

Geliş Tarihi:

13.07.2020

Kabul Tarihi:

15.03.2021

Yayımlanma Tarihi:

25.06.2021

Kaynakça Gösterimi: Cedolin, M., & Genevois, M. E. (2021).
ATM'lerdeki nakite yönelik talep tahmini üzerine
sistemik yazın analizi. *İstanbul Ticaret Üniversitesi
Sosyal Bilimler Dergisi*, 20(40), 287-309.
doi: 10.46928/iticusbe.768918

ATM'LERDEKİ NAKİTE YÖNELİK TALEP TAHMİNİ ÜZERİNE SİSTEMATİK YAZIN ANALİZİ

Araştırma

Michele Cedolin  

Sorumlu Yazar (Correspondence)

Galatasaray Üniversitesi

mcedolin@gsu.edu.tr

Müjde Erol Genevois  

Galatasaray Üniversitesi

merol@gsu.edu.tr

Michele Cedolin, Galatasaray Üniversitesi Endüstri Mühendisliği Bölümünde doktora öğrenimini sürdürmekte, aynı zamanda araştırma görevlisi olarak görev yapmakta ve talep tahmini konusunda araştırmalar yayınlamaktadır.

Müjde Erol Genevois, Galatasaray Üniversitesi Endüstri Mühendisliği Bölümünde doçent olarak görev yapmakta olup, üretim ve hizmet sistemleri alanlarında ders vermekte ve araştırmalar yayınlamaktadır.

ATM'LERDEKİ NAKİTE YÖNELİK TALEP TAHMİNİ ÜZERİNE SİSTEMATİK YAZIN ANALİZİ

Michele Cedolin
mcedolin@gsu.edu.tr
Müjde Erol Genevois
merol@gsu.edu.tr

ÖZET

Otomatik Vezne Makineleri, yaygın kullanılan ismi ile ATM'ler, bankacılık sektörünün en önemli servis kollarından birini oluşturmaktadır. Özellikle COVID-19 sürecinde, bankalar birçok şube içi işlemi bu makinelere kaydırmış, para çekme ve yatırma limitleri arttırılarak bu temassız servis noktasının kullanımını teşvik etmiştir. Bu makinelerde gerçekleşen nakit akışlarına yönelik yapılan talep tahminleri, herhangi bir üründen ziyade direk olarak nakit parayı hedef aldığından, katma değeri yüksek zorlu bir süreci oluşturmakla beraber; problemin karşıt amaçlarını ise, yeterli miktarda nakit bulunmaması durumunda müşteri ihtiyacının giderilememesi ve buna karşılık makine içerisindeki paranın banka tarafından herhangi bir yatırım aracında değerlendirilmemesi oluşturmaktadır. Bu çalışma kapsamında, günümüze kadar ATM talep tahmini üzerine yapılmış çalışmalar, veri yapısı, tahmin yöntemi, karşılaşılan sıkıntılar, alternatif modeller, tahmin dönemi gibi çeşitli başlıklarda sınıflandırılmakta, henüz değinilmemiş noktalar belirtilerek bundan sonraki çalışmalara zemin hazırlanmaktadır. Özellikle talep tahmininde makine öğrenmesi yöntemlerinin yaygın olarak kullanıldığı ve bu yöntemlerin sonuçlarının istatistiksel tahmin yöntemleri çıktıları ile karşılaştırıldığı tespit edilmiştir. Çalışmaların büyük bir çoğunluğu ortak bir açık veri seti kullanmakta ve karşılaştırılabilir sonuçlar sunmaktadır. Bildiğimiz kadarı ile bu çalışma, tasvir ettiğimiz alanda yapılan ilk yazın taraması olmakta, aynı zamanda ülkemizde henüz üzerinde durulmamış bir alanı işaret etmektedir.

Amaç: ATM'lerle ilgili mevcut talep tahmini yazının taranması, sınıflandırılması ve bu alandaki çalışmalar için yol haritası oluşturması.

Yöntem: Sistemik yayın taraması, makalelerin sınıflandırılması, kriterlerinin seçilmesi ve buna göre sınıflandırılıp analiz edilmesi.

Bulgular: ATM talep tahmini alanında 32 çalışmanın varlığı, ortak açık veri setlerinin kullanıldığı, yaygın olarak makine öğrenme metotlarının uygulandığı ve istatistiksel talep tahmin modellerinin karşılaştırma ölçütü olarak sunulduğunun tespiti.

Özgünlük: Bu alanda yapılan ilk sistemik yazın taraması ve analizi olması.

Anahtar Kelimeler: ATM Yönetimi, Nakit Yönetimi, Talep Tahmini, Finansal Optimizasyon

JEL Sınıflandırması: C1

A SYSTEMATIC LITERATURE ANALYSIS ON CASH FORECASTING PROBLEMS IN ATMS

ABSTRACT

Automated Teller Machines, ATM's, constitute one of the most important service branches of the banking sector. During COVID-19, banks shifted many in-branch transactions to these machines and encouraged the use of this contactless service point by increasing the deposit and withdrawal limits. Demand forecasts for cash flows in these machines create a challenging process with high added value as they target cash directly. The contradictory objectives of the problem are that if the cash is not available, the customer need cannot be met, but the stocked money may not be evaluated in any investment instrument. Within the scope of this study, the studies on ATM demand forecasting are classified under various topics such as data structure, forecasting method, alternative models, forecasting horizon, and the backgrounds for future studies are prepared by stating untouched points. Especially, it has been observed that machine learning methods are widely used in the literature and their results are compared with the outcomes of the statistical forecasting techniques. Most of the studies employ a common public data set and provide comparable results. To the best of our knowledge, this study is the first literature review in this field, and also marks an area that has not been addressed yet in our country.

Purpose: Review of the literature relevant to the ATMs forecasting studies, their classification and providing a roadmap for further studies in this area.

Method: Systematic literature review, classification of the articles, selection of the criteria and analyze by the selected criteria.

Findings: Presence of 32 papers on the ATM forecasting literature, employ of the common public data sets, widely utilization of the machine learning models, and detection of the use of statistical forecasting model results as the benchmark values.

Originality: Being the first systematic review and analysis article on this area.

Keywords: ATM Management, Cash Management, Demand Forecasting, Financial Optimization

JEL Classification: C1

GİRİŞ

Otomatik Vezne Makineleri veya ATM'ler bankaların nakit yönetimi operasyon süreçlerinin önemli bir kısmını kapsamaktadır. Banka şubelerinden farklı olarak 7/24 sürekli bir şekilde, personel gerektirmeden hizmet vermek üzere tasarlanmış olan ATM'ler, teknolojinin de gelişimi ile artık sadece para çekme ve para yatırma gibi temel işlemlerden farklı olarak para transferi, fatura ödeme, vergi ve harç yatırma gibi çeşitli fonksiyonlara sahiptir. Özellikle COVID-19 sürecinde bu makinelerin kullanım oranları ve hacimleri artmış, şube içerisinden gerçekleştirilen işlemler artık sadece bu makinelerden ve dijital yollardan gerçekleştirilebilir hale gelmiştir. Pandemi süreci sebebi ile dijitalleşmenin ivme kazandığı bu dönemde bu makinelerin efektif bir şekilde yönetilmesi önem kazanmaktadır. Bu yönetsel sürecin en önemli basamaklarından birini talep tahminleri etkin bir şekilde gerçekleştirmek oluşturacaktır. Talebin tahminindeki temel hedef her bir ATM için doğru stok miktarını bulmak ve para stokunu dengelerken, bu makinelerin efektif şekilde doldurulup boşaltılmasını sağlamaktır. Regülasyon gereği, makinelerin içindeki nakit stoku, bankanın “repo” diye adlandırdığımız gecelik faizinden faydalanamamakta bu durum da fırsat maliyetlerine yol açmaktadır. Öte yandan, makineler bir servis noktası olduğu düşünüldüğünde, burada yeterli nakit bulunmadığında müşteri para çekemeyecek, bu durumun tekrar edilmesi de müşteri kayıplarına yol açabilecektir. Bu sebeple, ATM nakit yönetimi problemi, doğası gereği karşıt amaçların çatıştığı, çift taraflı bir en iyileme problemine dönüşmektedir. Bu problemde temel amaç, makinenin içindeki nakit stokuna uygun bir denge noktası yaratmaktır. Bu denge noktasını yaratmanın ilk adımı talebi düzgün tahminleyebilmek, ikinci adımı ise bu tahmin doğrultusunda makinelerin doluluk miktarını ve zamanını saptayabilmektir.

“ATM” anahtar kelimesi ile yazın incelendiğinde ATM nakit yönetimi probleminin dört ana grupta kümelenmekte olduğu gözlemlenmektedir. Bu gruplar; makinelerin yerleşim problemleri, doldurma veya ikmal problemleri, talep tahmini problemleri ve sınıflandırılmayanlar olarak belirtilebilir.

Yerleşim problemi direkt olarak erişilebilirlik ölçütünü ve müşteri memnuniyetini etkilemekte ayrıca araç rotalama maliyetleri ile bağlantılı olmaktadır. Yazında ATM'lerin yerleşim problemleri, matematiksel modeller, genetik algoritma, coğrafik bütünleşme sistemleri gibi çeşitli yaklaşımlarla çözülmüştür.

Stok seviyesi kontrol ve zırlı araç rotalama, doldurma veya ikmal problemleri, yöneticilerin ilgilendiği bir diğer nakit en iyileme süreci olarak karşımıza çıkmaktadır. Bu süreçte temel hedef, toplam kiralanan araç sayısı ile araçların toplam güzergâhını en aza indirmektir.

Talebin kesikli ve sürekli değişken yapısı sebebi ile talep tahmini problemlerinin modellenmesi ise bankalar için zorlu bir süreçtir. Hassas tahmin yöntemleri, efektif stok seviyeleri ve doğru ikmal politikaları ile sonuçlanarak maliyetlerin azalmasını sağlar. ATM'lerin sürekli veri akışı sağlayan akıllı yapısı, talep tahmini problemini, büyük veri analizinin başlıca çalışma alanlarından biri haline getirmiştir. Alternatif modeller, değişik parametreler ve veri setleriyle test edilmiş, hibrit yaklaşımlar

geliştirilmiştir. Bu çalışmadaki temel amaç, ATM nakit yönetiminde en zorlu süreçlerden biri olduğu düşünülen talep tahmini yazını konusunda sistematik bir sınıflandırma ve analiz sunmaktır.

Çalışmanın devamında ATM talep tahmin yazını detaylı olarak incelenerek ilgili yazın, kullanılan veriler, yöntemler, girdi ve parametreler açısından analiz edilmekte, son bölümde ise ulaşılan sonuçlar tartışılmaktadır.

ATM TALEP TAHMİNİ YAZINI

ATM’leri konu alan yazın incelendiğinde, makinelerde gerçekleşen nakit akışının tahminine yönelik çalışmalar en geniş kategoriye oluşturmaktadır. Bu yazın taramasını oluşturmak için Web of Science (WoS) veri tabanına “Cash Management”, “Demand Forecasting” ve “ATM Management” gibi alternatif anahtar kelimeler yazılmış, ilgili makaleler incelenmiş ve bu çalışmaların ilgili referansları da okunarak toplamda otuz iki adet yazılı esere ulaşılmıştır.


Tablo 1 kronolojik sırada olup, yazar, sene ve çalışmanın başlığından oluşmaktadır. Dünyanın birçok bölgesinden araştırmacıların katıldığı bu yazına maalesef ülkemiz henüz katkıda bulunmamıştır. Bu sebeple bu çalışmanın bir amacı da ülkemiz araştırmacı ve kuruluşlarını bu alanda çalışmaya ve eserlerini sunmaya teşvik etmektir. Çalışmaların başlıkları genel itibarı ile kullanılan temel yöntemleri ve odak noktaları kapsadığından tabloya dâhil edilmesi gerekliliği görülmüştür. Bu çalışmanın temel kapsamında, ATM tahmin problemleri yazınında kullanılan teknikler ve metotlar, bu tekniklerin detayları, avantaj ve dezavantajları incelenecektir. Makalelerde kullanılan verinin özellikleri, sistemin girdi ve çıktıları, verinin kaynağı ve büyüklüğü, tahmin süresinin uzunluğu, kullanılan hata terimleri ve değerleri, aykırılıkların varlığı ve bunlara geliştirilen yaklaşımlar, bu problemin çözümünde kullanılan program ve araçlar incelenecek temel başlıkları oluşturmaktadır.

Tablo 1. ATM Talep Tahmini Yazını

Referans	Başlık
(Kumar and Walia, 2006)	Cash Forecasting: An Application of ANN in Finance
(Simutis et al., 2007)	Optimization of Cash Management for ATM Network
(Simutis et al., 2008)	Cash Demand Forecasting for ATMs using NN and SVR Algorithms
(Brentnall et al., 2008)	A Statistical Model for the Temporal Pattern of Individuals ATM Withdrawals
(Zapranis and Antonis, 2009)	Forecasting Cash Money Withdrawals Using Wavelet Analysis and Wavelet Neural Networks
(Brentnall et al., 2010a)	Predicting the Amount Individuals at ATMs using REMM
(Brentnall et al., 2010b)	Predictive-Sequential forecasting System Development for ATM Stocking
(Garcia-Pedrero and Gomez-Gil, 2010)	Time Series Forecasting Using RNN and WRS
(Paul and Mukherjee, 2010)	ATMs and Cash Demand Forecasting: A Study of Two Commercial Banks
(Rodrigues and Esteves, 2010)	Calendar Effects in Daily ATM withdrawals
(Van Anholt and Vis, 2010)	An Integrative Online ATM Forecasting Replenishment Model with A Target Fill Rate
(Wichard et al., 2010)	Forecasting the NN5 Time Series With Hybrid Models
(Andrews et al., 2011)	Forecast Combinations of CI and Linear Models for the NN5 Time Series Competition
(Atsalaki et al., 2011)	Cash Withdrawals Forecasting by NN
(Ramirez and Acuna, 2011)	Forecasting Cash Demand in ATM Using NN and Least Square SVM
(Teddy and Ng, 2011)	Forecasting ATM Cash Demands Using PSECMAC
(Dilijonas and Sakalauskas, 2011)	Self-Service Systems Performance Evaluation and Improvement Model

Referans	Başlık
(Acuna et al., 2012)	Comparing NARX and NARMAX models using ANN and SVM for cash demand forecasting for ATMs
(Darwish, 2013)	A Methodology to Improve Cash Demand Forecasting for ATM Network
(Gurgul and Suder, 2013)	Modelling of Withdrawals from Selected ATMs of the "Euro net" Network
(Wagner, 2013)	Forecasting Daily Demand in Cash Supply Chains
(Arora et al., 2014)	Approximating Methodology: Managing Cash in ATMs Using Fuzzy ARTMAP Network
(Kamini and Ravi, 2014)	Chaotic TSA with NN to Forecast Cash Demand in ATMs
(Venkatesh et al., 2014)	Cash Demand Forecasting in ATMs by Clustering and NN
(Catal et al., 2015)	Improvement of Demand Forecasting Models with Special Days
(Aseev et al., 2016)	Forecasting Cash Withdrawals in the ATM Network using a Combined Model based on the HWM and Markov Chains
(Nemeshaev and Tsyganov, 2016)	Model of the Forecasting Cash Withdrawals in the ATM Network
(Khanarsa and Sinapiromsaran, 2017)	Multiple ARIMA Subsequences Aggregate TSM to Forecast Cash in ATM
(Rajwani et al., 2017)	Regression Analysis for ATM Cash Flow Prediction
(Jadwal et al., 2018)	K-Means Clustering with NN for ATM Cash Repository Prediction
(Perera and Hewage, 2018)	Determinants of ATM Loading Requirements in Sri Lankan Cash Supply Chains
(Arabani and Komleh, 2019)	The Improvement of Forecasting ATMs Cash Demand of Iran Banking Network Using CNN

Şekil 1’de kısaca ön izlendiği üzere, otuz iki çalışmanın on dört senelik (tahmin problemleri için nispeten kısa bir süre) bir dönemde ortaya çıkması ve özellikle 2010 sonrası yoğunlaşması konunun önemini arz eden bir girdi olarak kabul edilmektedir.




Şekil 1. Talep Tahmini Çalışmalarının Yıllık Dağılımı

ATM nakit akışı tahmini problemlerinde ilk çalışma Kumar ve Walia’ya (2006) ait olup, 2010 yılından sonra bu çalışmaların yoğunluğunda önemli bir artış gözlemlenmektedir. 2010 yılı toplamda yedi makale ve 2011 yılı toplamda beş makale ile konunun en çok ön plana çıktığı yılları oluşturmaktadır. Bu yoğunluğun temel sebebi, 2010 yılında çevrimiçi bir platformda, İngiltere’ye ait bir bankanın 111 ATM’sine ilişkin iki yıllık veri setinin, Neural Network 5 “NN5” adı verilen bir makine öğrenmesi yarışmasında, araştırmacılara sunulmuş olmasıdır. Bu veri seti, çok büyük ve gerçek olmasından kaynaklı, yapay zekâ üzerine çalışan akademisyenlerin ilgisini çekmiş, yapılan çalışmalardan birçoğu 2010 yılında Barcelona’da gerçekleşen konferansta sunulmuştur.

Bu çalışmalarda yazarlar değişik metotlar kullanmış, aynı metotları kullananlar da parametreler ve modelin kurgulanmasında çeşitli değişikliklere gitmişlerdir. Bu metotlar “İstatistiksel Teknikler” ve “Yapay Zekâ Uygulamaları” olarak sınıflandırılabilir. Bu iki sınıfın dışında, bu iki metodu bütünleşmiş bir şekilde kullanan hibrit yaklaşım sınıfı bulunmaktadır. Kullanılan temel istatistiksel teknikler, ARMA, ARIMA, SARIMA gibi lineer modeller ve değişik parametrelerle noktasal veya aralık tahmini yapan regresyon modelleri olarak sıralanabilir. Üstel düzgünleştirme ve ilişileşim

testleri alternatif istatistikler araçlar olarak karşımıza çıkmaktadır. Yapay zekâ uygulamaları genelde alternatif yapay sinir ağları modelleri ile karşımıza çıkmaktadır. Bu modeller sırasıyla CNN, WNN, GRNN, RNN ve FNN olarak adlandırılmaktadır. MASA ve SVR, araştırmada kullanılan diğer araçlar olarak karşımıza çıkmaktadır. Bu tekniklerin kullanımı Şekil 2’de verilmiştir.



Şekil 2. Kullanılan Teknikler

32 makalenin 19’unda yapay zekâ temelli bir yaklaşım benimsenirken, çalışmaların 12’sinde ise istatistiksel temelli bir yaklaşım uygulanmıştır. Sadece üç çalışmada ise bu iki yaklaşım hibrit bir şekilde kullanılıp daha iyi sonuçlar elde edilmeye çalışılmıştır. Buna rağmen bu grafiği, yapay zekâ ve istatistiksel temelli yaklaşım kullanımı açısından bir denge varmış gibi yorumlamak hata olacaktır. Söz konusu çalışmalar incelendiğinde, istatistiksel teknikler, yapay zekâ uygulamaları için karşılaştırmalı bir değerlendirme aracı olarak sunulmaktadır. Diğer bir deyişle, istatistiksel tekniklerin sonuçları verilmekte ve genellikle bu sonuçlar yapay zekâ modelleri tarafından aşılmaktadır. Hibrit yaklaşımların sayısı ve oranının azlığı, bu alandaki çalışmaların evrilmesi gereken yönlerden biri olduğunu göstermektedir.

VERİ ÖZELLİKLERİ


Seçilen çalışmaların veri özellikleri dört temel kategoride incelenmiştir. Bu kategoriler sırası ile verinin kaynağı, veri setinin uzunluğu, verinin çıktısı veya tahmin dönemi ve ATM sayısıdır. ATM sayısı, problemde kullanılan zaman serisi sayısına denk düşmektedir. Her ATM bir zaman serisi oluşturmaktadır. Kullanılan bütün veri, ATM’lerin günlük veri akışından alınmıştır. Veriyi açıklayan ve özetleyen Tablo 2 aşağıda verilmiştir.

Tablo 2. Veri Özellikleri

Referans	Veri Kaynağı	Veri Uzunluğu	Çıktı	ATM Sayısı
(Kumar and Walia, 2006)	Bank of India	3 ay	Günlük/haftalık	1 Şube
(Simutis et al., 2007)	Simulasyon	2 yıl	Ertesi Gün	1225
(Simutis et al., 2008)	Simulasyon	2 yıl	Ertesi Gün	15
(Brentnall et al., 2008)	Simulasyon	4 ay	Para çekme zamanı	1000 hesap
(Zapranis and Antonis, 2009)	NN5	2 yıl	56 günlük talep	11
(Brentnall et al., 2010a)	Simulasyon	4 ay	Para çekme miktarı	5000 hesap
(Brentnall et al., 2010b)	Simulasyon	2 yıl	ATM skorları	190

Referans	Veri Kaynağı	Veri Uzunluğu	Çıktı	ATM Sayısı
(Garcia-Pedrero and Gomez-Gil, 2010)	NN5	2 yıl	56 günlük talep	11
(Paul and Mukherjee, 2010)	Bharath Bank	3 ay	Aylık talep	120
	Global Bank	Aylık	Aylık talep	33
(Rodrigues and Esteves, 2010)	Portugal Bank	7 yıl	Takvimsel Etkiler	1
(Van Anholt and Vis, 2010)	Dutch Bank	1.5 yıl	4 Ay	1
(Wichard et al., 2010)	NN5	2 yıl	56 günlük talep	111
(Andrews et al., 2011)	NN5	2 yıl	56 günlük talep	30
(Atsalaki et al., 2011)	Simulasyon	2 yıl	110 günlük talep	100
(Ramirez and Acuna, 2011)	NN5	2 yıl	100 günlük talep	30
(Teddy and Ng, 2011)	NN5	2 yıl	56 günlük talep	30
(Dilijonas and Sakalauskas, 2011)	India Bank	3 ay	Haftalık talep	5500
	Lithuanian Bank	6 ay	Haftalık talep	21
(Acuna et al., 2012)	NN5	2 yıl	100 günlük talep	30
(Darwish, 2013)	Simulasyon	1 yıl	Haftalık talep	25
(Gurgul and Suder, 2013)	Simulasyon	4 yıl	60 günlük talep	293
(Wagner, 2013)	European Bank	759 gün	28 günlük talep	20
(Arora et al., 2014)	X Bank	2 yıl	Ertesi Gün	1
(Kamini and Ravi, 2014)	NN5	2 yıl	56 günlük talep	111
(Venkatesh et al., 2014)	NN5	2 yıl	Haftalık talep	30
(Catal et al., 2015)	NN5	2 yıl	56 günlük talep	111
(Aseev et al., 2016)	Ekaterinburg Bank	8 ay	21 günlük	11
(Nemshaev and Tsyganov, 2016)	Russian Bank	7 ay	Haftalık talep	1
(Khanarsa and Sinapiromsaran, 2017)	NN5	2 yıl	2 yıl	111
(Rajwani et al., 2017)	Pakistan Bank	2.5 yıl	İşlem Miktarı	1
(Jadwal et al., 2018)	NN5	2 yıl	56 günlük talep	11
(Perera and Hewage, 2018)	Sri Lankan Bank	2 yıl	Aylık talep	1
(Arabani and Komleh, 2019)	Iran Bank	1 yıl	73 günlük	1056


Tablo 2’de görüldüğü üzere, yazının temel veri kaynağını “NN5” yarışmasının veri seti oluşturmaktadır. En çok kullanılan ikinci veri türü ise simülasyon çalışmalarıdır. Bunun sebebi genellikle finansal kuruluşların veri paylaşımı konusundaki çekimser tavrı olarak yorumlanabilir. Simülasyon verileri genellikle ARENA, Simulink veya ROCKWELL gibi özelleşmiş programlar aracılığı ile üretilmiştir. Simülasyon verilerindeki temel dezavantaj, müşteri gelişleri ile para yatırma ve çekme hareketlerinin herhangi bir istatistik dağılımına uymaması ve talebin modellenmesi için gerekli birçok parametrenin aslında tamamen bilinmemesidir. Bu sebeple benzetim verileri, çalışmaların içinde iyi bir sonuç verse dahi, gerçek hayattaki bir probleme uygulandığında, başarısı tartışılabilir konumda kalmaktadır. Öte yandan, bazı ülkelerin bankaları, ATM’leri ile ilgili işlem bilgilerini araştırmacılarla paylaşmıştır. Bunlara örnek olarak Portekiz, Almanya, Hindistan, Rusya gibi ülkeler verilebilir. Veri kaynaklarının dağılımı aşağıdaki Şekil 3 ile görselleştirilmiştir.



Şekil 3. Veri Kaynaklarının Dağılımı

Çalışmaların %41'i özel bankaların veri setini kullanmakta, %35'i ise "NN5" verisini kullanmaktadır. 31 çalışmadan 8'inin verileri simülasyon verisidir. Gerçek veri kullanmanın avantajı, zaman serisinin adlandırılabilen ve adlandırılmayan tüm karakteristik özelliklerini barındırmasıdır. Bu özelliklerin tamamının simülasyon teknikleri ile üretilmesi, her ne kadar hata terimi eklenebilse de, mümkün olmamaktadır. Aynı şekilde, talep tahmin hassasiyet karşılaştırması farklı veri setleri kullanan çalışmalar için anlamsız olacaktır. Buna rağmen, Paul and Mukherjee (2010) ve Dilijonas and Sakalauskas (2011), iki değişik ATM ağının verilerini kullanmaktadır. Bu sebeple, "NN5" veri seti sunmuş olduğu karşılaştırma imkânı sebebi ile yazarlar tarafından sıklıkla tercih edilmiştir. Bu veri seti İngiltere'ye bağlı bir bankanın 111 ATM'sinin günlük olarak iki senelik işlem tarihi ve miktarından oluşmaktadır. Öte yandan, bazı çalışmalar, bu veri setinin kısıtlı bir parçası olan 11 zaman serisi üzerine dayalı veri setini çözmeyi tercih etmişlerdir.

Veri serisinin uzunluğu da, çalışmaların incelenmesi gereken önemli bir karakteristiğini yansıtmaktadır. Veri setinin uzunluğu arttıkça, tahmin hassasiyetinin başarısını doğrudan etkilemektedir. Çalışmalarda görülen asgari zaman serisi uzunluğu üç ay (Kumar and Walia, 2006; Paul and Mukherjee, 2010; Dilijonas and Sakalauskas, 2011), azami uzunluk ise yedi yıldır (Rodrigues and Esteves, 2010). Tablo 2'deki veri uzunluğu kolonu, Şekil 4'de; iki seneye kadar, iki sene ve iki seneden fazla olarak sınıflandırılmıştır.




Şekil 4. Veri Uzunluğu Sınıflandırması

Şekil 3’de görüldüğü üzere, sadece dört çalışma iki seneden fazla bir veri seti uzunluğu kullanmakta, çalışmaların %53’ü iki senelik veri kullanmakta, on iki çalışma da üç ay, dört ay gibi, iki seneden az bir dönem kullanmaktadır. Verinin içindeki trend ve mevsimsellik etkilerini düşündüğümüzde, kısa dönemli veri üstüne yapılan bu çalışmalar, çeşitli dezavantajlar barındırmaktadır. Örneğin Dilijonas and Sakalauskas (2011) ve Darwish (2013) müşterilerin para çekme karakteristiğini direkt etkileyen özel takvim günleri faktörünü devre dışı bırakmaktadır. Dolayısı ile yılbaşı, sevgililer günü, milli bayramlar, dini bayramlar gibi alışveriş hacminin arttığı ve ATM nakit akışlarında düzensizlikler yaratan günlerin etkilerinin ölçülebilmesi adına, iki senelik bir çalışma periyodu, araştırmacıların çoğu tarafından bir eşik değer olarak kabul edilmiştir.

Diğer bir deyişle, çalışma periyodu, bu takvim günlerini içermediğinde, tahmini yönlendirecek çok değerli bir girdiyi kullanmamaktadır. Öte yandan, bu etkiyi iki kez barındıran, diğer bir deyişle sadece en azından iki senelik veri setine sahip makaleler bu etkiyi gösterebilmektedir. Bu sebeple, böylesine zor bir tahmin problemi için, makalelerin %85’inde olduğu üzere, veri setinin asgari iki sene olmasının bir gereklilik olduğuna inanılmaktadır. Rodrigues ve Esteves (2010), çalışmalarında Portekiz Bankasının yedi senelik verisini kullanmış ve özel takvimsel günlerin, günlük para çekme miktarı ile ilişkisini incelemiştir (Rodrigues and Esteves, 2010).

Tahmin döneminin uzunluğu çalışmaların bir diğer önemli yapıtaşını oluşturmaktadır. Prensipite, tahmin dönemi uzadıkça, hata payının artması beklenmektedir. Öte yandan, bu dönem kıaldıkça, tahmin hassasiyeti artmaktadır. Buna rağmen, anlamlı bir tahmin döneminin değeri yadsınamaz. Buna ek olarak, ATM’lerin dolumu ile ilgili yazın, zırlı araç ve hareket halindeki nakidin yüksek maliyetlerinden bahsetmekte, bu sebeple ATM’lerin günlük veya sürekli dolumuna yönelik bir politika mümkün olmamaktadır. Çalışmalara odaklanıldığında asgari tahmin dönemi “sonraki gün” (Simutis et al., 2007; Simutis et al., 2008; Arora et al., 2014), azami tahmin dönemi ise dört ay (Van Anholt and Vis, 2010) olmaktadır. Çalışmaların çoğunluğu, en güçlü mevsimsellik endeksi olan haftanın gününü dikkate alarak; haftalık, yirmi sekiz günlük veya elli altı günlük olmak üzere yedinin katı olan tahmin dönemlerini tercih etmişlerdir. Bu şekilde pazartesiden pazara, haftanın günlerinin ATM’ler üzerindeki etkisini dikkate alan çalışmalar, başarılı sonuçlara ulaşmıştır.

Brentnall et al., (2008; 2010a) diğer araştırmalardan farklı olarak, sırasıyla bin hesabın para çekme zamanını ve beş bin hesabın para çekme miktarını ölçümlemeye çalışmaktadır. Benzer olarak, Rajwani et al. (2017) Pakistan Bankası’nın tek şubesinin toplam talep miktarını tahmin etmeye çalışmaktadır. Sadece Kumar and Walia (2006), günlük ve haftalık olmak üzere iki değişik tahmin dönemi kullanmakta, öte yandan bu çalışma ATM özelinde değil Hindistan Bankası şubesinde gerçekleşmektedir. Brentnall et al. (2010b), 190 simüle edilmiş ATM arasından en iyi çalışan makineyi bulmaya çalışmakta ve ATM’leri puanlamaktadır. Rodrigues and Esteves (2010), çıktı olarak takvimsel etkilerin, talep zaman serileriyle korelasyonunu vermektedir. Bunlar dışında kalan çalışmaların, talep dönemi Şekil 5’de verilmiştir.



Şekil 5. Tahmin Dönemi


Şekil 5’de gözlemlendiği üzere, en çok tercih edilen tahmin dönemi %30 ile 56 günlük olmaktadır. Sekiz haftalık tahmin üzerine odaklanan tüm bu çalışmalar NN5 yarışmasının veri setini kullanmakta ve sonuçlarını karşılaştırmakta, bu sebeple tutarlı bir karşılaştırma için aynı tahmin dönemine ihtiyaç duymaktadır. İki aylık, yetmiş üç günlük, yüz günlük, yüz on günlük ve dört aylık tahmin dönemleri, iki-dört aylık tahmin dönemi kategorisinde birleştirilmiş ve çalışmaların %22’sini oluşturmaktadır. Yirmi yedi çalışmadan yalnızca üç tanesi ertesi gün tahmini yapmakta, çalışmaların %18’i ise haftalık tahmin dönemi kullanmaktadır. Aynı yüzdesel oran yirmi bir günlük ve aylık talep sınıfında da bulunmaktadır.

Kullanılan veri setinin uzunluğu arttıkça, tahmin döneminin uzunluğu da artmaktadır. Bütün çalışmalar, tahmin en iyilenmesi yapmaya çalışırken, daha teorik bir konu olan en iyi tahmin dönemi süresini seçme kısmı araştırılmalarda değinilmeyen bir konu olarak kalmaktadır. Gerçek sistemlerde ATM’lerden veri akışı anlık olup, tahmin dönemi uzun süreli olsa bile sürekli bir döngü halinde güncellenmektedir. Burada bahsedilen elli altı günlük gibi uzun dönemli planlar, kuruluşların bu iş özelindeki makro düzeydeki planlarını gerçekleştirmesi için gerekli olup, araç sayısı ve dolun tarihleri gibi, veri akışı ile günlük olarak düzeltilmekte, dolun miktarları ile değişik politikalar ile gerçekleştirilmektedir.

Her bir tekil çalışmada kaç adet zaman serisinin kullanıldığı, veri ile ilgili incelenmesi gereken temel kategorilerden birini oluşturmaktadır. Her bir ATM bir zaman serisi olarak düşünülebilir. Eğer çalışma tek bir ATM veya banka şubesi üzerinde yapıldıysa tek bir zaman serisi, alternatif makinelerin verisi kullanıldıysa çoklu zaman serisi modeline uymaktadır. Bu ikisi arasındaki temel fark, ilkinin karşılaştırma imkânının olmaması ve modelin seçili ATM’ye aşırı uyum gösterme tehlikesi altında kalmasıdır. Bu durumda, bir makine için tatmin edici sonuçlar üreten bir model, başka bir makineye uygulandığında, verimsiz sonuçlar doğurabilmektedir. Verinin içerisinde alternatif makinelere ait zaman serileri bulunduğu, model tüm zaman serileri için tatmin edici sonuçlar üretmeye çalışmakta dolayısı ile aşırı uyum problemi ortadan kalkmaktadır. Zaman serilerinin sayısının artması modelin sonuç performansını arttıracak fakat çözüm için gerekli hesaplama zamanını da buna bağlı olarak artacaktır.

Çoklu zaman serileri yapı itibarı ile gerçek hayat problemine daha yakınsamakta, fakat problemin karmaşıklığı çözüm süresi de buna bağlı olarak artmaktadır. Tekil makinelerde sağlanan düşük hata payı oranı da aynı şekilde çoklu zaman serileri kullanıldığında elde edilememektedir. Fakat tahminin esas amacının dolun sürecinin en iyilenmesi için gerekli girdiyi sağlamak olduğu düşünüldüğünde ve bankaların ATM’leri bütünleşik şekilde doldurma yaklaşımını benimsediği için, tekli zaman serileri, tahmin ötesinde bir katkı sağlamamaktadır.

Şekil 6’da, çalışmalarda kullanılan ATM sayıları (zaman serileri) verilmiştir. Kumar and Walia (2006), Brentnall et al. (2008) ve Brentnall et al. (2010a) sırasıyla bir şube, bin hesap ve beş bin hesabın verisini incelemekte, dolayısı ile grafikte verilmemektedir.



Şekil 6. Kullanılan ATM sayısı

Şekil 6’da belirtildiği gibi, yalnızca altı tekli zaman serisi mevcutken, geri kalan yirmi dört seri çoklu zaman serisi karakteristiği göstermektedir. On bir ve otuz ATM, kısıtlanmış NN5 veri setinin parçasını oluşturmaktadır. Sadece dört çalışma NN5 veri setindeki yüz on bir serinin tamamı üzerinden tahmin yapmaktadır. Bu kısıtlama, yarışma tarafından araştırmacılara sunulan veri setleri üzerinden gerçekleşmektedir.

En küçük çoklu zaman serisi, kısıtlanmış “NN5” veri setine ait on birli zaman serisi olmaktadır. On beş ile yirmi beş ATM’nin verisini kullanan dört çalışma bulunmakta olup, beş çalışma otuz zaman serisi, beş çalışma otuz üç ve yüz ATM, beş çalışma da yüz yirmi ile bin iki yüz yirmi arasında bir veri seti kullanmaktadır. Her bir ATM için ayrı ayrı modeli çözmek yerine, ATM’leri kümelemek ve bu kümeler için modelleri çözmek bilgisayar zamanı tasarrufu ve makineler arası etkileşimin modele dâhil edilmesi açısından farklı bir yaklaşım olacaktır. Venkatesh et al. (2014) ATM’leri kümeleyen tek çalışmadır. Diğer bir deyişle, her bir ATM için aynı modeli geliştirmek yerine, araştırmacılar makineleri önce gruptandırabilir ve her bir grup için test modelleri uygulayabilirler.

KULLANILAN YÖNTEMLER

Yazın Taramasının bir diğer önemli noktasını, metotların ve çalışmalarında kullanılan öğrenme algoritmalarının incelenmesi oluşturmaktadır. Genellikle, çalışmalar aynı veri seti üzerinde değişik algoritmalar kullanmakta ve sonuçlarını karşılaştırmaktadır. Bu teknikler daha önceden de bahsedildiği üzere, yapay zekâ, istatistiksel ve hibrit çalışmalar olarak sınıflandırılabilirken, metot detaylarında çok çeşitli yaklaşımlar bulunmaktadır.

Aynı metot kullanan algoritmalar da gizli katman sayısı, girdi sayısı ve parametreler gibi farklılıklar içermektedir. Tablo 3’de, bu metot ve algoritmalar, kullanılan hata terimi, ortalama hata yüzdesi ile birlikte verilmiştir. Tabloya sığabilmesi amacı ile genellikle terimlerin kısaltmaları kullanılmış olup, okuyucuya tablonun anlaşılabilmesi için kısaltmalar bölümünü göz önünde bulundurması tavsiye edilmektedir.

Tablo 3. Yazının Metodolojik olarak İncelenmesi ve Çalışmaların Tahmin Hassasiyeti

Eser	Tahmin Tekniği	Metot Detayları	Öğrenme Algoritması ve Konfigürasyonları	Hata Terimi	Ortalama Hata
(Kumar and Walia, 2006)	AI	ANN	Gizli Katman (7-12)	MFE - haftalık	6,32%
				MFE - günlük	5,41%
(Simutis et al., 2007)	AI	3 katman ileri besleme ANN	Levensberg-Marquardt	RMS	10,00%
(Simutis et al., 2008)	AI	3 katman ileri besleme ANN	Çapraz-Geçerlilik	MAPE	0,76%
		SVR			4,10%
(Brentnall et al., 2008)	İstatiksel	Rastgele Etki nokta süreci modeli		Kolmogorov Smirnov Test	95,00%
(Zapranis and Antonis, 2009)	AI	WNN	Her ATM için farklı	SMAPE	27,92%
		ARMA			33,20%
(Brentnall et al., 2010a)	İstatiksel Noktasal Tahmin	Dirichlet ve Deneysel Dağılım		MSE	
(Brentnall et al., 2010b)	İstatistiksel Yoğunluk Tahmin	Lineer Model		Logaritmik Skor CRPS	
		AR			
		Yapısal Zaman Serisi			
(Garcia-Pedrero and Gomez-Gil, 2010)	AI	ANN	İleriye Dönük	SMAPE	12,40%
					13,00%
			RNN + WRS		8,30%
(Paul and Mukherjee, 2010)	İstatiksel	Lineer Model			
(Rodrigues and Esteves, 2010)	İstatiksel	Korelasyon Test			
(Van Anholt and Vis, 2010)	İstatiksel	Dekompozisyon	Zaman Bazlı Katsayılar	MAPE	37,79%
		(Değişken Lineer Regresyon)	Dekompozisyon		
(Wichard et al., 2010)	Hibrit	ANN	1 Gizli Katman	SMAPE	42,42%
		Paskalya Düzeltmesi			22,87%
		Durum Uzayı Yapılanması ve NTM			24,19%
		ANN	1 veya 2 Gizli Katman		25,61%
(Andrawis et al., 2011)	Hibrit	Hibrit	Ağırlıklı Ortalama	SMAPE	19,38%
		GPR-ITER			19,90%
		GPR-DIR			21,20%
		GPR-LEV			20,20%
		NN-ITER			21,10%
		NN-LEV			19,80%
		MULT-REGR			19,00%
		MOV-AVG			19,50%
(Atsalaki et al., 2011)	AI	ANN	5 girdi 7 Gizli Katman	En iyi RMSE	4,69%
				En kötü RMSE	14,60%
(Ramirez and Acuna, 2011)	AI	MLP	9 girdi	SMAPE & IA	22%
		LS-SVM	Çapraz Geçerleme		27%
		RBF	9 girdi		26%

Eser	Tahmin Tekniği	Metot Detayları	Öğrenme Algoritması ve Konfigurasyonları	Hata Terimi	Ortalama Hata		
(Teddy and Ng, 2011)	AI	PSECMAC	MCES	SMAPE	27%		
			RreliefF		29%		
			CFS		27,5%		
(Dilijonas and Sakalauskas, 2011)	AI	ANN	1 Gizli Katman	Performans Artışı	24%		
(Acuna et al., 2012)	AI	NARX-ANN	9 girdi	SMAPE & IA	20,05%		
		NARMAX-ANN	10 girdi		24,09%		
		NARX-SVM	9 girdi		25,83%		
		NARMAX-SVM	10 girdi		24%		
(Darwish, 2013)	AI	IT2FNN	4 katman	MFE	6,5%		
(Gurgul and Suder, 2013)	İstatiksel	SARIMA	Geçiş Modelleri	MAPE	16,71%		
(Wagner, 2013)	İstatiksel	SARIMA	Box-Jenkins	MAPE	19,14%		
		Vektör Zaman Serileri			20,50%		
(Arora et al., 2014)	AI	Bulanık ARTMAP NN	NMI (Parametre Seçimi)	MFE	5,10%		
(Kamini and Ravi, 2014)	AI	ARIMA	MLFF	SMAPE	27,76%		
					WNN	23,87%	
					GRNN	23,33%	
					GRNN	23,16%	
(Venkatesh et al., 2014)	AI	MLFF	Kümeleme	SMAPE	18,44%		
					GMDH	21,10%	
					WNN	20,32%	
(Catal et al., 2015)	İstatiksel	Üssel Düzleme	Özel Gün Entegrasyonu	SMAPE	20,60%		
					21,57%		
(Aseev et al., 2016)	Hibrit	AHW	Trend + Mevsimsel Etkiler	MAPE	40,45%		
					MCD	İniş Çıkışlar	51,64%
					MCW	İniş Çıkışlar	57,28%
					Hibrit	35,72%	
(Nemeshaev and Tsyganov, 2016)	AI	ANN		MAPE	32,00%		
(Khanarsa and Sinapiromsaran, 2017)	İstatiksel	MASA	SARIMA	SMAPE	19,75%		
					ETS	29,36%	
					21,15%		
(Rajwani et al., 2017)	İstatiksel	Regresyon	Lineer	MSE	5,00%		
			Ridge Lineer		3,00%		
			LASSO		3,00%		
			Bayesian Ridge		3,00%		
			AI		Reküren NN	2,80%	
LSTM	2,90%						
(Jadwal et al., 2018)	AI	ANN	1 Gizli Katman (8 nöron)	RMSE	8,50%		
		Kümeleşmiş Zaman Serileri ANN	10 kat Çapraz Geçerleme		6,58%		
(Perera and Hewage, 2018)	İstatiksel	TSA	ARMA	Sistemik Hata	1,70%		
		Regresyon	13,28%				
(Arabani and Komleh, 2019)	AI (2 gizli katman)	CNN	Çapraz Geçerleme	RMSE	9,38%		
		CNN			4,74%		
		SVM			10,35%		
		SVM			Çapraz Geçerleme	13,66%	
		ANN			7,45%		
ANN	Çapraz Geçerleme	5,01%					

Tablo 3, ATM nakit yönetimi yazınının, tahmin tekniği, metot detayları, öğrenme algoritması ve bazı yapılandırma detaylarını, hata terimi ve ortalama hata başlıkları altında incelenmesini özetler niteliktedir. Yapay Zekâ teknikleri tahmin problemine yaklaşımda en çok kullanılan teknik olmuştur, bunu istatistiksel teknikler ve hibrit yöntemler izlemiştir. Kullanılan en yaygın yapay zekâ tekniği ANN (Kumar and Walia, 2006; Simutis et al., 2007; Garcia-Pedrero and Gomez-Gil, 2010; Van Anholt and Vis, 2010) olmuştur. WNN (Zapranis and Antonis, 2009; Kamini and Ravi, 2014; Venkatesh et al., 2014) ve CNN (Arabani and Komleh, 2019) kullanılan diğer NN tipleri olmaktadır. SVM (Simutis et al., 2008; Acuna et al., 2012; Arabani and Komleh, 2019) bu problem tipinde kullanılan bir diğer alternatif model olmaktadır. Bu sebeple, bu problem türüne en uygun algoritma üzerine ortak bir görüş bulunmamakta, fakat modeller arası tahmin hassasiyetine dayalı bir rekabet bulunmaktadır.


Kullanılan istatistiksel tekniklerde de, tıpkı yapay zekâ tekniklerinde olduğu gibi, çeşitli alternatif metotlar gözlemlenmektedir. Bu istatistiksel tekniklerden popüler olanları sırasıyla SARIMA (Gurgul and Suder, 2013; Wagner, 2013; Khanarsa and Sinapiromsaran, 2017) ARIMA (Kamini and Ravi, 2014) ve Regresyon (Van Anholt and Vis, 2010; Rajwani et al., 2017; Perera and Hewage, 2018) olarak karşımıza çıkmaktadır. Kullanılan diğer yöntemleri, lineer modeller (Paul and Mukherjee, 2010), korelasyon testleri (Rodrigues and Esteves, 2010), dekompozisyon (Van Anholt and Vis, 2010), üstel düzeltme (Catal et al., 2015), MASA (Khanarsa and Sinapiromsaran, 2017) ve ARMA (Perera and Hewage, 2018) şeklinde özetlemek mümkündür.

Tek bir teknik üzerine dayanan makalelerden farklı olarak bazı çalışmalar (Van Anholt and Vis, 2010; Kamini and Ravi, 2014; Rajwani et al., 2017) hem istatistiksel hem yapay zekâ teknikleri kullanıp sonuçlarını karşılaştırmaktadır. Van Anholt and Vis (2010)'de zaman bazlı katsayılar kullanılarak modifiye edilmiş lineer regresyon modeli, ANN'ye kıyasla daha iyi sonuçlar elde etmiştir. Bildiğimiz kadarı ile bu çalışma istatistiksel bir tekniğin ANN'ye göre daha iyi bir performans gösterdiği tek çalışmadır. Kamini and Ravi (2014)'de ARIMA modeli kullanılmaktadır, bilindiği üzere bu model zaman serilerinin mevsimselliğini dikkate almamaktadır. Diğer çalışmalarda özellikle vurgulanan mevsimsellik faktörü göz önüne alındığında, bu çalışmada SARIMA modelinin kullanılması, aynı makalede karşılaştırma amacı ile kullanılan MLFF, WNN ve GRNN gibi modellere karşı daha anlamlı sonuçlara yol açacaktır.

Eş zamanlı olarak hem istatistiksel hem yapay zekâ tekniklerini kullanan hibrit yaklaşımlar (Wichard et al., 2010; Andrawis et al., 2011; Aseev et al., 2016) son kategoriye oluşturmaktadır. Wichard et al. (2010), ANN modeli ile NTM ve durum uzayı yapılanmasını birleştirmekte, tahmin başarısını yaklaşık olarak yüzde beş arttırmaktadır. Öte yandan, Andrawis et al. (2011) değişik metotların birbirleri üzerine etkisini incelemekte ve yedi alternatif kombinasyonu sonuçları ile birlikte sunmaktadır. Aseev et al. (2016) hibrit modelin AHW, MCD ve MCW gibi modellere kıyasla nasıl daha iyi bir performans verdiğini göstermektedir. ATM'lerde gerçekleşen nakit akışı probleminde bulanık mantığın kullanıldığı yalnızca iki çalışma (Darwish, 2013; Arora et al., 2014) bulunmaktadır.

Darwish (2013) ikinci tip bulanık sayıları NN yapısı ile bütünleştirmekte, Arora et al. (2014) ise NMI kullanarak en iyi parametre seçimi üzerine odaklanmakta ve bulanık ARTMAP modelini kullanmaktadır. Her bir katmanda kullanılan nöron sayısı ve gizli katman sayısı, makalelerde değişiklik göstermekte, dolayısıyla NN kullanan çalışmalarda ortak bir yapılandırmaya rastlanmamaktadır.

Kullanılan ana yöntemler ve metot özellikleri gibi modellerin başarısını ölçen hata terimleri de çeşitlilik göstermektedir. SMAPE ve MAPE yazında en yaygın kullanılan hata terimleridir. Bu hata terimlerini sırası ile RMSE (Atsalaki et al., 2011; Jadwal et al., 2018; Arabani and Komleh, 2019), MSE (Brentnall et al., 2010a; Rajwani et al., 2017) ve MFE (Kumar and Walia, 2006; Darwish, 2013; Arora et al., 2014) gibi hata terimleri takip etmektedir. Bu ortak ölçümlerden farklı olarak Brentnall et al. (2008), Kolmogorov-Smirnov testini kullanmakta, Brentnall et al. (2010b) ise ATM'leri değerlemede logaritmik puanlama yapmaktadır. Dilijonas and Sakalauskas (2011), performans artışı ölçütüne odaklanmaktadır. Kullanılan hata terimlerinin yüzdesini yansıtan grafik aşağıda verilmiştir.



Şekil 7. Kullanılan Hata Terimi

Çalışmaların neredeyse yarısının (%42) SMAPE hata terimini kullanması, hata teriminin simetrik şekilde alınmasının araştırmacılar tarafından daha çok tercih edildiğini göstermektedir. Yine de altı çalışma MAPE kullanmayı tercih etmekle, hatanın simetrik yapısını göz ardı etmiştir. RMSE %15 ile en sık kullanılan üçüncü terim olmaktadır. Bu terimi %12 ile MFE ve %8 ile MSE izlemektedir.

GİRDİ VE PARAMETRELER

Nakit yönetiminde, hangi girdi ve çıktılar kullanılacağı, hangi parametrelerin modele dâhil edilip edilmeyeceği, daimi bir tartışma konusu olmuştur. ATM'lerden para çeken müşterilerin değişkenliği veya aynı müşterilerin zaman içinde değişen para çekme ve yatırma karakteristiği sistemin karmaşıklığını arttıran başlıca unsurlardan biridir. Bu sisteme ATM'nin bulunduğu konumdan hava durumuna, o günün tatil olup olmamasından ülkenin ekonomik durumuna kadar çok fazla sayıda faktör etki etmektedir. Bu faktörlerin bazılarını ölçümlemek mümkün olurken, bazıları ise ölçülemez nitelikte kalmaktadır. Bazı faktörler ise, belirsiz olmakta ismi bile konulamamaktadır.

Yazını dikkate aldığımızda ise girdiler ve parametrelerle ilgili kesin bir ortak görüş olmamakla birlikte, bazı girdilerin birçok çalışmada ortak olarak kullanıldığı gözlemlenmektedir. Bazı girdiler ise sadece bir iki çalışmada karşımıza çıkmaktadır. Bu sınıflandırmayı yaparken, Brentnall et al.


(2008) ve Brentnall et al. (2010a) farklı bir objektife odaklandığı için kapsam dışında tutulmuştur. Brentnall et al. (2010b), birinci derece oto-korelasyon, nakit kalmayan durum, sıfır para çekme, zaman serisindeki pikler, haftanın güçlü günü ve mevsimsel etkiler gibi girdileri kullanarak ATM'leri puanlamaya çalışmaktadır. Garcia-Pedrero and Gomez-Gil (2010), Atsalaki et al. (2011) ve Khanarsa and Sinapiromsaran (2017) sistemlerinin girdilerini açıkça belirtmemektedir. Teddy and Ng (2011) kendi başına en iyi parametre seçimi ile ilgili bir algoritma uygulamaktadır. Kamini and Ravi (2014) gecikme zamanı ve gömülü boyut gibi kaotik parametreleri modele dâhil etmekte, Nemeshaev and Tsyganov (2016) günlük para çekme miktarından bahsetmekte fakat girdileri detaylandırmamaktadır. Rajwani et al. (2017) tüm para çekim detaylarını (60 parametre) modele dâhil etmektedir. Geri kalan makalelerin girdileri ise aşağıdaki tabloda listelenmiştir.

Tablo 4. Girdi Listesi

	Haftanın Günü	Yılın Ayı	Ayın Haftası	Tatiller	Özel Tarihler	Ayın Günü	Geçen Haftanın Ortalama Günlük Talebi	ATM Konumu
(Kumar and Walia, 2006)	*							
(Simutis et al., 2007)	*	*		*			*	
(Simutis et al., 2008)	*	*		*		*	*	
(Zapranis and Antonis, 2009)	*							
(Paul and Mukherjee, 2010)								*
(Rodrigues and Esteves, 2010)	*	*	*	*				
(Van Anholt and Vis, 2010)	*	*				*		
(Wichard et al., 2010)	*	*	*	*				
(Andrawis et al., 2011)	*	*	*		*	*		
(Ramirez and Acuna, 2011)	*	*	*		*	*		
(Dilijonas and Sakalauskas, 2011)	*	*				*	*	
(Acuna et al., 2012)	*	*	*		*	*		
(Darwish, 2013)		*			*		*	*
(Gurgul and Suder, 2013)					*			*
(Wagner, 2013)	*	*		*				
(Arora et al., 2014)								*
(Venkatesh et al., 2014)	*							
(Catal et al., 2015)	*	*	*		*			
(Aseev et al., 2016)	*							
(Jadwal et al., 2018)	*	*	*	*				
(Perera and Hewage, 2018)	*			*				*
(Arabani and Komleh, 2019)	*	*	*	*				

Tablo 4’de, özellikle sekiz faktörün çalışmalarda önemli bir yer tuttuğu gözlemlenmektedir. “Haftanın günü” toplamda on sekiz makalede mevcut olup, problemin en sık karşılaşılan girdisi olmaktadır. Yılın ayı (on dört), ayın haftası (sekiz) ortak olarak kullanılan diğer girdileri oluşturmaktadır. Bu faktörleri takip eden tatiller (sekiz) kategorisiyle özel günler (altı) kategorisini birleştirmek istenmediyse de, çalışmalar detaylı olarak incelendiğinde bu iki girdinin aynı makalede kullanılmadığını gözlemlenmektedir. Bu sebeple bu iki girdinin araştırmacıların sözel ifadelerini dışında herhangi bir farklılık taşımadığı düşünülmektedir. Dolayısı ile haftanın özel günleri veya tatiller en azından on dört kere makalelere girdi olarak yansımış ve yılın ayı kadar önemli bir girdiyi oluşturmaktadır.

Ayın günü, önceki haftanın ortalama günlük talebi, ATM’nin konumu, maaş günü gibi girdiler ve kullanılma sıklığı yukarıdaki tablodan incelenebilir. Ayrıca yukarıdaki tabloda, kullanılma sıklığının azlığından dolayı bahsedilmeyen girdiler de mevcuttur. Bunlara örnek olarak, çalışma günü (Kumar and Walia, 2006), tatilden önceki gün (Dilijonas and Sakalauskas, 2011), müşteri özellikleri (Paul and Mukherjee, 2010), (Arora et al., 2014) ve hava durumu (Perera and Hewage, 2018) verilebilir. Şekil 8, kullanılan girdilerin sıklığını özetler niteliktedir.



Şekil 8. Kullanılan girdilerin frekansı

Zaman serilerinin en önemli elemanları trend ve mevsimseliktir. Buna rağmen, çalışmalar incelendiğinde bu özel problem türü için en önemli elementin 7 günlük döngüsellik yapısı olduğunu on dört değişik makaleden referans verilerek kabul edilmesi gerekmektedir. Haftalık mevsimsellik ATM nakit akışı probleminin en önemli karakteristiği olurken, bu elementi aylık döngüsellik (Simutis et al., 2007; Wichard et al., 2010; Darwish, 2013; Wagner, 2013) izlemektedir. Gurgul and Suder (2013), yıllık bir döngüden bahseden tek çalışma olurken, Catal et al. (2015) ise senenin çeyreklerinin mevsimselliğini ele almaktadır. Trend faktörü yalnızca (Perera and Hewage, 2018)’deki Sri Lanka bankası probleminde ele alınırken, enflasyon düzeltme tekniği de aynı çalışmada uygulanmıştır.

Nakit akışına yönelik zaman serilerinde, sıklıkla karşılaşılan bir diğer problem türü de kayıp değerler olmaktadır. Bu kayıp değerler, veri akışı veya saklanmasıdaki problemlerden kaynaklanabileceği gibi, makinelerde meydana gelen arızalardan da ortaya çıkabilmektedir. Aynı zamanda, makine para stoku bulundurmadağı duruma geldiğinde, gösterge o günkü nakit talebini gerçekleştiren para çekmeden aldığı için “0” kabul etmekte ve bu durum gerçeği yansıtmamaktadır. Araştırmacılar bu tip problemlerin çözümü için değişik yöntemlerin kullanılmasını öne sürmüşlerdir. 2 komşunun ortalaması (Garcia-Pedrero and Gomez-Gil, 2010), medyan enterpolasyonu (Wichard et al., 2010; Kamini and Ravi, 2014), kübik enterpolasyon (Ramirez and Acuna, 2011; Acuna et al., 2012), zaman serisinin ortalaması (Catal et al., 2015; Jadwal et al., 2018) bu yaklaşımlara örnek olarak verilebilir.

SONUÇ VE İLERİ ARAŞTIRMA

Bu çalışmada, ATM nakit talebi ile ilgili yazın çalışmaları detaylıca incelenmiştir. Bu çalışmalar kronolojik sıraya göre listelenmiş, değişik perspektiflere göre sınıflandırılmıştır. Tüm bu detaylar, bu probleme değinecek araştırmacılar için bir yol haritası niteliğindedir. Girdiler tablosu, herhangi bir araştırma yapıldığında hangi faktörlerin mutlaka ele alınması gerektiğini belirtirken, aynı zamanda bu faktörlerin ele alınıp alınmaması durumunda çıkan sonuçları karşılaştırma imkânı verecektir. Girdi tablosundaki bir diğer avantaj ise çalışmalardaki birçok girdinin para çekmenin zamanına dayalı olan tarih verisinde zaten mevcut olmasıdır. Tüm bu çalışmalar okunduktan sonra, faydalı bir çalışma olması açısından, araştırmacıların en azından iki yıllık bir veri setine ve asgari on bir değişik ATM’ye ait zaman serisine ihtiyaç duyduğu düşünülmektedir. Bu asgari koşulların altında yapılan bir çalışma yazını geliştirmek açısından yetersiz kalabilecektir.

Ek olarak, kullanılan teknik ve yöntemler, yapılandırmaları ile birlikte detaylı olarak incelenmiştir. Veri setinde yaşanabilecek eksik değerler veya uç değerler durumunda kullanılabilir veri düzeltme süreci teknikleri hakkında da çeşitli alternatif yöntemler sunulmuştur. Bu alternatifler kullanılarak düzeltilen veri setlerinin performansı da bir diğer araştırma konusu olarak kalmaktadır. Henüz hiçbir makale, alternatif veri seti düzeltme tekniklerinin çalışmanın performansına etkisi üzerine bir yorum getirmemiştir.

Yazında değinilmeyen bir diğer araştırma konusu ise girdiler arasında korelasyon testinin yapılmaması ve var kabul edilen mevsimsellik periyotları için herhangi bir test uygulanmamış olmasıdır. Mevsimsellik testi, veri inceleme açısından önemli olduğu gibi, araştırmaların devamında her bir mevsimselliğe çeşitli ağırlıklar verilerek ileri seviyeye taşınabilir olarak kalmaktadır. Bu sebeple ARIMA kullanan modellerin yeterliliği veya yetersizliği, SARIMA kullanmanın gerekliliği ölçülebilir. Bahsedilen istatistiksel modeller daha anlamlı karşılaştırma ölçütleri olarak yapay zekâ modellerinden önce çözümlenebilir. Yapay zekâ uygulamasında bulunurken, değişik yapılandırmalar kullanılabilir, öğrenme oranı değiştirilebilir. Gizli katman sayısının tahmin hassasiyetine etkisini ölçümlemek de bir diğer artı değer olacaktır.

Hata terimlerinin arsında performans kıyaslaması yapılabileceği gibi, çalışmanın sonuçlarını en sık kullanılan alternatif hata terimleri ile vermek ve bu hata terimleri arasında ATM performans sıralamaları arasında farkların var olup olmadığını gözlemlemek de çalışılması gereken bir konu olarak kalmaktadır. Yapılan çalışmaların neredeyse hepsi Dolar ve Euro gibi enflasyon karşısında güçlü para birimlerini kullanmaktadır. Özellikle Türkiye’de yapılan bir çalışma için trend faktörünün önemi ve uygun enflasyon düzeltme tekniklerinin kullanılması kaçınılmaz olacaktır. Aynı zamanda yeterli ATM sayısına ulaşıldığında bu zaman serilerini kümelemeden ve kümelendirmeden çözmek ve sonuçları karşılaştırmak da önem arz etmektedir.

Aynı zamanda bu çalışma şimdiye kadar kullanılmış girdi, teknik ve yöntemleri özetlemektedir. Yazının bu kısmında uzmanlardan görüş alıp eksik bir ölçütün sisteme dâhil edilmesi veya kullanılmayan bir yöntem ile bütünleştirilmesi de araştırmacılar için çok faydalı olacaktır. Duyarlılık analizleri ve senaryo analizleri ise çalışmaları zenginleştirebilecek bir ünite olarak düşünülebilir.

KISALTMALAR

AHW	Holt-Winters Additive Model
ANN	Artificial Neural Network
ARIMA	Auto Regressive Integrated Moving Average
ARMA	Auto Regressive Moving Average
ATM	Automated Teller Machine
ATMIA	ATM Industry Association
CFS	Correlation-Based Feature Selection
CI	Computational Intelligence
CNN	Convolutional Neural Network
CRPS	Continuous Ranked Probability Score
DIR	Direct Approach
EDA	Exploratory Data Analysis
ESN	Echo State Network
ETS	Exponential Triple Smoothing Model
GDO	Gradient Descent Optimization
GMDH	Group Method or Data Handling
GPR	Gaussian Process Regression
GRNN	General Regression Neural Network
HWM	Holt-Winter Method
IA	Index of Agreement
IT2FNN	Interval Type-2 Fuzzy Neural Network
ITER	Iterative Approach
LASSO	Least Absolute Shrinkage and Selection Operator

LSTM	Long Short-Term Memory
MASA	Multiple ARIMA Subsequences Aggregate TSM
MCD	Markov Chain-Based Model per Day
MCES	Monte Carlo Evaluative Selection
MCW	Markov Chain-Based Model per Week
MFE	Mean Forecasting Error
MLFF	Multi-Layer Feed Forward
MLP	Multi-layer Perceptron
MPO	Model Predictive Output
NARMAX	Nonlinear Autoregressive Moving Average with Exogenous Inputs
NARX	Nonlinear Autoregressive Exogenous Inputs
NMI	Neighborhood Mutual Information
NN	Neural Network
NTM	Nearest Trajectory Model
OSA	One-Step-Ahead
PSECMAC	Pseudo Self-Evolving Cerebellar Model Articulation Controller
RBF	Radial Basis Function
REMM	Random Effect Multinomial Model
RMS	Root Mean Square
RNN	Recurrent Neural Network
SAM	Sequence Alignment Method
SVM	Support Vector Machine
SVR	Support Vector Regression
TSA	Time Series Analysis
TSM	Time Series Model
WNN	Wavelet Neural Network
WRS	Wavelet Reconstructed Signals
WT	Wavelet Transform

KAYNAKÇA

- Acuna, G., Ramirez, C., & Curilem, M. (2012). Comparing NARX and NARMAX models using ANN and SVM for cash demand forecasting for ATM. *IEEE 2012 International Joint Conference on Neural Networks*, 1-6.
- Andrawis, R. R., Atiya, A. F., & El-Shishiny, H. (2011). Forecast combinations of computational intelligence and linear models for the NN5 time series forecasting competition. *International Journal of Forecasting*, 27(3), 672-688.
- Arabani, S. P., & Komleh, H. E. (2019). The Improvement of Forecasting ATMs Cash Demand of Iran Banking Network Using Convolutional Neural Network. *Arabian Journal for Science and Engineering*, 44(4), 3733-3743.
- Arora, N., & Saini, J. K. R. (2014). Approximating methodology: Managing cash in automated teller machines using fuzzy ARTMAP network. *International Journal of Enhanced Research in Science Technology & Engineering*, 3(2), 318-326.
- Aseev, M., Nemeshaev, S., & Nesterov, A. (2016). Forecasting cash withdrawals in the ATM network using a combined model based on the holt-winters method and markov chains. *International Journal of Applied Engineering Research*, 11(11), 7577-7582.
- Atsalaki, I. G., Atsalakis, G. S., & Zopounidis, C.D. (2011). Cash withdrawals forecasting by neural networks. *Journal of Computational Optimization in Economics and Finance*, 3(2), 133-142.
- Brentnall, A. R., Crowder, M. J., & Hand, D. J. (2008). A statistical model for the temporal pattern of individual automated teller machine withdrawals. *Journal of the Royal Statistical Society Series C-Applied Statistics*, 57, 43-59.
- Brentnall, A. R., Crowder, M. J., & Hand, D. J. (2010a). Predicting the amount individuals withdraw at cash machines using a random effects multinomial model. *Statistical Modelling*, 10(2), 197-214.
- Brentnall, A. R., Crowder, M. J., & Hand, D. J. (2010b). Predictive-sequential forecasting system development for cash machine stocking. *International Journal of Forecasting*, 26(4), 764-776.
- Catal, C., Fenerci, A., Ozdemir, B., & Gulmez, O. (2015). Improvement of demand forecasting models with special days. *Procedia Computer Science*, 59, 262-267.
- Darwish, S.M. (2013). A Methodology to Improve Cash Demand Forecasting for ATM Network. *International Journal of Computer and Electrical Engineering*, 5(4), 405-409.
- Dilijonas, D., & Sakalauskas, V. (2011). Self-service Systems Performance Evaluation and Improvement Model. *Conference on e-Business, e-Services and e-Society*, 87-98.
- Garcia-Pedrero, A., & Gomez-Gil, P. (2010). Time series forecasting using recurrent neural networks and wavelet reconstructed signals. *IEEE 2010 20th International Conference on Electronics Communications and Computers (CONIELECOMP)*, 169-173.
- Gurgul, H., & Suder, M. (2013). Modeling of Withdrawals from Selected ATMs of the Euronet Network. *AGH Managerial Economics*, 13, 65-82.
- Jadwal, P. K., Jain, S., Gupta, U., & Khanna, P. (2017). K-Means clustering with neural networks for ATM cash repository prediction. *International Conference on Information and Communication Technology for Intelligent Systems*, 588-596.
- Kamini, V., Ravi, V., & Kumar, D. N. (2014). Chaotic time series analysis with neural networks to forecast cash demand in ATMs. *2014 IEEE International Conference on Computational Intelligence and Computing Research*, 1-5.
- Khanarsa, P., & Sinapiromsaran, K. (2017). Multiple ARIMA subsequences aggregate time series model to forecast cash in ATM. *IEEE 9th International Conference on Knowledge and Smart Technology (KST)*, 83-88.

- Kumar, P., & Walia, E. (2006). Cash Forecasting: An Application of Artificial Neural Networks in Finance. *IJCSA*, 3(1), 61-77.
- Nemeshaev, S., & Tsyganov, A. (2016). Model of the forecasting cash withdrawals in the ATM network. *Procedia Computer Science*, 88, 463-468.
- Paul, J., & Mukherjee, A. (2010). ATMs and cash demand forecasting: A study of two commercial banks. *Journal of Regional Development*, 2(2), 653-671.
- Perera, K., & Hewage, U. (2018). Determinants of Automated Teller Machine Loading Demand Requirements in Sri Lankan Cash Supply Chains. *IEEE International Conference on Production and Operations Management Society (POMS)*, 1-7.
- Rajwani, A., Syed, T., Khan, B., & Behlim, S. (2017). Regression analysis for ATM cash flow prediction. *IEEE International Conference on in Frontiers of Information Technology (FIT)*, 212-217.
- Ramírez C., & Acuña G. (2011). Forecasting Cash Demand in ATM Using Neural Networks and Least Square Support Vector Machine. In San Martin C., & Kim SW. (Eds.), *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-25085-9_61
- Rodrigues, P., & Esteves, P. (2010). Calendar effects in daily ATM withdrawals. *Economics Bulletin*, 30(4), 2587-2597.
- Simutis, R., Dilijonas, D., Bastina, L., & Friman, J. (2007). A flexible neural network for ATM cash demand forecasting. *International Conference on Computational Intelligence, Man-Machine Systems and Cybernetics*, 163-168.
- Simutis, R., Dilijonas, D., & Bastina, L. (2008). Cash demand forecasting for ATM using neural networks and support vector regression algorithms. *Euro Mini Conference Continuous Optimization and Knowledge-Based Technologies*, 416-421.
- Teddy, S. D., & Ng, S. K. (2011). Forecasting ATM cash demands using a local learning model of cerebellar associative memory network. *International Journal of Forecasting*, 27(3), 760-776
- Van Anholt, R. G., & Vis, I. F. (2010). An integrative online ATM forecasting and replenishment model with a target fill rate. *Proceedings of The International Conference on Logistics and Maritime Systems*, 1-10.
- Venkatesh, K., Ravi, V., Prinzie, A., & Van Den Poel, D. (2014). Cash demand forecasting in ATMs by clustering and neural networks. *European Journal of Operational Research*, 232(2), 383-392.
- Wagner, M. (2010). Forecasting daily demand in cash supply chains. *American Journal of Economics and Business Administration*, 2(4), 377-383.
- Wichard, J. D. (2011). Forecasting the NN5 time series with hybrid models. *International Journal of Forecasting*, 27(3), 700-707.
- Zapranis, A., & Alexandridis, A. (2009). Forecasting cash money withdrawals using wavelet analysis and wavelet neural networks. *International Journal of Financial Economics and Econometrics*. ISSN 0975-2072.