

Stacked 오토엔코더 기반 승마보법의 분류

이재능¹, 궤근창^{2*}
^{1,2}조선대학교 제어계측공학과
 *e-mail:kwak@chosun.ac.kr

Classification of Horse Gaits Based on Stacked Auto-Encoder

Jae-Neung Lee¹, Keun-Chang Kwak^{2*}

^{1,2} Department of Control and Instrumentation Engineering, Chosun University

요 약

본 논문에서는 실 승마 코칭을 수행하기 위해 Stacked 오토엔코더를 이용한 승마 보법을 분류하고자 한다. Staked Auto-encoder(SAE)에서 은닉층 수를 조절하여 승마데이터에 적합하게 쌓고, 성능을 비교하고 은닉층의 수를 수정한다. 데이터베이스 구축 환경은 16개의 관성센서로 이루어진 무선 네트워크로 구성된 슈트를 착용하고 국가대표급 승마 전문가로부터 데이터베이스를 취득한다. DB를 이용하여 보법별(평보, 속보, 경속보, 구보)로 각각 특징들(볼기 y축 포지션, 허리각도)을 이용하여 보법분류를 한다. 구축된 승마 모션데이터로 실험한 결과, 은닉층의 수가 1층일 때 성능은 95%를 보여주었고 은닉층의 수가 2층일 때 94%의 성능을 나타내었다.

1. 서론

본 논문에서는 사용자 맞춤 코칭을 하기 위해 승마 보법분류를 하고, 자세교정을 위해 사용자의 자세를 파악하여 코칭을 하는데 목적이 있다. 국내의 관성센서기반 코칭 연구사례는 셀프-코칭을 위한 관성센서 기반 인체모션 취득 시스템 구현[1], 관성센서를 이용한 알파인 스노보드 선수 활강 자세의 운동학적 변인 분석[2], 스포츠 동작분석을 위한 모션캡처시스템의 동향분석[3]을 연구했다. 국외에서는 Chan[4]은 코칭을 위해 댄싱 훈련 시스템을 개발하였고, 동작분석기법을 활용한 골프코칭시스템 개발[5], 무선 관성센서를 사용하여 운동학적 코칭 분석[6], 테니스 스트로크 분류[7], 골프 훈련시스템[8]을 개발하였다. 국외 오토엔코더의 관련연구로는 영상처리, 신호처리에 주로 적용이 된다. 영상처리분야에서는 눈 위치 예측[9], 인공위성 이미지를 이용한 요약설명[10], 커널 오토엔코더[11], 차원 축소[12], 유방암 검출, 신호처리로는 고장진단, 과전압 검출[13]등이 연구되어졌다. 본 논문에서는 실 승마 사용자 맞춤 코칭을 하기 위해 관성센서기반의 구성된 슈트를 착용하고 승마 전문가의 DB를 통해서 말의 종류별(제주마, 더리브렛, 웹블러드)과 보법별(평보, 속보, 경속보, 구보)로 각각 특징(볼기 y축 포지션, 허리각도)을 통해 말의 보법을 분류한다. 말의 보법이 분류가 되면 보법에 따라 특징(팔각도, 무릎각도, 무릎간거리, 허리각도)에 기반 사용자와 전문가의 특징 점들의 차이를 분석한다. 분석된 자료에 의존함으로써 오디오 형태로 현재 사용자에게 코칭을 해주는데

목적이 있다. 본 논문의 구성은 다음과 같다. 2절에서는 오토엔코더의 이론적 배경에 대해 설명한다. 3절에서는 데이터베이스 구축환경 및 실험결과에 대해 다룬다. 4절에서 결론을 나타낸다.

2. 관련연구


2.1 오토엔코더

오토엔코더는 전형적인 Feedforward Neural Networks(FNN)이다. 데이터를 압축적이고 분배된 표현(인코딩)으로 학습하는 것이다. 입력 벡터는 $x \in [0, 1]^D$ 이고, 은닉층 $y \in [0, 1]^D$ 이고, 결정론적 맵핑은 $y = f_{\theta}(x) = s(Wx + b)$ 에 의해 정의된다. 여기서 $\theta = W, b$ 의 모수이고, W 는 $d \times D$ 의 가중치 행렬이며, b 는 바이어스 벡터이다. 손실함수는 식 1과 같이 정의 된다.

$$\theta^* = \operatorname{argmin} \frac{1}{N} \sum_{i=1}^n L(x^{(i)}, z^{(i)}) \quad (1)$$

2.2 Stacked 오토엔코더

Stacked 오토엔코더가 오토엔코더와 다른 점은 DBN(Deep Belief network)의 구조를 사용하는 것이다. 2.1 절에서 언급한 오토엔코더는 역전파를 활용하여 가중치를 학습한다. 하지만 레이어와 노드의 개수가 많아지면 가중치를 학습하는데 방대한 계산량과 지역 최적해(local minimum)에 빠질 위험이 존재한다. 그림 1은 Staked 오토엔코더의 구조를 보여준다.



(그림 1) Stacked 오토 엔코더 구조

3. 실험 및 결과


3.1 데이터베이스

관성센서 기반인 모션캡처슈트를 승마전문가가 착용을 한 후 보법별로 데이터를 취득한다. 실험에 사용된 말은 제주마, 더러브렛, 웹블러드이며, 보법분류를 위해 사용된 센서 데이터는 볼기 y축 값으로 사용했다. 승마는 엉덩이의 위치가 보법에 따라 움직임의 변화가 있으며, 데이터로 사용하기에 적절하다고 판단되어 볼기 y축 좌표값, 허리 각도데이터를 사용하였다. 두 개의 데이터를 이용하여 최소값, 최대값, 평균값을 추출하고 총 6차원의 데이터베이스를 구축하였다. 실험은 학습데이터 60% 검증데이터 40%로 하였다. 표 1은 승마 데이터베이스의 정보를 보여준다.

<표 1> 승마데이터

보법	평보	경속보	좌속보	구보	합계
데이터 크기	500×6	500×6	500×6	500×6	2000×6

승마 볼기데이터, 허리각도를 이용하여 최소값, 최대값, 평균값을 추출한다. 아래 그림 2는 데이터에서 최소, 최대, 평균값을 추출한 100프레임 데이터를 보여준다.




(그림 2) 승마데이터


3.2 실험

실험에 사용한 알고리즘은 오토엔코더와 Stacked 오토엔코더를 이용하였다. 오토엔코더 가중치는 0.001이다. 두 번째 오토엔코더 가중치는 0.0001이다. 기존의 연구된 보법 분류[14]와의 차이점은 데이터의 특징과 크기, 알고리즘이

다. 본 논문에 사용된 데이터는 6차원 2000개의 데이터를 사용하였다. 기존의 가장 우수한 ANFIS(Adaptive neuro fuzzy inference system)분류기를 이용한 분류율이 91%로 4% 낮은 성능을 보여주었다. 따라서 오토엔코더를 이용한 결과 4%향상된 성능을 보여준다. 그림 3은 오토엔코더의 구조를 보여준다. 입력벡터는 6개, 엔코더의 차원은 15차원 소프트웨어의 차원은 4차원이고 분류를 통해 얻은 출력 벡터는 4차원이다. 그림 4는 Stacked 오토엔코더의 구조를 보여준다.



(그림 3) (오토엔코더 구조)



(그림 4) (Stacked 오토엔코더 구조)

실험의 정확성을 위해 10번 반복하였고, 분류율을 나타내었다. 표 2는 오토엔코더를 사용하고, 은닉노드의 수에 따른 분류율 및 소요시간을 보여준다. 성능을 위해 히든노드수와 가중치를 조절하여 성능을 최적화 하였다. 표 3은 Stacked 오토엔코더를 사용하고, 은닉 노드에 따른 분류율 및 소요시간을 보여준다. 그림 5은 오토엔코더 분류율, 그림 6는 Stacked 오토엔코더의 분류율을 혼동행렬로 나타낸 것이다.

	혼동 행렬				
	평보	경속보	좌속보	구보	합계
평보	194 24.3%	0	0	0	100%
경속보	4 0.5%	189 23.6%	6 0.8%	0	95.5% 5.0%
좌속보	0	6 0.8%	182 22.8%	7 0.9%	93.3% 6.7%
구보	2 0.3%	5 0.6%	12 1.5%	193 24.1%	91.0% 9.0%
합계	97.0% 3.0%	94.5% 5.5%	91.0% 9.0%	96.5% 3.5%	94.8% 5.2%
	구보	경속보	좌속보	구보	합계

(그림 5) (오토엔코더 분류율)

혼동 행렬					
평보	192 24.0%	0	0	0	100%
경속보	8 1.0%	189 23.6%	9 1.1%	1 0.1%	91.3% 8.7%
좌속보	0	7 0.9%	173 21.6%	2 0.3%	95.1% 4.9%
구보	0	4 0.5%	18 2.3%	197 24.6%	90.0% 10.0%
합계	96.0% 4.0%	94.5% 5.5%	86.5% 13.5%	98.5% 1.5%	93.9% 6.1%
	구보	경속보	좌속보	구보	합계

(그림 6) (Stacked 오토엔코더 분류율)

<표 2> 오토엔코더 성능

실험차수/ 구분	1번째 오토엔코더 은닉 노드수	분류율	소요시간 (초)
1	4	93.5	38.1
2	10	94.3	48.3
3	15	94.9	56.1

<표 3> Stacked 오토엔코더 성능

실험차수/ 구분	1번째 오토엔코더 은닉 노드수	2번째 오토엔코더 은닉 노드수	분류율	소요시간 (초)
1	2	2	92.6	31.1
2	3	3	94.4	36.2
3	4	4	80.3	44.1

4. 결론

본 논문은 오토엔코더기반의 승마데이터 기반 보법 분류를 한다. 기존의 오토엔코더를 사용했을 때, 분류율 95%, 2층으로 쌓았을 때 분류율 94%를 나타내었다. 실 승마 보법분류를 하기 위해 처리시간이 빠른 Stacked 오토엔코더를 사용하고 보법에 맞게 실시간 자세 코칭이 이루어져야 한다. 31초의 소요시간은 보법을 판단하기에 많은 시간이기 때문에 10초 이내로 줄이는데 차후 목표이다.

참고문헌

[1] 고경리, 배성봉, 최장식. “셀프-코칭을 위한 관성센서 기반 인체모션 취득 시스템 구현”, 『한국정보기술학회 한국정보기술학회논문지』 제12권 제4호, 2014. pp.171-179.
 [2] 남기정. “관성 센서를 이용한 알파인 스노보드 선수 활강 자세의 운동학적 변인 분석”, 『제16회 운동학 학술대회』 제2015권 제5호, 2015. pp.138-138.
 [3] 변영현, 이명원, 곽근창. “스포츠 모션분석을 위한 모션 캡처시스템의 동향분석”, 『한국정보기술학회논문지』 제11권, 제5호, 2013. pp.191-201.

[4] Chan. J, Leung. H, Tang. J, Komura. T. “A virtual reality dance training system using motion capture technology”, IEEE Transactions on Learning Technologies. Vol.4 No.3, August 2011. pp.187-195.
 [5] Lim. S. J, “A development of golf coaching using human motion analysis”, KSMS. Vol.15 No.2, June 2013. pp.55-61.
 [6] Cheng. L, Hailes. S, “Analysis of wireless inertial sensing for athlete coaching support”, global telecommunications conference. Dec 2008. pp.1-5.
 [7] D. Connaghan, P. Kelly, M. Gaffney, M. Walsh, C. Mathuna, “Multi-sensor classification of tennis strokes”, IEEE trans. Sensors. Oct 2011. pp.1437-1440.
 [8] Burchfield. R, Venkatesan. S, “A framework for golf training using low-cost inertial sensors”, IEEE International Conference on Body Sensor Networks. June 2010. pp.267-272.
 [9] J. Han, D. Zhang, S. Wen, L. Guo, T. Liu, “Multi-Sensor classification of tennis strokesMulti-Sensor classification of tennis strokes”, IEEE Transactions on Cybernetics. Vol.46 No.2, February 2015. pp.487-498.
 [10] X. Yao, J. Han, “Semantic annotation of high-resolution satellite images via weakly supervised learning”, IEEE Transactions on Geoscience and Remote Sensing, Vol.54 No.6, June 2015. pp.487-498.
 [11] M. L, J. Wang, Y. Cao, J. Sun, “Deep learning of transferable representation for scalable domain adaptation”, IEEE Transactions on Knowledge and Data Engineering. Vol.99 No.99, April 2016. pp.1-14.
 [12] G. E. Hinton. R. R. Salakhutdinov. “Reducing the dimensionality of data with neural networks”, SCIENCE. Vol.313 No.5786, July 2006. pp.504-507.
 [13] K. Chen, J. Hu, J. He, “A framework for automatically extracting overvoltage features based on sparse autoencoder”, IEEE Transactions on Smart Grid Vol.99 No.99, July 2016. pp.1-11.
 [14] J. N. Lee, M. W. Lee, Y. H. Byeon, W. S. Lee, K. C. Kwak. “Classification of horse gaits using FCM-based neuro-fuzzy classifier from the transformed data information of inertial sensor”, Sensors. Vol.16 No.664, May 2016. pp. 664-681.