

ATM NAKİT İKMAL OPTİMİZASYONUNDA ASİMETRİK DESTEK VEKTÖR REGRESYON TAHMİN MODELİ YAKLAŞIMI

¹Özge TUĞRUL SÖNMEZ, ²C. Erhan BOZDAĞ

¹Ziraat Teknoloji, Yıldız Teknik Üniversitesi Davutpaşa Kampüsü, Teknoloji Geliştirme Bölgesi C2 Blok 34220
Esenler İstanbul

²İstanbul Teknik Üniversitesi, İşletme Fakültesi, Endüstri Mühendisliği Bölümü, 34367, Maçka İstanbul

¹oz_tug@yahoo.com.tr, ²bozdagc@itu.edu.tr

(Geliş/Received: 28.11.2015; Kabul/Accepted in Revised Form: 04.03.2016)

ÖZ: Bankacılık ve finans sektöründe ATM nakit ikmal problemi oldukça önemlidir. Bu problemin çözümü için en düşük tahmin hata oranını veren tahmin modelinin seçilmesinin yanı sıra minimum ikmal maliyetlerini veren optimizasyon modelinin bulunması da büyük bir öneme sahiptir. Bu çalışmada, yeni bir asimetrik tahmin modeli ve bu model ile entegre olarak çalışan, bir başka deyişle, tahmin ve optimizasyondan oluşan, iki aşamalı süreci tek bir aşamaya indiren ve nakit ikmal maliyetlerini minimize eden bir optimizasyon modeli önerilmiştir. Aynı zamanda diğer tahmin modelleri ile maliyet performans karşılaştırılması gerçekleştirilmiştir.

Anahtar Kelimeler: ATM Nakit Tahmini, Nakit Optimizasyonu, Destek Vektör Regresyon, Asimetrik Destek Vektör Regresyon

Asymmetric Support Vector Regression Approach in ATM Cash Replenishment Optimization

ABSTRACT: ATM cash replenishment problem is quite important in banking and finance sector. As well as choosing the forecast model giving the smallest forecast error ratio for the solution of this problem, finding the optimization model giving the minimum replenishment costs has importance. In this study, a new asymmetrical forecast model and an optimization model running integrated with the forecast model, in other words, an optimization model which reduces the two stage forecast and optimization process to a single step is proposed. At the same time, a comparison of costs with the other forecast models is performed.

Key Words: ATM Cash Forecast, Cash Optimization, Support Vector Regression, Asymmetric Support Vector Regression

GİRİŞ (INTRODUCTION)

Tahmin değerlerinin üretilmesi birçok sektör için önem teşkil etmektedir. Tahmin değerlerinin yüksek performans göstermesi ise perakende, enerji, finans gibi alanlarda verilebilecek operasyonel kararlar için sağlam bir girdi oluşturmaktadır. ATM nakit tahmini de bunlardan bir tanesidir. ATM nakit tahmini veya yönetimi ile ilgili bugüne kadar yapılmış pek çok çalışma bulunmaktadır. Bu çalışmaların bir kısmında en küçük hata oranını veren tahmin modeli bulunmaya çalışılmıştır (Andrawis ve diğ., 2011; Wichard, 2011; Taieb ve diğ., 2012). 2008 yılında 111 adet ATM'nin günlük zaman serileri için NN5 yapay zekâ tahmin yarışması düzenlenmiş ve bu yarışmada kullanılan tahmin

yöntemleri ile ilgili birçok makale yayınlanmıştır. Örneğin; NN5 günlük zaman serileri verileri için, çeşitli yapay sinir ağları yöntemleri kümeleme yöntemiyle birlikte kullanılıp; haftanın günlerinin etkisi ayrıştırılarak bir tahmin modeli geliştirilmiş ve diğer modellerin SMAPE (simetrik ortalama mutlak yüzde hata) değerleri ile karşılaştırılmıştır (Venkatesh ve diğ., 2014). Andrawis ve diğ. (2011) dokuz farklı tahmin modeli seçmiş ve bu modellerin kombinasyonu ile NN5 zaman serisi verilerini tahmin edip, SMAPE değerlerini bulmuştur. Teddy ve Ng (2011) NN5 verilerini kullanarak yeni bir yerel öğrenme modeli geliştirip, mevcut regresyon modelleri ile hata oranlarını karşılaştırmıştır. Wichard (2011) yedi günlük periyotlar için yapay sinir ağları ve en yakın yörünge modelini birlikte kullanan melez bir yöntem ile NN5 zaman serisi için tahmin değerleri üretip, performans ölçümü için SMAPE değerlerini kullanmıştır. Simutis ve diğ. (2008) esnek bir yapay sinir ağları yöntemi ve DVR (destek vektör regresyon) modelini kullanarak 15 gerçek ATM günlük nakit değerleri için tahminlerin ortalama mutlak hata değerlerini karşılaştıran bir çalışma yapmıştır.

Nakit tahminin doğruluğunun önemli olması kadar, tahminlerin müşteri taleplerini karşılayabilecek ve aynı zamanda ATM'lerde gereğinden çok atıl para bulundurmuyacak şekilde olması da gerekmektedir. Bu yüzden tahmine dayalı uygun bir nakit ikmal politikası da geliştirilmelidir. ATM nakit yönetimi ile ilgili yayınlanan ve nakit ikmalini de göz önünde bulunduran diğer bir grup çalışmada ise kullanılan hazır bir tahmin yöntemiyle ya da tarihsel veriye dayalı dağılım fonksiyonları kullanılarak minimum maliyeti veren nakit yükleme politikası bulunmaya çalışılmıştır. Castro (2009) belirli bir zaman aralığında ATM'lere yüklenecek nakit miktarını nakit talebinin deneysel olasılık dağılımlarını kullanarak bulan bir stokastik programlama yaklaşımı geliştirmiştir. Ancak bu modelde müşteri memnuniyetsizliği veya elde bulundurmama ceza katsayısı göz önünde bulundurmamaktadır. Darwish (2013) bulanık mantığa dayalı ortalama günlük nakit stokunu minimize eden bir metot geliştirmiştir; ancak bu çalışmada da nakit yükleme maliyetleri göz önünde bulundurulmamıştır. Buna benzer bir çalışmada da genetik algoritma yaklaşımı kullanılarak artık nakit stoku minimize edilmeye çalışılırken bir yandan da hizmet garantisi verilmeye çalışılmıştır (Armenise ve diğ., 2010). Bu yöntemle elde edilen maliyetler insan kararına dayanan yükleme maliyetleri ile karşılaştırılmıştır. Nakit yükleme maliyetlerinin optimizasyonu ile ilgili bir diğer çalışmada ise nakit ikmal maliyetlerini düşürmek için ATM'ler gruplandırılarak toplam günlük çekilen nakit miktarları tahmin modelinde girdi olarak kullanılıp; tahmin değerleri para çekilme oranları doğrultusunda ATM'lere paylaştırılmıştır (Ekinci ve diğ., 2015). Brentnall ve diğ. (2010) Birleşik Krallık'ta bulunan 190 ATM için envanter kontrol maliyetini düşürmede daha etkin olduğu gerekçesiyle, hata oranlarının diğer tahmin modellerine göre daha büyük çıkmasına rağmen nakit talebini ATM'nin servis dışı olma etkisinden ayırabilen Markov geçiş modelini önermişlerdir.

Literatürden anlaşıldığı gibi tahmin modelleri için nakit ikmal maliyetlerinin hesaplanarak karşılaştırıldığı veya standart tahmin modellerinden elde edilen tahminler ile nakit ikmal politikasında değişiklik yapılarak maliyetlerin düşürüldüğü çalışmalar bulunmaktadır. Ancak, doğrudan ATM nakit yönetim maliyetlerini minimize eden bir tahmin modeli oluşturulmamış veya nakit optimizasyon modeli ile tahmin modeli entegre bir şekilde tasarlanmamıştır. Ek olarak; nakit elde bulundurma ve bulundurmama maliyetlerini göz önünde bulundurarak negatif ve pozitif tahmin hatalarının ayrıştırıldığı ve model parametrelerinin minimum maliyeti verecek şekilde optimize edildiği bir model önerilmemiştir. Bu çalışma ile tahmin ve optimizasyon olmak üzere iki aşamadan oluşan ATM nakit yönetimi süreci tek bir aşamaya indirilmiştir. Bununla beraber, gerçek ATM günlük nakit talep tahmin hatalarının yüksekliği (daha önceki çalışmalarda ortalama mutlak yüzde hataların %20 ile %45 arasında değiştiği görülmüştür (Ekinci ve diğ., 2015)) ve farklı periyotlar için tahmin modellerinin kayıp fonksiyonlarında farklı derecede ve farklı yöne sahip asimetrisinin bulunması (Wang ve Lee, 2014) yeni bir nakit ikmal stratejisi üretilmesi ihtiyacını doğurmaktadır. Bu çalışmadaki amaç ATM'lerde elde bulundurma, elde bulundurmama ve para yükleme maliyetleri göz önünde bulundurulurken, asimetrik tahmin modeli ile entegre bir optimizasyon modeli oluşturmaktır. Bu doğrultuda oluşturulan modelin performansını test etmek amacıyla Türkiye'deki en büyük bankalardan birinin İstanbul'daki 28 adet ATM'sine ait veriler kullanılmıştır.

VERİ VE YÖNTEM (DATA AND METHOD)

Veri (Data)

Günlük ATM nakit tahmini için geçmiş günlük çekilen nakit miktarları bağımlı değişkendir. Günlük çekilen nakit miktarlarının 7, 28 ve 364 gün önceki çekilen değerleri, üretilen tahmin değerlerinden 3 ay öncesine kadar ATM'den en az iki defa para çekmiş olan müşterilerin hesaplarına yatan düzenli maaş miktarları, resmi tatil günleri, bayram günleri, maaş ödeme tarihleri bağımsız değişkenler olarak alınmıştır. 884 günlük verinin 1. gününden 772. gününe kadar olan kısmı eğitim verisi, 773. gününden 828. gününe kadar olan 56 günlük kısmı validasyon verisi ve son 56 günü (829. günden 884. güne kadar) test verisi olarak kullanılmıştır. Nakit çekme verilerinin olmadığı günlerin doldurulması amacıyla Wichard (2011) 364 gün önceki ve sonraki ve 6 gün önceki ve sonraki değerlerin medyanını kullanmıştır. Bu çalışmada da, sıfırdan farklı değerler olmak üzere 364 gün önceki ve sonraki, 4 hafta önceki ve sonraki, 7 gün önceki ve sonraki çekilen nakit değerlerinin medyanı ile boşluklar doldurulmuştur.

Yöntem (Method)

Tahmin Yöntemleri (Forecast Methods)

Tahmin yöntemleri olarak üstel düzeltme, ARIMA, regresyon, yapay sinir ağları, DVR, en küçük ortalama kareler, çok değişkenli uyarlanabilir regresyon uzanımları (MARS) gibi yöntemler bulunmaktadır. Bu yöntemlerden DVR modeli istatistiksel öğrenme teorisine dayanan bir yapay zekâ tahminleme aracıdır (Vapnik, 2000; Lu, 2014). Destek vektör makinelerinin sıradan regresyon modellerinden ve öğrenen modellerden daha iyi tahmin sonuçları elde ettiği gösterilmiştir (Erdal, 2011). DVR'nin gürültü terimine karşı sağlam olduğu ve dışa düşenlerin (outlier) destek vektör olarak kullanılabilirdiği gösterilmiştir (Hsiao ve diğ., 2011).

Vapnik'in (1999) ε (epsilon) duyarlı destek vektör regresyon kayıp fonksiyonu:

$$y_i - \varepsilon - \xi^- \leq t_i \leq y_i + \varepsilon + \xi^+ \quad (1)$$

$$L_{\varepsilon SVR}(t_i, y_i) = \begin{cases} 0 & \text{eğer } |t_i - y_i| \leq \varepsilon \\ |t_i - y_i| - \varepsilon & \text{eğer } |t_i - y_i| \geq \varepsilon \end{cases} \quad (2)$$

Modelin karmaşıklığını ifade eden yapısal risk w ve $\xi^+ \geq 0$, $\xi^- \geq 0 \forall i$ kısıtlarına bağlı olarak minimize edilecek amaç fonksiyonu:

$$C \sum_{i=1}^L (\xi_i^+ + \xi_i^-) + \frac{1}{2} \|w\|^2 = C \sum_{i=1}^L L_{\varepsilon SVR}(t_i, y_i) + \frac{1}{2} \|w\|^2 \quad (3)$$

Burada, t gerçek değer ve y tahmin değeri olmak üzere; ε - tüpünün dışına çıkan veri noktaları destek vektör olarak kabul edilmektedir. Bu tüpün altında veya üstünde kalan noktalar için simetrik olacak şekilde aynı C ceza katsayısı uygulanmaktadır.

Literatürde DVR modelinin farklı uyarlamaları mevcuttur. Ormándi'nin (2008) en küçük kareler DVR modeli kayıp fonksiyonu negatif ve pozitif hata ayırımı yapmadan hataların varyansını içermektedir. Mei ve Zhang'ın (2008) önerdiği yeni destek vektör regresyonda ε tüpünün altında ve üstünde kalan tahmin hatalarının sayısı, negatif ve pozitif hataların karelerinin toplamı ağırlık katsayısı üretmek için kullanılmıştır ve çalışmada negatif ve pozitif hatalar için aynı katsayılar verilmiştir. Huang ve diğ. (2014) yeni bir asimetrik v-tüpü DVR modeli önermiştir. Bu modeldeki asimetri parametresini (negatif ve pozitif hatalar için farklı olacak şekilde) ε -tüpünün altında ve üstünde kalan hataların katsayısı olarak kullanmışlardır. Stockman ve diğ. (2011) asimetrik ve alttan sınırlı DVR modelini önermişlerdir. Bu modelde ε -tüpünün üstünde ve altında kalan noktalar için farklı ceza katsayıları uygulanmıştır. Stockman ve diğ. (2012) ayrıca asimetrik ve ikinci dereceden bir DVR modeli önermiş; bu

modelde de ε tüpünün üzerinde kalan noktalar Vapnik'in (1999) modelindeki gibi kullanılmış; tüpün altında kalan tahmin hatalarının karesi alınarak farklı bir ceza katsayısıyla çarpılmıştır. Li ve diğ. (2014) önerdiği uyarlamalı ağırlıklı DVR modelinde ise birinci aşamada Vapnik'in (1999) ε -DVR modeli uygulanmış; ikinci aşamada ise kayıp öğrenme çözümleri ile her nokta için yeni ağırlıklar kullanılmıştır. Ancak, birinci fazdaki ağırlıkların ikinci fazda geçerli olmayabileceği belirtilmiştir. Huang ve Shen (2008) destek vektör regresyonda daha sistematik bir algoritma ile daha yüksek bir doğruluk elde etmişlerdir. Liu ve diğ. (2013) farklı olasılıklı destek vektör yaklaşımları için farklı tahmin aralıkları elde etmişlerdir. Zhang and Qi (2009) destek vektör regresyona dayanan hata düzeltmeli Markov zincirini ısıtma yükü aralığı tahmini için kullanmışlardır. Pozitif ve negatif tahmin hataları ve DVR nokta tahminlerini kullanarak tahmin aralığı ve olasılıklarını üretmişlerdir. Bu yöntemin dezavantajı bağıl hataların büyük olduğu durumda test verisi için tahmin aralığının dışında çıkabilmesidir.

Önerilen Asimetrik Hata Varyansını Minimize Eden DVR Yöntemi (Proposed Error Variance Minimizing Support Vector Regression Method)

Gerçek ATM'ler için günlük çekilen nakit miktarları oldukça büyük değişkenlik göstermekte ve nakit elde bulundurma ile bulundurmama önem düzeyleri farklılık göstermektedir. Literatürde hem pozitif ve negatif tahmin hatalarının büyüklüğünü, hem de bu hataların kendi içerisindeki değişkenliğini minimize etmeye çalışan bir model bulunmamaktadır. Bu nedenle yeni bir DVR kayıp fonksiyonu üretilmiştir:

t_i : i. günde çekilen gerçek nakit miktarı

y_i : i. gün için tahmin edilen nakit miktarı

L : Tahmin hatalarının standart sapmasının hesaplanabildiği maksimum gün

l : Tahmin hatalarının standart sapmasının hesaplandığı gün (minimum 2 gün olmak üzere)

C_1^- : Kayıp fonksiyonunda negatif hatanın karesinin katsayı değişkeni

C_2^- : Kayıp fonksiyonunda negatif hatanın standart sapmasının katsayı değişkeni

C_1^+ : Kayıp fonksiyonunda pozitif hatanın karesinin katsayı değişkeni

C_2^+ : Kayıp fonksiyonunda pozitif hatanın standart sapmasının katsayı değişkeni

$\hat{\sigma}_{p(t_i, l - y_{i, l} - \varepsilon)}$: Epsilondan büyük pozitif hataların standart sapma tahmini

$\hat{\sigma}_{n(|t_i, l - y_{i, l}|)}$: Negatif hataların standart sapma tahmini

$$\begin{cases} 0 & \text{if } 0 \leq (t_i - y_i) \leq \varepsilon \\ C_1^+ (t_i - y_i - \varepsilon)^2 + C_2^+ \hat{\sigma}_{p(t_i, l - y_{i, l} - \varepsilon)} & \text{if } (t_i - y_i) > \varepsilon \\ C_1^- (t_i - y_i)^2 + C_2^- \hat{\sigma}_{n(|t_i, l - y_{i, l}|)} & \text{if } (t_i - y_i) < 0 \end{cases} \quad i = 1 \dots l \text{ ve } 2 \leq l \leq L \quad (4)$$

ε -tüpünün üzerinde kalan pozitif hatalar ve standart sapmaları:

$$p_i = \text{Maks}(0, (t_i - y_i - \varepsilon)), \forall i. i = 1 \dots l \quad (5)$$

$$\hat{\sigma}_{p(t_i, l - y_{i, l} - \varepsilon)} = \sqrt{\frac{\sum_{i=1}^l (p_i - \bar{p})^2}{l - 1}}$$

$$L_{p(t, y, \varepsilon)} = \sum_{i=1}^l C_1^+ p_i^2 + C_2^+ \hat{\sigma}_{p(t_i, l - y_{i, l} - \varepsilon)} \quad (6)$$

Negatif hatalar ve standart sapmaları:

$$n_i = |\text{Min}(0, (t_i - y_i))|, \forall i. i = 1 \dots l \quad (7)$$

$$\hat{\sigma}_{n(|t_i, l - y_{i, l}|)} = \sqrt{\frac{\sum_{i=1}^l (n_i - \bar{n})^2}{l - 1}}$$

$$L_{n(t, y)} = \sum_{i=1}^l C_1^- n_i^2 + C_2^- \hat{\sigma}_{n(|t_i, l - y_{i, l}|)} \quad (8)$$

$$L_{aevmSVR}(t, y) = L_{n(t, y)} + L_{p(t, y, \varepsilon)} \quad (9)$$

Minimize edilen amaç fonksiyonu:

$$\text{Min } L_{aevmSVR}(t, y) + \frac{1}{2} \|w\|^2. \quad (10)$$

Burada $\|w\|$ yapısal riski, $L_{aevmSVR}(t, y)$ deneysel riski ifade etmektedir.

Asimetrik hata varyansını minimize eden (AHVM)-DVR modelinin ATM ikmal maliyeti performansını kıyaslayabilmek amacıyla Mei ve Zhang (2008), Huang ve diğ. (2014), Stockman ve diğ. (2011), Stockman ve diğ. (2012) önerdikleri asimetrik DVR modelleri de bu çalışmada kullanılan ATM verilerine uygulanmıştır. Aynı zamanda asimetrik DVR modellerinin diğer simetrik tahminleme metotlarına göre maliyet performanslarının karşılaştırılabilmesi amacıyla en küçük ortalama kareler (Sayed, 2003; Al-Saggaf ve diğ., 2015), DVR (Vapnik, 1999), çoklu lineer regresyon (Tiryaki ve diğ., 2014) ve çok değişkenli uyarlanabilir regresyon uzanımları "MARS" (Friedman, 1991) yöntemleri de bu çalışmada kullanılmıştır.

Önerilen Optimizasyon Modeli (Proposed Optimization Model)

ATM nakit yönetiminde kasaya nakit yükleme, paranın elde bulundurulması, karşılanmayan müşteri talebi maliyet kalemlerini oluşturmaktadır. ATM'lerde nakit bittiğinde; minimum stok düzeyine indiğinde veya belirli periyotlarla nakit yükleme yapılmaktadır. Bunun için en uygun zaman ve nakit miktarının belirlenmesi maliyet kalemleri açısından önemlidir. ATM nakit ikmal optimizasyonu için bir önceki bölümde açıklanan asimetrik DVR modelinde kullanılan $C_1^-, C_1^+, C_2^-, C_2^+$ değişkenlerinin her bir yükleme sıklığında minimum toplam maliyeti vermesi için optimum değerlerinin bulunması amaçlanmaktadır. Daha sonra her bir yükleme sıklığı için hesaplanan toplam maliyetler arasında en küçük maliyeti veren yükleme sıklığı ve optimum değişkenler test verisi için kullanılan maliyet fonksiyonunun yükleme sıklığı ve değişken değerleri olarak alınmaktadır. Yükleme sıklığının kararı, en sık her gün nakit yükleme yapılabildiği ve en seyrek 7 günde bir nakit yükleme yapılabildiği koşulu altında verilmektedir. Bunun sebebi ele alınan ATM'lerin nakit taleplerine göre kasa kapasitelerinin 7'den fazla gün için yetersiz olması ve en çok 7 günde bir nakit ikmal ihtiyacının oluşmasıdır. Önerilen optimizasyon modeli aşağıda açıklanmıştır.

Parametreler

- n : Maliyetin hesaplandığı toplam gün sayısı (56 gün)
- j : Gün cinsinden nakit yükleme sıklığı $j \in \{1,2,3,4,5,6,7\}$
- $s_{j,n}$: Toplam gün ve nakit yükleme sıklığına göre nakit yükleme sayısı
- r : Yıllık faiz oranı (%9)
- c : Nakit elde bulundurmama ceza katsayısı (0,03)
- R : ATM kasasına nakit yükleme maliyeti (80 TL)

Karar Değişkenleri

$$C_1^-, C_1^+, C_2^-, C_2^+$$

Yardımcı Değişken

y : Karar değişkenlerine bağlı olarak elde edilen tahmin değeri değişkeni

$$y = f(x)_{C_1^-, C_1^+, C_2^-, C_2^+} = \omega \cdot x + b \quad (11)$$

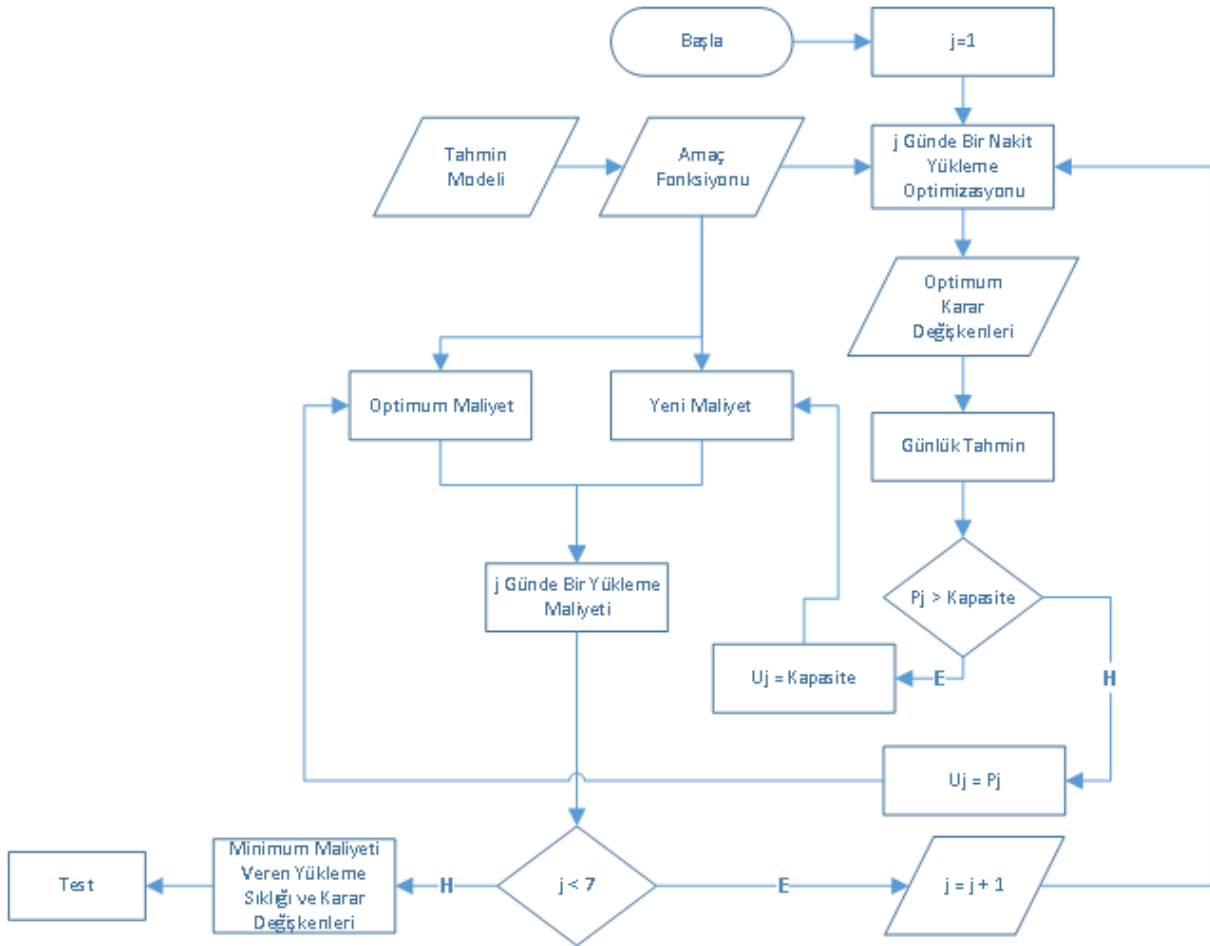
Amaç fonksiyonu:

$$\text{Min } Z = \left(\sum_{i=1}^{S_{j,n}} y_{i,j} * j \right) * \frac{r}{365} + \sum_{i=1}^{S_{j,n}} \left| \text{Min}(0, (y_{i,j} - t_{i,j})) \right| * c + R * s_{j,n} \quad (12)$$

Bu amaç fonksiyonunda birinci kısım elde bulundurma maliyetini, ikinci kısım karşılanmayan müşteri talebi maliyetini, üçüncü kısım ise nakit yükleme maliyetini göstermektedir. Nakit ikmal optimizasyon modelinin içinde yer aldığı nakit ikmal algoritması Şekil 1.'de verilmiştir. Algoritmaya göre optimizasyon modelinin bulunduğu optimum nakit yükleme miktarı ATM kapasitesini aşıyorsa, maksimum yüklenen miktar ATM kapasitesi kadar alınır. Bu durumda yüklenebilen maksimum nakit miktarına göre yeni maliyet hesaplanmaktadır. Karşılaştırılan tüm asimetric modellerin parametreleri Şekil 1.'deki algoritmaya göre hesaplanmıştır. Simetrik modellerde ise optimum karar değişkenlerinin hesaplanması dışındaki işlemler aynıdır.

U_j : j günlük nakit yükleme miktarı

P_j : j günlük optimum nakit yükleme miktarı



Şekil 1. ATM Nakit İkmal Algoritması

Figure 1. ATM Cash Replenishment Algorithm

Tahmin modellerinin girdi oluşturduğu amaç fonksiyonunda j günde bir nakit yüklenmesi durumuna göre minimum toplam maliyeti veren tahmin modeli parametreleri veya optimum karar değişkenleri ve günlük tahminler hesaplanır. Eğer j günlük optimum nakit yükleme miktarı ATM kapasitesini aşıyorsa, en fazla kapasite kadar nakit yüklendiği varsayılır ve yeni duruma göre maliyet tekrar hesaplanır. ATM'lere nakit yükleme zaman aralığı en fazla 7 gün olduğu kabul edilerek, 7 farklı

nakit yükleme sıklığı için hesaplanan maliyetler arasından en düşük maliyeti veren yükleme sıklığı ve buna bağlı olarak bulunan optimum parametreler test verisi için kullanılır.

Optimizasyon Modeli Çözüm Algoritmaları (Optimization Model Solution Algorithms)

Optimizasyon probleminin çözümü için iki farklı algoritma uygulanarak, en küçük amaç fonksiyonunu değerini bulan algoritmanın karar değişkeni değerleri kullanılmıştır.

Nelder-Mead Algoritması (Nelder-Mead Algorithm)

Çok değişkenli bir fonksiyonun yerel minimum noktasının belirlenmesi için Nelder-Mead tarafından önerilen basit bir yöntemdir (Nelder ve Mead, 1965). NM simpleks algoritması türev alınmayan ve lineer olmayan doğrudan arama algoritmalarından biridir. Simpleks n boyutlu arama uzayında (n+1) tepeye sahip çok yüzlü bir cisimdir ve iteratif bir süreçle kademeli olarak optimum noktaya ulaşır (Rajan ve Malakar, 2015).

BFGS Algoritması (BFGS Algorithm)

BFGS algoritması fonksiyonun mevcut noktasındaki gradyan bilgisini kullanarak daha iyi bir nokta bulabilmek için daha iyi bir yön tespit eder ve Hessian matrisini güncelleştirmek için iteratif olarak daha iyi bir yakınlık tespit eder ve minimum değere yaklaşmasını sağlar (Ngo ve diğ., 2015)

Tahminleme ve Optimizasyon Aracı (Forecasting and Optimization Tool)

AHVM DVR modeli için Teo ve diğ.'nin (2010) makine öğrenmesi problemlerinin çözümü için önerdiği genel amaçlı konveks çözücü kullanılmıştır. Bu konveks çözücünün avantajı yeni kayıp fonksiyonlarının, regülatörlerin ve çözücülerin adapte edilebilmesi ve dual problem yerine primal probleme odaklanmasıdır. Teo ve diğ.'nin (2010) konveks çözücüsü olan BMRM (Bundle Methods for Regularized Risk Minimization) risk minimizasyonu için paket yöntemler olarak sunulmuştur. "Bmrm" paketi, "libsvm (Library for Support Vector Machines)" ve "svmlight (Support Vector Machine-Light)" makine öğrenme çözücü paketlerine göre çok daha hızlıdır ve amaç fonksiyonu ile gradyanının hesaplanmasını çözücü modülünden ayırarak gerçekleştirir. Önerilen yöntemin uygulanabilmesi için R İstatistiksel Hesaplama yazılımındaki "bmrm", "NumDeriv", "fTrading" paketleri kullanılmıştır. ATM ikmal maliyetini minimize edecek tahmin modeli katsayı değişkenlerinin ($C_1^-, C_2^-, C_1^+, C_2^+$) belirlenmesi için ise yine R İstatistiksel Hesaplama yazılımındaki "optimx" paketi kullanılmıştır.

BULGULAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Önerilen AHVM tahmin modeli, optimizasyon modeli ve nakit ikmal algoritması ile elde edilen maliyet, hata oranı, ortalama nakit yükleme sıklığı, pozitif hata oranı (ATM'de yükleme periyodu içinde yüklenen nakdin talepten düşük olmama oranı) Çizelge 1. ve Çizelge 2.'de özetlenmiştir. Çizelge 1.'de AHVM modeli diğer asimetrik modellerle karşılaştırılmış; Çizelge 2.'de ise simetrik tahmin modelleri ile karşılaştırılmıştır. Diğer asimetrik ve simetrik tahmin modelleri ile karşılaştırıldığında hem validasyon hem de test verisi için AHVM modeli en düşük maliyete sahiptir. Test verilerinde Huang ve diğ. (2014) modeline göre %12,1, Mei ve Zhang'ın (2008) modeline göre %45,5, Stockman ve diğ. (2011) modeline göre %19,1 oranında; simetrik modellerden ϵ DVR modeline göre %51,8, en küçük ortalama kareler yöntemine göre %51,2, MARS modeline göre %31 ve çoklu lineer regresyon modeline göre %31,6 oranında maliyet azaltılmıştır. Stockman ve diğ.(2012) önerdiği asimetrik ve ikinci dereceden DVR modelinin test maliyeti AHVM modeline yakın çıkmıştır; ancak toplam 6.709.272 TL daha fazla nakit ikmalini önermektedir. ATM'lere yüklenen nakit miktarı belirli bir seviyeyi aştıktan sonra maliyetlerin

tekrar artmaya başladığı görülmüştür. Mei ve Zhang'ın (2008) önerdiği DVR modeli dışında diğer tüm asimetrik modellerin maliyeti simetrik modellere kıyasla daha düşük çıkmıştır. Şekil 2.'de görüldüğü üzere Stockman ve diğ. (2011) üretilen tahmin modeli değerleri diğer modellere kıyasla daha yüksek sonuçlar üretmiştir. Şekil 3'te örnek bir ATM için AHVM modelinin simetrik modellere kıyasla daha yüksek değerler ürettiği görülmektedir. Bunun sebebi, bir önceki bölümde parametrelerde verilen değerlere göre asimetrik modellerin elde bulundurmama ceza katsayısının elde bulundurma maliyetine göre daha yüksek olması ve tahmin değerlerini maliyeti minimize eden değişkenleri kullanarak üretmeleridir. Faiz oranı, elde bulundurmama ceza katsayısı, nakit yükleme maliyetleri değiştirildiğinde tahmin modeli değişkenleri de farklı değerler ile farklı tahmin sonuçları üretecektir.

Mei ve Zhang'ın (2008) tahmin modeli dışında diğer asimetrik modeller test verileri için günlük en az %70 oranında gerçek çekilen değerlerin üzerinde tahmin üreterek, nakit yükleme periyodu içerisinde en az %78,4 oranında ATM'deki nakdin tükenmemesini sağlamıştır. Mei ve Zhang'ın (2008) tahmin modeli için validasyon verisinde yükleme sıklığı içerisinde pozitif hata oranı %81,9 iken test verisinde bu oran %56,2'ye düşmüştür. Önerilen AHVM tahmin modeli validasyon verisi için yükleme sıklığı periyodunda en yüksek olan %93 pozitif hata oranına ve test verisi için de ikinci en yüksek olan %83,4'lük pozitif hata oranına sahiptir.


Çizelge 1. 28 ATM için Asimetrik Modellerin Sonuç Tablosu

Table 1. Asymmetric Models' Results Table for the 28 ATM

VALIDASYON	AHVM	Huang ve diğ. (2014) V-TUBE	Mei ve Zhang (2008) ANEW	Stockman ve diğ. (2012) QUAD	Stockman ve diğ. (2011) LOWER
<i>Maliyet</i>	113.612	121.632	146.219	123.994	138.271
<i>Günlük SMAPE</i>	0,402	0,405	0,399	0,466	0,362
<i>Günlük Pozitif Hata Oranı</i>	0,761	0,787	0,702	0,794	0,724
<i>Toplam Yüklenen Nakit</i>	93.978.319	92.755.250	85.362.313	102.329.304	83.641.109
<i>Ortalama Nakit Yükleme Sıklığı</i>	3,172	3,241	3,448	3	3,345
<i>Yükleme Sıklığı için SMAPE</i>	0,320	0,327	0,270	0,398	0,273
<i>Yükleme Sıklığı için Pozitif Hata Oranı</i>	0,930	0,907	0,819	0,914	0,864
TEST					
<i>Maliyet</i>	131.772	149.943	242.110	133.500	163.019
<i>Günlük SMAPE</i>	0,442	0,425	0,361	0,502	0,372
<i>Günlük Pozitif Hata Oranı</i>	0,763	0,748	0,524	0,797	0,700
<i>Toplam Yüklenen Nakit</i>	80.993.530	75.983.117	59.497.591	87.802.702	67.947.059
<i>Ortalama Nakit Yükleme Sıklığı</i>	3,172	3,241	3,483	3	3,345
<i>Yükleme Sıklığı için SMAPE</i>	0,357	0,344	0,242	0,427	0,285
<i>Yükleme Sıklığı için Pozitif Hata Oranı</i>	0,834	0,825	0,562	0,854	0,784

Çizelge 2. 28 ATM için Simetrik Modeller ile AHVM DVR Karşılaştırma Sonuç Tablosu
Table 2. Comparison of Asymmetric Variance Minimizing SVR Results with Symmetric Models' Results Table for the 28 ATM

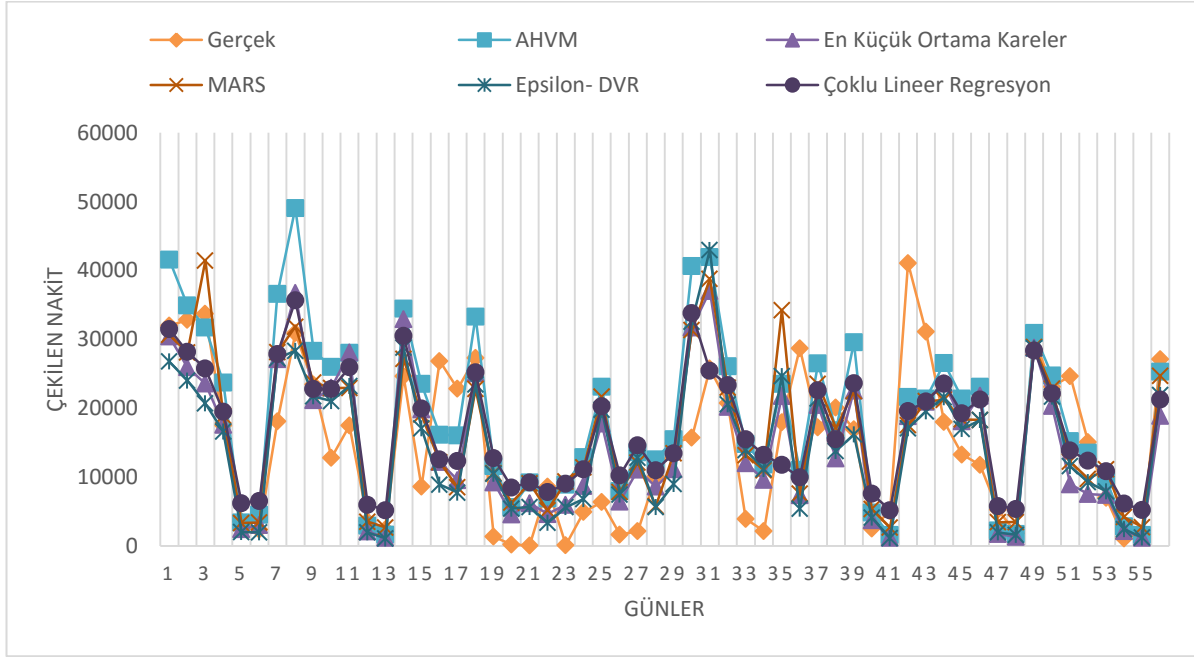
VALIDASYON	Epsilon-DVR	En Küçük Ortalama Kareler	MARS	Çoklu Lineer Regresyon
Maliyet	266.353	263.183	219.964	224.502
Günlük SMAPE	0,321	0,326	0,318	0,317
Günlük Pozitif Hata Oranı	0,473	0,487	0,570	0,584
Toplam Yüklenen Nakit	67.085.858	67.549.267	71.607.098	71.294.883
Ortalama Nakit Yükleme Sıklığı	4,207	4,207	3,897	3,931
Yükleme Sıklığı için SMAPE	0,175	0,186	0,196	0,203
Yükleme Sıklığı için Pozitif Hata Oranı	0,499	0,476	0,592	0,593
TEST				
Maliyet	273.717	270.113	191.110	192.803
Günlük SMAPE	0,328	0,346	0,330	0,333
Günlük Pozitif Hata Oranı	0,441	0,453	0,623	0,657
Toplam Yüklenen Nakit	53.920.368	54.656.350	61.304.554	61.085.384
Ortalama Nakit Yükleme Sıklığı	4,207	4,207	3,897	3,897
Yükleme Sıklığı için SMAPE	0,197	0,211	0,212	0,221
Yükleme Sıklığı için Pozitif Hata Oranı	0,415	0,418	0,666	0,676



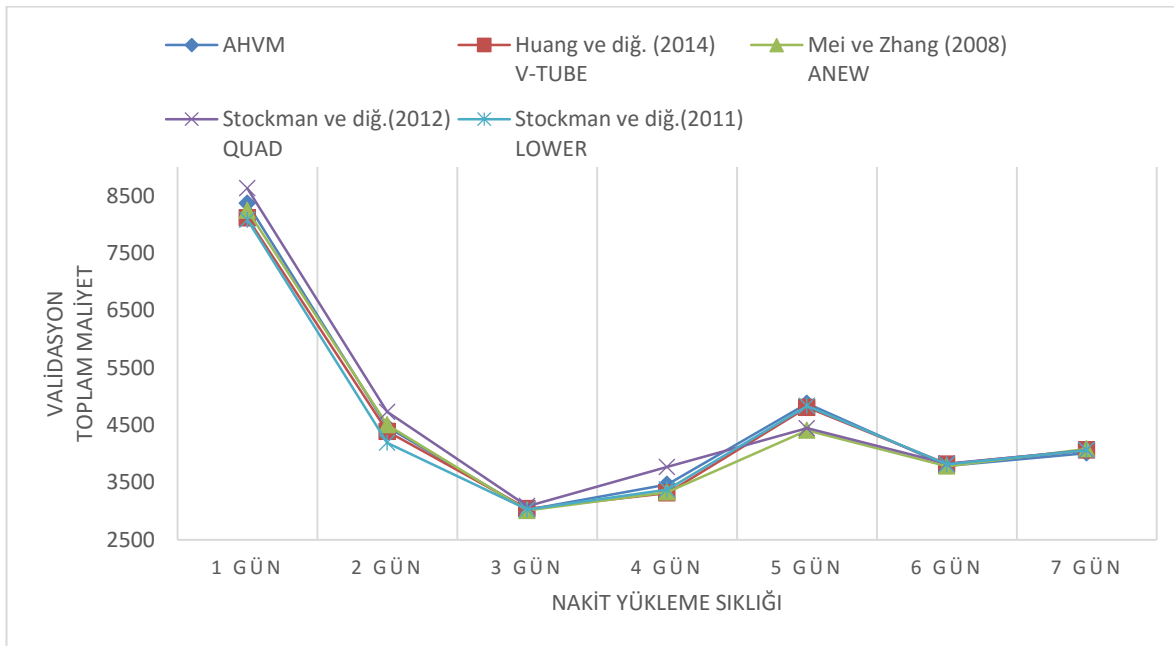
Şekil 2. Örnek bir ATM'nin test verisi için asimetrik modellerin tahminlerinin karşılaştırması
Figure 2. A comparison of daily cash withdrawn which asymmetric models forecast for the test data of an example ATM

Yükleme sıklığı periyodu içerisinde en küçük ortalama tahmin hatasına sahip model %19,7 ile Vapnik'in (1999) ϵ DVR modelidir. Asimetrik modellerin tahmin hata oranları (SMAPE) simetrik modellere kıyasla daha yüksek çıkmıştır. Önerilen yükleme sıklıkları ile tüm modellerde hata oranları %8-12 arasında düşürülmüştür.

Şekil 4, 5, 6 ve 7’de örnek bir ATM için validasyon ve test verilerindeki yükleme sıklıklarına bağlı AHVM modelinin diğer asimetrik ve simetrik modellerle karşılaştırıldığı maliyetler gösterilmiştir. Modellerin kıyaslandığı validasyon toplam maliyetlerinde tüm asimetrik (Şekil 4.) ve simetrik modeller (Şekil 6.) birbirine yakın sonuçlara sahiptir. Önerilen modelin ise diğer modellere oranla, optimizasyon modelinin çalıştırıldığı validasyon verisi dışında tüm yükleme sıklıkları için daha düşük maliyetler bulunduğu Şekil 5. ve Şekil 7.’de gösterilmiştir.

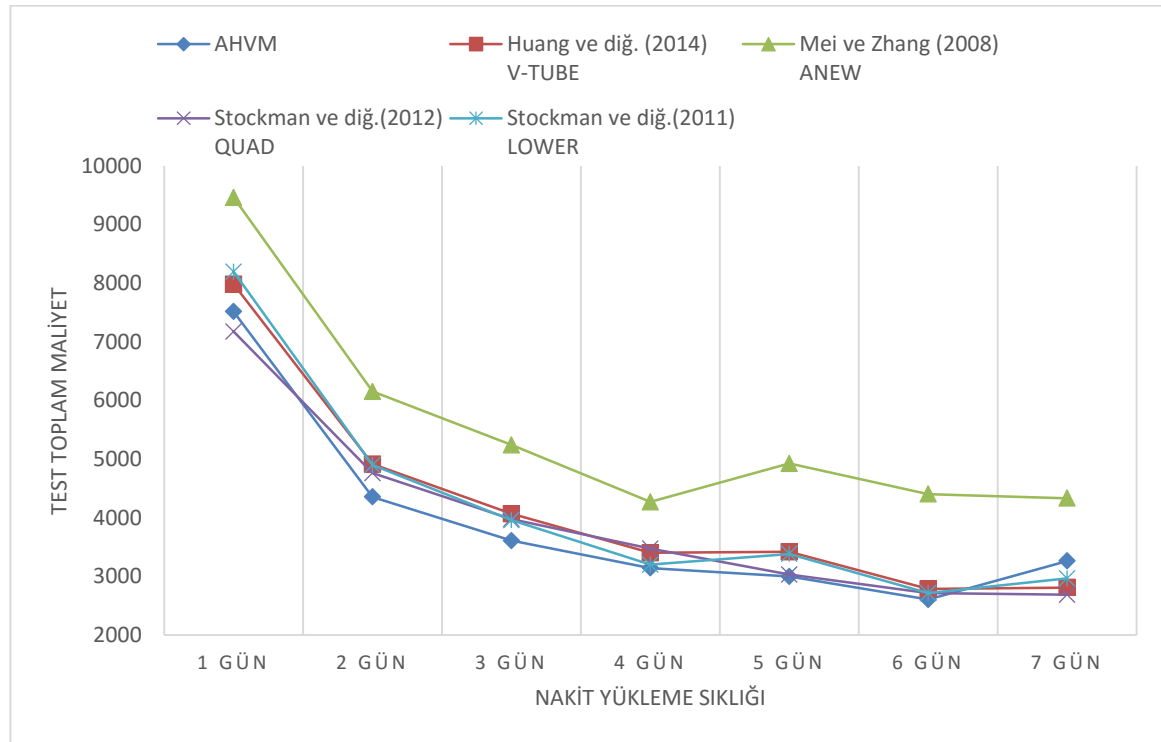


Şekil 3. Örnek bir ATM’nin test verisi için simetrik modellerin tahminlerinin karşılaştırması
Figure 3. A comparison of daily cash withdrawn which symmetric models forecast for the test data of an example ATM




Şekil 4. Örnek bir ATM’nin validasyon datası için asimetrik modellerin farklı yükleme sıklıklarındaki toplam maliyetleri

Figure 4. Total cost for an exmanple ATM’s validation data for different uploading frequency of asymmetric models




Şekil 5. Örnek bir ATM'nin test datası için asimetrik modellerin farklı yükleme sıklıklarındaki toplam maliyetleri

Figure 5. Total cost for an exmanple ATM's test data for different uploading frequency of asymmetric models



Şekil 6. Örnek bir ATM'nin validasyon datası için simetrik modellerin farklı yükleme sıklıklarındaki toplam maliyetleri

Figure 6. Total cost for an exmanple ATM's validation data for different uploading frequency of symmetric models



Şekil 7. Örnek ATM'nin test datası için simetrik modellerin farklı yükleme sıklıklarındaki toplam maliyetleri

Figure 7. Total cost for an example ATM's test data for different uploading frequency of symmetric models

SONUÇLAR (CONCLUSIONS)

ATM nakit talebi tahminlerinin önemli olduğu kadar maliyetler de önemlidir. Bu iki durumun birlikte ele alınması ATM nakit ikmal probleminin optimum çözümünü sağlamaktadır. Bu çalışma tahmin modeli ile optimizasyon modelini entegre bir şekilde kullanan algoritma ile tahmin değerlerini ve nakit yükleme sıklıklarını bulmaktadır. Optimizasyon modelinde tahmin modeli parametreleri karar değişkeni olarak kullanılmış ve minimum maliyeti veren tahmin değerleri ve nakit yükleme miktarları üretilmiştir. Bu bakımdan, önce tahmin değeri bulan ve sonra nakit yükleme maliyetlerini hesaplayan; en küçük tahmin hata oranını bulmaya çalışan veya tahmin modeli kullanmadan nakit yükleme kararı veren çalışmalardan farklılık göstermektedir. Aynı zamanda tahmin değerlerinin en küçük hata değerine sahip olmasının en düşük maliyeti sağlamayabileceği; tahmin hatalarının işaretinin ve değişkenliğinin de etkisinin olduğu gösterilmiştir. ATM nakit tahmin modeli olarak yeni bir asimetrik model önerilmiş ve yazındaki diğer modellere kıyasla daha düşük maliyetler elde edildiği gösterilmiştir. Bu yöntem yalnızca ATM ikmal problemi için değil, enerji, perakende, turizm gibi sektörlerde de uygulanabilir.

Bu çalışmaya ek olarak, ileride yeni nesil geri dönüşümlü ATM'ler için önerilen tahmin modeli geliştirilecek ve aynı sıklıkta para yükleme önerilen ATM'ler için yerleşkeleri hesaba katılarak rotalama problemi çözülecektir. Ele alınan problemde nakit yükleme sıklıkları 1 gün ile 1 hafta arasında değişmektedir. Farklı sektörlerde ikmal zamanlarının çok daha büyük değişkenlik gösterdiği durumlar için optimizasyon modeli geliştirilerek çözüm süresi kısaltılabilir.

KAYNAKLAR (REFERENCES)

- Al-Saggaf, U.M., Moinuddin, M., Arif, M., Zerguine, A., 2015, "The q-Least Mean Squares Algorithm", Signal Processing, Cilt 111, 50-60.
- 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, Cilt 27, 672-688.

- Armenise, R., Birtolo, C., Sangianantoni, E., Troiano, L., 2010, "A generative solution for ATM Cash Management", 2010 International Conference of Soft Computing and Pattern Recognition IEEE, 349-356.
- Brentnall, A.R., Crowder, M.J., Hand, D.J., 2010, "Predictive-sequential forecasting system development for cash machine stocking", International Journal of Forecasting, Cilt 26, 764-776.
- Castro, J., 2009, "A stochastic programming approach to cash management in banking", European Journal of Operational Research, Cilt 192, 963-974.
- Darwish, S.M., 2013, "A methodology to improve cash demand forecasting for ATM Network", International Journal of Computer and Electrical Engineering, Cilt 5, 405-409.
- Ekinci, Y., Lu, J.-C., Duman, E., 2015, "Optimization of ATM cash replenishment with group-demand forecasts", Expert Systems with Applications, Cilt 42, 3480-3490.
- Erdal, H.İ., 2011, "Destek Vektör Makineleri ile Tahmine Dayalı Modelleme ve Bir Uygulama", Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü.
- Friedman, J. H., 1991, "Multivariate adaptive regression splines", The Annals of Statistics, Cilt 19, Sayı 1,1-67.
- Hsiao, C.-C., Su, S.-F., Chuang, C.-C., 2011, "A Rough-based Robust Support Vector Regression Network for Function Approximation" 2011 IEEE International Conference on Fuzzy Systems, Taipei, Taiwan, 2814-2818, 27-30 Haziran.
- Huang, W., Shen, L., 2008, "Weighted support vector regression algorithm based on data description", 2008 ISECS International Colloquium on Computing, Communication, Control and Management, IEEE, 250-254.
- Huang, X., Shi, L., Pelckmans, K., Suykens, J. A. K., 2014, "Asymmetric v-tube support vector regression", Computational Statistics and Data Analysis, Cilt 77, 371-382.
- Li, Z., Li, Y., Yu, F., Ge, D., 2014, "Adaptively Weighted Support Vector Regression for Financial Time Series Prediction", 2014 International Joint Conference on Neural Networks (IJCNN), Pekin, Çin, 3062-3065, July 6-11.
- Liu, J., Seraoui, R., Vitelli, V., Zio, E., 2013, "Nuclear power plant components condition monitoring by probabilistic support vector machine", Annals of Nuclear Energy, Cilt 56, 23-33.
- Lu, C.-J., 2014, "Sales forecasting of computer products based on variable selection scheme and support vector regression", Neurocomputing, Cilt 128, 491-499.
- Mei, L., Zhang, S., 2008, "A new weighted support vector machine for regression and its parameters optimization", Advanced Intelligent Computing Theories and Applications. With Aspects of Artificial Intelligence, Cilt 5227, Editörler: Huang, D.-S., Wunsch II, D. C., Levine, D. S., Jo, K.-H., Springer Berlin Heidelberg, 597-604.
- Nelder J.A., Mead R., 1965, "A simplex method for function minimization", Computer Journal., Cilt 7, Sayı 4.
- Ngo, T.-T., Huang, J.-H., Wang, C.-C., 2015, "The BFGS Method for estimating the interface temperature and convection coefficient in ultrasonic welding", International Communications in Heat and Mass Transfer, Cilt 69, 66-75.
- Ormándi, R., 2008, "Variance Minimization Least Squares Support Vector Machines for Time Series Analysis", Data Mining, ICDM'08, Eight IEEE International Conference, 965-970.
- Rajan, A., Malakar, T., 2015, "Optimal reactive power dispatch using hybrid Nelder-Mead simplex based firefly algorithm", International Journal of Electrical Power and Energy Systems, Cilt 66, 9-24.
- Sayed, A.H., 2003, "Fundamentals of Adaptive Filtering", Wiley-Interscience, New York.
- Simutis, R., Dilijonas, D., Bastina, L., 2008, "Cash demand forecasting for ATM using neural networks and support vector regression algorithms", In 20th EURO mini conference – continuous optimization and knowledge-based technologies, Neringa, LITHUANIA, 416-421 , 20-23 Mayıs.

- Stockman, M., Awad, M., Khanna, R., 2011, "Asymmetrical and Lower Bounded Support Vector Regression for Power Estimation", Energy Aware Computing (ICEAC), 2011 International Conference, 1-6, 30 Kasım-2 Aralık.
- Stockman, M., El Ramli, R. S., Awad, M., Jabr, R., 2012, "An Asymmetrical and Quadratic Support Vector Regression Loss Function for Beirut Short Term Load Forecast", Systems Man and Cybernetics (SMC), 2012 IEEE International Conference, 651-656, 14-17 Ekim.
- Taieb, S.B., Bontempi, G., Atiya, A.F., Sorjamaa, A., 2012, "A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition", Expert Systems with Applications, Cilt 39,7067-7083.
- 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, Cilt 27,760-776.
- Teo, C.H., Vishwanathan, S.V.N., Smola, A., Le, Q.V., 2010, "Bundle Methods for Regularized Risk Minimization", Journal of Machine Learning Research, Cilt 11, 311-365.
- Tiryaki, S., Özşahin, Ş., Yıldırım, İ., 2014, "Comparison of artificial neural network and multiple linear regression models to predict optimum bonding strength of heat treated woods", International Journal of Adhesion & Adhesives, Cilt 55, 29-36.
- Vapnik, V., 1999, The Nature of Statistical Learning Theory, Springer.
- Vapnik, V., 2000, The Nature of Statistical Learning Theory, Springer, New York.
- 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, Cilt 232, 383-392.
- Wang, Y., Lee, T.-H., 2014, "Asymmetric loss in the Greenbook and the Survey of Professional Forecasters", International Journal of Forecasting, Cilt 30, 235-245.
- Wichard, J.D., 2011, "Forecasting the NN5 time series with hybrid models", International Journal of Forecasting, Cilt 27, 700-707.
- Zhang, Y.M., Qi, W.G., 2009, "Interval forecasting for heating load using support vector regression and error correcting Markov Chains", Proceedings of the Eighth International Conference on Machine Learning and Cybernetics, Baoding, 1106-1110.