



Conference Article

Natural Language Processing-Based Layered Reconciliation System for Financial Transaction Analysis

Dilara Hazırlar¹, Özlem Avcı², Mesut Tekir³, Buket Doğan^{4*}

¹ Elekse Elektronik Para ve Ödeme Kuruluşu Ar-Ge Merkezi, Orcid ID: <https://orcid.org/0009-0002-0563-0776>, e-mail: dilara.hazirlar@elekse.com

²Elekse Elektronik Para ve Ödeme Kuruluşu Ar-Ge Merkezi, Orcid ID: <https://orcid.org/0009-0004-1109-9453>, e-mail: ozlem.avci@elekse.com

³Elekse Elektronik Para ve Ödeme Kuruluşu Ar-Ge Merkezi, Orcid ID: <https://orcid.org/0009-0004-1932-8521>, e-mail: mesut@elekse.com

⁴Marmara Üniversitesi Teknoloji Fakültesi Bilgisayar mühendisliği Bölümü, Orcid ID: <https://orcid.org/0000-0003-1062-2439>, e-mail: buketb@marmara.edu.tr

* Sorumlu Yazar: buketb@marmara.edu.tr; 05326753597

Received: 18 June 2025

Revised: 01 October 2025

2nd Revised: 12 November 2025

3rd Revised: 03 December 2025

Accepted: 16 December 2025

Published: 31 December 2025

This is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

Reference: Hazırlar, D., Avcı, Ö., Tekir, M., & Doğan, B. (2025). Natural language processing-based layered reconciliation system for financial transaction analysis. *Orclever Proceedings of Research and Development*, 7(1), 30–42.

Abstract

With the widespread adoption of digital payment systems, the volume and diversity of financial transaction data have increased significantly. For payment institutions and electronic money companies in particular, the cross-verification of internal transaction logs with bank statements has become a critical requirement for ensuring financial security, accounting accuracy, and auditability. However, in practice, inconsistencies often occur between bank-side and firm-side records due to system interruptions, service errors, or manually entered transactions. This study presents a financial data reconciliation system based on Natural Language Processing (NLP) and rule-based analytical techniques, designed to detect inconsistencies by comparing bank transaction



records with internal operational logs. The system, developed by Elekse, automatically retrieves millions of transaction records from multiple banks via the Finekra platform and classifies them by transaction type using key attributes such as description, date, amount, and IBAN. Throughout this process, NLP techniques are used to identify linguistic patterns, extract meaningful expressions, and assign the appropriate accounting codes through predefined rules, enabling the automatic reconciliation of records. As a result, the need for manual inspection is reduced, error detection is accelerated, and overall data accuracy is improved.

Keywords: Financial Reconciliation, Rule-Based, Natural Language Processing



Finansal Hareketlerin Analizi için Doğal Dil İşleme Tabanlı Katmanlı Mutabakat Sistemi

Özet

Dijital ödeme sistemlerinin yaygınlaşmasıyla birlikte, finansal işlemlerde oluşan veri hacmi ve çeşitliliği önemli ölçüde artmıştır. Özellikle ödeme kuruluşları ve elektronik para firmaları açısından, hem firma içi işlem loglarının hem de bankalardan alınan hareketlerin karşılıklı olarak doğrulanması; finansal güvenlik, muhasebe doğruluğu ve denetlenebilirlik açısından kritik bir gereklilik hâline gelmiştir. Ancak uygulamada, sistem kesintileri, servis hataları veya manuel işlem kayıtları nedeniyle banka ve firma tarafında tutarsızlıklar görülebilmektedir. Bu çalışma, banka hareketleriyle firma içi işlem loglarını karşılaştırarak tutarsızlıkları tespit eden, doğal dil işleme (NLP) ve kural tabanlı analiz tekniklerine dayalı bir finansal veri eşleştirme sistemi sunmaktadır. Elekse tarafından geliştirilen sistem, farklı bankalardaki milyonlarca hesap hareketini Finekra platformu üzerinden otomatik olarak çekmekte ve açıklama, tarih, tutar, IBAN gibi temel alanlardan elde edilen verileri işlem tipine göre sınıflandırmaktadır. Bu süreçte doğal dil işleme teknikleriyle metinlerdeki örüntüler belirlenmekte, anlamlı ifadeler çıkarılmakta ve kurallar aracılığıyla doğru muhasebe kodları atanarak kayıtlar otomatik olarak eşleştirilmektedir. Böylece, manuel denetim gerektiren işlemler azaltılmış, hatalı kayıtların tespiti hızlandırılmış ve veri doğruluğu artırılmıştır. Sistem, açıklama metinlerinde yer alan çeşitli işlem ifadelerini analiz ederek otomatik mutabakat sağlamak ve tespit edilemeyen işlemleri kullanıcı geri bildirimiyle öğrenerek kendini geliştirmektedir. Gelecek çalışmalarda, mevcut kural tabanlı yapının makine öğrenmesi ve büyük dil modelleri (LLM) ile desteklenmesi; sistemin açıklamalardaki anlamsal benzerlikleri öğrenebilmesi ve yeni işlem tiplerini otomatik olarak tanımlayabilmesi planlanmaktadır.

Anahtar: Finansal Mutabakat, Kural Tabanlı, Doğal Dil İşleme



1. Giriş

Finansal hizmet sağlayıcılarının dijital dönüşüm süreciyle birlikte işlem hacimleri ve veri kaynaklarının çeşitliliği önemli ölçüde artmıştır [1]. Özellikle elektronik para ve ödeme kuruluşlarında, günlük yüz binlerce işlemin firma içi sistemler ile bankacılık sistemleri arasında eş zamanlı, doğru ve şeffaf biçimde kayıt altına alınması kritik bir gereklilik haline gelmiştir [2]. Ancak banka servislerinde yaşanan kesintiler, kullanıcı kaynaklı manuel girişler, açıklama alanlarındaki format farklılıkları ve işlem tipi sınıflandırma hataları; otomatik eşleştirme süreçlerinin doğruluğunu azaltmakta, manuel kontrol ihtiyacını artırmakta ve finansal kayıplara zemin hazırlamaktadır. McKinsey'nin 2024 Küresel Ödemeler Raporu [3], 2023 yılında küresel ödeme endüstrisinin 3,4 trilyon işlem ve 1,8 katrilyon dolar tutarında değer işlediğini ve bu gelir havuzunun 2028'e kadar %5 yıllık büyüme ile 3,1 trilyon dolara ulaşacağını rapor etmektedir. Raporda nakit kullanımının hızla azalması, anlık ödeme sistemlerinin yükselişi ve dijital ödeme kanallarının çeşitlenmesi gibi eğilimler vurgulanmaktadır. Yapay zekâ ve makine öğrenmesi alanındaki güncel çalışmalar, manuel mutabakat süreçlerinin yerini alacak otomatik sistemlerin gerçek zamanlı raporlama sunduğunu, hata tespitini kolaylaştırdığını ve yüksek hacimli veriyi insan müdahalesi olmaksızın işleyerek verimliliği artırdığını göstermektedir [1, 4]. Dolayısıyla ileri düzey makine öğrenmesi, doğal dil işleme ve sentetik veri üretimi yöntemlerinin entegre edildiği yeni nesil mutabakat sistemleri, yüksek hacimli finansal işlemlerin doğruluğunu ve güvenliğini sağlayacak anahtar teknolojiler olarak öne çıkmaktadır [3].

Ayrıca yatırım bankacılığında bulut tabanlı mutabakat çözümlerinin maliyetleri %43 azalttığını ve uyum kaynaklı sorunları %71 azalttığını rapor etmektedir. Ayrıca bulut platformlarının günlük milyonlarca işlemin %96'sını gerçek zamanlı eşleştirebildiğini ve hacim artışlarını performans kaybı olmadan yönetebildiğini belirtmektedir [5]. Bu bulgular, yüksek hacimli finansal işlemlerin ancak ölçeklenebilir ve otomatik sistemlerle yönetilebileceğini göstermektedir.

Bankacılık ve kurumsal muhasebe alanında, manuel mutabakat süreçlerinin yetersizlikleri ve yapay zekâ tabanlı yaklaşımların potansiyeli üzerine geniş bir literatür bulunmaktadır. Ikponmwoba ve arkadaşları [6], geleneksel banka mutabakatının manuel ve zaman alıcı olduğunu, insan hatalarına açık bulunduğunu ve yapay zekâ/makine öğrenmesi ile desteklenen denetim kontrollerinin süreci hızlandırıp doğruluğu artırabileceğini vurgulamışlardır. Olasoji ve çalışma arkadaşları [7], hesaba giren ödemeler süreçlerinde veri formatı tutarsızlıkları ve manuel müdahaleler nedeniyle yaşanan gecikmeleri analiz ederek öngörüselleştirme ile iş akışı verimliliğinin ve



mutabakat doğruluğunun iyileştirilebileceğini göstermiştir. Benzer şekilde, Muntala [8], Oracle Fusion Cloud Financials platformunda makine öğrenmesi destekli mutabakatın geleneksel kural tabanlı yöntemlere kıyasla kapanış sürelerini %32 kısalttığını ve anomali tespitini %57 oranında iyileştirdiğini rapor etmiştir. Makayasa ve arkadaşları [9] , muhasebe işlem kayıtlarının otomatikleştirilmesi için SVM, K-En Yakın Komşu (KNN) ve Rastgele Orman algoritmalarını TF-IDF, BoW ve Word2Vec modelleriyle karşılaştırmıştır. SVM + Word2Vec kombinasyonu dengeli veri setinde %92,5 doğruluk ve F1 skoru ile en iyi sonuçları vermiş, ancak veri setinin küçük olması performansı sınırlamıştır; araştırmacılar daha büyük veri kümeleri ve BERT benzeri modeller önermiştir. Pan [10] ayrıca finans sektörünün dijitalleşmesiyle geleneksel sahtecilik tespit yöntemlerinin veri hacmi ve karmaşıklığı karşısında yetersiz kaldığını vurgulamış; makine öğrenmesinin güçlü veri işleme ve örüntü tanıma yetenekleri sayesinde finansal güvenlik alanında giderek daha önemli bir rol oynayacağını ileri sürmüştür. Inampudi ve arkadaşları, makine öğreniminin mutabakat süreçlerini nasıl otomatikleştirdiğini incelemiştir. Çalışma, denetimli ve denetimsiz öğrenme tekniklerinin büyük işlem verilerindeki desenleri, anormallikleri ve tutarsızlıkları algılayabildiğini; karar ağaçları, destek vektör makineleri ve sinir ağları gibi modellerin zaman içinde doğruluk ve hızlarını artırarak manuel denetim ihtiyacını azalttığını vurgulamaktadır. Bu makale, AI tabanlı mutabakatın işlem eşleştirme ve anlaşmazlık çözümü süreçlerini nasıl iyileştirdiğine dair teorik ve uygulamalı bir çerçeve sunmaktadır [11]

Bu literatür bulguları, finansal veri yönetimi süreçlerinde otomasyonun aşamalı biçimde geliştirilebileceğini göstermektedir. Özellikle başlangıç aşamasında **kural tabanlı sistemler**, işlem türlerinin tanımlanması, açıklama kalıplarının belirlenmesi ve temel eşleştirme kurallarının oluşturulması açısından etkili ve güvenilir bir temel sunmaktadır. Ancak veri hacmi büyüdükçe ve açıklama metinleri daha karmaşık hâle geldikçe, yalnızca kural tabanlı yaklaşımlar yeterli olmamakta; **doğal dil işleme (NLP)** teknikleri bu noktada kritik bir rol üstlenmektedir. NLP yöntemleri, finansal açıklamalardaki dilsel örüntüleri ve bağlamsal anlam ilişkilerini çözümleyerek, sistemin farklı ifade biçimlerini tanımasını ve doğru muhasebe kodlarına yönlendirmesini mümkün kılmaktadır. Bu nedenle, kural tabanlı yapıdan başlayarak NLP tabanlı çözümlerle genişletilen hibrit bir mimari, finansal mutabakat ve veri anlamlandırma sistemlerinde en uygun yaklaşım olarak öne çıkmaktadır.

Bu çalışma, Elekse Elektronik Para ve Ödeme Kuruluşu A.Ş. tarafından geliştirilen Akıllı Mutabakat ve Finansal Güvenlik Sistemi'ni ele almaktadır. Sistem, dijital bankacılığın yaygınlaşmasıyla ortaya çıkan yüksek hacimli finansal verilerin anlamlandırılması ve




muhasabe sistemleriyle uyumlu hale getirilmesi sürecinde yenilikçi bir çözüm sunmaktadır.

Elekse tarafından geliştirilen bu katmanlı mutabakat mimarisi, Yetkili Vezne, EsnekPos ve Hoppa olmak üzere üç farklı ürün grubundan gelen finansal hareketleri tek bir merkezde toplayarak kural tabanlı doğal dil işleme (NLP) yöntemleriyle otomatik olarak analiz etmektedir. Manuel olarak yürütülen mutabakat işlemleri çok fazla insan gücü ve zaman gerektirirken, geliştirilen bu sistem sayesinde aynı işlemler çok kısa süre içerisinde ve hatasız biçimde tamamlanabilmektedir. Ayrıca açıklama metinlerinden anlam çıkarımı yapılarak veri bütünlüğü, işlem doğruluğu ve finansal güvenlik önemli ölçüde artırılmıştır.

Bu kapsamda çalışma, finansal veri yoğunluğunun yüksek olduğu elektronik para ve ödeme hizmetlerinde otomatik, ölçeklenebilir ve güvenilir mutabakat sistemlerinin geliştirilmesine yönelik önemli bir örnek sunmaktadır.

2. Materyal ve Yöntem

Geliştirilen sistem, finansal hareketlerin otomatik olarak anlamlandırılması ve muhasabe sistemine entegre edilmesi sürecinde Şekil 1’de görüldüğü gibi dört temel katman çalışmaktadır. Bu katmanlar: Veri Toplama Katmanı, Metin Ön İşleme Katmanı, Kural Tabanlı Anlamlandırma Katmanı ve Geri Besleme ve Öğrenme Katmanı olarak isimlendirilmişlerdir.



Şekil 1: Sistem Katman Yapısı

Bu katmanlı yapı, hem yatayda (veri akışı) hem dikeyde (anlam derinliği) bütünleşik bir işleyiş sağlamaktadır. Her katmanın görevi, veri bütünlüğünü korumak ve insan müdahalesi olmadan doğruluk oranı yüksek bir finansal mutabakat elde etmektir.

Bu katmanlı yapı, Elekse sisteminin bütünsel işleyişini tanımlayan ardışık bir veri işleme zinciri olarak tasarlanmıştır. Bu işlem, ilk sırada yer alan Veri Toplama Katmanı ile başlamaktadır. Bu katmanda, Finekra API'si üzerinden milyonlarca banka hareketi otomatik olarak çekilir ve ham veriler standart bir biçimde sisteme kaydedilir. Ardından,



Metin Ön İşleme Katmanı devreye girer; burada açıklama metinleri dilsel olarak temizlenir, gereksiz karakterlerden arındırılır, küçük harfe dönüştürülür ve anahtar kelimeler çıkarılarak kural motoru tarafından yorumlanabilir hale getirilir. Üçüncü adım olan Kural Tabanlı Anlamlandırma Katmanı, metinlerden çıkarılan öznitelikleri kullanarak işlem türlerini ve muhasebe kodlarını otomatik olarak belirler. Bu aşamada kural tabanı, örüntü kümeleri ve eşleştirme algoritmaları birlikte çalışarak açıklamaları anlamlı finansal kategorilere dönüştürür. Son olarak, Geri Besleme ve Öğrenme Katmanı, sistemin kendini geliştirme sürecini yönetir. Kullanıcı doğrulamaları, yeni örüntülerin tanımlanması ve makine öğrenmesi entegrasyonlarıyla sistem sürekli olarak güncellenir. Böylece Elekse, milyonlarca satır finansal veriyi anlık olarak işleyebilen, dilsel anlam çıkarımını otomatikleştiren ve doğruluğunu sürekli artıran dinamik bir akıllı mutabakat altyapısı ortaya koymaktadır.

2.1. Veri Toplama Katmanı

Bu katman, sistemin giriş noktasını oluşturur ve finansal hareketlerin farklı kaynaklardan otomatik olarak çekilmesini sağlar. Veriler, Finekra platformu üzerinden sağlanan REST API aracılığıyla toplanır. Sistem, belirli bir tarih aralığı ve IBAN parametreleri göndererek ilgili banka hesabına ait tüm hareketleri JSON formatında elde eder.

Toplanan ham veriler genellikle aşağıdaki alanlardan oluşur:

transactionDate: İşlem tarihi

description: Banka açıklama metni (doğal dilde)

amountForExcel: Tutar bilgisi (decimal formatta normalize edilir)

referenceNumber: İşlem referans numarası

iban: Gönderen/alıcı hesap numarası

currency: İşlem döviz

Bu veriler MSSQL veritabanında depolanır ve Entity Framework aracılığıyla yönetilir. Tarih biçimi ve para birimi farklılıkları JSON Convert sürecinde normalize edilir; “culture” parametresi Türkiye yerel ayarlarına göre ayarlanır.

Katmanın temel görevi, günlük finansal verileri tek bir formatta toplamak ve sonraki metin işleme aşamalarına hazır hale getirmektir. Ayrıca her veri kaydı için bir hesap kategorisi (ör. Hoppa, Yetkili Vezne, EsnekPos) etiketi atanır.

Örnek Senaryo:

IBAN: TR42 0001 0023 ...



Tarih: 2025-10-03

Açıklama: “Hoppa Transfer – EFT ile para girişi”

Bu kayıt Finekra’dan otomatik çekilir, JSON biçiminde sisteme kaydedilir ve “Hoppa – EFT Girişleri” tablosuna atanır.

Bu katman, sistemin dış kaynak bağımlılığını azaltır ve manuel veri aktarımı ihtiyacını ortadan kaldırır.

2.2. Metin Ön İşleme Katmanı

Finansal açıklamalar, bankalar arasında dilsel ve biçimsel olarak farklılık gösterebilmektedir. Bu nedenle Elekse sisteminde ikinci katman olarak doğal dil ön işleme (NLP Preprocessing) modülü geliştirilmiştir.

Bu katmanın amacı, açıklama metinlerini kural motorunun anlayabileceği biçime dönüştürmek, metinlerdeki gürültüyü temizlemek ve dilsel örüntüleri standart hale getirmektir.

Bu katmanda aşağıdaki adımlar uygulanmaktadır:

Karakter Normalizasyonu: Tüm metinler küçük harfe (ToLower()) dönüştürülür. Türkçe karakter desteği korunur.

Gürültü Temizleme :Noktalama, özel karakterler ve gereksiz boşluklar düzenli ifadeler (regex) ile kaldırılır.

Örneğin: "FTR ODM / ELEKTRİK ÖDEMESİ!!!" → "ftr odm elektrik ödemesi"

Tokenizasyon:Metin kelimelere ayrılır; bu adım anahtar kelime tespiti için gereklidir.

"eft hoppa para girişi" → [eft, hoppa, para, girişi]

Kök Bulma (Stemming):“ödendi”, “ödemesi”, “ödeme” gibi varyasyonlar “öde” köküne indirgenir.

Anahtar Kelime Tespiti: Sistem, önceden tanımlı kural kümesinde yer alan anahtar kelimeleri arar (ör. “virman”, “fatura”, “komisyon”, “hoppa”, “yetkili vezne”).

Dilsel Tutarlılık Kontrolü: Aynı anlamı taşıyan farklı kelimeler (“virmn”, “virman”, “iç transfer”) aynı standarda eşlenir.

Örnek:

Girdi: “FTR ODM – Ankara Şube”

Çıktı: [fatura, ödeme, ankara, şube]

Anahtar kelime: “fatura” → işlem tipi “Fatura Tahsilatı”

Bu katman, daha sonra çalışan kural motoru için anlamlı öznitelikler üretir ve sistemin metin kaynaklı hatalara karşı dayanıklılığını artırır.



2.3. Kural Tabanlı Anlamlandırma Katmanı

Üçüncü katman, sistemin çekirdek karar verme mekanizmasıdır. Bu katman, metin ön işleme modülünden gelen anahtar kelimeleri kural tabanı (rule base) ile eşleştirerek, her bir işlem için uygun muhasebe kodunu belirler.

Kural tabanı, bankAccountingCodes tablosunda depolanır ve Tablo 1’de görülen alanlara sahiptir.

Tablo 1: Örnek Senaryo

Banka	Hesap Tipi	Anahtar Kelime	Muhasebe Kodu
Ziraat	Fatura Ödeme	fatura, odm, elektrik	600-02
Vakıfbank	Komisyon	komisyon, masraf	770-01
Tümü	Virman	virman, iç transfer	108-05

Katman, metin içindeki anahtar kelimeleri bu tabloyla karşılaştırır.

Eşleşme bulunduğunda ilgili muhasebe kodu atanır; bulunamadığında “Anlamlandırılmadı” etiketiyle işaretlenir.

Ayrıca sistemde örüntü kümeleri (pattern clusters) bulunmaktadır. Bu kümeler, aynı anlamı taşıyan farklı kelimeleri grup haline getirir. Örneğin:

Küme 1: {“fatura ödeme”, “ftr odm”, “ödeme fatura”}

Küme 2: {“virman”, “virmn”, “ic transfer”}

Bu yapı sayesinde sistem, dilsel varyasyonlara rağmen doğru eşleştirmeyi sağlayabilir.

Örnek Senaryo:

Açıklama: “Virmn Hoppa Hesabı Arası Transfer”

Anahtar kelimeler: [virmn, hoppa, transfer]

“virmn” → Küme 2 (virman işlemi)

“hoppa” → Ürün tipi “dijital hesap”

Sonuç: Muhasebe Kodu = 108-05 (Hoppa Virmanları)

Bu katmanın çıktısı, muhasebe sistemine aktarılmaya hazır biçimde “işlem tipi – tutar – muhasebe kodu” formatında oluşturulur.

2.4. Geri Besleme ve Öğrenme Katmanı



Dördüncü katman, sistemin sürekli iyileştirme (continuous improvement) bileşeni olarak planlanmıştır.

Bu katmanda, kural tabanının tanımlayamadığı veya yanlış sınıflandırdığı işlemler kullanıcıya sunulur. Kullanıcı doğru muhasebe kodunu seçtiğinde, bu bilgi sistemde “doğrulanmış örnek” olarak kaydedilir.

Bu mekanizmanın iki temel işlevi bulunmaktadır:

Otomatik Kural Güncelleme: Kullanıcının doğruladığı yeni örüntüler, “pattern library” veri tabanına eklenir. Böylece sistem bir sonraki benzer açıklamada manuel işlem gerektirmeden doğru eşleştirme yapabilir.

Makine Öğrenmesi İçin Veri Hazırlığı: Kullanıcı tarafından doğrulanan her kayıt, ileride kullanılacak denetimli öğrenme (supervised learning) modelleri için etiketli veri haline gelir.

Örnek Senaryo:

1. Açıklama: “POS Tahsilatı – Sanalpos İşlem Bedeli”
2. Sistem bu ifadeyi tanıyamaz → “Anlamlandırılmadı”
3. Kullanıcı kodu seçer: 601-03 (POS Tahsilatları)
4. Sistem örüntüyü kaydeder ve kural tabanını günceller.
5. Bir sonraki benzer açıklama otomatik olarak tanınır.

Gelecek çalışmalarda bu katman, aktif öğrenme (active learning) mekanizmasıyla makine öğrenmesi modüllerine entegre edilecektir. Böylece sistem, hem kural tabanlı hem de istatistiksel olarak kendini geliştiren hibrit bir yapıya dönüşecektir.

3. Sonuçlar

Bu çalışma, finansal veri yönetimi süreçlerinde dil işleme ve otomasyonun önemini vurgulayan bir çerçeve sunmaktadır. Elekse’nin katmanlı yapısı, verilerin toplanmasından anlamlandırılmasına kadar uzanan tüm aşamaları otomatikleştirerek manuel hataları azaltmakta ve işlem hızını artırmaktadır. Kural tabanlı yaklaşım, özellikle açıklama metinlerinden anlamlı bilgi çıkarımı ve muhasebe kodu eşleştirme açısından yüksek doğruluk sağlamıştır.



Gelecek alışmalar kapsamında sistemin öğrenme yeteneđi güçlendirilerek, makine öğrenmesi ve büyük dil modelleriyle desteklenmesi planlanmaktadır. Bu sayede Elekse'nin sadece kurallara dayalı deđil, bağlamı anlayabilen, örüntüleri kendiliğinden keşfedebilen ve finansal işlemlerde anomali tespiti yapabilen akıllı bir mutabakat altyapısına dönüşmesi hedeflenmektedir.



Referanslar

- [1] S. Gunasekaran, "AI-Powered Transaction Reconciliation: A Reinforcement Learning Approach," *International Research Journal of Engineering and Technology*, vol. 11, no. 6, pp. 17-29, 2024-06, 2024.
- [2] M. Lecci, and T. Hanne, "Accounting Support Using Artificial Intelligence for Bank Statement Classification," *Computers*, vol. 14, no. 5, pp. 193, 2025.
- [3] P. Bruno, U. Jeenah, A. Gandhi, and I. Gancho, *Global payments in 2024: Simpler interfaces, complex reality*, McKinsey & Company, 2024.
- [4] A. P. Alessandro, B. Jess, M. Bazzi, K. Kennedy, M. Arderne, D. Rodrigues, and M. Lotz, "Categorising SME Bank Transactions with Machine Learning and Synthetic Data Generation," *arXiv preprint arXiv:2508.05425*, 2025.
- [5] J. K. Vemuri, "Cloud-based reconciliation systems in investment banking: A comprehensive analysis of architecture, implementation, and performance metrics," *International Research Journal of Modernization in Engineering, Technology and Science*, vol. 7, no. 2, pp. 1-16, 2025-02, 2025.
- [6] S. O. Ikponmwo, O. K. Chima, O. J. Ezeilo, B. M. Ojonugwa, A. Ochefu, and M. O. Adesuyi, "Conceptual Framework for Improving Bank Reconciliation Accuracy Using Intelligent Audit Controls," 2020.
- [7] O. Olasoji, E. F. Iziduh, and O. O. Adeyelu, "A Predictive Modeling Approach for Managing Accounts Payable Workflow Efficiency and Ledger Reconciliation Accuracy," *Shodhshauryam, International Scientific Refereed Research Journal*, vol. 6, no. 4, pp. 106-120, 2023.
- [8] P. S. R. P. Muntala, "Enhancing Financial Close with ML: Oracle Fusion Cloud Financials Case Study," *International Journal of AI, BigData, Computational and Management Studies*, vol. 3, no. 3, pp. 62-69, 2022.
- [9] B. A. Makayasa, M. U. Siregar, B. Sugiantoro, and A. Fatwanto, "Comparison of Classification Algorithm and Language Model in Accounting Financial Transaction Record: A Natural Language Processing Approach," *International Journal on Advanced Science, Engineering & Information Technology*, vol. 14, no. 3, 2024.
- [10] E. Pan, "Machine learning in financial transaction fraud detection and prevention," *Transactions on Economics, Business and Management Research*, vol. 5, pp. 243-249, 2024.
- [11] R. K. Inampudi, D. Kondaveeti, and T. Pichaimani, "Optimizing Payment Reconciliation Using Machine Learning: Automating Transaction Matching and Dispute Resolution in Financial Systems," *Journal of Artificial Intelligence Research*, vol. 3, no. 1, pp. 273-317, 2023.