실시간 휴먼 시뮬레이션을 위한 깊이 카메라 기반의 자세 판별 및 모션 보간

이진원 · 한정호 · 양정삼[†]

아주대학교 산업공학과

Depth Camera-Based Posture Discrimination and Motion Interpolation for Real-Time Human Simulation

Jinwon Lee, Jeongho Han, and Jeongsam Yang[†]

Department of Industrial Engineering, Ajou University

Received 25 October, 2013; received in revised form 8 January, 2014; accepted 9 January, 2014

ABSTRACT

Human model simulation has been widely used in various industrial areas such as ergonomic design, product evaluation and characteristic analysis of work-related musculoskeletal disorders. However, the process of building digital human models and capturing their behaviors requires many costly and time-consuming fabrication iterations. To overcome the limitations of this expensive and time-consuming process, many studies have recently presented a markerless motion capture approach that reconstructs the time-varying skeletal motions from optical devices. However, the drawback of the markerless motion capture approach is that the phenomenon of occlusion of motion data occurs in real-time human simulation. In this study, we propose a systematic method of discriminating missing or inaccurate motion data due to motion occlusion and interpolating a sequence of motion frames captured by a markerless depth camera.

Key Words: Human simulation, Locally linear embedding (LLE), Motion interpolation, Posture discrimination, Support vector machine (SVM)

1. 서 론

많은 산업현장에서는 3D 휴먼모델을 이용한 동작 분석을 통해 작업 현장에서 발생할 수 있는 안전사고에 대한 예측과 작업자의 근골격계 질환에 영향을 주는 위험요인을 분석하고 있다. 또한 제품 생산공정에서 작업자의 자세 분석과 공정 상의 작업성 평가를 통해 최적화된 공정 레이아웃 설계

와 작업 사이클 단축을 실현할 수 있다. 그러나 휴먼 시뮬레이션을 실행하기 위해서는 3차원 공간 상에서 인간의 움직임과 동일한 자유도로 휴먼모델의 자세를 정의하고 조정하는 과정이 선행되는데, 이 과정은 시뮬레이션 환경 구축에 소요되는 시간의 70% 이상을 차지하고 있다.

휴먼 시뮬레이션 환경 구축에 많은 노력이 요구되고 있는 상황에서, 최근에는 모션 캡처 장비를 통해 실시간으로 측정된 인체의 모션 데이터를 휴먼모델에 반영하여 자연스러운 동작을 생성하는 연구가 진행되고 있다. 모션 캡처 방식은 인체의

[†]Corresponding Author, jyang@ajou.ac.kr
©2014 Society of CAD/CAM Engineers

주요 위치에 센서 또는 마커를 부착시켜 위치와 회전 데이터를 획득한 후 모션 데이터 집합(Motion data set)으로 만드는 마커(Marker) 기반의 방식과 인체에 마커를 부착하지 않고 카메라와 같은 광학적 도구를 활용하여 동작의 실루엣 해석을 통해 모션을 복원하는 마커리스(Markerless) 기반의 방식이 있다. 특히 마커리스 방식은 마커 방식에 비해 모션 데이터의 정밀도가 낮고 휴먼모델과의 실시간 연동에 기술적으로 어려운 단점이 있지만, 주변 환경에 대한 제약과 인체 동작의 제한을 최소화한 상태에서 자연스런 모션 데이터를 획득할 수 있기 때문에 산업 현장에서의 요구는 높아지고 있다.

마커리스 기반의 카메라를 이용하여 모션 데이터를 획득하기 위해서는 영상 처리를 통해 모션 데이터를 획득할 수 있는 인체의 실루엣을 명시한 후 깊이 측정이 가능한 적외선 센서를 이용하여 카메라와 인체 사이의 깊이 데이터를 측정하는 것이 필요하다. 또한, 작업자가 취하고 있는 특정 자세의 주요 관절 정보에 대한 연산과정이 수반된다. 그러나, 자세를 판단하는 과정에서 주변 장애물에 의해 또는 중첩된 관절에 의해 모션이 가려지는 폐색현상과 작업자의 빠른 동작으로 인해 모션 캡처 과정에서 측정되지 않거나 부정확한 모션 데이터가 발생하는 경우에는 작업자의 자세를 정확히 판단하는 것이 불가능해진다. 부정확한 모션 데이터가 발생하는 경우를 줄이기 위하여 작업자의 자세가 장애물에 가려지지 않는 위치에 깊이 카메라를 배치하여 부정확한 데이터를 줄인다. 또한, 깊이 카메라의 위치가 인체의 전신을 찾지 못하는 경우 일부 관절데이터가 손실되므로 최적의 위치에 깊이 카메라를 배치한다. 만약 부정확한 모션데이터가 발생했을 때 작업자의 관절데이터를 인체모델에 적용했을 시에 인체모델이 작업자의 자세와 다른 자세를 표현하게 되고, 이를 다시 수작업으로 원하는 자세로 모델링 하는데 많은 시간이 걸린다. 이러한 문제점을 극복하기 위하여 본 논문에서는 표준 자세 템플릿을 정의한 후, 이를 시스템 상에 학습시켜 자세를 판별할 수 없는 부정확한 데이터가 카메라로부터 출력될 경우에 해당 데이터를 저 차원화 과정을 수행한 후 표준 자세 템플릿과 매칭시키는 연구를 수행한다. 이러한 과정에서 카메라와 인체 사이에 측정된 깊이 데이터는 휴먼모델에 직접 적용하기에는 데이터의 양이 크기 때문에 효과적인 연산을 수행하기 위해

서 대표적인 비선형 차원 축소 방법의 하나인 LLE(Locally linear embedding)을 이용하여 저 차원화 과정을 수행한다. 저 차원으로 변환된 모션 데이터는 SVM(Support vector machine)을 사용하여 서있는 자세, 상체를 숙인 자세, 앉아 있는 자세, 엎드린 자세로 분류한 후, 자세를 판별할 수 없었던 부정확한 관절 데이터를 미리 정의한 표준 자세 템플릿 모델의 관절 데이터와 대체함으로써 정확한 데이터가 출력될 수 있도록 한다.

2. 관련연구

2.1 상업용 휴먼 시뮬레이션

닷소시스템의 DELMIA Human Builder^[1]에서는 인체모델이 어깨, 손, 척추, 목 등을 포함한 총 99개의 독립적인 링크 정보와 104개의 인체 측정학적 변수로 정의되어 있다. Human Builder에 연동되는 Human Activity Analysis를 이용하여 들기, 놓기, 운반, 밀기, 당기기와 같은 움직임뿐 만 아니라 RULA(Rapid upper limb assessment)에서 제시된 작업자세로 인한 작업부하를 평가할 수 있다. 한편, 최근에 닷소시스템의 제품 군에 포함된 Safework Pro는 100개의 링크, 148개의 자유도를 통해 들기, 놓기, 운반하기, 밀기, 당기기에 대한 효율을 측정하여 밸런스 계산과 RULA분석이 가능하다. 또한 대상 집단에 대한 인체 모델을 생성 시 다항 통계 알고리즘(Multinomial statistical algorithm)을 사용하여 휴먼모델의 각 관절에 대한 변수들을 자동으로 조정할 수 있다.

작업자 집단을 대상으로 작업 공정을 최적화하는데 사용되는 지멘스의 Tecnomatix Human Product^[2]는 부상 위험, 사용자 안락함, 작업 도달 가능 거리, 시야, 에너지 소모, 피로 제한과 같은 인간공학 관점에서 안전도를 평가할 수 있다. 특히, 인체 모델링 도구인 Classic Jack 모듈은 68개의 관절로 휴먼모델을 구성하며, 동작 제어를 위해 두 자세간의 관절 위치를 보간하는 방법과 구속 기반 동작 방법이 사용되고 있다. 또한 정확한 자세 정의를 위해 자유도 감쇠 방법을 사용한다. 한편, 다양한 CAD 응용프로그램과 연동하여 사용되고 있는 PTC의 Manikin Extension^[3]은 제품과 사람간의 연관성을 파악할 수 있는 인체공학적인 동작 요소를 분석할 수 있다. 특히, 들어올리기, 내리기, 밀기, 당기기, 옮기기 등을 포함한 작업 분

석을 위한 표준 알고리즘을 포함하고 있으며, 자세를 움직이고 저장한 자세 및 분석 설정 방법을 재사용할 수 있어 인체 모델링을 보다 신속하게 한다.

Human Solution 센터에서 개발한 RAMSIS^[4]는 자동차 생산공정에 필요한 인체의 영향 및 안락감 평가를 위해 컴퓨터 시뮬레이션에 활용되고 있다. RAMSIS의 인체모델은 54개의 관절과 104개의 자유도로 표현되며 자동차 내장에 대한 초기 설계 단계에서 시야성 분석과 도달 자세에 따른 안락거리 분석과 같은 인간 공학적 평가를 위한 동적 해석에도 적용되고 있다. 또한, 우주 항공, 선박 산업에서 조립 및 유지보수 업무 분석에 적용한 보잉의 BHMS(Boeing human modeling system)^[5]는 인체모델을 24개의 척추 링크와 105개의 몸체 관절로 구성하며, 105개의 인체 측정요소로 구분하고 대화식으로 휴먼모델을 구성하여 시뮬레이션에 적용할 수 있다. 이때, 인체 모델은 시야, 충돌 탐지, 역 기구학 알고리즘을 지원한다.

범용적인 목적으로 개발된 상업용 휴먼 시뮬레이션 소프트웨어는 휴먼모델을 각각의 관절 단위로 값을 조정하여 모델링 하는 단순 작업의 반복으로 진행되기 때문에 시뮬레이션 환경을 구성하는 과정에서 작업자의 피로도는 매우 높게 발생된다. 따라서 손쉽게 모델링을 할 수 있는 새로운 방법이 필요하다.

2.2 모션 캡처 방식 및 자세 분류

Deutscher와 Reid^[6]은 마커로부터 측정된 위치 정보와 색상을 처리하여 30개의 자유도가 있는 인체 모델을 대상으로 시뮬레이션을 수행하였으며, Zordan과 Hodgins^[7]는 마커 기반의 모션 캡처 장비로부터 획득된 다수의 스포츠 동작에 대해 관절 간의 충돌 실험과 운동학적 요소를 파악한 후 피 실험자의 동작과 비교하는 연구를 수행하였다. Kang과 Sohn^[8]은 온톨로지를 활용하여 휴먼시뮬레이션의 작업환경 구축 및 적응성에 대해 연구하였다. Cha *et al.*^[9]은 가상현실 네비게이션의 위한 보행 이동 시스템에서 사람의 움직임을 파악하기 위해 깊이 카메라를 활용하였다. Izadi *et al.*^[10]은 깊이 카메라를 활용하여 실내의 환경에 대한 오브젝트들을 3D 환경에서의 데이터로 추출하였다. Wilson^[11]은 깊이 카메라를 활용하여 사물에 대상이 닿았는지 판단하는 터치 센서의 기능을 구현하였다. Biswas와 Veloso^[12]는 실내 환경을 깊이 카

메라를 활용하여 3차원 점 군(Cloud point)를 추출한 후 실내 환경을 구축하여 구성 객체를 파악하였다.

Corazza *et al.*^[13]은 마커리스 기반의 모션 캡처 장비를 사용하여 인체의 움직임을 Visual Hull 기법을 통해 파악하였고, 33개의 자유도가 있는 인체 모델의 시뮬레이션을 수행했다. Cucchiara *et al.*^[14]은 인체의 자세를 판단하기 위한 모션 캡처 과정에서 다수의 카메라를 적용하였을 때 발생할 수 있는 모션 데이터의 폐색현상을 개선하는 방법을 제시하였다. Ri *et al.*^[15]은 마커리스 모션 캡처 장비로 작업자의 자세 분석을 통한 근골격계 질환을 예방하기 위해 사람의 동선을 파악하고, 뼈대 정보를 통해 PTS(Predetermined time standard)를 구현하려는 시도가 있었다. 그러나, 이들 연구의 대부분은 제시된 방법에 대한 이론적인 검증에 목적을 두고 있었기 때문에 휴먼모델의 부드러운 동작을 재연하는 데에는 한계가 있다.

Kim^[16]은 모션 캡처 장비를 이용하여 반사 마커가 부착된 인체의 얼굴로부터 모션 데이터를 획득한 후, 비선형 매니폴드 학습인 Isomap 알고리즘을 통해 차원을 감소시켜 얼굴 표정을 종류별로 분류하는 연구를 수행하였다. Lee *et al.*^[17]는 영상 데이터로부터 동작상태, 이상동작상태, 준 정지상태를 구분하기 위해 다층 퍼셉트론 알고리즘을 통해 분류하여 응급상황 검출에 응용하였다. 그러나, 분류하고자 하는 자세의 종류가 3가지 밖에 되지 않았음에도 불구하고 자세 판별의 인식률이 좋지 않았다. Ray와 Teizer^[18]는 건설 현장에서 진행되고 있는 작업자의 자세를 판별하기 위해서 마커리스 카메라를 사용하였다. 우선, 카메라부터 사람까지의 깊이 데이터를 PCA(Principal component analysis)를 통해 차원을 감소하고 LDA(Linear discriminant analysis)를 통해 사람의 자세를 판별하였다. 그러나 차원을 감소하는 과정과 분류하는 과정에서 모션 데이터가 선형적이라는 가정으로 출발하였기 때문에 자세 판별의 분류율이 좋지 않았다. Wientapper *et al.*^[19]는 Time-of-Flight 카메라를 사용하여 사람까지의 깊이 데이터를 LPP(Locality preserving projections)을 이용하여 차원을 감소한 후, LDA를 통해 서있는 자세, 앉아있는 자세, 누워있는 자세를 판별하였다. 고 차원의 데이터를 차원 감소하는 과정에 비선형 데이터까지 고려함에 있어서 인식을 개선에 효과가 있었지만 분류하는 알고리즘으로는 선형 기법을 사용함으

Fig. 1 Human model generation process based on the markerless depth camera

로써 비선형 분류는 하지 못했다.

본 논문에서는 선형적인 방식의 차원 감소 알고리즘의 경우에는 인체의 자세를 분류하는 성능이 떨어지기 때문에 카메라로부터 출력되는 데이터에 대한 차원을 비 선형적 방식의 차원 감소 방식을 사용하여 모션 데이터가 가지고 있는 특성을 부각시켜 분류하고자 하는 데이터를 표준 자세 템플릿 모델과 정확하게 매칭시키는 연구를 수행한다.

3. 모션 데이터 추출과 보간

3.1 휴먼 시뮬레이션 생성 프로세스

3차원 휴먼 시뮬레이션은 타임라인 상에서 각 프레임 별 인체모델의 관절 값과 위치 값에 변화를 주어 매 프레임마다 차이를 발생시키고, 이를 실행하였을 때 자연스러운 애니메이션 효과와 함께 사용자에게 자세 정보를 전달하는 것을 목적으로 한다. 휴먼 시뮬레이션을 생성하기 위해서는 키 프레임이라 불리는 주요 프레임마다 인체 모델의 각 관절 값과 위치 값을 편집하여 인체 모델이 취하고 있는 자세를 변경해야 하기 때문에 사용자의 오랜 작업 시간을 필요로 한다. 본 논문에서는 인체모델링을 신속하게 진행하기 위하여 마커리스 방식의 깊이 카메라를 이용하여 모션캡처를 통해 사람의 관절데이터를 얻어 이를 인체모델에 적용한다.

마커리스 방식은 적외선 불빛을 픽셀단위로 캡

쳐하고 적외선 수신 카메라를 통해 대상물에 반사되는 픽셀의 깊이 정보를 수집하여 위치를 계산하는 방식이다. 마커 또는 센서를 이용한 기계식과 달리 무게가 나가는 철제 마커를 부착하지 않기 때문에 작업자가 자연스러운 자세를 취할 수 있다. 그러나, 마커 장비 설치가 빠르고 쉽다는 장점이 있지만, 섬세한 동작까지 측정하기 어렵다는 것과 마커가 가려져서 센서의 위치를 추적할 수 없어 발생하는 폐색현상이 발생하는 단점이 있다.

본 논문에서는 마커리스 카메라를 통해 작업자의 동작을 촬영하고, 촬영된 이미지로부터 관절 정보와 위치 정보를 추출하여 이를 휴먼 시뮬레이션상의 인체 모델에 적용시키는 방법을 도입하였다. 그러나, 마이크로소프트의 키넥트(Kinect)와 같은 깊이 카메라를 사용할 경우에는 장비적인 한계로 인하여, 촬영된 작업자의 촬영된 이미지와 깊이 값만을 이용해서는 충분한 관절 정보를 추출할 수 없다. 이러한 부정확한 데이터가 발생했을 경우에 직접적인 관절 정보 추출이 아닌 동영상 이미지 상에 나타난 작업자의 실루엣과 실루엣에 해당되는 깊이 값을 추출하여 차원을 감소한 후, 사전에 정의한 표준 자세 템플릿 데이터와의 비교하는 방식을 사용한다. 비교를 통해 선택된 표준 자세 템플릿 데이터를 부정확한 데이터가 발생한 프레임의 인체 모델의 데이터와 교체하는 모션 보간 방식으로 인체 모델의 관절데이터를 수정함으로써 마커리스 방식의 깊이 카메라를 활용하여 원하는 자세를 인체모델에 빠르게 적용하고 이를 통

해 효과적인 휴먼 시뮬레이션을 실행할 수 있다.

Fig. 1은 마커리스 기반의 카메라를 이용해서 모션 데이터를 획득하는 과정을 데이터의 흐름과 수행되는 모듈간의 관계를 보여준다. 우선, 하나의 영상 카메라와 두 개의 적외선 카메라를 가진 키넥트 디바이스로부터 색상 데이터인 모션 프레임 영상과 키넥트와 적외선 센서에 의한 깊이 정보를 OpenNI API를 통해 획득한 후 인체의 관절 데이터를 추출한다. 추출된 관절 데이터는 휴먼 시뮬레이터 상의 인체 모델과 연동되어 인체 모델 상의 각 관절 값들을 편집하게 되고, 이를 이용하여 시뮬레이션을 수행한다.

그러나, 물체를 드는 과정에서 상체를 구부리는 자세 또는 앉아서 용접하는 자세와 같이 인체의 일부분이 가려져 발생하는 폐색현상이 일어나는 자세에서는 추출된 관절 데이터가 실제 사람이 취한 자세의 데이터와 다르거나 제대로 된 관절 데이터를 추출하지 못하는 경우가 발생한다. 자세가 가려지거나 움직임이 너무 빨라 측정할 수 없어 정확한 관절데이터를 추출할 수 없는 자세들 중에서, 작업자가 많이 수행하는 자세를 파악하였다. 주요 자세는 쪼그려 앉은 자세, 구부린 자세, 엎드린 자세로 구분하였고, 그 밖의 정확한 관절데이터 추출되는 자세에 대해서는 서있는 자세로 구분하였다. 이런 주요 자세에 대해서는 전 처리기의 배경제거 기능을 통해 촬영된 이미지 상에 있는 인체의 실루엣을 파악하고, 실루엣 주위에 대한 깊이 데이터를 추출한다. 또한, 부정확한 데이터가 발생한 프레임 상에서 인체 실루엣의 깊이 데이터를 정규화된 크기로 변환한 후, 촬영된 이미지의 가로축과 세로축을 기준으로 측정된 깊이 값들을 행 벡터 형태의 특징 벡터로 생성한다.

특징벡터는 연산의 효율을 높이고 모션 데이터의 특징을 부각시킬 수 있도록 매니폴드 학습을 통해 고 차원 데이터에서 저 차원 데이터로 차원을 감소하게 된다. 생성된 저 차원 데이터는 SVM을 이용한 학습 및 분류 과정을 통해 어떠한 자세를 취하고 있는지 분류한 후, 표준 자세 템플릿 모델과 매칭하여 부정확하게 추출한 관절 데이터를 표준 자세 템플릿 모델의 관절 데이터로 변경한다. 마지막으로, 변경된 관절 데이터는 앞 프레임과 뒤 프레임 사이에 연결한 후 관절 데이터의 보간을 통해 자연스러운 시뮬레이션을 수행할 수 있도록 한다.

Fig. 2 Examples of missing or inaccurate motion data

3.2 표준 자세 템플릿 정의

휴먼 시뮬레이션을 수행하기 위해 키넥트 디바이스로부터 OpenNI를 인터페이스 하여 관절 데이터를 추출한다. 추출된 관절 데이터를 토대로 인체 모델에 적용했을 때 표현할 수 없거나 주변 장애물 또는 중첩된 관절에 의해 발생된 부정확한 관절 데이터일 경우 수정하는 과정이 수행된다.

본 논문에서는 Fig. 2에서 보는 바와 같이 쪼그려 앉은 자세, 장애물에 가려진 자세, 구부린 자세, 물체를 들은 자세, 엎드린 자세, 무릎 꿇은 자세에 대해 표준 자세 템플릿을 정의하여 데이터베이스에 저장하였다. 이 표준 자세 템플릿을 바탕으로 관절이 중첩되어 일부 관절 데이터를 추출할 수 없거나 주변 장애물에 의해 관절 데이터를 추출할 수 없는 부정확한 관절 데이터에 대해 표준 자세 템플릿 모델에서는 각각의 관절의 위치와 방향, 그리고 자세의 종류에 대한 정보를 미리 정의해 놓았다.

3.3 전처리 과정 및 특징 벡터 추출

주변 장애물에 의해 또는 중첩된 관절에 의해 사람의 모션이 가려지게 되는 경우와 연속된 모션에 의해 정확한 데이터가 출력되지 않은 경우에는 정확한 관절 데이터를 추출하지 못한다. 이와 같은 경우에는 영상의 이미지 프레임으로부터 사람의 형상에 대한 실루엣을 찾는 전처리 과정을 수행한다. Fig. 3(a)와 같이 연속된 여러 개의 이미지

Fig. 3 Pre-processing for extracting feature vectors

프레임들을 축적하여 평균 이미지를 만든 후 평균 이미지와 비교하여, 움직이지 않는 대상들을 배경으로 판단하여 제거하는 방식으로 배경을 제거한다. 배경이 제거된 이미지 프레임들을 바탕으로 (b)와 같이 사람의 실루엣을 찾을 수 있게 된다. 또한, 키넥트 디바이스에 있는 두 개의 적외선 카메라를 이용해서 (c)에서 보는 바와 같이 최대 6 m 까지 촬영된 이미지 프레임으로부터 깊이 데이터를 추출한 뒤, 앞서 촬영된 이미지를 통해 파악한 사람 실루엣과 겹치는 부분의 깊이 데이터를 따로 추출하면 (d)와 같은 깊이 데이터를 추출할 수 있다. 이렇게 추출한 사람의 실루엣에 대한 깊이 데이터를 토대로 자세 분류를 위한 특징벡터를 구한다.

특징 벡터는 색깔, 움직임, 글자, 문장, 특색모양과 같이 이미지 프레임 상에 있는 대상의 특성을 효과적으로 기술할 수 있는 요소들로서 특징점을 표현할 수 있다. 특징 벡터는 항목이 많을수록 대상을 구별하는 신뢰도는 높아지는 반면에, 데이터의 차원이 급격히 증가되어 연산과정에서 많은 시간이 소요된다. 따라서, 본 논문에서는 자세 판별을 하기 위한 특징 벡터를 카메라에서 사람까지의 거리로 정의하였고, 카메라로 촬영된 하나의 프레임에서는 한 개의 자세 데이터가 깊이 데이터로 표현되어 추출된다. 깊이 데이터는 Fig. 4의 좌측 이미지에서 보는 바와 같이 120×90 크기의 행렬로 표현된다. 깊이 데이터의 범위는 0부터 255까지 값을 가지며, 이 값은 물리적 공간에서 0.023 m 크기를 갖는다. 카메라와 대상물과의 거리가 0.6 m 보다 작을 경우에는 키넥트를 사용하여 거리를 추

Fig. 4 Transformation of a feature vector from depth data

출할 수 없기 때문에 0의 값 부여하고, 6.0 m 초과할 경우에도 0의 값을 갖게 된다.

측정한 자세가 어떤 자세인지 다른 자세들과 비교하기 위하여 Fig. 4에서 보는 바와 같이 120×90 행렬로 이루어진 깊이 데이터를 행 벡터($1 \times 10,800$) 형태의 특징벡터로 변환한다. 즉, 120×90 행렬에서 (0,120)과 (2,42)의 값은 각각 특징벡터의 120번째 요소와 282번째 요소에 위치하게 된다. 따라서, 하나의 자세는 10,800 차원의 특징벡터로 정의되며 벡터의 각 요소는 0과 255 사이의 값을 갖는다.

3.4 매니폴드 학습

영상 데이터와 깊이 데이터를 통해 인체의 자세를 판단하는 과정에서, 고 차원의 특징벡터로 정의된 모션 데이터는 자세들 간에 연관 관계를 찾기 어렵고 부가적인 연산 과정이 요구된다. 따라서 고 차원의 특징 벡터의 차원을 감소하여 정보의 겹 표면을 이루고 있는 불필요한 요소들을 제거하고, 출력 데이터가 가지고 있는 본질적인 요소를 부각시켜 촬영된 각각의 자세에 대한 연관 관계를 찾는 것이 필요하다. 데이터가 가지고 있는 특성을 부각시키는 위해서 매니폴드 학습을 수행하여 데이터의 차원을 감소시키고 자세간의 명확한 구분이 가능하도록 한다.

고 차원의 특징벡터를 저 차원화 하는 방법은 선형 차원 감소 기법과 비선형 차원 기법으로 구분할 수 있다. 영상 데이터와 같은 비선형 데이터를 선형 방식의 알고리즘을 사용하여 차원을 감소할 경우에는 차원이 감소될수록 데이터가 가지고 있는 본질적인 요소가 손실 또는 왜곡되는 상황이 발생할 수 있다. 따라서, 본 논문에서는 비선형 차원 감소 기법의 하나인 LLE 알고리즘^[20,21]을 사용하였다. 비선형 다양체가 국소적인 지역에서는 선형적인 특성을 나타내는 장점을 갖고 있는 LLE알

Fig. 5 Nonlinear dimensionality reduction using LLE algorithm

고리즘은 데이터의 지역적인 구조를 잘 보존하면서 저 차원의 다양체를 찾을 수 있다.

LLE 알고리즘은 Fig. 5에서 보는 바와 같이 두 단계를 거쳐 데이터의 차원을 감소시키게 된다. 첫 번째 단계인 인접한 특징벡터 검색에서는 특징벡터들의 집합 X 에서 하나의 임의의 원소 X_i 를 선택하여 이와 가장 가까운 k 개의 특징벡터를 찾는다. 각 특징 벡터 별로 인접한 특징벡터를 찾는 기법으로 데이터 간의 거리를 계산하여 가장 가까운 거리의 데이터를 k 개 만큼 찾는 방법인 K-Nearest Neighbor 알고리즘을 사용하였다. 가중치 연산에서는 식 (1)의 최적화 함수를 통하여 앞서 구한 가장 가까웠던 특징 벡터들과 X_i 사이에 얻은 복원 오차 결과를 측정하고, 이 오차를 최소화하는 가중치 ω 를 구한다.

$$\varepsilon(\omega) = \sum_j^k \left| X_i - \sum_j^k \omega_{ij} X_j \right|^2 \quad (1)$$

where, ω_{ij} is weights at the j th data point to the i th reconstruction.

두 번째 단계에서는 식 (2)를 통하여 M 차원에서의 데이터 X_i 에 대하여 앞 단계에서 찾아낸 가중치 ω 를 유지할 수 있으며, L 차원으로 저 차원화된 데이터 Y_i 를 생성하게 된다.

$$\varepsilon(\omega) = \sum_j^k \left| Y_i - \sum_j^k \omega_{ij} Y_j \right|^2 \quad (2)$$

최종적으로 가중치 ω 를 유지한 채 저 차원으로 변환한 데이터들의 경우, 서로간의 관계에 대한 정보라고 할 수 있는 ω 의 값이 저 차원화 하기 이전

의 고 차원 데이터에서의 ω 와 동일한 것을 알 수 있으며, ω 를 유지시키지 않은 데이터의 경우에는 고 차원상의 데이터간 관계성이 소실된다. 이처럼 한 개의 프레임에서 자세 데이터였던 특징벡터를 LLE알고리즘을 거쳐 각각의 특징벡터들간의 관계성을 최대한 유지하면서 특징벡터들의 본질적인 요소를 나타낼 수 있도록 저 차원화를 수행하게 된다.

3.5 자세 분류를 위한 SVM 적용

매니폴드를 수행하여 얻은 저 차원의 자세 데이터를 기계학습의 일종인 SVM^[22]을 통해 자세를 분류한다. SVM은 데이터를 구별하는 경계면을 찾기 위한 과정인 학습과정과 새로운 입력 데이터에 대해 자세를 구별하는 분류과정으로 나눌 수 있다. SVM에서는 새로운 데이터를 분류할 때 발생하는 일반화 오차를 줄이는 최적의 경계면을 찾는 것이 목적이다. Fig. 6(a)에서 보는 바와 같이 선형 분리가 가능한 두 가지 자세에 대한 데이터가 주어졌을 때, 자세를 분류하는 경계면은 여러 가지 경우의 수가 존재한다. 즉, 학습데이터의 분류를 통해 생성된 경계면 1,2,3은 자세 1과 자세 2의 영역 내에 있는 데이터에 대해 정확한 자세 판별을 할 수 있지만, 새로운 자세 데이터(New data)가 입력될 경우 두 개의 자세 가운데 어떤 자세로 판별하는 것은 모호하게 된다. 따라서, Fig. 6(b)에서 보는 바와 같이 최적의 경계면을 찾기 위해 마진의 개념을 도입하였다. 여기서 경계면과 가장 인접한 데이터들을 서포트 벡터(Support vector)로, 서포트 벡터와 경계면까지의 거리를 마진으로 정의한다. 이때, 두 자세를 구분하는 여러 가지 마진이 존재하는데 일반화 오차를 줄이기 위해서는 두 자세 간의 간격을 최대로 유지해야 한다. 즉, 최적의 경계면을 구하기 위해서는 최대 마진을 구하는 것이 필요하다.

Fig. 6 Posture discrimination based on SVM

식 (3)은 최대 마진 d 에 관한 수식을 나타내며 W 는 경계면과 직교하는 벡터이다. 따라서, 최대 마진을 구하기 위해서 $\|W\|$ 의 값이 최소가 되도록 W 와 b 를 찾아 최적의 경계면을 찾는다.

$$d = \frac{2}{\|W\|}, (W^T \cdot x + b) \geq 1 \quad (3)$$

만약 입력데이터가 선형적인 분류가 불가능할 경우, 입력 벡터 X 를 고 차원 벡터인 $\phi(x)$ 로 매핑시킨 후 고 차원에서 선형의 경계선을 찾는 커널법을 활용하여 비선형 분류를 수행한다. 커널함수를 이용하면 입력벡터를 고 차원의 벡터로 투영시킴으로써 내적에 대한 계산만 추가적으로 필요하게 되므로 연산의 복잡도가 크게 상승하지 않는다. 본 논문에서는 비선형 분류 특성을 갖는 데이터를 선형 분류가 가능하도록 식 (4)과 같이 가우시안(Gaussian) 커널함수를 사용하였다.

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (4)$$

4. 시스템 구현

4.1 시스템 개요

Table 1은 본 논문을 통해 구현한 휴먼 시뮬레이션 개발 환경을 보여준다. 마커리스 모션 캡처 장비는 마이크로소프트의 키넥트를 사용하였으며, 키넥트 디바이스에 접근하여 영상데이터, 깊이 데이터, 관절 데이터를 얻어오기 위한 라이브러리로 OpenNI 1.5.4버전을 사용했다. 또한, 3차원 가시화 환경과 인체모델 컨트롤 및 시뮬레이션을 구현하기 위해 Ogre3D 1.8.1와 SVM 구현을 위해 SVMTorch 2.0을 사용하였다.

Fig. 7은 10개의 모듈로 구성된 휴먼 모션 시뮬레이션 시스템의 구조를 보여준다. 키넥트에서 영상센서와 적외선 센서를 바탕으로 영상데이터와

Fig. 7 Overall architecture of a human motion simulation system

깊이 데이터, 관절 데이터를 추출한 후 역기구학(Inverse kinematics)을 적용하여 추출된 관절 데이터가 실제로 취할 수 있는 자세인지 판단한다. 만약에 장애물이나 중첩된 관절에 의한 부정확한 데이터가 추출되거나 추출된 관절 데이터가 취할 수 없는 자세라면 전처리 모듈에 의해 배경을 제거한다. 다음 단계는 인체 실루엣의 특징벡터에 대한 차원감소 모듈과 SVM 모듈을 거쳐 자세를 판별하게 된다. 또한, 휴먼모델의 표준 자세 템플릿과 매칭하여 관절 데이터를 대체하고 앞 자세와 뒤 자세를 고려하여 모션을 보간하는 작업을 한다. 만약에 역기구학 모듈에서 정확한 관절 데이터를 추출했으면 전처리 모듈을 거치지 않고 직접 휴먼모델에 관절 데이터를 적용한 후, 이를 시뮬레이션에 적용한다. 모델의 움직임이 발생했을 때 시뮬레이션을 화면에 가시화하거나 카메라를 회전, 줌, 이동과 같은 기능은 가시화 모듈에 의해 구현된다.

4.2 깊이 데이터 추출 및 변환과정

관절 데이터에 탐색에 실패했거나 인체가 표현할 수 없는 관절 데이터를 추출한 경우, 자세를 판별하여 표준 자세 템플릿과 매칭하여 관절 데이터를 수정해야 한다. 또한, 관절 데이터에 탐색에 실패했거나 인체가 표현할 수 없는 관절 데이터를 추출한 경우, 자세를 판별하여 표준 자세 템플릿과 매칭하여 관절 데이터를 수정해야 한다. Fig. 8는 자세 판별에 필요한 데이터 추출과정을 보여준

Table 1 Implementation environment

Item	Tools
Compiler	Visual C++ 2010
Markerless camera	Kinect for Xbox360
Interface library for Kinect	OpenNI v. 1.5.4
3D visualization library	Ogre3D v. 1.8.1
Machine learning library	SVMTorch v. 2.0

Fig. 8 Transformation process of motion data used in posture discrimination

다. 먼저, 키넥트로부터 촬영한 이미지 데이터의 평균값을 이용한 배경제거 기법을 활용하여 배경을 제거한 후 사람의 실루엣을 구한다. 다음으로 키넥트로부터 추출한 깊이 데이터를 실루엣과 일치하는 영역을 120×90 행렬의 크기로 정규화시켜 추출한다. 이후, 다른 자세들과 비교하기 위해 행 벡터 형태의 특징벡터로 추출한다. 이때, 특징벡터는 판별하고자 하는 자세 n 개의 특징벡터 집합으로 구성된다.

다음 단계에서는 차원의 크기를 줄여 불필요한 요소를 제거하고 데이터의 본질적인 요소를 부각시키기 위해 LLE 알고리즘을 거쳐 Fig. 8의 10 차원 상의 저 차원 특징벡터로 차원을 감소시켰다. 이렇게 구한 저 차원 특징벡터에서 한 개의 행은 10 차원의 데이터로 이루어져 있으며, 하나의 자세를 의미한다.

Fig. 8에서 사람 실루엣의 깊이 데이터는 0부터 255까지의 값을 가지고 있으며 120×90 형태의 행렬데이터이다. 이를 특징벡터로 변환하기 위해 두 번째 행의 값은 첫 번째 행의 뒤로 이동하면서 $1 \times 10,800$ 형태의 행 벡터로 변환한다. 다음으로 LLE 알고리즘을 통해 차원을 감소하여 자세를 분류하는데 필요한 연산을 줄인다. 인접한 자세 데이터를 찾기 위한 K-Nearest Neighbor 알고리즘에서 몇 개의 인접한 데이터를 찾을지 결정하는 K 값을 10으로 설정하여 인접한 벡터를 구했다. LLE에서 자세를 나타내는 10,800 차원의 특징벡터를 10 차원의 저 차원 특징벡터로 차원을 감소하였다.

4.3 SVM 구현 및 분류성능 검사

매니폴드 학습 후 자세를 나타내는 특징벡터는 10 차원상의 좌표로 나타나진다. 10 차원상의 점들이 어떤 자세인지를 분류하기 위한 경계면을 찾기 위해 SVM 학습과정을 먼저 수행한다. SVM 학습과정에서 이미 어떠한 자세인지를 알고 있는 10 차원상의 좌표를 가지고 데이터를 분류하는 경계면을 찾기 위해 학습을 수행한다. 본 논문에서는 SVM 학습에 사용할 데이터로서 30개의 서 있는 자세, 13개의 상체를 숙인 자세, 17개의 앉아있는 자세, 11개의 엎드려 있는 자세로 이루어진 71개의 차원이 감소된 10차원상의 데이터를 사용하였다. SVM의 학습과정에서 각 자세 별로 경계면에 근접한 서포트 벡터를 찾았으며, 서포트 벡터를 통해 최대 마진을 찾아내 경계면을 구했다. Table 2는 각 자세에 대한 서포트 벡터의 숫자를 보여준다.

SVM 학습과정을 거쳐 얻은 경계면과 서포트 벡터를 토대로 매니폴드를 거친 저 차원 형태의 새로운 자세 데이터가 들어왔을 때 앞서 정의한 표준 자세 템플릿들과 비교하여 어느 자세인지를 분류할 수 있다. 학습과정을 거쳐 얻은 경계면이 어느 정도의 정확도를 가지고 자세 데이터를 분류하는지 알기 위하여 학습과정에서 사용하지 않은 새로운 자세 데이터 75개를 대상으로 실험을 했다. Table 3은 75개의 실험데이터의 결과물로서 전체 75개의 자세 데이터 중에서 63개 데이터는 SVM 모듈을 통해 생성된 경계면에 따라 정확히 분류에 성공하여 84%의 성공률을 보였다.

Table 2 Number of support vectors of each posture

Type of posture	# of support vectors
Stand	44
Bend	29
Squat	34
Crawl	25

Table 3 Output of posture discrimination

Type of posture	Test data set	Success	Failure	Rate of success
Stand	31	24	7	77%
Bend	14	11	3	78%
Squat	19	17	2	89%
Crawl	11	11	0	100%

Fig. 9 Classification of posture data by hyperplanes after SVM learning

우선, 31개의 서있는 자세의 실험데이터는 24개를 서있는 자세로 정확히 분류하여 77%의 성공률을 보였다. 서있는 자세는 가장 일반적인 자세로 다른 특정한 자세에 비해 취할 수 있는 자세가 많은 범용적인 자세이기에 많은 학습을 거쳐야 했지만, SVM 학습에 사용한 데이터의 양이 부족하여 분류 성공률이 낮은 것으로 판단된다. 분류에 실패한 7개 자세는 모두 앉아있는 자세로 분류되었다. 상체를 숙인 자세 14개 데이터 중에서 11개는 분류를 성공하여 78%의 분류 성공률을 보였으며, 3개 분류 실패 중에서 1개는 엎드려 있는 자세로 2개는 앉은 자세로 분류되었다. 19개의 앉아있는 자세의 경우에는 17개는 분류를 성공하여 89%의 분류 성공률을 보였으며, 분류 실패한 2개는 모두 엎드린 자세로 분류되었다. 마지막으로 엎드려 있는 자세 11개는 모두 분류에 성공하였다.

Fig. 9는 매니폴드 학습을 통해 얻은 10 차원 자세 데이터를 2 차원으로 차원을 감소하여 각각의 자세 데이터를 평면상에 파란색 점으로 나타낸 것이다. 이때, 붉은색 점선은 자세 판별을 위한 SVM 학습과정을 통해 계산된 경계면을 의미한다. 이후, 추가로 자세 데이터가 입력될 경우에는 SVM 학습과정에서 구한 경계면과 서포트 벡터에 의해 자세를 판별하게 된다. 만약 새로운 자세 데이터가 Fig. 9의 우측하단에 위치하게 되면, SVM 분류과정을 통해 앉은 자세로 판별하게 된다.

4.4 모션 보간

OpenNI를 통해 추출할 수 있는 관절의 수는 하체 8개(좌우 엉덩이, 무릎, 발목, 발), 상체 10개(좌우 목, 어깨, 팔꿈치, 손목, 손), 몸통 4개(허리,

Fig. 10 Configuration of 22 joints of human model

몸통, 목, 머리) 총 22개이다. 본 논문에서 사용한 인체모델은 Fig. 10에서 보는 바와 같이 65개의 관절을 가지고 있으며 이중에서 OpenNI가 인식하지 못하여 연동이 불가능한 관절을 제외하고 연동되어 움직일 관절의 숫자는 하체 6개(좌우 허벅지, 다리, 발), 상체 8개(좌우 어깨, 팔, 팔꿈치, 손), 몸통 8개(척추 5개, 목, 머리, 정수리)로 총 22개이다. OpenNI API를 통해 얻은 관절의 변화는 인체 모델의 관절에 실시간으로 적용된다.

Fig. 11는 몸을 웅크리고 앉은 자세를 캡처했을 경우(a)에 추출된 관절 데이터가 부정확하게 표현된 폐색현상(b)의 예를 보여준다. 특히 다리와 발목 부근에서 부관절이 겹쳐서 부정확한 관절데이터가 추출되었고, 이 데이터를 인체모델에 적용했을 때 (c)에서 보는 바와 같이 상체와 팔은 정상적으로 표현이 되지만 다리의 경우 부정확한 관절데이터에 의해 앉은 자세가 아닌 서있는 자세로 그려지며 일부 관절은 뒤틀려서 정상적인 휴먼 시뮬레이션을 할 수 없게 된다.

이와 같은 부정확한 모션 데이터에 대해 SVM 분류과정을 거쳐 인체가 어떤 자세를 취하고 있는지 자세를 판별하고, 3.2절에서 정의한 표준 자세 템플릿에서 판별된 자세와 부합되는 템플릿을 찾아 부정확하게 추출된 관절데이터를 교체 또는 수정한다. Fig. 11(d)는 표준 자세 템플릿의 관절 데이터로 수정된 인체 모델의 결과를 보여준다. 표준 자세 템플릿으로 대체된 자세는 원활한 시뮬레이션을 위해 정확히 추출된 모션 데이터의 이전 프레임과 다음 프레임 사이에 추가된 후, 인체모델의 관절 데이터간의 선형 보간을 통해 관절의 부드러운 움직임을 표현할 수 있다.

Fig. 11 Posture discrimination for motion interpolation

5. 결 론

자세를 판단하는 과정에서 주변 장애물에 의해 또는 중첩된 관절에 의해 모션이 가려지는 폐색현상과 작업자의 빠른 동작으로 인해 모션 캡처 과정에서 측정되지 않거나 부정확한 모션 데이터가 발생하는 경우에는 작업자의 자세를 정확히 판단하는 것이 불가능해진다. 이러한 문제점을 극복하기 위하여 본 논문에서는 표준 자세 템플릿을 정의한 후, 이를 시스템 상에 학습시켜 자세를 판별할 수 없는 부정확한 데이터가 카메라로부터 출력될 경우에 해당 데이터를 저 차원화 과정을 수행한 후 표준 자세 템플릿과 매칭시키는 연구를 수행하였다. 자세를 분류하기 위해 깊이 데이터를 추출하고 변환하여 얻은 특징벡터가 비 선형적인 구조를 띠고 있어서 선형 차원 알고리즘을 사용할 경우 데이터 손실과 차원 감소의 정확도가 떨어지므로 이를 방지하기 위해 비선형 차원감소 알고리즘인 LLE를 사용하여 차원을 감소 하였다. 또한, 자세를 분류할 때 일반화 오차를 줄이고 성능을 높이기 위한 방법으로 SVM을 사용하여 4개 자세를 분류하였고, 가우시안 커널을 사용하여 비 선형적인 구조를 해결하였다. 이후 부정확하게 추출된 관절 데이터를 분류된 자세에 매칭되는 표준

자세 템플릿 모델의 관절 데이터와 대체하여 자연스러운 휴먼 시뮬레이션을 구현하였다.

표준 자세 템플릿의 설정에 있어서 본 논문에서는 4개 자세만 판별하였지만 그 밖에 부정확한 관절 데이터가 추출되는 더 많은 자세에 대해 연구의 진행이 요구되며, 기존에 SVM 학습에 사용했던 71개의 실험데이터보다 많은 실험데이터를 통해 SVM을 학습시킨다면 자세 판별에 있어서 더 뛰어난 성능을 보일 것으로 예상된다.

감사의 글

본 논문은 2012년 산학협동재단의 연구비를 지원받아 수행되었습니다.

References

1. Virtual Ergonomics Applications, <http://www.3ds.com/products-services/delmia/solutions/human-modeling/>
2. Tecnomatix Siemens PLM, http://www.plm.automation.siemens.com/en_us/products/tecnomatix/
3. PTC Creo Manikin Extension, <http://www.ptc.com/product/creo/manikin-extension/>
4. Human Solutions Assyst AVM, <http://www.human-solutions.com/mobility/>
5. Boeing Human Modeling System, <http://www.boeing.com/assocproducts/hms/>
6. Deutscher, J., Blake, A. and Reid, I., 2000, Articulated Body Motion Capture by Annealed Particle Filtering, *Proceedings IEEE conference Computer Vision and Pattern Recognition*, pp.126-133.
7. Zordan, V.B. and Hodgins, J.K., 2002, Motion Capture-Driven Simulations that Hit and React, *Proceeding of the 2002 ACM SIGGRAPH/Eurographics Symposium on Computer Animation*, pp.89-96.
8. Kang, S.H. and Sohn, M.Y., 2012, Research on Ontology-based Task Adaptability Improvement for Digital Human Model, *Transactions of the Society of CAD/CAM Engineers*, 17(2), pp.79-90.
9. Cha, M.H., Han S.H. and Huh, Y.C., 2013, A Walking Movement System for Virtual Reality Navigation, *Transactions of the Society of CAD/CAM Engineers*, 18(4), pp.290-298.
10. Izadi, S., Kim, D., Hilliges, O., Newcombe, R. and Fitzgibbon, A., 2011, KinectFusion: Real-time 3D Reconstruction and Interaction Using a Moving Depth Camera, *Proceedings of 24th*

- Annual ACM Symposium on User Interface Software and Technology*, pp.559-568.
11. Wilson, A.D., 2010, Using a Depth Camera as a Touch Sensor, *ACM International Conference on Interactive Tabletops and Surfaces*, pp.69-72.
 12. Biswas, J. and Veloso, M., 2012, Depth Camera Based Indoor Mobile Robot Localization and Navigation, *Robotics and Automation International Conference*, pp.1697-1702.
 13. Corazza, S., Mündermann, L., Chaudhari, A.M., Demattio, T., Cobelli, C. and Andriacchi, T.P., 2006, A Markerless Motion Capture System to Study Musculoskeletal Biomechanics: Visual Hull and Simulated Annealing Approach, *Annals of Biomedical Engineering*, 34(6), pp.1019-1029.
 14. Cucchiara, R., Prati, A. and Vezzani, R., 2005, Posture Classification in a Multi-Camera Indoor Environment, *IEEE International Conference In Image Processing*, pp.725-728.
 15. Ri, L.Q., Jeong, Y.K. and Noh, S.D., 2012, A Study on Modeling and Simulation of Assembly Workers' Moving Path Using Depth Camera (Kinect), *Proceedings of the Society of CAD/CAM Engineers Conference*, pp.529-533.
 16. Kim, S.H., 2007, Realtime Facial Expression Control and Projection of Facial Motion Data using Locally Linear Embedding, *Journal of the Korea Contents Association*, 7(2), pp.177-124.
 17. Lee, D.G., Lee, K.J., Whangbo, T.K. and Lim, H.K., 2006, Human Behavior Analysis and Remote Emergency Detection System Using the Neural Network, *Journal of the Korea Contents Association*, 6(9), pp.50-59.
 18. Ray, S.J. and Teizer, J., 2012, Real-Time Construction Worker Posture Analysis for Ergonomics Training, *Advanced Engineering Informatics*, 26(2), pp.439-455.
 19. Wientapper, F., Ahrens, K., Wuest, H. and Bockholt, U., 2009, Linear-Projection-Based Classification of Human Postures in Time-of-Flight Data, *IEEE International Conference System, Man and Cybernetic*, pp.559-564.
 20. Roweis, S.T. and Saul, L.K., 2000, Nonlinear Dimensionality Reduction by Locally Linear Embedding, *Science*, 290(5500), pp. 2323-2326.
 21. Tenenbaum, J.B., Silva, V.D. and Langford, J.C., 2000, A Global Geometric Framework for Nonlinear Dimensionality Reduction, *Science*, 290(5500), pp.2319-2323.
 22. Cortes, C. and Vapnik, V., 1995, Support-Vector Networks, *Machine Learning*, 20(3), pp.273-297.

이진원

2012년 아주대학교 산업정보시스템 공학부 학사
 2014년 아주대학교 산업공학과 석사
 2014년~현재 아주대학교 산업공학과 박사과정
 관심분야: Geometric modeling, Virtual simulation, Human simulation

한정호

2011년 아주대학교 산업정보시스템 공학부 학사
 2013년 아주대학교 산업공학과 석사
 2013년~현재 아주대학교 산업공학과 박사과정
 관심분야: Product lifecycle management (PLM), Geometric modeling, Virtual simulation

양정삼

2004년 KAIST 기계공학과 박사
 1997년~2000년 고등기술연구원
 2002년 Clausthal University of Technology (Germany) Visiting scholar
 2001년~2005년 (주)부품디비 연구개발팀장
 2005년~2006년 University of Wisconsin-Madison Postdoctoral associate
 2012년~2013년 Carnegie Mellon University Visiting scholar
 2006년~현재 아주대학교 산업공학과 부교수
 관심분야: Product data quality (PDQ), Product data exchange (PDE), Product data management (PDM), Geometric modeling, Virtual manufacturing