

# 로봇 운동솜씨의 작업 복잡도

## Task Complexity of Movement Skills for Robots

권 우 영<sup>1</sup>, 서 일 홍<sup>†</sup>, 이 준 구<sup>1</sup>, 유 범 재<sup>2</sup>, 오 상 록<sup>2</sup>

Woo Young Kwon<sup>1</sup>, Il Hong Suh<sup>†</sup>, Jungoo Lee<sup>1</sup>, Bum-Jae You<sup>2</sup>, Sang-Rok Oh<sup>2</sup>

**Abstract** Measuring task complexity of movement skill is an important factor to evaluate a difficulty of learning and/or imitating a task for autonomous robots. Although many complexity-measures are proposed in research areas such as neuroscience, physics, computer science, and biology, there have been little attention on the robotic tasks. To cope with measuring complexity of robotic task, we propose an information-theoretic measure for task complexity of movement skills. By modeling proprioceptive as well as exteroceptive sensor data as multivariate Gaussian distribution, movements of a task can be modeled as probabilistic model. Additionally, complexity of temporal variations is modeled by sampling in time and modeling as individual random variables. To evaluate our proposed complexity measure, several experiments are performed on the real robotic movement tasks.

**Keywords:** Complexity, Task Complexity, Movement Skills, Neural Complexity

### 1. 서론

자율로봇에게 원하는 작업을 수행하도록 하기 위해서는 해당 작업을 사람이 프로그래밍 해주거나, 다른 대상의 작업을 모방하거나, 스스로 학습하여야 한다. 로봇이 수행할 작업이 단순하다면 사람이 로봇에게 직접 작업을 알려주는 것이 가능하지만, 복잡한 작업의 경우에는 모든 경우에 대해 로봇에게 프로그래밍 해주는 것이 현실적으로 어렵기 때문에 다른 대상을 모방하거나 스스로 학습하는 방법이 요구된다. 그러나 복잡한 작업은 학습이나 모방을 어렵게 만드는 근본적인 원인이며 작업수행의 성공 가능성을 낮추는 주요 요인이 된다<sup>[1]</sup>. 따라서 복잡한 작업을 학습하는데 있어서는 많은 데이터, 사전지식, 또는 연산과정 등의 추가적인 정보 또는 계산을 요구한다. 위와 같은 추가적인 정보

또는 계산과정에 필요한 데이터의 양이나 모델을 선택하고, 사전지식을 얼마나 사용할지를 결정하는 것은 학습 및 모방에 필요한 작업의 복잡도에 따라서 달라진다. 따라서 작업의 복잡도를 정량적으로 측정하는 것은 학습 및 모방에 있어서 매우 중요한 기준이 된다.

인간과 관련된 작업의 복잡도를 측정하기 위한 방법은 언어나 행동을 통한 상호작용을 모델링 하는데 있어서 활발하게 연구되어 왔다<sup>[2-6]</sup>. 그러나 복잡도를 이용하여 로봇의 작업을 정량적으로 측정하고자 하는 방법에 대한 연구는 상대적으로 부족한 편이다.

복잡도(complexity)는 일상적으로 많이 사용되지만 적용되는 분야나 사용하는 사람에 따라 조금씩 다른 의미를 갖는다. 그럼에도 불구하고 일반적으로 널리 통용되는 정의는 다음과 같다. 복잡한 시스템은 단순하지 않은 방법으로 상호작용하는 많은 개수의 부분들로 구성되어 있으며, 이런 복잡한 시스템에서 전체는 부분들의 합으로 표현된다. 또한 복잡도는 유의미하고 반복되지 않는 요소들로 구성된 질서와 무질서 또는 규칙성과 임의성의 조합으로 표현된다<sup>[7]</sup>. 시각적인 장면의 예를 들어 위의 복잡도 정의를 설명하자면, Fig 1(a)은 규칙적인 도형으로 구성된 장면인데, 이런 장면은 너무 규칙적이어서 복잡하지 않다고 여겨진다. 반대로 Fig

Received : May 1, 2012; Reviewed : Jun. 13, 2012; Accepted : Jul. 12, 2012

※ This work was supported by the Global Frontier R&D Program on "Human-centered Interaction for Coexistence" funded by the National Research Foundation of Korea grant funded by the Korean Government(MEST) (NRFMIAXA003-2011-0028353)

<sup>†</sup> Corresponding author: Department of Electronics and Computer Engineering, Hanyang University, Korea (ihuh@hanyang.ac.kr)

<sup>1</sup> Department of Electronics and Computer Engineering, Hanyang University, Korea ({wykwon, jungoolee}@hanyang.ac.kr, )

<sup>2</sup> Korea Institute of Science and Technology, Seoul, Korea ({ybj, sroh}@kist.re.kr)




Fig. 1. Scenes having different complexities

1(b)과 같이 노이즈가 많은 장면은 너무 불규칙하여 이 장면을 기술하기 위한 규칙자체가 거의 없기 때문에 또한 복잡하지 않다고 여겨진다.

마지막으로 Fig 1(c)와 같은 장면은 질서와 무질서가 적절히 혼합되어 있으며 내부 구성 요소들 간의 연결이 단순하지 않게 구성되어 있다. 이러한 장면을 일반적으로 복잡도가 높다고 할 수 있다. 따라서 복잡도의 측정방법은 너무 규칙적이지도 않으면서 너무 무질서하지도 않은 상태를 찾을 수 있어야 한다. 다르게 표현하자면 측정 대상 내부에 얼마나 많은 유용한 정보가 표현되어 있는지 여부가 복잡도에 큰 영향을 준다고 할 수 있다.

부품 엔트로피(part entropy)<sup>[8-10]</sup> 라고 불리는 측정 방법은 작업에 필요한 부품들의 형상을 이용해 작업을 정량적으로 측정하는 접근 방법이다. 보다 상세하게는 부품들이 안정적인 상태를 유지할 확률을 엔트로피로 정량화하여 작업환경의 복잡도를 측정할 수 있도록 하고 있다. 이 방법은 복잡도의 계산이 비교적 용이하지만 간접적인 측정방법이기 때문에 동일한 대상을 가지고 복잡한 궤적을 필요로 하는 작업의 복잡도를 제대로 표현해 내기 어렵다는 단점이 있다.

직접적으로 대상의 복잡도를 정량적으로 측정하는 방법은 다양한 분야에서 이루어져 왔다. 콜모고로프(Kolmogorov) 복잡도<sup>[11]</sup>는 컴퓨터 과학(computer science) 분야에서 널리 사용되는 측정방법으로서 어떤 대상을 기술하기 위한 가장 작은 길이의 프로그램 또는 수열의 길이로서 복잡도를 측정한다. 콜모고로프 복잡도를 이용해 작업의 복잡도를 측정하기 위해서는 작업을 기술하는 최적의 프로그램을 작성한 후에 그 프로그램의 전체 길이를 측정하면 된다. 하지만 로봇이 수행할 작업의 최적 프로그램을 구하는 것 자체가 현실적으로 불가능하기 때문에 이론적으로만 사용가능한 방법이 된다. 또한 작업을 구성하는 요소들의 무질서도가 높을수록 복잡도가 높게 측정되는 특징을 보이기 때문에 앞서 정의한 복잡도의 정의와 맞지 않는 부분

이 있다.

시스템의 복잡도를 측정하기 위한 잘 알려진 방법 중 하나는 통계적 복잡도(statistical complexity) 또는 LMC 복잡도라고 불리는 측정방법이다<sup>[12]</sup>. 통계적 복잡도는 무질서와 질서의 척도를 수학적으로 정의하여 이 둘을 혼합하여 시스템의 복잡도를 정량적으로 표현하였다. 보다 상세하게는 무질서의 척도를 정보이론에서의 엔트로피를 사용하였으며, 질서의 척도로서 계의 평형상태로부터의 거리를 이용하였다. 이 두 가지 척도를 곱하면 질서와 무질서 중간에서 가장 높은 값을 갖는 평가지표를 얻을 수 있다. 이 방법은 물리적 실체를 갖는 시스템이나, 생물학적 대상의 복잡도를 측정하는 방법으로 널리 활용되고 있다. 하지만 작업의 복잡도를 측정하기 위해서는 어려움이 있다. 그 이유는 로봇의 작업에서 평형상태로부터의 거리를 정의하는 것이 어렵기 때문이다.

Tononi 등에 의해 제안된 신경 복잡도(neural complexity)<sup>[13-15]</sup>는 시스템을 구성하는 요소들 간의 지역적인 정보교환에 대한 평균치를 활용하여 대상의 복잡도를 측정하는 방법이다. 이 방법은 최초 인간의 뇌 활동의 복잡도를 측정하기 위해 제안되었으며, 다양한 분야에 널리 활용되고 있다. 로봇의 작업 수행 과정에서 로봇 내부요소들의 정보교환을 측정한다면 이는 신경 복잡도를 이용해 측정될 수 있으며 결국 작업 복잡도로 환산될 수 있다. 따라서 신경복잡도는 로봇의 작업 복잡도를 측정하는데 적합한 척도중의 하나가 될 수 있다. 하지만 신경 복잡도는 주로 긴 주기를 갖는 정적인 두뇌 활동을 측정하는데 적합한 방법으로서<sup>[16]</sup>, 짧은 기간 안에 변화가 많은 로봇의 작업을 측정하는데 직접적으로 사용하기에는 어려움이 있다. 본 논문에서는 로봇이 만들어내는 신호들 간의 정보교환뿐 아니라 신호의 시간적 변화에 따른 정보교환을 동시에 측정하는 방법에 의해 신경 복잡도를 측정하는 시분할 신경 복잡도(time-sliced neural complexity) 측정 방법 제안하고자 한다. 또한 제안한 방법을 이용하여 로봇 작업의 복잡도가 효과적으로 측정됨을 보이고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 신경복잡도에 대해 상세히 기술하며, 3장에서는 제안하는 시분할 신경 복잡도 측정방법과 이를 이용한 작업 복잡도 측정방법에 대해 소개한다. 4장에서는 실제 로봇 작업을 제안한 작업 복잡도 측정방법으로 측정된 실험

결과에 대해 소개하고 5장에서는 결론을 나타낼 것이다.

## 2. 신경 복잡도(Neural Complexity)

[13]에서 저자들은 주어진 시스템의 서브시스템간의 상호 정보량(mutual information)으로서 신경 복잡도를 소개하였다. 측정 대상이 되는 시스템의 시간에 따른 신호의 변화  $\mathbf{X}(t)$ 를 다변량 정적 확률과정(multivariate stationary stochastic process)으로 가정하고, 그 시스템  $\mathbf{X}$ 의 복잡도  $C_N(\mathbf{X})$ 를 아래와 같이 정의하였다.

$$C_N(\mathbf{X}) = \sum_{k=1}^{n/2} \langle MI(X_j^k; X - X_j^k) \rangle \quad (1)$$

여기서  $MI(X; Y)$ 는  $X$ 와  $Y$ 간의 상호 정보량이며  $X_j^k$ 는  $\mathbf{X}$ 의 서브시스템 중  $k$ 개의 원소를 갖는 서브시스템을 나타낸다.  $j$ 는 서브시스템을 나누는 여러 방법 중의 하나를 표현하며  $\langle \rangle$ 는 모든 서브시스템에 대한 앙상블 평균을 의미한다. 즉  $k$ 개의 원소를 갖는 임의의 서브시스템  $X_j^k$ 와 나머지와의 정보교환을 측정한 것이  $MI(X_j^k; X - X_j^k)$ 이 된다.

상호정보량은 시스템 내부의 정보교환을 나타내는 중요한 지표이기는 하지만, 많은 개수의 원소를 갖는 시스템의 결합 상호정보량(joint mutual information)을 구하는 것은 무척 많은 계산시간이 걸린다. 따라서 좀더 효과적인 계산 방법이 필요하다. 보다 효율적인 계산방법을 위한 기본적인 아이디어는 정보의 통합(integration)과 분할(seggregation)로서 시스템의 복잡도를 표현하는 것이다. 이 방법에서는 복잡한 시스템을 시스템 내부에서 교환되는 정보의 통합과 분할이 균형을 잡힌 상태로 표현된다고 하는 가정을 사용한다. 이를 위해 시스템 내부의 정보의 통합을 별도로 정의한다.

어떤 전체 시스템  $\mathbf{X}$ 에 대한 시스템의 통합  $I(\mathbf{X})$ 는 시스템의 모든 요소들을 독립이라고 가정했을 때, 각 요소들의 엔트로피의 총 합과 전체 시스템  $\mathbf{X}$ 의 결합 엔트로피와의 차이로서 정의된다. 수학적 표현은 아래와 같다.

$$I(\mathbf{X}) = \sum_{i=1}^n H(x_i) - H(\mathbf{X}) \quad (2)$$

여기서  $x_i$ 는 시스템을 구성하는 개별요소이며,  $n$ 은 시스템  $\mathbf{X}$ 안에 포함된 개별 요소들의 개수다.

만약 시스템의 요소들이 모두 독립이라면 시스템 전체에 대한 엔트로피가 결국 각각을 독립으로 가정했을 때의 엔트로피와 같아지기 때문에 그 값은 0이 된다. 이는 결국 시스템 내부의 정보교환이 없다는 것으로 해석될 수 있다. 반대로 통합 값이 커진다는 것은 각각의 요소가 다른 요소들에 의존적이라는 것으로서, 시스템 내부의 정보교환이 활발하다는 것을 의미한다.

신경 복잡도를 앞서 정의한 통합을 이용하여 다음과 같이 수학적으로 정의된다.

$$C_N(\mathbf{X}) = \sum_{k=1}^{n/2} \left[ \frac{k}{n} I(\mathbf{X}) - \langle I(X_j^k) \rangle \right] \quad (3)$$

$\langle I(X_j^k) \rangle$ 는  $k$ 개의 원소를 갖는 통합의 평균값이다.  $j$ 는 앙상블 평균을 할 때 사용되어 없어진다. 그리고  $(k/n)I(\mathbf{X})$ 는 전체 시스템의 정규화된 통합을 의미하며 서브시스템과의 비교를 위해  $k/n$ 으로 정규화되었다. 즉 모든 크기의 서브시스템 내부의 통합의 합이 복잡도가 된다. 식(3)과 식(1)은 수학적으로 동일하다는 사실이 [13]에 증명되어 있다. 실제 계산을 위해서는 시스템에 대한 모델링이 필요하며, [13]에서는  $\mathbf{X}(t)$ 를  $n$ 개의 차원을 갖는 다변량 가우시안(multivariate Gaussian) 확률분포로 모델링 하였다. 실제 엔트로피의 계산은  $\mathbf{X}(t)$ 분포의 공분산(covariance)을 이용하여 계산이 된다<sup>[17]</sup>.

신경 복잡도는 뇌파신호등의 다차원 신호로 구성된 시스템의 복잡도를 측정하기에 좋은 지표이지만, 로봇의 운동속씨에 관련된 작업 복잡도를 바로 측정하기에는 한 가지 문제가 있다. 측정하고자 하는 전체 시스템  $\mathbf{X}$ 를 다변량 정적 확률과정으로 가정했다는 점이 운동속씨의 측정에서 문제가 된다. 사실 신경 복잡도에서 측정되는 복잡도는 각 요소들 간의 상호 의존도에 따라서 변화하게 된다. 상호의존도가 큰 그룹과 작은 그룹과 적절히 분포되어 있을 때 가장 높은 복잡도를 갖도록 설계되어 있는 지표이다. 하지만 요소자체의 시간의 변화에 따른 복잡도는 별도로 측정하지 않는다.

그러나 로봇의 작업은 대부분 시간에 따른 변화가 심하고 복잡한 작업일수록 그 특징이 두드러진다. 무엇보다도 시간에 따른 변화가 복잡도 측정에 미치는 영

향이 증대하기 때문에 무시될 수 없다. 예를 들어 로봇 팔의 움직임으로 복잡도를 측정하고자 하는 경우를 본다면, 로봇 팔의 엔드 이펙터의 움직임은 3개의 위치좌표와 3개의 방향성분 좌표로 표현될 수 있다. 복잡한 움직임을 하는 동작의 경우 좌표축간의 상호연관성 뿐만 아니라 각 좌표의 시간적 변화도 매우 중요한 정보로서 활용될 수 있다. 하지만 다변량 정적 확률과정을 가정하고 있는 신경 복잡도에서는 시간에 따른 변화를 다변량 가우시안 분포로서 표현하기 때문에 공분산이라는 하나의 변수로서 단순화해서 표현된다. 따라서 하나의 좌표축 즉 신호가 내는 다양한 변화를 구분해내기가 어렵다는 문제가 있다. 이러한 문제점을 극복하려면 시간에 따른 신호의 변화를 적절히 복잡도 측정에 반영해야 한다.

### 3. 시분할 신경 복잡도(time-sliced neural complexity)에 의한 운동습씨의 복잡도 측정


#### 3.1 운동 습씨의 정보이론기반 표현

앞서 소개한 바와 같이 신경 복잡도는 기본적으로 측정대상을 다변량 확률과정으로 모델링하기 때문에, 요소 하나의 시간에 따른 다양한 변화를 복잡도로 표현하는 데에 어려움을 겪는다. 이 문제를 해결하기 위해서는 신호의 시간에 따른 변화를 다변량 확률과정에 명시적으로 표현할 필요가 있다. 기본적인 아이디어는 통계역학에서의 앙상블 평균(ensemble average)으로부터 출발한다. 앙상블은 관심이 가는 시스템과 동등한 시스템이 많이 모여 있는 집합이다. 이러한 앙상블의 특성을 기술할 때 사용되는 대표적인 지표는 시간 평균과 공간 평균이 있다. 시간 평균은 하나의 시스템을 시간에 대하여 평균을 낸 것이고, 공간 평균은 시스템의 시간에 따른 특성을 여러 시스템에 대해 평균을 낸 값이다. 신경 복잡도는 시스템을 기술할 때 시간 평균과 공간 평균을 모두 고려하여 복잡도를 계산하는 방법을 이용하였다. 하지만 로봇이 수행할 작업은 시간의 변화가 중요한 정보를 포함하는 경우가 많기 때문에 시간 평균을 고려하면 이 변화를 올바르게 표현하기 어렵다. 따라서 우리는 공간 평균만을 고려하여 다변량 가우시안 분포를 만드는 방법을 이용해 시간의 변화를 확률분포에 포함시키고자 한다.


먼저 운동습씨에 대한 표현을 위해 로봇 팔이 글씨

를 쓰는 운동습씨를 표현하는 예를 들도록 하겠다. 6 자유도를 갖기 때문에 모두 3개의 직교좌표성분과 3개의 방향성분, 총 6개의 신호가 정의된다. 하나의 습씨를 시연하게 되면 이 6종류의 신호는 시간에 따라 변하는 값을 갖게 될 것이며 이를 각각  $x^1(t), x^2(t), \dots, x^6(t)$ 로 표시하도록 한다. 이 신호는 통계학에서 말하는 표본함수(sample function)로 표현될 수 있다. 한 종류의 운동습씨에 대해 여러 번 관측을 수행하면 여러 개의 표본함수를 획득할 수 있다.  $i$ 번째 관측에서의 표본함수를  $x_i^1(t), x_i^2(t), \dots, x_i^6(t)$ 와 같이 표현하도록 하겠다. Fig 2(a)는 첫 번째 좌표축에 대한 10개의 표본함수들  $x_1^1(t), \dots, x_{10}^1(t)$ 들을 나타내고 있다.

한 종류의 표본함수에서 시간에 따른 신호의 연관관계를 보는 방법은 표본함수를 일정 시간간격으로 샘플링한 후 이를 이산 확률변수로 모델링하는 것이다. 예를 들어 첫 번째 좌표축의 표본함수를 1초 간격으로 샘플링한다면  $x_1^1(0), x_1^1(1), \dots, x_1^1(7)$  등 모두 8개의 데이



(a) 10 sample functions of a letter-writing skills.



(b) means and variances of discretized random variables with a 0.5 second time-step.

Fig. 2. An example of a movement trajectory by a robotic arm

터를 얻을 수 있다. 각 관측횟수  $i$ 의 데이터를 샘플링 시간별로 측정된 이산신호의 확률변수를 만들면 모두 8개의 확률 변수를 얻을 수 있다. 첫 번째 좌표축에 대한 8개의 확률변수는  $X^1(0), X^2(1), \dots, X^{10}(7)$ 와 같이 표시될 수 있다. 8개의 확률분포를 가우시안 분포로 모델링 했을 때 평균과 분산 값은 Fig 2(b)나타나 있다. 모두 6개의 좌표축이 있다면 총48개의 확률 변수가 존재하고 48차원의 다변량 가우시안 분포 모델링이 필요하게 된다.

### 3.2 PCA에 의한 차원축소

시간 축에 대한 샘플링을 하여 확률분포를 얻고 나면 시간에 대한 변화를 복잡도 측정의 입력으로 명확하게 모델링하는 것이 가능해진다. 하지만 이런 방법은 실질적으로 복잡도의 계산을 불가능하게 하는 두 가지 문제점을 내포하고 있다.

첫째는, 측정 대상이 되는 시스템의 요소의 개수 즉 확률 분포의 차원이 크게 늘어난다는 것이다. 차원의 증가는 공분산을 구하는 과정을 어렵게 만들뿐더러 식 (3)의 복잡도 계산 시 서브시스템을 나누는 과정에서 경우의 수가 지수적으로 늘어나게 된다. 샘플링 시간간격을 촘촘하게 한다면 계산이 불가능해지는 문제가 발생한다.

두 번째로, 시간에 대해 샘플링해서 확률분포를 만들어내는 방법을 이용하면 공분산을 계산할 때 행렬식 (determinant)이 0에 가깝게 되는 경우가 많이 발생하게 된다. 이 경우에 다변량 가우시안 분포로 모델링된 시스템의 상호 정보량의 계산이 수치적으로 매우 불안해지는 현상이 발생한다. 예를 들어 여러 번의 관측동안에 로봇 팔의  $z$ 축 좌표가 거의 변하지 않았다면, 시간에 대해 샘플링한 각각의 확률분포는 거의 동일하게 된다. 이럴 경우 모든 확률변수들의 상호연관을 나타내는 공분산 행렬은 행렬식이 0에 가까운 갖는 형태로 만들어지게 된다. 그렇다면 차원이 작더라도 복잡도의 계산이 불가능해진다. 이러한 문제점을 해결하는 방법은, 중복되는 패턴의 데이터가 없도록 다변량 확률과정의 차원을 줄이는 것이다. 확률과정의 차원을 줄이는 가장 효과적이고 잘 알려진 방법은 주성분 분석 (Principle Component Analysis: PCA) 방법이다<sup>[18]</sup>.  $m$ 개의 차원으로 이루어진 데이터  $x$ 가  $x = (x_1, \dots, x_m)$ 와 같이 정의될 때, 입력 데이터를  $n$ 개의 차원을 갖는 다

차원 데이터  $s = (s_1, \dots, s_n)$ 로 축소하는 변환식은 아래와 같다.

$$s = Ax \tag{4}$$

여기서  $A$ 는 차원 축소를 위한  $n \times m$  변환 행렬이며,  $n < m$ 의 관계를 갖는다.

다음으로는, 데이터가 갖는 정보의 왜곡을 최소화 하면서 차원을 축소하도록 하는 변환행렬  $A$ 를 찾는 것이 문제가 된다. 변환행렬은 데이터의 분산을 최대로 만드는 제1주성분을 먼저 구하고, 제1주성분과 상관관계가 없으면서 분산이 다음으로 큰 주성분들을 차례로 구하는 방법에 의해 얻어진다. 이는 데이터의 고유값 (eigenvalue)과 고유벡터(eigenvector)를 이용해 구할 수 있다.

데이터의 분산을 가장 크게 만드는 첫 번째 방향성분  $v_1$ 은 공분산의 정의를 이용해서 풀릴 수 있다. 공분산의 정의에 대해서  $v_1$ 을 변수로 둔 최적화 풀이를 수행하면

$$\Sigma v_1 = \lambda_1 v_1 \tag{5}$$

와 같이 표현된다. 여기서,  $\Sigma$ 는 데이터  $x$ 들을 여러 번 관측했을 때의 공분산을 나타내며,  $\lambda_1$ 는 스칼라 값으로서 데이터의 고유값이다. 또한  $v_1$ 은  $\lambda_1$ 에 대한 고유벡터(eigenvector)이다. 고유값의 크기 순서대로 고유벡터를 모두 구하면 변환행렬  $A$ 는  $A = [v_1, v_2, \dots, v_k]$ 와 같이 주어진다.  $k = m$ 일 경우에 변환행렬은 동일한 차원간의 변환을 수행하며  $k < m$ 일 경우 데이터의 차원을 감소시킨다.

데이터가 얼마나 왜곡되었는지를 측정하는 지표  $J$ 는 차원 축소과정 중에 생략된 고유값들의 합으로 다




Fig. 3. A schematic diagram of the complexity measure of movement skills

음과 같이 정의된다<sup>[19]</sup>.

$$J = \sum_{i=n+1}^m \lambda_i \quad (6)$$

여기서,  $i = 1, \dots, m$ 으로 표현되며 고유값들의 크기 순으로 정렬된 색인이다. 본 논문에서는  $J=0.01$ 로 왜곡이 1% 이하가 되도록 데이터의 차원을 축소하였다.

### 3.3 작업의 복잡도 계산

작업을 수행하기 위한 로봇의 운동습씨 데이터를 일정 시간간격으로 샘플링하고, 여러 번의 관측횟수에 따른 확률변수를 구한 후에, 차원을 줄이면 복잡도 계산을 위한 데이터의 가공이 완료되게 된다. 그 과정은 Fig 3의 개념도에 나타나 있다.  $K$ 개로 축소된 차원의 데이터  $s^1, s^2, \dots, s^K$ 를 이용해서 신경 복잡도를 구하기 위해 모든 데이터는 다변량 가우시안 분포로 모델링한 후 엔트로피를 구하였다. 다변량 가우시안 분포  $S$ 의 엔트로피는

$$H(S) = \frac{1}{2} \ln [(2\pi e)^N |\Sigma|] \quad (7)$$

와 같이 정의된다. 여기서  $N$ 은 데이터 차원의 개수이며,  $|\Sigma|$ 는 공분산 행렬의 행렬식이다. 시스템의 엔트로피가 측정되면 식 (2)와 (3)을 활용하여 작업의 복잡도를 계산할 수 있다.

Fig 4는 9개의 원소로 이루어진 시스템의 복잡도를 구하는 과정에서 서브시스템의 통합을 구하는 과정에 대한 예시를 설명한다. 이때 식(3)을 이용해서 서브시스템간의 통합을 이용하여 신경 복잡도를 구하는 과정이 적용되었다.

먼저 전체 시스템의 통합은 전체 시스템의 다변량 가우시안 분포를 식 (7)을 이용해서 엔트로피를 구한 후에 (2)의 식으로 계산한다. 식 (3)에 의하면  $k=2$ 부터 전체 시스템을 구성하는 총 원소 개수인  $k=9$ 가 될 때까지 서브시스템의 원소 개수를 증가시켜서 각각의 통합을 계산하게 된다. 서브시스템의 통합  $\langle I(X_j^k) \rangle$ 을 구할 때에는 데이터 원소의 개수에 따라서 상당히 많은 조합을 고려해야 한다. 예를 들어, 2개의 원소를 갖는 서브시스템의 경우,  ${}_9C_2$  만큼의 조합이 존재한다.  ${}_iC_j$ 는 총  $i$ 개의 원소로 이루어진 집합에서  $j$ 개의 원소를




Fig. 4. An example of bi-partitioning in complexity computation.

갖는 부분집합의 조합을 나타내는 기호이다. 예시처럼  ${}_9C_2$  정도는 실제로 계산이 가능하지만, 차원이 커지면 실제 계산이 불가능해진다. 이 경우 모든 조합에 대한 평균을 구하지 않고, 샘플링을 사용하여 통합 값을 추정한다.

$k=2$ 인 경우의 서브시스템의 통합에 대한 평균값  $\langle I(X_j^2) \rangle$ 을 구하고 정규화된 전체 시스템의 통합  $\langle I(X) \rangle$ 와의 차이를 구하면  $k=2$ 에 대한 계산이 완료된다. 이와 같은 과정을 모든  $k$ 에 대해 수행한 후 그 합을 하면 대상 시스템의 복잡도의 계산이 완료된다.

### 4. 실험 및 결과

제안한 시분할 작업 복잡도 측정지표의 유효성을 평가하기 위해서 로봇팔을 이용하여 두 가지 종류의 실험을 수행하였다. 로봇팔은 Katana-5D를 이용하였으며, 물체의 위치를 측정하기 위해서 OptiTrack사의 모션 캡처 장비<sup>[20]</sup>와 마커를 이용하였다. 로봇팔을 사람이 잡은 채로 움직여서 운동습씨를 알려주는 시연을 수행하였다. 각 시연에 대해서 위치정보 3종류의 직교 좌표  $(x, y, z)$ 와 3종류의 오일러 좌표  $(\alpha, \beta, \gamma)$ 를 일정 시간간격으로 샘플링하여 취득하였다. 실제 센서로부터 취득한 데이터의 주기는 0.1초 이었으며, 복잡도 계산을 위한 확률변수를 줄이기 위해서 1초의 샘플링 주기를 선택하였다.



### 4.1 글씨 쓰는 운동습씨

첫 번째 실험은 로봇팔을 이용해 글씨나 도형을 그리는 작업을 수행하게 한 후에 해당 작업의 복잡도를 측정하였다. 이는 측정하고자 하는 운동습씨의 형상이 복잡도에 어떻게 영향을 주는지를 알기 위함이다. 실험을 하는데 사용된 도형은 ‘1’, ‘8’, ‘라’, 그리고 무작위로 그린 도형 등 총 4개의 글씨를 각 글씨 당 10회 반복하였다. 실험 과정에 대한 영상을 Fig 5에 나타내었다. 이 실험에서 로봇팔의 엔드 이펙터 데이터를 이용하였다. 시간에 따른 변화가 복잡도 측정에 얼마나 영향을 주는지를 확인하기 위해서 Tononi의 신경 복잡도와 제안한 시분할 신경 복잡도에 대하여 측정을 수행하였다. 4종류의 글씨에 대한 두 가지 복잡도 측정 결과는 Table 1에 나타나 있다. 먼저 시간에 따른 변화를 고려하지 않는 신경복잡도로 측정한 결과를 보면 ‘1’을 쓰는 글씨가 가장 높게 나타나는 것을 볼 수 있으며 ‘라’의 글씨를 쓰는 경우가 그 다음의 복잡도를 나타내는 것을 볼 수 있다.

신경 복잡도로 측정했을 때 ‘1’의 복잡도가 가장 높게 나타나는 현상은 어떤 요소들 간의 상호연관성이 복잡도 측정에 참여하는지를 분석함으로써 설명될 수 있다. 시간에 대한 변화를 고려하지 않는 신경 복잡도에 의해 글씨 쓰는 운동습씨의 복잡도를 측정한다면, 결국 x축과 y축 간의 상호연관성으로서 그 수치가 표현 될 수 있다. ‘1’의 경우는 x축과 y축 간의 연관성이 뚜렷하게 보일 수 있다. 하지만 나머지 글자들은 두 좌표축간의 연관성이 뚜렷하게 나타나지 않기 때문에 모두 복잡도가 낮게 나온다고 볼 수 있다.




Fig. 5. An illustration of the movement skill of writing letters.

Table 1 Experimental results of the movement skill of writing letters.

	Neural complexity	Time-sliced neural complexity
(a): ‘1’	10.89	0.09
(b) ‘8’	0.45	1.93
(c) ‘라’	1.66	13.5
(d) random	-0.62	0.01

그러나 ‘1’보다는 다른 글씨들을 만들기 위해 더 많은 정보가 소요되므로 시간에 대한 변화를 고려하지 않는 신경복잡도는 운동습씨를 측정하는데 문제가 있다고 볼 수 있다. 반면 제안하는 시분할 신경복잡도로 측정한 결과에서는 ‘라’를 쓰는 운동습씨의 복잡도가 가장 높은 것으로 나왔으며, ‘8’을 쓰는 운동습씨가 그 다음 순서의 복잡도를 보이는 것으로 나타난다. 시간에 대한 변화를 고려하는 것이 운동습씨의 복잡도를 측정하는데 더 적절한 지표라는 것을 확인 할 수 있다.

Table 1의 시분할 신경복잡도의 결과로부터 글씨를 쓰기 위한 경로가 길고, 획수가 많으며, 변화가 다양한 글씨일수록 더 복잡하다고 여겨지는 것을 확인 할 수 있다. 또한, 신경복잡도와 제안하는 시분할 신경복잡도 Fig 5(d)에 나타난 바와 같은 무작위로 쓴 글씨의 복잡도가 낮다고 표현 하고 있다. Fig 5(d)는 매 시도횟수마다 전혀 다른 방향의 직선이 그어졌기 때문에 이와 같은 운동습씨는 무질서도가 상당히 높게 된다. 이와 같은 무질서한 운동은 이를 기술하는 규칙이 거의 없다시피 하기 때문에 내부에 담긴 정보량 자체가 작고 따라서 낮은 복잡도를 가진다고 판단 할 수 있다. 이는 너무 무질서하지도 않고 너무 규칙적이지도 않은 대상이 높은 복잡도를 갖는다는 복잡도의 정의와도 일치하는 내용이다.

### 4.2 컵에 물을 옮겨 따르는 운동습씨의 복잡도 측정

두 번째 실험의 목적은 동작을 정교하게 하는 것이 복잡도에 어떻게 영향을 주는 것 인지를 확인해 보기 위함이다. 이를 위해 사람이 로봇팔을 이용해 물병을 잡도록 한 후 입구의 폭이 각기 다른 컵에 물을 옮겨 담는 동작을 수행하였다. 이 과정은 Fig 6에 나타나 있다. 각 시연에 대해서 로봇팔의 6자유도 위치 및 방향 성분과 각각의 컵의 6자유도 위치 및 방향성분을 데이터로서 취득하였다. 이후 과정은 앞서 소개한 글씨 쓰기 작업과 동일하게 진행하였다.

물을 옮겨 따르는 작업에 따른 복잡도 측정 결과는 Table 2에 나타나 있다. 신경 복잡도로 측정했을 때에는 세 운동습씨간의 차이가 두드러지게 나타나지 않았다. 이는 시간에 따른 변화를 고려하지 않는 신경복잡도는 동작의 정교한 정도를 잘 구분해 내지 못한다는 것을 의미한다. 제안하는 시분할 신경 복잡도 측정 방법을 사용한 측정 결과에서는 Fig 6(b)에 나타난바와 같이 입구가 가장 넓은 컵에 물을 따르는 동작의 복잡도가 가장 낮게 나타난다. 입구가 넓은 대상에 물을 따르는 것은 허용되는 오차범위가 그만큼 크다는 것을 의미하며 정교한 동작을 요구하지 않는다는 것을 뜻한다. 반대로 Fig 6(c)처럼 입구가 좁은 다른 병에 물을 옮겨 담는 동작은 매우 정교한 동작을 요구한다. 이 경우 복잡도 측정 결과는 세 동작 중 가장 높게 나타난다. 이로부터 얻을 수 있는 결론은 정교한 동작일수록 높은 수준의 복잡도를 보인다는 점이다.




Fig. 6. An illustration of the movement skill of pouring water into a cup.

Table 2. Experimental result of movement skill of pouring water into a cup.

	Neural complexity	Time-sliced neural complexity
(a)	4.62	13.74
(b)	2.64	8.03
(c)	3.48	47.18

#### 4.3 물건을 집어 옮기는 운동습씨의 복잡도 측정

앞서 소개한 실험들은 엔드 이펙터 위치가 주요 측정대상이 되는 운동습씨의 복잡도를 측정하였다. 다시 말하면, 로봇의 기구학적 특성이 복잡도 측정에 반영되지 않았었다. 따라서 세 번째 실험에서는 로봇팔의 기

구학적 특성이 운동습씨를 나타내는데 영향을 주는 작업을 대상으로 하였다. 이 실험에서는 로봇팔을 이용해 선반위의 물체를 집어 특정 장소로 옮기는 운동 습씨의 복잡도를 측정하였다. 선반 2층의 물체를 옮기는 작업은 중간에 장애물이 적기 때문에 로봇 관절각도에 대한 제약조건이 적고, 선반 1층의 물체를 옮기는 작업은 보다 많은 관절각도의 제약조건을 포함하고 있다. 선반 2층의 물체를 옮기는 작업에 대한 예시는 Fig 7에 표현되어 있으며 선반 1층의 물체를 옮기는 작업에 대한 예시는 Fig 8에 표현되어 있다.

Table 3은 로봇 엔드 이펙터의 6자유도 정보를 이용하여 복잡도를 측정된 결과를 나타낸다. 신경 복잡도 측정방법에서는 선반 1층의 물체를 옮기는 동작과 선반 2층의 물체를 옮기는 작업의 차이를 거의 구분하지 못하고 있다. 시분할 신경복잡도 측정지표를 이용하면 더 높은 측정치를 보이는 것을 확인할 수 있다. 그리고 선반 1층의 물체를 옮기는 작업이 더 복잡한 작업으로 측정되는 것을 볼 수 있다. 이는 장애물에 의한 제약조건 때문에 더 정교한 동작을 요구하기 때문으로 볼 수 있다.

Table 4는 같은 작업에 대해 로봇팔의 관절 각도를 이용한 운동습씨의 복잡도를 측정된 결과이다. 이 지표




Fig. 7. Movement skills of pick and place an object in the shelf on the second floor. (a) Pick the object, (b) Place the object




Fig. 8. Movement skills of pick and place an object in the shelf on the second floor. (a) Pick the object, (b) Place the object



Table 3. Experimental result of movement skill of picking and placing an object by using end-effector trajectory.

	Neural complexity	Time-sliced neural complexity
Shelf on the second floor	1.5	44.0
Shelf on the first floor	1.34	117.6

[Table 4] Experimental result of movement skill of picking and placing an object by using joint trajectory.

	Neural complexity	Time-sliced neural complexity
Shelf on the second floor	0.37	44.31
Shelf on the first floor	0.22	51.99

상에서도 선반 1층 물체를 옮기는 작업이 더 복잡하다고 나오지만 엔드 이펙터를 이용했을 때보다는 그 차이가 줄어들어 있다.

이에 대한 분석은 다음과 같다. Fig 8에 나타난 선반 1층의 물체를 옮기는 작업에서는 장애물에 부딪히지 않고 정교하게 움직여야 하는 부분이 있다. 이 정교한 움직임은 엔드 이펙터의 움직임 측면에서 보면 쉽게 확인 할 수 있다. 하지만 관절각도 입장에서는 위와 같은 정교한 움직임을 만들어내는 관절 배치가 다양할 수 있기 때문에 덜 복잡하다고 간주 될 수 있다. 이를 통해서 복잡도 측정 결과가 같은 운동습씨를 어느 측면에서 관찰할 때 더 유용한 정보가 쉽게 추출될 수 있는지를 알려준다는 것을 볼 수 있다.

### 5. 결론

본 논문에서는 로봇의 운동습씨에 관한 작업의 복잡도를 정보처리 이론에 기반 하여 정량적으로 측정할 수 있는 측정 지표를 제안하였다. 제안하는 방법은 로봇의 동작 및 이와 관련한 센서정보를 시간에 대해 샘플링하고 다변량 가우시안 분포로 모델링 한 후에 이 모델의 부분적인 정보교환을 측정하는 방법에 의해 작업의 복잡도를 계산하였다. 제안한 시분할 신경 복잡도 측정 방법을 이용하여 로봇이 그리는 경로의 다양성에

따른 복잡도와 작업에 요구되는 정교함에 따른 복잡도를 실험을 통해 계산하였다. 이를 통해 복잡한 형상을 정교하게 하는 동작일수록 복잡하게 측정된다는 결론을 얻을 수 있었다. 제안한 작업의 복잡도 측정방법은 작업의 학습이나 모방을 할 때 얼마나 많은 데이터가 필요한지 그리고, 얼마나 복잡한 모델이 필요한지 등을 판단하는데 중요한 근거로 활용될 수 있다.

### 참고문헌

- [1] Kwang-Tae Jung, Won-dea Jung, and Jin-Kyun Park, "Fuzzy Linguistic Approach for Evaluating Task Complexity in Nuclear Power Plant", Journal of the KOSOS, Vol. 20, No. 1, pp. 126-132, 2005
- [2] J. Flack and D. Krakauer, "Challenges for complexity measures: A perspective from social dynamics and collective social computation," Chaos: An Interdisciplinary Journal of Nonlinear Science, vol. 21, no. 3, pp. 037 108--037 108, 2011.
- [3] P. Robinson, "Task complexity, task difficulty, and task production: Exploring interactions in a componential framework," Applied Linguistics, vol. 22, no. 1, pp. 27-57, 2001.
- [4] K. Bystrom and K. J'arvelin, "Task complexity affects information seeking and use," Information Processing & Management, vol. 31, no. 2, pp. 191-213, 1995.
- [5] J. Teo and H. Abbass, "Multiobjectivity and complexity in embodied cognition," Evolutionary Computation, IEEE Transactions on, vol. 9, no. 4, pp. 337-360, 2005.
- [6] A. Seth and G. Edelman, "Environment and behavior influence the complexity of evolved neural networks," Adaptive Behavior, vol. 12, no. 1, pp. 5-20, 2004.
- [7] H. Simon, "The architecture of complexity," Proceedings of the American philosophical society, vol. 106, no. 6, pp. 467-482, 1962.
- [8] G. Chirikjian, "Parts entropy and the principal kinematic formula," Stochastic Models, Information Theory, and Lie Groups, Volume 2,

- pp. 187--228, 2012.
- [9] M. Moll and M. Erdmann, "Manipulation of pose distributions," *The International Journal of Robotics Research*, vol. 21, no. 3, pp. 277-292, 2002.
- [10] A. Sanderson, "Parts entropy methods for robotic assembly system design," in *Robotics and Automation. Proceedings. 1984 IEEE International Conference on*, vol. 1. IEEE, 1984, pp. 600-608.
- [11] M. Li and P. Vitányi, *An introduction to Kolmogorov complexity and its applications*. Springer-Verlag New York Inc, 2008.
- [12] R. Lopez-Ruiz, H. Mancini, and X. Calbet, "A statistical measure of complexity," *Physics Letters A*, vol. 209, no. 5-6, pp. 321-326, 1995.
- [13] G. Tononi, O. Sporns, and G. Edelman, "A measure for brain complexity: relating functional segregation and integration in the nervous system," *Proceedings of the National Academy of Sciences*, vol. 91, no. 11, p. 5033, 1994.
- [14] G. Tononi, G. Edelman, and O. Sporns, "Complexity and coherency: integrating information in the brain," *Trends in cognitive sciences*, vol. 2, no. 12, pp. 474-484, 1998.
- [15] G. Tononi, "Information integration: its relevance to brain function and consciousness," *Archives italiennes de biologie*, vol. 148, no. 3, pp. 299-322, 2010.
- [16] L. Barnett, C. Buckley, and S. Bullock, "Neural complexity and structural connectivity," *Physical Review E*, vol. 79, no. 5, p. 051914, 2009.
- [17] —, "Neural complexity: A graph theoretic interpretation," *Physical Review E*, vol. 83, no. 4, p. 041906, 2011.
- [18] L. Smith, "A tutorial on principal components analysis," *Cornell University, USA*, vol. 51, 2002.
- [19] C. Bishop and S. S. en ligne), *Pattern recognition and machine learning*. springer New York, 2006, vol. 4.
- [20] OptiTrack, "Optitrack technical specifications: v100-r2," <http://www.naturalpoint.com/optitrack/products/v100-r2/specs.html>.



**권우영**

2001 한양대학교 기계공학과 (학사)  
 2003 한양대학교 정보통신공학과 (석사)  
 2008~현재 한양대학교 전자컴퓨터통신공학과 박사과정

관심분야: 머신러닝, Probabilistic Graphical Models, Proactive Interaction



**서일홍**

1977 서울대학교 전자공학과 (학사)  
 1979 한국과학기술원 전자공학과 (석사)  
 1982 한국과학기술원 전자공학과 (박사)


1985 대우중공업 기술연구소  
 1985~현재 한양대학교 교수  
 관심분야: 인간수준의 Manipulation, Planning, Navigation, Recognition을 위한 Robot intelligence



**이준구**

2011 한국외국어대학교 디지털정보통신공학과 (공학사)  
 1979~현재 한양대학교 전자컴퓨터통신공학과 석사과정

관심분야: Manipulation, 인공지능, 머신러닝



### 유 범 재

- 1985 서울대학교 공과대학 제어계측공학(학사)
- 1987 KAIST 전기 및 전자 공학(석사)
- 1991 KAIST 전기 및 전자 공학(박사)

1991~1994 (주)터보테크 로봇개발실장  
1994~현재 한국과학기술연구원(KIST) 책임연구원  
2010~현재 한국과학기술연구원(KIST) 실감교류 인체감응솔루션연구단 단장  
관심분야: 휴먼-컴퓨터-로봇 인터랙션, 시각 기반 로보틱스, 휴머노이드 로봇, 인간친화형 로봇, 실시간 고속 영상처리, 마이크로프로세서/신호처리프로세서 응용



### 오 상 록

- 1980 서울대 전자공학과(공학사)
- 1982~1987 한국과학기술원 전자공학 석사/박사
- 1991.10~1992.10 IBM T. J. Watson Research Center Visiting Research Staff

1995.12~1996.2 일본 통신성 기계기술연구소 객원 연구원  
1988~현재 한국과학기술연구원 선임 및 책임연구원  
2003~2008 정보통신부 지능형로봇 프로젝트 매니저  
2006~2008 정보통신부 IT정책자문관  
2009.11~2010.8 현재 한국과학기술연구원 로봇시스템본부장  
2010.9~2010.12 한국과학기술연구원 대외부원장  
2010.12~현재 한국과학기술연구원 로봇기반교육 지원단장  
2011.1~2011~12 한국로봇학회 회장  
관심분야: R-learning 시스템, 로봇공학