

Eylem Öğrenmenin Okul Yöneticileri ve Yönetici Adaylarının Karar Vermelerine Etkisinin Veri Madenciliği Teknikleri ile İncelenmesi

¹Dönüş Şengür, ²Muhammed Turhan, ³Songül Karabatak
1Şht.Pyd. Bnb. Zafer KILIÇ Anadolu İmam Hatip Lisesi, Elazığ/Türkiye
2 Fırat Üniversitesi, Eğitim Fakültesi, Elazığ/Türkiye
3 Fırat Üniversitesi, Enformatik Bölümü, Elazığ/Türkiye
e-mail: kdksengur@gmail.com

(Geliş/Received:09.07.2018; Kabul/Accepted:27.08.2018)

Özet

Etkili okul yöneticilerinde olması gereken özelliklerden biri de doğru karar verebilmedir. Yöneticilerin verdiği doğru kararlar, örgütün ayakta kalabilmesi için oldukça önemlidir. Doğru ve rasyonel karar verebilme ise okul yöneticisinin değerleri, bilgi ve becerileri ile yakından ilişkilidir ve okul yöneticilerinin doğru karar verebilmesi için bu konuda iyi yetişmiş olmaları gereklidir. Eylem öğrenme, karmaşık ve gerçek sorunlar üzerinde çalışmak amacıyla bir araya gelmiş bir grup gönüllü meslektaşın sürekli öğrendikleri ve öğrendiklerini yansıttıkları bir süreçtir. Bu çalışmada, eylem öğrenme sürecinin okul yöneticileri ile yönetici adaylarının karar vermelerinde herhangi bir etkisinin olup olmadığı veri madenciliği teknikleri ile incelenmiştir. Bu bağlamda eğitimci veri madenciliği yöntemlerinden karar ağaçları, diskriminant analizi, destek vektör makineleri (DVM), k-en yakın komşu (k-EYK) ve birleştirilmiş öğrenciler yöntemleri kullanılmıştır. Çalışmada verilerin toplanması için Melbourne Karar Verme Ölçeği I-II (MKVÖ) kullanılmıştır. 38 katılımcı ile gerçekleştirilen eylem öğrenme süreci öncesinde ve sonrasında testler katılımcılara uygulanarak veriler toplanmıştır. Gerçekleştirilen deneysel çalışmada, eylem öğrenme sürecine katılan okul yöneticisi ve adaylarının karar vermelerindeki anlamlı değişikliklerin veri madenciliği teknikleri ile yüksek doğrulukla belirlendiği görülmüştür. Ayrıca, DVM tekniklerinin, karar ağaçları, birleştirilmiş sınıflandırıcılar ve k-EYK yöntemlerine oranla daha başarılı sonuçlar ürettiği görülmüştür.

Anahtar Kelime: Okul yöneticisi yetiştirme, Eylem öğrenme, Karar verme, Veri madenciliği teknikleri, Sınıflandırma.

Data Mining Techniques Based Analysis of the Impact of Action Learning on Decision-Making Styles of School Administrators and Administrator Candidates

Abstract

One of the qualities, that effective school administrators should have, is making right decisions. The right decisions made by the organizational management are very important for the organization to survive. Right and rational decision making is closely related to the values, knowledge and skills of the school administrator and school administrators need to be well trained in this area so they can make the right decisions. Action learning is a process in which a group of volunteer colleagues who come together to work on complex and real problems reflect on what they are constantly learning. In this study, data mining techniques were used to examine whether action learning had any influence on school administrators and candidates' decision making. In this context, some of the data mining techniques such as, decision trees, discriminant analysis, support vector machines (SVM), k-nearest neighbors (k-NN) and ensemble learner methods are used. In order to collect data set, an experimental organization was constructed where 38 participants were applied a pre-test and a post-test of Melbourne Decision Making Questionnaire I-II (MDMQ). In the experimental study, it is seen that data mining techniques are quite successful in determining of the significant changes in decision making of school administrators and candidates who attended the action learning process. In addition, SVM techniques have shown better performance than decision trees, ensemble classifiers, and k-NN methods.

Keywords: School administrator training, action learning, decision making, data mining methods, classification.

1. Giriş

Son yıllarda örgütsel ve yönetsel anlayıştaki değişim, eğitim sistemlerinde de birtakım değişimleri zorunlu hale getirmiş ve bu durum okul yöneticilerinden beklenen davranışları da etkilemiştir. Okul yöneticilerinin okullarını yönetebilmeleri için sahip olmaları gereken bilgi, beceri ve üstlenilen rollerin de gitgide değişiklik göstermesine neden olmuştur. Okul yöneticileri 1940’larda yalnızca “yönetici ve denetçi” olarak tanımlanırken zamanla “problem çözen, vizyoner, değişim ajanı, dönüşümcü lider, kolaylaştırıcı” gibi çok daha fazla beceri ve yeterlik gerektiren sıfatlarla tanımlanmaya başlamıştır [1-4].

Okul yöneticilerinin zamanla değişen rolleri incelendiğinde okulu yönetici veya denetçi sıfatıyla yönetecek bir kimsenin çağın gerektirdiklerine cevap verebilmesi, dolayısıyla etkili bir okul yöneticisi olabilmesi pek mümkün görünmemektedir. Okul yöneticilerinin 21. yüzyılın gerektirdiği karmaşık yapıdaki ihtiyaç ve beklentileri karşılayarak etkili birer okul yöneticisi olabilmeleri için uluslararası düzeyde birtakım beceri ve yeterliklere sahip olması önemli görülmektedir [5, 6]. Bu ihtiyaçları karşılayabilecek eğitim programlarının içeriğinin de yöneticilerin mesleki yaşamlarında karşılaşılabilecekleri sorunlarla başa çıkabilmelerini sağlayacak türde hazırlanmaları gerekmektedir [7, 8]. Birçok okul yöneticisi geliştirme programında, okul yöneticilerinin bilgi, beceri ve kapasitelerine katkıda bulunan, yetişkin öğrenmesine dayalı olarak daha dinamik öğrenme deneyimlerine imkân tanıyan köklü ve güçlü pedagojik uygulamaların kullanımının üstünde durulmaktadır [9, 10]. Türkiye için de bu tür uygulamalara duyulan ihtiyaç birçok araştırmada [11-17] dile getirilmiştir. Eylem öğrenme bu programlarda tercih edilen metotlardan biridir [18]. Çünkü eylem öğrenme, liderlik becerilerinin geliştirilmesinde oldukça etkili ve güçlü bir öğrenme metodu olarak belirtilmektedir [19-26].

Eylem öğrenme, gerçek zamanlı bir sosyal öğrenme sürecidir [26]. Bu sürecin “babası” kabul edilen Revans [27-29], eylem öğrenmeyi bir cümle ile tanımlamaktan kaçınmış ve bu yaklaşımın tek bir biçiminin olmadığını, tek bir formül ya da bir teknik olarak görülmemesi

gerektiğini dile getirmiştir. [30]’a göre eylem öğrenme; bireyin, ekibin, örgütün ve hatta bütün sistemin değişmesi için öğrenme ve problem çözme becerisi kazandırabilen bir yaklaşımdır. Ayrıca eylem öğrenme, karmaşık ve gerçek sorunlar üzerinde çalışmak amacıyla bir araya gelmiş bir grup gönüllü meslektaşın sürekli öğrendikleri ve öğrendiklerini yansıttıkları bir süreç olarak da tanımlanmaktadır [31]. Bu tanımlamalardan yola çıkarak eylem öğrenmeyi, bir grup insanın bir araya gelerek bir sorun hakkındaki deneyim ve fikirlerini paylaştıkları ve bireyi soruna karşı çözüm üretip hayata geçirmesine teşvik eden bir süreç olarak tanımlamak mümkündür.

Etkili okul yöneticilerinde olması gereken özelliklerden biri de doğru karar verebilmedir. Örgüt yönetiminin verdiği doğru kararlar, örgütün ayakta kalabilmesi için oldukça önemlidir. Doğru ve rasyonel karar verebilme ise okul yöneticisinin değerleri, bilgi ve becerileri ile yakından ilişkilidir ve okul yöneticilerinin doğru kararlar verebilmesi için bu konuda iyi yetişmiş olmaları gereklidir [32]. Bu nedenle okul yöneticisi yetiştirme programları hazırlanırken karar verme becerilerine olumlu katkı sağlayabilecek içeriklerin dahil edilmesi gerektiği söylenebilir.

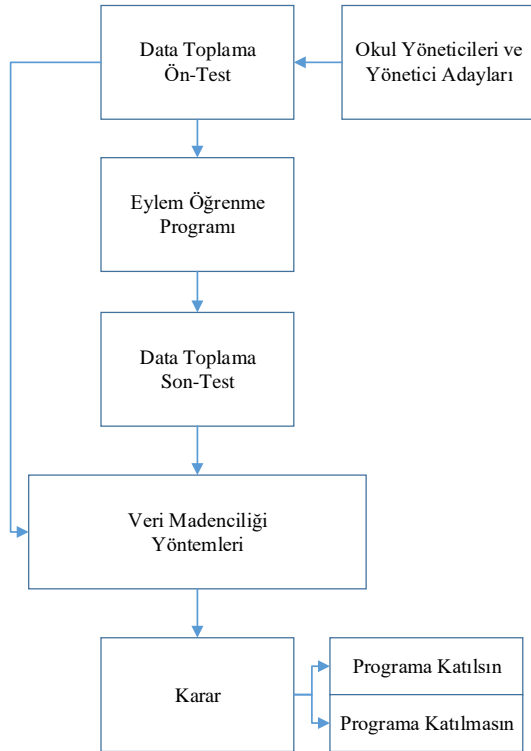
Bu çalışma ile okul yöneticisi yetiştirme programlarında da sıklıkla kullanılan eylem öğrenmenin yönetici ve yönetici adaylarının karar verme becerilerine etkisinin olup olmadığı belirlenmesi amaçlanmıştır. Bu amaçla gerçekleştirilen programın etkililiğinin belirlenmesi için veri madenciliği teknikleri kullanılmıştır. Karar ağaçları, diskriminant analizi, destek vektör makineleri (DVM), k-en yakın komşu (k-EYK) yöntemi ve birleştirilmiş öğrenciler gibi iyi bilinen veri madenciliği yöntemleri kullanılmıştır. Okul yöneticileri ve yönetici adaylarına program öncesinde bir ön-test ve program sonrasında da bir son-test uygulanmıştır. Programın okul yöneticileri ve yönetici adayları üzerindeki anlamlı etkisi veri madenciliği ile değerlendirilmiştir. Ayrıca programa katılmayan yeni yönetici adaylarının karar verme yeteneklerini geliştirmek için bu programa ihtiyacı olup olmadığı yine veri madenciliği analizleri ile ortaya konabilecektir.

Çalışmanın organizasyonu şöyledir; ikinci bölümde yöntem, veri toplama, çalışma gurubu,

veri madenciliği yöntemlerinden bahsedilmiştir. Bölüm 3’de deneysel çalışmalar ve elde edilen sonuçlar verilmiştir. Nihayet son bölümde ise elde edilen sonuçlar irdelenmiştir.

2. Materyal ve Metot

Çalışmada benimsenen yöntemin blok gösterimi Şekil 1’de verilmiştir. Şekil 1’den de görüleceği üzere, okul yöneticileri ve yönetici adaylarına hem eylem öğrenme programı öncesinde hem de sonrasında testler uygulanmaktadır. Program öncesinde ve sonrasında okul yöneticileri ve yönetici adaylarının karar vermesindeki olumlu etki veri madenciliği yöntemleri ile tahmin edilmektedir.



Şekil 1. Önerilen yöntemin blok gösterimi

2.1. Verilerin toplanması

Çalışmada verilerin toplanması için Mann vd. [33] tarafından geliştirilen ve Deniz [34] tarafından Türkçeye uyarlanan Melbourne Karar Verme Ölçeği I-II (MKVÖ) kullanılmıştır. Ölçek iki kısımdan oluşmaktadır. Ölçeğin birinci kısmı, karar vermede özsaygının belirlenmesi için hazırlanmıştır. Bu kısım, üçü ters olmak üzere altı maddeden oluşmaktadır. Ölçeğin ikinci kısmı

ise; karar verme stillerinin ölçüldüğü 22 maddeden oluşmaktadır. Dikkatli (6 madde), kaçınan (6 madde), erteleyici (5 madde) ve panik (5 madde) karar verme stillerinden oluşan dört alt faktörden oluşmaktadır [34].

2.2. Çalışma grubu

Araştırmada yer alan katılımcılar tesadüfi/seçkisiz olmayan örnekleme tekniklerinden amaçlı örnekleme yöntemi ile belirlenmiştir. Tesadüfi/seçkisiz olmayan örnekleme tekniğinden olan amaçlı örnekleme, çalışmanın amacına uygun, birtakım ölçütleri karşılayan ya da belli özellikleri taşıyan katılımcıların araştırmada yer alması gerektiğinde tercih edilen bir yöntemdir [35, 36]. Bu bağlamda araştırmanın amacı doğrultusunda katılımcıların belirlenmesinde gönüllülük kriterine dikkat edilmiştir. Ayrıca her bir grubun üyeleri seçilirken farklı deneyimlere sahip olmaları göz önünde bulundurulmuştur; yöneticilik deneyimi olan kimseler farklı gruplara dahil edilerek sürecin daha verimli olması sağlanmıştır. Eğitime katılanların demografik özellikleri Tablo 1’de gösterildiği gibidir.

Tablo 1. Katılımcıların Demografik Özellik Tablosu

Öğretmen	%	Yönetici	%	Yöneticilik Deneyimi
25	66	13	34	15

Tablo 1’de görüldüğü gibi deney grubu 38 katılımcıdan meydana gelmiştir. Bu grubun 25’i (%66) öğretmen ve 13’ü’ (%34) yöneticidir. Tabloda belirtildiği üzere, 15 katılımcı yöneticilik deneyimine sahiptir.

2.3. Verilerin analizi

Verilerin analizi sürecinde veri madenciliği teknikleri kullanılmıştır. Veri madenciliği, işlenmemiş ham verinin işlenerek değerli hale getirildiği süreç olarak tanımlanabilir. Veri madenciliğinde, veri kümeleme veya etiketleme, birliktelik kuralları ve veri dizileri analizi olarak adlandırılan üç temel bileşen bulunmaktadır. Bu çalışmada veri madenciliğinin veri kümeleme (veri sınıflandırma) ve etiketleme bileşenleri kullanılmıştır. Veri etiketleme, hem eğiticili

(danışmanlı) hem de eğiticiyiz (danışmansız) olarak gerçekleştirilmektedir. Eğiticiyiz sınıflandırma işleminde, veriler, belirlenen bir dizi kuralların yardımıyla bir dizi kümeye ayrılırlar. Eğiticiyiz sınıflamada ise sınıf etiketleri bilinen bir grup veri kullanılarak veriler ile sınıf etiketleri arasında bir bağ kurulmaya çalışılır ve bu bağ daha sonra sınıf etiketleri bilinmeyen veri elemanlarının sınıflandırılması için kullanılır [37, 38].

2.3.1. Karar ağaçları

Karar ağaçları iyi bilinen, etkili ve çok kullanılan veri sınıflandırma yaklaşımıdır [39]. Ayrıca karar ağaçları parametrik olmayan eğiticiyiz sınıflandırma yöntemi olarak da bilinirler. Karar ağaçlarının amacı, girdi veri kümesinden elde edilen basit karar kurallarını öğrenerek bir test örneğinin sınıf etiketini tahmin eden bir model oluşturmaktır. Bir karar ağacının yapısı, sırasıyla, yaprak ve iç düğüm gibi iki tür düğüm içerir. Bir yaprak, o yaprağa ulaşan eğitim örneklerinin çoğunluğunun oyu ile belirlenen bir sınıf etiketini tutar. Ayrıca, her iç düğüm, özelliklerle ilgili bir sorudur ve bu sorunun cevabına göre dallanmalar oluşturulmaktadır.

2.4. Diskriminant analiz

Diskriminant analizi, bir test örneğini sınıflandırmak için kullanılan giriş özelliği alanına dayalı bir dizi denklem üretir [40]. Diskriminant analizi, iki olası amacı göz önünde bulundurur. İlk amaç, bir test örneğini sınıflandırmak için tahmini bir denklem bulur. İkinci amaç, özellikler arasında var olabilecek ilişkileri daha iyi anlamak için tahmin edici denklemi yorumlamaya zorlamaktır.

2.3.3. Destek vektör makineleri (DVM)

Destek vektör makineleri (DVM), sınıflandırma ve regresyon problemleri için kullanılan, istatistiksel öğrenme teorisine dayalı iyi bilinen bir makine öğrenmesi yöntemidir [41]. Genel olarak DVM tekniği, başlangıçta iki sınıflı doğrusal olarak ayırt edilebilen verilerin sınıflandırılması için tasarlanmış olsa da teknik daha sonra çok sınıflı ve doğrusal olmayan

verilerin sınıflandırılması için geliştirilmiştir. DVM, sınıflandırılacak öznitelikleri, öznitelik uzayında inceler ve sınıflar arasındaki sınırı belirleyecek optimum hiper düzlemi bulmak için optimizasyon algoritmaları kullanır.

2.3.4. k-EYK

k-en yakın komşular (k-EYK) sınıflandırıcısı en basit, etkili ve parametrik olmayan sınıflandırma yaklaşımı olarak bilinir [42]. k-EYK sınıflandırma prosedüründe, tüm eğitim verileri, önceden belirlenmiş bir mesafe fonksiyonuna ve en yakın k komşu sayısına göre test verisinin sınıflandırılması için kullanılır. Diğer bir ifade ile, k-EYK yaklaşımı başlangıçta Öklit, Mahalanobis ve vb. bir mesafe fonksiyonu ile test örneği ve eğitim örnekleri arasında bir benzerlik ölçüsü hesaplar. Daha sonra, hesaplanan benzerlik ölçümüne dayanarak, test örneğinin k-en yakın komşuları belirlenir. Test örneğinin sınıf etiketi, önceden belirlenmiş k en yakın komşuların etiketlerinin çoğunluk oyu ile belirlenir.

2.3.5. Birleştirilmiş sınıflandırıcılar

Birleştirilmiş sınıflandırıcıların, özgün sınıflandırıcılardan oluştuğu bilinmektedir [43]. Diğer bir deyişle, bir birleştirilmiş sınıflandırıcı, özgün sınıflandırıcıların kararlarını bir şekilde birleştirerek örnek bir test sınıfı etiketi belirler. Birleştirilmiş sınıflandırıcı, çoğu zaman onu oluşturan özgün sınıflandırıcılardan çok daha iyi bir başarı elde eder. Belirtildiği gibi, birleştirilmiş sınıflandırıcı çeşitli sınıflandırıcıların kararını birleştirmek için torbalama ve hızlandırma gibi bazı yöntemler kullanır. Torbalama ve hızlandırma, veri madenciliği uygulamalarında yaygın olarak kullanılan iki iyi bilinen birleştirilmiş sınıflandırıcı yöntemidir. Torbalama, orijinal veri kümesinden eğitim için ek veri üretmek tahminlerin varyansını azaltır. Bu, orijinal verilerle aynı boyuttaki çoklu kümeler üretmek için tekrarlamalı kombinasyonlar kullanılarak gerçekleştirilir. Eğitim setinin artan büyüklüğü sadece varyansı azaltmakta, beklenen sonuca göre tahmini pek az farkla düzenlemektedir. Ayrıca, hızlandırma iki aşamalı bir yaklaşım olduğu bilinmektedir. İlk aşamada, bir dizi ortalama performans gösteren model üretmek

için orijinal verilerin alt kümelerini kullanır. İkinci aşamada ise, önceki performansların oylama şeması kullanılıp birleştirilmesiyle performans artırılır [43].

3. Deneysel Sonuçlar

Bu çalışmada kullanılan bütün veri madenciliği teknikleri MATLAB ortamında uygulanmıştır. Ayrıca çalışmada kullanılan very seti EK-1'de verilmiştir. Veri madenciliği teknikleri ile yapılan deneylerde iki farklı senaryo ele alınmıştır. Bunlardan birincisinde, eylem öğrenme eğitim sürecine katılmış ve katılmamış okul yöneticisi ve yönetici adaylarının oluşturduğu kümelenmeleri tahmin etmek için 28 ölçek maddesinin tümü kullanılmıştır. İkinci senaryoda ise her ölçek boyutu kendi içinde eğitime katılmış ve eğitime katılmamış okul yöneticisi veya adaylarını (kümelenmeleri) tahmin etmek için kullanılmıştır. Elde edilen en iyi doğruluk değerleri kalın yazı tipiyle gösterilmiştir. Tablo 2, ilk senaryo için elde edilen doğruluk değerlerini göstermektedir. Tablo 2'de görüldüğü üzere, doğruluk değerleri %47,4 ile %98,7 arasında dağılmaktadır. Diğer bir deyişle, en düşük doğruluk oranı olan %47,4 değeri ham k-EYK, hızlandırılmış ağaçlar ve RUSboost ağaçlar teknikleri tarafından üretilirken, en yüksek doğruluk olan %98,7 değeri ise kübik DVM, ağırlıklı k-EYK ve Altuzay EYK sınıflandırıcıları tarafından üretilmiştir.

Tüm karar ağaçları teknikleri %89,5'lük doğruluk değeri üretirken, doğrusal diskriminant

Tablo 2. Birinci senaryo için elde edilen tahmin doğruluk değerleri

Veri Yöntemi	Madenciliği Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	89,5
	Orta Ağaç	89,5
	Ham Ağaç	89,5
Diskriminant Analiz	Doğrusal	94,7
	Diskriminant	80,3
	Kuadratik	
DVM	Doğrusal DVM	97,4
	Kuadratik DVM	97,4
	Kübik DVM	98,7
	İyi Gaussian DVM	57,9
	Orta Gaussian DVM	93,4
	Ham Gaussian DVM	63,2
	k-EYK	İyi k-EYK
Orta k-EYK		97,4
Ham k-EYK		47,4
Kosinüs k-EYK		89,5
Kübik k-EYK		96,1
Ağırlıklı k-EYK		98,7
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	47,4
	Torbalı Ağaçlar	93,4
	Altuzay	94,7
	Diskriminant	98,7
	Altuzay EYK	
RUSBoost Ağaçları	47,4	

yöntemi %94,7 ve kuadratik diskriminant yöntemi %80,3'lük bir doğruluk değeri üretmiştir. İyi Gaussian ve ham Gaussian DVM teknikleri hariç, diğer tüm DVM teknikleri %90'nın üzerinde doğruluk değerleri üretmişlerdir. Doğrusal ve kuadratik DVM teknikleri %97,4'lük doğruluk değeri ve kübik DVM tekniği ise en yüksek doğruluk olan %98,7 değerini elde etmiştir. Daha önce de belirtildiği üzere, ham k-EYK yöntemi en düşük doğruluk oranı olan %47,4 değerini üretmiştir. Ayrıca, kosinüs k-EYK tekniği %89,5 doğruluk değeri üretirken, diğer tüm k-EYK yöntemleri yine %90 üzerinde doğruluk değerleri elde etmişlerdir. Birleştirilmiş sınıflandırıcılardan olan hızlandırılmış ağaçlar ve RUSBoost Ağaçları yöntemleri %47,4 olan en düşük başarımlarını üretirken, altuzay EYK yöntemi en yüksek başarımlarını %98,7 değerini elde etmiştir.

İkinci senaryo çerçevesinde karar vermede Öz saygı boyutu giriş olarak kullanıldığında elde edilen tahmin doğruluk oranları Tablo 3'teki gibidir.

Tablo 3. İkinci senaryo için karar vermede Öz saygı boyutu için elde edilen tahmin doğruluk değerleri

Veri Madenciliği Yöntemi	Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	56,6
	Orta Ağaç	56,6
	Ham Ağaç	50,0
Diskriminant Analiz	Doğrusal	50,0
	Diskriminant	
	Kuadratik Diskriminant	53,9
DVM	Doğrusal DVM	51,3
	Kuadratik DVM	57,9
	Küçük DVM	53,9
	İyi Gaussian DVM	52,6
	Orta Gaussian DVM	43,3
	Ham Gaussian DVM	55,3
k-EYK	İyi k-EYK	47,4
	Orta k-EYK	53,9
	Ham k-EYK	47,4
	Kosinüs k-EYK	51,3
	Küçük k-EYK	56,6
	Ağırlıklı k-EYK	47,4
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	50,0
	Torbalı Ağaçlar	55,3
	Altuzay Diskriminant	52,6
	Altuzay k-EYK	48,7
	RUSBoost Ağaçları	48,7

Karar vermede öz-saygı boyutu, 6 ölçek maddesini kapsamaktadır. Tablo 3'de görüldüğü gibi, en yüksek doğruluk oranı olan %57,9 değeri kuadratik DVM tekniği ile elde edilmiştir. Ayrıca, en düşük doğruluk oranı olan %43,3 değeri, orta Gaussian DVM yaklaşımı ile üretilmiştir. Tablo 2'deki önemli bir çıkarım, karar ağaçları sınıflandırma yaklaşımlarının tutarlı doğruluk puanları oluşturmasıdır. Ham ve orta ağaç teknikleri %56,6'lık doğruluk değerlerini üretirken, iyi ağaç yöntemi %50,0 doğruluk skoru elde etmiştir. Doğrusal diskriminant yöntemi de %50,0 doğruluk değeri üretirken, kuadratik diskriminant yönteminin başarımı %53,9'dur. DVM sınıflandırma yöntemlerinden olan orta Gaussian DVM tekniği %43,3'lük doğruluk oranı ile en düşük başarımı

elde etmiştir. Daha önce de belirtildiği gibi, kuadratik DVM tekniği en yüksek doğruluk oranını (%57,9) elde etmiştir. Küçük k-EYK sınıflandırıcısı %56,6'lık doğruluk değeri ile k-EYK sınıflandırıcıları içindeki en iyi başarımları üretmiştir. Ayrıca, iyi, ham ve ağırlıklı k-EYK yöntemleri %47,4'lük doğruluk değerleri üretmişlerdir. Birleştirilmiş sınıflandırıcılar için de torbalı ağaçlar yöntemi %55,3'lük en iyi doğruluk değerini üretmiştir. Ayrıca en düşük başarımları olan %48,7 değeri, altuzay k-EYK ve RUSBoost ağaçları yöntemleri tarafından üretilmişlerdir.

İkinci senaryonun panik karar verme boyutu girdi olarak kullanıldığında, elde edilen tahmin sonuçları Tablo 4'te gösterilmiştir.

Tablo 4. İkinci senaryo için Panik karar verme boyutunda elde edilen tahmin doğruluk değerleri

Veri Madenciliği Yöntemi	Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	89,5
	Orta Ağaç	89,5
	Ham Ağaç	89,5
Diskriminant Analiz	Doğrusal	76,3
	Diskriminant	
	Kuadratik Diskriminant	88,2
DVM	Doğrusal DVM	77,6
	Kuadratik DVM	84,2
	Küçük DVM	84,2
	İyi Gaussian DVM	86,8
	Orta Gaussian DVM	82,9
	Ham Gaussian DVM	82,9
k-EYK	İyi k-EYK	82,9
	Orta k-EYK	84,2
	Ham k-EYK	47,4
	Kosinüs k-EYK	81,6
	Küçük k-EYK	84,2
	Ağırlıklı k-EYK	81,6
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	47,4
	Torbalı Ağaçlar	88,2
	Altuzay Diskriminant	78,9
	Altuzay k-EYK	84,2
	RUSBoost Ağaçları	47,4

Panik karar verme boyutu beş ölçek maddesini kapsamaktadır. Tablo 4'ten görüleceği üzere, en yüksek doğruluk değeri %89,5'i bütün karar ağaçları yöntemleri üretmiştir. İkinci en yüksek doğruluk oranı olan %88,2 değerini kuadratik diskriminant sınıflandırıcı yöntemi üretmiştir.

Ayrıca doğrusal diskriminant yöntemi de %76,3 doğruluk değerini elde etmiştir. Bütün DVM teknikleri genel anlamda başarılı doğruluk değerleri üretmişlerdir. Kuadratik ve kübik DVM yöntemleri %84,2 ve orta ve ham Gaussian DVM yöntemleri ise %82,9 doğruluk değerlerini üretmişlerdir. Ham k-EYK yöntemi %47,4'lük doğruluk değeri ile en düşük başarıyı elde etmiştir. Diğer bütün k-EYK yöntemleri %80'in üzerinde doğruluk değerleri ile ilgili sınıflandırma işlemini gerçekleştirmişlerdir. Orta ve kübik k-EYK yöntemleri %84,2'lik doğruluk değerleri üretirken, kosinüs ve ağırlıklı k-EYK metotları %81,6'lık başarımlarını değerleri elde etmişlerdir.

Tablo 5. İkinci senaryo için Dikkatli karar verme boyutunda elde edilen tahmin doğruluk değerleri

Veri Madenciliği Yöntemi	Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	90,8
	Orta Ağaç	90,8
	Ham Ağaç	90,8
Diskriminant Analiz	Doğrusal	94,7
	Diskriminant	90,8
	Kuadratik	
DVM	Diskriminant	96,1
	Doğrusal DVM	
	Kuadratik DVM	
	Kübik DVM	
	İyi Gaussian DVM	
	Orta Gaussian DVM	
Ham Gaussian DVM	93,4	
k-EYK	İyi k-EYK	93,4
	Orta k-EYK	92,1
	Ham k-EYK	47,4
	Kosinüs k-EYK	89,5
	Kübik k-EYK	93,4
	Ağırlıklı k-EYK	94,7
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	47,4
	Torbalı Ağaçlar	89,5
	Altuzay	96,1
	Diskriminant	
	Altuzay k-EYK	
RUSBoost Ağaçları	47,4	

Hızlandırılmış ve RUSBoost ağaçları yöntemleri %47,4'lük en kötü doğruluk değerlerini elde ederken, torbalı ağaçlar yöntemi daha önce de belirtildiği üzere %88,2'lik en iyi ikinci doğruluk değerini üretmiştir. Altuzay diskriminant ve

altuzay k-EYK birleştirilmiş sınıflandırılmış yöntemleri sırası ile %78,9 ve %84,2'lik başarımlarını üretmişlerdir.

İkinci senaryo çerçevesinde Dikkatli karar verme boyutu giriş olarak kullanıldığında elde edilen tahmin doğruluk değerleri Tablo 5'teki gibi bulunmuştur.

Dikkatli karar verme boyutu 6 ölçek maddesini kapsamaktadır ve elde edilen sonuçlar Tablo 5'te verilmiştir. Tablo 5'te görüldüğü gibi, en yüksek doğruluk oranı olan %96,1'i, altuzay diskriminant birleştirilmiş sınıflandırıcı ve doğrusal DVM teknikleri tarafından üretilmiştir. Ayrıca, en iyi ikinci doğruluk oranı %94,7 değerini de doğrusal Diskriminant ve ağırlıklı k-EYK yöntemleri elde etmişlerdir. Bütün karar ağaçları yöntemleri ve kuadratik diskriminant analiz yöntemi %90,8'lik bir başarımlarını elde etmişlerdir. İyi Gaussian DVM yöntemi hariç diğer bütün DVM yöntemleri %90'nın üzerinde bir başarımlarını elde etmişlerdir. Kübik, orta ve ham Gaussian DVM teknikleri %93,4'lük bir doğruluk ile tahminlerini gerçekleştirmişlerdir. Ham k-EYK yöntemi, %47,4'lük doğruluk değeri ile k-EYK yöntemleri içerisinde en düşük başarımlarını elde ederken, iyi ve kübik k-EYK yöntemleri %93,4'lük doğruluk değerleri üretmişlerdir. Ağırlıklı k-EYK yöntemi ise %94,7'lük bir başarımlarını elde etmiştir. Hızlandırılmış ağaçlar ve RUSBoost ağaçlar teknikleri daha öncede ifade edildiği üzere en düşük başarımlarını değerini elde ederken, Altuzay diskriminant yöntemi en iyi başarımlarını üretmiştir. Altuzay k-EYK ve torbalı ağaçlar yöntemleri sırası ile %92,1 ve %89,5'lik başarımlarını değerleri üretmişlerdir.

İkinci senaryo çerçevesinde Kaçınan karar verme boyutu giriş olarak kullanıldığında elde edilen tahmin doğruluk değerleri Tablo 6'daki gibi bulunmuştur.

Kaçınan karar verme boyutu 6 ölçek maddesini kapsamakta ve elde edilen sonuçlar Tablo 6'te verilmiştir. Tablo 6'te elde edilen sonuçlar değerlendirildiğinde, kaçınan karar verme boyutunun eğitilmiş ve eğitilmiş olmayan katılımcıları ayırmada yeterince etkili olduğu görülmektedir. Karar ağaçları, doğrusal diskriminant analiz, doğrusal DVM, iyi, orta ve kosinüs k-EYK, altuzay diskriminant ve k-EYK yöntemleri %93,4'lük doğruluk değeri elde etmişlerdir. İyi iyi başarımlarını ise %97,4'lük

doğruluk değeri ile torbalı ağaçlar yöntemi üretmiştir. Diğer taraftan, en düşük başarımlık değeri olan %47,4 doğruluk değerini sırası ile ham k-EYK, hızlandırılmış ve RUSBoost ağaçlar yöntemleri üretmiştir.

Tablo 6. İkinci senaryo için Kaçınan karar verme boyutunda elde edilen tahmin doğruluk değerleri

Veri Madenciliği Yöntemi	Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	93,4
	Orta Ağaç	93,4
	Ham Ağaç	93,4
Diskriminant Analiz	Doğrusal	93,4
	Diskriminant	
	Kuadratik	96,1
DVM	Doğrusal DVM	93,4
	Kuadratik DVM	94,7
	Kübik DVM	90,8
	İyi Gaussian DVM	78,9
	Orta Gaussian DVM	96,1
	Ham Gaussian DVM	90,8
k-EYK	İyi k-EYK	93,4
	Orta k-EYK	93,4
	Ham k-EYK	47,4
	Kosinüs k-EYK	93,4
	Kübik k-EYK	96,1
	Ağırlıklı k-EYK	96,1
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	47,4
	Torbalı Ağaçlar	97,4
	Altuzay	93,4
	Diskriminant	93,4
	Altuzay k-EYK	93,4
	RUSBoost Ağaçları	47,4

İkinci senaryo çerçevesinde Erteleyici karar verme boyutu giriş olarak kullanıldığında elde edilen tahmin sonuçları Tablo 7'deki gibidir.

6 ölçek maddesini kapsayan erteleyici karar verme boyutu ile ilgili elde edilen sonuçlar Tablo 6'da verilmiştir. Tablo 6'da görüldüğü gibi, erteleyici karar verme boyutunun doğruluk sonuçları kaçınan karar verme boyutunun sonuçlarına oranla daha kötüdür. En yüksek doğruluk oranı olan %75,0 ve en düşük doğruluk oranı olan %47,4 sırasıyla doğrusal DVM ve ham k-EYK yöntemleri ile elde edilmiştir. %65,8 doğruluk oranı, iyi ve orta ağaç, kübik k-EYK ve

hızlandırılmış ve RUSBoost ağaçları yöntemleri ile elde edilmiştir.

Tablo 7. İkinci senaryo için Erteleyici karar verme boyutunda elde edilen tahmin doğruluk değerleri

Veri Madenciliği Yöntemi	Sınıflandırıcı Tipi	Doğruluk (%)
Karar Ağaçları	İyi Ağaç	65,8
	Orta Ağaç	65,8
	Ham Ağaç	63,2
Diskriminant Analiz	Doğrusal	71,1
	Diskriminant	
	Kuadratik	67,1
DVM	Doğrusal DVM	75,0
	Kuadratik DVM	61,8
	Kübik DVM	56,6
	İyi Gaussian DVM	61,8
	Orta Gaussian DVM	68,4
	Ham Gaussian DVM	67,1
k-EYK	İyi k-EYK	64,5
	Orta k-EYK	64,5
	Ham k-EYK	47,4
	Kosinüs k-EYK	64,5
	Kübik k-EYK	65,8
	Ağırlıklı k-EYK	61,8
Birleştirilmiş Sınıflandırıcılar	Hızlandırılmış Ağaçlar	65,8
	Torbalı Ağaçlar	60,5
	Altuzay Diskriminant	69,7
	Altuzay k-EYK	56,6
	RUSBoost Ağaçları	65,8

4. Sonuçlar

Elde edilen bulgular, veri madenciliğinin, eylem öğrenmenin, okul yöneticileri ve yönetici adaylarının karar vermelerine olumlu etkisinin belirlenmesinde gayet başarılı olduğunu göstermiştir. Uygulamada kullanılan birinci senaryonun, ikinci senaryoya oranla daha başarılı sonuçlar ürettiği görülmüştür. Bu durum, çok fazla ölçek maddesi ile yapılan sınıflandırma işlemlerinin daha başarılı olduğu gerçeğini bir kez daha göstermiştir. İkinci senaryo olarak gerçekleştirilen beş ayrı veri madenciliği uygulamalarında, kaçınan karar verme boyutunun diğer boyutlara oranla, eylem öğrenme sürecine katılmış yönetici ve yönetici adaylarının, sürece katılmamış yönetici ve yönetici adaylarından ayrımının daha başarılı bir

şekilde gerçekleştirildiği görülmüştür. Benzer şekilde dikkatli karar verme boyutu da başarılı sonuçların elde edildiği ikinci senaryo uygulamalarından biridir. İkinci senaryolar göz önüne alındığında, en kötü sınıflandırma başarımının karar vermede öz saygı boyutunda elde edildiği görülmüştür. Veri madenciliği teknikleri açısından değerlendirme yapıldığında, DVM tekniklerinin genel olarak başarılı sonuçlar ürettikleri görülmüştür. Karar ağaçları, birleştirilmiş sınıflandırıcılar ve k-EYK yöntemlerinin de başarılı sonuçların elde edilmesinde kullanılabilecek diğer veri madenciliği teknikleri olduğu ortaya çıkmıştır.

5. Kaynaklar

1. Balyer, A. (2014). School principals' role priorities. *Journal of Theory and Practice in Education*, **10**(1), 24-40.
2. Berg, E. E. (2009). *Perceived effects of teachers' unions on administrators' and teachers' roles and morale*. Ed.D. dissertation, Walden University, United States -- Minnesota.
3. Hallinger, P. (1992). The evolving role of American principals: From managerial to instructional to transformational leaders. *Journal of Educational Administration*, **30**(3).
4. Kincade, E. (2013). *The effect of principal leadership and teacher morale on student achievement (Order No. 3642269)*. Available from ProQuest Dissertations & Theses Global. (1630099753).
5. Education Department (2002). *Continuing professional development for school excellence-consultation paper on continuing professional development of principals*. Hong Kong: The Printing Department.
6. Yan, W., & Ehrich, L. C. (2009). Principal preparation and training: A look at China and its issues. *International Journal of Educational Management*, **23**, 51-64.
7. Davis, S., Darling-Hammond, L., LaPointe, M., & Meyerson, D. (2005). *School leadership study: Developing successful principals (Review of Research)*. Stanford, CA: Stanford University, Stanford Educational Leadership Institute.
8. Darling-Hammond, L., LaPointe, M., Meyerson, D., Orr, M. T., & Cohen, C. (2007). *Preparing school leaders for a changing world: Lessons from exemplary leadership development programs*. Stanford, CA: Stanford University, Stanford Educational Leadership Institute.
9. Hallinger, P., Shaobing, T., & Jiafang, L. (2017). Learning to make change happen in Chinese schools: adapting a problem-based computer simulation for developing school leaders. *School Leadership & Management*, **37**(1-2), 162-187.
10. Orr, M. T. (2006). Mapping innovation in leadership preparation in our nation's schools of education. *Phi Delta Kappan*, **87**(7), 492-499.
11. Aykut, C. M. (2006). *Türkiye ve ABD'de okul yöneticilerinin yetiştirilmesinin karşılaştırılması*, Yayınlanmamış Doktora Tezi, Dokuz Eylül Üniversitesi, Eğitim Bilimleri Enstitüsü.
12. Balyer, A., & Gündüz, Y. (2011). Değişik ülkelerde okul müdürlerinin yetiştirilmesi: Türk eğitim sistemi için bir model önerisi. *Kuramsal Eğitimbilim*, **4**(2), 182-197.
13. Cemaloğlu, N. (2005). Türkiye'de okul yöneticisi yetiştirme ve istihdamı varolan durum, gelecekteki olası gelişmeler ve sorunlar. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, **25**(2), 249-274.
14. Işık, H. (2003). Okul müdürlerinin yetiştirilmelerinde yeni bir model önerisi. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, **24**, 206-211.
15. Kocabaş, İ., & Yirci, R. (2010). Okul müdürü yetiştirmede yeni bir model önerisi: Mentorluk. *V. Ulusal Eğitim Yönetimi Kongresi Bildiriler Kitabı*.
16. Özdemir, T. Y. (2012). *İl eğitim denetmen ve yardımcıların mesleki gelişimlerini devam ettirmede e-mentorluk modeli*. Yayınlanmamış Doktora Tezi, Fırat Üniversitesi, Eğitim Bilimleri Enstitüsü Eğitim Yönetimi Teftişi Planlaması ve Ekonomisi Anabilim Dalı, Elazığ.
17. Turhan, M., & Karabatak, S. (2015). Okul liderlerinin web tabanlı yetiştirilmesinde problem temelli öğrenme: teorik bir model önerisi. *Kuram ve Uygulamada Eğitim Yönetimi*, **21**(3): 395-424.
18. Weindling, D. (2004). *Innovation in headteacher induction*. Nottingham: National College for School Leadership.
19. Acker-Hocevar, M., Pisapia, J. R., & Coukos-Semmel, E. D. (2002). *Bridging the abyss: Adding value and validity to leadership development through action learning—cases-inpoint*. (Report No.EA 031 828). Eugene OR: National Center for Research on Educational Administration.
20. Boulden, G. P., & Laat, R. D. (2005). Peer group learning in Roche Pharma development. *Action Learning: Research and Practice*, **2**(2): 197-204. doi:10.1080/14767330500207043
21. Hicks, S. A. (2000). *Action learning: Patterns in the practice of program design*. Published Dissertation, North Carolina State University, USA.

22. Lamm, S. (2000). *The connection between action reflection learning and transformative learning: An awakening of human qualities in leadership*. Unpublished doctoral dissertation, Teachers College, Columbia University, New York, **28**.
23. Lee, T. B. (2005). *A case study of an action learning program with regard to leadership behaviors and characteristics*. Doctoral dissertation, George Washington University.
24. Marquardt, M. (2004). *Optimizing the power of action learning*. Davies-Black Publishing.
25. Skipton Leonard, H. & Lang, F. (2010). Leadership development via action learning. *Advances in Developing Human Resources*, **12(2)**: 225-240.
26. Taylor, T. (2010). *Action learning as a vehicle for 21st century alignment in public education*. Doctoral dissertation, University of La Verne.
27. Boshyk, Y., & Dilworth, R. (Eds.). (2010). *Action learning: History and evolution*. Palgrave Macmillan.
28. Dunn, L. (2002). *Theories of learning. Learning and Teaching Briefing Papers Series, Oxford Centre for Staff and Learning Development OCSLD*, Oxford Brookes University.
29. Marquardt, M. (2003). Developing global leaders via action learning programs: a case study at Boeing. *Thai Journal of Public Administration*, **3(3)**: 133-157.
30. Pedler, M. (2008). *Action learning for managers*. Gower Publishing Ltd.
31. Brockbank, A., & McGill, I. (2003). *The action learning handbook: powerful techniques for education, professional development and training*. Routledge.
32. Bursalıoğlu, Z. (2002). *Okul Yönetiminde Yeni Yapı ve Davranışlar*. Ankara: Pegem Akademi.
33. Mann, L., Radford, M., Burnett, P., Ford, S., Bond, M., Leung, K., ... & Yang, K. S. (1998). Cross-cultural differences in self-reported decision-making style and confidence. *International Journal of Psychology*, **33(5)**: 325-335.
34. Deniz, M. E. (2004). Investigation of the relation between decision-making self-esteem, decision making styles and problem solving skills of university students. *Eurasian Journal of Educational Research*, **4(15)**: 23-35.
35. Büyüköztürk, Ş., Çakmak, E. K., Akgün, Ö. E., Karadeniz, Ş., ve Demirel, F. (2014). *Bilimsel araştırma yöntemleri*. Ankara: Pegem Akademi.
36. Christensen, L. B., Johnson, B., & Turner, L. A. (2015). *Araştırma yöntemleri: Desen ve analiz*. Ankara: Anı Yayıncılık.
37. Luan, J. (2002). *Data mining applications in higher education*. John Wiley and Sons, New York.
38. Şengür, D. (2013). *Öğrencilerin akademik başarılarının veri madenciliği metotları ile tahmini*. Yayınlanmamış Yüksek Lisans Tezi. Fırat Üniversitesi, Eğitim Bilimleri Enstitüsü, Bilgisayar ve Öğretim Teknolojileri Eğitimi.
39. Safavian, S. R., & Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems Man and Cybernetics*, **21**: 660-674.
40. Duda, R. O., Hart, P. E., & Stork, D. G. (2012). *Pattern classification*. John Wiley & Sons.
41. Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., & Scholkopf, B. (1998). Support vector machines, *IEEE Intelligent Systems and their Applications*, **13(4)**: 18-28.
42. Biçer, P. (2002). *Veri madenciliği: Sınıflandırma ve tahmin yöntemlerini kullanarak bir uygulama*. Yayınlanmamış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Sosyal Bilimler Enstitüsü.
43. Sengur, A. (2012). Support vector machine ensembles for intelligent diagnosis of valvular heart disease. *Journal of Medical Systems*, **36(4)**: 2649-2655.

