

GNN 기반 연관 규칙 마이닝을 통한 낙상 위험 포즈 패턴 분석

(Fall Risk Pose Pattern Analysis Using GNN-based Association Rule Mining)

조한진*

(Han-Jin Cho)

요약

본 연구에서는 낙상 위험 예측을 위해 GNN 기반의 연관 규칙 마이닝 기법을 제안한다. 기존 웨어러블 장치의 한계를 극복하고자 영상 처리 기술을 활용해 포즈 데이터를 수집하고, 이를 GNN 모델에 통합하여 정밀한 예측을 가능하게 하였다. DeepPose를 사용해 포즈 데이터를 추정하고, FP-growth 알고리즘으로 연관 규칙을 도출한 후 GAT 모델을 적용하여 포즈 간의 복잡한 상호작용을 학습하였다. 본 연구의 제안 방법은 OpenPose 기반 방법 대비 Accuracy, Precision, Recall, F1-Score에서 98% 이상의 성능을 기록하며 우수성을 입증하였다. 이 모델은 고위험군의 낙상 예방과 실시간 모니터링 시스템에 적용할 수 있는 가능성은 보여준다.

■ 중심어 : 낙상 위험 예측 ; 연관 규칙 마이닝 ; GNN ; GAT

Abstract

This study proposes a GNN-based association rule mining method for predicting fall risks. To overcome the limitations of wearable devices, pose data was collected using computer vision techniques and integrated into a GNN model for precise predictions. The use of DeepPose for pose estimation, coupled with FP-growth for association rule extraction, followed by the application of a GAT model, enables the learning of complex interactions between poses. The proposed method demonstrates superior performance, achieving over 98% in Accuracy, Precision, Recall, and F1-Score compared to OpenPose-based approaches. This model highlights the potential for enhancing fall prevention and real-time monitoring in high-risk groups.

■ keywords : Fall Risk Prediction ; Association Rule Mining ; GNN ; GAT

I. 서 론

포즈 추정(Pose Estimation)은 다양한 분야에서 연구의 필요성이 크다. 예를 들어, 물리 치료 및 재활 과정에서 환자의 운동을 분석하고 개선하는 데 활용되어, 치료사는 환자의 진행 상황을 자세히 모니터링하고, 맞춤형 치료 계획을 수립 할 수 있다. 또한, 스포츠 분야에서는 운동선수의 자세와 동작을 분석하여, 코치와 선수들이 기술을 향상시키고 부상을 예방하는 데 도움을 준다.

포즈 추정은 이러한 과정을 통해 선수들의 능력을 객관적으로 측정하고 훈련 방법을 최적화 하는 데 기여하고 있다[1].

인터랙티브 엔터테인먼트 분야에서는 사용자의 신체 움직임을 인식하여, 게임과 같은 응용 프로그램에 반영함으로써 사용자 경험을 향상시키고 몰입감 높은 환경을 제공한다. 더 나아가, 증강 현실(AR, Augmented Reality)과 가상 현실(VR, Virtual Reality)에서도 실시간으로 사용자의 움직임을 추적하여, 자연스러운 상호작용을 가능하게 하여 교육, 훈련, 게임 등의 응용 프로그램에서 사용자 경험을 극대화하고 있다[2,3].

본 논문의 주된 목적은 GNN 기반의 연관 규칙 마이닝(Association Rule Mining)을 활용하여, 낙상 위험을 유발할 수 있는 특정 포즈 및 움직임 패턴을 정밀하게 분석하고 식별하는 것이다.

* 정회원,

이 연구는 2024년도 극동대학교 교내연구비 지원에 의하여 수행된 것임(FEU2024R25)

접수일자 : 2024년 11월 10일

제재 확정일 : 2024년 11월 19일

교신저자 : 조한진 e-mail : hanjincho@kdu.ac.kr

이를 통해 낙상 사건이 발생하기 전 특정 징후 및 조건을 정확히 파악하고, 예방 조치를 마련함으로써 고위험군의 안전을 향상시키고자 한다.

특히 기존 연구들은 주로 낙상 사건 발생 후의 대응에 초점을 맞추고 있지만, 본 연구는 낙상 위험이 높은 포즈와 움직임 패턴을 사전에 분석하고 예측하는 새로운 방법론을 제시한다. 이를 통해 낙상 예방 가능성을 높이고, 고위험군 사용자의 안전성을 강화할 수 있다.

II. 관련 연구

1. 포즈 추정 기술

포즈 추정은 인체의 특정 지점(key point)을 식별하여 위치를 추정하는 기술이다. 이 기술은 보통 머리, 어깨, 팔꿈치, 무릎, 발목 등의 주요 지점을 식별하고, 이 지점들을 연결하여 전체적인 자세를 추정한다.

포즈 추정 모델은 크게 세 가지로 분류된다. 첫 번째는 Skeleton-based 모델로, 이는 인체의 주요 부위를 기반으로 신체 위치를 추정하는 데 유용하나, 전체적인 모양이나 부피를 추정하는 데는 한계가 있다. 두 번째는 Contour-based 모델로, 신체의 전체적인 모양을 파악할 수 있는 장점이 있다. 세 번째는 Volume-based 모델로, 3D 자세 추정에 사용되어 인체의 입체적인 정보를 제공한다.

본 논문에서는 여러 포즈 추정 모델 중 Google이 개발한 DeepPose를 채택하였다. DeepPose는 전통적인 이미지 분류 방식과 유사하게 CNN(Convolutional Neural Network)을 활용하여, 이미지에서 사람의 신체 주요 지점을 예측한다.

이 모델은 전체 이미지를 입력으로 받아 CNN을 통해 주요 특징을 추출하고, 이를 바탕으로 신체 각 부분의 위치를 회귀 방식으로 예측한다. CNN을 사용함으로써 복잡한 배경이나 다양한 인체 자세에서도 높은 신뢰성으로 포즈를 추정할 수 있다.

2. GNN 응용 기술

GNN(Graph Neural Networks)는 그래프 구조로 표현되는 데이터를 처리하는 데 특화된 신경망 구조로, 노드와 그 연결성을 분석하여 복잡한 패턴을 학습할 수 있다[2]. 최근에는 GNN이 다양한 컴퓨터 비전 작업에서 두각을 나타내고 있으며, 특히 그래프 데이터에서 복잡한 상호작용을 학습하는 데 강점을 보여준다. GNN의 최신 발전 중 하나인 Graph Transformer 모델도 포즈 추정에서 좋은 성능을 보이고 있다.

본 논문에서 사용한 포즈 데이터는 이러한 그래프 구조로 표현되며, GNN을 통해 상호 연관성을 모델링하는 데 효과적일 것으로 기대된다.

최근 연구에 따르면, GNN은 포즈 추정과 같은 컴퓨터 비전 작업에서도 주목받고 있다[3].

예를 들어, Y. Yang 등은 "Learning Dynamics via Graph Neural Networks for Human Pose Estimation and Tracking"에서 인간의 포즈를 그래프로 모델링하고, GNN을 활용해 가려진 Skeleton을 복구하는 정확도를 크게 향상시켰다[4].

본 연구에서는 다양한 GNN 모델 중에서 GAT(Graph Attention Network)를 선택했다[5]. GAT는 그래프 데이터의 노드 간 상호작용에서 중요한 부분에 더 많은 가중치를 부여하는 Attention Mechanism을 도입한 모델로 2018년에 처음 발표되었다. 이 메커니즘은 기존의 GCN(Graph Convolutional Network) 모델이 가진 한계를 극복하고, 그래프 내에서 더 유연하고 강력한 관계 학습을 가능하게 한다.

3. 낙상 감지 기술

기존의 낙상 감지 시스템들은 주로 웨어러블 장치를 통해 이루어졌으며, 가속도계와 자이로스코프를 사용하여 사용자의 움직임을 실시간으로 모니터링 한다.

이는 낙상을 효과적으로 감지할 수 있으나, 웨어러블 장치를 지속적으로 착용해야 하며, 배터

리 수명으로 인해 주기적인 충전이 필요하다는 단점이 있다. 또한, 고급 웨어러블 장치는 초기 비용이 높아 경제적 여건이 어려운 사람들에게 접근성이 낮을 수 있다.

이러한 문제점을 보완하기 위해 최근에는 영상 처리 기술을 이용한 낙상 감지가 점점 더 많이 사용되고 있다[6]. 영상 처리 기술을 통해 웨어러블 장치 없이도 넓은 공간에서 여러 사람의 움직임을 동시에 모니터링할 수 있다[7].

III. 낙상 위험 포즈 패턴 분석

본 논문에서는 GNN을 기반으로 연관 규칙 마이닝을 활용하여 낙상 위험을 유발할 수 있는 특정 포즈 및 움직임 패턴을 분석하고 식별한다.

기존 웨어러블 장치 기반 접근 방식이 갖는 한계를 극복하기 위해, 본 논문에서 포즈 추정과 GNN 기반의 연관 규칙 마이닝을 결합하여 고위험군의 낙상 위험을 사전에 예측하고 예방할 수 있는 새로운 방법론을 제시한다.

그림 1은 본 연구에서 제안하는 GNN 기반 연관 규칙 마이닝을 통한 낙상 위험 포즈 패턴 분석의 전체 프로세스를 나타내며, 각 과정은 순차적으로 수행된다.

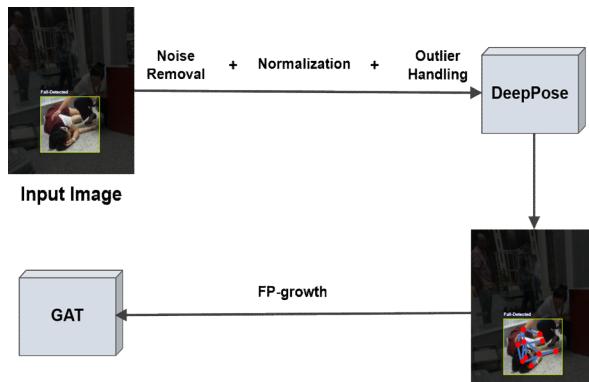


그림 1. 제안된 시스템의 구성도

1. 포즈/움직임 패턴 데이터 수집 및 전처리
본 연구의 첫 번째 단계는 포즈 및 움직임 패턴 데이터를 수집하고, 이를 분석에 적합한 형태로

전처리하는 것이다.

본 논문에서는 학습을 위한 데이터셋으로 Roboflow의 Fall Detection Dataset을 사용한다. Fall Detection Dataset은 주로 낙상 감지 시스템을 개발하고 테스트하기 위해 사용되는 데이터셋이다. Fall Detection Dataset은 실버 케어 모니터링, 직장 안전 관리, 공공안전, 요양 시설 지원, 스포츠 부상 감지 등에 이용된다[8]. 수집된 데이터는 낙상 사건을 포함한 일상적인 움직임 데이터를 포함하며, 다양한 상황에서 발생할 수 있는 포즈를 최대한 반영한다.

데이터 전처리 과정에서는 데이터의 품질을 향상시키기 위해 노이즈 제거, 정규화, 이상치 처리 등을 수행하고, 이러한 과정으로 GNN 모델의 학습 성능을 극대화한다[9]. 추가적으로, 데이터셋의 클래스 불균형 문제를 해결하기 위해 SMOTE(Synthetic Minority Over-sampling Technique) 방법을 사용하여 소수 클래스 샘플을 증대시켰다.

노이즈 제거는 이미지나 신호에서 원하지 않는 불필요한 정보를 제거하는 과정이다. 이미지에서 노이즈는 보통 사진을 찍을 때 발생하는 불규칙한 밝기나 색상 변동으로 나타나고, 이는 이미지 분석에 방해가 된다. 본 논문에서는 노이즈 제거를 위해 가우시안 필터(Gaussian Filter)를 사용한다. 가우시안 필터는 노이즈를 제거하는데 자주 사용되는 방법으로, 이미지를 부드럽게 하여 노이즈를 줄인다. 해당 필터는 가우시안 분포를 따르는 커널을 이미지에 적용해 각 픽셀의 값을 주변 픽셀의 가중 평균으로 변환한다. 식 1은 가우시안 필터 수식을 의미한다.

$$G(x,y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (1)$$

정규화는 데이터의 범위를 일정한 구간으로 변환하는 과정이다. 이미지 처리에서는 주로 픽셀 값을 [0,1] 또는 [-1,1] 범위로 조정하여 모델이

더 쉽게 데이터를 처리할 수 있도록 한다. 정규화를 통해 데이터 간의 크기 차이를 줄여 학습 과정에서 수렴 속도를 높일 수 있다.

본 논문에서는 Min-Max 정규화를 사용한다. Min-Max 정규화는 가장 간단한 정규화 방법으로, 데이터의 최소값을 0, 최대값을 1로 변환하는 방식이다. 식 2는 Min-Max 정규화를 위한 수식이다.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

마지막으로 이상치 처리는 데이터셋에서 일반적인 패턴과 크게 벗어난 값을 처리하는 과정이다. 이미지 데이터에서는 매우 밝거나 어두운 픽셀을 이상치로 간주할 수 있다. 이러한 이상치는 모델 학습에 부정적인 영향을 줄 수 있기 때문에 적절한 처리가 필요하다.

본 논문에서 사용하는 이상치 처리 방법은 클리핑(Clipping)이다. 클리핑은 데이터의 값을 특정 범위 내로 제한하는 기법이다. 특정 임계값 이하 또는 이상의 값을 해당 범위 내의 최소값 또는 최대값으로 설정한다. 이를 통해 데이터가 극단적인 값으로 인해 왜곡되는 것을 방지할 수 있다. 식 3은 클리핑을 위한 수식이다.

$$X' = \begin{cases} X_{\min} & \text{if } X < X_{\min} \\ X_{\max} & \text{if } X > X_{\max} \\ X & \text{otherwise} \end{cases} \quad (3)$$

2. 연관 규칙 마이닝을 통한 패턴 발견

Fall Detection Dataset에서 연관 규칙 마이닝 기법을 적용하여, 낙상 위험과 같은 포즈 간의 상관관계 및 패턴을 분석한다.

본 논문에서는 Apriori와 FP-growth 알고리즘을 활용해 데이터셋 내에서 Fall 라벨을 가지는 데이터 간의 연관 규칙을 도출한다. 이러한 알고리즘은 주어진 데이터셋에서 특정 자세 사이의

발생 빈도와 상호 관계를 분석함으로써, 낙상 사건의 발생 가능성을 높이는 패턴을 식별하는 데 중요한 역할을 한다.

연관 규칙 마이닝은 데이터셋에서 자주 발생하는 패턴을 찾는 데 효과적이며, 본 연구에서는 이를 통해 낙상 위험 포즈를 사전에 식별한다. 예를 들어, 특정 포즈의 연속적 발생이 낙상과 밀접한 연관을 보이는 경우, 이를 근거로 위험 패턴을 정의한다. 이 과정에서 식별된 규칙은 낙상 위험을 예측하는 데 중요한 지표로 사용되며, GNN 모델의 입력으로 활용해 보다 정밀한 예측이 가능하게 한다.

본 논문에서는 연관 규칙 마이닝 기법으로 FP-growth 알고리즘을 사용한다. FP-growth 알고리즘은 Apriori 알고리즘과 유사한 목적을 가지고 있지만, 데이터셋을 반복적으로 스캔하는 과정을 피하기 위해 “FP-트리”라는 데이터 구조를 사용하여 계산 효율성을 크게 향상시킨다. FP-growth 알고리즘의 주요 과정은 다음과 같다.

먼저, 데이터셋을 기반으로 빈발 항목을 트리 구조로 표현하는 압축된 트리인 FP-트리를 생성한다. 이 트리 구조는 항목 간의 빈발 패턴을 효과적으로 나타내며, 이후 탐색을 용이하게 한다. 이후 FP-트리 구조를 기반으로 자주 나타나는 항목 집합을 탐색하고, 이를 바탕으로 연관 규칙을 도출한다.

식 4와 식 5는 FP-growth 알고리즘에서 연관 규칙 도출을 위해 사용하는 지지도(Support)와 신뢰도(Confidence)를 도출하기 위한 수식이다.

$$\text{Support}(A) = \frac{\text{Frequency of } A}{\text{Total number of transactions}} \quad (4)$$

$$\text{Confidence}(A \Rightarrow B) = \frac{\text{Support}(A \cup B)}{\text{Support}(A)} \quad (5)$$

3. GNN을 이용한 낙상 위험 포즈 추정

본 연구에서는 발견된 패턴과 연관 규칙을 GNN 모델에 적용하여 낙상 위험이 높은 자세를

보다 정밀하게 추정한다. GNN은 자세 데이터 간의 복잡한 관계를 모델링하는데 매우 유리한 도구로, 포즈 간의 상호작용을 효과적으로 학습할 수 있다. 이러한 학습 과정을 통해 GNN은 다양한 상황에서 발생할 수 있는 낙상 위험을 비교적 정확하게 예측할 수 있다.

GNN 모델은 그래프 구조를 활용해 데이터 간의 연결성과 상호작용을 반영하는데 강점을 지니고 있다[6]. 특히 자세 간의 시퀀스나 상호작용이 복잡할 때, 이러한 구조를 기반으로 각 자세 간의 관계를 더욱 정밀하게 파악할 수 있다. 이를 통해 낙상으로 이어질 가능성이 높은 자세 조합을 정확히 예측할 수 있으며, 사전에 위험을 감지해 대응할 수 있는 시스템 구축에 기여할 수 있다.

4. 낙상 위험 포즈 패턴에 대한 평가

제안하는 방법의 성능 평가는 GNN 기반 연관 규칙 마이닝을 이용한 낙상 위험 포즈 패턴 분석을 진행하였다. 해당 결과는 Accuracy, Precision, Recall, F1-Score 등의 평가 지표를 통해 성능 평가한다. 또한, 정성 평가 등을 통해서도 제안하는 방법의 유효성을 평가한다.

Accuracy는 모델이 전체 데이터에서 얼마나 정확하게 예측했는지를 나타내는 지표다. 이는 모델이 올바르게 분류한 샘플의 비율을 측정한다. 식 6은 Accuracy를 계산하는 수식이다.

$$\text{Accuracy} = \frac{TP + TN}{\text{Total Number of Samples}} \quad (6)$$

이는 모델의 전반적인 성능을 평가하는 데 유용하지만, 클래스 불균형이 있는 경우 오해를 불러일으킬 수 있다. 예를 들어, 데이터의 대부분이 낙상이 아닌 경우, 단순히 모든 샘플을 낙상이 아닌 것으로 예측하는 모델도 높은 Accuracy를 가질 수 있다.

Precision은 모델이 '양성(positive)'으로 예측

한 사례 중 실제로 양성인 비율을 의미한다. 이는 예측된 낙상 중 실제 낙상이 얼마나 정확하게 예측되었는지를 측정한다. 식 7은 Precision을 계산하는 수식이다.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (7)$$

Precision이 높은 모델은 낙상 예측이 정확하다는 것을 의미하며, 잘못된 경고(False Positives)가 적음을 나타낸다. 낙상과 같은 상황에서는 불필요한 경고를 줄이는 것이 중요하기 때문에, Precision은 매우 중요한 지표이다.

Recall은 실제 양성(positive) 사례 중에서 모델이 정확하게 예측한 비율을 나타낸다. 이는 실제 낙상 중에서 모델이 얼마나 많은 낙상을 정확히 탐지했는지를 나타낸다. 식 8은 Recall을 계산하는 수식이다.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (8)$$

Recall이 높을수록 모델이 놓치지 않고 실제 낙상을 잘 감지한다는 것을 의미한다. 이는 특히 낙상과 같은 중요한 이벤트를 놓치는 위험을 줄이는 데 필수적이다.

F1-Score는 Precision과 Recall의 조화 평균으로, 두 지표 간의 균형을 나타내는 지표다. 특히 Precision과 Recall 간의 Trade-off가 있을 때 유용한 평가 척도다. 식 9는 F1-Score를 계산하는 수식이다.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (9)$$

F1-Score는 Precision과 Recall이 모두 높은 경우 높은 값을 가지며, 이는 모델이 균형 잡힌 성능을 가지고 있음을 의미한다. 낙상 감지 시스템에서는 정확성과 감지율 모두가 중요하기 때문에, F1-Score는 종합적인 성능 평가에 유용하다.

표1은 이러한 평가 지표를 이용해 기존의 Open-Pose를 이용한 낙상 감지 성능과 본 논문

에서 제안하는GNN 기반 연관 규칙 마이닝을 DeepPose에 적용한 성능을 나타낸다. 또한, 최신Transformer 기반 포즈 추정 방법과의 비교 실험에서도 제안된 방법이Precision, Recall, F1-Score에서 더 우수한 성능을 보였다.

표 1. 제안하는 방법의 성능 평가

	Accuracy	Precision	Recall	F1-Score
OpenPose-based	97.4	97.1	97.2	97.1
Our Proposal	98.2	98.1	98.3	98.2

IV. 결 론

본 연구에서 제안한 GNN 기반 연관 규칙 마이닝을 활용한 낙상 위험 예측 모델은 기존의 웨어러블 장치 기반 시스템이 가진 한계를 효과적으로 극복하였다.

영상 처리 기술과 GNN의 결합을 통해 낙상 감지의 정확성과 효율성을 크게 향상시켰으며, 특히 DeepPose를 사용하여 수집된 포즈 데이터를 기반으로 FP-growth 알고리즘을 적용함으로써 연관 규칙을 도출하였다. 이를 GAT 모델에 적용하여 다양한 상황에서 발생할 수 있는 낙상 위험을 높은 정확도로 예측할 수 있었다.

이러한 성과는 고위험군의 낙상 예방과 관리에 중요한 기여할 것으로 기대되며, 실시간 모니터링 시스템과 연계를 통해 다양한 응용 가능성을 제시한다. 향후 연구에서는 이 방법의 적용 범위를 다양한 환경에서 실험하고, 실제 응용에서의 유효성을 검증하여 더욱 확장된 연구를 수행할 필요가 있다. 특히, 실제 환경에서 다양한 조명 조건과 배경 복잡성을 고려한 실험을 추가로 수행할 계획이다. 또한, 제안된 시스템을 모바일 장치에 최적화하여 실시간 낙상 예측 시스템으로 발전시킬 예정이다.

REFERENCES

- [1] Salimi, M., Machado, J. J., Tavares, J. M. R. (2022). Using Deep Neural Networks for Human Fall Detection Based on Pose Estimation. Sensors, vol. 22, no. 12, pp. 4544-4558.
- [2] Gupta, A., Matta, P., Pant, B. (2021). Graph neural network: Current state of Art, challenges and applications. Materials Today: Proceedings, 46, pp. 10927-10932.
- [3] Pradhyumna, P., Shreya, G. P. (2021, August). Graph neural network (GNN) in image and video understanding using deep learning for computer vision applications. In 2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC), IEEE, pp. 1183-1189.
- [4] Yang, Y., Ren, Z., Li, H., Zhou, C., Wang, X., Hua, G., (2021). Learning Dynamics via Graph Neural Networks for Human Pose Estimation and Tracking. arXiv:2106.03772
- [5] Veličković, P., Cucurull, G., Casanova, A., Romero, A., Lio, P., & Bengio, Y. (2017). Graph attention networks. arXiv preprint arXiv:1710.10903.
- [6] Alam, E., Sufian, A., Dutta, P., Leo, M. (2022). Vision-based human fall detection systems using deep learning: A review. Computers in biology and medicine, vol. 146, 105626, 2022.
- [7] Baek, J. W., Chung, K. (2023). Multi-Context Mining based Graph Neural Network for predicting Emerging Health Risk. IEEE Access, vol. 11, no. 1, pp. 15153-15163.
- [8] Jeon, B. U., Chung, K. (2022). CutPaste-Based Anomaly Detection Model using Multi Scale Feature Extraction in Time Series Streaming Data. KSII Transactions on Internet & Information Systems, vol. 16, no. 8, pp. 2787-2800.
- [9] Yoo, H., Chung, K. (2020). Deep Learning-based Evolutionary Recommendation Model for heterogeneous Big Data Integration. KSII Transactions on Internet and Information Systems, vol. 14, no. 9, pp. 3730-3744.

저자 소개



조한진(정회원)

1999년 한남대학교 컴퓨터공학과 석사 졸업
2002년 한남대학교 컴퓨터공학과 박사 졸업
2002년~현재 극동대학교 에너지IT공학과 교수

<주관심분야 : 인공지능, 정보보호, 클라우드, 빅데이터>