T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

TORNALAMADA KESME KUVVETLERİNİN VE TAKIM UCU SICAKLIĞININ BULANIK MANTIK VE YAPAY SİNİR AĞI TEKNİKLERİYLE TAHMİN EDİLMESİ

İlker Ali ÖZKAN

YÜKSEK LİSANS TEZİ

BİLGİSAYAR SİSTEMLERİ EĞİTİMİ

ANA BİLİM DALI

KONYA, 2006

T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

TORNALAMADA KESME KUVVETLERİNİN VE TAKIM UCU SICAKLIĞININ BULANIK MANTIK VE YAPAY SİNİR AĞI TEKNİKLERİYLE TAHMİN EDİLMESİ

İlker Ali ÖZKAN

YÜKSEK LİSANS TEZİ

BİLGİSAYAR SİSTEMLERİ EĞİTİMİ ANA BİLİM DALI

Bu tez 28 /07/ 2006 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

.....	.....	.....
Prof. Dr.	**Prof. Dr.**	**Doç. Dr.**
Süleyman YALDIZ	**Novruz ALLAHVERDİ**	**Hacı SAĞLAM**
(Danışman)	**(Üye)**	**(Üye)**

ÖZET

Yüksek Lisans Tezi

TORNALAMADA KESME KUVVETLERİNİN VE TAKIM UCU SICAKLIĞININ BULANIK MANTIK VE YAPAY SİNİR AĞI TEKNİKLERİYLE TAHMİN EDİLMESİ

İlker Ali ÖZKAN

Selçuk Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Sistemleri Eğitimi Ana Bilim Dalı

Danışman: Prof. Dr. Süleyman YALDIZ

2006, 105 sayfa

Jüri:Prof. Dr. Süleyman YALDIZ
Prof. Dr. Novruz ALLAHVERDİ
Doç. Dr. Hacı SAĞLAM

Bu tezde tornalamada değişik kesme şartlarında elde edilen kesme kuvvetleri ve sıcaklık deney sonuçlarının Bulanık Mantık, Yapay Sinir Ağı ve Bulanık Sinir Ağından oluşan yapay zeka teknikleriyle modellenmesi amaçlanmıştır. Bunun için Bulanık Mantık, Yapay Sinir Ağı, Bulanık Sinir Ağı gibi yapay zeka tekniklerinin çıkarım, öğrenme sistemleri ve yapıları incelenmiştir. Daha sonra eldeki deney sonuçları üç yapay zeka tekniği de kullanılarak modellenmiştir. Test verileri üzerinde yapılan istatistiksel incelemelerle deney verilerini en iyi modelleyebilen yapay zeka tekniği ve diğer modelleme teknikleri arasında ki farklar araştırılmıştır.

Anahtar Kelimeler: Bulanık Mantık, Yapay Sinir Ağı, Bulanık Sinir Ağı, Modelleme

ABSTRACT

Master Thesis

PREDICTING OF CUTTING FORCES AND TOOL TIP TEMPERATURE IN TURNING USING FUZZY LOGIC AND ARTIFITICAL NEURAL NETWORK TECHNIQUES

İlker Ali ÖZKAN

Selçuk University
Graduate School of Natural and Applied Sciences
Computer Systems Education Department

Supervisor: Prof. Dr. Süleyman YALDIZ

2006, 105 pages

Jury: Prof. Dr. Süleyman YALDIZ
Prof.Dr. Novruz ALLAHVERDİ
Doç.Dr. Hacı SAĞLAM

In this thesis, It's aimed to model cutting forces obtained from different cutting conditions in turning and heating experiment results by artificial intelligent techniques that consist of Fuzzy Logic, Neural Network and Fuzzy Neural Network. Inference, learning system and structures of the artificial intelligence techniques such as fuzzy logic, neural network and fuzzy neural network were investigated. Later on, existing experiment results were modelled by three artificial intelligence techniques. Which of the artificial intelligence technique can model experiment data as best and the differences between techniques in modelling were investigated by statistical research on test data.

Keywords: Fuzzy Logic, Artificial Neural Network, Fuzzy Neural Networks, Modelling

ÖNSÖZ

Bu tez altı bölümden oluşmaktadır. Birinci bölümde, yapay zeka ve yapılan çalışma hakkında kısa bilgi verilmiştir. İkinci bölümde, genel olarak Bulanık Mantık kavramı üzerinde durulmuş, bulanık sistemlerde bulanıklaştırma, çıkarım ve durulaştırma üniteleri hakkında açıklamalar yapılmıştır. Üçüncü bölümde Yapay Sinir Ağları, sınıflandırmaları ve öğrenme algoritmaları anlatılmıştır. Dördüncü bölümde Bulanık Sinir Ağı ve bir Bulanık Sinir Ağı uygulaması olan ANFIS hakkında bilgi verilmiştir. Beşinci bölümde tornalamada kesme kuvvetleri ve sıcaklığın Bulanık Mantık, Yapay Sinir Ağı ve Bulanık Sinir Ağı modellemeleri oluşturulup istatistiksel olarak deney sonuçları ile karşılaştırılmıştır. Ve altıncı bölümde ise sonuç ve öneriler sunulmuştur.

Bu çalışma, S.Ü. Teknik Eğitim Fakültesi, Bilgisayar Sistemleri Eğitimi Ana Bilim Dalında, Prof. Dr. Süleyman YALDIZ'ın yönetiminde yürütülmüş ve Selçuk Üniversitesi, Fen Bilimleri Enstitüsüne yüksek lisans tezi olarak sunulmuştur.

Tezin hazırlanmasında yardımlarını esirgemeyen sayın hocam Prof. Dr. Süleyman YALDIZ'a saygı ve şükranlarımı sunarım. Ayrıca çalışma sonuçlarının istatistiksel değerlendirilmesinde yardımlarından dolayı Arş.Gör. Murat KÖKLÜ'ye teşekkür ederim.

İÇİNDEKİLER

ÖZET iii
ABSTRACT iv
İÇİNDEKİLER vi
SEKİLLER LİSTESİ vii
TABLOLAR LİSTESİ ix
1. GİRİŞ 1
2. BULANIK MANTIK 3
2.1. Bulanık Küme 5
2.2. Üyelik Fonksiyonu 7
2.2.1. Üyelik fonksiyonu tipleri 9
2.3. Bulanık Kural ve Gösterimi 12
2.3.1. Bulanık kuralın gösterimi 12
2.3.2. Yaklaşık akıl yürütme kuramı 13
2.3.3. Genelleştirilmiş modus ponens 14
2.3.4. Genelleştirilmiş modus tollens 14
2.4. Bulanık Sistemler 14
2.4.1. Bulanıklaştırma ünitesi 16
2.4.2. Çıkarım ünitesi 21
2.4.3. Durulama ünitesi 27
3. YAPAY SİNİR AĞLARI 32
3.2. Aktivasyon Fonksiyonları 34
3.3. Yapay Sinir Ağı Hücresi 36
3.4. YSA ile Hesaplamanın Özellikleri 38
3.5. Yapay Sinir Ağlarının Sınıflandırılması 40
3.5.1. YSA'ların yapılarına göre sınıflandırılması 40
3.5.2. YSA'ların öğrenme algoritmalarına göre sınıflandırılması 42
3.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları 44
3.6.1. Geri yayılım öğrenme algoritması 45
4. BULANIK SİNİR AĞI 49
4.1. ANFIS (Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi) Mimarisi 51
4.2. ANFIS Ağında Kullanılan Hibrid Öğrenme Algoritması 54
4.3. ANFIS Ağında Kullanılan Geri Yayılımlı Öğrenme Algoritması 57
5. TORNALAMADA KESME KUVVETLERİ VE SICAKLIĞIN YAPAY ZEKA TEKNİKLERİYLE TAHMİN EDİLMESİ 62
5.1. Bulanık Uzman Sistem (BUS) ile Tahmin Etme 62
5.1.1. Bulanıklaştırma 63
5.1.2. Bulanık kurallar 70
5.1.3. Çıkarım mekanizması 72
5.1.4. Durulaştırma 72
5.2. Yapay Sinir Ağı ile Tahmin Etme 78
5.3. Bulanık Sinir Ağı (ANFIS) ile Tahmin Etme 94
6. SONUÇ ve ÖNERİLER 102
KAYNAKLAR 104

SEKİLLER LİSTESİ

Şekil 2.1 A bulanık kümesi için üyelik fonksiyonu.....7
Şekil 2.2 Sıcak, normal ve soğuk dilsel ifadelerinin üyelik fonksiyonu.....8
Şekil 2.3 Aralık değerli üyelik fonksiyonu 8
Şekil 2.4 Üçgen üyelik fonksiyonu.....9
Şekil 2.5 Yamuk üyelik fonksiyonu 10
Şekil 2.7 Çan şekilli üyelik fonksiyonu 11
Şekil 2.8 Sigmodial üyelik fonksiyonu.....12
Şekil 2.9 Bulanık sistemin yapısı 16
Şekil 2.10 Algılayıcı okuyucu x_0 ile üyelik fonksiyonu $\mu(x)$'in $\mu(x_0)$' a gelmesi a) Keskin algılayıcı okuyucu b) Bulanık algılayıcı okuyucu 17
Şekil 2.11 Mamdani yöntemi ile çıkarım (Baykal 2004).....23
Şekil 2.12 Larsen yöntemi ile çıkarım (Baykal 2004) 24
Şekil 2.13 Tsukamoto yöntemi ile çıkarım (Baykal 2004) 26
Şekil 2.14 TSK yöntemi ile çıkarım (Baykal 2004) 27
Şekil 2.15 Üyelik fonksiyonlarının max noktaları ile durulama işlemi.....28
Şekil 2.16 Merkez yöntemi ile durulaştırma işlemi.....29
Şekil 2.17 Ağırlıklı ortalama yöntemi ile durulama işlemi.....29
Şekil 2.18 Max noktaların ortalaması yöntemiyle durulama işlemi.....30
Şekil 2.19 En büyük alan merkezi ile durulaştırma.....31
Şekil 3.1 Biyolojik sinir sisteminin blok gösterimi 33
Şekil 3.2Biyolojik hücrenin bilgi alışverişi (Öztemel 2003) 34
Şekil 3.3 YSA'larda en çok tercih edilen aktivasyon fonksiyonları a) sigmoid, b) doğrusal c) hiperbolik tanjant ve d) keskin sınırlayıcı.....36
Şekil 3.4 Yapay sinir hücresinin yapısı.....38
Şekil 3.5 İleri Beslemeli ağlar için blok diyagramı 41
Şekil 3.6 Geri beslemeli ağ için blok diyagram 41
Şekil 3.7 Danışmanlı öğrenme yapısı. 42
Şekil 3.8 Danışmansız öğrenme yapısı. 43
Şekil 3.9 Takviyeli öğrenme yapısı. 44
Şekil 3.10 İleri beslemeli çok katmanlı sinir ağı (Efe 2000).....46
Şekil 4.1 Sinirsel- Bulanık sistemlerin sinir ağları ve bulanık mantıkla ilişkisi 49
Şekil 4.2 (a) Birinci dereceden iki girişli ve iki kurallı "Sugeno Bulanık Modeli" ; (b) Eşdeğer ANFIS yapısı. 54
Şekil 4.3 Sinirsel bulanık sistemin akış şeması (a) Adaptif bir ağ yapısı, (b) Hatanın iletimi ve ağın eğitimi 56
Şekil 5.1 Geliştirilen Bulanık Uzman Sistemin Genel Şeması 62
Şekil 5.2 Talaş açısının üyelik fonksiyon grafiği 65
Şekil 5.3 Yaklaşma açısı üyelik fonksiyon grafiği.....66
Şekil 5.4 Kesme hızı üyelik fonksiyon grafiği.....67
Şekil 5.5 F_t kuvveti üyelik fonksiyon grafiği.....67
Şekil 5.6 F_f kuvveti üyelik fonksiyon grafiği.....68
Şekil 5.7 F_λ kuvveti üyelik fonksiyon grafiği 69
Şekil 5.8 T sıcaklık değeri üyelik fonksiyon grafiği.....69
Şekil 5.9 Ağırlık merkezli durulaştırıcı ile BUS sonuçları 73

Şekil 5.10 Ağırlık merkezli durulaştırıcı ile BUS sonuçları 74
Şekil 5.11 Deney ve BUS Sıcaklık Kolerasyon grafiği 77
Şekil 5.12 Tansig transfer fonksiyonu 79
Şekil 5.13 Yapay Sinir Ağının mimarisi 79
Şekil 5.14 MSE performans grafiği 81
Şekil 5.15 YSA'nın geri yayılım ağı test aşaması sonucu elde edilen çıkış ile istenilen çıkış arasındaki ilişki (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) ilerleme kuvveti, (d) sıcaklık 83
Şekil 5.16 YSA test aşaması sonucu elde edilen ve istenilen çıkış arasındaki hata değeri (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) İlerleme kuvveti, (d) Sıcaklık 86
Şekil 5.17 Levenberg-Marquardt metodu için MSE performans grafiği 88
Şekil 5.18 YSA'nın eğitimi sonucu elde edilen test çıkış ile istenilen çıkış arasındaki ilişki (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) ilerleme kuvveti, (d) sıcaklık 90
Şekil 5.19 YSA test aşaması sonucu elde edilen test çıkış ve istenen değer arasındaki hata değeri (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) İlerleme kuvveti, (d) Sıcaklık 93
Şekil 5.20 Tornalamada değişik kesme şartlarında ölçülen kesme kuvvetlerinin ve sıcaklığın modellenmesi için geliştirilen ANFIS yapısı 95
Şekil 5.21 Sistem girişlerinin üyelik fonksiyon grafikleri 96
Şekil 5.22 Eğitim verisi ile ANFIS eğitim çıkışının karşılaştırılması 97
Şekil 5.23 Test verisi ile ANFIS test çıkışlarının karşılaştırılması 97

TABLOLAR LİSTESİ

Tablo 3.1 Sinir sistemi ile YSA'nın benzerlikleri. 34
Tablo 4.1 Bulanık sistemler ve sinir ağlarının özellikleri (Baykal 2004). 50
Tablo 4.2 Sinirsel-bulanık sistem yapısındaki parametreler ve işaretler 56
Tablo 5.1 Geliştirilen BUS için oluşturulan kurallar 70
Tablo 5.2 Geliştirilen BUS ile deney verilerinin karşılaştırılması 74
Tablo 5.3 Bulanık Uzman Sistem için T-testi sonuçları 77
Tablo 5.4 Test verileri için Bulanık Uzman Sistem T-testi sonuçları 78
Tablo 5.5 Geri yayılımlı yapay sinir ağında farklı nöron ve katman sayılarında MSE hata ve test çıkışları için kolerasyon değerleri 86
Tablo 5.6 Tek katmanlı 9 nörona sahip geri yayılım ağı için T-testi sonuçları 87
Tablo 5.7 Levenberg-Marquardt metodlu geri yayılım ağı için T-testi sonuçları 93
Tablo 5.8 Sistem girişleri için üçgen üyelik fonksiyonların aralıkları 95
Tablo 5.9 3 dilsel ifadeli ANFIS eğitimi sonrasında Tegetsel Kesme Kuvveti girişi için üyelik fonksiyonların yeni aralık değerleri 98
Tablo 5.10 3 dilsel ifadeli ANFIS'in eğitimi sonucunda sistem çıkışlarının RMSE hata ve test çıkışlarının korelasyon oranları 98
Tablo 5.11 3 dilsel ifadeli ANFIS metodu elde edilen değerler ile gerçek çıkışlar arasında ki T-testi sonuçları 99
Tablo 5.12 4 dilsel ifadeye ayrılmış ANFIS eğitimi sonucunda sistem çıkışlarının RMSE hata ve test çıkışlarının korelasyon oranları 100
Tablo 5.13 4 dilsel ifadeli ANFIS metodu elde edilen test değerleri ile gerçek çıkışlar arasında ki t-testi sonuçları 100

1. GİRİŞ

20. yüzyılın ikinci yarısında temelleri atılan ve günümüzde büyük bir kitlenin üzerinde çalıştığı yapay zeka tekniği, pek çok problemin analizinde başarı ile kullanılmış ve klasik programlamaya alternatif olmuştur. Başlangıçta çok farklı amaçlar (Tıp alanında hastalık teşhisi; uydu fotoğraflarının okunması ve belirlenmesi, strateji belirleme gibi askeri amaçlı uygulamalarda, kontrol problemlerinde, endüstriyel uygulamalarda) için geliştirilen bu teknik günümüzde hemen her disiplinde kullanılır olmuştur. Yapay zeka olarak bilinen ve yapay sinir ağları; bulanık küme teorisi, genetik algoritmalar, uzman sistemler gibi çeşitli dalları olan mantıksal programlama tekniği geçen birkaç yıl içinde hemen her disiplinde yaygın olarak kullanılmaya başlanmıştır. Geçen zaman içinde yapay sinir ağları ve diğer mantıksal programlama tekniklerinin ispatlanmış teorilerinin ortaya çıkartılması nedeniyle konu pek çok teorisyenin ilgisini çekmiştir (Civalek 2004).

Bulanık sistemler ve Yapay Sinir Ağları sahip oldukları avantajlardan dolayı değişik bilimsel ve mühendislik uygulamalarında giderek daha cazip bir hale gelmişlerdir. Bunun temel sebebi, geleneksel çözüm yollarına kıyasla belirli bir kesin olmama toleransına sahip olmaları ve parçalı doğrular ile çalışabilme yetenekleridir. Günümüzdeki uygulama alanları; tüketici ürünleri ve endüstriyel uygulamalardan medikal cihazlara, haberleşme sistemlerinden karar verme analizlerine kadar çok geniş bir yelpaze oluşturmaktadır.

Bulanık Mantık, denetim ve bilgi süreçlerinin birçoğu için güçlü bir problem çözme yöntemidir ve kesin olmayan bulanık bilgiden dikkate alınacak kadar basit bir şekilde kesin sonuçlar elde edilmesine olanak sağlar (Zadeh 1965). Yapay Sinir Ağlarının en önemli özelliği öğrenebilme yeteneğidir. Bulanık Mantık ve Yapay Sinir Ağlarının birbirlerini tamamlayıcı özelliklerinden faydalanarak birçok uygulama gerçekleştirilmiştir (Wang 1993, Chen ve Chen 1994, Buja ve Todesco 1994).

Son yıllarda Yapay Sinir Ağları (YSA), Bulanık Mantık (BM) ve YSA ile BM' nin üstün özelliklerinin birleştirilmesi amacıyla elde edilen Bulanık Sinir Ağları (BSA) doğrusal olmayan, belirsiz ya da yarı belirgin sistemlerde yoğun şekilde

kullanılmaya başlanmıştır. Doğrusal olmayan yapılarıyla YSA, doğrusal olmayan fonksiyonları belirli bir eğitim sürecinden sonra öğrenme ve genelleme yeteneklerine sahiptir ve bu nedenle YSA doğrusal olmayan sistemlerin uyarlanır ve dayanıklı denetiminde kullanılmaktadır (Narendra 1997).

Yapılan tez çalışmasında tornalamada farklı talaş açısı, yaklaşma açısı ve kesme hızı değerlerinde oluşan teğetsel kesme kuvveti, radyal kuvveti, ilerleme kuvveti ve takım ucu sıcaklığının (Yaldız ve ark. 2005) yapay zeka teknikleriyle modellenmesi incelenmiştir.

Tornalamada değişik kesme şartlarında elde edilen bu kuvvet ve takım ucu sıcaklığı verilerinin istatistiksel metotlarla modellenmesi mümkündür. Fakat modellenecek sistemin giriş ve çıkış sayısının fazla olması, talaş kaldırmayı etkileyen verilerin nonlineer karakter göstermesi ve giriş verilerinin birbirleri ile etkileşiminin de çıkışa etki etmesinden dolayı çıkış verilerini oluşturmak için bir matematiksel metot geliştirmek zordur. Bu sebeple 64 adet değişik kesme şartında elde edilen kuvvet ve takım ucu sıcaklığı verilerinin Bulanık Mantık, Yapay Sinir Ağı ve Bulanık Sinir Ağı yapay zeka teknikleriyle modellemeleri incelenmiştir. Farklı yapay zeka teknikleriyle ele alınan sistem istatistiksel metotlar kullanılarak gerçek çıkışlar ile karşılaştırılıp en uygun modelleme bulunmaya çalışılmıştır. Yapay zeka teknikleriyle modelleme geliştirilirken MATLAB programı kullanılmıştır.

2. BULANIK MANTIK

Bulanık mantık her gün kullandığımız ve davranışlarımızı yorumladığımız yapıya ulaşmamızı sağlayan matematiksel bir disiplindir. Temelini doğru ve yanlış değerlerin belirlendiği Bulanık Küme Kuramı (Fuzzy Set Theory) oluşturur. Burada yine geleneksel mantıkta olduğu gibi (1) ve (0) değerleri vardır. Ancak bulanık mantık yalnızca bu değerlerle yetinmeyip bunların ara değerlerini de kullanarak; örneğin bir uzaklığın yalnızca yakın ya da uzak olduğunu belirtmekle kalmayıp ne kadar yakın ya da ne kadar uzak olduğunu da söyler.

Bulanık mantık iki anlamda kullanılmaktadır. Dar anlamda bulanık mantık, klasik iki değerli mantığın genelleştirilmiş halidir. Geniş anlamda ise bulanık kümeleri kullanan bütün teorileri ve teknolojileri ifade eder.

Sembolik mantık kuralları ile sadece somut değil, soyut düşüncelere dayalı önermeler de yapılarak genel çıkarımları elde edilmesi mümkündür. Ancak bunu yaparken kavram ve terimlerdeki belirsizlik ve bulanıklıkların işin başında durulaştırılarak kesinlik kazandırılması gerekir. Bundan dolayı, sembolik mantık idealleştirilmiş kavram ve terimlerle önermeden çıkarılacak ideal sonuçları verir. Oysa gerçek dünyada bulanıklık ve belirsizlik kaçınılmazdır.

İsminin insanlarda çağrıştırdığının aksine bulanık mantık ne belirsiz ifadeler ile yapılan belirsiz işlemlerdir ne de gelişmiş bir olasılık hesaplama yöntemidir. Aslında, modelleme aşamasında değişkenler ve kuralların esnek belirlenmesi halidir. Nasıl bir lastik, içinde bulunduğu duruma göre şeklini değiştirirken bütünlüğünü ve yapısını koruyabiliyorsa, bir bulanık mantık modeli de değişen koşullara cevaplar verirken özündeki yapıyı muhafaza eder.

Bulanık mantığın ardındaki temel fikir, bir önermenin doğruluğunun, önermelerle, kesin yanlış ve kesin doğru arasındaki sonsuz sayıdaki doğruluk değerlerini içeren bir kümedeki değerler, ya da sayısal olarak [0,1] gerçel sayı ilişkilendirilen bir fonksiyon olarak kabulüdür. Bu, Zadeh'in bulanık kümeler üzerindeki ilk çalışmasının bir sonucudur. Bulanık mantık yaklaşık akıl yürütmenin mantığıdır. Sözel olarak değişik sıfat dereceleri ile ifade edilen (ya da sayısal olarak [0,1] gerçel sayı aralığında yer alan) doğruluk değerine sahip oluşu –ki bu belirsizlik

içeren doğruluk tablolarını da beraberinde getirir-, ve geçerliliği kesin değil, fakat yaklaşık olan çıkarım kurallarına sahip oluşu ayırt edici özelliklerdendir.

Bulanık mantığın en çok geçerli olduğu iki durumdan ilki, incelenen olayın çok karmaşık olması ve bununla ilgili yeterli bilginin bulunamaması durumunda kişilerin görüş ve değer yargılarına yer verilmesi, ikincisi ise insan kavrayış ve yargısına gerek duyulan hallerdir. İnsan düşüncesinde sayısal olmasa bile belirsizlik, yararlı bir bilgi kaynağıdır.

Olayın bulanık mantıkla incelenmesi için öncelikle, yapılacak çıkarımların belirli tolerans sınırları içinde kalmasına önceden karar vermek gerekir. Bir sorunun çözülmesine başlamadan önce toplanabilen sayısal ve sözel veriler göz önünde bulundurularak çözüm için en uygun yöntem hakkında karar verilmelidir. Bulanık mantık sözel verilerin işlenmesinde de etkindir. Bu cins bilgiler bilgisayara tanıtılarak bulanık işlemler yapılması temin edilebilir.

Bilgi tabanlı sistemler (Knowledge Based Systems) günümüz karmaşık sistemlerinin denetlenmesinde de önemlerini arttırmışlardır. Matematiksel modellerin çıkartılmasını gerektirmeyen bilgi tabanlı sistemler bu özellikleri sebebiyle tıp,denetim ve ekonomi gibi birçok alanda kullanılmaya başlanmıştır. Bulanık mantık ise sayısal değerlerin sözel ifadelerinden yola çıkarak bilgi tabanlı denetleyiciler arasında insan düşünce yapısına yakınlaşmayı sağlamıştır. Bu tür sistemler tek başına kullanıldıkları gibi diğer modern veya klasik sistemlerle de kullanılabilmektedir.

Bulanık mantığın genel özellikleri aşağıdaki gibidir (Zadeh 1965).

1. Bulanık mantıkta kesin nedenlere dayalı düşünme yerine yaklaşık değerlere dayanan düşünme kullanılır
2. Bulanık Mantıkta her şey [0,1] aralığında bir sayı ile gösterilir.
3. Bulanık mantıkta bilgi büyük, küçük, çok, az gibi sözel ifadeler şeklindedir.
4. Bulanık çıkarım işlemi sözel ifadeler arasında tanımlanan kurallar ile yapılır.
5. Her mantıksal sistem bulanık olarak ifade edilebilir.
6. Bulanık mantık matematiksel modeli çok zor elde edilen sistemler için çok uygundur.

Bulanık mantığın uygulama alanları kontrol sistemlerinin de ötesine uzanmaktadır. Geliştirilen son teoremler bulanık mantığı ilke olarak, ister mühendislik, ister fizik, ister biyoloji ya da ekonomi olsun, her türlü konuda sürekli

sistemleri modellemek üzere kullanılabileceğini göstermektedir. Çoğu alanda bulanık mantık sağduyu modellerinin standart matematik modellerinden daha yararlı ya da kesin sonuçlar verdiği görülmektedir (Baykal 2004).

Bulanık Mantığın Avantajları :

- İnsan düşünce tarzına yakın olması
- Uygulanışının matematiksel modele ihtiyaç duymaması
- Yazılımının basit olması dolayısıyla ucuza mal olması
- Eksik tanımlı problemlerin çözümüne uygun olması
- Uygulanması kolaylığı

Bulanık Mantığın Dezavantajları :

- Uygulamada kullanılan kuralların oluşturulmasının uzmana bağlılığı
- Üyelik fonksiyonlarının deneme-yanılma yolu ile bulunmasından dolayı uzun zaman alabilmesi
- Kararlılık analizinin yapılışının zorluğu
- Bulanık mantık sistemleri öğrenilemez ya da öğretilemez

2.1. Bulanık Küme

Geleneksel küme teorisinde kullanılan küme kavramı bir nesnenin bir kümenin elemanı olması "1" yada olmaması "0" gibi iki seçenekli bir mantığa dayanmaktadır (Tong 1977). Geleneksel küme teorisinde bu ikisinin arası yoktur. Belirsizlik içeren bir problemin çözümü güçtür.

Klasik küme kuramında, bir X kümesindeki A alt kümesi kendisine ait karakteristik fonksiyonu olan μ_A ile ifade edilir.

$$\mu_A(x) = \begin{cases} 1 \;\; Eger \;\; x \in A \\ 0 \;\; Eger \;\; x \notin A \end{cases} \qquad (2.1)$$

Karakteristik fonksiyon X'in elemanlarını $\{0,1\}$ kümesine dönüştürür. Bu dönüşüm X'in her elemanı için bir sıralı ikili kümesiyle ifade edilebilir. Sıfır değeri ait olmamayı temsil ederken bir değeri ise aitliği gösterir.

$$\mu_A : X \longrightarrow \{0,1\} \qquad (2.2)$$

"x, A nın içindedir."

şeklindeki bir önermenin doğruluğu (x, $\mu_A(x)$) sıralı ikilisiyle belirlenir. Eğer sıralı ikilinin ikinci elemanı 1 ise önerme doğru, eğer bu değer 0 ise önerme yanlıştır.

Bulanık küme kavramında küme kuramı olan bulanık küme kuramında, kümedeki her bir birey, klasik çift değerli küme kuramlarında olduğu gibi üye ya da üye değil olarak değil bir dereceye kadar üye olarak görülmektedir. Bulanık küme de değişik üyelik derecesinde öğelere sahip olan bir fonksiyondur.

Bu teoride nesnelerin bir kümeye ne kadar ait olduğu derecelendirilmiştir. Öğeler bulanık kümeye kısmi derecede aittir. Klasik kümelerdeki karakteristik fonksiyon, $\mu_A:E\rightarrow\{0,1\}$, bulanık kümelerde yerini ,$\mu_A:E\rightarrow[0,1]$ olarak gösterilen üyelik fonksiyonuna bırakır.

Genel olarak küme üyelerinin değerleri ile değişiklik gösteren eğriye üyelik fonksiyonu denir. x ekseni üyeleri gösterirken, y ekseni üyelik derecelerini gösterir. A bulanık küme, $\mu_A(x)$ de üyelik derecesi olmak üzere $A=\{\mu_A(x),\ x)\}$ olarak yazılabilir.

$A=\{\mu_A(x), x)\}=\{\mu_A(x)/x)\}=\{\mu_A(x_1), x_1+\mu_A(x_2), x_2+\ldots.+\mu_A(x_n), x_n\}$ ve bu da

$A=\{\Sigma\mu_A(x_i),\ x_i\}$ olarak gösterilebilir. Bulanık kümenin sürekli olması durumunda gösterim

$A=\{S\mu_A(x_i), x_i\}$ şeklinde gösterilir. Örnek

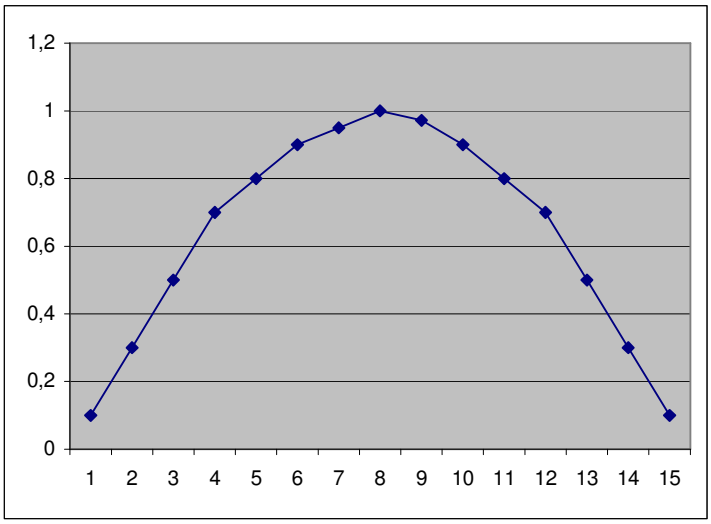
A=0.1/1+0.3/2+0.5/3+0.7/4+0.8/5+0.9/6+0.95/7+1.0/8+0.97/9+0.9/10+0.8/11+0.7/12+0.5/13+0.3/14+0.1/15

A bir bulanık kümedir. Bu bulanık kümenin klasik gösterimi;

$A=\{1,2,3,4,5,6,7,8,9,10,11,12,13,14,15\}$

ve ya

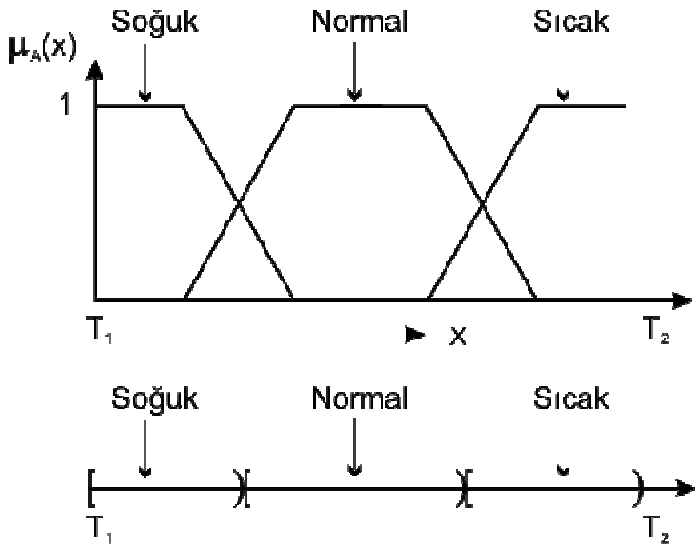
A=1/1+1/2+1/3+1/4+1/5+1/6+1/7+1/8+1/9+1/10+1/11+1/12+1/13+1/14+1/15



Şekil 2.1 A bulanık kümesi için üyelik fonksiyonu

2.2. Üyelik Fonksiyonu

[*T1, T2*] aralığında sıcaklığın sunumu bulanık ve klasik kümeler kullanılarak Şekil 2.2'de gösterilmiştir. İlk durumda [*T1*, *T2*]→[0, 1] üyelik fonksiyonları "soğuk", "normal", "sıcak" dilsel değerler olarak tanımlanıyor. İkinci durumda ise aralıklar klasik küme tarafından değişkenleri tanımlamada kullanılmaktadır.



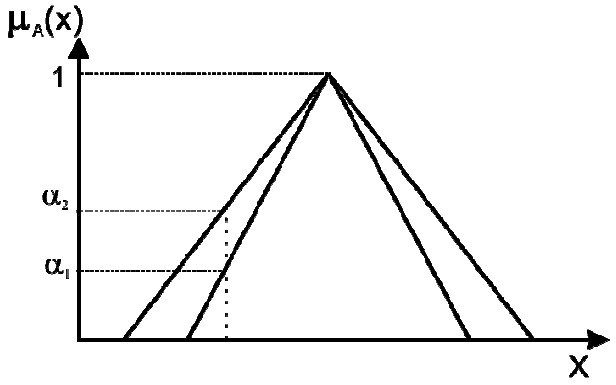
Şekil 2.2 Sıcak, normal ve soğuk dilsel ifadelerinin üyelik fonksiyonu

Eğer *A* bulanık kümesinin üyelik derecesi her bir *X* değerine karşılık gerçek sayı aralığına karşılık geliyorsa bu tür bulanık kümelere aralık-değerli bulanık kümeler denir.

$\mu_A: X \rightarrow \varepsilon[0,1]$

$$a=\mu_A(x_1^{\alpha 1}, x_1^{\alpha 2})/x_1+\ldots\ldots+\mu_A(x_n^{\alpha 1}, x_n^{\alpha 2})/x_n \quad (2.3)$$

Aralık değerli *A* Bulanık kümesinin üyelik fonksiyonu Şekil 2.3 de ki gibidir.

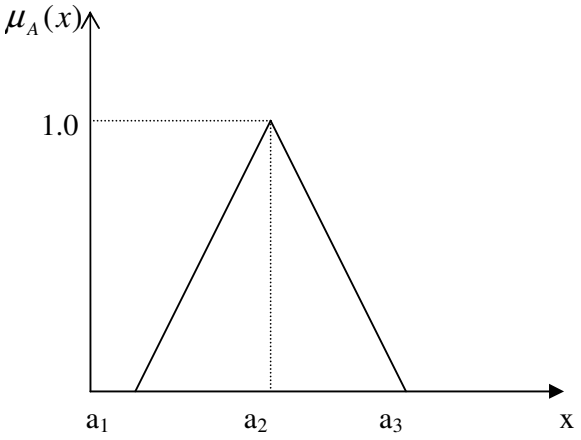


Şekil 2.3 Aralık değerli üyelik fonksiyonu

2.2.1. Üyelik fonksiyonu tipleri

Üçgen üyelik fonksiyonu; bir üçgen üyelik fonksiyonu a_1, a_2 ve a_3 olarak üç parametre ile tanımlanır (Nguyen 2003).

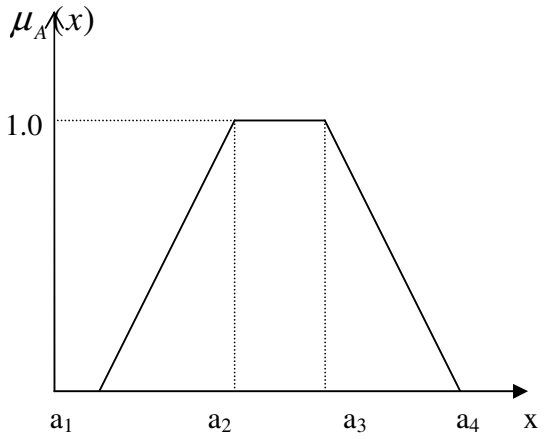
$$\mu_A(x;a_1,a_2,a_3)=\begin{cases} a_1 \le x \le a_2 \quad ise \quad (x-a_1)/(a_2-a_1) \\ a_2 \le x \le a_3 \quad ise \quad (a_3-x\ )/(a_3-a_2) \\ x > a_3 \quad veya \quad x < a_1 \quad ise\ 0 \end{cases} \tag{2.4}$$



Şekil 2.4 Üçgen üyelik fonksiyonu

Yamuk üyelik fonksiyonu; bir yamuk üyelik fonksiyonu üçgen üyelik fonksiyonunun özel bir durumu olup, a_1, a_2, a_3, a_4 olarak dört parametre ile tanımlanır.

$$\mu_A(x;a_1,a_2,a_3,a_4)=\begin{cases} a_1 \le x \le a_2 \quad ise \quad (x-a_1)/(a_2-a_1) \\ a_2 \le x \le a_3 \quad ise \quad 1 \\ a_3 \le x \le a_4 \quad ise \quad (a_4-x)/(a_4-a_3) \\ x > a_4 \quad veya \quad x < a_1 \quad ise\ 0 \end{cases} \tag{2.5}$$

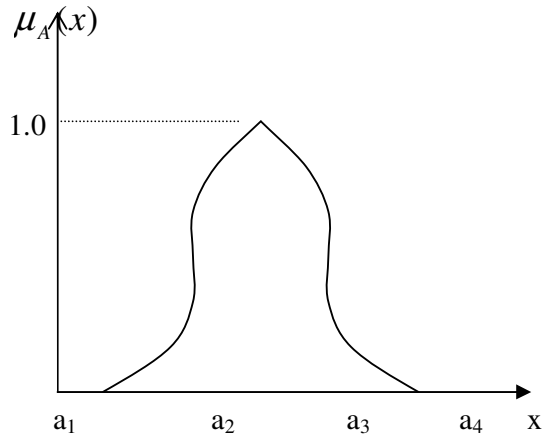


Şekil 2.5 Yamuk üyelik fonksiyonu

Gaussian üyelik fonksiyonu; bu tip bir üyelik fonksiyonu *m* ve *σ* ile tanılanır.

$$\mu_A(x;m,\sigma) = \exp\left\{\frac{-(x-m)^2}{2\sigma^2}\right. \tag{2.6}$$

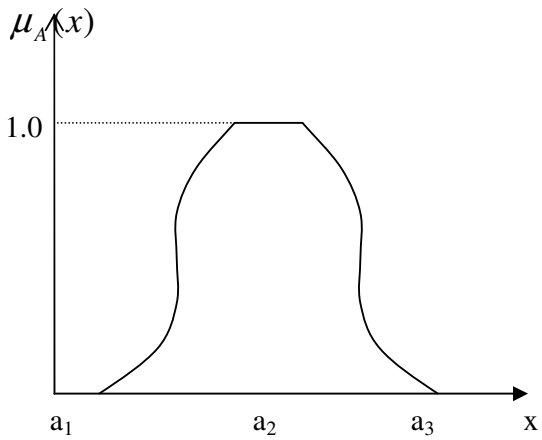
Fonksiyonda *m* fonksiyon merkezini, *σ* genişliği ifade eder. *σ* değerinin değişimi ile fonksiyon biçimi değiştirilebilir (Nguyen 2003)..



Şekil 2.6 Gaussian üyelik fonksiyonu

Çan Şekilli üyelik fonksiyonu; bu tip bir üyelik fonksiyonu a_1, a_2 ve a_3 olarak üç parametre ile tanımlanır (Nguyen 2003).

$$\mu_A(x;a_1,a_2,a_3)=\left\{\frac{1}{1+\left|\frac{x-a_3}{a_1}\right|^{a_2}}\right\} \tag{2.7}$$

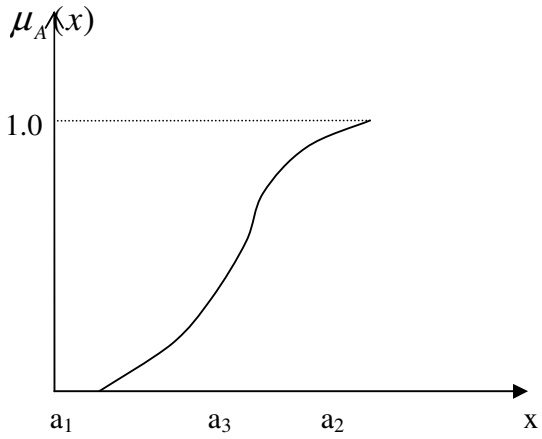


Şekil 2.7 Çan şekilli üyelik fonksiyonu

Sigmodial üyelik fonksiyonu; bu tip bir üyelik fonksiyonu a_1 ve a_2 parametreleri ile tanımlanır (Nguyen 2003).

$$\mu_A(x;a_1,a_2)=\left\{\frac{1}{1+e^{-a_1(x-a_2)}}\right\} \tag{2.8}$$

a_3 değeri sigmodial fonksiyonunda üye olma ile olmamama arasındaki kırım noktası olup değeri 0.5 olup Şekil 2.8 de gösterilmektedir.



Şekil 2.8 Sigmodial üyelik fonksiyonu

2.3. Bulanık Kural ve Gösterimi

Genel olarak çıkarım eldeki bilgileri kullanarak yeni bilgi elde etme olarak tanımlanabilir. Çıkarımda bilginin sunum ve gösterim şekli önemlidir. Sunum yöntemleri içinde *"eğer-o halde"* kural tipi en sık kullanılan sunum tipidir. Kural tipi sunum, içerme olarak yorumlanır ve öncül (eğer) ve soncul (o halde) kısımları içerir.
Örnekler;
Eğer basınç yüksek ise, o halde hacim küçüktür.
Eğer hız yüksek ise, o halde biraz fren yap.

2.3.1. Bulanık kuralın gösterimi

"Eğer *x A* ise , o halde *y B′* dir" şeklinde bulanık bir kural olsun. Bulanık kural öncül ve sonculda bulanık yüklemler içerebilir ve şu şekilde yazılır.

Eğer *x A*(*x*) ise , o halde *y B*(*y*) dir.

Bu kural *R*(*x*, *y*) bağıntısı aracılığı ile gösterilir.

$R(x, y)$: Eğer $A(x)$ ise $B(y)$ veya

$R(x, y)$: $A(x)$--> $B(y)$

Kuralda x A'dır parçasına öncül, y B'dir parçasına soncul denir. Genel olarak öncül ve soncul sözel değişkenler olarak temsil edilirler. Bilgi tabanlı bir sistemde bilgi tabanı genel olarak *"eğer-o halde"* kuralları ile sunulur. Gerçekte bulanık bir kural bulanık bir bağıntıdır. Çeşitli bulanık kuralları içeren bir bilgi tabanı da bağıntılarına göre bütünleştirilmiş bireysel kurallarla şekillendirilmiş bir bağıntıdır.

2.3.2. Yaklaşık akıl yürütme kuramı

1979 da Zadeh yaklaşık akıl yürütme kuramına giriş yapmıştır. Bu teori belirsizlik ve bulanıklık karşısında akıl yürütme için güçlü bir yapı sağlamıştır. Bu kuramın merkezinde önermelerin temsilinde değişken değerleri olarak bulanık kümelerin atanmış ifadelerinin sunumu yer alır.

$x \in X$ ve $y \in Y$ olmak üzere iki etkileşimli değişken ve bunlar arasında tam olarak nedensel bir bağıntı olduğunu kabul edelim. Bu durumda y=f(x) yazılabilir.

Öncül : y=f(x)

Olgu : x=x'

Sonuç : y=f(x')

Bu çıkarı kuralı $\forall x \in X$ için y=f(x) olduğunda x=x' ise y'nin f(x') değerini alacağını verir.

R_1 : Eğer x=x_1 ise o halde y=y_1

R_2 : Eğer x=x_2 ise o halde y=y_2

.....

R_n : Eğer x=x_n ise o halde y=y_n

Olgu : x=x'

Sonuç: y=y'

Yukarıdaki akıl yürütmede, olguların (x') kurallardaki öncüllerle (x_1, x_2...) aynı olmadığını, sonuçların (y') soncullardan (y_1, y_2...) farklı olabileceği görülür.

Bundan dolayı burada yapılabilecek tipteki çıkarıma yaklaşık akıl yürütme veya bulanık çıkarım denir.

2.3.3. Genelleştirilmiş modus ponens

Bulanık kümeleri içeren bir kural var ise, genelleştirilmiş modus ponens veya genelleştirilmiş modus tollens olarak iki tip akıl yürütme kullanılabilir.

Bulanık mantıkta ve yaklaşık akıl yürütmede en önemli bulanık içerme çıkarım kuralı genelleştirilmiş modus ponenstir (Çobanoğlu 2006).

olgu : x A' dır. :R(x)

Kural : Eğer x A ise, o halde y B'dir. :$R(x, y)$

Sonuç : y B'dir. : R(y) = R(x)oR(x, y)

B' çıkarımı olgunun bileşkesi olarak belirlenir ve bulanık içerme işlemcisi:

$B'=A'$o $(A\Rightarrow B)$

$B'(v)$=max-min$\{A'(u), (A\Rightarrow B)(u, v)\}$, v$\in$ V

2.3.4. Genelleştirilmiş modus tollens

olgu : y B'dir. :R(y)

Kural : Eğer x A ise, o halde y B dir. :R(x, y)

Sonuç : x A'dır. : R(x) = R(y)oR(x, y)

2.4. Bulanık Sistemler

Bulanık kümeler ya da bulanık mantığı ve buna karşılık gelen matematiksel çatıyı kullanan statik veya dinamik sistemler bulanık sistemler olarak tanımlanır. Bu

sistemler bulanık mantıkta çıkarım ve karar vermeye dayalı çalışma ilkeleri olan sistemlerdir. Bulanık sistemin yapısı Şekil 2.9'da gösterilmektedir.

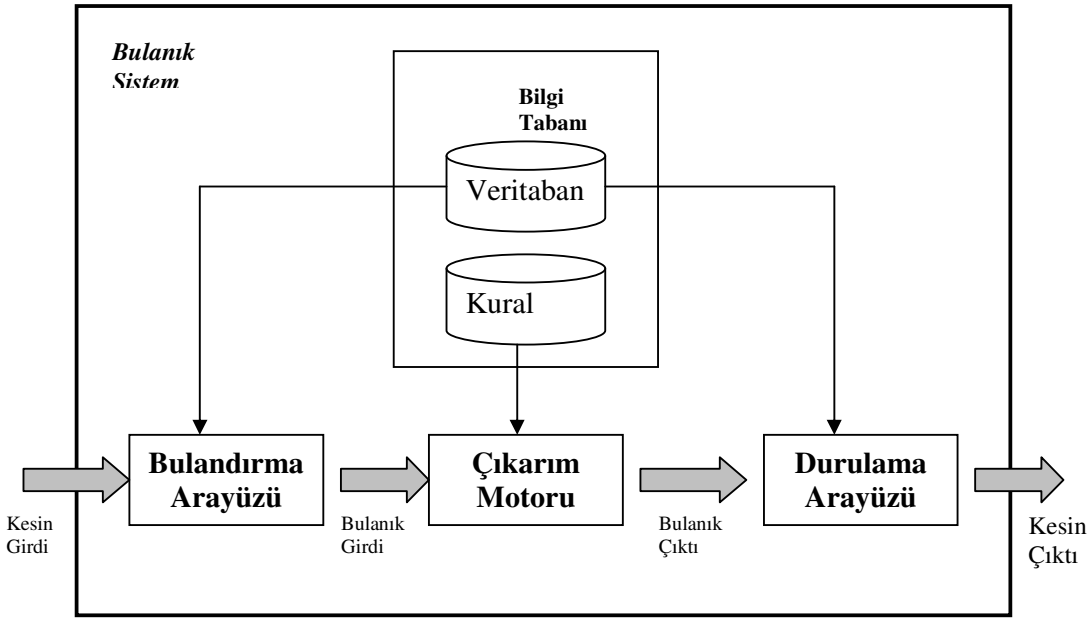
Bulanık mantığa dayanan sistemlerde genel olarak bulandırma arayüzü, çıkarım motoru, durulama arayüzü ve bilgi tabanı olmak üzere dört bölümden söz edilir.

Bulandırma arayüzü; kesin girdi değerlerini bulanık değerlere çevirir. Bunun için girdi değerlerini alır, girdi değişken aralığının uygun evrensel kümeye dönüştürülmesini sağlar ve girdi verilerini sözel değerlere (bulanık kümelere) dönüştürür.

Çıkarım motoru; bulanık kavramlara dayalı olarak insan karar verme işlevini taklit eder. Ayrıca bulanık içerme ve sözel kuralları kullanan bulanık denetim etkinliklerini uygular. Çıkarım motoru akıl yürütme işlemini elde etmek üzere uygulanır.

Bilgi tabanı; uygulama alanı hedeflerinin bilgisini içerir, kural ve üyelik fonksiyonlarını tanımlar. Bilgi tabanı veritabanı ve sözel kural tabanı bölümlerinden oluşur. Veritabanı denetim kuralları ve veri işlemede kullanılan gerekli tanımları içerir. Sözel kural tabanı stratejiyi ve kuralları sözel ifadeler aracılığı ile tanımlamaktadır. Kural tabanı sözel olarak ilgili sistemin modellenmiş hali olarak görülebilir.

Durulama arayüzü ise bulanık çıktı değerlerini kesin değerlere çevirir.



Şekil 2.9 Bulanık sistemin yapısı

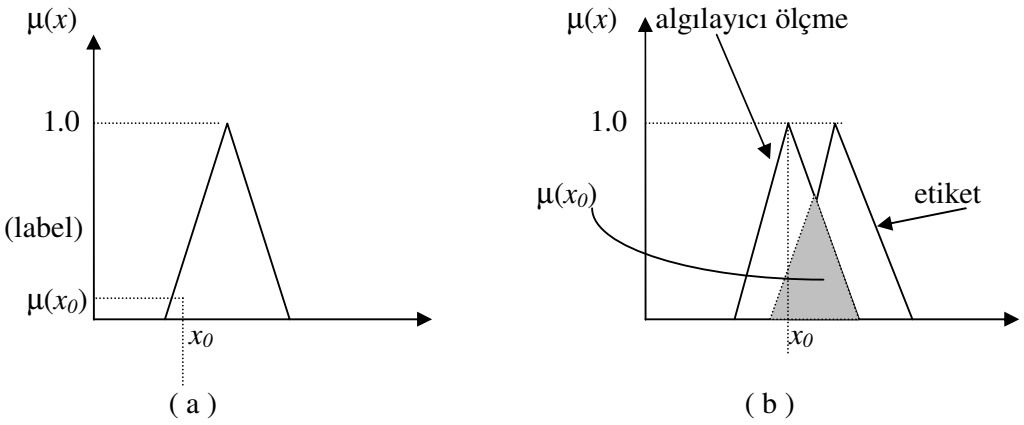
2.4.1. Bulanıklaştırma ünitesi

Fiziksel giriş bilgilerinin, dilsel niteleyicilerle ifade edebileceğimiz bulanık mantık bilgileri şekline çevirme işlemine bulanıklaştırma (fuzzification) adı verilir. Ancak bu bilgilerin tamamının mutlaka kesin bilgiler olması söz konusu değildir. Bulanıklaştırma işlemi önemli ölçüde kesin olmayan bilgiyi de içine alır ve bulanıklaştırır. Bulanıklaştırma sonucu elde edilen değişkenlere dilsel değişkenler (linguistic variables) denir ve işlemle birlikte tüm giriş değişkenlerinin değerleri, üyelik derecesi olarak buraya atanır.

Eğer algılayıcı kesin bir değer olursa, o zaman Şekil 2.10a'da görüldüğü gibi bulanıklaştırma aşamasında dilsel etiketin üyelik fonksiyonuyla algılayıcı ölçme karşılaştırılması gerekir. Eğer algılayıcı okuyucusunda gürültü var ise, üçgenin tepesi, algılayıcı ölçülerinin veri kümesinin değeri anlamında başvurulan üçgen üyelik fonksiyonu kullanılarak modellenmiş olabilir ve bilgi tabanı standart sapma fonksiyonuna başvurur. Bu örnek, bulanıklaştırma üyelik fonksiyonunun etiketinin kesişme noktasının araştırılıp öğrenmesine başvurur ve Şekil 2.10b'de görüldüğü

gibi anlamlandırılmış veri için dağıtır. Bununla beraber geniş çapta kullanılan bulanıklaştırılma metodu algılayıcı okuyucunun kesin olduğu örnektir.

Bulanıklaştırma işlemi göreceli olarak bu kadar kolay olmasına karşın, daha önce de değinildiği gibi uzman sistem kalıplarından dolayı bu işlemlerin yapılması büyük ölçüde deneyime dayanmaktadır. Operatörün sistemde çalışırken gösterdiği davranışlar, sistemin matematiksel modelinden daha önemlidir. Dolayısıyla bulanıklaştırma aşamasına gelinebilmesi için gerekli süre bazen çok uzun olabilir. Bununla birlikte kesin olmayan bilgileri kullanılabilmesi, sürecin matematiksel bir modeline gereksinim duyulmaması ve uygulamaya çabucak geçilebilmesi, bütün bunlardan sonra da yüksek derecede verim alınabilmesi bulanık mantığın önemini açıkça ortaya koymaktadır.



Şekil 2.10 Algılayıcı okuyucu x_0 ile üyelik fonksiyonu $\mu(x)$'in $\mu(x_0)$' a gelmesi a) Keskin algılayıcı okuyucu b) Bulanık algılayıcı okuyucu

Bulanık mantıkta, dilsel ifadelerle anılan bölgelerin sınırlarını belirtmede ve giriş bilgilerine ait üyelik ağırlıklarının tespit edilmesinde kullanılmak üzere uygun üyelik fonksiyonlarının belirlenmesi gerekir.

Bulanıklaştırma stratejileri arasında yer alan bulanık teklikte bulanıklaştırılmış ifadenin tek bir değeri verir. Bulanık sayıda ise sistemden alınan bilgiler bulanık sayılarla ifade edilebilir (yaklaşık 7 gibi). Karma bulanık rasgele sayı bulanıklaştırma stratejisinde ise, süreçten alınan bilgilerin bir kısmı kesin bir kısmı

istatiki bilgiler olabilir. Bu durumda bir kontrol istenirse bu strateji seçilir. Sistemin performansının iyi olması için sistem giriş-çıkış değişkenlerinin en uygun şekilde tanımlanması işlemleri işte bu bulanıklaştırma stratejileri kullanılarak yapılır.

Üyelik fonksiyonunun tespiti, çok önemli bir basamaktır ve sistemin hassasiyetini belirler. Üyelik fonksiyonlarını oluşturmada özel bir kural yoktur, fakat öncelikle, dilsel olarak ifade edilecek olan bölgelerin, sayıları tespit edilmelidir. Çünkü bu, sistemin en kaba haliyle hassasiyetini belirler. Örneğin bir koşul kümesindeki dilsel niteleyiciler {küçük, büyük, orta }= {small, medium, large} bazı alanlarda yeterli olmayabilirler. O zaman {çok küçük, küçük, orta, büyük ve çok büyük }={very small, medium, large and very large} beş koşul ünitesi kullanılması gerekebilir. Daha sonraki hassasiyet ise, üyelik fonksiyonlarının şekilleriyle arttırılır. En kullanışlı üyelik fonksiyonu elde edilinceye kadar birçok denemeler yapılır. Örneğin bu bölümün giriş kısmında da bahsedildiği gibi Japonya Sedai metrosunun bulanık kontrolü için 300.000 benzetim çalışması ve 3.000 insansız uygulama gerçekleştirilmiştir. Üyelik fonksiyonu tespiti, uzman kişinin deney ve tecrübesi sonucu çok çeşitli şekillerde olabilir.

Üyelik fonksiyonları sistem parametrelerini tanımlar. Üyelik fonksiyonlarının sayısına ve şekline ait hiçbir kısıtlama yoktur, tamamıyla tasarımcının istek ve tecrübesine bağlıdır. Bu zamana kadar yapılmış olan çalışmalarda en çok üçgen, yamuk, çan eğrisi şeklinde üyelik fonksiyonları kullanıldığı görülmektedir. Yine de bu fonksiyon1ar, kontrolü yapılan sisteme göre çok değişiklik gösterebilir.

Bilgi Tabanı; bulanık mantık uygulamalarında bilgi tabanı şeklinde kendi başına bir ünite yoktur, fakat teorik anlatımda, anlama kolaylığı sağlamak ve şematik ifade edebilme açılarından veri tabanı ve kural tabanı, ikisi beraber bilgi tabanı olarak gösterilir. Çıkarım ünitesi karar verme işlemlerinde, bilgi tabanına gidip, veri tabanından üyelik fonksiyonlarıyla ilgili bilgileri, kural tabanından ise değişik giriş değerleri için tespit edilmiş olan kontrol çıkışları bilgisini alır. Bu bakımdan bilgi tabanı ve çıkarım ünitesi sürekli ilişki halindedir.

Veri Tabanı; Üyelik fonksiyonlarının tespit edilmesi için yapılan ön çalışmalar ile, son hali belli olmuş üyelik fonksiyonlarının sınır ve eğim bilgilerini içeren veri tabanını ayrı düşünmek gerekmektedir. Bir bulanık kontrol sisteminde, Basic, Pascal, C gibi üst düzey dilleri kullanan bir bilgisayar veya Assembly dilini

kullanan bir mikroişlemci kullanılmış olabilir. Her iki şekilde de üyelik fonksiyonu bilgilerinin, program olarak oluşturulması gerekmektedir. Bir veya birden fazla üyelik fonksiyonunun sınırlandırmış olduğu bir alan, dilsel olarak ifade edilen bir bölgeyi oluşturur. Bu bölgelerin, bir program dilinde oluşturulabilmesi için, her bir bölgeyi sınırlandıran üyelik fonksiyonların başlangıç, bitiş noktaları ve fonksiyon denklemlerinin bilinmesi gerekmektedir.

Teorik çalışmalarda üyelik fonksiyonları grafik olarak izah edildiği ve gözle takip edilebildiği için veri tabanı grafiklerden ibaret kalmakta ve bazı çalışmalarda yüzeysel olarak anlatılmaktadır. Fakat uygulamalı bir bulanık kontrol çalışmasında, üyelik fonksiyonlarıyla oluşturulan bölge bilgilerinin, çalışmanın yapıldığı programlama dilinde oluşturulması, programlamanın önemli bir kısmını oluşturmaktadır.

Kural Tabanı; kural tabanında, sistemin bilgi girişlerinin alabileceği çeşitli değerlere göre mantıki olarak uygunluk gösteren sistem çıkış değerleri, kural satırları haline getirilerek, kural tabanı oluşturulur. Örneğin bir klima kontrolünde "içerisi az sıcak ise az soğut, çok sıcak ise çok soğut" şeklinde bir ilişki kurulabilir. Kural tabanında değerlendirilecek giriş bilgileri birden fazla olabileceği gibi, kontrol çıkışı da birden fazla olabilir.

Aslında "sıcak", "soğuk" gibi dilsel ifadeler sistemin girişinde ve çıkışındaki değer uzayını aralıklara ayırmaktadır. Kural tabanı bu şekliyle klasik sayısal kontrolleri andırmakta, fakat bölge bilgisinin yanında girişlere ait üyelik ağırlıklarının da dikkate alınıyor olması bulanık kontrolü, uzman sistemlerden ve diğer kontrollerden ayırmaktadır.

Basit olarak bir sistem için kural tabanı geliştirdiğimizde, sistem çıkışını etkileyebilecek ölçülebilen giriş değerleri tespit edilmelidir. Giriş bilgisine ait değer uzayı, üyelik fonksiyonları ile bölgelere ayrılarak, dilsel ifadelerle isimlendirilir ve aynı zamanda her giriş değeri için bir üyelik ağırlığı tespit edilmiş olur. Böylece her giriş değerinin, ait olduğu bir bölgesi ve bir üyelik ağırlığı olur. Kural tabanı, her birisi bir bölgeyi temsil eden dilsel ifadelerle düzenlenir. Örneğin "1. giriş sıcak, 2. giriş normal ise, çıkış yüksektir." gibi bir kural satırında görüldüğü gibi, kural tabanını oluşturan bilgiler, tamamen dilsel ifadelerdir. Fakat her kural satırındaki, tespit edilmiş olan çıkış değeri, birim fonksiyonlarla oluşturulmuş ise, sayısal

değerlerle de ifade edilebilir. Bu durumda oluşturulacak kural satırları "1. giriş sıcak. 2. giriş normal ise, çıkış l.5'tir." şeklinde bir kuralın benzeri olabilir. Kural satırları birbirlerine "veya" bağlacı ile bağlanır ve her kural satırında girişler ve çıkışlar arasında "ve" bağlacı kullanılır.

Kural tabanında, giriş değerleri ve kontrol çıkışı değerlerinin birbirleri arasında "ve" ifadesi, ayrı davranışları ifade eden kural kümeleri arasında "veya" ifadesi kullanılır. Kontrol tabanını oluşturan kurallar aşağıdaki özelliklere sahiptir.

1- Her kural bağımsız bilgi parçasını içerir.

2- Yeni kurallar diğer kurallardan bağımsız olarak kural tabanına eklenebilir.

3- Eski kurallar diğer kurallardan bağımsız olarak değiştirilebilir.

4- Kontrol sisteminin kararlarını ve çözümlerini içerir.

Bir bulanık kontrolcünün gerçekleşmesinde, denetlenecek sistemin bir matematiksel modelinden daha çok, o sistemi çalıştıracak operatörün sistem davranışı konusunda sahip olduğu bilgiler daha önemlidir. Tasarım sırasında genellikle bu tür bilgilerden yararlanılır. Böyle bir yaklaşım, uzun yıllar boyunca kazanılan deneyimlerin kontrolcü içerisine, yorumlanmış halde kolaylıkla yerleştirilebilmesine olanak sağlar. Bu yararın yanında getirdiği sakınca, kontrolcü tasarımında belirli bir otomasyon elde edilememesidir. Buna rağmen, bulanık kontrolcünün en önemli kısmını oluşturan kural tabanının oluşturulması için kullanılabilecek çeşitli yaklaşımlar şunlardır :

a- Kontrol kuralları doğrudan doğruya uzman kişinin bilgi ve deneyiminden yararlanılarak elde edilir.

b- Operatörünün kontrol davranışları gözlenir ve kontrolcü bu davranışlardan bulanık model oluşturur.

c- Kontrol kuralları sistemin karakteristiklerinin bulanık şekilde ifade edilmiş modellerinden elde edilebilir.

d- Kendi kendine organize etme/öğrenme.

Bulanık kontrol kurallarını üretmek için kullanılan yaklaşımlar ise;

1- Tecrübeye dayalı metot

2- Deterministik metot

şeklinde ifade edilir.

Tecrübeye dayalı metotta, bulanık kontrol kurallarını üretmek için uzman bilgisi ve kontrol edilen sürecin davranışının analizi kullanılmaktadır.

Deterministik metotta ise, bulanık modelleme ile kontrol kurallarının yapısı ve parametreleri belirlenmektedir.

2.4.2. Çıkarım ünitesi

Bu ünite, bulanıklaştırma biriminden gelen bulanık değerleri, kural tabanındaki kurallar üzerinde uygulayarak bulanık sonuçlar üretmektedir. İlk olarak, her bir giriş değerinin ne oranda hangi üyelik kümesine ait olduğu saptanmaktadır. Bu değerler kural tablosuna yerleştirilerek uygun çıkışlar elde edilmektedir. Bulanık mantık kuralları kural içerisindeki birleştiricilerin anlamlarının yorumlanması ile hesaplanmaktadır.

Bir girdi bulanık kural tabanında çıkarım mekanizması sayesinde işleme tabi tutulur. Kural tabanında bilginin modellenme şekline göre (mandani, takagi, sugeno kang vs.) eldeki girdiye karşılık gelen çıktı değeri belirlenecektir. Bu süreç çıkarım ve karar verme sürecidir. Burada girdinin işlenebileceği kurallarla işleme sokulması söz konusudur (Baykal 2004).

Bulanık Eğer-O halde Kurallarının Değerlendirilmesi

Bulanık *"eğer-o halde"* işlemleri bulanık içerme olara değerlendirilir.

$$\mu_{A\Rightarrow B}(a,b) \equiv \mu_B(b), a \in A, b \in B$$

Bulanık mantık için belirli bir mantık sistem seçimine göre "eğer-o halde" kuralları için çeşitli seçenekler söz konusudur.

$$\mu_A(a) \Rightarrow \mu_B(b)$$

yani;

$$\begin{aligned}
&\mu_{A\Rightarrow B}(a,b) = \min\{\mu_A(a), \mu_B(b)\} \\
&\mu_{A\Rightarrow B}(a,b) = \mu_A(a).\mu_B(b) \\
&\mu_{A\Rightarrow B}(a,b) = \min\{1, 1+\mu_A(b), \mu_B(a)\} \\
&\mu_{A\Rightarrow B}(a,b) = \max\{\min\{\mu_A(a), \mu_B(b)\}, 1-\mu_A(a)\} \\
&\mu_{A\Rightarrow B}(a,b) = \max\{1-\mu_A(a), \mu_B(b)\}
\end{aligned} \tag{2.9}$$

$$\mu_{A\Rightarrow B}(a,b)=\begin{cases}1 & Eger\ \mu_A(a)\le\mu_B(b)\\ \mu_B(b)/\mu_A(a) & Eger\ \mu_A(a)>\mu_B(b)\end{cases} \quad (2.10)$$

Çıkarım yöntemleri

Mandani yönteminde min işlemcisini *Rc* yi bulanık içerme olarak, max-min işlemcisini de bileşke olarak kullanılır. Bulanık kural şu şekilde verilmiş olsun;

R_i: Eğer x A_i ve y B_i ise o halde z C_i dir.

1. Girdi verisi $x=x_0$ ve $y=y_0$ gibi bir tekillik olduğunda (bu durumda girdi verisi bulandırılamaz) *Ai* ve *Bi* eşleşme derecesi sırayla $\mu_{Ai}(x_o)$ ve $\mu_{Bi}(x_o)$ dir. Bundan dolayı R_i kuralının eşleşme derecesi;

$$\alpha_i=\mu_{Ai}(x_o)\wedge\mu_{Bi}(x_o) \quad (2.11)$$

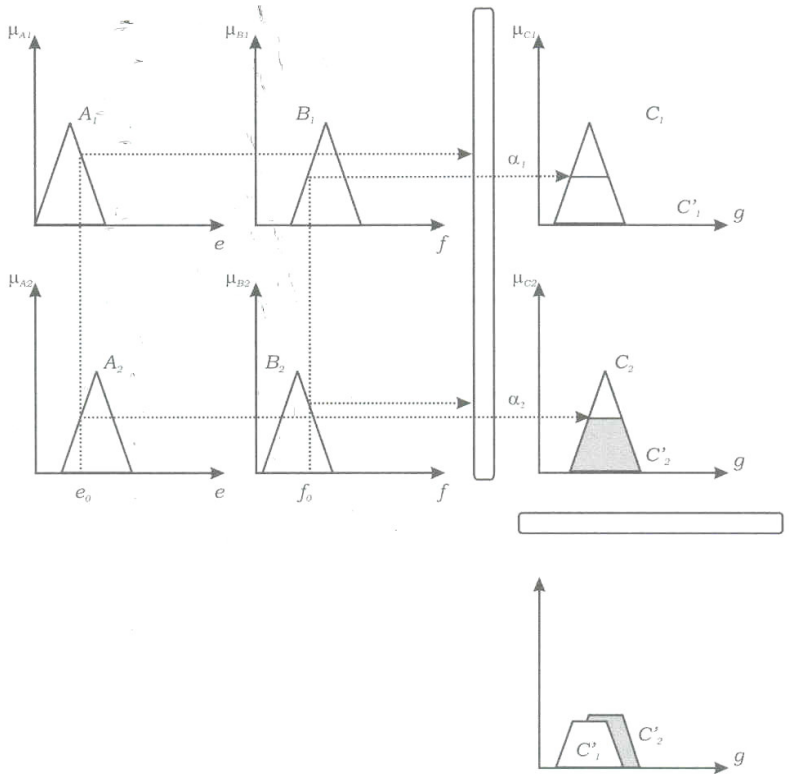
C'_i, R_i kuralının sonucu olduğunda;

$$\mu_{Ci}(z)=\alpha_i\wedge\mu_{Ci}(z) \quad (2.12)$$

Toplum sonuç C' bireysel denetim kurallarından türer;

$$\mu C'(z)=\vee_{i=1}^{n}[\alpha i\wedge\mu Ci(z)] \quad (2.13)$$

$$C'=\bigcup_{i=1}^{n}C'i \quad (2.14)$$



Şekil 2.11 Mamdani yöntemi ile çıkarım (Baykal 2004)

2. Girdi verileri *A'* ve *B'* bulanık kümeleri olduğunda *i*=1,2,....*n* olmak üzere;

$$\alpha_i = \min[\max(\mu_{A'}(x) \wedge \mu_A(x)), \max(\mu_B(y) \wedge \mu_B(y))] \quad (2.15)$$

$$\mu_{Ci}(z) = \alpha_i \wedge \mu_{Ci}(z) \quad (2.16)$$

Toplam *C'* sonucu

$$\mu C'(z) = \vee_{i=1}^{n} [\alpha i \wedge \mu Ci(z)] \quad (2.17)$$

$$C' = \bigcup_{i=1}^{n} C'i \quad (2.18)$$

olarak belirlenebilir.

Larsen yönteminde bulanık içerme için çarpım işlemcisi ve bulanık bileşke için de max-çarpım işlemcisi kullanılır. Bulanık kural aşağıdaki şekilde verilmiş olsun;

R_i: Eğer x A_i ve y B_i ise o halde z C_i dir.

1. Girdi verisi $x=x_0$ ve $y=y_0$ gibi bir tekillik olduğunda, eşleşme dereceleri;

$$\alpha_i = \mu_{Ai}(x_o) \wedge \mu_{Bi}(t) \tag{2.19}$$

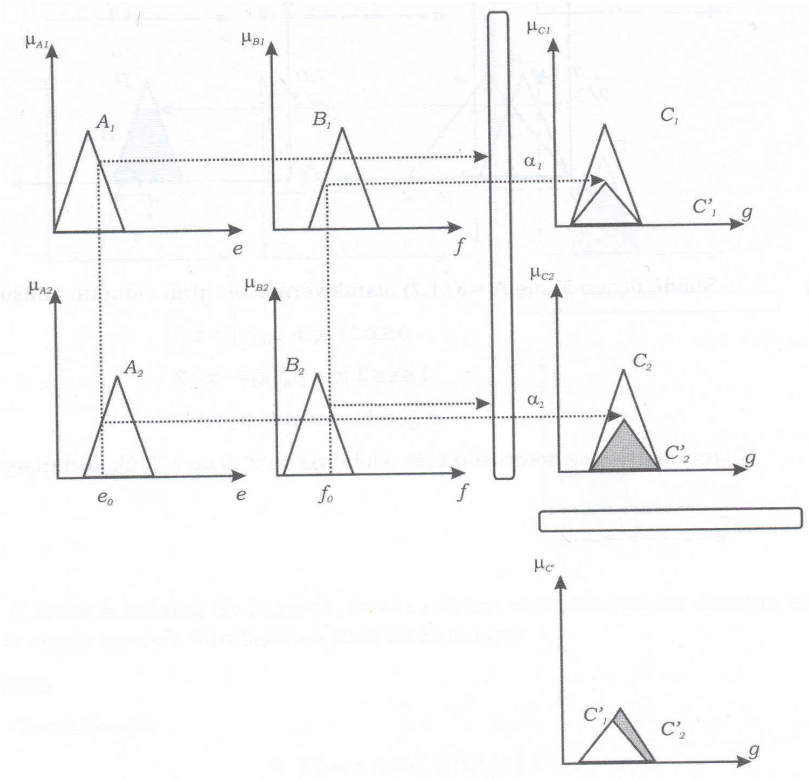
C'_i, R_i kuralının sonucu olduğunda;

$$\mu_{Ci}(z) = \alpha_i \wedge \mu_{Ci}(z) \tag{2.20}$$

Toplam C' sonucu;

$$\mu C'(z) = \vee_{i=1}^{n} [\alpha i \bullet \mu Ci(z)] \tag{2.21}$$

$$C' = \bigcup_{i=1}^{n} C'i \tag{2.22}$$



Şekil 2.12 Larsen yöntemi ile çıkarım (Baykal 2004)

2. Veri A' ve B' bulanık kümeleri olarak verildiğinde eşleşme dereceleri;

$\alpha_i = \min[\max(\mu_{A'}(x) \wedge \mu_A(x)), \max(\mu_{B'}(y) \wedge \mu_B(y))]$

$\mu_{Ci}(z) = \alpha_i \bullet \mu_{Ci}(z)$

$$\mu C'(z) = \vee_{i=1}^{n} [\alpha i \bullet \mu Ci(z)] \qquad (2.23)$$

$$C' = \cup_{i=1}^{n} C'i$$

olarak belirlenir.

Tsukamoto yönteminde her kuralın soncul parçası monotonik üyelik fonksiyonuna sahip bir bulanık küme ile temsil edildiğinde kullanılır. Her kuralın çıktısı kuralın ateşleme derecesi tarafından oluşturulan kesin bir değer olarak tanımlanır.

C_i monotonik üyelik fonksiyonu ($\mu_{Ci}(z)$)'na sahip ve bulanık kurallarda i=1,2,....n olmak üzere;

R_i: Eğer x A_i ve y B_i ise o halde z C_i dir.

şeklinde olsun.

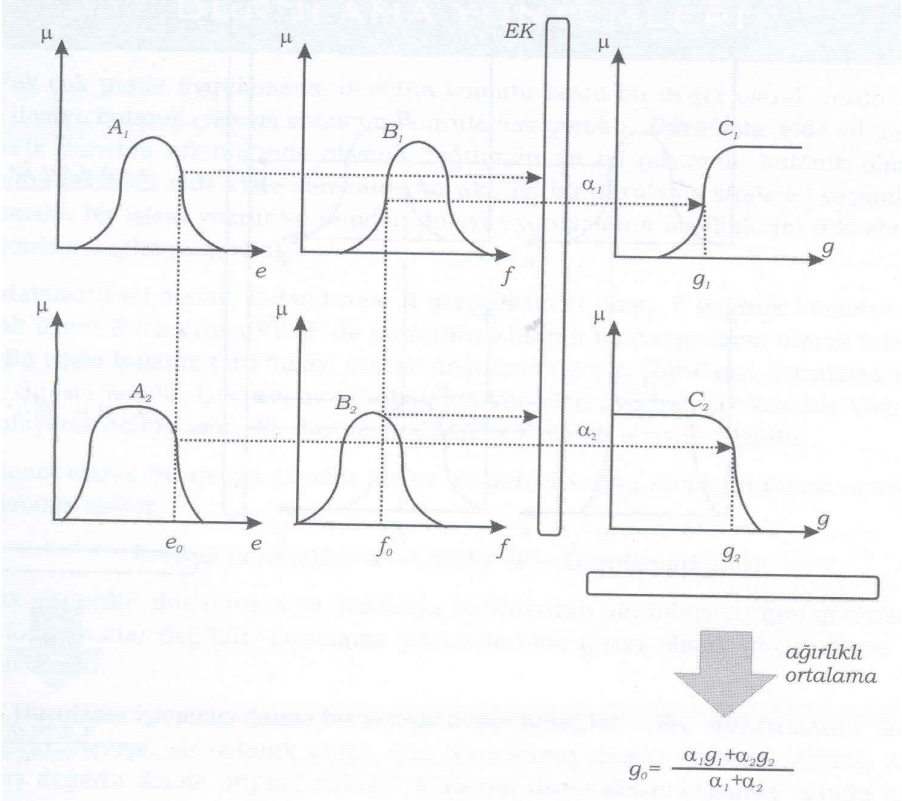
Hem tekillik girdisi hem de bulanık küme girdisi için her kuralın eşleşme derecesi α_i önceki yöntemlerdeki gibi tanımlanır. R_i kuralını z_i sonucu;

$$z_i = \mu^{-1}{}_{Ci}(\alpha_i) \qquad (2.24)$$

z' toplam sonucu, her kural çıktısının ağırlıklı ortalaması alındığında;

$$z' = \frac{\alpha_1 z_1 + \alpha_2 z_2}{\alpha_1 + \alpha_2} \qquad (2.25)$$

elde edilir. Bu yöntemde toplam bir sonuç olarak kesin bir değer verir ve bundan dolayı bunu durulamaya gerek yoktur.



Şekil 2.13 Tsukamoto yöntemi ile çıkarım (Baykal 2004)

TSK (Takagi-Sugeno-Kang) yönteminde soncul parça bir girdi değişkenleri fonksiyonu olarak verildiğinde kullanılır. Aşağıdaki gibi iki kural olduğunu kabul edelim.

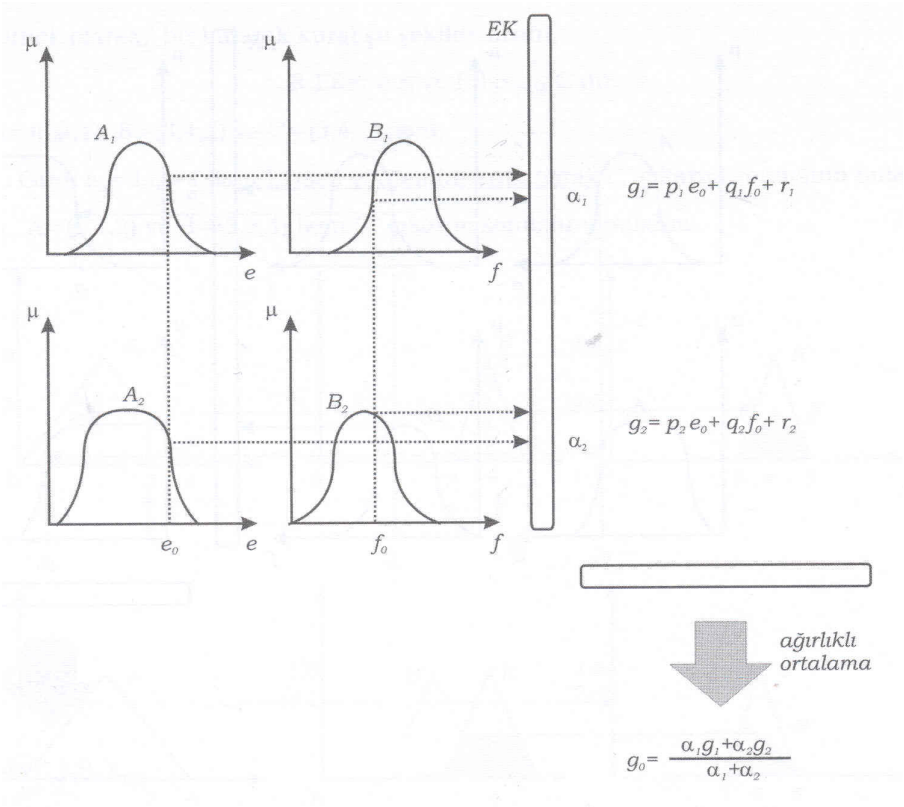
R_1: Eğer e A_1 ve f B_1 ise o halde $g=f_1(e,f)=p_1e+q_1f+r_1$

R_2: Eğer e A_2 ve f B_2 ise o halde $g=f_2(e,f)=p_2e+q_2f+r_2$

e_0 ve f_0 tekil girdiler ve α_i eşleşme değeri iken ilk kuraldan elde edilen denetim etkinliğinin çıkarım değeri $f_1(e_0, f_0)$'dir. Toplam sonuç ağırlıklı ortalama ile elde edilir.

$$g_0 = \frac{\alpha_1 g_1 + \alpha_2 g_2}{\alpha_1 + \alpha_2} \tag{2.26}$$

Bu yöntem sonuç kesin değer olduğu için durulaştırma zamanından tasarruf ettirir.



Şekil 2.14 TSK yöntemi ile çıkarım (Baykal 2004)

2.4.3. Durulama ünitesi

Bu ünite, çıkarım ünitesinden gönderilen kontrol işaretinin fiziksel ve kesin sayılara getirilmesini sağlamaktadır. Durulayıcı, bu işlemi aşağıda kullanılan yöntemlerden birini kullanarak yapmaktadır. (Şen 2001).

Pek çok uygulamada denetim komutu kesin bir değer olarak verilir. Bundan dolayı bulanık çıkarım sonucunu durulamak gerekir. Durulama, elde edilmiş bir bulanık denetim etkinliğinde olasılık etkinliğinde olasılık dağılımını en iyi gösteren, bulanık olmayan denetim etkinliği elde etme sürecidir.

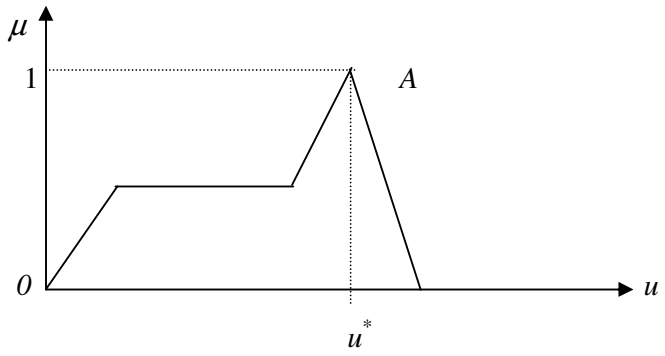
Bulandırma ve durulama birbirlerinin bütünleyicisi gibi görünse de, ters fonksiyonlar değildir. Otuzdan fazla durulama yöntemi vardır. Bunlardan en sıklıkla

kullanılanları en büyüklerin ortası, ağırlık merkezi yöntemi, ortalamaların merkezi ve alan merkezidir. Hangi yöntemin kullanılacağına sorunun türüne göre tasarımı yapan kişinin karar vermesi gerekir. En sık kullanılan durulama yöntemleri;

En büyük üyelik

Diğer bir adı da yükseklik yöntemidir. Kullanılabilmesi için tepeleri olan çıkarım bulanık kümelerine ihtiyaç vardır. En büyük üyelik ile durulaştırma işleminin gösterimi;

$\mu_A(u^*) \geq \mu_A(u)$

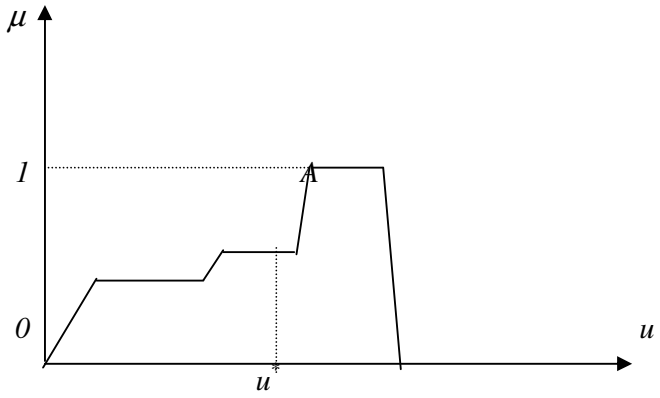


Şekil 2.15 Üyelik fonksiyonlarının max noktaları ile durulama işlemi

Ağırlık merkezi yöntemi

Durulaştırma işlemlerinde en çok kullanılan yöntemdir. Matematiksel denklemi aşağıdaki gibidir (Allahverdi 2003).

$$z^* = \frac{\int \mu(z).z dz}{\int \mu(z) dz} \tag{2.27}$$

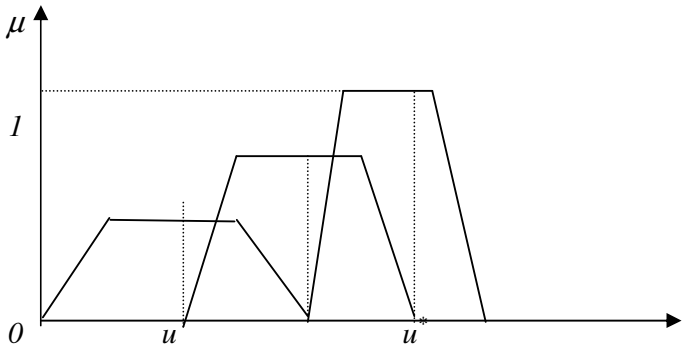


Şekil 2.16 Merkez yöntemi ile durulaştırma işlemi

Ağırlıklı ortalama yöntemi

Bunun kullanılabilmesi için simetrik üyelik fonksiyonlarının bulunması gereklidir. Çıkışı oluşturan bulanık kümelerin üyelik fonksiyonlarının her biri sahip oldukları en büyük üyelik derecesi değeri ile çarpılarak ağırlıklı ortalamaları alınır (Şen 2001).

$$z^* = \frac{\sum \mu(\bar{z}).\bar{z}}{\sum \mu(\bar{z})} \qquad (2.28)$$

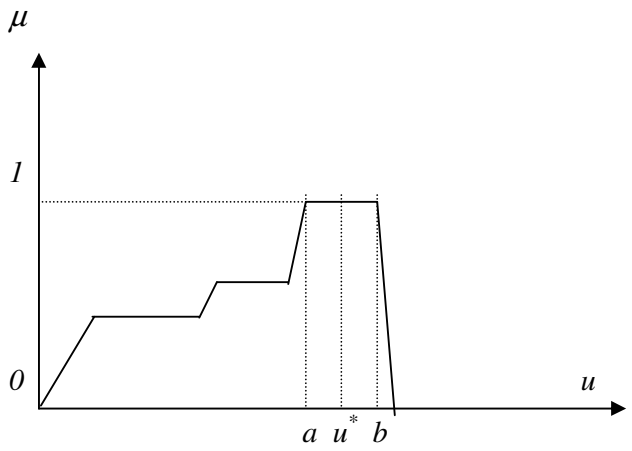


Şekil 2.17 Ağırlıklı ortalama yöntemi ile durulama işlemi

Ortalama en büyük üyelik

Diğer bir adı da en büyüklerin ortasıdır. En büyük üyeliğin konumu tekil olmayabilir, bu durumda *a* ve *b* sınırlandırılmış bir düzlüğe sahip ise durulaştırılmış değer şöyle ifade edilir (Şen 2001).

$$z^* = \frac{a+b}{2} \tag{2.29}$$



Şekil 2.18 Max noktaların ortalaması yöntemiyle durulama işlemi

Toplamların merkezi

Bu yöntemde iki bulanık kümenin birleşimi yerine onların cebirsel toplamı kullanılır. Bunun bir mahzuru örtüşen kısımların iki kez toplama girmesidir (Şen 2001).

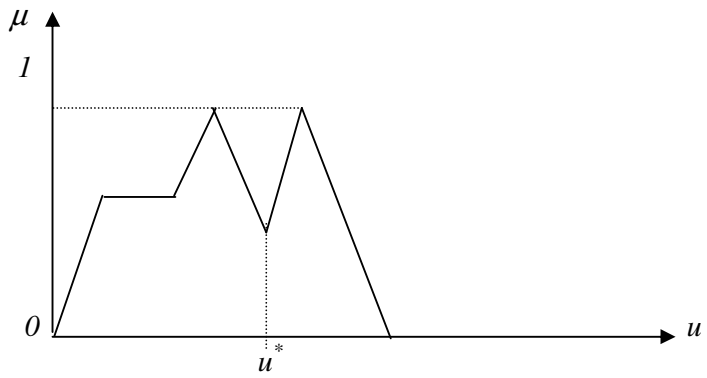
$$z^* = \frac{\int_z z \sum_{k=1}^{n} \mu(z) dz}{\int_z \sum_{k=1}^{n} \mu(z) dz} \tag{2.30}$$

Hesaplama tarzı ağırlıklı ortalama durulaştırmasına benzer, ancak toplamların merkezi yönteminde ağırlıklar ilgili üyelik fonksiyonlarının alanlarıdır. Ortalama ağırlık yönteminde ise bu üyelik derecesidir.

En büyük alanın merkezi

Eğer çıkış bulanık kümesi en azından iki tane dış bükey bulanık kümeyi içeriyor ise dış bükey bulanık kümelerin en büyük alanlısının ağırlık merkezi durulaştırma işleminde kullanılır (Şen 2001).

$$z^* = \frac{\int \mu_{EB}(z).z dz}{\int \mu_{EB}(z) dz} \tag{2.31}$$



Şekil 2.19 En büyük alan merkezi ile durulaştırma

3. YAPAY SİNİR AĞLARI

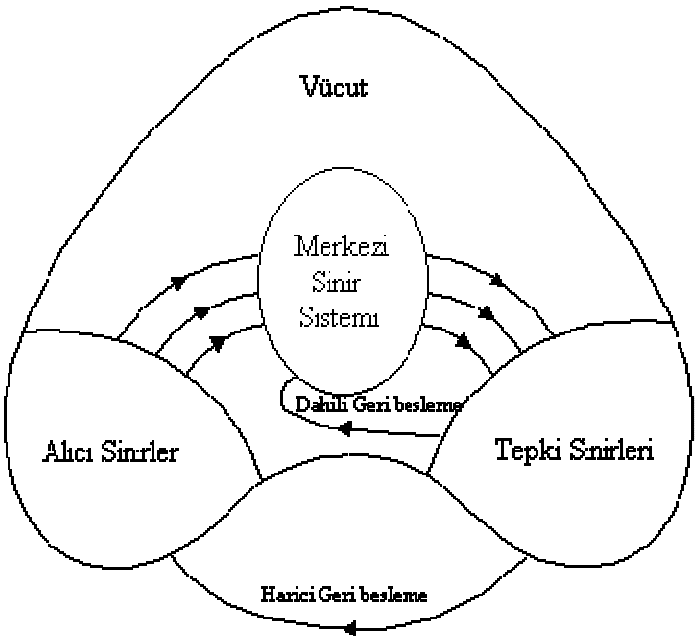
Yapay Sinir Ağları (YSA) insan beyninin özelliklerinden olan öğrenme yoluyla yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi kabiliyetleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek maksadıyla geliştirilen bilgisayar sistemleridir.

YSA, beynin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Literatürde 100'den fazla yapay sinir ağı modeli vardır . Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise beynin fonksiyonlarını kısmen yerine getiren bir çok modelleri oluşturmaya çalışmışlardır.

YSA'ların öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder.

3.1. Biyolojik Nöron Yapısı

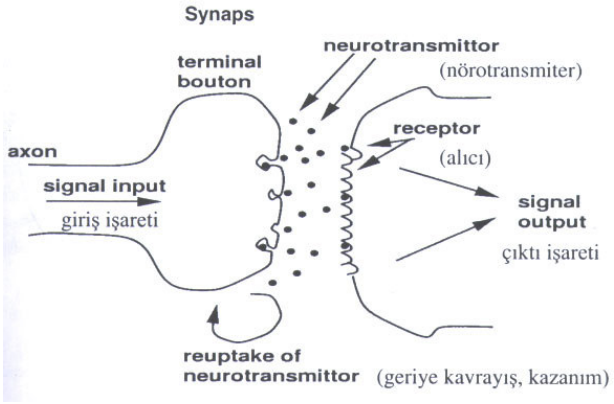
Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanmaktadır. Alıcı sinirler (receptor), organizma içerisinden ya da dış ortamdan algıladıkları uyarıları, elektriksel sinyallere dönüştürerek beyne iletirler. Tepki sinirleri (effector) ise, beynin ürettiği elektriksel sinyalleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 3.1'de biyolojik sinir sisteminin blok şeması görülmektedir.



Şekil 3.1 Biyolojik sinir sisteminin blok gösterimi

Sinir hücreleri nöron olarak bilinir. Nöron, özellikle beyin olmak üzere sinir sisteminin temel birimidir ve başlıca üç kısımdan oluşur. Bunlar:

- Gövde (cell body)
- Gövdeye gire sinyal alıcı lifler (dendrit),
- Gövdeden çıkan sinyal iletici lifler (axon).



Şekil 3.2 Biyolojik hücrenin bilgi alışverişi (Öztemel 2003)

YSA'lar, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmış olup aralarında yapısal olarak bazı benzerlikler vardır. Bu benzerlikler Tablo 3.1'de verilmiştir.

Tablo 3.1 Sinir sistemi ile YSA'nın benzerlikleri.

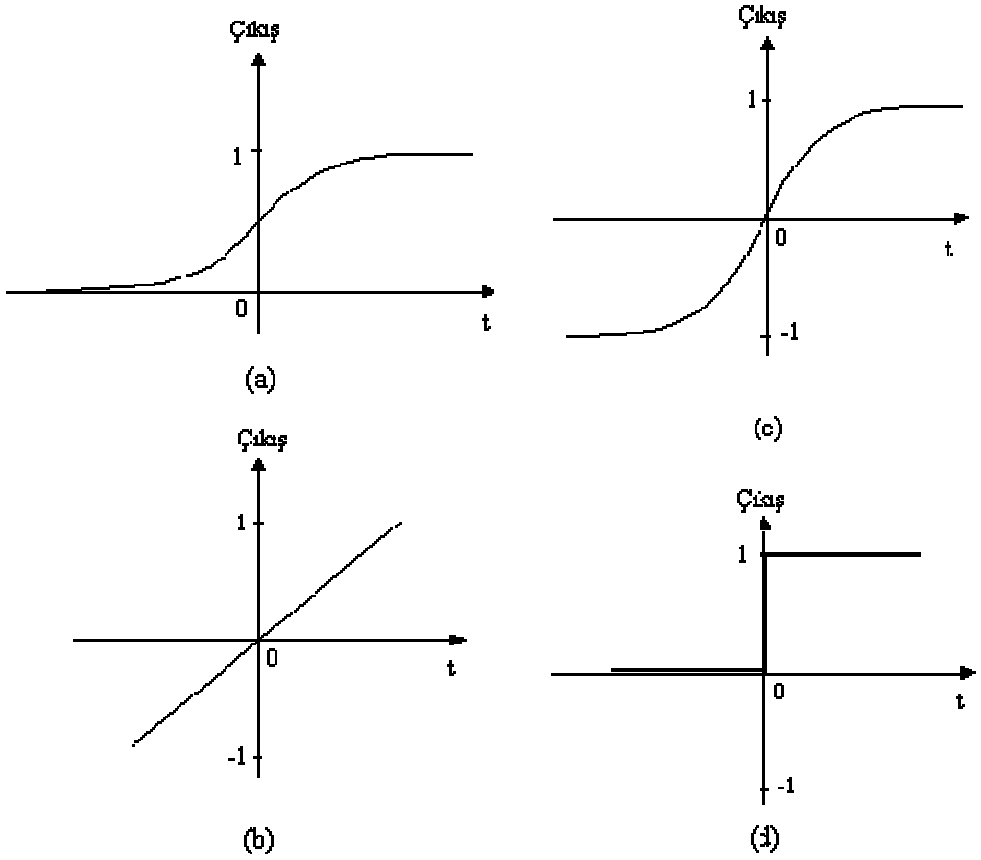
Sinir Sistemi	**YSA Sistemi**
Neuron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

3.2. Aktivasyon Fonksiyonları

Şekil 3.3'de, bir hücrenin girdisine göre hücre çıkışını tanımlayan aktivasyon fonksiyonlarından 4 tanesi verilmiştir.

Kullanılacak olan diğer fonksiyonların türevi alınabilir ve süreklilik arz etmeleri gerekir. YSA'nın kullanım amacına uygun olarak tek veya çift yönlü aktivasyon fonksiyonları da kullanılabilir.

YSA'larda en çok kullanılan aktivasyon fonksiyonu Şekil 3.3a'da verilmiştir. Doğrusal YSA'larda ve katmanlı YSA'ların çıkış katmanında kullanılan doğrusal fonksiyon Şekil 3.3b'de verilmiştir ve işlemci elemanın girdisini doğrudan işlemci elemanın çıktısı olarak verir. İki kutuplu özelliğe sahip olan tanjant hiperbolik fonksiyonu Şekil 3.3c'de gösterilmiştir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Şekil 3.3d'de görülen keskin sınırlayıcı aktivasyon fonksiyonu, mantıksal çıkış verir ve sınıflandırıcı ağlarda tercih edilir. Beyin, sıkışık olarak arabağlaşımlı milyarlarca (yaklaşık olarak 1011) nörondan oluşmaktadır. Her eleman kendi aralarında oldukça çok sayıda nörona (eleman başına yaklaşık olarak 104 bağlantı) bağlanmıştır. Bir nöronun aksonu (çıkış yolu) ayrıştırılmış ve bir sinaps olarak adlandırılan bir fonksiyon vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Bu fonksiyon uçlarındaki iletim doğal olarak kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Bu sinaptik büyüklük, beyin öğrenirken neyin modifiye edildiğini belirtir. Bu sinaps, beynin temel hafıza mekanizmasına dayanarak nöron içerisindeki bilginin işlenmesi ile birleştirilir.



Şekil 3.3 YSA'larda en çok tercih edilen aktivasyon fonksiyonları a) sigmoid, b) doğrusal c) hiperbolik tanjant ve d) keskin sınırlayıcı

3.3. Yapay Sinir Ağı Hücresi

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi YSA'nında sinir hücreleri vardır. Yapay sinir hücreleri mühendislikte "işlem elemanları" olarak adlandırılmaktadır. (Şekil 3.4) Her işlem elemanının beş temel elemanı vardır (Öztemel 2003). Bunlar;

1. Girdiler
2. Ağırlıklar
3. Toplama fonksiyonu

4. Aktivasyon fonksiyonu
5. Hücrenin çıktısı

olarak sıralanabilir. Burada girişler dış kaynaklardan, diğer işlem elemanlarından veya kendi kendisinden gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıkları da farklıdır.

Ağırlıklar yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıklar +/-, sabit veya değişken değer alabilirler.

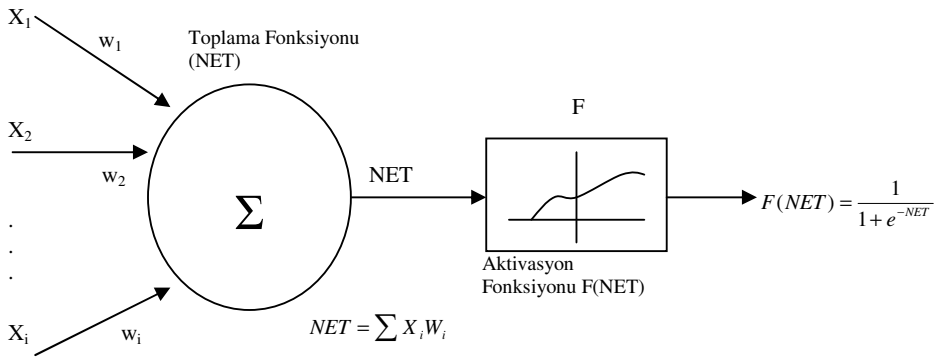
Toplama fonksiyonu bir hücreye gelen net girdiyi hesaplar. YSA'da girilen giriş değerlerine önce toplama fonksiyonları uygulanır ve her bir işlem elemanının çıktı (NET) değeri

$$NET = \sum_{i=1}^{n} X_i W_{ij} - \theta_i \tag{3.1}$$

olarak bulunur (Öztemel 2003). Burada X_i *i.* girişi, W_{ij} *j.* elemandan *i.* elemana bağlantı ağırlığını ve θ_i eşik (threshold) değerini göstermektedir. Daha sonra bu çıkış değerleri sigmoidal aktivasyon fonksiyonuna yani öğrenme eğrisine uygulanır. Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek karşılık üreteceği çıktıyı belirler. Çok-katmanlı algılayıcı modelinde genelde sigmoid fonksiyonu kullanılır.Sonuçta çıkış değeri aşağıdaki şekilde bulunur.

$$F(NET) = \frac{1}{1 + e^{-NET}} \tag{3.2}$$

Transfer fonksiyonları olarak çoğunlukla, Şekil 3.2'de verilen fonksiyonlardan birisi kullanılabilir. Uygulamalarda, en çok hiperbolik tanjant veya sigmoid fonksiyonu kullanılmaktadır. Şekil 3.3'de işlemci eleman çıkışında kullanılan sigmoid fonksiyona göre çıkış değerinin hesaplanması gösterilmiştir. Bu işlemci elemanın çıkış değeri diğer işlemci elemanlarına giriş veya ağın çıkış değeri olabilir. Hücrenin çıktısı aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış ortama veya bir başka hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak gönderebilir.



Şekil 3.4 Yapay sinir hücresinin yapısı

3.4. YSA ile Hesaplamanın Özellikleri

YSA hesaplama özelliklerini, paralel dağılmış yapısından, öğrenebilme ve genelleme yapma yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme süresince kullanılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu özellikleri ile YSA'lar karmaşık ve çözümlenmesi güç problemleri de çözebilme yeteneğine sahiptir. Nesne tanıma , işaret işleme, sistem tanımlama ve denetimi gibi birçok mühendislik alanında YSA'lar, aşağıda belirtilen özellikleri nedeniyle başarılı olarak kullanılmaktadır.

Doğrusal Olmama

YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik tüm ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlere çözüm getirmektedir.

Öğrenme

Aslında öğrenmeden kasıt, ilgili problemdeki girdi-çıktı ilişkisini en güzel tanımlayacak optimum ağırlıkların bulunmasıdır. Problemden alınan örneklerden faydalanılarak ilgili problemi kendisine uygulanan örneklerden öğrenmeye çalışır, probleme farklı bir çözüm sağlar.

Genelleme

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakteri tahmin ederler. Nöral hesaplamada hafızalar birleşiktir. Yani eğitilmiş ağa girişin sadece bir kısmı verilse bile ağ hafızadan bu girişe en yakınını seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA'ya eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleştirme özelliğidir.

Uyarlanabilirlik

YSA ağırlıkları uygulanan probleme göre değiştirilir. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA uyarlamalı örnek tanıma, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

Dağıtılmış birleşik hafıza

YSA'ların en önemli özelliklerinden biri de bilgiyi depolamalarıdır. Nöral hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları nöral ağın hafıza birimidir. Bu ağırlıklar ağın o andaki sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı verir. Bu bilgiler, ağdaki birçok ağırlıklar üzerine (hafıza birimine) dağıtılır.

Eğitilmiş ağa, eğitimde kullanılmamış herhangi farklı bir giriş uygulanırsa ağ daha önceki girişlerden öğrenmiş olduğu davranış doğrultusunda beklenen çıkışa uygun bir çıkış değeri üretebilecektir. YSA'ya verilen veri eksik, gürültülü veya daha önce hiç karşılaşmamış olsa bile ağ, kabul edilebilir uygun bir çıkış üretecektir. Bu özelliğe genelleştirme özelliği denir.

Hata toleransı

YSA'larda çok sayıda işlemci elemanların bağlantısı paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi ağdaki tüm bağlantılara dağılmıştır. Giriş veri setinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine

dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır.

Paralel işlem yapma

YSA'lar, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçeklenebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini ve örnek tanıma, işaret işleme, sistem kimliklendirme ve denetim gibi gerçek zaman uygulamalarında kullanımını artırır.

3.5. Yapay Sinir Ağlarının Sınıflandırılması

YSA'lar, genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile işlemci elemanlardan (neurons) oluşurlar. Her bir sinir hücresi arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan bir öğrenme kuralına göre, hatayı sıfıra indirecek şekilde, ağın ağırlıkları değiştirilir. YSA'lar yapılarına ve öğrenme algoritmalarına göre sınıflandırılırlar.

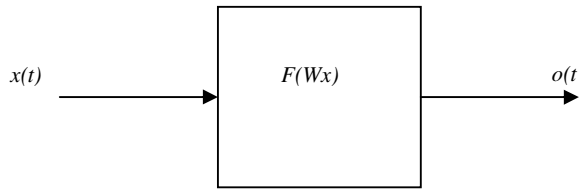
3.5.1. YSA'ların yapılarına göre sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.

İleri Beslemeli Ağlar

İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 3.5'de ileri beslemeli ağ için

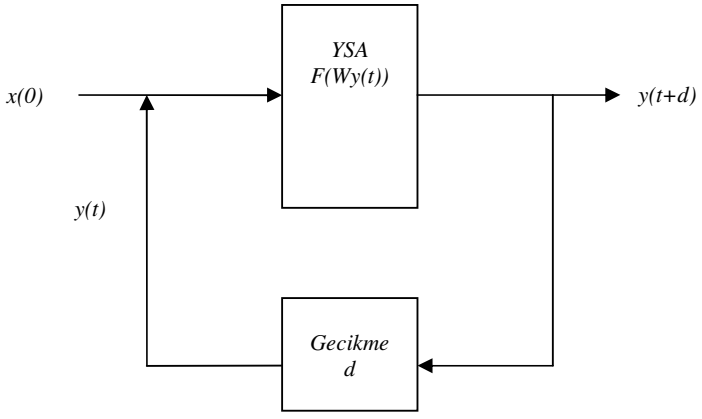
blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir (Kohonen 1988).



Şekil 3.5 İleri Beslemeli ağlar için blok diyagramı

Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 3.6'da bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundurlar. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir (Kohonen 1989, Kohonen 1990).



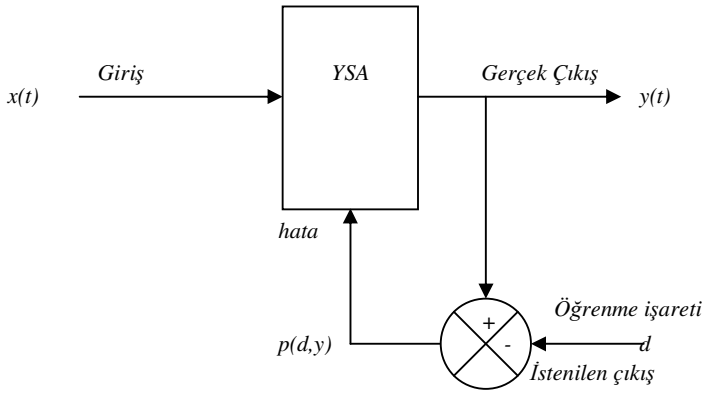
Şekil 3.6 Geri beslemeli ağ için blok diyagram

3.5.2. YSA'ların öğrenme algoritmalarına göre sınıflandırılması

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. O halde, birtakım metot ve kurallar, gözlem ve eğitime göre ağdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme kuralları aşağıda açıklanmaktadır.

Danışmanlı Öğrenme (Supervised Learning)

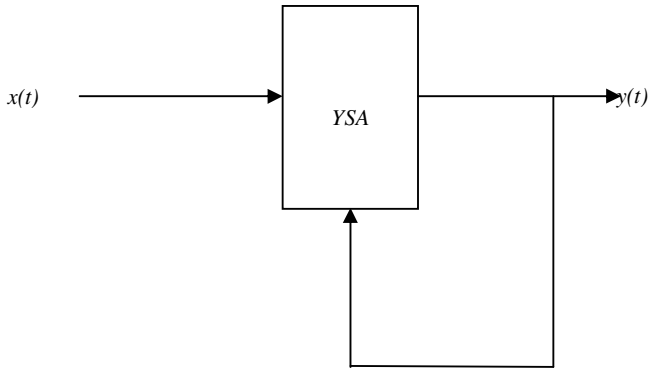
Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre İE'ler arası bağlantıların ağırlığı en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasının bir "öğretmene" veya "danışmana" ihtiyacı vardır. Şekil 3.7'de danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı (Widrow ve Hoff 1960). ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı (Rumelhart 1986) veya geri yayınma (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.



Şekil 3.7 Danışmanlı öğrenme yapısı.

Danışmansız Öğrenme (Unsupervised Learning)

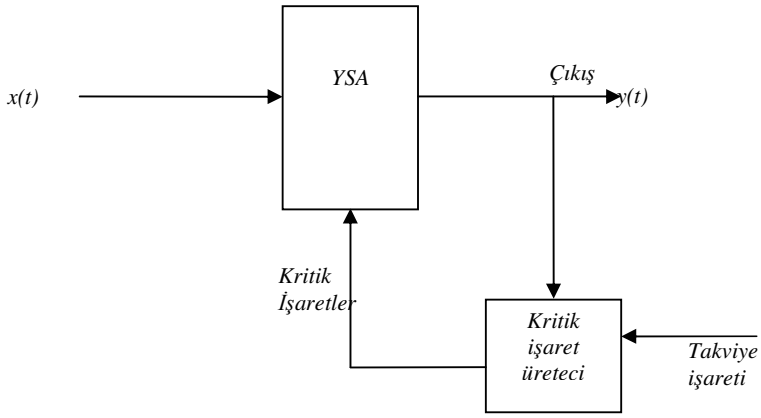
Öğretmesiz girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Şekil 3.8'de danışmansız öğrenme yapısı gösterilmiştir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir (Grossberg 1987, Kohonen 1988).



Şekil 3.8 Danışmansız öğrenme yapısı.

Takviyeli öğrenme (Reinforcement learning)

Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir metottur. Denetimsiz öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir "öğretmen" yerine, burada YSA'ya herhangi bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Şekil 3.9'de takviyeli öğrenme yapısı gösterilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya GA takviyeli öğrenmeye örnek olarak verilebilirler (Hinton ve ark. 1985).



Şekil 3.9 Takviyeli öğrenme yapısı.

3.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları

1990'lı yıllardan bugüne gelinceye kadar birçok öğrenme algoritması geliştirilmiştir. Öğrenme algoritmaları temelde üç grupta toplanmaktadır. Danışmanlı öğrenme, danışmansız öğrenme ve takviyeli öğrenme algoritmaları.

Eğiticili (supervised) öğrenmede, her bir örnekleme zamanında giriş uygulandığında sistemin arzu edilen cevabı y eğitici tarafından sağlanır. Arzu edilen çıkış *y* ile sinir ağı çıkışı *o* arasındaki fark hata ölçüsüdür ve ağ parametrelerini güncellemekte kullanılır. Ağırlıkların güncellenmesi süresince eğitici ödüllendirme-cezalandırma şemasını ağa uygulayarak hatayı azaltır. Bu öğrenme modelinde giriş ve çıkış örnekleri kümesi eğitim kümesi olarak adlandırılır.

Eğiticisiz öğrenmede, eğiticili öğrenmedeki gibi arzu edilen y çıkışları bilinmemektedir. Bu yüzden kesin bir hata bilgisini ağın davranışını değiştirmekte kullanmak mümkün değildir. Cevabın doğruluğu veya yanlışlığı hakkında bilgi sahibi olunmadığı için öğrenme, girişlerin verdiği cevaplar gözlenerek başarıya ulaşılır. Aslında eğiticisiz öğrenme demek doğru değildir, çünkü eğiticisiz öğrenme gerçekte mümkün değildir. Eğitici her öğrenme adımında dahil olmamasına rağmen, amaçları ayarlamaktadır.

Takviyeli öğrenmede, ağın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir.

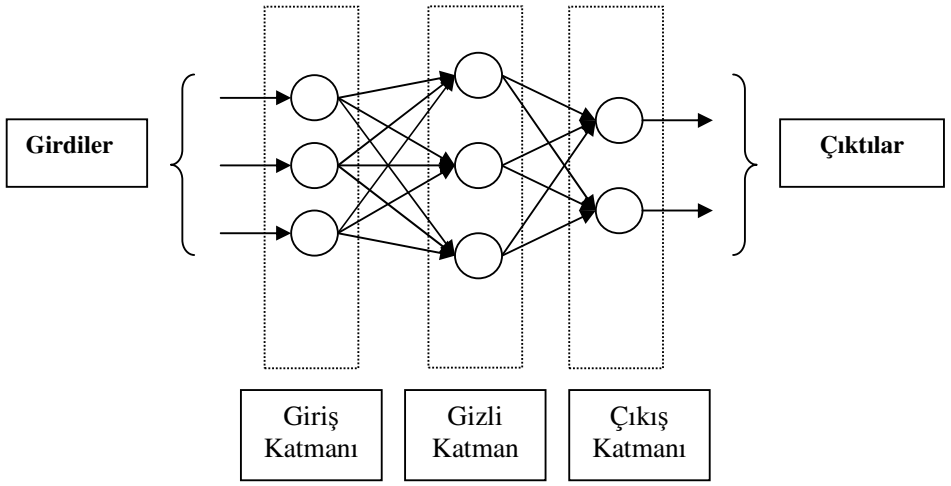
Geri yayınım algoritması eğiticili öğrenmede kullanılan en genel algoritmadır. Basit olması ve iyi bir öğrenme kapasitesine sahip olması birçok alana uygulanmasını sağlamıştır.

3.6.1. Geri yayılım öğrenme algoritması

Geri yayılım algoritması, sinir ağının eğiticili sınıfına giren genel bir algoritmadır. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata yani *e(k)*, arzu edilen çıkış (gerçek çıkış - *y(k)*) ile sinir ağının çıkışı (*o(k)*) arasındaki farktır.

$$e(k) = y(k) - o(k) \tag{3.3}$$

Aşağıdaki şekilde birçok sinir hücresinin bir birine bağlandığı ileri yönlü çok katmanlı bir yapay sinir ağı görülmektedir. Giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir, probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur.



Şekil 3.10 İleri beslemeli çok katmanlı sinir ağı (Efe 2000).

Şekildeki çok katmanlı ağı düşünürsek;

k+1. katmanda *i*. birime net giriş;

$$n^{k+1}(i) = \sum_{j=1}^{Sk} w^{k+1}(i,j) o^k(j) + b^{k+1}(i) \tag{3.4}$$

Birim *i*'nin çıkışı şöyle olacaktır.

$$o^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \tag{3.5}$$

M katmanlı bir ağ matris biçiminde ifade edilirse;

$$\underline{o}^0 = \underline{x} \tag{3.6}$$

$$\underline{o}^{k+1} = \underline{f}^{k+1}(W^{k+1}\,\underline{o}^k + \underline{b}^{k+1}) \tag{3.7}$$

$$k = 0,1,\ldots,M-1 \tag{3.8}$$

Ağın temel görevi giriş-çıkış çiftleri arasındaki ilişkiyi öğrenmektir.

$$\{(\underline{x}_1, \underline{y}_1), (\underline{x}_2, \underline{y}_2), \ldots, (\underline{x}_Q, \underline{y}_Q)\}$$

Ağın performansı şöyledir;

$$E = \frac{1}{2}\sum_{q=1}^{Q} (\underline{y}_q - \underline{o}_q^M)^T (\underline{y}_q - \underline{o}_q^M) = \frac{1}{2}\sum_{q=1}^{Q} \underline{e}_q^T \underline{e}_q \tag{3.9}$$

Buradaki o_q^M , *q.* giriş (x_q) olduğunda ağın çıkışıdır, $e_q = y_q - o_q^M$ ise *q.* girişin hatasıdır. Standart geri yayınım algoritması yaklaşık adım düşümü algoritmasını kullanır. Performans indeksiyle şöyle yaklaşılır;

$$E = \frac{1}{2} e_q^T e_q \tag{3.10}$$

burada toplam karelerin toplamı tek giriş-çıkış çifti için karesel hatayla yer değiştirilir. Yaklaşık adım (eğim) düşümü algoritması bundan sonra şöyle olur;

$$\Delta w^k(i,j) = -\alpha \frac{\partial E}{\partial w^k(i,j)} \tag{3.11}$$

$$\Delta b^k(i) = -\alpha \frac{\partial E}{\partial b^k(i)} \tag{3.12}$$

burada α öğrenme katsayısıdır, şöyle tanımlanır;

$$\delta^k(i) \equiv \frac{\partial E}{\partial n^k(i)} \tag{3.13}$$

performans indeksinin duyarlılığı *k.* katmanda *i.* birimin net girişinde değiştirilir. Şimdi (3.4), (3.10) ve (3.13) kullanılarak,

$$\frac{\partial E}{\partial w^k(i,j)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i,j)} = \delta^k(i) o^{k-1}(j) \tag{3.14}$$

$$\frac{\partial E}{\partial b^k(i)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial b^k(i)} = \delta^k(i) \tag{3.15}$$

Hassaslık yeterliği aşağıdaki tekrarlı ilişkiyle de gösterilebilir.

$$\underline{\delta}^k = \dot{F}^k(\underline{n}^k) W^{k+1} \underline{\delta}^{k+1} \tag{3.16}$$

burada;

$$\dot{F}^k(\underline{n}^k) = \begin{bmatrix} \dot{f}^k(n^k(1)) & 0 & .... & 0 \\ 0 & \dot{f}^k(n^k(2)) & ... & 0 \\ . & .. & ... & .. \\ 0 & 0 & ... & \dot{f}^k(n^k(Sk)) \end{bmatrix} \tag{3.17}$$

ve

$$f^k(n) = \frac{df^k(n)}{dn} \tag{3.18}$$

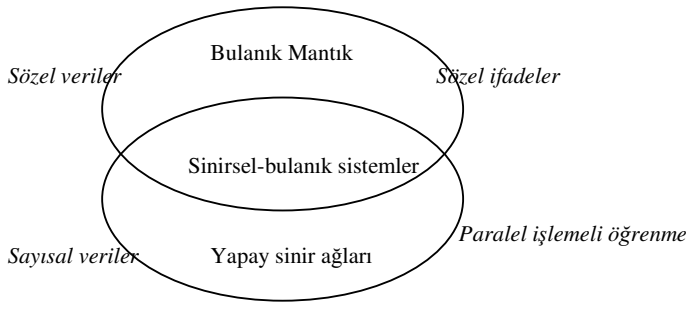
$$\underline{\delta}^{M} = -\dot{F}^{M}(\underline{n}^{M})(\underline{y}_{q} - \underline{o}_{q}) \tag{3.19}$$

Tüm öğrenme algoritmalarında şu adımlar izlenir. İlk önce (3.6)-(3.7) kullanılarak giriş ileri yönde yayılır, sonra (3.16) ve (3.19) kullanılarak geri yayılır ve son olarak ağırlıklar ve denge (3.11), (3.12), (3.14) ve (3.15) kullanılarak güncellenir (Öztemel 2003).

4. BULANIK SİNİR AĞI

Bundan önceki bölümlerde yapay sinir ağı ve bulanık mantığa ait bilgiler sunuldu. Sinir ağları veriden öğrenebilir, fakat sinir ağlarıyla sunulan bilgiyi anlamak zordur. Tersine, bulanık sistemler sözel terimler ve *"eğer-ise"* kuralları kullandıkları için kolayca anlaşılabilir ama, öğrenme algoritmaları yoktur. Tüm bunların yanı sıra sinir ağları pek çok zayıf özelliğe sahiptir. Örneğin; çok katmanlı ağ yapısında sistem bilgisi tüm ağa synaptik ağırlıklarla dağıtılmıştır. Bu yüzden, ağırlıkların anlamsal özelliklerini açıklamak zordur ve ağ sisteminde bulunan daha önceki bilgileri birleştirmek neredeyse imkansızdır. Bulanık mantık ise sistem bilgisini açıklamak için insanın anlayabileceği sözel ifadeleri kullanır. Bu özellik, sistem ve insan arasındaki kapalı bir etkileşimi mümkün kılar. Bu da arzu edilen bir durumdur (Erentürk 2002).

Sinirsel – bulanık sistemlerin amacı her iki yaklaşımında faydalarını toplayıp Şekil 4.1 de ki gibi birleştirmektir.



Şekil 4.1 Sinirsel- Bulanık sistemlerin sinir ağları ve bulanık mantıkla ilişkisi

Tablo 4.1 Bulanık sistemler ve sinir ağlarının özellikleri (Baykal 2004).

Yetenekler		Bulanık sistemler	Sinir ağları
Bilgi edinimi	Girdiler	İnsan uzmanlar	Örnek kümeler
	Araçlar	Etkileşim	Algoritmalar
Belirsizlik	Bilgi	Nicel ve nitel	Nicel
	Bilişsellik	Karar verme	Algı
Akıl yürütme	Mekanizma	Deneyimsel araştırma	Paralel bilgiişlem
	Hız	Düşük	Yüksek
Uyarlanma	Hata toleransı	Düşük	Çok yüksek
	Öğrenme	İndüksiyon	Ayarlanmış ağırlıklar
Doğal dil	Gerçekleştirme	Açık	Gizli
	Esneklik	Yüksek	Düşük

Bulanık mantık ile sinir ağlarının bütünleştirilmesi için pek çok araştırma yapılmıştır. Genel olarak halen bulanık sinirsel bulanık sistem oluşturmada iki yaklaşım söz konusudur.

1. Sinirsel-bulanık sistemler (Neural-fuzzy inference system)
2. Bulanık sinir ağı (Fuzzy neural networks)

Sinirsel-Bulanık sonuçlandırma sistemleri, yapay sinir ağı kavramlarıyla bulanık mantık sonuç sistemlerinin birleştirilmesinden doğmuştur. Her iki sistemin birleşimi olduğu için oluşturulan bu yeni sistemin mimarisi de paraleldir.

Bulanık sinir ağlarında, bulanık ifadeler sinir ağları ile birleştirilmiştir. Bulanık sinir ağları, bulanık sonuçlandırmanın sinir ağı prensiplerine uygulandığı sistemlerdir. Bu sistemler yalın haldeki bulanık denetleyicilerden daha iyi çalışırlar. Bu tip bulanık denetleyiciler, bir problem için üyelik fonksiyonlarının düzenlenmesi ve bulanık kuralların otomatik olarak yapılabilmesi bakımından pek çok avantaja sahiptirler.

Bulanık sinir ağı yapısının haricinde Jang tarafından önerilen Sinirsel-bulanık sistem yapısı (Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi- Adaptif Neuro Fuzzy Inference System) da mevcuttur. Bu yapı bulanık sonuçlandırma sistemine

adaptif sinir ağı uygulanması ile elde edilir. Bu yapı temelde Sugeno tarafından önerilen bulanık sonuçlandırma yapısının adaptif ağ yapısında sinir ağlarına uygulanmış şeklidir.

4.1. ANFIS (Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi) Mimarisi

Açık olarak uyarlamalı ağlara dayanan bulanık çıkarım sistemi veya uyarlamalı sinirsel bulanık çıkarım sistemi anlamına gelen ANFIS ismi, Adaptive Network-based Fuzzy Inference System veya Adaptive Neuro Fuzzy Inference System olan özgün adının baş harflerinden oluşmuştur.

Esasen ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur (Tsoukalas ve Uhrig, 1996).

Aslında bulanık çıkarım sistemi çok katmanlı perceptrona göre daha kuvvetlidir. Örnek olarak ANFIS denetleyicilerin özellikleri tanımlanabilir:

1. Öğrenme yeteneği
2. Paralel işlem
3. Yapılandırılmış bilgi temsili
4. Diğer denetim tasarım yöntemleriyle daha iyi bütünleşme

Basit olması açısından, bulanık çıkarım sistemini, x ve y gibi iki girişi ve z gibi bir çıkışı olduğunu farz ederek ele alalım. İki tane bulanık Eğer-O Halde kuralı bulunan birinci dereceden Sugeno bulanık modeli için tipik kural kümesi;

Kural-1: Eğer x *A1* ise ve y *B1* ise O Halde $f1 = p1\,x + q1\,y + r1$

Kural-2: Eğer x *A2* ise ve y *B2* ise O Halde $f2 = p2\,x + q2\,y + r2$

şeklinde ifade edilir. Şekil 4.2a bu Sugeno bulanık modeli için bulanık akıl yürütme mekanizmasını göstermektedir. Bu yapıya karşılık gelen eşdeğer ANFIS mimarisi Şekil 4.2b'de gösterildiği gibidir. Söz konusu bu ANFIS mimarisi için aynı katmanda bulunan düğümler, aşağıda da gösterildiği üzere aynı düğüm fonksiyonlarına sahiptirler. (Burada *l.* katmandaki *i.* düğümün çıkışı $O_{l,i}$ şeklinde belirtilmiştir.)

Katman-1

Bu katmanda yer alan her bir *i* düğümü, çıkışı aşağıdaki gibi tanımlanan, adaptif bir düğümdür.

$O_{l,i} = \mu A_i(x)$, i=1,2, yada (4.1)

$O_{l,i} = \mu B_{i-2}(x)$, i=3,4, için

Burada x (ya da y) düğümün girişini, A_i (ya da B_{i-2}) ise söz konusu düğüme ait bulanık kümeyi ifade etmektedir.

Bir başka ifadeyle, bu katmanın çıkışları, kuralların şart ya da öncül kısımlarına ait üyelik değerlerini oluştururlar. Burada A_i ve B_i için söz konusu üyelik fonksiyonları uygun bir biçimde parametrelendirilmiş herhangi bir üyelik fonksiyonu olabilir. Örneğin A_i aşağıda belirtilen genelleştirilmiş çan eğrisi fonksiyonu ile ifade edilebilir.

$$\mu_A(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{bi}} \tag{4.2}$$

Burada yer alan $\{a_i,\ b_i,\ c_i\}$ kümesi parametre kümesidir. Bu katmanın parametreleri, şart ya da giriş parametreleri olarak ifade edilirler.

Katman-2

Bu katmandaki her bir düğüm, kendisine gelen sinyallerin çarpımını çıkış olarak üreten, Π ile etiketlenmiş sabit bir düğümdür. Örneğin ;

$$O_{2,i} = w_i = \mu_{Ai}(x) \times \mu_{Bi}(y), \qquad i = 1,2 \tag{4.3}$$

Her bir düğümün çıkışı, her bir kural için gerçekleme derecesini oluşturur. (3) no'lu bağıntıda çarpma işlemi yerine bulanık (VE) işlemini icra eden, başka T-norm işlemleri de düğüm fonksiyonu gibi kullanılabilirler.

Katman-3

3. katmanda yer alan her bir düğüm, *N* ile etiketlenmiş, sabit bir düğümdür. Katmandaki *i*. düğüm, *i*. kuralın gerçekleme derecesinin, bütün kuralların gerçekleme dereceleri toplamına oranını hesaplar.

$$O_{3,i} = \overline{w_i} = \frac{w_i}{w_1 + w_2}, \qquad i = 1,2. \tag{4.4}$$

Bu katmanda yer alan düğümlerin çıkışları, hesaplanışlarına uygun olarak, normalize edilmiş gerçekleme dereceleri olarak adlandırılırlar.

Katman-4

Bu katmana ait her *i* düğümü, düğüm fonksiyonu aşağıdaki gibi olan adaptif bir düğümdür.

$$O_{4,i} = \overline{w_i} f_i = \overline{w_i}(p_i x + q_i y + r_i) \tag{4.5}$$

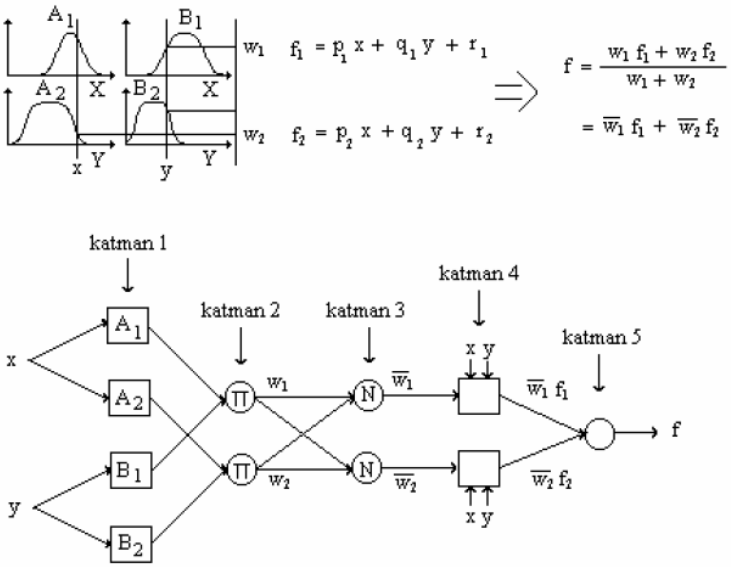
Burada $\overline{w_i}$, katman 3'ün çıkışı olup, $\{p_i, q_i, r_i\}$ ise bu katmanda bulunan düğümlerin parametrelerinden oluşan, parametre kümesidir. Bu katmanın parametreleri, sonuç ya da çıkış parametreleri olarak ifade edilecektir.

Katman-5

Son katman olan 5. katmanda, Σ ile etiketlenmiş olan ve toplam çıkışı hesaplamak üzere kendisine gelen sinyallerin tümünü toplayan sabit tek bir düğüm yer alır.

$$O_{5,i} = toplam\, cikis = \sum_i \overline{w_i} f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \tag{4.6}$$

Böylece, tamamıyla Sugeno bulanık modelinin işleyişine sahip, adaptif bir ağ yapısı inşa edilmiş olur (Jang, 1993, Yıldırım 2004).



Şekil 4.2 (a) Birinci dereceden iki girişli ve iki kurallı "Sugeno Bulanık Modeli" ; (b) Eşdeğer ANFIS yapısı.

4.2. ANFIS Ağında Kullanılan Hibrid Öğrenme Algoritması

Kimliklendirmede kullanılan ANFIS ağına ait parametrelerin güncellenmesinde, iki aşamalı bir öğrenme algoritması olan, hibrid öğrenme algoritması kullanılmıştır. Hibrid öğrenme algoritmasında, ANFIS ağ yapısına ait parametreler, giriş ve çıkış parametreleri olarak iki kısımda ele alınır. Toplam parametre kümesi; S=*S1*+ *S2* şeklinde ifade edilecek olursa, *S1* giriş parametrelerine, *S2* de çıkış parametrelerine karşılık gelir. Hibrid algoritmanın ilk aşaması ya da ileri yön geçişi ile ANFIS ağına ait giriş parametreleri, ikinci aşamada yada geri yön geçişinde ise ağın sonuç parametreleri güncellenir. Hibrid öğrenme algoritmasının ileri yön geçişini oluşturan ve en küçük kareler tahmini (LSE) yöntemi kullanılmak suretiyle gerçekleştirilen kısmında, ağın girişindeki üyelik fonksiyonlarına ait parametreler ya da kısaca *S1* ile belirtilen giriş parametreleri sabit tutulur. Böylece ağın çıkışı, *S2* parametre kümesi içinde bulunan çıkış parametrelerinin, lineer bir kombinasyonu haline gelir. Modellenecek sisteme ait *P* adet giriş-çıkış verisi ya da

eğitim verisi ile *S1* giriş parametrelerinin verilen değerleri kullanılarak ağın çıkışı matris formunda,

$$A\theta = B \tag{4.7}$$

şeklinde ifade edilebilir. Matrisel eşitlikte yer alan θ vektörü, *S2* çıkış parametrelerinin elemanlarından oluşan, bilinmeyen vektördür. Bu denklem, standart lineer en küçük-kareler (least-squares) problemini gösterir ve θ için en iyi çözüm, $\|A\theta = B\|^2$ nın minimum değeri olan en küçük kareler tahmini (LSE) θ^*dır.

$$\theta^* = (A^T A)^{-1} A^T B \tag{4.8}$$

Burada A^T, A matrisinin transpozesi ise ve eğer $A^T A$ tekil değilse, $(A^T A)^{-1} A^T$, A'nın sahte inversidir. Bunun yerine, tekrarlı olarak (LSE) formülü de kullanılabilir. Özel olarak denklem (7)'deki A matrisinin *i*. satırı a_i^T ile B matrisinin *i*. elemanı b_i^T ile gösterilsin. Bu taktirde θ vektörü, iteratif olarak aşağıdaki gibi hesaplanabilir.

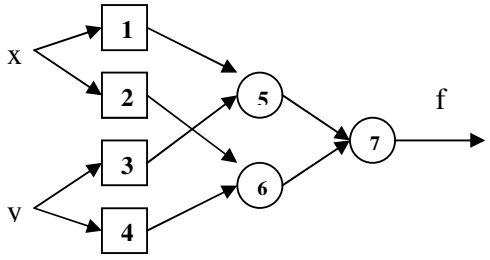
$$\theta_{i+1} = \theta_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T \theta_i) \tag{4.9}$$

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}} \qquad , i = 0,1.....,P-1 \tag{4.10}$$

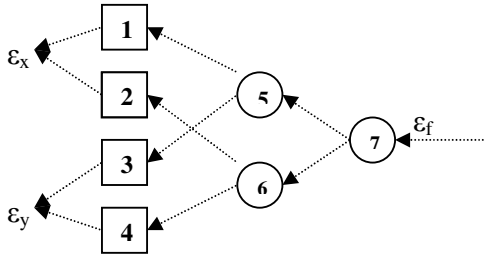
Burada en küçük kareler tahmini θ^*, θ_P' ye eşittir. (9) no' lu denklemde ihtiyaç duyulan başlangıç şartları şunlardır; $\theta_0=0$ ve $S_0 = \gamma I$. Burada γ, pozitif büyük bir sayı, I ise MxM boyutunda birim matristir. Hibrid öğrenme algoritmasının geri yön geçişinde, *S2* çıkış parametreleri sabit tutulur ve ağın çıkışındaki hata sinyali geriye doğru yayılarak, eğim düşümü yöntemiyle giriş parametreleri güncellenir. Geri yön geçişinde giriş parametreleri için güncelleme formülü aşağıdaki gibidir;

$$\Delta\alpha = -\eta \frac{\partial E}{\partial \alpha} \tag{4.11}$$

Burada α herhangi bir giriş parametresini, η öğrenme oranını, E ise ağın çıkışındaki hata değerini göstermektedir (Jang ve Sun, 1995).



(a)



(b)

Şekil 4.3 Sinirsel bulanık sistemin akış şeması (a) Adaptif bir ağ yapısı, (b) Hatanın iletimi ve ağın eğitimi

Sinirsel bulanık sistemin yapısındaki parametrelerin değişimi Tablo 4.2 de belirtilmiştir.

Tablo 4.2 Sinirsel-bulanık sistem yapısındaki parametreler ve işaretler

	İleri Yön	Geri yön
Varsayım parametreleri	Değişme yok	Delta kuralı
Sonuç parametreleri	En küçük kareler yöntemi	Değişme yok
İletilen işaretler	Düğüm çıkışları	Hata işareti

4.3. ANFIS Ağında Kullanılan Geri Yayılımlı Öğrenme Algoritması

Geri yayılımlı öğrenme algoritmasında ağın çıkışından elde edilen hata değeri giriş katmanına kadar geriye doğru yansıtılarak gerekli ağırlık değişkenlerinin ayarlanması gerçekleştirilir. Amaç *E* hata ölçütünü öğrenme işlemi sonunda bütün giriş örnekleri için sıfıra götürmektir. Ağın çıkışında hata, istenen değer *d* ile gerçek çıkış *f* arasındaki farktır ve (4.12)'de ki gibi ifade edilir.

$$e=d-f \tag{4.12}$$

Bu hata değerine en küçük kareler yöntemi uygulanarak hata ölçütü *E* aşağıda verildiği gibi hesaplanır.

$$E=\frac{1}{2}e^2 \tag{4.13}$$

Hata ölçütü kullanılarak hata geriye doğru katman katman aşağıdaki gibi yansıtılır.

Katman 5

Bu katmanda herhangi bir ağırlık değeri ayarlaması yoktur, sadece çıkıştaki hatanın katman çıkışına yansıması hesaplanır,

$$\delta^5=-\frac{\partial E}{\partial f}=-\left[\frac{\partial E}{\partial e}\frac{\partial e}{\partial f}\right]=e \tag{4.14}$$

Katman 4

Bu katmanda p_i, q_i ve r_i sonuç değişkenlerinin ayarlanması için gerekli hesaplamalar gerçekleştirilir.

$$\Delta p_i=-\frac{\partial E}{\partial p_i}=\left[-\frac{\partial E}{\partial f}\right]\left[\frac{\partial f}{\partial p_i}\right] \tag{4.15}$$

$$f=\sum_i \overline{\mu_i}(p_i x+q_i y+r_i) \quad i=1,2 \tag{4.16}$$

$$\frac{\partial f}{\partial p_i}=\overline{\mu_i}x \tag{4.17}$$

Buradan,

$$\Delta p_i = \delta^5 \overline{\mu}_i x \tag{4.18}$$

Aynı işlemler diğer sonuç değişkenlerine de uygulanarak değişimler hesaplanır. Buna göre,

$$\Delta q_i = \delta^5 \overline{\mu_i} y \tag{4.19}$$

$$\Delta r_i = \delta^5 \overline{\mu_i} \tag{4.20}$$

olur. Elde edilen bu ifadelere öğrenme oranı eklenerek üçgen (delta) kuralı uygulanır. n=$\{p,q,r\}$ olarak alınırsa bu ifadeler tek bir eşitlik olarak aşağıdaki gibi gösterilir.

$$n_i(k+1) = n_i(k) + \eta_n \Delta n_i(k+1) \tag{4.21}$$

Katman 3

Bu katmanda çıkış katmanından yansıyan hata değeri hesaplanır, herhangi bir ağırlık hesaplaması yoktur,

$$\delta_i^4 = -\frac{\partial E}{\partial \overline{\mu}_i} = \left[-\frac{\partial E}{\partial f} \right] \left[\frac{\partial f}{\partial \overline{\mu}_i} \right] \quad i = 1,2 \tag{4.22}$$

$$f = \sum_i \overline{\mu_i} f_i \tag{4.23}$$

$$\frac{\partial f}{\partial \overline{\mu_i}} = f_i \tag{4.24}$$

$$\delta_i^3 = \delta^5 f_i \tag{4.25}$$

Katman 2

Bu katmanda çıkış katmanından yansıyan hata değeri hesaplanır herhangi bir ağırlık hesaplaması yoktur,

$$\delta_i^2 = -\frac{\partial E}{\partial \overline{\mu}_i} = \left[-\frac{\partial E}{\partial f} \frac{\partial f}{\partial \overline{\mu}_i} \right] \left[\frac{\partial \overline{\mu_i}}{\partial \mu_i} \right] \quad i = 1,2 \tag{4.26}$$

$\overline{\mu_i} = \dfrac{\mu_i}{\sum_i \mu_i}$, bu ifade de $\alpha = \sum_i \mu_i$ olarak alınırsa,

$$\left[\frac{\partial\overline{\mu_i}}{\partial\mu_i}\right]=\left[\frac{\alpha-\mu_i}{\alpha^2}\right] \tag{4.27}$$

olarak bulunur. Bu ifade (4.26)'da yerine koyularak aşağıdaki son durum elde edilir.

$$\delta_i^2=\delta_i^3\left[\frac{\alpha-\mu_i}{\alpha^2}\right] \tag{4.28}$$

Katman 1

Bu katmanda hem hata değeri hem de giriş üyelik işlevlerine ait değişkenlerin ayarlanması gerçekleştirilir.

$$\delta_i^1=-\frac{\partial E}{\partial\mu_{Ai}}=-\left[\frac{\partial E}{\partial f}\frac{\partial f}{\partial\overline{\mu_i}}\frac{\partial\overline{\mu_i}}{\partial\mu_i}\right]\left[\frac{\partial\mu_i}{\partial\mu_{Ai}}\right]\quad i=1,2 \tag{4.29}$$

$$\frac{\partial\mu_i}{\partial\mu_{Ai}}=\mu_{Bi} \tag{4.30}$$

$$\delta_i^1=\delta_i^2\mu_{Bi} \tag{4.31}$$

$$\delta_{i+2}^1=-\frac{\partial E}{\partial\mu_{Bi}}=-\left[\frac{\partial E}{\partial f}\frac{\partial f}{\partial\overline{\mu_i}}\frac{\partial\overline{\mu_i}}{\partial\mu_i}\right]\left[\frac{\partial\mu_i}{\partial\mu_{Bi}}\right]\quad i=1,2 \tag{4.32}$$

$$\frac{\partial\mu_i}{\partial\mu_{Bi}}=\mu_{Ai} \tag{4.33}$$

$$\delta_{i+2}^1=\delta_i^2\mu_{Ai} \tag{4.34}$$

Bu katmanda kullanılan üyelik işlevlerinin değerleri aşağıdaki gibi hesaplanır,

$$\mu_{Ai}=\exp\left[-\left(\frac{x-m_i}{\sigma_i}\right)^2\right]\quad v_i=-\left[\frac{x-m_i}{\sigma_i}\right]^2\quad \mu_{Ai}=\exp[v_i] \tag{4.35}$$

Çan eğrisi şekilli üyelik işlevlerinin orta noktalarındaki değişim aşağıdaki gibi hesaplanır.

$$\Delta m_i=-\frac{\partial E}{\partial m_i}=-\left[\frac{\partial E}{\partial f}\frac{\partial f}{\partial\overline{\mu_i}}\frac{\partial\overline{\mu_i}}{\partial\mu_i}\frac{\partial\overline{\mu_i}}{\partial\mu_{Ai}}\right]\left[\frac{\partial\mu_{Ai}}{\partial v_i}\frac{\partial v_i}{\partial m_i}\right]\quad i=1,2 \tag{4.36}$$

$$\frac{\partial \mu_{Ai}}{\partial v_i} = \exp[v_i] = \mu_{Ai} \tag{4.37}$$

$$\frac{\partial v_i}{\partial m_i} = 2\left[\frac{x - m_i}{\sigma_i^2}\right]$$

$$\Delta m_i = 2\left[\frac{x - m_i}{\sigma_i^2}\right]\delta_i^2 \mu_{Ai} \qquad \delta_i^2 = \delta_i^3 \mu_{Bi}$$

$$\Delta m_i = 2\left[\frac{x - m_i}{\sigma_i^2}\right]\delta_i^3 \mu_{Ai}\mu_{Bi} \qquad \mu_i = \mu_{Ai}\mu_{Bi}$$

$$\Delta m_i = 2\left[\frac{x - m_i}{\sigma_i^2}\right]\delta_i^3 \mu_i \tag{4.38}$$

Aynı şekilde Δm_{i+2} aşağıdaki şekilde elde edilir.

$$\Delta m_{i+2} = 2\left[\frac{x - m_{i+2}}{\sigma_{i+2}^2}\right]\delta_i^3 \mu_i \tag{4.39}$$

Çan eğrisi şekilli üyelik işlevlerinin standart sapmalarındaki değişim aşağıdaki gibi hesaplanır,

$$\Delta\sigma_i = -\frac{\partial E}{\partial \sigma_i} = -\left[\frac{\partial E}{\partial f}\frac{\partial f}{\partial \overline{\mu_i}}\frac{\partial \overline{\mu_i}}{\partial \mu_i}\frac{\partial \overline{\mu_i}}{\partial \mu_{Ai}}\right]\left[\frac{\partial \mu_{Ai}}{\partial v_i}\frac{\partial v_i}{\partial \sigma_i}\right] \quad i = 1,2 \tag{4.40}$$

$$\frac{\partial v_i}{\partial \sigma_i} = 2\left[\frac{(x - m_i)^2}{\sigma_i^3}\right] \tag{4.41}$$

$$\Delta\sigma_i = 2\left[\frac{(x - m_i)^2}{\sigma_i^3}\right]\delta_i^3 \mu_i \tag{4.42}$$

Aynı şekilde $\Delta\sigma_{i+2}$ aşağıdaki şekilde elde edilir,

$$\Delta\sigma_{i+2} = 2\left[\frac{(y - m_{i+2})^2}{\sigma_{i+2}^3}\right]\delta_i^3 \mu_i \tag{4.43}$$

Elde edilen bu değişimlere üçgen kuralı uygulanarak üyelik işlevine ait değişkenlerin ayarlanması aşağıdaki şekilde gerçekleştirilir.

$$m_i(k+1) = m_i(k) + \eta_m \Delta m_i(k+1) \qquad \text{i=1,2,3,4} \tag{4.44}$$

$$\sigma_i(k+1) = \sigma_i(k) + \eta_m \Delta \sigma_i(k+1)$$

toplam olarak sekiz değişken ayarlanmaktadır (Elmas 2003).

5. TORNALAMADA KESME KUVVETLERİ VE SICAKLIĞIN YAPAY ZEKA TEKNİKLERİYLE TAHMİN EDİLMESİ

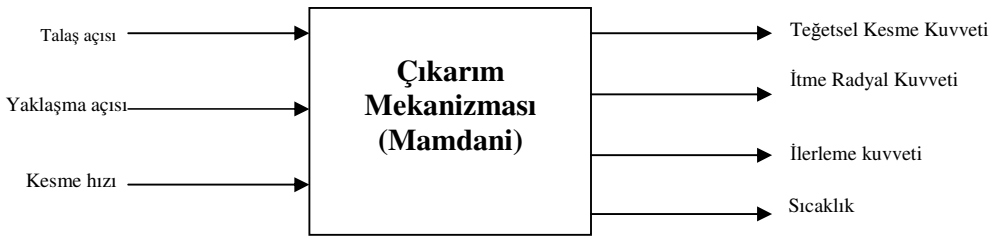
5.1. Bulanık Uzman Sistem (BUS) ile Tahmin Etme

Çalışmada kullanılan kesme kuvveti ve sıcaklık değerleri yapılmış olan bir talaşlama çalışmasından alınmıştır. Bu çalışmada; tornalamada talaş açısı (γ), yaklaşma açısı (χ), kesme hızı (v) girişlerine göre teğetsel kesme kuvveti (F_t), itme radyal kuvvet (F_λ), ilerleme kuvveti (F_f) ve sıcaklık (T) değerini hesaplayan çok girişli-çok çıkışlı bir bulanık uzman sistem tasarlanmış ve Matlab Fuzzy Toolbox programı yardımıyla sonuçlar hesaplanmıştır. Deneysel verilerle bulanık uzman sistem sonuçları karşılaştırılarak değerlendirmeler yapılmıştır.

Parametrelerin sınır değerleri aşağıdaki gibidir.

Talaş açısı (γ)=[0-20], yaklaşma açısı (χ)=[45-90], kesme hızı (v)=[75-236 m/min]'dır.

Teğetsel kesme kuvveti (F_t)=[302-520 N], radyal kuvvet (F_λ)=[24-372 N] , ilerleme kuvveti (F_f)=[60-379 N], sıcaklık (T)=[322-495 ^{o}C]'dır.



Şekil 5.1 Geliştirilen Bulanık Uzman Sistemin Genel Şeması

5.1.1. Bulanıklaştırma

Bir uzmandan da yardım alınarak BUS'da kullanılan parametrelerin bulanıklaştırılması aşağıdaki şekilde dilsel ifadeler yapılmıştır.

Talaş açısı, yaklaşma açısı ve kesme hızı girdi değişkenlerinin sırası ile γ={0,6,12,20}, χ={45,60,75,90} ve v={75,113,160,236} dört adet değerden oluşmasından dolayı giriş parametreleri dört dilsel ifadeye ayrılmıştır. Giriş parametreleri için aşağıdaki dilsel ifadeler kabul edilmiştir.

Talaş açısı (γ); Düşük (D), Negatif Orta(NO), Pozitif Orta(PO), Yüksek (Y)

Yaklaşma açısı (χ); Düşük (D), Negatif Orta(NO), Pozitif Orta(PO), Yüksek (Y)

Kesme hızı (v) ; Düşük (D), Negatif Orta(NO), Pozitif Orta(PO), Yüksek (Y)

Teğetsel kesme kuvveti [302-520 N], radyal kuvvet [24-372 N] , ilerleme kuvveti [60-379 N], sıcaklık [322-495 ^{o}C] çıktı değişkenlerinin sınır değerleri arasındaki farkın büyük olması ve giriş parametrelerinin yeteri kadar dilsel ifadeye ayrılamamasından dolayı daha hassas bir sonuca ulaşabilmek için teğetsel kesme kuvveti, ilerleme kuvveti ve sıcaklık on üç dilsel ifadeye, radyal kuvvet ise sınır değerleri arasında ki fark daha yüksek olduğu için on dokuz dilsel ifadeye ayrılmıştır. Çıkış parametreleri için aşağıdaki dilsel ifadeler kabul edilmiştir.

Teğetsel kesme kuvveti (F_{c-m}); Çok çok çok düşük (ÇÇÇD) ,Çok çok düşük(ÇÇD), Çok düşük (ÇD), Düşük (D), Çok düşük orta (ÇDO), Düşük orta(DO), Orta (O), Yüksek orta(YO), Çok yüksek orta(ÇYO), Yüksek (Y), Çok yüksek (ÇY), Çok çok yüksek(ÇÇY), Çok çok çok yüksek (ÇÇÇD)

İlerleme kuvveti (F_f); Çok çok çok düşük (ÇÇÇD) ,Çok çok düşük(ÇÇD), Çok düşük (ÇD), Düşük (D), Çok düşük orta (ÇDO), Düşük orta(DO), Orta (O), Yüksek orta(YO), Çok yüksek orta(ÇYO), Yüksek (Y), Çok yüksek (ÇY), Çok çok yüksek(ÇÇY), Çok çok çok yüksek (ÇÇÇD)

Radyal kuvvet (F_t); Çok düşük (ÇD), Pozitif Düşük(PD), Düşük (D), Negatif Düşük(ND), Çok Düşük Orta (ÇDO), Pozitif düşük orta (PDO), Düşük orta (DO), Negatif düşük orta(NDO), Negatif orta (NO), Orta (O), Pozitif Orta (PO), Negatif

yüksek orta(NYO), Yüksek orta (YO), Pozitif yüksek orta(PYO), Çok yüksek orta (ÇYO), Negatif Yüksek (NY), Yüksek (Y), Pozitif Yüksek (PY), Çok yüksek (ÇY)

Sıcaklık (T); Çok çok çok düşük (ÇÇÇD) ,Çok çok düşük(ÇÇD), Çok düşük (ÇD), Düşük (D), Çok düşük orta (ÇDO), Düşük orta(DO), Orta (O), Yüksek orta(YO), Çok yüksek orta(ÇYO), Yüksek (Y), Çok yüksek (ÇY), Çok çok yüksek(ÇÇY), Çok çok çok yüksek (ÇÇÇD)

Bulanık dilsel parametrelerin matematiksel ifadeleri aşağıdaki gibi bulunmuştur.

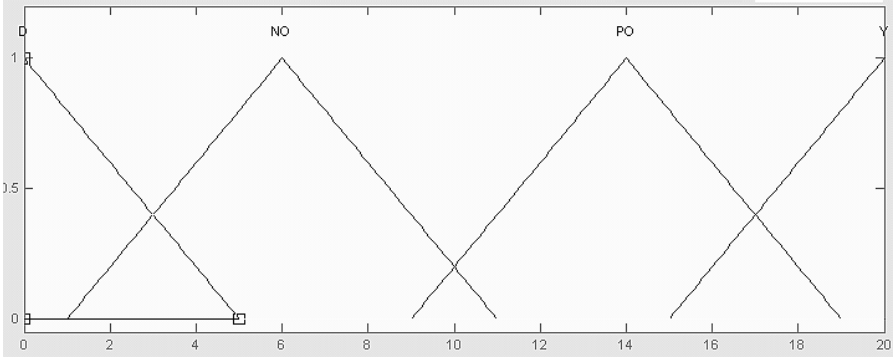
Talaş açısı (γ) giriş değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_\gamma(x)$ talaş açısının bulanık küme üyelik derecesi, x talaş açısı bulanık kümesinin elemanıdır.

$$\mu_{dusuk}(x)=\begin{cases}\dfrac{5-x}{5}; & 0\le x<5\\ 0 \quad ; & diger\ durumlar\end{cases} \tag{5.1}$$

$$\mu_{NegatifOrta}(x)=\begin{cases}\dfrac{x-1}{5}; & 1<x\le 6\\ \dfrac{11-x}{5}; & 6<x<11\\ 0 \quad ; & diger\ durumlar\end{cases} \tag{5.2}$$

$$\mu_{pozitif\ orta}(x)=\begin{cases}\dfrac{x-9}{5}; & 9<x\le 14\\ \dfrac{19-x}{5}; & 14<x<19\\ 0 \quad ; & diger\ durumlar\end{cases} \tag{5.3}$$

$$\mu_{yuksek}(x)=\begin{cases}\dfrac{x-15}{5}; & 15<x\le 20\\ 0 \quad ; & diger\ durumlar\end{cases} \tag{5.4}$$



Şekil 5.2 Talaş açısının üyelik fonksiyon grafiği

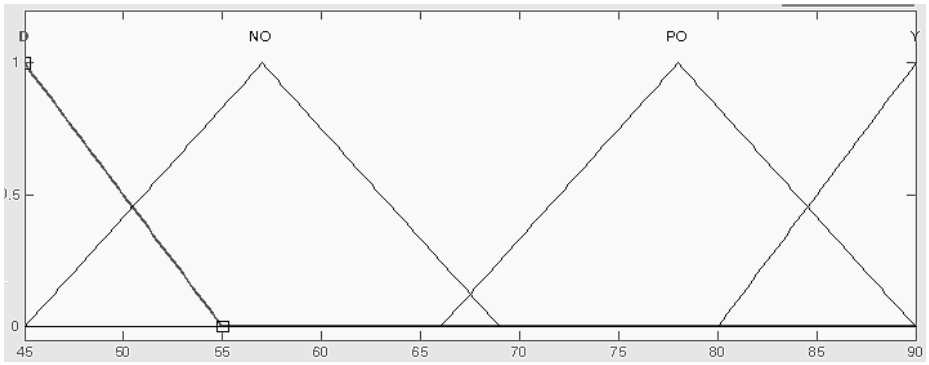
Yaklaşma açısı (χ) giriş değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_{\chi}(y)$ talaş açısının bulanık küme üyelik derecesi, y yaklaşma açısı bulanık kümesinin elemanıdır.

$$\mu_{dusuk}(y) = \begin{cases} \dfrac{55-y}{10}; & 45 < y \le 55 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.5}$$

$$\mu_{NegatifOrta}(y) = \begin{cases} \dfrac{y-45}{12}; & 45 < y \le 57 \\ \dfrac{69-y}{12}; & 57 < y \le 69 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.6}$$

$$\mu_{pozitif\ orta}(y) = \begin{cases} \dfrac{y-66}{12}; & 66 < y \le 78 \\ \dfrac{90-y}{12}; & 78 < y \le 90 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.7}$$

$$\mu_{yuksek}(y) = \begin{cases} \dfrac{y-80}{10}; & 80 < y \le 90 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.8}$$



Şekil 5.3 Yaklaşma açısı üyelik fonksiyon grafiği

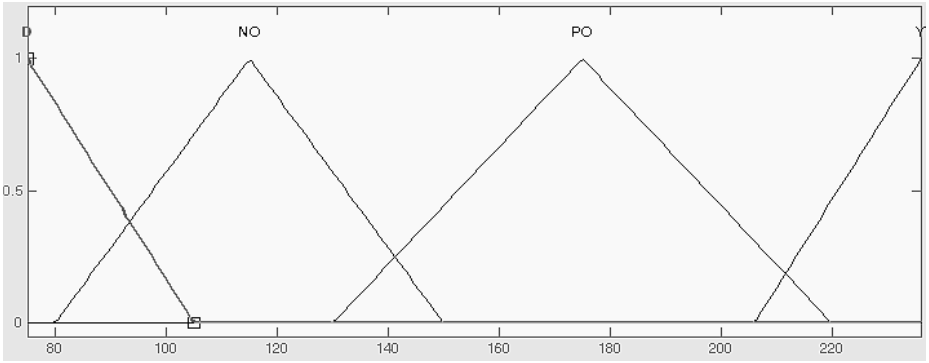
Kesme hızı (v) giriş değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_v(z)$ talaş açısının bulanık küme üyelik derecesi, z kesme hızı bulanık kümesinin elemanıdır.

$$\mu_{dusuk}(z) = \begin{cases} \dfrac{105-z}{30}; & 75 < z \le 105 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.9}$$

$$\mu_{NegatifOrta}(z) = \begin{cases} \dfrac{z-80}{35}; & 80 < z \le 115 \\ \dfrac{150-z}{35}\ ; & 115 < z \le 150 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.10}$$

$$\mu_{pozitif\ orta}(z) = \begin{cases} \dfrac{z-130}{45}; & 130 < z \le 175 \\ \dfrac{220-z}{45}\ ; & 175 < z \le 220 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.11}$$

$$\mu_{yuksek}(z) = \begin{cases} \dfrac{z-206}{30}; & 206 < z \le 236 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.12}$$

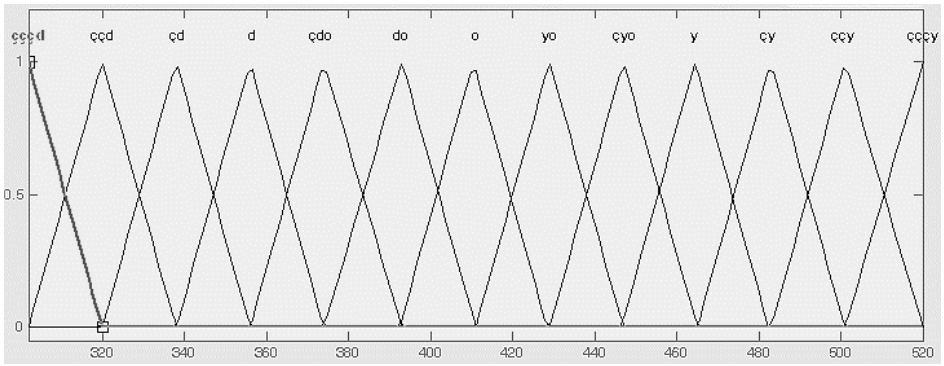


Şekil 5.4 Kesme hızı üyelik fonksiyon grafiği

Teğetsel kesme kuvveti (F_t) çıkış değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_{Ft}(t)$ talaş açısının bulanık küme üyelik derecesi, t teğetsel kesme kuvveti bulanık kümesinin elemanıdır.

$$\mu_{cccd}(t) = \begin{cases} \dfrac{320-t}{18}; & 302 < t \le 320 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.13}$$

Diğer üyelik dereceleri fonksiyonları bu şekilde hesaplanabilir.

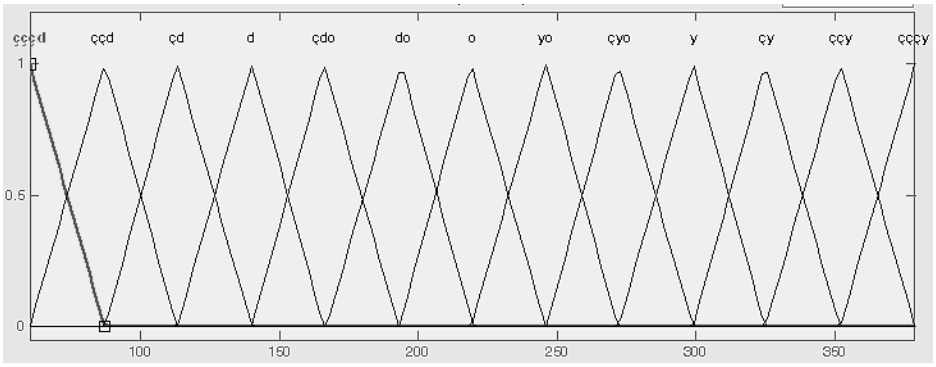


Şekil 5.5 F_t kuvveti üyelik fonksiyon grafiği

İlerleme kuvveti (F_f) çıkış değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_{Ff}(k)$ talaş açısının bulanık küme üyelik derecesi, k ilerleme kuvveti bulanık kümesinin elemanıdır.

$$\mu_{cccd}(k) = \begin{cases} \dfrac{87-k}{27}; & 60 < k \le 87 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.14}$$

Diğer üyelik dereceleri fonksiyonları bu şekilde hesaplanabilir.

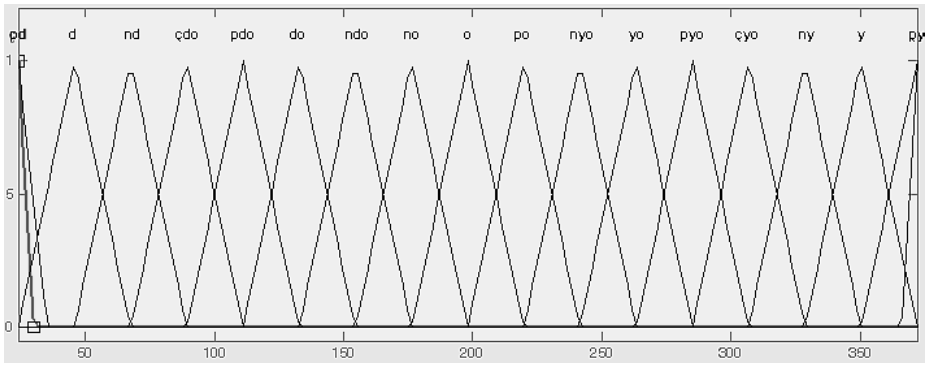


Şekil 5.6 F_f kuvveti üyelik fonksiyon grafiği

Radyal kuvvet (F_λ) çıkış değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_{F\lambda}(l)$ talaş açısının bulanık küme üyelik derecesi, l radyal kuvveti bulanık kümesinin elemanıdır.

$$\mu_{cd}(l) = \begin{cases} \dfrac{30-l}{6}; & 24 < l \le 30 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.15}$$

Diğer üyelik dereceleri fonksiyonları bu şekilde hesaplanabilir.

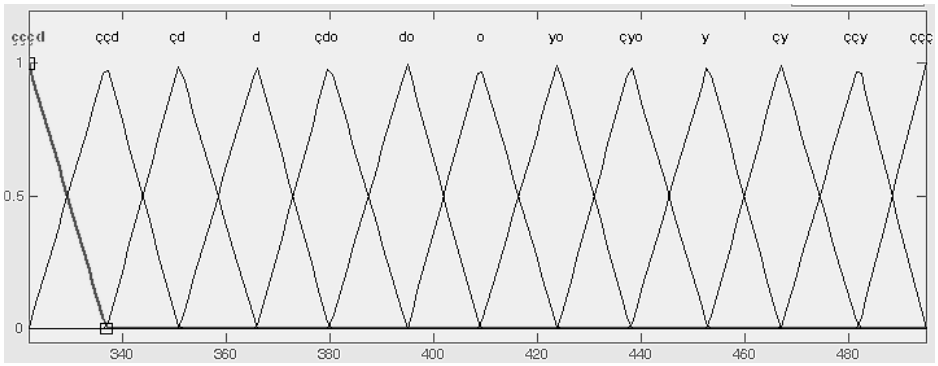


Şekil 5.7 F_{λ} kuvveti üyelik fonksiyon grafiği

Sıcaklık (T) çıkış değişkeninin dilsel ifadeleri belirlenmiş ve fonksiyonları aşağıda sırasıyla oluşturulmuştur. Burada $\mu_T(m)$ talaş açısının bulanık küme üyelik derecesi, m sıcaklık bulanık kümesinin elemanıdır.

$$\mu_{cccd}(m) = \begin{cases} \dfrac{337 - m}{15}; & 322 < m \le 337 \\ 0 \quad ; & diger\ durumlar \end{cases} \tag{5.16}$$

Diğer üyelik dereceleri fonksiyonları bu şekilde hesaplanabilir.



Şekil 5.8 T sıcaklık değeri üyelik fonksiyon grafiği

5.1.2. Bulanık kurallar

Tornalamada değişik kesme şartlarında ölçülen kesme kuvvetleri ve sıcaklığın tahmini için bir uzman yardımıyla belirlenmiş olan kurallar Tablo 5.1 de gösterilmektedir.

Tablo 5.1 Geliştirilen BUS için oluşturulan kurallar

Kural No	**T.A**		**Y.A**		**Hız**		**F_t**		**F_f**		**F_λ**		**T**
Kural 1	D	ve	D	ve	D	O halde	ÇÇÇD	ve	ÇÇÇD	ve	ÇD	ve	ÇD
Kural 2	D	ve	D	ve	NO	O halde	ÇY	ve	YO	ve	Y	ve	ÇDO
Kural 3	D	ve	D	ve	PO	O halde	ÇY	ve	DO	ve	ÇYO	ve	O
Kural 4	D	ve	D	ve	Y	O halde	ÇYO	ve	ÇDO	ve	PO	ve	Y
Kural 5	D	ve	NO	ve	D	O halde	ÇÇY	ve	ÇYO	ve	NYO	ve	ÇÇD
Kural 6	D	ve	NO	ve	NO	O halde	ÇY	ve	YO	ve	PO	ve	D
Kural 7	D	ve	NO	ve	PO	O halde	ÇYO	ve	O	ve	NO	ve	ÇDO
Kural 8	D	ve	NO	ve	Y	O halde	YO	ve	ÇDO	ve	PDO	ve	YO
Kural 9	D	ve	PO	ve	D	O halde	ÇY	ve	ÇÇY	ve	O	ve	ÇÇD
Kural 10	D	ve	PO	ve	NO	O halde	ÇY	ve	YO	ve	NO	ve	ÇD
Kural 11	D	ve	PO	ve	PO	O halde	ÇYO	ve	YO	ve	NDO	ve	ÇDO
Kural 12	D	ve	PO	ve	Y	O halde	O	ve	DO	ve	PDO	ve	DO
Kural 13	D	ve	Y	ve	D	O halde	ÇY	ve	ÇÇÇY	ve	NO	ve	ÇÇÇD
Kural 14	D	ve	Y	ve	NO	O halde	Y	ve	ÇÇY	ve	NDO	ve	ÇÇD
Kural 15	D	ve	Y	ve	PO	O halde	YO	ve	ÇYO	ve	DO	ve	ÇDO
Kural 16	D	ve	Y	ve	Y	O halde	O	ve	ÇYO	ve	PDO	ve	DO
Kural 17	NO	ve	D	ve	D	O halde	ÇYO	ve	DO	ve	DO	ve	ÇDO
Kural 18	NO	ve	D	ve	NO	O halde	YO	ve	ÇD	ve	ÇDO	ve	DO
Kural 19	NO	ve	D	ve	PO	O halde	O	ve	ÇÇD	ve	ND	ve	ÇYO
Kural 20	NO	ve	D	ve	Y	O halde	O	ve	ÇÇÇD	ve	ND	ve	ÇY
Kural 21	NO	ve	NO	ve	D	O halde	YO	ve	O	ve	PDO	ve	ÇD
Kural 22	NO	ve	NO	ve	NO	O halde	O	ve	D	ve	ÇDO	ve	ÇDO
Kural 23	NO	ve	NO	ve	PO	O halde	O	ve	ÇD	ve	ND	ve	DO
Kural 24	NO	ve	NO	ve	Y	O halde	DO	ve	ÇD	ve	D	ve	Y
Kural 25	NO	ve	PO	ve	D	O halde	YO	ve	YO	ve	ND	ve	ÇÇD
Kural 26	NO	ve	PO	ve	NO	O halde	O	ve	ÇDO	ve	D	ve	ÇDO
Kural 27	NO	ve	PO	ve	PO	O halde	DO	ve	ÇD	ve	D	ve	DO
Kural 28	NO	ve	PO	ve	Y	O halde	DO	ve	ÇÇÇD	ve	D	ve	YO

Kural 29	NO	ve	Y	ve	D	O halde	O	ve	Y	ve	ND	ve	ÇÇD
Kural 30	NO	ve	Y	ve	NO	O halde	O	ve	ÇDO	ve	D	ve	D
Kural 31	NO	ve	Y	ve	PO	O halde	DO	ve	D	ve	D	ve	ÇDO
Kural 32	NO	ve	Y	ve	Y	O halde	DO	ve	ÇD	ve	D	ve	YO
Kural 33	PO	ve	D	ve	D	O halde	O	ve	D	ve	PDO	ve	ÇDO
Kural 34	PO	ve	D	ve	NO	O halde	DO	ve	ÇD	ve	PDO	ve	YO
Kural 35	PO	ve	D	ve	PO	O halde	DO	ve	ÇD	ve	ÇDO	ve	Y
Kural 36	PO	ve	D	ve	Y	O halde	ÇDO	ve	ÇÇD	ve	ÇDO	ve	ÇÇÇY
Kural 37	PO	ve	NO	ve	D	O halde	DO	ve	D	ve	ÇDO	ve	D
Kural 38	PO	ve	NO	ve	NO	O halde	ÇDO	ve	D	ve	ND	ve	DO
Kural 39	PO	ve	NO	ve	PO	O halde	ÇDO	ve	ÇD	ve	ND	ve	YO
Kural 40	PO	ve	NO	ve	Y	O halde	ÇDO	ve	ÇÇD	ve	D	ve	Y
Kural 41	PO	ve	PO	ve	D	O halde	DO	ve	ÇDO	ve	D	ve	ÇD
Kural 42	PO	ve	PO	ve	NO	O halde	ÇDO	ve	D	ve	D	ve	ÇDO
Kural 43	PO	ve	PO	ve	PO	O halde	ÇDO	ve	D	ve	D	ve	DO
Kural 44	PO	ve	PO	ve	Y	O halde	ÇDO	ve	D	ve	D	ve	Y
Kural 45	PO	ve	Y	ve	D	O halde	DO	ve	ÇDO	ve	D	ve	ÇÇD
Kural 46	PO	ve	Y	ve	NO	O halde	ÇDO	ve	ÇDO	ve	D	ve	ÇDO
Kural 47	PO	ve	Y	ve	PO	O halde	ÇDO	ve	ÇDO	ve	PD	ve	DO
Kural 48	PO	ve	Y	ve	Y	O halde	ÇDO	ve	D	ve	ÇD	ve	ÇYO
Kural 49	Y	ve	D	ve	D	O halde	ÇDO	ve	ÇD	ve	ÇDO	ve	DO
Kural 50	Y	ve	D	ve	NO	O halde	D	ve	ÇÇD	ve	ND	ve	ÇYO
Kural 51	Y	ve	D	ve	PO	O halde	D	ve	ÇÇD	ve	ND	ve	ÇY
Kural 52	Y	ve	D	ve	Y	O halde	ÇD	ve	ÇÇÇD	ve	D	ve	ÇÇÇY
Kural 53	Y	ve	NO	ve	D	O halde	D	ve	ÇD	ve	ÇDO	ve	ÇDO
Kural 54	Y	ve	NO	ve	NO	O halde	D	ve	ÇÇD	ve	ND	ve	DO
Kural 55	Y	ve	NO	ve	PO	O halde	ÇD	ve	ÇÇD	ve	ND	ve	ÇYO
Kural 56	Y	ve	NO	ve	Y	O halde	ÇD	ve	ÇÇÇD	ve	ND	ve	ÇY
Kural 57	Y	ve	PO	ve	D	O halde	D	ve	ÇD	ve	ND	ve	D
Kural 58	Y	ve	PO	ve	NO	O halde	D	ve	ÇD	ve	ND	ve	DO
Kural 59	Y	ve	PO	ve	PO	O halde	ÇD	ve	ÇD	ve	D	ve	O
Kural 60	Y	ve	PO	ve	Y	O halde	ÇÇD	ve	ÇÇD	ve	D	ve	Y
Kural 61	Y	ve	Y	ve	D	O halde	D	ve	ÇDO	ve	D	ve	ÇD
Kural 62	Y	ve	Y	ve	NO	O halde	ÇD	ve	D	ve	D	ve	ÇDO
Kural 63	Y	ve	Y	ve	PO	O halde	ÇD	ve	ÇD	ve	ÇD	ve	O
Kural 64	Y	ve	Y	ve	Y	O halde	ÇÇD	ve	ÇÇD	ve	ÇD	ve	Y

5.1.3. Çıkarım mekanizması

Çıkarım mekanizması olarak "Mamdani Yaklaşımı" seçilmiştir. Mamdani max-min çıkarım uygulandığından, her bir kural için doğruluk dereceleri (α) belirlenmiştir. Aşağıda bazı kurallar için doğruluk derecelerinden örnekler verilmiştir.

Kural 1 için $\alpha_1=\min(\mu_D(x), \mu_D(y), \mu_D(z))$

Kural 13 için $\alpha_{13}=\min(\mu_D(x), \mu_Y(y), \mu_D(z))$

Kural 34 için $\alpha_{34}=\min(\mu_{PO}(x), \mu_D(y), \mu_{NO}(z))$

Kural 55 için $\alpha_{55}=\min(\mu_Y(x), \mu_{NO}(y), \mu_{PO}(z))$

5.1.4. Durulaştırma

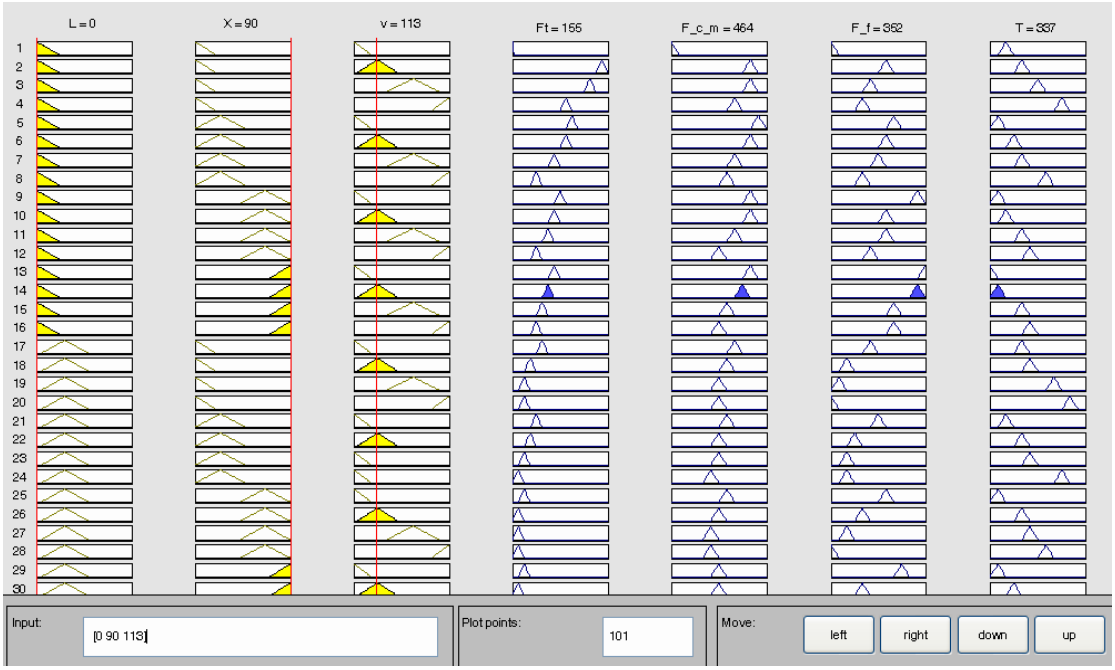
Durulaştırma işleminde ise bulunan doğruluk derecesine göre "ağırlık merkezli durulaştırma" yöntemi kullanılarak kesin çıktılar elde edilmiştir. Bir örnek olarak talaş açısı değeri 0^o, yaklaşma açısı 90^o, kesme hızı 113 m/dk değerleri için; F_t=474 N, F_f=341 N, F_λ=163 N, T= 344 ^oC deney sonuçlarına karşılık olarak, bulanık uzman sistemde F_t=464 N, F_f=352 N, F_λ=155 N, T= 337 ^oC değerleri elde edilmiştir.

Talaş açısı değeri 0^o, yaklaşma açısı 90^o, kesme hızı 113 m/dk değerleri için sadece 14 nolu kural ateşlenmiştir. Ateşlenen Kural 14 Şekil 5.9'da gösterilmiştir.

Kural 14 için $\alpha_{14}=\min(\mu_D(x), \mu_Y(y), \mu_{NO}(z))$

$\alpha_{14}=\min(1, 1, 0.94)$

$\alpha_{14}= 0.94$



Şekil 5.9 Ağırlık merkezli durulaştırıcı ile BUS sonuçları

Talaş açısı değeri 19^{o}, yaklaşma açısı 82^{o}, kesme hızı 200 m/dk değerleri için; bulanık uzman sistemde F_t=447 N, F_f=338 N, F_λ=113 N, T= 409 ^{o}C değerleri elde edilmiştir.

Talaş açısı değeri 19 ^{o}, yaklaşma açısı 82^{o}, kesme hızı 200 m/dk değerleri için 59 ve 63 nolu kurallar ateşlenmiştir.

Kural 59 için $\alpha_{59}=\min(\mu_Y(x), \mu_{PO}(y), \mu_{PO}(z))$

$\alpha_{59}=\min(0.8, 0.66, 0.44)$

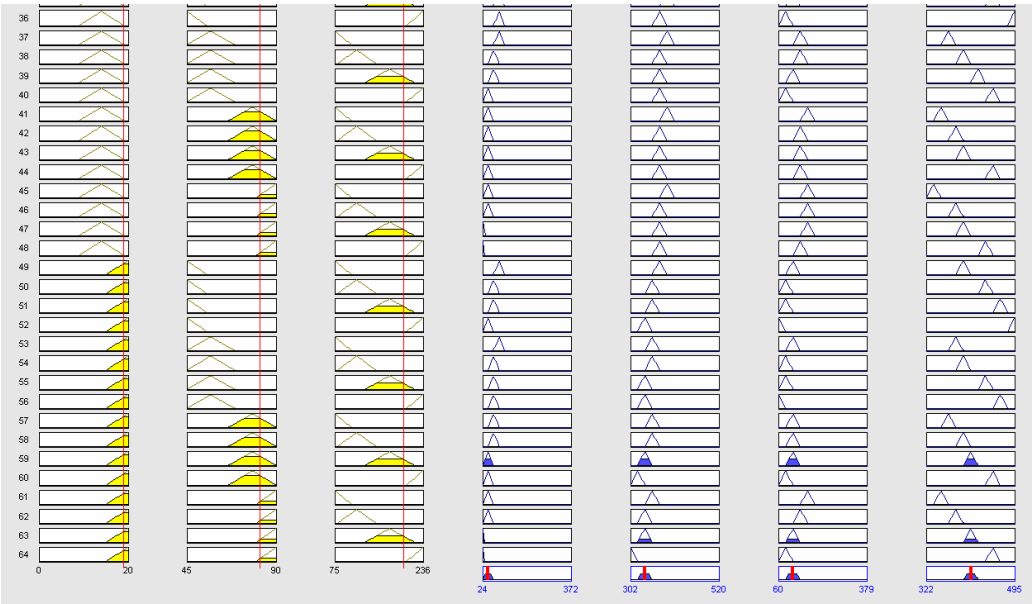
$\alpha_{59}= 0.44$

Kural 63 için $\alpha_{63}=\min(\mu_Y(x), \mu_Y(y), \mu_{PO}(z))$

$\alpha_{63}=\min(0.8, 0.2, 0.44)$

$\alpha_{63}= 0.2$

Mamdani max-min çıkarımından sistemin üyelik fonksiyonunu $\max(\alpha_{59}, \alpha_{63})=0.44$ olarak elde ederiz. Ateşlenen kurallar Şekil 5.10'da gösterilmiştir.



Şekil 5.10 Ağırlık merkezli durulaştırıcı ile BUS sonuçları

Deney verileri ile Bulanık Uzman Sistem sonucu alınan değerler karşılaştırmalı olarak Tablo 5.2 de gösterilmiştir.

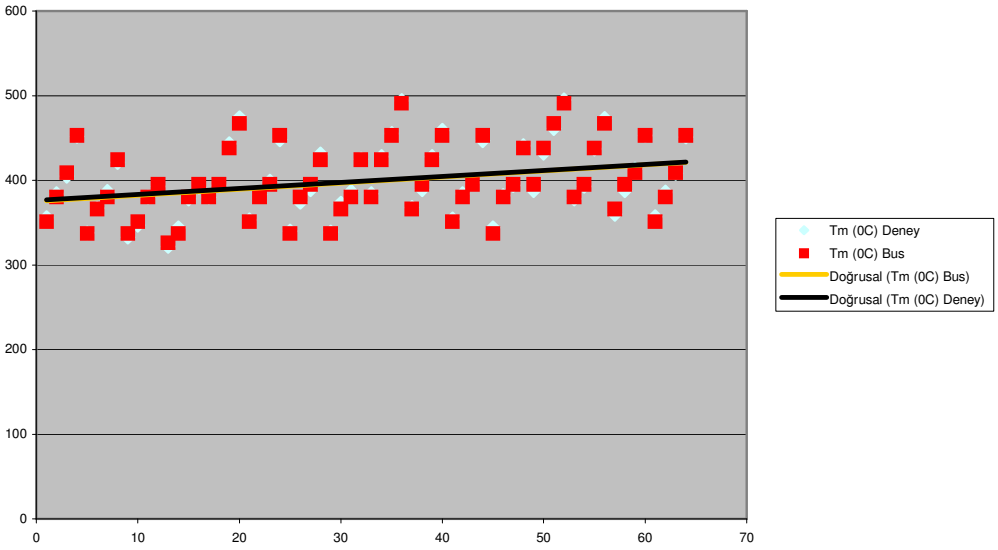
Tablo 5.2 Geliştirilen BUS ile deney verilerinin karşılaştırılması

D.	γ	χ	V	$\mathbf{F}_t$(N)		F_f		F_λ		T_m (^{0}C)	
No			m/min	**Deney**	**BUS**	**Deney**	**BUS**	**Deney**	**BUS**	**Deney**	**BUS**
1	0	45	75	520	514	267	272	372	371	356	351
2	0	45	113	491	483	252	246	341	350	384	380
3	0	45	160	481	483	194	193	306	307	405	409
4	0	45	236	456	447	159	166	216	220	452	453
5	0	60	75	497	501	279	272	239	242	338	337
6	0	60	113	480	483	247	246	210	220	367	366
7	0	60	160	453	447	217	219	185	176	387	380
8	0	60	236	423	429	172	166	111	111	421	424
9	0	75	75	490	483	344	352	190	198	333	337
10	0	75	113	475	483	258	246	176	176	347	351

11	0	75	160	448	447	233	246	150	155	380	380
12	0	75	236	417	410	203	193	144	133	393	395
13	0	90	75	481	483	379	371	172	176	322	326
14	0	90	113	474	464	341	352	163	155	344	337
15	0	90	160	433	429	269	272	138	133	378	380
16	0	90	236	410	410	271	272	118	111	392	395
17	6	45	75	456	447	194	193	132	133	380	380
18	6	45	113	437	429	107	113	95	89	394	395
19	6	45	160	419	410	95	86,7	78	68	443	438
20	6	45	236	406	410	60	68	58	68	474	467
21	6	60	75	423	429	225	219	106	111	353	351
22	6	60	113	411	410	147	140	82	89	383	380
23	6	60	160	405	410	117	113	76	68	399	395
24	6	60	236	398	393	111	113	48	46	448	453
25	6	75	75	422	429	252	246	69	68	340	337
26	6	75	113	409	410	177	166	56	46	374	380
27	6	75	160	400	393	124	113	48	46	389	395
28	6	75	236	395	393	69	69	44	46	431	424
29	6	90	75	416	410	288	299	57	68	339	337
30	6	90	113	406	410	168	166	45	46	373	366
31	6	90	160	400	393	144	140	43	46	387	380
32	6	90	236	388	393	111	113	37	46	425	424
33	12	45	75	403	410	138	140	118	111	384	380
34	12	45	113	398	393	118	113	105	111	428	424
35	12	45	160	386	393	105	113	94	90	455	453
36	12	45	236	379	374	94	87	90	90	494	491
37	12	60	75	396	393	150	140	92	90	368	366
38	12	60	113	382	374	136	140	78	68	389	395
39	12	60	160	376	374	118	113	72	68	428	424
40	12	60	236	369	374	92	87	50	46	459	453
41	12	75	75	393	393	164	166	56	46	354	351
42	12	75	113	381	374	149	140	53	46	384	380
43	12	75	160	372	374	142	140	49	46	397	395
44	12	75	236	368	374	130	140	44	46	447	453
45	12	90	75	386	393	168	166	46	46	344	337
46	12	90	113	378	374	156	166	37	46	382	380
47	12	90	160	371	374	154	166	33	27	394	395

48	12	90	236	367	374	136	140	29	25	441	438
49	20	45	75	368	374	104	113	93	90	388	395
50	20	45	113	363	356	80	87	74	68	432	438
51	20	45	160	362	356	74	87	59	68	461	467
52	20	45	236	347	338	60	68	53	46	495	491
53	20	60	75	363	356	107	113	83	89	378	380
54	20	60	113	352	356	88	87	66	68	393	395
55	20	60	160	342	338	83	87	63	68	437	438
56	20	60	236	324	338	71	69	58	68	473	467
57	20	75	75	362	356	123	113	77	68	360	366
58	20	75	113	351	356	115	113	69	68	388	395
59	20	75	160	342	338	107	113	49	46	413	409
60	20	75	236	319	320	82	87	41	46	453	453
61	20	90	75	358	356	154	166	50	46	357	351
62	20	90	113	345	338	144	140	44	46	386	380
63	20	90	160	341	338	125	113	29	25	408	409
64	20	90	236	302	307	98	87	24	25	451	453

Elde edilen deney sonuçları ile Bulanık Uzman Sistem gerçekleştirilerek alınan sonuçların kolerasyonu alınarak, teğetsel kesme kuvveti için %99.2, ilerleme kuvveti için %99.5, radyal kuvvet için %99.6 ve sıcaklık için %99.4'e yakın sonuçlar bulunmuştur. Deney sonuçları ile BUS arasındaki sıcaklık kolerasyon grafiği Şekil 5.11'de gösterilmiştir. Şekil 5.11'de görüleceği gibi sıcaklık çıktı değişkeni için Deney ve BUS'un doğrusal belirtimi tek bir doğru gibi gözükmektedir.



Şekil 5.11 Deney ve BUS sıcaklık kolerasyon grafiği

Tablo 5.3 Bulanık Uzman Sistem için T-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	t testi değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	64	401,0313	48,15088	,120	126	,905
	BUS Çıkışı	64	400,0156	47,51925			
İtme-radyal kuvvet	Gerçek Çıkış	64	159,9844	74,66252	-,003	126	,997
	BUS Çıkışı	64	160,0266	74,71638			
İlerleme kuvveti	Gerçek Çıkış	64	98,1719	74,25194	,033	126	,974
	BUS Çıkışı	64	97,7344	75,27584			
Sıcaklık	Gerçek Çıkış	64	399,2500	41,74070	,100	126	,921
	BUS Çıkışı	64	398,5156	41,75590			

Tablo 5.3'de görüldüğü gibi bulanık uzman sistem ile yapılan modellemedeki teğetsel kuvvet, radyal kuvveti, ilerleme kuvveti ve sıcaklık çıkışları ile deney

sonucu çıkışların T-testi ile karşılaştırılması sonucunda gruplar arasında manidar bir fark olmadığı görülmüştür.

Bu çalışmada yapay sinir ağları ve bulanık sinir ağında kullanılan 16 adet test veri girişinin bulanık uzman sistem ile elde edilen sonuçlarının gerçek çıkışlar ile kolerasyonu alındığında teğetsel kesme kuvveti için %99.28, ilerleme kuvveti için %99.51, radyal kuvvet için %99.12 ve sıcaklık için %99.44 'e yakın sonuçlar bulunmuştur. Tablo 5.4'de test verileri için BUS T-testi sonuçları verilmiştir. Tablo 5.4 incelendiğinde bulanık uzman sistem ile yapılan modellemedeki teğetsel kuvvet, radyal kuvveti, ilerleme kuvveti ve sıcaklık test çıkışları ile deney sonucu çıkışların karşılaştırılması sonucunda gruplar arasında manidar bir fark olmadığı görülmektedir.

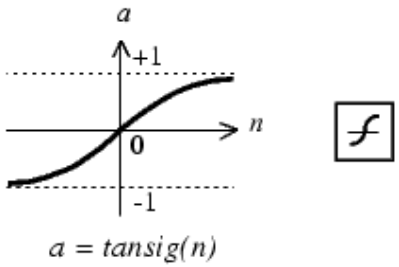
Tablo 5.4 Test verileri için Bulanık Uzman Sistem T-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	t testi değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	16	409,0000	42,52999	,049	30	,962
	BUS Çıkışı	16	408,2500	44,89618			
İtme-radyal kuvvet	Gerçek Çıkış	16	173,1875	66,37994	-,057	30	,955
	BUS Çıkışı	16	174,5000	64,77448			
İlerleme kuvveti	Gerçek Çıkış	16	101,5625	73,69303	,038	30	,970
	BUS Çıkışı	16	100,5625	75,51598			
Sıcaklık	Gerçek Çıkış	16	386,3750	35,88105	-,088	30	,931
	BUS Çıkışı	16	387,5000	36,70967			

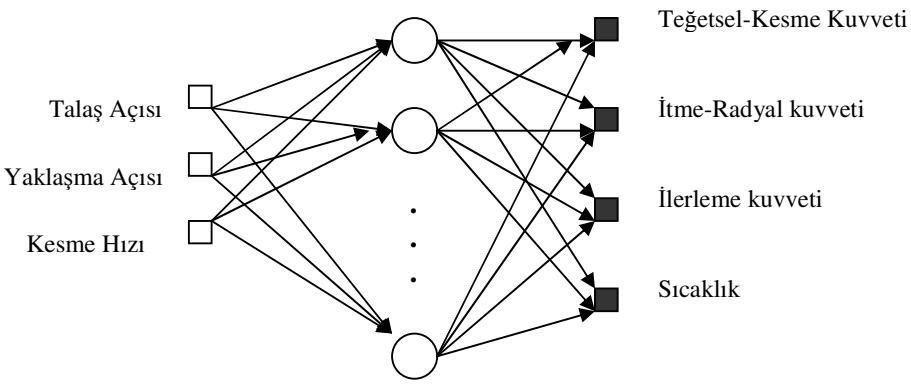
5.2. Yapay Sinir Ağı ile Tahmin Etme

Bu çalışmada ileri beslemeli Yapay Sinir Ağı ve öğrenme stratejisi olarak da eğiticili öğrenme kullanılmıştır. Standart bir sinir ağı, girdiyi alan bir saklı

katmandan ve çıktıyı düzenleyen bir çıktı katmanından oluşur. Saklı katmanda yeterli sayıda nöron olmak koşulu ile yapay sinir ağı kullanılarak, devamlı veya sonlu sayıda devamsızlığı olan bütün fonksiyonlar için bir yaklaşım elde edilebilir (Kaya 2004). Yaklaşımın başarısı kullanılan baz fonksiyonlarına doğrudan bağlıdır. Çok geniş bir gradyant aralığına sahip hiperbolik tanjant fonksiyonu bu amaç için en iyi fonksiyonlardan birisidir (Demuth 2005). Bundan dolayı gizli katmanda ve çıkış katmanında transfer fonksiyonu olarak Şekil 5.12'de gösterilen Tansig fonksiyonu kullanılmıştır. Tornalamada değişik kesme şartlarında ölçülen kesme kuvvetlerinin ve sıcaklığının Yapay Sinir Ağı ile modellenmesi için MATLAB 6.5 Neural Network Toolbox dan faydalanılmıştır.



Şekil 5.12 Tansig transfer fonksiyonu



Şekil 5.13 Yapay Sinir Ağının mimarisi

Yapay Sinir Ağının giriş nöronlarının sayısını sistemin girdilerinin sayısı, çıkış katmanındaki çıkış nöronlarının sayısını da sistemin çıktılarının sayısı belirlemektedir. Şekil 5.13'de görüldüğü gibi sistemin girdileri talaş açısı, yaklaşma açısı, kesme hızı değerleri, çıktıları ise teğetsel-kesme kuvveti, radyal kuvveti, ilerleme kuvveti ve sıcaklık değerleri alınmıştır. Buna göre oluşturulan YSA'nın giriş nöron sayısı 3 iken çıkış nöron sayısı 4 olmaktadır. Gizli katmanda ise ağın performansını değerlendirebilmek için 5'den 50'ye kadar değişik sayıda nöron kullanılmıştır.

Girdi değişkenleri talaş açısı, yaklaşma açısı ve kesme hızı girdi değişkenlerinin sırası ile γ={0,6,12,20}, χ={45,60,75,90} ve v={75,113,160,236} dört adet değer almaktadırlar. Girdi değişkenlerinin dört adet değer almasından dolayı 64 adet farklı veri seti bulunmaktadır. Sistemin giriş ve çıkışlarının sayısal değerlerinden oluşan veri seti denklem 5.17 kullanılarak [-1,1] arasında olmak üzere normalize edilmiştir.

$$pn = \frac{2*(p - \min p)}{(\max p - \min p)} - 1 \tag{5.17}$$

Oluşturulan ağın eğitim fonksiyonunun ağırlık ve eşik değerlerini güncelleştirmek için eğim düşüşüne göre eşik ve ağırlık değerlerini güncelleyen bir ağ eğitim fonksiyonu olan geri-yayılım ve Gauss-Newton tekniğinin ve Dik-İniş (Steepest-descent) metodunun en iyi özelliklerini birleştiren bu algoritmaların sınırlamalarının çoğundan kaçınarak, genellikle hızlı bir yakınsama yapan Levenberg-Marquardt (Ham 2002) öğrenme metotları kullanılmıştır.

Yapay sinir ağının eğitimi için performans ölçütü olarak hataların kareleri ortalaması kullanılmıştır. Verilen girişlere karşılık YSA'nın bulduğu çıkışlar ile hedef (istenen) çıkış karşılaştırılır. YSA çıkışı ile hedef çıkış arasındaki fark hata olarak hesaplanır. Bu hatanın toplamının ortalamasının minimize edilmesi gerekir. Bu minimize edilmek istenen değer MSE (Mean Squared Error) olarak tanımlanır ve ağ performansını belirler. MSE aşağıdaki gibi formülize edilir:

$$MSE = \frac{1}{Q}\sum_{k=1}^{Q} e(k)^2 = \frac{1}{Q}\sum_{k=1}^{Q} (t(k) - y(k))^2 \tag{5.18}$$

e(k): Hedef ve YSA çıkışları arasındaki hata

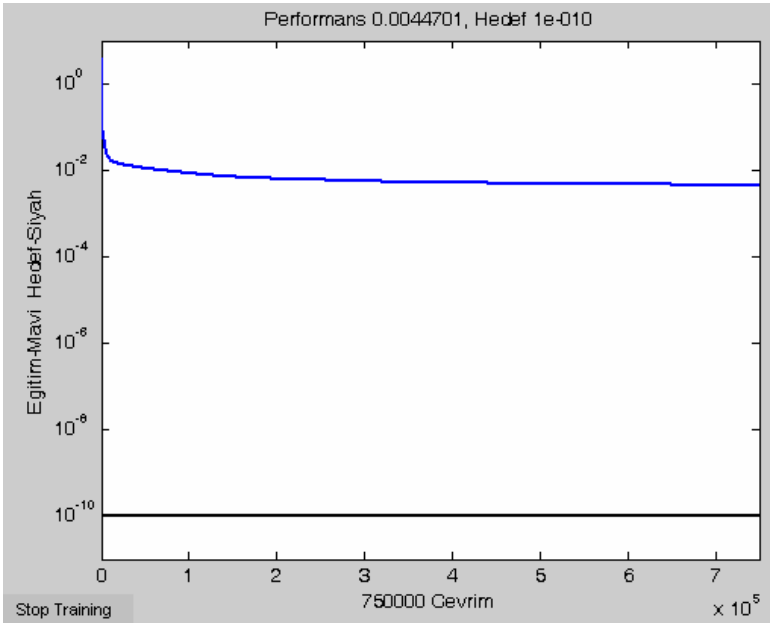
t(k): Hedef çıkış

y(k): YSA çıkışı

Yapay Sinir Ağı modeli oluşturmak için normalize edilen giriş ve çıkış veri setinin 48 adeti ağın eğitiminde, 16 adeti de ağın testinde kullanılmıştır. Test verileri rasgele seçilmiştir. Eğitim aşamasında ağa giriş ve çıkış verileri kullandırılmış, test aşamasında ise sadece giriş verileri verilmek suretiyle ağ çıkışı hesaplatılmıştır.

Yapay sinir ağının en iyi ağ performansını belirleyebilmek için Geri Yayılım ve Levenberg-Marquardt optimizasyon metotları teker teker denenmiştir.

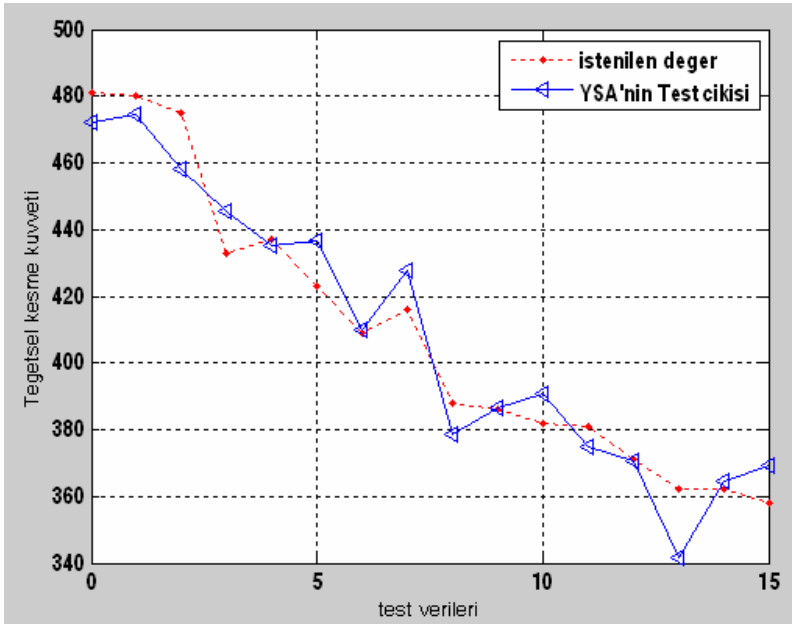
Geri yayılım ağında tek gizli katmanında 10 adet nörona sahip YSA'nın 750000 çevrim süren eğitimi esnasında hesaplanan MSE değerlerinin bulunduğu performans grafiği Şekil 5.14'deki gibidir.Şekil 5.14'de görüldüğü gibi 750000 çevrim sonucunda yapay sinir ağının MSE hata değeri 0.0044701 olarak bulunmuştur, hata oranının azalmasını sağlayan eğim çevrim sayısı ilerledikçe sıfıra yaklaşmıştır.



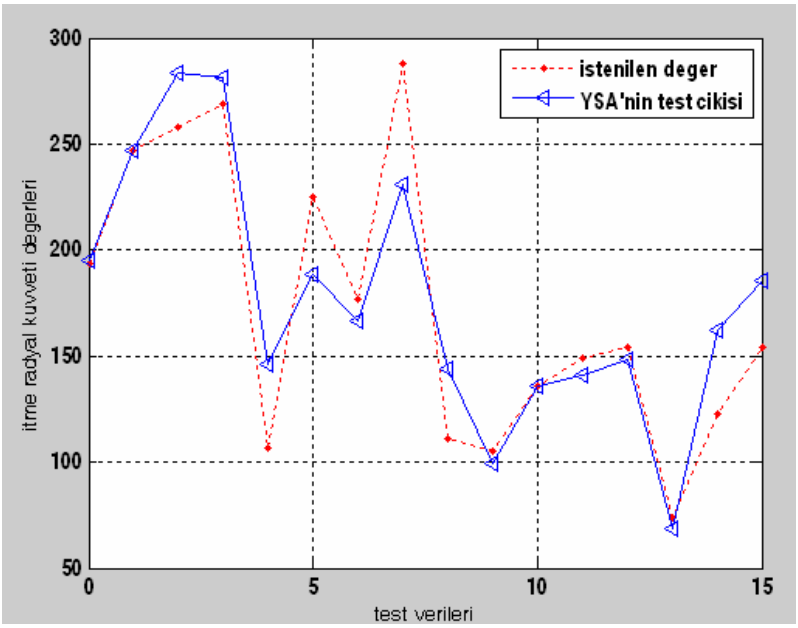
Şekil 5.14 MSE performans grafiği

Eğitimi tamamlanan Yapay Sinir Ağına 16 adet test verisi verilerek elde edilen çıkış değerlerinin ve hedeflenen çıkış değerleri ile karşılaştırıldığı grafikler

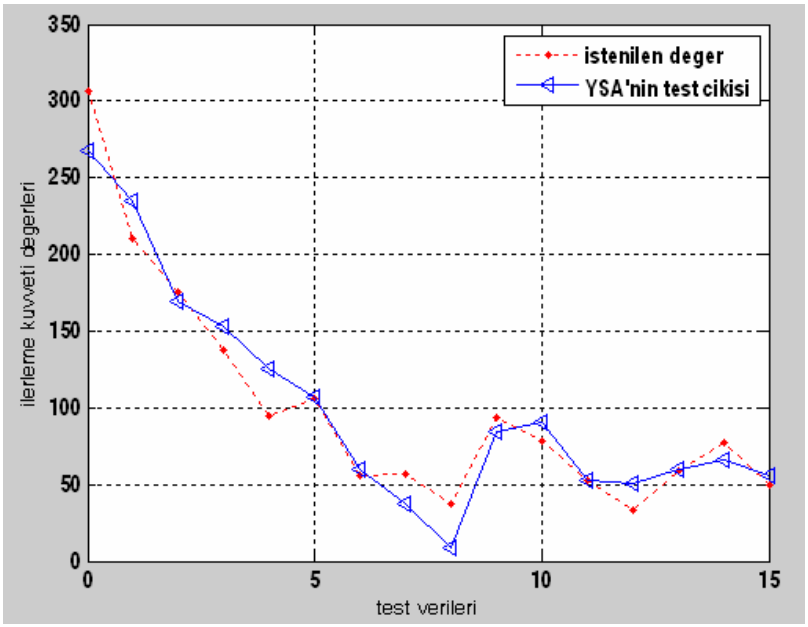
Şekil 5.15'de görülmektedir. Şekil 5.15'de sırası ile teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık çıktı değişkenlerine ait istenilen değer ile YSA'nın test çıkışları incelendiğinde grafiksel benzerlik kurulduğu gözlemlenmektedir.



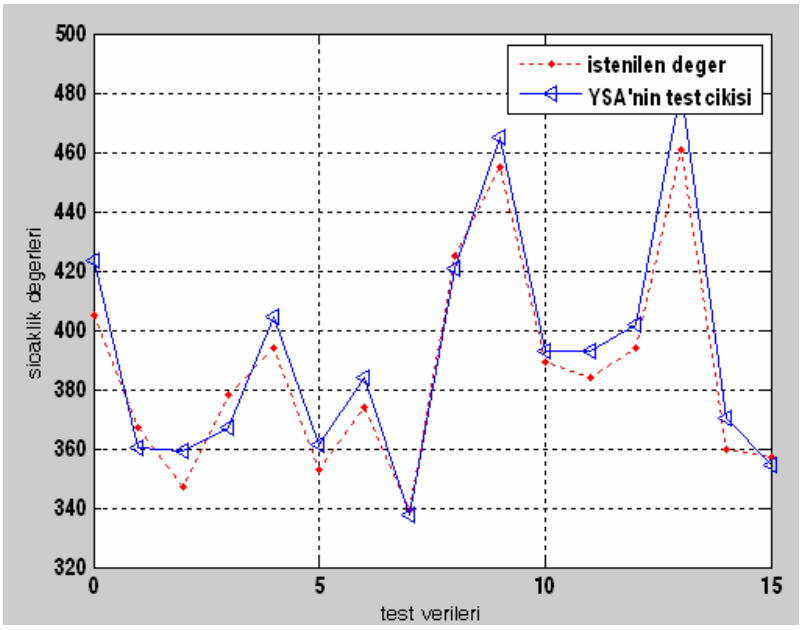
(a)



(b)



(c)



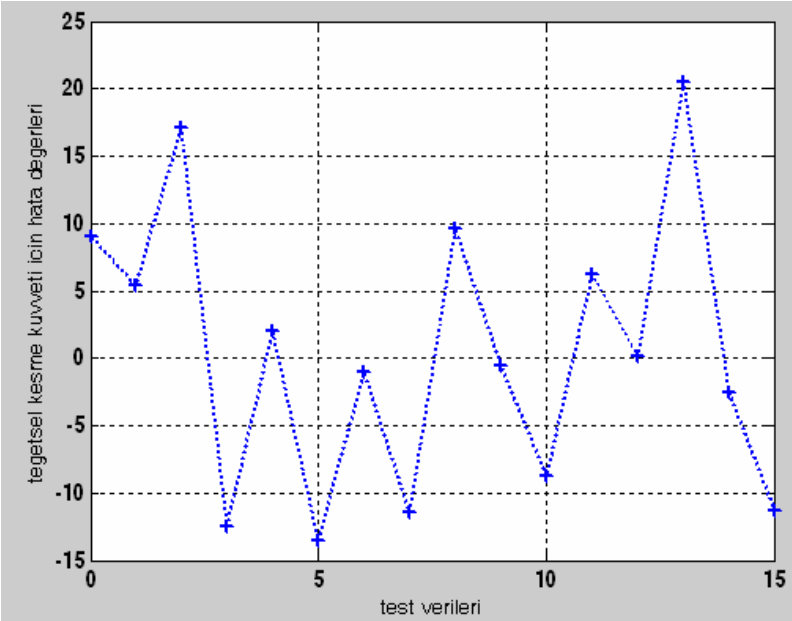
(d)

Şekil 5.15 YSA'nın geri yayılım ağı test aşaması sonucu elde edilen çıkış ile istenilen çıkış arasındaki ilişki (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) ilerleme kuvveti, (d) sıcaklık

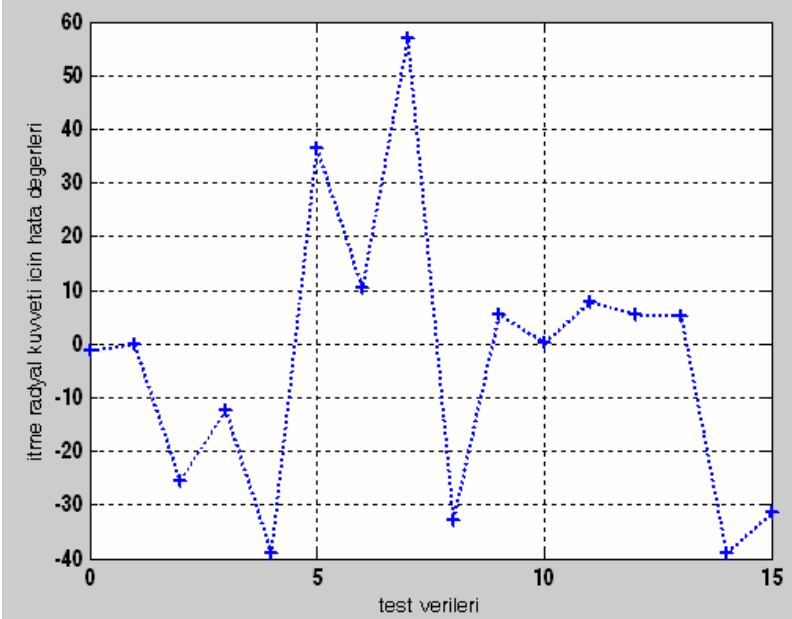
Ayrıca istenilen çıkış değerleri ve Yapay Sinir Ağı'nın testi aşaması sonucunda elde edilen çıkış değerleri arasındaki hata grafikleri sırasıyla Şekil 5.16'da verilmiştir. Hata değerleri aşağıdaki şekilde elde edilmiştir:

Hata = İstenilen Çıkış - YSA Çıkışı

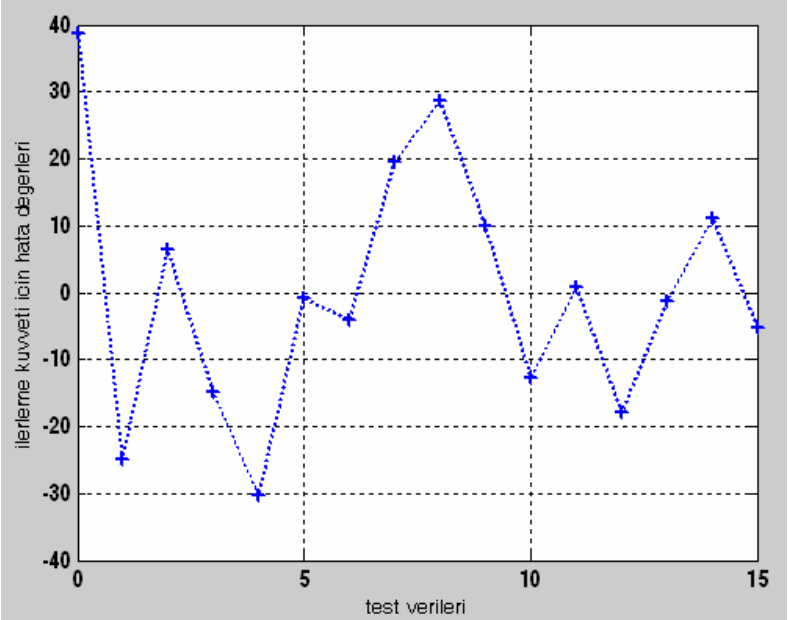
Şekil 5.16'da sırası ile teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık çıktı değişkenlerine ait hata grafikleri görülmektedir. Şekil 5.16a'da teğetsel kuvvet [302-520 N] sınır değeri aralığında en yüksek hata değerinin 20 olduğu gözükmektedir. Şekil 5.16b'da radyal kuvvet [24-372 N] sınır değeri aralığında en yüksek hata değerinin 56 olduğu gözükmektedir. Şekil 5.16c'da ilerleme kuvveti [60-379 N] sınır değeri aralığında en yüksek hata değerinin 40 olduğu gözükmektedir. Şekil 5.16d'da sıcaklık [322-495 ^{o}C] sınır değeri aralığında en yüksek hata değerinin 21 olduğu gözükmektedir.Şekil 5.16'da bulunan hata grafikleri incelendiğinde istenilen çıkış ile YSA çıkışı arasındaki farkın çıktı değişkenleri için belirli bir seviyede bulunduğu gözlemlenmektedir.



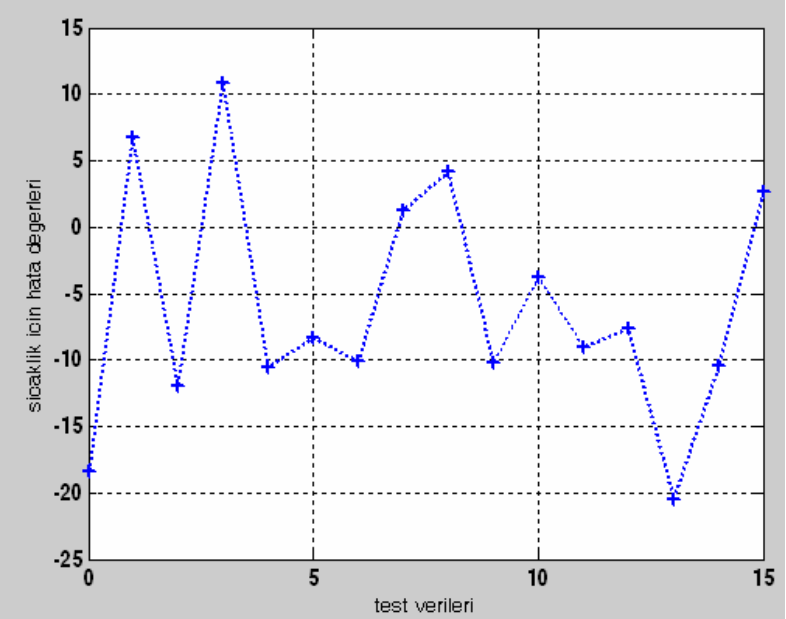
(a)


itme radyal kuvveti icin hata degerleri
test verileri
60
50
40
30
20
10
0
-10
-20
-30
-40
0
5
10
15

(b)


ilerleme kuvveti icin hata degerleri
test verileri
40
30
20
10
0
-10
-20
-30
-40
0
5
10
15

(c)



(d)

Şekil 5.16 YSA test aşaması sonucu elde edilen ve istenilen çıkış arasındaki hata değeri (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) İlerleme kuvveti, (d) Sıcaklık

Tek gizli katmanda 10 nöron ile yapılan bu eğitime ek olarak tek gizli katman 5-6-7-8-9-20-30-40-50 nöron ile ve 2 gizli katmanda 10-20-30-40-50 adet nöron ile de eğitimi yapılmıştır. Farklı gizli katman ve farklı nöron sayıları ile yapılan bu eğitimler sonucu elde edilen MSE performansları ve deney sonuçları ile Yapay Sinir ağının test çıkışları arasındaki kolerasyon Tablo 5.5 de gösterilmiştir.

Tablo 5.5 Geri yayılımlı yapay sinir ağında farklı nöron ve katman sayılarında MSE hata ve test çıkışları için kolerasyon değerleri

Gizli Katman	Nöron Sayısı	MSE	Kolerasyon
1	5	0.00751015	%95,90
1	6	0.00616336	%95,92
1	7	0.00581368	%96,76
1	8	0.00740903	%94,19
1	9	0.00322653	%97,02
1	10	0.0044701	%95,79

1	20	0.000923076	%91,90
1	30	0.000207819	%90,73
1	40	4.7823e-006	%69,64
1	50	3.21358e-010	%46,90
2	10x10	0.000961288	%93,90
2	10x20	7.17839e-005	%85,52
2	10x30	5.9826e-006	%71,95
2	10x40	1.93604e-009	%62,58
2	10x50	5.06155e-006	%51,46

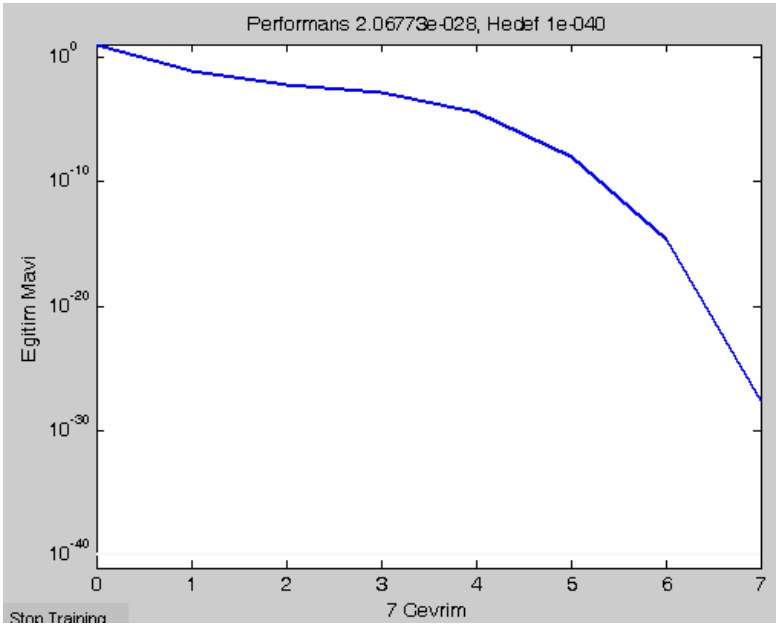
Geri yayılım ile eğitim sonucunda en iyi kolerasyon oranına sahip tek gizli katmanında 9 nöronu bulunan yapay sinir ağından elde edilen test çıkış değerleri ile gerçek çıkışlar arasında ki T-testi sonuçları Tablo 5.6 deki gibidir.

Tablo 5.6 Tek katmanlı 9 nörona sahip geri yayılım ağı için T-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	t değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	16	409,0000	42,52999	,060	30	,953
	YSA Çıkışı	16	408,0950	43,29137			
İtme radyal kuvvet	Gerçek Çıkış	16	173,1875	66,37994	-,050	30	,961
	YSA Çıkışı	16	174,3261	63,70068			
İlerleme kuvveti	Gerçek Çıkış	16	101,5625	73,69303	,069	30	,946
	YSA Çıkışı	16	99,8218	69,68774			
Sıcaklık	Gerçek Çıkış	16	386,3750	35,88105	-,125	30	,902
	YSA Çıkışı	16	387,9838	37,11432			

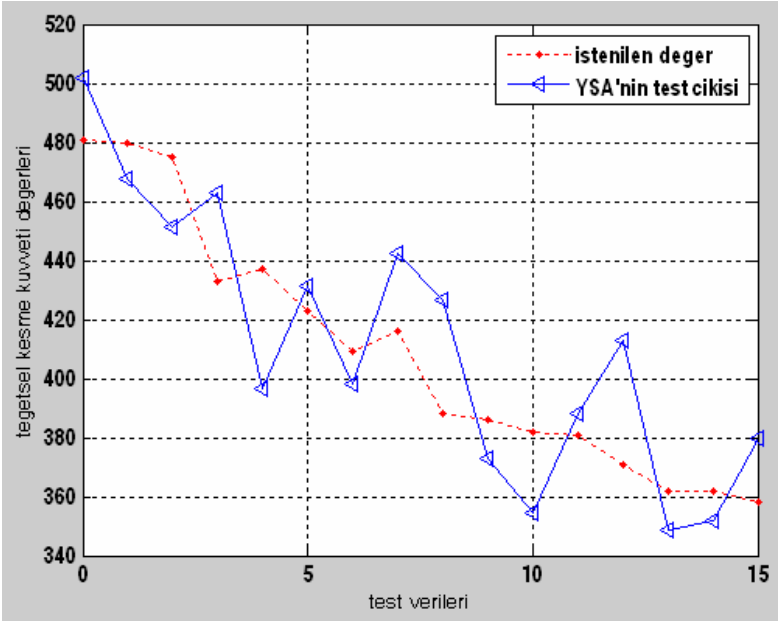
Tablo 5.6'da görüldüğü gibi tek gizli katman ve 9 nöronu bulunan geri yayılım metodu ile eğitim sonucunda teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık ağ çıkışları ile gerçek çıkışlarının karşılaştırılması sonucunda gruplar arasında manidar bir fark olmadığı görülmüştür.

Levenberg-Marquardt metodu kullanılarak tek gizli katmanda 40 adet nörona sahip YSA'nın eğitiminde hedeflenen MSE değeri 10^{-25} olarak verilmiş, 7 çevrim sonucunda hedefe ulaşılarak MSE değeri 2.06773e-028 olarak bulunmuştur. Eğitim sonucunda deney sonuçları ile Yapay Sinir Ağının test çıkışları arasında ki kolerasyon %78,94 olarak hesaplanmıştır. 7 çevrim süren eğitim esnasında hesaplanan MSE değerlerinin bulunduğu performans grafiği Şekil 5.17'de ki gibidir. Şekil 5.17 den görüldüğü gibi Levenberg-Marquardt metodu ile sadece 7 çevrim sonucunda hedeflenen hata değerine ulaşılmıştır.

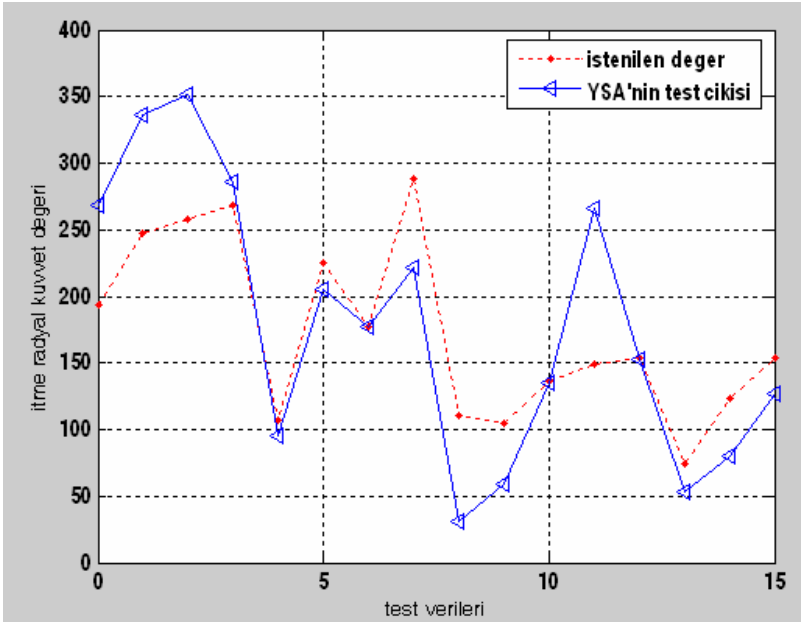


Şekil 5.17 Levenberg-Marquardt metodu için MSE performans grafiği

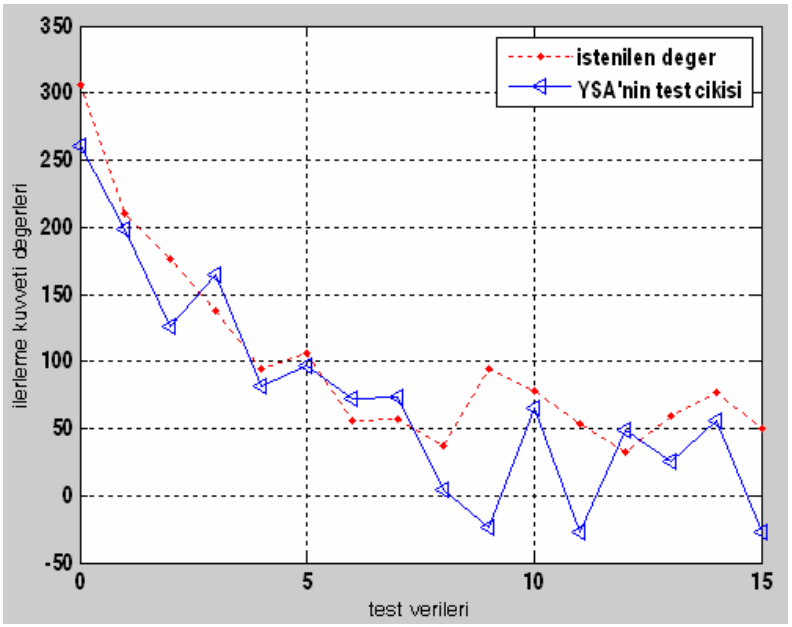
Eğitimi tamamlanan Yapay Sinir Ağının elde edilen test çıkış değerleri ve istenilen çıkış değerlerinin birlikte verildiği grafikler Şekil 5.18'de görülmektedir. Şekil 5.18'de çıktı değişkenlerinin test çıkış değerleri ile deney sonuç değerlerinin aynı anda verildiği şekiller incelendiğinde istenilen değer ve YSA'nın test çıkışları arasında grafiksel benzerliklerin çok az olduğu görülmektedir. Özellikle Teğetsel kuvvet ve sıcaklık çıktı değişken grafiklerinde istenilen değer ile YSA'nın test çıkışı arasındaki farklar belirgin bir biçimde gözükmektedir.


istenilen deger
YSA'nin test cikisi
tegetsel kesme kuvveti degerleri
test verileri
520
500
480
460
440
420
400
380
360
340
0
5
10
15

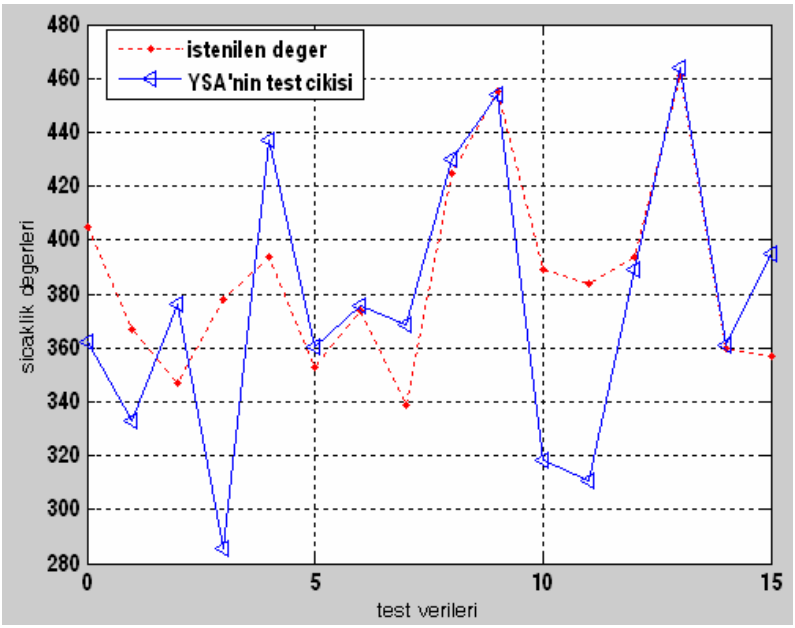
(a)


istenilen deger
YSA'nin test cikisi
itme radyal kuvvet degeri
test verileri
400
350
300
250
200
150
100
50
0
0
5
10
15

(b)



(c)



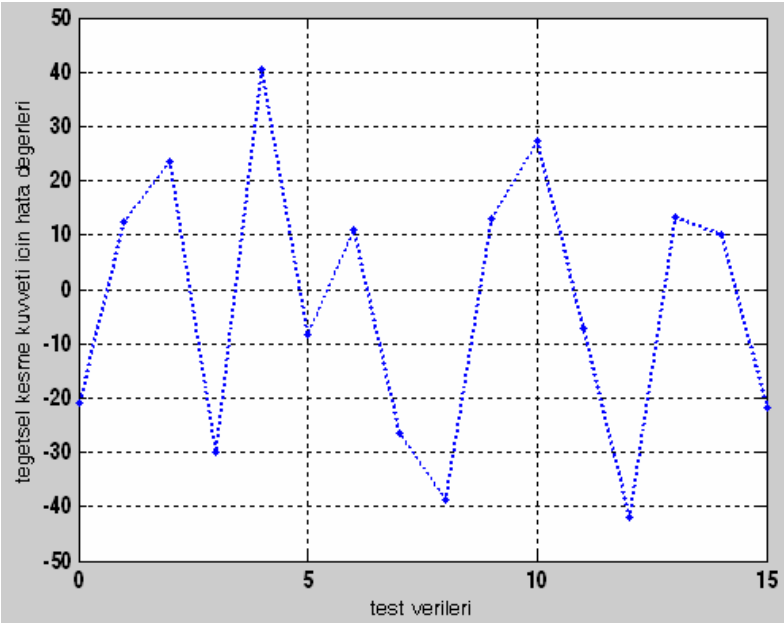
(d)

Şekil 5.18 YSA'nın eğitimi sonucu elde edilen test çıkış ile istenilen çıkış arasındaki ilişki (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) ilerleme kuvveti, (d) sıcaklık

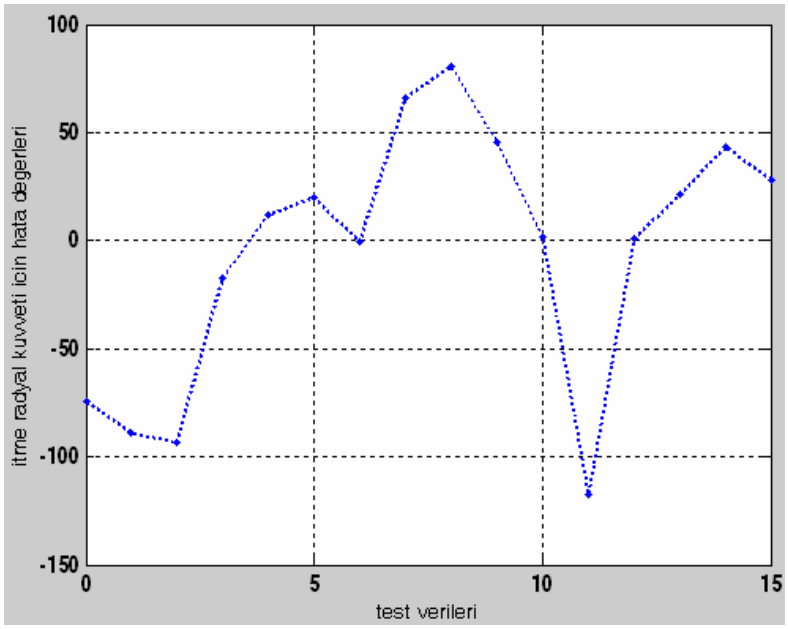
Ayrıca istenilen çıkış değerleri ve Yapay Sinir Ağı'nın testi sonucunda elde edilen çıkış değerleri arasındaki hata grafikleri sırasıyla Şekil 5.18'de verilmiştir. Hata değerleri aşağıdaki şekilde elde edilmiştir:

Hata = İstenilen Çıkış - YSA Çıkışı

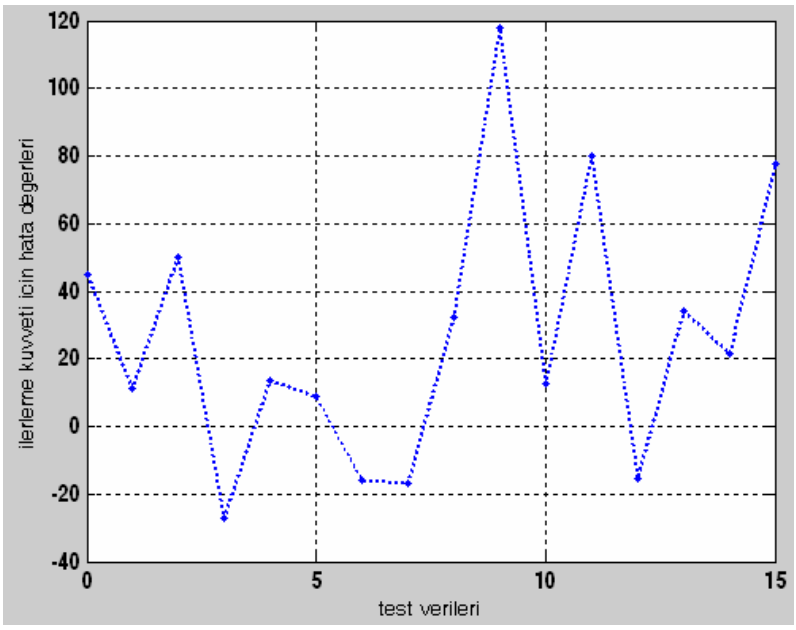
Şekil 5.19'da sırası ile teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık çıktı değişkenlerine ait hata grafikleri görülmektedir. Şekil 5.19a'da teğetsel kuvvet [302-520 N] sınır değeri aralığında en yüksek hata değerinin 41 olduğu gözükmektedir. Şekil 5.19b'da radyal kuvvet [24-372 N] sınır değeri aralığında en yüksek hata değerinin 121 olduğu gözükmektedir. Şekil 5.19c'da ilerleme kuvveti [60-379 N] sınır değeri aralığında en yüksek hata değerinin 120 olduğu gözükmektedir. Şekil 5.19d'da sıcaklık [322-495 ^{o}C] sınır değeri aralığında en yüksek hata değerinin 91 olduğu gözükmektedir. Şekil 5.19'da çıktı değişkenlerinin hata değeri grafikleri incelendiğinde geri-yayılım algoritmasına göre hatanın daha fazla arttığı gözlemlenmektedir. Bu metotla istenilen değer ile test çıkışı arasındaki farkın arttığı görülmektedir.



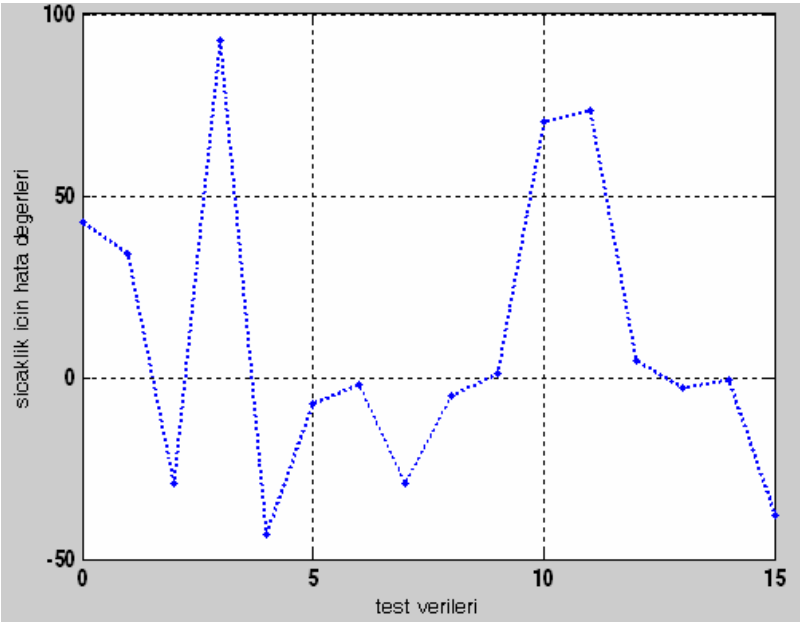
(a)


itme radyal kuvveti icin hata degerleri
test verileri
100
50
0
-50
-100
-150
0
5
10
15

(b)


ilerleme kuvveti icin hata degerleri
test verileri
120
100
80
60
40
20
0
-20
-40
0
5
10
15

(c)



(d)

Şekil 5.19 YSA test aşaması sonucu elde edilen test çıkış ve istenen değer arasındaki hata değeri (a) Teğetsel kesme kuvveti, (b) İtme radyal kuvveti, (c) İlerleme kuvveti, (d) Sıcaklık

Levenberg-Marquardt metodlu YSA'da elde edilen test çıkışları ile gerçek çıkışlar arasında ki T-testi sonuçları Tablo 5.7'deki gibidir.

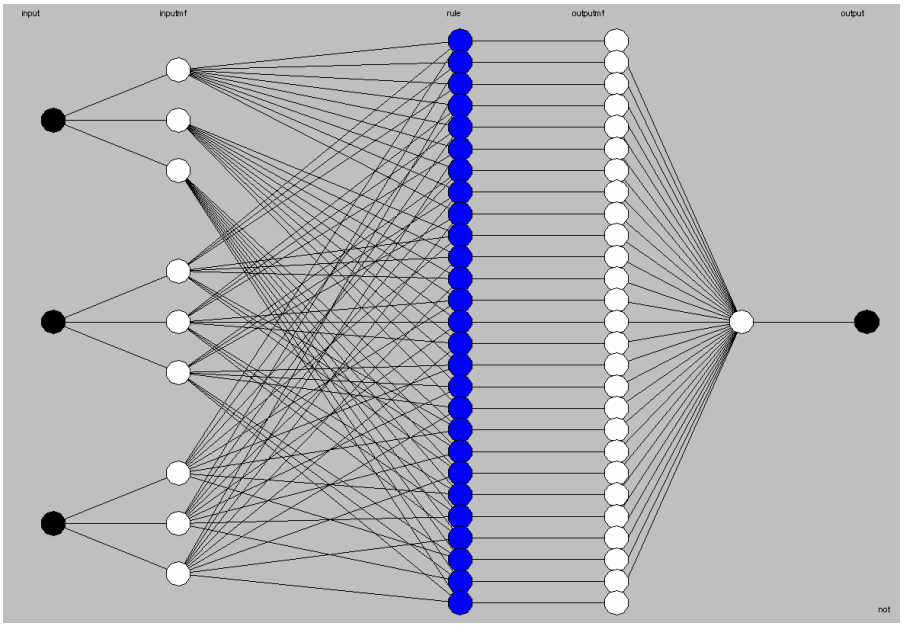
Tablo 5.7 Levenberg-Marquardt metodlu geri yayılım ağı için T-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	t değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	16	409,0000	42,52999	-,175	30	,862
	YSA Çıkışı	16	411,7282	45,66802			
İtme radyal kuvvet	Gerçek Çıkış	16	173,1875	66,37994	-,150	30	,881
	YSA Çıkışı	16	177,7921	102,88615			
İlerleme kuvveti	Gerçek Çıkış	16	101,5625	73,69303	,975	30	,337
	YSA Çıkışı	16	74,6979	81,87908			
Sıcaklık	Gerçek Çıkış	16	386,3750	35,88105	,648	30	,522
	YSA Çıkışı	16	376,2366	51,22663			

Tablo 5.7'den görüleceği gibi tek gizli katmanlı ve 40 nörona sahip bir ağda Levenberg-Marquardt metodu ile eğitim sonucunda teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık ağ çıkışları ile gerçek çıkışlarının karşılaştırılması sonucunda gruplar arasında manidar bir fark olmadığı görülmektedir fakat YSA'dan elde edilen T-testi sonuçları karşılaştırıldığında geri-yayılım metodunun deney sonuçlarını tahmin etmede daha başarılı olduğu söylenebilir.

5.3. Bulanık Sinir Ağı (ANFIS) ile Tahmin Etme

Bu kısımda "adaptif yapay sinir ağlı bulanık mantık çıkarım sistemi" (ANFIS) kullanılarak yaklaşma açısı, talaş açısı ve kesme hızı verilerine bağlı olarak tornalamada kesme kuvvetleri ve sıcaklığı tahmin etmeyi içermektedir. Bulanık Sinir Ağında modelleme oluşturma, eğitme, kontrol ve test etme işlemleri Matlab Fuzzy Toolbox kullanılarak gerçekleştirilmiştir. Öncelikle deney sonuçlarından elde edilmiş olan 64 adet veri seti bulanık modeli oluşturmak ve oluşturulan modelin doğruluğunun test edilebilmesi için eğitim ve test verileri olarak iki gruba ayrılmıştır. Sugeno sistemine dayanan ANFIS özel yapısı ile çıkış katmanında tek bir sonuç üretmektedir. Teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık çıktı değişkenlerini ANFIS ile modelleyebilmek için her bir çıktı değişkenine aynı ANFIS mimarisi kullanılmıştır. Şekil 5.20'de oluşturulan ANFIS mimarisi görülmektedir. Şekil 5.20'de görüldüğü gibi ANFIS yapısında 3 girdi değişkeni ve 1 çıktı değişkeni bulunmaktadır.

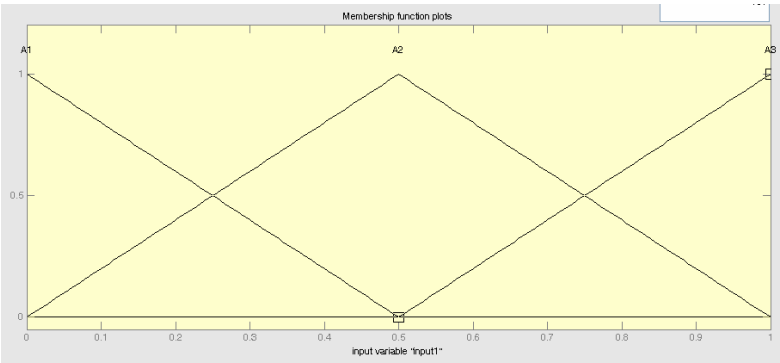


Şekil 5.20 Tornalamada değişik kesme şartlarında ölçülen kesme kuvvetlerinin ve sıcaklığın modellenmesi için geliştirilen ANFIS yapısı

İlk katmanda talaş açısı, yaklaşma açısı ve kesme hızı girişleri bulanıklaştırmaya tabii tutulmuştur. Bulanıklaştırma sonucunda her bir giriş 3 ayrı dilsel ifadeye ayrılmıştır. Ve bu alt bölgeler oluşturulurken üçgen üyelik fonksiyonu kullanılmıştır. Tüm girişler için kullanılan üçgen üyelik fonksiyonlarının aralıkları Tablo 5.8'deki gibi seçilmiştir. Ayrıca bu aralıklar Şekil 5.21 de grafiksel olarak gösterilmiştir.

Tablo 5.8 Sistem girişleri için üçgen üyelik fonksiyonların aralıkları

	Aralık değerleri
A1	-0.5 0.0 0.5
A2	0.0 0.5 1.0
A3	0.5 1.0 1.5



Şekil 5.21 Sistem girişlerinin üyelik fonksiyon grafikleri

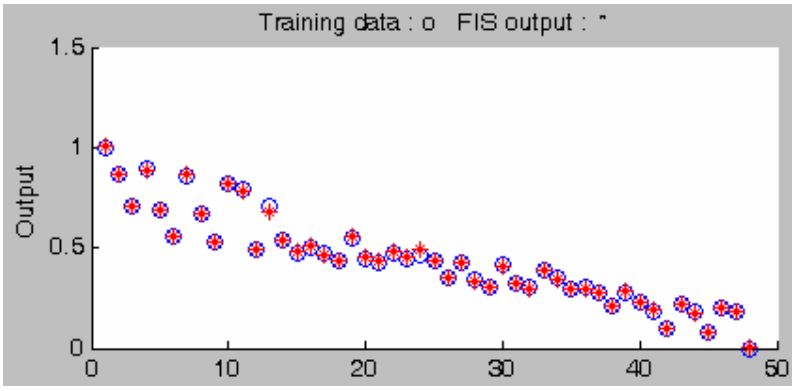
Girişler 3'er alt kümeye ayrıldığı için toplam 27 adet kural oluşturulur. Bu kurallardan bazıları sözel olarak aşağıdaki gibi yazılırlar.

Eğer Talaş Açısı A1 Yaklaşma Açısı B1 Kesme Hızı C1 ise Teğetsel Kesme Kuvveti N1

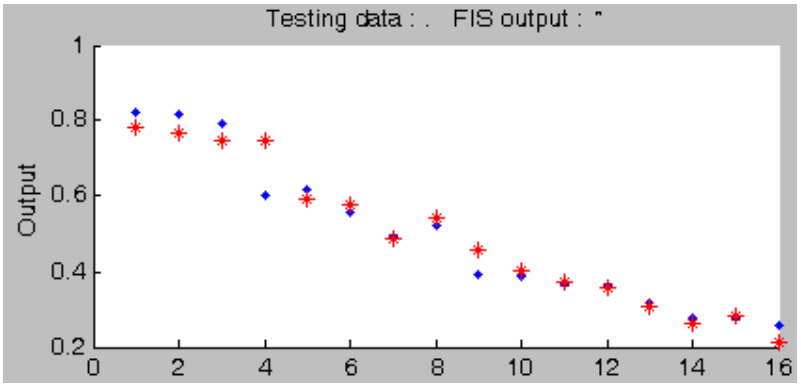
Eğer Talaş Açısı A2 Yaklaşma Açısı B2 Kesme Hızı C3 ise Teğetsel Kesme Kuvveti N15

Eğer Talaş Açısı A3 Yaklaşma Açısı B1 Kesme Hızı C2 ise Teğetsel Kesme Kuvveti N20

Her bir çıkış için oluşturulan ANFIS ağında girişler hybrid metodu ile eğitime tabii tutulmuşlardır. Yapılan eğitimde teğetsel kesme kuvvet çıkışı için 70 çevrim sonucunda oluşan RMSE hata oranı 0.047164 dır. Şekil 5.22'de eğitim verileri ile ANFIS çıkışının karşılaştırılması gösterilmektedir. Şekil 5.22'den görüldüğü gibi eğitim verileri ile ANFIS çıkışlarının çok büyük bir bölümü örtüşmektedir. Şekil 5.23'de ise test verisi ile ANFIS test çıkışını karşılaştırılması verilmiştir. Şekil 5.23'de ki grafik incelendiğinde test verileri ile ANFIS test çıkışlarının benzer karakteristik özellik gösterdiği görülmektedir.



Şekil 5.22 Eğitim verisi ile ANFIS eğitim çıkışının karşılaştırılması



Şekil 5.23 Test verisi ile ANFIS test çıkışlarının karşılaştırılması

Hybrid metodu ile 70 çevrimlik eğitim sonucunda ANFIS teğetsel kuvvet çıkışı için talaş açısı, yaklaşma açısı ve kesme hızı girişlerinin oluşan üyelik fonksiyonlarının yeni aralık değerleri Tablo 5.9'da ki gibi oluşmuştur. Tablo 5.9'da verilen yeni aralık değerleri Tablo 5.8 ile karşılaştırıldığında ANFIS eğitimi sonucunda üçgen üyelik fonksiyonunun tüm aralık değerlerinin değiştiği gözlemlenmektedir.

Tablo 5.9 3 dilsel ifadeli ANFIS eğitimi sonrasında Tegetsel Kesme Kuvveti girişi için üyelik fonksiyonların yeni aralık değerleri

Talaş Açısı	**Aralık değerleri**		
A1	-0.5	-0.05409	0.3802
A2	-4.832e-5	0.4148	0.9857
A3	0.4125	0.9862	1.5
Yaklaşma Açısı	**Aralık değerleri**		
B1	-0.5	-0.03549	0.3937
B2	0.001222	0.5023	1.0
B3	0.6675	1.04	1.5
Kesme Hızı	**Aralık değerleri**		
C1	-0.5	0.08304	0.3908
C2	-0.0001953	0.4098	0.9998
C3	0.4959	0.9998	1.5

Her bir çıkış için oluşturulan ANFIS ağlarının eğitimi sonrasında RMSE hata ve kolerasyon oranları Tablo 5.10'da verilmiştir.Tablo 5.10'da görüldüğü gibi en iyi kolerasyon oranı ilerleme kuvveti çıktı değişkeninde sağlanmıştır.

Tablo 5.10 3 dilsel ifadeli ANFIS'in eğitimi sonucunda sistem çıkışlarının RMSE hata ve test çıkışlarının korelasyon oranları

Sistem Çıkışı	**RMSE**	**Kolerasyon**
Teğetsel Kuvvet	0,047164	%96,88
Radyal Kuvveti	0,03325	%86,66
İlerleme Kuvveti	0,017145	%99,19
Sıcaklık	0,018419	%97,37

Tablo 5.11 3 dilsel ifadeli ANFIS metodu elde edilen değerler ile gerçek çıkışlar arasında ki T-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	t değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	16	409,0000	42,52999	-,051	30	,960
	ANFIS Çıkışı	16	409,7577	42,20525			
İtme radyal kuvvet	Gerçek Çıkış	16	173,1875	66,37994	-,011	30	,991
	ANFIS Çıkışı	16	173,4563	66,88904			
İlerleme kuvveti	Gerçek Çıkış	16	101,5625	73,69303	,069	30	,946
	ANFIS Çıkışı	16	99,7782	72,94743			
Sıcaklık	Gerçek Çıkış	16	386,3750	35,88105	-,149	30	,883
	ANFIS Çıkışı	16	388,3499	39,11592			

Tablo 5.11'de görüldüğü gibi 3 dilsel ifadeli ANFIS hybrid eğitim algoritması ile yapılan 70 çevrimlik eğitim sonucunda test verilerinin teğetsel kuvvet, radyal kuvveti, ilerleme kuvveti ve sıcaklık ağ çıkışları ile gerçek çıkışlarının karşılaştırılması sonucunda gruplar arasında manidar bir fark olmadığı görülmüştür.

Girdi değişkenlerinin 3 dilsel ifadeye ayrılarak oluşturulan ANFIS yapısına ek olarak girdi değişkenleri 4 dilsel ifadeye de ayrılarak eğitim yapılmıştır. Teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık bulanıklaştırmaya tabii tutularak 4 dilsel ifadeye ayrılmış ve toplam 64 kurallı bir ANFIS yapısı oluşturulmuştur. Girdi değişkenlerinin 4 dilsel ifadeye ayrılması ile oluşturulan ANFIS'in eğitimi sonucunda her bir çıkış için RMSE hata oranı ve kolerasyon oranları Tablo 5.12'de ki gibi oluşmuştur.

Tablo 5.12 4 dilsel ifadeye ayrılmış ANFIS eğitimi sonucunda sistem çıkışlarının RMSE hata ve test çıkışlarının korelasyon oranları

Sistem Çıkışı	RMSE	Kolerasyon
Teğetsel-Kesme Kuvveti	5.3634e-007	%64,54
İtme Radyal Kuvveti	3.9907e-007	%64,46
İlerleme Kuvveti	3,3531e-007	%89,46
Sıcaklık	5,3164e-007	-%0,33

Tablo 5.12 incelendiğinde 4 dilsel ifadeye ayrılarak yapılan eğitimde hata oranı 3 dilsel ifadeye göre yapılan eğitime göre daha düşük çıkmasına rağmen test çıkışı ile istenen çıkış arasındaki kolerasyon oranının iyi olmadığı gözükmektedir. Özellikle sıcaklık çıktı değişkenin kolerasyon oranı incelendiğinde test veri grubundan tamamen farklı bir veri kümesi oluştuğu gözlemlenmektedir. Girişin 3 dilsel ifadeye ayrılarak yapılan eğitiminde hata oran performansı iyi olmamasına rağmen test çıkışı ve istenen çıkış arasındaki kolerasyon oranı ve T-testi sonuçları modellemede iyi bir performans sergilediğini göstermektedir.

Tablo 5.13 4 dilsel ifadeli ANFIS metodu elde edilen test değerleri ile gerçek çıkışlar arasında ki t-testi sonuçları

Veri Grubu	Grublar	Deney sayısı (N)	Aritmetik ortalama (X)	Standart sapma (S)	T değeri (t)	Serbestlik derecesi (SD)	Anlamlılık seviyesi (p)
Teğetsel K. Kuvveti	Gerçek Çıkış	16	409,0000	42,52999	3,815	30	,001
	ANFIS Çıkışı	16	358,0813	32,27469			
İtme radyal kuvvet	Gerçek Çıkış	16	173,1875	66,37994	2,913	30	,007
	ANFIS Çıkışı	16	117,1582	38,91056			
İlerleme kuvveti	Gerçek Çıkış	16	101,5625	73,69303	1,017	30	,317
	ANFIS Çıkışı	16	78,9623	49,66100			
Sıcaklık	Gerçek Çıkış	16	386,3750	35,88105	6,501	30	,000
	ANFIS Çıkışı	16	327,6897	4,02786			

Tablo 5.13'de görüldüğü gibi 4 dilsel ifadeye ayrılmış ANFIS hybrid eğitim algoritması ile yapılan 30 çevrimlik eğitim sonucunda teğetsel kuvvet, radyal kuvvet, ilerleme kuvveti ve sıcaklık ağ çıkışları ile gerçek çıkışlarının karşılaştırılması sonucunda gruplar arasında fark bulunduğu görülmüştür.

6. SONUÇ ve ÖNERİLER

Bu çalışmada tornalamada farklı talaş açısı, yaklaşma açısı ve kesme hızı değerlerinde oluşan teğetsel kesme kuvveti, radyal kuvvet, ilerleme kuvveti ve takım ucu sıcaklığının Bulanık Mantık, Yapay Sinir Ağı ve Bulanık Sinir Ağı teknikleriyle modellemesi yapılmıştır.

Tornalamada değişik kesme şartlarında elde edilen kuvvetler ve takım ucu sıcaklığının en büyük özelliği belirsizlik içeren sözel ve sayısal bilgi ile verileri aynı anda insan aklına en yakın biçimde işleyebilen bulanık mantık ile modellemesi yapılmıştır. Deney sonuç değerleri bulanık mantık da sözel ifadelere ayrılırken, deney verilerindeki her bir verinin sadece dört değerden oluşmasından dolayı oluşturulan modelde girişler dört dilsel ifadeye ayrılıp çıkışlarda daha fazla hassasiyet sağlayabilmek için dilsel ifade sayısı daha yüksek sayıda tutulmuştur. Mandani çıkarım yöntemi ile oluşturulan modelde Tablo 5.3'de ki T-testi sonuçlarına göre deney sonuçları ile Bulanık Mantık ile oluşturulan model arasında önemli bir fark olmadığı görülmüştür.

Deney verilerinin Yapay Sinir Ağının Geri Yayılım ve Levenberg-Marquardt öğrenme metotları ile modellemelerinden genel olarak şu sonuçlar çıkarılmışıtr.

- Levenberg-Marquardt metodu geri-yayılım öğrenme metoduna göre daha az çevrimde daha iyi hata oranına sahip olabilmektedir.
- Nöron sayısının artması hata oranının azalması yönünde olumlu bir etkisi vardır.
- Nöron sayısının daha fazla ve hata oranının daha düşük olması deney verileri tahmin etmede her zaman olumlu bir etki yapmamaktadır (Kolerasyon oranı düşmektedir).
- Tablo 5.6 ile Tablo 5.7 karşılaştırıldığında Geri-yayılım metodu Levenberg-Marquardt metoduna göre deney verilerini tahmin etmede daha iyidir.

Deney verilerinin Bulanık Mantık ve Yapay Sinir Ağının birleşmesinden oluşan Bulanık Sinir Ağı ile eğitiminde eğitim verileri önce 3 dilsel ifadeye ayrılmıştır. Veriler normalize edilerek hybrid metodu ile eğitime tabii tutulmuştur. 70 çevrim sonucunda hata oranı yaklaşık olarak 10^{-2} bulunmuştur. 3 dilsel ifade için

oluşturulan bulanık sinir ağının T-testi sonuçları Tablo 5.11'de incelendiğinde deney veri grubuna çok yakın sonuçlar elde edildiği görülmektedir. Bulanık sinir ağında girişlerin 4 dilsel ifadeye ayrılarak yapılan eğitim sonucu hata oranı yaklaşık 10^{-7} olmasına rağmen Tablo 5.13 de ki T-testi sonuçları incelendiğinde teğetsel kesme kuvveti ve sıcaklık ($p<0,005$) çıkışlarının anlamlılık seviyesinin altında kalarak gerçek çıkış değerlerinden farklı bir veri grubu oluşturdukları görülmektedir.

Deney verilerini modellemek için oluşturulan üç ayrı yapay zeka tekniğinin T-testleri karşılaştırıldığında Bulanık Uzman Sistem ve Bulanık Sinir Ağının deney verilerini tahmin etmede daha başarılı olduğu gözükmektedir. YSA ile oluşturulan modellerde ise deney verilerini tahmin etmede Bulanık Uzman Sistem ve Bulanık Sinir Ağı kadar başarılı olmadığı görülmektedir.

Ayrıca bu çalışma ile maliyet ve zaman gereksinimine ihtiyaç duyan bu deneyin modellenmesi üç yapay zeka tekniği ile de sağlanmıştır. Bu modellemeler ile deney verileri içerisinde bulunmayan değerlere karşılık gelecek sonuçları da öğrenmek mümkün olmaktadır.

Yapılan bu çalışma az sayıda veri içeren benzer veri gruplarının modellenmesinde değerlerin dilsel ifadelere ayrılabildiği Bulanık Uzman Sistem ve Bulanık Sinir Ağı yapay zeka tekniklerinin sistem modellemesinde başarılı olduklarını göstermektedir.

KAYNAKLAR

Allahverdi , N., 2003. Bulanık Mantık ve Sistemler Ders Notları, http://farabi.selcuk.edu.tr/egitim/bulanik.

Baykal, N., Beyan, T., 2004. Bulanık Mantık İlke ve Temelleri, Bıçaklar Kitapevi, 413 sayfa

Buja, G. S. ve Todesco, F., 1994. Neural network implementation of a fuzzy logic controller, IEEE Transactions on Industrial Electronics, 41, 6,663-667.

Chen, C. ve Chen W., 1994. Fuzzy controller design by using neural network techniques, IEEE Transactions on Fuzzy Systems, 2, 3, 235-244.

Çobanoğlu, B., 2006. Bulanık Mantık ve Bulanık Küme Teorisi, http://www.cobanoglu.fws1.com/bulanik.htm.

Demuth, H., Beale, M., 2005. Neural Network Toolbox User's Guide. The Mathworks Version 4.

Ham, F.M., Kostonic, I., 2002. Principles of Neurocomputing for Science and Enginering, Mc-Grow Hill.

Jang, J. R. and Sun, C. 1995. Neuro-Fuzzy Modeling and Control, Proceedings of the IEEE, 83, 378-406.

Efe, Ö., Kaynak, O., 2000. Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, 148 sayfa.

Elmas, Ç., 2003. Bulanık Mantık Denetleyiciler (Kuram,Uygulama. Sinirsel Bulanık Mantık), Seçkin kitabevi, 230 sayfa.

Erentürk, S., Erentürk, K., 2003. International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003

Grossberg, S., 1987. Competitive learning: From interactive activation to adaptive resonance, Cognitive Science (Publication), 11.

Hinton, G.E., Sejnowski, T.J.Ackley, D.H., 1985. A Learning Algorithm for Boltzmann Machines, Cognitive Science, 9, 147-169.

Jang, J.S.R., 1993. ANFIS: Adaptive-Network Based Fuzzy Inference Systems. IEEE Trans. on Systems, Man, and Cybernetics,23 (03) 665-685

Jang, J. R. and Sun, C. 1995. Neuro-Fuzzy Modeling and Control, Proceedings of the IEEE, 83, 378-406.

Kaya, M., Tuncer, İ.H., 2004. Çırpan Kanat Kesitlerinde İtkinin yapay Zeka ile Eniyileştirilmesi, Havacılıkta İleri teknolojiler ve Uygulamaları Sempozyumu, HHO, İstanbul.

Kohonen, T., 1988. "An introduction to neural computing", Neural Networks.

Kohonen, T., 1989. "Self-Organization and Associative Memory", Berlin:Springer.

Kohonen, T., 1990. "The Self-Organizing Map", Proceedings of IEEE International Conference on Neural Networks, San Diego.

Narendra, K.S., 1997, Adaptive Control Using Neural Networks and Approximate Models,, IEEE Trans. on Neural Networks, 8, 475-485

Nguyen, H.T., Prasad, N.R., Walker, C.L., Walker, E.A., 2003, A First Course in Fuzzy and Neural Control, A Crc Pres Company,London.

Öztemel, E., 2003, Yapay Sinir Ağları, Papatya Yayıncılık, 232 sayfa, İstanbul.

Rumelhart D. E., Hinton G. E., ve Williams R., 1986. 'Learning Representations By Back Propagating Errors', Nature, 323, 533-536.

Şen, Z., 2001, Bulanık Mantık ve Modelleme İlkeleri, Bilge Yayıncılık, İstanbul.

Tong, R.M., 1977. A Control Engineering Review of Fuzzy Systems", Automatica, Vol:13, pp:559-569, Pergaman Pres.

Tsoukalas, L.H., Uhrig, R.E. 1996. Fuzzy and Neural Approaches in Engineering. New York, NY: John Wiley & Sons.

Wang, L. X., 1993. Stable adaptive fuzzy control of nonlinear systems, IEEE Transactions on Fuzzy Systems 1, 2, 46-155.

Widrow, B. ve Hoff, M.E., 1960. Adaptive switching circuits, 1960 IRE WESCON Convention Record, New York IRE, 96-100.

Yaldız, S., Sağlam,H. Ünsaçar,F., 2005. The Effect Of Tool Geometry And Cutting Speed On Main Cutting Force And Tool Tip Temperature Materials & Design , Received 9 December 2004; Accepted 25 May 2005.

Yıldırım, Y., Bayramoğlu, M., 2004. ANFIS Neuro Fuzzy Yöntemi ile havadaki SO Konsantrasyonunun Modellenmesi ve Tahmini, Cumhuriyet Üniversitesi Çevre Mühendisliği bölümü I. Ulusal Çevre Kongresi.

Zadeh, L.A., 1965. "Fuzzy Sets" , Information Control, Vol.8, pp. 338-353