

지역화폐 이상거래 탐지를 위한 머신러닝 모델 성능 비교

장예슬¹ · 이재우^{2*}

Comparison of Hybrid Machine Learning Model Performance for Local Currency Fraud Detection

Yeseul Chang¹ · Jaewoo Lee^{2*}

¹Ph.D Student, Department of Convergence Security, Chung-Ang University, Seoul, 06974 Korea

^{2*}Associate Professor, Department of Industrial Security, Chung-Ang University, Seoul, 06974 Korea

요 약

지역화폐가 지역 경제 활성화를 위한 대안화폐로 자리 잡으면서 지역화폐를 악용하는 사례가 증가하고 있다. 본 연구에서는 알려지지 않은 부정거래와 데이터 라벨부족 문제에 대응하기 위한 2단계의 머신러닝 프레임워크를 제시한다. 먼저 비지도학습 모델을 통해 라벨이 없는 데이터에서 pseudo label을 생성하였다. 이 과정에서 이상치 비율을 1%로 고정한 경우와 최적의 임계치를 모델 스스로가 결정한 경우의 차이를 분석하였다. 다음 단계에서는 라벨링된 데이터를 다양한 지도학습 모델로 훈련시키고 성능을 비교하였다. 그 결과 Random Forest, XGBoost, LightGBM과 같은 트리 기반 앙상블 모델이 가장 우수한 성능을 보였다. 특히 이상치 비율이 1%로 극히 제한된 환경에서는 XGBoost가, 이상치 범위가 완화된 환경에서는 Random Forest가 가장 높은 F1-Score를 기록했다. 이를 통해 라벨이 존재하지 않는 데이터만으로도 효과적인 이상거래 탐지가 가능함을 입증한다.

ABSTRACT

As local currencies become established as alternative currencies for revitalizing local economies, cases of abuse are on the rise. This study presents a two-stage machine learning framework to address the issues of unknown fraudulent transactions and a lack of data labels. First, we used an unsupervised learning model to generate pseudo-labels from unlabeled data. During this process, we analyzed the differences between fixing the outlier rate at 1% and allowing the model to determine the optimal threshold on its own. In the next step, we trained various supervised learning models on labeled data and compared their performance. As a result, tree-based ensemble models, such as Random Forest, XGBoost, and LightGBM, performed the best. In particular, XGBoost achieved the highest F1-Score in an environment with an extremely limited outlier rate of 1%, while Random Forest achieved the highest F1-Score in an environment with a relaxed outlier range. This demonstrates the potential for effective fraud detection even in unlabeled data.

키워드 : 지역화폐, 이상거래 탐지, 공공데이터, 하이브리드 머신러닝, 의사라벨

Keywords : Local Currency, Fraud Detection System(FDS), Public Data, Hybrid Machine Learning, Pseudo Label

Received 3 July 2025, Revised 24 July 2025, Accepted 12 August 2025

* Corresponding Author Jaewoo Lee(E-mail:jaewoolee@cau.ac.kr, Tel:+82-2-820-5935)

Associate Professor, Department of Industrial Security, Chung-Ang University, Seoul, 06974 Korea

Open Access <http://doi.org/10.6109/jkiice.2025.29.9.1221>

pISSN:2234-4772

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

지역화폐는 특정 지역 내에서만 통용되는 대안화폐의 한 종류로 전 세계적으로 지역 경제 순환을 촉진하는 수단으로 활용되고 있다[1,2]. 해외에서는 주로 지역 공동체 중심의 비영리 기반으로 운영되고 있으나 국내에서는 정부 주도하에 경제 활성화 및 복지 정책의 일환으로 도입되어 빠르게 확산되었다. 특히 경기도의 청년 배당을 시작으로 여러 지방자치단체가 지역사랑상품권을 발행하며 시민들을 위한 실질적인 금융 인프라로 자리 잡았다. 전국 지자체를 통해 판매된 지역화폐는 2021년 이후부터 매년 20조 이상으로 집계되며 실제 사용자들의 적극적인 사용 사례가 보도되었다[3].

그러나 지역화폐의 긍정적 효과 이면에 ‘부정거래’라는 그림자가 존재한다. 부정거래란 할인된 가격에 구매한 지역화폐를 현금화하는 부정유통 행위[4,5]나 실제 재화의 판매 또는 용역 제공 없이 거래를 위장하여 부당이익을 취하는 행위이다. 행정안전부가 발표한 ‘2024년 상반기 지역사랑상품권 일제단속 결과’에 따르면 부정유통 적발 사례는 꾸준히 증가하고 있으며, 특히 부정수취와 불법환전의 비중이 높아지는 추세이다[5]. 이에 각 지자체는 특별 점검을 강화하고 이상거래 탐지 시스템(Fraud Detection System; FDS)을 도입하여 대응하고 있으나 그 실효성에는 여전히 한계가 있다[6].

기존의 규칙 기반 FDS는 사전에 정의된 시나리오에 의존하기 때문에 이를 교묘히 회피하는 새로운 유형의 부정거래를 탐지하기 어렵다. 알려진 부정행위 적발에는 유용하지만 진화하는 사기 수법을 따라잡기에는 역부족이다[7,8]. 또한 국내 지역화폐 연구는 주로 경제적 파급효과나 정책적 영향 분석과 같은 거시적 관점에 치중되어 있어 데이터 기반의 이상거래 탐지 연구가 필요하다[9,10,11].

본 연구는 데이터 주도적 접근을 통해 지역화폐 이상거래 탐지 방안을 다음과 같이 제안한다. 라벨이 없는 공공 데이터로부터 신뢰성 있는 이상거래 패턴을 식별하기 위해 비지도학습과 지도학습을 결합한 2단계 머신러닝 학습 프레임워크를 적용한다. 1단계에서는 비지도학습 알고리즘으로 데이터 내에 잠재된 이상 징후를 탐색하여 pseudo label(의사라벨)을 생성한다. 2단계에서는 pseudo label을 기반으로 다양한 지도학습 모델을 훈련한 후 성능을 비교하여 지역화폐 데이터의 특성에 적

합한 이상거래 탐지 모델을 도출한다.

지역화폐 부정거래 방법이 다양해짐에 따라 본 연구는 지도학습과 비지도학습을 결합한 이상거래 탐지 프레임워크를 사용하여 사전에 정의된 규칙만으로는 발견하기 어려운 신규 이상 징후를 선별한다. 라벨이 없는 데이터에 pseudo label을 생성하여 이상거래를 탐지하고 개인 거래내역이 아닌 집계 데이터만으로도 탐지가 가능함을 입증한다. 이를 통해 알려지지 않은 지역화폐 부정거래로 인한 피해를 감소시키는 데 실질적으로 기여하고자 한다.

II. 관련연구

2.1 지역화폐 공공데이터 활용

전자정부법에 기반하여 정부는 다양한 행정 데이터를 공공데이터로 개방하고 있다. 각 지자체는 지역화폐의 발행·사용 내역을 월별, 시·군·구 단위로 집계하여 제공하고 있다[12,13,14]. 지역화폐의 경제적 효과를 분석하는 연구에 이러한 데이터가 활발하게 활용되어 왔으나[15,16] 부정거래 탐지 목적의 연구는 부족한 실정이다. 공공데이터는 개인정보보호를 위해 개인 식별자가 제거된 월별 집계 데이터 형태를 띠며, 실제 부정거래 여부를 나타내는 정답 라벨(ground truth label)이 존재하지 않는 데이터 구조적 한계가 있다. 이는 주로 라벨이 있는 데이터를 학습에 사용하여 이상거래를 탐지하는 일반적인 지도학습 모델에 적용하기 어렵다.

2.2 이상탐지 연구

머신러닝을 활용한 이상탐지 연구는 다양한 분야에서 활발히 진행되고 있다. 정보통신 분야에서는 Auto Encoder[17]나 Isolation Forest[18]등의 비지도학습 모델을 활용하여 네트워크 침입 및 보안 로그의 이상 패턴을 탐지하는 연구가 수행되었고 악성 URL의 특징을 학습 후 분류하는 지도학습 연구도 존재한다[19,20,21].

금융 분야에서도 전통적인 규칙 기반 FDS의 한계를 극복하기 위해 머신러닝 기반의 이상거래 탐지기법을 채택하고 있다[22,23]. 특히 기업의 거래정보 데이터에 지도학습을 사용하여 알려진 사기 패턴을 분류하고, 알려지지 않은 이상 패턴은 비지도학습으로 발굴하는 하이브리드 기반의 다양한 연구가 진행되고 있다[24,25].




Fig. 1 FDS detection performance comparison process

2.3 연구의 차별성

대부분의 이상거래 탐지 연구는 이상거래로 라벨링된 개별 거래내역 데이터를 사용하지만 본 연구에서는 라벨이 없는 집계 데이터를 사용한다는 차이가 존재한다[26,27]. 거래금액 급증과 같은 이상거래 라벨 정보는 기업의 자산으로 외부에 공개되지 않으며 공공데이터 기반의 지역화폐 연구에 직접 적용하기는 어렵다. 또한 금융감독원에서 권장하는 이상거래 탐지 규칙들은 주로 개인 또는 단말 식별을 전제로 하고 있어 본 연구에서 다루는 집계 데이터 분석에 적합하지 않다[28,29].

이러한 문제를 해결하기 위해 라벨이 없는 데이터를 비지도학습으로 분석하여 pseudo label을 생성하고 이를 지도학습에 활용하는 하이브리드 형태의 접근법이 연구되고 있다[30,31]. 특히 IFC Working Papers에서는 비지도학습 모델인 IF로 pseudo label을 생성하고 이를 지도학습 분류에 사용하여 이상징후를 탐지하는 방법을 제안하였다[31].

본 연구는 이러한 하이브리드 머신러닝 프레임워크를 지역화폐 공공데이터에 적용하고, 한 단계 더 나아가 단일 비지도학습을 사용하는 여러 모델과 이들의 앙상블(Ensemble) 결과를 비교한다. 또한 내부 클러스터 검증 지표를 통해 생성된 pseudo label의 신뢰도를 정량적으로 평가하여 가장 안정적인 pseudo label을 선정한다. 이렇게 선정된 pseudo label을 시간 순서로 구조화된 지역화폐 데이터에 적용하여 이상거래 탐지에 가장 효과적인 지도학습 모델이 무엇인지 체계적으로 비교·분석한다는 점에서 기존 연구와 차별점을 갖는다.

III. 연구방법

고도화되는 지역화폐 부정거래를 다각도로 탐지하기 위해 본 연구에서는 비지도학습 기반의 pseudo label을 생성하고 이를 지도학습에 적용하는 하이브리드 머신러닝 기반의 이상거래 탐지 방법을 제안한다. 일반적인 이상거래 탐지에 사용되는 금융데이터와 달리 본 연구에서 사용하는 지역화폐 공공데이터의 경우 라벨이 존재하지 않아 비지도학습을 통해 예측한 이상치로 pseudo label을 생성해 라벨 부재 문제를 해결한다. 이후 최적의 지도학습 모델로 이상거래를 탐지하는 비지도·지도 기반의 하이브리드 머신러닝 방법을 제안한다.

본 연구는 지역화폐 데이터의 이상거래를 효과적으로 탐지하는 최적의 지도학습 모델을 발굴하기 위해 그림 1과 같이 3단계의 프레임워크를 설계한다. 그림 1 (a), (b)는 경기데이터트림[32]에서 지역화폐 관련 데이터를 수집하고, 분석에 적합한 형태로 특징을 생성하고 정제하는 전처리 과정을 수행한다. 이후 비지도학습 기반 pseudo label 생성단계(그림 1 (c))에서는 라벨이 없는 데이터에 비지도학습 이상탐지 모델들을 적용하여 이상치를 식별하고, 내부 검증 지표를 통해 가장 신뢰도 높은 pseudo label을 선정한다. 마지막으로 지도학습 모델 성능 비교과정(그림 1 (d))에서는 생성된 pseudo label을 정답으로 하여 다양한 지도학습 모델에 적용하고, 성능 평가지표를 통해 각 모델의 이상거래 탐지 성능을 비교·분석한다.

3.1 데이터셋 및 전처리

본 연구에서는 경기데이터트림에서 제공하는 경기도 지역화폐 관련 공공데이터를 활용한다(그림 1 (a)). 수집한 데이터는 특정 월, 특정 행정동에서 발행 및 사용된 지역화폐 매출금액, 가맹점 정보 등을 포함하며 별도의 이상거래 여부 및 개인 식별자 없이 지역 단위로 집계된 시계열 데이터라는 특징이 있다. 이러한 구조는 통계적 관점에서 이상 패턴을 탐지하는 데 유용하다[29,31]. 이후 데이터의 규모 편차 및 시계열 특성을 반영하기 위해 원본 데이터를 가공(그림 1 (b))하여 ‘가맹점당 유입액’, ‘3개월 이동평균 대비 유입액 비율’ 등 의미 있는 특징을 생성한 후 Z-score 표준화를 통해 feature scaling을 진행하였다. 또한 데이터를 임의로 정상거래와 이상거래로 구별할 수 없으므로 비지도학습

을 통해 이상거래를 발견하고자 한다[33,34].

3.2 비지도학습 기반 Pseudo Label 생성

라벨이 없거나 부족한 데이터 환경에서 지도학습 모델을 적용하기 위해서는 그림 1 (c)와 같이 비지도학습을 통해 pseudo label을 생성하는 과정이 선행되어야 한다[31,35]. 본 연구에서는 지역화폐 데이터와 같은 다차원 시계열 데이터의 이상치 식별에 널리 활용되는 다음 세 가지 특성의 모델을 사용하였다:

- Isolation Forest(IF): 데이터를 무작위로 분할하여 고립시키기 어려운 정상 데이터와 쉽게 고립되는 이상 데이터를 분류하는 모델로 대규모 데이터를 효율적으로 처리함[18,36].
- Local Outlier Factor(LOF): 데이터의 지역적 밀도를 이웃과 비교하여 상대적으로 밀도가 낮은 데이터를 이상치로 판단하는 모델로 군집의 밀도가 다른 경우에도 정교한 탐지 가능함[37,38].
- One-Class SVM(OC-SVM): 정상 데이터의 분포 경계를 학습하여 그 경계 밖에 위치하는 데이터를 이상치로 분류하는 모델로 새로운 유형의 이상 패턴 발견에 유용함[25,33,39].

개별 비지도학습 모델은 오탐(False Positive) 및 미탐(False Negative)의 위험을 내포하고 있어 라벨의 신뢰도를 높이기 위해 앙상블(Ensemble) 모델을 추가로 활용한다[25]. 앙상블 모델은 3개의 개별 모델 중 2개 이상이 공통적으로 이상치라고 판단한 거래만을 최종 이상치로 분류하도록 설정한다. 이를 통해 개별 모델의 편향을 줄이고 보다 안정적인 결과 도출이 가능하다.

생성된 pseudo label의 품질을 객관적으로 평가하기 위해 다음 표 1에서 설명한 Silhouette, Extremeness 등 5가지 내부 클러스터 검증 지표를 활용한다[27]. 각 지표를 동일한 가중치로 종합한 종합점수(Composite Score)가 가장 높은 모델의 결과를 최종 pseudo label로 채택하여 지도학습 단계의 입력 데이터로 사용한다.

Table. 1 Evaluation Criteria

Silhouette [40]
$\frac{1}{n} \sum_{i=1}^n \frac{b(i) - a(i)}{\max(a(i), b(i))}$ Indicates how well each data point belongs within its assigned cluster, and how far it is from other clusters
Extremeness [33]
$\frac{1}{ A F} \sum_{i \in A} \sum_{f=1}^F \left \frac{x_{if} - \mu_f}{\sigma_f} \right $ Average absolute z-score of all detected outliers; higher scores mean anomalies lie farther from the main distribution
Cohesion [41]
$\frac{2}{ A (A - 1)} \sum_{p < q, p, q \in A} d(x_p, x_q)$ Mean pairwise distance within the outlier set; lower values indicate a tighter, more coherent anomaly group
Separation [41]
$\frac{1}{ A N } \sum_{p \in A} \sum_{q \in N} d(x_p, x_q)$ Mean distance between outliers and normal points; larger values show a clearer normal-anomaly gap
Mann-Whitney U (Mann-Whitney U) [42]
$\min(U_A, n^A n^N - U_A), U_A = n^A n^N + \frac{n^A(n^A + 1)}{2} - R$ Rank-sum test that detects distribution differences between two samples without assuming normality; robust for skewed financial data
Notation
• $a(i)$: Mean distance from point i to all other points in the same cluster • $b(i)$: Mean distance from point i to the nearest different cluster • A, N: Sets of data points detected as anomalies (A) and normals (N) • F: Set of all features (variables) in the dataset • A , N , F: Counts of anomalies, normals and total features, respectively • p, q: Two data points used when computing distances (cohesion or separation) • μ_f, σ_f: Mean and standard deviation of feature f (for z-score) • $d(p_i, p_k)$: Euclidean distance between points p_i and p_k • R: Rank-sum of anomaly group in the Mann-Whitney U test • U_A, U: Mann-Whitney U statistic for the anomaly group and the overall test

3.3 지도학습

비지도학습을 통해 생성된 pseudo label을 활용하여 6개의 지도학습 모델을 학습하고 평가하였다. 지역화폐 데이터의 시계열성 및 클래스 불균형 특성[26,27]을 고려하여 이상거래 탐지 분야에서 우수한 성능을 보이는 모델을 다음과 같이 선정한다:

- **Random Forest (RF):** 다수의 결정트리를 배깅(Bagging)으로 모아 다수결·평균으로 예측하는 앙상블 기법으로 변수간 비선형 관계가 복잡하고 이상치가 적은 대규모 데이터 분석에 활용함[43,44].
- **XGBoost:** Gradient Boosting을 개선해 정규화와 학습률 축소 및 특성 부분 샘플링을 결합하며 빠른 학습과 높은 표현력을 갖춘 모델로 정상·이상 패턴 미세 조정에 유리함[45,46].
- **LightGBM:** 리프중심 트리 분할 전략으로 XGBoost보다 메모리와 학습 시간을 줄인 부스팅 모델로 고차원 특징 데이터를 빠르게 분석함[47,48].
- **Decision Tree:** 지니지수·엔트로피로 반복 분할해 단일 트리 결정 규칙을 얻으며 해석성이 뛰어나 기본 베이스라인으로 활용함[49,50].
- **Support Vector Machine (SVM):** 커널 공간에서 최대 마진을 찾아 정상 클래스 지원영역을 구분하여 고차원·소표본에 강한 의사결정을 수행함[51,52].
- **Logistic Regression (LR):** 시그모이드 기반 선형 확률 모델로 임계치 조정이 가능하고 직관적 해석이 용이하므로 베이스라인 비교 및 실시간 추론 지표로 활용함[51,53].

지도학습 모델의 성능은 Recall, Precision, F1-Score로 평가한다. 이상거래 탐지의 핵심 목표인 '실제 이상거래를 놓치지 않으면서도(Recall), 정상 거래를 이상거래로 오탐하지 않는(Precision)' 균형을 종합적(F1-Score)으로 평가하기 위해 세 가지 지표를 사용한다.

IV. 실험결과

4.1 데이터 전처리 결과

첫 번째로 경기데이터트림에서 수집한 행정동 코드·

가맹점 정보·월별 거래 내역 데이터를 병합하고 정제하여 하나의 병합된 데이터를 생성하였다.




Fig. 2 (a): Distribution of operating stores count, (b): Payment ratio to 3-month moving average

병합 데이터는 그림 2 (a)에서 보이는 것처럼 행정동별로 운영 가맹점 수의 편차가 매우 컸다. 이러한 규모 편차를 보정하기 위해 '가맹점당 유입/유출액' 변수를 생성하였다. 또한 정책적 요인으로 특정 월에 사용액이 급증하는 경향을 고려하여 단순 월별 유입액이 아닌 '3개월 이동평균 대비 유입액 비율'이라는 추세 편차 변수를 추가하였다(그림 2 (b)). 추가로 규모 보정, Z-score 표준화를 통해 특정 지역이 과도하게 높은 거래금액/거래건수를 보일 경우 이상치로 탐지하였다. 본 연구가 설계한 규모 보정과 추세 편차 변수는 데이터의 극단적 편차로 인한 문제를 완화하면서도 급격한 변동성을 정량화해 이후 비지도학습 기반 이상치 탐지 및 pseudo label 생성 단계의 신뢰할 만한 입력을 제공한다.

4.2 비지도학습 기반 Pseudo Labeling 결과

비지도학습 모델을 통해 pseudo label을 생성하는 실험은 두 가지 시나리오로 진행되었다: (1) 이상치 비율을 1%로 고정한 경우, (2) 모델별로 최적의 임계치를 자율적으로 설정한 경우.

그림 3과 4는 이상치 비율을 시나리오와 같이 1%로 고정했을 때와 모델별로 최적의 임계치를 자율적으로 설정했을 때의 이상치 탐지 결과이다. 각 그래프는 왼쪽부터 IF, LOF, OC-SVM, Ensemble 모델의 PCA 분석 결과를 보여준다. x축인 PCA1(Magnitude)는 총 거래액·가맹점의 수와 같이 절대 규모를 나타내며, y축인 PCA2(Patten)은 규모로 설명되지 않는 상대적 특이성·변동성을 나타낸다. 파란색으로 표시된 점은 모델이 '정상'으로 판단한 거래를 의미하며 '이상거래'로 판단되면 붉은색으로 표시하였다.

그림 3은 이상치 비율을 1% 이내로 제한하여 이상치




Fig. 3 Outlier detection results by unsupervised learning model (Outlier Ratio: 1%)




Fig. 4 Outlier detection results by unsupervised learning model (Outlier Threshold: automatic model setting)

를 탐지한 결과이다. IF는 극단적인 경로 길이를 가진 데이터를 선별하여 군집의 외곽 및 우측 하단으로 흩어진 영역을 이상치로 표시하였고 거래액이나 가맹점수가 정상분포에서 크게 벗어난 지점을 주로 잡아냈다. LOF는 이상치가 극소수이며 밀도차가 큰 거래만 이상치로 선택하여 IF에 비해 좁은 영역을 이상치로 판단한다. OC-SVM은 원점에서 멀어진 측면을 따라 이상치를 표시하였으며 앙상블은 세 모델 중 두 모델 이상이 동시에 이상으로 판단한 경우만 이상치로 분류하여 개별 모델의 편향을 상쇄하고 분산을 감소시켰다. 이상치 비율을 1%로 설정한 경우 종합적인 이상거래를 판단한 앙상블이 보수적인 탐지로 신뢰도 높은 pseudo label을 제공함을 나타낸다.

그림 4는 모델별 최적의 임계치를 자동으로 설정하여 분류한 이상치를 나타낸다. 각 모델이 모델별 특성을 고려하여 임계치를 산정하였다. IF의 임계치가 7.2%로 급증하면서 외곽뿐 아니라 거래 규모가 다소 큰 내부 영역까지 이상치가 분포되었다. OC-SVM도 5.0%로 넓어지며 곡선 경계가 안쪽으로 확장돼 패턴 편차가 중간 정도인 사례까지 포함했다. 반면 LOF는 3.0%로 상대적으로 적게 증가했다. 두 단일 모델 이상이 일치해야 하는 앙상블은 4.0%로 증가는 있었지만 대부분의 단일 모델보다는 보수적인 탐지를 보였다. 이를 통해 모델의 이상치 비율을 1%로 지정하여 각 모델 고유의 강점을 확인하고 이를 교집합한 앙상블로 세 모델의 특

성을 모두 만족하는 이상거래를 확인하였다.

반면에 임계치를 자동으로 설정하여 이상치 비율이 증가되어 Isolation Forest와 OC-SVM은 이상치가 대폭 증가한 것을 확인하였다.

Pseudo label 생성에 사용된 모델의 신뢰도를 검증하기 위해 3.2절에서 소개한 다섯 가지 평가지표로 품질을 검증하였다. Silhouette, Extremeness, Separation은 값이 클수록 Cohesion, Mann-Whitney U는 값이 작을수록 양호하다. 마지막 열의 종합점수는 다섯 지표를 스케일에 맞게 정규화(Cohesion, Mann-Whitney U는 1의 보수를 취함)한 평균값이며 클수록 양호하다.

표 2는 이상치 비율을 1%로 지정하여 비지도학습 모델을 평가한 결과이다. 앙상블이 Silhouette (0.731), Extremeness(2.368), Separation(9.792)에서 가장 높은 결과를 보였으며 종합점수는 0.758로 가장 좋은 결과를 나타냈다. 이는 세 모델 중 과반수가 이상거래로 판단한 표본이 정상 거래와 선명하게 구분됨을 의미한다. IF와 OC-SVM은 Extremeness과 Separation에서 비슷한 결과를 보였다. 두 모델 모두 분포 외곽의 규모형 이상치를 잘 포착하지만 이상치 내부 거리가 다소 넓어 Cohesion이 높게 나타났다. LOF는 Cohesion과 Mann-Whitney U에서 가장 좋은 값을 보였으나 나머지 지표가 낮아 종합점수는 0.400에 그쳤다. 이는 LOF가 국지 희소성 위주의 매우 밀집된 소수 포인트만 잡아 정밀하지만 전체 분리도는 떨어짐을 의미한다.

Table. 2 Unsupervised learning Models Evaluation Result (Outlier Ratio: 1%)

Model	Silhouette (↑)	Extremeness (↑)	Cohesion (↓)	Separation (↑)	Mann-Whitney (↓)	Composite Score
IF	0.706	2.099	9.233	8.708	21951910	0.577
LOF	0.353	0.828	5.426	4.166	12523895	0.400
OC-SVM	0.688	1.961	10.338	8.409	18256042	0.578
Ensemble	0.731	2.368	11.027	9.792	14505830	0.758

Table. 3 Unsupervised learning Models Evaluation Result (Outlier Threshold: automatic model setting)

Model	Silhouette (↑)	Extremeness (↑)	Cohesion (↓)	Separation (↑)	Mann-Whitney (↓)	Composite Score
IF	0.664	1.781	8.478	7.555	29639538	0.519
LOF	0.398	0.889	5.930	4.469	7520398	0.400
OC-SVM	0.688	1.961	10.338	8.409	18256042	0.620
Ensemble	0.718	2.242	10.704	9.324	16310903	0.721

표 3은 모델에 따라 최적화된 임계치를 지정한 비지도 학습 모델 평가 결과이다. 모델별 이상치 분포가 달라지며 전반적으로 Silhouette와 Separation이 소폭 하락하였다. 반면 이상치의 종합점수는 0.721을 나타내었고 Silhouette, Extremeness, Mann-Whitney U에서도 가장 높은 점수를 유지하며 임계치 변화에도 최고의 성능을 보여준다. IF는 이상치가 1%에서 7%로 증가하며 Extremeness와 Separation가 낮아졌고 종합점수도 0.519로 떨어졌다. 이는 트리 깊이 기준이 완화된 탐지 범위가 넓어진 결과이다. LOF와 OC-SVM은 임계치 자동 설정에서도 이상치 비율이 1%일 때와 유사한 결과를 나타낸다.

생성된 pseudo label의 품질을 내부 검증 지표로 평가한 결과, 두 조건 모두에서 이상치 모델이 종합점수 1위를 기록하였다. 이는 임계치 변화와 관계없이 이상치 방식이 가장 안정적이고 신뢰할 수 있는 pseudo label을 제공함을 의미한다. 따라서 후속 지도학습 단계에서는 이상치 모델이 생성한 라벨을 활용하였다.

Table. 4 Supervised learning Models Evaluation Result (Outlier Ratio: 1%)

1%	Precision	Recall	F1-Score
XGBoost	0.4143	0.7632	0.5370
LightGBM	0.3919	0.7632	<u>0.5179</u>
RF	<u>0.3971</u>	0.7105	0.5094
DT	0.3380	0.6316	0.4404
SVM	0.2037	0.8684	0.3300
LR	0.1372	<u>0.8158</u>	0.2348

Table. 5 Supervised learning Models Evaluation Result (Outlier Threshold: automatic model setting)

Model	Precision	Recall	F1-Score
XGBoost	0.8298	0.9613	0.8907
LightGBM	<u>0.8303</u>	<u>0.9648</u>	<u>0.8925</u>
RF	0.8540	0.9472	0.8982
DT	0.8131	0.9190	0.8628
SVM	0.4722	0.9859	0.6385
LR	0.3865	0.9296	0.5460

4.3 지도학습 성능 비교 결과

비지도 이상치 탐지에서 산출한 pseudo label을 바탕으로 RF, XGBoost, LightGBM, Decision Tree, SVM, LR 여섯 가지 지도학습 모델의 이상거래 탐지 성능을 비교하고 비지도 단계에서 설정한 이상치 비율이 지도 학습 모델 성능에 미치는 영향을 확인하였다.

표 4는 비지도 단계에서 이상치 비율을 1%로 고정하여 생성한 pseudo label을 바탕으로 지도학습 모델의 Precision, Recall, F1-Score를 비교한 결과이다. 이상치 비율을 제한하여 이상거래 정보가 극도로 희소한 실제 환경을 모사한다. 이에 따라 전체적인 F1-Score는 낮게 나타났으며, XGBoost가 F1-Score 0.537로 가장 균형 있는 결과를 도출하였다. SVM은 Recall 0.868로 미탐 방지 유리하지만 Precision이 0.204에 그쳐 행정적 오탐 비용이 증가할 수 있음을 시사한다.

표 5는 모델별로 최적의 임계치를 자동으로 적용하여 생성한 pseudo label을 지도학습에 활용한 결과를 보여준다. 모든 모델의 이상치가 증가하며 지도학습 모델별 성능 또한 크게 향상되었으며 RF가 F1-Score 0.898로 가장 좋은 결과를 기록하였다. 이는 배경과 특성 부

분집합(random subspace)이 안정적인 이상거래 탐지 성능을 제공함을 보여준다. 또한 XGBoost과 LightGBM도 0.89±를 유지하여 이상불 계열의 일관된 우수성을 확인할 수 있다.

V. 결론

본 연구는 비지도학습과 지도학습을 결합한 하이브리드 머신러닝 프레임워크를 통해 라벨이 부재한 지역화폐 공공데이터에서 이상거래를 탐지하는 최적의 모델을 제시하였다. 비지도학습 단계에서 IF, LOF, OC-SVM 및 이들의 앙상블을 활용하여 pseudo label을 생성하고, 내부 검증 지표로 신뢰도를 평가하였다. 그 결과 앙상블 방식이 가장 높은 신뢰도를 보였다. 이후 지도학습 성능 평가에서는 이상치 비율이 제한된 1% 환경에서는 XGBoost가, 자동 임계치 환경에서는 RF가 가장 높은 F1-Score를 기록했다. 이를 통해 복잡한 데이터 패턴의 정밀도와 재현율을 균형 있게 확보함에 있어 트리 기반 앙상블 모델이 가장 효과적임을 나타냈다.

본 연구는 기존의 개별 거래 수준 데이터를 활용한 연구들과 달리 공개된 지역화폐 월별 집계 데이터만으로도 이상거래 탐지가 가능함을 입증하였다. 이는 개별 거래 정보 접근이 어렵거나 개인정보보호 제약이 있는 데이터에 적용가능한 실용적인 접근법이다. 실제 금융분야에서 사용하는 이상거래 탐지 방향과도 일맥상통하며 데이터가 제한적이고 라벨링이 어려운 상황에서 도 우수한 성과를 낼 수 있음을 증명하였다는 점에서 실무적 기여가 크다.

본 연구의 pseudo labeling 접근법은 한계를 지닌다. 비지도학습에 의해 생성된 라벨은 실제 부정거래정답 라벨(ground truth label)과 다를 수 있으며 모델의 오탐 가능성을 내포하므로, 실제 시스템 도입 시 FDS 또는 금융보안원에서 제공하는 라벨 기반의 규칙과 병행하여 정확도를 향상시킬 수 있다. 또한 본 연구에 사용된 개별 거래 정보를 이용하지 않는 집계 데이터 기반 방식은 직접적인 세부적인 거래 패턴 탐지에는 한계가 있으나 본 연구 결과를 통해서 집계 데이터만으로도 유의미한 이상거래 탐지가 가능함을 입증하였다.

ACKNOWLEDGEMENTS

This research was supported by the Chung-Ang University Research Scholarship Grants in 2023.

We appreciate Sunghwan Park for his constructive reviews on the experiment and the paper.

REFERENCES

- [1] K. H. Ryu, "Vitalization of Regional Economy through Local Currency," *International Area Studies Review*, vol. 19, no. 1, pp. 103-126, Jan. 2015.
- [2] B. H. Cho, "The Local Community Economy and Community Currency: The System of Community Currency for Social Economy," *Korean Development Economics Association*, vol. 26, no. 3, pp. 33-66, Sep. 2020. DOI: 10.20464/kdea.2020.26.3.2.
- [3] Ministry of the Interior and Safety. localVoucher [Internet]. Available: <https://www.mois.go.kr/ftr/sub/a06/b07/localVoucher/screen.do>.
- [4] J. H. Kim, "The Issue of Youth Dividend and the Trajectory of Basic Income: The formation and transformation of a policy-network," M. S. theses, Seoul National University Graduate School, Seoul, KR, 2022.
- [5] Korea Policy Briefing. 'localVoucher' 141 cases of illegal distribution detected [Internet]. Available: <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156643744>.
- [6] Boannews. KT to Detect Unusual Transactions in Local Currency Using Blockchain and AI [Internet]. Available: <https://www.boannews.com/media/view.asp?idx=100709>.
- [7] F. Li and Z. Chen, "Dynamic quantification anti-fraud machine learning model for real-time transaction fraud detection in banking," *Discover Computing*, vol. 28, no. 59, pp. 1-15, May 2025. DOI: 10.1007/s10791-025-09549-7.
- [8] E. S. Choi, "A study on improvement of effectiveness using anomaly analysis rule modification in electronic finance trading," M. S. theses, Korea University, Seoul, KR, 2015.
- [9] Y. H. Park, H. S. Shim, and W. S. Cho. "A Study on Current Status Analysis and Activation plan of Local Currency in Cheong-ju City using Data Visualization," *Social Economy & Policy Studies*, vol. 13, no. 2, pp. 71-91, May 2023. DOI: 10.22340/seps.2023.05.13.2.71.
- [10] M. H. Kim, "Growth of Changwon local coupons and their Impact on Local Economy," *Regional industry research*, vol. 43, no. 4, pp. 203-217, 2020. DOI: 10.33932/rir.43.4.10.

- [11] J. H. Kang and H. A. Kim, "Effects of Jeju's Local Currency on Small Business Sales," *The Journal of Convergence Society and Public Policy*, vol. 16, no. 4, Feb. 2023. DOI: 10.37582/CSPP.2022.16.4.207.
- [12] Ministry of the Interior and Safety. localVoucher Operating Instructions [Internet]. Available: <https://www.mois.go.kr/frt/sub/a06/b07/localVoucher/screen.do>.
- [13] Ministry of the Interior and Safety. 2019 Digital Government Innovation Promotion Plan [Internet]. Available: <https://www.mois.go.kr/frt/sub/a06/b04/egovVision/screen.do>.
- [14] Data.go.kr. Data list [Internet]. Available: <https://www.data.go.kr/tcs/dss/selectDataSetList.do>.
- [15] C. Kim, H. J. Kang, and J. Son, "Measuring Local Economy Efficiency With Two-Stage Bootstrap DEA: Evidence From Municipal Currency in South Korea," *International Journal of Software Innovation*, vol. 10, no. 1, pp. 1-14, Sep. 2022. DOI: 10.4018/IJSI.309964.
- [16] Y. H. Lim, "A Study of the Effect of Local Currencies amid COVID-19 : Focusing on the Local Currency of Daejeon, 'Ontong Daejeo,'" *The Korea Local Administration Review*, vol. 35, no. 4, pp. 221-246, 2021. DOI: 10.22783/krila.2021.35.4.221.
- [17] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 1, pp. 533-536, Oct. 1986. DOI: 10.1038/323533a0.
- [18] F. T. Liu, K. M. Ting, and Z. H. Zhou, "Isolation forest," in *Proceedings of the Eighth IEEE International Conference on Data Mining*, Pisa: IT, pp. 413-422, 2008. DOI: 10.1109/ICDM.2008.17.
- [19] M. Kim, H. Kye, and M. Kwon, "Network Anomaly Detection System Using Hidden Layer Information of Autoencoder," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 47, no. 9, pp. 1310-1321, 2022. DOI: 10.7840/kics.2022.47.9.1310.
- [20] F. Alhayan, A. Alshuhail, A. O. A. Ismail, O. Alrusaini, S. Alahmari, A. E. Yahya, S. S. Albouq, and M. A. Sadig, "Enhanced anomaly network intrusion detection using an improved snow ablation optimizer with dimensionality reduction and hybrid deep learning model," *Scientific Reports*, vol. 15, no. 13270, pp. 1-25, Apr. 2025. DOI: 10.1038/s41598-025-97398-1.
- [21] Y. J. Kim and J. W. Lee, "Development of a Malicious URL Machine Learning Detection Model Reflecting the Main Feature of URLs," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 26, no. 12, pp. 1786-1793, Dec. 2022. DOI: 10.6109/jkiice.2022.26.12.1786.
- [22] D. H. Kim, S. G. Lee, and S. K. Jung, "Design and implementation of a deep learning model for Fraud Detection System(FDS)," *Journal of convergence security*, vol. 21, no. 5, pp. 69-78, 2021. DOI: 10.33778/kcsa.2021.21.5.069.
- [23] Korea Policy Briefing. Using artificial intelligence (AI) to catch fraudulent distribution of localVoucher certificates. [Internet]. Available: <https://www.korea.kr/briefing/pressReleaseView.do?newsId=156510676>.
- [24] Y. Chen, C. Zhao, Y. Xu, C. Nie, and Y. Zhang, "Year-over-year developments in financial fraud detection via deep learning: A systematic literature review," *arXiv preprint arXiv:2502.00201*, Jan. 2025. DOI: 10.48550/arXiv.2502.00201.
- [25] F. Carcillo, Y. L. Borgne, O. Caelen, Y. Kessaci, F. Oble, and G. Bontempi, "Combining unsupervised and supervised learning in credit card fraud detection," *Information sciences*, vol. 557, pp. 317-331, May 2021. DOI: 10.1016/j.ins.2019.05.042.
- [26] I. Y. Hafez, A. Y. Hafez, A. Saleh, A. A. A. E. Mageed, and A. A. Abohany, "A systematic review of AI-enhanced techniques in credit card fraud detection," *Journal of Big Data*, vol. 12, no. 6, pp. 1-35, Jan. 2025. DOI: 10.1186/s40537-024-01048-8.
- [27] L. H. Aros, L. X. B. Molano, F. G. Portela, J. J. M. Hernandez, and M. S. R. Barrero, "Financial fraud detection through the application of machine learning techniques: a literature review," *Humanities and Social Sciences Communications*, vol. 11, no. 1130, pp. 1-22, Sep. 2024. DOI: 10.1057/s41599-024-03606-0.
- [28] Financial Supervisory Service. Guidelines for Operating the Financial Transaction Detection System [Internet]. Available: <http://fss.or.kr/fss/bbs/B0000188/view.do?nttId=130709&menuNo=200218>.
- [29] C. Whitrow, D. J. Hand, P. Juszczak, D. Weston, and N. M. Adams, "Transaction aggregation as a strategy for credit card fraud detection," *Data Mining and Knowledge Discovery*, vol. 18, no. 1, pp. 30-55, Feb. 2009. DOI: 10.1007/s10618-008-0116-z.
- [30] X. Niu, L. Wang, and X. Yang, "A comparison study of credit card fraud detection: Supervised versus unsupervised," *arXiv preprint arXiv:1904.10604*, Apr. 2019. DOI: 10.48550/arXiv.1904.10604.
- [31] V. L. W. Seng and S. A. B. S. Abidinsa, "Machine learning for anomaly detection in money services business outlets using data by geolocation," *IFC Working Papers*, no. 23, pp. 1-17, Nov. 2024.

- [32] Gyeonggi Data Dream. Gyeonggi Data Dream [Internet]. Available: <https://data.gg.go.kr/portal/mainPage.do>.
- [33] M. Goldstein and S. Uchida, "A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data," *PloS one*, vol. 11, no. 4, pp. 1-31, Apr. 2016. DOI: 10.1371/journal.pone.0152173.
- [34] R. K. L. Kennedy, F. Villanustre, and T. M. Khoshgoftaar, "Unsupervised feature selection and class labeling for credit card fraud," *Journal of Big Data*, vol. 12, no. 111, pp. 1-20, May 2025. DOI: 10.1186/s40537-025-01154-1.
- [35] B. Alshawi, "Comparison of SVM kernels in Credit Card Fraud Detection using GANs," *International Journal of Advanced Computer Science & Applications*, vol. 15, no. 1, pp. 330-337, 2024. DOI: 10.14569/ijacsa.2024.0150131.
- [36] F. Carcillo, A. D. Pozzolo, Y. A. L. Borgne, O. Caelen, Y. Mazzer, and G. Bontempi, "Scarff: a scalable framework for streaming credit card fraud detection with spark," *Information fusion*, vol. 41, pp. 182-194, May 2018. DOI: 10.1016/j.inffus.2017.09.005.
- [37] M. M. Breunig, H. P. Kriegel, R. T. Ng, and J. Sander, "LOF: identifying density-based local outliers," in *Proceedings of the ACM SIGMOD international conference on Management of data*, Dallas: USA, pp. 93-104, 2000.
- [38] A. Ali, S. A. Razak, S. H. Othman, T. A. E. Eisa, A. A. Dhaqm, M. Nasser, T. Elhassan, H. Elshafie, and A. Saif, "Financial fraud detection based on machine learning: a systematic literature review," *Applied Sciences*, vol. 12, no. 19, pp. 1-24, Sep. 2022. DOI: 10.3390/app12199637.
- [39] B. Scholkopf, R. C. Williamson, A. J. Smola, J. S. Taylor, J. C. Platt, "Support vector method for novelty detection," in *Proceedings of Advances in Neural Information Processing Systems 12 (NIPS 1999)*, Denver: USA, pp. 582-588, 1999.
- [40] P. Rousseeuw, "Silhouettes: a graphical aid to the interpretation and validation of cluster analysis," *Journal of computational and applied mathematics*, vol. 20, pp. 53-65, Nov. 1987. DOI: 10.1016/0377-0427(87)90125-7.
- [41] J. C. Dunn, "A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters," *journal of Cybernetics*, vol. 3, no. 3, pp. 32-57, Apr. 1973. DOI: 10.1080/01969727308546046.
- [42] H. B. Mann and D. R. Whitney, "On a test of whether one of two random variables is stochastically larger than the other," *The annals of mathematical statistics*, vol. 18, no. 1, pp. 50-60, Mar. 1947.
- [43] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, pp. 5-32, Oct. 2001. DOI: 10.1023/A:1010933404324.
- [44] P. Sundaravadeivel, R. A. Isaac, D. Elangovan, D. KrishnaRaj, V. V. L. Rahul, and R. Raja, "Optimizing credit card fraud detection with random forests and SMOTE," *Scientific Reports*, vol. 15, no. 17851, pp. 1-12, May 2025. DOI: 10.1038/s41598-025-00873-y.
- [45] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree-Boosting System," in *Proceedings of the 22nd ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, California: USA, pp. 785-794, 2016. DOI: 10.1145/2939672.2939785.
- [46] A. Purwar and M. Manju, "Credit card fraud detection using XGBoost for imbalanced data set," in *Proceedings of the Fifteenth International Conference on Contemporary Computing*, Noida: IN, pp. 216-219, 2023. DOI: 10.1145/3607947.3607986.
- [47] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T. Y. Liu, "Lightgbm: A highly efficient gradient boosting decision tree," in *Proceedings of the 31st International Conference on Neural Information Processing Systems*, California: USA, pp. 3149-3157, 2017.
- [48] A. A. Taha and S. Malebary, "An intelligent approach to credit card fraud detection using an optimized light gradient boosting machine," *IEEE access*, vol. 99, no.1-1, pp. 1-9, Feb. 2020. DOI: 10.1109/ACCESS.2020.2971354.
- [49] J. N. Morgan and J. A. Sonquist, "Problems in the analysis of survey data, and a proposal," *Journal of the American statistical association*, vol. 58, no. 302, pp. 415-434, 1963. DOI: 10.1080/01621459.1963.10500855.
- [50] B. Xu, Y. Wang, X. Liao, and K. Wang, "Efficient fraud detection using deep boosting decision trees," *Decision Support Systems*, vol. 175, no. C, pp. 114037, Dec. 2023. DOI: 10.1016/j.dss.2023.114037.
- [51] S. Bhattacharyya, S. Jha, K. Tharakunnel, J. C. Westland, "Data mining for credit card fraud: A comparative study," *Decision support systems*, vol. 50, no. 3, pp. 602-613, Feb. 2011. DOI: 10.1016/j.dss.2010.08.008.
- [52] C. Cortes and V. N. Vapnik "Support-vector networks," *Machine learning*, vol. 20, pp. 173-297, Sep. 1995. DOI: 10.1007/BF00994018.
- [53] D. R. Cox, "The Regression Analysis of Binary Sequences," *Journal of the Royal Statistical Society Series B: Statistical Methodology*, vol. 21, no. 1, pp. 238, Jan, 1959. DOI: 10.1111/j.2517-6161.1959.tb00334.x.



장예슬(Yeseul Chang)

2023년 2월 중앙대학교 융합보안학과 석사

2023년 9월-현재 중앙대학교 융합보안학과 박사과정

※관심분야: 문서보안, LLM, 데이터분석, 이상거래 탐지, 개인정보보호



이재우(Jaewoo Lee)

2006년 2월 서울대학교 컴퓨터공학부 학사

2008년 2월 서울대학교 컴퓨터공학부 석사

2017년 8월 University of Pennsylvania, Ph.D in Computer and Information Science

2018년 3월-현재 중앙대학교 산업보안학과 부교수

※관심분야: Real-time system, CPSsecurity