

DESTEK VEKTÖR REGRESYON VE İKİZ DESTEK VEKTÖR REGRESYON YÖNTEMİ İLE TEDARİKÇİ SEÇİMİ

SUPPLIER SELECTION WITH SUPPORT VECTOR REGRESSION AND TWIN SUPPORT VECTOR REGRESSION

Hüseyin İNCE⁽¹⁾, Salih Zeki İMAMOĞLU⁽²⁾

^(1,2) Gebze Teknik Üniversitesi, İşletme Fakültesi

⁽¹⁾ h.ince@gtu.edu.tr, ⁽²⁾ imamoglu@gtu.edu.tr

Geliş/Received: 24-12-2015, Kabul/Accepted: 16-02-2016

ÖZ: Tedarikçi seçimi sorunu son zamanlarda literatürde oldukça ilgi görmektedir. Güncel literatür, yapay zeka tekniklerinin geleneksel istatistiksel yöntemlerle karşılaştırıldığında daha iyi bir performans sağladığını göstermektedir. Son zamanlarda, destek vektör makinesi, araştırmacılar tarafından çok daha fazla ilgi görse de, buna dayalı tedarikçi seçimi çalışmalarına pek sık rastlanmamaktadır. Bu çalışmada, tedarikçi kredi endeksini tahmin etmek amacıyla, destek vektör regresyon (DVR) ve ikiz destek vektör regresyon (İDVR) teknikleri kullanılmıştır. Pratikte, tedarikçi verisini içeren örneklem sayısı oldukça yetersizdir. DVR ve İDVR daha küçük örneklemle analiz yapmaya uyarlabilir. Tedarikçilerin belirlenmesinde DVR ve İDVR yöntemlerinin tahmin kesinlikleri karşılaştırılmıştır. Gerçek örnekler İDVR yönteminin DVR yöntemine kıyasla üstün olduğunu göstermektedir.

Anahtar Kelimeler: Tedarikçi Seçimi, Destek Vektör Regresyon, İkiz Destek Vektör Regresyon

ABSTRACT: Suppliers' selection problem has attracted considerable research interest in recent years. Recent literature show that artificial intelligence techniques achieve better performance than traditional statistical methods. Recently, support vector machine has received much more attention from researchers, while studies on supplier selection based on it are few. In this paper, we applied the support vector regression (SVR) and twin support vector regression (TSVR) techniques to predict the supplier credit index. In practice, the suppliers' samples are very insufficient. SVR and TSVR are adaptive to deal with small samples. The prediction accuracies for SVR and TSVR methods are compared to choose appropriate suppliers. The actual examples illustrate that TSVR methods are superior to SVR.

Keywords: Supplier Selection, Support Vector Regression, Twin Support Regression

JEL Classifications: C61, C63, C65

1. Giriş

Tedarik Zinciri Yönetimi (TZY) özellikle üretim sektöründe işletmenin rekabet yeteneğini artıran ve tedarik zincirindeki ilgili ortakların malzeme/materyal akışı (lojistik), bilgi akışı ve sermaye akışını entegre eden bir modeldir. Tedarikçinin maliyet, kalite, teslim ve hizmet performansının tedarik zincirinin hedeflerine ulaşmada oynadığı kilit rol nedeniyle, tedarikçi seçimi tedarik zincirindeki satın alma yönetimine ilişkin en kritik faaliyetlerden biridir. Tedarikçi seçim süreci, işletmenin çıkarlarını ve geleceğini belirlemektedir. Bu nedenle, uygun tedarikçilerin nasıl seçildiği önemli bir sorundur. Tedarikçi seçimi, birçok çelişkili faktör tarafından etkilenen Çok Kriterli Karar Verme (ÇKKV) problemidir. Bu nedenle, satın alma

yöneticisinin kriterler arasındaki fayda-zarar ilişkisini analiz etmesi gerekmektedir. ÇKKV teknikleri, alternatifleri değerlendirmede karar alıcıları desteklemektedir.

Tedarikçi seçimini destekleyen yöntemler arasında, Yapay Zeka (YZ) tabanlı modeller önemli bir rol oynamaktadır. Bilgisayar destekli sistemlere dayalı YZ modelleri, satın alma uzmanı veya geçmiş veriler kullanılarak eğitilebilirler. Daha sonra, uzman olmayan çalışanlar da benzer ama yeni durumlarda bu sistemlere başvurabilirler (Guo, Yuan ve Tian, 2009). Daha önceden tedarikçi seçiminde uygulanmış olan YZ teknolojilerine dayalı yöntemlerin örnekleri, yapay sinir ağları ve diğer yeni teknikleri içermektedir. Bu yöntemlerin güçlü bir yönü, karar verme sürecinin formülasyonunu gerektirmemeleridir. Bu bağlamda, yapay zeka teknolojileri karmaşıklık ve belirsizlik ile “klasik yöntemlerden” daha iyi başa çıkabilir. Çünkü, bu sistemler bireysel yargı mekanizması gibi çalışmaktadır. Birçok araştırmacı farklı istatistik ve yapay zeka yöntemleri uygulayarak tedarikçilerin gerçek yetenek tahminleri üzerinde umut verici sonuçlar elde etmişlerdir. Son zamanlarda YZ teknikleri, özellikle kural tabanlı uzman sistemler, vaka tabanlı nedensel sistemler, Destek Vektör Regresyon (DVR) yöntemi ve Yapay Sinir Ağları (YSA) gibi bilgisayarla öğrenme teknikleri tedarikçi seçim problemini çözmek için kullanılmaktadır (Guo ve diğerleri, 2009; Vahdani, Iranmanesh, Meysam Mousavi ve Abdollahzade, 2012).

Tedarikçi seçimi konularında çalışan araştırmacıların az olmasına karşın, son zamanlarda araştırmacılar istatistiksel öğrenme teorisine dayalı Destek Vektör Makineleri (DVM) konularına artan bir ilgi göstermektedir (Sun, Xie ve Xue, 2005; Wen ve Li, 2006). DVM teorik olarak iyi bir temele sahip olmanın yanı sıra, pratik anlamda da üstün bir uygulama gücüne sahiptir. Ayrıca, DVM el yazısı tanıma (Kim, Pang, Je, Kim ve Bang, 2003), yüz algılama (Juang ve Shiu, 2008; Gunes ve Polat, 2009), güvenlik sistemleri (Sagiroglu, Yolacan ve Yavanoglu, 2011; Li, Xia, Zhang, Yan, Ai ve Dai, 2012), ve borsa tahmini (Ince ve Trafalis, 2008; Ince ve Trafalis, 2007) dahil olmak üzere çeşitli alanlarda başarıyla uygulanmaktadır. Bu durumların çoğunda DVM, geleneksel bilgisayarla öğrenme yaklaşımlarından ya daha iyi ya da benzer bir performans sergilemektedir. Bu çalışmada yeni bir DVM regresyon yaklaşımı olan İkiz Destek Vektör Regresyon (İVDR) tekniği tedarikçi seçimi için uygulanmaktadır.

2. Tedarikçi Seçme ve Değerlendirme Yöntemleri

Analitik Hiyerarşi Süreci (AHS) ve analitik ağ süreci (Bruno, Esposito, Genovese ve Passaro, 2012; Tseng, Chiang ve Lan, 2009; Abdollahi, Arvan ve Razmi, 2015), yapay zeka (Guosheng ve Guohong, 2008; Vahdani ve diğerleri, 2012; Choy ve Lee, 2002; Kar, 2015), çok amaçlı programlama ve Çok Kriterli Karar Verme (ÇKKV) (Weber ve Ellram, 1992; Dagdeviren ve Eraslan, 2008) ve istatistiksel analiz (Choi ve Hartley, 1996), Veri Zarflama Analizi (VZA) ve melez yöntemler (Wu ve Blackhurst, 2009; Kuo. ve Lin, 2012; Guo, Zhu ve Shi, 2014) dahil olmak üzere tedarikçi seçim kararlarının desteklenmesi için çeşitli tedarikçi seçim modelleri ve teknikleri geliştirilmiştir. Narasimhan, Talluri ve Mendez (2001), ve Talluri ve Narasimhan'a (2005) göre, şu anda tedarikçi seçim süreçlerinde kullanılan metodolojilerin nesnel değerlendirme üzerinde çok fazla durduğu, değerlendirme mekanizmasının yalnız performans sonuçlarına dayandırıldığı ve tedarikçinin yeteneklerini ve olanaklarını göz önünde bulundurmama hatası gibi bazı sorunları bulunmaktadır. Diğer yandan,

yukarıda belirtilen her bir yöntem ilgili sorun bağlamında tedarikçinin seçilmesi konusuna benzersiz bir katkı sağlamaktadır.

Çeşitli araştırmacılar tedarikçi seçimine AHS'yi uygulamışlardır. Örneğin, Arıkan ve Kucukce (2012), Nydick ve Hill (1992), ve Kuo ve Lin (2012) tedarikçi seçiminde, değerlendirme göstergeleri kalite, fiyat, hizmet ve teslim programına dayandıran AHS'yi kullanmışlardır. Mohanty ve Deshmukh (1993) de tedarik kaynaklarını değerlendirmek için AHS'yi kullanmıştır. Yakın zamanda, Noorul Haq ve Kannan (2006) Bulanık Analitik Hiyerarşi Süreci (BAHS) ve genetik algoritmayı kullanarak siparişe göre düzenlenmiş tedarik zinciri ortamında bir orijinal ekipman üretici firması için entegre tedarikçi seçimi ve çok kademeli dağıtım envanteri modelini geliştirmiştir.

Kao ve Liu (2000), Wu ve Blackhurst (2009), ve Narasimhan ve diğerleri (2001) tedarikçi seçimi için VZA yaklaşımını önermektedir. Kao ve Liu (2000) farklı ölçüm birimlerinde göstergeleri işleyerek ve tedarikçilerin performansını tespit ederek tedarikçi performansını seçmek ve geliştirmek amacı ile girdi ve çıktıları temsil eden 23 gösterge kullanmıştır. Narasimhan ve diğerleri (2001) birçok firma tarafından kullanılan ağırlık göstergelerinin çok öznel olma eğiliminde olduğunu ve yalnız fiyat, kalite ve teslim programı ile sınırlı olduğunu ve bunun da genel, nesnel ve daha iyi performans değerlendirmesini önlediğini belirtmektedirler. İlave olarak Wu ve Blackhurst (2009), tedarikçi değerlendirmesi ve seçimi için artırılmış bir VZA yaklaşımını önermektedir.

Son yıllarda, Veri Zarflama Analizi (VZA) tedarikçi değerlendirmesi ve kıyaslama süreçleri için bir yöntem olarak dikkat çekmektedir. Weber, Current ve Desai (2000) tedarikçi seçimi için VZA ve çok programlama tekniğini birleştiren bir model önermektedir. Narasimhan ve diğerleri (2001) tedarikçileri dört performans kümesine kategorize etmek amacı ile VZA'nın ağırlıklı model ile birlikte kullanıldığı bir tedarikçi değerlendirme yöntemini önermiştir: HE (yüksek performans ve verimli), HI (yüksek performans ve verimsiz), LE (düşük performans ve verimli) ve LI (düşük performans ve verimsiz). Talluri (2002) marjinal giderleri göz önünde tutarak tedarik kararlarını değerlendirmek için VZA'ya dayanan bir model önermektedir. Talluri ve Narasimhan (2003) tedarikçi değerlendirmesi için bir maks-min VZA yaklaşımını geliştirmiştir. Talluri ve Narasimhan (2005) tedarik temel optimizasyonu için VZA'ya dayanan bir metodoloji önermektedir. Talluri, Narasimhan ve Nair (2006) tedarikçi performans değerlendirmesi için olasılık-sınırlı bir VZA modeli geliştirmiştir.

Yakın zamanlarda, bazı bilim adamları farklı yöntemlerin kullanılması ve her bir yöntemin iyi yönlerinden tam olarak yararlanmayı önermektedir. Kuo, Hong, Lin ve Huang (2008) Tayvan'daki bir dizüstü bilgisayar üreticisi için uygun tedarikçiler seçmek amacı ile bulanık sinir ağı kullanmıştır. Ayrıca, Kuo, Lee ve Hu (2008) aynı zamanda tedarikçi seçimi için hem bulanık AHS ve hem de bulanık VZA'yı birleştiren bir yöntem de sunmaktadır. Aynı zamanda, Jain, Wadhwa ve Deshmukh (2007) veri madenciliği tekniklerinin umut verici sonuçlarından dolayı tedarikçi seçimi için bulanık ilişkili kurallara dayalı bir yaklaşım uygulamıştır.

Choy, Lee ve Lo (2003), ve Choy, Lee, Lau, Lu ve Lo (2004) en iyi tedarikçiyi seçmek için melez bir Yapay Sinir Ağları (YSA) ve Vaka Temelli Çözümleme (VTÇ) yaklaşımını teklif etmiştir. Özellikle, YSA potansiyel tedarikçilerin kıyaslanması için

kullanılmış ve VTÇ de önceki başarılı ve ilişkili vakalara dayanarak en iyi tedarikçiyi seçmek için kullanılmıştır. Lau, Lee, Ho, Pun ve Choy (2006) tedarikçi seçimi için melez bir YSA ve Genetik Algoritma (GA) yaklaşımını geliştirmiştir. YSA değerlendirme kriterleri açısından potansiyel tedarikçilerin kıyaslanmasından sorumludur. Bundan sonra, tedarikçilerin en iyi kombinasyonunu tespit etmek için GA kullanılmıştır. Kuo, Wang ve Tien (2010) YSA, VZA ve AHS'yi bir arada kullanan bir yeşil tedarikçi seçim modelini geliştirmiştir. Bu yöntem hem geleneksel tedarikçi seçim kriterlerini, hem de çevre yönetmeliklerini birlikte ele alarak değerlendirme yapmaktadır. Wu (2009) tedarikçilerin performanslarını değerlendirmek için VZA, karar ağaçları ve YSA'ları kullanan melez bir model önermektedir. Guo ve diğerleri (2009) potansiyel destek vektör makinesi yaklaşımını geliştirmiştir ve daha sonra özellik seçimi ve çok sınıflı sınıflandırma dahil olmak üzere tedarik seçimi ile ilgili hususlara değinmek amacı ile bu yöntemi karar ağaçları ile birleştirmiştir. Luo, Wu, Rosenberg ve Barnes (2009) seçim sürecinin erken aşamalarında çok sayıda potansiyel tedarikçinin elenmesinde ortaya çıkan bilgi-işleme zorlukları ile başa çıkan bir model geliştirmiştir. Radyal Tabanlı Fonksiyon-Yapay Sinir Ağları'na (RTF-YSA) dayanan model, potansiyel tedarikçilerin hem kalitatif hem de kantitatif ölçüler kullanılarak çoklu kriterlere karşı değerlendirilmesini sağlamaktadır.

Kuo, Hong ve Huang (2010) hem kantitatif hem de kalitatif faktörlerin göz önünde bulundurulmasını sağlayan bir akıllı tedarikçi karar destek sistemi geliştirmiştir. Bu sistem (1) kâr ve verimlilik gibi kantitatif verilerin bir derlemesini, (2) kalitatif verilere yönelik kuralları elde etmek için Bulanık Sinir Ağlarına (BSA) dayanan Parçalı Topluluk Optimizasyonunu (PTO) ve (3) optimum kararı elde etmek için hem kantitatif hem de belirsiz bilgi kararını bir araya getiren bir karar modelini içermektedir.

3. Destek Vektör Regresyonu ve İkiz Destek Vektör Regresyonu

3.1. Destek Vektör Regresyonu

Destek Vektör Makinesi (DVM) sınıflandırma ve regresyon için mükemmel bir kernel-tabanlı araçtır (Burges, 1998; Vapnik, 1998). Bu öğrenme stratejisi Vapnik (1998) tarafından geliştirilmiş ve makineli öğrenme algoritmalarında ilkelere dayalı ve çok güçlü bir yöntemdir.

Doğrusal olmayan DVR hiper uzayda $f(x) = w^T \phi(x) + b$ ile ifade edilen bir regresyon fonksiyonu bulmaya çalışır. Bu fonksiyon “ ϵ -duyarsız” kayıp fonksiyonu kullanılarak elde edilir. Doğrusal olmayan DVR aşağıdaki Karesel Programlama Problemi (KPP) çözümlenerek elde edilebilir:

$$\begin{aligned} \min_{w,b,\xi,\xi^*} \quad & \frac{1}{2} \|w\|^2 + C(e^T \xi + e^T \xi^*) \\ \text{s. t.} \quad & (\phi(A)w + eb) - Y \leq e\epsilon + \xi, \quad \xi \geq 0e \\ & Y - (\phi(A)w + eb) \leq e\epsilon + \xi^*, \quad \xi^* \geq 0e \end{aligned} \quad (1)$$

Burada C önceden belirlenen bir parametredir ve hataların uyarlanması ile regresyon fonksiyonunun düzlüğü arasındaki dengeyi sağlayan bir düzenleme parametresidir. ξ

ve ζ^* örneklerin ϵ -tüpüne girip girmediğini gösteren yapay değişkenlerdir, e ise birim vektördür.

Lagrange çarpanları α ve α^* ı kullanarak KPP'in (1) duali aşağıdaki şekilde elde edilir:

$$\begin{aligned} \max_{\alpha, \alpha^*} & -\frac{1}{2}(\alpha^* - \alpha)^T K(A, A^T)(\alpha^* - \alpha) + Y^T(\alpha^* - \alpha) + \epsilon e^T(\alpha^* + \alpha) \\ \text{s. t.} & e^T(\alpha^* + \alpha) = 0 \\ & 0e \leq \alpha, \alpha^* \leq Ce \end{aligned} \quad (2)$$

KPP (2) çözüldükten sonra, $\alpha^{(*)} = (\alpha_1, \alpha_1^*, \alpha_2, \alpha_2^*, \dots, \alpha_n, \alpha_n^*)$ 'yı ve b eşliğini bulabiliriz ve sonra regresyon fonksiyonunu elde ederiz,

$$f(x) = \sum_{i=1}^n (\alpha^* - \alpha) K(x_i, x) + b \quad (3)$$

Burada, $K(x_i, x) = (\phi(x_i) \cdot \phi(x))$ kernel fonksiyonunu temsil etmektedir ve hiper uzayda nokta çarpımını vermektedir. α ve α^* Lagrange çarpanlarıdır ve $\alpha_i \alpha_i^* = 0, i = 1, 2, \dots, n$ 'ı sağlamaktadırlar. $f(x)$ fonksiyonu, sadece Lagrange çarpanları $\alpha_i \neq 0$ or $\alpha_i^* \neq 0$ olan örnekler (destek vektörleri) tarafından belirlenir. Ayrıca sırası ile $A = (x_1, x_2, \dots, x_n)$ ve $Y = (y_1, y_2, \dots, y_n)$ eğitim setinin girdi ve çıktılarını göstermektedir.

3.2. İkiz Destek Vektör Regresyonu

İkiz Destek Vektör Regresyonu (İDVR), görünüş itibarı ile ikiz destek vektör makinelerine (İDVM) benzerdir. Çünkü, veri noktaları çevresinde bir çift paralel olmayan düzlem elde etmektedir. Fakat, özünde bazı farklılıklar vardır. Birincisi, İDVR ve İDVM'nin amaçları farklıdır; İDVR uygun regresyon fonksiyonu bulmaya çalışırken, İDVM sınıflandırıcı oluşturmaktadır. İkincisi, İDVM'deki her iki KPP'nin her biri tipik bir SVM formülasyonuna sahiptir, fakat burada problemin kısıtlayıcılarının tüm unsurları aynı anda görünmez, ve tüm veri noktaları TVSR çiftinin iki KPP'sinin her birisinin sınırlandırıcılarında görünür. Üçüncüsü, İDVM her bir düzlemin iki sınıftan birine yakın olduğu ve diğerinden mümkün olduğunca uzak olduğu iki hiper düzlem bulur, fakat İDVR nihai regresör için üst sınır ve alt sınır " ϵ -duyarsız" fonksiyonları bulur.

DVM'nin hesaplama hızını iyileştirmek için Jayadeva, Khemchandani ve Chandra (2007) yakınsal DVM'nin (Fung ve Mangasarian, 2005; Ghorai, Mukherjee ve Dutta, 2009) ruhunda bulunan ikili veri sınıflandırması için İkiz Destek Vektör Makinesini (İDVM) önermiştir. İDVM iki daha küçük-ebatlı Karesel Programlama Problemini (KPP) çözerek paralel olmayan iki hiper düzlemi oluşturmaktadır ve burada her bir hiper düzlem bir sınıfa yakın ve birbirine mümkün olduğunca uzaktır. Büyük ölçekli bir KPP'nin çözülmesi yerine daha küçük-ölçekli iki KPP'nin çözülmesi stratejisi İDVM'nin öğrenme hızını standart DVM'in öğrenme hızının yaklaşık dört misline çıkarmaktadır. Günümüzde, İDVM düşük hesaplama karmaşıklığından dolayı popüler yöntemlerden biri haline gelmiştir. İDVM'nin birçok farklı formülasyonu Peng (2010), Kumar ve Gopal (2009), ve Jayadeva, Khemchandani ve Chandra (2007) tarafından önerilmiştir. Kesin olarak, yukarıda belirtilen algoritmalar sınıflandırma

problemleri için uygundur. Regresyon problemi ile ilgili olarak Peng (2010) etkili bir İDVR önermiştir.

Hesaplama hızını iyileştirmek için Peng (2010) İDVR olarak adlandırılan regresyon problemine yönelik etkili bir İDVM yaklaşımı önermiştir. İDVR, $f_1(x) = w_1^T x + b_1$ olarak ifade edilen bir alt sınır “ ϵ -duyarsız” fonksiyon ve $f_2(x) = w_2^T x + b_2$ ile gösterilen üst sınır “ ϵ -duyarsız” fonksiyonu elde etmektedir. Denklem 4’te verilen nihai regresyon fonksiyonu $f(x)$ bu iki fonksiyonun ortalaması alınarak elde edilir.

$$f(x) = \frac{1}{2}(f_1(x) + f_2(x)) = \frac{1}{2}(w_1 + w_2)^T x + \frac{1}{2}(b_1 + b_2) \quad (4)$$

İDVR aşağıdaki KPP çiftinin çözülmesi ile elde edilir,

$$\begin{aligned} \min_{w_1, b_1, \xi} \quad & \frac{1}{2} \|Y - e\epsilon_1 - (Aw_1 + eb_1)\|^2 + C_1 e^T \xi \\ \text{s. t.} \quad & Y - (Aw_1 + eb_1) \geq e\epsilon_1 - \xi, \\ & \xi \geq 0e \end{aligned} \quad (5)$$

ve

$$\begin{aligned} \min_{w_2, b_2, \eta} \quad & \frac{1}{2} \|Y - e\epsilon_2 - (Aw_2 + eb_2)\|^2 + C_2 e^T \eta \\ \text{s. t.} \quad & (Aw_2 + eb_2 - Y) \geq e\epsilon_2 - \eta, \\ & \eta \geq 0e \end{aligned} \quad (6)$$

burada C_1 , C_2 , ϵ_1 ve ϵ_2 a priori olarak seçilen parametrelerdir ve, ξ ve η yapay değişkenlerdir. Lagrange çarpanları α ve β ’yi kullanarak dual problemleri aşağıdaki gibi elde ederiz,

$$\begin{aligned} \max_{\alpha} \quad & -\frac{1}{2} \alpha^T G(G^T G)^{-1} G^T \alpha + f^T G(G^T G)^{-1} G^T \alpha - f^T \alpha \\ \text{s. t.} \quad & 0e \leq \alpha \leq C_1 e, \end{aligned} \quad (7)$$

ve

$$\begin{aligned} \max_{\beta} \quad & -\frac{1}{2} \beta^T G(G^T G)^{-1} G^T \beta + h^T G(G^T G)^{-1} G^T \beta - h^T \beta \\ \text{s. t.} \quad & 0e \leq \beta \leq C_2 e, \end{aligned} \quad (8)$$

burada, $G = [A \ e]$, $f = Y - e\epsilon_1$, ve $h = Y - e\epsilon_2$ olarak tanımlanmıştır.

Denklem (7) ve (8) verilen dual problemler çözüldükten sonra, (4)’teki $[w_1 \ b_1]$ ve $[w_2 \ b_2]$ ’yi aşağıdaki gibi elde edebiliriz:

$$[w_1 \ b_1]^T = (G^T G)^{-1} G^T (f - \alpha) \quad (9)$$

$$[w_2 \ b_2]^T = (G^T G)^{-1} G^T (h + \alpha) \quad (10)$$

Doğrusal olmayan durum için aşağıdaki KPP’ler çözülür.

$$\begin{aligned} \min_{w_1, b_1, \xi} \quad & \frac{1}{2} \|Y - e\epsilon_1 - (K(A, A^T)w_1 + eb_1)\|^2 + C_1 e^T \xi \\ \text{s. t.} \quad & Y - (K(A, A^T)w_1 + eb_1) \geq e\epsilon_1 - \xi, \\ & \xi \geq 0e \end{aligned} \quad (11)$$

ve

$$\begin{aligned} \min_{w_2, b_2, \eta} \quad & \frac{1}{2} \|Y - e\epsilon_2 - (K(A, A^T)w_2 + eb_2)\|^2 + C_2 e^T \eta \\ \text{s. t.} \quad & (K(A, A^T)w_2 + eb_2 - Y) \geq e\epsilon_2 - \eta, \\ & \eta \geq 0e \end{aligned} \quad (12)$$

benzer şekilde KPP (11) ve (12)'nin dual problemlerini aşağıdaki gibi elde edebiliriz:

$$\begin{aligned} \max_{\alpha} \quad & -\frac{1}{2} \alpha^T H(H^T H)^{-1} H^T \alpha + f^T H(H^T H)^{-1} H^T \alpha - f^T \alpha \\ \text{s. t.} \quad & 0e \leq \alpha \leq C_1 e, \end{aligned} \quad (13)$$

ve

$$\begin{aligned} \max_{\beta} \quad & -\frac{1}{2} \beta^T H(H^T H)^{-1} H^T \beta + h^T H(H^T H)^{-1} H^T \beta - h^T \beta \\ \text{s. t.} \quad & 0e \leq \beta \leq C_2 e, \end{aligned} \quad (14)$$

burada, $H = [K(A, A^T) e]$, $f = Y - e\epsilon_1$ ve $h = Y - e\epsilon_2$ olarak tanımlanmıştır.

(13) ve (14) dual KPP'ler çözüldükten sonra aşağıdaki sonuçları elde edebiliriz:

$$[w_1 \ b_1]^T = (H^T H)^{-1} H^T (f - \alpha) \quad (15)$$

$$[w_2 \ b_2]^T = (H^T H)^{-1} H^T (h + \alpha) \quad (16)$$

İDVR modeli bir çift KPP'den meydana gelmektedir. Her bir KPP standart DVR'ye kıyasla yalnız bir sınırlayıcı grubunu kullanarak yukarı veya aşağı doğru fonksiyonlardan birini tespit etmektedir. Bu nedenle, İDVR tek bir büyükten ziyade iki küçük ebatlı KPP'yi çözer, ve bu da İDVR'nin teoride standart DVR'den yaklaşık dört misli daha hızlı olduğu anlamına gelir.

4. Tedarikçi Seçme Kriterleri ve Değerlendirme

4.1. Tedarikçi Seçme Kriterleri

Tedarikçi seçme kriterleri ile ilgili sorunlara literatürde değinilmiştir (Guosheng ve Guohong, 2008; Guo ve diğerleri, 2009). Literatür araştırmasına dayanarak, Tablo 1'de verilen tedarikçi seçim kriterleri belirlenmiştir.

Tablo 1'de verilen seçim kriterleri uzmanlar tarafından sayısallaştırılmıştır. Örneğin, Tablo 1'deki 14 tedarikçi seçim kriteri değerleri beş uzman tarafından verilen puanların (0-100 arası) ortalamaları alınarak elde edilmiştir. Beyaz eşya üreten bir şirketin 92 tedarikçisi kullanılmıştır. Tedarikçi kredi endeksi ise çıktı değişkenidir. Yüksek puanlara sahip sonuçlar yüksek seçilme fırsatına sahip partnerleri temsil etmektedir.

Tablo 1. Tedarikçi Seçim Kriterleri

C1: Teslim Zamanı	C8: Uygun Depolama Yeri
C2: Fiyat	C9: Duyarlılık
C3: Kalite	C10: Profesyonel İş Gücü
C4: Çalışma Deneyimi	C11: Üretim Planlama Sistemi
C5: Nakliye	C12: Mali Güç
C6: Teslim Yeri	C13: Bilgi Teknolojileri
C7: Satış Sonrası Hizmetler	C14: Hizmet Kalitesi

4.2. Performans Kriterleri ve Öngörü Sonuçları

Ortalama Mutlak Hata (MAE), Ortalama Hata Karesi (MSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Hata Karesinin Kökü (RMSE) gibi istatistiksel kriterler DVR ve İDVR'nin tahmin performansının değerlendirilmesi ve kıyaslanması için kullanılmışlardır.

DVR ve İDVR'nin performansları esas olarak C ve γ parametrelerinin belirlenmesinden etkilenir (Cherkassky ve Ma, 2004; Lu, Lee ve Chiu, 2009). Bu çalışmada kernel fonksiyonu olarak radyal tabanlı fonksiyon (RBF) seçilmiştir. C ve γ 'nin seçilmesi için genel kural yoktur. En iyi C ve γ 'nin araştırılması için ağ arama (grid search) algoritması kullanılmıştır. Grid arama algoritmasında (C , γ) çiftleri denenmiştir ve en iyi çapraz doğrulama derecesine sahip olan çift seçilmiştir. DVR için, C ve γ ile ilgili bir ağ araması 10-kat çapraz doğrulama kullanılarak eğitim setinde uygulanmıştır. Ağ araması C ve γ (i.e., $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$; $\gamma = 2^{-20}, 2^{-3}, \dots, 2^4$)'nin üssel sonuçlarının değerlendirilmesi ile gerçekleştirilmiştir. Temel olarak, tüm (C , γ) denenmiştir ve Hsu, Chang ve Lin (2004) tarafından önerildiği gibi parametrelerin iki çifti en iyi çapraz onaylama doğruluğuna sahip biri ile kısıtlanmıştır. Bu optimal parametre çiftleri elde edildikten sonra, tüm eğitim seti tekrar denenmiştir. Görülmeyen bir veri setini doğrulamak için her iki sınıflandırıcı kullanılacaktır. İDVR için, düzenleme parametreleri C_1 ve C_2 üzerinde iki boyutlu ağ araması 2^{-7} ile 2^{12} arasındaki değerlere uygulanmıştır. Kernel fonksiyon parametreleri ve düzenleme parametreleri en iyi sınıflandırma doğruluğu için ayarlanmıştır. Kumar ve Kopal'de (2009) olduğu gibi 2^{-20} ile 2^4 aralığındaki en iyi kernel fonksiyon parametresi γ elde edilmiştir. Radyal tabanlı kernel fonksiyonu kernel fonksiyon olarak kullanılmıştır ve ayarlanacak olan birkaç parametreye sahiptir. Bu çalışmada kullanılan tekniklerin parametreleri aşağıda verilmiştir:

$$\text{DVR: } C = 10000, \gamma = 15 \text{ ve } \text{İDVR: } C_1 = 12000, \gamma_1 = 7, C_2 = 17000, \gamma_2 = 25$$

Parametrelerin belirlenmesinden sonra, Tablo 2'de gösterilen eğitim seti ($s1$ 'den $s65$ 'e kadar) ve doğrulama (test) seti ($s66$ 'dan $s92$ 'ye kadar) DVR ve İDVR'nin eğitilmesi ve test edilmesi için kullanılmıştır. Mevcut tedarikçi kredi endeksleri ve hatalar Tablo 3'te gösterilmiştir.

Tablo 2. Tedarikçi kredi endeks değerleri

Veri Seti	Tedarikçiler														Tedarikçi Kredi Endeksi (Performans Değerleme)
	Kriter														
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	
Eğitim Veri Seti															
s1	97	59	72	94	52	97	79	83	52	53	58	53	74	41	68.86
s2	93	77	48	63	86	44	59	100	80	98	75	52	78	37	70.71
s3	55	95	75	82	93	61	68	87	86	78	62	83	65	85	76.79
s4	89	50	35	35	51	38	65	97	85	85	30	40	58	48	57.57
s5	34	55	86	67	100	94	92	43	43	52	83	55	74	46	66.00
s6	77	50	32	65	78	91	48	66	92	81	75	36	57	72	65.71
s7	63	89	68	37	32	33	91	90	46	85	50	85	100	96	68.93
s8	71	47	70	60	76	88	56	62	38	35	38	85	91	66	63.07
s9	92	72	34	35	75	72	50	30	89	50	32	34	50	99	58.14
s10	77	81	47	54	56	35	36	65	37	52	94	80	95	68	62.64
s11	93	50	51	63	93	72	80	72	31	83	66	33	99	83	69.21
s12	60	85	65	95	63	72	54	49	76	69	53	91	75	34	67.21
.
.
s63	45	98	98	63	42	76	90	98	54	73	79	50	58	78	71.57
s64	37	57	74	58	61	70	35	53	36	65	75	85	44	89	59.93
s65	53	100	75	85	91	38	40	61	64	56	98	37	53	87	67.00
Test Veri Seti															
s66	79	61	75	56	94	83	42	33	83	90	43	79	78	41	66.93
s67	45	65	70	53	62	50	53	61	88	32	60	41	96	81	61.21
s68	73	61	94	85	51	69	95	85	63	66	60	83	77	56	72.71
s69	38	34	75	41	59	75	64	69	72	99	84	72	78	51	65.07
s70	53	50	36	93	74	90	30	35	34	69	51	75	41	92	58.79
s71	50	50	79	61	73	62	49	44	54	100	93	58	37	59	62.07
s72	75	64	77	59	72	75	34	63	76	37	48	90	32	30	59.43
.
.
s90	89	100	77	63	33	63	88	75	43	30	75	76	78	47	66.93
s91	91	52	36	67	71	77	70	74	94	56	35	40	31	100	63.86
s92	42	59	75	65	97	56	49	32	62	55	40	44	47	40	54.50

DVR ve İDVR için MSE, RMSE, MAE ve MAPE değerleri hesaplanmıştır. Bu istatistikler eğitim ve test örnekleri için verilmiştir. DVR eğitim setinde İDVR yönteminden daha iyi sonuç elde edilmiştir. Diğer yandan, test örneklerinde İDVR, DVR'den daha iyi çıkmıştır. Amacımız tedarikçi kredi endeksinin öngörme olduğunu, İDVR'nin DVR'den daha iyi sonuçlar verdiğini söyleyebiliriz (Tablo 4).

Tablo 3. DVR ve İDVR ile tedarikçi kredi endeksinin mevcut ve öngörülen değerleri

	S1	S2	S3	...	S90	S91	S92
Gerçek Değer	68.857	70.714	76.786	...	66.929	63.857	54.500
DVR	68.861	70.709	76.784	...	67.073	63.623	55.146
Hata	-0.003	0.005	0.002	...	-0.145	0.235	-0.646
İDVR	68.970	70.890	75.740	...	66.950	63.990	54.590
Hata	-0.113	-0.176	1.046	...	-0.021	-0.133	-0.090

Tablo 4. DVR ve İDVR yöntemlerinin performanslarının karşılaştırılması

Yöntem	Eğitim Veri Seti				Test Veri Seti			
	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
DVR	0.115	0.339	0.283	0.440	0.109	0.331	0.280	0.438
İDVR	0.236	0.485	0.255	0.402	0.086	0.293	0.216	0.333

5. Sonuç

Tedarik zinciri yönetimi son yıllarda çok popüler bir araştırma alanıdır ve tedarikçi seçimi tedarik zinciri yönetiminde oldukça önemli ve zordur. Aynı zamanda tedarikçi seçimi çok fazla faktörden etkilenmektedir ve bunların geleneksel yöntemlerle belirlenmesi çok karmaşık bir işlemdir.

Bu çalışmada Destek Vektör Regresyonuna (DVR) dayanan akıllı bir yöntem, ev gereçleri sektöründe faaliyet gösteren bir firmanın tedarikçilerinin tedarikçi kredi endeks değerlerinin öngörülmesi için önerilmiştir. Söz konusu yöntem yüksek güvenilirlik ve aşırı tahminden kaçınma özellikleri ile diğerlerinden daha fazla avantaja sahiptir. Yukarıda belirtilen mevcut araştırmadan, İDVR algoritmasının eğitim ve test hassasiyeti konusunda DVR yönteminden daha üstün olduğu sonucu çıkarılabilir. İDVR algoritması tedarikçi seçimi problemini etkili bir şekilde çözebilmekte ve tedarikçi değerlendirme ve seçiminde güçlü bir matematiksel araç sağlamaktadır.

İDVR algoritması genel öngörüye iyi bir şekilde uymaktadır. Önerilen model mevcut verilere dayanan öğrenme ile ilgili ve kesin ve belirgin olmayan bilgileri desteklemektedir. Türkiye'deki ev cihazları sektöründe yapılan bir vaka çalışması sunulmuştur. Küreselleşme diğer firmaların kaynaklarını kullanmak isteyen firmalar için çeşitli fırsatlar yaratmaktadır. Fakat, karar alma ile ilgili çeşitli hususların göz önünde bulundurulması gerekir. Tedarikçilerin seçilmesi ile ilgili kararlar karmaşık hale gelebilir. Çünkü, karar alma sürecinde birbiri ile çelişkili çeşitli faktörlerin göz önünde bulundurulması gerekir. Tedarikçi seçilmesi ile ilgili gerçek veri seti kullanılarak, İDVR'nin sonuçları performans notunun tahmin edilmesi için destek vektör regresyonu (DVR) tekniği ile kıyaslanmıştır. Toplam 65 eğitim veri puanı ve 27 test veri puanı elde edilmiştir. Bu nedenle gerçek veri seti, eğitim ve test veri setine %70 ile %30 oranında bölünmüştür. Sonuç olarak, MAE, MSE, MAPE, ve RMSE dahil olmak üzere genel istatistik ölçütleri aracılığı ile kıyaslanma ile İDVR modelinin daha iyi bir genel performansa sahip olduğu ve daha düşük tahmin hatası verdiği sonucuna varılmıştır. Notun öngörülmesi ile ilgili İDVR modelinin performansları giriş parametrelerinin değerinden etkilenmektedir. Diğer bir araştırma olarak, tedarik zinciri yönetiminin diğer herhangi bir alanında üst yöneticiler için doğru karar almaya yönelik olarak İDVR modelinin uygulanması ilginç bir konu olabilir.

6. Referanslar

- Abdollahi, M., Arvan, M. ve Razmi, J. (2015). An integrated approach for supplier portfolio selection: Lean or agile?, *Expert Systems with Applications*, 42(1), 679-690.
- Arikan, F. ve Kucukce, Y.S. (2012). A supplier selection-evaluation problem for the purchase action and its solution, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 27(2), 255-264.
- Bruno, G. ve Esposito, E., Genovese, A., Passaro, R. (2012). AHP-based approaches for supplier evaluation: Problems and perspectives, *Journal of Purchasing and Supply Management*, 18(3), 159-172.
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition, *Data Mining Knowledge Discovery*, 2(2), 121- 167.

- Cherkassky, V. ve Ma, Y. (2004). Practical selection of SVM parameters and noise estimation for SVM regression, *Neural Networks*, 17, 113–126.
- Choi, T.Y. ve Hartley, J.L. (1996). An exploration of supplier selection practices across the supply chain, *Journal of Operations Management*, 14(4), 333–343.
- Choy, K.L. ve Lee, W.B. (2002). A generic tool for the selection and management of supplier relationships in an outsourced manufacturing environment: the application of case based reasoning, *Logistics Information Management*, 15(4), 235–253.
- Choy, K.L., Lee, W.B. ve Lo, V. (2003). Design of an intelligent supplier relationship management system: A hybrid case based neural network approach, *Expert Systems with Applications*, 24(2), 225–237.
- Choy, K.L., Lee, W.B., Lau, H.C.W., Lu, D. ve Lo, V. (2004). Design of an intelligent supplier relationship management system for new product development, *International Journal of Computer Integrated Manufacturing*, 17(8), 692–715.
- Dagdeviren, M. ve Eraslan, E. (2008). Supplier selection using promethee sequencing method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 23(1), 69-75.
- Fung, G. ve Mangasarian, O. (2005). Multicategory proximal support vector machine classifiers, *Machine Learning*, 59, 77–97.
- Ghorai, S., Mukherjee, A. ve Dutta, P. (2009). Nonparallel plane proximal classifier, *Signal Processing*, 89(4), 510–522.
- Gunes, T. ve Polat, E. (2009). Feature selection in facial expression analysis and its effect on multi-svm classifiers, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 24(1), 7-14.
- Guo, X., Yuan, Z. ve Tian, B. (2009). Supplier selection based on hierarchical potential support vector machine, *Expert Systems with Applications*, 36(3), 6978-6985.
- Guo, X., Zhu, W. ve Shi, J. (2014). Integration of semi-fuzzy SVDD and CC-Rule method for supplier selection, *Expert Systems with Applications*, 41(4), 2083-2097.
- Guosheng, H. ve Guohong, Z. (2008). Comparison on neural networks and support vector machines in suppliers' selection, *Journal of Systems Engineering and Electronics*, 19(2), 316-320.
- Hsu, C.-W., Chang, C.-C. ve Lin, C.-J. (2004). *A practical guide to support vector classification*. Technical Report, Department of Computer Science and Information Engineering, National Taiwan University.
- Ince, H. ve Trafalis, T.B. (2007). Kernel principal component analysis and support vector machines for stock price prediction, *IIE Transactions*, 39(6), 629-637.
- Ince, H. ve Trafalis, T.B. (2008). Short term forecasting with support vector machines and application to stock price prediction, *International Journal of General Systems*, 37(6), 677-687.
- Jain, V., Wadhwa, S. ve Deshmukh, S.G. (2007). Supplier selection using fuzzy association rules mining approach, *International Journal of Production Research*, 45(6), 1323–1353.
- Jayadeva, Khemchandani, R. ve Chandra, S. (2007). Twin support vector machines for pattern classification, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(5), 905–910.
- Juang, C.-F. ve Shiu, S.-J. (2008). Using self-organizing fuzzy network with support vector learning for face detection in color images, *Neurocomputing*, 71(16-18), 3409-3420.
- Kao, C. ve Liu, S.-T. (2000). Fuzzy efficiency measures in data envelopment analysis, *Fuzzy Sets and Systems*, 113(3), 427–437.
- Kar, A.K. (2015). A hybrid group decision support system for supplier selection using analytic hierarchy process, fuzzy set theory and neural network, *Journal of Computational Science*, 6(1), 23-33.
- Kim, H.-C., Pang, S., Je, H.-M., Kim, D. ve Bang, S.Y. (2003). Constructing support vector machine ensemble, *Pattern Recognition*, 36(12), 2757-2767.
- Kumar, M. ve Gopal, M. (2009). Least squares twin support vector machines for pattern classification, *Expert Systems with Applications*, 36(4), 7535–7543.
- Kuo, R.J. ve Lin, Y.J. (2012). Supplier selection using analytic network process and data envelopment analysis, *International Journal of Production Research*, 50(11), 2852-2863.

- Kuo, R.J., Hong, S.M., Lin, Y. ve Huang, Y.C. (2008). Continuous genetic algorithm-based fuzzy neural network for learning fuzzy IF–THEN rules, *Neurocomputing*, 71(13-15), 2893–2907.
- Kuo, R.J., Hong, S.Y. ve Huang, Y.C. (2010). Integration of particle swarm optimization-based fuzzy neural network and artificial neural network for supplier selection, *Applied Mathematical Modelling*, 34, 3976–3990.
- Kuo, R.J., Lee, L.Y. ve Hu, T.-L. (2008). An intelligent decision support system for supplier selection, *Proceedings of Tenth International Conference on Enterprise Information Systems*, June 12–16, Barcelona – Spain, 241–248.
- Kuo, R.J., Wang, Y.C. ve Tien, F.C. (2010). Integration of artificial neural network and MADA methods for green supplier selection, *Journal of Cleaner Production*, 18(12), 1161–1170.
- Lau, H.C.W., Lee, C.K.M., Ho, G.T.S., Pun, K.F. ve Choy, K.L. (2006). A performance benchmarking system to support supplier selection, *International Journal of Business Performance Management*, 8(2–3), 132–151.
- Li, Y., Xia, J., Zhang, S., Yan, J., Ai, X. ve Dai, K. (2012). An efficient intrusion detection system based on support vector machines and gradually feature removal method, *Expert Systems with Applications*, 39(1), 424–430.
- Lu, C.J., Lee, T.S. ve Chiu, C.C. (2009). Financial time series forecasting using independent component analysis and support vector regression, *Decision Support Systems*, 47(2), 115–125.
- Luo, X., Wu, C., Rosenberg, D. ve Barnes, D. (2009). Supplier selection in agile supply chains: An information-processing model and an illustration, *Journal of Purchasing & Supply Management*, 15, 249–262.
- Mohanty, R.P. ve Deshmukh, S.G. (1993). Using of analytic hierarchic process for evaluating sources of supply, *International Journal of Physical Distribution & Logistics Management*, 23(3), 22–28.
- Narasimhan, R., Talluri, S. ve Mendez, D. (2001). Supplier evaluation and rationalization via data envelopment analysis: an empirical examination, *Journal of Supply Chain Management*, 37(3), 28–37.
- Noorul Haq, A. ve Kannan, G. (2006). Design of an integrated supplier selection and multi-echelon distribution inventory model in a built-to-order supply chain environment, *International Journal of Production Research*, 44(10), 1963–1985.
- Nydick, R.L. ve Hill, R.P. (1992). Using the analytic hierarchy process to structure the supplier selection procedure, *International Journal of Purchasing and Materials Management*, 28(2), 31–36.
- Peng, X. (2010). TSVM: an efficient twin support vector machine for regression, *Neural Networks*, 23(3), 365–372.
- Sagiroglu, S., Yolacan, E.N. ve Yavanoglu, U. (2011). Designing and developing an intelligent intrusion detection system, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 26(2), 325–340.
- Sun, H.-L., Xie, J.-Y. ve Xue, Y.-F. (2005). An SVM-based model for supplier selection using fuzzy and pairwise comparison, *In Proceedings of 2005 international conference on machine learning and cybernetics*, 6, 3629–3633.
- Talluri, S. (2002). Enhancing supply decisions through the use of efficient marginal costs models, *Journal of Supply Chain Management*, 38(4), 4–10.
- Talluri, S. ve Narasimhan, R. (2005). A note on a methodology for supply base optimization, *IEEE Transactions on Engineering Management*, 52(1), 130–139.
- Talluri, S. ve Narasimhan, R. (2003). Vendor Evaluation with performance variability: a max-min approach, *European Journal of Operational Research*, 146(3), 543–552.
- Talluri, S., Narasimhan, R. ve Nair, A. (2006). Vendor performance with supply risk: a chance-constrained DEA Approach, *International Journal of Production Research*, 100(2), 212–222.
- Tseng, M.-L., Chiang, J.H. ve Lan, L.W. (2009). Selection of optimal supplier in supply chain management strategy with analytic network process and choquet integral, *Computers & Industrial Engineering*, 57(1), 330–340.

- Vahdani, B., Iranmanesh, S.H., Meysam Mousavi, S. ve Abdollahzade, M. (2012). A locally linear neuro-fuzzy model for supplier selection in cosmetics industry, *Applied Mathematical Modelling*, 36(10), 4714-4727.
- Vapnik, V. N. (1998). *Statistical learning theory*. New York: Wiley.
- Weber, C.A. ve Ellram, L.M. (1992). Supplier selection using multi-objective programming: a decision support system approach, *International Journal of Physical Distribution & Logistics Management*, 23(2), 3-14.
- Weber, C.A., Current, J. ve Desai, A. (2000). An optimization approach to determining the number of vendors to employ, *Supply Chain Management: An International Journal*, 5(2), 90-98.
- Wen, L. ve Li, J. (2006). Research of credit grade assessment for suppliers based on multi-layer SVM classifier, *In Proceedings of the sixth international conference on intelligent systems design and applications*, 1, 207-211.
- Wu, D. (2009). Supplier selection: A hybrid model using DEA, decision tree and neural network, *Expert Systems with Applications*, 36, 9105-9112.
- Wu, T. ve Blackhurst, J. (2009). Supplier evaluation and selection: an augmented DEA approach, *International Journal of Production Research*, 47(16), 4593-4608.