

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

**ANFİS VE ARİMA MODELLERİ İLE ENDÜSTRİ 4.0 VERİLERİNİN
KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Buket İPEK

**HAZİRAN 2019
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK VE BİLGİSAYAR BİLİMLERİ ANABİLİM DALI

**ANFIS VE ARIMA MODELLERİ İLE ENDÜSTRİ 4.0 VERİLERİNİN
KARŞILAŞTIRILMASI**

Buket İPEK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"YÜKSEK LİSANS (İSTATİSTİK)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 20 / 07 / 2019

Tezin Savunma Tarihi : 21 / 06 / 2019

Tez Danışmanı : Dr. Öğr. Üyesi Tolga BERBER

Trabzon 2019

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İstatistik ve Bilgisayar Bilimleri Anabilim Dalında
Buket İPEK tarafından hazırlanan**

**ANFIS VE ARIMA MODELLERİ İLE ENDÜSTRİ 4.0 VERİLERİNİN
KARŞILAŞTIRILMASI**

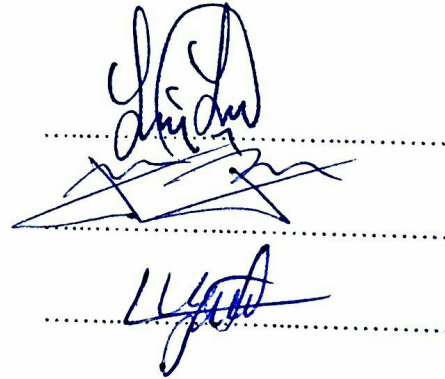
**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 28 / 05 / 2019 gün ve 1806 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Doç. Dr. Sinan SARAÇLI

Üye : Dr. Öğr. Üyesi Tolga BERBER

Üye : Dr. Öğr. Üyesi Uğur ŞEVİK



Prof. Dr. Asim KADIOĞLU

Enstitü Müdürü

ÖNSÖZ

“ANFIS ve ARIMA Modelleri ile Endüstri 4.0 Verilerinin Karşılaştırılması” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Bilimleri Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Başta tez çalışma süresince değerli yardım ve katkılarıyla beni yönlendiren danışman hocam Sayın Dr. Öğr. Üyesi Tolga BERBER’ e, değerli yardım ve katkılarını esirgemeyen hocam Sayın Doç. Dr. Hakan Çağdaş ALADAĞ’ a, değerli katkılarını esirgemeyen Sayın hocam Dr. Öğr. Üyesi Uğur ŞEVİK’ e, değerli yardım ve katkılarını esirgemeyen hocam Sayın Doç. Dr. Sinan SARAÇLI’ a, desteği ile her zaman yanımda olan, görüş ve önerilerinden her zaman yararlandığım, hiç bir yardımdan kaçınmayan sevgili İhsan BERK’ e, tez süresince desteklerini esirgemeyen arkadaşım Şeyma ARSLANDAĞ ve ailesine teşekkürü borç bilirim.

Son olarak tüm hayatım boyunca maddi manevi her zaman beni destekleyen, bugünlerimin mimarı olan aileme sonsuz teşekkürlerimi sunarım.

Buket İPEK
Trabzon 2019

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduđum “ANFIS ve ARIMA Modelleri ile Endüstri 4.0 Verilerinin Karşılaştırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr. Öğr. Üyesi Tolga BERBER’in sorumluluğunda tamamladığımı, verileri kendim topladığımı, analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 21/06/2019

Buket İPEK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY.....	IX
ŞEKİLLER DİZİNİ	X
ÇİZELGELER DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Bulanık Mantık Kavramı.....	2
1.3. Bulanık Mantık Tarihçesi.....	4
1.4. Bulanık Mantık Avantaj ve Dezavantajı	5
1.5. Önceki Çalışmalar	6
1.6. Bulanık Küme ve Sayı Kuramı	8
1.6.1. Bulanık Küme.....	9
1.6.2. Üyelik Fonksiyonları.....	9
1.6.3. Bulanık Sayı	10
1.6.4. Alfa Kesmesi	12
1.6.5. Eşitsizlikler.....	13
1.6.6. Kesikli Bulanık Kümeler.....	13
1.7. Bulanık Aritmetik.....	14

1.7.1.	Genişleme Prensipleri.....	14
1.7.2.	Aralık Prensipleri.....	15
1.7.3.	Bulanık Aritmetik.....	16
1.7.4.	Bulanık Fonksiyonlar	17
1.8.	Endüstri 4.0	17
1.9.	Zaman Serisi.....	18
1.9.1.	Zaman Serisinin Bileşenleri	19
1.9.2.	Durağanlık.....	21
1.9.2.1.	Tam Durağanlık.....	21
1.9.2.2.	Birinci ve İkinci Dereceden Durağanlık.....	22
1.9.3.	Otokovaryans ve Otokorelasyon Fonksiyonu	22
1.9.4.	Kısmi Otokorelasyon Fonksiyonu.....	23
1.9.5.	Doğrusal Zaman Serisi Modeli.....	24
1.9.5.1.	Otoregresif Modeli (AR(p))	24
1.9.5.2.	Hareketli Ortalama Modeli (MA(q)).....	25
1.9.5.3.	Otoregresif Hareketli Ortalama Modeli (ARMA(p,q))	27
1.10.	Bulanık Zaman Serisi	29
2.	YAPILAN ÇALIŞMALAR	32
2.1.	Sinirsel Bulanık Mantık Çıkarım Sistemi (ANFIS)	32
2.2.	Bulanık Mantık Çıkarım Sistemleri	33
2.3.	Bulanık Kural Tabanı	35
2.3.1.	Sinirsel Bulanık Mantık Sistem Yapısı	35
2.3.2.	Mamdani Modeli	38
2.3.3.	Takagi-Sugeno-Kang Modeli	41
2.3.3.1.	Takagi-Sugeno-Kang Modeli Kural Tabanı ve Adımları.....	42

2.4.	Üyelik Fonksiyonları	44
2.4.1.	Üçgen (Trimf) Üyelik Fonksiyonu.....	45
2.4.2.	Yamuk (Trapmf) Üyelik Fonksiyonu.....	45
2.4.3.	Çan Şekilli (Gbellmf) Üyelik Fonksiyonu	46
2.4.4.	Gauss (Gaussmf) Üyelik Fonksiyonu.....	46
2.4.5.	Sigmoidal (Psigmf) Üyelik Fonksiyonu.....	46
2.4.6.	Diğer Üyelik Fonksiyonları.....	47
2.5.	Kullanılan Başarı Ölçütleri.....	48
2.6.	Uygulama	48
2.7.	ANFIS Tahmin Modelinin Kurulması ve Test Edilmesi.....	49
2.8.	Zaman Serisi Tahmin Modelinin Kurulması.....	57
3.	BULGULAR	62
3.1.	ANFIS Model Sonuçları.....	62
3.2.	ARIMA Model Sonuçları.....	72
3.3.	Bulanık Zaman Serisi ile Zaman Serisinin Karşılaştırılması	76
4.	SONUÇLAR VE ÖNERİLER	79
5.	KAYNAKLAR.....	81

ÖZGEÇMİŞ

Yüksek Lisans

ÖZET

ANFIS VE ARIMA MODELLERİ İLE ENDÜSTRİ 4.0 VERİLERİNİN
KARŞILAŞTIRILMASI

Buket İPEK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik ve Bilgisayar Bilimleri Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Tolga BERBER
2019, 90 Sayfa

Bu çalışmada, bir üretim hattından elde edilen zaman serisi verisine klasik zaman serisi ve bulanık zaman serisi yaklaşımları uygulanarak sonuçları karşılaştırılmıştır. Sinirsel bulanık mantık çıkarım sistemi (ANFIS) kaotik bir zaman serisini tahmin etmek amacıyla kullanılan bir yaklaşım olduğu için, üretim hattından sensörler yardımı ile alınan veriler üzerinde uygulanmıştır. Çalışmada, birinci derece Sugeno bulanık çıkarım sistemi yöntemi kullanılmış olup, veri setleri için uygun üyelik fonksiyonları belirlenmiştir. Tahmin başarımlarının değerlendirilmesi amacıyla, hata kareleri ortalamasının karekökü (RMSE) ve mutlak hata yüzdeleri ortalaması (MAPE) değerleri hesaplanmıştır. Klasik zaman serisi yöntemlerinden biri olan Box-Jenkins yöntemi ile de ARIMA modelleri belirlenmiş olup, aynı başarımların değerleri bu modeller içinde hesaplanmıştır. ANFIS yaklaşımı ve ARIMA modelleri yardımıyla elde edilen RMSE ve MAPE değerleri karşılaştırılmıştır. Çalışma sonucunda, birinci derece Sugeno bulanık çıkarım sistemi yöntemi ile elde edilen hata kareleri ortalamasının ve mutlak hata yüzdeleri ortalamasının Endüstri 4.0 verileri üzerinde en iyi sonuçlar verdiği görülmüştür. Ayrıca, bulanık çıkarım sistemi yöntemi ile gerçek değerlere en yakın tahmin değerleri üretmiştir.

Anahtar Kelimeler: Sinirsel bulanık mantık çıkarım sistemi (ANFIS), RMSE, MAPE, Endüstri 4.0, ARIMA

Master Thesis

SUMMARY

COMPARISON OF ANFIS AND ARIMA MODELS VIA INDUSTRY 4.0 DATA

Buket İPEK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Statistical and Computer Science Graduate Program
Supervisor: Assistant Prof. Tolga BERBER
2019, 90 Pages

In this study, performances of classical and fuzzy time series approaches, which are applied to time series data obtained from a product line, are compared. As a result, an approach to avoid possible anomalies of product line and to provide preventive maintenance capabilities to Industry 4.0 is tried to be achieved. Since The Adaptive-Network-Based Fuzzy Inference System (ANFIS) was used to estimate chaotic time series, it was particularly applied on time series data obtained from production line using sensors. The first degree Sugeno fuzzy inference system method has been used and suitable membership functions have been determined for the dataset. The Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE) were calculated to assess estimation performance. ARIMA models, which is the one of the classical time series approaches, were determined by Box-Jenkins method and same performance metrics are calculated. The RMSE and MAPE values obtained by using ANFIS method and ARIMA models were compared. Finally, it was observed that the RMSE and MAPE obtained by first degree Sugeno fuzzy inference system method gave the best results on Industrial 4.0 data. In addition, the fuzzy inference system method produced the closest estimation values to actual values.

Key Words: Adaptive-Network-Based Fuzzy Inference System (ANFIS), RMSE, MAPE, Industrial 4.0 data, ARIMA.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Klasik küme ve bulanık küme grafiği.....	9
Şekil 2. Üçgen bulanık sayı	10
Şekil 3. Yamuk bulanık sayı	11
Şekil 4. Üçgen biçimli bulanık sayı	12
Şekil 5. Bulanık mantık çıkarım sisteminin genel yapısı.....	34
Şekil 6. İki girişli bir Sugeno bulanık mantık çıkarım sistemi	36
Şekil 7. İki girişli bir Sugeno bulanık mantık çıkarım sistemi mimarisi	36
Şekil 8. Mamdani bulanık çıkarım sistemi	40
Şekil 9. Durulaştırma işleminde kullanılan yöntemler	41
Şekil 10. Üyelik fonksiyon tipi ve adedinin seçimi	50
Şekil 11. Model girdilerinin eğitilmesi	51
Şekil 12. Eğitim seti içerisinde gerçek çıktı ve tahmini çıktılarının karşılaştırılması	52
Şekil 13. Model test verisi başarı grafiği	52
Şekil 14. Modelin kural yapısı	53
Şekil 15. Model üyelik fonksiyonunun sözel değer belirlenmesi	54
Şekil 16. Kurulan ANFIS mimarisi çıktısı.....	56
Şekil 17. Kurulan model ilişki grafiği.....	56
Şekil 18. Veri seti korelogram grafiği.....	59
Şekil 19. ACF korelogram grafiği	60
Şekil 20. PACF korelogram grafiği	61
Şekil 21. Alev değişkeni gerçek ve bulanık değer grafiği	64

Şekil 22.	Basınç deęişkeni gerçek ve bulanık deęer grafięi	65
Şekil 23.	Hareket deęişkeni gerçek ve bulanık deęer grafięi	67
Şekil 24.	Nem deęişkeni gerçek ve bulanık deęer grafięi	68
Şekil 25.	Sıcaklık deęişkeni gerçek ve bulanık deęer grafięi.....	70
Şekil 26.	Yüzey sıcaklığı deęişkeni gerçek ve bulanık deęer grafięi	71



TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Klasik mantık ve bulanık mantık arasındaki temel farklılıklar	5
Tablo 2. Matlab üyelik fonksiyonları.....	45
Tablo 3. RMSE ve MAPE hesaplama formülleri	48
Tablo 4. Alev veri setinin saatlik veri dönüşümü	49
Tablo 5. ANFIS sisteminin oluşturduğu kural tabanı	55
Tablo 6. Durağan modellerde ana kütle otokorelasyon ve kısmi fonksiyonlarının ilerleyişi	57
Tablo 7. Durağan olmayan modellerde ana kütle otokorelasyon ve kısmi fonksiyonlarının ilerleyişi.....	58
Tablo 8. Alev değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi	63
Tablo 9. Basınç değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi	64
Tablo 10. Hareket değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi	66
Tablo 11. Nem değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi	67
Tablo 12. Sıcaklık değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi	69
Tablo 13. Yüzey sıcaklığı değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi.....	70
Tablo 14. Alev değişkeni eğitim verisi için ARIMA model çıktısı	72
Tablo 15. Alev değişkeni test verisi için ARIMA model çıktısı.....	72
Tablo 16. Basınç değişkeni test verisi için ARIMA model çıktısı.....	73
Tablo 17. Basınç değişkeni test verisi için ARIMA model çıktısı.....	73
Tablo 18. Hareket değişkeni eğitim verisi için ARIMA model çıktısı	73

Tablo 19. Hareket deęiřkeni test verisi iin ARIMA model ıktısı.....	74
Tablo 20. Nem deęiřkeni eęitim verisi iin ARIMA model ıktısı.....	74
Tablo 21. Nem deęiřkeni test verisi iin ARIMA model ıktısı.....	75
Tablo 22. Sıcaklık deęiřkeni eęitim verisi iin ARIMA model ıktısı.....	75
Tablo 23. Sıcaklık deęiřkeni test verisi iin ARIMA model ıktısı.....	75
Tablo 24. Yüzey sıcaklığı deęiřkeni eęitim verisi iin ARIMA model ıktısı.....	76
Tablo 25. Yüzey sıcaklığı test verisi iin ARIMA model ıktısı.....	76
Tablo 26. ANFIS ve ARIMA RMSE ve MAPE deęerleri.....	77

SEMBOLLER DİZİNİ

(a, b)	: Açık aralık
$[a, b]$: Kapalı aralık
α	: Alpha
β	: Beta
$>$: Büyük
\geq	: Büyük ve eşit
\notin	: Elemanı değildir
\in	: Elemanıdır
$=$: Eşit
\approx	: Hemen hemen eşit, yaklaşık
\Rightarrow	: ise
$<$: Küçük
\leq	: Küçük ve eşit
<i>AND</i>	: Ve
<i>max</i>	: Maksimum
<i>min</i>	: Minimum
$\mu(x)$: Üyelik Fonksiyonu
U	: Bulanık Zaman Serisi
\cong	: Bulanık küçük eşit
\cong	: Bulanık büyük eşit
\tilde{A}	: A Bulanık Kümesi
\bar{N}	: N Bulanık Sayı Kümesi
\bar{A}	: A Bulanık Sayı
\mathbb{R}	: Reel Sayılar Kümesi
Σ	: Toplam
\forall	: Her
γ	: Otokovaryans Fonksiyonu
ρ	: Otokorelasyon Fonksiyonu
<i>Cov</i>	: Kovaryans
<i>Var</i>	: Varyans
\emptyset	: Otoregresif Parametresi

- θ : Hareketli Ortalama Parametresi
- ψ : Eğim Katsayısı
- ACF* : (Autocorrelation Function) Otokorelasyon fonksiyonu
- PACF* : (Partial Autocorrelation Function) Kısmi otokorelasyon fonksiyonu
- ANFIS* : (Adaptive Neuro-Fuzzy Inference System) Adaptif ağ tabanlı bulanık çıkarım sistemi
- AR* : (Autoregressive) Otoresif
- MA* : (Moving Average) Hareketli ortama
- ARMA* : (Autoregressive Moving Average) Otoresif hareketli ortalama
- ARIMA* : (Autoregressive Integrated Moving Average) Otoresif bütünleşik hareketli ortalama yöntemi
- MF* : (Membership Function) Üyelik Fonksiyonu
- MS* : (Mean Square) Ortalama hata kare
- MAPE* : (Mean Absolute Percentage Error) Ortalama mutlak yüzde hata
- RMSE* : (Root Mean Square Error) Ortalama hata karenin karekökü

1. GENEL BİLGİLER

1.1. Giriş

2011 yılında ilk kez Almanya'daki Hannover Fuarı'nda adını duyuran Endüstri 4.0, bir dijitalleşme sürecinin başlamasına sebep olmuştur. Tüm dünyayı hızla saran akıllı üretim olarak da ifade edilen dijitalleşme süreciyle birlikte yeni teknoloji faktörlerinin de üretimin her aşamasında yapay zekâ sistemleri ile bilgi alışverişi mümkün hale gelmiştir.

Bu dönüşümün birçok farklı sektörde yer almaya başladığı görülmektedir. Bunlardan biri olan akıllı fabrikalar, üretimi hızlı ve problemsiz bir şekilde yönetebilirken, elde edilen ürünlerin nitelikli, uzun ömürlü, sorunsuz ve otonom robotların üretimde olduğu, fabrikalar olarak tanımlanmaktadır. Günümüzde teknolojiyle birlikte bilgide yaşanan olağanüstü artışlar, internet ve farklı kaynakların gündelik hayatta bilgiye erişimi kolaylaştırmıştır. Fakat bununla birlikte yanlış ve yararsız bilgi sorununu da gündeme getirmiştir. Büyük veri teknolojisi sayesinde toplanan tüm verilerin anlamlı ve işlenebilir biçime dönüştürülebilir. Bu sebeple, bu çalışmada Endüstri 4.0 teknolojisini kullanılan bir fabrikanın üretim hattından sensörler yardımı ile alınan zaman serisi verileri üzerinde durulacaktır.

Gözlem sonucu elde edilen veriler bir değişkenin zaman içinde gösterdiği değişimleri ifade ediyorsa bu duruma ilişkin verilerin sunuş biçimine zaman serisi denir. Zaman serisi analizinin geleneksel kullanımı, bir değişkenin zaman yolunu tahmin etmektedir. Bir dizinin tahminlerini iyileştirmek için dinamik yolunu açığa çıkarmak gerekir. Ekonomik verilerin yorumlanmasında ve hipotez testlerinde uygun şekilde tahmin edilen denklemler kullanılabilir. Ayrıca, bu yaklaşım ile elde edilen veriler kullanılarak ilerleyen zamanlarda olası anomalilerinde tespiti yapılabilir.

Zaman serilerini çözmek için günümüzde iki yaklaşım bulunmaktadır. Bunlardan ilki olasılık temelli yaklaşım diğeri ise veri temelli yaklaşımlardır. Veri temelli yaklaşımlardan ise günümüzde en güncel olanı belirsizlik altında iyi sonuçlar verdiği için bulanık temelli yaklaşımlardır. Lotfi A. Zadeh (1965) bulanık mantık ve bu mantık kurallarını kullanan bulanık küme teorisini ortaya attığı makalesinde belirsizlik içeren sistemlerin incelenmesi yeni bir boyut almıştır. Bu çalışmada, bir üretim hattındaki olası anomalileri öngörebilmek

için bulanık küme kuramına dayalı olarak ANFIS (Sinirsel Bulanık Mantık Çıkarım Sistemi)) yöntemi uygulanacak, incelenecek, farklı üyelik fonksiyonların öngörüdeki etkisi araştırılarak en iyi üyelik fonksiyonu belirlenecek ve ARIMA modelleri ile karşılaştırılarak elde edilen bulgular hakkında yorumlar yapılacaktır.

1.2. Bulanık Mantık Kavramı

Dünyanın en karmaşık makinesi olarak kabul edilen insan beyni sayısal bir işlemi kısa bir sürede yapabilirken, anlamaya yönelik olayları çok daha kısa bir sürede yapar. Karmaşık sayısal işlemleri hızlıca çözebilen bilgisayarlar, anlama ve tecrübe ile kazanılmış bilgileri kullanabilmede çok yetersiz kalırlar. İnsanı ya da insan beynini üstün kılan ilk özelliklerden biri, sinirsel algılayıcılar vasıtası ile kazanılmış ve görelilik olarak sınıflandırılmış bilgileri kullanmasıdır. Bu sebeple, Bulanık Mantık (BM), Uzman Sistemler (US), Yapay Sinir Ağları (YSA) ve Genetik Algoritma (GA) vb. gibi yapay zekâ dalları son yıllarda, geniş bir uygulama alanı ve araştırma alanı bulmaktadır (Elmas, 2018).

Klasik mantığın sonuçları “tamamen doğru” ya da “tamamen yanlış” şeklinde ifade edilir. İdealleştirilmiş matematik dünyasına zıt olarak, gerçek dünyaya ilişkin algımız, keskin olmayan, tanımlanmış sınırları olmayan durumlardır. Bunun sonucu olarak ortaya farklı değerlerin de ihtiyacını doğurmuştur. Dilsel değişkenler kullanılarak daha güncel ve şartlara daha iyi hitap edebilen değerlerin kullanılması ortaya atılmıştır. Dilsel bir değişken, değerleri doğal veya sentetik bir dilde kelimeleri veya cümleleri olan bir değişkendir. Örneğin, değişkenimiz “yükseklik” ise dilsel bir değişken olarak ele alınırsa, değerleri “uzun, uzun değil, çok uzun, çok çok uzun, daha fazla veya daha az uzun” gibi dilsel değerlerin kullanılmasıdır. Bulanık mantık altında tıpkı insan beyninin çalışma mantığında olduğu gibi olaylara sayısal değil sözel bazı belirlemelerle yaklaşmaktadır. Dilsel veriler $[0,1]$ arasında aldıkları üyelik derecesi ile ifade edilirler. Üyelik derecesinin, çok değerli bir mantıkta bir yüklem gerçeğe değeri olarak yorumlanabilir. Örneğin, “genç” bir kişi söz konusu olduğunda, yaşını ele alacak olursak. Bu durumda, söylem evreni aralık $[0,120]$ olarak alınabilir ve “85 yaşındaki bir insanın” genç sınıftaki üyelik derecesi 0,6 olabilir. “Genç” kavramı hem içeriğe bağımlı hem de öznedir. Bulanık mantık anlayışında, eğer “yaş” bir bulanık değişken ise değerleri “genç, çok genç, yaşlı, çok yaşlı”

gibi dilsel ifadeleri kullanılmaktadır. Bulanık mantık, özellikle sistemin karmaşık olduğu ve kesinliğin bulunmadığı durumlara daha uygun bir yaklaşımdır (Zadeh, 1990).

Lotfi A. Zadeh'in (1965) bulanık küme kuramını ortaya koyduğu çalışmasında bulanık mantığın temel özelliklerini;

- i. Bulanık mantıkta, nesne sınıflarının kesin olarak tanımlanmış bir üyelik kriteri yoktur.
- ii. Bulanık mantıktaki veriler $[0,1]$ aralığındaki bir derece ile ifade edilir.
- iii. Bulanık mantıkta, kesin olarak tanımlanmamış (çok fazla, çok az, büyük, küçük gibi) dilsel ifadeler kullanılır.
- iv. Her mantıksal sistem bulanık olarak ifade edilebilir.
- v. Bulanık mantık çıkarım sistemi dilsel ifadeler arasında tanımlanan kurallar ile uygulanır.
- vi. Bulanık mantık, matematiksel modeli zor elde edilen sistemler için çok kullanışlıdır

şeklinde ifade edilir.

Bulanık mantığın ilk uygulaması, 1974 yılında Mamdani tarafından geliştirilen bir buhar motorunun bulanık denetiminin gerçekleştirilmesi ile başlamıştır. Geçmiş yıllar içinde ilk olarak Japonya, Amerika, Almanya'da yaklaşık 1000'den fazla ticari ve endüstriyel bulanık sistemleri başarıyla ortaya koymuştur. Japonya 1990'lardan bu yana bulanık teoriyi pek çok amaçla kullanmıştır. Örnek verirsek, bir çamaşır makinesinde bulanık mantığın kullanılması halinde makine üretim sürecinde eklenen algılayıcılar vasıtası ile içine yerleştirilen çamaşırların dokularına ve kirlilik seviyelerine göre en uygun yıkama programını ve su kullanım miktarını kolaylıkla belirleyebilmektedir. Bu tür ürünler piyasada rahatlıkla bulunabilmektedir. Bulaşık makineleri, televizyonlar, elektrik süpürgeleri vb. Bunların yanı sıra bulanık mantığın sanayi uygulamalarında yer aldığı görülmektedir (Elmas, 2018). İlerleyen yıllar içinde, bulanık mantık kontrolü, Sendai metrosundan Sugeno'nun bulanık otomobiline kadar geniş bir yelpazedeki sistemlerde büyük başarı ile kullanılmıştır (Özdaoğlu, 2016).

1.3. Bulanık Mantık Tarihiçesi

2000’li yıllardan bu yana, modern bilim, kesinlikler ve mutlaklıklar üzerine kuruludur. Evrendeki gerçeklikler genellikle gri olsalar da, bilim, yaptığı kesin tanımlamalarıyla onları siyaha ve beyaza boyar. Uç değerler arasında dereceli değerlerin var olduğu her dönemde bilinen bir gerçektir. Fakat bu gerçeği kabullenmek ve bilimsel saymak pek çok bilim adamı tarafından kolay olmamıştır (İşbilen Yücel, 2018).

Yunanca Logike kelimesinin Arapça tercümesi olan mantık kelimesi Logikos, söze, akla ve akıl yürütmeye ait demektir. Mantık, doğru ve düzgün düşünme formlarını inceleyen bilim dalıdır. Mantığı ilk defa sistematik şekilde ele alıp kuran Aristoteles’tir (Paksoy vd., 2013).

1920’lerden itibaren, Aristo mantığı olarak bilinen iki değerli klasik mantık filozof ve teorik matematikçilerin ürettikleri paradoksları açıklamakta yeterli olamamıştır. Aristo mantığı gerçek dünyayı bütünüyle tasvir etmekten uzaktır. Herhangi bir önermenin yalnızca doğru ya da yalnızca yanlış olması gerekliliği, ikili mantığın gelişerek çok değerli mantığa dönüşmesine sebep olmuştur. Üç değerli mantık çok değerli mantığın en ilkel hali olan, önermeleri $[0,1]$ değerlerinin yanında, $[0.5]$ değerini de almasını sağlamıştır ve böylece değer kümesi $[0, 0.5, 1]$ olarak geliştirilmiştir. Polonyalı mantık bilimcisi Lukasiewicz 1930’ların başında, üç değerli mantığı bütünüyle ele almıştır ve sonsuz değerli mantığı geliştirmiştir (İşbilen Yücel, 2018).

Bulanık mantığın ve bu mantık kurallarını kullanan bulanık küme teorisi ilk olarak Lotfi A. Zadeh’in (1965) çalışmasının yayınlanmasından sonra belirsizlik içeren sistemlerin incelenmesi yeni bir boyut kazanmıştır. 1965’de ortaya atılmasına rağmen, bulanık küme kavramı ancak 1970’li yılların ikinci yarısından sonra kullanılmaya başlanmıştır. Bunda özellikle Zadeh’in 1965 yılındaki ilk makalesinden daha fazla etkili olan ve bulanık mantığın belirsizlik içeren sistemlere uygulanabilirliğini açıklayan makalelerinin etkili olduğu görülmektedir (Altaş, 1999).

Bulanık mantık doğada var olan, fakat bilimsel olduğu, hatta olması gerektiği sonradan anlaşılan, farklı bir öğreti gibi varlığını çağlar boyu devam ettirmiştir. Kimi zaman paradokslar, kimi zaman üç değerli, kimi zaman çok değerli olarak karşımıza çıkmış, nihayet Zadeh’in tanımlamalarıyla gerçek kimliğini kazanmıştır. Klasik ve bulanık mantık arasındaki temel farklılıklar Tablo 1’de özetlenmiştir (İşbilen Yücel, 2018).

Tablo 1. Klasik mantık ve bulanık mantık arasındaki temel farklılıklar

KLASİK (İKİ DEĞERLİ) MANTIK	BULANIK (SONSUZ DEĞERLİ) MANTIK
A veya A değil	A ve A değil
Kesinlikle	Kısmen
{0,1}	[0,1]
Dijital Bilgisayar	İnsan Beyni
Basic, Pascal, C, vb.	Türkçe, İngilizce, vb.
Bitler (ikili birimler)	Fitler (kısmi, dereceli birimler)

1.4. Bulanık Mantık Avantaj ve Dezavantajı

Elmas'a (2003) göre bulanık mantığın avantajlarından en önemlisi insan beyninin işleyiş biçimine yakın olması aynı zamanda insan düşünce tarzının yansıtması olarak karşımıza çıkar. İstikrarsız ve doğrusal olmayan sistemler bulanık mantığın en başarılı şekilde uygulandığı alanlardır. Bununla birlikte, bulanık mantığa yönelik olarak yapılan bazı eleştiriler de vardır. Sistemin kararlı olup olmadığını kontrol etmek amacıyla kullanılacak belirli bir yöntem bulunmamaktadır. Üyelik değerleri ve fonksiyonlar sisteme özel olduğundan dolayı farklı problemlerde kullanılmak istenildiğinde uyarlanmaları bir zorunluluk olarak ortaya çıkar (Özdağoğlu, 2016).

Bulanık mantık uygulamalarında az miktarda değerler, kurallar ve kararlar gereklidir ve gözlemlenen miktarda değişken değerlendirilir. İnsan düşünce yapısına benzeyen dilsel, numerik olmayan, değişkenler kullanılır. Geleneksel kontrol sistemlerine göre oldukça hassas ve sabit sistemler olanak veren, çıktı ile girdi arasında, tüm değişkenlerin anlaşılmasına gerek kalmadan bağlantı kurar. Önceden çözülememiş problemlerin çözümüne olanak sağlar. Sistem tasarımcısının, sistem hakkında yeterli bilgiye sahip olmasa bile prototip oluşturmayı hızlandırır. Geleneksel kontrol sistemlerine göre daha ucuz ve daha etkilidir. Bilgi kazanımını ve gösterimini kolaylaştırır. Karmaşık durumlar da az sayıda kurallar kullanılır. Dezavantajlarında ise; bulanık bir sistemden model geliştirmek zordur. Sistem tasarımcısı çalışılan konunun en ince detaylarına hakim ise geleneksel sistemlerden daha kolay ve hızlı prototip oluşturur. En büyük dezavantajı,

kontrol sistemleri için matematiksel hassasiyet veya kesin sistemler ve lineer sistemler olmasıdır (Paksoy vd., 2013).

1.5. Önceki Çalışmalar

Zadeh (1965) tarafından önerilen bulanık küme teorisi ve bulanık mantık dilsel verilerle ifade edilen bilgilerdeki belirsizliği ele almak için genel bir yöntem sunmuştur. Zadeh'in (1965, 1975a, 1975b, 1975c) çalışmalarına dayanarak ilk bulanık zaman serisini Song ve Chissom (1993a, 1993b, 1994)'te ortaya koymuştur. Song ve Chissom (1993a, 1993b, 1994), iki bulanık zaman serisi modeli önermiştir; bunlardan ilki maksimum-minimum işlemleri olan bir zamanla değişmeyen modeldir ve diğeri ise zamana göre değişen bir değişkendir. Bununla birlikte, bulanık ilişki "R" çok büyük olduğunda, her iki modelde, basamağında kabul edilen maksimum-minimum veya minimum-maksimum kompozisyon işlemlerinden dolayı yüksek hesaplama yükü yaşanılmıştır. Yükü rahatlatmak için, Chen (1996)'da Song ve Chissom'un önerdiği yöntemi kolaylaştırarak bulanık mantık grup ilişki tablolarının kullanıldığı bir algoritma önermiştir bunun yanı sıra Sullivan ve Woodall (1994)'te bulanık mantık grup ilişki tablolarının kullanıldığı bir algoritma kullanarak Markov tabanlı bir alternatif model önermişlerdir. Chen'nin (1996) önerdiği basitleştirilmiş aritmetik işlem, sadeliği ve en azından eşdeğer doğruluğu nedeniyle çoğu araştırmacı tarafından tercih edilir. Mevcut modellerin birinci dereceden bulanık zaman serilerine dayanarak geliştirildiği ve tahminlerin doğruluğunun oldukça sınırlı olduğu gerçeği ışığında, Tsai ve Wu (1999, 2000, 2001) iyileştirmeye odaklanan, büyük oranda hassas, farklı uygulamalar için bir model ortaya koymuşlardır. Bununla birlikte, yüksek mertebeden bulanık ilişkiler oluşturmak için fazladan hesaplama ek yükü ile yüksek mertebeye arasındaki seçim, doğruluk ve verimlilik arasında bir dengedir. Aynı zamanda Yu (2005a) tarafından önerilen ve tahmin doğruluğunu iyileştirmek için ilişkilerin tekrarını ve ağırlığını göz önünde bulunduran ağırlıklı model için de geçerlidir. Söylem evrenini bölümlere ayırmak, zaman serisini bulanıklaştırma adımlarındaki gelişmeye odaklanan Huarng (2001a), aralıkların uzunluğunun belirsiz zaman serilerinde tahmin sonuçlarını etkilediğine ve bu konuya yaklaşmak için dağıtım tabanlı ve ortalama tabanlı uzunluk önerdiğine dikkat çekmektedir. Yu (2005b), tarif edilmiş gözlemleri ve tahminde bulunacak düzeltmeleri kullanarak rafine bir model önermiştir. Bunların yanı

sıra, Cheng, Chang ve Yeh (2006) bulanık zaman serilerine alternatif modeller önermişlerdir (Cheng, vd., 2008).

Önceki odaklanmaların dışında, Hwang, Chen ve Lee (1998), kayıt tahmin problemlerini ele almak için her yılın gerçek değerleri yerine iki yıl üst üste varyasyonları kullanarak yeni bir zamana göre değişen bir model önermiştir. Huarng ve Yu (2006), eşit aralığın küçük ve büyük gözlemleri için farklı anlamlara sahip olabileceğini yansıtmak amacıyla eşit aralıklarla uzunluk yerine orana dayalı uzunluk aralıklarını önermişlerdir. Chen ve Hwang (2000) sıcaklık tahmini için iki özellikli bir zamana göre değişen bir model önermişlerdir. Benzer bir fikre dayanarak, birkaç farklı model önerilmiştir. Huarng'da (2001b), borsaya özgü sezgisel bilgi, yani hisse senedi endeksinin ve eşiklerin varyasyonları, vadeli işlem endeksinin tahmin sonuçlarını geliştirmek için bulanık zaman serisi modeline entegre etmiştir. Hsu, Tse ve Wu'da (2003), bulanık Markov matrisi, hisse senedi endeksini tahmin etmek için kapanış fiyatları ve işlem hacmini kullanan iki değişkenli bulanık zaman serisi modelini önermişlerdir. Huarng ve Yu' da (2005), daha fazla gözlem değişkeni kullanmak için tip 2 modeli önermişlerdir (Cheng, vd., 2008).

Gerçek zamanlı dizi verilerinin birçok faktörden etkilenmektedir. Bu durumda, çok değişkenli bulanık zaman serisi tahmin modelinin kullanılması, daha doğru tahminler alabilmek için daha makul olabilir. Çok değişkenli bulanık zaman serisi yaklaşımı benimsendiğinde bulanık tahminler elde etmek için, en çok uygulanan yöntem bulanık ilişki tabloları kullanmaktır. Eğrioğlu ve arkadaşları (2009) çalışmalarında, bulanık ilişkileri belirlemek için bulanık mantık ilişkisi tablolarının kullanılmasını gerektirmeyen yeni bir yöntem tanıtıldı. Bu yöntem yerine, bulanık ilişkileri belirlemek için ileri beslemeli bir yapay sinir ağı modeli kullanılmış, böylece bulanık mantık ilişkisi tablolarının kullanımına ihtiyaç duyulmamıştır (Eğrioğlu vd., 2009).

Huarng ve Yu (2006b), Eğrioğlu ve arkadaşları (2009a, 2009b, 2009c) ile Yu ve Huarng (2008) bulanık ilişkilerin belirlenmesinde yapay sinir ağlarını kullanan yaklaşımlar ortaya koymuşlardır. Yolcu ve arkadaşları (2010) tarafından önerilen bulanık zaman serisi analizi yaklaşımı ile ortadan kaldırılan sorunların yanında, göz önüne alınması gereken durumlarda söz konusudur. Berraklaştırma aşamasında genel olarak merkezileştirme yöntemi kullanılmakla birlikte, Jilani ve Burney (2007, 2008) ile Jilani ve ark. (2007) bazı farklı yöntemler önermişlerdir (Yolcu, 2011).

1.6. Bulanık Küme ve Sayı Kuramı

Klasik küme kuramı bir elemanın o kümeye ait olma veya ait olmama durumunu tanımlayan fonksiyondur, hiçbir zaman kısmi üyelik söz konusu olamaz. Nesnenin üyelik değeri 1 ise kümenin tam elemanı, 0 ise elemanı değildir. Başka bir deyişle klasik kümelerde elemanların üyelikleri $\{0,1\}$ değerlerini alır (Elmas, 2018).

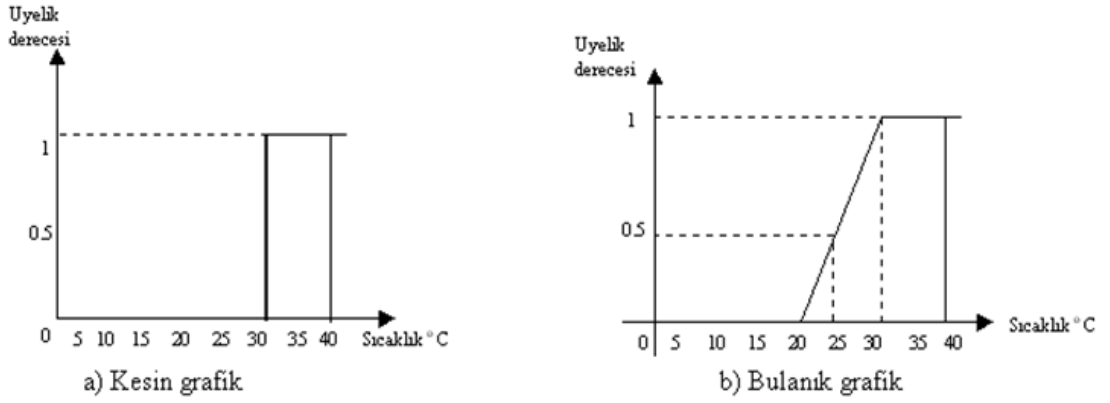
X klasik bir küme ise A , X 'in bir alt kümesi olsun, klasik kümenin elemanların üyelikleri Eşitlik (1)'de ki;

$$\mu_A(x) = \begin{cases} 1 & \text{ise } x \in A \\ 0 & \text{ise } x \notin A \end{cases} \quad (1)$$

şeklinde ifade edilir (Zadeh, 1975).

Ural (2006)' e göre; bulanık kümeler bulanık mantığın temelini oluşturmaktadır. Bir bulanık küme, μ_x üyelik fonksiyonuyla ifade edilen elemanlardan oluşur. Bu elemanlar kümeye tam olarak ait ise "1" üyelik derecesine sahip, eğer ait değil ise "0" üyelik derecesine sahip ya da kısmi aitlik söz konusu ise 0 ile 1 arasında üyelik değerli olabilirler (Paksoy, 2013).

Klasik kümelere ve bulanık kümelere örnek olarak, Şekil 1a kesin grafiği incelendiğinde, sıcaklığın 30 °C'nin altında olduğunda soğuk, üstünde olduğunda ise sıcak olarak ifade edildiği görülmektedir. Oysa gerçek dünyada, kesin sınırlar yoktur. Şekil 1b bulanık grafik incelendiğinde, 20-40 °C arasında değer aldığı ve sıcak kümesine üye olmalarına rağmen, 30-40 °C arasındaki sıcaklık değerleri, 1 üyelik derecelerine sahiptir. 20-30 °C arasındaki sıcaklık değerleri 0 ile 1 arasında bir üyelik derecesine sahip olacağı görülmektedir (URL-1, 2019).



Şekil 1. Klasik küme ve bulanık küme grafiği

1.6.1. Bulanık Küme

Ω bir küme ise, \bar{A} , Ω 'nın bulanık bir alt küme olsun. \bar{A} 'nın üyelik fonksiyonu $\bar{A}(x)$ ile tanımlansın. $\bar{A}(x)$ fonksiyonu Ω 'ya $[0, 1]$ aralığına eşleştirilir. Eğer $\bar{A}(x_0) = 1$ ise x_0 , \bar{A} 'ya ait olduğunu söyleriz, $\bar{A}(x_0) = 0$ ise x_0 , \bar{A} 'a ait olmadığını söyleriz. Eğer $\bar{A}(x_2) = 0.6$ ise x_2 'nin \bar{A} 'daki üyelik değeri 0.6'dır. $\bar{A}(x)$ daima 1 veya 0 ise \bar{A} bir bulanık küme değildir (Buckley, 2006).

1.6.2. Üyelik Fonksiyonları

Özkan (2003)'e göre, konuya ilişkin ele alınan bilgi, küme terimiyle sistematik olarak bir araya toplanır. İyi tanımlanmış nesnelere topluluğu "küme" adı verilir. Nesnelere oluşturduğu kümenin her bir ögesi (eleman, üye) üzerinde çalışılan kümenin her biri alt küme olarak isimlendirilir ve alt kümeleri kapsayan küme evrensel küme denir. Klasik bir küme, nesnelere ortak özelliklerine göre gruplama işlemi olarak tanımlanabilir. Klasik bir kümenin elemanları, ikiye bölme kuralına (1 veya 0, evet veya hayır, doğru veya yanlış gibi) dayanarak belirlenir (Yolcu, 2011).


Terano vd. (1987)' e göre bir bulanık küme için $\mu_A(x)$ ifadesi x elemanının üyelik fonksiyonu olarak adlandırılmaktadır. $[0, 1]$ aralığında değer alabilen fonksiyonlar ve bu değerler x elemanının üyelik derecesini gösterir. Bulanık mantık teorisinde yamuk üyelik fonksiyonu, üçgen üyelik fonksiyonu gibi pek çok üyelik fonksiyonu olduğu bilinmektedir

(Özdağođlu, 2016). Günümüzde üyelik fonksiyonlarının birçok türü kullanılmaktadır. En çok tercih edilen üçgen üyelik fonksiyonu olduđu görülmektedir.

1.6.3. Bulanık Sayı

Pedrycz (1989)'e göre; bulanık kümelerin özel bir alt kümesi olan bulanık sayılar, kesin olmayan ya da yaklaşık olarak ifade edilebilen sayısal miktarların nitelenmesinde bulanık sayıların kullanımı daha uygun bir yaklaşımdır. Evrensel kümede tanımlı olan bulanık sayılar, doğal sayılar kümesi, tamsayılar kümesi ya da gerçek sayılar kümesidir. Her bulanık küme, bulanık bir sayı değildir ama her bulanık sayı bulanık bir kümedir. Bulanık kümenin bir bulanık sayı olabilmesi için, ifade edilen özelliklerin sağlanması gerekmektedir (Yolcu, 2011). Bunlar; bulanık küme normal bulanık bir küme olmalıdır, Bulanık küme, dış bükey bir bulanık küme olmalıdır, Bulanık kümenin destek kümesi sınırlı olmalıdır, bulanık kümenin her bir α -kesimi, gerçel sayı doğrusunun kapalı bir aralığında tanımlı olmalıdır.

\bar{N} üçgen bulanık sayı $a < b < c$ üç sayı ile tanımlanır. Burada üçgenin tabanı $[a, c]$ aralığı, b tepe noktasını göstermektedir. Üçgen bulanık sayı bu parametrelere göre $\bar{N} = (a/b/c)$ olarak yazılır. Üçgen bulanık sayı $\bar{N} = (1.2/2/2.4)$ şekil 2'de gösterilmiştir. $\bar{N}(2) = 1$ ve $\bar{N}(1.6) = 0.5$ şeklindedir (Buckley, 2006).




Şekil 2. Üçgen bulanık sayı

Üçgen bulanık sayı yapısı Eşitlik (2)'de gösterilmiştir (Özdağođlu, 2016).

$$\mu_A(x; a, b, c) = \begin{cases} \text{eğer } a \leq x \leq b \Rightarrow \frac{x-a}{b-a} \\ \text{eğer } b \leq x \leq c \Rightarrow \frac{c-x}{c-b} \\ \text{eğer } x > c \text{ veya } x < a \Rightarrow 0 \end{cases} \quad (2)$$

Bir yamuk bulanık sayı $a < b < c < d$ dört sayı ile tanımlanır. Burada yamuk bulanık sayı taban aralığı $[a, d]$ ve üst taban aralığı $[b, c]$ 'dir. Yamuk bulanık sayı $\bar{M} = (a/b, c/d)$ şeklinde ifade edilir. Yamuk bulanık sayı $\bar{M} = (1.2/2, 2.4/2.7)$ Şekil 3'de gösterilmiştir (Buckley, 2006).



Şekil 3. Yamuk bulanık sayı


Yamuk bulanık sayının genel yapısı Eşitlik (3)'te gösterilmiştir (Özdağoğlu, 2016).

$$\mu_A(x; a, b, c, d) = \begin{cases} \text{eğer } a \leq x \leq b \Rightarrow \frac{x-a}{b-a} \\ \text{eğer } b \leq x \leq c \Rightarrow 1 \\ \text{eğer } c \leq x \leq d \Rightarrow \frac{d-x}{d-c} \\ \text{eğer } x > d \text{ veya } x < a \Rightarrow 0 \end{cases} \quad (3)$$

Üçgen biçimli bulanık bir sayı Şekil 4'te gösterilmiştir. Bu üçgen biçimli bulanık sayı $\bar{P} \approx (1.2/2/2.4)$ şeklinde gösterilir. Şekil 4'te $[1.2, 2]$ aralığında doğru olmayan bir çizgi ve $[2, 2.4]$ arasında ise bir doğru çizgi vardır. Bir $\bar{P} \approx (a/b/c)$ bulanık sayısının üçgen biçimli olması için,

- i. $[a, b]$ aralığı üzerinde monoton olarak artması ve sürekli olması gerekir
- ii. $[b, c]$ aralığı üzerinde monoton olarak azalması ve sürekli olması gerekir

şeklinde ifade edilmiştir (Buckley, 2006).



Şekil 4. Üçgen biçimli bulanık sayı

1.6.4. Alfa Kesmesi

Alfa kesmeleri, düzenli (bulanık olmayan) parçalarıdır. Eğer \bar{A} , Ω 'nın bulanık alt kümesi ise \bar{A} 'nın α - kesmesi $\bar{A}[\alpha]$ şeklinde yazılır (Buckley, 2004).

$$\bar{A}[\alpha] = \{x \in \Omega / \bar{A}(x) \geq \alpha\}, \text{ tüm } 0 \leq \alpha < 1 \quad (4)$$

Eşitlik (4) şeklinde tanımlanır. $\alpha = 0$ için $\bar{A}[0]$ ayrı ayrı tanımlanmalıdır. \bar{A} bir bulanık küme için, $\bar{A}[0]$, \bar{A} bulanık kümenin temeli (base) olarak adlandırılır. Bazı çalışmalarda bu temel değer (a, c) açık aralığı ile de ifade edilmesine rağmen bu çalışmada bu temel değer $[a, c]$ kapalı aralığı ile ifade edilmektedir. Bulanık sayının merkezi (core), üyelik değerinin 1 olduğu bir değer kümesidir.

$\bar{N} = (a/b/c)$ ve $\bar{N} \approx (a/b/c)$ şeklinde bulanık sayının merkezi tek bir b noktasıdır. $\bar{M} = (a/b, c/d)$ ve $\bar{M} \approx (a/b, c/d)$ şeklinde bulanık sayının merkezi $[b, c]$ kapalı aralığı olacaktır. Herhangi bir bulanık sayı \bar{Q} için $0 \leq \alpha < 1$ olmak üzere, $\bar{Q}[\alpha]$ kapalı, sınırlanmış bir aralık olduğu bilinir ve Eşitlik (5) ile gösterilir,

$$\bar{Q}[\alpha] = [q_1(\alpha), q_2(\alpha)] \quad (5)$$

Burada; $q_1(\alpha)$ alfanın artan, $q_2(\alpha)$ ise alfanın azalan fonksiyonu olacaktır. Eğer \bar{Q} , üçgen biçimli veya yamuk biçimli bulanık sayı ise;

- i. $q_1(\alpha); [0,1]$ α 'nın sürekli, monoton olarak artan bir fonksiyonudur.

- ii. $q_2(\alpha)$; $[0,1]$ α 'nın sürekli, monoton olarak azalan bir fonksiyondur.
- iii. Üçgen biçimli bulanık sayı için; $q_1(1) = q_2(1)$, yamuk biçimli bulanık sayı için; $q_1(1) < q_2(1)$

Şekil 2.'deki $\bar{N} = (1.2/2/2.4)$ üçgen bulanık sayısı için $\bar{N}[\alpha] = [n_1(\alpha), n_2(\alpha)]$ şeklinde ifade edilen $n_1(\alpha) = 1.2 + 0.8\alpha$ ve $n_2(\alpha) = 2.4 - 0.4\alpha$, $0 \leq \alpha \leq 1$ olarak elde edilir.

\bar{N} bulanık sayı olmak üzere gerçek sayıların bulanık küme için genel gereklilikleri şunlardır:

- i. Normalize edilmesi gerekir ya da bazı x için $\bar{N}(x) = 1$
- ii. Alfa kesmeleri $[0, 1]$ aralıklarıyla tüm alfalar için kapalı veya sınırlıdır.

1.6.5. Eşitsizlikler

Herhangi bir üçgen bulanık sayı $\bar{N} = (a/b/c)$ ve δ herhangi bir reel sayı olmak üzere , $a \geq \delta \Rightarrow \bar{N} \geq \delta$ ve $a > \delta \Rightarrow \bar{N} > \delta$ şeklinde yazılabileceği gibi $c \leq \delta \Rightarrow \bar{N} \leq \delta$ ve $c < \delta \Rightarrow \bar{N} < \delta$ şeklinde de yazılabilir.

\bar{A} ve \bar{B} , Ω kümesinin iki bulanık alt kümesi olsun. Eğer $\bar{A} \leq \bar{B}$ ise Ω kümesindeki tüm x elemanları için $\bar{A}(x) \leq \bar{B}(x)$ olacaktır ve \bar{A} , \bar{B} bulanık kümesinin bir alt kümesidir (Buckley, 2005).

1.6.6. Kesikli Bulanık Kümeler

\bar{A} , Ω kümesinin bir alt kümesi olduğunu düşünelim. Eğer $\bar{A}(x)$, Ω kümesindeki x değerinde sınırlı sayıda sıfırdan farklı ise o zaman \bar{A} kesikli bulanık küme olarak adlandırılır. Varsayalım ki $\bar{A}(x)$ 'in elemanları x_1, x_2, x_3, x_4 sıfır değildir. Bulanık küme Eşitlik (6) ile ifade edilir,

$$\bar{A} = \left\{ \frac{\mu_1}{x_1}, \frac{\mu_2}{x_2}, \frac{\mu_3}{x_3}, \frac{\mu_4}{x_4} \right\} \quad (6)$$

$i = 1,2,3,4$ olmak üzere μ_i , üyelik değerleridir. Ω 'da herhangi bir alanın kesikli bulanık alt kümelerine sahip olunabilir ve Eşitlik (7) ile ifade edilir (Buckley, 2006).

$$\bar{A}(x_i) = \begin{cases} \mu_i , & i = 1,2,3,4 \\ 0 & , \quad d.d. \end{cases} \quad (7)$$

1.7. Bulanık Aritmetik

Eğer \bar{A} ve \bar{B} iki bulanık sayı ise toplama, çıkarma, çarpma ve bölme gibi işlemlere ihtiyaç duyulabilir. $\bar{A} + \bar{B}$, $\bar{A} - \bar{B}$ ve benzeri gibi hesaplamaların iki temel yöntemi vardır:

- i. Genişleme prensibi
- ii. Alfa kesmeleri ve aralık aritmetiği

1.7.1. Genişleme Prensibi

İki bulanık sayı \bar{A} ve \bar{B} olsun. Eğer $\bar{A} + \bar{B} = \bar{C}$ ise \bar{C} üyeliği fonksiyonu Eşitlik (8)'de ki gibi tanımlanır (Klir ve Yuan, 1995).

$$\bar{C}(z) = \sup_{x,y} \{ \min (\bar{A}(x), \bar{B}(y)) / x + y = z \} \quad (8)$$

Eğer $\bar{C} = \bar{A} - \bar{B}$ ise \bar{C} için üyelik fonksiyonu Eşitlik (9)'da ki gibi tanımlanır;

$$\bar{C}(z) = \sup_{x,y} \{ \min (\bar{A}(x), \bar{B}(y)) / x - y = z \} \quad (9)$$

Eğer $\bar{C} = \bar{A} \cdot \bar{B}$ ise \bar{C} için üyelik fonksiyonu Eşitlik (10)'da ki gibi tanımlanır;

$$\bar{C}(z) = \sup_{x,y} \{ \min (\bar{A}(x), \bar{B}(y)) / x \cdot y = z \} \quad (10)$$

Eğer $\bar{C} = \bar{A} / \bar{B}$ ise \bar{C} için üyelik fonksiyonu Eşitlik (11)'de ki gibi tanımlanır;

$$\bar{C}(z) = \sup_{x,y} \{ \min (\bar{A}(x), \bar{B}(y)) / x / y = z \} \quad (11)$$

\bar{A} ve \bar{B} üçgen bulanık sayılar ise $\bar{A} + \bar{B}$, $\bar{A} - \bar{B}$ olduğu durumda \bar{C} bulanık bir sayıdır. Çarpma ve bölme işlemlerinde ise $\bar{A} \cdot \bar{B}$ ve \bar{A}/\bar{B} olduğunda \bar{C} üçgen biçimli bulanık sayılar olacaktır. Burada “sup” operatörü en küçük üst sınırı göstermektedir. Ω , gerçek sayılar kümesi olduğunda Ω maksimum üyeye sahip ise $\text{sup}(\Omega) = \max(\Omega)$ olur (Buckley, 2006).

1.7.2. Aralık Prensibi

$[a_1, b_1]$ ve $[a_2, b_2]$ iki kapalı, sınırlı, gerçel sayıların aralıkları olsun. * işareti toplama, çıkarma, çarpma veya bölmeyi gösterirse, $[a_1, b_1] * [a_2, b_2] = [\alpha, \beta]$ şeklinde gösterilir ve aralık aritmetiği Eşitlik (12)'deki gibi gösterilir (Moore, 1979)(Neumaier, 1990).

$$[\alpha, \beta] = \{a * b/a_1 \leq a \leq b_1, a_2 \leq b \leq b_2\} \quad (12)$$

Eşitlik (12) ile verilen denklem Eşitlik (13)-(16) ile basitleştirilebilir;

$$[a_1, b_1] + [a_2, b_2] = [a_1 + a_2, b_1 + b_2] \quad (13)$$

$$[a_1, b_1] - [a_2, b_2] = [a_1 - b_2, b_1 - a_2] \quad (14)$$

$$[a_1, b_1]/[a_2, b_2] = [a_1, b_1] \left[\frac{1}{b_2}, \frac{1}{a_2} \right] \quad (15)$$

Ve

$$[a_1, b_1] \cdot [a_2, b_2] = [\alpha, \beta] \quad (16)$$

şeklinde dönüşür.

$$\alpha = \min \{a_1 a_2, a_1 b_2, b_1 a_2, b_1 b_2\} \quad (17)$$

$$\beta = \max\{a_1a_2, a_1b_2, b_1a_2, b_1b_2\} \quad (18)$$

Eşitlik (17) ve (18) şeklindedir.

$a_1 > 0$ ve $b_2 < 0$ veya $b_1 > 0$ ve $b_2 < 0$ ve bunun gibi olduğunu biliyorsak, çarpma ve bölme basitleştirilebilir. Örneğin $a_1 \geq 0$ ve $a_2 \geq 0$ ise;

$$[a_1, b_1] \cdot [a_2, b_2] = [a_1a_2, b_1b_2] \quad (19)$$

$b_1 < 0$ ve $a_2 \geq 0$ olduğunda ise;

$$[a_1, b_1] \cdot [a_2, b_2] = [a_1b_2, a_2b_1] \quad (20)$$

Bunun yanında $b_1 < 0$ ve $b_2 < 0$ olduğunda ise;

$$[a_1, b_1] \cdot [a_2, b_2] = [b_1b_2, a_1a_2] \quad (21)$$

$a_1 \geq 0$ ve $b_2 < 0$ olduğunda ise;

$$[a_1, b_1] \cdot [a_2, b_2] = [a_2b_1, b_2a_1] \quad (22)$$

şeklinde olacaktır (Buckley, 2006).

1.7.3. Bulanık Aritmetik

\bar{A} ve \bar{B} iki bulanık sayı olsun. α -kesmelerinin kapalı, sınırlı ve aralıklı olduğunu biliyoruz. $\bar{A}[\alpha] = [a_1(\alpha), a_2(\alpha)]$, $\bar{B}[\alpha] = [b_1(\alpha), b_2(\alpha)]$ şeklindedir. $\bar{C} = \bar{A} + \bar{B}$ ise;

$$\bar{C}[\alpha] = \bar{A}[\alpha] + \bar{B}[\alpha] \quad (23)$$

$\bar{C} = \bar{A} - \bar{B}$ ise;

$$\bar{C}[\alpha] = \bar{A}[\alpha] - \bar{B}[\alpha] \quad (24)$$

eşitlikleri $[0,1]$ aralığındaki her α için yazılabilir. Bunun yanı sıra $\bar{C} = \bar{A} \cdot \bar{B}$ ise;

$$\bar{C}[\alpha] = \bar{A}[\alpha] \cdot \bar{B}[\alpha] \quad (25)$$

$\bar{B}[\alpha]$ değerlerinin sıfırdan farklı olması koşulu ile $\bar{C} = \bar{A}/\bar{B}$ ise;

$$\bar{C}[\alpha] = \bar{A}[\alpha]/\bar{B}[\alpha] \quad (26)$$

Eşitlikler ile gösterilir (Klir ve Yuan, 1995).

1.7.4. Bulanık Fonksiyonlar

Bir bağımsız \bar{X} değişkenine sahip bulanık bir fonksiyon için $H(\bar{X}) = \bar{Z}$ tanımlansın. \bar{X} üçgen bulanık bir sayı ise, \bar{Z} üçgen biçimli bulanık sayı elde ederiz. Bulanık fonksiyon kavramı iki şekilde ele alınır (Buckley, 2006).

- i. Genişleme prensibi
- ii. α -kesmeleri ve aralık aritmetiği kullanılır

1.8. Endüstri 4.0

I. Sanayi devrimi (1760-1830), ilk olarak İngiltere’de ortaya çıkan, ardından bütün Avrupa’yı saran devrimin temeli 18.yüzyılın ikinci yarısına denk gelmektedir. Sanayileşmenin başlangıcı olarak da kabul edilen ilk devrim, su ve buhar makinelerin üretimde kullanılmaya başlanmıştır. II. Sanayi devriminde (1840-1973) İngiltere, Almanya, ABD, Japonya yer almaktadır. Devrimin etkileri zamanla dünyanın birçok ülkesinde etkisini göstermiştir. Teknoloji devrimi olarak da nitelendirilen, hammadde ve enerji kaynağında değişiklikler yaşanmıştır. III. Sanayi devrimi (1974-2011) 20.yüzyılın ikinci yarısında internetin ortaya çıkması ile bilgi, iletişim ve elektronik teknolojilerle beraber programlanabilir mantıksal denetleyici(PLC)’ler, III. Sanayi devrimi için dönüm noktalarından biri olmuştur. Daha önceki devrimlere göre nitelik bakımından farklılık arz

eden bu sanayi döneminde küreselleşmenin önem kazanması yeni rekabet stratejilerinin ortaya çıkmasına neden olmuştur (Gabaçlı ve Uzunöz, 2017).

Devrim niteliğinde üç süreç geçirmiş olduğu görülen sanayi devrimi, endüstriyel dönüşümdeki son aşama olarak IV. Sanayi devrimi (2011- ...)’dir. Üretimde, insan faktörünün rolünü en aza indirildiği dönem olarak ifade edilebilir. IV. Sanayi devrimi ile programlanabilir devrelerin boyutları ciddi ölçüde küçülmüştür. Yazılım uygulamalarının artması ve otonom robot teknolojilerinin üretim hatlarındaki rolü hem artmış hem de büyümüştür (Berkun, 2018).

2011 yılında Almanya-Hannover fuarında ilan edilen yeni sanayi devrimi, Endüstri 4.0’dır (Şener ve Eleveli, 2017). Alman Ulusal Bilim ve Mühendislik Akademisi tarafından 2013 yılında yayınlanan bildirmede ekonomideki dijital dönüşümü vurgulamaktadır. Mrugalska ve Wyrwicka’ye (2017) göre, Endüstri 4.0, “ürünlerin yaşam döngüsü boyunca yeni bir değer zinciri organizasyonu ve yönetimi seviyesi” veya “cihazların ve karmaşık fiziksel makinelerin, ticari ve toplumsal sonuçlarını iyi tahmin etmek, kontrol etmek ve planlamak için kullanılan ağa bağlı sensörler ve yazılımlarla entegrasyonu” olarak ifade edilmektedirler. Endüstri 4.0, dijital verilerin yazılımın ve bilişim teknolojilerinin birbiri ile bütünleşmiş olarak çalışmasını, üretimle doğrudan ya da dolaylı olarak ilişkili tüm birimlerin birbiri ile ortak çalışması planlanmaktadır (Schuh vd., 2014; Kablan, 2018).

Sanayinin geleceğini şekillendirmesinde Endüstri 4.0 ’la birlikte adından söz ettiren teknoloji faktörü şu şekilde ifade edilebilir: Üç Boyutlu (3D) Yazıcılar, Bulut Bilişim Sistemi, Büyük Veri, Nesnelerin İnterneti, Simülasyon, Otonom Robotlar, Sistem Entegrasyonu, Arttırılmış Gerçeklik, Akıllı Fabrikalar, Siber Fiziksel Sistemlerdir (Gabaçlı ve Uzunöz, 2017).

Endüstri 4.0 teknolojilerinden biri olan akıllı fabrikaların üretimini iyileştirmek, hammadde kaybını engellemek, daha uygun üretim planı yapabilmek ve olası kötü durumlar için önlem alabilmek amacıyla fabrikanın üretim hattından sensör yardımıyla alınan zaman serisi verileri kullanılarak fabrikaya dair istatistiksel analizler ve gelecek tahminleri yapmak önemli bir hale gelmiştir.

1.9. Zaman Serisi

Bir konu hakkında bilgi edinilmek istenildiğinde ana kitleyi oluşturan birimler için, göz önünde bulunduran bir değişken yapılan bir ölçüm ya da gözlem sonucunda aldığı

değerler olan terimlerin, bir zaman değişkenin düzeylerine göre sıralanması ile zaman serisi elde edilir. Zaman serileri ilgilenilen bir konu üzerinde değişkenin zamana göre değişiminin hakkında araştırmacıya bilgi vererek gelecek dönemler hakkında birtakım yorumlar yapmasına da imkân sağlar. Zaman serileri, t zamanı göstermek üzere; t_1, t_2, \dots, t_n zaman dönemlerinde Y değişkenin aldığı değerler olan Y_1, Y_2, \dots, Y_n değerleri ile belirlenir (Şengül, Saraçlıvd., 2010).

Bir zaman serisi, zaman içinde art arda alınan bir dizi gözlemdir. Pek çok veri kümesi zaman dizisi olarak bir fabrikadan gönderilen mal miktarının aylık bir dizisini, haftalık trafik kazaları dizisini, günlük yağış miktarlarını, kimyasal işlemin verimi üzerine yapılan saatlik gözlemleri vb. elde edilen veriler zaman dizisine örnek verilebilir. Zaman serileri örnekleri, ekonomi, işletme, mühendislik, doğa bilimleri ve sosyal bilimler gibi alanlarda çok sık kullanılır (Box, Jenkins, Reinsel ve Ljung, 2016).

Bir olasılık uzayı (Ω, F, P) olsun, T bir indis kümesi olmak üzere, bir zaman serisi $\Omega \times T$ çarpım uzayından reel sayılara giden bir fonksiyondur. Yani, zaman serisi

$$\begin{aligned} X(.,.): \Omega \times T &\rightarrow \mathbb{R}, \\ &:(w, t) \rightarrow X(w, t) \end{aligned} \tag{27}$$

Eşitlik (27) ile tanımlanır. Burada, $X(w, t)$ yerine bazen $X_t(w)$ bazen de (ve genellikle) X_t gösterimi kullanılır (Akdi, 2003).

Bir zaman serisinin analizinin önemli bir parçası, veriler için uygun bir olasılık modelinin (veya model sınıfının) seçilmesidir. Gelecekteki gözlemlerin tahmin edilemeyen doğasına izin vermek için, her bir gözlemin x_t 'nin belli bir rastgele değişken X_t 'nin gerçek bir değeri olduğunu varsaymak doğaldır. Gözlenen veri x_t için bir zaman serisi modeli, X_t 'nin bir gerçekleştirme olarak varsayıldığı bir X_t rastgele değişkenler dizisinin ortak dağılımlarının bir özelliğidir (Brockwell ve Davis, 2016).

1.9.1. Zaman Serisinin Bileşenleri

Enders' e (1948) göre, zaman serisinin karşılaştığı görev, verilerle ilgili hipotezleri tahmin edebilen, yorumlayabilen ve test edebilen oldukça basit modeller geliştirmektir. Zaman serileri analizinin amacı temel olarak öngörmeye yardımcı olmaktır (Walter, 1948)

İktisadi bir olayın zamana göre aldığı değerlerin seyrinde bazı dalgalanmalar gözlemlenebilir. Bu dalgalanmalar, ekonomik, sosyal, psikolojik vb. gibi çeşitli sebeplerin ilgili olay üzerindeki tesir, yön ve şiddetinin farklı olmasından ileri gelir. Bu dalgalanmalar dört ana grupta toplanabilir. Bu dalgalanmalar “trend”, “mevsimsel dalgalanmalar”, “konjonktürel dalgalanmalar”, “rassal (tesadüf) dalgalanmalar” olarak sayılabilir (Özmen, 2007).

Trend, bir zaman serisinin eğilimini ifade eder. Zaman değişkeni bağımsız değişkendir. Kartezyen koordinat sisteminde bağımsız değişken X ekseninde gösterilir. Zamana bağlı olarak değişim gösteren değişken ise Y ekseninde gösterilir. X değerlerine karşı gelen Y değerleri işaretlendiğinde noktalar diyagramı elde edilir. Mevsimsel dalgalanmalar, bir yıldan daha az bir zaman içinde tekrar eden benzer hareketleri ifade eder. Bir hareketin mevsimlik hareket sayılabilmesi için aylık veya mevsimlik ölçümlerin yıllar itibariyle benzerlik göstermesi gerekir. Örnek olarak, kış aylarında palto satışlarının artması ve yaz aylarında dondurma satışlarındaki artışlar verilebilir. Konjonktürel dalgalanmalar, bir zaman serisinde yıllık dönemler itibariyle ortaya çıkan benzer hareketlere denir. Ekonomideki refah, durgunluk, gerileme gibi dalgalanmalar örnek verilebilir. Rassal dalgalanmalar, aniden ortaya çıkan ve önceden tahmin edilmesi mümkün olmayan hareketlerdir. Mesela deprem, sel gibi olayların etkisiyle bir anda bazı mal ve hizmet kalemlerine olan talep aşırı bir biçimde artabilir (Başar ve Oktay, 2000).

Bir zaman serisi trend (T), mevsimsel dalgalanmalar (M), konjonktürel dalgalanmalar (K) ve rassal dalgalanmalar (R) olarak dört bileşenden oluşmaktadır. Zaman serileri analizde yaygın olarak kullanılan toplamsal model ve çarpımsal model Eşitlik (28) ile verilmiştir. Toplamsal modelde bu dört bileşenin birbirinden bağımsız olduğu varsayılırken, çarpımsal modelde dört bileşenin birbiriyle ilişkili olduğu varsayılır (Şengül, Saraçlı vd., 2010).

$$Y = T + M + K + R$$

$$Y = TMKR$$

(28)

1.9.2. Durağanlık

Zaman serileri, ortalamadan gösterdiği sapmalara göre, durağan ve durağan olmayan seriler olmak üzere, başlıca iki ana başlık altında incelenmektedir. İncelenen zaman serisinin ortalaması (ya da trendi) ve varyansı simetrik bir değişme göstermiyorsa veya seri periyodik dalgalanmalardan arınmışsa, böyle serilere, durağan zaman serisi denir. Durağanlık, zaman serilerinde en önemli kavramlardan biridir. İstatistiki sonuç çıkarımlar, durağan zaman serileri için yapılmaktadır. Dolayısı ile seri durağan değil ise bazı teknikler kullanılarak ilk olarak seriyi durağan hale getirmek gerekir. Durağan olmayan serilerde iki durum söz konusudur. Serinin trendi deterministik veya stokastik olabilir (Akdi, 2003).

Zaman serileri stokastik bir süreçtir. Durağanlık, stokastik süreçlerle ilgili bir kavramdır. Bir zaman serisinin stokastik süreç olarak bilenen tüm özellikleri, yani varyansı, ortalaması, kovaryansı ve yüksek dereceden momentleri zamana göre değişmiyorsa veya seri periyodik dalgalanmalardan arınmışsa, seri durağan zaman serisi, bu durum ise “durağanlık” şeklinde isimlendirilir (Fuller, 1976).

Durağanlık incelenirken “tam durağanlık” ve “birinci ve ikinci derecen durağanlık” olarak ele alınabilir.

1.9.2.1. Tam Durağanlık

Bir stokastik süreç tam durağan olarak adlandırılabilmesi için; T 'nin (t_1, t_2, \dots, t_n) herhangi bir alt kümesi ve reel sayısı h için, $t_i + h \in T$, $i = 1, 2, \dots, n$ 'de Eşitlik (29)'da ki fonksiyona sahip oluruz;

$$F(x(t_1), x(t_2), \dots, x(t_n)) = F(x(t_1 + h), x(t_2 + h), \dots, x(t_n + h)) \quad (29)$$

Eşitlik (29)'da gösterilen $F(\cdot)$ 'nin değerlerinin birleşik dağılım fonksiyonudur. Bu durum, tam durağanlık sürecinin bütün momentlerinde, zamanın her noktasında sabit olduğunu gösterir (Gürbüz, 1997).

1.9.2.2. Birinci ve İkinci Dereceden Durağanlık

Bir zaman serisinin tüm özellikleri değil, sadece sıfır orijinine göre birinci momenti (aritmetik ortalaması) zamana göre değişmiyorsa birinci dereceden durağan seri, bu durağanlığa birinci dereceden durağanlık denir. Eğer zaman serisinin sıfır orijinine göre birinci momenti olan aritmetik ortalama ile aritmetik ortalamaya göre ikinci moment olan varyans ve kovaryans zamana göre değişmiyorsa bu seriye “ikinci dereceden durağanlık”, “kovaryans durağanlık” veya “zayıf durağanlık” denir (Gürbüz, 1997).

$\{X_t: t \in T\}$ bir zaman serisi olsun;

- $E(X_t) = \mu$ (yani beklenen değer zamana göre değişmiyor)
- $Cov(X_t, X_s)$ kovaryans sadece $|t - s|$ nin bir fonksiyonudur.

Koşullarını sağlıyorsa durağandır veya zayıf durağandır denir (Akdi, 2003).

1.9.3. Otokovaryans ve Otokorelasyon Fonksiyonu

Zaman serisi analizlerinde en önemli araçlardan biri olan otokovaryans ve otokorelasyon fonksiyonlarıdır. Otokovaryans ve otokorelasyon fonksiyonları zaman serisi modellerinin araştırılmasında ve de durağanlığın belirlenmesinde kullanılabilmektedir. Bir zaman serisi için $\{X_t: t \in T\}$, otokovaryans fonksiyonu denir ve $\gamma(h)$ ile gösterilir (Akdi, 2003).

$$\gamma(h) = Cov(X_t, X_{t+h}) \quad (30)$$

Eşitlik (30) ile tanımlanır. Eşitlik (30) ile verilen otokovaryans fonksiyonundan faydalanılarak serinin otokorelasyon fonksiyonu $\rho(h)$ ile gösterilir. Eşitlik (31) ile hesaplanır (Barrow, 2009: 241).

$$\rho(h) = \frac{\gamma(h)}{\gamma(0)} = \frac{Cov(X_t, X_{t+h})}{\sqrt{Var(X_t)Var(X_{t+h})}} \quad (31)$$

1.9.4. Kısmi Otokorelasyon Fonksiyonu

$\{X_t: t = 1, 2, 3, \dots, n\}$ bir zaman serisi verildiğinde X_t 'nin $X_{t-1}, X_{t-2}, \dots, X_{t-h}$ üzerine regresyonundaki, X_{t-h} 'nin katsayısı h 'nci kısmi otokorelasyon olarak adlandırılmaktadır.

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_h X_{t-h} + e_t \quad (32)$$

Eşitlik (32) fonksiyonu göz önüne alındığında h 'nci kısmi otokorelasyon olarak α_h olacaktır. Eşitlik (32)'i kullanarak kısmi otokorelasyon hesaplanması oldukça zor görülmektedir. Kısmi otokorelasyonları yine otokorelasyonlar yardımı ile daha kolay yoldan;

$$P_h = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdot & \cdot & \rho_{h-1} \\ \rho_1 & 1 & \rho_1 & \cdot & \cdot & \rho_{h-2} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \rho_{h-2} & \rho_{h-3} & \rho_{h-4} & \cdot & \cdot & \rho_1 \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \cdot & \cdot & 1 \end{bmatrix} \quad (33)$$

Ve

$$P_h^* = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdot & \cdot & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdot & \cdot & \rho_2 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \rho_{h-2} & \rho_{h-3} & \rho_{h-4} & \cdot & \cdot & \rho_{h-1} \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \cdot & \cdot & \rho_h \end{bmatrix} \quad (34)$$

Eşitlik (33) ve (34) olarak yazılır.

$$\phi(h) = \frac{\det(P_h^*)}{\det(P_h)} \quad (35)$$

Kısmi otokorelasyon $\phi(h)$ ile gösterilir. Eşitlik (35) elde edilir (Özmen, 1986).

1.9.5. Doğrusal Zaman Serisi Modeli

Doğrusal zaman serisi modelleri otoregresif modeli (AR(p)), hareketli ortalama modeli (MA(q)) ve otoregresif hareketli ortalama model (ARMA(p,q)) olarak ayrılır.

1.9.5.1. Otoregresif Modeli (AR(p))

Birçok ekonomik veri, otoregresif zaman serisi olarak modellenmektedir. Otoregresif zaman serilerinde serinin şimdiki değerleri geçmiş değerlerinden ve beyaz gürültüden etkilenir. Genel olarak, p 'inci dereceden bir otoregresif zaman serisi $e_t \sim WN(0, \sigma^2)$ bir beyaz gürültü serisi ve μ de serinin beklenen değeri olmak üzere,

$$(X_t - \mu) = \sum_{i=1}^p \alpha_i (X_{t-i} - \mu) + e_i \quad (36)$$

Eşitlik (36)'de ifade edilmektedir. Burada, AR(p) ile gösterilmektedir. μ, X_t serisinin ortalaması ve α_i 'ler ise modelin bilinmeyen parametreleridir, $\mu = 0$ olduğu varsayımı altında $Y_t = X_t - \mu$ dönüşümü de kullanılabilmektedir. AR(p) serisi Eşitlik (37) ile verilmiştir (Akdi, 2003).

$$X_t = \sum_{i=1}^p \alpha_i X_{t-i} + e_i \quad (37)$$

Burada x 'lerin her biri μ 'den farklı alınarak elde edilmiştir ve e_t bir beyaz gürültü sürecidir. Eşitlik (38) ve (39) ile serinin durağanlığı için gerekli koşullar verilmiştir (Özek, 2010).

$$E(X_t) = E((1 + \theta_1 B + \theta_2 B^2 + \dots)e_t) = 0 \quad (38)$$

ve

$$\text{Var}(X_t) = \sigma_e^2 \sum_{i=0}^{\infty} \theta_i^2 \quad (39)$$

Eşitlik (38) ve (39) ile verilen X_t zaman serinin durağanlığı için gerekli bir koşuldur.

$$\begin{aligned} \gamma(h) &= \text{Cov}(X_t, X_{t+h}) = \text{Cov}(\alpha X_{t-1} + e_t, X_{t+h}) \\ &= \alpha \text{Cov}(X_{t-1}, X_{t+h}) + \text{Cov}(e_t, X_{t+h}) \\ &= \alpha \text{Cov}(X_{t-1}, X_{t+h}) \\ &= \alpha \gamma(h-1) \end{aligned} \quad (40)$$

Eşitlik (40) ile verilen $\gamma(h)$, X_t zaman serisi için otokovaryans fonksiyonu olarak bulunur. p . dereceden bir otoregresif zaman serisi modeli AR(p)'nin durağan olabilmesi,

$$m^p - \sum_{i=1}^p \alpha_i m^{p-i} = 0 \quad (41)$$

Eşitlik (41)'de gösterilmiştir (Akdi, 2003).

1.9.5.2. Hareketli Ortalama Modeli (MA(q))

Bir zaman serisi, ortalaması sıfır olan herhangi bir $\{e_t: t \in T\}$ zaman serisinin otokovaryans fonksiyonu,

$$\gamma_e(h) = \begin{cases} \sigma^2, & h = 0 \\ 0, & d.d. \end{cases} \quad (42)$$

Eşitlik (42) şeklinde ise “beyaz gürültü (white noise)” serisi; $\{e_t: t \in T\}$ serisine denir. Herhangi bir beyaz gürültü serisini, $e_t \sim WN(0, \sigma^2)$ şeklinde gösterirsek;

$$X_t = e_t + \beta e_{t-1} \quad (43)$$

Eşitlik (43) ile tanımlanır. Bu serinin beklenen değeri sıfırdır ve varyansı Eşitlik (44) ile verilmiştir.

$$\text{Var}(X_t) = \text{Var}(e_t + \beta e_{t-1}) = \sigma^2(1 + \beta^2) \quad (44)$$

Eşitlik (45) ile otokovaryans fonksiyonu verilmiştir.

$$\gamma_X(h) = \text{Cov}(X_t, X_{t+h}) = \text{Cov}(e_t + \beta e_{t-1}, e_{t+h} + \beta e_{t+h-1}) \quad (45)$$

$h: 0$ için serinin varyansı olacağından,

$$\text{Cov}(X_t, X_{t+h}) = \text{Cov}(X_t, X_t) = \text{Var}(X_t) = \gamma_X(0) = \sigma^2(1 + \beta^2) \quad (46)$$

Eşitlik (46) ile bulunmuştur.

$$\begin{aligned} h = \pm 1 \text{ için} \quad \gamma_X(h) &= \beta\sigma^2 \\ |h| \geq 2 \text{ için} \quad \gamma_X(h) &= 0 \end{aligned} \quad (47)$$

Eşitlik (47) yardımı ile X_t zaman serisinin otokovaryansı Eşitlik (48) ile bulunur.

$$\gamma_X(h) = \begin{cases} \sigma^2(1 + \beta^2) & , h = 0 \\ \beta\sigma^2 & , h = \pm 1 \\ 0 & , |h| \geq 2 \end{cases} \quad (48)$$

Benzer şekilde otokorelasyon fonksiyonu Eşitlik (49) ile verilmiştir.

$$\rho(h) = \gamma(h)/\gamma(0) \quad (49)$$

Bu durumda Eşitlik (50) elde edilir.

$$\rho(h) = \begin{cases} 1 & , h = 0 \\ \beta/(1 + \beta^2) & , h = \pm 1 \\ 0 & , |h| \geq 2 \end{cases} \quad (50)$$

Burada serinin otokovaryans fonksiyonu ve otokorelasyon fonksiyonu $|h| \geq 2$ için sıfır olmaktadır (Akdi, 2003).

1.9.5.3. Otoresif Hareketli Ortalama Modeli (ARMA(p,q))

Durağan zaman serilerinin modellenmesinde kullanılan ARMA modelleri, otoresif (AR) ve hareketli ortalama (MA) modellerinin bir birleşimidir. Bu modellerde bir zaman serisinin herhangi bir dönemine ait gözlem değeri, ondan önceki belirli sayıda gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade edilir. ARMA modeli p terimli AR ve q terimli MA modelinin bir kombinasyonu ise, $p + q$ terim içerir ve ARMA(p,q) şeklinde yazılır (Özmen, 1986).

$$\phi(B)X_t = \theta(B)e_t \quad (51)$$

Eşitlik (51) ile ARMA(p,q) serisi gösterilmiştir. Ortalaması μ olan bir zaman serisi, θ_q hareketli ortalama parametresi, ϕ otoresif parametresi $\phi \neq 0$ ve $\theta_q \neq 0$ olmak üzere Eşitlik (52) olarak yazılır.

$$(X_t - \mu) = \sum_{j=1}^p \phi_j(X_{t-j} - \mu) + e_t + \sum_{i=1}^q \theta_i e_{t-i} \quad (52)$$

Eğer, serinin ortalaması sıfır ise genellikle sıfır varsayımı ile ele alınır, sıfır olmadığı durumlarda ise;

$$Y_t = X_t - \mu \quad (53)$$

Eşitlik (53) ile sıfır ortalamalı seri elde edilir, bu serinin durağan olması durumunda geçerli olur. ARMA(p,q) serisi;

$$X_t = \sum_{j=1}^p \phi_j X_{t-j} + e_t + \sum_{i=1}^q \theta_i e_{t-i} \quad (54)$$

Eşitlik (54) ile hesaplanır. Bu durumda, verilen serinin otokovaryansını hesaplamak için Eşitlik (55) ile verilen fonksiyon yardımı ile hesaplanır. Eğer, $X_t \sim ARMA(p, q)$ serisi durağan bir seri ise,

$$\sum_{j=0}^{\infty} |\psi_j| < \infty \quad (55)$$

Eşitlik (55) yarımdayı olmak üzere,

$$X_t = \sum_{j=0}^{\infty} \psi_j e_{t-j} \quad (56)$$

Eşitlik (56) şeklinde yazılabilir ve dolayısıyla serinin otokovaryans fonksiyonu,

$$\gamma(h) = \sigma^2 \sum_{j=0}^{\infty} \psi_j \psi_{j+h} \quad (57)$$

Eşitlik (57)'de ki biçimine dönüşecektir (Akdi, 2003). Bu modelin durağan olması için otoregresif kesime ait olan $\phi_p(B) = 0$ denkleminin tüm köklerinin mutlak değerce 1'den büyük olması gerekir. AR ya da MA modelini kullanarak çok sayıda parametreyi gerektiren veriler, bir ARMA modeli kullanılarak sadece birkaç parametre ile modellenebilmektedir (Wei, 1990; Özek, 2010).

$$\gamma(h) = \phi_1 \gamma(h-1) + \dots + \phi_p \gamma(h-p), \quad h \geq q+1 \quad (58)$$

Eşitlik (58) ile ARMA(p,q) zaman serisi modelinin otokovaryans fonksiyonu verilmiştir. Buna bağlı olarak elde edilen otokorelasyon fonksiyonu Eşitlik (59) ile verilmiştir.

$$\rho(h) = \phi_1 \rho(h-1) + \dots + \phi_p \rho(h-p), \quad h \geq q+1 \quad (59)$$

ARMA(p,q) modelinin otokorelasyonları $h > q$ değerleri için AR(p) modelinin otokorelasyonları ile aynı olmaktadır (Akdi, 2003).

1.10. Bulanık Zaman Serisi

1965 yılında L. Zadeh tarafından ortaya atılmasından bu yana, bulanık küme teorisi temel olarak, doğal dillerle ifade edildiği gibi insan bilgisinin belirsizliği ile başa çıkmak için resmi, güçlü ve niceliksel bir çerçeve sağlamaktır. Bulanık zaman serisi yaklaşımı ilk olarak Song ve Chissom (1993a, 1993b) tarafından tanıtıldı. Yılın ilk gününden başlayıp son günü ile biten bir yerin havasının gözlemlendiğini varsayalım. Derece santigrat gibi sayısal değerler kullanmak yerine, dilsel değerleri, yani hava koşullarını tanımlamak için kullanılan günlük kelimelerle ifade edilirse; bu kelimeler iyi, çok iyi, oldukça iyi, serin, oldukça soğuk, sıcak, çok sıcak vb. olabilir. Sıcaklık zamanla değişebilen bir veridir ve insanlar bu kelimeleri kullanarak bir günü değerlendirebilir. Dikkat edilmesi gereken iki nokta vardır: farklı günlerde, sıcaklık aralıkları farklı olabilir; farklı günlerde, hava koşullarında kullanılan olası kelimeler farklı olabilir. Kış ve yaz aylarında sıcaklıklar farklı aralıklarda verilir. Her gün hava durumu ile ilgili gözlemleri dilsel değerler açısından kaydederseniz, elde edilen verilerden dilsel değerler veya bulanık anlamı olan bir seri oluşturabiliriz ve zaman değiştikçe, bu gözlem değerleri de değişebilir. Bulanık kümeler halinde, bu tür diziler doğadaki gözlemler gibi bulanık kümelere sahiptir. Açıkçası, bu tür bir dizi geleneksel zaman serilerinden tamamen farklıdır ve zaman serilerinde kullanılan hiçbir model burada uygulanamaz. Yeni bir dinamik süreçle karşılaşılır. Bu süreçte bulanık zaman serileri denir (Song ve Chissom, 1993b).

$U = \{u_1, u_2, \dots, u_b\}$, evrensel küme ve evrensel kümenin belirlenen bir sabit aralık uzunluğuna göre parçalanması ile elde edilen u_i 'ler alt aralıklar olmak üzere bulanık kümeler Eşitlik (60)'deki gibi tanımlanabilir.

$$A_i = f_{A_i}(u_1)/u_1 + \dots + f_{A_i}(u_b)/u_b \quad (60)$$

Burada f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonu olduğunu gösterir, $f_{A_i}: U \rightarrow [0,1]$ olmaktadır. Burada, $f_{A_i}(u_a)$ ise u_a alt aralığının A_i 'ye ait olmasının üyelik derecesidir. $1 \leq a \leq b$, olmak üzere $f_{A_i}(u_a) \in [0,1]$ olacaktır.

Tanım 1: $Y(t)$ 'nin ($t = \dots, 0, 1, 2, \dots$) reel değerli zaman serisi olsun. Zaman serisine uygun evrensel küme tanımı yapıp ve alt aralıkları belirlendikten sonra A_i bulanık kümelerinden oluşan yeni seri, $F(t)$ bulanık zaman serisi olarak adlandırılır.

$F(t)$ bulanık zaman serisi, Tanım 1'e bakılarak aşağıdakiler söylenebilir;

- i. $F(t)$ bir dilsel değişken olarak tanımlanabilir ve olası dilsel değerlere sahip olarak ifade edilebilir.
- ii. $F(t)$ t zamanının bir fonksiyonudur. Ayrıca, söylem evrenleri farklı zamanlarda farklı olabileceğinden, t zamanında evren için $Y(t)$ kullanırız.

Tanım 2: “*” herhangi bir operatörü göstermek üzere, bulanık zaman serisi ilişkileri, $F(t)$ 'nin sadece $F(t - 1)$ 'den etkilendiğini varsayarsak, ilişki Eşitlik (61)'deki gibi ifade edilebilir.

$$F(t) = F(t - 1) * R(t, t - 1) \quad (61)$$

Birinci dereceden bulanık zaman serisi tahmin modeli olarak isimlendirilir. Song ve Chissom (1993a) tarafından Eşitlik (62) ve (63)'da ki gibi tanımlanmıştır.

$$f_i(t - 1) \rightarrow f_i(t) \quad (62)$$

$$F(t - 1) \rightarrow F(t) \quad (63)$$

$F(t - 1) = A_i$ ve $F(t) = A_j$ olsun. $F(t)$ ile $F(t - 1)$ arasındaki bulanık zaman serisi arasındaki bulanık ilişki,

$$A_i \rightarrow A_j \quad (64)$$

Eşitlik (64)'deki gibi olacaktır. Bu durumda A_i bulanık ilişkinin sol tarafı, A_j ise bulanık ilişkinin sağ tarafına karşılık gelir. Ayrıca, bulanık ilişkiler farklı bulanık ilişki kurmak için gruplandırılabilir.

Tanım 3: $F(t)$ bulanık zaman serisi olsun. Eğer $F(t - 1), F(t - 2), \dots, F(t - n)$, $F(t)$ 'e neden oluyorsa;

$$F(t - n), \dots, F(t - 2), F(t - 1) \rightarrow F(t) \quad (65)$$

bulanık mantık ilişkisi Eşitlik (65)'de verilen ifadeye n .dereceden bulanık zaman serisi öngörü modeli denilmektedir.



2. YAPILAN ÇALIŞMALAR

Bulanık mantık yöntemi modellemede, insan düşünme ve karar verme özelliğini kullanan kural tabanlı bir yöntemdir. Yapay sinir ağları ise öğrenme yeteneğini kullanarak problemi öğrenmekte ve daha önceden karşılaşmadığı veri setleri için başarılı bir şekilde sonuca ulaşmaktadır. Bulanık mantık ve yapay sinir ağları yöntemlerinin birleşiminden oluşan Sinirsel Bulanık Mantık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System-ANFIS) bir modelleme yöntemi olarak önerilmekte ve kullanılmaya başlanmaktadır (Fırat, 2007).

Bununla birlikte, dilsel olarak oluşturulan kontrol stratejisinin kendi başına beklenenden çok daha iyi olduğu yapılan çalışmalar ile ortaya konmuştur. Bulanık sistemin kontrol ve tahmin uygulamalarındaki uygulamalarında, temel olarak iki yaklaşım vardır; bunlardan ilki Mamdani yaklaşımı, diğeri Takagi-Sugeno yaklaşımıdır (Nayak, Sudheer ve Ramasastry, 2005).

2.1. Sinirsel Bulanık Mantık Çıkarım Sistemi (ANFIS)

Jang (1993), Uyarlanabilir ağlar çerçevesinde uygulanan bulanık bir çıkarım sistemi olan ANFIS'in (Sinirsel Bulanık Mantık Çıkarım Sistemi) temelindeki mimari ve öğrenme prosedürünü sunmuştur. Bir hibrit (melez) öğrenme prosedürü kullanarak, önerilen ANFIS, hem insan bilgisine (EĞER- İSE; bulanık biçiminde) hem de öngörülen girdi-çıkı veri çiftlerine dayalı bir girdi-çıkı eşleşmesi oluşturabilir. ANFIS mimarisi doğrusal olmayan fonksiyonları modellemek, bir kontrol sisteminde doğrusal olmayan bileşenleri çevrimiçi olarak tanımlamak ve tümü dikkate değer sonuçlar veren kaotik bir zaman serisini tahmin etmek için kullanılır.

ANFIS, uyarlanabilir bir ağ olan düğümlerin bağlandığı düğümlerden ve yön bağlantılarından oluşan bir ağ yapısıdır. Dahası, düğümlerin bir kısmı veya tamamı uyarlanabilir, bu da çıktıların bu düğümlerle ilgili parametrelere bağlı olduğu anlamına gelir ve öğrenme kuralı öngörülen bir hata ölçüsünü en aza indirmek için bu parametrelerin nasıl değiştirilmesi gerektiğini belirtir.

ANFIS, her düğümün gelen sinyaller üzerinde belirli bir fonksiyonu (düğüm fonksiyonu) ve bu düğümüne ilişkin bir dizi parametre gerçekleştirdiği, çok katmanlı bir besleme ağıdır. Düğüm işlevleri için formüller düğümden düğümüne değişebilir ve her düğüm fonksiyonunun seçimi, adaptif ağın gerçekleştirmesi için gereken genel giriş-çıkış fonksiyonuna bağlıdır. Uyarlanabilir bir ağdaki bağlantıların sadece düğümler arasındaki sinyallerin akış yönünü gösterdiği unutulmamalıdır. Farklı adaptif yetenekleri yansıtmak için, adaptif bir ağda hem daire hem de kare düğümleri kullanılır. Bir kare düğüm (uyarlamalı düğüm) parametrelere sahipken, bir daire düğümü (sabit düğüm) hiçbirini içermemektedir. Bir adaptif ağın parametre seti, her bir adaptif düğümün parametre setlerinin birleşimidir. İstenilen bir girdi-çıkış eşleşmesini elde etmek için, bu parametreler verilen eğitim verilerine öğrenme prosedürüne göre güncellenir.

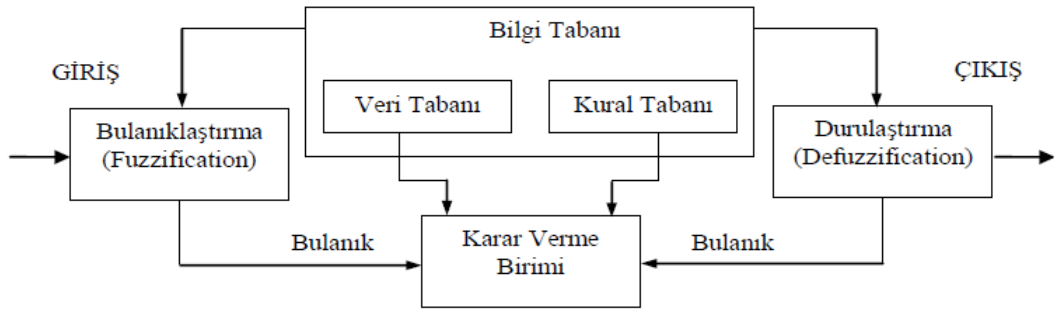
2.2. Bulanık Mantık Çıkarım Sistemleri

Genel olarak bulanık mantık çıkarım sistemi (Fuzzy Logic Inference System- FIS) olarak bilinen bulanık modellemenin temel yapısı, üç kavramdan oluşan *kural tabanlı* veya *bilgi tabanlı* bir sistemdir. Bulanık EĞER-İSE (IF-THEN) kuralları koleksiyonundan oluşan bir kural tabanı; bulanık kurallarda kullanılan üyelik fonksiyonunu (Membership Function- MF) tanımlayan bir veritabanı ve makul bir çıktı sonucu çıkarmak için bu kuralları girdilerden sistemin çıktılara kadar bir haritalama yordamına birleştiren bir muhakeme mekanizmasıdır (Şekil 5, Fırat, 2007).

FIS, giriş olarak bulanık kümeleri veya net değerleri alabilir, ancak toplam çıktılar her zaman bulanık kümelerdir. Bu nedenle, bulanık kümesi kesin bir değere dönüştürmek için bir “durulaştırma (defuzzification)” stratejisi gerekir. EĞER-İSE kurallarının giriş (öncül veya giriş terimleri) parametreleri, giriş boşluğunun bulanık bir bölgesini tanımlar ve çıkış parametreleri (sonucu veya çıkış terimleri) karşılık gelen çıktıyı belirtir. Bu nedenle, FIS’in etkinliği, hesaplama için kullanılan bulanık EĞER-İSE kurallarının sayısına bağlıdır. Bulanık teorinin uygulaması “fuzzification, mantık kararı ve defuzzification” üç adımı içerir. Bulanıklaştırma (Fuzzification), giriş değişkenlerinin ve kontrol değişkeninin (çıkış) tanımlanmasını, hem girişin hem de kontrol değişkeninin farklı alanlara bölünmesini ve bir üyelik fonksiyonunun seçilmesini içerir. Mantık kararı, EĞER-İSE kuralının tasarımını ve çıktı bulanık kümesinin belirlenmesini içerir. Durulaştırma

(Defuzzification), EĞER-İSE çıkarım sisteminin bulanık çıkışlarından kesin çıktıların belirlenmesini içerir. Giriş ve kontrol değişkeninin bölünmesi genellikle denetlenmemiş bir kümeleme algoritması kullanılarak yapılır (Nayak, Sudheer ve Ramasastri, 2005).

Bulanık çıkarım sistemleri, EĞER-İSE kurallarıyla dilsel etiketler kullanılarak bir sistemin girdi ve çıktı değişkenleri arasındaki bağıntıyı tanımlar. Birçok dereceli sistem model yapısı arasından Takagi-Sugeno, Mamdani vb. modeller geniş çapta kullanılan yaklaşımlar olarak bilinmektedir (Türkşen, 2015).



Şekil 5. Bulanık mantık çıkarım sisteminin genel yapısı

Bulanık çıkarım sistemleri, denetleyici olarak kullanıldığında bulanık kural tabanlı sistemler, bulanık modeller, bulanık ilişkisel veya bulanık denetleyiciler olarak da bilinir.

Genellikle, kural tabanı ve veritabanı ortaklaşa bilgi tabanı olarak adlandırılır. Temel olarak bulanık bir çıkarım sistemi, beş işlevsel kısımdan oluşur (Jang, 1993). Bulanık mantık yürütme (EĞER-İSE bulanık kurallar üzerine çıkarım işlemleri) bulanık çıkarım sistemleri tarafından gerçekleştirilen aşamalar;

- i. Giriş-çıkış üyelik değerlerinin belirlenmesi ve bulanıklaştırılması (Fuzzification),
- ii. Bulanık kuralın yazılması (Rule Base),
- iii. Yazılı bulanık kuralların değerlendirilmesi (Implication),
- iv. Bulanık kuralların toplanması ve derlenmesi (Aggregation),
- v. Sistem çıkışının elde edilmesi ve Durulaştırma (Defuzzification) şeklinde ifade edilebilir (Fırat, 2007).

2.3. Bulanık Kural Tabanı

Bulanık EĞER-İSE kuralları veya bulanık koşullu ifadeler, A ve B'nin etiket olduğu; "EĞERA İSE B" formunun ifadeleridir. Uygun üyelik fonksiyonları ile karakterize edilmiş bulanık kümelerin, kısa ve özlü formları nedeniyle, belirsiz ve belirsiz bir ortamda karar verebilme yeteneğinde önemli bir rol oynayan, belirsiz akıl yürütme biçimlerini yakalamak için sık sık bulanık kurallar kullanılır. "Eğer basınç yüksek, ise hacim küçüktür", basınç ve hacmin dilsel değişkenler, yüksek ve küçük dilsel değerler veya üyelik işlevleriyle karakterize edilen etiketlerdir. Giriş kısımda yüksek olanın dilsel bir etiket olduğu yer uygun bir üyelik fonksiyonu ile karakterize edilir. Bununla birlikte, sonuçta ortaya çıkan kısım, giriş değişkenin bulanık olmayan bir denklemi ile açıklanmaktadır (Jang, 1993). Eşitlik (66) ile verilmiştir.

$$EĞER (\text{öncül- giriş terimleri}), İSE (\text{sonuç-çıkış terimleri}) \quad (66)$$

Mamdani bulanık çıkarım sistemi modeli Eşitlik (67)'de ki gibi yazılabilir (Fırat, 2007).

$$EĞER x_1 = A_1 VE/VEYA x_2 = A_2 İSE y_1 = B_1 \quad (67)$$


Bir başka açıdan, giriş kısımlardaki niteleyiciler nedeniyle, her bir bulanık EĞER-İSE kuralı, ele alınan sistemin yerel bir açıklaması olarak görülebilir (Jang, 1993).

2.3.1. Sinirsel Bulanık Mantık Sistem Yapısı

ANFIS, Yapay sinir ağlarının eğitime yeteneğini kullanarak, eğitim veri seti kümesinden bulanık küme kuralları belirlemekte ve kural tabanlı bir modelleme gerçekleştirmektedir.

Bulanık çıkarım sisteminin iki giriş (x ve y) ve bir çıkışa (z) sahip olduğunu varsayalım. Kural tabanının Takagi ve Sugeno'nun türünün o zamana göre belirsiz iki kural içerdiğini varsayalım (Jang, 1993). İki girişe sahip bir Sugeno bulanık mantık çıkarım sisteminin grafiksel yapısı Şekil 6'da gösterilmiştir ve Eşitlik (68) ile formülü

verilmiştir.(Elmas, 2018). Eşitlik ile verilen; $\{\mu_1, \mu_2\}$ üyelik fonksiyonlarını, $\{p_{1,2}, q_{1,2}, r_{1,2}\}$ bulanık çıkarım sisteminin çıkış parametreleridir ve $\{f\}$ ise modelin çıktısını ifade etmektedir.



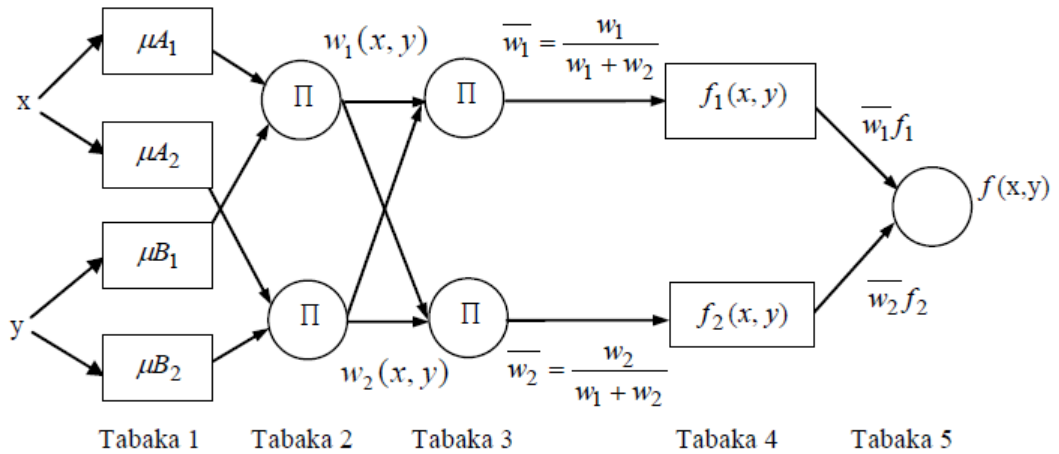
Şekil 6. İki girişli bir Sugeno bulanık mantık çıkarım sistemi

$$f_1 = p_1x + q_1y + r_1$$

$$f_2 = p_2x + q_2y + r_2$$

(68)

$$f = \frac{\mu_1 f_1 + \mu_2 f_2}{\mu_1 + \mu_2} = \bar{\mu}_1 f_1 + \bar{\mu}_2 f_2$$



Şekil 7. İki girişli bir Sugeno bulanık mantık çıkarım sistemi mimarisini

Şekil 7 ile verilen model iki girişli bir Sugeno bulanık mantık çıkarım sisteminin mimari yapısını göstermektedir (Jang, 1993). Sugeno'nun tipinde iki girişli bir model için

Eşitlik (69) ve (70) ile EĞER-İSE kurallar denklemi yazılabilir. $\{A_{1,2}, B_{1,2}\}$ dilsel değerler veya üyelik işlevleriyle karakterize edilen etiketlerdir, $\{p_{1,2}, q_{1,2}, r_{1,2}\}$ bulanık çıkarım sistemi çıkış parametrelerini ifade eder.

$$\text{Eğer } x = A_1 \text{ ve } y = B_1, \quad \text{ise } f_1 = p_1x + q_1y + r_1, \quad (69)$$

$$\text{Eğer } x = A_2 \text{ ve } y = B_2, \quad \text{ise } f_2 = p_2x + q_2y + r_2. \quad (70)$$

Tabaka 1 (Giriş düğümü): Bu tabakadaki her bir düğüm, giriş değişkenlerinin üyelik fonksiyonlarını meydana getirir ve her bir düğüm çıkışı denklemi Eşitlik (71) ile hesaplanır.

$$O_i^1 = \mu_{A_i}(x) \quad (71)$$

Burada x , i düğümüne girdidir ve A_i , bu düğüm fonksiyonuyla ilişkili dilsel etikettir (küçük, büyük vb.). Başka bir deyişle; O_i^1 , A_i 'nin üyelik fonksiyonudur. Verilen x 'in niceleyiciyi A_i 'nin ne kadar yerine getirdiğini belirtir. Genellikle $\mu_A(x)$ 'i maksimum olarak 1'e eşit ve minimum 0'a eşit olacak şekilde çan şeklinde seçeriz. Eşitlik (72) yardımıyla hesaplanır.

$$O_i^1 = \mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (72)$$

$$O_i^1 = \mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\}$$

$\{a_i, b_i, c_i\}$ Çan şeklinde üyelik fonksiyonun parametreleridir. Bu parametrelerin değerleri değiştiğinde, çan şeklindeki fonksiyonlar buna göre değişir. Bu durumda dilsel etiket A_i üzerinde çeşitli üyelik fonksiyonlarını gösterir. Bu katmandaki parametrelere giriş (öncül) parametreler denir.

Tabaka 2 (Kural düğümü): Bu katmandaki her bir düğüm genelleştirilmiş “ve/veya” işlemcileri kullanılarak Π ile gösterilen giriş sinyalleri çarpılır ve ateşleme kuvveti olarak tanımlanan düğüm çıktısı elde edilir. Çıkış ateşleme kuvveti $\{w_i\}$ ile ifade edilir. Denklem Eşitlik (73)'deki gibi hesaplanır;

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1,2. \quad (73)$$

Tabaka 3 (Ortalama Dügüm): Bu tabakada her bir düğümden elde edilen ateşleme kuvvetleri toplanır ve Eşitlik (74) ile hesaplar;

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2. \quad (74)$$

Tabaka 4: Bu katmandaki her bir düğümün model çıktısı üzerindeki katkısı Eşitlik (75) yardımıyla hesaplanır. Burada, \bar{w}_i , tabaka 3'ün çıktısıdır ve $\{p_i, q_i, r_i\}$ bulanık çıkarım sisteminin çıkış parametreleridir.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (75)$$

Tabaka 5 (Çıkış Dügümü): Sinirsel çıkarım sisteminin son adımını oluşturur ve çıkış tabakası olarak adlandırılır. Bu tabakada, ANFIS'in genel çıkışı hesaplanır ve durulaştırma işlemi ile bulanık değerden kesin değere dönüştürülür. Eşitlik (76) ile hesaplanır;

$$O_i^5 = \text{genel çıktı} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (76)$$

ANFIS'in eğitiminde denetimli öğrenme ve ileri beslemeli sinir ağı kullanılır. Eşitlikler ile verilen fonksiyonlar yardımıyla, yukarıda belirtilen "tabaka"ların en uygun değerleri adım adım belirlenir.

2.3.2. Mamdani Modeli

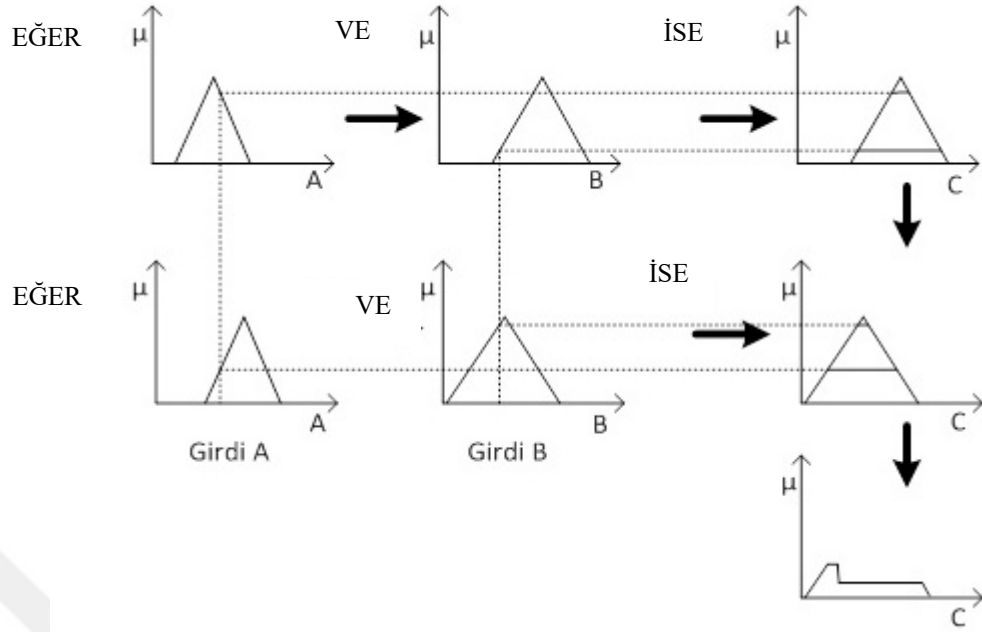
Mamdani modeli bulanık mantık sistemlerinden en çok kullanılan ve uygulanan yöntem olarak karşımıza çıkmaktadır. Ebrahim Mamdani (1974) tarafından ortaya konmuş, Mamdani bulanık çıkarım sistemi Zadeh'in (1965) bulanık mantığı, dilbilimsel kuralları tutarlı bir kontrol stratejisinde birleştirebilecekleri biçimde ifade etmenin bir yolunu sağlamıştır.

Mamdani modeli, bulanık mantıkla bir insan operatörü tarafından belirtilen sezgisel kontrol kurallarını otomatik kontrol stratejisine dönüştürmek için kullanılır. Bir öğrenme denetçisi ile insan etkileşimi olasılığını araştırmak için ortaya atılan bir yöntemdir. Mamdani bulanık çıkarım sistemi aşağıdaki işlem adımlarını içerir.

Bulanıklaştırma (Fuzzification); bulanık mantık ile modellemenin birinci aşaması olup, kesin değerlerin bulanık değerlere dönüştürülmesi olarak ifade edilmektedir. Giriş-çıkış değişkenleri ve yapıları bulanık mantık çıkarım sisteminin temelini meydana getirmektedir. Çünkü seçilen bu giriş yapısı, bulanık kuralları, ağırlıkları, model yapısını ve model sonuçlarını etkilemektedir. Giriş ve çıkış değişkenleri, bulanık küme içerisinde üyelik değerlerini belirlemek için [0,1] arasında bulanıklaştırılır. Bunun için, klasik küme teorisinden farklı olarak, bulanık mantık çıkarım sisteminde üyelik fonksiyonları tanımlanır ve her bir değişkenin derecesi belirlenir (Fırat, 2007). Bulanıklaştırma işlemi, Eşitlik (77) ile hesaplanır (Mamdani, 1974).

$$A = \sum_{i=1}^n \mu_A(u_i)/u_i = \sum_i \mu_A(u_i) \quad (77)$$

Kural tabanı, bulanık parametreler yardımıyla bulanık “giriş, çıkışlar” arasındaki ilişkinin ortaya konulduğu işlemidir. İkinci adım olarak bulanık mantık ile modellemede kuralların oluşturulmasıdır. “Giriş” ve “çıkış” değişkenlerinin üyelik fonksiyonları ile ilgili kavramsal terimlerden oluşur. Bu terimler, EĞER-İSE kuralları ile birbiriyle ilişkilendirilir. Modellemelerde esnasında kullanılan bulanık mantık parametreleri “ve” ve “veya”dır. Bunlar, “en büyükleme” ve “en küçükleme” şeklindedir. Giriş ve çıkış parametrelerine bağlı olarak yazılan kurallar yardımı ile sonuç değerini elde etmek için çıkarım işlemi adımdır. Buradaki kurallar çıkarım (Implication) olarak bilinen bu adımla üyelik fonksiyon oranları değerlendirilir. Çıkarım kümeleri, kuralların toplanması (Aggregation), işlemi ile bir küme olarak birleştirilir. Çıkarım kümeleri birlikte toplanırsa bu duruma toplama (Summation) fonksiyonu” olarak tanımlanır (Fırat, 2007).




Şekil 8. Mamdani bulanık çıkarım sistemi

Durulaştırma (Defuzzification), bulanık mantık ile modellemenin son adımıdır ve çıkarım işleminden elde edilen bulanık sonuçlar durulaştırılmış (gerçek) sonuçlara dönüştürülmesi gerekmektedir. Durulaştırma olarak tanımlanan işlemde kesin değerlere dönüştürülür. Şekil 8 ile Mamdani modeli çıkarım sistemi grafiksel olarak sunulmuştur (URL-2, 2019). Literatürde ağırlık merkezi yöntemi, en çok kullanılan durulaştırma yöntemidir (Fırat, 2007). Bulanık çıkış terimlerinin merkezleri ve bu merkezlerdeki üyelik derecelerinin birleşimi olarak tanımlanır ve Eşitlik (78) ile verilmiştir (Nayak, Sudheer ve Ramasastri, 2005).

$$X^* = \frac{\sum_{i=1}^N X_i \mu_A(X_i)}{\sum_{i=1}^N \mu_A(X_i)} \quad (78)$$

Şekil 9'de durulaştırma işleminde en çok kullanılan yöntemler verilmektedir (Fırat, 2007).



Şekil 9. Durulaştırma işleminde kullanılan yöntemler

2.3.3. Takagi-Sugeno-Kang Modeli

Bir sistemin bulanık modelini oluşturmak için matematiksel bir araç gerekmektedir. Bulanık kontrol ile ilgili kontrol kurallarını ifade etmek için bulanık etkilerin kullanıldığı bulanık kontrol konusunda çok sayıda çalışma yapılmıştır ve elde edilen sonuçların çoğu, dilsel olarak anlaşılabilir ve dolayısıyla dilsel değişkenler olarak adlandırıldığından, tekdüze üyelik işlevlerine sahip bulanık değişkenler içerir. Bununla birlikte, bu tür bir mantık yürütmeyi çok değişkenli kontrol için tekdüze bulanık değişkenlerle birlikte kullanıldığı zaman, birçok bulanık değişkene ihtiyaç duyulur. Sugeno bulanık mantık çıkarım sistemi veya Takagi-Sugeno-Kang yöntemi 1985 yılında bulanık bir uygulamanın iyileştirildiği ve mantığın basitleştirildiği bir çalışma geliştirilmiştir.

Bulanık kurallar girdi ve çıktı verileriyle model oluşturma iki şeyle karakterize edilir; bunlardan biri sistem modelini ifade eden matematiksel bir araçtır, diğeri ise tanımlama yöntemidir. Giriş alanının bulanık bir bölümüne dayanır. Her bulanık alt-alanda, doğrusal bir “girdi-çıkı” ilişkisi oluşur. Bulanık mantığın çıktısı, bir girdiye uygulanan bazı çıkarımlar tarafından çıkarılan değerlerin toplanmasıyla verilir. Bulanık çıkarım sisteminde tanımlama iki bölüme ayrılmıştır: yapı tanımlama ve parametre tanımlamadır (Takagi ve Sugeno, 1985).

Bu mantık çıkarım sisteminde, girişlerin bulanıklaştırılması Mamdani bulanık çıkarım sistemine benzemektedir. Sugeno yönteminin, Mamdani bulanık çıkarımdan farkı “çıkış üyelik fonksiyonlarının tanımlanması” ve “kuralların yazılmasıdır”. Sugeno çıkarım yönteminde çıkış değişkeni ya “sabit bir katsayı” ya da giriş değişkenlerine bağlı bir “polinom fonksiyon” olarak tanımlanmaktadır. Sugeno bulanık mantık çıkarım sisteminde

Mamdani çıkarım sistemine göre kural sayısı azdır. Başka bir deyişle, karmaşık problemlerin çözümünde büyük fayda sağlamaktadır (Fırat, 2007).

Burada A ve B , x ve y giriş (öncül) değişkendir. z 'nin sonucu çıkarılan sonucun değişkenidir. Uygulanabileceği bir bulanık alt alanı temsil eden doğrusal üyelik fonksiyonlarına sahiptir. Bulanık küme mantıksal işlemleri (ve, veya) bağlayıcıları kullanılır.

İki tip Sugeno bulanık çıkarım modeli kullanılmaktadır. Eğer çıkış değişkeni bir katsayı şeklinde tanımlanırsa bu tip modele “*Sıfıncı Dereceden Sugeno Model*”, eğer çıkış değişkeni giriş değişkenlerine bağlı bir polinom fonksiyon şeklinde tanımlanırsa bu tip model “*Birinci Dereceden Sugeno Model*” olarak adlandırılır. Sıfıncı dereceden Sugeno model denklemi Eşitlik (79)'daki gibi ifade edilebilir. Üyelik fonksiyonu sabit bir değer olarak verilir (Fırat, 2007).

$$\text{Eğer } x = A \text{ ve } y = B, \text{ ise } z = r \quad (79)$$

Birinci dereceden Sugeno modeli Eşitlik (80)'deki gibi tanımlanır (Takagi ve Sugeno, 1985).

$$\text{Eğer } x = A \text{ ve } y = B, \text{ ise } z = f(x, y) = px + qy + r \quad (80)$$

Eşitlik (80)'de verilen değişkenler aşağıdaki maddelerle açıklanmaktadır.

- i. x, y etki alanlarını oluşturan değişkenler.
- ii. A, B bulanık kümelerin tesis içindeki üyelik fonksiyonları, giriş parametreler olarak kısaltılmıştır.
- iii. p, q sonuç parametreleridir.

2.3.3.1. Takagi-Sugeno-Kang Modeli Kural Tabanı ve Adımları

Uygulanan ve incelenen bulanık mantık çıkarım sistemlerinden en yaygın olarak kullanılan Sugeno bulanık mantık çıkarım sistemidir. Sugeno dereceli kural tabanında bir kural giriş parçası toplama operatörü ile, sonuç ise regresyon doğrusu ile nitelendirilir. Sugeno modeli kural tabanı Eşitlik (81) ile verilmiştir (Takagi ve Sugeno, 1985).

$$R: VEYA_{i=1}^c [EĞER VE_{j=1}^{nv} (x_j \in X_j = A_i^j) İSE y_i = a_i x^T + b_i] \quad (81)$$

- i. a_i ve b_i , i 'nci kural ile ilişkili regresyon doğrusu katsayılarını
- ii. y_i , i 'nci kural R_i 'nin model çıktısını
- iii. İSE, her kuraldan model çıktısı elde etmek için verilen bir gözlemin ilgili ateşleme derecesini kullanarak her bir kural için y_i 'yi ağırlıklandırarak bağlacı
- iv. Veya, dereceli kuralların model çıktılarını birleştirmek için her bir kuralın model çıktısının ağırlıklı ortalamasını alan bağlacı

göstermektedir. Sugeno bulanık mantık çıkarım sistemi parametreleri; c , her bir kuraldaki her bir girdi değişkenin üyelik fonksiyonu, her bir kural için regresyon katsayıları, çıkarım yönetiminde kullanılan VE, İSE ve VEYA bağlaçlarıdır. $X_j, x_j (j = 1, \dots, nv)$ 'nin tanım kümesi olsun. $A_j, \mu_i(x_j): X_j \rightarrow [0,1]$ üyelik fonksiyonu ile gösterilen i kuralındaki x_j girdi değişkeni ile ilişkili üyelik fonksiyonunu ifade etmektedir. Bulanık kural tabanındaki kuralların sayısı c , tanımlanmış sistemdeki niteliklerin girdi boyutlarının sayısı nv ile gösterilmektedir (Türkşen, 2015). Sugeno bulanık mantık çıkarım sistemi aşağıdaki işlem adımlarını içerir.

Bulanıklaştırma; bulanıklaştırma, her bir i kuralında her dereceli A_i^j , kümesi için her yeni x' veri vektörüne üyelik değeri verilir (Türkşen, 2015);

$$\mu_i(x'_j), \quad \forall i = 1 \dots c, \quad \forall j = 1 \dots nv \quad (82)$$

Eşitlik (82) ile gösterilir (Takagi ve Sugeno, 1985).

Girişlerin Birleştirilmesi (Aggregation of Antecedents); bulanıklaştırma adımında elde edilen üyelik değerleri, üyelik değeri elde etmek için birleştirilir. Birleştirme işlemi, dereceli operatörler kullanılarak gerçekleştirilir, yeni x' girdi terimlerinin i kuralında üyelik fonksiyonları (Türkşen, 2015) Eşitlik (83) ile hesaplanır (Takagi ve Sugeno, 1985).

$$\mu_i(x'_j) = VE_{j=1}^{nv} \mu_i(x'_j), \quad \forall i = 1 \dots c, \forall j = 1 \dots c \quad (83)$$

Çıkarım; dereceli kural tabanlı yapının ardıl kısmının nasıl tanımlandığına bağlı olarak belirlenir. Sugeno tipi dereceli bulanık kural tabanlarında bu adım sadece her kuralın sayısal model çıktısını ağırlıklandırmak için kullanılır (Türkşen, 2015). Bu nedenle, i . kuralın y_i^* model çıktısı Eşitlik (84) yardımı ile ağırlıklandırılır (Takagi ve Sugeno, 1985).

$$y_i^* = \mu_i(x') \times y_i, \quad \forall i = 1 \dots c \quad (84)$$

Model çıktısının birleştirilmesi (Aggregation of the model output); Bu adım aynı zamanda kural tabanının sonuç yapısına da bağlıdır. Sugeno dereceli kural tabanlı yapılarda her bir kuralın model çıktısı Eşitlik (85)'deki gibi (Takagi ve Sugeno, 1985) dereceli kural tabanında her kuralın sayısal çıktısının ağırlıklı ortalamasının alınmasıyla birleştirilir (Türkşen, 2015).

$$y^* = \frac{\sum_{i=1}^c y_i^*}{\sum_{i=1}^c \mu_i(x')}, \quad \forall i = 1 \dots c \quad (85)$$

Durulaştırma; çıktı değişkeninin evrensel kümesindeki dereceli kümeyi klasik bir değere indirgenmek için kullanılır. Bu adım, dereceli kümeleri kuralların ardıl kısmında tanımlayan dereceli çıkarsama sistemleri için gereklidir (Türkşen, 2015).

2.4. Üyelik Fonksiyonları

Bu çalışmada bulanık mantık yaklaşımının uygulanması için MATLAB programı kullanılmıştır. Literatür kısmında bahsedilen ve “üyelik fonksiyonları” başlığı altında üyelik fonksiyonlarına yer verilmiştir. Tablo 2’de MATLAB programında ANFIS altında tanımlı olarak verilen üyelik fonksiyonları programda yer alan isim ve formüllerine gösterilmiştir (URL-3, 2019). Bulanık mantık modelinde hangi üyelik fonksiyonunun veri kümesine daha uygun olduğu genellikle deneme yanılma yöntemiyle karar verilir.

Tablo 2. Matlab üyelik fonksiyonları

Matlab Üyelik Fonksiyonları	Üyelik Fonksiyonları
Trimf	Üçgen Üyelik Fonksiyonu
Trapmf	Yamuk Üyelik Fonksiyonu
Gbellmf	Çan Şekilli Üyelik Fonksiyonu
Gaussmf	Gauss Üyelik Fonksiyonu
gauss2mf	Gauss Üyelik Fonksiyonu (tam simetrik)
Pimf	Π Üyelik Fonksiyonu
Dsigmf	Sigmoidial Üyelik Fonksiyonu (tam simetrik)
Psigmf	Sigmoidial Üyelik Fonksiyonu

2.4.1. Üçgen (Trimf) Üyelik Fonksiyonu

En çok tercih edilen üyelik fonksiyonu, içerdiği az sayıda parametre ve işlem kolaylığı bakımından üçgen üyelik fonksiyonudur. Bu üyelik fonksiyonu $a < b < c$ koşuluna uyan (a, b, c) üç parametreye sahiptir. Eşitlik (86)'da ki formül ile ifade edilmektedir (Şen, 2010).

$$f(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x - a}{b - a}, & a \leq x \leq b \\ \frac{c - x}{c - b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (86)$$

$$f(x; a, b, c) = \max \left(\min \left(\frac{x - a}{b - a}, \frac{c - x}{c - b} \right), 0 \right)$$

2.4.2. Yamuk (Trapmf) Üyelik Fonksiyonu

Fonksiyon $a \leq b \leq c \leq d$ koşuluna sahip (a, b, c, d) dört parametreye sahiptir. Yamuk üyelik fonksiyonu Eşitlik (87)'deki gibi ifade edilmektedir (Bede, 2013).

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (87)$$

$$f(x; a, b, c, d) = \max \left(\min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right)$$

2.4.3. Çan Şekli (Gbellmf) Üyelik Fonksiyonu

Bu fonksiyonun şekli çan eğrisine benzediğinden bu isimi almıştır. Fonksiyon tüm noktalarda pozitif bir değere sahiptir ve simetrik bir şekli vardır. Fonksiyon üç adet parametreye (a , b , c) sahiptir. Eşitlik (88)'de fonksiyonun gösterimi verilmiştir. Bu parametrelerden a eğrinin genişliğini, c ise eğrinin merkezini belirlemektedir (Zhao ve Bose, 2002; Özdaş 2015).

$$f(x; a, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (88)$$

2.4.4. Gauss (Gaussmf) Üyelik Fonksiyonu

Üyelik fonksiyonu grafiğın genişliğini belirleyen, grafiğın merkezini ve parametrelerine sahiptir. Eşitlik (89)'da fonksiyonun gösterimi verilmiştir (Güner ve Çomak, 2014; Özdaş 2015).

$$f(x; \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (89)$$

2.4.5. Sigmoidial (Psigmf) Üyelik Fonksiyonu

a ve c olarak iki parametreye sahiptir. Bu parametrelerden a şeklin sağa ya da sola açık olmasını belirler. Eşitlik (90)'da verilen formül yardımıyla elde edilir. Sigmoid üyelik

fonksiyonu “çok geniş” veya “çok negatif” ve benzeri gibi kavramları göstermek için uygundur (Şen, 2010).

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (90)$$

2.4.6. Diğer Üyelik Fonksiyonları

Diğer üyelik fonksiyonlarına ait Eşitlikler aşağıda verilmiştir.

Gauss (Gauss2mf) Üyelik Fonksiyonu (Tam Simetrik);

$$f(x; \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (91)$$

Π (*Pimf*) Üyelik Fonksiyonu;

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - 2 \left(\frac{x-c}{d-c} \right)^2, & c \leq x \leq \frac{c+d}{2} \\ 2 \left(\frac{x-d}{d-c} \right)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & x \geq d \end{cases} \quad (92)$$

Sigmoidal (Dsigmf) Üyelik Fonksiyonu (Tam Simetrik);

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (93)$$

2.5. Kullanılan Başarı Ölçütleri

Tahmini yapılan modelin etkinliğinin ölçülmesi konusunda, sayısal öngörüleme için yapay zekâ uygulamalarında kullanılan farklı performans ölçütleri vardır. Hata kareleri ortalamasının karekökü (RMSE- Root Mean Square Error) hesaplamasında, p_n mevcut değeri gösterirken a_n kurulan model ile tahmin edilen değeri, n ise toplam gözlem sayısını yansıtmaktadır. Mutlak hata yüzdeleri ortalaması hesaplamasında (MAPE- Mean Absolute Percentage Error), p_j mevcut değeri gösterirken a_j kurulan model ile tahmin edilen değeri, n ise toplam gözlem sayısını yansıtmaktadır. Bu performans ölçütlerinden RMSE sinirsel ağların performansını belirlemek için kullanılan önemli ifadelerden biridir. Tablo 3'te RMSE ve MAPE değerlerinin formülüne yer verilmiştir (Jequirim vd., 2009; Yücel, 2010).

Tablo 3. RMSE ve MAPE hesaplama formülleri

Performans Ölçütü	Formül
Hata Kareleri Ortalamasının Karekökü (RMSE)	$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}}$
Ortalama Mutlak Yüzde Hata (MAPE)	$\frac{1}{n} \sum_j \left \frac{p_j - a_j}{p_j} \right * 100$

2.6. Uygulama

Bu çalışmada, Endüstri 4.0 teknolojisini kullanılan bir fabrikanın üretim hattından sensör yardımı ile alınan zaman serisi verilerine klasik zaman serisi modeli ile bulanık zaman serisi modeli uygulanacak ve bu iki modelin hangisinin daha iyi sonuç vereceği RMSE ve MAPE ölçütlerine göre kıyaslanacaktır. Bunun yanı sıra, bulanık zaman serisinin üyelik fonksiyonları RMSE ve MAPE değerlerine bakılarak veri seti için en iyi üyelik fonksiyonu belirlenecektir. 2017 yılında bir fabrikanın üretim hattına entegre edilmiş ve her 15 dakikada veri toplayan sensörlerden elde edilen alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı verilerinin her biri saatlik veriye dönüştürülerek (aynı saat dilimi içerisindeki verilerin ortalaması alınarak) yeni bir veri seti elde edilmiştir. Elde edilen veri setinin örneklem büyüklükleri: alev (221), basınç (221), hareket (183), nem

(116), sıcaklık (44) ve yüzey sıcaklığı (170) şeklindedir. Tablo 4' te verilen 15 dakikada bir alınan alev veri setinin saatlik veri setine dönüştürülmesi örnek olarak verilmiştir.

Tablo 4. Alev veri setinin saatlik veri dönüşümü

Sıra	Veri	Tarih	Saat	Ortalama	Minimum	Maksimum
1	971.9285	9.07.2017	16:06:51+03	970.8562	969.4882	971.9285
2	969.4882	9.07.2017	16:21:51+03			
3	970.2332	9.07.2017	16:36:51+03			
4	971.7751	9.07.2017	16:51:52+03			
5	970.2987	9.07.2017	17:06:51+03	970.1218	969.555	970.7776
6	969.8558	9.07.2017	17:21:51+03			
7	970.7776	9.07.2017	17:36:51+03			
8	969.555	9.07.2017	17:51:51+03			
9	969.2215	9.07.2017	18:06:52+03	969.5557	966.3286	974.496
10	966.3286	9.07.2017	18:21:51+03			
11	974.496	9.07.2017	18:36:51+03			
12	968.1768	9.07.2017	18:51:51+03			
13	969.6173	9.07.2017	19:06:51+03	971.0013	969.3138	972.9888
14	972.9888	9.07.2017	19:21:51+03			
15	969.3138	9.07.2017	19:36:51+03			
16	972.0853	9.07.2017	19:51:51+03			
17	968.6809	9.07.2017	20:06:51+03	971.3817	968.6809	974.3095
18	974.3095	9.07.2017	20:21:51+03			
19	968.8754	9.07.2017	20:36:51+03			
20	973.6609	9.07.2017	20:51:51+03			
21	960.8677	9.07.2017	21:06:52+03	971.7063	960.8677	978.1316
22	973.8257	9.07.2017	21:21:51+03			
23	978.1316	9.07.2017	21:36:51+03			
24	974	9.07.2017	21:51:52+03			

2.7. ANFIS Tahmin Modelinin Kurulması ve Test Edilmesi

ANFIS tahmin modelini kurmak ve test etmek için alev, nem, basınç, hareket, sıcaklık ve yüzey sıcaklığı veri setleri kullanılacaktır. Bu veri setleri için en uygun üyelik fonksiyon tipinin belirlenmesi, RMSE ve MAPE değerlerinin hesaplanması amacıyla aşağıdaki adımlar ile uygulanmıştır. ANFIS kullanıcı editörünün (GUI) nasıl kullanıldığını göstermek için örnek olarak alev veri seti ele alınmıştır.

Alev veri seti saatlik veriye dönüştürülmüş ve dönüştürülen alev veri setinin 200'ü eğitim için, 21'i ise test verisi olarak kullanılmıştır. ANFIS'te modelin en iyi sonucu sağlayan üyelik fonksiyonunu belirlemek amacıyla modelde kullanılacak dilsel değişken sayısı, çevrim sayısı, hata toleransı, üyelik fonksiyonu tipinin belirlenmesi, bulanık mantık çıkarım derecesinin belirlenmesi gerekmektedir.

Bu çalışmada her bir değişkenin (alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı) girdilerine ait "minimum" ve "maksimum" dilsel değişkenleri seçilmiştir. Seçilen "minimum" ve "maksimum" dilsel değişkenleri bir saat içerisindeki değerlerin en küçük ve en büyük değerleri alınarak oluşturulmuştur. Bu çalışmada daha önce literatürde bahsedilen birinci derece Sugeno bulanık çıkarım modeli kullanılmıştır.

Alev veri setinin eğitim verisi yüklendikten sonra üyelik fonksiyonu tipi ve adedinin seçimi işleminin yapıldığı "Generate FIS" ekranı Şekil 10'da gösterilmektedir. "Number of MFs" üyelik fonksiyon sayısını vermekte olup "MF Type" kısmında ise üyelik fonksiyonlarının seçileceği bölüm yer almaktadır. Ekranın altındaki "output" bölümünde yer alan "MF Type" kısmında ise "constant" ve "linear" olmak üzere iki seçenek sunulmaktadır. "Linear" ifadesi birinci dereceden Sugeno bulanık modelini, "constant" seçeneği sıfır dereceden Sugeno bulanık modelini ifade etmektedir.

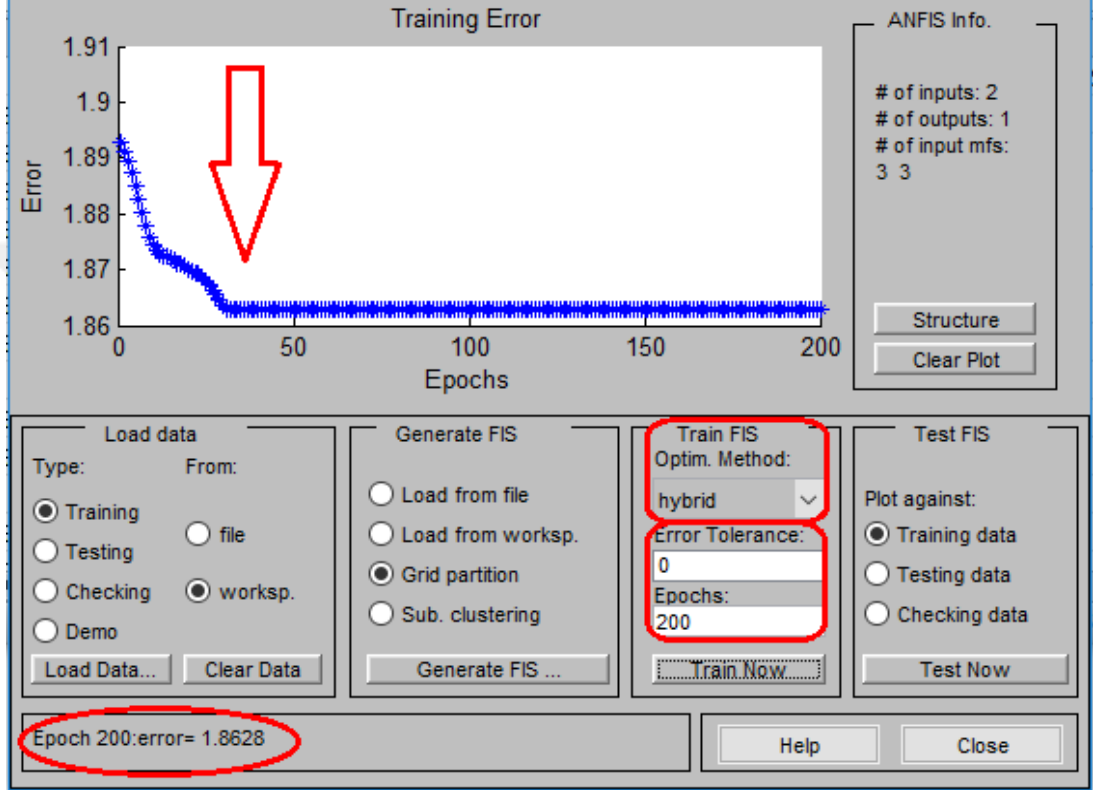
The image shows a dialog box titled "Generate FIS" with two main sections: "INPUT" and "OUTPUT".

- INPUT Section:**
 - Number of MFs:** A text box containing "3 3". Below it, a note reads: "To assign a different number of MFs to each input, use spaces to separate these numbers."
 - MF Type:** A list box containing several options: trimf, trapmf, gbellmf, gaussmf, gauss2mf, pimf, dsigmf, and psigmf. The option "psigmf" is currently selected and highlighted in blue.
- OUTPUT Section:**
 - MF Type:** A list box containing two options: constant and linear. The option "linear" is currently selected and highlighted in blue.

At the bottom of the dialog, there are two buttons: "OK" and "Cancel".

Şekil 10. Üyelik fonksiyon tipi ve adedinin seçimi

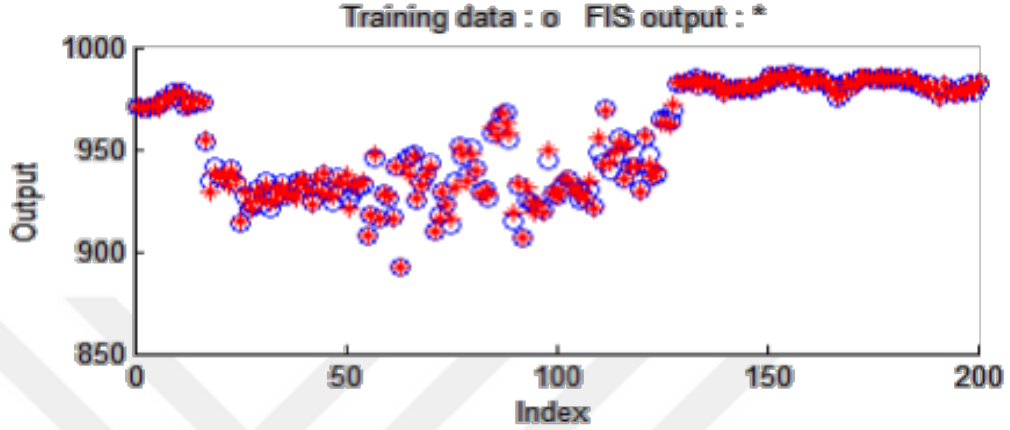
Şekil 11’de belirtilen ekran çıktısındaki “Train FIS” bölümünde yer alan “Optim. Method” kısmında ANFIS’in en önemli özelliklerinden biri olan “hybrid” öğrenme algoritması seçilmiştir. Bu çalışma esnasında “Error Tolerance” alanı “0” olarak seçilmiştir. Veri seti için “Epochs” kısmına eğitim verisi adedi yani 200 değeri yazılarak “Train Now” butonuna basılarak veri seti eğitilmiştir.



Şekil 11. Model girdilerinin eğitilmesi


Şekil 11 incelendiğinde orta bölümde yer alan grafik hata değerinin yaklaşık 40. çevrimden (epoch) sonra düz bir çizgi aldığı gözlemlenmektedir. Bu durum ilgili çevrimden sonra parametrelerin eğitilmesi işleminin durduğunu göstermektedir. Grafiğin X eksenini eğitilen çevrim (epoch) sayısını göstermektedir. Y eksenini ise girdi seçiminde de ele alınan RMSE değerlerini göstermektedir. Şekil 11’de görülen “Epoch 200:error= 1.8628” değeri, seçilen üyelik fonksiyonu tipi ve adedine uygun olarak hybrid (melez) eğitim algoritması ile eğitim verisi 200 çevrim eğitilmiş ve çıktı değeri 1.8628 büyüklüğünde bir hata değeri (RMSE) ile tahmin edilmiştir. Elde edilen RMSE değerinin optimal değere karar verilmesi için tüm üyelik fonksiyonlarının tek tek denenmesi gerekmektedir.

Seçilen üyelik fonksiyon tipinin modele uygunluğunu test etme adına Şekil 11’de ANFIS kullanıcı ara yüzünün sağ alt köşesinde yer alan “Test FIS” alanından faydalanılır. Şekil 12’de eğitilmiş eğitim veri seti ve test veri setinin gerçek çıktı ve tahmini çıktıları grafiksel olarak karşılaştırılmaktadır.



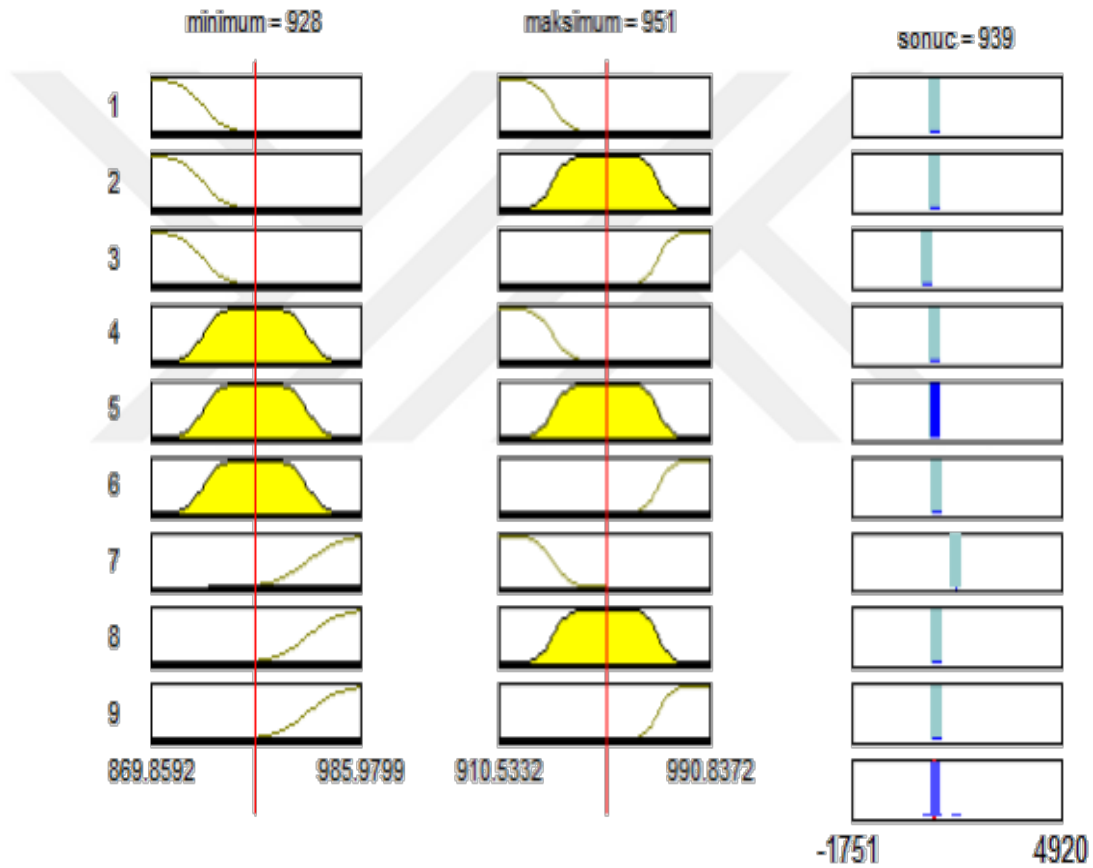
Şekil 12. Eğitim seti içerisinde gerçek çıktı ve tahmini çıktıların karşılaştırılması

Şekil 13’te yer alan model test verisi başarımlar grafiği verilmiştir. Grafiğe bakıldığında yıldız operatörü ile gösterilen bulanık mantık tahmini çıktı değerlerini ve nokta operatörü ile gösterilen test veri setini (gerçek değerleri) göstermektedir. Modelin test verisi başarımlar grafiği ile elde edilen “Average testing error” test hatası (RMSE) değerini ortaya koymaktadır ve 1,7957 hata büyüklüğü ile tahmin edildiği söylenebilir.



Şekil 13. Model test verisi başarımlar grafiği

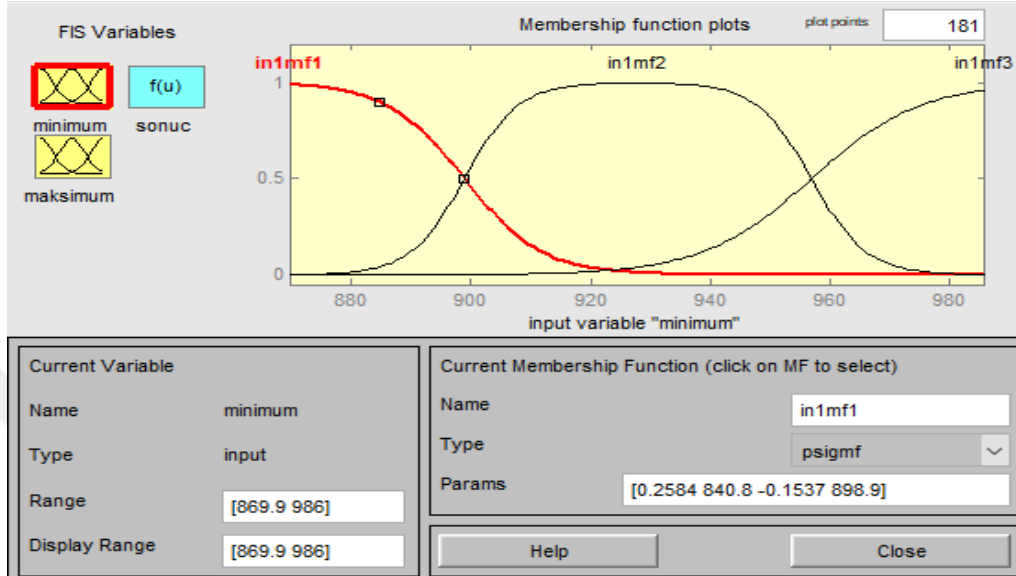
Çıkan modelin “Rules” kural görünümünü Şekil 14’te verilmektedir. Örnekte, girdi olarak [927,9;950,7] değerleri verilmiş ve sonuç olarak 939 değeri bulunmuştur. Elde edilen 939 değeri durulaştırılmış değerdir. Veri seti için 200 eğitim veri seti ve 21 test veri seti olmak üzere toplam 221 adet veri yer almaktadır. Kullanıcının “Rule Viewer” ekranını kullanarak ANFIS’te durulaştırılmış değerleri elde etmek için tek tek girdi değerlerinin yazılması gerekmektedir, bu durumda zaman kaybettirmektedir. Bu nedenle ANFIS modelinin hem eğitim hem de test verisine yönelik çıktıları bir liste halinde ortaya koyma bilmek adına çalışmada “evalfis” komutu kullanılmıştır.



Şekil 14. Modelin kural yapısı

ANFIS kullanıcı ara yüzündeki “Edit” menüsünde yer alan “Rules” seçeneği ile sistemin ürettiği kurallar elde edilebilir. Aynı menünün altında Şekil 15’te “Membership Functions” seçeneği ise üyelik fonksiyonlarına sözel değerlerinin belirlenmesi sağlanmaktadır. “Membership Function” ekranında sol üst köşesinde yer alan “FIS Variables” kısmı problemdeki girdi ve çıktıları göstermektedir. Ekranın sol altında yer alan

bölümde mevcut değişkenin ismi, tipi ve veri aralığı gösterilmektedir. Bunun yanı sıra sağ alt köşede üyelik fonksiyonun tipi ve sistemin eğitilmesi sonucu elde edilen parametre değerleri de yer almaktadır.



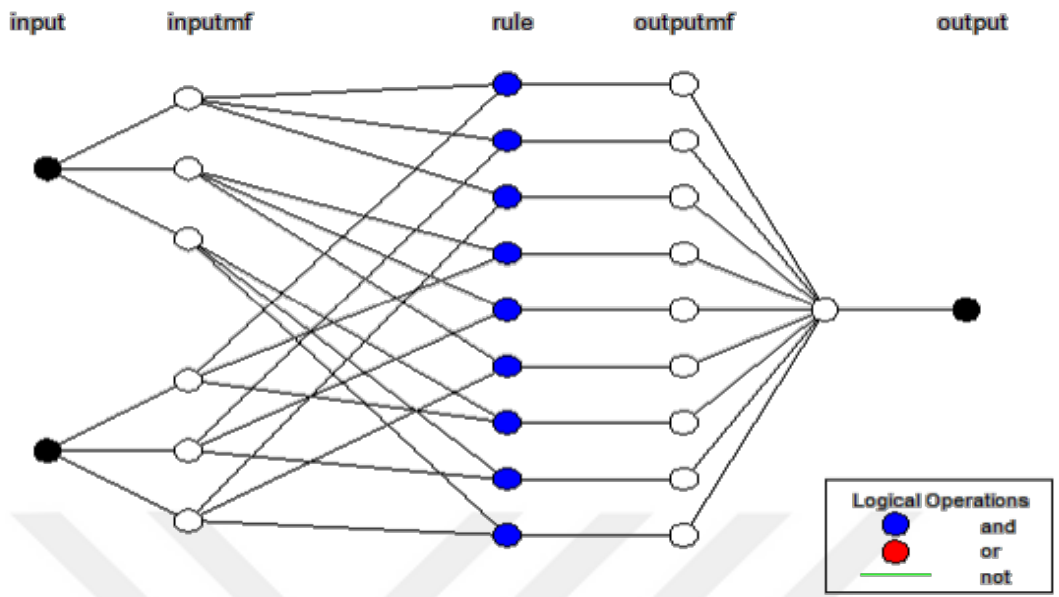
Şekil 15. Model üyelik fonksiyonun sözel değer belirlenmesi

Tablo 5’te ANFIS yapısının kurulan modelde “Edit” menüsü altında yer alan “Rules” seçeneği ile ANFIS yapısının oluşturduğu 9 kural görülmektedir. Kurulan modelin çıktılarına sözel değerler kullanılarak bulanık “eğer-ise” kural yapısı sunulmuştur. ANFIS’in oluşturduğu kural tabanında “ve” parametresi kullanılmıştır. Kurallar incelendiğinde “minimum” ve “maksimum” iki dilsel girdi değişkenin kullanıldığı, “sonuc” dilsel çıktı değişkenin tanımlandığı görülmektedir. “in1mf1” in1 (input1) birinci giriş değişkenini temsil ederken mf1 (membership function1) birinci üyelik fonksiyonunu ifade etmektedir. “out1mf1” out1 (output1) birinci çıktı, mf1 (membership function1) birinci çıktı üyelik fonksiyonunu ifade etmektedir. Tablo da yer alan (1) sonucuna bakıldığında girdilerin ve çıktıların tek bir katman halinde çıktığı ifade edilebilir.

Tablo 5. ANFIS sisteminin oluşturduğu kural tabanı


Kural Sıra Sayısı	Koşul	Girdi Koşulu	Koşul	Sonuç	Çıktı
1	EĞER	(minimum = in1mf1) VE (maksimum = in2mf1)	İSE	(sonuc = out1mf1)	(1)
2	EĞER	(minimum = in1mf1) VE (maksimum = in2mf2)	İSE	(sonuc = out1mf2)	(1)
3	EĞER	(minimum = in1mf1) VE (maksimum = in2mf3)	İSE	(sonuc = out1mf3)	(1)
4	EĞER	(minimum = in1mf2) VE (maksimum = in2mf1)	İSE	(sonuc = out1mf4)	(1)
5	EĞER	(minimum = in1mf2) VE (maksimum = in2mf2)	İSE	(sonuc = out1mf5)	(1)
6	EĞER	(minimum = in1mf2) VE (maksimum = in2mf3)	İSE	(sonuc = out1mf6)	(1)
7	EĞER	(minimum = in1mf3) VE (maksimum = in2mf1)	İSE	(sonuc = out1mf7)	(1)
8	EĞER	(minimum = in1mf3) VE (maksimum = in2mf2)	İSE	(sonuc = out1mf8)	(1)
9	EĞER	(minimum = in1mf3) VE (maksimum = in2mf3)	İSE	(sonuc = out1mf9)	(1)

Şekil 16'da elde edilen ANFIS mimari çıktısı yer almaktadır. ANFIS kullanıcı ara yüzündeki "structure" butonu yardımı ile ilgili mimari yapı elde edilir. Şeklin en solunda yer alan iki siyah düğüm (daire) problemle ilişkili kriterleri vermektedir. İkinci katmanda ise her bir girdi ile ilişkili üç adet üyelik fonksiyonu atanmaktadır. Üçüncü katman 9 adet kuraldan oluşmaktadır. Belirlenen kurallardan gelen her bir çıktı 4. katmanda yer alır, bütün kurallar ile ilişkili çıktılar toplanarak sistemin tahmin ettiği çıktı değerine 5. katmanda ulaşılır.



Şekil 16. Kurulan ANFIS mimarisi çıktısı

Şekil 17'deki grafikte iki girdili ANFIS modelinin girdileri ile çıktısı arasındaki ilişkisi sunulmuştur. Grafik üzerinden kurulan model ile ilgili çıkarımlar yapmak mümkündür. Şekil 17 incelenirse, minimum değerinin sonuca olan etkisi açıkça görülmektedir.



Şekil 17. Kurulan model ilişki grafiği

2.8. Zaman Serisi Tahmin Modelinin Kurulması

Zaman serisi literatür kısmında bulunan bilgiler doğrultusunda, AR(p) (Autoregressive- Otoregresif), MA(q) (Moving Average- Hareketli Ortalama) ve ARMA(p,q) (Autoregressive Moving Average- Otoregresif Hareketli Ortalama Yöntemi) modelleri, durağan zaman serilerinin analiz ve tahmininde bu modeller kullanılır. Bu çalışmada kullanılacak serinin yapısını ve belirli ölçütlere göre bu modellerden birine karar verilir. Modelin seçiminde serinin kısmi otokorelasyon ve otokorelasyon fonksiyonlarının ilerleyiş ölçütü olarak kullanılır. Durağan modeller arasında seçim yapabilmek için ilk önce analiz edilecek serinin kısmi otokorelasyon ve otokorelasyon fonksiyonları belirlenir. Belirlenen fonksiyonları korelogramı çizilir. Tablo 6'daki ölçüt göz önüne alınarak model tipi belirlenir (Özmen, 1986).

Tablo 6. Durağan modellerde ana kütle otokorelasyon ve kısmi fonksiyonlarının ilerleyişi

Model	Otokorelasyon Fonksiyonu	Kısmi Otokorelasyon Fonksiyonu
AR(p)	Üssel ve/ veya Sinüzoidal bir biçimde azalır.	p gecikmesinden sonra istatistiksel olarak anlamlı değildir.
MA(q)	q gecikmesinden sonra istatistiksel olarak anlamlı değildir.	Üssel ve/veya sinüzoidal bir biçimde azalır.
ARMA(p,q)	q-p gecikmesinden sonra üssel ve/veya sinüzoidal bir biçimde azalır.	p-q gecikmesinden sonra üssel ve/veya sinüzoidal bir biçimde azalır

ARIMA (p,d,q) durağan olmayan, mevsimsellik göstermeyen serilerin modellenmesinde kullanılır. ARIMA (Autoregressive Integrated Moving Average- Otoregresif Bütünleşik Hareketli Ortalama Yöntemi) modeli her zaman AR (Autoregressive- Otoregresif) ya da MA (Moving Average- Hareketli Ortalama) unsurlarını bulundurması gerekmemektedir, AR(p) unsuru içermiyorsa ARIMA(0,d,q) veya IMA(d,q) (Integrated Moving Average- Bütünleşik Hareketli Ortalama) tipi bir model olabilir. Aynı şekil MA(q) unsuru içermeye bilir, o halde model ARIMA(p,d,0) veya

IAR(p,d) (Integrated Autoregressive Bütünleşik Otoresif) tipi bir model olabilir. Örneklem otokorelasyon ve kısmi otokorelasyon katsayıları ilerleyişi ile ana kütle otokorelasyon ve $[P(k)]$ ve kısmi otokorelasyon (φ_{kk}) katsayılarının ilerleyişi birbirinin aynısı değildir, fakat benzerlik gösterebilir. Tablo 7’de durağan olmayan modellerde ana kütle otokorelasyon ve kısmi fonksiyonlarının ilerleyişi verilmiştir (Özmen, 1986).

Tablo 7. Durağan olmayan modellerde ana kütle otokorelasyon ve kısmi fonksiyonlarının ilerleyişi

Model	Otokorelasyon Fonksiyonu	Kısmi Otokorelasyon Fonksiyonu
IAR(1,d,o)	Üstel olarak azalır.	Yalnız φ_{11} için anlamlıdır.
IMA(o,d,1)	Yalnız (p1) için anlamlıdır.	Üstel olarak yazılır.
IAR(2,d,o)	Üstel fonksiyonlar karışımı veya azalan sinüs dalgaları görünümündedir.	Yalnız φ_{11} ve φ_{22} için anlamlıdır.
IMA(o,d,2)	Yalnız P(1) ve P(2) için anlamlıdır.	Üstel fonksiyonlar karışımı veya azalan sinüs dalgaları görünümündedir.
ARIMA(1,d,1)	P(k) birinci gecikmeden sonra ($k>2$) üstel olarak azalır.	φ_{kk} birinci gecikmeden sonra ($k>2$) üstel olarak yazılır.

Bu çalışmada, uygulamanın ilk kısmında oluşturulan veri kümesi kullanılarak ARIMA modellerinin tahmin etkinlikleri ölçülmüştür. Endüstri 4.0 teknolojisini kullanılan bir fabrikanın sensör yardımı ile alınan verilerinde Box-Jenkins yönteminin ARIMA modeli uygulanması için 15 dakika da bir elde edilen alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı verilerinin her biri saatlik veriye dönüştürülmüştür (aynı saat dilimi içerisindeki verilerin ortalaması alınarak), yeni bir veri seti elde edilmiştir. Zaman serileri modellerini uygulayabilmek için, R programından faydalanılmıştır. Bu çalışmalara başlamadan önce serinin korelogram analizi yapılmış, ACF, PACF ile serinin durağan mı durağan olmayan seri mi olduğuna dair fikir edinilmiştir.

ARIMA model, her bir değişken (alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı) için eğitim ve test verisi ile uygulanmıştır. Alev değişkeni örnek olarak

gösterilmiştir. Şekil 18’de alev değişkeninin eğitim seti için çizdirilen korelogram grafiği verilmiştir.




Şekil 18. Veri seti korelogram grafiği

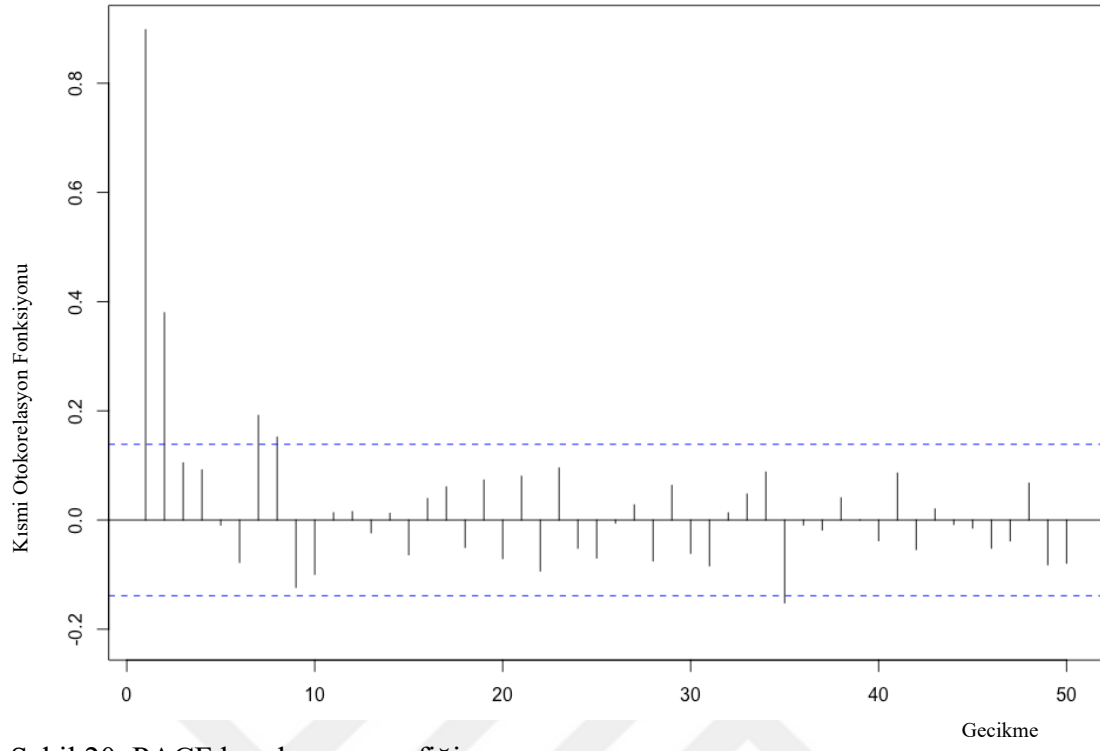
ARIMA modelinin belirlenmeden önce durağanlık analizi yapılmalıdır. Şekil 19’daki korelogram ACF (Autocorrelation Function - Otokorelasyon fonksiyonu) ve Şekil 20’deki korelogram PACF (Partial Autocorrelation Function - Kısmi otokorelasyon fonksiyonu) grafik değerleri gözlenmektedir. Korelogram grafiğinde görüldüğü üzere ortalamasının sabit olmadığı zaman içinde büyük değişimler gösterdiği dolayısıyla serinin durağan olmayan bir yapıya sahip olduğu görülmektedir. Veri sayısı $N=200$ olduğu için $k \geq N/4=50$ gecikmeye kadar ACF ve PACF korelogram grafikleri çizdirilmiştir. ACF ve PACF grafiklerine bakıldığında Otokorelasyon katsayılarının sıfıra yavaş bir şekilde yaklaşması serinin durağan olmadığı hakkında bir fikir vermektedir. Durağan olamayan bir serinin analiz edilebilmesi için durağan hale getirilmesi gerekir. Bu durumda serinin birinci farkları alınır. Eğer otokorelasyon değerleri birinci ve ikinci gecikmeden sonra hızlıca sıfıra yaklaşıyorsa veya istatistiki açıdan anlamlı değilse, birinci farklardan meydana gelen serinin durağan olduğuna karar verilir. Fakat birinci dereceden farklar serinin otokorelasyon katsayıları ilk iki gecikmeden sonra sıfıra yaklaşmıyorsa ve istatistiki açıdan anlamlı ise, seride durağanlığa ulaşılmadığı anlaşılır. Durağanlığın sağlanması için ikinci

dereceden farkının alınması gerekir. Seri durağan hale gelmiyorsa logaritması alınması gerekmektedir. Kullanılan serinin farkları alındıktan sonra durağanlaşmadığı görüldüğü için logaritması alınmıştır.

ARIMA model tahmini için en iyi sonuçları almak adına her bir model tek tek denerek belirlenmiştir. Seçilen ARIMA modelinin tahmin sonuçları, MS (Mean Square-Ortalama hata kare), P-değeri, katsayısı gibi istatistiksel sonuçlar elde edilmiştir. Elde edilen u_i 'ler (hata terimleri) yardımı ile tahmini değerler hesaplanmıştır.



Şekil 19. ACF korelogram grafiği



Şekil 20. PACF korelogram grafiği

3. BULGULAR

Bu çalışmada, Endüstri 4.0 teknolojisini kullanılan bir fabrikanın üretim hattından sensör yardımı ile alınan 15 dakika da bir elde edilen alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı verilerinin her biri saatlik veriye dönüştürülerek alev (221), basınç (221), hareket (183), nem (116), sıcaklık (44) ve yüzey sıcaklığı (170) yeni bir veri seti elde edilmiştir. Her bir veri eğitim ve test olmak üzere basit rassal ayırım yöntemi ile eğitim ve test veri seti olarak iki parçaya ayrılmıştır. ANFIS metodu doğası gereği bu ayırma ihtiyaç duymaktadır. Her bir veri setinin %90'ı eğitim veri seti, %10'u ise test veri seti olarak tespit edilmiştir. Modeller bu eğitim verilerine göre sistem yapısını öğrenecek ve daha sonra test verileri ile öğrendikleri yapının doğruluğunu tespit edeceklerdir.

Bulanık zaman serisinin üyelik fonksiyonları RMSE ve MAPE değerlerine bakılarak eğitim veri seti için en iyi üyelik fonksiyonu belirlendi. Burada, eğitim kümesi için başarıyı en iyi yapan model seçilmiştir. Veri setlerinin eğitim ve test değerlerinin ANFIS ve Box-Jenkins yöntemi kullanılarak elde edilen sonuçlar karşılaştırılmasında RMSE ve MAPE değerleri kullanılmıştır. İki model arasında hangisinin daha iyi sonuç vereceği elde edilen performans ölçülerine göre kıyaslanmıştır.

3.1. ANFIS Model Sonuçları

ANFIS yöntemi için literatür kısmında yer alan bilgilere baş vurularak, ANFIS yöntemi birinci derece Sugeno bulanık çıkarım sistemi kullanılarak veri setleri için en iyi üyelik fonksiyonunu belirlenmiştir. Her bir üyelik fonksiyonu tek tek denenerek elde edilen sonuçlar kendi aralarında karşılaştırılmıştır ve RMSE değeri en düşük fonksiyon tercih edilmiştir.

Alev değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi Tablo 2'de belirtilen üyelik fonksiyon tipleri için üyelik fonksiyonuna uygulanan işlemler tek tek yapılmıştır ve her bir üyelik fonksiyon çeşidi için elde edilen değerler verilmiştir. Eğitim kümesi için RMSE değerlerine bakılıp en az hataya sahip üyelik fonksiyonu seçilmiştir.

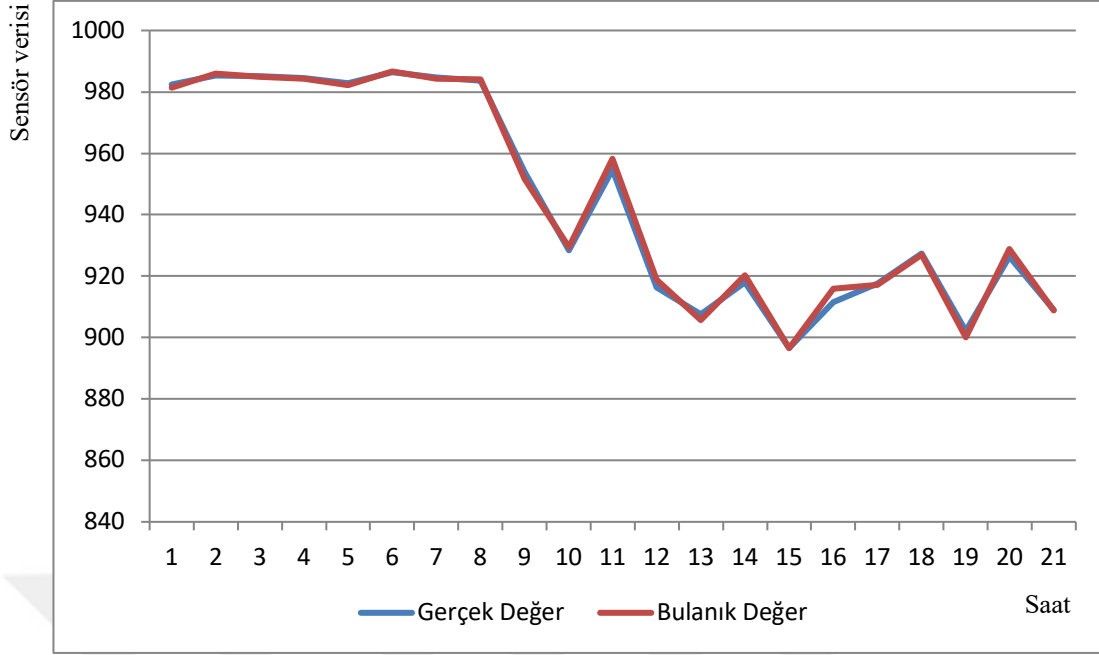
Tablo 8. Alev deęişkeni için üyelik fonksiyonlarının RMSE deęerlerinin gösterimi

Üyelik Fonksiyonu	Eđitim- RMSE	Test- RMSE
trimf	2.0351	3.2726
trapmf	1.9011	1.81
gbellmf	1.8664	1.6532
gaussmf	1.8783	1.9172
gauss2mf	1.8671	1.641
pimf	1.9112	1.8882
dsigmf	1.8729	1.7502
psigmf	1.8628	1.7957

Tablo 8 incelendiđinde, en iyi sonucun Sigmodial üyelik fonksiyonuna (psigmf) ait olduđu yani en az hata deęerinin Sigmodial üyelik fonksiyonuna ait olduđu görölmektedir. Sigmodial üyelik fonksiyonu formölü Eşitlik (94) ile verilmiştir.

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (94)$$

Alev deęişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettiđi test deęerleri ile gerçek test veri setinin karşılaştırma grafiđi Şekil 21'de görölmektedir. Şekil 21'de mavi olarak görölen çizgi gerçek deęerleri, kırmızı olarak görölen çizgi Sigmodial üyelik fonksiyonunun tahmin ettiđi bulanık deęerleri göstermektedir. Şekil 21'e bakıldığında gerçek deęerler ile Sigmodial üyelik fonksiyonuna ait bulanık deęerler arasında kabul edilebilir düzeyde bir yakınlık olduđu görölmektedir.



Şekil 21. Alev değişkeni gerçek ve bulanık değer grafiği

Basınç değişkeni için kullanılacak üyelik fonksiyonunu belirlemek için bütün üyelik fonksiyonları tek tek denenmiştir. Eğitim sonucu oluşan her bir üyelik fonksiyonları Tablo 9'da gösterilmiştir.


Tablo 9. Basınç değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi

Üyelik Fonksiyonu	Eğitim- RMSE	Test- RMSE
trimf	1.9713	2.4007
trapmf	1.901	1.8348
gbellmf	1.8538	2.1236
gaussmf	1.8637	2.1978
gauss2mf	1.8436	1.9602
pimf	1.8984	1.8836
dsigmf	1.8503	1.8258
psigmf	1.8644	1.8288

Tablo 9 incelendiğinde, Gauss üyelik fonksiyonunun (gauss2mf - tam simetrik) en az hata değerine sahip olduğu görülmektedir. Gauss üyelik fonksiyonu formülü Eşitlik (95) ile verilmiştir.

$$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (95)$$

Basınç değişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettiği test değerleri ile gerçek test veri setinin karşılaştırma grafiği Şekil 22'de görülmektedir. Şekil 22'de mavi olarak görülen çizgi gerçek değerleri, kırmızı olarak görülen çizgi Gauss üyelik fonksiyonunun tahmin ettiği bulanık değerleri göstermektedir. Şekil 22'e bakıldığında gerçek değerler ile Gauss üyelik fonksiyonuna ait bulanık değerler arasında kabul edilebilir düzeyde bir yakınlık olduğu görülmektedir.



Şekil 22. Basınç değişkeni gerçek ve bulanık değer grafiği

Hareket değişkeni için kullanılacak üyelik fonksiyonunu belirlemek için bütün üyelik fonksiyonları tek tek denenmiştir. Eğitim sonucu oluşan her bir üyelik fonksiyonları Tablo 10'da gösterilmiştir.


Tablo 10. Hareket deęişkeni için üyelik fonksiyonlarının RMSE deęerlerinin gösterimi

Üyelik Fonksiyonu	Eđitim- RMSE	Test- RMSE
trimf	0.82705	1.2857
trapmf	0.88326	1.324
gbellmf	0.85918	1.2963
gaussmf	0.86008	1.2852
gauss2mf	0.82465	1.3731
pimf	0.86961	1.3534
dsigmf	0.82438	1.3928
psigmf	0.82414	1.3837

Tablo 10'a göre en iyi sonucun Sigmoidal üyelik fonksiyonuna (psigmf) ait olduęu başka bir ifadeyle en az hata deęerinin Sigmoidal üyelik fonksiyonuna ait olduęu görölmektedir. Sigmoidal üyelik fonksiyonu formülü Eşitlik (96) ile verilmiştir.

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (96)$$

Hareket deęişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettięi test deęerleri ile gerçek test veri setinin karşılaştırma grafięi Şekil 23'te görölmektedir. Şekil 23'te mavi olarak görölen çizgi gerçek deęerleri, kırmızı olarak görölen çizgi Sigmoidal üyelik fonksiyonunun tahmin ettięi bulanık deęerleri göstermektedir. Şekil 23'e bakıldığında gerçek deęerler ile Sigmoidal üyelik fonksiyonuna ait bulanık deęerler arasında gözle görülebilir bir farklılık olduęu görölmektedir.



Şekil 23. Hareket değişkeni gerçek ve bulanık değer grafiği

Nem değişkeni için kullanılacak üyelik fonksiyonunu belirlemek için bütün üyelik fonksiyonları tek tek denenmiştir. Eğitim sonucu oluşan her bir üyelik fonksiyonları Tablo 11'de gösterilmiştir.


Tablo 11. Nem değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi

Üyelik Fonksiyonu	Eğitim- RMSE	Test- RMSE
trimf	1.9009	2.7704
trapmf	1.8477	3.0256
gbellmf	1.846	3.0157
gaussmf	1.8512	3.0394
gauss2mf	1.8818	3.0642
pimf	1.901	3.0554
dsigmf	1.89	3.0858
psigmf	1.892	3.0789

Tablo 11'e göre, en az hata değerine sahip olduğundan dolayı en iyi sonucun Çan şekilli üyelik fonksiyonuna (gbellmf) ait olduğu görülmektedir. Çan şekilli üyelik fonksiyonu formülü Eşitlik (97) ile verilmiştir.

$$f(x; a, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (97)$$

Nem değişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettiği test değerleri ile gerçek test veri setinin karşılaştırma grafiği Şekil 24'te görülmektedir. Şekil 24'te mavi olarak görülen çizgi gerçek değerleri, kırmızı olarak görülen çizgi Çan şekilli üyelik fonksiyonunun tahmin ettiği bulanık değerleri göstermektedir. Şekil 24'e bakıldığında gerçek değerler ile Çan şekilli üyelik fonksiyonuna ait bulanık değerler arasında farklılıklar olduğu görülmektedir.



Şekil 24. Nem değişkeni gerçek ve bulanık değer grafiği

Sıcaklık değişkeni için kullanılacak üyelik fonksiyonunu belirlemek için bütün üyelik fonksiyonları tek tek denenmiştir. Eğitim sonucu oluşan her bir üyelik fonksiyonları Tablo 12'de gösterilmiştir.

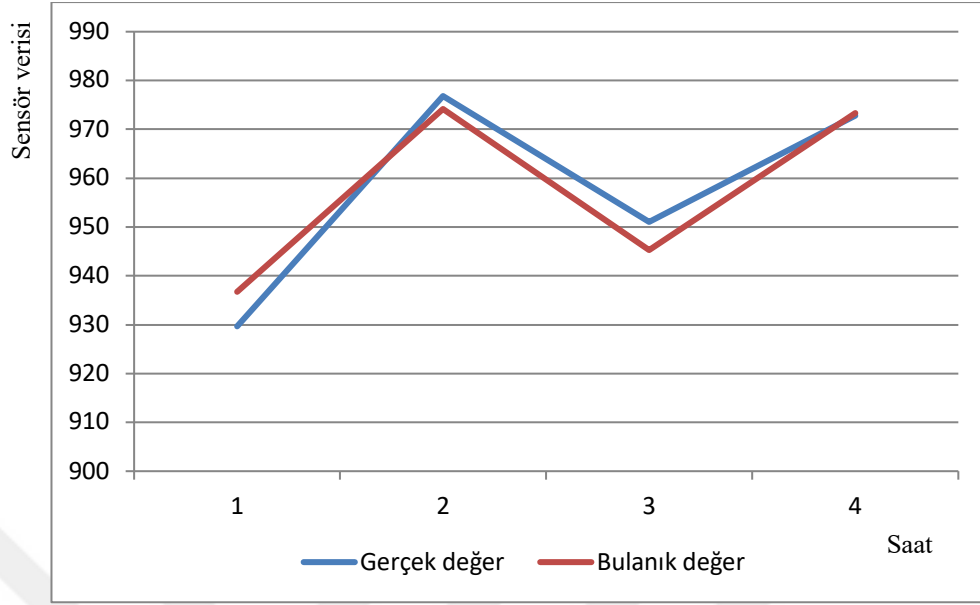
Tablo 12. Sıcaklık değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi

Üyelik Fonksiyonu	Eğitim- RMSE	Test- RMSE
trimf	1.4134	1.3843
trapmf	1.1303	4.2356
gbellmf	1.0952	29.1389
gaussmf	1.1457	38.0897
gauss2mf	1.2749	8.8098
pimf	1.0826	4.7564
dsigmf	1.9821	29.8031
psigmf	1.3208	20.5509

Tablo 12 incelendiğinde, en iyi sonucun en az hata değeri ile Π üyelik fonksiyonunun (pimf) olduğu görülmektedir. Π üyelik fonksiyonu formülü Eşitlik (98) ile verilmiştir.

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1 - 2 \left(\frac{x-c}{d-c} \right)^2, & c \leq x \leq \frac{c+d}{2} \\ 2 \left(\frac{x-d}{d-c} \right)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & x \geq d \end{cases} \quad (98)$$

Sıcaklık değişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettiği test değerleri ile gerçek test veri setinin karşılaştırma grafiği Şekil 25'te görülmektedir. Şekil 25'te mavi olarak görülen çizgi gerçek değerleri, kırmızı olarak görülen çizgi Π üyelik fonksiyonunun tahmin ettiği bulanık değerleri göstermektedir. Şekil 25 incelendiğinde gerçek değerler ile Π üyelik fonksiyonuna ait bulanık değerler arasında kesişen değerlerin olduğu ve bazı değerler arasında farklılıklar olduğu görülmektedir.



Şekil 25. Sıcaklık değişkeni gerçek ve bulanık değer grafiği

Yüzey sıcaklığı değişkeni için kullanılacak üyelik fonksiyonunu belirlemek için bütün üyelik fonksiyonları tek tek denenmiştir. Eğitim sonucu oluşan her bir üyelik fonksiyonları Tablo 13'te gösterilmiştir.


Tablo 13. Yüzey sıcaklığı değişkeni için üyelik fonksiyonlarının RMSE değerlerinin gösterimi

Üyelik Fonksiyonu	Eğitim- RMSE	Test- RMSE
trimf	0.84214	0.90862
trapmf	0.87013	0.95654
gbellmf	0.82185	0.89014
gaussmf	0.83067	0.89239
gauss2mf	0.83384	0.93337
pimf	0.87659	0.97335
dsigmf	0.83644	0.92874
psigmf	0.83577	0.92515

Tablo 13'e göre, Çan şekilli üyelik fonksiyonunun (gbellmf) en az hata değerine sahip olduğu görülmektedir. Çan şekilli üyelik fonksiyonu formülü Eşitlik (99) ile verilmiştir.

$$f(x; a, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (99)$$

Yüzey sıcaklığı değişkeni için, ANFIS aşamalarını adım adım gerçekleştirildikten sonra modelin tahmin ettiği test değerleri ile gerçek test veri setinin karşılaştırma grafiği Şekil 26'da görülmektedir. Şekil 26'da mavi olarak görülen çizgi gerçek değerleri, kırmızı olarak görülen çizgi Çan şekilli üyelik fonksiyonunun tahmin ettiği bulanık değerleri göstermektedir. Şekil 26'a göre gerçek değerler ile Çan şekilli üyelik fonksiyonuna ait bulanık değerler arasında bazı değerlerin örtüştüğü ve bazı değerlerin farklı olduğu görülmektedir.



Şekil 26. Yüzey sıcaklığı değişkeni gerçek ve bulanık değer grafiği

3.2. ARIMA Model Sonuçları

ARIMA modeli için literatür kısmında yer alan bilgilere baş vurularak, her bir veri seti için tahmin modeli kurulmuştur. Uygun ARIMA modeli belirlendikten sonra elde edilen tahmin değerleri ile literatür kısmında Tablo 3'te verilen formüller yardımıyla RMSE ve MAPE değerleri hesaplanmıştır.

Tablo 14'e göre, ARIMA modelinin Otoregresif terimi (AR(3)), Hareketli ortalama terimi (MA(3)) ve Sabit katsayısının anlamlı olduğu istatistiksel olarak söylenebilir ($p < 0.05$). Alev değişkeni eğitim veri seti için en uygun modelin ARIMA(3, 0, 3) olduğu söylenebilir.

Tablo 14. Alev değişkeni eğitim verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(3)	0.8247	0.0519	15.88	0.000
MA(3)	0.4893	0.0286	17.10	0.000
Sabit	51.272	1.048	48.91	0.000
Ortalama	961.84	19.67		

Tablo 15'te sunulan, ARIMA modelinin AR(2) ve Sabit katsayısının anlamlı olduğu istatistiksel olarak söylenebilir ($p < 0.05$). MA(3)'ün anlamlı olmadığı gözlenmektedir ($p > 0,05$). Yapılan sınamalarda MS (Mean Square) değeri en düşük çıkan ve gelecek dönem tahmini yapılabildiği gözlenen, alev değişkeni test veri seti için en uygun modelin ARIMA(2, 0, 3) olduğu söylenebilir.

Tablo 15. Alev değişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(2)	-0.9472	0.0990	-9.57	0.000
MA(3)	0.2734	0.3418	0.80	0.436
Sabit	45.5786	0.5070	89.90	0.000
Ortalama	945.01	10.51		

Tablo 16 incelendiğinde, ARIMA modelinin AR(2), MA(3) için ($p<0.05$) anlamlı olduğu görülmektedir, $d=1$ olarak alındığında basınç değişkeni eğitim veri seti için en uygun modelin ARIMA(2, 1, 3) olduğu söylenebilir.

Tablo 16. Basınç değişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(2)	-0.8450	0.0514	-16.44	0.000
MA(3)	0.5218	0.0353	14.76	0.000
Fark (d)	1			

Tablo 17'e göre, ARIMA modelinin AR(2) ve MA(2) modelinin istatistiksel olarak anlamlı olduğu söylenebilir ($p<0.05$). $d=1$ olarak alındığında basınç değişkeni test veri seti için en uygun modelin ARIMA(2, 1, 2) olduğu söylenebilir.

Tablo 17. Basınç değişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(2)	-1.0044	0.0359	-27.99	0.000
MA(2)	-1.0460	0.0874	-11.96	0.000
Fark (d)	1			

Tablo 18'de sunulan, ARIMA modelinin AR(5) ve MA(2) modelinin anlamlı olduğu görülmektedir ($p<0,05$), $d=1$ olarak alındığında hareket değişkeni eğitim veri seti için en uygun modelin ARIMA(5, 1, 2) olduğu söylenebilir.

Tablo 18. Hareket değişkeni eğitim verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(5)	0.1440	0.0793	1.82	0.071
MA(2)	-0.9763	0.0115	-84.97	0.000
Fark (d)	1			

Tablo 19’da sunulan, ARIMA modelinin MA(1) ve Sabit katsayısının değerlerine bakıldığında istatistiksel olarak anlamlı olduğu görülmektedir ($p<0.05$), $d=1$ olarak alındığında hareket değişkeni test veri seti için en uygun modelin ARIMA(0, 1, 1) olduğu söylenebilir.

Tablo 19. Hareket değişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
MA(1)	0.9381	0.2953	3.18	0.006
Sabit	0.71329	0.09587	7.44	0.000
Fark (d)	1			

Tablo 20 incelendiğinde, ARIMA modelinin AR(2), MA(3) modelinin anlamlı olduğu söylenebilir ($p<0.05$), $d=1$ olarak alındığında nem değişkeni eğitim veri seti için en uygun modelin ARIMA(2, 1, 3) olduğu söylenebilir.

Tablo 20. Nem değişkeni eğitim verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-değeri
AR(2)	-0.8132	0.0623	-13.05	0.000
MA(3)	0.5307	0.0373	14.24	0.000
Fark (d)	1			

Tablo 21’e göre, ARIMA modelinin AR(1), MA(1) modelinin istatistiksel olarak anlamlı olmadığı söylenebilir ($p>0,05$) ve Sabit katsayısının anlamlı olduğu görülmektedir ($p<0,05$), $d=2$ olarak alındığında nem değişkeni test veri seti için en uygun modelin ARIMA(1, 2, 1) olduğu söylenebilir.

Tablo 21. Nem deęişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-deęeri
AR(1)	-0.4635	0.4076	-1.14	0.299
MA(1)	1.6000	0.7697	2.08	0.083
Sabit	-1.645105	0.002905	-566.29	0.000
Fark (d)	2			

Tablo 22’de sunulan, ARIMA AR(2), MA(2) modelinin ve Sabit katsayısının anlamlı olduęu görölmektedir ($p < 0.05$), $d=1$ olarak alındığında sıcaklık deęişkeni eğitim veri seti için en uygun modelin ARIMA(2, 1, 2) olduęu söylenebilir.

Tablo 22. Sıcaklık deęişkeni eğitim verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-deęeri
AR(2)	-0.5302	0.1542	-3.44	0.002
MA(2)	-1.1230	0.0599	-18.76	0.000
Sabit	-1.6124	0.6906	-2.33	0.026
Fark (d)	1			

Tablo 23’e göre, ARIMA modelinin AR(1), Sabit katsayısının anlamlı olduęu görölmektedir ($p < 0.05$). Sıcaklık deęişkeni test veri seti için en uygun modelin ARIMA(1, 0, 0) olduęu söylenebilir.

Tablo 23. Sıcaklık deęişkeni test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	<i>t</i>	P-deęeri
AR(1)	-0.9983	0.2437	-4.10	0.055
Sabit	1917.72	5.67	337.94	0.000
Ortalama	959.692	2.840		

Tablo 24 incelendiğinde, ARIMA modelinin AR(2), Sabit katsayısının anlamlı olduęu görölmektedir ($p < 0.05$). Yüzey sıcaklığı deęişkeni eğitim veri seti için en uygun modelin ARIMA(2, 0, 0) olduęu söylenebilir.

Tablo 24. Yüzey sıcaklığı değişkeni eğitim verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	t	P-değeri
AR(2)	0.1907	0.0803	2.38	0.019
Sabit	347.839	0.426	817.19	0.000
Ortalama	970.854	1.188		

Tablo 25’te sunulan, ARIMA modelinin MA(1)’in anlamlı olduğu görülmektedir ($p < 0.05$). Sabit katsayısının anlamlı olmadığı söylenebilir ($p > 0.05$), $d=1$ olarak alındığında yüzey sıcaklığı değişkeni test veri seti için en uygun modelin ARIMA(0, 1, 1) olduğu söylenebilir.

Tablo 25. Yüzey sıcaklığı test verisi için ARIMA model çıktısı

Tür	Katsayı	Katsayı Standart Hatası	t	P-değeri
MA(1)	1.2027	0.2200	5.47	0.000
Sabit	-0.12002	0.08504	-1.41	0.180
Fark (d)	1			

3.3. Bulanık Zaman Serisi ile Zaman Serisinin Karşılaştırılması

Çalışmada, Excel kullanılarak ANFIS ve ARIMA yöntemleri ile elde edilen sonuçların karşılaştırılmasına yönelik kullanılan değerlerin hata kareleri ortalamasının karekökü (RMSE) ve mutlak hata yüzdeleri ortalaması (MAPE) değerleri her iki yöntem için de hesaplanmıştır.

Tablo 26’da verilen (alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı) değişkenlerin ANFIS ile elde edilen RMSE (eğitim ve test verileri) ve hesaplanan MAPE (eğitim ve test verileri) değerleri verilmiştir. Bunun yanı sıra tabloda kullanılan değişkenlerin ARIMA yöntemi ile elde edilen RMSE (eğitim ve test verileri) ve hesaplanan MAPE (eğitim ve test verileri) değerleri de verilmiştir.

Tablo 26. ANFIS ve ARIMA RMSE ve MAPE deęerleri

DEĐİŐKEN	ANFIS				ARIMA			
	Eđitim		Test		Eđitim		Test	
	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
ALEV	1.8628	0.1300	1.7957	0.1415	9.7929	0.6411	15.8003	1.1740
BASINÇ	1.8433	0.1276	1.9602	0.1638	9.8285	0.6483	15.1852	1.2332
HAREKET	0.8241	0.0654	1.3837	0.1088	5.4314	0.3483	2.3490	0.1849
NEM	1.8460	0.1504	3.0157	0.2832	10.7285	0.7942	10.3115	0.7869
SICAKLIK	1.0809	0.0805	4.7564	0.4231	10.8116	0.7636	11.3037	0.6672
YÜZEY SICAKLIK	0.8219	0.0664	0.8901	0.0793	5.2650	0.3486	1.6521	0.1037

Tablo 26’da yer alan RMSE ve MAPE deęerlerine bakıldıđında bu alıŐmada kullanılan, Endüstri 4.0 teknolojisi kullanılan bir fabrikanın üretim hattından sensör yardımı ile alınan zaman serisi verilerinde (alev, basınç, hareket, nem, sıcaklık, yüzey sıcaklığı) ANFIS yöntemi birinci derece Sugeno bulanık mantık ıkarım sistemi

kullanılarak elde edilen veri setlerinin hesaplanan RMSE ve MAPE deęerlerinin, ARIMA yntemi kullanılarak hesaplanan RMSE ve MAPE deęerlerine gre eęitim ve test deęerleri daha dşk olduęu grlmektedir. Bu alıřmada kullanılan veriler iin ANFIS ynteminin daha iyi sonular verdięi istatistiksel olarak %95 gvenilirlikle sylenbilir.



4. SONUÇLAR VE ÖNERİLER

Günümüzde hızlı bir şekilde ilerleyen teknoloji ile anı yakalayabilmek ve işletmenin gelirlerini artırmak ve aynı zamanda işletme olarak bulunduğu konumu koruması gerekmektedir. Bu sebeple ortaya çıkan gelecek tahmini ihtiyacını istatistiksel olarak kullanılabilen veriler ve istatistiksel olarak elde edilen sonuçları yorumlamayı bilmek gerekmektedir. Bugünlerde adından sıkça söz ettiren Bulanık Mantık kavramı sözselle ifadeleri, kurulacak olan modele ekleyebilmesi ya da modelden kullanılabilir ve anlaşılabilir sözselle ifadelerle çıkarım yaparak elde edilen sonuçların kolaylığı bakımından veri kümelerinden kullanılabilir bilgi edinmek amacıyla en çok tercih edilen yöntemlerden biri olmuştur.

Bu tez kapsamında, Endüstri 4.0 teknolojisi kullanan bir fabrikanın hammadde kaybını engellemek, daha uygun üretim planı yapabilmek ve olası kötü durumlar için önlem alabilmek amacıyla fabrikanın üretim hattından sensör yardımıyla elde edilen zaman serisi verilerini klasik zaman serisi ve bulanık zaman serisi yöntemlerine başvurularak veriler üzerinde kullanılan yöntemlerin hangisinin hata kareler ortalamasının (RMSE) ve ortalama mutlak yüzde hatasının (MAPE) en iyi olduğunu görmek, bu çalışmada kullanılan veriler için hangi modelin daha uygun ve daha açıklayıcı olduğunu görmek amacıyla uygulanmıştır.

ANFIS yöntemini kullanabilmek için veri setinin yapısı eğitilmesi gerekmektedir. Eğitim seti ve test seti olarak isimlendirilen veri setleri ANFIS'in etkin sonuçlar vermesi için kullanılmaktadır. Bu sebeple bütün veri kümeleri için eğitim setinin rassal yöntemle seçilmiştir. Çalışma sonuçları incelendiğinde ANFIS modeli ile ARIMA modelinin kıyaslamasında, ANFIS modelinin daha iyi sonuç verdiği görülmüştür. Fakat bu sonuçlar ANFIS model yapısını kurabilmek adına eğitim veri seti ve test veri seti olarak iki gruba ayrılan veri setleri ARIMA modeli içinde kullanıldığında daha iyi sonuç verdiği görülmüştür. Bunun yanı sıra, ANFIS modelinin en az iki girdiye ihtiyaç duyduğu ve az girdi sayısı ile daha etkin sonuçlar verdiği gözlenmiştir.

ANFIS yöntemi geleneksel yöntemlere göre daha az zamana ihtiyaç duymaktadır. Bu yöntemde, veri setleri arası ilişkinin tanımlanması gerektirmez. Veriler arasındaki ilişkiyi eğitim veri seti yoluyla ANFIS kendi kendine öğrenir. ANFIS ve ARIMA bu konuda

karşılaştıracak olursak; ANFIS, veri kümesi için uygun bir model seçimi söz konusu olduğunda ARIMA modeline göre daha az zaman ve efor gerektirmektedir. Bunun yanı sıra daha hassas ölçümler için zaman aralığı daha düşük hale getirilebilir.

Bu tez çalışmasında girdi değişkenleri için iki dilsel değişken tanımlanmıştır, fakat ANFIS de birçok farklı dilsel değişken tanımlanabilir. Burada girdi veri seti ve çıktı değeri, “minimum” ve “maksimum” iki dilsel değişken ile derecelendirebilir. Kurulan bu model veri kümesi içinden anlamlı kurallar türetmektedir. Bu çalışmada, uygulama kısmında modelin ürettiği kurallar verilmiştir. ANFIS modeli; kural değiştirme, tanımlanmış kuralın silinmesine veya yeni kurallar eklenmesine izin vermektedir. ANFIS modelinin mimari yapısının çıktısını verirken, bunun yanı sıra değişkenler arasındaki ilişkinin grafiksel olarak ifade edilmesini mümkün kılar. Bu çalışma için, bulanık mantık yöntemi klasik mantık yöntemine göre daha iyi sonuçlar verdiği görülmektedir. Ancak, ANFIS metodu ile ARIMA metodu arasındaki MAPE değerleri farkının oldukça az olduğu görülmektedir.

ANFIS ve ARIMA yöntemlerinde uygun modelin ortaya çıkarılması esnasında birçok deneme yapılmalıdır. ANFIS verileri için hangi eğitim metodunun kullanılacağı, veri setinin büyüklüğü, kullanılacak üyelik fonksiyonunun tipi, çıktı değerlerinin kalitesini belirler. Bu maddeler deneme yoluyla en iyi sonuç belirlenir. Bu çalışmada, ANFIS yaklaşımı için birinci derece Sugeno yaklaşımı en iyi sonucu verirken, ARIMA yönteminde her veri seti için farklı modeller en iyi sonucu vermiştir. Bu da, ARIMA modelleri için genelleştirme yapılamayacağı anlamına gelmektedir.

Bu çalışmada bulanık küme kuramına dayalı olarak ANFIS yaklaşımı tercih edildi. ANFIS yaklaşımı incelendi ve ANFIS yaklaşımında birinci derece Sugeno bulanık mantık çıkarım sistemi kullanılarak farklı üyelik fonksiyonların öngörüdeki etkisi araştırıldı ve en iyi üyelik fonksiyonu belirlendi. Ayrıca ARIMA yöntemi için en uygun modeller belirlenerek, bunun yanı sıra her iki yöntem için elde edilen RMSE ve MAPE değerleri karşılaştırılmıştır. Endüstri 4.0 teknolojisi kullanılan bir fabrikanın üretim hattından alınan zaman serisi verileri üzerinde ANFIS ve ARIMA modelleri kıyaslandığında ANFIS modelinin daha iyi sonuçlar verdiği gözlenmektedir.

5. KAYNAKLAR

- Akdi, Y., 2003. Zaman Serileri Analizi: (Birim Kökler ve Kointegrasyon), 298, Bıçaklar Kitapevi, Ankara.
- Altaş, İ.H., 1999. Bulanık Mantık: Bulanıklık Kavramı, Enerji, Elektrik, Elektromekanik-3e 62, 80-85.
- Barrow, M., 2009. Statistics for Economics, Accounting and Business Studies, Fifth Edition, Pearson, Essex.
- Başar, A. ve Oktay, E., 2000. Uygulamalı İstatistik 2 Kısa Teorik Bilgiler ve Çözümler Problemler, Aktif Yayınevi, Erzurum.
- Bede, B. 2013. Mathematics of Fuzz Sets and Fuzzy Logic, Springer-Verlag, Berlin Heidelberg.
- Berksun, E., 2018. Sanayide Endüstri 4.0 Süreçleri: Çorum Sanayisinde Bir Uygulama, Yüksek Lisans Tezi, Hitit Üniversitesi, Sosyal Bilimleri Enstitüsü, Çorum.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., 2016. Time Series Analysis Forecasting and Control, Fifth Edition, Canada.
- Brockwell P.J. ve Davis R.A., 2016. Introduction to Time Series and Forecasting, Third Edition, Springer International Publishing Switzerland.
- Buckley J.J., 2005. Fuzzy Probabilities: New Approach and Applications, Studies in Fuzziness and Soft Computing, Springer Berlin Heidelberg.
- Buckley, J. J., 2006. Fuzzy Probability and Statistics, Springer-Verlag Berlin Heidelberg, 196, 7-19, New York.

- Buckley, J.J., 2004. Fuzzy Statistics, Studies in Fuzziness and Soft Computing, Springer Berlin Heidelberg.
- Charles, R.N., 1973. Applied Time Series Analysis For Managerial Forecasting, U.S.A., Holden; Day, Inc., 21.
- Chen, G., ve Pham, T. T., 2000. Introduction to Fuzzy Sets, Fuzzy Logic and Fuzzy Control Systems, CRC Press, Florida.
- Chen, S. M., 1996. Forecasting Enrollments Based On Fuzzy Time Series, Fuzzy Sets and Systems, 81, 3 ,311-319.
- Chen, S. M., 2002. Forecasting Enrollments Based on High-Order Fuzzy Time Series, Cybernetics and Systems: An International Journal, 33, 1, 1-16.
- Chen, S. M., ve Hwang, J. R., 2000. Temperature Prediction Using Fuzzy Time Series, IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, 30, 263–275.
- Cheng, C. H., Chang, J. R., ve Yeh, C. A., 2006. Entropy-based and Trapezoid Fuzzification-based Fuzzy Time Series Approaches for Forecasting IT Project cost, Technological Forecasting and Social Change, 73, 524–543.
- Cheng, CH., Cheng, GW. ve Wang JW., 2008. Multi-Attribute Fuzzy Time Series Method Based on Fuzzy Clustering Expert Systems with Applications, 34, 1235–1242.
- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Uslu, V.R. ve Başaran, M.A., 2009a. A New Approach Based on Artificial Neural Networks for High Order Multivariate Fuzzy Time Series, Expert Systems with Applications, 36, 10589–10594.

- Egrioglu E., Aladağ Ç.H., Yolcu, U., Uslu, V.R ve Başaran, A., 2009b. A New Hybrid Approach Based on SARIMA and Partial High Order Bivariate Fuzzy Time Series Forecasting Model, Expert Systems with Applications, 36, 7424-7434.
- Egrioglu E., Uslu V.R., Yolcu U., Başaran M.A. ve Aladağ Ç.H., 2009c. A New Approach Based on Artificial Neural Networks for High Order Bivariate Fuzzy Time Series, Applications of Soft Computing, AISC 58, Springer-Verlag, Berlin Heidelberg, 265-273.
- Elmas, Ç., 2003. Bulanık Mantık Denetleyiciler (Kuram, Uygulama, Sinirsel Bulanık Mantık), Seçkin Yayıncılık, Ankara.
- Elmas, Ç., 2018. Yapay Zeka Uygulamaları, Seçkin Yayıncılık, 4. Baskı, 479, Ankara.
- Enders, W., 1948. Applied econometric time series, Walter, University of Alabama, Fourth edition.
- Fırat, M., 2007. Sinirsel Bulanık Mantık Yaklaşımı ile Havza Modellemesi, Doktora Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Fuller, W.A., 1976. Introduction to Statistical Time Series, U.S.A.:John-Wiley and Sons Inc., 3.
- Gabaçlı, N. ve Uzunöz, M., 2017. Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü kapsamında “Türkiye Otomotiv Sektörü ve Küresel Rekabet Gücünün Analizi” başlıklı Yüksek Lisans tezinden düzenlenmiştir, İktisat, IV.Sanayi Devrimi: Endüstri 4.0 ve Otomotiv Sektörü, 3rd International Congress on Political, Economic and Social Studies (ICPESS).
- Güner, N. ve Çomak, E. 2014. Lise Öğrencilerinin Matematik Dersine Yönelik Tutumlarının Bulanık Mantık Yöntemi ile İncelenmesi, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 20, 5, 189-196.

- Gürbüz, H., 1997. Zaman Serilerinin Durağanlaştırılmasında Birim Kök Testi ve Eşbütünleşme, Doktora Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta.
- İşbilen Yücel, L., 2018. Bulanık Teorinin Ekonometrik Uygulamaları, 98, Der Kitabevi Yayınevi, İstanbul.
- Jang, R.Jyh-Shing, 1993. ANFIS: Adaptive-Network-Based Fuzzy Inference System, IEEE Transactions On Systems, Man, and Cybernetics, 23, 3, 665-685.
- Jequirim, S. E-G., Dhouib, A. B., Sahnoun, M., Cheikhrouhou, M., Schacher, L. ve Adolphe, D., 2009. The Use of Fuzzy Logic and Neural Networks Models for Sensory Properties Prediction from Process and Structure Parameters of Knitted Fabrics, Journal of Intelligent Manufacturing, 1572-8145 (Online).
- Huarng, K., 2001a. Effective Lengths of Intervals to Improve Forecasting in Fuzzy Time Series, Fuzzy Sets and Systems, 123, 387–394.
- Huarng, K., 2001b. Heuristic Models of Fuzzy Time Series for Forecasting, Fuzzy Sets and Systems, 123, 369–386.
- Huarng, K., ve Yu, H. K., 2005. A Type 2 Fuzzy Time Series Model for Stock Index Forecasting, Physica A, 353, 445–462.
- Huarng, K., ve Yu, H. K., 2006a. Ratio-based Lengths of Intervals to Improve Fuzzy Time Series Forecasting. IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, 36, 328–340.
- Huarng, K., ve Yu, H.-K., 2006b. The Application of Neural Networks to Forecast Fuzzy Time Series, Physica A, 363, 481-491.
- Huarng, K. ve Yu, H.-K., 2008. A Bivariate Fuzzy Time Series Model to Forecast TAIEX, Expert Systems with Applications, 34, 2945-2952.

- Hsu, Y. Y., Tse, S. M., ve Wu, B., 2003. A New Approach of Bivariate Fuzzy Time Series Analysis to The Forecasting of A Stock Index, International Journal of Uncertainty, Fuzziness, and Knowledge-based Systems, 11, 671–690.
- Hwang, J. R., Chen, S. M., ve Lee, C. H., 1998. Handling Forecasting Problems Using Fuzzy Time Series, Fuzzy Sets and Systems, 100, 217–228.
- Jilani, T.A., ve Burney, S.M.A., 2007. M-factor High Order Fuzzy Time Series Forecasting for Road Accident Data: Analysis and Design of Intelligent Systems Using Soft Computing Techniques, Advances in Soft Computing, 41, 246–254.
- Jilani, T.A., ve Burney, S.M.A., 2008. Multivariate Stochastic Fuzzy Forecasting Models, Expert Systems with Applications, 35, 3, 691–700.
- Jilani, T.A., ve Burney, S.M.A., Ardil, C., 2007. Multivariate High Order Fuzzy Time Series Forecasting for Car Road Accidents, International Journal of Computational Intelligence, 4, 1, 15–20.
- Kablan, A., 2018. Endüstri 4.0, “Nesnelerin İnterneti” - Akıllı İşletmeler ve Muhasebe Denetimi, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Endüstri 4.0 ve Örgütsel Değişim Özel Sayısı, 23, 1561-1579.
- Klir, G.J. ve Yuan, B., 1995. Fuzzy Sets and Fuzzy Logic: Theory and Applications, Prentice Hall, Upper Saddle River, N.J.
- Mamdani, E. H., 1974. Application of Fuzzy Algorithms for Control of Simple Dynamic Plant, Proceedings of The Institution of Electrical Engineers, 121, 12, 1585-1588.
- Moore, R.E., 1979. Methods and Applications of Interval Analysis, SIAM Studies in Applied Mathematics, Philadelphia.

- Mrugalska, B., ve Wyrwicka, M.K., 2017. Towards Lean Production in Industry 4.0, Procedia Engineering, 182, 466- 473.
- Nayak, P.C., Sudheer, K.P., ve Ramasastry, K.S., 2005. Fuzzy Computing Based Rainfall-Runoff Model for Real Time Flood Forecasting, Hydrological Processes, 19, 955–968 .
- Neumaier, A., 1990. Interval Methods for Systems of Equations, Cambridge University Press, Cambridge, U.K.
- Özdağođlu, A., 2016. Bulanık İşlemler Durulaştırma ve Sözel Eşikler, 1. Baskı, 143, Detay Yayıncılık, Ankara.
- Özek, T., 2010. Zaman Serisi Modelleri Üzerine Bir Simülasyon Çalışması, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Özkan, M.M., 2003. Bulanık Hedef Programlama, Ekin Kitapevi, 288, Bursa.
- Özmen, A., 1986. Zaman Serileri Analizinde Box-Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi, T.C. Anadolu Üniversitesi Yayınları No:207, Fen Edebiyat Fakültesi Yayınları No:9, Eskişehir.
- Öztaş, T., 2015. Bulanık Zaman Serilerinin Talep Tahminlerde Kullanılmasına Yönelik İşletme Uygulaması, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Sosyal Bilimler Enstitüsü, Denizli.
- Paksoy, T., Yapıcı Pehlivan, N. ve Özceylan, E., 2013. Bulanık Küme Teorisi, 1. Baskı, 214, Nobel Yayıncılık, Ankara.
- Pedrycz, W., 1989. Fuzzy Control and Fuzzy Systems, Research studies press, 22, Taunton.

- Schuh, G., Potente, T., Wesch, C., Weber, A.R., ve Prote, J.P., 2014. Collaboration Mechanisms to Increase Productivity in The Content of Insdustrie 4.0, Robust Manufacturing Conference, 51-56, Elsivier B:V.
- Sofyaliođlu, Ç., ve Öztürk, Ş., 2013. Bir Çimento Firması İçin Dönemsel Satış Miktarlarının Tahmininde Bulanık Zaman Serisi Modellerinin Karşılaştırılması, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 18, 3, 161-186.
- Song, Q., ve Chissom, B. S., 1993a. Forecasting Enrollments With Fuzzy Time Series – Part I, Fuzzy Sets and Systems, 54, 1, 1-9.
- Song, Q., ve Chissom, B. S., 1993b. Fuzzy Time Series And Its Models, Fuzzy Sets and Systems, 54, 3, 269-277.
- Song, Q., ve Chissom, B. S., 1994. Forecasting Enrollments With Fuzzy Time Series – Part II, Fuzzy Sets and Systems, 62, 1, 1-8.
- Sullivan, J., ve Woodall, W. H., 1994. A Comparison of Fuzzy Forecasting and Markov Modeling, Fuzzy Sets and Systems, 60, 279–293.
- Şen, Z., 2010. Fuzzy Logic and Hydrological Modeling, CRC Press, Florida.
- Şengül, S., Köleođlu, N., Ođuzhan, A., Kayış, A.A., Çađlar A., Göktaş, A., Çankal, E., Kral, G., Öztürk, L., Gerşil, M., Omay, R.E., ve Aytemiz, T., 2010. İstatistik, Şengül, S., ve Kral, G., Bölüm Yazarı: Saraçlı, S., 1. Baskı, 383, Lisans Yayıncılık, İstanbul.
- Şener, S., ve Eleveli, B., 2017. Endüstri 4.0’da Yeni İş Kolları ve Yüksek Öğrenim, Mühendis Beyinler, 25-37.

- Takagi, T., ve Sugeno, M., 1985. Fuzzy Identification of Systems and Its Applications to Modeling and Control, IEEE Transactions on Systems, Man, and Cybernetics, 15, 1.
- Terano, T., Asai, K. ve Sugeno, M., 1987. Fuzzy Systems Theory and Its Applications, Academic Press Inc: Boston.
- Türkşen, İ.B., 2015. Bulanık Mantık-Dereceli Bulanık Sistem Modelleri, 1. Baskı, 295, Abaküs Yayınları, İstanbul.
- Tsai, C. C., ve Wu, S. J., 1999. A Study for Second-Order Modeling of Fuzzy Time Series, Presented at IEEE International Fuzzy Systems Conference Proceedings, Seoul, Korea.
- Tsai, C. C., ve Wu, S. J., 2000. Forecasting Enrollments With High-Order Fuzzy Time Series, Presented at Fuzzy Information Processing Society, NAFIPS, 19th international conference of the North American.
- Tsai, C. C., ve Wu, S. J., 2001. Forecasting Local Region Data With Fuzzy Time Series, Presented at IEEE International Symposium on Industrial Electronics.
- Ural, G.F., 2006. Bulanık Doğrusal Programlama Yöntemi Kullanılarak Bir Sanayi Kuruluşunda Üretim Planlama Çalışmasının Gerçekleştirilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Kocaeli.
- URL-1, <http://farabi.sutef.gen.tr/bulanik/bulanik/bolum02.htm> Bulanık Kümeler. 14 Mayıs 2019.
- URL-2, <http://portal.netcad.com.tr/pages/viewpage.action?pageId=104794233> Bulanık Mantık. 14 Mayıs 2019.

URL-3,<https://ch.mathworks.com/help/fuzzy/fismf.html#d117e44898>ÜyelikFonksiyonları.
14 Mayıs 2019.

Wei, W.W.S., 1990. Time Series Analysis: Univariate and Multivariate Methods, Addison-Wesley Publishing Company, Inc.

Yolcu, U., 2011. Bulanık Zaman Serilerinde Çok Değişkenli Çözümleme, Doktora Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.

Yu, H. K., 2005a. Weighted Fuzzy Time Series Models for TAIEX Forecasting, Physica A, 349, 609–624.

Yu, H. K., 2005b. A Refined Fuzzy Time-Series Model for Forecasting, Physica A, 346, 657–681.

Yücel, A., 2010. Tedarikçi Seçimi Problemlerinde Bütünleşik Sinirsel Bulanık Mantık Yaklaşımı, Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

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

Zadeh, L. A., 1975a. The Concept of a Linguistic Variable and its Application to Approximate Reasoning-I, Information Sciences, 8, 3, 199-249.

Zadeh, L. A., 1975b. The Concept of a Linguistic Variable and Its Application to Approximate Reasoning II. Information Science, 8, 301–357.

Zadeh, L. A., 1975c. The Concept of a Linguistic Variable and Its Application to Approximate Reasoning III. Information Science, 9, 43–80.

Zadeh, L. A., 1990. The Birth and Evolution of Fuzzy Logic, International Journal of General Systems, 17, 2-3, 95-105.

Zhao, J., ve Bose, B. K., 2002. Evaluation of Membership Functions for Fuzzy Logic Controlled Induction Motor Drive, Proceedings of the 2002 28th Annual Conference of the IEEE Industrial Electronics Society, 1, 4, 229-234.



ÖZGEÇMİŞ

Buket İPEK, 22 Kasım 1993 tarihinde Merzifon'da doğdu. Orta öğrenimini Ankara İMKB Anadolu Ticaret Meslek Lisesi, Bilgisayar Programlama Bölümü, Web Tasarım Dalını tamamladıktan sonra 2013 yılında Karadeniz Teknik Üniversitesi, Beşikdüzü Meslek Yüksek Okulu, Bilgisayar Programcılığı Bölümünden mezun oldu. 2016 yılında Afyon Kocatepe Üniversitesi, Fen Fakültesi, İstatistik Bölümünden mezun oldu. 2016-2017 eğitim öğretim yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Anabilim Dalı'nda tezli yüksek lisans programına başladı. 2017-2018 eğitim öğretim yılı bahar döneminde eğitimini Erasmus programı kapsamında Slovakya Comenius University in Bratislava'da sürdürmüştür.