

**T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI**

DOKTORA TEZİ

**ZAMAN SERİLERİNDE YAPAY SİNİR AĞLARI
VE BULANIK MANTIĞA DAYALI TAHMİN VE
BİR UYGULAMA**

**MUHAMMET ATALAY
2502100305**

**TEZ DANIŞMANI
PROF. DR. MEHMET ERDAL BALABAN**

İSTANBUL - 2015



T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



DOKTORA
TEZ ONAYI

ÖĞRENCİNİN;

Adı ve Soyadı : MUHAMMET ATALAY Numarası : 2502100305
Anabilim Dalı /
Anasanat Dalı / Programı : SAYISAL YÖNTEMLER Danışmanı : PROF.DR M.ERDAL BALABAN
Tez Savunma Tarihi : 10.12.2015 Saati : 14:00
Tez Başlığı : ZAMAN SERİLERİNDE YAPAY SİNİR AĞLARI VE BULANIK MANTIĞA DAYALI
TAHMİN VE BİR UYGULAMA

TEZ SAVUNMA SINAVI, İÜ Lisansüstü Eğitim-Öğretim Yönetmeliği'nin 50. Maddesi uyarınca yapılmış,
sorulan sorulara alınan cevaplar sonunda adayın tezinin KABULÜNE OYBİRLİĞİ / ÇOKLUYLA karar verilmiştir.

JÜRİ ÜYESİ	İMZA	KANAATI (KABUL / RED / DÜZELTME)
1-PROF.DR M.ERDAL BALABAN		Kabul
2- PROF.DR NECDET TEKİN		Kabul
3- PROF.DR HAKAN YILDIRIM		Kabul
4- DOÇ.DR SEDA TOLUN		Kabul
5- DOÇ.DR ÇİĞDEM ARICIGİL ÇILAN		Kabul

YEDEK JÜRİ ÜYESİ	İMZA	KANAATI (KABUL / RED / DÜZELTME)
1- PROF.DR RAUF NİŞEL		
2- PROF.DR MEHPARE TİMOR		

Versiyon: 1.0.0.2-61559050-302.14.06

ÖZ

ZAMAN SERİLERİNDE YAPAY SİNİR AĞLARI VE BULANIK MANTIĞA DAYALI TAHMİN VE BİR UYGULAMA

MUHAMMET ATALAY

Klasik mantıkta kullanılan kesin hatlarla birbirinden ayrılmış aralıklar yerine, tanımlanan fonksiyonlarla birbirine geçmiş çok sayıda aralıkları kullanan bulanık mantık ve biyolojik sinir sisteminin matematiksel bir modeli olarak da tanımlanabilecek olan yapay sinir ağları, biyolojik insan gibi karar verebilen ve muhakeme yeteneği olan zeki sistemler elde etmeyi amaçlayan yapay zeka teknikleridir. Bu iki tekniğin faydalarını bir araya getirmek için birlikte kullanıldığı hibrid sistemlerle, sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilen, sinir ağları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın kuralları ile ortadan kaldırılabilir.

Gözlemleri belirsizlik içeren veya bir zaman birimi içinde birden fazla değere sahip olan zaman serilerinin çözümlenmesinde bulanık zaman serileri yöntemleri tercih edilebilir. Temelde bulanıklaştırma, bulanık ilişkilerin bulunması ve durulaştırma olmak üzere üç aşamadan oluşan bu yöntemlerde, her bir aşama için sezgisel metotlar, matematiksel hesaplamalar, yapay zeka teknikleri, yapay zeka optimizasyon yöntemleri ve istatistiksel yöntemler kullanılmaktadır.

Bu çalışmada, çok değişkenli bulanık zaman serileri analizinde bulanık ilişkilerin belirlenmesinde yapay sinir ağları ve üyelik fonksiyonları kullanılarak, ağın öğrenme yeteneği ile bir tahmin yöntemi oluşturulmuştur. Metot, çok değişkenli bulanık zaman serilerinde klasik zaman serileri ve yapay sinir ağları yöntemlerini bir araya getirerek hibrit bir yöntem sunmaktadır. Önerilen yöntem, Türkiye’de meydana gelen trafik kazaları veri seti ile uygulanarak farklı modeller için sonuçlar karşılaştırmalı olarak hesaplanmış ve değişkenlerle ilgili tahminler yapılmıştır. Yapay sinir ağları ile desteklenmiş bulanık zaman serileri yöntemi ile çok değişkenle az sayıda veride dahi daha iyi sonuçlar elde edildiği görülmüştür.

Anahtar Kelimeler: Bulanık zaman serileri, bulanık mantık, yapay sinir ağı, zaman serileri, tahmin.

ABSTRACT

TIME SERIES FORECASTING BASED ON ARTIFICIAL NEURAL NETWORKS AND FUZZY LOGIC AND AN APPLICATION

MUHAMMET ATALAY

Fuzzy logic which uses many intervals intertwined with defined functions instead of the intervals left each other by exact lines in classical logic and also, artificial neural networks which can be defined as mathematical model of biological neural system, are artificial intelligent methods aimed to obtain the intelligent systems which have the abilities to decide and reason like human. Learning ability is brought to fuzzy logic for neural networks and by the hybrid systems which are occurred by these two methods to gather their advantages. The difficulty to grip the data presented by neural networks can be removed by the rules of fuzzy logic.

The methods of fuzzy time series can be preferred to analyse time series whose surveys containing uncertainties or which have values more than one in one time unit. Intuistic methods, mathematical computations, artificial intelligent techniques, artificial intelligent optimization methods and statistical methods are used for each level in these methods which are essentially comprised of fuzzification, establishing fuzzy relations and defuzzification.

In this study, artificial neural networks and membership functions are used to determine fuzzy relations in multivariate fuzzy time series analysis, therefore an estimate method is formed by learning ability of the network. The method have been formed by a hybrid one which is formed by classical time series and artificial neural networks in multivariate fuzzy time series. This method has been applied to data set of traffic accidents occurred in Turkey, then the results obtained about that subject by the method have been compared with the results get by various models and also some estimates have been made on variables. Finally, it has been seen that the better results have been obtained by limited number of data with multivariate by means of the method of fuzzy time series supported by artificial neural networks.

Keywords: Fuzzy time series, fuzzy logic, artificial neural network, time series, forecasting.

ÖNSÖZ

İnsan beynini model alan yapay zeka çalışmaları, günlük hayatın farklı alanlarında ürünler vermesinin yanında, tahmin, sınıflandırma, kümeleme gibi amaçlar için de kullanılmaktadır. Başlıca olarak uzman sistemler, genetik algoritmalar, bulanık mantık, yapay sinir ağları, makine öğrenmesi gibi teknikler, genel olarak yapay zeka teknolojileri olarak adlandırılmaktadır. Bulanık mantıkta, klasik küme kuramından farklı olarak bulanık küme kuramı ile bir kümede sınır koşulları esnek olarak tanımlanabilmekte, kesin sınırlamaları ve tanımlamaları gerektirmeyen problemlerin çözümü gerçekleştirilebilmektedir. Yapay sinir ağları ise, birbirleri ile bağlantılı yapay sinir hücrelerinin oluşturduğu bir sistem ile biyolojik sinir sisteminin bilgiyi depolama, kullanma ve işleme yeteneklerini taklit etmeyi ve insan gibi karar verebilen ve muhakeme yeteneği olan zeki sistemler elde etmeyi amaçlamaktadır. Yapay sinir ağlarının en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışabilmesidir. Öte yandan sinir ağlarının; çok katmanlı ağ yapısında, sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması gibi dezavantajları da bulunmaktadır. Bulanık mantığın en önemli eksiği ise öğrenme yeteneği olmamasıdır. Bu iki tekniğin faydalarını bir araya getirmek için birlikte kullanıldığı hibrid sistemlerde, yapay sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilen, sinir ağları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın kuralları ile ortadan kaldırılarak anlaşır çıktılar elde edilebilmektedir.

Zaman serileri analizi, zamana bağlı değerler alan değişkenlerin geçmiş değerlerinin çeşitli yöntemlerle incelenerek varsa aralarındaki ilişkilen ortaya çıkarılması, gelecekteki değerlerin tahmin edilmesi veya modellenmesine dayanmaktadır. Ancak gözlemleri belirsizlik içeren veya bir zaman birimi içinde birden fazla değere sahip olan verilerin çözümlenmesinde bulanık zaman serileri yöntemleri tercih edilebilir. Bu yöntemler, klasik zaman serisi kestirim modellerinin çözümlenmesinde bulunan doğrusallık, durağanlık, tersinirlik ve gözlem sayısı gibi birçok kısıtın olmaması, ilgilenilen olayın kendisinden kaynaklanan belirsizlikleri

dikkate alması, uygulamaların dilsel terimlere dayanan verilerle de gerçekleştirilebilmesi gibi avantajlara sahiptir. Temelde bulanıklaştırma, bulanık ilişkilerin bulunması ve durulaştırma olmak üzere üç aşamadan oluşan bu yöntemlerde, her bir aşama için sezgisel metotlar, matematiksel hesaplamalar, yapay zeka teknikleri, yapay zeka optimizasyon yöntemleri ve istatistiksel yöntemler kullanılmaktadır.

Bulanık ilişkilerin belirlenmesinde, gözlemlerin ait olduğu (en yüksek üyelik derecesine sahip olduğu) kümeler ve buna ait küme numaraları ile işlem yapılmakta, diğer kümeler ve üyelik değerleri ise ihmal edilmektedir. Bulanık ilişkiler belirlenirken, her bir gözlemin tüm bulanık kümelere ait olmasının üyelik değerlerinin dikkate alınması, hem bilgi kaybını önleyecek hem de bulanık zaman serisinde mevcut bulanık ilişkileri daha gerçekçi olarak ortaya koyacaktır. Bu çalışmada, çok değişkenli yüksek dereceli bulanık zaman serileri analizinde bulanık ilişkilerin belirlenmesinde yapay sinir ağları kullanılarak ağın öğrenme yeteneği ile bir tahmin yöntemi oluşturulmuştur.

Çalışmamızda öncelikle klasik zaman serileri yöntemlerinden VAR analizi ve koentegrasyon (eşbütünleşme) metodu yardımı ile değişkenler ve modelin derecesi tespit edilmiş, seçilen değişkenlere ait veriler düzenlenmiş ve analize hazır hale getirilmiştir. İlk olarak değişkenlerin gözlem değerleri bulanıklaştırılmadan, belirlenen ana faktöre ait değerler, yapay sinir ağları ile tahmin edilmiştir. Burada yapay sinir ağının eğitim aşamasında farklı yöntemler denenerek hata miktarını minimize edecek model bulunmuş, test aşaması ile modelin performansı araştırılmıştır. Sonrasında ise aynı verilerle gözlem değerleri bulanıklaştırılarak yapay sinir ağları ile hibrid bir model kurularak bulanık zaman serileri analizi yapılmıştır. Önerilen metotta, bulanıklaştırma aşamasında uygun aralıkların seçiminde aralık sayısının keyfi sayılara göre belirlenmesine alternatif olarak kesin olarak belirlenebildiği bir yöntem önerilmiş ve k-ortalamlar tekniği kullanılmıştır. Öte yandan bulanıklaştırma ve durulaştırma aşamalarında Gaussian, Sigmoidal ve Çan Şekilli üyelik fonksiyonları kullanılarak sonuçlar hesaplanabilir bir yöntemle bulunmuş ve karşılaştırılmıştır. Ayrıca burada koentegrasyon ile elde edilen modelin katsayıları kullanılarak, farklı değişkenlere ait üyelik değerlerinin eş zamanlı olarak

modele katılmasının sağlanması amaçlanmıştır. Bulanık ilişkilerin belirlenmesinde ise yapay sinir ağlarının öğrenme yeteneğinden faydalanılmıştır. Farklı üyelik fonksiyonları ile elde edilen tüm üyelik değerleri ile çok katmanlı ileri beslemeli geriye yayımlı yapay sinir ağı modelleri oluşturulmuş ve eğitim aşamasında farklı modeller hata miktarını en az kılacak şekilde denenmiştir. Elde edilen modeller test verileri ile teste tabi tutulmuş ve performansları ölçülmüştür. Öngörülerin durulaştırılmasında ise yine üyelik fonksiyonları ve belirlenen katsayılar yardımı ile hesaplanabilirlik sağlanmıştır. Bulunan sonuçlar kendi aralarında ve başlangıçta elde edilmiş olan standart yapay sinir ağları sonuçları ile karşılaştırılmıştır. Son olarak ise önerilen model yardımı ile geleceğe dair öngörüle bulunulmuştur.

Önerilen tüm metotlar, Türkiye’ de meydana gelen trafik kazaları ile ilgili değişkenlerin oluşturduğu ve farklı kaynaklardan derlenen 25 yıllık (1990-2014) güncel veri seti ile uygulanmaktadır. Verilerin ülkemiz için önemli bir yeri olan trafik kazalarını etkileyen faktörler ve sonuçları ile ilgili olarak seçilmesi ile, bulanık zaman serileri yöntemlerinin geliştirilmesine ilave olarak aynı zamanda güncel hayata dair bir katkı sunulması amaçlanmıştır.

Bu çalışmanın her aşamasında bilgi ve tecrübelerini benimle paylaşan ve verdiği fikirlerle tezimi şekillendiren, her konuda çok şey öğrendiğim danışman hocam Prof.Dr. Mehmet Erdal Balaban’a en içten saygı ve sonsuz şükranlarımı sunarım.

Geldiğim her noktada emekleri olan, bugünlerimin hazırlayıcıları sevgili anne ve babama, doktora eğitimim süresince bana destek olan, sabır, anlayış ve fedakarlık gösteren hayat arkadaşım değerli eşim Tuba Atalay’ a ve canım evlatlarım Büşra Nur, Zeynep Rana ve Halil Murat’ a sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZ	iii
ABSTRACT	iv
ÖNSÖZ	v
İÇİNDEKİLER	viii
ŞEKİLLER LİSTESİ	xii
TABLOLAR LİSTESİ	xiv
KISALTMALAR LİSTESİ	xvi
GİRİŞ	1
BÖLÜM 1	7
BULANIK MANTIK	7
1.1. Bulanık Mantık Kavramı	7
1.2. Bulanık Mantığın Tarihçesi ve Uygulamaları	8
1.3. Karar Analizi ve Bulanık Kümeler	9
1.4. Bulanık Kümeler ve Üyelik Derecesi	10
1.4.1. Üyelik Fonksiyonu	11
1.4.2. Üyelik Fonksiyonu Tipleri	12
1.4.3. Üyelik Fonksiyonunun Tespiti	16
1.4.4. Dilsel Değişkenlerin Gösterimi	16
1.5. Bulanık Kümelerle İlgili Tanımlar	18
1.5.1. Eşit Kümeler	19
1.5.2. Alt Küme	20
1.5.3. Destek (Support) Kümesi	20
1.5.4. Kesme (Cut) Kümesi	20

1.5.5.	Düzey Kümesi	20
1.5.6.	Normallik	20
1.5.7.	Dışbükeylik (Konvekslik)	21
1.5.8.	Bulanık Sayılar	22
1.6.	Bulanık Kümeler Üzerindeki İşlemler	23
1.6.1.	Birleşim İşlemi	23
1.6.2.	Kesişim İşlemi	24
1.6.3.	Kapsama	24
1.6.4.	Fark İşlemi	25
1.6.5.	Tümleme İşlemi	25
1.7.	Modelleme ve Bulanık Mantık	25
BÖLÜM 2.....		30
YAPAY SİNİR AĞLARI.....		30
2.1.	Giriş	30
2.2.	Biyolojik Sinir Hücresi	31
2.3.	Yapay Sinir Ağının Yapısı	34
2.4.	Yapay Sinir Hücresinin Öğeleri	36
2.4.1.	Girdiler	36
2.4.2.	Ağırlıklar	36
2.4.3.	Toplama (Birleştirme) Fonksiyonu	37
2.4.4.	Aktivasyon (Transfer) Fonksiyonu	38
2.4.5.	Hücrenin Çıktısı	40
2.5.	Yapay Sinir Ağında Katmanlar	40
2.5.1.	Girdi Katmanı.....	41
2.5.2.	Gizli Katman	41
2.5.3.	Çıktı Katmanı	41

2.6.	Yapay Sinir Ağı Çeşitleri	42
2.6.1.	Mimarisine Göre Ağ Çeşitleri	42
2.6.2.	Öğrenme Algoritmalarına Göre Ağ Çeşitleri	45
2.6.3.	Öğrenme Zamanına Göre Ağ Çeşitleri	49
BÖLÜM 3	50
HİBRİD SİSTEMLER	50
3.1.	Bulanık Sinir Ağları	52
3.1.1.	Bulanık Sinir Ağı Tipleri	54
3.2.	Sinirsel Bulanık Ağ Modeli	56
3.2.1.	Sinirsel Bulanık Ağ Yapısı	57
BÖLÜM 4	61
BULANIK ZAMAN SERİLERİ	61
4.1.	Zaman Serileri	61
4.2.	Bulanık Zaman Serileri	63
4.2.1.	Bulanık Zaman Serileri ile ilgili Kavram ve Tanımlar	65
4.2.2.	Yapılan Çalışmalar	68
4.3.	Chen (2002) Tarafından Önerilen Tek Değişkenli Yüksek Dereceli Bulanık Zaman Serisi Yöntemi	74
4.4.	Jilani, Burney ve Ardil (2008) Tarafından Önerilen Çok Değişkenli Yüksek Dereceli Bulanık Zaman Serisi Yöntemi	77
4.5.	Önerilen Yöntem	78
BÖLÜM 5	80
UYGULAMA	80
5.1.	Problemin Tanımlanması	80
5.2.	Türkiye Trafik Kazaları Verisi ve Tanımı	83
5.3.	Değişkenlerin Seçimi ve Verinin Hazırlanması	88

5.4. Metodoloji	103
5.4.1. Veri Setinin Eğitim ve Test Setlerine Ayrılması	103
5.4.2. Yapay Sinir Ağları İle Tahmin Modeli	104
5.4.3. Önerilen Hibrid Model	108
5.4.4. Gelecek Değer Tahmini	143
SONUÇ.....	145
KAYNAKÇA	151
EKLER.....	174
ÖZGEÇMİŞ.....	276

ŞEKİLLER LİSTESİ

Şekil 1.1: Üçgen Üyelik Fonksiyonlarının Gösterimi.....	13
Şekil 1.2: Yamuk Üyelik Fonksiyonlarının Gösterimi	13
Şekil 1.3: Gaussian Üyelik Fonksiyonlarının Gösterimi	14
Şekil 1.4: Çan Şekilli Üyelik Fonksiyonlarının Gösterimi	14
Şekil 1.5: Sigmoidal Üyelik Fonksiyonlarının Gösterimi.....	15
Şekil 1.6: S Üyelik Fonksiyonlarının Gösterimi	16
Şekil 1.7: Üç durumlu “sıcaklık” dilsel değişkeni	17
Şekil 1.8: “genç” ve “çok genç” dilsel değişkenleri	18
Şekil 1.9: Reel sayılarda tanımlı klasik ve bulanık kümelerin grafik gösterimi	19
Şekil 1.10: a) Normal Bulanık Küme b) Normal Altı Bulanık Küme	21
Şekil 1.11: a) Dışbükey Bulanık Küme b) Dışbükey Olmayan Bulanık Küme.....	21
Şekil 1.12: A ve B Bulanık Küme Birleşimleri	24
Şekil 1.13: A ve B Bulanık Küme Kesişimleri.....	24
Şekil 1.14: Bulanık Sistemin Genel Yapısı.....	29
Şekil 2.1: Biyolojik sinir hücresinin yapısı	32
Şekil 2.2: Sinir Hücreleri.....	32
Şekil 2.3: Bir Yapay Sinir Ağının Genel Yapısı	35
Şekil 2.4: Yapay Sinir Hücresi.....	37
Şekil 2.5. Bir yapay sinir ağı Yapısı	40
Şekil 2.6: Çok katmanlı ileri beslemeli sinir ağı mimarisi.....	43
Şekil 2.7: Çok katmanlı geri beslemeli sinir ağı mimarisi	44
Şekil 2.8: Çok tabakalı ileri beslemeli geri yayımlı sinir ağı mimarisi	44
Şekil 2.9: Danışmanlı Öğrenme	47
Şekil 2.10: Danışmansız Öğrenme	48
Şekil 3.1. Bulanık sinir ağı modeli.....	53
Şekil 3.2. Yamakawa'nın Bulanık Ağırlıklı Yapısı	54
Şekil 3.3. Ishibuchi ve arkadaşlarının Tip-2 Bulanık Sinir Ağı.....	55
Şekil 3.4. Basit Tip-3 Bulanık Sinir Ağı.....	55
Şekil 3.5. Bulanık Sistemler Kullanarak Sinir Ağları Kurma.....	56
Şekil 3.6. Bulanık küme tabanlı bir sistemin genel yapısı	57

Şekil 5.1. Yıllara Göre Nüfus (NX1), Toplam Kaza Sayısı (NX2) ve Toplam Otoyol (km)(NX23).....	94
Şekil 5.2. Yıllara Göre Toplam Kaza Sayısı (NX2), Kaza Yerinde Ölü Sayısı (NX5) ve Kaza Yerinde Yaralı Sayısı (NX6).....	95
Şekil 5.3. Yıllara Göre Toplam Otoyol (km)(NX23), 25-64 Yaş Ölü Sayısı (NX30) ve Sürücü Kusur Oranı (NX34)	95
Şekil 5.4. Yıllara Göre Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı (NX15), Toplam Otoyol (km)(NX23) ve Sürücü Kusur Oranı (NX34).....	96
Şekil 5.5. NX30 Değişkenine Ait Tahmin Değerlerinin Grafiği	102
Şekil 5.6. NX30 Değişkenine Ait Tahmin ve Gerçek Değerler ile Hata Terimleri .	102
Şekil 5.7. Yapay Sinir Ağı Mimarisi.....	107
Şekil 5.8. Küme Sayısına Göre Grup İçi Uzaklık Kareleri Toplamı	111
Şekil 5.12. Gaussian fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği	136
Şekil 5.13. Sigmoidal fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği	136
Şekil 5.14. Çan Tipi fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği	137

TABLolar LİSTESİ

Tablo 2.1: Biyolojik ve yapay sinir sisteminin karşılaştırılması.....	34
Tablo 2.2: Bazı Toplama Fonksiyonları	38
Tablo 2.3: Bazı Aktivasyon Fonksiyonları	39
Tablo 5.1. Avrupa Ülkelerine Ait 2013 Yılı Trafik Kazası ve Otomobil Sayısı Bilgileri	82
Tablo 5.2. Veri Kaynakları ve Kullanılan Verilerin Başlıkları.....	86
Tablo 5.3. 1990-2014 Trafik Kazaları Verisi Zaman Serileri.....	88
Tablo 5.4: Belirlenen Değişkenler ve Serilerin ve Normalize Edilmiş Serilerin Adları	91
Tablo 5.5. Değişkenler ve Aldığı Değerler	91
Tablo 5.6. Normalize Edilmiş Veriler.....	92
Tablo 5.7. Değişkenlere Ait Tanımsal İstatistikler	93
Tablo 5.8. Normalleştirilmiş Veriler İçin Tanımsal İstatistikler.....	94
Tablo 5.9. VAR Modeli İçin Uygun Gecikme Seçimi.....	97
Tablo 5.10. VAR(1) Modeli Tahmin Sonuçları.....	99
Tablo 5.11. ARDL Modeli Tahmin Sonuçları	100
Tablo 5.12. ARDL Modeli Hata Terimleri Serisi Birim Kök Testi Sonuçları.....	101
Tablo 5.13. Farklı gizli katman ve düğüm sayıları için toplam hata değerleri	106
Tablo 5.14. YSA Eğitim Sonuçları Tahmin Değerleri.....	108
Tablo 5.15. YSA Test Sonuçları Tahmin Değerleri.....	108
Tablo 5.16. Gaussian Fonksiyonu ile $t=2$ için 1. Aralık Üyelik Değerinin Hesaplanması	116
Tablo 5.17. Gaussian Fonksiyonu İle Belirlenen Üyelik Değerleri.....	117
Tablo 5.18. Sigmoidal Fonksiyon İle Belirlenen Üyelik Değerleri	118
Tablo 5.19. Çan Şekli Fonksiyon İle Belirlenen Üyelik Değerleri.....	118
Tablo 5.20. Gaussian Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve Hedef Değişkenleri	120
Tablo 5.21. Sigmoidal Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve Hedef Değişkenleri	121

Tablo 5.22. Çan Şekilli Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve Hedef Değişkenleri	121
Tablo 5.23. YSA Eğitim Sürecinde Kullanılan Parametreler	127
Tablo 5.24. Gaussian Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları.....	128
Tablo 5.25. Sigmoidal Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları.....	130
Tablo 5.26. Çan Şekilli Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları	131
Tablo 5.27. YSA Eğitim Sonuçlarına Göre Ağ Modellerinin Karşılaştırılması	135
Tablo 5.28. YSA Test Sonuçları	138
Tablo 5.29. YSA Test verileri için girdi ve çıktı değerleri	139
Tablo 5.30. Gerçek Gözlem Değerleri	142
Tablo 5.31. Durulaştırılmış Öngörü Verileri.....	142
Tablo 5.32. Tahmin İçin Kullanılacak Girdi Değerleri ve Elde Edilen Öngörüler..	144
Tablo 5.33. 2015 Yılı İçin Tahmin Değerleri	144

KISALTMALAR LİSTESİ

ADF	: Augmented Dickey-Fuller
AIC	: Akaike Bilgi Kriteri (Akaike Information Criteria)
Alg.	: Algoritma
AR	: Otoregresif (Autoregressive)
ARDL	: Otoregresif Dağıtılmış Gecikme (Autoregressive Distributed Lag)
ARMA	: Bileşik Otoregresif Hareketli Ortalama (Autoregressive Moving Average)
ARIMA	: Bileşik Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive İntegration Moving Average)
Bkz.	: Bakınız
BM	: Bulanık Mantık
FPE	: Son Tahmin Hatası Kriteri (Final Prediction Error)
FTS	: Bulanık Zaman Serileri (Fuzzy Time Series)
GA	: Genetik Algoritma
HQIC	: Hannan-Quinn Bilgi Kriteri (Hannan-Quinn Information Criteria)
HKT	: Hata Karelerinin Toplamı
HKO	: Hata Karelerinin Ortalaması
HKOK	: Hata Karelerinin Ortalamasının Karekökü
LR	: Benzerlik Oran Testi (Likelihood Ratio)
M _{1b}	: M1B Para Arzı
MA	: Hareketli Ortalama (Moving Average)
<i>max</i>	: Maksimum
MFTS	: Çokdeğişkenli Bulanık Zaman Serileri (Multivariate Fuzzy Time Series)
<i>min</i>	: Minimum
MYH	: Mutlak Yüzde Hata
NASDAQ	: National Association of Securities Dealers Automated Quotations

OMYH	: Ortalama Mutlak Yüzde Hata
SIC	: Schwarz Bilgi Kriteri (Schwarz Information Criteria)
TAIEX	: Taiwan Stock Exchange
TS	: Zaman Serileri (Time Series)
TÜİK	: Türkiye İstatistik Kurumu
VAR	: Vektör Otoregresif (Vector Autoregressive)
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zeka

GİRİŞ

Uzun yıllardan beri üzerinde birçok çalışmalar yapılan yapay zeka (YZ) teknikleri, oldukça geniş bir kullanım alanına sahiptir. Yapay zekanın bir çok alt çalışma kolu olmakla beraber Bulanık Mantık (BM) ve Yapay Sinir Ağları (YSA), üzerinde pek çok çalışmanın yapıldığı popüler konular olarak bilinmektedir.

Bulanık mantık, klasik mantıkta kullanılan kesin hatlarla birbirinden ayrılmış aralıklar yerine, tanımlanan fonksiyonlarla birbirine geçmiş çok sayıda aralıkları kullanmaktadır. Klasik kümelerde bir eleman ya kümeye aittir veya değildir. Yani bir önermenin doğruluk değeri ya 0 veya 1 olabilir. Bunu kümenin elemanları için üyelik değeri olarak düşünürsek, kümenin elemanı ise üyelik derecesi 1, değilse 0 olmalıdır. Bulanık bir kümede ise sınır koşulları esnek olarak tanımlanabilmektedir. 1965 yılında Prof. Lotfi Asker Zadeh, "Fuzzy Sets" başlıklı yazı ile bir dönüm noktası olarak yeni bir yönelim başlatmış ve bulanıklık kavramı dikkat çekmeye başlamıştır (Yang ve Liu, 2003: 305). Bulanık küme kuramında bir elemanın kısmi üyeliği de söz konusu olabilmekte ve bir elemanın üyelik derecesi $[0,1]$ aralığında herhangi bir değeri alabilmektedir. İşte bulanık kümeler, sınır koşulu ve üyelik derecesi yaklaşımı ile klasik kümelerden ayrılmakta ve daha geniş bir bakış açısı geliştirebilmektedir. Böylelikle kesin sınırlamaları ve tanımlamaları gerektirmeyen problemlerin çözümü gerçekleştirilebilmektedir. Dilimizde ifade edilen ve üzerinde çalışılan çoğu sınıflandırma kavramı, bu türde bir karakter de değildir. Örneğin; uzun boylu insanlar kümesi, pahalı otomobiller kümesi, yakın sürüş mesafesi, güvenilir kar araçları, birden çok büyük sayıların oluşturduğu küme gibi kavramlar klasik küme teorisinin öngördüğü şekilde incelenemezler. Bir bulanık küme, çalışma yapılan alana ait her bir elemana matematiksel olarak kümedeki üyelik derecesini temsil eden bir değer atayarak tanımlanır. Bu değer, elemanın bulanık küme tarafından ifade edilen kavrama üyelik derecesini ifade eder. Bundan dolayı bireylerin kümeye ait olması farklılaşır. Bulanık mantık, insanların kesin olmayan ifadelerle düşünme yeteneğiyle örtüşen mantık sistemidir. Bu bağlamda bulanık mantığın insan düşünüş tarzını taklit etmeye çalıştığı söylenebilmektedir (Özkan, 2003: 132). Bulanık modellemenin avantajları olarak; eksik, kesin olmayan ya da bulanık bilginin

işlenebilmesi, problemlere daha esnek değerlendirme imkânı sağlaması ve belirsiz sözel ifadeleri sayısal olarak tanımlayabilmesi özellikleri sayılabilir (Sarı v.d., 2005: 80, Baykal ve Beyan, 2004a: 192-193). Pek çok alanda verilerin bu ve benzeri durumlar taşıdığı bir gerçektir. Gerek üzerinde çalışılan problemde gerekse verinin özelliklerinden kaynaklanan bu durumlarda, bulanık mantık modelleri bu özellikleri ile daha iyi sonuçlar alınmasına imkan tanıyabilmektedir.

Bulanık mantığın tüm bu avantajlarının yanında bir takım dezavantajları da bulunmaktadır. Bulanık mantığın en önemli eksiği ise öğrenme yeteneği olmamasıdır. Bulanık mantıkta kullanılan üyelik fonksiyonları değişkenlerinin belirlenmesinde, kesin sonuç veren bir yöntem ve öğrenme yeteneği yoktur. En uygun yöntem deneme-yanılma yöntemidir, bu da çok uzun zaman alabilmektedir. Uzun testler yapmadan gerçekten ne kadar üyelik fonksiyonu gerektirdiğini önceden kestirmek çok güçtür. Bunun yanında bulanık mantık yaklaşımında üyelik fonksiyonu değişkenleri, sisteme özeldir ve başka sistemlere uyarlanması çok zordur (Elmas, 2003: 40). Bu eksikliklerin ortadan kaldırılması ancak bulanık mantık modellerine diğer yapay zeka teknikleri, optimizasyon teknikleri veya sezgisel yöntemler ilave edilerek yani hibrid modeller kullanılarak mümkün olabilir.

İnsan beyninin temel işlem elemanı ve sinir sisteminin en basit elemanı olan nöron ve bu nöronlar arası bağlantılara şekilsel ve işlevsel olarak benzeyen bir yapay sinir ağı, bu haliyle adeta biyolojik sinir sisteminin basit bir simülasyonudur. Yapay sinir ağları ile ilgili çalışmaların temelinde, insanda ve bazı canlılarda görülen deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabilme düşüncesi yatmaktadır. Yapay sinir ağları belirli bir işlevi yerine getirmek için eğitilebilirler ve bu eğitim bağlantılarının değerlerini değiştirmekle sağlanır. Yapay sinir ağlarını geleneksel sistemlerden ayıran en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışma özellikleridir. Bu özellikler yapay sinir ağlarına hız, hataya karşı tolerans ve verimlilik gibi avantajlar kazandırmaktadır (Durmuş, 2005: 48,49). Tüm bunların yanı sıra, sinir ağlarının; çok katmanlı ağ yapısında, sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması gibi dezavantajları da bulunmaktadır (Bernard, 1992). Dolayısıyla yapay sinir ağları

modelleri, hem avantajları ile diğer modellerin dezavantajlarını ortadan kaldırmak amacıyla hem de dezavantajlı olduğu yönlerindeki eksikliklerin diğer yöntemlerle tamamlanması için çeşitli yöntemlerle hibrid olarak kullanılabilir.

Bu iki tekniğin birlikte kullanılması ile meydana gelen hibrid sistemlerin amacı her iki yaklaşımın da faydalarını toplayıp, bir araya getirmektir. Yapay sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilir. Sinir ağları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın sözel terimleri ve eğer-o halde kuralları ile ortadan kaldırılarak anlaşır çıktılar elde edilebilmektedir. Genel olarak bulanık mantık ile yapay sinir ağlarının birleşmesi ile elde edilen hibrid sistemler, (1) Bulanık Sinir Ağları, (2) Sinirsel Bulanık Sistemler ve (3) Bulanık-Sinirsel Hibrid Sistemler şeklinde karşımıza çıkmaktadır.

Zamana bağlı bir olayın, gözlem ya da deney sonucunda aldığı değerlerden oluşan veri topluluğu olan zaman serileri, bir değişkenin farklı zamanlarda gözlenen değerler grubunu ifade etmektedir. Bir değişkenin geçmişteki durumunun çeşitli yöntemlerle incelenmesi ve elde edilen bilgilerden yararlanarak gelecekteki değerlerin tahmin edilmesine veya modellenmesine dayan zaman serileri analizlerinde amaç, (1) tek değişkenli zaman serileri analizlerinde tek bir seriye ait gözlemlerin dinamik veya zamana bağlı yapısının anlaşılması, (2) çok değişkenli zaman serileri analizlerinde ise iki ya da daha çok seri arasında önceleştirme, geciktirme ve geri besleme ilişkilerinin ortaya çıkarılması olmaktadır (Sevüktekin ve Çınar, 2014: 48). Bu tekniklerin en önemli sorunu ise durağanlık, normallik, doğrusallık, örneklem hacmi gibi kısıtların bir veya bir kaçına mutlaka sahip olmasıdır. Bunun yanında gözlem değerlerinde var olabilen belirsizlikler için ilave yöntemler kullanılması zaruri olmaktadır.

Gözlemleri belirsizlik içeren veya bir zaman birimi içinde birden fazla değere sahip olan borsa, sıcaklık, okullara kayıtlı öğrenci sayısı, hava kirliliği gibi verilerin çözümlenmesinde ise bulanık zaman serileri yöntemleri tercih edilebilir (Eğrioğlu v.d., 2010b). Bu yöntemler kendi aralarında; *birinci dereceden* ve *yüksek dereceli (n. dereceden)* bulanık zaman serisi modelleri ve *tek değişkenli (tek faktör)*, *iki değişkenli (çok değişkenli/iki faktör)* ve

m deęişkenli (çok deęişkenli/*m* – faktör) bulanık zaman serisi modelleri şeklinde sınıflandırılabilir. Bulanık zaman serisi analizi yöntemleri genel olarak, gözlemlerin bulanıklaştırılması (fuzzification), bulanık ilişkilerin belirlenmesi (establishing fuzzy relations) ve durulaştırma (defuzzification) olmak üzere üç aşamadan oluşmaktadır. Bu aşamalarda hesaplamaları kolaylaştırmak ve öngörü doğruluğunu güçlendirmek amacıyla, sezgisel metotlar, matematiksel hesaplamalar, yapay zeka teknikleri, yapay zeka optimizasyon yöntemleri ve istatistiksel yöntemler kullanılmaktadır.

Bu çalışmada, zaman serilerinin gözlem değerleri bulanıklaştırılarak ve yapay sinir ağları ile hibrid bir model kurularak bulanık zaman serileri analizi yapılmıştır. Böylelikle çok deęişkenli yüksek dereceli bulanık zaman serileri analizinde bulanık ilişkilerin belirlenmesinde yapay sinir ağları kullanılarak ağın öğrenme yeteneęi ile bir tahmin yöntemi oluşturulmuştur. Çalışma, bulanık zaman serileri metodlarında yukarıda saydığımız üç aşamanın her biri için öneriler getirmektedir. İlk olarak genellikle deneme yanılma ile tespit edilen modeldeki deęişken sayısı ve modelin derecesi, klasik zaman serileri yöntemlerinden VAR analizi ve koentegrasyon (eşbütünleşme) metodu ile entegre çalışılarak belirlenmektedir. İkinci olarak bulanıklaştırma aşamasında uygun aralıkların seçiminde aralık sayısının keyfi sayılara göre belirlenmesine alternatif olarak kesin olarak belirlenebildięi bir yöntem önerilmekte ve k-ortalamlar teknięi kullanılmaktadır. Üçüncü olarak bulanıklaştırma ve durulaştırma aşamalarında Gaussian, Sigmoidal ve Çan Şekilli üyelik fonksiyonları kullanılarak sonuçların hesaplanabilir bir yöntemle bulunması amaçlanmaktadır. Dördüncü olarak koentegrasyon ile elde edilen modelin katsayıları yapay sinir ağına katılacak üyelik değerlerinin hesaplanmasında kullanılarak, farklı deęişkenlere ait üyelik değerlerinin eş zamanlı olarak modele katılmasının sağlanması amaçlanmıştır. Son olarak ise öngörülerin durulaştırılmasında ise yine üyelik fonksiyonları ve belirlenen katsayılar yardımı ile hesaplanabilirlik sağlanmıştır.

Tahmin problemlerinde yaygın ve başarılı bir kullanımı olan çok katmanlı ileri beslemeli geriye yayımlı yapay sinir ağı modelleri bu çalışmada da tercih edilmiştir. Önerilen tüm modeller için eğitim aşamasında hata miktarını en az kılacak şekilde denemeler yapılmış, elde edilen modeller test verileri ile teste tabi tutulmuş ve

performansları ölçülmüştür. Bulunan sonuçlar kendi aralarında ve standart yapay sinir ağları sonuçları ile karşılaştırılmıştır. Son olarak ise önerilen model yardımı ile geleceğe dair öngöründe bulunulmuştur.

Bu çalışmada kullanılan klasik zaman serileri yöntemleri ile ilgili işlemler EViews 7.0 yazılımı ile, diğer tüm teknikler ise açık kaynak kodlu R programlama dili (R-project, 2015) ile paketler yardımıyla komutlar yazılarak uygulanmıştır.

Önerilen metot, Türkiye’ de meydana gelen trafik kazaları ile ilgili 8 değişkenden oluşan veri seti ile uygulanarak tahminler hesaplanmıştır. Konunun güncel hayata dair taşıdığı önem, bu çalışmanın kazanımlarındandır. Veri seti, Ulaştırma, Denizcilik ve Haberleşme Bakanlığı, TÜİK ve Karayolları Genel Müdürlüğü tarafından yayınlanan bülten ve verilerden derlenmiştir.

Çalışmanın giriş bölümünden sonraki bölümleri şu şekilde düzenlenmiştir:

Birinci bölümde bulanık mantık kavramı tanımlanarak genel özellikleri ifade edilmiştir. Bulanık kümeler, bulanık kümelerle kavramlar, bulanık küme teorisinde küme işlemleri, bulanık mantık ile modelleme anlatılmıştır.

İkinci bölümde yapay sinir ağları ele alınmıştır. YSA’ nın genel tanımı ve yapısı incelenmiş, yapay sinir ağı çeşitleri ve mimarileri ayrıntılarıyla açıklanmıştır.

Üçüncü bölümde yapay sinir ağları ve bulanık mantığın birlikte kullanıldığı hibrid sistemler anlatılmıştır.

Dördüncü bölümde, zaman serileri ve bulanık zaman serileri tanımlanmış ve karşılaştırmaları yapılmıştır. Bulanık zaman serileri çeşitleri tanımlanmış, bulanık zaman serileri analizi ve aşamaları anlatılmıştır. Günümüze kadar yapılan çalışmalardan detaylıca bahsedilmiş, literatürde uygulanan yöntemlerden tek değişkenli yüksek dereceli bulanık zaman serisi yöntemi (Chen, 2002) ve çok değişkenli yüksek dereceli bulanık zaman serisi yöntemi (Jilani, Burney ve Ardil, 2008) aşamaları ile açıklanmıştır. Ayrıca bu yöntemler temel alınarak çok değişkenli yüksek dereceli, bulanık mantık ve yapay sinir ağına dayanan bulanık zaman serisi öngörü modeli için yeni bir yaklaşım önerilmiştir.

Beşinci bölümde, önerilen yöntem Türkiye’ de meydana gelen trafik kazaları ile ilgili 8 değişkenden oluşan veri seti ile uygulanarak tahminler hesaplanmıştır. Sırası ile önce klasik zaman serileri yöntemlerinden olan VAR yöntemi ve koentegrasyon (eşbütünleşme) analizi ile değişkenler ve değişkenlerin gecikme seviyesi tespit edilmiş, sonrasında bu değişkenlere ait zaman serilerinde klasik yapay sinir ağı modeli kurulmuş, en son ise yapay sinir ağı ile hibrid çok değişkenli yüksek dereceli bulanık zaman serileri yöntemi uygulanarak sonuçlar karşılaştırılmıştır. En iyi sonucu veren model ile gelecek dönem öngörüsü hesaplanmıştır.

Son bölümde, beşinci bölümde elde edilen sonuçlar yorumlanmış ve çalışmanın geneli değerlendirilerek tespit ve öneriler geliştirilmiştir.

BÖLÜM 1

BULANIK MANTIK

1.1. Bulanık Mantık Kavramı

Klasik mantığa göre bir önerme “ya doğrudur ya da yanlıştır.” Halbuki doğruluk durumu açık olmayan durumlarla da karşılaşılabilir. Gerçek hayatta ise bir olayla ilgili önermenin durumu, kesin doğru, kısmen doğru, belli bir olasılıkla doğru veya yanlış olarak değerlendirilir. Bu durum, klasik mantık kurallarının daha esnek uygulanabilmesini gerektirmektedir. İki değerli mantıkta her şey ya doğru ya yanlıştır. Çok değerli mantıkta doğruluk derecelendirilebilir. Fakat bu iki ya da daha fazla değer arasında kalan durumlar izaha muhtaç kalmaktadır. 1965 yılında Prof. Lotfi Asker Zadeh, “Fuzzy Sets” başlıklı yazı ile bir dönüm noktası olarak yeni bir yönelim başlatmış ve bulanıklık kavramı dikkat çekmeye başlamıştır (Yang ve Liu, 2003: 305).

Bulanık mantığın iki anlamı bulunmaktadır. Özelde, dar anlamıyla bulanık mantık yaklaşık akıl yürütmeyi şekillendirmeyi amaçlayan bir mantık sistemidir. Bu anlamda bulanık mantık çok değerli mantığın bir uzantısı olsa da, gündemi klasik çok değerli mantıktan oldukça farklıdır. Geniş anlamda ise bulanık mantık, bulanık küme teorisini de kapsar ve dar anlamıyla bulanık mantığı da içerir. Günümüzde bulanık mantık denildiğinde anlaşılan geniş anlamda bulanık mantıktır (Baykal ve Beyan, 2004a: 102).

Bulanık mantığı, diğer mantık sistemlerinden ayıran önemli özelliklerden birisi, üçüncünün olmazlığı ilkesi ve çelişmezlik ilkesi olarak adlandırılan ve diğer mantık sistemleri için oldukça önemli olan hatta temel kural denilebilecek iki özelliğin, bulanık mantık için geçerli olmamasıdır. Bulanık mantıkta bir önerme aynı zamanda hem "doğru" hem de "yanlış" olmaz denilememektedir. Bu durum, doğruluğun çok değerli oluşundan kaynaklanmaktadır (Baykal ve Beyan, 2004b: 39).

Gerçek dünya olaylarındaki belirsizliği incelemek için, genellikle olasılık kuramının kavramları ve yöntemleri kullanılmaktadır. Fakat 1960'lı yıllarda, güncel

problemleri modellemede kullanılan olasılık kuramının kavramları ve yöntemleri tekrar gözden geçirilmiş ve bazı eleştirilere maruz kalmıştır. Daha sonraları, bu eleştiriler doğrultusunda olasılık kuramının yerine kullanılacak yöntemler geliştirmek için yoğun çalışmalar yapılmıştır (Yenilmez, 2001: 2). İşte bulanık küme kuramı, bu çalışmalara alternatif olarak geliştirilmiştir.

1.2. Bulanık Mantığın Tarihçesi ve Uygulamaları

Charles Sanders Peirce, mantıkta “belirsizlik (vagueness)” kavramı üzerine dikkat çekerek (Peirce, 1931) mantık biliminde bulanıklık ile ilgili ilk çalışmayı yapan kişi olmuştur. Sonrasında bu kavram üzerine 20. yüzyılın ilk yarısında çalışmalar (Copilowish, 1939; Hempel, 1939) yapılmıştır. Benzer şekilde Jan Lukasiewicz, çok değerli mantık üzerinde belirsiz değerleri “ara doğruluk değerleri” ile açıklamaya çalışmış (Lukasiewicz, 1910, 1920, 1929, 1930), ancak bu ara değerleri açıklayan ve bulanık üyelik fonksiyonunun fikrini ilk olarak ortaya atan Max Black (Black, 1937) bu konunun öncüsü olmuştur (Dubois ve Prade, 2000: 24-25). Bu fikir üzerine 1962 yılında çalışmaya başlayan Prof. Zadeh, yayınladığı makalede (Zadeh, 1965) bulanık küme kuramının temellerini oluşturmuştur (Yapıcı, 2000: 5). Zadeh bu makalede, sistemdeki karmaşıklığın yarattığı belirsizliğin farklı görünümelerini ve kişilerde algılama farklılıklarını ele almıştır (Özkan, 2002: 4).

1970'lerde bulanık mantık, endüstriyel uygulamalarda kullanılan bir bulanık mantık sistemi oluşturmak için uzman sistemlerle birleştirilmiştir. Mamdani ve Assilian tarafından yapılan gerçek bir kontrol uygulaması ile (Mamdani ve Assilian, 1975) bulanık kavram ve sistemleri dünyanın değişik araştırma merkezlerinin de dikkatini çekmiştir. Bu araştırmacılar ilk defa bir buhar makinesinin kontrolünü bulanık sistem ile modellemişlerdir. Bir çimento fabrikasının işletilmesi ve kontrolü için 1980'de Hollanda'da kullanılan bulanık sistem uygulaması, dünyanın birçok yerinde, özellikle de Japonya, Singapur, Kore ve Malezya'da kullanılmaya başlanmıştır. Kullanıldığı alanlardan bazılarına örnek olarak elektrikli süpürgeler, çamaşır makineleri, araçlarda yakıt püskürtme ve ateşleme sistemleri, asansörler, televizyon ve müzik setleri, ısı denetimi, elektrik akımı, sıvı gaz akımı, otomotiv ürünleri, kimyasal ve fiziksel süreç denetimleri, metro ve şirket işletimi söylenebilir

(Şen, 2004: 9; Elmas, 2010: 187-189). Günümüzde ise başta Japonya, Amerika ve Almanya'da olmak üzere binlerce ticari ve endüstriyel uygulamada bulanık sistemler başarı ile kullanılmaktadır.

1.3. Karar Analizi ve Bulanık Kümeler

Karar verme, gerek gündelik hayatta gerekse işletmeler açısından büyük önem taşıyan bir işlemdir. Bir işletmenin doğru kararlar vermesi ise mevcudiyetini devam ettirmesi ve gelişmesi açısından hayati öneme sahiptir. Bilim ve teknolojiye gelişmelerin karar süreçlerine etki eden etmenlerin çeşitliliğini, etkileme oranlarını ve değişkenliğini sürekli revize etmesi, bu süreçlerin incelenmesi zor bir özellik kazanmalarına sebebiyet vermektedir. Bu durum, etkili karar verme için karar destek sistemlerini yani yöneticilerin etkili karar alabilmeleri için gerekli tüm bilgi ve veriyi işleyebilen ve organize edebilen sistemleri gerektirmektedir. Karar verme sürecinde karar vericiler, dış çevrelerinde veya organizasyon içinde farklı biçimlerde bulunan bilgiyi (örneğin söylemeden anlaşılan veya açık bilgi) ve farklı tipteki veriyi (içsel veya dışsal veri) birleştirmektedir. Bu anlamda düşünüldüğünde karar vericinin görevi, karar vermeyi etkileyen belirsizlikler nedeniyle oldukça zordur (Aytaç, 2006: 44). Karar analizi, alternatiflerin en iyisini seçmek için akılcı bir sürecin kullanılmasıyla ilgilenir. Seçilen bir alternatifin "iyiliği" karar durumunun tanımında kullanılan verinin kalitesine bağlıdır. Bu durumda, bir karar verme süreci aşağıdaki üç sınıftan birinin içine girebilir:

1. Verinin deterministik olarak bilindiği belirlilik altında karar verme.
2. Verinin olasılık dağılımlarıyla tanımlanabildiği risk altında karar verme.
3. Verinin, karar sürecindeki ilişki derecesini temsil eden bağıl ağırlıklara atanamadığı belirsizlik altında karar verme (Taha, 2000: 511).

Belirlilik ortamı deterministiktir ve böyle bir ortamda genelde karşılaşılan seçenekler, minimum ya da maksimum olarak karar verici tarafından tercih edilmekte ve doğrusal programlama, CPM gibi optimizasyon tekniklerini yanı sıra diferansiyel hesap, türev, integral, fonksiyonlar teorisi gibi temel analiz yöntemleri kullanılarak problemin çözümüne gidilebilmektedir.

Risk koşullarında, her bir karar alternatifine ilişkin maliyetler olasılık dağılımlarıyla tanımlandığından, öncelikle olasılık teorisinin kullanılmak üzere, beklenen karı maksimize etmek veya beklenen maliyeti minimize etmek için, beklenen değer kavramı esas alınmaktadır. Burada da olasılıklı programlama, PERT, simülasyon gibi optimizasyon teknikleri olasılık teorisi ile birlikte kullanılmaktadır.

Belirsizlik altında karar verme, risk altında karar vermede olduğu gibi sonuçları tesadüfe (doğal durumlara) bağlı alternatif hareketlerle ilgilenir. Aradaki fark ise, belirsizlik durumunda durumların olasılık dağılımları bilinmiyor veya bilinemiyordur. Belirsizlik ortamında karar verme ile ilgili olarak ortaya atılan çeşitli yöntemler ise; Laplace, Minimaks, Savage ve Hurwicz kriterleri (Taha, 2000: 539), klasik olasılık kuramı, Bayes kuramı, klasik kümeler kuramına dayalı Hartley kuramı, Dempster Shafer Kuramı ve Zadeh'in Lukasiewicz Mantığını temel alan Bulanık Kümeler Kuramıdır (Aytaç, 2006: 45).

1.4. Bulanık Kümeler ve Üyelik Derecesi

Klasik kümelerde bir eleman ya kümeye aittir veya değildir. Yani bir önermenin doğruluk değeri ya 0 veya 1 olabilir. Bunu kümenin elemanları için üyelik değeri olarak düşünürsek, kümenin elemanı ise üyelik derecesi 1, değilse 0 olmalıdır. Fakat günlük hayatta her durum bu şekilde izah edilemez. Çünkü birden fazla doğruluk değeri/üyelik derecesi olan pek çok örnekle karşılaşılacaktır. Örneğin 18-34 yaş arası “genç”, 35-49 yaş arası “orta yaş”, 50 ve üzeri ise “yaşlı” olarak tanımlanmış olsun. Bu durumda 35 yaşındaki bir kişi de 49 yaşındaki bir kişi de orta yaş grubunda sayılacaktır. Halbuki 35 yaşında olan genç yaş grubuna yakın yaşta, 49 yaşında olan ise yaşlı grubuna daha yakın yaşta. Bu sorunu aşmak için, 35 yaşında bir kişinin, 18 yaşında bir kişi kadar olmasa da genç yaş grubuna da dahil edilebileceği söylenebilir. Aynı şekilde 49 yaşındaki bir kişi de yaşlı gruba bir dahil edilebilmesi gerekir. Bu durumda bir elemanın 0 veya 1 dışında da üyelik derecesi olabilmelidir.

Bulanık mantık, klasik mantıkta kullanılan kesin hatlarla birbirinden ayrılmış aralıklar yerine, tanımlanan fonksiyonlarla birbirine geçmiş çok sayıda aralıkları kullanmaktadır. Bu amaca matuf olmak üzere geliştirilen bulanık kümeler teorisiyle,

insan gibi düşünebilen, karar verebilen ve seçim yapabilen sistemlerin oluşması amaçlanmıştır. Başka bir deyişle bulanık küme kuramı, klasik matematiğin standartlarına göre pek çok bakımdan belirsiz olan veya kesin olmayan karar süreçlerine matematiksel bir kesinlik kazandıran kavramlar ve yöntemler bütünüdür (Yenilmez, 2001: 2).

Bulanık bir kümede sınır koşulları esnek olarak tanımlanabilmektedir. Bulanık küme kuramında bir elemanın kısmi üyeliği de söz konusu olabilmekte ve bir elemanın üyelik derecesi $[0,1]$ aralığında herhangi bir değeri alabilmektedir. İşte bulanık kümeler, sınır koşulu ve üyelik derecesi yaklaşımı ile klasik kümelerden ayrılmakta ve daha geniş bir bakış açısı geliştirebilmektedir. Böylelikle kesin sınırlamaları ve tanımlamaları gerektirmeyen problemlerin çözümü gerçekleştirilebilmektedir.

Bulanık kümeler iki yöntemle gösterilebilirler: İlki, kümelerin üyelik derecelerine göre sıralanması, ikincisi ise matematiksel olarak üyelik fonksiyonu tanımlamak şeklindedir. Klasik kümelerde üyelik dereceleri 0 ve 1 olmak üzere kesikli değer alırlar. Bulanık kümelerde ise üyelik dereceleri arasındaki geçiş yumuşak ve sürekli bir şekilde olmaktadır. Üyelik derecesi/fonksiyonu μ ile gösterilir. Klasik kümelerde bu üyelik fonksiyonu $\mu : E \rightarrow \{0,1\}$, bulanık kümelerde ise $\mu : E \rightarrow [0,1]$ şeklinde tanımlanır. Şunu da söylemek gerekir ki üyelik fonksiyonlarının oluşumu açık değildir ve bu durum bulanık küme kuramının bir dezavantajını oluşturmaktadır.

1.4.1. Üyelik Fonksiyonu

Genel olarak, küme üyelerinin değerleri ile değişiklik gösteren eğriye üyelik fonksiyonu adı verilmektedir. Üyelik fonksiyonu grafiğinde x eksenini, üyeleri gösterirken; y eksenini de, üyelik derecelerini göstermektedir (Baykal ve Beyan, 2004a: 105).

A bulanık küme, μ_A A'nın üyelik fonksiyonu, $\mu_A(x)$ ise $x \in A$ 'nın üyelik derecesi olmak üzere;

$\mu_A: A \rightarrow [0,1]$ veya $\mu_A(x) \in [0,1]$ olacaktır. Burada 0 sayısı, ilgili elemanın kümenin üyesi olmadığını, 1 sayısı tam üyesi olduğunu ve bu iki değer arasındaki herhangi bir sayı ise, ilgili elemanın kümeye üyelik derecesini veya kısmi üyeliğini belirtmektedir.

$A = \{(\mu_A(x), x)\}$ yazılabilir. Bu durumda;

$$A = \{(\mu_A(x), x)\} = \{\mu_A(x)/x\}$$

$$A = \{\mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n\}$$

ve bu da;

$$A = \left\{ \sum \mu_A(x_i)/x_i \right\} \quad (x_i \in A \text{ ve } i = 1, 2, \dots, n)$$

olarak gösterilebilir. Bulanık kümenin sürekli olması durumunda gösterim;

$$A = \left\{ \int \mu_A(x_i)/x_i \right\} \quad (x_i \in A \text{ ve } i = 1, 2, \dots, n)$$

olacaktır.

1.4.2. Üyelik Fonksiyonu Tipleri


Çok sayıda üyelik fonksiyonu olmakla birlikte pratikte en fazla kullanılanlar üçgen, yamuk, çan eğrisi, Gaussian ve sigmoidal fonksiyonlardır (Baykal ve Beyan, 2004b: 78). Çalışılan problemin özelliğine göre bunların dışında uygun bir fonksiyon da kullanılabilir.

1.4.2.1. Üçgen Üyelik Fonksiyonu

Bir üçgen üyelik fonksiyonu $a_1, a_2, a_3 \in R$ ve $a_1 < a_2 < a_3$ olmak üzere üç parametre ile tanımlanmaktadır.

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

Şekil 1.1' de üçgen üyelik fonksiyonuna bir örnek gösterilmektedir.




Şekil 1.1: Üçgen Üyelik Fonksiyonlarının Gösterimi

1.4.2.2. Yamuk Üyelik Fonksiyonu

Bir yamuk üyelik fonksiyonu $a_1, a_2, a_3, a_4 \in R$ ve $a_1 < a_2 < a_3 < a_4$ olmak üzere dört parametre ile tanımlanmaktadır. Aslında üçgen üyelik fonksiyonu, yamuk üyelik fonksiyonunun özel bir durumudur.

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

Şekil 1.2' de yamuk üyelik fonksiyonuna bir örnek gösterilmektedir.




Şekil 1.2: Yamuk Üyelik Fonksiyonlarının Gösterimi

1.4.2.3. Gaussian Üyelik Fonksiyonu

Bu tip bir üyelik fonksiyonu m ve σ parametreleri ile tanımlanmaktadır.

$$\mu_A(x; m, \sigma) = e^{\left(\frac{-(x-m)^2}{2\sigma^2}\right)}$$

Burada m , fonksiyon merkezini ve σ da genişliğini ifade etmektedir. σ değeri değiştirilerek fonksiyonun biçimi değiştirilebilir. σ küçük olduğunda üyelik fonksiyonu daha ince olurken, bu değer büyüdükçe üyelik fonksiyonu gittikçe yayvanlaşacaktır. Şekil 1.3' de Gaussian üyelik fonksiyonuna bir örnek gösterilmektedir.




Şekil 1.3: Gaussian Üyelik Fonksiyonlarının Gösterimi

1.4.2.4. Çan Şekilli Üyelik Fonksiyonu

Bu tip üyelik fonksiyonu $a_1, a_2, a_3 \in R$, $a_1 \neq 0$ ve $a_1 < a_2 < a_3$ olmak üzere üç parametre ile tanımlanmaktadır.

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

Şekil 1.4' de çan şekilli üyelik fonksiyonuna bir örnek gösterilmektedir.



Şekil 1.4: Çan Şekilli Üyelik Fonksiyonlarının Gösterimi


1.4.2.5. Sigmoidal Üyelik Fonksiyonu

Bu tip üyelik fonksiyonu $a_1, a_2 \in R$ ve $a_1 < a_2$ olmak üzere iki parametre ile tanımlanmaktadır.

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

Sigmoidal üyelik fonksiyonunda, $a_1 < a_3 < a_2$ olmak üzere bir $a_3 \in R$ değeri de mevcuttur. Bu değer üye olma ile olmama arasında bir büküm noktası olup üyelik değeri 0,5 tir. ($\mu_A(a_3) = 0,5$)

Şekil 1.5' de sigmoidal üyelik fonksiyonuna bir örnek gösterilmektedir.




Şekil 1.5: Sigmoidal Üyelik Fonksiyonlarının Gösterimi

1.4.2.6. S Üyelik Fonksiyonu

Bu üyelik fonksiyonu $a_1, a_2 \in R$ ve $a_1 < a_2$ olmak üzere iki parametre ile tanımlanmaktadır.

$$\mu_A(x; a_1, a_2) = \begin{cases} x \leq a_1 \text{ ise } 0 \\ a_1 \leq x \leq [(a_1 + a_2)/2] \text{ ise } 2[(x - a_1)/(a_2 - a_1)]^2 \\ [(a_1 + a_2)/2] \leq x \leq a_2 \text{ ise } 1 - 2[(x - a_2)/(a_2 - a_1)]^2 \\ x \geq a_2 \text{ ise } 1 \end{cases}$$

Şekil 1.6' da S üyelik fonksiyonuna bir örnek gösterilmektedir.



Şekil 1.6: S Üyelik Fonksiyonlarının Gösterimi

1.4.3. Üyelik Fonksiyonunun Tespiti

Bulanık kümelerin gerek üyelik derecelerinin gerekse bunların tümünü temsil edebilecek üyelik fonksiyonlarının belirlenmesinde kullanılan yöntemlerin başlıcaları; sezgi, çıkarım, mertebelenme, açılı bulanık kümeler, yapay sinir ağları, genetik algoritmalar, çıkarımcı muhakeme gibi değişik yaklaşımlardır (Aytaç, 2006: 61).

1.4.4. Dilsel Değişkenlerin Gösterimi

İnsan düşünce sisteminin ilk aşamaları oldukça bulanıktır. İnsan düşüncesi temelde önce kavramsal şekiller ve zihinsel örüntüler şeklindedir. Ancak bunların olgunlaşması ile sayısal olarak belirginleştirilebilir. Bir diğer ifade ile burada, sözelden sayısala geçiş söz konusudur. Fakat matematiğin diferansiyel ve integral hesapları, kullanımları kesinlik gerektirdiğinden, bu geçişi ifade edemeyebilir. İşte bulanık mantık, bulanık küme kavramları ile bu geçişi mümkün kılar.

Sözel ifadelerin bulanık olarak modellenmesi mümkündür. Bunun için, anlam temsil eden sözel birimler tespit edilir. Sözel kelimelerin sayısal değerini içeren üyelik fonksiyonları belirlenir. Sözel birimlerin başına ön sıfatlar eklenerek anlamları daraltılıp genişletilebilir. Böylelikle sözel kelimenin anlamı değiştirilmiş olur ve üyelik dereceleri de değişir.

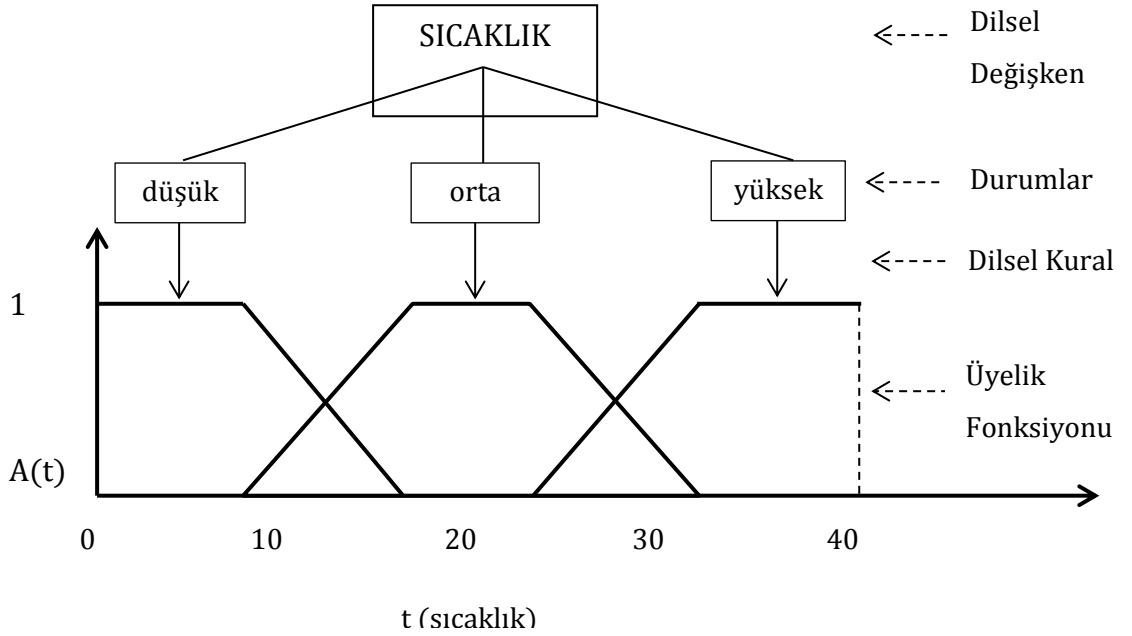
Dilsel deęişkenler, deęerleri sayılar deęil doęal ya da yapay kelime veya cümleler olan deęişkenlerdir. Bu kavram, sayısal deęişkenlerle birlikte kullanılmak üzere geliştirilmiştir. Bir L dilsel deęişkeni beş bileşenden oluşur ve

$$L = (x, A, X, g, m)$$

şeklinde gösterilebilir. Burada x temel deęişken,

$$A = \{A_1, A_2, \dots, A_n\}$$

olup L dilsel durumların kümesi (durum kümesi), X temel deęişkenin tanım kümesi, g dilsel terimler üretmek için kullanılacak dilsel kural ve m ise her bir dilsel terime dilsel kural ile atanan anlamı (X deki bulanık küme) ifade eder (Zadeh, 1975a,b,c). Şekil 1.7’de bir dilsel deęişken olan “Sıcaklık”, “Düşük, Orta ve Yüksek” olmak üzere üç durumda incelenmiştir. Temel deęişken sıcaklık ölçüm birimleri ile verilmiştir (Fernandez ve Herrera, 2012: 106).

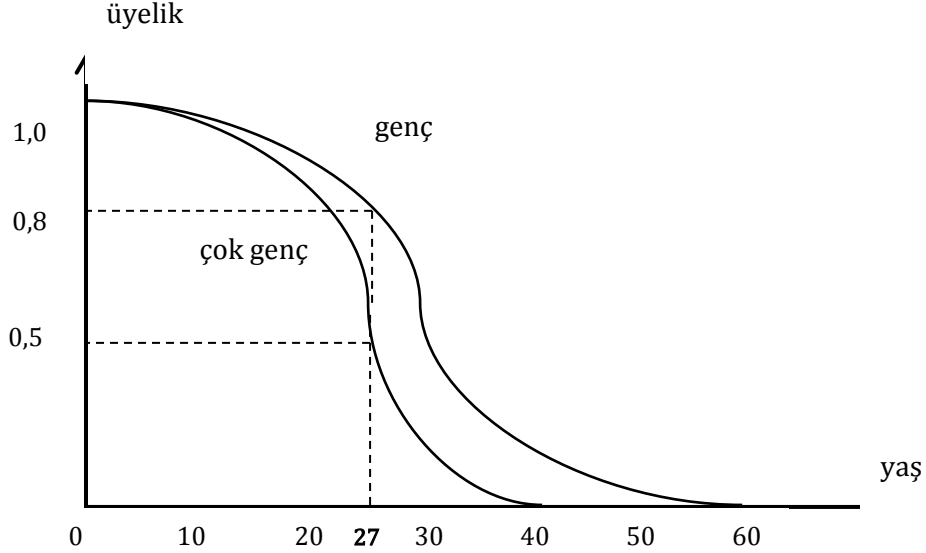


Şekil 1.7: Üç durumlu "sıcaklık" dilsel deęişkeni

Bir diğerk örnek olarak “Ayşe gençtir” ifadesini ele alalım. Burada genç tanımı belirsiz bir kavramdır. Bu belirsizliğı temsil etmek üzere üyelik fonksiyonu olarak gençlik kavramı [0,80] aralığında sürekli bir fonksiyon olarak tanımlansın. Şekil 1.8’ de verilen grafikte, yatay eksen yaşı, düşey eksen üyelik fonksiyonunun sayısal değerini göstermek üzere, ilk eğri “genç” bulanık kümesindeki üyelik fonksiyonu değerini göstermektedir. Bu fonksiyona göre, 10 yaşındaki bir kişi gençtir ve genç olma üyelik değeri 1, 27 yaş için ise 0,8 dir. 60 yaş ve üstü için ise bu değerk 0 olacaktır.

Önerme “Ayşe çok gençtir” olarak değıştirilirse, “çok genç” olma üyelik fonksiyonu grafikte görülebileceğı gibi farklı olacaktır. Burada üst sınır olarak 40 alınmış, ve 27 yaşındaki bir kişinin “çok genç” olma üyelik değeri 0,5 tir.

Öyleyse A=”genç” ve B=”çok genç” kümeleri ise, $\mu_A(27) = 0,8$ ve $\mu_B(27) = 0,5$ olacaktır.



Şekil 1.8: “genç” ve “çok genç” dilsel değışkenleri

1.5. Bulanık Kümelerle İlgili Tanımlar

Klasik kümelerde her elemanın üyelik derecesi 0 veya 1 olmak üzere iki değerk alabilir. Bulanık kümelerde ise kümenin elemanlarının üyelik dereceleri [0,1] kapalı aralığındaki herhangi bir değeri alabilmektedir (Şekil 1.9).

A, E evrensel kümede bir bulanık küme, μ_A A 'nın üyelik fonksiyonu, $\mu_A(x)$ ise $x \in A$ 'nın üyelik derecesi olmak üzere;

$\mu_A: E \rightarrow [0,1]$ ve dolayısıyla $\mu_A: A \rightarrow [0,1]$ veya $\mu_A(x) \in [0,1]$ olacaktır. Bu kümeyi ifade etmek için;

$$A = \{(\mu_A(x), x)\} = \{\mu_A(x)/x\}$$

$$A = \{\mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n\}$$


$$A = \left\{ \sum \mu_A(x_i)/x_i \right\} \quad (x_i \in A \text{ ve } i = 1, 2, \dots, n)$$

olarak gösterilebilir. Burada toplama işlemi küme öğelerinin topluluğunu ifade etmektedir.

Bulanık kümenin sürekli olması durumunda gösterim;

$$A = \left\{ \int \mu_A(x_i)/x_i \right\} \quad (x_i \in A \text{ ve } i = 1, 2, \dots, n)$$

olacaktır. Aynı şekilde burada integral işareti, topluluğu gösteren bir işaret olarak algılanmaktadır.



Şekil 1.9: Reel sayılarda tanımlı klasik ve bulanık kümelerin grafik gösterimi

1.5.1. Eşit Kümeler

E evrensel kümenin A ve B gibi iki bulanık kümesinin üyelik dereceleri aynı ise, bu iki kümeye eşit kümeler denir:

$$\forall x \in E \text{ için } A = B \Leftrightarrow \mu_A(x) = \mu_B(x)$$

1.5.2. Alt Küme

Eğer E evrensel kümesinin her bir elemanının bulanık A kümesindeki üyelik derecesi, bulanık B kümesindeki üyelik derecesinden küçük veya eşitse; A bulanık kümesi, B bulanık kümesinin alt kümesi olmaktadır:

$$\forall x \in E \text{ için } \mu_A(x) \leq \mu_B(x) \Rightarrow A \subseteq B$$

1.5.3. Destek (Support) Kümesi

E evrensel kümesindeki bir A bulanık kümesinin destek kümesi, E 'nin A bulanık kümesinde 0'dan farklı üyelik derecesine sahip olan elemanların hepsini içermektedir. E 'nin bulanık kümelerinin destekleyicileri aşağıda gösterildiği gibi ifade edilmektedir:

$$SuppA = \{x \in E | \mu_A(x) > 0\}$$

1.5.4. Kesme (Cut) Kümesi

$\alpha \in [0,1]$ olmak üzere, bir A bulanık kümesinin α -kesmesi A_α ile gösterilmekte ve E evrensel kümesinin A kümesindeki bütün elemanlarından üyelik derecesi α değerinden küçük olmayanları içermektedir:

$$A_\alpha = \{x \in E | \mu_A(x) \geq \alpha\}$$

Burada \geq yerine $>$ olursa buna kuvvetli(güçlü) α -kesme kümesi adı verilir.

1.5.5. Düzey Kümesi


$\alpha \in [0,1]$ olmak üzere, bir A bulanık kümesinin düzey kümesi A_A ile gösterilir ve α değeri üyelik fonksiyon değerini açıkça gösterir:

$$A_A = \{\alpha | \mu_A(x) = \alpha, \alpha \geq 0, x \in E\}$$

1.5.6. Normallik

Normal bulanık kümede, en azından bir tane üyelik derecesi 1'e eşit olan eleman bulunmalıdır. Aksi halde normal altı (subnormal) diye adlandırılır.


Normal altı bulanık bir kümeyi normal hale dönüştürmek için, üyelik derecelerinin her birinin kümenin en büyük üyelik derecesine bölünmesi gerekir. Şekil 1.10' da normal ve normal altı kümeler gösterilmektedir.



Şekil 1.10: a) Normal Bulanık Küme b) Normal Altı Bulanık Küme

1.5.7. Dışbükeylik (Konvekslik)

Dışbükeylik, üyelik fonksiyonunun sürekli artan, sürekli azalan veya üçgen gibi olması durumudur. Bir kümedeki herhangi iki noktayı birleştiren çizgideki her nokta bu kümenin elemanı ise küme dışbükeydir.



Şekil 1.11: a) Dışbükey Bulanık Küme b) Dışbükey Olmayan Bulanık Küme

Şekil 1.11 (a)'da da görüleceği gibi, aynı bulanık alt kümede x, y ve z gibi üç eleman için $x < y < z$ iken $\mu_A(y) \geq \min(\mu_A(x), \mu_A(z))$ oluyorsa o kümeye dışbükey bulanık küme adı verilmektedir (Şen, 2004: 29).

1.5.8. Bulanık Sayılar

Bulanık sayılar dışbükey, normalleştirilmiş, sınırlı-süreklî üyelik fonksiyonu olan ve gerçel sayılarda tanımlanmış bir bulanık küme olarak ifade edilir. Normal bir bulanık alt küme, üyelik fonksiyonu dışbükey olduğu ve üyelik derecesinin maksimum 1 değerini aldığı ve α -kesim kümesinin bulanık küme dahilinde kapalı bir aralıkta tanımlı olduğu takdirde “bulanık sayı” adını alır (Chen ve Pham, 2001: 42).

Bulanık kümeler, üyelik fonksiyonlarıyla tanımlandığı için bulanık sayılar da kendi üyelik fonksiyonlarıyla tanımlanmaktadır. Bu nedenle üyelik fonksiyonu çeşidi kadar bulanık sayı çeşidi vardır (Baykal ve Beyan, 2004a: 115). Bulanık küme teorisinde kullanılan bulanık sayılar için farklı tipler olmakla birlikte en çok kullanılan tipleri, üçgensel ve yamuk tipli bulanık sayılardır (Lai ve Hwang, 1992: 58). Bu iki bulanık sayı ve üyelik fonksiyonları aşağıda tanımlanmıştır.

Bulanık sayılar tek bir sayıyı değil, bir aralığı belirttikleri için aralıklı değişkenler için en genel yöntem olan aralıklı aritmetik ile hesaplanırlar. Aralıklı aritmetiğin temeli reel sayılar kümesinde içinde verilen iki kapalı aralığın aynen skaler aritmetikteki gibi toplama, çıkarma, çarpma ve bölmesini gösteren aralık aritmetiğine dayanır. Skaler aritmetikteki toplama, çıkarma gibi temel operatörler aralık hesaplaması için genişletilerek uygulanır (Degrauwe, Lombaert ve Roeck, 2010: 248).

1.5.8.1. Üçgensel Bulanık Sayı ve Üyelik Fonksiyonu

Bir üçgen bulanık sayı; $a_1, a_2, a_3 \in R$ için a_1 ve a_3 bulanık küme desteğinin alt ve üst sınır değerleri ve a_2 tam üyelikli tek sayı olmak üzere üç parametre ile tanımlanmaktadır:

$$\mu_A(x; a_1, a_2, a_3) = \begin{cases} a_1 \leq x \leq a_2 & \text{ise } (x - a_1)/(a_2 - a_1) \\ a_2 \leq x \leq a_3 & \text{ise } (a_3 - x)/(a_3 - a_2) \\ x < a_1 \text{ veya } x > a_3 & \text{ise } 0 \end{cases}$$

1.5.8.2. Yamuk Bulanık Sayı ve Üyelik Fonksiyonu

Bir yamuk bulanık sayı; $a_1, a_2, a_3, a_4 \in R$ için a_1 ve a_4 bulanık küme desteğinin alt ve üst sınır değerleri ve a_2 ve a_3 tam üyelikli sayıların kümesinin sınırlarını göstermek üzere dört parametre ile tanımlanmaktadır.

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

Yamuk bulanık sayı en sık kullanılan bulanık sayı çeşididir. Bunun bir sebebi de aslında üçgen bulanık sayıların, yamuk bulanık sayıların özel bir durumu olmasıdır (Baykal ve Beyan, 2004a: 117).

1.6. Bulanık Kümeler Üzerindeki İşlemler

Klasik Küme Teorisinden farklı olarak Bulanık Küme Teorisinde küme işlemleri üyelik fonksiyonu yardımı ile tanımlanır (Zimmermann, 1987: 17).


1.6.1. Birleşim İşlemi

İki tane bulanık alt kümenin birleşimi durumunda her bir kümeye ait öğenin, ait oldukları kümelerdeki üyelik derecelerinin en büyüğü alınmaktadır. Standart birleşim aşağıdaki şekilde hesaplanır:

$$A, B \subset E, \forall x \in E \text{ için } \mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x) = \max[\mu_A(x), \mu_B(x)]$$

Buradaki birleşim, "veya" birleştiricisine karşılık gelmektedir. Bunun dışında, Yager fonksiyonu, olasılıkçı toplam (cebirsal toplam), sınırlandırılmış toplam (Lukasiewicz), güçlü toplam (zorlayıcı), Hamacher toplamı ve Einstein toplamı gibi çeşitli işlemciler tanımlanmıştır (Baykal ve Beyan, 2004a: 110).

Şekil 1.12'de iki bulanık kümenin birleşimi gösterilmektedir.



Şekil 1.12: A ve B Bulanık Küme Birleşimleri


1.6.2. Kesişim İşlemi

İki bulanık alt kümenin standart kesişim işleminde her bir kümeye ait ögenin, ait oldukları kümelerdeki üyelik derecelerinin en küçüğü alınmaktadır.

$$A, B \subset E, \forall x \in E \text{ için } \mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \min[\mu_A(x), \mu_B(x)]$$

Buradaki kesişim "ve" birleştiricisine karşılık gelmektedir. Bunun dışında, Yager fonksiyonu, olasılıkçı çarpım (cebirsal çarpım), sınırlandırılmış çarpım (Lukasiewicz), zayıf çarpım (zorlayıcı), Hamacher çarpım ve Einstein çarpım gibi çeşitli işlemler tanımlanmıştır (Baykal ve Beyan, 2004a: 110).

Şekil 1.13'de iki bulanık kümenin kesişimi gösterilmektedir.



Şekil 1.13: A ve B Bulanık Küme Kesişimleri

1.6.3. Kapsama

A ve B bulanık kümelerinde $A \subset B$ ise bu bulanık kümelerin üyelik fonksiyonları arasında,

$$A \subset B \subset E, \forall x \in E \text{ için } \mu_A(x) < \mu_B(x)$$

ilişkisi ifade edilmektedir (Atin, 1999: 16).

1.6.4. Fark İşlemi

Bulanık kümelerde basit ve sınırlandırılmış olmak üzere iki fark işlemi bulunmaktadır. Bulanık A ve B kümeleri için basit fark işlemi;

$$A, B \subset E, \forall x \in E \text{ için } \mu_{A \cap B}(x) = \min[\mu_A(x), 1 - \mu_B(x)]$$

Sınırlandırılmış fark işlemi ise,

$$A, B \subset E, \forall x \in E \text{ için } \mu_{A \ominus B}(x) = \max[0, \mu_A(x) - \mu_B(x)]$$

olarak elde edilmektedir (Baykal ve Beyan, 2004a: 110).

1.6.5. Tümleme İşlemi

Standart tümleme işleminde bulanık bir kümenin tümleyenini bulmak için bu kümenin öğelerinin üyelik dereceleri 1'den çıkarılmalıdır. Bir A kümesinin tümleyeni \bar{A} ise bu kümenin üyelik değeri şu şekilde tanımlanır (Bojadziev, 1991: 123) :

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

Buradaki tümleyen "değil" bağlacına karşılık gelmektedir. Diğer tümleme işlemleri ise sürekli tümleme fonksiyonu, Yager fonksiyonu ve Sugeno fonksiyonudur (Baykal ve Beyan, 2004a: 109).

1.7. Modelleme ve Bulanık Mantık

Bilimsel yaklaşımda sistem ve model önemli iki kavramdır. Alt sistemlerden oluşan ve çevresi ile etkileşim içerisinde olan, girdi-çıkıtı-süreç ve geri besleme unsurlarından oluşan bütün olarak kabul edilen sistem, dört unsurdan oluşmaktadır: Birden çok bileşenin gerekliliği, bileşenler arası ilişkiler, bileşenlerin oluşturduğu bir bütün ve bütünün bir amacı olmasıdır.

Model ise, açıklama ya da kestirim gibi bir nedenden dolayı gerçekliğin basitleştirilmiş bir şekilde sunumudur. Bir diğer ifade ile sistemler bütünü olarak görülen doğada gerçekleşen olayların belirli bir yönünün çeşitli yöntemlerle ve çeşitli düzeylerde “minyatürleştirilmesi” olarak söylenebilir (Baykal ve Beyan,2004a: 157-168). Fiziksel, biyolojik, ekonomik, sosyal yada psikososyal sistemler, modeller kullanılarak basitleştirilerek gösterilebilirler. Modelin gerçek sisteme benzemesi genel bir zorunluluktur fakat yeterli değildir. Modeller gerçeği tam olarak ifade edemezler, çünkü özünde bu süreç gerçekliğin basitleştirilmesidir. Çok fazla basitleştirmek sistemi anlaşılır kılarken yanlış sonuçlara ulaşılmasına sebep olabilir, çok fazla ayrıntının modellenmesi ise sistemin anlaşılabilirliği amacından uzaklaşılmasına sebep olur.

Özellikle mühendislik ve benzeri disiplinlerde olaylar ve sistemler, kesin matematiksel modeller kullanılarak tanımlanabilirler. Genel anlamda matematiksel modelleme sistemin, temelinde bulunan girdi-çıkıı davranışını karakterize eden matematiksel terimlerle tanımlanmasıdır. Oluşturulan bu modellerin kullanılması ile olayın veya sistemin gelecekte alacağı durum veya göstereceği davranış biçimi tahmin edilmeye çalışılmaktadır. Bu sorunların bir kısmı tamamen belirli olmakta ve kolayca tanımlanabildiğinden çözüm getirilmesi kolay olmaktadır. Bunun yanı sıra, belirsizlikler içeren veya tam olarak tanımlanamayan sorunların çözümü nispeten zor olmakta ve görecelik arz etmektedir (Sarı v.d., 2005: 78). Bu tip problemlerin incelenmesinde ve çözümlenmesinde Bulanık Mantık (Fuzzy Logic) yaklaşımı kullanılabilir (Türkbey, 2003: 64). Bulanık mantığı ve buna karşılık gelen matematiksel çatıyı kullanan sistemlere “bulanık sistemler” adı verilmektedir.

Bulanık bir sistemde bulanık mantık çıkarım ve karar verme süreci ekseninde bir sistem geliştirilmektedir. Bunun için aralık/küme matematiği ve bulanık mantık birlikte kullanılmakta, güven aralığı ve bulanık üyelik fonksiyonları yardımı ile yaklaşık değer ile yapılan ölçümler anlamlı bir şekilde kullanılabilir. Bulanık küme teorisi ile kesin olmayan sınırlara sahip kümeler (Zadeh, 1965: 339-342) ortaya konabilmekte olup bulanık mantığın esasları bu kümelerdir (Zuhang ve Huang, 1994: 1266).

Bulanık sistemde bulanık kümelerin/bulanık mantığın kullanılması birkaç şekilde olabilir. Bunlar (Baykal ve Beyan, 2004a: 190-191);

1. Sistem “eğer-o halde” şeklinde kurallarla tanımlanabilir. Bu şekilde tanımlana sistemlere kural tabanlı bulanık sistemler adı verilir.
2. Sistem parametreleri gerçel sayılar yerine bulanık sayılar kullanılarak parametre değerlerindeki belirsizlik tanımlanabilir.
3. Sistemin girdi, çıktı ve durum değişkenleri insan algısı ile ilişkili nicelikleri ifade ediyor veya sözel bilgiyi taşıyorsa bu değişkenler bulanık küme ile tanımlanabilir.

Bu şekilde kurulan bulanık modeller, kullanım yerleri, kurulmaları sırasındaki bakış açısı ve vurgulanan boyutlarına göre; bulanık çıkarım sistemi, bulanık kural tabanlı sistem, bulanık uzman sistemler, bulanık mantık denetleyicileri olarak tanımlanırlar.

Bulanık mantık, bir sistemin girdi-çıkıtı ilişkilerini açıklamak için insana dayalı dili kullanan tahmini sebep tekniğidir. Başka bir deyişle, insanların kesin olmayan ifadelerle düşünme yeteneğiyle örtüşen mantık sistemidir. Bu bağlamda bulanık mantığın insan düşünüş tarzını taklit etmeye çalıştığı söylenebilmektedir (Özkan, 2003: 132). Bulanık küme teorisi dilimizde ifade edilen belirsiz kavramların anlamlı bir biçimde temsilini sağlar. Klasik küme teorisi, verilen bir alana ait bütün bireyleri incelenen özelliğe göre, kümeye ait olan elemanlar ve ait olmayanlar olmak üzere ele almaktadır. Dilimizde ifade edilen ve üzerinde çalışılan çoğu sınıflandırma kavramı, bu türde bir karakter de değildir. Örneğin; uzun boylu insanlar kümesi, pahalı otomobiller kümesi, yakın sürüş mesafesi, güvenilir kar araçları, birden çok büyük sayıların oluşturduğu küme gibi kavramlar klasik küme teorisinin öngördüğü şekilde incelenemezler. Bir bulanık küme, çalışma yapılan alana ait her bir elemana matematiksel olarak kümedeki üyelik derecesini temsil eden bir değer atayarak tanımlanır. Bu değer, elemanın bulanık küme tarafından ifade edilen kavrama üyelik derecesini ifade eder. Bundan dolayı bireylerin kümeye ait olması farklılaşır. Üyelik dereceleri 0 ile 1 arasındaki gerçel sayılarla temsil edilirler. Tam üye olma ve üye

olmama durumu, bulanık kümede sırasıyla 1 ve 0 değerleriyle karşılanır (Sarı v.d., 2005: 78).

Bulanık modelleme problemlerinde, genellikle bir uzman kişinin bilgi ve deneyimlerinden yararlanılarak, dilsel değişkenler (linguistic variables) doğrultusunda bir model kurulmaktadır. Örneğin yaş değişkeni eğer genç, biraz genç, çok genç, genç değil, yaşlı, çok yaşlı, biraz yaşlı,...vs. gibi günlük yaşantıda sıkça kullanılan kelimeler kullanılarak tanımlanmışsa bir dilsel değişken olur. Yani dilsel değişken, değişken değeri olarak bir dildeki kelimeleri ya da cümleleri alabilen değişkendir (Zadeh, 1975a: 199). Böylece dilsel değişkenler, karmaşık veya net olarak ifade edilemeyen kavramların ve karar proseslerinin, yaklaşık olarak nitelenebilmesini sağlamaktadır (Zadeh, 1975c: 78). İşte bu şekilde dilsel değişkenlerin kullanımına izin vermesi, bulanık mantığı diğer mantık sistemlerinden ayıran önemli bir farklılıktır (Aytaç, 2006: 47).

Bulanık modellemenin avantajları olarak; eksik, kesin olmayan ya da bulanık bilginin işlenebilmesi, problemlere daha esnek değerlendirme imkânı sağlaması ve belirsiz sözel ifadeleri sayısal olarak tanımlayabilmesi özellikleri sayılabilir (Sarı v.d., 2005: 80, Baykal ve Beyan, 2004a: 192-193).

Bulanık mantığın tüm bu avantajlarının yanında bir takım dezavantajları da bulunmaktadır. Bulanık mantıkta kullanılan üyelik fonksiyonları değişkenlerinin belirlenmesinde, kesin sonuç veren bir yöntem ve öğrenme yeteneği yoktur. En uygun yöntem deneme-yanılma yöntemidir, bu da çok uzun zaman alabilmektedir. Uzun testler yapmadan gerçekten ne kadar üyelik fonksiyonu gerektirdiğini önceden kestirmek çok güçtür. Bunun yanında bulanık mantık yaklaşımında üyelik fonksiyonu değişkenleri, sisteme özeldir ve başka sistemlere uyarlanması çok zordur (Elmas, 2003: 40).

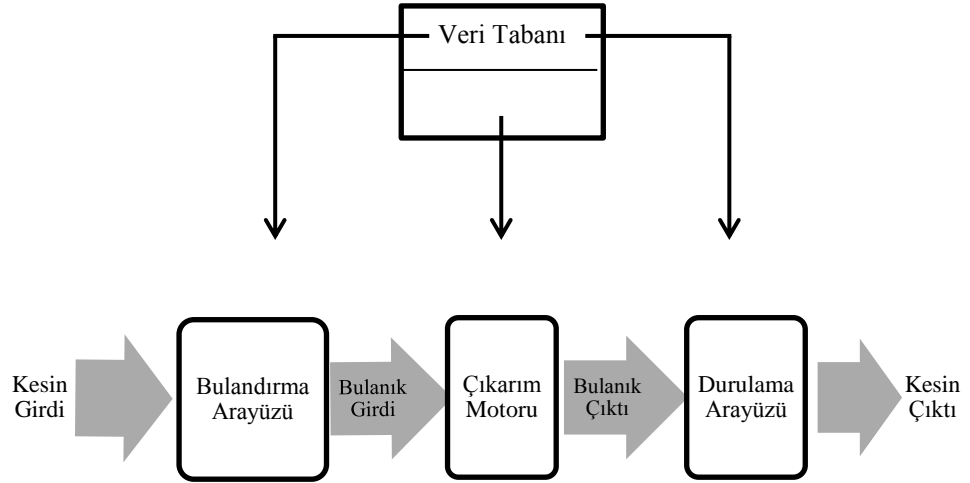
Bulanık mantığa dayanan sistemler genel olarak dört bölümden oluşur: Bulandırma arayüzü, çıkarım motoru (karar verme mantığı), durulama arayüzü ve bilgi tabanı (Şekil 1.14).

Bulandırma arayüzü kesin girdi değerlerini bulanık değerlere çevirir. Bunu yaparken girdi değerine ait girdi değişken aralığının uygun bir kümeye dönüşmesini sağlar ve girdileri sözel değerlere dönüştürür.

Çıkarım motoru (karar verme mantığı), bulanık kavramlara dayalı insan karar verme işlemini taklit eder. Bu akıl yürütme işlemi bulanık çıktıları elde etmek için uygulanır.

Bilgi tabanı, uygulama alanı hedeflerinin bilgisini içerir, kural ve üyelik fonksiyonlarını tanımlar. Bir veri tabanı ve sözel kural tabanından oluşur. Veri tabanı veri işlemede kullanılacak gerekli tanımları içerir, sözel kural tabanı ise kuralları sözel ifadeler yardımıyla tanımlar.

Durulama arayüzü ise bulanık çıktı değerlerini kesin değerlere çevirir (Baykal ve Beyan, 2004a: 195-196).



Şekil 1.14: Bulanık Sistemin Genel Yapısı (Baykal ve Beyan, 2004a: 196)

BÖLÜM 2

YAPAY SİNİR AĞLARI

2.1. Giriş


Yapay zekâ çalışmaları kapsamında ortaya çıkan alanlardan bir tanesi de yapay sinir ağlarıdır. İnsan beyninin temel işlem elemanı ve sinir sisteminin en basit elemanı olan nöron ve bu nöronlar arası bağlantılara şekilsel ve işlevsel olarak benzeyen bir yapay sinir ağı, bu haliyle adeta biyolojik sinir sisteminin basit bir simülasyonudur. Biyolojik sinir sisteminin matematiksel bir modeli olarak da tanımlanabilecek olan yapay sinir ağı, birbirleri ile bağlantılı yapay sinir hücrelerinin oluşturduğu bir sistem ile biyolojik sinir sisteminin bilgiyi depolama, kullanma ve işleme yeteneklerini taklit etmeyi ve insan gibi karar verebilen ve muhakeme yeteneği olan zeki sistemler elde etmeyi amaçlar.

Yapay sinir ağları ile ilgili çalışmaların temelinde, insanda ve bazı canlılarda görülen deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabilme düşüncesi yatmaktadır. Bu anlamda ilk çalışmalar olarak 19. yüzyılın sonları ile 20. yüzyılın başlarında yapılan Hermann von Helmholtz, Ernst Mach ve Ivan Pavlov gibi bilim adamlarının disiplinlerarası çalışmaları kabul edilir. (Marinescu, 2014) Bir yapay sinir hücresini konu alan ilk çalışma ise Warren McCulloch ve Walter Pitts' in, yapay sinir hücresinin biyolojik sinir hücresinin bir modeli olarak aritmetik/mantıksal bir fonksiyon için hesaplama yapabildiğini gösteren (McCulloch ve Pitts, 1943) "A Logical Calculus of Ideas Immanent in Nervous Activity" başlıklı çalışmalarıdır. (Hamzaçebi, 2011: 14) İlk yapay sinir ağı yaklaşımını ise Frank Rosenblatt "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain" başlıklı çalışmasında ortaya atmış (Cura, 2008: 19) ve bu ağı "perceptron" olarak adlandırmıştır. (Rosenblatt, 1958) Bu çalışma ve sonrasında hızlanan çalışmalar Marvin Minsky ve Seymour Papert' in 1969' da yayınladıkları kitapta (Minsky ve Papert, 1969) modelin sınırlarını ispat etmesiyle yavaşlamışsa da 1980' li yıllarda yeni düşünceler ortaya atılması ve güçlü dijital bilgisayarların


kullanılmaya başlanması ile yeniden kullanılmaya başlanmıştır. Özellikle John Hopfield' in "Neural Networks and Physical Systems with Emergent Collective Computational Abilities" başlıklı çalışmasında sinir ağlarının nasıl çalıştığını ve matematik temellerini göstermesi (Hopfield, 1982) ve başta David Rumelhart ile James McClelland' in yayınladıkları "Parallel Distributed Processing: Explorations in the Microstructure of Cognition" adlı kitap (Rumelhart ve McClelland, 1986) olmak üzere birçok çalışma ile çok katmanlı ağları eğitmede kullanılan geri yayılım algoritmasının geliştirilmesi bunda en önemli katkıyı sağlamıştır. 1987 yılında bu alanda ilk uluslararası konferans 1800'den fazla katılımcı ile Elektrik Elektronik Mühendisliği Enstitüsü (IEEE) tarafından düzenlenmiştir. (Hamzaçebi, 2011: 16-17, Elmas, 2011: 27-28) Temel olarak yapay sinir ağları ile; öngörü (tahmin), sınıflandırma, veri birleştirilmesi, veri kavramlaştırılması, veri süzülmesi, resim veya görüntü işleme (Elmas, 2011: 161) alanları başta olmak üzere bir çok uygulama yapılmış ve halen pek çok çalışma yapılmaya devam edilmektedir.

2.2. Biyolojik Sinir Hücresi

İnsan beyninin yapı taşı olan biyolojik sinir hücresi (nöron/düğüm) ve nöronlardan oluşan sinir sisteminin modellenmesi, insan beyninin yeteneklerine sahip ve biyolojik öğrenmeyi temel alan bir sistem kurulması, yapay sinir ağları düşüncesinde yatan temeli oluşturmaktadır. İnsan beyni, nöron olarak adlandırılan yaklaşık 10^{11} hesap elemanından oluşmaktadır. (Şekil 2.1 ve Şekil 2.2)



Şekil 2.1: Biyolojik sinir hücresinin yapısı (Özdemir, 2013)



Şekil 2.2: Sinir Hücreleri

(http://www.mind.ilstu.edu/curriculum/neurons_intro/neurons_intro.php,
20.04.2015)

Biyolojik sinir hücreleri nöronlar, dört temel bölümden oluşur: (Guyton ve Hall, 2006: 556)

- *Hücre gövdesi (Soma)*
- *Girişler (Dentrit)*
- *Çıkışlar (Akson)*
- *Bağlantılar (Sinaps)*

Her bir bölge bilginin alınması ve iletilmesinde farklı roller üstlenmiştir. Soma (hücre gövdesi), hücreyi denetler ve hücrenin tüm faaliyetlerini yönetir. Metabolizma merkezi olarak soma, kendini oluşturan çeşitli bileşenlerin sentezi için gerekli yapıya da sahiptir. Bunun için hücre gövdesinden iki çeşit uzantı çıkmaktadır: Dentritler ve akson.

Dentritler, bilgiyi diğer hücrelerden sinapslar aracılığıyla alan ve hücre girişi olarak görev yapan yapılardır. Hücre gövdesinden dışarı uzanan ağaç dalları biçimindedirler. Diğer nöronlardan bilgiyi iletim hatları olarak kullanılan uzun fiberlerden oluşmuş aksonlar boyunca alır ve hücre gövdesine taşırlar.

Aksonlar, hücre içerisinde bilgi işlendikten sonra gövdedeki bilgiyi diğer nöronların dentritlerine taşıyan yapılardır. Akson yüzeyleri düzdür ve genellikle bir sinir hücresinde bir akson vardır. Aksonlar sinir hücre gövdesinden uzakta dallanırlar. Hücre gövdesinden ayrıldıktan sonra miyelin denenen bir kılıfla yüzeyleri kaplanır. Bu kılıf aksonun seyri boyunca 0,2-2 milimetrede bir kesintiye uğrar. Bu kesinti noktalarına Ranvier düğümü adı verilir. Aksonun son bölümü ağaçsı bir yapıya sahiptir ve bu dalların sonunda küçük ve yuvarlaksı uçlar şeklindeki sinaptik terminaller vardır. Sinaptik terminaller ve diğer nöronların dentritleri arasında sinaps denilen sinaptik aralık/boşluk mevcuttur. Bir nöron diğeri ile doğrudan temas etmez. Akson boyunca iletilen sinirsel ileti sinaptik terminallere ulaştığında nörotransmitter adı verilen kimyasal bir madde salgılanmakta ve bu madde sinaptik boşlukta yayılarak sonraki nöronu uyarmakta, diğer nörondaki dentrit elektriksel sinyal başlatmakta ve böylelikle diğer nöronlar da harekete geçmektedir. (Andersen ve McNeill, 1992: 3,4)

Her sinir hücresi, diğer nöronlarla sinir başına 10^4 sinaps yardımı ile haberleşir. Aksonla dentritlerin bağlantı noktası olan bu sinapslar, nöronun kendi sinyalini diğer nörona tanıttığı ve bilgilerin uzun süre saklandığı bilgi depoları (uzun süreli bellek) olarak düşünülmektedir. Uyarılan sinirlerin alınan sinyallere cevabı destekleyici (excitatory) başka bir ifadeyle sinir hücresinin bir aksiyon potansiyeli oluşturmasını destekleyecek şekilde (uyarıcı) olabileceği gibi yasaklayıcı (inhibitory) yani engelleyici yönde de olabilmektedir. (Nabiyev, 2012: 566,567; Özdemir, 2013: 34) Biyolojik sinir hücresi, sinapslardan aldığı uyarımların uyarıcı olanlarını toplayarak ve engelleyici olanlarını çıkararak sonuçta kalan toplam uyarım miktarına göre hareket eder. Eğer bu değer eşik değerinin üzerinde ise yani uyarıcı olaylar yeterli sayıda olursa, postsinaptik sinir hücresinde yeni bir aksiyon potansiyeli oluşur ve mesaj akson boyunca iletilmiş olur. (Baykal ve Beyan, 2004a: 25) Sinapslarda ileti her zaman tek yönde, presinaptik düğümden postsinaptik hücreye doğru iletilir.

Bir hücrenin aksonu diğer hücrelerle bu sinapslar sayesinde binlerce bağlantı yapabilir (Guyton ve Hall, 2006: 559,560).

Sinir hücresinin tamamı dışarıdan hücre zarı ile sarılıdır ve kimyasal iyonlardan oluşur. Ancak hücre içindeki kimyasal bileşen ile hücreyi dışardan saran sıvının bileşeni içeriğindeki kimyasal iyonların farklılığı nedeniyle aynı değildir. Bu farklılık zarda elektrik potansiyel farkı oluşturur. Nöron tepkisini zarın toplam potansiyeli belli bir seviyeye ulaştığında göstermektedir. Nöron, uyarılması ile onun çıkışında sinyalin oluşmasına kadar geçen sürenin sonunda birikmiş uyarılardan darbe tepkisi yaratır ve ateşleme için gerekli şartlar sağlandığında bunu aksonlara gönderir. (Nabiyev, 2012: 569)


Biyolojik (Fiziksel) Sinirler	Yapay Sinirler
Hücre	Birim
Sinir eklemi (Sinaps)	Ara bağlantılı ağırlıklar
Destekleyici (excitatory) giriş	Pozitif ara bağlantı aralığı
Yasaklayıcı (inhibitory) giriş	Negatif ara bağlantı aralığı
Değişken uyarı girişi	DC uyarı seviyesi
Hücre fiziği ile sınırlı aktifleme aralığı	İşlemci karakteristiğiyle sınırlı aktifleme aralığı

Tablo 2.1: Biyolojik ve yapay sinir sisteminin karşılaştırılması

Bir biyolojik sinir ve onun işleyişini model alan yapay sinirin bu yapı ile benzerlikleri Tablo 2.1' de gösterilmiştir. (Nabiyev, 2012: 570)

2.3. Yapay Sinir Ağının Yapısı

Bir yapay sinir ağının temel yapısında; işlem elemanlarının (nöronlar) oluşturduğu katmanlar, nöronlar arasında bağlantı kuran ağırlık değerleri, bağlantı ağırlıklarının belirlenmesini sağlayan öğrenme algoritmaları ve transfer (aktivasyon) fonksiyonu bulunmaktadır. (Şekil 2.3)



Şekil 2.3: Bir Yapay Sinir Ağının Genel Yapısı (Akbilgiç, 2011)

Bir yapay sinir ağı, veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapar. Bunun için ağ ilgili olayın örnekleri ile eğitilerek genelleme yapılabilecek yeteneğe kavuşturulur ve benzer olaylara karşılık gelen çıktı setleri belirlenir. Ağa girilen bilgilerin kendi ağırlıkları ile çarpımlarının toplanması sonucu elde edilen net girdi bir transfer fonksiyonu ile işlenerek çıktı katmanından ağın ürettiği sonuç olarak alınmaktadır (Öztemel, 2003: 49).

Yapay sinir ağında katmanlar girdi katmanı, çıktı katmanı ve bu ikisinin arasında bulunan gizli katman(lar)dır. Her bir katman nöronlardan oluşmaktadır. Girdi ve çıktı katmanındaki nöron sayısı, bağımsız ve bağımlı değişkenlerinin sayısı ile belirlenmekte iken, gizli katmandaki katman sayısı ve her bir gizli katmanda bulunacak nöron sayıları, en iyi performansı verecek şekilde kullanıcı tarafından belirlenmektedir. (Yüksek v.d., 2007: 102) Girdi katmanı verilerin yapay sinir ağına alınmasını, çıktı katmanı ise ağ içerisinde işlenen bilginin sonucunu verir. Bir yapay sinir ağında gizli katman olması gerekmediği gibi, birden fazla gizli katman da bulunabilir. Girdi katmanı, ağı adlandırırken katman sayısına genellikle dâhil edilmemektedir. Bundan dolayı, girdi katmanı ile birlikte iki katmanlı olan bir yapay sinir ağı tek katmanlı, girdi katmanı ile birlikte üç katmandan oluşan bir yapay sinir ağı iki (çok) katmanlı bir ağ olarak adlandırılır. (Fausett, 1993: 12)

2.4. Yapay Sinir Hücresinin Ögeleri

Biyolojik sinir ağlarındaki sinir hücrelerine karşılık, yapay sinir ağında da yapay sinir hücreleri vardır. Her yapay sinir hücresinin temel elemanları; girdiler, ağırlıklar, toplama (birleştirme) fonksiyonu, transfer (aktivasyon) fonksiyonu ve hücrenin çıktısıdır. Yapay sinir hücreleri katmanlar şeklinde birleşerek yapay sinir ağını oluştururlar.

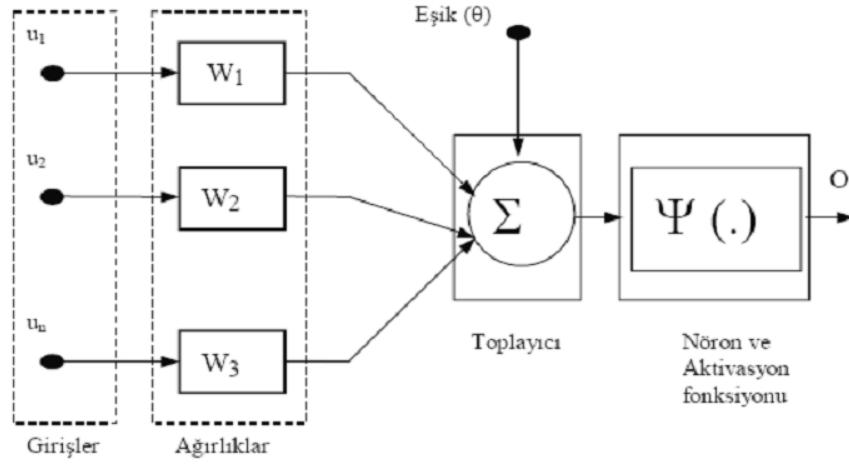
2.4.1. Girdiler

Girdiler (x_i ($i = 1, 2, \dots, n$)) bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendisinden de bilgiler gelebilir.

2.4.2. Ağırlıklar

Ağırlıklar, nöronlar arasındaki bağlantıların kuvvetini gösterir. Gizli katman(lar)daki ve çıktı katmanındaki nöronların girdisi, bu ağırlıklar yardımı ile hesaplanır. Bir nöron, genellikle aynı anda olarak birçok girdi almaktadır. Her x_i ($i = 1, 2, \dots, n$) girdisi gizli katmandaki y_j ($j = 1, 2, \dots, h$) gizli nöronlarına w_{ij} ağırlıkları ile bağlanmaktadır. Gizli katmandaki gizli nöronlar da diğer bir gizli katmandaki nöronlara ya da başka bir gizli katman bulunmuyorsa çıktı katmanındaki z_k ($k = 1, 2, \dots, p$) nöronlarına v_{jk} ağırlıkları ile bağlanmaktadır.

Yapay sinir hücresinde nöronlar aktif aktif olmak için bir eşik değerine (threshold -bias) sahiptir. Bu değer, regresyon analizindeki sabit terim görevini gören bir nöron ile hücreye dahil edilir ve nöronun net girdi toplamına ilave edilen bir başlangıç değeridir. Aktifleşmeyen bir nöronun aktifleştirilmesi için kullanılır, öğrenmeyi kolaylaştırır. Bias, 1 'e eşit olan sabit aktivasyon değerleriyle özel bir işlem elemanıdır. Bir geriye yayma ağında bias girdilerinin amacı, daha iyi öğrenme sağlamak için, giriş seviyelerini belli bir seviyeye kaydırmak ve aktivasyon fonksiyonunun orjinini dengeye getirmektir. Ağa eklenen eşik (bias) elemanı ağıın öğrenme hızını genelde olumlu yönde etkiler. (Yıldız, 2006: 92, <http://www.kirbas.com/index.php?id=164&sec=yapay%20sinir>, 20.04.2015)



Şekil 2.4: Yapay Sinir Hücresi (Çuhadar, 2006: 117; Yıldız, 2006:52)

2.4.3. Toplama (Birleştirme) Fonksiyonu

Hücrenin net girdisini hesaplayan fonksiyondur. Şekil 2.4’ de görüleceği gibi, nöron girdileri sinaptik bağlantılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır. (Çuhadar, 2006: 116) (2.1) ve (2.2) eşitliklerinde ağırlıklı toplamın oluşturulması ve nöron çıkışının hesaplanması verilmektedir.

Çalışmalarda farklı toplama fonksiyonlarının kullanıldığı görülmektedir. (Tablo 2.2) Bazen gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme-yanılma yolu ile toplama fonksiyonu belirlenmektedir. Ayrıca, bir yapay sinir ağında bulunan nöronların tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her nöron bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilir. (Öztemel, 2003: 49)

Toplam $Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.
Çarpım $Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak Net Girdi Hesaplanır.
Maksimum $Net = \text{Max}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü Net girdi olarak kabul edilir.
Minimum $Net = \text{Min}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü Net girdi olarak kabul edilir.
Çoğunluk $Net = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$	n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam $Net = \text{Net}(\text{eski}) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

Tablo 2.2: Bazı Toplama Fonksiyonları

2.4.4. Aktivasyon (Transfer) Fonksiyonu

Aktivasyon (Transfer) fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler (Smith ve Gupta, 2002: 5) :

j. gizli nöron için:

$$net_j^n = \sum_{i=1}^{n+1} w_{ji} \cdot x_i \text{ ve } y_j = f(net_j^n) \quad (2.1)$$

k. çıktı nöronu için:

$$net_k^h = \sum_{j=1}^{h+1} v_{kj} \cdot y_j \text{ ve } z_k = f(net_k^h) \quad (2.2)$$

olarak hesaplanır.

Bir katmandaki nöronların hepsinin aynı aktivasyon fonksiyonunu kullanması gerekmez. Bir problem için en uygun aktivasyon fonksiyonunun bulunması, ağı tasarlayanın denemeleri sonucunda belirleyebileceği bir durumdur. En yaygın olarak

kullanılan transfer fonksiyonları Tablo 2.3' de özetlenmiştir: (Fausett, 1993: 17, Akbilgiç, 2011: 23, Özdemir, 2013: 38)

Aktivasyon Fonksiyonu	Formülasyonu
Identity (Birim/Özdeş)	$f(x) = x$
Treshold (Eşik Değer)	$f(x) = \begin{cases} \alpha, & x \geq \theta \text{ ise} \\ \beta, & x < \theta \text{ ise} \end{cases}$
Piecewise Linear (Parçalı Doğrusal)	$f(x) = \begin{cases} \gamma, & x > \alpha \text{ ise} \\ \left(\frac{\gamma - \delta}{\alpha - \beta}\right)x + \left(\frac{\alpha\delta - \beta\gamma}{\alpha - \beta}\right), & \beta \leq x \leq \alpha \text{ ise} \\ \delta, & x < \beta \text{ ise} \end{cases}$
Logaritmik Sigmoid	$f(x) = \frac{1}{1 + e^{-\theta x}}$
Tanjant Hiperbolik	$f(x) = \frac{2}{1 + e^{-2x}} - 1$
Sekant Hiperbolik	$f(x) = \frac{2}{e^x + e^{-x}}$
Radyal Tabanlı Fonksiyonlar (RBF)	$f(x) = \theta \left(\frac{x - c}{r}\right)$

Tablo 2.3: Bazı Aktivasyon Fonksiyonları

Eşik fonksiyonunda α , β ve θ değerleri yapılan çalışmaya göre, $\theta = 0$ olmak üzere, $\alpha = 1$ ve $\beta = 0$ veya $\alpha = 1$ ve $\beta = -1$ olarak seçilebilir. Bu durumda aktivasyon fonksiyonu,

$$f(x) = \begin{cases} 1, & x \geq 0 \text{ ise} \\ 0, & x < 0 \text{ ise} \end{cases} \quad \text{veya} \quad f(x) = \begin{cases} 1, & x \geq 0 \text{ ise} \\ -1, & x < 0 \text{ ise} \end{cases}$$

olacaktır.


2.4.5. Hücrenin Çıktısı

Bir yapay sinir hücresinin çıktısı, girdiler, ağırlıklar ve aktivasyon fonksiyonu yardımıyla oluşturulur. Üretilen çıktı, dış dünyaya veya başka bir hücreye gönderilir. Hücre, kendi çıktısını kendisine girdi olarak da gönderebilir.

Bir nöronun birden fazla girdisi fakat yalnız bir çıktısı olmaktadır. Ağ şeklinde gösterildiğinde bir hücrenin birden fazla çıktısının görülmesi, aynı değer birden fazla hücreye girdi olarak gitmesinden kaynaklanmaktadır.

2.5. Yapay Sinir Ağında Katmanlar

Genel bir yapay sinir ağı modeli, girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanından (output layer) oluşmaktadır. (Şekil 2.5) Bu katmanların her biri, bilgi işleyişini sağlayacak şekilde farklı görevlere sahip yapay sinir hücreleri (nöronlar) içermektedir.



Şekil 2.5. Bir yapay sinir ağı Yapısı (Smith ve Gupta, 2002: 4)

Şekil 2.5'de, x_i ($i = 1, 2, \dots, n$) girdi katmanındaki işlem elemanlarını, y_j ($j = 1, 2, \dots, h$) gizli katmandaki işlem elemanlarını, z_k ($k = 1, 2, \dots, p$) çıktı katmanındaki işlem elemanlarını göstermektedir. Ayrıca w_{ij} , i . girdi işlem elemanından j . gizli işlem elemanına olan bağlantının ağırlığını ve v_{jk} , j . gizli işlem elemanından k . çıktı işlem elemanına olan bağlantının ağırlığını göstermektedir. (Smith ve Gupta, 2002: 4)

2.5.1. Girdi Katmanı

Bilginin ağı ilk gösterildiği kısım olan girdi katmanı, yapay sinir ağı modelinin dış dünya ile bağlantısını sağlamaktadır. Bu tabakaya giriş verileri normalize edildikten sonra verilir. Girdi katmanında bulunacak nöron sayısı, bağımsız değişken sayısı kadardır. Bazı yapay sinir ağı modellerinde, regresyon analizindeki sabit terim görevini gören ve “yan nöron (bias)” olarak adlandırılan bir nöron daha eklenmektedir. Yan nöronuna girilen bilginin sabit olarak 1 değerini aldığı varsayılmaktadır. Yan değeri veya bağımsız değişken değerleri, girdi katmanı nöronlarında herhangi bir işleme tabi tutulmazlar. (Akbiğiç, 2011: 21)

2.5.2. Gizli Katman

Gizli katman, girdi katmanından kendisine iletilen bilginin işlendiği katmandır. Gizli katman birden fazla alt katmandan oluşabilir. Gizli katmanın kaç alt katmandan oluşacağı ve her bir alt katmanda kaç nöron bulunacağı kullanıcı tarafından belirlenir. Literatürde bu sayılarla ilgili bazı öneriler bulunmakla beraber, genellikle deneme yanılma yolu ile en iyi sonucu veren sayılar bulunur. Gizli katman nöronları bilgiyi, her bir nöronda bulunan aktivasyon (transfer) fonksiyonları aracılığı ile işlerler. Aktivasyon fonksiyonunun seçimi yine kullanıcı tarafından belirlenen ve ağın başarısını önemli ölçüde etkileyen parametrelerden birisidir. Bazı basit yapay sinir ağı modellerinde girdi katmanı direk çıktı katmanına bağlanır. Ancak bu tip ağlar bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan ilişkiyi modelleyememektedir. Buradan hareketle gizli katman, yapay sinir ağına doğrusal olmayan ilişkileri modelleme gücünü kazandıran katmandır. (Akbiğiç, 2011: 21)

2.5.3. Çıktı Katmanı

Biyolojik nöron yapısında aksona karşılık gelen çıktı katmanı, modelde gizli katmandan gelen veriyi işleyerek gereken çıktıyı üretir ve dış dünyaya iletir. (Baykal ve Beyan, 2004a: 28) Gizli katmandan bağlantılar ile kendisine gelen bilgi, genellikle aynen ağın çıktısı olarak dış dünyaya iletilmektedir. Özellikle gizli katman bulunmayan basit yapay sinir ağı modellerinde ise çıktı katmanı nöronları, gelen

bilgiyi bir eşik değeri fonksiyonundan geçirerek dış dünyaya iletirler. Çıktı katmanında bulunacak olan nöron sayısı verideki açıklanan (bağımlı) değişken sayısı kadardır. (Akbiğiç, 2011: 21) Sınıflandırma problemlerinde bu çıktılar 0, 1 gibi değerler olurken tahmin problemlerinde ise sürekli değerler alırlar. (Smith ve Gupta, 2002: 5)

2.6. Yapay Sinir Ağı Çeşitleri

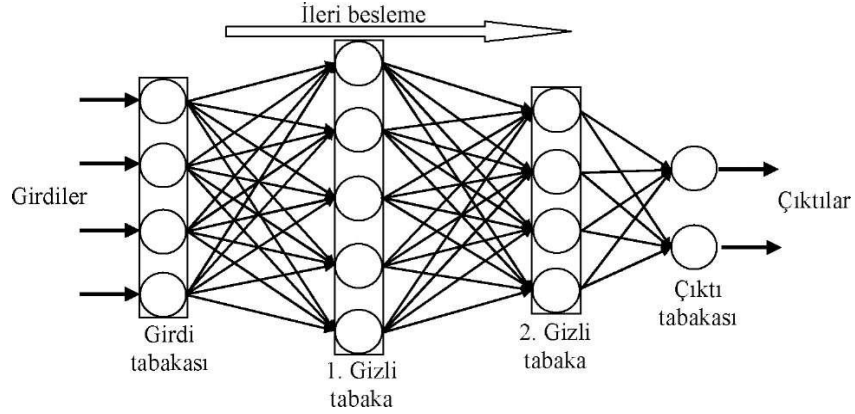
Yapay sinir ağı modelleri bir ağı öğrenmesi gereken giriş-çıkış bilgileri yani kullanılan veriye bağılı olarak; yapay sinir hücreleri arası ilişkilerle ifade edilen mimarilerine yani ağı yapısına, öğrenme biçimine-algoritmalarına ve öğrenme zamanına göre olmak üzere üç ana ölçüte göre farklılık göstermektedir.

2.6.1. Mimarisine Göre Ağ Çeşitleri

Yapay sinir ağlarının yapılarına göre, ileri beslemeli (feed-forward) ve geri beslemeli (feed-back) ağlar olmak üzere iki türü bulunmaktadır. Ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için geri yayılmalı öğrenme kuralının (back-propagation) kullanıldığı ileri beslemeli yapay sinir ağları yaygın kullanıma sahiptir.

2.6.1.1. İleri Beslemeli Ağlar

Giriş katmanından çıkış katmanına doğru sinyallerin tek yönlü bağlantılarla iletildiği ağ mimarisidir. Tüm hücreler bir sonraki katman ile bağlantılı olup aynı katman içerisinde bağlantıları bulunmamaktadır. (Jain ve Mao, 1996: 17) Çok katmanlı ileri beslemeli sinir ağının tipik mimarisi Şekil 2.6' da görülmektedir.




Şekil 2.6: Çok katmanlı ileri beslemeli sinir ağı mimarisi

Statik ağlar olarak da bilinen ileri beslemeli ağda öğrenme aşamasında girdi verileri ağın giriş katmanına sunulur. Bu katmandaki nöronlar çıktılarını hesaplayıp bir sonraki katmana girdi değeri olarak gönderirler. Sırasıyla her bir katman aynı işlemi yaptıktan sonra çıktı katmanında çıktı verileri üretilerek işlem sonuçlanır. (Yegnanarayana, 2005: 88)

2.6.1.2. Geri Beslemeli Ağlar


Geri beslemeli sinir ağı, çıkış ve gizli katman(lar)daki çıkışların, giriş birimlerine veya önceki gizli katman(lar)a geri gönderildiği bir ağ yapısıdır. Böylece, sinyaller hem ileri yönde hem de herhangi bir sinirin çıkışından girişine aktarılabilmektedir. (Yegnanarayana, 2005: 142-143) Çok tabakalı geri beslemeli sinir ağının tipik mimarisi Şekil 2.7’ de gösterilmiştir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. (Jain ve Mao, 1996: 17) Bu özellikleri ile tahmin problemlerinde sıkça kullanılırlar.



Şekil 2.7: Çok katmanlı geri beslemeli sinir ağı mimarisi

2.6.1.3. İleri Beslemeli Geri Yayılımlı Ağlar

İleri beslemeli olan bu tür ağ yapısında, geri yayılma (back propagation) kuralı, ağ içindeki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Aynı katmandaki sinir hücreleri arasında bağlantı mevcut değildir. Katmandaki her bir sinir hücresi bir sonraki katmandaki her bir sinir hücresine ayrı ayrı bağlıdır ve bunların giriş değerini vermektedir. İleri besleme ve geriye yayılım kombinasyonu ağı daha dirençli, daha az karmaşık ve daha hızlı eğitilebilir hale getirmektedir. (Utkun, 2014: 274) Çok tabakalı ileri beslemeli geri yayımlı sinir ağı tipik mimarisi Şekil 2.8’ de görülmektedir.



Şekil 2.8: Çok tabakalı ileri beslemeli geri yayımlı sinir ağı mimarisi

2.6.2. Öğrenme Algoritmalarına Göre Ağ Çeşitleri

Bir insanın düşünme ve gözlemlene yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi, insan beyninin sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir. (Çuhadar, 2006: 119) Örneğin sıcak bir nesneye dokunan çocuk önce deneyerek dokunmaması gerektiğini öğrenir, sonra zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterir ve sıcaklık bilgisini öğrenmiş olur. Yapay sinir hücresi de mevcut örnek kümesi üzerinde girdi ve çıktı arasındaki bağıntıyı ağırlıkların değiştirilmesiyle öğrenirler. (Keleşoğlu v.d., 2005: 60) Biyolojik sinirlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olmaktadır. İnsanlar doğumlarından itibaren bir “yaşayarak öğrenme” süreci içerisine girerler ve bu süreç içinde beyin sürekli bir gelişme gösterir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır, hatta yeni bağlantılar oluşur ve bu sayede öğrenme gerçekleşir. Bu durum yapay sinir ağları için de geçerlidir. (Çuhadar, 2006: 120)

Öğrenme sürecinin iki aşaması vardır. Birinci aşamada ağa gösterilen örnek için ağın üreteceği çıktı belirlenir. Dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınmasına benzer şekilde dış ortamdan girdiler alınır, bu girdilerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesine benzer şekilde yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıktısı üretilir. Bu çıktı dışarıdan verilen çıktıyla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıktıya yaklaşılmaya çalışılır. Bu çıktı değerinin doğruluk derecesine göre ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir ve yapay sinir ağının ağırlıkları her bir döngüde yenilenerek hata minimize edilir. Eğer yapay sinir ağları verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Yapay sinir ağında ağırlıkların sürekli yenilenip istenilen sonuca ulaşılması ve ağın bilinen örneklerden belirli bilgileri çıkartarak bilinmeyen örnekler hakkında genelleme yapabilme özelliğine kavuşması işlemine “ağın öğrenmesi/eğitimi” adı verilir. (Keleşoğlu v.d., 2005: 60, Çuhadar, 2006: 120) Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise, ağın “test edilmesi” denmektedir. Test etmek için ağın

öğrenme sırasında görmediği örneklerden yararlanır. Ağ, eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktıların doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. (Çuhadar, 2006: 120) Eğitimde kullanılan örnek setine “eğitim seti”, test için kullanılan sete ise “test seti” denilmektedir.

Yapay sinir ağındaki herhangi bir ağırlık (w) için öğrenme matematiksel olarak,

$$w_{yeni} = w_{eski} + \Delta w$$


şeklinde ifade edilebilir. Burada Δw , belirli bir kurala göre hesaplanarak o anki ağırlıklara uygulanacak düzeltme miktarını verir. Δw 'yi belirlemek için tanımlanmış kurallara “öğrenme algoritmaları” ya da “öğrenme kuralları” denilmektedir. (Hamzaçebi, 2011: 21)

Yapay sinir ağları için öğrenme yöntemleri temelde danışmanlı (supervised) öğrenme ve danışmansız (unsupervised) öğrenme olarak iki gruba ayrılmıştır. Bu öğrenme yöntemleri ve öğrenme kurallarından bazıları aşağıda kısaca açıklanmaktadır.

2.6.2.1. Danışmanlı (Supervised) Öğrenme/Eğitim

Danışmanlı öğrenme için ağa, verilerin girdi ve hedeflenen çıktı çiftlerinden oluşan eğitim bilgileri verilir. Bu şekilde ağa girilen veriler yapay sinir ağlarının hedeflenen değere karşı üreteceği değerleri öğrenmesini sağlar. Bu eğitim sırasında ağın ağırlık değerleri değiştirilir, hedeflenen çıktı ile ağın üretmiş olduğu çıktı arasındaki hata kabul edilebilir sınırlar içerisinde ise tüm ağırlıklar sabitlenerek eğitim sonlandırılır. (Şekil 2.9) Danışmanlı eğitimde işlem tamamen eğiticinin kontrolü altındadır ve en önemli özeliği, eğitime esnasında gerçek değerlerin kullanılmasıdır. Danışmanlı öğrenme kurallarına; çok katmanlı perceptron (multilayer perceptron), delta öğrenme kuralı (Widrow-Hoff veya en küçük kareler ortalaması (least mean square)- ADALINE), geri yayımlı öğrenme (back-


propagation) ve Boltzmann makinesi örnek olarak verilebilir. (Elmas, 2011: 97-131, Hamzaçebi, 2011: 22)



Şekil 2.9: Danışmanlı Öğrenme

2.6.2.2. Danışmansız (Unsupervised) Öğrenme/Eğitim

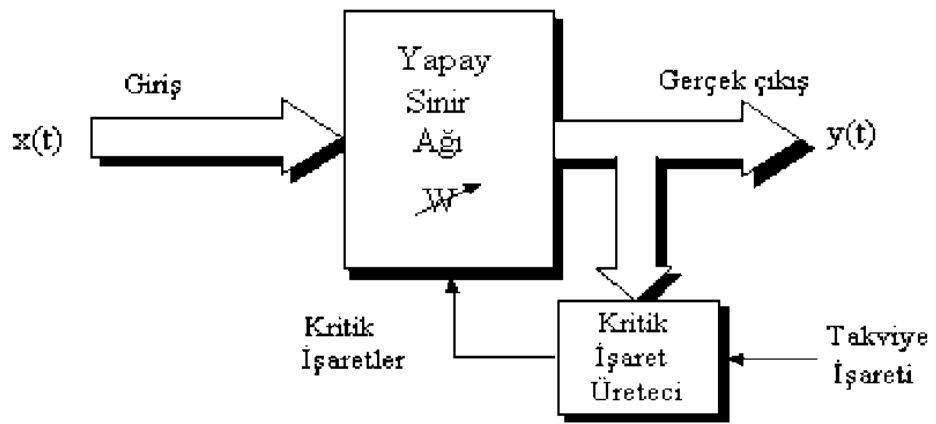
Danışmansız öğrenmede ağın giriş tabakasına çıktı bilgisi olmayan girdi değerleri verilir. Ağ bu bilgileri hedef bir çıktı değeri olmadan girdi bilgilerinin özelliklerine göre işler, ağırlık değerlerini ayarlar ve çıktılar üretir. (Şekil 2.10) Hedef değerlerini gösteren bilgiler ağa girilmediğinden dolayı hata dikkate alınmaz yani ağ yaparak öğrenmektedir. (Elmas, 2011: 137) Danışmansız öğrenme kurallarına; Yarışmacı Öğrenme (Competitive Learning), Kohonen'in Özörgütlemeli Harita Ağları (Self-Organizing Maps), Hebbian Öğrenme, Grossberg Öğrenme gibi öğrenme kuralları (Çuhadar, 2006: 123) ve Adaptif Rezonans Teorisi, Hopfield Ağı, Kohonen Ağı örnek olarak verilebilir. (Hamzaçebi, 2011: 22)



Şekil 2.10: Danışmansız Öğrenme

2.6.2.3. Takviyeli (Reinforcement) Öğrenme/Eğitim

Bir tür danışmanlı öğrenme yöntemi kullanan bu ağlarda, hedef çıktıyı vermek için bir danışman yerine burada yapay sinir ağına bir çıkış verilmemekte, elde edilen çıkışın verilen girişe karşılık iyi yada kötü olarak değerlendirilen bir kriter kullanılmaktadır. (Şekil 2.11) Optimizasyon problemlerini çözmek için Hilton ve Sejnowski tarafından geliştirilen “Boltzman Kuralı”, takviyeli öğrenmeye örnek olarak verilebilir. (Çuhadar, 2006: 123)



Şekil 2.11: Takviyeli Öğrenme

2.6.3. Öğrenme Zamanına Göre Ağ Çeşitleri

Yapay sinir ağları öğrenme zamanına göre de statik ve dinamik öğrenme olarak ikiye ayrılır (Khalil, 2012).

2.6.3.1. Statik Öğrenme:

Statik öğrenme kuralıyla çalışan yapay sinir ağları kullanmadan önce eğitilmektedir. Eğitim tamamlandıktan sonra ağ istenilen şekilde kullanılır. Ancak bu kullanım sırasında ağın üzerindeki ağırlıklarda herhangi bir değişiklik olmaz.

2.6.3.2. Dinamik Öğrenme:

Yapay sinir ağlarının çalıştığı süre boyunca öğrenmesini öngörerek tasarlanmıştır. Yapay sinir eğitim aşaması bittikten sonra da daha sonraki kullanımlarında çıkışların onaylanmasına göre ağırlıklarını değiştirerek çalışmaya devam eder.

BÖLÜM 3

HİBRİD SİSTEMLER

Yapay sinir ağı ve bulanık mantık tekniklerinin her ikisi de temel olarak insan beyninin çalışma mantığına dayanmaktadır; bulanık mantık insan beyninin sonuç çıkarma mekanizmasını taklit ederken, yapay sinir ağları beynin fiziksel yapısı temel alınarak oluşturulmuştur. (Zhang v.d., 2004) Her iki teknik de kontrol edilecek sistemin matematik modeline ihtiyaç duymazlar, bu sayede karmaşık ve doğrusal olmayan sistemler ile doğrusal sistemleri modelleyebilirler. (Nauck ve Kruse, 1994)

Bulanık mantığın çıkış noktası klasik küme kuramına getirilen eleştiriler olmuştur. Klasik küme kuramında bir eleman için tam üyelik söz konusu olup bir eleman herhangi bir kümeye ya aittir ya da değildir. Bulanık mantıkta ise üyelik fonksiyonları aracılığıyla bir eleman birden fazla kümeye belirli oranlarda üye olabilmektedir. Başka bir deyişle, bulanık kümeler, bir elemanın bir kümeye kısmi üyeliğine olanak sağlar. Bulanık mantık, girdileri çıktılara, bir bulanık kümeyi bir başkasına dönüştüren “A ise B’ dir” şeklindeki kurallara dayanmaktadır. (Kosko ve Isaka, 1993)

Bulanık mantık kontrolü, sağduyuya dayalı kurallar kullanarak sistemleri tanımlar ve kontrol eder. Bu kurallar, “X İSE Y” – X giriş, Y çıkış – formunda kurallardır. Bulanık mantıkta matematik değişkenler yerine insanın karar verme mekanizmasını taklit edecek şekilde kelimelerle ifade edilen değişkenler kullanılır. Geleneksel mantıkta bir değişkenin gerçeklik değeri ya ‘1’ ya da ‘0’ olabilir. Ancak bulanık mantıkta bu değer 0 ile 1 aralığı içindeki tüm değerleri alabilir. Bu değerlere üyelik değeri adı verilir. Bir girdinin hangi üyelik değerini alacağını belirleyen eğriler, üyelik fonksiyonları olarak adlandırılır. Kullanılan matematiğin basit olması, doğrusal olmayan sistemleri modelleyebilme yeteneği, günlük dile dayalı olması, esnek olması (kesin sınırlardan oluşmaması), ve kesin olmayan bilgiye karşı toleranslı olması bulanık mantığa dayalı sistemlerin kullanımının getirdiği en önemli avantajları arasındadır.

Yapay sinir ağıları ise beynin fizyolojik yapısı temel alınarak tasarlanan sistemler olup birbirleriyle paralel çalışan çok sayıda basit işlemciden oluşurlar. Bir sinir ağının davranış biçimini büyük oranda nöronlar arasındaki bağlantılar belirler; öğrenilen tüm bilgi bu bağlantılarda saklıdır. Yapay sinir ağıları belirli bir işlevi yerine getirmek için eğitilebilirler ve bu eğitim bağlantıların değerlerini değiştirmekle sağlanır. Yapay sinir ağılarını geleneksel sistemlerden ayıran en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışma özellikleridir. Bu özellikler yapay sinir ağılarına hız, hataya karşı tolerans ve verimlilik gibi avantajlar kazandırmaktadır (Durmuş, 2005: 48,49).

Sinir ağlarının iki önemli özelliği bulunmaktadır. Bunların ilki, nümerik verilerden doğrusal olmayan haritalama yapabilme özelliği, ikincisi ise, paralel çalışma özelliğidir. Tüm bunların yanı sıra, sinir ağlarının; çok katmanlı ağ yapısında, sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması gibi dezavantajları da bulunmaktadır (Bernard, 1992).

Bulanık bir sistem, sistem bilgisini açıklamak için insan düşüncesine benzer şekilde sözel ifadeler kullanır. Bu sayede, sistem ve insan arasındaki kapalı bir etkileşimi mümkün kılar ki bulanık mantığın önemli avantajlarından biri budur (Tortum ve Çodur, 2007). Bulanık mantığın en önemli eksiği ise öğrenme yeteneği olmamasıdır.

Yapay sinir ağıları ile bulanık mantığa öğrenme yeteneği kazandırılabilir. Sinir ağıları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın sözel terimleri ve eğer-o halde kuralları ile ortadan kaldırılarak anlaşır çıktılar elde edilebilir. Hibrid sistemlerin amacı her iki yaklaşımın da faydalarını toplayıp, bir araya getirmektir.

Genel olarak bulanık mantık ile yapay sinir ağlarının birleşmesi üç şekilde olmaktadır:

1. *Bulanık Sinir Ağları,*
2. *Sinirsel Bulanık Sistemler*

3. Bulanık-Sinirsel Hibrid Sistemler

Bulanık sinir ağı ile bulanık bilgi işleme yeteneğine sahip bir yapay sinir ağı ifade edilmek istenirken; sinirsel bulanık sistemler ile de bulanık çıkarım sistemleri sinir ağı yetenekleri ile zenginleştirilmektedir. (Baykal ve Beyan, 2004a: 426) Sinirsel bulanık sistemlerde esneklik, hız ve uyarlanabilirlik gibi özelliklerin sinir ağları ile bulanık sisteme eklenme durumu söz konusudur. (Jang, 1993) Bulanık-sinirsel hibrid sistemlerde ise sistem performansını geliştirmek için bulanık sistemler ile sinir ağlarının beraberce kullanılması sözkonusudur.

Başka bir sınıflamaya göre genel olarak sinir ağları ve bulanık mantık denetimi iki grupta toplanabilir:

1. *Ortak çalışan sistemler:* Sistemlerin her biri birbirinden bağımsız ve bileşkesi de bir bulanık sistemin bazı parametrelerinin yapay sinir ağı şeklinde belirlenmesi biçiminde olan sistemlerdir.

2. *Tamamen hibrid sistemler:* Burada bir yapay sinir ağı bulanık sistemin çalıştırılması söz konusudur. Bu yapı birbirinden ayrı iki homojen kısma ayrılmamaktadır. (Baykal ve Beyan, 2004a: 425-427)

3.1. Bulanık Sinir Ağları


Bulanık sinir ağlarında bulanık mantık ile klasik sinir ağlarının bilgi sunum yetenekleri zenginleştirilmektedir. Bulanık-sinir ağlarında ağın eğitim sürecinin bulanıklaştırılması, sinir ağı çıktılarının bulanık küme ile ifade edilmesi ve sinir hücrelerinin standart çarpım ve toplam işlemleri yerine bulanık küme teorisinde kullanılan birleşim, kesişim gibi çeşitli işlemlerin kullanılması adımları mevcuttur. (Şekil 3.1) Genel olarak bulanık sinir ağlarında sinirsel ağlarla bulanık kavramların dört farklı şekilde sentezi yapılabilmektedir (Baykal ve Beyan, 2004a: 427-437):

1. *Bulanıklığı sinir ağı çatısına sokmak:* Girdi verisini bulandırma, öğretim örneklerine bulanık etiketler atama, öğretim işlemlerini olabildiğince bulandırma ve sinir ağı çıktılarını bulanık küme terimleri ile sunma gibi.

2. *Sinir hücrelerinin temel özelliklerini değiştirme:* Sinir hücrelerinin standart çarpım ve toplam işlemcileri yerine bulanık küme teorisinde kullanılan çeşitli işlemcilerle (bulanık birleşim, kesişim ve bileşke) tasarlanması.

3. *Bir ağın kararsızlığı yada hatası olarak bulanıklık ölçümünün kullanımı:* Bir bulanık kümenin bulanıklık yada belirsizliğinin ölçümünün sinir ağına dayalı sistemlerde enerji fonksiyonu, hata yada kararsızlığın modellenmesi için kullanılması.

4. *Her bir sinir hücresini bulanık yapmak:* Sinir hücrelerinin girdi ve çıktıları bulanık kümedir ve bulanık sinir hücreleri içeren ağların aktivitesi de bulanık bir işlem olacaktır.



Şekil 3.1. Bulanık sinir ağı modeli (Baykal ve Beyan, 2004a: 428)

Basit bir sinir hücresinde tüm sinyal ve ağırlıklar gerçel sayılardır. $i=1,2,\dots,n$ olmak üzere, x_i sinyali w_i ağırlığı ile;

$$p_i = w_i x_i ,$$

olur. p_i girdi bilgisi girdi oluşturmak için toplandığında;

$$(\text{net}) = p_1 + p_2 + \dots + p_n = w_1 x_1 + w_2 x_2 + \dots + w_n x_n$$

elde edilir. Sinir çıktıyı hesaplamak için f aktivasyon fonksiyonunu kullanır:

$$y = f(\text{net}) = f(w_1 x_1 + w_2 x_2 + \dots + w_n x_n)$$


Bu sinir hücresinde kesin sinyal ve ağırlıklar ve kesin aktivasyon fonksiyonu (sigmoidal fonksiyonu gibi) yerine girdiler, ağırlıklar ve toplam girdinin hesaplanmasında t-norm, t-conorm yada diğer sürekli işlemci ve fonksiyonlar

kullanılırsa bir hibrid sinir ağı elde edilmiş olur. Bu hibrid sinir ağının tüm girdi, çıktı ve ağırlıkları $[0, 1]$ aralığından gerçel sayı olarak alınabilir. Bir hibrid sinir ağının işleme birimine *bulanık sinir hücresi* denir. Bulanık sinir hücresine “*Ve*” (EB-EK), “*Veya*” (EB-EK), “*Veya*” (EB-Çarpım), İçerme-“*Veya*”, Kwan ve Cai'nin *Bulanık Hücresi* olarak yaklaşımlar mevcuttur (Baykal ve Beyan, 2004a: 428-432).

3.1.1. Bulanık Sinir Ağı Tipleri

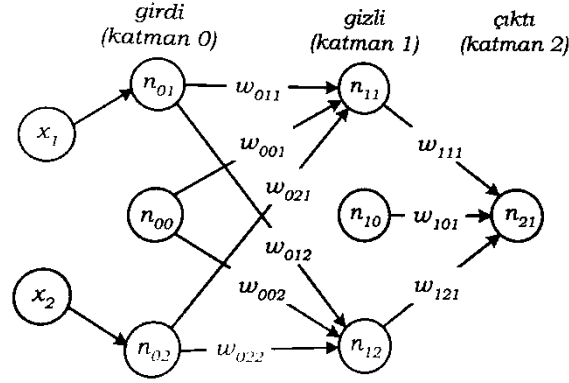
Bulanık sinir ağları (BSA) girdilerin gerçel sayı, ağırlıkların bulanık olduğu (BSA₁), girdilerin bulanık, ağırlıkların gerçel sayı olduğu (BSA₂) ve girdilerin ve ağırlıkların bulanık olduğu (BSA₃) tiplere ayrılmaktadır (Baykal ve Beyan, 2004a: 434).

1. *Yamakawa'nın Tip-1 Bulanık Sinir Ağı*: BSA₁'e örnek olarak Yamakawa tarafında geliştirilen yapı örnek gösterilebilir. (Yamakawa ve Teodorescu, 1996) Burada her x_i girdisi için sinir hücresi tek bir ağırlık yerine ağırlıklar dizisine (w_{ij} , $j=1,2,\dots,m$) sahiptir. Bunların da her biri üçgen bulanık sayı (μ_{ij}) ile ilişkilidir. Yamakawa'nın incelemelerinde, öğrenme, deneysel kural kullanılarak, ağırlıkların güncellenmesi ile sağlanmaktadır. (Şekil 3.2)




Şekil 3.2. Yamakawa'nın Bulanık Ağırlıklı Yapısı

2. *İleri Beslemeli Bulanık Sinir Ağı*: BSA₂ tüm girdi ve çıktıları bulanık sayılar olarak düşünen Ishibuchi ve arkadaşları tarafından bulunmuştur. (Ishibuchi v.d., 1995) Buradaki işlem, genel olarak, minimize edilecek hatanın hesaplanması için, bulanık girdi ve hedef sayı çiftini j-inci öğretim durumu olarak görmesi ve aralık aritmetiği kullanmasıdır. (Şekil 3.3)



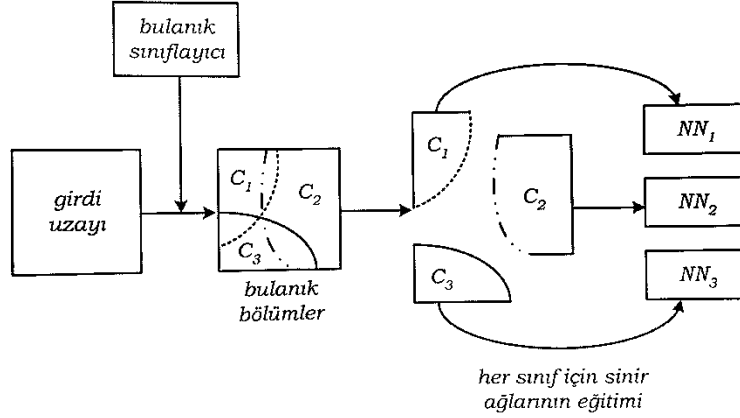
Şekil 3.3. Ishibuchi ve arkadaşlarının Tip-2 Bulanık Sinir Ağı

3. *Tip-3 Bulanık Sinir Ağı:* Önceki bulanık sinir ağında olduğu gibi, j-inci öğretim durumu bulanık sayı çiftidir. Standart bulanık aritmetik sinir hücresi girdisinin hesaplanmasında kullanılabilir ve genişleme ilkesi aktivasyon fonksiyonuna uygulanabilir. Bulanık çıkarma işlemi içeren hata hesabı için, hata sıfır civarında kabul edilebilir bir aralığa düştüğü zaman, durma kuralı ile iterasyonlar durdurulabilir. (Şekil 3.4)



Şekil 3.4. Basit Tip-3 Bulanık Sinir Ağı

Tüm bu yöntemler, bulanık sistem veya sinir ağı tasarlarken bulanık kural yapısı kullanılır. Bu model bir çeşit böl ve yönet yaklaşımıdır. Eldeki tüm girdi ve çıktı verisi için sinir ağının öğretimini sağlamak üzere ağlar kurulabilir. Farklı sınıflara verilen girdi-çıkı kümelerinin bulanık sınıflayıcıları oluşturulabilir, her sınıf için sinir ağı kurulabilir ya da uygun sınıfta girdi-çıkı verisi ile sinir ağı öğretimi yapılabilir. (Şekil 3.5)



Şekil 3.5. Bulanık Sistemler Kullanarak Sinir Ağları Kurma

3.2. Sinirsel Bulanık Ağ Modeli

Yapay zekâ tekniklerinden her birinin kendine özgü yetenekleri bulunmaktadır. Yapay sinir ağları insanın sinir sistemini taklit ederek bilgisayar öğrenmesini gerçekleştirir. Bulanık mantık ise insanın düşünüş tarzına çok yakındır. Aynı zamanda sözel değişkenleri de kullanabilmektedir. Yalnız bu tekniklerinin kendine özgü dezavantajları da bulunmaktadır. Bulanık tasarımlı sistemlerin en önemli dezavantajı bu sistemlerin öğrenme yeteneğinin olmamasıdır. Yapay zekâ teknolojilerindeki ilerlemelere paralel olarak bu tekniklerin birlikte kullanımı ile bu yöntemlerin dezavantajları ortadan kaldırılmaya çalışılmıştır (Yıldız ve Akkoç, 2009).

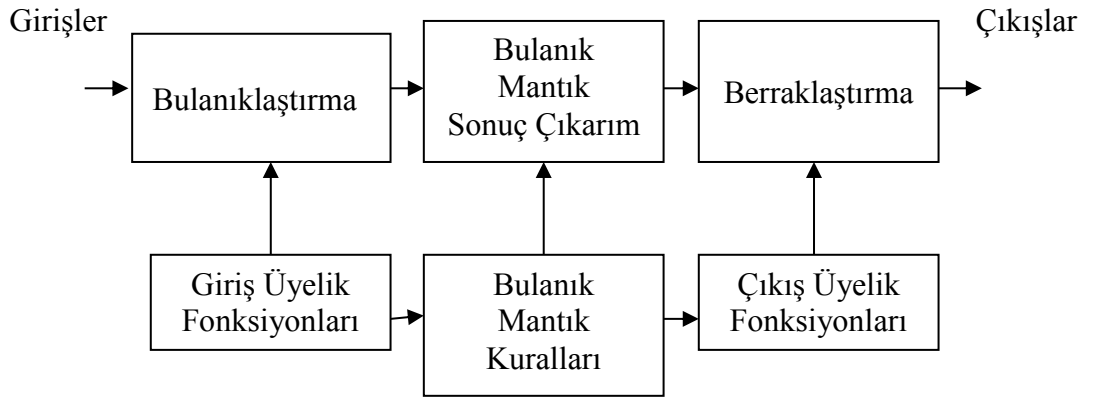
Sinirsel bulanık ağ, yapay sinir ağları ve bulanık sistemlerin sentezlenmesinden meydana gelen yapay zeka tekniklerinden birisidir. Bulanık mantığın belirsiz bilgileri işleme yeteneğinden ve yapay sinir ağının öğrenme yeteneğinden yararlanabilmek için bu iki teknoloji değişik yöntemlerle birleştirilmektedir (Jacek, 2003). Burada kastedilen, bulanık mantık biçimselliği ile sinir ağı tasarlamadır. Bulanık mantık ve karar vermeyi uygulamak ve bulanık kümeleri sunan üyelik fonksiyonu gerçekleştirmek için sinir ağları tasarlanacaktır (Baykal ve Beyan, 2004a: 426). Sinirsel bulanık ağların eğitimi ve özelliklerinin anlaşılması kolaydır. Sinirsel bulanık ağlar sözel değişkenleri kullanarak öğrenebilirler. Bu durum sinirsel bulanık ağların diğer doğrusal olmayan yapay zekâ

teknolojileriyle (yapay sinir ağı gibi) kıyaslandığında en önemli avantajıdır (Abonyi, 2002: 92).

Sıradan sinir ağlarında, düğümler aynı işlevselliğe sahiptir ve komşu katmanlardaki düğümler birbirine tamamen bağlıdır. Fakat sinirsel bulanık sistemlerde düğümler farklı işlevselliklere sahip olup, komşu katmanlardaki düğümler tamamen birbirlerine bağlı değildir. Bu farklılıklar genellikle bulanık sistemdeki özel bir bölümle uyumludur. Yani, bazı düğümler girdi değişkenlerinin sözel terimlerini ifade eder, bazı düğümler çıktı değişkenleri içindir ve bazı düğümler ve bağlantılar bulanık kuralları temsil etmek için kullanılır (Baykal ve Beyan, 2004a: 439).

3.2.1. Sinirsel Bulanık Ağ Yapısı

Bilindiği gibi bulanık küme tabanlı sistemler genel olarak; bulanıklaştırma, bulanık kural tabanı ve çıkarım ünitesi ve berraklaştırma birimlerinden oluşur.



Şekil 3.6. Bulanık küme tabanlı bir sistemin genel yapısı

Bulanıklaştırma birimi, giriş bilgilerini önceden belirlenmiş üyelik fonksiyonlarını kullanarak uygun sözel değerlerden oluşan bulanık ifadelere dönüştürür. Kural tabanı, uzman kişinin kontrol yöntemini “Eğer-İse” (If-Then) kuralları şeklinde ifade eden, bulanık kurallar kümesinden oluşur. Çıkarım ünitesi, bulanıklaştırıcı çıkışını kural tabanındaki bulanık kurallar ile eşleştirir ve bulanık uygulamayı gerçekleştirecek uygun bir yorumlama yaptıktan sonra bulanık bir

kontrol davranışına karar verir. Berraklaştırıcı, kontrol edilen sisteme uygulayabilmek için sayısal kontrol işaretine çevirir. Bulanık mantık kontrolörünün tasarımındaki en önemli sorun, bulanık mantık kuralları ve uygun üyelik fonksiyonlarının tanımlanmasıdır. (Lin ve Lee, 1994)

Yapay sinir ağı giriş ve çıkış eğitim çiftleri verilen bir statik fonksiyonu öğrenebilmektedir. Öğrenme işlemi, ağ içerisindeki ağırlıkların belirlenmesiyle gerçekleşmekte ve verilen fonksiyona optimal yaklaşım sağlanmaktadır. İşte sinirsel bulanık sistemlerde yapay sinir ağı, bulanık sistemin parametrelerini belirlemek için kullanılmaktadır. Öğrenme aşamasından sonra bulanık sistem yapay sinir ağına ihtiyaç duymadan çalışmaktadır. Sistem eğitim yaparken yapay sinir ağını, karar verme işleminde de bulanık mantığı kullanmaktadır. Bulanık sinir ağı, dört katmandan oluşmaktadır: Bulanıklaştırma katmanı, iki saklı katman, fonksiyon katmanı ve berraklaştırma katmanı (Memmedova, 2012).

Bulanıklaştırma katmanının girişleri, bulanık çalışma bölgelerini tanımlamak için kullanılan sistem değişkenleridir. Bu katmanda üç tip işlem birimi aktivasyon fonksiyonu kullanılmaktadır. Bunlar; sigmoid, gauss ve ters sigmoid fonksiyonlarıdır.

Kural katmanı bulanık çıkarım gerçekleştirmektedir. Bu katmandaki işlem birimleri sigmoid fonksiyonu kullanılmaktadır. Kural katmanının ilk katmanındaki işlem birimleri girişlerinin her biri bir bulanık kümeyle karşılık gelmektedir. Son katmandaki her bir işlem biriminin çıkışı ise çalışma bölgelerinin üyelik fonksiyonları olmaktadır.

Fonksiyon katmanındaki işlem birimleri, bulanık çalışma bölgeleri için azaltılmış dereceli modelleri gerçekleştirmektedir. Her bir işlem birimi bir çalışma bölgesine karşılık gelmektedir. İşlem birimlerinin çıkışları, ağırlıklandırılmış sistem değişkenlerinin toplamıdır. Fonksiyon katmanındaki ağırlıklar, çalışma bölgelerindeki doğrusal modellerin parametreleridir.

Berraklaştırma işlem biriminin girişi, çalışma bölgeleri ve bu bölgelere ait üyelik fonksiyonlarıdır. Berraklaştırma katmanı, ağırlık yöntemi ile berraklaştırma işlemini gerçekleştirmekte ve ağ çıkışını oluşturmaktadır.

Sinirsel bulanık mantık modelinin özellikleri şu şekilde özetlenebilir (Jang v.d., 1997:7-9) :

- Sinirsel bulanık modelleme, eğer ise bulanık kurallarını kullanarak insan tecrübesinin problem alanına uygulanmasını sağlar.
- Doğrusal olmayan sistem modellemede ve sınıflandırma problemlerinde, biyolojik sinir hücresinden esinlenerek oluşturulan yapay sinir ağlarının geniş bir şekilde uygulanmasına imkân tanır.
- Bu sistemler esnek yapıları sayesinde karmaşık problemlerin çözümünde kullanılabilir.
- Yapay sinir ağları ve bulanık çıkarım sistemleri, sadece örnek verilerin sisteme girilmesi ile model kurma yeteneğine sahiptir.
- Sistemde meydana gelebilecek olan hata durumlarında, sistem tamamen etkisiz hale gelmez, bu sistemler hata toleransına sahiptir.

Sinirsel bulanık ağlar verilerin sisteme girilmesi ve üyelik fonksiyonlarının tanımlanması ile en iyi öğrenmeyi gerçekleştirebilmek için uygun parametreleri kendisi atar. Öğrenme sürecinde bulanık kurallar kullanılır. Eğer x çok küçük ise y grup 1'e aittir şeklinde kurallar üyelik fonksiyonları göz önünde bulundurularak oluşturulur. Sinirsel bulanık ağ üyelik fonksiyonlarına göre oluşturulmuş kuralları kullanarak eğitim faaliyetini gerçekleştirir. Sorun alanına uygun çözümün geliştirilmesinde kuralların oluşturulması ve parametrelerin atanması sistem tarafından gerçekleştirildiği için belki de sinirsel bulanık ağlar, yapay sinir ağlarına oranla daha hızlı öğrenme gerçekleştirebilirler. Sinirsel bulanık ağ modelini yapay sinir ağ modelinden ayıran ve bu çalışma açısından sinirsel bulanık ağ modelinin en önemli özelliği, elde edilen modelin “Eğer...ise...” gibi kurallar şeklinde ortaya konabilecek olmasıdır (Yıldız ve Akkoç, 2009).

Sıradan sinir ađlarına sinirsel bulanık sistemlerin bir üstünlüğü de öğrenmeden önce uzman bilginin kolayca eklenebilmesidir. Sinirsel bulanık sistemlere başlangıçta bilgi yerleştirilir. Bu nedenle, lokal en küçüğe yakınsama, sıradan sinir ađlarındaki kadar ciddi olmayabilir.

Modern bulanık sistemler genel olarak ileri beslemeli ve çok katmanlıdır. Son yıllarda ANFIS, FALCON, FuNe, RuleNet, GARIC, NEFCLASS, NEFCON, NEFPROX adlı sinirsel bulanık sistemler ortaya konulmuştur. ANFIS modeli Sugeno benzeri bulanık sistem içerir ve geri yayımlı algoritma kullanır. GARIC, NEFCON, NEFCLASS ve NEFPROX modelleri de Mamdani tip bulanık sistemleri kullanmaktadır (Baykal ve Beyan, 2004a: 439).

BÖLÜM 4

BULANIK ZAMAN SERİLERİ

4.1. Zaman Serileri

Zamana bağlı bir olayın, gözlem ya da deney sonucunda aldığı değerlerden oluşan veri topluluğuna zaman serisi adı verilir. Zaman serileri (time series-TS), bir değişkenin farklı zamanlarda gözlenen değerler grubunu ifade etmektedir. Her değeri belirli bir zaman farkı ile arka arkaya gelen nümerik verilerden oluşmaktadır. Bu veriler; hisse senedi fiyatları gibi günlük, merkez bankasının yayınladığı para arzı gibi haftalık, işsizlik oranı veya tüketici fiyat indeksleri gibi aylık, gayri safi milli hasıla gibi üç aylık, devlet bütçeleri gibi yıllık dönemlerle gösterilebilmektedir.

Zaman içinde sürekli olarak kaydedilebilen verilere sahip serilere sürekli, yalnızca belirli aralıklarla elde edilebilen verilere sahip serilere kesikli zaman serileri denir. Elektrik sinyalleri, ses titreşimleri gibi mühendislik alanlarına ait veriler sürekli, faiz oranı, satış hacmi, enflasyon oranı gibi iktisadi veriler de kesikli zaman serileri için örnek olarak verilebilir (Kadılar, 2005: 3).

Eğer bir zaman serisinin gelecek değerleri yalnızca geçmişte aldığı değerlerden üretilebiliyorsa bu seri *deterministiktir*. Fakat çoğu zaman serisinde gelecek değerler kısmen geçmişteki değerlerden etkilenirler yani *stokastik* veya *olasılıksal/rassal* olurlar. Bir X değişkeninin belirli bir t anında almış olduğu değer x_t ile gösterildiğinde, T zaman indislerinin kümesi olmak üzere, x_t ' lerin oluşturduğu $\{x_t, t \in T\}$ kümesi bir olasılıksal süreçtir (Chatfield, 2000: 24).

Zaman serileri analizi, tahmini yapılacak değişkenin geçmişteki durumunun çeşitli yöntemlerle incelenmesi ve elde edilen bilgilerden yararlanarak gelecekteki değerlerin tahmin edilmesine veya modellenmesine dayanmaktadır. Burada amaç iki noktada özetlenebilir: (1) *Tek değişkenli* zaman serileri analizlerinde tek bir seriye ait gözlemlerin dinamik veya zamana bağlı yapısının anlaşılması, (2) *çok değişkenli* zaman serileri analizlerinde ise iki ya da daha çok seri arasında önceleştirme, geciktirme ve geri besleme ilişkilerinin ortaya çıkarılması (Sevüktekin ve Çınar,

2014: 48). O halde tek deęişkenli zaman serisi modelleri, kendi gemiş deęerleri ve hatalarına (kalıntılarına) göre kurulan modeller olup, genel olarak aőađıdaki biçimde ifade edilebilirler (Sevüktekin ve ınar, 2014: 148):

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, \varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots)$$

Burada, $Y_t, Y_{t-1}, Y_{t-2}, \dots$ zaman serisi ve zaman serisinin gemiş deęerlerini, $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots$ ise zaman serisinin hatalarını ve hatalarının gemiş deęerlerini göstermektedir. Buradaki fonksiyonel form, hangi zaman serisi modelinin uygun olduęuna, zaman serisi gözlemlerinin arasındaki veya gözlemlerin hatalar ile ya da gözlemlerin hem kendi arasındaki hem de hatalar ile olan ilişkileri incelenerek karar verilmesi gerektięini ifade etmektedir. (Koak, 2011: 47) Tek deęişkenli zaman serilerinin incelenmesinde kullanılan yöntemler Őu Őekilde sıralanabilir (Gujarati, 2011; Sevüktekin ve ınar, 2014, Orhunbilge, 1999):

1. Zaman Serilerinin Bileşenlerine Ayrılması Yöntemi
2. Üstel Düzgünleştirme Yöntemleri
3. Ototregressif (AR) Modeller
4. Hareketli Ortalama (MA) Yöntemleri
5. Bileşik Ototregressif Hareketli Ortalama (ARMA) Yöntemleri
6. Bileşik Ototregressif Bütünleşik Hareketli Ortalama (ARIMA) Yöntemleri (Box-Jenkins Yöntemi)

Birok zaman serisi, kendi gemiş deęerleri ve/veya rassal Őokların yanında, dięer serilerin deęişimlerine de baęlıdır. ok deęişkenli zaman serileri analizleri, birden ok zaman serisini bir arada ele alarak bir denklem yerine denklem sistemi ile modeller kurmaya veya tahmin yapmaya alışır (Sevüktekin ve ınar, 2014: 495). ok deęişkenli zaman serilerinin incelenmesinde kullanılan yöntemler ise Őu Őekilde sıralanabilir (Gujarati, 2011; Sevüktekin ve ınar, 2014, Orhunbilge, 1999):

1. Koentegrasyon (Eőbütünleşme) Analizi
2. Vektör Ototregresif (VAR) Modeli
3. Panel Veri (Karma Veri) Analizi

4.2. Bulanık Zaman Serileri

Nümerik değerler yerine bulanık kümelerden oluşan zaman serilerine bulanık zaman serileri (fuzzy time series-FTS) adı verilmektedir. Zadeh (1965) tarafından önerilen bulanık küme teorisi ve bulanık mantık, özellikle dilsel verilerle ifade edilen bilgilerdeki belirsizlik ve muğlaklığı ele almak için genel bir yöntem sağlar. Gözlemleri belirsizlik içeren veya bir zaman birimi içinde birden fazla değere sahip olan borsa, sıcaklık, okullara kayıtlı öğrenci sayısı, hava kirliliği gibi verilerin çözümlenmesinde bulanık zaman serileri yöntemleri tercih edilebilir (Eğrioğlu v.d., 2010b).

Zaman serisi yöntemleri, gelecekteki değerleri tahmin etmek için zamanla ölçülen geçmiş verilerin sıralı dizisindeki ilişkileri ortaya çıkarmaya çalışır. Geleneksel tahmin yöntemleri regresyon analizi, hareketli ortalamalar, otoregresif hareketli ortalamalar gibi istatistiksel araçlarla yürütülür. Ayrıca ARIMA ve ekonometrik modeller içeren kantitatif teknikler bu amaçla sıklıkla kullanılmakla birlikte, bu teknikler uygulama geçerliliğini kısıtlayan büyük örneklem hacmi (en az 50 örneklem verisi), normal dağılım ve kararlı veri trendlerine ihtiyaç duyarlar (Sofyalıoğlu ve Öztürk, 2013).

Klasik zaman serisi kestirim modellerinin çözümlenmesinde doğrusallık, durağanlık, tersinirlik ve gözlem sayısı gibi birçok kısıt bulunmaktadır. Bunun nedeni, zaman serisinin sadece bir olasılıksal süreç olarak ele alınmasından kaynaklanmakta, ilgilenilen olayın kendisinden kaynaklanan belirsizlik dikkate alınmamaktadır. (Koçak, 2011: 54) Bu yöntemlerin temel kısıtlarından biri de uygulamaların dilsel terimlere dayanan verilerle gerçekleştirilememesidir (Wang ve Hsu, 2008: 2732). Bulanık zaman serisi yaklaşımları ise, ilgilenilen olayın kendisindeki belirsizliği ortaya çıkaran yaklaşımları içerdiğinden, gözlemleri belirsizlik içeren gerçek hayat zaman serilerinin çözümlenmesinde daha gerçekçi yöntemlerdir. Bulanık zaman serisi yöntemleri, klasik zaman serisi yöntemlerinde gerekli olan kısıtları gerektirmediğinden doğrusal olmayan, durağan olmayan ve az sayıda gözleme sahip zaman serilerine de uygulanabilmektedir (Koçak, 2011: 54).

Bulanık zaman serisi kavramı, Zadeh (1965, 1973, 1975)' in bulanık mantık tanımına dayanarak, ilk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya atılmıştır. Song ve Chissom (1993a, 1993b, 1994) bulanık zaman serilerini zamanla değişen (time-variant) ve zamanla değişmeyen (time-invariant) olarak ikiye ayırmaktadır. Zamanla değişen bulanık zaman serilerinde, zaman serisinin gözlemleri arasındaki ilişkinin zaman içinde değiştiği, zamanla değişmez bulanık zaman serilerinde ise ilişkinin zamana göre değişmediği varsayılmaktadır. Çalışmaların büyük çoğunluğu zamanla değişmeyen (time-invariant) bulanık zaman serileri üzerine yapılan analizlerdir. Ayrıca Song ve Chissom (1993a, 1993b, 1994) bulanık zaman serilerini birinci derece ve yüksek dereceli olarak iki kısma ayırmaktadır:

$F(t)$ bulanık zaman serisi yalnızca bir gecikmeli $F(t - 1)$ bulanık zaman serisinden etkilenmekte ise, bu seri *birinci dereceden* bulanık zaman serisi olarak adlandırılır.

Eğer $F(t)$ bulanık zaman serisi, gecikmeli $F(t - 1), F(t - 2), \dots, F(t - n)$ bulanık zaman serilerinden etkilenmekte ise, $F(t)$ bulanık zaman serisine *yüksek dereceli (n . dereceden)* bulanık zaman serisi denir. Yüksek dereceli bulanık zaman serisi yaklaşımını ilk olarak Chen (2002) uygulamıştır.

Öte yandan, bir bulanık zaman serisi kendisiyle birlikte ikinci bir bulanık zaman serisinin gecikmeli değerleri ile de açıklanabiliyor ise bu tür modellere *iki değişkenli (iki faktör)* bulanık zaman serisi modelleri adı verilmektedir. Bu modellerle ilgili olarak Lee v.d. (2006), Yu ve Huarng (2008), Wang ve Chen (2009) ve Eğrioğlu v.d. (2009a) önemli çalışmalar yapmışlardır.

Eğer bir bulanık zaman serisi kendisiyle birlikte m adet bulanık zaman serisinin gecikmeli değerleri ile de açıklanabiliyor ise bu tür modellere de *m değişkenli ($m - faktör$)* bulanık zaman serisi (MFTS) modelleri denilmektedir. Jilani ve Burney (2008) ve Eğrioğlu v.d. (2009b)' nin yaptığı çalışmalar bu tür modellerin analizi ile ilgili yapılan çalışmalara örnek gösterilebilir.

4.2.1. Bulanık Zaman Serileri ile ilgili Kavram ve Tanımlar

Bulanık zaman serisi yaklaşımları bazı temel kavram ve tanımlara bağlıdır. Bu tanım ve kavramlar aşağıda özetlenmiştir.

Tanım 1. $U = \{u_1, u_2, \dots, u_b\}$ evrensel küme ve evrensel kümenin belirlenen bir sabit aralık uzunluğuna göre parçalanması ile elde edilen u_i ler alt aralıklar olmak üzere bulanık kümeler,

$$A_i = f_{A_i}(u_1)/u_1 + f_{A_i}(u_2)/u_2 + \dots + f_{A_i}(u_b)/u_b$$

şeklinde tanımlanır. Burada f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonunu gösterir ve

$$f_{A_i}: U \rightarrow [0,1]$$

olacaktır (Song ve Chissom, 1993a, 1993b, 1994).

Bunun yanında $f_{A_i}(u_a)$ ise u_k alt aralığının A_i bulanık kümesine ait olmasının üyelik derecesidir ve $1 \leq a \leq b$ olmak üzere $f_{A_i}(u_a) \in [0,1]$ olacaktır.

Tanım 2. $Y(t)$, ($t = \dots, -1, 0, 1, \dots$) reel değerli zaman serisi olsun. Zaman serisine uygun evrensel küme tanımı ve alt aralıkların tespit edilmesinden sonra bunlara bağlı olarak elde edilen A_i bulanık kümelerinden oluşan yeni zaman serisi, $F(t)$ bulanık zaman serisi olarak adlandırılır.

$F(t)$ bulanık zaman serisi hakkında şunlar söylenebilir:

- i. $F(t)$ zamanın bir fonksiyonudur.
- ii. $F(t)$ bulanık kümeler tarafından temsil edilen dilsel değerlere sahip, dilsel değişkenler olarak ifade edilebilir (Song ve Chissom, 1993a, 1993b, 1994).

Tanım 3. “ * ” herhangi bir operatörü göstermek üzere, eğer $F(t)$ bulanık zaman serisi yalnızca bir gecikmeli $F(t - 1)$ bulanık zaman serisinden etkilenmekte ise, $F(t)$ ile $F(t - 1)$ bulanık zaman serisi arasındaki bulanık ilişki,

$$F(t) = F(t - 1) * R(t, t - 1)$$

şeklinde ifade edilir ve *birinci dereceden* bulanık zaman serisi öngörü modeli olarak adlandırılır.

Bu bulanık ilişki Song ve Chissom (1993a) tarafından aşağıdaki gibi tanımlanmıştır:

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

Sonuç olarak $F(t - 1) = A_i$ ve $F(t) = A_j$ olduğunda;

$$A_i \rightarrow A_j$$

olacaktır, ki burada A_i bulanık ilişkinin sol yanı, A_j ise bulanık ilişkinin sağ yanı olarak adlandırılır (Song ve Chissom, 1993a).

Tanım 4. $F(t)$ bulanık zaman serisi mevsimsellik içerdiğinde, birinci dereceden bulanık zaman serisi öngörü modeli,

$$F(t - m) \rightarrow F(t)$$

şeklindedir. Burada m , periyodu ifade eder (Eğrioğlu v.d., 2010b).

Tanım 5. Eğer $F(t)$ bulanık zaman serisi, gecikmeli $F(t - 1), F(t - 2), \dots, F(t - n)$ bulanık zaman serilerinden etkilenmekte ise, $F(t)$ bulanık zaman serisi ile $F(t - 1), F(t - 2), \dots, F(t - n)$ bulanık zaman serileri arasındaki bulanık ilişki,

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

ifadesi ile verilebilir ve *n. dereceden* bulanık zaman serisi öngörü modeli olarak adlandırılır (Chen, 2002).

Tanım 6. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olsun. $F_1(t)$ bulanık zaman serisi, gecikmeli $F_1(t - 1), F_2(t - 1)$ bulanık zaman serilerinden etkilenmekte ise, $F_1(t)$ bulanık zaman serisi ile $F_1(t - 1), F_2(t - 1)$ bulanık zaman serileri arasındaki bulanık ilişki,

$$F_1(t - 1), F_2(t - 1) \rightarrow F_1(t)$$

ifadesi ile verilebilir ve *birinci dereceden iki deęişkenli (iki faktör)* bulanık zaman serisi öngörü modeli olarak adlandırılır. Burada $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak anılmaktadır (Yu ve Huarng, 2008).

Tanım 7. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olmak üzere, $F_1(t)$, gecikmeli $F_1(t-1), F_1(t-2), \dots, F_1(t-n)$ ve $F_2(t-1), F_2(t-2), \dots, F_2(t-n)$ bulanık zaman serilerinden etkilenmekte ise *n. dereceden iki deęişkenli (iki faktör)* bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{c} (F_1(t-n), F_2(t-n)), \\ \vdots \\ (F_1(t-1), F_2(t-1)) \end{array} \right\} \rightarrow F_1(t)$$

ifadesi ile verilebilir. Burada da yine $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır (Lee v.d., 2006, Wang ve Chen, 2009).

Tanım 8. $F_1(t)$ ve $F_2(t)$ iki bulanık zaman serisi iken, $F_1(t)$ bulanık zaman serisi, $F_1(t-m_1), F_1(t-m_2), \dots, F_1(t-m_k), F_2(t-n_1), F_2(t-n_2), \dots, F_2(t-n_l)$ bulanık zaman serilerinden etkilenmekte ise *(k, l)inci dereceden, kısmi yüksek dereceli, iki deęişkenli (iki faktör)*, bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{c} F_1(t-m_1), F_1(t-m_2), \dots, F_1(t-m_k) \\ F_2(t-n_1), F_2(t-n_2), \dots, F_2(t-n_l) \end{array} \right\} \rightarrow F_1(t)$$

ifadesi ile verilebilir. Burada, m_i ($i = 1, 2, \dots, k$) ve n_j ($j = 1, 2, \dots, l$) tamsayılar ve $1 \leq m_1 < m_2 < \dots < m_k$, $1 \leq n_1 < n_2 < \dots < n_l$ şeklindedir ve aynı zamanda $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır (Eğriođlu v.d., 2009a).

Tanım 9. $F_1(t), F_2(t), \dots, F_m(t)$, *m – adet* bulanık zaman serisi iken, $F_1(t)$ bulanık zaman serisi $F_1(t-1), F_2(t-1), \dots, F_m(t-1), F_1(t-2), F_2(t-2), \dots, F_m(t-2), \dots, F_1(t-n), F_2(t-n), \dots, F_m(t-n)$ gecikmeli bulanık zaman serilerinden etkilenmekte ise *n. dereceden m – deęişkenli (m – faktör)* bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} (F_1(t-n), F_2(t-n), \dots, F_m(t-n)), \\ \vdots \\ (F_1(t-1), F_2(t-1), \dots, F_m(t-1)) \end{array} \right\} \rightarrow F_1(t)$$

şeklinde ifade edilir. Burada, $F_1(t)$ ana faktör, $F_2(t), F_3(t), \dots, F_m(t)$ ise ikincil faktör olarak adlandırılır (Jilani ve Burney, 2008, Eğrioglu v.d., 2009b).

4.2.2. Yapılan Çalışmalar

Bulanık zaman serisi analizi yöntemleri genel olarak, gözlemlerin bulanıklaştırılması (fuzzification), bulanık ilişkilerin belirlenmesi (establishing fuzzy relations) ve durulaştırma (defuzzification) olmak üzere üç aşamadan oluşmaktadır. Yapılan çalışmalar, tahminlerin doğruluğunu iyileştirmek ve hesaplama yükünü azaltmak amacıyla, bu temel aşamalarda farklı yöntemler geliştirme üzerine yoğunlaşmaktadır.

Birinci derece bulanık zaman serisi modelleri üzerine yaptıkları çalışmaları ile Huarng (2001a), Huarng ve Yu (2004), Yu (2005a), yüksek dereceli bulanık zaman serileri üzerine ise Chen (2002) başta olmak üzere pek çok araştırmacı bulanık zaman serisi yöntemlerinde bulanıklaştırma aşamasını geliştirmek için yöntemler önermişlerdir. Bu aşamada uygun aralık genişliklerinin belirlenmesi, bulanık zaman serilerinde tahmin sonuçlarını önemli biçimde etkileyen bir faktördür. Çünkü farklı aralık genişlikleri tahmin sonuçlarını etkilemekte olup, aralık genişliği çok büyük olduğunda bulanık zaman serisinde dalgalanmalar kaybolmakta, aralık genişliği çok küçük olduğunda ise bulanık zaman serisinin kullanılmasının bir anlamı kalmamaktadır. Song ve Chissom (1993a, 1993b, 1994) ve Chen (1996, 2002) yaptıkları çalışmalarda aralık uzunluğunu sezgisel olarak belirlemişlerdir. Song ve Chissom (1993a)' un evrensel kümenin eşit aralıklara bölünecek şekilde parçalanması yaklaşımı birçok çalışmada yaygın olarak kullanılmıştır. Uygun aralık genişliğinin belirlenmesi amacıyla Huarng (2001a) ortalama ve dağılıma dayalı iki farklı yöntem önermiş, evrensel kümenin eşit aralıklara bölünmesinde kullanılan aralık uzunluğunun seçiminin kritik bir karar olduğunu, kestirim performansını direk etkilediğini göstermiştir. Yu (2005a), aralık genişliklerinin tahminleme sürecinin ilk adımı yerine bulanık ilişkiler formülasyonu boyunca düzeltilmediği bir model

önermiştir. Huarng ve Yu (2004), bulanık zaman serilerinin tahmininde aralık uzunluğunun belirlenmesi için dinamik bir yaklaşım uygulamış, böylece daha uygun bulanık ilişkiler yakalayan bir model önermişlerdir. Yine Huarng ve Yu (2006b), trend içeren birinci dereceden bulanık zaman serilerinin çözümlenmesinde sabit bir aralık uzunluğu belirlemek yerine, üstel olarak değişken aralık uzunluğuna sahip karmaşık birçok hesaplamayla belirledikleri orana dayalı bir yaklaşım önermişlerdir. Li ve Cheng (2007) ise aralık genişliğinin pozitif keyfi sayılara göre belirlenmesine alternatif olarak kesin olarak belirlenebildiği bir yöntem önermişlerdir. Yolcu v.d. (2009), Huarng ve Yu (2006b) yaklaşımını iyileştiren, optimizasyona dayalı bir yaklaşım önermektedirler. Eğrioğlu v.d. ise (2010a, 2011) birinci dereceden ve yüksek dereceden bulanık zaman serileri için, aralık uzunluğunun optimize edilmesine dayanan yaklaşımlar önermişlerdir. Aralık uzunluğunun optimize edilmesinde kullanılan bir başka yaklaşım ise yapay zeka optimizasyon yöntemleri olmuştur. Örneğin parçacık sürü optimizasyonunu Kuo v.d. (2009, 2010), Davari, Zarandi ve Turksen (2009), Park v.d. (2010) ve Hsu v.d. (2010), genetik algoritma yöntemini ise Chen ve Chung (2006), Lee v.d. (2007, 2008) ve Baş (2011) bu amaçla çalışmalarında kullanmışlardır. Chen ve Chung (2006), Lee v.d. (2007) ve Baş (2011) tespit edilen sabit bir aralık uzunluğu ile belirlenen alt aralıkların yerine, evrensel küme parçalanmasında farklı aralık uzunluklarının elde edilebildiği genetik algoritmaya dayalı yaklaşımlar önermektedirler. Chen, Wang ve Pan (2009) öğrenci kayıtları tahmini yaptıkları çalışmalarında, aralık uzunluklarının belirlenmesinde sayısal verileri aralıkların içine kümelemek için bir otomatik kümeleme algoritması önermektedirler. Wang ve Chen (2009) ise otomatik kümeleme tekniğini ve iki faktörlü yüksek dereceli bulanık zaman serisi modelini sıcaklık ve TAIEX tahmini için kullanmışlardır. Chen ve Kao (2013) çalışmalarında TAIEX tahmini için bulanık zaman serisi, parçacık sürü optimizasyonu ve destek vektör makinelerine dayalı bir yöntem sunmaktadırlar. Çalışmalarında parçacık sürüsü optimizasyonu tekniklerini optimal aralık uzunluklarını elde etmek için, destek vektör makinesi ise eğitim veri setini sınıflandırmak için kullanılmaktadır. Eğrioğlu v.d. (2011b) Gustafson-Kessel bulanık kümelemeye, Chen ve Tanuwijaya (2011), Bang ve Lee (2011) bulanık olmayan hiyerarşik kümeleme algoritmasına dayalı yöntemler önermişlerdir. Cheng, Cheng ve Wang (2008), Li, Cheng ve Lin (2008), Yolcu v.d. (2013), Özdemir (2013)

ve Eğriođlu v.d. (2013) ise, bulanıklařtırma ařamasında evrensel kme parçalanmasına ihtiyaç duymayan, bulanık C-ortalamalar yntemini kullanan yntemler nermiřlerdir. Cheng, Cheng ve Wang (2008) bulanıklařtırma iřlemine bulanık kmeleme ile yapmaktadırlar.

Bulanık iliřkinin belirlenmesi iin ise Song ve Chissom (1993a, 1993b, 1994) matris hesaplama iřlemlerine dayanan bir yntem nermiřler ve bulanık iliřkileri karmařık matris iřlemleriyle belirlemiřlerdir. Chen (1996) bulanık iliřki tablolarını kullanan, daha kolay ve etkin bir yntem geliřtirmiř ve basitleřtirilmiř aritmetik iřlemler kullanarak Alabama niversitesinin kayıt verileri iin etkin bir tahmin yntemi geliřtirerek tahmin dođruluđunu iyileřtirmiřtir. Bu yntem halen pek ok alıřmada tercih edilmektedir. Daha sonra bulanık iliřki tablolarını yksek dereceli bulanık zaman serisi modellerinde de kullanarak yeni bir yaklařım ortaya koymuřtur (Chen, 2002). Fakat Chen (1996, 2002)' nin alıřmalarında nerilen yntemler, bulanık mantık grup iliřki tablolarının elde edilmesini zorunlu kıldıđından olduka fazla iřlem gerektirmektedir. Alternatif olarak Huarng ve Yu (2006a) basit bir ileri beslemeli yapay sinir ađı kullanılarak bulanık iliřkilerin belirlendiđi bir birinci dereceden bulanık zaman serisi yaklařımı nermiřlerdir. Aladađ v.d. (2009) ve Eğriođlu v.d. (2009a, 2009b, 2009c), Yu ve Huarng (2008, 2010), Aladađ v.d. (2010a) ve Alpaslan v.d. (2012) ise bulanık iliřkilerin belirlenmesinde yapay sinir ađlarını yksek dereceli bulanık zaman serileri iin kullanmıřlardır. Bulanık iliřkilerin yapay sinir ađları ile belirlendiđi alıřmalara zellikle son yıllarda sıklıkla rastlanmaktadır. Fakat pek ok alıřmada bulanık iliřkiler belirlenirken, gzlemlerin ait olduđu (en yksek yelik derecesine sahip olduđu) kmeler ve buna ait kme numaraları ile iřlem yapılmakta, diđer kmeler ve yelik deđerleri ise ihmal edilmektedir. Bir bulanık zaman serisi gzlemi ait olduđu dřnlen bulanık kme dıřında diđer kmelere de belirli yelik deđerleri ile ait olduđundan, bulanık iliřkiler belirlenirken, her bir gzlemin tm bulanık kmelere ait olmasının yelik deđerlerinin dikkate alınması, hem bilgi kaybını nleyecek hem de bulanık zaman serisinde mevcut bulanık iliřkileri daha gereki olarak ortaya koyacak ve bylece ngr dođruluđunu ykseltecektir (Yolcu, 2011: 4). Bu amala, Yu ve Huarng (2010) bulanık iliřkilerin belirlenmesinde, girdileri gemiř gzlemlerin, ıktıları

gelecek gözlemlerin üyelik değerlerinden oluşan yapay sinir ağlarını kullanmışlardır. Ancak Yu ve Huarng (2010), her bir gözlemin evrensel kümenin parçalanması ile belirlenen bulanık kümelere ait olmasının üyelik değerlerini keyfi olarak belirlemektedirler. Bu durumun öngörü performansını olumsuz etkileyeceğinden hareketle, Yolcu v.d. (2013), bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan bulanık C-ortalamalar yöntemini kullanan ve bulanık ilişkilerin belirlenmesi aşamasında girdileri ve çıktıları, bu şekilde belirlenen üyelik değerlerinden oluşan yapay sinir ağlarının kullanıldığı bir yöntem önermişlerdir. Yolcu (2011) ise aynı yöntemi geliştirerek bir bulanık zaman serisinin diğer bazı bulanık zaman serileri ile aralarında mevcut olan bulanık ilişkileri ortaya çıkaracak, iki ve çok değişkenli (üç ve beş değişkenli) bir bulanık zaman serisi öngörü modeli önermektedir. Bulanık ilişki belirleme aşaması için Eğrioğlu (2012) genetik algoritmaya (GA), Aladağ v.d. (2012) ve Aladağ (2013) çarpımsal nöron modele dayalı yaklaşımları önermişlerdir.

Ayrıca Sullivan ve Woodal (1994), Hwang, Chen ve Lee (1998), Chen ve Hwang (2000), Huarng (2001b) ve Huarng ve Yu (2005) tarafından bu konudaki diğer önemli çalışmalar ortaya koyulmuştur. Sullivan ve Woodall (1994), Song ve Chissom (1993a, 1993b, 1994) modelinin bulanık ilişkilerin elde edilmesi adımıyla hesaplama yükünü azaltmak amacıyla, matris çarpımına dayalı Markov model tabanlı yöntem geliştirmişlerdir. Hwang v.d. (1998) ise bir yıla ait gözlem değerindeki değişimin geçmiş yıllara ait verilerin trendiyle ilişkili olduğunu öne sürmekte ve tahmin değerleri, bu trend ilişkisinden yararlanarak elde etmektedirler. Önerilen modelin ortalama tahminleme hatası Song ve Chissom (1993a, 1993b, 1994) tarafından önerilen modele göre daha düşük çıkmaktadır. Huarng (2001b) tahminlerin doğruluğunu arttırmak için bulanık mantık grupları içinde sezgisel artma-azalma eğilimi kavramını geliştirmiş, bulanık ilişkilerin belirlenmesinden sonra modele sezgisel bilgileri ekleyerek sezgisel bulanık mantık ilişki gruplarını oluşturarak tahmin gerçekleştirmiştir.

Durulaştırma aşamasında literatürdeki çalışmaların büyük çoğunluğunda merkezileştirme yöntemi kullanılmaktadır. Song ve Chissom (1994)' un çalışmalarında ise bulanık zaman serilerinde durulaştırma aşamasında yapay sinir

ağları kullanılmıştır. Yu (2005b), bulanık ilişki tablolarının dikkate alındığı ve ağırlıkların keyfi olarak seçildiği ağırlıklandırılmış-trend yöntemini önermiştir. Baş (2011) ise bulanık ilişki tablolarında tekrar eden ilişkileri göz önünde bulundurarak elde edilen ağırlıkların kullanıldığı yeni bir ağırlıklandırılmış-trende dayalı bulanık zaman serisi çözüm yöntemi önermiştir. Aladağ v.d. (2010b) merkezileştirme ile birlikte adaptif bekleyişler yöntemini kullanmaktadırlar.

Yu ve Huarng (2008) ise bulanık zaman serisi tahmininde sinir ağlarını uygulamakta ve tahmini iyileştirmek için iki değişkenli model önermektedir. Kuo v.d. (2009) çalışmalarında, parçacık sürü optimizasyon teknikleri kullanılarak öğrenci kayıtları tahmini için birinci dereceden ve yüksek dereceli bulanık zaman serisi modelleri oluşturmuşlardır. Chen ve Chen (2009, 2011) ise TAIEX tahmini için yüksek dereceli bulanık mantıksal ilişkiler kullanarak bulanık zaman serisi modeli oluşturmuşlardır. Eğrioğlu v.d. (2010a), Uslu v.d. (2010) ve Alpaslan v.d. (2012)' nin çalışmalarında mevsimsel zaman serilerinin çözülmesi için bulanık zaman serisi kestirim yöntemi olarak MA ve ARMA modelleri kullanılmaktadır.

Literatürde sıklıkla, birinci dereceden bulanık zaman serisi öngörü modelleri kullanılmaktadır. Bulanık zaman serisi öngörüsü için birinci dereceden bulanık zaman serisi öngörü modelleri kullanan çalışmalara; Song ve Chissom (1993a, 1993b, 1994), Sullivan ve Woodall (1994), Chen (1996), Chen ve Hwang (2000), Huarng (2001b), Huarng ve Yu (2006a, 2006b), Cheng, Cheng ve Wang (2008) ve Li, Cheng ve Lin (2008), Davari, Zarandi ve Turksen (2009), Yolcu v.d. (2009) ve Yu ve Huarng (2008, 2010) örnek gösterilebilir.

Fakat problemin sahip olduğu karmaşık ilişkilere göre, iki veya daha yüksek dereceli bulanık zaman serisi öngörü modelleri kullanılmıştır. Huarng (2001b), Lee v.d. (2006), Wang ve Chen (2009), Cheng, Chen ve Huang (2007), Yu ve Huarng (2008) çalışmalarında ikinci dereceden bulanık zaman serisi öngörü yöntemleri önermektedirler. Bulanık zaman serisi öngörüsü için yüksek dereceden bulanık zaman serisi öngörü modelleri kullanan çalışmalara örnek olarak; Chen (2002), Huarng ve Yu (2003), Chen ve Chung (2006), Chen, Cheng ve Teoh (2008), Jilani, Burney ve Ardil (2008), Jilani ve Burney (2007, 2008), Lee, Wang ve Chen (2007,

2008), Aladağ v.d. (2009, 2010a, 2010b), Eğrioğlu v.d. (2009b, 2009c, 2010a), Kuo v.d. (2009, 2010), Hsu v.d. (2010), Park v.d. (2010) ve Özdemir (2013) gösterilebilir. Chen (2002) Alabama Üniversitesi öğrenci kayıtları tahmini için yüksek dereceli bulanık zaman serisi modeli önermiştir. Aladağ v.d. (2009) ise bulanık ilişkileri belirlemede ileri beslemeli yapay sinir ağının kullanıldığı bir yöntem önermişlerdir. Chen ve Chung (2006) çalışmalarında öğrenci kayıtları tahmini için yüksek dereceli bulanık zaman serisi ve genetik algoritma içeren bir yöntem kullanılmışlardır. Wang ve Chen (2009) ise otomatik kümeleme tekniğini ve iki faktörlü yüksek dereceli bulanık zaman serisi modelini sıcaklık ve TAIEX tahmini için kullanmışlardır. Özdemir (2013), yüksek dereceden modelde hangi gecikmeli değişkenlerin yer alacağını belirlemek için, ikili parçacık sürü optimizasyonu yönteminin kullanıldığı bir bulanık zaman serisi öngörü algoritması ortaya koymuştur.

Değişken(ler)in sahip olduğu mevsimsel ilişkiler nedeniyle mevsimsel bulanık zaman serisi öngörü modelleri de kullanılmaktadır. Yüksek dereceli ve mevsimsel modellerin birlikte kullanıldığı modeller de çalışılmıştır. Mevsimsel modellerin kullanıldığı çalışmalara örnek olarak, Chang (1997), Song (1999) ve Eğrioğlu v.d. (2009a) sıralanabilir.

Bulanık zaman serisi öngörü modelleri, kullanılan değişken sayısına göre tek değişkenli bulanık zaman serisi öngörü modelleri ve iki veya çok değişkenli bulanık zaman serisi öngörü modelleri olarak iki çeşide ayrılmaktadır. Tek değişkenli bulanık zaman serisi öngörü modelleri kullanılan çalışmalara örnek olarak Song ve Chissom (1993a, 1993b, 1994), Chen (1996, 2002), Chang (1997), Song (1999), Huarng (2001a), Chen ve Chung (2006), Huarng ve Yu (2006a, 2006b), Cheng, Cheng ve Wang (2008), Davari, Zarandi ve Turksen (2009), Kuo v.d. (2009, 2010), Aladağ v.d. (2009), Yu ve Huarng (2010), Eğrioğlu v.d. (2010a, 2010b, 2011a, 2011b), Yolcu v.d. (2009, 2013), Cai v.d. (2015) Khiabani ve Aghabozorgi (2015) ve Wang v.d. (2015) çalışmaları örnek gösterilebilir.

Çok değişkenli bulanık zaman serisi öngörü modelleri kullanan çalışmalara örnek olarak Jilani, Burney ve Ardil (2008), Jilani ve Burney (2007, 2008), Jilani v.d. (2012), Cheng v.d. (2015), Sun v.d. (2015) iki değişkenli bulanık zaman serisi

öngörü modelleri kullanan çalışmalara ise örnek olarak ise Chen ve Hwang (2000), Hsu, Tse ve Wu (2003), Lee v.d. (2006), Lee, Wang ve Chen (2007, 2008), Li, Cheng ve Lin (2008), Yu ve Huarng (2008), Wang ve Chen (2009), Eğrioğlu v.d. (2009a, 2009b, 2009c), Hsu v.d. (2010), Park v.d. (2010), Chen, S.M. ve Chen, C.D (2011) çalışmaları verilebilir.

Bu bulanık zaman serisi modelleri, öğrenci kayıt verileri (Huarng, 2001a; Huarng ve Yu, 2006b) sıcaklık verileri (Lee v.d., 2007; Lee v.d., 2008) ve borsa verileri (Huarng ve Yu, 2004; Huarng ve Yu, 2005), trafik kazası verileri (Jilani ve Burney, 2008; Arutchelvan, Sivatsa ve Jaganathan, 2010), elektrik ücreti veri seti (Safarinejadian, Gharibzadeh ve Rakhshan, 2014), tarımsal iklim verileri (Mohammed, Gad Allah ve Hefny, 2014) gibi birçok farklı veri yapısına uygulanmıştır.

4.3. Chen (2002) Tarafından Önerilen Tek Değişkenli Yüksek Dereceli Bulanık Zaman Serisi Yöntemi

Chen, 2002 yılında yaptığı çalışmada öngörü elde etmede yüksek dereceli bulanık zaman serisi yaklaşımını önermiştir. Bu yöntemde yüksek dereceli modellerde tüm gecikmeli bulanık değişkenler bulunmaktadır. Örneğin 4. dereceden bir zaman serisinin çözümlenmesinde, $F(t)$ bulanık zaman serisi iken, $F(t-1)$, $F(t-2)$, $F(t-3)$, $F(t-4)$ bulanık gecikmeli değişkenleri modelde yer almaktadır. Birinci dereceden bulanık zaman serisi öngörü modellerine göre daha iyi sonuçlar veren, bu yüksek dereceli bulanık zaman serisi yönteminin algoritması aşağıdaki adımlardan oluşur (Chen, 2002).

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük ve en büyük değerleri sırasıyla D_{min} ve D_{max} , ayrıca keyfi iki sayı D_1 ve D_2 olmak üzere evrensel küme,

$$U = [D_{min} - D_1, D_{max} + D_2]$$

şeklinde ve sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$U = \{ u_1, u_2, \dots, u_b \}$$

olacak şekilde tanımlanır.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Üyelik dereceleri,

$$a_{jk} = \begin{cases} 1, & k = j \\ 0.5, & k = j - 1, j + 1 \\ 0, & \text{diğer hallerde} \end{cases}, \quad j = 1, 2, \dots, b$$

olmak üzere, bulanık kümeler aşağıdaki gibi tanımlanır:

$$A_j = a_{j1}/u_1 + a_{j2}/u_2 + \dots + a_{jb}/u_b, \quad j = 1, 2, \dots, b$$

Adım 3. Gözlemler bulanıklaştırılır. Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır.

Adım 4. Bulanık mantık ilişki ve grup ilişki tablosu oluşturulur. Örneğin, birinci dereceden bulanık mantık ilişkiler,

$$A_i \rightarrow A_j, \quad A_i \rightarrow A_i, \quad A_i \rightarrow A_k$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_i \rightarrow A_j, A_i, A_k$$

olarak elde edilir. Benzer şekilde genel bir ifade ile n. dereceden bulanık mantık ilişkiler,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}$$

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j2}$$

$$\vdots \quad \quad \quad \vdots$$

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{jp}$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp}$$

olarak elde edilir. Bulanık mantık ilişki ve grup ilişki tabloları, elde edilen bu bulanık mantık ilişki ve grup ilişkilerden oluşur.

Adım 5. Bulanık öngörüler elde edilir. n. dereceden bulanık zaman serisi öngörü modeli için bulanık öngörüler elde edilirken üç durum söz konusudur.

1. *Durum:* n. dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_j$$

ilişkisi mevcut ise bulanık öngörü, A_j olacaktır.

2. *Durum:* n. dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp}$$

ilişkisi mevcut ise bulanık öngöründe belirsizlik söz konusudur ve bulanık öngörünün elde edilebilmesi için belirsizlik giderilene kadar incelenen derecenin bir üst derecesine bakılarak $m > n$ olmak üzere,

$$A_{im}, A_{i(m-1)}, \dots, A_{i1} \rightarrow A_j$$

ilişkisini veren m aranır ve bu durumda bulanık öngörü, yine A_j olacaktır.

3. *Durum:* n. dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow \text{Boş}$$

ilişkisi mevcut ise reel öngörü $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ bulanık kümelerine bağlı olarak $u_{in}, u_{i(n-1)}, \dots, u_{i1}$ aralıklarının orta noktaları $m_{in}, m_{i(n-1)}, \dots, m_{i1}$ olmak üzere,

$$\frac{1 \times m_{in} + 2 \times m_{i(n-1)} + \dots + n \times m_{i1}}{1 + 2 + \dots + n}$$

ifadesi ile elde edilir.

Adım 6. Durulaştırma işlemi uygulanır. Durulaştırmada merkezileştirme yöntemi kullanılır. Öngörülerin elde edilmesinde karşılaşılan 1. Durum ve 2. Durum

için bulanık öngörü A_j olarak elde edilmişken, durulaştırılmış öngörü, A_j bulanık kümesinde en yüksek üyelik değerine sahip olan u_j aralığının orta noktası olacaktır. 3. Durum için ise reel öngörünün, $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ bulanık kümelerine bağlı olarak elde edilişi yukarıda anlatıldığı gibi olacaktır.

4.4. Jilani, Burney ve Ardil (2008) Tarafından Önerilen Çok Değişkenli Yüksek Dereceli Bulanık Zaman Serisi Yöntemi

Zaman serilerinin öngörülmesinde göz önüne alınması gereken bir husus da, zaman serisinin kendi gecikmeli değişkeninin yanı sıra farklı zaman serilerinden ve onların gecikmeli değişkenlerinden de etkilenebileceğidir. Aynı şekilde, bir zaman serisi veya bulanık zaman serisi de kendi gecikmeli değerleri yanında farklı zaman serileri veya bulanık zaman serilerinden ve onların gecikmeli değerlerinden de etkilenebilecektir (Yolcu, 2011, s.38). Bu nedenle öngörü modellerinde çok değişkenli yapıların oluşturulması gerekebilir.

Çok değişkenli (multivariate, m-factor) ya da iki değişkenli (bivariate, 2-factor) bulanık zaman serisi öngörü modelleri, son yıllarda çokça çalışılan bir konu olmuştur. İlk olarak Chen ve Hwang (2000) tarafından önerilen iki faktörlü birinci dereceden bulanık zaman serisi tahmin modeli ile sıcaklık değerleri, havanın bulut yoğunluğuna bağlı olarak tahmin edilmektedir. Çok değişkenli modellere ise ilk olarak Huarng, Yu ve Hsu (2007)' nun tek değişkenli modelleri çok değişkenli modellere entegre ettiği ve Taiwan Hisse Senedi İndeksini, sezgisel değişkenler olarak NASDAQ (USA), Dow Jones (USA) ve M_{1b} (Taiwan) günlük verileri ile tahmin ettiği çalışmasında rastlanmaktadır. Jilani ve Burney (2007) ve Jilani, Burney ve Ardil (2008) ise 1974-2004 arası Belçika trafik kazaları verisi üzerine yaptıkları çalışmalarında, yıllık olarak trafik kazalarında meydana gelen ölümlerin sayısını birincil, ölümcül yaralıları, 30 gün içinde meydana gelen ölümler, ağır yaralıları ve hafif yaralıların sayısını ikincil faktör olarak alarak 5 değişkenden oluşan çok değişkenli yüksek dereceli bulanık zaman serisi modeli önermişlerdir.

Önerilen modelin aşamaları aşağıdaki adımlardan oluşmaktadır:

Adım 1. Zaman serileri bulanıklaştırılır.

Adım 2. Bulanık zaman serilerinde bulanık ilişkiler oluşturulur.

Adım 3. Öngörüler elde edilir ve durulaştırılır.

4.5. Önerilen Yöntem

Bulanık zaman serileri için önerdiğimiz yöntemin tahmin algoritmaları şu aşamalardan oluşacaktır:

Adım 1. Model derecesi belirlenir ve gecikmeli değişkenler oluşturulur.

Oluşturulması planlanan ve (m) değişkenden oluşan yüksek dereceli çok değişkenli bulanık zaman serisi öngörü modelinin model derecesi (n) belirlenir. Çok değişkenli zaman serisi gözlemleri, belirlenen derece (n) kadar geciktirilerek gecikmeli zaman serisi gözlemleri oluşturulur.

Adım 2. Zaman serileri bulanıklaştırılır.

Ana faktöre ait evrensel küme (U) tanımlanır. Bunun için, geçmiş yıllardaki verilere ait en büyük ve en küçük gözlem değerleri sırasıyla D_{max} ve D_{min} ve keyfi iki pozitif reel sayı D_1 ve D_2 olmak üzere, $U = [D_{min} - D_1, D_{max} + D_2]$ şeklinde oluşturulur.

Benzer şekilde ikincil faktörlerin her biri için evrensel kümeler $(V_i, i = 1, 2, \dots, m - 1)$ tanımlanır. Her bir faktör için geçmiş yıllardaki verilere ait en büyük ve en küçük gözlem değerleri sırasıyla $(E_i)_{max}$ ve $(E_i)_{min}$ ve keyfi pozitif reel sayı ikililerinin oluşturduğu E_{i1} ve E_{i2} iki vektör olmak üzere $(i = 1, 2, \dots, m - 1)$, $V_i = [(E_i)_{min} - E_{i1}, (E_i)_{max} + E_{i2}]$ şeklinde oluşturulur.

Adım 3. Başlangıç ve bitiş noktaları belirlendikten sonra uygun aralık genişliği belirlenip her bir evrensel küme uygun sayıda eşit aralıklara ayrılır.

U evrensel kümesi için eşit aralıklar u_1, u_2, \dots, u_l ; V_i evrensel kümeleri için $(i = 1, 2, \dots, m - 1)$ ise $v_{1,j}, v_{2,j}, \dots, v_{m-1,j}$ ($j = 1, 2, \dots, l$) olarak adlandırılır.

Burada mesela $v_{1,p} = [v_{1,1}, v_{1,2}, \dots, v_{1,l}]$ şeklinde ilk ikincil faktöre ait aralıklardan oluşan bir vektördür. Bu şekilde $(m - 1) \times l$ boyutlu matris elde edilmiş olacaktır.

Adım 4. Oluşturulan evrensel kümeler ve oluşturulan aralıklara göre bulanık kümeler tanımlanır.

Birincil faktör için, A_j bulanık kümeleri ($j = 1, 2, \dots, l$) aşağıdaki gibidir:

$$A_j = f_{A_j}(u_1)/u_1 + f_{A_j}(u_2)/u_2 + \dots + f_{A_j}(u_l)/u_l, (j = 1, 2, \dots, l)$$

Benzer şekilde, ikincil faktörler için, $B_{i,j}$ bulanık kümeleri ($j = 1, 2, \dots, l$), ($i = 1, 2, \dots, m - 1$) aşağıdaki gibidir:

$$B_{i,j} = f_{B_{i,j}}(v_{i,1})/v_{i,1} + f_{B_{i,j}}(v_{i,2})/v_{i,2} + \dots + f_{B_{i,j}}(v_{i,l})/v_{i,l}, (j = 1, 2, \dots, l)$$

Daha sonra her bir gözlemin ait olduğu aralık belirlenerek, bu aralıkların her bir bulanık küme için üyelik değerleri tespit edilir.

Adım 5. Bulanık ilişkiler belirlenir.

Bulanık ilişkiler belirlenirken, ileri beslemeli geriye yayımlı yapay sinir ağı kullanılacaktır. Yapay Sinir Ağları, bulanık zaman serilerinin analizinde ilişki belirleme ve bunun gibi belirli aşamalarında kullanılabilir. Bulanık ilişkilerin yapay sinir ağı ile belirlenmesi bulanık mantık ilişki ve grup ilişki tablolarının oluşturulmasındaki karmaşıklığı ortadan kaldırmakta ve öngörülerini iyileştirmektedir. (Yolcu, 2008: 25) İlk olarak Huarng ve Yu (2006, 2008) bulanık zaman serilerinde bulanık ilişkilerin belirlenmesinde ileri beslemeli yapay sinir ağı kullanmışlardır.

Adım 6. Öngörüler durulaştırılır.

Yapay sinir ağına elde edilen çıktılar, $(t - 1)$, $(t - 2)$, ..., $(t - n)$ zamanındaki gözlemlerin bulanık aralıklara üyelik derecelerinin ağıya verilmesi ile elde edilen ve (t) zamana ait gözlemlerin üyelik değerleridir. Bu üyelik değerleri yardımı ile tahmin edilecek değerler hesaplanabilir. Burada bulanıklaştırma yapılan işlemler tersine yapılarak öngörüler durulaştırılmalıdır.

BÖLÜM 5

UYGULAMA

Çalışmanın bu kısmına kadar bulanık zaman serileri tahmin modelinin teorik altyapısı üzerinde durulmuştur. Bu bölümde ise önerilen bulanık zaman serileri tahmin modeli, 1990-2014 yıllarına ait ve Türkiye’de meydana gelmiş trafik kazaları ile ilgili 25 yıllık zaman serileri veri seti kullanılarak uygulanacaktır. Öncelikle uygulama için seçilen problem ve kullanılacak veriler tanıtılacak, sonra sırasıyla verinin analize hazırlanması, değişken seçimi, kullanılan metod ve uygulama ile elde edilen bulgular anlatılacaktır.

Bu uygulamanın amacı, zaman serilerinde bulanık mantık ve yapay sinir ağları temelinde hibrit yöntemler kullanılarak yapılacak tahminlemeyi aşamalarıyla göstermektir. Bunu yaparken ülkemizin gündeminde sürekli yer tutan ve insanlarımızın hayatını tehdit eden önemli olaylar arasında olan trafik kazaları sorunu ile ilgili farklı değişkenler üzerinde çalışılmıştır. TÜİK tarafından farklı başlıklarla değişik zamanlarda ve yayınlarda paylaşılan veriler derlenerek elde edilen bu değişkenler, öncelikle bir seçime tabi tutulmuştur. Bu işlem için zaman serileri analizinde yaygın olarak kullanılan EViews 7 paket programı kullanılmıştır. Değişkenler arasındaki ilişkilerin belirlenmesinde kullanılan yöntemler Johansen koentegrasyon testi, Granger nedensellik testi ve VAR modelidir. Sonrasında seçilen değişkenlerle ilgili temel istatistiklere yer verilmiş ve kullanılan metod adım adım uygulanmıştır. Bu aşamalarda ise açık kaynak kodlu bir yazılım olan R programlama dili paketleri kullanılmıştır. Bulanık zaman serileri tahmin modeli farklı parametreler ile denenerek test edilmiş, ele alınan veri üzerinde başarılı olduğu görülen model ile açıklanan değişkenin 2015 yılı değeri tahmin edilmiştir.

5.1. Problemin Tanımlanması

Trafik kazaları, Türkiye ve özellikle gelişmiş ya da gelişmekte olan tüm ülkelerde, insan hayatını tehdit eden önemli olaylardır (B. Şenel ve M. Şenel, 2013, s.66). 2014 yılında ülkemizde meydana gelen kayıtlı ölüm olaylarının % 1.39’ u

trafik kazaları nedeniyle meydana gelmiş olup bu oran erkeklerde % 1.95, kadınlarda % 0.73 olarak gerçekleşmiştir (TÜİK, Ölüm Nedeni İstatistikleri, 2014). Öte yandan Avrupa ülkeleri ile karşılaştırıldığında, son yıllarda nispeten bir iyileşme gözlenebile, halen trafik kazaları oranlarının ülkemiz açısından olumsuz seyrettiği görülmektedir. (Tablo 5.1) Bu kazaların ve kazalardaki ölüm, yaralanma ve maddi hasarın en aza indirilmesi için, hem sürücü, yaya ve yolcuların hem araç üreten firmaların hem de ilgili devlet birimlerinin üzerlerine düşen görev ve sorumlulukları yerine getirmeleri gerekmektedir. Bunun için bu kazaların sebep ve sonuçları ayrıntısıyla incelenmelidir.

Trafik kazaları ile ilgili istatistikler, kazaların nedenleri, meydana geliş ve sonuçlarını birlikte göstermesi açısından oldukça önemlidir. Bu istatistikler Ulaştırma, Denizcilik ve Haberleşme Bakanlığı ve Türkiye İstatistik Kurumu (TÜİK) tarafından demiryolu için 1935, karayolu için 1955, havayolu için 1959 ve denizyolu için 1993 yıllarından beri düzenli olarak tutulmakta ve kamuoyu ile paylaşılmaktadır. (Bkz. TÜİK, İstatistik Göstergeler 1923-2013, s.412) Buna göre meydana gelen kazaların 2013 yılında % 99.98' i karayollarında meydana gelmiştir. Trafik kazalarında meydana gelen ölümlerinin % 97.95' i, yaralanmaların ise % 99.96' sı karayollarında meydana gelen trafik kazalarında gerçekleşmiştir. Bu nedenle karayolu trafik kazaları, üzerinde hassasiyetle durulması gereken bir konudur.

Karayolunda meydana gelen trafik kazaları, en az bir taşıt, taşıtın/taşıtların sürücüsü/sürücüleri, taşıttaki/taşıtlardaki yolcular ve yayaların dâhil olduğu olaylardır. Bu kazalara önlem olarak; sürücülerin eğitilmesi ve sürücü belgesi ile trafiğe çıkmaları, trafik kurallarına uygun hareket edilmesi, aracın güvenlik ve bakımının eksiksiz olması, yolların bakım ve güvenlik tedbirlerinin tam olması ve sürücü, yolcu ve yayaların hava durumu, gün, saat, yol durumu gibi unsurların gerektirdiği önlemleri alarak hareket etmesi gerekmektedir. Sayılan hususlardan bir ya da bir kaçının eksik olması ya da olmaması veya insani hatalar, fiziksel şartlar vb. nedenler ile trafik kazaları meydana gelmektedir. Sonuçlarına göre ise ölümlü ve yaralamalı, yalnızca yaralamalı veya (ölüm veya yaralanma olmayan) maddi hasarlı trafik kazası olarak kayda geçmektedir.

Ülke	Ölümlü ve Yaralanmalı Kaza Sayısı		Bin Kişiyeye Düşen Otomobil Sayısı	Bir Milyon Kişiyeye Düşen Ölü Sayısı	Bir Milyon Otomobile Düşen Ölü Sayısı	
	Kaza Sayısı	Ölü Sayısı	Sayısı	Ölü Sayısı	Ölü Sayısı	
Türkiye	161306	3685	121	48	397	
EU-28	1054744	25938	491	51	105	
1	Belçika	35632	723	491	65	132
2	Bulgaristan	6859	601	402	83	210
3	Çek Cumh.	20342	655	450	62	139
4	Danimarka	2985	191	405	34	85
5	Almanya	291105	3339	543	41	77
6	Estonya	1382	81	478	61	132
7	İrlanda	5865	190	420	41	99
8	Yunanistan	12072	874	466	80	170
9	İspanya	89519	1680	474	36	76
10	Fransa	56812	3268	504	51	102
11	Hırvatistan	11228	368	341	86	254
12	İtalya	181227	3385	608	56	91
13	Kıbrıs	774	44	553	51	93
14	Letonya	3489	179	317	89	286
15	Litvanya	3418	256	615	87	144
16	Lüksemburg	949	45	661	83	125
17	Macaristan	15691	591	308	60	196
18	Malta	314	18	602	43	71
19	Hollanda	9522	476	471	28	60
20	Avusturya	38502	455	546	54	99
21	Polonya	35847	3357	504	88	176
22	Portekiz	30339	637	430	61	142
23	Romanya	24827	1861	235	93	405
24	Slovenya	6559	125	516	61	117
25	Slovakya	4729	251	347	46	136
26	Finlandiya	5334	258	574	47	83
27	İsveç	14942	260	466	27	58
28	İngiltere	144480	1770	468	28	59

Tablo 5.1. Avrupa Ülkelerine Ait 2013 Yılı Trafik Kazası ve Otomobil Sayısı

Bilgileri

Kaynak: Türkiye İstatistik Kurumu, Trafik Kaza İstatistikleri, 2013; EU Transport in Figures Statistical Pocketbook 2015 (2013 yılı bilgileri).

Ölüm veya yaralanma meydana gelen kazalarda mutlaka güvenlik kuvvetleri (Emniyet Müdürlüğü veya Jandarma Komutanlığı) olay yerine intikal ederek gerekli kayıtları tutmaktadır. Kaza sonrası düzenlenen tutanakta¹ (Bkz. Ek-3); kazanın yeri ve zamanı, kaza türü, hava ve gün durumu, yol ve çevre özellikleri, kazaya karışan araçlar, kazaya karışan sürücüler, kazazedeler (yolcu ve yayalar), kaza sonucu ile kazanın özeti, yeri ve krokisinden oluşan bilgiler tanzim edilerek kayıt altına alınmaktadır. Maddi hasarlı trafik kazalarında ise tarafların anlaşması halinde kazazedeler arasında tanzim edilen tutanaklar² (Bkz. Ek-29), aksi halde yine güvenlik kuvvetlerince tutulan kayıtlar (Bkz. Ek-28 ve 30) söz konusudur ve yine kazaya dair bilgiler bu tutanaklarla kayıt altına alınmaktadır. Bu kayıtlar Karayolları Genel Müdürlüğü tarafından istatistikler haline getirilmektedir. (Bkz. TÜİK, Ulaştırma İstatistikleri) Yıllık bültenler ve aylık raporlar ile bu istatistikler kamuoyu ile paylaşılmaktadır.

5.2. Türkiye Trafik Kazaları Verisi ve Tanımı

Çalışmamızda TÜİK tarafından yayınlanan, Ulaştırma, Denizcilik ve Haberleşme Bakanlığı ve Karayolları Genel Müdürlüğü'nce hazırlanmış bültenlerden derlenen 1990-2014 yıllarına ait verilerden elde edilen yıllık periyotlu zaman serileri veri seti kullanılmıştır. Veri seti, Tablo 5.2' de verilen birden fazla veri kaynağının taranması ve verilerin kontrol edilerek birleştirilmesi ile elde edilmiştir. Farklı yıllara ait değişkenlerin değerleri ayrı ayrı bulunarak birleştirilmiş ve 25 yıllık zaman serileri oluşturulmuştur. Bazı değişkenlerde (örneğin nüfus, kayıtlı araç sayısı) farklı değerlerle karşılaşılmış, bunlardan en güncel olanı alınmıştır. Bu farklılıkların sebebi ise yine TÜİK tarafından (TÜİK İstatistik Göstergeler 1923-2013, s. 2 ve 411, TÜİK Ulaştırma İstatistikleri Özeti 2011, s. 3) şu şekilde izah edilmektedir:

Nüfus verileri 2000 yılına kadar her 5 veya 10 yılda bir yapılan nüfus sayımları ile belirlenmiştir. Son nüfus sayımı 2000 yılında yapılmış, 2007 yılından itibaren ise

¹ Tutanak örneklerine TÜİK Trafik Kaza İstatistikleri Bülteninde ulaşılabilir.

² Türkiye Sigorta ve Reasürans Şirketleri Birliği tarafından hazırlanmaktadır.

adrese dayalı nüfus kayıt sistemine geçilmiştir. Dolayısıyla nüfus sayımları ile belirlenen nüfus, sayımın yapıldığı gün ikametinde bulunan toplam nüfusu ifade etmektedir. Diğer yıllara ait değerler bu nüfus değerleri esas alınarak üretilmiştir. 2007 ve sonrası nüfus değerleri ise ülke nüfusuna kayıtlı tüm bireylerin sayısı demektir. Her iki durumda da bu değerlerin yıl içinde belli bir zaman için hesaplandığı unutulmamalıdır.

TÜİK istatistikleri, 2004 yılından itibaren Emniyet Genel Müdürlüğü veri tabanı kullanılarak elde edilmiştir. İstatistiklerin revize edilmesi esnasında daha önce yayımlanan “Yol ve İş Makinaları” 2918 sayılı Karayolları Trafik Kanunu’na göre yeniden düzenlenmiştir. Buna göre; iş makinası türünden araçların, tarım kesiminde kullanılanları Ziraat Odalarınca, bunların dışında kalan iş makinaları da üyesi oldukları Ticaret ve Sanayi Odalarınca tescili yapıldığından Emniyet Genel Müdürlüğü veri tabanında kapsamamaktadır. Bu nedenle iş makinaları kapsamında yayımlanan taşıtlar, “Kamyon ve Özel Amaçlı Taşıtlar” başlığı altında yeniden revize edilmiş ve trafiğe kayıtlı araç sayıları buna göre düzenlenmiştir.

2008 yılından itibaren Emniyet Genel Müdürlüğü sorumluluk bölgesinde meydana gelen maddi hasarlı trafik kazalarında, tarafların anlaşarak kendi aralarında tutanak tanzim etmesi uygulaması başlamıştır. Bu kazalara ait bilgiler de sayılara dahil edilmektedir.

Veri Kaynağı	Başlık
Karayolu Trafik Kaza İstatistikleri 1990	Özet ve Ana Tablolar
Karayolu Trafik Kaza İstatistikleri 1991	Tablolar
Karayolu Trafik Kaza İstatistikleri 1992	Tablolar
Karayolu Trafik Kaza İstatistikleri 1993	Tablolar

Karayolu Trafik Kaza İstatistikleri 1994	Tablolar
Trafik kaza istatistikleri (Karayolu) 2003	Tarihsel Analiz Tabloları
Ulaştırma İstatistikleri Özeti 2004	Karayolu ve Trafik Kazaları İstatistikleri
Ulaştırma İstatistikleri Özeti 2011	Özet İstatistikler ve Karayolu İstatistikleri
İstatistik Göstergeler 1923-2013	Nüfus, Ulaştırma ve Haberleşme İstatistikleri
Karayolu Trafik Kaza İstatistikleri 2014	Tablolar
Ulaşım İstatistikleri 1966-2014	Motorlu kara taşıt sayısı
Ulaşım İstatistikleri 1984-2014	Karayolu uzunlukları
Ulaşım İstatistikleri 1990-2014	Trafik kaza sayısı ve sonuçları
Ulaşım İstatistikleri 1995-2014	Yıllara göre ölü ve yaralı sayılarının yaş gruplarına göre dağılımı
Ulaşım İstatistikleri 1995-2014	Trafik kazalarının nedeni kusurlar
Ulaşım İstatistikleri 2000-2014	Taşıt cinslerine göre trafiğe kayıtlı ve trafik kazasına karışan taşıtlar

Ulaşım İstatistikleri 2002-2014

Kaza, ölü ve yaralı sayıları

Trafik Kazaları Özeti 2014

Trafik kaza istatistikleri

Tablo 5.2. Veri Kaynakları ve Kullanılan Verilerin Başlıkları

Trafik kazaları, sürücü, yolcu ya da yayaların gerçekleştirdiği kural dışı hareketler veya araç, çevre ve iklim şartlarının sebep olduğu olumsuz şartlar nedeniyle meydana gelmektedir. Bu sebeple kazaların nedenleri tutulan resmi kayıtlarda genel olarak beş ana unsur olarak tanımlanmıştır. Bunlar; sürücü kusuru, yolcu kusuru, yaya kusuru, yol kusuru, araç kusuru olarak belirtilmiştir. 2014 yılı verilerine göre (TÜİK, Karayolu Trafik Kaza İstatistikleri, 2014), bunların içinde sürücü kusurlarının % 88.62, yolcu kusuru % 0.47, yaya kusuru % 9.38, yol kusuru % 0.95, araç kusuru ise % 0.58 oranında olduğu belirtilmektedir.

Trafik kazaları sonuçlarına göre ise maddi hasarlı, yaralanmalı ve ölümlü trafik kazaları olmak üzere 3 kategoriye ayrılarak incelenebilir. Yine aynı verilere göre, trafik kazalarında ölenlerin %42.7' sini sürücüler oluşturmakta, ölenlerin %76.8' inin erkek, yaralananların ise %70.2' sinin erkek olduğu görülmektedir. Ölümlü yaralanmalı trafik kazasına 264 bin 936 adet taşıt karışmış olup, bunların %50.6' sı otomobil, %16.3' ü motosiklet, %15.9' u kamyonet, %3.2' si minibüs, %3.1' i kamyon, %2.6' sı otobüs, %2.2' si çekici, %1.1' i traktör ve %5' i diğer taşıtlardan oluşmaktadır. Ölümlü yaralanmalı kazalar en fazla Ağustos en az Şubat ayında meydana gelmiştir.

Görüldüğü gibi trafik kazalarının nedenleri ve sonuçları pek çok faktörü barındırmaktadır. Bu çalışmada da bu faktörler arasındaki ilişkiler, bulanık zaman serileri analizi yöntemi ile incelenmiştir. Üzerinde çalışılacak faktörler, öncelikle 1990-2004 yılları arasında eksiksiz ve kesin veri sahibi olunanlardan seçilmiştir. Bu veriler ait olduğu yıla ait değerlerle karşılaştırılmış, uyumsuzluklar varsa güncel veriler tercih edilmiştir. Veri seti ile ilgili yapılan bu hazırlıklar sonucunda, trafik kazaları ile ilgili faktörleri meydana getiren ve Tablo 5.3' de başlıkları verilen 38 adet yıllık zaman serisi elde edilmiştir. Veri setinin tamamı Ek-1' de sunulmuştur.

	Değişken (Faktör)	Adı
1	Nüfus	x1
2	Toplam Kaza Sayısı	x2
3	Maddi Hasarlı Kaza Sayısı	x3
4	Ölümlü-Yaralanmalı Kaza Sayısı	x4
5	Kaza Yerinde Ölü Sayısı	x5
6	Kaza Yerinde Yaralı Sayısı	x6
7	Kayıtlı Toplam Taşıt Sayısı	x7
8	Kayıtlı Otomobil Sayısı	x8
9	Kayıtlı Otobüs Sayısı	x9
10	Kayıtlı Kamyon Sayısı	x10
11	Kayıtlı Kamyonet Sayısı	x11
12	Kayıtlı Minibüs Sayısı	x12
13	Kayıtlı Motosiklet Sayısı	x13
14	Kayıtlı Diğer Araçların Sayısı	x14
15	Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı	x15
16	Kazaya Karışan Taşıtlar İçinde Otobüslerin Oranı	x16
17	Kazaya Karışan Taşıtlar İçinde Kamyonların Oranı	x17
18	Kazaya Karışan Taşıtlar İçinde Kamyonetlerin Oranı	x18
19	Kazaya Karışan Taşıtlar İçinde Minibüslerin Oranı	x19
20	Kazaya Karışan Taşıtlar İçinde Motosikletlerin Oranı	x20
21	Kazaya Karışan Taşıtlar İçinde Diğer Araçların Oranı	x21
22	Toplam Bölünmüş Yol (km)	x22
23	Toplam Otoyol (km)	x23
24	Toplam Diğer Yollar (km)	x24
25	Toplam Köy Yolu (km)	x25
26	0-14 Yaş Ölü Sayısı	x26
27	0-14 Yaş Yaralı Sayısı	x27
28	15-24 Yaş Ölü Sayısı	x28
29	15-24 Yaş Yaralı Sayısı	x29
30	25-64 Yaş Ölü Sayısı	x30

31	25-64 Yaş Yaralı Sayısı	x31
32	65+ Yaş Ölü Sayısı	x32
33	65+ Yaş Yaralı Sayısı	x33
34	Sürücü Kusur Oranı	x34
35	Yolcu Kusur Oranı	x35
36	Yaya Kusur Oranı	x36
37	Yol Kusur Oranı	x37
38	Araç Kusur Oranı	x38

Tablo 5.3. 1990-2014 Trafik Kazaları Verisi Zaman Serileri

Bu faktörlerden tamamı yerine aralarında anlamlı ilişkiler bulunanları tercih edilecek ve uygulamada kullanılacaktır.

5.3. Değişkenlerin Seçimi ve Verinin Hazırlanması

İki ya da daha fazla zaman serilerinin arasında uzun dönem denge ilişkisinin var olup olmadığı veya aralarında anlamlı bir ilişki bulunup bulunmadığı koentegrasyon (eşbütünleşme) testi ile incelenmektedir. Engle ve Granger (1987), iki veya daha fazla durağan olmayan serinin doğrusal kombinasyonlarının durağan olabileceğini belirtmektedir. Bir başka deyişle, durağan olmayan serilerin doğrusal kombinasyonları durağansa, durağan olmayan bu seriler koentegredir yani eşbütünleşiktir. Buna göre, koentegrasyonun varlığından söz edilebilmesi için serilerin her birinin I(1) olması, yani durağan hale gelmeleri için birinci farklarının alınması durumunda, bu serilerin I(0) olmaları gerekmektedir. Bu nedenle ilk olarak serilerin durağanlığı Birim Kök Testi ile incelenmelidir.

Veride tüm değerler nümerik olup değişim aralıkları birbirinden oldukça farklıdır. Bu nedenle değerler normalize edilerek işleme alınacaktır. Normalizasyon yöntemi olarak min-max tekniği kullanılmıştır. (Balaban ve Kartal, 2015, s.43)

$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{yeni_max}_A - \text{yeni_min}_A) + \text{yeni_min}_A$$

Tüm deęişkenler için yeni deęerler [0, 1] aralıęında olacak şekilde hesaplama yapılmıřtır. Normalizasyon sonucu elde edilen veri seti Ek-2' de görüldüęü gibidir. Normalize edilmiř veriler $nx1, nx2, \dots, nx38$ şeklinde kısaltılmıřtır.

EViews 7.0 programı ile her bir nxi ($i=1, 2, \dots, 38$) zaman serisi için Augmented Dickey-Fuller Birim Kök Testi yapılmıřtır. Tahmin edilen modele dahil edilen gecikme sayısı Akaike (AIC), Schwarz (SIC), Hannan-Quinn (HQIC) Bilgi Kriterleri yardımıyla belirlenmektedir. Elde edilen sonuçlara göre;

- $nx24$ serisinde sabitsiz ve trendsiz modelde 0 gecikme durumunda,
 - $nx1, nx5, nx6, nx7, nx8, nx10, nx12, nx14, nx15, nx16, nx17, nx18, nx19, nx20, nx23, nx25, nx28, nx29, nx30, nx31, nx32, nx33, nx34, nx35, nx36, nx37, nx38$ serilerinde sabitli ve trendli modelde 0 gecikme durumunda,
 - $nx2, nx9, nx11, nx13, nx22, nx24, nx26, nx27$ serilerinde sabitli ve trendli modelde 1 gecikme eklendięi durumda,
 - $nx3$ serisinde sabitli ve trendli modelde 3 gecikme eklendięi durumda,
 - $nx4, nx21$ serilerinde sabitli ve trendli modelde 4 gecikme eklendięi durumda
- artıklardaki serisel korelasyonun ortadan kalktıęı görülmüřtür.

ADF testinde bu seriler için birim kök testi uygulandıęında sıfır hipotezinin reddedilemedięi görülmektedir. Bu sonuca göre tüm serilerimiz birim köke sahiptir yani duraęan dıřı oldukları ortaya çıkmaktadır. (Bkz. Ek-3) Bu durumda tüm serilerimizin birinci farkı alınarak yeniden birim kök testi uygulanacaktır. Herhangi bir nxi serisinin birinci farkı,

$Dnxi(t) = nxi(t) - nxi(t-1)$ ile hesaplanmaktadır. Buna göre, bu fark serileri için ADF birim kök testi sonuçlarına göre;

- $Dnx2, Dnx3, Dnx5, Dnx10, Dnx15, Dnx16, Dnx17, Dnx18, Dnx19, Dnx20, Dnx25, Dnx28, Dnx30, Dnx32, Dnx33, Dnx34, Dnx36$ serilerinde sabitsiz ve trendsiz modelde 0 gecikme durumunda,
- $Dnx1, Dnx6, Dnx9, Dnx12, Dnx14$ serilerinde sabitli ve trendsiz modelde 0 gecikme durumunda,

- $Dnx21, Dnx23, Dnx26, Dnx27, Dnx31, Dnx35, Dnx38$ serilerinde sabitli ve trendli modelde 0 gecikme durumunda,

- $Dnx37$ serisinde sabitsiz ve trendsiz modelde 1 gecikme durumunda,

sıfır hipotezi reddedilmekte yani birinci fark serilerinde birim kök olmayıp durağan hale gelmektedir. Bu seriler bu durumda $I(1)$ olarak adlandırılırlar.

- $Dnx4$ serisinde tüm modeller için 4 gecikme durumunda,

- $Dnx29$ serisinde tüm modeller için 1 gecikme durumunda,

- $Dnx7, Dnx8, Dnx11, Dnx13, Dnx22, Dnx24$ serilerinde ise,

tüm modeller için 0 gecikme durumunda sıfır hipotezi reddedilememekte yani bu fark serileri birim köke sahip olmakta ve durağan olmamaktadırlar. Bu seriler için tekrar fark serileri oluşturularak ADF Birim Kök Testi yapıldığında durağan hale geldikleri yani $I(2)$ oldukları görülmüştür (Bkz. Ek-4).

Durağan olmayan zaman serileri arasında uzun dönem ilişki bulunabilmesi için öncelikli şart olarak bu serilerin aynı düzeyde bütünleşik olması gerekmektedir. Aynı düzeyde bütünleşik iseler Engle ve Granger (1987)' in tek denklemlilik yaklaşımı veya Johansen (1988, 1995)' in çok denklemlilik ve eşanlı denklemlilik yaklaşımı ile değişkenler arasında eşbütünleşme (koentegrasyon) ilişkisi bulunabilmektedir. Yapılan birim kök testleri sonuçlarına göre, 38 zaman serisi içinden 30 tanesi $I(1)$ yani birinci fark düzeyinde durağan olup aynı düzeyde bütünleşiktirler. Bu durumda bu 30 değişken arasında uzun dönem eşbütünleşme ilişkisi bulunabilir. Ancak bu 30 değişken arasındaki koentegrasyon ilişkisi elbette ampiriktir ve teorik olarak da doğru olmalıdır. Bu çalışmada, belirlenen 30 değişken arasından aşağıdaki 8 değişken arasındaki ilişki incelenecektir (Tablo 5.4, 5.5) ve bundan sonraki tüm işlemlerde değişkenlerin gerçek değerleri yerine normalize edilmiş değerleri (Tablo 5.6) kullanılacaktır.

	Değişken (Faktör)	Seri	Norm. Seri
1	Nüfus	X1	NX1
2	Toplam Kaza Sayısı	X2	NX2
3	Kaza Yerinde Ölü Sayısı	X5	NX5

4	Kaza Yerinde Yaralı Sayısı	X6	NX6
5	Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı	X15	NX15
6	Toplam Otoyol (km)	X23	NX23
7	25-64 Yaş Ölü Sayısı	X30	NX30
8	Sürücü Kusur Oranı	X34	NX34

Tablo 5.4: Belirlenen Değişkenler ve Serilerin ve Normalize Edilmiş

Serilerin Adları

Yıl	Nüfus (bin) x1	Toplam Kaza Sayısı x2	Kaza Yerinde Ölü Sayısı x5	Kaza Yerinde Yaralı Sayısı x6	Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı x15	Toplam Otoyol (km) x23	25-64 Yaş Ölü Sayısı x30	Sürücü Kusur Oranı x34
1990	56154	115295	6317	87668	0.60	241	3434	0.8443
1991	57272	142145	6231	90520	0.62	342	3477	0.8753
1992	58392	171741	6214	94820	0.64	716	3369	0.9010
1993	59513	208823	6457	104330	0.68	1012	3567	0.9169
1994	60637	233803	5942	104717	0.67	1151	3333	0.9290
1995	61763	279663	6004	114319	0.68	1243	3368	0.9326
1996	62909	344643	5428	104599	0.67	1411	3052	0.9494
1997	64064	387533	5125	106246	0.65	1470	2900	0.9731
1998	65215	458661	6083	125793	0.65	1628	2760	0.9596
1999	66350	465915	5713	125158	0.66	1639	2698	0.9599
2000	67420	500664	5510	136751	0.67	1674	2395	0.9606
2001	68365	442960	4386	116203	0.68	1696	1793	0.9656
2002	69302	439777	4093	116412	0.65	1714	1825	0.9682
2003	70231	455637	3946	118214	0.65	1753	1813	0.9703
2004	71152	537352	4427	136437	0.64	1662	1940	0.9730
2005	72065	620789	4505	154086	0.64	1667	2043	0.9739
2006	72974	728755	4633	169080	0.60	1908	2173	0.9807
2007	70586	825561	5007	189057	0.61	1908	2251	0.9803
2008	71517	950120	4236	184468	0.51	1922	1949	0.9053
2009	72561	1053346	4324	201380	0.52	2036	1939	0.8960
2010	73723	1106201	4045	211496	0.51	2080	1848	0.8972
2011	74724	1228928	3835	238074	0.53	2119	1674	0.9020
2012	75627	1296634	3750	268079	0.52	2127	1669	0.8886
2013	76668	1207354	3685	274829	0.50	2127	2354	0.8869
2014	77696	1199010	3524	285059	0.51	2155	2189	0.8862

Tablo 5.5. Değişkenler ve Aldığı Değerler (Kaynak: TÜİK)

Uygulamada öngörülmesi amaçlanan ana faktör “25-64 Yaş Ölü Sayısı” ($X_{30}(t)$), ikincil faktörler ise “Nüfus” ($X_1(t)$), “Toplam Kaza Sayısı” ($X_2(t)$), “Kaza Yerinde Ölü Sayısı” ($X_5(t)$), “Kaza Yerinde Yaralı Sayısı” ($X_6(t)$), “Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı” ($X_{15}(t)$), “Toplam Otoyol (km)” ($X_{23}(t)$), “Sürücü Kusur Oranı” ($X_{34}(t)$) olarak belirlenmiştir.

Seçilen değişkenler incelendiğinde;

yıllar	nx1	nx2	nx5	nx6	nx15	nx23	nx30	nx34
1990	0	0	0.9523	0	0.5478	0	0.9299	0
1991	0.0519	0.0227	0.9229	0.0144	0.6511	0.0528	0.9526	0.2274
1992	0.1039	0.0478	0.9171	0.0362	0.7472	0.2482	0.8957	0.4158
1993	0.1559	0.0792	1	0.0844	0.9909	0.4028	1	0.5324
1994	0.2081	0.1003	0.8244	0.0864	0.9552	0.4754	0.8767	0.6212
1995	0.2604	0.1391	0.8456	0.135	1	0.5235	0.8952	0.6477
1996	0.3136	0.1941	0.6492	0.0858	0.9232	0.6113	0.7287	0.7708
1997	0.3672	0.2304	0.5459	0.0941	0.832	0.6421	0.6486	0.9449
1998	0.4206	0.2907	0.8725	0.1931	0.7917	0.7247	0.5748	0.8453
1999	0.4733	0.2968	0.7463	0.1899	0.8509	0.7304	0.5421	0.8478
2000	0.523	0.3262	0.6771	0.2487	0.948	0.7487	0.3825	0.8532
2001	0.5668	0.2774	0.2939	0.1446	0.9579	0.7602	0.0653	0.8898
2002	0.6103	0.2747	0.194	0.1456	0.8381	0.7696	0.0822	0.9087
2003	0.6535	0.2881	0.1439	0.1547	0.7973	0.79	0.0759	0.9239
2004	0.6962	0.3573	0.3079	0.2471	0.7347	0.7424	0.1428	0.9436
2005	0.7386	0.4279	0.3345	0.3365	0.7482	0.745	0.197	0.9507
2006	0.7808	0.5193	0.3781	0.4124	0.5601	0.871	0.2655	1
2007	0.6699	0.6012	0.5056	0.5136	0.5766	0.871	0.3066	0.9976
2008	0.7132	0.7067	0.2428	0.4904	0.026	0.8783	0.1475	0.447
2009	0.7616	0.7941	0.2728	0.5761	0.1143	0.9378	0.1423	0.3791
2010	0.8156	0.8388	0.1776	0.6273	0.059	0.9608	0.0943	0.3878
2011	0.862	0.9427	0.106	0.762	0.126	0.9812	0.0026	0.4232
2012	0.904	1	0.0771	0.914	0.092	0.9854	0	0.325
2013	0.9523	0.9244	0.0549	0.9482	0	0.9854	0.3609	0.3123
2014	1	0.9174	0	1	0.0138	1	0.274	0.3076

Tablo 5.6. Normalize Edilmiş Veriler

- “25-64 Yaş Ölü Sayısı” değişkeni tahmin edilecek olan ana faktör olarak seçilmiştir. Bunun nedeni, yetmiş insan gücünü temsil eden bu yaş aralığında ölüm ve yaralanma sayılarının fazla olması ve ülke için ciddi bir kayıp ifade etmesidir.

Burada kastedilen ölü sayısı, kaza anında olan ölümleri kapsamaktadır. Dolayısıyla ağır yaralanmalar nedeniyle bilahare meydana gelen ölümler bu sayıya dahil değildir. Bu sayılar istatistiklere dahil edilememekte ve gerçek sayı hesaplanamamaktadır.

- “Nüfus” değişkeni, yıl içinde veya yıl sonunda sayılan ülke toplam nüfusunu ifade etmektedir. Bu değer yılın belli bir zamanına ait olup yıl içinde değişimler meydana gelebilmektedir.

- “Kaza Yerinde Ölü Sayısı” ve “Kaza Yerinde Yaralı Sayısı” değişkenleri, kaza anında tutanaklara kaydedilen sayıları ifade etmektedir. Bu sayılarda da kaza sonrası değişimler hesaba katılamamaktadır. Bu değişkenler, hem meydana gelen kazanın etkisini hem kaza sonrasında meydana gelebilecek ölümleri modele dahil etmek amacıyla seçilmiştir.

- “Toplam Kaza Sayısı”, “Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı”, “Toplam Otoyol (km)” ve “Sürücü Kusur Oranı” değişkenleri, kazanın meydana gelişi ve sonuçları üzerinde etkili olacağı düşüncesi ile modele dahil edilmek istenmiştir.

Değişkenleri daha yakından tanımak için bazı tanımsal istatistik değerleri Tablo 5.7’ de verilmiştir. Hesaplamalar açık kaynak kodlu R programlama dili (R version 3.2.2 (2015-08-14), R-Project, 2015) ve R için bütünleşik bir geliştirme ortamı olan RStudio (RStudio Inc, Version 0.99.484 – © 2009-2015) kullanılarak yapılmıştır (R kodları için Bkz. Ek-5).

	x1	x2	x5	x6	x15	x23	x30	x34
Min.	56154	115295	3524	87668	0.5035	241	1669	0.8443
1. Kartil	62909	344643	4093	106246	0.5261	1411	1939	0.8972
Medyan	69302	465915	4633	125793	0.6375	1674	2251	0.9326
Arit. Ort.	67875	616052	4937	154312	0.6103	1576	2473	0.9310
3. Kartil	72561	950120	5942	189057	0.6561	1922	3052	0.9682
Max.	77696	1296634	6457	285059	0.6829	2155	3567	0.9807

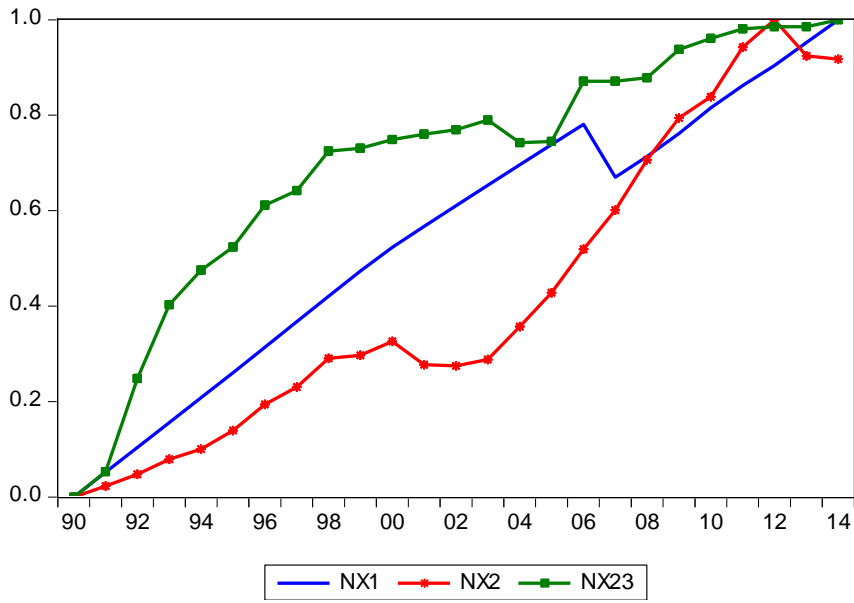
Tablo 5.7. Değişkenlere Ait Tanımsal İstatistikler

	nx1	nx2	nx5	nx6	nx15	nx23	nx30	nx34
Min.	0.0000	0.0000	0.0000	0.00000	0.0000	0.0000	0.0000	0.0000
1. Kartil	0.3136	0.1941	0.1940	0.09412	0.1260	0.6113	0.1423	0.3878
Medyan	0.6103	0.2968	0.3781	0.19314	0.7472	0.7487	0.3066	0.6477
Arit. Ort.	0.5441	0.4239	0.4817	0.33762	0.5953	0.6975	0.4234	0.6361
3. Kartil	0.7616	0.7067	0.8244	0.51365	0.8509	0.8783	0.7287	0.9087
Max.	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000


Tablo 5.8. Normalleştirilmiş Veriler İçin Tanımsal İstatistikler

Normalleştirilmiş veriler için bu istatistikler Tablo 5.8’ de görüldüğü gibidir.


Bu 8 değişkenin grafikleri incelendiğinde aralarındaki ilişkiler hakkında fikir edinilebilmektedir.




Şekil 5.1. Yıllara Göre Nüfus (NX1), Toplam Kaza Sayısı (NX2) ve Toplam Otoyol (km)(NX23)



Şekil 5.2. Yıllara Göre Toplam Kaza Sayısı (NX2), Kaza Yerinde Ölü Sayısı (NX5) ve Kaza Yerinde Yaralı Sayısı (NX6)



Şekil 5.3. Yıllara Göre Toplam Otoyol (km)(NX23), 25-64 Yaş Ölü Sayısı (NX30) ve Sürücü Kusur Oranı (NX34)



Şekil 5.4. Yıllara Göre Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı (NX15), Toplam Otoyol (km)(NX23) ve Sürücü Kusur Oranı (NX34)

Johansen (1988, 1995) koentegrasyon metodunda, modeldeki tüm değişkenler içsel kabul edilerek öncelikle VAR modeli tahmin edilir. Bunun için ise uygun gecikme sayısının belirlenmesi gerekir. Tablo 5.9’ da 0 ve 1 gecikme için hesaplanan sonuçlar verilmiştir. Bunun için AIC, SC ve HQ bilgi kriterleri yanında, LR test istatistiği ve son tahmin hatası kriterleri de incelenmiştir.

Görüldüğü üzere tüm kriterler uygun gecikmenin 1 olduğunu göstermektedir. Dolayısıyla bu, uygun modelin VAR(1) olması gerektiği anlamına gelecektir. Buna göre VAR(1) modeli Tablo 5.10’ da verilmiştir.

VAR Lag Order Selection Criteria

Endogenous variables: NX1 NX2 NX5 NX6 NX15 NX23

NX30 NX34

Exogenous variables: C @TREND

Sample: 1990 2014

Included observations: 24

Lag	LogL	LR	FPE	AIC	SC	HQ
0	230.7648	NA	2.34e-18	-17.89707	-17.11170	-17.68871
1	406.2152	204.6922*	3.32e-22*	-27.18460*	-23.25776*	-26.14281*

* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

Tablo 5.9. VAR Modeli İçin Uygun Gecikme Seçimi

Vector Autoregression Estimates

Sample (adjusted): 1991 2014

Included observations: 24 after adjustments

Standard errors in () & t-statistics in []

	NX1	NX2	NX5	NX6
NX1(-1)	0.531543 (0.26421) [2.01181]	-0.208165 (0.21492) [-0.96857]	1.343066 (0.75921) [1.76903]	0.630914 (0.36966) [1.70676]
NX2(-1)	-0.019250 (0.30623) [-0.06286]	1.480792 (0.24910) [5.94450]	0.761012 (0.87996) [0.86482]	0.795141 (0.42845) [1.85586]
NX5(-1)	-0.033182 (0.07427) [-0.44681]	-0.001332 (0.06041) [-0.02205]	0.090423 (0.21340) [0.42372]	-0.199038 (0.10390) [-1.91559]
NX6(-1)	-0.032515 (0.25634) [-0.12684]	-0.845787 (0.20851) [-4.05626]	-0.059538 (0.73658) [-0.08083]	0.357445 (0.35864) [0.99668]
NX15(-1)	0.120197 (0.11114) [1.08153]	0.062736 (0.09040) [0.69396]	-0.849642 (0.31935) [-2.66053]	-0.101306 (0.15549) [-0.65153]

NX23(-1)	0.100817 (0.14702) [0.68574]	-0.321170 (0.11959) [-2.68554]	-0.365703 (0.42246) [-0.86565]	-0.293067 (0.20570) [-1.42477]
NX30(-1)	-0.030368 (0.09235) [-0.32882]	0.278355 (0.07512) [3.70531]	0.383455 (0.26537) [1.44496]	0.250776 (0.12921) [1.94085]
NX34(-1)	-0.103811 (0.08231) [-1.26124]	0.061889 (0.06695) [0.92436]	0.737471 (0.23651) [3.11810]	0.096668 (0.11516) [0.83944]
C	0.034610 (0.14925) [0.23190]	-0.328143 (0.12140) [-2.70291]	1.107481 (0.42886) [2.58239]	0.062112 (0.20881) [0.29746]
@TREND	0.017962 (0.01482) [1.21236]	0.045277 (0.01205) [3.75677]	-0.124129 (0.04257) [-2.91559]	-0.022434 (0.02073) [-1.08227]
R-squared	0.991830	0.995867	0.949928	0.986917
Adj. R-squared	0.986578	0.993210	0.917738	0.978507
Sum sq. resids	0.014520	0.009607	0.119887	0.028421
S.E. equation	0.032204	0.026196	0.092538	0.045057
F-statistic	188.8512	374.8262	29.51056	117.3448
Log likelihood	54.86926	59.82485	29.53657	46.80953
Akaike AIC	-3.739105	-4.152071	-1.628047	-3.067461
Schwarz SC	-3.248249	-3.661215	-1.137192	-2.576605
Mean dependent	0.566780	0.441552	0.462084	0.351691
S.D. dependent	0.277978	0.317914	0.322644	0.307331

	NX15	NX23	NX30	NX34
NX1(-1)	2.967381 (0.64343) [4.61183]	0.142421 (0.35454) [0.40171]	0.202591 (0.97439) [0.20792]	3.327767 (0.40672) [8.18197]
NX2(-1)	-0.608130 (0.74576) [-0.81545]	0.662604 (0.41092) [1.61247]	-0.427539 (1.12936) [-0.37857]	0.993746 (0.47141) [2.10804]
NX5(-1)	0.115033 (0.18086) [0.63605]	-0.050999 (0.09965) [-0.51176]	-0.384962 (0.27388) [-1.40557]	-0.070516 (0.11432) [-0.61682]

NX6(-1)	0.156075 (0.62425) [0.25002]	-0.481483 (0.34397) [-1.39979]	1.363319 (0.94534) [1.44214]	-1.282197 (0.39460) [-3.24939]
NX15(-1)	0.166396 (0.27065) [0.61481]	0.124924 (0.14913) [0.83768]	-0.448511 (0.40986) [-1.09430]	0.311827 (0.17108) [1.82270]
NX23(-1)	0.852628 (0.35804) [2.38141]	0.506311 (0.19728) [2.56644]	-0.157047 (0.54220) [-0.28965]	-0.092160 (0.22632) [-0.40721]
NX30(-1)	-0.021037 (0.22490) [-0.09354]	0.209354 (0.12392) [1.68937]	0.497024 (0.34059) [1.45932]	0.464777 (0.14216) [3.26929]
NX34(-1)	-0.386707 (0.20044) [-1.92926]	0.043913 (0.11045) [0.39760]	0.369358 (0.30355) [1.21681]	0.112431 (0.12670) [0.88736]
C	0.761978 (0.36346) [2.09648]	-0.092810 (0.20027) [-0.46343]	1.237604 (0.55041) [2.24853]	-0.163606 (0.22975) [-0.71212]
@TREND	-0.160840 (0.03608) [-4.45771]	0.008766 (0.01988) [0.44092]	-0.085352 (0.05464) [-1.56208]	-0.103353 (0.02281) [-4.53155]
R-squared	0.972685	0.980752	0.924495	0.979215
Adj. R-squared	0.955125	0.968378	0.875956	0.965854
Sum sq. resids	0.086109	0.026144	0.197474	0.034406
S.E. equation	0.078426	0.043214	0.118766	0.049574
F-statistic	55.39338	79.26126	19.04649	73.28550
Log likelihood	33.50785	47.81187	23.54789	44.51630
Akaike AIC	-1.958987	-3.150989	-1.128991	-2.876358
Schwarz SC	-1.468131	-2.660133	-0.638135	-2.385503
Mean dependent	0.597260	0.726576	0.402244	0.662619
S.D. dependent	0.370220	0.243012	0.337212	0.268276

Tablo 5.10. VAR(1) Modeli Tahmin Sonuçları

Ancak VAR modelinde yalnızca değişkenlerin gecikmeli değerleri bulunduğundan bu durumun bir spesifikasyon hatasına yol açacağı düşüncesi ile Phillips ve Loretan (1991), eşbütünleşme ilişkisi olarak otoregresif dağıtılmış

gecikme (ARDL-Autoregressive Distributed Lag) modelini önermişlerdir. Bu modelde,

$$Y_t = \alpha + \sum_{j=1}^k \alpha_j \cdot Y_{t-j} + \sum_{j=0}^k \beta_j \cdot X_{t-j} + \varepsilon_t$$

denklemini elde edilerek tahmin edilen denge sapmasının durağanlığı test edilmektedir (Sevüktekin ve Çınar, 2014, s.576). Belirlenen değişkenler için tahmin edilen model aşağıda Tablo 5.11’ de verilmiştir.

Dependent Variable: NX30				
Method: Least Squares				
Sample (adjusted): 1991 2014				
Included observations: 24 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.397883	0.401908	0.989987	0.3552
@TREND	0.214755	0.061128	3.513210	0.0098
NX30(-1)	-0.603846	0.247171	-2.443028	0.0446
NX1	0.099930	0.435087	0.229679	0.8249
NX2	-1.014621	0.742554	-1.366393	0.2141
NX5	0.890304	0.243352	3.658499	0.0081
NX6	1.112869	0.763137	1.458282	0.1881
NX15	-0.379985	0.234927	-1.617459	0.1498
NX23	-0.236338	0.406673	-0.581149	0.5794
NX34	1.737049	0.286927	6.053966	0.0005
NX1(-1)	-6.578871	1.289490	-5.101916	0.0014
NX2(-1)	-2.286259	0.991197	-2.306565	0.0545
NX5(-1)	-0.087851	0.225843	-0.388991	0.7088
NX6(-1)	2.336384	0.886692	2.634946	0.0337
NX15(-1)	0.023405	0.241487	0.096919	0.9255
NX23(-1)	0.762478	0.324205	2.351839	0.0509
NX34(-1)	-0.653489	0.195611	-3.340748	0.0124
R-squared	0.994349	Mean dependent var	0.402244	
Adjusted R-squared	0.981432	S.D. dependent var	0.337212	
S.E. of regression	0.045950	Akaike info criterion	-3.137982	
Sum squared resid	0.014780	Schwarz criterion	-2.303527	
Log likelihood	54.65579	Hannan-Quinn criter.	-2.916601	
F-statistic	76.97929	Durbin-Watson stat	2.875876	
Prob(F-statistic)	0.000003			

Tablo 5.11. ARDL Modeli Tahmin Sonuçları

Görüldüğü gibi model bir bütün olarak anlamlıdır. Ancak serilerin koentegre olabilmesi yani aralarında uzun dönem ilişki bulunduğunun söylenebilmesi için, elde edilen denklemin hatalarından meydana gelen serinin durağan yani I(0) olması gerekmektedir. Modelin hata terimlerinin oluşturduğu seri Ek-6'da, yapılan ADF Birim Kök Testi sonuçları Tablo 5.12' de verilmiştir.

Null Hypothesis: RESID01 has a unit root		
Exogenous: Constant		
Lag Length: 1 (Automatic - based on SIC, maxlag=5)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.072762	0.0005
Test critical values: 1% level	-3.769597	
5% level	-3.004861	
10% level	-2.642242	

*MacKinnon (1996) one-sided p-values.


Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(RESID01)
 Method: Least Squares
 Date: 10/26/15 Time: 03:03
 Sample (adjusted): 1993 2014
 Included observations: 22 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID01(-1)	-1.880340	0.370674	-5.072762	0.0001
D(RESID01(-1))	0.299076	0.217203	1.376945	0.1845
C	6.30E-05	0.004936	0.012762	0.9900
R-squared	0.751748	Mean dependent var		0.000318
Adjusted R-squared	0.725617	S.D. dependent var		0.044194
S.E. of regression	0.023149	Akaike info criterion		-4.567575
Sum squared resid	0.010182	Schwarz criterion		-4.418797
Log likelihood	53.24333	Hannan-Quinn criter.		-4.532527
F-statistic	28.76764	Durbin-Watson stat		2.052544
Prob(F-statistic)	0.000002			


Tablo 5.12. ARDL Modeli Hata Terimleri Serisi Birim Kök Testi Sonuçları

Birim kök testi sonucuna göre, hata terimlerinden oluşan seri sabitli modelde seviyesinde durağandır. Bunun anlamı, değişkenler eşbütünleşik (koentegre) olup

aralarında uzun dönem ilişkiden bahsedilebilir. Tahmin edilen NX30 değişkenine ait modelin tahmin değerlerini gösteren grafik Şekil 5.5’ te, değişkenin aldığı gerçek değerlerle ve hata terimleri ile birlikte ise Şekil 5.6’ da görülmektedir.



Şekil 5.5. NX30 Değişkenine Ait Tahmin Değerlerinin Grafiği



Şekil 5.6. NX30 Değişkenine Ait Tahmin ve Gerçek Değerler ile Hata Terimleri

Bulunan tahmin modeli şu şekilde yazılabilir:

$$\begin{aligned} nx_{30}(t) = & 0.397883 + 0.214755 \cdot @trend - 0.603846 \cdot nx_{30}(t-1) + \\ & 0.099930 \cdot nx_1(t) - 1.014621 \cdot nx_2(t) + 0.890304 \cdot nx_5(t) + 1.112869 \cdot \\ & nx_6(t) - 0.379985 \cdot nx_{15}(t) - 0.236338 \cdot nx_{23}(t) + 1.737049 \cdot nx_{34}(t) - \\ & 6.578871 \cdot nx_1(t-1) - 2.286259 \cdot nx_2(t-1) - 0.087851 \cdot nx_5(t-1) + \\ & 2.336384 \cdot nx_6(t-1) + 0.023405 \cdot nx_{15}(t-1) + 0.762478 \cdot nx_{23}(t-1) - \\ & 0.653489 \cdot nx_{34}(t-1) \end{aligned}$$

Bu model ve katsayıları, çalışmanın bundan sonraki kısımlarında da kullanılacaktır.

5.4. Metodoloji

Zaman serisi yöntemleri, gelecekteki değerleri tahmin etmek için zamanla değişen geçmiş verilerin sıralı dizisindeki ilişkileri ortaya çıkarmaya çalışır. Fakat bir değişkeni yalnızca geçmiş değerlerine bağlı olarak modellemek yeterli olmayabilir. Bu nedenle değişkenin etkilenebileceği diğer değişkenlerle birlikte ele almak ihtiyaç olmuştur. Çok değişkenli zaman serileri yöntemleri, bir değişkeni hem kendi geçmiş değerleri hem de diğer değişkenlerin geçmiş değerleri ile birlikte modellemeyi amaçlar.

5.4.1. Veri Setinin Eğitim ve Test Setlerine Ayrılması

25 veriden ve 8 değişkenden oluşan veri seti, öncelikle eğitim (training) ve test (testing) seti şeklinde ayrılacaktır. Burada literatürde bu konu ile ilgili olarak çeşitli yöntemler önerilmektedir. Bu yöntemlerin başlıcaları; Holdout, Tekrarlı Holdout, Tabakalı Örnekleme, Üçlü Ayırma, Çapraz Geçerleme, Rasgele Örnekleme, Bootstrap Örnekleme olarak sayılabilir (Balaban ve Kartal, 2015, s.45-48). Bu çalışmada eğitim-test seti ayrımı %80-%20 oranlarında tercih edilmiştir. Bunun için $25 \cdot 0.80 = 20$ yıllık veri eğitim, kalan 5 yıllık veri ise modeli test etmek için kullanılacaktır. Bu veriler tüm değişkenler için, 1990-2009 arası eğitim seti, 2010-2014 arası test seti olacak şekilde belirlenmiştir.

5.4.2. Yapay Sinir Ağları İle Tahmin Modeli

Zaman serilerinde tahmin için regresyon, basit üstel düzgünleştirme, Holt'un doğrusal trend yöntemleri, ARIMA ve VAR gibi geleneksel yöntemler haricinde YSA modelleri de kullanılmaktadır. Klasik yöntemler tahmin için kullanılmakla beraber bu yöntemlerin en büyük dezavantajı doğrusallık, durağanlık gibi varsayımlara dayalı olarak geliştirilmelidir. Ancak gerçek hayattaki verilerin pek çoğu doğrusal olmamakta, durağanlık şartını sağlamamakta veya kriz dönemlerinde gözlemlendiği gibi zaman zaman yapısal kırılmaya sahip olmaktadır. Bu nedenle varsayımlara dayanmayan diğer yöntemlerle birlikte Yapay Sinir Ağları (YSA) modelleri de zaman serilerinin tahmininde kullanılmaktadır. YSA modellerinin tahmin başarısını ölçmek için de diğer zaman serisi yöntemleriyle karşılaştırmalar yapılmakta, hangi modelin tahmin performansının daha iyi olduğu ampirik çalışmalarla belirlenmeye çalışılmaktadır.

Zaman serilerinde yapay sinir ağları ile tahmin için öncelikle ağın yapısının belirlenmesi gerekir. Girdi, çıktı ve gizli katmanların yapısına karar verilerek ağ kurulmalıdır. Daha sonra aktivasyon fonksiyonu belirlenmeli ve ağın mimarisine karar verilmelidir. En son ağın çıktıları tahmin edilerek test değerleriyle karşılaştırılmalı ve tahminlerin doğruluğu araştırılmalıdır.

5.4.2.1. Ağın Mimarisi

YSA'nın girdi değerlerini normal (düzey) ve gecikmeli zaman serileri oluşturacaktır. Bu değerler normalizasyona tabi tutuldukları için [0,1] aralığında sayılardan oluşmaktadır.

Zaman serisi için girdi değerleri oluşturulurken, girdi tabakasındaki nöron sayısı m olmak üzere, m tane zaman serisi oluşturulur. Girdi değerleri, açıklayıcı değişkenlerin düzey ve bir gecikmeli değerleri olarak alınacaktır (Bkz. Ek-7). Bunu yaparken dayanak noktamız, bir önceki bölümde bulunan tahmin modeli denklemi ve VAR modelinde gecikme uzunluğunun 1 bulunmuş olmasıdır. Böylelikle tahmin edilen değişkenin gecikmeli değerlerinin serisi ile birlikte toplam 15 girdi düğümü bulunacaktır. Çıktı tabakası ise 1 düğümden oluşacak olup tahmin edilecek değişken

olarak belirlenecektir. Gizli katmanın ve düğümlerinin sayısı ise deneme yanılma yolu ile bulunacak ve HKOK değerini minimize eden sayılar tercih edilecektir. Ağın oluşturulmasında açık kaynak kodlu R programlama dili (R version 3.2.2 (2015-08-14), R-Project, 2015) ve R için bütünleşik bir geliştirme ortamı olan RStudio (RStudio Inc, Version 0.99.484 – © 2009-2015) kullanılarak yapılmıştır (R kodları için Bkz. Ek-8).

5.4.2.2. Yapay Sinir Ağının Eğitilmesi

Veri setinin %80-%20 oranlarında eğitim-test setine ayrıldığı söylenmişti. Şimdi yapılması gereken, girdi düğümlerine 15 değişkenin ilk 20 yıla ait değerleri ve çıktı düğümüne hedef değişkenin ilk 20 yıla ait değerleri verilerek ağın eğitilmesidir. Aktivasyon fonksiyonu olarak [0,1] aralığında değer alması nedeniyle Sigmoid fonksiyonu tercih edilmiştir. Ağda ileri beslemeli geriye yayımlı Esnek Geriye Yayımlı (Resilient Back-propagation) algoritması ile tahmin yapılacaktır.

Gizli katman sayısı ve katmanda bulunacak düğüm sayısı farklı değerler denenerek tespit edilmiştir. Buna göre, 1 gizli katmanda 40 düğümlü model toplam hatayı en küçük yapan model olmaktadır. (Tablo 5.13)


Gizli Tabaka	Repetition	Error	Reached Threshold	Steps
(1,1)	2	0.02509258723	0.009365815403	263
(1,2)	1	0.01916205387	0.007228703518	158
(1,3)	3	0.00710991149	0.009665624014	203
(1,4)	3	0.005670624202	0.009065457015	354
(1,5)	6	0.006554021651	0.006795917419	156
(1,6)	2	0.005147806243	0.007149221918	153
(1,7)	5	0.006041106447	0.008843046444	167
(1,8)	4	0.005776979272	0.009218453653	293
(1,9)	3	0.004578445074	0.006528166577	207
(1,10)	9	0.002397025803	0.009761694261	242
(1,11)	10	0.004599300194	0.009179311856	217
(1,12)	10	0.005686567971	0.009105919368	272
(1,13)	8	0.007411280422	0.009741353463	112
(1,20)	30	0.001474625200	0.009794544784	347
(1,25)	9	0.001402014134	0.009885973495	294

(1,30)	4	0.001631560989	0.009050152372	379
(1,40)	55	0.001333493341	0.009492395189	407
(1,41)	31	0.002857363961	0.009974908537	316
(2,1,1)	1	0.04090949322	0.005811144921	38
(2,1,2)	1	0.04612877608	0.006674479454	50
(2,2,1)	4	0.04298697319	0.005999085693	85
(2,2,2)	1	0.01560745572	0.008900388396	130
(2,3,3)	1	0.01898484808	0.007318438041	119
(2,5,5)	12	0.007882185415	0.009503726907	125
(2,10,10)	6	0.006847490563	0.004932029249	129
(2,20,20)	26	0.004305796708	0.008347804658	110
(2,40,40)	15	0.004241931574	0.009813057725	75
(2,25,40)	5	0.004608685647	0.009907145423	129
(3,5,5,5)	3	0.01847728268	0.009202272331	74
(3,10,10,10)	13	0.007468531364	0.007757617259	85
(3,20,20,20)	42	0.004597035839	0.005859544820	82
(3,40,40,40)	19	0.004036003818	0.003264745075	83

Tablo 5.13. Farklı gizli katman ve düğüm sayıları için toplam hata değerleri

Buna göre, ağ 55. tekrarda 407 adım sonunda öğrenmiş bulunmaktadır. Ağın grafiği Şekil 5.7' de verilmiştir.

Ağın tahmin edilen hedef değişkene ait gerçek değerleri ile tahmin (çıktı) değerleri ve hata miktarları, Hata Karaları Toplamı, Hata Karelerinin Ortalaması, Hata Karelerinin Ortalamasının Karekökü ve Ortalama Mutlak Yüzde Hata değerleri ise Tablo 5.14' de verilmiştir.



Şekil 5.7. Yapay Sinir Ağı Mimarisi

	tahmin x30(t)	nx30(t)	mutlak hata	hata^2	MYH
1	0,949743966	0,952581665	0,002837699	8,05253E-06	0,2979
2	0,902124933	0,895679663	0,00644527	4,15415E-05	0,7196
3	0,987845166	1	0,012154834	0,00014774	1,21548
4	0,14582955	0,876712329	0,730882779	0,534189636	83,3663
5	0,887286724	0,895152792	0,007866068	6,1875E-05	0,87874
6	0,906491243	0,728661749	0,177829493	0,031623329	24,4049
7	0,708167989	0,64857745	0,059590539	0,003551032	9,18788
8	0,654399212	0,574815595	0,079583617	0,006333552	13,8451
9	0,534190849	0,542149631	0,007958782	6,33422E-05	1,468
10	0,369268256	0,382507903	0,013239647	0,000175288	3,46127
11	0,086229021	0,065331928	0,020897093	0,000436688	31,986
12	0,087898619	0,082191781	0,005706838	3,2568E-05	6,94332
13	0,049388743	0,075869336	0,026480593	0,000701222	34,9029
14	0,15680904	0,142781876	0,014027164	0,000196761	9,82419

15	0,199061108	0,197049526	0,002011583	4,04646E-06	1,02085
16	0,583576417	0,265542677	0,31803374	0,10114546	119,767
17	0,256931917	0,306638567	0,049706649	0,002470751	16,2102
18	0,148814151	0,147523709	0,001290442	1,66524E-06	0,87474
19	0,306276736	0,142255005	0,164021731	0,026903128	115,301
	HKT	0,708087679	OMYH (%)	25,0356	
	HKO	0,037267773			
	HKOK	0,193048628			

Tablo 5.14. YSA Eğitim Sonuçları Tahmin Değerleri

5.4.2.3. Test Sonuçları

Eğitilen ağa test verileri verilerek ağın test edilmesi gerekmektedir. Girdi düğümündeki değişkenlerin son 5 yıla ait verileri öğrenen ağa verildiğinde Tablo 5.15’ deki tahmin değerleri bulunmaktadır.

Ağın eğitim seti için yaptığı tahminlerde HKOK yaklaşık 0,2 değerini almaktadır. Benzer şekilde test seti için de yakın bir sonuç bulunmuştur. Ancak OMYH değeri, eğitim sonuçlarına göre çok farklılık arz etmektedir. Bu sonuç, belirlenen birincil değişken için modelde iyi bir tahmin sonucuna ulaşılamaması anlamına gelmektedir.

Yıl	Tahmin $x_{30}(t)$	$nx_{30}(t)$	Mutlak Hata	Hata ²	MYH
2010	0,146180961	0,09431	0,051871161	0,002690617	55,00081779
2011	0,247770114	0,00263	0,245135762	0,060091542	-
2012	0,268461997	0	0,268461997	0,072071844	-
2013	0,23921814	0,36091	0,121688077	0,014807988	33,7173678
2014	0,055059236	0,27397	0,218913366	0,047923062	79,90337873
	HKT	0,197585053	OMYH (%)	56,20718811	
	HKO	0,039517011			
	HKOK	0,19878886			

Tablo 5.15. YSA Test Sonuçları Tahmin Değerleri

5.4.3. Önerilen Hibrid Model

Bulanık zaman serisi öngörü yöntemleri, klasik modellere göre bazı avantajlara sahiptir. Özellikle gözlemleri belirli bir zaman dilimi içinde değişiklik gösteren zaman serileri için uygun yöntemlerdir. Gerçek hayat zaman serilerinin birçoğunda

gözlemlerde belirsizlikler bulunabilir. Gözlemleri bulanık kümeler ile temsil edilen bu tür belirsizlik içeren zaman serilerinin tahmini, bulanık zaman serileri algoritmaları ile mümkün olmaktadır.

Bulanık zaman serileri için önerilen tahmin algoritmaları aşama aşama mevcut veri setine uygulanarak aşağıdaki sonuçlara ulaşılmıştır.

5.4.3.1. Modelin Derecesi ve Değişkenler

1. Adımda ilk olarak model derecesi belirlenir ve gecikmeli değişkenler oluşturulur.

Oluşturulması planlanan ve (m) değişkenden oluşan yüksek dereceli çok değişkenli bulanık zaman serisi öngörü modelinin model derecesi (n) belirlenir. Çok değişkenli zaman serisi gözlemleri, belirlenen derece (n) kadar geciktirilerek gecikmeli zaman serisi gözlemleri oluşturulur.

Yapılan eşbütünleşme ve VAR analizi sonucu dikkate alınarak, modelimiz 1. derece bulanık zaman serisi modeli olarak tasarlanacak olup bir gecikmeli değerler kullanılacaktır. Böylelikle gecikmeli değerlerden oluşan serilerle birlikte 16 zaman serisi üzerinde çalışılacaktır ve model kurulacaktır.

5.4.3.2. Bulanıklaştırma

2. Adımda zaman serileri bulanıklaştırılır.

Ana faktöre ait evrensel küme (U) tanımlanır. Bunun için, geçmiş yıllardaki verilere ait en büyük ve en küçük gözlem değerleri sırasıyla D_{max} ve D_{min} ve keyfi iki pozitif reel sayı D_1 ve D_2 olmak üzere, $U = [D_{min} - D_1, D_{max} + D_2]$ şeklinde oluşturulur.

Benzer şekilde ikincil faktörlerin her biri için evrensel kümeler ($V_i, i = 1, 2, \dots, m - 1$) tanımlanır. Her bir faktör için geçmiş yıllardaki verilere ait en büyük ve en küçük gözlem değerleri sırasıyla $(E_i)_{max}$ ve $(E_i)_{min}$ ve keyfi pozitif reel sayı ikililerinin oluşturduğu E_{i1} ve E_{i2} iki vektör olmak üzere ($i = 1, 2, \dots, m - 1$), $V_i = [(E_i)_{min} - E_{i1}, (E_i)_{max} + E_{i2}]$ şeklinde oluşturulur.

Normalize edilmiş veriler $[0, 1]$ aralığından değer almaktadır. Bu sebeple,

$$D_{max} = (E_i)_{max} = 1, (i = 1, 2, \dots, m - 1)$$

$$D_{min} = (E_i)_{min} = 0, (i = 1, 2, \dots, m - 1)$$

olacaktır. D_1 ve D_2 pozitif reel sayıları ve E_{i1} ve E_{i2} vektörlerinin pozitif reel sayı olan elemanları ise 0.5 seçilmiştir. Böylece,

$$U = [D_{min} - D_1, D_{max} + D_2] = [-0.5, 1.5]$$

$$V_i = [(E_i)_{min} - E_{i1}, (E_i)_{max} + E_{i2}] = [-0.5, 1.5], (i = 1, 2, \dots, m - 1)$$

olacaktır.

5.4.3.3. Aralıkların Belirlenmesi


3. Adım olarak, başlangıç ve bitiş noktaları belirlendikten sonra uygun aralık genişliği belirlenip her bir evrensel küme uygun sayıda eşit aralıklara ayrılır.

U evrensel kümesi için eşit aralıklar u_1, u_2, \dots, u_l ; V_i evrensel kümeleri için ($i = 1, 2, \dots, m - 1$) ise $v_{1,j}, v_{2,j}, \dots, v_{m-1,j}$ ($j = 1, 2, \dots, l$) olarak adlandırılır. Burada mesela $v_{1,j} = [v_{1,1}, v_{1,2}, \dots, v_{1,l}]$ şeklinde ilk ikincil faktöre ait aralıklardan oluşan bir vektördür. Bu şekilde $(m - 1) \times l$ boyutlu matris elde edilmiş olacaktır.

Burada uygun aralık genişliğinin belirlenmesi, modelin anlamlı olması için önemlidir. Bunun için de eşit aralıkların sayısının belirlenmesi gerekmektedir. Üzerinde çalışılan veri setinde, birden fazla değişkenin değerleri ile birlikte çalışılacağından, tüm değişkenlerde aynı aralık sayısının olması gerekecektir. Bu sebeple çalışmamızda veri seti kümeleme analizine tabi tutulmuş ve k-ortalamlar kümeleme tekniği ile Euclid uzaklıkları kullanılmıştır. Her bir k değeri için grup içi uzaklıklar karesi toplamını hesaplayarak grafiğini çizen döngü ile veri setinin 5 kümeye ayrılmasına karar verilmiştir.

Açık kaynak kodlu R programlama dili ile yapılan kümeleme analizi sonucunda, elde edilen grafik yardımı ile, veri setinin 5 kümeye ayrılmasının doğru olacağı görülmüştür. Kümeleme işleminde R'da yazılan kodlar Ek-9' da verilmiştir.

Buna göre, grup içi uzaklıkların kareleri toplamını minimize eden küme sayısı 5 olarak gerçekleşmektedir.



Şekil 5.8. Küme Sayısına Göre Grup İçi Uzaklık Kareleri Toplamı

Grafik, grup içi uzaklıklar karesi toplamının grup sayısına göre değişimini göstermektedir. Buna göre, 5 gruptan sonra bu toplam çok fazla değişmemektedir. (Şekil 5.8) Böylelikle uygun aralık sayısı olarak ($l = 5$) seçilmiştir. Bu durumda,

$U = [-0.5, 1.5]$ ve $V_i = [-0.5, 1.5]$, ($i = 1, 2, \dots, m - 1$) için bu aralıklar;

$u_1 = v_{i,1} = [-0.5, -0.1]$, $u_2 = v_{i,2} = [-0.1, 0.3]$, $u_3 = v_{i,3} = [0.3, 0.7]$,

$u_4 = v_{i,4} = [0.7, 1.1]$ ve $u_5 = v_{i,5} = [1.1, 1.5]$

olarak belirlenmiştir.

5.4.3.4. Üyelik Fonksiyonu Seçimi ve Bulanık Kümelerin

Oluşturulması

4. Adımda, oluşturulan evrensel kümeler ve oluşturulan aralıklara göre bulanık kümeler tanımlanır.

Birincil faktör için, A_j bulanık kümeleri ($j = 1, 2, \dots, l$) aşağıdaki gibidir:

$$A_j = f_{A_j}(u_1)/u_1 + f_{A_j}(u_2)/u_2 + \dots + f_{A_j}(u_l)/u_l, (j = 1, 2, \dots, l)$$

Benzer şekilde, ikincil faktörler için, $B_{i,j}$ bulanık kümeleri ($j = 1, 2, \dots, l$), ($i = 1, 2, \dots, m - 1$) aşağıdaki gibidir:

$$B_{i,j} = f_{B_{i,j}}(v_{i,1})/v_{i,1} + f_{B_{i,j}}(v_{i,2})/v_{i,2} + \dots + f_{B_{i,j}}(v_{i,l})/v_{i,l}, (j = 1, 2, \dots, l)$$

Daha sonra her bir gözlemin ait olduğu aralık belirlenerek, bu gözlemlerin her bir bulanık küme (aralık) için üyelik değerleri tespit edilir.

Veri setimizdeki her bir zaman serisi ve her bir gecikmeli zaman serisi, kümeleme analizi ile belirlenen küme sayısı kadar eşit aralıklara ayrılmıştır. Daha sonrasında üyelik fonksiyonları yardımıyla, herhangi bir (t) zamanda birincil faktör ve ikincil faktörlerin aldığı değerler ile birincil faktörün ve ikincil faktörlerin aynı (t) zamana karşılık gelen ($t - 1$) zamandaki gecikmeli değerlerinden oluşan vektörün her bir elemanı için bulanık kümelere ait üyelik değerleri belirlenmiştir. Her bir veri seti vektörü;

$$NX_t = \left(nx_1^{(t)}, nx_2^{(t)}, nx_5^{(t)}, nx_6^{(t)}, nx_{15}^{(t)}, nx_{23}^{(t)}, nx_{30}^{(t)}, nx_{34}^{(t)}, \dots \right. \\ \left. \dots, nx_1^{(t-1)}, nx_2^{(t-1)}, nx_5^{(t-1)}, nx_6^{(t-1)}, nx_{15}^{(t-1)}, nx_{23}^{(t-1)}, nx_{30}^{(t-1)}, nx_{34}^{(t-1)} \right), \\ t = (2, 3, \dots, 25)$$

elemanlarından oluşmaktadır.

Böyle bir vektör 16 elemandan oluşacak olup her biri için bulanık küme sayısı kadar yani 5 tane üyelik değeri hesaplanmıştır. Bu vektöre veri seti vektörü denilecek olup, her bir t değeri için hesaplandığından 24 adet vektör ($t = 1$ için gecikmeli değer bulunmayacağından 1990 yılına ait değerler hesaplanmayacaktır) ve her birine ait 5 farklı üyelik değeri bulunacaktır. Elbette ($t - 1$) zamandaki bir değer için üyelik değeri, bir önceki (t) zamanda hesaplanan üyelik değeri ile aynı olacaktır.

Üyelik fonksiyonu olarak Gaussian, Sigmoid ve Çan Sekilli üyelik fonksiyonları ayrı ayrı kullanılarak en iyi tahmin sonucuna ulaşılmaya çalışılmıştır.

Bu fonksiyonlar bulanıklaştırma işlemlerinde, sahip oldukları tek parçalı fonksiyon yapısı sayesinde yapılacak hesaplamalarda sağladıkları kolaylık nedeni ile tercih edilmektedirler.

a) *Gaussian Üyelik Fonksiyonu:*

Bu tip bir üyelik fonksiyonu m ve σ parametreleri ile tanımlanmaktadır.

$$\mu_A(x; m, \sigma) = e^{\left(\frac{-(x-m)^2}{2\sigma^2}\right)}$$

Burada m , fonksiyon merkezini ve σ da genişliğini ifade etmektedir. σ küçük olduğunda üyelik fonksiyonu daha ince olurken, bu değer büyüdükçe üyelik fonksiyonu gittikçe yayvanlaşmaktadır.

Burada m değeri, daha önce belirlenmiş olan aralıkların orta noktası olacaktır. Yani;

1. aralık $[-0.5, -0.1]$ olduğundan $m_1 = -0.3$,
2. aralık $[-0.1, 0.3]$ olduğundan $m_2 = 0.1$,
3. aralık $[0.3, 0.7]$ olduğundan $m_3 = 0.5$,
4. aralık $[0.7, 1.1]$ olduğundan $m_4 = 0.9$,
5. aralık $[1.1, 1.5]$ olduğundan $m_5 = 1.3$

olarak hesaplanır. Burada üyelik fonksiyonundaki bir diğer parametre olan $\sigma = 0.2$ alınacaktır. (Bkz. Ek-10)

b) *Sigmoidal Üyelik Fonksiyonu:*

Bu tip üyelik fonksiyonu $a_1, a_2 \in R$ ve $a_1 < a_2$ olmak üzere iki parametre ile tanımlanmaktadır.

$$\mu_A(x; a_1, a_2) = \frac{1}{1 + e^{-a_1 \cdot (x-a_2)}}$$

Burada a_1 fonksiyonun tanım kümesinin üst sınırını, a_2 ise fonksiyonun tanım kümesinin alt sınırını ifade etmektedir. Aralıkları içine alacak şekilde tanım kümelerini belirlemek için ardışık sınır değerleri içinde kalacak a_1 ve a_2 değerleri alınarak her bir aralık için üyelik değerleri hesaplanacaktır. Bu şekilde,

1. aralık $[-0.5, -0.1]$ ve 2. aralık $[-0.1, 0.3]$ olduğundan $a_1 = -0.7$ ve $a_2 = 0.1$,

2. aralık $[-0.1, 0.3]$ ve 3. aralık $[0.3, 0.7]$ olduğundan $a_1 = -0.3$ ve $a_2 = 0.5$,

3. aralık $[0.3, 0.7]$ ve 4. aralık $[0.7, 1.1]$ olduğundan $a_1 = 0.1$ ve $a_2 = 0.9$,

4. aralık $[0.7, 1.1]$ ve 5. aralık $[1.1, 1.5]$ olduğundan $a_1 = 0.5$ ve $a_2 = 1.3$,

5. aralık $[1.1, 1.5]$ olduğundan $a_1 = 0.9$ ve $a_2 = 1.7$ olarak alınacaktır.

Hesaplanan üyelik değerleri Ek-11' de verilmiştir.

c) *Çan Şekilli Üyelik Fonksiyonu:*

Bu tip üyelik fonksiyonu $a_1, a_2, a_3 \in R$, $a_1 \neq 0$ ve $a_1 < a_2 < a_3$ olmak üzere üç parametre ile tanımlanmaktadır.

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

Diğer üyelik fonksiyonlarında yapıldığı gibi, her bir aralık için bu parametreler belirlenmelidir. Belirlenen aralıkların orta noktaları a_3 değeri olarak, alt sınırları a_2 değeri olarak alınabilir. a_1 ve a_3 'ün orta noktası a_2 olacak şekilde a_1 de belirlenebilir. O halde,

1. aralık $[-0.5, -0.1]$ olduğundan $a_1 = -0.7$, $a_2 = -0.5$, $a_3 = -0.3$

2. aralık $[-0.1, 0.3]$ olduğundan $a_1 = -0.3$, $a_2 = -0.1$, $a_3 = 0.1$,

3. aralık $[0.3, 0.7]$ olduğundan $a_1 = 0.1$, $a_2 = 0.3$, $a_3 = 0.5$,

4. aralık $[0.7, 1.1]$ olduğundan $a_1 = 0.5$, $a_2 = 0.7$, $a_3 = 0.9$,

5. aralık [1.1, 1.5] olduğundan $a_1 = 0.9, a_2 = 1.1, a_3 = 1.3$

olarak alınacaktır. Hesaplanan üyelik değerleri Ek-12' de verilmiştir.

Bu 16 değer oluşturduğu vektör veri setinin birlikte her bir bulanık kümeye ait üyelik değeri için ise tüm bu 16 üyelik değerinin ağırlıklı aritmetik ortalaması alınmıştır. Kullanılacak ağırlıklar olarak ise, koentegrasyon yöntemi ile elde edilen ARDL tahmin modelinde bulunan katsayıların mutlak değerleri tercih edilmiştir. Böylece her bir değişkenin modeldeki ağırlığı, üyelik değerinde de kullanılacak ve veri setinin üyelik değerinde modeldeki ağırlığı ile katkısı olacaktır. Bu işlem, normalize edilmiş değerlerle yapılmıştır. Model ve kullanılacak katsayılar şu şekildedir:

$$\begin{aligned} nx_{30}(t) = & 0.397883 + 0.214755 \cdot @trend - 0.603846 \cdot nx_{30}(t - 1) + 0.099930 \\ & \cdot nx_1(t) - 1.014621 \cdot nx_2(t) + 0.890304 \cdot nx_5(t) + 1.112869 \\ & \cdot nx_6(t) - 0.379985 \cdot nx_{15}(t) - 0.236338 \cdot nx_{23}(t) + 1.737049 \\ & \cdot nx_{34}(t) - 6.578871 \cdot nx_1(t - 1) - 2.286259 \cdot nx_2(t - 1) \\ & - 0.087851 \cdot nx_5(t - 1) + 2.336384 \cdot nx_6(t - 1) + 0.023405 \\ & \cdot nx_{15}(t - 1) + 0.762478 \cdot nx_{23}(t - 1) - 0.653489 \cdot nx_{34}(t - 1) \end{aligned}$$

Her bir aralık için değişkenlerin aldığı normal ve gecikmeli değerlerin farklı üyelik fonksiyonları için hesaplanan üyelik değerlerinin ağırlıklı ortalamaları alındığında, 16 değerden oluşan her bir veri seti vektörünün bu aralıklara ait üyelik değerleri bulunmuştur. Hesaplamalarda MS Office Excel (Microsoft, 2010) tablo programı kullanılmıştır. Burada t=1 yani ilk yıla (1990) ait değer 1 gecikmeli zaman serisinde bulunmayacağından hesaplama katılmamıştır. Örneğin t=2 (1991 yılı) için, 1. aralıkta Gaussian üyelik fonksiyonu kullanıldığında bu hesaplama şu şekilde yapılmaktadır:

Değişken	t=2 için Gözlem Değerleri	Gözlemlerin Üyelik Değerleri	ARDL Modeli Katsayısı	(Üyelik Değ.) x (Katsayı)
nx1(t)	0.051898617	0.212692471	0.09993	0.021254359
nx2(t)	0.022728446	0.272008864	1.014621	0.275985905

nx5(t)	0.922945789	7.60124E-09	0.890304	6.76741E-09
nx6(t)	0.01444848	0.290551893	1.112869	0.323346195
nx15(t)	0.651144885	1.22687E-05	0.379985	4.66193E-06
nx23(t)	0.05276907	0.211067939	0.236338	0.049883375
nx30(t)	0.952581665	3.03817E-09	1	3.03817E-09
nx34(t)	0.227354595	0.030922047	1.737049	0.053713111
nx1(t-1)	0	0.324652467	6.578871	2.135846703
nx2(t-1)	0	0.324652467	2.286259	0.742239625
nx5(t-1)	0.952267303	3.06822E-09	0.087851	2.69546E-10
nx6(t-1)	0	0.324652467	2.336384	0.75851283
nx15(t-1)	0.547766152	0.00012542	0.023405	2.93545E-06
nx23(t-1)	0	0.324652467	0.762478	0.247540364
nx30(t-1)	0.929926238	6.13668E-09	0.603846	3.70561E-09
nx34(t-1)	0	0.324652467	0.653489	0.212156816
Toplam:			19.803679	4.820486894

Veri Seti Vektörünün 1. Aralık Üyelik Değeri: $4,820 / 19,804 = 0,243413706$

Tablo 5.16. Gaussian Fonksiyonu ile $t=2$ için 1. Aralık Üyelik Değerinin Hesaplanması

Her bir veri seti vektörünün aralıklara ait üyelik dereceleri olarak Tablo 5.17, 5.18 ve 5.19’ da gösterilen aşağıdaki değerler bulunmuştur.

Gaussian Fonksiyonu İçin Vektörlerin Üyelik Değerleri					
t	1. Aralık	2. Aralık	3. Aralık	4. Aralık	5. Aralık
1	-	-	-	-	-
2	0.243413706	0.749768365	0.097586313	0.137320519	0.025355486
3	0.171538906	0.744338269	0.175165859	0.148943373	0.021665759
4	0.116127197	0.718713682	0.232248468	0.156204187	0.041545413
5	0.078357218	0.684072784	0.29248001	0.185095933	0.024379267
6	0.0570098	0.640597489	0.3361187	0.205446841	0.02046447
7	0.039220585	0.582130144	0.409197347	0.209506596	0.011841537
8	0.036430528	0.51567681	0.465817306	0.210936784	0.021551575
9	0.024981596	0.43701737	0.527877332	0.242919169	0.019448695
10	0.011027834	0.361257631	0.62021373	0.248222856	0.013237712
11	0.009246156	0.328592582	0.656912134	0.245789608	0.015441633
12	0.019371804	0.365086089	0.610962268	0.241822217	0.019508404
13	0.033378445	0.428350759	0.510745073	0.266126297	0.020346604

14	0.034232192	0.422362309	0.475770998	0.299699126	0.02323048
15	0.022385113	0.370846713	0.490941109	0.33669377	0.027540152
16	0.009013999	0.286029701	0.538794078	0.379498111	0.030910652
17	0.003500889	0.196950962	0.580867793	0.421771667	0.044392464
18	0.001346032	0.117515459	0.57975981	0.500906933	0.055439476
19	0.010795146	0.173412649	0.69104183	0.357375344	0.019028402
20	0.010646475	0.199329656	0.603248204	0.421128755	0.014729784
21	0.016863693	0.199038886	0.485508344	0.523072258	0.028106728
22	0.028858397	0.184627011	0.379086806	0.614103919	0.051024497
23	0.037911423	0.197372107	0.238923813	0.688115681	0.097117303
24	0.027637106	0.182425292	0.200342247	0.711116341	0.139054818
25	0.023627444	0.180182565	0.189015545	0.703724872	0.161339813

Tablo 5.17. Gaussian Fonksiyonu İle Belirlenen Üyelik Değerleri

Sigmoidal Fonksiyonu İçin Vektörlerin Üyelik Değerleri					
t	1. Aralık	2. Aralık	3. Aralık	4. Aralık	5. Aralık
1	-	-	-	-	-
2	0.490376589	0.525593554	0.481465087	0.361716494	0.20367575
3	0.481255922	0.52169663	0.482766342	0.367696104	0.21102347
4	0.470061774	0.516824793	0.484393362	0.375336027	0.221219467
5	0.463750924	0.514163976	0.485280474	0.379397223	0.226051964
6	0.458200395	0.511785068	0.486073958	0.383091584	0.230772501
7	0.45384656	0.509952211	0.486684878	0.385889232	0.234093161
8	0.449155846	0.507899566	0.487369764	0.389150747	0.238624096
9	0.442519159	0.505032418	0.488325696	0.393660716	0.244649472
10	0.437247438	0.502789925	0.489073064	0.397132038	0.249005526
11	0.434983159	0.501809083	0.489400062	0.398680935	0.251101731
12	0.437670365	0.502947006	0.48902071	0.396933212	0.248971341
13	0.440712739	0.50422439	0.48859445	0.395006048	0.246780725
14	0.438215264	0.503113584	0.488964816	0.396813087	0.249484144
15	0.43178099	0.500309799	0.489900071	0.40125389	0.255580753
16	0.423455287	0.496692145	0.491106583	0.406971953	0.263365558
17	0.414631917	0.492818914	0.492398563	0.413160702	0.272117002
18	0.404544729	0.488374668	0.493880613	0.420305148	0.282413181
19	0.419302511	0.4949614	0.491681889	0.409633802	0.266561869
20	0.418276567	0.494488693	0.491839474	0.410433051	0.267901781
21	0.412461003	0.491854635	0.492718427	0.414781556	0.274729466
22	0.406176582	0.488988636	0.49367515	0.419536204	0.282312189
23	0.399191599	0.485751646	0.494757265	0.424947044	0.291181561
24	0.391279559	0.48217836	0.495951657	0.430760381	0.299984006

25 0.388375645 0.480855882 0.496394057 0.432920202 0.303304285

Tablo 5.18. Sigmoidal Fonksiyon İle Belirlenen Üyelik Değerleri

Çan Şekilli Fonksiyon İçin Vektörlerin Üyelik Değerleri					
t	1. Aralık	2. Aralık	3. Aralık	4. Aralık	5. Aralık
1	-	-	-	-	-
2	0.428503693	0.480010325	0.388977255	0.468525512	0.452268363
3	0.44457848	0.473361969	0.402181156	0.4888313	0.464003401
4	0.460273762	0.451330499	0.416117967	0.490748385	0.484408534
5	0.470775574	0.462153109	0.420857802	0.5073342	0.490473006
6	0.478653646	0.463483537	0.425928217	0.525648562	0.498358322
7	0.485542594	0.482578853	0.432065155	0.524684151	0.502516462
8	0.490546552	0.484296149	0.437380451	0.529882158	0.512027531
9	0.49847894	0.489181003	0.445787201	0.551809408	0.523051697
10	0.50576677	0.499545125	0.466984195	0.557342263	0.529637859
11	0.508283623	0.501025239	0.493459481	0.560057893	0.533626133
12	0.504211956	0.497893674	0.488866042	0.563228121	0.530636485
13	0.498870657	0.491184315	0.453072774	0.565658101	0.527930209
14	0.50071633	0.491304021	0.4398425	0.568590645	0.534087481
15	0.508036851	0.497144765	0.437580217	0.576367925	0.546242229
16	0.517584259	0.504298834	0.443856138	0.591664656	0.56136893
17	0.526365639	0.509204871	0.459625315	0.607597959	0.57997196
18	0.535472933	0.513214567	0.483442818	0.641602741	0.602234549
19	0.522767571	0.507471733	0.49494994	0.591884521	0.564634791
20	0.523073208	0.505691309	0.474053195	0.605878884	0.568057734
21	0.526343926	0.504503816	0.442008537	0.636533544	0.585297351
22	0.529346599	0.505379332	0.428595758	0.674799395	0.605231484
23	0.532458573	0.509432959	0.408928156	0.721703258	0.630539737
24	0.539384708	0.51348967	0.403357098	0.775809592	0.653291722
25	0.541851813	0.515013928	0.401244203	0.731993295	0.662352149

Tablo 5.19. Çan Şekilli Fonksiyon İle Belirlenen Üyelik Değerleri

5.4.3.5. Bulanık İlişkiler

5. Adım olarak bulanık ilişkiler belirlenir. Bulanık ilişkinin belirlenmesi için literatürde; matris hesaplama işlemleri, bulanık ilişki tabloları, yapay sinir ağı, genetik algoritma, çarpımsal nöron modele dayalı yaklaşımlar gibi yöntemler kullanılmaktadır. Bu çalışmada çok değişkenli yüksek dereceli bulanık zaman serisi

modeli için bulanık ilişkilerin belirlenmesinde, ileri beslemeli geriye yayımlı çok katmanlı yapay sinir ağı modeli kullanılmıştır.

Bulanık ilişkileri belirlemede kullanılan ileri beslemeli yapay sinir ağlarının girdi ve çıktı tabakasındaki nöron (düğüm) sayısı bulanık küme sayısına ($l = 5$) eşittir. Gizli tabakadaki nöronların sayısına ise deneme yanılma yolu ile karar verilecektir. Burada gizli tabaka birim sayısının ileri beslemeli yapay sinir ağının genelleştirme yeteneğini kaybetmeyecek şekilde seçilmesi (Yolcu, 2011: 40) gerekmektedir.

Yapay sinir ağının girdileri, her biri 16 reel sayıdan oluşan vektörlerin yukarıda belirlenen ($t - 1$) zamanındaki üyelik değerleridir. Hedef değerler ise aynı vektörlerin (t) zamanındaki üyelik değerleri olacaktır. Bu nedenle, 24 yıllık veri setinden 23 vektörden oluşan bir veri seti elde edilmiştir.

23 vektörlük veriden oluşan bu veri seti, öncelikle eğitim (training) ve test (testing) seti şeklinde ayrılacaktır. Bunun için veri setinin ilk %80' i ($23 * 0.8 = 18.4$) olan 18 vektöre ait veriler ($t = 2 - 19$ arası) eğitim, kalan 5 vektöre ait veriler ($t = 20 - 24$ arası) test veri seti olarak kullanılmıştır.

Çalışmamızda açık kaynak kodlu R programlama dili (R version 3.2.2 (2015-08-14), R-Project, 2015) ve R için bütünleşik bir geliştirme ortamı olan RStudio (RStudio Inc, Version 0.99.484 – © 2009-2015) kullanılmıştır. Programın çok katmanlı ileri beslemeli geriye yayımlı ağ kurmak için yazılmış olan “neuralnet” paketi (Fritsch ve Guenther, 2010) kodları yardımıyla ağ eğitilmiş, test değerleri sonuçları hesaplanmış ve ağın grafiği çizilmiştir.

Öğrenme algoritması olarak standart geriye yayılım (back-propagation) ve esnek geriye yayılım (resilient back-propagation) algoritmaları tercih edilmiş ve hata miktarları karşılaştırılmıştır.

Ağın girdi (g_1, g_2, g_3, g_4, g_5) ve hedef (h_1, h_2, h_3, h_4, h_5) değişkenlerinin farklı üyelik fonksiyonları için aldığı değerler Tablo 5.20, 5.21 ve 5.22' de gösterilmiştir.

	t	g1	g2	g3	g4	g5	h1	h2	h3	h4	h5
1	2	0.243	0.75	0.098	0.137	0.025	0.172	0.744	0.175	0.149	0.022
2	3	0.172	0.744	0.175	0.149	0.022	0.116	0.719	0.232	0.156	0.042
3	4	0.116	0.719	0.232	0.156	0.042	0.078	0.684	0.292	0.185	0.024
4	5	0.078	0.684	0.292	0.185	0.024	0.057	0.641	0.336	0.205	0.02
5	6	0.057	0.641	0.336	0.205	0.02	0.039	0.582	0.409	0.21	0.012
6	7	0.039	0.582	0.409	0.21	0.012	0.036	0.516	0.466	0.211	0.022
7	8	0.036	0.516	0.466	0.211	0.022	0.025	0.437	0.528	0.243	0.019
8	9	0.025	0.437	0.528	0.243	0.019	0.011	0.361	0.62	0.248	0.013
9	10	0.011	0.361	0.62	0.248	0.013	0.009	0.329	0.657	0.246	0.015
10	11	0.009	0.329	0.657	0.246	0.015	0.019	0.365	0.611	0.242	0.02
11	12	0.019	0.365	0.611	0.242	0.02	0.033	0.428	0.511	0.266	0.02
12	13	0.033	0.428	0.511	0.266	0.02	0.034	0.422	0.476	0.3	0.023
13	14	0.034	0.422	0.476	0.3	0.023	0.022	0.371	0.491	0.337	0.028
14	15	0.022	0.371	0.491	0.337	0.028	0.009	0.286	0.539	0.379	0.031
15	16	0.009	0.286	0.539	0.379	0.031	0.004	0.197	0.581	0.422	0.044
16	17	0.004	0.197	0.581	0.422	0.044	0.001	0.118	0.58	0.501	0.055
17	18	0.001	0.118	0.58	0.501	0.055	0.011	0.173	0.691	0.357	0.019
18	19	0.011	0.173	0.691	0.357	0.019	0.011	0.199	0.603	0.421	0.015
19	20	0.011	0.199	0.603	0.421	0.015	0.017	0.199	0.486	0.523	0.028
20	21	0.017	0.199	0.486	0.523	0.028	0.029	0.185	0.379	0.614	0.051
21	22	0.029	0.185	0.379	0.614	0.051	0.038	0.197	0.239	0.688	0.097
22	23	0.038	0.197	0.239	0.688	0.097	0.028	0.182	0.2	0.711	0.139
23	24	0.028	0.182	0.2	0.711	0.139	0.024	0.18	0.189	0.704	0.161

Tablo 5.20. Gaussian Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve

Hedef Değişkenleri

	t	g1	g2	g3	g4	g5	h1	h2	h3	h4	h5
1	2	0.49	0.526	0.481	0.362	0.204	0.481	0.522	0.483	0.368	0.211
2	3	0.481	0.522	0.483	0.368	0.211	0.47	0.517	0.484	0.375	0.221
3	4	0.47	0.517	0.484	0.375	0.221	0.464	0.514	0.485	0.379	0.226
4	5	0.464	0.514	0.485	0.379	0.226	0.458	0.512	0.486	0.383	0.231
5	6	0.458	0.512	0.486	0.383	0.231	0.454	0.51	0.487	0.386	0.234
6	7	0.454	0.51	0.487	0.386	0.234	0.449	0.508	0.487	0.389	0.239
7	8	0.449	0.508	0.487	0.389	0.239	0.443	0.505	0.488	0.394	0.245
8	9	0.443	0.505	0.488	0.394	0.245	0.437	0.503	0.489	0.397	0.249
9	10	0.437	0.503	0.489	0.397	0.249	0.435	0.502	0.489	0.399	0.251
10	11	0.435	0.502	0.489	0.399	0.251	0.438	0.503	0.489	0.397	0.249
11	12	0.438	0.503	0.489	0.397	0.249	0.441	0.504	0.489	0.395	0.247
12	13	0.441	0.504	0.489	0.395	0.247	0.438	0.503	0.489	0.397	0.249
13	14	0.438	0.503	0.489	0.397	0.249	0.432	0.5	0.49	0.401	0.256

14	15	0.432	0.5	0.49	0.401	0.256	0.423	0.497	0.491	0.407	0.263
15	16	0.423	0.497	0.491	0.407	0.263	0.415	0.493	0.492	0.413	0.272
16	17	0.415	0.493	0.492	0.413	0.272	0.405	0.488	0.494	0.42	0.282
17	18	0.405	0.488	0.494	0.42	0.282	0.419	0.495	0.492	0.41	0.267
18	19	0.419	0.495	0.492	0.41	0.267	0.418	0.494	0.492	0.41	0.268
19	20	0.418	0.494	0.492	0.41	0.268	0.412	0.492	0.493	0.415	0.275
20	21	0.412	0.492	0.493	0.415	0.275	0.406	0.489	0.494	0.42	0.282
21	22	0.406	0.489	0.494	0.42	0.282	0.399	0.486	0.495	0.425	0.291
22	23	0.399	0.486	0.495	0.425	0.291	0.391	0.482	0.496	0.431	0.3
23	24	0.391	0.482	0.496	0.431	0.3	0.388	0.481	0.496	0.433	0.303

Tablo 5.21. Sigmoidal Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve

Hedef Değişkenleri

t	g1	g2	g3	g4	g5	h1	h2	h3	h4	h5	
1	2	0.429	0.48	0.389	0.469	0.452	0.445	0.473	0.402	0.489	0.464
2	3	0.445	0.473	0.402	0.489	0.464	0.46	0.451	0.416	0.491	0.484
3	4	0.46	0.451	0.416	0.491	0.484	0.471	0.462	0.421	0.507	0.49
4	5	0.471	0.462	0.421	0.507	0.49	0.479	0.463	0.426	0.526	0.498
5	6	0.479	0.463	0.426	0.526	0.498	0.486	0.483	0.432	0.525	0.503
6	7	0.486	0.483	0.432	0.525	0.503	0.491	0.484	0.437	0.53	0.512
7	8	0.491	0.484	0.437	0.53	0.512	0.498	0.489	0.446	0.552	0.523
8	9	0.498	0.489	0.446	0.552	0.523	0.506	0.5	0.467	0.557	0.53
9	10	0.506	0.5	0.467	0.557	0.53	0.508	0.501	0.493	0.56	0.534
10	11	0.508	0.501	0.493	0.56	0.534	0.504	0.498	0.489	0.563	0.531
11	12	0.504	0.498	0.489	0.563	0.531	0.499	0.491	0.453	0.566	0.528
12	13	0.499	0.491	0.453	0.566	0.528	0.501	0.491	0.44	0.569	0.534
13	14	0.501	0.491	0.44	0.569	0.534	0.508	0.497	0.438	0.576	0.546
14	15	0.508	0.497	0.438	0.576	0.546	0.518	0.504	0.444	0.592	0.561
15	16	0.518	0.504	0.444	0.592	0.561	0.526	0.509	0.46	0.608	0.58
16	17	0.526	0.509	0.46	0.608	0.58	0.535	0.513	0.483	0.642	0.602
17	18	0.535	0.513	0.483	0.642	0.602	0.523	0.507	0.495	0.592	0.565
18	19	0.523	0.507	0.495	0.592	0.565	0.523	0.506	0.474	0.606	0.568
19	20	0.523	0.506	0.474	0.606	0.568	0.526	0.505	0.442	0.637	0.585
20	21	0.526	0.505	0.442	0.637	0.585	0.529	0.505	0.429	0.675	0.605
21	22	0.529	0.505	0.429	0.675	0.605	0.532	0.509	0.409	0.722	0.631
22	23	0.532	0.509	0.409	0.722	0.631	0.539	0.513	0.403	0.776	0.653
23	24	0.539	0.513	0.403	0.776	0.653	0.542	0.515	0.401	0.732	0.662

Tablo 5.22. Çan Şekilli Üyelik Fonksiyonu İçin Yapay Sinir Ağı Girdi ve

Hedef Değişkenleri

Ağ kurulurken gizli tabaka sayısı ve gizli tabakada bulunan düğüm sayısı araştırılacaktır. En küçük hatayı veren sayılar ağın sahip olduğu yapıyı belirleyecektir. Bu işlem üç veri setinin her biri için tekrarlanarak sonuçlar karşılaştırılacaktır.

5.4.3.6. Parametrelerin Seçimi ve Model Değerlendirme

Bulanık ilişkilerin belirlenmesinde kullanılan yapay sinir ağı, çok katmanlı ileri beslemeli geriye yayımlı ağıdır. Geri yayılım algoritması adı verilen metodun kullanıldığı bu tür ağlarda öğrenme, hataların geriye doğru çıkıştan girişe azaltılmaya çalışılması prensibi ile gerçekleşmektedir. Geri yayımlı öğrenme kuralı ağın çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Bir geri yayımlı ağ modelinde bir giriş, problemin özelliklerine göre bir veya daha fazla gizli ve bir çıkış katmanı bulunmaktadır. Çalışmamızda ağın girdi ve çıkış katmanlarına verilecek değerler, üyelik fonksiyonları yardımı ile elde edilen üyelik değerleri olduğu için 5' er adet nöron bulunacaktır.

Ancak bu ağlarda gizli katman ve bu katmanda bulunacak düğüm (nöron) sayısı için genel olarak bir ölçüt yoktur ve genellikle deneme yanılma bulunur. Bu katman ağın temel işlevini gören katman olup gizli katman sayısı ve katmandaki nöron sayısı probleme göre değişir. Gizli katman giriş katmanından aldığı ağırlıklandırılmış veriyi bir fonksiyonla işleyerek bir sonraki katmana iletir. Gizli katmanda gereğinden az nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olurken, gerektiğinden fazla sayıda nöron kullanılması durumunda ise ağda yeni veri gruplarının işlenmesinde zorluklar ortaya çıkmaktadır (Çetin, Uğur ve Bayzan, 2006). Katman sayısının artırılması ise, hem ağın öğrenebilmesi için gereken adım (döngü) sayısını ve dolayısıyla eğitim süresini hem de ağın öğrenmek ve genellemek yerine ezberleme olasılığını artıracaktır (Aslay ve Özen, 2013: 142). Literatürde pek çok çalışmada genellikle bir veya iki gizli katmanlı modellerin daha iyi sonuçlar verdiği ve özellikle tek gizli katmanlı modellerin tercih edildiği söylenebilir. Fakat ağın performansı yeterli görülmezse gizli katman sayısı ve bu katmanlardaki nöron sayısı aşamalı olarak artırılmalıdır.

Burada dikkat edilmesi gereken, katmanlardaki nöron sayısının dengeli bir şekilde tespit edilmesi gerektiğidir. Fakat gizli katman sayısının dörtten fazla olması pek de tavsiye edilmemektedir. (De Villiers ve Bernard, 1992: 139) Ağdaki katman ve nöron sayıları ile ilgili daha kesin tespitlerin yapıldığı çalışmalar da mevcuttur. Örneğin Karsoliya (2012); Boger ve Guterman (1997), Berry ve Linoff (2011) ve Blum (1992)' un çalışmalarında önerdikleri kısıtları sentezleyerek dört kural geliştirmiştir. Bunlar:

- Her bir gizli katmandaki gizli nöronların sayısı, girdi nöronlarının sayısının 2/3' ü veya %70' i ile %90' ı arası sayıda olmalıdır. Eğer bu yetersiz ise, çıkış katmanı nöronları daha sonra ilave edilebilir.
- Gizli katman nöronlarının toplam sayısı, girdi katmanındaki nöron sayısının iki katını aşmamalıdır.
- Gizli katman nöronlarının sayısı girdi ve çıktı nöronlarının sayısı arasında olmalıdır.
- Dolayısıyla tüm bu şartları sağlayabilmek için en fazla üç gizli katman kullanılmalıdır.

Bailey ve Thomson (1990) bir gizli katman kullanılan ağda bu gizli katmandaki nöron sayısının, girdi katmandaki nöron sayısının %75' i olması gerektiğini, Katz (1992) ise en uygun gizli nöron sayısının, giriş katmanındaki nöron sayısının 1.5-3 katı arası olduğunu söylemektedirler. Doig (1999) daha kesin bir yöntem önererek aşağıdaki formül yardımı ile gizli katmandaki nöron sayısını hesaplamaktadır:

$$N_{hid} = \frac{\frac{1}{2}(N_{in}+N_{out})+\sqrt{N_{cases}}}{N_{slabs}}$$

N_{hid} : Gizli Katmandaki Nöron Sayısı

N_{in} : Girdi Katmanındaki Nöron Sayısı

N_{out} : Çıktı Katmanındaki Nöron Sayısı

N_{slabs} : Toplam Katman Sayısı

N_{cases} : Gözlem Sayısı

Getirilen bu öneriler değerlendirildiğinde, hemen hemen birbirine yakın sayıda gizli tabaka ve nöron elde edildiği görülebilir. Kuracağımız ağda girdi katmanında 5, çıktı katmanında 5 nöron ve 23 gözlem bulunduğuna göre; Karsoliya (2012)' ya göre toplam nöron sayısı 10' u aşmayacak şekilde en fazla 3 gizli katman, Bailey ve Thomson (1990)' a göre en fazla 4 nöronlu 1 gizli katman, Katz (1992)' a göre toplam 8-15 arası gizli nöron bulunan gizli katmanlar ve Doig (1999)' e göre ise toplam nöron sayısı 10' u aşmayacak şekilde gizli katmanlar olmalıdır.

Tüm bu yaklaşımların yanında unutulmaması gereken husus, gizli katman ve bu katmanlardaki nöron sayısının yalnızca girdi veya çıktı katmandaki nöron sayıları ile belirlenemeyeceğidir. Bunların dışında problemin karmaşıklığı, verinin doğrusallık içerip içermediği, seçilen aktivasyon fonksiyonları, ağın mimarisi, öğrenme algoritması ve eğitimde kullanılan veriler de bu seçimde belirleyici olmaktadır. Bu sebeple, en iyi genellemeyi veren mümkün olduğunca en az sayıda katman ve nöronda karar kılınmaya çalışılmalıdır. Bunun için eğitim aşamasından sonra test sonuçlarının da incelenmesi gerekecektir.

Bu çalışmada da gizli tabaka ve nöron sayıları, ağın ürettiği çıktı değerleri ile hedef değerleri arasındaki hatayı minimize edecek şekilde deneme yanılma yoluyla belirlenecektir. Burada kullanılan hata fonksiyonu HKT-Hata Kareleri Toplamı (Sum of Squared Errors-SSE) olarak seçilmiştir. Hem yukarıda getirilen sistematik yaklaşımlar sonucu elde edilen nöron sayıları ile 3 gizli katmana kadar, hem de 4 gizli katmana kadar daha fazla gizli nöron sayıları için sonuçlar araştırılmıştır.

Hesaplanan hata miktarının belli bir değerin altında kalması istendiğinde, ağa bir eşik değeri (treshold) belirlenerek, hata fonksiyonunun kısmi türevleri mutlak değerce bu değere ulaşınca kadar eğitime devam etmesi sağlanabilmektedir. Bu parametre, çalışmamızda 0.01 ve 0.001 olarak denenmiş ve 0.001 değeri için iyi sonuçlar bulunmuştur.

Standart geri yayılma algoritması (traditional back-propagation), birçok uygulamada çok uzun eğitim süresine sahip olması nedeniyle pratiklik sağlayamamaktadır. Bu nedenle algoritmada yakınsamayı hızlandırmak için bazı metotlar geliştirilmiştir. Bunlardan birisi de esnek geriye yayılma (resilient back-

propagation) algoritmasıdır. Standart geriye yayılım algoritması dereceli azalma (gradient descent) algoritması temelli iken, esnek geriye yayılım algoritmasında kısmi türevin büyüklüğünün ağırlık artışının üzerindeki kötü etkisinin giderilmesi amaçlanmaktadır (Riedmiller, 1994). Esnek geriye yayılım algoritmasının bir avantajı da kısa sürede uyum sağlaması ve hızlı sonuç vermesidir. Bu nedenle hem standart hem esnek geriye yayılım algoritmaları kullanılmış, sonuçlar karşılaştırılmıştır. En iyi sonuçların esnek geriye yayılma öğrenme algoritması ile elde edildiği görülmüştür.

Yapay sinir ağında bir diğer önemli parametre ise aktivasyon fonksiyonudur. Bir yapay sinir hücresindeki bu fonksiyon, hücreye gelen net girdileri hesaplayarak üretilecek olan çıktı değerini belirler. Aktivasyon fonksiyonlarının lineer fonksiyon, step fonksiyon, sinüs fonksiyonu, eşik değer fonksiyonu, sigmoid fonksiyonları (hiperbolik tanjant veya tanjant sigmoid ve logaritmik sigmoid) olmak üzere değişik kullanımları mevcuttur. Uygulamaların çoğunda özellikle çok katmanlı ileri beslemeli tasarlanan ağlarda genel olarak sigmoid fonksiyonlarının tercih edildiği görülmektedir (Çevik ve Dandıl, 2012). Bu sebeple çıktı değerlerinin hesaplanmasında tanjant sigmoid ve logaritmik sigmoid fonksiyonları ayrı ayrı denenerek en iyi sonucu veren modellerin seçilmesi planlanmıştır. Bu fonksiyonların genel formu;

Logaritmik Sigmoid:
$$f(x) = \frac{1}{1 + e^{-\theta x}}$$

Tanjant Hiperbolik:
$$f(x) = \frac{2}{1 + e^{-2x}} - 1$$

şeklindedir.

Ancak tanjant sigmoid (hiperbolik tanjant) fonksiyonu negatif değerler üretebildiği için ağırlık çıktılarının negatif olmasına sebep olmaktadır. Bu ise üyelik değerleri $[0,1]$ aralığından değer alacağından arzu edilmeyen bir durumdur. Bu sebeple daha düşük hata payı vermesine rağmen bu fonksiyon aktivasyon fonksiyonu olarak kullanılmamıştır. Logaritmik sigmoid fonksiyonu, tüm katmanlarda aktivasyon fonksiyonu olacaktır. Ayrıca bu fonksiyon çıktı katmanına da

uygulanması, üretilen değerlerin [0,1] aralığında olmasını garanti altına alacaktır. Bu sebeple ağda çıktı katmanına uygulanan ve uygulanmayan sonuçlar ayrı ayrı incelenmiştir. Gaussian fonksiyonu ile üretilen üyelik değerleri ile eğitilen ağda, çıktı katmanında logaritmik sigmoid aktivasyon fonksiyonu ile daha iyi sonuçların elde edildiği görülmüştür. Çünkü aksi halde negatif çıktı değerleri hesaplanmaktadır ki üyelik değerlerinin [0,1] aralığında olması gerektiğinden bu istenmeyen bir durumdur.

Standart geriye yayılım algoritmasında kullanılan bir diğer parametre ise öğrenme katsayısıdır. Yapay sinir ağlarındaki geriye yayılma algoritmasında yer alan ve öğrenme oranı da (learning rate) denen bu parametre eğitim hızını da belirlemektedir. Öğrenme katsayı arttıkça eğitim hızı artmakta yani başka bir deyişle ağırlık değerlerinin güncelleme işleminin sayısı azalmaktadır. Bu sebeple daha hassas sonuç elde etmek için öğrenme katsayısı düşük tutulmalıdır. Çalışmamızda bu katsayı, standart geriye yayılma algoritması kullanıldığında, 0.01 olarak alınmıştır.

Öte yandan belirlenmesi gereken bir diğer parametre de öğrenme sayısı ya da iterasyon/yineleme (repetition) sayısıdır. Ağın verilen bilgiyi öğrenmesi için eğitim sayısı artırılarak tekrar tekrar eğitilebilir. Böylelikle ağ verilerdeki değişimler devamlı ise eğitime de devam eder ve en iyi sonuca ulaşmaya çalışılır. Çalışmamızda bu sayı da farklı değerler ile denenerek sonuçlar karşılaştırılmıştır.

Yapay sinir ağları eğitim sürecinde kullanılan parametreler Tablo 5.23' de özetlenmiştir.

Parametre	Kısaltması	Aldığı Değerler
Öğrenme Algoritması	Alg.	Standart Geriye Yayılım (bprop), Esnek Geriye Yayılım (r-bprop)
Aktivasyon Fonksiyonu	Akt. Fonk.	Logaritmik Sigmoid (logsig)
Gizli Tabaka Sayısı	-	1-4 Arası
Gizli Nöron Sayısı	-	1-40 Arası
Öğrenme (İterasyon) Sayısı	rep.	En az 1

Adım Sayısı	-	En az 1
Eşik (treshold) Değeri	-	0.01 ve 0.001
Hata Değeri	Hata	> 0
Hata Fonksiyonu	Hata Fonk.	Hata Kareleri Toplamı (HKT / SSE)

Tablo 5.23. YSA Eğitim Sürecinde Kullanılan Parametreler

Bulanık ilişkileri belirlemek için kurulan çok katmanlı ileri beslemeli geriye yayımlı ağ, R programlama dili “neuralnet” paketi (Fritsch ve Guenther, 2010) kodları yardımıyla eğitilmiş, test değerleri sonuçları hesaplanmış ve ağın grafiği çizilmiş olup kullanılan R kodları Ek-13’ te verilmiştir. Parametreler değiştirilerek en iyi sonuçlar elde edilmeye çalışılmış olup farklı bazı parametreler için yapay sinir ağı eğitim aşaması bazı sonuçları Tablo 5.24, 5.25 ve 5.26’ da özetlenmiştir (Tüm sonuçlar için bkz. Ek-14, 15 ve 16).

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğrenme Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katmanı Akt. Fonk.
1	1	5	360	r-bprop	0,0588	0,0010	Sig.
1	1	4	376	r-bprop	0,0589	0,0009	Sig.
1	1	3	53191	bprop	0,0657	0,0010	Sig.
1	4	5	732	r-bprop	0,0230	0,0009	Sig.
1	5	4	1584	r-bprop	0,0147	0,0010	Sig.
1	5	2	95070	bprop	0,0410	0,0010	Sig.
1	9	4	631	r-bprop	0,0140	0,0010	Sig.
1	10	2	958	r-bprop	0,0131	0,0010	Sig.
1	10	1	97140	bprop	0,0385	0,0010	Sig.
1	15	10	645	r-bprop	0,0138	0,0010	Sig.
1	15	2	47617	bprop	0,0427	0,0010	Sig.
1	18	14	1286	r-bprop	0,0130	0,0009	Sig.
1	30	11	591	r-bprop	0,0138	0,0009	Sig.
1	40	27	1710	r-bprop	0,0067	0,0009	Sig.
2	(1-1)	2	521	r-bprop	0,0585	0,0009	Sig.
2	(1-2)	2	646	r-bprop	0,0397	0,0010	Sig.
2	(1-14)	10	662	r-bprop	0,0293	0,0010	Sig.

2	(2-2)	1	1551	r-bprop	0,0254	0,0010	Sig.
2	(3-12)	2	887	r-bprop	0,0143	0,0010	Sig.
2	(5-10)	4	486	r-bprop	0,0145	0,0008	Sig.
2	(7-5)	9	759	r-bprop	0,0140	0,0010	Sig.
2	(9-3)	3	1208	r-bprop	0,0065	0,0009	Sig.
2	(11-4)	13	864	r-bprop	0,0074	0,0009	Sig.
2	(12-3)	11	775	r-bprop	0,0153	0,0010	Sig.
2	(15-3)	3	1847	r-bprop	0,0109	0,0009	Sig.
2	(20-3)	4	1055	r-bprop	0,0128	0,0010	Sig.
2	(32-12)	16	500	r-bprop	0,0118	0,0010	Sig.
3	(1-1-1)	19	482	r-bprop	0,0580	0,0009	Sig.
3	(1-1-2)	4	476	r-bprop	0,0579	0,0010	Sig.
3	(2-1-1)	8	713	r-bprop	0,0561	0,0009	Sig.
3	(2-11-2)	2	830	r-bprop	0,0261	0,0010	Sig.
3	(4-8-3)	9	659	r-bprop	0,0165	0,0010	Sig.
3	(5-5-5)	15	734	r-bprop	0,0136	0,0010	Sig.
3	(6-6-6)	18	1191	r-bprop	0,0114	0,0008	Sig.
3	(7-2-3)	2	720	r-bprop	0,0182	0,0010	Sig.
3	(8-5-2)	3	1833	r-bprop	0,0067	0,0009	Sig.
3	(8-5-2)	2	79535	bprop	0,0447	0,0010	Sig.
3	(8-9-3)	12	1550	r-bprop	0,0051	0,0009	Sig.
3	(12-2-1)	14	782	r-bprop	0,0494	0,0009	Sig.
3	(18-22-3)	15	965	r-bprop	0,0039	0,0009	Sig.
3	(22-18-6)	11	1303	r-bprop	0,0018	0,0010	Sig.
3	(22-18-6)	2	99723	bprop	0,0354	0,0010	Sig.
3	(24-16-9)	8	570	r-bprop	0,0035	0,0009	Sig.
4	(12-4-16-9)	5	597	r-bprop	0,0105	0,0010	Sig.
4	(22-24-16-9)	6	743	r-bprop	0,0027	0,0009	Sig.
4	(28-25-24-20)	13	471	r-bprop	0,0036	0,0008	Sig.

Tablo 5.24. Gaussian Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğr. Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katm. Akt. Fonk.
1	1	4	596	r-bprop	0,0006	0,0008	Lin.
1	1	1	207	r-bprop	0,0030	0,0009	Sig.
1	2	3	3048	r-bprop	0,0008	0,0006	Lin.

1	3	2	395	r-bprop	0,0006	0,0008	Lin.
1	4	3	338	r-bprop	0,0007	0,0010	Lin.
1	5	1	344	r-bprop	0,0007	0,0009	Lin.
1	8	5	865	r-bprop	0,0007	0,0009	Lin.
1	9	4	392	r-bprop	0,0007	0,0010	Lin.
1	10	4	371	r-bprop	0,0007	0,0010	Lin.
1	16	3	412	r-bprop	0,0007	0,0010	Lin.
1	21	5	314	r-bprop	0,0007	0,0007	Lin.
1	30	8	447	r-bprop	0,0007	0,0007	Lin.
2	(1-1)	1	576	r-bprop	0,0008	0,0008	Lin.
2	(1-5)	3	1278	r-bprop	0,0007	0,0008	Lin.
2	(1-18)	9	388	r-bprop	0,0006	0,0008	Lin.
2	(2-2)	7	704	r-bprop	0,0006	0,0009	Lin.
2	(2-13)	8	712	r-bprop	0,0007	0,0010	Lin.
2	(6-6)	5	501	r-bprop	0,0007	0,0006	Lin.
2	(6-9)	3	380	r-bprop	0,0006	0,0007	Lin.
2	(6-9)	3	65057	bprop	0,0010	0,0010	Lin.
2	(10-5)	2	1061	r-bprop	0,0006	0,0009	Lin.
2	(10-5)	4	50587	bprop	0,0009	0,0010	Lin.
2	(10-12)	2	611	r-bprop	0,0007	0,0009	Lin.
2	(18-10)	9	265	r-bprop	0,0006	0,0010	Lin.
2	(24-8)	6	309	r-bprop	0,0006	0,0009	Lin.
2	(32-9)	4	408	r-bprop	0,0006	0,0008	Lin.
3	(1-1-1)	5	42	r-bprop	0,0088	0,0008	Lin.
3	(1-5-2)	9	2287	r-bprop	0,0009	0,0009	Lin.
3	(1-12-1)	2	294	r-bprop	0,0007	0,0009	Lin.
3	(2-1-7)	11	1342	r-bprop	0,0008	0,0009	Lin.
3	(2-3-8)	1	387	r-bprop	0,0007	0,0007	Lin.
3	(8-9-4)	7	441	r-bprop	0,0007	0,0010	Lin.
3	(20-16-4)	25	258	r-bprop	0,0006	0,0010	Lin.
3	(25-16-9)	24	344	r-bprop	0,0006	0,0008	Lin.
3	(32-16-8)	3	306	r-bprop	0,0006	0,0008	Lin.
4	(1-1-1-1)	2	38	r-bprop	0,0088	0,0005	Lin.
4	(3-6-12-24)	33	396	r-bprop	0,0006	0,0009	Lin.
4	(8-10-9-8)	11	342	r-bprop	0,0006	0,0005	Lin.
4	(10-10-10-10)	6	299	r-bprop	0,0006	0,0009	Lin.
4	(16-8-8-16)	18	284	r-bprop	0,0006	0,0005	Lin.
4	(24-12-6-3)	11	9367	r-bprop	0,0005	0,0010	Lin.
4	(25-16-8-4)	5	366	r-bprop	0,0006	0,0009	Lin.
4	(32-16-8-4)	12	598	r-bprop	0,0006	0,0006	Lin.
4	(32-16-8-4)	30	195	r-bprop	0,0007	0,0010	Sig.

4	(32-16-9-9)	16	412	r-bprop	0,0006	0,0010	Lin.
4	(32-32-32-32)	24	253	r-bprop	0,0006	0,0009	Lin.

Tablo 5.25. Sigmoidal Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğr. Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katm. Akt. Fonk.
1	1	5	6905	r-bprop	0,0057	0,0010	Lin.
1	1	5	712	r-bprop	0,0055	0,0009	Sig.
1	2	1	8508	r-bprop	0,0055	0,0009	Lin.
1	2	2	515	r-bprop	0,0057	0,0010	Sig.
1	3	10	869	r-bprop	0,0050	0,0010	Lin.
1	5	7	527	r-bprop	0,0052	0,0009	Sig.
1	7	4	1818	r-bprop	0,0048	0,0010	Lin.
1	10	12	982	r-bprop	0,0047	0,0009	Lin.
1	10	2	523	r-bprop	0,0056	0,0009	Sig.
1	20	27	1402	r-bprop	0,0051	0,0010	Lin.
1	20	9	150	r-bprop	0,0054	0,0007	Sig.
1	40	5	1898	r-bprop	0,0043	0,0008	Lin.
2	(1-1)	10	3581	r-bprop	0,0053	0,0009	Lin.
2	(1-1)	8	229	r-bprop	0,0063	0,0009	Sig.
2	(1-5)	9	768	r-bprop	0,0056	0,0009	Lin.
2	(2-1)	3	5050	r-bprop	0,0053	0,0010	Lin.
2	(2-13)	6	1569	r-bprop	0,0052	0,0009	Lin.
2	(6-6)	15	1178	r-bprop	0,0049	0,0009	Lin.
2	(6-9)	8	1874	r-bprop	0,0054	0,0008	Lin.
2	(10-5)	2	1286	r-bprop	0,0043	0,0005	Lin.
2	(15-3)	9	1182	r-bprop	0,0067	0,0009	Lin.
2	(15-15)	5	293	r-bprop	0,0044	0,0005	Lin.
2	(24-6)	13	922	r-bprop	0,0057	0,0007	Lin.
2	(30-30)	26	920	r-bprop	0,0038	0,0007	Lin.
3	(1-1-1)	4	74	r-bprop	0,0387	0,0009	Lin.
3	(1-1-12)	7	1071	r-bprop	0,0059	0,0006	Lin.
3	(1-2-9)	10	1289	r-bprop	0,0057	0,0009	Lin.
3	(1-5-9)	1	952	r-bprop	0,0061	0,0009	Lin.
3	(5-3-3)	14	1363	r-bprop	0,0057	0,0009	Lin.
3	(5-5-5)	2	1005	r-bprop	0,0051	0,0010	Lin.
3	(5-6-4)	5	2146	r-bprop	0,0052	0,0010	Lin.

3	(11-1-2)	14	10123	r-bprop	0,0053	0,0010	Lin.
3	(11-2-1)	3	9874	r-bprop	0,0037	0,0010	Lin.
3	(11-2-1)	2	49	bprop	0,0396	0,0008	Lin.
3	(11-2-2)	9	3416	r-bprop	0,0039	0,0010	Lin.
3	(11-2-2)	2	48741	bprop	0,0058	0,0010	Lin.
3	(12-1-2)	4	13810	r-bprop	0,0050	0,0009	Lin.
3	(12-2-1)	8	9706	r-bprop	0,0039	0,0010	Lin.
3	(12-2-1)	4	93382	bprop	0,0058	0,0010	Lin.
3	(20-4-14)	20	744	r-bprop	0,0055	0,0008	Lin.
3	(20-18-16)	1	949	r-bprop	0,0041	0,0008	Lin.
3	(25-20-18)	6	1336	r-bprop	0,0036	0,0009	Lin.
3	(30-32-28)	43	901	r-bprop	0,0037	0,0007	Lin.
4	(12-10-8-5)	42	2821	r-bprop	0,0040	0,0009	Lin.
4	(24-16-18-9)	12	1892	r-bprop	0,0022	0,0009	Lin.
4	(24-18-16-9)	11	926	r-bprop	0,0038	0,0010	Lin.

Tablo 5.26. Çan Şekilli Fonksiyon Üyelik Değerleri YSA Eğitim Sonuçları

Alınan sonuçlara göre, Gaussian üyelik fonksiyonu ile elde edilen üyelik değerleri arasındaki bulanık ilişkileri öğrenmek için kurulan yapay sinir ağı, gizli katman ve bu katmanlardaki nöron sayısı sınırlandırılmadan toplam hata değerini minimize edecek şekilde oluşturulursa; 1 giriş, 3 gizli ve 1 çıkış katmanından oluşacak olup giriş katmanında 5, gizli katmanlarda 22, 18 ve 6, çıkış katmanında ise 5 nörondan oluşacaktır. Ağ esnek geriye yayılım algoritması ile eğitilmiş olup tüm katmanlarda Logaritmik Sigmoid aktivasyon fonksiyonu kullanılmıştır. Eğitim sürecinde, hata fonksiyonunun (HKT) kısmi türevlerinin mutlak değerleri 0.001' den (varsayılan eşik) küçük olana kadar ağın 11 iterasyonda 1303 adım eğitilmesi gerekmiştir. Bu durumda ağın toplam hatası 0.0018 olmaktadır.

Aynı yaklaşımla Sigmoidal üyelik fonksiyonu ile elde edilen üyelik değerleri arasındaki bulanık ilişkileri öğrenmek için kurulan yapay sinir ağı; 1 giriş, 4 gizli ve 1 çıkış katmanından oluşacak olup giriş katmanında 5, gizli katmanlarda 24, 12, 6 ve 3, çıkış katmanında ise 5 nörondan oluşacaktır. Ağ esnek geriye yayılım algoritması ile eğitilmiş olup çıktı katmanı hariç tüm katmanlarda Logaritmik Sigmoid aktivasyon fonksiyonu kullanılmıştır. Eğitim sürecinde, hata fonksiyonunun (HKT) kısmi türevlerinin mutlak değerleri 0.001' den (varsayılan eşik) küçük olana kadar

5.4.3.7. Ağın Performansı

Ağın eğitilmesi sonucunda elde edilen katsayılarla ağın performansının ölçülmesi gerekmektedir. Bunun için önce eğitim sonucunda elde edilen sonuçlar incelenmiştir.


Eğitim sonunda YSA ile sistemin genel karakteristik yapısı ağa öğretilmiştir. Modelin performans değerlendirmesi için önce 18 tane eğitim verisi için tahmin değerleri alınmış ve gerçek değerler ile karşılaştırılarak hata değerleri oluşturulmuştur. Ek 17-26' da farklı modeller ile elde edilen tahminler ile gerçek verilerin değerlerini ve hata değerlerini gösteren tablolar görülmektedir. Burada ayrıca ileri beslemeli ve geri yayımlı YSA yöntemi kullanılarak önerilen modellerin her biri için Hata Karelerinin Toplamı (HKT), Hata Karelerinin Ortalaması (HKO), Hataların Karelerinin Ortalamasının Karekökü (HKOK) ve Ortalama Mutlak Yüzde Hata (OMYH) değerleri bulunmuştur. HKOK, beş serinin her biri için gözlenen (hedef) ve tahmin edilen (çıktı) veri değerlerinin farklarının aritmetik ortalamalarının karelerinin toplanıp, toplam veri sayısına bölünmesiyle elde edilen değer kareköküdür. İstenen değer ile yapay sinir ağı modelinin üretmiş olduğu çıktı arasındaki hatayı karesel olarak gösteren parametredir. Bu değer sifıra yakın olması, tahmin edilen değer kuvvetli biçimde doğruya yakınsadığını gösterecektir. OMYH, hataların mutlak değerlerinin ortalamasının gerçek değerlerin yüzdesi olarak gösterilmesidir. Aslay ve Özen' in aktardığına göre (Aslay ve Özen, 2013); Witt ve Witt, OMYH değerleri %10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise doğru tahminler olarak, Lewis ise OMYH değeri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır.

Farklı modeller için hesaplanan sonuçlar Tablo 5.27' de özetlenmiştir.


Üyelik Tipi	Gizli Katman		HKT	HKO	HKOK	OMYH (%)
	Sayısı	Gizli Nöron Sayısı				
Gaussian	3	(22-18-16)	0.00046	2.6E-05	0.00508	12.3609
Gaussian	2	(9-3)	0.00165	9.2E-05	0.00958	18.6224
Gaussian	3	(8-5-2)	0.00174	9.7E-05	0.00984	22.7666
Sigmoidal	4	(24-12-6-3)	0.00017	9.7E-06	0.00311	0.66114
Sigmoidal	2	(6-9)	0.0002	1.1E-05	0.00332	0.68485
Sigmoidal	2	(10-5)	0.0002	1.1E-05	0.00332	0.70372
Çan Şekilli	4	(24-16-8-9)	0.00054	3E-05	0.00548	1.03337
Çan Şekilli	3	(11-2-2)	0.00094	5.2E-05	0.00723	1.33013
Çan Şekilli	3	(12-2-1)	0.00084	4.6E-05	0.00681	1.30143
Çan Şekilli	3	(11-2-1)	0.00079	4.4E-05	0.00662	1.2141

Tablo 5.27. YSA Eğitim Sonuçlarına Göre Ağ Modellerinin Karşılaştırılması


Bu sonuçlara göre, eğitim verileri için en iyi sonuç, HKOK değeri sıfıra en yakın ve OMYH değeri en küçük olan Sigmoidal üyelik fonksiyonu ile üretilen üyelik değerleri ile kurulan ve 1 girdi (5 nöronlu) , 4 gizli (24, 12, 6 ve 3 nöronlu) ve 1 çıktı (5 nöronlu) katmanından oluşan ağ modeli için (HKOK =0.00311, OMYH=% 0.66) elde edilmiştir. Genel olarak da bu fonksiyon ile üretilen değerler için kurulan her üç modelde de yakın değerler elde edilmektedir. Yani 2 gizli katmandan oluşan ağlar da (HKOK =0.00332, OMYH=% 0.68-0.70) ağın karmaşıklığını ortadan kaldırmak için tercih edilebilir. Bu sebeple 2 gizli katman ve bu katmanlarda sırasıyla (6-9) ve (10-5) nöron bulunan ağ modeli de bundan sonraki aşamalarda test edilecektir. Ayrıca Gaussian üyelik fonksiyonu ile üretilen üyelik değerleri için 3 gizli katman, Çan Şekilli üyelik fonksiyonu ile üretilen üyelik değerleri için 4 veya 3 gizli katman ile kurulacak ağların tercih edilebileceği görülmüştür. Gözlem değerleri ile tahmin değerlerini birlikte gösteren grafikler aşağıda verilmiştir.



Şekil 5.12. Gaussian fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği



Şekil 5.13. Sigmoidal fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği



Şekil 5.14. Çan Tipi fonksiyonu üyelik değerleri için YSA hedef ve çıktı değerleri grafiği

Elde edilen bu sonuçlar hedef ve elde edilen çıktı değerler arasındaki korelasyonun çok yüksek ve anlamlı olduğunu belirtmektedir. Ayrıca oluşturulan modelin performansının da oldukça başarılı olduğunun bir göstergesidir.

5.4.3.8. Yapay Sinir Ağı Test Sonuçları


Eğitim sonucunda seçilen elde edilen katsayılarla ağın performansının, ağa verilmemiş yeni verilerle test edilmesi gerekmektedir. Bunun için, daha önce ayrılmış olan 5 verinin girdi değerleri ağa verilmiş, üretilen çıktılar eldeki gözlem değerleri ile yine HKOK ve OMYH yardımı ile karşılaştırılmıştır. Sonuçların detayları Ek-27' de, özeti ise Tablo 5.28' de verilmiştir. Bu sonuçlara göre, test verileri için de her üç modelde HKOK değeri sifıra yakın, OMYH ise %2' nin altında gerçekleşmiştir.

Üyelik Tipi	Gizli Katman		HKT	HKO	HKOK	OMYH (%)
	Sayısı	Gizli Nöron Sayısı				
Sigmoidal	4	(24-12-6-3)	0.00025	4.9E-05	0.00701	1.86083
Sigmoidal	2	(6-9)	0.00019	3.8E-05	0.00619	1.75159
Sigmoidal	2	(10-5)	0.00016	3.1E-05	0.00558	1.41309

Tablo 5.28. YSA Test Sonuçları

Bu sonuçlara göre, test verileri için en iyi sonucu veren ve 2 gizli katmanda sırası ile 10 ve 5 nörondan oluşan ileri beslemeli geriye yayımlı ağı çıktıkları elde edilerek öngörü için kullanılabilir.

En iyi sonucu vermesi nedeniyle seçilen bu ağa ait grafik Şekil 5.15' de verilmiştir.



Şekil 5.16. İki Gizli Katmanlı Yapay Sinir Ağı

5.4.3.9. Öngörülerin Durulaştırılması:

6. adım olarak öngörüler durulaştırılır.

Yapay sinir ağında elde edilen çıktılar, $(t - 1)$ zamanındaki gözlemlerin bulanık aralıklara üyelik derecelerinin ağa verilmesi ile elde edilen ve (t) zamana ait

gözelemlerin üyelik değeri leridir. Bu üyelik değeri lerini yardımcı ile gerç ek öngörü değeri lerini hesaplanabilir. Eğitim seti ile öğrenen ağda test seti için elde edilen çıktı değeri lerini olan öngörüler Tablo 5.29' da görülmektedir. Burada bulanıklaştırma yapılan işlemler tersine yapılarak öngörüler durulaştırılmalıdır.

t	g1	g2	g3	g4	g5	o1	o2	o3	o4	o5
20	0,418	0,494	0,492	0,41	0,268	0,42	0,494	0,493	0,409	0,27
21	0,412	0,492	0,493	0,415	0,275	0,415	0,492	0,493	0,412	0,276
22	0,406	0,489	0,494	0,42	0,282	0,41	0,489	0,494	0,416	0,284
23	0,399	0,486	0,495	0,425	0,291	0,405	0,486	0,494	0,42	0,293
24	0,391	0,482	0,496	0,431	0,3	0,399	0,483	0,494	0,424	0,302

Tablo 5.29. YSA Test verileri için girdi ve çıktı değeri lerini

Yapılan çalışmalarda en çok kullanılan yöntemin merkezileştirme yöntemi olduğu görülmektedir. Bu yöntem e göre, bulunan üyelik değeri lerini önce toplamları 1 olacak şekilde ağırlıklara dönüştürülmekte, sonrasında her bir ağırlık ait olduğu aralık (küme) merkezi ile çarpılarak sonuçlar toplanmakta ve öngörü değeri elde edilmektedir.

Burada önerilen yöntem ise şu şekildedir:

Bilindiği gibi bu üyelik değeri lerini, bir (t) zamandaki,

$$(nx_1^{(t)}, nx_2^{(t)}, nx_5^{(t)}, \dots, nx_{34}^{(t)}, nx_1^{(t-1)}, nx_2^{(t-1)}, nx_5^{(t-1)}, \dots, nx_{34}^{(t-1)})$$

değeri lerinden oluşan 16 elemanlı vektörün her bir elemanı için Sigmoidal üyelik fonksiyonu yardımcı ile elde edilen üyelik değeri lerinin, koentegrasyon yöntemi ile elde edilen ARDL tahmin modelinde bulunan katsayıların mutlak değeri lerini ile ağırlıklandırılmış ağırlıklı aritmetik ortalamasıdır.

Yani 5 aralık için üyelik fonksiyonları,

$$\mu_1(x, a_1, a_2), \mu_2(x, a_1, a_2), \mu_3(x, a_1, a_2), \mu_4(x, a_1, a_2) \text{ ve } \mu_5(x, a_1, a_2)$$

olmak üzere, Sigmoidal fonksiyonu;

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

ve bölüm 5.4.3.4' de daha önce belirlenen 1. aralık için $a_1 = -0.7$ ve $a_2=0.1$, 2. aralık için $a_1 = -0.3$ ve $a_2=0.5$, 3. aralık için $a_1 = 0.1$ ve $a_2=0.9$, 4. aralık için $a_1 = 0.5$ ve $a_2=1.3$ ve 5. aralık için $a_1 = 0.9$ ve $a_2=1.7$ olduğundan, 16 değişkenin her biri için;

$$\mu_1(x, a_1, a_2) = \frac{1}{1 + e^{0.7 \cdot (x-0.1)}}$$

$$\mu_2(x, a_1, a_2) = \frac{1}{1 + e^{0.3 \cdot (x-0.5)}}$$

$$\mu_3(x, a_1, a_2) = \frac{1}{1 + e^{-0.1 \cdot (x-0.9)}}$$

$$\mu_4(x, a_1, a_2) = \frac{1}{1 + e^{-0.5 \cdot (x-1.3)}}$$

$$\mu_5(x, a_1, a_2) = \frac{1}{1 + e^{-0.9 \cdot (x-1.7)}}$$

fonksiyonları ile hesaplanan değerlerin; sırasıyla $k_1 = 0.09993$, $k_2 = 1.014621$, $k_3 = 0.890304$, $k_4 = 1.112869$, $k_5 = 0.379985$, $k_6 = 0.236338$, $k_7 = 1$, $k_8 = 1.737049$, $k_9 = 6.578871$, $k_{10} = 2.286259$, $k_{11} = 0.087851$, $k_{12} = 2.336384$, $k_{13} = 0.023405$, $k_{14} = 0.762478$, $k_{15} = 0.603846$ ve $k_{16} = 0.653489$ ağırlıkları ile hesaplanmış (Bkz. Tablo 5.11 ve 5.16) ağırlıklı aritmetik ortalamasıdır. Bu durumda, herhangi bir $t = t_0$ zamanda,

$$o_1 = \frac{k_1 \cdot \mu_1(nx_1(t_0)) + k_2 \cdot \mu_1(nx_2(t_0)) + k_3 \cdot \mu_1(nx_5(t_0)) + \dots + k_{16} \cdot \mu_1(nx_{34}(t_0 - 1))}{k_1 + k_2 + k_3 + \dots + k_{16}}$$

$$o_2 = \frac{k_1 \cdot \mu_2(nx_1(t_0)) + k_2 \cdot \mu_2(nx_2(t_0)) + k_3 \cdot \mu_2(nx_5(t_0)) + \dots + k_{16} \cdot \mu_2(nx_{34}(t_0 - 1))}{k_1 + k_2 + k_3 + \dots + k_{16}}$$

$$o_3 = \frac{k_1 \cdot \mu_3(nx_1(t_0)) + k_2 \cdot \mu_3(nx_2(t_0)) + k_3 \cdot \mu_3(nx_5(t_0)) + \dots + k_{16} \cdot \mu_3(nx_{34}(t_0 - 1))}{k_1 + k_2 + k_3 + \dots + k_{16}}$$

$$o_4 = \frac{k_1 \cdot \mu_4(nx_1(t_0)) + k_2 \cdot \mu_4(nx_2(t_0)) + k_3 \cdot \mu_4(nx_5(t_0)) + \dots + k_{16} \cdot \mu_4(nx_{34}(t_0 - 1))}{k_1 + k_2 + k_3 + \dots + k_{16}}$$

$$o_5 = \frac{k_1 \cdot \mu_5(nx_1(t_0)) + k_2 \cdot \mu_5(nx_2(t_0)) + k_3 \cdot \mu_5(nx_5(t_0)) + \dots + k_{16} \cdot \mu_5(nx_{34}(t_0 - 1))}{k_1 + k_2 + k_3 + \dots + k_{16}}$$

olacaktır. Bu eşitliklerden hareketle herhangi bir $t = t_0$ için bir değişkene ait üyelik değerleri her bir aralık için aşağıdaki şekilde hesaplanır:

i . aralık için ($i = 1, 2, 3, 4, 5; j = 1, 2, \dots, 16$):

$$\mu_i(nx_j) = \alpha_j \cdot \frac{k_1 + k_2 + k_3 + \dots + k_{16}}{k_j} \cdot o_i$$

Burada α_i ' ler 16 değişkenin herbiri için belirlenen ve üyelik değerini $[0, 1]$ aralığında tutacak katsayılardır ve toplamaları 1 olmalıdır. Bu eşitliklerden hareketle;

$$\mu_i(nx_j) = \frac{1}{1 + e^{0.7 \cdot (x-0.1)}} \Rightarrow x_{j,1} = \frac{1}{0.7} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 0.1$$

$$\mu_i(nx_j) = \frac{1}{1 + e^{0.3 \cdot (x-0.5)}} \Rightarrow x_{j,2} = \frac{1}{0.3} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 0.5$$

$$\mu_i(nx_j) = \frac{1}{1 + e^{-0.1 \cdot (x-0.9)}} \Rightarrow x_{j,3} = \frac{-1}{0.1} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 0.9$$

$$\mu_i(nx_j) = \frac{1}{1 + e^{-0.5 \cdot (x-1.3)}} \Rightarrow x_{j,4} = \frac{-1}{0.5} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 1.3$$

$$\mu_i(nx_j) = \frac{1}{1 + e^{-0.9 \cdot (x-1.7)}} \Rightarrow x_{j,5} = \frac{-1}{0.9} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 1.7$$

olacaktır. Örneğin $t=20$ için $x_{j,1}$ değeri, 1. Aralığa ait Sigmoidal üyelik fonksiyonunun tersi ile hesaplanmış $(nx_1^{(t)}, nx_2^{(t)}, nx_5^{(t)}, \dots, nx_{34}^{(t-1)})$ değerlerinin tamamı için normalize değer in öngörüsü olan değer olarak hesaplanacaktır. Aynı şekilde $x_{j,2}$ değeri, 2. Aralığa ait, $x_{j,3}$ değeri, 3. Aralığa ait, $x_{j,4}$ değeri, 4. Aralığa ait ve $x_{j,5}$ değeri, 5. Aralığa ait Sigmoidal üyelik fonksiyonunun tersi ile hesaplanmış aynı değerlerini kastetmektedir. Bu değerlerden, ortalama mutlak yüzde hatayı en küçük kılan değerler, durulaştırılmış öngörü değerleri olarak alınmıştır. Tüm değişkenler hesaba katılarak bu değer in 3. aralıktaki Sigmoidal fonksiyon ile en

küçük olduğu görülmüştür. Bu değerler, normalizasyon işlemi sonucunda elde edildiğinden,

$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{yeni_max}_A - \text{yeni_min}_A) + \text{yeni_min}_A$$

olup, $\text{yeni_max}_A = 1$, $\text{yeni_min}_A = 0$ alındığı için,

$$\frac{v - \min_A}{\max_A - \min_A} = x_{j,i}$$

eşitliği elde edilir. Burada v , normalizasyon öncesi değeri, \min_A ve \max_A ise normalize edilen zaman serisine ait en küçük ve en büyük değerleri göstermektedir. Bu durumda her hangi bir $x_i^{(t)}$ zaman serisi için, normalize edilmiş verinin kendisi elde edilmek istendiğinde, \min_A ve \max_A değerleri Tablo 5.7' ye göre alınmalıdır.

Verilerin gerçek gözlem değerleri Tablo 5.30' da, yukarıdaki işlemlerle elde edilmiş ve ters normalize işlemi uygulanmış veriler Tablo 5.31' de verilmiştir. Bu veriler gerçek gözlem değerleri ile karşılaştırılabilir. Elde edilen HKOK ve OMYH değerleri yapılacak tahminlerin isabeti hakkında ipucu verebilecektir.

t	x1	x2	x5	x6	x15	x23	x30	x34
20	72561	1053346	4324	201380	0,52	2036	1939	0,896
21	73723	1106201	4045	211496	0,51	2080	1848	0,8972
22	74724	1228928	3835	238074	0,53	2119	1674	0,902
23	75627	1296634	3750	268079	0,52	2127	1669	0,8886
24	76668	1207354	3685	274829	0,5	2127	2354	0,8869

Tablo 5.30. Gerçek Gözlem Değerleri

t	x1	x2	x5	x6	x15	x23	x30	x34
20	75332,9	1244122,7	3755,8	195059	0,48293	2655,05	1511,61	0,875369
21	76385	1279124,5	3389,7	204529,6	0,47303	2610,84	1413,14	0,874145
22	76783,6	1434454,9	3156,8	239977,7	0,48448	2528,93	1258,08	0,8768
23	76516,2	1448776,4	3064,7	277928,4	0,47761	2346,65	1259,24	0,855579
24	75998,7	1145203,7	2964,5	268058,2	0,46276	2118,73	1813,98	0,847903
OMYH (%)	2,44717	13,4698	16,97	2,67399	7,7133	17,1974	23,5822	3,15581
HKOK	2012,46	164650,87	663,47	6855,105	0,03999	419,851	448,171	0,028994

Tablo 5.31. Durulaştırılmış Öngörü Verileri

Bu sonuçlara göre, OMYH değeri ile hareket edilirse, $x_1^{(t)}$ değişkeni için öngörü değerleri %2,45' lik ortalama hata payı ile tahmin edilmektedir. Bu değer

%10' un altında olduğu için, modelin bu değişkeni tahmin oranı yüksek doğruluk derecesine sahip/çok iyi denilebilir. Bunun yanında $x_6^{(t)}$ ve $x_{34}^{(t)}$ değişkenleri için de benzer durum söz konusudur.

Öte yandan bu sonuç, Sigmoidal fonksiyonu yardımı ile bulanıklaştırılan bulanık zaman serilerinin ileri beslemeli geriye yayımlı yapay sinir ağı yardımı ile elde edilen üyelik değerlerinin durulaştırılması ile elde edilmiştir. Modelin derecesi, değişkenlerin tamamının içsel kabul edildiği VAR modeli ile belirlenmiş, koentegrasyon modeli ile elde edilen katsayılar da modele dahil edilmiştir. Başlangıçta her ne kadar bir değişken birincil değişken olarak kabul edilse de son aşamada belirlenen değişkenlerin tahmin değerlerinin doğruluk oranları görülerek, üç değişken için modelin iyi derecede tahmin sonucu verdiği görülmüştür. Elde edilen sonuçlar, zaman serisi bulanıklaştırılmadan elde edilen yapay sinir ağı sonuçları ile de karşılaştırılması anlamlı olacaktır. Buna göre, yapay sinir ağının $x_{30}^{(t)}$ değişkenini hedef değişken olarak kurulduğu hatırlanacak olursa, bulanık zaman serileri ile yapılan öngöründe test verileri için %23.5822 lik bir OMYH değeri elde edilirken, bu değer standart yapay sinir ağında %56.2072 olarak bulunmuştur. Bu durum, zaman serisinin bulanıklaştırılmasıyla %100 den daha (%138.35) fazla performans iyileştirmesi sağlandığını göstermektedir.

5.4.4. Gelecek Değer Tahmini

Bulunan sonuçlar, bulanıklaştırılan zaman serilerinde yapay sinir ağları yardımı ile yapılan tahmin değerlerine göre, $x_1^{(t)}$, $x_6^{(t)}$ ve $x_{34}^{(t)}$ değişkenleri için ağın ürettiği çıktıların tahminde kullanılabileceğini göstermektedir. Buna göre, iki gizli katmandan oluşan, girdi katmanı ve çıktı katmanında 5, gizli katmanlarında ise sorasıyla 10 ve 5 nöron bulunan ağ yardımı ile, 2014 yılı verileri kullanılarak 2015 yılı için tahmin yürütülecektir.

Tablo 5.32' de verilen ve yapay sinir ağında test setinde kullanılan verilerde son satırda bulunan üyelik değerleri, $t = 25$ (2014 yılı) için, zaman serisi vektörünün ilk 8 üyelik değeridir. Gecikmeli değerlerin oluşturduğu bu veri seti, ağa girdi olarak verilerek $t = 26$ için öngörü değerleri üretilebilir.

t	g1	g2	g3	g4	g5	o1	o2	o3	o4	o5
25	0,3884	0,4809	0,4964	0,4329	0,3033	0,3955	0,4872	0,4955	0,4312	0,2856

Tablo 5.32. Tahmin İçin Kullanılacak Girdi Değerleri ve Elde Edilen

Öngörüler

Bu öngörülerin durulaştırılması gerekmektedir.

$$\mu_i(nx_j) = \alpha_j \cdot \frac{k_1 + k_2 + k_3 + \dots + k_{16}}{k_j} \cdot o_i$$

ve

$$\mu_i(nx_j) = \frac{1}{1 + e^{-0.1 \cdot (x-0.9)}} \Rightarrow x_{j,3} = \frac{-1}{0.1} \cdot \ln\left(\frac{1}{\mu_i(nx_j)} - 1\right) + 0.9$$

eşitlikleri yardımı ile, bu üyelik değerleri durulaştırılarak gerçek değere dönüştürülecektir.

Ayrıca bulunan değer normalize edilmiş tahmin değeri olacağından,

$$\frac{v - \min_A}{\max_A - \min_A} = x_{j,i}$$

Eşitliği kullanılarak ters normalize işlemi ile gerçek öngörü değerine ulaşılmıştır.

t	x1	x2	x5	x6	x15	x23	x30	x34
20	75332,9	1244122,7	3755,8	195059	0,48293	2655,05	1511,61	0,875369
21	76385	1279124,5	3389,7	204529,6	0,47303	2610,84	1413,14	0,874145
22	76783,6	1434454,9	3156,8	239977,7	0,48448	2528,93	1258,08	0,8768
23	76516,2	1448776,4	3064,7	277928,4	0,47761	2346,65	1259,24	0,855579
24	75998,7	1145203,7	2964,5	268058,2	0,46276	2118,73	1813,98	0,847903
25	82916,2	1394624,9	3237,3	332891,9	0,48772	2618,81	1936,92	0,868443

Tablo 5.33. 2015 Yılı İçin Tahmin Değerleri

Bu sonuçlara göre, ağın test aşamasında elde edilen OMYH değerleri de göz önünde bulundurularak, $x_1^{(t)}$ (Nüfus (bin)) değerinin %2.45 hata ile 82916.2, $x_6^{(t)}$ (Kaza Yerinde Yaralı Sayısı) değerinin %2.67 hata ile 332892 ve $x_{34}^{(t)}$ (Sürücü Kusur Oranı) değerinin %3.16 hata ile 0.8684 olacağı tahmin edilmiştir.

SONUÇ

Sınır koşulu ve üyelik derecesi yaklaşımı ile klasik kümelerden ayrılan ve daha geniş bir bakış açısı geliştiren bulanık kümeler, bulanık mantığın temelini oluşturmaktadır. Bulanık mantığa dayalı modelleme, gerek üzerinde çalışılan problemlerden gerekse verinin özelliklerinden kaynaklanan eksik, kesin olmayan ya da bulanık bilginin işlenebilmesi, problemlere daha esnek değerlendirme imkânı sağlaması ve belirsiz sözel ifadeleri sayısal olarak tanımlayabilmesi gibi özellikleri ile daha iyi sonuçlar alınmasına imkan tanıyabilmektedir. Öte yandan bu modeller, öğrenme yeteneğinin olmaması ve üyelik fonksiyonlarının çoğunlukla deneme yanılma yöntemleri ile tespit edilebilmesi sebebiyle dezavantajlar da barındırmaktadır.

Diğer yapay zeka teknikleri gibi, insanda ve bazı canlılarda görülen bazı üstünlükleri bilgisayar ortamına aktarma düşüncesi taşıyan yapay sinir ağları ile, deneyerek (yaşayarak) öğrenme yeteneğinin modellenmesi amaçlanmaktadır. Bu amaçla yapay sinir ağları, belirli bir işlevi yerine getirmek için eğitilebilirler ve bu eğitim bağlantıların değerlerini değiştirmekle sağlanmaktadır. Yapay sinir ağlarını geleneksel sistemlerden ayıran en önemli noktalar ise öğrenme, genelleme yapabilme ve paralel çalışma özellikleridir. Fakat ağın kara kutu niteliğinde çalışması yani sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması nedeniyle taşıdığı dezavantajlar bulunmaktadır.

Bulanık modellemenin ve yapay sinir ağlarının birlikte kullanıldığı hibrid sistemler, her iki yöntemin avantajlarını bir araya getirmek, dezavantajlarını en aza indirmek amacıyla kullanılmaktadır. Genel olarak bulanık mantık ile yapay sinir ağlarının birleşmesi ile elde edilen hibrid sistemler, Bulanık Sinir Ağları, Sinirsel Bulanık Sistemler ve Bulanık-Sinirsel Hibrid Sistemler şeklinde karşımıza çıkmaktadır. Bulanık sinir ağı ile bulanık bilgi işleme yeteneğine sahip bir yapay sinir ağı ifade edilmek istenirken; sinirsel bulanık sistemler ile de bulanık çıkarım sistemleri sinir ağı yetenekleri ile zenginleştirilmektedir. Bulanık-sinirsel hibrid sistemlerde ise sistem performansını geliştirmek için bulanık sistemler ile sinir

ağlarının beraberce kullanılması söz konusudur. Bu çalışmada, bulanıklaştırılan verilere ait üyelik değerleri, bulanık ilişkilerin belirlenmesi aşamasında girdi ve hedef değerleri olarak yapay sinir ağlarına katılmıştır. Öte yandan burada yapay sinir ağları, bulanık ilişkilerin öğrenilerek belirlenmesi için kullanılmış bulunmaktadır. Bu haliyle elde edilen model her üç hibrid metodun özelliklerini taşımaktadır.

Zaman serileri pek çok disiplinde, özellikle işletme, finans ve toplum istatistikleri gibi önemli alanlarda çokça kullanılmakta ve üzerinde çalışmalar yapılmaktadır. Bu çalışmalar çok eski yıllara dayanmakta olup zaman serileri kavramı ilk olarak 1970' de Box ve Jenkins' in "Time Series Analysis: Forecasting and Control" kitabı ile bir yöntem olarak geliştirilmiştir. Tek ve çok değişkenli zaman serileri analizleri için geliştirilmiş klasik zaman serileri yöntemleri yanında bulanık zaman serileri yöntemleri, son yıllarda üzerinde çokça çalışılmalar yapılan bir konudur. İlk olarak Song ve Chissom' un 1993' de yaptığı "Fuzzy time series and its models" ve "Forecasting enrollments with fuzzy time series" başlıklı çalışmaları ile literatüre giren bulanık zaman serileri analizi ile, bulanık mantığın sözel (dilsel) ifadeleri ve zaman dilimi içinde değişkenlik veya belirsizlik içeren gözlem değerlerini de modelleyebilme özelliği sayesinde daha iyi sonuçlar alınması amaçlanmaktadır. Diğer taraftan klasik zaman serisi yöntemlerinin gerektirdiği durağanlık, örneklem hacmi, trend sahibi olma gibi bazı varsayımlara bağlı olmaması bu teknikleri tercih edilebilir kılmaktadır. Genel olarak bulanıklaştırma, bulanık ilişkilerin belirlenmesi ve durulaştırma olmak üzere üç temel aşamada gerçekleştirilen bu yöntemler, hem tek hem iki hem de çok değişkenle gerçekleştirilebilmektedir. Yine zaman serilerinin düzey değerleri ile yapılarak birinci dereceden, n dönem gecikmeli değerleri de modele katılmak suretiyle n . dereceden (yüksek dereceli) modeller kurulabilmektedir. Bu çalışmada, 8 ayrı değişkene ait zaman serilerinin bir dönem gecikmeli değerleri de modele dahil edilerek çok değişkenli birinci dereceden bulanık zaman serileri yöntemi önerilmiştir.

Çok değişkenli zaman serileri modellerinde ilk olarak hangi değişkenlerin analize katılacağı ve araştırılan değişkeni hangi faktörlerin etkileyebileceğinin tespit edilmesi gerekmektedir. Bunun için zaman serilerini eşanlı olarak modelleyebilen

VAR modelleri ve aralarındaki uzun dönem ilişkileri ortaya çıkarmaya çalışan koentegrasyon (eşbütünleşme) yöntemleri önerilen yaygın yöntemler olarak karşımıza çıkmaktadır. Benzer durum bulanık zaman serileri yöntemleri için de geçerli olup bu konuda kesin bir öneri getirilememektedir. Koentegrasyon yönteminde seviyelerinde durağan olmayan fakat aynı düzeyde durağan zaman serilerinin doğrusal kombinasyonlarının koentegre olabileceği yani aralarında uzun dönem ilişki bulunabileceği saptanmıştır. Bu çalışmada, VAR modeline de dayanan bu yöntem değişkenlerin seçiminde önerilmiş ve modeli karmaşık olmaktan çıkarmak için de belirlenen değişkenler arasından uzmanlarca da önemli görülen 8 tanesi ile önerilen yöntemler uygulanmıştır.

Kullanılan veriler, 1991-2014 arasına ait olup çeşitli kaynaklardan derlenen, Türkiye’ de trafik kazaları ve bunlarla ilgili faktörlere ait yıllık zaman serileridir. Konunun taşıdığı önem malum olup yapılan çalışma ile ülkemizin ve tüm dünyanın yaşadığı bu problemle ilgili bir öngörü yaklaşımı geliştirilmiştir.

Çalışma, bulanık zaman serileri metodlarında yukarıda saydığımız üç aşamanın her biri için öneriler getirmektedir. Bulanıklaştırma aşamasında uygun aralıkların seçiminde aralık sayısının keyfi sayılara göre belirlenmesine alternatif olarak kesin olarak belirlenebildiği bir yöntem önerilmiş ve k-ortalamlar tekniği kullanılmıştır. Buna göre zaman serilerinin normalize edilen değerleri için belirlenen tanım aralığının 5 eşit aralığa bölünmesine karar verilmiştir. Normalizasyonda min-max yöntemi kullanılarak tüm değerler $[0,1]$ aralığına düşürülmüştür. Belirlenen aralıklarda gözlem değerlerinin üyelik değerleri hesaplanarak veriler bulanıklaştırılmıştır. Bu aşamada üyelik fonksiyonu olarak Gaussian, Sigmoidal ve Çan Şekilli üyelik fonksiyonlarının her biri için ayrı ayrı hesaplamalar yapılmıştır. Bu fonksiyonlar, yapılarının tek parçalı olması nedeniyle tercih edilmiştir.

Bu aşamadan sonra pek çok çalışmada, bulanık ilişkilerin belirlenmesinde yalnızca bulanık ilişkiler tabloları ile elde edilen ve gözlem değerinin ait olduğu aralığın küme numarası ile işleme devam edildiği görülmektedir. Halbuki bu durum gözlemlerin aralıklara üyelik derecelerinin ihmal edilmesine yol açacaktır. Bu sebeple bu çalışmada, doğrudan gözlemlerin tüm üyelik değerleri işleme alınmıştır.

Model çok deęişkenli olduęu için, tüm deęişkenlerin eşanlı olarak modelde bulunması amacıyla, belirlenen üyelik deęerleri, daha önce belirlenmiş olan koentegrasyon modelinde bulunan katsayılar yardımı ile ağırlıklı ortalamaları alınarak bulanık ilişkiler hesaplanmıştır. Burada kullanılan yöntem ise zaman serilerinde tahmin modellerinde başarı ile kullanılan ileri beslemeli geriye yayımlı çok katmanlı yapay sinir aęlarıdır. Bu aęın girdileri üyelik deęerlerinin (t-1) zamandaki, hedefleri ise (t) zamandaki üyelik deęerleridir. Her üç üyelik tipi fonksiyonu ile elde edilen bu deęerler ile girdi katmanında 5 ve hedef katmanında 5 düęüm (nöron) olan ve en az bir gizli katmanı olan aęlar kurulmuştur. Gizli katman ve bu katman(lar)daki düęüm sayısı ise deneme yanılma yöntemi ile en küçük hata miktarını veren deęerler olarak bulunmuştur. Buna göre, Gaussian üyelik fonksiyonu ile elde edilen deęerler için 3, Sigmoidal üyelik fonksiyonu ile elde edilen deęerler için 4 ve Çan Şekilli üyelik fonksiyonu ile elde edilen deęerler için yine 4 adet gizli katman bulunan modeller seçilmiştir. Bu katmanlarda bulunan nöron sayısı ise sırasıyla (22,18,6), (24,12,6,3) ve (24,16,8,9) olmuştur. Ancak daha az sayıda gizli katman ile de yakın sonuçların bulunabileceęi görülmüş, bu nedenle en iyi sonuçları veren Sigmoidal fonksiyonuna ait deęerler için ayrıca 2 gizli katmanlı ve (6,9) ile (10,5) gizli nöronlardan oluşan modeller de deęerlendirmeye alınmıştır. Seçilen bu modellerin performansı, test verileri ile ölçülerek karşılaştırılmış ve en iyi sonucun Sigmoidal Fonksiyon için 2 gizli katman ve bu katmanlarda 10 ile 5 nöronlardan oluşan aęda yakalandığı anlaşılmıştır.

Son olarak ise öngörülerin durulaştırılması için ise yine üyelik fonksiyonları ve koentegrasyon modeli ile belirlenen katsayılar kullanılmıştır. Çalışmalarda genellikle kullanılan yöntemin merkezileştirme yöntemi olduęu görülmektedir. Bu yöntemle göre, bulunan üyelik deęerleri önce toplamları 1 olacak şekilde ağırlıklara dönüştürülmekte, sonrasında her bir ağırlık ait olduęu aralık (küme) merkezi ile çarpılarak sonuçlar toplanmakta ve öngörü deęeri elde edilmektedir. Bu çalışmada ise önce aęın ürettięi çıktı deęerleri katsayılar yardımı ile üyelik deęerlerine dönüştürülmekte, sonrasında ise bulunan üyelik deęerleri üyelik fonksiyonunda ters fonksiyon işlemi ile gerçek deęer haline getirilmekte yani durulaştırılmaktadır.

Seçilen modelin diğer modellerle karşılaştırılması, modelin performansını görmek açısından önemlidir. Bu amaçla öncesinde aynı zaman serileri ile klasik yapay sinir ağları yardımı ile çıktılar hesaplanmış ve bu çıktı değerleri için HKOK değeri bulunmuştur. Bu değer, çok değişkenli, birinci dereceden hibrid bulanık zaman serileri yöntemi ile elde edilen çıktı değerleri için de hesaplanarak karşılaştırılmıştır. Buna göre, iki yöntemde tahmin edilen değişkenin tahmin değerlerine göre; önerilen modelin HKOK ve OMYH değerlerinin daha düşük olduğu görülmüştür. Bulanık zaman serileri ile yapılan öngöründe test verileri için %23.5822 lik bir OMYH değeri elde edilirken, bu değer standart yapay sinir ağında %56.2072 olarak bulunmuştur. Bu durum, zaman serisinin bulanıklaştırılmasıyla %100 den daha (%138.35) fazla performans iyileştirmesi sağlandığını göstermektedir.

Oluşturulan modelin performansı ile ilgili bu karşılaştırmadan sonra, modelin gelecek öngörüsü hesaplanmıştır. Yöntem, gerçek bir zaman serisi ile uygulanarak öngörü sonuçları elde edilmiştir. Trafik kazaları, özellikle gelişmiş ve gelişmekte olan ülkeler için önemli bir sorun halindedir. Yapılan uygulama ile, trafik kazalarında 25-64 yaş ölüm sayıları tahmin edilmeye çalışılmış, bunun için de bu değişkeni etkilediği düşünülen 7 farklı değişken modele dahil edilmiştir. Ancak model eş anlı olduğundan tüm değişkenler için tahmin değerleri elde edilebilmektedir. Buna göre 2015 yılı için; Nüfus (bin) değerinin %2.45 hata ile 82916.2, Kaza Yerinde Yaralı Sayısı değerinin %2.67 hata ile 332892 ve Sürücü Kusur Oranı değerinin %3.16 hata ile 0.8684 olacağı öngörülmüştür. Önerilen yöntem, toplam 8 değişken ile uygulanmıştır. Bu çalışma ile, çok değişkenli bulanık zaman serilerinde değişken sayısı ilk defa bu kadar yüksek alınarak hesaplamalar gösterilmiştir.

Bu çalışmada kullanılan klasik zaman serileri yöntemleri ile ilgili işlemler EViews yazılımı ile, diğer tüm teknikler ise açık kaynak kodlu R programlama dili (R-project, 2015) ile paketler yardımıyla komutlar yazılarak uygulanmıştır. R programlama dili son yıllarda, bilginin paylaşımında sağladığı kolaylık ve bilgi çağının en belirgin özelliklerinden olan bilginin hızlı yayılmasına ayak uydurması nedeniyle, veri madenciliği, istatistik, makine öğrenmesi, optimizasyon ve yapay

zeka yöntemlerinde en çok tercih edilen araçlarından biri haline gelmiştir. Bu çalışmada R ile kullanılan kodlara da yer verilerek bundan sonra yapılacak çalışmalara katkı sağlanması amaçlanmıştır.

KAYNAKÇA

- ABONYİ, J.: 2003 “Fuzzy model identification”, **Fuzzy model identification for control**, 87-164, Birkhauser, Boston.
- AKBİLGİÇ, O.: 2011 “Hibrit Radyal Tabanlı Fonksiyon Ağları İle Değişken Seçimi ve Tahminleme: Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama” (Yayınlanmamış Doktora Tezi), İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- ALADAĞ, C.H.: 2013 “Using multiplicative neuron model to establish fuzzy logic relationships”, **Expert Systems with Applications**, 40, 850-853.
- ALADAĞ, C.H., BAŞARAN, M.A., EĞRİOĞLU, E., YOLCU, U., USLU, V.R.: 2009 “Forecasting in high order fuzzy time series by using neural networks to define fuzzy relations”, **Expert Systems with Applications**, 36, 4228-4231.
- ALADAĞ, C.H., EĞRİOĞLU, E., GÜNAY, S., YOLCU, U.: 2010a “Yüksek dereceli bulanık zaman serisi modeli ve IMKB uygulaması”, **Anadolu Üniversitesi Bilim ve Teknoloji Dergisi**, 11 (2), 95-101.
- ALADAĞ, C.H., EĞRİOĞLU, E., YOLCU, U.: 2010b “A high order fuzzy time series forecasting model based on adaptive expectation and artificial neural Networks”, **Mathematics and Computers in Simulation**, 81, 875-882.

- ALADAĞ, S.,
ALADAĞ, C.H.,
MENTEŞ, T.,
EĞRİOĞLU, E.:2012 “A new seasonal fuzzy time series method based on multilicative neuron model and SARIMA”, **Hacettepe Journal of Mathematics and Statistics**, 41(3), 337-345.
- ALPASLAN, F.,
CAĞCAĞ, Ö.,
ALADAĞ, C.H.,
YOLCU, U.,
EĞRİOĞLU, E.: 2012 “A novel seasonal fuzzy time series method”, **Hacettepe Journal of Mathematics and Statistics**, 41(3), 375-385.
- ANDERSON, D.,
MCNEİLL, G.: 1992 **Artificial Neural Networks Technology**, A DACS State-of-the-Art Report, Rome Laboratory.
- ARUTCHELVAN, G.,
SİVATSA, S.K.,
JAGANATHAN, R.: 2010 “Inaccuracy Minimization by Partitioning Fuzzy Data Sets – Validation of an Analytical Methodology”, **(IJCSIS) International Journal of Computer Science and Information Security**, Vol. 8, No. 1.
- ASLAY, F., ÖZEN, Ü.: 2013 “Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları ile Toprak Sıcaklığının Tahmini”, **Politeknik Dergisi Journal of Polytechnic**, Vol:16, No:4, s. 139-145.
- ATİN, M. H.: 1999 “Bulanık Lineer Programlama” (Basılmamış Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- AYTAÇ, E.: 2006 “Kalite kontrolde bulanık mantık yaklaşımı ve bir uygulama” (Basılmamış Yüksek Lisans Tezi), Pamukkale Üniversitesi, Sosyal Bilimler Enstitüsü, Denizli.
- BAILEY, D.,
THOMSON, D.: 1990 “Developing Neural Network Application”, **Journal AI Expert**, Volume 5, Issue 9, s. 34-41.

- BALABAN, M. E.,
KARTAL, E.: 2015 **Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları**, Çağlayan Kitabevi, İstanbul.
- BANG, Y.H., LEE,
C.H.: 2011 “Fuzzy time series prediction using hierarchical clustering algorithms”, **Expert Systems with Applications**, 38(4), 4312-4325.
- BAŞ, E.: 2011 “Bulanık zaman serisi Çözümlemesi için Genetik Algoritmaya Dayalı Yeni Bir Yaklaşım” (Basılmamış Yüksek Lisans Tezi), On Dokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- BAYKAL, N.,
BEYAN, T.: 2004a **Bulanık Mantık Uzman Sistemler ve Denetleyiciler**, Bıçaklar Kitabevi, Ankara.
- BAYKAL, N.,
BEYAN, T.: 2004b **Bulanık Mantık İlke ve Temelleri**, Bıçaklar Kitabevi, Ankara.
- BARNARD, E.: 1992 “Optimization for training neural nets”, **IEEE Transactions on Neural Networks**, 3 (2) , 232-240.
- BERRY, M.J.A.,
LINOFF, G.: 2011 **Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management, 3rd Edition**, New York, John Wiley & Sons.
- BLACK, M.: 1937 “Vagueness: An exercise in logical analysis”, **Philosophy of Science** 4: 427–455. Reprinted in R. Keefe, P. Smith (eds.): *Vagueness: A Reader*, MIT Press 1997.
- BLUM, A.: 1992 **Neural Networks in C++: An Object-Oriented Framework for Building Connectionist Systems**, New York, Wiley.

- BOGER, Z.,
GUTERMAN, H.: 1997 “Knowledge Extraction from Artificial Neural Network Models”, **IEEE Systems, Man, and Cybernetics Conference**, Orlando, USA.
- BOJADZIEV, G.,
BOJADZIEV, M.: 1991 **Fuzzy Sets, Fuzzy Logic, Applications**, London, World Scientific.
- BOX, G.E.P.,
JENKINS, G. M.: 1970 **Time Series Analysis: Forecasting and Control**, San Francisco, Holden Day.
- CAI, Q., ZHANG, D.,
ZHENG, W., LEUNG,
S. C.H.: 2015 “A New Fuzzy Time Series Forecasting Model Combined With Ant Colony Optimization And Auto-Regression”, **Knowledge-Based Systems**, 74, s. 61–68.
- CHANG, P.T.: 1997 “Fuzzy Seasonality Forecasting”, **Fuzzy Sets and Systems**, 90(1), pp. 1-10.
- CHATFIELD, C.: 2000 **Time Series Forecasting**, Chapman&Hall/CRC, London.
- CHEN, C.D., CHEN,
S. M.: 2009 “A new method for forecasting the TAIEX based on high-order fuzzy logical relationships”, In Proceedings of the 2009 IEEE **International Conference on Systems, Man, and Cybernetics**, San Antonio, Texas, USA, pp. 3556–3560.
- CHEN, G., PHAM,
T.T.: 2001 **Introduction to Fuzzy Sets, Fuzzy Logic and Fuzzy Control Systems**, USA, CRC Press LLC.
- CHEN, S.M.:1996 “Forecasting Enrollments based on Fuzzy Time Series”, **Fuzzy Sets and Systems**, Vol. 81, pp.311-319.

- CHEN, S.M.: 2002 “Forecasting enrollments based on high order fuzzy time series. **Cybernetics and Systems**, 33, 1-16.
- CHEN, S.M., CHEN, C. D.: 2011 “Handling forecasting problems based on high-order fuzzy logical relationships”, **Expert Systems with Applications**, 38, 3857–3864.
- CHEN, S.M., CHEN, C.D.: 2011 “TAIEX Forecasting Based on Fuzzy Time Series and Fuzzy Variation Groups”, **IEEE Transactions On Fuzzy Systems**, Vol. 19, No. 1.
- CHEN, S.M., CHUNG, N. Y.: 2006 “Forecasting enrollments using high-order fuzzy time series and genetic algorithms”, **International Journal of Intelligent Systems**, 21(5), 485–501.
- CHEN, S.M., HWANG, J. R.: 2000 “Temperature Prediction Using Fuzzy Time Series”, **IEEE Transactions on Systems, Man, and Cybernetics Part B**, 50(2), pp. 263-275.
- CHEN, S.M., KAO, P. Y.: 2013 “TAIEX forecasting based on fuzzy time series, particle swarm optimization techniques and support vector”, **Information Sciences**, 247, 62–71.
- CHEN, S.M., TANUWIJAYA, K.: 2011 “Multivariate fuzzy forecasting based on fuzzy time series and automatic clustering techniques”, **Expert Systems with Applications**, 38(8), 10594-10605.
- CHEN, S.M., WANG, N. Y., PAN, J.S.: 2009 “Forecasting enrollments using automatic clustering techniques and fuzzy logical relationships”, **Expert Systems with Applications**, 36(8), 11070–11076.

- CHEN, T.L., CHENG, C.H., TEOH, H.J.: 2008 “High-order fuzzy time-series based on multi-period adaptation model for forecasting stock markets”, **Physica A: Statistical Mechanics and its Applications**, 387(4), 876-888.
- CHENG, C.H., CHEN, T. L., HUANG, C.C.: 2007 “A new fuzzy time-series based on two factors to predict TAIEX”, **Proceedings of International Conference on Machine Learning and Cybernetics (ICMLC)**, Hong Kong.
- CHENG, C.-H., CHENG, G.-W., WANG, J.-W.: 2008 “Multi-attribute fuzzy time series method based on fuzzy clustering”, **Expert Systems with Applications**, 34, 1235-1242.
- CHENG, Y.-C., CHEN, P.-C., CHEN, C.-C., CHUANG, H.-C., Lİ, S.-T.: 2015 “An Enhanced HMM-Based for Fuzzy Time Series Forecasting Model”, **16th World Congress of the International Fuzzy Systems Association (IFSA), 9th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT)**.
- COPILOWISH IRVING, M.: 1939 “Border-line cases, vagueness, and ambiguity”, **Philosophy of science**, vol. 6, pp. 181–195.
- CRAN: “Package cluster”, (Çevrimiçi) <https://cran.r-project.org/web/packages/cluster/cluster.pdf>, 07.10.2015.
- CURA, T.: 2008 **Modern Sezgisel Teknikler ve Uygulamaları**, İstanbul, Papatya Yayıncılık Eğitim.
- ÇETİN, M., UĞUR, A., BAYZAN, Ş.: 2006 “İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı”, **8. Akademik Bilişim Konferansı**, Pamukkale Üniversitesi, Denizli.

- ÇEVİK, K.K.,
DANDIL, E.: 2012 “Yapay Sinir Ağları İçin Net Platformunda Görsel Bir Eğitim Yazılımının Geliştirilmesi”, **International Journal Of Informatics Technologies (Gazi Üniversitesi Bilişim Teknolojileri Dergisi)**, Cilt 5, Sayı 1, s. 19-28.
- ÇUHADAR, M.: 2006 “Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)” (Basılmamış Doktora Tezi), Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Isparta.
- DAVARI, S.,
ZARANDI, M.H.F.,
TURKSEN, I.B.: 2009 “An Improved fuzzy time series forecasting model based on particle swarm intervalization”, **The 28th North American Fuzzy Information Processing Society Annual Conferences (NAFIPS 2009)**, Cincinnati, Ohio, USA, June 14-17.
- DE VILLIERS, J.,
BERNARD, E.: 1992 “Backpropagation Neural Networks with One and Two Hidden Layers”, **IEEE Transactions on Neural Networks**, Vol. 4, No 1, s. 136–141.
- DEGRAUWE, D.,
LOMBAERT, G., DE
ROECK, G.: 2010 “Improving Interval Analysis in Finite Element Calculations by Means of Affine Arithmetic”, **Computers and Structures**, Volume 88, Issues 3-4, s. 247-254.
- DOIG, G.:1999 “Severity of Illness Scoring in the Intensive Care Unit: A Comparison of Logistic Regression and Artificial Neural Networks”, PhD , The University of Western Ontario, London, Ontario.
- DUBOIS, D., PRADE,
H.: 2000 **Fundamentals of Fuzzy Sets**, Springer Science & Business Media.

- DURMUŞ, A.: 2005 “Yapay ve Bulanık Sinir Ağları ile Sistemlerin Modellenmesi” (Yayınlanmamış Yüksek Lisans Tezi), Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- EĞRİOĞLU, E.: 2012 “A new time invariant fuzzy time series forecasting method based on genetic algorithm”, **Hindawi Publishing Corporation Advances in Fuzzy Systems**, Volume 2012, Article ID 785709, 6 pages, doi:10.1155/2012/785709.
- EĞRİOĞLU, E.,
ALADAĞ, C.H.,
BAŞARAN, M.A.,
USLU, V.R., YOLCU,
U.: 2011a “A new approach based on the optimization of the length of intervals in fuzzy time series”, **Journal of Intelligent and Fuzzy Systems**, 22, 15-19.
- EĞRİOĞLU, E.,
ALADAĞ, C.H.,
YOLCU, U.: 2013 “A hybrid fuzzy time series forecasting model based on fuzzy C-means and artificial neural networks”, **Expert Systems with Applications**, 40, 854-857.
- EĞRİOĞLU, E.,
ALADAĞ, C.H.,
YOLCU, U.,
BAŞARAN, M.A.,
USLU, V.R.: 2009a “A new hybrid approach based on SARIMA and partial high order bivariate fuzzy time series forecasting model”, **Expert Systems with Applications**, 36, 7424-7434.
- EĞRİOĞLU, E.,
ALADAĞ, C.H.,
YOLCU, U., USLU,
V.R., BAŞARAN,
M.A.: 2009b “A new approach based on artificial neural networks for high order multivariate fuzzy time series”, **Expert Systems with Applications**, 36, 10589-10594.

- EĞRİOĞLU, E., ALADAĞ, C.H., YOLCU, U., USLU, V.R., BAŞARAN, M.A.: 2010a “Finding an optimal interval length in high order fuzzy time series”, **Expert Systems with Applications**, 37, 5052-5055.
- EĞRİOĞLU, E., ALADAĞ, C. H., YOLCU, U., USLU, V. R., ERİLLİ, N. A.: 2011b “Fuzzy time series forecasting method based on Gustafson-Kessel fuzzy clustering”, **Expert Systems with Applications**, 38, 10355-10357.
- EĞRİOĞLU, E., USLU, V. R., YOLCU, U., BAŞARAN, M.A., ALADAĞ, C.H.: 2009c “A new approach based on artificial neural networks for high order bivariate fuzzy time series”, J.Mehnen et al. (Eds.), **Applications of Soft Computing, AISC 58**, Springer-Verlag Berlin Heidelberg, 265-273.
- EĞRİOĞLU, E., YOLCU U., ALADAĞ, Ç.H., USLU, V. R.: 2010b “Ankara Hava Kirliliği Zaman Serisinin Çözümlemesinde Klasik ve Bulanık Zaman Serileri Yaklaşımlarının Karşılaştırılması”, **VII. İstatistik Günleri Sempozyumu**, ODTÜ, Ankara.
- ELMAS, Ç.: 2003 **Bulanık Mantık Denetleyiciler**, Ankara, Seçkin Kitabevi.
- ELMAS, Ç.: 2011 **Yapay Zeka uygulamaları**, Ankara, Seçkin Yayıncılık.
- ENGLE, R.F., GRANGER, C.W.J.: 1987 “Co-integration and Error Correction: Representation, Estimation, and Testing”, **Econometrica**, Vol 55, 251–276.
- FAUSETT, L.V.: 1993 **Fundamentals of Neural Networks: Architectures, Algorithms And Applications**, US: Prentice Hall.

- FERNANDEZ, A.,
HERRERA, F.: 2012 **Linguistic Fuzzy Rules in Data Mining: Follow-Up Mamdani Fuzzy Modeling Principle, Combining Experimentation and Theory**, Studfuzz 271, Springer-Verlag Berlin Heidelberg.
- GUJARATI, D.N.:
2011 **Temel Ekonometri**, çev. Şenesen, Ü., Şenesen, G. G., Sekizinci Basım, İstanbul, Literatür Yayıncılık.
- GUYTON, A.C.,
HALL, J.E.: 2006 **Textbook of Medical Physiology**, Eleventh Edition, Elsevier Saunders.
- GÜNTHER, F.,
FRITSCH, S.: 2010 “Neuralnet: Training of Neural Networks”, **The R Journal**, Vol. 2/1, p. 30–38, ISSN 2073-4859.
- HAMZAÇEBİ, C.:
2011 **Yapay Sinir Ağları**, Bursa, Ekin Basım Yayın Dağıtım.
- HEMPEL, C.G.: 1939 “Vagueness and logic”, **Philosophy of Science**, 6, s. 163—180.
- HOPFIELD, J.: 1982 “Neural networks and physical systems with emergent collective computational abilities”, **Proc. Nat. Acad. Sci. USA**, Vol. 79, pp. 2554-2558.
- HSU, Y.-Y., TSE, S.-
M., WU, B.: 2003 “A New Approach of Bivariate Fuzzy Time Series Analysis to the Forecasting of a Stock Index”, **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, 11(6), pp. 671-690.
- HSU, L-Y., HORNG,
S-J., KAO, T-W.,
CHEN, Y-H., RUN, R-
S, CHEN, R-J., LAI, J-
L., KUO, IH.: 2010 “Temperature prediction and TAIEX forecasting based on fuzzy relationships and MTPSO techniques”, **Expert Systems with application**, 37,2756- 2770.

- HUARNG, K.: 2001a “Effective length of intervals to improve forecasting in fuzzy timeseries”, **Fuzzy Sets and Systems**, 123, 387-394.
- HUARNG, K.: 2001b “Heuristic models of fuzzy time series for forecasting”, **Fuzzy Sets and Systems**, 123(3), 369–386.
- HUARNG, K., YU, H.-K.: 2003 “An N-th order heuristic fuzzy time series model for TAIEX forecasting”, **International Journal of Fuzzy Systems**, vol. 5, no. 4, pp. 247-253.
- HUARNG, K., YU, H.-K.: 2004 “A dynamic approach to adjusting lengths of intervals in fuzzy time series forecasting”, **Intelligent Data Analysis**, vol. 8, no. 1, pp. 3-27.
- HUARNG, K., YU, H.-K.: 2005 “A type 2 fuzzy time series model for stock index forecasting”, **Physica A**, vol.353, pp. 445-462.
- HUARNG K., YU, T.H.-K.: 2006a “The application of neural networks to forecast fuzzy time series”, **Physica A**, 363, 481 -491.
- HUARNG, K., YU, T.H.-K.: 2006b “Ratio-based lengths of intervals to improve fuzzy time series forecasting”, **IEEE Transactions on Systems, Man,, and Cybernetics-Part B: Cybernetics**, 36, 328-340.
- HWANG, J. R., CHEN, S. M., LEE, C. H.: 1998 “Handling Forecasting Problems Using Fuzzy Time Series”, **Fuzzy Sets and Systems**, Vol. 100, pp. 217-228.
- ISHIBUCHI, H., KWON, K., TANAKA, H.: 1995 “A learning algorithm of fuzzy neural networks with triangular fuzzy weights”, **Fuzzy Sets and Systems**, 71, 277-293.

- JACEK, M.L.: 2003 “Neuro-Fuzzy System With Learning Tolerant To Imprecision”, **Fuzzy Sets and Systems**, 138, 427–439.
- JAIN, A.K., MAO, J.: 1996 “Artificial Neural Networks: A Tutorial”, **IEEE Computer Special Issue on Neural Computing**, March, 1996.
- JANG, J.-S.R.: 1993 “ANFIS: Adaptive-network-based fuzzy inference system”, **IEEE Trans Syst Man Cybern**, 23(3):665–685.
- JANG, J-S.R., SUN, C.-T., MIZUTANI, E.: 1997 **Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Learning**, Upper Saddle River, Prentice Hall.
- JILANI, T.A., BURNEY, S.M.A.: 2007 “M-factor high order fuzzy time series forecasting for road accident data”, **Analysis and design of intelligent systems using soft computing techniques, Advances in Soft Computing**, 41, 246–254.
- JILANI, T.A., BURNEY, S.M.A.: 2008 “Multivariate stochastic fuzzy forecasting models”, **Expert Systems with Applications**, 35(3), 691–700.
- JILANI, T. A., BURNEY, S.M.A., AMJAD, U., SIDDIQUI, T.A.: 2012 “A Particle Swarm Intelligence based Fuzzy Time Series Forecasting Model”, **International Journal of Computer Applications**, Volume 38, No.10., 975-997.
- JILANI, T.A., BURNEY, S.M.A., ARDIL, C.: 2008 “Multivariate High Order Fuzzy Time Series Forecasting for Car Road Accidents”, **International Journal of Computational Intelligence**, 4(1), 15–20.
- KADILAR, C.: 2005 **SPSS Uygulamalı Zaman Serileri Analizine Giriş**, Ankara Bizim Büro Basımevi.

- KARSOLIYA, S.: 2012 “Approximating Number of Hidden Layer Neurons in Multiple Hidden Layer BPNN Architecture”, **International Journal of Engineering Trends and Technology**, ISSN: 2231 -5381, Volume 3, Issue 6, s. 714-717.
- KATZ, J. O.: 1992 “Developing Neural Network Forecasters for Trading”, **Technical Analysis Inc. Stocks & Commodities**, V. 10:4, 160-168.
- KELEŞOĞLU, Ö. , EKİNCİ, C.E., FIRAT, A.: 2005 “The Using Of Artificial Neural Networks in Insulation Computations”, **Journal of Engineering and Natural Sciences**, Sigma, 2005/3.
- KHALIL, R.A.: 2012 “Comparison of Four Neural Network Learning Methods Based on Genetic Algorithm for Non-linear Dynamic Systems Identification”, **Al-Rafidain Engineering**, Vol.20 No.1.
- KHIABANI, K., AGHABOZORGI, S.R.: 2015 “Adaptive Time-Variant Model Optimization for Fuzzy-Time-Series Forecasting”, **IAENG International Journal of Computer Science**, 42(2).
- KOÇAK, C.: 2011 “Bulanık Zaman Serileri Öngörüsü İçin Yeni Bir Model Sınıfı” (Yayınlanmamış Doktora Tezi), Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- KOSKO, B., ISAKA, S.: 1993 “Fuzzy Logic”, **Scientific American Science**, Vol. 1, No. 1, 76-81.

- KUO, I.-H., HORNG, S.-J., CHEN, Y.-H., RUN, R.-S., KAO, T.-W., CHEN, R.-J., LAI, J.-L., LIN, T.-L.: 2010 “Forecasting TAIEX based on fuzzy time series and particle swarm optimization”, **Expert Systems with application**, 37, 1494-1502.
- KUO, I.H., HORNG, S.J., KAO, T.W., LIN, T.L., LEE, C.L., PAN, Y.: 2009 “An improved method for forecasting enrollments based on fuzzy time series and particle swarm optimization”, **Expert Systems with Applications**, 36(3), 6108–6117.
- LAI, Y.J., HWANG C.L.: 1992 **Fuzzy Mathematical Programming**, Berlin, Springer-Verlag.
- LEE, L.W., WANG, L.H., CHEN, S.M.: 2007 “Temperature prediction and TAIEX forecasting based on fuzzy logical relationships and genetic algorithms”, **Expert Systems with Applications**, 33, 539-550.
- LEE, L.W., WANG, L.H., CHEN, S.M.: 2008 “Temperature prediction and TAIEX forecasting based on high-order fuzzy logical relationships and genetic simulated annealing techniques”, **Expert Systems with Applications**, 34, 328–336.
- LEE, L.W., WANG, L.H., CHEN, S.M., LEU, Y.H.: 2006 “Handling forecasting problems based on two-factors high-order time series”, **IEEE Transactions on Fuzzy Systems**, 14 (3), pp. 468–477.
- LI, S.-T., CHENG, Y.-C.: 2007 “Deterministic fuzzy time series model for forecasting enrollments”, **Computers and Mathematics with Applications**, 53, 1904–1920.
- LI, S.-T., CHENG, Y.-C., LIN, S.-Y.: 2008 “A FCM-based deterministic forecasting model for fuzzy time series”, **Computers and Mathematics with Applications**, 56, 3052- 3063.

- LIN, C-T., LEE, C.S.G.: 1994 “Reinforcement Structureparameter Learning for Neural-Network-Based Fuzzy Logic Control Systems”, **IEEE Transactions On Fuzzy Systems**, Vol. 2, No. 1.
- LUKASIEWICZ, J.: 1910 **O zasadzie sprzeczności u Arystotelesa**, Krakow, Studium Krytyczne.
- LUKASIEWICZ, J.: 1920 “O logice trójwartościowej”, **Ruch Filozoficzny**, 5, 170-171.
- LUKASIEWICZ, J.: 1929 **Elementy logiki matematycznej**, Warsaw, University of Warsaw.
- LUKASIEWICZ, J.: 1930 “Philosophische Bemerkungen zu mehrwertigen Systemen des Ausagenkalküls”, **Comptes rendus des seances de la Societe des lettres et des sciences de Varsovie**, Classe 3, 23, 51-77.
- MAMDANI, E.H., ASSILIAN, S.: 1975 “An experiment in linguistic synthesis with a fuzzy logic controller”, **International Journal of Man-Machine Studies**, 7(1), 1–13.
- MARINESCU, S.I.: 2014 “Aspects regarding the use of neural networks in the organizational management of research and development operators in the nonconventional technologies field”, **Nonconventional Technologies Review, Romanian Association of Nonconventional Technologies**, December 2014, Romania.
- MCCULLOCH, W., PITTS, W.: 1943 “A Logical Calculus of Ideas Immanent in Nervous Activity”, **The bulletin of mathematical biophysics**, Volume 5, Issue 4, 115-133.

- MEMMEDOVA, N.: 2012 “Süt Sığırlarında Mastitisin Bazı Yapay Zeka Yöntemleri Kullanılarak Erken Dönemde Tespiti” (Basılmamış Doktora Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- MINSKY, M.L., PAPERT, S.: 1969 **Perceptrons: An Introduction to Computational Geometry**, Cambridge, MIT Press.
- MOHAMMED, A.H., GAD ALLAH, A.M., HEFNY, H.A.: 2014 “Fuzzy Time Series Approach for Optimizing Crops Planting Dates with Climate Changes”, **10th International Computer Engineering Conference (ICENCO)**, s. 36 – 41.
- NAUCK, D., KRUSE, R.: 1994 “Choosing Appropriate Neuro-Fuzzy Models”, **In Proc. Second European Congress on Fuzzy and Intelligent Technologies (EUFIT'94)**, Aachen, pp. 552-557.
- ORHUNBİLGE, N.: 1999 **Zaman Serileri Analizi ve Fiyat İndeksleri**, İstanbul, Tunç Matbaası.
- ÖZDEMİR, B.: 2013 “İkili Parçacık Sürü Optimizasyonu İle Bulanık Zaman Serisi Modelinde Bulanık Gecikmeli Değişken Seçimi” (Yayınlanmamış Yüksek Lisans Tezi), Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- ÖZDEMİR, Ö.: 2013 “Dağılım Ve Sinir Ağı Tabanlı Bulanık Zaman Serisi Modelleri” (Basılmamış Doktora Tezi), Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir.
- ÖZKAN, M.: 2002 “Bulanık Doğrusal Programlama ve Bir Tekstil İşletmesinde Uygulama Örneği” (Basılmamış Doktora Tezi), Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Bursa.

- ÖZKAN, M.: 2003 **Bulanık Hedef Programlama**, Bursa, Ekin Kitabevi.
- ÖZTEMEL, E.: 2003 **Yapay Sinir Ağları**, İstanbul, Papatya Yayıncılık.
- PARK, J.-I., LEE, D.-J., SONG, C.-K., CHUN, M.-G.: 2010 “TAIFEX and KOSPI 200 forecasting based on two factors high order fuzzy time series and particle swarm optimization”, **Expert Systems with application**, 37, 959-967.
- PEIRCE, C. S.: 1931 “Collected Papers of Charles Sanders Peirce”, **Principles of Philosophy**, Vol. 1.
- QUICK R: “Cluster Analysis”, (Çevrimiçi) <http://www.statmethods.net/advstats/cluster.html>, 07.10.2015.
- RIEDMILLER, M.: 1994 **Rprop – Description and Implementation Details**, Technical Report, University of Karlsruhe.
- ROSENBLATT, F.: 1958 “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, **Psychological Review**, Vol. 65, No. 6, 365-408.
- RUMELHART, D., MCCLELLAND, J.: 1986 **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, MA, The PDP Research Group, MIT Press.
- SAFARINEJADIAN, B., GHARIBZADEH, M., RAKHSHAN, M.: 2014 “An optimized model of electricity price forecasting in the electricity market based on fuzzy time series”, **Systems Science & Control Engineering**, 2:1, 677-683, DOI: 10.1080/21642583.2014.970733.

- SARI, M., MURAT, Y.S., KIRABALI, M.: 2005 “Fuzzy Logic Modelling Approach and Applications”, **Dumlupinar University Journal of Institute of Sciences**, 9(9), 77-92.
- SEVÜKTEKİN, M., ÇINAR, M.: 2014 **Ekonometrik Zaman Serileri Analizi**, 4. Baskı, Bursa, Dora Basım Yayın Dağıtım.
- SMITH, K., GUPTA, J.: 2002 **Neural Networks in Business: Techniques and Applications**, Idea Group Publishing.
- SOFYALIOĞLU, Ç., ÖZTÜRK, Ş.: 2013 “Bir Çimento Firması İçin Dönemsel Satış Miktarlarının Tahmininde Bulanık Zaman Serisi Modellerinin Karşılaştırılması”, **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, C.18, S.3, s.161-186.
- SONG, Q.: 1999 “Seasonal Forecasting in Fuzzy Time Series”, **Fuzzy Sets and Systems**, 107(2), pp.235.
- SONG, Q., CHISSOM, B.S.: 1993a “Fuzzy time series and its models”, **Fuzzy Sets and Systems**, 54, 269-277.
- SONG, Q., CHISSOM, B.S.: 1993b “Forecasting enrollments with fuzzy time series- Part I”, **Fuzzy Sets and Systems**, 54, 1-10.
- SONG, Q., CHISSOM, B.S.: 1994 “Forecasting enrollments with fuzzy time series- Part II”, **Fuzzy Sets and Systems**, 62, 1-8.
- STUFFLEBEAM, R.: “Neurons, Synapses, Action Potentials, and Neurotransmission”, (Çevrimiçi), http://www.mind.ilstu.edu/curriculum/neurons_intro/neurons_intro.php, 20.04.2015.

- SULLIVAN, J., WOODALL, A.: 1994 “A Comparison of Fuzzy Forecasting and Markov Modeling”, *Fuzzy Sets and Systems*, Vol.64, pp. 279-293.
- SUN, B.Q., GUO, H., KARIMI, H.R., GE, Y., XIONG, S.: 2015 “Prediction Of Stock Index Futures Prices Based On Fuzzy Sets And Multivariate Fuzzy Time Series”, *Neurocomputing*, 151, 1528–1536.
- ŞEN, Z.: 2004 **Mühendislikte Bulanık Mantık ile Modelleme Prensipleri**, 2.Baskı, İstanbul, Su Vakfı.
- ŞENEL, B., ŞENEL, M.: 2013 “Risk Analizi: Türkiye’de Gerçekleşen Trafik Kazaları Üzerine Hata Ağacı Analizi Uygulaması”, **Anadolu Üniversitesi Sosyal Bilimler Dergisi**, Sayı 13, No:3, ss:65-83.
- TAHA, H.A.: 2000 **Yönelem Araştırması**, 6. Baskıdan Çeviri, İstanbul, Literatür Yayıncılık.
- TAŞGETİREN, M. F.: “Yapay Sinir Ağları”, (Çevrimiçi), <http://www.kirbas.com/index.php?id=164&sec=yapay%20sinir>, 20.04.2015
- TEOH, H.J., CHEN, T.L., CHENG, C.H., CHU, H.H.: 2009 “A hybrid multi-order fuzzy time series for forecasting stock markets”, **Expert Systems with Applications**, 36 , 7888–7897.
- TORTUM A., ÇODUR, Y.: 2007 “Sinirsel Bulanık Sistemler İle Trafik Gürültüsünün Tahmini”, **7. Ulaştırma Kongresi**, TMMOB İnşaat Mühendisleri Odası, İstanbul, 19-21 Eylül 2007.
- TÜİK: “Ulaştırma İstatistikleri 2015”, (Çevrimiçi), http://www.tuik.gov.tr/PreTablo.do?alt_id=1051, 05.10.2015

- TÜİK: “Ölüm Nedeni İstatistikleri 2014”, (Çevrimiçi), <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=18855>, 06.10.2015
- TÜİK: “Ulaştırma İstatistikleri 2014”, (Çevrimiçi), http://www.tuik.gov.tr/PreTablo.do?alt_id=1051, 04.10.2015
- TÜRKBEY, O.: 2003 “Makina Sıralama Problemlerinde Çok Amaçlı Bulanık Küme Yaklaşımı”, **Gazi Üniv. Müh. Mim. Fak. Dergisi**, Cilt:18, No:2, s.63-77.
- USLU, V.R.,
ALADAĞ, C.H.,
YOLCU, U.,
EĞRİOĞLU, E.: 2010 “A new hybrid approach for forecasting a seasonal fuzzy time series”, **International Symposium Computing Science and Engineering Proceeding Book**, 1152-1158.
- UTKUN, E.: 2014 “Giyim Konforunun Tahminlenmesinde Yapay Sinir Ağları Sistemlerinin Kullanımına Yönelik Bir Literatür Araştırması”, **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 20 (7), 272-280.
- WANG, C.H. VE HSU, L.C.: 2008 “Constructing and Applying an Improved Fuzzy Time Series Model: Taking the Tourism Industry for Example”, **Expert Systems with Applications**, Vol.34, pp. 2732–2738.
- WANG, H., GUO, J.,
FENG, H., ZHANG,
F.: 2015 “A New Model of Forecast Enrollment Using Fuzzy Time Series”, **Education Management and Management Science**, Editor: Dawei Zheng, London, Taylor&Francis Group, p. 95-98.

- WANG, N.Y., CHEN, S.M.: 2009 “Temperature prediction and TAIFEX forecasting based on automatic clustering techniques and two-factors high order fuzzy time series”, **Expert Systems with Application**, 36(2), Part 1, 2143-2154.
- YAMAKAWA, T., TEODORESCU, H.-N. L.: 1996 **Neuro-fuzzy Systems: Hybrid Configurations**, Wiesbaden, Vieweg+Teubner Verlag.
- YANG, M., LIU, H.: 2003 “Fuzzy least-squares algorithms for interactive fuzzy linear regression models”, **Elsevier Science Fuzzy Sts and Systems**, Vol.135, s. 305-316.
- YAPICI, N.: 2000 “Bulanık Doğrusal Programlamaya Sinir Ağları Yaklaşımı” (Basılmamış Yüksek Lisans Tezi), Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- YEGNANARAYANA, B.: 2005 **Artificial Neural Networks**, New Delphi, Prentice-Hall of India Private Limited.
- YENİLMEZ, K.: 2001 “Bulanık Doğrusal Programlama Problemleri için Yeni Çözüm Yaklaşımları ve Duyarlılık Analizi” (Basılmamış Doktora Tezi), Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- YILDIZ, B., AKKOÇ, S.: 2009 “Banka Finansal Başarısızlıklarının Sinirsel Bulanık Ağ Yöntemi ile Öngörüsü”, **BDDK Bankacılık ve Finansal Piyasalar**, Cilt:3, Sayı:1, s. 9-36.
- YILDIZ, Ö.: 2006 “Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı” (Yayınlanmamış Yüksek Lisans Tezi), Eskişehir Osmangazi Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.

- YOLCU, U.: 2011 “Bulanık Zaman Serilerinde Çok Değişkenli Çözümleme” (Yayınlanmamış Doktora Tezi), Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- YOLCU, U.,
ALADAĞ, C.H.,
EĞRİOĞLU, E.,
USLU, V.R.: 2013 “Time series forecasting with a novel fuzzy time series approach: an example for İstanbul stock market”. **Journal of Statistical Computation and Simulation**, Vol. 83, No. 4, 599–612.
- YOLCU, U.,
EĞRİOĞLU, E.,
USLU, V.R.,
BAŞARAN, M.A.,
ALADAĞ, C.H.: 2009 “A New Approach for Determining the Length of Intervals for Fuzzy Time Series”, **Applied Soft Computing**, 9, 647-651.
- YU, H.-K.: 2005a “A Refined Fuzzy Time-Series Model for Forecasting”, **Physica A**, 346, pp. 657–681.
- YU, H.-K.: 2005b “Weighted fuzzy time series models for TAIEX forecasting”, **Physica A**, 349, 609-624.
- YU, T.H.-K.,
HUARNG, K.-H.: 2008 “A bivariate fuzzy time series model to forecast the TAIEX”, **Expert Systems with Applications**, 34(4), 2945–2952.
- YU T.H.-K.,
HUARNG K.-H.: 2010 “A neural network based fuzzy time series model to improve forecasting”, **Expert Systems with Applications**, 37, 3366-3372.
- YÜKSEK, A.G.,
BİRCAN, H.,
ZONTUL, M.,
KAYNAR, O.: 2007 “Sivas İlinde Yapay Sinir Ağları ile Hava Kalitesi Modelinin Oluşturulması Üzerine Bir Uygulama”, **Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi**, Cilt 8, Sayı 1, 97-112.

- ZADEH, L.A.: 1965 “Fuzzy sets”, **Information and Control**, 8, 338–353.
- ZADEH L.A.: 1973 “Outline of a new approach to the analysis of complex systems and decisions processes”, **IEEE Trans. Systems Man Cybernet.**, 3, 28-44.
- ZADEH, L.A.: 1975a “The Concept of a Linguistic Variable and Its Application to Approximate Reasoning-I”, **Information Sciences**, Vol:8, 199-249.
- ZADEH, L.A.: 1975b “The concept of a linguistic variable and its applications to approximate reasoning-II”, **Information Sciences**, Vol:8, 301–357.
- ZADEH, L.A.: 1975c “The Concept of a Linguistic Variable and Its Application to Approximate Reasoning-III”, **Information Sciences**, Vol:9, 43-80.
- ZHANG, D., BAI, X., CAI, K.: 2004 “Extended Neuro-Fuzzy Models Of Multilayer Perceptrons”, **Fuzzy Sets and Systems**, 142, 221–242.
- ZHANG, H.C., HUANG, S.H.: 1994 “A fuzzy approach to process plan selection”, **I. J.of Prod. Res.**, 32 (6), 1265-1279.
- ZIMMERMANN, H.J.: 1987 **Fuzzy Sets, Decicion Making and Expert Systems**, Boston, Kluwer Academic Publishers.

EKLER

EK 1: 1990-2014 Yılları Türkiye Trafik Kazaları Veri Seti

Yıl	Nüfus (bin) x1	Toplam Kaza Sayısı x2	Maddi Hasarlı Kaza Sayısı x3	Ölümlü- Yaralanmalı Kaza Sayısı x4	Kaza Yerinde Ölü Sayısı x5	Kaza Yerinde Yaralı Sayısı x6
1990	56154	115295	59354	55941	6317	87668
1991	57272	142145	85653	56532	6231	90520
1992	58392	171741	113437	58304	6214	94820
1993	59513	208823	145534	63289	6457	104330
1994	60637	233803	171219	62584	5942	104717
1995	61763	279663	213634	66029	6004	114319
1996	62909	344643	283853	60790	5428	104599
1997	64064	387533	326053	61480	5125	106246
1998	65215	458661	387421	71240	6083	125793
1999	66350	465915	393646	72269	5713	125158
2000	67420	500664	424673	75991	5510	136751
2001	68365	442960	376717	66243	4386	116203
2002	69302	439777	374029	65748	4093	116412
2003	70231	455637	388606	67031	3946	118214
2004	71152	537352	460344	77008	4427	136437
2005	72065	620789	533516	87273	4505	154086
2006	72974	728755	632627	96128	4633	169080
2007	70586	825561	718567	106994	5007	189057
2008	71517	950120	845908	104212	4236	184468
2009	72561	1053346	942225	111121	4324	201380
2010	73723	1106201	989397	116804	4045	211496
2011	74724	1228928	1097083	131845	3835	238074
2012	75627	1296634	1143082	153552	3750	268079
2013	76668	1207354	1046048	161306	3685	274829
2014	77696	1199010	1030498	168512	3524	285059

Yıl	Kayıtlı Toplam Taşıt Sayısı x7	Kayıtlı Otomobil Sayısı x8	Kayıtlı Otobüs Sayısı x9	Kayıtlı Kamyon Sayısı x10	Kayıtlı Kamyonet Sayısı x11	Kayıtlı Minibüs Sayısı x12
1990	3750678	1649879	63700	257353	263407	125399
1991	4101975	1864344	68973	273409	280891	133632
1992	4584717	2181388	75592	287160	308180	145312
1993	5250622	2619852	84254	305511	354290	159900
1994	5606712	2861640	87545	313771	374473	166424
1995	5922859	3058511	90197	321421	397743	173051
1996	6305707	3274156	94978	333269	442788	182694
1997	6863462	3570105	101896	353586	529838	197057
1998	7371541	3838288	108361	371163	626004	211495
1999	7758511	4072326	112186	378967	692935	221683
2000	8320449	4422180	118454	394283	794459	235885
2001	8521956	4534803	119306	396493	833175	239381
2002	8655170	4600140	120097	399025	875381	241700
2003	8903843	4700343	123500	405034	973457	245394
2004	10236357	5400440	152712	647420	1259867	318954
2005	11145826	5772745	163390	676929	1475057	338539
2006	12227393	6140992	175949	709535	1695624	357523
2007	13022945	6472156	189128	729202	1890459	372601
2008	13765395	6796629	199934	744217	2066007	383548
2009	14316700	7093964	201033	727302	2204951	384053
2010	15095603	7544871	208510	726359	2399038	386973
2011	16089528	8113111	219906	728458	2611104	389435
2012	17033413	8648875	235949	751650	2794606	396119
2013	17939447	9283923	219885	755950	2933050	421848
2014	18828721	9857915	211200	773728	3062479	427264

Yıl	Kayıtlı Motosiklet Sayısı x13	Kayıtlı Diğer Araçların Sayısı x14	Kazaya Karışan Taşıtlar İçinde Otomobillerin Oranı x15	Kazaya Karışan Taşıtlar İçinde Otobüslerin Oranı x16	Kazaya Karışan Taşıtlar İçinde Kamyonların Oranı x17
1990	531941	858999	0,60	0,06	0,11
1991	590488	890238	0,62	0,06	0,11
1992	655347	931738	0,64	0,06	0,10
1993	743320	983495	0,68	0,06	0,10

1994	788586	1014273	0,67	0,05	0,09
1995	819922	1062014	0,68	0,05	0,08
1996	854150	1123672	0,67	0,04	0,08
1997	905121	1205859	0,65	0,05	0,08
1998	940935	1275295	0,65	0,05	0,08
1999	975746	1304668	0,66	0,05	0,07
2000	1011284	1343904	0,67	0,04	0,06
2001	1031221	1367577	0,68	0,04	0,06
2002	1046907	1371920	0,65	0,05	0,06
2003	1073415	1382700	0,65	0,05	0,06
2004	1218677	1238287	0,64	0,05	0,07
2005	1441066	1278100	0,64	0,05	0,08
2006	1822831	1324939	0,60	0,04	0,06
2007	2003492	1365907	0,61	0,04	0,07
2008	2181383	1393677	0,51	0,04	0,08
2009	2303261	1402136	0,52	0,03	0,07
2010	2389488	1440364	0,51	0,03	0,07
2011	2527190	1500324	0,53	0,03	0,07
2012	2657722	1548492	0,52	0,03	0,06
2013	2722826	1601965	0,50	0,03	0,06
2014	2828466	1667669	0,51	0,03	0,05

Yıl	Kazaya	Kazaya	Kazaya	Kazaya	Toplam
	Karışan	Karışan	Karışan	Karışan	
	Taşıtlar İçinde	Taşıtlar İçinde	Taşıtlar İçinde	Taşıtlar İçinde	Bölünmüş
	Kamyonetlerin	Minibüslerin	Motosikletlerin	Araçların	Yol (KM)
	Oranı	Oranı	Oranı	Oranı	Oranı
	x18	x19	x20	x21	x22
1990	0,07	0,07	0,04	0,06	1909,5
1991	0,07	0,07	0,03	0,05	1971,2
1992	0,07	0,06	0,03	0,04	2042,8
1993	0,08	0,06	0,03	0,04	2184,4
1994	0,08	0,06	0,02	0,03	2350,51
1995	0,08	0,06	0,02	0,03	2416,31
1996	0,10	0,06	0,02	0,03	2554,67
1997	0,09	0,06	0,02	0,03	2752,35
1998	0,13	0,06	0,01	0,04	3170,21
1999	0,14	0,06	0,01	0,02	3396,43
2000	0,13	0,06	0,01	0,02	3863,08
2001	0,13	0,06	0,01	0,02	4124,68
2002	0,14	0,06	0,01	0,03	4326,43

2003	0,13	0,07	0,01	0,03	5446,747
2004	0,15	0,06	0,02	0,02	7309,701
2005	0,16	0,05	0,02	0,01	8511,442
2006	0,19	0,05	0,02	0,02	9777,38
2007	0,19	0,05	0,03	0,01	11065,475
2008	0,16	0,04	0,14	0,03	12536,016
2009	0,17	0,04	0,14	0,03	14458,298
2010	0,17	0,04	0,14	0,03	16783,151
2011	0,17	0,04	0,14	0,03	18154,407
2012	0,17	0,03	0,15	0,04	19066,172
2013	0,16	0,03	0,16	0,06	19835
2014	0,16	0,03	0,16	0,06	20305

Yıl	Toplam	Toplam	Toplam	0-14	0-14	15-24	15-24
	Otoyol	Diğer	Köy	0-14	Yaş	15-24	Yaş
	(KM)	Yollar	Yolu	Yaş Ölü	Yaralı	Yaş Ölü	Yaralı
	x23	(KM)	(KM)	Sayısı	Sayısı	Sayısı	Sayısı
		x24	x25	x26	x27	x28	x29
1990	241	57218,5	308587	1476	17815	899	18949
1991	342	57249,8	308602	1386	17633	924	19680
1992	716	57799,2	326521	1359	17597	953	21308
1993	1012	57585,6	327253	1271	18272	1015	24456
1994	1151	57481,49	320029	1265	19473	847	23352
1995	1243	57582,69	320055	1285	21083	852	24827
1996	1411	57670,33	320001	959	16702	790	23690
1997	1470	58088,65	319448	910	16844	781	24566
1998	1628	57714,79	317780	778	18162	806	26489
1999	1639	57526,57	321820	591	14688	638	25156
2000	1674	57226,92	354642	685	18410	460	26156
2001	1696	57180,32	363248	322	11979	441	21800
2002	1714	57041,57	364329	406	13312	384	21505
2003	1753	56044,25	365171	246	11141	378	22041
2004	1662	54504,3	285739	305	12790	409	25247
2005	1667	53427,56	285632	287	15065	420	28188
2006	1908	51986,62	285632	267	15370	431	30235
2007	1908	50846,53	286888	268	17123	463	34422
2008	1922	49486,98	288013	231	16175	365	33484
2009	2036	47760,7	298405	251	18333	428	37568
2010	2080	46001,85	302398	208	19244	366	40331
2011	2119	44775,59	305227	183	21334	384	47723
2012	2127	44188,83	320366	179	26112	351	54332
2013	2127	43661	323043	297	32708	527	68170

2014	2155	43449	170762	278	35003	582	73293
Yıl	25-64 Yaş		65+ Yaş		Sürücü Kusur Oranı x34	Yolcu Kusur Oranı x35	
	Ölü Sayısı x30	Yaralı Sayısı x31	Ölü Sayısı x32	Yaralı Sayısı x33			
1990	3434	46969	371	2107	0,8443	0,0045	
1991	3477	49167	317	2118	0,8753	0,0031	
1992	3369	50954	382	2951	0,9010	0,0020	
1993	3567	55987	449	3138	0,9169	0,0016	
1994	3333	56438	378	3197	0,9290	0,0015	
1995	3368	62334	360	3552	0,9326	0,0013	
1996	3052	58046	365	3340	0,9494	0,0054	
1997	2900	59296	355	3309	0,9731	0,0013	
1998	2760	63324	343	4175	0,9596	0,0026	
1999	2698	60555	352	4318	0,9599	0,0023	
2000	2395	65147	335	4400	0,9606	0,0025	
2001	1793	53530	252	4108	0,9656	0,0031	
2002	1825	54455	257	4415	0,9682	0,0023	
2003	1813	55575	280	4605	0,9703	0,0016	
2004	1940	64245	311	5315	0,9730	0,0011	
2005	2043	72853	372	6061	0,9739	0,0011	
2006	2173	81720	339	6423	0,9807	0,0009	
2007	2251	89201	380	7331	0,9803	0,0009	
2008	1949	86686	311	7176	0,9053	0,0043	
2009	1939	96273	318	8047	0,8960	0,0041	
2010	1848	101214	256	8775	0,8972	0,0036	
2011	1674	113732	274	9273	0,9020	0,0039	
2012	1669	126517	292	10982	0,8886	0,0044	
2013	2354	157301	488	15060	0,8869	0,0042	
2014	2189	159177	452	16585	0,8862	0,0047	

Yıl	Yaya Kusur Oranı x36	Yol Kusur Oranı x37	Araç Kusur Oranı x38
	1990	0,1312	0,0051
1991	0,1027	0,0042	0,0147
1992	0,0827	0,0021	0,0122
1993	0,0678	0,0019	0,0118
1994	0,0553	0,0054	0,0088
1995	0,0433	0,0151	0,0077

1996	0,0398	0,0014	0,0040
1997	0,0214	0,0000	0,0041
1998	0,0272	0,0045	0,0062
1999	0,0269	0,0056	0,0053
2000	0,0240	0,0077	0,0052
2001	0,0232	0,0043	0,0038
2002	0,0239	0,0025	0,0031
2003	0,0232	0,0022	0,0027
2004	0,0218	0,0019	0,0022
2005	0,0204	0,0022	0,0025
2006	0,0162	0,0013	0,0010
2007	0,0164	0,0011	0,0014
2008	0,0837	0,0042	0,0026
2009	0,0909	0,0061	0,0029
2010	0,0897	0,0063	0,0033
2011	0,0851	0,0060	0,0030
2012	0,0975	0,0062	0,0033
2013	0,0899	0,0105	0,0085
2014	0,0938	0,0095	0,0058

EK 2: Normalize Edilmiş Zaman Serileri İçin Birim Kök Testi

Sonuçları

Null Hypothesis: NX1 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.799007	0.6734
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX2 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.142847	0.4967
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX3 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 3 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.440525	0.0728
Test critical values: 1% level	-4.467895	
5% level	-3.644963	
10% level	-3.261452	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX4 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 4 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.030665	0.9997
Test critical values: 1% level	-4.498307	
5% level	-3.658446	
10% level	-3.268973	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX5 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.794629	0.2123
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX6 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.638076	0.9667
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX7 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.248654	0.9875
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX8 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.008075	0.9997
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX9 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.986960	0.5774
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX10 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.883784	0.6315
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX11 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.928583	0.6074
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX12 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.976848	0.5839
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX13 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.975579	0.5833
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX14 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.490323	0.8045
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX15 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.582265	0.2904
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX16 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.532380	0.7892
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX17 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.064386	0.5384
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX18 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.594308	0.7650
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX19 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.401273	0.8342
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX20 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.656533	0.7389
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX21 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 4 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.996510	0.9997
Test critical values: 1% level	-4.498307	
5% level	-3.658446	
10% level	-3.268973	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX22 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.256043	0.4392
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX23 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.893727	0.1816
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX24 has a unit root
Exogenous: None
Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.361304	0.1561
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX25 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.685246	0.7263
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX26 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.338265	0.9976
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX27 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.499661	0.9999
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX28 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.459738	0.9784
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX29 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.748191	1.0000
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX30 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.067936	0.9139
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX31 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.296281	0.9974
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX32 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.104565	0.5175
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX33 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.674688	1.0000
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX34 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.256693	0.4397
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX35 has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.526611	0.0590
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX36 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.425363	0.3585
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX37 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.298631	0.0904
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: NX38 has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.420061	0.8283
Test critical values: 1% level	-4.394309	
5% level	-3.612199	
10% level	-3.243079	

*MacKinnon (1996) one-sided p-values.

EK 3: Birinci Fark Zaman Serileri İçin Birim Kök Testi Sonuçları

Null Hypothesis: D(NX1) has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.414979	0.0022
Test critical values: 1% level	-3.752946	
5% level	-2.998064	
10% level	-2.638752	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.979013	0.0477
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX3) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.983847	0.0472
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX4) has a unit root

Exogenous: None

Lag Length: 4 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.501736	0.8145
Test critical values: 1% level	-2.692358	
5% level	-1.960171	
10% level	-1.607051	

*MacKinnon (1996) one-sided p-values.

Warning: Probabilities and critical values calculated for 20 observations

and may not be accurate for a sample size of 19

Null Hypothesis: D(NX5) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.961423	0.0000
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX6) has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.038928	0.0053
Test critical values: 1% level	-3.752946	
5% level	-2.998064	
10% level	-2.638752	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX7) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
--	-------------	--------

Augmented Dickey-Fuller test statistic	-0.671512	0.4151
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX8) has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.630784	0.4330
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX9) has a unit root
 Exogenous: Constant
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.315998	0.0259
Test critical values: 1% level	-3.752946	
5% level	-2.998064	
10% level	-2.638752	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX10) has a unit root
 Exogenous: None
 Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.869726	0.0005
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX11) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.643091	0.4276
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX12) has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.317701	0.0028
Test critical values: 1% level	-3.752946	
5% level	-2.998064	
10% level	-2.638752	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX13) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.175424	0.2117
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX14) has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
--	-------------	--------

Augmented Dickey-Fuller test statistic	-3.622100	0.0134
Test critical values: 1% level	-3.752946	
5% level	-2.998064	
10% level	-2.638752	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX15) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.062119	0.0000
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX16) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.507087	0.0012
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX17) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.729595	0.0000
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX18) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.818153	0.0000
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX19) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.344615	0.0001
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX20) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.693024	0.0001
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX21) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
--	-------------	--------

Augmented Dickey-Fuller test statistic	-7.873823	0.0000
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX22) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.866767	0.3296
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX23) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.087346	0.0198
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX24) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.129975	0.2272
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX25) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.368021	0.0203
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX26) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.271115	0.0000
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX27) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.120017	0.0003
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX28) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
--	-------------	--------

Augmented Dickey-Fuller test statistic	-4.321430	0.0001
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX29) has a unit root

Exogenous: None

Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	0.559099	0.8292
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX30) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.369414	0.0001
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX31) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.855137	0.0039
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX32) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.415022	0.0000
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX33) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.014140	0.0443
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX34) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.851753	0.0005
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX35) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
--	-------------	--------

Augmented Dickey-Fuller test statistic	-7.230307	0.0000
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX36) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.001304	0.0003
Test critical values: 1% level	-2.669359	
5% level	-1.956406	
10% level	-1.608495	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX37) has a unit root

Exogenous: None

Lag Length: 1 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.490770	0.0000
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX38) has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.604077	0.0001
Test critical values: 1% level	-4.416345	
5% level	-3.622033	
10% level	-3.248592	

*MacKinnon (1996) one-sided p-values.

EK 4: İkinci Fark Zaman Serileri İçin Birim Kök Testi Sonuçları

Null Hypothesis: D(NX4,2) has a unit root

Exogenous: Constant

Lag Length: 3 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.510657	0.0000
Test critical values: 1% level	-3.831511	
5% level	-3.029970	
10% level	-2.655194	

*MacKinnon (1996) one-sided p-values.

Warning: Probabilities and critical values calculated for 20 observations

and may not be accurate for a sample size of 19

Null Hypothesis: D(NX7,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.001202	0.0000
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX8,2) has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.162841	0.0000
Test critical values: 1% level	-3.769597	
5% level	-3.004861	
10% level	-2.642242	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX11,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.934376	0.0000
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX13,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.096141	0.0000
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX22,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.034577	0.0003
Test critical values: 1% level	-2.674290	
5% level	-1.957204	
10% level	-1.608175	

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX24,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.320830	0.0000

Test critical values:	1% level	-2.674290
	5% level	-1.957204
	10% level	-1.608175

*MacKinnon (1996) one-sided p-values.

Null Hypothesis: D(NX29,2) has a unit root

Exogenous: None

Lag Length: 0 (Automatic - based on SIC, maxlag=5)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-9.807952	0.0000
Test critical values:		
	1% level	-2.674290
	5% level	-1.957204
	10% level	-1.608175

*MacKinnon (1996) one-sided p-values.

EK 5: Tanımsal İstatistikler İçin Kullanılan R Kodları

```
> tez_data <- read.csv2("C:/Users/bmyo/Desktop/tez son/  
son datalar 19.10.2015/tez_data.csv")  
> View(tez_data)  
> summary(tez_data)  
  
> normaldata <- read.csv2("C:/Users/bmyo/Desktop/tez son/  
son datalar 19.10.2015/normaldata.csv")  
> View(normaldata)  
> summary(normaldata)
```

EK 6: ARDL Modeli Hata Terimleri Serisi

Yıllar	Hata Terimleri
1990	-
1991	0.01737594795048818
1992	-0.0212096131019715
1993	-0.02028847013440477
1994	-0.01406684211241543
1995	0.03374045521667229
1996	0.02196603357418175
1997	-9.71279863388741e-05
1998	-0.00557958938217451
1999	-0.001679682765278301
2000	0.01009706014042255
2001	-0.03407798007157203
2002	-0.0176398347567388
2003	0.05490112487290522
2004	-0.06489561279782508
2005	0.04153754257059761
2006	0.001787654725953103
2007	0.001588515081426101
2008	-0.005197374145658573
2009	0.01023869058648641
2010	0.01040860448222583
2011	-0.02285520561081039
2012	0.001898028484885183
2013	0.01626587214665975
2014	-0.01421819696770782

EK 7: Normal ve Gecikmeli Zaman Serileri

yıllar	nx1(t)	nx2(t)	nx5(t)	nx6(t)	nx15(t)	nx23(t)	nx30(t)	nx34(t)
1990	0	0	0,9523	0	0,5478	0	0,9299	0
1991	0,0519	0,0227	0,9229	0,0144	0,6511	0,0528	0,9526	0,2274
1992	0,1039	0,0478	0,9171	0,0362	0,7472	0,2482	0,8957	0,4158
1993	0,1559	0,0792	1	0,0844	0,9909	0,4028	1	0,5324
1994	0,2081	0,1003	0,8244	0,0864	0,9552	0,4754	0,8767	0,6212
1995	0,2604	0,1391	0,8456	0,135	1	0,5235	0,8952	0,6477
1996	0,3136	0,1941	0,6492	0,0858	0,9232	0,6113	0,7287	0,7708
1997	0,3672	0,2304	0,5459	0,0941	0,832	0,6421	0,6486	0,9449
1998	0,4206	0,2907	0,8725	0,1931	0,7917	0,7247	0,5748	0,8453
1999	0,4733	0,2968	0,7463	0,1899	0,8509	0,7304	0,5421	0,8478
2000	0,523	0,3262	0,6771	0,2487	0,948	0,7487	0,3825	0,8532
2001	0,5668	0,2774	0,2939	0,1446	0,9579	0,7602	0,0653	0,8898
2002	0,6103	0,2747	0,194	0,1456	0,8381	0,7696	0,0822	0,9087
2003	0,6535	0,2881	0,1439	0,1547	0,7973	0,79	0,0759	0,9239
2004	0,6962	0,3573	0,3079	0,2471	0,7347	0,7424	0,1428	0,9436
2005	0,7386	0,4279	0,3345	0,3365	0,7482	0,745	0,197	0,9507
2006	0,7808	0,5193	0,3781	0,4124	0,5601	0,871	0,2655	1
2007	0,6699	0,6012	0,5056	0,5136	0,5766	0,871	0,3066	0,9976
2008	0,7132	0,7067	0,2428	0,4904	0,026	0,8783	0,1475	0,447
2009	0,7616	0,7941	0,2728	0,5761	0,1143	0,9378	0,1423	0,3791
2010	0,8156	0,8388	0,1776	0,6273	0,059	0,9608	0,0943	0,3878
2011	0,862	0,9427	0,106	0,762	0,126	0,9812	0,0026	0,4232
2012	0,904	1	0,0771	0,914	0,092	0,9854	0	0,325
2013	0,9523	0,9244	0,0549	0,9482	0	0,9854	0,3609	0,3123
2014	1	0,9174	0	1	0,0138	1	0,274	0,3076

yıllar	nx1(t-1)	nx2(t-1)	nx5(t-1)	nx6(t-1)
1990	NA	NA	NA	NA
1991	0	0	0,95227	0
1992	0,0519	0,02273	0,92295	0,01445
1993	0,10389	0,04778	0,91715	0,03623
1994	0,15593	0,07917	1	0,08441
1995	0,20811	0,10032	0,82441	0,08637
1996	0,26038	0,13914	0,84555	0,13502
1997	0,31357	0,19414	0,64916	0,08577
1998	0,36719	0,23045	0,54586	0,09412
1999	0,42062	0,29066	0,87249	0,19314
2000	0,47331	0,2968	0,74633	0,18993
2001	0,52298	0,32621	0,67712	0,24866
2002	0,56685	0,27737	0,2939	0,14456
2003	0,61034	0,27467	0,194	0,14562
2004	0,65347	0,2881	0,14388	0,15475
2005	0,69622	0,35727	0,30788	0,24707
2006	0,7386	0,4279	0,33447	0,33648
2007	0,7808	0,51929	0,37811	0,41244
2008	0,66995	0,60124	0,50563	0,51365
2009	0,71316	0,70668	0,24275	0,4904
2010	0,76163	0,79406	0,27276	0,57607
2011	0,81557	0,8388	0,17763	0,62732
2012	0,86204	0,94269	0,10603	0,76197
2013	0,90396	1	0,07705	0,91398
2014	0,95228	0,92442	0,05489	0,94817

yıllar	nx15(t-1)	nx23(t-1)	nx30(t-1)	nx34(t-1)
1990	NA	NA	NA	NA
1991	0,54777	0	0,92993	0
1992	0,65114	0,05277	0,95258	0,22735
1993	0,74718	0,24817	0,89568	0,41584
1994	0,99088	0,40282	1	0,53245
1995	0,95524	0,47544	0,87671	0,62119
1996	1	0,52351	0,89515	0,64771
1997	0,92315	0,61129	0,72866	0,7708
1998	0,83202	0,64211	0,64858	0,94487
1999	0,79172	0,72466	0,57482	0,84533
2000	0,8509	0,73041	0,54215	0,8478
2001	0,94796	0,74869	0,38251	0,85321

2002	0,95789	0,76019	0,06533	0,88975
2003	0,83814	0,76959	0,08219	0,90869
2004	0,79726	0,78997	0,07587	0,92387
2005	0,73467	0,74242	0,14278	0,94362
2006	0,74823	0,74504	0,19705	0,95067
2007	0,56007	0,87095	0,26554	1
2008	0,57662	0,87095	0,30664	0,99758
2009	0,02598	0,87827	0,14752	0,44701
2010	0,11434	0,93783	0,14226	0,37908
2011	0,05904	0,96082	0,09431	0,38785
2012	0,12605	0,98119	0,00263	0,42319
2013	0,09201	0,98537	0	0,32502
2014	0	0,98537	0,36091	0,31234

EK 8: Yapay Sinir Ağı Oluşturulurken Kullanılan R Kodları ve

Çıktıları

```
> nnnn1<-neuralnet(nx30.t.~nx1.t.+nx2.t.+nx5.t.+nx6.t.+nx15.t.+nx23.t.+nx34.t.+nx1.t.1.+nx2.t.1.+nx5.t.1.+nx6.t.1.+nx15.t.1.+nx23.t.1.+nx30.t.1.+nx34.t.1.,data = ysadata_train,hidden=c(5,5,5),rep=15)
```

```
> print(nnnn1)
```

```
> nn40<-neuralnet(nx30.t.~nx1.t.+nx2.t.+nx5.t.+nx6.t.+nx15.t.+nx23.t.+nx34.t.+nx1.t.1.+nx2.t.1.+nx5.t.1.+nx6.t.1.+nx15.t.1.+nx23.t.1.+nx30.t.1.+nx34.t.1.,data = ysadata_train,hidden=40,rep=80)
```

```
> print(nn40)
```

```
Call: neuralnet(formula = nx30.t. ~ nx1.t. + nx2.t. + nx5.t. + nx6.t. + nx15.t. + nx23.t. + nx34.t. + nx1.t.1. + nx2.t.1. + nx5.t.1. + nx6.t.1. + nx15.t.1. + nx23.t.1. + nx30.t.1. + nx34.t.1., data = ysadata_train, hidden = 40, rep = 80)
```

80 repetitions were calculated.

	Error	Reached Threshold	Steps
55	0.001333493341	0.009492395189	407
65	0.004817347342	0.009976460146	247
17	0.005173743614	0.008382382869	308
4	0.00555249080	0.008380357058	219
32	0.006004865284	0.009549281063	253
54	0.006025771009	0.007178130808	281
33	0.006173497283	0.009878429214	369
49	0.006476922335	0.008584635637	383
31	0.006495342649	0.008348380270	260
76	0.006907125901	0.009371640128	367
13	0.007114956159	0.008108581735	184
50	0.007153367996	0.008323530950	216
15	0.007204855517	0.009300448628	232
22	0.007296595942	0.009866701509	294
66	0.007317737748	0.007891473699	239
8	0.007319319915	0.008776282327	241
41	0.008126653599	0.008348731566	189
47	0.008173210302	0.004875747304	164
16	0.008753112350	0.009494366736	347
29	0.009030625473	0.007237116238	244
70	0.009472675176	0.009402052158	181
73	0.009566196112	0.008121680476	101
75	0.009641222332	0.008198826767	412
26	0.009745785569	0.008254021931	290
71	0.009857311501	0.007698573274	146
40	0.010083914380	0.009473370093	280
34	0.010244609823	0.009722460004	274
44	0.010409606261	0.009781442009	163
69	0.010459034255	0.009974151124	96
59	0.010514023064	0.009079695552	265
5	0.010546187631	0.009983799192	168
43	0.010621984819	0.008913072638	163
72	0.010989767131	0.009799833413	166
63	0.011021740375	0.008390237300	230
80	0.011232479409	0.008207054893	118
45	0.011244800227	0.008987450560	272
39	0.011279725075	0.009809350020	141
79	0.011463495697	0.007415263029	116
67	0.011497083434	0.009684834288	187

35	0.011531520195	0.009618287995	151
74	0.011710074451	0.008730364202	222
12	0.011759870839	0.009383193882	106
38	0.011761933585	0.009879246086	276
25	0.011821961304	0.009391198847	144
46	0.011824552100	0.008756660927	273
30	0.012241210218	0.007566601923	236
64	0.012276584744	0.009845015982	212
21	0.012550407965	0.009679410341	179
57	0.012596954235	0.009024505987	241
52	0.012597818540	0.009108784715	194
14	0.012727846945	0.009219407346	300
1	0.012746098148	0.009087419432	139
3	0.012928724163	0.009684377739	131
68	0.013035560824	0.009612536752	115
6	0.013156151727	0.008627245396	190
53	0.013513179708	0.008508832637	218
10	0.013576758967	0.009981200744	256
36	0.013737166621	0.009843162567	156
11	0.013793281995	0.008682287795	211
56	0.013948149838	0.008756527751	143
60	0.014167523443	0.009972743064	260
42	0.014284747906	0.009235374482	123
20	0.014373997249	0.009511491250	194
48	0.014377975961	0.009920865181	263
62	0.014400138538	0.009546692810	454
51	0.014553607283	0.009737174654	234
77	0.015210704261	0.009792965086	124
61	0.015587923755	0.009276342009	131
28	0.015790679205	0.009854288887	177
19	0.015956639480	0.009311728195	141
23	0.016024513617	0.008454378965	150
27	0.016038277535	0.009670477568	111
24	0.016433712864	0.008686845780	123
18	0.016807184008	0.009246012475	144
9	0.017378395664	0.009067865702	176
58	0.019948855361	0.007823929266	194
7	0.021531142301	0.009957596079	159
2	0.022602778180	0.007570635134	307
37	0.024899307715	0.009392997837	152
78	0.026329366759	0.009913704596	197

```
> prediction(nn40)$rep55
```

```
Data Error: 0;
```

```

      nx30.t.
1  0.94974396604
2  0.90212493318
3  0.98784516560
4  0.14582955016
5  0.88728672416
6  0.90649124257
7  0.70816798942
8  0.65439921223
9  0.53419084923
10 0.36926825615
11 0.08622902096
12 0.08789861884
13 0.04938874311
14 0.15680903964
15 0.19906110842
16 0.58357641696
17 0.25693191748
18 0.14881415112

```

19 0.30627673607

```
> ysadata_test <- read.csv("C:/Users/matalay/Desktop/tez son/son dat  
alar 19.10.2015/ysadata_test.csv", sep=";", dec=",")
```

```
> View(ysadata_test)
```

```
> nn40<-neuralnet(nx30.t.~nx1.t.+nx2.t.+nx5.t.+nx6.t.+nx15.t.+nx23.t  
.+nx34.t.+nx1.t.1.+nx2.t.1.+nx5.t.1.+nx6.t.1.+nx15.t.1.+nx23.t.1.+nx  
30.t.1.+nx34.t.1.,data = ysadata_train,hidden=40,rep=80)
```

```
> nn40.test <- compute(nn40, ysadata_test)
```

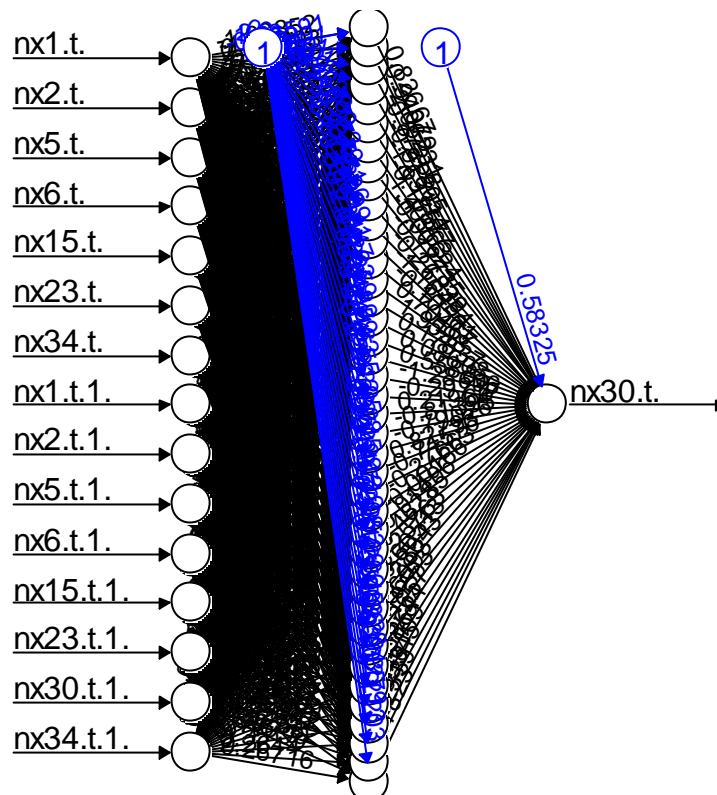
```
> ls(nn40.test)  
[1] "net.result" "neurons"
```

```
> print(nn40.test$net.result)
```

```
      [,1]  
[1,] 0.14618096093  
[2,] 0.24777011442  
[3,] 0.26846199742  
[4,] 0.23921814044  
[5,] 0.05505923636
```

```
> plot.nn(nn40)
```

There were 50 or more warnings (use warnings() to see the first 50)



EK 9: Kümeleme İçin Kullanılan R Kodları

```
> setwd("C:/Users/matalay/Desktop/tez son/son datalar")
> ysadata <- read.csv("C:/Users/matalay/Desktop/tez son/son datalar/ysadata.csv", sep=";", dec=",")
> View(ysadata)
> wss <- (nrow(ysadata)-1)*sum(apply(ysadata,2,var))
> for (i in 2:15) wss[i] <- sum(kmeans(ysadata,centers=i)$+withinss)
> plot(1:15, wss, type="b", xlab="Number of Clusters",ylab="Within groups sum of squares")
```

EK 10: Zaman Serilerinin Tüm Değerleri İçin Hesaplanan Üyelik Değerleri (Gaussian Fonksiyonu için)

1. Aralığın Merkezi (m_1)	2. Aralığın Merkezi (m_2)	3. Aralığın Merkezi (m_3)	4. Aralığın Merkezi (m_4)	5. Aralığın Merkezi (m_5)
-0,3	0,1	0,5	0,9	1,3

Gözlemlerin Üyelik Değerleri

t	nx1(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,051899	0,212692	0,971492	0,081273	0,000125	3,49E-09
3	0,10389	0,130147	0,999811	0,140677	0,000363	1,71E-08
4	0,155928	0,074394	0,961655	0,227679	0,000987	7,84E-08
5	0,208105	0,039671	0,864085	0,344717	0,002519	3,37E-07
6	0,260375	0,019737	0,725059	0,487848	0,006012	1,36E-06
7	0,313573	0,009042	0,565429	0,64763	0,013586	5,22E-06
8	0,36719	0,003832	0,40968	0,802132	0,028765	1,89E-05
9	0,42062	0,001517	0,27666	0,924258	0,056554	6,34E-05
10	0,473308	0,000567	0,175172	0,991134	0,102712	0,000195
11	0,522978	0,00021	0,106844	0,993422	0,169176	0,000528
12	0,566846	8,33E-05	0,065591	0,945676	0,249725	0,001208
13	0,610343	3,17E-05	0,038557	0,858822	0,350369	0,002618
14	0,653468	1,16E-05	0,02173	0,744975	0,467794	0,00538
15	0,696221	4,1E-06	0,011755	0,617989	0,595073	0,010495
16	0,738604	1,39E-06	0,006111	0,490835	0,722087	0,019457
17	0,7808	4,56E-07	0,003047	0,373211	0,837271	0,034403
18	0,669947	7,81E-06	0,01724	0,696961	0,516049	0,006998
19	0,713165	2,68E-06	0,009099	0,566663	0,646397	0,013505
20	0,761628	7,61E-07	0,004203	0,42502	0,787152	0,026701
21	0,81557	1,75E-07	0,001661	0,287998	0,914748	0,053215
22	0,862037	4,67E-08	0,000704	0,194294	0,982146	0,090932
23	0,903955	1,35E-08	0,00031	0,130062	0,999804	0,140768
24	0,952279	3,07E-09	0,000114	0,07754	0,966413	0,220607
25	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
t	nx2(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,022728	0,272009	0,928081	0,057998	6,64E-05	1,39E-09
3	0,047781	0,220491	0,96649	0,077594	0,000114	3,07E-09
4	0,079171	0,165773	0,994592	0,109294	0,00022	8,11E-09
5	0,100317	0,134907	0,999999	0,135764	0,000338	1,54E-08
6	0,139137	0,089769	0,981036	0,196366	0,00072	4,83E-08

7	0,194142	0,047254	0,895131	0,310565	0,001974	2,3E-07
8	0,230449	0,029683	0,80839	0,40324	0,003684	6,16E-07
9	0,290658	0,012766	0,63484	0,578221	0,009646	2,95E-06
10	0,296799	0,011654	0,616238	0,596823	0,010587	3,44E-06
11	0,326214	0,007433	0,527473	0,685559	0,01632	7,12E-06
12	0,277367	0,0155	0,674867	0,538178	0,007861	2,1E-06
13	0,274673	0,016113	0,682916	0,530119	0,007537	1,96E-06
14	0,288099	0,013257	0,642581	0,570479	0,009276	2,76E-06
15	0,35727	0,004516	0,437207	0,775189	0,025174	1,5E-05
16	0,427899	0,001329	0,260807	0,937085	0,061668	7,43E-05
17	0,519292	0,000227	0,111072	0,995358	0,163371	0,000491
18	0,601238	3,9E-05	0,043261	0,879753	0,327675	0,002235
19	0,706677	3,15E-06	0,010045	0,586289	0,626772	0,012272
20	0,794057	3,18E-07	0,002426	0,339299	0,869099	0,040773
21	0,838799	9,11E-08	0,001089	0,238161	0,95426	0,07003
22	0,942687	4,14E-09	0,00014	0,086324	0,97748	0,202725
23	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
24	0,924425	7,26E-09	0,000204	0,10522	0,992571	0,171494
25	0,917362	9,01E-09	0,000236	0,113338	0,996239	0,160389

t	nx5(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,922946	7,6E-09	0,000211	0,106881	0,99344	0,169124
3	0,91715	9,07E-09	0,000237	0,113588	0,99633	0,160064
4	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
5	0,824412	1,37E-07	0,001416	0,26833	0,931071	0,059172
6	0,845551	7,52E-08	0,00096	0,224795	0,963619	0,075656
7	0,649165	1,29E-05	0,023057	0,757201	0,455445	0,005017
8	0,545857	0,000131	0,083337	0,974056	0,208522	0,000818
9	0,872486	3,44E-08	0,000576	0,176521	0,990582	0,101814
10	0,746335	1,14E-06	0,005397	0,468364	0,744411	0,02167
11	0,677122	6,56E-06	0,015555	0,6756	0,537444	0,007831
12	0,293897	0,012168	0,625033	0,588028	0,010132	3,2E-06
13	0,193999	0,047338	0,895433	0,310226	0,001969	2,29E-07
14	0,14388	0,08519	0,976219	0,204893	0,000788	5,55E-08
15	0,307876	0,009864	0,582658	0,630403	0,012492	4,53E-06
16	0,33447	0,006526	0,502982	0,709991	0,018356	8,69E-06
17	0,378111	0,003189	0,380289	0,830513	0,03322	2,43E-05
18	0,505626	0,0003	0,127881	0,999604	0,14311	0,000375
19	0,242755	0,025165	0,77512	0,437277	0,004518	8,55E-07
20	0,272758	0,016562	0,688619	0,524408	0,007314	1,87E-06
21	0,177634	0,057747	0,92743	0,272805	0,00147	1,45E-07
22	0,106035	0,127352	0,999545	0,143689	0,000378	1,82E-08

23	0,077054	0,169124	0,99344	0,106881	0,000211	7,6E-09
24	0,054893	0,20714	0,974887	0,084036	0,000133	3,84E-09
25	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
t	nx6(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,014448	0,290552	0,912572	0,052497	5,53E-05	1,07E-09
3	0,036233	0,243374	0,950442	0,067983	8,91E-05	2,14E-09
4	0,084411	0,157686	0,996967	0,115449	0,000245	9,51E-09
5	0,086372	0,154735	0,997681	0,117819	0,000255	1,01E-08
6	0,135016	0,093903	0,98479	0,18916	0,000665	4,29E-08
7	0,085774	0,155631	0,997473	0,117093	0,000252	9,91E-09
8	0,094118	0,143473	0,999568	0,127549	0,000298	1,28E-08
9	0,193145	0,04784	0,897225	0,308201	0,001939	2,23E-07
10	0,189928	0,049769	0,903854	0,300649	0,001832	2,04E-07
11	0,248659	0,023218	0,758629	0,454001	0,004976	9,99E-07
12	0,144561	0,084549	0,975485	0,206137	0,000798	5,66E-08
13	0,14562	0,083558	0,974321	0,208083	0,000814	5,83E-08
14	0,154749	0,075399	0,963225	0,225377	0,000966	7,58E-08
15	0,247068	0,023729	0,763103	0,449472	0,004849	9,58E-07
16	0,336479	0,006321	0,497067	0,715884	0,018884	9,12E-06
17	0,41244	0,001756	0,29516	0,908615	0,05123	5,29E-05
18	0,513646	0,000255	0,117798	0,997675	0,154761	0,00044
19	0,490397	0,000406	0,148804	0,998848	0,122802	0,000277
20	0,576075	6,81E-05	0,058831	0,930212	0,26939	0,001429
21	0,627323	2,15E-05	0,030935	0,816572	0,394788	0,003496
22	0,76197	7,54E-07	0,00418	0,424072	0,788081	0,026824
23	0,913978	9,99E-09	0,000253	0,117394	0,997561	0,155258
24	0,948174	3,49E-09	0,000124	0,081207	0,971408	0,212828
25	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
t	nx15(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,651145	1,23E-05	0,022438	0,751593	0,461114	0,005181
3	0,74718	1,11E-06	0,005324	0,465927	0,746826	0,021925
4	0,990881	8,99E-10	4,91E-05	0,049191	0,901908	0,302876
5	0,955238	2,8E-09	0,000107	0,074981	0,962577	0,226331
6	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
7	0,923155	7,55E-09	0,00021	0,106645	0,993321	0,169458
8	0,832018	1,1E-07	0,001233	0,252095	0,943868	0,064726
9	0,791715	3,39E-07	0,002527	0,345168	0,863666	0,039581
10	0,850896	6,45E-08	0,000869	0,214574	0,97031	0,080365
11	0,947957	3,51E-09	0,000125	0,081405	0,971661	0,212422
12	0,957888	2,57E-09	0,000101	0,072747	0,958977	0,23154
13	0,838142	9,29E-08	0,001102	0,239488	0,953296	0,069502

14	0,797256	2,91E-07	0,002295	0,331372	0,876381	0,042451
15	0,734668	1,54E-06	0,006506	0,502398	0,710573	0,018407
16	0,748231	1,08E-06	0,005234	0,462906	0,749818	0,022245
17	0,560075	9,64E-05	0,070944	0,95589	0,235896	0,001066
18	0,576618	6,73E-05	0,058451	0,929248	0,270577	0,001443
19	0,025984	0,264923	0,933812	0,060287	7,13E-05	1,54E-09
20	0,114342	0,116952	0,997432	0,155804	0,000446	2,34E-08
21	0,059041	0,199612	0,979248	0,087987	0,000145	4,36E-09
22	0,126049	0,103419	0,991554	0,174123	0,00056	3,3E-08
23	0,092005	0,146482	0,999201	0,124837	0,000286	1,2E-08
24	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
25	0,013751	0,292147	0,911207	0,052054	5,45E-05	1,04E-09
t	nx23(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,052769	0,211068	0,972501	0,082069	0,000127	3,59E-09
3	0,248171	0,023374	0,760002	0,452612	0,004937	9,86E-07
4	0,402821	0,002082	0,317823	0,888655	0,04551	4,27E-05
5	0,475444	0,000544	0,171705	0,992491	0,105073	0,000204
6	0,523511	0,000208	0,106244	0,993114	0,170027	0,000533
7	0,611285	3,1E-05	0,038096	0,856582	0,352765	0,002661
8	0,642111	1,52E-05	0,025386	0,7769	0,435467	0,004471
9	0,72466	2E-06	0,007616	0,532111	0,680927	0,01596
10	0,730408	1,72E-06	0,006959	0,514996	0,698011	0,017328
11	0,748694	1,07E-06	0,005195	0,461576	0,751135	0,022388
12	0,760188	7,91E-07	0,004304	0,429032	0,78322	0,026188
13	0,769592	6,16E-07	0,003682	0,403128	0,808498	0,029699
14	0,789969	3,55E-07	0,002604	0,34958	0,859559	0,03871
15	0,742424	1,26E-06	0,005748	0,479688	0,733171	0,020525
16	0,745037	1,18E-06	0,005512	0,472113	0,740692	0,021284
17	0,870951	3,6E-08	0,000593	0,179056	0,989507	0,100155
18	0,870951	3,6E-08	0,000593	0,179056	0,989507	0,100155
19	0,878265	2,91E-08	0,000515	0,167201	0,994112	0,108257
20	0,937827	4,81E-09	0,000155	0,091068	0,982273	0,194054
21	0,960815	2,35E-09	9,49E-05	0,070342	0,954821	0,237383
22	0,981191	1,23E-09	6,09E-05	0,055337	0,920903	0,280695
23	0,985371	1,07E-09	5,55E-05	0,052612	0,912924	0,29014
24	0,985371	1,07E-09	5,55E-05	0,052612	0,912924	0,29014
25	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
t	nx30(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952582	3,04E-09	0,000113	0,077276	0,96603	0,221188
3	0,89568	1,73E-08	0,000366	0,141277	0,999767	0,129583
4	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652

5	0,876712	3,04E-08	0,000531	0,16967	0,993244	0,106495
6	0,895153	1,76E-08	0,00037	0,142015	0,999706	0,128894
7	0,728662	1,8E-06	0,007153	0,520182	0,692837	0,016902
8	0,648577	1,3E-05	0,023244	0,758858	0,453769	0,00497
9	0,574816	7,01E-05	0,059718	0,932424	0,266652	0,001397
10	0,54215	0,000141	0,086839	0,978037	0,201753	0,000762
11	0,382508	0,00296	0,368751	0,841512	0,035173	2,69E-05
12	0,065332	0,188559	0,985089	0,094259	0,000165	5,3E-09
13	0,082192	0,161076	0,996044	0,11281	0,000234	8,89E-09
14	0,075869	0,17102	0,992748	0,105548	0,000206	7,33E-09
15	0,142782	0,086233	0,977381	0,202896	0,000771	5,37E-08
16	0,19705	0,045583	0,888934	0,317513	0,002077	2,49E-07
17	0,265543	0,018353	0,709954	0,503019	0,006528	1,55E-06
18	0,306639	0,010051	0,586406	0,626656	0,012265	4,4E-06
19	0,147524	0,081801	0,972163	0,211613	0,000844	6,16E-08
20	0,142255	0,086738	0,977929	0,201943	0,000764	5,29E-08
21	0,09431	0,143201	0,999595	0,127798	0,000299	1,28E-08
22	0,002634	0,318273	0,888251	0,045404	4,25E-05	7,29E-10
23	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
24	0,360906	0,004254	0,42703	0,785183	0,026443	1,63E-05
25	0,273973	0,016276	0,685004	0,528029	0,007455	1,93E-06
t	nx34(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,227355	0,030922	0,816491	0,394872	0,003498	5,67E-07
3	0,415839	0,001653	0,287386	0,915268	0,053389	5,7E-05
4	0,53245	0,000173	0,096553	0,986924	0,184766	0,000634
5	0,621191	2,47E-05	0,033524	0,832275	0,378448	0,003152
6	0,647712	1,33E-05	0,023521	0,761295	0,451303	0,0049
7	0,770802	5,96E-07	0,003608	0,399847	0,811679	0,030178
8	0,944869	3,87E-09	0,000133	0,08426	0,975149	0,206702
9	0,845332	7,56E-08	0,000964	0,22522	0,963332	0,075469
10	0,847804	7,05E-08	0,000921	0,220447	0,966519	0,077614
11	0,853212	6,03E-08	0,000832	0,210244	0,973007	0,082476
12	0,889752	2,07E-08	0,000411	0,149743	0,998688	0,121993
13	0,90869	1,17E-08	0,000282	0,123954	0,999056	0,147483
14	0,923872	7,39E-09	0,000207	0,105838	0,992902	0,170606
15	0,943619	4,02E-09	0,000137	0,085437	0,976498	0,204417
16	0,950672	3,23E-09	0,000118	0,07896	0,968414	0,21754
17	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
18	0,997582	7,24E-10	4,23E-05	0,045282	0,887784	0,318794
19	0,447014	0,000935	0,221964	0,965515	0,076923	0,000112
20	0,379081	0,003137	0,37773	0,832961	0,033643	2,49E-05

21	0,387845	0,002701	0,354983	0,854504	0,037674	3,04E-05
22	0,423185	0,001448	0,271008	0,928898	0,058314	6,71E-05
23	0,32502	0,007573	0,531037	0,682	0,016042	6,91E-06
24	0,312337	0,009215	0,569164	0,643896	0,013342	5,06E-06
25	0,307632	0,0099	0,583397	0,629664	0,012447	4,51E-06
t	nx1(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
3	0,051899	0,212692	0,971492	0,081273	0,000125	3,49E-09
4	0,10389	0,130147	0,999811	0,140677	0,000363	1,71E-08
5	0,155928	0,074394	0,961655	0,227679	0,000987	7,84E-08
6	0,208105	0,039671	0,864085	0,344717	0,002519	3,37E-07
7	0,260375	0,019737	0,725059	0,487848	0,006012	1,36E-06
8	0,313573	0,009042	0,565429	0,64763	0,013586	5,22E-06
9	0,36719	0,003832	0,40968	0,802132	0,028765	1,89E-05
10	0,42062	0,001517	0,27666	0,924258	0,056554	6,34E-05
11	0,473308	0,000567	0,175172	0,991134	0,102712	0,000195
12	0,522978	0,00021	0,106844	0,993422	0,169176	0,000528
13	0,566846	8,33E-05	0,065591	0,945676	0,249725	0,001208
14	0,610343	3,17E-05	0,038557	0,858822	0,350369	0,002618
15	0,653468	1,16E-05	0,02173	0,744975	0,467794	0,00538
16	0,696221	4,1E-06	0,011755	0,617989	0,595073	0,010495
17	0,738604	1,39E-06	0,006111	0,490835	0,722087	0,019457
18	0,7808	4,56E-07	0,003047	0,373211	0,837271	0,034403
19	0,669947	7,81E-06	0,01724	0,696961	0,516049	0,006998
20	0,713165	2,68E-06	0,009099	0,566663	0,646397	0,013505
21	0,761628	7,61E-07	0,004203	0,42502	0,787152	0,026701
22	0,81557	1,75E-07	0,001661	0,287998	0,914748	0,053215
23	0,862037	4,67E-08	0,000704	0,194294	0,982146	0,090932
24	0,903955	1,35E-08	0,00031	0,130062	0,999804	0,140768
25	0,952279	3,07E-09	0,000114	0,07754	0,966413	0,220607
t	nx2(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
3	0,022728	0,272009	0,928081	0,057998	6,64E-05	1,39E-09
4	0,047781	0,220491	0,96649	0,077594	0,000114	3,07E-09
5	0,079171	0,165773	0,994592	0,109294	0,00022	8,11E-09
6	0,100317	0,134907	0,999999	0,135764	0,000338	1,54E-08
7	0,139137	0,089769	0,981036	0,196366	0,00072	4,83E-08
8	0,194142	0,047254	0,895131	0,310565	0,001974	2,3E-07
9	0,230449	0,029683	0,80839	0,40324	0,003684	6,16E-07
10	0,290658	0,012766	0,63484	0,578221	0,009646	2,95E-06
11	0,296799	0,011654	0,616238	0,596823	0,010587	3,44E-06

12	0,326214	0,007433	0,527473	0,685559	0,01632	7,12E-06
13	0,277367	0,0155	0,674867	0,538178	0,007861	2,1E-06
14	0,274673	0,016113	0,682916	0,530119	0,007537	1,96E-06
15	0,288099	0,013257	0,642581	0,570479	0,009276	2,76E-06
16	0,35727	0,004516	0,437207	0,775189	0,025174	1,5E-05
17	0,427899	0,001329	0,260807	0,937085	0,061668	7,43E-05
18	0,519292	0,000227	0,111072	0,995358	0,163371	0,000491
19	0,601238	3,9E-05	0,043261	0,879753	0,327675	0,002235
20	0,706677	3,15E-06	0,010045	0,586289	0,626772	0,012272
21	0,794057	3,18E-07	0,002426	0,339299	0,869099	0,040773
22	0,838799	9,11E-08	0,001089	0,238161	0,95426	0,07003
23	0,942687	4,14E-09	0,00014	0,086324	0,97748	0,202725
24	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
25	0,924425	7,26E-09	0,000204	0,10522	0,992571	0,171494

t	nx5(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952267	3,07E-09	0,000114	0,077551	0,966428	0,220584
3	0,922946	7,6E-09	0,000211	0,106881	0,99344	0,169124
4	0,91715	9,07E-09	0,000237	0,113588	0,99633	0,160064
5	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
6	0,824412	1,37E-07	0,001416	0,26833	0,931071	0,059172
7	0,845551	7,52E-08	0,00096	0,224795	0,963619	0,075656
8	0,649165	1,29E-05	0,023057	0,757201	0,455445	0,005017
9	0,545857	0,000131	0,083337	0,974056	0,208522	0,000818
10	0,872486	3,44E-08	0,000576	0,176521	0,990582	0,101814
11	0,746335	1,14E-06	0,005397	0,468364	0,744411	0,02167
12	0,677122	6,56E-06	0,015555	0,6756	0,537444	0,007831
13	0,293897	0,012168	0,625033	0,588028	0,010132	3,2E-06
14	0,193999	0,047338	0,895433	0,310226	0,001969	2,29E-07
15	0,14388	0,08519	0,976219	0,204893	0,000788	5,55E-08
16	0,307876	0,009864	0,582658	0,630403	0,012492	4,53E-06
17	0,33447	0,006526	0,502982	0,709991	0,018356	8,69E-06
18	0,378111	0,003189	0,380289	0,830513	0,03322	2,43E-05
19	0,505626	0,0003	0,127881	0,999604	0,14311	0,000375
20	0,242755	0,025165	0,77512	0,437277	0,004518	8,55E-07
21	0,272758	0,016562	0,688619	0,524408	0,007314	1,87E-06
22	0,177634	0,057747	0,92743	0,272805	0,00147	1,45E-07
23	0,106035	0,127352	0,999545	0,143689	0,000378	1,82E-08
24	0,077054	0,169124	0,99344	0,106881	0,000211	7,6E-09
25	0,054893	0,20714	0,974887	0,084036	0,000133	3,84E-09

t	nx6(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10

3	0,014448	0,290552	0,912572	0,052497	5,53E-05	1,07E-09
4	0,036233	0,243374	0,950442	0,067983	8,91E-05	2,14E-09
5	0,084411	0,157686	0,996967	0,115449	0,000245	9,51E-09
6	0,086372	0,154735	0,997681	0,117819	0,000255	1,01E-08
7	0,135016	0,093903	0,98479	0,18916	0,000665	4,29E-08
8	0,085774	0,155631	0,997473	0,117093	0,000252	9,91E-09
9	0,094118	0,143473	0,999568	0,127549	0,000298	1,28E-08
10	0,193145	0,04784	0,897225	0,308201	0,001939	2,23E-07
11	0,189928	0,049769	0,903854	0,300649	0,001832	2,04E-07
12	0,248659	0,023218	0,758629	0,454001	0,004976	9,99E-07
13	0,144561	0,084549	0,975485	0,206137	0,000798	5,66E-08
14	0,14562	0,083558	0,974321	0,208083	0,000814	5,83E-08
15	0,154749	0,075399	0,963225	0,225377	0,000966	7,58E-08
16	0,247068	0,023729	0,763103	0,449472	0,004849	9,58E-07
17	0,336479	0,006321	0,497067	0,715884	0,018884	9,12E-06
18	0,41244	0,001756	0,29516	0,908615	0,05123	5,29E-05
19	0,513646	0,000255	0,117798	0,997675	0,154761	0,00044
20	0,490397	0,000406	0,148804	0,998848	0,122802	0,000277
21	0,576075	6,81E-05	0,058831	0,930212	0,26939	0,001429
22	0,627323	2,15E-05	0,030935	0,816572	0,394788	0,003496
23	0,76197	7,54E-07	0,00418	0,424072	0,788081	0,026824
24	0,913978	9,99E-09	0,000253	0,117394	0,997561	0,155258
25	0,948174	3,49E-09	0,000124	0,081207	0,971408	0,212828
t	nx15(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,547766	0,000125	0,081579	0,971883	0,212066	0,000848
3	0,651145	1,23E-05	0,022438	0,751593	0,461114	0,005181
4	0,74718	1,11E-06	0,005324	0,465927	0,746826	0,021925
5	0,990881	8,99E-10	4,91E-05	0,049191	0,901908	0,302876
6	0,955238	2,8E-09	0,000107	0,074981	0,962577	0,226331
7	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
8	0,923155	7,55E-09	0,00021	0,106645	0,993321	0,169458
9	0,832018	1,1E-07	0,001233	0,252095	0,943868	0,064726
10	0,791715	3,39E-07	0,002527	0,345168	0,863666	0,039581
11	0,850896	6,45E-08	0,000869	0,214574	0,97031	0,080365
12	0,947957	3,51E-09	0,000125	0,081405	0,971661	0,212422
13	0,957888	2,57E-09	0,000101	0,072747	0,958977	0,23154
14	0,838142	9,29E-08	0,001102	0,239488	0,953296	0,069502
15	0,797256	2,91E-07	0,002295	0,331372	0,876381	0,042451
16	0,734668	1,54E-06	0,006506	0,502398	0,710573	0,018407
17	0,748231	1,08E-06	0,005234	0,462906	0,749818	0,022245
18	0,560075	9,64E-05	0,070944	0,95589	0,235896	0,001066

19	0,576618	6,73E-05	0,058451	0,929248	0,270577	0,001443
20	0,025984	0,264923	0,933812	0,060287	7,13E-05	1,54E-09
21	0,114342	0,116952	0,997432	0,155804	0,000446	2,34E-08
22	0,059041	0,199612	0,979248	0,087987	0,000145	4,36E-09
23	0,126049	0,103419	0,991554	0,174123	0,00056	3,3E-08
24	0,092005	0,146482	0,999201	0,124837	0,000286	1,2E-08
25	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
t	nx23(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
3	0,052769	0,211068	0,972501	0,082069	0,000127	3,59E-09
4	0,248171	0,023374	0,760002	0,452612	0,004937	9,86E-07
5	0,402821	0,002082	0,317823	0,888655	0,04551	4,27E-05
6	0,475444	0,000544	0,171705	0,992491	0,105073	0,000204
7	0,523511	0,000208	0,106244	0,993114	0,170027	0,000533
8	0,611285	3,1E-05	0,038096	0,856582	0,352765	0,002661
9	0,642111	1,52E-05	0,025386	0,7769	0,435467	0,004471
10	0,72466	2E-06	0,007616	0,532111	0,680927	0,01596
11	0,730408	1,72E-06	0,006959	0,514996	0,698011	0,017328
12	0,748694	1,07E-06	0,005195	0,461576	0,751135	0,022388
13	0,760188	7,91E-07	0,004304	0,429032	0,78322	0,026188
14	0,769592	6,16E-07	0,003682	0,403128	0,808498	0,029699
15	0,789969	3,55E-07	0,002604	0,34958	0,859559	0,03871
16	0,742424	1,26E-06	0,005748	0,479688	0,733171	0,020525
17	0,745037	1,18E-06	0,005512	0,472113	0,740692	0,021284
18	0,870951	3,6E-08	0,000593	0,179056	0,989507	0,100155
19	0,870951	3,6E-08	0,000593	0,179056	0,989507	0,100155
20	0,878265	2,91E-08	0,000515	0,167201	0,994112	0,108257
21	0,937827	4,81E-09	0,000155	0,091068	0,982273	0,194054
22	0,960815	2,35E-09	9,49E-05	0,070342	0,954821	0,237383
23	0,981191	1,23E-09	6,09E-05	0,055337	0,920903	0,280695
24	0,985371	1,07E-09	5,55E-05	0,052612	0,912924	0,29014
25	0,985371	1,07E-09	5,55E-05	0,052612	0,912924	0,29014
t	nx30(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,929926	6,14E-09	0,000182	0,099216	0,988868	0,180517
3	0,952582	3,04E-09	0,000113	0,077276	0,96603	0,221188
4	0,89568	1,73E-08	0,000366	0,141277	0,999767	0,129583
5	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
6	0,876712	3,04E-08	0,000531	0,16967	0,993244	0,106495
7	0,895153	1,76E-08	0,00037	0,142015	0,999706	0,128894
8	0,728662	1,8E-06	0,007153	0,520182	0,692837	0,016902
9	0,648577	1,3E-05	0,023244	0,758858	0,453769	0,00497

10	0,574816	7,01E-05	0,059718	0,932424	0,266652	0,001397
11	0,54215	0,000141	0,086839	0,978037	0,201753	0,000762
12	0,382508	0,00296	0,368751	0,841512	0,035173	2,69E-05
13	0,065332	0,188559	0,985089	0,094259	0,000165	5,3E-09
14	0,082192	0,161076	0,996044	0,11281	0,000234	8,89E-09
15	0,075869	0,17102	0,992748	0,105548	0,000206	7,33E-09
16	0,142782	0,086233	0,977381	0,202896	0,000771	5,37E-08
17	0,19705	0,045583	0,888934	0,317513	0,002077	2,49E-07
18	0,265543	0,018353	0,709954	0,503019	0,006528	1,55E-06
19	0,306639	0,010051	0,586406	0,626656	0,012265	4,4E-06
20	0,147524	0,081801	0,972163	0,211613	0,000844	6,16E-08
21	0,142255	0,086738	0,977929	0,201943	0,000764	5,29E-08
22	0,09431	0,143201	0,999595	0,127798	0,000299	1,28E-08
23	0,002634	0,318273	0,888251	0,045404	4,25E-05	7,29E-10
24	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
25	0,360906	0,004254	0,42703	0,785183	0,026443	1,63E-05

t	nx34(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,324652	0,882497	0,043937	4,01E-05	6,69E-10
3	0,227355	0,030922	0,816491	0,394872	0,003498	5,67E-07
4	0,415839	0,001653	0,287386	0,915268	0,053389	5,7E-05
5	0,53245	0,000173	0,096553	0,986924	0,184766	0,000634
6	0,621191	2,47E-05	0,033524	0,832275	0,378448	0,003152
7	0,647712	1,33E-05	0,023521	0,761295	0,451303	0,0049
8	0,770802	5,96E-07	0,003608	0,399847	0,811679	0,030178
9	0,944869	3,87E-09	0,000133	0,08426	0,975149	0,206702
10	0,845332	7,56E-08	0,000964	0,22522	0,963332	0,075469
11	0,847804	7,05E-08	0,000921	0,220447	0,966519	0,077614
12	0,853212	6,03E-08	0,000832	0,210244	0,973007	0,082476
13	0,889752	2,07E-08	0,000411	0,149743	0,998688	0,121993
14	0,90869	1,17E-08	0,000282	0,123954	0,999056	0,147483
15	0,923872	7,39E-09	0,000207	0,105838	0,992902	0,170606
16	0,943619	4,02E-09	0,000137	0,085437	0,976498	0,204417
17	0,950672	3,23E-09	0,000118	0,07896	0,968414	0,21754
18	1	6,69E-10	4,01E-05	0,043937	0,882497	0,324652
19	0,997582	7,24E-10	4,23E-05	0,045282	0,887784	0,318794
20	0,447014	0,000935	0,221964	0,965515	0,076923	0,000112
21	0,379081	0,003137	0,37773	0,832961	0,033643	2,49E-05
22	0,387845	0,002701	0,354983	0,854504	0,037674	3,04E-05
23	0,423185	0,001448	0,271008	0,928898	0,058314	6,71E-05
24	0,32502	0,007573	0,531037	0,682	0,016042	6,91E-06
25	0,312337	0,009215	0,569164	0,643896	0,013342	5,06E-06

EK 11: Zaman Serilerinin Tüm Değerleri İçin Hesaplanan Üyelik Değerleri (Sigmoidal Fonksiyonu için)

	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
a1	-0,7	-0,3	0,1	0,5	0,9
a2	0,1	0,5	0,9	1,3	1,7

Gözlemlerin Üyelik Değerleri

t	nx1(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,051898617	0,508417	0,533557	0,47881	0,348861	0,184931
3	0,103890075	0,499319	0,529673	0,480108	0,354789	0,192088
4	0,155927955	0,490214	0,525783	0,481407	0,360767	0,199461
5	0,208105097	0,481091	0,521878	0,48271	0,366805	0,207066
6	0,260375081	0,471964	0,517964	0,484015	0,372896	0,214896
7	0,313573484	0,462694	0,513978	0,485344	0,379137	0,223084
8	0,367189676	0,453378	0,509959	0,486683	0,385467	0,231559
9	0,420620184	0,444126	0,505953	0,488018	0,391815	0,240226
10	0,473307957	0,43504	0,502002	0,489334	0,39811	0,248987
11	0,522978368	0,426515	0,498277	0,490576	0,404076	0,25744
12	0,566846161	0,419021	0,494987	0,491672	0,409368	0,265059
13	0,610342587	0,411628	0,491725	0,492759	0,414637	0,272755
14	0,653467645	0,404337	0,488492	0,493837	0,41988	0,280521
15	0,696221335	0,39715	0,485288	0,494906	0,425096	0,288352
16	0,738603658	0,390069	0,482112	0,495965	0,430283	0,296242
17	0,780800297	0,383065	0,478952	0,49702	0,435462	0,304221
18	0,66994708	0,401562	0,487257	0,494249	0,421888	0,283524
19	0,71316498	0,394314	0,484018	0,495329	0,427167	0,291491
20	0,761628447	0,386241	0,480388	0,496541	0,433107	0,300581
21	0,815569585	0,377329	0,47635	0,497889	0,439741	0,310885
22	0,862036951	0,369718	0,472874	0,499051	0,445472	0,319914
23	0,903955065	0,362907	0,46974	0,500099	0,450656	0,328177
24	0,952279268	0,355123	0,466131	0,501307	0,456644	0,337837
25	1	0,347511	0,46257	0,5025	0,46257	0,347511

t	nx2(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,022728446	0,513519	0,535734	0,478082	0,345555	0,181006
3	0,047781374	0,509137	0,533864	0,478707	0,348393	0,184373
4	0,079171178	0,503645	0,53152	0,479491	0,351965	0,188659
5	0,100316675	0,499945	0,52994	0,480019	0,35438	0,191589
6	0,13913703	0,493151	0,527038	0,480988	0,358833	0,197059
7	0,19414241	0,483531	0,522923	0,482361	0,365185	0,20501

8	0,230448669	0,477187	0,520205	0,483267	0,369404	0,210387
9	0,290658312	0,466684	0,515695	0,484771	0,376444	0,21953
10	0,296798802	0,465615	0,515235	0,484925	0,377165	0,220478
11	0,326213729	0,460495	0,513031	0,485659	0,380626	0,225062
12	0,277367462	0,469001	0,516691	0,484439	0,374885	0,217487
13	0,274673062	0,46947	0,516893	0,484372	0,374569	0,217075
14	0,288098505	0,46713	0,515887	0,484707	0,376143	0,219136
15	0,357270013	0,455099	0,510703	0,486435	0,384293	0,229974
16	0,427899189	0,442868	0,505407	0,4882	0,392682	0,241424
17	0,519292091	0,427146	0,498553	0,490483	0,403632	0,256806
18	0,601238087	0,413172	0,492408	0,492532	0,413533	0,271132
19	0,706676915	0,395399	0,484504	0,495167	0,426374	0,290287
20	0,794057421	0,380874	0,47796	0,497351	0,437092	0,306752
21	0,838799024	0,373517	0,474612	0,49847	0,442604	0,315381
22	0,94268707	0,356662	0,466847	0,501067	0,455454	0,335908
23	1	0,347511	0,46257	0,5025	0,46257	0,347511
24	0,924424742	0,359601	0,468211	0,500611	0,453191	0,332252
25	0,91736157	0,36074	0,468739	0,500434	0,452316	0,330843
t	nx5(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,922945789	0,359839	0,468322	0,500574	0,453007	0,331957
3	0,917149676	0,360774	0,468755	0,500429	0,452289	0,330801
4	1	0,347511	0,46257	0,5025	0,46257	0,347511
5	0,824411865	0,375876	0,475688	0,49811	0,44083	0,312592
6	0,845550631	0,372411	0,474107	0,498639	0,443437	0,316695
7	0,649164678	0,405062	0,488815	0,493729	0,419356	0,27974
8	0,545857484	0,422602	0,496561	0,491147	0,406833	0,261395
9	0,87248551	0,368015	0,472093	0,499312	0,446763	0,321963
10	0,746334811	0,388782	0,481533	0,496158	0,43123	0,297695
11	0,6771224	0,400355	0,486719	0,494428	0,422764	0,284838
12	0,293897034	0,46612	0,515453	0,484852	0,376824	0,22003
13	0,193999318	0,483556	0,522934	0,482357	0,365169	0,204989
14	0,143879986	0,492322	0,526684	0,481106	0,359379	0,197736
15	0,307875895	0,463686	0,514405	0,485201	0,378467	0,222197
16	0,334469826	0,45906	0,512412	0,485866	0,381599	0,22636
17	0,378111149	0,451484	0,509141	0,486956	0,386762	0,233313
18	0,505625639	0,429489	0,499578	0,490142	0,401988	0,254465
19	0,242754859	0,475039	0,519284	0,483575	0,370838	0,212232
20	0,272758268	0,469804	0,517037	0,484324	0,374345	0,216782
21	0,177633822	0,486417	0,524159	0,481949	0,363274	0,202599
22	0,106034777	0,498944	0,529513	0,480161	0,355034	0,192388
23	0,077054211	0,504015	0,531678	0,479438	0,351723	0,188368

24	0,054892601	0,507893	0,533334	0,478885	0,349201	0,185337
25	0	0,517493	0,53743	0,477515	0,34299	0,177994
t	nx6(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,01444848	0,514967	0,536352	0,477876	0,344619	0,179904
3	0,036232655	0,511157	0,534727	0,478419	0,347084	0,182815
4	0,084411143	0,502728	0,531129	0,479622	0,352562	0,189382
5	0,086371719	0,502385	0,530982	0,479671	0,352786	0,189653
6	0,135016287	0,493872	0,527346	0,480885	0,358359	0,196473
7	0,085773921	0,50249	0,531027	0,479656	0,352718	0,18957
8	0,094117766	0,501029	0,530404	0,479864	0,353671	0,190727
9	0,193144571	0,483705	0,522998	0,482336	0,36507	0,204864
10	0,189927606	0,484268	0,523239	0,482256	0,364697	0,204392
11	0,248658753	0,474008	0,518842	0,483722	0,371527	0,213122
12	0,144560796	0,492202	0,526633	0,481123	0,359457	0,197833
13	0,145619608	0,492017	0,526554	0,481149	0,359579	0,197984
14	0,154748697	0,49042	0,525871	0,481377	0,360631	0,199292
15	0,247068002	0,474286	0,518961	0,483682	0,371342	0,212882
16	0,336479373	0,45871	0,512262	0,485916	0,381837	0,226677
17	0,412440283	0,44554	0,506567	0,487813	0,390841	0,238885
18	0,513645506	0,428114	0,498977	0,490342	0,402953	0,255837
19	0,490397232	0,432103	0,50072	0,489761	0,400159	0,251874
20	0,576074897	0,417449	0,494295	0,491903	0,410485	0,26668
21	0,627323434	0,408752	0,490452	0,493184	0,416699	0,275797
22	0,761969897	0,386185	0,480362	0,496549	0,433149	0,300645
23	0,913977841	0,361287	0,468992	0,500349	0,451896	0,330169
24	0,948173929	0,355781	0,466438	0,501204	0,456135	0,337011
25	1	0,347511	0,46257	0,5025	0,46257	0,347511
t	nx15(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,651144885	0,404728	0,488666	0,493779	0,419597	0,280099
3	0,747180388	0,388641	0,48147	0,49618	0,431334	0,297854
4	0,990881168	0,348959	0,46325	0,502272	0,461437	0,345652
5	0,955238448	0,354649	0,46591	0,501381	0,457011	0,338433
6	1	0,347511	0,46257	0,5025	0,46257	0,347511
7	0,923154924	0,359805	0,468306	0,500579	0,453033	0,331998
8	0,832018184	0,374628	0,475119	0,4983	0,441768	0,314065
9	0,791715421	0,381261	0,478135	0,497293	0,436804	0,306304
10	0,850896276	0,371537	0,473707	0,498772	0,444097	0,317737
11	0,947956756	0,355816	0,466454	0,501199	0,456108	0,336967
12	0,95788839	0,354224	0,465712	0,501447	0,45734	0,338967
13	0,838142329	0,373624	0,474661	0,498454	0,442523	0,315253
14	0,797255921	0,380346	0,477721	0,497431	0,437486	0,307364

15	0,734667993	0,390725	0,482407	0,495867	0,4298	0,295504
16	0,748230656	0,388467	0,481391	0,496206	0,431463	0,298052
17	0,560074649	0,420176	0,495495	0,491503	0,40855	0,263873
18	0,576618155	0,417357	0,494254	0,491916	0,41055	0,266776
19	0,025983734	0,51295	0,535491	0,478163	0,345923	0,181441
20	0,114341686	0,49749	0,528892	0,480369	0,355986	0,193552
21	0,059040873	0,507167	0,533024	0,478988	0,349672	0,185902
22	0,126048675	0,495442	0,528017	0,480661	0,357329	0,195202
23	0,092005087	0,501399	0,530561	0,479811	0,35343	0,190434
24	0	0,517493	0,53743	0,477515	0,34299	0,177994
25	0,013751242	0,515089	0,536404	0,477858	0,344541	0,179812
t	nx23(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,05276907	0,508265	0,533492	0,478832	0,34896	0,185049
3	0,248171369	0,474093	0,518878	0,48371	0,37147	0,213049
4	0,402821317	0,447204	0,507288	0,487573	0,389696	0,237314
5	0,475444096	0,434673	0,501842	0,489388	0,398366	0,249347
6	0,523510972	0,426424	0,498237	0,490589	0,40414	0,257531
7	0,611285266	0,411468	0,491654	0,492783	0,414751	0,272923
8	0,642110763	0,406253	0,489343	0,493553	0,418497	0,278463
9	0,724660397	0,392394	0,483157	0,495617	0,428574	0,293633
10	0,730407524	0,391435	0,482726	0,49576	0,429278	0,294707
11	0,748693835	0,38839	0,481357	0,496217	0,43152	0,298139
12	0,760188088	0,38648	0,480496	0,496505	0,43293	0,300308
13	0,769592476	0,38492	0,479792	0,49674	0,434085	0,30209
14	0,789968652	0,381549	0,478266	0,497249	0,436589	0,30597
15	0,742424242	0,389433	0,481826	0,496061	0,430751	0,29696
16	0,745036573	0,388998	0,481631	0,496126	0,431071	0,297451
17	0,870950888	0,368265	0,472207	0,499274	0,446574	0,321662
18	0,870950888	0,368265	0,472207	0,499274	0,446574	0,321662
19	0,878265413	0,367075	0,47166	0,499457	0,447478	0,3231
20	0,937826541	0,357443	0,46721	0,500946	0,454852	0,334933
21	0,960815047	0,353756	0,465494	0,50152	0,457703	0,339558
22	0,981191223	0,350502	0,463973	0,50203	0,460233	0,343682
23	0,985370951	0,349836	0,463661	0,502134	0,460752	0,344531
24	0,985370951	0,349836	0,463661	0,502134	0,460752	0,344531
25	1	0,347511	0,46257	0,5025	0,46257	0,347511
t	nx30(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952581665	0,355075	0,466108	0,501315	0,456682	0,337898
3	0,895679663	0,364247	0,470359	0,499892	0,449631	0,326537
4	1	0,347511	0,46257	0,5025	0,46257	0,347511
5	0,876712329	0,367328	0,471777	0,499418	0,447286	0,322794

6	0,895152792	0,364333	0,470398	0,499879	0,449566	0,326433
7	0,728661749	0,391726	0,482857	0,495717	0,429064	0,29438
8	0,64857745	0,405161	0,488859	0,493715	0,419285	0,279633
9	0,574815595	0,417664	0,494389	0,491871	0,410332	0,266458
10	0,542149631	0,423236	0,496839	0,491055	0,406386	0,260752
11	0,382507903	0,450722	0,508811	0,487066	0,387283	0,234021
12	0,065331928	0,506067	0,532554	0,479145	0,350388	0,18676
13	0,082191781	0,503116	0,531295	0,479566	0,352309	0,189076
14	0,075869336	0,504223	0,531767	0,479408	0,351588	0,188205
15	0,142781876	0,492514	0,526766	0,481079	0,359253	0,197579
16	0,197049526	0,483023	0,522706	0,482433	0,365522	0,205437
17	0,265542677	0,471062	0,517577	0,484144	0,3735	0,215682
18	0,306638567	0,463901	0,514498	0,48517	0,378321	0,222004
19	0,147523709	0,491684	0,526411	0,481197	0,359799	0,198256
20	0,142255005	0,492606	0,526805	0,481065	0,359192	0,197504
21	0,0943098	0,500996	0,530389	0,479869	0,353693	0,190754
22	0,002634352	0,517032	0,537233	0,477581	0,343286	0,178341
23	0	0,517493	0,53743	0,477515	0,34299	0,177994
24	0,360906217	0,454468	0,510431	0,486526	0,384723	0,230554
25	0,273972603	0,469592	0,516946	0,484354	0,374487	0,216968
t	nx34(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,227354595	0,477728	0,520437	0,48319	0,369043	0,209924
3	0,415838888	0,444952	0,506312	0,487898	0,391245	0,239441
4	0,532449793	0,424894	0,497566	0,490812	0,405217	0,259072
5	0,621191425	0,40979	0,490912	0,49303	0,415954	0,274696
6	0,647711858	0,405308	0,488923	0,493693	0,419179	0,279477
7	0,770802302	0,38472	0,479701	0,49677	0,434234	0,302319
8	0,944868552	0,356312	0,466684	0,501122	0,455725	0,336346
9	0,845331995	0,372447	0,474123	0,498633	0,44341	0,316652
10	0,847804403	0,372043	0,473938	0,498695	0,443715	0,317134
11	0,85321205	0,371159	0,473534	0,49883	0,444383	0,318189
12	0,889752151	0,365209	0,470802	0,499744	0,448898	0,325365
13	0,908690465	0,362141	0,469387	0,500217	0,451242	0,329118
14	0,923872355	0,35969	0,468252	0,500597	0,453122	0,332142
15	0,943618919	0,356513	0,466778	0,50109	0,45557	0,336095
16	0,950672184	0,355381	0,466251	0,501267	0,456445	0,337513
17	1	0,347511	0,46257	0,5025	0,46257	0,347511
18	0,997581552	0,347894	0,462751	0,50244	0,46227	0,347017
19	0,447014489	0,439569	0,503974	0,488677	0,394964	0,244588
20	0,379080774	0,451316	0,509068	0,48698	0,386877	0,233469
21	0,387845006	0,449797	0,508411	0,487199	0,387917	0,234883

22	0,423185088	0,443683	0,505761	0,488082	0,392121	0,240647
23	0,325019741	0,460703	0,513121	0,485629	0,380485	0,224875
24	0,312336776	0,462909	0,514071	0,485313	0,378991	0,222891
25	0,307631976	0,463728	0,514424	0,485195	0,378438	0,222159
t	nx1(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,517493	0,53743	0,477515	0,34299	0,177994
3	0,051898617	0,508417	0,533557	0,47881	0,348861	0,184931
4	0,103890075	0,499319	0,529673	0,480108	0,354789	0,192088
5	0,155927955	0,490214	0,525783	0,481407	0,360767	0,199461
6	0,208105097	0,481091	0,521878	0,48271	0,366805	0,207066
7	0,260375081	0,471964	0,517964	0,484015	0,372896	0,214896
8	0,313573484	0,462694	0,513978	0,485344	0,379137	0,223084
9	0,367189676	0,453378	0,509959	0,486683	0,385467	0,231559
10	0,420620184	0,444126	0,505953	0,488018	0,391815	0,240226
11	0,473307957	0,43504	0,502002	0,489334	0,39811	0,248987
12	0,522978368	0,426515	0,498277	0,490576	0,404076	0,25744
13	0,566846161	0,419021	0,494987	0,491672	0,409368	0,265059
14	0,610342587	0,411628	0,491725	0,492759	0,414637	0,272755
15	0,653467645	0,404337	0,488492	0,493837	0,41988	0,280521
16	0,696221335	0,39715	0,485288	0,494906	0,425096	0,288352
17	0,738603658	0,390069	0,482112	0,495965	0,430283	0,296242
18	0,780800297	0,383065	0,478952	0,49702	0,435462	0,304221
19	0,66994708	0,401562	0,487257	0,494249	0,421888	0,283524
20	0,71316498	0,394314	0,484018	0,495329	0,427167	0,291491
21	0,761628447	0,386241	0,480388	0,496541	0,433107	0,300581
22	0,815569585	0,377329	0,47635	0,497889	0,439741	0,310885
23	0,862036951	0,369718	0,472874	0,499051	0,445472	0,319914
24	0,903955065	0,362907	0,46974	0,500099	0,450656	0,328177
25	0,952279268	0,355123	0,466131	0,501307	0,456644	0,337837
t	nx2(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,517493	0,53743	0,477515	0,34299	0,177994
3	0,022728446	0,513519	0,535734	0,478082	0,345555	0,181006
4	0,047781374	0,509137	0,533864	0,478707	0,348393	0,184373
5	0,079171178	0,503645	0,53152	0,479491	0,351965	0,188659
6	0,100316675	0,499945	0,52994	0,480019	0,35438	0,191589
7	0,13913703	0,493151	0,527038	0,480988	0,358833	0,197059
8	0,19414241	0,483531	0,522923	0,482361	0,365185	0,20501
9	0,230448669	0,477187	0,520205	0,483267	0,369404	0,210387
10	0,290658312	0,466684	0,515695	0,484771	0,376444	0,21953
11	0,296798802	0,465615	0,515235	0,484925	0,377165	0,220478
12	0,326213729	0,460495	0,513031	0,485659	0,380626	0,225062

13	0,277367462	0,469001	0,516691	0,484439	0,374885	0,217487
14	0,274673062	0,46947	0,516893	0,484372	0,374569	0,217075
15	0,288098505	0,46713	0,515887	0,484707	0,376143	0,219136
16	0,357270013	0,455099	0,510703	0,486435	0,384293	0,229974
17	0,427899189	0,442868	0,505407	0,4882	0,392682	0,241424
18	0,519292091	0,427146	0,498553	0,490483	0,403632	0,256806
19	0,601238087	0,413172	0,492408	0,492532	0,413533	0,271132
20	0,706676915	0,395399	0,484504	0,495167	0,426374	0,290287
21	0,794057421	0,380874	0,47796	0,497351	0,437092	0,306752
22	0,838799024	0,373517	0,474612	0,49847	0,442604	0,315381
23	0,94268707	0,356662	0,466847	0,501067	0,455454	0,335908
24	1	0,347511	0,46257	0,5025	0,46257	0,347511
25	0,924424742	0,359601	0,468211	0,500611	0,453191	0,332252
t	nx5(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952267303	0,355125	0,466132	0,501307	0,456643	0,337834
3	0,922945789	0,359839	0,468322	0,500574	0,453007	0,331957
4	0,917149676	0,360774	0,468755	0,500429	0,452289	0,330801
5	1	0,347511	0,46257	0,5025	0,46257	0,347511
6	0,824411865	0,375876	0,475688	0,49811	0,44083	0,312592
7	0,845550631	0,372411	0,474107	0,498639	0,443437	0,316695
8	0,649164678	0,405062	0,488815	0,493729	0,419356	0,27974
9	0,545857484	0,422602	0,496561	0,491147	0,406833	0,261395
10	0,87248551	0,368015	0,472093	0,499312	0,446763	0,321963
11	0,746334811	0,388782	0,481533	0,496158	0,43123	0,297695
12	0,6771224	0,400355	0,486719	0,494428	0,422764	0,284838
13	0,293897034	0,46612	0,515453	0,484852	0,376824	0,22003
14	0,193999318	0,483556	0,522934	0,482357	0,365169	0,204989
15	0,143879986	0,492322	0,526684	0,481106	0,359379	0,197736
16	0,307875895	0,463686	0,514405	0,485201	0,378467	0,222197
17	0,334469826	0,45906	0,512412	0,485866	0,381599	0,22636
18	0,378111149	0,451484	0,509141	0,486956	0,386762	0,233313
19	0,505625639	0,429489	0,499578	0,490142	0,401988	0,254465
20	0,242754859	0,475039	0,519284	0,483575	0,370838	0,212232
21	0,272758268	0,469804	0,517037	0,484324	0,374345	0,216782
22	0,177633822	0,486417	0,524159	0,481949	0,363274	0,202599
23	0,106034777	0,498944	0,529513	0,480161	0,355034	0,192388
24	0,077054211	0,504015	0,531678	0,479438	0,351723	0,188368
25	0,054892601	0,507893	0,533334	0,478885	0,349201	0,185337
t	nx6(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,517493	0,53743	0,477515	0,34299	0,177994
3	0,01444848	0,514967	0,536352	0,477876	0,344619	0,179904

4	0,036232655	0,511157	0,534727	0,478419	0,347084	0,182815
5	0,084411143	0,502728	0,531129	0,479622	0,352562	0,189382
6	0,086371719	0,502385	0,530982	0,479671	0,352786	0,189653
7	0,135016287	0,493872	0,527346	0,480885	0,358359	0,196473
8	0,085773921	0,50249	0,531027	0,479656	0,352718	0,18957
9	0,094117766	0,501029	0,530404	0,479864	0,353671	0,190727
10	0,193144571	0,483705	0,522998	0,482336	0,36507	0,204864
11	0,189927606	0,484268	0,523239	0,482256	0,364697	0,204392
12	0,248658753	0,474008	0,518842	0,483722	0,371527	0,213122
13	0,144560796	0,492202	0,526633	0,481123	0,359457	0,197833
14	0,145619608	0,492017	0,526554	0,481149	0,359579	0,197984
15	0,154748697	0,49042	0,525871	0,481377	0,360631	0,199292
16	0,247068002	0,474286	0,518961	0,483682	0,371342	0,212882
17	0,336479373	0,45871	0,512262	0,485916	0,381837	0,226677
18	0,412440283	0,44554	0,506567	0,487813	0,390841	0,238885
19	0,513645506	0,428114	0,498977	0,490342	0,402953	0,255837
20	0,490397232	0,432103	0,50072	0,489761	0,400159	0,251874
21	0,576074897	0,417449	0,494295	0,491903	0,410485	0,26668
22	0,627323434	0,408752	0,490452	0,493184	0,416699	0,275797
23	0,761969897	0,386185	0,480362	0,496549	0,433149	0,300645
24	0,913977841	0,361287	0,468992	0,500349	0,451896	0,330169
25	0,948173929	0,355781	0,466438	0,501204	0,456135	0,337011
t	nx15(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,547766152	0,422276	0,496418	0,491195	0,407064	0,261727
3	0,651144885	0,404728	0,488666	0,493779	0,419597	0,280099
4	0,747180388	0,388641	0,48147	0,49618	0,431334	0,297854
5	0,990881168	0,348959	0,46325	0,502272	0,461437	0,345652
6	0,955238448	0,354649	0,46591	0,501381	0,457011	0,338433
7	1	0,347511	0,46257	0,5025	0,46257	0,347511
8	0,923154924	0,359805	0,468306	0,500579	0,453033	0,331998
9	0,832018184	0,374628	0,475119	0,4983	0,441768	0,314065
10	0,791715421	0,381261	0,478135	0,497293	0,436804	0,306304
11	0,850896276	0,371537	0,473707	0,498772	0,444097	0,317737
12	0,947956756	0,355816	0,466454	0,501199	0,456108	0,336967
13	0,95788839	0,354224	0,465712	0,501447	0,45734	0,338967
14	0,838142329	0,373624	0,474661	0,498454	0,442523	0,315253
15	0,797255921	0,380346	0,477721	0,497431	0,437486	0,307364
16	0,734667993	0,390725	0,482407	0,495867	0,4298	0,295504
17	0,748230656	0,388467	0,481391	0,496206	0,431463	0,298052
18	0,560074649	0,420176	0,495495	0,491503	0,40855	0,263873
19	0,576618155	0,417357	0,494254	0,491916	0,41055	0,266776

20	0,025983734	0,51295	0,535491	0,478163	0,345923	0,181441
21	0,114341686	0,49749	0,528892	0,480369	0,355986	0,193552
22	0,059040873	0,507167	0,533024	0,478988	0,349672	0,185902
23	0,126048675	0,495442	0,528017	0,480661	0,357329	0,195202
24	0,092005087	0,501399	0,530561	0,479811	0,35343	0,190434
25	0	0,517493	0,53743	0,477515	0,34299	0,177994
t	nx23(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,517493	0,53743	0,477515	0,34299	0,177994
3	0,05276907	0,508265	0,533492	0,478832	0,34896	0,185049
4	0,248171369	0,474093	0,518878	0,48371	0,37147	0,213049
5	0,402821317	0,447204	0,507288	0,487573	0,389696	0,237314
6	0,475444096	0,434673	0,501842	0,489388	0,398366	0,249347
7	0,523510972	0,426424	0,498237	0,490589	0,40414	0,257531
8	0,611285266	0,411468	0,491654	0,492783	0,414751	0,272923
9	0,642110763	0,406253	0,489343	0,493553	0,418497	0,278463
10	0,724660397	0,392394	0,483157	0,495617	0,428574	0,293633
11	0,730407524	0,391435	0,482726	0,49576	0,429278	0,294707
12	0,748693835	0,38839	0,481357	0,496217	0,43152	0,298139
13	0,760188088	0,38648	0,480496	0,496505	0,43293	0,300308
14	0,769592476	0,38492	0,479792	0,49674	0,434085	0,30209
15	0,789968652	0,381549	0,478266	0,497249	0,436589	0,30597
16	0,742424242	0,389433	0,481826	0,496061	0,430751	0,29696
17	0,745036573	0,388998	0,481631	0,496126	0,431071	0,297451
18	0,870950888	0,368265	0,472207	0,499274	0,446574	0,321662
19	0,870950888	0,368265	0,472207	0,499274	0,446574	0,321662
20	0,878265413	0,367075	0,47166	0,499457	0,447478	0,3231
21	0,937826541	0,357443	0,46721	0,500946	0,454852	0,334933
22	0,960815047	0,353756	0,465494	0,50152	0,457703	0,339558
23	0,981191223	0,350502	0,463973	0,50203	0,460233	0,343682
24	0,985370951	0,349836	0,463661	0,502134	0,460752	0,344531
25	0,985370951	0,349836	0,463661	0,502134	0,460752	0,344531
t	nx30(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,929926238	0,358714	0,4678	0,500748	0,453872	0,333351
3	0,952581665	0,355075	0,466108	0,501315	0,456682	0,337898
4	0,895679663	0,364247	0,470359	0,499892	0,449631	0,326537
5	1	0,347511	0,46257	0,5025	0,46257	0,347511
6	0,876712329	0,367328	0,471777	0,499418	0,447286	0,322794
7	0,895152792	0,364333	0,470398	0,499879	0,449566	0,326433
8	0,728661749	0,391726	0,482857	0,495717	0,429064	0,29438
9	0,64857745	0,405161	0,488859	0,493715	0,419285	0,279633
10	0,574815595	0,417664	0,494389	0,491871	0,410332	0,266458

11	0,542149631	0,423236	0,496839	0,491055	0,406386	0,260752
12	0,382507903	0,450722	0,508811	0,487066	0,387283	0,234021
13	0,065331928	0,506067	0,532554	0,479145	0,350388	0,18676
14	0,082191781	0,503116	0,531295	0,479566	0,352309	0,189076
15	0,075869336	0,504223	0,531767	0,479408	0,351588	0,188205
16	0,142781876	0,492514	0,526766	0,481079	0,359253	0,197579
17	0,197049526	0,483023	0,522706	0,482433	0,365522	0,205437
18	0,265542677	0,471062	0,517577	0,484144	0,3735	0,215682
19	0,306638567	0,463901	0,514498	0,48517	0,378321	0,222004
20	0,147523709	0,491684	0,526411	0,481197	0,359799	0,198256
21	0,142255005	0,492606	0,526805	0,481065	0,359192	0,197504
22	0,0943098	0,500996	0,530389	0,479869	0,353693	0,190754
23	0,002634352	0,517032	0,537233	0,477581	0,343286	0,178341
24	0	0,517493	0,53743	0,477515	0,34299	0,177994
25	0,360906217	0,454468	0,510431	0,486526	0,384723	0,230554
t	nx34(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,517493	0,53743	0,477515	0,34299	0,177994
3	0,227354595	0,477728	0,520437	0,48319	0,369043	0,209924
4	0,415838888	0,444952	0,506312	0,487898	0,391245	0,239441
5	0,532449793	0,424894	0,497566	0,490812	0,405217	0,259072
6	0,621191425	0,40979	0,490912	0,49303	0,415954	0,274696
7	0,647711858	0,405308	0,488923	0,493693	0,419179	0,279477
8	0,770802302	0,38472	0,479701	0,49677	0,434234	0,302319
9	0,944868552	0,356312	0,466684	0,501122	0,455725	0,336346
10	0,845331995	0,372447	0,474123	0,498633	0,44341	0,316652
11	0,847804403	0,372043	0,473938	0,498695	0,443715	0,317134
12	0,85321205	0,371159	0,473534	0,49883	0,444383	0,318189
13	0,889752151	0,365209	0,470802	0,499744	0,448898	0,325365
14	0,908690465	0,362141	0,469387	0,500217	0,451242	0,329118
15	0,923872355	0,35969	0,468252	0,500597	0,453122	0,332142
16	0,943618919	0,356513	0,466778	0,50109	0,45557	0,336095
17	0,950672184	0,355381	0,466251	0,501267	0,456445	0,337513
18	1	0,347511	0,46257	0,5025	0,46257	0,347511
19	0,997581552	0,347894	0,462751	0,50244	0,46227	0,347017
20	0,447014489	0,439569	0,503974	0,488677	0,394964	0,244588
21	0,379080774	0,451316	0,509068	0,48698	0,386877	0,233469
22	0,387845006	0,449797	0,508411	0,487199	0,387917	0,234883
23	0,423185088	0,443683	0,505761	0,488082	0,392121	0,240647
24	0,325019741	0,460703	0,513121	0,485629	0,380485	0,224875
25	0,312336776	0,462909	0,514071	0,485313	0,378991	0,222891

EK 12: Zaman Serilerinin Tüm Değerleri İçin Hesaplanan Üyelik Değerleri (Çan Şekilli Üyelik Fonksiyonu için)

a1	-0,7	-0,3	0,1	0,5	0,9
a2	-0,5	-0,1	0,3	0,7	1,1
a3	-0,3	0,1	0,5	0,9	1,3

Gözlemlerin Üyelik Değerleri

t	nx1(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,051898617	0,41487	0,454366	0,389372	0,408571	0,411036
3	0,103890075	0,431688	0,393044	0,398203	0,419314	0,422412
4	0,155927955	0,446611	0,458106	0,408371	0,430878	0,434393
5	0,208105097	0,460036	0,474505	0,420343	0,443399	0,447049
6	0,260375081	0,472219	0,484348	0,43483	0,457008	0,460422
7	0,313573484	0,483533	0,491506	0,45342	0,472127	0,474805
8	0,367189676	0,494	0,497104	0,478731	0,488879	0,490154
9	0,420620184	0,503629	0,501662	0,517313	0,50737	0,506374
10	0,473307957	0,512447	0,505465	0,597784	0,527717	0,523348
11	0,522978368	0,52022	0,508588	0,608541	0,549243	0,540317
12	0,566846161	0,526697	0,511054	0,530172	0,570576	0,556148
13	0,610342587	0,532795	0,513279	0,492619	0,594388	0,572686
14	0,653467645	0,538551	0,515306	0,46792	0,621279	0,589972
15	0,696221335	0,543997	0,517164	0,449616	0,652104	0,608046
16	0,738603658	0,54916	0,518879	0,435145	0,688158	0,626952
17	0,780800297	0,554085	0,520476	0,423178	0,731779	0,646826
18	0,66994708	0,54068	0,516039	0,46031	0,632605	0,596824
19	0,71316498	0,546088	0,517864	0,443475	0,665759	0,615482
20	0,761628447	0,551873	0,519763	0,428365	0,710799	0,637662
21	0,815569585	0,557993	0,521719	0,414653	0,776446	0,664043
22	0,862036951	0,563019	0,523288	0,404687	0,858708	0,688322
23	0,903955065	0,567374	0,524624	0,396794	0,967319	0,711556
24	0,952279268	0,572197	0,52608	0,38871	0,82929	0,740024
25	1	0,576768	0,527438	0,381584	0,755212	0,770029

t	nx2(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,022728446	0,404407	0,46614	0,384883	0,402864	0,404899
3	0,047781374	0,413442	0,456402	0,388719	0,407752	0,41016
4	0,079171178	0,423958	0,433706	0,39386	0,414111	0,416932
5	0,100316675	0,430598	0,335065	0,397558	0,418551	0,421612
6	0,13913703	0,441979	0,449257	0,404922	0,427051	0,43046
7	0,19414241	0,456578	0,471058	0,416931	0,43995	0,443596

8	0,230448669	0,465386	0,479192	0,426174	0,449077	0,452677
9	0,290658312	0,478782	0,488669	0,444816	0,465445	0,468511
10	0,296798802	0,480073	0,489462	0,447023	0,46721	0,470182
11	0,326213729	0,48608	0,492943	0,458645	0,47593	0,478344
12	0,277367462	0,475943	0,486864	0,44026	0,461689	0,464929
13	0,274673062	0,47536	0,486482	0,439371	0,460938	0,464209
14	0,288098505	0,478241	0,488332	0,443916	0,464715	0,467817
15	0,357270013	0,492127	0,496159	0,473341	0,485653	0,487247
16	0,427899189	0,504885	0,502223	0,524513	0,510046	0,508659
17	0,519292091	0,51966	0,508369	0,620964	0,547557	0,539024
18	0,601238087	0,531544	0,51283	0,499077	0,589155	0,569152
19	0,706676915	0,545292	0,517598	0,445765	0,660421	0,612616
20	0,794057421	0,55559	0,520957	0,419803	0,747665	0,653298
21	0,838799024	0,560533	0,522516	0,409491	0,813105	0,675993
22	0,94268707	0,571256	0,525797	0,390239	0,84845	0,734224
23	1	0,576768	0,527438	0,381584	0,755212	0,770029
24	0,924424742	0,569442	0,525251	0,39325	0,89219	0,723388
25	0,91736157	0,568732	0,525037	0,394452	0,913112	0,719268
t	nx5(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,922945789	0,569293	0,525206	0,3935	0,896324	0,722522
3	0,917149676	0,568711	0,52503	0,394489	0,913792	0,719145
4	1	0,576768	0,527438	0,381584	0,755212	0,770029
5	0,824411865	0,558966	0,522025	0,412642	0,7896	0,668548
6	0,845550631	0,561261	0,522743	0,40806	0,825222	0,679536
7	0,649164678	0,537989	0,515111	0,470045	0,618425	0,588205
8	0,545857484	0,523641	0,509904	0,558207	0,560068	0,548471
9	0,87248551	0,56412	0,523628	0,402632	0,883904	0,693992
10	0,746334811	0,550078	0,519179	0,432795	0,695484	0,630513
11	0,6771224	0,541595	0,516351	0,457229	0,637745	0,599852
12	0,293897034	0,479465	0,48909	0,445971	0,466374	0,469391
13	0,193999318	0,456542	0,47102	0,416897	0,439915	0,443561
14	0,143879986	0,443304	0,452089	0,405879	0,428123	0,431564
15	0,307875895	0,482369	0,49083	0,451183	0,470441	0,473226
16	0,334469826	0,487716	0,493839	0,462273	0,478461	0,480682
17	0,378111149	0,496029	0,498106	0,485159	0,492502	0,493392
18	0,505625639	0,51756	0,507541	0,70336	0,541434	0,534277
19	0,242754859	0,46824	0,481442	0,429606	0,452292	0,455833
20	0,272758268	0,474944	0,486206	0,438746	0,460406	0,463699
21	0,177633822	0,452365	0,466257	0,413102	0,435967	0,439577
22	0,106034777	0,432337	0,403567	0,398594	0,419774	0,422894
23	0,077054211	0,423274	0,436085	0,3935	0,413674	0,416469

24	0,054892601	0,415899	0,452773	0,38985	0,40917	0,411676
25	0	0,395644	0,472562	0,381584	0,398564	0,400232
t	nx6(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,01444848	0,401281	0,468674	0,383662	0,401283	0,403187
3	0,036232655	0,409354	0,461364	0,386923	0,405479	0,407719
4	0,084411143	0,425635	0,426603	0,394757	0,4152	0,418083
5	0,086371719	0,426257	0,423319	0,395096	0,415609	0,418515
6	0,135016287	0,440817	0,446506	0,404101	0,426127	0,429504
7	0,085773921	0,426067	0,424367	0,394993	0,415484	0,418383
8	0,094117766	0,428686	0,402951	0,396453	0,417236	0,42023
9	0,193144571	0,456327	0,470793	0,416693	0,439707	0,443351
10	0,189927606	0,455515	0,469917	0,415933	0,438924	0,442564
11	0,248658753	0,469587	0,482454	0,431314	0,453857	0,457361
12	0,144560796	0,443493	0,452471	0,406017	0,428277	0,431723
13	0,145619608	0,443787	0,453053	0,406233	0,428518	0,43197
14	0,154748697	0,446291	0,457577	0,408123	0,430606	0,434115
15	0,247068002	0,469226	0,482185	0,43085	0,453434	0,456949
16	0,336479373	0,488111	0,494052	0,463184	0,479083	0,481254
17	0,412440283	0,502202	0,501016	0,509962	0,504409	0,503828
18	0,513645506	0,518797	0,50803	0,645091	0,545002	0,537053
19	0,490397232	0,515177	0,506584	0,668838	0,534842	0,529076
20	0,576074897	0,528017	0,511543	0,520497	0,575388	0,559585
21	0,627323434	0,535095	0,514097	0,481891	0,604542	0,579384
22	0,761969897	0,551912	0,519776	0,428269	0,711154	0,637823
23	0,913977841	0,568391	0,524933	0,395036	0,924421	0,717309
24	0,948173929	0,571795	0,525959	0,38936	0,837243	0,737533
25	1	0,576768	0,527438	0,381584	0,755212	0,770029
t	nx15(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,651144885	0,538248	0,515201	0,469059	0,619733	0,589017
3	0,747180388	0,550178	0,519212	0,432543	0,696301	0,630905
4	0,990881168	0,575909	0,527184	0,382888	0,767373	0,764144
5	0,955238448	0,572486	0,526166	0,388245	0,823765	0,741829
6	1	0,576768	0,527438	0,381584	0,755212	0,770029
7	0,923154924	0,569314	0,525213	0,393465	0,895732	0,722644
8	0,832018184	0,559797	0,522286	0,410958	0,801669	0,672466
9	0,791715421	0,555326	0,520873	0,420388	0,744766	0,652147
10	0,850896276	0,561834	0,522921	0,406948	0,835411	0,682364
11	0,947956756	0,571774	0,525953	0,389395	0,837673	0,737401
12	0,95788839	0,572744	0,526243	0,387832	0,818952	0,743451
13	0,838142329	0,560462	0,522494	0,409631	0,811967	0,67565
14	0,797255921	0,555951	0,521072	0,419013	0,751692	0,654877

15	0,734667993	0,54869	0,518724	0,436372	0,684527	0,625153
16	0,748230656	0,550302	0,519252	0,432231	0,697321	0,631392
17	0,560074649	0,52572	0,510689	0,538144	0,567122	0,55365
18	0,576618155	0,528094	0,511571	0,519965	0,575675	0,559788
19	0,025983734	0,405617	0,46507	0,385369	0,40349	0,405575
20	0,114341686	0,434824	0,424565	0,400127	0,421568	0,424769
21	0,059040873	0,417311	0,450384	0,390518	0,410003	0,412566
22	0,126048675	0,438251	0,439207	0,402349	0,424133	0,427439
23	0,092005087	0,428028	0,410355	0,39608	0,41679	0,419761
24	0	0,395644	0,472562	0,381584	0,398564	0,400232
25	0,013751242	0,401014	0,468877	0,38356	0,401151	0,403044
t	nx23(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,05276907	0,41517	0,453913	0,38951	0,408745	0,411222
3	0,248171369	0,469476	0,482372	0,431171	0,453727	0,457235
4	0,402821317	0,500503	0,500234	0,502146	0,50099	0,500863
5	0,475444096	0,512792	0,505608	0,603786	0,528593	0,524058
6	0,523510972	0,520301	0,508619	0,606903	0,549488	0,540504
7	0,611285266	0,532924	0,513325	0,491981	0,594938	0,573054
8	0,642110763	0,537062	0,514788	0,473667	0,613833	0,58533
9	0,724660397	0,547486	0,518327	0,43959	0,675577	0,620619
10	0,730407524	0,548179	0,518556	0,437724	0,680669	0,623216
11	0,748693835	0,550356	0,51927	0,432093	0,697772	0,631606
12	0,760188088	0,551705	0,519708	0,42877	0,709306	0,636983
13	0,769592476	0,552797	0,520061	0,426163	0,719253	0,641441
14	0,789968652	0,555128	0,52081	0,420827	0,742631	0,65129
15	0,742424242	0,549614	0,519027	0,433974	0,691745	0,628708
16	0,745036573	0,549924	0,519129	0,433184	0,694235	0,629913
17	0,870950888	0,563959	0,523579	0,40293	0,879948	0,693154
18	0,870950888	0,563959	0,523579	0,40293	0,879948	0,693154
19	0,878265413	0,564725	0,523814	0,401522	0,899799	0,697162
20	0,937826541	0,570776	0,525653	0,391027	0,859013	0,731314
21	0,960815047	0,573028	0,526328	0,387378	0,813777	0,745249
22	0,981191223	0,574988	0,526911	0,384302	0,781164	0,75797
23	0,985370951	0,575386	0,527029	0,383688	0,775097	0,760623
24	0,985370951	0,575386	0,527029	0,383688	0,775097	0,760623
25	1	0,576768	0,527438	0,381584	0,755212	0,770029
t	nx30(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952581665	0,572226	0,526088	0,388662	0,828718	0,740208
3	0,895679663	0,566527	0,524366	0,398282	0,965306	0,706865
4	1	0,576768	0,527438	0,381584	0,755212	0,770029
5	0,876712329	0,564562	0,523764	0,401819	0,895358	0,696308

6	0,895152792	0,566473	0,52435	0,398377	0,962505	0,706568
7	0,728661749	0,547969	0,518487	0,438286	0,679109	0,622425
8	0,64857745	0,537912	0,515084	0,47034	0,618039	0,587965
9	0,574815595	0,527838	0,511477	0,521747	0,574724	0,559114
10	0,542149631	0,523093	0,509695	0,564436	0,55827	0,547135
11	0,382507903	0,496837	0,498498	0,487912	0,493983	0,494707
12	0,065331928	0,419424	0,446259	0,391545	0,411275	0,413921
13	0,082191781	0,424927	0,429862	0,394376	0,414738	0,417595
14	0,075869336	0,42289	0,437324	0,3933	0,41343	0,41621
15	0,142781876	0,442999	0,451462	0,405656	0,427874	0,431308
16	0,197049526	0,457305	0,471816	0,417628	0,440662	0,444311
17	0,265542677	0,473363	0,485141	0,436438	0,458418	0,461784
18	0,306638567	0,482114	0,490681	0,450706	0,470077	0,472884
19	0,147523709	0,444313	0,454066	0,406623	0,428951	0,432416
20	0,142255005	0,442852	0,451155	0,405549	0,427755	0,431185
21	0,0943098	0,428745	0,402153	0,396487	0,417276	0,420273
22	0,002634352	0,39669	0,471897	0,381958	0,399056	0,400768
23	0	0,395644	0,472562	0,381584	0,398564	0,400232
24	0,360906217	0,492817	0,49651	0,475272	0,486829	0,488309
25	0,273972603	0,475208	0,486381	0,439142	0,460743	0,464022
t	nx34(t)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,227354595	0,464658	0,478593	0,425337	0,448279	0,45189
3	0,415838888	0,502797	0,501286	0,51293	0,505633	0,504883
4	0,532449793	0,521648	0,509141	0,583618	0,553649	0,543666
5	0,621191425	0,53427	0,513805	0,485589	0,600814	0,576949
6	0,647711858	0,537799	0,515045	0,470776	0,61747	0,587611
7	0,770802302	0,552936	0,520106	0,425835	0,720569	0,642019
8	0,944868552	0,57147	0,525862	0,389888	0,84391	0,735537
9	0,845331995	0,561237	0,522735	0,408106	0,824817	0,679421
10	0,847804403	0,561503	0,522818	0,407589	0,829449	0,680726
11	0,85321205	0,562081	0,522998	0,406472	0,840008	0,683595
12	0,889752151	0,565917	0,52418	0,399367	0,938271	0,703537
13	0,908690465	0,567855	0,524771	0,395958	0,944625	0,714264
14	0,923872355	0,569386	0,525234	0,393344	0,893721	0,723064
15	0,943618919	0,571347	0,525825	0,390089	0,846496	0,734784
16	0,950672184	0,57204	0,526033	0,388964	0,832362	0,739047
17	1	0,576768	0,527438	0,381584	0,755212	0,770029
18	0,997581552	0,576541	0,527371	0,381927	0,758366	0,768461
19	0,447014489	0,508125	0,50364	0,547493	0,517274	0,51475
20	0,379080774	0,496208	0,498193	0,485757	0,492828	0,493682
21	0,387845006	0,49781	0,498966	0,491397	0,495797	0,496311

22	0,423185088	0,504073	0,501861	0,519773	0,508308	0,507177
23	0,325019741	0,485842	0,492811	0,458136	0,475567	0,478008
24	0,312336776	0,483281	0,491361	0,452929	0,47176	0,474462
25	0,307631976	0,482319	0,490801	0,451089	0,470369	0,473159
t	nx1(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,395644	0,472562	0,381584	0,398564	0,400232
3	0,051898617	0,41487	0,454366	0,389372	0,408571	0,411036
4	0,103890075	0,431688	0,393044	0,398203	0,419314	0,422412
5	0,155927955	0,446611	0,458106	0,408371	0,430878	0,434393
6	0,208105097	0,460036	0,474505	0,420343	0,443399	0,447049
7	0,260375081	0,472219	0,484348	0,43483	0,457008	0,460422
8	0,313573484	0,483533	0,491506	0,45342	0,472127	0,474805
9	0,367189676	0,494	0,497104	0,478731	0,488879	0,490154
10	0,420620184	0,503629	0,501662	0,517313	0,50737	0,506374
11	0,473307957	0,512447	0,505465	0,597784	0,527717	0,523348
12	0,522978368	0,52022	0,508588	0,608541	0,549243	0,540317
13	0,566846161	0,526697	0,511054	0,530172	0,570576	0,556148
14	0,610342587	0,532795	0,513279	0,492619	0,594388	0,572686
15	0,653467645	0,538551	0,515306	0,46792	0,621279	0,589972
16	0,696221335	0,543997	0,517164	0,449616	0,652104	0,608046
17	0,738603658	0,54916	0,518879	0,435145	0,688158	0,626952
18	0,780800297	0,554085	0,520476	0,423178	0,731779	0,646826
19	0,66994708	0,54068	0,516039	0,46031	0,632605	0,596824
20	0,71316498	0,546088	0,517864	0,443475	0,665759	0,615482
21	0,761628447	0,551873	0,519763	0,428365	0,710799	0,637662
22	0,815569585	0,557993	0,521719	0,414653	0,776446	0,664043
23	0,862036951	0,563019	0,523288	0,404687	0,858708	0,688322
24	0,903955065	0,567374	0,524624	0,396794	0,967319	0,711556
25	0,952279268	0,572197	0,52608	0,38871	0,82929	0,740024
t	nx2(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,395644	0,472562	0,381584	0,398564	0,400232
3	0,022728446	0,404407	0,46614	0,384883	0,402864	0,404899
4	0,047781374	0,413442	0,456402	0,388719	0,407752	0,41016
5	0,079171178	0,423958	0,433706	0,39386	0,414111	0,416932
6	0,100316675	0,430598	0,335065	0,397558	0,418551	0,421612
7	0,13913703	0,441979	0,449257	0,404922	0,427051	0,43046
8	0,19414241	0,456578	0,471058	0,416931	0,43995	0,443596
9	0,230448669	0,465386	0,479192	0,426174	0,449077	0,452677
10	0,290658312	0,478782	0,488669	0,444816	0,465445	0,468511
11	0,296798802	0,480073	0,489462	0,447023	0,46721	0,470182
12	0,326213729	0,48608	0,492943	0,458645	0,47593	0,478344

13	0,277367462	0,475943	0,486864	0,44026	0,461689	0,464929
14	0,274673062	0,47536	0,486482	0,439371	0,460938	0,464209
15	0,288098505	0,478241	0,488332	0,443916	0,464715	0,467817
16	0,357270013	0,492127	0,496159	0,473341	0,485653	0,487247
17	0,427899189	0,504885	0,502223	0,524513	0,510046	0,508659
18	0,519292091	0,51966	0,508369	0,620964	0,547557	0,539024
19	0,601238087	0,531544	0,51283	0,499077	0,589155	0,569152
20	0,706676915	0,545292	0,517598	0,445765	0,660421	0,612616
21	0,794057421	0,55559	0,520957	0,419803	0,747665	0,653298
22	0,838799024	0,560533	0,522516	0,409491	0,813105	0,675993
23	0,94268707	0,571256	0,525797	0,390239	0,84845	0,734224
24	1	0,576768	0,527438	0,381584	0,755212	0,770029
25	0,924424742	0,569442	0,525251	0,39325	0,89219	0,723388
t	nx5(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,952267303	0,572196	0,526079	0,388712	0,829313	0,740017
3	0,922945789	0,569293	0,525206	0,3935	0,896324	0,722522
4	0,917149676	0,568711	0,52503	0,394489	0,913792	0,719145
5	1	0,576768	0,527438	0,381584	0,755212	0,770029
6	0,824411865	0,558966	0,522025	0,412642	0,7896	0,668548
7	0,845550631	0,561261	0,522743	0,40806	0,825222	0,679536
8	0,649164678	0,537989	0,515111	0,470045	0,618425	0,588205
9	0,545857484	0,523641	0,509904	0,558207	0,560068	0,548471
10	0,87248551	0,56412	0,523628	0,402632	0,883904	0,693992
11	0,746334811	0,550078	0,519179	0,432795	0,695484	0,630513
12	0,6771224	0,541595	0,516351	0,457229	0,637745	0,599852
13	0,293897034	0,479465	0,48909	0,445971	0,466374	0,469391
14	0,193999318	0,456542	0,47102	0,416897	0,439915	0,443561
15	0,143879986	0,443304	0,452089	0,405879	0,428123	0,431564
16	0,307875895	0,482369	0,49083	0,451183	0,470441	0,473226
17	0,334469826	0,487716	0,493839	0,462273	0,478461	0,480682
18	0,378111149	0,496029	0,498106	0,485159	0,492502	0,493392
19	0,505625639	0,51756	0,507541	0,70336	0,541434	0,534277
20	0,242754859	0,46824	0,481442	0,429606	0,452292	0,455833
21	0,272758268	0,474944	0,486206	0,438746	0,460406	0,463699
22	0,177633822	0,452365	0,466257	0,413102	0,435967	0,439577
23	0,106034777	0,432337	0,403567	0,398594	0,419774	0,422894
24	0,077054211	0,423274	0,436085	0,3935	0,413674	0,416469
25	0,054892601	0,415899	0,452773	0,38985	0,40917	0,411676
t	nx6(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,395644	0,472562	0,381584	0,398564	0,400232
3	0,01444848	0,401281	0,468674	0,383662	0,401283	0,403187

4	0,036232655	0,409354	0,461364	0,386923	0,405479	0,407719
5	0,084411143	0,425635	0,426603	0,394757	0,4152	0,418083
6	0,086371719	0,426257	0,423319	0,395096	0,415609	0,418515
7	0,135016287	0,440817	0,446506	0,404101	0,426127	0,429504
8	0,085773921	0,426067	0,424367	0,394993	0,415484	0,418383
9	0,094117766	0,428686	0,402951	0,396453	0,417236	0,42023
10	0,193144571	0,456327	0,470793	0,416693	0,439707	0,443351
11	0,189927606	0,455515	0,469917	0,415933	0,438924	0,442564
12	0,248658753	0,469587	0,482454	0,431314	0,453857	0,457361
13	0,144560796	0,443493	0,452471	0,406017	0,428277	0,431723
14	0,145619608	0,443787	0,453053	0,406233	0,428518	0,43197
15	0,154748697	0,446291	0,457577	0,408123	0,430606	0,434115
16	0,247068002	0,469226	0,482185	0,43085	0,453434	0,456949
17	0,336479373	0,488111	0,494052	0,463184	0,479083	0,481254
18	0,412440283	0,502202	0,501016	0,509962	0,504409	0,503828
19	0,513645506	0,518797	0,50803	0,645091	0,545002	0,537053
20	0,490397232	0,515177	0,506584	0,668838	0,534842	0,529076
21	0,576074897	0,528017	0,511543	0,520497	0,575388	0,559585
22	0,627323434	0,535095	0,514097	0,481891	0,604542	0,579384
23	0,761969897	0,551912	0,519776	0,428269	0,711154	0,637823
24	0,913977841	0,568391	0,524933	0,395036	0,924421	0,717309
25	0,948173929	0,571795	0,525959	0,38936	0,837243	0,737533
t	nx15(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,547766152	0,523922	0,510011	0,555188	0,560999	0,549161
3	0,651144885	0,538248	0,515201	0,469059	0,619733	0,589017
4	0,747180388	0,550178	0,519212	0,432543	0,696301	0,630905
5	0,990881168	0,575909	0,527184	0,382888	0,767373	0,764144
6	0,955238448	0,572486	0,526166	0,388245	0,823765	0,741829
7	1	0,576768	0,527438	0,381584	0,755212	0,770029
8	0,923154924	0,569314	0,525213	0,393465	0,895732	0,722644
9	0,832018184	0,559797	0,522286	0,410958	0,801669	0,672466
10	0,791715421	0,555326	0,520873	0,420388	0,744766	0,652147
11	0,850896276	0,561834	0,522921	0,406948	0,835411	0,682364
12	0,947956756	0,571774	0,525953	0,389395	0,837673	0,737401
13	0,95788839	0,572744	0,526243	0,387832	0,818952	0,743451
14	0,838142329	0,560462	0,522494	0,409631	0,811967	0,67565
15	0,797255921	0,555951	0,521072	0,419013	0,751692	0,654877
16	0,734667993	0,54869	0,518724	0,436372	0,684527	0,625153
17	0,748230656	0,550302	0,519252	0,432231	0,697321	0,631392
18	0,560074649	0,52572	0,510689	0,538144	0,567122	0,55365
19	0,576618155	0,528094	0,511571	0,519965	0,575675	0,559788

20	0,025983734	0,405617	0,46507	0,385369	0,40349	0,405575
21	0,114341686	0,434824	0,424565	0,400127	0,421568	0,424769
22	0,059040873	0,417311	0,450384	0,390518	0,410003	0,412566
23	0,126048675	0,438251	0,439207	0,402349	0,424133	0,427439
24	0,092005087	0,428028	0,410355	0,39608	0,41679	0,419761
25	0	0,395644	0,472562	0,381584	0,398564	0,400232
t	nx23(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,395644	0,472562	0,381584	0,398564	0,400232
3	0,05276907	0,41517	0,453913	0,38951	0,408745	0,411222
4	0,248171369	0,469476	0,482372	0,431171	0,453727	0,457235
5	0,402821317	0,500503	0,500234	0,502146	0,50099	0,500863
6	0,475444096	0,512792	0,505608	0,603786	0,528593	0,524058
7	0,523510972	0,520301	0,508619	0,606903	0,549488	0,540504
8	0,611285266	0,532924	0,513325	0,491981	0,594938	0,573054
9	0,642110763	0,537062	0,514788	0,473667	0,613833	0,58533
10	0,724660397	0,547486	0,518327	0,43959	0,675577	0,620619
11	0,730407524	0,548179	0,518556	0,437724	0,680669	0,623216
12	0,748693835	0,550356	0,51927	0,432093	0,697772	0,631606
13	0,760188088	0,551705	0,519708	0,42877	0,709306	0,636983
14	0,769592476	0,552797	0,520061	0,426163	0,719253	0,641441
15	0,789968652	0,555128	0,52081	0,420827	0,742631	0,65129
16	0,742424242	0,549614	0,519027	0,433974	0,691745	0,628708
17	0,745036573	0,549924	0,519129	0,433184	0,694235	0,629913
18	0,870950888	0,563959	0,523579	0,40293	0,879948	0,693154
19	0,870950888	0,563959	0,523579	0,40293	0,879948	0,693154
20	0,878265413	0,564725	0,523814	0,401522	0,899799	0,697162
21	0,937826541	0,570776	0,525653	0,391027	0,859013	0,731314
22	0,960815047	0,573028	0,526328	0,387378	0,813777	0,745249
23	0,981191223	0,574988	0,526911	0,384302	0,781164	0,75797
24	0,985370951	0,575386	0,527029	0,383688	0,775097	0,760623
25	0,985370951	0,575386	0,527029	0,383688	0,775097	0,760623
t	nx30(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0,929926238	0,569991	0,525417	0,392329	0,87773	0,726624
3	0,952581665	0,572226	0,526088	0,388662	0,828718	0,740208
4	0,895679663	0,566527	0,524366	0,398282	0,965306	0,706865
5	1	0,576768	0,527438	0,381584	0,755212	0,770029
6	0,876712329	0,564562	0,523764	0,401819	0,895358	0,696308
7	0,895152792	0,566473	0,52435	0,398377	0,962505	0,706568
8	0,728661749	0,547969	0,518487	0,438286	0,679109	0,622425
9	0,64857745	0,537912	0,515084	0,47034	0,618039	0,587965
10	0,574815595	0,527838	0,511477	0,521747	0,574724	0,559114

11	0,542149631	0,523093	0,509695	0,564436	0,55827	0,547135
12	0,382507903	0,496837	0,498498	0,487912	0,493983	0,494707
13	0,065331928	0,419424	0,446259	0,391545	0,411275	0,413921
14	0,082191781	0,424927	0,429862	0,394376	0,414738	0,417595
15	0,075869336	0,42289	0,437324	0,3933	0,41343	0,41621
16	0,142781876	0,442999	0,451462	0,405656	0,427874	0,431308
17	0,197049526	0,457305	0,471816	0,417628	0,440662	0,444311
18	0,265542677	0,473363	0,485141	0,436438	0,458418	0,461784
19	0,306638567	0,482114	0,490681	0,450706	0,470077	0,472884
20	0,147523709	0,444313	0,454066	0,406623	0,428951	0,432416
21	0,142255005	0,442852	0,451155	0,405549	0,427755	0,431185
22	0,0943098	0,428745	0,402153	0,396487	0,417276	0,420273
23	0,002634352	0,39669	0,471897	0,381958	0,399056	0,400768
24	0	0,395644	0,472562	0,381584	0,398564	0,400232
25	0,360906217	0,492817	0,49651	0,475272	0,486829	0,488309
t	nx34(t-1)	1.Aralık	2.Aralık	3.Aralık	4.Aralık	5.Aralık
2	0	0,395644	0,472562	0,381584	0,398564	0,400232
3	0,227354595	0,464658	0,478593	0,425337	0,448279	0,45189
4	0,415838888	0,502797	0,501286	0,51293	0,505633	0,504883
5	0,532449793	0,521648	0,509141	0,583618	0,553649	0,543666
6	0,621191425	0,53427	0,513805	0,485589	0,600814	0,576949
7	0,647711858	0,537799	0,515045	0,470776	0,61747	0,587611
8	0,770802302	0,552936	0,520106	0,425835	0,720569	0,642019
9	0,944868552	0,57147	0,525862	0,389888	0,84391	0,735537
10	0,845331995	0,561237	0,522735	0,408106	0,824817	0,679421
11	0,847804403	0,561503	0,522818	0,407589	0,829449	0,680726
12	0,85321205	0,562081	0,522998	0,406472	0,840008	0,683595
13	0,889752151	0,565917	0,52418	0,399367	0,938271	0,703537
14	0,908690465	0,567855	0,524771	0,395958	0,944625	0,714264
15	0,923872355	0,569386	0,525234	0,393344	0,893721	0,723064
16	0,943618919	0,571347	0,525825	0,390089	0,846496	0,734784
17	0,950672184	0,57204	0,526033	0,388964	0,832362	0,739047
18	1	0,576768	0,527438	0,381584	0,755212	0,770029
19	0,997581552	0,576541	0,527371	0,381927	0,758366	0,768461
20	0,447014489	0,508125	0,50364	0,547493	0,517274	0,51475
21	0,379080774	0,496208	0,498193	0,485757	0,492828	0,493682
22	0,387845006	0,49781	0,498966	0,491397	0,495797	0,496311
23	0,423185088	0,504073	0,501861	0,519773	0,508308	0,507177
24	0,325019741	0,485842	0,492811	0,458136	0,475567	0,478008
25	0,312336776	0,483281	0,491361	0,452929	0,47176	0,474462

EK 13: Bulanık İlişkileri Belirlemede Kullanılan Yapay Sinir Ağı İçin R Kodları

```
> setwd("C:/Users/bmyo/Desktop/tez son/son datalar 19.10.2015/fts-ysa-R")
> gauss_train <- read.csv2("C:/Users/bmyo/Desktop/tez son/son datalar 19.10.2015/fts-ysa-R/gauss_train.csv")
> View(gauss_train)
> require(neuralnet)
Loading required package: neuralnet
Loading required package: grid
Loading required package: MASS
> gauss51<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,linear.output = FALSE,data =gauss_train ,hidden = c(22,18,6),threshold = 0.001,rep = 30)
> gauss51
Call: neuralnet(formula = h1 + h2 + h3 + h4 + h5 ~ g1 + g2 + g3 + g4 + g5, data = gauss_train, hidden = c(22, 18, 6), threshold = 0.001, rep = 30, linear.output = FALSE)
```

30 repetitions were calculated.

	Error	Reached Threshold	Steps
11	0.001765402355	0.0009549412565	1303
25	0.003449061726	0.0008463424518	849
6	0.003565186076	0.0008288727299	895
13	0.006727505572	0.0009512527326	755
21	0.007811866090	0.0009165270853	486
12	0.009405327374	0.0009878426439	423
3	0.010210538066	0.0009688459648	673
30	0.011039914451	0.0009207543248	546
19	0.012257782475	0.0009529912359	497
7	0.012331567778	0.0009734840166	418
24	0.012427931141	0.0009108245377	428
9	0.013264562349	0.0007809800993	465
1	0.013716289785	0.0009531004468	351
15	0.013783414858	0.0009643509940	274
27	0.013928374765	0.0007248487381	375
8	0.014770941934	0.0008551273735	332
29	0.015000100736	0.0007716077960	363
4	0.015361753107	0.0007625176250	275
2	0.015581602372	0.0009993722678	281
17	0.015690008160	0.0009497961743	273
20	0.016026073392	0.0009976732168	306
28	0.016607065152	0.0007238976970	303
14	0.016842623192	0.0009656286092	219
26	0.016904378014	0.0006994446560	283
16	0.016943518883	0.0009151165086	199
10	0.018676440033	0.0009963561311	314
18	0.019752032446	0.0009820829259	290
22	0.022621040773	0.0008702156948	266
5	0.023327226614	0.0006120644258	279
23	0.024454144563	0.0007933163521	262

```
> gauss119<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,linear
.output = FALSE,data =gauss_train ,hidden = c(9,3),threshold = 0.001
,rep = 15)
> gauss119
Call: neuralnet(formula = h1 + h2 + h3 + h4 + h5 ~ g1 + g2 + g3 + g4
+ g5, data = gauss_train, hidden = c(9, 3), threshold = 0.001,
rep = 15, linear.output = FALSE)
```

15 repetitions were calculated.

	Error	Reached Threshold	Steps
3	0.006494948796	0.0008626490294	1208
7	0.013917229195	0.0009825671359	1121
4	0.014001649117	0.0009069275700	770
1	0.014677616463	0.0009875913175	916
8	0.019949789750	0.0009856432638	761
9	0.022624892577	0.0009858787011	758
12	0.022961697179	0.0008356835341	555
11	0.023240824798	0.0009548504529	599
5	0.024307233580	0.0008954099973	417
15	0.024734039817	0.0009151254394	379
13	0.025040549121	0.0009391025126	363
2	0.026227258248	0.0009192696515	378
6	0.026540004345	0.0009697790947	691
14	0.026736966165	0.0008684720614	421
10	0.029136980944	0.0009346104716	346

```
> gauss146<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,linear
.output = FALSE,data =gauss_train ,hidden = c(8,5,2),threshold = 0.0
01,rep = 15)
> gauss146
Call: neuralnet(formula = h1 + h2 + h3 + h4 + h5 ~ g1 + g2 + g3 + g4
+ g5, data = gauss_train, hidden = c(8, 5, 2), threshold = 0.001
, rep = 15, linear.output = FALSE)
```

15 repetitions were calculated.

	Error	Reached Threshold	Steps
3	0.006669101088	0.0009436136552	1833
12	0.013829518959	0.0009909080122	1570
8	0.013991554697	0.0008680859652	1254
5	0.015220144903	0.0008476584430	1863
6	0.016497834294	0.0009550819517	803
15	0.024124066972	0.0009544926009	578
7	0.024607397661	0.0008925804830	774
2	0.025118797380	0.0009608665093	545
10	0.025921170382	0.0007939343318	440
14	0.027482465745	0.0009938285667	443
13	0.028367839606	0.0008997898651	447
9	0.028600833342	0.0008702683489	546
4	0.053606414892	0.0008550999973	448
1	0.058403231032	0.0009223245309	367
11	0.604170421432	0.0006563264803	36

```
> sigmoidal_train <- read.csv2("C:/Users/bmyo/Desktop/07.11.2015/fts
-ysa-R/sigmoidal_train.csv")
> View(sigmoidal_train)
```

```

> sig92<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =sig
moidal_train ,hidden = c(6,9),threshold = 0.001,rep = 15)
>
> sig92
Call: neuralnet(formula = h1 + h2 + h3 + h4 + h5 ~ g1 + g2 + g3 + g4
+ g5, data = sigmoidal_train, hidden = c(6, 9), threshold = 0.00
1, rep = 15)
> sig99<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =sig
moidal_train ,hidden = c(10,5),threshold = 0.001,rep = 15)
>
> sig99
> sig57<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =sig
moidal_train ,hidden = c(24,12,6,3),threshold = 0.001,rep = 40)
>
> sig57
Call: neuralnet(formula = h1 + h2 + h3 + h4 + h5 ~ g1 + g2 + g3 + g4
+ g5, data = sigmoidal_train, hidden = c(24, 12, 6, 3), threshol
d = 0.001, rep = 40)

> can_train <- read.csv2("C:/Users/bmyo/Desktop/07.11.2015/fts-ysa-R
/can_train.csv")
> View(can_train)
> bell197<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =ca
n_train ,hidden = c(24,16,18,9),threshold = 0.001,rep = 40)
bell197

> bell1155<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =c
an_train ,hidden = c(11,2,2),threshold = 0.001,rep = 15)
> bell1156<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =c
an_train ,hidden = c(12,2,1),threshold = 0.001,rep = 15)
> bell1157<-neuralnet(formula = h1+h2+h3+h4+h5~g1+g2+g3+g4+g5,data =c
an_train ,hidden = c(11,2,1),threshold = 0.001,rep = 15)

> can_tahmin <- read.csv2("C:/Users/bmyo/Desktop/12.11.2015/fts-ysa-R
/can_tahmin.csv")
> View(can_tahmin)
> gauss_tahmin <- read.csv2("C:/Users/bmyo/Desktop/12.11.2015/fts-ys
a-R/gauss_tahmin.csv")
> View(gauss_tahmin)
> sigmoidal_tahmin <- read.csv2("C:/Users/bmyo/Desktop/12.11.2015/ft
s-ysa-R/sigmoidal_tahmin.csv")
> View(sigmoidal_tahmin)

> gauss51.forecast <- compute(gauss51,gauss_tahmin)
> gauss119.forecast <- compute(gauss119,gauss_tahmin)
> gauss146.forecast <- compute(gauss146,gauss_tahmin)
> print(gauss51.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [
,5]
[1,] 0.009602239018 0.2683476029 0.6695307903 0.3016229936 0.0201512
404
> print(gauss119.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]
[,5]
[1,] 0.0009265841015 0.1374904699 0.7172840791 0.3324903361 0.022589
82488

```

```

> print(gauss146.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]
[1,] 0.003400624619 0.1519057078 0.7069181512 0.4509737085 0.0286692
5186

> sig57.forecast <- compute(sig57,sigmoidal_tahmin)
> sig92.forecast <- compute(sig92,sigmoidal_tahmin)
> sig99.forecast <- compute(sig99,sigmoidal_tahmin)
> print(sig57.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
]
[1,] 0.3819831668 0.4800155749 0.4855572467 0.4247419456 0.287521340
5
> print(sig92.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
]
[1,] 0.3857558367 0.4792709859 0.4867553678 0.4338343938 0.299300629
6
> print(sig99.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,] 0.395480842 0.4872156503 0.4955344957 0.431236245 0.2856037811

> bell197.forecast <- compute(bell197,can_tahmin)
> print(bell197.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,] 0.5298999926 0.4898123163 0.4831671772 0.715060836 0.6090977024
>
> bell155.forecast <- compute(bell155,can_tahmin)
> print(bell155.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,] 0.5684739127 0.5291568798 0.51672368 0.660160258 0.6281877214
>
> bell156.forecast <- compute(bell156,can_tahmin)
> print(bell156.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,] 0.5642178632 0.5409703272 0.5243776499 0.6736084912 0.6252544415
>
> bell157.forecast <- compute(bell157,can_tahmin)
> print(bell157.forecast$net.result)
      [,1]      [,2]      [,3]      [,4]      [,5]
[1,] 0.5705602637 0.5278746358 0.5179862069 0.6686544324 0.6385002471

```


EK 14: Bulanık İlişkileri Belirlemede Kullanılan İleri Beslemeli Geriye Yayımlı Yapay Sinir Ağı Eğitim Sonuçları (Gaussian Üyelik Fonksiyonu İçin)

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğrenme Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katmanı Akt. Fonk. Sig.
1	1	5	360	r-bprop	0,0588	0,0010	Sig.
1	1	4	376	r-bprop	0,0589	0,0009	Sig.
1	1	3	53191	bprop	0,0657	0,0010	Sig.
1	2	4	918	r-bprop	0,0269	0,0010	Sig.
1	2	1	98026	bprop	0,0438	0,0010	Sig.
1	3	5	924	r-bprop	0,0217	0,0009	Sig.
1	4	5	732	r-bprop	0,0230	0,0009	Sig.
1	5	4	1584	r-bprop	0,0147	0,0010	Sig.
1	5	2	95070	bprop	0,0410	0,0010	Sig.
1	6	5	592	r-bprop	0,0150	0,0010	Sig.
1	7	5	412	r-bprop	0,0226	0,0010	Sig.
1	8	4	597	r-bprop	0,0161	0,0010	Sig.
1	9	4	631	r-bprop	0,0140	0,0010	Sig.
1	10	2	958	r-bprop	0,0131	0,0010	Sig.
1	10	1	97140	bprop	0,0385	0,0010	Sig.
1	11	3	1283	r-bprop	0,0124	0,0009	Sig.
1	12	5	259	r-bprop	0,0184	0,0008	Sig.
1	13	8	1217	r-bprop	0,0141	0,0009	Sig.
1	14	8	436	r-bprop	0,0215	0,0009	Sig.
1	15	10	645	r-bprop	0,0138	0,0010	Sig.
1	15	2	47617	bprop	0,0427	0,0010	Sig.
1	16	7	778	r-bprop	0,0152	0,0010	Sig.
1	17	6	558	r-bprop	0,0179	0,0010	Sig.
1	18	14	1286	r-bprop	0,0130	0,0009	Sig.
1	24	6	798	r-bprop	0,0134	0,0009	Sig.
1	30	11	591	r-bprop	0,0138	0,0009	Sig.
1	32	16	715	r-bprop	0,0136	0,0010	Sig.
1	40	27	1710	r-bprop	0,0067	0,0009	Sig.
2	(1-1)	2	521	r-bprop	0,0585	0,0009	Sig.
2	(1-2)	2	646	r-bprop	0,0397	0,0010	Sig.
2	(1-3)	4	485	r-bprop	0,0414	0,0009	Sig.

2	(1-4)	3	841	r-bprop	0,0381	0,0009	Sig.
2	(1-5)	3	1087	r-bprop	0,0354	0,0010	Sig.
2	(1-6)	5	684	r-bprop	0,0433	0,0009	Sig.
2	(1-7)	1	581	r-bprop	0,0387	0,0009	Sig.
2	(1-8)	3	907	r-bprop	0,0289	0,0009	Sig.
2	(1-9)	2	958	r-bprop	0,0298	0,0009	Sig.
2	(1-10)	3	1057	r-bprop	0,0303	0,0009	Sig.
2	(1-11)	5	560	r-bprop	0,0419	0,0007	Sig.
2	(1-12)	7	892	r-bprop	0,0298	0,0010	Sig.
2	(1-13)	9	1477	r-bprop	0,0336	0,0010	Sig.
2	(1-14)	10	662	r-bprop	0,0293	0,0010	Sig.
2	(2-1)	1	406	r-bprop	0,0570	0,0010	Sig.
2	(2-2)	1	1551	r-bprop	0,0254	0,0010	Sig.
2	(2-3)	2	736	r-bprop	0,0261	0,0009	Sig.
2	(2-4)	3	785	r-bprop	0,0244	0,0009	Sig.
2	(2-5)	5	1016	r-bprop	0,0215	0,0010	Sig.
2	(2-6)	5	865	r-bprop	0,0181	0,0008	Sig.
2	(2-7)	1	679	r-bprop	0,0220	0,0009	Sig.
2	(2-8)	4	775	r-bprop	0,0178	0,0010	Sig.
2	(2-9)	5	833	r-bprop	0,0164	0,0010	Sig.
2	(2-10)	5	1097	r-bprop	0,0151	0,0009	Sig.
2	(2-13)	7	527	r-bprop	0,0245	0,0010	Sig.
2	(3-1)	5	459	r-bprop	0,0574	0,0010	Sig.
2	(3-4)	1	887	r-bprop	0,0168	0,0010	Sig.
2	(3-8)	1	954	r-bprop	0,0172	0,0010	Sig.
2	(3-12)	2	887	r-bprop	0,0143	0,0010	Sig.
2	(4-1)	2	240	r-bprop	0,0572	0,0009	Sig.
2	(4-5)	7	946	r-bprop	0,0144	0,0009	Sig.
2	(4-7)	2	919	r-bprop	0,0162	0,0010	Sig.
2	(4-11)	9	729	r-bprop	0,0162	0,0010	Sig.
2	(5-5)	7	1259	r-bprop	0,0144	0,0010	Sig.
2	(5-10)	4	486	r-bprop	0,0145	0,0008	Sig.
2	(6-3)	5	1452	r-bprop	0,0137	0,0008	Sig.
2	(6-6)	3	706	r-bprop	0,0133	0,0009	Sig.
2	(6-9)	8	591	r-bprop	0,0145	0,0009	Sig.
2	(7-1)	9	383	r-bprop	0,0574	0,0006	Sig.
2	(7-5)	9	759	r-bprop	0,0140	0,0010	Sig.
2	(7-8)	9	964	r-bprop	0,0141	0,0008	Sig.
2	(8-1)	10	337	r-bprop	0,0573	0,0008	Sig.
2	(8-3)	12	804	r-bprop	0,0145	0,0009	Sig.
2	(8-5)	3	652	r-bprop	0,0114	0,0010	Sig.

2	(8-7)	8	835	r-bprop	0,0133	0,0010	Sig.
2	(8-8)	1	802	r-bprop	0,0120	0,0008	Sig.
2	(9-1)	7	461	r-bprop	0,0545	0,0010	Sig.
2	(9-3)	7	834	r-bprop	0,0107	0,0010	Sig.
2	(9-3)	3	1208	r-bprop	0,0065	0,0009	Sig.
2	(9-3)	4	96751	bprop	0,0381	0,0010	Sig.
2	(9-6)	2	764	r-bprop	0,0117	0,0010	Sig.
2	(10-1)	1	437	r-bprop	0,0575	0,0009	Sig.
2	(10-2)	3	987	r-bprop	0,0191	0,0008	Sig.
2	(10-5)	11	507	r-bprop	0,0125	0,0009	Sig.
2	(10-6)	8	905	r-bprop	0,0137	0,0010	Sig.
2	(10-10)	6	561	r-bprop	0,0145	0,0010	Sig.
2	(11-2)	12	834	r-bprop	0,0164	0,0009	Sig.
2	(11-4)	13	864	r-bprop	0,0074	0,0009	Sig.
2	(12-3)	8	1070	r-bprop	0,0120	0,0010	Sig.
2	(12-3)	11	775	r-bprop	0,0153	0,0010	Sig.
2	(13-2)	2	1847	r-bprop	0,0105	0,0009	Sig.
2	(14-1)	1	349	r-bprop	0,0576	0,0009	Sig.
2	(15-3)	3	1847	r-bprop	0,0109	0,0009	Sig.
2	(18-3)	8	1806	r-bprop	0,0056	0,0009	Sig.
2	(20-3)	4	1055	r-bprop	0,0128	0,0010	Sig.
2	(20-4)	12	764	r-bprop	0,0108	0,0008	Sig.
2	(20-20)	18	558	r-bprop	0,0093	0,0008	Sig.
2	(32-12)	16	500	r-bprop	0,0118	0,0010	Sig.
3	(1-1-1)	19	482	r-bprop	0,0580	0,0009	Sig.
3	(1-1-2)	4	476	r-bprop	0,0579	0,0010	Sig.
3	(1-1-12)	1	484	r-bprop	0,0427	0,0009	Sig.
3	(1-2-1)	15	582	r-bprop	0,0580	0,0008	Sig.
3	(2-1-1)	8	713	r-bprop	0,0561	0,0009	Sig.
3	(2-1-12)	7	900	r-bprop	0,0395	0,0010	Sig.
3	(2-5-8)	9	587	r-bprop	0,0150	0,0008	Sig.
3	(2-9-4)	6	1601	r-bprop	0,0086	0,0010	Sig.
3	(2-11-2)	2	830	r-bprop	0,0261	0,0010	Sig.
3	(3-2-3)	19	1163	r-bprop	0,0194	0,0008	Sig.
3	(3-6-6)	8	1858	r-bprop	0,0128	0,0008	Sig.
3	(3-9-3)	14	1322	r-bprop	0,0140	0,0009	Sig.
3	(4-7-4)	1	1340	r-bprop	0,0071	0,0009	Sig.
3	(4-8-3)	9	659	r-bprop	0,0165	0,0010	Sig.
3	(5-3-7)	4	881	r-bprop	0,0134	0,0008	Sig.
3	(5-5-5)	15	734	r-bprop	0,0136	0,0010	Sig.
3	(6-3-6)	7	1445	r-bprop	0,0132	0,0010	Sig.

3	(6-6-3)	15	775	r-bprop	0,0146	0,0008	Sig.
3	(6-6-6)	18	1191	r-bprop	0,0114	0,0008	Sig.
3	(7-2-3)	2	720	r-bprop	0,0182	0,0010	Sig.
3	(7-5-2)	1	1641	r-bprop	0,0144	0,0010	Sig.
3	(7-5-8)	13	1314	r-bprop	0,0045	0,0010	Sig.
3	(8-2-3)	14	775	r-bprop	0,0222	0,0009	Sig.
3	(8-2-10)	3	674	r-bprop	0,0138	0,0010	Sig.
3	(8-5-2)	3	1833	r-bprop	0,0067	0,0009	Sig.
3	(8-5-2)	2	79535	bprop	0,0447	0,0010	Sig.
3	(8-9-3)	12	1550	r-bprop	0,0051	0,0009	Sig.
3	(8-9-10)	4	1143	r-bprop	0,0044	0,0010	Sig.
3	(9-3-3)	3	1512	r-bprop	0,0070	0,0010	Sig.
3	(10-2-3)	15	448	r-bprop	0,0224	0,0009	Sig.
3	(10-12-3)	7	1308	r-bprop	0,0038	0,0009	Sig.
3	(10-12-13)	19	602	r-bprop	0,0126	0,0010	Sig.
3	(11-3-1)	2	355	r-bprop	0,0535	0,0009	Sig.
3	(12-2-1)	14	782	r-bprop	0,0494	0,0009	Sig.
3	(12-15-3)	10	1106	r-bprop	0,0044	0,0009	Sig.
3	(12-15-4)	5	708	r-bprop	0,0032	0,0010	Sig.
3	(12-15-14)	1	841	r-bprop	0,0089	0,0010	Sig.
3	(15-12-4)	5	829	r-bprop	0,0037	0,0010	Sig.
3	(18-22-3)	15	965	r-bprop	0,0039	0,0009	Sig.
3	(18-22-15)	7	564	r-bprop	0,0118	0,0010	Sig.
3	(20-15-6)	2	1301	r-bprop	0,0025	0,0009	Sig.
3	(22-18-6)	11	1303	r-bprop	0,0018	0,0010	Sig.
3	(22-18-6)	2	99723	bprop	0,0354	0,0010	Sig.
3	(24-16-8)	17	372	r-bprop	0,0122	0,0009	Sig.
3	(24-16-9)	8	570	r-bprop	0,0035	0,0009	Sig.
3	(24-19-8)	38	827	r-bprop	0,0025	0,0010	Sig.
3	(24-20-10)	12	724	r-bprop	0,0041	0,0010	Sig.
3	(28-32-13)	13	301	r-bprop	0,0118	0,0010	Sig.
4	(12-4-16-9)	5	597	r-bprop	0,0105	0,0010	Sig.
4	(12-14-16-19)	16	599	r-bprop	0,0031	0,0009	Sig.
4	(22-24-16-9)	6	743	r-bprop	0,0027	0,0009	Sig.
4	(28-25-24-20)	13	471	r-bprop	0,0036	0,0008	Sig.

EK 15: Bulanık İlişkileri Belirlemede Kullanılan İleri Beslemeli Geriye Yayımlı Yapay Sinir Ağı Eğitim Sonuçları (Sigmoidal Üyelik Fonksiyonu İçin)

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğrenme Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katmanı Akt. Fonk.
1	1	4	596	r-bprop	0,000644	0,0008	Lin.
1	1	1	207	r-bprop	0,002962	0,0009	Sig.
1	2	3	3048	r-bprop	0,000840	0,0006	Lin.
1	3	2	395	r-bprop	0,000647	0,0008	Lin.
1	4	3	338	r-bprop	0,000651	0,0010	Lin.
1	5	1	344	r-bprop	0,000667	0,0009	Lin.
1	8	5	865	r-bprop	0,000701	0,0009	Lin.
1	9	4	392	r-bprop	0,000716	0,0010	Lin.
1	10	4	371	r-bprop	0,000698	0,0010	Lin.
1	12	5	445	r-bprop	0,000654	0,0007	Lin.
1	15	6	492	r-bprop	0,000693	0,0008	Lin.
1	16	3	412	r-bprop	0,000671	0,0010	Lin.
1	21	5	314	r-bprop	0,000678	0,0007	Lin.
1	24	6	511	r-bprop	0,000685	0,0010	Lin.
1	30	8	447	r-bprop	0,000664	0,0007	Lin.
2	(1-1)	1	576	r-bprop	0,000833	0,0008	Lin.
2	(1-2)	9	3113	r-bprop	0,000742	0,0010	Lin.
2	(1-5)	3	1278	r-bprop	0,000690	0,0008	Lin.
2	(1-14)	9	250	r-bprop	0,000663	0,0007	Lin.
2	(1-18)	9	388	r-bprop	0,000640	0,0008	Lin.
2	(2-2)	7	704	r-bprop	0,000650	0,0009	Lin.
2	(2-10)	5	919	r-bprop	0,000707	0,0007	Lin.
2	(2-13)	8	712	r-bprop	0,000683	0,0010	Lin.
2	(3-3)	10	1089	r-bprop	0,000656	0,0008	Lin.
2	(3-5)	4	684	r-bprop	0,000703	0,0009	Lin.
2	(3-9)	3	987	r-bprop	0,000652	0,0008	Lin.
2	(3-12)	9	503	r-bprop	0,000637	0,0010	Lin.
2	(4-8)	13	461	r-bprop	0,000641	0,0009	Lin.
2	(4-10)	12	487	r-bprop	0,000669	0,0008	Lin.
2	(4-12)	2	545	r-bprop	0,000646	0,0010	Lin.
2	(5-5)	15	670	r-bprop	0,000667	0,0006	Lin.

2	(5-8)	10	328	r-bprop	0,000665	0,0010	Lin.
2	(6-4)	1	299	r-bprop	0,000644	0,0003	Lin.
2	(6-6)	5	501	r-bprop	0,000663	0,0006	Lin.
2	(6-9)	3	380	r-bprop	0,000627	0,0007	Lin.
2	(6-9)	3	65057	bprop	0,001004	0,0010	Lin.
2	(7-3)	1	507	r-bprop	0,000645	0,0010	Lin.
2	(7-8)	15	264	r-bprop	0,000671	0,0010	Lin.
2	(8-4)	4	417	r-bprop	0,000640	0,0006	Lin.
2	(8-7)	7	372	r-bprop	0,000649	0,0008	Lin.
2	(8-8)	4	928	r-bprop	0,000652	0,0008	Lin.
2	(9-3)	12	1156	r-bprop	0,000653	0,0008	Lin.
2	(9-6)	8	597	r-bprop	0,000667	0,0010	Lin.
2	(10-3)	5	293	r-bprop	0,000664	0,0010	Lin.
2	(10-5)	2	1061	r-bprop	0,000632	0,0009	Lin.
2	(10-5)	4	50587	bprop	0,000879	0,0010	Lin.
2	(10-12)	2	611	r-bprop	0,000653	0,0009	Lin.
2	(11-4)	9	406	r-bprop	0,000694	0,0007	Lin.
2	(12-2)	14	355	r-bprop	0,000642	0,0005	Lin.
2	(14-1)	11	4291	r-bprop	0,000697	0,0010	Lin.
2	(14-12)	17	441	r-bprop	0,000653	0,0004	Lin.
2	(18-1)	2	346	r-bprop	0,000703	0,0006	Lin.
2	(18-10)	9	265	r-bprop	0,000648	0,0010	Lin.
2	(18-18)	4	262	r-bprop	0,000650	0,0008	Lin.
2	(24-8)	6	309	r-bprop	0,000632	0,0009	Lin.
2	(24-16)	24	459	r-bprop	0,000641	0,0010	Lin.
2	(25-25)	15	288	r-bprop	0,000641	0,0007	Lin.
2	(32-9)	4	408	r-bprop	0,000641	0,0008	Lin.
2	(32-32)	24	256	r-bprop	0,000658	0,0007	Lin.
3	(1-10-4)	3	304	r-bprop	0,000643	0,0005	Lin.
3	(1-1-1)	5	42	r-bprop	0,008825	0,0008	Lin.
3	(1-3-1)	13	4397	r-bprop	0,001167	0,0009	Lin.
3	(1-5-1)	2	58	r-bprop	0,008558	0,0008	Lin.
3	(1-5-2)	9	2287	r-bprop	0,000881	0,0009	Lin.
3	(1-8-3)	15	325	r-bprop	0,000651	0,0007	Lin.
3	(1-12-1)	2	294	r-bprop	0,000680	0,0009	Lin.
3	(2-1-7)	11	1342	r-bprop	0,000782	0,0009	Lin.
3	(2-2-11)	12	791	r-bprop	0,000644	0,0008	Lin.
3	(2-2-6)	10	660	r-bprop	0,000662	0,0006	Lin.
3	(2-3-8)	1	387	r-bprop	0,000703	0,0007	Lin.
3	(2-4-6)	13	414	r-bprop	0,000711	0,0005	Lin.
3	(2-5-3)	3	595	r-bprop	0,000662	0,0007	Lin.

3	(2-5-5)	12	434	r-bprop	0,000660	0,0009	Lin.
3	(2-6-7)	3	572	r-bprop	0,000647	0,0009	Lin.
3	(2-10-3)	11	354	r-bprop	0,000711	0,0008	Lin.
3	(3-4-3)	2	480	r-bprop	0,000648	0,0006	Lin.
3	(3-4-8)	7	486	r-bprop	0,000663	0,0009	Lin.
3	(4-5-3)	2	366	r-bprop	0,000660	0,0008	Lin.
3	(4-9-2)	1	1122	r-bprop	0,000681	0,0008	Lin.
3	(5-3-3)	12	454	r-bprop	0,000695	0,0008	Lin.
3	(5-5-5)	6	348	r-bprop	0,000640	0,0009	Lin.
3	(6-3-6)	3	946	r-bprop	0,000680	0,0010	Lin.
3	(6-9-6)	6	437	r-bprop	0,000637	0,0009	Lin.
3	(6-12-24)	17	595	r-bprop	0,000652	0,0009	Lin.
3	(7-6-2)	1	1398	r-bprop	0,000720	0,0009	Lin.
3	(8-4-3)	11	254	r-bprop	0,000612	0,0009	Lin.
3	(8-9-4)	7	441	r-bprop	0,000680	0,0010	Lin.
3	(9-3-3)	11	1200	r-bprop	0,000657	0,0009	Lin.
3	(10-2-2)	7	476	r-bprop	0,000666	0,0009	Lin.
3	(11-2-2)	12	1439	r-bprop	0,000851	0,0010	Lin.
3	(12-2-1)	7	4957	r-bprop	0,000856	0,0010	Lin.
3	(12-3-8)	11	394	r-bprop	0,000651	0,0008	Lin.
3	(12-8-10)	3	333	r-bprop	0,000646	0,0007	Lin.
3	(16-12-10)	18	392	r-bprop	0,000645	0,0009	Lin.
3	(16-16-9)	10	290	r-bprop	0,000628	0,0006	Lin.
3	(17-17-17)	22	290	r-bprop	0,000643	0,0009	Lin.
3	(20-16-4)	25	258	r-bprop	0,000630	0,0010	Lin.
3	(20-18-16)	40	363	r-bprop	0,000642	0,0008	Lin.
3	(24-9-24)	17	359	r-bprop	0,000632	0,0009	Lin.
3	(24-12-6)	13	256	r-bprop	0,000637	0,0008	Lin.
3	(24-18-12)	14	336	r-bprop	0,000634	0,0008	Lin.
3	(24-24-8)	20	371	r-bprop	0,000649	0,0006	Lin.
3	(24-24-24)	1	264	r-bprop	0,000636	0,0007	Lin.
3	(24-25-28)	29	484	r-bprop	0,000641	0,0007	Lin.
3	(25-16-9)	24	344	r-bprop	0,000631	0,0008	Lin.
3	(30-12-24)	9	202	r-bprop	0,000645	0,0007	Lin.
3	(32-16-8)	3	306	r-bprop	0,000636	0,0008	Lin.
4	(1-1-1-1)	2	38	r-bprop	0,008825	0,0005	Lin.
4	(3-6-12-24)	33	396	r-bprop	0,000640	0,0009	Lin.
4	(5-5-5-5)	4	264	r-bprop	0,000609	0,0009	Lin.
4	(5-10-10-5)	11	380	r-bprop	0,000627	0,0010	Lin.
4	(6-8-9-4)	9	401	r-bprop	0,000641	0,0010	Lin.
4	(8-10-9-8)	11	342	r-bprop	0,000628	0,0005	Lin.

4	(10-10-10-10)	6	299	r-bprop	0,000639	0,0009	Lin.
4	(16-8-4-2)	29	863	r-bprop	0,000651	0,0010	Lin.
4	(16-8-8-16)	18	284	r-bprop	0,000630	0,0005	Lin.
4	(20-18-18-16)	25	334	r-bprop	0,000629	0,0009	Lin.
4	(24-12-6-3)	11	9367	r-bprop	0,000529	0,0010	Lin.
4	(24-12-6-3)	3	26	bprop	0,008419	0,0010	Lin.
4	(24-12-6-6)	7	499	r-bprop	0,000616	0,0010	Lin.
4	(24-12-12-3)	18	477	r-bprop	0,000594	0,0008	Lin.
4	(24-18-16-9)	27	237	r-bprop	0,000638	0,0005	Lin.
4	(24-24-24-24)	15	217	r-bprop	0,000639	0,0009	Lin.
4	(25-16-4-8)	16	314	r-bprop	0,000627	0,0010	Lin.
4	(25-16-8-4)	5	366	r-bprop	0,000563	0,0009	Lin.
4	(30-16-8-4)	35	737	r-bprop	0,000580	0,0009	Lin.
4	(32-16-8-4)	12	598	r-bprop	0,000631	0,0006	Lin.
4	(32-16-8-4)	30	195	r-bprop	0,000652	0,0010	Sig.
4	(32-16-9-9)	16	412	r-bprop	0,000570	0,0010	Lin.
4	(32-32-32-32)	24	253	r-bprop	0,000636	0,0009	Lin.

EK 16: Bulanık İlişkileri Belirlemede Kullanılan İleri Beslemeli Geriye Yayılımlı Yapay Sinir Ağı Eğitim Sonuçları (Çan Şekli Üyelik Fonksiyonu İçin)

Gizli Katman Sayısı	Gizli Nöron Sayısı	Öğrenme Sayısı (rep.)	Döngü (Adım) Sayısı	Alg.	Hata	Ulaşılan Eşik	Çıktı Katmanı Akt. Fonk.
1	1	5	6905	r-bprop	0,0057	0,0010	Lin.
1	1	5	712	r-bprop	0,0055	0,0009	Sig.
1	2	1	8508	r-bprop	0,0055	0,0009	Lin.
1	2	2	515	r-bprop	0,0057	0,0010	Sig.
1	3	10	869	r-bprop	0,0050	0,0010	Lin.
1	3	1	405	r-bprop	0,0060	0,0009	Sig.
1	4	4	1846	r-bprop	0,0050	0,0009	Lin.
1	4	10	253	r-bprop	0,0059	0,0009	Sig.
1	5	7	527	r-bprop	0,0052	0,0009	Sig.
1	5	4	408	r-bprop	0,0052	0,0010	Lin.
1	7	4	1818	r-bprop	0,0048	0,0010	Lin.
1	7	8	634	r-bprop	0,0057	0,0010	Sig.
1	10	12	982	r-bprop	0,0047	0,0009	Lin.
1	10	2	523	r-bprop	0,0056	0,0009	Sig.
1	12	9	1879	r-bprop	0,0055	0,0008	Lin.
1	12	1	421	r-bprop	0,0051	0,0010	Sig.
1	14	20	1487	r-bprop	0,0044	0,0008	Lin.
1	14	20	255	r-bprop	0,0053	0,0007	Sig.
1	16	22	1975	r-bprop	0,0046	0,0008	Lin.
1	16	14	229	r-bprop	0,0055	0,0010	Sig.
1	20	27	1402	r-bprop	0,0051	0,0010	Lin.
1	20	9	150	r-bprop	0,0054	0,0007	Sig.
1	26	10	1312	r-bprop	0,0050	0,0010	Lin.
1	26	36	180	r-bprop	0,0047	0,0008	Sig.
1	40	5	1898	r-bprop	0,0043	0,0008	Lin.
1	40	3	422	r-bprop	0,0058	0,0009	Sig.
2	(10-2)	13	4703	r-bprop	0,0051	0,0010	Lin.
2	(10-5)	2	1286	r-bprop	0,0043	0,0005	Lin.
2	(1-1)	10	3581	r-bprop	0,0053	0,0009	Lin.
2	(1-1)	8	229	r-bprop	0,0063	0,0009	Sig.
2	(1-12)	4	1364	r-bprop	0,0053	0,0010	Lin.
2	(1-2)	6	5089	r-bprop	0,0058	0,0010	Lin.
2	(1-2)	7	283	r-bprop	0,0065	0,0009	Sig.
2	(12-12)	8	1233	r-bprop	0,0042	0,0007	Lin.

2	(12-3)	12	1236	r-bprop	0,0040	0,0009	Lin.
2	(12-4)	4	1090	r-bprop	0,0062	0,0010	Lin.
2	(12-7)	1	971	r-bprop	0,0042	0,0010	Lin.
2	(1-3)	8	1885	r-bprop	0,0060	0,0009	Lin.
2	(1-3)	5	532	r-bprop	0,0058	0,0010	Sig.
2	(13-12)	8	902	r-bprop	0,0046	0,0010	Lin.
2	(13-16)	12	1102	r-bprop	0,0049	0,0010	Lin.
2	(13-2)	12	1497	r-bprop	0,0045	0,0010	Lin.
2	(1-5)	9	768	r-bprop	0,0056	0,0009	Lin.
2	(15-15)	5	293	r-bprop	0,0044	0,0005	Lin.
2	(15-18)	16	911	r-bprop	0,0045	0,0009	Lin.
2	(15-3)	9	1182	r-bprop	0,0067	0,0009	Lin.
2	(18-3)	17	2401	r-bprop	0,0056	0,0010	Lin.
2	(19-16)	22	971	r-bprop	0,0046	0,0010	Lin.
2	(20-3)	10	1729	r-bprop	0,0058	0,0007	Lin.
2	(20-5)	14	1144	r-bprop	0,0057	0,0007	Lin.
2	(2-1)	3	5050	r-bprop	0,0053	0,0010	Lin.
2	(2-1)	10	589	r-bprop	0,0059	0,0008	Sig.
2	(2-13)	6	1569	r-bprop	0,0052	0,0009	Lin.
2	(2-2)	7	1792	r-bprop	0,0053	0,0010	Lin.
2	(2-2)	1	382	r-bprop	0,0057	0,0010	Sig.
2	(22-15)	8	818	r-bprop	0,0046	0,0010	Lin.
2	(24-24)	11	1019	r-bprop	0,0040	0,0010	Lin.
2	(24-27)	25	966	r-bprop	0,0042	0,0009	Lin.
2	(24-6)	13	922	r-bprop	0,0057	0,0007	Lin.
2	(2-6)	8	2341	r-bprop	0,0049	0,0009	Lin.
2	(28-25)	16	2160	r-bprop	0,0038	0,0010	Lin.
2	(30-30)	26	920	r-bprop	0,0038	0,0007	Lin.
2	(3-12)	9	1434	r-bprop	0,0054	0,0008	Lin.
2	(3-3)	8	2649	r-bprop	0,0049	0,0009	Lin.
2	(3-7)	3	926	r-bprop	0,0047	0,0009	Lin.
2	(4-11)	12	980	r-bprop	0,0056	0,0007	Lin.
2	(4-16)	2	863	r-bprop	0,0066	0,0010	Lin.
2	(4-3)	12	1586	r-bprop	0,0049	0,0009	Lin.
2	(4-6)	12	1597	r-bprop	0,0050	0,0010	Lin.
2	(4-6)	11	304	r-bprop	0,0057	0,0008	Sig.
2	(4-8)	8	1421	r-bprop	0,0051	0,0006	Lin.
2	(5-3)	10	1915	r-bprop	0,0047	0,0010	Lin.
2	(5-9)	12	897	r-bprop	0,0050	0,0009	Lin.
2	(6-6)	15	1178	r-bprop	0,0049	0,0009	Lin.
2	(6-9)	8	1874	r-bprop	0,0054	0,0008	Lin.
2	(7-2)	5	7842	r-bprop	0,0047	0,0010	Lin.
2	(7-8)	10	1386	r-bprop	0,0048	0,0009	Lin.

2	(8-10)	1	1776	r-bprop	0,0050	0,0008	Lin.
2	(8-3)	8	754	r-bprop	0,0047	0,0010	Lin.
2	(8-7)	9	1681	r-bprop	0,0046	0,0010	Lin.
2	(9-3)	12	965	r-bprop	0,0040	0,0009	Lin.
2	(9-6)	5	773	r-bprop	0,0041	0,0009	Lin.
3	(10-10-10)	2	1207	r-bprop	0,0048	0,0010	Lin.
3	(10-2-3)	7	3854	r-bprop	0,0050	0,0010	Lin.
3	(1-1-1)	4	74	r-bprop	0,0387	0,0009	Lin.
3	(1-1-12)	7	1071	r-bprop	0,0059	0,0006	Lin.
3	(11-1-2)	14	10123	r-bprop	0,0053	0,0010	Lin.
3	(1-11-3)	2	482	r-bprop	0,0055	0,0009	Lin.
3	(11-2-1)	3	9874	r-bprop	0,0037	0,0010	Lin.
3	(11-2-1)	2	49	bprop	0,0396	0,0008	Lin.
3	(11-2-2)	9	3416	r-bprop	0,0039	0,0010	Lin.
3	(11-2-2)	2	48741	bprop	0,0058	0,0010	Lin.
3	(12-1-2)	4	13810	r-bprop	0,0050	0,0009	Lin.
3	(12-2-1)	8	9706	r-bprop	0,0039	0,0010	Lin.
3	(12-2-1)	4	93382	bprop	0,0058	0,0010	Lin.
3	(1-2-9)	10	1289	r-bprop	0,0057	0,0009	Lin.
3	(14-16-3)	20	1060	r-bprop	0,0055	0,0009	Lin.
3	(15-13-12)	14	1355	r-bprop	0,0038	0,0009	Lin.
3	(1-5-9)	1	952	r-bprop	0,0061	0,0009	Lin.
3	(16-15-3)	15	1051	r-bprop	0,0058	0,0006	Lin.
3	(16-16-3)	1	915	r-bprop	0,0054	0,0010	Lin.
3	(16-20-24)	2	1095	r-bprop	0,0043	0,0008	Lin.
3	(18-18-18)	9	1209	r-bprop	0,0042	0,0009	Lin.
3	(1-8-4)	9	2007	r-bprop	0,0049	0,0010	Lin.
3	(20-18-16)	1	949	r-bprop	0,0041	0,0008	Lin.
3	(20-24-16)	24	1510	r-bprop	0,0047	0,0009	Lin.
3	(20-24-22)	29	884	r-bprop	0,0051	0,0009	Lin.
3	(20-24-4)	19	1206	r-bprop	0,0055	0,0010	Lin.
3	(20-4-14)	20	744	r-bprop	0,0055	0,0008	Lin.
3	(2-10-3)	1	4631	r-bprop	0,0053	0,0010	Lin.
3	(2-2-10)	10	614	r-bprop	0,0055	0,0008	Lin.
3	(2-3-2)	1	944	r-bprop	0,0050	0,0008	Lin.
3	(2-3-6)	6	2142	r-bprop	0,0054	0,0010	Lin.
3	(24-16-9)	5	1446	r-bprop	0,0033	0,0007	Lin.
3	(24-18-10)	13	954	r-bprop	0,0043	0,0009	Lin.
3	(24-18-12)	8	960	r-bprop	0,0038	0,0007	Lin.
3	(24-18-16)	9	817	r-bprop	0,0044	0,0006	Lin.
3	(24-20-16)	7	1357	r-bprop	0,0036	0,0006	Lin.
3	(24-22-18)	9	640	r-bprop	0,0041	0,0009	Lin.
3	(24-24-12)	1	1382	r-bprop	0,0033	0,0009	Lin.

3	(24-9-16)	14	732	r-bprop	0,0043	0,0010	Lin.
3	(25-20-18)	6	1336	r-bprop	0,0036	0,0009	Lin.
3	(25-24-22)	23	1280	r-bprop	0,0037	0,0009	Lin.
3	(25-25-25)	33	1360	r-bprop	0,0041	0,0008	Lin.
3	(25-25-25)	14	140	r-bprop	0,0052	0,0010	Sig.
3	(28-24-12)	12	1118	r-bprop	0,0036	0,0010	Lin.
3	(30-32-28)	43	901	r-bprop	0,0037	0,0007	Lin.
3	(3-10-2)	10	502	r-bprop	0,0052	0,0010	Lin.
3	(3-2-7)	2	348	r-bprop	0,0056	0,0007	Lin.
3	(4-10-1)	6	6320	r-bprop	0,0056	0,0010	Lin.
3	(4-2-6)	1	1153	r-bprop	0,0055	0,0009	Lin.
3	(4-3-4)	9	1012	r-bprop	0,0049	0,0008	Lin.
3	(4-3-8)	1	2060	r-bprop	0,0053	0,0009	Lin.
3	(4-4-4)	12	2417	r-bprop	0,0045	0,0010	Lin.
3	(4-4-7)	13	2127	r-bprop	0,0042	0,0010	Lin.
3	(4-5-3)	3	3338	r-bprop	0,0048	0,0010	Lin.
3	(4-5-6)	11	1001	r-bprop	0,0044	0,0004	Lin.
3	(4-6-3)	1	1061	r-bprop	0,0052	0,0010	Lin.
3	(4-7-4)	6	2255	r-bprop	0,0049	0,0009	Lin.
3	(4-9-2)	11	2970	r-bprop	0,0052	0,0009	Lin.
3	(5-3-3)	14	1363	r-bprop	0,0057	0,0009	Lin.
3	(5-5-5)	2	1005	r-bprop	0,0051	0,0010	Lin.
3	(5-6-4)	5	2146	r-bprop	0,0052	0,0010	Lin.
3	(6-3-5)	3	1325	r-bprop	0,0047	0,0007	Lin.
3	(6-6-3)	14	1111	r-bprop	0,0046	0,0010	Lin.
3	(7-3-5)	3	1646	r-bprop	0,0050	0,0009	Lin.
3	(7-5-8)	7	1411	r-bprop	0,0047	0,0006	Lin.
3	(8-4-3)	8	1106	r-bprop	0,0049	0,0010	Lin.
3	(9-3-3)	4	3849	r-bprop	0,0048	0,0008	Lin.
3	(9-5-1)	11	14459	r-bprop	0,0041	0,0010	Lin.
4	(12-10-8-5)	42	2821	r-bprop	0,0040	0,0009	Lin.
4	(18-14-22-16)	16	1215	r-bprop	0,0050	0,0009	Lin.
4	(20-24-22-20)	1	959	r-bprop	0,0049	0,0009	Lin.
4	(20-4-22-3)	39	926	r-bprop	0,0058	0,0009	Lin.
4	(22-20-18-18)	6	939	r-bprop	0,0024	0,0010	Lin.
4	(24-16-18-9)	12	1892	r-bprop	0,0022	0,0009	Lin.
4	(24-18-16-9)	11	926	r-bprop	0,0038	0,0010	Lin.
4	(24-20-18-16)	5	1227	r-bprop	0,0031	0,0009	Lin.
4	(24-24-24-24)	16	944	r-bprop	0,0035	0,0009	Lin.
4	(28-25-24-20)	14	984	r-bprop	0,0032	0,0009	Lin.

EK 17: Gaussian Fonksiyonu Üyelik Değerleri için 3 Gizli Katmanlı (22-18-6) Yapay Sinir Ağı Eğitim Sonuçları

	g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA)^2	MYH	
1	0.039	0.582	0.409	0.21	0.012	0.033	0.518	0.47	0.208	0.018	0.036	0.516	0.466	0.211	0.022	0.0038	0.00187	0.00421	0.00263	0.00358	0.003220891	1.03741E-05	5.91431	
2	0.011	0.361	0.62	0.248	0.013	0.017	0.325	0.658	0.242	0.011	0.009	0.329	0.657	0.246	0.015	0.00788	0.00322	0.00087	0.00348	0.004	0.003890817	1.51385E-05	22.7428	
3	0.009	0.329	0.657	0.246	0.015	0.02	0.369	0.611	0.249	0.013	0.019	0.365	0.611	0.242	0.02	0.00105	0.00362	0.00023	0.00753	0.00614	0.003711461	1.37749E-05	8.20483	
4	0.011	0.173	0.691	0.357	0.019	0.005	0.195	0.601	0.418	0.032	0.011	0.199	0.603	0.421	0.015	0.00579	0.00413	0.00224	0.00333	0.01728	0.006555221	4.29709E-05	34.994	
5	0.025	0.437	0.528	0.243	0.019	0.02	0.353	0.606	0.26	0.015	0.011	0.361	0.62	0.248	0.013	0.00866	0.00854	0.01452	0.01225	0.00163	0.009119141	8.31587E-05	20.0854	
6	0.019	0.365	0.611	0.242	0.02	0.03	0.429	0.519	0.26	0.018	0.033	0.428	0.511	0.266	0.02	0.00321	0.00053	0.00788	0.00627	0.00263	0.004104383	1.6846E-05	5.31704	
7	0.033	0.428	0.511	0.266	0.02	0.025	0.427	0.48	0.294	0.024	0.034	0.422	0.476	0.3	0.023	0.00894	0.00419	0.00459	0.00525	0.00099	0.004793319	2.29759E-05	6.81699	
8	0.057	0.641	0.356	0.205	0.02	0.044	0.588	0.404	0.206	0.021	0.039	0.582	0.409	0.21	0.012	0.00504	0.00607	0.00531	0.00323	0.00921	0.005770665	3.33006E-05	18.8962	
9	0.036	0.516	0.466	0.211	0.022	0.022	0.438	0.53	0.244	0.018	0.025	0.437	0.528	0.243	0.019	0.00344	0.00062	0.00239	0.00147	0.00122	0.00182572	3.33323E-06	4.24268	
10	0.172	0.744	0.175	0.149	0.022	0.115	0.713	0.225	0.159	0.027	0.116	0.719	0.232	0.156	0.042	0.00103	0.00619	0.00702	0.00307	0.01492	0.006445611	4.15459E-05	8.52957	
11	0.034	0.422	0.476	0.3	0.023	0.019	0.371	0.49	0.34	0.029	0.022	0.371	0.491	0.337	0.028	0.00373	1.1E-05	0.00054	0.00288	0.00184	0.001801684	3.24607E-06	4.86364	
12	0.078	0.684	0.292	0.185	0.024	0.059	0.642	0.347	0.199	0.024	0.057	0.641	0.336	0.205	0.02	0.00216	0.00092	0.01129	0.00601	0.00305	0.004684157	2.19413E-05	5.01972	
13	0.243	0.75	0.098	0.137	0.025	0.173	0.745	0.176	0.152	0.029	0.172	0.744	0.175	0.149	0.022	0.00136	0.00046	0.00093	0.0026	0.00759	0.002588443	6.70004E-06	7.63218	
14	0.022	0.371	0.491	0.337	0.028	0.013	0.282	0.536	0.376	0.03	0.009	0.286	0.539	0.379	0.031	0.00423	0.00038	0.00291	0.00334	0.00054	0.002964564	8.78864E-06	10.2783	
15	0.009	0.286	0.539	0.379	0.031	0.005	0.196	0.579	0.42	0.034	0.004	0.197	0.581	0.422	0.044	0.00195	0.00141	0.00148	0.00166	0.0103	0.003361465	1.12994E-05	16.0605	
16	0.116	0.719	0.232	0.156	0.042	0.075	0.683	0.289	0.191	0.027	0.078	0.684	0.292	0.185	0.024	0.00312	0.00103	0.000396	0.00541	0.00214	0.003130219	9.79827E-06	3.43236	
17	0.004	0.197	0.581	0.422	0.044	0.002	0.141	0.586	0.504	0.052	0.001	0.118	0.58	0.501	0.055	0.00065	0.02379	0.00653	0.0033	0.00385	0.007621418	5.8086E-05	15.4202	
18	0.001	0.118	0.58	0.501	0.055	0.021	0.156	0.684	0.359	0.022	0.011	0.173	0.691	0.357	0.019	0.01018	0.01707	0.00728	0.00183	0.00277	0.007825694	6.12415E-05	24.0458	
																					HKT	0,00046452		
																						HKO	2,58067E-05	
																						HKOK	0,005080027	
																						OMYH (%)	12,36091992	

EK 18: Gaussian Fonksiyonu Üyelik Değerleri için 2 Gizli Katmanlı (9-3) Yapay Sinir Ağı Eğitim Sonuçları

	g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA)^2	MYH	
1	0.039	0.582	0.409	0.21	0.012	0.03	0.508	0.489	0.215	0.016	0.036	0.516	0.466	0.211	0.022	0.00647	0.00726	0.02341	0.00374	0.00591	0.009359376	8.75979E-05	10.68251	
2	0.011	0.361	0.62	0.248	0.013	0.014	0.352	0.652	0.252	0.012	0.009	0.329	0.657	0.246	0.015	0.0044	0.02346	0.00537	0.00639	0.00328	0.008580631	7.36272E-05	15.87656	
3	0.009	0.329	0.657	0.246	0.015	0.015	0.367	0.619	0.255	0.014	0.019	0.365	0.611	0.242	0.02	0.00399	0.00195	0.00837	0.01338	0.00581	0.00670108	4.49045E-05	11.56491	
4	0.011	0.173	0.691	0.357	0.019	0.01	0.211	0.597	0.412	0.032	0.011	0.199	0.603	0.421	0.015	0.00091	0.01195	0.00584	0.00883	0.01769	0.009041957	8.1757E-05	27.52713	
5	0.025	0.437	0.528	0.243	0.019	0.017	0.376	0.594	0.26	0.015	0.011	0.361	0.62	0.248	0.013	0.00567	0.01447	0.02606	0.0113	0.00193	0.011888587	0.000141338	15.76179	
6	0.019	0.365	0.611	0.242	0.02	0.02	0.399	0.539	0.266	0.019	0.033	0.428	0.511	0.266	0.02	0.01321	0.02926	0.02788	0.00033	0.00182	0.014499048	0.000210222	12.1836	
7	0.033	0.428	0.511	0.266	0.02	0.023	0.411	0.485	0.28	0.023	0.034	0.422	0.476	0.3	0.023	0.01078	0.01128	0.00881	0.02015	0.00017	0.010235892	0.000104773	8.691038	
8	0.057	0.641	0.336	0.205	0.02	0.045	0.578	0.387	0.21	0.021	0.039	0.582	0.409	0.21	0.012	0.00584	0.0044	0.02234	0.00064	0.0087	0.008383481	7.02828E-05	18.96958	
9	0.036	0.516	0.466	0.211	0.022	0.023	0.454	0.536	0.231	0.015	0.025	0.437	0.528	0.243	0.019	0.00154	0.01652	0.00838	0.01219	0.00432	0.008589032	7.37715E-05	7.752449	
10	0.172	0.744	0.175	0.149	0.022	0.118	0.724	0.237	0.167	0.026	0.116	0.719	0.232	0.156	0.042	0.00192	0.00057	0.00426	0.01076	0.01569	0.007664334	5.8742E-05	9.785732	
11	0.034	0.422	0.476	0.3	0.023	0.021	0.368	0.475	0.316	0.029	0.022	0.371	0.491	0.337	0.028	0.00106	0.00244	0.01595	0.02054	0.00165	0.008327728	6.9351E-05	4.145701	
12	0.078	0.684	0.292	0.185	0.024	0.06	0.633	0.328	0.199	0.023	0.057	0.641	0.336	0.205	0.02	0.00336	0.00788	0.00827	0.00677	0.00244	0.00574209	3.29716E-05	4.958914	
13	0.243	0.75	0.098	0.137	0.025	0.17	0.766	0.188	0.155	0.03	0.172	0.744	0.175	0.149	0.022	0.00148	0.02186	0.01236	0.00644	0.00789	0.010005778	0.000100116	10.31865	
14	0.022	0.371	0.491	0.337	0.028	0.014	0.27	0.524	0.382	0.035	0.009	0.286	0.539	0.379	0.031	0.00521	0.01595	0.01467	0.00278	0.00403	0.008528407	7.27337E-05	15.97824	
15	0.009	0.286	0.539	0.379	0.031	0.01	0.193	0.574	0.449	0.041	0.004	0.197	0.581	0.422	0.044	0.00606	0.00429	0.00693	0.02694	0.00353	0.009550237	9.1207E-05	38.18177	
16	0.116	0.719	0.232	0.156	0.042	0.079	0.671	0.291	0.184	0.024	0.078	0.684	0.292	0.185	0.024	0.00097	0.01346	0.01008	0.00068	0.00068	0.003372404	1.13731E-05	1.348336	
17	0.004	0.197	0.581	0.422	0.044	0.008	0.15	0.602	0.494	0.046	0.001	0.118	0.58	0.501	0.055	0.00633	0.03268	0.02196	0.00667	0.00919	0.015365105	0.000236086	103.9782	
18	0.001	0.118	0.58	0.501	0.055	0.017	0.149	0.681	0.353	0.022	0.011	0.173	0.691	0.357	0.019	0.00591	0.02426	0.00959	0.00479	0.00304	0.009520617	9.06422E-05	17.49851	
																						HKT	0,001651498	
																						HKO	9,17499E-05	
																						HKOK	0,009578616	
																						OMYH (%)	18,62242182	

EK 19: Gaussian Fonksiyonu Üyelik Değerleri için 3 Gizli Katmanlı (8-5-2) Yapay Sinir Ağı Eğitim Sonuçları

	g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA)^2	OMYH	
1	0.039	0.582	0.409	0.21	0.012	0.027	0.517	0.473	0.207	0.016	0.036	0.516	0.466	0.211	0.022	0.00958	0.00109	0.00727	0.00394	0.00512	0.005399798	2.91578E-05	10.74155	
2	0.011	0.361	0.62	0.248	0.013	0.008	0.334	0.662	0.245	0.012	0.009	0.329	0.657	0.246	0.015	0.00088	0.00097	0.00556	0.00086	0.00298	0.003051315	9.31053E-06	6.311626	
3	0.009	0.329	0.657	0.246	0.015	0.012	0.366	0.602	0.251	0.015	0.019	0.365	0.611	0.242	0.02	0.00716	0.00068	0.0088	0.00891	0.0043	0.005971761	3.56619E-05	12.86705	
4	0.011	0.173	0.691	0.357	0.019	0.011	0.204	0.601	0.418	0.033	0.011	0.199	0.603	0.421	0.015	0.00071	0.00464	0.00258	0.00347	0.01864	0.006007764	3.60932E-05	27.35133	
5	0.025	0.437	0.528	0.243	0.019	0.013	0.362	0.594	0.258	0.016	0.011	0.361	0.62	0.248	0.013	0.00175	0.00047	0.02613	0.00962	0.00291	0.008176613	6.6857E-05	9.215656	
6	0.019	0.565	0.611	0.242	0.02	0.02	0.42	0.515	0.253	0.019	0.033	0.428	0.511	0.266	0.02	0.0129	0.00875	0.00423	0.01313	0.00104	0.008009436	6.41511E-05	10.31096	
7	0.033	0.428	0.511	0.266	0.02	0.022	0.39	0.499	0.283	0.024	0.034	0.422	0.476	0.3	0.023	0.01216	0.03248	0.02344	0.01629	0.00034	0.016942123	0.000287036	11.00847	
8	0.057	0.641	0.336	0.205	0.02	0.044	0.575	0.39	0.206	0.02	0.039	0.582	0.409	0.21	0.012	0.00444	0.00686	0.01897	0.00377	0.00839	0.008484762	7.19912E-05	17.95963	
9	0.036	0.516	0.466	0.211	0.022	0.019	0.453	0.528	0.224	0.016	0.025	0.437	0.528	0.243	0.019	0.00566	0.01563	3.1E-05	0.01863	0.00358	0.008707841	7.58265E-05	10.4637	
10	0.172	0.744	0.175	0.149	0.022	0.12	0.736	0.237	0.172	0.026	0.116	0.719	0.232	0.156	0.042	0.00413	0.01717	0.00486	0.01598	0.01598	0.011621819	0.000135067	11.34663	
11	0.034	0.422	0.476	0.3	0.023	0.026	0.369	0.465	0.319	0.031	0.022	0.371	0.491	0.337	0.028	0.00409	0.00186	0.02614	0.01757	0.00306	0.010544802	4.05189E-05	8.083447	
12	0.078	0.684	0.292	0.185	0.024	0.059	0.629	0.341	0.194	0.021	0.057	0.641	0.336	0.205	0.02	0.00233	0.01183	0.00495	0.01175	0.00097	0.006565445	0.000111193	3.571373	
13	0.243	0.75	0.098	0.137	0.025	0.169	0.764	0.192	0.176	0.031	0.172	0.744	0.175	0.149	0.022	0.00282	0.01997	0.01688	0.02712	0.00946	0.015248887	0.000232529	15.16889	
14	0.022	0.371	0.491	0.337	0.028	0.017	0.268	0.535	0.379	0.033	0.009	0.286	0.539	0.379	0.031	0.00811	0.01832	0.00401	0.00085	0.00258	0.006775119	4.59022E-05	21.1467	
15	0.009	0.286	0.539	0.379	0.031	0.012	0.2	0.588	0.431	0.036	0.004	0.197	0.581	0.422	0.044	0.00869	0.00355	0.00717	0.00886	0.008	0.00725312	5.26077E-05	54.26899	
16	0.116	0.719	0.232	0.156	0.042	0.082	0.678	0.291	0.185	0.023	0.078	0.684	0.292	0.185	0.024	0.00405	0.00628	0.00185	0.0001	0.00089	0.002633565	6.93566E-06	2.082194	
17	0.004	0.197	0.581	0.422	0.044	0.012	0.161	0.593	0.489	0.045	0.001	0.118	0.58	0.501	0.055	0.01017	0.04377	0.01352	0.01209	0.00997	0.01790356	0.000320537	163.0561	
18	0.001	0.118	0.58	0.501	0.055	0.006	0.177	0.703	0.389	0.022	0.011	0.173	0.691	0.357	0.019	0.0049	0.0033	0.01204	0.03138	0.00312	0.010949542	0.000119892	14.84506	
																						HKT	0,001741267	
																						HKO	9,67371E-05	
																						HKOK	0,009835501	
																						OMYH (%)	22,76663281	

EK 21: Sigmoidal Fonksiyonu Üyelik Değerleri için 2 Gizli Katmanlı (6-9) Yapay Sinir Ağı Eğitim Sonuçları

	g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA)^2	OMYH	
1	0.49	0.526	0.481	0.362	0.204	0.483	0.523	0.484	0.368	0.209	0.481	0.522	0.483	0.368	0.211	0.00149	0.00094	0.00087	0.00025	0.00229	0.001168053	1.36435E-06	0.36453	
2	0.481	0.522	0.483	0.368	0.211	0.473	0.519	0.485	0.373	0.217	0.47	0.517	0.484	0.375	0.221	0.00326	0.00179	0.00021	0.00199	0.00456	0.002360969	5.57417E-06	0.734624	
3	0.47	0.517	0.484	0.375	0.221	0.461	0.514	0.486	0.38	0.227	0.464	0.514	0.485	0.379	0.226	0.00227	0.00033	0.00053	0.001	0.00099	0.00102454	1.04968E-06	0.272833	
4	0.464	0.514	0.485	0.379	0.226	0.456	0.511	0.486	0.384	0.232	0.458	0.512	0.486	0.383	0.231	0.00212	0.00053	0.00042	0.00077	0.00109	0.000985398	9.71009E-07	0.26495	
5	0.458	0.512	0.486	0.383	0.231	0.451	0.509	0.487	0.387	0.236	0.454	0.51	0.487	0.386	0.234	0.00272	0.00092	0.00042	0.00121	0.00231	0.001517176	2.30182E-06	0.4336	
6	0.454	0.51	0.487	0.386	0.234	0.448	0.507	0.488	0.389	0.24	0.449	0.508	0.487	0.389	0.239	0.00145	0.00058	0.00022	0.00028	0.00095	0.000696584	4.85229E-07	0.190565	
7	0.449	0.508	0.487	0.389	0.239	0.443	0.505	0.488	0.392	0.244	0.443	0.505	0.488	0.394	0.245	0.00085	0.00046	0.00021	0.00129	0.00093	0.000748425	5.60141E-07	0.206789	
8	0.443	0.505	0.488	0.394	0.245	0.438	0.503	0.489	0.396	0.249	0.437	0.503	0.489	0.397	0.249	0.00056	0.00019	0.00022	0.00083	0.00012	0.000384372	1.47742E-07	0.093844	
9	0.441	0.504	0.489	0.395	0.247	0.436	0.502	0.489	0.398	0.251	0.438	0.503	0.489	0.397	0.249	0.00223	0.00081	9.3E-05	0.00077	0.00148	0.001077427	1.16085E-06	0.295574	
10	0.438	0.503	0.489	0.397	0.249	0.434	0.501	0.489	0.399	0.253	0.441	0.504	0.489	0.395	0.247	0.00672	0.00305	0.00081	0.00041	0.00614	0.004162114	1.73232E-05	1.163814	
11	0.437	0.503	0.489	0.397	0.249	0.434	0.501	0.489	0.399	0.253	0.435	0.502	0.489	0.399	0.251	0.00106	0.00079	4.9E-05	0.00051	0.00187	0.000857977	7.36125E-07	0.257283	
12	0.438	0.503	0.489	0.397	0.249	0.434	0.501	0.489	0.399	0.253	0.432	0.5	0.49	0.401	0.256	0.00191	0.00108	0.00056	0.00021	0.00229	0.001569178	2.46232E-06	0.433697	
13	0.435	0.502	0.489	0.399	0.251	0.432	0.5	0.49	0.401	0.255	0.438	0.503	0.489	0.397	0.249	0.00554	0.00276	0.00068	0.00036	0.00581	0.003676924	1.35198E-05	1.038404	
14	0.432	0.5	0.49	0.401	0.256	0.429	0.499	0.49	0.403	0.258	0.423	0.497	0.491	0.407	0.263	0.00516	0.00236	0.00104	0.00388	0.00489	0.003465563	1.20101E-05	0.942916	
15	0.423	0.497	0.491	0.407	0.263	0.423	0.496	0.491	0.408	0.265	0.415	0.493	0.492	0.413	0.272	0.00787	0.00329	0.00139	0.00052	0.00722	0.004995148	2.49515E-05	1.352141	
16	0.419	0.495	0.492	0.41	0.267	0.42	0.495	0.491	0.41	0.268	0.418	0.494	0.492	0.41	0.268	0.00177	0.00017	0.00035	0.00038	0.0004	0.000613615	3.76523E-07	0.153952	
17	0.415	0.493	0.492	0.413	0.272	0.416	0.493	0.492	0.413	0.272	0.405	0.488	0.494	0.42	0.282	0.01163	0.00473	0.00187	0.00704	0.01059	0.007171881	5.14359E-05	1.929234	
18	0.405	0.488	0.494	0.42	0.282	0.409	0.49	0.493	0.419	0.28	0.419	0.495	0.492	0.41	0.267	0.00995	0.00517	0.00148	0.00972	0.01307	0.007876841	6.20446E-05	2.198614	
																						HKT	0,000198475	
																						HKO	1,10264E-05	
																						HKOK	0,003320601	
																						OMYH (%)	0,684853586	

EK 22: Sigmoidal Fonksiyonu Üyelik Değerleri için 2 Gizli Katmanlı (10-5) Yapay Sinir Ağı Eğitim Sonuçları

	g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA) ²	OMYH
1	0.49	0.526	0.481	0.362	0.204	0.479	0.521	0.48	0.368	0.211	0.481	0.522	0.483	0.368	0.211	0.00216	0.00108	0.00275	1E-04	2.5E-05	0.001223538	1.49705E-06	0.253013
2	0.481	0.522	0.483	0.368	0.211	0.472	0.517	0.482	0.373	0.218	0.47	0.517	0.484	0.375	0.221	0.00146	0.00047	0.00213	0.00185	0.00277	0.001737689	3.01956E-06	0.517837
3	0.47	0.517	0.484	0.375	0.221	0.462	0.513	0.485	0.381	0.228	0.464	0.514	0.485	0.379	0.226	0.00203	0.00116	0.00062	0.00135	0.0019	0.00140994	1.98793E-06	0.396977
4	0.464	0.514	0.485	0.379	0.226	0.457	0.511	0.486	0.384	0.233	0.458	0.512	0.486	0.383	0.231	0.0016	0.00096	1.7E-05	0.00129	0.002	0.001171294	1.37193E-06	0.348129
5	0.458	0.512	0.486	0.383	0.231	0.452	0.509	0.487	0.388	0.237	0.454	0.51	0.487	0.386	0.234	0.00192	0.00112	0.00046	0.0018	0.00307	0.001673834	2.80172E-06	0.502881
6	0.454	0.51	0.487	0.386	0.234	0.448	0.507	0.488	0.39	0.24	0.449	0.508	0.487	0.389	0.239	0.00073	0.00053	0.00065	0.00095	0.00176	0.000923363	8.52599E-07	0.27614
7	0.449	0.508	0.487	0.389	0.239	0.444	0.506	0.489	0.393	0.244	0.443	0.505	0.488	0.394	0.245	0.00179	0.00058	0.00043	0.00067	0.00043	0.000779346	6.0738E-07	0.19058
8	0.443	0.505	0.488	0.394	0.245	0.439	0.503	0.49	0.397	0.249	0.437	0.503	0.489	0.397	0.249	0.00144	0.00047	0.00069	0.00029	0.00035	0.00064482	4.15793E-07	0.154603
9	0.441	0.504	0.489	0.395	0.247	0.437	0.503	0.49	0.398	0.251	0.438	0.503	0.489	0.397	0.249	0.00123	0.00058	0.00095	0.00122	0.00144	0.001085266	1.1778E-06	0.295301
10	0.438	0.503	0.489	0.397	0.249	0.435	0.502	0.49	0.4	0.253	0.441	0.504	0.489	0.395	0.247	0.00606	0.00263	0.00184	0.00455	0.00619	0.004253809	1.80949E-05	1.18661
11	0.437	0.503	0.489	0.397	0.249	0.434	0.502	0.491	0.4	0.253	0.435	0.502	0.489	0.399	0.251	0.00055	0.00029	0.00116	0.001	0.00204	0.001008199	1.01646E-06	0.296966
12	0.438	0.503	0.489	0.397	0.249	0.435	0.502	0.49	0.4	0.253	0.432	0.5	0.49	0.401	0.256	0.00295	0.00127	0.00026	0.00168	0.00261	0.001753137	3.07349E-06	0.485698
13	0.435	0.502	0.489	0.399	0.251	0.433	0.501	0.491	0.401	0.255	0.438	0.503	0.489	0.397	0.249	0.00513	0.00221	0.00182	0.00401	0.00586	0.003806756	1.44914E-05	1.069772
14	0.432	0.5	0.49	0.401	0.256	0.429	0.499	0.491	0.403	0.258	0.423	0.497	0.491	0.407	0.263	0.00587	0.00266	0.00023	0.00379	0.00559	0.003628832	1.31684E-05	1.004738
15	0.423	0.497	0.491	0.407	0.263	0.423	0.497	0.492	0.408	0.264	0.415	0.493	0.492	0.413	0.272	0.00789	0.00378	0.00075	0.00555	0.00844	0.00528115	2.78905E-05	1.453262
16	0.419	0.495	0.492	0.41	0.267	0.419	0.495	0.492	0.41	0.266	0.418	0.494	0.492	0.41	0.268	0.00116	0.00091	0.00028	0.00089	0.00164	0.000975427	9.51459E-07	0.269292
17	0.415	0.493	0.492	0.413	0.272	0.415	0.494	0.492	0.412	0.27	0.405	0.488	0.494	0.42	0.282	0.0108	0.00536	0.00178	0.00812	0.01267	0.007746199	6.00036E-05	2.109359
18	0.405	0.488	0.494	0.42	0.282	0.407	0.491	0.492	0.417	0.276	0.419	0.495	0.492	0.41	0.267	0.01192	0.00434	0.00052	0.00749	0.00966	0.006786632	4.60584E-05	1.855819
																					HKT	0,00019848	
																					HKO	1,10267E-05	
																					HKOK	0,003320646	
																					OMYH (%)	0,703720821	

EK 24: Çan Şekli Fonksiyonu Üyelik Değerleri için 3 Gizli Katmanlı (11-2-2) Yapay Sinir Ağı Eğitim Sonuçları

g1	g2	g3	g4	g5	h1'	h2'	h3'	h4'	h5'	h1	h2	h3	h4	h5	h1-h1'	h2-h2'	h3-h3'	h4-h4'	h5-h5'	ORT. HATA	(ORT. HATA)^2	OMYH	
1	0.429	0.48	0.389	0.452	0.448	0.455	0.408	0.486	0.463	0.445	0.473	0.402	0.489	0.464	0.003351	0.01853	0.00563	0.00245	0.00122	0.006267404	3.92803E-05	1.373477	
2	0.445	0.473	0.402	0.489	0.464	0.457	0.461	0.415	0.498	0.474	0.46	0.451	0.416	0.491	0.003333	0.01005	0.00069	0.00713	0.01063	0.006364378	4.0503E-05	1.35231	
3	0.46	0.451	0.416	0.491	0.484	0.465	0.468	0.423	0.506	0.482	0.471	0.462	0.421	0.507	0.00565	0.00614	0.00184	0.00136	0.00864	0.004727497	2.23492E-05	0.999448	
4	0.471	0.462	0.421	0.507	0.49	0.475	0.474	0.431	0.521	0.496	0.479	0.463	0.426	0.526	0.00407	0.01083	0.00465	0.00461	0.00248	0.005327603	2.83833E-05	1.130592	
5	0.479	0.463	0.426	0.526	0.498	0.48	0.478	0.435	0.529	0.504	0.486	0.483	0.432	0.525	0.00546	0.00465	0.00312	0.00477	0.00125	0.003850563	1.48253E-05	0.793697	
6	0.486	0.483	0.432	0.525	0.503	0.491	0.485	0.444	0.546	0.519	0.491	0.484	0.437	0.53	8.6E-05	0.00041	0.00061	0.01617	0.00724	0.006103014	3.72468E-05	1.215749	
7	0.491	0.484	0.437	0.53	0.512	0.497	0.489	0.449	0.555	0.527	0.498	0.489	0.446	0.552	0.00179	0.00026	0.00334	0.000287	0.00437	0.002524426	6.37273E-06	0.503108	
8	0.498	0.489	0.446	0.552	0.523	0.503	0.493	0.455	0.565	0.537	0.506	0.5	0.467	0.557	0.00248	0.00629	0.01233	0.00745	0.00726	0.007160208	5.12686E-05	1.419095	
9	0.499	0.491	0.453	0.566	0.528	0.503	0.493	0.455	0.564	0.536	0.501	0.491	0.44	0.569	0.00236	0.00205	0.0147	0.00484	0.00191	0.005170601	2.67351E-05	1.087633	
13	0.501	0.491	0.44	0.569	0.534	0.507	0.494	0.457	0.574	0.545	0.508	0.497	0.438	0.576	0.00128	0.00306	0.01959	0.00212	0.00093	0.005395138	2.91075E-05	1.176292	
11	0.504	0.498	0.489	0.563	0.531	0.505	0.498	0.457	0.557	0.531	0.499	0.491	0.453	0.566	0.00648	0.00711	0.00432	0.00823	0.00319	0.00586567	3.44061E-05	1.151741	
10	0.506	0.5	0.467	0.557	0.53	0.51	0.499	0.461	0.571	0.543	0.508	0.501	0.493	0.56	0.00189	0.00161	0.03259	0.01059	0.00926	0.01187923	0.00012517	2.184732	
14	0.508	0.497	0.438	0.576	0.546	0.515	0.499	0.464	0.591	0.56	0.518	0.504	0.444	0.592	0.00224	0.0057	0.0202	0.00103	0.00106	0.006045154	3.65439E-05	1.295221	
12	0.508	0.501	0.493	0.56	0.534	0.51	0.502	0.461	0.562	0.536	0.504	0.498	0.489	0.563	0.00532	0.00362	0.02784	0.00075	0.00536	0.008577511	7.35737E-05	1.723949	
15	0.518	0.504	0.444	0.592	0.561	0.524	0.504	0.471	0.605	0.574	0.526	0.509	0.46	0.608	0.00247	0.00553	0.01145	0.0023	0.00609	0.005568328	3.10063E-05	1.095025	
16	0.523	0.507	0.495	0.592	0.565	0.527	0.512	0.475	0.591	0.563	0.523	0.506	0.474	0.606	0.00345	0.00596	0.00093	0.01443	0.00524	0.006001225	3.60147E-05	1.067563	
17	0.526	0.509	0.46	0.608	0.58	0.532	0.509	0.478	0.615	0.583	0.535	0.513	0.483	0.642	0.00386	0.00375	0.00571	0.02656	0.01901	0.011776711	0.000138691	1.985508	
18	0.535	0.513	0.483	0.642	0.602	0.531	0.51	0.478	0.612	0.581	0.523	0.507	0.495	0.592	0.00871	0.00288	0.01706	0.02016	0.01609	0.012979966	0.00016848	2.387236	
																					HKT	0,000939959	
																					HKO	5,22199E-05	
																					HKOK	0,007226337	
																					OMYH (%)	1,330132132	

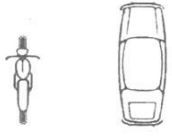

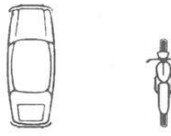

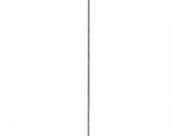
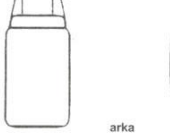
EK 29: Maddi Hasarlı Trafik Kazası Tespit Tutanağı-1

MADDİ HASARLI TRAFİK KAZASI TESPİT TUTANAĞI



1 Kaza Tarihi	Saat	2 Kaza Yeri	İl:	Mahalle:
			İlçe:	Cadde:
			Semt:	Sokak:

3 Görgü Tanıkları		
Adı Soyadı:	Adresi:	Tel No:

ARAÇ A	A	8- Uygun Kutulara (x) İşareti Koyunuz	B	ARAÇ B
4 Sürücü Bilgileri		Kırmızı ışık ihlalinde bulunmak		4 Sürücü Bilgileri
Adı Soyadı:		Taşıt giremez işareti bulunan karayoluna girmek		Adı Soyadı:
T.C. Kimlik No:		Karşı yönden gelen trafiğin kullandığı yola girmek		T.C. Kimlik No:
Sürücü Belge No. Ve Sınıfı:		Geçme yasası (sollama yasası) olan yerde geçiş yapmak		Sürücü Belge No. Ve Sınıfı:
Alındığı Yer (il/ilçe):		Kavşakta geçiş önceliğine uymamak		Alındığı Yer (il/ilçe):
Adres:		Yetkili memurun dur işaretinde geçmek		Adres:
Tel No:		Aynı istikamette ve aynı şeritte giderken önündeki araca arkadan çarpmak		Tel No:
5 Araç Bilgileri		Sağa dönüş kurallarına uymamak		5 Araç Bilgileri
Marka ve Modeli:		Sola dönüş kurallarına uymamak		Marka ve Modeli:
Plaka:		Geni manevra kurallarına uymamak		Plaka:
Kullanım Şekli:		Geçme (sollama) kurallarına uymamak		Kullanım Şekli:
6 Trafik Sigortası Poliçe Bilgileri		Geçiş önceliğine uymamak		6 Trafik Sigortası Poliçe Bilgileri
Sigortalının Adı Soyadı:		Parkeleme kurallarına uymamak		Sigortalının Adı Soyadı:
T.C. Kimlik No:		Duraklama kurallarına uymamak		T.C. Kimlik No:
Sigorta Şirketinin Ünvanı:	km/s	Kurallara uygun olarak park edilmiş araca çarpmak	km/s	Sigorta Şirketinin Ünvanı:
Acente No:	m	tespit edildi ise fren izi uzunluğu	m	Acente No:
Poliçe No.:				Poliçe No.:
TRAMER Belge No:				TRAMER Belge No:
Poliçenin Başlangıç-Bitiş Tarihi:				Poliçenin Başlangıç-Bitiş Tarihi:
7 Aracın ilk darbe aldığı yeri bir ok (->) ile gösteriniz.				7 Aracın ilk darbe aldığı yeri bir ok (->) ile gösteriniz.
	ön		ön	
	arka		arka	

9 Çarpışma yerinin ve anının taslağını çiziniz.

10 Sürücü görüşleri	10 Sürücü görüşleri

A **11** Sürücülerin İmzaları **11** B

ÖZGEÇMİŞ

1980 Adana doğumlu olan yazar, 2001 yılında Selçuk Üniversitesi, Eğitim Fakültesi, Matematik Öğretmenliği Bölümü' nden lisans derecesini almış, aynı yıl Milli Eğitim Bakanlığı' na bağlı kurumlarda matematik öğretmenliği yapmaya başlamıştır. 2001 yılında Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Ortaöğretim Matematik Eğitimi Anabilim Dalı' nda yüksek lisans eğitimine başlayarak bu programdan "Fark Denklem Sistemleri Üzerine" başlıklı tez çalışması ile 2005 yılında mezun olmuştur. 2010 yılında İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı' nda doktora eğitimine başlayan Muhammet Atalay, 2009 yılından beri Kırklareli Üniversitesi, Babaeski Meslek Yüksekokulu' nda öğretim görevlisi olarak çalışmaktadır. Uluslararası ve ulusal çeşitli dergilerde yayınlanmış makaleleri bulunan yazar evli ve 3 çocuk babası olup İngilizce bilmektedir.