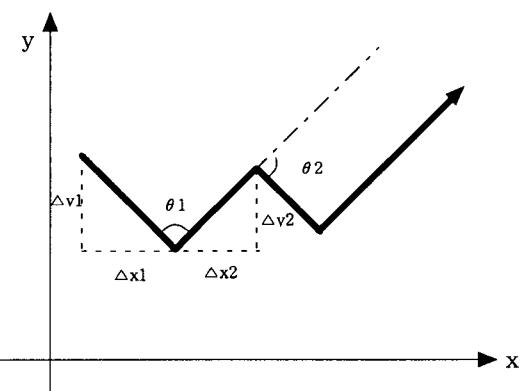


그림 3. 움직임 각도의 계산

5. 실험 방법 및 결과

본 논문은 IBM 호환 기종의 펜티엄 PC 상에서 Matlab 6.1 및 Visual C++ 6.0으로 구현하였으며, 15마리의 송사리 개체에 대하여 실험을 수행하였다. 즉 초기 관찰에서 15마리의 개체를 관찰한 후, 유사한 움직임 패턴을 갖는 9마리의 송사리를 선택하였다.

그리고 이러한 개체들 사이에서 다시 인공 신경망을 통한 학습을 수행하기 위하여 4마리의 개체를 선택하였고, 나머지 5마리의 개체에 대하여 테스트를 수행하였다. 실험을 위하여 1분 주기로 모두 16번의 관측을 통하여 패턴 A와 B를 추출하였으며, 4절에서 언급한 5개의 매개변수를 학습을 위하여 인공 신경망의 입력으로 사용하였다. 아래의 그림 4는 본 논문에서 제안하는 방법의 흐름도를 나타내고 있다. 그림에서 보듯이, 학습 데이터 또는 테스트 데이터가 입력되었을 때, 5가지 특징 매개변수를 추출하여 인공 신경망의 학습을 위한 입력 값으로 사용하였다. 학습이 이루어진 후, 테스트 데이터에 대하여 오염 여부를 판단하기 위한 최종적인 인식 단계를 거친 후 패턴 A 또는 B에 대한 판단을 하게 된다.

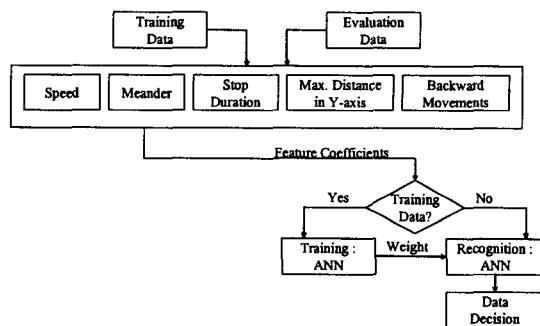


그림 4. 인공 신경망을 통한 인식 과정

표 2. 다이아지논 투여 전·후 패턴 A와 B에 대한 탐지율(%) 비교

			샘플 개수	개체 D		개체 F		개체 G		개체 I		개체 O	
투여 전	명기	평균(%)		42.44	33.94	54.89	17.56	55.17	4.78	49.76	8.53	52.06	2.67
		표준편차	(20)	27.74	23.39	28.29	18.03	24.76	4.67	20.33	7.18	29.83	3.53
	암기	평균(%)	(28)	46.93	4.55	58.04	5.69	27.25	2.39	52.66	3.10	28.40	9.60
		표준편차		27.42	3.69	22.46	4.74	21.75	2.99	16.53	2.27	24.09	10.03
	명기+암기	평균(%)	(4)	44.69	19.25	56.46	11.62	41.21	3.59	51.21	5.82	40.23	6.13
		표준편차		3.17	20.78	2.23	8.39	19.74	1.69	2.04	3.84	16.73	4.90
	명기	평균(%)	(20)	13.25	49.88	26.75	36.63	37.81	4.31	31.50	14.00	26.47	9.33
		표준편차		7.15	10.44	16.08	16.55	18.72	5.44	24.60	18.75	22.48	10.10
	암기	평균(%)	(28)	11.03	39.78	42.69	7.03	9.53	1.44	20.86	11.14	25.29	35.42
		표준편차		4.69	24.22	18.97	4.27	12.60	2.55	18.29	12.76	20.16	26.20
	명기+암기	평균(%)	(4)	12.14	44.83	34.72	21.83	23.67	2.88	26.18	12.57	25.88	22.38
		표준편차		1.57	7.14	11.27	20.93	20.00	2.03	7.53	2.02	0.83	18.45
전체	명기	평균(%)	(8)	27.85	41.91	40.82	27.09	46.49	4.55	40.63	11.26	39.26	6.00
		표준편차		20.64	11.26	19.90	13.48	12.27	0.33	12.92	3.87	18.09	4.71
	암기	평균(%)	(8)	28.98	22.17	50.36	6.36	18.39	1.92	36.76	7.12	26.85	22.51
		표준편차		25.38	24.91	10.85	0.95	12.53	0.68	22.48	5.68	2.20	18.26
	명기+암기	평균(%)	(16)	28.22	32.36	44.94	16.64	32.28	3.24	39.51	7.95	30.17	13.13
		표준편차		21.84	22.06	18.75	14.32	19.48	1.89	19.75	6.65	19.53	15.47

실험 결과 테스트를 위하여 5개의 송사리 움직임 패턴을 인공 신경망에 입력하였을 때, 패턴 A와 B가 효과적으로 인식됨을 알 수 있었다. 표 2는 약물 투여 전 후 명기와 암기에서의 패턴 A와 B에 대한 평균 탐지 비율(%)를 나타내고 있으며, 각 값들은 다음과 같은 과정을 통하여 얻어졌다. 패턴 A와 B의 탐지 수는 약 50분(3030초)의 주기를 통하여 카운팅 되었으며, 50분의 주기는 다시 1분 단위의 원도우들로 구성되어 있다. 그리고, 원도우간의 단절 효과를 없애기 위하여, 각 원도우간에 30초의 중복 시간을 두었다. 인식 결과의 통계적 분석의 용이성을 위하여, 3030초 단위에서의 인식 데이터는 또다시 각각 투여 전·후 2일씩 명기와 암기 상태로 그룹지었다. 각각의 송사리 개체에 있어서 명기와 암기에 대한 인식 결과의 평균과 표준편차는 표 2와 같다. 표 2에서 보듯이 패턴 A와 패턴 B는 약물 투여 전·후에 있어서 모두 나타나는 특징이다. 그러나, 약물 투여 전후의 패턴 A와 B의 발생 빈도 수는 현격한 대조를 이루고 있음을 볼 수 있다. 통계적 분석은 2-way ANOVA 테스트를 통하여 이루어졌으며, 패턴 A($df=1, 36$, $F=16.740$, $p<0.001$)와 패턴 B($df=1, 36$, $F=5.619$, $0.01<p<0.05$)가 약물 투여 전·후에 현격하게 차이가 있음을 볼 수 있다. 다이아지논 투여 후의 탐지율의 변화는 패턴 A에 있어서 더 확연하게 나타나고 있다. 그러나, 명기와 암기 사이에 있어서 탐지율의

변화는 패턴 A($df=(1, 36)$, $F=3.084$, $0.1 < p < 0.2$)와 패턴 B($df=(1, 36)$, $F=2.114$, $0.2 < p < 0.5$)에 있어서 크게 차이가 없음을 알 수 있다. 또한 빛과 약물 투여와의 상호 관계가 패턴 A($df=(4, 36)$, $F=0.050$, $p > 0.5$)와 패턴 B($df=(4, 36)$, $F=0.058$, $p > 0.5$)와 같이 미약하다 할 수 있다. 따라서, 명기와 암기 구분 없이 분석을 하여 보면, 전체 관찰 시간의 패턴 A의 경우 28~45%의 분포를 이루는 반면, 패턴 B의 경우 3~32%의 분포를 나타내고 있다(표 2). 특히, 패턴 B에 있어서 개체간 변이가 크다고 볼 수 있다. 개체 D, F, 그리고 O에 대하여 패턴 A와 B는 약물 투여 전·후에서 명확하게 관찰되었다(표 2). 그러나, 개체 G와 I의 경우 단지 패턴 A만 약물 투여 후에 더 명확하게 변화가 나타났다. 특히, 개체 G의 경우 패턴 B가 다이아지논 투여 후에 작은 감소를 보임을 알 수 있다.

위에서 언급한 것처럼, ANOVA 테스트를 통하여 명기와 암기 사이에 있어서 탐지율의 차이가 현저하지 않음에도 불구하고, 약물 투여 전·후에 있어서 각 패턴에 대한 일정한 주기 효과를 탐지할 수 있었다(표 3). 그림 5(a-b)는 전체 관찰 주기 동안 50분 단위에서의 움직임 패턴의 연속된 변화율에 대한 탐지 결과의 한 예를 보여주고 있다. 초기에 패턴 A의 비율이 높았으나(그림 5(a)), 다이아지논 투여 후 급격히 감소함을 볼 수 있다(그림 5(b)). 패턴 B의 경우는 패턴 A의 경우와 반대로, 초기에 적은 비율을 나타내고 있었으나 다이아지논 투여 후 급격히 증가함을 볼 수 있다.

그림 6은 꼬불꼬불한 움직임(meander)에 대한 인식 결과를 나타내고 있다. 그림 6(a)와 같이 다이아지논 투여 전에 데이터의 대부분이 패턴 A로 인식되었으며, 투여 후 초기단계에 패턴 B가 조금씩 증가하는 것을 볼 수 있다(그림 6(b)). 그리고, 다이아지논 투여 후 반부로 갈수록 패턴 B의 빈도수가 급격히 증가하는 것을 볼 수 있다(그림 6(c)).

표 3. 명기와 암기 사이의 패턴 A와 B에 대한 paired T-test

패턴	투여 시간	명기		암기		t value	p
		Mean (%)	SD	Mean (%)	SD		
패턴 A	투여 전	50.88	13.30	39.44	22.24	0.217	0.24
	투여 후	27.32	15.86	20.53	15.21	0.198	0.36
패턴 B	투여 전	13.48	13.71	3.89	1.55	0.545	0.04
	투여 후	22.84	16.42	18.01	14.87	0.131	0.49

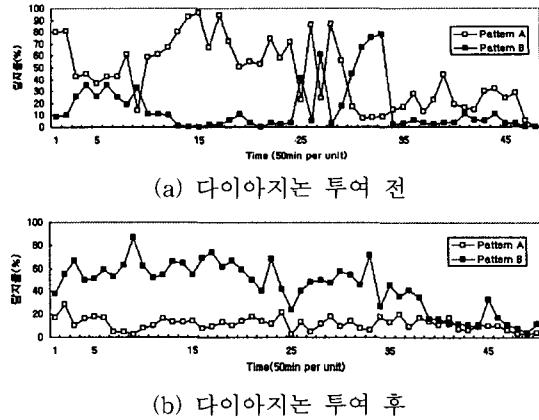


그림 5. 다이아지논 투여 전·후의 탐지율 변화

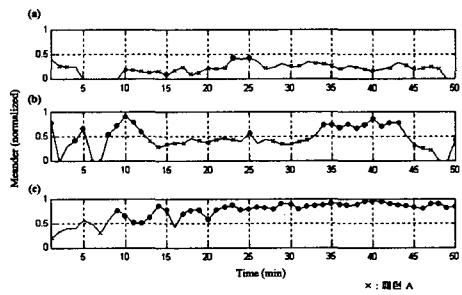


그림 6. 다이아지논 투여 전·후의 패턴 빈도 변화 비교

4. 결론 및 향후 연구 방향

본 논문에서는 독성 물질에 반응하는 생물체의 행동 차이를 인공 신경망의 적용을 통하여 성공적으로 탐지함으로써 환경의 오염 상태, 특히 수질의 오염 상태를 분석하는 방법을 제시하였다. 실험을 위하여 지표 생물종 중 하나인 송사리(medaka)를 사용하여 오염 여부에 대한 실험을 하였다. 모든 실험은 반자연적인(semi-natural) 상태에서 진행되었으며, 다이아지논(diazinon) 투여 전·후 이틀씩 모두 4일에 걸쳐서 연속적으로 진행되었다. 본 논문에서는 송사리의 움직임 탐지를 위하여 CCD 카메라를 이용하여 영상을 획득한 후, 획득된 영상에서 차영상을 이용하여 생물체의 영역을 탐지한 후 이를 추적하여 움직임 좌표를 얻었다. 이렇게 획득된 좌표값에 기반하여 모두 5가지 수리적 성분을 매개변수로 추출하였으며, 이 값을 학습을 위한 인공 신경망의 입력 값으로 사용하였다. 학습을 위한 인공 신경망으로는 오류 역전파 알고리즘을 사용하였다. 실험 결과, 일반적으로

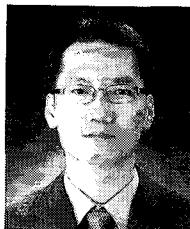
약물을 투여하지 않은 생물체의 움직임은 전반적으로 부드러운 궤적을 그리며 어항 속을 자유롭게 헤엄치는 패턴을 나타낸 반면, 약물을 투여한 후 움직임은 많이 날카로워졌으며 수직방향으로 움직이는 모양을 많이 나타내었다. 또한, 패턴 A와 패턴 B의 발생 빈도도 다이아지논 투여 전·후에 있어서 패턴 A의 경우 다이아지논 투여 전에 40%정도의 탐지율을 나타냈으나, 다이아지논 투여 후 15%정도로 줄어들었으며, 패턴 B의 경우 다이아지논 투여 전 10%정도의 탐지율을 보였으나, 다이아지논 투여 후 50%정도로 탐지율이 증가함과 같이 현격하게 차이가 나고 있음을 통계적인 테스트를 통하여 살펴보았다. 그리고, 명기와 암기 단계 사이의 각 패턴에 대한 인식 빈도의 차이는 발생하나 탐지율의 차이는 그다지 크지 않음을 알 수 있었다. 즉, 약물 투여와 조명과의 상호 관계는 오염도의 분석에서 그다지 큰 요인으로 되지 않음을 알 수 있었다. 향후 연구과제로는 움직임의 특징 추출에 있어서, 통계적인 방법(비선형 PCA)이나 인공신경망(SOM)과 같은 방법의 사용을 통하여 좀 특징 매개변수에 관한 또 다른 측면의 연구가 이루어질 수 있겠다.

참 고 문 헌

- [1] Lemly, A. D., Smith, R. J., A "behavioral assay for assessing effects of pollutants of fish chemoreception," *Ecotoxicology and Environmental Safety* 11(2), pp.210-218, 1986.
- [2] Dutta, H., Marcelino, J., Richmonds, Ch., "Brain acetylcholinesterase activity and optomotor behavior in bluegills, *Lepomis macrochirus* exposed to different concentrations of diazinon," *Arch Intern. Physiol. Biochim. Biophys.*, 100(5), pp.331-334, 1992.
- [3] Alt, W., Hoffman, G., "Biological Motion", Lecture notes in Biomathematics. Springer-Verlag, Berlin, 1989.
- [4] Tourtellot, M.K., Collins, R.D., Bell, W.J., "The

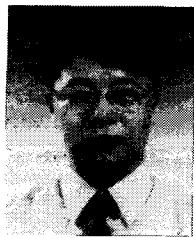
problem of movelength and turn definition in analysis of orientation data," *Journal of Theoretical Biology* 150, pp.287-297, 1991.

- [5] Tchernichovski, O., Benjamini, Y., "The dynamics of long-term exploration in the rat Part II. An analytical model of the kinematic structure of rat exploratory behavior," *Biological Cybernetics* 78, pp.433-440, 1998.
- [6] Lippmann, R.P., "An Introduction to Computing with Neural Nets," *IEEE ASSP Magazine*, pp.4-22, April. 1987.
- [7] Zurada, J. M, *Introduction to Artificial Neural Systems*, West Publishing Company, New York, 1992.
- [8] Rumelhart, D.E., Hinton, G.E., Williams, R.J., "Learning internal representations by error propagation, in Parallel distributed processing: explorations in the microstructure of cognition," In: Rumelhart, D.E., McClelland, J.L. (Eds.), MIT Press, Cambridge MA. pp.318-362, 1986.
- [9] Michael Chester, *Neural Networks : A Tutorial*, PTR Prentice Hall, 1993.
- [10] R. D. Collins, R. N. Gargesh, A. D. Maltby, R. J. Roggero, M. K. Tourtellot and W. J. Bell, "Innate control of local search behaviour in the house fly, *Musca domestica*," *Journal of Physiological Entomology*, vol. 19, pp.165-172, 1994.



김 철 기

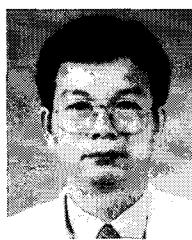
1999년 2월 부산대학교 전자계산
학과 졸업
2001년 2월 부산대학교 전자계산
학과(이학석사)
2003년 2월 부산대학교 전자계산
학과(이학박사)
2003년 3월~현재 밀양대학교 컴
퓨터정보통신공학부 전임강사
관심 분야: 영상처리, 컴퓨터비전, 신경회로망, 신호처리, Bioinformatics, 웨이블릿



김 광 백

1993년 2월 부산대학교 전자계
산학과(이학석사)
1999년 2월 부산대학교 전자계
산학과(이학박사)
1996년 3월 ~ 1997년 3월 동의공
업대학사무자동화과
전임강사

1997년 2월 ~ 현재 신라대학교 컴퓨터 정보공학부 부교수
관심 분야: 영상처리, 신경회로망, 컴퓨터비전, 퍼지 시
스템, 생체신호처리



차 의 영

1979년 2월 경북대학교 전자공학
과 졸업
1982년 2월 서울대학교 계산통계
학과(이학석사)
1998년 8월 서울대학교 컴퓨터공
학과(공학박사)
1985년 3월 ~ 현재 부산대학교
정보 컴퓨터공학부 교수

관심 분야: 영상처리, 컴퓨터비전, 신경회로망, 웨이블릿

교신저자

김 철 기 627-702 경상남도 밀양시 내이동 밀양대학교
컴퓨터정보통신 공학부 컴퓨터공학전공