

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EN KÜÇÜK KARELER DESTEK VEKTÖR
MEKANİZMALARINI KULLANARAK DARBELER
ARASI ZAMAN ÖLÇÜMÜ İLE ELDE EDİLEN
KAOTİK ZAMAN SERİLERİNİN TAHMİNİ**

Halil ALPASLAN

Yüksek Lisans Tezi

DENİZLİ – 2005

**EN KÜÇÜK KARELER DESTEK VEKTÖR
MEKANİZMALARINI KULLANARAK DARBELER
ARASI ZAMAN ÖLÇÜMÜ İLE ELDE EDİLEN
KAOTİK ZAMAN SERİLERİNİN TAHMİNİ**

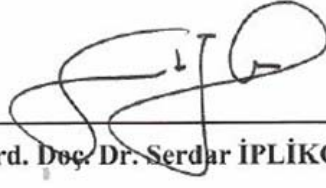
**Pamukkale Üniversitesi
Fen Bilimleri Enstitüsü
Taraından Kabul Edilen
Elektrik – Elektronik Mühendisliđi Anabilim Dalı
Yüksek Lisans Tezi**

Halil ALPASLAN

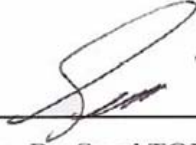
Tez Savunma Sınav Tarihi: 08.07.2005

TEZ SINAV SONUÇ FORMU

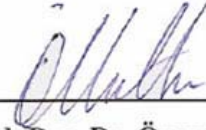
Bu tez tarafımızdan okunmuş, kapsamı ve niteliği açısından Yüksek Lisans Tezi olarak kabul edilmiştir.



Yrd. Doç. Dr. Serdar İPLİKÇİ
(Yönetici)



Yrd. Doç. Dr. Sezai TOKAT
(Jüri Üyesi)



Yrd. Doç. Dr. Özcan MUTLU
(Jüri Üyesi)

Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
..... tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Mehmet Ali SARIGÖL

Müdür

Fen Bilimleri Enstitüsü

TEŐEKKÜR

Yüksek Lisans Eğitim sürecim içerisinde bilgi, düşünce ve önerileri ile bana ışık tutan danışmanım sayın Yrd. Doç. Dr. Serdar İPLİKÇİ'ye en içten teşekkürlerimi sunarım.

Hayatım boyunca, gerek maddi gerekse manevi desteklerini esirgemeyen ve karşılaştığım zorlukları aşmamda tecrübeleri ile yol gösteren aileme sonsuz teşekkür ederim. Mesai arkadaşlarıma da ayrıca teşekkür ederim.

Halil ALPASLAN

ÖZET

Başlangıç koşulları bilinen gerekirci dinamik sistemlerin uzun dönem davranışlarını kestirebilir miyiz? Bu soruya, sistem kaotik ise Amerikan Meteorolojist Edward Lorenz'in bilimsel çalışmaları sonucunda bulunduğu ve *Kelebek Etkisi* olarak isimlendirilen düşünceye göre “*hayır*” cevabını verebiliriz. Kelebek Etkisi, kaotik davranışa yol açan en az bir pozitif Liapunov üstelden kaynaklanan başlangıç koşullarına hassas bağılılığı belirtir.

Bir kaotik sistemin matematiksel modelini kullanarak kısa dönem kestirim yapılabilmesine rağmen, pozitif Liapunov üstelden dolayı uzun dönem kestirim yapılamamaktadır.

Bu çalışmada, En Küçük Kareler Destek Vektör Mekanizmaları (LS-SVMs) ile integralini-al-ve-ateşle modeli kullanılarak elde edilen bazı sentetik kaotik ISI (Inter-Spike Interval) zaman serilerinin kısa dönem kestirimi uygulanması yapılmıştır. İncelenen Lorenz sistemi, Rössler sistemi ve Kimyasal sistem zaman aralığı 0.1 ms alınarak 4. dereceden Runga-Kutta metodu ile benzetim yapılmıştır. LS-SVM modelleri, bağlanım için tahmin kapasitelerinden dolayı kullanılır. Bunun yanı sıra tıp, ekonomi, mühendislik gibi farklı bilimsel alanlarda da sınıflandırma, örnek tanıma, kümeleme için kullanılabilir. LS-SVM yapısı ve onun ağırlıklı versiyonu olan WLS-SVM, Gausiyen ve Gausiyen olmayan gürültüye karşı dayanıklılıklarını test etmek amacıyla, gürültülü şartlar altında incelenmiştir.

Anahtar Kelimeler: Kaotik Zaman Serileri, Destek Vektör Mekanizmaları, Kaotik Zaman Serilerinin Tahmini

Halil ALPASLAN

ABSTRACT

Can we predict long-term future behavior of a deterministic dynamical system of which initial conditions are known exactly? If the system is chaotic, we can say “no” due to the so-called *Butterfly Effect* notion that was found at the end of the scientific studies of Edward Lorenz, an American meteorologist. The Butterfly Effect is the sign of the sensitive dependence on initial conditions stemming from at least one positive Lyapunov exponent that leads to the chaotic behavior.

Even though the governing mathematical model of a chaotic system enables us to predict short-term behavior, long-term behavior of the system is unpredictable due to positive Lyapunov exponent.

In this study, short-term prediction of some synthetic chaotic systems is carried out by using Least Squares Support Vector Machines (LS-SVMs) exploiting some time series inter-spike interval data gathered by integrate-and-fire model. Investigated systems namely Lorenz system, Rössler system and Chemical system are simulated by using 4th order Runge-Kutta method with a time step 0.1 msec. We use LS-SVM models for regression due to their approximation capability, which are also applicable in classification, pattern recognition, clustering in different areas such as medical science, engineering, economy etc. The LS-SVM structure and its weighted version WLS-SVM have both been investigated under noisy conditions in order to test their robustness against both Gaussian and non-Gaussian additive noise.

Keywords: Chaotic Time Series, Support Vector Machines, Chaotic Time Series Prediction

Halil ALPASLAN

İÇİNDEKİLER

	Sayfa
İçindekiler.....	VII
Şekiller Dizini.....	IX
Çizelgeler Dizini.....	XI
Simgeler Dizini.....	XII

Birinci Bölüm

GİRİŞ

1. GİRİŞ.....	1
1.1 Literatür Araştırması.....	4
1.2 Tezin Organizasyonu.....	8

İkinci Bölüm

PROBLEMİN TANIMI

2. PROBLEMİN TANIMI.....	9
2.1 Darbeler Arası Zaman Ölçümü.....	14
2.2 İleriye Yönelik Kestirim Problemi	16

Üçüncü Bölüm

EN KÜÇÜK KARELER DESTEK VEKTÖR

MEKANİZMASI

3. EN KÜÇÜK KARELER DESTEK VEKTÖR MEKANİZMASI	18
---	----

3.1 SVM ile Sınıflandırma	23
3.2 Destek Vektörleri ile Bağlanım	28
3.3 LS-SVM Sınıflandırıcı	32
3.4 Bağlanım için LS-SVM	34
3.5 WLS-SVM ve Bağlanım	36
3.6 Kümeleme	39

Dördüncü Bölüm

ÖRNEKLER VE BENZETİM SONUÇLARI

4. ÖRNEKLER VE BENZETİM SONUÇLARI	42
4.1 Lorenz Sistemi	44
4.2 Rössler Sistemi	52
4.3 Dört Boyutlu Kimyasal Sistem	60

Beşinci Bölüm

SONUÇLAR VE DEĞERLENDİRME

5. SONUÇLAR VE DEĞERLENDİRME	68
------------------------------------	----

KAYNAKLAR

Kaynaklar	72
-----------------	----

EKLER

EK-A	76
EK-B	79
Özgeçmiş	88

ŞEKİLLER DİZİNİ

Şekil 2.1 Liapunov üstelin hesaplanması (İplikçi, 2002)	12
Şekil 2.2 N boyutlu bir sistem	12
Şekil 2.3 Bir doğrultuda θ_{TH} eşik seviyelerini tek yönde geçiş zaman aralıkları ...	14
Şekil 2.4 İntegralini al-ve-Ateşle Modeli için zaman aralıklarının ölçümü	15
Şekil 2.5 Problem blok diyagramı	17
Şekil 3.1 R^n uzayından NU'ya Eşleme (M)	19
Şekil 3.2 İki sınıf sınıflandırıcılar	24
Şekil 3.3 En büyük mesafe hiperdüzlemi ve Destek Vektörleri.....	25
Şekil 3.4 Doğrusal bağlanım için ε -tolerans bandı	29
Şekil 3.5 Doğrusal olmayan bağlanım için ε -tolerans bandı	30
Şekil 3.6a Doğrusal ε -Tolerans Fonksiyonu.....	31
Şekil 3.6b Karesel ε -Tolerans Fonksiyonu	31
Şekil 3.7 Sınıflandırma Tipleri	39
Şekil 3.8 Bir kümeleme algoritması (İplikçi, 2002)	41
Şekil 4.1 Lorenz ISI zaman serisi	45
Şekil 4.2 Gürültüsüz Lorenz ISI için NPE değerleri	46
Şekil 4.3 Gausiyen gürültülü Lorenz ISI için en ideal NPE değerleri	47
Şekil 4.4 Gausiyen olmayan gürültülü Lorenz ISI için en ideal NPE değerleri.....	48
Şekil 4.5 Gürültüsüz Lorenz ISI için 1,5,10,15,20,40,100 adım NPE değerleri	49
Şekil 4.6 Gausiyen gürültülü Lorenz ISI için 1,5,10,15,20,40,100 adım NPE değerleri	50

Şekil 4.7	Gausiyen olmayan gürültülü Lorenz ISI için 1,5,10,20,40,100 adım NPE değerleri	51
Şekil 4.8	Rössler ISI zaman serisi	53
Şekil 4.9	Gürültüsüz Rössler ISI için NPE değerleri	54
Şekil 4.10	Gausiyen gürültülü Rössler ISI için en ideal NPE değerleri	55
Şekil 4.11	Gausiyen olmayan gürültülü Rössler ISI için en ideal NPE değerleri	56
Şekil 4.12	Gürültüsüz Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri	57
Şekil 4.13	Gausiyen gürültülü Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri	58
Şekil 4.14	Gausiyen olmayan gürültülü Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri	59
Şekil 4.15	CRS ISI zaman serisi	61
Şekil 4.16	Gürültüsüz CRS ISI için NPE değerleri	62
Şekil 4.17	Gausiyen gürültülü CRS ISI için en ideal NPE değerleri	63
Şekil 4.18	Gausiyen olmayan gürültülü CRS ISI için en ideal NPE değerleri	64
Şekil 4.19	Gürültüsüz CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri	65
Şekil 4.20	Gausiyen gürültülü CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri	66
Şekil 4.21	Gausiyen olmayan gürültülü CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri	67

ÇİZELGELER DİZİNİ

Çizelge 4.1	Gürültüsüz Lorenz ISI için LS-SVM hata değerleri	45
Çizelge 4.2	Gürültüsüz Lorenz ISI için WLS-SVM hata değerleri.....	45
Çizelge 4.3	Gausiyen gürültülü Lorenz ISI için LS-SVM hata değerleri	46
Çizelge 4.4	Gausiyen gürültülü Lorenz ISI için WLS-SVM hata değerleri.....	47
Çizelge 4.5	Gausiyen olmayan gürültülü Lorenz ISI için LS-SVM hata değerleri.	47
Çizelge 4.6	Gausiyen olmayan gürültülü Lorenz ISI için WLS-SVM hata değerleri	48
Çizelge 4.7	Gürültüsüz Rössler ISI için LS-SVM hata değerleri.....	53
Çizelge 4.8	Gürültüsüz Rössler ISI için WLS-SVM hata değerleri	53
Çizelge 4.9	Gausiyen gürültülü Rössler ISI için LS-SVM hata değerleri.....	54
Çizelge 4.10	Gausiyen gürültülü Rössler ISI için WLS-SVM hata değerleri.....	54
Çizelge 4.11	Gausiyen olmayan gürültülü Rössler ISI için LS-SVM hata değerleri	55
Çizelge 4.12	Gausiyen olmayan gürültülü Rössler ISI için WLS-SVM hata değerleri	56
Çizelge 4.13	Gürültüsüz CRS ISI için LS-SVM hata değerleri	61
Çizelge 4.14	Gürültüsüz CRS ISI için WLS-SVM hata değerleri	62
Çizelge 4.15	Gausiyen gürültülü CRS ISI için LS-SVM hata değerleri	62
Çizelge 4.16	Gausiyen gürültülü CRS ISI için WLS-SVM hata değerleri	63
Çizelge 4.17	Gausiyen olmayan gürültülü CRS ISI için LS-SVM hata değerleri	63
Çizelge 4.18	Gausiyen olmayan gürültülü CRS ISI için WLS-SVM hata değerleri.	64

SİMGELER DİZİNİ

t	Zaman
$\underline{x}(t)$	Sürekli zamanlı bir sistemin durum vektörü
\underline{z}_i	Ayrık zamanlı bir sistemin durum vektörü
$\underline{F}, \underline{\theta}, \underline{M}$	Eşleme (map)
\mathbf{R}^n	n boyutlu reel vektör uzayı
λ, λ_{\max}	Liapunov üstel, en büyük Liapunov üstel
d	İki nokta arasındaki uzaklık
N	Sistem boyutu
\mathbf{R}^N	N boyutlu dinamik sistemin durum uzayı
\mathbf{R}^m	Eşzamanlı ölçümler ile dinamik sistemden elde edilmiş verilerin oluşturduğu uzay (eş zamanlı ölçüm uzayı)
θ_{TH}	Genlik eşik seviyesi
θ_{FT}	Ateşleme eşik seviyesi
$\mathbf{S}(t)$	Ateşleme seviyeleri integral toplamı
T_i	Son ateşleme süresi
I	Darbeler arası aralık
$\underline{\mathbf{I}}_{zs}$	ISI Zaman serisi
φ	Kaydırma sabiti
$v(t)$	Giriş sinyali
\mathbf{R}	Reel vektör uzayı
\mathbf{NU}	Nitelik uzayı
u, v	Değişkenler
$\underline{\mathbf{u}}, \underline{\mathbf{v}}$	n boyutlu reel vektör uzayı içerisindeki değişkenlerin oluşturduğu vektör çiftleri
$\underline{\underline{\mathbf{J}}}, \underline{\underline{\mathbf{A}}}$	Katsayılar matrisleri
$\underline{\underline{\mathbf{H}}}$	Hessian matrisi, amaç fonksiyonu değişkenlerine göre ikinci dereceden türevlerin oluşturduğu matris

$\underline{\mathbf{f}}$	Fonksiyon çıkış vektörü
$\underline{\mathbf{w}}$	Ağırlık vektörü
$\mathbf{O}(\underline{\mathbf{w}}), \mathbf{D}(\underline{\mathbf{a}})$	Amaç fonksiyonları
$\mathbf{h}(\underline{\mathbf{w}})$	Eşitlik kısıtlama fonksiyonu
$\mathbf{g}(\underline{\mathbf{w}})$	Eşitsizlik kısıtlama fonksiyonu
\mathbf{L}	Lagrange fonksiyonu
$\underline{\mathbf{a}}, \underline{\mathbf{\beta}}$	Lagrange çarpanlarının oluşturduğu vektörler
b	Bias
S	Doğrusal dağılımlı eğitim kümesi
$\ \cdot \ $	Norm
$\langle \cdot \rangle$	İç çarpım
$\mathbf{K}(\underline{\mathbf{u}}, \underline{\mathbf{v}})$	Kernel fonksiyonu,
$\underline{\mathbf{x}}$	Sistem girişlerinin oluşturduğu vektör
y	Sistem çıkışı değerleri
g_s	Geometrik sınır
MMHD	En büyük mesafe hiperdüzleminin ikincil formdaki fonksiyonel ifadesi
ζ	Esneklik değişkeni
c	$\ \underline{\mathbf{w}}\ $ 'nin en iyi seçimine karşılık gelen bir parametre
SF	Sınır fonksiyonu
Gm	İkincil formda geometrik sınır fonksiyonu
ε	Hiperdüzleme en yakın verileri içerisine alabilecek hassasiyete sahip sınırları belirtmek için kullanılan bir parametre
\mathbf{f}_ε	ε doğruluğundaki tüm veri parçalarını gerçekleyen en uygun çözümü verecek fonksiyon
ξ, ξ^*	Gevşek değişkenler, hata değerlerini belirtmek için kullanılmıştır.
$ \xi _\varepsilon$	ε -toleranslı kayıp fonksiyonu
γ	LS-SVM için parametre
σ	Kernel fonksiyonu için parametre
\mathbf{I}	Birim matris
S_n	Kestirim yapılabilecek adım sayısı

v_k	Ağırlık faktörü
\hat{S}	Tahmini ağırlık değeri
MAD	Mutlak ortalama sapma fonksiyonu
EF_i	Uzam bilgisine dayalı geometrik fark fonksiyonu
MF_i	Mahalanobis fark fonksiyonu
Γ	Gömme boyutu
P_n	Prandtl sayısı
R	Reynolds sayısı

BİRİNCİ BÖLÜM

GİRİŞ

1. GİRİŞ

Başlangıç koşulları ve matematiksel modeli kesin olarak bilinen her sistemin gelecekteki davranışının kestirilebilir olduğu ilkesi uzun yıllar benimsenmiştir. Bu ilkenin doğru olup olmadığı, fizikteki basit sistemlerden birisi olan sarkaç sistemlerinin salınımı örneği ile incelenebilir. Sarkacın salınım yörüngesi, kesin fizik kanunları ile belirlenmiştir. Bu yörünge boyunca sarkaç sisteminin gelecekteki davranışı tespit edilebilir. Peki bu sarkaca salınım düzlemine dik bir titreşim yüklenirse yine sarkacın gelecekteki davranışı belirlenebilir mi? Yüklenen titreşimin etkisiyle, başlangıç koşullarının değiştiği, bu değişimden dolayı sarkaç yörüngesinde meydana gelen ani ve düzensiz değişimlerin oluşacağı düşünüldüğünde bu sorunun cevabının “hayır” olacağı söylenebilir.

Sarkaç yörüngesinde gözlenen bu değişimler, bilim adamlarını şu soruya cevap aramaya yönlendirmiştir; Sarkaç gibi basit bir sistemde başlangıç koşullarına olan duyarlılık ani ve düzensiz değişimlere yol açıyorsa, daha karmaşık sistemlerde başlangıç koşullarında meydana gelen küçük bir değişim nasıl bir etki yaratır?

Bu soruya cevap olarak, bir meteoroloji uzmanı olan Edward Lorenz’in 1961’de yaptığı araştırmalar sırasında bulduğu şu sonuç gösterilebilir :

Hava durumu başlangıç şartlarında meydana gelen küçük değişiklikler, hava akımları içerisinde bir kelebeğin kanat çırpması kadar önemsizken bir süre sonra kelebeğin kanat çırpışları büyük bir fırtınaya yol açabilir.

Edward Lorenz’in yaptığı araştırmalarda elde ettiği veriler doğrultusunda 1963’te Atmosferik Bilimler Dergisinde yayımladığı çalışması (Lorenz, 1963), yirminci yüzyıla damgasını vuracak olan deterministik sistemlerin belli bir düzen içindeki düzensiz,

öngörülemez davranışlarını inceleyen, başlangıç koşullarına ve sarsımlara (pertürbasyonlara) hassas bağıllık ve uzun dönem kestirilemezlik ilkelerine dayalı kaos teorisinin temeli olmuştur.

Suya damlatılan mürekkebin suda dağılışı, ağaç dalından düşen bir yaprağın düşme doğrultusu, kalbi saran sinirlerin oluşturduğu desen, kan dolaşım sistemi kaotik özellik gösteren sistemlere örnek olarak verilebilir.

Uzun dönem kestirilemezlik ilkesi, bilimcilerin araştırma konusu olmuştur. Geçmişten günümüze değin kaotik davranış sergileyen dinamik sistemlerin çıkışlarından alınan örnekler yardımıyla bu sistemler için ileriye yönelik kestirim ile ilgili çalışmalar yapılmış ve halen yapılmaktadır. Aşağıda kestirim metotları hakkında kısaca bilgi verilmiştir:

Nitel metotlar, kısmen veya tamamıyla var olmayan veriler için yapılacak olan ileriye yönelik kestirimlerde uzmanların fikirlerini kullanan metotlardır.

Nicel metotlar, geçmişe ait var olan verilerin analizi yapılarak bu analiz sonuçlarının kullanımı ile ileriye yönelik kestirimlerin yapılmasında sıkça kullanılan metotlardır. Zaman serileri ve nedenselliğe dayalı metotlar olmak üzere iki gruba ayrılırlar.

Tezin içeriği kaotik zaman serileri ile ilgili olduğu için, nicel kestirim metotları yüzeysel olarak aşağıda açıklanmıştır:

Nedenselliğe dayalı metotlar, başlangıçta tanımlanmış olan parametreler yardımıyla bir model oluşturulup bu model aracılığı ile diğer parametrik değerlerin kestiriminde kullanılan metotlardır.

Zaman serileri, giriş-çıkış ilişkisi bilinmeyen bir sistemin çıkış(lar)ının belirli zamanlarında gözlenmesiyle elde edilen her bir gözlem değerinin oluşturduğu veri kümeleridir. Zaman serilerinin elde edildiği sistemler, ekonomi, meteoroloji, tıp ve astronomi gibi çok farklı bilim alanlarından olabilir. Verilen zaman serisi tanımı göz

önünde bulundurulur, kaotik zaman serisi tanımı şu şekilde yapılabilir, kaotik davranış sergileyen dinamik sistemlerin çıkış(lar)ından belirli anlarda alınan sayısal örneklerin oluşturduğu veri kümeleridir.

Kaotik zaman serilerinin kestirimi uygulamalarında doğrusal fonksiyon yaklaşıklığı modeli, istatistiksel modeller ve doğrusal olmayan modeller kullanılmaktadır. Doğrusal fonksiyon yaklaşıklığı modeli kaotik zaman serilerinin ileriye yönelik kestirim uygulamalarında iyi bir kestirim performansı sergileyememektedir. Bundan dolayı doğrusal fonksiyon yaklaşıklığı modeli ve yapılan çalışma içeriği gereği kaotik zaman serilerinin ileriye yönelik kestirimi için kullanılan istatistiksel modeller incelenmeyecektir.

Kaotik zaman serilerinin ileriye yönelik kestirimi uygulamalarında kullanılan doğrusal olmayan modeller : Radyal Tabanlı Fonksiyon (RBF) Ağ modeli, Yapay Sinir Ağı modeli (NN), Bulanık Mantık (FL) Tabanlı modeller, Genetik Algoritma (GA) Tabanlı modeller, Filtre modeli gibi modellerdir

Genellikle istatistikçilerin yukarıda belirtilen modellerden bazıları ile kullandıkları ve gerekirci kaotik zaman serilerinin geçmişe ait verilerini kullanarak ileriye yönelik kısa dönem kestirimlerinde etkili kestirim metotlarından birisi en yakın komşuluk metodudur (Farmer ve Sidorowich, 1987). Bu metot konumuz dışında olduğu için açıklanmayacaktır.

Farmer ve Sidorowich'in (1987) yapmış olduğu bu çalışmanın arkasından; Mackey-Glass kaotik zaman serisi, kaotik Lorenz sistemi diferansiyel eşitliklerinden elde edilen zaman serisi ve Ikeda eşitliklerinden üretilmiş kaotik zaman serisi ele alınarak bu zaman serileri için, yerel kestirim tekniklerinden polinomik ve rasyonel kestirim teknikleri ile global kestirim tekniklerinden NN ve RBF tekniklerinin kısa dönem kestirim performansının karşılaştırıldığı bir çalışma yapılmıştır (Casdagli, 1989).

1.1 Literatür Araştırması

Casdagli'nin (1989) çalışması, kaotik zaman serilerinin kısa dönem kestirim uygulamaları için bir temel teşkil etmiştir. Bu çalışmaya paralel olarak tezin literatür araştırması sırasında kaotik zaman serilerinin ileriye yönelik kestirimi ile ilgili yapılmış çalışmalar aşağıdaki şekilde özetlenebilir:

Kuo ve arkadaşları, kaotik zaman serilerinin kestirimi için Periyodik NN Modeli önermiş ve geleneksel NN modeli ile hata ve performans açısından karşılaştırmışlardır (Kuo ve diğ., 1992).

1995 yılında, orijinali Edward Lorenz (1963) tarafından önerilen kestirim yöntemi değiştirilerek yeni bir metot önerilmiştir. Bu önerilen metot ile oluşturulan model ve Yerel Doğrusal Kestirim modeli, gürültü eklenmiş Henon, Ikeda kaotik zaman serileri için uygulanmış, iki modelin birbirlerine göre kestirim performansları karşılaştırılmıştır (Ikeguchi ve Aihara,1995).

Bir yıl sonra, Kaotik zaman serilerinin kestiriminde kullanılan RBF Modeli için Taşınmış (Relocating) - LMS algoritması önerilmiştir. Bu algoritma ile Uyarlanmış k-Ortalamalı Kümeleme ve Uyarlanmış En Yakın Komşu Sezgisel Algoritmaları, Mackey-Glass kaotik zaman serisi ve Lojistik eşleme fonksiyonu kullanılarak elde edilen kaotik zaman serisi için kestirim performansı açısından karşılaştırılmıştır (Saranlı ve Baykal,1996).

Yukarıda bahsedilen modellerin yanı sıra Brian S. Mulloy, Rick L. Riolo, Robert S. Sayit tarafından, J. R. Koza , Howard Oakley, ve Iba'nın Genetik Algoritma ile kaotik zaman serilerinin ileriye yönelik kestirimi ile ilgili hazırlanmış çalışmalar incelenmiş ve eğitim verilerinin ezberlenmesi üzerine bir çalışma yapılmıştır (Mulloy ve diğ., 1996).

Daha sonra, Yerel Doğrusal model, RBF modeli, NN Modeli ve Fonksiyonel Benzetim Ağacı modeli kaotik zaman serilerinin ileriye yönelik kestirim performansı açısından karşılaştırılmıştır. Bu çalışmada Lorenz kaotik zaman serisi ve Double-Scroll

diferansiyel eşitlikleri ile üretilmiş olan kaotik zaman serisi kullanılmıştır (Badel ve diğ., 1997).

Yine 1997 de, Tekli FL Sistem modeli ve Tekli Olmayan FL modeli ile Mackey-Glass kaotik zaman serisi için ileriye yönelik kestirim çalışması yapılmıştır. Mackey-Glass kaotik zaman serisi içerisine gürültü eklenerek bu iki modelin gürültüye karşı duyarlılıkları incelenmiştir (Mouzouris ve Mendel, 1997).

Aynı yıl, FL Tabanlı NN için Eğitici Çökme Algoritması kullanılarak bu modelin kestirim hatası ve performansı incelenmiştir. Bu çalışmada da Mackey-Glass kaotik zaman serisi kullanılmıştır (Studer ve Masulli, 1997).

Studer ve Masulli (1997) tarafından yapılan çalışmanın hemen arkasından, Farmer ve Sidorowich (1987) tarafından öne sürülen Yerel Doğrusal Kestirim modeli, Linsay (1991) tarafından öne sürülen Doğrusal İç Değer Kestirimi modeli, Navone ve Ceccatto (1995) tarafından öne sürülen Yerel Hiper-Düzlem Kestirim modeli kaotik zaman serilerinin ileriye yönelik kestirimi açısından analitik olarak incelenmiş ve performanslarının birbirine yakın değerler olduğu gözlemlenmiştir (Liu ve diğ., 1997).

Aynı yıl, Mukherjee ve çalışma arkadaşları tarafından; ilk defa 1995'te V. Vapnik tarafından iki veri kümesini sınıflandırılması amacıyla geliştirilmiş olan ve daha sonra fonksiyon yaklaşıklığı, kümeleme vb. uygulamalarda da kullanılmış Destek Vektör Mekanizması (SVM) ismi verilmiş model RBF ve NN modelleri ile kestirim hata performansı açısından karşılaştırılmıştır. Yapılan bu çalışmada Mackey-Glass, Ikeda ve Lorenz kaotik zaman serileri kullanılmıştır (Mukherjee ve diğ., 1997).

Mukherjee ve çalışma arkadaşlarının (1997) yaptığı çalışmadan bir yıl sonra, Angeline tarafından kaotik zaman serilerinin ileriye yönelik kestirimi için NN modeli, Genetik Programlama (GP) ve gelişmiş hesaplama tekniklerinin birleştirilmesi ile Çoklu Etkileşim Programı isimli bir metot geliştirilmiştir (Angeline, 1998).

Bir süre sonra, Oliveira ve çalışma arkadaşları tarafından kaotik zaman serilerinin ileriye yönelik kestirimi için İki-Katmanlı NN modeli kestirim hata performansı açısından incelenmiştir. Kaotik zaman serilerinin gömme boyutu ile Çok-Katmanlı Ağ Mimarisi arasında bir ilişkinin olduğu açıkça gösterilmiştir. Lorenz zaman serisi, Henon zaman serisi ve lojistik eşleme fonksiyonu ile üretilmiş kaotik zaman serisi kullanılmıştır (Oliveira ve diğ., 2000).

2000 yılında yapılmış olan bu çalışmadan bir yıl sonra, Leung ve çalışma arkadaşları tarafından gürültü eklenmiş kaotik zaman serilerinin ileriye yönelik kestiriminde Optimal RBF Ağı modeli oluşturabilmek için Çapraz-Denetimli Alt-uzayı metodu önerilmiştir (Leung ve diğ., 2001).

Bu metodun önerildiği yıllarda, Zhang ve Xiao tarafından Hiper-Kaotik zaman serilerinin ileriye yönelik kestiriminde kullanılabilecek, yüksek dereceli Volterra serisi tabanlı Uyarlanabilir Yüksek-Dereceli Doğrusal Olmayan Sonlu Darbe Cevap Filtresi modeli önerilmiş, bu filtre ile Geleneksel NN ve FL Tabanlı NN modelleri Mackey-Glass Hiper-Kaotik zaman serileri için hata performansı açısından karşılaştırılmıştır (Zhang ve Xiao, 2001).

Yukarıdaki çalışmadan bir yıl sonra, daha önce kaotik zaman serilerinin kestiriminde ilk defa Koza tarafından kullanılmış GA'ya ek olarak, Yen ve Lu tarafından, Hiyerarşik Genetik Algoritma (HGA) olarak adlandırılan yeni bir GA önerilmiştir. Bu algoritma hem NN hem de RBF modellerine uyarlanmıştır. Kaotik Mackey-Glass zaman serisi kullanılarak HGA Tabanlı Çok Katmanlı İleri-Beslemeli Yapay Sinir Ağı modeli ile HGA Tabanlı RBF modelleri kestirim hata performansı açısından karşılaştırılmıştır (Yen ve Lu, 2002).

HGA'nın önerildiği yıl, Cowper ve çalışma arkadaşları tarafından kaotik zaman serilerinin ileriye yönelik kestiriminde kullanılan RBF Ağı modeli için edilmiş Gaussian-Kernel Mimarisi önerilmiştir. Önerilmiş olan mimariye İleri-Geri Kestirim Metodu uyarlanmıştır. İleri-Geri Kestirim Metodu Tabanlı Düzgünleştirilmiş (normalize edilmiş) RBF Ağı modeli ve Düzgünleştirilmiş RBF Ağı modeli kaotik zaman serileri

içerisine eklenen gürültüye karşı duyarlılıkları, kestirim hata performansları açısından karşılaştırılmıştır (Cowper ve diğ., 2002).

Bu çalışmadan bir yıl sonra, Liu ve arkadaşları tarafından eğitim veri-kümesinin istatistiksel özellikleri ele alınarak rasgele olmayan hesaplamaların kullanıldığı Tablo Arama Düzeni Tabanlı Standart FL modelinde değişiklik yapılarak yeni bir kestirim modeli önerilmiştir. Bu model ile Standart FL modeli hata performansı açısından karşılaştırılmıştır. Mackey-Glass kaotik zaman serisi kullanılmıştır (Liu ve diğ., 2003).

Liu ve arkadaşları (2003) tarafından yeni bir modelin önerildiği yıl, Ke-Ping ve çalışma arkadaşları tarafından yeni bir teknik önerilmiştir: Kaotik zaman serilerinin ileriye yönelik kestirim performansı dinamik sistemlerin yerel Liapunov üstelleri ile ilişkilidir. Kestirim edilmiş noktanın komşuluğunda bulunan bazı noktalar, kullanılan deneysel veri aracılığıyla yerel dinamiklerin kestirim kabiliyetini büyük ölçüde sınırlar. Bu noktaların elenmesi, kestirim performansını artırır. Dinamik sistemin alabileceği tüm olası durumları içeren uzay içerisindeki en yakın yörüngeleri üstel olarak ayıran yerel Liapunov üstel, büyük olduğunda yörüngeden ayrılma hızlı olur. En yakın yörüngelerden ayrılma hızlı olduğu zaman bir sonraki sapma değeri büyük olur. Bu yapılan kestirim hatasının artmasına sebep olur. Kestirim hatasını küçültme amacıyla özellikle büyük yerel Liapunov üstelin yakın komşuluğunda yer alan noktaların atılması temeline dayalı bir kestirim işlemi yapılabilir (Ke-Ping ve diğ., 2003).

Ke-Ping ve arkadaşlarından bir yıl sonra, Mackey-Glass diferansiyel gecikme eşitliğine dördüncü dereceden Runge-Kutta algoritması uygulanarak üretilen zaman serisinin ileriye yönelik tek değer ve çok değer kestirimi için yeni bir teknik olan En Küçük Kareler Destek Vektör mekanizması (LS-SVM) kullanılmıştır. Bu mekanizma ile NN modeli kestirim hatası performansı açısından karşılaştırılmıştır (Mei-Ying ve Xiao-Dong, 2004).

Bu çalışmada; kaotik özellik sergileyen zaman serilerinin ileriye yönelik kestirim uygulamasında, istatistiksel öğrenme teorisi tabanlı bir öğrenme sistemi olan destek

vektör mekanizma çeşitlerinden LS-SVM ve bu mekanizmaların ağırlıklı versiyonu olan Ağırlıklı-LS-SVM (WLS-SVM) incelenmektedir.

1.2 Tezin Organizasyonu

Tez şu şekilde organize edilmiştir :

İkinci bölümde, problem detaylı olarak açıklanmış ve problemin daha iyi anlaşılabilmesi için ihtiyaç duyulabilecek kaos teorisinin temel kavramları anlatılmıştır.

Üçüncü bölümde, LS-SVM, WLS-SVM, kümeleme hakkında kısaca bilgi verilmiş ve uygulamada kullanılan kümeleme algoritması açıklanmıştır.

Dördüncü bölümde, ele alınan kaotik sistemler hakkında bilgi verilmiştir. LS-SVM ve WLS-SVM, elde edilen kaotik zaman serileri için ileriye yönelik kestirim açısından karşılaştırılmıştır.

Beşinci bölümde benzetim sonuçları değerlendirilmiş ve hazırlanan bu çalışmaya paralel olarak yapılabilecek çalışmalar önerilmiştir.

İKİNCİ BÖLÜM

PROBLEMİN TANIMI

2. PROBLEMİN TANIMI

Belli işlemleri yerine getirmek için bir araya gelmiş bileşenler ve bu bileşenler arasındaki ilişkiyi ifade eden fonksiyon veya fonksiyon grubu sistem olarak tanımlanmaktadır. Sistemler, statik sistemler ve dinamik sistemler olmak üzere iki ana gruba ayrılabilir.

Statik sistemler; nedensel ve hafızasız sistemlerdir. Belirli bir zamandaki sistem çıkışı, yalnızca o anki sistem girişine bağlı olup, önceki sistem girişlerinden bağımsızdır.

Dinamik sistemler, nedensel olabileceği gibi nedensel olmayabilen, bir hafızaya sahip, belirli bir zamandaki sistem çıkışı, o andan önceki sistem girişlerine ve sistem durumlarına bağımlı olan sistemlerdir. Bir dinamik sistemin durumu; bilinen veya verilmiş olan bir anda, yalnızca dinamik sistemin davranışını tanımlayan minimum bilgidir.

Dinamik sistemler şu şekilde gruplandırılabilir:

A- Toplu parametrelili dinamik sistemler

a. Rastlantısal sistemler

i. Ayrık sistemler

ii. Sürekli sistemler

- Doğrusal sistemler
- Doğrusal olmayan sistemler

b. Gerekirci (Deterministic) sistemler

i. Ayrık sistemler

ii. Sürekli sistemler

- Doğrusal sistemler
- Doğrusal olmayan sistemler

B- Dağılmış parametrelili dinamik sistemler

Toplu parametrelili sistemler; zamanla değişebilen uzaya bağlı değişim göstermeyen durum değişkenlerine sahip sistemlerdir.

Dağılmış parametrelili sistemler; zamanın ve uzayın her ikisine birden bağlı olarak değişim gösteren durum değişkenlerine sahip sistemlerdir.

Rastlantısal sistemler; üretilen herhangi bir değer belirlenmiş iki değer arasında kalma olasılığı söz konusu olduğu, yani bir belirsizliğin bulunduğu sistemlerdir, ve rastlantısal süreçlerle modellenabilirler.

Gerekirci sistemler; sistem parametreleri, durum değişkenleri ve zaman içeren diferansiyel denklem formlarında zamana göre durum değişkenlerinin değişim oranını veren kurallara göre geliştirilmiş, başlangıç durumu ve şartları biliniyorsa sonraki durumun belirlenebileceği sistemlerdir.

Sistemin matematiksel modeli, fark denklemleri ile ifade edilebiliyorsa ayrık sistem, diferansiyel denklemler ile ifade edilebiliyorsa sürekli sistemdir.

Bir sistem; toplamsallık ve çarpımsallık şartlarını sağlıyorsa doğrusal, sağlamıyorsa doğrusal olmayan bir sistemdir.

$\underline{x}(t)$, t anında sürekli zamanlı bir sistemin ve \underline{z}_i , i tekrar sonunda ayrık zamanlı sistemin durum vektörleri olmak üzere sürekli zamanlı dinamiklere sahip sistemler diferansiyel denklemler (denklem (2.1)) ile ayrık zamanlı dinamiklere sahip sistemler ise fark denklemleri (denklem (2.2)) ile temsil edilebilirler.

$$\dot{\underline{\mathbf{x}}}(t) = \underline{\mathbf{F}}(\underline{\mathbf{x}}(t)) \quad \underline{\mathbf{x}}(t) \in \mathbf{R}^n \quad (2.1)$$

$$\underline{\mathbf{z}}_{i+1} = \underline{\mathbf{T}}(\underline{\mathbf{z}}_i), \quad \underline{\mathbf{z}}_i \in \mathbf{R}^n \quad (2.2)$$

Başlangıç koşullarına ve sarsımlara hassas bağımlılık, periyodik çözümün olmaması, garip çekerlerin (strange attractors) varlığı gibi kendine has özelliklere sahip doğrusal olmayan dinamik sistemler kaotik sistemler olarak bilinir. Bu çalışmada incelenen kaotik sistemler (Lorenz, Rossler, Dördüncü Dereceden Kimyasal Reaksiyon), diferansiyel denklemler ile tanımlanmaktadır.


Bir dinamik sistemin alabileceği bütün mümkün durumların oluşturduğu kümeye durum uzayı ismi verilir. Bir eşleme (map); durum uzayı içerisinde sistemin sonraki durumunu, şu anki durumunun bir fonksiyonu gibi veren fonksiyon olarak düşünülebilir.

Sistem yörüngesi; durum uzayı içerisinde sistemin bulunabileceği herhangi bir nokta $\underline{\mathbf{x}}(t)$ ve bir eşleme $\underline{\mathbf{F}}$ olmak üzere, sistemin bir veya birden fazla $\underline{\mathbf{F}}$ eşlemi sonucu yer değiştirebileceği noktalar kümesidir $\{\underline{\mathbf{x}}(t), \underline{\mathbf{F}}^2(\underline{\mathbf{x}}(t)), \underline{\mathbf{F}}^3(\underline{\mathbf{x}}(t)), \dots\}$.

Kaotik yörünge, asimptotik periyodik olmayan sınır değerlerine sahip, kararsız davranış gösteren sürekli bir yörüngedir. Bu süreklilikteki kararsızlık, Liapunov üstelleri (λ) ve Liapunov sayıları ile belirtilir.

Kaotik yörünge için en az bir tane sıfırdan büyük λ mevcuttur (Alligood ve diğ., 1996). Pozitif bir λ , başlangıç durumuna hassas bağımlılık kaynağı gibi düşünülebilir. Sistem, boyutu kadar λ ya sahiptir.

Sistemin matematiksel modelinin bilinmediği durumlarda λ_{maks} . Şekil 2.1'e göre bulunur.



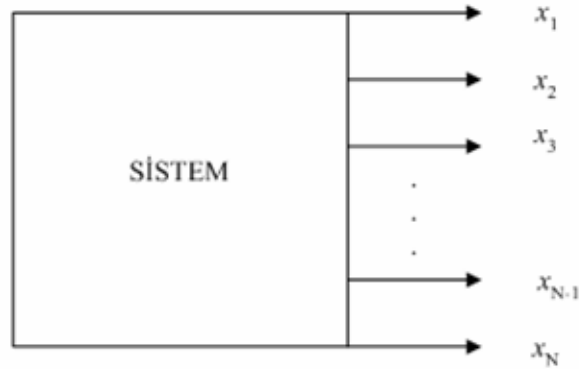
Şekil 2.1: Liapunov üstelin hesaplanması (İplikçi, 2002)

$i \geq 1$, tekrar sayısı (iterasyon), d_i , i tekrar sonunda iki nokta arasındaki uzaklık olmak üzere λ_{\max} 'ın hesabı denklem (2.5) de görülmektedir.

$$d_0 = ((x_0^b - x_0^a)^2 + (y_0^b - y_0^a)^2)^{1/2} \quad (2.3)$$

$$d_i = ((x_i^b - x_i^a)^2 + (y_i^b - y_i^a)^2)^{1/2} \quad (2.4)$$

$$Le_{\max} = \lim_{n \rightarrow \infty} \sum_{i=1}^n \ln\left(\frac{d_i}{d_0}\right) \quad (2.5)$$



Şekil 2.2: N boyutlu bir sistem

Kaotik sistemler için, genel diferansiyel denklem ifadesinde (2.1) verilmiş olan \underline{F} 'in bilindiği durumlarda sistem için ileriye yönelik kestirim kolayca yapılabilir.

\mathbf{F} 'in bilinmediği durumlarda ise ileriye yönelik kısa dönem kestirim yapabilmek amacıyla sistem üzerinde uzun süreli gözlem yapmak gerekir. Şekil 2.2'de görülen N boyutlu bir sistemin gözlemlenmesine ilişkin olası üç durum şu şekildedir:

1. Tüm durumlar ölçülebilmektedir.
2. Belirli bir büyüklük ölçülebilmektedir. Bu büyüklük sistem durumlarından birisi, birkaçı veya durumlarının doğrusal kombinasyonları olabilir.
3. Sadece büyüklüğü gerçekleştirme zamanları sırasında sistemin durum değişimi süreleri (darbeler arası zaman) ölçülebilmektedir. Nöronların dolma boşalma süreleri buna örnek verilebilir.

Sistem durumlarından birisi veya birkaçı ya da durumlarının doğrusal kombinasyonlarının ölçülebildiği düşünüldüğünde; 1936'da Whitney tarafından ortaya atılmış Whitney gömme (Embedding) teoreminden sonra öne sürülmüş Takens gömme teoreminden yararlanılmaktadır. Whitney gömme teoremine göre; \mathbf{R}^N , dinamik sistemin durum uzayı ve \mathbf{R}^m , eşzamanlı ölçümler ile dinamik sistemden elde edilmiş verilerin oluşturduğu uzay (m boyutlu) olmak üzere; \mathbf{R}^N durum uzayı içerisinde d_c -boyutlu bir veri kümesi ele alınmakta ve \mathbf{R}^N durum uzayından \mathbf{R}^m uzayına bir eşleme yapılmaktadır. Eğer $m > 2d_c$ ve $\Theta: \mathbf{R}^N \rightarrow \mathbf{R}^m$ genelleşmiş ise Θ , d_c -boyutlu veri kümesi üzerindeki veriler için birebir dağılım oluşturur.


Takens gömme teoremi ise Whitney teoremine ek olarak, eşleme fonksiyonunun zaman serilerini kullanmakta, ayrıca zaman gecikmeli koordinat yapısından oluşturulmuş eşleme fonksiyonlarının birleşimi olması gerektiğini vurgulamakta, aynı zamanda eğer $m \geq 2d_c$ olursa kaotik sistemlerin çekerlerinin topolojik özelliklerini koruyabileceklerini göstermektedir. Sistemin durumlarının ve doğrusal kombinasyonlarının hiçbirisinin ölçülemediği sadece ISI'ların ölçülebildiği düşünüldüğünde, sistemin sonraki davranışının ne olabileceğinin kestirilebilmesi için T.Sauer tarafından ortaya atılmış gömme teoreminden yararlanılmaktadır. Bu teorem Takens gömme teoreminin ISI versiyonudur (Alligood ve diğ., 1996, İplikçi, 2002).

2.1 Darbeler Arası Zaman Ölçümü

Darbeler arası zaman (ISI) ölçümü ile zaman serisi üretimi, Eşik-Geçiş Modeli veya İntegralini al-ve-Ateşle Modeli kullanılarak yapılır.

a) Eşik-Geçiş Modeli

Bir doğrultuda θ_{TH} eşik seviyelerini tek yönde geçiş zaman aralıkları ölçülür. Bu modelin işleyişi Şekil 2.3'te verilmiştir.




Şekil 2.3: Bir doğrultuda θ_{TH} eşik seviyelerini tek yönde geçiş zaman aralıkları

b) İntegralini al-ve-Ateşle Modeli

Bu model, özellikle biyolojik dinamik sistemlerin davranışlarını incelemek için kullanılmaktadır. Nöronların dolma ve boşalma sürelerinin ölçülmesi ile elde edilmiş olan giriş sinyalinin zamana bağlı integralinin alınması, bu integral toplamının eşik ateşleme seviyesine (θ_{FT}) eşitlenmesi ve eşik seviyesine eşit

olan zaman aralıklarının ölçülmesi yöntemi kullanıldığı için İntegralini al-ve-Ateşle modeli ismini almıştır.



Şekil 2.4: İntegralini al-ve-Ateşle Modeli için zaman aralıklarının ölçümü

Şekil 2.4'te zaman aralıklarının ölçümü verilmiş olan model şu şekildedir:

$$S(t) = \int_{T_i}^{T_{i+1}} v(t) dt \quad (2.6)$$

T_i, son ateşleme süresidir ve T_{i+1} > T_i dir. Bir darbe, nörona giren sinyalin zaman aralığı toplamı ateşleme seviyesi olarak bilinen sabit bir seviyeye ulaştığında, birikmiş olan mevcut potansiyel seviyenin denklem (2.7)'de görüldüğü gibi aniden sıfır değerine düşmesi ile oluşur

$$S(t): \theta_{FT} \rightarrow 0 \quad (2.7)$$

S(t)=0 olduğunda, bu integral baştan başlar. Darbeler arası aralık hesaplama formülü denklem (2.8)'de verilmiştir:

$$I=T_{i+1}-T_i \quad (2.8)$$

$v(t)$ giriş sinyali oluşturulurken, $x(t)$ durumuna bir φ sabiti eklenir. Bu sabit $v(t)$ 'nin pozitif olmasını sağlamak için eklenmiştir ve *kaydırma sabiti* olarak isimlendirilebilir.

$$v(t)=x(t)+\varphi \quad (2.9)$$

2.2 İleriye Yönelik Kestirim Problemi


Problem, sistem durumlarının ölçülemediği, sadece ISI'ların ölçülebildiği durumlarda sistem davranışının ileriye yönelik kısa dönem kestirimi olarak tanımlanabilir. Elimizde herhangi bir sisteme ait gerçek sistem çıkış verileri mevcut olmadığı için veriler, gerçek sistem yerine sentetik kaotik sistem diferansiyel denklemleri kullanılmak suretiyle belirli bir süre örnek alınarak elde edilmiştir. Bu verilerden yararlanarak kullanılan kaotik sistemin gelecekte nasıl bir davranış sergileyeceğinin anlaşılabilmesi için ileriye yönelik kısa dönem kestirim yapılmış, bu kestirim işleminin ne kadarlık bir hata ile doğru olduğu; kestirim işlemleri sonucu elde edilen veriler ile kaotik sistem için ölçülmüş ISI verileri karşılaştırılarak bulunmuştur.

Bunun için yapılan işlemler ve Şekil 2.5'de verilmiş blok diyagram kısaca şu şekilde özetlenebilir:

Zaman serisi verilerine düzgünleştirme (normalizasyon) işlemi uygulanmış, gecikmiş koordinat yapısı ile düzgünleştirilmiş veri gecikmeye uğratılmış, geciktirme sonucu elde edilmiş olan yeni veri kümesi üzerinde kümeleme işlemi yapılarak veri kümeleri oluşturulmuş, her bir veri kümesi için bir tane En Küçük Kareler Destek Vektör Mekanizması (LS-SVM) modeli kullanılmış, her bir LS-SVM modelinin çıkışından elde edilen veriler üzerine düzgünleştirme işleminin tersi işlem (denormalizasyon) uygulanarak bir sonraki sistem çıkışı elde edilmiştir.

Bu çıkış aynı zamanda geri besleme ile uygun kümeye giriş verisi gibi eklenerek daha sonraki sistem çıkışlarının elde edilmesinde kullanılmıştır.

Sistem parametrelerimiz, $\underline{\gamma}$ ve $\underline{\sigma}$ parametreleridir.



Şekil 2.5: Problem blok diyagramı

ÜÇÜNCÜ BÖLÜM

EN KÜÇÜK KARELER DESTEK VEKTÖR MEKANİZMASI


3. EN KÜÇÜK KARELER DESTEK VEKTÖR MEKANİZMASI

Destek vektör mekanizması (SVM), ilk defa Vladamir Vapnik ve arkadaşlarının iki gruplu sınıflandırma problemlerinin çözümü için öğrenme algoritmaları tabanlı model geliştirme çalışmaları sırasında öne sürülmüş ve tanıtılmıştır. Klasik öğrenme algoritma tabanlı Yapay Sinir Ağı sınıflandırıcı modeli, Radyal Tabanlı Fonksiyon sınıflandırıcı modeli ve polinomik sınıflandırıcı modeli ile hata performansı açısından karşılaştırılmış, SVM'lerin bu modellere göre daha düşük hata değeri ürettiği gözlemlenmiştir (Vapnik ve Cortes, 1995).

Vapnik ve arkadaşlarının bu çalışmasından kısa bir süre sonra, Suykens ve Vandewalle (1999) tarafından destek vektör mekanizma modeli üzerinde yeni düzenlemeler yapılmış ve günümüzde LS-SVM modeli ismi ile bilinen model geliştirilmiştir. Klasik SVM ile LS-SVM arasındaki farklar bölüm içerisinde belirtilecektir. Aşağıda, konunun daha iyi anlaşılabilmesi için gerekli olabilecek yardımcı bilgiler verilmiştir.

SVM; büyük boyutlu bir nitelik uzayı içerisindeki doğrusal fonksiyonların bir hipotez uzayını kullanan, optimizasyon (en iyileme) teorisi öğrenme algoritmaları ile eğitilen, istatistiksel öğrenme teorisi tabanlı sistemlerdir. *Nitelik uzayı (NU)*; reel vektör uzayı (\mathbf{R}) içerisindeki her bir elemana karşılık gelen niteliklerin oluşturduğu kümedir.

Doğrusal dağılım sergilemeyen verilere sahip bir uzay içerisinde matematiksel işlemler yapmanın, doğrusal dağılım sergileyen verilere sahip bir uzay içerisinde matematiksel işlemler yapmaktan daha zor olduğu düşünüldüğünde, Şekil 3.1 de görülen biçimde bir eşleme (\mathbf{M}), \mathbf{R}^n uzayında doğrusal dağılım sergilemeyen verilere karşılık gelen nitelikler, *NU* içerisinde doğrusal dağılım sergiledikleri için yapılır. Yapılan eşleme ise doğrusal değildir.



Şekil 3.1: R^n uzayından NU 'ya Eşleme (M)

Hipotez; NU içerisindeki, her bir niteliğe karşılık gelen çıkış değerleri ile nitelikler arasındaki matematiksel ilişkiyi belirten fonksiyondur.

Hipotez Uzayı; Hipotezlerin oluşturmuş olduğu veri kümesidir.

İç çarpım; $\forall \underline{u}, \underline{v} \in R^n$ vektör çiftine, $\langle \underline{u}, \underline{v} \rangle$ reel sayısı karşılık gelmektedir. $\langle \cdot, \cdot \rangle$ fonksiyonu aşağıdaki şartları sağlıyorsa bu fonksiyon R^n üzerinde bir iç çarpımdır. i ve j reel sayılar olmak üzere:

1. $\langle (i\underline{u}_1 + j\underline{u}_2), \underline{v} \rangle = i\langle \underline{u}_1, \underline{v} \rangle + j\langle \underline{u}_2, \underline{v} \rangle$, doğrusallık özelliği
2. $\langle \underline{u}, \underline{v} \rangle = \langle \underline{v}, \underline{u} \rangle$, simetri özelliği
3. $\langle \underline{u}, \underline{u} \rangle \geq 0$ ve $\langle \underline{u}, \underline{u} \rangle = 0 \Leftrightarrow \underline{u} = 0$, pozitif tanımlılık

Kernel; giriş uzayındaki verilere nitelik uzayında karşılık gelen veriler arasındaki iç çarpım fonksiyonudur (3.1a). Bu çalışmada Mercer şartları (Cristianini ve Shawe-Taylor, 2000) olarak bilinen, pozitif tanımlılık ve simetriklik özelliklerini gösteren Kernel fonksiyonlarından Radyal Tabanlı Kernel fonksiyonu (3.1b) kullanılmıştır.

$\underline{u}, \underline{v} \in \mathbf{R}^n$ olmak üzere;

$$\mathbf{K}(\underline{u}, \underline{v}) = \langle \mathbf{M}(\underline{u}), \mathbf{M}(\underline{v}) \rangle \quad (3.1a)$$

$$\mathbf{K}(\underline{u}, \underline{v}) = e^{-\left(\frac{\|\underline{u}-\underline{v}\|}{\sigma^2}\right)} \quad (3.1b)$$

Hiperdüzlem; $i_1 u_1 + i_2 u_2 + \dots + i_n u_n = v$ doğrusal denklemini sağlayan $(u_1, u_2, u_3, \dots, u_n)$ noktalarının kümesidir.

Asıl ve İkil Problem; İkil problem, asıl problemin çaprazı olarak düşünülebilir. denklem (3.2)'de bir en büyükleme problemi ve bu probleme karşılık gelen ikil problem, en küçükleme problemi denklem (3.3)'de görülmektedir (Venkataraman 2001). \underline{u} , asıl problemin \underline{v} ise ikil problemin değişkenleridir. i, j ve k değişken katsayılarıdır.

Asıl Form:

$$\text{Amaç fonk. } i_1 u_1 + i_2 u_2 + \dots + i_r u_r \quad (3.2)$$

$$\begin{aligned} \text{Kısıtlar} \quad & j_{11} u_1 + j_{12} u_2 + \dots + j_{1r} u_r \leq k_1 \\ & j_{21} u_1 + j_{22} u_2 + \dots + j_{2r} u_r \leq k_2 \\ & \cdot \\ & \cdot \\ & j_{p1} u_1 + j_{p2} u_2 + \dots + j_{pr} u_r \leq k_p \\ & \forall u_i \geq 0 \end{aligned}$$

İkil Form:

$$\text{Amaç fonk. } k_1 v_1 + k_2 v_2 + \dots + k_p v_p \quad (3.3)$$

$$\begin{aligned} \text{Kısıtlar} \quad & j_{11} v_1 + j_{21} v_2 + \dots + j_{p1} v_p \geq i_1 \\ & j_{12} v_1 + j_{22} v_2 + \dots + j_{p2} v_p \geq i_2 \\ & \cdot \\ & \cdot \\ & j_{1r} v_1 + j_{2r} v_2 + \dots + j_{pr} v_p \geq i_r \\ & \forall v_i \geq 0 \end{aligned}$$

Asıl problem ve ikil problem karşılaştırıldığında şu özellikler görülebilir:

- İkil problemin amaç fonksiyonundaki değişken sayısı (p), asıl problemin kısıt sayısına eşittir.
- İkil problemin kısıt sayısı, asıl problemin amaç fonksiyonundaki değişken sayısına (r) eşittir.
- Asıl problemin kısıtlarındaki değişkenlerin katsayılarının oluşturduğu katsayılar matrisi ($\underline{\underline{\mathbf{J}}}$), ikil problemin kısıtlarındaki değişkenlerin oluşturduğu katsayılar matrisinin transpozuna eşittir.
- Asıl problemden ikil probleme dönüşümde eşitsizlik yönleri değişmiştir.
- Asıl problemde verilmiş olan en büyükleme problemi (denklem (3.2)), ikil problemde en küçükleme problemine (denklem (3.3)) dönüşmüştür.

Karesel (Quadratic) Programlama; denklem (3.4) görüldüğü gibi doğrusal kısıtlara sahip fakat doğrusal olmayan matrissel formda ikinci dereceden bir fonksiyonun en küçüklemesini yapan bir programlamadır.

$$\text{Amaç fonk. } \frac{1}{2} \underline{\underline{\mathbf{u}}} \underline{\underline{\mathbf{H}}} \underline{\underline{\mathbf{u}}} + \underline{\underline{\mathbf{f}}} \underline{\underline{\mathbf{u}}} \quad (3.4)$$

$$\text{Kısıtlar} \quad \underline{\underline{\mathbf{A}}} \underline{\underline{\mathbf{u}}} \leq \underline{\underline{\mathbf{b}}}$$

$$u_{\min} \leq \forall u \in \underline{\underline{\mathbf{u}}} = \begin{bmatrix} u_1 \\ u_2 \\ \cdot \\ u_r \end{bmatrix} \leq u_{\max.}$$

Değişkenlerin oluşturduğu vektörü $\underline{\underline{\mathbf{u}}}$, değişkenlerin katsayılarının oluşturduğu katsayılar matrisini $\underline{\underline{\mathbf{A}}}$, fonksiyonun ikinci dereceden türevlerinin oluşturduğu matrisi $\underline{\underline{\mathbf{H}}}$, fonksiyon çıkış vektörünü $\underline{\underline{\mathbf{f}}}$, eşitsizlik kısıtlarında eşitsizliğin sağ tarafında kalan sayıların oluşturduğu vektörü $\underline{\underline{\mathbf{b}}}$, değişkenlerin alabileceği en küçük değer sınırını u_{\min} , değişkenlerin alabileceği en büyük değer sınırını $u_{\max.}$ belirtmektedir.

Fermat teorisi, $\mathbf{O}(\underline{\mathbf{w}})$, amaç fonksiyonunu en küçük yapan $\underline{\mathbf{w}}^*$ için gerek şart, $\frac{\partial \mathbf{O}(\underline{\mathbf{w}})}{\partial \mathbf{w}} = 0$ dır. Bu şart aynı zamanda amaç fonksiyonunun iç bükeyliği ile ilgili olan yeter şarttır (Cristianini ve Shawe-Taylor, 2000).

Lagrange Teorisi, eşitsizlik kısıtları olmadığı zaman başlangıç en iyileme probleminin çözümünü karakterize eder. Bu teorinin ana kavramları, Lagrange fonksiyonu ve Lagrange çarpanlarıdır. Bu metot, mekanik problemlerin çözümü için 1797 de Lagrange tarafından geliştirilmiştir (Cristianini ve Shawe-Taylor, 2000).

Amaç fonksiyonu $\mathbf{O}(\underline{\mathbf{w}})$ ve eşitlik kısıtları $\mathbf{h}_k(\underline{\mathbf{w}}) = 0$, Lagrange çarpanı β_k olmak üzere, amaç fonksiyonu için Lagrange fonksiyonu denklem (3.6)'daki gibi tanımlanır.

$$\mathbf{L}(\underline{\mathbf{w}}, \underline{\beta}) = \mathbf{O}(\underline{\mathbf{w}}) + \sum_{k=1}^p \beta_k \mathbf{h}_k(\underline{\mathbf{w}}) \quad (3.5)$$

Kuhn-Tucker teoremi; Lagrange teorisine ek olarak eşitsizlik kısıtlarını da kabul eder ve Lagrange teorisi ile Fermat teorisini birleştirir (Cristianini ve Shawe-Taylor 2000).

İç bükey en iyileme probleminin asıl formu:

$$\text{Amaç fonk. } \mathbf{O}(\underline{\mathbf{w}}) \quad (3.6)$$

$$\begin{aligned} \text{Kısıtlar} \quad & \mathbf{g}_l(\underline{\mathbf{w}}) \leq 0 \\ & \mathbf{h}_k(\underline{\mathbf{w}}) = 0 \\ & k = 1, 2, 3, \dots, p \\ & l = 1, 2, 3, \dots, r \end{aligned}$$

Genelleştirilmiş Lagrange fonksiyonu denklem (3.7)'deki gibi yazılabilir.

$$\mathbf{L}(\underline{\mathbf{w}}, \underline{\alpha}, \underline{\beta}) = \mathbf{O}(\underline{\mathbf{w}}) + \sum_{l=1}^r \alpha_l \mathbf{g}_l(\underline{\mathbf{w}}) + \sum_{k=1}^p \beta_k \mathbf{h}_k(\underline{\mathbf{w}}) \quad (3.7)$$

İç bükey en iyileme probleminin en iyi çözüm değerlerini ($\underline{\mathbf{w}}^*$, $\underline{\boldsymbol{\alpha}}^*$, $\underline{\boldsymbol{\beta}}^*$) bulabilmek için gerek ve yeter şartlar (3.8)'deki denklemlerde görülmektedir.

$$\begin{aligned}
\frac{\partial \mathbf{L}(\underline{\mathbf{w}}^*, \underline{\boldsymbol{\alpha}}^*, \underline{\boldsymbol{\beta}}^*)}{\partial \mathbf{w}} &= 0 \\
\frac{\partial \mathbf{L}(\underline{\mathbf{w}}^*, \underline{\boldsymbol{\alpha}}^*, \underline{\boldsymbol{\beta}}^*)}{\partial \boldsymbol{\beta}} &= 0 \\
\alpha_k \mathbf{g}_k(\underline{\mathbf{w}}^*) &= 0 \\
\mathbf{g}_k(\underline{\mathbf{w}}^*) &\leq 0 \\
\alpha_k^* &\geq 0, k=1, 2, \dots, n
\end{aligned} \tag{3.8}$$

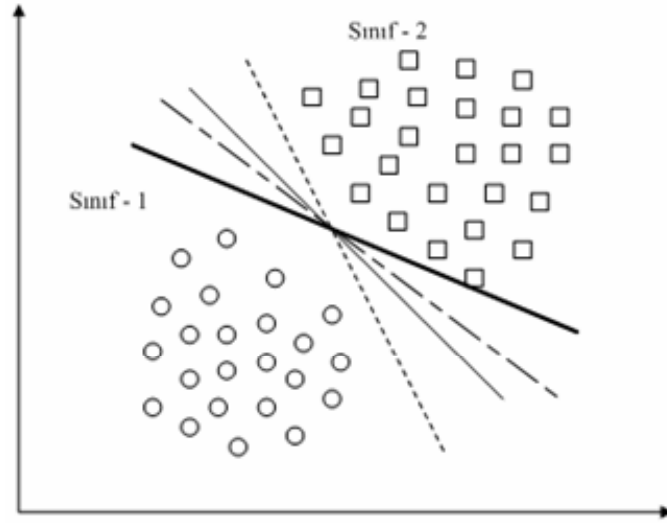
3.1 SVM ile Sınıflandırma:

Sınıflandırma problemi, iki-sınıf problemi ele alınarak incelenebilir. Bu problemdeki amaç, var olan verileri bir fonksiyonla iki sınıfa ayırmaktır. Bu fonksiyon, eldeki verileri sınıflandıran bir sınıflandırıcı görevi üstlenir.

Şekil 3.2'de görüldüğü gibi var olan verileri iki sınıfa ayırabilecek birden fazla doğrusal sınıflandırıcı üretilebilir.

SVM sınıflandırıcılarının en basit modeli, En Büyük Mesafe Sınıflandırıcı (MMC) modelidir. Bu model yalnızca veri kümeleri, nitelik uzayı içerisinde doğrusal olarak dağılmış ise sınıflandırma işlemini yapabilir.

MMC modeli, seçilmiş uygun bir kernel içerikli NU uzayı içerisinde en büyük mesafe hiperdüzleminin bulunması sonucu bu ismi almıştır. Bu model stratejisi, doğrusal eşitsizlik kısıtları altında karesel bir fonksiyonun üreteceği hatanın azaltılarak en küçük değere indirilebilmesi düşünülerek kullanılmıştır.



Şekil 3.2: İki sınıf sınıflandırıcılar

Doğrusal dağılımlı eğitim kümesi, $S = \{ (\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n) \}$ olmak üzere, geometrik sınırlı en büyük mesafe hiperdüzlemi ile çözülebilecek en iyileme problemi şu şekilde yazılabilir:

$$\text{Amaç fonk. } \langle \mathbf{w}, \mathbf{w} \rangle \quad (3.9)$$

$$\begin{aligned} \text{Kısıtlar} \quad y_k (\langle \mathbf{w}, \mathbf{x}_k \rangle + b) &\geq 1 \\ k &= 1, 2, \dots, n \end{aligned}$$

Verilmiş olan en iyileme probleminin çözümünde kullanılan en büyük mesafe hiperdüzlemi için geometrik sınır hesabı denklem (3.10b)'de verilmiştir.

$$\gamma = \frac{1}{2} \left(\langle \frac{\mathbf{w}}{\|\mathbf{w}\|}, \mathbf{x}^+ \rangle - \langle \frac{\mathbf{w}}{\|\mathbf{w}\|}, \mathbf{x}^- \rangle \right) \quad (3.10a)$$

$$\gamma = \frac{1}{2\|\mathbf{w}\|} (\langle \mathbf{w}, \mathbf{x}^+ \rangle - \langle \mathbf{w}, \mathbf{x}^- \rangle) = \frac{1}{\|\mathbf{w}\|} \quad (3.10b)$$

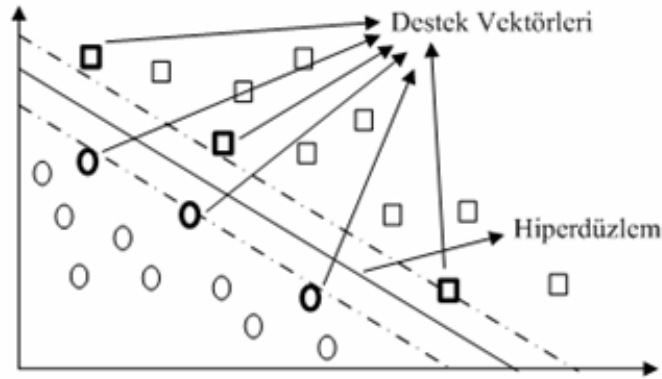
En iyileme problemi, bir sınıflandırma problemi olduğu için kanonik hiperdüzlem olarak bilinen bazı fonksiyonel sınırlı hiperdüzlemler ± 1 'e eşitlenir.

$$\begin{aligned} \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}^+ \rangle + b &= +1 \\ \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}^- \rangle + b &= -1 \end{aligned} \quad (3.11)$$

Denklem (3.9)'da verilmiş olan en iyileme problemi bir eşitsizlik kısıtı içerdiği için asıl formda bu problemin çözümü kolay değildir. Çözümü kolaylaştırmak için eşitsizlik kısıtları eşitlik kısıtlarına dönüştürülerek ikil forma geçiş yapılmalıdır.

En büyük mesafe hiperdüzlemi fonksiyonunun (MMHD) ikil formdaki fonksiyonel ifadesi denklem (3.12)'de verilmiştir:

$$\text{MMHD}(\underline{\mathbf{x}}, \underline{\alpha}^*, b^*) = \sum_{k=1}^n y_k \alpha_k^* \langle \underline{\mathbf{x}}_k \cdot \underline{\mathbf{x}} \rangle + b^* \quad (3.12)$$



Şekil 3.3: En büyük mesafe hiperdüzlemi ve Destek Vektörleri

Şekil 3.3'ten görüleceği gibi, sınıflandırılacak veriler içerisinde en büyük mesafe hiperdüzlemine en yakın veriler destek vektörleri olarak kabul edilmektedir. Diğer bir ifade ile, sınıflandırma probleminin Karesel Programlama ile çözümü sonucu elde edilen α_k^* parametrelerinin sıfırdan büyük değerlerine denk düşen veri noktaları destek vektörleridir. $\alpha_k^* = 0$ çözümünü veren noktaların, sınıflandırma işleminde $\alpha_k^* > 0$ noktaları kadar etkileri yoktur.

MMC modeli, önemli ve uygulaması basit bir model olmasına rağmen çoğu problemin çözümünde, özellikle veri kümesine gürültü eklenmişse kullanılamaz. Bunun sebebi, veri kümesine gürültü eklendiği zaman başlangıçta NU uzayı içerisinde doğrusal bir dağılım sergileyen verilerin doğrusal olmayan bir dağılım sergileyebilmeleridir.

NU uzayı içerisinde veri kümesi dağılımı doğrusal değilse Esnek Mesafe Sınıflandırıcı (SMC) modeli kullanılır. Bu model, norm sayısı $normn$ olmak üzere MMC modeli denklem (3.13)'de görüldüğü gibi en iyileme problemi içerisindeki değişkenlere bir *esneklik değişkeni* (ζ) eklenmesi ile elde edilir.

$$\text{Amaç fonk. } \langle \underline{\mathbf{w}}, \underline{\mathbf{w}} \rangle + C \sum_{k=1}^n \|\zeta_k\|^{normn} \quad (3.13)$$

$$\begin{aligned} \text{Kısıtlar} \quad y_k (\langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b) &\geq 1 - \zeta_k \\ \zeta_k &\geq 0, k=1, 2, \dots, n \end{aligned}$$

SMC modeli için verilmiş olan en iyileme problemindeki C parametresi, $\|\underline{\mathbf{w}}\|$ 'nin en iyi seçimine karşılık gelen bir parametredir. C 'nin değeri, $\|\underline{\mathbf{w}}\|$ değerinin verilmesiyle $\|\zeta\|$ 'nin en küçük değerini bulmak için kullanılacak olan en uygun sınırı verir.

SMC modeli,

- 1-Norm esnek mesafe sınıflandırıcısı
- 2-Norm esnek mesafe sınıflandırıcısı

olmak üzere iki gruba ayrılır.

1-Norm SMC için karesel en iyileme probleminin asıl formu (3.14a)'da ve ikil formu (3.14b)'de verilmiştir.

$$\text{Amaç fonk. } \frac{1}{2} \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{w}} \rangle + c \sum_{k=1}^n \zeta_k \quad (3.14a)$$

$$\begin{aligned} \text{Kısıtlar} \quad y_k (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}} \rangle + b) &\geq 1 - \zeta_k \\ \zeta_k &\geq 0, \quad k=1, 2, \dots, n \end{aligned}$$

$$\text{Amaç fonk. } \mathbf{D}(\underline{\alpha}) = \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,l=1}^n y_k y_l \alpha_k \alpha_l \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}_l) \quad (3.14b)$$

$$\begin{aligned} \text{Kısıtlar} \quad \sum_{k=1}^n y_k \alpha_k &= 0 \\ c \geq \alpha_k \geq 0, k &= 1, 2, \dots, n \end{aligned}$$

2-Norm SMC için karesel en iyileme probleminin asıl formu denklem (3.15a)'da ve ikil formu denklem (3.15b)'de verilmiştir.

$$\text{Amaç fonk. } \frac{1}{2} \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{w}} \rangle + c \sum_{k=1}^n \zeta_k^2 \quad (3.15a)$$

$$\begin{aligned} \text{Kısıtlar} \quad y_k (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}} \rangle + b) &\geq 1 - \zeta_k \\ \zeta_k &\geq 0, \quad k=1, 2, \dots, n \end{aligned}$$

$$\text{Amaç fonk. } \mathbf{D}(\underline{\alpha}) = \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,l=1}^n y_k y_l \alpha_k \alpha_l (\mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}_l) + \frac{1}{c} \delta_{kl}) \quad (3.15b)$$

$$\begin{aligned} \text{Kısıtlar} \quad \sum_{k=1}^n y_k \alpha_k &= 0 \\ \alpha_k &\geq 0, k = 1, 2, \dots, n \end{aligned}$$

1-Norm ve 2-Norm esnek mesafe sınıflandırıcıları için sınır fonksiyonu denklem (3.16)'da görülmektedir.

$$\mathbf{SF} = \sum_{k=1}^n y_k \alpha_k^* \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) + b^* \quad (3.16)$$

1-Norm SMC için denklem (3.17)'de ve 2-Norm SMC için denklem (3.18)'de geometrik sınır fonksiyonları verilmiştir.

$$\mathbf{Gm} = \left(\sum_{k,l \in SV} y_k y_l \alpha_k^* \alpha_l^* \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}_l) \right)^{-1/2} \quad (3.17)$$

$$\mathbf{Gm} = \left(\sum_{k \in SV} \alpha_k^* - \frac{1}{c} \langle \underline{\mathbf{a}}^*, \underline{\mathbf{a}}^* \rangle \right) \quad (3.18)$$

3.2 Destek Vektörleri ile Bağlanım (Regression, Regresyon)

Bağlanım, bir veri kümesi içerisindeki giriş verileri ve çıkış verileri arasında fonksiyonel bir ilişkinin bulunması olarak tanımlanabilir.

Sınıflandırmada, kullanılan veri kümesi içerisinde yer alan çıkış değerleri ayrık ve asıl formda verilmiş olan en iyileme probleminde eşitsizlik kısıtlaması denklem (3.9)'da görüldüğü gibi 1 değeri ile sınırlandırılıyordu. Bağlanımda ise, çıkış değerleri artık ayrık olmayacak, asıl formda verilmiş olan en iyileme problemindeki eşitsizlik kısıtları, en uygun hiperdüzleme en yakın verileri içerisine alabilecek hassasiyete sahip sınırları belirtmek için ε -toleransı ifadesi ile sınırlandırılacaktır.

Bağlanım için iç bükey en iyileme problemi denklem (3.19)'da verilmiştir.

$$\text{Amaç fonk. } \frac{1}{2} \|\underline{\mathbf{w}}\|^2 \quad (3.19)$$

$$\begin{aligned} \text{Kısıtlar} \quad & \langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b - y_k \leq \varepsilon \\ & k = 1, 2, \dots, n \end{aligned}$$

\mathbf{f}_ε , denklem (3.19)'da verilmiş olan en iyileme problemi için, ε doğruluğundaki tüm veri parçalarını gerçekleyen en uygun çözümü verecek bir fonksiyondur. Bazen bu mümkün olmamakla birlikte bazı hatalar kabul edilmektedir. Bu hatalar, ζ , ζ^* gevşek

değişkenleri ile belirtilecektir. Bu hata değerleri eklendiği zaman fonksiyon, esnek mesafe hata fonksiyonu olarak isimlendirilmektedir.


Hata değişkenleri ifade edildiğinde en iyileme problemi (3.20)'deki forma dönüşür.

$$\text{Amaç fonk.} \quad \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + c \sum_{k=1}^n (\xi_k + \xi_k^*) \quad (3.20)$$


$$\text{Kısıtlar} \quad \begin{aligned} y_k - \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle - b &\leq \varepsilon + \xi \\ \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b - y_k &\leq \varepsilon + \xi^* \end{aligned} \quad \xi_k, \xi_k^* \geq 0, k = 1, 2, 3, \dots, n$$

ε -toleranslı kayıp fonksiyonu $|\zeta|_\varepsilon$ aşağıda tanımlanmıştır:

$$|\zeta|_\varepsilon = \begin{cases} 0 & \text{eğer } |\zeta| \leq \varepsilon \\ |\zeta| - \varepsilon & \text{diğer durumlar} \end{cases} \quad (3.21)$$



Şekil 3.4: Doğrusal bağlanım için ε -tolerans bandı



Şekil 3.5: Doğrusal olmayan bağlanım için ε -tolerans bandı

a) Doğrusal ε -Tolerans Kayıp Fonksiyonu:

Denklem (3.20)'de asıl formda verilmiş olan en iyileme probleminde görüldüğü gibi kayıp fonksiyon (ζ), doğrusal bir fonksiyondur.

Bu doğrusal fonksiyon Şekil 3.4'te görülmektedir. Denklem (3.20)'deki en iyileme probleminin ikil formu denklem (3.22)'de görülmektedir.

Amaç fonk.
$$\mathbf{D}(\underline{\alpha}) = \sum_{k=1}^n y_k \alpha_k - \varepsilon \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,l=1}^n \alpha_k \alpha_l \langle \underline{\mathbf{x}}_k \cdot \underline{\mathbf{x}}_l \rangle$$

(3.22)

Kısıtlar
$$\sum_{k=1}^n \alpha_k = 0$$

$$-c \leq \alpha_k \leq c$$

$$k = 1, 2, \dots, n$$

b) Karesel ε -Tolerans Kayıp Fonksiyonu:

Şekil 3.5’de verilmiş doğrusal olmayan ε -Tolerans kayıp fonksiyonu, karesel kayıp fonksiyonu (ξ_k^2) içermektedir. En iyileme probleminin asıl formu aşağıda verilmiştir:


$$\text{Amaç fonk.} \quad \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + c \sum_{k=1}^n (\xi_k^2 + \xi_k^{*2}) \quad (3.23)$$

$$\begin{aligned} \text{Kısıtlar} \quad & (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b) - y_k \leq \varepsilon + \xi_k \\ & y_k - (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b) \leq \varepsilon + \xi_k^* \\ & \xi_k, \xi_k^* \geq 0, k = 1, 2, \dots, n \end{aligned}$$

Denklem (3.23)’de verilmiş olan en iyileme probleminin ikil formda karşılığı olan problem denklem (3.24)’de verilmiştir.

$$\text{Amaç fonk.} \quad \mathbf{D}(\underline{\alpha}) = \sum_{k=1}^n y_k \alpha_k - \varepsilon \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,l=1}^n \alpha_k \alpha_l (\langle \underline{\mathbf{x}}_k \cdot \underline{\mathbf{x}}_l \rangle + \frac{1}{c} \delta_{kl}) \quad (3.24)$$

$$\text{Kısıtlar} \quad \sum_{k=1}^n \alpha_k = 0, \alpha_k \geq 0, k = 1, 2, \dots, n$$



**Şekil 3.6: (a) Doğrusal ε -Tolerans Fonksiyonu,
(b) Karesel ε -Tolerans Fonksiyonu**

MMC, SMC, Doğrusal ε -Tolerans Kayıp Fonksiyon ve Karesel ε -Tolerans Kayıp Fonksiyon Bağlanım en iyileme problemlerinin ikil formlarının çözümünde karesel programlama yöntemi kullanılmaktadır. Karesel programlama, küçük veri kümelerinin sınıflandırılması ve bu veri kümeleri için bağlanım uygulamalarında iyi bir performans sergilemektedir. Ancak büyük veri kümelerinin sınıflandırılması ve bağlanım uygulamalarında problemin çözümü çok daha fazla zaman almaktadır.

Karesel programlamanın büyük veri kümeleri için düşük performans sergilemesi, veri sınıflandırma ve bağlanım ile ilgili çalışma yapan bilimcileri, bağlanım ve sınıflandırma problemlerinin çözümünde karesel programlamadan daha iyi performans sergileyebilecek yeni modeller geliştirme arayışına itmiştir. Bu arayış içerisinde farklı modeller geliştirilmiştir. Bu modellerden birisi LS-SVM modelidir.

3.3 LS-SVM Sınıflandırıcısı

Denklem (3.25)'te görüldüğü gibi bu sınıflandırıcı mekanizmasında, en iyileme problemindeki eşitsizlik kısıtları eşitlik kısıtları ile yer değiştirilmiş, hataların karelerinin toplamı ifadesi Ridge bağlanımına benzetilmiştir.

$$\text{Amaç fonk. } \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \gamma \frac{1}{2} \sum_{k=1}^n \xi_k^2 \quad (3.25)$$

$$\text{Kısıtlar} \quad y_k \cdot (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b) = 1 - \xi_k, k=1,2,\dots,n$$

Denklem (3.25)'e karşılık gelen Lagrange fonksiyonu denklem (3.26)'da verilmiştir.

$$L(\underline{\mathbf{w}}, \underline{\mathbf{a}}, \underline{\xi}, \gamma) = \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \gamma \frac{1}{2} \sum_{k=1}^n \xi_k^2 - \sum_{k=1}^n \alpha_k (y_k (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b) - 1 + \xi_k) \quad (3.26)$$

$$\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle = \underline{\mathbf{w}}^T \mathbf{M}(\underline{\mathbf{x}}_k) = \underline{\mathbf{w}}^T \underline{\mathbf{M}}_k \quad (3.27)$$

Denklem (3.27)'de görüldüğü gibi $\underline{\mathbf{M}}_k$ vektörü her bir $\underline{\mathbf{x}}_k$ vektörünün \mathbf{M} eşlemi sonucu elde edilmektedir. Denklem (3.26)'ya Kuhn-Tucker en uygunluk şartları uygulanırsa (3.28)'deki denklemler elde edilir.

$$\frac{\partial \mathbf{L}}{\partial \underline{\mathbf{w}}} = 0 \rightarrow \underline{\mathbf{w}} = \sum_{k=1}^n \alpha_k y_k \underline{\mathbf{M}}_k \quad (3.28)$$

$$\frac{\partial \mathbf{L}}{\partial b} = 0 \rightarrow \sum_{k=1}^n \alpha_k y_k = 0$$

$$\frac{\partial \mathbf{L}}{\partial \xi_k} = 0 \rightarrow \alpha_k = \gamma \xi_k$$

$$\frac{\partial \mathbf{L}}{\partial \alpha_k} = 0 \rightarrow y_k (\underline{\mathbf{w}}^T \underline{\mathbf{M}}_k + b) - 1 + \xi_k = 0, k=1, 2, \dots, n$$

(3.28)'deki denklemler matris formuna dönüştürülerek doğrusal denklem sistemi çözümleri formunda yazılabilir.

$$\begin{bmatrix} \underline{\mathbf{I}} & \underline{\mathbf{0}} & \underline{\mathbf{0}} & -\underline{\mathbf{Z}}^T \\ \underline{\mathbf{0}}^T & 0 & \underline{\mathbf{0}}^T & -\underline{\mathbf{y}}^T \\ \underline{\mathbf{0}} & \underline{\mathbf{0}} & \gamma \underline{\mathbf{I}} & -\underline{\mathbf{I}} \\ \underline{\mathbf{Z}} & \underline{\mathbf{y}} & \underline{\mathbf{I}} & \underline{\mathbf{0}} \end{bmatrix} \begin{bmatrix} \underline{\mathbf{w}} \\ b \\ \underline{\xi} \\ \underline{\alpha} \end{bmatrix} = \begin{bmatrix} \underline{\mathbf{0}} \\ 0 \\ \underline{\mathbf{0}} \\ \underline{\mathbf{1}} \end{bmatrix} \quad (3.29a)$$

$$\underline{\underline{\mathbf{Z}}} = [\mathbf{M}(\underline{\mathbf{x}}_1)^T y_1; \dots; \mathbf{M}(\underline{\mathbf{x}}_n)^T y_n] = \begin{bmatrix} Z_{11} & Z_{12} & \dots & Z_{1n} \\ Z_{21} & Z_{22} & \dots & Z_{2n} \\ \vdots & \vdots & \dots & \vdots \\ Z_{n1} & Z_{n2} & \dots & Z_{nn} \end{bmatrix}_{n \times n} \quad (3.29b)$$

$$\underline{\underline{\mathbf{0}}} = \begin{bmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}_{n \times n} \quad (3.29c)$$

$$\underline{\mathbf{0}} = [0; 0; \dots; 0]_{n \times 1} \quad (3.29d)$$

$$\underline{\mathbf{y}} = [y_1; y_2; \dots; y_n]_{n \times 1} \quad (3.29e)$$

$$\underline{\underline{\xi}} = [\xi_1; \xi_2; \dots; \xi_n]_{n \times 1} \quad (3.29f)$$

$$\underline{\alpha} = [\alpha_1; \alpha_2; \dots; \alpha_n]_{n \times 1} \quad (3.29g)$$

(3.29a)'da görülen matris sadeleştirildiğinde (3.30a)'daki matris oluşur.

$$\begin{bmatrix} 0 & -\underline{y}^T \\ \underline{y} & \underline{\underline{Z}}\underline{\underline{Z}}^T + \gamma^{-1}\underline{\underline{I}} \end{bmatrix} \begin{bmatrix} b \\ \underline{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \underline{\mathbf{1}} \end{bmatrix} \quad (3.30a)$$

$$\underline{\underline{Z}}\underline{\underline{Z}}^T = \sum_{k,l=1}^n y_k y_l \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}_l) \quad (3.30b)$$

$$k, l = 1, 2, 3, \dots, n$$

Sadeleştirilmiş matris formunun (3.30a) çözülmesi ile $\underline{\alpha}$ ve b parametreleri bulunur. Daha sonra bu parametreler denklem (3.31)'de yerine yazılarak herhangi bir $\underline{\mathbf{x}}_k$ vektörü için sonuç değeri bulunur.

$$y(x) = \text{sign}\left(\sum_{k=1}^n \alpha_k y_k \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) + b\right) \quad (3.31)$$

3.4 Bağlanım için LS-SVM

$S = \{(\underline{\mathbf{x}}_1, y_1), (\underline{\mathbf{x}}_2, y_2), \dots, (\underline{\mathbf{x}}_n, y_n)\}$ ile verilen bir eğitim kümesi için $\underline{\mathbf{x}}_k \in \mathbf{R}^n$, $y_k \in \mathbf{R}$, $k=0, 1, 2, \dots, n$ olmak üzere, asıl formda en iyileme problemi (3.32) denklemindeki gibi yazılır.

$$\text{Amaç fonk. } \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \frac{1}{2} \gamma \sum_{k=1}^n \xi_k^2 \quad (3.32)$$

$$\text{Kısıtlar} \quad y_k = \langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b + \xi_k, k = 1, 2, \dots, n$$

Asıl formda verilmiş olan en küçükleme problemine karşılık gelen Lagrange fonksiyonu denklem (3.33)'te verilmiştir:

$$\mathbf{L}(\underline{\mathbf{w}}, \underline{\mathbf{a}}, \underline{\xi}, \gamma, b) = \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \frac{1}{2} \gamma \sum_{k=1}^N \xi_k^2 - \sum_{k=1}^N \alpha_k (\langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b + \xi_k - y_k) \quad (3.33)$$

Kuhn-Tucker en uygunluk şartları uygulandığında (3.34)'teki denklemler elde edilir.

$$\frac{\partial \mathbf{L}}{\partial \underline{\mathbf{w}}} = 0 \rightarrow \underline{\mathbf{w}} = \sum_{k=1}^n \alpha_k \mathbf{M}(\underline{\mathbf{x}}_k) \quad (3.34)$$

$$\frac{\partial \mathbf{L}}{\partial b} = 0 \rightarrow \sum_{k=1}^n \alpha_k = 0$$

$$\frac{\partial \mathbf{L}}{\partial \xi_k} = 0 \rightarrow \gamma \xi_k = \alpha_k$$

$$\frac{\partial \mathbf{L}}{\partial \alpha} = 0 \rightarrow \langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b + \xi_k - y_k = 0$$

$$k = 1, 2, \dots, n$$

(3.34)'teki denklemler matris formuna dönüştürüldüğünde (3.35a)'daki matris elde edilir.

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \underline{\mathbf{a}} \end{bmatrix} = \begin{bmatrix} 0 \\ \underline{\mathbf{y}} \end{bmatrix} \quad (3.35a)$$

$$\underline{\underline{\mathbf{K}}} = \begin{bmatrix} K_{11} & K_{12} & \dots & K_{1n} \\ K_{21} & K_{22} & \dots & K_{2n} \\ \vdots & \vdots & \dots & \vdots \\ K_{n1} & K_{n2} & \dots & K_{nn} \end{bmatrix}_{n \times n} = \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) \quad (3.35b)$$

$$\underline{\underline{\mathbf{I}}} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}_{n \times n} \quad (3.35c)$$

$$\underline{\mathbf{y}} = [y_1; y_2; \dots; y_n]_{n \times 1} \quad (3.35d)$$

$$\underline{\mathbf{1}} = [1; 1; \dots; 1]_{n \times 1} \quad (3.35e)$$

$$\underline{\mathbf{a}} = [\alpha_1; \alpha_2; \dots; \alpha_n]_{n \times 1} \quad (3.35f)$$

(3.35a)'da verilmiş matris çözüldüğünde $\underline{\alpha}$ ve b parametre değerleri bulunur ve bu değerler sonuç fonksiyonunda (denklem (3.36)) yerine yazılır.

$$\mathbf{y}(x) = \sum_{k=1}^n \alpha_k \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) + b \quad (3.36)$$

LS-SVM modeli, Gauss gürültü içeren veri kümeleri için bağlanım açısından çok iyi performans sergileyememektedir. Bağlanım performansını arttırabilmek için model üzerinde bazı değişiklikler yapılmış ve WLS-SVM geliştirilmiştir (Suykens ve diğ., 2002).

3.5 WLS-SVM ve Bağlanım

Ağırlık faktörü v_k olmak üzere, en iyileme problemi denklem (3.37)'deki gibi yazılır.

$$\text{Amaç fonk. } \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \frac{1}{2} \gamma \sum_{k=1}^n v_k \xi_k^2 \quad (3.37)$$

$$\text{Kısıtlama} \quad \begin{aligned} y_k &= \langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b + \xi_k \\ k &= 1, 2, \dots, n \end{aligned}$$

Denklem (3.37)'de asıl formda verilmiş olan en iyileme probleminin Lagrange formu denklem (3.38)'de verilmiştir.

$$\mathbf{L}(\underline{\mathbf{w}}, \underline{\alpha}, \xi_k, \gamma, b) = \frac{1}{2} \|\underline{\mathbf{w}}\|^2 + \frac{1}{2} \gamma \sum_{k=1}^n v_k \xi_k^2 - \sum_{k=1}^n \alpha_k (\langle \underline{\mathbf{w}} \cdot \underline{\mathbf{x}}_k \rangle + b + \xi_k - y_k) \quad (3.38)$$

(3.38)'deki fonksiyona Kuhn-Tucker en uygunluk şartları uygulandığında (3.39)'daki denklemler elde edilir.

$$\frac{\partial \mathbf{L}}{\partial \mathbf{w}} = 0 \rightarrow \underline{\mathbf{w}} = \sum_{k=1}^n \alpha_k \mathbf{M}(\underline{\mathbf{x}}_k) \quad (3.39)$$

$$\frac{\partial \mathbf{L}}{\partial b} = 0 \rightarrow \sum_{k=1}^n \alpha_k = 0$$

$$\frac{\partial \mathbf{L}}{\partial \xi_k} = 0 \rightarrow \gamma v_k \xi_k = \alpha_k$$

$$\frac{\partial \mathbf{L}}{\partial \alpha} = 0 \rightarrow \langle \underline{\mathbf{w}}, \underline{\mathbf{x}}_k \rangle + b + \xi_k - y_k = 0, k = 1, 2, \dots, n$$

(3.39)'daki denklemler kullanılarak (3.40a)'daki matris formu elde edilir.

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) + \underline{\mathbf{v}} \end{bmatrix} \begin{bmatrix} b \\ \underline{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \underline{\mathbf{y}} \end{bmatrix} \quad (3.40a)$$

$$\underline{\mathbf{K}} = \begin{bmatrix} K_{11} & K_{12} & \dots & K_{1n} \\ K_{21} & K_{22} & \dots & K_{2n} \\ \vdots & \vdots & \dots & \vdots \\ K_{n1} & K_{n2} & \dots & K_{nn} \end{bmatrix}_{n \times n} = \mathbf{K}(\underline{\mathbf{x}}_k, \underline{\mathbf{x}}) \quad (3.40b)$$

$$\underline{\mathbf{y}} = [y_1; y_2; \dots; y_n]_{n \times 1} \quad (3.40c)$$

$$\mathbf{1} = [1; 1; \dots; 1]_{n \times 1} \quad (3.40d)$$

$$\underline{\alpha} = [\alpha_1; \alpha_2; \dots; \alpha_n]_{n \times 1} \quad (3.40e)$$

(3.40a)'daki matris formunda kullanılan $\underline{\mathbf{v}}$ matrisi (3.42b)'de ve her bir $\underline{\mathbf{x}}_k$ ya karşılık gelen v_k için seçim kriterleri denklem (3.41)'de verilmiştir.

$$v_k = \begin{cases} 1 & \text{eğer } |\xi_k / \hat{S}| \leq c_1 \\ \frac{c_2 - |\xi_k / \hat{S}|}{c_2 - c_1} & \text{eğer } c_1 \leq |\xi_k / \hat{S}| \leq c_2 \\ 10^{-4} & \text{diğerleri için} \end{cases} \quad (3.41)$$

$$\underline{\mathbf{v}} = \text{diagonal} \left\{ \frac{1}{\gamma v_1}, \frac{1}{\gamma v_2}, \dots, \frac{1}{\gamma v_k} \right\}, \quad k = 1, 2, \dots, n \quad (3.42a)$$

$$\underline{\mathbf{v}} = \begin{bmatrix} \frac{1}{\gamma v_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\gamma v_2} & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \frac{1}{\gamma v_n} \end{bmatrix}_{n \times n} \quad (3.42b)$$

\hat{S} , standart LS-SVM deki ζ hata değışkenlerinin standart sapmasının tahmini ağırlık değeridir. \hat{S} değerini bulmak için mutlak ortalama sapma algoritmasından (MAD) yararlanılır. Bu algoritma şu şekilde tanımlanabilir:

- $\underline{\mathbf{x}}_k$ vektörünün ortalamasını ($\bar{\underline{\mathbf{x}}}_k$) al.
- $\underline{\mathbf{x}}_k$ vektöründen $\bar{\underline{\mathbf{x}}}_k$ değeri çıkar. Fark vektörünün mutlak değeri al:

$$|\underline{\mathbf{x}}_k - \bar{\underline{\mathbf{x}}}_k| \quad (3.43)$$
- Fark vektörünün mutlak değeri alındıktan sonra elde edilen vektörün ortalamasını al.

\hat{S} değeri, MAD algoritması sonucu elde edilen değer ile 1.483 sabit sayısı çarpılması sonucu elde edilir. Bu çarpım denklem (3.44)'de görölmektedir.

$$\hat{S} = 1.483 \mathbf{MAD}(\underline{\mathbf{x}}_k) \quad (3.44)$$


Bu çalışmada c_1 ve c_2 değeri tipik olarak $c_1=2.5$, $c_2=3$ olarak seçilmiştir.

3.6 Kümeleme

Bir küme, birbirine benzeyen ve benzemeyen nesnelerin oluşturduğu topluluk içerisinde, birbirine benzeyen nesnelerin bir araya getirilmesi ile oluşmuş veri topluluğudur. Veri kümeleri farklı şekil ve boyutlarda olabilir.

Birbirine benzeyen veri kümeleri için fonksiyonel tanımlama kolayca yapılabilir ancak işlemsel tanımlama yapmak kolay değildir. Bunun nedeni, bir küme içerisine dahil edilen nesnelerin farklı amaçlar için o küme içerisinde yer alabilmeleridir.

Birbirine benzeyen ve benzemeyen verilerin oluşturduğu topluluk içerisinde, birbirine benzeyen verileri tespit edip bu verileri diğer verilerden ayırma ve bu verilerden yeni veri kümesi oluşturma işlemi *kümeleme* olarak tanımlanabilir. Aynı zamanda, kümeleme özel bir sınıflandırma çeşididir.



Şekil 3.7: Sınıflandırma Tipleri

Verilmiş olan tanımdan kümelemenin amacının birbirine benzeyen nesnelerin bulunması olduğu anlaşılmaktadır. Tüm kümeleme işlemlerinin temeli, aynı nitelik uzayı içerisindeki iki nesne arasındaki mesafenin bulunmasıdır. İki nesne arasındaki mesafenin bulunması işlemi şu yollar ile yapılabilir :

Uzam bilgisine dayalı (Euclidian) geometrik fark (EF_i); sezgisel bir görünüme sahiptir. İki veya üç boyutlu uzayda yer alan nesnelerin birbirlerine olan yakınlığını değerlendirmek için kullanılır.

Mahalanobis fark (MF_i); Uzam bilgisine dayalı geometrik fark gibi nesnelerin birbirine olan yakınlığını değerlendirmek için kullanılır. Hesaplanmasında, incelenecek veriler arasındaki bağımlılık ilişkisini veren kovaryans katsayı matrisine ihtiyaç duyar.

Veri matrisi $\underline{\underline{X}}$, bu veri matrisinin boyutu $n \times p$ olsun. Nesne sayısı n , değişken sayısı p , kovaryans katsayı matrisi $\underline{\underline{C}}_x$ ve $\underline{\underline{X}}$ matrisinin ortalama değer vektörü $\bar{\underline{x}}$ olmak üzere, $\underline{\underline{X}}$ matrisinin i . satır vektörü için uzam bilgisine dayalı geometrik fark denklem (3.45) ve Mahalanobis fark denklem (3.46)'daki gibi hesaplanır (Maesschalck ve diğ., 2000).

$$EF_i = \sqrt{(\underline{x}_i - \bar{\underline{x}})(\underline{x}_i - \bar{\underline{x}})'} \quad i = 1, 2, \dots, n \quad (3.45)$$

$$MF_i = \sqrt{(\underline{x}_i - \bar{\underline{x}})\underline{\underline{C}}_x^{-1}(\underline{x}_i - \bar{\underline{x}})'} \quad i = 1, 2, \dots, n \quad (3.46)$$

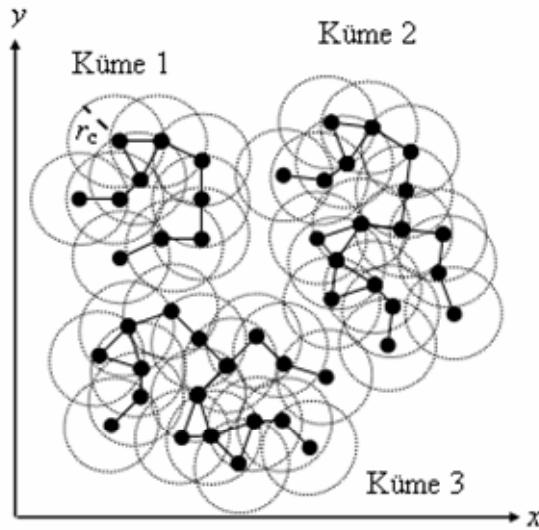
Uzam bilgisine dayalı geometrik fark ve/veya Mahalanobis fark hesaplamalarını kullanan farklı kümeleme algoritmaları geliştirilmiştir.

Bu çalışmada kullanılan kümeleme algoritması şu şekildedir:

- Her bir veri için r_c yarıçaplı bir daire çizilir. Rasgele bir veri seçilir. Başlangıçta kaç küme oluşacağı kesin olarak bilinmemekle beraber ilk seçilen veri birinci kümeymiş gibi kabul edilerek bütün veriler taranır.

Veriler arası mesafe Mahalanobis fark denklemi ile hesaplanır ve $0 \leq \mathbf{MF}_i \leq r_c$ aralığında kalan veriler birleştirilerek ilk kümeye dahil edilir.

- İlk veri haricinde birinci kümeye dahil edilmiş ikinci bir veri seçilir ve birinci şıktaki işlemler tekrarlanır. Bu veri içinde $0 \leq \mathbf{MF}_i \leq r_c$ şartı geçerlidir. Bu şartı sağlayan her bir veri ilk kümeye dahil edilir. $\mathbf{MF}_i > r_c$ mesafede olan veri diğer bir küme olarak kabul edilir ancak bu veri ilk küme içerisindeki diğer verilere $0 \leq \mathbf{MF}_i \leq r_c$ mesafede ise ilk seçilen kümeye dahil edilir. Birinci küme içerisindeki tüm veriler için $\mathbf{MF}_i > r_c$ şartını sağlayan her bir veri diğer bir kümeymiş gibi görülür. Bu işlemler kullanılmayan veri kalmayınca kadar devam eder (Şekil 3.8).



Şekil 3.8: Bir kümeleme algoritması (İplikçi, 2002)

DÖRDÜNCÜ BÖLÜM

ÖRNEKLER VE BENZETİM SONUÇLARI

4. ÖRNEKLER VE BENZETİM SONUÇLARI

Bu çalışmada, sistemlerin benzetiminde 4. dereceden Runga Kutta benzetim yöntemi ve kullanılan verilerin elde edilmesinde İntegralini-al-ve-Ateşle modeli kullanılmıştır. Runga Kutta benzetim yönteminde zaman adım aralığı (Δt), tüm sistemler için 0.0001 alınmıştır. ISI verilerinin ileriye yönelik kestirimi için LS-SVM veya WLS-SVM kullanılmıştır. İleriye yönelik kestirim yapabilmek amacıyla Sauer'in gömme teorisine göre elde edilmiş olan ISI zaman serilerinin yeniden düzenlenmesi, destek vektör model eğitimi için kullanılan veri sayısı n ve gömme boyutu Γ olmak üzere aşağıdaki biçimde yapılmıştır:

$$\underline{\mathbf{x}} = [x_1, x_2, x_3, \dots, x_n] \quad (4.1a)$$

$$\underline{\mathbf{x}}_{g_i} = [x_i, x_{i+1}, x_{i+2}, \dots, x_{i+\Gamma-1}] \quad (4.1b)$$

$$y_{g_i} = x_{g_{i+\Gamma}} \quad (4.1c)$$

$$\underline{\underline{\mathbf{X}}}_g = [\underline{\mathbf{x}}_{g_1}; \underline{\mathbf{x}}_{g_2}; \dots; \underline{\mathbf{x}}_{g_{n-\Gamma}}] \quad (4.1d)$$

$$\underline{\mathbf{y}}_g = [y_{g_1}; y_{g_2}; \dots; y_{g_{n-\Gamma}}] \quad (4.1e)$$

$$i = 1, 2, 3, \dots, n - \Gamma$$

Burada $\underline{\mathbf{x}}$ ISI serisi, Γ gömme boyutuna göre yeniden düzenlenerek giriş vektörü $\underline{\mathbf{x}}_{g_i}$ ve $\underline{\mathbf{x}}_{g_i}$ giriş vektörleri ile giriş matrisi $\underline{\underline{\mathbf{X}}}_g$ oluşturulmuştur. Her bir giriş vektörüne karşılık çıkış değeri y_{g_i} ve çıkış değerlerinin oluşturduğu çıkış vektörü $\underline{\mathbf{y}}_g$ dir. ISI serisi denklem (4.1d) ve denklem (4.1e)'de görüldüğü gibi $\underline{\underline{\mathbf{X}}}_g$ giriş matrisine karşılık

\underline{y}_g çıkış vektörü gelecek biçimde düzenlendikten sonra, $\underline{\mathbf{X}}_g$ matrisine kümeleme işlemi uygulanarak veri kümeleri elde edilmiştir. Her bir veri kümesi için Gausiyen radyal tabanlı kernel kullanılmış, σ_i kernel parametresi sabit tutularak kernel matrisleri oluşturulmuştur. Küme sayısı m ve darbeler arası zaman ölçüm değerleri (I_i) vektörü $\underline{\mathbf{I}}_{ZS}$ olmak üzere kernel parametresi σ_i , denklem (4.2c) ile elde edilmiştir (Mattera ve Haykin, 1999).

$$I_i = T_{i+1} - T_i \quad (4.2a)$$

$$\underline{\mathbf{I}}_{ZS} = [I_1 \ I_2 \ I_3 \ \dots \ I_n] \quad (4.2b)$$

$$\sigma_i = \left(\frac{0,75 \cdot \Gamma}{n} \sum_{i=1}^n \|\underline{\mathbf{I}}_{ZS}\|^2 \right)^{1/2} \quad (4.2c)$$

$$\underline{\boldsymbol{\sigma}} = [\sigma_1, \sigma_2, \dots, \sigma_m] \quad (4.2d)$$

Küme sayısı kadar LS-SVM kullanılmış, her bir LS-SVM eğitilmiş, eğitilen LS-SVM'lere 1,5,10,15,20,40,100 adım ileriye yönelik kestirim yaptırılmıştır. Veriler arası en büyük mesafe d ve iki yörünge arasındaki ilk mesafe e , olmak üzere kaotik bir zaman serisi için kestirim ufku saniye cinsinden aşağıdaki formül ile hesaplanmıştır (İplikçi, 2002).

$$\mathbf{P}_h = \frac{1}{\lambda_{\max}} \ln\left(\frac{d}{e}\right) = \frac{4,605}{\lambda_{\max}}, \frac{d}{e} \approx 100 \quad (4.3)$$

Aynı işlem basamakları WLS-SVM'ler içinde uygulanmıştır. Daha sonra gürültüsüz ISI verilerine 25dB'lik Gausiyen ve Gausiyen olmayan gürültü (EK-A (A.3)) eklenerek gürültülü ISI verisi zaman serileri üretilmiş, bu veriler içinde LS-SVM ve WLS-SVM'lere ileriye yönelik kestirim yaptırılmıştır. Benzetim sonuçları, kullanılan her bir kaotik sistem başlığı altında gösterilmiştir.

4.1 Lorenz Sistemi

Yaygın olarak kullanılan bir kaotik sistemdir. Diferansiyel denklemleri (4.4) ile verilmiştir. Denklemlerdeki parametrelerin değiştirilmesi sonucu sistem kaotik veya kaotik olmayan davranışlar sergileyebilir.


$$\begin{aligned}\dot{x} &= -p_n x + p_n y \\ \dot{y} &= -xz + rx - y \\ \dot{z} &= xy - bz\end{aligned}\tag{4.4}$$

Prandtl sayısı p_n , Reynolds sayısı r ve sistem parametresi b olmak üzere: $p_n = 10, b = 8/3, r \geq 24.74$ değerleri için sistem kaotik davranış sergilemektedir (Alligood ve diğ., 1996).

$r = 28$ alınarak toplam $n_T = 1500$ adet ISI verisi toplanmıştır. $n = 350$ için zaman serisi Şekil 4.1 de görülmektedir. $\theta_{FT} = 2.5$ ve $\varphi = 25$ alınmıştır.

Gürültüsüz ve gürültülü ISI verileri gömme boyutu $\Gamma = 5$ alınarak yeniden düzenlenmiş daha sonra verilere düzgünleştirme işlemi uygulanmıştır. Geciktirilmiş ve düzgünleştirilmiş ISI verisi, küre yarıçapı $r_c = 0.0839$ alınarak kümeleme işleminden geçirilmiş ve 1 küme oluşturulmuştur. (4.2c) denkleminde $\underline{\sigma} = [0.2096]$ bulunmuştur.

Lorenz için, $\lambda_{\max} = 0.905$, $\mathbf{P}_h = 5.088$ sn ve kestirim yapılabilecek adım sayısı (s_n) 52 dir. Bu nedenle çizelgeler 40 kestirim verisindeki en küçük düzgünleştirilmiş ideal hata değerleri (NPE) göz önünde bulundurularak doldurulmuştur. NPE'lerin hesaplanması için kullanılan formül EK-A (A.3)'te verilmiştir.




Şekil 4.1: Lorenz ISI zaman serisi

Çizelge 4.1: Gürültüsüz Lorenz ISI için LS-SVM hata değerleri

LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
250	-78.0265	-40.6616	-38.6303	-39.5163	-37.5626	-2.9044	1.2591

Çizelge 4.2: Gürültüsüz Lorenz ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
8050	-86.8068	-46.2872	-46.6793	-37.1561	-33.3782	-3.6180	1.1120



Şekil 4.2: Gürültüsüz Lorenz ISI için NPE değerleri

Çizelge 4.3: Gaussiyen gürültülü Lorenz ISI için LS-SVM hata değerleri

Gaussiyen gürültü eklenmiş ISI serisi için LS-SVM'nin NPE (dB) değerleri

γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
3000	-45.8838	-8.6052	4.0400	7.8128	0.2773	-0.0682	1.4687


Çizelge 4.1 ve Çizelge 4.2 de verilmiş olan düzgünleştirilmiş ideal hata değerleri (NPE), Şekil 4.2 de, Çizelge 4.3 ve Çizelge 4.4 de verilmiş olan NPE değerleri Şekil 4.3 de, Çizelge 4.5 ve Çizelge 4.6 da verilmiş olan NPE değerleri ise Şekil 4.4 de görülmektedir.

Çizelge 4.4: Gausiyen gürültülü Lorenz ISI için WLS-SVM hata değerleri

Gausiyen gürültü eklenmiş ISI serisi için WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
1150	-46.5916	-9.8872	-4.7282	7.4370	0.0059	-0.1743	1.4601


Çizelge 4.5: Gausiyen olmayan gürültülü Lorenz ISI için LS-SVM hata değerleri

Gausiyen olmayan gürültü eklenmiş ISI serisi için LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
900	-43.2302	-3.5877	4.3896	8.1020	0.4324	0.0329	1.6405

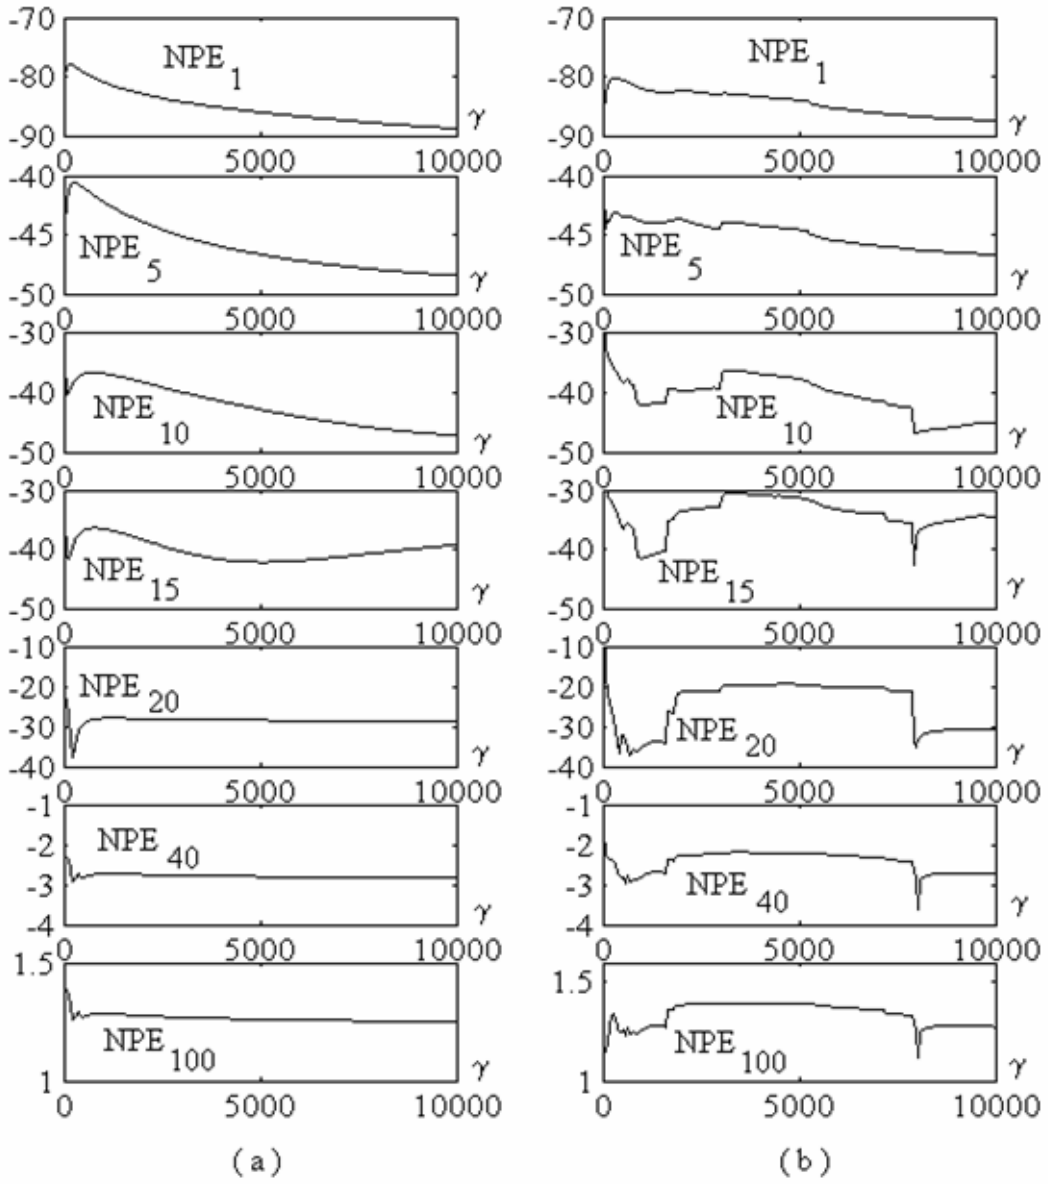
**Şekil 4.3: Gausiyen gürültülü Lorenz ISI için en ideal NPE değerleri**

Çizelge 4.6: Gausiyen olmayan gürültülü Lorenz ISI için WLS-SVM hata değerleri

Gausiyen olmayan gürültü eklenmiş ISI serisi için WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	-45.1683	-5.3933	4.2156	8.0573	0.3997	0.0194	1.6377




Şekil 4.4: Gausiyen olmayan gürültülü Lorenz ISI için en ideal NPE değerleri




Şekil 4.5: Gürültüsüz Lorenz ISI için 1,5,10,15,20,40,100 adım NPE değerleri

(a) γ 'ya göre LS-SVM'nin NPE değerleri

(b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.6: Gausiyen gürültülü Lorenz ISI için 1,5,10,15,20,40,100 adım NPE değerleri
 (a) γ 'ya göre LS-SVM'nin NPE değerleri
 (b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.7: Gaussiyen olmayan gürültülü Lorenz ISI için 1,5,10,15,20,40,100 adım NPE değerleri

(a) γ 'ya göre LS-SVM'nin NPE değerleri

(b) γ 'ya göre WLS-SVM'nin NPE değerleri

4.2 Rössler Sistemi

Rössler sistemi Alman bilimci O.Rössler tarafından bulunmuştur. Rössler eşitlikleri olarak bilinen diferansiyel denklem kümesi (4.5)'de verilmiştir.


$$\begin{aligned}\dot{x} &= -y - z \\ \dot{y} &= x + ay \\ \dot{z} &= b + (x - c)z\end{aligned}\tag{4.5}$$

Burada $a = 0.15, b = 0.2, c = 10, \theta_{FT} = 35, \varphi = 40$ olarak seçilmiştir. İlk $n=350$ veri için Rössler ISI zaman serisi Şekil 4.8'de görülmektedir.

Gürültüsüz ve gürültülü ISI verileri gömme boyutu $\Gamma=5$ alınarak yeniden düzenlenmiş ve verilere düzgünleştirme işlemi uygulanmıştır. Geciktirilmiş ve düzgünleştirilmiş ISI verisi, küre yarıçapı $r_c=0.13$ alınarak kümeleme işleminden geçirilmiş ve 4 küme oluşturulmuştur.

Denklem (4.2c)'den $\underline{\sigma} = [0.3138 \ 0.3949 \ 0.5842 \ 1.4272]$ bulunmuştur. Rössler için, $\lambda_{\max} = 0.072$, $\mathbf{P}_h = 63.958$ sn ve kestirim yapılabilecek adım sayısı 76 dır. Bu nedenle çizelgeler 100 kestirim verisindeki en küçük NPE göz önünde bulundurularak doldurulmuştur.

Çizelge 4.7 ve Çizelge 4.8 de verilmiş olan düzgünleştirilmiş ideal hata değerleri (NPE), Şekil 4.9 da, Çizelge 4.9 ve Çizelge 4.10 da verilmiş olan NPE değerleri Şekil 4.10 da, Çizelge 4.11 ve Çizelge 4.12 de verilmiş olan NPE değerleri ise Şekil 4.11 de görülmektedir.




Şekil 4.8: Rössler ISI zaman serisi

Çizelge 4.7: Gürültüsüz Rössler ISI için LS-SVM hata değerleri

LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
2750	-91.4928	-60.9779	-59.8440	-58.7999	-25.7524	-18.9947	-18.4026

Çizelge 4.8: Gürültüsüz Rössler ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
200	-103.9591	-56.4417	-49.1538	-43.0653	-26.9473	-20.4950	-15.8304




Şekil 4.9: Gürültüsüz Rössler ISI için NPE değerleri

Çizelge 4.9: Gaussiyen gürültülü Rössler ISI için LS-SVM hata değerleri

LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
3000	-47.3876	-28.3563	-31.1932	-20.8854	-18.6242	-14.9075	-8.5913

Çizelge 4.10: Gaussiyen gürültülü Rössler ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
3350	-47.2642	-27.9603	-31.0717	-21.1613	-20.0520	-14.1611	-10.2377




Şekil 4.10: Gausiyen gürültülü Rössler ISI için en ideal NPE değerleri

Çizelge 4.11: Gausiyen olmayan gürültülü Rössler ISI için LS-SVM hata değerleri

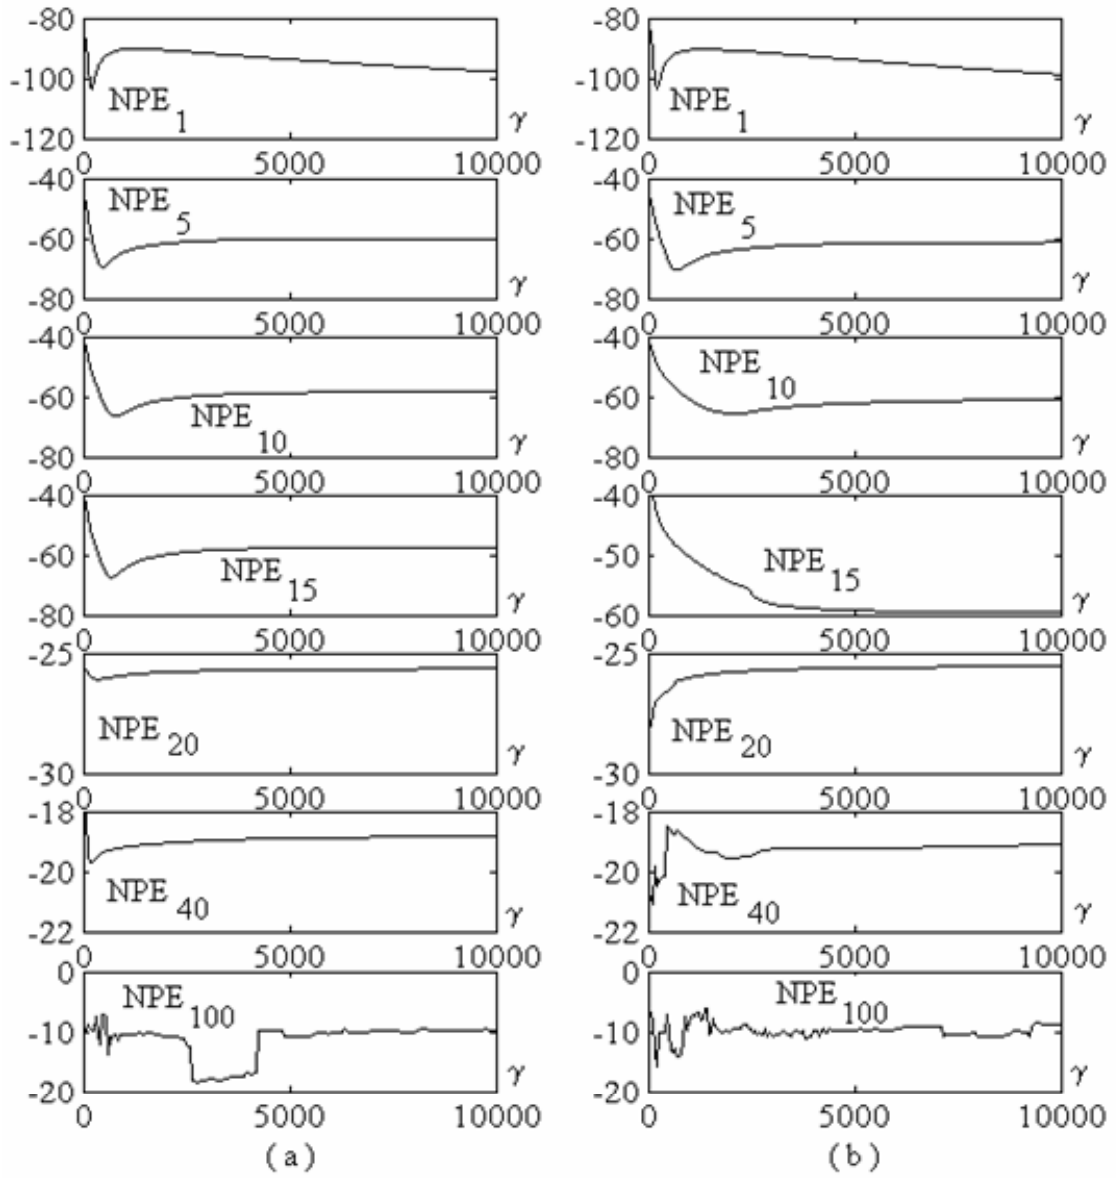
LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
1250	-50.0350	-27.4982	-26.0267	-27.3008	-21.7194	-16.5272	-12.7117

Çizelge 4.12: Gaussiyen olmayan gürültülü Rössler ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
850	-50.7634	-31.7751	-35.1633	-33.2887	-24.5488	-17.8420	-8.8689




Şekil 4.11: Gaussiyen olmayan gürültülü Rössler ISI için en ideal NPE değerleri



Şekil 4.12: Gürültüsüz Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri


(a) γ 'ya göre LS-SVM'nin NPE değerleri

(b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.13: Gausiyen gürültülü Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri

- (a) γ 'ya göre LS-SVM'nin NPE değerleri
 (b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.14: Gausiyen olmayan gürültülü Rössler ISI için 1,5,10,15,20,40,100 adım NPE değerleri
 (a) γ 'ya göre LS-SVM'nin NPE değerleri
 (b) γ 'ya göre WLS-SVM'nin NPE değerleri

4.3 Dört Boyutlu Kimyasal Sistem (CRS)

Küçük boyutlu kimyasal sistem zincirlerinde hiperkaos ve kaotik davranışın varolduğu G.Baier ve S.Sahle tarafından ispatlanmıştır (G.Baier vd S.Sahle 1994). Dört boyutlu kimyasal sistem için diferansiyel denklemler aşağıda görülmektedir:


$$\begin{aligned}
 \dot{x} &= \frac{pw}{(1+w^{10})} - 0.1x \\
 \dot{y} &= 0.1x - 0.2yz \\
 \dot{z} &= 0.2z(y-w) \\
 \dot{w} &= 0.2zw - 0.1w
 \end{aligned} \tag{4.6}$$

Dört boyutlu kimyasal sistem, p parametresinin 2.5 değerinde kaotik davranış sergilemektedir (Baier ve Sahle 1994). Toplam $n_T=1500$ adet ISI verisi toplanmıştır. Zaman serisinin ilk 100 elemanı Şekil 4.9 da görülmektedir.

Gürültüsüz ve gürültülü ISI verileri gömme boyutu $\Gamma=7$ alınarak yeniden düzenlenmiş daha sonra verilere düzgünleştirme işlemi uygulanmıştır. Geciktirilmiş ve düzgünleştirilmiş ISI verisi, küre yarıçapı $r_c=14$ alınarak kümeleme işleminden geçirilmiş ve 8 küme oluşturulmuştur. $\theta_{FT} = 1$ ve $\varphi = 0$ alınmıştır.

Denklem (4.2c)'den $\underline{\sigma} = [50.24 \ 29.77 \ 5.88 \ 11.90 \ 10.41 \ 9.35 \ 9.23 \ 15.71]$ bulunmuştur.

Rössler için, $\lambda_{\max} = 0.01$, $\mathbf{P}_h = 460.5$ sn ve kestirim yapılabilecek adım sayısı 18 dir. Çizelgeler 15 kestirim verisindeki en küçük NPE değerleri göz önünde bulundurularak doldurulmuştur.



Şekil 4.15: CRS ISI zaman serisi


Çizelge 4.13 ve Çizelge 4.14 de verilmiş olan düzgünleştirilmiş ideal hata değerleri (NPE), Şekil 4.16 da, Çizelge 4.15 ve Çizelge 4.16 da verilmiş olan NPE değerleri Şekil 4.17 de, Çizelge 4.17 ve Çizelge 4.18 de verilmiş olan NPE değerleri ise Şekil 4.18 de görülmektedir.

Çizelge 4.13: Gürültüsüz CRS ISI için LS-SVM hata değerleri

LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	-30.2511	-23.1312	-9.9992	-7.5226	-6.7312	-3.6004	-1.0353

Çizelge 4.14: Gürültüsüz CRS ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	-30.2511	-26.4204	-11.1247	-8.7452	-8.2990	-5.1287	-1.5633



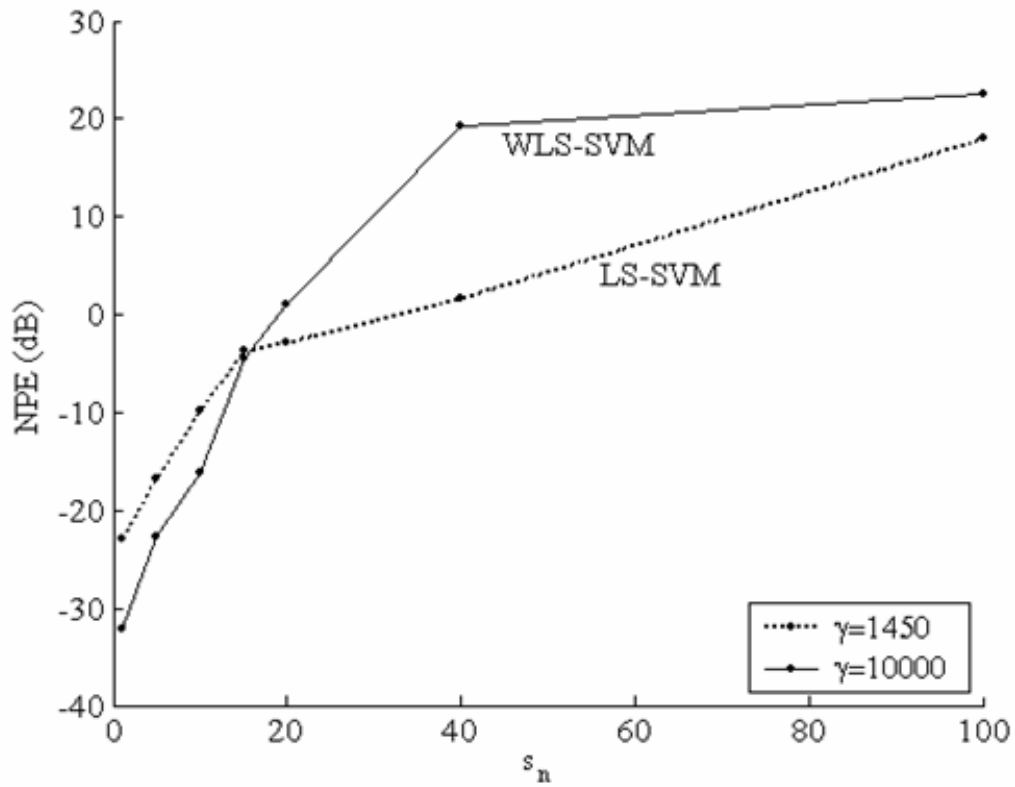
Şekil 4.16: Gürültüsüz CRS ISI için NPE değerleri

Çizelge 4.15: Gausiyen gürültülü CRS ISI için LS-SVM hata değerleri

LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
1450	-22.8895	-16.8133	-9.8805	-3.6306	-2.8355	1.5891	18.0982

Çizelge 4.16: Gausiyen gürültülü CRS ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	-32.0925	-22.7392	-16.2089	-4.5711	0.9958	19.2477	22.5349




Şekil 4.17: Gausiyen gürültülü CRS ISI için en ideal NPE değerleri

Çizelge 4.17: Gausiyen olmayan gürültülü CRS ISI için LS-SVM hata değerleri


LS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	2.6937	-4.1414	-3.2563	-1.9524	-1.6496	-1.2547	-0.2721

Çizelge 4.18: Gaussiyen olmayan gürültülü CRS ISI için WLS-SVM hata değerleri

WLS-SVM'nin NPE (dB) değerleri							
γ	NPE ₁	NPE ₅	NPE ₁₀	NPE ₁₅	NPE ₂₀	NPE ₄₀	NPE ₁₀₀
10000	2.1812	-4.5083	-3.5600	-2.1267	-1.5373	-0.6380	-0.1373




Şekil 4.18: Gaussiyen olmayan gürültülü CRS ISI için en ideal NPE değerleri



Şekil 4.19: Gürültüsüz CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri

(a) γ 'ya göre LS-SVM'nin NPE değerleri


(b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.20: Gaussiyen gürültülü CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri

(a) γ 'ya göre LS-SVM'nin NPE değerleri

(b) γ 'ya göre WLS-SVM'nin NPE değerleri



Şekil 4.21: Gausiyen olmayan gürültülü CRS ISI için 1,5,10,15,20,40,100 adım NPE değerleri

(a) γ 'ya göre LS-SVM'nin NPE değerleri

(b) γ 'ya göre WLS-SVM'nin NPE değerleri

BEŞİNCİ BÖLÜM

SONUÇLAR VE DEĞERLENDİRME

5. SONUÇLAR VE DEĞERLENDİRME

SVM'ler istatistiksel öğrenme teorisi tabanlı, kernel fonksiyonlarını kullanan, yerel en küçük değer sorunu olmayan, öğrenme sistemleridir. ϵ -toleranslı hata fonksiyonunu kullanan SVM'ler, problem çözümünde iç bükey karesel programlama tekniğini kullanırlar. İç bükey karesel programlama, küçük veri kümeleri için iyi bir hata performansı sergilemesine karşın büyük veri kümeleri için iyi bir hata performansı sergileyememektedir.

Bu çalışmanın amacı, kaotik zaman serilerinin ileriye yönelik kısa dönem kestiriminde, en iyileme problemindeki eşitsizlik kısıtlamaları eşitlik kısıtlamalarına dönüştürülerek nitelik uzayı içerisinde doğrusal denklem sistemi çözümü yöntemini kullanan, Ridge bağlanım algoritması tabanlı, iç bükey karesel programlama yöntemine göre çözüm üreten SVM'lere göre daha hızlı LS-SVM'lerin hata performanslarının incelenmesidir. Gerçek hayatta gözlenebilecek çoğu kaotik sistem çalışma süreçleri boyunca dış etkilere maruz kalmaktadır. Bu etkiler *gürültü* olarak düşünülebilir. Bu tür sistemler göz önüne alınarak, LS-SVM'lerin gürültüye karşı performanslarının değerlendirilebilmesi için ağırlıklı versiyonu olan WLS-SVM'ler de çalışma içerisinde ele alınmıştır.

Herhangi bir büyüklüğün ölçülemediği, sadece sistemin bir büyüklüğü gerçekleştirilmesi sırasında sistem durum değişimi sürelerinin ölçülebildiği düşünülerek Lorenz, Rössler ve Kimyasal sistemlerden ISI zaman serileri üretilmiş daha sonra bu zaman serileri içerisine 25dB'lik Gausiyen olmayan ve Gausiyen gürültü eklenerek sırasıyla Gausiyen olmayan ve Gausiyen gürültülü ISI zaman serileri de elde edilmiştir.

Her bir ISI zaman serisinin ilk 1000 veri değeri, LS-SVM ve WLS-SVM'ler için eğitim verisi olarak ele alınmıştır. Bu eğitim verilerine göre LS-SVM ve WLS-SVM'ler eğitilmiş, eğitilen SVM'lere ileriye yönelik kestirim yaptırılmıştır. Uygulama sonucunda: LS-SVM ve WLS-SVM'lerin belirli bir süre boyunca iyi bir kestirim performansı sergilediği, bu süre sonrası için ise performanslarının kötü olduğu elde edilen düzgünleştirilmiş hata değerlerinden gözlemlenmiştir. Bu gözlem sonucu, kaotik sistem verileri için belirli bir kestirim ufkunun olduğu düşüncesini desteklemektedir.

Bölüm 4'deki çizelgelerden, yapılan ileriye yönelik kestirimlerde; gürültü eklenmemiş Lorenz ISI zaman serisi için $\Gamma=5$ alınmak suretiyle kestirim ufkunun yaklaşık 5.088 sn (52 adım), Rössler ISI zaman serisi için $\Gamma=5$ alınmak suretiyle kestirim ufkunun yaklaşık 63.958 sn (76 adım), Kimyasal ISI zaman serisi için $\Gamma=7$ alınmak suretiyle kestirim ufkunun yaklaşık 460.5 sn (18 adım) olduğu görülmektedir. Γ 'nun değiştirilmesi ile verilmiş olan kestirim süreleri değişebilir (Baier ve Sahle, 1994).

Dördüncü bölümdeki çizelge ve şekillerden görülebileceği gibi; gürültü eklenmemiş ISI zaman serilerinin ileriye yönelik kestirimlerinde LS-SVM, WLS-SVM'ye veya WLS-SVM, LS-SVM'ye göre daha küçük hata değerleri üretir genellemesi yapılamaz (Şekil 4.2, Şekil 4.9, Şekil 4.15). Buna karşılık her bir sistem için elde edilen NPE değerleri göz önüne alındığında kestirim ufkunu boyunca WLS-SVM nin gürültü eklenmiş ISI zaman serileri için LS-SVM'ye göre daha küçük hata değerleri ürettiği söylenebilir (Şekil 4.3, Şekil 4.4, Şekil 4.10, Şekil 4.11, Şekil 4.17, Şekil 4.18). Bu sonuç, WLS-SVM nin LS-SVM'ye göre gürültü eklenmiş veri kümeleri için daha iyi bir hata performansı sergilediği düşüncesini (Suykens ve diğ., 2002, Vallyon ve Horvát, 2003) desteklemektedir.

Gerçek hayatta karşılaşılan kaotik sistem çıkış değerlerine çalışma süreçleri boyunca gerek dış etkilerden gerekse sistem içi etkilerden dolayı gürültü eklenebilir ve sistemden istenen gürültüsüz çıkış değerleri elde edilemeyebilir. Bu sistemlerin çıkış verileri kullanılarak ileriye yönelik kestirim yapılmak isteniyorsa, LS-SVM'lerin yerine WLS-SVM'ler tercih edilebilir.

Bu çalışmada kestirim ufku göz önünde bulundurulmuş ve belirli bir γ değerinde NPE değerlerinin en küçük olduğu gözlenmiştir.

Gürültüsüz ISI zaman serileri:

Lorenz ISI ve CRS ISI için kestirim ufku boyunca, γ değerinin artması NPE değerlerini azaltmaktadır (Şekil 4.5, Şekil 4.19). Rössler ISI için ise γ değerinin artırılması NPE değerlerinin artmasına neden olmaktadır (Şekil 4.12).

Gausiyen gürültülü ISI zaman serileri:

Lorenz ISI, CRS ISI ve Rössler ISI zaman serileri için kestirim ufku boyunca NPE değerleri, artan γ değeri ile artmaktadır (Şekil 4.6, Şekil 4.13, Şekil 4.20).

Gausiyen olmayan gürültülü ISI zaman serileri:

Lorenz ISI ve Rössler ISI için kestirim ufku boyunca artan γ değeri ile NPE değerleri artmaktadır (Şekil 4.7, Şekil 4.14). CRS ISI zaman serisi için NPE değerleri, γ değerinin artması ile azalmaktadır (Şekil 4.21).

Yukarıda verilmiş açıklamalardan incelenen her sistem için, γ değerinin artması/azalması NPE değerlerini arttırır veya azaltır şeklinde bir genelleme yapılamaz.

Kullanılan kaotik zaman serileri için çizilmiş olan grafiklerden, LS-SVM ve WLS-SVM'lerin belirli bir kestirim ufku süresine kadar kararlı çalıştığı gözlenebilir (Şekil 4.5, Şekil 4.6, Şekil 4.7, Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.19, Şekil 4.20, Şekil 4.21).

Yukarıda verilmiş olan açıklamalardan WLS-SVM'lerin, LS-SVM'lere göre gürültüye karşı daha dayanıklı olduğu, Kaotik zaman serilerinin kısa dönem kestirim

uygulamalarında LS-SVM ve WLS-SVM'lerin kullanımının pratiklik sağladığı, LS-SVM ve WLS-SVM'lerin kestirim potansiyelleri yüksek olduğu söylenebilir.

Yapılan bu çalışmaya paralel olarak aşağıda verilmiş çalışmalar da yapılabilir:

- Kaotik zaman serilerinin yeniden düzenlenmesi ve farklı kümeleme algoritmaları kullanılarak, LS-SVM ve WLS-SVM'ler ile ileriye yönelik kısa dönem kestirim sonuçlarıyla kümeleme işlemi uygulanmadan LS-SVM ve WLS-SVM'ler ile ileriye yönelik kısa dönem kestirim sonuçlarının karşılaştırılması.
- EEG, EKG, EMG gibi biyolojik sinyallerin LS-SVM ve WLS-SVM'ler ile ileriye yönelik kestirimi ve analizi.
- LS-SVM'ler ile standart SVM'lerin, ISI zaman serilerinin ileriye yönelik kestiriminde hata performansı açısından karşılaştırılması.
- Biyolojik Sistemlerden elde edilecek ISI serilerinin ileriye yönelik kestirimlerinde, LS-SVM'lerin diğer global öğrenme sistemleri ile performans hataları açısından karşılaştırılması.

KAYNAKLAR

Alligood, K. T., Sauer T. D. and Yorke, J. A., CHAOS An Introduction to Dynamical Systems, Textbooks in Mathematical Sciences, ISBN 0-387-94677-2, 595 p., Springer-Verlag New York, 1996.

Angeline, P. J., Evolving Predictors for Chaotic Time Series, Proceedings of SPIE: Application and Science of Computational Intelligence, Vol. 3390, 170-180, 1998.

Badel, A. E., Guégan, D., Mercier, L. and Michel, O., Comparison of Several Methods to Predict Chaotic Time Series, IEEE International Conference ICASSP97, Vol. 5, 3793-3796, 1997.

Baier, G. and Sahle S., Hyperchaos and Chaotic Hierarchy in Low-Dimensional Chemical Systems, The Journal of Chemical Physics, Vol. 100, Issue 12, 8907-8911, 1994.

Casdagli, M., Nonlinear Prediction of Chaotic Time Series, Physica D, Vol. 35, 335-356, 1989.

Cortes, C. and Vapnik, V, Support Vector Networks, Machine Learning, Vol. 20, 1-25, 1995.

Cowper, M. R., Mulgrew, B. and Unsworth, C. P., Nonlinear Prediction of Chaotic Signals Using A Normalized Radial Basis Function Networks, Signal Processing, Vol. 82, Issue 5, 2002.

Cristianini, N. and Shawe-Taylor, J., An Introduction to Support Vector Machines, Cambridge University Press, ISBN 0-521-78019-5, 187 p., United Kingdom, 2000.

- Farmer, D. and Sidorowich, J., Predicting Chaotic Time Series, *Phys. Rev. Lett.* Vol. 59(8), 845–848, 1987.
- Ikeguchi, T. and Aihara, K., Prediction of Chaotic Time Series with Noise, *IEICE Trans. Fundamentals*, Vol. E78-A, 1291-1298, 1995.
- İplikçi, S., Computationally Intelligent Techniques for Stabilisation and Targeting of Chaotic Time Series, Ph. D. Thesis, Boğaziçi University, Institute of Sciences and Engineering, Electrical and Electronics Engineering Dept., 2002.
- Ke-Ping, L., Zi-You, G. and Tian-Lun, C., Improving The Prediction of Chaotic Time Series, *Chinese Phys. Soc.*, Vol. 12, 1213-1217, 2003.
- Kuo, J., Principe, J. C., Vries, B., Prediction of Chaotic Time Series Using Recurrent Neural Networks, *Neural Networks for Signal Processing, Proceedings of The 1992 IEEE-SP Workshop*, ISBN 0-7803-0557-4, 436-443, 1992.
- Leung, H, Lo T., and Wang S., Prediction of Noisy Chaotic Time Series Using an Optimal Radial Basis Function Neural Network, *IEEE Transactions on Neural Networks*, Vol. 12, 1163-1172, 2001.
- Linsay, P.S., An Efficient Method of Forecasting Chaotic Time Series Using Linear Interpolation, *Physics Letters A*, Vol. 153, 353-3356, 1991.
- Liu X., Kwan, B. W. And Foo, S. Y., Time Series Prediction Based on Fuzzy Principles, (<http://devils.eng.fsu.edu/publications.shtml>).
- Liu, Z., Ren, X. and Zhu, Z., Equivalence Between Different Local Prediction Methods of Chaotic Time Series, *Physics Letters A*, Vol. 227, Issues 1-2, 37-40, 1997.
- Lorenz, E. N., Deterministic Nonperiodic Flow, *Journal of The Atmospheric Science*, Vol. 20, 130-141, 1963.

- Maesschalck, R. D., Jouan-Rimbaud, D. and Massart, D. L., The Mahalanobis Distance, *Chemometrics and Intelligent Laboratory Systems*, Vol 50, Issue 1, 1-18, 2000.
- Mattera, D. and Haykin, S., Support Vector Machines for Dynamic Reconstruction of a Chaotic System. In *Advances in Kernel Methods: Support Vector Learning*, ed. B. Schölkopf, C. J. C. Burges and A. J. Smola, Cambridge, MA: The MIT Press, 211-242, 1999.
- Mei-Ying, Y. and Xiao-Dong, W., Chaotic Time Series Prediction Using Least Squares Support Vector Machines, *Chinese Phys. Soc.*, Vol. 13, 454-458, 2004.
- Mouzouris, G. C. and Mendel, M., Nonsingleton Fuzzy Logic Systems: Theory and Application, *IEEE Transactions on Fuzzy Systems*, Vol. 5, 56-71, 1997.
- Mukherjee, S., Osuna, E. and Girosi, F., Nonlinear Prediction of Chaotic Time Series Using Support Vector Machines, *Neural Networks for Signal Processing - Proceedings of The IEEE Workshop*, 511-520, 1997.
- Mulloy, B. S., Riolo, R. L. and Savit, R. S., Dynamics of Genetic Programming and Chaotic Time Series Prediction, *Proceedings of The First Annual Conference*, MIT Press, 166-174, 1996.
- Navone, H. D. and Ceccatto, H. A., Forecasting Chaos from Small Data Sets: A Comparison of Different Nonlinear Algorithms, *J. Phys. A.*, Vol. 28, 3381-3388, 1995.
- Oliveira, K. A., Vanucci, A. and Silva E. C., Using Artificial Neural Networks to Forecast Chaotic Time Series, *Physica A: Statistical Mechanics and Its Applications*, Vol. 284, Issues 1-4, 393-404, 2000.

- Saranlı, A. and Baykal, B., Chaotic Time Series Predictions and The Relocating-LMS (RLMS) Algorithm for Radial Basis Function Networks, EUSIPCO96, Vol. 2, 1247-1250, 1996.
- Studer, L. and Masulli, F., Building A Neuro-fuzzy system to Efficiently Forecast Chaotic Time Series, Nuclear Instruments and Methods in Physics Research A, Vol. 389, 264-267, 1997.
- Suykens, J. A. K., Brabanter, J. De, Lukas, L. and Vandewalle, J., Weighted Least Squares Support Vector Machines: Robustness and Sparse Approximation, Neurocomputing, Vol. 48, Issues 1-4, 85-105, 2002.
- Suykens, J. A. K. and Vandewalle, J., Least Square Support Vector Machine Classifiers, Neural Processing Letters, No: 3, 293-300, 1999
- Valyon, J. and Horváth, G., A Weighted Generalized LS-SVM, Periodica Polytechnica Ser. El. Eng., Vol. 47, 229-251, 2003.
- Venkataraman, P., Applied Optimisation with MATLAB Programming, A Wiley – Interscience publication, ISBN 0-471-34958-5, 391 p., United States of America, 2001.
- Yen, G. and Lu H., Hierarchical Genetic Algorithm for Near-Optimal Feedforward Neural Network Design, International Journal of Neural Systems, Vol. 12, 31-43, 2002.
- Zhang, Jia-Shu. and Xiao, Xian-Ci, Prediction Hyper-Chaotic Time Series Using Adaptive Higher-Order Nonlinear Filter, Chinese Phys.Lett., Vol. 18, 337-340, 2001.

EK-A

A.1 Dördüncü Dereceden Runga-Kutta Benzetim Yöntemi Fonksiyonu

Uygulama sırasında Lorenz sistemi için MATLAB'te yazılan, 4. Dereceden Runga-Kutta benzetim yöntemi fonksiyonu aşağıda görülmektedir. Verilmiş olan fonksiyonda düzenleme yapılarak Rössler sistemi ve Kimyasal sistem içinde ayrıca iki fonksiyon yazılmıştır.

```
function [x,y,z]=lorenz(x,y,z,sigma,ro,beta,delta)
```

```
X=x;Y=y;Z=z;
```

```
k1x=delta*( sigma*(y-x) );
```

```
k1y=delta*( ro*x-y-x*z );
```

```
k1z=delta*( x*y-beta*z );
```

```
x=X+k1x/2;
```

```
y=Y+k1y/2;
```

```
z=Z+k1z/2;
```

```
k2x=delta*( sigma*(y-x) );
```

```
k2y=delta*( ro*x-y-x*z );
```

```
k2z=delta*( x*y-beta*z );
```

```
x=X+k2x/2;
```

```
y=Y+k2y/2;
```

```
z=Z+k2z/2;
```

```
k3x=delta*( sigma*(y-x) );
```

```
k3y=delta*( ro*x-y-x*z );
```

```
k3z=delta*( x*y-beta*z );
```

$$\begin{aligned}x &= X + k_3x; \\ y &= Y + k_3y; \\ z &= Z + k_3z;\end{aligned}$$

$$\begin{aligned}k_4x &= \text{delta} * (\text{sigma} * (y - x)); \\ k_4y &= \text{delta} * (\text{ro} * x - y - x * z); \\ k_4z &= \text{delta} * (x * y - \text{beta} * z);\end{aligned}$$

$$\begin{aligned}x &= X + (k_1x + 2 * k_2x + 2 * k_3x + k_4x) / 6; \\ y &= Y + (k_1y + 2 * k_2y + 2 * k_3y + k_4y) / 6; \\ z &= Z + (k_1z + 2 * k_2z + 2 * k_3z + k_4z) / 6;\end{aligned}$$

A.2 ISI Zaman Serilerinin Toplanması için Yazılmış Program

Lorenz sistemi için ISI zaman serilerinin toplanması amacıyla yazılmış program aşağıda verilmiştir. Threshold (θ_{FT}), $\varphi = 25$ değerinde ve her bir sistem için gerekli sistem parametreleri ile Lorenz sisteminin ihtiyaç duyduğu sigma, ro, beta parametrelerinin yer değiştirilmesi suretiyle aşağıda verilmiş program Rössler sistemi ve Kimyasal sistem için yeniden düzenlenmiştir.

```
x=rand;y=rand;z=rand;
sigma=10;ro=28;beta=8/3;
threshold=2.5;delta=0.0001;

for i=1:100000

[x,y,z]=lorenz(x,y,z,sigma,ro,beta,delta);

end

fprintf('Sit to Attractive ')
t=0;
for i=1:1500
```

```

sum=0;m=0;

while sum<threshold

    fs=x+25;

    [x,y,z]=lorenz(x,y,z,sigma,ro,beta,delta);

    ls=x+25;

    sum=sum+(fs+ls)*delta/2;

    m=m+1;

end

I(i)=m*delta;

End

```

A.3 Düzgünleştirilmiş Kestirim Hatası Denklemi (NPE) ve Veri Kümesine Gürültü Eklemek için Kullanılan Denklem

Kestirim yapılacak veri sayısı n , kestirim yapılacak veri kümesi S_{kestirim} olmak üzere düzgünleştirilmiş kestirim hatası denklemi şu şekilde yazılabilir (İplikçi, 2002):

$$\text{NPE} = 10 \log \left(\frac{\sum_{i=1}^n \text{Hata}_i^2}{n \cdot \text{varyans}(S_{\text{kestirim}})} \right)$$

Veri kümesine gürültü eklemek için kullanılan denklem (İplikçi, 2002):

$$10 \log \left(\frac{\text{varyans}(\text{sinyal})}{\text{varyans}(\text{gürültü})} \right) = \text{Gürültü Miktarı (dB)}$$

EK-B

B.1 ISI Zaman Serisi Verilerinin Kümelenmesi için Yazılmış Program

```

function [group]=Clusteree(P,radius)
group=[];
N=size(P,2);
d=dist(P',P);
for k=1:N;
    d(k,k)=inf;
end;
S=1:N;
F=1:N;
loop=1;
while loop
    if isempty(S);loop=0;
else
    k=S(1);
    I=find(d(k,:)<=radius);
    if isempty(I);
F(k)=0;
        S=find(F~=0);
    else
        if isempty(group);
group(1,:)=[k,I];
            F(k)=0;F(I)=0;
            S=find(F~=0);
        else
            a=[];loop1=isempty(a);m=0;
            while loop1;m=m+1;[a
m==length(I);loop1=0;end;end
                b]=find(group==I(m));loop1=isempty(a);if
                    if isempty(a);

```

```

group(size(group,1)+1,1:length(I)+1)=[k,I];

F(k)=0;F(I)=0;
S=find(F~=0);
else
if F(k)~=0
X=find(group(a,)==0);
if isempty(X);X=length(group(a,))+1;else X=X(1);end
group(a,X)=[k];
end

for i=1:length(I)
if F(I(i))~=0
X=find(group(a,)==0);
if isempty(X);X=length(group(a,))+1;else X=X(1);end
group(a,X)=[I(i)];
end
end
F(k)=0;F(I)=0;
S=find(F~=0);
end
end
end
end;

```

B.2 Elde Edilen ISI Zaman Serilerinin Yeniden Düzenlenmesi için Yazılmış Fonksiyon

```

function [X_delay,Y_delay]=lssvm_gecik(Full_Data,To1,To,Using_Samp_Numb)

train_data=Full_Data(1:Using_Samp_Numb);
k=0;

```

```

for j=To1:1:(size(train_data,1)-To-1)

    k=k+1;
    Delayed_train_data(k,:)=train_data(j:j+To,1)';

end

Delayed_Out=[Delayed_train_data(2:end,To+1);train_data(end,end)];

X_delay=Delayed_train_data;
Y_delay=Delayed_Out;

```

B.3 LS-SVM'nin Eğitimi için Yazılmış Fonksiyon

```

function [alpha,b]=lssvm_egit(X,Y,sigma,gamma)

ort_X=ones(size(X,1),1)*mean(X);std_X=ones(size(X,1),1)*std(X);
norm_X=( X-ort_X )./std_X;

ort_Y=ones(size(Y,1),1)*mean(Y);std_Y=ones(size(Y,1),1)*std(Y);
norm_Y=( Y-ort_Y )./std_Y;

Ker_Matrix=Rbf_Ker(norm_X,sigma,norm_X);

bir_matrix=ones(size(Ker_Matrix,1),1);

for i=1:size(Y,2)

    A=Ker_Matrix+eye(size(Ker_Matrix,1) )*(1/gamma(i));

    H=[0 bir_matrix'; bir_matrix A];

```

```

        y_hat=[0 ; norm_Y(:,i)];
    b_b=inv(H)*y_hat;

    b(1,i)=b_b(1);

    alpha(:,i)=b_b(2:size(b_b,1));

end

```

B.4 LS-SVM'nin Test Edilmesi ve Benzetimi için Yazılmış Fonksiyon

```

function Y_sim=lssvm_sim(test_data,X,Y,alpha,b,sigma)

ort_X=ones(size(X,1),1)*mean(X);std_X=ones(size(X,1),1)*std(X);
norm_X=( X-ort_X )./std_X;

ort_Y=ones(size(Y,1),1)*mean(Y);std_Y=ones(size(Y,1),1)*std(Y);
norm_Y=( Y-ort_Y )./std_Y;

ort_test_data=ones(size(test_data,1),1)*mean(X);std_test_data=ones(size(test_data,1),1)*std
(X);
norm_test_data=( test_data-ort_test_data )./std_test_data;

Ker_Matrix=Rbf_Ker(norm_X,sigma,norm_test_data);

for i=1:size(Y,2)

norm_Y_sim(:,i)=( alpha(:,i)*Ker_Matrix+b(:,i)*ones(1,size(test_data,1)) )';

end

standart_Y=ones(size(test_data,1),1)*std(Y);

```



```
ortalama_Y=ones(size(test_data,1),1)*mean(Y);
```

```
Y_sim=norm_Y_sim.*standart_Y+ortalama_Y;
```

B.5 LS-SVM ile Kaotik Zaman Serilerinin Kestirimi için Yazılmış Ana Program

```
clear
```

```
clc
```

```
format long e
```

```
load R_ISI;
```

```
Full_Data=R_ISI';
```

```
To1=1; To=4; Using_Samp_Numb=1000;
```

```
[XX_delay,YY_delay]=lssvm_gecik(Full_Data,To1,To,1500);
```

```
[X_delay,Y_delay]=lssvm_gecik(Full_Data,To1,To,Using_Samp_Numb);
```

```
[group]=Clusteree(X_delay',0.13);
```

```
[X_Data,Y_Data,indis]=Data_topla(X_delay,Y_delay,group);
```

```
[M,N]=means_and_nsigmas(X_delay',group);
```

```
for i=1:size(Y_Data,1)
```

```
    sigma(i,1)=sqrt((Y_Data{i,1}*Y_Data{i,1})*0.75*(To+1)*(1/Using_Samp_Numb));
```

```
end
```

```
gamma=50;
```

```
delta_gamma=50;
```

```
max_gamma=50;
```

```

n=0;
predict_time=[1 5 10 15 20 40 100];
while gamma<=max_gamma
n=n+1;
[alpha,b,Y_sim]=level_1_cluster_train(X_Data,Y_Data,sigma,gamma);
Train_Error=level_2_normalize_train_error(Y_sim,Y_Data);
testt=[X_delay(end,2:end) Y_delay(end,end)];

[clust_index]=mah_find_group(testt,M,N);
% fprintf('Küme indisi : %d\n',clust_index)

for i=1:size(predict_time,2)

    prediction_time=predict_time(1,i);

[gercek_deger,tahmin]=level_3_cluster_predict(YY_delay,X_Data,Y_Data,alpha,b,sigma,prediction_time,Y_delay,testt,clust_index,M,N);

Normalize_predict_error_desibel(1,i)=level_4_normalize_predict_error(Full_Data,gercek_deger,tahmin,prediction_time);

end

Degerler(n,:)= [ gamma Normalize_predict_error_desibel];
gamma=gamma+delta_gamma;

fprintf('%8.f\t\t%d\t%d\t%d\t%d\t%d\t%d\t%d\t%d\t%d\t\t\n',Degerler(n,1),Train_Error,Degerler(n,2),Degerler(n,3),Degerler(n,4),Degerler(n,5),Degerler(n,6),Degerler(n,7),Degerler(n,8));

end

```

B.6 WLS-SVM'lerin kullandığı Ağırlık Faktörü Değerlerinin Bulunması için Yazılmış Program

```
function v_gamma=v_weightss(Full_Data,X,Y,Using_Samp_Numb,sigma,gamma,c1,c2)
```

```
[alpha,b]=lssvm_egit(X,Y,sigma,gamma);
```

```
e=alpha./gamma;
```

```
Norm_data_for_mad=(
                                Full_Data(1:Using_Samp_Numb)-
ones(Using_Samp_Numb,1)*mean(Full_Data(1:Using_Samp_Numb)))/(
ones(Using_Samp_Numb,1)*std(Full_Data(1:Using_Samp_Numb)) );
```

```
s=1.483*mad(Norm_data_for_mad);
```

```
Degisken=abs(e./s);
```

```
for i=1:size(Degisken,1)
```

```
    if Degisken(i,.)<=c1
```

```
        v(i,.)=1;
```

```
    elseif Degisken(i,.)>=c1 & Degisken(i,.)<=c2
```

```
        v(i,)=(c2-Degisken(i,))/(c2-c1);
```

```
    else
```

```
        v(i,)=1e-4;
```

```
    end
```

```
end
```

```
v_gamma=diag(1./(gamma.*v));
```

B.7 WLS-SVM ile Kaotik Zaman Serilerinin Kestirimi için Yazılmış Ana Program

```
clear
clc
format long e
load R_ISI;
Full_Data=R_ISI';
c1=2.5;
c2=3;
To1=1; To=6; Using_Samp_Numb=1000;

[XX_delay,YY_delay]=lssvm_gecik(FullData,To1,To,1500);
[X_delay,Y_delay]=lssvm_gecik(Full_Data,To1,To,Using_Samp_Numb);
[group]=Clusteree(X_delay',14);
[X_Data,Y_Data,indis]=Data_topla(X_delay,Y_delay,group);

[M,N]=means_and_nsigmas(X_delay',group);

for i=1:size(Y_Data,1)

    sigma(i,1)=sqrt((Y_Data{i,1}*Y_Data{i,1})*0.75*(To+1)*(1/Using_Samp_Numb));

end

gamma=50;
delta_gamma=100;
max_gamma=5000;

n=0;
```


ÖZGEÇMİŞ

Adı, soyadı : Halil ALPASLAN
Ana adı : Neriman
Baba adı : Ali Osman
Doğum yeri ve tarihi : DENİZLİ / 1981
Lisans eğitimi ve mezuniyet tarihi : Pamukkale Üniversitesi / Mühendislik Fakültesi
Elektrik-Elektronik Mühendisliği Bölümü, 2001
Çalıştığı yer : Pamukkale Üniversitesi / Teknik Eğitim Fakültesi
Bildiği yabancı diller : İngilizce