



**TÜRKİYE'DEKİ ENERJİ SANTRALLERİNDE
DOĞAL GAZ TÜKETİMİNİN DESTEK
VEKTÖR REGRESYON İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Gizem MERAL

Danışman

Doç. Dr. Sinan SARAÇLI

İSTATİSTİK ANABİLİM DALI

Haziran 2019

Bu tez çalışması 18.Fen.Bil.15 numaralı proje ile Afyon Kocatepe Üniversitesi BAPK tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**TÜRKİYE'DEKİ ENERJİ SANTRALLERİNDE
DOĞAL GAZ TÜKETİMİNİN DESTEK VEKTÖR
REGRESYON İLE TAHMİNİ**

Gizem MERAL

Danışman

Doç. Dr. Sinan SARAÇLI

İSTATİSTİK ANABİLİM DALI

Haziran 2019

TEZ ONAY SAYFASI

Gizem MERAL tarafından hazırlanan "Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketiminin Destek Vektör Regresyon ile Tahmini" adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 17/06/2019 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **İstatistik Anabilim Dalı'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman :Doç. Dr. Sinan SARAÇLI

Başkan :Dr.Öğr. Üyesi Özer ÖZAYDIN
Eskişehir Osmangazi Üniv., Fen-Edebiyat Fak.

Üye :Doç. Dr. Sinan SARAÇLI
Afyon Kocatepe Üniv., Fen-Edebiyat Fak.

Üye :Doç. Dr. İbrahim KILIÇ
Afyon Kocatepe Üniv., Veteriner Fak.

İmza



Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve
.....sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

17/06/2019



Gizem MERAL

ÖZET
Yüksek Lisans Tezi

**TÜRKİYE'DEKİ ENERJİ SANTRALLERİNDE DOĞAL GAZ TÜKETİMİNİN
DESTEK VEKTÖR REGRESYON İLE TAHMİNİ**

Gizem MERAL

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

İstatistik Anabilim Dalı

Danışman: Doç. Dr. Sinan Saraçlı

Bu çalışmanın amacı, destek vektör makinelerinde regresyon yöntemini kullanarak Türkiye'deki enerji santrallerinin doğalgaz tüketimi üzerine ön kestirim yapmaktır. Bu amaçla, araştırmada kullanılacak veri seti 2013-2018 yılları arasında Türkiye Enerji Piyasası Düzenleme Kurumu ve Enerji İşleri Genel Müdürlüğünden elde edilmiştir.

Bu çalışmada ilk olarak, Türkiye'de doğalgazın enerji piyasasındaki yeri, birincil enerji kaynakları içindeki payı, üretim, tüketim, ithalat ve ihracat değerleri incelenmiştir. Bu değerlerin ölçü birimlerinin farklılığından dolayı, ilgili veri seti istatistiksel analizden önce standartlaştırılmıştır. Enerji santralleri tüketimi (bin sm^3) bağımlı değişken iken; sanayi tüketimi (bin sm^3), şehir tüketimi (bin sm^3), üretim (milyon sm^3), ithalat (milyon sm^3) ve ihracat (milyon sm^3) değerleri bağımsız değişken olarak belirlenmiştir. Destek Vektör Regresyonda kullanılan tüm çekirdek fonksiyonları (Doğrusal, Polinomsal, Radyal Tabanlı Fonksiyon(RTF) ve Sigmoid) test edilmiştir. En küçük Hata Kareler Ortalaması (HKO)'na sahip olan RTF kestirim çekirdek fonksiyonu olarak seçilmiştir. Daha sonra, destek vektörler, ağırlıklar ve karar sabiti belirlenmiştir. Ağırlıklar ve destek vektörler çarpılıp yan eklenerek, son model elde edilmiştir.

Son model yardımıyla da Mayıs - Aralık 2018 için Türkiye'deki enerji santrallerinin doğalgaz tüketimlerine ait tahminler yapılmıştır.

2019, viii+ 35 sayfa

Anahtar Kelimeler: Destek Vektör Makineleri, Destek Vektör Regresyon, Çekirdek Fonksiyonları

ABSTRACT
M. Sc. Thesis

ESTIMATION OF NATURAL GAS CONSUMPTION OF POWER PLANTS IN
TURKEY VIA SUPPORT VECTOR REGRESSION

Gizem MERAL

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Statistics

Supervisor: Assoc. Prof. Sinan SARAÇLI

The aim of this study is to forecast the natural gas consumptions of power plants in Turkey via support vector machines regression method. With this aim the data set is obtained from Turkey's Energy Market Regulatory Authority and Energy Affairs General Directorate between the years 2013-2018.

In this study, first of all, the place in Turkish market, ratio within the primary energy sources, production, consumption, import and export values of natural gas, as a power supply is examined. Because of the differences in measurements of these values, the related data set is standardized before the statistical analysis. While, the consumption in energy plants (thousand cm^3) is considered as a dependent variable, industrial consumption (thousand cm^3), city consumption (million cm^3), production (million cm^3), import (million cm^3) and export (million cm^3) values are considered as independent variables. All types of kernel functions (Linear, Polynomial, Radial Basis Function (RBF) and Sigmoid) in Support Vector Regression are tested. RBF is chosen as the forecasting kernel function because of having the minimum Mean Square Error (MSE). Then, support vectors, weights and decision constants are determined. By multiplying weights with support vectors and adding the bias, the final model is obtained.

By the help of final model, estimates of natural gas consumption of power plants in Turkey, for May-December 2018 are obtained.

2019, viii + 35 pages

Keywords: Support Vector Machines, Support Vector Regression, Kernel Functions

TEŐEKKÜR

Bu arařtırmanın konusu,deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarında dolay tez danıřmanım Sayın Do. Dr. Sinan SARALI'ya, arařtırma ve yazım sresince yardımlarını esirgemeyen Servet ÖKSZ'e, her konuda neri ve eleřtirileriyle yardımlarını grdęm hocalarıma ve arkadařlarıma teőekkr ederim.

Bu arařtırma boyunca maddi ve manevi desteklerinden dolay aileme teőekkr ederim.

Ayrıca bu tezin oluřmasına 18.Fen.Bil.15 numaralı proje ile katkı saęlayan BAPK'ne teőekkrlerimi sunarım.

Gizem MERAL
AFYONKARAHİSAR, 2019

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET.....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	iv
İÇİNDEKİLER DİZİNİ.....	v
SİMGELER ve KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	ix
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	2
2.1 Makine Öğrenmesi ve Öğrenme Türleri	2
2.2 İstatistiksel Öğrenme Teoremi.....	3
2.2.1 Beklenen Risk Minimizasyonu (BRM).....	5
2.2.2 Deneysel Risk Minimizasyonu (DRM).....	5
2.2.3 Yapısal Risk Minimizasyonu (YRM)	6
2.3 Vapnik-Chervonenkis (VC) Boyutu	6
2.4 Destek Vektör Makineleri (DVM).....	7
2.4.1 DVM'de Sınıflandırma	8
2.4.1.1 Eğitim Hatasının Bulunmadığı Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma.....	8
2.4.1.2 Eğitim Hatasının Bulunduğu Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma.....	11
2.4.1.3 Doğrusal Olarak Ayrılamayan Verilerde Sınıflandırma.....	13
2.4.2 Çekirdek Fonksiyonları.....	14
2.4.2.1 Doğrusal Çekirdek Fonksiyonu	16

2.4.2.2 Polinomsal Çekirdek Fonksiyonu.....	16
2.4.2.3 Radyal Tabanlı Çekirdek Fonksiyonu (RTF).....	16
2.4.2.4 Sigmoid Çekirdek Fonksiyonu	17
2.4.3 Destek Vektör Regresyon	17
2.5 Model Belirleme Kriterleri	18
2.5.1 R^2	18
2.5.2 Düzeltilmiş R^2	19
2.5.3 Akaike Bilgi Kriteri ve Bayesçi Bilgi Kriteri (AIC ve BIC).....	20
2.6 Performans Fonksiyonları.....	20
3. MATERYAL ve METOT	22
4. BULGULAR	24
5. TARTIŞMA ve SONUÇ	29
6. KAYNAKLAR.....	31
ÖZGEÇMİŞ	35

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

w	Ağırlık Vektörü
B	Bias (yan)
ξ	Gevşek Değişken
Sm^3	Santimetre Küp

Kısaltmalar

VC-Boyutu	Vapnik-Chervonenkis Boyutu
DVM	Destek Vektör Makineleri
DVR	Destek Vektör Regresyon
RTF	Radyal Tabanlı Fonksiyon
AIC	Akaike Bilgi Kriteri
BIC	Bayesçi Bilgi Kriteri
OMH	Ortalama Mutlak Hata
HKO	Hata Kareler Ortalaması
HKOK	Ortalama Hata Karelerin Karekökü
TKH	Toplam Karesel Hata
YRM	Yapısal Risk Minimizasyonu
KKT	Karush-Kuhn-Tucker

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Hipotez Uzayından Model Seçilirken Oluşan Hatalar	4
Şekil 2.2 YRM Prensibi	6
Şekil 2.3 DVM' nin Ağ Yapısı	7
Şekil 2.4 Eğitim Hatasının Bulunmadığı Doğrusal Olarak Ayrılabilen Veriler İçin Sınıflandırmada Optimal Hiper Düzlem	8
Şekil 2.5 n Adet Hiper Düzlem	9
Şekil 2.6 Optimum hiper düzlem	9
Şekil 2.7 Eğitim Hatasının Bulunduğu Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma	11
Şekil 2.8 Çekirdek Fonksiyonu İle Verinin Daha Yüksek Bir Boyuta Dönüşümü.....	14
Şekil 2.9 DVR'de Kullanılan Kayıp Fonksiyonları	17
Şekil 2.10 ϵ -Duyarsız Kayıp Fonksiyonu ve Gevşek Değişkenler.....	18
Şekil 4.1 DVM Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılmasını Gösteren Grafik	27
Şekil 4.2 Trend Analizi Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılmasını Gösteren Grafik	28

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 İstatistiksel Öğrenme ve Makine Öğrenme Karşılaştırması	4
Çizelge 4.1 Bağımsız Değişkenlerin Seçimi İçin Kurulan Modeller	24
Çizelge 4.2 DVR'de Kullanılacak Olan Eğitim Kümesi	24
Çizelge 4.2 (Devam) DVR'de Kullanılacak Olan Eğitim Kümesi	25
Çizelge 4.3 DVR'de Kullanılacak Olan Test Kümesi	25
Çizelge 4.4 Doğrusal Çekirdek Fonksiyonu Performans Kriterleri	25
Çizelge 4.5 Polinomial Çekirdek Fonksiyonu Performans Kriterleri	26
Çizelge 4.6 RBF Çekirdek Fonksiyonu Performans Kriterleri	26
Çizelge 4.7 Sigmoid Çekirdek Fonksiyonu Performans Kriterleri	26
Çizelge 4.8 DVM Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılması	27
Çizelge 4.9 Trend Analizinin Yapılmasında En Uygun Denklem Belirlenmesi	27
Çizelge 4.10 Trend Analizi Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılması	28

1. GİRİŞ

İleri beslemeli ağ kategorisinde yer alan Destek Vektör Makineleri (DVM), özellikle karmaşık model problemlerini çözebilmesi sebebiyle popülaritesi giderek artan bir hâl almaktadır. DVM makine öğrenmesinin bir alt alanıdır ve doğrusal, sigmoid, polinomsal ve radyal tabanlı çekirdek yöntemlerine sahiptir. Bu yöntemler doğrusal olmayan problemlerin çözümünde kullanılır ve yüksek boyutlu uzaya haritalama yaparken işlemlerin yapılmasında kolaylık sağlamaktadır. DVM, Vapnik vd. tarafından 1992 yılında ilk ortaya çıktığında daha çok sınıflandırma problemlerinde kullanılırken daha sonra 1997 yılında regresyon problemlerinde de kullanılmaya başlanmış ve Destek Vektör Regresyon (DVR) adını almıştır. DVR'de kullanılan örneklem büyüklüğü problemlerin çözümünde sorun oluşturmamaktadır.

Bu bağlamda, çalışmanın ilk bölümünde makine öğrenmesi kavramı üzerinde durulmuş ve DVM'nin alt yapısını oluşturan istatistiksel öğrenme teorisinin matematiksel temelleri incelenerek yapısal risk minimizasyonu, deneysel risk minimizasyonu, beklenen risk ve Vapnik-Chervonenkis (VC) boyutu hakkında bilgiler elde edilmiştir.

İkinci bölümde, DVM'nin tanımı yapılarak hangi problemlerde nasıl kullanıldığı araştırılmış olup problemlerin çözümünde kullanılan çekirdek fonksiyonları kavramı üzerinde durulmuş ve DVR'de kullanılan kayıp fonksiyonları incelenmiştir.

Son olarak, Türkiye'de enerji santrallerindeki doğalgaz tüketiminin ön kestirimi için düzenlenen verilerde DVR ile çalışılarak bir model elde edilmiş ve bu modele bağlı olarak tahminler yapılmıştır.

2.LİTERATÜR BİLGİLERİ

2.1 Makine Öğrenmesi ve Öğrenme Türleri

İnsanların makinelerle olan ilişkisi aslında çok eskilere dayanır. Yunan mitolojisinde Demircilerin Tanrısı olan Hephaestus; Zeus ve Hera'nın oğluydu ve ateş ile demir, bakır, altın ve gümüşü işler ve mekanik hizmetçiler yapardı. Yine aynı mitolojide bronz adam Talos'dan söz edilir. Antik dönemde de insana benzer makineler anlatılırdı. Aristo'nun M.Ö. 4. Yüzyılda sembolik mantığı geliştirmesi bugüne gelinmesinde çok önemlidir. Cizre'de doğup, Cizre'de ölen Kitab'ul Hiyel'in yazarı El-Cezeri, 1206 yılında ilk programlanabilir insansı robotu yaptı. Su gücüyle çalışan bu robot, dört müzisyeni taşıyan bir kayıktan oluşuyordu. 15. Yüzyılda matbaa, 16. Yüzyılda ise saatler ortaya çıktı. 17. Yüzyılda 1642 yılında ünlü matematikçi Pascal, ilk toplama ve çıkarma uygulayan hesap makinesini yaptı. 1671 yılında Leibniz bunu çarpma, bölme yapacak ve karekök alacak şekilde geliştirdi. 18. Yüzyılda mekanik oyuncaklar yapıldı. 19. Yüzyılda önemli bir gelişme oldu, Joseph-Marie Jacquard delikli kartlarla işleyen ilk programlanabilir makine olan dokumamakinesini 1801 yılında buldu (Gürsakal 2017).

Gelişen teknolojiyle beraber insan-makine arasında ayırım hızla bulanıklaşıyor. Biz günlük işlerimiz ile ilgilenip işe gidip, maçı seyrederken; bilgisayarlar bizim anlamayacağımız modelleri üretiyorlar. Bu modeller insanın anlayabileceği, kavrayabileceği kapsamın dışında işler yapıyorlar. Günümüzde insanın öğretmenliğinde makineler büyük bir hızla öğreniyor (Gürsakal 2017).

Makine öğrenmesini daha iyi anlayabilmek için öncelikle öğrenme kavramının tanımlanması gerekmektedir. Genel olarak öğrenme, insanın içinde bulunduğu ortamda yaşamını sürdürebilmesi ve yaşamından doyum alabilmesi için gerekli olan bilgilerin, deneyimlerin, görgülerin, becerilerin ve eylemlerin kazanılması süreci olarak tanımlanabilir (Selçuk 1999, Yılmaz 2009). Makine öğrenmesi ise bu öğrenme işleminin bilgisayarlar tarafından gerçekleştirilmesidir. Burada, zaman içerisinde iyileşme kavramına dikkat edilmelidir. Diğer bir deyişle makine öğrenmesi "Bilgisayarın bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak

benzeri olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesidir" denilebilir. Bilgisayarın öğrenebilmesi ve tecrübe sahibi olabilmesi bilgisayarın ilgili olay hakkında bilgiler ile donatılmasına bağlıdır (Öztemel 2006). Makine öğrenmesinde elemanlar arasındaki bağlantıların ağırlık değerlerinin belirlenmesi işlemi "ağın eğitilmesi" olarak ifade edilmektedir. İlk olarak ağırlık değerleri rastsal olarak verilir. Yapay Sinir Ağları (YSA), kendisine gösterilen örneklerle bu ağırlıkları güncelleştirir. Amaç, ağa verilen örneklere ait çıktıları doğru üretecek ağırlıkların bulunmasıdır. Örnekler ağa sürekli gösterilir ve en doğru ağırlıklar bulunmaya çalışılır. Ağ, ağırlıklar doğru değerlerine ulaştığında genelleme yapabilme yeteneğine kavuşmuş olur. Bu genelleştirme yeteneğine kavuşması işlemine ağın öğrenmesi denir. Ağırlıklarında değişmesi için belli öğrenme kuralları vardır (Kaytez 2012). Bugün kullanılan öğrenme algoritmalarının çoğu Hebb, Delta, Kohonen ve Hopfield olmak üzere dört farklı öğrenme kuralından esinlenerek türetilmiştir (Sağıroğlu vd. 2003).

2.2 İstatistiksel Öğrenme Teoremi

İstatistiksel Öğrenme Teoremi birçok makine öğrenmesi algoritmalarına teorik alt yapı oluşturur ve yapay zekâ konusunun en iyi şekilde geliştirilmiş dallarından biridir. 1960'larda Rusya'da geliştirilmeye başlayan teorem DVM'nin tanınmasıyla birlikte popüler olmaya başlamıştır. Teorem, yeni geliştirilen öğrenme algoritmalarına temel olmakla birlikte deneysel veriden gerekli bilgileri çekmek ve geçerli sonuçları elde etmek için de kullanılmaktadır. Bu bilgileri elde etmek ve sonuçları yorumlayabilmek için ise bir öğrenme algoritmasından elde edilecek en iyi fonksiyonun bulunması gerekmektedir. Bunun için gereken en iyi yaklaşım, $S = \{\vec{x}_i, y_i\}_{i=1}^n$ eğitim kümesi için kabul edilebilir tahmin fonksiyonlarının doğruluklarını ve ne kadar "iyi" olduklarını ölçen bir ölçüt üzerinde optimizasyon problemi tanımlamaktır. Hipotez uzayında bulunan her hipotez tahmin fonksiyonuna $f \in H$ bu tür bir ölçüt veya daha doğru ifadeyle $l(f\{\vec{x}, y\})$ şeklinde bir kayıp fonksiyonu uygulandığında, Eşitlik 2.1'deki gibi gösterilen ve kayıp fonksiyonları kümesi olarak isimlendirilen fonksiyonlar uzayı elde edilir.


$$L(H, .) = \{l(f, .) : f \in H\} \quad (2.1)$$

Eşitlik 2.1'deki bu uzaydan alınan bir kayıp fonksiyonu yardımıyla elde edilen hipotez fonksiyonu tüm gözlem uzayı üzerinden değerlendirilir. Ancak, eğitim verisindeki tüm gözlemler $P(\vec{x}, y)$ gibi bir dağılımdan geldiği için kullanılacak kayıp fonksiyonu bu dağılım fonksiyonuyla birlikte hesaplanmalıdır (Arat 2014). İstatistiksel öğrenme ile makine öğrenmesi arasındaki farklar Çizelge 2.1'de sunulmuştur (Gollapudi and Laxmikanth 2016).

Çizelge 2.1 İstatistiksel Öğrenme ve Makine Öğrenme Karşılaştırması

İSTATİSTİKSEL ÖĞRENMEYE KARŞI MAKİNE ÖĞRENME

Makine öğrenmesiyle benzerlikleri	Makine öğrenmesiyle farklılıkları	Makine öğrenmesiyle ilişkisi
İstatistiksel öğrenme de makine öğrenmesi gibi, bazı durumlarda verilere göre çıkarım yapabilmeyeni temsil eder.	Makine öğrenmesi, geçerli sonuçlara varmaya odaklanırken, istatistiksel öğrenme tahminlerle ilgilidir. İstatistiksel öğrenme, Makine öğrenmeye karşı varsayımlar üzerinde çalışır. Makine öğrenmesi ve istatistikler farklı gruplar tarafından uygulanmaktadır.	Makine öğrenmesi teknolojisi istatistiksel teknikleri uygular.



Şekil 2.1 Hipotez Uzayından Model Seçilirken Oluşan Hatalar

Modellemedeki amaç, hedef uzaya en yakın olan hipotez uzayından bir model seçmektir. Model seçilirken hatalar yapılabilir bu hatalar iki durumdan

kaynaklanmaktadır. Şekil 2.1'de modelleme hataları gösterilmiştir (Vapnik 1998, Gunn 1998).

1. Yaklaşım Hatası, hipotez alanının hedef alandan daha küçük olmasının bir sonucudur ve bu nedenle temel işlev hipotez alanının dışında kalabilir. Model alanının zayıf seçimi büyük bir yaklaşım hatasına neden olur ve model uyumsuzluğu olarak adlandırılır.

2. Tahmin Hatası, hipotez uzayından optimal olmayan modeli seçen bir teknikle sonuçlanan öğrenme prosedüründen kaynaklanan hatadır.

Birlikte bu hatalar genelleme hatasını oluşturur. Hataların oluşmasında karşılaşılan belli başlı risk minimizasyonu problemleri vardır bu risk minimizasyon problemleri sırasıyla beklenen risk minimizasyonu, deneysel risk minimizasyonu ve yapısal risk minimizasyonudur.

2.2.1 Beklenen Risk Minimizasyonu (BRM)

Beklenen risk minimizasyonu, verinin türetildiği dağılıma göre $X \times Y$ gözlem uzayı üzerinde sabit bir fonksiyonun ürettiği ortalama kayıp veya hatadır.

$$R_x(f) = E[l(f, \{\vec{x}, y\})] = \int_X \int_Y l(f, \{\vec{x}, y\}) dP(\vec{x}, y) = \int_X \int_Y l(f, \{\vec{x}, y\}) P(\vec{x}, y) d\vec{x} dy \quad (2.2)$$

Bu durumda kullanılan öğrenme algoritması, sabit bir kayıp fonksiyonu l için f^* tahmin fonksiyonunu, tüm ölçülebilir fonksiyonlar üzerinden Eşitlik 2.2'deki beklenen riski minimize ederek bulmaya çalışır (Arat 2014).

2.2.2 Deneysel Risk Minimizasyonu (DRM)

$$R(\alpha) = \int Q(z, \alpha_0) dF(z), \alpha \in N \quad (2.3)$$

Eşitlik 2.3'te kullanılan risk fonksiyonunu en aza indirmek yerine deneysel fonksiyon olarak adlandırılan fonksiyon en aza indirgenebilir.


$$R_{emp}(\alpha) = \frac{1}{l} \sum_{i=1}^l Q(z, \alpha_i), \alpha \in N \quad (2.4)$$

örnekleri negatif örneklerden ayıran $h \in H$ olacak şekilde bir hipotez bulunabilir. O zaman H , N adet noktaları parçalara ayırır denir. Yani, N adet örnek yolu ile tanımlanabilen herhangi bir öğrenme problemi H 'den çekilen bir hipotez yolu ile hatasız öğrenilebilir. H tarafından parçalara ayrılabilen maksimum noktaların sayısı, H 'nin Vapnik-Chervonenkis (VC) boyutu adı verilir ve $VC(H)$ olarak gösterilir (Alpaydın 2010).

2.4 Destek Vektör Makineleri (DVM)

Denetimli öğrenme yöntemini kullanan DVM, sınıflandırma ve regresyon problemlerinin çözümünde kullanılır. DVM ilk kez Vapnik vd. tarafından 1992 COLT (Computational Learning Theory) konferansında önerilmiş ve günümüzde kullanılan halini, Cortes ve Vapnik tarafından 1995 yılında almıştır. 1997 yılında ise, DVM algoritması yine Vapnik vd. tarafından regresyon uygulamalarını da kapsayacak şekilde genişletilmiştir (Bilişik 2011).

DVM sınıflandırma problemlerinin birkaç türü vardır. Bunlardan en temel olanı eğitim hatasının bulunmadığı doğrusal ayrılabilirlik durumu ve doğrusal olarak ayrılamama durumudur (Çomak 2008). Şekil 2.3'te DVM'nin ağ yapısı gösterilmektedir (Uçak 2012).




Şekil 2.3 DVM' nin Ağ Yapısı

2.4.1 DVM'de Sınıflandırma

2.4.1.1 Eğitim Hatasının Bulunmadığı Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma


Doğrusal olarak ayrılabilen iki sınıflı öğrenmede amaç verilen örneklerin iki sınıfın maksimal bir sınır ile bölebileceği bir hiper düzlem tanımlamaktır. Bu tür hiper düzlemler iyi genelleştirmeyi sağlar. Genelleştirme yeteneği bir sınıflandırıcının eğitim verisinde çok iyi sınıflandırma performansı olduğu gibi aynı zamanda aynı dağılımdan gelecek veriler için yüksek tahmin kalitesini garanti eder. Eğitim hatasının bulunmadığı doğrusal olarak ayrılabilen veriler için sınıflandırmada optimal hiper düzlem Şekil 2.4'te gösterilmiştir (Kuzey 2012).




Şekil 2.4 Eğitim Hatasının Bulunmadığı Doğrusal Olarak Ayrılabilen Veriler İçin Sınıflandırmada Optimal Hiper Düzlem

DVM ile sınıflandırmada çoğunlukla $\{-1,1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır ve karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper düzlem bulunur (Kavzoğlu ve Çölkesen 2010). Örneğin; Şekil 2.5'e bakıldığında bir veri setindeki iki sınıfı ayırabilen birçok hiper düzlem (en uygun ayırım yapan düzlem) çizilebilir. Hiper düzlem ile verilerin başladığı nokta arasındaki uzaklığa marj denir. Sınıflandırmanın daha iyi yapılabilmesi için marj maksimum değere sahip olmalıdır. Şekil 2.6'da görüldüğü gibi tam sınırdaki noktalar destek vektörleri olarak

tanımlanır ve bu destek vektörler marjiniin maksimum olmasını sağlar (Kavzoğlu ve Çölkesen 2010).



Şekil 2.5 n Adet Hiper Düzlem



Şekil 2.6 Optimum hiper düzlem

w ve b sırası ile hiper düzlemde ağırlık vektörü ve yan olsun. İlgili hiper düzlem Eşitlik 2.5'teki gibi ifade edilebilir;

$$w^T x + b = 0 \quad (2.5)$$

x örnek verisinden optimal hiper düzleme ve istenilen yönde geometrik uzaklık $r = g(x)/w$ olarak ifade edilir. Burada $g(x) = w^T x + b$ hiper düzlem tarafından tanımlanan bir diskriminant fonksiyonudur (Christianini and Taylor 2000).

Bu fonksiyon, w bulunarak hesaplanabilmektedir. n adet eğitim verisi olan bir veri kümesinde w ve b değerleri

$$|w_i \cdot x_i + b| = 1, i = 1, \dots, n \text{ için} \quad (2.6)$$

Eşitlik 2.6'daki gibi olacak şekilde düzenlenebilir. Veriler farklı sınıflardan olduğundan, eşitlikler

$$w \cdot x + b = +1 \quad (2.7)$$

$$w \cdot x + b = -1 \quad (2.8)$$

ya Eşitlik 2.7'de ya da Eşitlik 2.8'de olduğu durumlarda sağlanır. Burada 1 ve -1 değerleri sınıfları ifade eder. Ağırlığın ve beklenen riskin küçük olması marjın yüksek olmasını sağlar. Bu yüzden DVM'de sınıflandırma maksimum sınır sınıflandırıcısı olarak da isimlendirilebilmektedir. Eğitim hatasının bulunduğu doğrusal olarak ayrılabilen verilerde ise bir miktar hataya izin verilerek optimum hiper düzlem bulunabilir (Bican 2014).

Marjın en yüksek değerine ulaşması için $\|w\|$ ifadesi minimum olmalıdır. Bu durumda en uygun hiper düzlemin belirlenmesi için Eşitlik 2.9'daki sınırlı optimizasyon probleminin çözülmesi gerekir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (2.9)$$

Buna bağlı sınırlar ise;

$$y(w \cdot x + b) - 1 \geq 0 \text{ ve } y \in \{-1, 1\} \quad (2.10)$$

Eşitlik 2.10'daki gibidir (Vapnik1995). Bu problem Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında;

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha y_i (w \cdot x_i + b) + \sum_{i=1}^k \alpha \quad (2.11)$$

Eşitlik 2.11 elde edilir. Sonuç olarak, karar fonksiyonu Eşitlik 2.12'deki hale gelir (Osuna *et al.* 1997).


$$f(x) = \text{sign}(\sum_{i=1}^k \lambda y_i (x \cdot x_i) + b) \quad (2.12)$$

2.4.1.2 Eğitim Hatasının Bulunduğu Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma

Sabit marjlı destek vektör makinelerinde, eğitim verilerinin doğrusal olarak ayrılabilir olduğu varsayılır. Veriler doğrusal olarak ayrılamaz olduğunda uygulanabilir bir çözüm yoktur ve sabit marjlı destek vektör makinesi çözülemez. Burada destek vektörü genişletilir böylece ayrılmaz bir duruma uygulanabilir. Eğitim hatasının bulunduğu doğrusal olarak ayrılabilen verilerde sınıflandırma Şekil 2.7'de gösterilmiştir (Abe 2010).

Ayrılamayan problemleri çözebilmek için öncelikle negatif olmayan gevşek değişkenleri $\xi \geq 0$ tanımlanır ve böylece Eşitlik 2.13 elde edilir (Abe 2010).

$$y_i(w^T x_i + b) \geq 1 - \xi_i, i = 1, 2, \dots, M \text{ için} \quad (2.13)$$



Şekil 2.7 Eğitim Hatasının Bulunduğu Doğrusal Olarak Ayrılabilen Verilerde Sınıflandırma

Gevşek değişken ξ_i tarafından uygulanabilir eğriler her zaman mevcuttur. x_i eğitim verileri için, eğer $0 < \xi_i < 1$ ise, veriler maksimum marja sahip değildir ancak yine de zorla sınıflandırılmaktadır. Fakat $\xi_i \geq 1$ ise, veriler optimum hiper düzlem tarafından yanlış sınıflandırılır. Maksimum marjına sahip olmayan eğitim verisi sayısının minimum olduğu optimum hiper düzlemi elde etmek için Eşitlik 2.14'ten faydalanılır (Abe 2010).

$$Q(w) = \sum_{i=1}^M \theta(\xi_i) \quad (2.14)$$

Burada

$$\theta(\xi_i) = \begin{cases} 1, & \xi_i > 0 \text{ için} \\ 0, & \xi_i = 0 \text{ için} \end{cases} \quad (2.15)$$

Eşitlik 2.15 bütünlük bir optimizasyon problemi ve çözmesi zor olduğundan bunun yerine Eşitlik 2.16'daki minimizasyon problemi ele alınır:

Minimize

$$Q(w, b, \xi) = \frac{1}{2} \|w\|^2 + \frac{C}{p} \sum_{i=1}^M \xi_i^p y_i (w^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0 \quad i = 1, \dots, M \text{ için} \quad (2.16)$$

Burada $\xi = (\xi_1, \xi_2, \dots, \xi_M)^T$ ve C, marjın maksimize edilmesi ve sınıflandırma hatasının minimuma indirgenmesi arasındaki dengeyi belirleyen marj parametresidir. p değeri 1 veya 2 olarak seçilir (Abe 2010). Doğrusal olarak ayrılabilir duruma benzer şekilde negatif olmayan Lagrange çarpanları α_i ve β_i tanıtlır,

$$Q(w, b, \xi, \alpha, \beta) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi - \sum_{i=1}^M \alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) - \sum_{i=1}^M \beta_i \xi_i \quad (2.17)$$

Eşitlik 2.17'de L'nin primal parametrelere göre türevi alınırsa Eşitlik 2.18, Eşitlik 2.19 ve Eşitlik 2.20 elde edilir (Yalçın 2016).

$$\frac{\partial L}{\partial w} = 0 \text{ ise } w = \sum_{i=1}^M \alpha_i y_i x_i \quad (2.18)$$

$$\frac{\partial L}{\partial b} = 0 \text{ ise } \sum_{i=1}^M \alpha_i y_i = 0 \quad (2.19)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \text{ ise } C = \alpha_i + \beta_i \quad (2.20)$$

Eşitlik 2.16 ve 2.17 ile verilen ifadelerden faydalanılarak dual model Eşitlik 2.21 elde edilir.

$$\text{maks } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle, \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \forall i \quad (2.21)$$

Eşitlik 2.21'deki optimizasyon probleminin çözülmesi ile ağırlıklar, Eşitlik 2.22'den bulunur.

$$w = \sum_{i=1}^N \alpha_i y_i x_i \quad (2.22)$$

x test örneği olmak üzere diskriminant fonksiyonu Eşitlik 2.23'teki gibi yazılır.

$$f(x) = \sum_{i=1}^N \alpha_i y_i \langle x_i, x \rangle + b \quad (2.23)$$

Burada önemli bir nokta problemin Lagrange formülünde eğitim verilerinin sadece iç çarpımlar şeklinde yer almasıdır. Bu özellik modelin doğrusal olmayan duruma genelleştirilmesinde kullanılmaktadır. Karush-Kuhn-Tucker (KKT) tamamlayıcı koşulları Eşitlik 2.24 ve Eşitlik 2.25'te gösterilmiştir.

$$\alpha_i (y_i (w \cdot x_i + b) - 1 + \xi_i) = 0 \forall i \quad (2.24)$$


$$\beta_i \xi_i = 0 \forall i \quad (2.25)$$

b 'nin hesaplanmasında KKT tamamlayıcı koşullarından faydalanılabilir. Eşitlik 2.20 ve Eşitlik 2.25 incelendiğinde görülmektedir ki eğer $\alpha_i < C$ ise $\xi_i = 0$ olur. Dolayısıyla $0 < \alpha_i < C$ olan eğitim örnekleri Eşitlik 2.24'te yerine konularak ($\xi_i = 0$ olacağından) b hesaplanabilir veya daha güvenilir bir sonuç için tüm mümkün b değerleri hesaplanarak ortalaması alınabilir. Yeni bir test örneği verildiğinde $\text{sgn}(w \cdot x + b)$ hesaplanarak bu örneğin hangi sınıfa ait olduğu bulunur (Yalçın 2016).

2.4.1.3 Doğrusal Olarak Ayrılamayan Verilerde Sınıflandırma

Doğrusal olarak ayırt edilemeyen sınıflarda ise çekirdek fonksiyonları devreye girer ve n boyutlu bir veri kümesi $m > n$ olmak üzere m boyutlu yeni bir veri kümesine dönüştürülerek yüksek boyutta doğrusal sınıflandırma işlemi gerçekleştirilir. Şekil

2.8'de çekirdek fonksiyonu kullanılarak verinin daha yüksek bir boyuta dönüşümü gösterilmiştir.



Şekil 2.8 Çekirdek Fonksiyonu İle Verinin Daha Yüksek Bir Boyuta Dönüşümü

DVM matematiksel olarak $K(x_i, x_j) = \phi(x) \cdot \phi(x_j)$ şeklinde ifade edilen bir çekirdek fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayırılmasına imkan sağlanmaktadır. Sonuç olarak, doğrusal olarak ayıramayan iki sınıflı bir problemin çözümü ile ilgili karar kuralı Eşitlik 2.26'daki şekilde yazılabilir (Osuna *et al.* 1997):

$$f(x) = \text{sign}(\sum_i a_i y_i \phi(x) \cdot \phi(x_j) + b) \quad (2.26)$$

Buradaki en önemli husus yüksek boyutlu uzaya haritalama yaparken işlemlerin yapılması zor olacaktır. Bundan dolayı çekirdek fonksiyonları kullanılır (Bican 2014).

2.4.2 Çekirdek Fonksiyonları

Doğrusal olarak ayıramayan problemleri çözmek için kullanılan metotlardan birisidir. Problem verilen giriş verileri arasında iç çarpıma dayalı uygun bir çekirdek fonksiyonu tanımlamak, problemleri doğrusal olarak ayrılabilir yapmak için giriş uzayından, yüksek boyutlu öznitelik uzayına verinin doğrusal olmayan dönüşümünü yapmaktır (Haykin 2001).

$\Phi : X \rightarrow H$ giriş uzayından $X \subset R_m$ öznitelik uzayına H doğrusal olmayan dönüşümü gösterdiği farz edilirse problem H' 'de doğrusal olarak ayrılabilir. Buna karşılık gelen en uygun hiper düzlem Eşitlik 2.27'deki şekilde ifade edilebilir.

$$W^{\Phi T} \Phi(x) + b = 0 \quad (2.27)$$

Öznitelik uzayında hesaplanan optimal hiper düzlem ise Eşitlik 2.28'de gösterildiği gibidir.

$$\sum_{i=1}^n a_i * y_i W^{\Phi T}(x_i) \Phi(x) = 0 \quad (2.28)$$

Eşitlik 2.28'de yer alan $W^{\Phi T}(x_i) \phi(x) = 0$ terimi $\phi(x_i)$ ve $\phi(x)$ vektörlerinin iç çarpımını göstermektedir. Bu yüzden de burada iç çarpım çekirdek fonksiyonunu kullanmak gerekmektedir. Çekirdek fonksiyonu Eşitlik 2.29'daki gibi bir fonksiyondur.

$$K = (x, x) = \phi^T(x) \phi(x) \quad (2.29)$$

Eşitlik 2.29'daki ϕ giriş uzayı (input space) olan X 'ten öznitelik uzayı olan H' 'ye olan dönüşüm fonksiyonunu göstermektedir. Optimal öznitelik uzayında hiper düzlem oluşturmak için ϕ dönüşümünün somutlaştırılmış biçimini gözetmeksizin çekirdek fonksiyonunu kullanabilmektedir. Bu sebeple, DVM için çekirdek fonksiyonun önemi çok büyüktür. Çekirdek fonksiyonunun uygulanması, geçerli algoritmanın boyuta bağlılığını ortadan kaldırmaktadır. Bununla birlikte doğrusal olarak ayrılamayan veri problemlerinin etkili çözümü ile yüksek boyutlu bir uzayda doğrusal bir sınıflandırıcıyı eğitmek amacıyla da tercih edilmektedir. Bahsedilen bu durum Eşitlik 2.29'daki $\phi^T(x) \phi(x)$ yerine $K(x_i, x)$ kullanarak yapılabilir ve optimal hiper düzlem Eşitlik 2.30'daki biçimde verilir (Christianini and Taylor 2000).

$$\sum_{i=1}^n a_i^* y_i K(x_i, x) \quad (2.30)$$

Çekirdek fonksiyonları hesaplamayı basitleştirmek için öncelikli tercih edilen yöntemlerden biridir. Bu yöntem sayesinde karmaşık öznitelik uzayını hesaplama

karmaşıklığından sakınılmış olunabilir. Çekirdek fonksiyonunu uygulamadan önce, fonksiyonun nasıl seçileceği, hangi karakteristik özellikleri taşıyacağı oldukça önemlidir. Yani bir çekirdek fonksiyonu hangi karakteristikleri sağlamalıdır? Gerçek bir çekirdek fonksiyonu olarak kabul gören çekirdek fonksiyonunun özelliğini karakterize eden "Mercer teoreminin" iyi bilinmesi de çekirdek fonksiyonun özelliklerinin anlaşılması için oldukça önemlidir (Christianini and Taylor 2000).

DVM'de sık kullanılan bazı çekirdek fonksiyonları doğrusal çekirdek fonksiyonu, polinomsal çekirdek fonksiyonu, sigmoid çekirdek fonksiyonu ve radyal tabanlı çekirdek fonksiyonudur (Yu *et al.* 2006).

2.4.2.1 Doğrusal Çekirdek Fonksiyonu

Bu aslında vektörlerin nokta ürünüdür ve haritalama uygulanmaz. DVR bir çekirdek işlevi ile kodlanacağından doğrusal çekirdek seçimler arasında olacaktır (Uzman 2015). Eşitlik 2.31'de doğrusal çekirdek fonksiyonu gösterilmiştir.

$$K(x_i, x_j) = x_i \cdot x_j \quad (2.31)$$

2.4.2.2 Polinomsal Çekirdek Fonksiyonu

Polinomsal çekirdek fonksiyonu doğrusal olmayan modelleme için popüler seçimler arasındadır ve Eşitlik 2.32'deki şekilde formüle edilmiştir. Burada d polinom derecesinin çekirdek parametresidir (Uzman 2015).

$$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + c)^d \quad (2.32)$$

2.4.2.3 Radyal Tabanlı Çekirdek Fonksiyonu (RTF)

İki vektör arasındaki öklid mesafesinin karesini kullanan RTF, Eşitlik 2.33'teki formül ile hesaplanmaktadır (Uzman 2015).

$$K(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2) \quad (2.33)$$


2.4.2.4 Sigmoid Çekirdek Fonksiyonu

Sigmoid çekirdek fonksiyonu ise Eşitlik 2.34'te olduğu gibi hesaplanmaktadır.

$$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) + c) \quad (2.34)$$


2.4.3 Destek Vektör Regresyon

Destek vektör regresyonda da sınıflandırma algoritmasında olduğu gibi doğrusal öğrenme metotları ve çekirdek fonksiyonları yardımıyla elde edilen doğrusal olmayan fonksiyonlar kullanılarak maksimum marj metodunun temel özelliklerinin bulunması amaçlanmaktadır. DVR'nin ana prensibi, birkaç küçük farklılığa sahip olmakla beraber sınıflandırma için DVM ile aynıdır. Temel olarak, DVM alternatif bir kayıp fonksiyonunun içe aktarılmasıyla regresyon problemlerine uygulanabilir (Haykin 2001). Şekil 2.9'da farklı olası kayıp fonksiyonlarını göstermektedir (Gunn 1998).



Şekil 2.9 DVR'de Kullanılan Kayıp Fonksiyonları

Regresyon problemleri için, gürültünün ardındaki dağılım uzun bir uzantıya sahip olduğu durumlarda bağımsız değişkende meydana gelen kötü performansa sahip olan aykırı verilerin var olması ile birlikte geleneksel en küçük kareler tahmin edicisi uygulanamayabilir (Haykin 2001). Bu sebeptendir ki, tasarlanan model içinde ufak farklılıklara karşın ϵ duyarsızlık kayıp fonksiyonu tanımlanmıştır. Duyarsızlık kayıp fonksiyonunun regresyon doğrusu üzerinde bulunduğu nokta Şekil 2.10'da gösterilmektedir (İnt.Kyn.2).



Şekil 2.10 ε -Duyarsız Kayıp Fonksiyonu ve Gevşek Değişkenler

Şekil 2.9'da (a) en küçük hata kriterleri ile ilgili olan ikinci dereceden kayıp fonksiyonu, (b) ikinci dereceden kayıp fonksiyonundan ziyade sapmalara daha az duyarlı olan Laplacian tip kayıp fonksiyonu, (c) veri dağılımı bilinmediğinde en uygun özellikleri içeren Huber kayıp fonksiyonu ve (d) duyarsızlık kayıp fonksiyonudur (Kor 2015).

2.5 Model Belirleme Kriterleri

Bir modele eklenen her açıklayıcı değişken uyumu iyileştirmez. Açıklayıcı değişken istatistiksel olarak anlamlı olsa bile modele eklenmesi faydalı olmayabilir. Açıklayıcı değişkenlerin sayısının artırılması, parametre sayısını artırır ve uyumun hatalarını azaltır. Bununla birlikte, modelde ne kadar fazla parametre varsa $\widehat{\beta}_j$ 'nin varyansları o kadar büyük olur (Jong and Heller 2008).

Araştırmacılar tarafından başvurulan yaygın model seçim ölçütleri R^2 , Düzeltilmiş R^2 , Akaike Bilgi Kriteri, Bayesçi Bilgi Kriteri, Hannan-Quinn Ölçütü olarak sıralanabilir (İnt.Kyn.3).

2.5.1 R^2

0 ve 1 aralığında değerler alır, 1'e yaklaştığında en iyi açıklanabilirliği verir ve Eşitlik 2.35 yardımıyla hesaplanabilir.

$$R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (2.35)$$

Fakat R^2 birmodel seçiminde kullandığında birkaç sorunla karşılaşılabilir (Gujarati 2003, Ucal 2006):

- Verilen örnekler içerisinde tahmini değerler gerçek değerlere ne kadar yakın çıksa dahi gelecek tahmininde bu garanti sağlanmayabilir.
- R^2 'lerin karşılaştırılabilmesi için modellerin fonksiyonel yapısının ve tahmin edicilerinin aynı olması gerekmektedir.

2.5.2 Düzeltilmiş R^2

Regresyon uyum iyiliği (goodness of fit) olarak R^2 kullanıldığında artıkların toplam karesi ne kadar düşük olursa uyum o kadar yüksek oluyor. Ancak bağımsız değişken sayısı arttıkça payda düşmeye devam eder. Böylelikle R^2 düşmez ve ne kadar çok değişken modele katılırsa o kadar yüksek bir uyum ortaya çıkar. Model karmaşıklığını azaltmak ve anlaşılabilir, yorumlanabilir modeller oluşturmak için hedef değişkene etkisi olmayan, az olan veya etkisi ihmal edilebilen değişkenler modele dahil edilmez. Bu sebeple uyum iyiliği kullanırken R^2 geliştirilerek düzeltilmiş R^2 kullanılmaktadır. Düzeltilmiş R^2 'nin R^2 'den farkı gereksiz eklenen bağımsız değişkenleri cezalandırıyor olmasıdır. Eşitlik 2.36'da bunun nasıl olduğu görülebilir (İnt.Kyn.4).

$$Düzeltilmiş R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad (2.36)$$

p: bağımsız değişken sayısını

n: örneklem büyüklüğünü gösterir

Düzeltilmiş R^2 , EKK yöntemiyle tahminde daha sık kullanılmaktadır (Burnham and Anderson 2002).

2.5.3 Akaike Bilgi Kriteri ve Bayeşçi Bilgi Kriteri (AIC ve BIC)

Bir modelin uyum iyiliğini, parametre sayısı için bir ceza terimiyle dengeleyen bir dizi kriter vardır. En bilinenleri AIC ve BIC'dir (Fabozzi *et al.* 2014). AIC ve BIC değerleri sırasıyla Eşitlik 2.37 ve Eşitlik 2.38'deki gibi hesaplanır.

$$AIC = -2\log L(\hat{\theta}) + 2k \quad (2.37)$$

Burada:

$L(\hat{\theta})$ = model tarafından elde edilebilecek θ' 'nin en yüksek olasılık tahmini

k = modeldeki parametre sayısı

Her model için hesaplanan AIC değeri, hangi modelde daha düşük sonuç veriyorsa o model en iyisidir.

$$BIC = -2\log L(\hat{\theta}) + k \ln(N) \quad (2.38)$$

Burada:

N = kullanılan veri sayısıdır (Little 2007).

Bu iki kriterin uygulamaları genellikle ulaşılan sonuçlarda geniş bir uzlaşma göstermiştir ancak modellerin detaylı sıralamasında ara sıra farklar ortaya çıkmıştır (Burnham and Anderson 2002).

2.6 Performans Fonksiyonları

Kurulan modellere ait performanslarının değerlendirilmesinde kullanılan literatürde birçok fonksiyon bulunmaktadır. Bunlar, ortalama mutlak hata (OMH), hata kareler ortalaması (HKO), ortalama hata karelerin karekökü (HKOK) ve toplam karesel hata

(TKH) olarak bilinmektedir. Bu performans fonksiyonlarının formülleri sırasıyla Eşitlik 2.39, Eşitlik 2.40, Eşitlik 2.41 ve Eşitlik 2.42'de gösterilmiştir.

$$OMH = \frac{1}{N} \sum_{j=1}^n |e_j| \quad (2.39)$$

OMH, iki sürekli değişken arasındaki farkı ölçer, regresyon ve zaman serisi problemlerinde sıkça kullanılır. Değeri 0'dan ∞ 'a kadar değişebilir. Tahmin edicinin değeri düştüğünde daha iyi bir performansa sahip olur (İnt.Kyn.5).

$$HKO = \frac{1}{N} \sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2 \quad (2.40)$$

Basitçe, hata kareler ortalaması bir regresyon eğrisinin ortalamaya olan yakınlığını gösterir. HKO her zaman pozitif değer alır ve sıfıra yaklaştıkça tahmin edici daha iyi bir performans sergiler (İnt.Kyn.5).

$$HKOK = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2} \quad (2.41)$$

HKOK tahminde yapılan hataların (kalıntıların) standart sapmasıdır. 0 ile ∞ arasındadır. Eğer HKOK sıfırsa model hiç hata yapmamıştır (İnt.Kyn.5).

$$TKH = \sum_{k=1}^N (y_{gerçek} - y_{tahmin})^2 \quad (2.42)$$

3. MATERYAL ve METOT

Bu çalışmada Türkiye'nin doğal gaz piyasasındaki yeri, üretim, tüketim, ithalat ve ihracat değerleri incelenmiştir. 1980'li yıllarda ilk olarak ısınma amaçlı olarak ülkemizde kullanımına başlanılan doğal gaz, bugün başta elektrik üretimi olmak üzere konut, sanayi ve diğer kullanımlarda etkinliğini artırmış ve ülkemiz enerji sektörünün önemli kaynaklarından biri konumuna gelmiştir (EPDK 2012). Konut sektörü, doğal gazı ağırlıklı olarak ısınma amaçlı kullanmakta, dolaylı olarak elektrik tüketimi nedeniyle de doğal gaz talebini etkilemektedir. Sanayi sektöründe, doğal gaz hammadde olarak kullanılmakta olup ikamesi güçtür. Elektrik üretimi sektöründe de, gerek dünya genelinde gerek ülkemizde, elektrik piyasaları mevcut haliyle doğal gaza bağımlı durumdadır (Topçu 2013).

Türkiye'de doğal gaz üretimi yapılan şehirler arasında; Adıyaman, Düzce, Edirne, İstanbul, Mardin, Kırklareli ve Tekirdağ yer almakla beraber zamanla üretim sahası artmış ve Adana ve Çanakkale illeri de dahil olmuştur. Doğal gaz LNG ve Boru gazı olarak ikiye ayrılmaktadır. Boru gazı ithal edilen ülkeler Rusya, İran, Azerbaycan; LNG ithal edilen ülkeler ise Cezayir, Nijerya ve diğerleridir. Türkiye doğal gaz ihracatını ise sadece Yunanistan'a yapmaktadır (EPDK 2017).

Son yıllarda literatürde gelecek dönem doğal gaz tüketim tahmini için zaman serisi analizi, yapay sinir ağları oldukça kullanılmıştır. Yine bu çalışmalarda girdi olarak birçok farklı bağımsız değişken kullanılmıştır. Doğal gazın enerji santralleri tüketiminde (bin sm^3) en çok kullanılan bağımsız değişkenlerin arasında sanayi tüketimi (bin sm^3), şehir tüketimi (bin sm^3), üretim (milyon sm^3), ithalat (milyon sm^3) ve ihracat (milyon sm^3) verileri gösterilebilir. Bu değişkenlerden bazıları, elde edilebilecek tahmin üzerinde büyük etkiye sahipken bazılarının daha zayıf etkisi olacaktır. Çalışmada Enerji İşleri Genel Müdürlüğü'nün ve Türkiye Enerji Piyasası Düzenleme Kurumunun doğal gaz piyasası sektör raporları derlenerek 2013 Ocak - 2018 Nisan aylarını kapsayan aylık doğal gaz tüketim miktarları elde edilmiş ve DVR yardımıyla gelecek sekiz ayın enerji santrallerindeki doğal gaz tüketim miktarları tahmin edilmiştir. Daha sonra veriler üzerinde trend analizi yapılarak da tahminler elde edilmiştir ve her iki yöntemle de

ıkan sonular karşılařtırılmıřtır. alıřmada DVR ile hangi ekirdek fonksiyonunun seilmesine karar vermek amacıyla Statistica, gerekli hesaplamaların yapılması iin ise MATLAB paket programı kullanılmıřtır. Ayrıca trend analizinin yapılabilmesi iin Minitab programı kullanılmıřtır.



4. BULGULAR

Bu çalışmada ilk olarak, Türkiye'de doğal gazın enerji piyasasındaki yeri, birincil enerji kaynakları içindeki payı incelenmiştir. Üretim (milyon sm^3), sanayi tüketimi (bin sm^3), şehir tüketimi (bin sm^3), ithalat (milyon sm^3) ve ihracat (milyon sm^3) değerlerine bakılmıştır. Bu değerlerin ölçü birimlerinin farklılığından dolayı, ilgili veri seti istatistiksel analizden önce standartlaştırılmıştır. Daha sonra çalışmada kullanılacak bağımsız değişken seçimi için 4 farklı model kurulmuştur. Bu modeller Çizelge 4.1'de gösterilmiştir ve model seçiminde AIC'nin en düşük değerine bakarak karar verilmiştir.

Çizelge 4.1 Bağımsız Değişkenlerin Seçimi İçin Kurulan Modeller

Modeller	X ₁	X ₂	X ₃	X ₄	X ₅	S.D	AIC	BIC
Model1	Sanayi Tüketimi	Şehir Tüketimi	Üretim	İthalat	İhracat	5	99,869	112,823
Model2	Şehir Tüketimi	Üretim	İthalat	İhracat		4	167,504	180,953
Model3	Şehir Tüketimi	Üretim	İhracat			3	169,660	186,614
Model4	Şehir Tüketimi	İthalat				2	167,684	186,638

Model belirlendikten sonra veriler %75 eğitim ve %25 test verisi olarak ikiye ayrılmıştır. Çizelge 4.2 ve Çizelge 4.3'te analizde kullanılan eğitim ve test kümeleri gösterilmektedir.

Çizelge 4.2 DVR'de Kullanılacak Olan Eğitim Kümesi

Sanayi Tüketimi (bin sm^3)	Şehir Tüketimi (bin sm^3)	Üretim (milyon sm^3)	İthalat (milyon sm^3)	İhracat (milyon sm^3)	Enerji Santralleri Tüketimi (bin sm^3)
0,94446	0,84808	1,724989	0,49992	-0,49148	0,26247
0,20661	0,16519	2,020390	-0,30977	-1,25760	-0,52581
-0,34378	-0,56065	1,404581	-0,86275	0,31755	-0,76560
-3,00254	-1,09276	1,090425	-0,78089	-1,01244	-0,18707
-0,61794	-1,16177	1,106055	-1,24367	0,80787	0,28155
-0,38885	-1,17185	1,445218	-0,91677	0,45239	0,52726
-0,63137	-1,20907	0,970077	-1,08655	0,32981	0,10085
-0,02352	-0,64636	1,615582	-0,74046	1,13270	-0,42919
0,58248	-0,25707	2,065716	-0,25033	1,07754	0,61259
2,14247	1,12742	1,964123	1,03332	0,23787	-1,48336
1,24815	0,64162	2,137612	0,81992	0,91819	0,87357
0,56351	0,28329	0,918499	0,10375	0,49529	-0,31365
0,41427	0,10898	1,340500	0,49895	0,23787	0,98367
0,00479	-0,60488	0,973203	-0,02741	-1,01857	0,33710
-0,21061	-0,96264	0,910684	-0,31903	-1,71114	0,53495
-0,25139	-1,19598	0,172964	-0,55958	0,96722	1,35230
-0,18573	-1,20352	0,332387	-0,38571	1,26141	1,49039
-0,22364	-1,13249	0,360520	-0,30387	0,99786	1,41428
-0,23545	-0,79085	0,183905	-0,86966	-1,94404	0,48732

Çizelge 4.2 (Devam) DVR'de Kullanılacak Olan Eğitim Kümesi

Sanayi Tüketimi (bin sm ³)	Şehir Tüketimi (bin sm ³)	Üretim (milyon sm ³)	İthalat (milyon sm ³)	İhracat (milyon sm ³)	Enerji Santralleri Tüketimi (bin sm ³)
1,18018	0,61337	0,724691	1,08547	0,01723	1,68909
1,65418	1,16615	0,035423	1,07768	-1,41082	0,10142
0,76656	0,75422	-0,672600	0,62295	-0,45470	-0,27889
0,77435	0,52824	-0,324059	0,17610	0,81400	-0,17899
0,14675	-0,10415	-0,136503	-0,70593	-0,13600	-1,02576
-0,52106	-1,00499	-0,267792	-1,00627	-0,09309	-1,02948
-0,67145	-1,08931	-0,427215	-1,17084	-2,04211	-0,91011
-0,67694	-1,14149	-0,786697	-1,01552	1,09593	-0,23359
-0,50152	-1,13945	-0,533496	-0,49502	1,12657	1,34149
1,45092	1,45680	-0,671037	1,50751	0,80174	0,62629
-0,39916	1,09553	-0,128688	-0,40587	0,72819	-1,46852
-2,04966	0,58385	-0,533496	-0,73017	1,01012	-1,18436
-2,17919	0,55323	-0,663223	-1,15293	1,09593	-1,93479

Çizelge 4.3 DVR'de Kullanılacak Olan Test Kümesi

Sanayi Tüketimi (bin sm ³)	Şehir Tüketimi (bin sm ³)	Üretim (milyon sm ³)	İthalat (milyon sm ³)	İhracat (milyon sm ³)	Enerji Santralleri Tüketimi (bin sm ³)
0,246624	0,41428	1,24203	-0,05205	-0,54664	-0,378434
-0,322606	-1,14217	1,27329	-0,76333	0,82625	0,354053
-0,443816	-1,13198	0,40585	-1,04583	-0,11761	0,559740
0,894652	0,06411	0,52619	0,52802	-1,26986	1,184472
-0,682967	-1,13641	-1,15556	-0,56595	0,42174	0,391663
-0,086994	-0,78383	-0,59133	-0,48920	-0,56502	0,200445
0,616107	-0,15053	-0,92580	0,76939	-1,26373	0,004457
1,256476	1,97520	0,04636	1,57227	-0,20954	-0,606998
-0,443340	1,21004	-0,43659	-0,21617	-2,39759	-0,875817

Çalışmada kullanılan Model 1 içerisinde yer alan bağımsız değişkenler; sanayi tüketimi, şehir tüketimi, üretim, ithalat ve ihracat olarak belirlendikten sonra DVM'de kullanılacak olan çekirdek fonksiyonunun seçiminde daha önceki bölümlerde anlatılan tüm çekirdek fonksiyonları denenmiş ve performanslarına göre en iyi çekirdek fonksiyonu en düşük HKO değerine sahip olan RTF çekirdek fonksiyonu olarak belirlenmiştir. Çizelge 4.4, Çizelge 4.5, Çizelge 4.6 ve Çizelge 4.7 farklı çekirdek fonksiyonlarına ait performansları göstermektedir.

Çizelge 4.4 Doğrusal Çekirdek Fonksiyonu Performans Kriterleri

Performans	Eğitim	Test
OMH	0,374	0,522
HKO	0,254	0,431
HKOK	0,503	0,656
TKH	16,256	27,584

Çizelge 4.5 Polinomial Çekirdek Fonksiyonu Performans Kriterleri

Performans	Eğitim	Test
OMH	0,533	0,433
HKO	0,461	0,290
HKOK	0,679	0,539
TKH	29,504	18,560

Çizelge 4.6 RBF Çekirdek Fonksiyonu Performans Kriterleri

Performans	Eğitim	Test
OMH	0,333	0,440
HKO	0,249	0,276
HKOK	0,499	0,525
TKH	15,936	17,664

Çizelge 4.7 Sigmoid Çekirdek Fonksiyonu Performans Kriterleri

Performans	Eğitim	Test
OMH	0,412	0,454
HKO	0,353	0,328
HKOK	0,594	0,573
TKH	22,592	20,992

Çalışmanın devamında MATLAB paket programına geçilerek RTF çekirdek fonksiyonu kullanılarak oluşturulan modelin katsayıları hesaplanmıştır. Burada da daha önce bilgisi verilen DVM'nin yapısı gereği öncelikle destek vektörlerle ağırlıklar çarpılmış, üzerine yan (0,1) eklenmiş ve ortaya bir model çıkmıştır.

C parametresi 8 ve yan terimi 0,1 iken hesaplanan model katsayıları Eşitlik 4.1'deki gibidir:

$$\hat{Y} = -0,349 - 0,072 * X_1 - 4,449 * X_2 + 0,459 * X_3 + 4,890 * X_4 + 0,895 * X_5 \quad (4.1)$$

Burada -0,349 sabit katsayı ve

X₁: Sanayi Tüketimi,

X₂: Şehir Tüketimi,

X₃: Üretim,

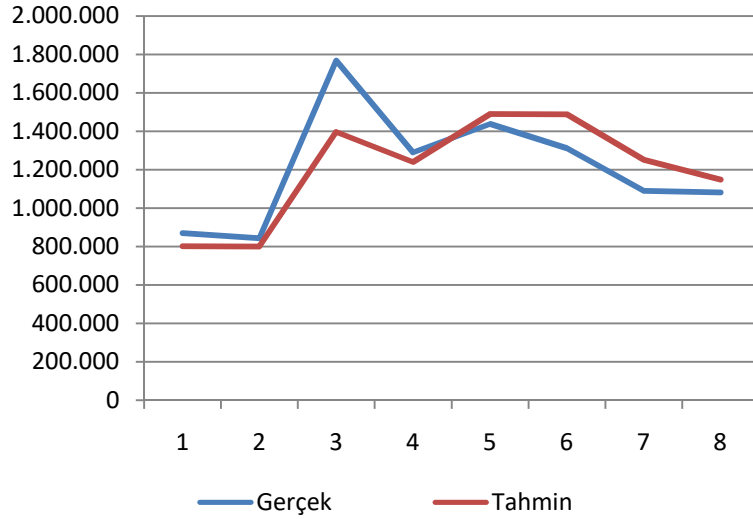
X₄: İthalat,

X₅: İhracat

ise bağımsız değişkenlerdir. Burada 2018 yılının son sekiz aylık dönemi için tahmin yapılmış bu tahminler gerçek değerler ile karşılaştırılmıştır çıkan değerler Çizelge 4.8'de ve bu karşılaştırmayı gösteren grafik ise Şekil 4.1'de verilmiştir.

Çizelge 4.8 DVM Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılması

Aylar	Gerçek	Tahmin
Mayıs	869 451	873 048
Haziran	843 344	822 499
Temmuz	1 767 067	1 881 988
Ağustos	1 289 299	1 306 750
Eylül	1 438 252	1 401 496
Ekim	1 311 603	1 316 965
Kasım	1 089 548	1 155 373
Aralık	1 082 018	1 070 842




Şekil 4.1 DVM Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılmasını Gösteren Grafik

Çizelge 4.9 Trend Analizinin Yapılmasında En Uygun Denklemin Belirlenmesi

Denklemler	HKO
Doğrusal	0,410
Üstel	0,413
İkinci Dereceden	0,404

Çizelge 4.10 Trend Analizi Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılması

Aylar	Gerçek	Tahmin
Mayıs	869 451	1 278 501
Haziran	843 344	1 282 944
Temmuz	1 767 067	1 287 547
Ağustos	1 289 299	1 292 308
Eylül	1 438 252	1 297 227
Ekim	1 311 603	1 302 306
Kasım	1 089 548	1 312 940
Aralık	1 082 018	1 318 485



Şekil 4.2 Trend Analizi Kullanılarak Yapılan Tahminler ile Gerçek Değerlerin Karşılaştırılmasını Gösteren Grafik

Çizelge 4.8'de yapılan karşılaştırmaya göre destek vektör makineleri yöntemi kullanarak yapılan tahminlerin, gerçeğe uygunluğunun yüksek olduğu görülmektedir. Ayrıca destek vektör makinelerinin yanında verilere trend analizi uygulanmış en uygun trend denkleminin belirlenmesinde ortaya çıkan HKO değerleri Çizelge 4.9 da gösterilmiştir. Trend analiziyle yapılan tahminler Çizelge 4.10'da ve tahminler ile gerçek değerlerin arasındaki farkı gösteren grafik ise Şekil 4.2'de gösterilmiştir. Böylece buradan da öngörüm değerleri elde edilmiştir. Destek vektör makineleriyle elde edilen sonuçlar ile trend analizi sonuçları karşılaştırıldığında destek vektör makinelerinin daha iyi sonuçlar verdiği gözlemlenmiştir. Bu sonuçlardan hareketle doğal gaz tüketim tahminlerinde yapay sinir ağları ve zaman serisi analizi yanında destek vektör makinelerinin de kullanılabileceği söylenebilir.

5. TARTIŞMA ve SONUÇ

Destek Vektör Makinelerinde regresyon yöntemi kullanılarak Türkiye'deki enerji santrallerinde doğal gaz tüketimi tahmininin bulunması amaçlanan bu çalışmada; veriler üzerinde trend analizi yapılmış en uygun HKO değerine sahip denklem olan ikinci dereceden denklem seçilerek tahmin değerleri elde edilmiştir. Daha önce destek vektör makineleri kullanılarak farklı alanlarda yapılan çalışmalar incelendiğinde (Bilişik 2011, Yakut vd. 2014, Yalçın 2016, Uzman 2015, Yüreklı 2017, Sönmez 2016, Uçak 2012, Arat 2014, Akdağ 2016) DVM'lerinin diğer yöntemlerden daha iyi sonuç verdiği dikkat çekmektedir. Ancak daha önceki doğal gaz tahminine yönelik yapılan çalışmalarda Akgül (2013), yapay sinir ağları yöntemi ve klasik zaman serileri yöntemi kullanılarak doğal gaz tüketim tahminlerini yıllık olarak elde etmiş, sonucunda doğrusal olmayan problemlerde iyi sonuçlar veren yapay sinir ağlarının yine zaman serilerine göre daha iyi sonuçlar verdiği karar vermiştir. Topçu (2013) ise, doğal gaz tüketim tahminlerini üretirken sadece zaman serileri yöntemini kullanmış ve uzun dönem yıllık doğal gaz tüketim tahminlerini elde etmiştir.

Bu çalışmada elde edilen sonuçlar özetlenecek olursa ilk olarak, değişkenlerdeki ölçü birimlerinin farklılığından dolayı veriler standart normal dağılıma uygun hale getirilmiştir. Hemen ardından bağımsız değişkenlerin seçimi için serbestlik dereceleri sırasıyla 5, 4, 3, 2 olan modeller kurulmuş ve bunların AIC ve BIC değerlerine bakılmıştır. Serbestlik derecesi 5 ve en düşük AIC değerine sahip (99,869) olan model en iyi olarak seçilmiş ve çalışmaya bu modeldeki bağımsız değişkenler üzerinden devam edilmiştir. Daha sonra doğrusal olmayan destek vektör regresyonda kullanılan çekirdek fonksiyonlarının hepsi denenmiş ve performansları karşılaştırılmıştır en iyi performansın RTF (Eğitim HKO = 0,249, Test HKO = 0,276 olmak üzere) tarafından verildiği görülmüştür. Bunun üzerine ortaya çıkan destek vektörler ile ağırlıklar çarpılmış ve üzerine yan eklenerek katsayılar belirlenmiş böylece $\hat{Y} = -0,349 - 0,072 * X_1 - 4,449 * X_2 + 0,459 * X_3 + 4,890 * X_4 + 0,895 * X_5$ denklemi elde edilmiştir. Bu denkleme bağlı olarak tahminler elde edilmiş ve daha sonra verilere trend analizi uygulanmış burada da en düşük HKO değerine sahip olan ikinci dereceden denkleme göre tahminler

bulunmuştur. Sonuçlar karşılaştırıldığında destek vektör makinelerinin daha iyi sonuçlar verdiği gözlemlenmiştir.

Dolayısıyla, bu çalışmada karmaşık model problemlerinde daha çok tercih edilen DVR'nin doğal gaz tüketimi tahmininde de kullanılabileceği gösterilmiş ve daha önce doğal gaz tüketim tahminlerinde bu yöntem kullanılmadığından dolayı literatüre katkı sağlayacağı da öngörülmektedir.

Çalışmadan elde edilen bulgular doğrultusunda, doğal gaz tüketim tahminine yönelik gelecek çalışmalarda bu çalışmada kullanılan bağımsız değişkenler dışında farklı değişkenler (örneğin: Türkiye'nin nüfusu, doğal gaz fiyatı, ekonomik koşullar vb.) kullanılarak DVR, yapay sinir ağları, zaman serileri analizi gibi yöntemler yardımı ile gelecek dönemler için öngörülerde bulunulabilir.

6. KAYNAKLAR

- Abe, S. (2010). Support Vector Machines for Pattern Classification. Springer London Limited, New York.
- Akdağ, R. (2016). Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İçme Suyu Talebi Tahmini ve Karşılaştırmalı Analizi. *Business and Economics Research Journal*, **136**: 123-138.
- Akgül, S. (2013). Doğal Gaz Tüketim Tahmini, *Sosyal ve Beşeri Bilimler Dergisi*, **450**: 440-452.
- Alpaydın, E. (2010). Yapay Öğrenme. Boğaziçi Üniversitesi Yayınevi, 2. Baskı, İstanbul.
- Anonim, 2012. Doğalgaz Piyasası Sektör Raporu. EPDK, Ankara.
- Anonim, 2017. Doğalgaz Piyasası Sektör Raporu. EPDK, Ankara.
- Arat, M. (2014). Destek Vektör Makineleri Üzerine Bir Çalışma. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Bican, B. (2014). Zaman Serilerinin Öngörüsü İçin GKA Tabanlı DVR Metodları. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bilişik, M.T. (2011). Destek Vektör Makinesi, Çoklu Regresyon ve Doğrusal Olmayan Programlama ile Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma. XI. Üretim Araştırmaları Sempozyumu, İstanbul Kültür Üniversitesi, 23-24 Haziran 2011, 785-799.
- Burnham, K. and Anderson, D. (2002). Model Selection and Multimodel Inference A practical Information - Theoretic Approach. Springer - Verlag, Second Education, New York.
- Christiannini, N. and Taylor J.S. (2000). An Introduction to Support Vector Machines and Other Kernel - Based Learning Methods. Cambridge University Press, Cambridge.
- Çomak, E. (2008). Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.

- Fabozzi, F.J, Focardi, S.M., Rachev, S.T. and Arshanapalli, B.G. (2014). The Basics of Financial Econometrics: Tools, Concepts and Asset Management Applications. John Wiley & Sons, Inc. Published.
- Gollapudi, S. And Laxmikanth, V.(2016). Practical Machine Learning. Pact Publishing, Birmingham, U.K.
- Gunn, S.R. (1998). Support Vector Machines for Classification and Regression. University of Southampton. Technical Report Faculty of Engineering, Science and Mathematics School of Electronics and Computer Science, İngiltere.
- Gujarati, D. (2003). Basic Econometrics. Mc Graw Hill Higher Education, Fourth Edition, Singapore.
- Gürsakal, N. (2017). Makine Öğrenmesi ve Derin Öğrenme. Dora Yayınları, 1. Baskı, Gündoğan, Bodrum .
- Haykin, S. (2001). Neural Networks: A Compherensive Foundation. Pearson Education Publishing, Second Edition, India.
- Jong, P. and Heller, G. (2008). Generalized Linear Models For Innsurance Data. Cambridge University Press, New York.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Çekirdek Fonksiyonlarının Etkilerinin İncelenmesi, *Harita Dergisi*, **75**: 73-82.
- Kaytez, F. (2012). En Küçük Kareler Destek Vektör Makineleri İle Türkiye'nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellenmesi. Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Kor, K. (2015). Penetration Rate Optimization With Support Vector Regression Method. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Kuzey, C. (2012). Veri Madenciliğinde Destek Vektör Makineleri ve Karar Ağaçları Yöntemlerini Kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama. Doktora Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Little, A.R. (2007). Information Criteria For Astrophysical Model Selection. *Monthly Notices of the Royal Astronomical Society: Letters*, **72**: 71-76.

- Osuna, E.E., Freund, R. and Girosi, F. (1997). Support Vector Machines: Training and Applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory, Massachusetts.
- Öztemel, E. (2006). Yapay Sinir Ağları. Papatya Yayıncılık, 2. Baskı, Çağaloğlu, İstanbul.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M.(2003). Mühendislikte Yapa Zeka Uygulamaları I: YapaySinir Ağları. Ufuk Kitap Kırtasiye - Yayıncılık, 1. Baskı, Kayseri.
- Selçuk, Z. (1999). Gelişim ve Öğrenme: Eğitim Psikolojisi. Nobel Yayıncılık, 13. Baskı, Ankara
- Sönmez, Ö.T. (2016). ATM Nakit İkmal Optimizasyonunda Asimetrik Destek Vektör Regresyon Tahmin Modeli Yaklaşımı. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Topçu, G.Y. (2013). Türkiye Doğal Gaz Tahmini. Yüksek Lisans Tezi, Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.
- Ucal, M. Ş. (2006). Ekonometrik Model Seçim Kriterleri Üzerine Kısa Bir İnceleme. *C.Ü. İktisadi ve İdari Bilimler Dergisi*, **44**: 41-57.
- Uçak, K. (2012). Destek Vektör Regresyonu İle Pid Kontrolör Tasarımı. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Uzman, F. (2015). Estimating Physical Properties of the Products of an Atmospheric Distillation Column by Support Vector Regression. The Degree of Master of Science, Koç Üniversitesi, Graduate School of Sciences and Engineering, İstanbul.
- Vapnik, N.V. (1998). Statistical Learning Theory. John Wiley & Sons, New York.
- Vapnik, N.V. (2000). The Nature of Statistical Learning Theory. Springer - Verlag, Second Education, New York.
- Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **139**: 139-157.
- Yalçın, C. (2016). Destek Vektör Regresyon İle Uçaklarda Anlık Yakıt Tüketiminin Analizi. Doktora Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Yılmaz, M. (2009). Öğrenme ve Bilgi İlişkisi. *Gazi Eğitim Fakültesi Dergisi*, **175**: 173-191.
- Yolasıǧmaz, İ.B. (2015). Destek Vektör Regresyon Metodu Kullanarak İnşaat Projelerinin Kavramsal Maliyet Tahmini. Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Yu, P.S., Chen, S.T. and Chang, F. (2006). Support Vector Regression For Real-Time Flood Stage Forecasting. *Journal of Hydrology*, **707**: 704–716.
- Yürekli, Ş. (2017). Geniş Çalışma Bölgesi Bir Mikrodalga Transistörünün Destek Vektör Regresyon Makinesi İle Modellenmesi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

İnternet Kaynakları

- 1- <http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf>, 05.04.2019
- 2- <https://alex.smola.org/papers/2003/SmoSch03b.pdf>, 07.04.2019
- 3- http://www.acikders.org.tr/pluginfile.php/2616/mod_resource/content/2/ekonometri2-tuba, 26.03.2019
- 4- <http://www.datascience.istanbul/2017/07/11/r-kare-ve-duzeltilmis-r-kare/>, 28.03.2019
- 5- <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>, 28.03.2019

ÖZGEÇMİŞ

Adı Soyadı : Gizem Meral
Doğum Yeri ve Tarihi : Karacabey-29.06.1994
Yabancı Dili : İngilizce
İletişim (Telefon/E-posta) : gizem.meral.1994@gmail.com

Eğitim Durumu (Kurum ve Yıl)

Lise : İMKB Kız Teknik ve Meslek Lisesi (2008-2012)
Önlisans : Balıkesir Üniversitesi Edremit MYO (2012-2014)
Lisans : Afyon Kocatepe Üniversitesi (2014-2017)

Çalıştığı Kurum/Kurumlar ve Yıl:

Yayınları (SCI ve diğer):

Diğer Konular: