



**HAFİF RAYLI SİSTEM ARAÇLARINDA MEYDANA GELEN  
ARIZALARIN TAHMİNİ**

**Semah GÜLERYÜZ**

**YÜKSEK LİSANS TEZİ  
ENERJİ SİSTEMLERİ MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**OCAK 2023**

## ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Semah GÜLERYÜZ

26/01/2023

# HAFİF RAYLI SİSTEM ARAÇLARINDA MEYDANA GELEN ARIZALARIN TAHMINİ

(Yüksek Lisans Tezi)

Semah GÜLERYÜZ

GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2023

## ÖZET

Günümüzde artan rekabet ile birlikte özellikle lojistik ve hizmet sektöründe stratejik planlar günden güne önem kazanmakta ve işletmelerin hedefi maliyet ve zaman açısından kar elde etmektir. Bu hedefe ancak doğru bir plan yapılarak ulaşılabilir. Etkin ve verimli bir bakım planı yapabilmek için meydana gelen arıza tiplerini ve bu arıza tiplerinin ne zaman ortaya çıkacağını kestiriminin yapılması çok önemlidir. Arıza kestirim problemi doğası gereği birçok belirsizliği içermekte olup doğru kestirim yapabilmek oldukça zordur. Çünkü doğru sonuç elde edebilmek için kullanılan verinin yapısı, büyüklüğü ve karmaşıklığı son derece önemlidir. Bu nedenle arıza tahmini konusunda birçok yöntem geliştirilmiştir. Bu yöntemlerin en başarılı olanlarından biri yapay zeka temelli yöntemeye dayanan Destek Vektör Regresyondur (DVR). Bu çalışmada 15 adet tramvay aracının geçmiş dönem arıza bilgileri kullanılarak gelecekte meydana gelebilecek arızaların tahmin edilmesi hedeflenmiştir. DVR sonucu incelendiğinde eğitim Ortalama Mutlak Yüzde Hata (MAPE) değeri 1.26843, test MAPE değeri ise 1.65218 olarak bulunmuştur. Determinasyon katsayıları ise eğitim ve test değerleri için sırası ile 0.999727 ve 0.999628 olarak sonuçlandırılmıştır.

Bilim Kodu : 90607

Anahtar Kelimeler : Destek vektör regresyon, Tahmin modellemesi, Arıza tahmini, Hafif raylı sistem araçları

Sayfa Adedi : 45

Danışman : Prof. Dr. Fatih Emre BORAN

# PREDICTION OF FAILURES ON LIGHT RAIL SYSTEM

(M. Sc. Thesis)

Semah GÜLERYÜZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2023

## ABSTRACT

With the increasing competition, strategic plans are gaining importance day by day, especially in the logistics and service sector, and the goal of the operations is to make profit in terms of cost and time. This goal can only be achieved by making the right plan. In order to make an effective and efficient maintenance plan, it is very important to predict the types of failures that occur and when these types of failures will occur. The fault estimation problem, by its nature, contains many uncertainties and it is very difficult to make an accurate estimation because the structure, size and complexity of the data used are extremely important in order to obtain accurate results. For this reason, many methods have been developed for fault prediction. One of the most successful of these methods is Support Vector Regression (SVR) based on artificial intelligence-based method. In this study, it is aimed to predict future failures by using the historical failure information of 15 trams. As a result of the DVR, the training MAPE value is 1.26843 and the test MAPE value is 1.65218. The determination coefficients are 0.999727 and 0.999628 for the training and test values, respectively.

Science Code : 90607

Key Words : Support Vector Regression, estimation models, fault prediction,  
light rail system vehicles

Page Number : 45

Supervisor : Prof. Dr. Fatih Emre BORAN

## TEŞEKKÜR

Başarı yolunda bana ışık tutan ve tüm destekleriyle yanımda olan saygıdeğer tez danışmanım Prof. Dr. Fatih Emre BORAN ‘a ve aldığım her kararda bana maddi ve manevi destek olan canım babam Mehmet GÜLERYÜZ’e ve şefkati ile üzerime titreyen, sevgisi ile bana hayat olan canım annem Hülya GÜNEY’e, bu süreçte yol arkadaşı olan manevi kız kardeşim Büşra KARACA’ya ve beni gökyüzünden izlediğine inandığım can dostum Dr. Sertaç GENÇ’e sonsuz teşekkürlerimi bir borç bilirim.

## İÇİNDEKİLER

|                                                              | Sayfa |
|--------------------------------------------------------------|-------|
| ÖZET .....                                                   | iv    |
| ABSTRACT.....                                                | v     |
| TEŞEKKÜR.....                                                | vi    |
| İÇİNDEKİLER .....                                            | vii   |
| ÇİZELGELERİN LİSTESİ.....                                    | ix    |
| ŞEKİLLERİN LİSTESİ.....                                      | x     |
| SİMGELER VE KISALTMALAR.....                                 | xi    |
| 1. GİRİŞ.....                                                | 1     |
| 2. LİTERATÜR TARAMASI .....                                  | 3     |
| 3. ZAMAN SERİLERİ .....                                      | 9     |
| 3.1. Zaman Serilerinin Bileşenleri.....                      | 10    |
| 3.1.1. Trend unsuru.....                                     | 10    |
| 3.1.2. Mevsimsel hareketler .....                            | 11    |
| 3.1.3. Konjonktürel dalgalanmalar .....                      | 12    |
| 3.1.4. Düzensiz hareketler .....                             | 12    |
| 3.2. Arıza Tahmini İçin Zaman Serisi Verilerinin DVR'si..... | 13    |
| 4. DESTEK VEKTÖR REGRESYONU (DVR) .....                      | 15    |
| 4.1. DVM'nin Kullanım Alanları .....                         | 19    |
| 4.2. DVM'lerde Tercih Edilen Yöntemler .....                 | 20    |
| 4.2.1. Doğrusal destek vektör regresyon .....                | 20    |
| 4.2.2. Doğrusal olmayan destek vektör regresyon .....        | 22    |
| 4.3. Kayıp Fonksiyonları .....                               | 24    |
| 4.3.1. Karesel kayıp fonksiyonu .....                        | 25    |
| 4.3.2. Mutlak kayıp fonksiyonu .....                         | 25    |

|                                                                               | <b>Sayfa</b> |
|-------------------------------------------------------------------------------|--------------|
| 4.3.3. Huber kayıp fonksiyonu.....                                            | 25           |
| 4.3.4. Vapnik kayıp fonksiyonu ( $\epsilon$ -duyarsız kayıp fonksiyonu) ..... | 26           |
| 4.4. Özellik Alanı.....                                                       | 26           |
| 4.4.1. Çekirdek işlevleri .....                                               | 26           |
| 4.4.2. Veri normalleştirme .....                                              | 30           |
| 4.4.3. Çekirdek seçimi.....                                                   | 30           |
| 5. UYGULAMA.....                                                              | 31           |
| 6. SONUÇ VE ÖNERİLER .....                                                    | 39           |
| KAYNAKLAR .....                                                               | 41           |
| ÖZGEÇMİŞ .....                                                                | 45           |

## ÇİZELGELERİN LİSTESİ

| Çizelge                                                                                 | Sayfa |
|-----------------------------------------------------------------------------------------|-------|
| Çizelge 5.1. DVR modellemesindeki eğitim kalıpları .....                                | 33    |
| Çizelge 5.2. Kullanılan veri setinin bazı örnekleri .....                               | 34    |
| Çizelge 5.3. Girdi değerleri değiştirilerek elde edilen bazı çıktı değerleri .....      | 36    |
| Çizelge 5.4. En iyi girdi değerleri ile elde edilen ileri tarih ve saat değerleri ..... | 38    |

## ŞEKİLLERİN LİSTESİ

| Şekil                                                                                  | Sayfa |
|----------------------------------------------------------------------------------------|-------|
| Şekil 3.1. Trend doğrusu grafiği .....                                                 | 11    |
| Şekil 3.2. Mevsimsel hareketler grafiği .....                                          | 11    |
| Şekil 3.3. Düzensiz hareketler grafiği.....                                            | 12    |
| Şekil 4.1. $\epsilon$ -Duyarsız kayıp fonksiyonu .....                                 | 16    |
| Şekil 4.2. DVM'nin uygulama alanları.....                                              | 20    |
| Şekil 4.3. Doğrusal olarak ayrılabilen veriler .....                                   | 21    |
| Şekil 4.4. Doğrusal olarak ayrılamayan veriler .....                                   | 23    |
| Şekil 4.5. Doğrusal olarak ayrılamayan verilerin çekirdek ile haritalanması .....      | 24    |
| Şekil 4.6. En çok kullanılan 4 temel kayıp fonksiyonu .....                            | 25    |
| Şekil 4.7. Çekirdek fonksiyonu ile verinin daha yüksek bir boyuta dönüşmesi .....      | 27    |
| Şekil 5.1. DVR modelinin temel yapısı .....                                            | 32    |
| Şekil 5.2. Tasarlanan DVR arayüz.....                                                  | 35    |
| Şekil 5.3. En iyi girdi değerleri ile elde edilen eğitim tahmin ve gözlem grafiği..... | 37    |
| Şekil 5.4. En iyi girdi değerleri ile elde edilen test tahmin ve gözlem grafiği.....   | 37    |

## SİMGELER VE KISALTMALAR

Bu çalışmada yer alan simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda belirtilmiştir.

| Simgeler                                        | Açıklamalar                   |
|-------------------------------------------------|-------------------------------|
| <b>b</b>                                        | Bias terimi                   |
| <b>c</b>                                        | Ayarlanabilir kesme sabiti    |
| <b>C</b>                                        | Konjonktürel dalgalanmalar    |
| <b>C</b>                                        | Ceza katsayısı                |
| <b>d</b>                                        | Polinom derecesi              |
| <b>E</b>                                        | Tesadüfi hareketler           |
| <b>J</b>                                        | Bessel değeri                 |
| <b>K</b>                                        | Çekirdek fonksiyonu           |
| <b>L</b>                                        | Lagrange                      |
| <b>N</b>                                        | Verinin boyutu                |
| <b>p</b>                                        | Giriş vektörünün boyutu       |
| <b>R<sup>2</sup></b>                            | Determinasyon katsayısı       |
| <b>S</b>                                        | Mevsimlik dalgalanmalar       |
| <b>T</b>                                        | Trend                         |
| <b>w</b>                                        | Ağırlık vektörü               |
| <b><math>\sigma^2</math></b>                    | Bant genişliği                |
| <b><math>\varepsilon</math></b>                 | Duyarsız kayıp fonksiyonu     |
| <b><math>x_i</math></b>                         | Girdi verileri                |
| <b><math>y_i</math></b>                         | Çıktı verileri                |
| <b><math>f()</math></b>                         | Regresyon fonksiyonu          |
| <b><math>\xi +</math> ve <math>\xi -</math></b> | Gevşek değişkenler            |
| <b><math>\alpha, \beta</math></b>               | Lagrange çarpanları           |
| <b><math>\Phi()</math></b>                      | Haritalama fonksiyonu         |
| <b><math>\gamma</math></b>                      | Çekirdek genişliği, parametre |

**Kısaltmalar****Açıklamalar****ARM**

Ampirik Risk Minimizasyonu

**ÇKA**

Çok katmanlı algılayıcı

**DVM**

Destek vektör makinesi

**DVR**

Destek vektör regresyon

**EKDVM**

Enküçük kareler destek makinesi

**KKT**

Karush Kuhn Tucker

**NOKKH**

Normalleştirilmiş ortalama kareler kök hatası

**OMYH**

Ortalama mutlak yüzde hata

**OREHO**

Oto regresif entegre hareketli ortalama

**RTİ**

Radyal temel işlev

**SDT-YOTSA**

Sonsuz darbe tepkisi yerel olarak tekrarlayan sinir ağı

**YRM**

Yapısal risk minimizasyonu

**YSA**

Yapay sinir ağları

**ZS**

Zaman serileri

## 1. GİRİŞ

Ulaşım sektöründe mevcut rekabet ortamından dolayı, güvenilirlik ve arıza tahmini için tekniklerin geliştirilmesine yoğun bir ilgi gösterilmiştir. Güvenilirlik analizi, ürün performanslarının değerlendirilmesinde ve sürdürülebilir üretim için bakım planlarının yapılmasında çok önemli bir rol oynamaktadır. Özellikle bu sektördeki temel endişe, müşterilerden gelen artan talepleri karşılamak ve hükümetler tarafından uygulanan daha sıkı yasa ve düzenlemelere uymaktır. Sistem güvenilirlik indeksleri zamanla değiştiğinden, bunu doğru bir şekilde tahmin etmek kolay değildir. Aslında, bir ögenin güvenilirliğinin tahmin modellemesi, tasarım, doğrulama ve tanımlama, çalıştırma ve bakım aşamaları dahil olmak üzere işletme döngüsünün çeşitli aşamalarında gerçekleştirilebilir. Yani tahmin modellemesi, herhangi bir kademede elde edilen güvenilirlik tahminleri, bakımı ve muhtemelen iyileştirilmesi için uygun eylemlerin gerçekleştirilmesine izin vermek için bileşenin performans gelişimini tahmin etme odaklı çalışır.

Modern süreçlerde, sistemlerde ve tesislerde artan karmaşıklık nedeniyle, iş karlılığının olağan ihtiyaçları, insan yaşamının güvenliği ve çevrenin korunması ile birlikte, mühendislik sistemlerinin güvenli ve güvenilir çalışması giderek daha önemli hale gelmekte ve araştırma ve uygulamada artan ilgi görmektedir. Güvenilirlik analizi ve risk değerlendirmesi, olasılıklarının ve sonuçlarının sayısallaştırılmasıyla bileşen ve sistem arızalarının incelenmesi için sağlam teknik çerçeveler sunar. Bu analiz çerçeveleri içinde, önemli bir görev güvenilirlik tahminidir. Güvenilirlik durumunun tarihsel eğiliminin bir zaman serisi olarak verildiği durumlarda, güvenilirlik tahmini, çözümü geçmiş veri gözlemlerine dayalı olarak güvenilirliğin gelecekteki değerlerini tahmin etmeyi gerektiren bir zaman serisi tahmin problemi olarak kabul edilebilir.

İşletme tesisi sahipleri, güvenilirlik analistlerinin maliyetli arızaları ve kazaları ortadan kaldırarak ve nihayetinde maliyet kayıplarını ve itibarın azalmasını önleyerek kârlarını en üst düzeye çıkarmalarını istemektedir. Çalışan bileşenlerin ve sistemlerin güvenilirliği sabit olmadığından ve kullanım ömürleri boyunca değiştiğinden, istenen düzeyde arızasız çalışma ortamı ve güvenliğin garanti edilebilmesi için meydana gelen arıza sıklığını izlemek ve kontrol etmek için bakım, iyileştirme ve yenileme eylemleri kullanılır.

Mevcut pazarın rekabetçi doğası nedeniyle tahminler, bileşenin farklı aşamalarındaki performans gelişimi hakkında fikir verir ve bakım ve tasarım aşamaları sırasında uygun proaktif eylemlerin hayata geçirilmesini mümkün kılar. Bir güvenlik sisteminin güvenilirliğini tahmin etme yeteneği, başarılı bir sistem tasarımı için kritik öneme sahiptir ve bu soruna yaklaşmanın çeşitli yolları vardır. Güvenilirlik tahmini, arıza oranını ve arızalar arasındaki ortalama süreyi hesaplamak için en yaygın güvenilirlik analizi biçimlerinden biridir.

Gerçek dünyada, bazıları birbirine bağımlı olan bir dizi zamana bağlı ve harici değişken (operasyonel ve çevresel) güvenilirlik ölçüsünü etkiler. Gerçek güvenilirlik performansındaki homojenlikler buna dahildir. Sonuç olarak, güvenilirlik davranışının karmaşıklığını gerçekçi bir şekilde modellemek için, gelişmiş matematiksel formülasyonlara ve külfetli sayısal çözümlere ağırlık verilerek daha karmaşık olasılıksal modeller uygulanmalıdır. Bununla birlikte, zorlu modelleme görevinin, model parametrelerini ayarlamak için gerekli veriler mevcut olmayabileceğinden, beklenen doğrulukta güvenilirlik tahminlerine yol açmayabileceği belirtilmelidir.

Tüm bu açıklamalar neticesinde, çalışmanın ilk kısmında makine öğrenmesi kavramının hangi amaç ile ortaya çıktığından, gelişim süreci ve tarihinden ve bu zamana kadar yapılmış olan kayıtlara geçmiş literatürden bahsedilmiştir bahsedilmiştir.

Devam eden bölümlerde, Destek Vektör Makineleri (DVM) algoritmalarında kullanılan veri yapılarının öneminden bahsedilmiş ve problemlerin analizinde kullanılan çekirdek fonksiyonlarından bahsedilmiş olup Destek Vektör Regresyonda (DVR) kullanılmakta olan kayıp fonksiyonları ve zaman serileri incelenmiştir.

Son olarak, şehir içi bir ulaşım firmasının bünyesinde yer alan bir tramvay hattına ait 15 adet hafif raylı sistem aracında meydana gelen arızaların tahmini için düzenlenen verilerde Destek Vektör Regresyon ile çalışılarak MATLAB R2018a programında bir modelleme yapılmış ve bu modele dayanarak tahminler elde edilmiştir. Yapılan modellemede 2019-2021 yılları arasında meydana gelen 603 adet tramvay arızası kullanılmıştır. DVR için çekirdek fonksiyonları arasında en az hata oranına sahip olan çekirdek seçilmiştir. En iyi tahmin en az hata oranlarına sahip olan Polinom çekirdek ile gerçekleştirilmiştir.

## 2. LİTERATÜR TARAMASI

Literatürde yer alan daha önceden yapılmış çalışmalara dair son yıllarda, regresyonunun ampirik tekniklerine dayanan yeni güvenilirlik modelleme paradigmaları ortaya çıkmıştır. Özellikle, Yapay Sinir Ağları (YSA), bir zaman veya uzay alanı üzerinde sürekli değişen doğrusal olmayan fonksiyonların regresyonu için evrensel bir yaklaşım olarak önerilmiştir. Bu tekniğin uygulamaları güvenilirlik tahminini içermektedir. Örneğin, Karunanithi ve diğerleri [1], Dohi ve diğerleri [2], Cai ve diğerleri [3], Ho ve diğerleri [4], Tian ve Noore [5,6] ve Hu ve diğerleri [7], yazılım güvenilirliğini tahmin etmek için hem klasik hem de tekrarlayan Çok Katmanlı Algılayıcı (ÇKA) sinir ağlarını kullanmıştır. Xu ve diğerleri [8] motor güvenilirliğini tahmin etmek için ileri beslemeli ÇKA ve Radyal Temel İşlev (RTİ) sinir ağlarını uygulamıştır. Kullanılacak sinir ağlarının uygun mimarilerini belirlemek için bir duyarlılık analizi yapılmıştır. Deneysel sonuçlar, önerilen sinir modelinin geleneksel ÇKA ve Otoresif Entegre Hareketli Ortalama (OREHO) modellerinden daha üstün tahmin performansına sahip olduğunu göstermiştir. Su ve diğerleri [9] motor güvenilirliğini tahmin etmek için OREHO modellerini sinir ağı teknikleriyle birleştirmiştir. Ortaya çıkan modelin, OREHO' dan daha iyi tahmin doğruluğu elde ettiği ortaya çıkmıştır ve geri yayılım sinir ağı modelleri ayrı ayrı kullanılmıştır. [10]'da, donanım bileşenlerinin güvenilirliğini ve arıza süresini tahmin etmek için bir Sonsuz Darbe Tepkisi Yerel Olarak Tekrarlayan Sinir Ağı (SDT-YOTSA) modelleme yaklaşımı [11] önerilmiştir. Güvenilirlik tahmininde IIR-LRNN yeteneklerini araştırmak için ÇKA, OREHO ve RTİ dahil olmak üzere çeşitli öğrenme modellerinin tahmin performansı, motor arıza süreçleri ile ilgili karşılaştırmalı çalışmalarda değerlendirilmiştir. Sonuçlar, STD-YOTSA' nin RTİ ve OREHO modellerinden daha iyi performans gösterdiğini ve ÇKA modeliyle karşılaştırılabilir doğruluğa sahip olduğunu göstermiştir.

Sinir ağları, verilerin özellikleri hakkında önsel varsayımlar olmaksızın herhangi bir doğrusal olmayan işlevi eşleyebilen evrensel işlev tahmincileridir. Teori, geleneksel istatistiksel modellere kıyasla güvenilirlik dinamiklerini tanımlamada daha güçlüdür. İstatistiksel öğrenme teorisinin ortaya çıkması ve gelişmesiyle birlikte, sinir ağlarının güvenilirlik mühendisliğindeki uygulamalarının araştırılması kademeli olarak yapılmıştır. Zheng, sinir ağı topluluklarına dayalı, parametrik olmayan bir yazılım güvenilirlik tahmin sistemini göstermiş olup birden fazla sinir ağını birleştirerek sistem öngörülebilirliğini geliştirmiştir. Lolas ve Olatunbosun, sinir ağları gibi bir aracın güvenilirlik performansı

tahminlerinde kullanım için nasıl tasarlanabileceğini ve optimize edilebileceğini göstermiştir.

Diğer bir öğrenme yöntemi ise Vapnik tarafından önerilen, yapılandırılmış risk minimizasyonu ilkesine ve istatistiksel öğrenme teorisine dayanan Destek Vektör Makinesidir (DVM). DVM' ler, diğer sinir ağı modellerinden daha iyi genelleme performansına sahiptir. DVM' lerin çözümü benzersizdir, optimaldir ve doğrusal olmayan optimizasyon gerektiren diğer ağların eğitiminden farklı olarak yerel minimumda takılıp kalma tehlikesiyle karşı karşıyadır. Ancak, DVM' lerin hesaplama maliyeti çok yüksektir. Suykens ve ark. Enküçük Kareler Destek Makinesi (EKDVM) olarak bilinen değiştirilmiş en küçük kareler kayıp fonksiyonunu DVM' lere tanıtmıştır. DVM' lerin aksine EKDVM, eşitsizlik kısıtlamalarını eşitlik kısıtlamalarına çevirerek hesaplama verimliliğini artırır. Aynı zamanda EKDVM, tüm eğitim örneklerinin eğitim hatalarını dikkate alır. Şimdiye kadar DVM' ler, örüntü tanıma problemleri, fonksiyon tahmini, zaman serileri tahmini, tıpta hastalık tespiti gibi birçok alanda başarıyla uygulandı. Ancak DVM' lerin ve EKDVM' nin güvenilirlik tahmininde uygulanmasına ilişkin araştırma çok sınırlıdır.

Güçlü bir modelleme aracı olarak ortaya çıkan bir diğer öğrenme yöntemi, Destek Vektör Makineleri (DVM) olarak bilinir. DVM' ler, özellikle girdileri çıktılara eşleyen temel süreç bilinmediğinde veya etkileyen birbirine bağlı faktörlerin sayısının artması nedeniyle böyle bir matematiksel ilişkinin elde edilmesinin çok pahalı olduğu durumlarda yararlıdır.

Destek Vektör Makineleri' nin temelleri 1909 yılında yayımlanan James Mercer' in makalesine dayanmaktadır. Bu makalede Mercer, bilim dünyasında Mercer Teoremi olarak tanınan kuramı içeren ve “Pozitif ile Negatif Fonksiyonlar ve Bunların İntegral Eşitlikler Teorisine Bağlantısı” adlı makalesinde [12], DVM' nin temeli olan çekirdek kavramını ilk kez ortaya çıkarmıştır.

Daha yeni araştırmalar, regresyon problemlerinde Destek Vektör Makinelerini (DVM) kullanmaktadır. DVM' ler, YSA' nın aksine, daha düz ve daha az karmaşık bir işlev elde etmeyi amaçlayan Yapısal Risk Minimizasyonu içerir. Destek Vektörü Regresyonu (DVR), yeni bir kayıp işlevi uygulayarak, hatanın duyarsız bölge için önceden tanımlanmış bir genişlik içinde tutulduğu ve önceden tanımlanmış bir maliyet faktörünün aykırı verileri işlediği en düz yolu seçer. Ayrıca, çekirdek fonksiyonlarını kullanarak, DVR doğrusal

olmayan bir tahmin fonksiyonu oluşturmak için eğitilebilir. Son olarak, DVR' nin kullanıcı tanımlı parametreleri, genelleştirme performansını en üst düzeye çıkarmak için Genetik Algoritma gibi küresel optimize edicilere veya klavuz arama gibi daha basit çözücülere gömülü çapraz doğrulama yoluyla optimize edilebilir.

Modellemesi yapılan DVM' lerin bilinen ilk halleri, ikili şeklindeki veri kümesini doğrusal vektör yardımı ile sınıflama yapmak için kullanılan güçlü sınıflandırıcılardır. Daha sonraki dönemlerde geliştirilen DVM modellemeleri ise çekirdek fonksiyonları kullanarak iç içe girmiş karmaşık yapıdaki birden fazla sınıfı da kolay bir şekilde ayırabilecek yetenektedir. Bu yetenekten ötürü birçok makine öğrenme uygulamasında tercih edilme nedeni olmuştur.

DVM, 1992 yılında Vapnik tarafından ilk defa ortaya atıldığında sınıflandırma problemlerinde kullanılırken 1997 yılından itibaren regresyon problemlerinde de kullanılmaya başlanmış ve Destek Vektör Regresyon (DVR) adı verilmiştir. Destek vektör makinelerinin regresyon problemlerinin çözümünde kullanılmasına ilişkin detaylı bir çalışma 2004 yılında Smola ve Schölkopf [13] tarafından ortaya konulmuştur.

DVM' lerin regresyon problemlerine uygulandığında başarılı olduğu gösterilmiştir [14]. Ampirik sonuçlar, SVM' nin diğer tekniklerden daha iyi bir performansa sahip olduğunu göstermiştir [15]. SVM, YSA gibi diğer tekniklerle karşılaştırıldığında iki nedenden dolayı başarılı bir performans sergilemiştir. Birincisi SVM, YSA tarafından kullanılan Ampirik Risk Minimizasyonu (ARM) yerine Yapısal Risk Minimizasyonu (YRM) kullanır. YRM, eğitim hatalarını en aza indirir ve genelleme hatası için bir üst sınırı en aza indirmeye çalışır; bu, hesaplama açısından ARM' den daha az zahmetli görünmektedir çünkü ARM, büyük örneklem boyutlarıyla uğraşmak için kullanılır [29]. YRM, genel bir tanımla, bir eğitim veri setini tanımlamada yeterli kapasiteye sahip bir model seçer ve ardından test verisi olarak da bilinen eğitim için kullanılmayan girdi-çıkı çiftleri gibi görünmeyen verileri doğru bir şekilde tahmin eder [16]. Bu nedenle, DVM, eğitim aşamasında modelin doğruluğu ile modelin gelecekteki değerleri tahmin etme yeteneği arasındaki dengeye odaklanırken, YSA' lar makinenin genel performansını dikkate almaz, bu da yetersiz veya aşırı uydurma sorunlarına neden olabilir. DVM' nin bu özelliği, yaklaşan çıktıların tahminindeki etkinliğini artırır. İkincisi, DVM için bir çözüm bulmak, bir dışbükey ikinci dereceden optimizasyon problemini çözmek anlamına gelir. Böylece, küresel bir optimum için gerekli ve yeterli koşullar, Karush–Kuhn Tucker (KKT) ifadeleriyle belirlenir [17]. Bununla birlikte, YSA'

larda, düzgün seçilmiş bir optimizasyon algoritmasının bile sınırlı bir kaynakla, yani hesaplama süresiyle küresel minimuma ulaşması garanti edilmez [18].

Destek vektör regresyonunda da tıpkı sınıflandırma algoritmasındaki gibi doğrusal öğrenme yöntemleri ve çekirdek fonksiyonları yardımı ile elde edilen doğrusal olmayan fonksiyonlar kullanılarak maksimum marj metodunun temel özelliklerinin bulunması hedeflenmektedir [20]. DVR makine öğrenmesi dünyasının güçlü ve esnek modelleme tekniklerinden birisidir. İlk olarak ortaya sınıflandırma problemleri için çıkmış ve sonrasında regresyon problemlerine de uyarlanmıştır. Regresyon problemlerine uyarlandığında kendisine robust (dayanıklı) regresyon [21] yani dayanıklı regresyon alanında yer bulmuş dayanıklı bir regresyon modelleme tekniğidir. Buradaki dayanıklı ifadesi aykırı gözlemlere karşı dayanıklı olmayı ifade etmektedir. Amaç, bir marjın aralığına maksimum noktayı en küçük hata ile alabilecek şekilde doğru ya da eğri belirlemektir [22].

DVR' nin temel prensibi, birkaç ufak farklılık olmakla birlikte sınıflandırma problemleri için DVM ile eşdeğerdir. Temel olarak, DVM alternatif bir kayıp fonksiyonu yardımıyla bağlanım problemlerinde kullanılmaktadır [23,24]. En büyük sınır algoritmasını tanımlayan tüm temel özellikler burada da korunmaktadır. Doğrusal olmayan bir fonksiyon, çekirdek tabanlı özellik uzayında bir doğrusal öğrenme makinesi tarafından kestirim yapılmaya çalışılır. Bununla eş zamanlı olarak, sistemin kapasitesi, uzayın boyutuna bağlı olmayan bir parametre tarafından kontrol edilir. Sınıflandırma probleminde olduğu gibi, bağlanım analizinde de öğrenme algoritması dışbükey bir fonksiyoneli minimize etmeye çalışır. Bu işlem sonucunda da elde edilen çözüm seyrek olur [25].

DVM ile diğer regresyon yöntemleri arasındaki fark, ampirik risk minimizasyonu kullanan diğer regresyon yöntemlerinin aksine, DVM' nin yapısal riski en aza indirmesidir. Ampirik risk minimizasyonu, yalnızca gürültüyü veya aykırı değerleri tanımlayan ve görünmeyen test verilerini tahmin etmede düşük performansa sahip olacak bir modelle sonuçlanabilecek tahmin hatasını en aza indirmeye odaklanırken, yapısal risk minimizasyonu olabildiğince düz bir işlevi eğitmeye odaklanır.

Regresyon durumunda, DVR' nin düzlük ile tahmin hatası arasındaki dengeyi etkileyen iki ana parametresi  $\epsilon$  ve  $C$  vardır.  $\epsilon$  parametresi, tahmin hatasının hiçbir maliyetinin olmadığı duyarsız bölgeyi tanımlar ve  $C$  parametresi, duyarsız bölge dışındaki hatanın ağırlığını

tanımlar. Çekirdek işlevleri kullanıldığında, bir veya daha fazla ekstra parametre tanımlanabilir.  $C$  parametresi için büyük bir değer, algoritmanın tüm eğitim hatasını duyarsız bölge içine koymasına neden olacak ve bu da DVR' nin eğitim verilerini ezberlemesine ve görünmeyen test verilerine kötü bir şekilde genelleme yapmasına neden olacaktır.  $\epsilon$  parametresi için küçük bir değer, verilerde hiç gürültü olmadığını varsayacak ve yine DVR' nin fazla uymasına neden olacaktır. Bunun tersine,  $C$  parametresi için küçük bir değer veya  $\epsilon$  parametresi için büyük bir değer, DVR' nin yetersiz oturmasına neden olur. Bu parametrelerin optimizasyonunda çapraz doğrulama yönteminin uygulanması, görünmeyen verilerin tahmininde büyük performans gösteren bir fonksiyonun gerilemesini sağlayacaktır.

Doğru regresyon/tahmin elde etmek için DVR'de parametre seçimi çok önemlidir. DVR için mevcut parametre seçimi yöntemleri iki sınıfa ayrılabilir. Yöntemlerin birinci sınıfı, analistin eldeki sorunla ilgili ön bilgisine dayanır. Örneğin Cherkassky [26], DVR parametrelerinin eğitim verilerinin istatistiksel özelliklerine göre uygun olduğu konusunda mevcut bazı fikir birliğine dayanarak, DVR parametrelerini doğrudan eğitim verilerinden seçmek için bir analitik seçim yöntemi önermiştir. Bu uzman deneyimi tipi metodoloji, ön bilgilerin yeterince bilgilendirici olması koşuluyla, parametreleri belirlemek için basit ve etkilidir. Açıkçası, karmaşık problem ortamlarında (yüksek boyutlu uzaylar, çok doğrusal olmayan fonksiyonlar, az temsili veri vb.), bu yöntemler uygun değildir.

İkinci yöntem sınıfı, algoritmanın belirli performans hedefleri üzerinde tanımlanan bir optimizasyon şeması içindeki parametrelerin değerlerini arar. Genel olarak, DVR parametre seçimi için kullanılabilecek üç tür arama yöntemi vardır.

Birincisi, tüm parametre uzayında parametrelerin en iyi değerlerini aramak için kapsamlı yöntemlerdir. DVR gerçek değerli parametrelere sahip olduğu için, aramadan önce arama uzayının bir ayrıklaştırma işlemi gereklidir. Bu nedenle, bazı bilgiler kaybolabilir ve rafine bir ızgara benimsenirse yöntem çok zaman alabilir. Tipik kapsamlı bir yöntem, parametre alanını düzgün bir şekilde ayrıklaştıran ve her bir ızgara noktasının değerlerinde ayarlanan parametrelerle DVR genelleştirme performansını hesaplayan Izgara Arama yöntemidir.

Arama yöntemlerinin ikinci sınıfı, gradyan iniş yöntemi, elipsoid yöntemi ve eşzamanlı pertürbasyon stokastik yaklaşım yöntemini içeren geleneksel optimizasyon yöntemlerini

içerir. Yöntemler kolayca genelleştirilemez ve yalnızca belirli durumlarda iyi performans gösterir.

Üçüncü sınıf, son yıllarda hızla ortaya çıkan ve oldukça karmaşık da olsa çeşitli problem ortamlarındaki iyi performansları nedeniyle büyük ilgi gören güçlü arama yöntemleri olan akıllı optimizasyon yöntemlerini içermektedir. Örneğin, sistem güvenilirliği indirgemesine uygulanan DVR parametrelerinin optimal değerlerini aramak için benzetilmiş tavlama, genetik algoritma ve parçacık sürüsü optimizasyonu önerilmiştir. Bu yöntemler uygulamada popüler hale geldi ve genetik algoritma, kanıtlanmış küresel arama etkinliği nedeniyle belki de en sık kullanılan yöntemdir.

### 3. ZAMAN SERİLERİ

Zaman serisi tahmin teknikleri, finansal piyasa tahmini, elektrik kullanım yükü tahmini, hava durumu ve çevresel durum tahmini ve güvenilirlik tahmini gibi birçok hayata geçirilmiş uygulamada kullanılmıştır. Altta yatan sistem modelleri ve zaman serisi veri üretme süreçleri, bu uygulamalar için genellikle karmaşıktır ve bu sistemler için modeller genellikle önceden bilinmez. Bu sistemler tarafından üretilen zaman serisi verilerinin doğru ve tarafsız tahmini, iyi bilinen doğrusal teknikler kullanılarak her zaman elde edilemez ve bu nedenle tahmin süreci, daha gelişmiş zaman serisi tahmin algoritmaları gerektirir. Bu çalışma aynı zamanda yeni bir makine öğrenimi yaklaşımı kullanan zaman serisi tahmin uygulamalarının bir incelemesini sunmaktadır: destek vektör makineleri (DVM). DVM'leri kullanmanın altında yatan motivasyon, bu metodolojinin, temel sistem süreçleri tipik olarak doğrusal olmadığına, durağan olmadığına ve önceden tanımlanmadığına zaman serisi verilerini doğru bir şekilde tahmin etme yeteneğidir. DVM'lerin, çok katmanlı algılayıcılar gibi sinir ağı tabanlı doğrusal olmayan tahmin teknikleri dahil olmak üzere diğer doğrusal olmayan tekniklerden daha iyi performans gösterdiği de kanıtlanmıştır.

Zaman serisi, eşit zaman aralıklarında bir değişkene ait gözlemlerin meydana gelmesidir. Zaman serileri saat, gün, ay, yıl şeklinde ifade edilebilmektedir. Belirli bir zaman birimine ait bir gözlemin verileri incelendiğinde, bu verilerin bir takım dalgalanmaların etkisi altında kaldığı anlaşılmıştır.

Zaman serileri ile ilgili birçok tahmin tekniği bulunmaktadır. Geleneksel olarak, stokastik süreç teorisine dayanan yöntemler geliştirilmiş ve tüm kullanım ömrü boyunca sistem güvenilirliğini değerlendirmek için yaygın olarak kullanılmıştır. Ancak başarısızlık sınıflarına bazı kısıtlamalar getirirler, bu nedenle tüm varsayımları yerine getirmek ve doğrulamak zordur. Uygulamada, bunları basitleştirmenin yolu sıklıkla kullanılır. Sistem güvenilirliği zamanla değişen fonksiyondur. Arıza önkestirimi için, rastgele değişkenlerin bir koleksiyonu olarak kabul edilebilecek arızalar arasındaki süre, arızaya kadar geçen süre veya toplam arıza sayıları olabilir. Dolayısıyla arıza tahmini, geleneksel zaman serisi analiz yöntemiyle tamamlanabilir.


Zaman serisi (ZS) verileri, bir zaman dizisinde meydana gelen bir deęiřken üzerindeki gözlemleri ifade eder. Çoęunlukla bu gözlemler eřit aralıklı, ayrıık zaman aralıklarında toplanır. Bu tür kronolojik verilerin ZS hareketleri, trend, periyodik (örneğin mevsimsel), döngüsel ve düzensiz varyasyonlar gibi ayırt edilebilir bileřenlere ayrıřtırılabilir veya ayrıřtırılabilir. Herhangi bir ZS analizinde/modellemesinde temel bir varsayım, geėmiř modelin bazı yönlerinin gelecekte de kalmaya devam edeceęidir. Burada geėmiřle ilgili bilgilerin sayısal veriler biçiminde mevcut olduęu varsayılır. İdeal olarak, ZS modellemede öncü olan Box ve Jenkins tarafından öne sürüldüęü gibi, ZS analizi/modellemesi yapmak için en az 50 gözlem gereklidir.

### **3.1. Zaman Serilerinin Bileřenleri**

ZS verilerini analiz etmede önemli bir adım, bu modellere en uygun modellerin kullanılabilmesi için veri modellerinin türlerini dikkate almaktır. Dört tip ZS bileřeni ayırt edilebilir. Zaman serilerinin bileřenleri řeklinde de ifade edilebilen bu etkiler sırası ile trend, mevsimlik dalgalanmalar, konjonktürel dalgalanmalar ve tesadüfi hareketler olarak isimlendirilmektedir.

#### **3.1.1. Trend unsuru**


Trend, zamana göre gözlemlenen bir deęiřkenin uzun dönemde gösterdięi azalma veya artmadır. Zaman serisinin ölçüldüęü yıl, ay, hafta, gün ve benzeri birimlerin herhangi birinde trend unsuru gözlemlenebilir. Genelde iklimsel olayların uzun dönemli incelemelerinde gözlemlenebilir. Örneğin, yüzyıl boyunca bir ülkeye düşen yağmur miktarına ait verilerde trend unsurunu görmek mümkündür.



Şekil 3.1. Trend doğrusu grafiği

### 3.1.2. Mevsimsel hareketler

Zaman serileri ölçüldükleri birime bağlı olarak benzer biçimde tekrar eden seyre sahip olabilirler. İşte mevsimsel unsur bu benzer seyirden kaynaklanmaktadır. Mevsimlik dalgalanmalar (S), zaman serilerinde kolay takip edilebilen ve sıkça meydana gelen bir etkidir. Periyodik hareketlerle kendisini belli eder. Bir yıl ve bir yıldan az bir süre içinde meydana gelen tam dairesel süreçte mevsim hareketlerinin veriler üzerindeki etkisini ifade eder. Satış rakamları, sıcaklık değerleri, turizmdeki istatistikler gibi değişkenlere ait verilerde etkileri görülmektedir.




Şekil 3.2. Mevsimsel hareketler grafiği

### 3.1.3. Konjonktürel dalgalanmalar

Konjonktürel dalgalanmalar (C) yani devri hareketler, uzun süreli hareketleri genel trend seviyesinde gösterir. Dairesel hareketlere sahiptir. Hareketlerin uzunluk ve yoğunlukları birbirinden farklı olabilir. Sıcaklıkta meydana gelen günlük değişimler konjonktürel dalgalanmalara örnek olarak verilebilir.

### 3.1.4. Düzensiz hareketler

Son bileşen olan düzensiz hareketler (E) ise, periyodik olmayan değişimleri ifade eder. Varlığı önceden tahmin edilemeyen tesadüfen gerçekleşen olayların ortaya çıkardığı dalgalanmalardır. Genellikle verilerdeki gürültü olarak bilinirler. Örnek olarak, doğal afetlerin etkisi ile verilerde oluşan artışlar ya da azalmalar verilebilir.



Şekil 3.3. Düzensiz hareketler grafiği

Bu bileşenler  $t$  sürecinde gözlenen bir değişkenin zaman serisi modelini tanımlamada kullanılır. Söz konusu tanımlamalar orijinal verileri (eğilimin kendisindeki döngüsel model dahil) ayrıştırmanın kaba ama pratik bir yolu, aşağıdaki gibi bir toplama veya çarpma modeli varsayarak mevsimsel bir ayrıştırmaya gitmektir.

$$Y_t = T \times C \times S \times E \quad (\text{Çarpımsal model}) \quad (3.1)$$

$$Y_t = T + C + S + E \quad (\text{Toplamsal model}) \quad (3.2)$$

Burada  $Y_t$  orijinal zaman serisi verisi, T trend unsuru, C mevsimsel dalgalanma ve E ise hata/düzensiz bileşendir. Serinin düzeyi arttıkça bir ZS'nin mevsimsel değişimleri artıyorsa, o zaman çarpımsal bir modele, başka bir toplama modeline gidilmesi gerekir. Alternatif olarak, ZS' nin günlüğe kaydedilen değerlerinin ek bir bileşimi de yapılabilir. Ayırıştırma yöntemleri, ZS bileşenlerinin ayrı ayrı çalışılmasına olanak sağlayabilir veya çalışanların trendi azaltmasına veya daha fazla analiz için gerekirse mevsimsel ayarlamalar yapmasına olanak tanır.

İstatistiksel çalışmalarda ana kütlelen çekilen örnek yardımıyla bütün hakkında istatistiksel yorumlara ulaşılabilir. Zaman serilerinin çözümlenmesinde de aynı teknik geçerlidir. Yani teorik bir zaman serisinden elde edilen gözlem verilerine ait stokastik süreç hakkında analiz yapılır ve tüme yönelik yorumlarda bulunulur. Bu şekilde çıkarımlarla ileriye yönelik tahminlerde de bulunulabilir.

Zaman serileri sıralanan faktörlerden birini ya da hepsini içerebilir ve bir seride bu hareketlerden birinin etkisi bir diğerinin içinde kendisini gösterebilir. Zaman serisi üzerinde gerçekçi bir analiz yapmak ve ileriye dönük doğru tahminlerde bulunmak için, serilerin bu etkilerden arındırılması gerekmektedir.

### 3.2. Arıza Tahmini İçin Zaman Serisi Verilerinin DVR'si

Fuller'a [27] göre, gerçek değerli bir zaman serisi, zamana (örneğin, borsalar veya talep) endekslenen rastgele değişkenlerin bir koleksiyonu veya başarısızlık zamanları gibi zamana göre sıralanan bir dizi gözlem olarak düşünülebilir. Zaman serisi regresyonunun geleneksel ayarında, t 'inci çıkış değeri  $y_t$ , Eş 3.3 'te gösterildiği gibi, y 'nin kendisinin p gecikmeli son değerlerinin bir girdi vektörü  $x_t$  'nin bilinmeyen bir fonksiyonu olarak temsil edilir. Burada p, geri zaman adımlarının sayısıdır.

$$y_t = f(x_t) = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}) \quad (3.3)$$



#### 4. DESTEK VEKTÖR REGRESYONU (DVR)

Destek Vektör Makineleri (DVM), Vapnik tarafından geliştirilmiştir. Bir öğrenme yöntemi olmasıyla birlikte regresyon ve sınıflandırma için de kullanılmaktadır. Bu yöntemin doğrusal olmayan problemleri çözmedeki performansı diğer öğrenme yöntemlerine göre, çok daha iyidir. Genellikle sınıflandırma problemlerinde kullanılan DVM'nin regresyon için biçimlenmesi Smola ve arkadaşları tarafından ortaya atılmıştır. Zamanla geliştirilen bu metot ise Destek Vektör Regresyonu (DVR) olarak adlandırılmıştır. DVM'ler, İstatistiksel Öğrenme Kuramı'ndan [28] doğan temel kavramlara ve aynı zamanda süreç analizinden ortaya çıkan bir dizi girdi/çıkı örneğine dayalı olarak yaklaşıklık fonksiyonunu oluşturan öğrenme yöntemleridir. DVM tarafından ele alınan regresyon öğrenme problemi şu şekilde formüle edilebilir. Çok boyutlu bir girdi vektörü  $x$  ile çıktı  $y$  arasında bilinmeyen, gerçek değerli ve muhtemelen doğrusal olmayan bir  $y=f(x)$  eşleştirmesi vardır. Mevcut tek bilgi, çözümü regresyon fonksiyonu  $f(x)$  olan öğrenme süreci üzerinde kullanılan veri kümesi  $D$ 'dir [29]. Destek Vektör Regresyonu (DVR) için bu, bir dışbükey optimizasyon probleminin çözülmesine yol açar. Bu bölüm, doğrusal DVR' yi destekleyen temel kavramları ve çekirdek işlevleriyle doğrusal olmayan eşlemelerin uzantısını sunar. Bir doğrusal eşleme  $f(x)$ 'in eldeki problem için uygun bir regresyon alternatifi olduğunu varsayalım. Bu, gelecekteki çıktı değerlerini tahmin etmek amacıyla kullanılabilmesi için mevcut bir girdi/çıkı eğitim verisi setine en iyi uyan doğrusal regresyon hiperdüzleminin bulunmasını gerektirir. Bu fonksiyon şu şekilde yazılabilir:

$$f(x) = w^T x + b \quad (4.1)$$

burada  $w$  ve  $b$ , sırasıyla, optimal regresyon için tanımlanacak modelin ağırlık vektörü ve kesişimidir. DVM'de, eğitim (ampirik) hatası, aşağıdaki gibi tanımlanan bir kayıp işlevi aracılığıyla ( $\varepsilon$  –duyarsız) ölçülür.

$$e(x,y,f) = \max(0, |y-f(x)| - \varepsilon) \quad (4.2)$$


Tahmin edilen  $f(x)$  değeri ile gözlemlenen  $y$  değeri arasındaki fark  $\varepsilon$  'dan küçükse hata dikkate alınmaz, aksi halde Eş. 4.2 'deki  $(f(x)-y)$  ve  $\varepsilon$  arasındaki mutlak farka eşittir. Böylece

$\varepsilon$ -duyarsız kayıp fonksiyonu,  $\varepsilon$  yarıçaplı hatasız bir tüpü tanımlar. Aşağıda gösterilen iki olası ve birbirini dışlayan durum,

$|y-f(x)|-\varepsilon = \xi$  tüpün "üstündeki" veri noktaları için

$|y-f(x)|-\varepsilon = \xi^*$  tüpün "altındaki" veri noktaları için

$\xi$  ve  $\xi^*$  'nin gevşek değişkenler olduğu yeri tanımlayabiliriz. Şekil 4.1. bu kayıp fonksiyonunu göstermektedir.



Şekil 4.1.  $\varepsilon$ -Duyarsız kayıp fonksiyonu (Smola ve Schölkopf, 2004)

Optimum regresyon hiperdüzlemini bulmak için ampirik (deneysel) hatanın yanı sıra, makine kapasitesi ile ilgili doğrusal ağırlıkların ( $\|w\|^2$ ),  $l_2$  normunu minimize etmek gerekir. Eğitim aşamasını temsil eden ikinci dereceden optimizasyon problemi,  $C$  'nin ampirik ve genelleştirme hataları arasındaki dengeyi modüle ettiği denklem aşağıdaki gibidir.

Min

$$\frac{1}{2} \|w\|^2 + C \sum_t (\xi_t + \xi_t^*)$$

Kısıtlar

$$y_t - w^T x_t - b \leq \varepsilon + \xi_t \quad (4.3)$$

$$w^T x_t + b - y_t \leq \varepsilon + \xi_t^* \quad (4.4)$$

$$\xi_t \geq 0 \quad (4.5)$$

$$\xi_t^* \geq 0 \quad (4.6)$$

İlk Lagrange fonksiyonu  $L_P$  ;

$$L_P(w, b, \xi, \xi^*, \alpha, \alpha^*, \beta, \beta^*) = \frac{1}{2} w^T w + C \sum_t (\xi_t + \xi_t^*) + \sum_t (\xi_t \beta_t + \xi_t^* \beta_t^*) - \sum_t \alpha_t (w^T x_t + b - y_t + \varepsilon + \xi_t) - \sum_t \alpha_t^* (y_t - w^T x_t - b + \varepsilon + \xi_t^*) \quad (4.7)$$

Burada  $\alpha_t$ ,  $\alpha_t^*$ ,  $\beta_t$  ve  $\beta_t^*$ , sırasıyla Eş 4.3, 4.4, 4.5 ve 4.6 kısıtlamalarıyla ilişkili Lagrange çarpanlarıdır. Eş. 4.3 ve 4.4'ü aynı anda sağlayan bir nokta olmadığından,  $\alpha_t$  ve  $\alpha_t^*$ 'nin her ikisinin de kesin olarak pozitif olamayacağı gözlemlenebilir.

Eş 4.7 en aza indirilmesi gerekir. Birincil değişkenler  $w$ ,  $b$ ,  $\xi$ ,  $\xi^*$  ve maksimize edilmiş ikili değişkenler  $w$ ,  $b$ ,  $\xi$ ,  $\xi^*$  Karush Kuhn Tucker (KKT) koşulları,  $L_P$  'nin kısmi türevlerinin olduğunu belirtir. İlkel değişkenler, optimal noktada değerlendirildiğinde ortadan kaybolmalıdır. KKT tamamlamıcılık koşulları tarafından sağlanan bazı eşitlikleri tekrar  $L_P$  'ye dahil ederek, bu daha sonra yalnızca  $\alpha, \alpha^*$  ikili değişkenlerinin fonksiyonu haline gelir ve ikili Lagrange ( $L_D$ ) elde edilir.

Max

$$L_D(\alpha, \alpha^*) = -\frac{1}{2} \sum_t \sum_j (\alpha_t - \alpha_t^*)(\alpha_j - \alpha_j^*) x_t^T x_j - \sum_t (\varepsilon - y_t) \alpha_t - \sum_t (\varepsilon + y_t) \alpha_t^* \quad t, j = 1, 2, \dots, l$$

Kısıtlar

$$\sum_t (\alpha_t + \alpha_t^*) = 0$$

$$0 \leq \alpha_t \leq C$$

$$0 \leq \alpha_t^* \leq C \quad (4.8)$$

İkili eğitim probleminin çözümü, '0' indeksinin optimalliği temsil ettiği tahmini regresyon fonksiyonunu sağlar.

$$f_0(x) = w_0^T x + b_0 = \sum_t (\alpha_{t0} + \alpha_{t0}^*) x_t^T x + b_0 \quad (4.9)$$

DVR'nin lineer olmayan regresyonunun altında yatan ana fikir,  $x_t \in \mathbb{R}^d$  girdi vektörlerini bir  $\phi(x_i)$  eşleme fonksiyonu aracılığıyla daha yüksek boyutlu bir özellik uzayına yani  $F$  'ye taşımak ve ardından  $F$  'de bir lineer regresyon çözmektir. Eş. 4.8'de girdi verileri  $x_t^T x_j$  ile değiştirilebilen  $\phi^T(x_t) \phi(x_j)$  nokta çarpımları şeklinde sunulur. Bununla birlikte, uygun bir eşleme fonksiyonunun seçimine ek olarak, eşlenmiş girdi vektörleri ile nokta çarpımların açık bir şekilde hesaplanması, hesaplama açısından pahalı olabilir. Bu şekilde, nokta çarpımlar,  $x$  'i  $F$  ile örtülmüş olarak eşleyen giriş uzayında tanımlanan  $K(x_t, x_j)$  çekirdek işlevleriyle değiştirilir. Bu fonksiyonlardan biri, parametresinin  $\sigma$  olduğu Gauss çekirdeğidir.

$$K(x_t, x_j) = \exp(-0.5 \|x_t - x_j\|^2 / \sigma^2) \quad (4.10)$$

Gauss çekirdeklerini kullanmanın ana faydası, sonsuz boyutlu uzaylarda çalışma olasılığıdır [30,31] .

Bu nedenle, regresyon işlevi orijinal giriş alanında doğrusal olmasa bile, özellik alanında doğrusaldır. Doğrusal olmayan regresyon fonksiyonları için DVR eğitim aşaması daha sonra doğrusal duruma benzer, ancak  $x_t^T x_j$   $K(x_t, x)$  ile değiştirilir. İlişkili ikili Lagranjiyi çözdükten sonra, tahmini regresyon fonksiyonu şu şekildedir :

$$f_0(x) = w_0^T x + b_0 = \sum_t (\alpha_{t0} + \alpha_{t0}^*) K(x_t, x) + b_0 \quad (4.11)$$

Eğer  $\alpha_{t0}$  veya  $\alpha_{t0}^*$  pozitifse, ilgili  $x_i$  'nin gerçekten de regresyon fonksiyonlarının hesaplanmasına katkıda bulunduğuna dikkat edilmelidir (Eş. 4.9 ve 4.11). Bu özelliğe sahip olan giriş vektörleri, destek vektörleri olarak adlandırılır.

Gauss çekirdeği ile bir DVR ayarlamak için ayarlanması gereken üç parametre vardır, yani  $C$ ,  $\varepsilon$  ve  $\sigma$ . DVR performansı büyük ölçüde bu üçlü parametreye bağlıdır. Genel olarak konuşursak, parametre seçim problemi, test verileri, yani eğitim aşamasında kullanılmayan veriler üzerinde DVM regresyon performansını en üst düzeye çıkarmak için  $C$ ,  $\varepsilon$  ve  $\sigma$  karar değişkenlerinin değerlerinin seçilmesinden oluşur. Bu veriler üzerindeki DVR performansının kalitesi,  $\hat{y}_t$  'nin  $t$  'nci çıktı gözlemi için DVR tahmini olduğu Normalleştirilmiş Ortalama Kareler Kök Hatası (NOKKH) olarak adlandırılan hesaplama yoluyla ölçülebilir.


$$\text{NOKKH} = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{\sum y_t^2}} \quad (4.12)$$

#### 4.1. DVM'nin Kullanım Alanları

Birçok örüntü uygulamasında DVM'lerden faydalanılmaktadır. Şekil 4.2' de de görüldüğü üzere yüz algılama, biyoinformatik, homoloji tespiti, metni sınıflandırma, görüntü sınıflandırma, protein çaprazlama, el yazısı tanıma, jeoloji ve çevre bilimleri genelleştirilmiş önkestirim temelli kontrol uygulamaları kullanılan alanlardan sadece bazılarıdır.

Örneğin yüz algılama uygulamasında görüntünün bölümleri yüz ve yüz olmayan bölümler şeklinde sınıflandırılarak  $M \times M$  boyutuna sahip bir görüntüdeki her bir piksel değeri yüz ve yüz olmayan bölümler adı ile iki farklı biçimde etiketlenir. Belirtilen bu veriler eğitim verilerini oluşturur. Sonra piksel parlaklığına göre yüzlerin etrafında bir karesel sınır oluşturulur ve her bir görüntü için aynı işlem tekrar edilerek, DVM ile sınıflandırma işlemleri gerçekleştirilir.

Aynı şekilde homoloji tespiti, protein yapıları ve fonksiyonları çalışmalarında önemli bir rol oynar. Esnek hesaplama algoritmalarının çoğu, protein dizilerini temsil etmek için sabit uzunluk özelliklerine ihtiyaç duyar. Sınırlı protein bilgisi ile ayırt edici özellikleri tespit etme işlemi zor bir iştir. Buna rağmen literatürde bu işlemlerde DVM'lerden oldukça başarılı sonuçlar elde edilmiştir.



Şekil 4.2. DVM'nin uygulama alanları

#### 4.2. DVM'lerde Tercih Edilen Yöntemler


Kullanılacak verilerin lineer olarak ayrılabilir yapıda olması veya lineer olarak ayrılamayan yapıda olması DVM'lerde karşılaşılabilecek iki durumdur.

##### 4.2.1. Doğrusal destek vektör regresyon

Destek vektörü optimizasyon problemi, ancak eğitim verisi sayısı çok küçük olduğunda veya eğitim verilerinden hangilerinin destek vektörü olacağı önceden bilindiğinde ayrılabilir durum için analitik olarak çözülebilir. Kullanılacak  $N$  elemandan oluşan verinin  $\theta = \{x_i, y_i\}$ ,  $i = 1, 2, \dots, N$  olduğunu düşünelim. Burada  $y_i \in \{-1, 1\}$  etiket değerleri ve  $x_i \in \mathbb{R}^d$  özellikler vektörüdür. Bir düzlem ile ayrılabilen durumlarda (lineer olarak ayrılabilir durumu), bu iki değerli veriler direkt ayrılabilir. Bu düzlem ayırıcı aşırı düzlem olarak adlandırılmaktadır (Şekil 4.3). DVM'lerin amacı bu aşırı düzlemin iki değişik sınıfta bulunan örnek grubuna eşit mesafede olmasını sağlamaktır.

$\varepsilon$  -duyarsız destek vektör regresyonda ( $\varepsilon$  -DVR) hedef tüm eğitim verisi için gerçek yanıt değişkeni  $y_i$ ' lerden maksimum düzeyde  $\varepsilon$  sapmaya sahip olan olası en düz  $f(x)$

fonksiyonunu bulmaktır. Burada anlatılmak istenen, hatalar  $\varepsilon$ ' dan küçük değerde olduğu sürece önemsenmeyecektir ve bu değerden daha büyük bir sapma kabul edilmeyecektir [32].



Şekil 4.3. Doğrusal olarak ayrılabilen veriler

#### Esnek marjın destek vektör regresyon

Kimi durumlarda tüm  $(x_i, y_i)$  ikililerini  $\varepsilon$  kesinliğinde yakınsayan  $f$  fonksiyonu bulunmayabilir ya da kimi zamanlarda bazı hatalara izin verilmek istenebilir. Bunu mümkün hale getirmek, esnek (yumuşak) marjın kayıp fonksiyonunun kullanılmasıyla olur ve modellemeye  $\xi^+$  ve  $\xi^-$  gevşek değişkenleri eklenir. Böylece optimizasyon problemi aşağıda belirtildiği gibi yazılır.

$$\text{Min} \quad \frac{1}{2} \|w\|^2 + C \sum_t (\xi_t^+ + \xi_t^-)$$

$$y_i - (w \cdot x_i + b) \leq \varepsilon + \xi_t^+$$

$$(w \cdot x_i + b) - y_i \leq \varepsilon + \xi_t^-$$

$$\xi_t^+, \xi_t^- \geq 0 \tag{4.13}$$

$C > 0$  sabiti  $f$  fonksiyonunun düzlüğü ve tolere edilecek hata miktarı arasında dengeyi sağlamaktadır.

### Dual problem

Dual formülasyon Lagrange çarpanları kullanılarak elde edilmektedir.

$$L = \left\{ \frac{1}{2} ||w||^2 + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) - \sum_{i=1}^n (\beta_i^+ \xi_i^+ + \beta_i^- \xi_i^-) - \sum_i \alpha_i^- (\varepsilon + \xi_i^- - y_i + (w \cdot x_i + b)) - \sum_i \alpha_i^+ (\varepsilon + \xi_i^+ - y_i + (w \cdot x_i + b)) \right\} \quad (4.14)$$

$\beta_i^+, \beta_i^-, \alpha_i^-, \alpha_i^+$  Lagrange çarpanlarıdır.  $L$ 'nin  $w, b, \xi^+, \xi^-$  'ye göre kısmi türevi alınır

$$\frac{dL}{dw} = 0 \Rightarrow w = \sum_{i=1}^n x_i (\alpha_i^+ - \alpha_i^-) \quad (4.15)$$


$$\frac{dL}{db} = 0 \Rightarrow \sum_{i=1}^n (\alpha_i^+ - \alpha_i^-) = 0 \quad (4.16)$$

$$\frac{dL}{d\xi_i^+} = 0 \Rightarrow C - (\alpha_i^+ + \beta_i^+) = 0 \quad \forall_i \quad (4.17)$$

$$\frac{dL}{d\xi_i^-} = 0 \Rightarrow C - (\alpha_i^- + \beta_i^-) = 0 \quad \forall_i \quad (4.18)$$

### **4.2.2. Doğrusal olmayan destek vektör regresyon**

Lineer olarak ayrılabilme durumunda veriler iki ayrı sınıfa doğrusal bir düzlem ile ayrılabilirken bu durum yapılan uygulamalarda her zaman geçerli olmayabilir. Yani doğrusal bir düzlem ile veriler birbirinden ayrılamayabilir. (Şekil 4.4)




Şekil 4.4. Doğrusal olarak ayrılamayan veriler

Verilerin düz bir düzlem ile ayrılamadığı durumlarda doğrusal bir sınıflandırıcı yerine doğrusal olmayan sınıflandırıcılar kullanılmalıdır. Bu bağlamda Doğrusal Olmayan Özellik Uzayı;  $x_i \in R^n$  gözlem vektörünü daha yüksek mertebeden bir uzayda  $z$  vektörüne dönüştürerek, bu yeni uzayda doğrusal sınıflandırıcıları elde etmek söz konusu olabilir. Bu  $z$  vektörünün bulunduğu özellik uzayı  $F$  ile gösterilsin. Bu durumda  $\emptyset$  ifadesi  $R^n \rightarrow R^F$  eşlemesini yapmak üzere  $z = \emptyset(x)$  şeklinde (Eş. 4.19) ifade edilebilir.

$$x \in R^n \rightarrow z(x) = [a_1, \emptyset_1(x), \dots, a_n, \emptyset_n(x)]^T \in R^F \quad (4.19)$$


Doğrusal olmayan haritalama fonksiyonu yardımı ile doğrusal olarak ayrılamayan DVM, orijinal giriş uzayından doğrusal olarak kolayca sınıflandırma yapabileceği yüksek boyutlu nitelik uzayına geçiş yapabilir. Yani çekirdek fonksiyonları kullanılarak bütün değerlerin yeniden çarpılıp hesaplanması yerine doğrudan çekirdek fonksiyonunda değerin yerine konularak nitelik uzayındaki değerinin bulunması sağlanır. Böylece, boyutu çok yüksek olan bir nitelik uzayı ile uğraşma işlemi ortadan kalkar. Çekirdek fonksiyonlarının diğer avantajlarından biri de, eğitme aşamasında bir eğitim örneği için değerler bulunduktan sonra diğer örnekler için de aynı kalıp değerleri ile eğitim örneği dışında tamamen hazır olduğu için daha kolay hesaplanmasıdır [33].



Şekil 4.5. Doğrusal olarak ayrılamayan verilerin çekirdek ile haritalanması

### 4.3. Kayıp Fonksiyonları

Destek vektör makinelerinin, destek vektör regresyona uyarlanabilmesi için tasarlanan modele kayıp fonksiyonu [34] eklenmelidir. Sürekli kullanılan kayıp fonksiyonu önceki kısımlarda gösterilen  $\varepsilon$ -duyarsız kayıp fonksiyonudur. Fakat yaygın olarak kullanılan 4 temel kayıp fonksiyonu vardır. Şekil 4.6(a)'daki kayıp fonksiyonu, geleneksel en küçük kareler hata kriterine karşılık gelir. Şekil 4.6(b)'deki kayıp fonksiyonu, aykırı değerlere ikinci dereceden kayıp fonksiyonundan daha az duyarlı olan bir Laplace kayıp fonksiyonudur. Huber, Şekil 4.6(c)'deki kayıp fonksiyonunu, verilerin temel dağılımı bilinmediğinde optimal özelliklere sahip olan sağlam bir kayıp fonksiyonu olarak önerilir. Bu üç kayıp fonksiyonu, destek vektörlerinde seyreklik oluşturmamaktadır. Bu sorunu çözmek için Vapnik, Şekil 4.6(d)'deki kayıp fonksiyonunu Huber'in seyrek bir destek vektörleri setinin elde edilmesini sağlayan kayıp fonksiyonuna bir yaklaşım olarak önermiştir.



Şekil 4.6. En çok kullanılan 4 temel kayıp fonksiyonu (Gunn, 1998)

#### 4.3.1. Karesel kayıp fonksiyonu

En çok kullanılan kayıp fonksiyonudur.  $L_2$  kayıp fonksiyonu şeklinde de adlandırılabilir.

$$\ell(f, \{\vec{x}, y\}) = \ell(y - f(\vec{x})) = \ell(y - f(\vec{x}))^2 \quad (4.20)$$

#### 4.3.2. Mutlak kayıp fonksiyonu

$L_1$  Kayıp fonksiyonu olarak da tanımlanabilir ve denklemi,

$$\ell(f, \{\vec{x}, y\}) = \ell(y - f(\vec{x})) = |y - f(\vec{x})| \quad (4.21)$$

#### 4.3.3. Huber kayıp fonksiyonu

$L_1$  kayıp fonksiyonunun tersine türevlenebilirdir ve denklemi,

$$\ell(f, \{\vec{x}, y\}) = \ell(y - f(\vec{x}))_{\epsilon} = \begin{cases} \frac{1}{4\epsilon} (y - f(\vec{x}))^2, & |y - f(\vec{x})| \leq 2\epsilon \\ |y - f(\vec{x})| - \epsilon, & \text{öteki değerler} \end{cases} \quad (4.22)$$

#### 4.3.4. Vapnik kayıp fonksiyonu ( $\varepsilon$ -duyarsız kayıp fonksiyonu)

Bu kayıp fonksiyonu Vladimir Naumovich Vapnik tarafından öne sürülmüştür.  $\varepsilon$ -duyarsız kayıp fonksiyonu şeklinde de adlandırılır ve denklemi,

$$\ell(f, \{\vec{x}, y\}) = \ell(y - f(\vec{x}))_\varepsilon = \begin{cases} 0, & |y - f(\vec{x})| \leq \varepsilon \\ |y - f(\vec{x})| - \varepsilon, & \text{öteki değerler} \end{cases} \quad (4.23)$$

#### 4.4. Özellik Alanı

Bu bölüm, çekirdekleri çoğaltma yoluyla yüksek boyutlu bir özellik uzayına bir eşleme oluşturmak için kullanılabilecek yöntemi tartışır. Çekirdek fonksiyonunun [35] fikri, işlemlerin potansiyel olarak yüksek boyutlu özellik uzayından ziyade girdi uzayında gerçekleştirilmesini sağlamaktır. Bu nedenle, iç çarpımın özellik uzayında değerlendirilmesine gerek yoktur. Bu, boyutsallık kavramını ele almanın bir yolunu sağlar. Bununla birlikte, hesaplama hala kritik olarak eğitim modellerinin sayısına bağlıdır ve yüksek boyutlu bir problem için iyi bir veri dağılımı sağlamak genellikle büyük bir eğitim seti gerektirecektir.

##### 4.4.1. Çekirdek işlevleri

Düz bir düzlem ile ayrılamayan verilerin başka bir yöntem ile ayrılması gerekmektedir. Destek vektör regresyonu ile yapılan çalışmaların bu kadar başarılı olmalarındaki en önemli neden çekirdek yöntemlerinin kullanılmasıdır. Verileri düz bir doğru ile ayrılamayan sınıfların boyutu artırılarak bir düzlem aracılığı ile ayırmak mümkündür. Bu amaç için kullanılabilecek farklı tipte çekirdek fonksiyonları bulunmaktadır. Bir başka deyişle çekirdek işlevleri, doğrusal olmayan bir fonksiyonun doğrusal regresyonunu sağlayan yüksek boyutlu bir özellik uzayına bir eşleme oluşturmak için kullanılır. Bu, haritalamanın önceden işlendiği ve DVR' nin bu özellik uzayındaki en düz işlevi bulmak için yeniden amaçlandırıldığı anlamına gelir.

Girdi verileri  $x_i$  olarak eşlenir, ancak  $\phi(x_i)$ ' i açıkça tanımlamamıza gerek yoktur. Çünkü DVR, regresyon prosedüründe ve nihai tahmin fonksiyonunda yalnızca iç çarpıma ihtiyaç duyar. Aşağıdaki teori, Çekirdek Hilbert Uzaylarının Yeniden Üretilmesi' ne [36]

dayanmaktadır. Özellik alanındaki bir iç çarpım, belirli koşulların sağlanması şartıyla giriş alanında eşdeğer bir çekirdeğe sahiptir.


$$K(x_t, x_j) = \langle \phi(x_t), \phi(x_j) \rangle \quad (4.24)$$

$K$ , Mercer Koşullarını sağlayan simetrik pozitif tanımlı bir fonksiyon ise,

$$K(x_t, x_j) = \sum_m^{\infty} a_m \phi_m(x_t) \phi_m(x_j), \quad a_m \geq 0 \quad (4.25)$$

$$\iint K(x_t, x_j) g(x_t) g(x_j) dx_t dx_j > 0, \quad g \in L_2 \quad (4.26)$$

çekirdek, özellik uzayında meşru bir iç çarpımı temsil eder. Mercer'in koşullarını karşılayan geçerli fonksiyonlar şimdi verilmiştir. Aksi belirtilmedikçe tüm gerçek  $x_t$  ve  $x_j$  için geçerlidir.



Şekil 4.7. Çekirdek fonksiyonu ile verinin daha yüksek bir boyuta dönüşmesi (Smola ve Schölkopf, 2004)

### Doğrusal çekirdek fonksiyonu

En basit çekirdek fonksiyonunu ifade etmektedir. Bu aslında vektörlerin iç çarpımıdır ve eşleme uygulanmaz. DVR bir çekirdek fonksiyonu ile kodlanacağı için doğrusal çekirdek seçenekler arasında olacaktır.

$$K(x_t, x_j) = x_t^T x_j \quad (4.27)$$

### Polinom çekirdek fonksiyonu

Polinom çekirdeği, doğrusal olmayan modelleme için popüler seçenekler arasındadır. Durağan olmayan bir çekirdek fonksiyonudur. Genel olarak bütün eğitim verilerinin normalize edildiği problemler için uygundur. Denklemden belirtilen  $d$  polinom derecesinin çekirdek parametresidir. 1 (bir) eklenmesi Hessian'ın sıfır olmasını engeller.

$$K(x_t, x_j) = (1 + x_t^T x_j)^d \quad (4.28)$$

### Gauss çekirdek fonksiyonu

Gauss çekirdeği radyal taban fonksiyonu çekirdeğine örnektir. İki vektör arasındaki Öklid mesafesinin karesini kullanan Gauss radyal temel fonksiyonu, esnekliği nedeniyle DVM' de de yaygın olarak kullanılmaktadır. Gauss çekirdek performansında uygulamaya göre dikkatli bir şekilde seçilmesi gereken, ayarlanabilir parametreler önemli bir rol oynamaktadır. Aşırı tahmin gerçekleştirilmeye çalışıldığında üstel ifade doğrusala yaklaşmaya çalışır ve bir doğruymuş gibi hareket etmeye başlar. Yani doğrusal olmayan yapısını kaybetmeye başlar. İki vektör arasındaki Öklid mesafesini kullanır.

$$K(x_t, x_j) = (e)^{-\gamma ||x_t - x_j||^2}, \gamma > 0 \quad (4.29)$$

### Laplace çekirdek fonksiyonu

Laplace çekirdeği, radyal tabanlı fonksiyon çekirdeği ile eşdeğerdir. Aynı zamanda tümüyle üstel çekirdek fonksiyonuna denktir. Sigma değerindeki değişikliklere karşı diğer çekirdek fonksiyonlarına göre daha az duyarlıdır.

$$K(x_t, x_j) = (e)^{\frac{-||x_t - x_j||}{\sigma}} \quad (4.30)$$

### Anova çekirdek fonksiyonu

Gauss ve Laplace çekirdeği gibi radyal tabanlı bir fonksiyon çekirdeğidir. Yüksek boyuta sahip regresyon denklemlerinde iyi bir performans sergilediği bilinmektedir.

$$K(x_t, x_j) = \sum_{i=1}^n \exp(-\sigma(x_t^i - x_j^i)^2)^d \quad (4.31)$$

### Sigmoid çekirdek fonksiyonu

Sigmoid çekirdeğinde iki adet ayarlanabilir  $\alpha$  ve  $c$  kesme sabiti mevcuttur.  $\alpha$  için ortak değer olarak  $(1/N)$  kullanılabilir ve  $N$  değeri verinin boyutunu ifade etmektedir.

$$K(x_t, x_j) = \tanh(\alpha x_t^T x_j + c) \quad (4.32)$$

### Bessel çekirdek fonksiyonu

Düzgün fraksiyonel uzaylar kuramında iyi bilinen çekirdeklerden biridir. Denklemden bulunan  $J$  ibaresi birinci dereceden bessel değeridir.

$$K(x_t, x_j) = \frac{J_{v+1}(\sigma ||x_t - x_j||)}{||x_t - x_j||^{-n(v+1)}} \quad (4.33)$$

Yüksek boyutlu özellik uzayına eşlemenin boyutluluk lanetine yol açtığına dikkat edilmelidir, yani, boyutluluk arttıkça, alanın hacmi artar ve bu yüksek boyutlu uzayda eğitim verileri seyrekleşir. Boyut probleminin üstesinden gelmek için, DVR' ye iyi bir veri dağılımına sahip büyük bir eğitim seti sağlanmalıdır.

DVR' ye uygulanabilecek çeşitli türde çekirdekler vardır ve bu çekirdeklerin kombinasyonları mümkündür. Doğrusal olmayan çekirdekler, DVR' nin ana parametreleri olan  $\epsilon$  ve  $C$  gibi kullanıcı tarafından önceden tanımlanmış parametrelere sahip olabilir.

#### 4.4.2. Veri normalleştirme

Kısıtlı etki alanları nedeniyle belirli çekirdekler için veri normalleştirme gereklidir ve ayrıca kısıtlanmamış çekirdekler için de avantajlı olabilir. Verilerin normalleştirilmesinin (izotropik veya izotropik olmayan) gerekli olup olmadığını belirlemek için giriş özelliklerinin dikkate alınması gerekir. Ek olarak, normalleştirme, optimizasyon problemindeki hesseli numaranın durumunu iyileştirecektir.

#### 4.4.3. Çekirdek seçimi

Ortaya çıkan bariz soru, aralarından seçim yapılabilecek pek çok farklı eşleme ile belirli bir problem için hangisinin en iyisi olduğudur. Bu yeni bir soru değil, ancak birçok eşlemenin tek bir çerçevede dahil edilmesiyle karşılaştırma yapmak daha kolay olmaktadır. VC boyutundaki (VC boyutu, bir dizi işlevin kapasitesini ölçen skaler bir değerdir) üst sınır ,


$h \leq [\min R^2 A^2, n] + 1$  denkleminde (n boyutlu uzayda kurallı hiperdüzlemler kümesinin VC boyutu, h ile sınırlandırılmıştır. Burada R, tüm veri noktalarını kapsayan bir hiperkürenin yarıçapıdır ve çekirdekleri karşılaştırmanın bir yolunu sağlamak için potansiyel bir yoldur. Ancak, doğrusal olmayan özellik uzayındaki verileri çevreleyen hiperkürenin yarıçapının tahminini gerektirir. Son bir uyarı olarak, bir çekirdek seçmek için güçlü bir teorik yöntem geliştirilse bile, bu çok sayıda problem üzerinde bağımsız test setleri kullanılarak doğrulanmadıkça, önyükleme ve çapraz doğrulama gibi yöntemler çekirdek seçimi için tercih edilen yöntem olmaya devam edecektir.

## 5. UYGULAMA

Bir DVR modelini verimli bir şekilde oluşturmak için DVR' nin parametreleri dikkatli bir şekilde belirlenmelidir. Bu parametreler şunları içerir:

- (1) Çekirdek işlevi: Çekirdek işlevi, DVR giriş alanı üzerinde doğrusal olmayan bir karar hiper yüzeyi oluşturmak için kullanılır. Genel olarak, Gauss fonksiyonunun kullanılması daha iyi tahmin performansı sağlayacaktır [37]. Bu nedenle, bu çalışmada SVR çekirdek fonksiyonu olarak Polinom fonksiyonu kullanılmıştır.
- (2) Düzenleştirme parametresi ( $C$ ) :  $C$ , eğitim hatasının en aza indirilmesi ile modelin karmaşıklığının en aza indirilmesi arasındaki uzlaşma maliyetini belirler.
- (3) Çekirdek fonksiyonunun bant genişliği ( $\sigma^2$ ) :  $\sigma^2$ , çekirdek fonksiyonunun varyansını temsil eder.
- (4)  $\epsilon$  - duyarsız kayıp fonksiyonu tüp boyutu ( $\epsilon$ ): Eğitim veri noktalarına yerleştirilen yaklaşma doğruluğuna eşdeğerdir.

DVR' de, uygun olmayan şekilde seçilen parametreler aşırı sığdırma veya yetersiz sığdırma ile sonuçlanır. Genel olarak, parametreleri seçerken, çoğu araştırmacı hala standart prosedürü (deneme-yanılma) takip eder, önce farklı parametre setlerine dayalı birkaç DVR modeli oluşturur, ardından optimal parametreleri elde etmek için bunları doğrulama setinde test eder. Ancak, bu durum zaman almaktadır.



Şekil 5.1. DVR modelinin temel yapısı

Arıza tahmini modellememizde DVR' nin girdileri geçmiş,  $\{x_i\}$  veri serisinin gecikmiş gözlemleri ve çıktıları gelecek değerlerdir. Şekil 5.1, DVR' nin temel mimarisini göstermektedir.

Burada,  $x_i$ ,  $i$  'inci yazılım arızasındaki arızalar arası süre anlamına gelir.  $p$ , giriş vektörünün boyutu (giriş düğümlerinin sayısı) veya gelecekteki değerle ilgili geçmiş gözlemlerin sayısı anlamına gelir. DVR yaklaşımı, arızalar arası sürenin uygun dahili temsili keşfetmeye çalışır. Tahmin problemlerinin çözümünün anahtarı,  $f$  fonksiyonuna nasıl yaklaşılabileceğidir. Modelleme sürecinde doğrusal olarak sınırlandırılmış ikinci dereceden bir programlamayı çözerek, veriler arasındaki özilinti keşfedilebilir ve daha iyi tahminler elde edilebilir.

Arıza analizinde, DVR önce geçmiş güvenilirlik endeksleri ile ilgili hedefler arasındaki ilişkiyi öğrenmek ve daha sonra gelecekteki müdahale süresini tahmin etmek için eğitilebilir. Çizelge 5.1. DVR modelleme sürecinde eğitim kalıplarının nasıl oluşturulabileceğine dair bir örnektir.

Çizelge 5.1. DVR modellemesindeki eğitim kalıpları

| $X$       |             |             |     | $Y$       |           |
|-----------|-------------|-------------|-----|-----------|-----------|
| $x_1$     | $x_2$       | $x_3$       | ... | $x_p$     | $x_{p+1}$ |
| $x_2$     | $x_3$       | $x_4$       | ... | $x_{p+1}$ | $x_{p+2}$ |
| $x_3$     | $x_4$       | $x_5$       | ... | $x_{p+2}$ | $x_{p+3}$ |
| $x_4$     | $x_5$       | $x_6$       | ... | $x_{p+3}$ | $x_{p+4}$ |
| ...       | ...         | ...         | ... | ...       | ...       |
| ...       | ...         | ...         | ... | ...       | ...       |
| ...       | ...         | ...         | ... | ...       | ...       |
| $x_{i-p}$ | $x_{i-p+1}$ | $x_{i-p+2}$ | ... | $x_{i-1}$ | $x_i$     |

Yapılan modellemede bir şehir içi ulaşım firmasına ait olan 15 adet tramvay aracında Nisan 2019- Aralık 2021 yılları arasında meydana gelmiş 603 adet arızanın tahmin işlemi gerçekleştirilmiştir. Belirtilen yıllar arasında meydana gelen arızaların başlangıç tarihi ve saati önem arz etmektedir. Modelleme için kullanılacak olan veri setinin belirli bir kısmı Çizelge 5.2.'de gösterilmiştir. Modellemenin işlem çıktısı 591 adet gözlemden oluşmaktadır. Bunların %70' lik kısmı olan 414 adet gözlem eğitim kümesi, kalan %30' luk kısmı olan 177 adet gözlem ise test kümesi olarak belirlenmiştir.

Çizelge 5.2. Kullanılan veri setinin bazı örnekleri

| <b>tarih</b> | <b>başlama saati</b> |
|--------------|----------------------|
| 5.08.2019    | 17:58                |
| 3.09.2019    | 16:54                |
| 30.09.2019   | 18:12                |
| 26.11.2019   | 14:04                |
| 1.12.2019    | 13:20                |
| 1.01.2020    | 19:55                |
| 9.02.2020    | 06:00                |
| 26.03.2020   | 09:52                |
| 14.04.2020   | 09:56                |
| 4.05.2020    | 13:52                |
| 13.06.2020   | 06:10                |
| 19.07.2020   | 06:15                |
| 17.08.2020   | 18:50                |
| 2.09.2020    | 12:30                |
| 6.10.2020    | 23:00                |
| 30.10.2020   | 20:19                |
| 11.11.2020   | 16:38                |
| 1.12.2020    | 15:42                |
| 12.01.2021   | 05:52                |
| 3.02.2021    | 08:04                |
| 4.03.2021    | 10:33                |
| 13.04.2021   | 12:14                |
| 14.05.2021   | 14:23                |
| 2.08.2021    | 14:00                |
| 21.08.2021   | 07:52                |
| 6.09.2021    | 07:48                |
| 16.11.2021   | 16:37                |
| 10.12.2021   | 16:36                |

The screenshot displays a software interface for DVR (Dynamic Vehicle Regression) modeling. It is divided into two main sections: 'Girdi Değerleri' (Input Values) on the left and 'Çıktı' (Output) on the right.

**Girdi Değerleri (Input Values):**

- Polinom:** A dropdown menu showing 'Polinom'.
- Ceza Değeri:** A text box containing '500'.
- Parametre:** A text box containing '2.5'.
- Epsilon:** A text box containing '100'.
- İleri Tahmin:** A text box containing '5'.
- KAYDET:** A button to save the input values.

**Çıktı (Output):**

- Eğitim MAPE:** A text box containing '1.26843'.
- Test MAPE:** A text box containing '1.65218'.
- Eğitim R Kare:** A text box containing '0.999727'.
- Test R Kare:** A text box containing '0.999628'.
- D süresi:** A text box containing '11'.
- İLERİ TAHMİN SONUÇLARI:** A table showing the results of the forward prediction.
- EXCEL KAYDET:** A button to save the output results to an Excel file.

|   | 1                    |
|---|----------------------|
| 1 | 26-May-2021 11:12:50 |
| 2 | 27-May-2021 18:48:03 |
| 3 | 29-May-2021 07:04:36 |
| 4 | 30-May-2021 15:17:44 |
| 5 | 01-Jun-2021 07:15:04 |


Şekil 5.2. Tasarlanan DVR arayüz

Tasarlanan modellemelerde bir arayüz oluşturulmuş ve girdi verileri işlenerek en uygun çıktı verileri elde edilmeye çalışılmıştır. Modelleme için en uygun yöntemin Polinom DVR olduğu görülmüştür. Girdi değerleri bölümünde ceza değeri değeri 100 ile 1000 arasında 100' er artış olacak şekilde, parametre değeri 0.5 ile 3 arasında 0.5 olarak artacak şekilde ve epsilon değeri 100 ile 300 arasında 50' şer artış olacak şekilde toplamda 300 adet DVR modellemesi yapılmıştır. İleri tahmin süresi için 5 değeri girilmiştir. Yapılan modellemeler arasında elde edilen en iyi kombinasyon  $C=500$  Parametre= $2.5$  Epsilon= $100$  olarak belirlenmiştir. Bu parametrelerin sonucunda eğitim MAPE değeri 1.26843, test MAPE değeri 1.65218 olarak bulunmuştur. Determinasyon katsayıları ise eğitim ve test değerleri için sırası ile 0.999727 ve 0.999628 olarak sonuçlandırılmıştır. D süresinde bulunan çıktı verisi ise modellemenin kaç dönem geriye dönük tahmin ettiğini belirlemektedir. Matlab 2018a ile yapılan 300 adet DVR modellemesi arasından çeşitli girdi değerleri işlenerek elde edilen çıktı değerleri Çizelge 5.3' teki gibi gösterilmiştir.


Çizelge 5.3. Girdi değerleri değiştirilerek elde edilen bazı çıktı değerleri

| POLİNOM ÇEKİRDEK                     |                                      | MAPE     |          | R <sup>2</sup> |          |
|--------------------------------------|--------------------------------------|----------|----------|----------------|----------|
|                                      |                                      | Eğitim   | Test     | Eğitim         | Test     |
| epsilon değeri değiştirilerek        | C=100 $\gamma = 0.5$ $\epsilon=100$  | 0.395983 | 0.453828 | 0.998992       | 0.998688 |
|                                      | C=100 $\gamma = 0.5$ $\epsilon=150$  | 0.424042 | 0.304937 | 0.99893        | 0.999371 |
|                                      | C=100 $\gamma = 0.5$ $\epsilon=200$  | 0.361177 | 0.38506  | 0.999045       | 0.998945 |
|                                      | C=100 $\gamma = 0.5$ $\epsilon=250$  | 0.370109 | 0.38081  | 0.999151       | 0.999068 |
|                                      | C=100 $\gamma = 0.5$ $\epsilon=300$  | 0.37463  | 0.403844 | 0.999026       | 0.998802 |
| ceza katsayısı değeri değiştirilerek | C=100 $\gamma = 2.5$ $\epsilon=100$  | 1.72623  | 1.57581  | 0.999556       | 0.999581 |
|                                      | C=200 $\gamma = 2.5$ $\epsilon=100$  | 1.53031  | 1.37617  | 0.999628       | 0.999582 |
|                                      | C=300 $\gamma = 2.5$ $\epsilon=100$  | 1.40097  | 1.37364  | 0.999686       | 0.999677 |
|                                      | C=400 $\gamma = 2.5$ $\epsilon=100$  | 1.38947  | 1.16846  | 0.999692       | 0.999788 |
|                                      | C=500 $\gamma = 2.5$ $\epsilon=100$  | 1.26843  | 1.65218  | 0.999727       | 0.999628 |
|                                      | C=600 $\gamma = 2.5$ $\epsilon=100$  | 1.32483  | 1.15601  | 0.999753       | 0.999762 |
|                                      | C=700 $\gamma = 2.5$ $\epsilon=100$  | 1.25305  | 1.35206  | 0.999803       | 0.999689 |
|                                      | C=800 $\gamma = 2.5$ $\epsilon=100$  | 1.38314  | 1.46716  | 0.999674       | 0.999625 |
|                                      | C=900 $\gamma = 2.5$ $\epsilon=100$  | 1.4044   | 1.31641  | 0.999681       | 0.999734 |
|                                      | C=1000 $\gamma = 2.5$ $\epsilon=100$ | 1.25562  | 1.02167  | 0.999809       | 0.99977  |
| parametre değeri değiştirilerek      | C=500 $\gamma = 0.5$ $\epsilon=150$  | 0.269823 | 0.310276 | 0.999519       | 0.999451 |
|                                      | C=500 $\gamma = 1$ $\epsilon=150$    | 0.267894 | 0.302992 | 0.999545       | 0.999521 |
|                                      | C=500 $\gamma = 1.5$ $\epsilon=150$  | 0.273181 | 0.306237 | 0.999513       | 0.999522 |
|                                      | C=500 $\gamma = 2$ $\epsilon=150$    | 1.19823  | 1.56791  | 0.999723       | 0.999741 |
|                                      | C=500 $\gamma = 2.5$ $\epsilon=150$  | 1.46184  | 1.57555  | 0.99962        | 0.999537 |
|                                      | C=500 $\gamma = 3$ $\epsilon=150$    | 0.915889 | 0.960529 | 0.999923       | 0.999911 |

En iyi kombinasyona ait olan eğitim tahmin ve gözlem grafiği Şekil 5.3’de, test tahmin ve gözlem grafiği ise Şekil 5.4’de verilmiştir. Mavi olarak belirtilen değerler tahmin verilerini, kırmızı olarak belirtilen değerler ise DVR modellemesinde elde edilen gözlem verilerini göstermektedir.



Şekil 5.3. En iyi girdi değerleri ile elde edilen eğitim tahmin ve gözlem grafiği



Şekil 5.4. En iyi girdi değerleri ile elde edilen test tahmin ve gözlem grafiği

Çizelge 5.4’ de de ileri tahmin değeri 5 girildiği için meydana gelecek olan arızanın 5 günlük tahmini tarih ve saat olarak elde edilmiştir.

Çizelge 5.4. En iyi girdi değerleri ile elde edilen ileri tarih ve saat değerleri

| ileri tahmin değeri | ileri tahmin tarih ve saati |
|---------------------|-----------------------------|
| 1                   | 26-May-2021 11:12:50        |
| 2                   | 27-May-2021 18:48:03        |
| 3                   | 29-May-2021 07:04:36        |
| 4                   | 31-May-2021 15:17:44        |
| 5                   | 01-Haz-2021 07:15:04        |

## 6. SONUÇ VE ÖNERİLER

Modelleme ve güvenilirlik analizi, teknik sistem yönetimi sürecinde önemli bir unsurdur. Herhangi bir arıza, teknik araçlar kullanılarak gerçekleştirilen işletme süreçlerinin verimliliğinde azalmaya neden olabilir. Arıza tahmini dikkate alınarak bir işlemin modellenmesi, bu tür arızalardan kaynaklanan kayıpların en aza indirilmesini mümkün kılar. Ayrıca, ileri düzeyde güvenilirlik bilgisi, periyodik bakım ve yedek parça tedariki için planlama sürecini desteklemelidir. Bu nedenle, birçok bilim ve teknoloji alanında ve ekonominin dallarında, teknik nesnelerin ve cihazların sömürülmesinin gerçek operasyonel süreçlerini yansıtan modeller yaratmaya çalışılmaktadır. Hafif raylı sistemlerin etkin çalışması, güvenilir bir araç filosu gerektirir. İşletim sırasında ulaşım araçlarında arızaların meydana gelmesi neredeyse her zaman tüm sistem için daha fazla veya daha az kayıpla sonuçlanır. Hafif raylı sistem araçlarının gereklilikleri karşılamak için uygun bakım, teşhis ve onarım sistemlerinin organize edilmesi gerekmektedir.

Bu nedenle yapılan modellemede bir şehir içi ulaşım firmasına ait olan 15 adet tramvay aracında 2019-2021 yılları arasında meydana gelmiş 603 adet arızanın tahmin işlemi gerçekleştirilmiştir. Belirtilen yıllar arasında meydana gelen arızaların başlangıç tarihi ve saati önem arz etmektedir. Modellemenin işlem çıktısı 591 adet gözlemden oluşmaktadır. Bunların %70'lik kısmı olan 414 adet gözlem eğitim kümesi, kalan %30'luk kısmı olan 177 adet gözlem ise test kümesi olarak belirlenmiştir. DVM regresyonu için çekirdek fonksiyonları arasında en az hata oranına sahip olan Polinom çekirdek seçilmiştir. Toplamda 603 olmak üzere 29 farklı arıza için tasarlanan DVR modeline ait 300 adet kombinasyon arasından en iyi parametrelerin seçilmesi sonucunda eğitim MAPE değeri 1.26843 , test MAPE değeri 1.65218 olarak bulunmuştur. Determinasyon katsayıları ise eğitim ve test değerleri için sırası ile 0.999727 ve 0.999628 olarak sonuçlandırılmıştır. Yapılan çalışma yalnızca hafif raylı sistem araçlarında değil işleyen bir sistemde arıza meydana gelen her alanda gerçekleştirilebilir. Benzer bir modelleme üretim, enerji iletimi ve dağıtımı, savunma sanayi, sağlık gibi sektörlerde yapılmaya elverişlidir.



## KAYNAKLAR

1. Karunanithi, N., Whitley, D., Malaiya, Y. K. (1992). Prediction of software reliability using connectionist models. *IEEE Transactions on Software Engineering*, 18, 563–74.
2. Dohi, T., Nishio, Y., Osaki, S. (1999). Optimal software release scheduling based on artificial neural networks. *Annals of Software Engineering*, 8, 167–85.
3. Cai, K. Y., Cai, L., Wang, W.D., Yu, Z.Y., Zhang, D. (2001). On the neural network approach in software reliability modeling. *Journal of Systems and Software*, 58, 47–62.
4. Ho, S.L., Xie, M., Goh, T.N. (2003). A study of the connectionist models for software reliability prediction. *Computers and mathematics with applications*, 46, 1037–45.
5. Tian, L., Noore, A. (2005). Evolutionary neural network modeling for software cumulative failure time prediction. *Reliability Engineering & System Safety*, 87, 45–51.
6. Tian, L., Noore, A. (2005). On-line prediction of software reliability using an evolutionary connectionist model. *Journal of Systems and Software*, 77, 173–80.
7. Hu, Q.P., Xie, M., Ng, S.H., Levitin, G. (2007). Robust recurrent neural network modeling for software fault detection and correction prediction. *Reliability Engineering & System Safety*, 92, 332–40.
8. Xu, K., Xie, M., Tang, L.C., Ho, S.L. (2003). Application of neural networks in forecasting engine systems reliability. *Applied Soft Computing*, 2, 255–68.
9. Su, C.T., Tong, L.I., Leou, C.M. (1997). Combining time series and neural network approaches. *Journal of the Chinese Institute of Industrial Engineers*, 4, 419–30.
10. Zio, E., Broggi, M., Golea, L., Pedroni, N. (2008). Failure and reliability predictions by infinite impulse response locally recurrent neural networks. In: *Proceedings of the ECCOMAS 5th European Congress on computational methods in applied science and engineering*. Venice, Italy.
11. Back, A.D., Tsoi, A.C. (1991). FIR and IIR synapses ,a new neural network architecture for time series modelling. *Neural Computation*, 3, 375–85.
12. Mercer, J. (1909). Functions of positive and negative type and their connection with the theory of integral equations, *Philosophical Transaction of the Royal Society of London, Series A, containing papers of a mathematical or physical character*, 209, 441-458, 415-446.
13. Smola, A.J., Schölkopf, B. (2004). A tutorial on support vector regression, *statist. Comput*, 14(1), 199-222.
14. Muller, K. R., Smola, A.J., G., Ratsch, B., Scholkopf, B. and Kohlmorgen, J. (1999). *Advances in Kernel Methods – Support Vector Learning*, 243–254. *Using support vector machines for time series prediction*. Cambridge, MA: MIT Press.

15. Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. New York: Springer Verlag.
16. Schölkopf, B. And Smola, A.J. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Cambridge, MA: MIT Press.
17. Secchi, P. , Zio, E., and Di Maio, F. (2008). “Quantifying Uncertainties in the Estimation of Safety Parameters by Using Bootstrap Artificial Neural Networks.” *Annals of Nuclear Energy* 35 (12): 2338–2350. doi:10.1016/j.anucene.2008.07.010.
18. Zio, E. (2006). “A Study of the Bootstrap Method for Estimating the Accuracy of Artificial Neural Networks in Predicting Nuclear Transient Processes.” *IEEE Transactions on Nuclear Science* 53 (3): 1460–1478. doi:10.1109/TNS.2006.871662.
19. Cristianini, N., and Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines: And Other Kernel-Based Learning Methods*. Cambridge University Press, Cambridge.
20. Haykin, S. (2001). *Neural Networks: A Comprehensive Foundation*. Pearson Education Publishing, Second Edition, India.
21. Jin, L., Lai, Y.J., Long, T.X. (2004). Peak load forecasting based on Robust regression. *In Proceedings of 8th International Conference on Probabilistic Methods Applied to Power Systems*, 123-128.
22. Boser, B.E., Guyon, I. M., Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers. *In Proceedings of the fifth annual workshop on Computational learning theory*, 144-152.
23. Smola, A.J. (1996). *Regression estimation with support vector learning machines*. Technische Universität, München.
24. Vapnik, V., Golowich, S., Smola, A. (1996). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing, *Neural Information Processing Systems*, 9, 281-287.
25. Akay, Ö., Tunçeli, M. (2021). Use of the Support Vector Regression in Medical Data Analysis. *Experimental and Applied Medical Science*, 2(4): 242-256.
26. Cherkassky, V. and Ma, Y. (2004), “Practical selection of SVM parameters and noise estimation for SVM regression,” *Neural Network*, vol. 17, pp. 113–126.
27. Fuller, W. (1996). *Introduction to statistical time series*. 2 ed. New York: John Wiley & Sons;.
28. Vapnik, V. N. (2000). *The nature of statistical learning theory*. 2 ed. New York: Springer-Verlag.
29. Kecman, V. (2005). Support vector machines - an introduction. *In: Wang L, editor. Support vector machines: theory and applications. Studies in fuzzy and soft computing*. Berlin Heidelberg, Springer-Verlag.

30. Schölkopf, B. and Smola, A.J. (1999). *Support Vector Machines and Kernel Algorithms*. MIT Press, Cambridge(MA).
31. Cristianini, N., Shawe-Taylor, J. (2000). *An introduction to support vector machines and other Kernel-based learning methods*. Cambridge University Press, Cambridge (UK).
32. Burges, C.J.C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining Knowledge Discovery*, 2 (2), 121- 167.
33. Kecman, V. (2001). *Learning and soft computing: Support vector machines, neural networks, and fuzzy logic models*. MIT Press, Cambridge, İngiltere.
34. Han, F., Wang, Z., Lei, M. and Zhou, Z. (2008). An Iterative Modified Kernel for Support Vector Regression, *IEEE Conference on Cybernetics and Intelligent Systems*, vol. 1-2, s. 1116-1121
35. Kecman, V. (2001). *Learning and Soft Computing: Support Vector Machines. Neural Networks and Fuzzy Logic Models*, MIT Press, Cambridge, Massachusetts.
36. Heckman, N. (1997). *The theory and application of penalized least squares methods or reproducing kernel hilbert spaces made easy*. University of British Columbia, Canada.
37. Smola, A.J. (1998). *Learning with Kernels, Ph.D. Dissertation, Department of Computer Science, Technical University, Berlin, Germany*.





*Gazili olmak ayrıcalıktır*