

Farklı Makine Öğrenmesi Yöntemleri ile ATM Para Çekim Miktarı Tahmini

ATM Cash Stock Prediction Using Different Machine Learning Approaches

D. Ece Gökçay, Furkan Coşkun, Berrin Yanıkoğlu
Veri Analitiği Araştırma ve Uygulama Merkezi
Sabancı Üniversitesi
İstanbul, Türkiye 34956
{egokcay,furkancoskun,berrin}@sabanciuniv.edu

Ali Turan, Serkan Ertem
IBTech Uluslararası Bilişim ve İletişim Teknolojileri
Gebze, Kocaeli, Türkiye 41470
{ali.turan,serkan.ertem}@ibtech.com.tr

Özetçe —ATM nakit tahmini, banka sistemlerindeki en yaygın problemlerden biridir. ATM’de yeterli nakit bulunmaması, müşteri memnuniyetini azaltırken, gereğinden fazla para olması ise bankanın kar payını negatif etkiler. Bu çalışmada ATM’lerden çekilen para miktarını tahmin eden bir sistem geliştirilmiştir. Tahmin aşamasında yapay sinir ağları, doğrusal regresyon, destek vektör makinesi, derin öğrenme ve istatistiksel analiz (ARIMA) methodları kullanılmış; ve makine öğrenmesi methodlarının, istatistiksel methodlara göre çok daha iyi performans sergilediği gösterilmiştir. Ayrıca makine öğrenmesi methodları içerisinde de LSTM modelinin çok daha az öz nitelik kullanarak daha başarılı tahminler yaptığı belirlenmiştir.

Anahtar Kelimeler—ATM Nakit Tahmini, Regresyon, Makine Öğrenmesi, LSTM

Abstract—One of the most common problems related to banking systems is the Automated Teller Machine (ATM) cash demand forecasting. Cash shortage adversely affects customer satisfaction, while too much cash reduces bank’s profitability. We have developed an ATM cash prediction system using different statistical and machine learning approaches, including linear regression, artificial neural networks, support vector machines, LSTMs and statistical analysis (ARIMA). We compare the results of these methods and show that machine learning methods in comparison with ARIMA have higher accuracy. Also it was shown that among the machine learning model LSTM gives the most accurate predictions and use less features compared to other models.

Keywords—ATM stock prediction, LSTM, regression, machine learning

I. GİRİŞ

ATM’ler bankalar ve müşteriler arasındaki etkili etkileşim ve iletişim noktalarıdır. Bankalar ATM’lerde fiziksel nakit depolayarak müşterilerin 7 gün 24 saat boyunca, bu bankada hesabı olup olmasına bakılmaksızın müşterilere hizmet sağlarlar. Türkiye Bankalar Birliği tarafından yapılan araştırmalara göre, 2018 yılında Türkiye çapında ATM sayısı 46,344’idir.

978-1-7281-7206-4/20/\$31.00 ©2020 IEEE

ATM’de yeterli nakit bulunmaması, bankanın popülerliğine zarar vererek müşteri memnuniyetini azaltırken gereğinden fazla para olması ise, paranın kullanılabilirliğini azalttığından ötürü bankanın kâr payını negatif etkileyecektir. Etkili para birimi yönetimi ve kontrolü, para arzını ve talebini doğru bir şekilde tahmin etmek için gelişmiş algoritmalar ile bankaların talebi tahmin etmelerini ve ağları boyunca para birimini proaktif olarak yönetmelerini sağlar. Birçok banka ATM’lerinde genellikle gerekenden %40 kadar daha fazla nakit para tutarken, uzmanlar bu nakit fazlalığının %15 ila %20 oranının yeterli olduğunu belirtmişlerdir [3].

ATM’ler üzerine Türkiye’de ve uluslararası, gerçek banka verisi ile geliştirilen birçok benzer yayın bulunmuştur. Bunlar temel olarak günlük ATM’lerden çekilen nakit miktarı ve nakit güncellemesi olarak 2’ye ayrılmaktadır. Bizim çalışmamız günlük olarak çekilen nakit miktarı tahmini üzerine yapılmıştır ve maalesef bu konuda az sayıda benzer çalışma vardır. Çalışmamıza benzer yayınlar incelenmiştir. [2]–[5].

Ekinci ve diğerlerinin çalışmasında ATM’lerin lokasyon bilgilerini kullanarak kümeleme işlemi gerçekleştirmiş ve bu kümeleme bilgilerini tahmin işleminde kullanmıştır. Çalışmalarında %22.69 Ortalama Mutlak Hata Oranı (OMHO) elde edilmiştir. [2]. Bilir ve Döşeyen’in kapsamlı çalışmasında, bir bankanın pek çok ATM’sinin veri seti üzerinde %26.44 Ortalama Mutlak Hata Oranı (OMHO) elde edilmiştir. [3]. Serengil ve Özpınar ise ATM nakit tahmini ve optimizasyonu ile, 41 ATM’lik bir veri üzerinde, optimizasyon ile nakit giderlerini %30 indirdiklerini bildirmişlerdir. [4]. Sarveswararao ve Ravi’nin çalışmasında ise Hindistan’da bulunan ATM’ler üzerinde 9 farklı method denemiş ve aralarında en başarılı rastgele tahmin ile oluşturulan model olmuştur. [5].

Bu çalışmada özel bir banka verileri kullanılarak ATM nakit tahmini yapan bir sistem gerçekleştirilmiştir. Yukarıdaki çalışmalardan en önemli farkı ise veriseti içerisindeki fiziksel sorunlardan kaynaklı oluşan hata girdiler gözardı edilmemiştir. Bunun sebebi ise sistemin olabildiğince gerçek durumlardaki tepkilerini ölçmektir. Değerlendirme kriteri olarak Ortalama Mutlak Hata (OMH) kriterinin kullanıldığı deneylerde, makine öğrenmesi yöntemlerinin istatistiksel yöntemleri geçtiği

gözlenmiştir.

II. GELİŞTİRİLEN SİSTEM

Çalışmamızda günlük ATM'den çekilen nakit miktarını tahmin etmek için farklı regresyon modelleri geliştirilmiştir. Bu modelleri detaylı anlatmadan önce, sistemimizde kullandığımız veri setinin anlatılması daha iyi olacaktır.

A. Veri seti

Veriseti olarak özel bir bankanın farklı 2 ATM'sinin 2 senelik verileri kullanılmıştır. Veri seti içerisinde gün bazında para çekme miktarının yanı sıra, o güne ait bilgiler de bulunmaktadır. Örneğin; o günün haftanın hangi günü olduğu, tatil olarak sayılıp sayılmadığı, hangi iş gününe karşılık geldiği bilgileri veri seti içinde mevcuttur.

Bu veriseti üzerindeki verilen bilgiler kullanılarak yeni öznitelikler oluşturulmuş, böylece modeller için kullanılacak yeni ve verimli farklı öznitelikler eklenmiştir. Yeni eklenen öznitelikler şunlardır:

- 1, 2, 3 ve 4 hafta önceki haftanın aynı gününde çekilen nakit miktarı;
- bir önceki ayın en benzer günündeki çekilen nakit miktarı;
- bir önceki ayda ortalama çekilen nakit miktarı;
- ayın ilk, orta veya son iş gününde olup olmadığının bilgisi.

Bu özniteliklerin bazıları kukla (dummy) olarak, bazıları (örn. haftanın günleri) sıralı bir değişken olarak gösterilmiştir. Yeni öznitelikler arasında, geçen ayın en benzer gününün seçilmesi kayan tatillere karşı gürbüzlük sağlamak için gereklidir. Bu şekilde örneğin bakılan gün ayın ikisi ve o ayın ilk iş günü olsun; o zaman en benzer gün olarak geçen ayın birinci iş günü kullanılmıştır.

Bu veri seti üzerinde 13. ve 14. aylara ait kayıtlar doğrulama kümesi olarak ayrılmıştır. Bu veriler kullanılarak modellerimiz için en uygun parametreler seçilmiştir.

B. Regresyon Modelleri


Çalışmamızdaki amacımız, ATM'lerden çekilen nakit miktarını gerçek miktarına en yakın şekilde tahmin etmek olduğundan, problem bir regresyon problemi olarak ele alınmıştır. Bu amaçla lineer regresyon, Destekçi Vektör Makinesi (DVM), Yapay Sinir Ağları (YSA) ve Uzun Kısa-Dönem Hafıza (LSTM) modelleri değerlendirilmiştir.

DVM yönteminde en iyi performansa lineer çekirdek, 0.5 epsilon değeri, 0.0001 gamma değeri ile ulaştık.

YSA yönteminde ise en iyi performansı için olması gereken parametre değerlerini doğrulama setimiz üzerinde kafes araması kullanarak inceledik ve en iyi sonucu tanh aktivasyon fonksiyonu, 0.01 alpha değeri, 34 hücreden oluşan 1 adet gizli katman, 0.0001 başlangıç öğrenme oranı ile elde edildiğini gördük.

Son olarak LSTM ile tek gizli katmanlı ve 2 gizli katmanlı olmak üzere 2 farklı derin öğrenme modeli oluşturduk. Şekil

1'de farklı parametreler kullanılarak oluşturulan bir adet gizli LSTM katmanı bulunan modellerin zamana bağlı olarak OMH değeri değişimi gösterilmiştir. Yaptığımız çalışmalar sonucu, gizli katmanında 8 adet nöron ile oluşturulan 2 LSTM modelimizin de en iyi performansı gösterdiği belirlenmiştir. Modeller aşırı uyumun başladığı 10. devire kadar eğitilmiştir.



Şekil 1: Uzun Kısa Süreli Bellek Ağlarında eğitim ve test kümeleri için Ortalama Mutlak Hatanın (OMH) zamana göre değişimi.

III. MODELLERİN DEĞERLENDİRİLMESİ

Zaman serileri tahmininde, makine öğrenmesinde performans değerlendirmesi için genelde kullanılan çapraz geçişleme metodu kullanılamaz, çünkü gelecekteki bilgi sızması ve hep geleceğe yönelik tahminlerin yapılması gerekir.

Bu sebeple, mevcut veri setinde 13. ve 14. aylar doğrulama kümesi olarak ayrılıp, parametre optimizasyonu gerçekleştirildikten sonra, modellerimiz *kayan* eğitim kümeleri ile eğitilmiş ve hep bir sonraki ay tahmin edilmiştir. Bu şekilde ilk eğitim 1-14. aylar ve test kümesi 15. ay olarak seçilmiş, sonrasında 1-15. aylar eğitim ve 16. ay test olacak şekilde modellerin değerlendirilmesine devam edilmiştir. Dikkat edilmelidir ki gerçek problemde veriyi en iyi kullanan değerlendirme yöntemi bu olsa da, her test değerlendirmesi için kullanılan eğitim kümesi gitgide büyümektedir; örneğin son test için 1-23. aylar eğitim, 24. ay test için kullanılmıştır.

Bu şekilde her test seti gelecekteki 1 aylık süreden ibaret olmuş, en sonunda bu şekilde değerlendirilen her biri birer aylık 10 test setinin ortalaması (15-24. aylar), test seti hatası olarak değerlendirilmiştir.

Değerlendirme için Ortalama Mutlak Hata (OMH) metriği kullanılmıştır. Bu problemde ayrıca Ortalama Mutlak Hata Oranı (OMHO) metriği de kullanılmakta, ancak bu durumda fiziksel arızalardan ötürü para çekimlerinin sıfır olduğu durumlar sorun oluşturmaktadır.

Modellerimizin başarıları değerlendirilirken 6 farklı öznitelik kümesi oluşturulmuş ve bu öznitelik kümelerinin modellerin başarıya etkisi incelenmiştir. Öznitelik setleri olarak;

- F0: Veriye ait olan günün bir hafta öncesindeki aynı günde çekilen para miktarı;

Öznitelik Seti	ORTALAMA MUTLAK DEĞER Eğitim Seti/Test Seti		
	LR	DVM	YSA
F0	18,780/18,008	18,638/17,997	19,171/18,256
F1	16,417/15,995	16,814/16,195	16,784/17,031
F2	15,220/15,786	15,680/15,999	15,840/17,285
F3	14,796/16,263	15,286/16,035	15,437/20,399
F4	15,172/15,789	15,559/15,971	15,785/18,076
F5	14,786/16,242	15,189/16,053	15,328/21,119
	LSTM		
	Tek Katmanlı		Çift Katmanlı
F6	15,063/13,755		14,972/ 13,824

TABLO I: Farklı Öznitelik Setleri Kullanılarak Oluşturulan Regresyon Modellerinin OMH Değerleri. Her modelin en iyi sonucu koyu olarak gösterilmiştir.

- F1: Verinin haftanın hangi gününe ait olduğu, bu günün tatil olup olmadığı, bu günden 1 hafta öncesindeki çekilen para miktarı, bu güne 1 önceki ay en benzer günde çekilen para miktarı ve bir önceki ayın ortalama çekilen para miktarı;
- F2: F1 setine ilave olarak, verinin ait olduğu günün ayın 11. iş günü olup olmadığı, o güne ait bulunduğu şehirde ve ilçedeki maaş yatırılma miktarı;
- F3: F2 setine ek olarak, verinin hangi aya ait olduğu ve ayın ilk veya son iş günü olup olmadığı bilgileri;
- F4: F2 setine ilaveten, bu verinin ait olduğu günden 2,3 ve 4 hafta öncesinin aynı günündeki çekilen para miktarı;
- F5: F3 ve F4 setlerinin birleşimi;
- F6: Bu verinin ait olduğu günden geriye dönük 30 günlük para çekim miktarı, bu günün tatil olup olmadığı ve hangi gün olduğu seçilen öznitelikler olmuştur. Bu öznitelik seti sadece LSTM modeli üzerinde kullanılmıştır.


Bu öznitelik setleri kullanılarak oluşturduğumuz regresyon modelleri test edilmiştir.

Tablo 1’de farklı öznitelik setleri kullanılarak eğitilen makine öğrenmesi modellerinin test verileri üzerindeki OMH değerleri verilmiştir. Tablodaki değerlerin de gösterdiği üzere farklı modeller farklı öznitelik setleri ile en iyi tahminleri yapabilmişlerdir. Yapay sinir ağı modeli en başarılı performansını F1 öznitelik kümesi kullanılarak eğitildiğinde verirken, Lineer Regresyon ve Destekçi Vektör Makinesi modelleri F2 ve F4 öznitelik seti ile eğitildiğinde vermiştir. Bir diğer önemli çıkarım olarak LSTM modelinin çok daha az öznitelik kullanıldığı halde diğer modellere oranla daha başarılı tahminlerde bulunduğu görülmüştür.

Makine öğrenmesi modellerinin istatistiksel modellerden daha başarılı olacağı hipotezimizi test etmek amacıyla bir adet en yaygın olarak kullanılan istatistiksel model olan ARIMA modeli oluşturulmuştur. Doğrulama seti üzerinde yaptığımız kafe araması sonucunda, ARIMA modelinin en iyi performansa 8 adet gecikmeli değer kullanıldığında ulaştığı saptanmıştır.

Şekil 2’de lineer regresyon, destekçi vektör makinesi, yapay sinir ağı, LSTM ve ARIMA yöntemleri kullanılarak

oluşturulan regresyon modellerinin, en iyi tahminleri gerçekleştirdiği durumlardaki (öznitelik kümesi ve en iyi değeri veren parametrelerle) eğitim ve test veriseti üzerindeki OMH değerleri gösterilmiştir. Buradan da görüleceği gibi en iyi sonucu 1 gizli katmanlı LSTM ağı 13,755 hata ile vermiştir. Bu sonuç, bu veri seti için %20.2 ortalama mutlak hata oranına denk gelmektedir, ki uzmanların yeterli gördüğü orana yeterince yakındır ve literatürde bahsi geçen çalışmalardan daha başarılı olduğu görülmüştür.



Şekil 2: Regresyon Modellerinin parametre ve öznitelik setleri ile aldığı sonuçlar.

IV. SONUÇ

Bu çalışmamızda ATM’den geçmişte çekilen nakit miktarlarını göz önüne alarak, günlük ATM’den çekilecek para miktarını en az hata oranı olacak şekilde tahmin edilmesi amaçlanmıştır. Bu amaçla lineer regresyon, destekçi vektör makinesi, yapay sinir ağı, LSTM ve ARIMA algoritmaları kullanılarak 6 farklı model oluşturulmuş ve bu modellerin birbirleri ile hata oranları kıyaslanmıştır. Modeller eğitilirken farklı öznitelik setlerinin modeller üzerindeki etkisi de incelenmiş ve modellerin en iyi performanslarını farklı öznitelik kümeleri üzerinde verdiği görülmüştür. Ayrıca deney öncesi verisetinde bulunan fiziksel sorunlardan kaynaklı olan girdiler elenmemiş, böylece daha gerçekçi bir veriseti üzerine sistemimiz kurulmuştur. Deney sonuçları, LSTM ünitelerinin uzun süreli etkileşimleri yakalama ve Tekrarlayan Sinir Ağlarında (RNN) iyileşme kabiliyetine sahip olmalarından dolayı LSTM ağının en iyi sonuçlara sahip olduğunu göstermiştir. Ayrıca oluşturulan diğer makine öğrenmesi modelleri de ARIMA modeline göre çok daha iyi sonuçlar vermiştir ki bu da makine öğrenmesi modellerinin istatistiksel modellerden çok daha başarılı tahminler yapacağı hipotezimizi doğrulamaktadır.

KAYNAKLAR

- [1] Chatfield, C. “The Analysis of Time Series An Introduction”, Fifth Edition, 1996.
- [2] Ekinci, Y., Lu, J.-C., ve Duman, E., “Optimization of ATM Cash Replenishment with Group-demand Forecasts” Expert Systems with Applications 42 (7), 3480-3490, 2015.

- [3] Bilir, C. ve Döşeyen, A., "Optimization of ATM and Branch Cash Operations Using An Integrated Cash Requirement Forecasting and Cash Optimization Model", Business & Management Studies: An International Journal, Vol IV, 237-255,2018.
- [4] Serengil, Ş. ve Özpınar, A., "ATM Cash Flow Prediction and Replenishment Optimization with ANN", Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, Vol 11 (1), 402-408,2019.
- [5] Sarveswararao,V., Ravi, V., "ATM Cash demand forecasting in an Indian Bank with chaos and deep learning", ,2020.