

KEDİ SÜRÜSÜ OPTİMİZASYONUNA DAYALI YENİ BİR BULANIK ZAMAN SERİSİ YAKLAŞIMI

A NEW FUZZY TIME SERIES APPROACH BASED ON CAT SWARM OPTIMIZATION

YASEMİN BURCU GÜNDOĞDU

DOÇ. DR. ÇAĞDAŞ HAKAN ALADAĞ
Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin


İstatistik Anabilim Dalı için Öngördüğü

DOKTORA TEZİ olarak hazırlanmıştır.


2018

YASEMİN BURCU GÜNDOĞDU'nun hazırladığı “**Kedi Sürüşü Optimizasyonuna Dayalı Yeni Bir Bulanık Zaman Serisi Yaklaşımı**” adlı bu çalışma aşağıdaki jüri tarafından **İSTATİSTİK ANABİLİM DALI**'nda **DOKTORA TEZİ** olarak kabul edilmiştir.


Prof. Dr. Birdal ŞENOĞLU
Başkan



Doç. Dr. Çağdaş Hakan ALADAĞ
Danışman




Prof. Dr. M. Özgür YENİAY
Üye



Dr. Öğr. Üyesi İbrahim ZOR
Üye



Dr. Öğr. Üyesi Şükrü ACITAŞ
Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **DOKTORA TEZİ** olarak onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU
Fen Bilimleri Enstitüsü Müdürü

*Canım Annem **NURHAN AÇIL**'in anısına,*

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- ☐ **Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.**

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etseniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- ☒ **Tezimin/Raporumun 08/06/2021 tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.**

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım taktirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.**

- ☐ **Serbest Seçenek/Yazarın Seçimi**

08 / 06 / 2018



Yasemin Burcu Gündoğdu

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

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

beyan ederim.

08/06/2018



YASEMİN BURCU GÜNDOĞDU

ÖZET

KEDİ SÜRÜSÜ OPTİMİZASYONUNA DAYALI YENİ BİR BULANIK ZAMAN SERİSİ YAKLAŞIMI

Yasemin Burcu GÜNDOĞDU

Doktora, İstatistik Bölümü

Tez Danışmanı: Doç. Dr. Çağdaş Hakan ALADAĞ

Haziran 2018, 83 sayfa

Model varsayımı ve gözlem sayısı gibi teorik kısıtları içermemesi sebebiyle belirsizlik içeren verilerin analiz edilmesinde klasik zaman serileri yerine tercih edilen bulanık zaman serilerinin önemi giderek artmaktadır. Bulanık zaman serilerinde öngörü elde edilmesinde, bulanıklaştırma, bulanık ilişkileri belirleme ve berraklaştırma biçiminde temel olarak üç aşama kullanılmaktadır. Literatürde her üç aşamanın da geliştirilmesi üzerine birçok çalışma bulunmaktadır. Bu çalışmaların büyük bir bölümü parçacık sürü optimizasyonu, genetik algoritma gibi sezgisel optimizasyon yöntemlerine dayanmaktadır. Bu çalışmada ise bulanık zaman serileri üzerine yapılmış olan literatürdeki diğer çalışmalardan farklı olarak küme merkezlerinin belirlenmesinde kedi sürüsü optimizasyonuna, bulanık ilişkilerin belirlenmesinde ise destek vektör makinelerine dayalı yeni bir yöntem önerilmiştir. Kedi sürüsü optimizasyonuna dayalı önerilen bu yeni yöntemin etkinliği, ilk olarak literatürde sıklıkla kullanılan veriler üzerinden değerlendirilmiştir. Daha sonra ise küme merkezlerinin belirlenmesi aşamasında kedi sürüsü optimizasyonu yerine sırasıyla parçacık sürü optimizasyonu, genetik algoritma, yapay arı koloni algoritması ve karınca koloni algoritması kullanılmış ve söz konusu yöntemler yeni bir veri seti üzerinde uygulanarak, önerilen yaklaşım ile etkinlikleri karşılaştırılmıştır. Çalışmanın sonucunda, kedi sürü optimizasyonunun bulanık zaman serilerinde ele alınan başta sezgisel yöntemler olmak üzere birçok çalışmaya göre oldukça etkin olabileceği sonucuna varılmıştır.

Anahtar Kelimeler: bulanık zaman serileri, kedi sürüsü optimizasyonu, destek vektör makineleri

ABSTRACT

A NEW FUZZY TIME SERIES APPROACH BASED ON CAT SWARM OPTIMIZATION

Yasemin Burcu GÜNDOĞDU

Doctor of Statistics, Department of Statistics

Supervisor: Doç. Dr. Çağdaş Hakan ALADAĞ

June 2018, 83 pages

Since there are no theoretical constraints such as the model assumption and the number of observations, the importance of the preferred fuzzy time series instead of classical time series is day by day increasing in analysis of data containing uncertainty. In obtaining predictions in fuzzy time series, basically three stages are used in the form of fuzzification, determination of fuzzy relations and defuzzification. There are many studies on the development of each of these three phases in the literature. Most of these studies are based on heuristic optimization methods such as particle swarm optimization, genetic algorithm. In this study, unlike other studies in the literature on fuzzy time series, a new approach has been proposed based on cat swarm optimization in the determination of cluster centers and support vector machine in determining of fuzzy relations. The effectiveness of this new proposed approach based on cat swarm optimization, was firstly assessed on the data commonly used in the literature. Then, respectively particle swarm optimization, genetic algorithm, artificial bee colony algorithm and ant colony algorithm were used instead of cat swarm optimization in the determination of cluster centers and these methods were applied on a new data set and the effectiveness of these methods was compared with the proposed approach. As the result of study, it has been concluded that the cat swarm optimization can be quite effective compared to many studies, especially the heuristic methods discussed in the fuzzy time series.

Keywords: fuzzy time series, cat swarm optimization, support vector machine

TEŞEKKÜR

Tez çalışmamın her aşamasında desteklerini benden esirgemeyen ve değerli katkıları ile beni yönlendiren danışman hocam Sayın Doç. Dr. Çağdaş Hakan ALADAĞ'a ve Sayın Dr. Öğr. Üyesi İbrahim ZOR'a,

Tez çalışmam sırasında işyerinde göstermiş oldukları anlayış ve desteklerinden dolayı Daire Başkanım Sayın Ali Caner GÜRER'e, Sayın Murat SAVAŞ'a ve Sayın Buse PEKALP'e,

Varlıklarından güç aldığım ve hayatımın her aşamasında olduğu gibi çalışmam boyunca da maddi ve manevi desteklerini bir an olsun esirgemeyen canım ailem, annem Nurhan AÇIL, babam Ahmet AÇIL, kardeşim Duygu AÇIL'a, sevgili eşim Erkan GÜNDOĞDU'ya ve hayattaki yegâne mutluluğum biricik kızım Mira GÜNDOĞDU'ya,

içtenlikle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
TABLolar	vi
ŞEKİLLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. BULANIK MANTIK	4
2.1. Bulanık Mantık ve Bulanık Küme Teorisi	4
2.1.1. Bulanık kümelerde temel kavramlar	6
2.1.2. Bulanık kümelerde temel işlemler	8
2.2. Bulanık Mantık ve Bulanık Sayılar	9
2.2.1. Bulanık sayılarda işlemler	10
2.2.2. Bulanık sayı çeşitleri	11
2.2.2.1. L-R bulanık sayıları	11
2.2.2.2. Üçgensel bulanık sayılar	12
2.2.2.3. Yamuksal bulanık sayılar	14
3. SEZGİSEL OPTİMİZASYON	16
3.1. Kedi Sürüşü Optimizasyonu	16
3.1.1. Arama Modu	17
3.1.2. İzleme Modu	18
3.1.3. Kedi Sürüşü Optimizasyonu Algoritması	19
3.2. Parçacık Sürü Optimizasyonu	20
3.3. Genetik Algoritma	21
3.4. Yapay Arı Koloni Algoritması	22
3.5. Karınca Koloni Algoritması	24
4. DESTEK VEKTÖR MAKİNELERİ	26
4.1. Doğrusal Destek Vektör Makineleri	27
4.2. Doğrusal Olmayan Destek Vektör Makineleri	30
5. BULANIK ZAMAN SERİLERİ	32

5.1. Bulanık Zaman Serileri Kavramı.....	32
5.2. Bulanık Zaman Serileri Modelleri	33
5.3. Bulanık Zaman Serilerinde Önerilen Yöntem	40
6. BULGULAR VE TARTIŞMA	47
6.1. Alabama Üniversitesi Verileri Üzerine Uygulama	49
6.2. TAIFEX Verileri Üzerine Uygulama	51
6.3. İMKB Verileri Üzerine Uygulama.....	54
6.4. Dış Ticaret Hadleri Verileri Üzerine Uygulama	63
7. SONUÇ VE ÖNERİLER	70
KAYNAKLAR.....	72
EKLER	78
ÖZGEÇMİŞ	83

TABLÖLAR

Tablo 1. Uygulamada kullanılan zaman serileri	47
Tablo 2. Uygulamalarda kullanılan kedi sürüşü optimizasyonuna ilişkin parametreler	48
Tablo 3. “Alabama Üniversitesi kayıt verileri” zaman serisi.....	49
Tablo 4. Alabama Üniversitesi kayıt verileri eğitim kümesi için yöntemlerin öngörülleri	50
Tablo 5. “TAIFEX” zaman serisi.....	51
Tablo 6. Test kümesi için TAIFEX değerleri ve yöntemlerin öngörülleri.....	53
Tablo 7. Veri seti 1 için İMKB verileri ve yöntemlerin öngörülleri	55
Tablo 8. Veri seti 2 için İMKB verileri ve yöntemlerin öngörülleri	56
Tablo 9. Veri seti 3 için İMKB verileri ve yöntemlerin öngörülleri	56
Tablo 10. Veri seti 4 için İMKB verileri ve yöntemlerin öngörülleri	58
Tablo 11. Veri seti 5 için İMKB verileri ve yöntemlerin öngörülleri	59
Tablo 12. Veri seti 6 için İMKB verileri ve yöntemlerin öngörülleri	59
Tablo 13. “Dış Ticaret Hadleri” zaman serisi.....	63
Tablo 14. Veri seti 7 için beş farklı yöntemin DTH verileri test kümesine ilişkin en iyi sonuçlar	65
Tablo 15. Veri seti 8 için beş farklı yöntemin DTH verileri test kümesine ilişkin en iyi sonuçlar	66
Tablo 16. Önerilen yöntem ile diğer sezgisel yöntemlerin DTH verileri simülasyon sonuçları.....	67

ŞEKİLLER

Şekil 1. L-R tipindeki bulanık sayı	12
Şekil 2. Üçgensel bulanık sayı	13
Şekil 3. Yamuksal bulanık sayı	14
Şekil 4. Destek Vektör Makinelerinin ağ yapısı	26
Şekil 5. Doğrusal ayrılabilme durumunda ayırıcı hiper düzlem	27
Şekil 6. Doğrusal ayrılamama durumunda ayırıcı hiper düzlem.....	30
Şekil 7. k. kedinin X_k pozisyon vektörünün grafiksel gösterimi	41
Şekil 8. k. kedinin V_k hız vektörünün grafiksel gösterimi.....	41
Şekil 9. Akış Diyagramı.....	46
Şekil 10. Alabama Üniversitesi kayıt verileri ile öngörülerinin birlikte grafiği	51
Şekil 11. TAIFEX verilerine ilişkin test kümesinin gözlemleri ile öngörülerinin birlikte grafiği	54
Şekil 12. Veri seti 1 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	61
Şekil 13. Veri seti 2 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	61
Şekil 14. Veri seti 3 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	61
Şekil 15. Veri seti 4 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	62
Şekil 16. Veri seti 5 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	62
Şekil 17. Veri seti 6 için İMKB değerleri ve öngörülerinin birlikte grafiği.....	62
Şekil 18. Veri seti 7 için en iyi model (ksodvm) için test kümesi ile öngörülerinin birlikte grafiği	67
Şekil 19. Veri seti 8 için en iyi model (ksodvm) için test kümesi ile öngörülerinin birlikte grafiği	67

SİMGELER VE KISALTMALAR

Simgeler

$[a, b]$	Kapalı aralık
$[a,b), (a, b]$	Yarı açık aralık
$\{ \}$	Küme
μ	Mü
$/$	Koşul / Bölme
$\tilde{A}$	Bulanık küme
Σ	Toplam
$\int$	İntegral
Supp	Destek
Core	Çekirdek
hgt	Yükseklik
α	Alfa
λ	Lambda
min	Minimum
max	Maksimum
$\in$	Elemanı
$\notin$	Elemanı değil
$\cap$	Kesişim
$\cup$	Birleşim
$\leq$	Küçük ve eşit
$<$	Küçük
$>$	Büyük
$\geq$	Büyük ve eşit
$+$	Artı
$-$	Eksi
$*$	Çarpma
$\times$	Kartezyen çarpım
$\cdot$	İç çarpım
$ a $	Mutlak değer
$=$	Eşit

$\neq$	Eşit değil
$\Re$	Gerçek sayılar
$\Re^-$	Negatif gerçel sayılar
$\Re^+$	Pozitif gerçel sayılar
∞	Sonsuz
θ	Teta
β	Beta
γ	Gamma
T	Transpoz
F(t)	Bulanık zaman serisi
Sgn(x)	İşaret (Signum) fonksiyonu

Kısaltmalar

L-R	Sol taraf (left side)-Sağ taraf (right side)
KSO, kso	Kedi sürüşü optimizasyonu
AHH	Arama hafızası havuzu
DBS	Değişen boyutların sayısı
KO	Karışım oranı
KPD	Kendi pozisyonunu değerlendirme
SBA	Seçilen boyutun arama aralığı
UD	Uygunluk değeri
TAIFEX	Taiwan Futures Exchange (Taiwan Vadeli İşlem Borsası)
İMKB	İstanbul Menkul Kıymetler Borsası
DTH	Dış ticaret hadleri
HKO	Hata kareler ortalaması
HKOK	Hata kareler ortalamasının karekökü
OMYH	Ortalama mutlak yüzdeler hata
YD	Yön doğruluğu
MLP	Multiple layer perception (Çok katmanlı algılayıcı)
dvm	Destek vektör makineleri
pso	Parçacık sürü optimizasyonu
ga	Genetik algoritma
yaka	Yapay arı koloni algoritması

kka	Karınca koloni algoritması
ksodvm	Kedi sürüsü optimizasyonu - Destek vektör makineleri (Önerilen yöntem)
psodvm	Parçacık sürü optimizasyonu - Destek vektör makineleri (Önerilen yöntemde kso yerine pso'nun kullanıldığı yöntem)
gadvm	Genetik algoritma – Destek vektör makineleri (Önerilen yöntemde kso yerine ga'nın kullanıldığı yöntem)
yakadvn	Yapay arı koloni algoritması – Destek vektör makineleri (Önerilen yöntemde kso yerine yaka'nın kullanıldığı yöntem)
kka	Karınca koloni algoritması – Destek vektör makineleri (Önerilen yöntemde kso yerine kka'nın kullanıldığı yöntem)



1. GİRİŞ

Kişisel düşünceler ile “dilsel değerler” adı verilen ve günlük konuşma dilinde kullanılan sözcükler bazı belirsizlikler içermektedir. Bu şekildeki sözel belirsizliklerin matematiksel olarak modellenmesini sağlamak amacıyla 1965 yılında Zadeh tarafından *bulanık küme teorisi* ortaya atılmıştır.

Karar verme, planlama, mantık, sistem teorisi, yapay zeka, ekonomi, kontrol teorisi gibi birçok alana uygulanabilen bulanık küme teorisinin en önemli uygulama alanlarından birisi ise ilk olarak Song ve Chissom [63] tarafından ortaya atılan *bulanık zaman serileri analizi*dir.

Son yıllarda önemi giderek artan bulanık zaman serisi analizi yöntemleri, model varsayımı ve gözlem sayısı gibi teorik kısıtları içermediği için belirsizlik içeren verilerin olduğu pek çok bilim dalında klasik zaman serilerine tercih edilmektedir [1, 11, 63].

Bulanık zaman serisi öngörü yöntemleri, sırasıyla gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve berraklaştırma olmak üzere üç temel aşamadan oluşmaktadır. Bulanık zaman serilerinde öngörü performansını etkileyen bu üç aşamanın da iyileştirilmesi üzerine literatürde birçok çalışma bulunmaktadır [11, 71].

Evrensel küme parçalanmasına dayalı olarak aralık uzunluklarının belirlendiği bulanıklaştırma aşamasında; Song ve Chissom [63, 64, 65], Chen [18, 19] keyfi, Huarng [41] ortalamaya ve dağılıma dayalı, Eğrioğlu ve ark. [33, 34] optimizasyona dayalı, Davari ve ark. [27], Kuo ve ark. [52, 53], Park ve ark. [62], Hsu ve ark. [39], Huang ve ark. [40], Chen ve Kao [22] parçacık sürü optimizasyonuna dayalı, Chen ve Chung [20], Lee ve ark. [55, 56], Cai ve ark. [16] genetik algoritmaya dayalı, Eğrioğlu ve ark. [36] yapay arı kolonisi algoritmasına dayalı, Cai ve ark. [17] karınca koloni algoritmasına dayalı yaklaşımlar ileri sürmüştür. Aralık uzunluklarındaki değişimin orana dayalı yaklaşımı Huarng ve Yu [42], oranın optimizasyonuna dayalı yaklaşımı ise Yolcu ve ark. [70] tarafından ileri sürülmüştür. Ayrıca Cheng ve ark. [23], Li ve ark. [57], Yolcu [72], Yolcu ve ark. [73], Baş ve ark. [12] tarafından aralık uzunluklarının

belirlenmesinde evrensel küme parçalanmasına ihtiyaç duymayan bulanık C ortalamalar yöntemini kullanan yaklaşımlar önerilmiştir.

Bulanık ilişkilerin belirlenmesi aşamasında; Song ve Chissom [63, 64, 65] tarafından öngörü elde edilmesinde karmaşık matris işlemlerine dayalı bir yöntem önerilmiştir. Chen [18] ise bu karmaşık matris işlemlerinin yerine daha kolay işlemler içeren ve bulanık grup ilişki tablolarına dayanan yeni bir yaklaşım önermiştir. Hwang ve ark. [45], gözlemler arasındaki farka dayalı olarak aritmetik işlem sürecini daha da kolaylaştıran çalışma yapmışlardır. Huarng ve Yu [43], Aladağ ve ark. [3, 4], Eğrioğlu ve ark. [30, 31, 32], Yu ve Huarng [77, 78], Yolcu [72], Yolcu ve ark. [73], Yolcu ve ark. [75] bulanık ilişkilerin belirlenmesinde yapay sinir ağlarını, Aladağ ve ark. [6] parçacık sürü optimizasyonunu, Eğrioğlu [35] genetik algoritmayı kullanan yaklaşımlar önermişlerdir.

Berraklaştırma aşamasında ise genellikle merkezileştirme yöntemi kullanılmış olup, Jilani ve Burney [46, 47], Jilani ve ark. [48] farklı yöntemler kullanmışlardır. Ayrıca Yu [76] ağırlıklandırılmış-trend yöntemini, Huang ve ark. [40] ise bulanık ilişkilerin lokal ve global bilgisine dayalı bir yöntem kullanmıştır.

Bu üç temel aşamanın dışında bulanık zaman serilerinde öngörü elde edilmesinde; literatürde birinci dereceden, yüksek dereceden, tek değişkenli ve çok değişkenli modelleri kullanan çalışmalar yer almaktadır. Song ve Chissom [63, 64, 65], Chen [18], Huarng [41], Huarng ve Yu [42, 43], Cheng ve ark. [23], Li ve ark. [57], Davari ve ark. [27], Yolcu ve ark. [70], Yu ve Huarng [77, 78], Cai ve ark. [16], Chen ve Kao [22], Yolcu ve ark. [73] çalışmalarında birinci dereceden modeller kullanılmıştır. Chen [19], Chen ve Chung [20], Lee ve ark. [55, 56], Jilani ve Burney [46, 47], Jilani ve ark. [48], Aladağ ve ark. [3], Eğrioğlu ve ark. [30, 32], Kuo ve ark. [52, 53], Eğrioğlu ve ark. [33], Park ve ark. [62], Hsu ve ark. [39], Aladağ ve ark. [4], Huang ve ark. [40], Yolcu [72] çalışmalarında yüksek dereceden modeller kullanılmıştır. Song ve Chissom [63, 64, 65], Chen [18, 19], Huarng [41], Huarng ve Yu [42, 43], Chen ve Chung [20], Yolcu ve ark. [70], Aladağ ve ark. [3], Davari ve ark. [27], Yu ve Huarng [78], Aladağ ve ark. [4], Eğrioğlu ve ark. [33, 34], Kuo ve ark. [52, 53], Huang ve ark. [40], Cai ve ark. [16], Chen ve Kao [22], Yolcu ve ark. [73] çalışmalarında tek değişkenli, Lee ve ark. [55, 56], Li ve ark. [57], Eğrioğlu ve ark. [31, 32], Park ve ark. [62], Hsu ve ark. [39] iki değişkenli ve Huarng ve ark. [44], Jilani ve Burney [46, 47], Jilani ve ark. [48], Cheng

ve ark. [23], Eğrioğlu ve ark. [30], Chen ve Chen [21], Yolcu [72] çalışmalarında ise çok değişkenli modeller kullanılmıştır.

Mevsimsel ilişkileri içeren bulanık zaman serileri ise Eğrioğlu ve ark. [31], Aladağ ve ark. [5], Alpaslan ve Cagcag [7] ve Alpaslan ve ark. [8] çalışmalarında ele alınmıştır.

Literatür incelemesi yapıldığında; bulanık zaman serilerinden öngörü elde edilmesinde birçok sezgisel optimizasyon yönteminin kullanıldığı ve bu sezgisel yöntemlerden özellikle parçacık sürü optimizasyonu ve genetik algoritmanın, çalışmaların çoğunluğunu oluşturduğu görülmektedir. Bunun dışında özellikle son yıllarda Yolcu ve ark. [74] tarafından yapay arı koloni algoritmasına ve Cai ve ark. [17] tarafından ise karınca koloni algoritmasına dayalı yaklaşımlar da ileri sürülmüştür. Bu çalışma kapsamında ise bulanık zaman serilerinde, literatürde yer alan sezgisel yöntemlerden farklı olarak kedi sürüsü optimizasyonu yöntemi kullanılmış ve diğer yöntemlere göre öngörü performansı değerlendirilmiştir.

Çalışmanın birinci bölümünde bulanık zaman serilerine kısa bir giriş yapılmış, klasik zaman serilerinden farkı belirtilmiş ve konu ile ilgili literatürde yer alan çalışmalarda kullanılan yöntemlerden kısaca bahsedilmiştir. İkinci bölümde, bulanık mantık ile bulanık sayılar, üçüncü bölümde başta kedi sürüsü optimizasyonu olmak üzere çalışma kapsamında kullanılacak olan sezgisel yöntemlerden bahsedilmiştir. Dördüncü bölümde ise destek vektör makineleri kavramı kısaca tanıtılmıştır. Beşinci bölümde, bulanık zaman serileri kavramı detaylı bir şekilde anlatılmıştır. Ayrıca yine bu bölümde kedi sürüsü optimizasyonuna dayalı yeni bir bulanık zaman serisi yaklaşımı ileri sürülmüştür. Altıncı bölümde, ileri sürülen yönteme ilişkin ilk olarak literatürde yer alan veriler üzerinden uygulamalara yer verilmiştir. Daha sonra bulanık zaman serilerine ilişkin literatürde yer alan ve bu kapsamda daha önce kullanılmış olan sezgisel yöntemler ile önerilen yaklaşımın karşılaştırılabilmesi açısından yeni bir veri seti üzerinden uygulamalar yürütülmüştür. Yedinci ve son bölümde ise söz konusu uygulamalar kapsamında elde edilen sonuçlar ve öneriler değerlendirilmiştir.

2. BULANIK MANTIK

1965 yılında Zadeh tarafından ileri sürülen ve birçok araştırmada kullanılan bulanık mantık, belirsizliklerin anlatılabilmesi için kurulmuş bir matematik düzen olarak tanımlanmaktadır [1]. Bulanık mantık, kesin doğru ya da kesin yanlış ifadelerini içeren klasik mantıktan farklı olarak, kesin doğru ile kesin yanlış arasındaki sonsuz sayıda değerleri de içermektedir. Zadeh [79] çalışmasında tanımlanan bulanık mantıkta; büyük, küçük, çok, az gibi dilsel ifadeler kullanılmakta ve her şey 0 ile 1 arasındaki üyelik dereceleri ile ifade edilmektedir [13].

2.1. Bulanık Mantık ve Bulanık Küme Teorisi

Bulanık kümeler, verileri kesin olmayan problemlere çözüm üretmek amacıyla geliştirilmiştir. Örneğin 1.85 boyundaki bir erkek çok rahat olarak “uzun boylu erkekler” kümesine dâhil edilebilmektedir ancak 1.80 boyundaki bir erkeğin bu kümeye dâhil olup olmayacağı bilinmemektedir. Çünkü “uzun” kavramının sınırları net olarak belirtilmiştir. Bu ve benzeri durumlarla günlük hayatta defalarca karşılaşılmaktadır. Böyle durumlar keskin kümeler olarak da adlandırılan klasik kümelerle iyi bir şekilde ifade edilememektedir. Çünkü herhangi bir klasik kümedeki eleman o kümeye aittir ya da ait değildir. Fakat klasik kümelerin genelleştirilmiş şekli olan bulanık kümelerde bir eleman birden fazla kümenin elemanı olabilmektedir [1].

Klasik kümelerde bir elemanın o kümeye ait olup olmaması karakteristik fonksiyon ile tanımlanmaktadır. X evrensel, Y ise klasik küme olmak üzere karakteristik fonksiyon;

$$\mu_Y(x): X \rightarrow \{0,1\} \quad (2.1)$$

biçiminde tanımlanmaktadır. Eşitlik (2.1) evrensel kümeden $\{0,1\}$ kümesine bir fonksiyon olarak tanımlanabilmektedir. Burada $\mu_Y(x)=1$ ise x , Y kümesinin elemanıdır ve $\mu_Y(x)=0$ ise x , Y kümesinin elemanı değildir, yani klasik kümelerde bir eleman bir kümeye ya aittir ya da değildir.

Bulanık kümelerde, karakteristik fonksiyon yerini genelleştirilmiş şekli olan üyelik fonksiyonuna bırakmaktadır. Bu durumda, X evrensel, $\tilde{Y}$ bulanık küme olmak üzere üyelik fonksiyonu;

$$\mu_{\tilde{Y}}(x): X \rightarrow [0,1] \quad (2.2)$$

biçiminde tanımlanmaktadır. Bulanık kümelerde elemanlar, klasik kümelerden farklı olarak 0 ile 1 arasındaki üyelik dereceleri ile kümeye ait olmaktadır.

x elemanının $\tilde{Y}$ bulanık kümesindeki üyelik derecesi $\mu_{\tilde{Y}}(x)$ olmak üzere;

$$\tilde{Y} = \{\mu_{\tilde{Y}}(x)/x\}, x \in X \quad (2.3)$$

ya da

$$\tilde{Y} = \{\mu_{\tilde{Y}}(x), x\}, x \in X \quad (2.4)$$

biçiminde ifade edilmektedir. Eşitlik (2.3) ve Eşitlik (2.4)'deki $\mu_{\tilde{Y}}(x)$, $[0,1]$ aralığında bir gerçel sayıdır. $\mu_{\tilde{Y}}(x)$ değeri ne kadar bire yaklaşırsa, x elemanının $\tilde{Y}$ bulanık kümesine üyeliği de o kadar artmaktadır. Bu durumda $X = \{x_1, x_2, \dots, x_n\}$ sonlu bir evrensel küme olmak üzere X 'deki bulanık küme $\tilde{Y}$,

$$\tilde{Y} = \{\mu_{\tilde{Y}}(x_i)/x_i\} = \{\mu_{\tilde{Y}}(x_1)/x_1 + \mu_{\tilde{Y}}(x_2)/x_2 + \dots + \mu_{\tilde{Y}}(x_n)/x_n\} = \left\{ \sum_{i=1}^n \mu_{\tilde{Y}}(x_i)/x_i \right\} \quad (2.5)$$

biçiminde ifade edilmektedir [13]. Eşitlik (2.5)'deki bölünme işareti, bölme işlemini değil alttaki elemana üstteki üyelik derecesinin karşılık geldiğini göstermektedir.

Eğer yukarıda tanımlanan X evrensel kümesi sonlu değilse, buna ait bulanık küme $\tilde{Y}$,

$$\tilde{Y} = \int_{x \in X} \mu_{\tilde{Y}}(x) / x \quad (2.6)$$

biçiminde ifade edilmektedir. Eşitlik (2.5) ve Eşitlik (2.6)'daki $\sum$ ve $\int$ sembolleri sırasıyla toplam ve integral anlamında kullanılmayıp üyelik fonksiyonlarının birleşimini ifade etmektedir [10].

2.1.1. Bulanık kümelerde temel kavramlar

(1) Bulanık kümenin desteği: $\tilde{Y}$ bulanık kümesinin desteği, üyelik derecesi sıfır olmayan elemanlarından oluşmaktadır ve

$$Supp(\tilde{Y}) = \{x \in X \mid \mu_{\tilde{Y}}(x) > 0\} \quad (2.7)$$

biçiminde ifade edilmektedir [10].

(2) Bulanık kümenin çekirdeği: $\tilde{Y}$ bulanık kümesinin çekirdeği, üyelik derecesi 1'e eşit olan elemanlarından oluşmaktadır ve

$$Core(\tilde{Y}) = \{x \in X \mid \mu_{\tilde{Y}}(x) = 1\} \quad (2.8)$$

biçiminde ifade edilmektedir [68].

(3) Bulanık kümenin alfa kesmesi: Alfa kesimler, bulanık kümelerden klasik kümeler (bulanık olmayan kümeler) üreten dilimlerdir [15]. $\tilde{Y}$ bulanık kümesinin α 'dan büyük üyelik derecesine sahip elemanlarının oluşturduğu güçlü α kesmesi,

$$\tilde{Y}_{\alpha} = \{x \in X \mid \mu_{\tilde{Y}}(x) > \alpha\}, \quad \alpha \in (0,1] \quad (2.9)$$

biçiminde ifade edilmektedir. $\tilde{Y}$ bulanık kümesinin α 'ya eşit ve α 'dan büyük üyelik derecesine sahip elemanlarının oluşturduğu zayıf α kesmesi ise,

$$\tilde{Y}_\alpha = \{x \in X \mid \mu_{\tilde{Y}}(x) \geq \alpha\}, \alpha \in (0,1] \quad (2.10)$$

biçiminde ifade edilmektedir [51].

(4) Bulanık kümenin yüksekliği: $\tilde{Y}$ bulanık kümesinin yüksekliği, elemanlarının üyelik derecesi en büyük olanıdır ve

$$hgt(\tilde{Y}) = \sup_{x \in X} \mu_{\tilde{Y}}(x) \quad (2.11)$$

biçimindedir. Eşitlik (2.11)'deki $\tilde{Y}$ bulanık kümesinin yüksekliği 1'e eşitse bu küme, normal bulanık kümedir [10].

(5) Bulanık kümenin konveksliği: $\tilde{Y}$ bulanık kümesi $x_1, x_2 \in X$ ve $\lambda \in [0,1]$ için

$$\mu_{\tilde{Y}}(\lambda x_1 + (1-\lambda)x_2) \geq \min(\mu_{\tilde{Y}}(x_1), \mu_{\tilde{Y}}(x_2)) \quad (2.12)$$

eşitliğini sağlıyorsa konveks bulanık kümedir [28].

(6) Bulanık kümenin tümleyeni: $\tilde{Y}$ bulanık kümesinin tümleyeninin üyelik fonksiyonu $\mu_{\tilde{Y}^c}(x)$,

$$\mu_{\tilde{Y}^c}(x) = 1 - \mu_{\tilde{Y}}(x), x \in X \quad (2.13)$$

biçiminde ifade edilmektedir [80].

(7) Bulanık kümenin m. kuvveti: $\tilde{Y}$ bulanık kümesinin m. kuvvetinin üyelik fonksiyonu,

$$\mu_{\tilde{Y}^m}(x) = [\mu_{\tilde{Y}}(x)]^m, x \in X \quad (2.14)$$

biçimindedir [28].

2.1.2. Bulanık kümelerde temel işlemler

$\tilde{Y}$ ve $\tilde{Z}$, evrensel küme X 'in iki farklı bulanık alt kümesi olmak üzere bulanık kümelerde bazı işlemler aşağıdaki gibi tanımlanabilmektedir.

(1) Bulanık kümelerin eşitliği: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin eşitliği $\tilde{Y} = \tilde{Z}$ şeklinde gösterilmekte olup üyelik fonksiyonları,

$$\mu_{\tilde{Y}}(x) = \mu_{\tilde{Z}}(x), \quad x \in X \quad (2.15)$$

biçiminde ifade edilmektedir [10].

(2) Bulanık kümelerin kesişimi: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin kesişimi $\tilde{Y} \cap \tilde{Z}$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{Y} \cap \tilde{Z}}(x) = \min \{ \mu_{\tilde{Y}}(x), \mu_{\tilde{Z}}(x) \}, \quad x \in X \quad (2.16)$$

biçiminde ifade edilmektedir [28].

(3) Bulanık kümelerin birleşimi: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin birleşimi $\tilde{Y} \cup \tilde{Z}$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{Y} \cup \tilde{Z}}(x) = \max \{ \mu_{\tilde{Y}}(x), \mu_{\tilde{Z}}(x) \}, \quad x \in X \quad (2.17)$$

biçiminde ifade edilmektedir [28].

(4) Bulanık kümelerde kapsama: $\tilde{Z}$ bulanık kümesinin $\tilde{Y}$ bulanık kümesini kapsama durumu $\tilde{Y} \subseteq \tilde{Z}$ biçiminde gösterilmekte olup,

$$\mu_{\tilde{Y}}(x) \leq \mu_{\tilde{Z}}(x), \quad x \in X \quad (2.18)$$

eşitliğini sağlaması gerekmektedir [68].

(5) Bulanık kümelerde cebirsel çarpım: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin cebirsel çarpımı $\tilde{Y} \cdot \tilde{Z}$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{Y} \cdot \tilde{Z}}(x) = \mu_{\tilde{Y}}(x) \cdot \mu_{\tilde{Z}}(x), \quad x \in X \quad (2.19)$$

biçiminde ifade edilmektedir [80].

(6) Bulanık kümelerde cebirsel toplam: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin cebirsel toplamı $\tilde{Y} + \tilde{Z}$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{Y} + \tilde{Z}}(x) = \mu_{\tilde{Y}}(x) + \mu_{\tilde{Z}}(x) - \mu_{\tilde{Y}}(x) \cdot \mu_{\tilde{Z}}(x), \quad x \in X \quad (2.20)$$

biçiminde ifade edilmektedir [80].

(7) Bulanık kümelerde fark: $\tilde{Y}$ ve $\tilde{Z}$ bulanık kümelerinin farkı $\tilde{Y} - \tilde{Z}$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{Y} - \tilde{Z}}(x) = \min \{ \mu_{\tilde{Y}}(x), \mu_{\tilde{Z}^c}(x) \} = \min \{ \mu_{\tilde{Y}}(x), 1 - \mu_{\tilde{Z}}(x) \}, \quad x \in X \quad (2.21)$$

biçiminde ifade edilmektedir [80]. Eşitlik (2.21)'deki $\tilde{Z}^c$, $\tilde{Z}$ bulanık kümesinin tümleyenidir.

2.2. Bulanık Mantık ve Bulanık Sayılar

Gerçek sayılarda tanımlı, kapalı ve konveks bir alt küme olan $\tilde{Y}$ bulanık sayısı $[y, k]$ sınırları ile tanımlanabilmektedir. Burada y alt sınırı, k ise üst sınırı vermektedir. Dolayısıyla bulanık sayının sol tarafı $y: [0,1] \rightarrow \mathfrak{R}$ monoton artan iken sağ tarafı $k: [0,1] \rightarrow \mathfrak{R}$ monoton azalandır.

2.2.1. Bulanık sayılarda işlemler

$[y, k]$ kapalı, sınırlı ve gerçel sayıların aralığı olmak üzere, α kesme işleminin bulanık sayılara uygulanması aşağıda verilmektedir.

$\tilde{Y}$ bulanık sayısı için α kesme aralığı Y_α ,

$$\tilde{Y}_\alpha = [y^\alpha, k^\alpha] \quad (2.22)$$

biçiminde ifade edilmektedir [13].

(1) Bulanık sayılarda toplama işlemi: $\tilde{Y}$ ve $\tilde{Z}$ herhangi iki bulanık sayı, Y_α ve Z_α , $\alpha \in [0, 1]$ için güven aralıkları olarak verilsin. Bu durumda,

$$Y_\alpha(+)Z_\alpha = [y_1^\alpha, k_1^\alpha](+)[y_2^\alpha, k_2^\alpha] = [y_1^\alpha + y_2^\alpha, k_1^\alpha + k_2^\alpha] \quad (2.23)$$

biçimindedir [50].

(2) Bulanık sayılarda çıkarma işlemi: $\tilde{Y}$ ve $\tilde{Z}$ herhangi iki bulanık sayı, Y_α ve Z_α , $\alpha \in [0, 1]$ için güven aralıkları olarak verilsin. Bu durumda,

$$Y_\alpha(-)Z_\alpha = [y_1^\alpha, k_1^\alpha](-)[y_2^\alpha, k_2^\alpha] = [y_1^\alpha - k_2^\alpha, k_1^\alpha - y_2^\alpha] \quad (2.24)$$

biçimindedir [50].

(3) Bulanık sayılarda çarpma işlemi: Çarpma işlemi, $\Re^+$ pozitif gerçel sayılar ve $\mathbb{N}$ doğal sayılar kümesi, $\tilde{Y}$ ve $\tilde{Z}$, $\Re^+$ 'da tanımlı herhangi iki bulanık sayı olmak üzere çarpma işlemi;

$$Y_\alpha(.)Z_\alpha = [y_1^\alpha, k_1^\alpha](.)[y_2^\alpha, k_2^\alpha] = [y_1^\alpha \cdot y_2^\alpha, k_1^\alpha \cdot k_2^\alpha] \quad (2.25)$$

biçimindedir. Eğer $\tilde{Y}$ ve $\tilde{Z}$, $\Re^+$ 'da tanımlı herhangi iki bulanık sayı ise çarpma işlemi,

$$Y_{\alpha}(\cdot)Z_{\alpha} = [\min(y_1^{\alpha} \cdot y_2^{\alpha}, y_1^{\alpha} \cdot k_2^{\alpha}, k_1^{\alpha} \cdot y_2^{\alpha}, k_1^{\alpha} \cdot k_2^{\alpha}), \max(y_1^{\alpha} \cdot y_2^{\alpha}, y_1^{\alpha} \cdot k_2^{\alpha}, k_1^{\alpha} \cdot y_2^{\alpha}, k_1^{\alpha} \cdot k_2^{\alpha})] \quad (2.26)$$

biçiminde hesaplanmaktadır [50].

(4) Bulanık sayılarda bölme işlemi: $\Re^+$ pozitif gerçel sayılardaki herhangi iki bulanık sayının bölümü;

$$Y_{\alpha}(/)Z_{\alpha} = [y_1^{\alpha}, k_1^{\alpha}](/)[y_2^{\alpha}, k_2^{\alpha}] = [y_1^{\alpha}/k_2^{\alpha}, k_1^{\alpha}/y_2^{\alpha}] \quad (2.27)$$

biçimindedir. Eğer bu sayılar $\Re^-$ negatif gerçel sayılarda tanımlı ise bölme işlemi, $y_2^{\alpha} \neq 0, k_2^{\alpha} \neq 0$ olmak üzere,

$$Y_{\alpha}(/)Z_{\alpha} = [\min(y_1^{\alpha}/y_2^{\alpha}, y_1^{\alpha}/k_2^{\alpha}, k_1^{\alpha}/y_2^{\alpha}, k_1^{\alpha}/k_2^{\alpha}), \max(y_1^{\alpha}/y_2^{\alpha}, y_1^{\alpha}/k_2^{\alpha}, k_1^{\alpha}/y_2^{\alpha}, k_1^{\alpha}/k_2^{\alpha})] \quad (2.28)$$

biçiminde hesaplanmaktadır [50].

2.2.2. Bulanık sayı çeşitleri

Bulanık kümeler üyelik fonksiyonlarıyla tanımlandığı için bulanık sayılar kadar üyelik fonksiyonu bulunmaktadır [50].

2.2.2.1. L-R bulanık sayıları

Dubois ve Prade [28] tarafından önerilen L (left side-sol taraf) ya da R (right side-sağ taraf) bulanık sayısı,

$$i) L(-x) = L(x)$$

$$ii) L(0) = 1$$


$$iii) L, [0, +\infty) \text{ aralığında artan}$$

şartlarını sağlarsa bir bulanık sayı olarak ifade edilmektedir.

L-R tipindeki bir $\tilde{A} = (a, b, c)$ bulanık sayısının üyelik fonksiyonu;

$$\mu_{\tilde{A}}(x) = \begin{cases} L\left(\frac{b-x}{a}\right), & x \leq b, a > 0 \\ R\left(\frac{x-b}{c}\right), & x \geq b, c > 0 \end{cases} \quad (2.29)$$

biçiminde ifade edilmektedir. Eşitlik (2.29)'daki b , $\tilde{A}$ bulanık sayısının orta, a ve c ise sırasıyla sol ve sağ yayılım değerleridir. $a = c = 0$ olduğunda, A , bir b keskin sayısı olmaktadır [28, 38]. L-R tipindeki bulanık sayılar Şekil 1'de verilmektedir.




Şekil 1. L-R tipindeki bulanık sayı

2.2.2.2. Üçgensel bulanık sayılar

Üçgensel bulanık sayı $\tilde{A} = (a, b, c)$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{A}}(x) = \begin{cases} (x-a)/(b-a), & a \leq x \leq b \text{ ise} \\ (c-x)/(c-b), & b \leq x \leq c \text{ ise} \\ 0, & \text{d.d.} \end{cases} \quad (2.30)$$

biçiminde ifade edilmekte ve Şekil 2'de gösterilmektedir [13, 38].



Şekil 2. Üçgensel bulanık sayı

Üçgensel bulanık sayılarda aritmetik işlemler α kesmeleri kullanılarak ya da aralık işlemleri kullanılarak yapılabilmektedir [13].

$\tilde{Y} = (y_1, y_2, y_3)$ ve $\tilde{Z} = (z_1, z_2, z_3)$ şeklinde iki üçgensel bulanık sayı olmak üzere $\tilde{Y}$ ve $\tilde{Z}$ bulanık sayılarının,

(1) Toplama işlemi:

$$\tilde{Y}(+) \tilde{Z} = (y_1 + z_1, y_2 + z_2, y_3 + z_3) \quad (2.31)$$

(2) Çıkarma işlemi:

$$\tilde{Y}(-) \tilde{Z} = (y_1 - z_3, y_2 - z_2, y_3 - z_1) \quad (2.32)$$

(3) Çarpma işlemi:

$$\tilde{Y}(\cdot) \tilde{Z} = (y_1 \cdot z_1, y_2 \cdot z_2, y_3 \cdot z_3) \quad (2.33)$$

(4) Bölme işlemi:

$$\tilde{Y}(/) \tilde{Z} = (y_1 / z_3, y_2 / z_2, y_3 / z_1) \quad (2.34)$$

$\tilde{Y}$ bulanık sayısının m gibi bir sabite bölümü,

$$\tilde{Y}(/m) = (y_1/m, y_2/m, y_3/m), \quad m > 0 \quad (2.35)$$


biçiminde ifade edilmektedir [49, 61].

2.2.2.3. Yamuksal bulanık sayılar

Yamuksal bulanık sayı $\tilde{A} = (a, b, c, d)$ 'nin üyelik fonksiyonu,

$$\mu_{\tilde{A}}(x) = \begin{cases} 0, & x < a \text{ ve } x > d \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \end{cases} \quad (2.36)$$

biçiminde ifade edilmektedir ve Şekil 3'de gösterilmektedir [13, 38].



Şekil 3. Yamuksal bulanık sayı

$\tilde{Y} = (y_1, y_2, y_3, y_4)$ ve $\tilde{Z} = (z_1, z_2, z_3, z_4)$ şeklinde iki yamuksal bulanık sayı olmak üzere $\tilde{Y}$ ve $\tilde{Z}$ bulanık sayılarının,

(1) Toplama işlemi:

$$\tilde{Y}(+)\tilde{Z} = (y_1 + z_1, y_2 + z_2, y_3 + z_3, y_4 + z_4) \quad (2.37)$$

(2) Çıkarma işlemi:

$$\tilde{Y}(-)\tilde{Z} = (y_1 - z_4, y_2 - z_3, y_3 - z_2, y_4 - z_1) \quad (2.38)$$

(3) Çarpma işlemi:

$$\tilde{Y}(\cdot)\tilde{Z} = (y_1 \cdot z_1, y_2 \cdot z_2, y_3 \cdot z_3, y_4 \cdot z_4) \quad (2.39)$$

(4) Bölme işlemi:

$$\tilde{Y}(/)\tilde{Z} = (y_1 / z_4, y_2 / z_3, y_3 / z_2, y_4 / z_1) \quad (2.40)$$

biçiminde elde edilmektedir.

3. SEZGİSEL OPTİMİZASYON

Optimizasyon, bir problemin çözümünde verilen amaç için belirli kısıtlamalar altında tüm çözümler arasından en uygun çözümün elde edilme sürecidir. Klasik yöntemler, bazı problemlerin çözümünde esnek değildir ve bu problemlerin matematiksel fonksiyonlarla tanımlanması gibi kısıtları içermektedir. Sezgisel yöntemler, hem basit olması hem de kesin çözümü bulma gibi bir zorunluluk içermemesi sebebiyle klasik yöntemlere göre karar vericiler açısından daha çok tercih edilmektedir. Bu açıdan sezgisel yöntemler özellikle son yıllarda oldukça önem kazanmıştır [2, 59].

Literatürde sezgisel yöntemlere ilişkin birçok algoritma bulunmaktadır. Ancak daha sonraki bölümlerde kullanılacak olması sebebiyle bu çalışmada sadece biyolojik tabanlı olan Genetik Algoritma ile sürü tabanlı olan Parçacık Sürü Optimizasyonu, Karınca Koloni Algoritması ve Yapay Arı Koloni Algoritmasından kısaca bahsedilmiştir. Bulanık zaman serilerine ilişkin literatürde yer alan söz konusu bu yöntemlerin ele alınmasının sebebi, bu çalışmada bulanık zaman serileri literatüründe ilk defa önerilen Kedi Sürüsü Optimizasyonu yöntemi ile etkinliklerinin karşılaştırılmasıdır.

3.1. Kedi Sürüsü Optimizasyonu

Kedi Sürüsü Optimizasyonu (Cat Swarm Optimization); 2006 yılında Chu, Tsai ve Pan tarafından kedilerin davranışlarının gözlenmesi ile ortaya çıkarılan ve kedilerin davranışlarının çözümlenmesiyle arama ve izleme modu şeklinde iki alt model oluşturulan sürü zekâsına dayalı bir algoritma yöntemidir.

Biyolojik sınıflandırmaya göre, aslan, kaplan, leopar, kedi gibi yaklaşık 32 tane farklı kedigil türü bulunmaktadır. Bu kedigillerin yaşam alanları farklı olmasına rağmen birçok davranışı birbirine benzemektedir. Kedigillerin avlanma becerileri kalıtsal olmamasına rağmen bu konuda eğitilmeleri mümkün olmaktadır. Vahşi kedigillerin avlanma becerisi, kendi ırkının hayatta kalmasını sağlamaktadır. Evcil kediler ise hareket eden herhangi bir şeye karşı doğası gereği güçlü bir merak sergilemektedir. Ancak bu güçlü meraklarına rağmen tüm kediler zamanlarının çoğunu hareketsiz yani dinlenme modunda geçirmektedir. Dinlenme zamanları dahi olsa kediler oldukça atik

yaratıklardır. Sürekli etraflarını gözetlemekle birlikte her zaman tetiktedirler. Zeki ve bilinçli yaratıklar olmalarına rağmen genellikle tembel gibi görünmektedirler [24].

Chu, Tsai ve Pan (2006) tarafından önerilen Kedi Sürüsü Optimizasyonu için kedilerin davranışları *arama* ve *izleme* olmak üzere iki mod biçiminde modellenmiş ve bunların birleşimi ile performansın artırılması amaçlanmıştır [25]. Kedi Sürüsü Optimizasyonuna ilişkin Chu, Tsai ve Pan [24] tarafından önerilen algorithmada optimizasyon problemlerinin çözümünde kedilerin davranışları modellenmektedir [24]. Kedi Sürüsü Optimizasyonunun ilk aşamasında kedi sayısına karar verilir, ikinci aşamasında kediler, Kedi Sürüsü Optimizasyonuna uygulanır. Üçüncü aşamasında her bir kedinin pozisyonu, hızı, uygunluk değeri ve bayrağı belirlenir. Dördüncü aşamada kediler bayraklarına göre arama ya da izleme moduna atanır. Son aşamada ise Kedi Sürüsü Optimizasyonunun maksimum iterasyona ulaşınca kadar en iyi çözüm saklamasına bağlı olarak final çözüm, kedilerden birinin en iyi pozisyonu olacaktır [25].

3.1.1. Arama Modu

Kedi Sürüsü Optimizasyonunun alt modu olan Arama Modu; kedinin dinlenme, etrafına bakma ve hareket için bir sonraki pozisyonu arama durumunu modellemektedir. Arama modunda; arama hafızası havuzu (AHH), seçilen boyutun arama aralığı (SBA), değişen boyutların sayısı (DBS) ve kendi pozisyonunu değerlendirme (KPD) biçiminde dört önemli faktör tanımlanmaktadır [24].

AHH, kedilerin arama hafızası büyüklüğünü belirtmek ve kedi tarafından seçilen herhangi bir noktayı göstermek için kullanılmaktadır. SBA seçim yapılan boyutların mutasyon oranını göstermektedir. Bir boyutun mutasyon için seçilmesi durumunda, eski ile yeni sonuçlar arasındaki fark SBA tarafından belirlenen aralık dışında olmamalıdır. DBS boyutlardan ne kadarının değişime uğradığını göstermektedir. KPD ise bir Boolean değeridir ve kedinin yer aldığı noktanın hareket etmesi için uygun nokta olup olmayacağının kararını vermektedir. KPD'nin değerinin doğru ya da yanlış olması AHH'nin değerini etkilememektedir [25].

Arama modunun adımları aşağıda verilmektedir [24]:

Adım 1. $a = AHH$ iken i . kedinin bulunduğu pozisyonundan a kopya oluştur. KPD doğru ise $a = AHH - 1$ olarak ata ve kedinin bulunduğu pozisyonu uygun noktalardan biri olarak hafızada tut.

Adım 2. Kopyaların her biri için, DBS 'ye göre, kedinin bulunduğu pozisyon değerlerinin SBA yüzdelerini rastgele arttırma, azaltma ya da eskisinin yerine koyma biçiminde değiştir.

Adım 3. Her bir nokta için uygunluk değerini hesapla.

Adım 4. Bütün uygunluk değerlerinin eşit olmaması durumunda, Eşitlik (3.1)'i kullanarak, noktaların her birinin seçim olasılığını hesapla, aksi durumda noktaların her birinin seçim olasılığına bir değerini ver.

Adım 5. Uygun noktadan hareket edeceğin noktayı rastgele seçerek, i . kedinin pozisyonu ile yer değiştir.

$$P_m = \frac{|UD_m - UD_k|}{|UD_{max} - UD_{min}|}, \quad 0 < m < a \quad (3.1)$$

Uygunluk fonksiyonunun amacı minimum çözümü bulmak ise $UD_k = UD_{max}$, aksi takdirde $UD_k = UD_{min}$ dir.

3.1.2. İzleme Modu

Hedefi izleyen kedinin durumunun modellenmesi için kullanılan ve Kedi Sürüsü Optimizasyonunun alt modu olan izleme moduna ilişkin adımlar aşağıda verilmektedir [24]:

Adım 1. Her bir boyut için hızları $(v_{i,b})$ Eşitlik (3.2) ile güncelle.

Adım 2. Hızları kontrol et, eğer maksimum hızın üzerinde hız varsa onu maksimum hıza eşitle.

Adım 3. i. kedinin pozisyonunu Eşitlik (3.3) ile güncelle.

$$v_{i,b} = v_{i,b} + r_1 * c_1(x_{eniyi,b} - x_{i,b}), b = 1, 2, \dots, M \quad (3.2)$$

$x_{eniyi,i}$, uygunluk değeri en iyi olan kediye ait pozisyon; $x_{i,b}$, i. kedinin pozisyonu, c_1 , sabit, r_1 ise 0 ile 1 arasında rastgele bir değerdir.

$$x_{i,b} = x_{i,b} + v_{i,b} \quad (3.3)$$

3.1.3. Kedi Sürüşü Optimizasyonu Algoritması

Kedi Sürüşü Optimizasyonunun alt modları olan “arama modu” ile “izleme modu”nu algoritma şeklinde birleştirmek için bir Karışım Oranı (KO) tanımlanması gerekmektedir. Kediler dinlenme zamanında pozisyon değişikliklerini dikkatli ve yavaş bir şekilde yapmakta, hatta bazen aynı pozisyonda kalmaktadırlar. Bu davranış, Kedi Sürüşü Optimizasyonuna arama modu biçiminde yansıtılırken, kedinin hedefi takip etmesi izleme modu biçiminde yansıtılmaktadır. Kedilerin gerçek hayattaki gibi zamanlarının çoğunu arama moduna ayırması için KO'ya küçük değer verilmesi gerekmektedir. Sonuç olarak, Kedi Sürüşü Optimizasyonuna ilişkin algoritma aşağıda verilmektedir [25]:

Adım 1. Kedi sayısı (N) belirlenir ve belirlenen sayıda kedi oluşturulur.

Adım 2. Çözüm uzayının boyut sayısı (M) belirlenerek, kediler rastgele bir şekilde bu çözüm uzayına dağıtılır. Kedilerin hızları, belirlenen hız aralıklarında rastgele oluşturulur. Her bir kediye rastgele bir numara verilir ve kediler bayraklarına göre arama ya da izleme moduna yerleştirilir.

Adım 3. Kedilerin pozisyonları kullanılarak her bir kedinin uygunluk değeri hesaplanır ve amaç fonksiyonuna göre uygunluk değeri en iyi olan kedinin pozisyonu (x_{eniyi}) hafızada saklanır.

Adım 4. Her bir kedi bayrağına göre hareket ettirilir, i. kedi arama modunda ise arama modu, izleme modunda ise izleme modu işlemleri uygulanır.

Adım 5. Tekrar rastgele numara verilen kediler arama ya da izleme moduna yerleştirilir.

Adım 6. Sonlandırma koşulları kontrol edilir, eğer sonuç memnun edici ise program sonlandırılır, aksi takdirde Adım 3 ile Adım 5 arası tekrar edilir.

3.2. Parçacık Sürü Optimizasyonu

1995 yılında Kennedy ile Eberhart'ın ileri sürdüğü Parçacık Sürü Optimizasyonu (Particle Swarm Optimization), kuşların davranışlarının gözlenmesi ve çözümlenmesiyle ortaya atılan sürü zekâsına dayalı bir algoritma yöntemidir.

Yiyecek kaynağını bilmeyen kuşlar, söz konusu kaynağa ne kadar uzaklıkta olduklarını öğrenmeye çalışırlar ve bunun için de kaynağa en yakın kuşu takip ederler. Parçacık Sürü Optimizasyonunda her bir parçacık bir kuşu ifade etmektedir. Ayrıca her parçacığın bulunduğu pozisyonun uygunluk fonksiyonuna uygulanması ile elde edilen bir uygunluk değeri bulunmaktadır. Bu değer parçacığın yani kuşun yiyecek kaynağına ne kadar uzaklıkta bulunduğunu göstermektedir.

Parçacık Sürü Optimizasyonunda öncelikle belirli sayıda rastgele parçacık üretilir. Daha sonra her parçacığın kendine ait en iyi çözümü (p_{iyi}) ve parçacıkların tamamının en iyi çözümü (p_{eniyi}) güncellenerek hafıza saklanır ve böylelikle en uygun çözüm bulunmaya çalışılır.

Parçacık Sürü Optimizasyonuna ilişkin algoritma aşağıdaki adımlardan oluşmaktadır [26][59]:

Adım 1. Her bir parçacığın pozisyonuna ve hızına rastgele değerler ver.

Adım 2. Her bir parçacığın uygunluk değerini hesapla.

Adım 3. Her bir parçacığın kendine ait en iyi çözümü (p_{iyi}) hesapla.

Adım 4. Adım 3'de hesaplanan en iyi çözümlerden (p_{iyi}) en iyisini (p_{eniyi}) bul.

Adım 5. Her bir parçacığın pozisyon ve hızını sırasıyla Eşitlik (3.4) ve Eşitlik (3.5)'i kullanarak güncelle.

$$v_{i,b} = w * v_{i,b} + r_1 * c_1(p_{iyi,b} - x_{i,b}) + r_2 * c_2(p_{eniyi} - x_{i,b}) \quad (3.4)$$

$$x_{i,b} = x_{i,b} + v_{i,b} \quad (3.5)$$

Eşitlik (3.4) ve Eşitlik (3.5)'deki $p_{iyi,b}$, i. parçacığın uygunluk değeri en iyi olan pozisyonu; p_{eniyi} , parçacıkların tamamının arasında uygunluk değeri en iyi olan parçacığın pozisyonu, $x_{i,b}$, i. parçacığın pozisyonu, $v_{i,b}$, i. parçacığın hızı, w ağırlık değeri, c_1 ve c_2 sabit, r_1 ve r_2 ise 0 ile 1 arasında rastgele bir değerdir.

Adım 6. Sonlandırma koşullarını kontrol et, eğer sonuç memnun edici ise programı bitir, aksi takdirde Adım 2 ile Adım 5 arasını tekrarla.

3.3. Genetik Algoritma

1975 yılında Holland tarafından ileri sürülen Genetik Algoritma (Genetic Algorithm), doğada gözlenen evrimsel sürece benzer şekilde en iyinin hayatta kalması ilkesine göre çalışan biyolojik tabanlı bir optimizasyon yöntemidir. Genetik Algoritma parametreleri genleri, bu parametrelerin tamamı da kromozomu ifade etmektedir [59].

Genetik Algoritmanın aşamaları aşağıda verilmektedir [14, 54]:

Adım 1. n adet kromozom içeren topluluk oluştur.

Adım 2. Her bir kromozom için uygunluk değerini hesapla.

Adım 3. Yeni topluluk oluşuncaya kadar aşağıdaki adımları tekrar et.

Adım 3.1. Uygunluk değerine göre topluluktan iki tane kromozomu, çaprazlamak amacıyla seç. Uygunluk değeri yüksek olanın seçilme şansı yüksektir.

Adım 3.2. Çaprazlama oranını kullanarak seçili ebeveyn kromozomlarını çaprazla ve yeni kromozomlar oluştur. Aksi takdirde yeni kromozom anne ya da babanın kopyası olacaktır.

Adım 3.3. Mutasyon olasılığını kullanarak yeni kromozomun konumunu değiştir.

Adım 3.4. Yeni kromozomu yeni topluluğa ekle.

Adım 4. Yeni topluluğu eskisiyle değiştir.

Adım 5. Eğer sonuç memnun edici ise algoritmayı sonlandır ve son topluluğu çözüm olarak ata.

Adım 6. Adım 2'ye geri dön.

3.4. Yapay Arı Koloni Algoritması

Yapay Arı Koloni Algoritması (Artificial Bee Colony Algorithm), 2005 yılında Karaboğa tarafından arıların yiyecek kaynağı arama sırasındaki davranışlarının modellenmesi ile geliştirilen sürü zekâsına dayalı bir algoritmadır. Bu algortmada kaşif arı, işçi arı ve gözcü arı olmak üzere üç farklı tür arı bulunmaktadır.

Yapay Arı Koloni Algoritmasında ilk olarak yiyecek kaynaklarının pozisyonları,

$$x_{km} = x_m^{min} + r_1 * (x_m^{max} - x_m^{min}) \quad (3.6)$$

eşitliği ile üretilmektedir. Eşitlik (3.6)'daki x_{km} , k. kaynağın m. pozisyonu, $k = 1, 2, \dots, N$, $m = 1, 2, \dots, M$, M, pozisyon sayısı, N, yiyecek kaynağı sayısı, x_m^{min} ve x_m^{max} , sırasıyla pozisyonların alt ve üst limitleri, r_1 ise 0 ile 1 arasında rastgele bir değerdir.

Daha sonra yiyecek kaynaklarındaki besin miktarlarının uygunluk değeri,

$$UD_i = \begin{cases} \frac{1}{1+uygunluk_i}, & uygunluk_i \geq 0 \\ 1 + |uygunluk_i|, & uygunluk_i < 0 \end{cases} \quad (3.7)$$

eşitliği ile hesaplanmaktadır. Eşitlik (3.7)'deki $uygunluk_i$, i. yiyecek kaynağının besin miktarı, UD_i , i. yiyecek kaynağının besin miktarının uygunluk değeridir.

Yiyecek kaynaklarının pozisyonunu ve bu kaynaklardaki besin miktarlarının uygunluk değerini hafızalarında saklayan işçi arılar,

$$v_{i,j} = x_{i,j} + \theta_{i,j} * (x_{i,j} - x_{k,j}) \quad (3.8)$$

eşitliği ile yeni yiyecek kaynakları bulurlar. Eğer buldukları yiyecek kaynağındaki besin miktarının uygunluk değeri hafızalarında sakladıkları yiyecek kaynağındaki besin miktarının uygunluk değerinden daha iyi ise yeni yiyecek kaynağını hafızalarına alarak, eski yiyecek kaynağını hafızalarından silerler. Eşitlik (3.8)'deki $\theta_{i,j}$, -1 ile 1 arasında rastgele bir değerdir.

İşini tamamlayan işçi arıların paylaşmış olduğu bilgiler ile gözcü arılar,

$$p_i = \frac{UD_i}{\sum_{j=1}^N UD_i} \quad (3.9)$$

eşitliği ile hesaplanan olasılık değerine göre yiyecek kaynağı seçerler. Yiyecek kaynağındaki besin miktarının uygunluk değeri arttıkça o kaynağın seçilme olasılığı artmaktadır. Gözcü arılar, Eşitlik (3.9) ile yiyecek kaynağını seçtikten sonra işçi arılar gibi Eşitlik (3.8) ile yeni yiyecek kaynağı bulurlar. Bulunan bu yeni yiyecek kaynağının besin miktarı daha iyiye yeni kaynağı hafızalarına alırlar ve eski kaynağı hafızalarından silerler.

İşçi ve gözcü arıların yiyecek kaynaklarını arama işlemleri tamamlandıktan sonra daha iyi yiyecek kaynakları bulunduğu zaman sayaç sıfırlanır aksi takdirde sayaç bir arttırılır. Sayaç değerinin limit değerini aşması durumunda ise yiyecek kaynağının besin miktarının tükendiği varsayıldığından o kaynağı kaşif arı kullanmaya başlar ve kaşif arı

Eşitlik (3.6) ile yeni yiyecek kaynağı aramaya devam eder. Sonlandırma kriteri ya da maksimum iterasyon sayısı sağlanıncaya kadar tüm bu işlemler devam eder [37, 60].

3.5. Karınca Koloni Algoritması

Karınca Koloni Algoritması (Ant Colony Optimization), 1996 yılında Dorigo ve arkadaşları tarafından karıncaların davranışlarından esinlenilerek geliştirilmiş bir sürü zekâsı optimizasyon yöntemidir. Karıncalar çevre şartlarına göre yiyecek kaynağı ile yuvaları arasındaki en kısa yolu bulma yeteneğine sahiptirler. Karıncalar hem yollarını kaybetmemek hem de diğer karıncalar ile bağlantılarını koparmamak için geçtikleri yollara feromon adında bir madde bırakmaktadır. Böylece yiyecek kaynağına ulaşan karıncanın geçtiği yola bıraktığı feromon maddesi sayesinde diğer karıncaların da bu maddeyi takip ederek en kısa yoldan yiyecek kaynağına ulaşması mümkün olmaktadır. Yol kısaltıkça feromon maddesinin yoğunluğu artmaktadır. Dolayısıyla karıncalar hangi yolu seçeceğine öncelikle bu maddenin yoğunluğuna göre daha sonra ise gidebilecekleri yollar arasında seçim yapılmasını sağlayan,

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \eta_{ij}^\beta}{\sum_{C_{il} \in N(S^p)} \tau_{il}^\alpha \eta_{il}^\beta}, & C_{ij} \in N(S^p) \text{ ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (3.10)$$

eşitliğine göre karar vermektedir. Eşitlik (3.10)'daki p_{ij}^k , i. noktadaki k. karıncanın gidebileceği olası yollar kümesi olan S^p 'den j. yolu seçme olasılığının fonksiyonu, l, k. karıncanın gidebileceği nokta, $N(S^p)$, uygun (i, l) yollarının kümesi, τ_{ij} , (i, j)'deki feromon izi, d_{ij} , (i, j) noktaları arasındaki uzaklık, $\eta_{ij} = 1/d_{ij}$, (i, j) noktaları arasındaki uzaklığın tersi, α , yolun feromon izinin önemini belirleyen parametre ve β , gidilecek noktanın seçiminde yol uzunluğunun önemini gösteren parametredir.

Feromon uçucu bir madde olduğundan az geçiş yapılan yollardaki feromon bir müddet sonra buharlaşacağından zamanla kaybolacak ve çok geçiş yapılan yollardaki feromon miktarı da artacağından karıncaların yiyecek kaynağına ulaşması kolaylaşacaktır. Dolayısıyla karıncaların tamamı turlarını tamamladıktan sonra yollar üzerindeki

feromon miktarlarında güncelleme yapılacaktır. Feromon güncellemesi lokal ve global olmak üzere iki şekilde gerçekleşmektedir. Lokal feromon,

$$\tau_{ij} \leftarrow (1 - p) * \tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k \quad (3.11)$$

eşitliğine göre güncellenmektedir. Eşitlik (3.11)'deki p ($0 < p < 1$), feromon buharlaşma oranı, m , karınca sayısı, $\Delta\tau_{ij}^k$, k. karıncanın (i, j) yoluna bıraktığı feromon miktarı olup,

$$\Delta\tau_{ij}^k = \begin{cases} \frac{\theta}{L_k}, & k \text{ karıncası } (i, j) \text{ yolunu kullanmış ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (3.12)$$

biçiminde ifade edilmektedir. Eşitlik (3.12)'deki θ , sabit değer, L_k , k. karıncanın toplam tur uzunluğudur. Global feromon ise,

$$\tau_{ij} \leftarrow (1 - p) * \tau_{ij} + \Delta\tau_{ij}^k \quad (3.13)$$

$$\Delta\tau_{ij}^k = \begin{cases} \frac{1}{L_{eniyi}}, & (i, j) \text{ en iyi tura ait ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (3.14)$$


eşitliklerine göre güncellenmektedir. Eşitlik (3.14)'deki L_{eniyi} , geçerli iterasyondaki en iyi turun uzunluğudur. Lokal ve global feromonun toplanması ile bir yoldaki toplam feromon elde edilmektedir.

Karınca Koloni Algoritmasını özetlemek gerekirse, ilk olarak başlangıç feromon miktarları belirlenir. Daha sonra karıncalar noktalara rastgele yerleştirilir. Her karınca Eşitlik (3.10)'u kullanarak gideceği yolu belirler ve turunu tamamlar. Daha sonra her karınca için seçilen yolun uzunluğu hesaplanır ve lokal feromon güncellemesi yapılır. O ana kadar bulunan en kısa yol yani en iyi çözüm hesaplanarak global feromon güncellemesi yapılır. Sonlandırma kriteri ya da maksimum iterasyon sayısı sağlanıncaya kadar devam edilir [2, 58].

4. DESTEK VEKTÖR MAKİNELERİ

1960'lı yılların sonlarında Vapnik tarafından geliştirilen Destek Vektör Makineleri (Support Vector Machine), istatistiksel öğrenme yöntemi ve yapısal risk minimizasyonuna dayanan ve sınıflandırma ile regresyon problemleri için kullanılan bir makine öğrenmesi yöntemidir. Veri setinin ortalama hata karesini en aza indirerek çalışmasından dolayı eğitim verisi sayısının az olduğu durumlarda bile Destek Vektör Makineleri iyi sonuçlar verebilmektedir.

Destek vektör makinelerinin ağ yapısı Şekil 4'de verilmektedir.



Şekil 4. Destek Vektör Makinelerinin ağ yapısı

Şekil 4'den görüldüğü üzere, Destek Vektör Makinelerinde çıktı değeri,


$$y = f(x) = \sum_{k=1}^m \alpha_k \cdot A(x, x_k) + b \quad (4.1)$$

biçiminde girdilerin iç çarpımları ile ağırlıkların bağımsız kombinasyonlarının toplamı ile hesaplanmaktadır. Eşitlik (4.1)'deki $A(x, x_k)$, $k = 1, 2, 3, \dots, m$ destek vektörleri, $\alpha_k \geq 0$ ağırlıklar (Lagrange çarpanları), b yan değeridir.

Destek Vektör Makineleri, doğrusal ve doğrusal olmayan destek vektör makineleri olarak ikiye ayrılmaktadır.

4.1. Doğrusal Destek Vektör Makineleri

Doğrusal olarak ayrılabilen verilerin olması durumunda, Destek Vektör Makinelerinin amacı, iki sınıfı birbirinden ayıran ve Şekil 5'de gösterilen optimal ayırıcı hiper düzlemi bulmak ve hiper düzlemin iki sınıfa aynı mesafede olmasına imkân tanımaktır.



Şekil 5. Doğrusal olarak ayrılabilen verilerin olması durumunda hiper düzlem

Şekil 5'den görüldüğü üzere, ayırıcı hiper düzleme en yakın iki sınıfa ait örnek grupları olan destek vektörleri, hangi sınıfa ait ise o sınıfın sınırını belirlemektedir ve ayırıcı hiper düzleme paralel bir şekilde yer almaktadır. Kesikli çizgiler ile gösterilen *sınır düzlemlerinin* üzerinde destek vektörleri yer almaktadır. *Ayırıcı hiper düzlem* ise sınır düzlemleri ortasında ve iki sınıfa aynı mesafede yer almaktadır.

Destek Vektör Makinelerinin eğitiminde kullanılan ve N elemanlı olan verinin $\{x_k, y_k\}, k = 1, 2, \dots, N$ olduğu varsayılın. $y_k \in \{-1, 1\}$ etiket değerleri ve $x_k \in R^d$ özellik vektörü olmak üzere;

$$y_k = +1 \text{ için, } w \cdot x_k + b \geq +1$$

$$y_k = -1 \text{ için, } w \cdot x_k + b \leq -1$$

eşitsizlikleri,

$$y_k (w \cdot x_k + b) \geq +1 \quad (4.2)$$

biçiminde birleştirilmektedir. Eşitlik (4.2)'deki w ağırlık vektörü, b sabit terim, x_k destek vektörleridir.

Doğrusal olarak ayrılabilme durumunda optimizasyon problemi,

$$\text{Minimizasyon: } \frac{1}{2} \|w\|^2 \quad (4.3)$$

$$\text{Kısıt: } y_k (w \cdot x_k + b) \geq +1 \quad (4.4)$$

biçiminde ifade edilmektedir ve

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{k=1}^N \alpha_k y_k (w \cdot x_k + b) + \sum_{k=1}^N \alpha_k \quad (4.5)$$

biçimindeki Lagrange fonksiyonu ile çözülmektedir. Eşitlik (4.5)'deki fonksiyonun w ve b 'ye göre birinci dereceden kısmi türevleri,

$$\frac{\partial L_p}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_k y_k x_k \quad (4.6)$$

$$\frac{\partial L_p}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_k y_k = 0 \quad (4.7)$$

biçiminde alınarak sıfıra eşitlenmektedir. Eşitlik (4.6) ve Eşitlik (4.7)'deki sonuçlara *Krush Kuhn Tucker koşulları* adı verilmektedir. Eşitlik (4.6) ve Eşitlik (4.7)'deki değerler Eşitlik (4.5)'de yerine konulduğunda,

$$L_D = \sum_{k=1}^N \alpha_k - \frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N \alpha_k \alpha_l y_k y_l x_k \cdot x_l \quad (4.8)$$

eşitliği elde edilmektedir. Böylece primal optimizasyon problemi,

$$\text{Maksimizasyon: } L_D \quad (4.9)$$

$$\text{Kısıtlar: } \sum_{k=1}^N \alpha_k y_k = 0 \text{ ve } \alpha_k \geq 0, k = 1, 2, \dots, N \quad (4.10)$$

biçiminde dual optimizasyon problemine dönüşmektedir. Sonuç olarak karar fonksiyonu,

$$f(x) = \text{sgn}(\sum_{k=1}^N \alpha_k y_k x_k \cdot x_l + b) \quad (4.11)$$

biçiminde ifade edilmektedir.

Bazı durumlarda veriler belirli bir hata ile doğrusal olarak ayrılabilir. Böyle durumlarda hataları temsil eden pozitif $\varepsilon_k, k = 1, 2, \dots, N$ gevşek değişkenler modele eklenerek problem çözülmektedir. Gevşek değişkenlerin eklenmesi ile Eşitlik (4.3) ve Eşitlik (4.4)'deki optimizasyon problemi,

$$\text{Minimizasyon: } \frac{1}{2} \|w\|^2 + C \sum_{k=1}^N \varepsilon_k \quad (4.12)$$

$$\text{Kısıtlar: } y_k (w \cdot x_k + b) - 1 + \varepsilon_k \geq 0 \text{ ve } \varepsilon_k \geq 0 \quad (4.13)$$

biçimine dönüşmektedir. Eşitlik (4.12)'deki C sabit bir terimdir. Lagrange fonksiyonu,

$$L_p = \frac{1}{2} \|w\|^2 - C \sum_{k=1}^N \varepsilon_k - \sum_{k=1}^N \alpha_k (y_k (w \cdot x_k + b) - 1 + \varepsilon_k) - \sum_{k=1}^N \beta_k \varepsilon_k \quad (4.14)$$

biçiminde elde edilmektedir. Eşitlik (4.14)'deki β_k lagrange çarpanıdır. Çözüm zorluğu nedeniyle Eşitlik (4.14),

$$\frac{\partial L_p}{\partial w} = 0 \Rightarrow w = \sum_{k=1}^N \alpha_k y_k x_k \quad (4.15)$$

$$\frac{\partial L_p}{\partial b} = 0 \Rightarrow \sum_{k=1}^N \alpha_k y_k = 0 \quad (4.16)$$

$$\frac{\partial L_p}{\partial \varepsilon_k} = 0 \Rightarrow C - \alpha_k - \beta_k = 0 \Rightarrow \alpha_k = C - \beta_k \quad (4.17)$$

biçimindeki *Krush Kuhn Tucker koşulları* yardımıyla dual optimizasyon problemine dönüştürülmektedir. Eşitlik (4.15), Eşitlik (4.16) ve Eşitlik (4.17)'deki değerler Eşitlik (4.14)'de yerine konulduğunda dual optimizasyon problemi,

$$\text{Maksimizasyon: } L_D = \sum_{k=1}^N \alpha_k - \frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N \alpha_k \alpha_l y_k y_l x_k \cdot x_l \quad (4.18)$$


$$\text{Kısıtlar: } \sum_{k=1}^N \alpha_k y_k = 0 \text{ ve } 0 \leq \alpha_k \leq C \quad (4.19)$$

biçiminde elde edilmektedir.

Doğrusal olarak ayrılabilen destek vektör makineleri ve belirli bir hata ile doğrusal olarak ayrılabilen destek vektör makineleri arasındaki tek farklılık Lagrange çarpanlarını sınırlandıran ve kullanıcı tarafından belirlenen C sabitidir.

4.2. Doğrusal Olmayan Destek Vektör Makineleri

Şekil 6'daki gibi verilerin doğrusal bir düzlem ile birbirinden ayıramadığı durumlarda ise optimizasyon problemini çözmek için boyutu n olan x girdi vektörünün boyutu F olan z özellik vektörüne dönüştürülmesi gerekmektedir.



Şekil 6. Doğrusal ayrılamayan verilerin olması durumunda hiper düzlem

$x \in R^n$ girdi vektörünün yüksek dereceden bir uzayda z vektörüne dönüştürülebilmesi için optimal ayırıcı hiper düzlemin özellik uzayında tanımlanması gerekmektedir. Bu durum,

$$x \in R^n \rightarrow z(x) = [\phi_1(x), \phi_2(x) \dots, \phi_n(x)] \in R^F \quad (4.20)$$

biçiminde ifade edilmektedir. Eşitlik (4.20)'deki x girdi vektörü x_i gözlemlerinden oluşurken, $z(x)$ özellik uzayı $\phi_i(x)$ gözlemlerinden oluşmaktadır. Bu durumda, Eşitlik (4.11)'deki karar fonksiyonu,

$$f(x) = \text{sgn}(\sum_{k=1}^N \alpha_k y_k \phi_k(x) \cdot \phi_l(x) + b) = \text{sgn}(\sum_{k=1}^N \alpha_k y_k K(x_k, x_l) + b) \quad (4.21)$$

biçiminde hesaplamaktadır. Eşitlik (4.21)'deki $K(x_k, x_l)$, çekirdek (kernel) fonksiyonunu temsil etmektedir.

Verilerin doğrusal olarak ayırlamadığı durumlarla günlük hayat problemlerinde oldukça sık karşılaşılmaktadır. Bu gibi durumlarda çekirdek fonksiyonları kullanılarak veriler doğrusal ayrılmasının mümkün olduğu yüksek dereceden özellik uzayına taşınmaktadır. Destek vektör makinelerinde yaygın olarak kullanılan çekirdek fonksiyonları aşağıdaki gibidir:

Doğrusal Çekirdek Fonksiyonu: $K(x_k, x_l) = x_k \cdot x_l$ (4.22)

Polinom Çekirdek Fonksiyonu: $K(x_k, x_l) = (\gamma x_k \cdot x_l + r)^d, \gamma > 0$ (4.23)

Sigmoid Çekirdek Fonksiyonu: $K(x_k, x_l) = \tanh(\gamma x_k \cdot x_l + r)$ (4.24)

Radyal Tabanlı Çekirdek Fonksiyonu (RBF):

$$K(x_k, x_l) = \exp(-\gamma \|x_k - x_l\|^2), \gamma > 0 \quad (4.25)$$

eşitlikleri ile elde edilmektedir [9, 66, 69].

5. BULANIK ZAMAN SERİLERİ

5.1. Bulanık Zaman Serileri Kavramı

Zadeh'in 1965 yılında ileri sürdüğü bulanık küme teorisi hem teoride hem de pratikte birçok çalışmanın temelini oluşturmuştur. Bulanık küme teorisinin amacı, günlük konuşma dili ile ifade edilen kişisel düşüncelerdeki belirsizlik ile başa çıkmak için etkili ve nicel bir yapı sağlamaktır.

Karar alma, planlama, mantık, sistem teorisi, yapay zeka, ekonomi, kontrol teorisi gibi geniş alanlarda kullanılan bulanık küme teorisi, araştırmacılar tarafından birçok çalışmada gerçekçi problemlere ve yöntemlere uygulanmıştır. Song ve Chissom [63] tarafından verilen çalışmada ise verileri dilsel değerler olan ve *bulanık zaman serileri* adı verilen dinamik bir süreç tanımlanmıştır.

Belirli bir yerin hava şartlarını tanımlarken verilerin, santigrat derece gibi sayısal değerler yerine "dilsel değerler" adı verilen ve günlük hayatta da kullanılan iyi, çok iyi, oldukça iyi, çok çok iyi, serin, çok serin, oldukça serin, sıcak, çok sıcak, soğuk, çok soğuk, çok çok soğuk gibi kelimeler aracılığıyla kayıt altına alındığı durumlarda klasik zaman serileri kullanılamaz. Çünkü zaman değiştikçe sıcaklıklar dolayısıyla gözlem değerleri de değişecektir. Bu tür serilerin doğada kendi gözlemleri kadar bulanık kümeleri olduğundan bu dilsel değerler bulanık kümelere dönüştürülebilmektedir. Bu gibi durumlarda klasik zaman serileri yerine bulanık zaman serileri tercih edilmektedir.

Özetlemek gerekirse; klasik zaman serileri ile bulanık zaman serileri arasındaki temel farklılık, klasik zaman serilerinin gözlemlerinin gerçel sayılar olması, bulanık zaman serilerinin gözlemlerinin ise bulanık kümeler ya da dilsel değerler olmasıdır.

Bulanık zaman serisinin tanımı Song ve Chissom [63] tarafından aşağıdaki gibi verilmiştir.

Tanım 1. Gerçel sayıların bir alt kümesi olan $Y(t)$ ($t = \dots, 0, 1, 2, \dots$), $f_k(t)$ ($k = 1, 2, \dots$) bulanık kümeleri ile tanımlanan evrensel küme olsun. Eğer $F(t)$, $f_k(t)$ bulanık

kümelerinden oluşuyorsa, $F(t)$, $Y(t)$ evrensel kümesinde tanımlı bir bulanık zaman serisidir.

Tanım 1'e göre, bulanık zaman serisi $F(t)$, zamanın bir fonksiyonudur ve bulanık kümelerin temsil ettiği dilsel değerleri olan dilsel değişkenlerdir.

5.2. Bulanık Zaman Serileri Modelleri

Klasik zaman serilerinde olduğu gibi bulanık zaman serilerinin modellenmesinde de birden fazla yaklaşım bulunmaktadır. Bu yaklaşımlardan ilki olan Song ve Chissom [63] çalışmasında modelleme sürecinde bulanık ilişki eşitlikleri kullanılmıştır. Bu eşitliklerin kullanılmasının nedeni, bulanık zaman serilerinin değerlerinin bulanık kümeler olması ve t zamanındaki gözlemlerin önceki zamanlardaki gözlemlerin birikimli sonuçları olarak varsayılmasıdır. Yani, t zamanındaki gözlemler ile önceki zamanlardaki gözlemler arasında nedensel bir ilişki bulunmaktadır. Dolayısıyla, modelleme süreci, esas itibarıyla, ilgilenilen farklı zamanlardaki gözlemler arasındaki bulanık ilişkileri geliştirmek için kullanılmaktadır.

Süreç ile ilgili olarak, $F(t-1)$ ve $F(t)$ 'nin indis kümeleri sırasıyla K ve L olmak üzere aşağıdaki tanımlar da verilebilmektedir.

Tanım 2. Herhangi bir $f_l(t) \in F(t)$, $l \in L$ için $R_{kl}(t, t-1)$ bulanık ilişki ve "o" max-min operatörü olmak üzere $f_l(t) = f_k(t-1) o R_{kl}(t, t-1)$ eşitliğini sağlayan bir $f_k(t-1) \in F(t-1)$, $k \in K$ varsa $F(t)$ yalnızca $F(t-1)$ 'den etkilenmektedir. Bu ilişki,

$$f_k(t-1) \rightarrow f_l(t) \quad (5.1)$$

ya da

$$F(t-1) \rightarrow F(t) \quad (5.2)$$

biçiminde gösterilmektedir.

Tanım 3. Herhangi bir $f_l(t) \in F(t), l \in L$ için $R_{kl}(t, t-1)$ bulanık ilişki olmak üzere $f_l(t) = f_k(t-1) o R_{kl}(t, t-1)$ eşitliğini sağlayan bir $f_k(t-1) \in F(t-1), k \in K$ varsa ve “ $\cup$ ” birleşim operatörü olmak üzere $R(t, t-1) = \cup_{k,l} R_{kl}(t, t-1)$ ise $F(t)$ ile $F(t-1)$ ’den arasındaki bulanık ilişki $R(t, t-1)$ ile gösterilmektedir ve bulanık ilişki eşitliği,

$$F(t) = F(t-1) o R(t, t-1) \quad (5.3)$$

biçiminde tanımlanmaktadır.

Tanım 4. $F(t), (t = \dots, 0, 1, 2, \dots)$ bulanık zaman serisi ve $t_1 \neq t_2$ olsun. Herhangi bir $f_k(t_1) \in F(t_1)$ için $f_k(t_1) = f_l(t_2)$ ya da tam tersi eşitliklerini sağlayan bir $f_l(t_2) \in F(t_2)$ varsa $F(t_1) = F(t_2)$ dir.

Tanım 5. $F(t)$ ve $F(t-1)$ arasındaki iki bulanık ilişki $R_1(t, t-1) = \cup_{k,l} R_{kl}^1(t, t-1)$ ve $R_2(t, t-1) = \cup_{k,l} R_{kl}^2(t, t-1)$ olsun. Herhangi bir $f_l(t) \in F(t), l \in L$ için $R_{kl}^1(t, t-1)$ ve $R_{kl}^2(t, t-1)$ bulanık ilişkiler olmak üzere $f_l(t) = f_k(t-1) o R_{kl}^1(t, t-1)$ ve $f_l(t) = f_k(t-1) o R_{kl}^2(t, t-1)$ eşitliklerini sağlayan bir $f_k(t-1) \in F(t-1), k \in K$ varsa $R_1(t, t-1) = R_2(t, t-1)$ dir.

Tanım 6. Herhangi bir $f_l(t) \in F(t), l \in L$ için $m > 0, m: \text{tamsayı}, R_b^p(t, t-m)$ bulanık ilişki, “ $\times$ ” kartezyen çarpım, $l \in L, k_i \in K_i, F(t-i) (i = 1, \dots, m)$ ’nin indis kümesi K_i olmak üzere $f_l(t) = (f_{k_1}(t-1) \times f_{k_2}(t-2) \times \dots \times f_{k_m}(t-m)) o R_b^p(t, t-m)$ eşitliği sağlanıyorsa $F(t)$ aynı anda $F(t-1), F(t-2), \dots, F(t-m)$ ’den etkilenmektedir. $F(t)$ ile $F(t-1), F(t-2), \dots, F(t-m)$ arasındaki bulanık ilişki $R_b(t, t-m) = \cup_p R_b^p(t, t-m)$ olarak tanımlanmaktadır. Bu ilişki,

$$f_{k_1}(t-1) \cap f_{k_2}(t-2) \dots \cap f_{k_m}(t-m) \rightarrow f_l(t) \quad (5.4)$$

ya da

$$F(t-1) \cap F(t-2) \cap F(t-3) \dots \cap F(t-m) \rightarrow F(t) \quad (5.5)$$

biçimindedir. Burada “ $\cap$ ” kesişim operatörüdür. Bulanık ilişki eşitliği ise,

$$F(t) = (F(t-1) \times F(t-2) \dots \times F(t-m)) \circ R_b(t, t-m) \quad (5.6)$$

biçiminde gösterilmektedir.

Tanım 7. Tanım 6’daki koşullar aynı olmak üzere, $f_l(t) = (f_{k_1}(t-1) \cup f_{k_2}(t-2) \cup \dots \cup f_{k_m}(t-m)) \circ R_c^p(t, t-m)$ eşitliğini sağlayan bir $R_c^p(t, t-m)$ bulanık ilişkisi varsa $F(t)$, $F(t-1)$ ya da $F(t-2)$ ya da ... ya da $F(t-m)$ ’in herhangi birinden etkilenmektedir. Bu ilişki,

$$f_{k_1}(t-1) \cup f_{k_2}(t-2) \dots \cup f_{k_m}(t-m) \rightarrow f_l(t) \quad (5.7)$$

ya da

$$F(t-1) \cup F(t-2) \cup F(t-3) \dots \cup F(t-m) \rightarrow F(t) \quad (5.8)$$

biçiminde gösterilmektedir. Bulanık ilişki eşitliği ise,

$$F(t) = (F(t-1) \cup F(t-2) \cup \dots \cup F(t-m)) \circ R_c(t, t-m) \quad (5.9)$$

biçimindedir. Burada $R_c(t, t-m) = \cup_p R_c^p(t, t-m)$ dir ve $R_c(t, t-m)$, $F(t)$ ile $F(t-1)$ ya da $F(t-2)$ ya da ... ya da $F(t-m)$ arasındaki bulanık ilişkidir.

Yukarıdaki tanımlardan yola çıkılarak modellerin dereceleri kavramı tanımlanabilmektedir ve bulanık zaman serileri iki farklı şekilde sınıflanabilmektedir.

Tanım 8. $F(t)$, yalnızca $F(t-1)$ ’den etkileniyorsa bu ilişki,

$$F(t) = F(t-1) \circ R(t, t-1) \quad (5.10)$$

biçimindeki bulanık ilişki eşitliği ile tanımlanmaktadır.

$F(t)$, $F(t - 1)$ ya da $F(t - 2)$ ya da ... ya da $F(t - m)$ ($m > 0$)'den etkileniyorsa bu ilişki,

$$F(t) = (F(t - 1) \cup F(t - 2) \cup \dots \cup F(t - m)) \text{ o } R_c(t, t - m) \quad (5.11)$$

biçimindeki bulanık ilişki eşitliği ile tanımlanmaktadır. Bu eşitliklere $F(t)$ 'nin *birinci dereceden modeli* adı verilmektedir.

Tanım 9. $F(t)$, $F(t - 1)$, $F(t - 2)$, ..., $F(t - m)$ ($m > 0$)'den aynı anda etkileniyorsa bu ilişki,

$$F(t) = (F(t - 1) \times F(t - 2) \times \dots \times F(t - m)) \text{ o } R_b(t, t - m) \quad (5.12)$$

biçimindeki bulanık ilişki eşitliği ile tanımlanmaktadır. Bu eşitliğe $F(t)$ 'nin *m. dereceden modeli* adı verilmektedir.

Tanım 10. Tanım 8 ve Tanım 9'daki eşitliklerde; $F(t)$ 'nin $R(t, t - 1)$ ya da $R_b(t, t - m)$ ya da $R_c(t, t - m)$ bulanık ilişkisi t zamanından bağımsız ise yani t_1 ve t_2 farklı zamanları için $R(t_1, t_1 - 1) = R(t_2, t_2 - 1)$ ya da $R_b(t_1, t_1 - m) = R_b(t_2, t_2 - m)$ ya da $R_c(t_1, t_1 - m) = R_c(t_2, t_2 - m)$ eşitlikleri sağlanıyorsa, $F(t)$ 'ye zamanla değişmez bulanık zaman serisi adı verilmektedir. Aksi takdirde, zamanla değişen bulanık zaman serisi denilmektedir.

Zamanla değişmez bulanık zaman serileri durumunda,

$$R(t, t - 1) = R \quad (5.13)$$

$$R_b(t, t - m) = R_b(m) \quad (5.14)$$

$$R_c(t, t - m) = R_c(m) \quad (5.15)$$

biçimindedir.

Burada dikkat edilmesi gereken nokta; genellikle t_1 ve t_2 farklı zamanlarında $R(t_1, t_1 - 1) \neq R(t_2, t_2 - 1)$, $R_b(t_1, t_1 - m) \neq R_b(t_2, t_2 - m)$ ve $R_c(t_1, t_1 - m) \neq$

$R_c(t_2, t_2 - m)$ biçimindedir. Bu durumun iki sebebi vardır: birincisi, bulanık kümelerin tanımlandığı evrensel kümeler farklı zamanlarda farklı olabilir; ikincisi, $F(t)$ 'nin değerleri farklı zamanlarda farklı olabilir. Bu nedenle, bulanık zaman serilerinin sınıflandırılması anlamlıdır.

Zamanla değişmez bulanık zaman serilerinin modelleri t zamanından bağımsız olduğundan, zamanla değişmez bulanık zaman serilerinin zamanla değişen bulanık zaman serilerinden daha basit olduğu görülmektedir. Bazı iyi ve basit özellikleri, zamanla değişmez zaman serilerinin daha çok kullanılmasını sağlamaktadır. Verilen bir bulanık zaman serisinde ilk soru ne zaman, zamanla değişmez olduğudur. Aşağıdaki teorem bunun cevabını vermektedir.

Teorem 1.

Herhangi bir t zamanı için $F(t)$, sadece $f_k(t)$ ($k = 1, 2, \dots, n$) sonlu elemanlara sahip bir bulanık zaman serisi ve $F(t) = F(t - 1)$ ise $F(t)$, zamanla değişmez bulanık zaman serisidir.

Zamanla değişen bulanık zaman serilerinin aksine zamanla değişmez bulanık zaman serilerinde bulanık ilişkilerin hesaplanması çok kolaydır. Zamanla değişen bulanık zaman serilerinde Tanım 3'e göre, $R(t, t - 1)$ bulanık ilişkisini hesaplarken $F(t)$ ve $F(t - 1)$ 'in herhangi bir olası eleman çifti arasındaki tüm olası bulanık ilişkilerin göz önüne alınması gerekmektedir. Ancak zamanla değişmez bulanık zaman serilerinde tüm olası t değerleri için $F(t)$ ve $F(t - 1)$ 'in sadece bir olası eleman çiftine ihtiyaç duyulmaktadır. Yani, bulanık ilişkiyi hesaplamak için farklı t zamanında $F(t)$ ve $F(t - 1)$ 'in farklı eleman çiftleri kullanılabilir. Bu özellik aşağıdaki gibi ifade edilebilir:

Teorem 2.

Herhangi bir t için $F(t)$, sadece $f_k(t)$ ($k = 1, 2, \dots, n$) sonlu elemanlara sahip bir bulanık zaman serisi ve $F(t) = F(t - 1)$ ise $R(t, t - 1)$ aşağıdaki gibi ifade edilebilir.

$$R = R(t, t-1) = \dots \cup f_{k_1}(t-1) \times f_{l_c}(t) \cup f_{k_2}(t-2) \times f_{l_1}(t-1) \dots \cup f_{k_m}(t-m) \times f_{l_{m-1}}(t-m+1) \dots \quad (5.16)$$

Burada $m > 0$ dır ve bulanık kümelerin her bir çifti farklıdır [63].

Literatürde hem zamanla değişen hem de zamanla değişmez bulanık zaman serileri üzerine çalışmalar bulunmaktadır. Bu çalışma kapsamında ise zamanla değişmez bulanık zaman serileri kullanılmıştır.

Yukarıdaki tanımların dışında bulanık zaman serilerine ilişkin diğer tanımlar aşağıda verilmektedir:

Tanım 11. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olsun. $F_1(t)$ bulanık zaman serisi, gecikmeli $F_1(t-1), F_2(t-1)$ bulanık zaman serilerinden etkilenmekte ise, $F_1(t)$ bulanık zaman serisi ile $F_1(t-1), F_2(t-1)$ bulanık zaman serileri arasındaki bulanık ilişki,

$$F_1(t-1), F_2(t-1) \rightarrow F_1(t) \quad (5.17)$$

ifadesi ile verilebilir ve *birinci dereceden iki değişkenli (iki faktör) bulanık zaman serisi öngörü modeli* olarak adlandırılır. Burada $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak anılmaktadır.

Tanım 12. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olmak üzere, $F_1(t)$, gecikmeli $F_1(t-1), F_1(t-2), \dots, F_1(t-n)$ ve $F_2(t-1), F_2(t-2), \dots, F_2(t-n)$ bulanık zaman serilerinden etkilenmekte ise *n'inci dereceden iki değişkenli bulanık zaman serisi öngörü modeli*,

$$\left. \begin{array}{l} (F_1(t-n), F_2(t-n)), \\ \vdots \\ (F_1(t-2), F_2(t-2)), \\ (F_1(t-1), F_2(t-1)) \end{array} \right\} \rightarrow F_1(t) \quad (5.18)$$

ifadesi ile verilebilir. Burada da yine $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır.

Tanım 13. $F_1(t)$ ve $F_2(t)$ iki bulanık zaman serisi iken, $F_1(t)$ bulanık zaman serisi, $F_1(t - m_1), F_1(t - m_2), \dots, F_1(t - m_k), F_2(t - n_1), F_2(t - n_2), \dots, F_2(t - n_l)$ bulanık zaman serilerinden etkilenmekte ise (k, l) 'inci dereceden, kısmi yüksek dereceli, iki değişkenli bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} F_1(t - m_1), F_1(t - m_2), \dots, F_1(t - m_k), \\ F_2(t - n_1), F_2(t - n_2), \dots, F_2(t - n_l) \end{array} \right\} \rightarrow F_1(t) \quad (5.19)$$

ifadesi ile verilebilir. Burada, $m_k (k = 1, 2, \dots, a)$ ve $n_l (l = 1, 2, \dots, b)$ tamsayılar ve $1 \leq m_1 < m_2 < \dots < m_a, 1 \leq n_1 < n_2 < \dots < n_b$ şeklindedir ve aynı zamanda $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır.

Tanım 14. $F_1(t), F_2(t), \dots, F_m(t)$, m adet bulanık zaman serisi iken, $F_1(t)$, bulanık zaman serisi $(F_1(t - 1), F_2(t - 1), \dots, F_m(t - 1)), (F_1(t - 2), F_2(t - 2), \dots, F_m(t - 2)), \dots, (F_1(t - n), F_2(t - n), \dots, F_m(t - n))$ gecikmeli bulanık zaman serilerinden etkilenmekte ise n 'inci dereceden m değişkenli (m -faktör) bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} (F_1(t - n), F_2(t - n), \dots, F_m(t - n)), \\ \vdots \\ (F_1(t - 2), F_2(t - 2), \dots, F_m(t - 2)), \\ (F_1(t - 1), F_2(t - 1), \dots, F_m(t - 1)) \end{array} \right\} \rightarrow F_1(t) \quad (5.20)$$

biçiminde ifade edilir. Burada, $F_1(t)$ ana faktör, $F_2(t), F_3(t), \dots, F_m(t)$ ise ikincil faktör olarak [11].

5.3. Bulanık Zaman Serilerinde Önerilen Yöntem

Literatürde yer alan çalışmalar incelendiğinde; bulanık zaman serileri kavramının bulanıklaştırma, bulanık ilişkilerin belirlenmesi ve berraklaştırma olmak üzere üç temel aşama üzerine kurgulandığı görülmektedir. Bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duyulmayacak şekilde öncelikle kedi sürüsü optimizasyonu ile küme merkezleri elde edilmektedir. Daha sonra Öklid uzaklığı ile her bir gözlemin bu küme merkezlerine uzaklığı hesaplanmakta ve bu uzaklıklardan yola çıkılarak Bulanık C ortalamalar yöntemindeki gibi gözlemlerin küme merkezlerine üyelik değerleri hesaplanmaktadır. Böylece her bir gözlemin her bir küme merkezine olan üyelik değerleri dikkate alınmaktadır. Bulanık ilişkilerin belirlenmesi aşamasında, literatürde yer alan çalışmalardan farklı olarak destek vektör makineleri kullanılmaktadır. Destek vektör makineleri, kendi içinde iterasyona imkân tanıyan bir yöntem olmasının yanında az sayıdaki eğitim verilerinde bile daha az hata ile daha iyi performans göstermesi açısından oldukça kullanışlı bir yöntemdir. Bulanıklaştırma aşamasında elde edilen üyelik değerleri bu aşamada destek vektör makinelerinde sıklıkla kullanılan radyal tabanlı çekirdek fonksiyonu yardımıyla epsilon destek vektör regresyonu kullanılarak eğitilmekte ve bulanık öngörüler elde edilmektedir. Berraklaştırma aşamasında ise Yu [76] çalışmasında ileri sürülen ağırlıklandırılmış yöntem kullanılarak bir önceki aşamada elde edilen bulanık öngörüler ile öngörü değerleri elde edilmektedir. Önerilen yeni yöntemin adımları aşağıda verilmektedir:

Adım 1. Evrensel küme tanımlanır ve önerilen yöntemin girdileri belirlenir.

Zaman serisinin en küçük (x_{min}) ve en büyük (x_{max}) gözlem değerleri, evrensel kümenin (U) en küçük ve en büyük değerleri olarak alınır ve evrensel küme,

$$U = [x_{min}, x_{max}]$$

biçiminde tanımlanır. Her bir kedinin eleman (boyut) sayısı M kullanıcı tarafından belirlenir ve bu değer küme sayısı olarak alınır. Ayrıca kedi sayısı (N), arama hafızası havuzu (AHH), seçilen boyutun arama aralığı (SBA), değişen boyutların sayısı (DBS),

kariřım oranı (KO) ve maksimum iterasyon sayısı ($MaxIt$) da kullanıcı tarafından belirlenir.

Adım 2. Bařlangıç popölasyonu rastgele oluřturulur.

M boyutlu çözümler uzayına rastgele N tane kedi serpiřtirilir ve her kediye 1'den N 'e kadar rastgele bir numara verilir. N tane kedinin ilk pozisyon ve hızları rastgele üretilir. $x_{k,d} \in [x_{min}, x_{max}]$, $1 \leq d \leq M$ olmak üzere k . kedinin pozisyonu $x_{k,1}, x_{k,2}, \dots, x_{k,M}$ elemanlarını ięeren X_k ile řekil 7'deki gibi gösterilmektedir. $v_{k,d} \in [v_{min}, v_{max}]$, $1 \leq d \leq M$ olmak üzere k . kedinin hızı $v_{k,1}, v_{k,2}, \dots, v_{k,M}$ elemanlarını ięeren V_k ile řekil 8'deki gibi gösterilmektedir.

$x_{k,1}$	$x_{k,2}$	...	$x_{k,M}$
-----------	-----------	-----	-----------

řekil 7. k . kedinin X_k pozisyon vektörünün grafiksel gösterimi

$v_{k,1}$	$v_{k,2}$	...	$v_{k,M}$
-----------	-----------	-----	-----------

řekil 8. k . kedinin V_k hız vektörünün grafiksel gösterimi

Yani $x_{k,d}$: d . boyuttaki k . kedinin pozisyonu, $v_{k,d}$: d . boyuttaki k . kedinin hızı, $k = 1, 2, \dots, N$ ve $d = 1, 2, \dots, M$ olmak üzere her bir kedinin pozisyonu için x_{min} ile x_{max} aralıęında $x_{k,d}$ rastgele sayıları ve her bir kedinin hızı için v_{min} ile v_{max} aralıęında $v_{k,d}$ rastgele sayıları üretilir. Dolayısıyla bu adımda, k . ($1 \leq k \leq N$) kedi için rastgele üretilen bařlangıç pozisyon vektörü X_k ve rastgele üretilen bařlangıç hız vektörü V_k olan N kedi üretilmiř olmaktadır.

Adım 3. Kedilerin uygunluk değeri hesaplanır.

k . kedinin uygunluk değeri, X_k pozisyon vektörüne göre hesaplanır. Bu iřlem N kedinin her biri için tekrarlanır ve $X_{eni yi} = [y_{k,1}, y_{k,2}, \dots, y_{k,M}]$ bięiminde gösterilen ve en iyi uygunluk değeri veren kedinin pozisyonu hafızada saklanır.

Adım 4. Kedilerin bayrakları belirlenir ve bu bayraklar kullanılarak kedilere arama ya da izleme modu işlemi uygulanır.

Kedilerin karışım oranına (KO) göre bayrakları belirlenir. Bu çalışmada, kedinin numarası $(KO * N)$ 'e eşit ya da küçükse bayrağı 1'e eşitlenmiş yani kedi arama moduna atanmıştır, aksi takdirde kedinin bayrağı 0'a eşitlenmiş ve kedi izleme moduna atanmıştır.

Adım 5. Kediler bayraklarına göre hareket ettirilir.

Eğer k . kedi izleme moduna atanmış ise yani bayrağı 0'a eşitse, k . kedi izleme modu sürecine uygulanır. Eşitlik (3.2) ve Eşitlik (3.3)'e dayanarak k . $(1 \leq k \leq N)$ kedinin V_k hız vektörü ve X_k pozisyon vektörü güncellenir.

Eğer k . kedi arama moduna atanmış ise yani bayrağı 1'e eşitse, k . kedi arama modu sürecine uygulanır. k . kedinin pozisyon vektörü X_k 'dan AHH tane kopya oluşturulur. Her bir kopya için DBS'ye dayalı birkaç boyutu seçilir ve mevcut değerlerinin SBA yüzdeleri kullanılarak değerleri güncellenir. Her bir kopyanın uygunluk değeri hesaplanır. Uygunluk değerlerinin tamamı eşit değilse kopyaların seçim olasılığı Eşitlik (3.4) kullanılarak hesaplanır, aksi durumda kopyaların seçim olasılıklarının tamamına bir değeri atanır. Kopyalardan taşınmak için nokta rastgele çıkartılır ve k . kedinin pozisyonuyla değiştirilir. Bu çalışmada, aday noktalardan taşınmak için noktanın çıkartılması *rulet tekerleği yöntemi* ile yapılmıştır.

Adım 5.1. Güncellenen X_k pozisyon vektörüne göre k . kedinin uygunluk değeri hesaplanır. Her bir kedinin X_k pozisyon vektörü, problem için bir çözüm sunmaktadır.

Adım 5.1.1. k . kedinin X_k pozisyon vektöründeki elemanlar $x_{k,1} < x_{k,2} < \dots < x_{k,M}$ olacak şekilde küçükten büyüğe sıralanır ve her bir eleman küme merkezi olarak alınır. Daha sonra n gözlem sayısı olmak üzere x ile y arasındaki Öklid uzaklığını (d_{ij}) hesaplayan,

$$d_{ij} = \|x - y\|^2 = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5.21)$$

eşitliğinden yola çıkılarak her bir gözlemin küme merkezlerine olan uzaklığı hesaplanır. Son olarak da hesaplanan bu uzaklık değerleri yardımıyla Bulanık C ortalamalar yöntemindeki gibi,

$$u_{ij} = 1 / \sum_{k=1}^M (d_{ij} / d_{ik})^{(2/q-1)} \quad (5.22)$$

eşitliği ile gözlemlerin küme merkezlerine üyelik değerleri hesaplanır. Eşitlik (5.22)'deki u_{ij} , üyelik değerleri, M , küme sayısı, $q > 1$ ise bulanıklık indeksidir.

Adım 5.1.2. Bulanık ilişkiler ve bulanık öngörüler belirlenir.

Bulanık ilişkilerin belirlenmesinde, Destek Vektör Makineleri'nde sıklıkla kullanılan radyal tabanlı çekirdek fonksiyonu yönteminin yardımıyla epsilon destek vektör regresyonu kullanılmıştır. Radyal tabanlı çekirdek fonksiyonuna ilişkin formülasyon,

$$K(x_k, x_l) = \exp(-\gamma \|x_k - x_l\|^2), \gamma > 0 \quad (5.23)$$

biçiminde Bölüm 4'de verilmişti. Eşitlik (5.23)'deki γ , gamma değeridir. Epsilon destek vektör regresyonu ise $x_k \in R^n$ ve $y_k \in R$, $k = 1, 2, \dots, N$ olmak üzere;

$$\text{Minimizasyon: } \frac{1}{2} \|w\|^2 + C \sum_{k=1}^N (\xi_k + \xi_k^*) \quad (5.24)$$

$$\text{Kısıtlar: } y_k - (w \cdot x_k + b) \leq \varepsilon + \xi_k, (w \cdot x_k + b) - y_k \leq \varepsilon + \xi_k^* \text{ ve } \xi_k, \xi_k^* \geq 0 \quad (5.25)$$

biçimindeki optimizasyon problemi ile tanımlanmaktadır ve

$$y = \sum_{k=1}^N (\alpha_k - \alpha_k^*) K(x_k, x_l) + b \quad (5.26)$$

biçiminde elde edilmektedir.

Adım 5.1.1.'de elde edilen üyelik değerleri, bu değerlerin gecikmeli değerleri etiket değerleri olarak alınarak radyal tabanlı çekirdek fonksiyonunu kullanan epsilon destek vektör regresyonu yardımıyla eğitilir ve n gözlem sayısı olmak üzere, $\hat{U}_{ij}, i =$

$1, 2, \dots, M, j = 1, 2, \dots, n$ bulanık öngörüler elde edilir.

Adım 5.1.3. Öngörü değerleri elde edilir.

Öngörü değerlerinin elde edilmesinde berraklaştırma yöntemi, Adım 5.1.2’de elde edilen bulanık öngörü değerlerinin ağırlıklandırılması ve bu ağırlıkların Adım 5.1.1’de elde edilen küme merkezleri ile çarpılması biçiminde uygulanmaktadır. Destek vektör makineleri kullanılarak elde edilen bulanık öngörü değerleri $(\hat{U}_{ij})$, ağırlık olarak düşünüldüğünde bu ağırlıkların,

$$\begin{aligned}\sum_{i=1}^M \hat{U}_{i1} &= 1 \\ \sum_{i=1}^M \hat{U}_{i2} &= 1 \\ &\vdots \\ \sum_{i=1}^M \hat{U}_{in} &= 1\end{aligned}\tag{5.27}$$

eşitliklerini sağlaması gerekmektedir. Bu eşitliklerin sağlanması için $\hat{U}_{ij}$ değerleri,

$$w_{ij} = \frac{\hat{U}_{ij}}{\sum_{i=1}^M \hat{U}_{ij}}, i = 1, 2, \dots, M, j = 1, 2, \dots, n\tag{5.28}$$

biçiminde standartlaştırılmaktadır ve öngörü değerleri de,

$$\text{öngörü değeri} = \sum_{i=1}^M w_{ij} x_i, i = 1, 2, \dots, M, j = 1, 2, \dots, n\tag{5.29}$$

eşitliği ile elde edilmektedir. Eşitlik (5.27), (5.28) ve (5.29)’daki $\hat{U}_{ij}$, i . kedinin j . gözlemine ilişkin bulanık öngörü değeri, w_{ij} , i . kedinin j . gözlemine ilişkin ağırlık değeri, M , küme sayısı ve n , gözlem sayısıdır.

Adım 5.1.4. k . kedinin uygunluk değeri hesaplanır.

Uygunluk fonksiyonu olarak,

$$HKO = \frac{\sum_{i=1}^N (X_i - \hat{X}_i)^2}{N} \quad (5.30)$$

biçiminde ifade edilen Hata Kareler Ortalaması kullanılır.

N kedinin her biri için Adım 5 tekrarlanır. Pozisyon vektörü $X_k = [x_{k,1}, x_{k,2}, \dots, x_{k,M}]$ olan k . kedinin uygunluk değeri mevcut iterasyonda X_{eniyi} 'nin uygunluk değerinden küçük ise o zaman mevcut iterasyonda X_k pozisyon vektöründeki elemanların değeri aşağıda gösterildiği gibi $X_{\text{eniyi}} = [y_{k,1}, y_{k,2}, \dots, y_{k,M}]$ en iyi pozisyon vektöründeki elemanlara atanır.

$$y_{k,1} = x_{k,1}$$

$$y_{k,2} = x_{k,2}$$

⋮


$$y_{k,M} = x_{k,M}$$

Adım 6. Her bir kediye tekrar rastgele bir numara verilir ve kedilerin bayrakları Adım 4'deki gibi belirlenir.

Adım 7. Sonlandırma kriteri kontrol edilir.

Eğer maksimum iterasyon sayısına ulaşılmışsa program durdurulur. Son iterasyonda elde edilen uygunluk değeri, problemin en iyi çözümünü vermektedir.

Önerilen yeni yöntemin akış diyagramı Şekil 9'da verilmektedir.



Şekil 9. Önerilen Yöntemin Akış Diyagramı

6. BULGULAR VE TARTIŞMA

Bölüm 5.3.'de önerilen kedi sürüsü optimizasyonuna dayalı bulanık zaman serisi yöntemi, ilk olarak, literatürde daha önceki çalışmalarda kullanılmış olan ve Tablo 1'de verilen altı farklı zaman serisi verisine uygulanmıştır.

Tablo 1. Uygulamada kullanılan zaman serileri

Zaman Serisinin Adı	Zaman Aralığı	Gözlenme Sıklığı	Gözlem Sayısı
Alabama Üniversitesi kayıt verileri	1971 – 1992	Yıllık	22
TAIFEX verileri	03.08.1998 – 30.09.1998	Günlük	47
İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi verileri	01.10.2009 – 31.12.2009	Günlük	63
	02.02.2009 – 29.05.2009	Günlük	82
	01.10.2010 – 23.12.2010	Günlük	55
	01.04.2010 – 31.05.2010	Günlük	41

Tablo 1'den de görüldüğü üzere, önerilen yöntemin çözümlenmesinde, yıllık olarak gözlenmiş olan Alabama Üniversitesi kayıt verilerine ilişkin bir adet, günlük olarak gözlenmiş olan TAIFEX (Taiwan Futures Exchange) verilerine ilişkin bir adet ve yine günlük olarak gözlenmiş olan İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi verilerine ilişkin ise dört adet zaman serisi kullanılmıştır.

Literatürde kullanılan verilerden farklı olarak, bu bölümde ayrıca, 2010 yılı Ocak ayı ile 2016 yılı Aralık ayı arasında aylık bazda gözlenmiş olan “DIŞ TİCARET HADLERİ” verileri üzerine bir uygulama da yapılmıştır. Söz konusu uygulamada, küme merkezlerinin belirlenmesi aşamasında kedi sürüsü optimizasyonu yerine sırasıyla parçacık sürü optimizasyonu, genetik algoritma, yapay arı koloni algoritması ve karınca koloni algoritması yöntemleri kullanılmış ve bu yöntemlerin sonuçları ile önerilen yöntemin sonuçları karşılaştırılmıştır.

Önerilen yeni yönteme ilişkin kodlamalar MATLAB 7.12.0 programında yapılmış olup, destek vektör makinelerinin kullanılabilmesi amacıyla *libsvm* kütüphanesinden

yararlanılmıştır. Bir örneği EK 1’de verilmiş olan program kodları vasıtasıyla elde edilen sonuçların diğer yöntemler ile karşılaştırılmasında,

$$HKOK = \sqrt{\frac{\sum_{i=1}^N (X_i - \hat{X}_i)^2}{N}} \quad (6.1)$$

$$OMYH = \frac{1}{N} \sum_{i=1}^N \left| \frac{X_i - \hat{X}_i}{X_i} \right| \quad (6.2)$$

$$YD = \frac{1}{N-1} \sum_{i=1}^{N-1} \begin{cases} 1, & (X_{i+1} - X_i)(\hat{X}_{i+1} - X_i) > 0 \\ 0, & \text{aksi halde} \end{cases} \quad (6.3)$$

eşitlikleri kullanılmıştır. Eşitlik (6.1)’deki HKOK: Hata Kareler Ortalamasının Karekökü, Eşitlik (6.2)’deki OMYH: Ortalama Mutlak Yüzdelik Hata, Eşitlik (6.3)’deki YD: Yön Doğruluğu, N: gözlem sayısı, X_i : zaman serisinin i. gözleminin gerçek değeri, $\hat{X}_i$: zaman serisinin i. gözleminin öngörü değeri, X_{i+1} : bir gecikmeli zaman serisinin (i + 1). gözleminin gerçek değeri ve $\hat{X}_{i+1}$: bir gecikmeli zaman serisinin (i + 1). gözleminin öngörü değeridir.

Önerilen yöntemde küme merkezlerinin belirlenmesi aşamasında kullanılan kedi sürüsü optimizasyonuna ilişkin parametre bilgileri Tablo 2’de verilmiştir.

Tablo 2. Uygulamalarda kullanılan kedi sürüsü optimizasyonuna ilişkin parametreler

Parametre Adı	Parametre Sembolü	Parametre Değeri
Kedi Sayısı	N	5
Boyut Sayısı	M	[6,15] aralığındaki tamsayı değerleri
Maksimum İterasyon Sayısı	MaxIt	100
Arama Hafızası Havuzu	AHH	3
Seçilen Boyutun Arama Aralığı	SBA	0.2
Değişen Boyutların Sayısı	DBS	0.2

Tablo 2 (Devamı). Uygulamalarda kullanılan kedi sürüşü optimizasyonuna ilişkin parametreler

Parametre Adı	Parametre Sembolü	Parametre Değeri
Karışım Oranı	KO	0.3
Sabit	c_1	2
Rastgele Değer	r_1	[0, 1] aralığında rastgele bir değer
Maksimum Pozisyon Değeri	$X_{\max}$	Zaman serisinin maksimum değeri
Minimum Pozisyon Değeri	$X_{\min}$	Zaman serisinin minimum değeri
Maksimum Hız Değeri	$V_{\max}$	$(X_{\max} - X_{\min}) * 0,1$ 'in en yakın tamsayı değeri
Minimum Hız Değeri	$V_{\min}$	$-V_{\max}$

Bulanık ilişkilerin belirlenmesi aşamasında ise radyal tabanlı çekirdek fonksiyonu yönteminden yararlanan epsilon destek vektör regresyonu kullanılmıştır. Radyal tabanlı çekirdek fonksiyonuna ilişkin γ gamma değeri 0.05 alınırken, epsilon destek vektör regresyonuna ilişkin C parametresi 100 ve ε epsilon parametresi ise 0.003 olarak alınmıştır.

6.1. Alabama Üniversitesi Verileri Üzerine Uygulama

Bu bölümde, önerilen yeni yöntem, 1971 ile 1992 yılları arasında yıllık olarak gözlenmiş olan “Alabama Üniversitesi kayıt verileri” zaman serisine uygulanmıştır. Söz konusu zaman serisi verileri Tablo 3’de verilmektedir.

Tablo 3. “Alabama Üniversitesi kayıt verileri” zaman serisi

Yıl	Kayıt Sayısı	Yıl	Kayıt Sayısı
1971	13055	1982	15433
1972	13563	1983	15497
1973	13867	1984	15145
1974	14696	1985	15163
1975	15460	1986	15984
1976	15311	1987	16859
1977	15603	1988	18150

Tablo 3 (Devamı). “Alabama Üniversitesi kayıt verileri” zaman serisi

Yıl	Kayıt Sayısı	Yıl	Kayıt Sayısı
1978	15861	1989	18970
1979	16807	1990	19328
1980	16919	1991	19337
1981	16388	1992	18876


Tablo 3’de verilen zaman serisine ilişkin çözümlemeler eğitim kümesi üzerinden gerçekleştirilmiştir. Eğitim kümesi üzerinden yapılan çözümlemelerde, önerilen yöntem, 1971 ile 1992 yılları arasında yıllık olarak gözlenmiş olan Alabama Üniversitesi kayıt verileri zaman serisine küme sayısı 6 ile 15, model derecesi ise 1 ile 10 arasında değiştirilerek uygulanmıştır. Yapılan 100 farklı çözümleme için zaman serisine ilişkin en uygun öngörü modelinin küme sayısının 13 ve model derecesinin 2 olduğunda elde edildiği belirlenmiştir. Önerilen yöntemden elde edilen Hata Kareler Ortalaması (HKO) değeri Yolcu ve ark. [75] çalışmasından alınan diğer yöntemlerin HKO değerleri ile karşılaştırmalı bir şekilde Tablo 4’de verilmektedir.

Tablo 4. Alabama Üniversitesi kayıt verileri eğitim kümesi için yöntemlerin öngörülleri

Yöntem/Yıl	Model Derecesi	HKO
Song ve Chissom [63]	1	412499
Song ve Chissom [65]	1	775687
Chen [18]	1	407507
Hwang ve ark. [45]	5	278919
Huang [41] (Ortalamaya dayalı)	1	78792
Huang [41] (Dağılıma dayalı)	1	124707
Chen [19]	3	86694
Cheng ve ark. [23]	1	228918
Aladağ ve ark. [3]	2	78073
Eğrioğlu ve ark. [33]	3	60714
Eğrioğlu ve ark. [34]	1	66661
Aladağ ve ark. [6]	2	46422
Baş ve ark. [12]	2	26108
Yolcu ve ark. [75]	2	10987
Önerilen Yöntem	2	3676

Tablo 4 incelendiğinde, önerilen yöntemden elde edilen HKO değerinin literatürdeki diğer yöntemlerden elde edilen HKO değerlerine göre 3676 değeri ile daha iyi öngörü performansına sahip olduğu görülmektedir. Ayrıca, OMYH değeri %0,25 ve YD değeri de %89,47 olarak elde edilmiştir. Zaman serisinin eğitim kümesinin gerçek değerleri ile önerilen yöntemden elde edilen en iyi duruma ait öngörülerinin birlikte grafiği Şekil 10’da görülmektedir. Şekil 10 incelendiğinde, önerilen yöntemden elde edilen öngörülerin Alabama Üniversitesi kayıt verilerine ilişkin eğitim kümesinin gözlemleri ile oldukça uyumlu olduğu görülmektedir.

Şekil 10. Alabama Üniversitesi kayıt verileri ile öngörülerinin birlikte grafiği



6.2. TAIFEX Verileri Üzerine Uygulama

Kedi sürüsü optimizasyonuna dayalı önerilen yöntem, bu bölümde, 3 Ağustos 1998 ile 30 Eylül 1998 tarihleri arasındaki günlük olarak gözlenmiş olan “TAIFEX” verileri üzerine uygulanmıştır. Söz konusu zaman serisine ilişkin veriler Tablo 5’de verilmektedir.

Tablo 5. “TAIFEX” zaman serisi

Tarih	TAIFEX	Tarih	TAIFEX
03.08.1998	7552,00	02.09.1998	6430,00
04.08.1998	7560,00	03.09.1998	6200,00
05.08.1998	7487,00	04.09.1998	6403,20
06.08.1998	7462,00	05.09.1998	6697,50

Tablo 5 (Devamı). “TAIFEX” zaman serisi

07.08.1998	7515,00	07.09.1998	6722,30
10.08.1998	7365,00	08.09.1998	6859,40
11.08.1998	7360,00	09.09.1998	6769,60
12.08.1998	7330,00	10.09.1998	6709,75
13.08.1998	7291,00	11.09.1998	6726,50
14.08.1998	7320,00	14.09.1998	6774,55
15.08.1998	7320,00	15.09.1998	6762,00
17.08.1998	7219,00	16.09.1998	6952,75
18.08.1998	7220,00	17.09.1998	6906,00
19.08.1998	7285,00	18.09.1998	6842,00
20.08.1998	7274,00	19.09.1998	7039,00
21.08.1998	7225,00	21.09.1998	6861,00
24.08.1998	6955,00	22.09.1998	6926,00
25.08.1998	6949,00	23.09.1998	6852,00
26.08.1998	6790,00	24.09.1998	6890,00
27.08.1998	6835,00	25.09.1998	6871,00
28.08.1998	6695,00	28.09.1998	6840,00
29.08.1998	6728,00	29.09.1998	6806,00
30.08.1998	6566,00	30.09.1998	6787,00
01.09.1998	6409,00		

Tablo 5’de verilen zaman serisinin çözümlenmesinde yöntemin performans değerlendirmesi test kümesi üzerinden gerçekleştirilmiştir. 03 Ağustos 1998 ile 30 Eylül 1998 tarihleri arasında 47 gözlemden oluşan zaman serisinin 10 Eylül 1998 ile 30 Eylül 1998 tarihleri arasındaki son 16 gözlemi test verisi olarak alınmıştır. Ayrıca önerilen yöntem için küme sayısı 6 ile 15 arasında değiştirilerek, 1. dereceden 10. dereceye kadar 100 farklı çözümleme yapılmıştır. Yapılan çözümlemeler sonucunda, 03 Ağustos 1998 ile 30 Eylül 1998 tarihleri arasında günlük olarak gözlenmiş olan TAIFEX verilerine ilişkin zaman serisine en uygun modelin küme sayısı 10 olan 1. dereceden öngörü modeli olduğu belirlenmiştir.

Önerilen yöntemden elde edilen en iyi duruma ait sonuçlar ile Lee ve ark. [55], Lee ve ark. [56], Hsu ve ark. [39] ve Aladağ ve ark. [6] çalışmalarının sonuçları Tablo 6’da özetlenmiştir. Tablo 6 incelendiğinde, TAIFEX veri seti için önerilen dört farklı

yöntemde HKOK değerinin Lee ve ark. [55] çalışmasında 93,49, Lee ve ark. [56] çalışmasında 102,96, Hsu ve ark. [39] çalışmasında 80,02 ve Aladag ve ark. [6] çalışmasında 74,94 olarak bulunduğu görülmektedir. Bu çalışma kapsamında önerilen yöntemin en iyi durumuna ilişkin HKOK değeri ise 71,90 olarak elde edilmiş olup, bahsi geçen diğer yöntemlere daha küçük bir HKOK değerine sahiptir. Ayrıca önerilen yönteme ilişkin OMYH değerinin de %0,75 ile diğer yöntemlere göre daha küçük bir değere sahip olduğu görülmektedir. Bu değerler ile önerilen yöntemin, diğer yöntemlerden daha iyi öngörü performansına sahip olduğu söylenebilmektedir. Ayrıca, önerilen yöntem, %80 ile yüksek bir yön doğruluğuna da sahiptir.


Tablo 6. Test kümesi için TAIEX değerleri ve yöntemlerin öngörülleri

Tarih	TAIFEX	Lee ve ark. [55]	Lee ve ark. [56]	Hsu ve ark. [39]	Aladag ve ark. [6]	Önerilen Yöntem
10.09.1998	6709,75	6621,43	6917,40	6745,45	6778,28	6793,97
11.09.1998	6726,50	6677,48	6852,23	6757,89	6778,28	6746,46
14.09.1998	6774,55	6709,63	6805,71	6731,76	6778,28	6756,10
15.09.1998	6762,00	6732,02	6762,37	6722,54	6778,28	6799,29
16.09.1998	6952,75	6753,38	6793,06	6753,72	6778,28	6786,05
17.09.1998	6906,00	6756,02	6784,40	6761,54	6856,52	6864,39
18.09.1998	6842,00	6804,26	6970,74	6857,27	6925,15	6867,49
19.09.1998	7039,00	6842,04	6977,22	6898,97	6856,52	6857,84
21.09.1998	6861,00	6839,01	6874,46	6853,07	6856,52	6880,08
22.09.1998	6926,00	6897,33	7126,05	6951,95	6856,52	6864,40
23.09.1998	6852,00	6896,83	6862,49	6896,84	6856,52	6866,20
24.09.1998	6890,00	6919,27	6944,36	6919,94	6856,52	6861,82
25.09.1998	6871,00	6903,36	6831,88	6884,99	6856,52	6867,77
28.09.1998	6840,00	6895,95	6843,24	6894,10	6856,52	6866,31
29.09.1998	6806,00	6879,31	6858,45	6866,17	6856,52	6856,89
30.09.1998	6787,00	6878,34	6825,64	6865,06	6778,28	6832,36
HKOK		93,49	102,96	80,02	74,94	71,90
OMYH		%1,09	%1,14	%0,87	%0,76	%0,75
YD		%53,33	%80,00	%73,33	%73,33	%80,00

Ayrıca zaman serisinin test kümesinin gerçek değerleri ile önerilen yöntemden elde edilen en iyi duruma ait öngörülerinin birlikte grafiği Şekil 11’de görülmektedir. Şekil 11

incelendiğinde, önerilen yöntemden elde edilen öngörülerin TAIEX verilerine ilişkin test kümesinin gözlemleri ile uyumlu olduğu görülmektedir.

Şekil 11. TAIEX verilerine ilişkin test kümesinin gözlemleri ile öngörülerinin birlikte grafiği



6.3. İMKB Verileri Üzerine Uygulama

Bu bölümde ise önerilen yöntem, 2009 ve 2010 yıllarında günlük olarak gözlenmiş olan “İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi” verileri üzerine her bir yıl için ayrı ayrı uygulanmıştır. 2009 yılı için öncelikle 63 gözlemden oluşan zaman serisinin 01 Ekim 2009 ile 31 Aralık 2009 tarihleri arasındaki son 7 gözlemi (veri seti 1), daha sonra ise 82 gözlemden oluşan 02 Şubat 2009 ile 29 Mayıs 2009 tarihleri arasındaki son 7 gözlemi (veri seti 2) ve son 15 gözlemi (veri seti 3) test verisi olarak alınmıştır. 2010 yılı için de öncelikle 55 gözlemden oluşan zaman serisinin 1 Ekim 2010 ile 23 Aralık 2010 tarihleri arasındaki son 7 gözlemi (veri seti 4), daha sonra ise 41 gözlemden oluşan 1 Nisan 2010 ile 31 Mayıs 2010 tarihleri arasındaki son 7 gözlemi (veri seti 5) ve son 15 gözlemi (veri seti 6) test verisi olarak alınmıştır. Küme sayısı 6 ile 15, model derecesi ise 1 ile 10 arasında değiştirilerek her bir veri seti için 100 farklı öngörü modeli için çözümleme yapılmıştır. Önerilen yönteme ilişkin performans değerlendirmesi test kümesi üzerinden gerçekleştirilmiş olup, bulanık ilişkilerin belirlenmesi aşamasında eğitim kümesi Destek Vektör Makineleri eğitilmiş ve test kümesine ilişkin öngörü değerleri elde edilmiştir.

2009 yılına ilişkin önerilen yöntem ile literatürdeki diğer yöntemlerden elde edilen değerler karşılaştırmalı şekilde Tablo 7, Tablo 8 ile Tablo 9’da verilmektedir.

Tablo 7. Veri seti 1 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	Song ve Chissom [63]	Chen [18]	Huarng [41]		Huarng ve Yu [43]	Cheng ve ark. [23]	Aladağ ve ark. [6]	Yolcu ve ark. [73]	Yolcu ve ark. [75]	Önerilen Yöntem
				Dağılıma Dayalı	Ortalamaya Dayalı						
23.12.2009	51162	51137	52150	51900	51573	51033	50872	51682,64	51317	51238,30	51708,60
24.12.2009	51461	51137	50850	50700	50373	51033	50763	51682,64	51317	51339,81	51302,58
25.12.2009	51661	51137	50850	50700	51240	51033	50763	51682,64	51317	51339,81	51656,87
28.12.2009	51619	51137	52150	51900	51573	51033	50763	51682,64	51317	51339,81	51767,18
29.12.2009	51786	51137	52150	51900	51573	51033	50763	51682,64	51317	51339,81	51752,63
30.12.2009	51668	51137	52150	51900	51773	52004	50763	51682,64	51317	51339,81	51770,31
31.12.2009	52825	51137	52150	51900	51573	51033	50763	51682,64	51317	51339,81	51769,15
HKOK		771	667	660	671	830	1084	484	640	622	459
OMYH		%1,16	%1,23	%1,11	%0,97	%1,28	%1,85	%0,57	%0,90	%0,84	%0,56
YD		%33,33	%33,33	%33,33	%33,33	%16,67	%33,33	%83,33	%50,00	%50,00	%83,33

01 Ekim 2009 ile 31 Aralık 2009 tarih aralığında gözlenen İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 7 olduğu 1. dereceden model olarak belirlenmiştir. Tablo 7 incelendiğinde, veri seti 1 için literatürdeki çalışmalar arasında önerilen en iyi yöntemin sırasıyla 484 ve %0,57 ile en küçük HKOK ve OMYH değerlerine sahip olan Aladag ve ark. [6] olduğu görülmektedir. Bu çalışma kapsamında ise önerilen yöntemin en iyi durumuna ilişkin HKOK değeri 459 ve OMYH değeri %0,56 elde edilmiş olup, özellikle HKOK değerinin küçük olması bakımından diğer yöntemlerden daha iyi bir öngörü performansı elde edilebileceği görülmektedir. Önerilen yöntemin yön doğruluğu da Aladag ve ark. [6] çalışmasındaki gibi %83,33 olarak elde edilmiştir.

Tablo 8. Veri seti 2 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
21.05.2009	34721	35140	35140	35179	33641	35218	34565	35023,51
22.05.2009	35015	34721	34721	34803	33641	35039	34836	34917,49
25.05.2009	35408	35015	35014	35114	33641	35127	34869	35067,22
26.05.2009	34861	35408	35408	35407	33641	35733	35217	34990,03
27.05.2009	35169	34861	34861	34966	33641	35191	35017	35018,36
28.05.2009	35021	35169	35169	35246	33641	35401	35014	35064,86
29.05.2009	35003	35021	35021	35098	33641	35399	35032	35068,20
HKOK		345	345	325	1402	446	267	194
OMYH		%0,87	%0,87	%0,83	%3,96	%1,01	%0,58	%0,46
YD		%0,00	%0,00	%66,67	%50,00	%50,00	%66,67	%83,33

2 Şubat 2009 ile 29 Mayıs 2009 tarih aralığında gözlenen ve son 7 gözlemi test kümesi olarak alınan İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 6 olduğu 5. dereceden model olarak belirlenmiştir. Tablo 8 incelendiğinde, önerilen yöntemin en iyi durumuna ilişkin HKOK değerinin 194 ve OMYH değerinin ise %0,46 olduğu görülmektedir. Baş ve ark. [12] çalışmasından alınan diğer yöntemlerin sonuçlarına göre önerilen yöntemin daha küçük HKOK ve OMYH değerlerine sahip olması sebebiyle yüksek öngörü performansına sahip olduğu söylenebilmektedir. Ayrıca, önerilen yöntemin yön doğruluğu %83,33 olarak elde edilmiş olup, bu değer diğer yöntemlerden elde edilen en yüksek değer olan %66,67 değerinden de yüksektir.

Tablo 9. Veri seti 3 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
08.05.2009	32806	32843	32843	33061	33641	33179	33356	32776,61
11.05.2009	32203	32806	32806	33159	33641	33102	32908	32702,84
12.05.2009	33043	32203	32203	32531	33641	32618	32452	32395,97
13.05.2009	32829	33043	33043	33339	33641	33314	32699	33162,21
14.05.2009	33095	32829	32829	33031	33641	33193	32940	32744,73

Tablo 9 (Devamı). Veri seti 3 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
15.05.2009	33485	33095	33095	33356	33641	33350	33085	33258,34
18.05.2009	33666	33485	33485	33651	33641	33790	33347	33650,94
20.05.2009	35140	33666	33666	33795	32757	33961	33662	33636,68
21.05.2009	34721	35140	35140	34926	32757	35353	34559	34880,44
22.05.2009	35015	34721	34721	34547	32757	35066	35000	34598,09
25.05.2009	35408	35015	35014	34887	32757	35248	35042	34964,21
26.05.2009	34861	35408	35408	35108	32757	35721	35258	34637,09
27.05.2009	35169	34861	34861	34727	32757	35197	35186	34872,82
28.05.2009	35021	35169	35169	35002	32757	35445	35104	34879,33
29.05.2009	35003	35021	35021	34845	32757	35370	35103	34963,61
HKOK		540	540	525	1754	534	514	501
OMYH		%1,20	%1,20	%1,14	%4,38	%1,22	%1,07	%1,04
YD		%7,14	%7,14	%71,42	%64,29	%64,29	%71,43	%71,43

02 Şubat 2009 ile 29 Mayıs 2009 tarih aralığında gözlenen ve son 15 gözlemi test kümesi olarak alınan İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 11 olduğu 8. dereceden model olarak belirlenmiştir.

Tablo 9 incelendiğinde, veri seti 3 için Baş ve ark. [12] çalışmasından alınan yöntemlerde en iyi yöntemin 514 HKOK değeri ve %1,07 OMYH değeri ile Baş ve ark. [12] tarafından önerilen yöntem olduğu görülmektedir. Bu çalışma kapsamında önerilen yöntemin ise en iyi durumuna ilişkin HKOK değeri 501 ve OMYH değeri %1,04 olarak elde edilmiştir. Bu değerlerin Baş ve ark. [12] çalışmasındaki değerlerden daha küçük olduğu ve dolayısıyla iyi bir öngörü performansı verebileceği söylenebilmektedir. Önerilen yöntemin yön doğruluğu da %71,43 ile Baş ve ark. [12] çalışmasındaki gibi yüksek bir değer olarak elde edilmiştir.

2010 yılına ilişkin önerilen yöntemden elde edilen öngörü değerleri ile literatürdeki diğer yöntemlerden elde edilen öngörü değerleri karşılaştırmalı şekilde Tablo 10, Tablo 11 ve Tablo 12’de verilmektedir.

Tablo 10. Veri seti 4 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	Song ve Chissom [63]	Chen [18]	Huarng [41]		Huarng ve Yu [43]	Cheng ve ark. [23]	Aladağ ve ark. [6]	Yolcu ve ark. [73]	Yolcu ve ark. [75]	Önerilen Yöntem
				Dağılıma Dayalı	Ortalamaya Dayalı						
15.12.2010	65499	65355	65500	66167	66500	67254	65992	66177,15	65999	64975,75	66422,19
16.12.2010	64429	65355	65500	65500	66300	66035	65992	65332,19	64813	63613,39	64123,66
17.12.2010	63524	65974	65500	66000	64500	65435	65992	64841,98	64864	64181,55	64358,09
20.12.2010	63502	64736	64950	63500	63500	63668	65992	64841,98	64871	64067,28	63659,31
21.12.2010	64820	64736	64950	63500	63500	63668	65992	64841,98	64858	64179,37	64204,19
22.12.2010	65440	64974	65500	66000	65500	66038	65992	64841,98	65522	66137,00	65620,52
23.12.2010	66219	65355	65500	65500	66300	66035	65992	66397,62	64813	66045,79	65896,43
HKOK		1.161	1.048	1.213	1.015	1.257	1.545	862	930	611	558
OMYH		%1,37	%1,20	%1,51	%1,17	%1,63	%1,99	%1,12	%1,13	%0,90	%0,74
YD		%50,00	%50,00	%50,00	%50,00	%50,00	%50,00	%66,67	%50,00	%83,33	%83,33

1 Ekim 2010 ile 23 Aralık 2010 tarih aralığında gözlenen İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 10 olduğu 6. dereceden model olarak belirlenmiştir. Tablo 10 incelendiğinde, veri seti 4 için literatürdeki çalışmalar arasında en iyi öngörü performansına sahip yöntemin 611 HKOK ve %0,90 OMYH değeri ile Yolcu ve ark. [75] çalışmasında önerilen yöntem olduğu görülmektedir. Bu çalışma kapsamında önerilen yöntemden ise HKOK değeri 558 ve OMYH değeri %0,74 olarak elde edilmiştir. Bu değerlerin, Yolcu ve ark. [75] tarafından önerilen yöntemdeki değerlerden bile küçük olması sebebiyle, önerilen yöntemin Tablo 10'da verilen yöntemlere göre daha iyi bir öngörü performansı sunmasının mümkün olduğu görülmektedir. Ayrıca önerilen yöntemden elde edilen yön doğruluğu da %83,33 ile Yolcu ve ark. [75] çalışmasındaki gibi yüksek bir değere sahiptir.

Tablo 11. Veri seti 5 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
21.05.2010	54112	54450	54520	54249	53278	54349	53724	54597,23
24.05.2010	54558	54112	54123	54460	53278	54032	54316	54152,82
25.05.2010	52257	54558	54546	54751	53278	54602	54515	54523,09
26.05.2010	54104	52257	52321	53127	53897	52430	53164	53601,72
27.05.2010	54498	54104	54054	54013	53278	54111	53774	54098,03
28.05.2010	55234	54498	54486	54715	53278	54561	54475	54522,93
31.05.2010	54385	55234	55213	55032	54791	55100	55033	54620,95
HKOK		1.221	1.208	1.077	1.128	1.180	1.050	964
OMYH		%1,84	%1,85	%1,43	%1,82	%1,75	%1,59	%1,34
YD		%0,00	%66,67	%66,67	%50,00	%66,67	%66,67	%83,33

1 Nisan 2010 ile 31 Mayıs 2010 tarih aralığında gözlenen ve son 7 gözlemi test kümesi olarak alınan İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 10 olduğu 2. dereceden model olarak belirlenmiştir. Tablo 11 incelendiğinde, önerilen yöntemin en iyi durumuna ilişkin HKOK değerinin 964 ve OMYH değerinin ise %1,34 olarak elde edildiği görülmektedir. Bu değerlerin Baş ve ark. [12] çalışmasından alınan diğer yöntemlerden elde edilen değerlerden daha küçük olması sebebiyle öngörü performansının diğer yöntemlere göre başarılı olma ihtimalinin yüksek olabileceği söylenebilmektedir. Ayrıca, önerilen yöntem, %83,33 ile Tablo 11'deki diğer yöntemlerden daha yüksek bir yön doğruluğuna sahiptir.

Tablo 12. Veri seti 6 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
10.05.2010	56448	52687	52687	52671	52522	51771	54619	54514,54
11.05.2010	56462	56448	56448	56424	57061	56908	55443	56892,37
12.05.2010	57976	56462	56462	56438	57061	56109	55794	56842,75
13.05.2010	57930	57976	57976	57902	57817	57735	56291	58148,98
14.05.2010	55748	57930	57930	57859	57817	57827	56252	58020,92
17.05.2010	56071	55748	55748	55718	54791	54773	56070	55823,23
18.05.2010	56978	56071	56071	56045	54791	55595	55923	56392,09


Tablo 12 (Devamı). Veri seti 6 için İMKB verileri ve yöntemlerin öngörülleri

Tarih	İMKB	ARIMA	Üstel Düzleştirme	MLP Yapay Sinir Ağı	Song ve Chissom [64]	Türkşen [67]	Baş ve ark. [12]	Önerilen Yöntem
20.05.2010	54450	56978	56978	56949	57061	56677	56545	57035,47
21.05.2010	54112	54450	54450	54398	53278	53543	55432	54713,74
24.05.2010	54558	54112	54112	54058	53278	53789	54496	54547,81
25.05.2010	52257	54558	54558	54507	53278	54475	54630	54733,74
26.05.2010	54104	52257	52257	52275	52522	51697	53635	54689,68
27.05.2010	54498	54104	54103	54050	53278	54378	53584	54537,87
28.05.2010	55234	54498	54498	54446	53278	54445	53961	54769,76
31.05.2010	54385	55234	55234	55195	54791	55221	54361	55240,75
HKOK		1.612	1.612	1.603	1.742	1.852	1.357	1.299
OMYH		%2,20	%2,20	%2,20	%2,65	%2,64	%2,02	%1,75
YD		%7,14	%7,14	%57,14	%64,29	%64,29	%57,14	64,29


1 Nisan 2010 ile 31 Mayıs 2010 tarih aralığında gözlenen ve son 15 gözlemi test kümesi olarak alınan İMKB verilerine ilişkin önerilen yöntemden elde edilen en iyi öngörü modeli, küme sayısının 10 olduğu 4. dereceden model olarak belirlenmiştir. Tablo 12 incelendiğinde, Baş ve ark. [12] çalışmasından alınan yöntemler arasında en iyi öngörü performansına sahip yöntemin 1.357 HKOK ve %2,02 OMYH değeri ile Baş ve ark. [12] tarafından önerilen yöntem olduğu görülmektedir. Bu çalışma kapsamında ise önerilen yöntemin en iyi durumuna ilişkin HKOK değeri 1.299 ve OMYH değeri ise %1,75 olarak elde edilmiştir. Bu değerler ile önerilen yöntemin, Baş ve ark. [12] tarafından önerilen yöntemden bile daha küçük değerler alması, Tablo 12'deki yöntemlerden daha iyi öngörü performansına sahip olabileceği anlamına gelmektedir. Ayrıca, önerilen yöntem, Song ve Chissom [64] ve Türkşen [67] çalışmasında önerilen yöntemlerdeki gibi %64,29 yön doğruluğuna sahiptir.

İMKB zaman serilerine ilişkin test kümesinin gerçek değerleri ile önerilen yöntemden elde edilen en iyi duruma ait öngörülerinin birlikte grafiği aşağıdaki şekillerde verilmektedir. Tüm şekiller incelendiğinde, önerilen yöntemden elde edilen öngörülerin her bir test kümesine ilişkin gözlemleri ile uyumlu olduğu görülmektedir.


Şekil 12. Veri seti 1 için İMKB değerleri ve öngörülerinin birlikte grafiği




Şekil 13. Veri seti 2 için İMKB değerleri ve öngörülerinin birlikte grafiği




Şekil 14. Veri seti 3 için İMKB değerleri ve öngörülerinin birlikte grafiği




Şekil 15. Veri seti 4 için İMKB değerleri ve öngörülerinin birlikte grafiği



Şekil 16. Veri seti 5 için İMKB değerleri ve öngörülerinin birlikte grafiği



Şekil 17. Veri seti 6 için İMKB değerleri ve öngörülerinin birlikte grafiği



6.4. Dış Ticaret Hadleri Verileri Üzerine Uygulama

Uygulamanın bu son bölümünde ise literatürde bulanık zaman serileri üzerine yapılan çalışmalarda kullanılan verilerden farklı olarak yeni bir veri seti kullanılmıştır. Türkiye İstatistik Kurumu'ndan elde edilen ve *Dış Ticaret Hadleri* olarak adlandırılan bu veri seti, ihracat fiyatlarının ithalat fiyatlarına oranını vermekle birlikte, 2010 yılı Ocak ayından 2016 yılı Aralık ayı sonuna kadar olan dönemdeki verileri içermektedir. Söz konusu veriler, Tablo 13'de verilmektedir.

Tablo 13. “Dış Ticaret Hadleri” zaman serisi

Dönem	DTH	Dönem	DTH	Dönem	DTH	Dönem	DTH
Ocak 2010	103,1	Mart 2012	95,4	Mayıs 2014	100,0	Temmuz 2016	112,5
Şubat 2010	100,8	Nisan 2012	94,8	Haziran 2014	100,2	Ağustos 2016	113,1
Mart 2010	100,1	Mayıs 2012	95,6	Temmuz 2014	101,2	Eylül 2016	112,7
Nisan 2010	99,0	Haziran 2012	96,5	Ağustos 2014	99,9	Ekim 2016	110,5
Mayıs 2010	98,9	Temmuz 2012	98,2	Eylül 2014	99,8	Kasım 2016	110,9
Haziran 2010	99,4	Ağustos 2012	98,2	Ekim 2014	100,9	Aralık 2016	110,2
Temmuz 2010	101,8	Eylül 2012	97,2	Kasım 2014	101,0		
Ağustos 2010	99,7	Ekim 2012	97,4	Aralık 2014	102,3		
Eylül 2010	99,9	Kasım 2012	96,9	Ocak 2015	105,6		
Ekim 2010	99,2	Aralık 2012	97,5	Şubat 2015	105,3		
Kasım 2010	99,0	Ocak 2013	99,0	Mart 2015	104,2		
Aralık 2010	99,0	Şubat 2013	97,4	Nisan 2015	105,4		
Ocak 2011	99,4	Mart 2013	97,6	Mayıs 2015	106,9		
Şubat 2011	98,9	Nisan 2013	97,5	Haziran 2015	106,7		
Mart 2011	98,4	Mayıs 2013	98,9	Temmuz 2015	107,7		
Nisan 2011	97,5	Haziran 2013	99,8	Ağustos 2015	107,8		
Mayıs 2011	97,6	Temmuz 2013	100,0	Eylül 2015	109,5		
Haziran 2011	98,3	Ağustos 2013	99,3	Ekim 2015	108,7		
Temmuz 2011	98,1	Eylül 2013	98,7	Kasım 2015	107,9		
Ağustos 2011	95,6	Ekim 2013	97,4	Aralık 2015	110,0		
Eylül 2011	95,2	Kasım 2013	98,8	Ocak 2016	113,9		
Ekim 2011	94,0	Aralık 2013	98,2	Şubat 2016	114,8		
Kasım 2011	95,4	Ocak 2014	100,4	Mart 2016	113,8		
Aralık 2011	95,9	Şubat 2014	98,8	Nisan 2016	114,6		
Ocak 2012	97,5	Mart 2014	97,6	Mayıs 2016	112,6		
Şubat 2012	97,4	Nisan 2014	98,6	Haziran 2016	111,7		

Önerilen yöntemin performans değerlendirmesi test kümesi üzerinden gerçekleştirilmiştir. Dış Ticaret Hadleri (DTH) verilerine ilişkin zaman serisi, eğitim kümesi ve test kümesi olarak ikiye ayrılmıştır. 2010 yılı Ocak ayı ile 2015 yılı Aralık ayı arasındaki 72 gözlem eğitim kümesi olarak alınmıştır. Test kümesi olarak ise 2016 yılına ilişkin öncelikle son 6 gözlem (veri seti 7), daha sonra ise son 12 gözlem (veri seti 8) ele alınmıştır.

Bu bölümde de diğer bölümlerde olduğu gibi bulanık ilişkilerin belirlenmesi aşamasında eğitim kümesi Destek Vektör Makinelerinde sıklıkla kullanılan radyal tabanlı çekirdek fonksiyonundan yararlanan epsilon destek vektör regresyonu ile eğitilmiş ve test kümesine ilişkin öngörü değerleri elde edilmiştir.

Bilindiği üzere, bu çalışmada kedi sürüsü optimizasyonu küme merkezlerinin belirlenmesinde, destek vektör makineleri ise bulanık ilişkilerin belirlenmesinde kullanılmaktadır. Bu bölümde ise kedi sürüsü optimizasyonunun etkinliğinin bulanık zaman serileri literatüründe yer alan diğer sezgisel yöntemlerle karşılaştırılabilmesi açısından, literatürde yer alan ve Bölüm 3’de belirtilen bu yöntemlerin her biri için ayrı ayrı Matlab programında kodlama yapılmıştır. Bu programların tamamında bulanık ilişkilerin belirlenmesi aşamasında Destek Vektör Makineleri (dvm) kullanılmıştır. Parçacık Sürü Optimizasyonu, Genetik Algoritma, Yapay Arı ile Karınca Koloni Algoritması ise Kedi Sürüsü Optimizasyonunun kullanıldığı şekilde küme merkezlerinin belirlenmesinde kullanılmıştır. Söz konusu beş farklı yöntem için küme sayısı 6 ile 15, model derecesi ise 1 ile 10 arasında değiştirilerek veri seti 7 için $100 \times 5 = 500$ ve veri seti 8 için $100 \times 5 = 500$ olmak üzere toplam 1000 farklı öngörü modeli için çözümleme yapılmıştır.

Kedi sürüsü optimizasyonuna dayalı önerilen yöntem *ksodvm* biçiminde ifade edilirken, kedi sürüsü optimizasyonun yerine parçacık sürü optimizasyonunun kullanıldığı yöntem *psodvm*, genetik algoritmanın kullanıldığı yöntem *gadvm*, yapay arı koloni algoritmasının kullanıldığı yöntem *yakadvm* ve karınca koloni algoritmasının kullanıldığı yöntem *kkadvm* ile ifade edilmiştir. Ayrıca bu yöntemlerin her birinde aynı olan parametreler eşit olarak alınmış olup, genetik algoritmada çaprazlama oranı 0.7 ve mutasyon olasılığı 0.3 olarak alınmıştır.

Yapılan çözümler sonucunda zaman serisine en uygun modelin veri seti 7’de psodvm için küme sayısının 12 olduğu 3. dereceden, gadvm için küme sayısının 10 olduğu 5. dereceden, yakadvn için küme sayısının 14 olduğu 8. dereceden, kkadvn için küme sayısının 12 olduğu 6. dereceden ve ksodvm için küme sayısının 13 olduğu 7. dereceden öngörü modeli, veri seti 8’de ise psodvm için küme sayısının 15 olduğu 4. dereceden, gadvm için küme sayısının 11 olduğu 1. dereceden, yakadvn için küme sayısının 10 olduğu 8. dereceden, kkadvn için küme sayısının 6 olduğu 9. dereceden ve ksodvm için küme sayısının 14 olduğu 5. dereceden öngörü modeli olduğu belirlenmiştir. Önerilen yöntemden elde edilen en iyi sonuçlar ile diğer optimizasyon yöntemlerinden elde edilen en iyi sonuçlar Tablo 14 ve Tablo 15’de verilmiştir.

Tablo 14. Veri seti 7 için beş farklı yöntemin DTH verileri test kümesine ilişkin en iyi sonuçlar

Dönem	DTH	psodvm	gadvm	yakadvn	kkadvn	ksodvm
Temmuz 2016	112,5000	111,7537	111,872	111,6804	111,5958	111,7125
Ağustos 2016	113,1000	112,0684	111,9807	112,0057	112,0960	112,0175
Eylül 2016	112,7000	113,0466	112,2669	112,9668	112,3232	111,9929
Ekim 2016	110,5000	112,1853	111,9955	112,1075	112,1090	111,9685
Kasım 2016	110,9000	110,5649	111,0661	110,2815	110,7449	110,7905
Aralık 2016	110,2000	110,7841	111,0806	110,5947	111,1366	110,7353
HKOK		0,9161	0,9013	0,9186	0,9538	0,8895
OMYH		%0,71	%0,71	%0,72	%0,75	%0,70
YD		%80,00	%60,00	%60,00	%60,00	%80,00

Tablo 14’den görüldüğü üzere; veri seti 7 için elde edilen en iyi modellere ilişkin sonuçların, parçacık sürü optimizasyonu için 0,9161 HKOK, %0,71 OMYH; %80,00 YD; genetik algoritma için 0,9013 HKOK, %0,71 OMYH ve %60,00 YD; yapay arı koloni algoritması için 0,9186 HKOK, %0,72 OMYH ve %60,00 YD; karınca koloni algoritması için 0,9538 HKOK, %0,75 OMYH ve %60,00 YD olarak elde edildiği görülmektedir. Önerilen yöntemin sonuçlarına bakıldığında ise en iyi modelin durumuna ilişkin HKOK değerinin 0,8895 ve OMYH değerinin ise %0,70 olduğu görülmektedir. Bu değerler ile önerilen yöntemin, diğer yöntemlere göre daha iyi bir öngörü performansına sahip olabileceği söylenebilmektedir. Ayrıca, önerilen yöntemden elde edilen %80,00 yön doğruluğu yüksek bir yön doğruluğu olmakla birlikte, parçacık sürüsü optimizasyonu kullanıldığında da aynı değerin elde edildiği görülmektedir.


Tablo 15. Veri seti 8 için beş farklı yöntemin DTH verileri test kümesine ilişkin en iyi sonuçlar

Dönem	DTH	psodvm	gadvm	yakadv	kkadv	ksodvm
Ocak 2016	113,9000	110,7015	110,9900	110,671	111,0359	111,1056
Şubat 2016	114,8000	114,5059	113,7018	113,6474	113,8539	114,2207
Mart 2016	113,8000	112,7631	113,1436	112,2382	113,4419	112,0752
Nisan 2016	114,6000	113,8686	113,5753	113,5485	113,8162	113,4421
Mayıs 2016	112,6000	113,1723	113,2939	112,4613	113,5616	112,4244
Haziran 2016	111,7000	111,0369	112,5157	112,0077	112,2455	111,6059
Temmuz 2016	112,5000	111,034	111,5940	111,7423	111,4284	111,9049
Ağustos 2016	113,1000	111,2357	112,3460	112,0833	112,1547	112,1818
Eylül 2016	112,7000	112,2794	112,7559	113,0719	113,2472	112,4382
Ekim 2016	110,5000	111,3524	112,6397	112,1395	112,4526	112,1128
Kasım 2016	110,9000	110,3716	110,8890	110,8209	111,2947	110,9128
Aralık 2016	110,2000	111,0691	110,7794	111,0996	111,4073	111,5052
HKOK		1,2993	1,2453	1,3122	1,2527	1,2271
OMYH		%0,92	%0,86	%0,90	%0,93	%0,83
YD		%63,64	%63,64	%63,64	%54,55	%72,73


Tablo 15'den görüldüğü üzere; veri seti 8 için ise elde edilen en iyi modellere ilişkin sonuçların, parçacık sürü optimizasyonu için 1,2993 HKOK, %0,92 OMYH; %63,64 YD; genetik algoritma için 1,2453 HKOK, %0,86 OMYH ve %63,64 YD; yapay arı koloni algoritması için 1,3122 HKOK, %0,90 OMYH ve %63,64 YD; karınca koloni algoritması için 1,2527 HKOK, %0,93 OMYH ve %54,55 YD olarak elde edildiği görülmektedir. Önerilen yöntemin sonuçlarına bakıldığında ise en iyi modelin durumuna ilişkin HKOK değerinin 1,2271 ve OMYH değerinin ise %0,83 olduğu görülmektedir. Önerilen yöntemden diğer yöntemlere göre daha küçük HKOK ve OMYH değerlerinin elde edilebilmesi, önerilen yöntemin diğer yöntemlerden daha etkin olmasının mümkün olabileceğini göstermektedir. Ayrıca, önerilen yöntem, Tablo 15'deki diğer yöntemlerden %72,73 ile daha yüksek bir yön doğruluğuna sahiptir.

Ayrıca DTH zaman serilerine ilişkin test kümesinin gerçek değerleri ile önerilen yöntemden elde edilen en iyi duruma ait öngörülerinin birlikte grafiği Şekil 18 ve Şekil 19'da görülmektedir. Şekil 18 ve Şekil 19 incelendiğinde, önerilen yöntemden elde edilen öngörülerin DTH verilerine ilişkin test kümesinin gözlemleri ile uyumlu olduğu görülmektedir.

Şekil 18. Veri seti 7 için en iyi model (ksodvm) için test kümesi ile öngörülerinin birlikte grafiği



Şekil 19. Veri seti 8 için en iyi model (ksodvm) için test kümesi ile öngörülerinin birlikte grafiği



Önerilen yöntemin ve çalışma kapsamında kullanılan diğer sezgisel yöntemlerin her bir derece ve her bir küme sayısı için DTH verilerine uygulanması ile elde edilen simülasyon sonuçlarına ilişkin minimum HKOK, ortalama HKOK ve HKOK'ların standart sapmaları Tablo 16'da verilmektedir.

Tablo 16. Önerilen yöntem ile diğer sezgisel yöntemlerin DTH verileri simülasyon sonuçları

		psodvm	gadvm	yakadvm	kkadvm	ksodvm
Veri Seti 7	Minimum	0,9161	0,9013	0,9186	0,9538	0,8895
	Ortalama	1,2297	1,1789	1,1813	1,1813	1,1661
	Standart Sapma	0,2685	0,1884	0,1759	0,2962	0,1728

Tablo 16 (Devamı). Önerilen yöntem ile diğer sezgisel yöntemlerin DTH verileri simülasyon sonuçları

Veri Seti 8	Minimum	1,2993	1,2453	1,3122	1,2527	1,2271
	Ortalama	2,9558	2,8888	2,8402	3,1069	2,5708
	Standart Sapma	1,3853	1,3899	1,4953	1,1599	1,0239

Tablo 16'dan görüldüğü üzere, veri seti 7 için;

- minimum HKOK değerleri
 $kkadv m > yakadv m > psodvm > gadv m > ksodvm$
- ortalama HKOK değerleri
 $psodvm > yakadv m > kkadv m > gadv m > ksodvm$
- HKOK'ların standart sapma değeri
 $kkadv m > psodvm > gadv m > yakadv m > ksodvm$

veri seti 8 için ise;

- minimum HKOK değerleri
 $yakadv m > psodvm > kkadv m > gadv m > ksodvm$
- ortalama HKOK değerleri
 $kkadv m > psodvm > gadv m > yakadv m > ksodvm$
- HKOK'ların standart sapma değeri
 $yakadv m > gadv m > psodvm > kkadv m > ksodvm$

biçiminde sıralanmaktadır. Sıralama sonuçlara bakıldığında, bulanık zaman serilerinde önerilen kedi sürüsü optimizasyonuna dayalı yöntemin DTH verilerinde gerek minimum HKOK gerek ortalama HKOK gerekse de HKOK'ların standart sapması açısından ele alınan diğer sezgisel yöntemlerden daha küçük, daha istikrarlı ve dolayısıyla daha iyi performans değerlerini vermesinin mümkün olduğu görülmektedir.

7. SONUÇ VE ÖNERİLER

Karar verme sürecinde vazgeçilmez bir unsur olan ve gelecek olayları ya da koşulları tahmin etmek için kullanılan öngörü sürecinde karar vericiler belirsizlik altında çalışmaktadırlar. Bu belirsizlik ortamlarında geliştirilen zaman serisi analizi yöntemleri, tecrübe ya da düşünce gibi nitel yöntemlerden ziyade, eldeki somut verilerle ileriye yönelik tahmin yapma sürecinde kullanılan etkili yöntemlerdir.

Zaman içerisinde belirli aralıklar ile gözlemlenmiş olan verilerin istatistiki açıdan incelenmesi ve öngörüsünün gerçeğe yakın şekilde yapılmasına olanak tanıyan zaman serisi analizi yöntemleri, model varsayımı ve gözlem sayısı gibi teorik kısıtları içeren klasik yöntemlerden oluşmaktadır. Ancak son yıllarda geliştirilen ve belirsizlik içeren verilerde etkili olan bulanık zaman serisi analizi yöntemlerinin önemi giderek artmaktadır. Bu yöntemler, herhangi bir teorik kısıt içermemesi sebebiyle klasik zaman serisi yöntemlerine tercih edilmektedir.

Literatürde yer alan çalışmalar, bulanık zaman serilerini bulanıklaştırma, bulanık ilişkilerin belirlenmesi ve berraklaştırma biçiminde temel olarak üç aşama halinde ele almaktadır. Bulanıklaştırma aşamasında, evrensel küme parçalanmasına dayalı aralık uzunluklarının keyfi olarak belirlenmesinin önüne geçmek için genellikle optimizasyona dayalı yaklaşımlar önerilirken, evrensel küme parçalanmasına ihtiyaç duymayan ve gözlemlerin bulanık kümeler üyeliği değerlerini dikkate alan çalışmalar da önerilmiştir. Bulanık ilişkilerin belirlenmesi aşamasındaki amaç ise genel olarak karmaşık ve hesaplanması zor yöntemler yerine daha basit ve işlem kolaylığı olan yöntemlerin uygulanması yönünde olmuştur. Berraklaştırma aşamasında da ağırlıklandırılmış yöntem gibi farklı yöntemler kullanan birkaç çalışma dışında genellikle merkezileştirme yöntemi kullanılmıştır.

Yapılan tüm çalışmalarda da ortak amaç, öngörü performansını arttırarak daha iyi ve gerçek değerlere daha yakın öngörü değerleri elde etmek olmuştur. Bu ortak amacı temel alarak bu çalışmada yapılanlar ve literatürdeki diğer çalışmalara göre üstün olabilecek tarafları aşağıda maddeler halinde belirtilmektedir:

- Bulanıklaştırma aşamasında evrensel küme parçalanması ile aralık uzunluklarının belirlendiği yöntemlerden ziyade evrensel küme parçalanmasına ihtiyaç duyulmayan ve gözlemlerin üyelik değerlerinin dikkate alındığı çalışmaların daha iyi performans gösterdiği ve bulanık ilişkilerin belirlenmesi aşamasında kullanılan yöntemin daha etkin olmasını sağladığı görülmektedir. Bu amaçla, bu çalışmada üyelik değerlerinin de dikkate alınması açısından kedi sürüsü optimizasyonu yöntemi ile küme merkezleri belirlenmiş, Öklid uzaklığı ile gözlemlerin küme merkezlerine uzaklığı hesaplanmış ve son olarak da bu uzaklıklar yoluyla Bulanık C ortalamalar yöntemindeki gibi gözlemlerin kümelere üyelik değerleri hesaplanmıştır.
- Bulanık ilişkilerin belirlenmesi aşamasında yapay sinir ağlarıyla yakından ilişkili olan destek vektör makineleri kullanılmıştır. Destek vektör makineleri, bir fonksiyon yardımıyla veriyi sınıflandırma ve dolayısıyla sadeleştirme mantığına dayalı olduğu için daha doğru tahmin yapılmasına olanak sağlamaktadır. Ayrıca eğitim verileri çok az olsa bile ortalama hata karesini en aza indirdiği için iyi sonuçlar verebilmektedir. Söz konusu yöntem ile hem karmaşık matris işlemleri, bulanık grup ilişki tabloları gibi hesaplanması zor yöntemlerin kullanılmasının önüne geçilmiş hem de işlem kolaylığı olan yapay sinir ağları gibi diğer yöntemlere alternatif oluşturmuştur.
- Berraklaştırma aşamasında ise gözlemlerin kümelere üyelik değerleri de dikkate alındığından, bir önceki aşamada elde edilen bulanık üyelik değerleri ağırlıklar olarak alınmış ve bu ağırlıkların küme merkez değerleriyle çarpılması yöntemi ile zaman serilerine ilişkin öngörü değerleri elde edilmiştir.
- Literatürde yer alan ve optimizasyona dayalı çalışmalarda özellikle parçacık sürü optimizasyonu ve genetik algoritma gibi yöntemler kullanılmış olup, kedi sürüsü optimizasyonunun bulanık zaman serilerinde kullanıldığı herhangi bir çalışmaya rastlanılmamıştır. Bu sebeple, bu çalışma bulanık zaman serilerinde kedi sürüsü optimizasyonu yönteminin kullanıldığı literatürdeki ilk çalışma olma özelliğini taşımaktadır.

- Bulanık ilişkilerin belirlenmesinde kullanılan destek vektör makineleri, bulanık zaman serilerinin bu aşamasında ilk defa kullanılması bakımından da önemlidir.
- Önerilen yöntem hem birinci dereceden hem de yüksek dereceden modeller üzerinde uygulanmış ve öngörü performanslarının daha da artırılması amaçlanmıştır.
- Önerilen yöntem hem eğitim kümesi hem de test kümelerine uygulanmış ve söz konusu yöntemin her iki kümeye ilişkin öngörülerin de performansını artırma konusunda oldukça başarılı olduğu sonucuna varılmıştır.

Daha sonra yapılacak çalışmalarda, bulanık ilişkilerin belirlenmesi aşamasında destek vektör makineleri yerine farklı yöntemlerin kullanılmasının ya da ele alınan değişkenleri etkileyebilecek diğer değişkenlerin de dikkate alınarak çok değişkenli analizlerin yapılmasının, önerilen yöntemin öngörü performansını arttıracığı düşünülmektedir.

KAYNAKLAR

- [1] Ahlatçioğlu, B., *Bulanık Karar Verme ve Tesis Yeri Seçimine Bir Uygulama*, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, **2005**.
- [2] Akyol, S., Alataş, B., Güncel sürü zekası optimizasyon algoritmaları, *Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi*, 1, 36-50, **2012**.
- [3] Aladag, C.H., Basaran, M.A., Egrioglu E., Yolcu, U., Uslu V.R., Forecasting in high order fuzzy time series by using neural networks to define fuzzy relations, *Expert Systems with Applications*, 36, 4228-4231, **2009**.
- [4] Aladağ, Ç.H., Eğrioglu, E., Günay, S., Yolcu, U., 2010, Yüksek dereceli bulanık zaman serisi modeli ve İMKB uygulaması, *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 11, 2, 95-101, **2010**.
- [5] Aladag, S., Aladag, C.H., Menten, T., Egrioglu, E., A new seasonal fuzzy time series method based on the multiplicative neuron model and SARIMA, *Hacettepe Journal of Mathematics and Statistics*, 41, 3, 337-345, **2012a**
- [6] Aladag, C.H., Yolcu, U., Egrioglu, E., Dalar, A.Z., A new time invariant fuzzy time series forecasting method based on particle swarm optimization, *Applied Soft Computing*, 12, 3291-3299, **2012b**
- [7] Alpaslan, F., Cagcag, O., 2012, A seasonal fuzzy time series forecasting method based on gustafson-kessel fuzzy clustering, *Social and Economic Statistics*, 2, 1, **2012**.
- [8] Alpaslan, F., Cagcag, O., Aladag, C.H., Yolcu, U., Egrioglu, E., A novel seasonal fuzzy time series method, *Hacettepe Journal of Mathematics and Statistics*, 41, 3, 375-385, **2012**.
- [9] Ayhan, S., Erdoğan, Ş., Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9, 1, 175-198, **2014**.
- [10] Bandemer, H., Gottwald, S., *Fuzzy Sets Fuzzy Logic Fuzzy Methods with Applications*, John Wiley & Sons, England, **1995**.
- [11] Baş, E., *Bulanık Zaman Serisi Çözümlemesi İçin Genetik Algoritmaya Dayalı Yeni Bir Yaklaşım*, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun, **2011**.
- [12] Bas, E., Egrioglu, E., Aladag, C.H., Yolcu, U., Fuzzy-time-series network used to forecast linear and nonlinear time series, *Appl Intell*, 43, 343-355, **2015**.
- [13] Baykal, N., Beyan, T., *Bulanık Mantık İlke ve Temelleri*, Bıçaklar Kitabevi, Ankara, **2004**.
- [14] Bolat, B., Erol, K.O., İmrak, C.E., Genetic algorithms in engineering applications and the function of operators, *Journal of Engineering and Natural Sciences Mühendislik ve Fen Bilimleri Dergisi*, Sigma 4, **2004**.
- [15] Buckley, J.J., *Fuzzy Statistics: Regression and Prediction*, Soft Computing, 9, 769-775, **2005**.

- [16] Cai, Q., Zhang, D., Wu, B., Leung, C.H., A novel stock forecasting model based on fuzzy time series and genetic algorithm, *International Conference on Computational Science*, 00, 000-000, **2013**.
- [17] Cai, Q., Zhang, D., Zheng, W., Leung, S.C.H., A new fuzzy time series forecasting model combined with ant colony optimization and auto-regression, *Knowledge-Based Systems*, 74, 61-68, **2015**.
- [18] Chen, S. M., Forecasting enrollments based on fuzzy time-series, *Fuzzy Sets and Systems*, 81, 311-319, **1996**.
- [19] Chen, S.-M., Forecasting enrollments based on high order fuzzy time series, *Cybernetics and Systems: An International Journal*, 33:1, 1-16, **2002**.
- [20] Chen, S.M., Chung, N.Y., Forecasting enrolments using high order fuzzy time series and genetic algorithms, *International Journal of Intelligent Systems*, 21, 485-501, **2006**.
- [21] Chen, S.-M., Chen, C.-D., TAIEX forecasting based on fuzzy time series and fuzzy variation groups, *IEEE Transactions on Fuzzy Systems*, 19, 1, **2011**.
- [22] Chen, S.-M., Kao, P.-Y., TAIEX forecasting based on fuzzy time series, particle swarm optimization techniques and support vector machines, *Information Sciences*, 247, 62-71, **2013**.
- [23] Cheng, C.-H., Cheng, G.-W., Wang, J.-W., 2008, Multi-attribute fuzzy time series method based on fuzzy clustering, *Expert Systems with Applications*, 34, 1235-1242, **2008**.
- [24] Chu, S.C., Tsai, P.W., Pan, J.S., Cat Swarm Optimization, *Springer-Verlag Berlin Heidelberg*, 854-858, **2006**.
- [25] Chu, S.C., Tsai, P.W., Computational intelligence based on the behavior of cats, *International Journal of Innovative Computing, Information and Control*, 3, 1, 163-173, **2007**.
- [26] Çevik, K.K., Koçer, H.E., Parçacık sürü optimizasyonu ile yapay sinir ağları eğitime dayalı bir esnek hesap uygulaması, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 17, 2, 39-45, **2013**.
- [27] Davari, S., Zarandi, M.H.F., Turksen, I.B., An improved fuzzy time series forecasting model based on particle swarm intervalization, *The 28th North American Fuzzy Information Processing Society Annual Conferences (NAFIPS 2009)*, Cincinnati, Ohio, USA, June 14-17, **2009**.
- [28] Dubois, D., Prade, H., *Fuzzy Sets and Systems: Theory and Applications*, Academic Press, United States of America, **1980**.
- [29] Eberhart, R., Kennedy, J., A new optimizer using particle swarm theory, *Sixth International Symposium on Micro Machine and Human Science*, **1995**.
- [30] Egrioglu, E., Aladag, C.H., Yolcu, U., Uslu, V.R., Basaran, M.A., A new approach based on artificial neural networks for high order multivariate fuzzy time series, *Expert Systems with Applications*, 36, 10589-10594, **2009a**.
- [31] Egrioglu, E., Aladag, C.H., Yolcu, U., Basaran, M.A, Uslu, V.R., A new hybrid approach based on SARIMA and partial high order bivariate fuzzy time series forecasting model, *Expert Systems with Applications*, 36, 7424-7434, **2009b**.

- [32] Egrioglu, E., Uslu, V. R., Yolcu, U., Basaran, M.A., Aladag, C.H., A new approach based on artificial neural networks for high order bivariate fuzzy time series, *Springer-Verlag Berlin Heidelberg*, 265-273, **2009c**.
- [33] Egrioglu, E., Aladag, C.H., Yolcu, U., Uslu, V.R., Basaran, M.A., Finding an optimal interval length in high order fuzzy time series, *Expert Systems with Applications*, 37, 5052-5055, **2010**.
- [34] Egrioglu, E., Aladag, C.H., Basaran, M.A., Yolcu, U., Uslu, V.R., A new approach based on the optimization of the length of intervals in fuzzy time series, *Journal of Intelligent & Fuzzy Systems*, 22,15-19, **2011**.
- [35] Egrioglu, E., A new time invariant fuzzy time series forecasting method based on genetic algorithm, *Hindawi Publishing Corporation Advances in Fuzzy Systems*, **2012**.
- [36] Egrioglu, E., Aslan, Y., Aladag, C.H., A new fuzzy time series method based on artificial bee colony algorithm, *Turkish Journal of Fuzzy Systems*, 5, 1, 59-77, **2014**.
- [37] Eke, İ., Taplamacıoğlu, M.C., Kocaarslan, İ., Yapay arı kolonisi algoritması tabanlı kararlı güç sistemi dengeleyicisi tasarımı, *Gazi Üniversitesi Mühendislik Mimarlık Fakülte Dergisi*, 26, 3, 683-690, **2011**.
- [38] Hanss, M., *Applied Fuzzy Arithmetic: An Introduction with Engineering Applications*, Springer Berlin Heidelberg, New York, **2005**.
- [39] Hsu, L-Y., Horng, S-J., Kao, T-W., Chen, Y-H., Run, R-S, Chen, R-J., Lai, J-L., Kuo, I.H., Temperature prediction and TAIEX forecasting based on fuzzy relationships and MTPSO techniques, *Expert Systems with Application*, 37, 2756- 2770, **2010**.
- [40] Huang,Y.-L., Horng, S.-J., He, M., Fan, P., Kao, T.-W., Khan, M.K., Lai, J.-L., Kuo,I.-H., A hybrid forecasting model for enrollments based on aggregated fuzzy time series and particle swarm optimization, *Expert Systems with Applications*, 38, 8014-8023, **2011**.
- [41] Huarng, K., Effective length of intervals to improve forecasting in fuzzy time series, *Fuzzy Sets and Systems*, 123, 387-394, **2001**.
- [42] Huarng, K., Yu, T.H.-K., Ratio-based lengths of intervals to improve fuzzy time series forecasting, *IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics*, 36, 2, 328-340, **2006a**.
- [43] Huarng, K., Yu, H.-K., The application of neural networks to forecast fuzzy time series, *Physica A*, 363, 481-491, **2006b**.
- [44] Huarng, K.-H., Yu, H.-K., Hsu, Y.W., A multivariate heuristic model for fuzzy time-series forecasting, *IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics*, 37, 4, 836-846, **2007**.
- [45] Hwang, J.R., Chen, S.M., Lee, C.H., Handling forecasting problems using fuzzy time series, *Fuzzy Set Syst.*, 100, 2, 217-228, **1998**.
- [46] Jilani, T.A., Burney, S.M.A., M-factor high order fuzzy time series forecasting for road accident data: analysis and design of intelligent systems using soft computing techniques, *Advances in Soft Computing*, 41, 246–254, **2007**.

- [47] Jilani, T.A., Burney, S.M.A., Multivariate stochastic fuzzy forecasting models, *Expert Systems with Applications*, 35, 691–700, **2008**.
- [48] Jilani, T.A., Burney, S.M.A., Ardil, C., Multivariate high order fuzzy time series forecasting for car road accidents, *International Journal of Information and Mathematical Sciences*, 4, 1, 15–20, **2008**.
- [49] Kaufmann, A. and Gupta, M.M., *Fuzzy Mathematical Models in Engineering and Management Science*, Elsevier Science Publishers Co., United States of America, **1988**.
- [50] Kaufmann, A. and Gupta, M.M., *Introduction to Fuzzy Arithmetic*, Van Nostrand Reinhold Co., New York, **1991**.
- [51] Klir, G.J., Yuan, B., *Fuzzy Sets and Fuzzy Logic Theory and Applications*, Prentice Hall Inc., United Saddle River, **1995**.
- [52] Kuo, I.-H., Horng, S.-J., Kao, T.-W., Lin, T.-L., Lee, C.-L., Pan, Y., An improved method for forecasting enrollments based on fuzzy time series and particle swarm optimization, *Expert Systems with Applications*, 36, 6108-6117, **2009**.
- [53] Kuo, I.-H., Horng, S.-J., Chen, Y.-H., Run, R.-S., Kao, T.-W., Chen, R.-J., Lai, J.-L., Lin, T.-L., Forecasting TAIEX based on fuzzy time series and particle swarm optimization, *Expert Systems with Applications*, 37, 1494-1502, **2010**.
- [54] Kurt, S., Semetay, C., Genetik Algoritma ve Uygulama Alanları, <https://polen.itu.edu.tr/bitstream/11527/678/1/7578.pdf>, (Kasım, **2016**).
- [55] Lee, L.-W., Wang, L.-H., Chen, S.-M., Temperature prediction and TAIEX forecasting based on fuzzy logical relationships and genetic algorithms, *Expert Systems with Applications*, 33, 539-550, **2007**.
- [56] Lee, L.-W., Wang, L.-H., Chen, S.-M., 2008, Temperature prediction and TAIEX forecasting based on high-order fuzzy logical relationships and genetic simulated annealing techniques, *Expert Systems with Applications*, 34, 328–336, **2008**.
- [57] Li, S.-T., Cheng, Y.-C., Lin, S.-Y., A FCM-based deterministic forecasting model for fuzzy time series, *Computers and Mathematics with Applications*, 56, 3052-3063, **2008**.
- [58] Özdağ, H., Aygör, N., Parlak, A., Karınca Kolonisi Algoritmasının Zaman Çizelgelemesi Üzerine: Bir Modellemesi ve Uygulaması, *XIV. Akademik Bilişim Konferansı Bildirileri*, Uşak Üniversitesi, **2012**.
- [59] Özsağlam, M.Y., Çunkaş, M., Optimizasyon Problemlerinin Çözümü için Parçacık Sürü Optimizasyonu Algoritması, *Politeknik Dergisi*, 11, 4, 299-305, **2008**.
- [60] Öztürk, C., Hançer, E., Karaboğa, D., Küresel En İyi Yapay Arı Koloni Algoritması ile Otomatik Kümeleme, *Gazi Üniversitesi Mühendislik Mimarlık Fakülte Dergisi*, 29, 4, 677-687, **2014**.
- [61] Parchami, A., Mashinchi, M., Yavari, A.R., Maleki, H.R., Process Capability Indices as Fuzzy Numbers, *Austrian Journal of Statistics*, 34, 4, 91-402, **2005**.

- [62] Park, J.-I., Lee, D.-J., Song, C.-K., Chun, M.-G., TAIEX and KOSPI 200 forecasting based on two-factors high order fuzzy time series and particle swarm optimization, *Expert Systems with Applications*, 37, 959-967, **2010**.
- [63] Song, Q., Chissom, B.S., Fuzzy time series and its models, *Fuzzy Sets and Systems*, 54, 269-277, **1993a**.
- [64] Song, Q., Chissom, B.S., Forecasting enrollments with fuzzy time series – Part I, *Fuzzy Sets and Systems*, 54, 1-10, **1993b**.
- [65] Song, Q., Chissom, B.S., Forecasting enrollments with fuzzy time series – Part II, *Fuzzy Sets and Systems*, 62, 1-8, **1994**.
- [66] Tayyar, N., Tekin, S., İMKB-100 endeksinin destek vektör makineleri ile günlük, haftalık ve aylık veriler kullanarak tahmin edilmesi, *Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 13, 1, 189-217, **2013**.
- [67] Turksen, B., Tekin, S., Fuzzy function with LSE, *Appl Soft Comput*, 8, 1178-1188, **2008**.
- [68] Yager, R.R., Filev, D.P., *Essentials of Fuzzy Modeling and Control*, John Wiley & Sons, United States of America, **1994**.
- [69] Yakut, E., Elmas, B., Yavuz, S., Yapay sinir ağları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19, 1, 139-157, **2014**.
- [70] Yolcu, U., Egrioglu, E., Uslu, V.R., Basaran, M.A., Aladag, C.H., A new approach for determining the length of Intervals for fuzzy time series, *Applied Soft Computing*, 9, 647-651, **2009**.
- [71] Yolcu, U., *Bulanık Zaman Serilerinde Çok Değişkenli Çözümleme*, Doktora Tezi, Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Samsun, **2011**.
- [72] Yolcu, U., The forecasting of Istanbul stock market with a high order multivariate fuzzy time series forecasting model, *Turkish Journal of Fuzzy Systems*, 3, 2, 118-135, **2012**.
- [73] Yolcu, U., Aladag, C.H., Egrioglu, E., Uslu, V.R., Time-series forecasting with a novel fuzzy time-series approach: an example for Istanbul stock market, *Journal of Statistical Computation and Simulation*, 83, 4, 599-612, **2013**.
- [74] Yolcu, U., Cagcag, Ö., Aladag, C.H., Egrioglu, E., An enhanced fuzzy time series forecasting method based on artificial bee colony algorithm, *Journal of Intelligent and Fuzzy Systems*, 26, 6, 2627-2637, **2014**.
- [75] Yolcu, O.C., Yolcu, U., Egrioglu, E., Aladag, C.H., High order fuzzy time series forecasting method based on an intersection operation, *Applied Mathematical Modelling*, 40, 8750-8765, **2016**.
- [76] Yu, H.-K., Weighted fuzzy time series models for TAIEX forecasting, *Physica A*, 349, 609-624, **2005**.
- [77] Yu, H.-K., Huarng, K., A bivariate fuzzy time series model to forecast TAIEX, *Expert Systems with Applications*, 34, 2945-2952, **2008**.
- [78] Yu, T.H.-K., Huarng, K.-H., A neural network-based fuzzy time series model to improve forecasting, *Expert Systems with Applications*, 37, 3366-3372, **2010**.

- [79] Zadeh L.A., Fuzzy Sets, *Inform and Control*, 8, 338-353, **1965**.
- [80] Zimmermann, H.J., *Fuzzy Set Theory and Its Applications*, Kluwer Academic Publishers, United States of America, **1991**.





EK 1. Birinci Dereceden Kedi Sürüşü Optimizasyonuna Dayalı Bulanık Zaman Serisi Öngörü Modeli için Örnek MATLAB programı

X: Zaman Serisi Verisi
N: Kedi Sayısı
M: Boyut Sayısı
MaxIt: Maksimum İterasyon Sayısı
AHH: Arama Hafızası Havuzu
SBA: Seçilen Boyutların Arama Aralığı
DBS: Değişen Boyutların Sayısı
KO: Karışım Oranı
ntest: Test Kümesi Eleman Sayısı

```
function Sonuc=csoprgtest1(X,N,M,MaxIt,AHH,SBA,DBS,KO,ntest)
r1=rand;
c1=2;
secilen_boyut=round(M*DBS);
bayrak_belirleme=round(KO*N);
kedino=randperm(N);
bos_kedino.Pozisyon=[];
bos_kedino.Hiz=[];
bos_kedino.Uygunluk=[];
kedi=repmat(bos_kedino,N,1);
Eniyi.Uygunluk=inf;
n1=size(X,1);
n=n1-ntest;
a=sort(X);
Xmin=a(1);
Xmax=a(n1);
Vmax=round(0.1*(Xmax-Xmin));
Vmin=-Vmax;
for i=1:N
    kedi(i).Pozisyon=round(Xmin+rand(1,M)*(Xmax-Xmin));
    kedi(i).Hiz=randi([Vmin,Vmax],1,M);
    kedi(i).Uygunluk=TestFonksiyonuprg1(kedi(i).Pozisyon,n1,M,n,X,ntest);
    y=find(kedino==i);
    if(y<=bayrak_belirleme)
        kedi(i).Bayrak=1;
    else
        kedi(i).Bayrak=0;
    end
    if kedi(i).Uygunluk<=Eniyi.Uygunluk
        Eniyi=kedi(i);
    end
end
for j=1:MaxIt
    for i=1:N
        if (kedi(i).Bayrak==0)
            for d=1:M
                kedi(i).Hiz(d)=kedi(i).Hiz(d)+r1*c1.*(Eniyi.Pozisyon(d)-kedi(i).Pozisyon(d));
                if (kedi(i).Hiz(d)<Vmin)||kedi(i).Hiz(d)>Vmax
                    kedi(i).Pozisyon(d)=Eniyi.Pozisyon(d);
                else
```

```

        kedi(i).Pozisyon(d)=kedi(i).Pozisyon(d)+kedi(i).Hiz(d);
    end
end
else
    kedi_kopya=repmat(kedi(i).Pozisyon,AHH,1);
kedi(i).Pozisyon=mutasyon11(kedi_kopya,M,secilen_boyut,SBA,Xmin,Xmax,X,n1,n,ntest);
end
    kedi(i).Uygunluk=TestFonksiyonuprg1(kedi(i).Pozisyon,n1,M,n,X,ntest);
    if kedi(i).Uygunluk<=Eniyi.Uygunluk
        Eniyi=kedi(i);
    end
end
Eniyi_Uygunluk(j)=Eniyi.Uygunluk;
disp(['İterasyon ' num2str(j) ': En iyi uygunluk değeri= ' num2str(Eniyi_Uygunluk(j))]);
kedino=randperm(N);
for k=1:N
    y=find(kedino==k);
    if (y<=bayrak_belirleme)
        kedi(k).Bayrak=1;
    else
        kedi(k).Bayrak=0;
    end
end
end
disp(num2str(min(Eniyi.Uygunluk)));
end

```

```

function MSEegt=TestFonksiyonuprg1(x,n1,M,n,X,ntest)
for j=1:M
    center=sort(x)';
end
y=zeros(size(center,1),size(X,1));
for k=1:size(center,1)
    y(k,:)=sqrt(sum(((X-ones(size(X,1),1)*center(k,:)).^2)',1));
end
for i=1:M
    for j=1:n1
        if y(i,j)==0
            y(i,j)=0.01;
        end
    end
end
end
q=2;
d=y.^2;
a=1./d.^(1/(q-1));
b=sum(a);
U=a./(ones(M,1)*b);
x1=[U(:,(1:(n-1)))];
x1a=x1';
a=reshape(x1a,(n-1)*M,1);
x2=[U(:,(2:n))];
x2a=x2';
b=x2a(:);

```

```

model = svmtrain(a,b,['-s 3 -t 2 -c 100 -g 0.05 -p 0.0003 -h 0']);
h1=svmpredict(a,b,model);
h2=reshape(h1,n-1,M);
h3=h2';
top=sum(h3);
for i=1:M
    for j=1:(n-1)
        stdycegt1(i,j)=h3(i,j)/top(j);
    end
end
ongegt=((center(:,1))*stdycegt1)';
x3=[U(:,(n+1):n1)];
for i=1:n1test
    x4a=[U(:,n+i-1)];
    x5a=reshape(x4a,M,1);
    h4(:,i)=svmpredict(x3(:,i),x5a,model);
end
top=sum(h4);
for i=1:M
    for j=1:n1test
        stdycegt2(i,j)=h4(i,j)/top(j);
    end
end
ongtest=((center(:,1))*stdycegt2)';
disp(num2str(ongtest));
Yegt=X(2:n);
Ytest=X((n+1):n1);
MSEegt=sum((Yegt-ongegt).^2)/length(Yegt);
MSEtest=sum((Ytest-ongtest).^2)/length(Ytest);
RMSEegt=MSEegt^0.5;
RMSEtest=MSEtest^0.5;
disp(num2str(RMSEegt));
disp(num2str(RMSEtest));
end

```

EK 2. Alabama Üniversitesi Kayıt Verileri için Önerilen Yöntemin En İyi Modeline İlişkin Sonuçlar (Küme Sayısı: 13 ve Model Derecesi: 2)

Yıl	Kayıt Verileri	Önerilen Yöntem
1971	13055	-
1972	13563	-
1973	13867	13868
1974	14696	14696
1975	15460	15473
1976	15311	15314
1977	15603	15474
1978	15861	15765
1979	16807	16832
1980	16919	16884
1981	16388	16567
1982	15433	15465
1983	15497	15470
1984	15145	15082
1985	15163	15105
1986	15984	15968
1987	16859	16877
1988	18150	18097
1989	18970	18989
1990	19328	19317
1991	19337	19319
1992	18876	18864
HKOK		3.676

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Yasemin Burcu GÜNDOĞDU
Doğum Yeri : Ankara
Medeni Hali : Evli
E-posta : ybacil@gmail.com
Adresi : Cumhurbaşkanlığı Cad. Haldız Ihlamur Evleri B Blok No:23
Beştepe, Yenimahalle, Ankara

Eğitim

Lisans : Başkent Üniversitesi, Fen-Edebiyat Fakültesi,
İstatistik ve Bilgisayar Bilimleri Bölümü (2004-2008)
Yüksek Lisans : Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü,
İstatistik Anabilim Dalı (2008-2011)
Doktora : Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü,
İstatistik Anabilim Dalı (2011-2018)

Yabancı Dil ve Düzeyi

İngilizce : 81 (2010 KPDS Sonbahar Dönemi)

İş Deneyimi

Ocak 2009 – Haziran 2012 : Hacettepe Üniversitesi, Fen Fakültesi, İstatistik Bölümü
Araştırma Görevlisi
Temmuz 2012 – Ekim 2016 : T.C. Ekonomi Bakanlığı, Teşvik Uygulama ve Yabancı
Sermaye Genel Müdürlüğü, Dış Ticaret Uzman Yrd.
Kasım 2016 - ... : T.C. Ekonomi Bakanlığı Teşvik Uygulama ve Yabancı
Sermaye Genel Müdürlüğü, Dış Ticaret Uzmanı

Deneyim Alanları

Olasılık, Zaman Serileri, Benzetim Teknikleri

Tezden Üretilmiş Projeler ve Bütçesi: -

Tezden Üretilmiş Yayınlar: -

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar: -



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
İSTATİSTİK ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 03/07/2018

Tez Başlığı / ~~Konusu~~: KEDİ SÜRÜSÜ OPTİMİZASYONUNA DAYALI YENİ BİR BULANIK ZAMAN SERİSİ YAKLAŞIMI

Yukarıda başlığı/~~konusu~~ gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 72 sayfalık kısmına ilişkin, 29/06/2018 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 7 'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.


03/07/2018

Adı Soyadı: YASEMİN BURCU GÜNDOĞDU
Öğrenci No: N10248066
Anabilim Dalı: İSTATİSTİK
Programı: İSTATİSTİK
Statüsü: ☐ Y.Lisans ☒ Doktora ☐ Bütünleşik Dr.

DANIŞMAN ONAYI

UYGUNDUR.


Doc. Dr. Çağdaş Hakan ALADAĞ