

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÖNGÖRÜ İÇİN YENİ BİR SEZGİSEL BULANIK ÇIKARIM
SİSTEMİ

Busenur KIZILASLAN

DOKTORA TEZİ
İstatistik Anabilim Dalı
İstatistik Programı

Danışman
Doç. Dr. Atıf Ahmet EVREN

Temmuz, 2020

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÖNGÖRÜ İÇİN YENİ BİR SEZGİSEL BULANIK ÇIKARIM
SİSTEMİ**

Busenur KIZILASLAN tarafından hazırlanan tez çalışması 13.07.2020 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Atıf Ahmet EVREN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Atıf Ahmet EVREN, Danışman
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Doğan YILDIZ, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Müjgan TEZ, Üye
Marmara Üniversitesi

Prof. Dr. Gülhayat GÖLBAŞI ŞİMŞEK, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Erol EĞRİOĞLU, Üye
Giresun Üniversitesi

Danışmanım Doç. Dr. Atıf Ahmet EVREN sorumluluğunda tarafımca hazırlanan Öngörü için Yeni Bir Sezgisel Bulanık Çıkarım Sistemi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Busenur KIZILASLAN

İmza

Tanıdığım en güçlü insan olan annem'e



TEŐEKKÜR

Çalıőma boyunca beni hem akademik hem insani yönde destekleyen danıőmanım Sayın Doç. Dr. Atıf Ahmet EVREN'e, tüm sorularımı içtenlikle yanıtlayan, yol gösteren ve yüreklendiren Sayın Prof. Dr. Erol EĞRİOĐLU'na, zor günlerde yoluma ışık tutan, çalışmamda desteklerini esirgemeyen bölüm hocalarım Sayın Prof. Dr. Müjgan TEZ, Sayın Doç. Dr. Birsen EYGİ ERDOĐAN ve Sayın Doç. Dr. Deniz İNAN'a, sevgili dostum Çisem BALKAN BOS'a, hayat yolculuğumda her zaman beni destekleyen, yolumu açan aileme, hayattaki en büyük şansım ve destekçim, sevgili eşim Doç. Dr. Fatih KIZILASLAN'a, sanıyorum bugünü en çok görmek isteyen, ne yazık ki tez sürecinde aramızdan ayrılan, her zaman arkamda duran ve varlıklarını hep hissedeceğim, güneşim, canım anneciğime ve canım babacığma teşekkürlerimi sunarım.

Busenur KIZILASLAN

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xii
ÖZET	xiii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür	1
1.2 Tezin Amacı	3
1.3 Hipotez	4
2 BULANIK MANTIK VE BULANIK KÜME TEORİSİ	5
2.1 Bulanık Kümeler ve İşlemler	6
2.1.1 Bulanık C-Ortalamalar Kümeleme Yöntemi	10
2.2 Bulanık Çıkarım Sistemleri	12
2.2.1 Mamdani Bulanık Çıkarım Sistemi	13
2.2.2 Sugeno Bulanık Çıkarım Sistemi	15
2.2.3 Uyarlamalı Ağ Bulanık Çıkarım Sistemi	15
2.2.4 AR-Uyarlamalı Ağ Bulanık Çıkarım Sistemi	17
2.2.5 Tip 1 Bulanık Fonksiyonlar Yöntemi	19
2.3 Sezgisel Bulanık Kümeler	21
2.3.1 Sezgisel Bulanık C-Ortalamalar Kümeleme Yöntemi	24
3 REGRESYON ANALİZİ	26
3.1 Çoklu İç İlişki Problemi	27
3.2 Yanlı Tahmin Ediciler	28
3.2.1 Ridge Tahmin Edici	29
3.2.2 Liu Tahmin Edici	30

3.2.3 Liu Tipi Tahmin Edici	31
4 HİPERPARAMETRE OPTİMİZASYONU	33
4.1 Izgara Arama Yöntemi	33
4.2 Çapraz Geçerlik Yöntemi	34
4.2.1 Zaman Serileri için Çapraz Geçerlik Yöntemi	37
4.3 Tekrarlı Izgara Arama İleri Doğru Geçerlik Yöntemi	39
5 PARÇACIK SÜRÜ OPTİMİZASYONU	41
6 ÖNERİLEN YÖNTEM	45
6.1 Sezgisel Ridge Regresyon Bulanık Fonksiyonlar Yaklaşımı	48
6.2 Sezgisel Liu Tipi Regresyon Bulanık Fonksiyonlar Yaklaşımı	51
7 UYGULAMA	55
8 SONUÇ VE ÖNERİLER	68
KAYNAKÇA	70
TEZDEN ÜRETİLMİŞ YAYINLAR	77

SİMGE LİSTESİ

I	Birim matris
Π	Çarpma operatörü
g_{best}	Global en iyi pozisyon
ϵ	Hata
σ	Standart sapma
p_{best}	Yerel en iyi pozisyon

KISALTMA LİSTESİ

ANFIS	Uyarlamalı Ağ Bulanık Çıkarım Sistemi
ARIMA	Bütünleşik Otoregresif Hareketli Ortalama
AR-ANFIS	AR-Uyarlamalı Ağ Bulanık Çıkarım Sistemi
BIST100	Borsa İstanbul 100 Endeksi
CV	Çapraz Geçerlik
FCM	Bulanık C-Ortalamalar
FIS	Bulanık Çıkarım Sistemi
IFCM	Sezgisel Bulanık C-Ortalamalar
LSE	En Küçük Kareler Tahmin Edici
LTE	Liu Tipi Tahmin Edici
LOOCV	Birini Dışarıda Bırakma Çapraz Geçerlik
MAPE	Ortalama Mutlak Yüzde Hata
MSE	Hata Kareler Ortalaması
PSO	Parçacık Sürü Optimizasyonu
RFO	İleri Doğru Geçerlik
RMSE	Hata Kareler Ortalaması Karekökü
RRE	Ridge Regresyon Tahmin Edici
SC	Zamandan Bağımsız Bulanık Zaman Serileri
TAIEX	Tayvan Kapitalizasyon Ağırlıklı Borsa Endeksi
T1FF	Tip 1 Bulanık Fonksiyonlar
T1FFRR	Tip 1 Ridge Regresyon Bulanık Fonksiyonlar
T1IFFRR	Tip 1 Sezgisel Ridge Regresyon Bulanık Fonksiyonlar
T1IFFLR	Tip 1 Sezgisel Liu Tipi Regresyon Bulanık Fonksiyonlar

TSK Takagi-Sugeno-Kang
VIF Varyans Şişme Deęeri



ŞEKİL LİSTESİ

Şekil 2.1	Üyelik fonksiyonu kısımları [37]	8
Şekil 2.2	Normal ve normal olmayan bulanık kümeler	8
Şekil 2.3	Dışbükey bulanık küme	8
Şekil 2.4	Dışbükey olmayan bulanık küme	9
Şekil 2.5	Klasik kümeleme yöntemi üyelik fonksiyonu	10
Şekil 2.6	Bulanık kümeleme yöntemi üyelik fonksiyonu	11
Şekil 2.7	Bulanık çıkarım sistemi [45]	13
Şekil 2.8	Mamdani bulanık çıkarım sistemi [44]	14
Şekil 2.9	Sugeno bulanık çıkarım sistemi [44]	15
Şekil 2.10	ANFIS ağ yapısı	16
Şekil 2.11	AR-ANFIS ağ yapısı	18
Şekil 2.12	Sezgisel bulanık küme geometrik yorumu - 1 [48]	22
Şekil 2.13	Sezgisel bulanık küme geometrik yorumu - 2 [48]	22
Şekil 2.14	Sezgisel bulanık küme için mümkün olmayan geometrik yorum [48]	23
Şekil 3.1	β 'nın (a) yansız ve (b) yanlı kestiricilerinin örnekleme dağılımı [56]	28
Şekil 3.2	Ridge regresyon tahmin edici geometrik yorumu	29
Şekil 3.3	MSE ve k dengesi [59]	30
Şekil 4.1	Izgara arama yöntemi	34
Şekil 4.2	İkiye bölme yöntemi	35
Şekil 4.3	K gözlü çapraz geçerlik yöntemi	36
Şekil 4.4	Birini dışarıda bırakma çapraz geçerlik yöntemi	36
Şekil 4.5	Eğitim ve test seti açısından varyans-yan dengesi	37
Şekil 4.6	İleri doğru geçerlik yöntemi [79]	39
Şekil 4.7	Örnek1: İleri doğru geçerlik yöntemi	40
Şekil 5.1	PSO akış diyagramı [89]	44
Şekil 6.1	Önerilen yöntem akış diyagramı	48
Şekil 7.1	BIST100 2014 zaman serisi	56
Şekil 7.2	BIST100 2015 zaman serisi	56
Şekil 7.3	BIST100 2016 zaman serisi	56
Şekil 7.4	BIST100 2017 zaman serisi	56
Şekil 7.5	BIST100 veri seti ntest=5 için yıllara göre RMSE değerleri	59

Şekil 7.6	BIST100 veri seti $n_{test}=10$ için yıllara göre RMSE değerleri	60
Şekil 7.7	BIST100 veri seti $n_{test}=20$ için yıllara göre RMSE değerleri	61
Şekil 7.8	BIST100 veri seti $n_{test}=5$ için yıllara göre MAPE değerleri	62
Şekil 7.9	BIST100 veri seti $n_{test}=10$ için yıllara göre MAPE değerleri	63
Şekil 7.10	BIST100 veri seti $n_{test}=20$ için yıllara göre MAPE değerleri	64
Şekil 7.11	TAIEX veri seti RMSE değerleri	66
Şekil 7.12	TAIEX veri seti RMSE değerleri eğitim-test karşılaştırma (Seri6) . . .	67
Şekil 7.13	TAIEX veri seti öngörü ve gerçek değer karşılaştırması (Seri6)	67



TABLO LİSTESİ

Tablo 4.1	Izgara arama ileri doğru geçerlik yöntemi	40
Tablo 7.1	Zaman serileri ve özellikleri	55
Tablo 7.2	T1IFFRR en iyi sonuç parametreleri (RMSE)	57
Tablo 7.3	T1IFFLR en iyi sonuç parametreleri (RMSE)	58
Tablo 7.4	BIST100 veri seti, ntest=5 için yıllara göre RMSE değerleri	58
Tablo 7.5	BIST100 veri seti, ntest=10 için yıllara göre RMSE değerleri	59
Tablo 7.6	BIST100 veri seti, ntest=20 için yıllara göre RMSE değerleri	60
Tablo 7.7	BIST100 veri seti, ntest=5 için yıllara göre MAPE değerleri	61
Tablo 7.8	BIST100 veri seti, ntest=10 için yıllara göre MAPE değerleri	62
Tablo 7.9	BIST100 veri seti, ntest=20 için yıllara göre MAPE değerleri	63
Tablo 7.10	TAIEX test setleri için <i>RMSE</i> değerleri	65

Öngörü için Yeni Bir Sezgisel Bulanık Çıkarım Sistemi

Busenur KIZILASLAN

İstatistik Anabilim Dalı

Doktora Tezi

Danışman: Doç. Dr. Atıf Ahmet EVREN

Öngörü, geçmişten günümüze önemini yitirmeyen bir çalışma alanı olmuştur. Literatürde bu alana yönelik olasılıksal bir çok yöntem önerilmiş olmakla birlikte bu yöntemlerin kullanılabilmesi için sağlanması gereken önkoşullar da mevcuttur. Belirsizliklerle dolu gerçek dünyada bu önkoşulların sağlanması ve matematiksel modelin belirlenmesi her zaman mümkün olmamaktadır. Bu gibi durumlarda ön koşul gerektirmeyen, sistemdeki belirsizlikleri de tanımlayarak modele dahil edebilen ve karmaşık işlem yapısından uzak bulanık çıkarım sistemleri kullanılabilir. Bu çalışmada tip-1 bulanık fonksiyonlar yöntemi belirtilen avantajları ve kural gerektirmeyen yapısı nedeniyle tercih edilmiştir. Klasik tip-1 bulanık fonksiyon yapısına ek olarak sezgisel bulanık kümeler tercih edilmiş ve bu sayede üye olmama bilgisinin de kullanılabildiği bir öngörü yöntemi önerilmiştir. Yapısı itibarıyla dinamik bir regresyon modeli olan yöntem, ridge ve liu tipi tahmin ediciler açısından incelenmiş ve alternatif yöntem öngörü performanslarıyla karşılaştırılmıştır.

Anahtar Kelimeler: Bulanık çıkarım sistemleri, öngörü, parçacık sürü optimizasyonu, Liu tipi tahmin edici, ridge tahmin edici

A New Intuitionistic Fuzzy Inference System for Forecasting

Busenur KIZILASLAN

Department of Statistics
Doctor of Philosophy Thesis

Advisor: Assoc. Prof. Dr. Atıf Ahmet EVREN

Forecasting has been a field of study that has not lost its importance from the past to the present. Although many probabilistic methods have been proposed in the literature, there are also prerequisites for these methods to be used. It is not always possible to provide these prerequisites and determine the mathematical model in the real world full of uncertainties. In such cases, fuzzy inference systems that do not require prerequisites, can identify the uncertainties in the system and include them in the model and are far from the complex processing structure can be used. In this study, the type-1 fuzzy functions method was preferred because of its advantages and its rule-free structure. In addition to the classical type-1 fuzzy function structure, intuitionistic fuzzy clusters are preferred, and a forecasting method is proposed in which non-membership information can also be used. The method, which is a dynamic regression model due to its structure, was examined in terms of ridge and liu type estimators and alternative method was compared with the forecasting performances.

Keywords: Forecasting, fuzzy inference systems, Liu type estimator, particle swarm optimization, ridge estimator

1.1 Literatür

Öngörü, karar verme sürecinin en önemli basamaklarından biridir. Zaman serisi öngörü problemlerinde, olasılıksal ve olasılıksal olmayan çıkarım sistemlerinden faydalanılabilir. Olasılıksal yaklaşıma dayalı istatistiksel çıkarım sistemleri sık kullanılan yöntemlerden olmakla birlikte gerektirdiği ön koşullar nedeniyle uygulamayı zorlaştırmaktadır. Karmaşık gerçek hayat verileri için normal dağılım ve durağanlık gibi ön koşulların sağlanması güçleşmektedir. Olasılıksal olmayan çıkarım yöntemleri, basit yapısı ve uygulama kolaylığı sayesinde bu güçlüklerin üstesinden gelebilmektedir [1]. Uyarlamalı ağ bulanık çıkarım sistemleri ve bulanık fonksiyonlar, olasılıksal olmayan çıkarım sistemlerine örnek olarak verilebilir. Bu yöntemlerin zaman bağımlılığını da dikkate alan zaman serilerine özgü versiyonları da literatürde mevcuttur.

Bulanık küme teorisi 1965 yılında Zadeh [2] tarafından önerilmiştir. Bulanık küme teorisinin ilk gerçek hayat uygulamasını ise 1974 yılında Mamdani [3] gerçekleştirmiştir. Kural tabanlı olan bu sistemde kuralın hem öncül hem ardıl kısmı bulanık kümelerden oluşmaktadır. Sistem çıktısının kesin sayı olarak ifade edilebilmesi için durulaştırma aşamasına ihtiyaç duyan bu yöntem alternatif olarak 1985 yılında Takagi ve Sugeno [4] tarafından durulaştırma aşamasına ihtiyaç duymayan, ardıl kısmı doğrusal modellerden oluşan bir sistem geliştirilmiştir. Bu sistemin yapay sinir ağı üzerinde tasarlanmış hali uyarlamalı ağ bulanık çıkarım sistemi 1993 yılında Jang [5] tarafından önerilmiştir. Uyarlamalı ağ bulanık çıkarım sistemlerinin öngörü amacıyla kullanımı üzerine literatürde bir çok çalışma mevcuttur. 2008 yılında Chang [6] tarafından aşırı salınım ve oynaklık (volatilité) kümeleme etkilerinin zaman serisi öngörüsü üzerindeki etkisi uyarlamalı ağ bulanık çıkarım sistemi ile incelenmiştir. 2009 yılında Cheng vd. [7] Tayvan Kapitalizasyon Ağırlıklı Borsa Endeksi tahmini için çoklu stok oynaklık nedenselliğine dayanan füzyon uyarlamalı ağ bulanık çıkarım sistemini önermişlerdir. 2011 yılında Catalao vd. [8] parçacık sürü optimizasyonu ve uyarlamalı ağ bulanık çıkarım sisteminden oluşan

melez bir öngörü yöntemi önermişlerdir. 2011 yılında Ho ve Tsai [9] yapısal eşitlik modeli ve uyarlamalı ağ bulanık çıkarım sistemini yeni ürün geliştirme performansı öngörüsü amacıyla karşılaştırmıştır. 2012 yılında Pousinho vd. [10], 2013 yılında Cheng vd. [11] ve 2018 yılında Sarıca vd. [12] çalışmaları uyarlamalı ağ bulanık çıkarım sistemlerini öngörü amacıyla kullanan benzer çalışmalardır, bu çerçevede örnekler çoğaltılabilir.

Bulanık çıkarım sistemleri kural tabanlı olup konunun uzmanı tarafından tanımlanması gereken kurallara ihtiyaç duymaktadır. Kural tanımlanmasındaki güçlük ve subjektif etkinin sistemden dışlanması düşüncesi ile 2008 yılında Türkşen [13] kural yapısı yerine bulanık regresyon fonksiyonları kullanan sistemi önermiştir. Tip 1 bulanık fonksiyonlar yaklaşımı üzerine 2008 yılında Çelikyılmaz ve Türkşen [14, 15], 2011 yılında Türkşen [16] ve 2013 yılında Zarandi vd. [17] çeşitli çalışmalar gerçekleştirmiştir.

Bulanık fonksiyonlar yöntemi, öngörü amacıyla 2010 yılında Beyhan ve Alcı [18] tarafından doğrusal olmayan sistem tanıma için bulanık fonksiyonlar yaklaşımında kullanılmıştır. 2013 yılında Zarandi vd. [17], 2014 ve 2016 yıllarında ise Aladağ vd. [19, 20], 2016 yılında Goudarzi vd. [21], 2018 yılında Tak vd. [22] ve Tak [23], 2020 yılında Tak [24] tarafından benzer çalışmalar gerçekleştirilmiştir.

Zaman serilerine uyumlu birçok bulanık çıkarım sistemi literatürde mevcuttur. Bulanık küme teorisini temel alan bulanık zaman serileri yaklaşımı 1993 yılında Song ve Chissom [25] tarafından önerilmiştir. Farklı yapılarda birçok bulanık zaman serisi öngörü yöntemi literatürde yer almaktadır, ağ yapısıyla tanımlanan ilk bulanık zaman serisi yaklaşımı ise 2015 yılında Baş vd. [26] tarafından önerilmiştir. 2020 yılında Baş vd. [27] çalışmasında ise sezgisel bulanık kümeler açısından bulanık zaman serisi yaklaşımı incelenmiştir.

Tez kapsamında klasik bulanık kümeler yerinde sezgisel (intuitionistic) bulanık kümeler kullanılmıştır. Sezgisel bulanık kümeler 1986 yılında Atanassov [28] tarafından önerilmiştir. Klasik bulanık kümelerden farklı olarak sezgisel bulanık kümelerde tereddüt (hesitation) derecesi tanımlanarak üye olmama değeri de değerlendirmeye dahil edilebilmektedir. Son dönemde literatürde sezgisel bulanık kümelerin öngörü amacıyla kullanımı giderek artmaktadır, bu çalışmalara örnek olarak 2013 yılında Zheng [29] tarafından önerilen sezgisel bulanık kümelerde modelleme uygulamaları çalışması verilebilir. 2019 yılında Bisht ve Kumar [30] finansal zaman seri öngörüsü amacıyla sezgisel bulanık kümeleri temel alan bir yöntem önermişlerdir.

Tez kapsamında bulanık fonksiyonlar sezgisel bulanık kümelerle birlikte kullanılmış

olup literatürde benzer çalışmalar mevcuttur. 2020 yılında Baş vd. [27] sezgisel bulanık zaman serileri fonksiyonu yaklaşımını ve Tak [31] geri beslemeli tip 1 sezgisel bulanık fonksiyonlar yaklaşımını öngörü amacıyla önermişlerdir.

Bulanık fonksiyonların çoklu iç ilişki açısından değerlendirilmesi üzerine 2019 yılında Baş vd. [32] çalışması önerilmiştir. Bulanık fonksiyonların girdi matrisinde meydana gelen çoklu iç ilişki problemini ridge regresyon tahmin edici ile gideren yöntemin devamı olarak, tez kapsamında Kızılaslan vd. [33] tarafından aynı problem sezgisel bulanık kümeler açısından incelenmiştir.

1.2 Tezin Amacı

Geleceğin planlanması ve yönetilebilmesi açısından öngörü her dönem önemini korumuştur. Zamana bağlı verilere dair öngörü, zaman serileri analizi yardımıyla yapılabilmektedir. Bu açıdan olasılıksal yöntemlerin uygulanabilmesi için sağlanması gereken varsayımlar bulunmaktadır. Güncel hayat verilerinde bu varsayımların doğrulanması genellikle güçtür ve zaman, maliyet kaybına neden olmaktadır. Bu açıdan olasılıksal olmayan yöntemler üzerine çalışmalar son yıllarda oldukça artmıştır.

Olasılıksal olmayan yöntemlerden tip 1 bulanık fonksiyonlar yaklaşımı, hem uygulama kolaylığı (kural gerektirmeyen yapısı), hem de öngörü performansındaki başarısı açısından tercih edilen yöntemler arasındadır. Bulanık yapısı sayesinde daha esnek çalışma imkanı sağlayan yöntem, girdi matrisine üyelik değerlerinin doğrusal olmayan dönüşümlerini dahil ederek öngörü performansında da artış sağlamaktadır [34].

Regresyon problemleri açısından tip 1 bulanık fonksiyonlar yaklaşımını incelendiğinde, açıklayıcı değişkenler arasında doğrusal ilişki bulunması halinde tahmin performansı olumsuz yönde etkilenmektedir, nitekim [32] çalışması bu noktaya ışık tutmuştur. Değişkenler arasındaki doğrusal ilişkiden doğan çoklu iç ilişki problemine yanlı tahmin yöntemlerinden ridge regresyon uygulanmış ve tahmin performansının arttığı gösterilmiştir.

Tez kapsamında, tüm bu bilgiler ışığında, öngörü hatasını azaltacak bir zaman serisi öngörü yöntemi önerilmesi hedeflenmiştir. Bu amaçla, [32] çalışmasının devamı olarak problemin ridge regresyon ve liu tipi regresyon modelleri ile incelenmesi planlanmış, klasik bulanık kümeler yerine sezgisel bulanık kümeler tercih edilerek bulanık kümelerin üyelik bilgisine ek olarak üye olmama bilgisinden de sistemin girdisi olarak yararlanılması amaçlanmıştır.

1.3 Hipotez

Tip 1 (sezgisel) bulanık fonksiyonlar [13] yaklaşımında her bir (sezgisel) bulanık küme için kullanılan çoklu doğrusal regresyon modelinde çoklu bağlantı probleminin giderilmesi öngörü performansını arttırmaktadır.

Sezgisel ridge regresyon bulanık fonksiyonlar ve ridge regresyon bulanık fonksiyonlar yöntemleri karşılaştırıldığında, sezgisel ridge regresyon bulanık fonksiyonlar yöntemi daha iyi öngörü performansı sergilemektedir.

Liu tipi tahmin ediciler çoklu iç ilişki problemini giderme açısından daha başarılı olduğundan (sezgisel) bulanık fonksiyonlar yaklaşımında en küçük kareler tahmin edicisi ve ridge regresyon tahmin edicisine kıyasla daha başarılı öngörü elde edilmesini sağlayan bulanık yaklaşımlar elde edilmesine olanak sağlamaktadır.

İnsanı diğer canlılardan ayıran en önemli özellik düşünebilme yetisidir [35]. Bu açıdan düşünme sisteminin işleyişi, geçmişten günümüze önemini kaybetmeyen bir araştırma konusu olmuştur. Aristo, mantık üzerine yaptığı çalışmaları, "alet", "araç" anlamlarına gelen "Organon" olarak isimlendirmiş ve mantığı, düşünmenin aracı olarak tanımlamıştır.

Özdeşlik, çelişmezlik, üçüncü şıkkın imkansızlığı ve yeter-sebep ilkesi olmak üzere dört temel ilke ile açıklanan klasik mantık, siyah ve beyazdan ibaret bir düşünce sistemini tanımlar. Ancak dünya kesikli değil sürekli bir yapıdadır. Siyah ve beyaz arasındaki geçiş keskin değildir, gri bölgeler mevcuttur [36].

Klasik mantık sisteminin işleyebilmesi, varsayımlar ve bazı önsel kabuller sayesinde mümkün olabilmektedir. Bu önsel kabuller sayesinde çalışma ortamının sınırları belirlenmiş ve sistemdeki belirsizlik soyutlanmış olmaktadır. Karşılaşılan bir çok mekanik problemin çözülmesinde faydalı olan bu mantık sistemi, karmaşık sistemlerde ve iyi tanımlanmamış problemlerin çözülmesinde yetersiz kalmaktadır. [37].

Bulanık mantık, Lotfy A. Zadeh tarafından 1965 yılında bu probleme çözüm niteliğinde önerilmiştir [2]. Aristo mantığına alternatif olarak önerilen bulanık mantık, ilk yıllarda kabul görmemiş ve mantık biliminden uzak bulunmuştur.

Bulanık mantığın ön yargı ile karşılanmasının nedenlerinden biri tanımlayıcı olarak "bulanık" kelimesinin seçilmesidir. Bulanık kelimesi güvenilir olmayan, matematiksel temeli bulunmayan gibi anlamlara çekilmeye çalışılsa da zamanla "dereceli" manasında kullanıldığı kabul görmüştür.

Belirsizlik içeren problemlere olasılık teorisi ve istatistiksel yöntemlerin çözüm ürettiği, bulanık mantığın gerekli olmadığı öne sürülmüştür. Ancak tüm belirsizlikler rastgele karakterde değildir, rastgele karakterde olmayan özelliklerle sözel belirsizlikler bulanık mantığın ana çalışma alanını oluşturur. Benzer şekilde sözel ifadelerin Bayesçi

yaklaşım ile sisteme dahil edilebileceği öne sürülse de sağlanması gereken varsayımlar (normallik, doğrusallık vb.) bulunmaktadır. Bulanık mantığın bu varsayımları sağlama zorunluluğunun bulunmaması yöntemin avantajlarından yalnızca biridir [37].

Daha sonraki yıllarda teknolojinin gelişmesine paralel olarak, yöntemin güncel hayat problemlerine uygulanma imkanı doğmuş, düşük maliyetle başarılı sonuçlar elde edildiği görülmüş ve bu sayede yaygın olarak kullanılmaya başlanmıştır.

Matematiksel yöntemlerin çözüm üretilmediği karmaşık problemlerde, klasik yöntemlerle çözüm üretilebilen ancak maliyetli olan durumlarda veya uzman bilgisine ihtiyaç duyan problemlerin çözülmesinde bulanık mantık işlevli bir çözüm seçeneği haline gelmektedir.

Son yıllarda bulanık mantık finansal deprem mühendisliğine kadar bir çok alanda sayısız uygulama imkanı bulmuştur. Özellikle Japonya'da otomatik tren operatörü (Hitachi), araç kontrolü (Tokyo Teknoloji Enstitüsü, Sugeno Laboratuvarı), robot kontrolü (Hoei Üniversitesi, Hirota Laboratuvarı), konuşma tanıma (Ricoh) gibi alanlarda bulanık mantık kullanılmaktadır [38].

Bulanık sistemler günlük hayatta, metrolarda hassas frenleme mekanizmalarına imkan sağlamakta bu sayede hem yolcuların konforunu hem de zaman tasarrufunu arttırmaktadır. Çamaşır makinelerinde ise uygun deterjan, ısı ve yıkama şeklini organize ederek uzman bilgisini günlük yaşama adapte etmektedir. Yine bulanık sistemlere örnek olarak fotoğraf makinesi ve kamera gibi günlük hayatta sıklıkla kullandığımız cihazlarda odaklama, renk, parlaklık ve ışık gibi değişkenlerin ayarlanmasında rol oynayarak en iyi görüntüyü elde etmeyi sağlamaktadır. Örnekler çoğaltılabilir, burada esas olan bulanık sistemlerin hayatı kolaylaştıran, basit yapıları sistemler olması ve insan düşünce sistemine benzerliği sayesinde verimli sonuçlar elde edilmesini sağlamasıdır [39].

2.1 Bulanık Kümeler ve İşlemler

Bulanık kümeler, sınırları kesin olmayan kümeler olarak tanımlanabilir. Bu özellik sayesinde üyelik değerleri, üye ve üye olmama kavramlarına ek olarak bu iki kavram arasındaki dereceyi de ifade edebilmektedir. [40].

Klasik kümelerde bir elemanın kümeye ait olması ancak üyelik değerinin 1 olması ile mümkündür. Diğer alternatif ise 0 üyelik değeri ile kümeye ait olmaması durumudur. Bulanık kümeler bu noktada elemana dereceli şekilde kümelere üye olma imkanı tanır

ve bu sayede keskin olan geçişi daha esnek ve sürekli hale getirir [37].

Bulanık küme: X , evrensel küme olmak üzere X 'in bir alt kümesi olan A için üyelik μ_A karakteristik fonksiyonu ile gösterilir. Belirtilen fonksiyon (2.1)'de belirtildiği gibi $[0, 1]$ aralığında değer alır ve \tilde{A} bulanık kümesi (2.2) olarak ifade edilir.

$$\mu_A : X \rightarrow [0, 1] \quad (2.1)$$

$$\tilde{A} = \{(x, \mu_A(x)) | x \in X\} \quad (2.2)$$

Kesikli bulanık küme: Tanımlanan evrensel kümenin kesikli olması durumunda, küme kesikli bulanık küme olarak adlandırılır ve (2.3) ile gösterilir. Burada " \sum " kesikli olma durumunu ifade ederken "/" bölme işlemini değil x elemanın $\mu_A(x)$ üyelik değerine sahip olduğunu ifade etmektedir.

$$\tilde{A} = \sum_X \mu_A(x)/x \quad (2.3)$$


Sürekli bulanık küme: Tanımlanan evrensel kümenin sürekli olması durumunda, küme sürekli bulanık küme olarak adlandırılır ve (2.4) ile gösterilir. Burada " \int " sürekli olma durumunu ifade ederken "/" bölme işlemini değil x elemanın $\mu_A(x)$ üyelik değerine sahip olduğunu ifade etmektedir.

$$\tilde{A} = \int_X \mu_A(x)/x \quad (2.4)$$

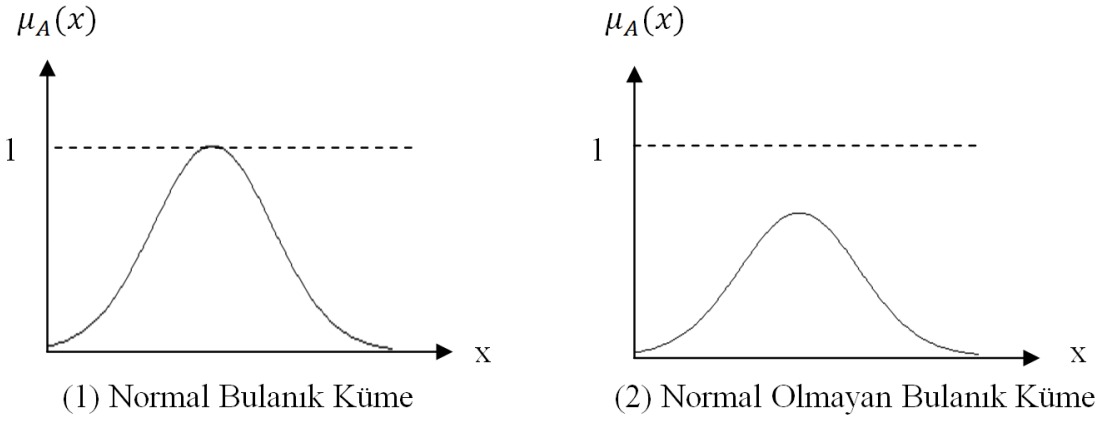
Üyelik fonksiyonu: Bulanık kümelerin sahip olduğu üyelik derecelerini göstermek amacıyla kullanılan fonksiyondur. Fonksiyon normallik ve dışbükeylik özelliklerini sağlamak zorundadır. En genel hali ile yamuk şekilli üyelik fonksiyonu Şekil 2.1'deki kısımlara sahiptir.

Normal bulanık küme: En az bir x değerine karşılık gelen üyeliğin 1'e eşit olduğu bulanık kümedir. Şekil 2.2'de çan eğrisi şekilli normal ve normal olmayan bulanık kümeler görselleştirilmiştir.

Dışbükeylik: Üyelik fonksiyonunun sürekli artan, sürekli azalan ya da üçgen şekilde olması halidir. Bir bulanık kümede, herhangi iki kümeyi birleştiren bir çizgideki tüm




Şekil 2.1 Üyelik fonksiyonu kısımları [37]



Şekil 2.2 Normal ve normal olmayan bulanık kümeler


noktalar bu kümenin elemanı ise küme dışbükeydir [39]. Şekil 2.3 ve Şekil 2.4 sırasıyla dışbükey ve dışbükey olmayan bulanık kümeleri göstermektedir.



Şekil 2.3 Dışbükey bulanık küme

Bulanık fonksiyonların belirlenmesi için literatürde bir çok yöntem bulunmaktadır. Detaylı bilgi için [41] incelenebilir.

Klasik kümelerde tanımlı olan birleşim, kesişim ve tümleyen gibi işlemler bulanık



Şekil 2.4 Dışbükey olmayan bulanık küme

kümeler için de tanımlıdır.

Birleşim: \tilde{A} ve \tilde{B} bulanık kümeleri için üyelik fonksiyonları $\mu_A(x)$ ve $\mu_B(x)$ olmak üzere birleşim operatörü bireysel üyelik fonksiyonlarının maksimumu olarak tanımlanır ve (2.5) ile gösterilir.

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)), \forall x \in X \quad (2.5)$$

Kesişim: \tilde{A} ve \tilde{B} bulanık kümeleri için üyelik fonksiyonları $\mu_A(x)$ ve $\mu_B(x)$ olmak üzere kesişim operatörü bireysel üyelik fonksiyonlarının minimumu olarak tanımlanır ve (2.6) ile gösterilir.

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)), \forall x \in X \quad (2.6)$$

Tümleyen: Bir bulanık küme için tümleyen operatörü bulanık kümedeki üyelik derecelerinin 1'den çıkarılması anlamına gelir. \tilde{A} ve \tilde{B} bulanık kümeler olmak üzere tümleyen işlemi (2.7) ile gösterilir.


$$\mu_{\tilde{A}}(x) = 1 - \mu_A(x), \forall x \in X \quad (2.7)$$

Kapsama: \tilde{A} ve \tilde{B} bulanık kümeleri (2.8) koşulunu sağlıyorsa \tilde{B} , \tilde{A} 'yı kapsar denir.

$$\mu_A(x) \leq \mu_B(x), x \in X \quad (2.8)$$

2.1.1 Bulanık C-Ortalamalar Kümeleme Yöntemi

K-Ortalamalar kümeleme yönteminin genişletilmiş hali olan Bulanık C-Ortalamalar (Fuzzy C-Means (FCM)) kümeleme yöntemi Dunn [42] tarafından önerilmiş ve Bezdek [43] tarafından geliştirilmiştir. Klasik kümeleme yöntemlerinde gözlem kümelerden herhangi birine kesin elemandır veya değildir, bu nedenle alabileceği üyelik değeri 0 veya 1 iken bulanık kümeleme yöntemlerinde gözlemin alabileceği değer üyelik değer aralığı olan $[0, 1]$ aralığında bir değer olabilmektedir. Bu avantaj da kümeler arası keskin geçişin daha gerçekçi ve esnek olabilmesine imkan sağlamaktadır. Şekil 2.5 de A ve B kümeleri arasındaki keskin geçiş görülebilmektedir.




Şekil 2.5 Klasik kümeleme yöntemi üyelik fonksiyonu

Şekil 2.6 da ise sınıra yakın gözlemlerde her iki kümeye de belirli derecelerde üyelik tanımlandığı ve geçişin daha hassas hale getirildiği gözlenmektedir.

Bir sınıf öğrenciyi zayıf ve kilolu öğrenciler olmak üzere iki kümeye ayırmak istediğimizi varsayalım. A zayıf öğrencileri içeren küme ve B şişman öğrencileri içeren küme olarak tanımlansın. Kümeleri ayıran sınır değer olarak 60 kilo alınır ve 60 kilo üzeri öğrencilerin şişman kümesine atanacağı düşünülürse klasik kümeleme açısından 60 kiloya sahip öğrenci zayıfken 61 kilo öğrenci şişman olarak atanacaktır. Bulanık kümeleme yaklaşımında ise bu 1 kiloluk farkın yaratacağı keskin etkinin yumuşatılması adına 61 kilo öğrenciyi her iki kümeye de dahil olmasını sağlayacak üyelik değerleri tanımlanır. Öğrenci 0.49 üyelik değeriyle zayıf kümesine dahilken aynı zamanda 0.51 üyelik değeriyle şişman kümesine dahil olabilir.

FCM kümeleme yöntemi için amaç fonksiyonu (2.9)'da verilmiştir. Verilen kısıtlar (2.10), (2.11) ve (2.12) ışığında amaç fonksiyonu minimize edilir ve kümeleme gerçekleştirilmiş olur.

$$J_m = \sum_{i=1}^c \sum_{k=1}^n (\mu_{ik})^m \|x_k - v_i\|^2, \quad 1 \leq m < \infty \quad (2.9)$$



Şekil 2.6 Bulanık kümeleme yöntemi üyelik fonksiyonu

Burada μ_{ik} i 'nci küme, k 'nci gözlem için üyelik değerini temsil etmektedir. m bulanıklık derecesini gösterirken, c küme sayısı, n gözlem sayısı olmak üzere, x_k , k 'nci gözlemi ve v_i , i 'nci küme merkezini göstermektedir.

$$\mu_{ik} \in [0, 1] \quad \forall i = 1, 2, \dots, c; \quad \forall k = 1, 2, \dots, n \quad (2.10)$$

$$\sum_{i=1}^c \mu_{ik} = 1 \quad \forall k = 1, 2, \dots, n \quad (2.11)$$

$$0 < \sum_{k=1}^n \mu_{ik} < n \quad \forall i = 1, 2, \dots, c \quad (2.12)$$

FCM Kümeleme Algoritması

Adım 1 Bulanıklık derecesi m , durdurma kriteri ε belirlenir, ilk adım için rasgele üyelik değerleri μ_{ik} $i = 1, 2, \dots, c; k = 1, 2, \dots, n$ üretilir.

Adım 2 Küme merkezleri v_i , $i = 1, 2, \dots, c$ (2.13) ile hesaplanır.

$$v_i = \frac{\sum_{k=1}^n (\mu_{ik})^m x_k}{\sum_{k=1}^n (\mu_{ik})^m}, \quad 1 \leq i \leq c \quad (2.13)$$

Adım 3 Öklid uzaklıkları d_{ik} , $i = 1, 2, \dots, c; k = 1, 2, \dots, n$, (2.14) ile hesaplanır.

$$d_{ik} = \sqrt{(x_k - v_i)^2} \quad (2.14)$$

Adım 4 Üyelik değerleri μ_{ik} $i = 1, 2, \dots, c$; $k = 1, 2, \dots, n$ (2.15) ile güncellenir.

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{2/(m-1)}}, \quad i = 1, 2, \dots, c; \quad k = 1, 2, \dots, n \quad (2.15)$$

Adım 5 Durdurma kriteri ε kontrol edilir. Yakınsama sağlanıyorsa iterasyon durdurulur, sağlanmıyorsa *Adım 2* ye geri dönülür.

2.2 Bulanık Çıkarım Sistemleri

İnsan düşünce sistemi sözel ifadelerden oluşur. Dolayısıyla insanlar arası etkileşim yine sözel ifadelerin kullanımı ile sağlanır. Bu noktada insanlar karşılaştıkları problemlerde önceki tecrübelerini gözden geçirerek ve ilişkilendirerek belli kurallar oluşturur ve bu kurallar ışığında karar verirler. Bahsi geçen kurallar belirsizlik içermesi nedeniyle diferansiyel ve integral gibi bilinen matematiksel yöntemler ile ifade edilemezler. Bu açıdan sözel ifadeleri kullanarak çıkarım yapabilmek için iyi tanımlanmış bulanık kurallara ve kuralları işleyerek çıkarım yapabilecek bir yapıya yani bulanık çıkarım sistemlerine (Fuzzy Inference System (FIS)) ihtiyaç vardır [37].

Bulanık çıkarım sistemleri dilsel öğelerden faydalanarak insan düşünce sistemindeki kural yapısına benzer bir yapı aracılığıyla çıkarım yapmayı hedeflemektedir. Bu hedefi, tanımlanan bulanık kurallar ve bulanık kümeler yardımı ile girdi ve çıktı değişkenleri arasındaki ilişkiyi açıklayarak gerçekleştirir.

Bulanık mantık yaklaşımı bahsedilen bulanık kural yapısını "EĞER ... İSE ..." şeklinde tanımlamaktadır. Bu tanımlamada İSE kelimesinden önce yer alan kısım "öncül", İSE kelimesinden sonra yer alan kısım ise "ardıl" olarak ifade edilmektedir [37].

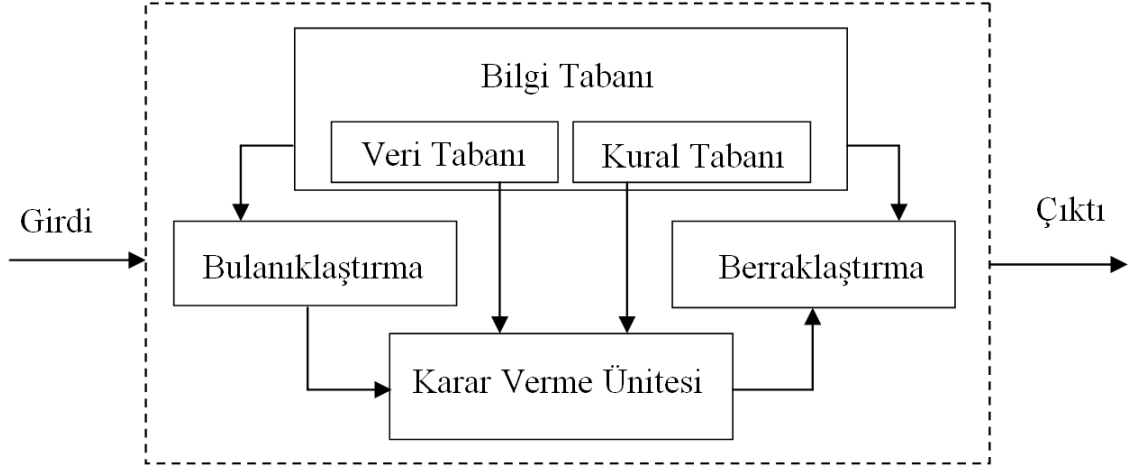
İki girişli ve bir çıkışlı bir bulanık sistem kuralı (2.16) şeklinde tanımlanabilir. Burada x, y, z dilsel değişkenleri tanımlamaktadır. A_i, B_i, C_i ise sırasıyla U, V, W uzaylarında tanımlı bulanık kümelerdir. Yani $x \in U, y \in V$ ve $z \in W$ 'dir. i ise $i = 1, \dots, n$ kural indisidir [44]. Çıktının matematiksel fonksiyon olduğu kural biçimi (2.17) ile gösterilmektedir.

$$EĞER \quad x = A_i \quad ve \quad y = B_i \quad İSE \quad z = C_i, \quad i = 1, \dots, n \quad (2.16)$$

$$EĞER \quad x = A_i \quad ve \quad y = B_i \quad İSE \quad z = f_i(x, \dots, y) \quad (2.17)$$

Bu kural yapısı sisteme subjektif bir katkı sağladığından kural tanımlama işleminin konunun uzmanı tarafından yapılması önem arz etmektedir.

Bulanık çıkarım sisteminin genel yapısı Şekil 2.7 ile gösterilmiştir.



Şekil 2.7 Bulanık çıkarım sistemi [45]

Bulanıklaştırma: Girdi değişkenlerin bulanık kural tabanında kullanılmak üzere bulanık kümelerle temsil edilmesidir. Sistemdeki ihtiyaca göre farklı şekillerde bulanık kümeler tercih edilebilir.

Çıkarım: Bulanık çıkarım sisteminin beyni olarak kabul edilen çıkarım birimi, dilsel ifadeler ve tanımlanan kuralları işleyerek sembolik sonuçları elde eder.

Berraklaştırma: Sistem çıktısı olan bulanık yapının tek bir sayıya indirgenmesi işlemidir. Problemin tipine göre uygulanabilecek farklı berraklaştırma yöntemleri mevcuttur (ağırlıklı ortalama yöntemi, sentroid yöntemi, en büyük üyelik ilkesi vb.).

Bulanık çıkarım sistemleri literatürde bulanık model, bulanık kural tabanlı sistem, bulanık uzman sistem, bulanık ilişkilendirme, bulanık kontrol gibi isimlerle de ifade edilmektedir [45].

2.2.1 Mamdani Bulanık Çıkarım Sistemi

Mamdani ve Assilian tarafından 1975 yılında gerçekleştirilen buhar makinesi uygulaması, bulanık küme teorisi kullanılarak gerçekleştirilen ilk FIS uygulamasıdır [3].

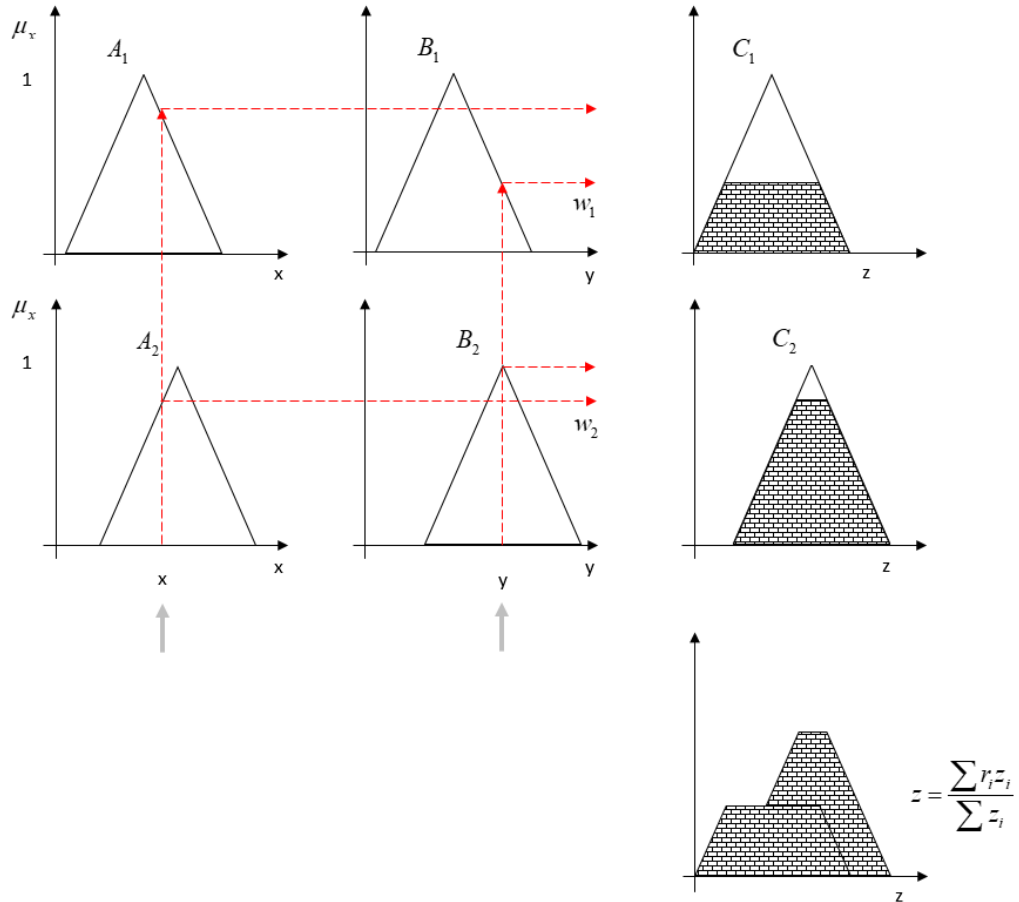
Klasik bir Mamdani FIS uygulaması uzman tarafından kuralların tanımlanması ile başlar. Girdilerin bulanıklaştırılmasının ardından tanımlanan kurallar ışığında kesişim

veya birleşim işlemi uygulanarak her bir kural için çıktı elde edilir. Kuralların çıktıları her zaman olmasa da genellikle birleşim operatörü ile kombine edilir [45]. Son aşamada ise ihtiyaca bağlı olarak elde edilen bulanık çıktı seçilen durulaştırma yöntemi ile durulaştırılabilir.

Örnek olarak iki kuralları Mamdani FIS, Şekil 2.8 de görselleştirilmiştir. Kural 1 (K_1) ve Kural 2 (K_2), (2.18) ve (2.19) ile gösterilmiştir. Tanımlanan kurallar ışığında kesişim (ve) işlemi ile her bir kural için çıktı elde edilir, ardından birleşim (veya) işlemi ile nihai bulanık küme elde edilir. Keskin çıkış ise seçilen durulama yöntemi kullanılarak hesaplanır.

$$K_1 : \text{EGER } x = A_1 \text{ ve } y = B_1 \text{ İSE } z = C_1 \quad (2.18)$$


$$K_2 : \text{EGER } x = A_2 \text{ ve } y = B_2 \text{ İSE } z = C_2 \quad (2.19)$$



Şekil 2.8 Mamdani bulanık çıkarım sistemi [44]

2.2.2 Sugeno Bulanık Çıkarım Sistemi

Takagi-Sugeno-Kang (TSK) olarak da bilinen yöntem [4], 1985 yılında ardıl kısmın, öncül değişkenlerin matematiksel fonksiyonu olabileceği düşüncesi ile önerilmiştir. Şekil 2.9 de görüleceği üzere her bir kuralın çıktısı birinci dereceden bir fonksiyondur. İki den fazla girdili bir sistemin çıktısı tıpkı bir regresyon fonksiyonuna benzer [37]. Sistemin nihai çıktısı Şekil 2.9 de gözlenen z fonksiyonu ile elde edilir. Sugeno FIS, son adımında durulaştırmaya ihtiyaç duymaması bakımından kullanışlı bir yöntemdir.



Şekil 2.9 Sugeno bulanık çıkarım sistemi [44]

2.2.3 Uyarlamalı Ağ Bulanık Çıkarım Sistemi

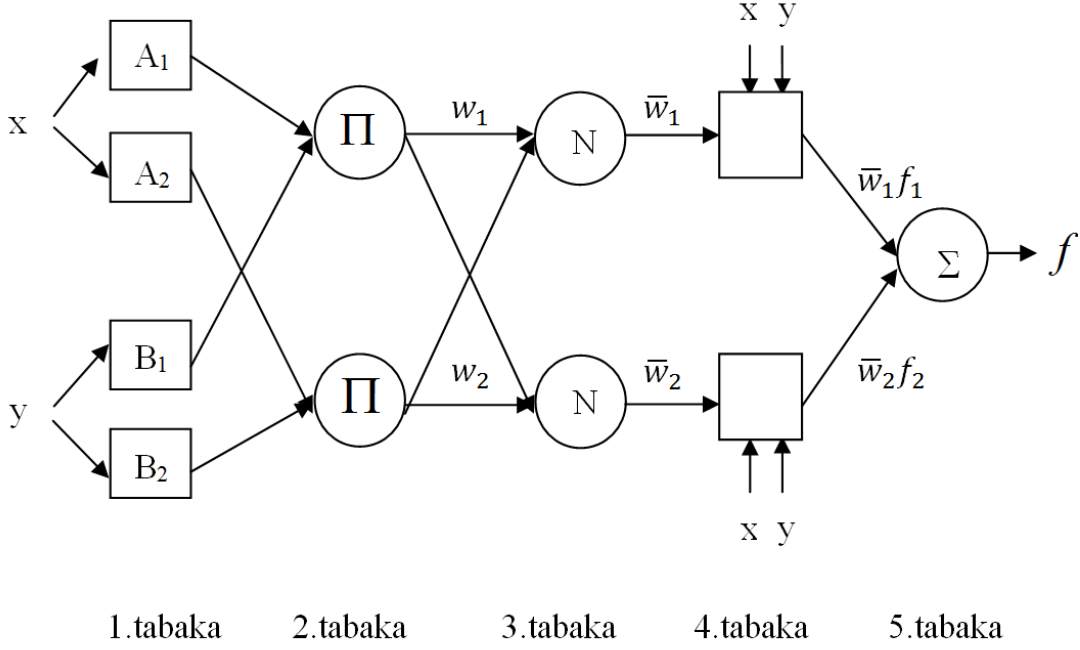
Uyarlamalı Ağ Bulanık Çıkarım Sistemi (Adaptive Network Fuzzy Inference System (ANFIS)) Jang tarafından 1993 yılında önerilmiştir [5]. Yapay sinir ağları ve bulanık mantığı bir araya getiren yöntem, yapay sinir ağlarının öğrenme yeteneğinden faydalanırken, bulanık mantık sayesinde sisteme uzman bilgisini dahil ederek iki sistemin de üstün yanlarından oluşan yeni bir sistem geliştirmiştir. Bulanık mantık ile tanımlanan kurallar yapay sinir ağlarının daha hızlı öğrenmesini sağlamıştır [44].

İki girdili ve iki kurallı Sugeno tip ANFIS yapısı Şekil 2.10 ile gösterilmiştir. Burada x ve y girdi değişkenlerini, f ise çıktıyı temsil etmektedir. ANFIS mimarisinde karesel

düğümmler parametre içerirken, yuvarlak düğümler parametre içermemektedir. Şekil 2.10 için $i = 1, 2$ olmak üzere bulanık kurallar ve tabakalar aşağıda tanımlanmıştır.

Kural 1: Eğer $x : A_1$ ve $y : B_1$ ise $f_1 = p_1x + q_1y + r_1$

Kural 2: Eğer $x : A_2$ ve $y : B_2$ ise $f_2 = p_2x + q_2y + r_2$



Şekil 2.10 ANFIS ağ yapısı

1. Tabaka: Bu tabakada A_i ve B_i bulanık kümeleri temsil etmektedir. Burada düğüm girdileri seçilen üyelik fonksiyonu yardımıyla bulanıklaştırılarak üyelik değerleri elde edilir. Bu işlem her i 'nci düğüm için gerçekleştirilir. Üyelik değerleri (2.20) ile gösterilmiştir.

$$O_i^1 = \mu_{A_i}(x), \quad i = 1, 2 \quad (2.20)$$

2. Tabaka: Bir önceki düğümden gelen üyelik değerleri, tanımlanan bulanık kural ışığında çarpılarak bir sonraki düğüme aktarılır. Çarpım operatörü ile tanımlanan bu tabakadaki işlem akışı (2.21) ile gösterilmiştir.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad (2.21)$$

3. Tabaka: Normalleştirilmiş seviyelerin belirlendiği bu tabakada bir önceki

düğümünden gelen değerler ağırlıklandırılır. Bu işlem (2.22) ile gösterilmiştir.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (2.22)$$

4. Tabaka: Sonuç ağırlıklarının hesaplandığı karesel düğümdür, (2.23) ile tanımlanmıştır. Burada $p_i, q_i, r_i \in R$ olmak üzere sonuç değişkenleridir.

$$O_i^4 = \bar{w}_i \times f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (2.23)$$

5. Tabaka: Toplam operatörü ile tanımlı bu tabakada bir önceki tabakadan gelen değerler toplanır ve çıkış değeri elde edilir. İşlem akışı (2.24) ile gösterilmiştir.

$$O_i^5 = \sum_i \bar{w}_i \times f_i, \quad i = 1, 2 \quad (2.24)$$

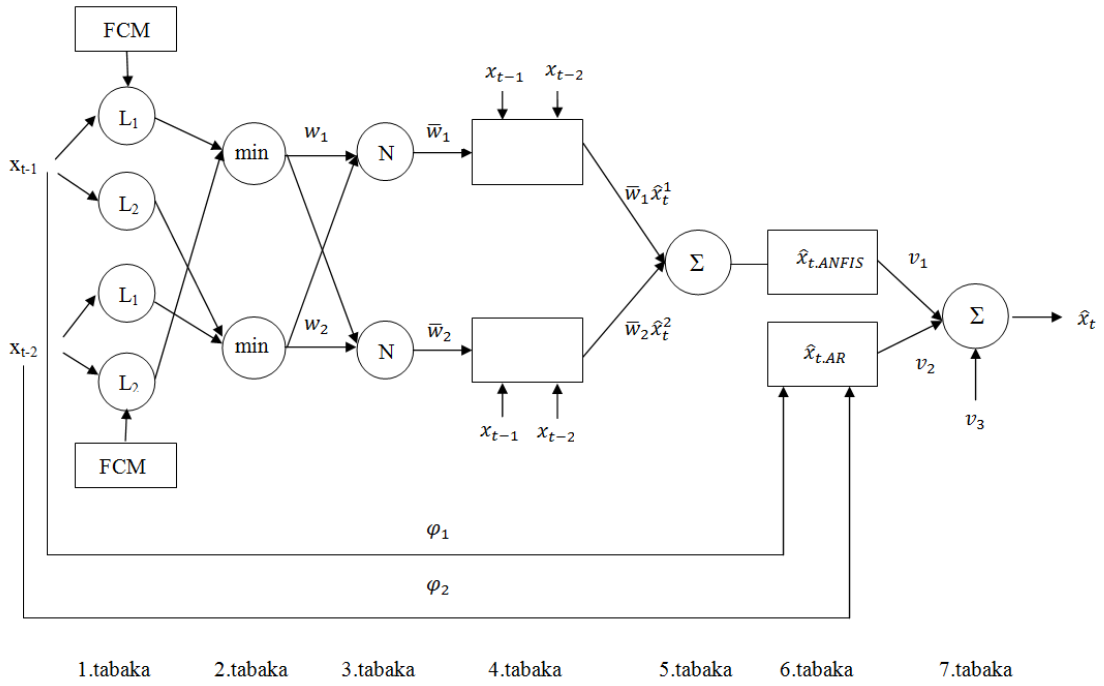
Sonuç değişkenleri (p_i, q_i, r_i) ve üyelik işlevlerine ait değişkenler (çan eğrisi üyelik fonksiyonu için (μ, σ)) geri yayımlı öğrenme algoritması ile ayarlanabilir. Bu algoritma temelde ağın çıkışından elde edilen hatayı ilk düğüme kadar geri yansıtarak gereken değişkenlerin ayarlanmasını hedefler. Yöntemin detayları için [44] incelenebilir.

2.2.4 AR-Uyarlamalı Ağ Bulanık Çıkarım Sistemi

AR-Uyarlamalı Ağ Bulanık Çıkarım Sistemi (AR-ANFIS) [12], ANFIS'in zaman serileri öngörüsüne özelleştirilmiş halinin [46] devamı niteliğindedir. Gerçek hayat zaman serilerinin yapısı, salt doğrusal ya da bilinen eğrisel bir yapıya uymamaktadır. Bu problemin çözümü olan melez yöntem, veriye dayalı ve modele dayalı iki yaklaşımı tek bir yapıda bir araya getirmiştir. Hem doğrusal hem doğrusal olmayan seriler için kullanılabilen yaklaşım, türev bilgisine de ihtiyaç duymamaktadır. Tüm bu avantajlara ek olarak, daha az kural ve parametre ile çalışma imkanı da sunmaktadır. AR-ANFIS yapısı Şekil 2.11 ile gösterilmiştir.

İki girdili ve iki kurallı AR-ANFIS'de x_{t-1} ve x_{t-2} girdileri, \hat{x}_t ise çıktıyı temsil etmektedir.

1. Tabaka: FCM kümeleme yöntemi ile üyelik değerleri elde edilir. İlk tabakanın



Şekil 2.11 AR-ANFIS ağ yapısı

çıktıları (2.25) ve (2.26) ile gösterilmiştir.

$$O_i^1 = \mu_{L_i}(x), \quad i = 1, 2 \quad (2.25)$$

$$O_i^1 = \mu_{L_{i-2}}(x), \quad i = 3, 4 \quad (2.26)$$

2. Tabaka: İlk tabakada elde edilen üyelik değerleri bu tabakada kurala göre bir araya getirilir ve minimum operatörü ile düğüm çıktısı hesaplanır. İkinci tabaka çıktıları (2.27) ve (2.28) ile gösterilmiştir.

$$O_1^2 = w_1 = \min(O_1^1, O_4^1) \quad (2.27)$$

$$O_2^2 = w_2 = \min(O_2^1, O_3^1) \quad (2.28)$$

3. Tabaka: İkinci tabaka çıktıları (2.29) ile normelleştirilir.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (2.29)$$

4. Tabaka: Bulanık kuralların sağ tarafında yer alan doğrusal fonksiyonların değerleri hesaplanır. Ağ yapısındaki iki kurala karşılık gelen doğrusal fonksiyonların çıktı değerleri (2.30) ve (2.31) ile gösterilmiştir.

$$\hat{x}_t^1 = p_1 x_{t-1} + q_1 x_{t-2} + r_1 \quad (2.30)$$

$$\hat{x}_t^2 = p_2 x_{t-1} + q_2 x_{t-2} + r_2 \quad (2.31)$$

5. Tabaka: ANFIS kısmının çıktısı hesaplanır. Toplam operatörü (2.32) ile uygulanır.

$$\hat{x}_{t,ANFIS} = \bar{w}_1 \hat{x}_t^1 + \bar{w}_2 \hat{x}_t^2 \quad (2.32)$$

6. Tabaka: AR kısmının çıktısı (2.33) ile hesaplanır.

$$\hat{x}_{t,AR} = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} \quad (2.33)$$

7. Tabaka: AR-ANFIS çıktısı (2.34) ile hesaplanır.

$$\hat{x}_t = v_1 \hat{x}_{t,ANFIS} + v_2 \hat{x}_{t,AR} + v_3 \quad (2.34)$$

Öğrenme algoritması olarak geri yayımlı öğrenme algoritması yerine Parçacık Sürü Optimizasyonu'nu kullanan yöntem, ayarlanması gereken parametreleri $p_i, q_i, r_i, \varphi_i, i = 1, 2$ ve $v_j, j = 1, 2, 3$ bu yöntem aracılığıyla hesaplamaktadır.

2.2.5 Tip 1 Bulanık Fonksiyonlar Yöntemi

Tip 1 Bulanık fonksiyonlar (Type 1 Fuzzy Functions (T1FF)) yaklaşımı Türkşen [13] tarafından, bulanık çıkarım sistemlerindeki öznellik ve genelleme problemine çözüm niteliğinde önerilmiştir. Bulanık fonksiyonlar yaklaşımının öngörü problemine uyarlanması üzerine [18], [19], [20] çalışmaları gerçekleştirilmiştir.

Bulanık çıkarım sistemlerinde uzman bilgisine ihtiyaç duyulmaktadır. Uzmanın, kuralları tanımlayabilmesi için bulanık mantık kuramı hakkında temel bilgiye sahip olması gerekir. Tüm bu şartlar sağlansa dahi uzman bilgisi sisteme öznel bir katkı sağlamaktadır. Bu noktada bulanık fonksiyonlar yaklaşımı, sistemi kural tanımlama

zorunluluğundan kurtararak daha genel bir yapı oluşturmaktadır. Uygun üyelik fonksiyonun belirlenmesi problemine ise üyelik değerlerini FCM ile hesaplayarak çözüm getirmiştir.

T1FF yaklaşımı her bir bulanık kurala karşılık bir regresyon fonksiyonu tanımlamaktadır.

Çok girdili tek çıktılı (Multiple Input Single Output) regresyon modeli için Tip 1 Bulanık Fonksiyonlar yaklaşımı adımları;

Adım 1 Gecikmeli değişkenlerden oluşan X girdi matrisi oluşturulur.

Adım 2 Girdi uzayı FCM kümeleme yöntemi ile kümelenecek üyelik değerleri (μ_{ik} $i = 1, 2, \dots, c$; $k = 1, 2, \dots, n$) hesaplanır. Burada c bulanık küme sayısını, n ise gözlem sayısını ifade etmektedir.

Adım 3 Bulanık regresyon fonksiyonları oluşturulur. Her bir bulanık küme için oluşturulan regresyon fonksiyonu (2.35)'de gösterilmiştir.

$$Y^{(i)} = X^{(i)}\beta^{(i)} + \varepsilon^{(i)}, \quad i = 1, 2, \dots, c \quad (2.35)$$

Sistem girdi matrisi ve çıktı vektörü sırasıyla (2.36) ve (2.37)'de gösterilmiştir. (2.36)'da p bağımsız değişken sayısını temsil etmektedir.

$$X^{(i)} = \begin{bmatrix} \mu_{i1} & x_{11} & \cdots & x_{p1} \\ \mu_{i2} & x_{12} & \cdots & x_{p2} \\ \vdots & \vdots & \vdots & \vdots \\ \mu_{in} & x_{1n} & \cdots & x_{pn} \end{bmatrix} \quad (2.36)$$

$$Y^{(i)} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad (2.37)$$

Üyelik değerlerinin dönüşümlerinin (özellikle üstel ve logaritmik) tahmin performansını arttırdığı yapılan kapsamlı araştırmalarda görülmüştür [34].

Adım 4 Bulanık regresyon fonksiyonlar, her bir bulanık küme için En Küçük Kareler (LSE) yöntemi kullanılarak (2.38) ile tahmin edilir.

$$\hat{Y}^{(i)} = X^{(i)}\hat{\beta}^{(i)}, \quad i = 1, 2, \dots, c \quad (2.38)$$

Adım 5 Her bir küme için elde edilen çıktı değeri, ilgili üyelik değeriyle ağırlıklandırılarak nihai çıktı (2.39) ile elde edilir.

$$\hat{y}_k = \frac{\sum_{i=1}^c \hat{y}_{ik} \mu_{ik}}{\sum_{i=1}^c \mu_{ik}}, \quad i = 1, 2, \dots, c; \quad k = 1, 2, \dots, n \quad (2.39)$$

2.3 Sezgisel Bulanık Kümeler

Sezgisel (intuitionistic) bulanık kümeler Atanassov [47] tarafından klasik bulanık kümelerin genelleştirilmiş hali olarak önerilmiştir. Klasik bulanık kümelerde üye olma ve üye olmama değerlerinin toplamı bire eşittir. Ancak bu yapıda bulanık kümenin tanımlanmasındaki belirsizlik göz ardı edilmektedir. Sezgisel bulanık kümelerde Atanassov bu belirsizliği tereddüt (hesitation) olarak tanımlayarak analize dahil etmiştir.

X , evrensel küme olmak üzere X 'in bir alt kümesi olan A sezgisel bulanık kümesi (2.40) ile gösterilmiştir. Burada μ_A üyelik derecesini gösterirken, ν_A üye olmama derecesini temsil etmektedir.

$$A = \{ \langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in X \} \quad (2.40)$$

Üyelik ve üye olmama derecelerinin tanım aralıkları (2.43) koşulunu sağlamak üzere (2.41) ve (2.42) ile gösterilmiştir.

$$\mu_A : X \rightarrow [0, 1] \quad (2.41)$$

$$\nu_A : X \rightarrow [0, 1] \quad (2.42)$$

Üyelik ve üye olmama değerlerinin toplamında alt ve üst sınırlar (2.43) ile gösterilmiştir.

$$0 \leq \mu_A(x) + \nu_A(x) \leq 1 \quad (2.43)$$

Sezgisel bulanık kümeleri, klasik bulanık kümelerden ayıran tereddüt derecesi (2.44)


ile gösterilmiştir.

$$0 \leq \pi_A(x) \leq 1 \quad (2.44)$$

Terredüt derecesi için tanım aralığı (2.45)'de gösterilmiştir.


$$\pi_A : X \rightarrow [0, 1] \quad (2.45)$$

Sezgisel bulanık kümelerde üyelik ve üye olmama değerleri arası ilişkinin geometrisi Şekil 2.12 ve Şekil 2.13 ile görselleştirilmiştir. Şekil 2.12'den de açıkça görüleceği üzere μ_A ve ν_A birbirinin tümleyeni değildir, tereddüt derecesi mevcuttur.



Şekil 2.12 Sezgisel bulanık küme geometrik yorumu - 1 [48]


Şekil 2.13 incelendiğinde eğrilerin paralel olmadığı açıktır. Tereddüt derecesinin yarattığı bu farklılık sayesinde klasik bulanık kümelerde mevcut olmayan ek bilgiyi kullanma imkanı doğmaktadır.



Şekil 2.13 Sezgisel bulanık küme geometrik yorumu - 2 [48]

μ_A ve $1 - \nu_A$ için mevcut eğrilerin aynı salınımda olması hali $\pi_A(x) = 0$ durumunda

yani klasik bulanık kümelerde mümkündür. Şekil 2.14 sezgisel bulanık kümeler için mümkün olmayacak geometrik yorumu göstermektedir.



Şekil 2.14 Sezgisel bulanık küme için mümkün olmayan geometrik yorum [48]

Küme işlemleri, klasik kümeler ve klasik bulanık kümelerde olduğu gibi sezgisel bulanık kümeler için de tanımlanmıştır. Üye olmama değerinin de dikkate alınması gereken işlemler aşağıda açıklanmıştır.

Birleşim: \tilde{A} ve \tilde{B} sezgisel bulanık kümeleri için üyelik değerleri $\mu_A(x)$ ve $\mu_B(x)$ olmak üzere birleşim operatörü bireysel üyelik değerlerinin maksimumu ve bireysel üye olmama değerlerinin minimumu olarak tanımlanır ve (2.46) ile gösterilir.

$$\mu_{A \cup B}(x) = \{ \langle x, \max(\mu_A(x), \mu_B(x)), \min(\nu_A(x), \nu_B(x)) \rangle : x \in X \} \quad (2.46)$$

Kesişim: \tilde{A} ve \tilde{B} sezgisel bulanık kümeleri için üyelik değerleri $\mu_A(x)$ ve $\mu_B(x)$ olmak üzere kesişim operatörü bireysel üyelik değerlerinin minimumu ve bireysel üye olmama değerlerinin maksimumu olarak tanımlanır ve (2.47) ile gösterilir.

$$\mu_{A \cap B}(x) = \{ \langle x, \min(\mu_A(x), \mu_B(x)), \max(\nu_A(x), \nu_B(x)) \rangle : x \in X \} \quad (2.47)$$

Tümleyen: \tilde{A} sezgisel bulanık küme olmak üzere tümleyen işlemi (2.48) ile gösterilir.

$$A^c = \{ \langle x, \nu_A(x), \mu_A(x) \rangle : x \in X \} \quad (2.48)$$

Kapsama: \tilde{A} ve \tilde{B} bulanık kümeleri (2.49) koşulunu sağlıyorsa \tilde{B} , \tilde{A} 'yı kapsar denir.

$$A \subseteq B \leftrightarrow \mu_A(x) \leq \mu_B(x) \text{ ve } \nu_A(x) \geq \nu_B(x) \quad \forall x \in X \quad (2.49)$$

2.3.1 Sezgisel Bulanık C-Ortalamalar Kümeleme Yöntemi

FCM kümeleme yöntemini de kapsayan sezgisel bulanık c-ortalamalar (IFCM) kümeleme yöntemi üyelik bilgisine ek olarak üye olmama bilgisini de kullanarak küme merkezlerinin tahmininde daha gerçekçi sonuçlar elde etmektedir [49]. Literatürde sezgisel bulanık kümeleri temel alan FCM kümeleme yöntemi, 2007 yılında Zhang ve Chen [50] tarafından, 2010 yılında Xu vd. [51] tarafından ve 2011 yılında Chaira [52] tarafından önerilmiştir. Tez kapsamında Chaira tarafından önerilen yöntem kullanılmış olduğundan akışa Chaira [52] algoritması ile devam edilecektir.

IFCM Kümeleme Algoritması

Adım 1 $\mu_{ik}, i = 1, 2, \dots, c; k = 1, 2, \dots, n$ k 'nci veri i 'nci küme üyelik değerini temsil etmektedir. $r_{ik}, i = 1, 2, \dots, c; k = 1, 2, \dots, n$ ise düzgün dağılımdan $(0, 1)$ parametreleri ile üretilmiş başlangıç değerleridir. Üyelik değerleri (2.50) ile elde edilir.

$$\mu_{ik} = \frac{r_{ik}}{\sum_{i=1}^c r_{ik}} \quad (2.50)$$

Adım 2 Tereddüt derecesi (π_{ik}) ve sezgisel bulanık üyelik değeri (μ_{ik}^*) sırasıyla (2.51) ve (2.52) ile hesaplanır.

$$\pi_{ik} = 1 - \mu_{ik} - (1 - \mu_{ik}^\alpha)^{1/\alpha}, \alpha > 0 \quad (2.51)$$

$$\mu_{ik}^* = \mu_{ik} + \pi_{ik} \quad (2.52)$$

Sezgisel üyelik değerleri (μ_{ik}^*), U_{eski} matrisinde saklanır.

Adım 3 Küme merkezleri (v_i^*) (2.53) kullanılarak hesaplanır.

$$v_i^* = \frac{\sum_{k=1}^n (\mu_{ik}^*)^m x_k}{\sum_{k=1}^n (\mu_{ik}^*)^m}; i = 1, 2, \dots, c \quad (2.53)$$

x_k, k^{th} nci gözlem ve m bulanıklık katsayısını temsil etmektedir.

Adım 4 Üyelik değerleri (2.54) kullanılarak güncellenir.

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{2/(m-1)}}; i = 1, 2, \dots, c; k = 1, 2, \dots, n \quad (2.54)$$

burada d_{ik} , k 'ncü gözlem ve i 'ncü küme merkezi arasındaki öklid uzaklığını gösterir ve (2.55) ile hesaplanır.

$$d_{ik} = \sqrt{(x_k - v_i^*)^2} \quad (2.55)$$

Adım 5 Tereddüt derecesi (π_{ik}) ve sezgisel bulanık üyelik değeri sırasıyla (2.51) ve (2.52) ile güncellenir. Güncellenmiş sezgisel bulanık üyelik değerleri (μ_{ik}^*), U_{yeni} matrisinde saklanır.

Adım 6 Durdurma kriteri kontrol edilir.

$$\text{Durdurma Kriteri : } \|U_{yeni} - U_{eski}\|_2 < \varepsilon$$

Durdurma kriteri sağlanırsa algoritma sonlandırılır, aksi takdirde $U_{eski} = U_{yeni}$ olarak atanır ve *Adım 2*'ye geri dönlür.

burada ε pozitif küçük bir sayı olup $\|\cdot\|_2$, L_2 normunu gösterir.

3

REGRESYON ANALİZİ

Regresyon terimi ilk kez Galton tarafından kullanılmıştır. Anne, baba boyu ile çocuk boyu arasındaki ilişkinin incelendiği çalışma [53], sonrasında Pearson tarafından doğrulanmıştır [54].

Regresyon çözümlemesinin temel amacı; bağımlı ve bağımsız değişkenler arasındaki ilişkiyi matematiksel modelle açıklayarak bağıntılar bulmak ve bağımsız değişkenler yardımı ile bağımlı değişkeni kestirmektir [55].

Çoklu doğrusal regresyon modeli (3.1) biçiminde ifade edilir.

$$y = X\beta + \varepsilon \quad (3.1)$$

Burada y , $n \times 1$ boyutlu yanıt değişken vektörü, X , $n \times p$ boyutlu stokastik olmayan önceden belirlenmiş açıklayıcı değişkenlerin tam kolon ranklı matrisi, β , $p \times 1$ boyutlu bilinmeyen parametreler vektörü ve ε , $n \times 1$ boyutlu $NID(0, \sigma^2)$ dağılımlı rastgele hataların vektörüdür. Doğrusal regresyon modelinin katsayı tahmini için en sık en küçük kareler tahmin edici (LSE) kullanılmaktadır. İlgili varsayımlar altında türetilen LSE, parametrelerin doğrusal, en iyi, yansız tahmin edicisidir.

β 'nın en küçük kareler tahmin edicisi (3.2) ile gösterilmiştir.

$$\hat{\beta}_{EKK} = (X'X)^{-1}X'y \quad (3.2)$$

burada X matrisinin tam kolon ranklı olma koşulu dolayısıyla $(X'X)^{-1}$ ters matrisinin mevcut olması sağlanmalıdır. Eğer bağımsız değişkenler doğrusal bağımsız ise X matrisinin hiçbir sütununun diğer sütunlarla doğrusal bir birleşimi yoktur [56]. Bu varsayım sağlanmadığı takdirde çoklu iç ilişki (çoklu bağlantı (multicollinearity)) problemi ortaya çıkmaktadır.

3.1 Çoklu İç İlişki Problemi

Çoklu iç ilişki, doğrusal regresyonda, iki veya daha fazla bağımsız değişken arasındaki doğrusal bağıntı olarak tanımlanabilir [57]. Örneklemin evreni iyi temsil etmemesi, gözlem sayısının değişken sayısından fazla olması veya bağımsız değişkenler arasında ilişki olması durumu problemin nedenleri olarak sıralanabilir [55].

X_1, X_2, \dots, X_k bağımsız değişkenler ve a_1, a_2, \dots, a_k hepsi aynı anda sıfır olmayan sabitler olmak üzere (3.3) sağlanıyorsa bağımsız değişkenler tam çoklu doğrusal bağımlıdır.

$$a_1X_1 + a_2X_2 + \dots + a_kX_k = 0 \quad (3.3)$$

Bağımsız değişkenlerin tam olmasa da birbirleriyle ilişkili olması durumu ise (3.4) ile gösterilmiştir.

$$a_1X_1 + a_2X_2 + \dots + a_kX_k + v_i = 0 \quad (3.4)$$

burada v_i olasılıklı hata terimini temsil etmektedir. Eğer çoklu iç ilişki problemi (3.3) şeklinde tam ise, regresyon katsayıları belirsiz olup standart hataları sonsuzdur. Eğer çoklu iç ilişki problemi (3.4) gibi tamdan az ise regresyon katsayıları belirlenebilmekle birlikte çok büyük standart hatalara sahip olurlar [58].

Çoklu doğrusal regresyon modeli üzerinden yapılan çıkarsamaların doğruluğu, modelin doğru belirlenmesine dolayısıyla regresyon katsayılarının doğru kestirimine bağlıdır. Bu açıdan regresyon katsayılarının standart hatalarının büyümesi, gerçekte anlamlı olan parametrelerin anlamsız olarak değerlendirilmesine, dolayısıyla modelin yanlış belirlenmesine neden olabilmektedir. Çoklu iç ilişki probleminin tespit edilmesi bu nedenle oldukça önemlidir. Problemin tespiti için literatürde bir çok yaklaşım mevcuttur. Bunlardan bazıları;

- Korelasyon matrisinin incelenmesi
- Varyans şişme değerleri (Variance Inflation Factor (VIF))
- Koşul sayısının incelenmesi


Problemin tespiti ve büyüklüğünün değerlendirilmesi sonrasında hangi yöntem ile çözüleceğine karar verilmesi gerekmektedir.

Çoklu iç ilişki probleminin giderilmesi için ek veri toplanması veya modelin yeniden belirlenmesi (bağımsız değişkenlerin yeniden tanımlanması, bağımsız değişken

eleme) yoluna gidilebileceği gibi yanlı tahmin yöntemlerinden de faydalanılabilir. Yanlı tahmin yöntemleri ve diğer yöntemler karşılaştırıldığında iç ilişki probleminde yanlı kestirim üstünlük sağlamaktadır [56].

3.2 Yanlı Tahmin Ediciler

LSE ile elde edilen regresyon katsayılarında çoklu iç ilişki nedeniyle meydana gelen olumsuz etkinin giderilmesi için yanlı tahmin yöntemlerinden faydalanılabilir. Bahsedilen etkinin yanlı ve yansız kestiriciler açısından görselleştirilmiş hali Şekil 3.1'da yer almaktadır.



Şekil 3.1 β 'nın (a) yansız ve (b) yanlı kestiricilerinin örnekleme dağılımı [56]

Görüleceği üzere β 'nın, (a) yansız kestiricilerinin örnekleme dağılımında $\hat{\beta}$ 'nin varyansı oldukça büyük olup güven aralıkları geniştir. Bu durum da $\hat{\beta}$ 'nin nokta tahmininin kararsız olacağı fikrini yaratmaktadır. β 'nin, (b) yanlı kestiricilerinin örnekleme dağılımında ise yanlı kestirici olarak $\hat{\beta}^*$ 'nin varyansı küçük, güven aralığı dar dolayısıyla nokta tahminlerinin daha kararlı olacağı sonucuna varılır [56].

Tahmin edici performanslarını kıyaslamak için hata kareler ortalaması (Mean Squared Error (MSE)) bir göstergedir. $\hat{\beta}^*$ kestiricisinin MSE değeri (3.5) ve (3.6) ile gösterilmektedir.

$$MSE(\hat{\beta}^*) = E(\hat{\beta}^* - \beta)^2 = Var(\hat{\beta}^*) + [E(\hat{\beta}^*) - \beta]^2 \quad (3.5)$$

$$MSE(\hat{\beta}^*) = Var(\hat{\beta}^*) + (\hat{\beta}^*daki\ yan)^2 \quad (3.6)$$

Görüleceği üzere $\hat{\beta}^*$ için az miktarda yanlılık eklenerek varyansta büyük miktarda azalış sağlanabilir. Bu nedenle çoklu iç ilişki problemi bulunan çalışmalarda yanlı tahmin ediciler tercih edilerek varyansta azalma sağlanırken, dar güven aralığı sayesinde daha kararlı regresyon katsayıları elde edilmesi mümkün olacaktır.


Çalışma kapsamında yanlı tahmin yöntemlerinden ridge regresyon, liu ve liu tipi regresyon yöntemlerine yer verilecektir.

3.2.1 Ridge Tahmin Edici

Hoerl ve Kennard'ın 1970 yılında önerdiği yöntemde [59], bağımsız değişkenler arasında çoklu iç ilişki bulunması durumunda $X'X$ matrisinde meydana gelen kötü koşulluluğu $X'X$ matrisinin köşegen elemanlarına sabit bir katsayı ekleyerek çözmüştür. Ridge regresyon tahmin edici (RRE) olarak adlandırılan tahmin edici sayesinde MSE'si, LSE MSE'sinden daha düşük regresyon katsayıları tahmin edilebilmiştir. RRE (3.7) biçiminde tanımlanır.

$$\hat{\beta}_{Ridge} = (X'X + kI)^{-1}X'y \quad (3.7)$$


Burada $k \geq 0$ yan parametresi olmak üzere bir sabit ve I birim matristir. $k = 0$ durumunda RRE, LSE'ye dönüşmektedir.



Şekil 3.2 Ridge regresyon tahmin edici geometrik yorumu

Şekil 3.2'de LSE ve RRE'nin geometrik konumu gösterilmiştir. LSE, elipsin ortasında yer alan nokta olup, amaç fonksiyonunu minimum yapan ve yansız olan tahmin edicidir. Eksenin merkezinde yer alan daire ise parametre tahmini için mevcut kısıtı ifade etmektedir. Elips ve dairenin kesişim noktası RRE'yi temsil etmektedir.

RRE MSE'sinin, LSE MSE'sine tercih edilebilmesi için k değerinin küçük seçilmesi gerekmektedir. Bu noktada, optimum k değerinin seçimi için literatürde bir çok yöntem önerilmiştir. Tez kapsamında Hoerl, Kennard ve Baldwin'in önerdiği [60], (3.8)'de verilen yöntem kullanılmıştır.



Şekil 3.3 MSE ve k dengesi [59]

$$k = \frac{p\hat{\sigma}^2}{\hat{\beta}'\hat{\beta}} \quad (3.8)$$

burada p , bağımsız değişken sayısı, $\hat{\sigma}^2$ ve $\hat{\beta}$, LSE tahmin değerleridir.

Şekil 3.3 ridge regresyon tahmin edicinin, k yanlılık parametresinin artışına bağlı olarak varyans ve yanlılık açısından seyrini göstermektedir. Görüleceği üzere k değerinin büyük seçilmesi varyansı azaltmakla birlikte yanlılık ve hata kareler ortalamasını arttırmaktadır. Bu açıdan ileri derece çoklu iç ilişki problemlerinde düşük k seçimi problemi çözümleyemediğinden alternatif yanlı tahmin yöntemlerinden faydalanılabilir.

3.2.2 Liu Tahmin Edici

Çoklu iç ilişki varlığında kullanılabilir yanlı tahmin yöntemlerinden biri de Liu tahmin edicidir (LE). Liu tarafından 1993 yılında önerilmiştir [61]. Stein tahmin edici [62] ile RRE'nin [59] pozitif yanlarını dikkate alan yeni bir yanlı tahmin edicidir. Ayrıca LSE ile önerdiği yöntem tahmin edicisinin MSE değerlerini karşılaştırarak yönteminin daha küçük MSE değerine sahip olduğunu göstermiştir [63]. LE (3.9)

biçiminde tanımlanır.

$$\hat{\beta}_{Liu} = (X'X + I)^{-1}(X'y - d\hat{\beta}) \quad (3.9)$$

burada I birim matris, d ise Liu tahmin edicisi için $0 < d < 1$ olmak üzere yanlılık parametresidir. $\hat{\beta}$ ise LSE değeridir.

Burada mühim olan modele en uygun d değerinin seçilmesidir, bu nedenle bir çok araştırmacı bu noktaya yoğunlaşmıştır. Literatürde k değerinde olduğu gibi d değerinin hesaplaması için de farklı yöntemler önerilmiştir.

3.2.3 Liu Tipi Tahmin Edici

Liu tarafında 1993 yılında önerilen Liu tipi tahmin edici (LTE) [64], RRE'nin kötü koşullu olma durumunu tamamen yok etmemesi problemine yönelik önerilmiştir. Önerilen yöntem k değerinin büyük seçilmesine imkan vererek varyansı azaltırken d parametresi ile sistemdeki yanlılığı dengelemektedir. (3.10) Liu tipi tahmin ediciyi tanımlamaktadır.

$$\hat{\beta}_{Liu.T} = (X'X + kI)^{-1}(X'y - d\hat{\beta}) \quad (3.10)$$

burada $k > 0$, $-\infty < d < \infty$ olmak üzere $\hat{\beta}$, β 'nin herhangi bir tahmin edicisidir. Bu tahmin edici, k parametresi ile $X'X + kI$ matrisindeki iç ilişkiyi kontrol etmeyi hedefler. $X'X + kI$ matrisinin koşul indeksinin gerekli seviyeye düşürülmesiyle sisteme yansıyan yanlılık ikinci parametre olan d ile dengelenir. Liu çalışmasında [64], parametrelerin ortalama hata kareleri açısından LTE'nin RRE'den üstün olduğunu göstermiştir [65].

(3.1)'in kanonik formu (3.11) olmak üzere;

$$y = Z\alpha + \varepsilon \quad (3.11)$$

burada $Z = X\theta$, $\alpha = \theta'\beta$ ve θ , $X'X$ matrisinin özdeğerlerinden oluşan $p \times p$ 'lik ortogonal matristir.

$$Z'Z = \theta'X'X\theta = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p) \quad (3.12)$$

buarada $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$, $X'X$ matrisinin sıralı özdeğerleridir. (3.11)'de α için LSE,

RRE ve LTE sırası ile (3.13), (3.14) ve (3.15) ile gösterilmiştir.

$$\hat{\alpha}_{LS} = \Lambda^{-1}Z'Y \quad (3.13)$$

$$\hat{\alpha}_R = (\Lambda + kI)^{-1}Z'Y \quad (3.14)$$

$$\hat{\alpha}_{k,d} = (\Lambda + kI)^{-1}(Z'Y - d\hat{\alpha}) \quad (3.15)$$

Liu çalışmasında [64], $\hat{\alpha} = \hat{\alpha}_R$ için d parametresini (3.16) ile tanımlamıştır.

$$d = \frac{\sum_{i=1}^p (\lambda_i(\sigma^2 - k\alpha_i^2))/(\lambda_i + k)^3}{\sum_{i=1}^p (\lambda_i(\lambda_i\alpha_i^2 + \sigma^2))/(\lambda_i + k)^4} \quad (3.16)$$

Ancak bu eşitliğin nümerik olarak hesaplanması mümkün olmadığından k ve d için (3.17) ve (3.18) önerilmiştir.

$$\hat{k} = \frac{\lambda_1 - 100\lambda_p}{99} \quad (3.17)$$

$$\hat{d} = \frac{\sum_{i=1}^p (\lambda_i(\hat{\sigma}_R^2 - \hat{k}\hat{\alpha}_{R_i}^2))/(\lambda_i + \hat{k})^3}{\sum_{i=1}^p (\lambda_i(\lambda_i\hat{\alpha}_{R_i}^2 + \hat{\sigma}_R^2))/(\lambda_i + \hat{k})^4} \quad (3.18)$$

LTE için k ve d önerilen şekilde seçildiğinde $X'X + kI$ matrisinin koşul indeksi 10'un altına düşmekte ve çoklu iç ilişki problemi elimine edilmektedir. Aynı zamanda \hat{k} 'nin yeterli derecede büyük seçilmesinden kaynaklı yanlılık etkisi \hat{d} tarafından giderilmektedir.

Hiperparametre optimizasyonu sonuçlara yön vermesi açısından önem arz etmektedir. Başarılı ayarlanmış hiperparametreler, iyi parametre tahminlerini dolayısıyla iyi bir modeli ve gerçeğe yakın öngörü elde edilmesini sağlar.

Çalışma kapsamında Liu tipi tahmin edici için k ve d parametrelerinin ayarlanması noktasında son yıllarda literatürde de artış gösteren veri tabanlı yöntemlerden faydalanılmıştır. Bu açıdan çapraz geçerlik yöntemi en yaygın kullanılan yöntemlerden biridir[66]. Izgara arama çapraz geçerlik yöntemi sıklıkla kullanılan yöntemlerden biri olarak tercih edilmiş olup çapraz geçerlik noktasında zaman serilerine uygun versiyonu dikkate alınmıştır. Izgara arama çapraz geçerlik yönteminin kısa tanımı 'ızgaradaki her nokta için performans istatistiklerinin çapraz geçerlik tahminlerinin üretilmesi' şeklinde yapılabilir.

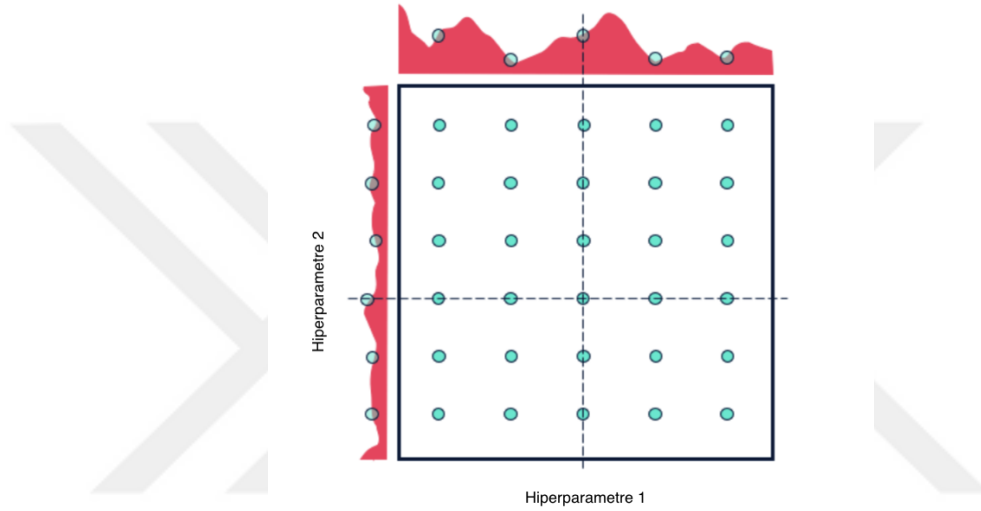
Dudoit ve van der Laan [67] çalışması, k gözlü çapraz geçerlik yöntemi ile hiperparametre seçiminin asimptotik yaklaşımını göstermesi nedeniyle yöntemin teorik temeli olarak gösterilmektedir [68]. Varma ve Simon [69] çalışmasında hiperparametre optimizasyonu için birini dışarıda bırakma çapraz geçerlik yöntemini kullanmıştır. Algamal [66] çalışmasında ridge regresyon tahmin edici hiperparametre optimizasyonu için değiştirilmiş çapraz geçerlik yöntemini kullanmıştır. Golub, Heath ve Wahba [70] ridge regresyon tahmin edici hiperparametre optimizasyonu için genelleştirilmiş çapraz geçerlik yöntemini kullanmıştır. Özkale [71] de benzer şekilde ridge regresyon hiperparametre optimizasyonunda çapraz geçerlik yönteminin başarılı sonuç elde ettiğini göstermiştir.

4.1 Izgara Arama Yöntemi

Izgara arama yöntemi (grid search), hiperparametre optimizasyonunda sıklıkla kullanılan yöntemlerden biridir [72]. Hiperparametreler için tüm kombinasyonları değerlendirmesi ve uygulama kolaylığı bakımından kullanışlı bir yöntemdir. Büyük arama uzaylarında artan çalışma süresi yöntemin dezavantajı olarak görülmektedir

[73].

Hiperparametrelere örnek olarak ridge regresyon için k , liu tipi regresyon için k ve d verilebilir. Izgara arama yönteminde, hiperparametre uzayı belirlenir, olası kombinasyonlar için modeller eğitilir ve ilgili metrik yardımıyla performanslar değerlendirilir. Şekil 4.1'da iki hiperparametrelilik bir yapı için ızgara arama yöntemi görselleştirilmiştir. Her bir nokta, model için olası hiperparametre ikilisini temsil etmektedir. Optimizasyon sürecinde uzaydaki tüm noktalar sınanarak uygun çözüm bulunmaktadır.



Şekil 4.1 Izgara arama yöntemi

Izgara arama yöntemine alternatif olarak rasgele arama yöntemi ve iki yöntem açısından pozitif ve negatif özellikler Bergstra ve Bengio [72] çalışmasında incelenmiştir.

4.2 Çapraz Geçerlik Yöntemi

Regresyon çözümlemesinde model, eldeki veriye en iyi uyumu sağlayacak şekilde belirlenir. Model eğitiminde yer almayan yeni bir veriden elde edilecek performans her zaman çok iyi olmayabilir. Bu açıdan amacın öngörü olduğu araştırmalarda modelin tahmin performansının incelenmesi gerekmektedir. Öngörü hatasında ortaya çıkan bu yanlışlığın giderilmesi amacıyla önerilen yöntemler "Bilgi Kriteri" ve "Tekrar Örnekleme" yöntemleri olarak iki ana başlık altında toplanmaktadır. Bilgi kriteri yöntemlerinde (Akaike Bilgi Kriteri (AIC), Bayesci Bilgi Kriteri (BIC) vb.) bu yanlışlık çeşitli kısıtlarla giderilmeye çalışılır. Tekrar örnekleme yöntemlerinde ise veri iki kısma ayrılarak bir kısmı gelecekteki, şu an mevcut olmayan veriler şeklinde

değerlendirilerek yanlılık giderilmeye çalışılır [74].

Öngörü performansının değerlendirilmesi için alternatif bir yol olarak yeni gözlem elde etme düşünülebilir ancak problemin hem uygulanabilirlik hem maliyet açısından değerlendirilmesi gerekir.

Tekrar örnekleme yöntemleri bu açıdan uygulaması kolay ve tercih edilen yöntemlerdir. Çapraz geçerlik (cross validation (CV)) [75], [76] yöntemi sınıflandırma ve regresyon problemlerinde en sık kullanılan yöntemlerden biridir [77]. Bu yöntemde, veri eğitim ve test olarak iki kısma ayrılır, eğitim kısmı ile model eğitilirken, test kısmı ile modelin gelecek yeni verilerde göstereceği performans değerlendirilir.

Tez kapsamında temel çapraz geçerlik yöntemleri kısaca tanıtılacak ve kullanılan yöntem detaylandırılacaktır.

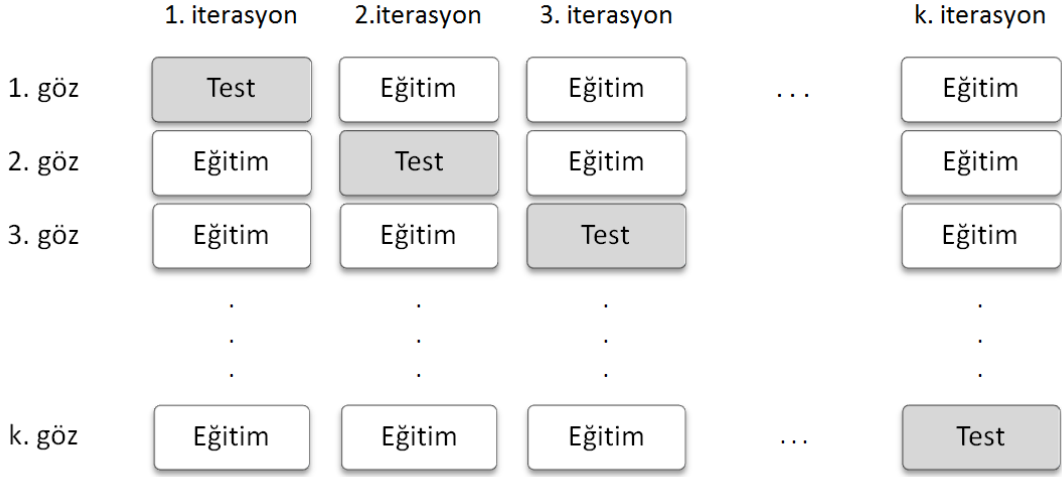
İkiye bölme (holdout) yöntemi: En basit çapraz geçerlik yöntemidir [78]. Veri eğitim ve test olmak üzere iki kısma ayrılır, test genellikle eğitim veri setinden daha küçük olacak şekilde seçilir. Eğitim veri seti ile model belirlenir, daha önce kullanılmamış olan test veri seti ile modelin öngörü performansı değerlendirilir. Verinin bölünme biçimi Şekil 4.2'da görselleştirilmiştir. Büyük veri setleri için kullanışlı olan yöntem, iteratif olmayışı sebebiyle dezavantaj yaratmaktadır. Tek bir eğitim - test veri seti kullanıldığından bölünme önem arz eder. Farklı bölünmelerde farklı sonuçlar elde edileceğinden varyans açısından kullanışlı bir yöntem değildir.



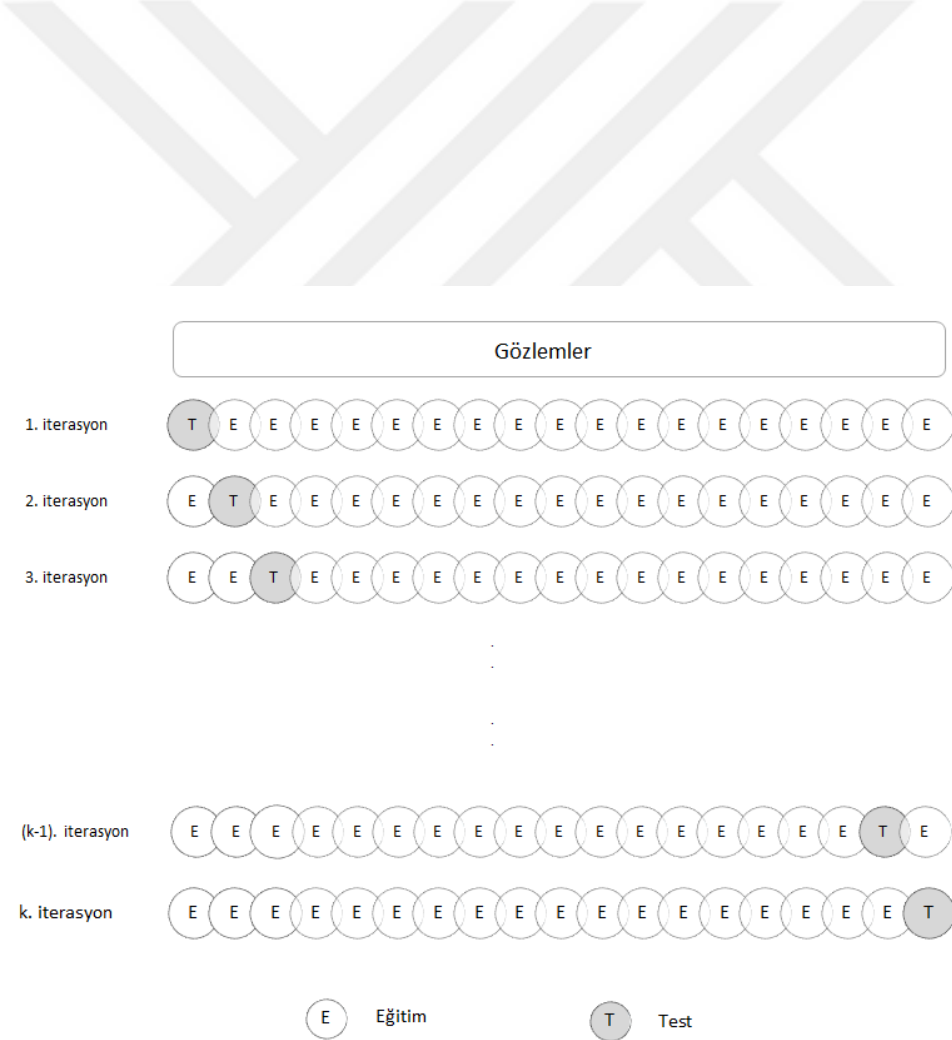
Şekil 4.2 İkiye bölme yöntemi

K gözlü çapraz geçerlik yöntemi (K-fold cv): Eğitim ve test kümesindeki bölünme problemini çözmek üzere önerilen yöntem, veriyi k farklı, eşit gözlem içeren parçaya bölerek her iterasyonda bir parçayı test seti olarak seçer, geri kalan veriyi eğitim aşamasında kullanır. Yapının görsel hali Şekil 4.3 ile açıklanmıştır. Elde edilen hataların ortalaması alınarak modelin öngörü performansı değerlendirilir. $k = 1$ olması halinde yöntem 'ikiye bölme' halini alır.

Birini dışarıda bırakma çapraz geçerlik yöntemi (Leave one out cv) (LOOCV): En bilinen çapraz geçerlik yöntemlerinden biri olan LOOCV, yalnızca 1 gözlemi test için ayırır. Gözlem sayısı kadar iterasyon gerçekleştirilir, ve hataların ortalaması hesaplanır. Eşitlik 4.4'da her bir yuvarlak bir gözlemi temsil etmektedir.



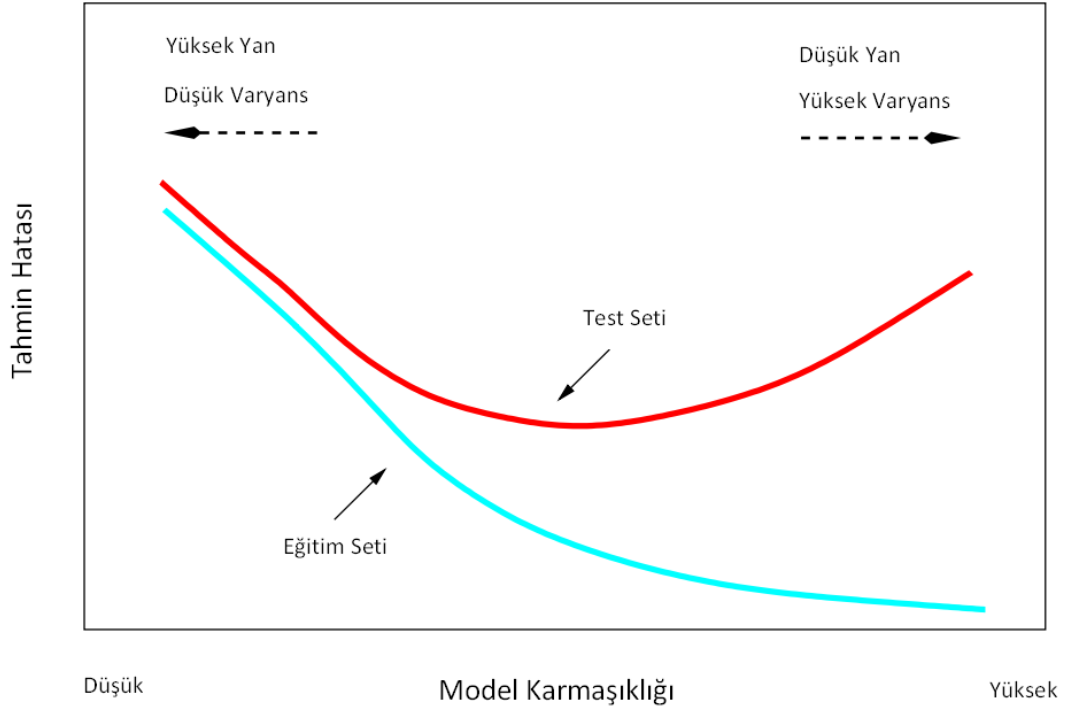
Şekil 4.3 K gözlü çapraz geçerlik yöntemi



Şekil 4.4 Birini dışarıda bırakma çapraz geçerlik yöntemi

Çapraz geçerlik yöntemleri model performansına ek olarak optimum parametre değerinin hesaplanması noktasında da kullanılabilir.

Model belirlenmesi noktasında istenen, modelin hem eldeki veri için iyi performans sergilemesi hem de bu sonuçların yeni veriler için de genellenebilir olmasıdır. Bu açıdan yanlılık-varyans dengesi önemli bir kriterdir. Şekil 4.5’de bu denge görselleştirilmiştir. Eğitim ve test hatası birlikte değerlendirilerek aşırı uyum (overfitting) gibi problemlerin gözden kaçması engellenebilir.



Şekil 4.5 Eğitim ve test seti açısından varyans-yan dengesi

Çapraz geçerlik yöntemleri gözlemlerin birbirinden bağımsız olduğunu varsayar, bu nedenle seçilen eğitim-test gruplarının sıralamasının bir önemi yoktur. Söz konusu zaman serileri olduğunda gözlemlerin birbirleriyle olan ilişkileri nedeniyle çapraz geçerlik yöntemleri doğrudan uygulanamamaktadır. Gerçek dünya uygulamalarında, gelecekteki gözlemleri tahmin etmek için geçmiş gözlemler kullanılır. Zaman serilerindeki mevcut olan kronoloji düşünülüğünde, çapraz geçerlik algoritmasındaki rassallığın kronolojiyi bozacağı açıktır. Bu nedenle zaman serilerinde kullanılmak üzere bu zaman bağımlılığını dikkate alan geçerlik yöntemleri önerilmiştir.

4.2.1 Zaman Serileri için Çapraz Geçerlik Yöntemi

Zaman serileri kronolojik yapıda olduğundan eğitim-test veri seti belirlenmesi aşamasında bu kronolojinin korunması gerekmektedir. Eğitim seti, yalnızca test

veri setini oluşturan gözlemden önce meydana gelen gözlemlerden oluşabilir. Yine performans ölçütü test veri setinden elde edilen hataların ortalaması olarak değerlendirilir [79]. Bu açıdan önerilen üç yöntemden kısaca bahsedilecektir.

Eğitim-test bölme yöntemi: İkiye bölme yönteminin zaman serilerine uyarlanmış halidir. Veri eğitim ve test olarak ikiye bölünür. Verinin büyüklüğüne bağlı olarak 50-50, 70-30 veya 90-10 olarak seçilebilir. Burada dikkat edilecek nokta ikinci kısmın test veri seti olarak tanımlanması gerekliliğidir. Serinin zamana göre sıralı olduğu düşünüldüğünde ilk 50 gözlem eğitim için kullanıldığında ikinci 50 gözlem test için kullanılacaktır. Tek bir model eğitilip test edildiğinden büyük veriler için uygun bir seçenektir.

Çoklu eğitim-test bölme yöntemi: Birden fazla model kurarak uygulanan bir yöntemdir. Veri yine eğitim test olarak bölünür burada birden fazla model kurulması işlem zamanını arttırsa da daha gerçekçi modeller elde edilmesini sağlamaktadır. Test veri seti büyüklüğünün tüm modeller için eşit seçilmesi gerekir, bu sayede tutarlı ve karşılaştırılabilir performans değerleri elde edilir. Verinin 3 modelle inceleneceği 2820 gözlemden oluşan bir örnek için


1. bölme : 705 eğitim, 705 test
2. bölme : 1410 eğitim, 705 test
3. bölme : 2115 eğitim, 705 test

olarak tasarlanabilir. Daha sonra test veri setlerinden elde edilen performans değerlerinin ortalaması alınarak nihai performans elde edilir.

İleri doğru geçerlik (walk forward validation, rolling forecast origin (RFO)) yöntemi: Zaman serileri için en çok tercih edilen yöntemdir. Modelin eğitilmesi için gerekli eğitim ve test gözlem sayısına karar verilir. Her model için sistem bir adım ileri kaydırılarak süreç tekrarlanır. Belirlenen kritere bağlı olarak (RMSE, MAPE vb.) elde edilen değerlerin ortalaması alınarak sonuç yorumlanır.

İleri doğru geçerlik (RFO) yönteminin bir gözlem kaydırma ile oluşturulmuş hali Şekil 4.6 ile görselleştirilmiştir. Ancak RFO yöntemi bir gözlem kaydırma ile sınırlı değildir. İlgilenilen probleme bağlı olarak birden fazla kaydırma ile işlem gerçekleştirilebilir.

Tez kapsamında liu tipi regresyon modelinde k ve d seçimi için ızgara arama ve RFO yöntemleri bir arada kullanılmıştır.



Şekil 4.6 İleri doğru geçerlik yöntemi [79]

4.3 Tekrarlı Izgara Arama İleri Doğru Geçerlik Yöntemi


Dudoit ve van der Laan [67] çalışması, hiperparametre seçiminin asimptotik yaklaşımını göstermesi nedeniyle yöntemin teorik temeli olarak gösterilmektedir ancak gerçek yaşam verileri asimptotik olmayan bir çalışma ortamı yaratmaktadır. Buna ek olarak verinin farklı bölünmeleri farklı en iyi hiperparametre seçimlerini getirmektedir [68]. Tez kapsamında tüm bu problemlere çözüm niteliğinde, aynı zamanda zaman serileri yapısına uygun olması bakımından tekrarlı ızgara arama RFO yöntemi kullanılmıştır.

Yöntem temelinde, her ızgara noktası için çapraz geçerlik hata miktarı t (tekrar) kez hesaplanır ve hata ortalamaları elde edilir. Minimum RFO hata ortalamasına sahip ızgara noktasına ait hiperparametre ikilisi optimal çözüm olarak seçilir.

Yöntem örnek eşliğinde Şekil 4.7 ve Tablo 4.1 üzerinden detaylı olarak açıklanmıştır.

Şekil 4.7’de toplam 478 gözlemden oluşan bir zaman serisi incelenmiştir, eğitim için başlangıç gözlem sayısı 36 ve test gözlem sayısı 12 olarak belirlenmiştir. Zaman serisi olması bakımından test veri seti daima eğitim veri setinin ardından gözlenen gözlemlerdir. Verilen örnek için RFO yöntemi kullanılarak 431 liu tipi regresyon modeli değerlendirilmiştir. Performans metriği olarak RMSE kullanılmıştır.

Görselin anlaşılır olması bakımından k ve d hiperparametreleri için üçer noktanın



Şekil 4.7 Örnek1: İleri doğru geçerlik yöntemi

dolayısıyla 9 ızgara noktasının denendiği bir örnek Tablo 4.1 de verilmiştir. Her ızgara noktası için 431 tekrar uygulanarak RMSE değerleri hesaplanmış, ortalama RMSE değerleri üzerinden minimum değer optimal nokta olarak seçilmiştir.

Tablo 4.1 Izgara arama ileri doğru geçerlik yöntemi

		Yanılılık Parametreleri								
Eğitim	Test	(k_1, d_1)	(k_1, d_2)	(k_1, d_3)	(k_2, d_1)	(k_2, d_2)	(k_2, d_3)	(k_3, d_1)	(k_3, d_2)	(k_3, d_3)
36	12	rmse1 ₁₁	rmse1 ₁₂	rmse1 ₁₃	rmse1 ₂₁	rmse1 ₂₂	rmse1 ₂₃	rmse1 ₃₁	rmse1 ₃₂	rmse1 ₃₃
37	12	rmse2 ₁₁	rmse2 ₁₂	rmse2 ₁₃	rmse2 ₂₁	rmse2 ₂₂	rmse2 ₂₃	rmse2 ₃₁	rmse2 ₃₂	rmse2 ₃₃
38	12	rmse3 ₁₁	rmse3 ₁₂	rmse3 ₁₃	rmse3 ₂₁	rmse3 ₂₂	rmse3 ₂₃	rmse3 ₃₁	rmse3 ₃₂	rmse3 ₃₃
39	12	rmse4 ₁₁	rmse4 ₁₂	rmse4 ₁₃	rmse4 ₂₁	rmse4 ₂₂	rmse4 ₂₃	rmse4 ₃₁	rmse4 ₃₂	rmse4 ₃₃
40	12	rmse5 ₁₁	rmse5 ₁₂	rmse5 ₁₃	rmse5 ₂₁	rmse5 ₂₂	rmse5 ₂₃	rmse5 ₃₁	rmse5 ₃₂	rmse5 ₃₃
.
.
.
466	12	rmse431 ₁₁	rmse431 ₁₂	rmse431 ₁₃	rmse431 ₂₁	rmse431 ₂₂	rmse431 ₂₃	rmse431 ₃₁	rmse431 ₃₂	rmse431 ₃₃
Ortalama		rmse ₁₁	rmse ₁₂	rmse ₁₃	rmse ₂₁	rmse ₂₂	rmse ₂₃	rmse ₃₁	rmse ₃₂	rmse ₃₃

Sınıflandırma ve regresyon modelleri üzerine tekrarlı ızgara arama çapraz geçerlik yöntemi, çeşitleri ve detaylarını içeren Krstajic vd. [68] çalışması incelenebilir.

Optimizasyon, bir çok alanda ihtiyaç duyulan bir çözüm yöntemidir. Optimumu bulmak adına fonksiyonun minimize veya maksimize edilmesi noktasında kullanılabilir tek bir algoritma yoktur. Bir problem için en iyi sonucu veren algoritma diğeri için iyi sonuç vermeyebilir. Bu açıdan probleme uygun algoritmanın seçilmesi önemli bir noktadır. Ayrıca algoritmanın çalışma süresi, yapısı ve uygulanabilirliği de önemli kriterlerdendir.

Karmaşık davranışların açıklanabilmesi için daha basit yapıları parçacıkların kullanılması fikri ilk olarak bilgisayar animasyonlarında doğa olaylarının gerçekleştirilmesi amacıyla kullanılmıştır [80].

Reeves 1983 yılında, stokastik süreçlerin parçacık sistemindeki parçacıkların oluşturulması ve kontrol edilmesinde kullanılabilirliğini ve bu sayede bulanık objelerin (ateş, bulut ve su gibi) oluşturulmasında kullanılabilirliğini göstermiştir [81]. Uzay Yolu II: Khan'ın Gazabı [82] filminde bu uygulama gerçekleştirilmiştir.

Bu parçacık sistemi yapısında, stokastik olarak hareket eden noktalar üretilir ve bunlara daha önceden belirlenen başlangıç değerleri atanır. Ek olarak her bir noktaya bir başlangıç hız vektörü atanır ve bu hız vektörleri iteratif olarak bazı faktörlere göre ayarlanır. Mevcut parçacık hız vektörüne bağlı olarak sınırlı bir alan içerisinde hareket ettirilir.

Bazı animasyonlardaki daha yüksek seviyeli grup davranışlarını açıklama ihtiyacı sonrası Reynolds [83] bu konuya yeni bir bakış açısı getirmiştir.

Reynolds 1987 yılında, Reeves'in önerdiği yapıya oryantasyon ve parçacıklar arası iletişim bilgisini dahil ederek sürü bilincinin sisteme eklenmesini sağlamıştır. Bu bakımdan parçacıklar çarpışmaktan kaçınmalı, birbirlerinin hız vektörlerine uyum sağlayarak aralarındaki mesafeyi azaltmaya çalışmalıdır. Bu yaklaşım parçacıklarının zekasını arttırmış ve bireysel yörünge ihtiyacını gereksiz kılmıştır.

Kennedy ve Eberhart 1995 yılında, hem Reynolds'un yöntemini ileriye taşımak hem de 1990 yılında alternatif bir sürü yaklaşımı öneren Heppner ve Grenander'in [84] basit hedefini daha gerçekçi bir hedef olan yiyecek arama hedefiyle değiştirmek amacıyla kuş ve balık sürülerinden etkilenecek parçacık sürü optimizasyonu (PSO) algoritmasını ortaya atmıştır [85].

Sezgisel bir yöntem olan PSO, basit yapısı, uygulama kolaylığı, türev bilgisine ihtiyaç duymaması ve hafıza özelliği sayesinde tercih edilen optimizasyon yöntemlerinden biri haline gelmiştir.

Sezgisel yöntemler en iyi çözümü garanti etmemekle birlikte hızlı ve pratik olmaları sayesinde optimuma en yakın çözümü elde etme imkanı sağlarlar. Özetle, mevcut sürede elde edilebilecek en iyi çözümü belirleyebilmelerine rağmen en iyi çözümü garanti etmezler.

PSO'da her bir parçacık aday bir çözümü temsil etmektedir. Sürü, popülasyonu, parçacıklar ise popülasyondaki bireyleri ifade etmektedir. Her bir parçacık, kendi mevcut konumu ve komşu parçacıkların konumundan faydalanarak yeni konumunu belirlemekte ve bu akış içerisinde optimum sonuca gidilmektedir. Burada hız vektörü bahsi geçen bilgileri içermekte ve akışı yönlendirmektedir.

D boyutlu bir arama uzayında $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, i 'nci parçacığı temsil etmektedir. $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$, i 'nci parçacık için kaydedilmiş önceki en iyi pozisyon temsil eder ve p_{best} olarak adlandırılır. Popülasyondaki tüm parçacıklar için en iyi pozisyon ise g_{best} olarak tanımlanır. Pozisyonun değişme oranı (hız, velocity), i 'nci parçacık için $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ile gösterilir. Bu oran g_{best} ve p_{best} değerleri göz önüne alınarak (5.1) ile güncellenir ve elde edilen hız üzerinden yeni konum bilgisi (5.2) ile hesaplanır [86].

$$v_{id} = v_{id} + c_1 * rand_1 * (p_{id} - x_{id}) + c_2 * rand_2 * (p_{gd} - x_{id}) \quad (5.1)$$

$$x_{id} = x_{id} + v_{id} \quad (5.2)$$

burada boyut $1 < d < D$ olmak üzere c_1 ve c_2 , parçacıkların arama uzayındaki dağılımlarını etkileyen pozitif sabitler olup sırasıyla bilişsel ve sosyal parametreler olarak adlandırılır. Bilişsel kısım parçacığın bireysel bilgisini taşıırken sosyal kısım parçacıklar arası işbirliğini sağlar [87]. p_{id} yerel en iyi pozisyonu, p_{gd} ise global en iyi pozisyonu temsil etmektedir. $rand_1$ ve $rand_2$, $[0, 1]$ aralığında tekdüze dağılımdan

üretmiş iki rasgele sayıdır. Yönteme stokastik özelliği kazandıran bu rasgele sayıların varlığıdır.

Shi ve Eberhart çalışmasında [88] mevcut yonteme eylemsizlik ağırlığı adı verilen w parametresini dahil eder. Eylemsizlik ağırlığı global ve yerel arama arasındaki dengeyi sağlayan pozitif bir katsayı olarak tanımlanır. Önceki hızın sisteme katkısını ayarlayarak parçacığın momentumunu kontrol eder. Hız ve konum güncellemeleri (5.3) ve (5.4) ile gösterilmektedir.


$$v_{id} = w * v_{id} + c_1 * rand_1 * (p_{id} - x_{id}) + c_2 * rand_2 * (p_{gd} - x_{id}) \quad (5.3)$$

$$x_{id} = x_{id} + v_{id} \quad (5.4)$$

Shi ve Eberhart, w 'nun $[0.9, 1.2]$ aralığında seçildiği taktirde ortalamada en az iterasyon sayısı ile en iyi global sonuca ulaşıldığını göstermiştir [88].

PSO algoritması akış diyagramı Şekil 5.1 ile gösterilmiştir.

PSO algoritmasının geliştirilmesi (çözüm kalitesi, yakınsama hızı) adına bir çok çalışma gerçekleştirilmiş olup konu üzerine çalışılmaya devam edilmektedir. Tez kapsamında [88] versiyonu kullanıldığından diğer yöntemlerin detaylarına girilmemiştir.



Şekil 5.1 PSO akış diyagramı [89]

6 ÖNERİLEN YÖNTEM

Bulanık çıkarım sistemleri, sözel bilgiyi kullanabilmeleri, veriye dayalı (data driven) yaklaşımlar olması ve uzman bilgisini kurallar vasıtasıyla sisteme dahil edebilmeleri açısından avantajlı sistemlerdir. Ancak uzman bilgisinin sistemde subjektif etki yaratma ihtimali ve uzmanın bulanık mantık yapısına hakim olması gerekliliği daha uygulanabilir bir yöntem arayışına neden olmuştur. Bu dezavantajların giderilmesi noktasında, her bir kurala karşılık bir bulanık fonksiyon tanımlayan sistem yani T1FF önerilmiştir [13]. Sınıflama ve regresyon problemleri için çözüm üretebilen yöntemin regresyon kısmı, önerilen yöntemin temelini oluşturmaktadır.

Aladağ vd. 2014 yılında T1FF yaklaşımını öngörü problemine uyarlamış [19] ve diğer yöntemlere üstünlüğünü göstermişlerdir. Yöntem, girdi olarak zaman serisinin gecikmeli değişkenlerini kullanmıştır.

T1FF yapısal olarak dinamik bir regresyon modelidir. Her bir küme için elde edilen regresyon modelinin, ilgili üyelik değerlerine bağlı olarak her bir öğrenme örneğini ağırlıklandırması, ana modeldeki regresyon katsayılarının değişken olmasına (gözlemden gözleme değişmesine) neden olmaktadır. Bu değişkenlik ise regresyon modeline dinamik olma özelliği kazandırmaktadır.

Dinamik regresyon modelinin matematiksel gösterimi, basitlik açısından iki küme için gerçekleştirilecektir. (6.1) ve (6.2) sırasıyla birinci ve ikinci kümelerin regresyon modellerini temsil etmektedir. Burada birinci küme için $\hat{X}_t^{(1)}$, bağımlı değişkenin tahminini, X_{t-1} , bağımsız değişkeni, $\beta_0^{(1)}$ ve $\beta_1^{(1)}$ ise regresyon katsayılarını göstermektedir. Görüleceği üzere bağımsız değişken zaman serisinin bir gecikmeli hali olarak alınmıştır. İkinci küme için de tanımlamalar benzer şekildedir.

$$\hat{X}_t^{(1)} = \beta_0^{(1)} + \beta_1^{(1)}X_{t-1} \quad (6.1)$$

$$\hat{X}_t^{(2)} = \beta_0^{(2)} + \beta_1^{(2)}X_{t-1} \quad (6.2)$$

Her bir kümeden gelen öngörü bilgisi, ana modelin öngörüsünü oluşturmaktadır. (6.3), nihai regresyon modelini oluşturmaktadır. Burada w_{1t} ve w_{2t} sırasıyla birinci ve ikinci kümelerin öngörü ağırlıklarını temsil etmektedir.

$$\hat{X}_t = w_{1t}\hat{X}_t^{(1)} + w_{2t}\hat{X}_t^{(2)} \quad (6.3)$$

Her iki kümenin regresyon modelini ana modelde yerine koyduğumuzda (6.4) elde edilmektedir.

$$\hat{X}_t = w_{1t}(\beta_0^{(1)} + \beta_1^{(1)}X_{t-1}) + w_{2t}(\beta_0^{(2)} + \beta_1^{(2)}X_{t-1}) \quad (6.4)$$

Eşitliğin regresyon katsayıları açısından düzenlenmesi sonucunda (6.5) ve nihai model (6.6) elde edilmektedir.

$$\hat{X}_t = (w_{1t}\beta_0^{(1)} + w_{2t}\beta_0^{(2)}) + (\beta_1^{(1)}w_{1t} + \beta_1^{(2)}w_{2t})X_{t-1} \quad (6.5)$$

$$\hat{X}_t = \beta_{0t} + \beta_{1t}X_{t-1} \quad (6.6)$$

Baş vd. ise 2018 yılında yayınladığı çalışmada [32], öngörü problemi için geliştirilen bulanık fonksiyonlar yaklaşımında çoklu iç ilişki sorununu incelemiş ve ridge regresyon modeli kullanıldığında parametre tahminlerinin varyansındaki küçülmenin etkisine bağlı olarak öngörü performansının arttığını göstermiştir.

Öngörü performansının iyileştirilmesi amacıyla gerçekleştirilen bu çalışmaların devamı olarak planlanan tez çerçevesinde, sezgisel bulanık kümelerin katkısı ve liu tipi tahmin edicinin çoklu iç ilişki problemine etkisi incelenmiştir.

Genelinde T1FF yöntemine alternatif, özelinde ise öngörü problemi için geliştirilen bulanık fonksiyonlar yaklaşımına sezgisel bakış açısını dahil eden bir sistem düşünülmüştür. [33].

Çalışmada klasik bulanık kümeler yerine sezgisel bulanık kümelerin tercih edilme nedeni, üye olma bilgisine ek olarak üye olmama bilgisinin de sisteme dahil

edilebilmesi ile tereddüt derecesinin kullanılabilmesidir.

Tez kapsamında ilk olarak, sezgisel bulanık ridge regresyon fonksiyonları yaklaşımı (T1IFFRR) önerilmiş, çoklu iç ilişkinin ileri seviye incelenmesi adına Liu tipi tahmin ediciye dayalı sezgisel bulanık regresyon fonksiyonları yaklaşımı (T1IFFLR) önerilmiştir.

Çapraz Geçerlik: Yöntemlerin öngörü performansının değerlendirilebilmesi için veri, eğitim ve test veri seti olmak üzere iki kısma ayrılarak kullanılmıştır. Model, eğitim veri seti ile kurulmuş ve öngörüler test seti üzerinden elde edilmiştir. Gözlemler zamana bağlı olduğundan test veri seti zaman serisinin son kısmından seçilerek kronolojik düzen korunmuştur.

Standardizasyon: Girdi matrisinde, üyelik değerleri ve gecikmeli değişkenler gibi ölçek olarak birbirinden oldukça farklı değişkenler bulunmaktadır . Bu açıdan veriler analize başlamadan önce (6.7) ile z skoru üzerinden standartlaştırılmıştır.

$$z = \frac{x - \mu_e}{\sigma_e} \quad (6.7)$$

burada μ_e eğitim veri seti için ortalama değeri, σ_e ise eğitim veri seti için standart sapmayı temsil etmektedir.

Burada önemli nokta, standardizasyonun eğitim veri seti parametreleri ile gerçekleştirilmesi gerekliliğidir [90], [91]. Standardizasyonun tüm veri seti üzerinden gerçekleştirilmesi test veri seti (gözlenmemiş veri seti) bilgisinin de kullanılmasına dolayısıyla sonuçta yapay pozitif bir etkiye neden olacaktır.

Karşılaştırma Kriteri: Yöntemler hata kareler ortalamasının karekökü (RMSE) ve ortalama mutlak yüzde hata (MAPE) kriterleri üzerinden değerlendirilmiştir. Karşılaştırma kriterleri sırasıyla (6.8) ve (6.9) ile gösterilmiştir.

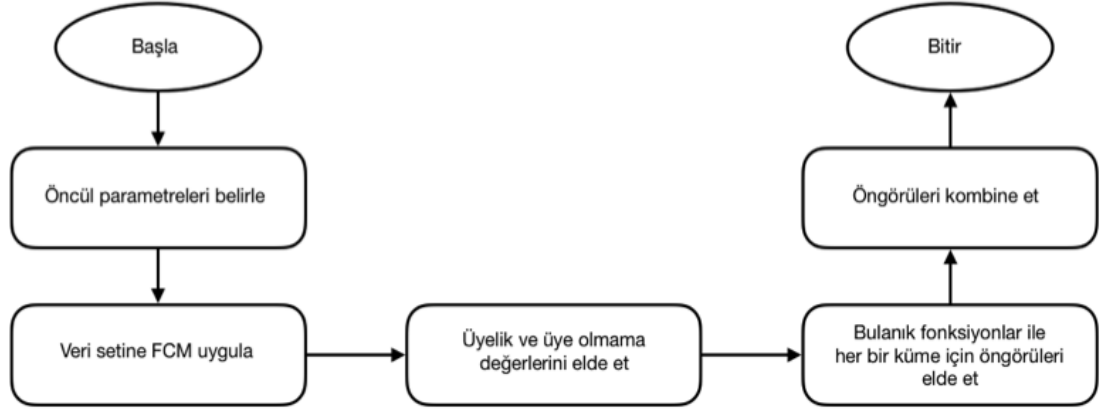
$$RMSE = \sqrt{\frac{1}{ntest} \sum_{j=n+1}^{n+ntest} (Y_{t_j} - \widehat{Y}_{t_j})^2} \quad (6.8)$$

$$MAPE = \sqrt{\frac{1}{ntest} \sum_{j=n+1}^{n+ntest} \frac{|Y_{t_j} - \widehat{Y}_{t_j}|}{Y_{t_j}}} \times 100 \quad (6.9)$$

burada n , eğitim veri seti gözlem sayısını ve $ntest$, test veri seti gözlem sayısını

göstermektedir. $\widehat{Y}t_j$ ise test veri setinde yer alan j 'nci gözlem için elde edilmiş olan öngörüü temsil etmektedir. Hata kriterleri değerlendirilirken eğitim veri setindeki minimum hataya karşılık gelen test hata değeri kullanılmıştır.

Önerilen yöntemler için akış diyagramı Şekil 6.1 ile gösterilmiştir.



Şekil 6.1 Önerilen yöntem akış diyagramı

6.1 Sezgisel Ridge Regresyon Bulanık Fonksiyonlar Yaklaşımı

Denge hali yaşamın tamamında gözlenebilmektedir. Kazanmak için çalışmak, almak için vermek dolayısıyla pozitif etkilerden yararlanmak için de bir takım negatif etkileri göze almak gerekmektedir. Öngörü problemi için T1FF yaklaşımı girdi olarak gecikmeli değişkenler ve üyelik fonksiyonlarını kullanması bakımından kullanışlı olmakla birlikte gecikmeli değişkenlerin ve üyeliklerin doğrusal olmayan dönüşümlerinin birbirleri ile ilişkisi nedeniyle çoklu iç ilişki problemini gündeme getirmektedir. Bu açıdan LSE yerine yanlı bir tahmin edici olan RRE kullanılması anlamlıdır.

Belirsizliğin azaltılması, öngörü açısından pozitif etki yaratacağından klasik bulanık kümeler yerine sezgisel bulanık kümeler tercih edilmiştir. Ancak denge prensibi burada da kendini göstermiştir. Girdi matrisinde yer alan üyelik değerleri ve doğrusal olmayan dönüşümlerine ek olarak üye olmama değerleri ve doğrusal olmayan dönüşümlerinin eklenmesi sonucunda ilişkili değişkenler olduğundan, çoklu iç ilişki problemi tekrar gündeme gelmektedir.

Sezgisel bulanık kümeler ve RRE kullanımı ile artan iç ilişki dengelenmiş ve önerilen yöntem Baş vd. çalışmasından [32] daha iyi performans sergilemiştir.

Yöntemde yanlılık parametresi k 'nın seçimi Hoerl, Kennard ve Baldwin'in [60] yöntemi ile gerçekleştirilmiş ve (6.10)'da gösterilmiştir.

$$k = \frac{p\hat{\sigma}^2}{\hat{\beta}'\hat{\beta}} \quad (6.10)$$

burada p , bağımsız değişken sayısı, $\hat{\sigma}^2$ ve $\hat{\beta}$, LSE tahmin değerleridir.

T1IFFRR Algoritma

Adım 1 Öncül parametrelerin belirlenmesi.

- Sezgisel bulanık küme sayısı (cn)
- Sistem girdi (gecikmeli değişken) sayısı (p)
- Tereddüt derecesi (π), alfa-kesme ($\alpha - kesme$)
- Test veri seti büyüklüğü (n_{test})

Adım 2 Girdiler ve çıktıdan oluşan girdi matrisi (6.11) oluşturulur ve matris satırları sezgisel bulanık c-ortalamar kümeleme yöntemi ile gruplanır.

$$Z = \begin{bmatrix} X_{t-1} & X_{t-2} & \dots & X_{t-p} & X_t \end{bmatrix} \quad (6.11)$$

Sezgisel üyelik değerleri ($\mu_A(x)$) ve üye olmama değerleri ($v_A(x)$) sezgisel bulanık c-ortalamar yöntemi ile elde edilir. Sezgisel üyelik ve üye olmama değerleri $\alpha - kesme$ ile doğrulanır. Eğer $\mu_A(x) < \alpha - kesme$ ise $\mu_A(x) = 0$. Benzer şekilde, eğer $v_A(x) < \alpha - kesme$ ise $v_A(x) = 0$. $\alpha - kesme$ uygulandıktan sonra doğrulanmış üyelik ve üye olmama değerleri u_{ij} ve μ_{ij} olarak isimlendirilir. u_{ij} ve μ_{ij} , sırasıyla i^{nci} küme and j^{nci} eğitim seti için doğrulanmış sezgisel üyelik ve üye olmama değerlerini temsil eder.

Adım 3 Her bir sezgisel bulanık küme için , sezgisel bulanık regresyon fonksiyonu ridge regresyon ile elde edilir. x_1, x_2, \dots, x_n zaman serileri olup eğitim veri setini temsil

eder.

$$X^{(i)} = \begin{bmatrix} 1 & u_{i1} & u_{i1}^2 & \exp(u_{i1}) & \mu_{i1} & \mu_{i1}^2 & \exp(\mu_{i1}) & x_1 & x_2 & \dots & x_p \\ 1 & u_{i2} & u_{i2}^2 & \exp(u_{i2}) & \mu_{i2} & \mu_{i2}^2 & \exp(\mu_{i2}) & x_2 & x_3 & \dots & x_{p+1} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ 1 & u_{in} & u_{in}^2 & \exp(u_{in}) & \mu_{in} & \mu_{in}^2 & \exp(\mu_{in}) & x_{n-p} & x_{n-p+1} & \dots & x_{n-1} \end{bmatrix} \quad (6.12)$$

$$Y^{(i)'} = \begin{bmatrix} x_{p+1} & x_{p+2} & \dots & x_n \end{bmatrix} \quad (6.13)$$

$$\hat{\beta}_k = (X^{(i)'}X^{(i)} + kI)^{-1} (X^{(i)'}Y^{(i)}) \quad (6.14)$$

burada $k > 0$ 'dır.

$$\hat{Y}^{(i)} = X^{(i)}\hat{\beta}^{(i)} \quad (6.15)$$

Adım 4 Eğitim seti öngörülere üyelik ve üye olmama değerleri için sırasıyla (6.16) ve (6.17) ile hesaplanır.

$$\hat{Y}_j^m = \frac{\sum_{i=1}^c u_{ij} \hat{Y}_j^{(i)}}{\sum_{i=1}^c u_{ij}}; j = 1, 2, \dots, n \quad (6.16)$$

$$\hat{Y}_j^{nm} = \frac{\sum_{i=1}^c \mu_{ij} \hat{Y}_j^{(i)}}{\sum_{i=1}^c \mu_{ij}}; j = 1, 2, \dots, n \quad (6.17)$$

burada $Y_j^{(i)}$, j^{nci} gözlem ve i^{nci} sezgisel bulanık regresyon fonksiyonunun öngörüsünü temsil etmektedir. \hat{Y}_j^m her bir sezgisel bulanık küme için elde edilen öngörülere sezgisel üyelik değerleri ile ağırlıklandırılarak üyelik öngörüsünü elde eder. Benzer şekilde, \hat{Y}_j^{nm} üye olmama değerlerini ağırlık olarak kullanır.

Adım 5 Eğitim seti için nihai öngörü (6.18) ile elde edilir.

$$\hat{Y}_j^{IFF} = (1 - \theta) \hat{Y}_j^m + \theta \hat{Y}_j^{nm} \quad (6.18)$$

burada θ ağırlık parametresi olup parçacık sürü optimizasyonu ile elde edilmektedir. Optimizasyon sürecinde RMSE amaç fonksiyonu olarak kullanılmıştır.

Adım 6 Test seti için öngürler elde edilir. Girdi matrisi ($Xt^{(i)}$) her bir sezgisel bulanık küme için test seti (6.19) ile oluşturulur. Test seti öngörülere ($\widehat{Yt}^{(i)}$) her bir sezgisel bulanık regresyon fonksiyonu için (6.20) elde edilir.

$$Xt^{(i)} = \begin{bmatrix} 1 & u_{i,n+1} & u_{i,n+1}^2 & e^{\mu_{i,n+1}} & \mu_{i,n+1} & \mu_{i,n+1}^2 & e^{\mu_{i,n+1}} & x_{n-p+1} & x_{n-p+2} & \dots & x_n \\ 1 & u_{i,n+2} & u_{i,n+2}^2 & e^{\mu_{i,n+2}} & \mu_{i,n+2} & \mu_{i,n+2}^2 & e^{\mu_{i,n+2}} & x_{n-p+2} & x_{n-p+3} & \dots & x_{n+1} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ 1 & u_{i,n+ntest} & u_{i,n+ntest}^2 & e^{\mu_{i,n+ntest}} & \mu_{i,n+ntest} & \mu_{i,n+ntest}^2 & e^{\mu_{i,n+ntest}} & x_{n-p+ntest} & x_{n-p+ntest+1} & \dots & x_{n+ntest-1} \end{bmatrix} \quad (6.19)$$

$$\widehat{Yt}^{(i)} = Xt^{(i)}\widehat{\beta}^{(i)} \quad (6.20)$$

Her bir küme için elde edilen üyelik ve üye olmama öngörülere (6.21) ve (6.22) ile ağırlıklandırılır.

$$\widehat{Yt}_j^m = \frac{\sum_{i=1}^c u_{ij} \widehat{Yt}_j^{(i)}}{\sum_{i=1}^c u_{ij}}; \quad j = n+1, n+2, \dots, n+ntest \quad (6.21)$$

$$\widehat{Yt}_j^{nm} = \frac{\sum_{i=1}^c \mu_{ij} \widehat{Yt}_j^{(i)}}{\sum_{i=1}^c \mu_{ij}} \quad (6.22)$$

Test seti için nihai öngörü (6.23) ile elde edilir.

$$\widehat{Yt}_j^{IFF} = (1 - \hat{\theta}) \widehat{Yt}_j^m + \hat{\theta} \widehat{Yt}_j^{nm} \quad (6.23)$$

Test seti için üyelik (u_{ij}) ve üye olmama (μ_{ij}) değerleri, Adım 2'de elde edilen en iyi küme merkezleri kullanılarak elde edilmiştir.

Yöntemin öngörü performansı zaman serileri uygulamaları ile gösterilmiştir. Önerilen yöntem, öngörü performansında bir çok öngörü tekniğine kıyasla dikkate değer iyileştirme sağlamasına rağmen ridge regresyon çoklu iç ilişki problemini tam olarak çözümleyememiştir. Bu nedenle tezin devamında ridge regresyon yerine liu tipi regresyon ile incelemeye gidilmiştir.

6.2 Sezgisel Liu Tipi Regresyon Bulanık Fonksiyonlar Yaklaşımı

Öngörü performansının iyileştirilmesi amacıyla, Kızılaslan vd. çalışmasının [33] devamı olarak sezgisel Liu tipi regresyon bulanık fonksiyonlar (T1IFFLR) yöntemi

önerilmiştir. Yöntemin literatüre katkısı, RRE ile tamamen çözümlenemeyen çoklu iç ilişki probleminin LTE ile incelenmesidir.

Yöntem, Liu çalışmasında [64] önerilen yanlılık parametreleri ile uygulanmış ancak başarılı sonuç elde edilememiştir. Sonrasında yanlılık parametreleri seçimi için ızgara arama ve ileri doğru geçerlik yöntemi uygulanarak performans iyileştirilmiştir.

Yanlı tahmin yöntemlerinde kritik nokta yanlılık parametrelerinin seçimidir. T1FFLR yönteminde yanlılık parametreleri, tekrarlı ızgara arama RFO yöntemi ile elde edilmiştir.

Tekrarlı Izgara Arama RFO Yöntemi Algoritma

Adım 1 k ve d için arama uzayı, eğitim ve test gözlem sayısı belirle

Adım 2 Arama uzayındaki her (k, d) ikilisi için RFO yöntemini kullanarak eğitim veri seti ile Liu tipi bulanık fonksiyonları oluştur.

Adım 3 Liu tipi bulanık fonksiyonlar yardımıyla her bir kombinasyon için test seti RMSE değeri hesapla.

Adım 4 Adım 2 ve Adım 3'ü t kez tekrarla.

Adım 5 Her (k, d) ikilisi için ortalama RMSE değeri hesapla

Adım 6 Ortalama RMSE'ler içinde minimum olan model için kullanılan (k, d) 'yi optimum değerler olarak seç.

T1FFLR Algoritması

Adım 1 Öncül parametrelerin belirlenmesi.

- Sezgisel bulanık küme sayısı (cn)
- Sistem girdi (gecikmeli değişken) sayısı (p)
- Tereddüt derecesi (π), alfa-kesme ($\alpha - kesme$)
- Test veri seti büyüklüğü (n_{test})

Adım 2 Girdiler ve çıktudan oluşan girdi matrisi oluşturulur ve matris satırları sezgisel bulanık c-ortalama kümeleme yöntemi ile gruplanır.

$$Z = \begin{bmatrix} X_{t-1} & X_{t-2} & \dots & X_{t-p} & X_t \end{bmatrix} \quad (6.24)$$

Sezgisel üyelik değerleri ($\mu_A(x)$) ve üye olmama değerleri ($\nu_A(x)$) sezgisel bulanık c-ortalama yöntemini ile elde edilir. Sezgisel üyelik ve üye olmama değerleri $\alpha - kesme$ ile doğrulanır. Eğer $\mu_A(x) < \alpha - kesme$ ise $\mu_A(x) = 0$. Benzer şekilde, eğer $\nu_A(x) < \alpha - kesme$ ise $\nu_A(x) = 0$. $\alpha - kesme$ uygulandıktan sonra doğrulanmış üyelik ve üye olmama değerleri u_{ij} ve μ_{ij} olarak isimlendirilir. u_{ij} ve μ_{ij} , sırasıyla i^{nci} küme and j^{nci} eğitim seti için doğrulanmış sezgisel üyelik ve üye olmama değerlerini temsil eder.

Adım 3 Her bir sezgisel bulanık küme için , sezgisel bulanık regresyon fonksiyonu ridge regresyon ile elde edilir. x_1, x_2, \dots, x_n zaman serileri olup eğitim veri setini temsil eder.

$$X^{(i)} = \begin{bmatrix} 1 & u_{i1} & u_{i1}^2 & \exp(u_{i1}) & \mu_{i1} & \mu_{i1}^2 & \exp(\mu_{i1}) & x_1 & x_2 & \dots & x_p \\ 1 & u_{i2} & u_{i2}^2 & \exp(u_{i2}) & \mu_{i2} & \mu_{i2}^2 & \exp(\mu_{i2}) & x_2 & x_3 & \dots & x_{p+1} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ 1 & u_{in} & u_{in}^2 & \exp(u_{in}) & \mu_{in} & \mu_{in}^2 & \exp(\mu_{in}) & x_{n-p} & x_{n-p+1} & \dots & x_{n-1} \end{bmatrix} \quad (6.25)$$

$$Y^{(i)'} = [x_{p+1} \quad x_{p+2} \quad \dots \quad x_n] \quad (6.26)$$

$$\hat{\beta}_{k,d} = (X^{(i)'}X^{(i)} + kI)^{-1} (X^{(i)'}Y^{(i)} - d\hat{\beta}) \quad (6.27)$$

burada $k > 0$, $-\infty < d < \infty$ ve $\hat{\beta}$, β 'nin herhangi bir tahminidir.

$$\hat{Y}^{(i)} = X^{(i)}\hat{\beta}^{(i)} \quad (6.28)$$

Adım 4 Eğitim seti öngörülere üyelik ve üye olmama değerleri için sırasıyla (6.29) ve (6.30) ile hesaplanır.

$$\hat{Y}_j^m = \frac{\sum_{i=1}^c u_{ij} \hat{Y}_j^{(i)}}{\sum_{i=1}^c u_{ij}}; j = 1, 2, \dots, n \quad (6.29)$$

$$\hat{Y}_j^{nm} = \frac{\sum_{i=1}^c \mu_{ij} \hat{Y}_j^{(i)}}{\sum_{i=1}^c \mu_{ij}}; j = 1, 2, \dots, n \quad (6.30)$$

burada $Y_j^{(i)}$, j^{nci} gözlem ve i^{nci} sezgisel bulanık regresyon fonksiyonunun öngörüsünü temsil etmektedir. \hat{Y}_j^m her bir sezgisel bulanık küme için elde edilen

öngörülerini sezgisel üyelik değerleri ile ağırlıklandırarak üyelik öngörüsünü elde eder. Benzer şekilde, \widehat{Y}_j^{nm} üye olmama değerlerini ağırlık olarak kullanır.

Adım 5 Eğitim seti için nihai öngörü (6.31) ile elde edilir.

$$\widehat{Y}_j^{IFF} = (1 - \theta) \widehat{Y}_j^m + \theta \widehat{Y}_j^{nm} \quad (6.31)$$

burada θ ağırlık parametresi olup parçacık sürü optimizasyonu ile elde edilmektedir. Optimizasyon sürecinde RMSE amaç fonksiyonu olarak kullanılmıştır.

Adım 6 Test seti için öngörüler elde edilir. Girdi matrisi ($Xt^{(i)}$) her bir sezgisel bulanık küme için test seti (6.32) ile oluşturulur. Test seti öngörülerini ($\widehat{Y}t^{(i)}$) her bir sezgisel bulanık regresyon fonksiyonu için (6.33) elde edilir.

$$Xt^{(i)} = \begin{bmatrix} 1 & u_{i,n+1} & u_{i,n+1}^2 & e^{\mu_{i,n+1}} & \mu_{i,n+1} & \mu_{i,n+1}^2 & e^{\mu_{i,n+1}} & x_{n-p+1} & x_{n-p+2} & \dots & x_n \\ 1 & u_{i,n+2} & u_{i,n+2}^2 & e^{\mu_{i,n+2}} & \mu_{i,n+2} & \mu_{i,n+2}^2 & e^{\mu_{i,n+2}} & x_{n-p+2} & x_{n-p+3} & \dots & x_{n+1} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \dots & \cdot \\ 1 & u_{i,n+ntest} & u_{i,n+ntest}^2 & e^{\mu_{i,n+ntest}} & \mu_{i,n+ntest} & \mu_{i,n+ntest}^2 & e^{\mu_{i,n+ntest}} & x_{n-p+ntest} & x_{n-p+ntest+1} & \dots & x_{n+ntest-1} \end{bmatrix} \quad (6.32)$$

$$\widehat{Y}t^{(i)} = Xt^{(i)} \widehat{\beta}^{(i)} \quad (6.33)$$

Her bir küme için elde edilen üyelik ve üye olmama öngörülerini (6.34) ve (6.35) ile ağırlıklandırılır.

$$\widehat{Y}t_j^m = \frac{\sum_{i=1}^c u_{ij} \widehat{Y}t_j^{(i)}}{\sum_{i=1}^c u_{ij}}; j = n + 1, n + 2, \dots, n + ntest \quad (6.34)$$

$$\widehat{Y}t_j^{nm} = \frac{\sum_{i=1}^c \mu_{ij} \widehat{Y}t_j^{(i)}}{\sum_{i=1}^c \mu_{ij}} \quad (6.35)$$

Test seti için nihai öngörü (6.36) ile elde edilir.

$$\widehat{Y}t_j^{IFF} = (1 - \theta) \widehat{Y}t_j^m + \theta \widehat{Y}t_j^{nm} \quad (6.36)$$

Test seti için üyelik (u_{ij}) ve üye olmama (μ_{ij}) değerleri, Adım 2'de elde edilen en iyi küme merkezleri kullanılarak elde edilmiştir.

7

UYGULAMA

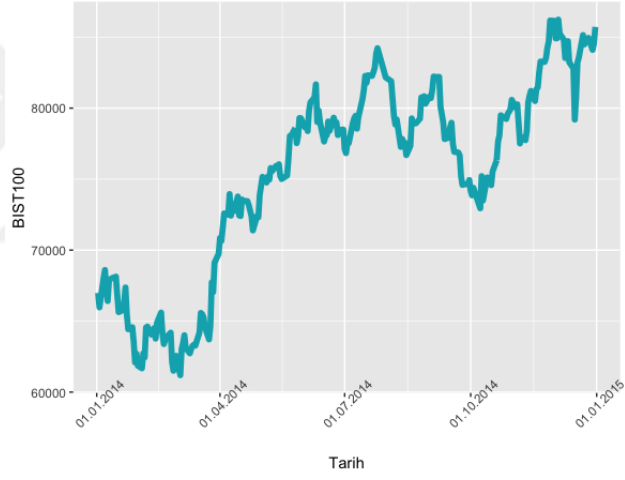
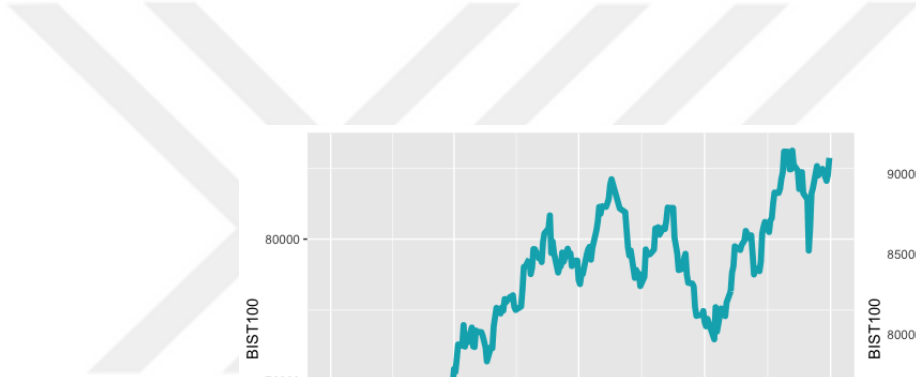
Önerilen yöntem öngörü performansının değerlendirilmesi için dokuz zaman serisi RStudio programı kullanılarak analiz edilmiştir. İlk dört zaman serisi Borsa İstanbul 100 Endeksi (BIST100) 2014-2017 yılları arasında elde edilen günlük verileridir. Diğer beş zaman serisi ise Tayvan Kapitalizasyon Ağırlıklı Borsa Endeksi (TAIEX) 2000-2004 yılları arası günlük verileridir.

Uygulamada kullanılan zaman serileri ve özellikleri Tablo 7.1 ile açıklanmıştır.

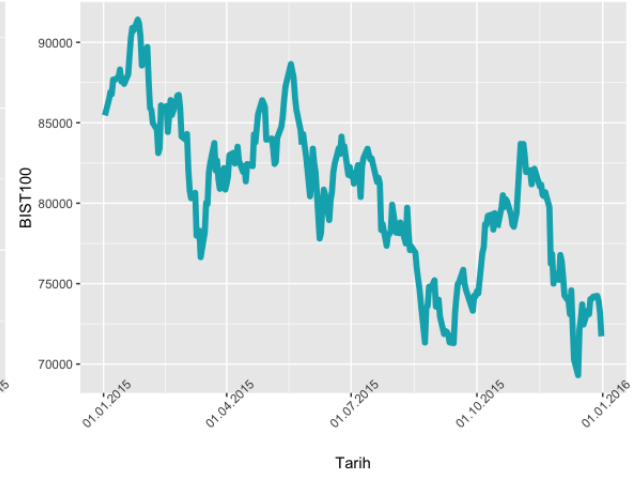
Tablo 7.1 Zaman serileri ve özellikleri

Seri no	Seri	Yıl	Gözlem sayısı	Gecikme sayısı	Küme sayısı	ntest
1	BIST100	2014	251	1:5	4:15	5,10,20
2	BIST100	2015	253	1:5	4:15	5,10,20
3	BIST100	2016	251	1:5	4:15	5,10,20
4	BIST100	2017	253	1:5	4:15	5,10,20
5	TAIEX	2000	271	1:5	4:15	47
6	TAIEX	2001	244	1:5	4:15	43
7	TAIEX	2002	248	1:5	4:15	43
8	TAIEX	2003	249	1:5	4:15	43
9	TAIEX	2004	250	1:5	4:15	45


İlk dört seri için zaman serisi grafikleri sırası ile Şekil 7.1, Şekil 7.2, Şekil 7.3 ve Şekil 7.4 ile görselleştirilmiştir.




Şekil 7.1 BIST100 2014 zaman serisi



Şekil 7.2 BIST100 2015 zaman serisi



Şekil 7.3 BIST100 2016 zaman serisi



Şekil 7.4 BIST100 2017 zaman serisi

Her bir veri seti, analize başlamadan önce z skoru üzerinden standardize edilmiştir.

Tez kapsamında ilk olarak T1IFFRR yöntemi önerildiğinden aynı veri seti için en iyi sonuç parametreleri hem T1IFFRR hem de T1IFFLR yöntemleri için sırasıyla Tablo 7.2 ve 7.3 ile ayrı ayrı gösterilmiştir.

Tablo 7.2 T1IFFRR en iyi sonuç parametreleri (RMSE)

Seri	n _{test}	Gecikme Sayısı	Küme Sayısı	$\alpha - Kesme$	k
Seri1	5	4	7	0.1	2.24e-07
	10	4	6	0.1	6.88e-09
	20	1	4	0	7.79e-09
Seri2	5	1	6	0.2	6.23e-09
	10	5	6	0.1	4.85e-09
	20	5	5	0.1	7.23e-08
Seri3	5	3	10	0.2	1.38e-08
	10	4	10	0	2.51e-08
	20	3	5	0.1	1.25e-07
Seri4	5	2	4	0.2	1.88e-08
	10	5	5	0	2.26e-07
	20	3	5	0.2	5.46e-08

BIST100 veri seti, bir hafta (n_{test}=5), iki hafta (n_{test}=10) ve bir aylık (n_{test}=20) gözlemler üzerinden test edilmiştir. Zaman dilimleri hem kendi aralarında hem de genel anlamda değerlendirilerek yöntem performansları RMSE ve MAPE kriterleri üzerinden karşılaştırılmıştır.

Seri 1-4 için önerilen yöntem öngörü performans karşılaştırması amacıyla Box ve Jenkins tarafından önerilen Bütünleşik Otoresif Hareketli Ortalama (ARIMA) [92] yöntemi, Song ve Chissom tarafından önerilen Zamandan Bağımsız Bulanık Zaman Serileri (SC) [93] yöntemi, Jang tarafından önerilen ANFIS [5] yöntemi, Türkşen tarafından önerilen T1FF [13] yöntemi, Sarıca vd. tarafından önerilen AR-ANFIS [12] yöntemi ve Baş vd. tarafından önerilen T1FFRR [32] yöntemi kullanılmıştır.

n_{test}=5 için yöntemlerin RMSE değerleri yıllara göre karşılaştırılmış ve Tablo 7.4 ile gösterilmiştir. Yıllara göre sıralanmış yöntemlerden elde edilen sonuçlar incelendiğinde, 2014 yılı için T1IFFLR yöntemi diğer yöntemlere kıyasla belirgin seviyede fark yaratmıştır. 2015 yılı açısından ise T1IFFRR ve T1IFFLR yöntemlerinin diğer yöntemlerden ayrıldığı görülmektedir. 2016 yılı için T1FFRR, T1IFFRR ve T1IFFLR yöntemleri yakın RMSE değerlerine sahiptirler. 2017 yılında ise T1IFFRR yöntemi tüm yöntemlerden daha iyi sonuç elde etmiştir. Nihayet ortalama değerler üzerinden yorumlanacak olursa T1IFFRR ve T1IFFLR yöntemleri yakın olmakla birlikte T1IFFLR yöntemi en iyi sonucu elde etmiştir.

Tablo 7.3 T1IFFLR en iyi sonuç parametreleri (RMSE)

Seri	n _{test}	Gecikme Sayısı	Küme Sayısı	<i>k</i>	<i>d</i>
Seri1	5	1	9	0.1	-0.2
	10	1	10	0.4	-0.8
	20	1	13	0.7	-2.3
Seri2	5	1	8	1	-5
	10	1	13	0.4	-0.5
	20	1	15	0.4	-0.2
Seri3	5	1	14	0.4	-0.5
	10	1	12	3.4	0.1
	20	1	13	0.1	-0.2
Seri4	5	1	8	0.1	-0.2
	10	1	10	0.1	-0.5
	20	1	10	0.4	-3.5
Seri5	47	1	14	4.9	4.6
Seri6	43	1	15	0.1	0.4
Seri7	43	1	12	1	4.9
Seri8	43	1	12	1.3	-2
Seri9	45	1	14	0.4	-0.2


Tablo 7.4 BIST100 veri seti, n_{test}=5 için yıllara göre RMSE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	681	1234	674	669	668	645	639	392
Seri2	750	603	743	650	770	600	341	388
Seri3	449	414	436	389	514	344	343	349
Seri4	1156	2570	1624	1226	1118	1267	596	786
Ortalama	759	1205.25	869.25	733.50	767.50	714	479.75	478.75
Ortanca	715.5	918.5	708.5	659.5	719	622.5	469.5	390

Haftalık test verisi için sonuçlar Şekil 7.5'den incelendiğinde, 2014 ve 2017 yıllarında SC yönteminin diğer yöntemlere kıyasla oldukça yüksek hata ile öngörü elde ettiği gözlenmektedir. Diğer yöntemler benzer eğilim gösterse de önerilen yöntemler T1IFFRR ve T1IFFLR düşük hata miktarı ile eğilimden sıyrılmaktadır.

Önerilen yöntem ve alternatif yöntemlerin iki haftalık veri seti üzerinden test edilmesi sonucunda elde edilen RMSE değerleri Tablo 7.5 ile gösterilmiştir. İlk üç yıl bazında T1IFFLR yöntemi diğer yöntemlerden belirgin derecede daha düşük hata ile öngörü elde etmiştir. 2017 yılında ise T1IFFRR ve T1IFFLR yöntemleri yakın RMSE değerlerine sahip olmakla birlikte T1IFFRR yöntemi daha üstündür. Genel ortalama da ise T1IFFLR yöntemi en düşük RMSE değerine sahip yöntem olarak gözlenmektedir.

İki haftalık sonuçların grafiksel değerlendirilmesi Şekil 7.6 ile yapılmıştır. Yöntemler



Şekil 7.5 BIST100 veri seti ntest=5 için yıllara göre RMSE değerleri


Tablo 7.5 BIST100 veri seti, ntest=10 için yıllara göre RMSE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	1060	1371	1145	1009	1066	1066	889	725
Seri2	779	870	773	727	743	694	668	311
Seri3	434	392	418	382	433	373	389	263
Seri4	911	2251	964	944	873	938	544	555
Ortalama	796	1221	825	765.50	778.75	767.75	622.50	463.50
Ortanca	845	1120.5	868.5	835.5	808	816	606	433

genelinde en düşük RMSE değerleri 2016 yılında elde edilmiştir. Yine 2014 ve 2017 yılları en yüksek RMSE değeri SC yöntemi ile elde edilmiştir. Tüm yöntemler yıllara göre farklı miktarda fakat benzer eğilimde hareket etmişlerdir. Yalnızca T1IFFLR yöntemi genel seyirden sıyrılarak en düşük RMSE değerlerini elde etmiştir.

BIST100 veri seti, bir aylık test veri değerlendirmesi sonuçları Tablo 7.6 ile gösterilmiştir. Yıl bazında ve genel ortalama en düşük RMSE değeri önerilen yöntem T1IFFLR ile elde edilmiştir.

BIST100 test veri seti aylık değerlendirmesinin grafik yorumu Şekil 7.7 ile



Şekil 7.6 BIST100 veri seti ntest=10 için yıllara göre RMSE değerleri


Tablo 7.6 BIST100 veri seti, ntest=20 için yıllara göre RMSE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	1316	1536	1312	1292	1316	1292	1281	1036
Seri2	1225	2209	1175	1171	1286	1192	1169	775
Seri3	600	376	562	456	593	436	564	302
Seri4	1031	1854	1182	1033	1154	1071	800	712
Ortalama	1043	1493.75	1057.75	988	1087.25	997.75	953.50	706.25
Ortanca	1128	1695	1178.5	1102	1220	1131.5	984.5	743.5

gösterilmiştir. Yöntemler arasında en sıçramalı RMSE değerlerine sahip yöntem diğer grafiklerde de gözleendiği gibi SC olmuştur. Benzer şekilde diğer yöntemler yakın seyirde olup T1IFFLR x eksenine en yakın yolu izleyen yöntem olarak yıl bazında en düşük RMSE değerlerini elde etmiştir.

BIST100 veri seti uygulamasında kullanılan yöntemler arasında farklılık olup olmadığının sınanmasında için Tablo 7.4, Tablo 7.5 ve Tablo 7.6 de verilen RMSE değerleri üzerinden Kruskal-Wallis H testi uygulanmıştır.

$$H_0 = \tau_{ARIMA} = \tau_{SC} = \dots = \tau_{T1IFFLR}$$



Şekil 7.7 BIST100 veri seti ntest=20 için yıllara göre RMSE değerleri

$H_1 = \tau_j$ parametrelerinden en az biri farklıdır.

analiz sonucunda $\chi^2 = 14.596$ elde edilmiş olup, p-değeri=0.04154 bulunmuştur. Bu bilgiler ışığında %95 güven düzeyinde yöntemler arasında anlamlı farklılık olduğu söylenebilir.


BIST100 veri seti değerlendirmeleri ikinci bir performans kriteri olarak MAPE ile gerçekleştirilmiştir.

Tablo 7.7 BIST100 veri seti, ntest=5 için yıllara göre MAPE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	0.0061	0.0125	0.0066	0.0061	0.0058	0.0058	0.0055	0.0015
Seri2	0.0075	0.0065	0.0075	0.0067	0.0078	0.0065	0.0040	0.0039
Seri3	0.0047	0.0042	0.0047	0.004	0.0056	0.0038	0.0035	0.0057
Seri4	0.0074	0.0203	0.0123	0.0082	0.0070	0.0087	0.0045	0.0052
Ortalama	0.00642	0.01087	0.00777	0.00625	0.00655	0.00620	0.00437	0.00407
Ortanca	0.00675	0.00950	0.00705	0.00640	0.00640	0.00615	0.00425	0.00455

BIST100 veri seti ntest=5 için önerilen ve alternatif yöntemler MAPE değerleri Tablo 7.7 da verilmiştir. 2014 yılı için T1IFFLR MAPE değeri, alternatif yöntemlerden

belirgin seviyede ayrılmaktadır. 2015 yılı MAPE değerleri T1IFFRR ve T1IFFLR yakın olmakla birlikte diğer yöntemlerden daha düşük hatayla öngörü elde etmektedir. 2016 yılı için alternatif yöntemler T1IFFLR yönteminden daha düşük hata elde etmiştir, T1IFFRR ise en düşük hata elde eden yöntem olmuştur. Son olarak 2017 yılında ise T1IFFRR en düşük MAPE değerine sahip olup onu T1IFFLR takip etmiştir. Ortalamada ise T1IFFLR yöntemi en düşük MAPE değerine sahiptir.



Şekil 7.8 BIST100 veri seti ntest=5 için yıllara göre MAPE değerleri


Aynı verileri grafiksel olarak incelediğimizde RMSE hareketlerine benzer olarak MAPE için de başlangıç ve bitiş açısından en yüksek değerlerin SC yönteminde elde edildiği Şekil 7.8 de gözlenmektedir. 2015-2017 yılları arasında T1IFFLR yönteminin alternatif yöntemlerin aksi yönünde artış ve azalış gösterdiği grafikten izlenebilmektedir.

Tablo 7.8 BIST100 veri seti, ntest=10 için yıllara göre MAPE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	0.0094	0.0144	0.011	0.0094	0.0092	0.0098	0.0079	0.0055
Seri2	0.0082	0.0091	0.0083	0.0078	0.0080	0.0072	0.0075	0.0034
Seri3	0.0048	0.0042	0.0046	0.0042	0.0048	0.0038	0.0043	0.0028
Seri4	0.0058	0.0167	0.0091	0.0061	0.0051	0.0058	0.0041	0.0051
Ortalama	0.00705	0.01111	0.00825	0.00687	0.00677	0.00665	0.00595	0.00420
Ortanca	0.00700	0.01175	0.00870	0.00695	0.00655	0.00650	0.00590	0.00425

İki haftalık test veri seti için MAPE değerlendirmesi Tablo 7.8'da yapılmıştır. T1IFFLR

alternatif yöntemlere kıyasla daha düşük MAPE değerleri elde etmiştir, yalnızca 2017 yılı MAPE performansında T1IFFRR'ın gerisinde kalmıştır. Ortalamada tüm yöntemler arasında en düşük hata ile öngörü elde eden yöntem T1IFFLR olmuştur.




Şekil 7.9 BIST100 veri seti ntest=10 için yıllara göre MAPE değerleri

MAPE değerlerinin grafiksel görünümü Şekil 7.9 incelendiğinde ntest=10 için RMSE ve MAPE görselinde bir farklılık olmadığı görülmektedir. En iyi performansın T1IFFLR yöntemi ile elde edildiği açıktır.

Tablo 7.9 BIST100 veri seti, ntest=20 için yıllara göre MAPE değerleri

Seri	ARIMA (1970)	SC (1993)	ANFIS (1993)	T1FF (2008)	AR-ANFIS (2018)	T1FFRR (2018)	T1IFFRR (2019)	T1IFFLR (2020)
Seri1	0.0122	0.0135	0.0123	0.0121	0.0121	0.0121	0.0118	0.0079
Seri2	0.0135	0.0191	0.013	0.0128	0.0146	0.013	0.0125	0.0073
Seri3	0.0058	0.004	0.0055	0.0049	0.0058	0.0047	0.0063	0.0034
Seri4	0.0077	0.0137	0.0091	0.0078	0.0085	0.0079	0.0059	0.0049
Ortalama	0.00980	0.01257	0.00997	0.00940	0.01025	0.00942	0.00912	0.00587
Ortanca	0.00995	0.01360	0.01070	0.00995	0.01030	0.01000	0.00905	0.00610

BIST100 veri seti değerlendirmesindeki son tablo olan aylık test seti için MAPE incelemesi sonuçları Tablo 7.9'da verilmiştir. T1IFFLR, alternatif yöntemler içinde tüm yıllar için en düşük MAPE değerlerini elde etmiş olup en iyi öngörü yöntemi olarak değerlendirilebilir.



Şekil 7.10 BIST100 veri seti ntest=20 için yıllara göre MAPE değerleri

Şekil 7.10'dan da görüleceği üzere yıllara göre alternatif yöntemlere kıyasla en düşük MAPE değerleri T1IFFLR yöntemi ile elde edilmiştir.

BIST100 veri seti uygulamasında kullanılan yöntemler arasında farklılık olup olmadığının sınanmasında için Tablo 7.7, Tablo 7.8 ve Tablo 7.9 de verilen MAPE değerleri üzerinden Kruskal-Wallis H testi uygulanmıştır.

$$H_0 = \tau_{ARIMA} = \tau_{SC} = \dots = \tau_{T1IFFLR}$$

$H_1 = \tau_j$ parametrelerinden en az biri farklıdır.

analiz sonucunda $\chi^2 = 19.241$ elde edilmiş olup, p-değeri=0.007465 bulunmuştur. Bu bilgiler ışığında %95 güven düzeyinde yöntemler arasında anlamlı farklılık olduğu söylenebilir.

Seri 5-9 için önerilen yöntem öngörü performans değerlendirmesi amacıyla önerilen yöntem ve Jang (1993)[5], Chen (1996) [94], Yu ve Huarng (2008) [95], Chen ve Chang (2010) [96], Chen ve Chen (2011) [97], Chen vd. (2012) [98], Chen ve Kao (2013) [99], Eğrioğlu vd. (2014) [46], Chen vd. (2014) [100], Cai vd. (2015) [101], Sarıca (2018) [12], Ye vd. (2016) [102], Cheng vd. (2016) [103], Chen ve Jian (2017) [104], Chen ve Phuong (2017) [105], Tak vd. (2018) [22], Huarng ve Yu (2006) [106], Tak (2020) [49], Baş vd. (2019) [32], Eğrioğlu vd. (2019) [1], Baş

(2020) [27] yöntemleri karşılaştırılmıştır.

Tablo 7.10 TAIEX test setleri için *RMSE* değerleri

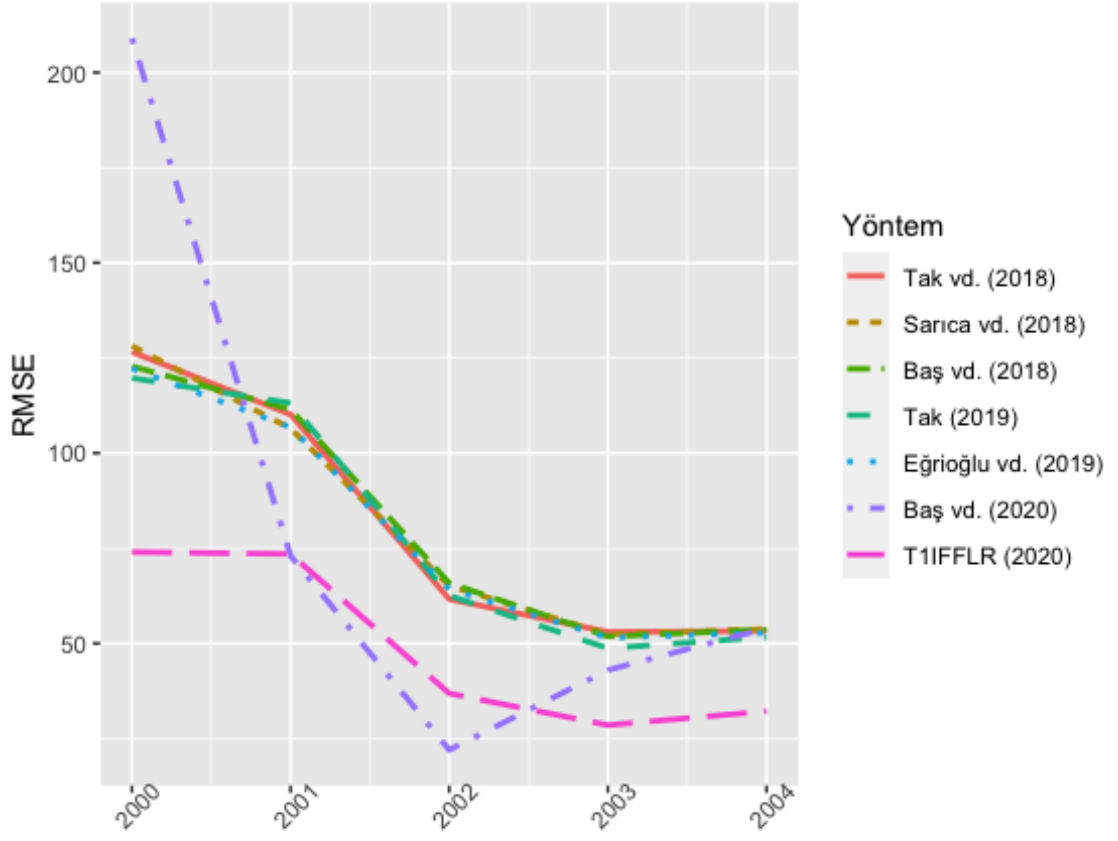
	Seri5	Seri6	Seri7	Seri8	Seri9	Ortalama	Ortanca
Jang (1993)	137	115	66	57	61	87.2	66
Chen (1996)	176.32	147.84	101.18	74.46	84.28	116.816	101.18
Huarng ve Yu (2006)	152	130	84	56	116	107.6	116
Yu ve Huarng (2008)	259	113	85	58	67	116.4	85
Chen ve Chang (2010)	129.42	113.33	66.82	53.51	60.48	84.712	66.82
Chen ve Chen (2011)	123.62	115.33	71.01	58.06	57.73	85.15	71.01
Chen vd. (2012)	119.98	114.47	67.17	52.49	52.27	81.276	67.17
Chen ve Kao (2013)	125.34	114.57	76.86	54.29	58.17	85.846	76.86
Egrioglu vd. (2014)	124.92	112.47	62.57	52.33	53.66	81.19	62.57
Chen vd. (2014)	125.55	114.16	65.42	53.63	53.25	82.402	65.42
Cai vd. (2015)	131.53	112.59	60.33	51.54	50.33	81.264	60.33
Ye vd. (2016)	125.42	113.22	63.99	52.99	52.4	81.604	63.99
Cheng vd. (2016)	125.62	113.04	62.94	51.46	54.25	81.462	62.94
Chen ve Jian (2017)	128.95	110.66	60.41	50.65	52.86	80.706	60.41
Chen ve Phuong (2017)	126.59	110.17	61.62	53.01	53.28	80.934	61.62
Tak vd. (2018)	128.18	106.48	65.14	52.38	53.78	81.192	65.14
Sarica vd. (2018)	122.81	111.49	65.86	51.83	53.63	81.124	65.86
Baş vd. (2018)	119.73	113.17	62.55	48.73	51.66	79.168	62.55
Tak (2019)	122.23	106.81	64.24	51.5	52.79	79.514	64.24
Eğrioğlu vd. (2019)	209	73	22	43	54	80.2	54
Baş vd. (2020)	119.91	111.42	63.86	51.64	51.86	79.74	63.86
T1IFFLR	74	73.5	36.86	28.54	32.18	49.016	36.86

TAIEX veri seti literatürde sıklıkla kullanılan bir veri seti olduğundan önerilen yöntem performansı yirmi bir farklı araştırma ile karşılaştırılmıştır. Tablo 7.10'den görüldüğü gibi beş seriden dördünde en düşük test hatası önerilen yöntemde elde edilen hata miktarıdır, yalnızca 2002 yılında Eğrioğlu vd. (2019) [1] çalışması daha iyi performans sergilemiştir. Yöntemler genel anlamda kıyaslandığında ise hem ortalama hem de ortanca açısından en iyi performansı yine önerilen yöntem sergilemiştir.

Karşılaştırma kolaylığı açısından son altı yöntem ile önerilen yöntem grafiksel olarak Şekil 7.11 ile değerlendirilmiştir. RMSE açısından yöntemlerin büyük çoğunluğunun seyri benzerdir. Eğrioğlu vd. (2019) [1] çalışması bu seyrin dışındadır, 2002 yılında düşük hata elde etmiş olsa da 2000, 2003 ve 2004 yıllarındaki hata miktarı önerilen yöntem hatasından yüksektir.


Seri6 için 10 tekrar üzerinden elde edilen eğitim ve test RMSE değerleri Şekil 7.12'de görselleştirilmiştir.

244 gözlemden oluşan Seri6 için son 43 gözlem test veri seti olarak alınmış olup diğer seriler için detaylar Tablo 7.1 de açıklanmıştır. Test gözlemleri ve bu gözlemler için önerilen yöntemle elde edilen öngörüler Şekil 7.13 ile gösterilmiştir. Önerilen

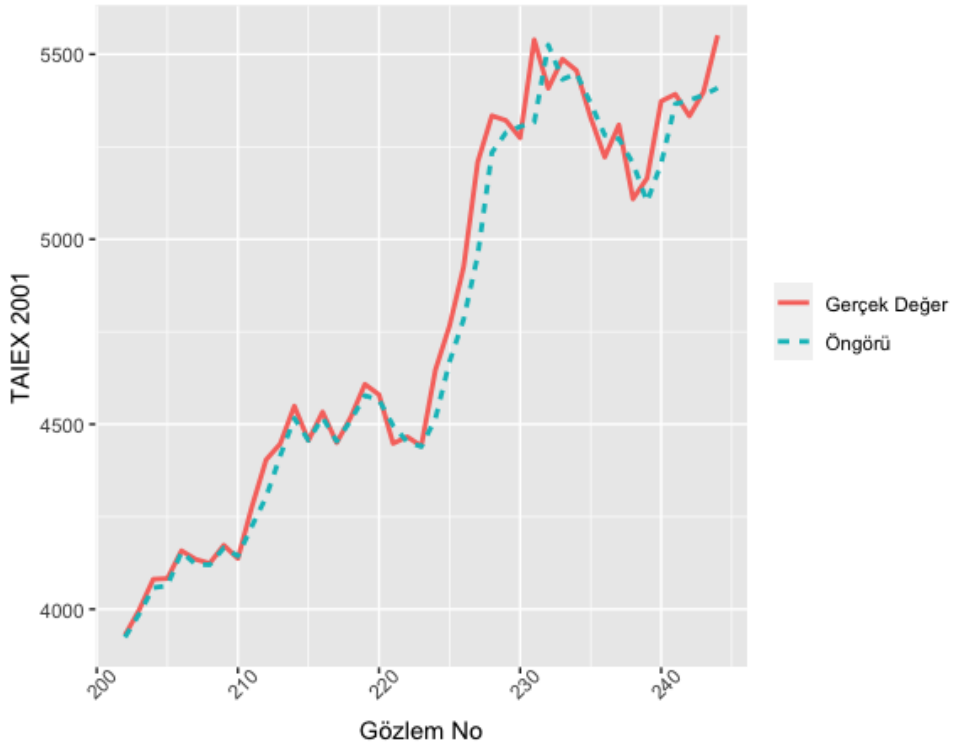


Şekil 7.11 TAIEX veri seti RMSE değerleri

yöntemin düşük hata ile öngörü elde ettiği Tablo 7.10 ile gösterilmiş olup gerçek değer ve öngörü karşılaştırma grafiği Seri 6 için Şekil 7.13 de verilmiştir.



Şekil 7.12 TAIEX veri seti RMSE değerleri eğitim-test karşılaştırma (Seri6)



Şekil 7.13 TAIEX veri seti öngörü ve gerçek değer karşılaştırması (Seri6)

8 SONUÇ VE ÖNERİLER

Çalışma kapsamında T1FF yaklaşımını temel alan yeni bir sezgisel bulanık çıkarım sistemi tasarlanmıştır. Öngörü performansını arttırma hedefiyle önerilen yöntemde, sezgisel bulanık kümeler kullanılarak tereddüt derecesi tanımlanmış ve üye olmama değerinin etkisi de sisteme dahil edilmiştir. Bu sayede tip 2 bulanık kümelerde olduğu gibi belirsizliğe ek bir bakış sağlanmıştır.

Bulanık fonksiyonların tanımlanması aşamasında, girdi matrisinde yer alan üyelik değerleri ve dönüşümlerine ek olarak üye olmama değerleri ve dönüşümleri eklenerek tahmin performansında artış sağlanmıştır. Girdi matrisinde yer alan bu değişkenler arasındaki çoklu iç ilişki problemi ridge regresyon tahmin edici ile incelenerek, RMSE ve MAPE açısından düşüş sağladığı alternatif yöntemlerle karşılaştırmalı olarak gösterilmiştir. Ridge tahmin edici ile sistemki çoklu iç ilişki problemi azaltılmış ancak tamamen giderilememiştir. Bu açıdan çalışmanın ikinci kısmında aynı problem liu tipi tahmin edici açısından incelenmiştir. Liu tipi tahmin edicinin yanlılık parametreleri seçilirken çoklu iç ilişki miktarına odaklı klasik seçim yöntemleri yerine her bir model için olası hata miktarını hesaplayan ve bu tüm modelleri göz önüne alarak parametreyi belirleyen veri tabanlı arama yöntemi kullanılmıştır. Yüksek iç ilişki durumunda tercih edilen liu tipi tahmin edici kullanılmış olmasına rağmen girdi matrisindeki yüksek miktar iç ilişki tamamen giderilememiş ancak oldukça büyük miktarda azalış sağlanmıştır. Çoklu iç ilişki tamamen giderilememiş olmasına rağmen öngörü performansı alternatif yöntemlerden daha başarılıdır.

Nihai model belirlenmesi aşamasında hem üyelik hem üye olmama değerleri, hatayı minimize etme hedefiyle parçacık sürü optimizasyonu ile ağırlıklandırılmıştır.

Tez kapsamında düşük hata ile öngörü hedefiyle, belirsizlik ortamında çalışabilen, gerçek hayat verileri için gerçekleşmesi zor varsayımları gerektirmeyen, çoklu iç ilişki problemini dikkate alan dinamik bir regresyon modeli önerilmiştir. Önerilen yöntem gerçek yaşam verilerine uygulanmış, elde edilen sonuçlar benzer çalışmaların sonuçları ile karşılaştırılarak performans üstünlüğü ispatlanmıştır. Yöntem, ekonomi,

finans ve meteoroloji gibi zaman serileri ile çalışılan alanlarda kullanılabilir.

Gelecek çalışmalarda hiperparametrelerin farklı yöntemlerle seçimi ve performans karşılaştırması yapılabileceği gibi farklı bulanık regresyon fonksiyonları üzerinden de öngörü performansının artırılması hedeflenebilir.



- [1] E. Egrioglu, E. Bas, O. C. Yolcu, U. Yolcu, “Intuitionistic time series fuzzy inference system,” *Engineering Applications of Artificial Intelligence*, vol. 82, pp. 175–183, 2019.
- [2] L. A. Zadeh, “Fuzzy sets,” *Information and control*, vol. 8, no. 3, pp. 338–353, 1965.
- [3] A. Mamdani, S. Assilian, “An experiment in linguistic synthesis with a fuzzy logic controller,” *Int. J. Man-machine studies*, vol. 7, pp. 1–13, 1975.
- [4] M. Sugeno, *Industrial applications of fuzzy control*. Elsevier Science Inc., 1985.
- [5] J.-S. Jang, “Anfis: Adaptive-network-based fuzzy inference system,” *IEEE transactions on systems, man, and cybernetics*, vol. 23, no. 3, pp. 665–685, 1993.
- [6] B. R. Chang, “Resolving the forecasting problems of overshoot and volatility clustering using anfis coupling nonlinear heteroscedasticity with quantum tuning,” *Fuzzy Sets and Systems*, vol. 159, no. 23, pp. 3183–3200, 2008.
- [7] C.-H. Cheng, L.-Y. Wei, Y.-S. Chen, “Fusion anfis models based on multi-stock volatility causality for taieex forecasting,” *Neurocomputing*, vol. 72, no. 16-18, pp. 3462–3468, 2009.
- [8] J. P. d. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes, “Hybrid wavelet-pso-anfis approach for short-term electricity prices forecasting,” *IEEE Transactions on Power Systems*, vol. 26, no. 1, pp. 137–144, 2011.
- [9] Y.-C. Ho, C.-T. Tsai, “Comparing anfis and sem in linear and nonlinear forecasting of new product development performance,” *Expert Systems with Applications*, vol. 38, no. 6, pp. 6498–6507, 2011.
- [10] H. M. I. Pousinho, V. Mendes, J. P. d. S. Catalão, “Short-term electricity prices forecasting in a competitive market by a hybrid pso–anfis approach,” *International Journal of Electrical Power & Energy Systems*, vol. 39, no. 1, pp. 29–35, 2012.
- [11] C.-H. Cheng, L.-Y. Wei, J.-W. Liu, T.-L. Chen, “Owa-based anfis model for taieex forecasting,” *Economic Modelling*, vol. 30, pp. 442–448, 2013.
- [12] B. Sarıca, E. Eğrioğlu, B. Aşıkıl, “A new hybrid method for time series forecasting: Ar–anfis,” *Neural Computing and Applications*, vol. 29, no. 3, pp. 749–760, 2018.
- [13] I. B. Türkşen, “Fuzzy functions with lse,” *Applied Soft Computing*, vol. 8, no. 3, pp. 1178–1188, 2008.

- [14] A. Celikyilmaz, I. B. Turksen, "Enhanced fuzzy system models with improved fuzzy clustering algorithm," *IEEE Transactions on Fuzzy Systems*, vol. 16, no. 3, pp. 779–794, 2008.
- [15] A. Celikyilmaz, I. B. Turksen, "Uncertainty modeling of improved fuzzy functions with evolutionary systems," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 38, no. 4, pp. 1098–1110, 2008.
- [16] I. Türksen, "A review of developments in fuzzy system models: Fuzzy rule bases to fuzzy functions," *Scientia Iranica*, vol. 18, no. 3, pp. 522–527, 2011.
- [17] M. F. Zarandi, M. Zarinbal, N. Ghanbari, I. Turksen, "A new fuzzy functions model tuned by hybridizing imperialist competitive algorithm and simulated annealing. application: Stock price prediction," *Information Sciences*, vol. 222, pp. 213–228, 2013.
- [18] S. Beyhan, M. Alci, "Fuzzy functions based arx model and new fuzzy basis function models for nonlinear system identification," *Applied Soft Computing*, vol. 10, no. 2, pp. 439–444, 2010.
- [19] C. H. Aladag, I. B. Turksen, A. Z. Dalar, E. Egrioglu, U. Yolcu, "Application of type-1 fuzzy functions approach for time series forecasting," *Turkish Journal of Fuzzy Systems*, vol. 5, no. 1, pp. 1–9, 2014.
- [20] C. H. Aladag, U. Yolcu, E. Egrioglu, I. B. Turksen, "Type-1 fuzzy time series function method based on binary particle swarm optimisation," *International Journal of Data Analysis Techniques and Strategies*, vol. 8, no. 1, pp. 2–13, 2016.
- [21] S. Goudarzi, M. B. Khodabakhshi, M. H. Moradi, "Interactively recurrent fuzzy functions with multi objective learning and its application to chaotic time series prediction," *Journal of Intelligent & Fuzzy Systems*, vol. 30, no. 2, pp. 1157–1168, 2016.
- [22] N. Tak, A. A. Evren, M. Tez, E. Egrioglu, "Recurrent type-1 fuzzy functions approach for time series forecasting," *Applied Intelligence*, vol. 48, no. 1, pp. 68–77, 2018.
- [23] N. Tak, "Meta fuzzy functions: Application of recurrent type-1 fuzzy functions," *Applied Soft Computing*, vol. 73, pp. 1–13, 2018.
- [24] N. Tak, "Type-1 possibilistic fuzzy forecasting functions," *Journal of Computational and Applied Mathematics*, vol. 370, p. 112 653, 2020.
- [25] Q. Song, B. S. Chissom, "Fuzzy time series and its models," *Fuzzy sets and systems*, vol. 54, no. 3, pp. 269–277, 1993.
- [26] E. Bas, E. Egrioglu, C. H. Aladag, U. Yolcu, "Fuzzy-time-series network used to forecast linear and nonlinear time series," *Applied Intelligence*, vol. 43, no. 2, pp. 343–355, 2015.
- [27] E. Bas, U. Yolcu, E. Egrioglu, "Intuitionistic fuzzy time series functions approach for time series forecasting," *Granular Computing*, pp. 1–11, 2020.
- [28] K. Atanassov, "Intuitionistic fuzzy sets. fuzzy sets and systems 20 (1), 87-96," 1986.
- [29] K. Zheng, Y. Lei, R. Wang, Y. Wang, "Modeling and application of ifts," *Control and Decision*, vol. 28, no. 10, pp. 1525–1530, 2013.

- [30] K. Bisht, S. Kumar, “Intuitionistic fuzzy set-based computational method for financial time series forecasting,” *Fuzzy Information and Engineering*, vol. 10, no. 3, pp. 307–323, 2019.
- [31] N. Tak, “Type-1 recurrent intuitionistic fuzzy functions for forecasting,” *Expert Systems with Applications*, vol. 140, p. 112 913, 2020.
- [32] E. Bas, E. Egrioglu, U. Yolcu, C. Grosan, “Type 1 fuzzy function approach based on ridge regression for forecasting,” *Granular Computing*, vol. 4, no. 4, pp. 629–637, 2019.
- [33] B. Kizilaslan, E. Egrioglu, A. A. Evren, “Intuitionistic fuzzy ridge regression functions,” *Communications in Statistics-Simulation and Computation*, pp. 1–10, 2019.
- [34] A. Celikyilmaz, I. B. Turksen, “Modeling uncertainty with fuzzy logic,” *Studies in fuzziness and soft computing*, vol. 240, pp. 149–215, 2009.
- [35] M. Z. Esenyel, “İnsanın, insan olmak bakımından işlevi nedir?: Aristotelesçi bir bakış,” *Kaygı. Uludağ Üniversitesi Fen-Edebiyat Fakültesi Felsefe Dergisi*, no. 18, pp. 209–220, 2012.
- [36] Ş. Işıklı, “Bulanık mantık ve bulanık teknolojiler,” 2008.
- [37] Z. Şen, *Bulanık mantık ilkeleri ve modelleme:(Mühendislik ve sosyal bilimler)*. Su Vakfi, 2009.
- [38] L. A. Zadeh, “Fuzzy logic,” *Computer*, vol. 21, no. 4, pp. 83–93, 1988.
- [39] T. Paksoy, N. Y. Pehlivan, E. Özceylan, *Bulanık küme teorisi*. Nobel, 2013.
- [40] İ. Türksen, “Dereceli bulanık sistem modelleri,” *Abaküs Yayıncılık, Türkiye*, 2015.
- [41] T. J. Ross, *Fuzzy logic with engineering applications*. McGraw Hill, 1995.
- [42] J. C. Dunn, “A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters,” 1973.
- [43] J. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, 1981.
- [44] Ç. Elmas, *Yapay zeka uygulamaları:(yapay sinir ağı, bulanık mantık, genetik algoritma)*. Seçkin Yayıncılık, 2007.
- [45] S. Sivanandam, S. Sumathi, S. Deepa, *et al.*, *Introduction to fuzzy logic using MATLAB*. Springer, 2007, vol. 1.
- [46] E. Egrioglu, C. Aladag, U. Yolcu, E. Bas, “A new adaptive network based fuzzy inference system for time series forecasting,” *Aloy J Soft Comput Appl*, vol. 2, pp. 25–32, 2014.
- [47] K. Atanassov, “Intuitionistic fuzzy sets. vii. itkr’s session. sofia, 1983,” *Deposited in Central Science—Technology Library of Bulgaria Academy of Science—1697/84*, 1986.
- [48] K. T. Atanassov, “Intuitionistic fuzzy sets,” in *Intuitionistic fuzzy sets*, Springer, 1999, pp. 1–137.
- [49] N. Tak, “Type-1 recurrent intuitionistic fuzzy functions for forecasting,” *Expert Systems with Applications*, vol. 140, p. 112 913, 2020.

- [50] H.-m. Zhang, Z.-s. Xu, Q. Chen, “On clustering approach to intuitionistic fuzzy sets,” *Control and Decision*, vol. 22, no. 8, p. 882, 2007.
- [51] Z. Xu, J. Wu, “Intuitionistic fuzzy c-means clustering algorithms,” *Journal of Systems Engineering and Electronics*, vol. 21, no. 4, pp. 580–590, 2010.
- [52] T. Chaira, “A novel intuitionistic fuzzy c means clustering algorithm and its application to medical images,” *Applied Soft Computing*, vol. 11, no. 2, pp. 1711–1717, 2011.
- [53] F. Galton, “I. family likeness in stature,” *Proceedings of the Royal Society of London*, vol. 40, no. 242-245, pp. 42–73, 1886.
- [54] K. Pearson, A. Lee, “On the laws of inheritance in man: I. inheritance of physical characters,” *Biometrika*, vol. 2, no. 4, pp. 357–462, 1903.
- [55] R. Alpar, *Uygulamalı çok değişkenli istatistiksel yöntemlere giriş 1*. Nobel, 2003.
- [56] D. C. Montgomery, E. A. Peck, G. G. Vining, *Introduction to linear regression analysis*. John Wiley & Sons, 2012, vol. 821.
- [57] A. Alin, “Multicollinearity,” *Wiley Interdisciplinary Reviews: Computational Statistics*, vol. 2, no. 3, pp. 370–374, 2010.
- [58] D. Gujarati, D. Porter, Ş. Temel Ekonometri, “Ü. ve şenesen, gg, (çev.), literatür yayınları, 5,” *Basım, İstanbul*, 2012.
- [59] A. E. Hoerl, R. W. Kennard, “Ridge regression: Biased estimation for nonorthogonal problems,” *Technometrics*, vol. 12, no. 1, pp. 55–67, 1970.
- [60] A. E. Hoerl, R. W. Kannard, K. F. Baldwin, “Ridge regression: Some simulations,” *Communications in Statistics-Theory and Methods*, vol. 4, no. 2, pp. 105–123, 1975.
- [61] L. Kejian, “A new class of biased estimate in linear regression,” *Communications in Statistics-Theory and Methods*, vol. 22, no. 2, pp. 393–402, 1993.
- [62] C. Stein, “Inadmissibility of the usual estimator for the mean of a multivariate normal distribution,” Stanford University Stanford United States, Tech. Rep., 1956.
- [63] S. Kaçiranlar, S. Sakallıoğlu, “Liu ve temel bileşenler regresyon tahmin edicilerinin birleştirilmesi,” *İstatistik Araştırma Sempozyumu*, pp. 17–21, 2000.
- [64] K. Liu, “Using liu-type estimator to combat collinearity,” *Communications in Statistics-Theory and Methods*, vol. 32, no. 5, pp. 1009–1020, 2003.
- [65] D. Inan, E. Egrioglu, B. Sarica, O. E. Askin, M. Tez, “Particle swarm optimization based liu-type estimator,” *Communications in Statistics-Theory and Methods*, vol. 46, no. 22, pp. 11 358–11 369, 2017.
- [66] Z. Y. Algama, “Shrinkage parameter selection via modified cross-validation approach for ridge regression model,” *Communications in Statistics-Simulation and Computation*, pp. 1–9, 2018.
- [67] S. Dudoit, M. J. van der Laan, “Asymptotics of cross-validated risk estimation in estimator selection and performance assessment,” *Statistical Methodology*, vol. 2, no. 2, pp. 131–154, 2005.

- [68] D. Krstajic, L. J. Buturovic, D. E. Leahy, S. Thomas, “Cross-validation pitfalls when selecting and assessing regression and classification models,” *Journal of cheminformatics*, vol. 6, no. 1, pp. 1–15, 2014.
- [69] S. Varma, R. Simon, “Bias in error estimation when using cross-validation for model selection,” *BMC bioinformatics*, vol. 7, no. 1, p. 91, 2006.
- [70] G. H. Golub, M. Heath, G. Wahba, “Generalized cross-validation as a method for choosing a good ridge parameter,” *Technometrics*, vol. 21, no. 2, pp. 215–223, 1979.
- [71] M. R. Özkale, “Predictive performance of linear regression models,” *Statistical Papers*, vol. 56, no. 2, pp. 531–567, 2015.
- [72] J. Bergstra, Y. Bengio, “Random search for hyper-parameter optimization,” *Journal of machine learning research*, vol. 13, no. Feb, pp. 281–305, 2012.
- [73] M. Ataei, M. Osanloo, “Using a combination of genetic algorithm and the grid search method to determine optimum cutoff grades of multiple metal deposits,” *International Journal of Surface Mining, Reclamation and Environment*, vol. 18, no. 1, pp. 60–78, 2004.
- [74] A. K. Uludağ, *Doğrusal regresyon modellerinde çapraz geçerlik yöntemleri*, 2005.
- [75] M. Stone, “Cross-validated choice and assessment of statistical predictions,” *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 36, no. 2, pp. 111–133, 1974.
- [76] S. Arlot, A. Celisse, *et al.*, “A survey of cross-validation procedures for model selection,” *Statistics surveys*, vol. 4, pp. 40–79, 2010.
- [77] J. Friedman, T. Hastie, R. Tibshirani, *The elements of statistical learning*, 10. Springer series in statistics New York, 2001, vol. 1.
- [78] R. Kohavi *et al.*, “A study of cross-validation and bootstrap for accuracy estimation and model selection,” in *Ijcai*, Montreal, Canada, vol. 14, 1995, pp. 1137–1145.
- [79] R. J. Hyndman, G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2018.
- [80] D. Karaboğa, “Yapay zeka optimizasyon algoritmaları,” *Nobel Akademik Yayıncılık*, vol. 245, 2014.
- [81] W. T. Reeves, “Particle systems—a technique for modeling a class of fuzzy objects,” *ACM Transactions On Graphics (TOG)*, vol. 2, no. 2, pp. 91–108, 1983.
- [82] S. T. I. Paramount, *The wrath of khan (film)*, 1982.
- [83] C. W. Reynolds, “Flocks, herds and schools: A distributed behavioral model,” in *Proceedings of the 14th annual conference on Computer graphics and interactive techniques*, 1987, pp. 25–34.
- [84] F. Heppner, U. Grenander, “A stochastic nonlinear model for coordinated bird flocks,” *The ubiquity of chaos*, vol. 233, p. 238, 1990.
- [85] J. Kennedy, R. Eberhart, “Particle swarm optimization,” in *Proceedings of ICNN’95-International Conference on Neural Networks*, IEEE, vol. 4, 1995, pp. 1942–1948.

- [86] Y. Shi, R. C. Eberhart, "Empirical study of particle swarm optimization," in *Proceedings of the 1999 congress on evolutionary computation-CEC99 (Cat. No. 99TH8406)*, IEEE, vol. 3, 1999, pp. 1945–1950.
- [87] J. Kennedy, "The particle swarm: Social adaptation of knowledge," in *Proceedings of 1997 IEEE International Conference on Evolutionary Computation (ICEC'97)*, IEEE, 1997, pp. 303–308.
- [88] Y. Shi, R. Eberhart, "A modified particle swarm optimizer," in *1998 IEEE international conference on evolutionary computation proceedings. IEEE world congress on computational intelligence (Cat. No. 98TH8360)*, IEEE, 1998, pp. 69–73.
- [89] M. Y. ÖZSAĞLAM, M. ÇUNKAŞ, "Optimizasyon problemlerinin çözümü için parçacık sürü optimizasyonu algoritması," *Politeknik Dergisi*, vol. 11, no. 4, pp. 299–305, 2008.
- [90] S. Raschka, *Python machine learning*. Packt Publishing Ltd, 2015.
- [91] C.-W. Hsu, C.-C. Chang, C.-J. Lin, *et al.*, *A practical guide to support vector classification*, 2003.
- [92] G. E. Box, G. M. Jenkins, "Time series analysis: Forecasting and control san francisco," *Calif: Holden-Day*, 1976.
- [93] Q. Song, B. S. Chissom, "Forecasting enrollments with fuzzy time series—part 1," *Fuzzy Sets Syst.*, vol. 54, no. 1, pp. 1–9, Feb. 1993, ISSN: 0165-0114. DOI: 10.1016/0165-0114(93)90355-L. [Online]. Available: [https://doi.org/10.1016/0165-0114\(93\)90355-L](https://doi.org/10.1016/0165-0114(93)90355-L).
- [94] S.-M. Chen *et al.*, "Forecasting enrollments based on fuzzy time series," *Fuzzy sets and systems*, vol. 81, no. 3, pp. 311–319, 1996.
- [95] T. H.-K. Yu, K.-H. Huarng, "A bivariate fuzzy time series model to forecast the taïex," *Expert Systems with Applications*, vol. 34, no. 4, pp. 2945–2952, 2008.
- [96] S.-M. Chen, Y.-C. Chang, "Multi-variable fuzzy forecasting based on fuzzy clustering and fuzzy rule interpolation techniques," *Information sciences*, vol. 180, no. 24, pp. 4772–4783, 2010.
- [97] S.-M. Chen, C.-D. Chen, "Taïex forecasting based on fuzzy time series and fuzzy variation groups," *IEEE Transactions on Fuzzy Systems*, vol. 19, no. 1, pp. 1–12, 2011.
- [98] S.-M. Chen, H.-P. Chu, T.-W. Sheu, "Taïex forecasting using fuzzy time series and automatically generated weights of multiple factors," *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 42, no. 6, pp. 1485–1495, 2012.
- [99] S.-M. Chen, P.-Y. Kao, "Taïex forecasting based on fuzzy time series, particle swarm optimization techniques and support vector machines," *Information Sciences*, vol. 247, pp. 62–71, 2013.
- [100] Y.-S. Chen, C.-H. Cheng, W.-L. Tsai, "Modeling fitting-function-based fuzzy time series patterns for evolving stock index forecasting," *Applied intelligence*, vol. 41, no. 2, pp. 327–347, 2014.

- [101] Q. Cai, D. Zhang, W. Zheng, S. C. Leung, "A new fuzzy time series forecasting model combined with ant colony optimization and auto-regression," *Knowledge-Based Systems*, vol. 74, pp. 61–68, 2015.
- [102] F. Ye, L. Zhang, D. Zhang, H. Fujita, Z. Gong, "A novel forecasting method based on multi-order fuzzy time series and technical analysis," *Information Sciences*, vol. 367, pp. 41–57, 2016.
- [103] S.-H. Cheng, S.-M. Chen, W.-S. Jian, "Fuzzy time series forecasting based on fuzzy logical relationships and similarity measures," *Information Sciences*, vol. 327, pp. 272–287, 2016.
- [104] S.-M. Chen, W.-S. Jian, "Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups, similarity measures and pso techniques," *Information Sciences*, vol. 391, pp. 65–79, 2017.
- [105] S.-M. Chen, B. D. H. Phuong, "Fuzzy time series forecasting based on optimal partitions of intervals and optimal weighting vectors," *Knowledge-Based Systems*, vol. 118, pp. 204–216, 2017.
- [106] K. Huarng, T. H.-K. Yu, "The application of neural networks to forecast fuzzy time series," *Physica A: Statistical Mechanics and its Applications*, vol. 363, no. 2, pp. 481–491, 2006.

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgileri: busenur.sarica@marmara.edu.tr

Makale

1. B. Kizilaslan, E. Egrioglu, and A. A. Evren, “Intuitionistic fuzzy ridge regression functions,” Communications in Statistics - Simulation and Computation, pp. 1–10, 2019.

Konferans Bildirisi

1. B. Kizilaslan, E. Egrioglu, and A. A. Evren, “Intuitionistic fuzzy liu-type regression functions,” 21st European Young Statisticians Meeting, 2019, p. 33.
2. B. Kizilaslan, E. Egrioglu, and A. A. Evren, “Intuitionistic fuzzy ridge regression functions,” International Conference on Trends and Perspectives in Linear Statistical Inference (LinStat2018), 2018, p. 96.

Ödül

1. **Young Scientists Awards, (2nd):** B. Kizilaslan, E. Egrioglu, and A. A. Evren, “Intuitionistic fuzzy ridge regression functions,” International Conference on Trends and Perspectives in Linear Statistical Inference (LinStat2018), 2018, p. 96.