

혼합 시퀀스 커널을 이용한 조종사의 비동적 행위 모델링

최예림^{*,1)} · 전승욱¹⁾ · 지철규²⁾ · 박종헌¹⁾ · 신동민³⁾

¹⁾ 서울대학교 산업공학과

²⁾ 국방과학연구소 제7기술연구본부

³⁾ 한양대학교 산업경영공학과

A Non-Kinetic Behavior Modeling for Pilots Using a Hybrid Sequence Kernel

Yerim Choi^{*,1)} · Sungwook Jeon¹⁾ · Cheolkyu Jee²⁾ · Jonghun Park¹⁾ · Dongmin Shin³⁾

¹⁾ Department of Industrial Engineering, Seoul National University, Korea

²⁾ The 7th Research and Development Institute, Agency for Defense Development, Korea

³⁾ Department of Industrial and Management Engineering, Hanyang University, Korea

(Received 7 March 2014 / Revised 25 September 2014 / Accepted 7 November 2014)

ABSTRACT

For decades, modeling of pilots has been intensively studied due to its advantages in reducing costs for training and enhancing safety of pilots. In particular, research for modeling of pilots' non-kinetic behaviors which refer to the decisions made by pilots is beneficial as the expertise of pilots can be inherent in the models. With the recent growth in the amount of combat logs accumulated, employing statistical learning methods for the modeling becomes possible. However, the combat logs consist of heterogeneous data that are not only continuous or discrete but also sequence independent or dependent, making it difficult to directly applying the learning methods without modifications. Therefore, in this paper, we present a kernel function named hybrid sequence kernel which addresses the problem by using multiple kernel learning methods. Based on the empirical experiments by using combat logs obtained from a simulator, the proposed kernel showed satisfactory results.

Key Words : Non-Kinetic Behavior Modeling(비동적 행위 모델링), Pilots(조종사), Hybrid Sequence Kernel(혼합 시퀀스 커널), Combat Logs(전투 로그), Support Vector Machines(지지기반벡터)

1. 서론

국방시스템에서 조종사 모델링은 실제 조종사와 유사하게 행동 및 사고하는 모델을 만듦으로써 보다 사실적인 에이전트 기반 시뮬레이터의 구현이 가능해 진다는 점^[1]과 진화된 무인전투기에 활용이 가능하다는 점^[2]에서 주목받고 있는 연구 주제이다. 사실적인

* Corresponding author, E-mail: iangoozh@gmail.com
Copyright © The Korea Institute of Military Science and Technology

비행 시뮬레이션을 활용하면 실제와 유사한 수준의 훈련을 수행하면서도 전투기를 실제 운용하는데 소요되는 연료 비용, 위험 비용과 같은 다양한 비용을 절감할 수 있으며, 실전 상황과 유사한 상황의 재현을 통해 전투에서 앞으로 발생할 상황을 예측 및 대비하여 효과적인 전투를 수행할 수 있다^[3]. 최종적으로는, 조종사 모델링을 통해 조종사의 판단 과정을 기계가 대체함으로써 유인전투기의 진입이 불가능한 지역을 운행할 수 있게 될 뿐만 아니라 조종이 불가능한 지형에서도 활용 가능한 진화된 무인전투기를 개발하는데 기초적 발판을 마련할 수 있다.

조종사 모델링의 대상은 크게 세 가지로 나누어 볼 수 있는데 첫째, 조종사의 심리 상태^[4,5], 둘째, 조종사의 동적 행위^[6], 마지막으로 조종사의 비동적 행위^[7,8]가 있다. 조종사의 심리 상태 모델은 조종사의 집중 상태^[4], 피로도^[5] 등 다양한 종류의 심리 상태를 예측하기 위한 것으로, 심리 상태 모델을 통해 조종사의 상태를 미연에 파악하여 사고 예방의 효과를 기대할 수 있다. 조종사의 동적 행위 모델링은 전투기의 궤도를 재생산 할 수 있는 모델을 설계하는 것으로, 1960년대에 매우 활발하게 이루어 졌으며, 수학적 모델을 이용하여 주어진 전투기의 상황 변수 값에 대해 최적의 궤도를 계산해 내는 방식이다. 하지만 대부분의 연구는 한정된 환경에서의 전투기 움직임을 모사하고자 하였으며, 상황의 변화에 따라 모델 파라미터를 수작업을 통해 변환해 줘야한다. 따라서 예상되지 않은 상황에서는 적절한 반응을 보일 수 없다는 단점이 있으며, 행위에 기반이 되는 조종사의 상황 판단에 대해서는 고려하지 않는다. 즉, 동적 행위 모델은 전투기의 움직임을 성공적으로 재생산 및 예측 할 수 있지만, 움직임이 아닌 조종사의 경험 및 노하우를 반영한 상황에 대한 판단, 예를 들어, 공격이 필요한 상황인지 혹은 정교한 속도 조절이 필요한 상황인지에 대한 결정 등은 예측할 수 없다.

이러한 상황에 대한 판단에서 도출된 항공기의 궤도와 관련되지 않은 행위를 비동적 행위라고 정의한다. 조종사의 비동적 행위 모델은 인지모델^[7]이나 규칙기반모델^[9]을 통해 개발되어 왔으나, 사전에 제작된 모델을 사용하는 경우 모델링의 정교함에 성능이 좌우될 뿐만 아니라, 규칙의 충돌이나 새로운 상황에 반응할 수 없다는 문제가 발생할 수 있다. 따라서 본 연구에서는 이를 해결하기 위해 통계적 학습 기법을 사용하여 모델링하고자 한다.

통계적 학습 기법은 대용량의 데이터로부터 규칙과 정보를 추출하기 위해 사용되는 방법론으로 이상 탐지 분야^[10,11], 문서 분류 분야^[12] 등 다양한 분야에서 성공적으로 적용되었다. 본 연구에서도 이러한 기법을 통해 기존 비동적 행위 모델링 연구의 한계를 극복할 수 있을 것으로 기대된다. 실제로 다수의 인간 행위 모델링 연구에서 은닉마코프모델(HMM : Hidden Markov Models)^[13,14], 지지기반벡터(SVM : Support Vector Machine)^[15,16]와 같은 다양한 종류의 통계적 학습 기법이 사용되었다. 본 논문에서는, 이러한 기법들 중 경쟁력 있는 성능을 보이는 것으로 알려져 있으며, 커널 함수를 이용하여 선형분리가 불가능한 데이터도 효과적으로 분류할 수 있는 지지기반벡터^[17]를 도입한다.

지지기반벡터를 이용한 조종사의 비동적 행위 모델링을 위해서는 학습을 위한 데이터의 축적이 필요하다. 최근, 데이터 수집 및 저장 기법의 발달로 군사 훈련 및 실전 데이터들의 축적이 이루어지고 있으며 이를 이용하면 실제 조종사의 행위를 모사할 수 있을 것으로 기대된다. 본 연구에서는 조종사의 행위와 주변 상황을 기록한 데이터를 행위 데이터라고 명명하며, 행위 데이터를 상태 변수와 행위 변수로 구분한다. 상태 변수란 특정 시점에서 조종사와 전투기의 주변 상황을 나타내는 변수를 의미하는데, 전투기의 속도 및 고도 등이 포함된다. 행위 변수는 특정 시점에서 조종사가 취한 행동 혹은 판단으로, 공격 여부에 대한 판단 등이 있다.

Das et al.^[11]에 따르면, 항공 및 군사 분야에서 추출되는 상태 변수는 크게 두 가지 특성을 가진다. 첫째, 시간에 따라 계속적으로 발생하므로 시계열 성격을 가지며, 둘째, 이산형 변수와 연속형 변수가 혼재되어 있다. 이처럼 다양한 성질의 상태 변수가 섞여있는 데이터를 이용하여 통계적 학습 방법론을 사용한다면, 만족할 만한 성능을 얻을 수 없다고 알려져 있다^[18]. 따라서 Das는 이산형 변수와 연속형 변수를 분리하여 각 변수 별 시퀀스 유사도를 측정하는 방법인 다중 커널(multiple kernel)을 제안하였다. 다중 커널은 기존의 기법 대비 우수한 성능을 나타내었지만 변수 별로 시퀀스를 추출한 후 유사도를 계산하기 때문에 시간 복잡도가 높아 상대적으로 매우 긴 학습 시간을 필요로 한다. 하지만 방대한 규모의 조종사 행위 데이터를 처리하기 위해서는 적절한 수준의 시간 복잡도를 유지되어야 하므로 다중 커널의 높은 시간 복잡도는 해결되어야 할 문제이다.

추가적으로 본 연구에서는 특정 시점의 행위 변수가 동일 시점의 상태 변수가 취하는 값에만 영향을 받는지, 이전 시점의 상태 변수 값과도 관련을 가지는지에 따라 각각 시퀀스 비의존적(sequence independent) 변수와 시퀀스 의존적(sequence dependent) 변수의 개념을 도입하였다. 이는 상태 변수에 따라서는 특정 시점의 값과 행위 변수의 상관관계가 이전 시점의 값들로 이루어진 시퀀스와 행위 변수의 상관관계보다 높을 수 있다는 점과, 이와 같은 시퀀스 비의존적 변수에 속하는 상태 변수에는 일반적인 커널 함수 방식을 도입하여 유사도를 계산하면 시간 복잡도를 줄일 수 있다는 점에 기초한다. 즉, Table 1과 같이 변수 값의 속성과 시계열적 의미의 유무의 두 가지 기준에 따라 상태 변수를 시퀀스 비의존적 연속(IC) 변수, 시퀀스 비의존적 이산(ID) 변수, 시퀀스 의존적 연속(DC) 변수, 시퀀스 의존적 이산(DD) 변수의 네 종류로 구분한다.

Table 1. Four types of status attributes

	Sequence independent	Sequence dependent
Continuous	IC	DC
Discrete	ID	DD

본 연구에서는 지지기반벡터를 이용하여 조종사의 비동적 행위를 모델링하는데 있어 다양한 종류의 상태 변수를 구분하여 유사도를 계산하는 혼합 시퀀스 커널(HS kernel : Hybrid Sequence kernel)을 제안한다. 이를 위해 상태 변수 별 각기 다른 커널 함수를 사용하는 다중 커널 학습 기법^[9]을 도입하여 Das et al.^[11]와 유사하게 연속형 및 이산형 변수를 나누어 계산 하였으며, 추가적으로 시퀀스 비의존적 및 시퀀스 의존적 변수의 개념을 사용하여 정확도를 높이는 동시에 학습 시간을 줄일 수 있는 커널 함수를 개발하였다.

구체적으로, 혼합 시퀀스 커널은, 시퀀스 비의존적 변수 커널, 시퀀스 의존적 연속 변수 커널, 시퀀스 의존적 이산 변수 커널, 총 세 커널의 가중 합으로 정의되며, 각 커널은 해당하는 상태 변수를 대상으로 계산된다. 시퀀스 비의존적 변수 커널은 시퀀스 비의존적 연속 변수와 시퀀스 비의존적 이산 변수의 특정 시점에서 발생한 변수 값들로 구성된 벡터를 입력 받는 커널

함수로 일반적으로 많이 사용되는 선형(linear) 커널을 사용하였다. 또한, 시퀀스 의존적 연속 변수 커널은 하나의 시퀀스 의존적 연속 변수 별로 계산된 세부 커널의 합으로 정의되며, 이때, 세부 커널로는 각 변수 별로 특정 시점부터 미리 지정된 수의 선행하는 변수 값들로 구성된 벡터인 시퀀스 벡터를 입력으로 받는 선형 커널을 사용하였다. 마지막으로, 시퀀스 의존적 이산 변수 커널은 시퀀스 의존적 연속 변수 커널과 동일하게 각 시퀀스 의존적 이산 변수 별로 계산된 세부 커널의 합으로 정의되지만, 세부 커널로는 이산형 데이터에서 효과적이라고 알려진 스펙트럼(spectrum) 커널^[20]을 조종사의 비동적 행위 모델링 문제에 적합하도록 수정하여 사용하였다.

본 논문은 다음과 같이 구성된다. 2장에서 지지기반 벡터와 다중 커널 학습 방법론을 설명한 후 3장에서 제안하는 혼합 시퀀스 커널을 상세히 소개한다. 4장에서는 혼합 시퀀스 커널의 성능을 비교하기 위해 사용된 데이터와 실험 설정에 대해 언급하고, 실험 결과와 그 의미를 분석 및 제시한다. 마지막으로 5장에서 제안한 모델과 실험 결과를 요약하며 논문을 마무리한다.

2. 지지기반벡터와 다중 커널 학습

지지기반벡터는 Vapnik(1995)^[17]에 의해 제안된 통계적 학습 기법의 하나로 주어진 데이터 사이의 최대 마진(margin)을 갖도록 하는 초평면을 찾는 이진분류기다. 다른 분류기들과 비교했을 때 경쟁력 있는 성능을 보이는 것으로 알려져 있다. 특히, 지지기반벡터는 커널 함수를 이용하여 데이터의 비선형 형태의 분류가 가능하다는 장점을 가진다. 커널 함수란 주어진 데이터를 고차원 공간으로 사상하여 해당 공간에서 정의되는 유사도(혹은 거리)를 나타내는 것으로, 확장된 차원에서 데이터의 선형 분류를 수행 할 수 있게 해준다^[21]. 이처럼 두 입력 벡터간의 유사도를 새롭게 정의함으로써 데이터에서 주어진 정보 외에 다양한 정보를 추가적으로 이용하여 분류기의 정확도를 높일 수 있다.

하나의 커널 함수를 이용하여 서로 다른 성질을 가지는 전체 변수들의 유사도를 계산할 경우 성능 하락 문제가 발생할 수 있다. 예를 들어, 두 벡터의 유사도를 특정 패턴의 각 벡터에서의 발생 횟수의 곱으로

정의하여 이산형 변수의 유사도 측정에 유리한 스펙트럼 커널^[20]을 연속형 변수에 사용하면 연속형 변수는 매우 다양한 값들을 가질 수 있으므로 일반적으로 동일한 패턴이 출현할 확률은 매우 낮아 대부분의 입력 벡터 간 유사도가 0에 가까운 값으로 구성된 커널 행렬을 얻게 될 것이다. 즉, 해당 커널 행렬을 사용하여 수행한 분류는 낮은 정확도를 보일 것이다.

이러한 문제를 해결하기 위해 한 종류의 커널을 전체 데이터에 사용하는 대신, 각 변수마다 다른 커널을 적용하여 이 커널들의 조합을 최종 유사도로 이용하는 다중 커널 학습 방법이 제안되었다^[19]. 다중 커널 학습 방법은 영상 처리^[22], 표정 감지^[23]와 같이 다양한 특성의 데이터들이 혼재된 분야에서 적용되어 좋은 성능을 나타냈다. 다만, 하나의 커널로 전체 변수에 대해 유사도를 구하는 일반적인 커널 계산법과는 달리 각 변수마다 다른 커널을 사용하여 개별적으로 유사도를 구한 후 추가적인 처리로 전체 유사도를 구하는 만큼 계산 복잡도가 높은 편이다.

다중 커널 학습 기법을 도입한 연구들 중 Das et al. (2010)^[11]는 항공우주분야에서 항공기의 이상 징후를 단일-클래스(one-class) 지지기반벡터를 이용하여 감지하는 모델을 개발하였다. 이때, 항공기에서 생성되는 정보들이 시계열의 형태를 하고 있으며 이산형 및 연속형 변수가 섞여 있으므로 이산형, 연속형 변수를 각기 다른 커널을 사용하여 계산한 다중 커널을 제안하였다. 본 연구에서도 이를 응용하여 사전 지식을 통해 이산형 및 연속형 변수들을 분류하여 유사도를 계산하였고, 기존 연구와는 달리 시계열 정보를 활용할 필요 없는 변수를 추출하여 일반적 커널 함수 계산 방식을 사용함으로써 계산 복잡도를 낮추었다.

3. 제안 커널 함수

3.1 문제 정의

본 연구에서는 조종사의 행위 데이터를 이용하여 조종사의 비동적 행위를 모델링하고자 한다. 제안하는 모델에서 사용되는 특정 조종사로부터 생성된 행위 데이터는 $\{(\mathbf{x}_t, y_t) | t=1, \dots, T\}$ 로 표기된다. 여기서 \mathbf{x}_t 와 y_t 는 t 시점에서의 상태 변수 벡터와 행위 변수 값을 각각 나타내며, T 는 생성된 데이터의 마지막 시점을 의미한다. 본 연구에서 제안하는 조종사의 비동적 행위 모델인 지지기반벡터를 학습시키기 위해 행위 변

수 값이 주어진 과거 행위 데이터를 이용하며, 학습된 모델에 새로운 시점에 상태 변수 벡터 \mathbf{x}_t 를 입력하면 해당 상황 하에 조종사의 판단으로 예측되는 행위 변수 값 y_t 을 얻을 수 있다.

본 모델에서 고려되는 상태 변수의 집합을 $A = a_1, a_2, \dots, a_N$ 로 표현하며, 집합의 원소인 a_n 은 n 번째의 상태변수를, N 은 상태변수의 총 개수를 의미한다. 따라서 t 시점에서의 상태변수벡터 \mathbf{x}_t 는 $\mathbf{x}_t = \langle a_{1,t}, a_{2,t}, \dots, a_{N,t} \rangle$ 와 같이 표기되고, 벡터의 원소인 $a_{n,t}$ 는 n 번째 상태변수의 t 시점에서의 값을 나타낸다. 특히, 특정된 시점으로부터 선행하는 값들로 구성된 시퀀스 벡터에 대해 원소의 총 개수를 의미하는 시퀀스 벡터 사이를 w 로 표기한다.

3.2 조종사의 비동적 행위 모델을 위한 커널 함수

식 (1)은 주어진 두 상태 변수 벡터 $\mathbf{x}_i, \mathbf{x}_j$ 에 대한 커널 함수의 형태를 나타낸다. $\Phi(\cdot)$ 은 입력 벡터의 고차원으로의 사상을 나타내며, 커널 함수는 최종적으로 확장된 각 입력 벡터의 값의 내적으로 표현된다.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) \tag{1}$$

본 연구에서 사용되는 커널 함수에는 선형 커널, RBF(Radial Basis Function) 커널, 스펙트럼 커널이 있다. 선형 커널은 가장 기본적인 커널로 두 입력 벡터의 내적으로 정의되어 식 (2)과 같이 계산된다.

$$k_{linear}(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j \tag{2}$$

또한, RBF 커널은 두 입력 벡터의 유클리디안 거리를 유사도로 사용하는 커널 함수로 식 (3)와 같이 정의된다.

$$k_{RBF}(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \tag{3}$$

여기서 $\|\mathbf{x}_i - \mathbf{x}_j\|$ 는 두 벡터 \mathbf{x}_i 와 \mathbf{x}_j 간의 유클리디안 거리를 의미한다.

마지막으로 스펙트럼 커널의 경우 바이오정보과학 분야에서 유전자간의 유사도를 계산하기 위해 개발된 커널로 식 (4)와 같이 주어진 두 벡터의 유사도를 특정 패턴의 각 벡터에서의 발생 횟수의 곱으로 정의한다^[11].

$$k_{Spectrum}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{\sigma \in \Sigma} \text{app}(\sigma, \mathbf{x}_i) \cdot \text{app}(\sigma, \mathbf{x}_j) \quad (4)$$

이때, $\text{app}(\sigma, \mathbf{x}_i)$ 는 시퀀스 σ 가 \mathbf{x}_i 에서 발견되는 횟수를 반환하는 함수이며, Σ 는 미리 정의된 유의미한 패턴 σ 로 구성된 집합이다.

3.3 혼합 시퀀스 커널

본 절에서는 해당 논문에서 제안하는 혼합 시퀀스 커널의 기본 아이디어를 설명한다. 혼합 시퀀스 커널의 기본 아이디어는 Das et al.^[11]이 제안한 다중 커널에 기초한다. 상태 변수를 이산형과 연속형으로 분리하여 각기 다른 커널을 이용하여 유사도를 계산한다. 추가적으로 기존 연구와는 달리 시퀀스 비의존적 변수와 시퀀스 의존적 변수의 개념을 도입하여 상태 변수를 총 네 종류로 구분하여 커널을 적용하였다. 즉, 상태 변수의 집합 A 은 식 (5)와 같이 네 개의 부분 상태 변수 집합의 합집합으로 표현 될 수 있다.

$$A = (IC \cup ID) \cup (DC \cup DD) \quad (5)$$

이때, IC 와 ID 는 시퀀스 비의존적 연속 변수 집합, 시퀀스 비의존적 이산 변수 집합으로 상태 변수 중 시퀀스 비의존적 값이 행위 변수 값에 영향을 미치는 연속형, 이산형 변수의 집합을 각각 의미한다. 또한, DC 와 DD 는 시퀀스 의존적 연속 변수 집합, 시퀀스 의존적 이산 변수 집합으로 상태 변수 값들의 시퀀스가 행위 변수 값에 영향을 미치는 연속형, 이산형 변수들의 집합을 각각 의미한다. 이렇게 분리된 네 종류의 상태 변수들에 적합한 커널 함수를 각각 이용하여 입력 벡터간의 유사도가 측정된다.

구체적으로, Fig. 1과 같이 시퀀스 비의존적 변수

커널(sequence independent attribute kernel), 시퀀스 의존적 연속 변수 커널(sequence dependent and continuous attribute kernel), 시퀀스 의존적 이산 변수 커널(sequence dependent and discrete attribute kernel), 세 종류의 커널 함수가 제안하는 혼합 시퀀스 커널에 사용된다. 시퀀스 비의존적 변수 커널은 일반적인 커널 함수와 유사하게 주어진 두 입력 벡터의 유사도를 추가적인 정보 없이 계산한다. 즉, 제안하는 모델에서는 전체 상태 변수 입력 벡터 중 시퀀스 비의존적 변수에 해당하는 값들만을 부분 벡터 형태로 조합하여 유사도를 계산한다. 입력 벡터간의 내적 값을 유사도로 사용하는 커널 함수인 선형 커널을 도입하였다. 시퀀스 비의존적 연속 변수와 시퀀스 비의존적 이산 변수가 혼재되어 있어, 단일 커널 함수로 유사도를 계산했을 때 발생할 수 있는 성능 하락 문제를 해결하기 위해 시퀀스 비의존적 이산 변수의 경우 자연어 처리 분야에서 많이 사용되는 이진 부호화 방식을 사용하였다^[24].

시퀀스 비의존적 변수와는 달리 시퀀스 의존적 변수의 경우 특정 시점의 단일 변수 값 외에 이전 시점의 변수 값들을 통해 얻을 수 있는 추가 정보를 사용하면 보다 정교하게 유사도를 계산할 수 있을 것으로 기대된다. 따라서 각 변수 별로 미리 정해진 개수의 선행하는 값들로 구성된 시퀀스 벡터를 세부 커널 함수들의 입력으로 이용하여 각 시퀀스 의존적 변수 별로 유사도를 계산 한 후 그 값들의 합으로 전체 유사도를 정의한다. 이때, 시퀀스 의존적 연속 변수와 시퀀스 의존적 이산 변수는 서로 다른 특성을 가지므로 각각 시퀀스 의존적 연속 변수 커널, 시퀀스 의존적 이산 변수 커널을 사용하여 유사도를 계산하였다.

Fig. 2 (a)는 시퀀스 의존적 연속 변수의 예시로 한 시나리오에서 전투기 속도(velocity)의 시간에 따른 변

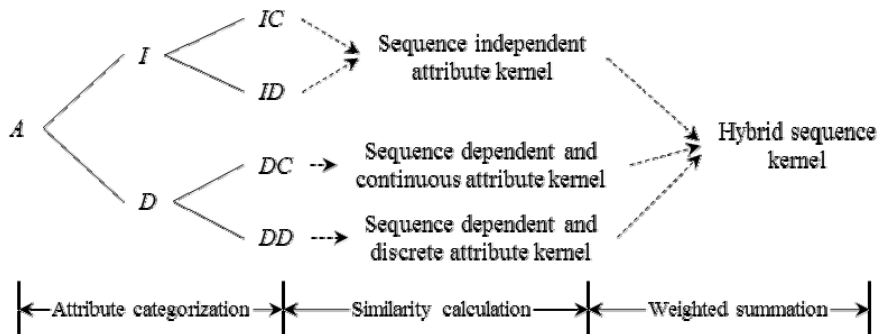


Fig. 1. Concept of hybrid sequence kernel composed of three kernels




Fig. 2. Examples for the two types of the attributes, DC and DD

화 양상을 나타낸다. 시퀀스 의존적 연속 변수를 구성하는 값들은 가능한 경우의 수가 무한하고 대체로 계속적으로 변하는 특징을 보인다. 따라서 본 연구에서는 시퀀스 의존적 연속 변수들을 단일 값으로 사용하지 않고 각 변수 별로 시퀀스 벡터를 추출하여 세부 커널을 통해 이들의 유사도를 계산하였으며, 세부 커널로는 선형 커널을 이용하였다. 이산형 변수는 Fig. 2 (b)에서 나타나는 것과 같이 가질 수 있는 값의 경우의 수가 다양하지 않다는 것과 동일한 값이 오랜 시간 지속되는 경우가 많다는 특징을 가진다. 예를 들어, 표적포착(lock-on target)은 네 개의 경우의 수를 가지고 대체로 같은 값을 지속적으로 유지한다. 따라서 시퀀스 의존적 이산 변수 커널의 세부 커널로는 기존의 스펙트럼 커널을 본 문제에 적합하도록 개선한 수정 스펙트럼 커널을 사용하였다. 구체적으로, 동일한 값이 반복되어 나타나는 횟수보다는 변화하는 패턴이 의미가 있다고 가정하였다. 따라서 기존의 스펙트럼 커널이 동일한 값의 반복을 포함하는 패턴의 발생 횟수를 이용하였다면, 수정 스펙트럼 커널에서는 동일한 값의 반복은 하나로 압축한 형태의 패턴을 새롭게 정의하고 마찬가지로 방식으로 압축된 입력 시퀀스 벡터에서 이러한 패턴의 발생 횟수를 이용하여 유사도를 계산하였다.

3.4 혼합 시퀀스 커널을 이용한 유사도 계산

본 연구에서 제안하는 혼합 시퀀스 커널 K_{HS} 은 상태 변수들이 값으로 이루어진 두 개의 입력 벡터 \mathbf{x}_i 와 \mathbf{x}_j , $i, j = 1, \dots, T$ 에 대하여 식 (6)으로 정의된다.

$$\lambda_I K_I(\mathbf{x}_i, \mathbf{x}_j) + \lambda_{DC} K_{DC}(\mathbf{x}_i, \mathbf{x}_j) + \lambda_{DD} K_{DD}(\mathbf{x}_i, \mathbf{x}_j) \quad (6)$$

여기서 K_I , K_{DC} , K_{DD} 은 각각 시퀀스 비의존적 변수 커널, 시퀀스 의존적 연속 변수 커널, 시퀀스 의존적 이산 변수 커널을 나타낸다. 또한, λ_I , λ_{DC} , λ_{DD} 는 각 커널에 대한 중요도 계수로 각 커널의 기여도를 결정하며 $\lambda_I + \lambda_{DC} + \lambda_{DD} = 1$, $\lambda_I, \lambda_{DC}, \lambda_{DD} \geq 0$ 이다. 본 모델에서는 각 중요도 계수를 식 (7)과 같이 대응하는 상태 변수 집합의 상대 크기로 지정하였다.

$$\lambda_l = \frac{\text{size}(l)}{\text{size}(A)} \quad (7)$$

단, $l \in \{I, DC, DD\}$ 이며, $\text{size}()$ 는 주어진 집합의 원소의 수를 반환하는 함수이다.

시퀀스 비의존적 변수 커널은 입력 벡터 \mathbf{x}_i 와 \mathbf{x}_j 의 값 중 상태 변수 집합 I 에 속하는 변수 값을 대상으로 유사도를 구하는 방식으로 식 (8)과 같이 정의된다.

$$K_I(\mathbf{x}_i, \mathbf{x}_j) = k_{Linear}(\mathbf{x}_i^I, \mathbf{x}_j^I) \quad (8)$$

이때, k_{Linear} 는 선형 커널로 식 (2)와 같이 정의되며, \mathbf{x}_i^I 와 \mathbf{x}_j^I 는 각각 상태 변수 집합 I 에 속하는 변수 값으로만 구성된 \mathbf{x}_i 와 \mathbf{x}_j 의 부분 벡터이다.

시퀀스 의존적 연속 변수 커널은 상태 변수 집합 DC 에 속하는 변수 값을 대상으로 유사도를 계산한다. 구체적으로, 각 변수마다 특정된 두 시점으로부터

선행하는 w 개의 값들로 구성된 두 시퀀스 벡터의 유사도를 구하며 식 (9)와 같이 정의된다.

$$K_{DC}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{n=1}^N k_{DC}(a_{n,i}, a_{n,j}) \quad (9)$$

여기서 $k_{DC}(a_{n,i}, a_{n,j})$ 는 n 번째 상태 변수의 i 시점과 j 시점에서의 유사도를 구하는 세부 커널로 식 (10)과 같이 n 번째 상태 변수가 집합 DC 에 속하는 경우에는 선형 커널을 이용하여 해당 시점으로부터 선행하는 w 개의 값들로 구성된 시퀀스 벡터 간의 유사도를 구하고, 속하지 않는 경우에는 0을 반환한다.

$$k_{DC}(a_{n,i}, a_{n,j}) = \begin{cases} k_{Linear}(\mathbf{a}_{n,i}, \mathbf{a}_{n,j}), & \text{if } a_n \in DC \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

여기서 k_{Linear} 는 선형 커널이며, $\mathbf{a}_{n,i}$ 와 $\mathbf{a}_{n,j}$ 는 i, j 시점으로부터 선행하는 w 개의 값들로 구성된 시퀀스 벡터, $\mathbf{a}_{n,i} = \langle a_{n,i} \dots a_{n,i-w+1} \rangle$ 와 $\mathbf{a}_{n,j} = \langle a_{n,j} \dots a_{n,j-w+1} \rangle$ 를 의미한다.

시퀀스 의존적 이산 변수 커널은 상태 변수 집합 DD 에 속하는 변수 값을 대상으로 연속 변수 커널과 동일한 방식으로 식 (11)과 (12)를 이용하여 유사도를 계산한다. 다만, 각 시퀀스 벡터의 유사도는 이산형 값의 유사도 계산에 적합한 스펙트럼 커널을 이용한다.

$$K_{DD}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{n=1}^N k_{DD}(a_{n,i}, a_{n,j}) \quad (11)$$

$$k_{DD}(a_{n,i}, a_{n,j}) = \begin{cases} k_{MSP}(\mathbf{a}_{n,i}, \mathbf{a}_{n,j}), & \text{if } a_n \in DD \\ 0, & \text{otherwise} \end{cases} \quad (12)$$

특히, 본 연구에서는 이산형 변수들의 특성에 적합하도록 개선된 수정 스펙트럼(modified spectrum) 커널을 사용하였다. 수정 스펙트럼 커널 k_{MSP} 은 식 (13)과 같이 정의된다.

$$k_{MSP}(\mathbf{a}_{n,i}, \mathbf{a}_{n,j}) = \sum_{\sigma \in \Sigma_n} \text{app}(\sigma, \text{sum}(\mathbf{a}_{n,i})) \cdot \text{app}(\sigma, \text{sum}(\mathbf{a}_{n,j})) \quad (13)$$

이때, $\text{app}(\sigma, \text{sum}(\mathbf{a}_{n,i}))$ 는 시퀀스 패턴 σ 가 $\text{sum}(\mathbf{a}_{n,i})$ 에서 발견되는 횟수를 반환하는 함수이며, $\text{sum}()$ 는

입력 시퀀스 벡터를 요약하는 함수로 반복되는 동일한 값을 하나의 값으로 대체하는 방식으로 이루어진다. 또한, Σ_n 은 n 번째 변수에서 추출한 시퀀스 패턴 σ 의 집합을 의미하며, σ 는 미리 지정된 수의 크기로 해당 변수에서 시퀀스 벡터를 추출한 후 각 패턴에 $\text{sum}()$ 함수를 적용한 후 나온 패턴 중 유일한 것들을 의미한다.

제안하는 혼합 시퀀스 커널의 경우 커널 함수의 형태를 보면 기존 커널의 가중합으로 이루어져 있으므로, 결과적인 커널 행렬은 양방전치행렬인 것이 자명하다. 따라서 Shawe-Taylor and Cristianini^[25]에 의하면 양방전치행렬은 머서(Mercer)의 조건^[26]을 만족하므로 제안하는 커널은 유효한 커널을 의미하는 머서 커널이다.

4. 실험

4.1 데이터 셋

본 연구에서 제안한 혼합 시퀀스 커널의 성능을 평가하기 위해 국방과학연구소 관급 전투 시뮬레이터에서 생성된 로그를 수집 및 가공하여 사용하였다. 실제 전투나 훈련에서 사용된 데이터의 경우, 보안 문제 상 사용의 제약이 있으므로 시뮬레이터에서 생성된 데이터로 대체하였다. 본 연구에서 사용된 시뮬레이터는 규칙기반모델을 사용하여 전투기의 행위를 생성하는 행위 생성 모듈, 시각화 모듈, 통제 모듈의 총 세 개의 모듈로 구성된다. 이때, 제안하는 모델이 시뮬레이터에서 생성되는 행위를 정확히 재생산한다면, 실제 전투에서 수집된 데이터를 기반으로 제안하는 모델을 학습시킬 경우 동일한 수준의 정확도를 얻을 수 있을 것이라고 가정하였다.

국방과학연구소 관급 전투 시뮬레이터는 공대공, 공대지 전투를 지원하며, 전투 종류, 레이더 범위, 아군과 적기의 전투기 기종, 방어무장, 전투의 시작 위치 및 종료 위치 등 시뮬레이션을 수행할 상황에 대한 정보를 지정하는 시나리오를 직접 생성하여 시뮬레이션을 수행할 수 있다. Table 2는 본 연구에서 사용된 시나리오의 예시를 보여준다. 해당 시나리오의 결과로 KF-16과 Mig29, 두 기종의 전투기가 공대공, 일대일 전투를 수행하였으며 이 과정에서 적기의 회피, 아군의 회피가 이루어진 후 아군기가 적기를 격추시킴으로 전투가 종료되었다.

Table 2. Example of a scenario for air-to-air combat simulator

Type	Air to air/One versus one		
FOV	60		
Radar range	8000		
Our force		Enemy force	
Fighter model	KF-16	Fighter model	MIG 29
Offensive weapons	AIM120A	Offensive weapons	AIM120A
	AA11		AA11
	Machine gun		Machine gun
Defensive weapon	Chaff	Defensive weapon	Chaff
	Flare		Flare
Results	Our force finds enemy first and fires AIM120A		
	Our force evades missile		
	Both fighters fire AA11		
	Our force evades missile and enemy force is shot down		

이러한 방식으로 생성된 총 8 종류의 시나리오를 이용하여 시뮬레이션 로그를 추출하였으며, 각 시나리오의 공대공, 일대일 전투로 한정하였다. Table 3은 본 연구에서 사용된 시뮬레이션 로그 데이터의 통계치를 나타낸다. 각 전투는 평균적으로 130초가량 지속되었으며 상태 정보는 평균 12600개의 행, 행동 정보는 평균 50개의 행이 생성되었다. 또한, 0.1초 간격으로 조

종사의 행위를 추출하여 총 약 11000개의 경우가 모델을 학습 및 평가하는데 사용되었다.

Table 3. Statistics of log data generated from the simulator according to scenario number

Scenario number	Duration(s)	Number of rows	
		Status	Behavior
1	224	19998	46
2	110	9954	28
3	83	8072	34
4	86	7728	22
5	94	9719	50
6	97	9690	33
7	111	11425	47
8	262	24394	123

출출된 로그는 전처리를 통해 총 18가지의 상태 변수와 행위 변수로 구성된 행위 데이터로 변환되었다. 상태 변수에는 아군기의 속도, 고도, 적기와의 속도 차이 등이 있으며, 두 가지 기준에 따라 이산형 변수, 연속형 변수와 시퀀스 비의존적 변수, 시퀀스 의존적 변수로 나누었다. 이산형 변수와 연속형 변수의 경우 값의 성질에 따라 명확하게 구분되며, 시퀀스 비의존적 변수와 시퀀스 의존적 변수의 구분은 전문가의 판단에 의해 결정되었다.

Table 4는 실험에서 사용된 상태변수의 예시를 나타낸다. Altitude와 Velocity는 각각 고도와 속력을 나타내는 상태 변수로 시퀀스 의존적이며 연속형 변수이

Table 4. Examples of status features according to their names, categories and semantics

Name	Category	Semantic	Name	Category	Semantic
Aim intensity	IC	Aim intensity against a target	Target altitude difference	DC	Altitude difference from a target
Altitude	DC	Altitude	Target distance	DC	Distance from a target
Midrange missile measure	ID	Quantity of mid-range missiles	Target speed difference	DC	Speed difference from a target
Move aim	DD	Aiming of an enemy force	Velocity	DC	Velocity

다. 반면에 Midrange missile measure는 보유 중거리미사일 개수를 나타내는 상태 변수로 시퀀스 비의존적이며 이산형 변수이다. 행위 변수로는 공격이 필요한 상황인지에 대한 조종사의 판단이 사용되었다. 즉, 행위 변수는 공격이 필요한 상황과 공격이 불필요한 상황을 의미하는 두 종류의 값을 갖는다.

4.2 실험 설정

총 세 개의 커널 함수를 이용하여 혼합 시퀀스 커널과 비교하였다. 일반적인 커널 함수인 선형 커널과 RBF 커널을 사용하였으며, Das et al.^[11]가 제안한 다중 커널을 함께 비교하였다. 이때, 다중 커널의 경우 세부 커널은 혼합 시퀀스 커널과 동일하게 사용하면서 시퀀스 비의존적 변수의 개념을 도입하지 않는 방식으로 구현되었다.

이러한 커널들을 이용한 지지기반벡터는 대표적인 지지기반벡터 라이브러리인 libsvm^[27]을 이용하여 구현되었다. 지지기반벡터에서 필요한 매개변수들은 libsvm이 제공하는 기본값을 사용하였으며, 시퀀스 의존적 이산 변수 커널에서 사용되는 시퀀스 패턴을 추출하기 위한 시퀀스 크기(w)는 동일하게 5로 지정하였다. 또한, 학습 데이터와 테스트 데이터의 구분은 k-fold 방식을 도입하여 총 8개의 시나리오 중 무작위로 선정된 6개의 시나리오에서 추출된 행위 데이터는 학습 데이터로 2개의 시나리오에서 추출된 행위 데이터는 테스트 데이터로 이용하였다.

본 실험에서 모델의 성능을 평가하기 위한 지표로 통계적 학습 기법 분야에서 전통적으로 사용되는 정확도(accuracy)를 도입하였다. 특히, 정확도는 인간 모델의 성능 평가 지표로 많이 사용되었으며^[4,28,29], 식 (14)를 통해 정확도를 계산한다.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (14)$$

여기서 TP , FN , FP , TN 은 각각 예측된 값과 실제 값이 모두 공격이 필요하다고 판단한 경우의 수(true positive), 공격이 필요 없다고 예측했으나 실제 공격이 필요하다고 판단한 경우의 수(false negative), 공격이 필요하다고 예측했으나 실제 공격이 불필요하다고 판단한 경우의 수(false positive), 예측된 값과 실제 값이 모두 공격이 불필요하다고 판단한 경우의 수(true negative)를 의미한다.

4.3 실험 결과

본 연구에서 제시하는 커널 함수인 혼합 시퀀스 커널을 이용한 조종사의 비동적 행위 모델의 성능을 평가하기 위해 두 번의 실험을 수행하였다. 첫 번째 실험에서는 다양한 종류의 시퀀스 벡터 사이즈 w 에 따른 혼합 시퀀스 커널의 성능을 측정하였고 이를 통해 모델의 성능을 극대화 시키는 최적의 w 값을 찾았다. 두 번째 실험은 혼합 시퀀스 커널의 상대적 성능을 평가하기 위해 기존에 제안된 다른 커널 함수들과의 성능을 비교하였다.

우선, 다양한 w 값에 따른 혼합 시퀀스 커널을 이용한 모델의 성능을 정리하면 Fig. 3과 같다. 총 10 종류의 5와 50 사이의 w 값을 실험에 사용하였는데, 모든 w 값에서 약 80% 이상의 정확도를 나타내었다. 특히, w 값이 10인 경우가 가장 우수한 성능인 94.7%의 정확도를 보였으며, 그 보다 작은 w 값에서나 w 값이 증가함에 따라 그 성능이 떨어지는 추세가 있었다. 이는 w 값이 커짐에 따라 시퀀스 의존적 연속 커널에서는 유사한 시퀀스 벡터의 발생이 줄어들 것이고, 반대로 시퀀스 의존적 이산 커널에서는 미리 주어진 시퀀스 패턴이 발생할 가능성이 증가하고, 실제 입력 상태 변수의 시점보다 멀리서 발생한 시퀀스 패턴의 발생 횟수가 포함되어 유사하지 않은 두 입력 벡터를 유사하다고 판단할 가능성이 증가하기 때문이다.




Fig. 3. Experiment results of HS kernel in terms of accuracy with various sizes of a sequence vector, w

다만, w 값이 45인 경우 전체 실험 결과 중 세 번째로 우수한 성능인 89.5%의 정확도를 나타내어 예외가 존재함을 보여주었다. 앞서 언급한 바와 같이, w 값이 커질 경우 시퀀스 의존적 이산 커널에서는 두 입력

벡터 간 유사도를 과대하게 판단할 가능성이 높아지지만, 변화 양상이 매우 적게 발생하는 상태 변수의 경우에는 큰 w 값은 빈도수가 낮은 변화 패턴을 유사도에 반영하는 데에 유리할 것이다. 즉, w 값이 45일 때, 특정 상태 변수가 보다 효과적으로 유사도를 계산할 수 있게 되었고 이것이 전체 커널 함수에 반영되어 모델의 성능이 개선되었을 것이다. 따라서 상태 변수 별로 다른 w 값을 이용하여 유사도를 계산한다면 더욱 높은 성능을 얻을 수 있을 것으로 기대된다.

다음으로, 혼합 시퀀스 커널(HS kernel)과 기존 커널, 다중 커널(multiple kernel), RBF 커널(RBF kernel), 선형 커널(linear kernel)의 성능을 비교하였다. Fig. 4는 실제 조종사의 행위와 혼합 시퀀스 커널 및 기존 커널들의 예측 행위를 주요 상태 변수와 함께 나타낸 그래프로, Fig. 4 (a)에서 1은 공격 확률을 높이는 판단, 0은 공격 확률을 낮추는 판단을 각각 의미한다. Fig. 4 (b)는

상태 변수 중 aim intensity, target distance, target speed difference를 표시하였다. 상태 변수의 시계열적 변화를 반영하는 혼합 시퀀스 커널과 다중 커널은 비교적 일정하게 행위 변수 값을 예측하는 반면에 한 시점의 상태 변수만을 반영하여 예측하는 RBF 커널과 선형 커널은 행위 변수 값이 계속적으로 변화하는 양상을 보였다. 또한, 모든 상태 변수의 시계열 패턴을 반영하는 다중 커널보다는 선별적으로 반영하는 혼합 시퀀스 커널이 조금 더 유연하게 변화하는 것을 확인할 수 있다. 상태 변수와 예측 값의 관계를 살펴보면 적기와의 거리가 가까워지고 속도 차이가 줄어드는 전투 상황에서는 공격 가능성을 계속 높이고 전투 상황이 종료되고 회피 기동을 수행하는 시점에서는 공격 가능성을 낮게 예측하는 것을 알 수 있다.

정확도와 학습 시간 측면에서 위의 결과를 비교하였다. 조종사의 비동적 행위 모델링은 조종사의 행위를

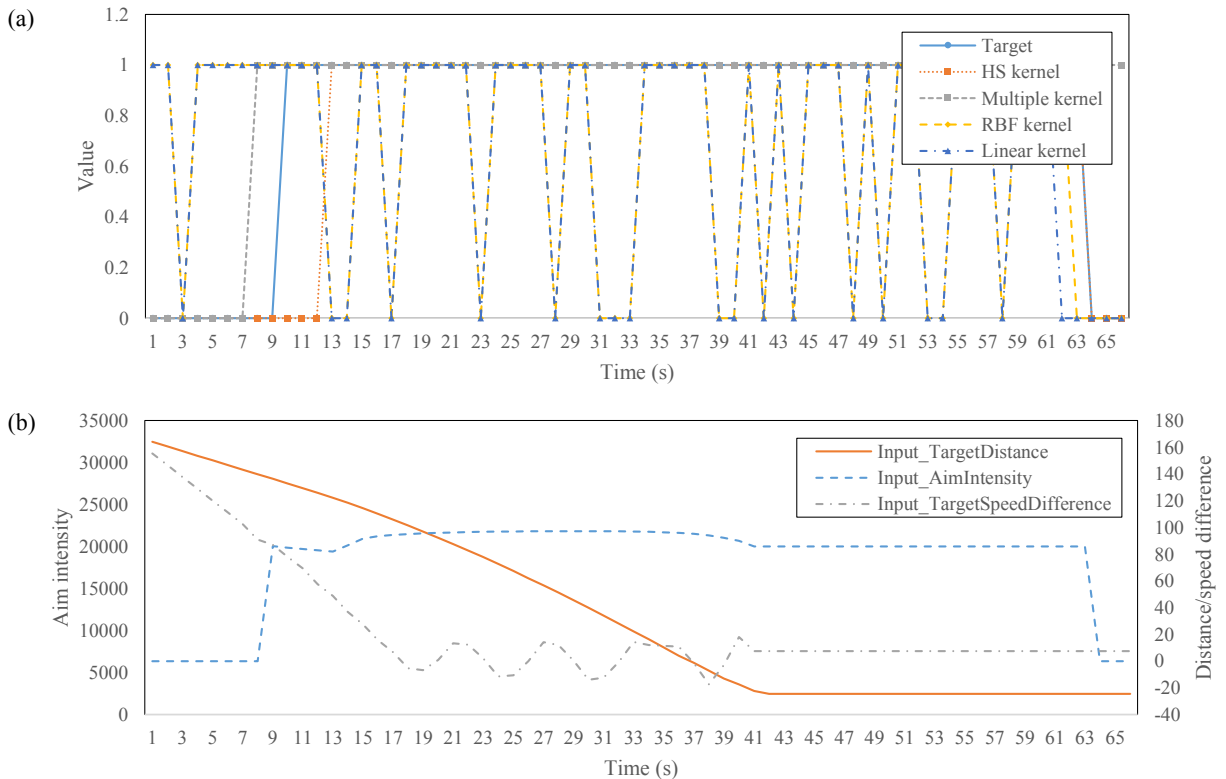


Fig. 4. Graphs comparing (a) pilot's actual behavior(target) with predicted behaviors by HS, multiple, RBF, and linear kernels according to (b) the values of three status features of aircraft, aim intensity, target distance, and speed difference

모사하는 것으로 정확도가 높을수록 좋은 성능을 나타낸다고 할 수 있다³⁰⁾. 또한, 사전에 모델을 학습시킨 후 사후에 예측을 수행하므로 학습 시간은 상대적으로 덜 중요하며 예측 시간은 학습 시간 대비 무시할 만하다고 알려져 있다³¹⁾. 하지만 모델의 사용 목적에 따라 잦은 학습이 필요하거나 학습 후 짧은 시간 내에 예측 수행이 필요한 경우에 긴 학습 시간은 문제가 될 수 있다. 즉, 예측 모델의 평가에서 정확도가 가장 중요한 지표이지만, 높은 정확도가 보장된 경우 학습 시간은 빠를수록 좋고, 사용 목적을 달성할 수 없는 수준의 긴 학습 시간은 모델의 치명적 단점이 된다.

Table 5는 정확도와 학습 시간을 기준으로 한 비교 실험 결과를 나타낸다. 혼합 시퀀스 커널은 학습 시간 측면에서는 선형 커널이나 RBF 커널에 비해 약 8배의 시간이 소요되었지만, 정확도 측면에서는 10% 이상 개선된 성능을 나타내었다. 혼합 시퀀스 커널의 학습 시간은 약 6분 정도로 사전에 학습이 이루어질 조종사 행위 모델에서는 허용될 만한 수준이다. 또한 다중 커널 역시도 선형 커널과 RBF 커널에 비해서는 낮은 정확도를 보여주었다. 즉, 상태 변수의 유사도 측정에 있어서, 주어진 상태 변수 값으로 구성된 입력 벡터뿐 만 아니라 추가적으로 해당 변수에서 선행하는 값들을 고려하는 것이 성능 향상에 도움이 되었다는 것을 나타낸다.

Table 5. Performance of HS kernel with $w = 10$, Das kernel, RBF kernel, and linear kernel in terms of accuracy and training time

Model	Accuracy	Time(s)
HS kernel ($w = 10$)	0.947	391
Multiple kernel ($w = 10$)	0.859	1,008
RBF kernel	0.849	81
Linear kernel	0.827	53

정확도와 학습 시간의 두 가지 측면 모두에서 혼합 시퀀스 커널은 다중 커널에 비해 우월한 결과를 나타내었다. 학습 시간에서의 성능 향상은 혼합 시퀀스 커널이 시퀀스 비의존적 변수의 개념을 도입함으로써 해당 변수에 속하는 입력 벡터의 유사도 계산에서 필요

한 학습 시간을 줄일 수 있다는 점에서 자명하다. 하지만 정확도 측면에서도 다중 커널 대비 혼합 시퀀스 커널이 좋은 성능을 보였다는 것은 모든 상태 변수에서 선행하는 변수 값들을 고려하는 것보다는 오히려 특정 상태 변수는 해당 시점의 변수 값만을 고려하는 것이 유리하다는 것을 의미한다.

5. 결론 및 향후 연구

본 연구에서는 시퀀스 비의존적 변수 커널, 시퀀스 의존적 연속 변수 커널, 시퀀스 의존적 이산 변수 커널, 세 커널의 가중합으로 정의되는 혼합 시퀀스 커널을 제안한다. 이러한 혼합 시퀀스 커널을 이용한 지지기반벡터를 통해 조종사의 비동적 행위를 모델링한다. 국방과학연구소 관급 전투 시뮬레이터에서 추출된 로그 데이터를 이용하여 수행한 실험에서 혼합 시퀀스 커널은 우수한 성능을 보여주었으며, 선형 커널, RBF 커널과의 성능 비교를 통해 선행하는 변수 값들을 이용한 유사도 계산의 유효성이 밝혀졌다. 특히, 다중 커널과의 비교에서는 시퀀스 비의존적 변수의 도입이 정확도와 학습 시간의 두 가지 측면 모두에서 성능 향상을 가져올 수 있다는 것을 보여줬다.

항공기에서 발생하는 다양한 신호 데이터들은 상호 영향을 주고받으며 발생하므로 효과적인 실제 상황에 적용되기 위해서는 이에 대한 고려가 필요하다. 하지만 본 논문에서는 문제 복잡도를 낮추고 핵심 아이디어에 집중하기 위해 상태 변수들 간 독립을 가정하였다. 따라서 추후연구로써 상태 변수간의 종속성을 고려한 커널 함수 개발을 진행해 볼 수 있을 것이다.

후 기

본 연구는 국방과학연구소의 연구비 지원 하에 인건 판단 모의 기법 기술 과제 일부로서 수행되었음.

References

- [1] Park, S., Shin, H., Lee, T. and Choi, B., "Design of the Agent-based Network-Centric Warfare Modeling System," Journal of the Korea Society for Simulation,

- Vol. 19, No. 4, pp. 271~280, 2010.
- [2] Gunetti, P., Thompson, H. and Dodd, T., "Autonomous Mission Management for UAVs uSing Soar Intelligent Agents," *International Journal of Systems Science*, Vol. 44, No. 5, pp. 831~852, 2011.
- [3] Kim, S. J. and Choi, B. W., "A Study on the Wargame System Development Plan for ROK Army," *Korea Association of Defense Industry Studies*, Vol. 17, No. 2, pp. 200~227, 2010.
- [4] Choi, Y., Kwon, N., Yoon, J., Park, J., Lee, H., Kim, Y., Kim, S. and Shin, D., "A BCI Based Ground Control Framework for Attention Maintenance of UAV Operators," *Entrue Journal of Information Technology*, Vol. 12, No. 1, pp. 101~115, 2013.
- [5] Perhinschi, M. G. and Smith, B., "Preliminary Analysis of Parameters for Pilot Fatigue Detection Based on Aircraft States Measurements," *Proceedings of the AIAA Modeling and Simulation Technologies Conference*, pp. 1~7, 2007.
- [6] Mrcruer, D. T. and Jex, H. R., "A Review of Quasi-Linear Pilot Models," *IEEE Transactions on Human Factors in Electronics*, Vol. 8, No. 3, pp. 231~249, 1967.
- [7] Gunetti, P., Dodd, T. and Thompson, H., "Simulation of a Soar-Based Autonomous Mission Management System for Unmanned Aircraft," *Journal of Aerospace Information Systems*, Vol. 10, No. 2, pp. 53~70, 2013.
- [8] Jones, R. M., Laird, J. E., Nielsen, P. E., Coulter, K. J., Kenny, P. and Koss, F. V., "Automated Intelligent Pilots for Combat Flight Simulation," *AI Magazine*, Vol. 20, No. 1, pp. 27~42, 1999.
- [9] Ionita, S. and Sofron, E., "The Fuzzy Model for Aircraft Landing Control," *Lecture Notes in Computer Science*, Vol. 2275, pp. 47~54, 2002.
- [10] Cho, M. and Baek, J., "One-Class Classification Based Fault Classification for Semiconductor Process Cyclic Signal," *IE Interfaces*, Vol. 25, No. 2, pp. 170~177, 2012.
- [11] Das, S., Matthews, B. L., Srivastava, A. N. and Oza, N. C., "Multiple Kernel Learning for Heterogeneous Anomaly Detection: Algorithm and Aviation Safety Case Study," *Proceedings of the ACM International Conference on Knowledge Discovery and Data Mining*, pp. 47~56, 2010.
- [12] Kim, K., Chung, B., Choi, Y., Lee, S., Jung, J. and Park, J., "Language Independent Semantic Kernels for Short-Text Document Classification," *Expert Systems with Applications*, Vol. 41, No. 2, pp. 735~743, 2014.
- [13] Chung, P. C. and Liu, C. D., "A Daily Behavior Enabled Hidden Markov Model for Human Behavior Understanding," *Pattern Recognition*, Vol. 41, No. 5, pp. 1572~1580, 2008.
- [14] Ping, G. and Zhenjiang, M., "Multi-Person Activity Recognition Through Hierarchical and Observation Decomposed HMM," *Proceedings of the IEEE International Conference on Multimedia and Expo*, pp. 143~148, 2010.
- [15] Lee, K. K., Yu, M. and Xu, Y., "Modeling of Human Walking Trajectories for Surveillance," *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems*, Vol. 2, pp. 1554~1559, 2003.
- [16] Yulan, L., Reyes, M. L. and Lee, J. D., "Real-Time Detection of Driver Cognitive Distraction Using Support Vector Machines," *IEEE Transactions on Intelligent Transportation Systems*, Vol. 8, No. 2, pp. 340~350, 2007.
- [17] Vapnik, V., *The Nature of Statistical Learning Theory*, Springer-Verlag, 1995.
- [18] Baek, J.-G., Kim, C.-O. and Kim, S.-S., "Multi-Interval Discretization of Continuous-Valued Attributes for Constructing Incremental Decision Tree," *Journal of the Korean Institute of Industrial Engineers*, Vol. 27, No. 4, pp. 394~405, 2001.
- [19] Bach, F. R., Lanckriet, G. R. G. and Jordan, M. I., "Multiple Kernel Learning, Conic Duality, and the SMO Algorithm," *Proceedings of the International Conference on Machine Learning*, pp. 6~13, 2004.
- [20] Leslie, C., Eskin, E. and Noble, W. S., "The Spectrum Kernel: A String Kernel for SVM Protein Classification," *Proceedings of the Pacific Symposium on Biocomputing*, pp. 566~575, 2002.

- [21] Scholkopf, B. and Smola, A. J., Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond, MIT Press, 2002.
- [22] Bailer, W., "Learning Multiple Sequence-Based Kernels for Video Concept Detection," Proceedings of the IEEE International Symposium on Multimedia, pp. 73~77, 2012.
- [23] Senechal, T., Rapp, V., Salam, H., Seguiet, R., Bailly, K. and Prevost, L., "Facial Action Recognition Combining Heterogeneous Features via Multikernel Learning," IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, Vol. 42, No. 4, pp. 993~1005, 2012.
- [24] Lee, Y., Lee, S., Lee, s. and Park, J., "A Tag-Based Similarity Computation Method Using Multiple Term Mapping in Vector Space Model," Telecommunications Review, Vol. 19, No. 4, pp. 655~665, 2009.
- [25] Shawe-Taylor, J. and Cristianini, N., Kernel Methods for Pattern Analysis, Cambridge University Press, 2004.
- [26] Burges, C. C., "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, Vol. 2, No. 2, pp. 121~167, 1998.
- [27] Chang, C. and Lin, C., "LIBSVM: A Library for Support Vector Machines," ACM Transactions on Intelligent Systems and Technology, Vol. 2, No. 3, pp. 1~27, 2011.
- [28] Isoda, Y., Kurakake S. and Nakano H., "Ubiquitous Sensors Based Human Behavior Modeling and Recognition Using a Spatio-Temporal Representation of User States," Proceedings of the IEEE International Conference on Advanced Information Networking and Applications, Vol. 1, pp. 512~517, 2004.
- [29] Ziebart, B., Maas, A., Bagnell, A. and Dey, A., "Human Behavior Modeling with Maximum Entropy Inverse Optimal Control," Proceedings of the AAAI Spring Symposium: Human Behavior Modeling, pp. 92~97, 2009.
- [30] Pentland, A. and Liu A., "Modeling and Prediction of Human Behavior," Neural computation, Vol. 11, No. 1, pp. 229~242, 1999.
- [31] Roqueiro, D. and Petrushin V., "Counting People Using Video Cameras," The International Journal of Parallel, Emergent and Distributed Systems, Vol. 22, No. 3, pp. 193~209, 2007.