



MAYA HÜCRELERİNİN BÜYÜME EĞRİSİNİN  
AKILLI SİSTEMLER İLE MODELLENMESİ

Necati KARAKUŞ

Yüksek Lisans Tezi

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Şubat - 2019

MAYA HÜCRELERİNİN BÜYÜME EĞRİSİNİN AKILLI SİSTEMLER İLE  
MODELLENMESİ

Necati KARAKUŞ

Kütahya Dumlupınar Üniversitesi

Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliği Uyarınca

Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında

YÜKSEK LİSANS TEZİ

Olarak Hazırlanmıştır.

Danışman: Doç. Dr. Eyyüp GÜLBANDILAR

Şubat – 2019

## KABUL VE ONAY SAYFASI

Necati KARAKUŞ 'un Yüksek Lisans tezi olarak hazırladığı “Maya Hücrelerinin Büyüme Eğrisinin Akıllı Sistemler İle Modellenmesi” başlıklı bu çalışma, jürimizce Kütahya Dumlupınar Üniversitesi Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

06/02/2019

Prof. Dr. Önder UYSAL

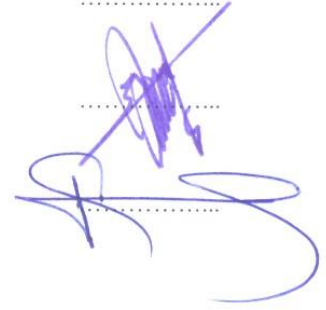
**Enstitü Müdürü, Fen Bilimleri Enstitüsü**

Prof. Dr. Mehmet Ali EBEOĞLU

**Elektrik-Elektronik Mühendisliği Anabilim Dalı Başkanı**

Doç. Dr. Eyyüp GÜLBANDILAR

**Danışman, Bilgisayar Müh. Bölümü, ESOGÜ**



**Sınav Komitesi Üyeleri**

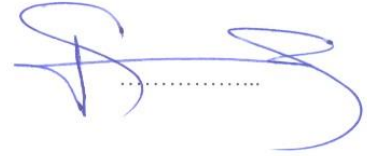
Prof. Dr. Ecir Uğur KÜÇÜKSİLLE

Bilgisayar Müh. Bölümü, Süleyman Demirel Üniversitesi



Doç. Dr. Eyyüp GÜLBANDILAR

Bilgisayar Müh. Bölümü, Eskişehir Osmangazi Üniversitesi



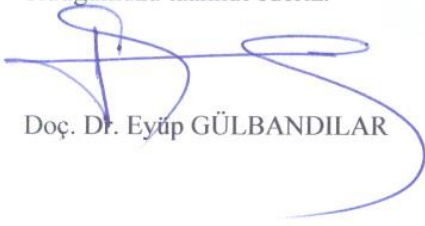
Dr. Öğr. Üyesi Muammer AKÇAY

Bilgisayar Müh. Bölümü, Kütahya Dumlupınar Üniversitesi



## ETİK İLKE VE KURALLARA UYGUNLUK BEYANI

Bu tezin hazırlanmasında Akademik kurallara riayet ettiğimizi, özgün bir çalışma olduğunu ve yapılan tez çalışmasının bilimsel etik ilke ve kurallara uygun olduğunu, çalışma kapsamında teze ait olmayan veriler için kaynak gösterildiğini ve kaynaklar dizininde belirtildiğini, Yüksek Öğretim Kurulu tarafından kullanılmak üzere önerilen ve Dumlupınar Üniversitesi tarafından kullanılan İntihal Programı ile tarandığını ve benzerlik oranının %23 çıktığını beyan ederiz. Aykırı bir durum ortaya çıktığı takdirde tüm hukuki sonuçlara razı olduğumuzu taahhüt ederiz.



Doç. Dr. Eyüp GÜLBANDILAR



Necati KARAKUŞ

# MAYA HÜCRELERİNİN BÜYÜME EĞRİSİNİN AKILLI SİSTEMLER İLE MODELLENMESİ

Necati KARAKUŞ

Elektrik – Elektronik Mühendisliği, Yüksek Lisans Tezi, 2019

Tez Danışmanı: Doç. Dr. Eyyüp GÜLBANDILAR

## ÖZET

Bu çalışmada gıda sektöründe yaygın bir şekilde kullanılan *Saccharomyces cerevisiae* maya hücresinin üreme eğrisinin yapay sinir ağları (YSA), uyarlamalı ağ tabanlı bulanık çıkarım (ANFİS) ve bulanık mantık kullanılarak modellenmesi amaçlanmıştır.

YSA modelinin tasarımı aşamasında üreme zamanı giriş değişkeni olarak belirlenirken, saatlik hücre sayıları çıkış değişkeni olarak belirlenmiştir. Deneysel verilerin 144 tanesi modelin eğimi için kullanılırken, 48 tanesi eğitilmiş modelin test edilmesi için kullanılmıştır.

ANFİS modelinin tasarımı için üreme zamanı ve hücre sayıları birlikte giriş değişkeni olarak belirlenmiştir. Tüm öğrenme algoritmaları deneyerek ortaya çıkan en iyi korelasyonun 300 epoch olarak eğitilmiştir. Deneysel verilerin 168 tanesi modelin eğimi için kullanılırken, 24 tanesi eğitilmiş modelin test edilmesi için kullanılmıştır.

Bulanık Mantık (Fuzzy Logic) modelinde, giriş üyelik fonksiyonları zaman, çıkış üyelik fonksiyonları için hücre sayıları kullanılmıştır. Zaman aralıkları ve hücre sayılarından oluşan üyelik fonksiyonlarını, sezgisel olarak en iyi sonuç vereceği düşünülen aralıklara yerleştirilmiştir. Deneysel verileride gözönünde bulundurarak, modelin kuralları belirlenmiştir. Belirlenen kurallar çerçevesinde tüm üyelik fonksiyonlarından çıkış verileri elde edilmiş olup kayıt altına alınmıştır.

Geliştirilen modeller için hem eğitim hem de test verilerinde yüksek uyum göstermiştir ( $R^2=0,996-0,999$  RMS=0,32-0,87 MAPE=1,80-6,13). Ayrıca YSA modellerinden elde edilen matematiksel model parametreleri yazılmıştır.

**Anahtar Kelimeler:** Anfis, Bulanık mantık, *Saccharomyces cerevisiae*, Uyarlamalı ağ tabanlı bulanık çıkarım, Üreme eğrisi, Yapay sinir ağları.

# MODELING OF GROWTH CURVE OF MAYA CELLS WITH SMART SYSTEMS

Necati KARAKUŞ

Electrical- Electronics Engineering, M.S. Thesis, 2019

Thesis Supervisor: Doç. Dr. Eyyüp GÜLBANDILAR

## SUMMARY

In this study, it is aimed to model the growth curve of *Saccharomyces cerevisiae* yeast cell, which is widely used in food industry, using artificial neural networks (ANN), adaptive network based fuzzy inference (ANFIS) and fuzzy logic.

At the design stage of ANN model, the growth time was determined as an input variable, while the cell numbers per hour were determined as an output variable. 144 experimental data were used for the training of the model while 48 were used for testing the trained model.

For designed ANFIS model, growth time and cell numbers were determined as an input variable. All the training algorithms are tested and the best correlation is found for 300 epoch. While 168 of the experimental data were used for the training of the model, the 24 trained model were used for testing.

The same input and output parameters were used for the fuzzy logic model. The membership functions, which consist of the growth time and cell numbers per hour, are intuitively placed at intervals considered to be the best result. Considering the experimental data, the rules of the model were determined. Output data from all membership functions have been obtained within the framework of the determined rules and recorded.

It is found that a high level corelation for training and testing data in the developed models ( $R^2=0,996-0,999$  RMS=0,32-0,87 MAPE=1,80-6,13). In addition, mathematical model parameters obtained from ANN models were written.

**Keywords:** Anfis, fuzzy logic, *Saccharomyces cerevisiae*, Adaptive network-based fuzzy inference, growth curve, Artificial neural networks.

## TEŞEKKÜR

Tezimin sonuçlanmasında bana sınırsız destek veren özellikle danışmanım Doç. Dr. Eyyüp GÜLBANDILAR'a, beni her daim destekleyen hayat arkadaşım ve eşim Didem ÖZDEN KARAKUŞ'a, tezi bitirmem için beni cesaretlendiren Mahmut Onur FİKİRLİ'ye, emeklerini ve desteklerini esirgemeyen tüm dostlarıma teşekkür ederim.



## İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET .....	v
SUMMARY .....	vi
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ .....	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiii
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	3
2.1. Bulanık Mantık (Fuzzy Logic) .....	3
2.1.1. Bulanık mantık tarihçesi.....	3
2.1.2. Bulanık mantık ve kapsamı .....	3
2.1.3. Bulanık mantığın avantajları/dezavantajları .....	5
2.1.4. Bulanık mantık modelleme aşamaları.....	6
2.2. Yapay Sinir Ağları (YSA).....	19
2.2.1. Yapay sinir ağları kavramı ve kapsamı .....	19
2.2.2. Yapay sinir hücresi modeli .....	20
2.2.3. Yapay sinir ağlarının avantaj ve dezavantajları.....	24
2.3. ANFIS .....	26
2.3.1. ANFIS kavramı ve özellikleri.....	26
2.3.2. ANFIS modelinin mimarisi .....	27
3. MATERYAL VE METOD.....	30
3.1. Bulanık Mantık Tasarımı .....	31
3.1.1. Bulanıklaştırma birimi.....	32
3.1.2. Kural ve veri tabanı .....	34
3.1.3. Çıkarım birimi.....	36
3.1.4. Durulaştırma Birimi .....	37
3.2. Yapay Sinir Ağlarının Tasarımı .....	38
3.2.1. YSA eğitim safhası .....	39
3.2.2. YSA test safhası.....	44
3.3. ANFIS Tasarımı.....	46
3.3.1. Üçgen üyelik fonksiyonu.....	48
3.3.2. Yamuk üyelik fonksiyonu .....	51



**İÇİNDEKİLER (devam)**

	<b><u>Sayfa</u></b>
3.3.3.Çan eğrisi üyelik fonksiyonu.....	52
3.3.4. Gauss1 üyelik fonksiyonu .....	53
3.3.5. Gauss2 üyelik fonksiyonu .....	54
3.3.6. Pi şekilli üyelik fonksiyonu .....	55
3.3.7. Sigmodial (Psigma ve dsigma) üyelik fonksiyonu.....	56
4. SONUÇLAR .....	58
KAYNAKLAR DİZİNİ.....	59
ÖZGEÇMİŞ	



## ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. Bulanık çıkarım sistemi.....	6
2.2. Bulanık çıkarım sistemlerinin genel çalışma şeması. ....	7
2.3. Üyelik fonksiyonunun kısımları. ....	7
2.4. MATLAB’de kullanılan üyelik fonksiyonları.....	8
2.5. Üçgen üyelik fonksiyonu.....	9
2.6. Gauss üyelik fonksiyonu. ....	10
2.7. Yamuk üyelik fonksiyonu.....	11
2.8. Mamdani çıkarım yöntemi. ....	13
2.9. TSK çıkarım yönteminin gösterimi ....	14
2.10. En büyüklerin en küçüğü yöntemi. ....	15
2.11. En büyüklerin en büyüğü yöntemi.....	16
2.12. Ağırlık merkezi yöntemi.....	16
2.13. Mean-Max üyelik yöntemi. ....	17
2.14. Ağırlık ortalaması yöntemi. ....	18
2.15. Maksimum üyelik yöntemi.....	19
2.16. Merkezi sinir ağı. ....	21
2.17. Biyolojik sinir hücresinin bölümleri.....	21
2.18. Yapay sinir hücre modelinin yapısı. ....	23
2.19. Bir işlemci elemanı (yapay nöron). ....	24
2.20. ANFIS temel yapısı. ....	27
3.1. Gaussian üyelik fonksiyonu ve üyelik derecesi hesaplama denklemi. ....	32
3.2. On ikinci saat için verilen üyelik fonksiyonu ve üyelik dereceleri. ....	33
3.3. Zaman giriş verilerinin üyelik fonksiyonları ve üyelik fonksiyonu dereceleri.....	33
3.4. Hücre sayısı çıkış verilerinin üyelik fonksiyonları ve üyelik fonksiyonu dereceleri.....	34
3.5. Çıkış verilerine bir örnek.....	35
3.6. Yapay sinir ağlarında network oluşturma seçenekleri.....	39
3.7. Feed-forward backprop ağında kullanılan iki katmanlı YSA modelinin blok şeması. ....	39
3.8. Feed-forward backprop ağında kullanılan üç katmanlı YSA modelinin blok şeması.....	40
3.9. Feed-forward ağında backprop kullanılan dört katmanlı YSA modelinin blok şeması. ....	41
3.10. Elman backprop ağında kullanılan iki katmanlı YSA modelinin blok şeması. ....	42
3.11. Elman backprop ağında kullanılan üç katmanlı YSA modelinin blok şeması. ....	42

## ŞEKİLLER DİZİNİ (devam)

<u>Sekil</u>	<u>Sayfa</u>
3.12. Elman backprop ađında kullanılan dört katmanlı YSA modelinin blok şeması. ....	43
3.13. YSA modelinin eğitim ve test safhaları için sonuçların mukayyesesi. ....	45
3.14. ANFIS modelinin genel görüntüsü ve parametreleri. ....	47
3.15. Giriş deđişkeni olarak girilen zaman üyelik fonksiyonları. ....	47
3.16. Üçgen üyelik fonksiyonu girdi verilerinin yüklenmesi. ....	48
3.17. Üyelik fonksiyon tipi ve nöron sayısının belirlenmesi. ....	48
3.18. Eğitim sonucu hata oranı. ....	49
3.19. Üçgen üyelik fonksiyonun zaman aralıkları. ....	50
3.20. Üçgen üyelik fonksiyonu giriş-çıkış verileri. ....	50
3.21. Yamuk üyelik fonksiyonu eğitim sonrası hata oranı. ....	51
3.22. gbellmf üyelik fonksiyonu eğitim sonrası hata oranı. ....	52
3.23. Gaussmf üyelik fonksiyonu eğitim sonrası hata oranı. ....	53
3.24. Gauss2mf üyelik fonksiyonu eğitim sonrası hata oranı. ....	54
3.25. Pimf üyelik fonksiyonu eğitim sonrası hata oranı. ....	55
3.26. Sigmoidal üyelik fonksiyonu eğitim sonrası hata oranı. ....	56

## ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
2.1. Fuzzy Logic ile Klasik modellerin belli başlı farklılıkları .....	4
2.2. Yapay sinir ağları elemanlarının biyolojik sinir sistemdeki karşılıkları .....	22
3.1. Bulanık mantık modelinde test ve deneysel sonuçlar arasındaki hata oranları .....	38
3.2. Feed-forward backprop ağında iki katmanlı modelde kullanılan parametre değerleri .....	40
3.3. Feed-forward backprop ağında üç katmanlı modelde kullanılan parametre değerleri.....	40
3.4. Feed-forward backprop ağında dört katmanlı modelde kullanılan parametre değerleri .....	41
3.5. Elman backprop ağında iki katmanlı modelde kullanılan parametre değerleri .....	42
3.6. Elman backprop ağında üç katmanlı modelde kullanılan parametre değerleri.....	43
3.7. Elman backprop ağında dört katmanlı modelde kullanılan parametre değerleri .....	43
3.8. YSA matematiksel modelin katsayıları.....	44
3.9. YSA modelinin eğitimi ve testi neticesinde oluşan hata verileri.....	46
3.10. Anfis modelinde eğitim ve deneysel sonuçlar arasındaki hata oranları.....	57
4.1. Akıllı sistemlerin karşılaştırma sonuç oranları .....	58

## SİMGELER VE KISALTMALAR DİZİNİ

### Simgeler

Knot	Hava Aracı Hız Birimi
$\mu_{\bar{A}}$	Üyelik Fonksiyonu
$\sigma$	Üyelik Fonksiyonunun Genişliği
$\text{mm}^3$	Milimetre Küp
ml	Mililitre
m	Üyelik Fonksiyonu Orta Noktası
$Z^*, Y^*$	Durulaştırılmış Değer
$\Theta, b$	Eşik değeri
$t_i$	Zaman
$O_i$	Çıktı

### Kısaltmalar

### Açıklama

ANFIS	Adaptive Neuro Fuzzy Inference
YSA	Yapay Sinir Ağları
TSK	Takagi-Sugeno-Kang
Nntool	Neural Network Fitting Tools
FIS	Fuzzy Inference System
ANN	Artificial Neural Network
ART	Adaptive Resonance Theory
$R^2$	Regrasyon (Test ve Eğitim verileri için belirleme katsayısı)
RMS	Root Mean Square Standart Error
MAPE	Mean Absolute Percentage Error
HS	Hücre Sayısı

## 1. GİRİŞ

Tomurcuklanan bir maya türü olan *Saccharomyces cerevisiae* eski çağlardan beri bira, şarap ve ekmek mayası olarak kullanılmaktadır. Maya hücreleri dairesel veya halka biçimlidir, 5-10 mikrometre çapı vardır. *Saccharomyces cerevisiae* hücreleri bölünme yoluyla (tomurcuklanma) üretilmektedir (Wikipedi, 2018). Maya hücreleri, funguslar âleminin Ascomycetes sınıfının Saccharomycetaceae alt sınıfının bir üyesidir. *Saccharomyces cerevisiae* bununla beraber gıdasal ferment ve ferment özünün temelidir. *Saccharomyces cerevisiae* biyolojide geniş bir kullanım sahası vardır. *Saccharomyces cerevisiae* elverişli besin şartlarında tomurcuklanarak gelişmesi ve kültürlenmesi kolay olmasından ötürü hücre döngüsü araştırmalarında çok fazla kullanılmaktadır. Model, organizmalar arasında biyolojide üzerinde en çok çalışma yapılan hücrelerdendir. *Saccharomyces Cerevisiae* hücrelerinin hayat çevrimi haploid ve diploid olarak 2 şekildedir. Haploid hücre olağan durumlardaki yaşam çevriminde görülürken, Diploid hücre stres şartlarında mayoz bölünmeye başlamaktadır (Gülbandılar, 1996).

Maya hücrelerinin yaşam sürecinde zaman hücre sayısı grafiği oluşturulabilir. Bu oluşturulan grafiğin ismi ise büyüme eğrisi olarak adlandırılır. *Saccharomyces cerevisiae* maya hücrelerinin büyüme eğrisini matematiksel model denklemler ile tanımlanabilir. Zwietering ve arkadaşları tarafından düzenlenen Gompertz denklemi ve

$$N(t) = A + C \cdot \exp[-\exp[-B(t - M)]] \quad (1)$$

şeklinde gösterilebilir. Matematiksel modelde A zamanın eksi sonsuza gittiği durumdaki sabiti, C logaritmik fazın bitimindeki hücrenin sayısal olarak miktarını, M bakterilerin azami büyüme yüzdesine eriştiği zamanı, B ise M anındaki göreceli büyüme yüzdesini sergilemektedir (Simon ve Kariml, 2001). Diğer bir matematiksel model bakış açısı da S-biçimindeki büyüme eğrisinin ilk tanımlaması ise Verhulst tarafından gerçekleştirilmiştir. Matematiksel tanım Verhulst lojistik denklemi şeklinde tanımlanır. Denklem;

$$N(t) = \frac{N_s}{1+k \cdot e^{-\mu \cdot t}} \quad (2)$$

şeklinde yazılabilir. Bu matematiksel tanımda,  $N_s$  denklik şartlarındaki bakteri sayısını,  $\mu$  artış değerini (oransal olarak),  $t$  süreyi,  $N_0$  ekilen bakteri miktarını ve  $k = \frac{N_s - N_0}{N_0}$  sabit bir değeri göstermektedir (Gülbandılar, 1996).

Son dönemlerde, bu alanda akıllı sistemler ile yapılan çalışmaların kullanımı yaygınlaşmaktadır. Hajmeer vd. farklı görüş ortaya koyarak, *Escherichia coli* hücrelerinden

meydana getirdikleri üreme eğrisinin YSA ile tasarlanması adına araştırma uygulamışlardır (Hajmeer vd., 2000). Jeyamkondan S. ve arkadaşları da *Escherichia coli*, *Aeromonas hydrophila*, *Shigella flexneri* ve *Brochothrix thermosphacta* bakterileri döngüsü üzerine çalışmışlardır (Jeyamkondan S. vd., 2002). Yine olasılıksal yapay sinir ağları tekniği kullanılarak Simon ve Kariml, *Bacillus subtilis* bakterilerinin hayat çevrimindeki gelişme aşamalarının olasılıksal YSA (Probabilistic neural networks) desteğiyle tahmin uygulamasını sonuca ulaştırmışlardır (Simon ve Kariml, 2001). Garcia-Gimeno vd. gerçekleştirdikleri araştırmalarında besinlerindeki mikrobiyal gelişme döngüsünün kararlaştırılmasında YSA ve genetik algoritma metodunu kullanmışlardır (Garcia-Gimeno vd., 2002). Gıda sektöründe kapsamlı olarak faydalanılan *Saccharomyces cerevisiae* hücresinin tomurcuklanma evresinin meydana gelmesi akademik ve sanayi çalışmalarında deneyler düzenlenmeden model baz alınarak ortaya konması, deney maliyetlerini ve işçilik maliyetlerini yok edecektir. Yaptığımız çalışmayla *Saccharomyces cerevisiae* hücresinin çoğalma eğrisinin matematiksel modelleme araştırmalarına değişik görüş açısı geliştirilmesi amaçlanmıştır. Belirtilen alanlarda çok fazla yararlanılan ve akıllı sistem yöntemleri olarak ANFIS, YSA ve Bulanık mantık (Fuzzy Logic) tercih edilmiştir.

Hemen hemen tüm bilim dallarında kullanılan akıllı sistemler, son dönemlerde yapılan çalışmalarla gıda alanında da rahatlıkla kullanılabileceğini gösterilmiştir. Bu çalışmada akıllı sistemlerin özellikleri, Bulanıklaştırma aşamasında üçgen, yamuk, Gauss1, Gauss2, pi, psigma ve dsigma üyelik fonksiyonları kullanılmış. Çıkarım aşamasında Neural Network Fitting Tools, Takagi-Sugeno-Kang (TSK) ve Mamdani yöntemi kullanılmıştır. Analizler MATLAB (Matrix Laboratory) programın FIS, ANFIS ve Neural Network Fitting Tools (nntool) editörü ile yapılmıştır.

Tez çalışmasının birinci bölümünde temel bilgiler anlatılmakta ve tez çalışması kısaca özetlenmektedir. İkinci bölümde yapılan çalışmada kullanılan akıllı sistemler hakkında daha detaylı bilgiler verilmekte olup bu akıllı sistemlerin genel olarak bilgilendirmesi yapılmaktadır. Üçüncü bölümde, maya hücrelerinin zamanla üremeleri sonucunda elde edilen hücre sayılarını baz alarak MATLAB'in editörleri olan FIS (Fuzzy Inference System) MAMDANI metodu kullanılarak Bulanık mantık (Fuzzy Logic) ile modellenmeye çalışılmıştır, yine MATALAB'in Neuro-Fuzzy Design editörüyle ANFIS sistemi modellenmeye çalışılmıştır ve son olarak Neural Network Fitting Tools editor kullanılarak maya hücrelerinin büyüme eğrisi Yapay Sinir Ağlarıyla (YSA) modellenmiştir. Dördüncü bölüm ve Sonuç kısmında yapılan çalışmayla ilgili ulaşılan sonuçlar değerlendirilmektedir.

## 2. GENEL BİLGİLER

### 2.1. Bulanık Mantık (Fuzzy Logic)

#### 2.1.1. Bulanık mantık tarihçesi

Mantık kavramının esaslarını oluşturan eski dönemden modern döneme kadar birçok filozof, araştırmacı, düşünür mantık alanına katkıda bulunmuştur. Aristo mantığında sadece "sıcak" ve "soğuk" vardır. 1900'lü yılların başlarında Jan Lukasiewicz (1878-1956) Aristo mantığına ek olarak iki değer yanına üçüncü bir değer olarak 2 değerini eklemiştir [0,1,2], Donald E. Knuth (1938) [-1,0,1] tamsayı değerlerini kullanmıştır. Belirtilen yöntemler ilerleyen yıllarda önemsenmemiş ve kabul görmemiştir (Kıyak, 2003). 1965 yılında ilk olarak Azerbaycan asıllı bilim adamı Lütüfî Askerzade (Zadeh), insan düşüncesindeki belirleyici fikirlerin sayılar olmayıp bulanık kümelerin seviyeleri olduğunu gözlemlemesi ile Bulanık mantığı bilim dünyasına kazandırmıştır. 1975 tarihinde Assilian ve Mamdani tarafından bulanık mantık kavramı ilk defa bir buhar makinasının kontrol sistemine entegre edilmesi ile uygulamaya geçmiştir. 1980 yılında ise Danimarka'da bulunan bir çimento fabrikasının işletilmesi ve kontrolünde ticari amaçla kullanılmıştır. 1987 yılında Hitachi firması tarafından Sendai metrosu bulanık mantık temeliyle gerçekleştirilmiş ve trenin istenen konumda durması üç kat daha iyileştirilmiştir. 1988 yılında Tokyo Borsasında kara Pazar olarak da anılan krizin sinyallerini Yamaichi Securities tarafından bulanık mantık temelli akıllı sistem tam 18 gün önceden haber vermiştir (Keskenler ve Keskenler, 2017).

Yaşanan olumlu gelişmeler üzerine bulanık mantık çalışmalarına ilgi artmış ve 1989 yılında aralarında IBM, Matsuhita, Toshiba, Omron, SGS, Thomson gibi firmalarında olduğu toplam 51 şirket bir araya gelerek Laboratory for Interchange Fuzzy Engineering (LIFE) isimli laboratuvarları kurmuştur (Ertunç, 2012). Bulanık mantığın Türk dünyası ve Japonya'da batıya nazaran daha çok kabul görmesinin nedeni olarak buralardaki düşünce yapısının uyumluluğundan kaynaklanmaktadır.

#### 2.1.2. Bulanık mantık ve kapsamı

Bulanık mantık, puslu mantık olarak da anılmaktadır. Zadeh'in 1961 yılında yayımladığı bir makalenin neticesinde oluşmuş düşünce yapısıdır. Bulanık mantığın temeli bulanık küme ve alt kümelere dayanır. İkili mantık olarak bilinen klasik yaklaşımda bir varlık kümenin elemanıdır veya değildir. Varlığın kümeyle olan üyelik bağları bakımından matematik açısından ifade edilecek olursak, kümeye ait eleman olması durumunda "1", kümeye ait eleman olmadığı



durumda ise “0” değerini alır. Bulanık mantık, gündelik hayat için yeterli olmayan klasik kümenin genişletilmiş gösterimidir. Bulanık mantık kümelerinde tüm varlıkların kendine ait bir üyelik derecesi mevcuttur. Üyelik fonksiyonlarının üyelik derecesiyse, [0, 1] arasında bir değer alabilir ki bu değer olan üyelik fonksiyonunu  $M(x)$  şeklinde gösterebiliriz. Klasik kümelerin aksine insan düşünce, yapısı ve doğal dil ruhunu daha yakın olan, bulanık kümelerde varlıkların üyeliklerinin derecesi [0, 1] arasında sonu olmayan şekilde değiştirilebilir. Net olan kümelerdeki siyah-beyaz, genç-yaşlı, kolay-zor, uzun-kısa, zayıf-şişman gibi ikili değişkenler, bulanık mantıkta çok beyaz, orta yaşlı, biraz kısa ve benzer tamamlayıcılarla yumuşatılarak normal hayatta kullanılır. Buradaki önemli nüans, bu çeşit bir yapıda alınan verinin kaynağında bulunan küme üyelik bilgilerinin net olarak belirtilmiş ön koşullarının bulunmayışı ve daha fazla problemlerle random verilerin hazır olmayışındandır.

**Çizelge 2.1.** Fuzzy Logic ile Klasik modellerin belli başlı farklılıkları.

<b>Klasik Mantık</b>	<b>Bulanık Mantık</b>
A veya A Değil	A ve A Değil
Kesin	Kısmi
Hepsi veya Hiçbiri	Belirli Derecelerde
0 veya 1	0 ve 1 Arasında Süreklilik
İkili Birimler	Bulanık Birimler
modern dünya düşüncesine uygun değil.	Gerçek dünya düşüncesine uygun

İnsanlar herhangi bir konu hakkındaki kanaatlerini sözel olarak ifade ederler. Bu da gerçek dünya düşüncesine uygun (kesinlik içermeyen) bir gerçeği açıklar. Bulanıklık kavramı olarak karşımıza çıkacak en önemli ifade özellikle sözel belirsizliktir. Bununla beraber bulanık mantık, insanın bir konuyu kavrayıp muhakeme etmesi ve karar vermesine yardımcı bakımından önemli bir görevi; incelenen çok karmaşık ve yeterli bilgi olmaması durumunda uzman kişilerin görüş ve değer yargılarına yer vermesidir (Şen, 2009).

İnsanoğlu, özel hayatında ve iş hayatında hergün defalarca bir konu hakkında karar alabilir. Karar verirken sistemi tam olarak analiz edebilmek ve gerekli tüm değişkenlerin mevcut olmaması durumunda doğru kararlar verebilmektedirler. Bu konuya gerçek hayattan bir örnekle anlatacak olursak, uçakla piste inmeye çalışan bir pilot, uçağın hızını, rüzgarın hangi yönden kaç knot estiğini buna karşılık uçağın inişe geçince kaç derece açıyla piste yaklaşması gerektiği, pist bölgesinde hava sıcaklığını ve meteorolojik durumu, pist uzunluğu ve bu şartlarda uçağın pist

içinde durma mesafesi ve son olarak uçağın tekerini koyduğu pistin üzerindeki zeminin buzlu, ıslak ve kuru olduğunu sayısal olarak bilmediğimiz halde, uçağın üstünde bir şekilde dengede durur ve uygun bir açıyla düşmeden o uçağı piste indirebiliriz. Yapılan davranış, hiçbir matematiksel hesaplama yapılmadan doğru bir şekilde verilmesinde, insanların daha önceki tecrübeleri, deneyimleri ve benzer değerlerle karar verebilme kabiliyetinden kaynaklanmaktadır.

### **2.1.3. Bulanık mantığın avantajları/dezavantajları**

Çalışma prensibi açısından bulanık mantık, insana özgü düşünce yapısına ve karar verme mekanizmasına benzediğinden dolayı anlamlandırmak daha kolaydır. Uygulamasında matematiksel modelin gerekliliği yoktur (Kıyak, 2003).

#### **Bulanık mantık uygulamalarının avantajları şunlardır:**

- Kullanıcı girdilerine ve kullanıcının tecrübelerinden faydalanılabilmesine imkan vermesidir, İnsan düşünme tarzına yakın olması,
- Yazılımın basit çözümler getirdiğinden dolayı daha ekonomiktir.
- Uygulanışının matematiksel modele ihtiyaç duymaması, doğrusal olmayan düzenlerde güzel netice vermektedir.
- Farklı sistemlerde bulanık denetleyici adaptasyonu kolay bir şekilde yapılabilmektedir.
- Sisteme verilecek olan giriş-çıkış değişkenleri eş zamanlı olarak kullanılabilir, uyuşmayan kurallar modele uydurulabilir.
- İnter-output verilerinin, birleşimlerin tamamı için çıkış belirtme mecburiyeti bulunmamaktadır.

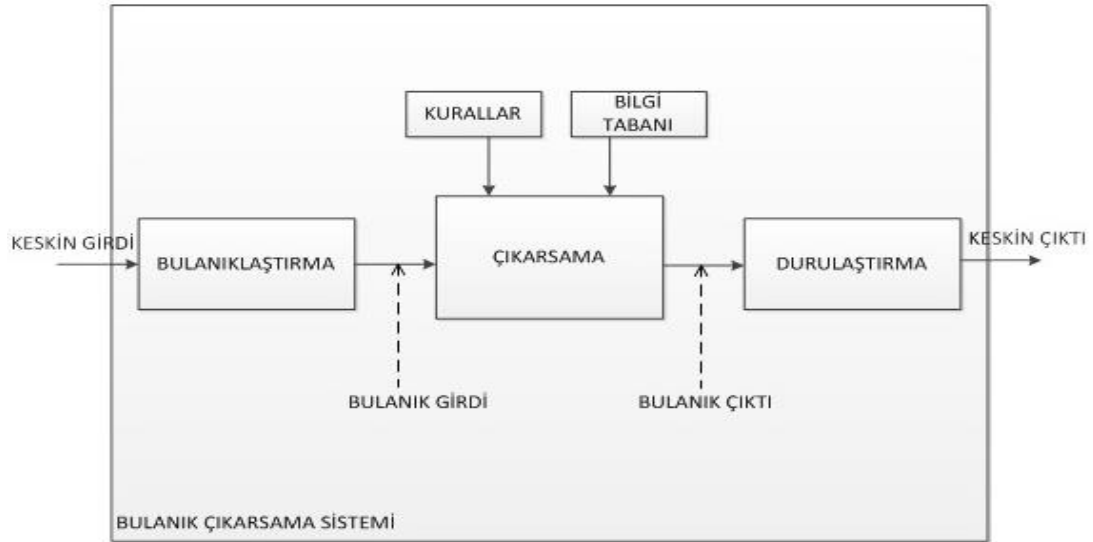
#### **Bulanık mantık uygulamalarının dezavantajları:**

- Yararlanılacak üyelik fonksiyonlarının seçiminde genel kurallar yoktur. Seçim işleri ise deneme yanılma yoluyla saptanması nedeniyle uzun sürebilmektedir.
- Denetlenebilirlik, gözetlenebilirlik, kararlılık ve analizinin yapılamaması bu yöntemin ana sorunudur.
- Çalışmalardaki yararlanılan kuralların belirlenmesinde söz sahibi uzmandır. Yararlanılan kurallar tabanı uzman deneyimlerine dayanmasına ihtiyaç vardır. Çünkü karar mekanizmasının temelinde yer almaktadır.

- Bulanık mantık ile tasarlanmış sistemler kendi kendine öğrenme kabiliyetleri yoktur. Bu yeteneğe sahip olmak için YSA kullanımı ve endüktif öğrenme gibi modeller kullanılmaktadır. Belirtilen koşulları sağlamayan hallerde, varolan kurallar kullanmak olası değil, şeklinde sıralanabilir (Sattarov, 2015).

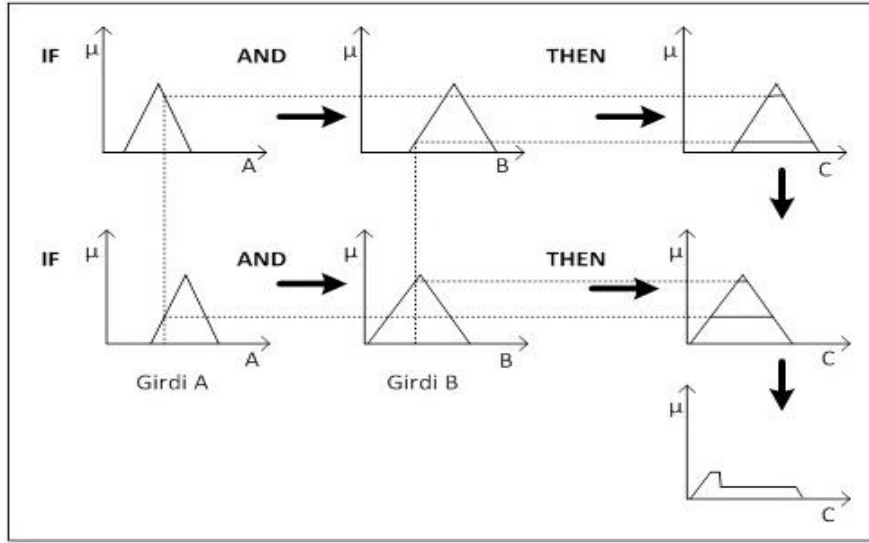
#### 2.1.4. Bulanık mantık modelleme aşamaları

Bulanık mantık modelleme safhasında 3 önemli aşaması bulunmaktadır. Bunlar sırasıyla bulanıklaştırma, çıkarım ve durulaştırma evreleridir. Takagi-Sugeno modelde ayrıca bir durulaştırmaya gerek duyulmaz (Takagi ve Sugeno, 1985). Tez kapsamında, bu evreler ayrı ayrı incelenmiştir. Şekil 2.1’de bulanık çıkarıma sisteminin genel görünümü gösterilmiştir.



Şekil 2.1. Bulanık çıkarım sistemi (netcad, 2018).


Bulanık mantık klasik mantığın daha genel hali olduğu için, aralık değerli sistemlerin genel hali olarak gösterilebilir. Kural tabanlı bulanık sistemler, if then (eğer ise) biçiminde tanımlanan bulanık sistemlerdir. Şekil 2.2’de bulanık çıkarım modellerinin yaygın olarak kullanılan uygulama şeması gösterilmiştir.



Şekil 2.2. Bulanık çıkarım sistemlerinin genel çalışma şeması (Kıyak ve Kahvecioğlu, 2003).

### Bulanıklaştırma aşaması

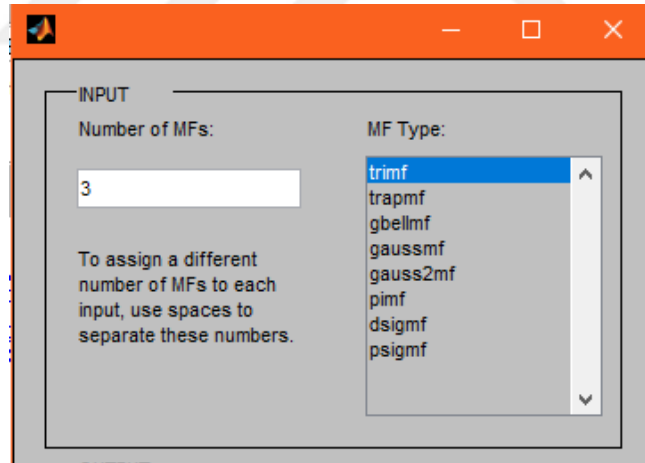
Genel anlamda, klasik küme olarak belirtilen aralıkların bulanıklaştırılması, sistem, mantık ve bulanık küme işlemleri için zorunludur. Bu sebepten dolayı, belirlenen değerlerde saptanabilecek elemanların tamamının, üyelik derecesi 1'e eşit olması gerektiği yerde, [0-1] arası farklı veri değerlerine sahip olması düşünülür. Dolayısıyla, bir takım değişkenlerin kararsızlık içerdikleri kabul edilir. Kararsızlıkların, sayısal olmayan hallerden meydana gelmesi durumunda bulanık mantıktan bahsedilir. Bulanıklaştırma aşamasında, bahse konu üyelik fonksiyonları, sorunların amacına ve yapısına yeterli olmalıdır. Genel olarak üyelik fonksiyonları matematiksel, geometrik, sezgisel veya istatistik bakış açılarına dayandırılabilir (Kıyak ve Kahvecioğlu, 2003).



Şekil 2.3. Üyelik fonksiyonunun kısımları (Görgülü, 2007).

Yukarıda belirtildiği üzere, sözel değişkenlere ait bulanık kümelerin ifade edilmesinde üyelik fonksiyonlarından faydalanılmaktadır. Bir üyelik fonksiyonu 5 kısımdan oluşur. Bunlar, üyelik fonksiyonunun çekirdeği, desteği, sınırları, dönüm noktası ve yüksekliğidir. Bir A bulanık kümesinin aidiyet derecesinin 1 olduğu durumdaki ( $\mu_A(x) = 1$ ) tüm değerlerin bulunduğu bölge çekirdek bölgesidir ve derecesi sıfırdır. Destek bölgesi olarak adlandırılan kısım 0' dan büyük tüm derecelerinin bulunduğu bölgeyi ( $\mu_A(x) > 0$ ) ifade eder. Bu bölgedeki her bir değer ilgili bulanık kümeye belirli bir derecede aittir. Son olarak sınır bölgesi ise bir bulanık kümeye olan aidiyet derecesi 0 ile 1 aralığında olan ( $1 > \mu_A(x) > 0$ ) tüm değerleri kapsayan kısımdır ve bu bölgede bulanıklıktan bahsedebiliriz. Bulanık kümelerde 0.5 üyelik derecesine sahip elemanların oluşturdukları bölge üyelik fonksiyonunun dönüm noktası olarak tanımlanır (Mutlu, 2014).

Bulanık kümeleri göstermek için standart fonksiyonlar kullanılabilir. MATLAB'de kullanılan üyelik fonksiyonları şunlardır: üçgen (trimf), yamuk (trapmf), çan eğrisi (gbellmf), Gaussian (gaussmf), Gaussian2 (gauss2mf), Sigmoidal (dsigmf ve pdsigmf) ve Pi şekilli (pimf). MATLAB'de kullanılan üyelik fonksiyonlarının MATLAB'deki görüntüsü **Şekil 2.4**'de gösterilmiş olup bu tez için Üçgen, Yamuk ve Gauss üyelik fonksiyonları incelenecektir.



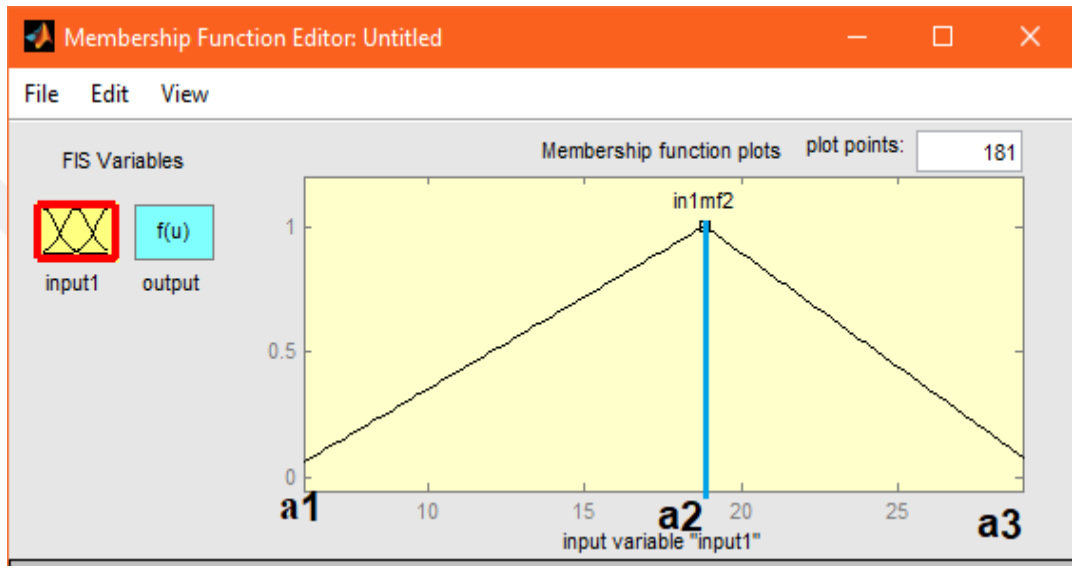
**Şekil 2.4.** MATLAB'de kullanılan üyelik fonksiyonları.

### *Üçgen üyelik fonksiyonu*

Genel kullanımda daha fazla karşımıza çıkan üçgen üyelik fonksiyonunun elemanları  $A = (a_1, a_2, a_3)$  şeklinde tanımlanan fonksiyonlardır. Burada, fonksiyonun çekirdeği konumunda bulunan  $a_2$  üyelik derecesinin 1 olduğu değeri, o kümenin tam olarak elemanı olduğunu,  $a_1$  ve  $a_3$  ise alt ve üst sınırı göstermektedir. Üyelik derecesi değerinin  $a_1$ 'den itibaren doğrusal arttığı, aynı şekilde  $a_3$  değerine kadar doğrusal azaldığı,  $a_3$  değerinden sonra üyelik derecesinin 0 olduğu

görülür (Lee vd., 2008). Bu şekilde tanımlanan üçgensel üyelik fonksiyonu **Denklem 3**'de verilmiştir. Üçgensel üyelik fonksiyonuna ait grafik, **Şekil 2.5** 'te verilmiştir.

$$\mu_{\tilde{A}}(x) = \mu_{\tilde{A}}(x; a_1, a_2, a_3) = \begin{cases} 0, & x < a_1 \text{ ve } x > a_3 \\ \frac{x-a_1}{a_2-a_1}, & a_1 \leq x \leq a_2 \\ \frac{a_3-x}{a_3-a_2}, & a_2 \leq x \leq a_3 \end{cases} \quad (3)$$




**Şekil 2.5.** Üçgen üyelik fonksiyonu.

### *Gaussian üyelik fonksiyonu*

Gaussian üyelik fonksiyonu, **Şekil 2.6**'da ve **Denklem 4**'de verilen  $m$  ve  $\sigma$  değişkenlerine bağlı olarak ifade edilmektedir. Burada önemli olan bulanık sayının dağılım şekli,  $m$  ise dağılımın orta noktasını gösterir.  $\sigma$  değeri küçüldükçe üyelik fonksiyonu dikleşirken, büyüdükçe üyelik fonksiyonu genişleyecektir (Kaya, 2007).

$$\mu_{\tilde{A}}(x, m, \sigma) = e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (4)$$

Bu şekilde tanımlanan gauss üyelik fonksiyonu ve parametreleri **Şekil 2.6**'da gösterilmiştir.




Şekil 2.6. Gauss üyelik fonksiyonu.

#### Yamuk üyelik fonksiyonu

Yamuk üyelik fonksiyonunun 4 adet parametresi vardır. Bunlar;  $a_1$ ,  $a_2$ ,  $a_3$  ve  $a_4$  ile tanımlanır. Bu fonksiyonda  $a_1$ - $a_2$ ,  $a_3$  -  $a_4$  arasında kalan değerler fonksiyonun sınırlarını oluşturmaktadır. Fonksiyonun çekirdeği ise  $a_2$ ,  $a_3$  parametreleri arasında kalan noktalardır. Yamuk üyelik fonksiyonunda değeri  $x$  olan bir elemanın üyelik derecesinin hesaplanması

$$\mu_{\tilde{A}}(x; a_1, a_2, a_3, a_4) = \begin{cases} a_1 \leq x \leq a_2 & \Rightarrow (x - a_1)/(a_2 - a_1) \\ a_2 \leq x \leq a_3 & \Rightarrow 1 \\ a_3 \leq x \leq a_4 & \Rightarrow (a_4 - x)/(a_4 - a_3) \\ x > a_4 \text{ ve } x < a_1 & \Rightarrow 0 \end{cases} \quad (5)$$


**Denklemler** 5'deki gibi tanımlanabilir. Şekil 2.7'de yamuk üyelik fonksiyonu ve parametrelerin gösterilmiştir (Uçuk S., 2009).



Şekil 2.7. Yamuk üyelik fonksiyonu.

#### Çıkarım (Karar verme) aşaması

Bulanık mantık modelinin en öncelikli arabirimidir. Çıkarım (Karar Verme) aşaması, var olan bilgileri kullanarak yeni bilgileri elde etme süreci olarak tanımlanır (Baykal ve Beyan, 2004). Dilsel bir söyleyiş olarak, input verilerinin durumu itibariyle uzman kişilerden beklenen denetleme işlemini, bilgi açısından ifadesinin bulanık kavram ve kurallardan faydalanılarak üretilmesidir. Çıkarım aşamasında girdi ve çıktı değişkenleri arasındaki ilişkiler konunun uzmanından alınan bilgiler doğrultusunda IF- THEN mantıksal ifadeleri kullanılarak açıklanır. Karar verme aşamasında mantıksal ifadelerin herbirinin son kısmında sonuç aşaması, elde edilen sonuç bilgilerinin biraraya getirilmesiyle sonuç kümesi elde edilir (birleştirme aşaması). Çıktı verileri ve üyelik fonksiyonu bilinen bulanık sayı/sayılar yada bulanık küme elde edilir. Çıkarım motorunun çalışma şeması aşağıdaki gibidir:





Kurallar bölümünde VE mantıksal bağlacı ile kurallar bağlanmışsa eşik değeri ( $w_i$ ) en küçük üyelik derecesine VEYA kullanılmışsa en büyük üyelik derecesine sahip olur (Uçuk S., 2009). Bu çalışma için çıkarım safhasında Mamdani, Takagi-Sugeno-Kang (TSK) çıkarım yöntemleri üzerinde durulmuştur. Bu çıkarım yöntemleri genellikle birbirlerine benzemektedir.

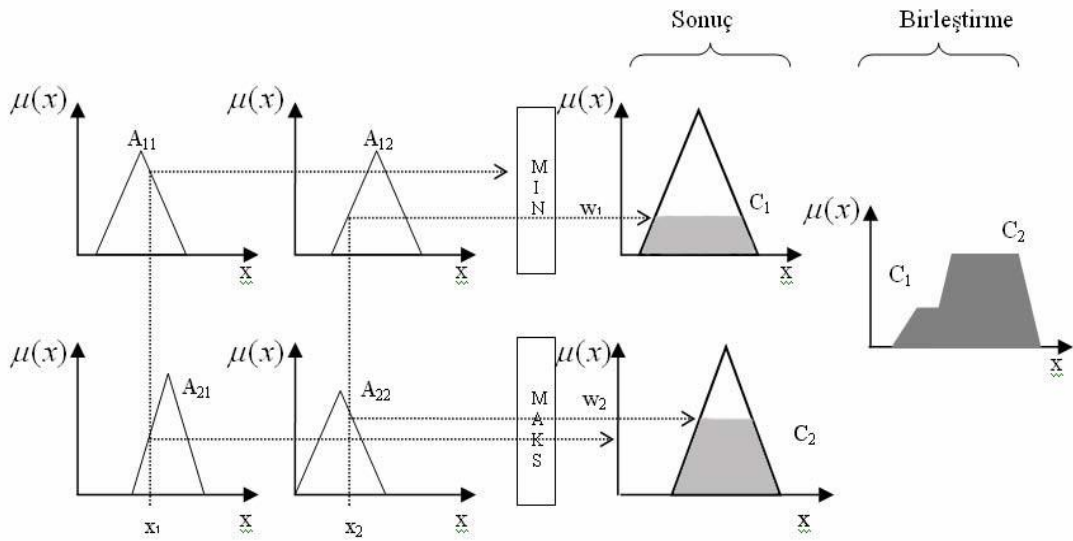
### *Mamdani yöntemi*

Bulanık çıkarım yöntemleri arasında Mamdani yöntemi, küme teorisi kullanılarak çalışılan ve ilk kontrol sisteminde kullanılan yöntem olmuştur. 1974 yılında, ilk kez Ebrahim MAMDANI tarafından kullanılmıştır. Yapılan ilk çalışmayla, bulanık uzman sistemlerin değerlendirilebileceğini kanıtlamış ve ilerleyen dönemlerde birçok çalışmaya örnek olmuştur (Tron ve Margaliot, 2004). Bu yöntemin kural yapısı;

Eğer ( $X_1=A_{11}$ ) ve ( $X_2=A_{12}$ ) ise ( $Z_1=C_1$ )

Eğer ( $X_1=A_{21}$ ) veya ( $X_2=A_{22}$ ) ise ( $Z_2=C_2$ )

şeklinde. Burada bulunan parametreler,  $x_1$  ve  $x_2$  girdi parametreleri,  $z$  ise çıktı parametreleridir.  $A_{11}$  ve  $A_{12}$  girdi verilerinin alt düzeylerini sembolize eden üyelik fonksiyonlarıdır.  $C_1$ ,  $C_2$  sembolleri her kural bölümünün son kısmında oluşan sonuç kümeleridir. Mamdani çıkarım metodunda sonuç bölümünde ve threshold değerinin oluşturduğu bölgenin alt bölgesindeki alanda  $C_1$ ,  $C_2$  bulanık meydana gelmektedir (Cerrada vd., 2005). Kurallar sonucu oluşan bulanık sonuç kümeleri birleşim aşamasında bulanık kümelerde birleşim kuralı sonucunda birleştirilerek birleşim kümesi oluşturulur. Mamdani yönteminde sonuç bir bulanık küme olduğu için, bu kümeler kesin kontrol değerini elde etmek amacı ile durulaştırma evresi uygulanır.



Şekil 2.8. Mamdani çıkarım yöntemi (Lee, 2006).

#### Takagi-Sugeno-Kang (TSK) yöntemi

TSK yöntemine kısaca Sugeno da denilmektedir. Bulanık çıkarım sürecinin ilk iki bölümü aynıdır. Bunlar; girişleri bulanıklaştırmak ve bulanık operatörü uygulamaktır. Mamdani ve Sugeno arasındaki temel fark, Sugeno çıkış üyelik fonksiyonlarının ya doğrusal ya da sabit olmasıdır. Bundan dolayı durulaştırmaya gerek duymamaktadır. Kullanım kolaylığı sağlaması ve bilhassa sayısal değişkenlerle çalıştığında çok olumlu sonuçların oluşmasından dolayı geniş bir kullanım sahası vardır (mathworks, 2018). TSK yöntemine ait kural yapısı

$$\text{Eğer } (X_1=A_{11}) \text{ ve } (X_2=A_{12}) \text{ ise } (Z_1= P_{10}+P_{11}X_1+P_{12}X_2)$$


$$\text{Eğer } (X_1=A_{21}) \text{ ve } (X_2=A_{22}) \text{ ise } (Z_2= P_{20}+P_{21}X_1+P_{22}X_2)$$

veya

$$\text{Eğer } (X_1=A_{11}) \text{ ve } (X_2=A_{12}) \text{ ise } (Z_1= C_1)$$

$$\text{Eğer } (X_1=A_{21}) \text{ ve } (X_2=A_{22}) \text{ ise } (Z_2= C_2)$$

şeklinde. TSK çıkarım yönteminin gösterimi Şekil 2.9'da verilmiştir.



**Şekil 2.9.** TSK çıkarım yönteminin gösterimi (Dualibe vd., 2003).

Burada bir veya birden çok girdi değişkeni tek bir çıktı değişkeni ( $z_i$ ) vardır. Çıktı değişkeni olan  $z_i$ ,  $x_1$  ve  $x_2$  girdi değişkenlerinin doğrusal bir fonksiyonu olabileceği gibi sabit ( $c_i$ ) bir sayıda olabilir. Çıktı değişkeni doğrusal bir fonksiyon olarak tanımlandığında,  $p_{i0}$ ,  $p_{i1}$  ve  $p_{i2}$  bu fonksiyonun parametreleridir. Burada  $N$  kural sayısıdır. Bu parametreler her kural için farklı değerlere sahiptir.

Parametre değerleri hesaplanırken başlangıçta girdi değişkenlerinin ilk değerleri için rasgele değerler atanır. Bu ilk parametre değerlerinin hiçbir önemi yoktur. İstenirse bu değerler olay hakkında hiçbir bilgisi ve tecrübesi olmayan bir kişi tarafından da rasgele belirlenebilir. Bu başlangıç  $p_i$  tahminleri kullanılarak girdi değişkenlerine ait ( $x_1$  ve  $x_2$ ) tüm değerler için çıktı değişkeninin ( $z_i$ ) değerleri tahmin edilir (Görgülü, 2007). Bu değerler ve her bir kural için tespit edilen eşik değerleri kullanılarak;

$$\text{Sonuç çıktısı} = \frac{\sum_{i=1}^N W_i Z_i}{\sum_{i=1}^N W_i} \quad (6)$$

yardımla bir sonuç değerine ulaşılır (mathworks, 2018).


Çıktı değişkenine ait elde edilen tahmin değerleri ile önceden bilinen gözlem değerleri arasındaki farklar hata olarak kabul edilir. Tahmin edilen değerler, gözlem değerlerine ne kadar yakın olursa, hata o kadar küçük olacak demektir. Hata değeri istenilen sınırlar içerisinde olmadığında  $p_{i0}$ ,  $p_{i1}$  ve  $p_{i2}$  parametreleri değiştirilerek sonuç değerleri yeniden hesaplanır. Nihai  $p_i$  değerleri bağıl hata değerinin %5 veya %10' un altında olmasını sağlayan değerdir.

### *Durulařtırma*


Durulařtırma, bulanık iřlemcinin son safhasını oluřturmaktadır. Mamdani ıkarım yntemi kullanılırsa, ıkarım ařamasında sonu deęerlerinin bulanık bir kme olarak elde edilen safhaya gerek duyulur. TSK ıkarım yntemi kullanıldıęında, durulařtırma ařamasına gerek yoktur. ünkü TSK, sonu deęerini kesin deęer olarak vermektedir. Durulařtırma, bulanık modelin ıkarımıyla oluřturulan bulanık kontrol iřleminin bulanıklařtırılmamıř kontrol iřlemine dnřtrlmesine denir. (Ően, 2004). Pratik uygulamalarda genellikle net sayılarla alıřmaya ihtiya olmaktadır. Byle durumlarda bulanıklařtırılmıř Őekilde oluřturulmuř yada eldeki verilerden faydalanarak ihtiya duyulan cevapların retilbilmesi iin birden fazla durulařtırma modeli vardır. En ok kullanılanları, en byk yelik ilkesi, sentroid yntemi, ortalama en byk yelik, aęırlıklı ortalama yntemi, en byklerin en kę ve en byklerin en byę yntemleridir (Baykal ve Beyan, 2004).

#### *En byklerin en byę ve en kę yntemi*

Bu ynteme gre durulařtırılmıř deęer, bulanık birleřim kmesinde btn elemanlar ierisinde en byk yelik derecelerinin bulunduęu kmenin elemanları iinde en kk deęerli (Őekil 2.10) ve en byk deęerli (Őekil 2.11) eleman olarak kabul edilir (Ően, 2004).



Őekil 2.10. En byklerin en kę yntemi (Elmas, 2007).



**Şekil 2.11.** En büyüklerin en büyüğü yöntemi (Baykan ve Beyan, 2004).


### *Ağırlık merkezi yöntemi*

Alan merkezi veya Sentroid yöntemi olarak da adlandırılmaktadır. Diğer yöntemlere oranla en fazla kullanılan yöntemdir. Sentroid yöntemi **Denklem 7** ile hesaplanır (Baykal ve Beyan, 2004; Elmas, 2007).

$y^*$ , durulaştırılmış değer:

$$y^* = \frac{\sum_{i=1}^n y_i \cdot \mu_B(y_i)}{\sum_{i=1}^n \mu_B y_i} \quad (7)$$

Sentroid yöntemi genel olarak gösterimi, **Şekil 2.12**'de gösterilmiştir.




**Şekil 2.12.** Ağırlık merkezi yöntemi (Elmas, 2007).

### Mean-Max üyelik yöntemi

Yöntemin diğer adı en büyüklerin ortası veya ortalama en büyük üyelik yöntemi olarak da bilinmektedir. En yüksek olabilirlik derecesine sahip çıktı değerlerinin ortasını gösterir. Bu yöntemin formülü **Denklem 8**'de verilmiştir (Elmas, 2007).

$$z^* = \frac{a+b}{2} \quad (8)$$

Bu yöntemin görünümü **Şekil 2.13.**'deki gibidir.



**Şekil 2.13.** Mean-Max üyelik yöntemi (Esra, 2006).


### Ağırlık ortalaması yöntemi

Ağırlık ortalaması yönteminde, bütün bulanık değerler ve üyelik dereceleri kullanılarak durulaştırma yapılmaktadır. Bu yöntem simetrik bir üyelik işleviyle ifade edildiği durumlarda kullanılır. **Denklem 9**'da verilen formül kullanılarak çıkış değeri hesaplanır. Ağırlık ortalaması yöntemi **Şekil 2.14**'da gösterilmiştir.

$y^*$ , durulaştırılmış değer:

$$y^* = \frac{a.\mu(a)+b.\mu(b)}{\mu(a)+\mu(b)} \quad (9)$$

formülüyle hesaplanır. a ve b sonuç değişkenini temsil eden üyelik işlevinin merkezini ifade eder (Elmas, 2007).



Şekil 2.14. Ağırlık ortalaması yöntemi (Elmas, 2007).

#### *Maksimum üyelik yöntemi*

Bu yöntemin diğer adı yükseklik yöntemi olarak bilinmektedir. En yüksek üyelik derecesine sahip olan küme olduğu anlamına gelir. Yöntem kullanılmak istenirse çıkarım biriminde oluşturulan bulanık kümenin modunun (tepe noktası) olması lazımdır. Bu yöntemin denklemi **Denklem 10** 'da verilmiştir:

$$\mu_B(y^*) \geq \mu_B(y_i) \quad \forall y \in B \quad (10)$$


B: Larsen ve Mamdani çıkarım yöntemlerinin bulanık birleşim kümesidir.

$y^*$ : küme içerisinde en büyük değere sahip eleman ve durulaştırılmış değerdir.

$y_i$ : bulanık birleşim kümesinin  $i$ 'inci elemanıdır.

$y^*$  Durulaştırılmış değer elde edilişi (Görgülü, 2007).

Yükseklik yöntemi Şekil 2.1.5'te gösterilmiştir.



Şekil 2.15. Maksimum üyelik yöntemi (Görgülü, 2007).

## 2.2. Yapay Sinir Ağları (YSA)

### 2.2.1. Yapay sinir ağları kavramı ve kapsamı

Zeka sözlük olarak, anlama ve kavrama yeteneği tanımından hareketle Yapay Sinir Ağları, tıpkı insan vücudundaki biyolojik sinir sisteminin fonksiyonlarını taklit ederek sistemlere öğrenme, tahminde bulunma, ilişkilendirme, hatırlama, optimizasyon ve karar verme gibi yetenekleri modelleyen bilgi işleme sistemi olarak tanımlanır.

YSA'nın esas amacı, insan davranış yapılarını ve düşünce kabiliyetlerini bilgisayar ortamında modellenmesidir. YSA'nın dayandığı ilk hesaplama modelinin temelleri 1940'larda Mc. Culloch ve Pitts nöronun, lojik fonksiyonlarını sağlayan basit bir eşik cihazı olarak modellenebileceğini gösterdi. Aynı zaman aralığında mühendislik temelleri geri besleme ve beyin fonksiyonlarından faydalanan Wiener, sibernetiğin temellerini atıyordu. 1949'da Donald Hebb hücresele seviyede beynin öğrenme seviyesi konusunda bazı çalışmalar yaptı. Hebb'in biyolojik öğrenme kuralına göre, bir nörondan dentrit yoluyla gelen bir aksonal giriş onun bir darbe üretmesine sebep olur. Sonraki aksonal girişlerin darbe üretmesi olasılığı artar. 1960'lı yıllarda Widrow ve Hoff, bu basit nöron modellerini kullanarak ilk öğrenebilen uyarlamalı sistemler üzerinde çalışmıştır. Fakat 1969'da Minsky ve Papert yayınladıkları Perceptron adlı bir kitapta YSA yardımı ile öğrenmede ve hesaplamsada aşılması zor engeller olduğunu iddia etmişler ve bu iddia YSA konusundaki çalışmalarını büyük ölçüde yavaşlatmıştır (Pankaj ve Wah, 1992).



1982’de J.J. Hopfield tarafından yayınlanan “Neural Networks and Physical Systems” çalışma, nöronların karşılıklı etkileşimlerine dayanan bir nöral hesaplama modeli ile çağdaş YSA devri başlamış oluyordu. Hopfield ağ seviyesinde, tek tek nöron seviyesinde var olmayan hesaplama kapasitesinin bulunduğunu öne sürdü ve bu, Hopfield Ağı olarak adlandırılmıştır. 1976’da Grossberg ART (Adaptive Resonance Theory) adında bir YSA yapısı geliştirdi. 1986’da Rumelhart ve arkadaşlarının “Parallel Distributed Processing” grubu ileri beslemeli modellerde yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (error back propagation algorithm) geliştirerek, Back-propagation algoritması, çok kullanılan, öğrenilmesi kolay bir ağıdır. Günümüzde YSA’nın teorik çalışmaları büyük ölçüde tamamlanmış olup 1986’dan bu yana uygulamaya yönelik çalışmalar son derece yoğun bir şekilde devam etmektedir (Öztemel, 2003). Artık günümüzde YSA rutin deneysel çalışmalardan çıkmış, kimyasal proseslerin kontrolünden elektronik kulaklara kadar birçok alanda uygulanmaya konmuştur.

Yapay Sinir Ağları’nın geniş kullanım alanı olduğundan tüm uygulama alanlarını sıralamak mümkün olmamakla birlikte, genel bir sınıflandırma ile yapay sinir ağlarının kullanım alanlarını aşağıdaki gibi gruplanabilir.

- Otomasyon ve Kontrol
- Arıza Analizi ve Tespiti
- Savunma Sanayi
- Üretim
- Haberleşme
- Tıp Alanında

### **2.2.2. Yapay sinir hücresi modeli**

YSA biyolojik sinir sisteminden etkilenerek geliştirilmiştir. İnsanda sinir sistemi, 3 bölümlü bir model olarak tanımlanan ve devamlı veriyi alıp yorumlayarak uygun bir sonuç oluşturan beyinin var olduğu sistem olarak tanımlanır. Bunları tanımlarsak; Reseptörler, etrafından etkileştiği inputları elektriksel sinyal dönüşümüyle beyne iletir. Merkezi Sinir Ağı, reseptörlerden girdileri alan beyin oluşturduğu elektriksel sinyalleri uygun tepkiler üretmesini sağlayan alıcı sinir ile tepki sinyalleri arasında etkileşimi sağlayan sinir ağıdır.



Şekil 2.16. Merkezi sinir ağı (Öztemel, 2003).

### *Sinir hücresinin temel yapısı*


Sinir hücresi (Nöron), birbiriyle bağlantılı synapse, dentrite, akson ve soma (hücre gövdesi) olmak üzere 4 önemli bölümü bulunmaktadır.

**Dentrit:** Sinir hücresine girdilerin sağlanması olan uzantılardır.

**Soma (Hücre Gövdesi):** Hücrenin yaşamasını sağlayan işlevleri görür. Somaya gelen girdilerin ağırlıklı toplamı axon üzerinde çıktı oluşturacak değere ulaştığında, bu değere "eşik değer" adı verilmektedir.

**Axon:** Hücre çıktısını göndermeye yarayan uzantısıdır.

**Synapse:** Görevi, aksondaki elektriksel iletinin elektro-kimyasal süreçlerle diğer hücelere aktarılmasıdır (Öztemel, 2003).



Şekil 2.17. Biyolojik sinir hücresinin bölümleri (Öztemel, 2003).

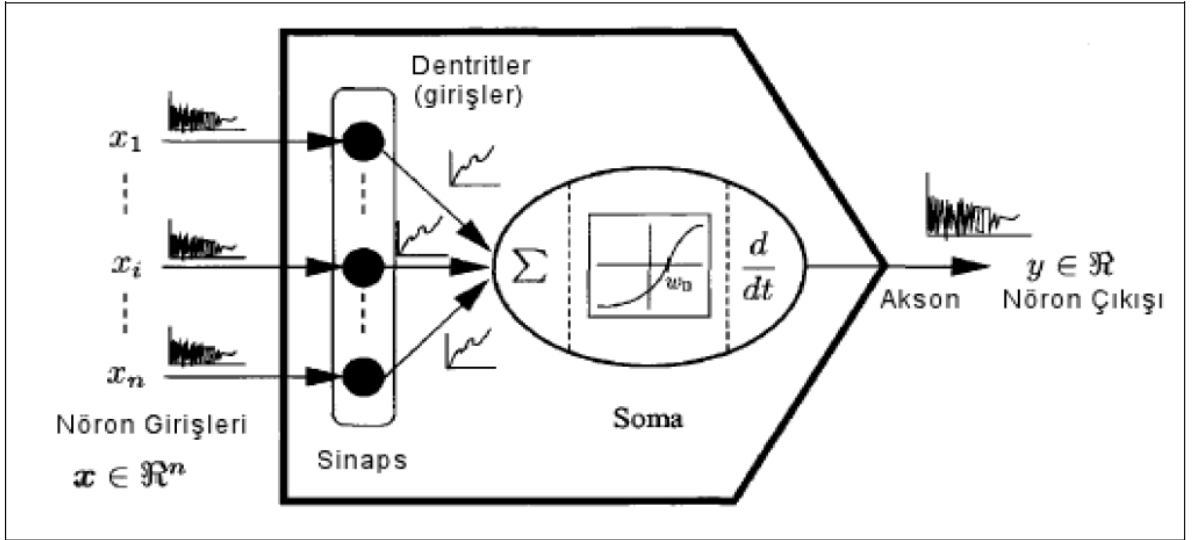
Biyolojik hücre, çevredeki hücelerden aktarılan sinyalleri, snapslarıyla dentritlere alır. Dentritlere ulaşan sinyaller ise snapslar aracılığıyla ya gücü azaltılır yada güçlendirerek sinyalleri gövdeye iletir. Gövdeye, iletilen sinyaller kendilerini yeterince kadar kuvvetlendirip eşik

değerinin üzerinde çıkabilirlerse, biyolojik hücredeki akson sinyal göndererek siniri aktif vaziyete geçirir. Yoksa, aksona sinyal verilemeyeceği gibi sinir pasif durumda kalır (Öztemel, 2003). Biyolojik sinir hücreleri; algılama, düşünme, hatırlatma ve öğrenim vb. bilinçsel davranışların tamamını kapsayan, insan davranışının her türlüünün temelinde yer almaktadır (Demir, 1997). Konuyu daha iyi anlamak için **Çizelge 2.2** 'de YSA alt elemanlarının biyolojik sinir sistemindeki karşılıkları gösterilmiştir (Gülez, 2004).

**Çizelge 2.2.** Yapay sinir ağı elemanlarının biyolojik sinir sistemindeki karşılıkları (Gülez, 2004).

YAPAY SİNİR AĞLARI	SİNİR SİSTEMİ
Girişler	Dendrit
Ağırlıklar	Sinaps
Çıkışlar	Akson
Yapay Nöron	Soma

Yapay sinir hücresi, biyolojik sinir sisteminde olduğu üzere YSA'da da ana unsurdur. YSA'lar, birbirine doğrusal veya doğrusal olmayan birçok işlemci biriminden oluşur. Biyolojik sinir sistemine olan benzerlikten dolayı ağ içerisinde bulunan her bir işlemci birimi yapay sinir hücresi olarak adlandırılır. Yapay sinir ağı bünyesinde bulunan nöronların tamamı bir yada birden çok veri girişi yapılabilir fakat sadece bir çıktı oluşturulur. Elde edilen çıktılar bir başka nörona girdi olarak verilebilmesinin yanında YSA dışına çıktı olarak da verilebilir. Yapay sinir hücreleri temel olarak beş bölümden meydana gelmektedir. Bunlar; Girdiler, Ağırlıklar, Birleşme fonksiyonu, Aktivasyon fonksiyonu ve Çıktı şeklinde sıralayabiliriz (Özveren, 2006).



Şekil 2.18. Yapay sinir hücre modelinin yapısı (Gupta vd., 2003).

### *Giriş verileri (Input)*

Giriş verileri, etrafındaki hücrelerden veya dış ortamlardan yapay sinir hücrelerine giren bilgilerdir. Bu giriş verileriyle YSA öğrenme işlemi oluşturulur (Öztemel, 2003).

### *Ağırlıklar*

Ağırlıklar, girişlerin yapay sinir hücreleri üzerinden hücreye girer ve ağırlıklar, ilgili girişin hücre üzerindeki etkisini belirleyen ve öğrenme işleminin gerçekleşmesini sağlayan katsayılardır. YSA içinde giriş verilerinin nöronlar arasında iletimini sağlayan bağlantıların tamamı değişik ağırlık değerleri almaktadır (Öztemel, 2003).

### *Toplama ve aktivasyon işlemleri*

Toplama ve Aktivasyon fonksiyonu, hücreye gelen bilgileri net olarak hesaplayan fonksiyon şeklinde tanımlanır. Hesap yapılırken, herhangi bir hücredeki net girdilerin kendi ağırlıklarıyla çarpımları ve bunların toplanmasıdır. Toplama ve aktivasyon fonksiyonu, ağırlık yapısı itibarıyla minimum alan, maksimum alan ya da normalleştirme algoritmaları gibi değişik fonksiyonlar olabilir. Ağırlıklı toplamı bulabilmek için yapay sinir hücresinin girişindeki her bir ağırlığın ait olduğu girişlerle çarpımının toplamları eşik değeri ile toplanır. Eşik değeri biyolojik sinir hücrelerinin yüzeylerindeki potansiyel farkının bir benzerini yapay sinir hücrelerinde elde etmek için kullanılan kat sayıdır (Haykin, 2005). Yapay sinir ağlarının genel mantığı,

nöronlarla ağırlıkların çarpımı ve bias değeri ile toplanmasıyla oluşan denklem fonksiyonu şeklinde yazılması sonucu ortaya çıkar. **(Denklem 11)**

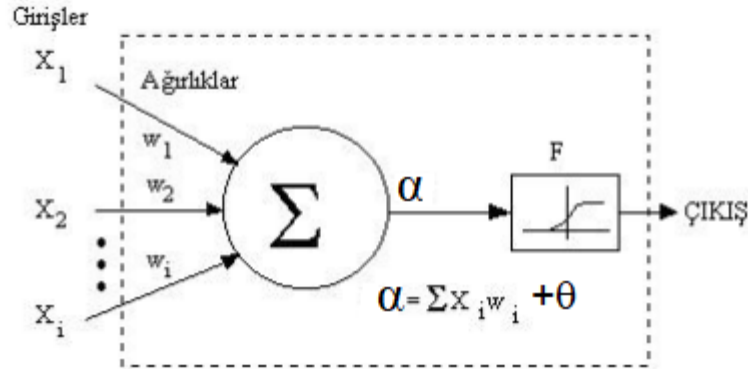
$$\alpha = \sum X_i W_i + \Theta \quad B = F(\alpha) \quad (11)$$

Burada;  $\alpha$ : Hücre net girişini,  $w$ : Hücrenin ağırlıklar matrisi,  $x$ : Hücre giriş vektörü ve  $B$ : Hücre çıkışını belirtmektedir. Burada  $X_i$ ,  $i$ 'inci girişi,  $W_{ij}$ ,  $i$ 'inci elemandan  $j$ 'inci elemana bağlantı ağırlığını ve  $\Theta$  eşik (threshold) değerini göstermektedir.

Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları şunlardır: Doğrusal aktivasyon fonksiyon, Sigmoid aktivasyon fonksiyonu, Tanjant hiperbolik aktivasyon fonksiyonu (Öztemel, 2003).

### Çıkışlar

Çıkışlar Toplama ve Aktivasyon işlemlerinden geçirildikten sonra elde edilen değer, çıkış değeridir. Çıkış  $B = F(\alpha)$ , aktivasyon fonksiyonu sonucunun dış dünyaya ya da diğer sinirlere gönderildiği yerdir. Bir sinirin sadece bir çıkışı vardır. Bir sinirin çıktısı başka bir sinirin girişi olabilir.



Şekil 2.19. Bir işlemci elemanı (yapay nöron) (Saridoğan, 2009).

### 2.2.3. Yapay sinir ağlarının avantaj ve dezavantajları

YSA uygulama itibarıyla uzunca bir dönem kullanılmasına rağmen aktif olarak tüm alanındaki kullanımı son 10-15 yıl içerisinde yaygınlaşmıştır. Yapay sinir ağları modeli oluşturulurken, biyolojik sinir sisteminin çalışma şekline benzetimiyle ortaya çıkarılmıştır. Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan yapay sinir ağları, biyolojik

sinir sisteminden avantajları ve dezavantajları vardır. Özellikle diğer istatistiksel analiz yöntemlerine göre daha esnek ve gerçeğe yakın sonuçlar ortaya koymasından dolayı tercih edilme oranı bundan sonra da artacaktır. Bununla beraber YSA yönteminin bazı avantaj ve dezavantajları bulunmaktadır (Elmas, 2003).

#### *Yapay sinir ağları uygulamalarının avantajları*

Yapay Sinir Ağlarının diğer modellere göre güçlü yönleri; doğrusal olmayan çok boyutlu yapıyı modelleme ve genelleştirebilme kabiliyeti, bilginin saklanması, adaptasyon ve elastikiyet, hata toleransına sahip olması, istatistiki veya başka modelleme tekniklerindeki ön şart ve kabullerin bulunmayışıdır (Zhang, 2003).

Yapay Sinir Ağları öğrenme kabiliyetiyle bilindik modelleri kullanarak daha önce karşılaşmadığı durumlar hakkında genelleme yeteneği kazanabilmektedir. Öğrenme aşamasında veriler kullanılarak ve girdi-çıkıtı değişkenleri arasında en az hatayı veren YSA modeli kurulabilmektedir. Adaptasyon ve elastikiyet özelliği sayesinde Yapay Sinir Ağları, yeni bilgilerin türetilmesi ve ortamda değişiklik olması durumunda birbiriyle ilişkili olan ağırlıkları değiştirerek ağı tekrar eğitebilirler. Aralarında birbirine sıkı sıkıya bağlanmış nöronlardan oluşan Yapay Sinir Ağlarının bilgi eksikliğiyle çalışabilmeleri hatalara karşı daha toleranslı olmalarını sağlamaktadır. YSA'ı kullanarak sorunları başarılı bir şekilde çözebilmek için sorunun iyi modellenmesine ihtiyaç vardır. YSA, modelleme için sadece örneklere ihtiyaç duymakta olup başka herhangi bir ön bilgiye ihtiyaç duymaz. YSA uygulamaları pratiktir ve daha ucuzdur (Öztemel, 2003).

#### *Yapay sinir ağları uygulamalarının dezavantajları*

YSA, herhangi bir girdi parametresinin çıkıtı parametresine nasıl dönüştürdüğü konusunda bilgi vermemektedir. Girdi-çıkıtı arasındaki bağlantının genel kural/kurallar ağ tarafından tanınmamaktadır ve ağın bunu açıklama yeteneği bulunmamaktadır (Chen vd., 2005). Bu sebeple, oluşturulan ağa karşı güveni azaltarak genel güveni sarsmaktadır. Problemleri doğru temsil edebilen örneklerin hiç yada az olduğu durumlarda, uygun çözümler üretmek mümkün olamamaktadır.

YSA parametrelerin belirlenmesinde belli kurallar seti bulunmamaktadır. Konuyu araştıran kişinin, yeteneğine dayalı olarak belirlenmektedir. Eğitimin ne zaman sonlanacağına dair herhangi bir metoda da rastlanmamaktadır. YSA donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. YSA'lar özellikle paralel işlem yapmalarından dolayı çok hızlı çalışan paralel işlemcilerle ihtiyaç duyarlar. Her problem için farklı bir yapay sinir ağı yapısı

geliştirilmelidir. Bu da deneme yanılma yoluyla olmaktadır. YSA birçok dezavantajlı yönleri olmasına karşın, çoğu problem için başarılı çözümler ve uygulamalar sunmaktadır. Başarılı sonuçlar elde etmek için çözülecek olan problemler ve YSA'lar konusunda genel anlamda bilgi sahibi olmak yeterli olacaktır. YSA yöntemi ile problemlere çözüm aranmasında bu gerçek göz ardı edilmeden bir ağ oluşturmanın mümkün olabileceği fakat bunun kolay bir süreç olmadığını da bilinmesi gerekmektedir (Öztemel, 2006).

### 2.3. ANFIS

Profesyonel fikir ve deneyimlerin ışığında bulanık kurallar oluşturulabilir. Bu oluşturulan bilgi kümesini elde etmek kolay olmayabilir ve bu bilgi kümesini kullanabilmek için standart bir metot yoktur. Jang 1990'lı yılların başlarında, bulanık kuralları oluşturmak ve otomatik bilgi elde edebilmek için yapay sinir ağları öğrenme algoritmaları ve bulanık sistemleri birleştirerek ANFIS'i ileri sürdü. Bu yöntem, yapay sinir ağlarının öğrenme yeteneğini ve bulanık mantığın çıkarım yeteneğinden aynı anda kullanan bir karma yapıdır.

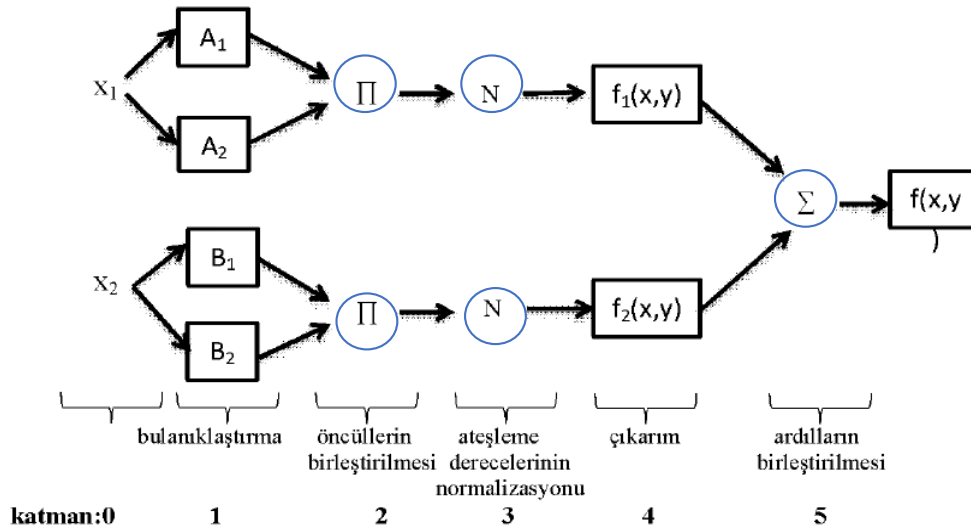
#### 2.3.1. ANFIS kavramı ve özellikleri

ANFIS tanım olarak, Adaptive Neuro Fuzzy Inference System kelimelerinin baş harflerinden meydana gelmiştir. 1990'lı yıllarda Jang'ın geliştirdiği, karmaşık zaman kayıtlarının modellenmesinde ve irrasyonel denklemlerin tahmininde kullanılmıştır. Bulanık mantık çıkarım sistemlerinde, matematiksel denklemlerden ziyade bulanık küme ve bulanık kural tabanlarını kullanırlar. Yapıları itibarıyla, belirsiz ya da bulanık ortamlarda insan muhakeme ve düşünce kabiliyetini yansıtırma yeteneği vardır. Bulanık “*if-then*” kuralları, “*If A=koşul then B=sonuç*” kural yapısıyla anlatılabilecek olup, bulanık sisteminin ana esaslarını oluşturur. Yöntemin çıkış noktası, insan düşünce ve bilgisini yansıtan bulanık “*if-then*”kurallarının avantajı ile sinirsel ağların öğrenme yeteneklerini bir araya getirerek karma etkili bir çözüm sunma gereksinimidir (Yücel vd., 2010).

Adaptif Sinirsel Bulanık Çıkarım Sistemi, bünyesinde birbirine bağlanmış birden çok düğümler barındıran, mevcut input-output bilgilerini meydana çıkmasını sağlayan ağ yapısıdır. Düğümlerin herbiri kendi içinde işlem ünitesi barındırır ve aralarındaki ilişkiler, birleştirilen düğümler arasındaki nedensel ilişkiyi belirler (Şit, 2013). Girdi ve çıktı verileri belli olan sistemlerin bulanık mantıkla modellenmesi için kural tabanı ve üyelik fonksiyonu verilerinin optimize edilmesini sağlar. Düğümlerin tamamı veya bir kısmı uyarlanabilir.

### 2.3.2. ANFIS modelinin mimarisi

ANFIS mimari yapısı, Takagi-Sugeno-Kang bulanık çıkarım sistemine dayalı bir tür yapay sinir ağı yapısıdır. Böyle karma yöntemlerde; tereddütlü ve kesin olmayan durumları bulanık çıkarım incelerken, YSA, uyarlanılabirliği incelemektedir. ANFIS bu çıkarım sistemini uygulamak için verilen giriş-çıkış veri seti ve uygun üyelik fonksiyonları ile bulanık kurallar üretir. ANFIS, YSA'nın öğrenme yeteneğini uygulamak için melez öğrenme algoritmasını kullanarak üyelik fonksiyonların aralıklarını değiştirir ve düzenler. Karma sistemler genellikle Sugeno bulanık modeli şeklinde anılmaktadır. TSK, girdi-çıkıı değişken kümelerinden bulanık kurallar oluşturulan modeli önermişlerdir (Jang, 1996; Aali vd., 2009). Anfis modelinin temel yapısı Şekil 2.20'de gösterilmiştir.



Şekil 2.20. ANFIS temel yapısı (Jang vd., 1997).

$$\text{Eğer } x=A \text{ ve } y=B \text{ ise } z = f(x, y) \quad (12)$$

Burada A ve B bulanık önerme kümelerini,  $z=f(x, y)$  ise çıkarımdaki ham fonksiyonunu göstermektedir. Genellikle  $f(x, y)$ , x ve y giriş değişkenlerini göstermek üzere bir polinom fonksiyonudur. Eğer  $f(x, y)$  birinci dereceden bir polinom ise bu model, birinci derece Sugeno bulanık model olarak tanımlanır. Eğer f sabit ise, sıfırıncı derece Sugeno bulanık model denir. Birinci derece Sugeno bulanık çıkarım sistemi için aşağıdaki gibi iki bulanık çıkarım "if-then" kuralları ile örneklenebilir. (Gülbandılar ve Gülbandılar, 2016).



### ANFIS yapısı;

$$\text{Kural-1: if } X=A_1 \text{ ve } Y=B_1 \text{ than } f_1= P_1X+ Q_1Y +R_1 \quad (13)$$

$$\text{Kural-2: if } X=A_2 \text{ ve } Y=B_2 \text{ than } f_2= P_2X+ Q_2Y+ R_2 \quad (14)$$

Bu çıkarım sisteminde A ve B, x ve y üyelik fonksiyonları için tanımlanmış giriş bölümündeki bulanık kümeler; P, Q ve R ise çıkış parametreleridir. Böylece her bir kural için bir çıktı değeri elde edilir (Sarı ve Arslan, 2007). Son çıkış, her bir kuralın çıkışının ağırlık ortalamasıdır ( $\bar{w}_i$ )

$$f = \frac{w_1f_1+w_2f_2}{w_1+w_2} \quad (15)$$

w: Yöntem tarafından belirlenen ağırlık.

Giriş ve çıkış değerleri verildiği durumlarda Adaptif Sinirsel Bulanık Çıkarım ağı tarafından yapay sinir ağları öğrenme teknikleri kullanılarak w ağırlık değerleri eğitilmekte sonuçları bilinmeyen veri setleri için sistem modellenmektedir. ANFIS 5 adet katmandan oluşmaktadır. Her katmanda bulanık mantık kural sayısı kadar nöron bulunur. Bu mimaride her katman farklı bir işlev icra eder **Şekil 2.20**'de 2 girişli ve 2 kurallı bulanık mantık sisteminin Sugeno yöntemiyle modellenmiş çıkarım yapısı verilmiştir (Gökçe ve Sonugür, 2016). Aşağıda aynı katmandaki düğüm fonksiyonunun davranışları ayrıntılı olarak ifade edilmektedir (Not:  $O_i^j$ , j-inci tabakadaki i-inci düğümün çıkışını göstermektedir).

**Katman 1 (Bulanıklaştırma katmanı):** Bu katmanda yer alan her i düğüm, düğüm fonksiyonuyla uyumlu davranış gösterir ve çıkışı aşağıdaki gibi uyarlamalı bir düğümdür.

$$\begin{aligned} O_i^1 &= A_i(x), & \text{icin } i &= 1,2, \text{veya} \\ O_i^1 &= B_{i-2}(y), & \text{icin } i &= 3,4 \end{aligned} \quad (16)$$

Burada x veya y i-inci düğümün girişini ve Ai veya Bi-2 ise uzun, kısa gibi dilsel ifadelerle söz konusu düğüme ait bulanık kümeyi ifade etmektedir. Diğer bir ifadeyle  $O_i^j$ , A veya B bulanık kümelerinin üyelik derecelerini göstermektedir ve

$$O_i^1 = \mu A_i(x) = \frac{1}{1+[(x-c_i)/a_i]^{2b_i}} \quad (17)$$

şeklinde gösterilmektedir. Burada  $\{a_i, b_i, c_i\}$  küme parametrelerini göstermektedir. Genelleştirilmiş çan eğrisi üyelik fonksiyonu için bu parametrelerin değerleri  $A_i$  dilsel etiketin

üyelik derecesini verir. Bu üyelik derecesi fonksiyonlarının değişik tipleri bulunmaktadır ve üyelik fonksiyonuna tipine göre **Denklem 14** değişiklik göstermektedir. Bu katmandaki parametreler öncül parametreler olarak tanımlanmaktadır. Bu katmanın çıkışı öncül kısmın üyelik derecesinin değeridir (Gülbandılar ve Gülbandılar, 2016).

**Katman 2 (Çıkarım kuralı katmanı):** İkinci katman, kural katmanıdır. Bu katmandaki giriş değerleri bir önceki katmandan elde edilen üyelik derecelerdir. Böylece her düğümdeki üyelik derecelerin çarpımı sonucu çıkış değeri hesaplanır ve bu çıkış ilgili kuralın ateşleme ağırlığını temsil eder.

$$O_i^2 = w_i = \mu A_i(x) \cdot \mu B_i(y) \quad i = 1, 2, \dots, n \quad (18)$$

Her bir düğümün çıkışı, her bir kural için gerçekleşme derecesini gösterir.

**Katman 3 (Normalizasyon katmanı):** Bu katmandaki i. düğüm, i. kuralın gerçekleştirme derecesinin, bütün kuralların gerçekleştirme dereceleri toplamına oranlanmasıyla hesaplanmaktadır.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2 + \dots + w_n} \quad i = 1, 2, \dots, n \quad (19)$$

**Katman 4 (Sonuç katmanı):** Bu katmandaki parametreler, sonuç parametreleri olarak isimlendirilir. Düğüm çıkışı, **Denklem 21**'de ifadesi ile verilen çıkış üyelik fonksiyonudur. Bu tabakadaki i-inci düğüm, düğüm fonksiyonu ve normalize çıkışın çarpılması ile hesaplanmaktadır.

$$O_i^4 = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i \cdot x + q_i y + r_i) \quad i = 1, 2, \dots, n \quad (20)$$

**Katman 5 (Çıkış katmanı):** Bu katmanda tek düğüm vardır. Bu düğüm gelen tüm işaretlerin toplamını hesaplayarak sistemin nihai çıkışını elde eder (Gülbandılar E. ve Gülbandılar A., 2016).

$$O_i^5 = \text{toplancikis} = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad i = 1, 2, \dots, n \quad (21)$$

### 3. MATERYAL VE METOD

Akıllı sistemler çok geniş bir kullanım alanına sahiptir. Bu tez çalışmasında uygun sıcaklık ortamında, toplamda 6 deneyden ve her deneyde 24 deney tüpü kullanılarak *Saccharomyces cerevisiae* maya hücrelerinin ekimi yapılmıştır. Bu veriler kullanılarak, *Saccharomyces cerevisiae* maya hücreleri akıllı sistemlerle modellenmeye çalışılmıştır. Modelleme safhasında 3 farklı model kullanılmıştır. Bu aşamalar sırasıyla Bulanık Mantık, Yapay sinir ağları ve ANFIS ile modelleme olarak gerçekleşmiştir. MATLAB'ın Neuro-Fuzzy Design editörüyle ANFIS (Sugeno metodu) modeli, Fuzzy Logic Design editörü (FIS) kullanılarak Bulanık mantık (Mamdani metodu) modeli kullanılmıştır. Her iki model içinde toplamda 8 adet üyelik fonksiyonu kullanılmıştır. Bunlar; Üçgen, Yamuk, Çan eğrisi, Gauss1, Gauss2, Pi, Psigma ve dsigma üyelik fonksiyonlarıdır. Neural Network Fitting Tools (nntool) editörü kullanılarak *Saccharomyces cerevisiae* maya hücrelerinin büyüme eğrisi Yapay Sinir Ağlarıyla (ANN) modellenmiştir.

#### ***Saccharomyces cerevisiae* Hücre Ekim ve Sayım İşlemleri**

Bu çalışmada, Tomurcuklanma, Ale ve Fırıncı mayası olarak da bilinen *Saccharomyces cerevisiae* maya hücrelerinin sayıca çoğaltılması için şu şartlar ve ortamlardan yararlanılmıştır; Sabouraud's dextrose (SD) agar (Oxoid CM41) ile Sabouraud's liquid medium (Oxoid CM147) besiyerlerinden yararlanılmıştır. Bu besiyerleri önce 121 C sıcaklıkta 15 dakika otoklavda sterilize edilmiş ve ortam pH değeri  $5.6 \pm 0.2$  olarak seçilmiştir. Başlangıçta katı besiyerine ekilen kuru maya hücreleri 30 C sıcaklıkta 24 saat süre ile inkübe edilerek burada üretilmiş, daha sonra bu hücreler pasajlama yapılarak sıvı Sabouraud's besiyerine aktarılmıştır. Elde edilen bu stok hücre kültüründen eşit sayıda  $(5.48 \pm 0.09) \times 10^5$  hücreler alınarak içinde sıvı besiyeri (6ml) bulunan tüplere steril koşullarda pasajlama yapılmıştır (Gülbandılar ve Gülbandılar, 2016).

Eşit sayıda hücre içeren tüpler ilk 6 saat uyum dönemi olarak dikkate alınmıştır. Zaman dikkate alınarak toplamda 24 tüp ekimi yapılmış olup 6. Saatten itibaren birer saatlik aralar ile 29. saate kadar zaman arttırılmıştır ve saatte bir tüp alınarak hücre sayımı yapılmıştır. Yapılan bu deney aynı şartlarda sekiz kez tekrarlanmıştır. Toplamda 192 adet tüp kullanılarak ekim yapılmıştır.

Hücre sayısı, Thoma lamı adı verilen mikroskopik sayım yöntemi kullanılarak saptanmıştır. Böyle bir sistemle bulunan hücre sayısı,

$$\text{"Millimetredeki hücre sayısı"} = \text{"AxSFx10000"} \quad (22)$$

**Denklem 22**'deki formül ile hesaplanmaktadır.

A= İlgilenilen sayım alanındaki maya hücresi sayısını

SF= Seyreltme faktörü,

10.000 ise 0.1 mm<sup>3</sup> deki sayım sonucunu 1 ml deki sayıya dönüştürmek ve standart sonucu elde etmek için kullanılan bir sabiti göstermektedir (Gulbandılar, 1996).

### 3.1. Bulanık Mantık Tasarımı

Bulanık mantık (Fuzzy Logic) modelin oluşturulması aşamasında MATLAB'in Fuzzy Logic Designer (fuzzy) kullanılmıştır. Fuzzy Logic Designer açıldıktan sonra 2 yöntem mevcuttur. Bunlar, anfis modelinin tasarımında kullanılan Sugeno, Bulanık mantık modelinin tasarımında kullanılan Mamdani yöntemidir. Bulanık mantık tasarımı süresince Mamdani yöntemini kullanılmıştır. Bulanık mantık modelinde bilgi girişi olarak 6-30 saat olarak zaman aralıkları belirlenmiştir. Bu modelin çıkış bilgisi ise hücre sayıları 0-33x10<sup>5</sup> aralığında dağılım sağlanmıştır. Modelin tasarımında ilk olarak gaussian üyelik fonksiyonu tercih edilmiştir. Üyelik fonksiyonlarının üyelik dereceleri belirlenirken deneme yanılma yöntemleri kullanılarak tahmini olarak en iyi kolerasyonu verecek olan değerler tespit edilmiştir. Tespit edilen zaman ve hücre sayılarının değer aralıklarını gözönünde bulundurularak tahmini en iyi sonucu vereceği düşünülen kurallar eklenmiştir.

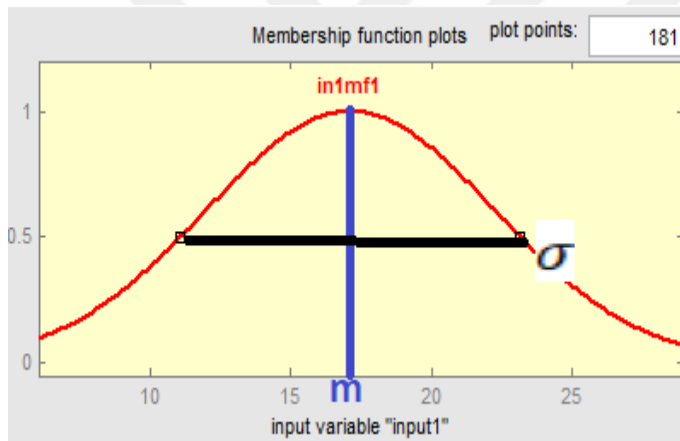
Bulanık model tasarlarken veriler otomatik olarak sisteme yüklenmesi için tasarlanmamıştır. Kullanıcı tarafından üyelik fonksiyonları ve üyelik fonksiyon sayıları tahmini olarak en iyi sonucu verecek şekilde tasarlanır. Bu model de giriş bilgisi olarak girilen zaman aralıklarına 20 adet üyelik fonksiyonu belirlenmiştir. Çıkış bilgisi olarak ise belirlenen hücre sayısı için 15 adet üyelik fonksiyonu tercih edilmiştir. Giriş ve çıkış için kullanılan üyelik fonksiyonları 20 adet zaman üyelik fonksiyonuna karşılık gelen en uygun hücre sayısı üyelik fonksiyonları kurullarla belirlenmiştir.

Tasarım sonucunda elde edilen verileri (6-29 saatleri arasında) kayıt altına alınarak 1 deneysel tekrar ile karşılaştırarak modelin hata oranları ortaya konmuştur. Gaussian modelinde elde edilen en iyi modelin değerleri sabit tutularak diğer üyelik fonksiyonlarındaki hata oranları da tespit edilmiş ve elde edilen sonuçlar arasında istatistiksel olarak anlamlı bir farklılığın olmadığı gözlemlenmiştir.

### 3.1.1. Bulanıklaştırma birimi

Bulanık mantık tasarlanması aşamasında, bulanıklaştırma işleminin temel amacı: giriş bilgisi olarak verilen sayısal bilgilerin sözel veya dilsel ifadelerle belirtilmesi işlemidir. Üyelik işlevinden yararlanarak verilen giriş bilgilerinin ilgili olduğu bulanık kümeleri ve üyelik derecelerinin tespit edip girilen sayısal değere; zaman için T1...T20 (Time), Hücre sayıları için H1...H15 (Hücre Sayısı) gibi dilsel değişkenler atar. Bulanıklaştırma işleminde yamuk, gaussian, üçgen, pi şekilli, çan eğrisi ve sigmoidal tipi üyelik tipleri seçilerek değerlendirme yapılmış ve sonuçlar incelendiğinde aralarında istatistiki anlamda bir fark olmadığı görülmüştür.

Elde edilen sonuçlar doğrultusunda, giriş verileri olan zaman bilgilerinin bulanıklaştırmasında gaussian üyelik fonksiyonu tercih edilmiştir (Şekil 3.1).




$$\mu_{\tilde{A}}(x, m, \sigma) = e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (23)$$

Şekil 3.1. Gaussian üyelik fonksiyonu ve üyelik derecesi hesaplama denklemi.

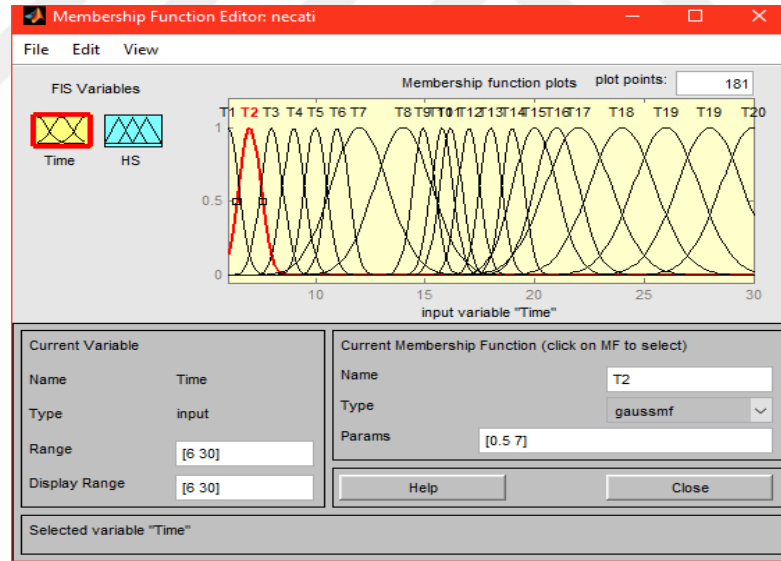
Bir örnekle anlatılmak istenirse T=12 için diğer zaman gruplarının alacağı değerler incelenmiştir. Örnekte verilen giriş bilgisinin ilgili olduğu bulanık kümeleri ve üyelik derecelerini tespit edilmiştir.

T 1	0
T 2	0
T 3	0
T 4	0
T 5	0,03
T 6	0,43
T 7	1
T 8	0,03
T 9	0
T 10	0
T ...	0
T 20	0



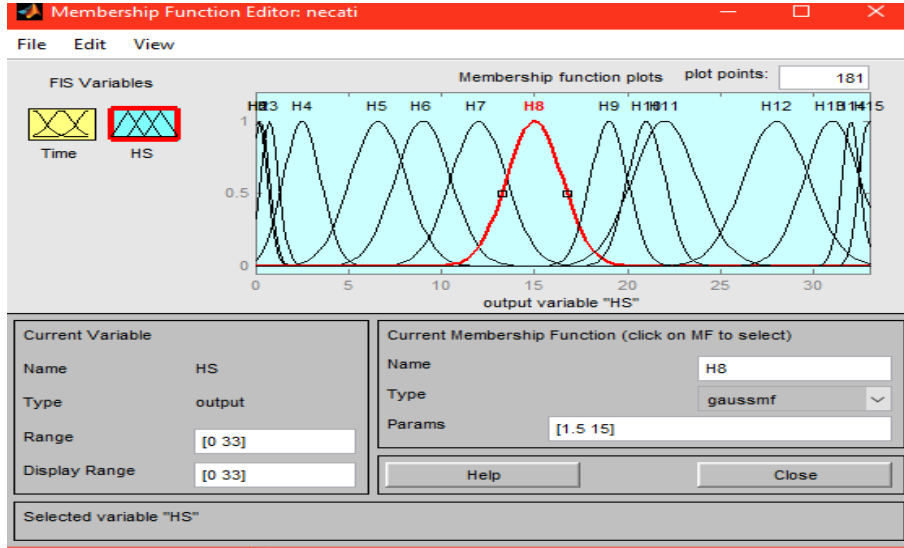
**Şekil 3.2.** On ikinci saat için verilen üyelik fonksiyonu ve üyelik dereceleri.

6 ile 30 saatler arasındaki zaman giriş verilerinin değerleri **Şekil 3.3** de görüldüğü gibi yirmi adet gaussian üyelik fonksiyonu oluşturulmuştur.



**Şekil 3.3.** Zaman giriş verilerinin üyelik fonksiyonları ve üyelik fonksiyonu dereceleri.

Aynı şekilde çıkış verileri olan hücre sayıları bilgilerinin bulanıklaştırmasında gaussian üyelik fonksiyonu tercih edilmiştir. 0 ile  $33 \times 10^6$  arasındaki hücre sayısı, çıkış verilerinin değerleri **Şekil 3.4** 'de görüldüğü gibi on beş adet gaussian üyelik oluşturulmuştur.

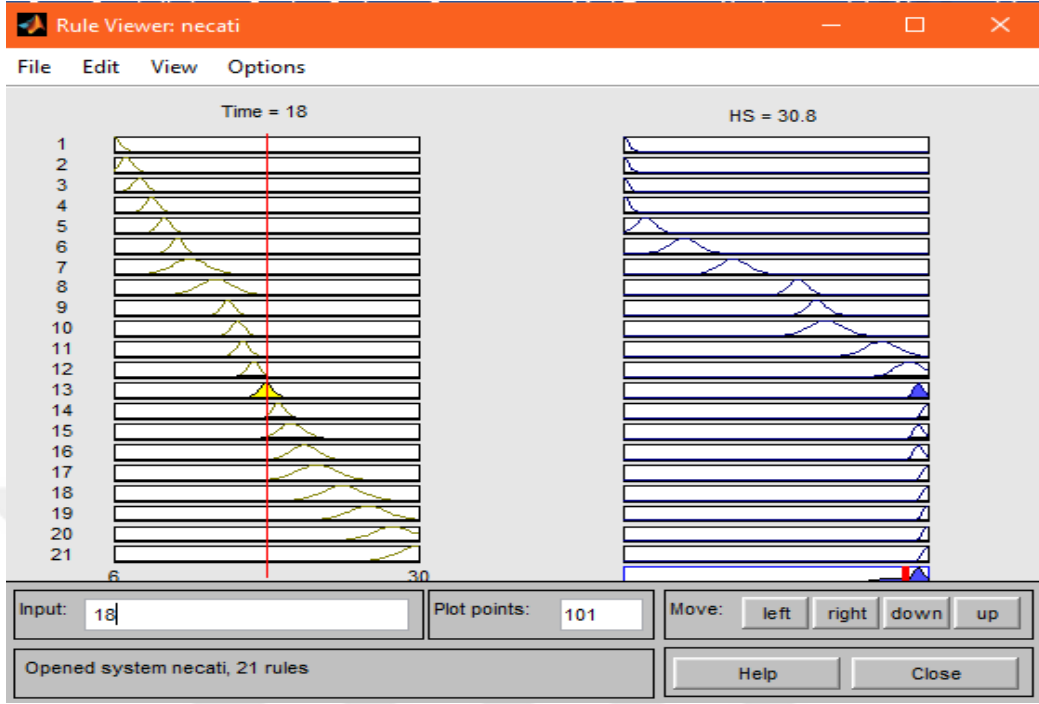


Şekil 3.4. Hücre sayısı çıkış verilerinin üyelik fonksiyonları ve üyelik fonksiyonu dereceleri.

### 3.1.2. Kural ve veri tabanı

Kural tabanı, T (zaman) dilsel verilerine karşılık gelecek olan balanıklaştırılmış H (hücre sayısı) çıkış verilerinden oluşan kurallar dizisidir. Kural ve veri tabanında toplam on iki adet çıkış bilgisi kullanılmıştır. Bunlar; H-1, H-2, H-4, H-5, H-7, H-9, H-10, H-11, H-12, H-13, H-14 ve H-15'dir.

Örnek verilecek olursa, 18'nci saat içerisinde çoğalma evresinde bulunan maya hücrelerinin ait olduğu üyelik küme bilgisi T12, T13, T14, T15' dir. Verilen giriş bilgisine karşılık gelen çıkış bilgisi H13, H14' dür. Hücre sayısında yüksek oranda artışın görüldüğü on dörd'üncü kural aktif olmaktadır (Şekil 3.5).



Şekil 3.5. Çıkış verilerine bir örnek.

Giriş bilgisi ve çıkış bilgileri arasındaki bağlantılar, kural ve veri tabanındaki kurallar kullanılarak sağlanmaktadır. A giriş bilgileri B ise çıkış bilgileri olan bir model için,

EĞER  $A=x$  ise  $B=y$ ,

biçiminde bir kural, A'nın aldığı değere göre B çıkışının bulanık değerlerini belirlenmektedir. Giriş ve çıkışlar arasında oluşturulan kural tablosu aşağıda verilmiştir.

*If (Time is T1) then (HS is H1),*

*If (Time is T2) then (HS is H1),*

*If (Time is T3) then (HS is H1),*

*If (Time is T4) then (HS is H2),*

*If (Time is T5) then (HS is H4),*

*If (Time is T6) then (HS is H5),*

*If (Time is T7) then (HS is H7),*

*If (Time is T8) then (HS is H9),*



*If (Time is T9) then (HS is H10),*

*If (Time is T10) then (HS is H11),*

*If (Time is T11) then (HS is H12),*

*If (Time is T12) then (HS is H13),*

*If (Time is T13) then (HS is H14),*

*If (Time is T14) then (HS is H15),*

*If (Time is T15) then (HS is H14),*

*If (Time is T16) then (HS is H14),*

*If (Time is T17) then (HS is H15),*

*If (Time is T18) then (HS is H15),*

*If (Time is T19) then (HS is H15),*

*If (Time is T20) then (HS is H15),*

### **3.1.3. Çıkarım birimi**

Çıkarım Biriminde, insan beyninin düşünce ve karar verme yeteneğinin bir kopyası olan bir yöntemle bulanık modeller işlenir ve çıkarım yapılır. Çıkış biriminin görevi, bulanık üniteye elde edilen giriş bilgilerine karşılık gelen çıkış verilerinin kural tabanına göre belirlenmesi işlemi bu birimde meydana gelir. Bulanık mantıkta, bulanık ilişkiyi tamamlamanın birden fazla yolu vardır. Bulanık mantık sistemi bünyesinde, hangi tipin kullanılacağı daha çok sezgisel olarak belirlenir.

EĞER İSE bağlaçlarında giriş bilgileri birbirine ve bağlacı ile bağlanmıştır. Klasik mantık önermeleri birbirine ve bağlacı ile bağlı ise minimum çıkarım gerektirmektedir. Farklı giriş bilgilerine karşılık elde edilen çıkış bilgileri de veya bağlacı ile bağlıdır. Klasik mantıkta veya bağlacı maksimum ilişkiyi gerektirir. Bu sebepten dolayı, bu çalışmada *min-maks* yöntemi kullanılmıştır (Gülbandılar, 2004).

### 3.1.4. Durulaştırma Birimi

Durulama işleminde, kural tabanının sonucu ile elde edilen bulanık değerlerin tekrardan kesin değerlere dönüştürüldüğü aşamadır. Durulama işleminde çıkarım biriminde *min-maks* yöntemi tercih edildiğinden dolayı *ağırlık ortalaması* yöntemi kullanılmıştır. Ağırlık ortalaması yöntemi;

$$y^* = \frac{\sum_{i=1}^n y_i \mu_B(y_i)}{\sum_{i=1}^n \mu_B} \quad (24)$$

Bağlantısına göre hesaplanır. Burada  $\sum$  cebirsel toplamayı ifade eder. Çıkarım biriminde elde edilen dilsel çıkışların, ağırlık ortalaması yöntemi kullanılarak, hücre sayıları sınıflandırılmış olur. Çalışmada, giriş bilgileri olan zamana karşılık hücre sayılarının sınıflandırılması gerçekleştirilmiştir.

Bulanık model ve diğer modeller için, eğitim ve test verilerinin deneysel sonuçlar ile karşılaştırılmasında; belirleme katsayısı ( $R^2$ ), ortalama mutlak yüzde hata (MAPE) ve karekök ortalama hata (RMS) kriterleri kullanılmıştır. Bu kriterler **Denklem (25), (26) ve (27)** yardımıyla hesaplanmıştır.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N |t_i - o_i|^2} \quad (25)$$

$$R^2 = 1 - \left( \frac{\sum_{i=1}^N (t_i - o_i)^2}{\sum_{i=1}^N (o_i)^2} \right) \quad (26)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \left( \frac{t_i - o_i}{o_i} \right) \right| * 100 \quad (27)$$

Burada  $t$  (target) hedef değeri,  $o$  (output) Bulanık mantığın çıkış değerini ve  $N$  toplam örneklem sayısını belirtmektedir (Özcan vd., 2009).

MATLAB'in Fuzzy Logic Designer da bulunan tüm üyelik fonksiyonları kullanılmış olup hata oranları tek tek kayıt altına alınmıştır. Kayıt altına alınan üyelik fonksiyonlarının  $R^2$ , **RMS** ve **MAPE** hata oranları hesaplanarak kıyaslama yapılmıştır (**Çizelge 3.1**).

**Çizelge 3.1.** Bulanık mantık modelinde test ve deneysel sonuçlar arasındaki hata oranları.

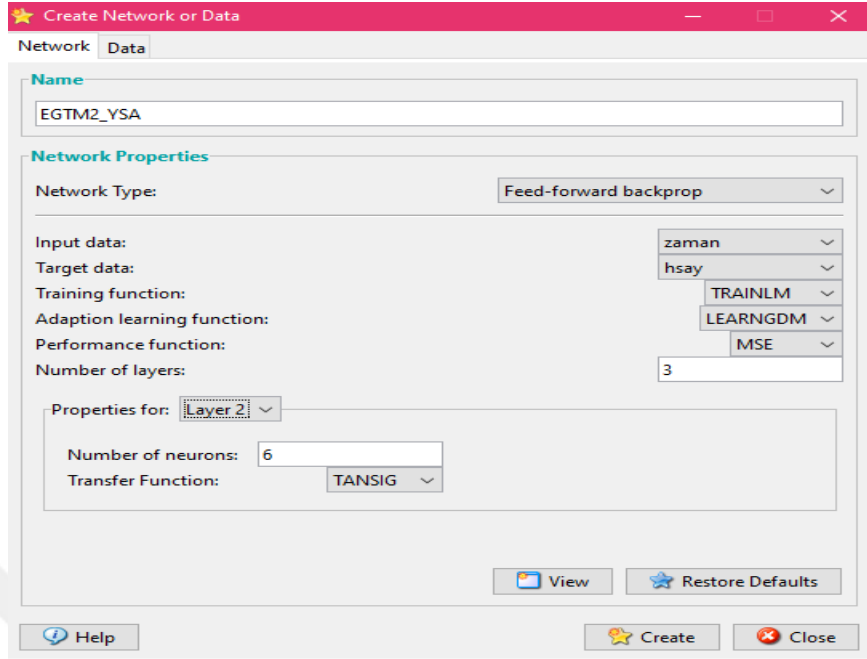
HATA	ÜÇGEN	YAMUK	ÇAN	GAUSS	GAUSS2	PI ŞEKİLLİ	DSİGMODİAL	PSİGMODİAL
<b>R<sup>2</sup></b>	0,995	0,995	0,996	0,995	0,995	0,994	0,996	0,996
<b>RMS</b>	0,94	1,07	0,96	0,86	1,01	1,19	0,87	0,87
<b>MAPE</b>	8,67	10,87	8,29	7,52	10,49	12,78	6,13	6,13

Ayrıca veriler arasındaki hata oranının da test grupları arasında çok düşük hatanın bulunduğu görülmektedir.

### 3.2. Yapay Sinir Ağlarının Tasarımı

Yapay sinir ağlarında (YSA) modelin oluşturulması aşamasında MATLAB'in Neural Network Fitting Tools (nntool) kullanılmıştır. YSA modelinin eğitim ve test için giriş değişkeni zaman, çıkış değişkeni olarak deneysel hücre sayıları kullanılmıştır.

Toplam 192 hücre sayımı verisinin, modelin eğitimi için 144 adet (6 deneysel tekrar, her deneyde 24 ölçüm) veri kullanılırken, 48 adet (2 deneysel tekrar, her deneyde 24 ölçüm) veri modelin doğruluğunun testi için ayrılmıştır. Bu nedenle Eğitim ve Test safhası olmak üzere YSA modeli 2 safhada incelenecektir. Eğitim ve Test safhasının her ikisinde de YSA modeli Network tipi feed-forward back propagation ve elman backprop tercih edilmiştir. 2-3-4 gizli katman denenmiştir, eğitim fonksiyonu (trainlm), adaptation learning fonksiyonu (learnlstm), transfer fonksiyonu (tansig) ve performans fonksiyonu (MSE-mean squared error) seçilerek oluşturulmuştur (**Şekil 3.6**).




Şekil 3.6. Yapay sinir ağlarında network oluşturma seçenekleri.

### 3.2.1. YSA eğitim safhası

Bu safhada 144 adet (6 deneysel tekrar, her deneyde 24 ölçüm) veri kullanılacaktır. Giriş parametresi zaman çıkış parametresi hücre sayısı olarak YSA eğitilmiştir. İki network tipinde eğitim yapılmıştır bunlar;

#### *Feed-forward backprop*

Network tipi seçimi yapıldıktan sonra 2-3-4 gizli katman ve her katmanda farklı nöron sayıları denenmiştir. İki katmandan oluşan network tipinde 1 giriş ve 2 gizli katman bulunmaktadır. Bunlar; giriş katmanı nöron sayısı 1 iken, gizli katman nöron sayısı 10 olarak belirlenmiştir (Şekil 3.7.). Kullanılan parametreler Çizelge 3.2'dedir.

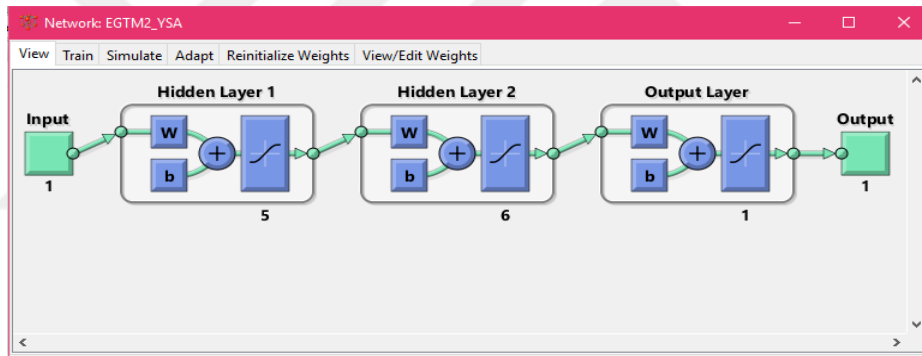


Şekil 3.7. Feed-forward backprop ağında kullanılan iki katmanlı YSA modelinin blok şeması.

**Çizelge 3.2.** Feed-forward backprop ağında iki katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Gizli tabaka sayısı	2
Birinci gizli tabakasındaki nöron sayısı	10
İkinci gizli tabakasındaki nöron sayısı	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	23

Üç Katmandan oluşan Network tipinde 3 gizli katman bulunmaktadır. Bunlar, giriş katmanı nöron sayısı 5 iken, birinci gizli katman nöron sayısı 6, ikinci gizli katman nöron sayısı 1 olarak belirlenmiştir (Şekil 3.8). Kullanılan parametreler Çizelge 3.3’dedir.




**Şekil 3.8.** Feed-forward backprop ağında kullanılan üç katmanlı YSA modelinin blok şeması.

**Çizelge 3.3.** Feed-forward backprop ağında üç katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Gizli tabaka sayısı	3
Birinci gizli tabakasındaki nöron sayısı	5
İkinci gizli tabakasındaki nöron	6
Üçüncü gizli tabakasındaki nöron sayısı	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	17

4 Katmandan oluşan Network tipinde 1 giriş ve 3 gizli katman bulunmaktadır. Bunlar, giriş katmanı nöron sayısı 10 iken, birinci gizli katman nöron sayısı 8, ikinci gizli katman nöron sayısı 4 ve üçüncü gizli katman nöron sayısı 1 olarak belirlenmiştir (**Şekil 3.9**). Kullanılan parametreler **Çizelge 3.4**'dadır.



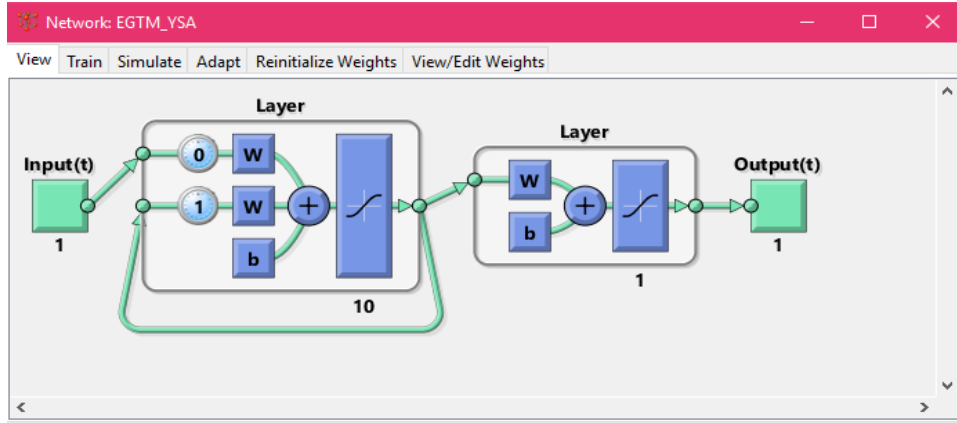
**Şekil 3.9.** Feed-forward ağında backprop kullanılan dört katmanlı YSA modelinin blok şeması.

**Çizelge 3.4.** Feed-forward backprop ağında dört katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Gizli tabaka sayısı	4
Birinci gizli tabakasındaki nöron sayısı	10
İkinci gizli tabakasındaki nöron	8
Üçüncü gizli tabakasındaki nöron sayısı	4
Dördüncü gizli tabakasındaki nöron	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	21

### *Elman backprop*

Diğer bir network tipi elman backprop seçimi yapıldıktan sonra 2-3-4'üncü katman ve her katmanda farklı nöron sayıları denenmiştir. İki katmandan oluşan network tipinde giriş ve çıkışlar haricinde iki katman bulunmaktadır. Bunlar; giriş katmanı nöron sayısı 1 iken, diğer katman nöron sayısı 10 olarak belirlenmiştir (**Şekil 3.10**). Kullanılan parametreler **Çizelge 3.5**'dedir.

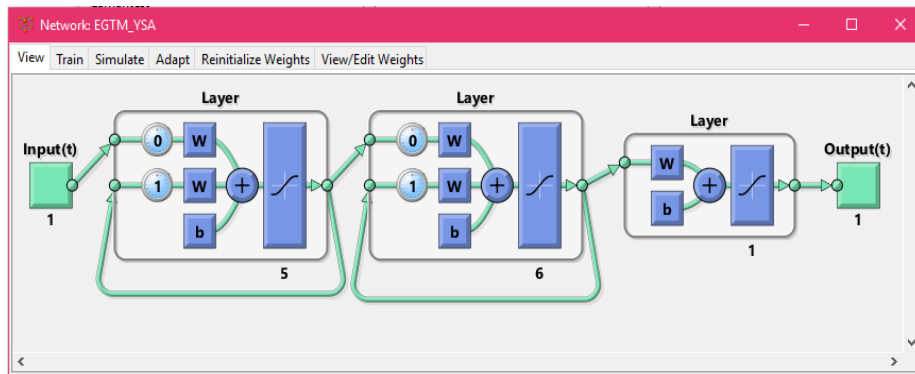


Şekil 3.10. Elman backprop ağında kullanılan iki katmanlı YSA modelinin blok şeması.

Çizelge 3.5. Elman backprop ağında iki katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Tabaka sayısı	2
Birinci tabakasındaki nöron sayısı	10
İkinci tabakasındaki nöron sayısı	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	31

Üç Katmandan oluşan Network tipinde 3 katman bulunmaktadır. Bunlar, giriş katmanı nöron sayısı 5 iken, birinci katman nöron sayısı 6, ikinci katman nöron sayısı 1 olarak belirlenmiştir (Şekil 3.11). Kullanılan parametreler Çizelge 8.'dedir.

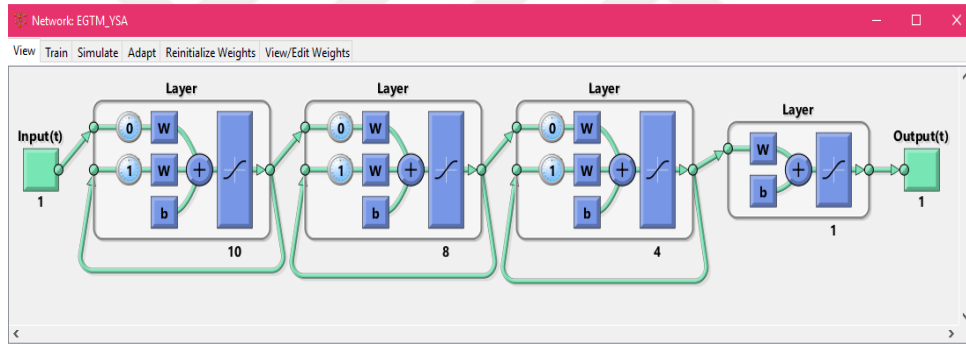


Şekil 3.11. Elman backprop ağında kullanılan üç katmanlı YSA modelinin blok şeması.

**Çizelge 3.6.** Elman backprop ağında üç katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Tabaka sayısı	3
Birinci tabakasındaki nöron sayısı	5
İkinci tabakasındaki nöron	6
Üçüncü tabakasındaki nöron sayısı	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	17

Dört Katmandan oluşan Network tipinde 4 katman bulunmaktadır. Bunlar, giriş katmanı nöron sayısı 10 iken, birinci katman nöron sayısı 8, ikinci katman nöron sayısı 4 ve üçüncü katman nöron sayısı 1 olarak belirlenmiştir (Şekil 3.12). Kullanılan parametreler Çizelge 9.'dadır.



**Şekil 3.12.** Elman backprop ağında kullanılan dört katmanlı YSA modelinin blok şeması.

**Çizelge 3.7.** Elman backprop ağında dört katmanlı modelde kullanılan parametre değerleri.

Parametreler	ANN model
Giriş tabakasındaki nöron sayısı	1
Gizli tabaka sayısı	2
Birinci gizli tabakasındaki nöron sayısı	10
İkinci gizli tabakasındaki nöron	8
Üçüncü gizli tabakasındaki nöron sayısı	4
Dördüncü gizli tabakasındaki nöron	2
Çıkış tabakasındaki nöron sayısı	1
Öğrenme sonucundaki hata	$1 \times 10^{-7}$
Öğrenme döngüsü	33



### 3.2.2. YSA test safhası

Bu safhada 48 adet (2 deneysel tekrar, her deneyde 24 ölçüm) veri kullanılacaktır. Giriş parametresi zaman, çıkış parametresi hücre sayısı olacaktır. İki network tipinde eğitim yapılmıştır. Bunlar; Feed-forward backprop ve Elman backprop ağlarıdır. Her iki network tipinde de 2-3-4 katmanlı ağ oluşturulmuştur. YSA test safhası, eğitim safhasında uygulanan işlemlerin bir kopyasıdır. Eğitim safhasında 144 adet deneysel veri kullanılırken, bu sistemi test eden safhada 48 adet deneysel veri kullanılarak modelleme yapılmıştır. Bu veriler, MATLAB'in Neural Network Fitting Tools (nntool) programında işlendikten sonra, elde edilen sonuçlar kayıt altına alınmıştır.


YSA modelinde deneysel sonuçların toplam 192 verinin 144 âdeti modelin eğitimi için kullanılmışken 48 adet veri modelin testi kullanılmıştır. Eğitim ve test çalışmaları sonucunda elde edilen sonuçlar ile deneysel sonuçlar arasındaki dağılım grafiği **Şekil 3.13**'de verilmiştir. Ayrıca bu şekiller üzerinde **Denklem 25, 26 ve 27**'den elde edilen istatistiksel sonuçlar görülmektedir.

YSA modelinin testi için kullanılan 48 adet verinin deneysel sonuçları ile modelden elde edilen sonuçların zamana karşı ortalama hücre sayıları **Şekil 3.13**'de verilmiştir. **Şekil 3.13**'de test verilerinin ortalama hücre sayısı ve ortalama deneysel sonuçlarının zamana göre değişimleri arasındaki benzerlik grafik üzerinde de görülmektedir.

Tasarlamış olduğumuz modelin iterasyonlar sonucunda hatanın en düşük olduğu durumlar da sabitlenen matematiksel YSA denkleminin katsayı değerleri **Çizelge 8**'de ortaya konulmuştur.

**Çizelge 3.8.** YSA matematiksel modelin katsayıları.

İlk gizli katman ağırlıkları	14,48	13,85	-15,04	13,31	12,97	-11,81	-9,09	12,18	13,84	14,32
Bias 1	-14,19	-11,61	5,14	-2,87	-1,06	-0,73	-3,10	7,11	10,81	13,87
İkinci gizli katman ağırlıkları	0,12	0,022	-0,06	0,024	0,05	-0,36	-0,26	0,25	0,75	0,93
Bias 2	-1.54									



Şekil 3.13. YSA modelinin eğitim ve test safhaları için sonuçların mukayyesesi.

**Çizelge 3.9.** YSA modelinin eğitimi ve testi neticesinde oluşan hata verileri.

Network Tipi	Feedforward backprop			Elman backprop		
Katman Sayısı	matlabann2 (1_10)	matlabann3 (5_6_1)	matlabann4 (10_8_4_1)	matlabann2 (1_10)	matlabann3 (5_6_1)	matlabann4 (10_8_4_1)
VERİ TİPİ	EĞİTİM VERİLERİ					
<b>R<sup>2</sup></b>	0,999	0,998	0,999	0,998	0,997	0,997
<b>RMS</b>	0,3726	0,4116	0,3814	0,5230	0,5945	0,6359
<b>MAPE</b>	1,9296	3,1339	2,1021	4,4703	8,3675	23,3807
VERİ TİPİ	TEST VERİLERİ					
<b>R<sup>2</sup></b>	0,999	0,999	0,999	0,999	0,998	0,998
<b>RMS</b>	0,1390	0,1769	0,1482	0,3783	0,4509	0,5479
<b>MAPE</b>	3,7411	4,8090	4,1908	7,5480	12,3948	30,2262

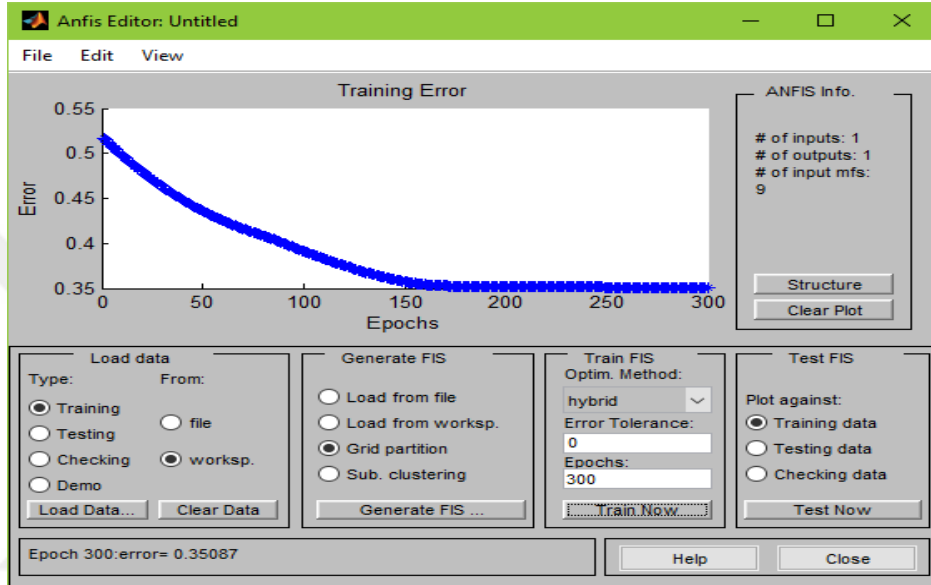
Eğitim ve test verileri istatistiksel karşılaştırma sonuçlarına bakıldığında **Çizelge 9'**daki veriler arasında yüksek bir ilişkinin olduğu görülmektedir ( $R^2_{\text{eğitim}}=0,998$  ve  $R^2_{\text{test}}=0,999$ ). Ayrıca veriler arasındaki hata oranının da hem eğitim hem de test grupları arasında çok düşük hatanın bulunduğu görülmektedir.

### 3.3. ANFIS Tasarımı

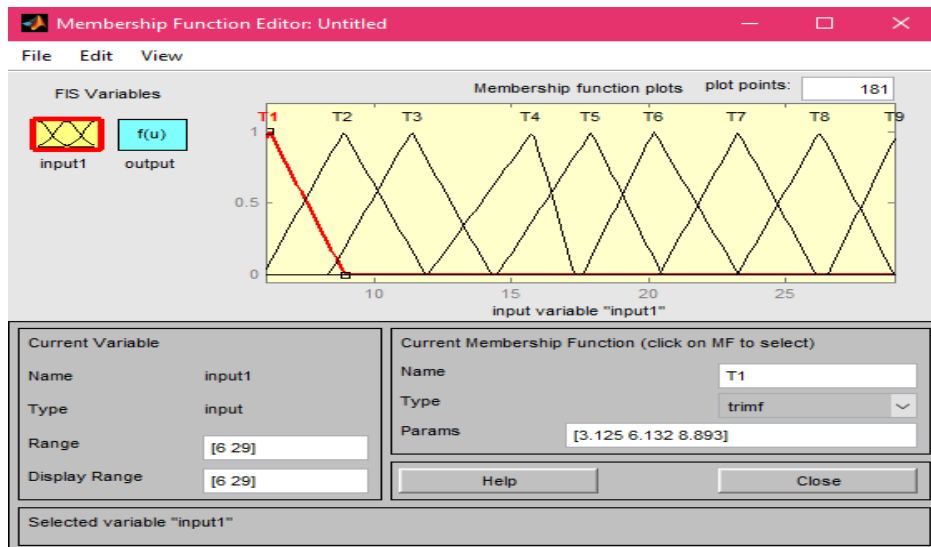
ANFIS'in modellenmesi aşamasında, MATLAB, Neuro-Fuzzy Design editörü tercih edilmiştir. Adaptif Sinirsel Bulanık Çıkarım Sistemi eğitim ve test için deneysel olarak elde edilen zaman göre hücre sayıları giriş değişkeni olarak, bu zaman dilimine karşılık gelen hücre sayılarını ise çıkış değişkeni olarak belirlenmiştir.

Toplam 192 hücre sayımı verisinin, modelin eğitimi için 168 adet (7 deneysel tekrar, her deneyde 24 ölçüm) veri kullanılırken, 24 adet (1 deneysel tekrar) veri modelin doğruluğunun testi için ayrılmıştır. Bu modelde farklı epochlarla farklı öğrenme algoritmaları denendikten sonra en iyi korelasyonun 300 epoch ve hibrit öğrenme algoritmasında olduğunu belirlenmiştir (**Şekil 3.14**). Modelimizde tüm giriş değişkenleri için MATLAB, Neuro-Fuzzy Design editöründe

bulunan 8 adet üyelik fonksiyonunun tamamı uygulanmıştır. Ayrıca giriş ve çıkış tabakalarındaki nöron sayısı 9 olarak belirlenmiştir (Şekil 3.15.) Giriş parametrelerinin uygulandığı Üçgen, Yamuk, Çan eğrisi, Gauss1, Gauss2, Pi, Psigma ve dsigma üyelik fonksiyonlarını sırayla incelenecektir. Model ve testlerde elde edilen sonuçlarda R2, RMS ve MAPE karşılaştırmalı olarak verilmiştir.



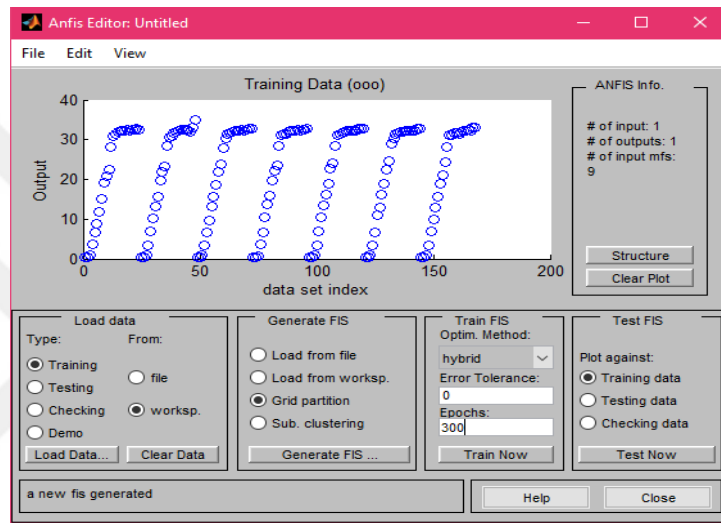
Şekil 3.14. ANFIS modelinin genel görüntüsü ve parametreleri.



Şekil 3.15. Giriş değişkeni olarak girilen zaman üyelik fonksiyonları.

### 3.3.1. Üçgen üyelik fonksiyonu

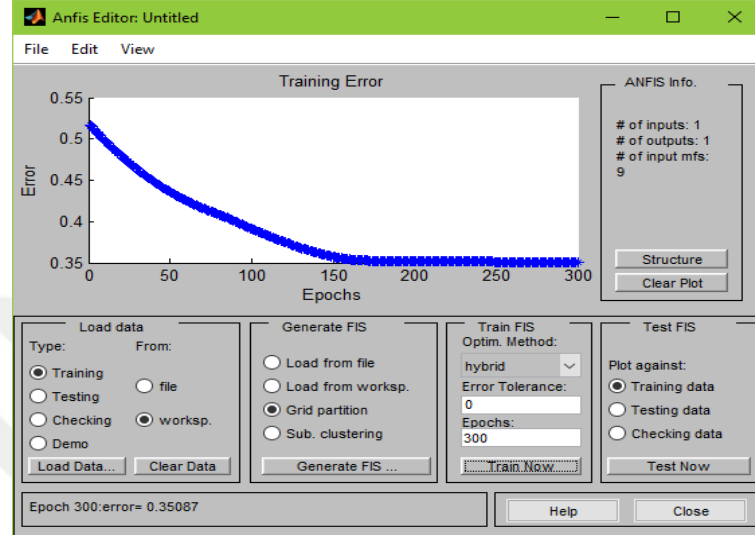
Üçgen üyelik fonksiyonu uygulama safhasında nöron sayısının 9 olarak belirlenmesi ile hata oranlarının daha da azaltmak amaçlanmıştır. Zamana göre hücre sayılarından oluşan 7 deneysel tekrar (girdi parametreleri) sistemin eğitimi için MATLAB, Neuro-Fuzzy Design editörüne yüklenmiştir (Şekil 3.16).



Şekil 3.16. Üçgen üyelik fonksiyonu girdi verilerinin yüklenmesi.

Şekil 3.17. Üyelik fonksiyon tipi ve nöron sayısının belirlenmesi.

Giriş verilerinin sisteme yüklenme işleminin devamında, Generate FIS bölümünde yer alan seçeneklerden Grid partition seçimi yapılarak üyelik tipi trimf, nöron sayısı 9 ve tipi constant olarak seçilmiştir (Şekil 3.17).



Şekil 3.18. Eğitim sonucu hata oranı.

Üyelik fonksiyonu seçimi işlemiyle beraber, en iyi korelasyon 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,35087 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği ve 300 epoch eğitim sonrası hata oranı Şekil 3.18’de gösterilmiştir.

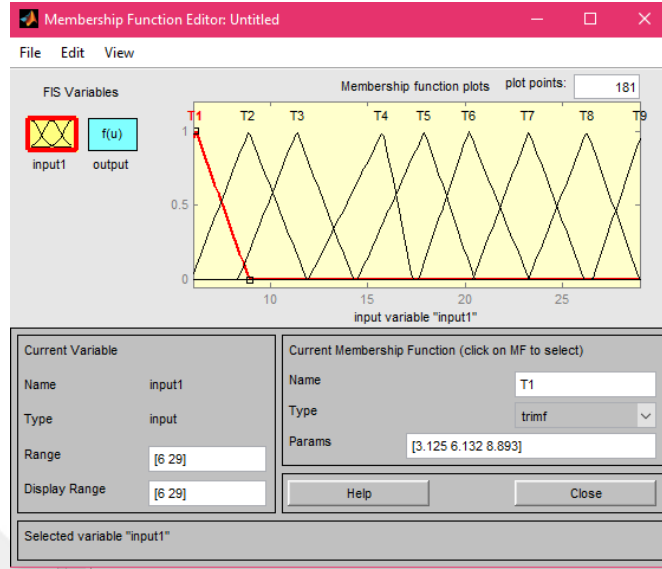
Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	27
Toplam parametre sayısı:	36
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

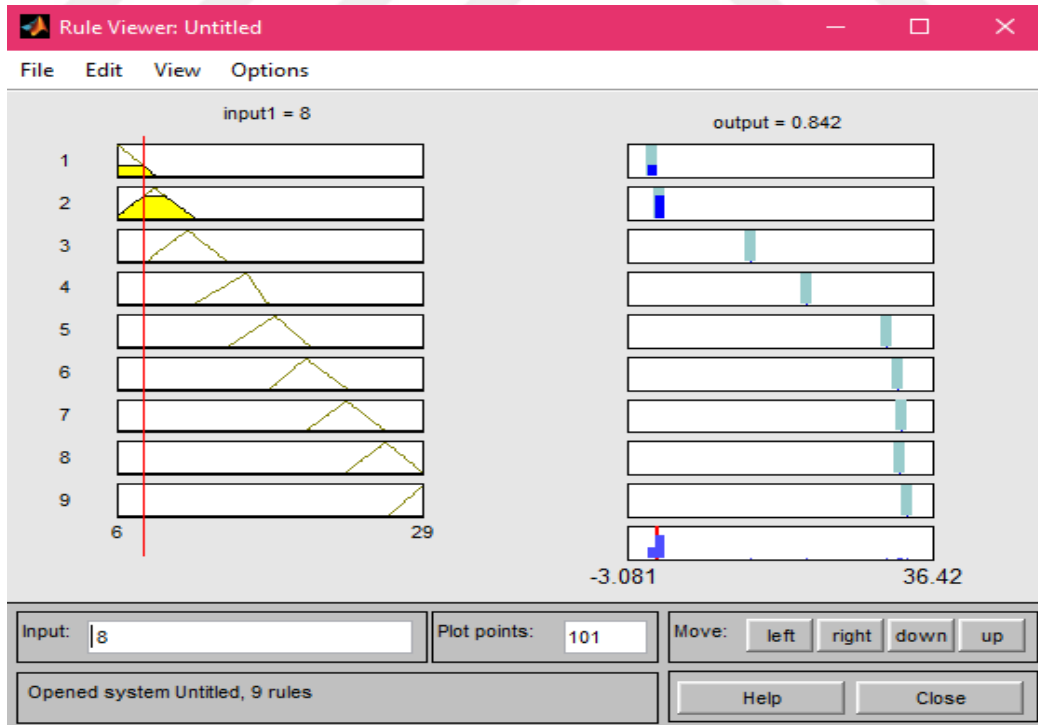
ANFIS hata oranları:

1	0.350875
2	0.350866



Şekil 3.19. Üçgen üyelik fonksiyonun zaman aralıkları.

Üçgen üyelik fonksiyonunda nöron sayısı 9 olarak belirtilen ve eğitim sonrası zaman aralıkları Şekil 3.19)' de gösterilmiştir.

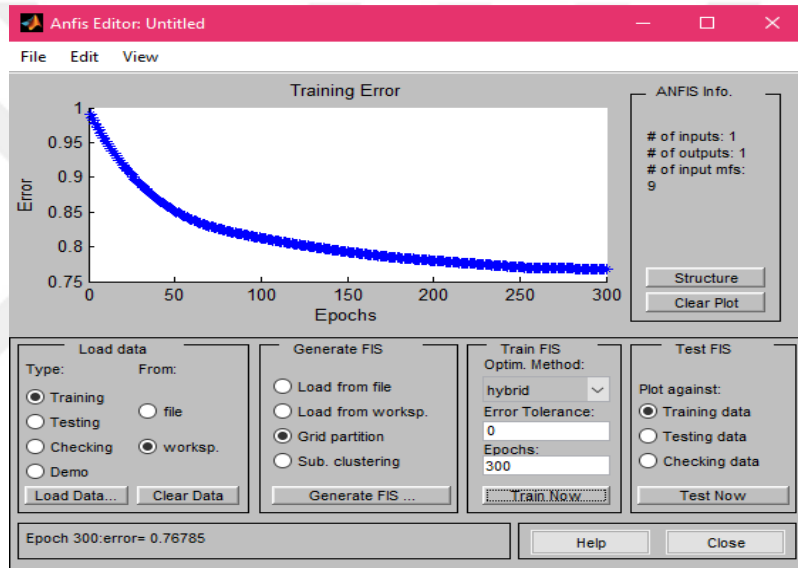


Şekil 3.20. Üçgen üyelik fonksiyonu giriş-çıkış verileri.

Tasarlanan ANFIS modelin eğitiminin sonucunda zaman değişkeninin 8 saat değeri giriş olarak uygulandığında elde edilen hücre sayısı  $0,842 \times 10^{+6}$  olarak bulunmuştur (Şekil 3.20). Tüm saat aralıklarındaki veriler (6-29 saatleri arası) tek tek bulunarak kayıt altına alınmıştır.

### 3.3.2. Yamuk üyelik fonksiyonu

Sistem girdi değerleri nöron sayısı ve tipi üçgen üyelik fonksiyonunda seçildiği gibidir. Girdi değerleri seçiminin ardından trapmf üyelik fonksiyonu seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,76785 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği Şekil 3.21’ de gösterildiği gibidir.



Şekil 3.21. Yamuk üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	36
Toplam parametre sayısı:	45
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9



ANFIS hata oranları:

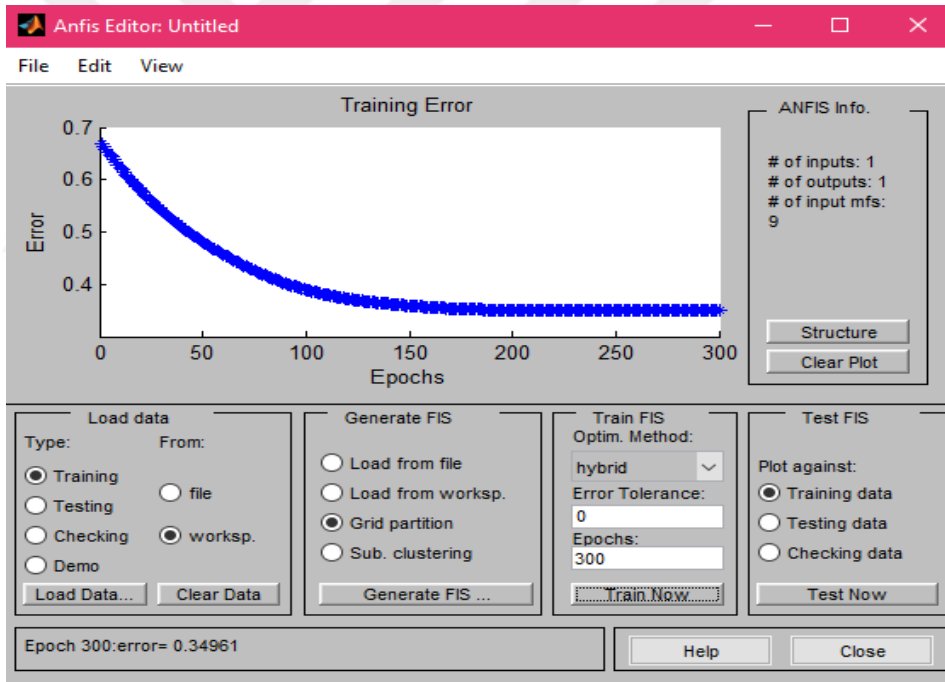
1 0.767846

2 0.767805

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

### 3.3.3.Çan eğrisi üyelik fonksiyonu

Sistem girdi değerleri, nöron sayısı ve tipi diğer üyelik fonksiyonlarında seçildiği gibidir. Girdi değerleri seçiminin ardından gbellmf üyelik fonksiyonu seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,34961 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği Şekil 3.22' de gösterildiği gibidir.



Şekil 3.22. gbellmf üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	27
Toplam parametre sayısı:	36

Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

ANFIS hata oranları:

1	0.349608
2	0.349604

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

### 3.3.4. Gauss1 üyelik fonksiyonu

Sistem girdi değerleri nöron sayısı ve tipi diğer üyelik fonksiyonlarında seçildiği gibidir. Girdi değerleri seçiminin ardından Gauss1mf üyelik fonksiyonu seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,3494 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği Şekil 3.23' de gösterildiği gibidir.



Şekil 3.23. Gaussmf üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9

Nonlinear parametrelerin sayısı:	18
Toplam parametre sayısı:	27
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

ANFIS hata oranları:

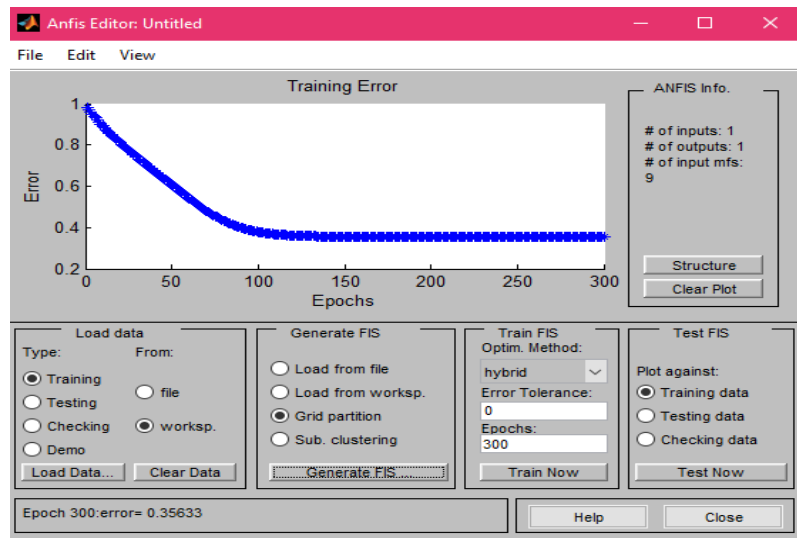
1 0.349401

2 0.3494

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

### 3.3.5. Gauss2 üyelik fonksiyonu

Sistem girdi değerleri nöron sayısı ve tipi diğer üyelik fonksiyonlarında seçildiği gibidir. Girdi değerleri seçiminin ardından Gauss2mf üyelik fonksiyonu seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,35633 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği **Şekil 3.24.**'de gösterildiği gibidir.



**Şekil 3.24.** Gauss2mf üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	36
Toplam parametre sayısı:	45
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

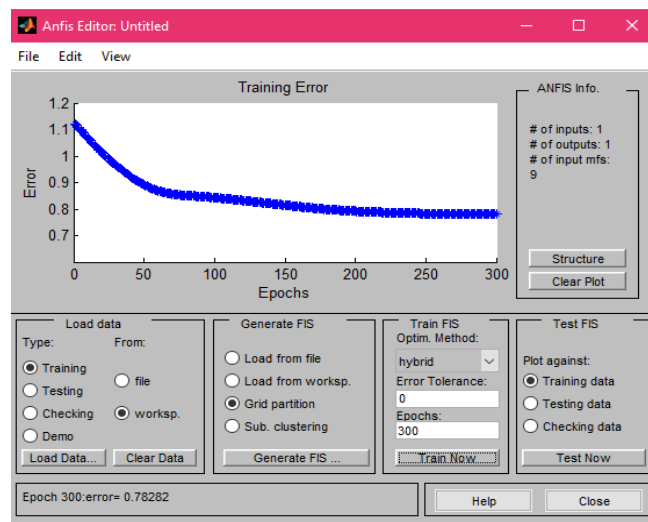
ANFIS hata oranları:

1	0.356329
2	0.356334

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

### 3.3.6. Pi şekilli üyelik fonksiyonu

Sistem girdi değerleri nöron sayısı ve tipi diğer üyelik fonksiyonlarında seçildiği gibidir. Girdi değerleri seçiminin ardından Pimf üyelik fonksiyonu seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,78282 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği Şekil 3.25.' de gösterildiği gibidir.



Şekil 3.25. Pimf üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	36
Toplam parametre sayısı:	45
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

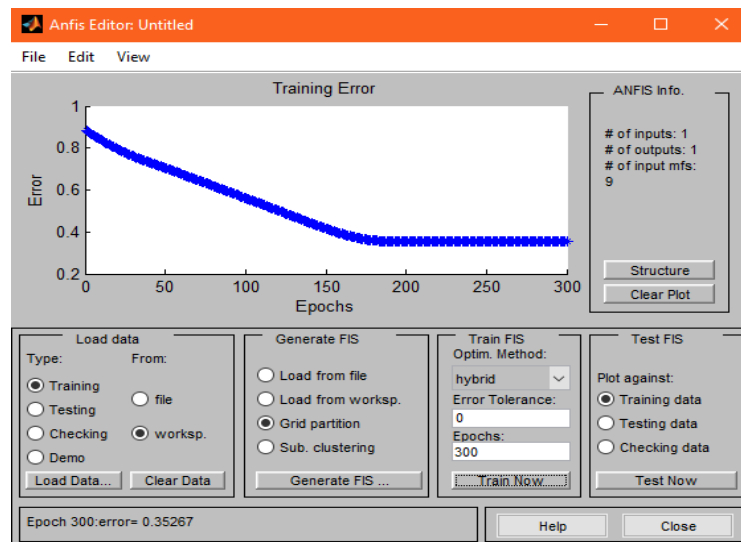
ANFIS hata oranları:

1	0.782818
2	0.782837

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

### 3.3.7. Sigmoidal (Psigma ve dsigma) üyelik fonksiyonu

Sistem girdi değerleri nöron sayısı ve tipi diğer üyelik fonksiyonlarında seçildiği gibidir. Girdi değerleri seçiminin ardından disigmf ve dsigmf üyelik fonksiyonları seçilir 300 epoch olarak eğittikten sonra hibrit öğrenme algoritmasında ortalama hata 0,35267 olarak gözlemlenmiştir. Hata oranı-epochs dağılım grafiği Şekil 3.26' de gösterildiği gibidir.



Şekil 3.26. Sigmoidal üyelik fonksiyonu eğitim sonrası hata oranı.

Eğitim süreci boyunca, ANFIS aşağıdaki bilgileri görüntüler:

ANFIS bilgisi:

Düğüm sayısı:	40
Linear parametrelerin sayısı:	9
Nonlinear parametrelerin sayısı:	36
Toplam parametre sayısı:	45
Eğitim veri çiftlerinin sayısı:	168
Test veri çiftlerinin sayısı:	0
Kural sayısı:	9

ANFIS hata oranları:

1	0.352672
2	0.35266

Hata oranları 6'ncı saat ile 29'uncu saat aralığında tek tek elde edilmiş ve kayıt altına alınmıştır.

ANFIS modelinde deneysel sonuçlarının 192 toplam verinin 168 âdeti modelin eğitimi için kullanılmışken 24 adet veri modelin testi kullanılmıştır. Eğitim ve test çalışmaları sonucunda elde edilen sonuçlar **Çizelge 3.10.** üzerinde **Denklem 25, 26 ve 27'**den elde edilen istatistiksel sonuçlar görülmektedir. Test verileri istatistiksel karşılaştırma sonuçlarına bakıldığında dağılım verileri arasında yüksek bir ilişkinin olduğu görülmektedir. Ayrıca veriler arasındaki hata oranının da çok düşük hatanın bulunduğu görülmektedir.

**Çizelge 3.10.** Anfis modelinde eğitim ve deneysel sonuçlar arasındaki hata oranları.

HATA	ÜÇGEN	YAMUK	ÇAN	GAUSS	GAUSS2	PI ŞEKİLLİ	DSIGMODIAL	PSIGMODIAL
R <sup>2</sup>	0,999	0,997	0,999	0,999	0,999	0,996	0,999	0,999
RMS	0,32	0,76	0,32	0,32	0,32	0,67	0,31	0,31
MAPE	2,36	6,64	2,49	1,80	2,58	10,21	2,62	2,62

## 4. SONUÇLAR

Bu tez çalışmasında, *Saccharomyces cerevisiae* üreme eğrisinin belirlenmesinde üç farklı akıllı sistem birlikte incelenmiştir. Akıllı sistemlerin tamamı deneysel model olarak elde edilen veriler yardımıyla eğitilmiştir. Bu modellerin tamamında farklı üyelik fonksiyonları ve ağ tipi denenerek elde edilen sonuçlar kayıt altına alınmıştır. Çalışma sonucunda ortaya koyulan modellerin sonuçları *Saccharomyces cerevisiae* üreme eğrisinin belirlenmesinde başarılı bir şekilde kullanılabileceğini göstermiştir. Kullanılan akıllı sistemler önceden ortaya konulan matematiksel modeller kadar tahminde başarılı bir şekilde kullanılabilir olduğu ortaya konulmuştur. Yapılmış olan bu çalışmayla akıllı sistemlerin matematiksel modellerden daha hızlı bir şekilde de kullanımı söz konusu olduğu gösterilmiştir.

Akıllı sistemler ile modellenmiş olan çalışmaların kayıt altına alınan verileri karşılaştırılmıştır. Elde edilen sonuçların, üç farklı akıllı sistemdeki karşılaştırma sonuç oranının tahminleri **Çizelge 4.1**'de gösterilmiştir.

**Çizelge 4.1.** Akıllı sistemlerin karşılaştırma sonuç oranları.

	R <sup>2</sup>	RMS	MAPE
BULANIK MANTIK	0,996	0,87	6,13
YSA	0,999	0,37	1,93
ANFIS	0,999	0,32	1,80

Bu karşılaştırma sonuçlarının oranları kontrol edildiğinde, karşılaştırma sonuç oranının %1'in çok altında olduğu ve karşılaştırma sonuç oranının gözardı edilebilecek seviye de olduğu yapılan çalışma sonucunda tespit edilmiştir. Bu sonuçtan hareketle akıllı sistemlerin hepsi çok düşük oranlarda hata payıyla doğru sonuçlar üretmektedir.

Gerçekleştirmiş olduğumuz deneysel modellerde, üzerinde çalıştığımız akıllı sistem modellerinin sınırlamalarını ortaya koymaktadır. *Saccharomyces cerevisiae* maya hücrelerinin tek bir üreme sıcaklığında, tek pH değerinde ve belirli bir başlangıç hücre sayısındaki durumlarda deneysel çalışmalar yapılmıştır. Gelecekte yapılacak projelerde yukarıdaki sınırlamalar daha da genişletilerek model oluşturmada kullanılan veri havuzumuz zenginleştirilerek modelin çalışma yelpazesi genişletilebilir.

## KAYNAKLAR DİZİNİ

- Aali, K.A., Parsinejad, M., Rahmani, B. (2009). Estimation of saturation percentage of soil using multiple regression, ANN, and Anfis techniques Comput. Inform, 127–136.
- Baykal, N. ve Beyan, T. (2004). Bulanık mantık ilke ve temelleri. Bıçaklar Kitapevi, Ankara. 413.
- Caudill, M. (1987). Neural network primer, Bölüm 1. AI Expert, 47.
- Cerrada, M., Aguilar, J., Colina, E. ve Titli, A. (2005). Dynamical membership functions: an approach for adaptive fuzzy modelling. Fuzzy Sets and Systems, 513–533.
- Chen, C. T., Lin, C. T. ve Huang, S. F. (2005). A fuzzy approach for supplier evaluation and selection in supply chain management, International Journal of Production Economies, 1-13.
- Demir, Y. K. (1997). Yapay sinir ağları ile ulaştırma taleplerinin modellenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Elmas, Ç., (2003), Yapay sinir ağları, Seçkin Yayıncılık, Ankara.
- Elmas, P. D. Ç. (2007). Yapay zekâ uygulamaları. Seçkin Yayıncılık, Ankara.
- Ertunç, H. M. (2012). Introduction To Fuzzy Logic. Kocaeli Üniversitesi Mekatronik Mühendisliği.
- Esra, A. (2006). Kalite kontrolde bulanık mantık yaklaşımı ve bir uygulama, Yüksek Lisans Tezi, Pamukkale Üniversitesi, 79-80.
- Gökçe, B. ve Sonugür, G. (2016). Anfis ve YSA yöntemleri ile işlenmiş doğal taş üretim sürecinde verimlilik analizi. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 179-181.
- Görgülü, Ö. (2007). Bulanık mantık (Fuzzy logic) teorisi ve tarımda kullanım olanakları Üzerine bir araştırma, Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 98.
- Gülbandılar, E. ve Gülbandılar, A. (2016). Alanya/Antalya – Turkey Saccharomyces cerevisia Maya Hücresinin Büyüme Eğrisinin Anfis ile Modellenmesi.
- Gülbandılar, E. (2005). Effects of pulsing electromagnetic field on the growth of saccharomyces cerevisiae, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 55-64.
- Gülbandılar, E. (1996). Puslu elektromagnetik alanın saccharomyces cerevisiae mayasının üremesi üzerine etkisi. Osmangazi Üniversitesi Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 10-11.
- Gülbandılar, E. (2004). Bulanık mantık algoritması ile beyin travma derecesinin incelenmesi, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 37-38.



### KAYNAKLAR DİZİNİ (devam)

Gülez, K. (2004). A General Regression, Neural Network, 761-777.

Güzeller, C., Önder, R., Dursun, C. (2016). Matlab, yapay zekâ ve sosyal istatistik uygulamaları. Maya Akademi, 147.

Haykin, S. (2005). Neural Networks: A Comprehensive Foundation, Pearson Prentice all, Delhi.

<http://portal.netcad.com.tr/pages/viewpage.action?pageId=104794233> (netcad, 2018)

<https://www.mathworks.com/help/fuzzy/what-is-sugeno-type-fuzzy-inference.html> (mathworks, 2018)

Jang, J-S.R., Sun, C.T., Mizutani, E. (1997). Neuro-Fuzzy and Soft Computing Computational Approach to Learning and Machine Intelligence. MATLAB Curriculum Series, 335-340.

Jang, J-S.R. (1996). Input selection for ANFIS learning, Fuzzy Systems. Proceedings of the Fifth IEEE International Conference, 1493 –1499.

JANG, J-S.R. (1993). Anfis: Adaptive - Network Based Fuzzy İnference Systems. IEEE Trans. On Systems. Man. and Cybernetics, 665- 685.

Kaya, Ö. (2007). Bulanık doğrusal programlama ve üretim planlama üzerine bir uygulama, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, 17-18.

Keskenler, M. F. ve Keskenler, E. F. (2017) Bulanık mantığın tarihi gelişimi, Türkiye Takvim-i Vekayi Dergisi, 4-6.

Kıyak, E. ve Kahvecioğlu, A. (2003). Bulanık mantık ve uçuş kontrol problemine uygulanması. Havacılık ve Uzay Teknolojileri Dergisi Cilt 1 Sayı 2, 63-72.

Kıyak, E. (2003). Bulanık mantık yöntemiyle uçuş kontrol uygulamaları. Yüksek Lisans Tezi, Anadolu Üniversitesi.

Lee, A. H. I., Chen, W. C., ve Chang, C. J. (2008). A fuzzy AHP and BSC approach for evaluating performance of IT department in the manufacturing industry in Taiwan, Expert Systems with Applications, 96-107.

Mutlu, B. (2014). Hiyerarşik bulanık çıkarsama sistemlerinde bulanıklığın düzeyler arası aktarımı için yöntem önerisi, Hacettepe Üniversitesi, Yüksek Lisans Tezi, 6.

Özcan, F., Atis, C.D., Karahan, O., Uncuoglu, E., ve Tanyildizi, H. (2009). Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete. Advances in Engineering Software, 856–863.

Öztemel, E. (2003). Yapay sinir ağları, Papatya Yayıncılık, İstanbul.

### KAYNAKLAR DİZİNİ (devam)

- Özveren, U. (2006). Pem yakıt hücrelerinin yapay sinir ağları ile modellenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Pankaj, M., Benjamin, W. (1992). *Artifisial Neural Networks Concepts and Theory*, IEEE Computer Society Press, Washington, 45.
- Sarı, N. İ. ve Arslan, E. (2007). Geoit yüksekliğinin anfis ile adım adım hesaplanması, Jeodezi Jeoinformasyon ve Arazi Yönetimi Dergisi, 31-38.
- Sarıdoğan, M. (2009). Öz örgütlemeli (Kohonen) haritalar ile esnek üretimde yer alan otomatik güdümlü araçların (Oga) rotalarının belirlenmesi, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, 32.
- Sattarov, R. (2015). Kalite fonksiyon yayılımında bulanık mantık yaklaşımı: Beyaz eşya sektöründe bir uygulama, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Şen, Z. (2004). Mühendislikte bulanık mantık ile modelleme prensipleri, Su vakfı yayınları. 191.
- Şen, Z. (2009). Bulanık mantık ilkeleri ve modelleme, Üçüncü Baskı, 14-18.
- Şit, S. (2013). Üç Fazlı sincap kafesli indüksiyon motorunun bulanık mantık esaslı yöntemler kullanılarak denetimi, Yüksek Lisans Tezi, Kahraman Maraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, 87.
- Takagi, T. ve Sugeno, M. (1985). Fuzzy Identification of Systems and Its Applications to Modelling and Control, IEEE Transactions on Systems, Man and Cybernetics, 116-132.
- Tron, Z. ve Margaliot, M. (2004). Mathematical modeling of observed natural behavior: A fuzzy logic approach. Fuzzy Sets and Systems, 437-450.
- Uçuk, S. (2009). Bir vinçteki yük salınımının bulanık mantık tabanlı kontrolü, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 22.
- Yücel, A. ve Güneri, A. F. (2010). Application Of Adaptive Neuro Fuzzy Inference System to Supplier Selection Problem. Sigma Dergisi, 224-234.
- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing, 159-175.

## ÖZGEÇMİŞ

Necati KARAKUŞ, 1983 yılında Nizip'te doğdu. Orta öğrenimini Gaziantep'te tamamladıktan sonra 2002 yılında Hava Harp Okulu Bilgisayar Mühendisliği Bölümü'nde lisans eğitimine başladı. 2006 yılından beri Hava Kuvvetleri Komutanlığı'nda çalışmaktadır.

