

**KONTROL VE SİSTEM TANIMLAMA  
UYGULAMALARI İÇİN ÇOK KATMANLI  
DİNAMİK BULANIK AĞ TASARIMLARI**

Sevcan Yılmaz  
Doktora Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Kasım, 2014

Bu tez çalışması TÜBİTAK tarafından desteklenmiştir. Proje No: 113E579

## **JÜRİ VE ENSTİTÜ ONAYI**

**Sevcan Yılmaz'ın "Kontrol ve Sistem Tanımlama Uygulamaları için Çok Katmanlı Dinamik Bulanık Ağ Tasarımları" başlıklı Bilgisayar Mühendisliği Anabilim Dalındaki, Doktora Tezi 11.11.2014 tarihinde, aşağıdaki jüri tarafından Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.**

**Adı-Soyadı**

**İmza**

**Üye (Tez Danışmanı) : Prof. Dr. YUSUF OYSAL**

**Üye : Prof. Dr. AYDIN AYBAR**

**Üye : Doç. Dr. RİFAT EDİZKAN**

**Üye : Doç. Dr. SERKAN GÜNAL**

**Üye : Yard. Doç. Dr. AHMET YAZICI**

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

**Enstitü Müdürü**

**ÖZET**  
**Doktora Tezi**  
**KONTROL VE SİSTEM TANIMLAMA**  
**UYGULAMALARI İÇİN ÇOK KATMANLI DİNAMİK BULANIK AĞ**  
**TASARIMLARI**

**Sevcan YILMAZ**

**Anadolu Üniversitesi**  
**Fen Bilimleri Enstitüsü**  
**Bilgisayar Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Yusuf OYSAL**  
**2014, 106 sayfa**

Bu tezde, üç farklı yeni nöro-bulanık sinir ağı modeli, sistem tanıma ve kontrol problemleri için önerilmektedir. Önerilen modellerin yapısı, bilinmeyen bir fonksiyonun giriş-çıkış verilerinden bulanık kural tabanı elde etmek için kullanılan adaptif nöro bulanık çıkarım sistemi (ANFIS) fikrinden gelmektedir. Birinci model, tip-2 bulanık dalgacık sinir ağı (T2FWNN) 'dir. T2FWNN yapısında, kuralların üyelik fonksiyonları alışılmış bulanık kümelerden farklı olarak zaman ve frekansta yerellik özelliklerine sahip tip-2 dalgacık fonksiyonları ile temsil edilmektedir. Kuralların sonuç kısmında ise dalgacık fonksiyonlarının ağırlıklı toplamı kullanılmıştır. İkinci model, dinamik adaptif nöro bulanık çıkarım sistemi (DANFIS) 'dir. DANFIS, her bir kuralın sonuç bölümünde sabit terim ile birlikte yerel lineer dinamikleri içeren Takagi-Sugeno afın bulanık model bir sinir ağının temsilidir. Böylece, DANFIS ile lineer olmayan dinamik bir sistemin iç davranışının modellenmesi mümkün olacaktır. DANFIS'te, üyelik fonksiyonu olarak Gauss fonksiyonları kullanılmıştır ve kuralların sonuç kısmı ise girişlerin lineer diferansiyel denklemi ile temsil edilmektedir. DANFIS'e ait uygun parametreler gradyan tabanlı öğrenme algoritması ve ek duyarlılık analizi ile belirlenir. Tezin üçüncü bölümünde DANFIS modelinden farklı olarak dalgacık fonksiyonları üyelik fonksiyonu olarak kullanılmaktadır ve yeni ağ dinamik bulanık dalgacık sinir ağı (DFWNN) olarak adlandırılmıştır. Simülasyon sonuçları, önerilen T2FWNN, DANFIS, DFWNN modellerinin etkinliğini göstermek için, sistem tanıma ve kontrol problemleri için verilmiştir.

**Anahtar Kelimeler:** Tip-2 Bulanık Dalgacık Sinir Ağı, Dinamik Adaptif Nöro-Bulanık Çıkarım Sistemi, Dinamik Bulanık Dalgacık Sinir Ağı, Sistem Tanımlama, Kontrol

**ABSTRACT**  
**PhD Dissertation**

**MULTILAYER DYNAMIC FUZZY NEURAL NETWORK DESIGN FOR  
CONTROL AND SYSTEM IDENTIFICATION APPLICATIONS**

**Sevcan YILMAZ**

**Anadolu University  
Graduate School of Sciences  
Computer Engineering Program**

**Supervisor: Prof. Dr. Yusuf OYSAL**  
**2014, 106 pages**

In this thesis, three different new neuro-fuzzy neural network models have been proposed for system identification and control problems. The structure of introduced models comes from the idea of adaptive neuro-fuzzy inference system (ANFIS) which is used for obtaining fuzzy rule base from the input-output data of an unknown function. The first model is type-2 fuzzy wavelet neural network (T2FWNN). In the T2FWNN structure, membership functions of fuzzy rules are represented with type-2 wavelet functions which have time and frequency localization properties, unlike the conventional fuzzy sets. In the consequent part of the rules, the weighted summation of wavelet functions is used. The second model is dynamic adaptive neuro-fuzzy inference system (DANFIS). DANFIS is a neural network representation of Takagi-Sugeno affine fuzzy model that incorporates local linear dynamics with bias terms into consequent parts of each fuzzy rule. Thus, the internal behavior of a nonlinear dynamical system will be able to be modeled with DANFIS. In DANFIS, Gaussian functions are used as membership functions and consequent part of the rules are represented with linear differential equation of the inputs. The suitable parameters of DANFIS are determined by gradient based training algorithm and adjoint sensitivity method. In the third model, wavelet functions are used as membership function different than DANFIS model and new network is called as dynamic fuzzy wavelet neural network (DFWNN). Simulation results are given to demonstrate the effectiveness of the proposed T2FWNN, DANFIS, DFWNN models for system identifications and control problems.

**Keywords:** Type-2 Fuzzy Wavelet Neural Network, Dynamic Adaptive Neuro-Fuzzy Inference System, Dynamic Fuzzy Wavelet Neural Network, System Identification, Control

## TEŐEKKÜR

Tez alıőmam sırasında yaptıđı rehberlik ve destek iin danıőmanım Prof. Dr. Yusuf Oysal'a teőekkürü bir bor bilirim.

Ayrıca, tez komitemde bulunan Prof. Dr. Aydın Aybar, Do. Dr. Rifat Edizkan, Do. Dr. Serkan Gunal ve Yard. Do Dr. Ahmet Yazıcı'ya deđerli katkılarından dolayı teőekkürlerimi sunarım.

Bu tezin bir kısmı 113E579 proje numarasıyla TÜBİTAK tarafından desteklenmiştir. TÜBİTAK'a maddi katkılarından dolayı teőekkür ederim.

Son olarak, benden hiçbir zaman sevgisini ve desteđini esirgemeyen sevgili aileme itenlikle teőekkür ederim.

Sevcan YILMAZ

Kasım, 2014

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>İÇİNDEKİLER</b> .....	<b>iv</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>vii</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>x</b>
<b>KISALTMALAR</b> .....	<b>xii</b>
<b>1. GİRİŞ</b>	<b>1</b>
1.1. Kapsam ve Tezde Önerilen Modeller .....	8
1.2. Tez İçeriği .....	9
<b>2. GENEL BİLGİLER</b>	<b>10</b>
2.1. Tip-1 Nöro-Bulanık Çıkarım Sistemleri .....	10
2.2. Tip-2 Bulanık Sistemlere Bakış .....	12
2.3. Dalgacık Fonksiyonlarına Bakış .....	15
<b>3. SİSTEM TANIMA UYGULAMALARI İÇİN TİP-2 BULANIK DALGACIK SİNİR AĞI (T2FWNN) MODELİ TASARIMI</b>	<b>20</b>
3.1. Giriş.....	20
3.2. T2FWNN Modellerinin Yapısı .....	21
3.3. T2FWNN Öğrenme Algoritması .....	25
3.4. Sistem Tanıma Sonuçları .....	29
3.4.1. Örnek 1 .....	30
3.4.2. Örnek 2 .....	32
3.4.3. Örnek 3 .....	34
3.5. Sonuçlar .....	36

<b>4. SİSTEM MODELLEME VE KONTROL UYGULAMALARI İÇİN DİNAMİK ADAPTİF NÖRO-BULANIK ÇIKARIM SİSTEMİ (DANFIS) TASARIMI</b>	<b>37</b>
4.1. Giriş.....	37
4.2. DANFIS Yapısı.....	39
4.3. DANFIS Öğrenme Algoritması .....	42
4.3.1. DANFIS Gradyan Hesabı .....	46
4.3.2. Gradyan bilgisiyle parametre güncelleme.....	49
4.4. DANFIS ile Denetleyici Tasarımı.....	50
4.5. Sonuçlar .....	52
<b>5. SİSTEM MODELLEME VE KONTROL UYGULAMARI İÇİN DİNAMİK BULANIK DALGACIK SİNİR AĞI (DFWNN) TASARIMI</b>	<b>53</b>
5.1. Giriş.....	53
5.2. DFWNN Yapısı.....	54
5.3. DFWNN Öğrenme Algoritması .....	58
5.4. DFWNN ile Denetleyici Tasarımı .....	62
5.5. Sonuçlar .....	63
<b>6. DANFIS VE DFWNN İLE BENZETİM SONUÇLARI</b>	<b>64</b>
6.1. DANFIS ve DFWNN ile Modelleme Sonuçları .....	64
6.1.1. Van der Pol osilatörü.....	64
6.1.2. Sürekli karıştırılmalı tank reaktör sistemi (CSTR).....	70
6.1.3. Biyoreaktör.....	81
6.2. DANFIS ve DFWNN Modelleri ile Denetleyici Tasarımı Sonuçları .....	87
6.2.1. CSTR kontrolü .....	88
6.2.2. Bioreaktör kontrolü .....	91
6.3. Sonuçlar .....	93
<b>7. SONUÇLAR</b>	<b>95</b>





## ŞEKİLLER DİZİNİ

Şekil 2.1. ANFIS Yapısı .....	10
Şekil 2.2. Tip-2 bulanık mantık sistemi .....	12
Şekil 2.3. Belirsiz standart sapma ile tip-2 bulanık kümesi ( $\sigma = [0.1, 0.15]$ ) .....	14
Şekil 2.4. Belirsiz orta nokta ile tip-2 bulanık kümesi ( $\mu = [0.45, 0.55]$ ) .....	14
Şekil 2.5. Gauss ve Meksika Şapkası dalgacık fonksiyonları.....	16
Şekil 2.6. Gauss ve Meksika Şapkası dalgacık fonksiyonunun Fourier dönüşümü .....	16
Şekil 2.7. Meksika Şapkası dalgacık fonksiyonunda öteleme parametresinin etkisi .....	17
Şekil 2.8. Meksika Şapkası fonksiyonunda genişlik parametresinin etkisi .....	18
Şekil 2.9. Meksika Şapkası fonksiyonun Fourier dönüşümünde genişlik parametresinin etkisi .....	18
Şekil 3.1. T2FWNN-M1 yapısı.....	22
Şekil 3.2. T2FWNN-M2 yapısı.....	22
Şekil 3.3. T2FWNN-M2’de Örnek 1 için gürültü olmadan eğitim performansı ..	31
Şekil 3.4. T2FWNN-M2’de Örnek 1 için gürültü olmadan test performansı .....	31
Şekil 3.5. Gürültü olmadan Örnek-2 için T2FWNN-M2 eğitim performansı .....	33
Şekil 3.6. std=0.1 gürültülü Örnek-2 için T2FWNN-M2 eğitim performansı.....	34
Şekil 3.7. Box Jenkins veri setinin T2FWNN-M2 eğitim ve test sonuçları .....	35
Şekil 4.1. DANFIS ve DFWNN yapısı.....	40
Şekil 4.2. DANFIS öğrenme süreci .....	43
Şekil.5.1. (a) Meksika Şapkası ve normalleştirilmiş Meksika Şapkası dalgacık fonksiyonları (b) Fourier dönüşümleri.....	56
Şekil 6.1. VDP osilatörü için iterasyon sayısına karşı eğitim performans değerleri (4.15).....	65
Şekil 6.2. VDP osilatörü için $x(0)=[5,0]$ başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a) $x_1$ (b) $x_2$ .....	66
Şekil 6.3. VDP osilatörü için $x(0)=[5,0]$ başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a) $x_1$ (b) $x_2$ .....	67

<b>Şekil 6.4.</b> VDP osilatörü için $x(0)=[3,0.5]$ başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	68
<b>Şekil 6.5.</b> VDP osilatörü için $x(0)=[3,0.5]$ başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	69
<b>Şekil 6.6.</b> Sıfır-giriş CSTR için iterasyon sayısına karşı eğitim performans değerleri (4.15).....	71
<b>Şekil 6.7.</b> Sıfır-giriş CSTR için $x(0)=[0,0]$ başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	72
<b>Şekil 6.8.</b> Sıfır-giriş CSTR için $x(0)=[0,0]$ başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	73
<b>Şekil 6.9.</b> Sıfır-giriş CSTR için $x(0)=[-0.1,-0.1]$ başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	74
<b>Şekil 6.10.</b> Sıfır-giriş CSTR için $x(0)=[-0.1,-0.1]$ başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	75
<b>Şekil 6.11.</b> CSTR PRBS giriş cevabı için beklenen $x_1$ ve $x_2$ değerleri .....	76
<b>Şekil 6.12.</b> CSTR, PRBS giriş cevabı için iterasyon sayısına karşı eğitim performans değerleri (4.15).....	77
<b>Şekil 6.13.</b> CSTR PRBS giriş cevabı için $x(0)=[0,0]$ başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	78
<b>Şekil 6.14.</b> CSTR PRBS giriş cevabı için $x(0)=[0,0]$ başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	79
<b>Şekil 6.15.</b> CSTR PRBS giriş cevabı için $x(0)=[0.1,0.1]$ başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ ..	80
<b>Şekil 6.16.</b> CSTR PRBS giriş cevabı için $x(0)=[0.1,0.1]$ başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ ..	81
<b>Şekil 6.17.</b> Biyoreaktörün PRBS giriş cevabı için beklenen $x_1$ ve $x_2$ değerleri ....	82
<b>Şekil 6.18.</b> Biyoreaktör PRBS giriş cevabı için iterasyon sayısına karşı eğitim performans değerleri (4.15).....	83
<b>Şekil 6.19.</b> Biyoreaktör PRBS giriş cevabı için $x(0)=[0.1090, 0.7920]$ başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri <b>(a)</b> $x_1$ <b>(b)</b> $x_2$ .....	84

<b>Şekil 6.20.</b> Biyoreaktör PRBS giriş cevabı için $x(0)=[0.1090, 0.7920]$ başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a) $x_1$ (b) $x_2$ .....	85
<b>Şekil 6.21.</b> Biyoreaktör PRBS giriş cevabı için $x(0)=[0.135, 0.540]$ başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a) $x_1$ (b) $x_2$ .....	86
<b>Şekil 6.22.</b> Biyoreaktör PRBS giriş cevabı için $x(0)=[0.135, 0.540]$ başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a) $x_1$ (b) $x_2$ .....	87
<b>Şekil 6.23.</b> Besleme sıcaklığı 40.s’de 295°K’den 300°K’ya yükseltildiğinde $x(0)=[-0.2, -0.2]$ başlangıçlı CSTR sistem cevabı (a) DANFIS-LQR denetleyici kullanıldığında (b) DFWNN-LQR denetleyici kullanıldığında .....	90
<b>Şekil 6.24.</b> $x(0)=[0.135, 0.540]$ başlangıçlı biyoreaktör sistem cevabı (a) DANFIS-LQR denetleyici kullanıldığında (b) DFWNN-LQR denetleyici kullanıldığında .....	93

## ÇİZELGELER DİZİNİ

<b>Çizelge 3.1.</b> Sistem tanımlama örnek 1 için eğitim sonuçları.....	32
<b>Çizelge 3.2.</b> Sistem tanımlama örnek 1 için test sonuçları .....	32
<b>Çizelge 3.3.</b> Sistem tanımlama örnek 1'in gürültüsüz performansının diğer bulanık sinir ağlarıyla karşılaştırılması .....	32
<b>Çizelge 3.4.</b> Örnek-2 için eğitim sonuçları .....	34
<b>Çizelge 3.5.</b> Örnek-2'nin gürültü olmadığı durumda diğer ağlarla eğitim performansının karşılaştırılması.....	34
<b>Çizelge 3.6.</b> Box Jenkins veri setinin eğitim sonuçları .....	35
<b>Çizelge 3.7.</b> Box Jenkins veri setinin test sonuçları .....	35
<b>Çizelge 6.1.</b> VDP osilatörü için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri .....	66
<b>Çizelge 6.2.</b> Sıfır-giriş CSTR için 5 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri .....	72
<b>Çizelge 6.3.</b> CSTR PRBS giriş cevabı için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri .....	77
<b>Çizelge 6.4.</b> Biyoreaktör için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri.....	83
<b>Çizelge 6.5.</b> DANFIS ve DFWNN denetleyicilerinin performans indeksleri (Yesil ve ark., 2004; Oysal, 2005) .....	88
<b>Çizelge 6.6.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[0,0]$ başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	89
<b>Çizelge 6.7.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[-0.2, -0.2]$ başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	89
<b>Çizelge 6.8.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[0.5, 0.5]$ başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	90
<b>Çizelge 6.9.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[0.009,0.009]$ başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	92
<b>Çizelge 6.10.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[0.1090, 0.7920]$ başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	92

<b>Çizelge 6.11.</b> DANFIS-LQR ve DFWNN-LQR ile $x(0)=[0.135, 0.540]$ başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri.....	92
--	----

## KISALTMALAR

ANFIS	: Adaptif Nöro-Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System)
BFGS	: Broyden-Fletcher-Goldfarb-Shanno
CSTR	: Sürekli Karıştırmalı Tank Reaktör (Continuously Stirred Tank Reactor)
DANFIS	: Dinamik Adaptif Nöro-Bulanık Çıkarım Sistemi (Dynamic Adaptive Neuro-Fuzzy Inference System)
DFWNN	: Dinamik Bulanık Dalgacık Sinir Ağı (Dynamic Fuzzy Wavelet Neural Network)
DFP	: Davidon-Fletcher-Powel
FWNN	: Bulanık Dalgacık Sinir Ağı (Fuzzy Wavelet Neural Network)
LSE	: En Küçük Kareler Tahmin Yöntemi (Least Square Estimation)
LQR	: Lineer Kuadratik Düzenleyici (Linear Quadratic Regulator)
MIMO	: Çok Girişli Çok Çıkışlı (Multi input multi output)
MAPE	: Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)
PRBS	: Rasgele Özellikli İkili Dizi (Pseudo Random Binary Sequence)
RMSE	: Kök ortalama kare hatası (Root Mean Square Error)
T-S	: Takagi- Sugeno
T1FWNN	: Tip-1 Bulanık Dalgacık Sinir Ağı (Type-1 Fuzzy Wavelet Neural Network)
T2FWNN	: Tip-2 Bulanık Dalgacık Sinir Ağı (Type-2 Fuzzy Wavelet Neural Network)

T2FWNN-M1 : Tip-2 Bulanık Dalgacık Sinir Ağı Model 1  
(Type-2 Fuzzy Wavelet Neural Network Model 1)

T2FWNN-M2 : Tip-2 Bulanık Dalgacık Sinir Ağı Model 2  
(Type-2 Fuzzy Wavelet Neural Network Model 2)

VDP : Van der Pol

WNN : Dalgacık Sinir Ağı  
(Wavelet Neural Network)

## 1. GİRİŞ

Bulanık mantık sistemleri, çeşitli lineer olmayan süreçlerin modellemek için kullanılan etkili yapay zekâ ile hesaplama yöntemlerinden biridir. Günümüze kadar, birçok endüstriyel uygulamalarda kullanılmıştır. Bu sistemlerin, herhangi bir lineer olmayan fonksiyonu belirli bir doğruluk derecesinde modellemek için uygulanabilirliği kanıtlanmıştır. Bulanık sistemlerin kullanılmasının ana nedeni, uzman bilgisinin dilsel kurallarla gösterilmesiyle lineer olmayan sistemlerin modellenmesidir. Ancak bazı lineer olmayan sistemler için uzmanlar tarafından bulanık kuralların elde edilmesi kolay değildir ya da imkânsızdır. Bulanık sistemi kural tabanı ile beraber tasarlamak için, sistematik yöntemlerden birisi de, sinir ağlarının öğrenme mekanizması ile bulanık sistemleri birleştirmektir. Bu ikisinin birleşiminden oluşan sistemler “nöro-bulanık sistemler” olarak adlandırılır. Bu sistemler giriş-çıkış verisinden direk olarak kuralları öğrenebilmesinin avantajını sunarken aynı zamanda uzman bilgisini de sağlamaktadır (Horikawa ve ark., 1992; Jang, 1993; Juang ve Lin, 1998; Kim ve Kasabov, 1999). Nöro-bulanık sistemler, birçok lineer olmayan dinamik sistemin modellenmesinde ve kontrolünde, hızlı ve doğru öğrenme özelliklerine sahiptir. En popüler nöro-bulanık sistem adaptif nöro-bulanık çıkarım sistemi (ANFIS)'dir (Jang, 1993). Nöro-bulanık sistemler, yapay sinir ağlarının düşük-düzeyle öğrenmesi ve hesaplama gücü ile bulanık sistemlerin insan gibi düşünme avantajını bütünleştirir (Lin ve Lee, 1996). ANFIS iyi bir kestirici, tahmin edici, evrensel yakınsayıcı ve enterpolatör yöntemi olarak geniş alanda çeşitli yararlı uygulamalarda kullanılmıştır. Birçok uygulama göstermiştir ki, ANFIS yapay sinir ağlarının çevrimdışı hızlı öğrenme özelliklerine sahiptir ve lineer olmayan fonksiyonun yaklaşık değerinin hesaplanması ANFIS ile kolayca yapılabilmektedir.

Yapay sinir ağlarının öğrenme yöntemlerini kullanarak olağan bulanık sistem tasarımında; üyelik fonksiyonları ve bulanık kurallar yapılandırılırken çoğunlukla uzman bilgisi ile öğrenme algoritması birleştirilmektedir. Bu aşamada modellenecek ya da kontrol edilecek sistemin elimizde olan verileri kullanılır. Ancak çoğu durumda, sistemden ölçülen veri çeşitli formlarda belirsizlik içerebilmektedir ve bu da bulanık sistem tasarlarken dikkat edilmesi gereken



konulardan birisidir. Elde ettiğimiz verilerde, eksiklik, kesin olmama, tamamen güvenilir olmama gibi bilgi eksikliği varsa bu belirsizlik sistem tasarımını etkilemektedir (Klir ve Yuan, 1995; Castillo ve Melin, 2008). Tip-1 bulanık sistemleri  $[0, 1]$  aralığındaki üyelik fonksiyonu değerleriyle bu belirsizliğin üstesinden gelmektedir. Ancak, ölçüm cihazlarının hassasiyeti, ölçüm cihazlarındaki gürültü ya da çevresel etkiler nedeniyle oluşan ölçüm belirsizliği gibi belirsizlik durumlarında, uygun ve doğru bir şekilde üyelik fonksiyonu belirlemek kolay ve olası olmayabilir. Bu nedenle, bu belirsizlikleri giderebilmek için bulanık kümelerin ikinci bir çeşidine ihtiyacımız vardır ve bu kümeler tip-2 bulanık kümeler (Zadeh, 1975) olarak adlandırılmaktadır. Tip-2 bulanık sistemleri, gürültülü veri ve çevre değişimlerinin sistem üzerindeki etkisi gibi belirsizliklerin etkisini azaltmaktadır. Çünkü tip-2 bulanık sistemleri, modelleme belirsizliği ve bilgi güvensizliğinden kaynaklanan belirsizlikleri giderebilme özelliklerine sahiptir (Liang ve Mendel, 2000).

Tip-2 bulanık sistemlerinde birincil ve ikincil olmak üzere iki çeşit üyelik fonksiyonu vardır. Birincil üyelik fonksiyonları  $[0, 1]$  kapalı aralığındaki değerleri alabilmektedirler. Diğer yandan, her bir birincil üyelik fonksiyonuna karışık gelen ikincil üyelik fonksiyonları vardır ve bunlar birincil üyelik fonksiyonlarının olasılığını ifade etmektedir (Liang ve Mendel, 2000). Bu ikincil üyelik fonksiyonları da  $[0, 1]$  kapalı aralığındaki değerleri alabilirler. Lineer olmayan dinamik sistem tanıma problemlerindeki bazı önemli belirsizlikleri giderebilmek için bu tip-2 üyelik fonksiyonları kuralların koşul ve/veya sonuç kısmında kullanılabilir (Karnik ve ark., 1999; Liang ve Mendel, 2000). Tip-2 bulanık kümeleri üç boyutlu yapısı nedeniyle hesaplama karmaşıklığını arttırmasına rağmen, son zamanlarda tip-2 nöro-bulanık sistemleri birçok farklı alanlarda uygulanmıştır. Bunlar, lineer olmayan sistemlerin tanımlaması (Wang ve ark., 2004a; Juang ve Tsao, 2008; Castro ve ark., 2009; Aliev ve ark., 2011; Mendez ve Hernandez, 2013; Tung ve ark., 2013), kontrol (Lin ve Chou, 2009; Abiyev ve ark., 2013), zaman serisi tahmini (Castro ve ark., 2011), gürültülü regresyon (Juang ve ark., 2010), sistem modelleme (Singh ve ark., 2009; Yeh ve ark., 2011; Tung ve ark., 2013), stok ücret tahmini (Liu ve ark., 2012) ve mobil robotların denetimi (Castillo ve ark., 2012; Melin ve ark., 2013) uygulamalarıdır. Tip-2 bulanık

sistemlerinin örüntü tanıma, sınıflandırma ve kümeleme problemleri için incelemesi örnekleri de (Melin ve Castillo, 2013)'de verilmiştir.

Endüstriyel uygulamaların büyük bir çoğunluğu çeşitli dinamik süreçlerin modellenmesi ve kontrolü ile uğraşmaktadır. Ancak, bazı sistemlerin lineer olmayan ve dinamik özelliklerinden dolayı, doğru bir model elde etmek ve bu sistemleri kontrol etmek zorlu bir iştir. Bu süreçler karmaşık, lineer olmayan ve bazen durağan olmayan dinamiklere sahiptir ve ölçülemez parametre ve değişkenlerin etkisiyle diferansiyel denklem sistemi olarak gösterilemez. Diğer bir ifadeyle, süreç dinamiğinin hassas modellerini yapmak, süreç karmaşıklığı arttıkça zorlaşmaktadır. Ayrıca önceden herhangi bir bilginin olmaması birçok pratik sistem modellenmesi için dikkate alınması gereken faktörlerden biridir. Mevcut yapay zekâ ile hesaplama yöntemlerinin burada açıklanan önemli bir dezavantajı, ileri besleme ağı yapısı nedeniyle uygulama alanının statik problemlerle kısıtlı olmasıdır. Dinamik sistemler, dinamik giriş ve çıkış özelliklerinden dolayı statik eşleştirme teknolojileri tarafından kolayca tanımlanamayabilirler ya da kontrol edilemeyebilirler. Çünkü statik eşleştirme teknolojileri geçmiş girdi ve/veya çıktılarının bir fonksiyonu değildir. Yapay sinir ağları yapısında iç hafıza olarak kullanılan geri besleme bağlantılarında gecikme çizgileri kullandığımızda, yapay sinir ağlarının bu kısıtlarının üstesinden gelebiliriz (Juang ve Lin, 1999; Lee ve Teng, 2000; Zhao ve Zhang, 2009; Zhao ve Zhang, 2010; Zhao ve ark., 2011). Ancak, modellenen ya da kontrol edilecek lineer olmayan dinamik sistemin karmaşıklığına bağlı olarak bazı durumlarda, uzun ve daha fazla gecikmeli giriş çizgisi kullanmamız gerekebilir. Bu da giriş boyutunun artmasına ve zaman aralığındaki dinamik tepkiyi gösterebilmek için sinir ağının yapısının büyümesine neden olmaktadır. Bu durum “boyut fazlalığı” (“curse of dimensionality”) problemi olarak adlandırılmaktadır. Bu sinir ağlarının öğrenmesi optimal değerlere yakınsamayabilir. Çünkü başlangıçta düğümlerin ve ağırlıkların anlamı tam olarak bilinmez ve bu nedenle sinir ağı yapısının başlangıç parametrelerinin belirlenmesi, modellenen bazı süreçler için imkânsızdır. ANFIS gibi şimdiye kadar önerilen yapay zekâ ile hesaplama modelleri sistemin dış davranışını dikkate almaktadır. Örneğin, ANFIS gerçekte Sugeno tipinde bir bulanık çıkarım mekanizmasıdır ve ANFIS’i bir fonksiyon yakınsayıcı sistemi olarak düşünülebiliriz. ANFIS’te yapısal

parametrelerden sistemin iç davranışını belirlemek ve bu model parametreleriyle denetleyici tasarlamak çok zordur (Cao ve Rees, 1995).

Lineer olmayan dinamik bir sistemin iç davranışını modellemek ve onun için bir denetleyici tasarlamak için, en bilinen bulanık sistemlerden biri olan Takagi-Sugeno (T-S) bulanık sistemi kullanılabilir. Çünkü T-S dinamik bulanık modeli, hem bulanık IF-THEN kurallarını hem de yerel dinamik modelleri içermesi nedeniyle birleşik bir sistem içine nitel ve nicel bilgiyi birleştirmek için bir yapay zeka birimi sunmaktadır. Bu model 1985'te sunulduğundan beri birçok araştırmacı bu konu üzerine odaklanmıştır (Takagi ve Sugeno, 1985). Yerel lineer olmayan sistemler ile insan uzmanlarının işbirliği T-S bulanık modelinin iyi bir evrensel kestirim yöntemi olduğunu kanıtlamıştır (Passino ve Yurkovich, 1998). T-S bulanık kontrol sistemleri, literatürde bilinen Lyapunov kararlılık analizi ve denetleyici sentez metotları kullanılarak birçok araştırmacı tarafından kapsamlı bir şekilde incelenmiştir. Örnek olarak literatürdeki şu çalışmalar gösterilebilir (Sugeno, 1999; Baranyi ve ark., 2002; Baranyi, 2004; Hsiao ve ark., 2004; Wang ve ark., 2004b; Wang ve Luoh, 2004; Wang ve Sun, 2004; Chen ve ark., 2005; Lam ve Leung, 2005; Sala ve Arino, 2007; Kruszewski ve ark., 2008; Chiu ve Chiang, 2009).

T-S modeller ile literatürde önerilen ANFIS benzeri fonksiyonel bulanık modeller karşılaştırıldığında, T-S modellerinin bazı dezavantajları olduğu görülür. Fonksiyonel bulanık modellerin en önemli avantajı, sistemin dış davranışını bulanık kurallar ve uzmanların tecrübesiyle modelleyebilmesidir. (Cao ve ark., 1997; Ismail ve ark., 2009). Ancak, eğer uzmanın amacı kontrol ise, geleneksel bulanık mantık genel bir kontrol kuralı oluşturamaz. Sadece, uzman tecrübesinin o anki fonksiyonel haritalamasını gösterir. Diğer bir deyişle, üzerinde çalışılan sistemin genel dinamiği hakkında bilgi vermez. Fakat T-S bulanık modellerinde, üyelik fonksiyonu parametrelerinin elde edilmesi zor olmasına rağmen, bu modeller yerel dinamik özellikleri modelledikleri için sistemin iç davranışını tam olarak temsil ederler. Literatürde T-S bulanık modeller üzerine yer alan çalışmaların çoğunluğu kararlılık analizi ve yerel modellerin sentezi üzerinedir. Fakat "T-S modellerdeki yerel modeller nasıl elde edilir?" sorusu cevaplanması gereken önemli bir sorudur. Genelde yapılan işlem modellenecek sistemin kritik çalışma noktalarında doğrusallaştırılmasıdır. Fakat bunun için sistemin kritik çalışma noktaları ile

matematiksel modelinin bilinmesi gerekir. Bu çalışma noktalarının sistematik olarak belirlenmesi için bu tezde; cebirsel fonksiyon gerçekleştirilmede ANFIS'in sinir ağı yaklaşımli öğrenme yaklaşımını, dinamik fonksiyonların yakınsanması için dinamik ANFIS (DANFIS) yani dinamik adaptif nöro-bulanık çıkarım sistemi adı ile önerilmiştir.

Bu tezde cevap verilmesi amaçlanan diğeri bir soru da "Herhangi bir lineer olmayan dinamik sistemin modeli olan DANFIS'in en uygun parametreleri nasıl bulunacaktır?" sorusudur. Cevap basit değildir. Çünkü diğeri sinir ağlarından farklı olarak DANFIS yapısında dinamikler vardır. Amaç cebirsel fonksiyon yaklaşımı olsa, sinir ağları için kullanılan öğrenme algoritmalarından herhangi birisi seçilebilirdi. Bu tezde, DANFIS eğitimi için ek duyarlılık analizi kullanılacaktır (Bryson ve Ho, 1969; Konar ve Samad, 1992; Cao ve ark., 2002). Bu yöntem dinamik kısıtlamaları olan bir optimizasyon probleminde, seçilen bir amaç fonksiyonunun minimize edilmesinde kullanılacak gradyan hesaplamalarını yapmamızı sağlamaktadır. DANFIS eğitimi için seçilecek performans indeksinin minimize edilmesi DANFIS'teki dinamiklere bağılı olduğundan bu yöntem düşünölmüştür. Sayısal çalışmalar, ek duyarlılık yönetiminin bulunması hedeflenen parametre sayısının çok, amaç fonksiyonları sayısının da az olduğu durumlarda etkin olarak kullanılabilir bir yöntem olduğunu göstermektedir. DANFIS parametrelerine göre gradyanlar hesaplandıktan sonra, herhangi bir gradyan tabanlı öğrenme algoritması kullanılarak optimal parametrelerin belirlenmesi hedeflenmektedir. Bu tezde gradyan hesaplamalarındaki kritik noktalar da ilerleyen bölümlerde açıklanacaktır.

Öte yandan dalgacık tabanlı fonksiyonlar zaman-frekans aralığında yerellik özelliklerine sahip olduğu için, dalgacık dönüşümü yerel özellikleri temsil etmesiyle popüler olmuştur (Mallat ve Hwang, 1992; Mallat ve Zhong, 1992). Dalgacık dönüşümünün yeteneğini geliştirebilmek için dalgacık sinir ağları (WNN) Zhang ve Benveniste (Zhang ve Benveniste, 1992) tarafından önerilmiştir. Bu tasarımda dalgacıklar yapay sinir ağına aktivasyon fonksiyonu olarak bütünleştirilmiştir. WNN, dalgacıkların yerelleştirme özellikleri ile sinir ağlarının öğrenme kapasitesini birleştirerek hızlı yakınsama ve yüksek doğruluk özelliklerini sunmaktadır (Zhang ve Benveniste, 1992; Zhang ve ark., 1995; Zhang, 1997;

Holmes ve Mallick, 2000; R.K.H. Galvao ve ark., 2004; Billings ve Wei, 2005; Chen ve ark., 2006).

WNN'nin en önemli özelliği, sinir ağının gizli katmanında sadece zamanda yerellik özelliğine sahip Gauss ya da Sigmoid fonksiyonlarının yerine dalgacık fonksiyonlarının aktivasyon fonksiyonları olarak kullanılmasıdır. WNN, zaman ve frekansta yerellik özelliklerine sahip dalgacık fonksiyonlarının genişletilmiş ve ötelenmiş versiyonlarını kullanarak, sistemin giriş-çıkış haritalamasını veren lineer olmayan bir regresyon yapısına sahiptir. İki çeşit WNN yapısı vardır. İlkinde aktivasyon fonksiyonu olarak dalgacıklar sürekli dalgacık dönüşümünden gelmektedir. Bu yapıda, dalgacık fonksiyonunun genişlik ve öteleme parametreleri herhangi bir reel pozitif sayı olabilir ve çıkış katmanındaki ağırlıklar ayarlanabilir. İkinci çeşit WNN'de aktivasyon fonksiyonu olarak dalgacıklar kesikli dalgacık dönüşümünden gelmektedir. Bu durumda genişlik ve öteleme parametreleri değiştirilemez ve sadece çıkış katmanındaki ağırlıklar ayarlanabilir. Literatürde çeşitli WNN modelleri önerilmiştir (Holmes ve Mallick, 2000; R.K.H. Galvao ve ark., 2004; Billings ve Wei, 2005; Chen ve ark., 2006). Yerel lineer dalgacık sinir ağı (Chen ve ark., 2006)'de gösterilmiştir ve bu model yukarıda belirtilen birinci çeşit WNN modelidir. Bu ağda, gizli katman ve çıkış katmanı arasındaki bağlantı ağırlıkları yerel lineer bir modelle değiştirilmiştir. Geleneksel WNN'de bunlar ayarlanabilir sabit değerlerdir. (R.K.H. Galvao ve ark., 2004)'de geleneksel WNN ile girişlerin ağırlıklı lineer toplamını birleştiren bir lineer dalgacık ağı önerilmiştir. (Billings ve Wei, 2005)'de yukarıda bahsedilen ikinci tipteki dalgacık ağları orta ya da büyük boyuttaki problemler için önerilmiştir. Bu model çok boyutlu fonksiyonu dalgacık ayrışımını kullanarak az boyutlu alt modellere genişletir. (Holmes ve Mallick, 2000)'de Bayes yaklaşımı dalgacık ağlarında parametrik olmayan regresyon uygulamaları için kullanılmıştır.

Dinamik sistemlerin modellenmesi ve kontrolünde diğer bir yenilik de nöro-bulanık sistemleri dalgacık fonksiyonları ile birleştirmektir. Bu yeni model bulanık dalgacık sinir ağı (FWNN) olarak adlandırılır. FWNN, nöro-bulanık sistemleri dalgacıklar ile bütünleştirerek bu tekniklerin gücünü arttırmaktadır. FWNN yapay sinir ağlarının, bulanık sistemlerin ve dalgacıkların bütün özelliklerini ve avantajlarını almaktadır. Bunlar, yapay sinir ağlarının genelleştirme ve öğrenme

yeteneđi, dalgacıkların zaman ve frekansta yerellik özellikleri ile bulanık mantık sistemlerinin çıkarım mekanizmasıdır. Literatürde çeşitli FWNN modelleri zaman serisi analizi, sistem tanımlama ve kontrol problemleri için önerilmiştir (Ho ve ark., 2001; Karatepe ve Alci, 2005; Srivastava ve ark., 2005; Abiyev ve Kaynak, 2008; Banakar ve Azeem, 2008; Zekri ve ark., 2008; Yılmaz, 2009; Yılmaz ve Oysal, 2009; Oysal ve Yılmaz, 2010; Yılmaz ve Oysal, 2010). (Ho ve ark., 2001) ve (Zekri ve ark., 2008)'de, her bir kural tek boyutlu dalgacık fonksiyonlarından oluşan alt WNN modelleri ile tanımlanır. Buradaki dalgacık fonksiyonlarının bütün boyutlarında tek bir genişleme parametresi vardır ve ortogonal en küçük kare algoritması önemli dalgacıkları seçmek için kullanılmıştır. Sonuçta elde edilen sinir ađı (Ho ve ark., 2001)'de fonksiyon yaklaşımı ve (Zekri ve ark., 2008)'de ise lineer olmayan sistemlerin kontrolü için kullanılmıştır. (Karatepe ve Alci, 2005)'de önerilen modelde bulanık kuralların sonuç kısmında dalgacık fonksiyonunun seri açılımı vardır ve bu model sistem modelleme uygulamaları için kullanılmıştır. (Banakar ve Azeem, 2008)'de WNN'nin gizli katmanında hem sigmoid hem de dalgacık fonksiyonları kullanılmıştır ve bu yeni WNN modelinin çıktısı iç katmandaki sonuçların çarpımı ve toplamı ile hesaplanmaktadır. Daha sonra elde edilen bu WNN modeli, FWNN modelinin bulanık kurallarının sonuç kısmında kullanılmaktadır. (Srivastava ve ark., 2005)'de girişler kesikli dalgacık dönüşüm blođuna girdikten sonra bu blođun çıktısı bulanıklaştırılır ve bu bulanık sonuç sinir ađının girdisi olmuş olur. Elde edilen bu model sistem tanımlama ve kontrol uygulamaları için kullanılmıştır. (Abiyev ve Kaynak, 2008)'de önerilen FWNN modelinin kurallarının sonuç kısmı dalgacık fonksiyonlarının genişletilmesi ve ötelenmesiyle oluşan versiyonlarının toplamından oluşmaktadır. Elde edilen bu model de sistem tanımlama ve kontrol uygulamaları için kullanılmıştır. Dalgacık fonksiyonları (Oysal ve Yılmaz, 2010)'de bulanık kurallarda üyelik fonksiyonu olarak kullanılmıştır ve bu model fonksiyon tanıma uygulamalarında kullanılmıştır. Son olarak, (Yılmaz, 2009; Yılmaz ve Oysal, 2010)'de üç farklı FWNN modeli önerilmiştir. Bu modellerde kuralların sonuç kısmı dalgacık fonksiyonlarının toplamı, çarpımı ve dalgacıkların bir radyal fonksiyonu olarak ifade edilmiştir.

## 1.1. Kapsam ve Tezde Önerilen Modeller

Bu tezin ilk kısmında yeni bir tip-2 bulanık dalgacık sinir ağı (T2FWNN) modeli önerilmiştir. Önerilen T2FWNN modelinin, sistem üzerindeki bazı temel belirsizliklerin üstesinden gelinmesi amaçlanmıştır. Bu modelde, bulanık kural tabanı oluşturulurken üyelik fonksiyonlarında ve kuralların sonuç kısmında dalgacık fonksiyonları kullanılmıştır. Bu tezde tanıtılan T2FWNN modeli, tip-2 bulanık sistemlerini dalgacıkların yerellik özelliği ile bir adaptif sinir ağı çerçevesinde birleştirmiştir. Böylece yapay sinir ağlarının öğrenme yöntemleri kolayca bu modele uygulanmıştır. Sistem tanımlama sonuçları önerilen modellerin etkinliğini göstermek için verilmiştir.

T-S bulanık modellerinde, üyelik fonksiyonu parametreleri ile beraber bulanık kuralları elde etmek, lineer olmayan dinamik sistemler için kolay değildir. Bu tezin ikinci kısmında dinamik sistemlerin yerel modellerini elde etmek için bir dinamik adaptif nöro-bulanık çıkarım sistemi (DANFIS) (Yılmaz ve Oysal, 2014) önerilmiştir. Bu model T-S modelinin bir yapay sinir ağı gösterimidir. Bilindiği üzere T-S bulanık sistemleri homojen ve afin bulanık modeller olarak iki sınıfa ayrılabilirler (Kim ve Kim, 2002). Bu iki model arasındaki fark, afin modellerde her bir kuralda bir baz terimin olmasıdır. Ancak homojen modellerde bu terim yoktur. Bu tezde önerilen DANFIS afin bir modeldir. DANFIS modeli ile sadece sistemin giriş-çıkış verisi arasındaki bağıntı değil, ayrıca sistemin iç davranışı da modellenmiş olur. Böylece modelin yapısal parametrelerinden kolayca bir denetleyici tasarlanabilir.

Bu tezin üçüncü kısmında, DANFIS modelindeki Gauss üyelik fonksiyonları yerine dalgacık fonksiyonları kullanılmıştır. Önerilen bu yeni model dinamik bulanık dalgacık sinir ağı (DFWNN) olarak adlandırılmıştır. DFWNN modeli, dalgacıkların zaman ve frekansta yerelleştirme özellikleri ile DANFIS özelliklerini birleştirmiştir. Son olarak elde edilen DANFIS ve DFWNN modelleri bazı önemli ölçüt sistem tanımlama ve kontrol uygulamaları için denenmiş ve sonuçlar karşılaştırılmıştır.

## 1.2. Tez İeriđi

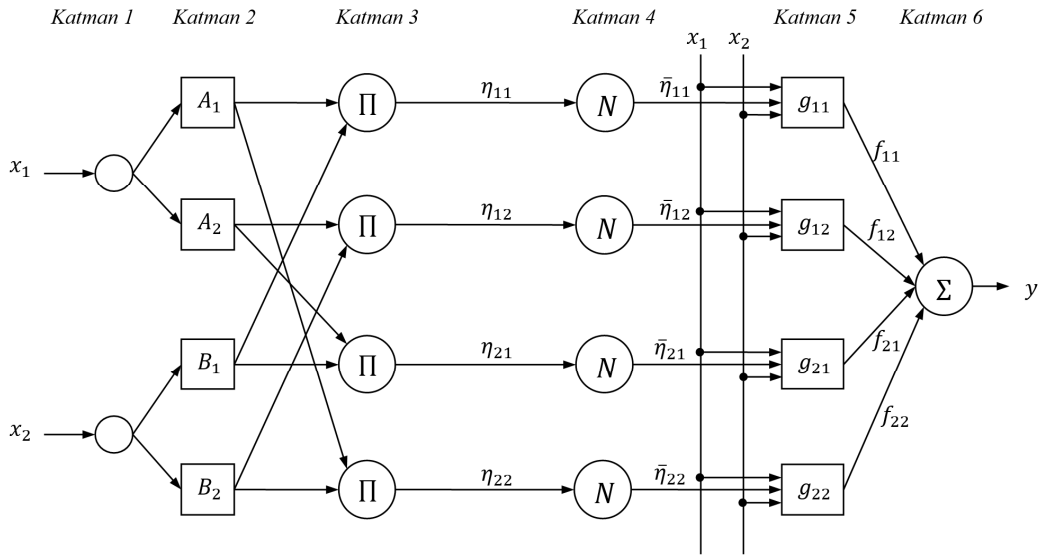
Doktora tez alıřmasının ayrıntıları řu řekilde organize edilmiřtir. Blm 2’de tip-1 ve tip-2 bulanık sinir ađları ve dalgacıklar hakkında genel bir bilgi verilecektir. Blm 3’de tezde nerilen birinci model T2FWNN’nin yapısı ve benzetim sonuları verilecektir. Blm 4 ve 5’de sırasıyla DANFIS ve DFWNN modellerinin yapısı ve đrenme algoritmaları tanıtılacaktır. Blm 6’da DANFIS ve DFWNN ile dinamik sistemlerin modelleme ve kontrol sonuları aıklanacaktır. Son olarak, Blm 7’de tez hakkında genel tartıřma ve sonular verilecektir.



## 2. GENEL BİLGİLER

### 2.1. Tip-1 Nöro-Bulanık Çıkarım Sistemleri

Tip-1 nöro-bulanık sistemlerden en popüler olanı ANFIS'tir (Jang, 1993). ANFIS öğrenme ve adaptasyonu kolaylaştırma özelliğine sahip Sugeno tipinde adaptif bir bulanık sistemdir (Jang, 1993). Sugeno bulanık sistemlerde giriş alanı bulanık bölgelere ayrılır ve bu bölgeler bulanık üyelik fonksiyonları ile ifade edilir. Bu üyelik fonksiyonları üçgen, çan ya da Gauss tipinde olabilir. Kuralların sonuç kısımları ise bir sabit ile ya da girişlerin lineer fonksiyonu şeklinde ifade edilir. ANFIS yapısı, önceden tanımlanmış bulanık sistemin çıkışını vermek üzere düzenlenmiştir. ANFIS'te bulanık kuralların bilinmeyen parametreleri çoklu bir öğrenme algoritması ile belirlenmektedir (Jang, 1993).



Şekil 2.1. ANFIS Yapısı

ANFIS'in öğrenmesi iki giriş ve tek çıkışlı, her bir girişin iki üyelik fonksiyonuna sahip olduğu lineer bir ANFIS yapısı üzerinden tanıtılacaktır. Örnek olarak bu ANFIS modelinin ilk bulanık kuralı şu şekilde ifade edilebilir:

$$\text{IF } x_1 \text{ is } A_{11} \text{ AND } x_2 \text{ is } A_{21} \text{ THEN } g_{11} = p_{11}x_1 + q_{11}x_2 + r_{11}$$

Bu ANFIS modelinin yapısı Şekil 2.1’de gösterilmiştir. Her bir düğümdeki fonksiyonlar aynı fonksiyon ailesinden seçilmiştir. ANFIS yapısındaki katmanlar şu şekilde açıklanabilir:

- **Katman 1:** Bu katman giriş katmanıdır. Bu katmandaki her bir düğüm gelen giriş sinyalini ikinci katmana iletir.
- **Katman 2:** Bu katman bulanıklaştırma katmanıdır. Bu katmandaki düğümler kuralların IF kısmındaki bulanık kümeleri gösterir. Bu katmanın çıkışı bulanık üyelik fonksiyonlarının değerleridir.  $i$ . giriş için  $j$ . Gauss tipindeki üyelik fonksiyonu şu şekilde verilmiştir:

$$A_{ij}(x_i) = \exp\left(-\frac{1}{2} \left(\frac{x_i - \mu_{ij}}{\sigma_{ij}}\right)^2\right) \quad i=1,2 \text{ ve } j=1,2 \quad (2.1)$$

- **Katman 3:** Bu katman bulanık kural katmanıdır. Bu katmandaki her bir düğüm, o bulanık kuralın işleyiş derecesini temsil etmektedir. Bu katmanın çıktısı şu şekilde hesaplanır:

$$\eta_{ij} = A_{1i}(x_1) \cdot A_{2j}(x_2) \quad i=1,2 \text{ ve } j=1,2 \quad (2.2)$$

- **Katman 4:** Bu katman normalleştirme katmanıdır. Bu katmandaki her bir düğüm verilen kuralın normalleştirilmiş işleyiş derecesini şu şekilde hesaplar:

$$\bar{\eta}_{ij} = \frac{\eta_{ij}}{\sum_{i=1}^2 \sum_{j=1}^2 \eta_{ij}} \quad i=1,2 \text{ ve } j=1,2 \quad (2.3)$$

- **Katman 5:** Bu katman kesin değerlerin hesaplandığı arındırma katmanıdır. Bu katmanın çıkışı şu şekilde hesaplanır:

$$\begin{aligned} f_{ij} &= \bar{\eta}_{ij} g_{ij} \\ &= \bar{\eta}_{ij} (p_{ij} x_1 + q_{ij} x_2 + r_{ij}) \end{aligned} \quad (2.4)$$

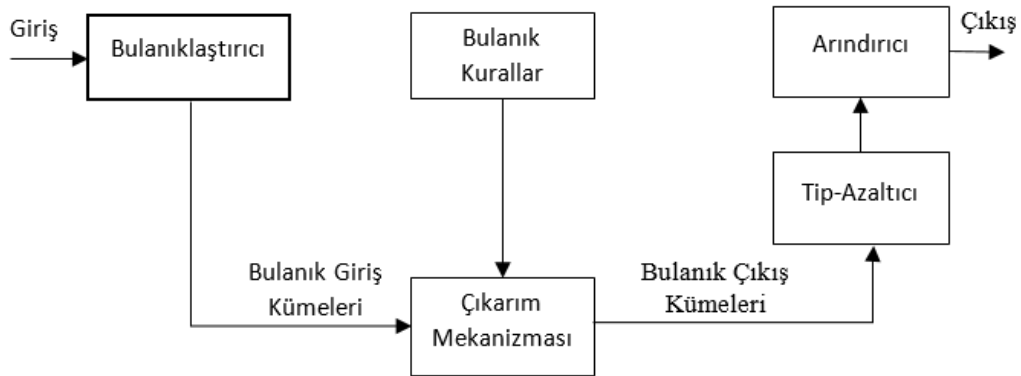
- **Katman 6:** Bu katman çıkış katmanıdır. Sistemin kesin toplam çıkışı bu katmanda şu şekilde hesaplanır:

$$y = \sum_{i=1}^2 \sum_{j=1}^2 f_{ij} \quad (2.5)$$

ANFIS ağlarının bilinmeyen parametreleri, kuralların IF kısmındaki lineer olmayan ( $\mu$  ve  $\sigma$ ) parametreler ile kuralların THEN kısmındaki lineer ( $p$ ,  $q$  ve  $r$ ) parametrelerdir. Gradyan yöntemi ile en küçük kareler tahmin yönteminin (LSE) birleşiminden oluşan melez bir algoritma ANFIS'in bilinmeyen parametrelerini öğrenmek için kullanılmaktadır (Jang, 1993).

## 2.2. Tip-2 Bulanık Sistemlere Bakış

Bu bölümde tip-2 bulanık sistemleri tanıtılacaktır. Bir karakteristik tip-2 bulanık mantık sisteminin yapısı Şekil 2.2'de gösterilmiştir. Bu sistem beş ana parçadan oluşmaktadır. Bunlar bulanıklaştırıcı, bulanık kurallar, çıkarım mekanizması, tip azaltıcı ve arındırıcıdır. Popüler bulanıklaştırıcılar Gauss, üçgen ya da çan şeklindekilerdir. Arındırma yöntemleri ise, ağırlık merkezi yöntemi, en büyük değer yöntemi ya da eşit iki parçaya bölüm noktasını hesaplayan yöntem şeklinde sıralanabilir. Bulanık sistemlerde kesin girdiler bulanıklaştırıcıya girer ve bulanık giriş kümeleri bulunur. Çıkarım mekanizmasını kullanarak kural tabanından işleyen kurallar elde edilir. Sistemin bulanık çıktısı tip azaltıcıya girerek boyutu azaltılır ve daha önceden belirtilen arındırma yöntemlerinden biri kullanılarak sistemin kesin değeri hesaplanır.



Şekil 2.2. Tip-2 bulanık mantık sistemi

Tip-1 bulanık mantıkta belirsizlik sadece dilsel değişkenlerdedir. Ancak tip-2 bulanık kümeleri üyelik fonksiyonunda da belirsizliğe sahiptir (Castillo ve Melin, 2008). Tip-1 bulanık kümelerde üyelik fonksiyonun derecesi  $[0, 1]$  aralığında kesin

bir deęer alırken, tip-2 bulanık kümelerde [0, 1] aralıęında bulanık bir deęer alır (Mendel, 2007). Tip-2 bulanık kümeleri, kesin üyelik derecesinin belirlenemedięi durumlarda kullanılır.

Gerçek hayattaki bazı problemler modellenirken, tip-2 bulanık kümelere ihtiyaç duyulur. Örneęin gürültülü bir zaman serisi tahmininde tip-2 bulanık kümeleri kullanılabilir (Castillo ve Melin, 2008). Tip-2 bulanık kümeleri modellenirken, ařaęıda verilen üç farklı üyelik fonksiyonu tasarımı kullanılır.

- a) Sabit standart sapma  $\sigma$ , belirsiz orta  $\mu$
- b) Sabit orta  $\mu$ , belirsiz standart sapma  $\sigma$
- c) Belirsiz orta  $\mu$ , belirsiz standart sapma  $\sigma$

Gauss üyelik fonksiyonu için belirsiz standart sapma örneęi Şekil 2.3'te verilmiřtir.


$$gauss(x) = \exp\{-0.5((x - \mu) / \sigma)^2\}; \sigma \in [0.1, 0.15] \quad (2.6)$$

Şekil 2.3'te görüldüğü üzere verilen bir  $x$  için üyelik fonksiyonu olası bir sayıda deęer alabilir. Örneęin  $x=0.65$  seçildięinde, üyelik fonksiyonu deęeri [0.34, 0.63] kapalı aralıęıdır.


Şimdi de Gauss üyelik fonksiyonu için belirsiz orta nokta durumunu inceleyelim. Üyelik fonksiyonu ařaęıda belirtilen fonksiyon ile verilsin:

$$gauss(x) = \exp\{-0.5((x - \mu) / \sigma)^2\}; \mu \in [0.45, 0.55] \quad (2.7)$$

Bu durumdaki sonuç Şekil 2.4'te verilmektedir. Eęer  $x=0.4$  olursa, üyelik fonksiyonu [0.3, 0.88] aralıęındaki olası deęerleri alabilir. Şekil 2.3 ve Şekil 2.4'te görüldüğü üzere, tip-2 bulanık kümelerde üyelik fonksiyonu dereceleri de belirsizdir.



Şekil 2.3. Belirsiz standart sapma ile tip-2 bulanık kümesi ( $\sigma = [0.1, 0.15]$ )



Şekil 2.4. Belirsiz orta nokta ile tip-2 bulanık kümesi ( $\mu = [0.45, 0.55]$ )

### 2.3. Dalgacık Fonksiyonlarına Bakış

Dalgacıklar belirli matematiksel gereksinimleri sağlayan fonksiyonlardır ve eldeki veriyi ya da başka bir fonksiyonu göstermek için kullanılırlar. Ana dalgacık olarak adlandırılan  $\Psi(x)$  fonksiyonunun genişletilmesi ve ötelenmesiyle dalgacık fonksiyonları elde edilmektedir.

$$\psi_{b,c}(x) = \frac{1}{\sqrt{c}} \psi\left(\frac{x-b}{c}\right) \quad (2.8)$$

Denklem (2.8)'de,  $c$  genişlik katsayısı  $b$  ise öteleme katsayısıdır.  $c^{-1/2}$  ise farklı ölçeklerde enerji normalleştirme katsayısıdır.

Ana dalgacığın “uyumluluk koşulu” denilen koşulu sağlaması gerekmektedir.

$$\int_0^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (2.9)$$

Burada  $\Psi(\omega)$ , ana dalgacık  $\Psi(x)$ 'nin Fourier dönüşümüdür. Uyumluluk koşulu zaman etki alanında dalgacık fonksiyonun ortalama değerinin sıfır olduğunu belirtmektedir:


$$\int_{-\infty}^{\infty} \Psi(x) dx = 0 \quad (2.10)$$

ve bu nedenle dalgacıklar salınımlı olmalıdır, diğer bir deyişle  $\Psi(x)$  bir dalga olmalıdır.

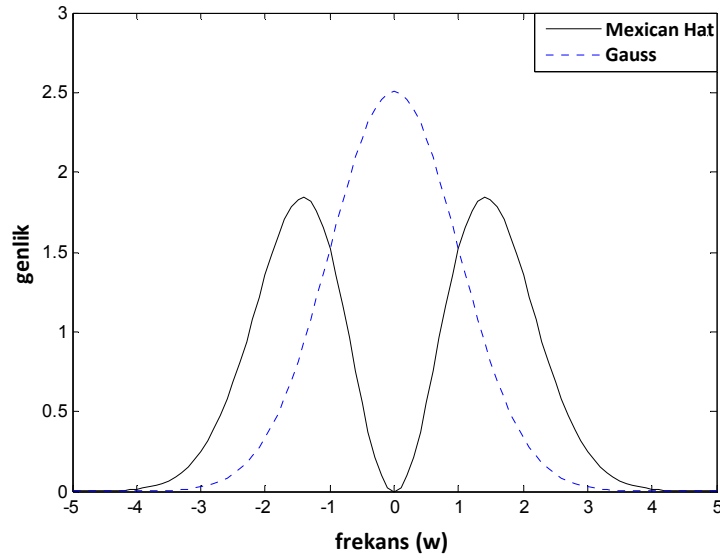
Fonksiyonların belirli bir sınıfı dalgacıkların lineer bir fonksiyonu olarak temsil edilebilir. Yani, fonksiyonlar dalgacık fonksiyonunun genişletilmiş ve ötelenmiş versiyonlarının sonlu lineer kombinasyonu olarak gösterilebilirler. Sinyal zamanda davranışını değiştiriyorsa, dalgacık gösterimleri, Fourier seri gösterimlerinden daha etkilidir (Valens, 1999; Iyengar ve ark., 2002). Hem dalgacık hem de Fourier gösterimleri frekansta yerellik özelliklerine sahiptir. Ancak, Fourier gösteriminde sin ve cos fonksiyonları zamanla yerellik özelliklerine sahip değilken, dalgacıklar zamanda da yerelleşmiştir (Graps, 1995). Bu özellik fonksiyon yaklaşımında dalgacık gösterimini Fourier gösteriminden daha etkili yapmaktadır. Fourier dönüşümleri sabit sin ve cos fonksiyon tabanlarına sahipken, dalgacıklar

daha esnektir. Analiz edeceğimiz sinyalin çeşidine göre çeşitli dalgacıklardan istediğimiz dalgacık ailesini seçebiliriz (Iyengar ve ark., 2002).

ANFIS'te üyelik fonksiyonları Şekil 2.5'te gösterilen Gauss fonksiyonu gibi yerel taban fonksiyonlarıdır. Yerel taban fonksiyonları sadece belirli girişler için aktiftirler. Ancak Şekil 2.6'da gösterildiği gibi frekansta yerellik özellikleri yoktur. Sinyal gösterimlerinde hem zamanda hem de frekansta yerellik özellikleri çok önemli bir konudur. Bu nedenle dalgacık fonksiyonlarının görevi önemlidir.



Şekil 2.5. Gauss ve Meksika Şapkası dalgacık fonksiyonları



Şekil 2.6. Gauss ve Meksika Şapkası dalgacık fonksiyonunun Fourier dönüşümü

Meksika Şapkası dalgacık fonksiyonu Gauss fonksiyonunun ikinci türevidir. Ortonormal olmayan Meksika Şapkası taban fonksiyonu analitik formda aşağıdaki gibi yazılabilir ve onun Fourier dönüşümü yine kolaylıkla aşağıdaki gibi hesaplanabilir:


$$\psi(x) = (1 - x^2) \exp\left(-\frac{x^2}{2}\right), x \in R \quad (2.11)$$

$$\psi(\omega) = \sqrt{2\pi} \omega^2 \exp\left(-\frac{\omega^2}{2}\right), \omega \in R \quad (2.12)$$

Burada  $\omega$  reel frekanstır. Meksika Şapkası dalgacık fonksiyonu öteleme ( $b$ ) ve genişlik ( $c$ ) parametreleri ile aşağıdaki gibi genelleştirilebilir:


$$\psi\left(\frac{x-b}{c}\right) = \left(1 - \left(\frac{x-b}{c}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x-b}{c}\right)^2\right) \quad (2.13)$$

Öteleme parametresi Şekil 2.7'de gösterildiği gibi dalgacığın merkez pozisyonunu belirlerken, genişlik parametresi ise Şekil 2.8'de gösterildiği gibi dalgacığın yayılımını kontrol etmektedir.




Şekil 2.7. Meksika Şapkası dalgacık fonksiyonunda öteleme parametresinin etkisi





Şekil 2.8. Meksika Şapkası fonksiyonunda genişlik parametresinin etkisi



Şekil 2.9. Meksika Şapkası fonksiyonunun Fourier dönüşümünde genişlik parametresinin etkisi

Şekil 2.8 ve Şekil 2.9'da Meksika Şapkası fonksiyonu için sırasıyla zaman ve frekans ekseninde genişlik parametresinin etkisi gösterilmektedir. Frekans spektrumundan görüldüğü gibi dalgacık fonksiyonları zaman ve frekansta yerellik özelliklerine sahiptir (Mallat, 1989). Genişleme parametresi değiştiğinde dalgacık fonksiyonun destek alanının genişliği değişirken, döngülerin sayısı değişmemektedir (Becerikli ve ark., 2003). Yani tepe noktası sayısı

değişmemektedir. Ancak, genişlik parametresi azaldığında spektrumun tepe noktası yüksek frekanslara doğru kaymaktadır. Böylece, genişlik parametresini değiştirilerek bütün frekans spektrumu elde edilebilir.

Gauss tabanlı ANFIS ağlarının eksikliği frekansta yerellik özelliklerine sahip olmamasıdır. Bu yüzden Gauss tabanlı ağları bazı uygulamalarda kullanmak zordur (Sanner ve Slotine, 1992). Bütün bu problemlerin üstesinden gelebilmek için zaman ve frekansta yerellik özelliklerine sahip dalgacık fonksiyonları bu tezde kullanılmıştır.

### 3. SİSTEM TANIMA UYGULAMALARI İÇİN TİP-2 BULANIK DALGACIK SİNİR AĞI (T2FWNN) MODELİ TASARIMI

#### 3.1. Giriş

Tezin bu kısmında bazı temel sistem belirsizlikleri durumunda da kullanılabilecek yeni bir T2FWNN modeli önerilecek ve tanıtılacaktır. T2FWNN, dalgacık fonksiyonlu bulanık kural tabanını belirlemek için bir tasarım yöntemi sunmaktadır ve bu modelde iç parametreler belirsizlikleri göstermektedir. Tezde önerilen bu model dalgacıkların yerellik özellikleri ile tip-2 bulanık sistemlerini bir yapay sinir ağı çerçevesine gömmüştür. Böylece sinir ağı teknolojilerinin öğrenme algoritmaları kolayca bu modele uygulanmıştır. T2FWNN modelinin fikri (Yılmaz ve Oysal, 2010)'den gelmektedir. (Yılmaz ve Oysal, 2010)'da üç farklı FWNN modeli lineer olmayan dinamik sistemlerin tahmini ve tanımlanması için önerilmiştir. (Yılmaz ve Oysal, 2010)'de önerilen FWNN modelleri dalgacıkların zaman ve frekansta yerellik özellikleri sayesinde etkileyici bir genelleştirme yeteneğine sahiptir.

Tezin bu kısmında önerilen model daha önce önerilen çalışmanın (Yılmaz ve Oysal, 2010) daha geliştirilmiş ileri bir modelidir. Bu model dinamik sistemlerin tanımlaması için gürültülü ölçümler, iç ve çevresel etkilerin neden olduğu bozukluk durumunda oluşan belirsizliği gidermek için önerilmiştir. Taban model ANFIS(Jang, 1993)'tir. Ancak burada önerilen ağ modelinde, tip-2 dalgacık üyelik fonksiyonları yeni tipte bir yapay sinir ağı oluşturmak için kullanılmıştır ve bu model T2FWNN olarak adlandırılmaktadır. Standart ANFIS'te gizli katmandaki aktivasyon fonksiyonları (kuralların koşul kısmı) daha önce belirtildiği gibi genellikle Gauss fonksiyonlarıdır ve kuralların sonuç kısmı ise giriş değişkenlerinin lineer bir fonksiyonudur. Bu tezde önerilen T2FWNN modellerinde nöron aktivasyon fonksiyonları tip-2 dalgacık taban fonksiyonları ile değiştirilmiştir. Bulanık kuralların sonuç kısımları ise (Yılmaz ve Oysal, 2010)'de önerilen FWNN-S modeli gibi dalgacık fonksiyonlarının ötelenmiş ve genişletilmiş versiyonlarının ağırlıklı toplamıdır. Bu tezde önerilen T2FWNN modellerinde, kuralların koşul ve sonuç kısmındaki bilinmeyen parametre değerleri gradyan tabanlı bir öğrenme algoritmasıyla bulunmuştur.

### 3.2. T2FWNN Modellerinin Yapısı

Bu bölümde önerilen T2FWNN modellerinin yapısı tanıtılacaktır. Burada gösterilen T2FWNN modelleri lineer olmayan dinamik fonksiyonlardaki belirsizliği giderebilmek için tip-2 dalgacık fonksiyonları ile ANFIS ağlarının adaptif yapısını birleştirmiştir. Birinci model (T2FWNN-M1) ANFIS'in kafes bölümlendirme yapısına benzemektedir. İkinci model (T2FWNN-M2) ise ANFIS'in kümeleme yapısına benzemektedir. Şekil 3.1 ve Şekil 3.2 sırasıyla T2FWNN-M1 ve T2FWNN-M2'nin yapısını göstermektedir.

Her bir T2FWNN modeli toplam olarak altı temel katmandan oluşmaktadır. Bu bulanık sistemdeki bulanık kurallar aşağıdaki formda verilmiştir:

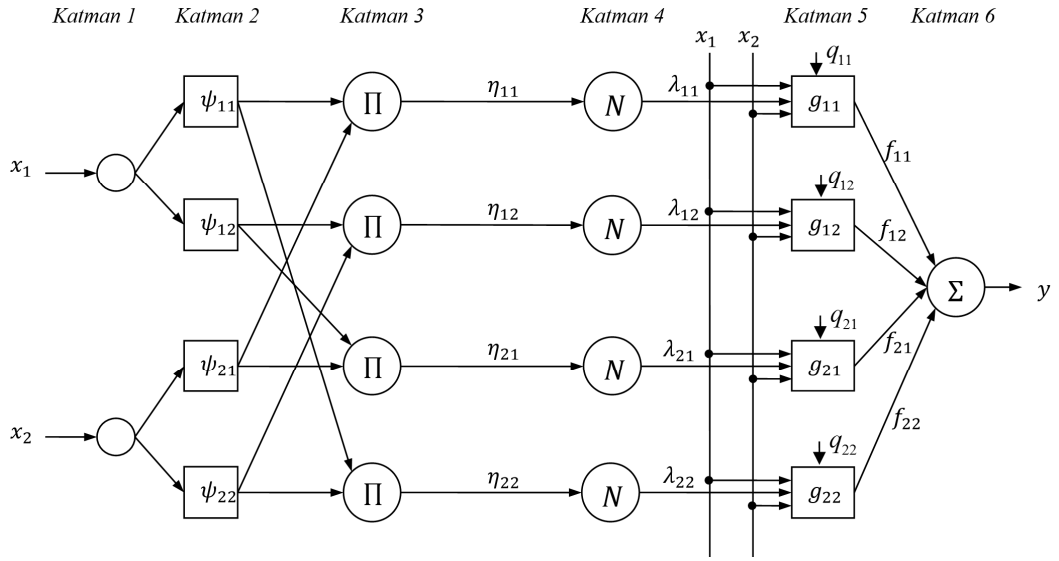
$$\text{IF } x_1 \text{ is } \psi_1^{i_1} \text{ and } x_2 \text{ is } \psi_2^{i_2} \text{ and } \dots \text{ and } x_n \text{ is } \psi_n^{i_n} \text{ THEN } g_l(x) \quad (3.1)$$

Burada  $x_1, x_2, \dots, x_n$  tanımlanacak sistemin durumlarını gösteren giriş değişkenleri,  $\psi_j^{i_j}$  ise  $j$ . giriş için  $i_j$ . dalgacık tipinde üyelik fonksiyonu ve  $g_l(x)$  ise  $l$ . bulanık kuralın çıktısıdır.

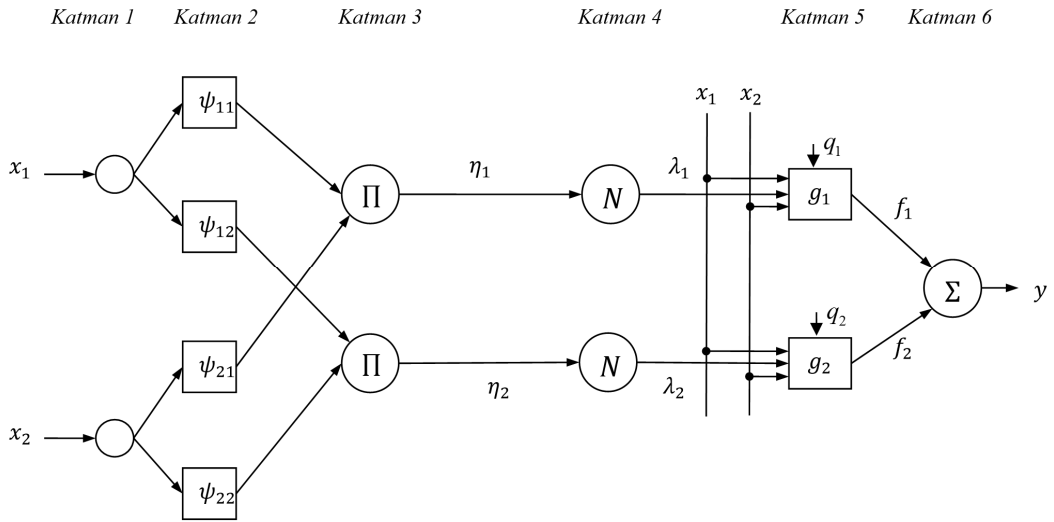
Önerilen modellerde Meksika Şapkası dalgacık fonksiyonları, kuralların koşul kısmında üyelik fonksiyonu olarak kullanılmıştır. Kuralların sonuç kısmında ise yine dalgacık fonksiyonlarının girişe bağlı olarak ağırlıklı toplamı kullanılmıştır. Bu tezde kullanılan Meksika Şapkası dalgacık fonksiyonunun ötelenmiş ve genişletilmiş hali aşağıdaki fonksiyon ile verilmektedir:

$$\psi\left(\frac{x-b_i}{c_i}\right) = \left(1 - \left(\frac{x-b_i}{c_i}\right)^2\right) \exp\left(-\frac{1}{2}\left(\frac{x-b_i}{c_i}\right)^2\right) \quad (3.2)$$

Kolaylık ve anlaşılması açısından, burada açıklanacak modeller iki girişli sahiptir ve ayrıca her bir girişin iki tane üyelik fonksiyonu vardır. Buradaki hesaplamalar kolaylıkla çok girişli çok çıkışlı modellere genişletilebilir. Modellerdeki her bir katmanın matematiksel anlamı aşağıda verilmiştir.



Şekil 3.1. T2FWNN-M1 yapısı



Şekil 3.2. T2FWNN-M2 yapısı

**Katman 1:** İlk katman giriş katmanıdır.  $x_1, x_2$  girişlerini alır ve ikinci katmana iletir.

**Katman 2:** Bu katman bulanıklaştırma katmanıdır. Aralıklı tip-2 dalgacık üyelik fonksiyonları bu katmanda kullanılmıştır. Alt ve üst üyelik fonksiyonları  $(\underline{\Psi}_{ij}, \bar{\Psi}_{ij})$  sırasıyla T2FWNN-M1 ve T2FWNN-M2 modelleri için aşağıdaki gibi verilmiştir.

$$\Psi_{ij} = (\underline{\Psi}_{ij}, \bar{\Psi}_{ij}) \quad (3.3)$$

$$\underline{\Psi}_{ij} = \left(1 - \left(\frac{x_j - \underline{\mu}_{ij}}{\underline{\sigma}_{ij}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x_j - \underline{\mu}_{ij}}{\underline{\sigma}_{ij}}\right)^2\right) \quad (3.4)$$

$$\bar{\Psi}_{ij} = \left(1 - \left(\frac{x_j - \bar{\mu}_{ij}}{\bar{\sigma}_{ij}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x_j - \bar{\mu}_{ij}}{\bar{\sigma}_{ij}}\right)^2\right) \quad (3.5)$$

$$j = 1, 2 \text{ ve } i = 1, 2$$

Burada  $\underline{\mu}_j$ ,  $\bar{\mu}_j$  merkez ve  $\underline{\sigma}_{ij}$ ,  $\bar{\sigma}_{ij}$  standart sapma parametreleri uygun başlangıç değerlerini alabilirler ve öğrenme fazında güncelleştirilirler.

**Katman 3:** Bu bulanık kural katmanıdır. Bu tezde VE operatörü olarak çarpım işlemi kullanılmıştır.

T2FWNN-M1 için:

$$\underline{\eta}_{ij} = \underline{\Psi}_{1i}(x_1) \underline{\Psi}_{2j}(x_2) \quad (3.6)$$

$$\bar{\eta}_{ij} = \bar{\Psi}_{1i}(x_1) \bar{\Psi}_{2j}(x_2) \quad (3.7)$$

T2FWNN-M2 için:

$$\underline{\eta}_j = \underline{\Psi}_{1j}(x_1) \underline{\Psi}_{2j}(x_2) \quad (3.8)$$

$$\bar{\eta}_j = \bar{\Psi}_{1j}(x_1) \bar{\Psi}_{2j}(x_2) \quad (3.9)$$

T2FWNN-M2'nin T2FWNN-M1'e göre farkı her bir giriş değişkeni için kural sayısının üyelik fonksiyonu sayısına eşit olmasıdır. Ancak T2FWNN-M1'de giriş alanı için kafes bölümlendirmesi kullanılmıştır ve bu nedenle toplam kural sayısı, girişlerin üyelik fonksiyonlarının olası kombinasyon sayısına eşittir. T2FWNN-M1'de giriş üyelik fonksiyonlarının her bir kombinasyonu bir bulanık kuralı temsil etmektedir. Her bir değişken için üyelik fonksiyonu sayısı bu modelde farklı olabilir. Ancak T2FWNN-M2'de üyelik fonksiyonu sayıları eşittir ve bir girişteki üyelik fonksiyonu sayısı kural sayısına eşittir. Aynı üyelik fonksiyonu sayılarıyla, Şekil 3.1'deki T2FWNN-M1 modelinde 4 tane kural varken, Şekil 3.2'deki T2FWNN-M1 modelinde 2 tane kural vardır.

**Katman 4:** Bu katman normalleştirme katmanıdır. Her bir kuralın normalleştirilmiş ağırlığı bu katmanda hesaplanmaktadır.

T2FWNN-M1 için:

$$\underline{\lambda}_{ij} = \frac{\underline{\eta}_{ij}}{\sum_{i=1}^2 \sum_{j=1}^2 \underline{\eta}_{ij}} \quad (3.10)$$

$$\bar{\lambda}_{ij} = \frac{\bar{\eta}_{ij}}{\sum_{i=1}^2 \sum_{j=1}^2 \bar{\eta}_{ij}} \quad (3.11)$$

T2FWNN-M2 için:

$$\underline{\lambda}_j = \frac{\underline{\eta}_j}{\sum_{j=1}^2 \underline{\eta}_j} \quad (3.12)$$

$$\bar{\lambda}_j = \frac{\bar{\eta}_j}{\sum_{j=1}^2 \bar{\eta}_j} \quad (3.13)$$

**Katman 5:** Her bir kuralın işleyiş derecesi bu katmanda hesaplanmaktadır. Alt ve üst üyelik fonksiyonları için tasarım faktörü T2FWNN-M1 için  $q_{ij}$  ile T2FWNN-M2 için  $q_j$  ile gösterilmektedir.

T2FWNN-M1 için:

$$f_{ij} = (q_{ij} \underline{\lambda}_{ij} + (1 - q_{ij}) \bar{\lambda}_{ij}) g_{ij} \quad (3.14)$$

$$g_{km} = \sum_{i=1}^n w_i^{km} \left(1 - \left(\frac{x_i - b_i^{km}}{c_i^{km}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x_i - b_i^{km}}{c_i^{km}}\right)^2\right) \quad (3.15)$$

T2FWNN-M2 için:

$$f_j = (q_j \underline{\lambda}_j + (1 - q_j) \bar{\lambda}_j) g_j \quad (3.16)$$

$$g_j = \sum_{i=1}^n w_{ij} \left(1 - \left(\frac{x_i - b_{ij}}{c_{ij}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x_i - b_{ij}}{c_{ij}}\right)^2\right) \quad (3.17)$$

Geleneksel olarak, daha önceki çalışmalarda (Juang ve Tsao, 2008; Juang ve ark., 2009b; Singh ve ark., 2009; Aliev ve ark., 2011) bütün kural tabanı için tek bir tasarım faktörü belirlenmiştir. Ancak bu tezde, üyelik fonksiyonlarının alt ve üst kısımlarını ayarlayabilmek için, her bir kural için ayrı bir tasarım faktörü belirlenmiştir.

**Katman 6:** Modelin toplam çıktı değeri her bir kuralın çıkış değerlerinin ağırlıklı toplamı olarak hesaplanmaktadır.

T2FWNN-M1 için:

$$y = \sum_{i=1}^2 \sum_{j=1}^2 f_{ij} \quad (3.18)$$

T2FWNN-M2 için:

$$y = \sum_{j=1}^2 f_j \quad (3.19)$$

### 3.3. T2FWNN Öğrenme Algoritması

Sistem tanımlama veya fonksiyon yaklaşımı problemlerinde T2FWNN model parametrelerinin optimal değerlerini elde etmek için, gradyan tabanlı bir öğrenme algoritması seçilmiştir. Bu tip algoritmalarda öncelikli olarak minimize edilecek amaç fonksiyonu seçilir ve böylece T2FWNN modeli, modellenecek sistemin durumlarını ya da fonksiyon çıkışlarını yakalayabilir. Burada ortalama kare hata (MSE) performans indeksi olarak seçilmiştir:

$$E = \frac{1}{N} \sum_{k=1}^N (y - y_d)^2 \quad (3.20)$$

Burada  $N$  yaklaşımı yapılacak fonksiyonun giriş-çıkış veri sayıdır.  $y_d$  sistemin beklenen çıkışı iken,  $y$  ise T2FWNN'nin model çıkışıdır.

Bu tezde Newton benzeri algoritmalarından biri olan Davidon-Fletcher-Powel (DFP) (Nocedal ve Wright, 2006) algoritması, sistemdeki bilinmeyen parametrelerin eğitimi için kullanılmıştır. Bu yöntem öğrenme kuralının her bir iterasyonunda amaç fonksiyonunun gradyanlarına ihtiyaç duymaktadır.

$$g_p^k = \frac{\partial E}{\partial p} \text{ (geri geçiş)} \quad (3.21)$$

$$p_{k+1} = p_k + \alpha_k d_k \text{ (parametre yenileme)} \quad (3.22)$$

$$\alpha_k = \min_{\alpha} J(p_k + \alpha d_k) > 0 \text{ (optimal adım uzunluğu belirleme)}$$

(3.23)

$$d_{k+1} = -H_k g_k \quad (3.24)$$



$$H_{k+1} = H_k + \left[ \frac{\Delta p_k (\Delta p_k)^T}{(\Delta p_k)^T \Delta g_k} - \frac{H_k \Delta g_k (\Delta g_k)^T (H_k)^T}{(\Delta g_k)^T H_k \Delta g_k} \right], \quad H_0 = I \quad (3.25)$$

$$\Delta p_k = p_{k+1} - p_k, \quad \Delta g_k = g_{k+1} - g_k \quad (3.26)$$

$\Delta p$  ve  $\Delta g$  sırasıyla parametre ve gradyan vektörlerinin geri farklarını göstermektedir. Bunlar parametre ve gradyan değişimlerinin geçmiş bilgisini vererek ikinci dereceden yaklaşık bir bilgi sunmaktadır.

T2FWNN modelinin öğrenme algoritması her bir yenileme döneminde üç ana adımdan oluşmaktadır.

1. Model çıkışı hesaplama
2. Parametre gradyanlarını hesaplama
3. Ağ parametrelerini güncelleme

DFP algoritmasının en önemli özelliklerinden biri, yöntemin kararsız sonuçlar üretmemesidir. Görüldüğü üzere DFP formülü düzenlemelerle Hessian matrisini tahmin etmektedir. Amaç fonksiyonu eğrisinde yanlış bir tahmin olduğu zaman Hessian yaklaşımı (3.25) birkaç adımda kendi kendini düzeltecektir. (Nocedal ve Wright, 2006)'de belirtildiği ve kanıtlandığı üzere DFP yöntemi Wolfe koşullarını sağlayan bir çizgi arama yöntemiyle gerçekleştirildiğinde kararlıdır. Wolfe koşulları, kuadratik amaç fonksiyonunun kararsızlıkla karşı karşıya kalmadan uygun eğri bilgisini elde edebilmek için, gradyanların örneklendiğini garanti etmektedir (Nocedal ve Wright, 2006). Bu tezde kullanılan kübik interpolasyon çizgi arama yöntemi de Wolfe koşullarını sağlamaktadır.

Öğrenilecek parametre sayısı çok olduğunda, eğitim çok zaman alabilir ve oldukça fazla hafızaya ihtiyaç duyabilir. Bu da işlemi yavaşlatır. Eğitim zamanını hızlandırmak için eğitim setini birkaç parçaya bölebiliriz ve her bir parçanın gradyanlarını paralel olarak hesaplayabiliriz. Böylece gradyanlar paralel olarak hesaplanmış ve öğrenme işlemi hızlanmış olur. Ayrıca şunu söyleyebiliriz ki, öğrenmenin her bir iterasyonunda, gradyan ve maliyet hesabına ek olarak  $O(n^2)$  aritmetik operasyon gerçekleşmiş olduğu söylenebilir. T2FWNN model eğitimi için seçilen öğrenme algoritması tasarlanan model için güçlü ve yeterince hızlı yakınsama özelliklerine sahiptir (Nocedal ve Wright, 2006). Sonuç olarak, DFP

algoritmasının en önemli avantajı ikinci dereceden türevlerin hesabına gerek duymamasıdır.

Öğrenme algoritmasının her bir iterasyonunda, performans indeksinin bütün bilinmeyen parametrelere ( $q$ ) göre kısmi türevlerinin  $g = \frac{\partial E}{\partial q}$  hesaplanması gerekmektedir. Performans indeksinin, T2FWNN modellerindeki üyelik fonksiyonu parametrelerine göre türevi aşağıdaki formüller ile hesaplanabilir:

$$\frac{\partial E}{\partial \mu_{ij}} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial \Psi_{ij}} \frac{(x_j - \mu_{ij})}{\sigma_{ij}^2} \left( 3 - \left( \frac{x_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (3.27)$$

$$\frac{\partial E}{\partial \sigma_{ij}} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial \Psi_{ij}} \frac{(x_j - \mu_{ij})^2}{\sigma_{ij}^3} \left( 3 - \left( \frac{x_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (3.28)$$

$$\frac{\partial E}{\partial y} = \frac{2}{N} \sum_{k=1}^N (y - y_d) \quad (3.29)$$

Denklem (3.27) ve (3.28)'deki hesaplamalar, alt ve üyelik fonksiyonlarının her ikisi için de geçerlidir. Yukarıdaki hesaplamalar için, çıkış  $y$ 'nin her bir üyelik fonksiyonuna göre kısmi türevlerine ihtiyaç vardır. Örnek olması açısından ilk giriş değişkeninin ilk üyelik fonksiyonuna göre türevi aşağıdaki gibi hesaplanabilir.

T2FWNN-M1 için:

$$\frac{\partial y}{\partial \Psi_{11}} = \frac{(q_{11}g_{11}\Psi_{21} + g_{12}\Psi_{22}) - yq_{11}(\Psi_{21} + \Psi_{22})}{\sum_{i=1}^2 \sum_{j=1}^2 \Psi_{1i}\Psi_{2j}} \quad (3.30)$$

$$\frac{\partial y}{\partial \bar{\Psi}_{11}} = \frac{(1 - q_{11})(g_{11}\bar{\Psi}_{21} + g_{12}\bar{\Psi}_{22}) - y(1 - q_{11})(\bar{\Psi}_{21} + \bar{\Psi}_{22})}{\sum_{i=1}^2 \sum_{j=1}^2 \bar{\Psi}_{1i}\bar{\Psi}_{2j}} \quad (3.31)$$

T2FWNN-M2 için:

$$\frac{\partial y}{\partial \Psi_{ij}} = \frac{q_j g_j \frac{\eta_j}{\Psi_{ij}} \sum_{k=1}^2 \eta_k - y q_j \frac{\eta_j}{\Psi_{ij}}}{\sum_{j=1}^2 \Psi_{1i} \Psi_{2j}} \quad (3.32)$$

$$\frac{\partial y}{\partial \bar{\Psi}_{ij}} = \frac{(1-q_j)g_j \frac{\bar{\eta}_j}{\bar{\Psi}_{ij}} \sum_{k=1}^2 \bar{\eta}_j - y(1-q_j) \frac{\bar{\eta}_j}{\bar{\Psi}_{ij}}}{\sum_{j=1}^2 \bar{\Psi}_{1i} \bar{\Psi}_{2j}} \quad (3.33)$$

Diğer gradyan hesaplamaları aşağıda verilmiştir.

T2FWNN-M1 için:

$$\frac{\partial E}{\partial w_i^{km}} = \frac{\partial E}{\partial y} v_{km} \left( 1 - \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \quad (3.34)$$

$$\frac{\partial E}{\partial b_i^{km}} = \frac{\partial E}{\partial y} v_{km} w_i^{km} \frac{(x_i - b_i^{km})}{(c_i^{km})^2} \left( 3 - \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \quad (3.35)$$

$$\frac{\partial E}{\partial c_i^{km}} = \frac{\partial E}{\partial y} v_{km} w_i^{km} \frac{(x_i - b_i^{km})^2}{(c_i^{km})^3} \left( 3 - \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \quad (3.36)$$

$$\frac{\partial E}{\partial q_{km}} = \frac{\partial E}{\partial y} \left( \frac{\eta_{km}}{\sum_{l=1}^t \eta_l} - \frac{\bar{\eta}_{km}}{\sum_{l=1}^t \bar{\eta}_l} \right) \sum_{i=1}^n w_i^{km} \left( 1 - \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_i^{km}}{c_i^{km}} \right)^2 \right) \quad (3.37)$$

$$v_{km} = \frac{q_{km} \eta_{km}}{\sum_{i=1}^t \eta_i} + \frac{(1-q_{km}) \bar{\eta}_{km}}{\sum_{i=1}^t \bar{\eta}_i} \quad (3.38)$$

T2FWNN-M2 için:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y} v_j \left( 1 - \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \quad (3.39)$$

$$\frac{\partial E}{\partial b_{ij}} = \frac{\partial E}{\partial y} v_j w_{ij} \frac{(x_i - b_{ij})}{(c_{ij})^2} \left( 3 - \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \quad (3.40)$$

$$\frac{\partial E}{\partial c_{ij}} = \frac{\partial E}{\partial y} v_j w_{ij} \frac{(x_i - b_{ij})^2}{(c_{ij})^3} \left( 3 - \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \quad (3.41)$$

$$\frac{\partial E}{\partial q_j} = \frac{\partial E}{\partial y} \left( \frac{\eta_j}{\sum_{l=1}^t \eta_l} - \frac{\bar{\eta}_j}{\sum_{l=1}^t \bar{\eta}_l} \right) \sum_{i=1}^n w_{ij} \left( 1 - \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{x_i - b_{ij}}{c_{ij}} \right)^2 \right) \quad (3.42)$$

$$v_j = \frac{q_j \eta_j}{\sum_{i=1}^t \eta_i} + \frac{(1 - q_j) \bar{\eta}_j}{\sum_{i=1}^t \bar{\eta}_i} \quad (3.43)$$

Prensip olarak, T2FWNN-M1 modelinde üyelik fonksiyonu sayısını seçerken herhangi bir kısıtlama yoktur. Verilen benzetim örneklerinde üyelik fonksiyonu sayısı önceden belirlenmiştir. Girişlerin ve bunların üyelik fonksiyonlarının sayısı kümeleme algoritmaları kullanılarak da bulunabilir. Genel olarak girişteki değişken sayısı arttıkça, kural sayısı artmaktadır. Böyle olduğunda, T2FWNN model tasarımında “boyut fazlalığı” problemi ile karşı karşıya gelebiliriz.

Gradyan tabanlı öğrenme algoritması kullandığımızda düşünmemiz gereken diğer bir nokta da T2FWNN başlangıç parametrelerinin değerlerini nasıl seçeceğimizdir. DFP algoritması yerel bir minimum noktasına yakınsayacağını garanti etmektedir. Bu tezde önerilen T2FWNN modellerinde, sistem tanımlama benzetimlerinde başlangıç değerleri rasgele alınmıştır ve çok sayıda benzetim yapılarak elde edilen en iyi sonuçlar sunulmuştur. Verilen sonuçlar optimum sonuçlar olmayabilir. Çünkü, diğer gradyan tabanlı algoritmalar gibi DFP algoritması global minimumu bulacağını garanti etmez.

### 3.4. Sistem Tanıma Sonuçları

Bu bölümde önerilen T2FWNN modellerinin sistem tanımlama performansını gösterebilmek için üç farklı simülasyon örneği verilmiştir. Hem tip-1 bulanık dalgacık sinir ağının (T1FWNN) hem de T2FWNN modellerinin gürültülü ve gürültüsüz sonuçları verilmiştir. Böylece belirsizlik olarak gürültülü durumlarda modelin sonuçları incelenmiştir. Ayrıca önerilen T2FWNN modelleri kendi arasında da karşılaştırılmıştır.

### 3.4.1. Örnek 1

Bu örnekte, tanımlanacak sistem aşağıdaki denklemlerle verilmiştir:


$$y(k) = 0.72y(k-1) + 0.025y(k-2)u(k-2) + 0.01u^2(k-3) + 0.02u(k-4) \quad (3.44)$$

Sistemin çıktısı geçmiş iki çıkış değerine ve geçmiş üç giriş değerine bağlı olarak değişmektedir. Ancak sadece  $u(k-1)$  ve  $y(k)$ , T1FWNN ve T2FWNN modellerinde çıkış  $y(k+1)$ 'i tahmin etmek için giriş verisi olarak kullanılmıştır. Her bir FWNN modelinin girişi için ikişer tane üyelik fonksiyonu seçilmiştir. (Juang ve Lin, 1999; Juang, 2002)'e benzer olarak 900 tane giriş verisi kullanılmıştır. Girişlerin yarısı  $[-2, 2]$  üzerinde, bağımsız ve eş dağılmış (i.i.d) tekdüze bir dizidir ve geri kalan yarısı da  $1.05\sin(\pi k / 45)$  ile verilen bir sinüs fonksiyonudur. Eğitim yapıldıktan sonra aşağıda (3.45) ile verilen sinyal test için kullanılmıştır.


$$u(k) = \begin{cases} \sin(\pi k / 25) & k < 250 \\ 1.0 & 250 \leq k < 500 \\ -1.0 & 500 \leq k < 750 \\ 0.3\sin(\pi k / 25) + 0.1\sin(\pi k / 32) \\ \quad + 0.6\sin(\pi k / 10) & 750 \leq k < 1000 \end{cases} \quad (3.45)$$

T1FWNN ve T2FWNN için eğitim ve test sonuçları kök ortalama kare hata (RMSE) kullanılarak Çizelge 3.1 ve Çizelge 3.2'de sırasıyla verilmiştir. Belirsizlik olduğundaki test performansını görmek için 0.1 ve 0.3 standart sapmalarıyla (std) Gauss gürültüsü eğitim verilerine eklenmiştir. Bu gürültüler sadece eğitim setine eklenmiştir. Gürültü olmadığı durumdaki eğitim ve test performansı sırasıyla Şekil 3.3 ve Şekil 3.4'te gösterilmiştir. Sonuçlardan görüldüğü üzere eğitim verilerimize gürültü eklediğimizde T2FWNN modellerinin performansı daha iyidir. T2FWNN modellerinin diğer tip-1 ve tip-2 ağırlarıyla performans karşılaştırması Çizelge 3.3'te verilmiştir. T2FWNN modellerinin eğitim sonuçları daha kötü olmasına rağmen, literatürdeki diğer modellerle test sonuçları karşılaştırıldığında T2FWNN modeli en iyi modellerden biridir. Sonuçlardan görüldüğü üzere, T2FWNN modeli

T1FWNN modeliyle benzer sonuçlar vermiştir. Bunun nedeni de tip-2 bulanık kümeleri kullandığımızda ağın karmaşıklığının artması ve boyut fazlalığı problemiyle karşı karşıya gelmemizdir.



Şekil 3.3. T2FWNN-M2'de Örnek 1 için gürültü olmadan eğitim performansı



Şekil 3.4. T2FWNN-M2'de Örnek 1 için gürültü olmadan test performansı

**Çizelge 3.1.** Sistem tanımlama örnek 1 için eğitim sonuçları

	RMSE (gürültü yok)	RMSE (gürültü std=0.1)	RMSE (gürültü std=0.3)
T1FWNN	0.009771	0.100014	0.300717
T2FWNN-M1	0.010510	0.102387	0.295035
T2FWNN-M2	0.010578	0.097798	0.297917

**Çizelge 3.2.** Sistem tanımlama örnek 1 için test sonuçları

	RMSE (gürültü yok)	RMSE (gürültü std=0.1)	RMSE (gürültü std=0.3)
T1FWNN	0.022226	0.023932	0.026112
T2FWNN-M1	0.022488	0.023927	0.025841
T2FWNN-M2	0.022800	0.023072	0.024228

**Çizelge 3.3.** Sistem tanımlama örnek 1'in gürültüsüz performansının diğer bulanık sinir ağlarıyla karşılaştırılması

Modeller	Ağ parametreleri	RMSE Eğitim	RMSE Test
ERNN (Elman, 1990)	54	0.036	0.078
RSONFIN (Juang ve Lin, 1999)	49	0.03	0.06
TRFN-S (Juang, 2002)	33	0.0067	0.0313
FWNN-S (Yılmaz ve Oysal, 2010)	32	0.009771	0.022226
RSEIT2FNN-UD (Juang ve ark., 2009b)	42	0.0033	0.0058
RSEIT2FNN-UM (Juang ve ark., 2009b)	42	0.0034	0.006
IRT2FNN (Lin ve ark., 2010)	45	-	0.027
IT2RFNN (Juang ve ark., 2009a)	55	-	0.028
T2FWNN-M1	44	0.010510	0.022488
T2FWNN-M2	45	0.010578	0.022800


### 3.4.2. Örnek 2

İkinci örneğimiz aşağıdaki fark denklemini ile verilen sistemi modellemektedir (Juang ve Tsao, 2008; J.-Y. Chang, 2011).

$$y(k+1) = \frac{y(k)}{1+y^2(k)} + u^3(k) \quad (3.46)$$


Eğitim örnekleri  $k=1, \dots, 200$  aralığında  $u(k) = \sin(2\pi k/100)$  hesaplanarak elde edilmiştir. Bu örnekte kontrol sinyali  $u(k)$  ve geçmiş çıkış  $y(k)$ , çıkış  $y(k+1)$ 'i

tahmin etmek için kullanılmıştır. Modellerde, her bir giriş için üçer tane üyelik fonksiyonu seçilmiştir. Bu durumda T2FWNN-M1’de toplam 9 tane kural varken, T2FWNN-M2’de 3 tane kural vardır. Eğitim RMSE değerleri Çizelge 3.4’te verilmiştir. Gürültü eklenmemiş eğitim sonuçları Şekil 3.5’te gösterilirken, 0.1 standart sapmalı gürültülü eğitim sonuçları ise Şekil 3.6’da gösterilmiştir. Bu sistem için sonuçları incelediğimizde, gürültü olmayan eğitim örneklerinde T1FWNN tahmin performansı T2FWNN’nin tahmin performansından daha iyidir. Ancak veriye  $\text{std}=0.1$  ve  $\text{std}=0.3$  olacak şekilde Gauss gürültüsü eklediğimizde, T2FWNN modelinin sonuçlarının daha iyi olduğu görülmüştür. Böylece, T2FWNN modellerinin belirsizlik ortamında daha başarılı kestirimde bulunduğu görülmüştür. Ayrıca, önerilen modeller, literatürde önerilen diğer tip-2 bulanık sistemleriyle karşılaştırılmıştır. Çizelge 3.4’de gürültü sonuçlar verilmişken Çizelge 3.5’de ise gürültü olmadığı durumda model diğer sinir ağı modelleriyle karşılaştırılmıştır. Sonuçlara göre T2FWNN modellerinin sonuçları hem gürültülü hem de gürültüsüz girişler için iyidir.



Şekil 3.5. Gürültü olmadan Örnek-2 için T2FWNN-M2 eğitim performansı





Şekil 3.6.  $\text{std}=0.1$  gürültülü Örnek-2 için T2FWNN-M2 eğitim performansı

Çizelge 3.4. Örnek-2 için eğitim sonuçları

	RMSE (gürültü yok)	RMSE (gürültü $\text{std}=0.1$ )	RMSE (gürültü $\text{std} = 0.3$ )
T1FWNN	0.000156	0.089081	0.264917
T2FWNN-M1	0.003102	0.086421	0.253627
T2FWNN-M2	0.002712	0.094232	0.269761


Çizelge 3.5. Örnek-2'nin gürültü olmadığı durumda diğer ağlarla eğitim performansının karşılaştırılması

	Ağ parametreleri	RMSE Eğitim
SEIT2FNN (Juang ve Tsao, 2008)	36	0.0062
FLIT2CFNN (J.-Y. Chang, 2011)	66	0.0035
T1FWNN	66	0.000156
T2FWNN-M1	87	0.003102
T2FWNN-M2	60	0.002712

### 3.4.3. Örnek 3

Bu bölümde önerilen modeller, metan-hava karışımının yanma işleminden elde edilen verilerden oluşan Box-Jenkins zaman serisi (gaz ocağı verisi) (Box, 1970; Chen ve ark., 2006) verisine uygulanmıştır. Bu sürecin girişi  $u(k)$  gaz akış

oranı ve çıkışı  $y(k)$  ise çıkış gazı içerisindeki  $\text{CO}_2$  konsantrasyonudur (Chen ve ark., 2006). Çıkış  $y(k)$ 'i tahmin edebilmek için  $u(k-4)$  ve  $y(k-1)$  modellerde giriş olarak kullanılmıştır. Toplamda 292 tane giriş-çıkış verisi bulunmaktadır. Bunlardan ilk 200 tanesi modellerin eğitimi için kullanılırken kalanı da modelleri test etmek için kullanılmıştır. Her bir T2FWNN modeli 500 dönemde (epoch) eğitilmiştir. Eğitim ve test tahmin sonuçları ile tahmin hatası değerleri Şekil 3.7'de gösterilmiştir. Ayrıca, Çizelge 3.6 ve Çizelge 3.7'de bu veri setinde eğitim ve testteki RMSE değerleri verilmektedir. Sonuçlardan görüldüğü ki önerilen modeller Box-Jenkins veri setini iyi bir şekilde modelleyebilmektedir.



Şekil 3.7. Box Jenkins veri setinin T2FWNN-M2 eğitim ve test sonuçları

Çizelge 3.6. Box Jenkins veri setinin eğitim sonuçları

	RMSE (gürültü yok)	RMSE (gürültü std=0.05)	RMSE (gürültü std=0.1)
<b>T2FWNN-M1</b>	0.0244	0.0512	0.0881
<b>T2FWNN-M2</b>	0.0169	0.0448	0.0961

Çizelge 3.7. Box Jenkins veri setinin test sonuçları

	RMSE (gürültü yok)	RMSE (gürültü std=0.05)	RMSE (gürültü std=0.1)
<b>T2FWNN-M1</b>	0.0347	0.0562	0.0626
<b>T2FWNN-M2</b>	0.0233	0.0353	0.0414

### 3.5. Sonular

Tezin bu kısmında, yeni bir T2FWNN modeli sunulmuştur ve gradyan tabanlı bir algoritmaya göre parametre güncelleme kuralları türetilmiştir. Önerilen modellerin performansını deęerlendirmek için, benzetim alıřmaları gerekleřtirilmiştir ve dinamik sistemlerin tanımlanması için sonular sunulmuştur. Bütün durumlarda, T2FWNN modelleri yüksek yaklařım doęruluęu ve aynı zamanda sistemden gürültüyü kaldırarak iyi bir genelleřtirme performansı göstermiştir. Daha önce önerdięimiz FWNN modelini tip-2 bulanık kümeleriyle birleřtirdięimizde, elde ettięimiz T2FWNN modelinin gürültü ve belirsizlik olduęu durumlarda dięer nöro-bulanık mimarilere göre üstün özellikler tařıdıęı görülmüştür. Gürültü olmadıęı durumlarda, T2FWNN modellerinin performansı FWNN modelinin performansına göre ok deęiřmemiştir. Bunun nedeni de tip-2 bulanık kümelerinin üç boyutlu yapısının sistemin hesaplama karmařıklıęını arttırmasıdır. Karmařıklıęın artması global minimumu yakalama řansının azalması demektir.

## 4. SİSTEM MODELLEME VE KONTROL UYGULAMALARI İÇİN DİNAMİK ADAPTİF NÖRO-BULANIK ÇIKARIM SİSTEMİ (DANFIS) TASARIMI

### 4.1. Giriş

Endüstriyel uygulamaların büyük çoğu dinamik süreçlerin modellenmesi ve kontrolü ile ilgilidir. Bu süreçler karmaşık, lineer olmayan ve bazen durağan olmayan dinamiklere sahiptir. Ölçülemez parametre ve değişkenlerin etkisiyle diferansiyel denklem sistemi olarak gösterilemezler. Diğer bir ifadeyle, süreç dinamiğinin hassas modellerini yapmak, süreç karmaşıklığı arttıkça zorlaşmaktadır. Daha önce bahsedildiği gibi ANFIS en çok kullanılan nöro-bulanık sistemlerden biridir. Ancak, ANFIS sayısal çıkışların değerini hesaplamak için girişlerin polinom fonksiyonlarını kullanan cebirsel fonksiyon yapısına sahiptir. Bu nedenle, ANFIS ile süreçlerin dinamik yapısını belirleyen çalışma yoktur. Daha önce önerilen ANFIS gibi bulanık modeller sistemin sadece dış davranışı ile ilgilenmektedir. Modelin yapısal parametrelerinden iç davranışını elde etmek ve bu model parametrelerini denetleyici tasarlamak için kullanmak oldukça zordur (Cao ve Rees, 1995).

Lineer olmayan dinamik sistemin iç davranışını modellemek ve onun için bir denetleyici tasarlamak istediğimizde, iyi bilinen bulanık sistemlerden biri olan T-S bulanık sistemi kullanılabilir. Çünkü T-S dinamik bulanık modeli hem bulanık IF-THEN kurallarını hem de yerel dinamik modelleri içermesi nedeniyle birleşik bir sistem içine nitel ve nicel bilgiyi birleştirecek bir yol sağlamaktadır. Bu model 1985'te sunulduğundan beri birçok araştırmacı bu konu üzerine odaklanmıştır (Takagi ve Sugeno, 1985).

Literatürde önerilen ANFIS benzeri fonksiyonel bulanık modellerle karşılaştırıldığında, T-S modellerinin bazı dezavantajları vardır. Fonksiyonel bulanık modellerin en önemli avantajı, ilgilendikleri sistemin dinamik özellikleri o anki ele alınan sürecinin dış davranışını gerçeklemek için bulanık kurallar ile uzmanların tecrübesinde tutulmasıdır (Cao ve ark., 1997; Ismail ve ark., 2009). Ancak, eğer uzmanın amacı kontrol ise, geleneksel bulanık mantık genel bir kontrol

kuralı oluşturmaz. Sadece, uzmanın tecrübesinin o anki fonksiyonel haritalamasını gerçekleştirir. Diğer bir deyişle üzerinde çalışılan sistemin genel dinamiği hakkında bilgi vermez. Fakat T-S bulanık modelleri, kurallarındaki üyelik fonksiyonlarının parametrelerinin elde edilmesi zor olmasına rağmen, yerel dinamik özellikleri modelleyebildikleri için sistemin iç davranışını tam olarak temsil ederler. Literatürde T-S bulanık modeller üzerine yer alan çalışmaların çoğunluğu kararlılık analizi ve yerel modellerin sentezi üzerinedir. Fakat “T-S modellerdeki yerel modeller nasıl elde edilir?” sorusu cevaplanması gereken önemli bir sorudur. Bu tezde bu sorunun cevabı için DANFIS (Yılmaz ve Oysal, 2014) olarak adlandırılan yeni bir model önerilmektedir. Bu model T-S modelinin bir yapay sinir ağı gösterimidir. Bilindiği üzere T-S bulanık sistemler homojen ve afin bulanık modeller olarak iki sınıfa ayrılabilirler (Kim ve Kim, 2002). Bu iki model arasındaki fark afin modellerde her bir kuralda baz bir terimin bulunmasıdır. Ancak homojen modellerde bu terim yoktur. Bu tezde önerilen DANFIS afin bir modeldir. DANFIS modeli ile sadece sistemin giriş-çıkış verisi arasındaki bağıntı değil ayrıca sistemin iç davranışını da modellenmiş olur. Böylece modelin yapısal parametrelerinden kolayca bir denetleyici tasarlanabilir.

DANFIS ağının model fikri ANFIS’ten gelmektedir. Standart ANFIS’te gizli katmandaki (kural tabanındaki sebep kısımları) aktivasyon fonksiyonları genellikle Gauss fonksiyonlarıdır. Her bir kuralın sonuç kısmında da giriş değişkenlerinin polinom fonksiyonları yer alır. Bu tezde önerilen DANFIS modelinde ANFIS’ten farklı olarak sonuç kısmındaki kurallarda yerel dinamikleri temsil eden baz terimli lineer diferansiyel denklemler yer almaktadır. Baz teriminin olması bazı araştırmacılara göre T-S bulanık sistemlerin fonksiyon yaklaşımı yeteneklerini arttırmaktadır (Cao ve ark., 1997). Aynı zamanda, bu terimin olması kararlılık analizlerini zorlaştırmamaktadır (Wang ve Yang, 2013). Bu durumları dikkate alarak, bulanık kuralların sonuç kısımlarında bu terimlerin olmasının ilginç sonuçlar elde etmemizi sağlayacağı düşünülmüştür.

## 4.2. DANFIS Yapısı

Önerilen DANFIS yapısını anlatmadan önce, T-S bulanık modelin bilinen ayrıntılarına bakalım. T-S bulanık sistemi IF-THEN bulanık kuralları ile açıklanır. Kurallarının IF kısmında girişlere ait Gauss tipi üyelik fonksiyonlu bulanık kümeler vardır. THEN kısımlarında ise modellenen dinamik sistemin giriş-çıkış ilişkisini temsil eden yerel dinamik denklemler vardır. T-S bulanık sistemler homojen ve afin adlarında iki kategoride değerlendirilir. Homojen T-S bulanık sistemde sonuç kısmındaki denklemler homojendir. Afin sistemlerde ise artı baz terimleri mevcuttur. Bu tezde afin sistemler daha genel olduğu için kuralların sonuç kısımlarında sabitler de bulunmaktadır. Bu tezde kullanılan afin T-S bulanık sistemde yer alan kurallar şu formdadır:

$$R_j : \text{IF } x_1 \text{ is } M_{1j} \text{ and } x_2 \text{ is } M_{2j}, \dots, x_n \text{ is } M_{nj}, \\ \text{THEN } \dot{x} = A_j x + B_j u + c_j$$

Burada  $x^T = (x_1, x_2, \dots, x_n)$  modellenecek sistemin lineer durum değişkenleridir;  $u$  kontrol girişleridir;  $R_j$  ( $j = 1, 2, \dots, r$ )  $j$ . bulanık kuraldır ve  $M_{1j}, M_{2j}, \dots, M_{nj}$  ise kuralların koşul kısımlarındaki bulanık kümelerdir. Bu durumda T-S bulanık sistemin arındırma mekanizmasına göre sonuç durum denklemleri şu şekilde yazılabilir:

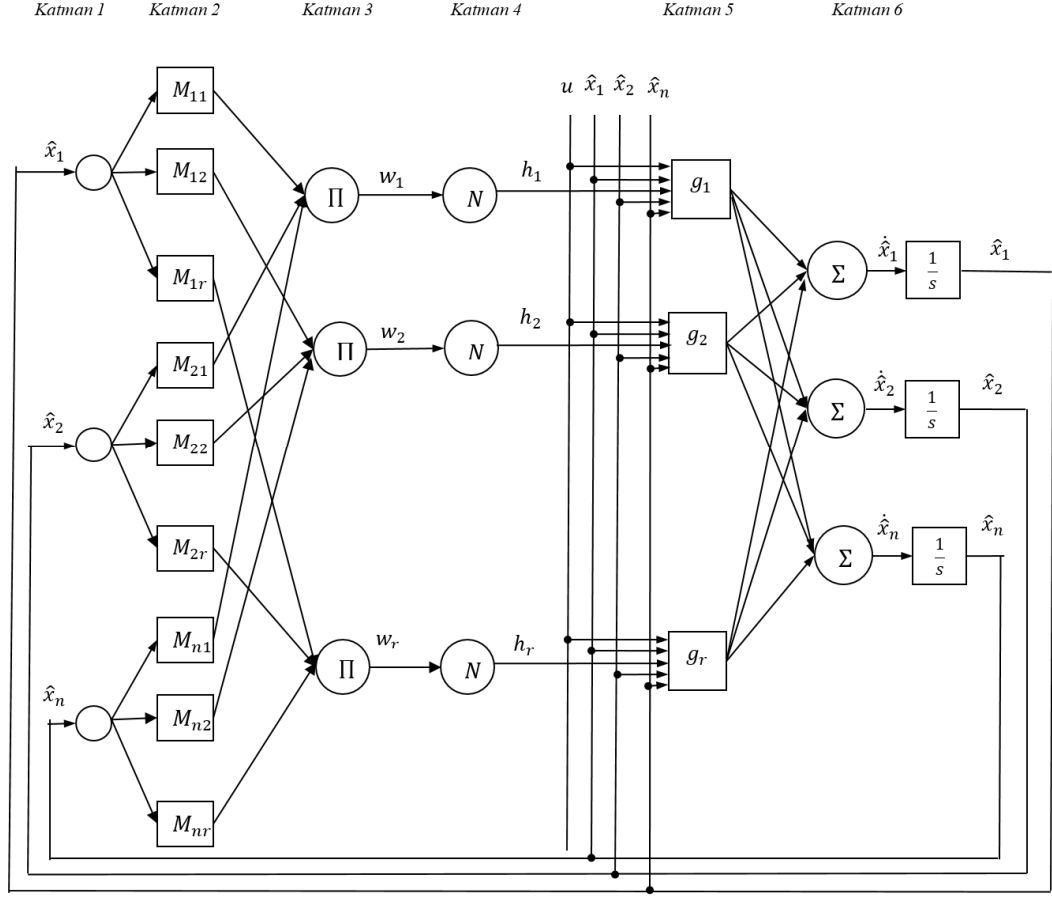
$$\dot{x} = \frac{\sum_{j=1}^r w_j (A_j x + B_j u + c_j)}{\sum_{j=1}^r w_j} = \sum_{j=1}^r h_j(x) \{A_j x + B_j u + c_j\} \quad (4.1)$$

$$w_j(x) = \prod_{i=1}^n M_{ij}(x_i) \quad (4.2)$$

$$h_j(x) = \frac{w_j(x)}{\sum_{i=1}^r w_i(x)}, \quad h_j(x) \geq 0 \quad (4.3)$$

Şimdi yukarıdaki ifadelerle sahip afin T-S bulanık modeline eşdeğer adaptif bir sinir ağ yapısı olan DANFIS'i tanıtabiliriz. Burada T-S bulanık modelimizin  $n$

tane durum değişkenine  $r$  tane kurala sahip olduğunu varsayalım. Şekil 4.1 DANFIS modelinin yapısını katmanları ile göstermektedir.



Şekil 4.1. DANFIS ve DFWNN yapısı

Katman 1, modellenecek sistemin durum değişkenlerini temsil etmektedir. Üzerlerine şapka imgeci, DANFIS modelinin kestirdiği durum değişkenleri ile gerçek durum değişkenlerini birbirinden ayırt etmek için konulmuştur. Katman 2, bulanıklaştırma katmanıdır. Bu katmanda aşağıdaki gibi Gauss tipi üyelik fonksiyonları kullanılarak bulanıklaştırma yapılmıştır.

$$M_{ij} = \exp\left(-\frac{1}{2} \left(\frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}}\right)^2\right) \quad (4.4)$$

Burada  $\mu_{ij}$  ve  $\sigma_{ij}$   $i$ . durum değişkeninin  $j$ . kuralına ait üyelik fonksiyonunda yer alan merkez ve genişlik parametreleridir. Katman 3'teki her bir düğüm bir bulanık kuralın sebep kısmını temsil eder. Kurallar içerisindeki bağlaç “ve” olarak

düşünüldüğünden bu bağlaç işlemi için çarpım t-norm operatörü seçilmiştir. Bu katmanın çıkışı (4.2) denklemindeki kuralların işleyiş derecelerini göstermektedir. 4. Katman normalizasyon katmanıdır. Bu katmanda her kuralın diğer kuralların işleyiş derecesine bağlı ağırlığı belirlenmektedir. Bu katmandan sonra kuralların sonuç kısmına ulaşılır. Kuralların sonuç kısmı lineer diferansiyel denklemlerdir. Her bir denklem modellenecek sistemin yerel bölgelerdeki durum değişkenlerinin girişe bağlı dinamiğini temsil eder. Katman 5, bu türev denklemlerinin sağ tarafında yer alan fonksiyonları üretmektedir.  $i$ . durum değişkeni için  $j$ . kuralın fonksiyon ifadesi şu şekildedir:

$$g_{ij}(\hat{x}) = \sum_{m=1}^n k_{ij}^m \hat{x}_m + c_{ij} + b_{ij}u \quad (4.5)$$

Katman 6, her bir kuralın sonuç ifadesidir. Durum değişkenlerinin o anki değerlerine bağlı olarak her bir kuralın ağırlıklandırılmış işleyiş derecesi hesaplanır ve her kuralın dinamiği bu ağırlığa göre tüm sistem dinamiğine katkı sağlar. Yani bu katmandaki nihai dinamikler önceki katmandan gelen lineer fonksiyonların ağırlıklandırılmış toplamıdır ve kestirilen sistem dinamikleri şu şekilde yazılabilir:

$$\dot{\hat{x}}_i = \hat{f}_i(\hat{x}, p) = \sum_{j=1}^r h_j g_{ij}(\hat{x}) \quad (4.6)$$

DANFIS modelinin yapısını tanıttıktan sonra ve öğrenme yöntemlerini konuşmadan önce, afin bulanık modelinin kararlılığını değerlendirmeliyiz. Lineer olmayan dinamik sistemleri modellerken ilk örnek “sıfır-giriş cevabı”dır. Böyle olduğunda DANFIS modelinin çıkışı şu şekildedir:

$$\dot{\hat{x}} = \frac{\sum_{j=1}^r w_j (A_j \hat{x} + c_j)}{\sum_{j=1}^r w_j} = \sum_{j=1}^r h_j(\hat{x}) \{A_j \hat{x} + c_j\} \quad (4.7)$$

Denklem (4.1) ve (4.7) ile verilen afin bulanık modelinin kararlılığı, yani açık-döngü ve kapalı-döngü kararlılık analizi, kuadratik Lyapunov fonksiyonlarına göre (Kim ve Kim, 2002)’de açıkça verilmiştir. Burada sıfır-giriş durumu özetlenmiştir. Denklem (4.7) için kararlılık koşullarını yeniden anımsayalım.  $I_\xi$  orijin  $x=0$ ’ı içeren bulanık kurallar için indeksler kümesi olsun:

$$I_\xi \equiv \{\xi \mid h_\xi(0) \neq 0\}$$



Sonra,  $i \in I_\xi$  için, (4.7)'deki sabit terimin 0 olacağı varsayılır ve bu varsayım orijin  $x=0$ 'ın afin bulanık sistemin denge noktası olduğunu garanti eder. Afin bulanık sistemin (4.7) kuadratik kararlı olması için yeterli olan koşul (Kim ve Kim, 2002)'de aşağıdaki teorem ile verilmiştir:

*Teorem (Kim ve Kim, 2002)* : Eğer aşağıdaki koşulları sağlayan bir ortak pozitif tanımlı matris  $P = P^T$  ve  $\tau_{iq}$  varsa, sürekli afin bulanık sistemi (4.7) kuadratik olarak kararlıdır:

$$A_i^T P + P A_i < 0 \quad (4.8)$$

bulanık kurallar için  $R_i$  ( $i \in I_\xi$ ) ve

$$\tau_{iq} > 0, \left( \begin{array}{cc} A_i^T P + P A_i - \sum_{q=1}^n \tau_{iq} T_{iq} & P c_i - \sum_{q=1}^n \tau_{iq} u_{iq} \\ c_i^T P - \sum_{q=1}^n \tau_{iq} u_{iq}^T & - \sum_{q=1}^n \tau_{iq} v_{iq} \end{array} \right) < 0 \quad (4.9)$$

diğer bulanık kurallar için  $R_i$  ( $i \notin I_\xi$ ),  $T_{iq}$ ,  $u_{iq}$  ve  $v_{iq}$  aşağıdaki gibi tanımlandığı durumda

$$F_{iq}(x) = x^T T_{iq} x + 2u_{iq}^T x + v_{iq} \leq 0 \quad (4.10)$$

koşulu bütün  $x$ 'ler için sağlanır ( $R_i$  ( $h_i(x) > 0$ )).

Bu teoremin detayları ve ispatı (Kim ve Kim, 2002)'de verilmiştir. Açık-döngü afin bulanık sistemi için kararlılık koşulları (4.8) ve (4.9) ile özetlenmiştir. Bu koşullar lineer matris eşitsizliği (LMI) açısından temsil edilmiştir. Böylece, DANFIS için kararlılık koşulları iç nokta algoritmaları ile nümerik olarak kolay ve etkili bir şekilde çözülebilir.

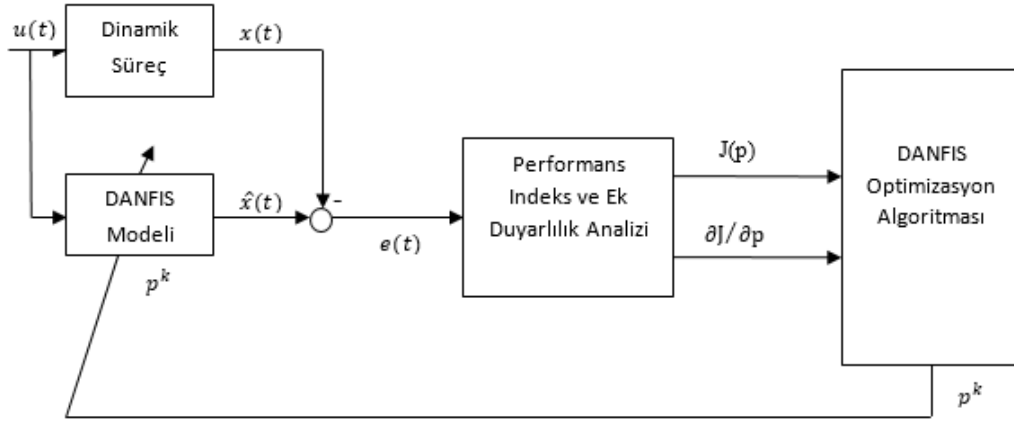
### 4.3. DANFIS Öğrenme Algoritması

Bu bölümde DANFIS modelinin öğrenme aşamaları tanıtılacaktır. Bu modelde de gradyan tabanlı bir öğrenme algoritması kullanılmıştır. İstenilen dinamik giriş-çıkış haritalamasını elde etmek için, DANFIS modelinin bilinmeyen parametreleri, lineer olmayan dinamik bir sistemin iç davranışını modelleyecek

şekilde, performans ölçütü minimize edilerek güncellenmiştir. DANFIS parametreleri amaç fonksiyonunu en aza indirgeyecek şekilde güncellenmiştir. Böylece, arzu edilen bir zaman aralığı içerisinde hedef durum eğrileri seçilen başlangıç koşullarından başlanarak izlenebilmektedir.

Modelimizin en uygun parametre değerlerini bulmak için, Şekil 4.2’de verildiği gibi bir optimizasyon problemine dayalı bir öğrenme algoritması kullanılmıştır. Algoritmanın adımları aşağıdaki gibi verilmiştir.

1. Başlangıç parametre değerleri  $(\mu_{ij}, \sigma_{ij}, k_{ij}^m, c_{ij})$  uzman tecrübesiyle, rasgele olarak ya da kümeleme algoritması ile belirlenir.
2. DANFIS model çıkışı o anki parametre değerlerine göre hesaplanır.
3. Performans ölçütü ve performans ölçütünün parametrelere göre gradyanları hesaplanır.
4. Eğer performans ölçütü hedef değere küçültülememişse, parametre değerleri optimizasyon algoritmasına göre tekrar güncellenir ve 2. adımdan algoritma döngüye devam eder.



Şekil 4.2. DANFIS öğrenme süreci

Bu tezde DANFIS modeli için üyelik fonksiyonlarının merkez değerleri bulanık c-ortalama (FCM) (Bezdek ve ark., 1984) kümeleme algoritması ile belirlenmiştir. FCM algoritması, verilen veriyi belirli bir sayıdaki kümelere ayıran

bir kümeleme algoritmasıdır. Bu yöntem aşağıda verilen amaç fonksiyonun minimize edilmesine dayanır (Bezdek ve ark., 1984):

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - \mu_j\|^2, 1 \leq m \leq \infty \quad (4.11)$$

Burada  $m$  1'den büyük herhangi bir reel sayı,  $x_i$   $i$ . veri,  $\mu_j$   $j$ . küme ve  $u_{ij}$  ise  $x_i$  verisinin  $j$ . kümede olmasının üyelik derecesidir. Bu algoritma aşağıdaki adımlardan oluşmaktadır (Bezdek ve ark., 1984).

1. Üyelik fonksiyonu matrisi  $U=[u_{ij}]$  başlangıç değerleri  $U^{(0)}$  belirlenir.
2.  $k$ . adımda: merkez vektörü  $C^{(k)}=[\mu_j]$ ,  $U^{(k)}$ 'ya bağlı olarak hesaplanır.

$$\mu_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (4.12)$$

3.  $U^{(k)}$  matrisi bir sonraki adım için  $U^{(k+1)}$ 'e güncellenir.

$$U_{ij} = \frac{1}{\sum_{k=1}^C \left( \frac{\|x_i - \mu_j\|}{\|x_i - \mu_k\|} \right)^{\frac{2}{m-1}}} \quad (4.13)$$

4.  $\|U^{(k+1)} - U^{(k)}\| < \varepsilon$  ise durulur; değilse 2. Adımdan devam edilir.

FCM algoritması ile bulunan merkez değerleri kullanılarak, kuralların koşul kısmındaki üyelik fonksiyonlarının merkez parametrelerinin başlangıç değerleri belirlenmiştir. Eğer modellenecek sürecin, doğrusal olmayan matematiksel modeli biliniyorsa, DANFIS modelinin sonuç kısmındaki lineer parametrelerin başlangıç değerleri, kümeleme algoritmasıyla bulduğumuz merkez değerlerinde doğrusallaştırma işlemi yapılarak bulunabilir. Tezin bu kısmında iyi bilinen dinamik sistemler ile çalışılmış ve modellerdeki parametrelerin başlangıç değerleri doğrusallaştırma işlemi ile bulunmuştur.

DANFIS ile modellemek istediğimiz doğrusal olmayan sistemin dinamiği aşağıdaki gibi verilmiş olsun:

$$\dot{x}(t) = f(x(t), u(t)) \quad (4.14)$$

Burada  $f$  doğrusal olmayan bir fonksiyon,  $x(t) = [x_1(t) \ x_2(t) \ \dots \ x_n(t)]^T$  durum vektörü, ve  $u(t) = [u_1(t) \ u_2(t) \ \dots \ u_m(t)]^T$  ise giriş vektörüdür. DANFIS öğrenmesiyle, eğitim ağı parametrelerini ayarlayarak doğrusal olmayan dinamik sistemin yörüngeleri takip edilebilmektedir. Bunun için, öncelikli olarak bir performans ölçütü seçilmelidir. Bu tezde kuadratik formda bir amaç fonksiyonu seçilmiştir:

$$\begin{aligned}
 J &= \int_{t_0}^{t_f} F(x, \hat{x}) dt \\
 &= \int_{t_0}^{t_f} 0.5[\hat{x}(t) - x(t)]^T [\hat{x}(t) - x(t)] dt
 \end{aligned} \tag{4.15}$$

Burada  $x(t)$ ,  $[t_0 \ t_f]$  zaman aralığında (4.14)'de verilen fonksiyon tarafından üretilen beklenen yörünge ve  $\hat{x}(t)$  ise aynı aralıkta DANFIS modelinin bulduğu cevaptır. Görüldüğü üzere amaç fonksiyonu hatanın  $e(t) = \hat{x}(t) - x(t)$  bir fonksiyonudur. Daha önce belirtildiği gibi DANFIS modelinin en uygun parametreleri, ANFIS modelinde olduğu gibi doğrudan en küçük kareler tahmini (LSE) ile bulunamaz. Çünkü ANFIS'te polinom fonksiyonlar var iken, DANFIS modelinde yerel dinamikleri gösteren diferansiyel denklemler vardır. Bu parametreleri optimize etmek için, bu tezde ek duyarlılık yöntemi (ASM) parametre gradyan hesabında kullanılmıştır (Bryson ve Ho, 1969; Konar ve Samad, 1992; Cao ve ark., 2002). ASM kısıtlı dinamik optimizasyon problemlerini çözmek için varyasyonlar hesabına dayalı bir yaklaşımdır. DANFIS modeli için, (4.14) ile verilen doğrusal olmayan bir sistemin modellenmesinde, optimizasyon problemi şu şekilde yazılabilir:

$$\begin{aligned}
 \min_{\hat{p}} J &= \int_{t_0}^{t_f} F(x, \hat{x}) dt, \\
 \dot{\hat{x}}(t) &= \hat{f}(x(t), p) = \sum_{j=1}^r h_j(\hat{x}(t)) \{A_j \hat{x}(t) + c_j\} \quad x(t_0) = x_0
 \end{aligned} \tag{4.16}$$

DANFIS'i belirli bir yörüngeyi takip etmek için ayarlamak, DANFIS parametrelerinin belirlenmesine eşdeğerdir. Böylece (4.6) tarafından üretilen model yörüngeleri (4.15)'de verilen amaç fonksiyonu minimize eder.

ASM'de yeni dinamik sistem ek durum değişkenleri  $\lambda$  ile tanımlanır:

$$-\dot{\lambda} = \left( \frac{\partial \hat{f}}{\partial \hat{x}} \right)^T \lambda + \frac{\partial F}{\partial \hat{x}} \quad \lambda(t_f) = 0 \quad (4.17)$$

Burada ek durum vektörümüzün boyutu,  $n$ , modellenecek dinamik sistemdeki durum değişken sayısını eşittir ve DANFIS ağının parametre sayısından bağımsızdır. Bu da hassasiyetleri hesaplamak için  $n$  bileşenin olduğunu gösterir. Diferansiyel denklemin integrali son zaman  $t_f$ 'ten ilk zaman  $t_0$ 'a zamanda geriye doğru hesaplanmalıdır. Bu tezde integral hesabını yaparken 5. dereceden Runge-Kutta-Butcher algoritması kullanılmıştır (Chapra ve Canale, 1988).

#### 4.3.1. DANFIS Gradyan Hesabı

Öğrenme işlemi, optimal DANFIS model parametrelerini elde edebilmek için, amaç fonksiyonunun (4.15) bütün parametrelere göre gradyanlarına ihtiyaç duymaktadır. Bilinmeyen parametre sayısı ne olursa olsun, ek durum vektörünün boyutu doğrusal olmayan sistemdeki durum vektörünün boyutuna eşittir. Ek yörüngeler elde edildikten sonra, DANFIS parametrelerine göre maliyet gradyanları aşağıdaki gibi hesaplanır:

$$\frac{\partial J}{\partial p} = \int_{t_0}^{t_f} \left( \frac{\partial \hat{f}}{\partial p} \right)^T \lambda(t) dt \quad (4.18)$$

Burada öğrenme algoritmasının her bir döngüsünde amaç fonksiyonlarının gradyanlarının hesaplandığı varsayılmaktadır.

Sadelik açısından daha açık gradyan formüllerini elde etmek için, dinamik kısıtlarla birlikte optimize edilecek amaç fonksiyonu performans kriterine bağlı olarak aşağıdaki gibi yazılabilir:

$$J = \int_{t_0}^{t_f} F(x) dt \quad (4.19)$$

$$F(x) = \sum_{i=1}^n 0.5(\hat{x}_i - x_i)^2 \quad (4.20)$$

Burada, sürecin  $i$ . durum değişkeni için  $\hat{x}_i$  DANFIS model cevabı iken,  $x_i$  beklenen süreç cevabıdır.

Her bir tekrarlama, ek değişkenleri hesaplayabilmek için aşağıda verilen diferansiyel denklem zamanda geriye doğru çözülür.

$$-\begin{bmatrix} \dot{\lambda}_1 \\ \dot{\lambda}_2 \\ \vdots \\ \dot{\lambda}_n \end{bmatrix} = \begin{bmatrix} \frac{\partial \hat{f}_1}{\partial \hat{x}_1} & \frac{\partial \hat{f}_2}{\partial \hat{x}_1} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_1} \\ \frac{\partial \hat{f}_1}{\partial \hat{x}_2} & \frac{\partial \hat{f}_2}{\partial \hat{x}_2} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial \hat{f}_1}{\partial \hat{x}_n} & \frac{\partial \hat{f}_2}{\partial \hat{x}_n} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_n} \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \end{bmatrix} + \begin{bmatrix} \hat{x}_1 - x_1 \\ \hat{x}_2 - x_2 \\ \vdots \\ \hat{x}_n - x_n \end{bmatrix} \quad (4.21)$$

burada  $\lambda(t_f) = 0$

Katsayısı matrisi, (4.6) 'de verilen DANFIS durum fonksiyonlarının birinci türevleri tarafından belirlenir. Ek değişkenleri hesaplarken,  $\frac{\partial \hat{f}}{\partial \hat{x}}$  matrisini aşağıdaki gibi hesaplamamız gerekmektedir:

$$\frac{\partial \hat{f}_m}{\partial \hat{x}_i} = \frac{z_2 \frac{\partial z_{1m}}{\partial \hat{x}_i} - z_{1m} \frac{\partial z_2}{\partial \hat{x}_i}}{(z_2)^2} \quad (4.22)$$

$$z_{1m} = \sum_{j=1}^r w_j(\hat{x}) g_{mj}(\hat{x}) \quad (4.23)$$

$$z_2 = \sum_{j=1}^r w_j(\hat{x}) \quad (4.24)$$

$$\frac{\partial z_{1m}}{\partial \hat{x}_i} = \sum_{j=1}^r \left( w_j \frac{(\mu_{ij} - \hat{x}_i)}{\sigma_{ij}^2} g_{mj}(\hat{x}) + w_j k_{mj}^i + w_j b_{ij} u \frac{(\mu_{ij} - \hat{x}_i)}{\sigma_{ij}^2} \right) \quad (4.25)$$

$$\frac{\partial z_2}{\partial \hat{x}_i} = \sum_{j=1}^r w_j \frac{(\mu_{ij} - \hat{x}_i)}{\sigma_{ij}^2} g_{mj}(\hat{x}) \quad (4.26)$$

Daha sonra ek değişkenleri kullanarak parametre gradyanlarını

$\left[ \frac{\partial J}{\partial \mu}, \frac{\partial J}{\partial \sigma}, \frac{\partial J}{\partial k}, \frac{\partial J}{\partial c}, \frac{\partial J}{\partial b} \right]$  hesaplayabiliriz.

$$\frac{\partial J}{\partial \mu_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial \mu_{ij}} \right] dt \quad (4.27)$$

$$\frac{\partial J}{\partial \sigma_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial \sigma_{ij}} \right] dt \quad (4.28)$$

$$\frac{\partial J}{\partial k_{ij}^m} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial k_{ij}^m} \right] dt \quad (4.29)$$

$$\frac{\partial J}{\partial c_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial c_{ij}} \right] dt \quad (4.30)$$

$$\frac{\partial J}{\partial b_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial b_{ij}} \right] dt \quad (4.31)$$

Parametre gradyanlarını (4.27)-(4.31), hesaplayabilmek için, öncelikli olarak  $\left[ \frac{\partial \hat{f}}{\partial \mu}, \frac{\partial \hat{f}}{\partial \sigma}, \frac{\partial \hat{f}}{\partial k}, \frac{\partial \hat{f}}{\partial c}, \frac{\partial \hat{f}}{\partial b} \right]$  türevlerinin hesaplanması gerekmektedir.

$$\frac{\partial \hat{f}_m}{\partial \mu_{ij}} = \frac{\partial \hat{f}_m}{\partial M_{ij}} \frac{(\hat{x}_j - \mu_{ij})}{\sigma_{ij}^2} \exp \left( -\frac{1}{2} \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (4.32)$$

$$\frac{\partial \hat{f}_m}{\partial \sigma_{ij}} = \frac{\partial \hat{f}_m}{\partial M_{ij}} \frac{(\hat{x}_j - \mu_{ij})^2}{\sigma_{ij}^3} \exp \left( -\frac{1}{2} \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (4.33)$$

$$\frac{\partial \hat{f}_m}{\partial M_{ij}} = \frac{w_j \left( g_{mj}(\hat{x}) - \sum_{i=1}^r h_i g_{mj}(\hat{x}) \right)}{M_{ij} \sum_{i=1}^m w_i(\hat{x})} \quad (4.34)$$

$$\frac{\partial \hat{f}_m}{\partial k_{ij}^m} = \begin{cases} h_j \hat{x}_m & m = j \\ 0 & m \neq j \end{cases} \quad (4.35)$$

$$\frac{\partial \hat{f}_m}{\partial b_{ij}} = \begin{cases} h_j u_i & m = j \\ 0 & m \neq j \end{cases} \quad (4.36)$$

$$\frac{\partial \hat{f}_m}{\partial c_{ij}} = \begin{cases} h_j & m = j \\ 0 & m \neq j \end{cases} \quad (4.37)$$

Artık, bir afın T-S bulanık sistem olan DANFIS'in parametreleri bu gradyanları kullanarak güncellenmeye hazırdır. Herhangi bir birinci dereceden gradyan algoritması, optimizasyon için kullanılabilir. Burada bizim seçimimiz Broyden-Fletcher-Goldfarb-Shanno (BFGS) yöntemi olmuştur.

### 4.3.2. Gradyan bilgisiyle parametre güncelleme

DANFIS modelinde kural sayısını seçmede herhangi bir kısıt yoktur. Eğitim algoritmasının her yinelemesinde, performans indeksinin bütün bilinmeyen parametrelere ( $\mathbf{p}$ ) göre gradyanlarının  $\mathbf{g} = \partial J / \partial \mathbf{p}$  ASM kullanılarak hesaplanması gerekmektedir. Öğrenme algoritması olarak BFGS gradyan yöntemi kullanılmıştır (Gill ve ark., 1981; Konar, 1991). BFGS yaklaşık ikinci dereceden gradyan algoritmalarından biridir ve tepe-tırmanma optimizasyon yöntemlerinin bir sınıfı olan Newton yönteminden türetilmiştir. Gradyanın sıfır olduğu sabit bir noktayı bulana kadar aramalarına devam eder. BFGS algoritmasında parametre güncelleme kuralları aşağıdaki gibi verilmiştir:

$$\mathbf{p}^{k+1} = \mathbf{p}^k + \tau^k \mathbf{d}^k \quad (4.38)$$

$$\tau^k = \min_{\tau} J(\mathbf{p}^k + \tau \mathbf{d}^k) \quad (4.39)$$

$$\mathbf{d}^k = -\mathbf{H}^k \mathbf{g}_p^k \quad (4.40)$$

Burada  $\mathbf{p}$  güncellenecek parametre,  $\mathbf{d}$  arama yönü,  $\tau$  arama yönündeki optimal arama adımı,  $\mathbf{g}$  parametre  $\mathbf{p}$ 'ye göre maliyet gradyanı ve  $\mathbf{H} \cong (\nabla_{\mathbf{p}} J)^{-1}$  ise aşağıda verilen yaklaşık Hessian matrisinin tersidir:

$$\mathbf{H}^{k+1} = \left[ \mathbf{I} - \frac{\Delta \mathbf{p}^k (\Delta \mathbf{g}_p^k)^T}{(\Delta \mathbf{p}^k)^T \Delta \mathbf{g}_p^k} \right] \mathbf{H}^k \left[ \mathbf{I} - \frac{\Delta \mathbf{p}^k (\Delta \mathbf{g}_p^k)^T}{(\Delta \mathbf{p}^k)^T \Delta \mathbf{g}_p^k} \right]^T + \frac{\Delta \mathbf{p}^k (\Delta \mathbf{p}^k)^T}{(\Delta \mathbf{p}^k)^T \Delta \mathbf{g}_p^k}, \quad \mathbf{H}^0 = \mathbf{I} \quad (4.41)$$

$\Delta \mathbf{p}$  ve  $\Delta \mathbf{g}$  sırasıyla parametre ve gradyan vektörlerinin geriye doğru farklarıdır. Parametre ve gradyan vektörlerinin geçmiş değişimlerini sağlarlar ve böylece yaklaşık ikinci dereceden bilgi edinilmiş olur.

Performans indeksi duyarlılıklarını hesaplama ek yolu, gradyan hesaplamaları için çözülmesi gereken diferansiyel denklemlerin sayısıyla etkili bir yoldur. Ancak, zaman aralığındaki ara hesaplamalar DANFIS'in iç dinamik modeli hakkında bilgi vermez. İleri duyarlılık yöntemi durum ve cevap duyarlılığı yörüngelerini üretirken, ek yöntemi ek değişkenlerin yörüngesini üretir (Becerikli



ve ark., 2004). Hem ek ve hem de ileri cevap hassasiyetlerini hesaplarken, BFGS algoritmasındaki bir diğer önemli nokta Hessian hesabının verimli bir şekilde hesaplanabilmesidir.

#### 4.4. DANFIS ile Denetleyici Tasarımı

DANFIS modelleme işlemini uyguladıktan sonra, doğrusal olmayan bir sistemin yerel modelleri elde edilmiş olur. Bu bölümde, bir sistem için oluşturulan DANFIS modelindeki kuralların aynı sebep kısmını paylaşan bulanık bir denetleyici tasarlanacaktır. Bu bölümün başında, sıfır-giriş cevabı için kararlılık analizi yapılmıştı. Şimdi ise, sisteme giriş uygulandığındaki kararlılık analizi yapılacaktır. Denklem (4.1)'de verilen afin bulanık sisteminin, sisteme kontrol girişi uygulandığındaki kararlılık analizi, kuadratik Lyapunov fonksiyonlarına göre (Wang ve Yang, 2013)'de verilmiştir. Burada (4.1) için kararlılık koşullarını inceleyebiliriz.  $I_\xi$ 'nin bulanık kurallar için indis kümesini gösterdiğini varsayalım:

$$I_\xi \equiv \left\{ \xi \mid h_\xi(0) \neq 0 \right\} \quad (4.42)$$

Sonra,  $j \in I_\xi$  için, kuralların THEN kısmındaki sabit terim  $c_j$ 'nin sıfır olduğunu varsayalım. Bu varsayım  $x=0$ 'ın bulanık sistemin bir denge noktası olduğunu garantilemektedir (Wang ve Yang, 2013). Afin bulanık sistemde kuralların THEN kısmı baz terim içerdiğinden, her bir kural için denetleyici de bir baz terim içerir ve kontrol  $u$  aşağıdaki gibi hesaplanabilir:

$$u = \sum_{j=1}^r h_j(x)(K_j x + d_j) \quad (4.43)$$

Benzer şekilde, denetleyicideki baz terim  $d_j$ 'nin  $j \in I_\xi$  için sıfır olduğu varsayılmaktadır. Sonra, kapalı-döngü bulanık sistemi aşağıdaki gibi tanımlanabilir (Wang ve Yang, 2013) :

$$\dot{x} = \sum_{j=1}^r h_j(x)[(A_j + B_j K_j)x + (B_j d_j + c_j)] \quad (4.44)$$

Aşağıda verilen teorem afin bulanık sisteminin kuadratik olarak kararlı olduğunu göstermektedir.

**Teorem** (Wang ve Yang, 2013): Denklemler (4.44) ile verilen afin bulanık sistemin kuadratik olarak kararlı olabilmesi için  $P > 0$ , uygun boyutlarda  $F$  ve  $W$  matrisleri,  $\tau_{jq} \geq 0$  ( $j = 1, 2, \dots, r$ ;  $q = 1, 2, \dots, n$ ) ve  $\alpha$  ve  $k$  yeterince büyük pozitif sabitler olduğunda koşullar sağlanmalıdır:

$$\begin{bmatrix} -2kP & P + (A_j + B_j K_j + kI)^T W \\ P + W^T (A_j + B_j K_j + kI) & -W - W^T \end{bmatrix} < 0 \quad (4.45)$$

Bulanık kurallar  $R_j$  ( $j \in I_\xi$ ) için

$$\begin{bmatrix} \phi_j - 2\alpha \bar{P} & \bar{P} + (\bar{A}_j + \alpha I)^T F \\ \bar{P} + F^T (\bar{A}_j + \alpha I) & -F - F^T \end{bmatrix} < 0 \quad (4.46)$$

Diğer bulanık kurallar için

$$\bar{A}_j = \begin{bmatrix} A_j + B_j K_j & B_j d_j + c_j \\ 0 & 0 \end{bmatrix} \quad (4.47)$$

$$\phi_j = \begin{bmatrix} -\sum_{q=1}^n \tau_{jq} T_{jq} & -\sum_{q=1}^n \tau_{jq} u_{jq} \\ -\sum_{q=1}^n \tau_{jq} u_{jq}^T & -\sum_{q=1}^n \tau_{jq} v_{jq} \end{bmatrix} \quad (4.48)$$

$$\bar{P} = \begin{bmatrix} P & 0 \\ 0 & 1 \end{bmatrix} \quad (4.49)$$

Burada  $T_{jq}$ ,  $u_{jq}$  ve  $v_{jq}$

$$F_{jq}(x) \triangleq x^T T_{jq} x + 2u_{jq}^T x + v_{jq} < 0 \quad (4.50)$$

$R_j(h_j(x) > 0)$ 'yi çalıştıran her  $x$  için yukarıdaki koşul sağlamalıdır.

Bu teoremin detayları ve ispatı (Wang ve Yang, 2013)'de verilmiştir. Bu teoremin sonuçlarına göre lineer kuadratik düzenleyici (LQR) yöntemi kararlı denetleyici tasarımında DANFIS modeli için kullanılabilir.  $\dot{x} = Ax + Bu + c$  için LQR'de optimal kontrol kuralı aşağıdaki gibi yazılabilir:

$$u = -[R + B^T Q B]^{-1} B^T Q [c + Ax] \quad (4.51)$$

Burada  $Q$  negatif olmayan tanımlı bir matristir ve durumları ağırlıklandırma matrisi olarak adlandırılır.  $R$  ise kontrol girişlerini ağırlıklandıran pozitif tanımlı bir

matristir. Bu matrislerin optimal seçimi, denetleyicinin dinamik hızıyla durum değişkeni ve kontrol sinyallerinin genliğini belirler. Örneğin,  $Q$  büyük seçilirken,  $R$  küçük seçilirse daha fazla kararlılık büyük kontrol çabaları ile elde edilecektir (Al-Hadithi ve ark., 2012).

Sistemin modelleme aşamasından sonra, afin T-S bulanık sistemi denetleyici tasarımında kullanılmıştır. LQR kullanıldığında bulanık kontrol sistemimizin kuralları aşağıdaki gibi olur.

$R_j$  : IF  $x_1$  is  $M_{1j}$  and  $x_2$  is  $M_{2j}$ , ...,  $x_n$  is  $M_{nj}$ ,

$$\text{THEN } u_j = -[R + B_j^T Q B_j]^{-1} B_j^T Q [c_j + A_j x] \quad (4.52)$$

Burada  $Q$  ve  $R$  matrislerini uygun bir şekilde seçildiğinde, kontroldeki sistem durumları istenilen bir işlem noktasına yakınsayabilir.

#### 4.5. Sonuçlar

Tezin bu kısmında, DANFIS olarak adlandırılan yeni bir bulanık sinir ağı dinamik sistem modelleme ve kontrol uygulamaları için tanıtılmıştır. Prensip olarak, DANFIS herhangi bir doğrusal olmayan sürece yaklaşmalıdır. DANFIS modelinin etkileyici genelleme yeteneği öncelikle T-S bulanık sistemlerinden gelmektedir. DANFIS modeli ASM ile gradyan tabanlı eğitim algoritmasıyla eğitildiğinde dinamik sistemleri yerelleştirme yeteneğine sahiptir. DANFIS modelinin hem modelleme hem de kontrol benzetim örnekleri Bölüm 6'da verilmiştir.

Bu modeldeki bir araştırma konusu bulanık denetleyicini formu ile ilgilidir. Bu çalışmada kullanılan bulanık denetleyicinin formu, giriş üyelik fonksiyonu parametrelerinin dinamik sistemin durumlarına göre seçildiği standart bulanık sistemdir. Daha ileri çalışmalarda, seçilen uygulama için hangi bulanık çıkarım mekanizmasının daha uygun olacağını belirlemek yeni bir araştırma konusu olabilir.

## 5. SİSTEM MODELLEME VE KONTROL UYGULAMARI İÇİN DİNAMİK BULANIK DALGACIK SINIR AĞI (DFWNN) TASARIMI

### 5.1. Giriş

Dalgacık tabanlarının zaman ve frekansta yerellik özellikleri sayesinde, dalgacık dönüşümü popüler olmuştur (Mallat ve Hwang, 1992; Mallat ve Zhong, 1992). Dalgacık dönüşümünün yeteneğini daha da genişletmek için dalgacık sinir ağı olarak adlandırılan yeni bir sinir ağı Zhang ve Benveniste (Zhang ve Benveniste, 1992) tarafından önerilmiştir. Bu tasarımda dalgacıklar aktivasyon fonksiyonu olarak yapay sinir ağına eklenmiştir. Dalgacık sinir ağları, dalgacıkların yerellik davranışları ve sinir ağlarının öğrenme yeteneği sayesinde azaltılmış ağ büyüklüğüyle hızlı yakınsama ve yüksek doğruluk özelliklerini sunmaktadır (Zhang ve Benveniste, 1992; Zhang ve ark., 1995; Zhang, 1997; Holmes ve Mallick, 2000; R.K.H. Galvao ve ark., 2004; Billings ve Wei, 2005; Chen ve ark., 2006).

Son yıllarda, yapay zekâ ile hesaplama yöntemleri bulanık sistemlerle birleştirilerek FWNN olarak adlandırılan yeni bir sinir ağı yapısı önerilmiştir (Ho ve ark., 2001; Zekri ve ark., 2008; Yılmaz ve Oysal, 2010; Lu, 2011; Davanipoor ve ark., 2012). FWNN modelleri kural tabanlarında dalgacıkları kullanan bulanık sistemlerdir. FWNN modellerinin lineer olmayan fonksiyon öğrenmesi, doğrusal olmayan sistemlerin tanımlaması ve kontrolü gibi uygulamalardaki etkinliği çeşitli çalışmalarda gösterilmiştir (Ho ve ark., 2001; Karatepe ve Alci, 2005; Srivastava ve ark., 2005; Abiyev ve Kaynak, 2008; Banakar ve Azeem, 2008; Zekri ve ark., 2008; Yılmaz, 2009; Yılmaz ve Oysal, 2009; Oysal ve Yılmaz, 2010; Yılmaz ve Oysal, 2010).

Tezin bu kısmında, bir önceki bölümde önerilen DANFIS modelinin kurallarının sebep kısmındaki üyelik fonksiyonları, dalgacık fonksiyonu ile değiştirilerek yeni bir sinir ağı tanıtılmıştır. Böylece bu ağ, dalgacıkların avantajlarını da sağlayacaktır. Önerilen yeni ağ DFWNN olarak adlandırılmıştır. Önerilen DFWNN modeli de afin T-S bulanık sistemidir. Bir önceki bölümde modelimizin kararlı olduğunu gösterilmiştir (Kim ve Kim, 2002; Wang ve Yang,

2013). Bu nedenle, DFWNN modelinin kurallarının çıkışı afin bulanık sistemlerin ilginç ve etkili sonuçları ile geliştirilmiştir.

Genel olarak T-S bulanık sistemleri bir kural kümesinde oluşur ve her bir kural “yerel dinamik model” gibi davranır. Bu modelde kurallar iç parametrelerle birlikte bir lineer diferansiyel denklem seti olarak gösterilir. Burada cevaplaması gereken en önemli soru “Modellenecek doğrusal olmayan dinamik sistem için DFWNN afin modelinin en uygun kural parametreleri nasıl bulunacaktır?” sorusudur. Her bir kuralın sonuç kısmında dinamik fonksiyonlar olduğu için cevabı basit değildir. Bu tezde, DANFIS modelinde olduğu gibi DFWNN modelinde de bilinmeyen parametrelerin öğrenilmesi için ASM (Bryson ve Ho, 1969; Konar ve Samad, 1992; Cao ve ark., 2002) kullanılmıştır. ASM, amaç fonksiyonumuz dinamik kısıtlar içerdiğinde duyarlılık hesabı için kullanılan etkili bir nümerik hesaplama yöntemidir.

## 5.2. DFWNN Yapısı

DFWNN yapısı üyelik fonksiyonu olarak dalgacık fonksiyonlarını kullanan bir T-S bulanık modeli gösterim şeklidir. Daha önce belirtildiği üzere T-S bulanık sistemi bulanık kuralların koşul kısmında Gauss tipi üyelik fonksiyonu kullanmaktadır. Kuralların sonuç kısmı ise modellenecek doğrusal olmayan dinamik sistemin giriş-çıkış ilişkisini yerel lineer dinamikler ile göstermektedir. Model yine afin bulanık sistemi temsil eder. Yani lineer denklemler baz terim içermektedir. DFWNN modelinde Gauss üyelik fonksiyonları yerine dalgacık fonksiyonları kullanılmıştır. Önerilen DFWNN modelini tanıtmak için, modellenecek sistemde  $n$  tane durumun olduğunu ve kural tabanının  $m$  tane bulanık IF-THEN kuraldan oluştuğunu varsayalım. DFWNN modelinde kurallar aşağıdaki formda verilmiştir:

$$R_j : \text{IF } x_1 \text{ is } M_{1j} \text{ and } x_2 \text{ is } M_{2j}, \dots, x_n \text{ is } M_{nj},$$

$$\text{THEN } \dot{x} = A_j x + B_j u + c_j$$

Burada  $x^T = (x_1, x_2, \dots, x_n)$  doğrusal olmayan sistemin durumları;  $u$  kontrol girişini,  $R_j$  ( $j = 1, 2, \dots, r$ )  $j$ . bulanık kuralı ve  $M_{1j}, M_{2j}, \dots, M_{nj}$  ise kuralların şart kısmındaki dalgacık üyelik fonksiyonlarını göstermektedir.

Meksika Şapkası dalgacık fonksiyonu Gauss fonksiyonunun ikinci türevidir. Ortonormal olmayan Meksika Şapkası fonksiyonu analitik formda aşağıdaki gibi yazılabilir ve onun Fourier dönüşümü ise aşağıdaki gibi kolayca hesaplanabilir.

$$\psi(x) = (1 - x^2) \exp\left(-\frac{x^2}{2}\right), x \in R \quad (5.1)$$

$$\psi(\omega) = \sqrt{2\pi} \omega^2 \exp\left(-\frac{\omega^2}{2}\right), \omega \in R \quad (5.2)$$

Burada  $\omega$  gerçek frekanstır. Meksika Şapkası dalgacık fonksiyonu öteleme ( $\mu$ ) ve genişleme ( $\sigma$ ) parametreleri ile aşağıdaki gibi genelleştirilebilir.

$$\psi\left(\frac{x-\mu}{\sigma}\right) = \left(1 - \left(\frac{x-\mu}{\sigma}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2\right) \quad (5.3)$$


Öteleme parametresi dalgacığın merkez pozisyonunu belirlerken, genişleme parametresi dalgacığın yayılımını kontrol eder. Bilindiği üzere dalgacık fonksiyonları zaman ve frekansta yerellik özellikleriyle bilinirler (Mallat, 1989). Genişleme parametresi değiştiğinde dalgacık fonksiyonunun destek bölgesinin genişliği değişirken tepe noktası sayısı değişmez (Becerikli ve ark., 2003). Ancak genişlik parametresi azalır, spektrumun tepe noktası yüksek frekanslara doğru kayar. Böylece, genişlik parametresini değiştirerek bütün frekans spektrumu elde edilir.

Tezin bu kısmında normalleştirilmiş Meksika Şapkası dalgacık fonksiyonları kullanılmıştır. Normalleştirilmiş Meksika Şapkası fonksiyonu aşağıdaki gibi tanımlanmıştır:

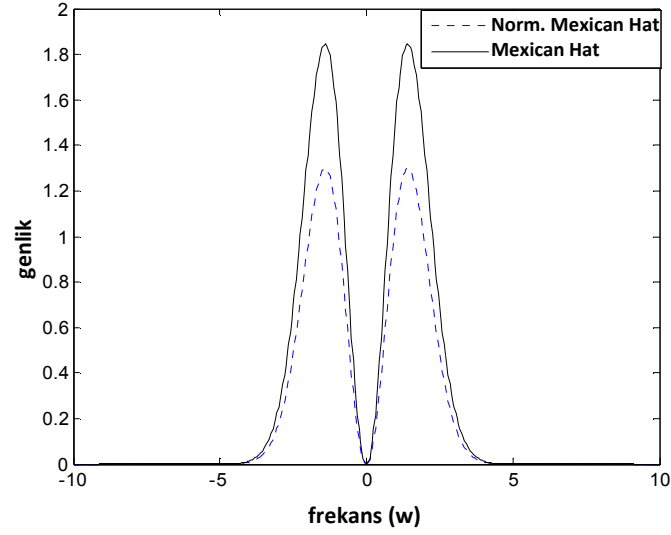
$$M_{ij} = \frac{\left(1 - \left(\frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}}\right)^2\right) \exp\left(0.5 \left(\frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}}\right)^2\right) + \varepsilon}{1 + \varepsilon} \quad (5.4)$$

sabit  $\varepsilon = 0.4461$ .

Burada,  $i$ . durumun  $j$ . kuralı için seçilen üyelik fonksiyonunun,  $\mu_{ij}$  merkez ve  $\sigma_{ij}$  genişlik parametresidir. Şekil 5.1’de normalleştirme işlemi yapılmış ve yapılmamış Meksika Şapkası fonksiyonları ve de onların Fourier dönüşümü gösterilmektedir.



(a)



(b)

**Şekil.5.1. (a)** Meksika Şapkası ve normalleştirilmiş Meksika Şapkası dalgacık fonksiyonları **(b)** Fourier dönüşümleri

DFWNN ağının yapısı Şekil 4.1’de katmanlarla gösterilen DANFIS ağının yapısına benzerdir. Birinci katman doğrusal olmayan dinamik sistemin durum

değişkenlerini göstermektedir. İkinci katman bulanıklaştırma katmanıdır. Normalleştirilmiş Meksika Şapkası dalgacık fonksiyonları bulanıklaştırma işlemi için kullanılmıştır. Üçüncü katman bulanık kural katmanıdır. Bu katmanın çıkışını hesaplamak için çarpma işlemi t-norm operatörü olarak kullanılmıştır. Bu katmanın çıktısı aşağıdaki gibi verilmiştir:

$$w_j(x) = \prod_{i=1}^n M_{ij}(x_i) \quad (5.5)$$

Dördüncü katman normalleştirme katmanıdır. Her bir kuralın normalleştirilmiş aktivasyon gücü bu katmanda aşağıdaki gibi hesaplanmıştır:

$$h_j(x) = \frac{w_j(x)}{\sum_{i=1}^r w_j(x)}, \quad h_j(x) \geq 0 \quad (5.6)$$

Beşinci katman bulanık kuralların sonuç kısımlarını göstermektedir. Bu katmandaki her bir kural lineer diferansiyel denklem sistemi ile gösterilmektedir. DFWNN'nin  $j$ . kuralındaki  $i$ . durum değişkeni için bu katmandaki fonksiyon aşağıdaki gibidir:

$$g_{ij}(\hat{x}) = \sum_{m=1}^n k_{ij}^m \hat{x}_m + c_{ij} + b_{ij}u \quad (5.7)$$

Son olarak altıncı katman çıkış katmanıdır. Bu katmandaki final diferansiyel denklemler bir önceki katmandaki lineer fonksiyonların ağırlıklı toplamı olarak hesaplanmaktadır:

$$\dot{\hat{x}}_i = \hat{f}_i(\hat{x}, p) = \sum_{j=1}^r h_j g_{ij}(\hat{x}) \quad (5.8)$$

Daha sonra doğrusal olmayan dinamik sistemin DFWNN modeli aşağıdaki gibi matris formunda yazılabilir.

$$\dot{\hat{x}} = \frac{\sum_{j=1}^r w_j (A_j \hat{x} + B_j u + c_j)}{\sum_{j=1}^r w_j} = \sum_{j=1}^r h_j(\hat{x}) \{A_j \hat{x} + B_j u + c_j\} \quad (5.9)$$



Denklem (5.9) ile verilen afin bulanık sistemin kararlılığı, yani açık ve kapalı devre kararlılık analizi (Kim ve Kim, 2002; Wang ve Yang, 2013)'de verilmişti ve bir önceki bölümde açıklanmıştı. Bu nedenle bu analizin detayları burada tekrar açıklanmamıştır. T-S bulanık modeli ve DFWNN modeli sadece üyelik fonksiyonlarının normalleştirilmiş Meksika Şapkası fonksiyonları olmasında farklılık göstermektedir. Bütün üyelik fonksiyonları  $[0,1]$  aralığı ile sınırlı olduğundan, T-S bulanık sistemleri için verilen kararlılık analizi DFWNN modeli için de geçerlidir.

### 5.3. DFWNN Öğrenme Algoritması

DFWNN modelini doğrusal olmayan bir dinamik sistemi modellemek için kullanmak istediğimizde, öncelikli olarak bu sistemin iç davranışının modellenmesi gerekmektedir. Bu aşamayı öğrenme aşaması olarak adlandırabiliriz. Bu bölümde DFWNN modelinin öğrenme işlemleri tanıtılacaktır. Burada önerilen algoritma gradyan tabanlı bir yöntemdir. Verilen giriş-çıkış haritalamasına göre performans ölçütü minimize edilerek verilen dinamik sistemin iç davranışı modellenir. DFWNN modelinin parametreleri amaç fonksiyonunu minimize edecek şekilde güncellenir. Böylece, hedef durum eğrileri, istenilen bir zaman aralığında seçilen bir başlangıç noktasından itibaren takip edilebilir. Verilen bir dinamik sistemi modellerken en uygun ağ parametrelerini bulmak için performans ölçütünü minimize edecek şekilde izlenecek adımlar aşağıdaki gibi özetlenebilir.

1. Parametrelerin  $(\mu_{ij}, \sigma_{ij}, k_{ij}^m, c_{ij})$  başlangıç değerleri belirlenir.
2. O anki parametre değerlerine göre DFWNN modelinin çıkışı hesaplanır.
3. Performans ölçütü ve performans ölçütünün parametrelere göre gradyanları hesaplanır.
4. Eğer performans ölçütümüz hedef değere ulaşmamışsa, parametre değerleri optimizasyon algoritmasına göre güncellenir ve sonraki iterasyon için 2. adıma gider.

DFWNN modelinde kuralların koşul kısmındaki dalgacık üyelik fonksiyonlarının başlangıç merkez değerleri, DANFIS modeline benzer şekilde FCM (Bezdek ve ark., 1984) kullanılarak belirlenmiştir. Üyelik fonksiyonlarının

genişlik parametreleri ise başlangıçta 1 seçilmiştir. Kuralların sonuç kısmındaki lineer diferansiyel denklemin başlangıç parametreleri ise modellenecek doğrusal olmayan dinamik sistemin FCM ile bulunan merkez noktalarında doğrusallaştırılması ile elde edilmiştir.

DFWNN tarafından modellenecek doğrusal olmayan dinamik sistemin aşağıdaki fonksiyon ile verildiğini düşünelim:

$$\dot{x}(t) = f(x(t), u(t)) \quad (5.10)$$

Burada  $f$  doğrusal olmayan bir fonksiyon,  $x(t) = [x_1(t) \ x_2(t) \ \dots \ x_n(t)]^T$  durum vektörü ve  $u(t) = [u_1(t) \ u_2(t) \ \dots \ u_n(t)]^T$  ise giriş vektörüdür. DFWNN öğrenme işlemi için seçilen kuadratik performans ölçütü aşağıdaki gibi seçilmiştir.

$$\begin{aligned} J &= \int_{t_0}^{t_f} F(x, \hat{x}) dt \\ &= \int_{t_0}^{t_f} 0.5[\hat{x}(t) - x(t)]^T [\hat{x}(t) - x(t)] dt \end{aligned} \quad (5.11)$$

Burada  $x(t)$ , verilen zaman aralığındaki beklenen yörünge,  $\hat{x}(t)$  ise aynı aralıkta DANFIS modelinin cevabıdır. Görüldüğü üzere DFWNN modeli için seçilen amaç fonksiyonu hatanın  $e(t) = \hat{x}(t) - x(t)$  bir fonksiyonudur. Sistemi modelleyecek en uygun parametre değerlerini bulmak için, performans ölçütünün bütün bilinmeyen parametrelere göre kısmi türevlerinin hesaplanması gerekmektedir. ASM, diferansiyel kısıtlı bu optimizasyon probleminin çözmek için kullanılmıştır (Bryson ve Ho, 1969; Konar ve Samad, 1992; Cao ve ark., 2002; Oysal ve ark., 2003). DFWNN modeli için kısıtlı optimizasyon problemi şu şekilde tanımlanabilir:

$$\min_{\hat{p}} J = \int_{t_0}^{t_f} F(x, \hat{x}) dt \quad (5.12)$$

$$\dot{\hat{x}}(t) = \hat{f}(x(t), p) = \sum_{j=1}^r h_j \left( \sum_{m=1}^n k_{ij}^m \hat{x}_m + c_{ij} + b_{ij} u \right) \quad (5.13)$$

$$x(t_0) = x_0$$

Bu kısıtlı optimizasyon problemini çözmek, DFWNN modelinin parametrelerini gerçek sistemin yörüngelerini takip edecek şekilde ayarlayabilmemizi sağlar.

ASM'de, amaç fonksiyonun DFWNN modelinin bilinmeyen parametrelerine ( $p$ ) göre gradyanları aşağıdaki formül ile hesaplanır:

$$\frac{\partial J}{\partial p} = \int_{t_0}^{t_f} \left( \frac{\partial \hat{f}}{\partial p} \right)^T \lambda(t) dt \quad (5.14)$$

Burada ek durum değişkeni  $\lambda$ , her bir yinelemede aşağıdaki diferansiyel denklemin zamanda geriye doğru çözülmesiyle hesaplanır:

$$-\dot{\lambda} = \left( \frac{\partial \hat{f}}{\partial \hat{x}} \right)^T \lambda + \frac{\partial F}{\partial \hat{x}} \quad \lambda(t_f) = 0 \quad (5.15)$$

Bilinmeyen parametre sayısı ne olursa olsun ek yörüngelerin sayısı doğrusal olmayan sistemin durum değişkeni sayısına eşittir ve ek durum değişkeni (5.15) daha açık formda aşağıdaki gibi yazılabilir:

$$-\begin{bmatrix} \dot{\lambda}_1 \\ \dot{\lambda}_2 \\ \vdots \\ \dot{\lambda}_n \end{bmatrix} = \begin{bmatrix} \frac{\partial \hat{f}_1}{\partial \hat{x}_1} & \frac{\partial \hat{f}_2}{\partial \hat{x}_1} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_1} \\ \frac{\partial \hat{f}_1}{\partial \hat{x}_2} & \frac{\partial \hat{f}_2}{\partial \hat{x}_2} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial \hat{f}_1}{\partial \hat{x}_n} & \frac{\partial \hat{f}_2}{\partial \hat{x}_n} & \dots & \frac{\partial \hat{f}_n}{\partial \hat{x}_n} \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \end{bmatrix} + \begin{bmatrix} \hat{x}_1 - x_1 \\ \hat{x}_2 - x_2 \\ \vdots \\ \hat{x}_n - x_n \end{bmatrix} \quad (5.16)$$

Burada  $\lambda(t_f) = 0$ .

Ek değişkenlerini hesaplariken, DFWNN model çıktısının durum değişkenlerine göre birinci türevinin  $\frac{\partial \hat{f}}{\partial \hat{x}}$  hesaplanması gerekmektedir. Bu hesaplamalar aşağıdaki gibi yazılabilir:

$$\frac{\partial \hat{f}_m}{\partial \hat{x}_i} = \frac{z_2 \frac{\partial z_{1m}}{\partial \hat{x}_i} - z_{1m} \frac{\partial z_2}{\partial \hat{x}_i}}{(z_2)^2} \quad (5.17)$$

$$z_{1m} = \sum_{j=1}^r w_j(\hat{x}) g_{mj}(\hat{x}) \quad (5.18)$$

$$z_2 = \sum_{j=1}^r w_j(\hat{x}) \quad (5.19)$$

$$\frac{\partial z_{1m}}{\partial \hat{x}_i} = \sum_{j=1}^r \left( \frac{\partial w_j}{\partial \hat{x}_i} (g_{mj}(\hat{x}) + b_{ij}u) + w_j k_{mj}^i \right) \quad (5.20)$$

$$\frac{\partial z_2}{\partial \hat{x}_i} = \sum_{j=1}^r \frac{\partial w_j}{\partial \hat{x}_i} \quad (5.21)$$

$$\frac{\partial w_j}{\partial \hat{x}_i} = \frac{1}{1 + \varepsilon} \frac{w_j}{M_{ij}} \left( \frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}^2} \right) \left( -1 - \left( \frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \exp \left( 0.5 \left( \frac{\hat{x}_i - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (5.22)$$

Daha sonra amaç fonksiyonun parametrelere göre gradyanlarını

$\left[ \frac{\partial J}{\partial \mu}, \frac{\partial J}{\partial \sigma}, \frac{\partial J}{\partial k}, \frac{\partial J}{\partial c}, \frac{\partial J}{\partial b} \right]$  ek değişkenleri kullanarak aşağıdaki gibi hesaplayabiliriz:

$$\frac{\partial J}{\partial \mu_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial \mu_{ij}} \right] dt \quad (5.23)$$

$$\frac{\partial J}{\partial \sigma_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial \sigma_{ij}} \right] dt \quad (5.24)$$

$$\frac{\partial J}{\partial k_{ij}^m} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial k_{ij}^m} \right] dt \quad (5.25)$$

$$\frac{\partial J}{\partial c_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial c_{ij}} \right] dt \quad (5.26)$$

$$\frac{\partial J}{\partial b_{ij}} = \int_{t_0}^{t_f} \left[ \sum_{i=1}^n \lambda_i \frac{\partial \hat{f}_i}{\partial b_{ij}} \right] dt \quad (5.27)$$

Görüldüğü üzere, bu hesaplamaları yapabilmemiz için

$\left[ \frac{\partial \hat{f}}{\partial \mu}, \frac{\partial \hat{f}}{\partial \sigma}, \frac{\partial \hat{f}}{\partial k}, \frac{\partial \hat{f}}{\partial c}, \frac{\partial \hat{f}}{\partial b} \right]$  türevleri hesaplanmalıdır ve sonuçta DFWNN çıkış

fonksiyonunun parametrelere göre gradyanları aşağıdaki gibi hesaplanır:

$$\frac{\partial \hat{f}_m}{\partial \mu_{ij}} = \frac{\partial \hat{f}_m}{\partial M_{ij}} \frac{1}{1+\varepsilon} \frac{(\hat{x}_j - \mu_{ij})}{\sigma_{ij}^2} \left( 3 - \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (5.28)$$

$$\frac{\partial \hat{f}_m}{\partial \sigma_{ij}} = \frac{\partial \hat{f}_m}{\partial M_{ij}} \frac{1}{1+\varepsilon} \frac{(\hat{x}_j - \mu_{ij})^2}{\sigma_{ij}^3} \left( 3 - \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \exp \left( -\frac{1}{2} \left( \frac{\hat{x}_j - \mu_{ij}}{\sigma_{ij}} \right)^2 \right) \quad (5.29)$$

$$\frac{\partial \hat{f}_m}{\partial M_{ij}} = \frac{w_j \left( g_{mj}(\hat{x}) - \sum_{i=1}^r h_i g_{mj}(\hat{x}) \right)}{M_{ij} \sum_{i=1}^m w_i(\hat{x})} \quad (5.30)$$

$$\frac{\partial \hat{f}_m}{\partial k_{ij}^m} = \begin{cases} h_j \hat{x}_m & m = j \\ 0 & m \neq j \end{cases} \quad (5.31)$$

$$\frac{\partial \hat{f}_m}{\partial b_{ij}} = \begin{cases} h_j u_i & m = j \\ 0 & m \neq j \end{cases} \quad (5.32)$$

$$\frac{\partial \hat{f}_m}{\partial c_{ij}} = \begin{cases} h_j & m = j \\ 0 & m \neq j \end{cases} \quad (5.33)$$

Gradyanlar yukarıda verildiği şekilde hesaplandıktan sonra, herhangi bir gradyan tabanlı algoritma eğitim için kullanılabilir. Burada BFGS algoritması seçilmiştir. Bir önceki bölümde açıklandığı gibi BFGS algoritması Newton optimizasyon yönteminden türetilen yaklaşık ikinci dereceden algoritmalardan biridir. Gradyanın sıfır olduğu bir sabit noktayı bulmaya çalışır (Gill ve ark., 1981).

#### 5.4. DFWNN ile Denetleyici Tasarımı

Bu bölümde, ikinci bir aşama olarak DFWNN modeli kullanılarak doğrusal olmayan dinamik sistemler için bulanık denetleyici tasarlanacaktır. Buradaki denetleyici, DANFIS modeline benzer şekilde tasarlanacaktır. DFWNN modelinde bir dinamik sistem için öğrenme aşaması gerçekleştirildikten sonra, elimizde afın yerel modelleri sağlayan bir kural tabanı oluşur. Tasarlanan denetleyici, DFWNN modeli ile aynı IF kısımlarına sahiptir. Bulanık denetleyicinin THEN kısımlarında ise her bir yerel model için gerçekleştirilecek eylemi tanımlanmaktadır. Kapalı çevrim DFWNN modeli matris formunda aşağıdaki gibi yazabilir:

$$\begin{aligned}\dot{x} &= \frac{\sum_{j=1}^r w_j (A_j x + B_j u + c_j)}{\sum_{j=1}^r w_j} \\ &= \sum_{j=1}^r h_j(x) (A_j x + B_j u + c_j)\end{aligned}\quad (5.34)$$

Önceki bölümde açıklandığı gibi afin bulanık sistemin kararlılık analizi, Lyapunov fonksiyonlarına göre (Wang ve Yang, 2013)'de verilmiştir. Bu analize göre LQR modeli kararlı denetleyici tasarımında kullanılabilir.  $\dot{x} = Ax + Bu + c$  ile verilen bir sistem için LQR optimal kontrol kuralı aşağıdaki gibi yazılabilir:

$$u = -[R + B^T Q B]^{-1} B^T Q [c + Ax] \quad (5.35)$$

Burada  $Q$  negatif olmayan tanımlı, durum ağırlıklandırma matrisi,  $R$  ise pozitif tanımlı kontrol girişlerini ağırlıklandırma matrisidir. Bu bilgilerle, DFWNN kontrol sistemi kuralları aşağıdaki formda yazılabilir:

$R_j$  : IF  $x_1$  is  $M_{1j}$  and  $x_2$  is  $M_{2j}$ , ...,  $x_n$  is  $M_{nj}$ ,

THEN  $u_j = -[R + B_j^T Q B_j]^{-1} B_j^T Q [c_j + A_j x]$

Uygun  $Q$  ve  $R$  değerleri seçilerek kontroldeki sistem durumları istenilen bir işletim noktasına getirilebilir.

## 5.5. Sonuçlar

Tezin bu kısmında DFWNN olarak adlandırılan sinir ağı modeli, doğrusal olmayan dinamik sistemlerin modellenmesi ve kontrolü için tanıtılmıştır. Burada verilen DFWNN modeli üyelik fonksiyonu olarak dalgacık fonksiyonlarını kullanan bir T-S bulanık sistemidir. Önerilen DFWNN modelinin dinamik sistemlerin modellenmesi ve kontrolü için performans örnekleri DANFIS ile karşılaştırılmalı olarak bir sonraki bölümde verilmiştir.

## 6. DANFIS VE DFWNN İLE BENZETİM SONUÇLARI

Bu bölüm, DANFIS ve DFWNN modellerinin modelleme ve kontrol performansını karşılaştırmalı olarak göstermektedir. Burada önerilen modeller üç lineer olmayan karmaşık dinamik sisteme, T-S bulanık kurallarıyla birlikte yerel iç dinamikleri elde etmek için uygulanmıştır. Bu tezde önerilen DANFIS ve DFWNN modellerinde üyelik fonksiyonu sayısını seçmede herhangi bir kısıt yoktur. Daha önce de belirtildiği gibi, benzetim örneklerinde her bir giriş için üyelik fonksiyonları FCM ile belirlenmiştir. Giriş değişkeni sayısı çok fazla olduğunda, üyelik fonksiyonu sayısı da artmaktadır. Bu da DANFIS ve DFWNN modellerinde çok fazla kural olmasına neden olmaktadır. Bu çalışmanın en önemli noktası öğrenme algoritmasının etkili bir algoritma olmasıdır. Modelleme deneyimindeki benzetim sonuçları ile bu konu incelenmiştir.

### 6.1. DANFIS ve DFWNN ile Modelleme Sonuçları

#### 6.1.1. Van der Pol osilatörü

Van der Pol (VDP) osilatörü elektrik mühendisi ve fizikçi Balthasar Van der Pol tarafından önerilmiştir (Cartwright, 1960). Van der Pol vakum tüplere uygulanan elektrik devrelerinde kararlı osilasyonlarla karşılaştığı çalışmasında, buna osilasyon-durgunluğu adını vermiştir (Van der Pol, 1927). Günümüzde bu durağan döngülere, limit döngü adı verilmektedir. İki boyutlu bu sistemin matematiksel modeli şu şekildedir:

$$\frac{dx_1}{dt} = x_2 \quad (6.1)$$

$$\frac{dx_2}{dt} = -x_1 + \mu(1 - x_1^2)x_2 \quad (6.2)$$

Burada  $x_1$  ve  $x_2$  pozisyon koordinatları ve  $\mu$  lineer olmama özelliğini belirleyen parametre değeridir. Bu tezdeki benzetim çalışmalarında  $\mu$ , 1 olarak seçilmiştir. Üyelik fonksiyonlarının başlangıç değerleri FCM kümeleme algoritması ile bulunmuştur. Bu kümeleme değerlerini ( $c_1, c_2$ ) kullanarak, (6.1) ve (6.2) ile verilen VDP denklemleri bu merkez değerlerinde doğrusallaştırılmıştır:

$$k_{11} = 0, \quad k_{12} = 1 \quad (6.3)$$

$$k_{13} = -c_1 k_{11} - c_2 k_{12} - c_1 + c_2 \quad (6.4)$$

$$k_{21} = -2\mu c_1 c_2 - 1, \quad k_{22} = -\mu(c_1^2 - 1) \quad (6.5)$$

$$k_{23} = -c_1 k_{21} - c_2 k_{22} - c_1 + \mu(1 - c_1^2)c_2 \quad (6.6)$$

Denklemler (6.3)-(6.6) ile elde edilen değerler kullanılarak, bulanık kuralların başlangıç değerleri (6.7) hesaplanmıştır.

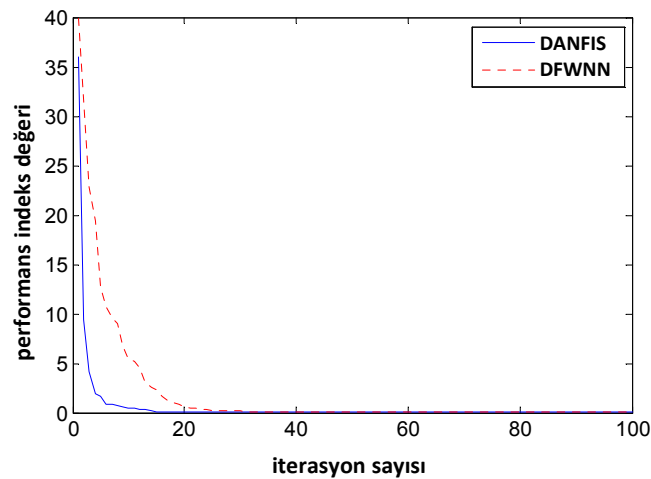
$$\text{IF } x_1 \text{ is } M_1 \text{ and } x_2 \text{ is } M_2 \text{ THEN } \dot{x}_1 = k_{11}x_1 + k_{12}x_2 + k_{13} \quad (6.7)$$

$$\dot{x}_2 = k_{21}x_1 + k_{22}x_2 + k_{23}$$

Şekil 6.1 iterasyon sayısına karşı performans indeksi değerlerini (4.15) göstermektedir. Eğitim ve test ortalama mutlak yüzde hata değerleri (MAPE) Çizelge 6.1’de özetlenmiştir.

$$MAPE = \frac{1}{m} \sum_{t=1}^m \left| \frac{x^t - \hat{x}^t}{x^t} \right| \quad (6.8)$$

Şekil 6.2 ve Şekil 6.3, DANFIS ve DFWNN modellerinin  $x(0)=[5,0]$  başlangıç değeriyle eğitimdeki modelleme sonuçlarını ve hata değerlerini göstermektedir. Şekil 6.4 ve Şekil 6.5 ise bu modellerin  $x(0)= [3,0.5]$  başlangıç değeriyle testteki başarısını göstermektedir.

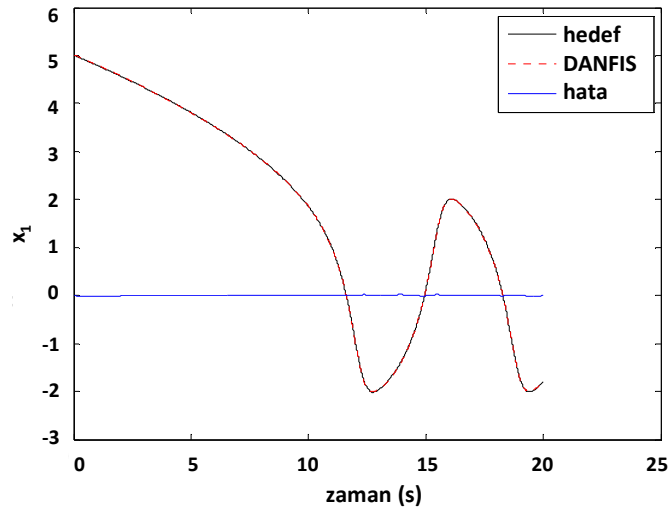


Şekil 6.1. VDP osilatörü için iterasyon sayısına karşı eğitim performans değerleri (4.15)

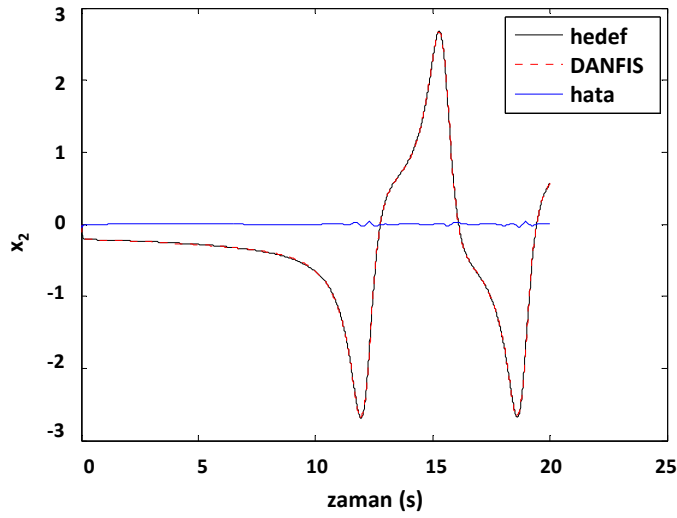


**Çizelge 6.1.** VDP osilatörü için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri

	DANFIS		DFWNN	
	MAPE ( $x_1$ )	MAPE ( $x_2$ )	MAPE ( $x_1$ )	MAPE ( $x_2$ )
Eğitim $x(0)=[5,0]$	0.05250	0.02174	0.01397	0.02151
Test $x(0)=[4.9,0.1]$	0.07096	0.02689	0.11476	0.06257
Test $x(0)=[4.9,-0.1]$	0.07864	0.08349	0.04097	0.05023
Test $x(0)=[5.1,-0.1]$	0.00898	0.02790	0.08932	0.08790
Test $x(0)=[5.1,0.1]$	0.10977	0.14896	0.07322	0.09402
Test $x(0)=[3,0.5]$	0.02863	0.03139	0.05171	0.04347




(a)




(b)

**Şekil 6.2.** VDP osilatörü için  $x(0)=[5,0]$  başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)




(b)

**Şekil 6.3.** VDP osilatörü için  $x(0)=[5,0]$  başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)




(b)

**Şekil 6.4.** VDP osilatörü için  $x(0)=[3,0.5]$  başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$



(a)



(b)

**Şekil 6.5.** VDP osilatörü için  $x(0)=[3,0.5]$  başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$

DANFIS ve DFWNN modellerinin hem eğitim hem de test aşamalarında başarılı olduğu görülmüştür. Çizelge 6.1’de görüldüğü üzere DFWNN modeli eğitim aşamasında DANFIS modelinden daha başarılıdır. Eğitilen modeller farklı başlangıç değerleri kullanılarak test edilmiştir. Bu modellerin testteki üstünlüğü, başlangıç koşullarına bağlı olarak değişmektedir. Çizelge 6.1 incelendiğinde, bazı başlangıç koşullarında DANFIS modeli daha başarılıyken, diğerlerinde DFWNN modeli daha başarılı olduğu görülebilir.

Burada dikkate alınması gereken diğer bir nokta da, gradyan tabanlı algoritmalarda global minimum çözümleri ararken, bulunan yerel minimum değerinin bilinmeyen parametrelerin başlangıç değerine kesin olarak bağlı olmasıdır. VDP osilatörünün matematiksel modelini bilmemiz nedeniyle, istenilen yörüngeyi takip etmek için doğrusallaştırma işlemi bize amaç fonksiyonumuzun global minimuma yakınsamasını sağlamaktadır. Ancak bazı endüstriyel uygulamalarda matematiksel model elde edilemeyebilir. Bu gibi durumlarda başlangıç değerlerini bulma sezgisel yöntemlerle yapılabilir. Ancak böyle durumlarda optimal çözümleri bulacağımızın garantisi yoktur.

### 6.1.2. Sürekli karıştırılmalı tank reaktör sistemi (CSTR)

İkinci örnek olarak CSTR süreci seçilmiştir. CSTR kimyasal endüstride önemli ve temel bir süreçtir ve çok güçlü lineer olmayan dinamiklere sahiptir. CSTR sistemi durum denklemleri şu şekildedir (Ray, 1981; Oysal ve ark., 2006):

$$\frac{dx_1}{dt} = -x_1 + Da(1-x_1)e^{\frac{x_2}{1+x_2/\gamma}} \quad (6.9)$$

$$\frac{dx_2}{dt} = -x_2 + BDa(1-x_1)e^{\frac{x_2}{1+x_2/\gamma}} - \beta(x_2 - x_{2c}) + d + \beta u \quad (6.10)$$

Burada  $x_1$  ve  $x_2$  sırası ile boyutsuz reaktant dönüşümü ve sıcaklığı;  $Da$ , Damkohler sayısı ve  $d$ ,  $u$  değişkenleri de besleme sıcaklığı bozucusundaki ve ceket sıcaklığındaki kontrol sinyali değişimlerdir. Gerçek reaktör sıcaklığı  $T$  ve reaktör konsantrasyonu  $C_A$  aşağıdaki formüllerden hesaplanır:

$$C_A = C_{Af}(1-x_1), \quad T = T_{f0} \left( \frac{RT_{f0}}{E} x_2 + 1 \right) \quad (6.11)$$

Burada  $C_{Af}$  tank içerisindeki reaktant konsantrasyonu;  $T_{f0}$ , besleme sıcaklığı için nominal tasarım değeri göstermektedir.  $R$  ve  $E$  reaktöre ait fiziksel sabitlerdir. Bu tezde  $R=1.99$  ve  $E=30000$  olarak alınmıştır. Aşağıda verilen denklemler (6.12)-(6.17) FCM ile bulunan merkez değerlerinde CSTR sürecinin doğrusallaştırılmasıyla elde edilmiştir. Böylece, (6.7) formundaki bulanık kuralların başlangıç parametreleri bulunmuştur.

$$k_{11} = -Da \exp\left(\frac{c_2}{(c_2/\gamma + 1)}\right) - 1 \quad (6.12)$$

$$k_{12} = -Da \exp\left(\frac{c_2}{(c_2/\gamma + 1)}\right) \left(\frac{1}{(c_2/\gamma + 1)}\right) - \frac{c_2}{(\gamma(c_2/\gamma + 1)^2)}(c_1 - 1) \quad (6.13)$$

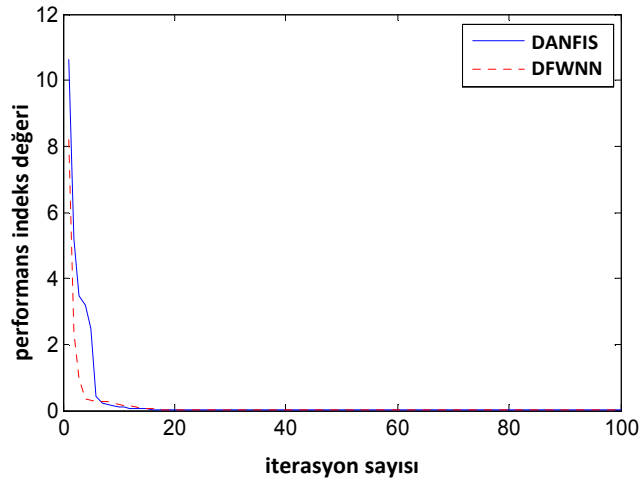
$$k_{13} = -c_1 k_{11} - c_2 k_{12} - c_1 + Da(1 - c_1) e^{\frac{c_2}{1+c_2/\gamma}} \quad (6.14)$$

$$k_{21} = -BDa \exp\left(\frac{c_2}{(c_2/\gamma + 1)}\right) \quad (6.15)$$

$$k_{22} = -\beta - BDa \exp\left(\frac{c_2}{(c_2/\gamma + 1)}\right) \left(\frac{1}{(c_2/\gamma + 1)} - \frac{c_2}{\gamma(c_2/\gamma + 1)^2}\right) (c_1 - 1) - 1 \quad (6.16)$$

$$k_{23} = -c_1 k_{21} - c_2 k_{22} - c_2 + BDa(1 - c_1) e^{\frac{c_2}{1+c_2/\gamma}} - \beta(c_2 - x_{2c}) \quad (6.17)$$

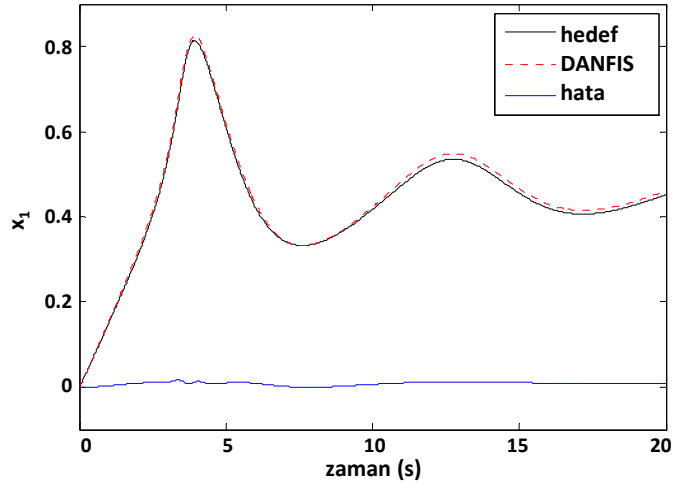
Şekil 6.6, iterasyon sayısına karşı modellerin eğitim performans indeksi değerlerini göstermektedir. Sıfır girişli CSTR için DANFIS ve DFWNN modellerinin eğitim ve test aşamalarındaki MAPE değerleri Çizelge 6.2’de verilmiştir. Şekil 6.7 ve Şekil 6.8, DANFIS ve DFWNN modellerinin eğitim sonuçlarını gösterirken, benzer şekilde Şekil 6.9 ve Şekil 6.10 modellerin test sonuçlarını göstermektedir. Test sonuçlarından görüldüğü üzere bazı başlangıç değerlerinde DANFIS modeli başarıyla, diğer başlangıç noktalarında DFWNN modeli daha başarılıdır.




Şekil 6.6. Sıfır-giriş CSTR için iterasyon sayısına karşı eğitim performans değerleri (4.15)

**Çizelge 6.2.** Sıfır-giriş CSTR için 5 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri

	DANFIS		DFWNN	
	MAPE ( $x_1$ )	MAPE ( $x_2$ )	MAPE ( $x_1$ )	MAPE ( $x_2$ )
Eğitim $x(0)=[0,0]$	0.00563	0.00232	0.01002	0.00180
Test $x(0)=[0.1,0.1]$	0.03029	0.04408	0.02888	0.03357
Test $x(0)=[-0.1,0.1]$	0.04699	0.04473	0.04699	0.04009
Test $x(0)=[-0.1,-0.1]$	0.03824	0.03536	0.04469	0.04417
Test $x(0)=[0.1,-0.1]$	0.03636	0.05904	0.02916	0.04372




(a)




(b)

**Şekil 6.7.** Sıfır-giriş CSTR için  $x(0)=[0,0]$  başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)




(b)

**Şekil 6.8.** Sıfır-giriş CSTR için  $x(0)=[0,0]$  başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$






(a)




(b)

**Şekil 6.9.** Sıfır-giriş CSTR için  $x(0)=[-0.1,-0.1]$  başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)



(b)

**Şekil 6.10.** Sıfır-giriş CSTR için  $x(0)=[-0.1,-0.1]$  başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri **(a)**  $x_1$  **(b)**  $x_2$


Lineer olmayan dinamik bir sistemin iç davranışını modellemek için, sisteme yeteri kadar sarsacak bir giriş sinyali uygulanmalıdır. Dinamik sistemin bu eğrisi DANFIS ve DFWNN modelleri tarafından öğrenilebilmeli ve takip edilebilmelidir. Bu amaçla rasgele özellikli ikili dizi (PRBS) girişi CSTR sistemine uygulanmıştır. CSTR sistemine uygulanan PRBS girişi ve bu sistemin beklenen giriş cevapları  $x_1$  ve  $x_2$  Şekil 6.11’de verilmiştir. Eğitim ve test MAPE değerleri Çizelge 6.3’de verilmiştir. Şekil 6.12, DANFIS ve DFWNN modellerinin eğitim performans indeks değerlerini karşılaştırmalı olarak vermektedir. Şekil 6.13 ve Şekil 6.14’de görüldüğü üzere eğitim aşamasında beklenen değerler ile önerilen modellerin aynı girişe verdikleri cevaplar neredeyse aynıdır ve ayırt edilememektedir. Şekil 6.15 ve Şekil 6.16 modellerin test sonuçlarını göstermektedir. Sonuçlardan görüldüğü üzere, hem DANFIS modeli hem de DFWNN modeli yüksek yaklaşım doğruluğu ve aynı zamanda CSTR modelinin iç davranışını modellemede iyi bir genelleştirme performansı göstermiştir.




Şekil 6.11. CSTR PRBS giriş cevabı için beklenen  $x_1$  ve  $x_2$  değerleri

**Çizelge 6.3.** CSTR PRBS giriş cevabı için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri


	DANFIS		DFWNN	
	MAPE ( $x_1$ )	MAPE ( $x_2$ )	MAPE ( $x_1$ )	MAPE ( $x_2$ )
Eğitim $x(0)=[0,0]$	0.02454	0.06049	0.03000	0.00644
Test $x(0)=[0.1,0.1]$	0.02546	0.01630	0.02689	0.01793
Test $x(0)=[-0.1,0.1]$	0.02880	0.02139	0.08740	0.02535
Test $x(0)=[-0.1,-0.1]$	0.02507	0.02780	0.09709	0.03173
Test $x(0)=[0.1,-0.1]$	0.03217	0.03003	0.03422	0.02735
Test $x(0)=[0.5,0.5]$	0.04325	0.03708	0.04149	0.02927



**Şekil 6.12.** CSTR, PRBS giriş cevabı için iterasyon sayısına karşı eğitim performans değerleri (4.15)




(a)




(b)

**Şekil 6.13.** CSTR PRBS giriş cevabı için  $x(0)=[0,0]$  başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)




(b)

**Şekil 6.14.** CSTR PRBS giriş cevabı için  $x(0)=[0,0]$  başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri **(a)**  $x_1$  **(b)**  $x_2$




(a)




(b)

**Şekil 6.15.** CSTR PRBS giriş cevabı için  $x(0)=[0.1,0.1]$  başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri **(a)**  $x_1$  **(b)**  $x_2$



(a)



(b)

Şekil 6.16. CSTR PRBS giriş cevabı için  $x(0)=[0.1,0.1]$  başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$

### 6.1.3. Biyoreaktör

Üçüncü örnek olarak, lineer olmayan özelliklere sahip diğer bir kimyasal biyoreaktör seçilmiştir. Bu tezde kullanılan biyoreaktör su, besin ve biyolojik hücrelerden oluşan bir tanktır. Besleyici maddeler ve hücreler tankın içerisine




sokulur ve karıştırılır. Bu biyoreaktör süreci aşağıdaki denklemler ile verilmiştir (Ungar, 1991; Derdiyok ve Levent, 2000):

$$\dot{x}_1 = -x_1u + x_1(1-x_2)e^{x_2/\gamma} \quad (6.18)$$

$$\dot{x}_2 = -x_2u + x_1(1-x_2)e^{x_2/\gamma} \frac{(1+\beta)}{(1+\beta-x_2)} \quad (6.19)$$

Burada  $x_1$  hücre sayısını,  $x_2$  besin miktarını karakterize etmektedir. Yukarıda belirtilen matematiksel modelde, büyüme hızı parametresi  $\beta = 0.02$  ve besin engelleme parametresi  $\gamma = 0.48$  olarak alınmıştır. Tank içeriğinin hacmi, gelen akış hızına eşit bir hızda tankın içindekiler kaldırılarak, sabit bir seviyede tutulmaktadır. Gelen akış hızı  $u$  ile gösterilmektedir.




Şekil 6.17. Biyoreaktörün PRBS giriş cevabı için beklenen  $x_1$  ve  $x_2$  değerleri

Biyoreaktör sistemi için, Şekil 6.7 uygulanan PRBS girişi ile bu girişle beklenen  $x_1$  ve  $x_2$  değerlerini göstermektedir. Çizelge 6.4’de eğitim ve test için MAPE değerleri verilmiştir. Şekil 6.18’de modellerin eğitim aşamasındaki performans indeks değerleri karşılaştırılmıştır. Şekil 6.19 ve Şekil 6.20’de önerilen DANFIS ve DFWNN modelleri için eğitim sonuçları gösterilmiştir. Benzer şekilde bu modellerin test sonuçları ise Şekil 6.21 ve Şekil 6.22’de verilmiştir. Bütün farklı


başlangıç noktalarıyla benzetim sonuçlarından görüldüğü üzere, ASM ile öğrenme algoritmasının birleşimiyle eğitilen DANFIS ve DFWNN modelleri biyoreaktör süreci için iyi bir modelleme yeteneğine sahiptir.

**Çizelge 6.4.** Biyoreaktör için 6 kurallı DANFIS ve DFWNN modellerinin eğitim ve test MAPE değerleri


	DANFIS		DFWNN	
	MAPE ( $x_1$ )	MAPE ( $x_2$ )	MAPE ( $x_1$ )	MAPE ( $x_2$ )
Eğitim $x(0) = [0.1090, 0.7920]$	0.03272	0.00792	0.02992	0.00745
Test $x(0) = [0.135, 0.540]$	0.04900	0.01468	0.05212	0.01653



**Şekil 6.18.** Biyoreaktör PRBS giriş cevabı için iterasyon sayısına karşı eğitim performans değerleri (4.15)




(a)




(b)

**Şekil 6.19.** Biyoreaktör PRBS giriş cevabı için  $x(0)=[0.1090, 0.7920]$  başlangıcı ile eğitildiğinde, beklenen, DANFIS model tahmini ve hata değerleri **(a)**  $x_1$  **(b)**  $x_2$

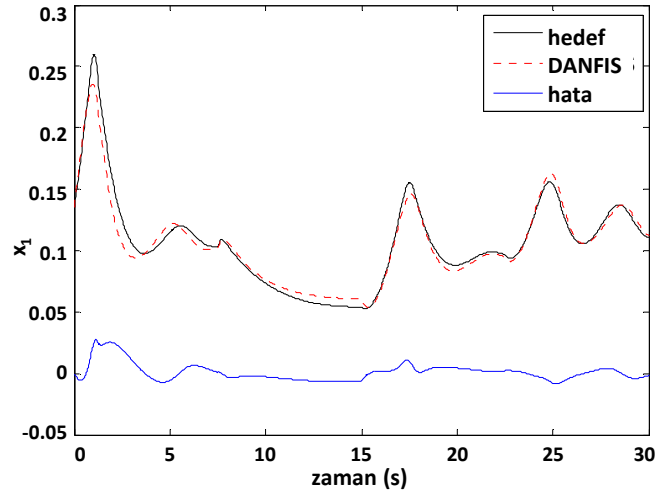


(a)




(b)

Şekil 6.20. Biyoreaktör PRBS giriş cevabı için  $x(0)=[0.1090, 0.7920]$  başlangıcı ile eğitildiğinde, beklenen, DFWNN model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$




(a)




(b)

Şekil 6.21. Biyoreaktör PRBS giriş cevabı için  $x(0)=[0.135 \ 0.540]$  başlangıcı ile test edildiğinde, beklenen, DANFIS model tahmini ve hata değerleri (a)  $x_1$  (b)  $x_2$



(a)



(b)

**Şekil 6.22.** Biyoreaktör PRBS giriş cevabı için  $x(0)=[0.135 \ 0.540]$  başlangıcı ile test edildiğinde, beklenen, DFWNN model tahmini ve hata değerleri **(a)**  $x_1$  **(b)**  $x_2$

## 6.2. DANFIS ve DFWNN Modelleri ile Denetleyici Tasarımı Sonuçları

Bir önceki bölümde, önerilen DANFIS ve DFWNN modellerinin sistem tanımlama performansı incelenmişti. Bu bölümde ise bu modeller LQR ile denetleyici tasarlamak için kullanılmıştır. Modellerin kontroldeki performanslarını

karşılaştırmak için Çizelge 6.5 ile verilen performans indeksleri kullanılmıştır. Verilen her bir indeksin listede belirtildiği gibi bir kullanım amacı vardır.

**Çizelge 6.5.** DANFIS ve DFWNN denetleyicilerinin performans indeksleri (Yesil ve ark., 2004; Oysal, 2005)

Performans İndeks	Formül	Kullanım amacı
ISE: Hatanın karesinin integrali	$ISE = \int_{t=t_0}^{t_f} e^2(t)dt$	Aşırı ve eksik sönümlü cevaplar
ITAE: Mutlak hatanın zaman ile çarpımının integrali	$ITAE = \int_{t=t_0}^{t_f} t e(t) dt$	Uzun süreli geçişleri ve cevaptan sonra oluşan hatalar
ITSE: Hatanın karesinin zaman ile çarpımının integrali	$ITSE = \int_{t=t_0}^{t_f} te^2(t)dt$	Büyük ilk ve son hatalar

### 6.2.1. CSTR kontrolü

DANFIS ve DFWNN'nin modellemedeki başarısından sonra, bulanık kontrol sistemi elde etmek için LQR yöntemi kullanılarak, konsantrasyon ve sıcaklık denetleyicileri tasarlanabilir. Burada verilen denetleyicinin amacı, besleme sıcaklığı 40. saniyede 295°K'de 300°K'ye getirildiğinde CSTR sistemini istenen çalışma noktasına getirmektir. Bu işlem daha az frekans düşüşü ve frekansta hızlı dışarı sönümlü salınımlar ile gerçekleşmelidir. Denetleyici tasarımında, CSTR sürecinin durum değişkenlerini istediğimiz noktaya getirebilmek için, LQR'in  $Q$  ve  $R$  matrisleri aşağıdaki gibi seçilmiştir:

$$R = 41, Q = \begin{bmatrix} 10 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.20)$$

Burada Çizelge 6.5 ile verilen hata değerlerine ek olarak yerleşme zamanı ve maksimum aşma değerleri de hesaplanmıştır. Yerleşme zamanı, belirli bir hata bandı içerisinde final değeri yakalamak ve içerisinde kalmak için geçen zamandır. CSTR örneğinde hata bandı %±5 seçilmiştir. Bu faktör, sistemin kararlı bir şekilde arzu edilen bir noktaya ne kadar hızlı şekilde ulaştığını gösterir. Maksimum aşma, sistemin beklenen tepkisinden, cevap eğrisine ölçülen maksimum zirve değeridir (Ogata, 1995).

$x_1$  ve  $x_2$  için başlangıç değerleri  $[0,0]$ ,  $[-0.2,-0.2]$  ve  $[0.5,0.5]$  olarak seçilmiştir. Bu başlangıç noktalarıyla DANFIS ve DFWNN modellerinin performansı ISE, ITAE, ITSE, yerleşme zamanı ve maksimum aşma açısından Çizelge 6.6, Çizelge 6.7 ve Çizelge 6.8’de karşılaştırılmıştır. Sıcaklık ve konsantrasyon için başlangıç değerleri  $x(0) = [-0.2, -0.2]$  seçildiğinde, DANFIS ve DFWNN denetleyicilerinin sonuçları Şekil 6.23’te gösterilmiştir.

Benzetim sonuçlarından görüldüğü üzere önerilen bulanık denetleyiciler besleme sıcaklığının geçici değişikliklerinde güçlüdür. Sonuçlar incelendiğinde, DFWNN denetleyicisinin daha az ISE, ITAE ve ITSE hata değerlerine, daha az yerleşme zamanına ve daha küçük aşma değerine sahip olduğu görülmektedir. Bu nedenle, CSTR süreci için önerilen DFWNN modelinin kontrol işlemlerinde DANFIS modelinden daha başarılı olduğu görülmüştür.

**Çizelge 6.6.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[0,0]$  başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri

	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
<b>ISE</b>	0.01384	0.08392	0.01262	0.07189
<b>ITAE</b>	0.67719	2.52401	0.60989	1.81604
<b>ITSE</b>	0.03469	0.52573	0.03063	0.28085
<b>Yerleşme zamanı (s)</b>	3.6	3.5	3.2	3.0
<b>Maksimum aşma</b>	0.03575	0.26443	0.03627	0.20691


**Çizelge 6.7.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[-0.2, -0.2]$  başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri

	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
<b>ISE</b>	0.02803	0.14664	0.02453	0.10571
<b>ITAE</b>	0.71836	2.70625	0.63652	1.91092
<b>ITSE</b>	0.04169	0.62723	0.03537	0.32110
<b>Yerleşme zamanı (s)</b>	4.0	3.7	3.4	3.1
<b>Maksimum aşma</b>	0.07971	0.56930	0.07578	0.42352




**Çizelge 6.8.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[0.5, 0.5]$  başlangıçlı CSTR kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri

	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
ISE	0.00176	0.07088	0.00244	0.06913
ITAE	0.65092	2.45288	0.59818	1.80098
ITSE	0.03014	0.51751	0.02779	0.28793
Yerleşme zamanı (s)	2.6	2.3	2.4	2.0
Maksimum aşma	0.09820	0.02828	0.09980	0.04322



(a)



(b)

**Şekil 6.23.** Besleme sıcaklığı 40.s'de 295°K'dan 300°K'ya yükseltildiğinde  $x(0)=[-0.2, -0.2]$  başlangıçlı CSTR sistem cevabı (a) DANFIS-LQR denetleyici kullanıldığında (b) DFWNN-LQR denetleyici kullanıldığında

### 6.2.2. Bioreaktör kontrolü

DANFIS ve DFWNN modellerine bağlı olarak ikinci denetleyici tasarımı için bioreaktör süreci seçilmiştir. Bu örnekte, bioreaktör durumları keyfi başlangıç noktalarından kararlı  $x_1 = 0.1207$  ve  $x_2 = 0.8801$  durumlarına getirilmesi ve ayrıca hücre miktarının istenen bir seviyede tutulması amaçlanmıştır. Bioreaktör kontrolünde, durum değişkenlerini belirtilen noktalara getirebilmek için, LQR'da  $R$  ve  $Q$  matrisleri aşağıdaki gibi seçilmiştir.

$$R = 12, Q = \begin{bmatrix} 5 & 0 & 0 \\ 0 & 5 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.21)$$

Bioreaktör kontrolü için  $x(0) = [0.009, 0.009]$ ,  $x(0) = [0.1090, 0.7920]$ ,  $x(0) = [0.135, 0.540]$  başlangıç değerleriyle birlikte, DANFIS ve DFWNN denetleyicilerinin yerleşme zamanı, maksimum aşma ve hata değerleri hesaplanmış, Çizelge 6.9, Çizelge 6.10 ve Çizelge 6.11'de özetlenmiştir. Denetleyicinin yerleşme zamanını hesaplarken, tolerans  $\% \pm 10$  seçilmiştir.  $x(0) = [0.135, 0.540]$  başlangıç değeri için, DANFIS ve DFWNN denetleyici kullanıldığında bioreaktör sistem cevapları Şekil 6.24'de verilmiştir. Bioreaktör sürecinin kısıtlamaları düşünüldüğünde verilen modellerin kontrol eyleminde başarılı ve uygun olduğu görülmüştür. Bu örnekte de CSTR örneğine benzer olarak, DFWNN denetleyicinin daha az ISE, ITAE ve ITSE hata değerlerine, daha az yerleşme zamanına ve daha küçük maksimum aşma değerine sahip olduğu görülmüştür. Bu nedenle önerilen DFWNN modelinin bioreaktör kontrolünde DANFIS modelinden daha başarılı olduğunu söylenebilir.

**Çizelge 6.9.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[0.009,0.009]$  başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri


	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
<b>ISE</b>	0.13092	2.13753	0.09360	2.11652
<b>ITAE</b>	3.14085	6.86244	2.24949	5.51044
<b>ITSE</b>	0.45463	3.27349	0.29400	3.16555
<b>Yerleşme zamanı (s)</b>	7.6727	5.4204	6.0811	3.8889
<b>Maksimum aşma</b>	0.38224	0.11549	0.38313	0.10262

**Çizelge 6.10.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[0.1090, 0.7920]$  başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri


	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
<b>ISE</b>	0.00171	0.00564	0.00071	0.00197
<b>ITAE</b>	1.21668	1.67328	0.79139	1.10854
<b>ITSE</b>	0.01323	0.02580	0.00558	0.01096
<b>Yerleşme zamanı (s)</b>	2.8378	0	0	0
<b>Maksimum aşma</b>	0.01077	0.04545	0.00706	0.00985

**Çizelge 6.11.** DANFIS-LQR ve DFWNN-LQR ile  $x(0)=[0.135, 0.540]$  başlangıçlı biyoreaktör kontrolü için yerleşme zamanı, maksimum aşma ve hata değerleri

	DANFIS		DFWNN	
	$x_1$	$x_2$	$x_1$	$x_2$
<b>ISE</b>	0.00953	0.03627	0.00802	0.02449
<b>ITAE</b>	1.27492	1.78262	0.87872	1.10776
<b>ITSE</b>	0.01808	0.03918	0.01041	0.01391
<b>Yerleşme zamanı (s)</b>	3.5135	1.2613	2.4625	0.3604
<b>Maksimum aşma</b>	0.11528	0.10292	0.11616	0.03999



(a)



(b)

Şekil 6.24.  $x(0)=[0.135, 0.540]$  başlangıçlı biyoreaktör sistem cevabı (a) DANFIS-LQR denetleyici kullanıldığında (b) DFWNN-LQR denetleyici kullanıldığında

### 6.3. Sonuçlar

Bu bölümde, önerilen DANFIS ve DFWNN modellerinin modelleme ve kontrol sonuçları verilmiştir. VDP osilatörü, CSTR ve biyoreaktör süreci modelleme sonuçları göstermiştir ki önerilen her iki model de yüksek yaklaşım doğruluğu ve iyi genelleştirme performansı sunmaktadır. DANFIS ve DFWNN'nin modellemedeki test sonuçları karşılaştırıldığında, bazı başlangıç noktalarında DANFIS modeli başarılı, bazılarında da DFWNN modeli başarılı olmuştur.

Modelleme işleminden sonra, DANFIS ve DFWNN modelleme parametreleri kullanılarak LQR bulanık denetleyicisi tasarlanmıştır. Her iki modelin de CSTR ve biyoreaktör sürecini denetlemede başarılı olduğu görülmüştür. Ancak, hata değerleri, yerleşme zamanı ve maksimum aşma değerleri incelendiğinde her iki süreç için de DFWNN denetleyicisinin daha başarılı olduğu görülmüştür.

## 7. SONUÇLAR

Bu tezde üç farklı bulanık sinir ağı modeli önerilmiştir. Bunlar T2FWNN, DANFIS ve DFWNN modelleridir. İlk model T2FWNN’de kuralların IF kısmında tip-2 dalgacık fonksiyonları üyelik fonksiyonu olarak kullanılmıştır. Kuralların THEN kısmında ise dalgacık fonksiyonlarının ağırlıklı toplamı kullanılmıştır. T2FWNN model yapısı ve bu modelin parametre güncelleme kuralları gradyan tabanlı bir algoritmaya göre verilmiştir. Önerilen modelin performansını göstermek için, dinamik sistemlerin tanımlanması benzetim çalışmaları yapılmıştır ve bunların sonuçları verilmiştir. Bütün benzetim durumlarında T2FWNN modeli yüksek yaklaşım doğruluğu ve sistemden gürültüyü kaldırarak iyi bir genelleştirme performansı göstermiştir. Daha önce önerdiğimiz FWNN modelini tip-2 bulanık kümeler ile birleştirerek önerilen yeni T2FWNN modelinin, sistemdeki yüksek derecedeki gürültüyü ve belirsizliği kaldırmada tip-1 nöro-bulanık sistemlerine göre daha üstün olduğu görülmüştür. Ancak, T2FWNN modelinin performansı FWNN modeline göre çok fazla değişmemiştir. Çünkü tip-2 bulanık kümelerinin üç boyutlu yapısı sistem karmaşıklığını arttırmaktadır. İlerleyen araştırmalarımız T2FWNN modelinin performansını arttırmak için yeni eğitim yöntemlerini denemek yönünde olacaktır. Prensipte olarak, T2FWNN modeli herhangi bir doğrusal olmayan sisteme yaklaşabilmelidir. T2FWNN modellerinin etkileyici genelleştirebilme özelliği öncelikli olarak dalgacık fonksiyonlarının modellerde kullanılmasından ve onların zaman ve frekansta yerellik özelliklerine sahip olmasından gelmektedir. Belirsizlikle başa çıkma özelliğinden dolayı, T2FWNN modelleri verilen veri setinin eğitiminde daha büyük doğruluk yakalamalıdır ve ayrıca sistem tanımlama örneklerindeki rasgele bozukluğu gidermelidir.

Tezin ikinci kısmı olarak, yeni bir dinamik nöro-bulanık sistem DANFIS doğrusal olmayan dinamik sistemlerin modellenmesi için tanıtılmıştır. DANFIS modeli iyi bilinen ölçüt dinamik sistemlerine hem sistem modellenmesi hem de kontrol uygulamaları için uygulanmıştır. Önerilen DANFIS modeli, bütün örneklerde yüksek yaklaşım doğruluğu göstermesinin yanı sıra sistemin iç dinamik davranışını modellemede iyi bir genelleştirme performansı göstermiştir. DANFIS modelinin, sistemin dış davranışını modelleyen cebirsel nöro-bulanık modellere

göre sistemin iç davranışını da modelleyen yapısı ve öğrenme algoritması ile beraber üstün bir model olduğu görülmüştür. Ayrıca DANFIS modeli, yerel lineer dinamikleri denetleyici tasarımında kullanmamıza olanak sağlamaktadır. DANFIS modeliyle LQR denetleyicisi, CSTR ve biyoreaktör süreçleri için uygulanmıştır ve başarılı olduğu görülmüştür. DANFIS modeli herhangi doğrusal olmayan dinamik bir süreci iç davranışlarıyla modelleyebilir. DANFIS modellerinin etkileyici genelleştirebilme yeteneği öncelikli olarak T-S bulanık sistemlerinin ASM ile birlikte gradyan tabanlı bir algoritma ile eğitilmesi ve böylece dinamik sistemleri yerelleştirebilme özelliğinden gelmektedir. Bu yeteneklerle birlikte, DANFIS ile dinamik sistemlerin yörünge takibinde yüksek bir doğrulukla başarı elde etmiştir.

Tezin üçüncü kısmı olarak, DANFIS modelindeki Gauss tipi üyelik fonksiyonları, DFWNN modelinde dalgacık üyelik fonksiyonları olarak değiştirilmiştir. DFWNN modeli de bir afin T-S afin bulanık modelidir. Dalgacıkların zaman ve frekanstaki yerelleştirme özellikleriyle birlikte doğrusal olmayan dinamik sistemin iç davranışı da T-S bulanık sistemiyle modellenmiştir. Afin bulanık sistem ile doğrusal olmayan sistemin arasındaki hatayı minimize etmek için, DFWNN modelinin uygun parametreleri DANFIS modeline benzer bir şekilde ASM ve gradyan tabanlı bir algoritma olan BFGS ile bulunmuştur. Bazı önemli doğrusal olmayan dinamik sistemler için DFWNN modelleme ve kontrol uygulamaları yapılmıştır ve bulunan sonuçlar DANFIS modelinin sonuçları ile karşılaştırılmıştır. Modelleme örneklerinde her iki model de benzer performans göstermişken, kontrol uygulamalarına baktığımızda DFWNN modelinin daha başarılı olduğu görülmüştür.

DANFIS ve DFWNN modellerinin diğer bir araştırma alanı farklı t-norm operatörlerinin ve bulanık çıkarım mekanizmalarının kullanılması alanında ya da kullanılan öğrenme algoritmasının geliştirilmesi aşamasında olabilir. DANFIS ve DFWNN modellerinin finansal veri analizi ve tahmini ya da diğer sistem tanımlama ve kontrol uygulamaları gibi geniş gerçek hayat problemlerinde uygulanabileceği düşünülmektedir.

## KAYNAKLAR

- Abiyev, R. H. ve Kaynak, O. (2008), "Fuzzy wavelet neural networks for identification and control of dynamic plants - A novel structure and a comparative study," *IEEE Transactions on Industrial Electronics*, **55**(8), 3133-3140.
- Abiyev, R. H., Kaynak, O. ve Kayacan, E. (2013), "A type-2 fuzzy wavelet neural network for system identification and control," *Journal of the Franklin Institute-Engineering and Applied Mathematics*, **350**(7), 1658-1685.
- Al-Hadithi, B. M., Jimenez, A. ve Matia, F. (2012), "A new approach to fuzzy estimation of Takagi-Sugeno model and its applications to optimal control for nonlinear systems," *Applied Soft Computing*, **12**(1), 280-290.
- Aliev, R. A., Pedrycz, W., Guirimov, B. G., Aliev, R. R., Ilhan, U., Babagil, M. ve Mammadli, S. (2011), "Type-2 fuzzy neural networks with fuzzy clustering and differential evolution optimization," *Information Sciences*, **181**(9), 1591-1608.
- Banakar, A. ve Azeem, M. F. (2008), "Artificial wavelet neural network and its application in neuro-fuzzy models," *Applied Soft Computing*, **8**(4), 1463-1485.
- Baranyi, P. (2004), "TP model transformation as a way to LMI-based controller design," *IEEE Transactions on Industrial Electronics*, **51**(2), 387-400.
- Baranyi, P., Yam, Y., Varkonyi-Koczy, A. R., Patton, R. J., Michelberger, P. ve Sugiyama, M. (2002), "SVD-based complexity reduction to TS fuzzy models," *IEEE Transactions on Industrial Electronics*, **49**(2), 433-443.
- Becerikli, Y., Oysal, Y. ve Konar, A. F. (2003), "On a dynamic wavelet network and its modeling application," *Artificail Neural Networks and Neural Information Processing - Ican/Iconip 2003*, **2714**, 710-718.
- Becerikli, Y., Oysal, Y. ve Konar, A. F. (2004), "Trajectory priming with dynamic fuzzy networks in nonlinear optimal control," *IEEE Transactions on Neural Networks*, **15**(2), 383-394.
- Bezdek, J. C., Ehrlich, R. ve Full, W. (1984), "Fcm - the Fuzzy C-Means Clustering-Algorithm," *Computers & Geosciences*, **10**(2-3), 191-203.



- Billings, S. A. ve Wei, H. L. (2005), "A new class of wavelet networks for nonlinear system identification," *IEEE Transactions on Neural Networks*, **16**(4), 862-874.
- Box, G. E. P. (1970), "*Time Series Analysis, Forecasting and Control* Holden Day, San Francisco.
- Bryson, A. E. ve Ho, Y.-C. (1969), "*Applied optimal control : optimization, estimation, and control*," Blaisdell Pub. Co., Waltham, Mass.
- Cao, S. G. ve Rees, N. W. (1995), "Identification of Dynamic Fuzzy Models," *Fuzzy Sets and Systems*, **74**(3), 307-320.
- Cao, S. G., Rees, N. W. ve Feng, G. (1997), "Analysis and design for a class of complex control systems .1. Fuzzy modelling and identification," *Automatica*, **33**(6), 1017-1028.
- Cao, Y., Li, S. T. ve Petzold, L. (2002), "Adjoint sensitivity analysis for differential-algebraic equations: algorithms and software," *Journal of Computational and Applied Mathematics*, **149**(1), 171-191.
- Cartwright, M. L. (1960), "Balthazar van der Pol," *J. London Math. Soc.*, **35**, 367-376.
- Castillo, O., Martinez-Marroquin, R., Melin, P., Valdez, F. ve Soria, J. (2012), "Comparative study of bio-inspired algorithms applied to the optimization of type-1 and type-2 fuzzy controllers for an autonomous mobile robot," *Information Sciences*, **192**, 19-38.
- Castillo, O. ve Melin, P. (2008), "*Type-2 Fuzzy Logic: Theory and Applications*," Springer Berlin Heidelberg.
- Castro, J. R., Castillo, O., Melin, P., Mendoza, O. ve Rodriguez-Diaz, A. (2011), "An Interval Type-2 Fuzzy Neural Network for Chaotic Time Series Prediction with Cross-Validation and Akaike Test," *Soft Computing for Intelligent Control and Mobile Robotics*, **318**, 269-285.
- Castro, J. R., Castillo, O., Melin, P. ve Rodriguez-Diaz, A. (2009), "A hybrid learning algorithm for a class of interval type-2 fuzzy neural networks," *Information Sciences*, **179**(13), 2175-2193.
- Chapra, S. C. ve Canale, R. P. (1988), "*Numerical methods for engineers*," McGraw-Hill, New York.

- Chen, S. S., Chang, Y. C., Su, S. F., Chung, S. L. ve Lee, T. T. (2005), "Robust static output-feedback stabilization for nonlinear discrete-time systems with time delay via fuzzy control approach," *IEEE Transactions on Fuzzy Systems*, **13**(2), 263-272.
- Chen, Y. H., Yang, B. ve Dong, J. W. (2006), "Time-series prediction using a local linear wavelet neural network," *Neurocomputing*, **69**(4-6), 449-465.
- Chiu, C. S. ve Chiang, T. S. (2009), "Robust Output Regulation of T-S Fuzzy Systems With Multiple Time-Varying State and Input Delays," *IEEE Transactions on Fuzzy Systems*, **17**(4), 962-975.
- Davanipoor, M., Zekri, M. ve Sheikholeslam, F. (2012), "Fuzzy Wavelet Neural Network With an Accelerated Hybrid Learning Algorithm," *IEEE Transactions on Fuzzy Systems*, **20**(3), 463-470.
- Derdiyok, A. ve Levent, M. (2000), "Sliding mode control of a bioreactor," *Korean Journal of Chemical Engineering*, **17**(6), 619-624.
- Elman, J. L. (1990), "Finding structure in time," *Cognit. Sci.*, **14**, 179-211.
- Gill, P. E., Murray, W. ve Wright, M. H. (1981), "*Practical optimization*," Academic Press, London ; New York.
- Graps, A. (1995), "An Introduction to Wavelets," *IEEE Computational Science & Engineering*, **2**(2), 50-61.
- Ho, D. W. C., Zhang, P. A. ve Xu, J. H. (2001), "Fuzzy wavelet networks for function learning," *IEEE Transactions on Fuzzy Systems*, **9**(1), 200-211.
- Holmes, C. C. ve Mallick, B. K. (2000), "Bayesian wavelet networks for nonparametric regression," *IEEE Transactions on Neural Networks*, **11**(1), 27-35.
- Horikawa, S., Furuhashi, T. ve Uchikawa, Y. (1992), "On Fuzzy Modeling Using Fuzzy Neural Networks with the Backpropagation Algorithm," *IEEE Transactions on Neural Networks*, **3**(5), 801-806.
- Hsiao, C. C., Su, S. F., Lee, T. T. ve Chuang, C. C. (2004), "Hybrid compensation control for affine TSK fuzzy control systems," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **34**(4), 1865-1873.

- Ismail, R., Jusoff, K., Ahmad, T., Ahmad, S. ve Ahmad, R. S. (2009), "Fuzzy State Space Model of Multivariable Control Systems," *Computer and Information Science*, **2**(2), 19-25.
- Iyengar, S. S., Cho, E. C. ve Phoha, V. V. (2002), "*Foundations of Wavelet Networks and Applications*," CRC Press, USA.
- J.-Y. Chang, Y.-Y. L., M.-F. Han, C.-T. Lin (2011), "A Functional-Link based Interval Type-2 Compensatory Fuzzy Neural Network for Nonlinear System modeling," *Proceedings of the*.
- Jang, J. S. R. (1993), "Anfis - Adaptive-Network-Based Fuzzy Inference System," *IEEE Transactions on Systems Man and Cybernetics*, **23**(3), 665-685.
- Juang, C.-F., Lin, Y. Y. ve Chung, I.-F. (2009a), "Dynamic System Identification Using A Type-2 Recurrent Fuzzy Neural Network," *Proceedings of the Proceedings of the 7th Asian Control Conference*.
- Juang, C. F. (2002), "A TSK-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms," *IEEE Transactions on Fuzzy Systems*, **10**(2), 155-170.
- Juang, C. F., Huang, R. B. ve Cheng, W. Y. (2010), "An Interval Type-2 Fuzzy-Neural Network With Support-Vector Regression for Noisy Regression Problems," *IEEE Transactions on Fuzzy Systems*, **18**(4), 686-699.
- Juang, C. F., Huang, R. B. ve Lin, Y. Y. (2009b), "A Recurrent Self-Evolving Interval Type-2 Fuzzy Neural Network for Dynamic System Processing," *IEEE Transactions on Fuzzy Systems*, **17**(5), 1092-1105.
- Juang, C. F. ve Lin, C. T. (1998), "An on-line self-constructing neural fuzzy inference network and its applications," *IEEE Transactions on Fuzzy Systems*, **6**(1), 12-32.
- Juang, C. F. ve Lin, C. T. (1999), "A recurrent self-organizing neural fuzzy inference network," *IEEE Transactions on Neural Networks*, **10**(4), 828-845.
- Juang, C. F. ve Tsao, Y. W. (2008), "A Self-Evolving Interval Type-2 Fuzzy Neural Network With Online Structure and Parameter Learning," *IEEE Transactions on Fuzzy Systems*, **16**(6), 1411-1424.

- Karatepe, E. ve Alci, M. (2005), "A new approach to fuzzy wavelet system modeling," *International Journal of Approximate Reasoning*, **40**(3), 302-322.
- Karnik, N. N., Mendel, J. M. ve Liang, Q. L. (1999), "Type-2 fuzzy logic systems," *IEEE Transactions on Fuzzy Systems*, **7**(6), 643-658.
- Kim, E. ve Kim, S. (2002), "Stability analysis and synthesis for an affine fuzzy control system via LMI and ILMI: Continuous case," *IEEE Transactions on Fuzzy Systems*, **10**(3), 391-400.
- Kim, J. ve Kasabov, N. (1999), "HyFIS: adaptive neuro-fuzzy inference systems and their application to nonlinear dynamical systems," *Neural Networks*, **12**(9), 1301-1319.
- Klir, G. J. ve Yuan, B. (1995), "*Fuzzy Sets and Fuzzy Logic Theory and Applications*," Prentice Hall.
- Konar, A. F. (1991), "Gradient and curvature in nonlinear identification," *Proceedings of the Honeywell Advanced Control Workshop*, 21-22.
- Konar, A. F. ve Samad, T. (1992). *Dynamic Neural Networks*. Honeywell Technol. Center.
- Kruszewski, A., Wang, R. ve Guerra, T. M. (2008), "Nonquadratic stabilization conditions for a class of uncertain nonlinear discrete time TS fuzzy models: A new approach," *IEEE Transactions on Automatic Control*, **53**(2), 606-611.
- Lam, H. K. ve Leung, F. H. F. (2005), "Stability analysis of fuzzy control systems subject to uncertain grades of membership," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **35**(6), 1322-1325.
- Lee, C. H. ve Teng, C. C. (2000), "Identification and control of dynamic systems using recurrent fuzzy neural networks," *IEEE Transactions on Fuzzy Systems*, **8**(4), 349-366.
- Liang, Q. L. ve Mendel, J. M. (2000), "Interval type-2 fuzzy logic systems: Theory and design," *IEEE Transactions on Fuzzy Systems*, **8**(5), 535-550.
- Lin, C.-T. ve Lee, C. S. G. (1996), "*Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*" Prentice Hall.

- Lin, F. J. ve Chou, P. H. (2009), "Adaptive Control of Two-Axis Motion Control System Using Interval Type-2 Fuzzy Neural Network," *IEEE Transactions on Industrial Electronics*, **56**(1), 178-193.
- Lin, Y.-Y., Chang, J.-Y. ve Lin, C.-T. (2010), "An Internal Interconnection Recurrent Type-2 Fuzzy Neural Network (IRT2FNN) for Dynamic System Identification," *Proceedings of the 2010 IEEE International Conference on Systems Man and Cybernetics (SMC)*.
- Liu, C. F., Yeh, C. Y. ve Lee, S. J. (2012), "Application of type-2 neuro-fuzzy modeling in stock price prediction," *Applied Soft Computing*, **12**(4), 1348-1358.
- Lu, C. H. (2011), "Wavelet Fuzzy Neural Networks for Identification and Predictive Control of Dynamic Systems," *IEEE Transactions on Industrial Electronics*, **58**(7), 3046-3058.
- Mallat, S. ve Hwang, W. L. (1992), "Singularity Detection and Processing with Wavelets," *IEEE Transactions on Information Theory*, **38**(2), 617-643.
- Mallat, S. ve Zhong, S. (1992), "Characterization of Signals from Multiscale Edges," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **14**(7), 710-732.
- Mallat, S. G. (1989), "A Theory for Multiresolution Signal Decomposition - the Wavelet Representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **11**(7), 674-693.
- Melin, P., Astudillo, L., Castillo, O., Valdez, F. ve Garcia, M. (2013), "Optimal design of type-2 and type-1 fuzzy tracking controllers for autonomous mobile robots under perturbed torques using a new chemical optimization paradigm," *Expert Systems with Applications*, **40**(8), 3185-3195.
- Melin, P. ve Castillo, O. (2013), "A review on the applications of type-2 fuzzy logic in classification and pattern recognition," *Expert Systems with Applications*, **40**(13), 5413-5423.
- Mendel, J. M. (2007), "Type-2 fuzzy sets and systems: An overview," *IEEE Computational Intelligence Magazine*, **2**(1), 20-29.

- Mendez, G. M. ve Hernandez, M. D. (2013), "Hybrid learning mechanism for interval A2-C1 type-2 non-singleton type-2 Takagi-Sugeno-Kang fuzzy logic systems," *Information Sciences*, **220**, 149-169.
- Nocedal, J. ve Wright, S. J. (2006), "*Numerical optimization*," Springer, New York.
- Ogata, K. (1995), "*Discrete-time control systems*," Prentice Hall, Englewood Cliffs, N.J.
- Oysal, Y. (2005), "A comparative study of adaptive load frequency controller designs in a power system with dynamic neural network models," *Energy Conversion and Management*, **46**(15-16), 2656-2668.
- Oysal, Y., Becerikli, Y. ve Konar, A. F. (2003), "Generalized modeling principles of a nonlinear system with a dynamic fuzzy network," *Computers & Chemical Engineering*, **27**(11), 1657-1664.
- Oysal, Y., Becerikli, Y. ve Konar, A. F. (2006), "Modified descend curvature based fixed form fuzzy optimal control of nonlinear dynamical systems," *Computers & Chemical Engineering*, **30**(5), 878-888.
- Oysal, Y. ve Yilmaz, S. (2010), "An adaptive wavelet network for function learning," *Neural Computing & Applications*, **19**(3), 383-392.
- Passino, K. M. ve Yurkovich, S. (1998), "*Fuzzy Control*," Addison-Wesley Longman, Inc.
- R.K.H. Galvao, V. M. Baccara, J. M.F. Calad ve Silva, P. M. (2004), "Linear-Wavelet Networks," *Int. J. Appl. Math. Comput. Sci.*, **14**(2), 221-232.
- Ray, W. H. (1981), "New approaches to the dynamics of nonlinear systems with implications for process and control design," *Chemical Process Control*, **2**(119).
- Sala, A. ve Arino, C. (2007), "Asymptotically necessary and sufficient conditions for stability and performance in fuzzy control: Applications of Polya's theorem," *Fuzzy Sets and Systems*, **158**(24), 2671-2686.
- Sanner, R. M. ve Slotine, J. J. E. (1992), "Gaussian Networks for Direct Adaptive-Control," *IEEE Transactions on Neural Networks*, **3**(6), 837-863.
- Singh, M., Srivastava, S., Hanmandlu, M. ve Gupta, J. R. P. (2009), "Type-2 fuzzy wavelet networks (T2FWN) for system identification using fuzzy

- differential and Lyapunov stability algorithm," *Applied Soft Computing*, **9**(3), 977-989.
- Srivastava, S., Singh, M., Hanmandlu, M. ve Jha, A. N. (2005), "New fuzzy wavelet neural networks for system identification and control," *Applied Soft Computing*, **6**(1), 1-17.
- Sugeno, M. (1999), "On stability of fuzzy systems expressed by fuzzy rules with singleton consequents," *IEEE Transactions on Fuzzy Systems*, **7**(2), 201-224.
- 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), 116-132.
- Tung, S. W., Quek, C. ve Guan, C. (2013), "eT2FIS: An Evolving Type-2 Neural Fuzzy Inference System," *Information Sciences*, **220**, 124-148.
- Ungar, L. H. (1991), "A bioreactor benchmark for adaptive-network based process control," *Neural Networks for Control*, MA, USA MIT Press, 387 - 402.
- Valens, C. (1999) " A Really Friendly Guide to Wavelets, " <http://pagesperso-orange.fr/polyvalens/clemens/download/arfgtw.pdf>.
- Van der Pol, B. (1927), "On relaxation-oscillations," *The London, Edinburgh and Dublin Phil. Mag. & J. of Sci.*, **2**(7), 978-992.
- Wang, C. H., Cheng, C. S. ve Lee, T. T. (2004a), "Dynamical optimal training for interval type-2 fuzzy neural network (T2FNN)," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **34**(3), 1462-1477.
- Wang, H. M. ve Yang, G. H. (2013), "Controller design for affine fuzzy systems via characterization of dilated linear matrix inequalities," *Fuzzy Sets and Systems*, **217**, 96-109.
- Wang, R. J., Lin, W. W. ve Wang, W. J. (2004b), "Stabilizability of linear quadratic state feedback for uncertain fuzzy time-delay systems," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **34**(2), 1288-1292.
- Wang, W. J. ve Luoh, L. (2004), "Stability and stabilization of fuzzy large-scale systems," *IEEE Transactions on Fuzzy Systems*, **12**(3), 309-315.

- Wang, W. J. ve Sun, C. H. (2004), "A relaxed stability criterion for T-S fuzzy discrete systems," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **34**(5), 2155-2158.
- Yeh, C. Y., Jeng, W. H. R. ve Lee, S. J. (2011), "Data-Based System Modeling Using a Type-2 Fuzzy Neural Network with a Hybrid Learning Algorithm," *IEEE Transactions on Neural Networks*, **22**(12), 2296-2309.
- Yesil, E., Guzelkaya, M. ve Eksin, I. (2004), "Self tuning fuzzy PID type load and frequency controller," *Energy Conversion and Management*, **45**(3), 377-390.
- Yilmaz, S. (2009). A New Fuzzy Wavelet Neural Network Design for Time Series Prediction Master of Science Thesis, Anadolu University.
- Yilmaz, S. ve Oysal, Y. (2009), "A Fuzzy Wavelet Neural Network Model for System Identification," *Proceedings of the 9th The International Conference on Intelligent Systems Design and Applications (ISDA)*, Pisa, Italy.
- Yilmaz, S. ve Oysal, Y. (2010), "Fuzzy Wavelet Neural Network Models for Prediction and Identification of Dynamical Systems," *IEEE Transactions on Neural Networks*, **21**(10), 1599-1609.
- Yilmaz, S. ve Oysal, Y. (2014), "Nonlinear System Modeling with Dynamic Adaptive Neuro-Fuzzy Inference System," *Proceedings of the 2014 IEEE International Symposium on INnovations in Intelligent SysTems and Applications*, Bari, Italy.
- Zadeh, L. A. (1975), "The concept of a linguistic variable and its application to approximate reasoning," *Information Sciences*, **8**, 199-249.
- Zekri, M., Sadri, S. ve Sheikholeslam, F. (2008), "Adaptive fuzzy wavelet network control design for nonlinear systems," *Fuzzy Sets and Systems*, **159**(20), 2668-2695.
- Zhang, J., Walter, G. G., Miao, Y. B. ve Lee, W. N. W. (1995), "Wavelet Neural Networks for Function Learning," *IEEE Transactions on Signal Processing*, **43**(6), 1485-1497.
- Zhang, Q. G. ve Benveniste, A. (1992), "Wavelet Networks," *IEEE Transactions on Neural Networks*, **3**(6), 889-898.



- Zhang, Q. H. (1997), "Using wavelet network in nonparametric estimation," *IEEE Transactions on Neural Networks*, **8**(2), 227-236.
- Zhao, H. Q., Zeng, X. P. ve He, Z. Y. (2011), "Low-Complexity Nonlinear Adaptive Filter Based on a Pipelined Bilinear Recurrent Neural Network," *IEEE Transactions on Neural Networks*, **22**(9), 1494-1507.
- Zhao, H. Q. ve Zhang, J. S. (2009), "Nonlinear dynamic system identification using pipelined functional link artificial recurrent neural network," *Neurocomputing*, **72**(13-15), 3046-3054.
- Zhao, H. Q. ve Zhang, J. S. (2010), "Pipelined Chebyshev Functional Link Artificial Recurrent Neural Network for Nonlinear Adaptive Filter," *IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics*, **40**(1), 162-172.