

SEM-Artificial Neural Network 2단계 접근법에 의한 클라우드 스토리지 서비스 이용의도 영향요인에 관한 연구

Guangbo Jiang* · 권순동**

A SEM-ANN Two-step Approach for Predicting Determinants of Cloud Service Use Intention

Guangbo Jiang* · Sundong Kwon**

Abstract

This study aims to identify the influencing factors of intention to use cloud services using the SEM-ANN two-step approach. In previous studies of SEM-ANN, SEM presented R^2 and ANN presented MSE(mean squared error), so analysis performance could not be compared. In this study, R^2 and MSE were calculated and presented by SEM and ANN, respectively. Then, analysis performance was compared and feature importances were compared by sensitivity analysis. As a result, the ANN default model improved R^2 by 2.87 compared to the PLS model, showing a small Cohen's effect size. The ANN optimization model improved R^2 by 7.86 compared to the PLS model, showing a medium Cohen effect size. In normalized feature importances, the order of importances was the same for PLS and ANN. The contribution of this study, which links structural equation modeling to artificial intelligence, is that it verified the effect of improving the explanatory power of the research model while maintaining the order of importance of independent variables.

Keywords : Structural Equation Modeling, Artificial Neural Network, SEM-ANN, Cloud Service, TAM, AI

1. 서론

최근 사회과학이나 경영학 분야에서 딥러닝 기술을 적용한 SEM-ANN 논문들이 발표되고 있다[Zabukovšek et al., 2019; Lau et al., 2021; Sharma et al., 2021]. 이는 SEM의 인과관계 설명의 장점과 ANN의 예측 정확도의 장점을 활용해 설명가능한 인공지능(XAI, eXplainable Artificial Intelligence)의 효과를 얻으려는 노력의 일환이다. SEM(structural equation modelling)은 관찰 가능한 측정변수(measurement variable)에 의해 간접적으로 측정되는 잠재변수(latent variable) 간의 구조적 인과관계를 다루는 구조방정식모형이다. SEM은 신뢰성과 타당성을 검증함으로써 측정에 따른 문제점을 확인하거나 통제할 수 있고, 이론 모형의 적합도를 확인하며, 연구가설을 검증할 수 있다는 장점이 있다. 그러나 SEM은 개념적으로 다르나 변수 간 상관성이 높으면 다중공선성 문제가 발생하여 유의한 관계를 유의하지 않다고 잘못 결론을 내릴 위험이 있다는 단점이 있다[Grewal et al., 2004].

ANN(artificial neural network)은 인간 두뇌의 뉴런(neuron)과 같은 역할을 하는 노드(node)들로 이루어진 은닉층을 인위적으로 쌓아 네트워크로 연결한(dense) 것이다. ANN은 순전파(forward propagation)와 역전파(back propagation) 과정을 반복하면서 실제값과 예측값의 오차를 최소화하는 노드 간의 가중치를 탐색한다. ANN은 SEM에 비해 예측력(또는 설명력)이 더 높다는 장점이 있다. 그러나 ANN은 모델이 복잡하여 노드 수나 은닉층 수가 많아지면, 마치 Blackbox처럼 해당 결과가 어떤 과정이나 근거로 나왔는지를 이해하거나 설명하기 어렵다는 단점이 있다. 따라서 ANN은 인과관계 검증에는 적합하지 않다.

SEM-ANN 2단계 접근법은 SEM의 인과관계 설명의 장점과 ANN의 높은 예측력의 장점을 결합한 것이다. 즉, 모델에 있는 변수 간의 인과관계를 설명하면서 예측력을 극대화하는 방법이다. SEM-ANN은 SEM 분석을 통해 신뢰성과 타당성과 인과성을 검증한 결과를 ANN의 입력값으로 투입하여 다시 학습한다는 점에서 일종의 전이학습(transfer learning)으로 볼 수 있다. SEM-ANN 연구는 2020년 이후에 경영

[Sharma et al., 2021], 보건의료[Nguyen et al., 2021; Chen et al., 2022], 교육[Binsawad, 2020] 등의 분야에서 많이 수행되었다. 그러나 SEM이 사회과학을 기반으로 연구한 반면, ANN은 공학을 기반으로 연구함으로써 데이터 분석 및 결과 해석에서 비교하지 못하는 한계점을 보였다. 예를 들어, SEM-ANN 논문의 상당수가 SEM 분석에서는 설명력(결정계수)인 R^2 만 제시하고, ANN 분석에서는 평균제곱오차(MSE, mean squared error)나 평균제곱근오차(RMSE, root mean squared error)만을 제시하여 SEM 분석결과를 ANN에 투입함으로써 얻게 되는 이점을 상호 비교하지 못하는 한계점을 보였다.

본 연구에서는 이러한 SEM과 ANN의 분석결과를 상호 비교 가능하도록 하였다. 이를 위해 SEM에서 R^2 와 MSE를 제시하고, SEM에서 사용한 동일한 계산 방식으로 ANN에서도 R^2 와 MSE를 계산하여 결과를 제시함으로써 SEM과 ANN의 결과를 상호 비교 가능하도록 하였다. 아울러 본 연구에서는 ANN 모델을 최적화함으로써 설명력과 예측오차가 어느 정도 개선되는지를 연구하였다.

2. 문헌연구

2.1 선행연구 검토

구조방정식모형(SEM)에서 관계를 추정하는 접근법으로 CB(covariance based)-SEM과 PLS(partial least squares based)-SEM이 있다. CB-SEM은 공분산을 기반으로 측정변수와 표본 공분산행렬 간의 차이가 최소화되는 모수를 추정하고, PLS-SEM은 독립 잠재변수와 종속 잠재변수 간의 공분산이 최대가 되는 잠재변수와 측정변수 간의 선형결합을 반복적으로 탐색하여 종속 잠재변수에 대한 설명력(R^2)이 최대가 되는(또는 잔차제곱합이 최소화되는) 경로계수를 추정하는 방법이다. CB-SEM은 주로 모델의 적합도 평가와 이론검증에 사용되고, PLS-SEM은 예측이나 설명 또는 이론 개발을 위한 탐색적 연구에 주로 사용된다. 통계분석 도구로서 CB-SEM은 AMOS가 주로 사용되고, PLS-SEM은 SmartPLS가 주로 사용된다.

경영정보 분야에서 SEM과 ANN을 연계한 연구는 2009년에 Scott & Walczak이 Information &

Management 저널에 게재된 ERP 주제로 시작되었다. SEM과 ANN을 연계한 연구들은 CB-SEM이나 PLS-SEM의 분석결과를 ANN의 입력 데이터로 투입하여 추가 분석하는 방식을 취하였다. 본 연구는 SEM의 설명력이 ANN을 통하여 얼마나 더 개선되는지에 초점을 맞추고 있다. 따라서 이론검증에 사용되는 CB-SEM보다 예측에 사용되는 PLS-SEM이 본 연구의 목적에 적합하다고 판단하여 PLS-SEM으로 분석한 다음 ANN으로 다시 분석한 선행연구를 검토하였다. <Table 1>은 이와 같은 방식의 선행연구를 검토하여 정리한 것이다. <Table 1>의 16개 논문은 SmartPLS 통계도구로 분석한 결과를 SPSS의 Neural Networks의 Multi-layer Perceptron (이하 SPSS MLP라 칭함)에 투입하여 추가 분석한 것이다.

<Table 1>에서 논문 1번부터 12번까지는 PLS의 분석결과로 R^2 를 제시하고, SPSS MLP 분석결과로 RMSE를 제시한 것이다. 논문 13번부터 16번까지는 PLS의 분석결과로 R^2 를, 그리고 SPSS MLP 분석결과로 R^2 와 RMSE를 제시한 것이다. 논문 1번부터 12

번까지는 모델 성능평가 도구가 설명력인 R^2 와 예측오차인 RMSE로 서로 달라서 PLS와 SPSS MLP의 분석결과를 비교할 수가 없다. 논문 13번부터 16번까지는 PLS의 R^2 와 SPSS MLP의 R^2 가 제시되어 있어서 비교 가능한 것처럼 보이나, SPSS MLP의 R^2 계산방식이 PLS와 달라서 사실상 비교가 불가능하다 (자세한 설명은 바로 다음 절에 설명하였다). 이처럼 선행연구에서는 SEM과 ANN의 연계를 통하여 얻는 성과를 서로 비교하지 못한다는 한계점이 있다. 따라서 본 연구에서는 PLS의 R^2 계산방식과 ANN의 R^2 계산방식을 일치시켜 분석모델의 성능을 상호 비교 가능하도록 하였다.

2.2 선행연구의 설명력과 예측오차 계산방식 검토

2.2.1 PLS의 R^2 계산방식

PLS의 R^2 계산방식은 선형회귀(linear regression)에서의 계산방식과 동일하다. R^2 는 결정계수(coefficient of determination), 설명력(explanatory power), 또는 예측력(predictive power)이

<Table 1> SEM-ANN Literature Review

No	Author	Research Topic	Data sample	PLS	SPSS MLP	
				R^2	R^2	RMSE
1	Zabukovšek et al.(2019)	ERP Extended use	208	0.320		0.134
2	Binsawad(2020)	Corporate Social Responsibility in Higher Education	205	0.732		0.085
3	Sohaib et al.(2020)	Cryptocurrency Use Intention	140	0.448		0.085
4	Alam et al.(2021)	Behavioral Intention of m-Health	434	0.453		0.469
5	Alharbi and Sohaib(2021)	Cryptocurrency Adoption	160	0.489		0.090
6	Lau et al.(2021)	Mobile Taxi Booking Adoption	330	0.591		0.092
7	Nguyen et al.(2021)	Behavioral Intention to Get Vaccination	474	0.566		0.089
8	Sharma et al.(2021)	Purchase Intention towards SMS advertising	483	0.619		0.403
9	Chen et al.(2022)	AI Adoption in Hospitality	290	0.490		0.416
10	Hayat et al.(2022)	Tax Compliance Behavior	250	0.610		0.487
11	Lo et al.(2022)	Buying on Live Commerce	295	0.534		0.084
12	Sharma et al.(2022)	Digital Assistant Purchasing Intentions	345	0.563		0.449
13	Abbasi et al.(2021)	Cryptocurrency Adoption	314	0.682	0.740	0.074
14	Alhumaid et al.(2021)	Mobile learning Use Intention	280	0.487	0.810	0.162
15	Al-Sharafia et al.(2022)	Virtual Meeting Platforms Use Intention	470	0.619	0.597	0.062
16	Rehman et al.(2022)	Smart Wearable Devices Use Intention	473	0.645	0.784	0.088

라 불리며, 독립변수가 종속변수를 얼마나 설명하거나 예측하는지를 결정하거나(determine) 제시하는 지표로 사용된다. 종속변수를 y 라 하고, 종속변수의 예측값을 \hat{y} (y hat)라 할 때, y 와 \hat{y} 의 차이를 제공하여 더한 값을 오차제곱합(SSE, sum of squared error)이라 하고, 종속변수 y 와 y 평균의 차이를 제공하여 더한 값을 편차제곱합(SSD, sum of squared deviation)이라 할 때, R^2 는 다음과 같이 산출된다.¹⁾ 결과적으로 R^2 산출식은 독립변수가 종속변수를 예측하는 모델이 종속변수의 평균값으로 예측하는 것에 비해 얼마나 더 우수한가를 보여준다.

$$R^2 = 1 - \frac{SSE}{SSD}$$

2.2.2 PLS의 MSE 계산방식

선형회귀(linear regression)에서는 평균제곱오차(MSE, mean squared error)나 MSE의 제곱근인 평균제곱근오차(RMSE, root mean squared error)를 계산한다. PLS 또한 선형회귀와 같은 방식으로 경로계수(coefficient)와 종속변수값을 예측하기 때문에 MSE나 RMSE 계산방식도 선형회귀와 동일하다. MSE는 종속변수 y 와 예측값 \hat{y} 의 차이인 오차(error, 또는 잔차 residual)를 제공하여 더한 오차제곱합(SSE, sum of squared error)을 샘플수로 나눈 값이다.²⁾ 그리고 RMSE는 MSE의 제곱근 값이다.

1) 선형회귀 분석에서 자유도(샘플수 n , 독립변수의 수 k , 상수항 1)를 고려하여 조정된 R^2 를 다음과 같이 계산하기도 한다. 그러나 PLS에서는 자유도를 고려하지 않고 R^2 를 계산한다. 또한 샘플수가 많은 Machine Learning이나 Deep Learning에서는 자유도를 고려하지 않고 R^2 를 계산한다.

$$\text{Adjusted } R^2 = 1 - \frac{SSE/(n-k-1)}{SSD/(n-1)}$$

2) 통계학에서 또는 데이터 샘플수가 적은 경우에는 자유도(샘플수 n , 독립변수의 수 k , 상수항 1)를 고려하여 MSE를 계산하기도 한다. 그러나 샘플수가 많은 Machine Learning이나 Deep Learning에서는 자유도를 고려하지 않고 MSE를 계산한다.

$$MSE = \frac{SSE}{(n-k-1)}$$

$$MSE = \frac{SSE}{n}$$

$$RMSE = \sqrt{\frac{SSE}{n}}$$

2.2.3 SPSS MLP의 상대오차 계산방식

SPSS의 Neural Networks의 Multi-layer Perceptron으로 분석한 결과에서는 상대오차(Relative Error)가 제시된다. 이것은 LinearRegression이나 PLS에서 R^2 를 계산하는 과정에서 있던 오차제곱합(SSE)을 편차제곱합(SSD)으로 나눈 값에 해당된다.

$$\text{상대오차(Relative Error)} = \frac{SSE}{SSD}$$

2.2.4 SPSS MLP의 MSE와 R^2 계산방식

ANN 관련 선행연구에서 제시된 MSE나 R^2 는 경사하강법(gradient descent)에 기반하여 계산한 것이다. 경사하강법은 실제값과 예측값의 차이인 오차의 제곱합 또는 평균제곱오차를 최소화한다는 점에서 선형회귀 분석의 MSE와 개념상 같지만, 편미분의 편리를 위해 오차의 평균제곱근오차를 2로 나눈다는 점에서 차이가 있다. 선행연구(Phillips et al., 2015; Leong et al., 2018; Leong et al., 2019; Elareshi et al., 2022)에서 인용된 경사하강법에 따라 RMSE와 R^2 계산과정을 살펴보면 다음과 같다. Phillips et al.[2015]의 연구에서는 패턴 p 에 대한 뉴런 o 의 원하는 출력값(desired output)을³⁾ d_o^p 로 표기하고, 이에 해당되는 출력값(correspondent output)을 y_o^p 로 표기하며, 원하는 출력값의 샘플수를 N_o 로 표기하고, 입력 패턴의 수를 N_p 로 표기할 때, 평균제곱근오차(RMSE) 계산식은 다음과 같다.

$$RMSE = \frac{1}{2} \sqrt{\frac{1}{N_p N_o} \sum_{p=1}^{N_p} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2}$$

다음으로 R^2 는 원하는 출력값(desired output)의 분산 s_y^2 로 RMSE를 나누어 계산한 값으로 1을 차

3) 원하는 출력값(desired output)은 PLS에서의 실제값을 의미하고, 해당되는 출력값(correspondent output)은 PLS에서의 예측값을 의미한다.

감하여 산출한다.

$$R^2 = 1 - \frac{RMSE}{s_y^2}$$

Phillips et al.[2015]이 제시한 계산방식에 따라 RMSE와 R^2 를 제시한 논문으로 Leong et al.[2018, 2019], Elareshi et al.[2022]이 있다.

2.3 PLS와 SPSS MLP 계산방식 비교

2.3.1 RMSE 비교검토

선형회귀나 PLS에서 RMSE는 종속변수 y 와 예측값 \hat{y} 의 차이를 제공하여 더한 SSE를 샘플수 n 으로 나눈 다음 제곱근을 취해($\sqrt{\frac{SSE}{n}}$) 계산한다. 이에 비해 SPSS MLP로 분석한 선행연구에서는 SSE를 샘플수 n 으로 나누어 제곱근을 취하는 것은 동일하지만, 결과값을 1/2로 나눈다는 점에서 차이가 있다 ($\frac{1}{2} \sqrt{\frac{1}{N_p N_o} \sum_{p=1}^{N_p} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2}$). 이것은 인공지능에서 경사하강법(gradient descent)으로 weight를 구할 때, 편미분의 편리를 위해 1/2을 추가하는 방식이 RMSE 계산에 반영되어 나타난 것으로 해석된다.

SPSS MLP로 분석한 논문들의 RMSE 계산식인 $\frac{1}{2} \sqrt{\frac{1}{N_p N_o} \sum_{p=1}^{N_p} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2}$ 를 PLS 관점에서 살펴보면 $\frac{1}{2} \sqrt{MSE}$ 또는 $\frac{1}{2} RMSE$ 이다. 예를 들어, SPSS MLP로 분석한 논문에서 RMSE가 0.25이면 PLS에서의 RMSE는 0.5로 2배가 된다. 따라서 PLS의 RMSE와 SPSS MLP의 RMSE를 동일선상에서 비교하는 것은 타당하지 않게 된다.

2.3.2 R^2 비교검토

SPSS MLP로 분석한 논문에서 R^2 는 RMSE를 원하는 출력값(desired output), 즉 실제값의 분산 s_y^2 으로 나누어 계산한 결과값을 1에서 차감하여 ($R^2 = 1 - \frac{SE}{s_y^2}$) 산출한다. 이에 비해 PLS에서는 SSE를 SSD로 나눈 결과값을 1에서 차감하여 ($R^2 = 1 - \frac{SSE}{SSD}$) 산출한다.

PLS의 R^2 계산식에 분자와 분모를 샘플수 N 으로 나누면 $R^2 = 1 - \frac{SSE/N}{SSD/N}$ 이 되는데, 여기서 분자인 SSE/N 은 MSE에 해당되고, 분모인 SSD/N 은 모집단 y 의 분산인 s_y^2 에 해당된다. 따라서 PLS의 R^2 는 $1 - \frac{MSE}{s_y^2}$ 가 된다. 따라서 R^2 계산과정에서 PLS와 SPSS MLP는 PLS의 MSE나 SPSS MLP의 RMSE나에서만 차이가 있다. 이것을 PLS 관점에서 해석하여 표현하면, PLS의 MSE나 SPSS MLP의 $\frac{1}{2} \sqrt{MSE}$ (또는 $\frac{1}{2} RMSE$)나 하는 차이이다.

만약 SPSS MLP의 RMSE($\frac{1}{2} \sqrt{\frac{1}{N_p N_o} \sum_{p=1}^{N_p} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2}$)가 0.25라면, PLS의 RMSE는 0.5 그리고 MSE는 0.25가 되어, 이를 가지고 R^2 를 계산하면 SPSS MLP는 $1 - \frac{0.25}{s_y^2}$, PLS는 $1 - \frac{0.25}{s_y^2}$ 로 같아지게 된다. 그러나 만약 SPSS MLP의 RMSE가 0.25 미만이면, R^2 에 있어서 PLS가 SPSS MLP보다 더 크게 된다. 그러나 만약 SPSS MLP의 RMSE가 0.25를 초과하면, R^2 에 있어서 SPSS MLP가 PLS보다 더 크게 된다.⁴⁾ 따라서 R^2 에 있어서 PLS와 SPSS MLP를 동일선상에서 비교하는 것은 타당하지 않게 된다.

2.3.3 본 연구의 계산방법

본 연구에서는 PLS의 분석결과와 SPSS MLP의 분석결과를 동일선상에서 비교 분석하기 위해 PLS의 R^2 계산방식과 MSE 계산방식을 그대로 SPSS MLP에 적용하여 계산하였다. 본 연구의 데이터 분석 결과의 예측오차와 설명력 계산과정은 다음과 같다. 계산과정에서 y : 종속변수의 실제값, \bar{y} : 종속변수의 실제값의 평균, \hat{y} : 종속변수의 예측값, n : 샘플수를 의미한다.

4) 예를 들어, SPSS MLP의 RMSE가 0.2이면, SPSS MLP의 R^2 는 $1 - \frac{0.2}{s_y^2}$, PLS의 R^2 는 $1 - \frac{0.16}{s_y^2}$ 로, 분산 s_y^2 동일하기 때문에 결과적으로 PLS의 R^2 가 더 크게 된다. SPSS MLP의 RMSE가 0.3이면, SPSS MLP의 R^2 는 $1 - \frac{0.3}{s_y^2}$, PLS의 R^2 는 $1 - \frac{0.36}{s_y^2}$ 로, 결과적으로 SPSS MLP의 R^2 가 더 크게 된다.

$$SSE(\text{sum of squared error}) = \sum_1^n (y - \hat{y})^2$$

$$SSD(\text{sum of squared deviation}) = \sum_1^n (y - \bar{y})^2$$

$$MSE = \frac{SSE}{n}$$

$$R^2 = 1 - \frac{SSE}{SSD}$$

3. 연구모형과 연구가설

3.1 연구대상

3.1.1 클라우드 스토리지 서비스

클라우드 스토리지 서비스(cloud storage service)는 클라우드 컴퓨팅 서비스의 한 종류이다. 클라우드 컴퓨팅은 인터넷으로 사용자에게 컴퓨팅 리소스를 제공하는 분산 컴퓨팅 시스템이다[Varghese et al., 2018]. 클라우드 컴퓨팅 서비스는 소프트웨어 서비스(SaaS), 인프라 서비스(IaaS), 플랫폼 서비스(PaaS)로 구분되는데, 클라우드 스토리지 서비스(cloud storage service)는 IaaS에 해당된다[Buyya et al., 2009]. 클라우드 스토리지 서비스는 사용자가 인터넷을 통해 데이터를 생성, 저장, 검색, 업데이트, 삭제할 수 있는 개인화된 온라인 저장 공간이다[Wu et al., 2017]. 클라우드 스토리지 서비스는 랜섬웨어와 같은 바이러스에 대처하는 수단이 된다.

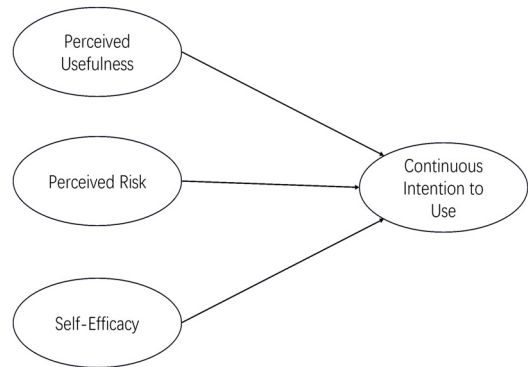
3.1.2 랜섬웨어

랜섬웨어(Ransomware)는 몸값을 의미하는 ransom과 software의 합성어로서 사용자 동의 없이 시스템에 설치되어 파일을 암호화한 다음 이를 풀어 정상 작동하게 하는 대가로 금전을 요구하는 악성 코드이다. 케르베르(Cerber), 크립토타커(CryptoLocker), 워너크라이(Wanna Cry) 등이 잘 알려져 있다. 이 가운데 워너크라이는 2017년에 등장하여 강력한 전염력으로 전 세계적으로 매우 큰 영향을 주었다. 바이러스들은 일반적으로 컴퓨터의 소프트웨어나 하드웨어를 파괴하거나 데이터를 유출하는 데 비해 랜섬웨어는 인질 강도처럼 협박하고 금품을 요구하는 특성이 있다.

3.2 연구모형

본 연구의 목적은 PLS와 ANN의 예측 성능을 비교

연구하는 것이다. 본 연구를 위해 사용된 연구모형은 클라우드 스토리지 서비스의 인지된 유용성, 인지된 위험, 자기효능감이 클라우드 스토리지 서비스의 지속이용의도에 영향을 미친다는 것이다. 본 연구모형은 Davis가 1989년도에 주장한 인지된 유용성과 인지된 용이성이 이용의도에 영향을 준다는 TAM(technology acceptance model)(Davis, 1989)에 랜섬웨어에 대한 사용자의 위험인식과 자기효능감을 추가한 것이다. 그러나 인지된 용이성은 클라우드 서비스에 로그인만 하면 파일 탐색기처럼 누구나 쉽게 사용할 수 있기 때문에 인지된 용이성은 연구모형에서 고려하지 않았다. 본 연구의 모형은 <Figure 1>과 같다.



<Figure 1> Research Model

3.2.1 인지된 유용성과 지속이용의도

인지된 유용성(perceived usefulness)은 새로운 기술과 서비스를 이용하는 것이 그것을 이용하지 않는 것보다 목적 달성에 더 도움이 된다고 지각하는 정도를 의미한다[Davis, 1989; Venkatesh et al., 2003]. 클라우드 스토리지 서비스는 PC나 모바일 디바이스에 저장된 개인정보나 콘텐츠를 클라우드 스토리지와 동기화하는 편리한 기능을 제공하고 있다. 그리고 데이터를 자동 백업 및 복구하는 기능을 제공하고 있다. 정보 기술에 관한 다양한 분야에서 지각된 유용성은 이용의도에 영향을 미치는 요인으로 제시되었다[Ahmed et al., 2020; Mariani et al., 2021; Sultana et al., 2020; Almaroi et al., 2019]. 이용자가 클라우드 스토리지 서비스의 유용성에 대해 인지할수록 서비스 이용의도는 높아진다고 볼 수 있다.

3.2.2 인지된 위험과 지속이용의도

인지된 위험(perceived risk)은 사용자가 어떠한 선택적 상황에서 주관적으로 인식하게 되는 위험이다. 인지된 위험은 경제적 손실이나 불확실성으로 인한 심리적 불안으로 의사결정을 지연시키거나 포기시키는 부정적인 효용으로 작용한다[Kwon et al., 2012]. 인지된 위험은 성과, 사회, 시간, 재정, 프라이버시, 신체적 및 심리적 위험 등이 있다[Wu et al., 2015]. 사용자가 랜섬웨어 바이러스에 감염되면 심리적 스트레스나 경제적 손실이나 시간적 손실을 경험할 수 있다. 본 연구에서 인지된 위험은 사용 중인 PC나 스마트폰, 태블릿 등이 바이러스에 감염될 수 있다고 인지하거나, 바이러스에 감염될 경우에 시스템이 고장나거나 데이터가 손실되거나 유출될 위험이 있다고 인지하는 것을 의미한다. 사용자가 랜섬웨어 바이러스에 대한 감염위험, 정보유출위험, 정보삭제위험 등을 인식하면 클라우드 스토리지 서비스의 이용의도가 높아진다고 예상할 수 있다. 클라우드 스토리지가 안전한 접근과 데이터의 안전성을 제공하여 위험을 감소시킬 수 있다고 인지할 수 있기 때문이다.

3.2.3 자기효능감과 지속이용의도

자기효능감(self-efficacy)은 어떤 행위를 수행하는 능력에 대한 자신감이다[Bandura, 1977]. 본 연구에서 자기효능감은 컴퓨터 바이러스에 대한 예방, 퇴치,

복구의 자신감을 의미한다. 자기효능감은 PC나 모바일 기기에 백신 프로그램을 설치하거나 주기적으로 업데이트할 수 있는 자신감을 의미하고, 홈페이지 링크, 첨부파일, 프로그램 등에 바이러스가 존재하는지를 확인할 수 있는 효능감을 의미하며, 바이러스에 감염되었을 때 백신 프로그램을 이용하여 시스템을 복구시킬 수 있는 자신감을 의미한다. 사회 인식 이론에 의하면 자기효능감이 높은 사람은 옳은 행동을 수행할 가능성이 더 높고[Rimal, 2000], 자기효능감은 기술 사용 행위의 중요한 결정 요인으로 작용하고 있다[Agarwal et al., 1998; Ratten, 2013; Kranthi et al., 2018]. 본 연구는 랜섬웨어 바이러스를 대상으로 하고 있다. 랜섬웨어 바이러스는 기존의 다른 바이러스와 달리 일단 감염되면 복호화 키 없이는 감염된 데이터를 복구하기 어렵다. 자기효능감이 높은 사람은 랜섬웨어의 효과적인 예방수단이 클라우드 스토리지 서비스 이용이라 인식할 수 있기 때문에 자기효능감이 높을수록 클라우드 스토리지 서비스의 지속이용의도가 높을 수 있다고 예상할 수 있다.

4. 연구방법론

4.1 설문문항과 데이터 특성

연구모형 검증에 사용된 설문은 선행연구에서 사용된 설문 문항을 클라우드 스토리지 서비스 이용 환경에 적합하도록 수정한 것이다. 클라우드 스토리지 서비스

〈Table 2〉 Construct and Survey Items

Construct	Survey items
Perceived usefulness	Cloud storage services (CSS) synchronize personal information stored on a PC or mobile device
	CSS automatically backs up and restores data stored on a PC or mobile device
	CSS automatically synchronizes video/audio/image files
Perceived risk	I think my current PC, smartphone, tablet, etc. are exposed to viral infection.
	I think there is a risk of personal information leakage in my current PC, smartphone, tablet, etc.
	I think there is a risk of loss, damage, and leakage of data stored on my PC, smartphone, tablet, etc.
Self-efficacy	I have confidence in preventing the virus by installing a vaccine or program on my PC or mobile tablet.
	I can update my PC or mobile tablet periodically to prevent the virus.
	I am confident in recovering a PC or mobile tablet with a vaccine or program when it is infected with a virus.
	I am confident in judging websites, attachments, programs, links, etc. where viruses may exist.
Continuous intention to use	I am confident in preventing, fighting and recovering the virus.
	I will continue to use the current CSS.
	I will continue to use the current CSS often.
	I will continue to actively use the CSS I currently use for my life or work.
	In the future, I will actively share content with close people using the current CSS.
	In the future, I will continue to use CSS even when changing my PC or mobile device.

의 지속이용의도와 인지된 유용성은 Venkatesh et al.(2003)의 설문 문항을 참조하였고, 인지된 위험은 Kwon et al.(2012)의 설문문항을 참조하였으며, 자기효능감은 Bandura(1977)의 설문 문항을 참조하였다. 본 연구에 사용한 설문문항은 <Table 2>와 같다.

본 연구에 사용된 데이터 샘플수는 310개이다. 이것은 랜섬웨어가 2015년에 전 세계를 강타한 이듬해인 2016년 10월에 랜섬웨어에 관심이 있는 사람들의 온라인 커뮤니티에서 랜섬웨어 감염 경험자 152명과 비경험자 158명을 대상으로 설문조사한 결과이다. 설문조사는 온라인 커뮤니티에 활동하는 사람들을 대상으로 진행되었고, 총 391부의 설문이 회수되었는데, 이 가운데 81부는 응답이 불성실하여 제외되었다. 따라서 모형 분석에는 310부가 사용되었다. 응답자의 성별은 남성이 47.42%, 여성이 52.58%이고, 연령은 18~31세가 83.55%로 다수를 차지하였으며, 클라우드 스토리지 서비스 사용 경험은 6개월 미만인 38.71%이고, 6개월~2년 미만인 42.26%이며, 2년 이상이 19.03%이다.

4.2 분석도구

본 연구에서는 예측이나 설명에 적합한 PLS-SEM을 선택하였다. PLS-SEM은 CB-SEM에 비해 데이터 샘플수가 상대적으로 적거나 데이터가 정규분포를

따르지 않아도 분석이 가능하고, 반영지표(reflective indicator)뿐만 아니라 조형지표(formative indicator)를 포함한 연구모형도 분석이 용이하다는 특징이 있다. 데이터 분석을 위해서는 PLS-SEM 분석에 가장 많이 사용되고 있는 SmartPLS 소프트웨어를 사용하였다.

본 연구에서는 SmartPLS 분석을 통해 신뢰성과 타당성을 검증하고, 모형의 적합도를 확인하며, 경로 계수의 유의성을 검증하였다. 다음으로 SmartPLS 분석 결과로 산출된 잠재변수값(latent variables)을 ANN의 입력 데이터로 투입하여 분석하였다. ANN 분석에는 <Table 1>의 16편의 논문에서 모두 사용한 SPSS 소프트웨어의 Neural Networks의 Multi-layer Perceptron(이하 SPSS MLP라 칭함)를 사용하였다. SPSS MLP는 Forward propagation과 Back propagation 과정을 반복하면서 잔차를 최소화하는 노드 간의 가중치를 탐색한다.

4.3 측정모형

<Table 3>은 SmartPLS로 측정모형의 신뢰성을 확인한 결과이다. 각 구성개념의 AVE값은 0.5 이상이고, 복합신뢰도(CR)는 0.7 이상이며, 크론바하 알파는 0.6 이상으로 신뢰성이 있는 것으로 나타났다. 측

<Table 3> Reliability Test

Construct	Factor Loadings	AVE	CR	Cronbach's Alpha
Perceived usefulness	0.826	0.712	0.881	0.797
	0.858			
	0.846			
Perceived risk	0.755	0.695	0.872	0.787
	0.877			
	0.865			
Self-efficacy	0.738	0.609	0.886	0.839
	0.770			
	0.745			
	0.815			
	0.829			
Continuous intention to use	0.816	0.684	0.915	0.884
	0.863			
	0.811			
	0.810			
	0.833			

〈Table 4〉 Discriminant Validity Analysis

	Perceived risk	Perceived usefulness	Continuous intention to use	Self-efficacy
Perceived risk	■ 0.834			
Perceived usefulness	△ 0.490	■ 0.844		
	◎ 0.605			
Continuous intention to use	△ 0.472	△ 0.711	■ 0.827	
	◎ 0.541	◎ 0.846		
Self-efficacy	△ 0.403	△ 0.389	△ 0.470	■ 0.780
	◎ 0.494	◎ 0.476	◎ 0.543	

※: ■ = Square root of AVE; △ = Correlation coefficient between variables ◎ = HTMT

정항목 각각의 요인적재값은 0.738~0.877 사이에 있고 요인값의 t값은 모두 1.96 이상으로 나타났다.

〈Table 4〉와 판별타당성을 검증한 결과이다. 표의 대각선은 AVE의 제곱근 값으로, 가장 작은 값(0.780)이 대각선 이외의 변수 간 상관계수 값의 가장 큰 값(0.711)보다 크게 나타났다. 다음으로 HTMT (heterotrait-monotrait ratio) 값이 0.476~0.846 사이로 기준치 0.85보다 낮게 나타나 판별타당성이 있는 것으로 나타났다.

5. 데이터 분석 및 논의

5.1 PLS 분석

연구모형의 적합도(Goodness-of-Fit, GoF)는 61.4%로 높게 나타났고, 독립변수의 종속변수에 대한 설명력인 R²는 55.76%로 나타났으며, MSE(평균제곱오차)는 0.4424로 나타났다. 연구모형의 각각의 경로계수는 5% 유의수준에서 모두 유의하게 나타났다. 따라서 클라우드 스토리지 서비스의 인지된 유용성($\beta = 0.580$, $t=10.973$)은 클라우드 스토리지 서비스의 지속이용의도에 유의한 영향을 미치는 것으로 나타났고, 인지된 위험($\beta = 0.107$, $t=1.961$)은 지속이용

의도에 유의한 영향을 미치는 것으로 나타났으며, 자기효능감($\beta = 0.201$, $t=3.922$)은 지속이용의도에 유의한 영향을 미치는 것으로 나타났다.

5.2 ANN 분석

5.2.1 ANN 기본 모델 분석

SEM-ANN 관련 선행연구에서는 대부분 SPSS MLP가 제공하는 기본 옵션에 따라 데이터분석을 수행하였다[Alharbi and Sohaib, 2021; Nguyen et al., 2021]. 따라서 본 연구에서는 선행연구와 마찬가지로 기본 옵션에 따라 모형을 분석하였다. 이를 위해 SPSS의 Neural Networks의 Multi-layer Perceptron의 Architecture 옵션을 Automatic architecture selection으로 선택하여 분석을 수행하였다. SmartPLS 분석을 통해 산출된 잠재변수값(latent variables)을 SPSS MLP의 입력값 중에서 90%를 훈련 데이터로 이용하고 나머지 10%를 검증 데이터로 이용하였다. 즉, 310개의 전체 데이터 중에서 279개를 무작위로 선택하여 훈련 데이터로 이용하고, 나머지 31개를 검증 데이터로 이용하였다. 그리고 인지된 유용성, 인지된 위험, 자기효능감을 신경망의 입력층으로 설정하고, 지속이용의도는 출력층으로

〈Table 5〉 PLS Analysis Results

Path	Coefficients	T-values	P-values	R ²	MSE
Perceived usefulness → Continuous intention to use	0.580	10.973	0.000	0.5576	0.4424
Perceived risk → Continuous intention to use	0.107	1.961	0.050		
Self-efficacy → Continuous intention to use	0.201	3.922	0.000		

설정하였다. <Figure 2>는 SPSS MLP로 분석한 ANN 분석결과와 network diagram이다.

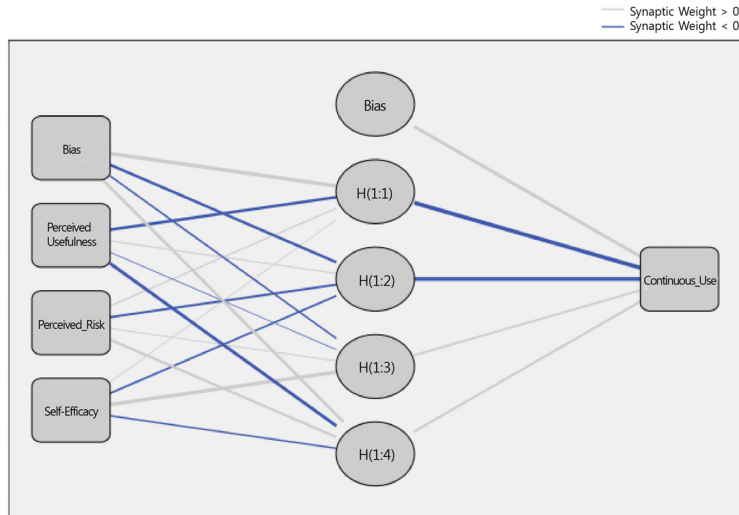
SPSS MLP 분석에서는 전체 데이터를 섞은 다음 (shuffle) 학습 데이터와 검증 데이터를 9:1 비율로 할당하여 10회 교차검증(cross validation)을 수행하였다. 그리고 PLS와 ANN의 예측(설명력) 성능을 비교하기 위해 R²와 MSE를 산출하였다. 이를 위해 학습 및 검증으로 구분된 종속변수 y와 SPSS MLP의 예측값 \hat{y} 를 Excel 파일로 저장한 다음 y(실제값)와 \hat{y} (예측값)의 오차(잔차, residuals)를 확인하여 R²

$$\left(1 - \frac{\sum(y - \hat{y})^2}{\sum(y - \bar{y})^2}\right) \text{와 } \text{MSE}\left(\frac{\sum(y - \hat{y})^2}{n}\right) \text{를 각각 계산하여}$$

여 <Table 6>과 같이 정리하였다.

ANN 10회 교차검증하여 산출한 평균값을 살펴보면, R²는 학습 데이터가 56.34%, 검증 데이터가 58.67%로 나타나 검증 데이터의 설명력이 2.33%만큼 약간 높게 나타났다. MSE는 학습 데이터가 0.43645, 검증 데이터가 0.3974로 나타나 검증 데이터의 오차가 0.0391만큼 미세하게 작게 나타났다.

R²에 대하여 PLS의 결과와 ANN과 검증 데이터의



<Figure 2> SPSS MLP Analysis Results

<Table 6> ANN Basic Model Analysis Results

Train data			Test data		
N	R ²	MSE	N	R ²	MSE
279	0.5290	0.4683	31	0.6354	0.3832
279	0.5737	0.4181	31	0.7093	0.3349
279	0.5218	0.4745	31	0.4531	0.5597
279	0.5793	0.4206	31	0.5200	0.4754
279	0.5911	0.4230	31	0.4209	0.3978
279	0.5950	0.4153	31	0.5667	0.3310
279	0.5866	0.4078	31	0.5422	0.5117
279	0.5135	0.4954	31	0.6217	0.3149
279	0.5662	0.4317	31	0.6999	0.2819
279	0.5776	0.4098	31	0.6975	0.3832
Mean	0.5634	0.4364	Mean	0.5867	0.3974
SD	0.0288	0.0295	SD	0.0979	0.0862

결과를 비교할 때, PLS가 55.76%이고, ANN이 58.67%로서 ANN이 2.87%만큼 약간 높게 나타났다. MSE에 대해서는 PLS가 0.4424, ANN이 0.3974로서 ANN의 오차가 0.0446만큼 약간 적게 나타났다.

본 연구에서는 PLS와 기본 ANN 모형 간의 R^2 차이를 코헨(Cohen, 1988)이 주장한 집단 간 평균 차이의 효과크기(effect size)를 구조조방정식모형에 적합하게 수정하여(Hair et al., 2016) 산출하였다. 구조방정식모형에서의 효과크기 f^2 는 외생잠재변수(독립변수)가 내생잠재변수(종속변수)에 미치는 영향의 크기를 의미하는데(Hair et al., 2016), 값이 0.35 이상인 경우를 큰 효과(large)라 하고, 0.15에서 0.35 사이인 경우를 중간 효과(moderate), 0.02에서 0.15 사이인 경우를 작은 효과(small)라 한다. 일반적으로 연구모형의 모든 변수를 포함하여 분석한 R^2 를 R^{2A} 라 하고, 연구모형에 변화를 주어(예를 들어, 어떤 한 변수를 제거하고) 분석한 R^2 를 R^{2B} 라 할 때, 효과크기 f^2 계산식은 다음과 같이 계산된다.

$$f^2 = \frac{R^{2A} - R^{2B}}{1 - R^{2A}}$$

PLS의 분석결과로 산출된 잠재변수값을 기본 ANN 모형에 투입하여 분석하였을 때의 효과크기 f^2 는

$$0.0704 (= \frac{0.5867 - 0.5576}{1 - 0.5867})$$

로 작게(small) 나타났다. 일반적으로 ANN이 PLS보다 예측 성능이 더 높다고 주장하는데(Sohaib et al., 2019; Elareshi et al., 2022; Duc and Viet 2022; Duc et al., 2023), f^2 확인 결과, ANN의 분석결과는 PLS 분석 결과에 비해 작은(small) 효과크기를 보였다.

5.2.2 ANN 민감도 분석

민감도 분석(sensitivity analysis)은 원래 모델에서 하나의 독립변수를 제거하거나 변화시켰을 때 모델의 결과가 어떻게 변하는지 분석하는 방법이다. SPSS MLP에서는 민감도 분석을 통해 독립변수의 종속변수에 대한 상대적 중요도(relative importance)를 계산한다. 상대적 중요도는 원래 모델을 학습시켜 결과를 산출하고, 다음으로 하나의 독립변수를 제거하거나 무작위로 섞은 변경 모델을 학습시켜 결과를 산출한 다음, 원래 모델의 결과와 변경 모델의 결과의 차이를 원래 모델의 결과로 나누어 상대적 중요도를 산출한다. 다음으로, 독립변수의 상대적 중요도 가운데 가장 큰 중요도로 각각의 상대적 중요도를 나누어 정규화된 변수 중요도(normalized variable importance)를 계산한다.

<Table 7>은 ANN 10회 교차분석하여 산출한 정규

<Table 7> ANN Basic Model - Normalized Feature Importances

	Perceived usefulness	Perceived risk	Self-efficacy
ANN(1)	0.555	0.225	0.220
ANN(2)	0.573	0.164	0.263
ANN(3)	0.592	0.150	0.258
ANN(4)	0.399	0.125	0.476
ANN(5)	0.654	0.234	0.111
ANN(6)	0.656	0.163	0.182
ANN(7)	0.522	0.147	0.331
ANN(8)	0.647	0.238	0.115
ANN(9)	0.462	0.174	0.364
ANN(10)	0.602	0.096	0.302
Mean	0.566	0.172	0.262

<Table 8> PLS Path Coefficients and Normalized Feature Importances

	Perceived usefulness	Perceived risk	Self-efficacy
Path Coefficients	0.580	0.107	0.201
Normalized Feature Importances	0.653	0.120	0.226

화된 변수 중요도이다. 변수 중요도의 교차분석 평균을 살펴보면, 첫째는 인지된 유용성(0.566)이고, 둘째는 자기효능감(0.262)이며, 셋째는 인지된 위험(0.172)으로 나타났다. <Table 8>은 PLS의 정규화된 변수 중요도로서, 인지된 유용성이 0.653으로 가장 크고, 자기효능감이 0.226, 인지된 위험이 0.12로 나타났다. ANN과 PLS의 정규화된 변수 중요도를 비교하면 값은 크기는 약간 차이가 있지만 크기의 순서는 같음을 알 수 있다.

5.2.3 ANN 최적화 모델 분석 결과

본 연구에서는 선행연구에서와 같은 방식으로 SPSS MLP에서 제공하는 기본 옵션에 따라 ANN 분석을 수행하였고, 그 결과 R²에서 ANN이 2.87%만큼 약간 높게 나타난 것을 확인하였다. 본 연구에서 SPSS MLP의 R²와 MSE를 더 향상시키기 위해 기본 옵션을 변경하여 최적화를 시도하였다.

SPSS MLP의 하이퍼파라미터 최적화를 위해 먼저 Architecture 옵션을 Custom architecture로 설정하고 은닉층수(Number of Hidden Layers)를 한 개(One)로 지정하고 노드수(Number of Units)를 Custom으로 선택하여 입력하였다. 노드수는 독립변수 개수인 3을 시작으로 9, 27, 81, 243, 729, 2187 순서로 증가하면서 분석하였다. 노드수를 독립변수 수의 거듭제곱으로 입력한 이유는 SPSS MLP에는 하이퍼파라미터 자동 탐색 기능이 없어 탐색시간 절약을 위해 휴리스틱으

로 선택한 방식이다. 하이퍼파라미터 탐색 결과, 첫 번째 은닉층에서는 노드수 243개일 때가 성능이 가장 우수하였다. 다음으로 첫 번째 은닉층의 노드수를 243개로 지정하고, 두 번째 은닉층의 노드수를 3, 9, 27, 81, 243, 729, 2187로 변경하면서 분석하였다. 결과적으로, 한 개 은닉층의 243개 노드수를 가진 ANN 모델이 성능이 가장 높게 나타났다. 다음으로 본 연구에서는 하이퍼파라미터를 최적화한 ANN 모델을 이용하여 10회 교차검증을 수행하였다. <Table 9>는 10회 교차검증한 결과를 표로 정리한 것이다.

최적화 ANN 모형의 10회 교차검증한 R² 평균값을 살펴보면, 학습 데이터에서 59.14%, 검증 데이터에서 63.62%로 나타났다. MSE는 학습 데이터에서 0.4071, 검증 데이터에서 0.3425로 나타났다. 하이퍼파라미터를 최적화한 ANN 모델과 기본 옵션으로 분석한 ANN 모델의 성능을 검증 데이터의 R²로 비교하면, 최적화 ANN 모델에서는 63.62%로 기본 ANN 모델의 58.67%보다 예측력이 4.95%만큼 더 향상되었고, 검증 데이터의 MSE로 비교하면, 최적화 ANN 모델에서는 0.3974로 기본 ANN 모델의 0.3425보다 예측오차가 0.0549만큼 줄어들었다.

PLS의 분석결과로 산출된 잠재변수값을 최적화 ANN 모형에 투입하여 분석했을 때에 코헨의 효과크기 f^2 는 $0.2161 (= \frac{0.6362 - 0.5576}{1 - 0.6362})$ 로 중간(moderate)으로 나타났다.

<Table 9> ANN Hyper-parameter Optimization Analysis Results

Train data			Test data		
N	R ²	MSE	N	R ²	MSE
279	0.6339	0.3787	31	0.3980	0.4135
279	0.6193	0.3904	31	0.5778	0.3225
279	0.6508	0.3445	31	0.5483	0.5049
279	0.4998	0.5094	31	0.6505	0.2909
279	0.5792	0.4188	31	0.6832	0.2976
279	0.6261	0.3627	31	0.7247	0.3487
279	0.5206	0.4553	31	0.6521	0.5040
279	0.5816	0.4209	31	0.6881	0.2552
279	0.6029	0.3710	31	0.8158	0.2799
279	0.5997	0.4194	31	0.6239	0.2079
Mean	0.5914	0.4071	Mean	0.6362	0.3425
SD	0.0460	0.0464	SD	0.1065	0.0961

〈Table 10〉 ANN Optimized Model - Normalized Feature Importances

	Perceived usefulness	Perceived risk	Self-efficacy
ANN(1)	0.554	0.121	0.325
ANN(2)	0.466	0.156	0.378
ANN(3)	0.628	0.215	0.157
ANN(4)	0.619	0.186	0.195
ANN(5)	0.574	0.148	0.279
ANN(6)	0.554	0.149	0.297
ANN(7)	0.481	0.285	0.234
ANN(8)	0.676	0.157	0.167
ANN(9)	0.523	0.155	0.321
ANN(10)	0.487	0.249	0.264
Mean	0.556	0.182	0.262

6. 결 론

6.1 PLS-SEM 분석 결과 요약

본 연구모형은 클라우드 서비스의 인지된 유용성, 인지된 위험, 자기효능감이 서비스의 지속이용의도에 영향을 미친다는 것이다. 연구모형을 PLS-SEM으로 신뢰성과 타당성을 검증하고 가설을 검증하였다. 분석 결과, 모형의 설명력인 R²는 55.8%로 나타났고, 평균 제곱오차인 MSE는 0.442로 나타났다. 그리고 서비스 지속이용의도에 미치는 인지된 유용성, 인지된 위험, 자기효능감의 영향은 5% 유의수준에서 모두 유의하게 나타났다. 첫째, 클라우드 서비스의 유용성은 지속이용의도에 가장 큰 영향을 미치는 것으로 나타났다. 둘째, 바이러스 문제해결에 대한 자기효능감은 지속이용의도에 다음으로 큰 영향을 미치는 것으로 나타났다. 이는 자기효능감이 높은 사람일수록 클라우드 스토리지를 랜섬웨어 예방의 효과적 수단으로 인식하여 서비스 지속 의도를 갖게 됨으로써 나타난 결과라 해석된다. 셋째, 바이러스에 대한 인지된 위험은 서비스 지속 의도에 유의한 영향을 미치는 것으로 나타났다.

6.2 SEM-ANN 예측 성능 비교

본 연구에서는 SEM과 ANN에서 둘 다 R²는 $1 - \frac{\sum(y - \hat{y})^2}{\sum(y - \bar{y})^2}$ 로 산출하고, MSE는 $\frac{\sum(y - \hat{y})^2}{n}$ 로 산출하여 분석 결과를 비교하였다. SEM을 ANN과 연계하여 2단계로 분석함으로써 설명력은 증가하고, 오차는 감소하는 것을 확인하였다. 그리고 ANN의 기본 모델보다 하이퍼파라미터를 최적화한 모델이 더 우수한 성능을 보이는 것을 확인하였다.

6.2.1 ANN 기본 모델 분석 결과 요약

PLS 분석을 통해 산출된 310개의 잠재변수값(latent variables) 중에서 90%는 훈련 데이터로 나머지 10%는 검증 데이터로 구분한 다음, 이를 SPSS MLP 입력값으로 투입하여 분석하였다. 선행 연구와 같은 방법으로 SPSS MLP가 제공하는 기본 옵션에 따라 10회 교차검증한 결과, 검증 데이터의 R²는 58.67%로 나타났고, 검증 데이터의 MSE는 0.3974로 나타났다. 이는 PLS의 R² 분석 결과와 비

〈Table 11〉 Predictive Performance Summary

	SmartPLS	SPSS MLP(Default)	SPSS MLP(Optimization)
R ²	0.5576	0.5867	0.6362
MSE	0.4424	0.3974	0.3425
f ²	-	0.0704	0.2161

* SmartPLS is the result of overall data analysis, and SPSS MLP is the result of test data analysis.

교할 때, 2.87만큼 높아진 것으로, 코헨의 효과크기로는 0.0704로 작은(small) 효과에 해당되었다.

6.2.2 ANN 최적화 모델 분석 결과 요약

본 연구에서는 ANN 기본 모델이 하이퍼파라미터 최적화를 통해 어느 정도 향상되는지 비교하였다. SPSS MLP에는 하이퍼파라미터 자동 탐색 기능이 없어서 휴리스틱에 의해 하이퍼파라미터 탐색을 14회 수작업으로 하였다. 그 결과, 한 개 은닉층의 243개 노드를 가진 ANN 모델이 가장 우수하여 이 모델로 10회 교차 검증하였다. 분석 결과, 검증 데이터의 R²는 63.62%로 나타났고, 검증 데이터의 MSE는 0.3425로 나타났다. 이는 PLS의 R² 분석 결과와 비교할 때, 7.86만큼 높아진 것으로, 코헨의 효과크기로는 0.2161로 중간(moderate) 효과에 해당되었다.

6.2.3 SEM-ANN 2단계 분석 변수 중요도 비교

<Table 12>는 인지된 유용성, 인지된 위험, 자기효능감의 정규화된 변수 중요도를 요약한 것으로, PLS-SEM 모델로 1회 분석한 결과와 ANN 기본 모델로 10회 교차분석한 평균과 ANN 최적화 모델로 10회 교차분석한 평균이다. 영향력의 순서는 인지된 유용성>자기효능감>인지된 위험 순으로 세 모형이 모두 동일하게 나타났다. 영향력의 크기에서는 PLS에서의 인지된 유용성의 영향력은 ANN에서 약간 줄어든 반면, PLS에서의 인지된 위험과 자기효능감의 영향력은 ANN에서 약간 증가함으로써 PLS와 ANN 간에 약간의 차이가 있는 것으로 나타났다. ANN 기본 모델과 ANN 최적화 모델 간에는 거의 차이가 없는 것으로 나타났다.

6.2.4 SEM-ANN 2단계 분석 효과성 논의

PLS-SEM의 분석결과를 ANN에 입력하여 분석

한 SEM-ANN 2단계 분석은 결과적으로 독립변수 영향력의 순서상 변화는 없고, 모형의 설명력은 높아진다고 종합할 수 있다. 연구 목적상 설명력(예측력) 향상이 중요한 경우라면 SEM-ANN 2단계 분석이 효과적이라 볼 수 있다.

6.3 연구의 시사점

본 연구의 이론적 시사점은 구조방정식모형에서의 전통적 분석방법에 인공지능 기법을 연계함으로써 얻게 되는 효과를 검증하였다는 점에서 의미가 있고, 지표 계산 및 분석 결과에 있어서 다음과 같은 시사점이 있다. 첫째, 동일한 성능 지표 계산식을 사용하여 비교 가능성을 확보하였다는 점이다. SEM-ANN 선행연구에서 대부분 SEM 분석에서는 R²만 제시하고, ANN 분석에서는 MSE(또는 RMSE)만을 제시하였으며, 일부 연구에서는 R²와 MSE 계산방법이 PLS-SEM과 SPSS-MLP가 서로 달라 상호 비교하지 못하는 한계점을 지녔다.

본 연구에서는 SEM과 ANN에서 R²를 $1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2}$

로 그리고 MSE를 $\frac{\sum (y - \hat{y})^2}{n}$ 로 동일 방식으로 계산하

여 결과를 비교하였다. 둘째, ANN 최적화 모델을 추가 분석하여 분석 성능을 향상시켰다는 점이다. SEM-ANN 선행연구에서는 대부분 SPSS MLP가 제공하는 기본 옵션에 따라 분석한 결과를 제시하였다. 본 연구에서는 PLS, ANN 기본 모델, ANN 최적화 모델을 각각 분석하여 예측 성능의 차이를 비교하였고, SEM-ANN 2단계 분석으로 인한 R² 향상 정도를 코헨의 효과크기에 따라 분석하여 PLS-기본ANN에서 작은 효과가 있고, PLS-최적화ANN에서는 중간 효과가 있는 것을 확인하였다는 점에서 의미가 있다.

본 연구의 실무적 시사점은 예측력을 높였다는 점이다. 먼저, PLS 분석을 통해 인과관계를 규명하였고, 다음으로, PLS 결과값을 인공신경망에 입력하여 분석하는

<Table 12> Normalized Feature Importances Comparison

	Perceived usefulness	Perceived risk	Self-efficacy
PLS-SEM model	0.653	0.120	0.226
ANN Basic Model (10 CV)	0.566	0.172	0.262
ANN Optimized Model (10 CV)	0.556	0.182	0.262

SEM-ANN 2단계 분석을 통하여 PLS의 55.76% 설명력을 63.62%로 향상시켰다. 이러한 설명력 향상으로 인해 구조방정식 모형을 현실에 적용할 때 문제의 원인을 더 잘 규명하고 저 정확하게 해결책을 제시하게 될 것이라 기대된다.

6.4 연구의 한계와 향후 연구의 제언

본 연구에서는 SEM과 ANN을 동일 조건에서 비교하지 않았다는 한계점이 있다. ANN은 학습 및 검증 데이터로 구분하고 10회 교차검증한 비례, PLS-SEM은 전체 데이터로 분석하였다. 만약 PLS-SEM에서도 전체 데이터를 학습 및 검증 데이터로 구분하고 10회 교차검증한다면 검증 데이터의 R^2 가 감소하여 비교 결과가 달라질 수도 있다. 따라서 PLS 분석에서 학습 데이터와 검증 데이터로 구분하고 교차검증하여 이를 ANN과 비교함으로써 보다 타당한 연구결과를 제시하는 것을 향후 연구로 제안하는 바이다.

다음으로, 본 연구에서는 하나의 데이터 세트만을 분석하여 제시하였기 때문에 일반화의 한계가 있다. 따라서 더 많은 데이터 세트를 분석하여 보다 일반화된 결과를 제시하는 것을 향후 연구로 제안하는 바이다.

마지막으로, 본 연구에서는 ANN 최적화 모델을 수작업 휴리스틱 방식으로 제한적으로 탐색했다는 한계점이 있다. AutoKeras 패키지와 같은 AutoML솔루션을 이용하면 ANN의 하이퍼파라미터를 더 빠르게 최적화하여 더 우수한 결과를 산출할 수 있으리라 기대된다. 따라서 SPSS MLP와 AutoKeras 비교 분석을 향후 연구로 제안하는 바이다.

References

- [1] Abbasi, G. A., Tiew, L. Y., Tang, J., Goh, Y. N., and Thurasamy, R., "The adoption of cryptocurrency as a disruptive force: Deep learning-based dual stage structural equation modelling and artificial neural network analysis", *Plos one*, Vol. 16, No. 3, 2021, p. e0247582.
- [2] According to a New IDC Forecast. [Online], "The Growth in Connected IoT Devices Is Expected to Generate", 79.4ZB of Data in 2025, 2020, Available: <https://www.idc.com/getdoc.jsp?containerId=prUS45213219>. Accessed on: Mar. 1.
- [3] Agarwal, R. and Prasad, J., "A conceptual and operational definition of personal innovativeness in the domain of information technology", *Information Systems Research*, Vol. 9, No. 2, 1998, pp. 204-215.
- [4] Ahmed, W., Hizam, S. M., Sentosa, I., Ali, J., and Ali, T., "Structural equation modeling for acceptance of cloud computing", In 2019 International conference on advances in the emerging computing technologies (AECT), IEEE, February 2020, pp. 1-6.
- [5] Alam, M. Z., Hu, W., Hoque, M. R., and Kaium, M. A., "Adoption intention and usage behavior of mHealth services in Bangladesh and China: A cross-country analysis", *International Journal of Pharmaceutical and Healthcare Marketing*, Vol. 14, No. 1, 2020, pp. 37-60.
- [6] Alhumaid, K., "Developing an educational framework for using mobile learning during the era of COVID-19", *International Journal of Data and Network Science*, Vol. 5, No. 3, 2021, p. 215.
- [7] Al-Sharafi, M. A., Al-Emran, M., Arpaci, I., Marques, G., Namoun, A., and Iahad, N. A., "Examining the impact of psychological, social, and quality factors on the continuous intention to use virtual meeting platforms during and beyond COVID-19 pandemic: A hybrid SEM-ANN approach", *International Journal of Human-Computer Interaction*, Vol. 39, No. 13, 2023, pp. 2673-2685.
- [8] Alharbi, A. and Sohaib, O., "Technology readiness and cryptocurrency adoption:

- PLS-SEM and deep learning neural network analysis”, *IEEE Access*, Vol. 9, 2021, pp. 21388-21394.
- [9] Ali, U., Mehmood, A., Majeed, M. F., Muhammad, S., Khan, M. K., Song, H., and Malik, K. M., “Innovative citizen’s services through public cloud in Pakistan: user’s privacy concerns and impacts on adoption”, *Mobile Networks and Applications*, Vol. 24, 2019, pp. 47-68.
- [10] Almazroi, A. A., Kabbar, E., Naser, M., and Shen, H., “Gender effect on cloud computing services adoption by university students: Case study of Saudi Arabia”, *International Journal of Innovation*, Vol. 7, No. 1, 2019, pp. 155-177.
- [11] Arpaci, I., “Understanding and predicting students’ intention to use mobile cloud storage services”, *Computers in Human Behavior*, Vol. 58, 2016, pp. 150-157.
- [12] Asadi, S., Nilashi, M., Husin, A. R. C., and Yadegaridehkordi, E., “Customers’ perspectives on adoption of cloud computing in the banking sector”, *Information Technology and Management*, Vol. 18, 2017, pp. 305-330.
- [13] Asadi, Z., Abdekhoda, M., and Nadrian, H., “Cloud computing services adoption among higher education faculties: development of a standardized questionnaire”, *Education and Information Technologies*, Vol. 25, 2020, pp. 175-191.
- [14] Bandura, A., “Self-efficacy: toward a unifying theory of behavioral change”, *Psychological Review*, Vol. 84, No. 2, 1977, p. 191.
- [15] Bhatia, T. and Verma, A. K., “Data security in mobile cloud computing paradigm: A survey, taxonomy and open research issues”, *The Journal of Supercomputing*, Vol. 73, 2017, pp. 2558-2631.
- [16] Burda, D. and Teuteberg, F., “The role of trust and risk perceptions in cloud archiving—Results from an empirical study”, *The Journal of High Technology Management Research*, Vol. 25, No. 2, 2014, pp. 172-187.
- [17] Binsawad, M. H., “Corporate social responsibility in higher education: A PLS-SEM neural network approach”, *IEEE Access*, Vol. 8, 2020, pp. 29125-29131.
- [18] Cohen, J. E., “*Statistical Power Analysis for the Behavioral Sciences*”, Hillsdale, NJ: Lawrence Erlbaum Associates, Inc., 1988.
- [19] Caudill, E. M. and Murphy, P. E., “Consumer online privacy: Legal and ethical issues”, *Journal of Public Policy & Marketing*, Vol. 19, No. 1, 2000, pp. 7-19.
- [20] Chen, S. L., Chen, J. H., and Chang, S. C., “Understanding the antecedents of individuals’ intention of using cloud services”, *Journal of Economics and Management*, Vol. 13, No. 2, 2017, pp. 139-166.
- [21] Chen, Y., Hu, Y., Zhou, S., and Yang, S., “Investigating the determinants of performance of artificial intelligence adoption in the hospitality industry during COVID-19”, *International Journal of Contemporary Hospitality Management*, Vol. 35, No. 8, 2023, pp. 2868-2889.
- [22] Chong, A. Y. L. and Bai, R., “Predicting open IOS adoption in SMEs: An integrated SEM-neural network approach”, *Expert Systems with Applications*, Vol. 41, No. 1, 2014, pp. 221-229.
- [23] Compeau, D. R. and Higgins, C. A., “Application of social cognitive theory to training for computer skills”, *Information Systems Research*, Vol. 6, No. 2, 1995,

- pp. 118-143.
- [24] Davis, F. D., "Perceived usefulness, perceived ease of use, and user acceptance of information technology", *MIS Quarterly*, 1989, pp. 319-340.
- [25] De Ruyter, K., Wetzels, M., and Kleijnen, M., "Customer adoption of e-service: an experimental study", *International Journal of Service Industry Management*, Vol. 12, No. 2, 2001, pp. 184-207.
- [26] Duc, M. L. and Viet, Q. N. K., "Analysis Affect Factors of Smart Meter: A PLS-SEM Neural Network", *International Research Journal on Advanced Science Hub*, Vol. 4, No. 12, 2022, pp. 288-301.
- [27] Duc, M. L., Bilik, P., and Martinek, R., "Analysis of Factors Affecting Electric Power Quality: PLS-SEM and Deep Learning Neural Network Analysis", *IEEE Access*, 2023.
- [28] Elareshi, M., Habes, M., Youssef, E., Salloum, S. A., Alfaisal, R., and Ziani, A., "SEM-ANN-based approach to understanding students' academic-performance adoption of YouTube for learning during Covid", *Heliyon*, Vol. 8, No. 4, 2022.
- [29] Featherman, M. S. and Pavlou, P. A., "Predicting e-services adoption: A perceived risk facets perspective", *International Journal of Human-Computer Studies*, Vol. 59, No. 4, 2003, pp. 451-474.
- [30] Featherman, M. S., Miyazaki, A. D., and Sprott, D. E., "Reducing online privacy risk to facilitate e-service adoption: The influence of perceived ease of use and corporate credibility", *Journal of Services Marketing*, Vol. 24, No. 3, 2010, pp. 219-229.
- [31] Featherman, M. S. and Pavlou, P. A., "Predicting e-services adoption: A perceived risk facets perspective", *International Journal of Human-Computer Studies*, Vol. 59, No. 4, 2003, pp. 451-474.
- [32] Grewal, R., Cote, J. A., and Baumgartner, H. "Multicollinearity and measurement error in structural equation models: Implications for theory testing", *Marketing Science*, Vol. 23, No. 4, 2004, pp. 519-529.
- [33] Gartner, "Gartner Forecasts Worldwide Public Cloud Revenue to Grow 17% in 2020", Accessed February 2020. [Online]. Available: <https://www.gartner.com/en/newsroom/press-releases/2019-11-13-gartner-forecasts-worldwide-public-cloud-revenue-to-grow-17-percent>.
- [34] Gharaibeh, A., Salahuddin, M. A., Hussini, S. J., Khreishah, A., Khalil, I., Guizani, M., and Al-Fuqaha, A. "Smart cities: A survey on data management, security, and enabling technologies", *IEEE Communications Surveys & Tutorials*, Vol. 19, No. 4, 2017, pp. 2456-2501.
- [35] Hair, J. F., Hult, G. T. M., Ringle, C. M., and Sarstedt, M., "A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)" (2nd ed.), Los Angeles, CA: Sage Publications, 2016.
- [36] Hammouri, Q. and Abu-Shanab, E. A., "Major factors influencing the adoption of cloud computing in Jordan", *International Journal of Technology and Human Interaction (IJTHI)*, Vol. 16, No. 4, 2020, pp. 55-69.
- [37] Hayat, N., Salameh, A. A., Mamun, A. A., Helmi Ali, M., and Makhbul, Z. K. M., "Tax compliance behavior among Malaysian taxpayers: A dual-stage PLS-SEM and ANN analysis", *SAGE Open*, Vol. 12, No. 3, 2022, p. 21582440221127190.
- [38] Hsieh, P. J., "An empirical investigation

- of patients' acceptance and resistance toward the health cloud: The dual factor perspective", *Computers in Human Behavior*, Vol. 63, 2016, pp. 959-969.
- [39] Hsieh, P. J. and Lin, W. S., "Explaining resistance to system usage in the PharmaCloud: A view of the dual-factor model", *Information & Management*, Vol. 55, No. 1, 2018, pp. 51-63.
- [40] Iimedia Research, 2022. Retrieved from: <https://www.iimedia.cn/c400/84607.html>.
- [41] Koehler, P., Anandasivam, A., and Ma, D., "Cloud services from a consumer perspective", *AIS*, 2010.
- [42] Kranthi, A. K. and Ahmed, K. A., "Determinants of smartwatch adoption among IT professionals: An extended UTAUT2 model for smartwatch enterprise", *International Journal of Enterprise Network Management*, Vol. 9, No. 3-4, 2018, pp. 294-316.
- [43] Kwon, S. D., Chun, D. Y., and Kim, Y. Y., "Reexamination of Effect of Perceived Risk on Purchasing Intention", *Journal of Information Technology Applications and Management*, Vol. 19, No. 2, 2012, pp. 233-247.
- [44] Lau, A. J., Tan, G. W. H., Loh, X. M., Leong, L. Y., Lee, V. H., and Ooi, K. B., "On the way: Hailing a taxi with a smartphone? A hybrid SEM-neural network approach", *Machine Learning with Applications*, Vol. 4, 2021, p. 100034.
- [45] Leong, L. Y., Hew, T. S., Ooi, K. B., Lee, V. H., and Hew, J. J., "A hybrid SEM-neural network analysis of social media addiction", *Expert Systems with Applications*, Vol. 133, 2019, pp. 296-316.
- [46] Leong, L. Y., Hew, T. S., Tan, G. W. H., and Ooi, K. B., "Predicting the determinants of the NFC-enabled mobile credit card acceptance: A neural networks approach", *Expert Systems with Applications*, Vol. 40, No. 14, 2013, pp. 5604-5620.
- [47] Leong, L. Y., Hew, T. S., Ooi, K. B., and Dwivedi, Y. K., "Predicting trust in online advertising with an SEM-artificial neural network approach", *Expert Systems with Applications*, Vol. 162, 2020, p. 113849.
- [48] Lopes, N. and Ribeiro, B., "An efficient gradient-based learning algorithm applied to neural networks with selective actuation neurons", *Neural, Parallel & Scientific Computations*, Vol. 11, No. 3, 2003, pp. 253-272.
- [49] Lo, P. S., Dwivedi, Y. K., Tan, G. W. H., Ooi, K. B., Aw, E. C. X., and Metri, B., "Why do consumers buy impulsively during live streaming? A deep learning-based dual-stage SEM-ANN analysis", *Journal of Business Research*, Vol. 147, 2022, pp. 325-337.
- [50] Mariani, M. M., Styven, M. E., and Teulon, F., "Explaining the intention to use digital personal data stores: An empirical study", *Technological Forecasting and Social Change*, Vol. 166, 2021, p. 120657.
- [51] Mollah, M. B., Azad, M. A. K., and Vasilakos, A., "Security and privacy challenges in mobile cloud computing: Survey and way ahead", *Journal of Network and Computer Applications*, Vol. 84, 2017, pp. 38-54.
- [52] Nicolaou, A. I. and McKnight, D. H., "Perceived information quality in data exchanges: Effects on risk, trust, and intention to use", *Information Systems Research*, Vol. 17, No. 4, 2006, pp. 332-351.
- [53] Nguyen, P. H., Tsai, J. F., Lin, M. H., and Hu, Y. C., "A hybrid model with spherical fuzzy-AHP, PLS-SEM, and

- ANN to predict vaccination intention against COVID-19”, *Mathematics*, Vol. 9, No. 23, 2021, p. 3075.
- [54] Phillips, P., Zigan, K., Silva, M. M. S., and Schegg, R., “The interactive effects of online reviews on the determinants of Swiss hotel performance: A neural network analysis”, *Tourism Management*, Vol. 50, 2015, pp. 130-141.
- [55] Rimal, R. N., “Closing the knowledge-behavior gap in health promotion: The mediating role of self-efficacy”, *Health Communication*, Vol. 12, No. 3, 2000, pp. 219-237.
- [56] Ratten, V., “Cloud computing: A social cognitive perspective of ethics, entrepreneurship, technology marketing, computer self-efficacy, and outcome expectancy on behavioral intentions”, *Australasian Marketing Journal*, Vol. 21, No. 3, 2013, pp. 137-146.
- [57] Rehman, I. H. U., Ahmad, A., Akhter, F., and Aljarallah, A., “A dual-stage SEM-ANN analysis to explore consumer adoption of smart wearable healthcare devices”, *Journal of Global Information Management (JGIM)*, Vol. 29, No. 6, 2021, pp. 1-30.
- [58] Scott, J. E. and Walczak, S., “Cognitive engagement with a multimedia ERP training tool: Assessing computer self-efficacy and technology acceptance”, *Information & Management*, Vol. 46, No. 4, 2009, pp. 221-232.
- [59] Senyo, P. K., Addae, E., and Boateng, R., “Cloud computing research: A review of research themes, frameworks, methods, and future research directions”, *International Journal of Information Management*, Vol. 38, No. 1, 2018, pp. 128-139.
- [60] Sharma, M., Joshi, S., Luthra, S., and Kumar, A., “Impact of digital assistant attributes on millennials’ purchasing intentions: A multi-group analysis using PLS-SEM, artificial neural network, and fsQCA”, *Information Systems Frontiers*, 2022, pp. 1-24.
- [61] Sheehan, K. B. and Hoy, M. G., “Dimensions of privacy concern among online consumers”, *Journal of Public Policy & Marketing*, Vol. 19, No. 1, 2000, pp. 62-73.
- [62] Sultana, J., “Determining the factors that affect the uses of Mobile Cloud Learning (MCL) platform Blackboard—a modification of the UTAUT model”, *Education and Information Technologies*, Vol. 25, No. 1, 2020, pp. 223-238.
- [63] Sohaib, O., Hussain, W., Asif, M., Ahmad, M., and Mazzara, M., “A PLS-SEM neural network approach for understanding cryptocurrency adoption”, *IEEE Access*, Vol. 8, 2019, pp. 13138-13150.
- [64] Teing, Y. Y., Dehghantanha, A., Choo, K. K. R., and Yang, L. T., “Forensic investigation of P2P cloud storage services and backbone for IoT networks: BitTorrent Sync as a case study”, *Computers & Electrical Engineering*, Vol. 58, 2017, pp. 350-363.
- [65] Trček, D., Trobec, R., Pavešić, N., and Tasič, J. F., “Information systems security and human behavior”, *Behaviour & Information Technology*, Vol. 26, No. 2, 2007, pp. 113-118.
- [66] Venkatesh, V. and Brown, S. A., “A longitudinal investigation of personal computers in homes: Adoption determinants and emerging challenges”, *MIS Quarterly*, 2001, pp. 71-102.
- [67] Venkatesh, V., Morris, M. G., Davis, G. B., and Davis, F. D., “User acceptance

- of information technology: Toward a unified view", *MIS Quarterly*, 2003, pp. 425-478.
- [68] Venkatesh, V., Thong, J. Y., and Xu, X., "Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology", *MIS Quarterly*, 2012, pp. 157-178.
- [69] Wu, K., Vassileva, J., and Zhao, Y., "Understanding users' intention to switch personal cloud storage services: Evidence from the Chinese market", *Computers in Human Behavior*, Vol. 68, 2017, pp. 300-314.
- [70] Wu, K., Vassileva, J., Noorian, Z., and Zhao, Y., "How do you feel when you see a list of prices? The interplay among price dispersion, perceived risk, and initial trust in the Chinese C2C market", *Journal of Retailing and Consumer Services*, Vol. 25, 2015, pp. 36-46.
- [71] Xia, Z., Shi, T., Xiong, N. N., Sun, X., and Jeon, B., "A privacy-preserving handwritten signature verification method using combinational features and secure kNN", *IEEE Access*, Vol. 6, 2018, pp. 46695-46705.
- [72] Xia, Z., Xiong, N. N., Vasilakos, A. V., and Sun, X., "EPCBIR: An efficient and privacy-preserving content-based image retrieval scheme in cloud computing", *Information Sciences*, Vol. 387, 2017, pp. 195-204.
- [73] Yang, H. L. and Lin, S. L., "User continuance intention to use cloud storage service", *Computers in Human Behavior*, Vol. 52, 2015, pp.219-232.
- [74] Sternad Zabukovšek, S., Kalinic, Z., Bobek, S., and Tominc, P., "SEM - ANN based research of factors' impact on extended use of ERP systems", *Central European Journal of Operations Research*, Vol. 27, 2019, pp. 703-735.
- [75] Zhang, J., Chen, B., Zhao, Y., Cheng, X., and Hu, F., "Data security and privacy-preserving in edge computing paradigm: Survey and open issues", *IEEE Access*, Vol. 6, 2018, pp. 18209-18237.

■ 저자소개



Guangbo Jiang

충북대학교 경영정보학과에서 석사 학위를 취득하였으며, 현재 충북대학교 대학원 경영정보학과 박사과정을 수료하였다. 주요 관심분야는 Machine Learning 및 Deep Learning 기반의 데이터 분석과

SEM-ANN 2단계 분석이다.



권 순 동

현재 충북대학교 경영정보학과 교수로 재직하고 있다. 서울대학교 경영대학에서 경영정보학전공으로 박사 학위를 취득하였다. British Journal of Management, Journal of Information Technology Appli-

cation and Management, Information Systems Review, Asia Pacific Journal of Information Systems, 경영학연구, 한국경영과학회지, 기업경영연구, 경영과정정보연구 등의 국내·외 저널에 다수의 논문을 발표하였고, 저서 및 역서로 한국기업의 경영정보시스템 변천사(서울대), 경영정보시스템(생능출판사), B2B와 e마켓플레이스(법문사), 대학경영혁신과 정보인프라 구축(서울대) 등이 있다. 주요 관심분야는 SCM 기반의 Smart Factory, Machine Learning 및 Deep Learning 기반의 데이터경영 등이다.