

**KOCAELİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**DOKTORA TEZİ**

**OTOMOTİV YEDEK PARÇA TALEPLERİNİN TAHMİNİ İÇİN  
BULANIK KÜMELEME MODEL ÖNERİSİ**

**BAŞAK ÖZÇİFT**

**KOCAELİ 2018**

KOCAELİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ  
ANABİLİM DALI

DOKTORA TEZİ

OTOMOTİV YEDEK PARÇA TALEPLERİNİN TAHMİNİ İÇİN  
BULANIK KÜMELEME MODEL ÖNERİSİ

BAŞAK ÖZÇİFT

Prof. Dr. Zerrin ALADAĞ  
Danışman, Kocaeli Üniversitesi  
Prof. Dr. Cemalettin KUBAT  
Jüri Üyesi, Sakarya Üniversitesi  
Doç. Dr. Gülşen AKMAN  
Jüri Üyesi, Kocaeli Üniversitesi  
Doç. Dr. Özer UYGUN  
Jüri Üyesi, Sakarya Üniversitesi  
Dr. Öğr. Üyesi Atakan ALKAN  
Jüri Üyesi, Kocaeli Üniversitesi

  
.....  
  
.....  
  
.....  
  
.....  
  
.....

Tezin Savunulduğu Tarih: 17.07.2018

## **ÖNSÖZ VE TEŞEKKÜR**

Otomotiv yedek parçaları sektöründe ön sıralarda yer alabilmek için parça bulunurluğu olan karşılama oranını yüksek seviyelerde tutmak gerekmektedir. Bunu sağlayabilmek için ise ihtiyaçları doğru tahminlemek gerekmektedir. Doğru tahmin üretmek uygun bir ifade olmasa da daha az hatalı tahminleme yapmak amaçlanmalıdır.

Bu amacı gerçekleştirebilmek için yola çıkmamı sağlayan ve çalışma fırsatı veren yöneticilerim Barış GÜNDÜZ, Barış KARAKAŞ ve Serhan TURFAN'a, tezimin ve doktora eğitimimin her aşamasında beni cesaretlendiren annem Nevin ÜNAL, babam Abdullah ÜNAL, kardeşim Banu ÜNAL, kuzenim Hatice ÜNAL, eşim Alper ÖZÇİFT'e, biricik kızım Lina ÖZÇİFT'e ve önemli katkıları için çok değerli danışman hocam Prof. Dr. Zerrin ALADAĞ'a, çalışmalarım farklı açılardan katkı sağlayan Orkun AŞA'ya ve ayrıca doktora eğitimimdeki maddi desteği için TÜBİTAK'a teşekkür ederim.

Haziran-2018

Başak ÖZÇİFT

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ .....	v
SİMGELER VE KISALTMALAR DİZİNİ .....	vi
ÖZET .....	ix
ABSTRACT .....	x
GİRİŞ .....	1
1. GENEL BİLGİLER.....	4
1.1. Literatür Araştırması .....	4
1.2. Yedek Parça Taleplerinin Yapısı.....	10
1.3. Literatürde Yer Alan Zaman Serisi Temelli Yöntemler.....	11
1.3.1. Brown'ın tek üssel düzeltme yöntemi.....	11
1.3.2. Hareketli ortalama.....	12
1.3.3. Ağırlıklı hareketli ortalama.....	13
1.3.4. Holt'un lineer modeli .....	14
1.3.5. Holt Winters metotları.....	15
1.3.6. Croston'un metodu.....	17
1.3.7. Syntetos ve Boylan'ın metodu .....	18
1.3.8. Bootstrap metodu .....	19
1.3.9. Otoregresif hareketli ortalamalar modeli (ARMA modeli) .....	20
1.3.10. Durağan olmayan doğrusal stokastik model (ARIMA modeli).....	21
1.3.11. S-ARIMA Modeli .....	23
1.4. Performans Ölçütleri .....	23
1.4.1. Ortalama mutlak yüzde hata (Mean absolute percentage error – MAPE) .....	23
1.4.2. Simetrik ortalama mutlak yüzde hata (Symetric-mean absolute percentage error – S-MAPE).....	24
1.4.3. Düzeltilmiş ortalama mutlak yüzde hata (Adjusted mean absolute percentage error – AMAPE) .....	25
1.4.4. Kök ortalama karesel hata (Root mean square error – RMSE).....	25
1.4.5. Göreceli geometrik kök ortalama karesel hata (Relative geometric root-mean square error – RGRMSE) .....	26
1.4.6. Yüzde en iyi (Percentage best – PB).....	26
2. BULANIK SİSTEM MODELLEME.....	28
2.1. Bulanık Kural Tabanlı Bulanık Sistemler .....	28
2.1.1. Zadeh BKT yapısı .....	29
2.1.2. Mizumoto BKT yapısı .....	30
2.1.3. Takagi –Sugeno BKT yapısı .....	32
2.2. Bulanık Fonksiyonlar .....	34
2.3. Bulanık Öbeleme Algoritmaları .....	36
2.3.1. Bulanık öbek ortalama öbeleme metodu.....	37

2.3.2. Bulanık öbek regresyon modelleme (BÖRM) öbekleme metodu .....	42
2.3.3. Höppner & Klawonn'un bulanık model öbekleme metodu .....	45
2.3.4. Bulanık fonksiyon yapılı bulanık model (BFBM) .....	47
2.3.5. Geliştirilmiş bulanık öbekleme (GBÖ) öbekleme metodu .....	49
2.3.6. Öbekleme yaklaşımlarının farklılıkları .....	53
2.4. Bulanık Sistem Modelleme .....	56
2.4.1. Geliştirilmiş bulanık fonksiyonlar ile bulanık sistem modelleme .....	56
2.4.2. BÖRM fonksiyon yapısı ile bulanık sistem modelleme .....	61
2.4.3. BM ve BFBM ile bulanık sistem modelleme.....	63
3. UYGULAMA.....	66
3.1. Yedek Parça Girdi Seçim Kriterleri .....	66
3.2. Bulanık Öbek Ortalamaları ile Bulanık Fonksiyonlar.....	71
3.3. Bulanık Fonksiyonlar ile Bulanık Model .....	77
4. SONUÇLAR VE ÖNERİLER .....	82
KAYNAKLAR .....	85
KİŞİSEL YAYIN VE ESERLER .....	92
ÖZGEÇMİŞ .....	93

## ŞEKİLLER DİZİNİ

Şekil 1.1	Bir yedek parçanın kesikli tüketim örneği .....	10
Şekil 2.1	Mizumoto bulanık çıkarsama yapısı .....	31
Şekil 2.2.	Genelleştirilmiş tip-1 bulanık çıkarsama sistemleri (Bulanık mantık sistemi) .....	32
Şekil 2.3	Takagi Sugeno bulanık çıkarsama yapısı .....	34
Şekil 2.4.	Harmoniklerin görsel gösterimi .....	46
Şekil 2.5.	Geliştirilmiş bulanık fonksiyonlar ile bulanık sistem modelleme.....	57
Şekil 2.6.	GBF ile yapı tanımlama .....	59
Şekil 2.7.	BSMGBF'nin önerilen çıkarsama mekanizması.....	60
Şekil 2.8.	BÖRM ile yapı tanımlama .....	62
Şekil 2.9.	BM ile yapı tanımlama.....	63

## TABLULAR DİZİNİ

Tablo 1.1. Literatürde yer alan zaman serisi temelli yöntemler .....	6
Tablo 1.2. Pegels'in talep yapısı sınıflandırması.....	8
Tablo 2.1. Geçici fonksiyon yapılarına göre algoritmaların karşılaştırılması .....	54
Tablo 2.2. Uzaklık fonksiyonuna göre algoritmaların karşılaştırılması .....	54
Tablo 2.3. Algoritmalara göre geçici fonksiyonların katsayılarını güncelleme .....	55
Tablo 2.4. Algoritmalara göre üyelik güncelleme fonksiyonları.....	55
Tablo 3.1. Tüm deneylerde kullanılan parametre kombinasyonları.....	67
Tablo 3.2. $l=3$ ay geriye dönük veri seti örneği.....	68
Tablo 3.3. Çalışılan bulanık modellerin ortalama AMAPE değerleri .....	69
Tablo 3.4. Tablo 3.3'de verilen bulanık modellerin parametre değerleri.....	69
Tablo 3.5. BÖO ile bulanık fonksiyonlar modeline göre AMAPE değerleri .....	72
Tablo 3.5. BÖO ile bulanık fonksiyonlar modeline göre AMAPE değerleri (devam).....	73
Tablo 3.6. $f=u, um=13$ için 5 farklı deney sonucuna ait AMAPE ve ortalama AMAPE değerleri (Mayıs 2017) .....	75
Tablo 3.7. $f=\{u^2\}=5$ için 5 farklı deney sonucuna ait AMAPE ve ortalama AMAPE değerleri (Mayıs 2017) .....	76
Tablo 3.8. $f=\{u, um\}$ için oluşturulan modelden elde edilen Mayıs 2017 tahminlemesi için öbek doğrulama indeks değerleri.....	77
Tablo 3.9. $f=\{u^2\}$ için oluşturulan modelden elde edilen Mayıs 2017 tahminlemesi için öbek doğrulama indeks değerleri.....	77
Tablo 3.10. BFBM göre AMAPE değerleri .....	78
Tablo 3.11. 3 ay geriye dönük veri seti için 6 aylık tahmin ayı bilgisi kullanılarak yapılan BFBM modeline ait AMAPE sonuçları .....	79
Tablo 3.11. 3 ay geriye dönük veri seti için 6 aylık tahmin ayı bilgisi kullanılarak yapılan BFBM modeline ait AMAPE sonuçları (Devam).....	80
Tablo 4.1. Bulanık sistem modellerinin en iyi parametrelerine göre üssel düzeltilme yöntemi ile karşılaştırılması.....	83

## SİMGELER VE KISALTMALAR DİZİNİ

$a_i$	i. kuralla ilişkili regresyon doğrusu katsayıları,
$A_{ji}$	i kuralında $\mu_{A_{ji}}(x_j): X_j \rightarrow [0,1]$ üyelik fonksiyonuna sahip $x_j$ girdi değişkeni ile ilişkili dilsel etiket,
$b_i$	i. kuralla ilişkili regresyon doğrusu sabiti,
$B_i$	i kuralında $\mu_{B_i}(y): Y \rightarrow [0,1]$ üyelik fonksiyonuna sahip $y$ çıktı değişkeni ile ilişkili dilsel etiket,
$c$	Sabit terim, (bölüm 1.3.9)
$c$	Sistem modelindeki kuralların sayısı, öbek sayısı, (bölüm 2-3)
$C_x$	Kovaryans matrisi,
$d_{ik}^2$	$x_k$ noktasından $v_i$ öbek merkezine olan A – norm uzaklığının karesi
$D_i$	Köşegen matris,
$D_{t-1}$	t-1 dönemine ait trend/yığılma değeri,
$E_{ik}(\beta_i)$	Bulanık öbek regresyon modeli için hata fonksiyonu,
$F_t$	t dönemine ait tahmin değeri,
$G_t$	t anındaki ardışık talepler arasındaki gerçek zamanı,
$J_m^{IFC}$	Geliştirilmiş bulanık öbekleme için amaç fonksiyonu
$J_m$	Bulanık öbek ortalamaları için amaç fonksiyonu,
$k$	Tahmin ayı sayısı,
$l$	Eğitim veri seti geriye dönük ay sayısı
$L_t$	t dönemine ait veriden şimdiye kadar olan tahminlerin mevcut seviyesi,
$m$	Üssel ağırlık, bulanıklık mertebesi
$p$	Varışlar arası zamanların ortalaması, (bölüm 1.3.7)
$p$	Otoregresif kısmın derecesi, (bölüm 1.3.9)
$P_t$	t anındaki ardışık talepler arasındaki düzeltiliş zamanı,
$q$	Hareketli ortalama kısmının derecesi,
$s$	Bir sezondaki dönem sayısı,
$S_t$	t dönemine ait sezonsal endeksi,
$SE_{ik}$	Geliştirilmiş bulanık öbekleme için $y_k$ çıktı değeri ile geçici fonksiyonun değeri arasındaki hata,
$t_i$	Ardışık iki talep arasındaki zaman/açıklık,
$U$	Bulanık bölümlenme matrisi,
$w_t$	t dönemindeki talep değerine verilmiş ağırlık,
$W_t$	ARIMA modeli için zaman serisi verisi,
$X_t$	t anındaki her bir talebin gerçek büyüklüğünü, zaman serisi verisi,
$x_j$	j. girdi değişkeni, $j=1, \dots, n_v$ , $n_v$ girdi değişkenlerinin toplam sayısı
$X_j$	$x_j$ 'nin tanım kümesi,
$y$	Çıktı değişkeni,
$Y$	y'nin tanım kümesi,
$y_i$	i. kuralın, $R_i$ , model çıktısı,
$\hat{Y}_{t+1}$	t+1 dönemine ait tahmin değeri,
$Z_t$	t anındaki her bir talebin düzeltilmiş büyüklüğünü,



$\alpha$	Üssel düzeltme katsayısı,
$\beta$	Trend düzeltme katsayısı,
$\beta_i$	Bulanık öbek regresyon modeli ve bulanık model için fonksiyon parametreleri,
$\gamma$	Sezonsal endeksler için düzeltme katsayısı,
$\gamma_i$	Bulanık fonksiyonlar ile bulanık model fonksiyon parametreleri,
$\varepsilon$	Durdurma parametresini,
$\varepsilon_i$	i dönemindeki yedek parçanın tüketim miktarı,
$\varepsilon_t$	Hata terimi,
$\theta$	Hareketli ortalama parametresi,
$\nu_i$	i öbeğinin merkezi,
$\mu$	Taleplerin ortalaması,
$\mu_i(x_j')$	Her bir i kuralı ve her bir j veri vektörü elemanı için üyelik değeri,
$\mu_{ik}$	i. öbekteki k.vektörün üyelik derecesinin değeri,
$\eta$	Harmonikler için sabit
$\tau_i$	Geliştirilmiş bulanık öbekleme için üyelik değerleri vektörü,
$\tau_i(x')$	Öncüllerin toplanması sonucu i kuralının üyelik değeri,
$\phi$	Otoregresyon model parametresi,
$\Phi_i$	Geliştirilmiş bulanık öbekleme için girdi vektörü
$\hat{\omega}_i$	Geliştirilmiş bulanık öbekleme için fonksiyon parametreleri,
$\  \cdot \ _A$	$R^n$ 'in A – norma bağımlılığı,
$\wedge$	MİN bağlacını kullanan üçgen norm,
$\vee$	MAK bağlacını kullanan üçgen norm,

### Kısaltmalar

ADI	: Average Demand Interval (Talepler Arası Varyasyon Ortalaması)
ADF	: Augmented Dickey-Fuller Test (Birim Kök Testi)
AMAPE	: Adjusted Mean Absolute Percentage Error (Düzeltilmiş Ortalama Mutlak Yüzde Hata)
AR	: Autoregressive (Otoregresif)
ARIMA	: Autoregressive Integrated Moving Averages (Durağan Olmayan Doğrusal Stokastik Model)
ARMA	: Autoregressive Moving Averages (Otoregresif Hareketli Ortalamalar)
BFBM	: Bulanık Fonksiyonlar ile Bulanık Model
BKT	: Bulanık Kural Tabaları
BM	: Höppner & Klawonn'un Bulanık Modeli
BSM	: Bulanık Sistem Modelleme
BSMGBF	: Bulanık Sistem Modeli Geliştirilmiş Bulanık Fonksiyonlar
BÖO	: Bulanık Öbek Ortalama
BÖRM	: Bulanık Öbek Regresyon Modeli
CV	: Coefficient of Variance (Varyans Katsayısı)
GBÖ	: Geliştirilmiş Bulanık Öbekleme
GBF	: Geliştirilmiş Bulanık Fonksiyonlar
İSE	: Mantıksal Gerektirme Bağlacı,
KURAL	: Bulanık Kuralların Model Çıktılarını Toplamak İçin Kullanılan Mantıksal Bağlaç,

MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MA	: Moving Averages (Hareketli Ortalamalar)
PB	: Percentage Best (Yüzde En İyi)
RGRMSE	: Relative Geometric Root-Mean Square Error (Göreceli Geometrik Kök Ortalama Karesel Hata)
RMSE	: Root Mean Square Error (Kök Ortalama Karesel Hata)
S-ARIMA	: Seasonal Autoregressive Integrated Moving Averages (Sezonsal Durağan Olmayan Doğrusal Stokastik Model)
S-MAPE	: Symetric-Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hata)
T-S	: Takagi-Sugeno
'üi'	: Üyelik İlişkisinde İse - Atamanın Veya Tanımlamanın Kesin Olmadığını Gösterir,
VE	: Her Kuralın Ateşleme Derecesini Bulmak İçin Verilen Bir Gözlem İçin Girdi Değişkenlerinin Üyelik Değerlerinin Toplamak İçin Kullanılan Mantıksal Bağlaç,

## OTOMOTİV YEDEK PARÇA TALEPLERİNİN TAHMİNİ İÇİN BULANIK KÜMELEME MODEL ÖNERİSİ

### ÖZET

Bu çalışmada, bir otomotiv şirketi için yedek parça taleplerinin tahmini için bulanık kümeleme modeli önerilmiştir. Bulanık modelleme yaklaşımına bulanık fonksiyon yapısını yani üyelikleri ve/ya üyelikler ile girdi değişkenlerinin çarpımlarını dahil ederek yeni bir öbeleme algoritması önerilmiştir. Buna bağlı olarak, sistemi modellemek için bulanık modelleme çıkarsama algoritması kullanılmıştır. Bu algortima öbeleme algortimasına üyelikerin dahil edilmesi sebebi ile modifiye edilmiştir. Önerilen modelleme yaklaşımı, literatürde yer alan önceki modeller ile gerçek veri üzerinden karşılaştırılmıştır. Çalışmada, veriye en uygun modeller ve bu modellere ait parametreler saptanmıştır. Önerilen model, uygulamaya konu yedek parça verisi için diğer modellere ile karşılaştırıldığında AMAPE ölçütüne göre daha iyi performans göstermiştir.

**Anahtar Kelimeler:** Bulanık Modelleme, Bulanık Öbeleme, Yedek Parça Talep Tahmini.

## **FUZZY CLUSTERING MODEL PROPOSAL FOR FORECASTING AUTOMOTIVE SPARE PART DEMANDS**

### **ABSTRACT**

In this study, a fuzzy clustering model is proposed for an automotive firm to forecast spare part demands. A new fuzzy function structure is proposed to fuzzy modeling approach by adding memberships and/or multiplying memberships and input variables. Correspondingly, fuzzy modeling inference algorithm is used for modeling the system. This algorithm is modified due to adding the memberships to the clustering algorithm. Proposed modeling algorithm is compared with the earlier models in literature by real data. In this study, the proper models to the data and the parameters belong to the models are determined. Suggested model is performed better than by comparing with other models for the spare part data subject to this application by AMAPE measure.

**Keywords:** Fuzzy Modelling, Fuzzy Clustering, Spare Part Demand Forecasting.

## **GİRİŞ**

Endüstriler servis kalitesini cevap verme süresi olarak ölçmektedirler, bu da müşteri sorununu bildirdikten itibaren tamire veya yedek parça değişimine kadar geçen süreyi kapsar. Yüksek servis kalitesi sağlamak için üreticiler, merkezi depo veya servis sağlayıcılar cevap verme süresini en aza indirmek için depolarında parça stoklamaktadırlar. Yedek parçalar pahalıdırlar ve zamanla değerini kaybetme ve/veya devre dışı olma riski ve maliyetlerini barındırırlar. Dolayısıyla, bu durum üreticileri/merkezi depo yöneticilerini stok seviyelerini oldukça düşük seviyede tutmaya zorunlu kılmaktadır. Çelişen bu durum uygun stok politikası belirlenerek, talebin doğru tahminlemesi ile doğru bir dengeye oturacaktır.

Cevap verme süresinde müşteri beklentisinin karşılanması stok politikasına bağlıdır. Eğer talep edilen yedek parça stoklarda ise müşteri ihtiyacı hızla yanıtlanacaktır ve cevap verme süresi önemini yitirecektir. Diğer taraftan talep edilen yedek parça stoklarda mevcut değil ise, cevap verme süresi yedek parçanın değişim / tamir süresine ek olarak tedarik sürelerini de içerecektir.

Otomotiv ve uzay endüstrisini karakterize eden bazı önemli noktalar; yüzlerce hatta binlerce yedek parça ve müşteri, düşük arızalanma oranları, sıkı cevap verme süreleri, çok sayıda yedek parça servis sağlayıcısı ve her depoda her parçadan içerecek temel bir stok politikasıdır.

Otomotiv yedek parçalarında ortaya çıkacak talep yalnızca arızalanmaya bağlı değildir, aynı zamanda araçların periyodik bakım kapsamında yedek parça ihtiyaçları bulunmaktadır. Diğer taraftan kazalar sebebi ile ortaya çıkan parça değişim ihtiyaçları da söz konusudur. Dolayısıyla ihtiyaç tek bir sebepten değil birden çok sebepten kaynaklanabilmektedir. Zaten yedek parça talepleri sürekli bir talep içermediği için bu tip bir belirsizliğin sisteme dahil olması tahminlemeyi daha da güçleştirmektedir.

Literatürde yedek parça taleplerin tahmini için önerilen başlıca yöntemler hareketli ortalama, ağırlıklı hareketli ortalama, tek üssel düzeltme, Holt'un Lineer Modeli, Holt-Winter metodu, Croston'un metodu, Syntetos ve Boylan'ın metodu, Bootstrap metodu ve son zamanlarda gelişmekte olan yapay sinir ağları ile geliştirilen modeller gibi metodlar bulunmaktadır. Yapılan literatür incelemeleri sonucu yedek parça talep tahminlemede bulanık sistem modelleme ile ilgili bir çalışmaya rastlanmamıştır.

Bu tez kapsamında bir otomotiv firması için yedek parça taleplerinin tahminlemesi bulanık sistem modelleme ile yapılacaktır.

Bulanık sistem modelleri, klasik matematik modellerin tatmin edici sonuçlar ortaya koymada başarısız olduğu belirsiz ve tam olarak açıklanmamış sistemlerin karmaşıklığı ile başa çıkmaya çalışmaktadır. (Ünal, 2009) Bulanık sistemler, bulanık kümeler ve bulanık mantık teorilerini temel alır. Bulanık sistemler belirsizlik içeren kavramları barındıran sistemler için kullanışlıdır. Genellikle bulanık sistemler; modellemede bulanık kural tabanlarını ve girdi çıktı değişkenlerinin üyelik fonksiyonlarının birlikte kullanılması ile yapılandırılır. Bu modellerde, "Eğer ... ise..." kuralları girdi çıktı ilişkilerinin ifade edilmesinde kullanılır.

Sistem en yaygın tanımıyla birbirleri ile etkileşim içerisinde bulunan elemanlar bütünüdür. Bu elemanlar çoğunlukla anlamlı bir bütün oluşturma amacı ile bir araya gelirler. Sistemdeki elemanlar girdiler ve çıktılar olup, bunlar arasındaki ilişkiyi tanımlayan ifadeye model denir. Eğer sistemdeki elemanlar arasındaki ilişkiler bilinmiyorsa, sistemin modellenmesi ihtiyacı ortaya çıkar. Algoritmik tekniklerin mantıksal çıkarım ve buluşsal teknikler ile harmanlanması ile popülerliği giderek aratan bir yaklaşım da akıllı sistemlerdir. Bulanık mantık, yapay sinir ağları ve genetik algoritmalar gibi teknikler klasik yapay zeka kavramlarından türetilmiştir (Ünal, 2009).

Bu tez kapsamında yedek parçaların talep tahminlemede bulanık fonksiyonların kullanımını barındıran sistem modelleme yaklaşımları kullanılacaktır. Bulanık Kural Tabanları (BKT) ile sistem modelleme klasik Bulanık Sistem Modelleme (BSM) yöntemleridir. BKT; hesaplama gücü, optimizasyon problemleri ve öznellik gibi bir takım güçlükleri beraberinde getirir. Bu yaklaşımlar birden çok girdi değişkeni içeren ve bir çıktı değişkenine sahip sistemlerin modellenmesi için önerilmiştir,

dolayısıyla sonraki dönemin talebinin tahminlenmesinde kullanılabilir bir modelleme yöntemi olarak denenecektir.

Bulanık fonksiyonlar ile bulanık sistem modelleme yaklaşımı, bulanık kural tabanlı bulanık sistem modellerinden farklı olarak fonksiyon yapısında üyelik değerlerini de kullanır. Üyelik değerleri “atomlar” gibi düşünülebilir ki, sahip olduğu gücü ortaya çıkarmak için aktive edilecek sistem davranışı ile ilgili potansiyel bilgiyi tutar. Üyelik değerlerinden saptanan böyle potansiyel bilgi sistem davranışının tahmin edicileri olan yerel bulanık fonksiyonlarda tutulur (Ünal, 2009). Bulanık kural tabanı yapılarının yerine, verilen bir sistem için modellerin oluşturulmasında bulanık fonksiyonlar kullanılır (Celikyılmaz ve Turksen, 2009; Turksen, 2008).

İlk bölümde literatür araştırması ve literatürde yer alan genel yöntemler ile ilgili özet bilgiler verilecektir. İkinci bölümde bulanık sistem modellemede kullanılacak model yapıları detaylı bir şekilde ele alınacaktır. Üçüncü bölümde yapılan çalışmaya ait deney sonuçları ve bulgular verilecektir. Son olarak da; bulanık sistem modelleme ile yapılan çalışma, incelenen sistemde mevcutta kullanılan tek üssel düzeltme yöntemi ile karşılaştırılarak sonuçlar ve öneriler özetlenecektir.

Bu çalışma ile yedek parça talep tahminlemede bulanık sistem modelleme ile modelleme yapılabirliği sınanacak, literatürde bu konuda çalışma olmamasının nedenleri tartışılacaktır.

## 1. GENEL BİLGİLER

### 1.1. Literatür Araştırması

Bir merkez deponun yedek parça envanteri, otomobil tedarik zincirleri ve lojistik sistemlerinin operasyonel maliyetlerinin azaltılması ve hizmet seviyelerinin artırılmasında önemli rol oynar (Li ve Kuo, 2008). Arzu edilen servis düzeyini sağlamayı garanti altına almak ve satış sonrası servisleri sağlayabilmek için tedarik zincirinde uygun noktalarda yedek parça stoklarının bulunurluğu sağlanmalıdır. Bu tür parçaların çoğu oldukça pahalı olduğundan büyük miktarlarda paranın yatırımını gerektirdiği Botter ve Fortuin (2000) tarafından vurgulanmıştır. Gallagher ve diğ. (2005) çalışmalarında otomotiv yedek parça işinin dünya çapında tüm yedek parça endüstrisi içerisinde %25'lik bir yer kaplayarak 50 milyon \$'lık bir hacme sahip olduğunu göstermişlerdir.

Sipariş karşılama oranının maksimize etmek ve otomobilleri çalışır durumda tutabilmeyi sağlayacak bir bakım kadrosu asiste etmek için, merkez deponun büyük bir güvenlik stoğu tutması gerekmektedir. Sonuç olarak, büyük bir para bağlanmış olur ve envanter maliyeti hızlı bir biçimde artar. Dolayısıyla, sipariş karşılama oranını arttırırken, envanter maliyetlerinin azaltılması son yıllarda odak çalışma konusu haline gelmiştir.

Bu zamana kadar, literatür dikkatini, yedek parça envanter yönetiminde genellikle, istatistik prosese dayalı talep değişimi varsayımı üzerinde yoğunlaştırmıştır (Kennedy ve diğ. 2002). Sonuç olarak, güvenlik stoğu ve kayıt noktası her zaman statik ve sabit olarak dikkate alınır. Aslında, otomobil yedek parçaları endüstrisinde, talep gitgide daha değişken ve belirsiz hale gelmektedir. Talepteki bu tip dalgalanmalar, bazen son müşterinin otomobilindeki belirsiz koşullardan ileri gelebilmekte, fakat oldukça sık olarak tedarik zinciri talep belirsizliğinde önemli bir kaynaktır (ör. kırbaç etkisi; Lee ve diğ., 1997).



Bu durumda, tahminleme merkez depoda otomobil yedek parçalarının yönetimini vadetmektedir. Dolayısıyla, son yıllarda, birçok araştırmacı çalışmalarını, hizmet seviyesinin geliştirilmesi ve envanter maliyetlerinin azaltılmasına yardımcı olarak yedek parçaların talep tahmini üzerine odaklanmaktadır. Literatürün çoğu yedek parça tahminlemesi üzerine modeller ve algoritmaların tartışılması ve analizi üzerinedir. Ancak, bunların çok azı yerel depoları, final bakım istasyonlarını ve dahili ve deniz aşırı imalatçıları besleyen, merkez depodaki otomobil yedek parçalarının üzerinedir. Yedek parçaların talep tahminlerinde geleneksel yaklaşımlar yöneticilerin bilgi ve deneyimini temel alan yönetici kararını, analog yaklaşımı (Applebaum, 1996), zaman serilerini ve regresyon modellerini içerir.

Cohen ve Agrawal (2006) yayınladıkları makalede yedek parça endüstrisinin ne kadar büyük olduğunu rakamlarla ortaya koymaktadırlar. Boylan ve Syntetos (2010) taleplerin kesikli veya hem kesikli hem de kararsız oluşlarının talep tahminlemeyi zorlaştırdığını vurgulamışlardır. Bunlar uğraştığımız problemin karmaşıklığının ve büyüklüğünün bir göstergesidir.

Ghobar ve Friend (2003) teorinin pratiği ne derece yansıttığını göstermek için 13 farklı tahmin metodunu sınıamışlardır. Çalışmalarında; Winter'ın Toplamlı Sezonallık (Markidakis ve diğ., 1998; Winters, 1960), Winter'ın Çarpımlı Sezonallık (Markidakis ve diğ., 1998; Winters, 1960), Sezonl Regresyon Modeli (Ragsdale ve Plane, 2000), Bileşen Servis Ömrü (Bowser, 1994), Talep Oranlarının Ağırlıklı Hesaplaması (Boylan ve diğ., 2008), Talep Tahminleyicilerin Ağırlıklı Regresyonu (Boylan ve diğ., 2008), Croston (1972), Tek Üssel Düzeltme (Markidakis ve diğ., 1998), Üssel Ağırlıklı Hareketli Ortalama (Holt, 2004), Trend Ayarlı Üssel Düzeltme (Sharaf ve Helmy, 2001), Ağırlıklı Hareketli Ortalama (Markidakis ve diğ., 1998), Çift Üssel Düzeltme (Persson ve Sacconi, 2009), Uyarlamalı Cevap Oranlı Tek Üssel Düzeltme (Markidakis ve diğ., 1998) yöntemlerini karşılaştırmışlardır. Sonuç olarak; Üssel Ağırlıklı Hareketli Ortalama ve Croston'un tahminleme metodlarının diğerlerine göre oldukça başarılı sonuçlar verdiği vurgulanmıştır. Literatürde yer alan ve tez kapsamında değinilecek olan zaman serisi temelli yöntemler Tablo 1.1'de verilmiştir.

Tablo 1.1. Literatürde yer alan zaman serisi temelli yöntemler

<b>Sınıf</b>	<b>Tahminleme Yöntemi</b>	<b>Referans</b>
Geleneksel Zaman Serisi Yaklaşımları	Hareketli Ortalama, Üssel Düzeltme, Üssel Ağırlıklı Hareketli Ortalama	(Brown, 1959), (Brown, 1962), (Markidakis ve diğ., 1998)
Değiştirilmiş Geleneksel Zaman Serisi Yaklaşımları	Ayarlamalı Üssel Ağırlıklı Hareketli Ortalama, Ayarlamalı Holt Metodu, Holt-Winters Metodu	(Johnston ve Boylan, 1996), (Bermudez ve diğ., 2006), (Altay ve diğ., 2008)
Croston'un Metodu ve Değiştirilmiş Versiyonları	Croston, Syntetos & Boylan Yaklaşımı, Croston'un Değiştirilmiş Yaklaşımı	(Croston, 1972), (Rao, 1973), (Schultz, 1987), (Syntetos ve Boylan, 2001), (Syntetos ve Boylan, 2005), (Leven ve Segerstedt, 2004)
Önyükleme Metodu	Değiştirilmiş Bootstrap Metodu	(Snyder, 2002), (Willemain ve diğ., 2004)
Talep Toplama / Ayrıştırma	Filtreleme / Öbekleme Metodu	(Kalchschmidt ve diğ., 2003), (Kalchschmidt ve diğ., 2006)

Boylan ve Syntetos (2010) tarafından geliştirilen tahmin destek sistemi 3 bileşenden oluşmaktadır. Bunlar; ön işleme, işleme ve son işlemedir.

Ön işleme süreci; hızlı veya yavaş hareket gören, kesikli veya hem kesikli hem kararsız olup olmadığına dair kuralları içerir. Williams yavaş hareket gören öğeler ile ilgili problemi ortaya koymuştur (Williams, 1984). Burada en temel kriter, sınıflandırma yaparken kategorizasyonun nasıl yapılacağına net bir şekilde ortaya konması gerekliliğidir. Syntetos ve diğ. (2005) kesikli ve kesikli olmayan talep öğeleri için tasarlanmış metodların performanslarını hangi tahminleme metodunun daha üstün olduğuna dair kuralları çıkarsamak için karşılaştırmıştır. Sınıflandırma değişkenleri (i) talepler arası ortalama zaman ve (ii) talep büyüklüklerinin varyans katsayısı olarak belirlenmiştir. Bu yaklaşım Boylan ve diğ. (2008) tarafından otomobil yedek parçaları sisteminde uygulanmıştır, ayrıca sistem performansının hangi kesişim noktalarında daha gürbüz olduğu belirlenmiştir.

İşleme; ön işleme yani sınıflandırma fazı tamamlandıktan sonra uygun tahmin metodunun uygulanmasını ifade eder. Hızlı hareket gören yedek parçalar için genel ve yaygın yöntem üssel düzeltme ve yöntemin çeşitli varyasyonlarıdır. Kısa talep geçmişine sahip hızlı hareket gören parçalar için sezonsal bileşenlerin tahmini oldukça

zor olabilmektedir, bunun için Miller ve Williams (2003) sezonsal tahminleri indirgeyerek bir “daraltma” metodu önermişlerdir. Dekker ve diğerleri (2004), Holt-Winters metodunun seviye ve trendi öge bazında, sezonsallığı ise grup bazında olduğu bir varyasyonunu önermişlerdir.


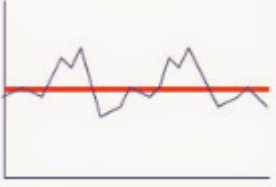
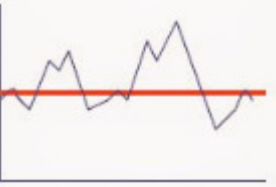

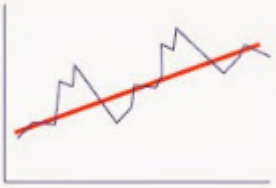
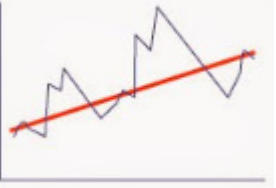
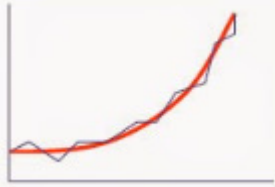

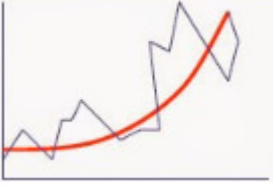
Son işleme kullanıcı tarafından istatistiksel tahminle yapılan ayarlamayı ifade eder. Yönetici düşüncelerini yansıtan eleştirel metotlar pratikte sıklıkla uygulanmaktadır (Klassen ve Flores, 2001; McCarthy ve diğ., 2006). Tahmin doğruluğunda empirik bulgular karmaşık sonuçlar sergilemektedir (O’Connor ve diğ., 1993; Sanders ve Ritzman, 2001). Boylan ve Syntetos (2010) çalışmalarında yavaş hareket gören ögeler için bazı pozitif sonuçlar sunmuştur.

Croston’un yöntemi esasen talep yapısının doğasını ortaya çıkaran bir metottur ki talepler arası varışları ve talep büyüklüğünü dikkate alır. Aslında talepler arası açıklıkları ve talep büyüklüklerinin dikkate alındığı tek üssel düzeltme yapısını kullanmayı önermektedir (1972). Synder (2002), Croston’un metodunu teorik olarak incelemiş ve modeli istikrarsız olarak bulmuştur. Shenstone ve Hydman (2005), Croston’un modeli ile birlikte stokastik modellemeye dayandırdıkları 3 farklı modelin de kesikli talepler için istikrarsız olduğunu vurgulamışlardır.

1950’lerin sonuna doğru Holt, Brown ve Winters zaman serilerinde üssel düzeltme yöntemini kullanarak talep tahmin çalışmalarına yeni bir bakış açısı kazandırmışlardır. Holt tek üssel düzeltme yöntemine zaman serilerinde trend etkisini dikkate alan çift üssel düzeltme yöntemini geliştirmiştir. Brown ise Holt’un geliştirdiği çift üssel düzeltme yöntemi üzerinde çalışmalar yapmıştır. Winters ise literatürde de Holt-Winters metodu olarak yer alan yöntemi Holt’un geliştirdiği yöntemde sezonsal etkinin de dikkate alınması ile geliştirilen yeni bir yöntem ortaya koymuştur.

Pegels (1969) ise tek üssel düzeltme, Holt’un ve Winters’in metodlarını kullanarak ve talep yapısını 9 farklı sınıfa ayırmayı önermiştir. Bu sınıflandırma yapısı Tablo 1.2 ile verilmiştir.

Tablo 1.2. Pegels'in talep yapısı sınıflandırması

	Sezonsallık Yok	Lineer Sezonsallık	Lineer Olmayan Sezonsallık
Trend Yok			
Lineer Trend			
Lineer Olmayan Trend			

Tahmin alanında yapay sinir ağı uygulamaları oldukça tatminkardır. Son yıllarda, örnek veri küme seti temel alınarak birçok önemli faktörün tahminlemede YSAların nasıl kullanıldığı üzerine birçok araştırma mevcuttur. Birçok uygulama alanını içinde talep tahmini odaklanılmıştır (Charytoniuk ve diğ., 2000; Gorucu ve diğ., 2004).

Son zamanlarda, yapay sinir ağı talep tahmin problemlerinin çözümünde en popüler metot olarak uygulanmaya başlamıştır. Ancak, geleneksel yapay sinir ağları çalışılmamış örneklerin tahminlenmesinde düşük doğruluk problemine sebep olmaktadır. Dolayısıyla, Genetik Algoritmalar, bulanık sistem ve uzman sistemler gibi birçok yapay zeka tekniğini temel alarak geliştirilmiş birçok yapay sinir ağları mevcuttur.

Kuo (2001) pazarlama uzmanlarından promosyon saptaması için EĞER-İSE bulanık kuralları öğrenmesi için genetik algoritma ile ilk ağırlıkların oluşturulması ile bir bulanık sinir ağı önermiştir. Bu yöntemden gelen sonuç yapay sinir ağı tahmini ile daha entegredir. Uygun bir depo firması için model değerlendirme sonuçlarına göre, önerilen sistem geleneksel istatistiksel metoda ve tekli yapay sinir ağına göre daha doğru performans sağlamaktadır. Senjyu ve diğ. (2005) kısa dönemli yük tahmin

problemleri için yapay sinir ağı ve bulanık kuralların kombine ederek bir yaklaşım sunmuşlardır. Uzman bilgisi ile yapılandırılan bulanık kurallar, sonraki günün tahmini yük bilgisinin saptanması için sinir ağının çıktısını düzeltmek için kullanılırlar. Test sonuçları, önerilen tahminleme metodunun tahmin doğruluğunda kayda değer bir gelişme sağladığını göstermiştir. Chu ve Zhang (2003) toplu perakende satış tahmini için doğrusal ve doğrusal olmayan çeşitli modellerin tahmin doğruluğunu karşılaştırmışlardır. Doğrusal olmayan modellerin doğrusal olan emsallerinden daha üstün performans gösterdiğini, verinin öncelikle sezonsal düzeltilmesi sinir ağı modellerinin tahmin performansını belirgin şekilde arttırdığını göstermişlerdir.


Literatür incelemesinde yapay sinir ağı uygulamalarının zaman serisi bilgisine ek başka birtakım bilgilerin de işlenmesi ile çalıştığı gözlemlenmiştir. Li ve Kuo (2008) “Merkezi Depoda Otomobil Yedek Parçaları için Envanter Yönetim Sistemi” başlıklı çalışmalarında talep faktörünün yanı sıra; parçaya ait bazı özellikleri, talep faktörleri olarak son 20 yılda ve son 3 yılda satılmış araç sayısı, zaman faktörü olarak sezonsallık gibi faktörlerin de dikkate alındığı bir yapı önermektedirler. Dolayısıyla önerilen yapı oldukça karmaşık bir veri toplamayı gerektirmektedir.

Son birkaç on yılda, yapı tanımlama ve parametre tahminleme üzerine sezgisel yaklaşımlar (Bagis, 2008), kuvvet vektör öğrenme mekanizması (Chiang ve Hao, 2004) vb farklı metodlar bulunmuştur. Sezgisel yaklaşımdan farklı olarak bulanık öbeleme tekniği veri uzayını bölümlendiren iyi yapılandırılmış bir yaklaşımdır. Literatürde birçok gelişmiş bulanık öbeleme algoritmaları mevcuttur, örneğin FCM (Bezdek vd., 1984, Pal vd., 2005), Gath-Geva (1989), Gustafson-Kessel (1978) (Babuka vd., 2002), Vektör Kuantumlama (Sentés vd., 1998), Çıkarmalı Öbeleme (Vernieuwe vd., 2006), ve Çevrimiçi Öbeleme Algoritmaları (Angelov ve Filev, 2004) gibi. Jiao, Shang ve diğerlerinin çalışmalarında (2012, 2016) kavramsal olarak birçok farklı öbeleme algoritması bulunabilir. Huang ve Chen’in (2016), Deng vd’nin (2015) ve Heydari vd’nin (2016) Takagi-Sugeno-Kang modelleme alanında farklı çalışmalar bulunmaktadır. Dam ve Deb’in (2017) çalışmaları da dinamik sistem verisini takip edebilmek için yine TS bulanık model ile öbeleme yapan bir algoritma sunmaktadır.

Ayrıca yine literatürde karşımıza çıkan problemlerden birisi de yapılan tahminlemelerde kullanılan parça sayısının sınırlılığıdır, oysa gerçekte özellikle de yedek parça sistemleri için yüzlerce parça için tahminlemeye ihtiyaç duyulmaktadır.

## 1.2. Yedek Parça Taleplerinin Yapısı

Yedek parça talepleri çok özeldir. Çoğu durumda, düzensiz zaman aralıklarında ve çok farklı miktarlarda olabilmektedir. Bu durum Şekil 1.1’de gösterilmiştir.



Şekil 1.1 Bir yedek parçanın kesikli tüketim örneği

$\varepsilon_i$ = yedek parçanın tüketim miktarı

$t_i$ = ardışık iki talep arasındaki zaman/açıklık

Yedek parça taleplerindeki bu çift karakterli durumu değerlendirmek için literatürde iki parametre tanıtılmıştır. Bunlar;

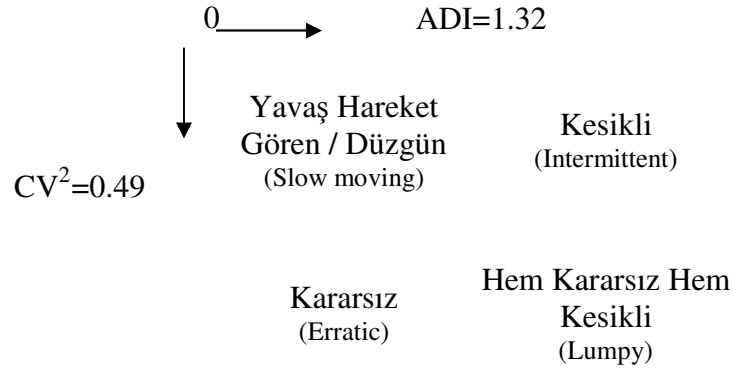
- ADI – Talepler arası varışların ortalaması: bir yedek parça için iki talep arasındaki zamanların ortalaması,
- CV – Varyans katsayısı: Talebin ortalama talebe bölünmesi ile elde edilen standart hatadır;

$$ADI = \frac{\sum_{i=1}^N t_i}{N} \quad (1.1)$$

$$CV = \frac{\sqrt{\frac{\sum_{i=1}^N (\varepsilon_i - \varepsilon)^2}{N}}}{\varepsilon} \quad (1.2)$$

$$\varepsilon = \frac{\sum_{i=1}^N \varepsilon_i}{N} \quad (1.3)$$

Denklem (1.1)'de verildiği üzere; ADI için N "0" olmayan talepler için periyodların sayısını gösterirken, Denklem (1.2)'de verildiği üzere CV için N tüm periyodların sayısıdır.



Şekil 1.2 Yedek parça taleplerinin kategorizasyonundaki temel motif

Ghobbar ve diğerleri (2003) yedek parça taleplerinin kesiklilik durumunu standart hale getirmek ve daha detaylı bir karakterizasyon sağlamak için “kesim değerleri” önermişlerdir. Şekil 1.2 yedek parçalar için kesim değerleri ile birlikte dört kategori göstermektedir.

Yedek parça taleplerinin kategorizasyonundaki dört temel motif:

- Yavaş hareket gören / Düzgün: Bu kategorideki kalemler düşük rotasyon görmektedir.
- Kesikli: Yoğun olarak ara sıra ortaya çıkan bir talebe sahip (bir çok periyodun “0” taleple geçildiği) kalemlerdir.
- Kararsız: Talep miktarının oldukça değişken olduğu fakat, talep aralıklarının düzgün olduğu kalemlerdir.
- Hem kararsız hem kesikli: kontrolü en zor olan kategoridir, çünkü hem “0” talepli dönemler çoktur, hem de talep miktarındaki dalgalanma çok yüksektir.

### 1.3. Literatürde Yer Alan Zaman Serisi Temelli Yöntemler

#### 1.3.1. Brown’ın tek üssel düzeltme yöntemi

Bu yöntem geçmiş veriye ait gözlemlerin hepsinin eşit olarak değil, en yeni gözlemin daha fazla ağırlıklandırılmasına dayanan bir yöntemdir. Bu yöntem üssel ağırlıklandırılmış hareketli ortalamalar yöntemi olarak da anılabilmektedir. Üssel düzeltme yönteminin kullanılmasındaki temel düşünce talepte tesadüfi dalgalanmaların etkilerini gidererek genel yönelime uygun bir tahminde bulunabilmektir.

$\alpha$  üssel düzeltme katsayısı veya üssel sabit olarak adlandırılır ve 0 ile 1 arasında değerler alır. Literatürde 0,1 ile 0,4 arasında değer aldığı vurgulanmaktadır (Callegaro, 2010),

$$L_t = \alpha Y_t + (1-\alpha)L_{t-1} \quad (1.4)$$

Denklem (1.4)'de L veriden şimdiye kadar olan tahminlerin mevcut seviyesini (yerel ortalama değer) göstermektedir. L'nin t zamanındaki değeri kendinin bir önceki değerinden özyinelemeli olarak hesaplanmaktadır. Dolayısıyla, mevcut düzeltilmiş değer önceki düzeltilmiş değer ile mevcut gözlem arasındaki interpolasyondur.  $\alpha$  burada en son gözlemin interpolasyonlu değerine olan yakınlığını kontrol eder. Bir sonraki döneme ait tahmin basit olarak; mevcut düzeltilmiş değerdir ve bu aşağıdaki gibi gösterilir;

$$\hat{Y}_{t+1} = L_t \quad (1.5)$$

Böylece, bir sonraki döneme ait tahmini önceki döneme ait tahminler ve önceki döneme ait gözlemler şeklinde ifade edebiliriz;

$$F_{t+1} = \hat{Y}_{t+1} = \alpha Y_t + (1-\alpha)\hat{Y}_t \quad (1.6)$$

Denklem (1.6) ifadesi önceki dönemlerde gerçekleşmiş gözlemler cinsinden tekrar ifade edildiğinde;

$$F_{t+1} = \hat{Y}_{t+1} = \alpha[Y_t + (1-\alpha)Y_{t-1} + (1-\alpha)^2 Y_{t-2} + (1-\alpha)^3 Y_{t-3} + \dots] \quad (1.7)$$

olarak yazılır.

### 1.3.2. Hareketli ortalama

Hareketli ortalama kendinden önceki n adet verinin ortalamasıdır. Denklem (1.8)'de gösterildiği gibi formüle edilir;

$$F_t = \frac{Y_{t-1} + Y_{t-2} + \dots + Y_{t-n}}{n} \quad (1.8)$$

Denklem (1.8)'de,  $F_t$  t dönemine ait tahmin değeri,



$Y_i$ ,  $i$ :  $t-1, t-2, \dots, t-n$  değerler alırken gerçekleşmiş talep değerleri,

$n$  tahminlemede kullanılacak toplam dönem sayısını, göstermektedir.

Uygulaması oldukça basit olmasına rağmen bu metot yalnızca yavaş hareket eden taleplerde uygulanabilmektedir. Diğer bir ifade ile gözlemler arasındaki sapmaların çok yüksek olmadığı verilerde daha başarılı sonuçlar sunmaktadır. Uzun dönem tahminlerde hareketli ortalama modelinin yatay düz bir çizgi ile gösterilebildiği düşünülebilir, yani verinin herhangi bir trend izlemediği varsayımı vardır.

Bu yöntemde  $n$ 'in kaç alınması gerektiği konusu tartışmaya açıktır. Genel görüş çok fazla geçmiş verinin dikkate alınmaması yönündedir. Pratikte;  $n$  2 ile 10 arasında değer almaktadır (Taha, 1992). Ancak en uygun  $n$  değeri ortalamadan en az tahmin hatasını veren değer olarak belirlenebilir (Nau).

### 1.3.3. Ağırlıklı hareketli ortalama

Ağırlıklı hareketli ortalama metodu güncel verinin tahminlemede daha etkin olduğu düşüncesinden hareketle, daha güncel olan verinin daha büyük katsayılar ile ağırlıklandırmasına dayanır;

$$F_t = \frac{1}{n} \sum_{t=t-n+1}^t w_t Y_t \quad (1.9)$$

Denklem (1.9)'da,  $F_t$   $t$  dönemine ait tahmin değeri,

$Y_i$ ,  $i$ :  $t-1, t-2, \dots, t-n$  değerler alırken gerçekleşmiş talep değerleri,

$w_i$ ,  $i$ :  $t-1, t-2, \dots, t-n$  değerler alırken talep değerlerine verilmiş ağırlıkları,

$n$  tahminlemede kullanılacak toplam dönem sayısını, göstermektedir.

Bu yöntemin en büyük dezavantajı ağırlık katsayılarının tecrübeye veya deneme yanılmaya bağlı olarak seçilmesidir. Aynı zamanda hareketli ortalamalar yönteminde olduğu gibi yine  $n$  dönem sayısının da net olarak bilinmemesi bir diğer dezavantajdır.

### 1.3.4. Holt'un lineer modeli

Tek üssel düzeltme yönteminde talebin mevsimsel veya trende dayalı bir eğilim izlemediği, ortalama etrafında rasgele dağıldığı varsayımı geçerlidir. Holt'un metodunda ilk olarak modele trend eklenmektedir. Bu da yığılmanın yani trendin D ile gösterimi ile Denklem (1.10)'daki gibi ifade edilmektedir;

$$L_t = \alpha Y_t + (1-\alpha)(L_{t-1} + D_{t-1}) \quad (1.10)$$

Denklem (1.10)'da,  $L_t$  t dönemine ait düzeltilmiş değeri,

$Y_i$ , i: t-1, t-2, ..., t-n değerler alırken gerçekleşmiş talep değerleri,

$D_{t-1}$ , t-1 dönemine ait trend/yığılma değerini,

$\alpha$ , üssel düzeltme katsayısını,  $0 \leq \alpha \leq 1$ ,

$$D_t = \beta(L_t - L_{t-1}) + (1-\beta)D_{t-1} \quad (1.11)$$

Denklem (1.11)'de,  $\beta$ , trend düzeltme katsayısıdır. Denklem (1.11) ile iki ardışık dönem arasındaki düzeltilmiş değerleri dikkate alarak bunlar arasındaki farkın trendi gösterdiğinden yola çıkılmaktadır. Bu farklılıkların bazılarının rasgele oluşmuş olabileceği varsayımı ile bu rasgele değişim  $\beta$  katsayısı ile düzeltilmektedir. Bu katsayı tek üssel düzeltmede yer alan üssel düzeltme katsayısı  $\alpha$ 'da olduğu gibi 0 ile 1 arasında değerler alır.  $\beta$ 'nin küçük değerleri trendin daha fazla düzeltilmesini sağlarken, trenddeki rassallığın yüksek olması durumunda faydalıdır;

$$F_{t+m} = L_t + D_t \cdot m \quad (1.12)$$

Denklem (1.12) genel tahminleme ifadesidir, burada, m ileriye yönelik kaç dönemin tahmini yapılacağını göstermektedir.

Bu yöntemde  $\alpha = \beta$  iken, Brown'ın Çift (Linear) Üssel Düzeltme yöntemine eşit olmaktadır (Nau).

### 1.3.5. Holt Winters metotları

Holt'un lineer düzeltme yönteminde üssel düzeltme yöntemine trend etkisi eklenerek model geliştirilmiştir. Zaman serilerinde yalnızca trend etkisi değil sezonsal etki de söz konusu olabilmektedir. Bu etkiyi yansıtabilmek için Holt'un modeli Winters tarafından geliştirilerek Holt-Winters modeli önerilmiştir. Holt-Winters modeli temel, trend ve sezonsallığı bir arada barındırmaktadır. Bu model iki farklı yöntem sunmaktadır. Bunlar; toplamlı sezonsallık ve çarpımlı sezonsallık yöntemleridir.

#### 1.3.5.1. Çarpımlı sezonsallık

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1-\alpha)(L_{t-1} + D_{t-1}) \quad (1.13)$$

Denklem (1.13)'de,  $L_t$  t dönemine ait düzeltilmiş değeri,

$Y_i$ , i: t-1, t-2, ..., t-n değerler alırken gerçekleşmiş talep değerleri,

s, bir sezondaki dönem sayısını,

$S_t$ , t dönemine ait sezonsal endeksi,

$D_{t-1}$ , t-1 dönemine ait trend/yığılma değerini,

$\alpha$ , üssel düzeltme katsayısını,  $0 \leq \alpha \leq 1$  göstermektedir,

$$D_t = \beta(L_t - L_{t-1}) + (1-\beta)D_{t-1} \quad (1.14)$$

Denklem (1.14)'de,  $\beta$ , trend düzeltme katsayısını,  $0 \leq \beta \leq 1$  göstermektedir,

$$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma)S_{t-s} \quad (1.15)$$

Denklem (1.15)'de,  $\gamma$ , sezonsal endeksler için düzeltme katsayısını,  $0 \leq \gamma \leq 1$  göstermektedir,

$$F_{t+m} = (L_t + D_t \cdot m) S_{t-s+m} \quad (1.16)$$

Denklem (1.16) genel tahminleme ifadesidir, burada,  $m$  ileriye yönelik kaç dönemin tahmini yapılacağını göstermektedir. Başlangıç değerleri ise şu şekilde hesaplanmaktadır;

$$L_s = \frac{1}{s} (Y_1 + Y_2 + \dots + Y_s) \quad (1.17)$$

$$D_s = \frac{1}{s} \left[ \frac{Y_{s+1} - Y_1}{s} + \frac{Y_{s+2} - Y_2}{s} + \dots + \frac{Y_{s+s}}{s} \right] \quad (1.18)$$

$$S_1 = \frac{Y_1}{L_s}, S_2 = \frac{Y_2}{L_s}, \dots, S_s = \frac{Y_s}{L_s} \quad (1.19)$$

### 1.3.5.2. Toplamlı sezonsallık

$$L_t = \alpha(Y_t - S_{t-s}) + (1-\alpha)(L_{t-1} + D_{t-1}) \quad (1.20)$$

Denklem (1.20)'de,  $L_t$  t dönemine ait düzeltilmiş değeri,

$Y_i$ ,  $i$ :  $t-1, t-2, \dots, t-n$  değerler alırken gerçekleşmiş talep değerleri,

$s$ , bir sezondaki dönem sayısını,

$S_t$ ,  $t$  dönemine ait sezonsal endeksi,

$D_{t-1}$ ,  $t - 1$  dönemine ait trend/yığılma değerini,

$\alpha$ , üssel düzeltme katsayısını,  $0 \leq \alpha \leq 1$  göstermektedir,

$$D_t = \beta(L_t - L_{t-1}) + (1-\beta)D_{t-1} \quad (1.21)$$

Denklem (1.21)'de,  $\beta$ , trend düzeltme katsayısını,  $0 \leq \beta \leq 1$  göstermektedir,

$$S_t = \gamma(Y_t - L_t) + (1-\gamma)S_{t-s} \quad (1.22)$$

Denklem (1.22)'de,  $\gamma$ , sezonsal endeksler için düzeltme katsayısını,  $0 \leq \gamma \leq 1$  göstermektedir,

$$F_{t+m} = L_t + D_t \cdot m + S_{t-s+m} \quad (1.23)$$

Denklem (1.23) genel tahminleme ifadesidir, burada, m ileriye yönelik kaç dönemin tahmini yapılacağını göstermektedir. Başlangıç değerleri ise şu şekilde hesaplanmaktadır;

$$L_s = \frac{1}{s} (Y_1 + Y_2 + \dots + Y_s) \quad (1.24)$$

$$D_s = \frac{1}{s} \left[ \frac{Y_{s+1} - Y_1}{s} + \frac{Y_{s+2} - Y_2}{s} + \dots + \frac{Y_{s+s}}{s} \right] \quad (1.25)$$

$$S_1 = Y_1 - L_s, S_2 = Y_2 - L_s, \dots, S_s = Y_s - L_s \quad (1.26)$$

### 1.3.6. Croston'un metodu

1972'de Croston tarafınsan önerilen metod hem talep büyüklüğünü hem de taleplerin gelişleri arasındaki zamanı dikkate almaktadır, diğer bir ifade ile talep oluşmayan zamanları da dolaylı olarak dikkate almış olmaktadır. Croston'un (1972) metodu yayınlandığı günden itibaren birçok araştırmacı tarafından incelenmiştir. Rao (1973), Croston'un önerdiği prosedür üzerinde değil ancak bazı ifadelerde birtakım düzeltmeler yapmıştır. Shultz (1987) ise yine Croston'un modelini temel alan tahminleme prosedürü geliştirmiştir, ki bu prosedür ikmal gecikmelerini dikkate alan bir temel stok politikasını önermektedir. Ayrıca biri talep büyüklüğünü, diğeri talepler arası varışlar için kullanılmak üzere 2 düzeltme parametresi önermektedir. Willemain ve diğerleri (2004) Croston'un metodunu üssel düzeltme yöntemi ile karşılaştırmış ve gerçek verilerin bazı durumlarda daha az belirgin fayda sağlamasına karşılık yine de Croston'un metodunun üssel düzeltmeye göre güçlü bir şekilde üstün olduğu sonucuna varmışlardır. Johnston ve Boylan'da (1996) benzer sonuçlar elde etmişler ancak talepler arası varışların 1,25'den daha büyük olduğu durumlarda Croston'un metodunun üssel düzeltmeye göre her zaman daha üstün olduğunu göstermişlerdir. Sani ve Kingsman (1997) çeşitli tahminleme ve stok kontrol metodlarını uzun dönemli düşük talepli gerçek yedek parça verisi üzerinden karşılaştırmışlardır. Çalışmalarının sonucunda, hareketli ortalama metodunun en iyi sonucu verdiğini, bunu ise Croston'un metodunun izlediği ortaya konmuştur (Callegaro, 2010). Syntetos ve Boylan (2001) Croston'un metodunun yanlı olduğunu göstermiş, bu yanlılığı ortadan kaldırmaya yönelik bir model önermişler ve bu önerinin etkinliğini deneysel olarak destekleyerek göstermişlerdir. Synder (2002) Croston'un metodunu uygulamada yaşanan

güçlüklerin üstesinden gelebilmek için incelemiş ve bu yöntemin altında yatan teori ve önerilen modifikasyonları düzeltmiştir. Bir diğer önemli çalışma ise Teunter ve diğerleri (2010) tarafından yapılmış ve yıllar içerisinde önerilmiş Croston metodunun tüm farklı varyasyonlarını deneyerek Croston'un ve Syntetos ve Boylan'ın yaklaşımının (Croston'un bir varyasyonu) hareketli ortalama ve üssel düzeltme yöntemlerine göre üstün performans sergilediğini ortaya koymuşlardır.

Croston'un orijinal metodu;

$$Z_t = \alpha X_t + (1-\alpha)Z_{t-1} \quad (1.27)$$

$$P_t = \alpha G_t + (1-\alpha)P_{t-1} \quad (1.28)$$

Denklem (1.27) ve Denklem (1.28)'de,

$Z_t$ , t anındaki her bir talebin düzeltilmiş büyüklüğünü,

$X_t$ , t anındaki her bir talebin gerçek büyüklüğünü,

$P_t$ , t anındaki ardışık talepler arasındaki düzeltiliş zamanı,

$G_t$ , t anındaki ardışık talepler arasındaki gerçek zamanı,

$\alpha$ , düzeltme katsayısını,  $0 \leq \alpha \leq 1$ , göstermektedir.

t anındaki talep tahmini Denklem (1.29)'daki gibi hesaplanır;

$$F_{t+1} = \frac{Z_t}{P_t} \quad (1.29)$$

### 1.3.7. Syntetos ve Boylan'ın metodu

Croston'un metodunu incelemişler ve metodun yanlış olduğunu göstermişler ve bu yanlışlığı gidermek için t anındaki talep tahmini fonksiyonunu Denklem (1.30)'daki gibi değiştirmeyi önermişlerdir;

$$F_{t+1} = \left(1 - \frac{\alpha}{2}\right) \frac{Z_t}{P_t} \quad (1.30)$$

Yanlılığın göstergesi olarak ise  $F_t$ 'nin beklenen değerinin  $\mu/p$  olması gerekirken, beklenen değer denklemin (1.31)'deki gibi olması ifade edilmiştir;

$$E(F_t) = \frac{\mu}{p} \left[ 1 + \frac{\alpha}{2-\alpha} \frac{p-1}{p} \right] \quad (1.31)$$

Denklem (1.31)'de,  $\mu$  taleplerin ortalaması,  $p$  ise varışlar arası zamanların ortalamasıdır.

Buradaki yanlılığın tam olarak giderildiğini söyleyemeyiz. Croston'un orijinal metodu  $1/p$  büyüdükçe yani çok az talep "0" ise yanlılığın az olduğunu, Syntets ve Boylan'ın metodunda ise  $1/p$  küçüldükçe yani çok sayıda talep "0" ise yanlılığın az olduğunu söyleyebiliriz.

### 1.3.8. Bootstrap metodu

Hua ve diğerleri (2006) geçmiş verinin sınırlı kaldığı durumlarda, yedek parça talep tahminlemede "bootstrap" metodunun kullanışlı bir araç olduğunu vurgulamışlardır. Bookbinder ve Lordahl (1989) bu metodun bağımsız veriler için yedek parça taleplerinin yüksek yüzdelerinin tahmini için normal yaklaşımlara göre daha üstün olduğunu bulmuşlardır. Wang ve Rao (1992) bootstrap metodunun düzgün talepler ile çalışmak için de oldukça etkin olduğunu bulmuşlardır. Tüm bu çalışmalar kesikli talebin yönetiminde ortaya çıkan problemleri dikkate almamışlardır. Willemain ve diğerleri ise yedek parça stoklarının kesikli taleplerin tahmini için bir yaklaşım önermişlerdir (2004). Önerilen bu yaklaşım; sabit bir tedarik zamanı üzerinden kesikli taleplerin toplamının dağılımını tahminleyen bir bootstrap temelli yaklaşımdır.

Bootstrap modern, yoğun bilgisayar kullanımı gerektiren, istatistiksel çıkarıma için genel amaçlı yaklaşımdır. Bu yaklaşım tahmini bir dağılımdan örneklem alındığında bunun özelliklerini tahminleme pratiği sunar.

Bootstrap Prosedürü:

1.  $n$  adet gözlemlenen örneklem al,  $X=(x_1, x_2, \dots, x_n)$

2.  $X$ 'den  $m$  adet yeni örneklem al, ki bu  $n$  adet veriden temin edilsin.  $X_1, X_2, \dots, X_m$  (her bir bootstrap çıkartmasında, gözlemlenen örneklemden veri birden fazla kez çıkarılabilir ve her bir veri  $1/n$  olasılıkla çıkarılır)
3. Çalışmanın parametresi olan  $\theta$ 'nın tahmin edicisi  $T$  (talep tahmininde ortalama talebi ifade eder) her bir bootstrap örneği için hesaplanır. Bu şekilde  $\theta$ 'nın  $m$  adet tahmini hesaplanmış olur.
4. Bu tahminlerden arzu edilen değer hesaplanır. Talep tahminleme için;  $T_1, T_2, \dots, T_m$ 'nin ortalaması olacaktır.

Bu metod sadece ortalama talep için değil talepler arası varişların ortalamalarını bulmak için veya başka herhangi bir değerın hesaplanması için de kullanılabilir.

### 1.3.9. Otoresif hareketli ortalamalar modeli (ARMA modeli)

Box-Jenkins modelleri olarak da bilinen zaman serisi kestirimi ve öngörme yöntemi olup eşit zaman aralıklarında gözlenen zaman serisi verilerinde uygulanır. Tek değişkenli zaman serilerinin analizinde kullanılan Box Jenkins yönteminin esası, zaman serilerinin herhangi bir dönemdeki değerini aynı serinin geçmiş dönemdeki gözlem değerlerinin ve hata terimlerinin doğrusal bir bileşimi ile açıklamaktır.

$X_t$  şeklinde bir zaman serisi verisi verildiğinde, ARMA modeli, serinin gelecek dönemlerdeki değerlerini tahmin etmek için kullanılır. Model iki kısımdan oluşur. Bunlardan ilki otoresif kısım olarak adlandırılır ve ingilizce kısaltma olan (AR) ile gösterilir, diğeri ise hareketli ortalamalar kısmıdır ve yine ingilizce kısaltma olan (MA) ile gösterilir. Model, genellikle  $p$  otoresif kısmın derecesi,  $q$  ise hareketli ortalama kısmının derecesi olmak üzere ARMA( $p, q$ ) modeli şeklinde gösterilir.

AR( $p$ ) ifadesi  $p$ . dereceden otoresif modeli ifade eder,

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t \quad (1.32)$$

Denklem (1.32)'de,  $\phi_1, \phi_2, \dots, \phi_p$ , modelin parametrelerini;  $c$ , sabit terimi;  $\varepsilon_t$  ise hata terimini simgeler. Modelin durağan olması için parametreler üzerinde kısıtlamaya



gidilmelidir.  $|\phi_1|>1$  durumunun geçerli olduğu bir AR(1) modeli durağan değildir. AR(1) modeli Denklem (1.33)'deki gibi gösterilir;

$$X_t = c + \phi_1 X_{t-1} + \varepsilon_t \quad (1.33)$$

Denklem (1.33)'de,  $\varepsilon_t$  beyaz gürültülü ve 0 ortalamaya sahip  $\sigma^2$  varyanslı bir süreçtir. Eğer  $|\phi|<1$ , sağlanırsa süreç kovaryans durağandır. Eğer  $\phi=1$  sağlanıyorsa süreç birim kök içermektedir ve durağan olduğu söylenemez.  $\phi=1$  durumu aynı zamanda rassal yürüyüş olarak da bilinen özel bir durumdur. Bu özel durumda  $X_t$  için "beklenen değeri" hesaplamak mümkün değildir. AR(p) modeli parametreleri olan  $\phi_i$ 'lerin hesaplanması için Yule-Walker denklemleri kullanılır.

Hareketli Ortalamalar (MA(q)) modeli q. dereceden hareketli ortalamalar modelini ifade eder ve Denklem (1.34)'deki gibi gösterilir;

$$X_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1.34)$$

$\theta_1, \theta_2, \dots, \theta_q$  modelin parametreleridir ve  $\varepsilon_t, \varepsilon_{t-1}, \dots$  modelin hata terimleridir. Yani, "hareketli ortalamalar" modelinde belirli bir zaman noktasındaki bir zaman serisi değişkeninin değeri q tane daha önceki her bir zaman noktasında yapılan hataların ağırlıklı olarak bileştirilmesi ile açıklanmaktadır.

ARMA(p,q) modeli Denklem(1.33) ve Denklem (1.34)'ün birleştirilmesi ile Denklem (1.35)'deki gibi hesaplanır;

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1.35)$$

### 1.3.10. Durağan olmayan doğrusal stokastik model (ARIMA modeli)

Zaman serisinin durağan olduğu, yani sürecin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmediği durumlarda AR, MA veya ARMA modellerinden uygun olanları kullanılmaktadır. Ancak zaman serilerinin çoğu, zaman boyunca değişen belirli bir stokastik sürecin özelliklerini taşıması nedeniyle durağan değildir (Pindyck ve Rubinfeld, 1998). Durağan olmayan zaman serilerine

Box Jenkins yönteminin uygulanabilmesi için önce durağanlığı bozan trend ve mevsimsellik gibi unsurların bazı dönüşüm yöntemleriyle ortadan kaldırılarak, serinin durağan hale getirilmesi gerekir (Özmen, 1986). Durağanlık koşulunun varlığını test etmek için Dickey ve Fuller'in (1981) çalışmalarında geliştirdiği, bağımlı değişkenin gecikmeli değerleri açıklayıcı değişken olarak kullanılarak oluşturulmuş olan birim kök testlerinden ADF testinden yararlanılır.

Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülen serilere uygulanan modellere “durağan olmayan modeller” adı verilmektedir. Durağan olmayan modeller, d sayıda farkı alınarak uygulanan AR ve MA modellerinin bir bileşimidir. Eğer otoregresyon parametresi olan  $\phi$ 'nin derecesi p, hareketli ortalama parametresi  $\theta$ 'nin derecesi de q ise ve d kez fark alma işlemi yapılmışsa, bu modele (p,d,q) dereceden Durağan Olmayan Doğrusal Stokastik Model adı verilir ve ARIMA(p,d,q) şeklinde gösterilir. ARIMA(p,d,q) modelinin genel ifadesi;

$$W_t = \varepsilon_t + \sum_{i=1}^p \phi_i W_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1.36)$$

Denklem(1.36)'da, ARMA modelindeki eşitlikte  $X_t$  teriminin yerine  $W_t$  teriminin yazılmış şeklidir. Burada, durağan olmayan  $X_t$  sürecinin d derece farkı alınarak durağanlaştırılması sonucu  $W_t$  süreci elde edilmekte ve  $\Delta^d X_t = W_t$  olarak yazılmaktadır.

Fark alma derecesi  $d=0$  olduğunda, yani seri orijinal değerler itibariyle durağan ise bu durumda, ARIMA(p,d,q) modeli AR, MA, ARMA modellerinden birine dönüşmektedir. Bu nedenle ARIMA(p,d,q) modeli esnek bir modeldir. ARIMA(p,d,q) modelinde p veya q sıfır olabilir. p'nin sıfır olması durumunda model IMA(d,q), q'nun sıfır olması durumunda ise ARI(p,d) model türüne indirgenir (Box ve Jenkins, 1976). Ele alınan modelin, otoregresyon parametresinin yada hareketli ortalama parametresinin kaç gecikmeli değer içereceğinin tespit aşamasına, geçici uygun model belirleme safhası adı verilmektedir.

### 1.3.11. S-ARIMA Modeli

ARMA ve ARIMA modellerinde sezonsallık dikkate alınmamıştır, ancak zaman serilerinde sezonsallık sıkça karşımıza çıkmaktadır. Sezonsallığın bir yıla yayılmış olduğu durumlarda, modellerde birbirini izleyen gözlem değerleri ve birbirini izleyen yılların aynı aylarına ait gözlem değerleri arasında ilişki bulunmaktadır. Sezonsal modellerde, birbirini izleyen gözlem değerleri arasındaki ilişki için ARIMA (p,d,q) modeli kullanılabileceği gibi, birbirini izleyen aynı mevsim gözlem değerleri arasındaki ilişki için de S-ARIMA modeli kullanılabilir. Buradaki s, birbirini izleyen aynı mevsim gözlem değerleri arasındaki zaman aralığıdır. Aylık gözlem değerlerinden yani 12 aylık zaman serilerinde s=12, altı aylık zaman serilerinde s=6 alınmaktadır. Mevsimsel zaman serileri modeli kısaca, ARIMA (p,d,q) (P,D,Q)s şeklinde gösterilir.

### 1.4. Performans Ölçütleri

Performans ölçütleri, hangi tahminleme metodunun gerçeğe daha yakın sonuçlar verdiğini karşılaştırmak açısından önemlidir. Performans ölçütleri, gerçekleşen talepleri dikkate alarak, iki veya daha fazla tahminleme metodunun değerlendirilmesinde referans sağlarlar. Literatürde bir çok performans ölçütü kullanılmaktadır. Bunlardan en yaygın olarak kullanılanlar bu bölümde incelenecektir. Bu performans ölçütleri ikiye ayrılabilir. İlki tam doğruluk ölçütleridir (MAPE, SMAPE, AMAPE, RMSE), ikincisi ise diğer metodlara bağlı göreceli doğruluk ölçütleridir (RGRMSE, PB).

#### 1.4.1. Ortalama mutlak yüzde hata (Mean absolute percentage error – MAPE)

Ortalama mutlak yüzde hata doğruluğu yüzde cinsinden açıklar ve Denklem (1.37)'deki gibi hesaplanır;

$$MAPE = \frac{100}{n} \sum_{t=1}^N \left| \frac{A_t - F_t}{A_t} \right| \quad (1.37)$$

Denklem (1.37)'de,  $A_t$  gerçekleşen değer ve  $F_t$  ise tahmin değerini göstermektedir.

Öncelikle, gerçekleşen değer ile tahmin değerinin farkının gerçekleşen değere bölümü hesaplanır. Zaman içerisindeki tahmin noktaları bu değerlerin mutlak değerleri toplamı için toplanır ve zaman içerisindeki tahmin noktalarının sayısına bölünerek bulunur. Yüzdesele gösterim için 100 ile çarpılır. Bu ölçüt yüzdesele hatayı gösterdiğinden değişen seviyelerdeki zaman serilerindeki hatayı karşılaştırmak için kullanılabilir.

MAPE konsept olarak oldukça basit ve ikna edici olsa da, pratikte bazı temel sorunlara sebep olmaktadır. Bunlar şu şekilde sıralanabilir;

- Eğer “0” değerleri varsa (ki yedek parça taleplerinde oldukça sık karşımıza çıkan bir durumdur) “0” a bölme hatası verecektir.
- Tahminler için, çok düşük yüzdesele hata olduğunda yüzdesele hata %100’ü geçmez, ancak tersi durum için yani çok yüksek hatalar olduğunda yüzdesele hata için bir üst sınır yoktur.
- MAPE yanlı bir metod olup, tahminleri daha düşük olan metodun sistematik olarak seçilmesini sağlar. Bu az bilinen ancak ciddi konu doğruluk ölçütü olarak tahmin değerinin gerçekleşen değere bölünmesi (Doğruluk Oranı) ile aşılabilir. (Tofallis, 2015)

#### **1.4.2. Simetrik ortalama mutlak yüzde hata (Symetric-mean absolute percentage error – S-MAPE)**

Simetrik ortalama mutlak yüzde hata doğruluğu yüzde hatalar üzerinden açıklar, Denklem (1.38)’deki gibi kullanılır;

$$SMAPE = \frac{100}{n} \sum_{t=1}^N \frac{|A_t - F_t|}{(A_t + F_t)/2} \quad (1.38)$$

Denklem (1.38)’de,  $A_t$  gerçekleşen değer ve  $F_t$  ise tahmin değerini göstermektedir.

Öncelikle, gerçekleşen değer ile tahmin değerinin mutlak farkının gerçekleşen değer ve tahmin değerlerinin toplamının yarısına bölümü hesaplanır. Bu hesaplama her bir tahmin noktası için yapılır ve bunların toplamı da toplam tahmin noktası sayısı olan  $n$ ’ye bölünür. Yüzdesele gösterim için 100 ile çarpılır. MAPE’nin aksine SMAPE’nin bir alt ve üst sınırı vardır. Öyle ki formül bize alt sınır olarak %0 ve üst sınır olarak da %200 değerlerini vermektedir. Ancak yüzdesele bir hatanın %0 ile %100 arasında

olması daha anlaşılır olacağından formül pratikte Denklem (1.39)'daki gibi kullanılmaktadır;

$$SMAPE = \frac{100}{n} \sum_{t=1}^N \frac{|A_t - F_t|}{(A_t + F_t)} \quad (1.39)$$

SMAPE ile ilgili problem söylendiği gibi simetrik olmayışıdır, çünkü gerçekleşen değer in altında veya üstündeki eşit tahminler aynı doğruluk yüzdesi ile ifade edilmemektedir. Örnek vermek gerekirse; Denklem (1.39) formülü aşağıdaki örneğe uygulandığında SMAPE değerleri şu şekilde gerçekleşmektedir:

- Gerçek Değer Üzerinde Tahmin:  $A_t=100$  ve  $F_t=110$  iken  $SMAPE = \%4.76$
- Gerçek Değer Altında Tahmin:  $A_t=100$  ve  $F_t=90$  iken  $SMAPE = \%5.26$

#### 1.4.3. Düzeltilmiş ortalama mutlak yüzde hata (Adjusted mean absolute percentage error – AMAPE)

Literatürde MAPE'nin çeşitli varyasyonları çalışılmıştır. Bunların arasında Hoover (2006) tarafından yapılmış olan çalışma önemlidir ki düzeltilmiş ortalama mutlak yüzde hata yedek parça talep tahminleme metotlarının karşılaştırılmasında en çok kullanılan yöntemdir. Denklem (1.40)'daki gibi formüle edilmiştir;

$$AMAPE = \frac{\frac{\sum_{t=1}^N |A_t - F_t|}{N}}{\frac{\sum_{t=1}^N A_t}{N}} \quad (1.40)$$

#### 1.4.4. Kök ortalama karesel hata (Root mean square error – RMSE)

Kök ortalama karesel hata gerçekleşen değer ile tahmin değeri arasındaki farkların ölçümü için sıklıkla kullanılmaktadır. Formül (1.41)'deki gibidir;

$$RMSE = \frac{1}{N} \sum_{t=1}^N \sqrt{(F_t - A_t)^2} \quad (1.41)$$

Armstrong ve Collopy tarafından yapılan çalışmada 90 farklı yıllık ve 101 farklı çeyreklik zaman serisi ile çalışılmış ve bunların hataları karşılaştırılarak ölçümlenmiştir (Armstrong ve Collopy, 1992). Çalışmada, MAPE'nin küçük hatalar

tarafında yanlı olan bir yaklaşım olduğu ve eğer büyük hatalar bekleniyor ise MAPE'nin uygun bir seçenek olmaması gerektiği sonucuna ulaşılmıştır. Çalışmada ayrıca, birçok araştırmacı tarafından RMSE tercih edilse de hatanın büyüklüğü ile tanımlandığı için RMSE'nin güvenilir olmadığı sonucuna ulaşılmıştır. Çalışma AMAPE'nin birçok zaman serisi verisi mevcut olduğu durumda daha doğru metodun seçimi için önerilmektedir. Ancak AMAPE'nin kullanımını zorlaştıran bir unsur kesikli talep yapılarında karşımıza çıkan “0” taleplerin varlığıdır.

#### 1.4.5. Göreceli geometrik kök ortalama karesel hata (Relative geometric root-mean square error – RGRMSE)

Göreceli geometrik kök ortalama karesel hata Denklem (1.42)'deki gibi hesaplanır;

$$RGRMSE = \frac{(\prod_{t=1}^N (A_{a,t} - F_{a,t})^2)^{1/2n}}{(\prod_{t=1}^N (A_{b,t} - F_{b,t})^2)^{1/2n}} \quad (1.42)$$

Burada  $A_{k,t}$  ve  $F_{k,t}$  sırasıyla k. metodun t dönemindeki gerçek ve tahmini talepleridir. Eğer RGRMSE 1'den küçük ise metot a metot b'den daha iyi performans gösteriyor denir. Fildes (1992) RGRMSE'nin arzu edilen bir istatistiksel özellik olduğunu vurgulamıştır. Ona göre, belirli bir zaman periyodunda hata iki kısımdan oluşur. Birincisi metoda bağlıdır ikincisi ise zaman periyoduna bağlıdır.

#### 1.4.6. Yüzde en iyi (Percentage best – PB)

Yüzde en iyi, bir metodun incelenmekte olan diğer metotlara göre nasıl performans gösterdiğinin zaman periyodlarındaki yüzdesidir. Bu bağlamda, PB anlamlıdır, çünkü tüm serileri ve her serideki tüm veri periyodları sonuç üretmektedir (Syntetos ve Boylan, 2005). Herhangi bir m metodu için Denklem (1.43)'deki gibi hesaplanır;

$$PB_m = \frac{\sum_{t=1}^N B_{m,t}}{N} 100 \quad (1.43)$$

burada,

$$B_{m,t} = \begin{cases} 1 & \text{eğer } (A_{m,t} - F_{m,t}), \forall \text{ diğer } (A_{k,t} - F_{k,t}) \text{ en küçüğü ise} \\ 0 & \text{diğer durumlarda} \end{cases} \quad (1.44)$$

k farklı metodun değerlendirilmesinde, en büyük PB değerine sahip olan metod diğer metotlara göre daha iyi performans gösterir denir.



## 2. BULANIK SİSTEM MODELLEME

Geleneksel bulanık sistem modelleme yaklaşımları genellikle akıl yürütme için Eğer... ise kural yapıları ile bulanık kural tabanını temel alır (Ünal, 2009). En yaygın olarak kullanılan Takagi-Sugeno (T-S) bulanık kural tabanıdır, bu kural tabanında; her kuralda bulanık kümeler öncül ve lineer fonksiyonlar ise ardıllardır. Fonksiyonlar ile bulanık sistem modelleme yaklaşımları bulanık kural tabanlarının sebep olduğu öznellik, hesaplama karmaşıklığı gibi problemlerin üstesinden gelebilmek ve sistem model performansını iyileştirmek için bulanık öbeleme algoritmalarını temel alan farklı bulanık fonksiyon yapıları kullanılarak bulanık kural tabanlı sistem modellemeye alternatif olarak sunulmuşlardır.

BSM yaklaşımları sistem davranışını anlamak için kullanılır. Bulanık kural tabanı yaklaşımları sistemin dilsel özelliklerini tanımlamada uzman bilgisini kullanır, bu da ister istemez öznelliği beraberinde getirir. Özneliğin üstesinden gelmek için, uzman bilgisi kullanımı yerine kendi kendine öğrenen sistemler oluşturularak daha objektif BSM geliştirilir. BSM’de; uzmanların sunmuş olduğu kural tabanlarına aittir karşılık gelen bilgi olan üyelik dereceleri bulanık öbelem ortalamaları gibi öbeleme algoritmaları ile veriden öğrenilir.

BKT yaklaşımları uzman bilgisine dayalı olduğu için öznellik, birçok farklı parametre kullanımı ve çok sayıda hesaplama adımı gerektirdiği için hesaplama güçlüğü ve optimizasyon gibi bazı güçlükleri beraberinde getirirler. Dolayısıyla, bu çalışmada, eğer... ise kural yapısı gerektirmeyen bulanık öbeleme ve bulanık fonksiyon kullanımı ile geliştirilmiş BSM’leri kullanılmıştır.

### 2.1. Bulanık Kural Tabanlı Bulanık Sistemler

Geleneksel bulanık sistem modelleri sistemin elemanları arasındaki ilişkileri EĞER-İSE kuralları ile tanımlar. Birçok bulanık sistem model yapılarının arasında en ünlü ve en çok kullanılanlar Zadeh (1965), Takagi ve Sugeno (1985) ve Mizumoto (1989) tarafından önerilen yaklaşımlardır.



### 2.1.1. Zadeh BKT yapısı

Zadeh'in (1965) bulanık kural tabanı yapısı Denklem (2.1)'deki gibi formüle edilebilir;

$$R: \text{KURAL} \left[ \bigwedge_{i=1}^c \left[ \text{EĞER } \bigvee_{j=1}^{nv} (x_j \in X_j \text{ üi } A_{ji}) \text{ İSE } y \in Y \text{ üi } B_i \right] \right] \quad (2.1)$$

Denklem (2.1)'de;

- c sistem modelindeki kuralların sayısı,
- $x_j$  j. girdi değişkeni,  $j=1, \dots, nv$ , nv girdi değişkenlerinin toplam sayısı
- $X_j$   $x_j$ 'nin tanım kümesi,
- $A_{ji}$  i kuralında  $\mu_{A_{ji}}(x_j): X_j \rightarrow [0,1]$  üyelik fonksiyonuna sahip  $x_j$  girdi değişkeni ile ilişkili dilsel etiket,
- y çıktı değişkeni,
- Y y'nin tanım kümesi,
- $B_i$  i kuralında  $\mu_{B_i}(y): Y \rightarrow [0,1]$  üyelik fonksiyonuna sahip y çıktı değişkeni ile ilişkili dilsel etiket,
- VE her kuralın ateşleme derecesini bulmak için verilen bir gözlem için girdi değişkenlerinin üyelik değerlerinin toplamak için kullanılan mantıksal bağlaç,
- İSE mantıksal gerektirme bağlacı,
- KURAL bulanık kuralların model çıktılarını toplamak için kullanılan mantıksal bağlaç,
- 'üi' (üi: üyelik ilişkisindeyse) Zadeh (1965) tarafından tanıtılmıştır ve atamanın veya tanımlamanın kesin olmadığını gösterir, bu atama veya tanımlama bulanıktır.

Bulanık mantık yapısını tanımlama metodunu kullanmadan önce tanımlanması gereken parametreler; kural sayısı, her bir girdi değişkeni için üyelik fonksiyonlarının tipi, çıktı değişkeninin üyelik fonksiyonu ve VE, İSE ve KURAL işlemcilerinin tipleridir.

### 2.1.2. Mizumoto BKT yapısı

Mizumoto (1989) bulanık kural tabanı yapıları; Zadeh bulanık kural tabanı yapılarında ardılların daha basit olarak  $B_i$  bulanık kümesi yerine, bir  $b_i$  sabiti ile gösterilmesi ile elde edilir. Mizumoto tipi çıkarsama yapısı Denklem (2.2)'deki gibi tanımlanır;

$$R: \text{KURAL}_{i=1}^c \left[ \text{EĞER } \bigvee_{j=1}^{nv} (x_j \in X_j \text{ üi } A_{ji}) \text{ İSE } y_i = b_i \right] \quad (2.2)$$

Denklem (2.2)'de  $b_i$  i kuralı ile ilişkili sabit bir değerdir. Mizumoto bulanık çıkarsama sistemini kullanmada tanımlanacak çıkarsama parametreleri Zadeh kural tabanında tanımlanan parametreler ile aynıdır. Mizumoto kural tabanı için genelleştirilmiş bulanık çıkarsama yapısı Şekil 2.2'de de gösterilen adılar ile aşağıdaki gibi açıklanabilir:

**Bulanıklaştırma:** Her bir i kuralı ve her bir j veri vektörü elemanı  $A_{ji}$  bulanık kümesindeki veri vektörüne,  $x'$ , bir üyelik değeri atar. Bu üyelik değeri her bir i kuralı ve her bir j veri vektörü elemanı için  $\mu_i(x'_j)$  ile gösterilir.

**Öncüllerin Toplanması:** Bulanıklaştırma adımında her bir kural için ölçülen üyelik değerleri tek bir üyelik değeri belirlemek için toplanır. Toplama işlemi bulanık işlemciler kullanılarak gerçekleştirilir, en yaygın olarak MİN bağlacını kullanan üçgen normdur ve  $\wedge$  ile gösterilir. Dolayısıyla,  $x'$  yeni girdi vektörünün i kuralının üyelik derecesi Denklem (2.3)'deki gibi hesaplanır;

$$\tau_i(x') = \bigvee_{j=1}^{nv} \mu_i(x'_j), \forall i=1 \dots c \quad (2.3)$$

**Gerektirme:** Üyelik derecesi öncüller ve girdi değişkenleri arasındaki uyumluluğun bir ölçüsünü gösterir. Üyelik derecesi aynı zamanda son model çıktısı bulanık kümesini tanımlayan her bir kuralın çıktı bulanık kümelerinin katkı seviyesini de tanımlar. Mamdani tipi çıkarsama metodunda (Mamdani ve Assilian, 1974), VE bağlacı gerektirme bağlacı olarak kullanılır, burada MİN işlemi verilen bir  $x'$  gözlem için i kuralında model çıktı bulanık kümenin saptanmasında kullanılır, Denklem (2.4)'deki gibidir;


$$\mu'_i(y) = \tau_i(x') \vee \mu_i(y) = \tau_i(x') \wedge \mu_i(y), \forall i=1 \dots c \quad (2.4)$$

Ardılların Toplanması: Gerektirme adımında her kural için bir çıktı bulanık kümesi tanımlanır. KURAL işlemcisi her bir kural için oluşturulmuş çıktı bulanık kümeleri toplayarak tek bir çıktı bulanık küme tanımlamak için kullanılır. Mamdani bulanık çıkarsama planı örneği üzerinden devam edecek olursak, KURAL VEYA işlemcisidir, burada MAK işlemcisi olarak alınır. Ardılların toplanması ile çıktının üyelik değeri Denklem (2.5)'deki gibi hesaplanır;

$$\mu'(y) = \bigvee_{i=1}^c \mu'_i(y) \quad (2.5)$$

Berraklaştırma: Bulanık çıkarsama metodunun son adımı kesin bir çıktı elde etmeyi sağlayan berraklaştırmadır. En yaygın olarak kullanılan ağırlık merkezi berraklaştırma metodu Denklem (2.6)'daki gibi tanımlanır;

$$y' = \frac{\int_y y \mu'(y)}{\int_y \mu'(y)} \quad (2.6)$$



Şekil 2.1 Mizumoto bulanık çıkarsama yapısı

### 2.1.3. Takagi –Sugeno BKT yapısı

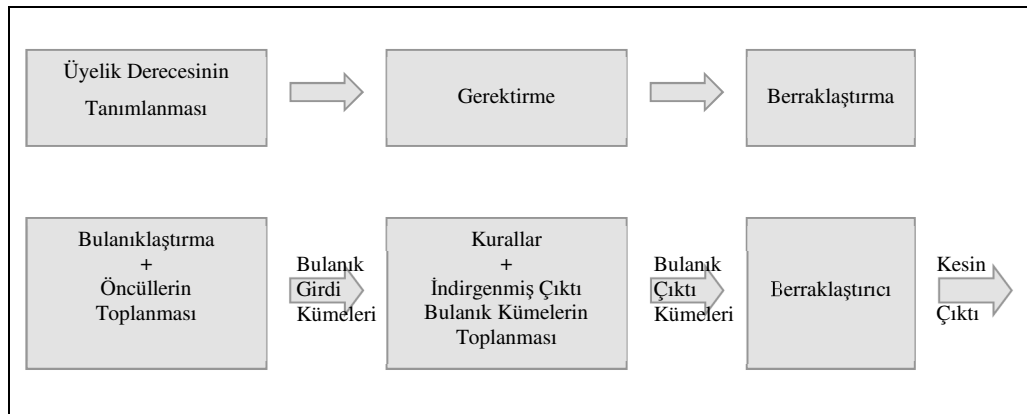
Takagi-Sugeno (TS) (1985) bulanık kural tabanı sistemleri en yaygın olarak uygulanan ve araştırılan bulanık çıkarım sistemlerinden biridir. Zadeh'in bulanık kural tabanı ile karşılaştırıldığında kısmen farklıdır, burada da farklılık Mizumoto BKT'da olduğu gibi kural tabanı yapısının ardıl kısmıdır. TS bulanık kural tabanında, öncül kısım toplama operatörü ile karakterize edilirken ardıl kısım ise regresyon doğrusu ile karakterize edilir. TS için bulanık kural tabanı yapısı Denklem (2.7)'deki gibi verilebilir;

$$R: \text{KURAL} \left[ \bigvee_{i=1}^c \left[ \bigwedge_{j=1}^{nv} (x_j \in X_j \text{ üi } A_{ji}) \right] \rightarrow E y_i = a_i x^T + b_i \right] \quad (2.7)$$

Denklem (2.7)'de,

- $a_i$  ve  $b_i$  i. kuralla ilişkili regresyon doğrusu katsayıları,
- $y_i$  i. kuralın,  $R_i$ , model çıktısıdır.

Denklem (2.7)'deki TS tipi BKT'nın ardıl kısmı lineer bir fonksiyon olarak verilmiştir. TS tipi BKT'da ardıl kısım herhangi lineer olmayan yüksek mertebeden polinomsal bir fonksiyon olarak da kullanılabilir. TS bulanık kural tabanı metodunun çıkarsama parametreleri Zadeh'in BKT'da olduğu gibi kural sayısı, her kuraldaki her girdi değişkeninin üyelik fonksiyonu, çıkarsama metodunda bağlaçlar ve Zadeh'in BKT'dan farklı olarak her kuralın regresyon doğrusu katsayılarıdır.



Şekil 2.2. Genelleştirilmiş tip-1 bulanık çıkarsama sistemleri (Bulanık mantık sistemi)

Bulanık çıkarsama sistemlerinin genelleştirilmiş yapısı Şekil 2.2'de gösterilmiştir.

Bulanıklaştırma ve Öncüllerin Toplanması: Mizumoto BKT'da yer alan bulanıklaştırma adımı ile aynı şekildedir. Öncüllerin toplanmasında üyelik derecesi Denklem (2.8)'deki gibi hesaplanır;

$$\mu_i(x') = \bigvee_{j=1}^{nv} \mu_i(x'_j), \forall i=1 \dots c \quad (2.8)$$


Gerektirme: TS tipi bulanık kural tabalarında gerektirme adımı her bir kuralın model çıktısının ağırlık verilmesinde kullanılır. Bu sebeple, Denklem (2.7)'deki bir i kuralının model çıktısı Denklem (2.9)'daki gibi hesaplanır;

$$y_i^* = \mu_i(x') \times y_i, \forall i=1 \dots c \quad (2.9)$$

Model Çıktısının Toplanması: TS bulanık kural tabanı yapısında, her kuralın model çıktısı; bulanık kural yapısındaki her bir kuralın çıktılarının ağırlıklandırılmış ortalaması alınarak Denklem (2.10)'daki gibi bulunur;

$$y^* = \frac{\sum_{i=1}^c y_i^*}{\sum_{i=1}^c \mu_i(x')}, \forall i=1 \dots c \quad (2.10)$$

Berraklaştırma: Bulanık kümeyi çıktı değişkeninin kesin bir değere indirgenmesi için kullanılan adım berraklaştırmadır. Her ne kadar bulanık kural tabanlı sistemler için berraklaştırma adımı gerekli olsa da, TS kural tabanlarının ardıl kısımları skalar değerlerden oluşan fonksiyonlar ile tanımlandığı için berraklaştırma adımı TS bulanık kural tabanları için gerekli değildir.



Şekil 2.3 Takagi Sugeno bulanık çıkarsama yapısı

## 2.2. Bulanık Fonksiyonlar

“Bulanık Fonksiyonlar” değişik amaçlarla kullanılır. Bunlardan birisi bulanık fonksiyonların üyelik fonksiyonlarını ifade ettiği yönündedir. Siy ve Chen (1972) çalışmalarında bulanık kümelerde tanımlanmış mak, min ve tümleyen operasyonları ile yapılan operasyonların bulanık fonksiyonları oluşturduğunu söylemişlerdir. Türkşen (2006) ise bulanık fonksiyonları bulanık sistem modellerinin geliştirilmesi ile en küçük kareler tahminleme tekniği ile oluşturulan fonksiyonları tanımlamak için kullanmıştır. Sasaki (1993) ve Demirci (1999) tarafından farklı bulanık fonksiyon tanımları yapılmıştır.

Zadeh (1965) bulanık fonksiyonların ilk tanımlarını oluşturan mantıksal bağlayıcılar, çıkarsama kuralları, ilişkiler ve aritmetik işlemler gibi temel bazı özellikleri bulanık kümeler için önermiştir. Marinos (1969) bulanık mantık sisteminin tasarımı ile iyi bilinen geleneksel anahtarlama teorisi tekniklerini tanıtmıştır. Bir çok farklı araştırmacı tarafından bulanık fonksiyonlar üzerinde birçok farklı aritmetik işlem keşfetmiş ve sunmuşlardır (Siy ve Chen, 1972 ;Sasaki, 1993; Demirci, 1999). Ayrıca, “Bulanık Fonksiyonlar”ın matematiksel temellerini de tanımlamışlardır.

Bulanık fonksiyonlar ile ilgili temel tanımlar aşağıda verilmiştir (Çelikyılmaz ve Türkşen, 2009).  $X$  ve  $Y$  iki bulanık küme ve  $x$  ve  $y$  sırasıyla  $X$  ve  $Y$ 'ye ilişkin bir "nesne"nin üyelik derecesi olsun.

Tanım 1:  $X$  ve  $Y$  bulanık kümeleri birbirine eşittir, ancak ve ancak her bir  $i$  nesnesi için,  $X$ 'in üyelik derecesi  $\mu(x_i)$ ,  $Y$ 'nin üyelik derecesine  $\mu(y_i)$ 'ye eşitse.

Tanım 2: Eğer her  $i$  nesnesi için  $X'$ 'de  $x_i'$  üyelik derecesi  $(1-x_i)$ 'ye eşit ise  $X'$  bulanık kümesi  $X$  bulanık kümesinin tümleyenidir denir, burada  $x_i$   $X$ 'te  $i$  nesnesinin üyelik derecesidir.

Tanım 3: Eğer her  $i$  nesnesi için  $x_i \leq y_i$  mevcutsa,  $Y$  bulanık kümesi  $X$  bulanık kümesini içerir denir.

Tanım 4: Eğer her  $i$  nesnesi için  $z = \max(x_i, y_i)$  varsa  $X$  ve  $Y$  bulanık kümeleri bir birleşim oluştururlar denir ve  $Z = X + Y$  ile gösterilir.

Tanım 5: Eğer her  $i$  nesnesi için bir  $z = \min(x_i, y_i)$  varsa  $X$  ve  $Y$  bulanık kümeleri bir kesişim oluştururlar denir ve  $Z = X \cdot Y$  ile gösterilir.

Tanım 1-5 temel alındığında, bulanık kümeler cebri iki değerli mantık cebrine benzer olarak geliştirilmiştir. Üyelik derecesi yerine "bulanık değişken" ifadesi kullanılarak, bulanık fonksiyonu matematiksel olarak ifade etmek gerekirse, Denklem (2.11) gibi tanımlanabilir;

$$f(x,y) = x \cdot y' + x' \cdot y \quad (2.11)$$

yani;

$$f(x,y) = \max[\min(x, 1-y), \min(1-x, y)] \quad (2.12)$$

Diğer bir ifadeyle, Denklem (2.12) fonksiyonu, üyelik değerleri ile tanımlanan iki bulanık küme arasında tanımlanan bir fonksiyondur ve bu fonksiyonun üyelik değerleri nesnelere üyelik değerleri arasındaki  $(\cdot)$  ve  $(+)$  işlemleri ile tanımlanır.

Takagi-Sugeno bulanık çıkarım sistemlerinde ardıllar girdi değişkenleri ile çıktı değişkenleri arasındaki doğrusal veya doğrusal olmayan fonksiyonlar ile ifade

edilmektedir. “Bulanık fonksiyonlar” bulanık kural tabanlı sistemlerde bulanık kurallar yerine kullanılır. Bu sistemlerde her yerel model, yani bulanık kural, ayrı birer fonksiyon ile tanımlanır.

Türkşen (2008), “Bulanık Fonksiyonlar”ı sistem modellerinin yapısını tanımlamak veya bu modeller ile çıkarsama yapmak için önerilmiştir. Önerilen “Bulanık Fonksiyonlar” çok değişkenli kesin değerli fonksiyonlar olup, X girdi değişkenlerinin yanı sıra bulanık kümedeki nesnelerin üyelik değerlerinin,  $\mu$ , de kullanılması ile,  $f(X, \mu)$ , tanımlanmıştır. Bu tip bulanık fonksiyonlar bulanık kural tabanı yapısındaki her bir eşsiz bulanık kuralın, fonksiyonlarca gösterimini temel alan bir düşünceden çıkar. Bulanık fonksiyonları bu şekilde formüle etmenin dezavantajlarından biri yalnızca bulanık fonksiyonların nasıl formüle edileceği ve verilen sistemin bulanık kümelerinin ne şekilde saptanacağı bilgisini gerektirmesidir. Diğer taraftan bulanık kural tabanlarına göre daha az bulanık işlemci gerektirdiği için daha kullanışlıdır. Bu bulanık fonksiyonların parametrelerinin bulunması için herhangi bir fonksiyon tahmin metodu, örneğin en küçük kareler (Türkşen, 2008) veya sinir ağları araç olarak kullanılabilir.

### **2.3. Bulanık Öbeleme Algoritmaları**

Öbeleme algoritmaları üzerine birçok çalışma yapılmakta olup, bunlar öbeleme yapısına göre bulanık bağıntıları temel alan, amaç fonksiyonunu ve kovaryans matrisini temel alan, parametrik olmayan sınıflandırma, sinir ağları-bulanık öbeleme olarak sınıflandırılabilir.

Bu tez kapsamında amaç fonksiyonunu temel alan bulanık öbeleme algoritmaları kullanılmaktadır. Amaç tabanlı algoritmalar, her öbeğe bir hata atayarak bu değerleri bir fonksiyon ile değerlendirerek hatayı en küçükmeye çalışır, diğer bir ifade ile bir optimizasyon problemi çözmeye çalışır.

Amaç fonksiyonu, bulanık bölümlene matrisi ve öbek merkezi bu algoritmalara ait ortak bazı ifadelerdir. Bu ifadelerin tanımları aşağıda verilmiştir. (Ünal, 2009)



Tanım (Amaç Fonksiyonu)  $J(f)$  veya  $J$ , bir hata ölçüsüdür ve bulanık öbeikleme algoritmasında amacımız öbek algoritmalarının yapısına göre  $J$ 'nin global en küçüğünü bulmaktır.

$X=\{x_1,x_2,\dots,x_3\}$  n nesneli bir kümeyi gösterebilir, her  $k$  nesnesi,  $k=1,\dots,n$ ,  $nv$ , boyutlu bir özellik vektörünü gösterebilir,  $x_k=[x_{1,k},\dots,x_{nv,k}]^T \in \mathbb{R}^{nv}$ . Bu takdirde,  $n$  adet özellik vektörünün bir kümesi  $n \times nv$  boyutlu bir veri matrisi ile Denklem (2.13)'deki gibi gösterilebilir;

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,nv} \\ \dots & \dots & \dots & \dots \\ x_{n,1} & x_{n,2} & \dots & x_{n,nv} \end{bmatrix} \quad (2.13)$$

Tanım (Bulanık Bölümleme Matrisi) Bulanık Bölümleme Matrisi,  $U$ , her  $x_k, k=1,\dots,n$ , nesnesinin her  $i, i=1,\dots,c$ , öbeğindeki üyelik derecelerinin bir matrisidir.  $i$ . öbekteki  $k$ . vektörün üyelik derecesinin değeri  $\mu_{ik} \in U$  ile gösterilir. Bölümleme matrisinin yapısı Denklem (2.14)'de verildiği gibidir;

$$U = \begin{bmatrix} \mu_{1,1} & \mu_{1,2} & \dots & \mu_{1,n} \\ \dots & \dots & \dots & \dots \\ \mu_{c,1} & \mu_{c,2} & \dots & \mu_{c,n} \end{bmatrix} \quad (2.14)$$

Tanım (Öbek Merkezi/Prototipi) Bulanık öbeikleme algoritmasında, her öbek “öbek merkezi” veya “öbek prototipi” olarak adlandırılan bir vektör ile gösterilir.  $nv$  boyutlu özellik vektörlerinden oluşan bir veri kümesinde, bulanık öbek algoritması  $c$  adet öbek merkezi,  $V=[v_1 \ v_2 \ \dots \ v_c]^T \in \mathbb{R}^{c \times nv}$ , tanımlar ki burada her öbek merkezi de,  $v_i \in \mathbb{R}^{nv}$ ,  $nv$  boyutlu bir vektördür. Her öbek merkezi ( $v_i$ ) genellikle nesnelere merkezleri olarak gösterilir, örneğin ilgili öbeğe ait tüm verinin ortalaması gibi.

### 2.3.1. Bulanık öbek ortalama öbeikleme metodu

BÖO algoritması incelenen veri kümesine merkezler ve bulanık bölümlenmeler bulan bir algoritma olup, birçok veri analizinde kullanılabilen bir yöntemdir. Bu öbekler daha önce analizi yapılmamış verilerde önerilen altyapı veya bilinen altyapıların doğrulanması açısından kullanışlıdır. Alt kümelerin birleştirilmesinde kullanılan öbeikleme kriteri en küçük kareler amaç fonksiyonunun genelleştirilmiş bir halidir.

$X=\{x_1,x_2,\dots,x_N\}$  ve  $Y=\{y_1,y_2,\dots,y_N\}$   $R^n$ 'de  $N$  gözlem örneği,

$x_k$ :  $k$ . özellik vektörü,

$x_{kj}$ :  $x_k$ 'nın  $j$ . özelliği olsun.

Eğer  $c$  bir tamsayı,  $2 \leq c < n$ , ise  $X$ 'in geleneksel veya katı bir  $c$ -bölümlemesi  $X$ 'nin alt kümelerinin  $c$ -değişken seti  $(X_1, X_2, \dots, X_c)$  Denklem (2.15)'deki koşulları sağlar;

$$X_i \neq \emptyset, 1 \leq i \leq c;$$

$$X_i \cap X_j \neq \emptyset, i \neq j \quad (2.15)$$

$$\bigcup_{i=1}^c X_i = X$$

Denklem seti (2.15)'de  $\emptyset$  boş kümeyi,  $\cap$  kesişimi ve  $\cup$  ise bileşimi göstermektedir.

BÖO algoritmaları en iyi, Denklem seti (2.15)'deki koşulların yeniden ifade edilmesi ile tarif edilir. Bu bağlamda,  $U$  gerçek bir  $c \times N$  matris olsun,  $U = [\mu_{ik}]$ . Denklem seti (2.16)'da,  $U$  Denklem seti (2.15)'te yer alan  $\{X_i\}$  bölümlemesinin matris gösterimidir;

$$\mu_i(x_k) = \mu_{ik} = \begin{cases} 1; x_k \in X_i \\ 0; \text{d.d.} \end{cases}$$

$$\sum_{k=1}^N \mu_{ik} > 0 \quad \forall i \text{ için} \quad (2.16)$$

$$\sum_{i=1}^c \mu_{ik} = 1 \quad \forall k \text{ için}$$

Denklem (2.16)'da,  $\mu_i$  bir fonksiyondur,  $X \rightarrow \{0,1\}$ .  $\mu_i$  ve  $X_i$  birbirini tanımlar, bu sebeple  $\mu_i$  bölümlemenin bir katı altkümesi olarak düşünülebilir. Denklem setleri (2.15) ve (2.16)'nın koşulları eşit olduğundan  $U$ ,  $X$ 'in katı  $c$ -bölümlemesi olarak ifade edilir.  $U$ 'nun elemanları Denklem (2.16)'nın 2. ve 3. denklemlerini sağladığı ve  $[0,1]$  birim aralığında değerler aldığında,  $U$   $X$ 'in bulanık  $c$ -bölümlemeleri olarak tanımlanabilir.

Bir  $x_k$  noktası tamamıyla tek bir öbeğe ait olabilir veya kısmi olarak bir öbeğe ve onu tümleyecek şekilde bir veya birden fazla başka öbeğe ait olabilir. Bu durum bulanık bölümlenme ile mümkündür.  $X$ 'in katı ve bulanık  $c$ -bölümlenmeleri Denklem seti (2.17)'deki gibi gösterilir;

$$M_c = \{U_{c \times N} | \mu_{ik} \in \{0,1\}\} \quad (2.17)$$

$$M_{fc} = \{U_{c \times N} | \mu_{ik} \in [0,1]; \text{denklem}(2.16)\}$$

Literatürde farklı öbekleme kriterleri  $X$ 'in en iyi bulanık  $c$ -bölümlenmelerinin tanımlanması için önerilmektedir. Bulanık öbek ortalamaları metodunda; genelleştirilmiş en küçük karesel hatalar fonksiyonu kullanılmaktadır,

$$J_m(U, v) = \sum_{k=1}^N \sum_{i=1}^c (\mu_{ik})^m \|x_k - v_i\|_A^2 \quad (2.18)$$

Denklem (2.18)'in bileşenlerini ifade etmek istersek;

$$X = \{x_1, x_2, \dots, x_n\} \subset \mathbb{R}^n = \text{veriler}$$

$c$ :  $X$ 'deki öbeklerin sayısı;  $2 \leq c < n$

$m$ : üssel ağırlık;  $1 \leq m < \infty$

$U$ :  $X$ 'in bulanık  $c$ -bölümlenmesi  $U \in M_{fc}$

(2.19)

$v = (v_1, v_2, \dots, v_c)$ : merkezler vektörü

$v_i = (v_{i1}, v_{i2}, \dots, v_{in})$ :  $i$  öbeğinin merkezleri  $i=1, \dots, c$

$\| \cdot \|_A: \mathbb{R}^n$ 'in  $A$  – norma bağımlılığı

$A$ :  $(n \times n)$  boyutlu pozitif tanımlı ağırlık matrisidir.

Denklem (2.18)'de gösterilen  $x_k$  ile  $v_i$ ,  $i=1, \dots, c$ , arasındaki mesafenin karesi  $A$  – normda Denklem (2.20)'deki gibidir;

$$d_{ik}^2 = \|x_k - v_i\|_A^2 = (x_k - v_i)^T A (x_k - v_i) \quad (2.20)$$

$(\mu_{ik})^m$  her karesel hatayı ağırlıklandırır – i. öbekteki  $x_k$ 'ların üyeliklerinin m. kuvvetidir. Denklem (2.19)'da verilen  $\{v_i\}$  vektörleri c-alkümelerin “öbek merkezleri”dir. Eğer  $m=1$  ise,  $J_m$  yalnızca katı  $U \in M_c$ 'lerde en küçüklenir ve böylece  $v_i$ 'lerin,  $X_i$ 'lerin geometrik merkezleri olur. Bu bilgilerden hareketle,  $J_m$ 'i  $x_k$ 'nın hangi niteliklerini gösterdiğini anlamak için asli ögelerine ayırabiliriz.

$d_{ik}^2 : x_k$  noktasından  $v_i$  öbek merkezine olan A – norm uzaklığının karesidir.

$(\mu_{ik})^m d_{ik}^2 : x_k$ 'nın i,  $i=1, \dots, c$  öbeğinde  $x_k$ 'nın i öbeğine olan üyeliği ile öbek merkezlerinin gösteriminden kaynaklanan A – hata karesidir.

$\sum_{i=1}^c (\mu_{ik})^m d_{ik}^2 : \{v_i\}$  veya  $\sum_{i=1}^c (u_{ik})^m d_{ik}^2 = \{v_i\}$  merkezlerinin tüm öbekler ile  $x_k$ 'ların kısmi yer değiştirmesine bağlı A – hatasının karelerinin toplamıdır.

$\sum_{k=1}^N \sum_{i=1}^c (\mu_{ik})^m d_{ik}^2 : v$  ile X'in yer değiştirmesine bağlı genelleştirilmiş A – hatalarının ağırlıklı toplamının tamamıdır.

Denklem seti (2.18)'deki değişkenlerin görevleri oldukça nettir.  $J_m$ 'de yer alan parametrelerden m ve A, daha ayrıntılı olarak incelenecektir. m üssel ağırlık olup,  $m \rightarrow 1$ 'e giderken  $J_m$ 'i minimize etmek kolay değildir. Diğer taraftan en iyi üyeliklerin girişiyle  $J_m$ ,  $m \rightarrow \infty$ , iken  $(1/c)$ 'ye yakınsar. Dolayısıyla, m 1'den uzaklaştıkça üyelikler azalmaktadır, bu da merkezlerden uzaklaşmaya sebep olmaktadır. Çelikyılmaz ve Türkşen (2009) ne teorik ne de hesaba dayalı bir bulgunun en iyi bir m ayırt edemediğini vurgulamışlardır. Bezdek (1981) m için kullanışlı değer aralığını [1,30] veya buna benzer bir aralık olarak tanımlamıştır. Bezdek (1981) Bulanık Öbek Ortalamaları yöntemi için çoğu veride  $1,5 \leq m \leq 3,0$  aralığının iyi sonuçlar verdiğini belirtirken, Özkan ve Türkşen (2007) ise  $1,4 \leq m \leq 2,6$  aralığının iyi sonuçlar verdiğini, Höppner ve Klawonn ise  $m \leq 1,5$  aralığının iyi sonuçlar verdiğini çeşitli çalışmalarında vurgulamışlardır.

Amaç fonksiyonunun irdelenmesi gereken, bir diğer parametresi  $A$  ağırlık matrisidir.  $R^n$ 'de tanımlı her  $A$  – norm Denklem (2.21)'deki ifadeyle bir iç çarpıma sebep olmaktadır,

$$\langle x, y \rangle_A = x^T A y \quad (2.21)$$

Bu öbekleme algoritmasının amaç fonksiyonu ile kullanılabilen birçok  $A$ – norm vardır, ancak bunlardan çok küçük bir kısmı, uygulamada geniş bir kullanım alanı bulmaktadır. Bu algoritmanın amaç fonksiyonu Denklem seti (2.18) ile yaygın olarak kullanılan en önemli 3 norm şunlardır;

$A=I$  Euclid Norm

$$A=D_x^{-1}: \text{Diagonal Norm} \quad (2.22)$$

$A=C_x^{-1}$ : Mahalonobi Norm

Denklem seti (2.22)'deki her bir norm kendine has bir ağırlık matrisine sahiptir. Örneğin; Mahalonobis Norm'daki  $C_x$  kovaryans matrisi olup Denklem (2.23)'deki gibi hesaplanır;

$$C_x = \sum_{k=1}^N (x_k - c_x)(x_k - c_x)^t \quad (2.23)$$

burada  $c_x$   $X$ 'in örnek ortalamasıdır.

Denklem (2.22)'de yer alan köşegen norm  $D_x(d_x)_{ii}=a_i$  köşegen elemanlarına sahip bir köşegen matristir, burada  $\{a_i\}$   $C_x$ 'in özdeğerlerini göstermektedir. Denklem (2.22)'da yer alan Euclid Norm ile ifade edilen  $I$  ise birim matristir.

Bu seçeneklere ait geometrik ve olasılıklı çıkarımların detaylı tartışmaları Bezdek'in (1981) çalışmasında görülebilir.

$X$ 'nin en iyi bulanık öbeklemeleri,  $J_m$ 'in yerel en küçüğü olan  $(\hat{U}, \hat{v})$  çifti ile tanımlanır.  $m > 1$  için, eğer tüm  $j$  ve  $k$ 'lar için  $x_k \neq \hat{v}_j$  ise  $(\hat{U}, \hat{v})$   $J_m$  için yerel en iyi olabilir, ancak ve ancak;

$$\hat{v}_i = \sum_{k=1}^N (\hat{\mu}_{ik})^m x_k / \sum_{k=1}^N (\hat{\mu}_{ik})^m ; 1 \leq i \leq c \quad (2.24)$$

$$\hat{\mu}_{ik} = \left( \sum_{j=1}^c \left( \frac{\hat{d}_{ik}}{\hat{d}_{jk}} \right)^{2/(m-1)} \right)^{-1} ; 1 \leq k \leq N ; 1 \leq i, j \leq c$$

Burada,  $\hat{d}_{ik} = \|x_k - \hat{v}_i\|_A$  'dır.

Denklem (2.24)'de verilen öbek merkezi ve üyelik derecesi hesaplamalarında ileri geri döngüler ile  $J_m$ 'in en iyilenmesi için ortalamaları sağlarlar. Bu tekrarlar  $\hat{U} = [\hat{\mu}_{ik}]$ ,  $i=1, \dots, c$ ,  $k=1, \dots, N$  veya  $\hat{v} = [\hat{v}_i]$ ,  $i=1, \dots, c$ 'nin ard arda girişlerindeki kullanıcı tanımlı küçük değişime (ör.,  $10^{-3}$ ,  $10^{-4}$ ) bağlı olarak algoritma tekrarına son verilir.

### 2.3.1.1. Bulanık Öbek Ortalamaları (BÖO) Algoritması Adımları

(A1) Verilen  $X = \{x_1, \dots, x_n\}$  veri kümesi için,

- c: öbek (kural) sayısı,
- m: bulanıklık derecesi,
- A: uzaklık normunu,
- $\epsilon$ : durdurma parametresini,
- mak-adım : maksimum adım sayısını belirle.

(A2)  $U^{(0)} \in M_{fc}$  için bir başlangıç matrisi seç.

(A3) Sonra adım t'yi ilerlet.  $t=0, 1, \dots, \text{mak-adım}$

(A4)  $\hat{v}^{(t)}$ 'yi Denklem (2.24)'deki gibi hesapla,  $i=1, 2, \dots, c$ .

(A5) Denklem (2.24) ile  $\hat{U}^{(t+1)} = [U_{ik}^{(t+1)}]$  güncel üyelik matrisini hesapla.

(A6) Eğer  $\|\hat{U}^{(t+1)} - \hat{U}^{(t)}\| < \epsilon$  ise dur. Değilse  $\hat{U}^{(t)} = \hat{U}^{(t+1)}$  olarak güncelle ve (A4)'e dön.

### 2.3.2. Bulanık öbek regresyon modelleme (BÖRM) öbektleme metodu

BÖRM algoritması çok basit şekilde tariflemek gerekirse ve iki boyutta düşünülürse; girdi değişkeninin hangi regresyon denklemini kullanılacağına karar veren bir yöntemdir. Hataway ve Bezdek bu tip regresyon probleminin tanımını yapmak için Hosmer'ın (1974) örneğini ele almıştır. Bu örneğe benzer bir başka örnek ile problemi

tanımlamak istersek; birden fazla araç üretim hattındaki işçi sayısı ve üretilen araç maliyetini düşünelim. İşçi sayısının üretilen araç maliyeti ile doğru orantılı olduğunu ancak bu orantının her bir üretim hattında farklılık gösterdiği bilinmektedir. Burada verinin üretim hattı bilgisini içermeyen varsayımı vardır. Üretim hatlarına ait doğrusal ilişki eğrilerini tanımlayan parametreler, regresyon problemi olarak veri analizinde kullanılarak tahmin edilebilir. Bu algoritma için c, öbek sayısının bilindiği varsayımı geçerlidir. Burada üretim hattı sayısı öbek sayısını göstermektedir. Öbek sayısı bilinmeyen ve çok girdili problemlerde de farklı öbek sayıları denenerek bu algoritma çalışılabilir.

BÖRM'ün ilgilendiği bu tip regresyon problemlerinin çözümü için önerilen alternatiflerden birisi katı c-ortalamar (Bezdek, 1981) gibi herhangi bir geleneksel öbekleme algoritması kullanılarak elde edilen c-bölümleme için aşağıda daha sonra verilen Denklem (2.26)'yı her bir öbek için çözmek olacaktır. Bu yöntemin amacı veriyi bölümlenmek ve aynı zamanda en uygun regresyon modellerini tanımlayan parametrelerin tahminini sağlamaktır (Hataway ve Bezdek, 1993).

BÖRM algoritmasını BÖO'dan ayıran en önemli farklılık öbek merkezlerinin geometrik nesnelere yerine fonksiyonlar olmasıdır. BÖRM yalnızca doğrusal örüntüleri değil aynı zamanda 2. dereceden polinom şeklindeki örüntüleri de tanımlayabilmektedir.

BÖO ile BÖRM algoritmaları karşılaştırıldığında; iki algoritmanın öbek gösterimlerinin birbirinden farklı olduğu anlaşılmaktadır. BÖO'da karşımıza Euclid norm kullanıldığında hiper küresel yapıda öbek merkezleri çıkarken, BÖRM'de karşımıza hiper düzlemsel yapıda öbekler çıkmaktadır. Ayrıca BÖO'da öbek merkezleri geometrik şekiller ile ifade edilebiliyor iken, BÖRM'de öbekler fonksiyonlar ile ifade edilmektedir.

BÖRM'ün öbek gösterimi nv -boyutlu girdi ve tek çıktı, yani çok girdi tek çıktı modeli, ile Denklem (2.25)'deki gibi gösterilir, burada  $\beta_i$  her  $i, i=1, \dots, c$ , fonksiyonunun regresyon katsayılarıdır;

$$y_i = \beta_i^0 + \beta_i^1 x_1 + \dots + \beta_i^{nv} x_{nv} \quad (2.25)$$

BÖO algoritması öbek merkezlerini Denklem (2.24)'da verildiği gibi hesaplar. BÖRM öbekleri temsil eden fonksiyonları ağırlıklandırılmış en küçük kareler regresyon algoritması ile hesaplar.

Burada ağırlıklandırma işlemi üyelik değerlerinden oluşan bir köşegen matris ile yapılır (bkz., Denklem (2.30)).

BÖRM'de her bir öbek ya da diğer bir ifade ile her bir kural şu şekilde tanımlanır;

$$y_k = f_i(x_k, \beta_i) \quad (2.26)$$

$x_k = [x_{1,k}, \dots, x_{nv,k}]^T \in \mathbb{R}^{nv}$  k. veri nesnesini gösterir.  $\beta_i \in \mathbb{R}^{nv}$ ,  $i=1, \dots, c$ , iken,  $f_i$  fonksiyonlarının parametreleridir,  $c$  ise fonksiyonların toplam sayısını göstermektedir. Bu fonksiyonların performansı genellikle şöyle ölçülür;

$$E_{ik}(\beta_i) = (y_k - f_i(x_k, \beta_i))^2 \quad (2.27)$$

Amaç fonksiyonu ise toplam hatanın en küçüklenmesi olup,

$$E(U, \beta_i) = \sum_{i=1}^c \sum_{k=1}^n (\mu_{ik})^m E_{ik}(\beta_i) \quad (2.28)$$

burada  $m \in (1, \infty)$  olup "bulanıklaştırıcı" üstür ve BÖO'dan (Bezdek, 1981) farklı olarak fonksiyonların örtüşmesini belirler.

BÖRM'de, üyelik değerleri,  $\mu_{ik}$ , ağırlıklar olarak anılır, yani regresyon fonksiyonlarının katsayılarıdır. Bu sebeple bu algoritmanın üyelik fonksiyonu şu şekli alır;

$$\mu_{ik} = \sum_{j=1}^c (E_{ik}/E_{jk})^{\frac{1}{1-m}}, \forall i, j=1, \dots, c < n \quad (2.29)$$

Amaç fonksiyonunun - Denklem (2.28) - en küçüklenmesi ile en iyileme modeli sağlanır. Algoritma adımları aşağıda verilmiştir.



### 2.3.2.1. Bulanık Öbek Regresyon Modeli (BÖRM) Algoritması

Verilen  $X=\{x_1, \dots, x_n\}$  veri vektörleri için;

(A1) regresyon modellerinin yapısını iskelet olarak seç,

- c: öbek (kural) sayısını,
- m : bulanıklık derecesini,
- $\varepsilon$  : durdurma sabitini,
- mak-adım : maksimum adım sayısını, ( $t=1, \dots, \text{mak-adım}$ )
- U: başlangıç bölümlene matrisini rasgele oluştur.

(A2) Amaç fonksiyonunu en küçükleyecek  $\beta_i$  model parametrelerinin değerlerini hesapla;

$$\beta_i = [X^T D_i X]^{-1} X^T D_i y \quad (2.30)$$

burada  $D_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{in} \end{bmatrix}$  şeklindedir.

(A3) Bölümlene matrisini,  $\mu_{ik} \in U$ , Denklem (2.29)'u kullanarak güncelle. Eğer  $|U^{(t)} - U^{(t-1)}| \leq \varepsilon$  ise dur, değilse (A1)'e git.

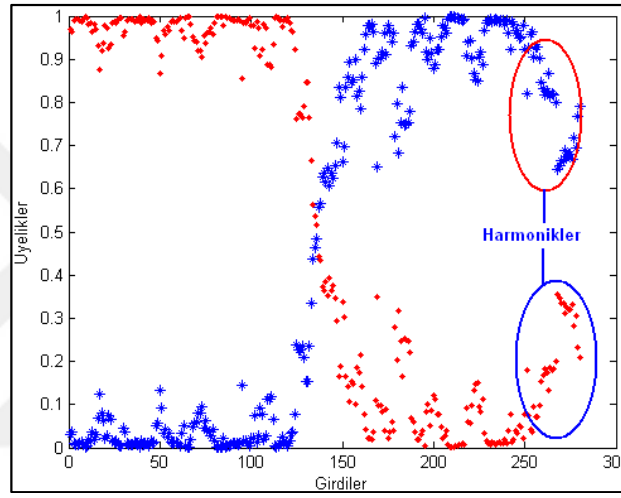
### 2.3.3. Höppner & Klawonn'un bulanık model öbekleme metodu

Höppner ve Klawonn (2003) BÖO ile BÖRM algoritmalarını birleştirerek farklı bir öbekleme algoritması olan Bulanık Model (BM)'i önermişlerdir. kesin üyelik değerlerini ödüllendirerek bulanık öbeklemede kullanılan amaç fonksiyonu değiştirilmiş ve farklı üyelik fonksiyonları saptanmıştır. Böylece harmoniklerin etkilerinden kurtularak tek tepeli olma veya destek bağımlılığından kurtulmak gibi gereksinimler karşılanmış olmaktadır. Harmonik elde edilmek istenen üyelik fonksiyonlarının eteklerinde meydana gelen ufak sapmalardır (Şekil 2.4).

Burada kullanılan üyelik fonksiyonu Denklem (2.31) ile verilmiştir;

$$\mu_{ik} = \sum_{j=1}^c \left( \frac{d_{ik}^2 - (\min d_{ik}^2 - \eta)}{d_{jk}^2 - (\min d_{jk}^2 - \eta)} \right)^{-1}, \eta > 0 \quad (2.31)$$

burada  $\eta > 0$  kullanıcı tanımlı bir sabittir ve öbek merkezine olan uzaklığa göre hangi nesnelerin öbek dışına doğru itileceğini belirlemeyi sağlar. Böylece öğelerin uzaklıklarını temel alarak harmoniklerden kurtulma işlemi büyük üyelikleri “1”e küçük üyelikleri de “0”a iterek üyelik değerleri bulmaktır. BM’de, her fonksiyon,  $\hat{y}_i = \hat{\beta}_i^T \hat{x}_i$ , bir TS modelindeki bir kural olarak yorumlanabilir.



Şekil 2.4. Harmoniklerin görsel gösterimi

Voronoi uzaklıklarının direkt olarak uzaklık fonksiyonuna etkisi görülmemektedir, ancak üyelik fonksiyonundaki kesin üyeliklerin ödüllendirilmesi yoluyla bu durum öbek merkezlerini, öbek merkezleri de uzaklıkları etkilemektedir. Höppner ve Klawon'un (2003) önerdiği uzaklık şu şekilde ifade edilmiştir;

$$d^2((x_k, y_k)(v_i, \hat{\beta}_i)) = \underbrace{\|x_k - v_i(x)\|^2}_{\text{noktasal uzaklık}} + \underbrace{(y_k - \hat{\beta}_i^T \hat{x}_k)^2}_{\text{fonksiyon uzaklığı}} \quad (2.32)$$

burada  $(x_k, y_k)$  verilen bir girdi-çıkıktı veri örneği,

$x_k \in X, y_k \in Y, k=1, \dots, n$  n eğitim veri vektörlerinin toplam sayısı,

$d^2$ : uzaklık fonksiyonu,

$v_i$ : i öbeğinin öbek merkezi, (BÖO ile aynı öbek merkezi fonksiyonudur),

c: öbeklerin sayısı, (i=1,...,c)

$\hat{\beta}_i$ : her bir i öbeğinin polinom katsayıları,

$\hat{x}_k$  kullanıcı tanımlı bir polinomdur.

Örnek vermek gerekirse; Denklem (2.33)'de yer alan bir polinom olarak yapılandırılabilir. Bu polinoma ait katsayılar ise Denklem (2.34)'deki gibi güncellenir;

$$\hat{x}_1(x_1, x_2) = (1, x_1, x_2, x_1 x_2, x_1^2, x_2^2) \quad (2.33)$$

$$\hat{\beta}_i = \left( \sum_{k=1}^n (\mu_{ik})^m (y_k \hat{x}_k) \right) / \sum_{k=1}^n (\mu_{ik})^m (\hat{x}_k \hat{x}_k^T), \forall i=1, \dots, c \quad (2.34)$$

### 2.3.3.1. Bulanık Model Algoritması

(A1) c öbek sayısını,

- $\varepsilon > 0$  durdurma eşiğini,
- $\eta > 0$ 'ı seç.

(A2) öbek merkezlerini,  $v_i$  başlat

(A3) Denklem (2.31) ile üyelik matrisini ve Denklem (2.32) ile uzaklıkları güncelle

(A4) BÖO'nun Denklem (2.24a) ile öbek merkezlerini ve Denklem (2.34) ile de katsayıları güncelle

(A5)  $|U^{(t)} - U^{(t-1)}| < \varepsilon$  oluncaya kadar (A3) ve (A4)'ü tekrarla.

### 2.3.4. Bulanık fonksiyon yapılı bulanık model (BFBM)

BÖRM kullanılan geçici fonksiyon yapısının katsayılarını güncellemek için Denklem (2.30)'da verilen fonksiyonu kullanır. Halbuki Höppner ve Klawonn'un BM'i geçici fonksiyon katsayılarını güncellemek için Denklem (2.34) ile verilmiş olan fonksiyonu kullanır. Dolayısıyla, BM doğrudan BÖO ve BÖRM'in doğrudan birleştirilmesi ile elde edilmemiştir.

Ayrıca BM BÖO'dan kaynaklanan noktasal uzaklıklardan ve BÖRM'den kaynaklanan fonksiyona bağımlı hatalardan ileri gelen bir uzaklık fonksiyonuna sahip iken BÖRM yalnızca fonksiyona bağımlı bir hatalardan ileri gelen bir uzaklık fonksiyonundan yola

çıkar. Dolayısıyla, burada Höppner ve Klawonn'un BM'i oluşturulurken neden BÖRM'nin geçici fonksiyon yapısının katsayı güncelleme fonksiyonunun kullanılmadığı sorusu akla gelmektedir. Buradan yola çıkarak, hem Höppner ve Klawonn'un BM'sine alternatif oluşturabilecek yeni bir yaklaşım ortaya konulmuş hem de BÖRM ve BÖO metotları geliştirilmiş olmaktadır.

Burada önerilen yaklaşımda yine BÖO ve BÖRM'ün uzaklık fonksiyonlarını birleştirerek, şu uzaklık fonksiyonunu oluşturur;

$$d^2((x_k, y_k)(v_i, \hat{\beta}_i)) = \|x_k - v_i(x)\|^2 + (y_k - \gamma_i^T \hat{x}_k)^2 \quad (2.35)$$

Denklem (2.35)'te,  $(x_k, y_k)$  verilen bir girdi-çıkıktı veri örneği,  $x_k \in X, y_k \in Y, k=1, \dots, n$  n eğitim veri vektörlerinin toplam sayısı,  $d^2$  uzaklık fonksiyonu,  $v_i$  i öbeğinin öbek merkezi,  $i=1, \dots, c$ , c öbeklerin sayısıdır.  $\hat{x}_k$  kullanıcı tanımlı bir polinom olup Denklem (2.36)'daki gibi olabilir;

$$\hat{x}_{ik}(x_1, x_2) = (1, \mu_{i1}, \mu_{i2}, x_1, x_2, \mu_{i1}x_1, \mu_{i2}x_2) \quad (2.36)$$

Bu polinoma ait katsayılar Denklem (2.37)'deki gibi güncellenir;

$$\gamma_i = [\hat{X}^T D_i \hat{X}]^{-1} \hat{X}^T D_i Y \quad (2.37)$$

burada  $D_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{in} \end{bmatrix}$  şeklindedir.

$D_i$  matris yapısında yer alan üyelik değerleri güncelleme işlemi ise yine BM'de olduğu gibi Denklem (2.31) fonksiyonu ile yapılır.

#### 2.3.4.1. Bulanık Fonksiyon Yapılı Bulanık Model Algoritması

(A1) c öbek sayısını,

- $\varepsilon > 0$  durdurma eşiğini,
- $\eta > 0$ 'ı seç

(A2) öbek merkezlerini,  $v_i$  hesapla

(A3) Denklem (2.31) ile üyelik matrisini ve Denklem (2.35) ile uzaklıkları güncelle

(A4) BÖO'nun Denklem (2.24a) merkez fonksiyonu ile öbek merkezlerini ve Denklem (2.37) ile de katsayıları güncelle

(A5)  $|U^{(t)} - U^{(t-1)}| < \epsilon$  oluncaya kadar (A3) ve (A4)'ü tekrarla

### 2.3.5. Geliştirilmiş bulanık öbikleme (GBÖ) öbikleme metodu

GBÖ (Çelikyılmaz ve Türksen, 2007, 2008, 2009) yaklaşımı Höppner ve Klawonn (2003), Chen vd. (1998) ve Menard (2001) tarafından yapılan çalışmaları temel alır. Bu araştırmacıların yaptığı çalışmaların yapısı ile Çelikyılmaz ve Türksen'in GBÖ yaklaşımı (2007, 2008, 2009) standart bulanık öbikleme ve regresyonu birleştiren amaç fonksiyonu aynı olduğu için birbirlerine benzemektedir. İlk bakışta anlaşılmasa da bunlar arasındaki yapısal farklılıklar bunların özellikle ortaya konan farklılıklarından ileri gelir. Çelikyılmaz ve Türksen'in önerdiği GBÖ, BM'de (Höppner ve Klawonn, 2003) olduğu gibi BÖO öbikleme metodu ile Hataway ve Bezdek'in (1993) öbek merkezlerini polinomlar olarak kullanan BÖRM'ü birleştirir.

Celikyılmaz ve Türksen (2.32)'deki geometrik ve fonksiyonel uzaklıkları birlikte içeren fonksiyonunun yapısını kullanarak yeni bir öbikleme algoritması önermişlerdir (2007, 2008, 2009).

Höppner ve Klawonn'un (2003) geliştirdiği BM öbikleme metodu ile GBÖ (Çelikyılmaz ve Türksen, 2007, 2008, 2009) arasında yapısal bir farklılık mevcuttur. BM'de polinom fonksiyonlar üyelik değerlerinin ağırlıklandırmak için kullanılırlar ve her bir öbekteki çıktının tahmininde kullanılırlar. Ayrıca bunların hatası uzaklık fonksiyonuna ikinci bir terim olarak eklenir. Fakat Çelikyılmaz ve Türksen'in önerdiği GBÖ (2007, 2008, 2009) algoritmasının her adımında, girdi değişkenlerinin üyelik değerleri ve bunların kullanıcı tanımlı dönüşümleri kullanılarak her öbek için özel bir regresyon fonksiyonu tahmin edilir.

Uzaklık fonksiyonuna hata bilgisinin eklenmesi üyelik fonksiyonunu etkiler veya üyelik fonksiyonunda meydana gelen değişiklik uzaklık fonksiyonunu etkiler. Höppner ve Klawonn (2003) çalışmalarında böyle bir etki açık bir şekilde araştırılmamıştır. Denklem (2.31)'de verildiği şekli ile yeni bir üyelik fonksiyonu ortaya konmuştur. Höppner ve Klawonn'ın (2003) sunduğu üyelik fonksiyonu

özellikle daha kesin üyelik değerleri elde etme amacına hizmet eder. Uzaklık fonksiyonunun değişmesi ile birlikte yeni bir üyelik fonksiyonu sunulmuştur.

Çelikyılmaz ve Türkşen'in önerdiği GBÖ algoritması esnasında, her öbek için regresyon fonksiyonları basit en küçük kareler tahmini metodunun lineer modelleri ile veya çekirdek fonksiyonları ile daha karmaşık olan kuvvet vektör regresyonunun lineer olmayan modelleri ile tahmin edilir (2007, 2008, 2009). Bu çalışmada en küçük kareler tahmini metodu ile yapılan tahminler ele alınmıştır.

Bulanık öbeklemeyi temel alan yeni amaç fonksiyonu regresyon fonksiyonlarının hatalarını azaltabilen üyelik değerleri bulmak için önerilmiştir. Önerilen algoritma yalnızca verinin en iyi bölümlenmelerini araştırır, aynı zamanda BF'lar (bulanık fonksiyonlar) ile çıktının tahmininde üyelik değerlerinin tahmin gücünü arttırmayı amaçlar. Dolayısıyla, Çelikyılmaz ve Türkşen'in önerdiği öbekleme algoritması "geliştirilmiş bulanık öbekleme" olarak adlandırılır (2007, 2008, 2009).

Verilen bir çok girdili tek çıktılı sistem için, girdi matrisi şu şekilde gösterilsin  $xy = \{(x_1, y_1), \dots, (x_{nd}, y_{nd})\}$ , burada  $x_k = \{x_1 \dots x_{nv}\}$  nv boyutlu k. veri vektörü,  $k=1, \dots, nd$ , nd veri vektörlerinin toplam sayısı (örnek sayısı) ve her  $y_k$  da bunlarla ilgili çıktı değeridir.

Bu algoritma ile verilen amaç fonksiyonu; bölümlenme matrisinin iyi bir gösterimini bulmak böylece her öbeğin BF'ların tahmininde kullanmak için üyelik değerlerini hesaplamayı sağlamaktır. Diğer bir amacı ise BF modellerinin hatasını en küçükleyecek üyelik değerleri sağlayarak BSM algoritmasının performansını arttırmaktır. Üyelik fonksiyonlarının en iyilenmesi için Çelikyılmaz ve Türkşen'in (2008) önerdiği GBÖ'de, amaç fonksiyonuna regresyon fonksiyonlarının hatası aşağıdaki gibi eklenmiştir;

$$J_m^{IFC} = \underbrace{\sum_{i=1}^c \sum_{k=1}^{nd} \mu_{ik}^m d_{ik}^2}_{BÖO} + \sum_{i=1}^c \sum_{k=1}^{nd} \mu_{ik}^m \underbrace{\frac{(y_k - f_i(\tau_{ik}))^2}{\text{Bulanık Fonksiyonun Karesel Hatası}}}_{(2.38)}$$

burada  $\mu_{ik}$  i öbeğindeki k veri vektörünün üyelik değeri,  $i=1, \dots, c$ , ve m öbekler arasındaki örtüşmeyi belirleyen bulanıklık derecesi parametresidir. Denklem

(2.38)'deki en küçüklenecek olan amaç fonksiyonunun,  $J_m^{IFC}$ , ilk terimi BÖÖ'dan da bilindiği gibi her öbekteki öğelerin üyelikler ile ağırlıklandırılmış uzaklıkları toplamıdır. İkinci terim ise her  $i$ . öbek için bulanık fonksiyonun toplam karesel hatasıdır,  $f(\tau_i)$ . İkinci terim girdi değişkenleri olarak orijinal skalar girdileri değil, üyelik değerlerini ve/veya onların dönüşümlerini kullanılarak oluşturulan tahmini kullanıcı tanımlı BF'lerin karesel hatalarını ölçer (Çelikyılmaz ve Türkşen, 2008).

Bulanık fonksiyonun tahmini için kullanılan,  $\tau_i$ , üyelik değerlerini ve/veya bunların dönüşümlerini içeren kullanıcı tanımlı bir girdi matrisidir. Örneğin  $i$ . öbeğin girdi vektörü üyelik değerleri ve bunların log-odds dönüşümlerini içeren 2-boyutlu girdi vektöründen,  $\tau_i = [\mu_i, \log((1-\mu_i)/\mu_i)]$ , oluşsun.  $i$ . öbek için  $R^2$ 'deki düzlemler kümesi Denklem (2.39)'deki gibi tanımlanabilir;

$$f_i = \hat{\omega}_{0i} + \hat{\omega}_{1i}\mu_i + \hat{\omega}_{2i}\log((1-\mu_i)/\mu_i), \text{veya } f_i = (\tau_i \hat{\omega}_i) \quad (2.39)$$

$f_i = \hat{\omega}_{0i} + \hat{\omega}_{1i}\mu_i + \hat{\omega}_{2i}\log((1-\mu_i)/\mu_i)$ , burada  $\hat{\omega}_i^T = [\hat{\omega}_{0i} \ \hat{\omega}_{1i} \ \hat{\omega}_{2i}]$ 'dir.  $R^2$  BF'lerin özel bir yapısı şu şekilde tanımlanır;

$$\hat{y}_i = f_i(\tau_i \hat{\omega}_i) = \hat{\omega}_{0i} + \hat{\omega}_{1i}\mu_i + \hat{\omega}_{2i}\log\left(\frac{(1-\mu_i)}{\mu_i}\right) = \hat{\omega}_{0i} + \sum_{j=1}^2 \hat{\omega}_{ji} \tau_{ji} \quad (2.40)$$

burada  $\hat{y}_i$   $t$ 'inci tekrarda  $i$ 'inci bulanık fonksiyondan saptanan tahmini çıktı değeridir.  $\tau_i$   $t$ . tekrarda  $i$ . öbeğin üyelik değerleri ve bunun yanı sıra bunların log-odd dönüşümlerini içeren girdi matrisidir.  $\hat{\omega}$  en küçük kareler regresyon metodu kullanılarak, bulanık fonksiyonun tahmin edilmiş parametrelerini gösterir. Yeni uzaklık fonksiyonu aşağıdaki gibidir;

$$d_{ik}^{IFC} = (d_{ik}^2 + SE_{ik}) = \|x_k y_k - v_i(xy)\|^2 + (y_k - f(\tau_{ik}))^2 \quad (2.41)$$

burada  $x_k y_k$  girdi-çıktı vektörünü,  $v_i(xy)$   $i$  öbeğini,  $SE_{ik}$  ise  $y_k$  çıktı değeri ile geçici fonksiyonun değeri arasındaki hatayı göstermektedir. Her öbeğin,  $f(\tau_i)$ , tahmin edilmiş BF'leri gözlemlenen çıktıyı en iyi şekilde açıkladığında Denklem (2.41) ifadesinin ikinci terimi düşer.

Yeni amaç fonksiyonunun,  $J_m^{IFC}$ , en küçüklenmesi için çözüm amaç fonksiyonunun Lagrange dönüşümü kullanılarak ve  $\sum_i^c \mu_{ij} = 1$  kısıtı göz önünde bulundurularak bulunabilir. Dönüşüm sonucu elde edilen yeni üyelik fonksiyonu Denklem (2.42)'deki gibi bulunmuştur;

$$\mu_{ik} = \left( \sum_{j=1}^c \left[ \frac{d_{ik}^2 + (y_k - f_i(\hat{t}_{ik}))^2}{d_{jk}^2 + (y_k - f_j(\hat{t}_{jk}))^2} \right]^{1/(m-1)} \right)^{-1} \quad (2.42)$$

Çelikyılmaz ve Türkşen'in önerdiği GBÖ için öbek merkezi fonksiyonu BÖÖ'nun öbek merkezi fonksiyonu ile benzer olup çıktı değişkenini de içerir ve aşağıdaki gibi formüle edilir;

$$\forall_{1 < i \leq c} v_i = \frac{\sum_{k=1}^{nd} (\mu_{ik})^m (x_k y_k)}{\sum_{k=1}^{nd} (\mu_{ik})^m} \quad (2.43)$$

Verilen algoritmanın ilerletilebilmesi için bir başka öbekleme algoritmasından faydalanılarak bölümlene matrisi,  $U^0$ , ve öbek merkezleri,  $v^0$ , için başlangıç değerleri oluşturulmasına ihtiyaç vardır.

### 2.3.5.1. GBÖ – Geliştirilmiş Bulanık Öbekleme Algoritması

(A1) Denklem (2.39)'da olduğu gibi kullanıcı tanımlı bulanık fonksiyonların yapısını ve m bulanıklık derecesini, c öbek sayısını,  $\varepsilon$  durdurma sabitini belirle.

(A2) Bir öbekleme algoritması kullanarak, örneğin BÖÖ,  $U^{(t=0)}$  üyelik değerlerinin ve  $v^{(t=0)}$  öbek merkezlerini oluştur.

(A3) Her tekrar için  $t=1, \dots, mak$ -adım

(A3.1) Her öbek için (c adet) bulanık fonksiyonları hesapla ve her vektör için karesel hataları ölç,  $SE_{ik}, i=1, \dots, c, k=1, \dots, nd$ .

(A3.2) Denklem (2.42)'i kullanarak her öbekteki her bir girdi vektörü için üyelik değerlerini hesapla.

(A3.3) Denklem (2.43)'u kullanarak her öbeğin öbek merkezlerini bul.

(A3.4) Denklem (2.38) ile verilen amaç fonksiyonundaki değişim,  $\left| (J_m^{IFC})^t - \right.$

$\left. (J_m^{IFC})^{t-1} \right| < \varepsilon$  ise dur, değilse Adım 3.1'e dön.



### 2.3.6. Öbekleme yaklaşımlarının farklılıkları

Bu bölümde incelenen öbekleme algoritmaları ya geometrik ya polinomsal ya da hem geometrik hem polinomsal yapılar oluşturarak öbekleme yaparlar. Geometrik yapılar ile öbek merkezi olarak adlandırılan noktalar elde edilir. Örneğin 3 boyutlu bir veri vektörü düşünüldüğünde;  $X=\{x_1,x_2,x_3\}$  bu verinin  $i$  öbeğine ait öbek merkezi  $V_i=(v_{i1},v_{i2},v_{i3})$  şeklinde ifade edilir. Kullanıcı tanımlı polinom yapılar ile fonksiyonlar oluşturularak bu fonksiyonlara ait katsayılar elde edilir. Bu fonksiyonlar geçici bulanık fonksiyonlar olarak adlandırılır. Hataway ve Bezdek (1993) BÖRM’de geçici fonksiyonlar için ilk etapta doğrusal yapı önermiş olsa da fonksiyon yapısında girdilerin kuvvetlerinin de bulunabildiği örnekler yer vermişlerdir. Höppner ve Klawonn (2003) BM’de yine hem doğrusal hem de kullanıcı tanımlı olmak üzere fonksiyon yapısının doğrusal olmayabileceği durumları da incelemişlerdir. Çelikyılmaz ve Türkşen (2007, 2008, 2009) ise GBÖ için kullandıkları geçici fonksiyon yapısında hem üyeliklerin hem de üyeliklerin çeşitli dönüşümlerinin girdi teşkil ettiği bir fonksiyon yapısı önermişlerdir.

BÖRM’de (Hataway ve Bezdek, 1993) kullanılan fonksiyonun girdileri yalnızca gerçek girdiler ve/veya girdilerin kuvvetleri şeklinde olabilirken, fonksiyon katsayıları üyelikler ile ağırlıklandırılmış regresyon ile elde edilir. BM (Höppner ve Klawonn, 2003) algoritmasında fonksiyonun girdileri yine girdiler, girdilerin kuvvetleri ve/veya bu girdilerin birbirleri ile çarpımlarından oluşan kullanıcı tanımlı bir fonksiyon olup, bu fonksiyona ait katsayılar ise iyi bilinen BÖO algoritmasının geometrik merkezleri bulmak için kullandığı fonksiyona benzer bir fonksiyon yardımıyla bulunur. BFBM ise yine üyelikler, girdiler ve/veya bu girdilerin üyelikleri ile çarpımlarından oluşan kullanıcı tanımlı bir polinomdan oluşabilir. Bu fonksiyona ait katsayılar BÖRM’de olduğu gibi ağırlıklandırılmış regresyon ile bulunur. GBÖ’nün (Çelikyılmaz ve Türkşen, 2007, 2008, 2009) fonksiyon yapısında gerçek girdiler yerine üyelikler ve bunların dönüşümlerinden oluşan kullanıcı tanımlı bir yapı söz konusudur ve bu yapıya ait katsayılar ise regresyon ile bulunur.

GBÖ’de başlangıç öbek merkezlerini ve başlangıç üyeliklerini bulmak için herhangi bir öbekleme algoritması kullanımı gereklidir. Ancak BM algoritmalarında ve BÖRM algoritmasında böyle bir ön öbekleme ihtiyacı yoktur.

Tablo 2.1. Geçici fonksiyon yapılarına göre algoritmaların karşılaştırılması

Algoritma	Karşılaştırma Kriteri:	
	Geçici Fonksiyon Yapıları	Girdi Yapıları
BÖÖ (Bezdek, 1981)	Fonksiyon içermez.	
BÖRM (Hataway & Bezdek, 1993)	$f_i(x_k, \beta_i) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$ veya $f_i(x_k, \beta_i) = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + \beta_{n+1} x_1^2 + \dots + \beta_{2n} x_n^2$	$X_k = [x_1, x_2, \dots, x_n]$ veya $X_k = [x_1, x_2, \dots, x_n, x_1^2, x_2^2, \dots, x_n^2]$
BM (Höppner & Klawonn 2003)	$f_i(\hat{x}_k, \hat{\beta}_i) = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_1 x_2 + \hat{\beta}_4 x_1^2 + \hat{\beta}_5 x_2^2$	$\hat{X}_k(x_1, x_2) = [x_1, x_2, x_1 x_2, x_1^2, x_2^2]$ gibi kullanıcı tanımlı girdi üyelikleri kümesi
BFBM	$f_i(\hat{x}_k, \gamma_i) = \gamma_0 + \gamma_1 \mu_{i1} + \gamma_2 \mu_{i2} + \gamma_3 \mu_{i1} x_1 + \gamma_4 \mu_{i2} x_2$	$\hat{X}_{ik}(x_1, x_2) = [\mu_{i1}, \mu_{i2}, \mu_{i1} x_1, \mu_{i2} x_2]$ gibi kullanıcı tanımlı girdi ve bunların üyeliklerinden oluşan veri kümesi
GBÖ (Çelikyılmaz & Türkşen, 2008)	$f_i(\tau_{ik}, \hat{\omega}_i) = \hat{\omega}_0 + \hat{\omega}_1 \mu_i + \hat{\omega}_2 \log((1 - \mu_i) / \mu_i)$	$\tau_{ik} = [\mu_{ik}, \log((1 - \mu_{ik}) / \mu_{ik})]$ gibi kullanıcı tanımlı girdi üyelikleri kümesi

Tablo 2.2. Uzaklık fonksiyonuna göre algoritmaların karşılaştırılması

Algoritma	Karşılaştırma Kriteri: Uzaklık Fonksiyonu
BÖÖ (Bezdek, 1981)	$d_{ik}^2 = \ x_k - v_i(x)\ _A^2$ A seçilecek uzaklık normuna bağlıdır.
BÖRM (Hataway & Bezdek, 1993)	$E_{ik}(\beta_i) = (y_k - f_i(x_k, \beta_i))^2$
BM (Höppner & Klawonn 2003)	$d_{ik}^2 = \ x_k - v_i(x)\ ^2 + (y_k - f_i(\hat{x}_k, \hat{\beta}_i))^2$
BFBM	$d_{ik}^2 = \ x_k - v_i(x)\ ^2 + (y_k - f_i(\hat{x}_k, \gamma_i))^2$
GBÖ (Çelikyılmaz & Türkşen, 2008)	$d_{ik}^2 = \ x_k y_k - v_i(xy)\ ^2 + (y_k - f_i(\tau_{ik}, \hat{\omega}_i))^2$

Tablo 2.3. Algoritmalarla göre geçi fonksiyonların katsayılarını güncelleme

Algoritma	Karşılaştırma Kriteri: Geçi Fonksiyonların Katsayılarını Güncelleme
BÖRM (Hataway & Bezdek, 1993)	$\beta_i = [X^T D_i X]^{-1} X^T D_i y$ $D_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{in} \end{bmatrix}$ (Ağırlıklandırılmış regresyon (EKK))
BM (Höppner & Klawonn 2003)	$\hat{\beta}_i = \left( \sum_{k=1}^n (\mu_{ik})^m (y_k \hat{x}_k) \right) / \left( \sum_{k=1}^n (\mu_{ik})^m (\hat{x}_k \hat{x}_k^T) \right)$
BFBM	$\gamma_i = [X^T D_i X]^{-1} X^T D_i y$ $D_i = \begin{bmatrix} \mu_{i1} & 0 & \dots & 0 \\ 0 & \mu_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mu_{in} \end{bmatrix}$ (Ağırlıklandırılmış regresyon (EKK))
GBÖ (Çelikiylmaz & Türkşen, 2008)	$\beta_i = [\tau_i^T I \tau_i]^{-1} \tau_i^T I y$ (Lineer regresyon (EKK))

Tablo 2.4. Algoritmalarla göre üyelik güncelleme fonksiyonları

Algoritma	Karşılaştırma Kriteri: Üyelik Güncelleme Fonksiyonları
BÖÖ (Bezdek, 1981)	$\mu_{ik} = \left( \sum_{j=1}^c \left( \frac{\hat{d}_{ik}}{\hat{d}_{jk}} \right)^{2/(m-1)} \right)^{-1}$
BÖRM (Hataway & Bezdek, 1993)	$\mu_{ik} = \sum_{j=1}^c (E_{ik}/E_{jk})^{\frac{1}{1-m}}$
BM (Höppner & Klawonn 2003)	$\mu_{ik} = \sum_{j=1}^c \left( \frac{d_{ik}^2 - (\text{mind}_{ik}^2 - \eta)}{d_{jk}^2 - (\text{mind}_{jk}^2 - \eta)} \right)^{-1}, \eta > 0$
BFBM	$\mu_{ik} = \sum_{j=1}^c \left( \frac{d_{ik}^2 - (\text{mind}_{ik}^2 - \eta)}{d_{jk}^2 - (\text{mind}_{jk}^2 - \eta)} \right)^{-1}, \eta > 0$
GBÖ (Çelikiylmaz & Türkşen, 2008)	$\mu_{ik} = \left( \sum_{j=1}^c \left[ \frac{d_{ik}^2 + (y_k - f_i(\hat{\tau}_{ik}))^2}{d_{jk}^2 + (y_k - f_j(\hat{\tau}_{jk}))^2} \right]^{1/(m-1)} \right)^{-1}$

Tablo 2.1-2.4'te, bu bölümde verilen tüm öbeleme algoritmalarına ait algoritma fonksiyonları verilmiştir. Böylelikle, öbeleme algoritmaları arasındaki farklılıklar fonksiyon bazında ortaya konmuştur.

#### **2.4. Bulanık Sistem Modelleme**

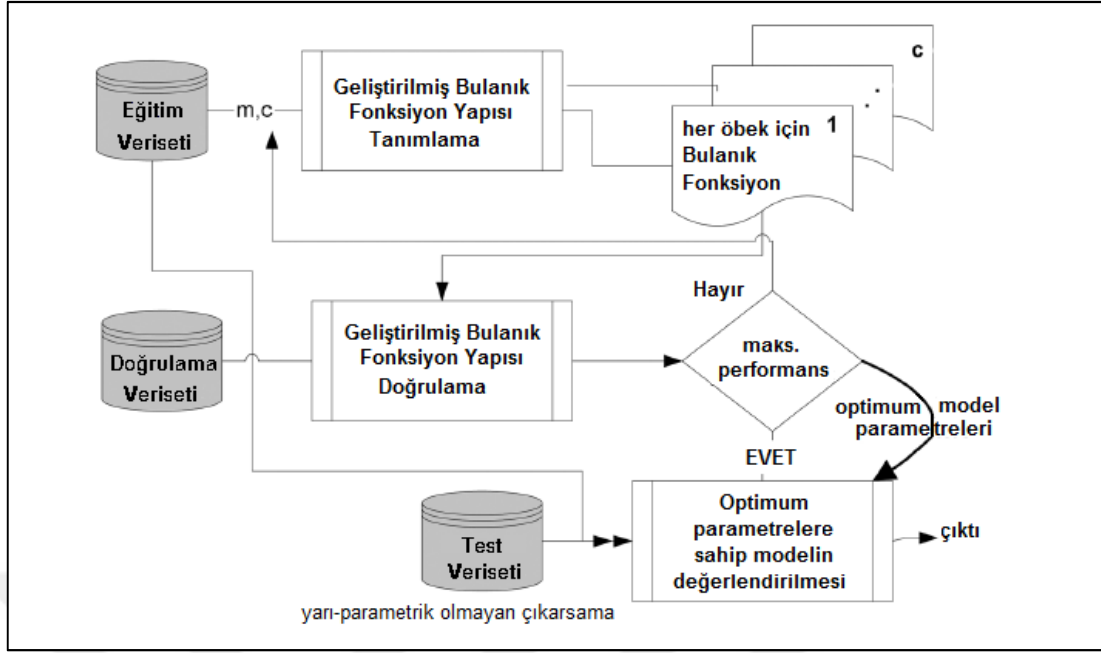
Bu bölümde önceki bölümde verilen bulanık öbeleme algoritmaları ile birlikte çalışan sistem modelleme yaklaşımları incelenecektir. Bu çıkarım algoritmaları “Bulanık Fonksiyon” yapıları ile birleştirilerek bulanık kural tabanlarına (BKT) alternatif olarak önerilen yöntemler arasındadır.

Bulanık sistem modelleme yaklaşımı Türkşen ve Çelikyılmaz (2006) tarafından geliştirilmiştir. Ünal (2009) benzer şekilde öbeleme algoritmaları için Bulanık Fonksiyon yapılarını oluşturup, bu yaklaşımlar için çıktı tahmini yapabilecek mekanizmalar, yani çıkarsama algoritmaları önermiştir.

Bu bölümde ilk olarak Çelikyılmaz ve Türkşen tarafından önerilen GBF'lar ile GBÖ'nün (2007, 2008, 2009) çıkarsama algoritması detayları ile incelenecektir. Bu yaklaşıma ait çıkarsama algoritması verilecektir. Daha sonra ise, Ünal'ın (2009) Hataway ve Bezdek'in önerdiği BÖRM (1993), Höppner ve Kalwonn'un BM (2003) ve Ünal'ın bu model (2009) için geliştirdiği çıkarsama algoritmaları sunulacaktır. Bu model üyeliklerin dahil edilmesi ile önerilen BFBM için de modifiye edilerek sunulacaktır.

##### **2.4.1. Geliştirilmiş bulanık fonksiyonlar ile bulanık sistem modelleme**

Bu yaklaşım Çelikyılmaz ve Türkşen tarafından geliştirilmiştir. Yaklaşımın temeli yine Türkşen tarafından geliştirilen ve BKT'na alternatif olarak önerilen Bulanık Fonksiyonlar (2008) yaklaşımıdır. Bulanık Fonksiyonlar BÖO'nun çıktılarını kullanarak çıktı tahminlemede BKT'na alternatif olarak sunulan bir yöntemdir. Bulanık Fonksiyonlar aynı zamanda Geliştirilmiş Bulanık Fonksiyonlar ile Bulanık Sistem Modellemenin temelini oluşturur.



Şekil 2.5. Geliştirilmiş bulanık fonksiyonlar ile bulanık sistem modelleme

Geliştirilmiş Bulanık Fonksiyonlar ile Bulanık Sistem Modelleme yaklaşımı Bulanık Kural Tabanı ile Bulanık Sistem Modelleme yaklaşımlarından farklıdır. Bulanık Kural Tabanı yapısı ile sistem modellemeye Bölüm 2.1’de değinilmiştir. Bulanık kural tabanı ile sistem modelleme uzman bilgisine dayalı ve sübjektif birtakım yaklaşımlar gerektirdiğinden uzmanlık gerektirir. Ayrıca sistem modelini uygulamaya dökmek oldukça karmaşıktır. Hem BF ile hem de GBF ile sistem modelleme yaklaşımları ise Bulanık Kural Tabanı yapıları ile sistem modellemeye göre oldukça kolay bir biçimde kodlanabilir ve uygulanabilir.

#### 2.4.1.1. Geliştirilmiş Bulanık Fonksiyonların Tahmini

Bulanık fonksiyonlar yaklaşımı orijinal girdi matrisine ek boyutlar olarak bu girdilerden elde edilmiş üyelik değerleri ve/veya bunların çeşitli dönüşümlerini kullanarak yeni bir girdi matrisi oluşturulmasını sağlar. Bu ek boyutlar kullanıcı tanımlıdır ve  $(\mu_i^*)^p$ ,  $\exp((\mu_i^*)^p)$ ,  $\ln((1-\mu_i^*)/\mu_i^*)$ ,  $1/(1+\exp(\mu_i^*))$ ,  $p \in \mathbb{R}$  vb gibi dönüşümler kullanılabilir. Her  $i$ ,  $i=1, \dots, c$ , öbeği için  $nv$  özellikte orijinal girdi söz konusu iken  $nm$  özellikte üyelik ve/veya bunların dönüşümü kullanılarak oluşturulur. Böylece orijinal girdi uzayı  $\mathbb{R}^{nv}$  iken  $\mathbb{R}^{nv+nm}$  uzayına dönüşür. Örnek vermek gerekirse; tek girdi ( $nv=1$ ), tek çıktı ve ek boyut olarak da yalnızca üyeliklerin ( $nm=1$ ) yer aldığı

bir yapı düşünülürken;  $\mathbb{R}^1 \rightarrow \mathbb{R}^{1+1}$ , de bir fonksiyon oluşturulması gerekir. Bu durum Denklem (2.44)'deki gibi gösterilebilir;

$$\Phi_i(x, \mu_i^*) \in \mathbb{R}^{nv+1} = \begin{bmatrix} \mu_{i,1}^* & x_1 \\ \vdots & \vdots \\ \mu_{i,nd}^* & x_{nd} \end{bmatrix} \forall i=1, \dots, c, \quad nm=1, \quad nv=1 \quad (2.44)$$

Denklem (2.44)'de tanımlandığı gibi her bir öbek için  $\mathbb{R}^2$  gibi bir uzaylar kümesi şöyle tanımlanır:  $\hat{y} = \hat{h}(\Phi_i) = \hat{\omega}_0 + \hat{\omega}_{1i}(\mu_i^*) + \hat{\omega}_{2i}x$  veya  $\hat{h}_i = (\Phi_i^T \hat{\omega}_i)$ , burada  $\hat{\omega}_i = [\hat{\omega}_0 \quad \hat{\omega}_{1i} \quad \hat{\omega}_{2i}]$ 'dir.

Çelikyılmaz ve Türkşen (2008), BF'ların parametrelerinin tahmininde En Küçük Kareler yoluyla regresyon fonksiyonu tahmin metodunu önermişlerdir.

Öğrenme algoritmasının son adımı olarak, her bir eğitim veri kümesi örneği için çıktının değeri Denklem (2.45)'de verilen adım ile berraklaştırılır. İlk olarak her öbek için ağırlıklı çıktı değerleri hesaplanır;

$$g_i = \mu_i^* \hat{h}_i(\Phi_i) \quad (2.45)$$

En son çıktı tahmini,  $\hat{y}$ , üyelik değerlerini temel alan ağırlıklandırma formülü ile (2.46)'da verildiği gibi hesaplanır;

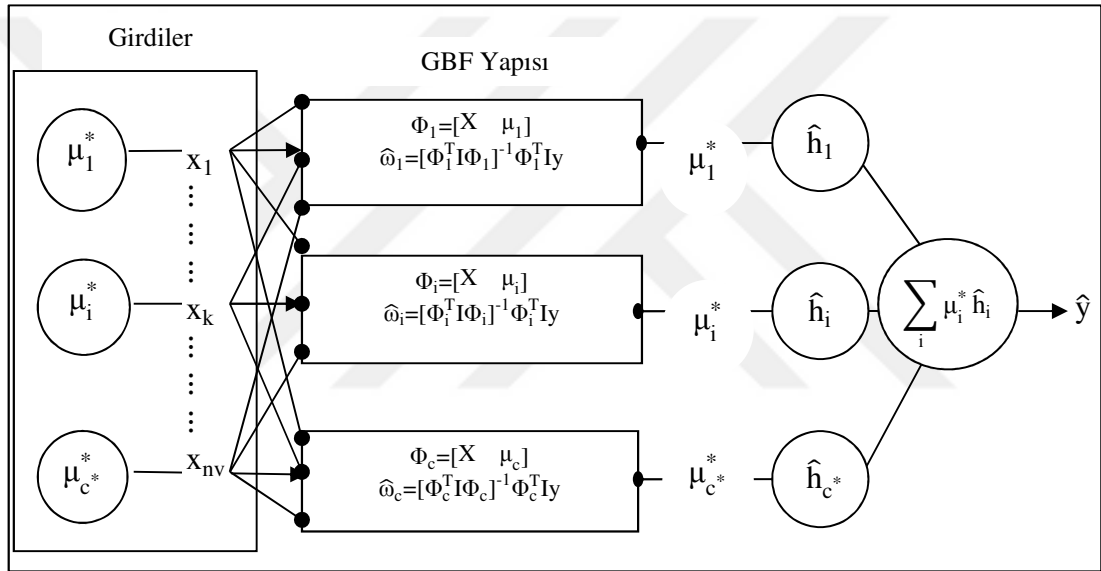
$$\hat{y} = \frac{\sum_{i=1}^c g_i}{\sum_{i=1}^c \mu_i^*} = \frac{\sum_{i=1}^c \mu_i^* \hat{h}_i(\Phi_i)}{\sum_{i=1}^c \mu_i^*} \quad (2.46)$$

Önerilen yaklaşımın parametreleri şöyledir:

- BF'lerinin  $f(\tau_i)$  en iyi parametreleri, GBÖ sırasında tahmin edilmiş çıktıların hesaplanmasında ve  $\tau_i$  girdi matrisinin yapılandırılmasında kullanılan her öbeğin  $\hat{\omega}_i$ ,  $i=1, \dots, c$ , fonksiyon katsayıları
- m bulanıklık derecesi,
- c öbek sayısı,
- Orijinal değişkenlere ek olarak kullanılan farklı tipteki üyelik değerleri dönüşümlerinin listesi: her öbeğin  $\hat{\omega}_i$ ,  $i=1, \dots, c$ , sistem BF'lerinin  $\hat{h}_i(\Phi_i)$  en iyi parametreleri ve bunların yapısı  $\Phi_i$

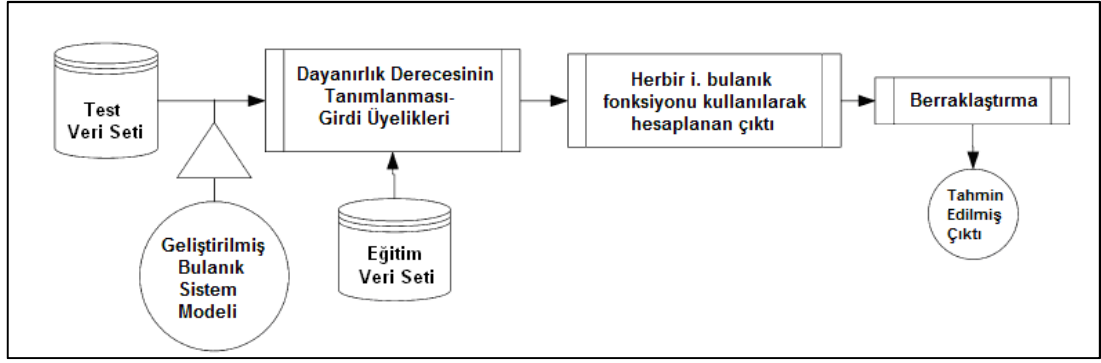
Akıl yürütme mekanizması yeni veri vektörlerinin çıktı değerlerini çıkarsamada kullanılır. Şekil 2.5’de görülebileceği gibi; GBF ile BSM yaklaşımı eğitim veri seti ile elde edilmiş sistem parametrelerini, doğrulama veri kümesini kullanarak optimize etmek için bir alt öbeikleme, yani doğrulama metodu uygular. Verilen sistemin en iyi parametrelerini bulmak için öğrenme mekanizması eğitim veri kümesini, çıkarsama mekanizması da doğrulama veri kümesini kullanır.

En iyi bulanık fonksiyon model parametreleri hesaplandıktan sonra, Geliştirilmiş Bulanık Fonksiyonlar ile Bulanık Sistem Modellerinin tüm performansı test veri kümesi üzerinden ölçülür.



Şekil 2.6. GBF ile yapı tanımlama

GBÖ (2.42)’de yer alan üyelik fonksiyonunu kullanır, bu üyelik fonksiyonu test veri örneklerinin üyelik değerlerinin bulunması için GBF ile BSM için verilen akıl yürütme tasarımında kullanılır. Bu üyelik değerleri ve/veya bunların dönüşümleri test verisinin çıktılarının tahmini için orijinal girdi değişkenlerine ek girdi değişkenleri olarak kullanılırlar.



Şekil 2.7. BSMGBF'nin önerilen çıkarılma mekanizması

Eğitim (ve doğrulama) veri setinin çıktı değerleri bilinirken, test veri setinin çıktı değerleri bilinmemektedir. Test veri vektörlerinin üyelik değerlerini hesaplamak için Denklem (2.42)'deki üyelik fonksiyonunu yeniden gözden geçirmek gerekir. Çelikyılmaz ve Türkşen'in önerdiği GBÖ'nün (2007, 2008, 2009) üyelik fonksiyonu, her  $i$  öbeğindeki  $k$  veri vektörü için ek bir hata terimi, yani  $SE_{ik} = (y_k - f(\tau_{ik}))^2$ , içermektedir. Denklem (2.42)'de  $y_k$  gerçek çıktıdır, ancak test verisi için tahmin edilmek istenen değerdir.  $\tau_i$  geliştirilmiş üyelik değerleri ve/veya bunların kullanıcı tanımlı dönüşümlerinin girdi matrisi de üyelik değerlerinin hesaplanmamış olmasından dolayı henüz hesaplanmamıştır. Modelden gelen tek parametre tahmin edilmiş en iyi fonksiyon parametreleridir,  $\hat{\omega}_i$ ,  $i=1, \dots, c$ . Dolayısıyla, test veri örneklerinin yeni geliştirilmiş üyelik değerlerini hesaplayabilmek için bilinmeyen parametrenin,  $SE_{ik}$ , tahmin edilmesi gerekir.  $\kappa$  –en yakın komşu yaklaşımına benzer bir yaklaşım ile eğitim veri örnekleri ve bunların üyeliklerini kullanarak hata terimi tahmin edilir.

#### 2.4.1.2. Çelikyılmaz ve Türkşen'in önerdiği GBÖ ile Bulanık Sistem Modelleme Çıkarılma Mekanizması Adımları

Algoritmayı her bir test veri vektörü için  $r=1, \dots, ndte$ 'ye kadar tekrarla

Adım 1:  $r$ . test vektörünün her bir eğitim veri vektörüne uzaklığını bul ve bunları aşağıdaki gibi kaydet,

$$D_r = \left\{ d_{rq} \in \mathbb{R} \mid d_{rq} = \|x_r^{te} - x_q\|_A^2 \right\}, q=1, 2, \dots, nd \quad (2.47)$$



Adım 2:  $D_r$ 'deki uzaklıkları artan sıraya göre sırala ve ilk  $\kappa$  tanesini  $r$  test verisine en yakın veri örnekleri olarak eğitim vektöründen seç.

Adım 3:  $\kappa$ -en yakın eğitim veri örneklerinin uzaklıklarını,  $D_r^*=[d_{r1}^*\dots d_{rk}^*]^T$ , bunlarla ilişkili her bir  $i$  öbeğindeki geliştirilmiş üyelik değeri,  $U_i^*=[\mu_{i1}^*,\dots,\mu_{ik}^*]^T, i=1,\dots,c^*$  ve bunların gerçek çıktı değerlerini,  $y^*=[y_1^*,\dots,y_k^*]^T$  kaydet.

Adım 4: Her öbekteki  $\kappa$ -en yakın veri örneğinin ortalama hata terimini ( $SE_{ir}$ ) hesapla;

$$\widehat{SE}_{ir}=\sum_{q=1}^{\kappa} SE_{iq}^* \eta_{rq}, \eta_{rq}=1-\left(\frac{d_{rq}^*}{\sum_{s=1}^{\kappa} d_{rs}^*}\right) \quad (2.48)$$

$$SE_{iq}=\left(y_q^*-\hat{y}_i(\tau_{iq}^*)\right)^2 \quad (2.49)$$

Adım 5: Her öbekteki  $r$  test örneğinin geliştirilmiş üyelik değerini,  $\mu_{ir}^*$ , hesapla.

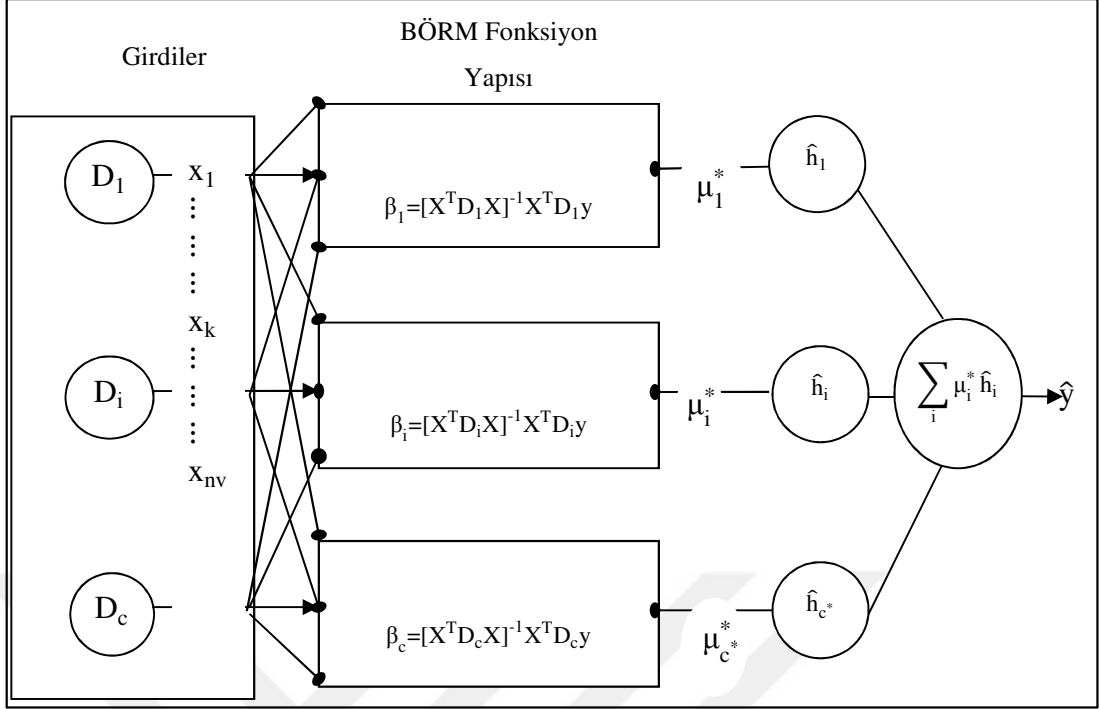
Adım 6:  $r$  test vektörünü her bir öbeğe öbek uzayındaki  $\Phi_i$  eşleştirme yapısını kullanarak,  $\Phi_{ir}$ , eşleştir ve bunları bulanık fonksiyonları kullanarak,  $\hat{y}_{ir}(\Phi_{ir})$ , her bir öbek için çıktı değerlerini çıkar.

Adım 7:  $\hat{y}_{ir}(\Phi_{ir})$ 'leri geliştirilmiş üyelik değerlerini kullanarak ağırlıklandırıp tek bir çıktı değeri bul.

#### 2.4.2. BÖRM fonksiyon yapısı ile bulanık sistem modelleme

Bu alt bölümde verilen BS modelinin detayları Ünal'ın (2009) çalışmasında bulunabileceği ve temel olarak GBÖ ile BSM'yi temel aldığı için algoritma adımları ve yapı tanımlama mekanizması Şekil 2.8 ile verilmiştir.

$$\text{Şekil 2.8'de yer alan } D_i=\begin{bmatrix} \mu_{i,1} & 0 & 0 & 0 \\ 0 & \mu_{i,2} & 0 & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \mu_{i,nv} \end{bmatrix} \text{şeklindedir.}$$



Şekil 2.8. BÖRM ile yapı tanımlama

#### 2.4.2.1. BÖRM için Çıkarılma Mekanizması Adımları

Algoritmayı her bir test veri vektörü için  $r=1, \dots, ndte$ 'ye kadar tekrarla

Adım 1:  $r$ . test vektörünün her bir eğitim veri vektörüne uzaklığını bul ve bunları (2.47)'deki gibi kaydet.

Adım 2:  $D_r$ 'deki uzaklıkları artan sıraya göre sırala ve ilk  $\kappa$  tanesini  $r$  test verisine en yakın veri örnekleri olarak eğitim vektöründen seç.

Adım 3:  $\kappa$ -en yakın eğitim veri örneklerinin uzaklıklarını,  $D_r^* = [d_{r1}^* \dots d_{r\kappa}^*]^T$ , ve bunlarla ilişkili bunların gerçek çıktı değerlerini,  $y^* = [y_1^*, \dots, y_k^*]^T$  kaydet.

Adım 4: Her bir öbek için  $\hat{y}_{ir}(\beta_{ir}^*)$  değerlerini hesapla. (Burada  $\beta_{ir}^*$  BÖRM'de hesaplanan fonksiyonun katsayılarıdır)

Adım 5: Her öbekteki  $\kappa$ -en yakın veri örneğinin ortalama hata terimini ( $E_{ir}$ ) hesapla;

$$\tilde{E}_{ir} = \sum_{q=1}^{\kappa} E_{iq}^* \eta_{rq}, \eta_{rq} = 1 - \left( \frac{d_{rq}^*}{\sum_{s=1}^{\kappa} d_{rs}^*} \right) \quad (2.50)$$

$$E_{iq} = \left( y_q^* - \hat{y}_i(x_q^{te}, \beta_{iq}^*) \right)^2 \quad (2.51)$$

Adım 6: Her öbekteki r test örneğinin geliştirilmiş üyelik değerini,  $\mu_{ir}^*$ , hesapla,

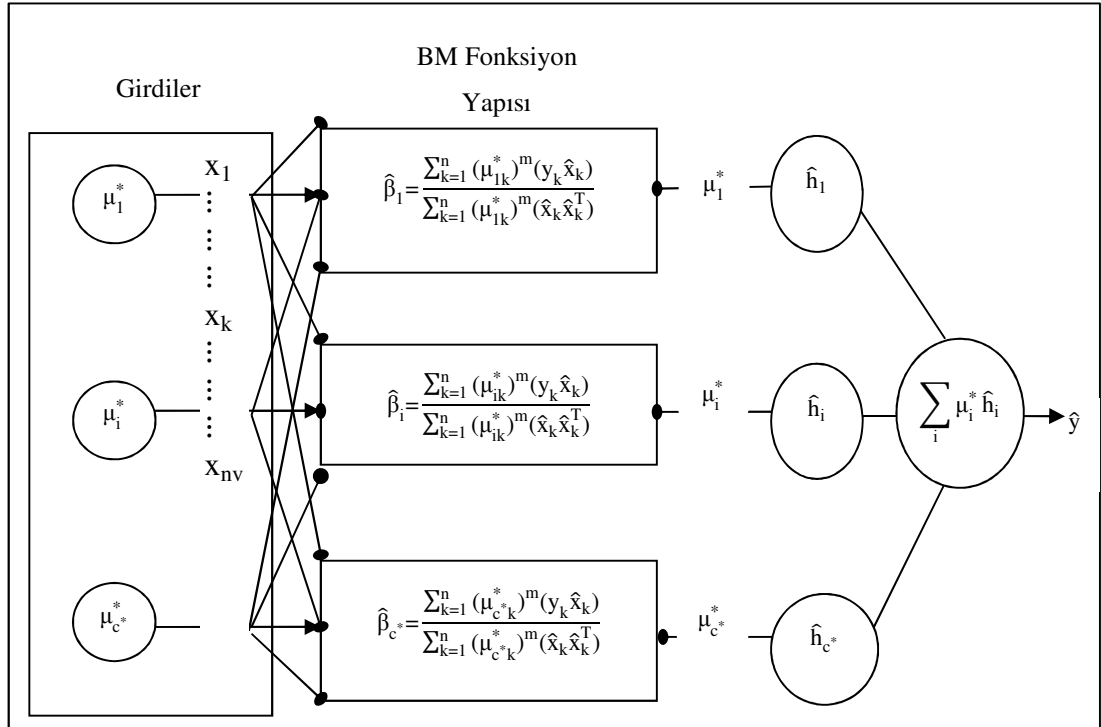
$$\mu_{ir}^* = \sum_{j=1}^c (E_{ir}/E_{jr})^{\frac{1}{1-m}}, \forall i, j=1, \dots, c < n \quad (2.52)$$

Adım 7: r test vektörünü her bir öbeğe öbek uzayındaki  $(X, \beta_i)$  eşleştirme yapısını kullanarak,  $(X, \beta_{ir})$ , eşleştir ve bunları bulanık fonksiyonları kullanarak,  $\hat{y}_{ir}(X, \beta_{ir})$ , her bir öbek için çıktı değerlerini çıkararsa.

Adım 8:  $\hat{y}_{ir}(X, \beta_{ir})$ 'leri geliştirilmiş üyelik değerlerini kullanarak ağırlıklandırıp tek bir çıktı değerini bul.

### 2.4.3. BM ve BFBM ile bulanık sistem modelleme

Bu alt bölümde verilen BS modelinin detayları Ünal'ın (2009) çalışmasında bulunabileceği ve temel olarak GBÖ ile BSM'yi temel aldığı için algoritma adımları ve yapı tanımlama mekanizması Şekil 2.9 ile verilmiştir.



Şekil 2.9. BM ile yapı tanımlama

Şekil 2.9’da verilen girdi fonksiyonu şu şekildedir;  $\hat{x}_k(x_1, x_2) = (x_1, x_2, \mu_1 x_1, \mu_2 x_2)$ .

#### 2.4.3.1. BM için Önerilen Çıkarılma Metodunun Adımları:

Algoritmayı her bir test veri vektörü için  $r=1, \dots, n_{\text{de}}$ ’ye kadar tekrarla

Adım 1:  $r$ . test vektörünün her bir eğitim veri vektörüne uzaklığını bul ve bunları Denklem (2.47)’deki gibi kaydet.

Adım 2:  $D_r$ ’deki uzaklıkları artan sıraya göre sırala ve ilk  $\kappa$  tanesini  $r$  test verisine en yakın veri örnekleri olarak eğitim vektöründen seç.

Adım 3:  $\kappa$ -en yakın eğitim veri örneklerinin uzaklıklarını,  $D_r^* = [d_{r1}^* \dots d_{r\kappa}^*]^T$ , ve bunlarla ilişkili bunların gerçek çıktı değerlerinin,  $y^* = [y_1^*, \dots, y_k^*]^T$ , ortalamasını al,  $y_r^* = \frac{1}{\kappa} \sum_{j=1}^{\kappa} y_j^*$ .

Adım 4: Her bir öbek için  $\hat{y}_{ir}(\hat{\beta}_{ir}^*)$  değerlerini hesapla. (Burada  $\hat{\beta}_{ir}^*$  kullanılan öbekleme algoritmasının fonksiyonunun katsayılarıdır)

Adım 5: Her öbekteki  $r$  test örneğinin üyelik değerini,  $\mu_{ir}^*, y_r^*$ ’dan  $\hat{y}_{ir}(\hat{\beta}_{ir}^*)$ ’dan faydalanarak uzaklıkları,  $d_{ir}^2$ , bul ve Denklem (2.54)’deki gibi hesapla;

$$d_{ir}^2 = \underbrace{\|x_r^{\text{te}} - v_i(x)\|^2}_{\text{BÖO uzaklığı}} + \underbrace{\left(y_r^* - \hat{y}_{ir}(\hat{\beta}_{ir}^*)\right)^2}_{\text{BÖRM uzaklığı}} \quad (2.53)$$

$$\mu_{ir}^* = \sum_{j=1}^c \left( \frac{d_{ir}^2 - (\text{mind}_{ir}^2 - \eta)}{d_{jr}^2 - (\text{mind}_{jr}^2 - \eta)} \right)^{-1}, \quad \eta > 0 \quad (2.54)$$

Adım 6:  $r$  test vektörünü her bir öbeğe öbek uzayındaki  $(\hat{X}, \hat{\beta}_i)$  eşleştirme yapısını kullanarak,  $(\hat{X}, \hat{\beta}_{ir})$ , eşleştir ve bunları bulanık fonksiyonları kullanarak,  $\hat{y}_{ir}(\hat{X}, \hat{\beta}_{ir})$ , her bir öbek için çıktı değerlerini çıkarırsa.

Adım 7:  $\hat{y}_{ir}(\hat{X}, \hat{\beta}_{ir})$ ’leri geliştirilmiş üyelik değerlerini kullanarak ağırlıklandırıp tek bir çıktı değeri bul.

BFBM algoritmasının BM algoritmasından farklılığı yalnızca fonksiyon yapısında üyeliklerin de kullanılmasından ileri gelmektedir, ancak bu algoritma yapısında bazı değişiklikleri gerekli kılmaktadır.

BFBM için önerilen çıkarsama metodunun dikkat edilmesi gereken farklılıkları kısaca şöyledir; test veri seti ile yapılacak öğrenme sonrası adımlarda tekrar iteratif bir yapı kullanmadan üyelik, çıktı tahmin değerlerinin ve eğitim veri setinin en yakın komşulukları bulunmalıdır.



### 3. UYGULAMA

#### 3.1. Yedek Parça Girdi Seçim Kriterleri

Tüm yedek parça verisi ile çalışmalar yapılmış bu çalışmalardan sonra çeşitli kriterlere göre veri üzerinde bazı eliminasyonlar yapılmıştır.

Yapılan çalışmalar neticesinde tüm veriyi olduğu gibi kullanmanın başarılı sonuçlar vermediği gözlemlenmiştir. Bu nedenle veriyi etkileyen faktörler ortaya konmuştur. Bunlar şu şekilde özetlenebilir:

1. Yedek parçalar için her ne kadar merkez depodan satış modeli üzerinde de çalışılsa alternatif kaynaklardan (fason) sağlanabildiği için çok eski model araçlara ait yedek parçaların dışarıda bırakılması bir seçenek olarak karşımıza çıkmıştır. Bu sebeple en yeni araç modellerinden birine ait yedek parça tahminlemesi yapmak nispeten fason etkisinden kurtulmayı sağlamıştır.
2. Satışı desteklemek için parçalara özel kampanyalar yapılmaktadır, bu da yedek parça temin eden bayilerin toplu alım yaparak ihtiyaç halinde alım yapmaktan ziyade kampanyalı ve daha düşük maliyetle parça temin etmesine olanak sağladığından kampanya yapılan parçaların da tahminleme çalışması dışında bırakılmasını gerekli kılmıştır. Ayrıca kampanya yapılan bu parçaların temini ve bayiye satışı bir plan çerçevesinde olduğu için bir tahminleme ihtiyacı olmamaktadır.
3. CV indeksi 1'e yakın çıkmaktadır, bu da verinin kararsız olduğunun bir göstergesidir, ayrıca ADI indeksi kesiklilik ve sürekliliğin bir göstergesidir, bu indeksi hesaplamaya bu veri için gerek yoktur çünkü verilerin çoğunda bazı aylar hiç talep gelmemektedir. Verinin kesikli olduğu aşikardır. Bu durumda hem kararsız hem de kesikli (lumpy) yapıya sahip bir veri ile karşı karşıyayız. Bu durum da tahmin zorluğunu artıran bir faktördür.

Tüm bu faktörler göz önüne alındığında bu tez çalışması çerçevesinde 130 parça için tahminleme çalışması yapılmıştır.

Bu çalışma kapsamında yapılan deneylere ait tüm parametreler Tablo 3.1’de verilmiştir. Ayrıca her çalışmanın altında yine çalışmaya konu parametreler verilmiştir. Ortak parametreler şu şekildedir:

- Durdurma sabiti:  $10^{-2}$
- Maksimum iterasyon sayısı: 100

Yapılan çalışmaya ait deneyler MATLAB R2015b (64- bit (maci64)) versiyonu ile 1,2 GHz Intel Core m5 işlemci ve macOS High Sierra işletim sistemine sahip MacBook’da (Retina, 12-inch, Early 2016) koşulmuştur.

Tablo 3.1. Tüm deneylerde kullanılan parametre kombinasyonları

Yöntem	c: Öbek sayısı	m: Üyelik dereceleri	Fonksiyon yapısı ek girdiler	Komşu Sayısı	$\eta$ : Eta	Uzaklık Ölçütü	k: Tahmin Ayı Sayısı	l: Eğitim Veri Seti Geriyeye Dönük Ay Sayısı
BÖÖ	2-10	{1,2 1,5 1,7 2,1 2,4 2,7}	Öbekleme yapısında yalnızca girdi değişkenleri kullanılırken, bulanık modelde $\{u, u^2, u^m, e^u, e^{u^2}\}$ üyelik kombinasyonları x girdi değişkenlerine eklenmiştir. *1	-	-	Euclid	{6,9,12}	{1,3,5}
BÖRM			$\{x_1, \dots, x_6, x_1x_2, x_1^2, \dots, x_6^2\}$ $\{x_1, \dots, x_6, x_1x_2, x_2x_3, x_1x_3, x_1^2, \dots, x_6^2\}$ değişkenlerin çarpımlı kombinasyonları da girdi değişkeni olarak alınmıştır. *2	-	-	-	{6,9,12}	{1,3,5}
BM			$\{x_1, \dots, x_6\}$ $\{x_1, \dots, x_6, x_1^2, \dots, x_6^2\}$ $\{x_1, \dots, x_6, x_1x_2, x_1^2, \dots, x_6^2\}$	3	0,05	Voronoi	{6,9,12}	{1,3,5}
BFBM			$\{u, x_1, \dots, x_6, ux_1\}$ $\{u, x_1, \dots, x_6, ux_1, ux_2, ux_3\}$ $\{u, x_1, \dots, x_6, ux_1, \dots, ux_6\}$ *1,*3	3	0,05	Voronoi	{6,9,12}	{1,3,5}
GBÖ			$\{u, \log(1-u/u)\}$ *1	3	-	Euclid	{6,9,12}	{1,3,5}

\*1: u ile verilen her bir üyelik her öbek için tekrar eder, gösterim kolaylığı olması açısından indis kullanılmamıştır. \*2: değişkenlerin çarpımlı kombinasyonları en yakın ayları kapsayacak şekilde en yakın 4 ay için denenmiş ve değişken sayısı arttıkça (tahmin ayından uzaklaştıkça) model doğruluğu azalmıştır. \*3: değişkenlerin çarpımlı kombinasyonları en yakın ayları kapsayacak şekilde en yakın 4 ay ve kombinasyonları için denenmiş ve değişken sayısı arttıkça (tahmin ayından uzaklaştıkça) model doğruluğu azalmıştır.

Literatürde yer alan çalışmalarda öbek sayısının genel olarak 2-10 arasında çalışıldığı, bazı çalışmalarda ise öbek sayısının veri sayısına bağlı olarak belirlenebileceği vurgulanmıştır. Bu çalışmada 130 veri ile çalışıldığı düşünüldüğünde 10 adet öbeğin fazla olacağı bile söylenebilir. Diğer taraftan bulanıklık mertebesi ile ilgili kullanışlı aralık farklı çalışmalardaki değerlendirmeler de göz önünde bulundurulduğunda 1,2-

2,7 aralığında 0,3 artırımlı olarak seçilmiş ve çalışmalar buna göre yapılmıştır. Bu seçimin bir diğer sebebi de deney sayısının çok fazla ve öbek sayısının bilinmiyor olmasıdır.

Çalışmada kullanılan eğitim veri setinin nasıl şekillendirildiğine bakacak olursak; n. ayın tahminini yapmak için kendinden önceki (k) 6, 9 ve 12 aylık talepleri dikkate alarak ve bunların da n., n-1. ve n-2. ayların taleplerinden oluşacak şekilde bir eğitim veri seti oluşturulmuştur. Örnek olması açısından girdilerin nasıl yapılandırıldığı Tablo 3.2’de verilmiştir. Burada 12 aylık taleplere göre şekillendirilmiş veri seti gösterilmiştir.

Tablo 3.2. l=3 ay geriye dönük veri seti örneği

	x12	x11	x10	x9	x8	x7	x6	x5	x4	x3	x2	x1	y
Parça	Oca. 2016	Şub. 2016	Mar. 2016	Nis. 2016	May. 2016	Haz. 2016	Tem. 2016	Ağu. 2016	Eyl. 2016	Eki. 2016	Kas. 2016	Ara. 2016	Oca. 2017
p1	0,000	0,000	0,000	0,250	0,000	0,000	0,000	0,286	0,182	0,000	0,000	0,000	0,000
p2	0,182	0,143	0,087	0,300	0,238	0,000	0,238	0,095	0,318	0,188	0,045	0,176	0,381
p3	0,182	0,238	0,130	0,350	0,429	0,182	0,286	0,095	0,409	0,500	0,227	0,235	0,429
	Ara. 2015	Oca. 2016	Şub. 2016	Mar. 2016	Nis. 2016	May. 2016	Haz. 2016	Tem. 2016	Ağu. 2016	Eyl. 2016	Eki. 2016	Kas. 2016	Ara. 2016
p1	0,684	0,000	0,000	0,000	0,250	0,000	0,000	0,000	0,286	0,182	0,000	0,000	0,000
p2	0,368	0,182	0,143	0,087	0,300	0,238	0,000	0,238	0,095	0,318	0,188	0,045	0,176
p3	0,263	0,182	0,238	0,130	0,350	0,429	0,182	0,286	0,095	0,409	0,500	0,227	0,235
	Kas. 2015	Ara. 2015	Oca. 2016	Şub. 2016	Mar. 2016	Nis. 2016	May. 2016	Haz. 2016	Tem. 2016	Ağu. 2016	Eyl. 2016	Eki. 2016	Kas. 2016
p1	0,190	0,684	0,000	0,000	0,000	0,250	0,000	0,000	0,000	0,286	0,182	0,000	0,000
p2	0,048	0,368	0,182	0,143	0,087	0,300	0,238	0,000	0,238	0,095	0,318	0,188	0,045
p3	0,048	0,263	0,182	0,238	0,130	0,350	0,429	0,182	0,286	0,095	0,409	0,500	0,227

BÖÖ, BÖRM, H&K’nun BM’i ve Önerilen BFBM ile modelleme çalışmalarına ait sonuçlar; öbek sayısı {2 3 4 5 6 7 8 9 10} ve bulanıklık mertebesi {1,2 1,5 1,8 2,1 2,4 2,7} olarak alınmış ve tüm bu deneylerin ortalama AMAPE cinsinden değerleri Tablo 3.3’de verilmiştir. Burada geriye dönük l=3 aylık veri seti ile çalışılmıştır. GBÖ metodu ile de çalışılmış ancak algoritma bu veri seti için çözüm üretmede başarısız olmuştur. GBÖ metodu sonuç üretmediği için iterasyon sayısı artırılarak 1000 iterasyon ve durdurma sabiti de azaltılarak  $10^{-1}$  seçilerek de deneme yapılmış ancak yine de algoritma sonuç üretmemiştir.



Tablo 3.3. Çalışılan bulanık modellerin ortalama AMAPE değerleri

Algoritma	k	May. 2017	Haz. 2017	Tem. 2017	Ağu. 2017	Eyl. 2017	Eki. 2017	Kas. 2017	Ara. 2017	Ocak 2018	Ortalama
Üssel Düzeltme (alfa=0,3)	12	46,4%	59,9%	44,7%	56,9%	51,5%	55,6%	47,7%	53,5%	48,0%	51,6%
BÖO	6	45,2%	58,1%	44,5%	58,0%	50,2%	56,0%	47,6%	52,8%	50,9%	51,5%
BÖO	9	44,9%	57,9%	44,6%	59,0%	50,4%	55,9%	47,8%	52,6%	50,9%	51,6%
BÖO	12	45,3%	59,2%	44,4%	59,2%	50,0%	56,2%	48,0%	53,1%	51,2%	51,8%
BÖRM	6	48,9%	67,2%	51,3%	60,5%	52,2%	57,6%	53,3%	56,2%	52,1%	55,5%
BÖRM	9	52,6%	68,7%	47,8%	57,1%	52,3%	58,7%	53,1%	54,6%	51,1%	55,1%
BÖRM	12	49,2%	66,4%	50,9%	58,2%	53,5%	58,6%	54,0%	56,2%	50,1%	55,2%
BFBM	6	45,5%	57,1%	43,2%	56,5%	50,2%	55,5%	50,0%	49,9%	47,0%	50,5%
BFBM	9	46,1%	58,1%	43,3%	58,2%	51,2%	57,8%	52,8%	50,4%	47,9%	51,7%
BFBM	12	45,7%	60,1%	42,7%	58,7%	51,4%	58,5%	52,4%	50,6%	49,8%	52,2%
H&K BM	6	56,3%	75,2%	65,4%	66,4%	61,1%	66,2%	55,4%	60,5%	61,7%	63,1%
H&K BM	9	55,5%	72,8%	63,2%	67,8%	58,3%	65,2%	56,7%	64,5%	58,7%	62,5%
H&K BM	12	55,9%	78,0%	61,3%	65,1%	62,5%	66,6%	57,3%	62,6%	58,5%	63,1%

Tablo 3.4. Tablo 3.3’de verilen bulanık modellerin parametre değerleri

Yöntem	c: Öbek sayısı	m: Üyelik dereceleri	Fonksiyon yapısı ek girdiler	Komşu Sayısı	$\eta$ : Eta	Uzaklık Ölçütü	k: Tahmin Ayı Sayısı	İ: Eğitim Veri Seti Geriye Dönük Ay Sayısı
BÖO	2-10	{1,2 1,5 1,7 2,1 2,4 2,7}	Öbekleme yapısında yalnızca girdi değişkenleri kullanılırken, bulanık modelde $\{u, u^2\}$ üyelik kombinasyonları x girdi değişkenlerine eklenmiştir. *1	-	-	Euclid	{6,9,12}	3
BÖRM			$\{x_1, \dots, x_6, x_1x_2, x_1^2, \dots, x_6^2\}$ değişkenlerin çarpımlı kombinasyonları da girdi değişkeni olarak alınmıştır. *2	-	-	-	{6,9,12}	3
BM			$\{x_1, \dots, x_6, x_1x_2, x_1^2, \dots, x_6^2\}$	3	0,05	Voronoi	{6,9,12}	3
BFBM			$\{u, x_1, \dots, x_6, ux_1, ux_2, ux_3\}$ *1, *3	3	0,05	Voronoi	{6,9,12}	3
GBÖ			$\{u, \log(1-u/u)\}$ *1	3	-	Euclid	{6,9,12}	3

\*1: u ile verilen her bir üyelik her öbek için tekrar eder, gösterim kolaylığı olması açısından indis kullanılmamıştır. \*2: değişkenlerin çarpımlı kombinasyonları en yakın ayları kapsayacak şekilde en yakın 4 ay için denenmiş ve değişken sayısı arttıkça (tahmin ayından uzaklaştıkça) model doğruluğu azalmıştır. \*3: değişkenlerin çarpımlı kombinasyonları en yakın ayları kapsayacak şekilde en yakın 4 ay ve kombinasyonları için denenmiş ve değişken sayısı arttıkça (tahmin ayından uzaklaştıkça) model doğruluğu azalmıştır.

Bu çalışma uygulama alanı olan bir veri seti ile yapıldığından ve gerçekte kullanılan yöntemin üssel düzeltme yöntemi olması sebebi ile karşılaştırma kriteri olarak karşımıza çıkmıştır. Tablo 3.4 den de görüleceği üzere modellerin hepsi l=3 ay geriye dönük veriseti için çalışılmıştır. Tablo 3.3’de BÖO algoritması üssel düzeltme yöntemi ile karşılaştırıldığında Ağustos ve Ekim 2017 ile Ocak 2018 için AMAPE değerinin daha yüksek olması sebebi ile başarılı olamamış, diğer taraftan geri kalan 6 ayın tahminlemede üssel düzeltmeye göre daha başarılı olmuştur. Burada k=6, 9 ve 12 için yapılan çalışmalardan ise 9 aylık veri kullanımının daha başarılı olduğu görülebilir. BÖRM ise üssel düzeltme yöntemine göre hiçbir ayın tahminlemede daha iyi yapamamıştır. Yöntem kendi içerisinde değerlendirildiğinde k=9 için yapılan modellemenin daha iyi olduğu söylenebilir. BFBM yöntemi üssel düzeltme yöntemi ile karşılaştırıldığında Kasım 2017 (47,7%) için AMAPE değerinin 50% olduğunu bu sebeple üssel düzeltmenin daha iyi olduğunu, bunun dışında kalan 8 ayın tahminlemede için ise BFBM modelinin daha iyi sonuçlar ürettiğini söylemek mümkündür. Ayrıca model en iyi k=6 için çalışmıştır. H&K BM modeli de yine BÖRM’de olduğu gibi üssel düzeltme yöntemine göre hiçbir ayın tahminlemede daha iyi yapamamıştır. Özetlemek gerekirse; BÖO algoritması ve BFBM algoritmaları mevcut yöntem ile karşılaştırıldığında yakın ve/veya daha iyi sonuçlar verdiği, BÖRM ve H&K BM algoritmalarının ise üssel düzeltme yöntemine göre başarısız olduğu görülmektedir.

BÖRM algoritmasının çalışma mantığı düşünüldüğünde düzlemdeki yapıları dikkate aldığından en azından üssel düzeltmede olduğu gibi bir katsayı yapısı önermesi beklenebilirdi. Tam tersine düzlemleri değil noktasal yapıları dikkate alan BÖO algoritmasının BÖRM algoritmasını temel alan yapıya göre yaklaşık %4 daha iyi sonuç vermesi bu noktada şaşırtıcıdır. Diğer taraftan BÖO algoritması; BÖRM ve BÖO algoritmalarını birleştiren H&K’ın BM’ine göre %11 daha iyi sonuçlar sunmaktadır. BFBM yapısı yine BM’in fonksiyon yapısında üyeliklerin kullanılması ile değiştirilmiş olup, BÖO algoritmasına benzer şekilde iyileşme sağlamaktadır. Hem BÖO hem de BFBM modeli üyeliklerin modele dahil edilmesi ile çalıştığı için; bu veri seti özelinde daha iyi sonuçlar sağlayan modeller olarak karşımıza çıkmaktadır.

Bu bağlamda çalışmalar BFBM ve BÖO algoritmaları ile modellemeler üzerinde yoğunlaşmıştır. İki modelin en iyi sonuçları verdiği veri yapıları farklılık göstermektedir. BÖO algoritması geriye doğru 9 aylık talepler ile çalıştığı daha iyi

sonular sunarken, BFBM 6 aylık talepler ile daha iyi sonular sunmaktadır. Daha detaylı alıřmalar ile en iyi parametreleri sunan modellerin retilmesi amalanmıřtır.

### 3.2. Bulanık bek Ortalamaları ile Bulanık Fonksiyonlar

Bulanık fonksiyon yapısı ile BO modelleme alıřmalarında 135.594 deneyin sonucuna gre alt alıřma parametreleri saptanmıřtır. Bu deney iin kullanılan parametreler řu řekildedir:

- 9 farklı bek sayısı  $c=\{2, 3, 4, 5, 6, 7, 8, 9, 10\}$ , 6 farklı bulanıklık mertebesi ile  $m=\{1, 2, 1,5, 1,8, 2,1, 2,4, 2,7\}$  olarak toplam 54 kombinasyon oluřacak řekilde,
- Tm veriler iin toplamda 9 farklı ıktı ayı tahminlemesi yaparak,
- 31 farklı fonksiyon kombinasyonu ile  $\{u, u^2, u^m, e^u, e^{u^2}\}$ ,
- Eđitim veri seti modeli iin  $l=\{5, 3, 1\}$  ay geriye dnk olarak,
- Her bir verinin  $k=\{6, 9, 12\}$  aylık talepleri ierecek řekilde deneyler yapılmıřtır.

Tablo 3.5’de verilen her bir AMAPE deđerini ilgili eđitim veri seti modeli, fonksiyon kombinasyonu ve verinin ka aylık talebi ierdiđine gre 54 farklı deneyin 9 farklı ıktı ayı iin (bek sayısı ve bulanıklık mertebesi) ortalama AMAPE deđerini gstermektedir. Ayrıca Tablo 3.5’deki ortalama AMAPE deđerleri modellerin performansına yani en dřk ortalama AMAPE deđerine gre sıralanmıřtır. Tablo 3.5’de sıralama dikkate alındıđında 5 ay geriye dnk eđitim veri seti ierisinde 6, 9, 12 aylık veri kullanımı, daha sonra 3 ay geriye dnk eđitim veri seti ierisinde 9, 12, 6 aylık veri kullanımı, en son ise 1 ay geriye dnk veri kullanımı ile 6, 9 ve 12 aylık veri kullanımı sıralaması gze arpmaktadır. Burada baskın olarak 5 ay geriye dnk veri seti kullanımının daha etkin olduđu sonucuna varabiliriz.

Buradan yola ıkarak modeli 5 ay geriye dnk eđitim veri seti modeli ile 6 tahminleme ayı kullanarak alıřıldıđında ve fonksiyon yapısı  $\{e^{u^2}\}$  veya  $\{u, u^m\}$  seildiđinde en iyi modeli sađladıđı saptanmıřtır.

Tablo 3.6’de fonksiyon yapısı  $\{u, u^m\}$  iin elde edilen AMAPE deđerlerine gre bek sayısı  $c=2$  ve bulanıklık mertebesi  $m=1,2$  iken en kk AMAPE deđerini saptanmaktadır. Ayrıca;  $\{e^{u^2}\}$  fonksiyon yapısı iin Tablo 3.7’de de bek sayısı  $c=2$  ve bulanıklık mertebesi  $m=1,2$  iken en kk AMAPE deđerini saptanmaktadır.

Tablo 3.5. BÖÖ ile bulanık fonksiyonlar modeline göre AMAPE değerleri

Üssel Düzeltme			46,4%	59,9%	44,7%	56,9%	51,5%	55,6%	47,7%	53,5%	48,0%	51,6%
Bulanık Fonksiyonlar {f: üyelik dönüşümü} {1: u, 2: u <sup>2</sup> , 3: u <sup>m</sup> , 4: exp(u), 5: exp(u <sup>2</sup> )}												
l	k	f	Mayıs 2017	Haziran 2017	Temmuz 2017	Ağustos 2017	Eylül 2017	Ekim 2017	Kasım 2017	Aralık 2017	Ocak 2018	Ortalama
5	6	5	45,4%	58,2%	44,5%	58,1%	49,9%	55,9%	47,7%	53,1%	50,4%	51,5%
5	6	13	45,3%	58,1%	44,5%	58,1%	50,1%	55,7%	47,7%	53,2%	50,5%	51,5%
5	6	12	45,4%	58,1%	44,6%	58,0%	50,2%	55,7%	47,7%	53,2%	50,5%	51,5%
5	6	3	45,4%	58,3%	44,6%	58,0%	49,9%	55,9%	47,7%	53,2%	50,5%	51,5%
5	6	1	45,4%	58,2%	44,5%	58,0%	50,0%	55,9%	47,8%	53,2%	50,5%	51,5%
5	6	4	45,5%	58,3%	44,5%	58,0%	50,0%	55,9%	47,7%	53,2%	50,4%	51,5%
5	9	134	45,1%	58,1%	44,5%	59,0%	50,3%	56,1%	48,0%	53,0%	50,3%	51,6%
5	9	5	45,2%	58,2%	44,6%	58,8%	50,1%	56,1%	48,1%	53,0%	50,4%	51,6%
5	9	25	45,1%	58,1%	44,6%	58,8%	50,3%	56,1%	48,0%	52,9%	50,4%	51,6%
5	9	3	45,3%	58,2%	44,7%	58,7%	50,1%	56,1%	47,9%	52,9%	50,5%	51,6%
5	9	145	45,1%	58,2%	44,5%	58,8%	50,3%	56,2%	47,9%	53,1%	50,2%	51,6%
5	9	15	45,1%	58,0%	44,6%	58,9%	50,3%	56,1%	48,0%	53,0%	50,4%	51,6%
5	12	1	45,2%	59,0%	44,0%	58,9%	49,8%	56,4%	47,9%	53,4%	51,0%	51,7%
5	12	5	45,2%	58,9%	44,0%	58,9%	49,8%	56,5%	48,0%	53,4%	51,1%	51,8%
5	12	4	45,2%	59,0%	44,0%	58,9%	49,8%	56,5%	48,0%	53,4%	51,1%	51,8%
5	12	2	45,2%	59,0%	44,1%	59,0%	49,8%	56,5%	48,0%	53,5%	51,1%	51,8%
5	12	3	45,2%	59,0%	44,0%	58,9%	49,8%	56,5%	48,0%	53,4%	51,1%	51,8%
5	12	123	45,1%	59,1%	44,1%	59,1%	50,0%	56,4%	48,0%	53,5%	50,9%	51,8%
3	9	2	45,9%	58,1%	43,1%	59,5%	52,6%	57,8%	50,6%	52,0%	49,4%	52,1%
3	9	4	45,9%	58,1%	43,2%	59,5%	52,5%	57,9%	50,6%	51,9%	49,4%	52,1%
3	9	5	45,9%	58,1%	43,1%	59,5%	52,7%	57,8%	50,5%	52,0%	49,4%	52,1%
3	9	25	45,8%	57,9%	43,2%	59,5%	53,0%	57,8%	50,5%	52,1%	49,3%	52,1%
3	9	24	45,7%	58,0%	43,1%	59,5%	53,0%	57,7%	50,6%	52,1%	49,3%	52,1%
3	9	15	45,7%	57,9%	43,1%	59,5%	53,0%	57,8%	50,5%	52,1%	49,3%	52,1%
3	12	3	45,8%	59,2%	42,3%	59,2%	51,6%	58,4%	50,4%	51,9%	50,5%	52,1%
3	12	4	45,7%	59,2%	42,3%	59,2%	51,6%	58,4%	50,4%	51,9%	50,5%	52,1%
3	12	1	45,7%	59,2%	42,3%	59,1%	51,6%	58,4%	50,4%	52,0%	50,5%	52,1%
3	12	5	45,7%	59,2%	42,2%	59,2%	51,7%	58,5%	50,4%	51,9%	50,5%	52,1%
3	12	2	45,8%	59,2%	42,3%	59,2%	51,6%	58,4%	50,5%	52,0%	50,5%	52,1%
3	12	15	45,6%	59,3%	42,4%	59,3%	51,8%	58,4%	50,4%	52,0%	50,4%	52,2%
3	6	24	45,3%	57,2%	43,6%	58,6%	58,5%	57,0%	49,4%	51,8%	49,1%	52,3%
3	6	13	45,3%	57,3%	43,7%	58,5%	58,6%	57,0%	49,2%	51,8%	49,0%	52,3%
3	6	14	45,3%	57,2%	43,8%	58,5%	58,4%	57,1%	49,3%	51,8%	49,0%	52,3%
3	6	45	45,3%	57,2%	43,7%	58,5%	58,5%	57,0%	49,4%	51,8%	49,0%	52,3%
3	6	35	45,3%	57,3%	43,7%	58,5%	58,5%	57,0%	49,3%	51,8%	49,0%	52,3%
3	6	5	45,4%	57,2%	43,8%	58,5%	58,5%	57,2%	49,3%	51,7%	49,0%	52,3%

Tablo 3.5. BÖO ile bulanık fonksiyonlar modeline göre AMAPE değerleri (devam)

Üssel Düzeltme			46,4%	59,9%	44,7%	56,9%	51,5%	55,6%	47,7%	53,5%	48,0%	51,6%
Bulanık Fonksiyonlar {f: üyelik dönüşümü} {1: u, 2: u <sup>2</sup> , 3: u <sup>m</sup> , 4: exp(u), 5: exp(u <sup>2</sup> )}												
l	k	f	Mayıs 2017	Haziran 2017	Temmuz 2017	Ağustos 2017	Eylül 2017	Ekim 2017	Kasım 2017	Aralık 2017	Ocak 2018	Ortalama
1	6	1	46,3%	54,7%	43,2%	62,8%	57,2%	58,5%	50,1%	57,5%	46,9%	53,0%
1	6	2	46,2%	54,8%	43,1%	62,8%	57,0%	58,8%	50,1%	57,5%	46,8%	53,0%
1	6	5	46,1%	54,7%	43,2%	62,9%	57,3%	58,5%	50,3%	57,4%	46,9%	53,0%
1	6	4	46,2%	54,7%	43,1%	62,8%	57,3%	58,6%	50,3%	57,5%	46,9%	53,0%
1	6	3	46,2%	54,8%	43,1%	62,8%	57,3%	58,7%	50,3%	57,4%	47,0%	53,1%
1	6	13	46,2%	55,0%	43,6%	62,6%	57,2%	58,9%	50,3%	58,2%	47,0%	53,2%
1	9	4	45,5%	56,5%	44,3%	64,7%	61,6%	57,5%	52,2%	59,0%	47,5%	54,3%
1	9	25	44,6%	56,7%	44,5%	64,4%	61,7%	57,7%	52,7%	59,2%	47,3%	54,3%
1	9	2	45,7%	56,6%	44,5%	64,8%	61,4%	57,5%	51,9%	58,9%	47,6%	54,3%
1	9	24	44,7%	56,5%	44,6%	64,5%	62,0%	57,6%	52,8%	59,0%	47,2%	54,3%
1	9	3	45,5%	56,6%	44,5%	64,7%	61,8%	57,6%	52,2%	58,8%	47,4%	54,3%
1	9	15	44,9%	56,6%	44,6%	64,6%	61,7%	57,6%	52,7%	59,2%	47,3%	54,3%
1	12	2	48,3%	57,2%	45,7%	62,4%	62,9%	57,8%	51,9%	64,5%	48,7%	55,5%
1	12	1	48,2%	57,2%	45,6%	62,4%	62,9%	57,9%	51,9%	64,7%	48,8%	55,5%
1	12	25	47,5%	57,2%	45,7%	62,6%	63,1%	58,1%	52,2%	64,6%	48,6%	55,5%
1	12	4	48,2%	57,2%	45,6%	62,4%	62,9%	58,0%	51,9%	64,9%	48,8%	55,5%
1	12	3	48,1%	57,3%	45,6%	62,3%	63,1%	58,0%	52,1%	64,7%	48,7%	55,5%
1	12	45	47,6%	57,2%	45,9%	62,4%	63,2%	57,9%	52,1%	65,1%	48,4%	55,6%

BÖO algoritması için literatürde bir çok doğrulama indeksi bulunmaktadır. Öbekleme yapıldıktan sonra doğru öbek sayısının kaç olduğunu bulmak için elverişli bir yöntemdir. Bu çalışmada model sonuçlarının AMAPE'ye göre yorumlanarak en iyi öbek sayısı saptanmıştır, daha sonra da belirlenen öbek sayısının doğruluğunu tespit etmek için ise öbek doğrulama indeksi kullanılmıştır.

Xei-Beni ve geliştirilmiş Xei-Beni öbek doğrulama indekslerine göre Mayıs 2017 tahminlemesi için hem  $\{u, u^m\}$  hem de  $\{e^{u^2}\}$  fonksiyonlarına göre oluşturulan model için bulunan öbek doğrulama indeksi Tablo 3.8 ve Tablo 3.9'da verilmiştir. Buna göre; farklı bulanıklık mertebeleri için farklı öbek sayılarında en iyi öbek sayısının belirlenebileceği görülebilir. Ancak yine de, bulanıklık mertebesinin birçok değeri için her iki doğrulama indeksine göre de öbek sayısının 2 olmasının yeterli olacağı Tablo 3.8-3.9'den görülebilir. Zaten verilerden elde edilen sonuçlara göre de en küçük

AMAPE'yi veren öbek sayısı 2 olarak karşımıza çıkmaktadır. Buradan hareketle; BÖO ile Bulanık Fonksiyon modeli için en iyi parametre grubu şu şekildedir:

- $c=2$
- $m=1,2$
- $f=\{u, u^m\} = 13$
- $k=6$  tahminleme ayı kullanılarak
- $l=5$  ay geriye dönük eğitim veri seti ile çalışılmalıdır.

Tablo 3.5' de verilen f fonksiyon kısaltması kullanılmıştır. Örneğin f: 13 ise  $f=\{u, u^m\}$  anlamına gelmektedir. {1: u, 2:  $u^2$ , 3:  $u^m$ , 4:  $\exp(u)$ , 5:  $\exp(u^2)$ }



Tablo 3.6.  $f=\{u,u^m\}=13$  için 5 farklı deney sonucuna ait AMAPE ve ortalama AMAPE değerleri (Mayıs 2017)

Süre		12,43 sn	14,93 sn	16,62 sn	13,85 sn	16,45 sn	
$\{u, u^m\}$		Deneme 1	Deneme 2	Deneme 3	Deneme 4	Deneme 5	
Öbek Sayısı	Bulanıklık Mertebesi	AMAPE	AMAPE	AMAPE	AMAPE	AMAPE	Ortalama
2	1,2	44,33%	44,37%	44,52%	44,12%	44,36%	44,34%
5	1,2	44,78%	45,04%	44,76%	45,05%	44,54%	44,83%
3	1,2	44,97%	45,06%	44,95%	44,89%	44,92%	44,96%
2	2,1	44,97%	44,77%	44,98%	45,45%	45,31%	45,10%
4	1,2	45,23%	44,80%	45,33%	45,34%	44,88%	45,11%
2	1,5	45,36%	45,23%	45,24%	44,68%	45,15%	45,13%
3	1,5	44,92%	45,15%	45,26%	45,22%	45,11%	45,13%
6	2,1	45,08%	45,20%	45,34%	44,99%	45,13%	45,15%
6	2,7	45,17%	45,31%	45,03%	45,33%	45,02%	45,18%
2	1,8	45,08%	44,79%	45,57%	45,04%	45,44%	45,18%
9	2,1	45,18%	45,22%	45,26%	45,09%	45,22%	45,19%
5	2,4	45,42%	44,99%	45,48%	44,98%	45,18%	45,21%
10	1,8	45,22%	45,33%	45,15%	45,29%	45,10%	45,22%
7	2,4	45,10%	45,52%	45,04%	45,16%	45,30%	45,23%
4	2,4	45,00%	45,33%	45,12%	45,41%	45,28%	45,23%
10	2,1	45,41%	45,16%	45,16%	45,10%	45,34%	45,23%
4	2,1	45,30%	45,26%	45,33%	45,00%	45,29%	45,23%
8	2,4	45,24%	45,35%	45,29%	45,24%	45,06%	45,24%
3	1,8	45,34%	45,43%	45,26%	45,03%	45,12%	45,24%
10	2,4	45,19%	45,22%	45,33%	45,14%	45,33%	45,24%
5	2,7	45,20%	45,05%	45,33%	45,20%	45,55%	45,27%
10	2,7	45,34%	45,20%	45,33%	45,42%	45,06%	45,27%
8	2,7	45,31%	45,47%	45,09%	45,27%	45,32%	45,29%
7	1,8	45,09%	45,39%	45,38%	45,40%	45,20%	45,29%
6	2,4	45,23%	45,15%	45,31%	45,33%	45,46%	45,29%
6	1,8	45,24%	45,63%	45,13%	45,22%	45,30%	45,30%
4	1,8	45,32%	45,26%	45,02%	45,51%	45,41%	45,31%
3	2,4	45,39%	45,50%	45,21%	45,12%	45,44%	45,33%
4	1,5	45,33%	45,30%	45,42%	45,32%	45,27%	45,33%
5	2,1	45,33%	45,44%	45,31%	45,29%	45,31%	45,33%
8	1,8	45,12%	45,22%	45,60%	45,32%	45,45%	45,34%
9	2,7	45,24%	45,23%	45,30%	45,46%	45,47%	45,34%
5	1,8	45,41%	45,46%	45,08%	45,59%	45,19%	45,35%
7	2,7	45,28%	45,17%	45,37%	45,61%	45,32%	45,35%
9	1,8	45,30%	45,52%	45,30%	45,40%	45,35%	45,37%
7	2,1	45,25%	45,15%	45,48%	45,52%	45,57%	45,39%
8	2,1	45,28%	45,28%	45,47%	45,26%	45,69%	45,40%
9	2,4	45,58%	45,19%	45,45%	45,47%	45,33%	45,40%
3	2,1	45,01%	45,07%	45,65%	45,58%	45,71%	45,40%
5	1,5	45,38%	45,31%	45,58%	45,71%	45,37%	45,47%
10	1,5	45,44%	45,43%	45,46%	45,55%	45,47%	45,47%
8	1,5	45,56%	45,56%	45,43%	45,48%	45,42%	45,49%
3	2,7	45,59%	45,02%	45,34%	46,13%	45,49%	45,51%
6	1,2	45,37%	45,09%	45,04%	45,23%	46,92%	45,53%
4	2,7	45,20%	45,70%	45,39%	45,91%	45,46%	45,53%
2	2,7	45,41%	45,15%	46,09%	45,50%	45,51%	45,53%
7	1,5	45,53%	45,60%	45,52%	45,53%	45,59%	45,55%
6	1,5	45,62%	45,61%	45,75%	45,60%	45,45%	45,61%
2	2,4	45,86%	45,56%	45,13%	45,67%	45,82%	45,61%
9	1,5	45,60%	45,70%	45,64%	45,66%	45,73%	45,67%
7	1,2	46,32%	45,44%	45,15%	45,91%	46,15%	45,79%
10	1,2	46,38%	46,09%	46,41%	45,77%	45,08%	45,95%
9	1,2	46,14%	45,27%	47,04%	45,98%	46,95%	46,28%
8	1,2	46,24%	46,11%	46,55%	46,71%	45,83%	46,29%

Tablo 3.7.  $f=\{e^{u^2}\}=5$  için 5 farklı deney sonucuna ait AMAPE ve ortalama AMAPE değerleri (Mayıs 2017)

Süre		13,73 sn	12,27 sn	12,32 sn	11,91 sn	14,52 sn	
{exp(u <sup>2</sup> )}		Deneme 1	Deneme 2	Deneme 3	Deneme 4	Deneme 5	
Öbek Sayısı	Bulanıklık Mertebesi	AMAPE	AMAPE	AMAPE	AMAPE	AMAPE	Ortalama
2	1,2	44,96%	44,72%	44,11%	44,19%	44,35%	44,47%
5	1,2	44,79%	45,16%	45,21%	44,15%	45,05%	44,87%
3	1,2	45,16%	45,18%	45,17%	45,10%	44,98%	45,12%
2	1,5	44,92%	44,96%	46,00%	44,73%	44,98%	45,12%
4	1,2	45,00%	44,78%	45,22%	45,40%	45,29%	45,14%
2	2,4	45,34%	44,98%	45,43%	45,24%	45,05%	45,21%
5	1,8	45,16%	45,35%	45,38%	45,23%	45,09%	45,24%
4	2,7	45,20%	45,11%	45,46%	45,46%	45,20%	45,29%
3	2,7	45,34%	45,15%	45,10%	45,48%	45,36%	45,29%
3	2,4	45,38%	45,31%	45,10%	45,34%	45,33%	45,29%
3	2,1	45,56%	45,20%	45,31%	45,28%	45,18%	45,31%
5	2,4	45,36%	45,28%	45,51%	45,38%	45,03%	45,31%
9	1,8	45,28%	45,49%	45,20%	45,44%	45,17%	45,32%
6	1,2	45,23%	45,41%	45,40%	45,18%	45,39%	45,32%
6	2,7	45,14%	45,45%	45,41%	45,32%	45,29%	45,32%
5	2,7	45,29%	45,25%	45,62%	45,26%	45,23%	45,33%
6	2,1	45,28%	45,33%	45,36%	45,40%	45,30%	45,33%
9	2,7	45,34%	45,39%	45,30%	45,24%	45,42%	45,34%
6	2,4	45,55%	45,11%	45,31%	45,58%	45,16%	45,34%
8	2,1	45,54%	45,35%	45,14%	45,42%	45,29%	45,35%
4	2,4	45,19%	45,55%	45,21%	45,45%	45,38%	45,36%
10	2,4	45,48%	45,52%	45,38%	45,14%	45,28%	45,36%
7	2,1	45,45%	45,20%	45,65%	45,22%	45,33%	45,37%
10	2,7	45,48%	45,32%	45,45%	45,27%	45,34%	45,37%
7	1,8	45,55%	45,32%	45,28%	45,33%	45,39%	45,38%
8	2,7	45,32%	45,62%	45,50%	45,32%	45,13%	45,38%
9	2,1	45,37%	45,50%	45,28%	45,36%	45,38%	45,38%
7	2,7	45,35%	45,42%	45,37%	45,39%	45,36%	45,38%
3	1,5	45,35%	45,54%	45,52%	45,50%	45,03%	45,39%
9	2,4	45,24%	45,62%	45,43%	45,21%	45,47%	45,39%
10	1,8	45,47%	45,60%	45,31%	45,26%	45,36%	45,40%
10	2,1	45,50%	45,32%	45,51%	45,29%	45,39%	45,40%
8	2,4	45,65%	45,51%	45,53%	45,18%	45,25%	45,42%
8	1,8	45,34%	45,52%	45,49%	45,29%	45,54%	45,44%
3	1,8	45,48%	45,43%	45,36%	45,66%	45,41%	45,47%
2	2,1	45,81%	45,38%	45,34%	45,10%	45,71%	45,47%
5	2,1	45,35%	45,33%	45,80%	45,63%	45,29%	45,48%
6	1,8	45,53%	45,52%	45,46%	45,44%	45,52%	45,49%
4	1,8	45,23%	45,21%	45,80%	45,44%	45,82%	45,50%
4	2,1	45,33%	45,84%	45,23%	45,67%	45,44%	45,50%
7	1,2	45,99%	45,48%	45,30%	45,39%	45,36%	45,50%
8	1,2	45,52%	45,81%	46,00%	45,92%	44,44%	45,54%
2	1,8	46,12%	45,53%	45,45%	45,33%	45,33%	45,55%
7	2,4	45,65%	45,53%	45,47%	45,49%	45,80%	45,59%
4	1,5	45,82%	45,55%	45,62%	45,73%	45,26%	45,59%
2	2,7	45,25%	45,89%	45,55%	45,66%	45,67%	45,60%
5	1,5	45,70%	45,46%	45,84%	45,72%	45,91%	45,73%
7	1,5	45,94%	45,82%	45,35%	45,86%	45,85%	45,76%
6	1,5	45,74%	45,83%	45,79%	45,86%	45,70%	45,78%
10	1,2	45,47%	45,28%	46,75%	44,92%	46,63%	45,81%
9	1,5	45,79%	45,81%	45,85%	45,81%	45,91%	45,83%
10	1,5	45,78%	45,74%	46,06%	45,80%	45,92%	45,86%
8	1,5	45,91%	45,79%	45,85%	45,76%	46,00%	45,86%
9	1,2	46,37%	45,97%	45,41%	45,97%	45,67%	45,88%



Tablo 3.8.  $f=\{u,u^m\}$  için oluşturulan modelden elde edilen Mayıs 2017 tahminlemesi için öbek doğrulama indeks değerleri

CVI Geliştirilmiş Xei Beni	c								
m	2	3	4	5	6	7	8	9	10
1,2	0,9	0,7	0,5	0,5	0,4	0,4	0,3	0,3	0,3
1,5	47,2	10,3	3,0	13,6	20,5	11,6	609,5	45,3	69,2
1,8	17,1	100,5	91,7	391,9	293,4	696,9	372,0	154,8	91,2
2,1	103,5	272,6	266,4	509,3	629,2	209,2	1.035,2	158,1	84,8
2,4	34,4	445,5	560,2	257,0	287,9	55,7	144,0	138,7	64,0
2,7	182,9	278,7	108,0	120,1	150,7	500,3	265,4	249,5	167,6
CVI Xei Beni	c								
m	2	3	4	5	6	7	8	9	10
1,2	4,6	4,5	4,3	3,8	3,4	3,3	3,2	3,3	2,9
1,5	318,8	80,5	29,3	133,2	263,6	212,8	5.357,4	622,4	950,3
1,8	114,9	834,4	1.089,7	3.299,6	4.002,3	6.539,1	4.959,7	2.008,9	1.436,1
2,1	709,7	2.305,9	3.074,1	6.508,2	5.681,3	3.132,6	9.797,9	3.060,6	1.673,7
2,4	235,1	3.144,7	4.218,4	3.803,7	2.848,2	1.021,8	2.538,1	2.643,9	1.397,4
2,7	1.261,2	2.575,6	1.181,5	1.123,7	1.519,9	7.538,7	3.932,5	2.687,3	3.234,8

Tablo 3.9.  $f=\{e^{u^2}\}$  için oluşturulan modelden elde edilen Mayıs 2017 tahminlemesi için öbek doğrulama indeks değerleri

CVI Geliştirilmiş Xei Beni	c								
m	2	3	4	5	6	7	8	9	10
1,2	0,9	0,7	0,5	0,4	0,4	0,4	0,3	0,3	0,3
1,5	0,8	115,6	98,4	11,5	126,9	142,3	123,9	25,8	67,0
1,8	9,4	29,7	107,8	122,6	119,2	72,2	226,3	42,6	36,5
2,1	745,1	38,2	161,6	406,0	851,2	129,4	147,2	394,9	1193,0
2,4	101,1	130,8	391,4	166,9	193,6	165,2	105,0	336,0	77,3
2,7	241,9	329,8	1634,0	1418,4	299,0	220,8	89,3	1067,1	339,4
CVI Xei Beni	c								
m	2	3	4	5	6	7	8	9	10
1,2	5,1	4,5	4,3	4,2	3,6	3,4	3,4	3,0	2,9
1,5	4,6	911,5	775,1	110,0	1243,4	1345,1	1299,2	425,6	928,5
1,8	62,7	259,0	1117,1	1682,2	1505,7	1405,6	2614,7	926,3	1009,8
2,1	5126,0	338,6	1828,9	4397,1	8833,5	1942,0	1902,8	5816,9	12393,3
2,4	691,7	1225,2	4178,3	1462,3	2170,0	2698,1	2256,1	5642,8	1246,2
2,7	1663,0	3056,6	11733,5	13482,4	3255,7	3143,8	1307,7	10868,5	5507,0

### 3.3 Bulanık Fonksiyonlar ile Bulanık Model

Bulanık fonksiyon ile BM çalışmalarında 4.374 deneyin sonucuna göre alt çalışma parametreleri saptanmıştır. Burada fonksiyon yapısı kayda değer sonuçlar sunan bir yapı ile çalışılmış olup, 6 aylık tahmin verisi kullanılan yapı için;  $f_i=\gamma_0+\gamma_1x_1+\gamma_2x_2+\dots+\gamma_6x_6+\gamma_7\mu_{i1}x_1+\gamma_8\mu_{i2}x_2+\gamma_9\mu_{i3}x_3$  yapısındadır. Burada üyelikler önceki tecrübelerden ve klasik yaklaşımlardan esinlenerek son ayların etkisinin daha fazla olduğu bilgisinden hareketle son üç aya ait üyelik değerleri ile ağırlıklandırılmış bir bulanık fonksiyon yapısı önerilmiştir. Burada sonuçlarına yer verilmemiş olsa da

sadece en yakın ay, tüm aylar kullanılarak da çalışılmış ancak en iyi sonuçlar bu fonksiyon modeli ile elde edilmiştir. Ayrıca fonksiyonda üyeliklerin de girdi olarak kullanıldığı model de çalışılmış ve yine başarılı olamamıştır.

Bu deney için kullanılan diğer parametreler şu şekildedir:

- 9 farklı öbek sayısı  $c=\{2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10\}$ , 6 farklı bulanıklık mertebesi ile  $m=\{1,2\ 1,5\ 1,8\ 2,1\ 2,4\ 2,7\}$  olarak toplam 54 kombinasyon oluşacak şekilde,
- Tüm veriler için toplamda 9 farklı çıktı ayı tahminlemesi yaparak,
- Eğitim veri seti modeli için 5 ay, 3 ay ve 1 ay geriye dönük olarak,
- Her bir verinin (k) 6, 9 ve 12 aylık talepleri içerecek şekilde deneyler yapılmıştır.

Deney sonuçları Tablo 3.10'da sunulmuştur. Burada en iyi parametrelerin 3 ay geriye dönük veri seti kullanılarak, 6 ay tahminleme ayı bilgisi ile ortalama AMAPE değeri %50,53 olarak elde edilmiştir.

Tablo 3.10. BFBM göre AMAPE değerleri

Eğitim seti modeli	k	May. 2017	Haz. 2017	Tem. 2017	Ağu. 2017	Eyl. 2017	Eki. 2017	Kas. 2017	Ara. 2017	Ocak 2018	Ortalama
5 ay geriye dönük	6	45,87%	57,96%	44,16%	56,94%	49,16%	58,91%	54,39%	50,32%	47,21%	51,66%
	9	46,00%	58,71%	44,22%	57,94%	49,28%	59,03%	54,50%	50,41%	48,09%	52,02%
	12	46,11%	59,83%	44,04%	57,29%	49,95%	59,41%	55,77%	50,68%	47,86%	52,33%
3 ay geriye dönük	6	45,46%	57,06%	43,21%	56,51%	50,16%	55,49%	50,00%	49,92%	46,97%	50,53%
	9	46,07%	58,12%	43,28%	58,19%	51,15%	57,84%	52,75%	50,36%	47,89%	51,74%
	12	45,72%	60,09%	42,73%	58,72%	51,40%	58,52%	52,38%	50,55%	49,79%	52,21%
1 ay geriye dönük	6	50,56%	54,91%	44,53%	59,21%	50,43%	55,84%	51,75%	55,48%	45,70%	52,05%
	9	50,88%	55,33%	44,57%	60,69%	51,10%	56,61%	54,18%	57,54%	46,62%	53,06%
	12	50,82%	55,75%	44,13%	60,77%	52,02%	59,07%	55,20%	57,74%	47,03%	53,61%

Buradan hareketle, 3 ay geriye dönük veri seti kullanılarak, 6 ay tahminleme ayı kullanılarak; 9 farklı öbek sayısı  $c=\{2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10\}$ , 6 farklı bulanıklık mertebesi ile  $m=\{1,2\ 1,5\ 1,8\ 2,1\ 2,4\ 2,7\}$  seçilmiş modele ait AMAPE değerleri 9 farklı tahmin için Tablo 3.11'de verilmiştir. Bu öbeleme algoritması için uygun bir öbek doğrulama indeksi olmadığından sonuçlardan hareketle en iyi parametre tahmini yapılacaktır. Bunu yaparken ortalama bulanıklık mertebesine ve ortalama öbek sayısına göre en küçük ortalamaları veren modeller incelenmiş ardından deney sürelerinin BÖÖ ile bulanık fonksiyonlar modeline göre oldukça uzun olması sebebi ile en az öbek sayısı

ile sağlanan çözüm tercih edilmiştir. Bu durumda öbek sayısı 5 ve bulanıklık mertebesi 2,4 olarak seçilmiştir.

Tablo 3.11. 3 ay geriye dönük veri seti için 6 aylık tahmin ayı bilgisi kullanılarak yapılan BFBM modeline ait AMAPE sonuçları

Mayıs 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	46,40%	45,64%	46,51%	46,40%	45,41%	44,17%	46,40%	45,70%	46,85%
1,5	47,68%	47,75%	46,80%	46,35%	44,31%	45,65%	45,10%	45,36%	44,68%
1,8	49,74%	48,78%	45,65%	44,25%	45,36%	45,54%	44,71%	44,06%	44,59%
2,1	45,46%	48,52%	45,33%	44,60%	44,18%	44,92%	44,04%	44,35%	44,54%
2,4	47,39%	46,20%	44,02%	44,67%	45,46%	44,07%	43,69%	44,49%	44,49%
2,7	46,92%	46,59%	44,24%	44,14%	44,39%	44,72%	44,86%	44,72%	43,91%
süre (sn)	21,44	20,68	43,39	25,35	36,08	39,97	39,98	43,31	43,19
Haziran 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	58,47%	58,73%	60,21%	58,32%	59,48%	58,88%	59,19%	56,27%	55,59%
1,5	60,85%	55,41%	55,43%	56,17%	56,05%	58,34%	57,71%	57,40%	56,47%
1,8	61,27%	58,74%	55,49%	56,77%	56,36%	56,31%	56,06%	56,18%	55,57%
2,1	59,72%	57,87%	56,62%	54,24%	56,57%	56,16%	54,84%	55,84%	55,89%
2,4	60,18%	57,88%	56,47%	56,08%	55,43%	56,10%	57,49%	55,30%	55,22%
2,7	61,93%	58,04%	58,91%	54,67%	54,47%	56,12%	55,85%	55,49%	55,95%
süre (sn)	20,94	21,15	39,41	39,10	36,32	39,02	39,11	39,01	38,98
Temmuz 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	49,55%	41,47%	47,47%	43,40%	43,56%	45,02%	45,36%	46,14%	42,69%
1,5	47,77%	43,51%	44,40%	42,58%	42,91%	42,95%	42,51%	43,23%	43,27%
1,8	46,60%	44,31%	45,28%	43,23%	42,74%	41,43%	42,29%	41,85%	42,26%
2,1	47,22%	43,43%	44,12%	40,77%	41,82%	42,76%	42,79%	40,93%	41,86%
2,4	46,81%	42,11%	41,14%	41,68%	41,87%	40,37%	41,12%	41,34%	42,02%
2,7	49,61%	40,72%	41,46%	42,40%	40,39%	42,10%	41,12%	41,83%	41,53%
süre (sn)	20,76	36,90	36,59	36,42	36,55	36,83	36,49	36,81	36,67
Ağustos 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	58,80%	57,47%	53,09%	60,12%	58,19%	59,03%	58,46%	56,57%	56,24%
1,5	57,79%	58,17%	54,03%	57,68%	56,66%	56,71%	56,61%	57,19%	53,99%
1,8	56,17%	54,19%	53,19%	57,93%	55,75%	55,70%	58,09%	56,73%	56,54%
2,1	59,60%	55,31%	60,30%	54,80%	55,41%	54,48%	55,67%	57,36%	53,65%
2,4	58,65%	56,23%	55,12%	54,57%	55,55%	56,04%	56,54%	54,04%	57,13%
2,7	61,40%	58,92%	58,72%	52,40%	56,93%	55,85%	55,79%	54,21%	55,86%
süre (sn)	21,77	25,64	25,33	25,81	25,49	25,51	25,77	25,31	25,43
Eylül 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	50,56%	52,76%	51,16%	48,29%	52,17%	48,65%	52,79%	52,07%	51,02%
1,5	52,25%	51,53%	49,44%	49,36%	48,92%	47,73%	53,47%	48,90%	50,62%
1,8	51,91%	51,42%	49,65%	49,31%	48,78%	49,61%	46,95%	52,24%	49,67%
2,1	51,67%	51,04%	50,64%	50,30%	48,42%	50,31%	47,62%	51,25%	48,85%
2,4	52,15%	50,10%	49,20%	48,96%	49,72%	48,49%	48,62%	49,37%	49,65%
2,7	50,99%	52,24%	50,10%	50,77%	51,30%	48,45%	49,24%	48,69%	49,33%
süre (sn)	21,21	23,99	25,71	25,91	25,76	25,89	25,62	25,87	25,90

Tablo 3.11. 3 ay geriye dönük veri seti için 6 aylık tahmin ayı bilgisi kullanılarak yapılan BFBM modeline ait AMAPE sonuçları (Devam)

Ekim 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	57,05%	56,96%	56,51%	57,78%	56,84%	57,24%	54,63%	56,82%	56,26%
1,5	56,89%	57,37%	58,03%	54,12%	55,17%	56,81%	55,69%	56,12%	55,51%
1,8	57,69%	58,73%	54,67%	55,01%	55,43%	52,45%	55,39%	55,43%	54,82%
2,1	56,69%	57,23%	57,26%	52,24%	55,68%	54,51%	53,86%	54,09%	53,77%
2,4	58,13%	55,01%	55,12%	52,77%	55,18%	53,26%	53,33%	53,94%	54,02%
2,7	56,67%	56,66%	56,57%	54,43%	54,69%	53,80%	54,06%	54,38%	53,49%
süre (sn)	21,23	25,34	25,52	24,96	25,44	24,21	25,46	25,40	25,41
Kasım 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	53,85%	52,61%	49,97%	51,13%	52,96%	49,81%	50,87%	50,78%	50,04%
1,5	56,15%	51,03%	50,61%	48,90%	49,54%	50,05%	50,31%	49,77%	49,69%
1,8	50,98%	50,11%	50,29%	49,58%	49,60%	48,83%	48,43%	48,55%	48,25%
2,1	51,91%	50,26%	48,48%	49,76%	49,72%	49,10%	49,44%	49,59%	49,03%
2,4	54,26%	48,10%	49,09%	49,88%	49,18%	50,32%	48,28%	48,91%	48,83%
2,7	54,33%	49,99%	48,58%	48,42%	48,56%	48,20%	48,45%	48,46%	48,36%
süre (sn)	22,62	23,81	23,97	24,31	27,53	27,53	27,32	27,25	27,42
Aralık 2017									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	49,64%	49,73%	50,97%	49,05%	49,31%	49,95%	50,43%	50,13%	49,80%
1,5	54,48%	49,87%	50,63%	49,54%	49,55%	48,71%	49,79%	49,72%	49,48%
1,8	51,73%	51,06%	50,83%	49,45%	48,84%	50,11%	49,55%	49,39%	48,57%
2,1	54,01%	49,91%	51,06%	49,97%	48,42%	49,17%	49,64%	48,86%	49,39%
2,4	52,77%	49,88%	50,30%	48,74%	48,61%	47,84%	49,32%	49,87%	49,20%
2,7	51,74%	52,14%	51,09%	49,84%	48,59%	48,44%	49,26%	48,88%	48,68%
süre (sn)	22,44	23,31	24,38	23,71	27,64	27,77	27,46	26,72	26,84
Ocak 2018									
m	c=2	c=3	c=4	c=5	c=6	c=7	c=8	c=9	c=10
1,2	50,16%	46,11%	47,65%	48,79%	47,53%	47,97%	47,28%	46,93%	45,86%
1,5	50,64%	46,58%	47,59%	46,59%	45,88%	46,32%	46,55%	45,63%	46,89%
1,8	48,49%	47,39%	46,86%	46,79%	46,19%	46,53%	46,79%	46,59%	47,39%
2,1	48,73%	47,70%	46,70%	45,78%	46,42%	45,89%	45,66%	45,77%	46,88%
2,4	47,69%	46,45%	46,15%	46,18%	45,99%	46,91%	46,36%	46,41%	46,05%
2,7	50,86%	46,52%	47,32%	47,57%	46,68%	45,43%	46,38%	47,07%	46,62%
süre (sn)	21,65	21,98	24,71	25,97	25,75	25,45	25,96	25,89	31,75

Tablo 3.11 daha detaylı incelendiğinde bulanıklık derecesine göre her bir verinin ortalama AMAPE değeri incelendiğinde Haziran 2017 için 2,1 bulanıklık mertebesinde ve Kasım 2017 için 2,7 bulanıklık mertebesinde en düşük AMAPE değerleri karşımıza çıkmaktadır, diğer ayların tahminlemesi için ise 2,4 bulanıklık mertebesinde en düşük AMAPE ortalaması karşımıza çıkmaktadır. Bu işlemin tersine öbeklerin içerisinde en düşük ve bir sonraki düşük ortalama AMAPE değerine sahip sınıflandırma yapıldığında; öbek sayısı Haziran (55,8%), Ağustos (55,6%) ve Kasım (49,0%) tahminleri için en düşük, Temmuz (42,3%) için ikinci en düşük değere sahip olmak üzere 10 öbekte 4 tahmin ayı; Eylül (48,9%) tahmini için en düşük, Mayıs (44,8%) ve Aralık (49,0%) için ikinci en düşük tahmin değerine sahip olmak üzere 7

öbekte 3 tahmin ayı ve Ekim (54,4%) tahmini için en düşük, Haziran (56,0%) ve Eylül (49,5%) için ikinci en düşük tahmin değerine sahip olmak üzere 4 öbekte 3 tahmin ayı için iyi sonuçlar vermektedir. Bu çıktı değerlerini göz önünde bulundurduğumuzda ve işlem sürelerini de dikkate aldığımızda; 10 öbek için ortalama süre 31,3 sn, 7 öbek için ortalama süre 30,2 sn ve 5 öbek için 27,9 sn olduğundan, en kısa sürede sonuç üreten 5 öbekli yapı tercih edilebilir.

Bu modele ait parametre seti şu şekilde oluşmuştur:

- $c=5$
- $m=2,4$
- 6 tahminleme ayı kullanılarak
- 3 ay geriye dönük eğitim veri seti ile çalışılmalıdır.
- Model yapısı  $f_i = \gamma_0 + \gamma_1 x_1 + \gamma_2 x_2 + \dots + \gamma_6 x_6 + \gamma_7 \mu_{i1} x_1 + \gamma_8 \mu_{i2} x_2 + \gamma_9 \mu_{i3} x_3$  şeklindedir.

#### 4. SONUÇLAR VE ÖNERİLER

Höppner ve Klawonn'un önerdikleri BM'den hareketle modele üyelik derecelerinin/ üyelik dereceleri ile değişkenlerin çarpımlarının eklenmesi ve çıkarsama modelinin de buna göre modifiye edilmesi ile yeni bir yaklaşım önerilmiştir. Önerilen BFBM yaklaşımı H&K BM'ye göre yedek parça verisi ile yapılan çalışma temel alındığında %18'lik bir iyileşme sağlamaktadır.

Önerilen model; yaklaşım olarak GBÖ algoritmasına benzese de GBÖ algoritması bu veri için sonuç üretmede başarısız olmuştur. Ayrıca GBÖ modeli oldukça farklı yapılandırılmış bir algoritmadır. Örneğin GBÖ modeli eğitim verisinden öğrendikten sonra kendini doğrulama verisi ile düzelten bir yapıya sahiptir. Bu veri için çözüm üretememesinin temel sebebi talep yapısının hem kesikli hem de kararsız olmasından kaynaklı olduğu düşünülebilir, çünkü verilerin bir çok noktasında "0" taleplerin yer alması "0" a bölme hatası yaratmakta ve algortima maksimum iterasyon sayısı tamamlandığı için durmaktadır.

Otomotiv yedek parça verisinin daha önce açıklanmış olan eliminasyonlar neticesinde 130 parçaya indirgenerek elde edilmiş veri ile 5 farklı öbikleme algoritması ve bulanık modelleme yapıları ile çalışılarak talep tahminleri üretilmiştir. Bu yöntemler literatürde yer alan BÖO, BÖRM, H&K BM ve GBÖ öbikleme algoritmaları ve önerilen BFBM öbikleme algoritması ile bunların bulanık modelleme yapılarıdır.

Bu 5 öbikleme algoritmasından BÖO ve önerilen BFBM yöntemleri verinin mevcut durumda kullanılan üssel düzeltme yöntemine göre daha iyi ve/veya yakın sonuçlar verdiği uygulamalar bölümünde gösterilmiştir. Diğer 3 yöntem ise üssel düzeltme yöntemine göre daha iyi sonuçlar üretmediğinden tez çalışmasında detaylı olarak incelemesine yer verilmemiştir.

BÖO ve önerilen BFBM modelleri ile oluşturulmuş sistem modelleme yaklaşımlarının mevcutta uygulama alanı bulmuş olan üssel düzeltme yöntemine göre karşılaştırması Tablo 4.1'de verilmiştir. Bu tablodaki öbikleme parametreleri uygulamalar

bölümünde saptanmış en iyi parametre yapısına göre oluşturulmuş modeller ile yapılandırılmıştır.

Tablo 4.1 Bulanık sistem modellerinin en iyi parametrelerine göre üssel düzeltme yöntemi ile karşılaştırılması

Tahmin Ayı	Üssel Düzeltme	BFBM	Üssel Düzeltmeye Göre İyileşme /Kötüleşme	BÖÖ	Üssel Düzeltmeye Göre İyileşme /Kötüleşme
Mayıs 2017	46,41%	44,67%	4%	44,18%	5%
Haziran 2017	59,87%	56,08%	6%	57,21%	4%
Temmuz 2017	44,68%	41,68%	7%	44,17%	1%
Ağustos 2017	56,92%	54,57%	4%	58,20%	-2%
Eylül 2017	51,49%	48,96%	5%	51,26%	0%
Ekim 2017	55,64%	52,77%	5%	55,62%	0%
Kasım 2017	47,69%	49,88%	-5%	47,74%	0%
Aralık 2017	53,51%	48,74%	9%	52,82%	1%
Ocak 2018	47,99%	46,18%	4%	50,02%	-4%
Ortalama İyileşme /Kötüleşme			4%		1%

Tablo 4.1’de de görüleceği üzere; BÖÖ ile bulanık fonksiyonlar yaklaşımı üssel düzeltme ile karşılaştırıldığında 9 farklı tahmin dönemi için 3 ayda üssel düzeltmeye göre iyi sonuçlar vermemiştir. Diğer taraftan, toplamda AMAPE ölçütüne göre %1’lik bir iyileşme sağlamıştır. BFBM modeline bakıldığında ise hem üssel düzeltme yöntemine hem de BÖÖ ile bulanık fonksiyonlar modeline göre daha iyi sonuçlar verdiği görülmüştür. BFBM modeli üssel düzeltme yöntemine göre AMAPE ölçütleri karşılaştırıldığında %4’lük bir iyileşme sağlamıştır.

Bu çalışma ile yedek parça talep tahminlemede üssel düzeltme yöntemine alternatif olarak BÖÖ ve BFBM öbekleme algoritmaları ile bulanık sistem modelleri önerilmiştir, kurulacak model ile temel parametrelerin neler olacağı çalışılmıştır. Ayrıca bu modellerin performansları ortaya konmuştur.

İleriye yönelik olarak; buna benzer bir veri seti için daha geniş bir veri analizi yapılarak yalnızca parça talep bilgileri değil ek bilgi olarak;

- yedek parçaya ihtiyaç duyacak satılmış araç sayısı ve hatta bunların yaşlar bazında kırılımı,

- varsa araç satışı yapılmış müşteri ile ilgili bilgiler, sadakat ve yetkili servis kullanım bilgileri
- parçaya ihtiyacın sebebi; arıza, kaza veya bakım ve ortalama arıza, kaza veya bakım sıklığı
- parça'nın fason üretiminin mevcut olup olmadığı bilgisi
- parça'nın ithal veya yerli olup olmadığı
- parça fiyatı bilgisi

gibi bilgilerin de verisetine dahil edilmesi sağlanarak daha yüksek doğruluk oranına sahip tahminleme çalışması yapılabilir. Bu tahminleme çalışması önerilen şekilde veri seti için yapılacak olursa; bu tez çalışması kapsamında başarısız sonuçlar vermiş olan BÖRM, GBÖ ve H&K'nun BM algoritmalarının da tekrar sınanması önerilir.

Literatürde, bu tip ek bilgilerin bulunduğu çalışmalar daha çok yapay sinir ağları ile çalışılmış örneklerden oluşmaktadır ve veri sayısı sınırlıdır. Bu çalışmada olduğu gibi veri sayısının daha fazla olduğu ancak buna ilaveten bahsi geçen ek bilgiler ile zenginleştirilmiş olan yedek parça talep tahmini için bulanık öbekleme çalışmaları çoğaltılabilir



## KAYNAKLAR

Altay N., Rudisill F., Litteral L., Adapting Wright's Modification of Holt's Method to Forecasting Intermittent Demand, *International Journal of Production Economic*, 2008, **111**, 389–408.

Angelov P.P., Filev D.P., An Approach to Online Identification of Takagi-Sugeno Fuzzy Models, *IEEE Transactions on Systems, Man and Cybernetics B.*, 2004, **34**(1), 484-498.

Applebaum W., Method for Determining Store Trade Areas, Marketing Penetration and Potential Sales, *Journal of Marketing Research*, 1996, **3**(2), 124–141.

Armstrong J.S., Collopy F., Error Measures for Generalizing about Forecasting Methods: Empirical Comparisons, *International Journal of Forecasting*, 1992, **8**, 69-80.

Babuka R., Van der Veen P., Kaymak U., Improved Covariance Estimation for Gustafson-Kessel Clustering, in *Proceedings of the IEEE International Conference on Fuzzy Systems*, 2002, **2**, 1081-1085

Bagis A., Fuzzy Rule Base Design Using Tabu Search Algorithm for Nonlinear System Modeling, *ISA Transactions*, 2008, **47**(1), 32-44.

Bermudez J.D., Segura J.V., Vercher E., Improving Demand Forecasting Accuracy Using Nonlinear Programming Software, *Journal of the Operational Research Society*, 2006, **57**, 94–100.

Bezdek J. C., Pattern Recognition with Fuzzy Objective Function, Plenum Press, New York, 1981.

Bezdek J. C., Ehrlich R., Full W., Fcm: The Fuzzy C-means Clustering Algorithm, *Computers & Geosciences*, 1984, **10**(2), 191-203

Bookbinder H., Lordahl A.E., Estimation of Inventory Re-order Levels Using the Bootstrap Statistical Procedure, *IIE Transactions*, 1989, **21**, 302–312.

Botter R., Fortuin L., Stocking Strategy for Service Parts: a Case Study, *International Journal of Operation and Production Management*, 2000, **20**, 656–674.

Box G.E.P., Jenkins G.M., *Time Series Analysis Forecasting and Control*, Revised Edition, Holden Day Inc., California, 1976.

Boylan J.E., Syntetos A.A., Spare Parts Management: a Review of Forecasting Research and Extensions, *IMA Journal of Management Mathematics*, 2010, **21**, 227–237.

- Boylan J.E., Syntetos A.A., Karakostas G.C., Classification for Forecasting and Stock Control: a Case Study, *Journal of Operational Research Society*, 2008, **59**, 473–481.
- Bowser K., Design a Math Model to Provision Spare Part Requirements, *Remanufacturing Seminar Proceedings-APICS*, USA, 1994.
- Brown R.G., *Statistical Forecasting for Inventory Control*, New York: McGraw- Hill, 1959.
- Brown R.G., *Smoothing Forecasting and Prediction of Discrete Time Series*, New Jersey, Prentice-Hall, 1962.
- Callegaro A., Forecasting Methods for Spare Parts Demand, PhD Thesis, Università Degli Studi Di Padova, Facolta Di Ingegneria, Padua, Italy, 2010.
- Celikyilmaz A., Turksen I.B., Evolutionary Fuzzy System Models with Improved Fuzzy Functions and Its Application to Industrial Process, *IEEE-SMC*, Montreal, 2007
- Celikyilmaz, A., Turksen, I.B., Enhanced Fuzzy System Models with Improved Fuzzy Clustering Algorithm, *IEEE Transactions on Fuzzy Systems*, 2008, **16**(3), 779-794.
- Celikyilmaz A., Turksen I.B., *Modeling Uncertainty with Fuzzy Logic with Recent Theory and Applications*, Springer, Berlin / Heidelberg, 2009.
- Charytoniuk W., Box E.D., Lee W.J., Chen M.S., Neural Network Based Demand Forecasting in a Deregulated Environment, *IEEE Transactions on Industry Applications*, 2000, **36**(3), 893–898.
- Chen J.-Q., Xi Y.-G., Zhang Z.-J., A Clustering Algorithm for Fuzzy Model Identification, *Fuzzy Sets and Systems*, 1998, **98**, 319-329.
- Chiang J. -H., Hao P.-Y., Support Vector Learning Mechanism for Fuzzy Rule-Based Modeling: A New Approach, *IEEE Transactions on Fuzzy Systems*, 2004, **12**(1), 1-12.
- Chu C.W., Zhang G.Q., A Comparative Study of Linear and Nonlinear Models for Aggregate Retail Sales Forecasting, *International Journal of Production Economics*, 2003, **86**(3), 217–231.
- Cohen M.A., Agrawal N., Winning in the Aftermarket, *Harvard Business Review*, 2006, **84**, 129–138.
- Croston J.D., Forecasting and Stock Control for Intermittent Demands, *Operational Research Quarterly*, 1972, **23**(3), 289–303.
- Dam T., Deb A.K., Aclustering Algortihm Based TS Fuzzy Model for Tracking Dynamical System Data, *Journal of the Franklin Institute*, 2017, **354**, 5617-5645.
- Dekker R., Van Donselaar K., Ouwehand P., How to Use Aggregation and Combined Forecasting to Improve Seasonal Demand Forecasts, *International Journal of Production Economics*, 2004, **90**, 151–167.

- Deng Z., Cao L., Jiang Y., Wang S., 2015, Minimax Probability TSK Fuzzy System Classifier: A More Transparent And High Interpretable Classification Model, *IEEE Transactions on Fuzzy Systems*, **23**(4), 813-826.
- Demirci M., Fuzzy Functions and Their Fundamental Properties, *Fuzzy Sets and Systems*, 1999, **106** (2), 239-246.
- Dickey D.A., Fuller W.A., Likelihood Ratio Statistics for Autoregressive Time Series with Unit Root, *Econometrica*, 1981, **5**, 455-461.
- Fildes R., The Evaluation of Extrapolative Forecasting Methods, *International Journal of Forecasting*, 1992, **8**, 88-98.
- Gallagher T., Mitchke M.D., Rogers M.D., Profiting From Spare Parts, *The McKinsey Quarterly*, 2 March 2005
- Gath I., Geva A.B., Unsupervised Optimal Fuzzy Clustering, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989, **11**(7), 773-780.
- Ghobbar A.A., Friend C.H., Evaluation of Forecasting Methods for Intermittent Parts Demand in the Field of Aviation: a Predictive Model, *Computers & Operations Research*, 2003, **30**, 2097-2114.
- Gorucu F.B., Geris P.U., Gumrah F., Artificial Neural Network Modeling for Forecasting Gas Consumption, *Energy Sources*, 2004, **26**(3), 299-307.
- Gustafson D.E., Kessel W.C., Fuzzy Clustering with a Fuzzy Covariance Matrix, *IEEE Conference on Decision and Control including the 17th Symposium on Adaptive Processes*, San Diego, CA, USA, 10-12 Jan 1979.
- Heydari G., Gharaveisi A., Vali M., New Formulation for Representing Higher Order TSK Fuzzy Systems, *IEEE Transactions on Fuzzy Sets*, 2016, **24**(4), 854-864
- Holt C.C., Forecasting Seasonal and Trends by Exponentially Weighted Moving Averages, *International Journal of Forecasting*, 2004, **20**(1), 5-10.
- Hoover J., Measuring Forecast Accuracy: Omissions in Today's Forecasting Engine and Demand Planning Software, *International Journal of Applied Forecasting*, 2006, **1**, 32-35.
- Hosmer Jr., D. W., Maximum Likelihood Estimates of the Parameters of a Mixture of Two Regression Lines, *Communications in Statistics*, 1974, **3**(10), 995-1005.
- Höppner F., Klawonn F., Improved Fuzzy Partitions for Fuzzy Regression Models, *International Journal of Approximate Reasoning*, 2003, **32**, 85-102.
- Hua Z., Zhang B., A Hybrid Support Vector Machines and Logistic Regression Approach for Forecasting Intermittent Demand of Spare Parts, *Applied Mathematics and Computation*, 2006, **181**, 1035-1048.

- Huang S., Chen M., Constructing Optimized Interval Type-2 TSK Neuro Fuzzy System with Noise Reduction Property by QuantumInspired BFA, *Neurocomputing*, 2016, **173**, 1839-1850.
- Jiao L., Shang F., Wang F., Liu Y., Fast Semi-supervised Clustering with Enhanced Spectral Embedding, *Pattern Recognition*, 2012, **45**(12), 4358-4369.
- Johnston FR, Boylan J.E., Forecasting for Items with Intermittent Demand, *Journal of the Operational Research Society*, 1996, **47**, 113–121.
- Kalchschmidt M, Verganti R, Zotteri G., Forecasting Demand from Heterogeneous Customers, *International Journal of Operations & Production Management*, 2006, **26**, 619–638.
- Kalchschmidt M., Zotteri G., Verganti R., Inventory Management in a Multi- echelon Spare Parts Supply Chain, *International Journal of Production Economics*, 2003, **81–82**, 397–413.
- Kennedy W.J., Patterson J.W., Fredendall L.D., An Overview of Recent Literature on Spare Parts Inventories, *International Journal of Production Economics*, 2002, **76**(2), 201–215.
- Klassen R.D., Flores B.E., Forecasting Practices of Canadian Firms: Survey Results and Comparisons, *International Journal of Production Economics*, 2001, **70**, 163–174.
- Kuo R.J., A Sales Forecasting System Based on Fuzzy Neural Network with Initial Weights Generated by Genetic Algorithm, *European Journal of Operational Research*, 2001, **129**(3), 496–517.
- Lee H.L., Padmanabhan V., Whang S., The Bullwhip Effect in Supply Chains, *Sloan Management Review*, 1997, **38**(3), 93–102.
- Leven E., Segerstedt A., Inventory Control with a Modified Croston -Procedure and Erlang Distribution, *International Journal of Production Economics*, 2004, **90**, 361–367.
- Li S.G., Kuo X., The Inventory Management System for Automobile Spare Parts in a Central Warehouse, *Expert Systems with Applications*, 2008, **34**, 1144-1153
- Makridakis S., Wheelwright S.C., Hyndman R.J., *Forecasting: Methods and Applications*, 3rd ed. New York: Wiley, 1998.
- Marinos P.N., Fuzzy Logic and Its Application to Switching Systems, *IEEE Transactions on Computers*, 1969, **18**(4), 343-348.
- McCarthy T.M., Davis D.F., Golicic S.L., Mentzer J.T., The Evolution of Sales Forecasting Management: a 20-year Longitudinal Study of Forecasting Practices, *Journal of Forecasting*, 2006, **24**, 303–324.

- Menard M., Fuzzy Clustering and Switching Regression Models Using Ambiguity and Distance Rejects, *Fuzzy Sets and Systems*, 2001, **122**, 363-399.
- Miller D.M., Williams D., Shrinkage Estimators of Time Series Seasonal Factors and Their Effect on Forecast Accuracy, *International Journal of Forecasting*, 2003, **19**, 669–684.
- Mizumoto M., Method of Fuzzy Inference Suitable for Fuzzy Control, *Journal of the Society of Instrument and Control Engineers*, 1989, **58**, 959-963.
- Nau F.R., <http://people.duke.edu/~rnau/411avg.htm> (Ziyaret Tarihi: 5 Mart 2017)a
- O'Connor M., Remus W., Griggs K., Judgemental Forecasting in Times of Change. *International Journal of Forecasting*, 1993, **9**, 163–172.
- Ozmen A., *Zaman Serisi Analizinde Box Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi*, Anadolu Üniversitesi Yayınları, Eskişehir, 1986.
- Ozkan I., Turksen I.B., Upper and Lower Level of Fuzziness of FCM, *Information Sciences Special Issue*, 2007, **177** (23), 5143-5152.
- Pal N.R., Pal K., Keller J.M., Bezdek J.C., A Possibilistic Fuzzy C-means Clustering Algorithm, *IEEE Transactions on Fuzzy Sets*, 2005, **13**(4), 517-530.
- Pegels C.C., Exponential Forecasting: Some New Variations, *Management Science*, 1969, **15**, 311-315.
- Persson F., Saccani N., Managing the After Sales Logistic Network - a Simulation Study, *Production Planning & Control*, 2009, **20**, 125–34.
- Pindyck R.S., Rubinfeld D.L., *Econometric Models and Economic Forecasts*, Irwin/McGraw Hill International Edit, Singapore, 1998.
- Ragsdale C.T., Plane D.R., On Modelling Time Series Data Using Spreadsheets, *Omega*, 2000, **28**(2), 215–221.
- Rao A.V., A Comment on: Forecasting and Stock Control for Intermittent Demands, *Operational Research Society*, 1973, **24**, 639–640.
- Sanders N., Ritzman L., *Judgmental Adjustments of Statistical Forecasts, Principles of Forecasting*, (J. Armstrong ed.). New York: Kluwer Academic Publishers, 405–416, 2001
- Sani B., Kingsman B.G., Selecting the Best Periodic Inventory Control and Demand Forecasting Methods for Low Demand Items, *Journal of the Operational Research Society*, 1997, **48**, 700–713.
- Sasaki M., Fuzzy Functions, *Fuzzy Sets and Systems*, 1993, **55**(3), 295-301.

Schultz C.R., Forecasting and Inventory Control for Sporadic Demand Under Periodic Review, *Journal of the Operational Research Society*, 1987, **38**, 453–458.

Senjyu T., Mandal P., Uezato K., Funabashi T., Next Day Load Curve Forecasting Using Hybrid Correction Method, *IEEE Transactions on Power Systems*, 2005, **20**(1), 102–109.

Setnes M., Babuska R., Verbruggen H., Rule-based Modelling: Precision and Transparency, *IEEE Transactions on Systems, Man and Cybernetics C*, 1998, **28**(1), 165-169

Sharaf M.A., Helmy H.A., A Classification Model for Inventory Management of Spare Parts, In: *Proceedings of the 7th international conference on Production, Industrial Engineering, Design and Control (PEDAC 2001)*, 375–382, 2001.

Shang R., Zhang Z., Jiao L., Wang W., Yang S., Global Discriminative-based Nonnegative Spectral Clustering, *Pattern Recognition*, 2016, **55**, 172-182.

Shenstone L., Hyndman R.J., Stochastic Models Underlying Croston's Method for Intermittent Demand Forecasting, *Journal of Forecasting*, 2005, **24**, 389–402.

Siy P., Chen C.S., Minimization of Fuzzy Functions, *IEEE Transactions on Computers*, 1972, **32** (1), 100-102.

Snyder R., Forecasting Sales of Slow and Fast Moving Inventories, *European Journal of Operational Research*, 2002, **140**, 684–699.

Syntetos A.A., Boylan J.E., The Accuracy of Intermittent Demand Estimates, *International Journal of Forecasting*, 2005, **21**, 303–314.

Syntetos A.A., Boylan J.E., Croston J.D., On the Categorisation of Demand Patterns, *Journal of Operational Research Society*, 2005, **56**, 495–503.

Syntetos A.A., Boylan J.E., On the Bias of Intermittent Demand Estimates, *International Journal of Production Economics*, 2001, **71**, 457–466.

Taha H.A., *Operations Research – An Introduction*, Mac Millan Comp., New York, 1992.

Takagi T., Sugeno M., Fuzzy Identification of Systems and Its Applications to Modeling and Control, *IEEE Transactions on Systems, Man and Cybernetics*, 1985, **15**(1), 116-132.

Teunter R.H., Syntetos A.A., Babai M.Z., Determining Order-up-to Levels Under Periodic Review for Compound Binomial (Intermittent) Demand, *European Journal of Operational Research*, 2010, **16**, 619-624.

Tofallis C., A Better Measure of Relative Prediction Accuracy for Model Selection and Model Estimation, *Journal of the Operational Research Society*, 2015, **66**(8), 1352-1362.

Türkşen I.B., Celikyilmaz A., Comparison of Fuzzy Functions with Fuzzy Rule Base Approaches, *International Journal of Fuzzy Systems*, 2006, **8**(3), 137-49.

Türkşen I.B., Fuzzy Functions with LSE, *Applied Soft Computing*, 2008, **8**(3), 1178-1188.

Ünal B., Bulanık Fonksiyonlar ile Bulanık Sistem Modelleme, Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2009, 244547

Vernieuwe H., De Baets B., Verhoest N.E., Comparison of Clustering Algorithms in the Identification of Takagi-Sugeno Models: a Hydrological Case Study, *Fuzzy Sets and Systems*, 2006, **157**(21), 2876-2896.

Wang M., Rao S.S., Estimating Reorder Points and Other Management Science Applications by Bootstrap Procedure, *European Journal of Operational Research*, 1992, **56**, 332–342.

Willemain T.R., Smart C.N., Schwarz H.F., A New Approach to Forecasting Intermittent Demand for Service Parts Inventories, *International Journal of Forecasting*, 2004, **20**, 375–387.

Williams T.M., Stock Control with Sporadic and Slow-Moving Demand, *Journal of Operational Research Society*, 1984, **35**, 939–948.

Winters P.R., Forecasting Sales by Exponentially Weighted Moving Averages, *Management Science*, 1960, **6**(3), 324–342.

Xei L.X., Beni G., A Validity Measure for Fuzzy Clustering, *IEEE Transactions of Pattern Analysis and Machine Intelligence*, 1991, **13**(8), 841-847.

Zadeh L.A., Fuzzy Sets, *Information and Control*, 1965, **8**, 338-353.

## **KİŞİSEL YAYIN VE ESERLER**

**Özçift B.**, Self-Deciding Demand Forecast System for A Spare Parts Company, EURO-INFORMS 26th European Conference on Operational Research, Rome, 1-4 July 2013.

**Ünal B.**, Bulanık Fonksiyonlar ile Bulanık Sistem Modelleme, Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2009, 244547

**Ünal B.**, Efe M.Ö., Bir Biyoreaktör Sisteminin Gürbüz Nörokontrolü, *Otomatik Kontrol Ulusal Toplantısı (TOK'07)*, İstanbul, Sabancı Üniversitesi, 5-7 Eylül 2007.





## ÖZGEÇMİŞ

1982 yılında Ankara’da doğdu. 2005 yılında Gazi Üniversitesi Endüstri Mühendisliği bölümünden lisans derecesi ile mezun oldu. 2009 yılında burslu olarak okuduğu TOBB Ekonomi ve Teknoloji Üniversitesinde yüksek lisans eğitimini tamamladı, bu süre zarfında aynı üniversitede araştırma görevlisi olarak çalıştı. 2010 yılında girdiği Ford Otomotiv San A.Ş. Kocaeli Fabrikası’nda sırasıyla Malzeme Planlama ve Lojistik departmanında ithal ikmal mühendisi, Bilgi Teknolojileri direktörlüğünde Süreç mühendisi, Pazarlama, Satış ve Satış Sonrası departmanında Fiyatlandırma mühendisi ve son olarak da Muhasebe ve Finans departmanında Bütçe ve Finansal analiz uzmanı olarak çalışmaktadır. Evli ve bir kız çocuğu annesidir.