KOCAELİ ÜNİVERSİTESİ * FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV SATIŞ SONRASI HİZMETLERİ İÇİN EŞZAMANLI SİNİRSEL BULANIK SİSTEM ÖNERİSİ

DOKTORA TEZİ

Fehmi Evren DİNÇ

Anabilim Dalı: Endüstri Mühendisliği

Danışman: Prof. Dr. Zerrin Aladağ

KOCAELİ, 2012

KOCAELİ ÜNİVERSİTESİ * FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV SATIŞ SONRASI HİZMETLERİ İÇİN EŞZAMANLI SİNİRSEL BULANIK SİSTEM ÖNERİSİ

DOKTORA TEZİ

Fehmi Evren DİNÇ

Tezin Enstitüyü Verildiği Tarih: 10 Ocak 2012
Tezin Savunulduğu Tarih: 24 Şubat 2012

Tez Danışmanı	Üye	Üye
Prof. Dr. Zerrin ALADAĞ	Prof. Dr. Coşkun ÖZKAN	Prof. Dr. Semra BİRGÜN
Üye	Üye	
Doç. Dr. Y. Esra ALBAYRAK	Yard. Doç. Dr. Gülşen AKMAN	

KOCAELİ, 2012

ÖNSÖZ

Çalışmamın başından itibaren fikir ve öngörüleriyle daima yol gösterici olan, sağladığı katkı, gösterdiği ilgi ve emek ile çalışmamın ilerlemesini sağlayan danışman hocam Sayın Prof. Dr. Zerrin ALADAĞ' a,

Değerli fikirleriyle katkı sağlayan ve beni destekleyen hocalarım Sayın Prof. Dr. Semra BİRGÜN ve Prof. Dr. Coşkun ÖZKAN' a,

Desteğini benden esirgemeyen arkadaşım Arş. Gör. Dr. Yıldız YULUĞKURAL' a,

Çalışmam sırasında manevi destekleri ve teşvikleriyle her zaman yanımda olan tüm arkadaşlarıma,

Eğitim ve kariyer hayatım boyunca; sonsuz sevgi, emek, sabır ve yoğun manevi desteği ile yanımda olan anneme ve babama,

Sonsuz teşekkürlerimi sunuyorum.

İÇİNDEKİLER

ÖNSÖZ i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iv
TABLOLAR DİZİNİ v
SEMBOLLER vi
ÖZET vii
İNGİLİZCE ÖZET viii
1. GİRİŞ 1
2. ARIZA TAHMİN SÜRECİNDE KULLANILAN YÖNTEMLER VE OTOMOTİV SEKTÖRÜNE UYARLANMASI 5
2.1. Bulanık Mantık Sistemleri ve Sinirsel Ağlar ile Arıza Tespitine Genel Bir Bakış 5
2.2. Otomotiv Servis Sektörüne Genel Bakış ve Servis Danışmanlarının Sektördeki Yeri 6
2.3. Otomotiv Sektöründe Arıza Teşhis ve Maliyet Tahmini Sürecinin Değerlendirilmesi 7
3. YAPAY SİNİR AĞLARI 9
3.1. Sinir Ağlarının Mimarisi ve Nöron Modeli 11
3.2. Yapay Sinir Ağlarının Avantajları ve Dezavantajları 13
3.3. Sinir Ağlarında Öğrenme Algoritmaları 14
3.3.1. Danışmanlı öğrenme 15
3.3.2. Danışmansız öğrenme 16
4. YAPAY SİNİR AĞLARINDA KÜMELEME VE ÖZ ÖRGÜTLEMELİ HARİTALAR 18
4.1. Öz Örgütlemeli Harita Topolojisi 19
4.2. Öz Örgütlenmeli Haritaların Avantajları ve Dezavantajları 21
4.3. Öz Örgütlemeli Haritaların Özellikleri 22
4.4. Öz Örgütlenmeli Harita Öğrenme Algoritması 22
4.4.1. Öz örgütlemeli harita sapma öğrenme kuralı 27
4.4.2. Öz örgütlemeli harita modelinde sınıflandırmayı etkileyen faktörler 28
4.4.3. Öz Örgütlemeli Harita' nın bazı türevleri 29
4.4.4. Öz örgütlemeli harita sonuçlarının görselleştirilmesi 30
4.5. Öz Örgütlemeli Haritada Mesafe Matrisleri 32
5. SİNİRSEL BULANIK SİSTEMLER 35
5.1. Bulanık Mantık 35
5.2. Bulanık Mantık Çıkarım Süreci ve Genel Özellikleri 37
5.3. Sinirsel Bulanık Mantık Yaklaşımı ve Türleri 38
5.4. Müşterek Sinirsel Bulanık Sistemler 39
5.5. Bulanık İlişkisel Hafızalar 40
5.6. Öz Örgütlemeli Haritalar Kullanarak Bulanık Kural Çıkarımı 41
5.6.1. Bulanık küme parametrelerini öğrenen sistem 42
5.7. Eşzamanlı Sinirsel Bulanık Sistemler 42
5.8. Bütünleşik Sinirsel Bulanık Sistemler 43
5.8.1. Mamdani entegreli sinirsel bulanık sistemler 44

5.8.2. Takagi-Sugeno entegreli sinirsel bulanık sistemler 46
5.8.3. Uyarlanabilir ağ bazlı bulanık çıkarım sistemi 48
5.8.4. Bulanık uyarlanabilir öğrenme kontrol ağı 49
5.8.5. Genelleştirilmiş yaklaşık çıkarım tabanlı akıllı denetim..... 51
5.8.6. Sinirsel-Bulanık denetim birimi..... 52
5.8.7. Sinirsel-Bulanık sınıflandırma 54
5.8.8. Sinirsel-Bulanık fonksiyon yaklaşıklama 56
5.8.9. Ayarlamalı bulanık çıkarsama ortam yazılımı 56
5.8.10. Kendini inşa eden sinirsel-bulanık çıkarsama ağı..... 56
5.8.11. Bulanık ağ 58
5.8.12. Evrimleşen bulanık sinirsel ağlar..... 59
5.8.13. Dinamik evrimleşen bulanık sinirsel ağlar..... 60
6. UYARLAMALI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ VE TAHMİN PROBLEMİ..... 61
6.1. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi Mimarisi..... 61
6.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Parametre Ayarlaması ve Eğitim.....66
6.3. Literatür Araştırması..... 70
7. EŞZAMANLI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ İLE OTOMOTİV SERVİS ENDÜSTRİSİ ÜZERİNE BİR ÇALIŞMA 72
7.1. Eşzamanlı Sinirsel Bulanık Çıkarım Modelinin Oluşturulması..... 72
7.2. Başlangıç Veri Setinin Oluşturulması..... 73
7.3. Öz Örgütlenmeli Harita Modelinin Kurulması 76
7.4. Öz Örgütlenmeli Harita Ağında Sıralama ve Ayarlama Fazları 79
7.5. Öz Örgütlenmeli Harita Ağının Sonuçlarının Elde Edilmesi..... 80
7.6. Öz Örgütlenmeli Harita Arıza İndeks Değerlerinin Oluşturulması 85
7.7. Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi İle Araç Arıza Tutarının Hesaplanması..... . 86
7.8. Kontrol Veri Dizilerini Kullanarak Model Doğrulama..... 87
7.9. MATLAB Bulanık Mantık Araç Kutusu ile Eğitim Süreci 88
7.10. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ve Değişkenlerinin Arıza Tutarı Üzerindeki Etkisi 99
7.11. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ve Doğrusal Regresyon Karşılaştırması.....101
SONUÇLAR ve ÖNERİLER..... 102
KAYNAKLAR 104
EKLER..... 117
ÖZGEÇMİŞ 139

ŞEKİLLER DİZİNİ

Şekil 3.1: Sinir Ağlarının Mimarisi ve Nöron Yapısı Modeli..... 11
Şekil 3.2: Danışmanlı öğrenme örneği.....16
Şekil 4.1: Öz Örgütlemeli Harita ağının topolojik yapısı..... 20
Şekil 4.2: Öz Örgütlemeli Harita Kazanan Nöron hesaplanması..... 25
Şekil 4.3: Kazanan nöronun doğrusal komşuluğu..... 26
Şekil 4.4: Kazanan nöronun dikdörtgensel komşuluğu..... 26
Şekil 4.5: Küçük katlardaki nesneleri bağlama 32
Şekil 4.6: Kümeleme görselleştirmeleri.....34
Şekil 5.1: Müşterek Sinirsel Bulanık sistemler.....40
Şekil 5.2: Eşzamanlı Sinirsel Bulanık Sistemler 43
Şekil 5.3: Mamdami entegreli sinirsel bulanık sisteminin mimarisi ve beş katmanı .46
Şekil 5.4: Uyarlanabilir Ağ Bazlı Bulanık Çıkarım Sistemi.....49
Şekil 5.5: Tsukamoto Bulanık Çıkarım Sistemi..... 49
Şekil 5.6: Bulanık Uyarlanabilir Öğrenme Kontrol Ağı modeli.....51
Şekil 5.7: Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetim İşlem Seçim Ağı' nın modeli..... 52
Şekil 5.8: İki girdili ve beş bulanık kurallı Sinirsel-Bulanık Denetim Birimi mimarisi.....54
Şekil 5.9: Sinirsel-Bulanık Sınıflandırma mimarisi 55
Şekil 6.1: MATLAB ANFIS Editör Arayüzü Model 1..... 69
Şekil 6.2: MATLAB ANFIS Editör Arayüzü Model 2..... 70
Şekil 7.1: Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi ile Arıza Tahmin Modeli.... 73
Şekil 7.2: SOM kümeleme modeli ve kümeler aralarındaki mesafeler 83
Şekil 7.3: SOM kümeleme sonuçları 85
Şekil 7.4: Seçilen ANFIS model yapısı..... 93
Şekil 7.5: ANFIS modelinin eğitim ve kontrol hata eğrileri..... 94
Şekil 7.6: ANFIS kural tabanı..... 96
Şekil 7.7: Araç Yaşı ve Araç Kilometresi' nin Arıza Tutarı üzerindeki etkisi 97
Şekil 7.8: Araç Yaşı ve Arıza İndeksinin Arıza Tutarı üzerindeki etkisi..... 97
Şekil 7.9: Araç Kilometresi ve Arıza İndeksi' nin Arıza Tutarı üzerindeki etkisi..... 98
Şekil 7.10: Araç Yaşı üyelik fonksiyonu değerleri 98
Şekil 7.11: Araç Kilometre Değeri üyelik fonksiyonu değerleri 99
Şekil 7.12: Arıza İndeks Değeri üyelik fonksiyonu değerleri..... 99
Şekil 7.13: Girdilerin çıktı üzerindeki etkileri 100

TABLOLAR DİZİNİ

Tablo 5.1: Sinirsel ağlar ve bulanık çıkarım sistemi karşılaştırması 44
Tablo 7.1: Şikâyet ağırlık değerleri..... 75
Tablo 7.2: Müşteri şikâyet listesi 75
Tablo 7.3: SOM kümeleme performansı..... 77
Tablo 7.4: Araçların SOM ile Atandığı Hücreler..... 82
Tablo 7.5: Arıza İndeks Değerleri..... 86
Tablo 7.6: ANFIS Mimarileri ve En Uygun Modelin Seçimi..... 91
Tablo 7.7: Minimum kontrol hatası eğitim süreci..... 92
Tablo 7.8: ANFIS ile kontrol grubu tahmin sonuçları 95
Tablo 7.9: Girdilerin çıktı üzerindeki etkileri 101
Tablo 7.10: ANFIS ile Kontrol Grubu Tahmin Sonuçları 101

SEMBOLLER

α	: Öğrenme Katsayısı
ANFIS	: Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi / Adaptive Neural Fuzzy Inference System
ART2	: Adaptive Resonance Theory2 / Uyarlamalı rezonans teorisi
BÇS	: Bulanık Çıkarım Sistemi
BİH	: Bulanık İlişkisel Hafızalar
BMU	: Kazanan Nöron /Best Matching Unit
CNFS	: Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi / Concurrent Neuro-Fuzzy System
Dsigmf	: İki sigmoidal üyelik fonksiyonları arasındaki fark oluşur üyelik fonksiyonu
FIS	: Bulanık Çıkarım Sistemi / Fuzzy Inference System
Gaussmf	: Gauss eğrisi üyelik fonksiyonu
Gauss2mf	: Gaussian kombinasyon üyelik fonksiyonu
Gbellmf	: Genelleştirilmiş çan şeklindeki üyelik fonksiyonu
Input 1	: Aracın model yılı
Input 2	: Aracın kilometre bilgisi
Input 3	: Arıza İndeksi
LMS	: Least Mean Square / En Az Ortalama Kareler
MAPE	: Mean Absolute Percentage Error / Ortalama Mutlak Hata Yüzdesi
NN	: Sinirsel Ağ / Neural Network
Output	: Çıktı
Pimf	: Π şeklindeki yerleşik üyelik fonksiyonu
Psigmf	: İki sigmoidal şeklinde üyelik fonksiyonları ürününden oluşan üyelik fonksiyonu
R	: Başlangıç komşuluk uzaklığı
RMSE	: Root Mean Square Error / Ortalama Karekök Hatası / Ortalama Hata Kareler / Hata Kareleri Ortalaması
SMTS	: Servis Müşteri Takip Sistemi
SOM	: Self Organizing Map / Kendini Düzenleyen Haritalar / Öz Örgütlemeli Harita Yayılım
Ss	: Adım boyutu
Ssdec	: Adım boyutunda azalma oranı
Ssinc	: Adım boyutu artış oranı
Trimf	: Üçgen şeklinde üyelik fonksiyonu
ÜF	: Üyelik Fonksiyonları
YSA	: Yapay Sinir Ağları

OTOMOTİV SATIŞ SONRASI HİZMETLERİ İÇİN EŞZAMANLI SİNİRSEL BULANIK SİSTEM ÖNERİSİ

Fehmi Evren DİNÇ

Anahtar Kelimeler: Eşzamanlı Nöro-Bulanık Sistem, Bulanık Çıkarım Sistemleri, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi, Öz Örgütlenmeli Harita, Maliyet Tahmini, Otomotiv Servis Sektörü, Karar Destek Sistemleri

Özet: Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi ile otomotiv servis endüstrisi üzerine yapılan bu çalışmada, seçilen bir otomotiv firmasının yetkili servisleri tarafından kullanılan Servis Müşteri Takip Sistemi incelenmiştir. Sayısal değerlerle ölçülebilen kriter ve sayısal olarak ölçülemeyen, iletişim yoluyla belirlenen dilsel kriterlerin bir arada değerlendirilebileceği, araçlardaki arızaların tespiti ve tahmin için bir model olarak Yapay Sinir Ağları ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi (Concurrent Neuro-Fuzzy System - CNFS) geliştirilmiştir.

Sistemin tasarlanabilmesi için farklı bütünleşik kriterleri ve veri gruplarını sınıflandırmak ve sıralamak gerekmiştir. Müşteri şikâyetleri ile gelen öznellik Yapay Sinir Ağlarından faydalanılarak aşılmıştır. Model, Yapay Sinir Ağlarının özel bir türü olan Öz Örgütlenmeli Harita (Self organize Map - SOM) yöntemi kullanarak çeşitli müşteri şikâyetleri ile servise getirilen araçları gruplamakta, gruplanan şikâyetleri belirli bir puanlama sistemine göre sıralamaktadır. SOM heterojen veri gruplarında kümeleme ve sınıflama için uygun bir metodoloji olması sebebiyle seçilmiştir.

Arızaları tahmin etmenin; yüksek metodolojik ve çevresel belirsizlik özellikleri taşıdığı bilinmektedir. Eşzamanlı Sinirsel Bulanık Çıkarım sisteminde oluşturulan Öz Örgütlenme Harita çıktıları tahmin ve sınıflandırmadaki belirsizlikleri azaltmak amacıyla, aracın kilometre ve yaş bilgileri ile beraber özel bir sinirsel bulanık sistem olan Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neural Fuzzy Inference System ANFIS)' nde hesaplamaya sokulmuş ve arıza tespiti ve arıza tutarının tahmin edilebilmesi için kullanılmıştır.

Model yapısı içinde yer alan Öz Örgütlenmeli Ağ, ANFIS' in öncül girdi besleyicisi olarak konumlandırılmıştır.

A CONCURRENT NEURO-FUZZY INFRENCE SYSTEM PROPOSAL FOR AUTOMOTIVE AFTER SALE SERVICES

Fehmi Evren DİNÇ

Keywords: Concurrent Neuro-Fuzzy System, Fuzzy Inference Systems, Adaptive Neuro-Fuzzy Inference System, Self Organizing Maps, Cost Predicting, Automotive Service Industry , Decision Support Systems

Abstarct: In this operation that was carried out over Concurrent Neural Fuzzy Inference System (CNFS) and automotive service industry, Service Consumer Tracking System (SCTS), used by authorized service of a selected automotive company, was analyzed. As a system in which measures that can be measured with numerical values and linguistic measures that cannot be determined with numerical values but with communication can be evaluated together, CNFS has been developed with Artificial Neural Networks and Adaptive Neural Fuzzy Inference System (ANFIS), for the detection and estimation of the vehicles' malfunctions.

The subjectivity that came with consumer complaints is exceeded by using Artificial Neural Networks. Model groups vehicles that comes to service with various consumer complaints by using a special type of Artificial Neural Networks, Self-Organized Map (SOM), and then lines the grouped complaints in a specific scoring system. SOM is selected for the reason that it is a suitable methodology for clustering and classifying in heterogeneous data groups.

It is known that estimating malfunctions has high methodological and environmental obscureness features. SOM outputs, which are generated in CNFS, have been put into calculation in ANFIS which is a special neural fuzzy system, with vehicle's kilometer and age information and have been used for estimating the malfunction detection and malfunction cost in an aim to decrease the suspense in estimation and classification.

The SOM Network, which takes part in model structure, has been positioned as ANFIS's antecedant input feeder.

1. GİRİŞ

Günümüzde otomotiv satış sonrası hizmet ağı ve kalitesi, tüketicilerin satın alma kararları üzerinde, ürün veya hizmetin kendisi kadar etkili olabilmektedir. Otomotiv pazarında yaşanan rekabete paralel olarak, satış sonrası servis hizmetleri de sektörde firmaların rekabet kabiliyeti açısından büyük önem kazanmıştır. Başarılı satış sonrası servis hizmeti sağlayan markaya olan müşteri bağlılığı ve yeni müşteri kazanma olasılığı, verilen hizmetle paralellik göstermektedir.

Müşteri için değer ifade eden özelliklerin neler olduğu, doğrudan ya da dolaylı olarak müşteriye sorularak elde edilebilir. Müşteriler arasında yapılan araştırmalar; tüketici ihtiyaçları, tercihleri, beklentileri, tüketim alışkanlıkları, davranış biçimleri, ürünler hakkındaki düşünceleri gibi konularda pazarlamacılara son derece güzel ipuçları vermektedir [1].

Yapılan bir araştırmada yerli otomobil sahiplerinin araç seçerken göz önünde bulundurdukları başlıca tercih sebepleri sorulmuştur. Verilen cevaplar son derece dikkat çekicidir;

- Alım-satım kolaylığı, yedek parça ve servis imkânları, milli ekonomiye katkı.

- Servis hizmetlerinin ve yedek parçanın ucuzluğu, bakım onarım süresinin kısalığı.

Başlıca ürün tercih nedenler olarak tüketiciler tarafından ifade edilmektedir [4].

Satış sonrası servis müşterisi beklentilerinin araştırılması ve müşteri ilişkilerinin iyileştirmesi çalışmalarında kullanılmak üzere çeşitli firmalar tarafından beklenti anketleri düzenlemiştir. Örnek anket çalışmasında bir otomotiv firmasının servis müşterilerine hizmet almak için yetkili servise geldiğinde beklentileri, ihtiyaçları ve

düşünceleri sorulmuştur. Aracın servise getirilme kararının verilmesinden, araçla ilgili sorunun tespit edilmesi ve tahmini fiyat verilmesine kadar geçen süreç içerisinde, müşteri memnuniyetini etkileyen başlıca maddeler aşağıdaki gibi belirtilmiştir [4].

- Aracımı servise getirdiğimde işlem süreçlerini uygun ve kolay hale getirin.
- Servis randevusu ayarlamamı kolay hale getirin.
- Uygun gün ve saat için randevu alabilmeme olanak sağlayın.
- Resepsiyon işlemlerini hızlı bir şekilde tamamlayın.
- İşe başlamadan önce aracı benimle birlikte muayene edin.
- Bana aracın servis işlemlerinin ne zaman tamamlanacağını ile ilgili tahmin verin.
- Servis yoğunluğundan dolayı beni bekletmeyin.
- Servise geldiğimde başka bir tarihe randevu vermeyin.
- İşe başlamadan önce tutarlı bir fiyat tahmininde bulunun.

Özet olarak bu süreçte müşteri beklentisi, “Serviste en az süre bekleyerek araçtaki sorunun doğru ve hızlı bir şekilde belirlenmesi” olarak ifade edilebilir.

Geleneksel pazarlama anlayışına göre şirketlerin amacı sadece daha çok satmakken, modern anlayışa göre firmanın müşterisi ile ilişkisi satış öncesini ve sonrasını kapsamaktadır. İlişkinin devamı için gereken ise müşterinin her zaman memnun kalmasıdır. Bugün hemen hemen tüm pazarlamacıların kabul ettiği gibi yeni bir müşteriyi etkilemek mevcut müşteriyi etkilemekten daha maliyetlidir. Bu nedenle yeni müşterinin dikkatini çekmektense mevcut müşteriyi kaybetmeme daha önemli görülmektedir. Müşteriyi kaybetmemenin anahtarı da müşteri memnuniyetidir.

Ayrıca bir ürünün değer taşıyabilmesi o ürünün müşteriye anlamlı bir fayda sağlamasına dayanmaktadır. Bu durumda değerin müşteri tarafından belirlendiğini söylemek hiç de yanlış olmayacaktır. Ancak, doğru değerin ortaya çıkarılması için tüketicinin çok iyi tanınması gerekmektedir [1].

Bir şirketin en önemli değerlerinden biri olarak kabul edilen müşteri memnuniyeti, uygun koşullar ile sağlandığında, müşteri şirket ile ilgili olumlu düşünlerini çevresindeki insanlar ile paylaşır. Belirli ürün gurupları için almış olduğu üründen memnun olan bir müşterinin medyada yer alan reklamdan daha etkili reklam kaynağı olduğu söylenebilir. Aldığı ürün veya hizmetten memnun olmuş bir müşteri, şirket için olumlu bir reklam fırsatı oluştururken, memnun olmamış müşteri, yüksek oranda potansiyel tehlike teşkil etmektedir. "Memnun olan müşteri iyi bulduğu ürün hakkında üç kişiye olumlu şeyler söylerken; memnun olmamış bir müşteri tam 11 kişiye ürünü kötülemektedir. Bu 11 kişiden her biri, bir diğer on bir kişiye anlatmakta ve bu zincir böyle devam etmektedir" [6].

Özellikle rekabetin gün geçtikçe yoğunlaştığı ve işletmelerin birbirlerinden müşteri koparmaya çalıştığı bir ortamda, müşterilerin bir işletmeye bağlanması ve diğer işletmelere rağmen o işletmeyi tercih etmeye devam etmesi işletme adına önemli bir rekabet avantajıdır. Çünkü yeni müşteri kazanmanın maliyeti, eski müşteriyi elde tutma maliyetinden çok daha yüksektir [7].

Otomotiv Yetkili Satıcıları Derneği (OYDER)' in 2006 yılında yaptığı araştırma sonuçlarına göre müşteri sadakati günümüzün yoğun rekabet ortamında markalara önemli bir avantaj ve tasarruf getirmektedir. Kaybedilen bir müşterinin yerine yenisini koymanın maliyeti, var olan müşteriyi elde tutmaya kıyasla tam dört kat daha yüksek olarak belirtilmiştir. Aynı araştırma kapsamında satıştan ve satış sonrasından memnun kalan bir tüketicinin aynı markayı tercih etme oranı yüzde 93. Satış sonrasından memnun değilse markayı tercih etme oranı ise yüzde 18' e kadar düşmektedir. Satıştan memnun olmayıp satış sonrasından memnun olan bir müşterinin aynı markayı tercih etme oranı ise yüzde 46' ya çıkmaktadır. Yani otomotiv firmaları için artık sadece araç satmak değil sonrasını da düşünecekleri bir dönem başlamıştır [34].

Yapılan bir başka araştırmaya göre ise müşteri kaybına neden olan etmenlerin başında yüzde 68 ile "kötü hizmet" gelmektedir. Ürün kaynaklı müşteri kayıpları yüzde 17, fiyat kaynaklı müşteri kayıpları yüzde 10 olarak tespit edilmiştir. Görüleceği üzere fiyat ve ürün kaynaklı müşteri kayıpları hizmet kaynaklı kayıplardan çok daha sonra gelmektedir. "Kötü hizmet ile ne demek istiyorsunuz?" diye sorulduğunda ise yüzde 41 doğru insana ulaşamama, yüzde 26 uzlaşmama ve çözümsüzlük, yüzde 20 çalışanların kabalığı, yüzde 13 yanıt vermeme veya sorun çözmede yavaş olunması şeklinde belirlenmiştir [8].

Otomotiv servislerine müşteriler tarafından getirilen arızalı araçların, arıza maliyetlerini değerlendirilmesini kolaylaştıran ve hızlandıran bir akıllı modelin tanımlanması satış sonrası müşteri memnuniyetinin korunması üzerinde etkili olacaktır.

Akıllı sistem, kararlar alabilme yeteneği olan bir sistemdir. Verdiği kararlar ise akıllı insanlar tarafından verilmiş gibi kabul edilir. Akıllı sistemler kendilerini bazı örnek durumlarda belirli bir sistemin girdisi olarak sisteme adapte ederler ve benzer durumlar için otomatik olarak doğru kararların alınmasına sağlayan sistemler oluşturabilirler. Özellikle, yapay sinir ağları ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neural Fuzzy Inference System - ANFIS), modelleme ve veri analizi için sıklıkla tercih edilen yöntemler haline gelmişlerdir.

Çalışma kapsamında seçilen servislerdeki Servis Müşteri Takip Sistemi (SMTS)' den elde edilen bilgiler, arızaların değerlendirmesine yönelik bir eşzamanlı sistemin geliştirilmesinde kullanılmıştır. Bu sistemin müşterilerin rahatlıkla ulaşabileceği bir platform aracılığı ile sunulması ve devamlı bir şekilde çalışması amaçlanmıştır.

2. ARIZA TAHMİN SÜRECİNDE KULLANILAN YÖNTEMLER VE OTOMOTİV SEKTÖRÜNE UYARLANMASI

2.1. Bulanık Mantık Sistemleri ve Sinirsel Ağlar ile Arıza Tespitine Genel Bir Bakış

Arıza tespiti için kullanılan bulanık mantık ve bulanık çıkarım uygulamaları içerisinde en göze çarpan çalışmalar proses endüstrisi, elektromekanik sistemleri, trafik ve aviyonik kontrolü, tahmin ve biyomedikal sistemlerdir.

Evsukoff ve arkadaşları, arıza tespiti ve izolasyonu için bir karar destek sistemi önermiştir [134]. Yang ve Liao, uyarlamalı bir bulanık model önermiştir [135]. Çalışma arıza tanıma sisteminin gelişmiş bir tasarımsal yaklaşımıdır. Bulanık mantık algoritması ile bulanık teşhis sistemi oluşturulmuştur. Bu sistemde, bir evrimsel optimizasyon algoritması geliştirilmiş ve If-then üyelik fonksiyonları ile çıkarım kuralları belirlenmiştir. Insfran ve arkadaşları, bulanık kümeler ile bir teşhis yaklaşımı geliştirmiştir [136]. Mechefske, frekans spektrumları sınıflandırmak için bulanık mantık teknikleri ile rulman hataları tespit etmiştir [137]. Patton, bulanık sistemler için uyarlanabilir öğrenme algoritmaları yaklaşımı ile kuralların sayısını, konumunu ve türünü yapay sinir ağlarına uygulamak için bulanık sistem parametreleri belirlemiştir [138].

Bulanık sistemlerde bulanık kurallar, oluşturulacak olan sistemle birlikte çalışacak olan insan uzmanlardan elde edilir. Uzmanlar kendilerinde olan bilgileri her zaman paylaşmak istemeyebilir ayrıca toplanan bilgilerin doğruluğu her zaman kolaylıkla kontrol edilemeyebilir. Oluşabilecek hatalı bir sistem yapısının önüne geçebilmek için Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi yöntemi bilginin toplanması, derlenmesi, tekrar tekrar kullanılabilmesi ve kendiliğinden eğitilebilmesi gibi avantajları ile tahmin problemlerinin başarılı bir şekilde çözümlenmesinde uygun bir yöntem olarak dikkat çekmiştir.

Arıza tespitinde sinir ağları kullanımı büyük ilgi görmüştür. Genel olarak arıza tespitinde kullanılan YSA uygulamaları iki sınıfa ayrışmıştır;

a)Ağ mimarisine göre.

b)Öğrenme stratejisine göre.

Çoklu Çözünürlüklü Hiyerarşik Sinir Ağı ile oluşturulmuş olanlar literatürde dikkat çekmektedir [150]. Bir başka çalışmada ise kendi kendine öğrenen algoritmalar ile arıza tespitine yönelik sinir ağı yapıları oluşturulmuştur. Bu çalışmalara paralel olarak Uyarlamalı rezonans teorisi (Adaptive Resonance Theory–ART2) veya Öz Örgütlemeli Ağ (Self Organizing Map-SOM) ağı gibi yapılar kullanılmıştır.

Arıza tespiti için kullanılan sinir ağı uygulamalarında en popüler yaklaşımlardan biri denetimli öğrenme stratejisi olmuştur. Geri yayılım algoritması kullanılarak geliştirilen pek çok çalışma karşımıza çıkmaktadır. Kimya alanında sinir ağları ve hata teşhisi konusunda çalışmaları sayılabilir. Bu çalışmadan sonra Vaidyanathan ve Venkatasubramanian tarafından dinamik süreç verilerini kullanmak için Venkatasubramanian önceki çalışmasının genişletilmiş bir uyarlaması hiyerarşik sinir ağı mimarisine sahip yapı dikkat çekmektedir [133].

Birden fazla hatanın tespitine yönelik bir çalışma ise Watanabe ve arkadaşları tarafından önerilmiştir. Çoğu çalışma standart geri yayılım algoritmasının iyileştirilmesine yönelik olarak tasarlanmıştır. Geri yayılım algoritmasının temel fonksiyonu üzerinde yapılan modifikasyonlar bir başka çalışma grubunu oluşturmaktadır. Radyal temel kullanımı önerilen arıza teşhisi uygulamaları için çeşitli fonksiyonlar ile çalışmalar yapılmıştır bunlardan bazıları; Gaussian veya radyal hesaplama tekniği kullanarak gizlenmiş düğüm problemlerinin çözümünde başlıca çalışmalar olarak literatürde göze çarpmaktadır [133].

2.2. Otomotiv Servis Sektörüne Genel Bakış ve Servis Danışmanlarının Sektördeki Yeri

2005 rakamlarına göre ülkemizde 41 otomotiv markası, 1.470 satış noktasında 44.900 personel ile hizmet vermektedir. Yine 1.621 işletme satış sonrası hizmet

noktası olarak servis ve yedek parça faaliyetini 20.968 personel istihdamı suretiyle yerine getirmektedir. Toplam 66 bini aşkın doğrudan istihdam ile hizmet sektörünün gelişmesine katkıda bulunulmakta ve katma değer yaratılmaktadır [5].

Yetkili servislerde işçilik maliyetleri önemli bir gider kalemi olarak karşımıza çıkmaktadır. Bunun öncelikli nedeni teknisyen işçilerin konularında uzmanlaşmış ve piyasada az bulunan kalifiye işçiler olmalarıdır. Buna paralel olarak servis danışmanlarının araçlardaki sorunlu noktaları hızlıca tespit etmesi, iş çizelgelerinin tanımlanmış iş sürelerinin dikkate alınarak hazırlanması, müşteriye teslim süreleri ve işçilerin verimlilikleri üzerinde olumlu etki yaratmaktadır.

Servis danışmanları, çeşitli şikâyetlerle servise gelen araçlarla ilgili olarak, araçların teknik özellikleri, araçlarda kullanılan parçalar, araçların arıza tipleri, model bazında arıza sıklıkları, genel müşteri şikâyetleri, sorunun atanabileceği bölüm ve personel, ortalama tamir süreleri ve maliyetleri konusunda bilgi sahibidir.

Genel olarak sektörde, müşteri şikâyetlerini değerlendirme süreci iyi tanımlanmamış olup servis danışmanlarının tercih ettiği değerlendirme yöntemine göre değişebilmektedir. Değerlendirme konunun uzmanı olan servis danışmanlarının kişisel gözlemlerine göre yapılmaktadır. Servislerde yapılan çalışmalarla görülmüştür ki müşteri şikâyeti değerlendirme süreci mevcut durumda servis danışman tecrübesine ihtiyaç duymaktadır. Genellikle değerlendirme için az sayıda konu uzmanı servis danışmanı bulunmaktadır. Bunun nedeni ise kalifiye servis danışmanı yetiştirilmesi son derece masraflı bir süreç olmasıdır.

2.3. Otomotiv Sektöründe Arıza Teşhis ve Maliyet Tahmini Sürecinin Değerlendirilmesi

Servis danışmanları gün içerisindeki fiziksel ve zihinsel yorgunluklarını işe yansıtabilmektedirler. Bunun sonucunda kritik detayları atlayabilmekte ve aynı şikâyetler ile gelen müşterilere günden güne değişen arıza teşhisleri koyabilmektedir. Otomotiv sektöründeki araç çeşitliliğinin artması sonucunda servis danışmanlarının iş yükü artmakta, dolayısıyla danışmanların hafızalarında tutmaları gereken bilgi

miktarı çoğalmakta ve bunun sonucu olarak karar verme süreci uzamakta veya yanlış sonuçlar ortaya çıkmaktadır.

Servislerde karşılaşılan bir başka problemli nokta ise danışmanların müşteri şikâyetlerini kasıtlı olarak çarpıtması, değiştirmesi, sorumluluktan kaçmak için saklaması ve işten ayrılarak bilgi birikimlerini yanlarında götürmeleridir. Bu gibi sorunların önüne geçebilmek için tasarlanan sistemler uzman insanlar gibi düşünme ve sezgi yeteneğine sahip olmalıdır.

Çalışmada amaçlanan sistem ile servis danışmanının karar sürecinin bir benzeri, akıllı yapay sistem ile taklit edilecektir. Ana unsur yapay zekâ yargılama kabiliyetinin, uzman yargısını taklit edebilecek düzeye gelmesidir. Otomotiv sektöründe maliyet tahmini ile ilgili literatür çalışmaları incelediğimizde pek çok yöntem ile çalışmalar yapıldığı ve başarılı sonuçlar elde edildiği görülmektedir.

Çalışma kapsamında, servis müşterilerinden, Servis Müşteri Takip Sistemi (SMTS) vasıtasıyla elde edilen şikâyetlerin, Yapay Sinir Ağları (YSA)' nın özel bir metodu olan Öz Örgütlenmeli Harita ve Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminden oluşan Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi ile değerlendirerek, şikâyetlerle ilişkili araçtaki muhtemel arızaların maliyetini ve sınıfını hesaplayabilen bir sistemin oluşturulması amaçlanmıştır.

3. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA), ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem elemanlarından oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır [11].

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalardır [9].

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece YSA denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır [10].

İnsan beyninin temel işlem elemanı olan nöronu şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA, biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir "girdi veriden öğrenme" kapasitesi sağlamaktadır ve birçok avantajlar sunmaktadır. Gün geçtikçe gelişen bu teknolojiden, günümüzde birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, "Evrensel Fonksiyon Yakınsayıcı Yöntem" olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar [11].

YSA, evrensel yaklaşımcı olarak tanımlandıklarında, insan beynindeki sinir sistemine benzer bir yapıya ve çalışma prensiplerine sahip olan YSA, genelleme yapabilme özelliği sayesinde son derece karmaşık problemlerin çözümünde faydalanılabilmektedir. YSA öğrenme yeteneği ile karmaşık sistemlerin modellenmesinde oldukça önemli bir yöntem olarak son yıllarda dikkat çekmektedir. Sistem yapısının bir kısmının bilinebildiği veya sistemin matematiksel modelinin çıkarılmasının oldukça zor veya tamamıyla imkânsız olduğu durumlarda, YSA sistem verileri ile eğitilerek sistemin modellenmesini sağlayabilmek için iyi bir alternatif olarak kullanılmaktadır.

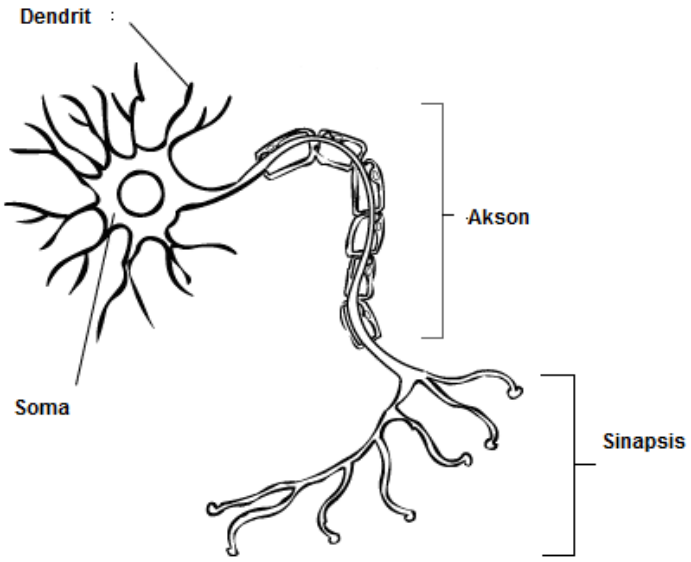
Sinirsel hesaplamanın merkezinde dağıtılmış, uyarlamalı ve doğrusal olmayan işlem kavramları vardır. Yapay Sinir Ağları, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. YSA' lar ise her biri büyük bir problemin bir parçası ile ilgilenen, çok sayıda basit işlem elemanlarından oluşmaktadır. En basit şekilde, bir işlem elemanı, bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur. İlk bakışta, işlem elemanlarının çalışma şekli yanıltıcı şekilde basittir. Sinirsel hesaplamanın gücü, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısından gelmektedir [11].

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Uyarlanabilme özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır. YSA' nın temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen yapay sinir ağları da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile yapay sinir ağları, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur [17]. Değişken yapısına ilişkin herhangi bir kısıtlama getirmeksizin değişkenler arasındaki ilişkiyi ortaya koyan bir yöntemdir [15].

3.1. Sinir Ağlarının Mimarisi ve Nöron Modeli

Bir insan beyni milyonlarca işlem elemanı (nöron) içerir. Bunlar aksonlar ve sinapslar yardımıyla haberleşirler. Beyin sık elektriksel anahtarlama elemanlarından oluşmuş biyokimyasal bir sistem olarak düşünülebilir. Bu sistemin girişi duyu organında bulunan algılayıcılardır Merkezi Sinir Sistemi bu alıcılar yardımıyla alınan bilgileri işleyerek etkileyiciler yardımı ile hareket organlarına iletir ve bu organlardan bir geri besleme yardımıyla emirlerin uygulanıp uygulanmadığını kontrol eder [22].

Yapay sinir hücresi, gerçek biyolojik hücreyle aynı ilkelere dayandırılmaya çalışılmıştır. Bu nedenle ilk olarak biyolojik sinir hücresinin (nöron) yapısının incelenmesi gerekmektedir. Bir biyolojik nöron, temel olarak, diğer kaynaklardan girdiler alır, belirli bir şekilde bunları birleştirir, sonuç üzerinde bir işlem (genelde doğrusal olmayan) uygular ve nihai sonucu üretir [21].



Şekil 3.1: Sinir Ağlarının Mimarisi ve Nöron Yapısı Modeli [10]

Dendrit: Görevi diğer sinir hücrelerinden iletilen sinyalleri, sinir hücresinin çekirdeğine iletmektedir. Bu yapı basit gibi görünse de günümüzde dendritlerin görevlerinin daha karmaşık olduğu yolunda söylemler hakim olan görüştür. Hücrenin çekirdeği ile her bir dendrit arasında farklı bir iletişim söz konusudur. Bu sebeple bazı dendritlerin etkileşimde ağırlıklı (dominant) pay sahibi, diğerlerinin de pasif

(resesif) olduğu gözlenmektedir. Bu ise dışarıdan alınan sinyallerde seçicilik gibi önemli bir olgunun sinir hücresi tarafından gerçekleştirilmesi anlamını taşımaktadır.

Soma: Dendritler yoluyla iletilen tüm sinyalleri alıp toplayan merkezdir. Biyolojik olarak hücre çekirdeği (nükleus) olarak da bilinen yapıdır. Çekirdek gelen toplam sinyali diğer sinir hücrelerine göndermek üzere, bilgiyi aksona iletir.

Akson: Hücre çekirdeğinden aldığı toplam bilgiyi bir sonraki sinir hücresine dağıtmakla görevlidir. Ancak akson bu toplam sinyalin ön işlemden geçirilmeden diğer sinir hücresine aktarılmasına engel olur. Çünkü akson ucunda sinapsis denilen birimlere bilgiyi aktarır.

Sinapsis: Aksondan gelen toplam bilgiyi ön işlemden geçirdikten sonra diğer sinir hücrelerinin dendritlerine iletmekle görevlidir. Sinapsisin ön işlem ile gerçekleştirdiği görev çok önemlidir. Bu ön işlem gelen toplam sinyalin, belli bir eşik değerine göre değiştirilmesinden ibarettir. Böylece toplam sinyal olduğu gibi değil, belli bir aralığa indirgenerek diğer sinir hücrelerine iletilmiş olunur. Bu açıdan, her gelen toplam sinyal ile dendrite iletilen sinyal arasında bir korelasyon (ilişki) oluşturulur. Buradan yola çıkılarak "öğrenme" işleminin sinapsislerde gerçekleştiği fikri ortaya atılmış ve bu hipotez, günümüz yapay sinir ağı dünyası için teori haline dönüşmüştür. Yapay sinir ağı modelleri üzerinde "öğrenme" bu teoriye dayanılarak, sinapsisler ve dendritler arasında yer alan ağırlık katsayılarının güncellenmesi olarak algılanmaktadır.

Taklit edilmeye çalışılan sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olur. Yani, insanlar doğumlarından itibaren yaşayarak öğrenme süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum yapay sinir ağları için de geçerlidir. Öğrenme, eğitme yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi/çıktı verilerinin

işlenmesiyle, yani eğitme algoritmasının bu verileri kullanarak bağlantı ağırlıklarını bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur. Ağırlıkların değişimi öğrenmeyi ifade eder. Yapay sinir ağlarında ağırlık değişimi yok ise öğrenme işlemi de durmuştur [10].

Benzer karakteristiğe sahip Yapay Sinir Ağları (YSA) işlemci elemanları katmanlar halinde yapılandırılırlar ve transfer fonksiyonları eşzamanlı olarak çalıştırılırlar. Hemen hemen tüm ağlar şu kısımlardan oluşur: girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış. Oluşturulan YSA' nın ana öğesi olan matematiksel fonksiyon, ağın mimarisi tarafından şekillendirilir. Daha açık bir şekilde ifade etmek gerekirse, fonksiyonun temel yapısını ağırlıkların büyüklüğü, öğrenme algoritması ve işlem elemanlarının işlem şekli belirler [37].

3.2. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay Sinir Ağlarının başlıca avantajları;

- Paralel olarak geliştirilmiş olmalarından dolayı hataya daha toleranslı olmaları ve bu sayede hızlı bir şekilde problem çözme kabiliyetine sahip olmaları.

- Uyarlamalı olarak tasarlanabilmeleri, daha önce öğrendiği bilgiyi eksik veya bozuk giriş verildiği zaman bile düzenlenmiş şekilde değerlendirebilmesi.

- Doğrusal olmayan bir yapıya sahip olmaları nedeniyle doğrusal olmayan problemlere daha doğru çözümler getirebilmeleri.

- Büyük ve karmaşık yapıdaki veri setleri için çözüm elde etme özelliğine sahip olması.

- Herhangi bir dağılım şartı bulunmaması.

- Çok değişkenli doğrusal olmayan problemlere uygulanabilmesi.

- Bağımlı ve bağımsız değişkenler arasındaki karmaşık doğrusal olmayan ilişkileri tespit edebilmesi.

- Tahmin edici değişkenler arasındaki tüm olası etkileşimleri tespit edebilmesi.

- Ayrıca yapay sinir ağlarının gerçek dünya problemlerine adapte edilebilir olması da avantajlarından bir tanesidir [9].

Yapay sinir ağlarının avantajlarının yanı sıra hala tartışılan bazı kısıtlamaları bulunmaktadır;

- Sinir ağı dizaynı için bilinen en iyi yöntemleri yoktur.

- Sinir ağı verilere ve uygulamalara son derece bağımlıdır. Bağımlılık problemi henüz ilerisi için görünür çözümlere sahip değildir. Araştırmacıların odaklandığı ve çeşitli topolojilerde ve farklı veri modellerinde çalıştıkları sayısız testlerdeki çabalara rağmen sonuçlar hala belli durumlarda çok bağımlıdır.

- Yapay sinir ağları iyi eğitilmiş olmak için çok geniş sayıda geçmiş durumlar istemektedir. Birçok karışık ağda güvenirlilik azalabilir. Bu yüzden çeşitli ağ çalışmaları için yapılan çözümler daha fazla deney sonucu istemektedir. Genellikle sonuçlar, sinir ağlarının güvenirliliği için istatistiksel uygunluklara ihtiyaç duymaktadır [18].

- Sinir ağları insan beyninin işleyiş şeklinden yola çıkmış olsa da henüz beynin hızına ulaşamamasına rağmen, karmaşık eşleştirmelerin hassas bir biçimde gerçeklenebilmesi ve yapısal büyüklüğe sahip olmaları nedeniyledir ki gün geçtikçe uygulama alanları genişlemektedir [19].

3.3. Sinir Ağlarında Öğrenme Algoritmaları

Öğrenme süreci iki esas prensip altında meydana gelmektedir; "Danışmanlı Öğrenme" ve "Danışmansız Öğrenme". Yapay sinir ağları temelde bu iki öğrenme metodundan ya birini ya da hibrit denilen karma modeli kullanır.

Giriş ve çıkış bilgilerinin nasıl sunulacağı veya nasıl kodlanacağı bir ağı başarılı bir şekilde yönlendirmek için önemli bir unsurdur. Yapay sinir ağları sadece sayısal giriş bilgileri ile çalışırlar [24].

Eğitim işlemi sırasında her bir eğitim bilgisi çifti için oluşan hata değerine göre ağırlıkların değiştirilmesine "artımlı tip" öğrenme, tüm eğitim kümesi için hataların toplanarak toplam hata değerine göre ağırlıkların değiştirilmesine ise "yığın tipi" öğrenme denilmektedir.

3.3.1. Danışmanlı öğrenme

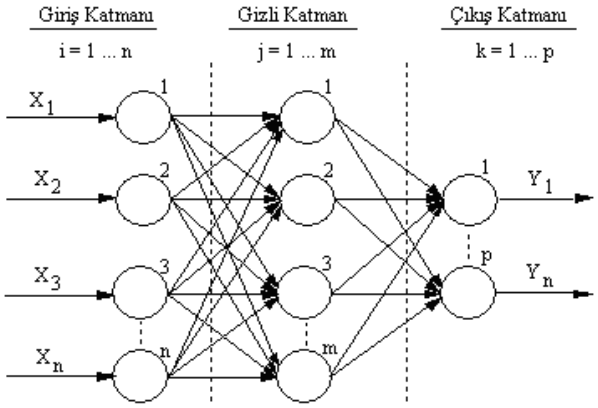
Danışmanlı eğitim sürecinde, Yapaya Sinir Ağları (YSA) bir giriş vektörü ile beslenir ve YSA çıkışı hedef vektörü ile karşılaştırılır. Giriş ile çıkış vektörü arasında bir farkın olması durumunda YSA' nın ağırlık katsayıları küçük miktarlarda değiştirilerek çıkışta üretilen hatanın minimize edilmesi sağlanır. Bu süreç farklı giriş-çıkış vektör çiftleri için defalarca tekrarlanarak YSA' nın arzu edilen çıkışları vermeyi öğrenmesi sağlanır [122].

Danışmanlı öğrenmede hem girdi hem de çıktı veriler kullanılır. Öncelikle, ağ rastsal olarak belirlenen başlangıç ağırlıklarını kullanarak girdileri işler ve çıktıyı istenilen çıktı ile karşılaştırır. Girilen değerle istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değerin altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Elde edilen hatalar sistem içinde geriye gönderilir ve bu hatalar kullanılarak ağı kontrol eden bağlantı ağırlıkları güncellenir [11].

Eğitme işlemi doğru bir şekilde tamamlandığında, yani hem daha fazla öğrenmeye gerek kalmamış hem de aşırı eğitme yapılmamışsa, istenildiği takdirde ağırlıklar dondurulabilir. Bazı sistemler ise kullanılırken de öğrenmeye devam edebilirler.

Bazı ağlar öğrenme işlevini hiç yapamayabilir. Bunun sebebi girdi verinin istenen çıktıya ait belirli bir bilgi taşımaması olabilir. Ayrıca, tam öğrenmeyi sağlayacak kadar yeterli veri olmaması durumunda ağ yakınsamayabilir. İdeal olarak, gerekli testlerin yapılabilmesi için veri setinin bir bölümünün ayrılabileceği kadar geniş bir

veri seti gereklidir. Fazla sayıda işlem elemanı içeren çok tabakalı ağlar veri için hafıza oluşturabilme yeteneğine sahiptirler. Ağın hafızaya alma sürecinin yeterli olup olmadığının gözlenebilmesi için ise danışmanlı öğrenmede veri setinin bir bölümü, eğitme sonrasında gerekli testlerin yapılabilmesi için ayrılmalıdır [11].



Şekil 3.2: Danışmanlı öğrenme örneği [11]

Danışmanlı öğrenme yönteminde üç farklı katman ile öğrenme gerçekleşmektedir. Bunlar "Giriş Katmanı", "Gizli Katman" ve "Çıkış Katmanı" olarak adlandırılmaktadır.

3.3.2. Danışmansız öğrenme

Danışmansız öğrenme ayrıca uyarlamalı öğrenme olarak da adlandırılır. Bu öğrenme yaklaşımında, ağa girdi sağlanır ama istenilen çıktı değerler sağlanmaz. Sistem girdi veriyi gruplandırmak için hangi özellikleri kullanacağına kendi kendisine karar verir ki bu yöntem kendi kendine öğrenme veya adaptasyon olarak bilinir. Ayrıca, bu ağın bağlantı ağırlıkları için başlangıç değerleri verilmelidir ve girdi değerler normalize edilmelidir [11].

Danışmansız öğrenmeye Hebbian Öğrenme, Grossberg Öğrenme, Kohonen' in Öz Örgütlemeli Harita Ağı örnek olarak verilebilir. Kohonen tarafından geliştirilen danışmansız öğrenme yönteminin kullanıldığı Öz Örgütlemeli Harita' da biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Bu yöntemde sinirler öğrenmek için elverişli durum ya da ölçülerini güncellemek için yarışırlar. En büyük çıkış ile işlenen sinir kazananı belirler ve komşularına bağlantı boyutlarını güncellemeleri için izin verir. Danışmansız öğrenmede ağ istenen dış verilerle değil girilen bilgilerle

çalışır. Bu tür öğrenmede gizli sinirler dışarıdan yardım almaksızın kendilerini örgütlemek içim bir yol bulmalıdırlar. Bu yaklaşımda verilen giriş vektörleri için önceden bilinebilen performansını ölçebilecek ağ için hiçbir çıkış örneği sağlanmaz yani ağ yaparak öğrenmektedir [24]. Danışmansız öğrenme sürecinde çıkış vektörünün bilinmesine gerek yoktur [122].

4. YAPAY SİNİR AĞLARINDA KÜMELEME VE ÖZ ÖRGÜTLEMELİ HARİTALAR

Kümeleme çalışmalarında, klasik istatistiksel yöntemler yerine Yapay Sinir Ağları (YSA) kullanılabilir. YSA, veriler için dağılım varsayımlarına gerek duymaz. Bir veri setindeki eleman ve değişken sayısının çok fazla olması sinir ağları için bir zorluk yaratmaz. Kümeleme çalışmalarında en çok kullanılan yapay sinir ağları Öz Örgütlenmeli Haritalar (Self-Organized Map-SOM) sinir ağlarıdır.

Bu ağlar, girdilerindeki düzenlilikleri ve korelasyonları tespit etmeyi ve bu girdiye göre ileride verecekleri tepkilerini uyarlamayı öğrenebilir. Rekabetçi ağların nöronları, benzer girdi vektörlerinin guruplarını tanımayı öğrenebilir. SOM' un nöron katmanında fiziksel olarak birbirinin yanında olan nöronların benzer girdi vektörlerine tepki vermesiyle benzer girdi vektörlerini tanımayı öğrenebilir. SOM' un amaçları girdi vektörlerini benzer vektör kümelerine bölmek olduğu için hedef vektörlere sahip değildir. Bu tip ağlar için istenen bir çıktı yoktur [130].

SOM ağında giriş katmanına ek olarak birbiriyle topolojik olarak ilişkili sinirlerden oluşan tek bir çıkış katmanı vardır. Her bir giriş, çıkış katmanındaki her bir sinire bağlıdır. Ağ rastgele ağırlıklarla çalışmaya başlar. Herhangi bir giriş uygulandığında, giriş vektörüne uzaklığı en az olan sinir seçilir ve bu sinire gelen bağlantı giriş ağırlıkları giriş vektörüne yaklaşacak şekilde yenilenir. Bu kazanan sinirle birlikte onun topolojik komşuluğunda bulunan belli sayıda sinire gelen ağırlıklar da benzeri şekilde değiştirilir [24].

SOM yapısı kolayca açıklanabilir, basit ve belki de en önemlisi görselleştirmesi kolaydır. Çok boyutlu verinin görselleştirilmesi genelde iki boyutlu olarak yapılır [39]. Tabi ki istisnalar da vardır. Örneğin, Kivilioto başarılı şekilde üç boyutlu harita (eşlem) ızgaralarını görselleştirmiştir [40].

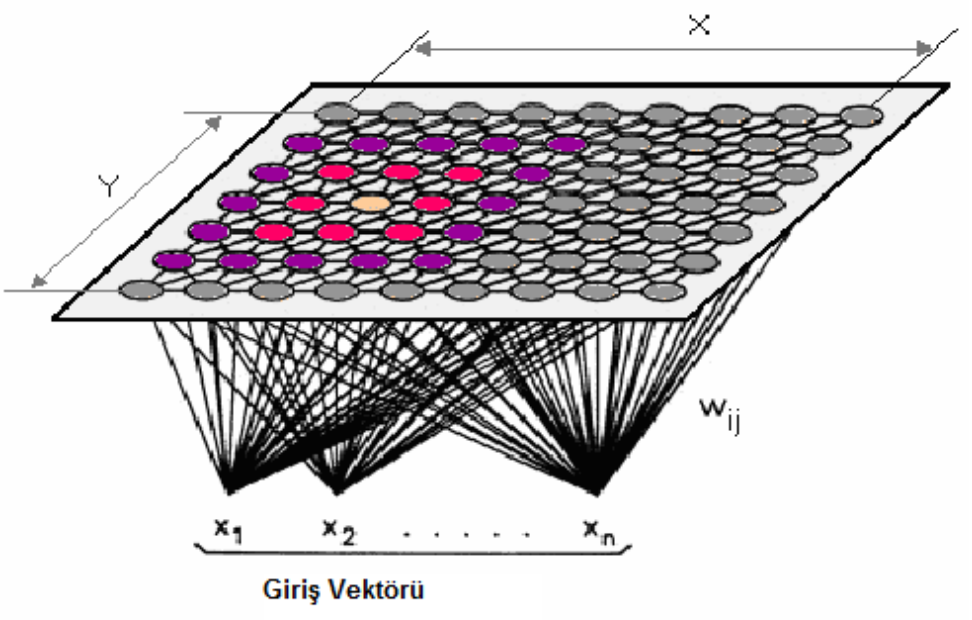
SOM, klasik istatistikteki K-Ortalama ile çok boyutlu ölçekleme yöntemlerinin her ikisinin de işlevlerini yerine getirebilir. Yani, veri setindeki elemanları hem kümelendirir hem de haritalandırır.

4.1. Öz Örgütlemeli Harita Topolojisi

Öz Örgütlenmeli Haritalar (Self-Organized Map-SOM) sinir ağının topolojik yapısı Şekil 4.5.1' de görülmektedir. Bu ağ iki katman ve işlem elemanlarından oluşur. İlk katman giriş katmanı ve diğer katman çıkış katmanıdır. Çıkış katmanı iki boyutlu yapıdadır. Giriş katmanı ise dağıtım katmanı gibi davranır.

Temelde SOM, düzgün düşük boyutlu, genellikle bir veya iki boyutlu ızgarada bulunan nöronlarından oluşur. Daha yüksek boyutlu ızgaralar mümkündür, fakat bunlar genellikle kullanılmaz çünkü görselleştirilmeleri problemlidir.

Giriş katmanı haritanın oluşturulmasında kullanılacak parametre sayısı kadar düğüme sahiptir. Her bir giriş düğümü çıkış katmanını oluşturan tüm düğümlere bir ağırlık katsayısı ile bağlıdır. Çıkış katmanındaki düğümlerin sayısı keyfi olarak seçilir. Çıkış katmanındaki her bir düğüm kafes örgüde topolojik bir konuma sahip olup giriş vektörü ile eş boyutlarda bir ağırlık vektörüne sahiptir [123].



Şekil 4.1: Öz Örgütlemeli Harita ağının topolojik yapısı[37]

Giriş nöronlarının sayısını veri setindeki değişken sayısı belirler. Çıkış nöronlarının her biri, bir kümeyi temsil eder. Diğer yapay sinir ağlarından farklı olarak, çıkış katmanındaki nöronların dizilimi çok önemlidir. En çok dikdörtgensel ve altıgen şeklindeki dizilimler tercih edilmektedir. Pratikte, çoğu kez dikdörtgensel dizilim karesel dizilim olarak uygulanır. Buradaki dizilim topolojik komşuluk açısından önemlidir. Aslında, çıkış nöronları arasında doğrudan bir bağlantı yoktur. Giriş nöronları ile her bir çıkış nöronu arasındaki bağlantıyı referans vektörleri gösterir. Bu vektörler bir katsayılar matrisinin sütunları olarak da düşünülebilir. Öz Örgütlemeli Harita ağları eğitilirken bu topolojik komşuluk referans vektörlerinin yenilenmesinde kullanılır [122].

SOM girdi alanında nasıl gruplandıklarına göre girdi vektörlerini sınıflandırmayı öğrenmektedir. SOM komşu nöronların giriş alanının komşu kısımlarını tanımayı öğrenme konusunda rekabetçi katmanlardan farklılık gösterir. Böylece, SOM eğitildikleri girdi vektörlerinin hem dağılımını (rakip katmanların yaptığı gibi) hem de topolojisini öğrenir [130].

4.2. Öz Örgütlenmeli Haritaların Avantajları ve Dezavantajları

Öz Örgütlenmeli Haritalar' ın (Self-Organized Map-SOM) amacı ayrılmış bir yüzey veya çizgi üzerinde verinin yerel olarak sıralanmış bir eşleştirmesi (haritalanması) oluşturmaktır. Görselleştirme faydalarına ek olarak, SOM' un öncelikli faydaları şunlardır:

- Sağlamlık: Komşuluk işlevi, tüm referanslar tüm veri örneklerinden etkilenir.

- Yerel ayar: Topolojik sıralama öncelikli olarak her harita biriminin komşuluğunda çalışır ve bu yüzden yerel olarak veri yoğunluğuna uyumlu olur.

- Görselleştirme kolaylığı: Düzenli harita ızgarası, etkili görselleştirmeler ve kullanıcı ara yüzleri oluşturmayı kolaylaştırır.

Yukarıdaki faydaların çoğu komşuluk ilişkilerinden dolayıdır. Komşuluk SOM' un yapısını oluşturmak için faydalıdır. Ancak, aynı zamanda komşuluk etkisi üç yan etkiye sahiptir.

- Sınır etkisi: Komşuluk tanımı haritanın sınırlarında simetrik değildir. Bu yüzden, yoğunluk tahmini, sınır birimleri için haritanın merkez birimleri için olandan farklıdır.

- Daralma: Değişken değerlerin aralığı daralır. Vektörel niceleme işlemi tarafından yapılan ve komşuluk işlevi tarafından geliştirilen ortalama, uç değerlerin ortalamasını alır. Eğer uç değerler analiz açısından ilginç ise bazı durumlarda istenmeyen bir yan etki olabilir.

- Ara değerleme birimleri: Veri devamlı değilse, ara değerleme birimleri, veri dağıtımının uygun dış değerlemeli tahminleri sağlayan veri kümeleri arasında konumlandırılır. Ancak, bazı analiz araçları olduğu takdirde, örneğin tek bağlantı kümelenmesi, bunlar veri çeşitliliğinin şekli konusunda yanlış ipuçları verebilir ve vurgunun kaldırılması veya tamamen hariç tutulması gerekebilir [42].

4.3. Öz Örgütlemeli Haritaların Özellikleri

- Genellikle sınıflandırma problemleri için kullanılmaktadır.

- Yüksek boyutlu haritadaki verileri, iki boyutlu haritaya dönüştürülebilmekte ve farklı haritalama seçenekleri ile kullanılabilmektedirler.

- Girdi uzayındaki komşuluk ilişkileri korunmakta ve bu şekilde harita komşuluk ilişkilerine göre oluşmaktadır.

- Danışmansız öğrenme algoritmasıdır. Bu nedenle beklenen çıktıların belirlenemediği problemler ve sistemler için idealdirler.

- İleri ya da geri besleme şeklinde tasarlanabilirler. Yarışmayı kazanma esasına göre şekillenirler; kazanan eleman 1, diğerleri 0 değerini alır ve ağırlıklar güncellenir.

- Girdi değerleri harita katmanına ulaşır ve dizilim oluştururlar.

- Girdiler belirli bir bölgede yoğunlaşır, bu kazanan sinir hücresidir. Bu sinir hücresine ait alan, aktivasyon alanıdır ve öğrenme esnasında değişir.

- İki nesne arasındaki bağın kuvvetliliğinden yararlanılarak ağ yapılanır.

- Komşuluk hesapları genelde öklid mesafesi (uzaydaki iki nokta arasındaki mesafe) uyarınca hesaplanır.

4.4. Öz Örgütlenmeli Harita Öğrenme Algoritması

Öz Örgütlenmeli Haritalar (Self-Organized Map-SOM) ağlarında kullanılan öğrenme algoritması bu ağlara ismini de veren, Kohonen algoritmasıdır, kullanılan öğrenme algoritması danışmansızdır. Yani, ağ eğitilirken bağımlı değişken kullanılmaz. Veri setindeki giriş vektörleri ağa girildikçe ağ kendi kendini düzenler ve Ağırlık Referans Vektör değerleri oluşur [21].

Kohonen kuralı, bir nöronun ağırlıklarının girdi vektörünü öğrenmesine izin verir ve bundan dolayı tanıtma uygulamalarında faydalıdır. Böylece, ağırlığı girdi vektörüne en yakın olan nöron daha da yakın olacak şekilde güncellenir. Sonuç, bir dahaki sefere benzer bir girdi vektörü sunulduğunda kazanan nöronun kuvvetle muhtemel yarışmayı kazanması ve çok farklı bir vektör sunulduğunda daha az olasılıkla yarışmayı kazanması olacaktır. Daha fazla sayıda girdi sunuldukça, bir girdi vektörleri gurubuna yakın katmandaki her nöron ağırlık vektörünü kısa sürede bu girdi vektörlerine doğru ayarlar. Nihayet, yeterli nöron bulunması durumunda, girdi vektörleri diğer zamanlarda 0 çıktı verirken, benzer bir vektör sunulduğunda, 1 çıktısı veren bir nörona sahip olacaktır. Bu şekilde rekabetçi ağ yapısı girdi vektörlerini kategorize etmeyi öğrenir [130]. Kohonen ağlarında kullanılan öğrenme algoritması aşağıda verilmiştir.

Bu algoritmada kullanılan semboller:

w_{ij}: i. satır j. sütundaki çıkış nöronuna ait referans vektörü.

x: Giriş vektörü.

D(i,j) : x vektörünün (i,j) koordinatındaki çıkış nöronuna olan öklid uzaklığının karesi. Uzaklık hesaplama yöntemi olarak farklı yöntemler seçilebilir.

I, J: x vektörünün en yakın olduğu çıkış nöronun koordinatları.

α : öğrenme katsayısı.

Algoritma:

0. w_{ij} katsayılarına ilk değer ata.

Topolojik komşuluk parametrelerini belirle.

Öğrenme katsayı parametrelerini ayarla.

1. Bitiş şartı yanlışken adım 2-8 i takip et.

2. Her bir x giriş vektörü için adım 3-5 i takip et.

3. Her bir i,j için $D(i,j) = \sum_{ij}(w_{ij} - x)^2$ öklid uzaklık değerlerini hesaplanır.

4. D(I,J)' nin minimum olduğu I, J değerini bul. Bu değere BMU denir.

5. I, J' nin belirtilen komşuluğundaki bütün çıkış nöronları için

w_{ij} (yeni)= w_{ij} (eski)+ α (x- w_{ij}) (eski)

6. Öğrenme katsayısını güncelle.

7. Belirtilen zamanlarda topolojik komşuluk parametresini azalt.

8. Bitiş şartını kontrol et.

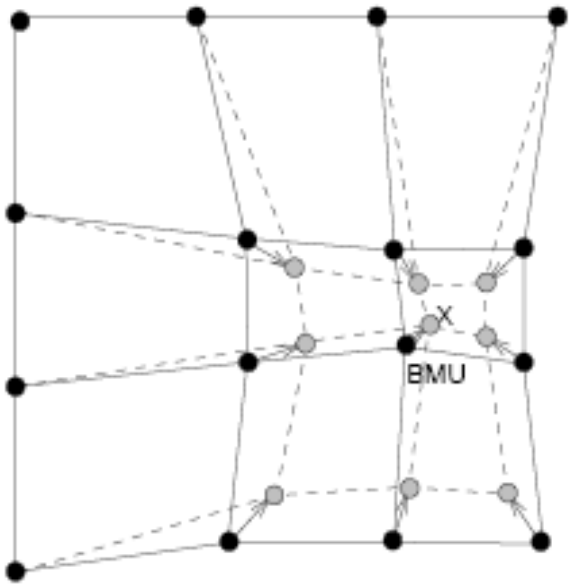
SOM algoritmasında referans vektörlerinin öğrenilmesini etkileyen bir diğer önemli faktör de öğrenme katsayısıdır(α). Algoritmada yeni katsayılar aşağıdaki formüle göre hesaplanmaktadır:

wij (yeni)= wij (eski)+ α (x- wij) (eski)

Bu formülden de anlaşılacağı gibi yeni katsayılar giriş değerleri ile eski katsayılar arasındaki farkın öğrenme katsayısı ile çarpılıp eski katsayıya eklenmesi ile bulunmaktadır. Genelde öğrenme katsayısı 0 ile 1 arasında bir değerdir. Döngü sayısı arttıkça, bu değer belli bir oranda azaltılmalıdır. Aksi takdirde, katsayılardaki değişim sürekli devam edecektir. Bu da sonsuz döngüye neden olur. Bazı çalışmalarda, öğrenme katsayısı yerine sürekli azalan ve 0 ile 1 arasında değer alan bir fonksiyon kullanılmıştır [122,125].

Şekil 4.2' de SOM' da Kazanan Nöron (Best Matching Unit- BMU) hesaplanması görsel olarak temsil edilmiştir. Bu hesaplamada X ve tüm referans vektörleri arasındaki mesafe hesaplanır. Daha sonra, vektörler güncellenir. D(I,J)' nin

minimum olduğu I, J ve onun topolojik komşuları gösterildiği gibi giriş boşluğundaki giriş vektörüne daha yakın olacak şekilde hareket ettirilir [122,125].

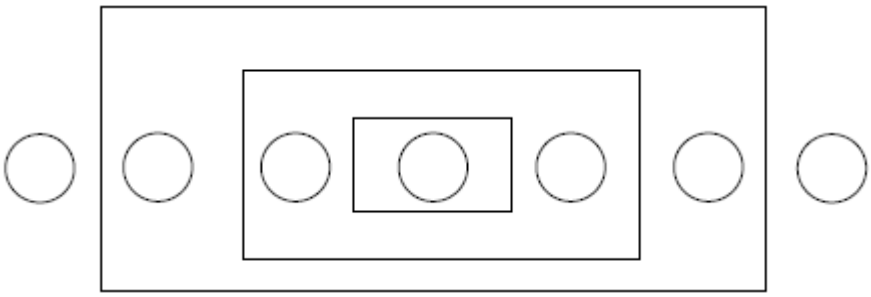


Şekil 4.2: Öz Örgütlemeli Harita Kazanan Nöron hesaplanması

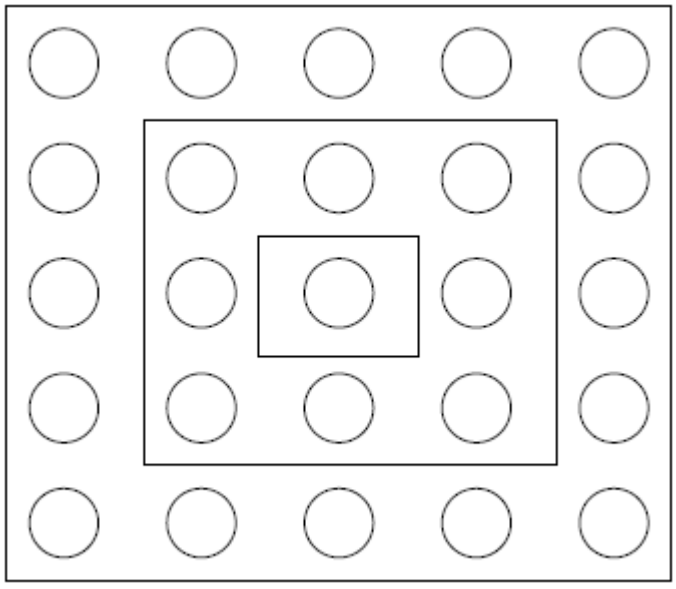
Yukarıdaki algoritmadan da anlaşılacağı üzere, ilk önce referans vektörlerine bir ilk değer verilir. Döngüye başlamadan önce öğrenme katsayısı (α) ve komşuluk değişkenine (R) yüksek bir değer atanır. α' ya genelde 0 ile 1 arasında bir değer atanır. Bu değerin 1' e yakın olması tercih edilir. Algoritma için bir döngü veri setindeki tüm satırların birer kere SOM ağına girdi olarak sunulmasıdır. Veri setinin bir satırı x vektörüdür, x vektörünün çıkış katmanındaki her bir nörona olan öklid uzaklığının karesi bulunur. Çıkış katmanındaki her bir nöronu bir referans vektörü (w_{ij}) temsil eder. Dolayısıyla, bu uzaklık x vektörü ile w_{ij} arasındaki uzaklıktır. Hesaplanan uzaklıklardan en küçüğü bulunur. Bu uzaklık hangi çıkış nöronuna aitse o nöron kazanan nörondur. Yani, SOM ağları "yarışmacı" bir ağdır [122].

Kazanan nöron ve komşu nöronların referans vektörleri yeniden hesaplanır. Şekil 4.3' de kazanan nöronun doğrusal komşuluğu ve Şekil 4.4' de kazanan nöronun dikdörtgensel komşuluğu görülmektedir. Bu şekillerden de görüldüğü gibi, dikdörtgensel komşulukta kazanan nöronun etrafında daha fazla komşu nöron bulunmaktadır. Burada, x vektörü ile w_{ij} referans vektörü arasındaki fark, öğrenme katsayısı α ile çarpılır ve w_{ij} referans vektörüne ilave edilir. Bu sebeple, w_{ij} referans

vektörlerine ilk değer olarak çok küçük değerler verilmişse α değeri 1’ e yakın bir değer alınmalıdır. Böylece, referans vektörleri kendilerini oluşturma şansına sahip olurlar. Böylece, veri setindeki tüm satırlar için bu işlemler tekrarlandığında bir döngü tamamlanmış olur. Döngüler devam ettikçe referans vektörleri değişmeye devam eder. Döngünün belirli periyotlarında α ve R değerleri azaltılır. Kaç döngüde bir bu değişkenlerin azaltılacağı kesin kurallara bağlanmamıştır. Bu konuda değişik görüşler vardır. Çoğu zaman bu değişkenlerin doğrusal bir fonksiyonla azaltılması yeterli olur. Referans vektörlerindeki değişim sona erdiğinde döngü de sona ermiş olur [122].



Şekil 4.3: Kazanan nöronun doğrusal komşuluğu [122]



Şekil 4.4: Kazanan nöronun dikdörtgensel komşuluğu[122]

Şekil 4.3 ve Şekil 4.4’ de görüleceği üzere Öz Örgütlenmeli Harita algoritması, yalnızca kazanan nöronu güncellemek yerine, kazanan nöronun belli bir komşuluğu

civarındaki tüm nöronlar Öz Örgütlenmeli Harita Öğrenme Kuralı **(**Kohonen) kuralı kullanılmak suretiyle günceller [130].

4.4.1. Öz örgütlemeli harita sapma öğrenme kuralı

Rekabetçi ağların sınırlamalarından biri bazı nöronların daima tahsis edilememesidir. Diğer bir deyişle, bazı nöron ağırlık vektörleri girdi vektörlerinden uzakta çıkabilir ve ne kadar süreyle eğitildiği hiç fark yaratmadan yarışmayı asla kazanamayabilir. Başka bir ifadeyle ağırlıkları asla öğrenemez ve asla kazanamazlar. Ölü nöronlar olarak adlandırılan bu şanssız nöronlar asla faydalı bir fonksiyon yerine getiremez. Buna son vermek için yalnızca sık kazanan nöronlar üzerinde bir avantaj olarak yarışmayı nadiren kazanan (kazanmışsa) nöronları verecek sapmalar kullanılabilir. Negatif uzaklığa eklenen pozitif bir sapma uzak bir nöronun kazanmasını daha muhtemel hale getirebilir. Bu durumu oluşturabilmek için nöronların çıktılarının ortalaması hesaplanır. Bu Ortalama Sapma Öğrenme Kuralı sapmaları güncellemek için kullanılmaktadır, böylece sık aktif nöronların sapması daha küçük hale gelir ve seyrek olarak aktif olan nöronların sapmaları daha büyük hale gelmektedir. Seyrek olarak aktif olan nöronların sapmaları büyüdüğünden dolayı, bu nöronlardaki girdi alanı büyüme tepkisi verir. Girdi alanı büyüdüğü için seyrek olarak aktif olan nöronlar tepki verir ve girdi vektörlerine doğru hareket eder.

Sonuç olarak, nöron, diğer nöronlar gibi aynı sayıda vektöre tepki verir. Bu durum iki iyi etkiye yol açar.

İlk olarak, bir nöronun ağırlığının girdi vektörlerinden uzak olmasından dolayı hiçbir yarışma kazanamaması durumunda, sapması er geç kazanmasına yeterli olacak kadar genişler. Bu durum meydana geldiğinde, bazı girdi vektörleri guruplarına doğru hareket ederler. Nöronun ağırlığı bir girdi vektörü gurubuna hareket edince ve nöron sürekli biçimde kazanınca, sapması 0’ a inecektir. Böylece, ölü nöronlar problemi çözümlenebilmektedir.

Sapmaların ikinci avantajı her nöronu girdi vektörlerini sınıflandırmaya zorlamasıdır. Bu şekilde, bir girdi alanının herhangi bir bölgesi, başka bir bölgeye kıyasla daha

fazla sayıda girdi vektörleriyle bağlanması halinde, daha sık bir şekilde doldurulan bölge daha fazla nöronu çekecek ve daha küçük alt kısımlarda sınıflayacaktır [130].

4.4.2. Öz örgütlemeli harita modelinde sınıflandırmayı etkileyen faktörler

Ağ yapısı ve öğrenme algoritması belirlenen bir Öz Örgütlenmeli Haritalar (Self-Organized Map-SOM) modelinde başarılı bir sınıflama çalışması gerçekleştirebilmek için bazı faktörlere dikkat etmek gerekir. Ancak, bunlar kesin kurallara bağlı değildir. Çoğu kez deneme yanılma yoluyla bu faktörler için en iyi değerler bulunur [124].

Bu faktörler şunlardır:

- Çıkış katmanındaki nöron sayısı: Çıkış katmanındaki nöron sayısı, elde edilebilecek maksimum küme sayısını belirtir.

- Verilerin normalleştirilmesi: Veri setindeki değişken değerleri arasında büyük farklar varsa değerler normalleştirilmelidir. Böylece, tüm değişkenlere eşit şans verilmiş olur. Sütun bazında yapılan normalleştirme üç şekilde yapılabilir:

  Her bir sütundaki değerler sütun standart sapmasına bölünür.

  Her bir sütundaki değerlerden sütun ortalaması çıkartılıp çıkan sonuç sütun standart sapmasına bölünür. Böylece, ortalaması 0 standart sapması 1 olan standart dağılım elde edilir.

  Her bir sütundaki değerler diğer sütun vektör uzunluğuna bölünür [122].

- Referans vektörlerine ilk değer atanması: Referans vektörlerine ilk değer atanması, SOM modelinde çok kritik bir yere sahiptir. Bu ilk değerler atanırken veri setindeki giriş vektör değerleri göz önünde bulundurulmalıdır. Pratikte, referans vektörlerine rastgele değerler atamak bazen sakıncalı olabilir. Tüm vektörlere 0' dan çok az büyük bir değer atanırsa öğrenme katsayısı 1' e yakın bir değerle başlatılmalı ve belli bir döngü boyunca azaltılmamalıdır. Ayrıca, komşuluk değişkeni büyük bir değerle başlatılmalı ve öğrenme katsayısının değişmediği periyotta sabit kalmalıdır. Böylece, referans vektörleri giriş vektörlerine uygun bir forma kavuşurlar. Referans

vektörlerine, giriş vektörlerinin dağılımına uygun bir ilk atama yapıldığında öğrenme katsayısı ve komşuluk değişkeni daha küçük bir değerle başlatılabilir. Bu da algoritmanın öğrenme hızını artırır [122].

- Uzaklık ölçüsü: Öz örgütlemeli harita algoritmasında giriş vektörleriyle referans vektörleri arasındaki uzaklık Öklid uzaklığının karesi ile ifade edilmektedir. Ancak, Öklid uzaklığı yerine başka uzaklık ölçüleri de kullanılabilir: Minkowski ölçüsü, City-Block uzaklığı, Manhattan uzaklık, Bağlantı uzaklık gibi [122].

- Öğrenme katsayısı ve Komşuluk değişkeni: Öğrenme katsayısı 0 ile 1 arasında bir değerle başlamalı ve döngü arttıkça 0' a yaklaşmalıdır. Komşuluk değişkeni, çıkış katmanındaki dizilime uygun büyük bir değerle başlamalı ve döngü ilerledikçe azaltılmalıdır. Bu değişkenler genellikle lineer olarak azalan fonksiyonlarla temsil edilir [122].

4.4.3. Öz Örgütlemeli Harita' nın bazı türevleri

Yığın Haritası: Yığın Haritası öğrenme oranının kullanılmadığı Öz Örgütlemeli Haritalar Algoritması' nın (Self-Organized Map-SOM) bir versiyonudur. Aynı zamanda bu algoritma tekrarlıdır, fakat bir seferde tek bir veri vektörü kullanmak yerine bütün veri seti herhangi bir ayarlama yapılmadan önce haritaya sunulur. Bu yüzden ismi "Yığın"dır. Her eğitme aşamasında, veri seti harita ağırlık vektörlerine göre bölümlenir, yani her veri vektörü ona en yakın olan harita biriminin veri setine aittir. Bundan sonra, yeni ağırlık vektörleri hesaplanır. Yeni ağırlık vektörü veri örneklerinin ağırlıklı bir ortalamasıdır [43].

Ağaç Yapılı SOM: Klasik SOM' un yeni bir versiyonudur. Her biri verinin tam bir nicelemesi olan bir dizi tabakadan oluşur. Tabakalar arasındaki farklılık referansların sayısının aşağıya doğru geçiş yaptırılırken üssel olarak artmasıdır. Örneğin, ilk tabaka sadece 4 referans vektörüne sahiptir, ikincisi 16, üçüncüsü 64, vs. bu yüzden bir tabakanın her referans vektörü bir sonraki tabakada dört katına sahip olur. Üst tabakalardan sonrakilerin eğitiminde faydalanılır. Verilen bir veri vektörünü diyelim ki tabaka 3' ün tüm referans vektörleriyle karşılaştırmak yerine, öncelikli olarak ilk tabaka referanslarla karşılaştırılır, daha sonra birinci tabakanın ilk ve komşularının

türdeşleri ile karşılaştırılır şeklinde süreç devam eder. Mesafe hesaplarının sayısı daha düşük tabakalarda azaltılır. Aynı zamanda, tabakalar her bir seferde bir tane eklenir ve böylece gittikçe daha detaylı bir veri eşleştirmesi edinilebilir [53, 54].

Artan Hücre Yapıları: Algoritmada uyumluluk bir adım öteye götürülmüştür. Sabit bir referans vektör sayısına sahip olmak yerine, algoritma yalnızca iki ile başlar ve daha sonra hata işlev ölçütlerine göre yeni vektörleri ekler. Komşuluklar yeni bir referans ağa eklendiği zamanda tanımlanır [56, 57].

4.4.4. Öz örgütlemeli harita sonuçlarının görselleştirilmesi

Öz Örgütlenmeli Haritalar (Self-Organized Map-SOM) hem vektörel görselleştirme hem de vektör izdüşümü algoritmalarının özelliklerine sahiptir. N eğitme örneklerinden M referanslara görselleştirme, orijinal veri seti ile birlikte çalışılacak daha küçük temsili bir sete indirgenmesidir. İndirgenmiş (azaltılmış) veri seti yalnızca eğer orijinal verinin gerçekte temsili ise geçerlidir [59-61]. İndirgenmiş (azaltılmış) bir veri seti kullanmanın öncelikli faydası kümelemenin karmaşıklığı azaltmaktır [64].

Görselleştirmenin amacı veri özelliklerinin nitel bir fikrini vermek için çok fazla miktarda detaylı bilgi sunmaktır. Genellikle etkili görselleştirme alan bağımlı değil aynı zamanda da kültür bağımlıdır. Her uygulamanın özel nitelikleri ve tarihsel gelenekleri ne tür görselleştirmelerin istenilen bilgiyi daha etkili ve güvenilir şekilde ileteceğini belirler. Gerçek görselleştirmeler veri örnekleri ve bunların özellikleri ve ilişkileri konusunda bilgi vermektir [106].

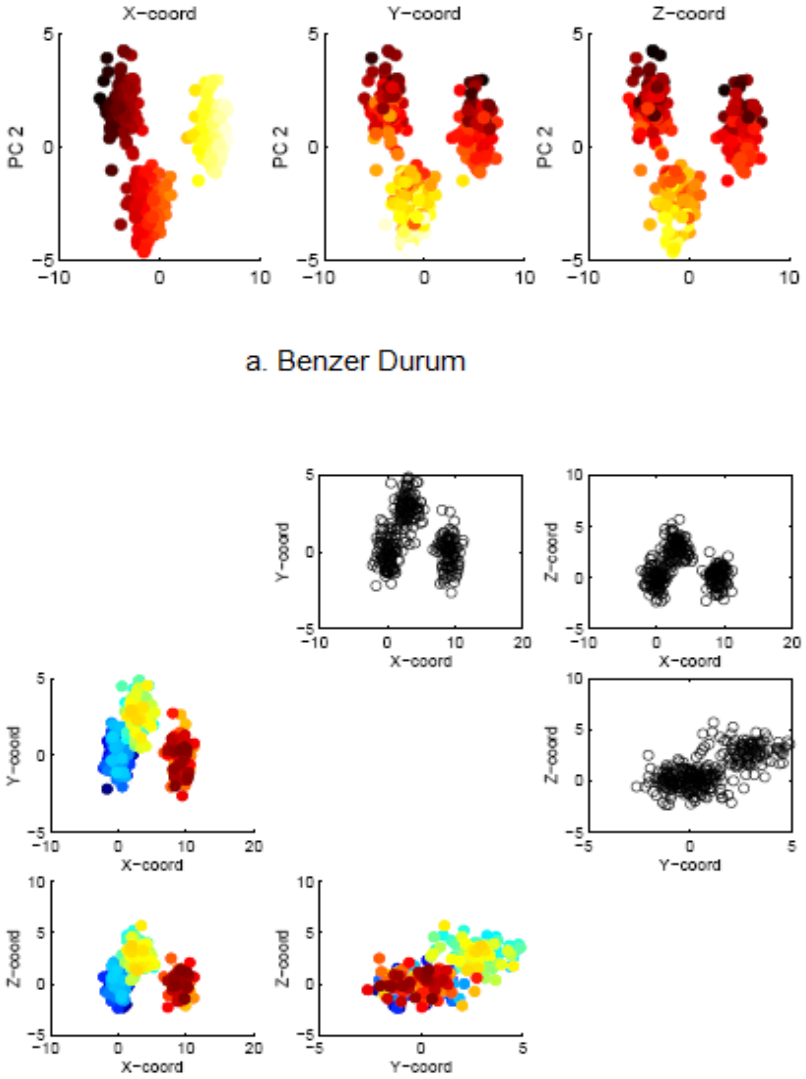
Çok boyutlu bilginin görselleştirilmesindeki problemlerden birisi görsel boyutların sınırlı olmasıdır. Görsel boyutlar farklı değerleri göstermek için kontrol edilebilen görselleştirmenin özellikleridir. Etkili olmak için, görsel boyutlarda ayırt edici özellikler öyle şekilde olmalıdır ki insan görsel sistemi bunları hızlıca ve az çabayla algılamalıdır [108].

Genel anlamda, görselleştirilmesi gereken özelliklerin sayısı, kullanılabilir görsel boyutların sayısından daha yüksektir. Ancak bunları tek bir figürde veya

görselleştirmede göstermek imkânsızdır. Çözüm birbirine bağlanmış birtakım görselleştirmeler kullanmaktır, böylece bir kişi aynı nesneyi farklı görselleştirmelerden tanıyabilir [107]. Birkaç görselleştirme aynı şekilde bağlayıp izlenmesi çok etkilidir, bunlar benzer bir yolda yorumlanır. Bu tür görselleştirmeler küçük katlar olarak adlandırılır [106].

SOM' un görselleştirilmesi için birtakım teknikler vardır. Amaçlarına bağlı olarak, üç gruba ayrılabilir: Küme yapısının ve şeklinin görselleştirilmesi, bileşenlerin görselleştirilmesi ve harita üzerindeki verinin görselleştirilmesi.

Şekil 4.5 (a)' da, üç Gauss tabakasının üç boyutlu bir veri seti üç küçük kat şeklinde sunulur. Katlar benzer konumda bağlanır. Renkler denk düşen değişken değerleri gösterir. (b)' de, her değişkenin diğerine karşı dağılım grafiğini gösteren altı küçük katı vardır. Renk kullanılarak bağlanır [60].



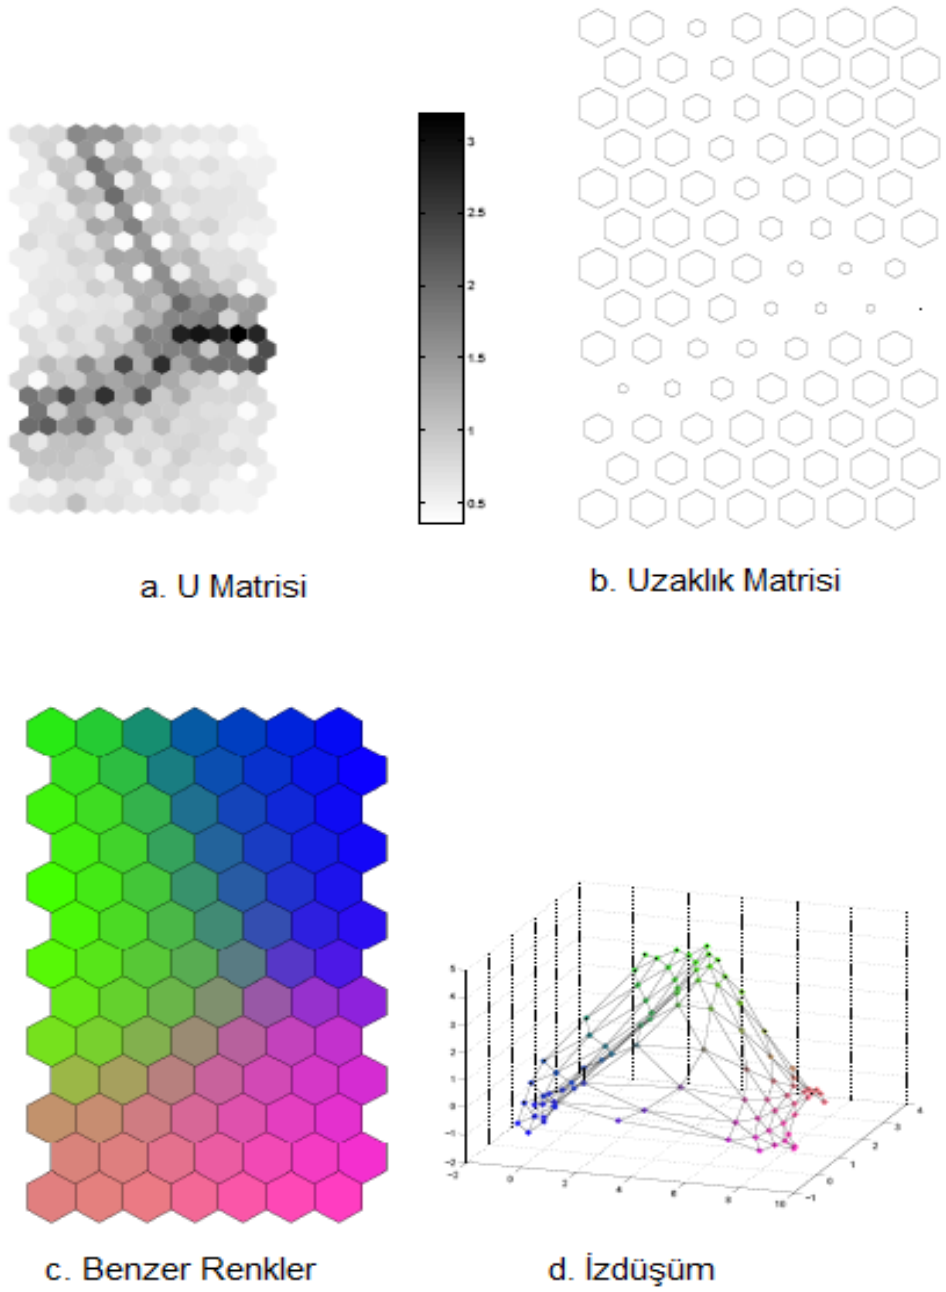
Şekil 4.5: Küçük katlardaki nesneleri bağlama [60]

4.5. Öz Örgütlemeli Haritada Mesafe Matrisleri

Öz Örgütlenmeli Haritalarda (Self-Organized Map-SOM) kümelerin ilişkisini belirlemek için en yaygın şekilde kullanılan görselleştirme tekniği mesafe matrisleridir. Bu matrisler komşu harita birimleri arasındaki mesafeleri temsil ederler. Mesafe matrisi ya harita birimleri ve onların en yakın komşuları arasındaki tüm mesafeleri U-matrisindeki [105] gibi tutar ya da sadece her harita birimi için tek bir değer tutar [104]. Mesafe matrisleri örneğin gri gölge kullanılarak görselleştirilebilir, fakat diğer teknikler de mümkündür [102,103].

Renk haritaları, benzer harita birimlerine benzer renkler vermektir [99-101], [99]' da tanıtılan yöntemleri bile orijinal verideki mesafeleri mümkün olduğunca sadık şekilde yansıtmak için renklerin algısal farklılıklarını dikkate alır. Bu renk haritaları kullanışlıdır, sadece bir kümeleme görselleştirmesi olarak değil, aynı zamanda küme yapısını dikkate alan renk kodlamaları oluşturmak için kullanılabilir. Renk kodlaması daha sonra farklı görselleştirmeleri birlikte yorumlamak için kullanılabilir [95, 96].

Değişkenler arasındaki olası karşılıklı ilişkileri belirlemek kolaydır. Bileşen yüzeylerini birbirleriyle karşılaştırarak, karşılıklı ilişkiler bileşen yüzeylerinin benzer konumlarındaki benzer şekiller olarak ortaya çıkartılır, bir değişkenin değerleri ne zaman değişirse, diğer değişken de değişir [97].



Şekil 4.6: Kümeleme görselleştirmeleri [60]

Şekil 4.6 (a)' da gri ölçek kullanılarak gösterilen değerlerle birlikte U-matrisi, (b) değerleri göstermek için altıgen ölçüsü kullanılarak mesafe matrisi, (c) benzerlik renklemesi, (d) üç boyutlu boşlukta harita ağı. (c) ve (d)' deki renkler birbirine uyar [60].

5. SİNİRSEL BULANIK SİSTEMLER

5.1. Bulanık Mantık

Bulanık mantık yaklaşımı ilk defa 1965 yılında Lotfi A. Zadeh tarafından yayınlanan bir makalede bulanık mantık veya bulanık küme kuramı adı altında ortaya konmuştur. Bu çalışmada insan düşüncesinin büyük çoğunluğunun kesin olmadığı, bulanık olduğu belirtilmiştir. Ayrıca Zadeh insanların denetim alanında mevcut makinelerden daha iyi olduğunu ve kesin olmayan dilsel bilgilere bağlı olarak etkili kararlar alabildiklerini savunmuştur [24].

Klasik mantık, "her önerme ya doğrudur ya da yanlıştır" varsayımına dayanarak hareket etmektedir. Oysa bazı önermelerin doğruluk değeri ölçümlerin temel sınırlamalarından dolayı belirsiz olabilmektedir. Bulanık mantık, klasik mantıkta iki önerme arasında belirsizlik adı verilen üçüncü bir önerme ortaya konmuştur. Böylece klasik iki değerli mantığın doğru ve yanlış olan doğruluk değerleri daha esnek hale getirilmiştir [12].

Bulanık mantık işlemleri, bir problemin analizi ve tanımlanması, değişken kümelerin ve mantık ilişkilerinin değiştirilmeden bulunan bilgilerin bulanık kümelere dönüştürülmesi ve modelin yorumlanması işlemlerinden oluşmaktadır.

Bir veya birden fazla denetim değişkeninin olduğu durumlarda ve sisteme ait matematiksel bir modelin bulunmadığı veya bulunsa da bunu kodlamanın zor olduğu durumlar ile gerçek zaman işlemleri için ayrıntılı hesaplamanın çok karmaşık olduğu durumlarda bulanık mantık uygulanabilir. Bulanık mantık algoritması her türlü problem için uygun olmayabilir. Başka bir modelin uygun olduğu durumda bulanık mantık kullanmak istenen sonucu her zaman vermeyebilir [13].

Bulanık mantığın genel özellikleri Zadeh tarafından şu şekilde ifade edilmiştir;

- Bulanık mantıkta, kesin değerlere dayanan düşünme yerine yaklaşık düşünme kullanılır.

- Bulanık mantıkta her şey [0,1] aralığında belirli bir derece ile gösterilir.

- Bulanık mantıkta bilgi, büyük, küçük, çok, az gibi dilsel ifadeler şeklindedir.

- Bulanık çıkarım işlemi dilsel ifadeler arasında tanımlanan kurallar ile yapılır.

- Her mantıksal sistem bulanık olarak ifade edilebilir.

- Bulanık mantık matematiksel modeli çok zor elde edilen sistemler için çok uygundur. Bulanık mantık, tam olarak bilinmeyen veya eksik girilen bilgilere göre işlem yapma yeteneğine sahiptir [24].

Bulanık mantığın diğer özelliklerine değinecek olursak;

Bulanık mantığın kavramsal olarak anlaşılması kolaydır. Bulanık akıl yürütmenin ardındaki matematiksel kavram çok basittir. Bulanıklığı güzel yapan yaklaşımının "doğallığı" ve geniş kapsamlı karmaşıklığıdır. Bulanık mantık keyfi karmaşıklığın doğrusal olmayan fonksiyonlarını modelleyebilir. Herhangi bir girdi-çıktı verisi dizisini eşleştirmek için bulanık bir sistem oluşturulabilir. Bu süreç Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neural Fuzzy Inference System- ANFIS) gibi uyarlamalı sistemler tarafından özellikle kolay hale getirilmektedir.

Bulanık mantık kesin olmayan verilere karşı toleranslıdır. Bulanık akıl yürütme, sonuçları değerlendirmekten ziyade bu anlayışı süreçte inşa etmektedir Bulanık mantık, belirsizliklerin ifade edilmesi ve belirsizliklerle çalışılabilmesi için kurgulanmış bir matematik modelleme olarak tanımlanabilir. Bilindiği gibi klasik kümeler teorisinde, belirsizliklerle değil kesinliklerle çalışılır. Klasik yaklaşımlar bulanık kavramların açıklanmasında çoğu zaman yetersiz kalmaktadır. Özellikle sözel olarak kesin olmayan ve sınıflandırılamayan genel algılama prensipleri bu kapsamda değerlendirilebilir. Ancak, günlük hayatta daha çok belirsizliklerden

bahsedilir. Dolayısıyla, insanoğlunun sonuç çıkarabilme metot ve kabiliyetini bilgisayar ortamına aktarabilmek için "belirsizliklerin" modellenmesi gereklidir [31].

Bulanık mantık geleneksel kontrol teknikleriyle birlikte harmanlanabilir. Bulanık sistemlerin mutlaka geleneksel kontrol yöntemlerinin yerini alması gerekmez. Bulanık sistemi esnetmek kolaydır veya yeniden başlamadan üzerine daha fazla işlevsellik yaratmak da kolaydır. Bulanık Mantık' da bilgi, değişkenlerin bulanık kısıtları elastik bir biçimde yorumlanması ile elde edilir. Elastik kısıtların yayılım prosesinin ardından çıkarım gerçekleşir [30].

Bulanık mantık, uzmanların deneyimleri üzerine inşa edilebilir. Bulanık mantık, eğitim verilerini alan ve geçirimsiz, nüfuz edilemez modeller üreten sinir ağlarıyla doğrudan tezat oluşturacak şekilde sistemi çoktan kavramış olan kişilerin deneyimlerine güvenilmesini mümkün kılar. Bulanık mantığın temeli insan iletişiminin temelidir. Bulanık mantık bir giriş alanını bir çıkış alanına eşleştiren uygun bir yoldur. Bir başka ifadeyle, bulanık mantık sağduyunun kodlanmasıdır [131].

5.2. Bulanık Mantık Çıkarım Süreci ve Genel Özellikleri

Mamdani tarafından 1975 yılında önerilen bulanık mantık çıkarımının (kontrolünün) asıl amacı karmaşık bir problemi tatminkâr bir seviyede kontrol edebilecek bir insan operatörünün davranışlarını taklit etmektir. Bir bulanık kontrol sürecinde, insan operatörün bilgisini alan ve eğer-ise kuralları üreten, bilgi edinme sürecinde insan operatör gibi davranan, bulanık kontrol birimine ihtiyaç duyulmaktadır. Genellikle, bir insan operatörden "dilbilimsel ve sayısal" türde bilgiler sağlanır. Deneyimli bir insan operatör, genellikle, kesin olmayan ancak kabaca doğru olan üyelik fonksiyonları ile bir dizi bulanık eğer-ise kuralları ile kontrol kararlarını bulmak amacıyla kendi akıl yürütme süreçlerini özetler. Bu üyelik fonksiyonları, belli miktarda deneme yanılmanın yanında, uzun bir mülakat sürecinden sonra elde edilmektedir. Bu dilbilimsel bilgiye karşılık gelmektedir [133].

Bulanık çıkarım sistemleri otomatik kontrol, veri sınıflandırma, karar analizi, uzman sistemleri ve bilgisayar ile veri analizi gibi alanlara başarıyla uygulanmıştır. Bulanık

mantık çıkarım morfolojisi, insan varsayım yeteneğini bilgi tabanlı bir sistem ile taklit edebilmektedir. Bulanık mantık teorisi kesin olmayan durumların matematiksel ifadesinde insan algısı gibi çalışarak, düşünme ve sonuç çıkarma faaliyetlerinin bir benzerini gerçekleştirmektedir [26].

5.3. Sinirsel Bulanık Mantık Yaklaşımı ve Türleri

Bulanık mantık ve sinir ağları, akıllı sistemlerin geliştirilmesinde birlikte kullanılan tamamlayıcı araçlardır. Yapay sinir ağları, ham verilerle uğraşıldığında iyi sonuçlar veren yapılardır. Bulanık mantık ise uzman görüşü sonucu elde edilen dilsel bilgileri kullanarak daha yüksek seviyeli sonuçlar çıkarmaktadır. Aslında bulanık sistemlerin öğrenme kabiliyeti kısıtlıdır ve kendilerini yeni çevreye kolayca adapte edemezler. Diğer yandan yapay sinir ağları öğrenme kabiliyetine sahiptir; fakat kullanıcı tarafından anlaşılmazlar [115].

Sinirsel bulanık mantık yaklaşımı yapay sinir ağlarının öğrenme yeteneği ve en uygunu bulma özelliği ile bulanık mantığın insan gibi karar verme ve uzman bilgisi sağlama kolaylığı gibi üstünlükleri birleştirmesi fikrine dayanmaktadır. Bu yolla bulanık çıkarım sistemlerine sinir ağlarının öğrenme ve hesaplama gücü kazandırılmaktadır [14].

Algısal belirsizlikler içeren bir sistem hakkında insansı sezgisel çıkarımda bulunabilmek için YSA bütünleşik olan bulanık mantık uygulaması işlevsel bir yaklaşımdır. Bu uygulama ile oluşturulacak olan hibrit sistemin sinir ağları bileşeni bulanık mantık üyelik fonksiyonları ile etkileşim içerisinde olacaktır. Bulanık mantık yardımı ile uzman bilgisi dilsel kural öğeleri ile tanımlanarak kullanılabilir fakat bu uzun ve yorucu bir çalışma gerektirmektedir. Sinir ağının öğrenme mekanizması bu süreci kısaltarak performans artışı sağlamaktadır [29].

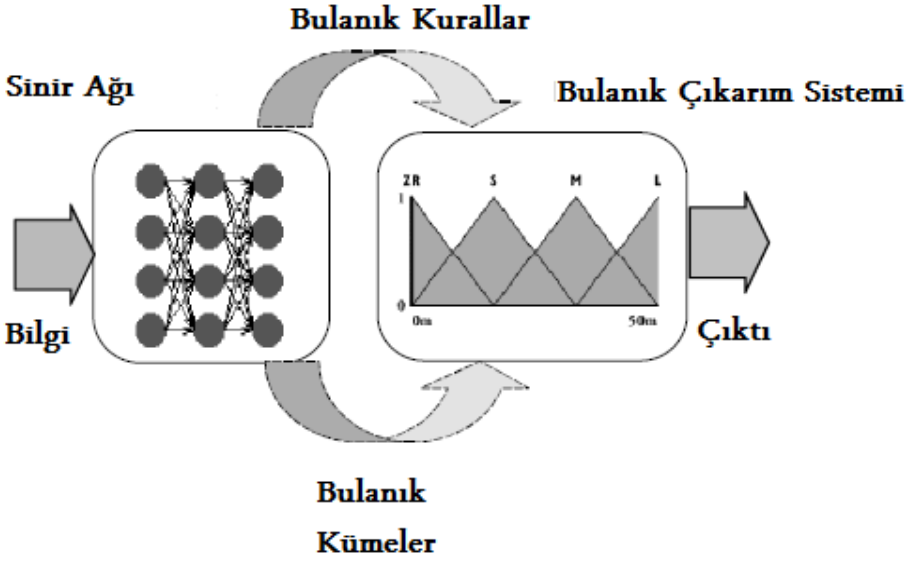
Yapay sinir ağları ve bulanık çıkarım sistemi birleşimi son zamanlarda yoğun ilgi gören araştırma alanlarından bir tanesidir. Pek çok farklı alandaki araştırmacılar ve mühendisler gelişen talep neticesinde uyarlanabilir akıllı sistemler yardımıyla gerçek hayata dair problemlerin çözümüne yönelmişlerdir. Yapay Sinir Ağları ve bulanık çıkarım sistemlerinin bütünleştirilme süreci üç temel kategoride ele alınabilir [38].

- Müşterek Sinirsel Bulanık Sistemler
- Eş Zamanlı Sinirsel Bulanık Sistemler
- Bütünleşik Sinirsel Bulanık Sistemler

5.4. Müşterek Sinirsel Bulanık Sistemler

Basit olarak, bir müşterek model, içerisinde Yapay Sinir Ağları (YSA) öğrenim mekanizmasının bulanık çıkarım sistemi üyelik fonksiyonlarını ya da eğitme verilerindeki bulanık kuralları belirlediği bir önişlemci olarak tanımlanabilir. Bulanık İlişkisel Hafızalar (BİH) parametreleri belirlendiği zaman, YSA arka plana gider. Bulanık İlişkisel Hafızalar' ı, Pesrycz tarafından kendini düzenleyen haritalar kullanarak bulanık kuralların belirlenmesi ve Nomura' nın bulanık küme parametrelerini öğrenebilen sistemleri, Müşterek Sinirsel-Bulanık Sistemlerin iyi örneklerindendir [35].

Şekil 5.1' de Müşterek Sinirsel Bulanık sistemlerin sinirsel ağ öğrenme mekanizmasının bulanık kurallarını, bulanık kümelerin parametrelerini, kural ağırlıklarını vs. belirlemek için kullanıldığı bir Müşterek Sinirsel-Bulanık modeli tasvir etmektedir.



Şekil 5.1: Müşterek Sinirsel Bulanık sistemler [35]

5.5. Bulanık İlişkisel Hafızalar

Kosko, bulanık bir kuralı önceki ve devamı arasındaki ilişki şeklinde yorumlar. Eğer bulanık bir küme birim hiperküpte bir nokta olarak ve kurallar da ilişkiler olarak görülürse, sinirsel ilişkisel hafızaları bulanık kuralları saklamak için kullanmak mümkündür. Bir Sinirsel İlişkisel Hafıza kendisinin bağlantı matrisi tarafından temsil edilebilir. İlişkisel Anımsama Matrisi, bir kilit unsuru çoğaltmaya eşdeğerdir. Ağırlıklar, kilit *k* ve bilgi kısmı *i'* nin özellikleri arasındaki ilişkiyi depolar. İlişkisel hafızaların kısıtlı kapasiteleri ve çoklu matrislerin bağlantılarının tek bir matrise olan bileşimlerinin, aşırı bilgi kaybı yüzünden önerilmemesi sebebiyle her bulanık kuralı tek bir BİH (Bulanık İlişkisel Hafıza) içerisinde depolamak gereklidir. Öncüllerine bağlanarak birleştirilmiş değişkenler, her biri bir adet kural depolayan BİH' ler ile gösterilebilir. BİHler bütün bireysel çıktılar (Mamdani bulanık sistemi durumunda maksimum operatör) ve bir bulanıklaştırma bileşeni birleştirilerek tamamlanır. BİH' lerin çıktılarıyla ilişkili ağırlıkları, öğrenme ya da sadece BİH ile birleştirilebilir. Bir sinirsel ağ öğrenim algoritması bulanık kurallar için kural ağırlıklarını belirler.

Bu tür faktörler genellikle bir kuralın etkisi olarak tanımlanır ve kural çıktıları ile çoğaltılırlar. Kural ağırlıkları, üyelik fonksiyonları modifiye edilerek eşit bir şekilde değiştirilebilir. Ancak bu bulanık kümelerin yanlış yorumlanmasıyla sonuçlanabilir ve eş dilbilimsel değerler farklı kurallar içerisinde farklı şekilde gösterilebilir. Kosko

BİH' leri öğrenebilmek için bir tür uyarlanabilir vektör niceleme tekniği öne sürer. Bu yöntem Diferansiyel Rekabetçi Öğrenim olarak adlandırılır ve SOM öğrenimine çok benzer. Kosko' nun uyarlanabilir BİH' i bir Müşterek Sinirsel-Bulanık modeldir çünkü kuralları ve onların ağırlıklarını belirlemek için bir öğrenme tekniği kullanır.

BİH' in ana dezavantajı kuralların ağırlaştırılmasıdır. Bazı kuralların çok fazla etkisi olamaması onların önemli olmadığı anlamına gelmez. Bu yüzden BİH' lerin bazı uygulamalar için güvenilirliği sorgulanabilirdir. Uygulamalarının kolaylığından dolayı BİH' ler birçok uygulamada kullanılmaktadır [35].

5.6. Öz Örgütlemeli Haritalar Kullanarak Bulanık Kural Çıkarımı

Pedryz eğitim verilerini bir araya getirmek için düzlemsel rekabet katmanı ile birlikte kendini düzenleyen haritalar kullanmıştır. Bu haritalar öğrenim sonuçlarını okuyabilmek için gereken yöntemleri sağlamaktadır. Öğrenim sonuçları iki girdi vektörünün birbirine benzer olup olmadığını ya da aynı sınıfa ait olup olmadıklarını gösterebilir. Ancak yüksek boyutlu girdi vektörleri söz konusu olduğu zaman, öğrenim probleminin yapısı nadiren iki boyutlu haritalarda belli olabilir. Dilbilimsel değişkenleri kullanarak öğrenim sonuçlarını yorumlamak için bir prosedür kullanılmaktadır. Öğrenim aşamasından sonra, ağırlık matrisi, çıktıya doğru olan girdi kalıplarının ağırlığını temsil eder. Bu tür bir matris sadece tek bir özellik için bir harita belirler. Girdi kalıplarının her bir özelliği için, bulanık kümeler dilbilimsel tanımı (her değişken için bir bulanık küme) ile belirtilir. Birkaç dönüşken matris elde etmek için ağırlık matrisine uygulanır. Dilbilimsel terimlerin kombinasyonlarının her biri bir kalıbın, altkümenin ya da kümenin olası tanımıdır.

BİH' ler ile karşılaştırıldığı zaman ortaya çıkan önemli bir avantaj, kuralların ağırlıklaştırılmamasıdır. Üyelik fonksiyonunun biçimi performansta önemli bir rol oynadığı için, BİH ile karşılaştırıldığında, daha iyi bir şekilde kullanılabilir. Kosko' nun öğrenim prosedürü çıktı nöronları arasındaki komşu ilişkileri dikkate almadığından, girdi kalıplarından çıktı kalıplarına olan mükemmel topolojik haritalamalar bazen mümkün olmayabilir. Bu yüzden, BİH öğrenim prosedürü, eğitim verisi sıralamasına Pedryz prosedüründen daha bağımlıdır.

Öznitelik uzayının yapısı başlangıçta belirlenir ve uygun dilbilimsel bölümler kullanılarak öğrenim sonuçlarına en iyi uyan dilbilimsel tanımlar elde edilir. Eğer çok fazla sayıda kalıp hiçbir tanıma uymaz ise bunun sebebi yetersiz sayıda üyelik fonksiyonu seçimi olabilir ve bunlar tekrar belirlenebilir. Bu yüzden, bulanık kuralları öğrenmek için bu yöntem BİH' ler ile karşılaştırıldığında daha tercih edilirdir. Bu metodun performansı yine de öğrenim oranlarına bağlıdır ve probleme bağlı ağırlık modifikasyonu için gerekli olan komşu boyutu bulgusal olarak belirlenebilir [83, 117, 119].

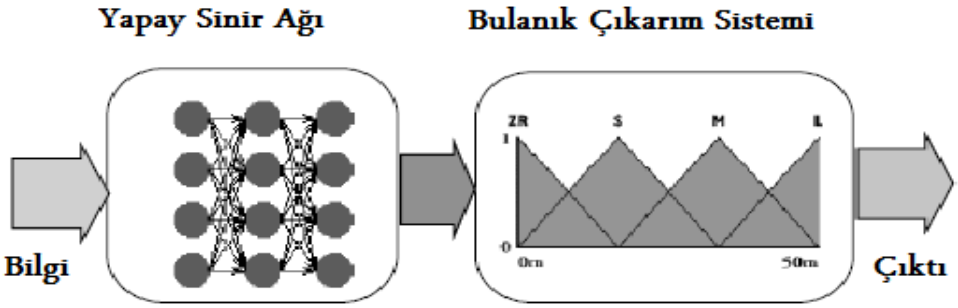
5.6.1. Bulanık küme parametrelerini öğrenen sistem

Nomura ve arkadaşları varolan Sugeno tipi bulanık sistemin bulanık kümelerine ince ayar yapmak için denetlenen bir öğrenme tekniği öne sürmüştür Öğrenim algoritması, üyelik fonksiyonlarının (ÜF) parametrelerini ince ayarlamak için hata ölçüsü E (asıl ve hedef çıktılar arasındaki fark) kullanan bir gradyan iniş prosedürü kullanır. Bu prosedür çok katmanlı algılayıcılar için olan delta kuralına çok benzer. Öğrenme çevrimdışı modda meydana gelir. Girdi vektörü için, oluşan hata E güncellenen kısımlara (gerçek bir değer) göre hesaplanır ve onlara bağlıdır. Daha sonra aynı kalıplar tekrar çoğaltılır ve sadece üyelik fonksiyonlarının parametreleri güncellenir. Bu işlem öncüller değiştirildikten sonra soncul değişikleri hesaba katmak için yapılır. Bu yöntemin büyük bir dezavantajı ise girdi değişkenlerinin dilbilimsel değerlerinin gösterimlerinin yer aldıkları kurallara bağlı olmasıdır. Başlangıçta eş dilbilimsel terimler eş üyelik fonksiyonları tarafından gösterilir. Öğrenme süreci boyunca, eş dilbilimsel terimlerin farklı bulanık kümeler tarafından temsil edilebilmeleri için farklı şekilde geliştirilebilir. Öne sürülen yöntem sadece Sugeno türü bulanık çıkarım sistemine uygulanabilir [115,118].

5.7. Eşzamanlı Sinirsel Bulanık Sistemler

Eşzamanlı Sinirsel Bulanık Sistemler, girdi değişkenlerinin direk olarak ölçülemediği durumlarda, gerekli olan parametrelerin belirlenmesinin öncül şart olduğu durumlarda faydalanılmaktadır. Yapay Sinir Ağları, Sinirsel Bulanık Sistemin giriş kontrollerinin değişkenlerini direkt olarak hesapladığından, istenen parametrelerin belirlemesinde devamlı olarak rol oynar [35].

Eşzamanlı bir modelde sinirsel ağ, gereken parametreleri belirlemek için, özellikle denetleyicinin giriş değişkenleri direkt olarak ölçülemiyorsa, bulanık sisteme yardım eder (ya da tam tersi). Bu tür kombinasyonlar bulanık sistemi daha iyi hale getirmez, sadece genel sistemin performansını geliştirmeye yardımcı olur. Bazı durumlarda bulanık çıktılar sürece direkt olarak uyarlanamayabilir. Bu durumda sinirsel ağ bulanık çıktıların ardişlemcisi görevini alabilir.



Şekil 5.2: Eşzamanlı Sinirsel Bulanık Sistemler [35]

Şekil 5.2’ de giriş verisi sinirsel bir ağa bağlanmış ve sinirsel ağın çıktısının daha sonra bulanık sistem tarafından işlendiği bir Eşzamanlı Sinirsel-Bulanık Modeli gösterilmektedir [35].

5.8. Bütünleşik Sinirsel Bulanık Sistemler

Bütünleşik bir modelde, sinirsel ağ öğrenim algoritmaları, bulanık çıkarım sistemlerinin parametrelerini hesaplamak için kullanılır. Birleşik Sinirsel Bulanık sistemler veri yapılarını ve bilgi gösterimlerini paylaşır. Bulanık çıkarım sistemi, önemli bileşenlerini kural ve veri bazında depolayarak insan bilgilerini faydalı hale getirebilir ve tüm çıktı değerini belirlemek için bulanık mantık kullanabilir.

Eğer-İse kurallarının türetilmesi ve eşdeğer üyelik fonksiyonları, ağırlıklı olarak incelenmekte olan öncül bilgiye dayanır. Fakat uzman bireylerin bilgi tecrübelerini bulanık çıkarım sistemi tabanındaki bilgilere dönüştürmenin sistematik bir yolu yoktur. Gerekli hata oranı içerisinde çıktı üretmek için uyarlanabilirlik ya da bazı öğrenme algoritmalarına ihtiyacı vardır. Diğer yandan, sinirsel ağ öğrenim mekanizması bireyin uzmanlığı üzerine kurulu değildir. Sinirsel ağın homojen yapısı sebebiyle, yerleşmiş bilgileri ağın ağırlığından ya da ağın yapı bilgilerinden elde

etmek kolay değildir. Sinirsel ağın ağırlığı, girdi boşluğunu farklı çıktı değerleri olan iki bölgeye ayıran hiperdüzlemlerin katsayılarını yansıtır. Eğitme verilerinde bulunan bu hiperdüzlem yapısını görselleştirebilirsek, bir sinirsel ağdaki öğrenim yöntemleri azaltılabilir. Ancak, gerçekte önsel bilgi genellikle uzman bireylerden elde edilir, bilgiyi bir dizi bulanık eğer-ise kuralları olarak ifade etmek daha doğru olur ve bunu sinirsel ağa kodlamak oldukça zordur.

Tablo 5.1: Sinirsel ağlar ve bulanık çıkarım sistemi karşılaştırması

	Yapay Sinir Ağı	Bulanık Çıkarım Sistemi
1	Önceki kural bilgisi kullanımı zordur	Öncül kural eklenebilir
2	Sıfırdan Öğrenme	Dilsel bilgileri öğrenemez
3	Kara kutu	Yorumlanabilir (eğer-ise kuralları)
4	Karmaşık öğrenme algoritmaları	Basit yorumlanması ve uygulanması
5	Bilgi ayıklamak zor	Bilginin kullanılabilir olması gerekir

Bu iki yaklaşıma ait olan kusurlar büyük oranda bütünleyici gözükmektedir. Bu yüzden, Bulanık Çıkarım Sistemi (BÇS) ve YSA modellemesi kavramlarını birleştiren tümleşik bir sistem inşa etmeyi düşünmek doğaldır. Bir öğrenme algoritmasını bulanık bir sisteme uygulamanın yaygın bir yolu, onu mimarisi özel bir sinirsel ağ içerisinde göstermektir. Ancak çıkarım sürecinde kullanılan fonksiyonlar genelde türevsiz olduğu için klasik öğrenim algoritmaları (gradyan iniş) direkt olarak bu tür bir sisteme uygulanamaz [35].

5.8.1. Mamdani entegreli sinirsel bulanık sistemler

Üyelik fonksiyonlarının parametrelerini öğrenmek için denetlenen bir öğrenme tekniği kullanır. Mamdani Yönteminin Avantajları [131]:

- Sezgiseldir.
- Yaygın kabulü vardır.
- İnsan bilgi girişi için uygundur.

Mamdami Sinirsel Bulanık sisteminin mimarisi beş katmandan oluşur. Şekil 5.3' de gösterilmiştir. Her bir katmanın detaylı işlevi aşağıdaki gibidir:

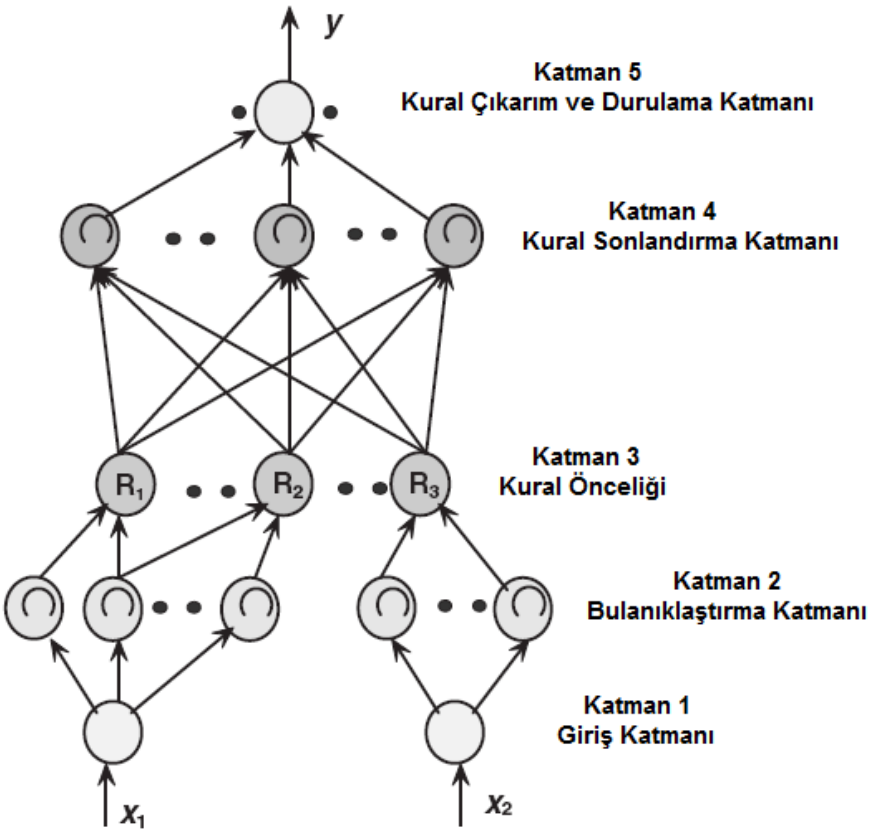
Katman-1 (giriş katmanı): Bu katmanda hiçbir hesaplama yapılmaz. Bu katmandaki, bir girdi değişkenine tekabül eden her bir düğüm girdi değişkenlerini sadece sonraki katmana direkt olarak iletir. Birinci katmandaki bağlantı ağırlığı birdir.

Katman-2 (bulanıklaştırma katmanı): Bu katmandaki her bir düğüm birinci katmandaki girdi değişkenlerinden birinin dilbilimsel etiketine (mükemmel, iyi, vs.) tekabül eder. Bir diğer deyişle, bulanık bir sisteme ait olan girdi değerinin derecesini belirten, üyelik değerinde gösterilen çıktı bağlantısı ikinci katmanda hesaplanır. Bir kümeleşme algoritma her bir girdi değişkenine ayırılacak olan başlangıç sayısına ve üyelik fonksiyonunun türüne karar verecektir. Üyelik fonksiyonlarının son şekillerine ağ öğrenimi esnasında ince ayar yapılır.

Katman-3 (kural önceliği katmanı):Bu katmanda bir düğüm, bir kuralın öncül kısmını temsil eder. Bu düğümde genellikle bir üçgen norm operatörü kullanılır. Bu katman düğümünün çıktısı yöndeş bulanık kuralın gücünü gösterir.

Katman-4 (kural sonlandırma katmanı): Bu düğümün esas olarak iki görevi vardır: Gelen kural öncüllerini birleştirmek ve girdi dilbilimsel etiketine (yüksek, orta, düşük, vb.) olan aitliklerinin derecesini belirlemek. Bu katmandaki düğümlerin sayısı kuralların sayısına eşit olacaktır.

Katman-5 (kural çıkarım ve durulama katmanı): Bu düğüm üçgen conorm operatörü kullanarak bütün kural sonuçlarının birleşimini sağlar ve son olarak bulanıklaştırmadan sonraki yeni çıktıyı hesaplar [35].



Şekil 5.3: Mamdami entegreli sinirsel bulanık sisteminin mimarisi ve beş katmanı [35]

5.8.2. Takagi-Sugeno entegreli sinirsel bulanık sistemler

Takagi-Sugeno entegreli sinirsel bulanık sistemler üyelik fonksiyonlarını öğrenmek için geri yayılmanın bir karışımını kullanırlar, bu şekilde kuralların sonuçlarındaki doğrusal kombinasyonları kesinleştirirler. Öğrenme prosedürü iki bölümdür. İlk bölümde giriş desenleri türetilmiştir ve en uygun sonuç parametreleri prosedür ile tahmin edilmiştir. İkinci bölümde ise desenler tekrar türetilirmiş ve geri yayılma önceki parametreleri değiştirmek için kullanılmıştır. Böylece sonuç parametreleri dengeli kalmıştır. Sonrasında ise prosedür yenilenmiştir [121].

Sugeno Yönteminin Avantajları;

Genel olarak, çıktı üyelik fonksiyonlarının ya doğrusal ya da kalıcı olduğu sonuç çıkarma sistemini modellemek için Sugeno-tipi sistemler kullanılabilir.

- Hesaplama verimlidir.

- Lineer teknikler ile çalışır.
- Optimizasyon ve uyarlamalı tekniklerle başarılıdır.
- Çıkışın sürekliliği garantidir.
- Matematiksel analiz için uygundur [131].

Takagi-Sugeno sinirsel-bulanık sistemleri üyelik fonksiyonlarını öğrenmek için geri yayılımı ve kuralın sonuçlarındaki doğrusal kombinasyonların katsayılarını belirlemek için en küçük kare tahminini kullanır. Sistemin 6 katmandan oluşan bir yapısı vardır, katmanları tek tek incelediğimizde;

Katman-1 (girdi katmanı): Bu katmanda hiçbir hesaplama yapılmaz. Bu katmandaki, bir girdi değişkenine tekabül eden her bir düğüm girdi değişkenlerini sadece sonraki katmana direkt olarak iletir. Birinci katmandaki bağlantı ağırlığı birdir.

Katman-2 (bulanıklaştırma katmanı): Bu katmandaki her bir düğüm birinci katmandaki girdi değişkenlerinden birinin dilbilimsel etiketine (mükemmel, iyi, vs.) tekabül eder. Bir diğer deyişle, bulanık bir sisteme ait olan girdi değerinin derecesini belirten, üyelik değerinde gösterilen çıktı bağlantısı ikinci katmanda hesaplanır. Bir kümeleşme algoritma her bir girdi değişkenine ayırılacak olan başlangıç sayısına ve üyelik fonksiyonunun türüne karar verecektir. Üyelik fonksiyonlarının son şekillerine ağ öğrenimi esnasında ince ayar yapılır.

Katman-3 (öncül kural katmanı):Bu katmanda bir düğüm, bir kuralın öncül kısmını temsil eder. Bu düğümde genellikle bir üçgen norm operatörü kullanılır. Bu katman düğümünün çıktısı yöndeş bulanık kuralın gücünü gösterir.

Katman-4 (kural güç düzeltimi): Bu katmandaki bütün düğümler i. kuralının çıkış gücünün bütün kuralların çıkış güçlerinin toplamına olan oranını hesaplar.

$$wi=wi/ (W1+W2), i=1,2... \quad (5.1)$$

Katman-5 (kural sonuç katmanı): Bu katmandaki her düğüm i, içerisinde wi' nin 4. katmanın çıktısı ve *{pi, qi, ri}*' nın parameter kümesi olduğu bir düğüm fonksiyonu

$$wifi = wi\ (pi\ x1 + qi\ x2 + ri) \tag{5.2}$$

ile beraber oluşturur. İyi yapılandırılmış bir yöntem ise sonuç parametrelerini en küçük ortalama kareler algoritmasını kullanarak belirlemektir.

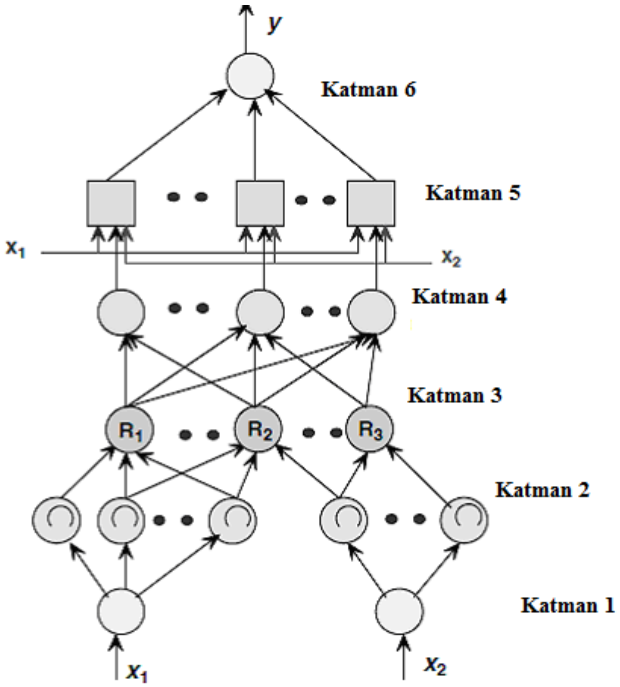
Katman-6 (kural çıkarım katmanı) Bu katmandaki tek bir düğüm, gelen bütün sinyallerin özeti olarak tüm çıktıları hesaplar [35].

$$\text{Toplam Çıktı} = \sum_i \overline{w_i}\, f_i = \frac{\sum_i w_i\, f_i}{\sum_i wi} \tag{5.3}$$

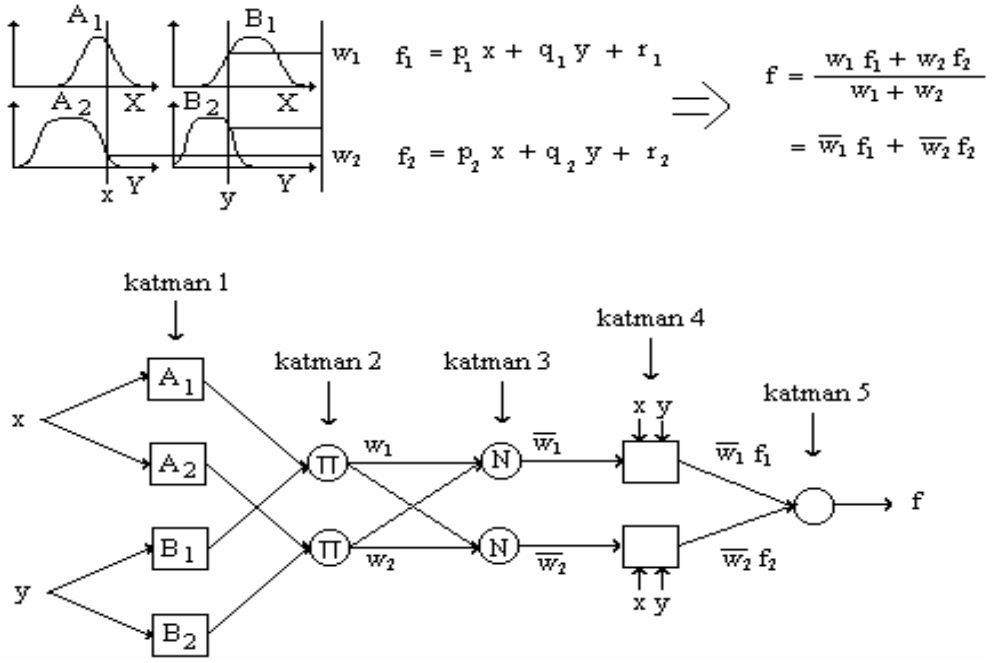
5.8.3. Uyarlanabilir ağ bazlı bulanık çıkarım sistemi

Uyarlanabilir Ağ Bazlı Bulanık Çıkarım Sistemi belki de ilk tümleşik melez sinirsel-bulanık modeldir. Mimarisi Şekil 5.4' de gösterilmiştir. ANFIS' in değiştirilmiş bir versiyonu, Şekil 5.5' de gösterildiği üzere Tsukamoto bulanık çıkarım sistemini uygulama yetisine sahiptir. Tsukomoto Bulanık Çıkarım Sisteminde bütün çıktıların kural çıkış gücü (ürün ya da öncül kısımların eşleşmelerinin derecelerinin minimumu) ve çıktı üyelik fonksiyonlarının neden olduğu kuralın yeni çıktısının ağırlaştırılmış ortalamasıdır. Kullanılan çıktı üyelik fonksiyonları monoton artan olmak zorundadır.

İlk saklı katman, girdi değişkenlerinin bulanıklaştırılması içindir ve üçgen norm operatörleri kural öncül kısımlarını hesaplayabilmek için ikinci saklı katmanda konuşlandırılmıştır. Üçüncü saklı katman, içerisinde kuralın birbirini izleyen parametrelerinin belirlendiği dördüncü saklı katman tarafından izlenen kural güçlerini normalleştirir. Çıktı katmanı, bütün çıktıyı gelen tüm sinyallerin toplamı olarak hesaplar.



Şekil 5.4: Uyarlanabilir Ağ Bazlı Bulanık Çıkarım Sistemi [35]



Şekil 5.5: Tsukamoto Bulanık Çıkarım Sistemi [35]

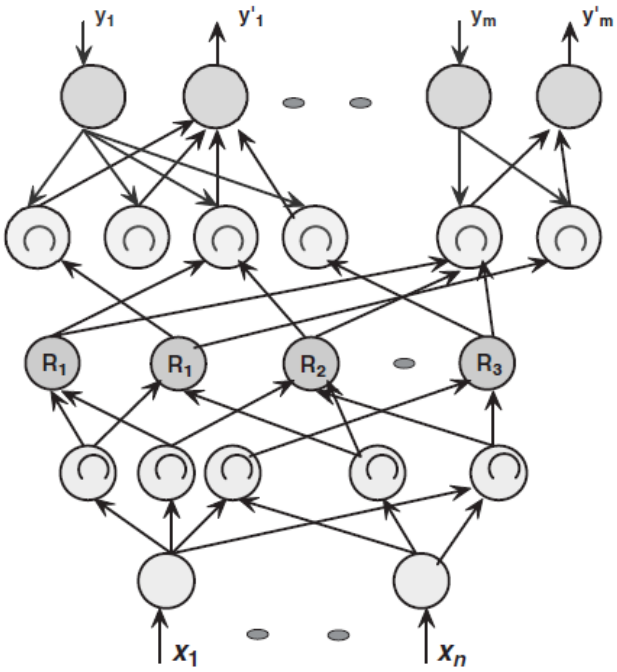
5.8.4. Bulanık uyarlanabilir öğrenme kontrol ağı

Her çıktı için iki adet dilbilimsel düğüm bulunmaktadır. Bir tanesi eğitme verisi (istenen çıktı) diğeri ise asıl Bulanık Uyarlanabilir Öğrenme Kontrol Ağı çıktısı içindir. İlk saklı kat her girdi değişkeninin bulanıklaştırmasından sorumludur. Her

düğüm basit üyelik fonksiyonunu (ÜF) ya da karmaşık ÜF' yi hesaplayan çok katmanlı düğümlerden oluşan bir yapıdadır.

İkinci saklı katman, üçüncü saklı katmandaki birbirini izleyen kuralların önkoşullarını tanımlar. Bulanık Uyarlanabilir Öğrenme Kontrol Ağı, istenen çıktıları üretmek amacıyla parametreleri ideal bir şekilde uyarlamak için danışmansız öğrenme ve inişli öğrenmeden oluşan bir melez-öğrenme algoritması kullanır. Melez-öğrenme iki aşamada meydana gelir. Başlangıç aşamasında üyelik fonksiyonlarının merkezleri ve genişliği, kendini düzenleyen öğrenme teknikleri, analoglar ve istatistiksel kümeleme teknikleri tarafından belirlenir. Başlangıç parametreleri belirlendikten sonra kural öncüllerini formüle etmek kolaydır. Rekabetçi bir öğrenme algoritması her kural düğümünün, birbirini izleyen doğru kural bağlarını belirlemek için kullanılır. Bulanık kural tabanı kurulduktan sonra, bütün ağ yapısı kurulmuş olur. Sonrasında ağ üyelik fonksiyonlarının parametrelerini (girdi ve çıktı) ideal bir şekilde düzenlemek için ikinci öğrenme aşamasına girer. Geri yayılım algoritması, danışmanlı öğrenme için kullanılır. Bu sayede Bulanık Uyarlanabilir Öğrenme Kontrol Ağı algoritması sinirsel-bulanık sistemlerin tasarlanması için bir parametre adaptasyonu ve yapı için bir iskelet sağlar.

Bulanık Uyarlanabilir Öğrenme Kontrol Ağı Şekil 5.6' da gösterildiği üzere beş katmanlı bir mimariye sahiptir ve Mamdani türü bir Bulanık Çıkarım Sistemi'dir.



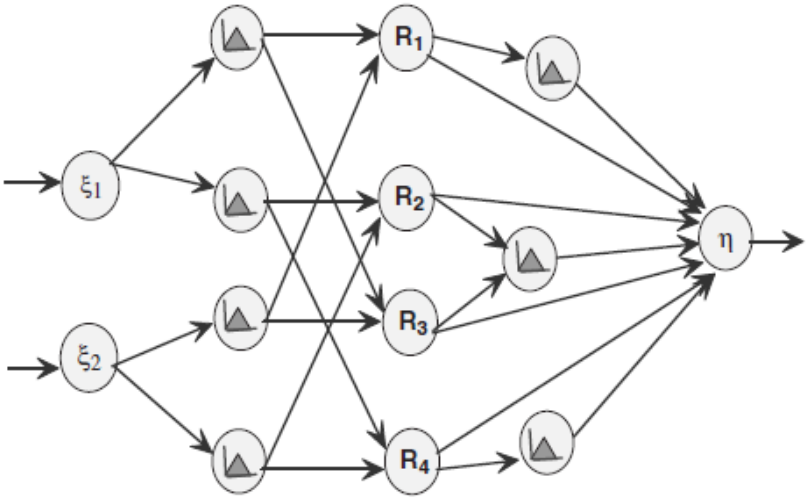
Şekil 5.6: Bulanık Uyarlanabilir Öğrenme Kontrol Ağı modeli [35]

5.8.5. Genelleştirilmiş yaklaşık çıkarım tabanlı akıllı denetim

Berenji' nin geliştirdiği Yaklaşık Çıkarım Tabanlı Akıllı Denetiminin genişletilmiş bir versiyonudur. Yaklaşık Çıkarım Tabanlı Akıllı Denetimi gibi, bir İşlem Durumu Değerlendirme Ağı ve bir İşlem Seçim Ağı' ndan oluşur. İşlem Durumu Değerlendirme Ağı ve İşlem Seçim Ağı' nın işlemlerini değerlendiren bir uyarlanır çıkarım sistemidir. İşlem Seçim Ağı hiç ağırlıklı bağlantı kullanmaz ama öğrenme süreci, ağın birimlerinin içinde depolanan parametreleri değiştirir. Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetim İşlem Seçim Ağı' nın mimarisi Şekil 5.7' de tarif edilmiştir.

Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetimin İşlem Seçim Ağı beş katmanlı bir ileri besleme ağıdır. İlk gizli katman bütün girdi değişkenlerinin dilsel değerlerini depolar. Her girdi birimi sadece ilişkili dilsel değerleri temsil eden birinci gizli katmanın birimlerine bağlıdır. İkinci gizli katman softmin işletimi kullanarak bir kuralın tamamlama derecesini belirleyen bulanık kurallar düğümlerini temsil eder. Üçüncü gizli katman, denetim çıktısı dilsel değerleri temsil eder. Kuralın sonuçları, kural düğümü katmanı tarafından hesaplanan ön kuralların gücüne bağlı olarak hesaplanır. Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetim kural

çıktılarını hesaplamak için yerel maksimumun ortalaması yönteminden faydalanır. Bu yöntem her kuralın net çıktı değerlerine ihtiyaç duyar. Bu nedenle sonuçlar, denetim biriminin son çıktı değerlerine dönüşmeden durulanmalıdır.



Şekil 5.7: Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetim İşlem Seçim Ağı' nın modeli [35]

Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetimin İşlem Durumu Değerlendirme Ağı' nın öğrenme algoritması, atası olan Yaklaşık Çıkarım Tabanlı Akıllı Denetiminkine eşdeğerdir. Ama İşlem Seçim Ağı' nın öğrenme prosedürü Yaklaşık Çıkarım Tabanlı Akıllı Denetim te kullanılan prosedürden farklıdır. Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetim düğüm parametrelerini ince ayarlamak için gradyan iniş ile danışmanlı öğrenmenin bir karışımını kullanır. Eğer İşlem Durumu Değerlendirme Ağı' nın çıktısı değişmeye son verirse karma öğrenme durur. Genelleştirilmiş Yaklaşık Çıkarım Tabanlı Akıllı Denetimin göreceli olarak karmaşık öğrenme yöntemi ve mimarisi temel dezavantajı olarak görülebilir [35].

5.8.6. Sinirsel-Bulanık denetim birimi

Bu yöntem daha önceden belirlenmiş bir kural tabanına ihtiyaç duyan Yaklaşık Çıkarım Tabanlı Akıllı Denetimin Ağının bir uzantısı gibi düşünülebilir.

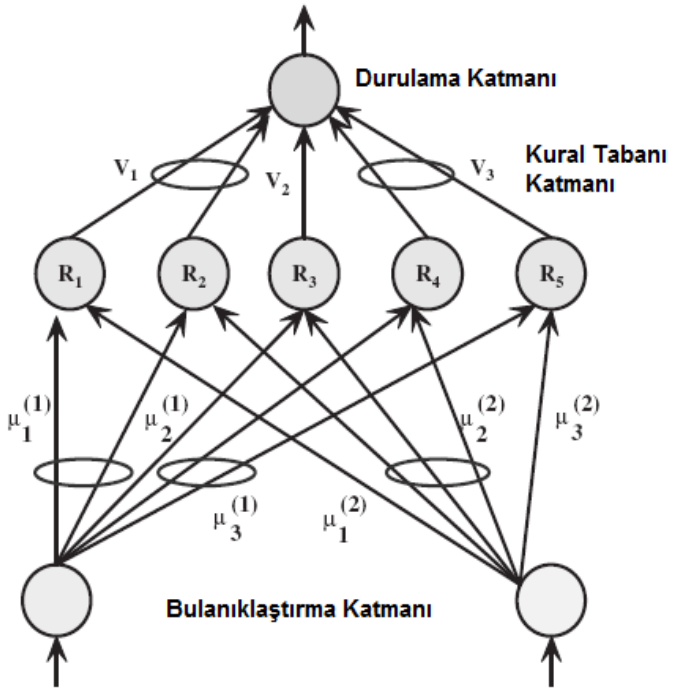
Sinirsel ağların tersine Sinirsel-Bulanık Denetim Birimindeki bağlantılar gerçek sayılar yerine bulanık kümelerle ölçülür. Aynı geçmişe sahip kurallar, Şekil 5.8' de

gösterildiği gibi bağlantıların etrafına çizilen elipsler tarafından temsil edilen sözde paylaşılan ölçüleri kullanır. Kural tabanının doğruluğunu sağlama alırlar. Bulanık sistemin bilgi tabanı ağ yapısı tarafından dolaylı olarak oluşturulur. Girdi birimleri, bulanıklaştırma arayüzünün görevini üstlenir. Çıkarım mantığı yayılma fonksiyonu tarafından temsil edilir ve çıktı birimi durulama arayüzüdür.

Sinirsel-Bulanık Denetim Birimi modelinin öğrenme süreci iki temel aşamaya ayrılabilir. İlk aşama kural tabanını öğrenmek için tasarlanmıştır ve ikinci aşama ise kuralların bulanık gruplarını değiştirerek kuralları optimize eder. Kural tabanını öğrenmek için iki yöntem vardır. Artımlı kural öğrenimi, doğru çıktı bilinmediğinde ve kurallar, tahmini çıktı değerlerini temel olarak aldığında kullanılır. Öğrenme devam ettikçe gereksinime göre daha çok kural eklenir. Azalan kural öğrenimi için işlem değişkenlerinin bulanık bölümleri nedeniyle önce kurallar yaratılır ve gereksiz kurallar öğrenme sürecinde çıkarılır. Azalan kural öğrenimi artan yaklaşımına göre daha az etkindir. Fakat bilinmeyen işlemlere zorluk çıkmadan uygulanabilir ve ideal çıktı değerini bilmeye veya tahmin etmeye gerek yoktur. İki yöntem de kural tabanını öğrenmek veya en iyi şekilde kullanmak için güncel sistem durumunun değerini açıklayan bulanık hata *E*'yi kullanır. Gereken hesaplamaların karmaşıklığından dolayı azalan öğrenim kuralı sadece çok fazla bulanık grupları olmayan birkaç girdi değişkeni varsa kullanılır. Daha büyük sistemler için artan öğrenim kuralı en idealidir. Kural tabanının üyelik fonksiyonları Bulanık Hata Geri yayılım algoritmasına göre değiştirilir. Bulanık Hata Geri Yayılım algoritması üyelik fonksiyonlarını uyarlayabilir ve sadece bulanık kuralların kurallar tabanı varsa uygulanabilir. Öğrenme algoritmasının amacı aynıdır: kuralın işlemi doğru yöne doğru gidiyorsa o kuralın etkisini arttır (ödüllendiren), ve eğer bir kural ters yönde üretken davranıyorsa etkisini azaltır (cezalandıran) [35].

5.8.7. Sinirsel-Bulanık sınıflandırma

Sinirsel-Bulanık Sınıflandırma farklı sınıflara ayrılabilen bir veri grubundan bulanık kurallar türetmek için kullanılır. Sinirsel-Bulanık Sınıflandırma, öğrenme algoritmasındaki ve kuralların yorumlanmasındaki küçük farklılıklar dışında çokça Sinirsel-Bulanık Denetim Birimi sistemini andırır.



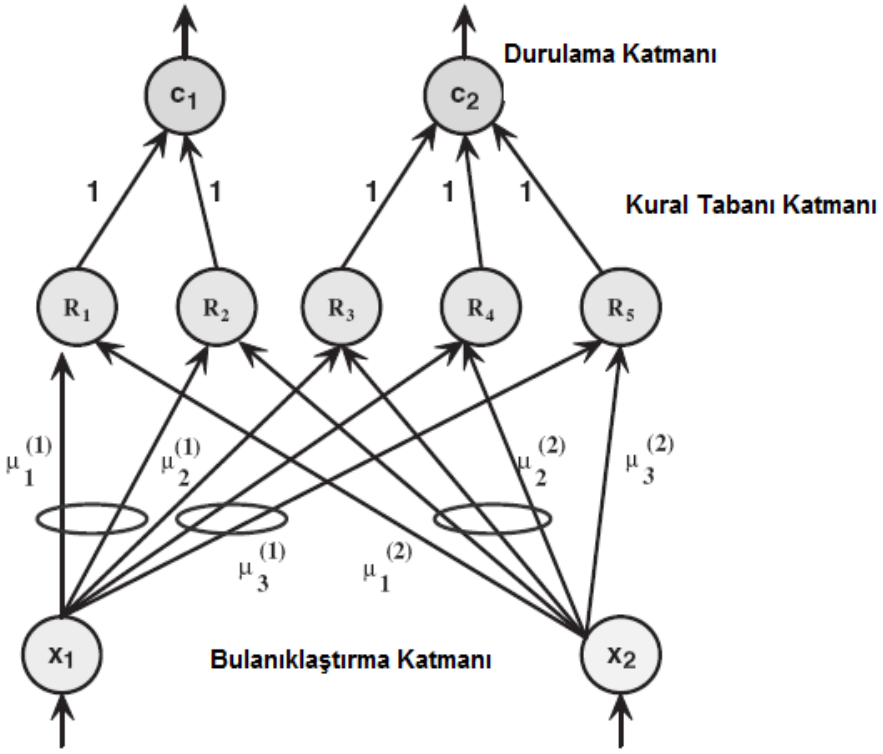
Şekil 5.8: İki girdili ve beş bulanık kurallı Sinirsel-Bulanık Denetim Birimi mimarisi [35]

Sinirsel-Bulanık Denetim Birimi sistemindeki gibi Sinirsel-Bulanık Sınıflandırmakta bir girdi değişkeninin özdeş dilsel değerleri aynı bulanık grupları tarafından temsil edilir. Sınıflandırma Sinirsel-Bulanık Sınıflandırma' nın temel görevi olduğundan özdeş geçmişleri olan iki kural olmalıdır ve her kural birimi sadece tek bir çıktı birimine bağlı olmalıdır. Bir Sinirsel-Bulanık Sınıflandırma sistemi kısmi bir bilgi ile oluşturulabilir ve daha sonra öğrenme ile geliştirilebilir ya da öğrenme ile tamamen baştan yaratılabilir [35].

Sinirsel-Bulanık Sınıflandırma üçgensel üyelik fonksiyonlarından faydalanır ve üyelik fonksiyonlarının öğrenme algoritması bir kuralın yerine getirme derecesinin daha yüksek mi alçak mı olması gerektiğini ölçen bir hata ölçüsü ile kullanılır. Bu bilgi, girdi bulanık gruplarını değiştirmek için tasarlanmıştır. Bir sınıflandırma

sistemi olduğu için kesin çıktı değerleriyle çok ilgilenmeyiz. Buna ilaveten çıktı için kazanan hepsini alır yorumlaması yapılabilir ve aslen doğru sınıflandırma sonucu ile ilgilenilir.

Sinirsel-Bulanık Sınıflandırmadaki artan kural öğrenimi, Sinirsel-Bulanık Denetim Birimi' ndeki azalan kural öğreniminden çok daha karmaşıktır. Eğitim seti boyunca her seferinde bir kural tabanı kurmak mümkündür. Daha yüksek boyutlu problemler için bile kural tabanı en fazla üç aşamada tamamlanır. Sinirsel ağlarla karşılaştırıldığında Sinirsel-Bulanık Sınıflandırma çok daha basit bir öğrenme stratejisi kullanılır. Diğer avantajlar da yorumlanabilirlik, başlangıç durumuna getirilme olasılığı (daha önceki bilgiyi katarak) ve basitliğidir [35].



Şekil 5.9: Sinirsel-Bulanık Sınıflandırma mimarisi [35]

Şekil 5.9' da beş dilsel kural kullanarak iki öznitelikli şekil düzenlerini iki farklı sınıfa eşleyen Sinirsel-Bulanık Sınıflandırma sistemini gösteriyor [35].

5.8.8. Sinirsel-Bulanık fonksiyon yaklaşıklama

Sinirsel-Bulanık Fonksiyon Yaklaşıklama sistemi, yalın denetimli öğrenmeye (sabit öğrenme problemi) dayalıdır ve bu model yaklaşık değer belirlemek için kullanılır. Sinirsel-Bulanık Denetim Birimi modelinin değiştirilmiş versiyonudur.

Sinirsel-Bulanık Fonksiyon Yaklaşıklama, Sinirsel-Bulanık Denetim Birimi sadece tek çıktı düğümü olması ve Sinirsel-Bulanık Sınıflandırma sistemlerinin sonuç tarafında üyelik fonksiyonu kullanmaması dışında Sinirsel-Bulanık Denetim Birimine ve Sinirsel-Bulanık Sınıflandırmaya çok benzer. Sinirsel-Bulanık Fonksiyon Yaklaşıklama sistemi zaten uygun kuralları biliyorsa ilk kullanıma hazırlanabilir aksi halde sistem artan bir şekilde bütün kuralları öğrenebilir [35].

5.8.9. Ayarlamalı bulanık çıkarsama ortam yazılımı

Ayarlamalı Bulanık Çıkarsama Ortam Yazılımı kendini ayarlamak için tasarlanmıştır. Ayarlamalı Bulanık Çıkarsama Ortam Yazılımı iki tür ayarlama işlemi yapabilir, kombinasyon fonksiyonlarının ayarlanması ve içerme fonksiyonunun ayarlanması. Genelleştirilmiş yapı dört yolla geliştirilir, birliktelik ve iptal etme doğası olan toplama operatörleri, parametrelerle ifade edilmiş bir gereklilik fonksiyonu, bulanıklığı azaltabilen bir kombinasyon fonksiyonu, genelleştirilmelere dayalı geriye zincirleme. Birliktelik ve iptal etme doğası olan toplama operatörleri bazı parametreleri kullanarak tanımlanır [35].

5.8.10. Kendini inşa eden sinirsel-bulanık çıkarsama ağı

Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı bir Takagi-Sugeno tipi bulanık çıkarım sistemidir. Bulanık kurallar yaratılır ve simültane yapı ve parametre tanılama yolu ile devam eden çevrimiçi öğrenme olarak uyarlanır.

Ön koşul kısmının yapı teşhisinde, sıraya dizilmiş kümelenmeye dayalı algoritmaya göre girdi boşluğu esnek bir yolla bölümlenmiştir. Birbirini izleyen kısımın yapı teşhisinde en başta her kurala sadece kümeleme metodu tarafından seçilen bir değer atanmıştır. Daha sonra, öğrenim devam ederken, birbirini izleyen kısma her kural için izdüşüm-tabanlı ilinti ölçüsü yolu ile seçilen bazı fazladan, girdi değişkenleri

artarak eklenir. Parametre tanılama için, birbirini izleyen parametreler En Az Ortalama Kareler [Least Mean Square- LMS] ya da Özyineli En Az Kareler algoritmaları ile sabit olarak ayarlanır ve önkoşul parametreleri geri yayılım algoritması ile ayarlanır.

Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı in parametre tanılama evresinde, uygun doğrusal dönüşümler dinamik olarak öğrenilir. Parametre öğrenimi denetlenen öğrenme algoritmalarına dayalıdır, birbirini izleyen kısımlarda doğrusal eşitliklerin parametreleri ya En Az Ortalama Kareler ya da Özyineli En Az Kareler algoritmaları kullanılarak ayarlanır ve önkoşul kısmındaki parametreler geri yayılım algoritması ile ayarlanır.

Girdi boşluğunun nasıl bölümlendiği, eğitim verilerinden çıkarılan kuralların sayısını belirler, hem de her girdi değişkeninin söylem evrenindeki bulanık grupların sayısını belirler. Her oluşturulan kural için bir sonraki adım, her girdi değişkeni için çok boyutlu üyelik fonksiyonunu karşı düşen üyelik fonksiyonuna ayrıştırmaktır. Çıktı boşluğu bölümlemesi için neredeyse aynı yöntem benimsenir. Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı' nın performansı, veri grubunun bütün bilgisini sağlayan dönüştürücü matris yapının içine eklenir.

Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı birbirini izleyen kısmında daha az parametreye ihtiyaç duyulur, özellikle çok sayıda kuralları olan karmaşık sistemlerde.

Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı' ndaki birbirini izleyen yapı tanımlama şeması, Yapay Sinir Ağları' ndaki düğüm büyütme metodunun bir çeşididir. Parametre öğrenmenin etkisi azaldığında birbirini izleyen kısma fazladan terimler eklenir.

Ağ yapısı, güncel eğitim düzenine göre ayarlandıktan sonra ağ, aynı eğitim düzenini ideal bir şekilde temel alarak ağın parametrelerini ayarlamak için parametre tanımlama evresine girer. Düğümler yeni eklenmiş olsalar da veya başlangıçta da var olsalar da parametre öğrenimi yapı öğreniminden sonra bütün ağ üzerinde gerçekleştirilir. Bu danışmanlı öğrenmede geri yayılım algoritması kullanılır. Diğer

bütün sinirsel-bulanık modeller arasında Kendini İnşa Eden Sinirsel-Bulanık Çıkarsama Ağı belki de en zorudur [35].

5.8.11. Bulanık ağ

Bulanık Ağ' da bulanık kuralların ve üyelik fonksiyonların anlaşılır ve seçilebilir kılmak için, aktivasyon fonksiyonları ile mantık tabirlerini değerlendiren özel nöronlar tanımlanır. Ağ bir girdi, bir çıktı ve üç gizli katmandan oluşur. Her katmanın nöronlarının bulanık arayüzün hesaplanmasındaki üç farklı aşamayı temsil eden farklı aktivasyon fonksiyonları vardır. Aktivasyon fonksiyonu, problemler için bireysel olarak seçilebilir. Ağ, bir bulanık kural tabanı ve karşılıklı üyelik fonksiyonları ile başlatılır. Girdi değişkenleri, girdi nöronlarında saklanır. İlk katmandaki nöronlar üyelik fonksiyonları içerir ve bu girdi değerlerinin bulanıklaştırılmasını gerçekleştirir. İkinci gizli katmanda birleşmeler bulanık-VE hesaplanır. Çıktı değişkenlerinin üyelik fonksiyonları üçüncü gizli katmanda saklanır. Son olarak, çıktı nöronları çıktı değişkenlerini içerir ve bir durulama aktivasyon fonksiyonu vardır.

Kurallar ve üyelik fonksiyonları, Bulanık Ağ başlangıç ağı inşa etmek için kullanılır. Sonra kural tabanı, ağın veya nöronlardaki verilerin yapısını değiştirerek optimize edilebilir. Kuralları öğrenmek için, kuralların ve bulanık değerlerin arasındaki bağlantılar değiştirilir. Üyelik fonksiyonlarını öğrenmek için, birinci ve üçüncü gizli katmanlardaki düğümlerin verileri değiştirilir. Bulanık Ağ, danışmanlı ve danışmansız öğrenim gibi standart sinirsel stratejilerle eğitilebilir.

Kurallar, katmanların arasındaki bağlantılar sayesinde temsil edilir. Kuralların öğrenilmesi bir olasılıksal arama olarak uygulanır: rastgele seçilmiş bir bağlantı değiştirilir ve yeni ağ performansı maliyet fonksiyonu ile doğrulanır. Eğer performans daha kötü ise değişiklik geri alınır, eğer tam tersi performans arttıysa değişiklik korunur ve istenilen çıktı başarılana kadar daha başka değişiklikler test edilir.

Bulanık Ağ üyelik fonksiyonlarını güncellemek için, gradyan inişi ve anlamsal aramanın bir karışımını kullanır. Bulanık Ağ sistemi her değişken için belirli

sayıdaki kurallar ve belirli sayıdaki ilk bulanık gruplar belirleyerek başlatılır ve ağ üyelik fonksiyonlarının ve ağ, ağ yapısının içindeki bağlantıların rastgele parametrelerini değiştiren olasılıksal bir prosedür sayesinde öğrenir. Resmi bir sinirsel ağ öğrenme tekniği kullanılmadığından Bulanık Ağ' a bir sinirsel-bulanık sistem demek tartışmaya açıktır [35].

5.8.12. Evrimleşen bulanık sinirsel ağlar

Evrimleşen Bulanık Sinirsel Ağlar ve Dinamik Evrimleşen Bulanık Sinirsel Ağlar evrimsel, artımlı, hibrit (denetimli/denetimsiz) ve çevrimiçi öğrenme için biçimlenmiş uyarlanır akıllı sistemler Evrimleşen Bağlayıcı Sistemler iskeletine dayalıdır.

Yerel element ayarlamasıyla yeni özellikler ve yeni sınıflar içeren yeni girdi verilerini barındırabilirler. Evrimleşen Bulanık Sinirsel Ağlar' da bütün düğümler öğrenim sırasında yaratılır. İkinci düğüm katmanı her girdi değişkeni boşluğunun bulanık ölçümünü temsil eder. Burada değişkenin bulanık ölçümünü temsil etmek için her girdi değişkeni boşluklu dizilmiş nöronlar tarafından temsil edilir. Üyelik fonksiyonlarını temsil eden düğümler (üçgensel, Gaussian, vs.) öğrenme sırasında modifiye edilebilir. Üçüncü katman hibrit danışmanlı/danışmansız öğrenme sayesinde evrimleşen kural düğümlerini içerir. Kural düğümleri girdi-çıktı veri ortaklıklarının prototipini temsil eder, grafiksel olarak hiper-çemberlerin bulanık girdi ve çıktı boşluklarıyla ortaklıkları şeklinde temsil edilir. Her kural düğümü iki bağlantı ağırlığı vektörü ile tanımlanır: birincisi çıktı hatasına dayalı denetimli öğrenim ile ayarlanırken, ikincisi girdi problem boşluğunun yerel bir bölgesindeki benzerlik ölçüsüne dayalı denetimsiz öğrenim ile ayarlanır. Dördüncü katmanı çıktı değişkenleri için bulanık ölçümünü temsil eder. Beşinci katman çıktı değişkenlerinin gerçek değerlerini temsil eder [35].

5.8.13. Dinamik evrimleşen bulanık sinirsel ağlar

Dinamik Evrimleşen Bulanık Sinirsel Ağlar modeli, sadece kazanan kural düğümünün aktivasyonunun yayılmadığı, bir grup kural düğümünün her yeni girdi vektörü için dinamik olarak seçildiği ve onların aktivasyon değerlerinin çıktı fonksiyonunun dinamik parametrelerini hesaplamak için kullanıldığı fikri ile geliştirilmiştir.

Evrimleşen Bulanık Sinirsel Ağlar, Mamdani tipinin ağırlıklı bulanık kurallarını kullanırken, Dinamik Evrimleşen Bulanık Sinirsel Ağlar Takagi-Sugeno bulanık kurallarını kullanır. Dinamik Evrimleşen Bulanık Sinirsel Ağlar' ın birinci, ikinci ve üçüncü katmanları, Evrimleşen Bulanık Sinirsel Ağlar ile tamamen aynı yapıya ve fonksiyonlara sahip. Dördüncü katman (bulanık çıkarsama katmanı) kural düğümlerini bulanık girdi vektörüne en yakın bulanık normalleştirilmiş yerel uzaklığa sahip üçüncü katmandan seçmiştir ve daha sonra, ağırlıklı en küçük kare yöntemi kullanarak bir Takagi Sugeno bulanık yapısı oluşturmaktadır.

Son katman Dinamik Evrimleşen Bulanık Sinirsel Ağlar çıktısını hesaplar. Çıktı değerlerini hesaplamak için kullanılan aktive edilmiş düğümlerin sayısı, girdi düğümlerinin sayısının bir fazlasından az değildir. Evrimleşen Bulanık Sinirsel Ağlar gibi, Dinamik Evrimleşen Bulanık Sinirsel Ağlar da hem çevrimdışı hem de çevrimiçi öğrenim için kullanılabilir böylece küresel veya yerel genelleştirme hatası optimize edilir.

Dinamik Evrimleşen Bulanık Sinirsel Ağlar yeni bir girdi vektörü için (çıktı vektörü bilinmeyen) kural düğümlerinden oluşmuş bir alt uzay bulunur ve en küçük kare metodunu kullanarak bir ilk Takagi Sugeno yapısı oluşturur [35].

6. UYARLAMALI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ VE TAHMİN PROBLEMİ

Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neural Fuzzy Inference System- ANFIS), bir girdi/çıktı dizisi kullanmak suretiyle veya yalnız başına bir geri yayılma algoritması kullanarak ya da bu yöntemin en küçük kareler tipiyle birlikte kullanılması üzere üyelik fonksiyon parametreleri ayarlanan bir Bulanık Çıkarım Sistemi (FIS) oluşturur. Bu durum bulanık sistemin modellediği verilerden öğrenebilmesini mümkün kılar [131].

ANFIS yapısı, Takagi Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur [25].

Sinirsel bulanık öğrenme tekniklerinin ardındaki temel fikir çok basittir. Bu teknikler, verilen girdi ve çıktı verilerini izlemek amacıyla bileşik bulanık çıkarım sistemine izin veren üyelik fonksiyon parametrelerini hesaplamak için bir veri dizisi hakkında bilgi öğrenmek, bulanık modelleme prosedürü için bir yöntem temin etmektedir. Bu öğrenme yöntemi YSA'ya benzer şekilde işlemektedir.

ANFIS, Bulanık Çıkarım Sistemleri ve Çok Katmanlı Uyarlamalı Ağların çok genel hesaplama yönteminin özel örneğidir. ANFIS, uyarlamalı ağların, işlevsel olarak bulanık çıkarım sistemine eşdeğer olan bir sınıfıdır. Üyelik fonksiyonu parametre ayarlamasını sonuçlandıran sistem olarak bilinir [131]. Popülerlikleri yapının basitliğinden, çok iyi kurulmuş teorik temelden ve diğer sinirsel ağ tiplerine göre daha hızlı öğrenme özelliğinden ileri gelmektedir.

6.1. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi Mimarisi

ANFIS' in temel öğrenme algoritması, en küçük kareler yöntemi ile geri yayılmalı öğrenme algoritmasının bir arada kullanılmasından oluşan melez öğrenme

algoritmasıdır. ANFIS, ele alınan problem için oluşturulan yapıya göre olası tüm kuralları atayabilmekte veya kuralların veriler yardımıyla uzman tarafından atanmasına olanak vermektedir. ANFIS' in kural oluşturabilmesi veya kural oluşturulmasına olanak sağlaması uzman görüşlerinden faydalanması anlamına gelmektedir. Bu nedenle birçok tahmin probleminde YSA uzman görüşlerinden faydalanma imkânı tanıdığı için ortalama hata kareler kriterine göre daha iyi sonuçlar elde edilmesini mümkün kılmaktadır [32,33].

ANFIS için kullanılan modelleme yaklaşımı birçok sistem tanımlama tekniklerine benzerdir. Önce, parametreleştirilen bir model yapısı varsayımlanır. Daha sonra, eğitim için ANFIS tarafından kullanılabilecek biçimde olmak üzere girdi-çıktı verileri toplanır. Bundan sonra seçilen bir hata kriterine göre üyelik fonksiyon parametrelerini değiştirmek suretiyle sunulan eğitim verilerini taklit etmek amacıyla modellenir. Bulanık çıkarım sistemi modelini ağa öğretmek için ANFIS kullanabilir [131].

ANFIS tahmin aracı tasarımı iki bölümden oluşmaktadır: inşa etme ve eğitme. İnşa kısmında yapı parametreleri belirlenir. Bunlar girdi üyelik fonksiyonları (MF) tipi ve sayısı, çıktı üyelik fonksiyonları tipidir. Birçok üyelik fonksiyonları arasından uygun üyelik fonksiyonu seçilebilir [133].

ANFIS' deki bazı kısıtlamalara ise;

ANFIS, yalnızca Sugeno tipi sistemleri destekler ve bu sistemler aşağıdaki özelliklere sahip olmalıdır.

- Birinci veya sıfırıncı sıra Sugeno tipi sistemler için uygulanabilir.

- Tek çıktı ağırlıklı ortalama durulaştırma kullanılarak elde edilir (doğrusal veya sürekli çıktı üyelik fonksiyonları).

- Her kural için birim ağırlık belirlenir.

Kurulan üyelik fonksiyonları ve oluşturulan kural tabanı sistemi tam olarak tanımlamayabilir. Bu gibi durumlarda belli girişlere verilmesi gereken tepki biliniyorsa, bir başka deyişle sistem hakkında elde yeterli ve sağlıklı veriler varsa, ANFIS sistemi kullanılarak tüm sistemin programlanması otomatikleştirilebilir [126,127].

Basit olması açısından, bulanık çıkarım sistemini, x ve y gibi iki girişi ve z gibi bir çıkışı olan bir ANFIS yapısı için, iki tane bulanık Eğer-O Halde kuralı bulunan, birinci dereceden Sugeno bulanık modelinin tipik kural kümesi;

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

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

Şeklinde ifade edilir. Bu yapıya karşılık gelen, eşdeğer ANFIS mimarisi Şekil 5.4' de gösterildiği gibidir. Söz konusu ANFIS mimarisi için aynı katmanda bulunan düğümler, aşağıda da gösterildiği üzere aynı düğüm fonksiyonlarına sahiptirler.

ANFIS yapısının bazı eşsiz özellikleri şöyle tanımlanabilir.

- Öğrenme yeteneği.
- Paralel işlem.
- Yapılandırılmış bilgi temsili.
- Diğer denetim tasarım yöntemleriyle daha iyi bütünleşme.

ANFIS mimarisi 6 katmandan oluşmaktadır. Birinci dereceden iki girişli ve iki kurallı "Sugeno Bulanık Modeli" ve eşdeğer ANFIS yapısı.

1.Katman:

Bu katmanda yer alan her bir *i* düğümünün çıkışı aşağıdaki gibi tanımlanan uyarlamalı bir düğümdür. Burada x düğümün girişini temsil etmektedir.

$O_{l,i} = \mu_{A\,i}(x)$, $i=1,2$ ya da (6.1)

$O_{l,i} = \mu_{B\,i-2}(x)$, $i=3,4$ için (6.2)

Bir başka ifadeyle, bu katmanın çıkışları, kuralların şart ya da öncül kısımlarına ait üyelik değerlerini oluştururlar. Burada *Ai* ve *Bi* için söz konusu üyelik fonksiyonları, uygun bir biçimde parametrelendirilmiş herhangi bir üyelik fonksiyonu olabilir.

2. Katman:

Bulanıklaştırma katmanı olarak adlandırılır. Bu katmanda her bir düğümün çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır ve 2. katmandan elde edilen üyelik dereceleri $\mu_{A_j}(x), \mu_{B_j}(y)$ şeklinde gösterilir.

3.Katman:

Kural katmanıdır. Bu katmandaki her bir düğüm, Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve sayısını ifade etmektedir. Her bir kural düğümünün çıkışı μ_i, 2. katmandan gelen üyelik derecelerinin çarpımı olmaktadır. μ_i değerlerinin elde edilişi ise, (j=1,2) ve (i=1,….,n) olmak üzere;

$$y_i^3 = \prod_i = \mu_{Ai}(x) \times \mu_{Bi}(y) = \mu_i \quad (6.3)$$

şeklindedir. Burada, y_i^3, 3. katmanın çıkış değerlerini; n ise bu katmandaki düğüm sayısını ifade etmektedir.

4. Katman:

Normalizasyon katmanıdır. Bu katmandaki her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul etmekte ve her bir kuralın normalleştirilmiş ateşleme seviyesini hesaplamaktadır.

Normalleştirilmiş ateşleme seviyesi $\overline{\mu}_i$' nin hesaplanması ise;

$$y_i^4 = Ni = \frac{\mu_i}{\sum_{i=1}^{n} \mu_i} = \mu_i \ , \ \text{(i=1,n)} \tag{6.4}$$

formülüne göre gerçekleştirilir.

5.Katman:

Arındırma katmanıdır. Arındırma katmanındaki her bir düğümde verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanmaktadır. 5 katmandaki i. düğümün çıkış değeri ise;

$$y_i^5 = \overline{\mu_i}\left[p_i x_i + q_i x_2 + r_i\right] \text{, (i=1,n)} \tag{6.5}$$

şeklinde olmaktadır. Buradaki (p_i, q_i, r_i) değişkenleri, i. kuralın sonuç parametreleri kümesidir.

6.Katman:

Toplama katmanıdır. Bu katmanda sadece bir düğüm vardır ve Σ ile etiketlenmiştir. Burada, 5. katmandaki her bir düğümün çıkış değeri toplanarak ANFIS sisteminin gerçek değeri elde edilir.

Sistemin çıkış değeri olan *y*' nin hesaplanması ise;

$$y_i = \sum_{i=1}^{n} \overline{\mu}_i\left[p_i x_i + q_i x_2 + r_i\right] \text{, (i=1,n)} \tag{6.6}$$

denklemine göre olmaktadır [11].

Bulanık çıkarım sisteminin temel yapısı girdi niteliklerini, girdi üyelik niteliklerine, girdi üyelik niteliklerini kurallara, kuralları bir dizi çıktı niteliklerine, çıktı niteliklerini de tek bir değerli çıktıya veya çıktı ile bağlantılı bir karara eşlemleyen bir modeldir.

6.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Parametre Ayarlaması ve Eğitim

ANFIS, karar süreçlerinde tercih edilen bir yaklaşım olarak literatürde yer almaktadır. ANFIS, insan benzeri karar verme yetisini hızlıca öğrenmekte ve bulanık üyelik fonksiyonları yardımıyla doğrusal olmayan kısıtlar için uygunluk derecesi hesaplayıp bunları sisteme entegre edebilmektedir.

Genel anlamda bulanık çıkarım, üyelik fonksiyonlarının şekli ve üyelik fonksiyonlarının şeklini değiştirmek için ayarlanabilen parametrelere dayanmaktadır. Parametreler modellemeye çalıştığımız verilere bağlı olarak otomatik olarak ayarlanabilir [132].

Verilen bir üyelik fonksiyonu ile bağlantılı parametreleri gelişigüzel olarak seçmekten ziyade, bu parametreler, veri değerlerindeki varyasyonları açıklamak amacıyla üyelik fonksiyonlarını girdi-çıktı verilerine uydurmak için seçilebilir. Üyelik fonksiyonları ile bağlantılı parametreler öğrenme süreci vasıtasıyla değişecektir. Bu parametrelerin hesaplanması bulanık sonuç çıkarma sisteminin bir dizi parametre için girdi-çıktı verilerini ne kadar iyi modellediğini gösteren bir eğim vektörü tarafından kolaylaştırılır. Eğim vektörü elde edildiğinde, bazı hatalı ölçümleri azaltmak için parametreleri ayarlamak amacıyla birçok optimizasyon rutinlerinden herhangi biri uygulanabilir. ANFIS eğitimi için mevcut olan iki parametre optimizasyon yöntemi mevcuttur. İlk yöntem hibrit (en küçük kare ve geri yayılım) veya geri yayılım seçenekleridir. Hata toleransı, hatanın boyutuna bağlı olan eğitim durdurma hata kriteri yaratmak için kullanılır. Eğitim veri hatasının tolerans dahilinde kalmasından sonra duracaktır [131].

MATLAB programı ANFIS Bulanık Mantık Araç Kutusu ile eğitimin başarısı kolayca görselleştirilebilir. Eğitim belirlenen parametreler ile tamamlanır. Ağın eğitim başarısı kontrol veri grubunun RMSE değerlerindeki değişim incelenerek kolayca belirlenir. Seçilen üyelik fonksiyonu parametreleri için genellikle en iyi yöntem yoktur, bu nedenle deneme yöntemi ile ağın performansı kontrol edilir.

Kural olarak, kontrol veri dizisi hatası, eğitimin aşırı uyuma başlayan noktaya kadar gerçekleşmesi yüzünden azalmaya eğilim göstermektedir. Daha sonra kontrol verisi için model hatası aniden artar. Model doğrulama için bir kontrol veri dizisi kullanımının arkasında yatan temel kritik noktalardan biri de eğitimde belirli bir noktadan sonra modelin eğitim veri dizisine aşırı uymasıdır. Aşırı uyum oluşursa bulanık çıkarım sistemi özellikle başka bağımsız veri kümeleri için iyi bir tahmin aracı olmaktan uzaklaşabilir. Bu gibi durumların önlenebilmesi için bir kontrol veri seti yararlı olabilir. Seçilecek veri seti bulanık çıkarım modelini çapraz doğrulamak için kullanılır. Bu çapraz doğrulama için seçilen kontrol veri modeli sisteme girilmeli ve daha sonra model ile verilerin ne kadar iyi bir uyuma sahip olduğu kontrol edilmelidir. Üyelik fonksiyonu parametrelerini ayarlamak için Ortalama Karekök Hatası (Root Mean Square Error-RMSE) yöntemi kullanılır. RMSE, bir tür genelleştirilmiş standart sapmadır. Alt gruplar arasındaki farklılıkların ya da değişkenler arasındaki ilişkileri açıklar.

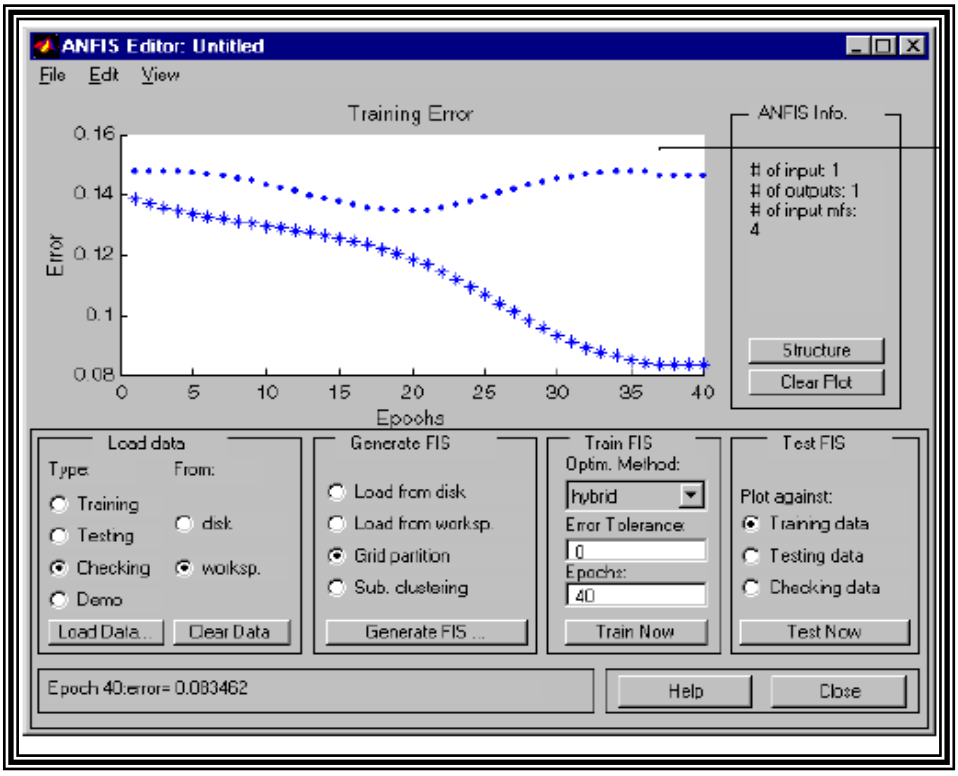
$$\text{RMSE} = \sqrt{\frac{\sum \left(f(x_i) - y_i \right)^2}{n}} \tag{6.7}$$

x_i tahmin edilen değeri, y_i ise gerçek değeri göstermektedir, n veri seti büyüklüğüdür.

Eğitim hatası, eğitim sonrası veri çıkış değeri ile aynı eğitim sonucu için veri giriş değerine (eğitimin veri çıkış değeri ile ilişkili olan) karşılık gelen bulanık çıkarım sisteminin çıkışları arasındaki fark olarak RMSE şeklinde tanımlanabilir. Kontrol Hatası ise kontrol verilerin her döngü için bulanık çıkarım sisteminin tahmin yeteneğini test etmesiyle RMSE formülü ile hesaplanır.

ANFIS kullanılarak inşa edilen modeller için model doğrulaması ile ilgili bir problem de doğrulama sürecinde eğitim verisinden yeterli şekilde ayrı olan hem de eğitilen modelin taklit etme amacında olmayan veri dizisinin seçilmesidir. Büyük sayıda veri toplamış olunması halinde, umulmalıdır ki bu veriler tüm gerekli temsil özelliklerini içersin, bu şekilde, kontrol veya test amaçlarına yönelik bir veri dizisi seçimi daha kolay olmaktadır. Bununla birlikte, gürültü sebeplerinin kapsanmadığı durumlarda, eğitim veri dizisinin modellemek istenen tüm temsil özelliklerini içermemesi mümkündür.

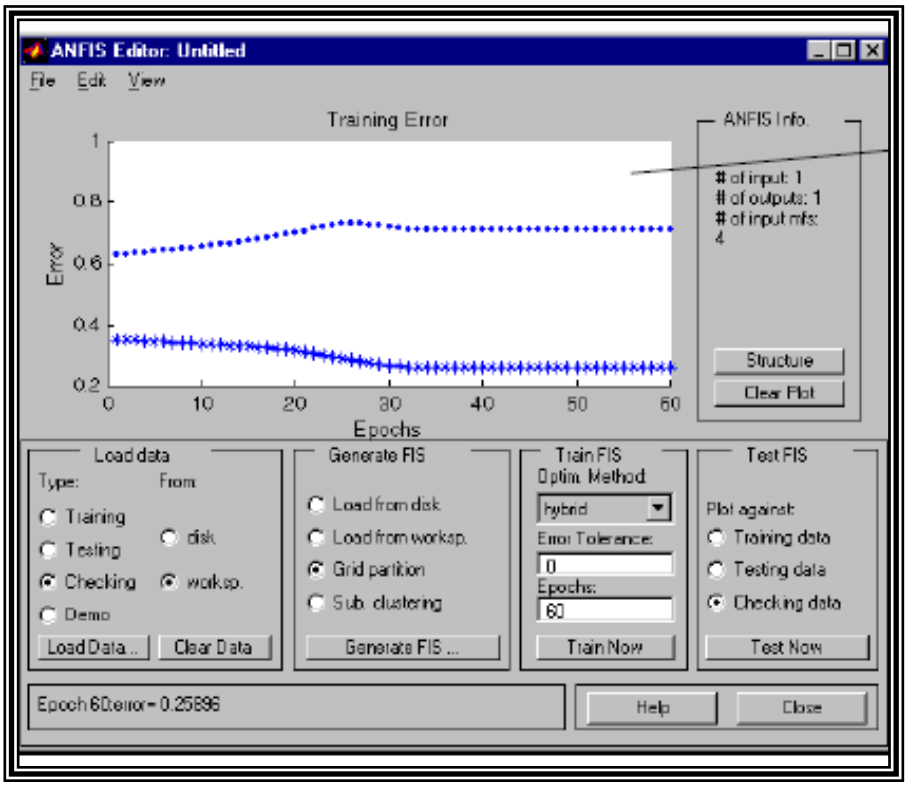
Şekil 6.1’ de kontrol RMSE değeri belli bir noktaya kadar azalır ve sonra da artar. Bu artış modeli aşırı uyumlu noktasını temsil eder. ANFIS, minimum kontrol RMSE değeri ile oluşan model parametrelerini seçer. Bu örnek, ANFIS kontrol veri seçeneğinin neden kullanışlı olduğunu gösterir. Kontrol hatasının eğitimle belirli bir noktaya kadar nasıl düştüğünü ve daha sonra arttığına dikkat etmek gereklidir.



Şekil 6.1: MATLAB ANFIS Editör Arayüzü Model 1

Şekil 6.2' de, kontrol RMSE değeri oldukça büyüktür. Minimum kontrol RMSE değeri, ilk deneme içinde meydana gelmiştir. Bu örnekteki üyelik fonksiyonları eğitim veri modellemesi için iyi bir seçenek değildir [131].

ANFIS eğitimi konusunda önemli bir nokta da öğrenmenin sürekli devam edeceğidir. Bir optimum noktaya gelindiğinde, veri setinin genel istatistiksel trendine göre kendisini biçimlendirir. Optimum noktadan sonra ise eğitmeye devam edilmesi durumunda ağ öğrenmeye devam edecektir. Bu aşamada, ağ veri setinden hatalı ilişkiler çıkartmaya başlayabilir. Bu yüzden aşırı eğitme sorununa dikkat edilmeli ve eğitme uzunluğu kontrol verileriyle iyi ayarlanmalıdır [11].



Şekil 6.2: MATLAB ANFIS Editör Arayüzü Model 2

6.3. Literatür Araştırması

Çalışma kapsamında Eşzamanlı Sinirsel Bulanık Sistemler (Concurrent Neural Fuzzy Inference System–CNFS) ve otomotive arıza - maliyet tahmini yöntemleri üzerine literatürdeki çalışmaları incelenmiştir;

CNFS ile basketbolda oyuncu seçimi için bir model geliştirmiştir [139]. Başka bir çalışmada CNFS ile mikroşerit antenlerin rezonans frekansının hesaplanması için bir model geliştirmişlerdir [140]. Başarılı bir doktora tezinde, CNFS içerisinde SOM ve ANFIS yapıları kullanılarak su kalitesini değerlendirmek için bir model oluşturmuştur [141]. Çelik tabakaların ısıl işlem süreci CNFS ile modellemiştir [142]. Çalışma ile güç sistemlerinin güvelik değerlendirme süreçleri CNFS ile modellenmiştir [143]. İnternet üzerindeki arama performansının iyileştirmesi için yapılan çalışmada, oluşturulan CNFS bulanık sınıflama, bulanık çıkarım ve SOM modüllerinden oluşmaktadır [144]. Düşen yağmur miktarının tahmin edilebilmesi için oluşturulan CNFS algoritmalarını kullanmaktadır [145].

Otomotiv sektöründe maliyet tahmini çalışmalarda, otomotiv sigorta sektöründe müşteri odaklı risk sınıflandırma ve maliyet tahmini sorunlarına YSA yardımıyla çözümler üretmiştir [146]. Benzer başka bir çalışmada maliyet tahmini sorunlarına YSA' nın özel bir türeci yardımıyla çözümler üretmiştir [147]. Otomotiv sigorta sektöründe başka bir çalışmada Bulanık-C, K-Ortalamalar ve sezgisel metotlar ile maliyet tahmini modelleri oluşturmuştur [148-149]. Otomotiv satış rakamlarını tahmin edebilmek için ANFIS yapısından yararlanılmıştır [150]. Araçların farklı noktalarından toplanan sinyallerin, geliştirilen YSA ile arızaları tespit etmesini sağlayan bir çalışma yapılmıştır [151]. Geliştirilen mimari, araç arızalarını YSA ve bulanık mantık temelli tekrarlı bir modelle belirlemektedir [152]. Oluşturulan eşzamanlı mimari ile YSA, bulanık çıkarım ve geleneksel regresyon metotları ile makine arızalarının sürelerini göz önüne alan bir teslimat süresi hesaplayıcısı geliştirilmiştir [153].

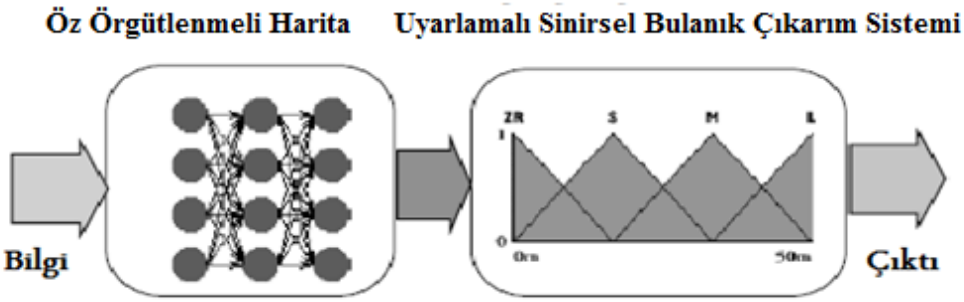
7. EŞZAMANLI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ İLE OTOMOTİV SERVİS ENDÜSTRİSİ ÜZERİNE BİR ÇALIŞMA

7.1. Eşzamanlı Sinirsel Bulanık Çıkarım Modelinin Oluşturulması

Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi (Concurrent Neural Fuzzy Inference System-CNFS) ile otomotiv servis endüstrisi üzerine yapılan çalışmada, seçilen bir otomotiv firmasına ait belirli bir modeldeki aracın, 2003 ve 2007 model yılına ait Servis Müşteri Takip Sistemi (SMTS) kayıtları incelenmiştir. Araç modelinin kısıtlanmasının nedeni farklı modeller arasındaki şikâyet ve arıza ilişkisinin ayrı ayrı ele alınmasının daha sağlıklı bir sistem oluşturacağının öngörülmesidir. Çalışma kapsamında seçilen araç Türkiye' de geniş bir coğrafi kullanım alanına sahiptir.

CNFS' nin öncelikli olarak SMTS' den seçilmiş olan araçlara ait müşteri şikâyetlerini sınıflandırması ve sıralaması gerekmiştir. SOM yöntemi kullanılarak çeşitli müşteri şikâyetleri ile servise getirilen araçlar gruplamakta, gruplanan şikâyetler belirli bir puanlama sistemine göre sıralanmaktadır.

SOM modülü, CNFS' nin ilk işlem elemanı veya başka bir ifadeyle giriş modülünü oluşturmaktadır. Elde edilen arıza indeks puanları ile beraber aracın kilometre ve yaş bilgileri özel bir Sinirsel Bulanık Çıkarım Sistemi olan ANFIS' de hesaplamaya sokulmuştur. ANFIS sistemi arıza tespiti ve arıza tutarının tahmin edilebilmesi için kullanılmıştır. ANFIS, CNFS' nin ikincil işlem birimini bir başka ifadeyle çıkış modülünü oluşturmaktadır. Tasarlanan CNFS Şekil 7.1' de belirtilmiştir.



Şekil 7.1: Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi ile Arıza Tahmin Modeli

7.2. Başlangıç Veri Setinin Oluşturulması

Çalışma kapsamında geliştirilen Eşzamanlı Sinirsel Bulanık Çıkarım Sistemi (Concurrent Neural Fuzzy Inference System-CNFS), arızaların tahmini tamir maliyetini ve arıza türünü hesaplayabilmek için tasarlanmıştır. Müşteri şikâyetleri veri seti, otomotiv firmasının yetkili servislerine gelen müşteriler tarafından servis danışmanlarına aktarılan ve servis danışmanlarının SMTS' ye girişini yaptığı sözel verilerden oluşmaktadır.

Mevcut durumda servise gelen araçlarda tespit edilen kullanıcı şikâyetleri ve aracın tamir sürecinin başlayıp müşteriye teslim edilmesine kadar geçen süre zarfında yapılan tüm işlemler SMTS' ye kayıt edilmekte ve sistem üzerinden takip edilebilmektedir. Servis danışmanları müşteri şikâyetleriyle beraber aracın kilometre ve model yılı bilgilerini de SMTS' ye girmektedirler. Ayrıca aracın ruhsat bilgileri, aracın garanti bilgileri ve arıza tespit bilgileri de SMTS' ye servis danışmanları tarafından kayıt edilmektedir. Aracın tamir işlemlerinin tamamlanmasının ardından masraf tutarı ve atanan departman gibi ilave bilgiler sisteme aktarılmaktadır.

Otomotiv firmasının servislerinde kullanılan SMTS' de müşteri şikâyetlerinin sınıflandırılması ve bunların değerlendirilmesine yönelik bir işlem yapılmamakta, müşteri şikâyetleri ile araç üzerinde yapılan işlemler akıllı bir sistem aracılığı ile karşılaştırılmamaktadır.

Çalışmaya başlarken firmanın yetkili servislerinde servis danışmanları tarafından SMTS' ye kayıt edilmiş müşteri şikâyet bilgileri uygun şekilde derlenmiştir. Derleme işlemi sırasında, kayıtlar içerisinde çeşitli ön kontroller yapılarak hata faktörleri

tespit edilmiş ve ayıklanmıştır. Seçilen arıza ve müşteri şikâyet kombinasyonları, SMTS eğitmenleri yardımıyla detaylandırılmıştır. Mevcut arızalara ait müşteri şikâyetlerine, gözardı edilmiş ve unutulmuş şikâyetler de SMTS eğitmenleri tarafından dahil edilmiştir. Çalışmanın kapsamı araçların motor, şanzıman ve yürüyen aksamında meydana gelen arızalar kapsayacak şekilde daraltılmıştır.

Yapılan bu derleme ile yetkili servislerde kullanılan mevcut sistemin kullanıcıları olan servis danışmanlarının, araçtaki farklı arızalar için tek bir arızayı göz önüne alan şikâyetler girmesi ve servis otomasyon kayıtlarının sisteme girilmesi sırasında arıza şiddeti detayından kaçınılmış olmasının yaratmış olduğu veri kirliliği ve kaybı ortadan kaldırılmaya çalışılmıştır.

Geliştirilen sistemin başarısını arttırmak için tekrar eden şikâyetlerden ve hatalı girilmiş olası şikâyetlerden arındırılmış bir veri seti ile çalışılmaya başlanmıştır. Bu amaçla yaklaşık 35.000 araca ait şikâyet taranarak, doğru sınıflandırma sonuçları elde edebilmek için uygun görülen 141 araca ait şikâyetler seçilmiştir. Böylece geliştirilecek yapının en doğru müşteri şikâyet kayıtları ile oluşması ve öğrenmenin doğru kayıtlarla gerçekleştirilmesi amaçlanmıştır. Toplam 37 adet müşteri şikâyeti çalışma kapsamına dahil edilmiştir.

Müşterilerin vermiş olduğu yanıtlara ve servis SMTS uzman öngörülerine göre şikâyet parametrelerinin ve şikâyetlere verilen cevapların ağırlıkları belirlenmiştir. Müşteri şikâyet açıklamaları düzenlendikten sonra verilen cevaplara ve SMTS eğitmenleri öngörülerine göre [0,1] aralığında değerler şikâyetler Tablo 6.1' deki gibi atanmıştır.

SMTS' ye aktarılmış arızalı araçlardan toplanan 141 kaydın her bir satırında 37 farklı şikâyete verilen cevaplar ve bu cevapların ağırlıkları yer almaktadır. Bu işlem için oluşturulan matris Ek 4' de Şikâyet Ağırlık Matrisi olarak sunulmuştur. Cevaplanmayan veya belirtilmeyen müşteri şikâyetleri için sisteme 1.0 E-04 gibi çok küçük bir değer girilmiştir. Kümeleme işleminde her bir şikâyetin cevaplardaki farklılıklardan dolayı baskın çıkması bu şekilde önlenmiştir. Verilerin düzenlenmesi,

modelin kurulması ve sonuçların değerlendirilmesi için MATLAB programı YSA araç kutusu, ANFIS editörü ve komut satırlarından faydalanılmıştır.

Tablo 7.1: Şikâyet ağırlık değerleri

No	Arıza Değeri	Şikâyet Açıklaması
1	0,9999	Evet /Her Zaman/Çok Fazla/Çok Kötü
2	0,75	Evet /Sıklıkla/Fazla/Kötü
3	0,5	Evet /Bazen
4	0,25	Evet /Çok Az
5	0,0001	Belirtilmemiş

Tablo 7.2: Müşteri şikâyet listesi

1. Aracın zayıf/bitmiş akü lambası yanıyor mu?
2. Araç sabahları zor mu çalışıyor?
3. Araç durduktan sonra tekrar çalıştırmakta zorlanıyor musunuz?
4. Aracın motoru ateşleme yapmıyor mu?
5. Aracın motoru ateşleme yapıyor ancak çalışmıyor mu?
6. Araç düzensiz rölanti yapıyor mu?
7. Araç seyir sırasında stop ediyor mu?
8. Araç yüksek yakıt tüketimi yapıyor mu?
9. Aracın motorundan düşük devirde faklı ses geliyor mu?
10. Araç düzgün çalışıyor ancak performans düşük mü?
11. Motordan farklı bir ses geliyor mu?
12. Araç sabahları hava soğukken çalışmıyor mu?
13. Araç seyir halinde titriyor mu?
14. Motor soğukken çalıştırıldığında beyaz duman atıyor veya tekleme yapıyor mu?
15. Araç ısınınca stop ediyor mu?
16. Aracın motoru aşırı ısınıyor/su kaynatıyor mu?
17. Aracın motoru çok hızlı ısınıyor mu?
18. Araç motor uyarı lambası yanıyor mu?
19. Araç egzozdan duman atıyor mu?
20. Araç siyah duman atıyor mu?
21. Frenlerde sürtme sesi var mı?

Tablo 7.2: Müşteri şikâyet listesi(Devamı)

22. Fren pedalı sert mi?
23. Araç frene basılınca sola veya sağa çekiyor mu?
24. Frenlerin durdurma performansı iyi mi?
25. Fren pedalında titreme var mı?
26. Araç tümsekten geçerken ses yapıyor mu?
27. Fren sıvısı sızıntısı yapıyor mu?
28. Yakıt sızıntısı yapıyor mu?
29. Belirlenemeyen sıvı sızıntısı var mı?
30. Vites değiştirirken veya geri vitese takarken ses var mı?
31. Dönerken ses var mı?
32. Araç rölanti vaziyetteyken titreşim var mı?
33. Fren yaparken titreşim var mı?
34. Kalkışta kavrama yapmama oluyor mu?
35. Araç vitesten kendi kendine atıyor mu?
36. Vites değiştirirken ses ve ön taraftan uğultu geliyor mu?
37. Aracın alt/ön tarafından ses geliyor mu?

7.3. Öz Örgütlenmeli Harita Modelinin Kurulması

Tasarlanan sistemin ilk adımı olan Öz Örgütlemeli Haritalar (Self-Organized Map-SOM) mimarisi, MATLAB komut satırı kullanılarak oluşturulmuştur. SOM ağını oluşturmak için MATLAB programı 'newsom' fonksiyonu, doğru parametreler ile tanımlanmıştır. Ağ yapısının tanımlanması aşamasında ızgara yapısının büyüklüğü, çıktı topolojisi, uzaklık fonksiyonu, adım sayısı, başlangıç komşuluk uzaklığı değerleri sırasıyla aşağıda belirtildiği üzere tanımlanmıştır.

Çıktı Izgara Yapısının Büyüklüğü (Di), Ağ oluşturulurken çıktı katmanındaki satır ve sütun sayıları belirlenmiştir. Çalışmada en başarılı kümeleme sonuçlarını veren 6x6 ızgara çıktı katmanı seçilmiştir. SOM parametrelerinin sabit tutulduğu ve ızgara yapısının 5x5 ve 4x4 ile oluşturulduğu ağlarda doğru kümeleme performansında azalma tespit edilmiştir. 7x7' lık ızgara yapısında istenilen seviyede kümeleme

gerçekleşmemiştir. Ek 3' de detaylı olarak kümeleme sonuçları hakkında bilgi verilmiştir.

Tablo 7.3: SOM kümeleme performansı

SOM Mimarisi	6x6 Mimari	5x5 Mimari	4x4 Mimari
Kümeleme Başarı Oranı	92.20%	75.89%	74.47%

- Çıktı Topolojisi (TFCN), altıgen çıktı topolojisi seçilmiştir. Öz örgütlemeli harita dahilindeki katmandaki nöronlar, belirli bir topoloji fonksiyonuna göre orijinal olarak düzenlenir. MATLAB programında yer alan gridtop, hextop veya randtop fonksiyonları nöronları bir şebeke dizge, altıgen veya rastlantısal topolojiye göre düzenler. Nöronlar arasındaki uzaklıklar mesafe fonksiyonu vasıtasıyla konumlarından hesaplanır.

- Uzaklık Fonksiyonu (DFCN), Bağlantı uzaklık fonksiyonu seçilmiştir. Bağlantı uzaklık fonksiyonu öklid uzaklığın vektörel hesaplamalar için geliştirilmiş özel bir türevidir.

- Adım Sayısı: (STEPS), Komşuluk uzaklığını 1 basamak düşürmek için gerekli olan adım sayısı 1000 adım olarak belirlenmiştir.

- Başlangıç Komşuluk Uzaklığı (IN), 3 birim olarak tanımlanmıştır.

Oluşturulan ağ yapısı için MATLAB programı YSA araç kutusu komut satırına, uygun eğitim algoritmasının tanımlanması gerekmiştir. Sınıflandırma için artımlı eğitim algoritması kullanılarak SOM ağının eğitimi gerçekleştirilmiştir. Seçilebilecek iki eğitim algoritmasını incelediğimizde;

- Yığın/toplu eğitim algoritması ile ağın eğitilmesi genellikle artımlı algoritmadan çok daha hızlıdır. Bu algoritma MATLAB uygulamasında SOM ağları eğitimi için varsayılan algoritmadır. SOM yığın öğrenme özelliği varsayılan yığın eğitim modu olan 'trainbuwb' fonksiyonu ile oluşur. SOM için MATLAB uygulamasında ağırlık öğrenme fonksiyonu 'learnsomb' fonksiyonu ile ifade edilir.

Ağırlıkların güncellenmesi girdi verilerinin tamamının geçişi sonunda oluşur. MATLAB yığın eğitim uygulamasında ‘trainbuwb’ eğitim fonksiyonuna ait olan eğitim parametrelerine göre ağ oluşur.

- Artımlı eğitim algoritması, eğitim aşamasında artımlı algoritma danışmansız şekilde ağı eğitir. Öğrenme fonksiyonu ‘learnsom’ ve eğitim fonksiyonu ‘trainr’ olarak belirlenmiştir. Başlangıç ağırlıkları ‘initsompc‘ fonksiyonu ile oluşturulmaktadır. Öğrenme hızı ve komşuluk büyüklüğü iki aşamadan değişime uğrar. Bu aşamalar sıralama ve ayarlama aşamalarıdır.

Artımlı eğitim algoritması, öğrenme parametrelerine göre oluşur. Bu değerler, eğitim ve sıralama süreçleri içerisinde kullanılır.

Çalışma kapsamında belirlenen artımlı algoritma öğrenme parametreleri;

- Sıralama fazı öğrenme oranı (LP.order_lr) : 0.9
- Sıralama fazı adım sayısı (LP.order_steps) : 1000
- Ayarlama fazı öğrenme oranı (LP.tune_lr) : 0.02
- Ayarlama fazı komşuluk uzaklığı (LP.tune_nd) : 1
- Döngü sayısı (net.trainParam.epochs): 5000

Kümeleme çalışması için giriş vektörleri yeterlidir. SOM ağının eğitim sırasında her bir nöron ile ilişkili ağırlık referans vektörü giriş vektörlerinin toplandığı kümenin merkezi haline gelebilmek için hareket eder. Buna ek olarak topolojik olarak birbirine bitişik olan nöronlar giriş esnasında birbirine yakınlaşacak şekilde hareket eder.

Giriş katmanı önyargısız bir ağırlığa sahiptir. Uyum ve eğitim ‘trainr’ fonksiyonu ile yapılır. Ağırlık güncellemesi ‘learnsom’ fonksiyonu ile tamamlanır. Başlangıç ağırlıkları ‘initsompc’ MATLAB fonksiyonu tarafından SOM öğrenme hızının

arttırılması için girdilerin temel bileşenlerini dikkate alarak uzaya yayılmış olan bir alan içerisinde Ek 2' de görüleceği şekilde başlangıç ağırlıklarını oluşturur. 'initsompc' fonksiyonu başlangıç ağırlık vektörü belirleme fonksiyonu olarak seçilmiştir.

Rekabetçi katmanlar sınıflandırma sorunlarını çözmek için kullanıldıkları için ağırlıkların dağılımı öğrenme hızı üzerinde son derece etkilidir. Öncelikle ağ her bir girdi vektörü için kazanan nöronu tespit eder. Her bir ağırlık vektörü ortalama pozisyonunu tüm vektörler içerisinde kazanan ve kazananın komşuluğuna göre belirler. Uzaklık komşuluğun iki eğitim fazı arasında oluşturduğu farklılığı göstermektedir. MATLAB 'learnsom' fonksiyonu nöron girişi, nöron aktivasyon katman çıkışı ve öğrenme oranı parametreleri ile belirli bir nöron için ağırlık değişimi değerini hesaplar.

7.4. Öz Örgütlenmeli Harita Ağında Sıralama ve Ayarlama Fazları

Sıralama fazında komşuluk uzaklığı belirli bir başlangıç değeri ile oluşturulur, çalışma kapsamında bu değer 3 olarak belirlenmiştir. Ayarlama fazı komşuluk uzaklığı 1 olarak atanmıştır, 1000 döngü sonunda komşuluk uzaklığından düşer. Yani sıralama aşaması sıralama fazı adım sayısının tamamlanmasıyla geçici olarak sonlanır, ardından ayarlama fazı ayarlama fazı komşuluk uzaklığı kadar aşağıya çekilir. Nöronların ağırlıkları anlaşılacağı üzere başlangıçta daha büyük adımlarla belirlenmektedir. Başlangıçta ağdaki nöronlar kendilerini girdi uzayındaki topoloji ile konumlandırırlar.

Ayarlama fazında genellikle sıralama fazında belirlenen topolojik yapıyı koruyarak giriş içerisinde görece olarak ufak değişiklikler ile yığılmaları önlemeye çalışır. Sıralama fazının ardından eğitim ya da adaptasyonun geri kalanı için ayarlama fazı devam eder. Ayarlama fazı eğitimin tamamlanmasıyla sonlanır. Ayarlama fazında, ayarlama fazı komşuluk uzaklığı 1 olarak belirlenmiştir, ağırlıklar topolojik sıralanmalarına göre girdi alanı üzerinde nispeten eşit olarak yayılmaları beklenir.

7.5. Öz Örgütlenmeli Harita Ağının Sonuçlarının Elde Edilmesi

Seçilen araçlardaki müşteri şikâyet veriler düzenlendikten sonra kümelenmeleri için SOM sinir ağı modeline giriş vektörü olarak sunulmuştur. Oluşan modelde, 37 giriş vektörü ve 36 çıkış nöronu kullanılmıştır. 37 giriş vektörü, 37 şikâyet değişkenine ve 36 çıkış nöronu, olası 36 kümeye denk düşmektedir. 141 arızanın yaklaşık %25' i kadar küme öngörülmüştür. Ancak SOM kümelemeyi tamamladıktan sonra bütün kümelerin dolu olması gerekmemektedir. 36 çıkış nöronu 6x6' lık bir kare şeklinde dizilmiştir.

Her bir sütunu bir referans vektöründen oluşan ağırlık matrisi, giriş nöronlarıyla çıkış nöronları arasındaki ilişkiyi gösteren bir matristir. Ağırlık referans matrisinin son değerleri SOM öğrenme algoritması ile 5000 döngüsü sonucunda oluşmaktadır. Algoritmanın ağırlık matrisini hesaplayabilmesi için başlangıç ağırlık değerleri Ek. 2' de görülen değerlerdir ve MATLAB 'initsompc' fonksiyonu ile atanmıştır. Çalışmada başlangıç ağırlık matrisi ilk değer atama MATLAB fonksiyonu olarak 'initsompc' seçilmesinin nedeni, bu fonksiyonun SOM öğrenme hızını arttırmasıdır.

MATLAB programı ile yapılan çalışmada ağırlık matrisini güncelleştirmek için MATLAB 'learnsom' fonksiyonu kullanılmıştır. Referans vektörlerine ilk değer atanmasının ardından öğrenme katsayısı (α=0.9) olarak belirlenmiştir. Öğrenme katsayısının yüksek olması algoritmanın yavaşlatılması içindir. Belirli bir döngü boyunca bu değer değiştirilmemiştir. Böylece, referans vektörlerinin kendi ilk değerlerini giriş vektörlerinden oluşturması sağlanmıştır. Daha sonra her 1000 döngüde, α değeri 0.02 oranında lineer olarak azaltılmıştır.

Kümeleme için her bir şikâyet, hazırlanan SOM modeline bir kez girilir. Giriş vektörleri çıkış katmanındaki her bir nöronun referans vektörü ile çarpılır. Hangi çarpım değeri daha yüksek ise o şikâyet ilgili kümeye aittir.

SOM modelinde referans vektörlerinin veya bir diğer deyişle katsayılar matrisinin değişimini etkileyen bir diğer faktör de kazanan nöronun komşuluğudur. Modelde çıkış nöronlarının dizilimi topolojik komşuluk açısından önemlidir. Komşuluğun hem yatay hem de dikey eksende olabilmesi için çalışmada çıkış nöronları karesel

olarak dizilmiştir. Başlangıç komşuluk uzaklığı (R)' nin ilk değerine, çıkış nöronlarından oluşan karenin bir kenarındaki nöron sayısı verilmiştir. Bu çalışmada kullanılan 6x6' lik ızgara diziliminde Başlangıç Komşuluk Uzaklığı 3 olacaktır. Döngü sayısı arttıkça Başlangıç Komşuluk Uzaklığı değeri de belli aralıklarla azaltılmıştır. Böylece algoritmanın bitiminde Başlangıç Komşuluk Uzaklığı sıfır olacak ve yalnızca kazanan nöronun referans vektörü güncellenecektir. Bu çalışmada her bir 1000 döngüde, başlangıç komşuluk uzaklığı değeri bir azaltılmaktadır. Ancak, ilk 1000 döngü boyunca başlangıç komşuluk uzaklığı değerinin sabit kalması sağlanmıştır.

MATLAB programında SOM uygulaması tek katmanlı uzaklık fonksiyonundan, net toplam ağ girdi fonksiyonundan ve rekabetçi bir transfer fonksiyonundan fonksiyonlarından oluşmuştur. Her bir ağırlık güncellemesi her giriş sonunda, öğrenme fonksiyonuna göre aşağıdaki koşullardan herhangi biri karşılandığında eğitim durur.

- Maksimum tekrar sayısına ulaşıldığında.
- Performans hedefine ulaşıldığında.
- Azami süre aşıldığında.
- Doğrulama performansı maximum hata sayısını aşmışsa.

Tüm giriş vektörleri 5000 döngü boyunca SOM modeline girildikten sonra, ağırlık referans vektörleri oldukça kararlı bir hale gelmiştir ve değişimler daha az görülmeye başlanmıştır.

Ek 1' de SOM modelindeki Ağırlık Referans Vektörleri, giriş nöronları ile çıkış nöronları arasındaki ilişkiyi göstermektedir. Giriş nöronları her bir şikâyetin 37 değişkenini ve çıkış nöronları da olası 36 kümeyi göstermektedir. Burada dikkat edilmesi gereken nokta oluşan küme sayısının 21 ile sınırlı kalmasıdır.

5000 döngü sonunda, MATLAB programı ile kurulan SOM modelinin eğitiminin, derlenmiş olan müşteri şikâyet kayıtları ile tamamlandığına karar verilmiştir. Belirtilen adımlar ile SOM modelinin oluşumu tamamlanmıştır. Sonrasında belirlenmesi gereken hangi giriş vektörünün hangi nöronda gruplandığının tespit edilmesidir. Tablo 7.4' de kümeleme tablosunda araçların atandığı kümelerin bilgisi yer almaktadır.

Referans vektör değerleri yüksek değerler alan kümeler ilgili şikâyet veya şikâyetlerden yoğun olarak etkilendiğini gösterir. Düşük değerler de ilgili şikâyetin ilgili kümenin etkinliği üzerinde az etkin olduğunu gösterir. SOM modelindeki topolojik yapıyı ve kümelerin komşuluğunu görebilmek için kümeleri incelemek gerekir. 5 ve 35 nolu kümenin Ağırlık Referans Vektör değerleri çok düşüktür. Bu kümedeki şikâyetlerin daha hafif şikâyetler olduğu söylenebilir. Aynı tabloda, 11 ve 13 nolu kümelerin Ağırlık Referans Vektör değerleri çok yüksektir. Bu kümedeki şikâyetlerin şiddetli ve araç üzerinde oldukça etkili olduğu söylenebilir. En yoğun birikim 1 numaralı hücrede meydana gelmiştir.

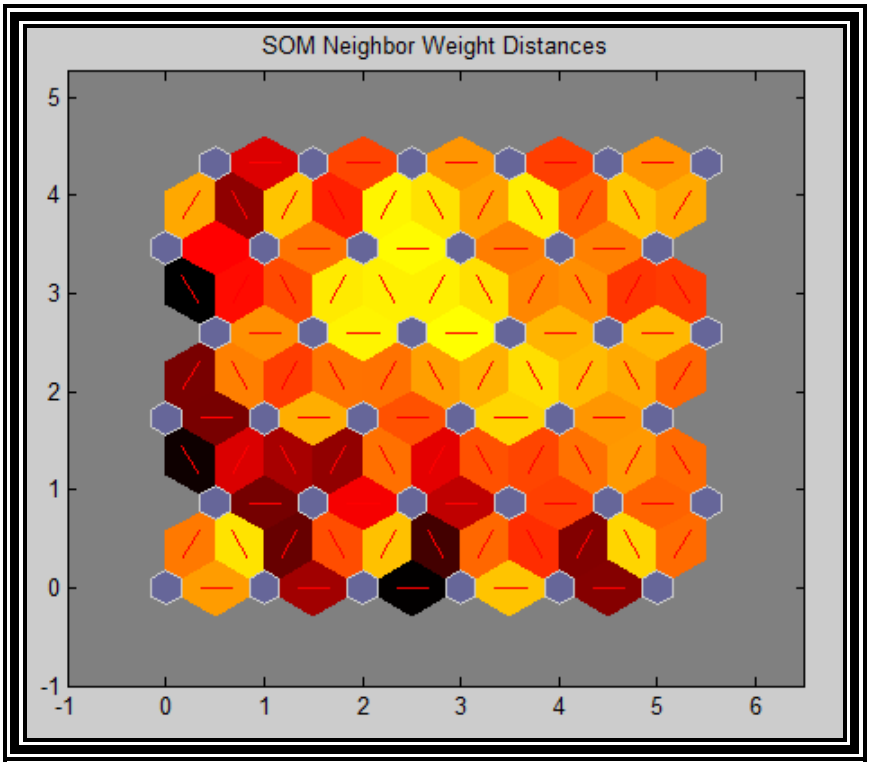
Tablo 7.4’ de kümeleme çizelgesinde, SMTS’ ye girilmiş olan 141 aracın SOM ile atanmış olduğu hücreler gösterilmektedir.

Tablo 7.4: Araçların SOM ile Atandığı Hücreler

Araç	Hücre	Araç	Hücre	Araç	Hücre	Araç	Hücre
1	20	36	33	71	35	106	36
2	27	37	33	72	28	107	5
3	20	38	28	73	35	108	5
4	20	39	12	74	35	109	1
5	27	40	28	75	24	110	36
6	20	41	12	76	31	111	1
7	27	42	32	77	12	112	36
8	23	43	20	78	4	113	1
9	20	44	28	79	35	114	31
10	20	45	17	80	1	115	31
11	16	46	32	81	1	116	5
12	16	47	35	82	31	117	36
13	27	48	17	83	28	118	36
14	27	49	17	84	1	119	31
15	28	50	17	85	28	120	1
16	19	51	21	86	1	121	1
17	19	52	21	87	31	122	1

Tablo 7.4: Araçların SOM ile Atandığı Hücreler (Devamı)

Araç	Hücre	Araç	Hücre	Araç	Hücre	Araç	Hücre
18	19	53	12	88	1	123	1
19	20	54	28	89	28	124	1
20	27	55	33	90	31	125	1
21	20	56	33	91	1	126	1
22	23	57	12	92	4	127	36
23	20	58	12	93	24	128	36
24	16	59	18	94	1	129	36
25	27	60	33	95	1	130	8
26	20	61	35	96	5	131	36
27	23	62	35	97	35	132	8
28	28	63	24	98	1	133	8
29	12	64	12	99	31	134	8
30	23	65	24	100	31	135	8
31	28	66	35	101	36	136	8
32	33	67	33	102	1	137	36
33	18	68	12	103	31	138	8
34	33	69	35	104	1	139	13
35	17	70	4	105	1	140	13
						141	13



Şekil 7.2: SOM kümeleme modeli ve kümeler aralarındaki mesafeler

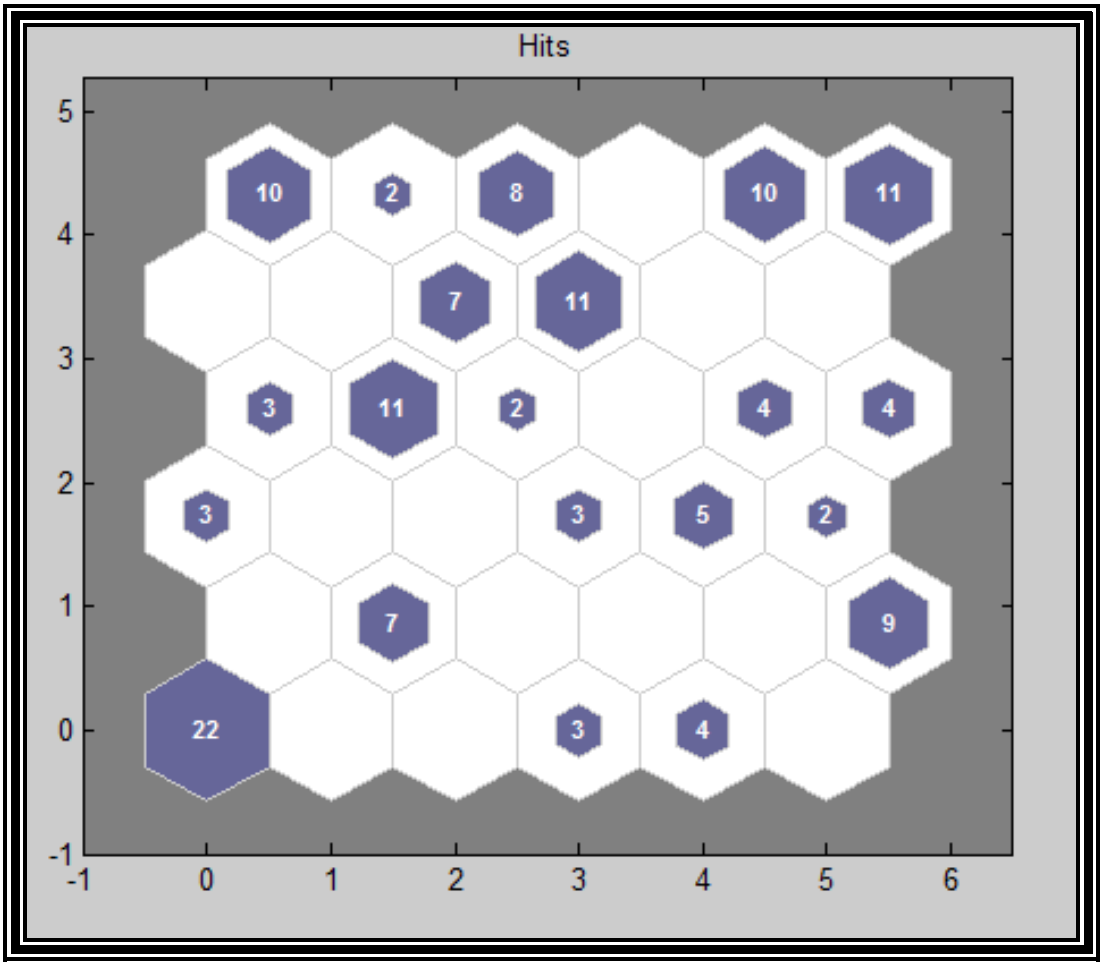
Şekil 7.2' de SOM arıza kümeleme modeli için bir harita oluşturulmuş ve bu harita kümeler aralarındaki mesafelere göre renklendirilmiştir. Böylece, küme yoğunlukları

ve kümelerin birbirine olan topolojik komşulukları görselleştirilmiştir Koyu renkler yakın, açık renkler uzak olan SOM hücrelerini ifade etmektedir.

Şekil 7.3’ de Her bir kümeye denk gelen araç sayısı gösterilmiştir. Kümelerin Ağırlık Referans Vektör değerleri ile topolojik konumları Ek 1’ de görülebileceği üzere birbirini desteklemektedir. Bu durum çalışmada kurulan SOM modellerinin başarılı olduğunun kanıtıdır.

SOM ile 141 servis kaydına ait müşteri şikâyeti gruplanarak sınıflandırılmış, parametre çeşitliliği azaltılarak bulanık çıkarım yapabilecek bir ANFIS sistemine girdi olarak sunulmuştur.

SOM sınıflandırması sonucu elde edilen kümeler önemli bilgiler içermektedir. 6x6’ lik matris de yer alan her bir altıgen bir kümeyi temsil etmektedir. Harita üzerinde, arıza kaynağı farklı olan arıza kümelerinin birbirine en uzak konumda olduğu belirlenmiştir. Arıza eğilimleri birbirine yakın olan kümeler ise haritalar üzerinde birbirine en yakın konumdadır.



Şekil 7.3: SOM kümeleme sonuçları

7.6. Öz Örgütlenmeli Harita Arıza İndeks Değerlerinin Oluşturulması

Tasarlanan Eşzamanlı Sinirsel Bulanık Çıkarım Sisteminde kümeler ait Arıza İndeks değerlerinin belirlenebilmesi için SOM hücrelerinde toplanan araç arıza maliyetlerinin ortalaması alınarak normalize edilmiştir. Elde edilen değer kümenin Arıza İndeks değerini vermektedir.

Tablo 7.5' de Arıza İndeks değerleri gösterilmiştir. Ayrıca oluşan kümelerde bulunan arızaların muhtemel kaynak noktalarının ifade eden isimler atanmıştır. Görüleceği üzere benzer arıza teşhisi alan kümeler birbirlerine en yakın konumlarda çıkmıştır.

Arıza İndeks değerlerinin belirlenmesi için 21 adet hücrenin ortalama Arıza Tutarı hesaplanmıştır Bu kümelerin Ağırlık Referans Vektör değerleri incelediğinde, vektörel değerleri yüksek olan kümelerin arıza şikâyetlerinin şiddetli olduğu

araçlardan, Ağırlık Referans Vektör el değerleri düşük olan kümelerin ise arıza şikâyetlerinin hafif olduğu araçlardan oluşturduğu gözlemlenmiştir. SOM çıktı kümelerine ait 5000 döngü sonucu oluşan Ağırlık Referans Vektör değerleri Ek 1' de gösterilmiştir.

Tablo 7.5: Arıza İndeks Değerleri

Küme Numarası	Ortalama Tutar	Arıza İndeks Değeri	Kümenin İsmi
1	420.09	0.26	Motor çalışma3
4	283.33	0.175	Akü şarj2
5	424.25	0.263	Akü şarj1
8	890.14	0.551	Motor çalışma2
12	178.56	0.111	Motor çalışma4
13	1615.67	1	Motor çalışma1
16	60.67	0.038	Akü şarj3
17	150.4	0.093	Akü şarj1
18	160	0.099	Motor çalışma4
19	65.33	0.04	Motor/soğutma/yağlama2
20	58.64	0.036	Motor çalışma5
21	162.5	0.101	Yakıt sistemi1
23	78.5	0.049	Direksiyon2
24	251.75	0.156	Direksiyon1
27	49.71	0.031	Frenler3
28	185.64	0.115	Vites kutusu/kavrama/aks3
31	378.5	0.234	Frenler1
32	143	0.089	Frenler4
33	162.38	0.101	Frenler2
35	232.7	0.144	Süspansiyon/sürüş1
36	563.55	0.349	Vites kutusu/kavrama/aks1

7.7. Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi İle Araç Arıza Tutarının Hesaplanması

ANFIS yardımı ile araçlardaki arıza tutarlarının hesaplanması bağımlı değişkenlerin tahminine yönelik bir çalışmadır. Bir tahmin aracı tasarlamak için öncelikle, tahmin aracı olan ağı eğitmek amacıyla veri dizileri sahip olunmalıdır. Çalışma kapsamında aracın Arıza İndeks değeri, Araç Kilometre ve Araç Yaş bilgileri ANFIS girdi veri dizisi, aracın arıza maliyetleri çıktı veri dizisi olarak kullanılmıştır. ANFIS' in bir tahmin aracı olarak tasarımlanma sürecinde en iyi performansı veren mimariyi

bulmak için MATLAB programı ANFIS Bulanık Mantık Araç Kutusu ile farklı ANFIS yapıları sınanmıştır. (Bkz. Tablo 7.6)

Oluşturulan CNFS' nin birinci elemanı olan SOM ile toplanan bilgiler, girdi ve çıktı verilerine sahip olunan bir ANFIS mimarisi içerisinde kullanılmıştır. ANFIS yapısının bize tanımış olduğu bir avantaj ise sistemdeki değişkenlerin niteliklerine dayanan önceden belirlenmiş model yapısına sahip olmak zorunda olmamamızdır. Verilen bir üyelik fonksiyonu ile bağlantılı parametreleri gelişigüzel olarak seçmekten ziyade, bu parametreler, veri değerlerindeki varyasyonları açıklamak amacıyla üyelik fonksiyonları girdi-çıktı verilerine uydurulmuştur. ANFIS' de üyelik fonksiyonunun şekli parametrelere bağlıdır ve bu parametrelerin değiştirilmesi üyelik fonksiyonunun şeklini değiştirecektir.

Bir başka ifadeyle önceden elimizde bir girdi-çıktı veri havuzu olduğundan, çıktı veriye yakınsayacak olan bir bulanık çıkarım sistemi inşa etmemiz ANFIS ile mümkün olmaktadır. ANFIS bir veri işleme ve tahmin aracı yöntemi olduğu için girdi-çıktı verisinin sistemin hem girdi hem de çıktı değişkenleri için belirlenen değerleri içeren yeterli sayıda olması çok büyük öneme sahiptir. Bu durum sağlanamadığı taktirde, tahmin aracı performansı garanti edilemez ve bunun sonucunda tasarlanan sistemin güvenilir olması beklenilemez.

MATLAB programı ANFIS Bulanık Mantık Araç Kutusu' na eğitim amacıyla 121 girdi verisi seçilmiştir, asgari ve azami sınırlar üyelik fonksiyonları ile belirlenmiştir. Çalışmada farklı mimariye sahip olan üyelik fonksiyon türleri ve yapıları elde edilen veri dizileriyle eğitilmiştir. MATLAB programı çıktıları kullanılarak en başarılı tahminleri üreten üyelik fonksiyon parametreleri seçilmiştir. MATLAB programı dahilindeki ANFIS fonksiyonu kullanılarak çalışmaya konu olan Eşzamanlı Sinirsel Bulanık Çıkarım Sisteminin tahmin edici ANFIS modülü oluşturulmuştur.

7.8. Kontrol Veri Dizilerini Kullanarak Model Doğrulama

Eğitilen tahmin araçlarının performansı, kontrol verisi ortalama karekök hatası sapması ile değerlendirilmiştir. Model doğrulama, ANFIS' in eğitiminde kullanılmayan girdi-çıktı verilerinden oluşan girdi vektörlerinin, hangilerinin çıktı

değerlerini önceden ne kadar iyi kestirdiğini görmek için eğitilen ANFIS modeline sunulmasından ibaret bir süreçtir. Toplam 20 kontrol verisi kullanılarak MATLAB programı ile model kontrol edilmiştir. Ayrıca kontrol veri dizisi, modelin aşırı uyum ile modellemesine yönelik potansiyeli sınamak için kullanılmıştır.

ANFIS' e kontrol verisi ile birlikte eğitim verisi de sunulduğunda, asgari kontrol veri model hatası ile bağlantılı parametrelere sahip ANFIS modeli seçilir. En iyi tahmin sonuçlarını üreten ANFIS model mimarisi yapılan deneme çalışmaları sonucunda belirlenmiştir. Simülasyonlar ANFIS yapılarını kontrol ve genelleştirmek için yapılmıştır. Kontrol işlemi, tahmin aracı yapısının, verilen eğitim verilerini ne kadar iyi öğrendiğini gösterir.

7.9. MATLAB Bulanık Mantık Araç Kutusu ile Eğitim Süreci

MATLAB programı ANFIS Editörü arayüzünde Sugeno bulanık mantık modeline göre modelleme yaparak çözümler üretmektedir. Müşteri şikâyetlerinin belirlenmiş olduğu arızalı araçların kilometre, yaş bilgilerini ve Eşzamanlı Sinirsel Bulanık Çıkarım Sisteminin içerisinde yer alan SOM ile müşteri şikâyetlerinin gruplanması ile hesaplanan Arıza İndeks değeri ANFIS modelinde girdi olarak kullanılmıştır.

Eğitim, kontrol ve test verisinin ayrılması: Genel olarak literatürü incelediğimizde ANFIS uygulamalarında tüm veri setinin %15' i ile %20' si arasında bir grubun kontrol seti olarak ayrıldığı tespit edilmiştir.

Girdiler [0,1] aralığında normalize edilerek ANFIS' e girilmiştir. Aşağıda sıralanan maddelerle ANFIS eğitim yapısı oluşturulurken göz önüne alınan değişkenler belirtilmiştir.

- Üyelik fonksiyonu sayısı: Girdi olarak seçilen Araç Kilometresi, Araç Yaşı, Arıza İndeks değerlerinin Bulanık Üyelik Değerleri belirlenmiştir.

- Girdi üyelik fonksiyonlarının tipi: Farklı üyelik fonksiyonları ile denemelere yapılmıştır.

- Çıktı üyelik fonksiyonlarının tipi: Sabit veya Doğrusal çıktı seçilmiştir.

- Kural sayısı: Üç girdi ve toplam onsekiz bulanık kural oluşacaktır.

- Performans fonksiyonu: Kullanılan performans fonksiyonu Hata Kareleri Ortalamasıdır (RMSE).

- Optimizasyon yöntemleri: Geri-yayılım veya Hibrit (Geri-Yayılım ve En Küçük Kareler) optimizasyon yöntemleri seçilerek denemeler yapılmıştır.

- Tekrar sayısı: Uygulamada farklı tekrar sayıları seçilmiştir.

Eşzamanlı Sinirsel Bulanık Çıkarım Sisteminin ikinci modülü olan tahmin operatörü ANFIS sadece giriş ve çıkış verileri kullanılarak MATLAB programı Bulanık Mantık Araç Kutusu vasıtasıyla çok kısa sürede sınanabilir. Girdi üyelik fonksiyonlarının sayısı ve tipi tanımlanınca, tahmin aracı kural temeli inşa edilir. Uzman bilgisinden faydalanmak adına standart bir yöntem bulunmamasından dolayı, otomatik kural yaratma yöntemi tercih edilmiştir. MATLAB programı ANFIS Bulanık Mantık Araç Kutusu tahmin aracı tasarım aşamaları aşağıda belirtilmiştir.

- Eğitim ve kontrol verisi ANFIS arayüzüne yüklenir.

- Tasarım parametreleri, girdi üyelik fonksiyon sayısı, girdi ve çıktı üyelik fonksiyon tipleri seçilir. Böylece ilk ANFIS yapısı oluşturulur. Üyelik fonksiyonlarının şekli, sayısı ve dilsel değişken değerleri ile çıktı üyelik fonksiyonun tipi ANFIS arayüzü yardımıyla tanımlanmaktadır.

- Eğitim algoritması ilk yapı ile birlikte işlenir.

- Eğitimden sonra inşa edilen ANFIS yapısı bir tahmin aracı olarak kullanılmak üzere kaydedilir.

Bulanık model oluşturulurken girdi üyelik fonksiyonu bilgilerinin kaç dilsel bölgeye ayrılacağının belirlenmesi gerekmiştir. Ardından hangi çeşit üyelik fonksiyonun

kullanılacağı belirlenmiştir. Daha sonra çıktı fonksiyonunu türü ve tekrar sayısı seçilmiştir.

Sabit olarak belirlenen değerler Hata Toleransı, İlk Adım Büyüklüğü, Adım Büyüklüğü Azalma Oranı ve Adım Büyüklüğü Artış Oranı' dır. Bu parametrelerin optimum nitelikli olanının bulunması için literatürde hiçbir kesin yöntem kullanılmaktadır. MATLAB programı adım büyüklüğü seçeneklerini kontrol edemez. Komut satırı kullanılarak ANFIS ilk adım büyüklüğü ve karşılık gelen azalma ve artış oranları belirlenebilir. Adım büyüklüğü ve hata tolerans değerleri tüm denemeler boyunca aşağıdaki değerler uyarınca sabit tutulmuştur. ANFIS modelinde üyelik fonksiyonları araç yaşı (input1), araç kilometre bilgisi (input2), Arıza İndeks değeri (input3) ve çıktı Arıza Tutarı (output) şeklinde isimlendirilmiştir.

Hata Toleransı= 0

İlk Adım Büyüklüğü = 0.01

Adım Büyüklüğü Azalma Oranı(ssdec) = 0.9

Adım Büyüklüğü Artış Oranı(ssinc) = 1.1

Kontrol verisinin eğitilen modelle yeterli düzeyde performans gösterip göstermediğini görmek için kontrol hatası görselleri analiz edilmiştir. Bazı örneklerde kontrol hatası eğitim için daha fazla veriye ihtiyaç gösterecek kadar büyüktür veya üyelik fonksiyonu seçenekleri (hem üyelik seçenek sayısı, hem de tipi) değiştirmek gerekebilir. Aksi takdirde, sistem, eğitim verisinin temsil etmeye çalıştığı özellikleri yeterli biçimde yakalayamaz.

Uygulamada farklı üyelik (Üçgen, Trapezoid, vs.) fonksiyonları denenmiş olsa da arıza tutarı tahmininde trapezoidal üyelik fonksiyonu diğer üyelik fonksiyonlarından daha başarılı olmuştur. Farklı üyelik fonksiyonları, eğitim optimizasyon yöntemi, çıktı üyelik fonksiyonu türleri ile yapılan denemeler Tablo 7.7' de listelenmiştir.

Tablo 7.6: ANFIS Mimarileri ve En Uygun Modelin Seçimi

Girdi Üyelik Fonksiyonu	Çıktı Üyelik Fonksiyonu	Tekrar Sayısı	Optimizasyon Metodu	Eğitim Hatası TL RMSE	Kontrol Hatası TL RMSE
trapmf 3 3 2	Sabit	40	Hibrit	71.4846	43.1854
Pimf 3 3 2	Sabit	40	Hibrit	74.2792	44.3008
gauss2mf3 3 2	Sabit	40	Hibrit	70.764	46.4003
gaussmf 3 3 2	Sabit	40	Hibrit	70.6864	47.511
Pimf 3 2 2	Sabit	40	Hibrit	76.0589	48.861
gbellmf 3 2 2	Sabit	25	Hibrit	74.2288	51.2001
trapmf 3 2 3	Sabit	40	Hibrit	71.5571	52.2713
trapmf 2 3 3	Sabit	40	Hibrit	74.6552	52.4285
Pimf 2 2 3	Sabit	40	Hibrit	76.8912	53.2535
trapmf 3 3 3	Sabit	40	Hibrit	71.1384	53.9139
gbellmf 3 2 3	Sabit	40	Hibrit	67.0058	54.2549
gaussmf 2 2 2	Sabit	40	Hibrit	78.3875	54.9699
Pimf 2 3 3	Sabit	40	Hibrit	72.9443	56.6078
trimf 3 2 2	Sabit	40	Hibrit	73.6334	57.0093
Pimf 2 2 2	Sabit	40	Hibrit	79.7942	57.0486
Pimf 3 2 3	Sabit	40	Hibrit	71.7742	57.1929
gauss2mf3 2 3	Sabit	40	Hibrit	66.7961	57.3978
Pimf 3 3 3	Sabit	40	Hibrit	68.9969	57.6384
trapmf 2 2 3	Sabit	40	Hibrit	77.7597	58.5325
dsigmf 3 2 3	Sabit	40	Hibrit	71.1821	58.6764
psigmf 3 2 3	Sabit	40	Hibrit	71.1821	58.6764
gbellmf 2 3 3	Sabit	40	Hibrit	72.0858	59.0556
gaussmf 3 2 2	Sabit	40	Hibrit	73.2236	60.5107
gauss2mf2 2 3	Sabit	40	Hibrit	76.1205	60.5514
dsigmf 3 3 2	Sabit	40	Hibrit	84.1719	64.6944
psigmf 3 3 2	Sabit	40	Hibrit	84.172	64.6944
gbellmf 3 3 3	Sabit	40	Hibrit	64.3757	65.6033
trimf 3 3 2	Sabit	40	Hibrit	71.5789	67.1914
trimf 2 3 3	Sabit	40	Hibrit	70.8953	69.6238
dsigmf 3 2 2	Sabit	40	Hibrit	86.8493	71.172
psigmf 3 2 2	Sabit	40	Hibrit	86.8493	71.172
psigmf 2 2 2	Sabit	40	Hibrit	93.1975	83.2775
gaussmf 2 3 3	Sabit	40	Hibrit	71.8148	83.4017
dsigmf 2 3 3	Sabit	40	Hibrit	72.0359	109.973
psigmf 2 3 3	Sabit	40	Hibrit	72.0359	109.973
trimf 3 2 3	Sabit	40	Hibrit	69.8203	138.887
trimf 3 3 3	Sabit	40	Hibrit	67.7061	157.601
trapmf 4 4 4	Sabit	40	Hibrit	62.7533	214.057
dsigmf 3 3 3	Sabit	40	Hibrit	66.0392	256.711
psigmf 3 3 3	Sabit	40	Hibrit	66.0392	256.712
gauss2mf3 3 3	Sabit	40	Hibrit	62.7619	338.851
dsigmf4 4 4	Doğrusal	40	Hibrit	53.5292	386.253
gauss2mf3 3 2	Doğrusal	40	Hibrit	47.3665	414.574
dsigmf4 4 4	Doğrusal	40	Hibrit	37.9669	422.323
gauss2mf3 3 2	Sabit	40	Geri Yayılım	420.139	488.362
gbellmf 3 3 2	Sabit	40	Geri Yayılım	420.184	488.405

Tablo 7.6: ANFIS Mimarileri ve En Uygun Modelin Şeçimi (Devamı)

Girdi Üyelik Fonksiyonu	Çıktı Üyelik Fonksiyonu	Tekrar Sayısı	Optimizasyon Metodu	Eğitim Hatası TL RMSE	Kontrol Hatası TL RMSE
gbellmf 3 3 2	Doğrusal	40	Hibrit	45.1074	653.604
gbellmf 4 4 4	Sabit	40	Hibrit	52.4457	678.9
Pimf 4 4 4	Sabit	40	Hibrit	62.2926	737.463
gaussmf 4 4 4	Sabit	40	Hibrit	48.3763	1115.25
trapmf 3 3 2	Doğrusal	40	Hibrit	53.2221	2122.74
gbellmf 4 4 4	Doğrusal	40	Hibrit	26.899	4563.42

Tablo 7.7: Minimum kontrol hatası eğitim süreci

Döngü Sayısı	Eğitim Hatası	Kontrol Hatası
40. döngü	71.4846 TL	43.1854 TL
41. döngü	71.2433 TL	44.1306 TL

Çalışmada en başarılı sonucu 40. döngü aşamasında trapezoidal üyelik fonksiyonu, 3-2-2 dilsel değişken, hibrit optimizasyon ve sabit çıktı ANFIS mimari versiyonu vermiştir. Her girdi üzerindeki üyelik fonksiyonu sayısı, dilbilimsel etiketleri anlamlı bir biçimde tanımlamak gerekmiştir. Üyelik fonksiyonu değerleri her bir karar döngüsü için ANFIS' e girdi olarak sunulmuştur.

ANFIS üyelik fonksiyonu dilsel değerleri;

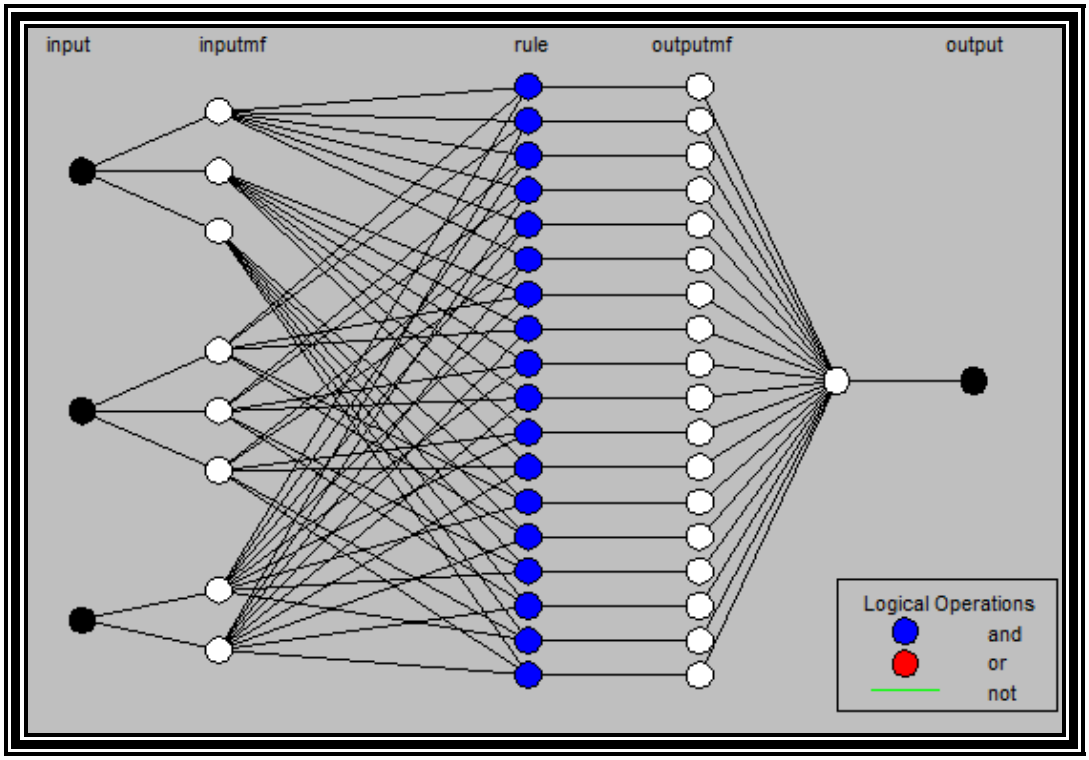
Araç Yaşı (Eski/in1mf1, Orta/in1mf2, Yeni/in1mf3)

Araç Kilometresi (Düşük /in2mf1, Normal/in2mf2, Yüksek/in2mf3)

Arıza İndeksi (Hafif/in3mf1, Şiddetli/in3mf2)

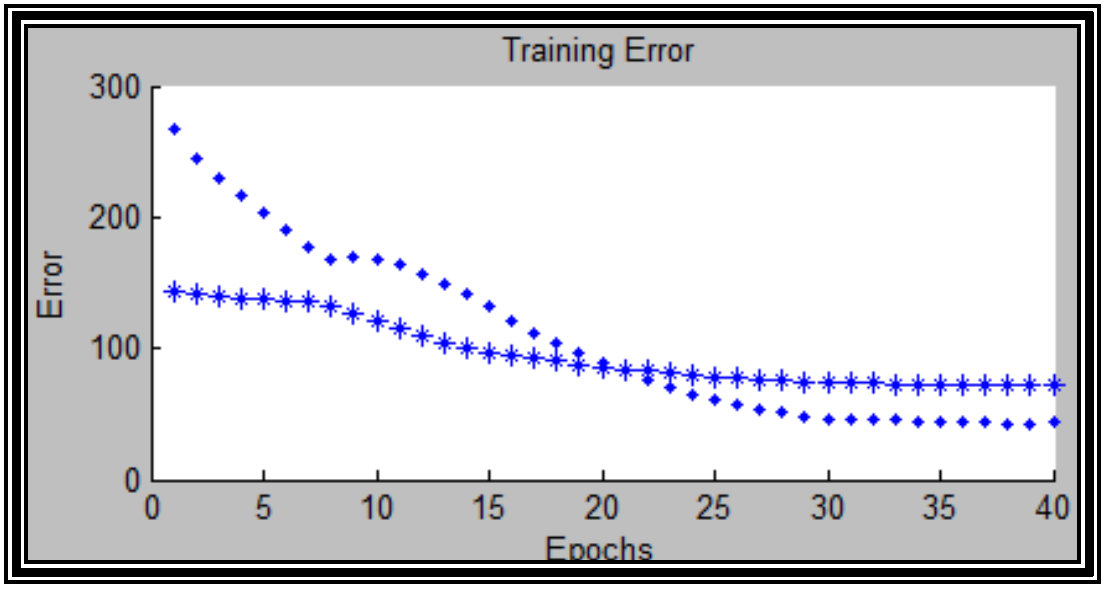
Girdi alanının verimli bölümlendirilmesi önemli bir husustur ve kural sayısını azaltabileceğinden dolayı hem eğitim, hem de uygulama safhasının hızını arttırabilir. İki girdi üzerinde üç üyelik fonksiyonu ve bir girdi üzerinde iki üyelik fonksiyonu bulunan bir ANFIS modeli 3x3x2=18 Sugeno bulanık eğer-ise kuralı oluşturmaktadır. MATLAB programının getirdiği hız avantajından dolayı bu çalışmada kural tabanı ile oluşturulan kurallar göz ardı edilmektedir. Kontrol hatası değerleri Tablo 7.7' de belirtilmiştir.

Oluşturulan ANFIS mimarisinde toplam 58 düğüm vardır. Eğitim veri sayısı 121, kontrol veri sayısı 20 ve bulanık kuralların sayısı 18 olarak belirlenmiştir.



Şekil 7.4: Seçilen ANFIS model yapısı

Şekil 7.5' de en başarılı sonucu veren ANFIS modelinin eğitim ve kontrol hata eğrilerinin almış olduğu değerler gösterilmektedir. En küçük kontrol hatası 40. döngüde ortaya çıkmaktır. Daha sonrasında kontrol hatasının değerinin artmakta olduğu göze çarpmaktadır, bu durum modelin aşırı uyumlu hale geldiğini göstermiştir. 40. döngüde bile eğitim eğrisi düşmeye devam etmektedir fakat düşüş oranı son derece küçüktür daha fazla döngü ile yapılan denemede bir performans iyileşmesi ile karşılaşılmamıştır.



Şekil 7.5: ANFIS modelinin eğitim ve kontrol hata eğrileri

Ağın eğitiminin başarısını değerlendirmek amacıyla kontrol veri grubu sisteme girilmiştir. ANFIS modelinin de minimum kontrol hatası Trapezoidal üyelik fonksiyonu, 3-3-2 dilsel değişken mimarisi, 40 tekrar, Hibrit Eğitim Algoritması ve Doğrusal Çıktı Üyelik Fonksiyonu ile oluşmuştur. (Bkz Tablo 7.5)

Hibrit Eğitim Algoritması, Geri Yayılım Algoritması' na göre çok başarılı sonuçlar vermiştir. Bu nedenle ANFIS eğitim optimizasyon metodu olarak Hibrit Eğitim Algoritması yöntemi seçilmiştir.

Sabit Çıktı ve Hibrit Eğitim Algoritması yöntemi beraber kullanıldığında ise; doğrusal ve geri yayılım parametrelerine göre daha iyi sonuçlar vermiştir. Ayrıca lineer çıktı ile oluşan model 3-4 kat daha uzun sürede hesaplama yapabilmektedir.

ANFIS bulanık çıkarım sistemi, modellemenin yanı sıra tahmin uygulamalarında da kullanılmakta olup, bulanık ve sinirsel yaklaşımların birlikte kullanımına oldukça güzel bir örnektir. Yapılan çalışma ile elde edilen sonuçlardan da görüldüğü gibi, belirli müşteri şikâyetleri ile servise getirilen aracın CNFS ile servis danışmanının yapmış olduğu karar sürecinin bir benzeri burada tekrarlanmakta ve yüksek oranda doğru sınıflandırma ve başarılı tahmin sonucu ile çıktılar üretilmektedir.

40. tekrarda bile eğitim hatası eğrisi düşmeye devam etmektedir, düşüş oranı son derece küçüktür fakat kontrol hatası artmaya başlamıştır. Hesaplama süresi 2.2 GHz Core 2 işlemci ile yaklaşık 10 sn. sürmektedir. Eğitimin tamamlanmasının ardından, FIS parametreleri minimum kontrol hatası ile hesaplanmıştır. ANFIS tahmin sürecindeki kontrol hatası RMSE değerinin 43.1854 TL ye kadar indiği görülmüştür.

Belirtilen şikâyetler ile hesaplanan masraf tutarı için verilen kararlar, her bir araç-müşteri kombinasyonu için hesaplanmaktadır. Elde edilen sonuçlar Müşteri Servis Takip Sistemine girilen arıza tutarı değerleri ile kontrol edilerek sistemin başarısı hesaplanmıştır. Arıza İndeks değeri, arıza tutarı üzerinde en etkin ANFIS girdi parametresi olarak belirlenmiştir.

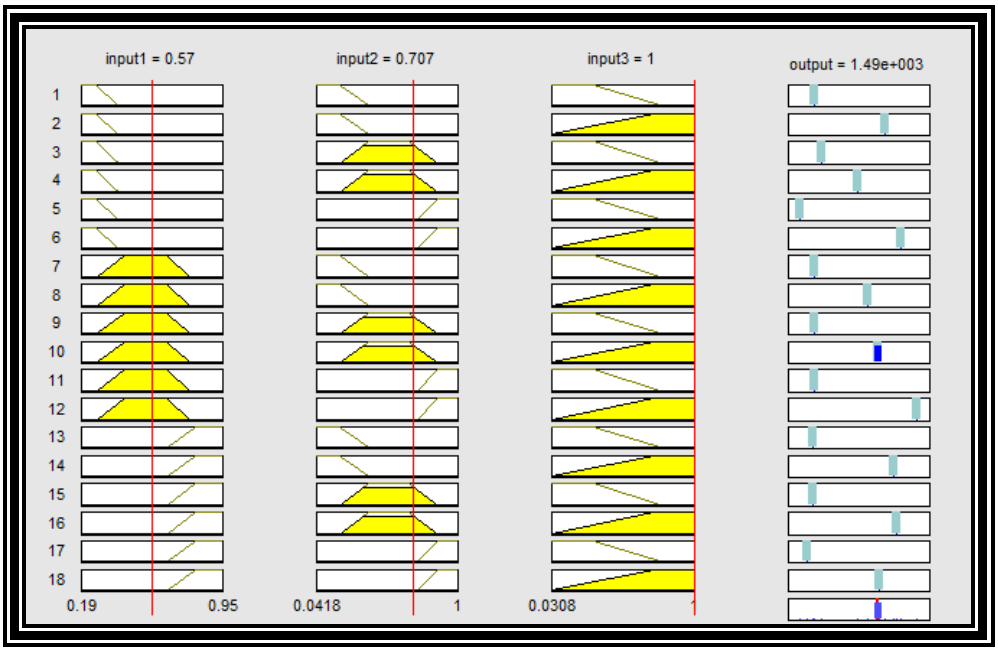
Tablo 7.8' de girdiler ve ANFIS tahmin sonuçları ile SMTS' ye ait değerler gösterilmiştir. ANFIS tahmini ile gerçek değerler arasında oluşan farklar hesaplanmıştır.

Tablo 7.8: ANFIS ile kontrol grubu tahmin sonuçları

Yıl	Km	Arıza İndeksi	Gerçek Tutar	ANFIS Tutar	Fark
0.38	0.1694	0.0363	46	62.1	-16.1
0.76	0.4743	0.0363	70	37	33
0.38	0.1367	0.0363	96	62.1	33.9
0.38	0.4639	0.1149	118	198	-80
0.38	0.2294	0.1105	134	164	-30
0.57	0.2206	0.1149	147	167	-20
0.38	0.2968	0.1006	163	159	4
0.38	0.2699	0.1105	194	171	23
0.38	0.4339	0.1105	205	191	14
0.57	0.3637	0.1105	224	174	50
0.19	0.0745	0.144	237	242	-5
0.19	0.1164	0.1149	297	187	110
0.38	0.299	0.2343	339	350	-11
0.19	0.1012	0.2626	360	430	-70
0.76	0.5115	0.2343	415	419	-4
0.57	0.4178	0.26	448	402	46
0.95	0.3629	0.26	517	471	46
0.76	0.7653	0.3488	577	563	14
0.38	0.6128	0.5509	933	905	28
0.57	0.7066	1	1522	1490	32

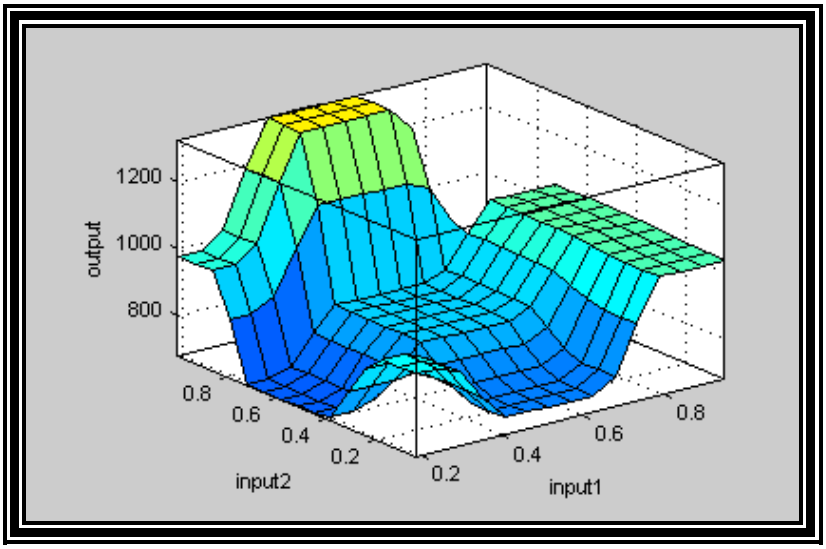
Çalışma ile hazırlanan sistemin tahmin başarısının alternatif metotlarla sınanması için doğrusal regresyon modeli seçilmiştir. Kontrol grubunun Ortalama Karekök Hatası (Root Mean Square Error- RMSE) değerleri ANFIS için 43.1854 TL olarak hesaplanmıştır. Sistemin başarısını arttırmak ve sürekliliğini sağlamak için periyodik olarak eğitim ve kontrol veri setinin güncellenmesi ve adetsel büyüklüğünün arttırılması gerekmektedir.

ANFIS' in çalışması neticesinde oluşan kurallar incelendiğinde, bazı kuralların diğerlerinden daha kuvvetli olduğunu görülmüştür. Kurallar ile ilgili bir diğer noktada, bu kuralların bulanık kurallar olduğu ve kesin yargı taşımadığıdır. ANFIS eğitimi tamamlandıktan sonra var olan 18 kurala karşı az sayıda kural etkin olarak karşımıza çıkmaktadır. Kural sayısının artması eğitim süresinin kısalması ve etkinliğinin artmasına yarayacaktır. Bir sonraki çalışma kapsamında belirlenen kuralların ANFIS modelinde kullanılması ve performans üzerindeki etkisinin izlenmesi faydalı olacaktır.



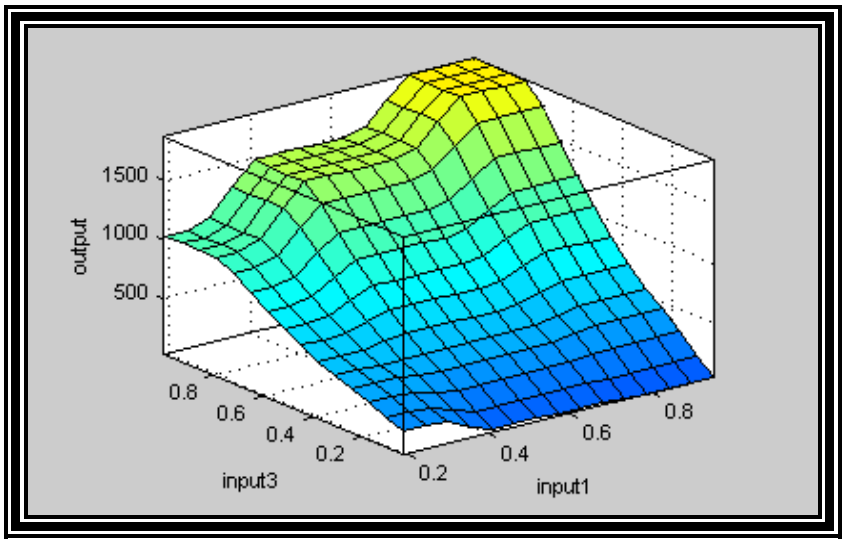
Şekil 7.6: ANFIS kural tabanı

Şekil 7.7’ de ANFIS modeli girdileri ve çıktı değerini incelediğimizde ilginç sonuçlar ortaya çıkmıştır. Aracın kilometre değeri ve aracın yaşı arttıkça beklendiği üzere arıza tutarı üzerinde doğrusal bir etki yaratmaktadır. Bunun başlıca nedeni yüksek kilometre ve yaşa sahip araçların özellikle ufak arıza tutarlı problemler ile sıklıkla karşılaşmaya başlaması olarak yorumlanabilir.

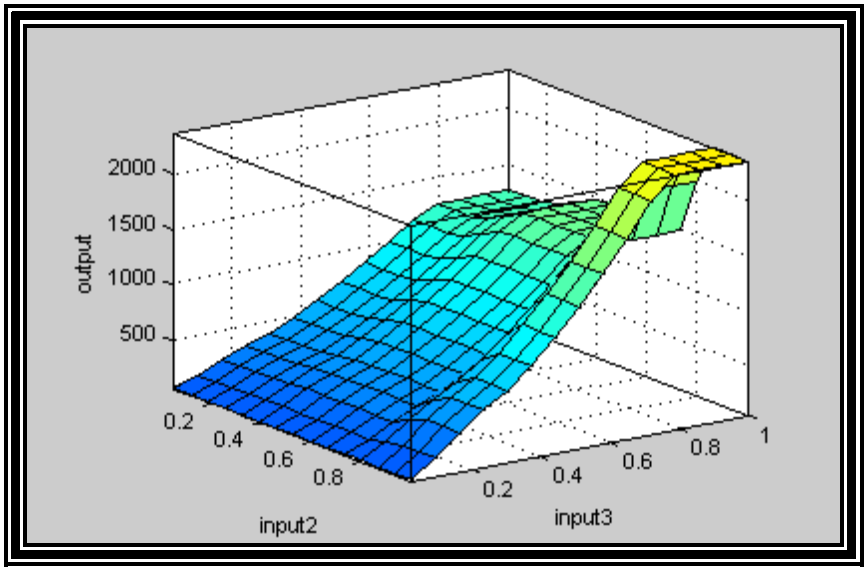


Şekil 7.7: Araç Yaşı ve Araç Kilometresi’ nin Arıza Tutarı üzerindeki etkisi

Şekil 7.7 ve 7.8’ de Arıza İndeksi ile Araç Yaşı ve Araç Kilometresi değerleri yükseldikçe aracın arıza masraflarında artış aşağıdaki grafiklerde gösterilmiştir.



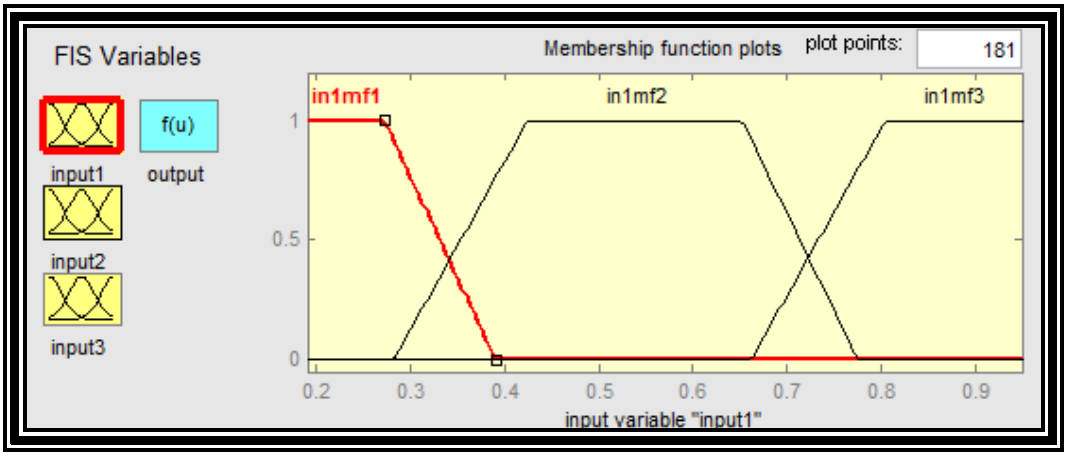
Şekil 7.8: Araç Yaşı ve Arıza İndeksinin Arıza Tutarı üzerindeki etkisi



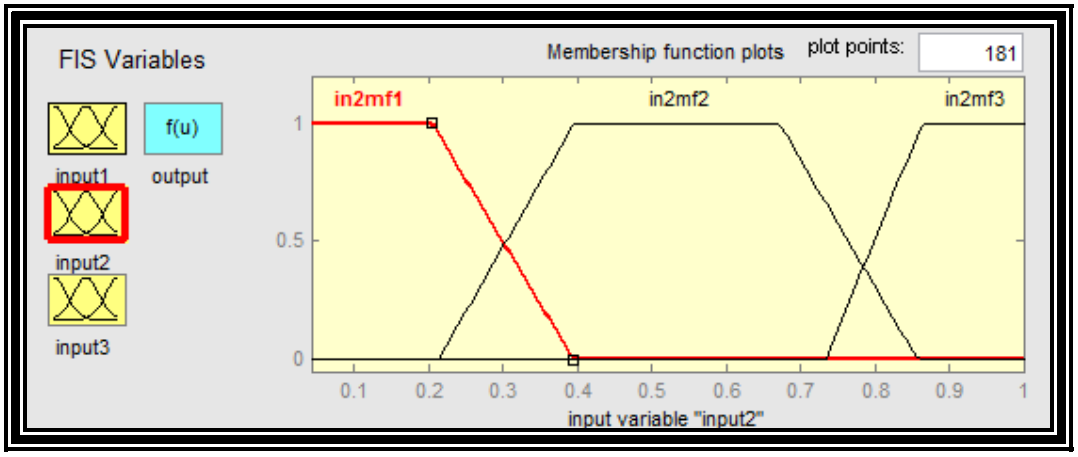
Şekil 7.9: Araç Kilometresi ve Arıza İndeksi' nin Arıza Tutarı üzerindeki etkisi

Arıza indeksinin değeri Şekil 7.8 ve 7.9' da arıza tutarı üzerinde doğrusal bir etki yaratmaktadır. Benzer şekilde arıza indeksi ve aracın kilometre değerleri yükseldikçe aracın arıza masraflarında artış görülmektedir.

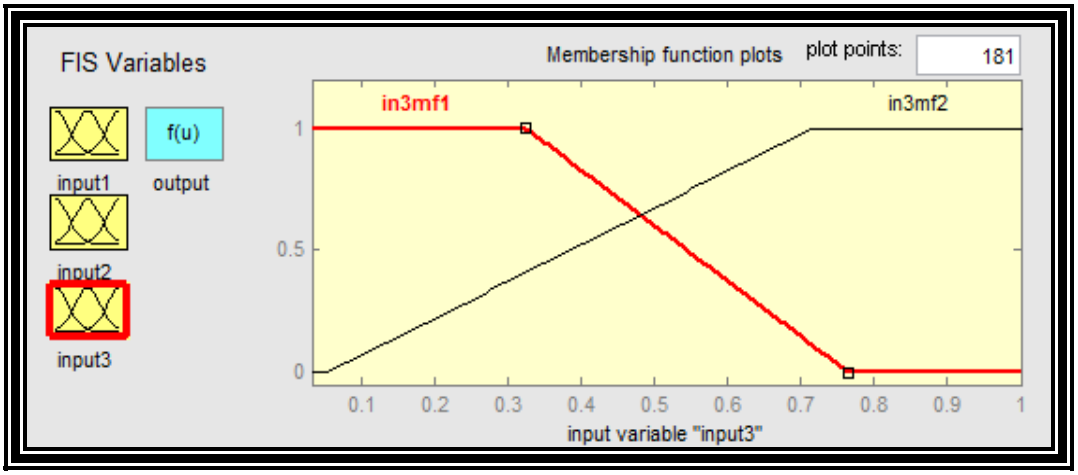
Şekil 7.10, 7.11 ve 7.12' de üyelik fonksiyonlarının, seçilen ANFIS modeli ile eğitilmesi sonucunda oluşturdukları Trepozoidal eğriler belirtilmiştir.



Şekil 7.10: Araç Yaşı üyelik fonksiyonu değerleri



Şekil 7.11: Araç Kilometre Değeri üyelik fonksiyonu değerleri



Şekil 7.12: Arıza İndeks Değeri üyelik fonksiyonu değerleri

Şekil 7.10, 7.11 ve 7.12' de üyelik fonksiyonu değerleri [0, 1] aralığına değerler almaktadır. Bunun nedeni girilen eğitim setindeki veri kümesinin normalize edilmiş olmasıdır.

7.10. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ve Değişkenlerinin Arıza Tutarı Üzerindeki Etkisi

ANFIS' in tahmin modülünde yer alan değişkenlerin arıza tutarı üzerindeki etkisinin hesaplanması için MATLAB komut satırına 'exhsrch' fonksiyonu uygun bir şekilde girilmiştir. Esasen 'exhsrch' her kombinasyon için bir ANFIS modeli oluşturmaktadır ve bir döngü için eğitim ve kontrol hata değerlerini hesaplar. ANFIS girdi veri kümesi iki eşit kısıma ayrılarak fonksiyonun çalışması izlenmiştir.

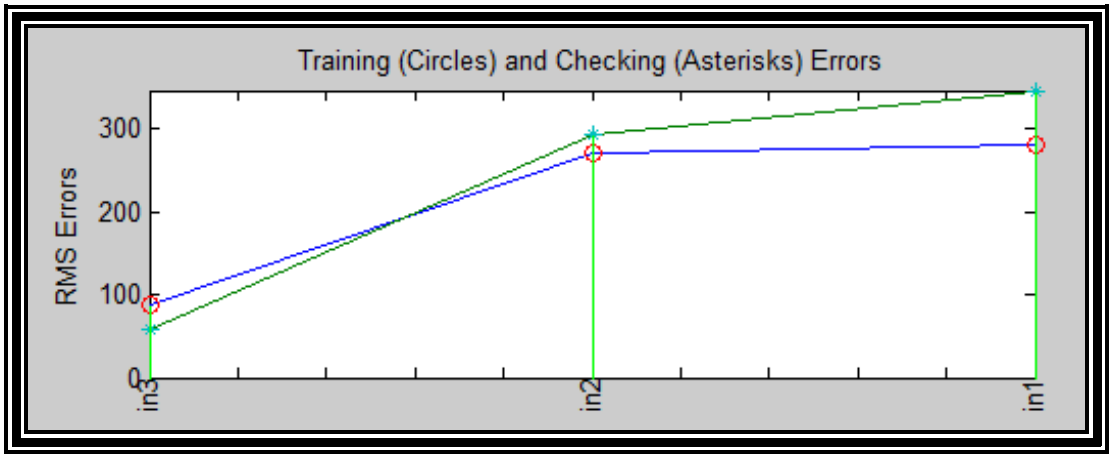
MATLAB ‘exhsrch’ fonksiyonu mevcut girdiler içerisinde arıza tutarına en fazla etkisi olan giriş değişkenini seçmek için kapsamlı bir arama gerçekleştirir. Mevcut değişkenlere verilen isimler sırasıyla;

in1: Araç Yaşı,

in2: Araç Kilometresi,

in3: Arıza İndeksi olarak belirlenmiştir.

Şekil 7.9’ da en iyi sonucu veren ANFIS yapısının sadece bir adım çalıştırılarak girdilerin çıktı üzerindeki etkileri görülmektedir. Tüm girdilerin arıza tutarı üzerinde etkin olduğunu belirlenmiştir. En soldaki girdi değişkeni olan arıza indeksi (in3) en düşük hata değerine sahiptir. Bir başka ifade ile arıza tutarı üzerinde en etkili değişken Arıza İndeks değeridir.



Şekil 7.13: Girdilerin çıktı üzerindeki etkileri

Tablo 7.9: Girdilerin çıktı üzerindeki etkileri

ANFIS Girdileri	Eğitim Hatası TL (RMSE)	Kontrol Hatası TL (RMSE)
ANFIS model 1: Aracın Yaşı (in1)	279.7557	346.1733
ANFIS model 2: Aracın Kilometresi (in2)	271.7916	293.0059
ANFIS model 3: Aracın Arıza indeksi (in3)	87.4066	57.1023

7.11. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ve Doğrusal Regresyon Karşılaştırması

Doğrusal regresyon modeli ile seçilen en başarılı ANFIS modelinin karşılaştırılması sistemin performansını kontrol etmek için olası yöntem olarak öngörülmüştür. ANFIS ile elde edilen tahmin verilerine ait olan kontrol Ortalama Karekök Hatası (Root Mean Square Error-RMSE) değeri, doğrusal regresyon modeli ile karşılaştırarak değerlendirilmiştir.

Genel çoklu doğrusal regresyon modelinde p tane bağımsız değişken olduğu varsayılır ve ana kütle modeli şöyle ifade edilir:

$$y_i = \beta_0 + \sum_{j=1}^{p} x_{ij}\beta_j + \varepsilon_i \qquad (7.1)$$

Burada ϵ_i bir hata terimidir ve i alt-indeksleri bir belirlenmiş mümkün gözlemi ifade eder. y_i parametrelerin bir doğrusal birleşiği olur. Bağımsız değişken (x_i) ve değişken parametreli (β_i) ile ifade edilir.

Tablo 7.10: ANFIS ile Kontrol Grubu Tahmin Sonuçları

Tahmin Edici	Kontrol Hatası TL (RMSE)
Doğrusal Regresyon Modeli	52.1880
ANFIS modeli	43.1854

Kontrol veri grubu için RMSE değerleri ANFIS ile 43.1854 TL, doğrusal regresyon modeli ile 52.188 TL olarak hesaplanmıştır. Sonuçlardan görüleceği üzere seçilen ANFIS mimarisi daha başarılı tahmin performansı sağlamıştır.

SONUÇLAR ve ÖNERİLER

Çalışmada tasarlanan Eşzamanlı Sinirsel Bulanık Çıkarım Sisteminin arızaları doğru sınıflandırılması ve olası masrafların tespit edilebilmesi için gerekli olan akıllı karar vericinin yerine karar vermesi amaçlanmıştır. Motor, ön aksam ve şanzıman arızalarının tespitine yönelik bir perspektif belirlenmiştir.

Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE) popüler bir tahmin başarı değerlendirme ölçütüdür. Elde edilen bilgilerin genelde müşteri şikâyetleri bağlantılı sezgisel veriler olmasından dolay MAPE oranının çok düşük olması beklenmemelidir. Uygulanan yöntemlerin tahmin doğrulukları, Ortalama Mutlak Yüzde Hata (MAPE) istatistiği yardımıyla değerlendirilmiştir. Literatürde, MAPE istatistiğinin tahmin hatalarını yüzdesel olarak ifade etmesi ve tek başına bir anlamının olması, diğer kriterlere göre üstünlüğü olarak kabul edilmektedir [156]. Witt, MAPE değerleri %10' un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise "doğru tahmin" modelleri olarak sınıflandırmıştır [154]. Lewis, MAPE 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 [155].

Çalışma kapsamında belirlenen 20 kontrol değeri için MAPE %17.7 olarak hesaplanmıştır, %10 ile %20 arasındaki MAPE oranı tahmin performansının başarılı olduğunu göstermektedir.

Daha sonraki çalışmalarda daha geniş bir veri havuzu kullanılarak araştırmanın kapsamı genişletilebilir. Böylece arızaların yıllara göre kümesel değişimleri gözlenebilir. Çevresel faktörlerde meydana gelen değişiklikler ve belirli parçalarda oluşan kusurlar, periyodik olarak sistem yöneticileri tarafından aktarılacak olan güncel eğitim bilgileri yardımıyla sistemin içerisine eklenebilecektir.

Sistem tatminkâr bir hızla çalışmakta ve gerçek dünyadaki problemlere çözüm getirmektedir. Araçlardaki arızalar daha hızlı ve doğru bir biçimde tespit edilebilmekte, müşterilerin serviste bekleme sürelerinin azaltılmasına katkı sağlamakta böylece müşteri memnuniyeti üzerinde olumlu bir etki yaratılmaktadır.

Sistem istenildiği taktirde internet üzerinden 7 gün 24 saat faaliyet gösterebilme yeteneğine sahiptir. Bu sayede müşteriler araçlarını servise getirmeden araçtaki olası problemli nokta ve arıza tutarını öğrenebilir. Böylece, servis randevularını organize edebilirler. Oluşturulan sistem ile servislerdeki iş gücünün verimli bir şekilde atanması, paralel olarak teknisyenlerin araçlardaki sorunlu noktaları hızlıca tespit etmesi, iş çizelgelerini ve tanımlanmış iş sürelerini dikkate alınarak müşteriye verilen teslim süresi tahmini iyileştirilmesine olanak sağlayabilir. Belirli arıza tipleri için kullanıcıları acil olarak en yakın servise yönlendiren bir uyarı mekanizması mevcut sisteme rahatlıkla eklenebilir. Bu sayede olası kazaların ve çekici masraflarının önüne geçilebilir.

Geliştirilen sistemin en önemli avantajlarından bir diğeri ise servis danışmanlarının müşteri şikâyetlerini kasıtlı olarak çarpıtması, değiştirmesi, sorumluluktan kaçmak için saklaması ve işten ayrılarak bilgi birikimlerini yanlarında götürmelerinin önüne geçmesi olacaktır. Sistem, servis müşterilerine, kişisel ön yargıdan uzak, anlık bilgilendirmede bulunmaktadır. Ayrıca servis danışmanlarının aşırı iş yükünden kaynaklanan fiziksel ve zihinsel yorgunluklarının işe yansıtma riski bu sistem ile ortadan kalkmaktadır.

KAYNAKLAR

[1] Uzunoğlu E., Müşteri Odaklı Pazarlama Anlayışına Göre Değer Yaratma: Bir Model Olarak Değer İletim Sistemi, ***Eskişehir Osmangazi Üniversitesi İİBF Dergisi***, 2(1), 11-29 Dr. Ebru Uzunoğlu, 2007.

[2] Czogala, E., Leski, J., "Fuzzy and Neuro-Fuzzy Intelligent Systems", ***Physica-Verlag Heidelberg***, New York, 2000.

[3] Ferré-Huguet, N., Nadal, M., Schuhmacher, M., Domingo, J.L., Environmental impact and human health risks of polychlorinated dibenzo-p-dioxins and dibenzofurans in the vicinity of a new hazardous waste incinerator: A case study. ***Environmental Science and Technology*** 40, 61-66, 2006.

[4] Piar Araştırma Ltd. Şti, ***Otomobil Sektör Araştırması***, 1990.

[5] İktısadî Araştırmalar Vakfı, Türkiye Otomotiv Sektörünün Bugünü Ve Yarını, Seminer Kayıtları, Syf 72, ***İktisadî Araştırmalar Vakfı***, İstanbul, 2005.

[6] Kotler Philip ve Turner Ronald E., Marketing Management-Analysis, Planning, Implementation and Control, Canadian 7Th Ed., ***Prentice Hall Inc***., 1993.

[7] LIN, Hsin-Hui ve Yi-Shun Wang, An Examination Of The Determinants Of Customer Loyalty İn Mobile Commerce Contexts, ***Information & Management***, 43, ss. 271–282, 2006.

[8] Trotter M., Feinberg R., Anton J., At Anytime – From Anywhere – In Any Form (1/15/1999) CRM Project Volume 1, Center for Customer-Driven Insight Jon Anton, ***Purdue University Press***, Center for Customer-Driven Insight, 1999.

[9] Öztemel E., Yapay Sinir Ağları, syf 10- 29, ***Papatya Yayıncılık***, İstanbul, 2003.

[10] Sağıroğlu, S., Besdok, E., Erler, M., Mühendislikte yapay zeka uygulamaları-I: Yapay Sinir Ağları, ***Ufuk Kitap Kırtasiye Yayıncılık***, Kayseri, 23-116, 2003.

[11] Yurtoğlu Hasan, DPT – Uzmanlık Tezleri, Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, ***Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü***, 2005.

[12] Zadeh, L.A., Information and Control, Fuzzy Sets, ***Department of Electrical Engineering and Electronics Research Laboratory University of California***, 8, 338-353, 1965.

[13] Anderson, J. A., An Introduction to Neural Networks, ***MIT Press,*** Cambridge, 1995.

[14] Elmas Ç., Yapay Zeka Uygulamaları, ***Seçkin Yayıncılık***, ISBN 978-975-02-0614-6, 2007.

[15] Türe M., Kurt İ., Yavuz E. Hipertansiyonun tahmini için çoklu tahmin modellerinin karşılaştırılması, Sinir ağları, lojistik regresyon ve esnek ayırma analizleri, ***Anadolu Kardiyoloji Dergisi***, 2005.

[16] Lın C., Lee G., Neural Fuzzy Systems, ***Prentice Hall***, pp 236-240, 242, 445-448, 1996.

[17] Ergezer H., Dikmen M., Özdemir E.,Yapay Sinir Ağı ve Tanıma Sistemleri, Başkent Üniversitesi, Bilgisayar Mühendisliği, ***Pivolka,*** yıl 2, sayı 6**,** 2003.

[18] Afolabi M. O, Olude O., ***Bilim ve Endüsri Sistemleri Mühendisliği, Binghamton Üniversitesi***, 2007.

[19] Efe M. Ö., Kaynak O. Yapay Sinir Ağları ve Uygulamaları syf 1, ***Boğaziçi Üniversitesi***, İstanbul, 2004.

[20] Wang, S., ve Archer, N.P., A neural network technique in modelling multiple criteria multiple person decision making. ***Computers Operations Research***, 21, 2, 127-142, 1993.

[21] Fausett, L., Fundamentals of Neural Networks: Architectures, Algorithms, and Applications, ***Prentice Hall***, New Jersey, 1994.

[22] Zaruda, J.M., Introduction to Artificial Neural Systems, ***West Publishing Company***, 683 p. New York, 1992.

[23] Klir, G.J. and Yuan B., Fuzzy Sets and Fuzzy Logic, ***Prentice-Hall***, USA, 1995.

[24] Elmas Ç., Bulanık mantık derleyicileri, kuram, uygulama, sinirsel bulanık mantık, ***Seçkin Yayıncılık***, 20- 230 p., 2003.

[25] Tsoukalas, L. H. , Uhrıg, R.E., Fuzzy And Neural Approaches in Engineering, ***Jhon Wiley & Sons Inc***, New York, 1996.

[26] Robert Fuller. Neural Fuzzy Systems, ***Abo Akademi University***, ISBN 951-650-624-0, ISSN 0358-5654, 1995.

[27] Narendra, K. Ve Parthasarathy, K., Identification and Control of Dynamical Systems Using Neural Networks, ***IEEE Trans. on Neural Networks***,1:4-27, 1990.

[28] Jang, J.S.R., Sun, C.T., Mizutani, E., Neuro Fuzzy and Soft Computing A Computational Approach to Learning, ***Prentice Hall***, 1996.

[29] Ahmad M. Ibrahim, Fuzzy Logic for Embedded Systems Applications, ***Elsevier***, 2004.

[30] R.J. Machado and A.F. Rocha, A hybrid architecture for fuzzyconnectionist expert systems, in: A. Kandel and G. Langholz eds.,Hybrid Architectures for Intelligent Systems, ***CRC Press,*** Boca Raton, FL, 1992.

[31] Zekâî Şen, Bulanık Mantık ve Modelleme İlkeleri, ***Bilge Kültür Sanat***, İstanbul, 2001.

[32] Jang, J.S.R., Sun C.T., Mizutani, E., Neuro Fuzzy and Soft Computing A Computational Approach to Learning and Machine Intelligence, ***Prentice Hall***, 1997.

[33] Jang, J. S. R., ANFIS: Adaptive-Network Based Fuzzy Inference Systems. ***IEEE Trans. On Systems***, ***Man and Cybernetics***, 23, 1993.

[34] OYDER Otomotiv Yetkili Satıcıları Derneği Yayını, Yetkili Satıcıların Memnuniyeti ve Karlılığı Araştırması, ***Otoban Dergisi sayı 1-8***, 2007-2008.

[35] Abraham A., "Adaptation of Fuzzy Inference System Using Neural Learning, Fuzzy System Engineering: Theory and Practice", Nadia Nedjah et al. (Eds.), Studies in Fuzziness and Soft Computing, ***Springer Verlag,*** Germany, ISBN 3-540-25322-X, Chapter 3, pp. 53–83, 2005.

[36] Roussinov D.G., Chen H., A scalable self-organizing map algorithm fortextual classification: a neural network approach to thesaurus generation, ***Communication and Cognition - Artificial Intelligence***, 15(1-2): 81-111, 1998.

[37] Yılmaz Alpdoğan Kendinden Düzenlenen Haritalar İle Doküman Sınıflandırma, ***Gazi Üniversitesi Fen Bilimleri Enstitüsü,*** Syf 35-40, Bilim Kodu: 902.1.014, 2007.

[38] Ajith Abraham , Neuro Fuzzy Systems: State-of-the-art Modeling Techniques, ***School of Computing & Information Technology Monash University***, 2008.

[39] Teuvo Kohonen. Self-Organizing Maps, ***Springer Series in Information Science***, volume 30, Berlin, Heidelberg, 1995.

[40] K.Kiviluto, Comparing 2D and 3D self-organizing maps in financial data visualization, ***5th International Conference on Soft Computing and Information/Intelligent Systems (IIZUKA'98)***, pages 68-71, 1998.

[41] H.Speckmann, G. Raddatz, and W. Rosensitel, Considerations of geometrical and fractal dimension of SOM to get better learning results, ***In Proceeding of the International Conference on Artificial Neural Networks ICANN'94***, pages 342 345, 1994.

[42] Juha Vesanto and Esa Alhoniemi, Clustering of the Self-Organizing Map, ***IEEE Transactions on Neural Networks***, 1l(3):586-600, 2000.

[43] D.Alahakoon ans S.K. Halgamuge. Knowledge Discovery with Supervised and Unsupervised Self Evolving Neural Networks, ***IEEE Transactions on Neural Networks***, Pages 907-910, 1998.

[44] Justine Blackmore and Risto Miikulanien. Visulizing High-Dimensional Structure with Incremental Grid Growing Neural Networks, In A.Prieditis and S.Russell editors, ***Machine Learning proceedings of the 12th International Conference***, sayfa 55-63, Kaufmann, 1995.

[45] Bernd Fritzke, Growing Grid a self-organizing network with constant neighborhood range and adaptation strenght, ***Neural Processing Letters***, 2(5):9 13, 1995.

[46] Stefan Jockush. A neural network which adapts its structure to a given set of patterns. In R.Eckmiller, G Hartman and G.Hauske, editors, Paralel Processing in Neural systems and Computers, ***Elsevier Science Paublishers***, pages 169-172, 1990.

[47] Marina Resta, Self organizing evolutionary models in financial markets forecasting, ***In Proceedings of WSOM' 97*** ,pages 187-190, 1997.

[48] Joaquim S. Rodrigues and Luis B.Almeida. Improving the learning speed in topological maps pattern, ***In proceeding of International Neural Network Conference***, volume 2, pages 813-816, 1990.

[49] Pasi Koikkalainen, Fast deterministic self-organizing maps, ***In Proceedings of International Conference on Artificial Neural Networks ICANN'95***, pages 63-68, 1995.

[50] Pasi Koikkalainen and Erkki Oja, Self-organizing hierarchial feature maps, ***In Proceeding of International Joint Conference on Neural Networks IJCNN'90***, pages 279-284, 1990.

[51] T.M Martinetz S.G. Beragovich and K.J. Schulten "Neural Gas" network for vector quantization and its application to time-series prediction, ***IEEE Transactions on Neural Networks***, 4(4):558 569, 1993.

[52] Bernd Fritzke, Growing Cell Structures A Self-Organizing neural Network for Unsupervised and Supervised learning, ***Neural Networks***, (9):1441 1460, 1994.

[53] Bernd Fritzke, Growing Cell Structures A Self-Organizing neural Network for Unsupervised and Supervised learning, ***Neural Networks***, (9):1441 1460, 1994.

[54] Allen Gersho, Asymptotically Optimal Block Quantization, ***IEEE Transactions on Information Theory***, IT 25(4):373 380, 1979.

[55] Christopher G. Healey, Effective Visualization of Large Multidimensional Datasets, ***PhD. thesis***, ***The University of British Columbia***, 1996.

[56] Tcnvo Kohoiieii, Comparison of SOM Point Densities Based on Different Criteria, ***Neural Computation***, 11(8):2081-2095, 1999.

[57] Paul L. Zador, Asymptotic Quantization Error of Continuous Signals and the Quantization Dimension, ***IEEE Transactions on Information Theory***, IT-28(2):139-149), 1982.

[58] Helge Ritter, Asymptotic Level Density for a Class of Vector Quantization Processes, ***IEEE Transactions on Neural Networks***, 2(1):173-175, 1991.

[59] W.DuMouchel, C. Volinsky, T. Johnson, C. Cortes, and D. Pregibon Squashing flat files flatter, ***In Proceedings of the Fifth International Conference on Knowledge Discovery and Data Mining KDD'99***, 1999.

[60] Juha Vesanto and Esa Alhoniemi, Clustering of the Self-Organizing Map, ***IEEE Transactions on Neural Networks***, 2000.

[61] John W. Sammon Jr. A. Nonlinear Mapping for Data Structure Analysis, ***IEEE Transactions on Computers***, C-18(5):401-409, 1969.

[62] M. J. D. Powell, Radial basis functions for multivariable interpolation: a review, In J. C. Mason and M. G. Cox, editors. Algorithms for Approximation, ***Clarendon Press Oxford University***, pages 143-167, 1987.

[63] Christopher M. Bishop, Neural Networks for Pattern Recogition, ***Oxford University Press***, 1995.

[64] Bart Kosko, Fuzzy Engineering, ***Prentice Hall International***, 1997.

[65] Robert M. Gray., Vector quantization, ***IEEE ASSP Magazine***, pages 4-29, 1984.

[66] John Moody and Christian J. Darken. Fast Learning in Networks of Locally-Timed Processing Units, ***Neural Computation***, l(2):281-294,1989.

[67] James C. Bezdek. Pattern Recognition with Fuzzy Objective Function Algorithms, ***Plenum Press***, New York, 1981.

[68] T. Hastie and W. Stnetzle. Principal curves, ***Journal of the American Statistical Association***, 84:502-516, 1989.

[69] Vladimir Cherkassky and Filip Mulier. Learning From Data: concepts, theory, and methods, ***John Wiley & Sons Inc.***, 1998.

[70] Samuel Kaski, Data Exploration Using Self-Organizing Maps, PhD thesis, ***Helsinki University of Technology, Acta Polytechnica Scandinavica Mathematics***, Computing and Management in Engineering, 1997.

[71] Vladimir Cherkassky and Filip Mulier. Learning From Data: concepts, theory, and methods, ***John Wiley & Sons, Inc***., 1998.

[72] F. Murtagh, Interpreting the Kohonen self-organizing map using contiguity-constrained clustering, Pattern Recognition Letters, pages 399-408, ***Elsevier***, 1995.

[73] Xnegoiig Zhang and Yanda Li, Self-Organizing Map as a New Method for Clustering and Data Analysis, ***In Proceedings of International Joint Conference on Neural Networks UCNN'93***, pages 2448-2451, 1993.

[74] Varfis and C.versino, Clustering of Socio-Economic Data with Kohonen Maps, ***Neural Network World***, 2(6):813-834,1992.

[75] J. Lampiiieii and E. Oja, Clustering Properties of Hierarchical Self-Organizing Maps, ***Journal of Mathematical Imaging and Vision***, 2(2-3):261-272, 1992.

[76] Paul Mangiameli, Shaw K.Chen, and David West, A comparison of SOM Neural Network and hierarchical clustering methods, ***European Journal of Operational Research,*** 93(2), 1996.

[77] Joachim Buhmann, Complexity Optimezed Data Clustering by Competitive Neural Networks, ***Neural Computation***, 5(3):75-88, 1993.

[78] Eric Boudaillier and Georges Hebrail, Interactive Interpretation of Hierarchical Clustering, ***Intelligent Data Analysis***, 2(3), 1998.

[79] Anil K. Jain and Richard C. Dubes. Algorithms for Clustering Data, ***Prentice-Hall***, 1998.

[80] James G. Bezdek, Some New Indexes of Cluster Validity. ***IEEE Transac tions on Systems, Man, and Cybernetics Part B: Cybernetics***, 28(3):301-315, 1998.

[81] Glenn W. Milligan and Martha C.Cooper, An Examination of Procedures for Determining the Number of Clusters in a Data Set, ***Psychometrika,*** 50(2):159-179, 1985.

[82] Geoffrey J. McLahlan and Kaye E.Basford, Mixture Models: Inference and Applications to Clustering, ***Statistics: Textbooks and Monographs***, volume 84, Marcel Dekker, 1987.

[83] James G. Bezdek and Saiikar K. Pal, editors, Fuzzy Models for Pattern Recognition: Methods That Search for Structures in Data, ***IEEE Press***, 1992.

[84] Vladimir Cherkassky and Filip Mulier, Learning From Data: concepts, theory, and methods, ***John Wiley & Sons Inc.***, 1998.

[85] Vesanto J., Himberg J., Siponen M., and Simula O. Enhancing SOM Based Data Visualization. In Yamakawa T. and Matsumoto G., editors, **Proceedings of the 5th International Conference on Soft Computing and Information/Intelligent Systems**, pages 64-67, 1998.

[86] Juha Vesanto, Petri Vasara, Riina-Riitta Helminen, and Olli Simula. Integrating environmental, technological and financial data in forest industry analysis. ***Stichting Neural Network Conference***, pages 153-156, Amsterdam, Netherlands, 1997.

[87] Juha Vesanto SOM-Based Data Visualization Methods, ***Intelligent Data Analysis***, 3(2):111-126, 1999.

[88] V. Tryba and K. Goser. Self-Organizing Feature Maps for process control in chemistry, In T. Kohoiieii, K. Makisara, O. Simula, and J. Kaiigas, editors, ***Proceedings of International Conference on Artificial Neural Networks ICANN'91***, pages 847-852, Amsterdam, Netherlands, 1991.

[89] M. Kasslin, J. Kaiigas, and O. Simula, Process state monitoring using self-organizing maps. In I. Aleksaiider and J. Taylor, editors, ***Artificial Neural Networks***, volume 2, pages 1531-1534, Amsterdam, Netherlands, 1992.

[90] Esa Alhoniemi, Johan Himberg, and Juha Vesanto, Probabilistic Measures for Responses of Self-Organizing Map Units., ***ICSC Academic Press***, pages 286-290, 1999.

[91] Samuel Kaski, Jaime Nikkila, and Teuvo Kohoiieii, Methods for interpreting a self-organized map in data analysis. In Michel Verleyseii, editor, Proceedings of ESANN'98, ***6th European Symposium on Artificial Neural Networks***, Bruges, *22-24*, pages 185-190. D-Facto, Brussels, Belgium, 1998.

[92] Johan Himberg. Enhancing SOM-based data visualization by linking different data projections, In L. Xn, L. W. Chan, and I. King, editors, Intelligent Data Engineering and Learning, ,IDEAL'98, pages 427-434., ***Springer***, 1998.

[93] Juha Vesanto and Jussi Ahola, Hunting for Correlations in Data Using the Self-Organizing Map. In Proceeding of the International ICSC Congress on Computational Intelligence Methods and Applications (CIMA'99), ***ICSC Academic Press***, page. 279-288, 1999.

[94] John W. Sammon, Jr. A Nonlinear Mapping for Data Structure Analysis, ***IEEE Transactions on Computers***, page 401-409, 1969.

[95] Samuel Kaski, Jarko Venna, and Teuvo Kohonen. Coloring that reveals high-dimensional structures in data. In T.Gedeon, P.Wong,S. Hagamuge,Kasabov, D. Nanck, and K. Fnknshima, editors, Proceedings of ICONIP '99, ***6th International Conference on Neural Information Processing***, volume II, pages 729-734. IEEE-Service Center, Piscataway, NJ, 1999.

[96] Samuel Kaski, Jarko Venna, and Teuvo Kohonen. 14: Tips for Processing and Color-Coding of Self Organizing Maps, In Deboeck and Kohonen, ***Springer Verlag***, pages 195-202.

[97] Johan Himberg, A SOM based cluster visualization and its application for false coloring, ***International Joint Conference in Neural Networks***, (IJCNN), 2000.

[98] Jukka livariiieii, Teuvo Kohoiieii, Jari Kaiigas, and Sami Kaski, Visualizing the Clusters on the Self-Organizing Map. In Christer Carlsson, Timo Jarvi, and Tapio Repoiieii, editors. ***Proceedings of Conference on Artificial Intelligence Research in Finland, number 12 in Proceedings of Conference of Finnish Artificial Intelligence Society***, pages 122-126, Helsinki, Finland, 1994.

[99] Erkki Hakkinen and Past Koikkalainen, The neural data analysis environment., ***In Proceedings of the Workshop on Self-Organizing Map***, pages 69-74, 1997.

[100] M.A. Kraaijveld, J. Mao,and A. K. Jain. A nonlinear projection method based on kohonen's topology preserving maps, ***IEEE Transactions on Neural Networks***, 6(3):548-559, 1995.

[101] Ultsch and H. P. Siemoii. Kohoiieirs Self Organizing Feature Maps for Exploratory Data Analysis, ***In Proceedings of International Neural Network Conference INNC'90***, pages 305-308, Dordrecht, Netherlands, 1990.

[102] Edward Tnfte, The Visual Display of Quantitative Information, ***Graphics Press***, 1983.

[103] Andreas Buja, John Alan McDonald, John Michalak, and Werner Stuetzle, Interactive data visualization using focusing and linking, ***In Proceedings of IEEE Conference on Visualization***, pages 156-163, 1991.

[104] Christopher G. Healey, Effective Visualization of Large Multidimensional Datasets, ***PhD thesis, The University of British Columbia***, 1996.

[105] S. P. Lnttrell, A Bayesiaii analysis of self-organising maps, ***Neural Computation***, 6(5):767-794, 1994.

[106] Tom M. Heskes and Bert Kappeii. Error potential for self-organization. ***In Proceedings ICNN'93 International Conferance on Neural Networks***, volume III, pages 1219-1223, Piscataway, NJ, 1993.

[107] Teuvo Kohonen, Self Kohonen, T. Self-organizing maps: optimization approaches. In Kohonen, T., Mäkisara, K., Simula, O., and Kangas, J., editors, ***Artificial Neural Networks. Proceedings of ICANN'91 International Conference on Artificial Neural Networks***, volume II, pages 981-990, North-Holland, Amsterdam, 1991.

[108] Ed Erwin, Klaus Obermayer, and Klaus Schulten, Self-organizing maps: Ordering, convergence properties and energy functions, ***Biological Cybernetics***, 67(1):47:55, 1992.

[109] J. B. Kruskal, Multidimensional Scaling by Optimizing Goodness of Fit to a Nonmetric Hypothesis, ***Psychometrika***, 29(1):1-27, 1964.

[110] Vladimir Cherkassky and Filip Mulier, *Learning From Data:* concepts, theory, and methods, ***John Wiley & Sons Inc.***, 1998.

[111] X.H. Li and C.L.P. Chen, The Equivalance Between Fuzzy Logic Systems and Feedforward Neural Networks, ***IEEE Transactions on Neural Networks***, Vol 11, No. 2, pages 356–365, 2000.

[112] Narendra, K. ve Parthasarathy K., Identification and Control of Dynamical Systems Using Neural Networks, ***IEEE Trans. on Neural Networks***, 1:4-27, 1990.

[113] B. Kosko, Neural Networks and Fuzzy Systems: A Dynamical Systems Approac to Machine Intelligence, ***Prentice Hall,*** Englewood Cliffs, New Jersey, 1992.

[114] W. Pedrycz and H.C. Card, Linguistic Interpretation of Self Organizing Maps, ***In Prroceedings of the IEEE International Conference on Fuzzy Systems***, San Diego, pp. 371–378, 1992.

[115] H. Nomura, I. Hayashi and N. Wakami, A Learning Method of Fuzzy Inference Systems by Descent Method, ***In Proceedings of the First IEEE International conference on Fuzzy Systems***, pages 203–210, San Diego, USA, 1992.

[116] Kohonen T., Self-organization of very large document collections: State of theart, ***Proceedings of the 8th International Conference on Artificial Neural Networks***, Skovde, Sweden, 1: 65-74, 1998.

[117] E.H. Mamdani and S. Assilian, An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller, ***International Journal of Man-Machine Studies***, Vol 7, No.1, pp. 1–13, 1975.

[118] M. Sugeno, Industrial Applications of Fuzzy Control, ***Elsevier Science Pub Co.***, 1985.

[119] C.T. Lin and C.S.G. Lee, Neural Network based Fuzzy Logic Control and Decision System, ***IEEE Transactions on Comput.***, 40(12): pp. 1320–1336, 1991.

[120] H.R. Berenji and P. Khedkar, Fuzzy Rules for Guiding Reinforcement Learning, ***In International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems, (IPMU' 92),*** pp. 511–514, 1992.

[121] D. Nauck and R. Kruse, NEFCON-I: An X-Window Based Simulator for Neural Fuzzy Controllers, ***In Proceedings of the IEEE International Conference on Neural Networks***, Orlando, pp. 1638–1643, 1994.

[122] Bircan H., Zontul M., Yüksek A.G., Som Tipinde Yapay Sinir Ağlarını Kullanarak Türkiye' nin İhracat Yaptığı Ülkelerin Kümelenmesi Üzerine Bir Çalışma, ***Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi***, 20(2):219-238, 2006.

[123] Kohonen T. ,Self-organized formation of topologically correct feature maps, ***Biological Cybernetics***, 43:59-69, 1982.

[124] Kohonen T., Self-Organizing Maps Third, extended edition, ***Springer***, 2001.

[125] Rauber, Anderas, Cluster Visualization in Unsupervised Neural Networks., Jang, J. S., Gulley N., Fuzzy Logic Toolbox User's Guide, ***The Mathworks Inc.***, 1995.

[126] Jang J.S., ANFIS: Adaptive-Network-based Fuzzy Inference System, IEEE Trans. On System, ***Man and Cybernetics***, 1993.

[127] Neuro-Fuzzy classification for the job assignment problem Arpad Kelemen, Robert Kozma and Yulan Liang, ***Department of Mathematical Sciences The University of Memphis***, TN 38152, 2002.

[128] R. Agrawal, H. Mannila, R. Srikant, H. Toivonen and A. Verkamo, Fast Discovery of Associstion Rules, in Advances in Knowledge Discovery and Data Mining, ***MIT Press***, pages 307-328, 1996.

[129] Martin T. Hagan, Howard B. Demuth and Mark Hudson Beale Neural Network Toolbox 7 User's Guide, ***The MathWorks Inc***., 1992-2000.

[130] Fuzzy Logic Toolbox User's Guide, ***The MathWorks Inc***, 1995-1999.

[131] *A.P. Paplinski*, ***Adaptive Neuro-Fuzzy Inference System (ANFIS Vol 20)***, *2005.*

[132] Güner, Evren M.S., Department of Chemical Engineering Adaptive Neuro Fuzzy Inference System (Anfis) Applications In Chemical Processes, M.S., ***Department of Chemical Engineering***, ***The Middle East Technical University***, 2003.

[133] Evsukoff, A., S. Gentil and J. Montmain, Fuzzy , Reasoning in Cooperative Supervision Systems, ***Control Engineering Practice***, pages 389- 407, 2000.

[134] Yang ve Liao, Yang, W.H., Liao, C.J. Survey of scheduling research involving setup times, ***Journal of Systems Science,*** 30, 143-155, 1999.

[135] Insfran A. H. F., da Silva A. P. A., Lambert Torres G, Fault diagnosis using fuzzy sets, ***Engineering intelligent systems for electrical engineering and communications***, Vol.7, No.4, pp.177-182, 1999.

[136] Mechefske, CK Objective Machinery Fault Diagnosis Using Fuzzy Logic, ***Mechanical Systems and Signal Processing***, Vol 12, pages 855-862, 1998.

[137] Chen J., Patton R. J., Robust Model Based Fault Diagnosis For Dynamic Systems, ***Kluwer Academic Publishers***, ISBN 0-7923-8411-3, 1999.

[138] Serkan BALLI, Bahadır KARASULU, Aybars UĞUR, Serdar KORUKOĞLU "Basketbolda oyuncu seçimi için sinirsel-bulanık karar destek sistemi, ***İTÜ Dergisi/d***, Cilt 8, Sayı 1, 2009.

[139] K. Güney and N. Sarikaya, Concurrent neuro-fuzzy systems for resonant frequency computation of rectangular, circular, and triangular microstrip antennas, ***Progress In Electromagnetics Research***, Vol. 84, 253-277, doi:10.2528/PIER08070603, 2008.

[140] William Andrés Ocampo Duque, On the development of decision-making systems based on fuzzy models to assess water quality in rivers, ***PhD Programme: Graduate Studies in Chemical and Process Engineering Department of Chemical Engineering Universitat Rovira i Virgili,*** Italy, 2006.

[141] Ahmad Mohammad Rashwa, Using neuro-fuzzy system for plate forming in shipyards, ***Naval Architecture & Marine Eng. Dept., Faculty of Eng., Alexandria University***, Alexandria, Egypt, 2004.

[142] Assis T.M.L., Nohara A.A., Valentini T.M., Power System Dynamic Security Assessment through a Neuro-Fuzzy Scheme Fluminense Fed. Univ. (UFF), Niteroi, Brazil Intelligent System Applications to Power Systems***, ISAP' 09. 15th International Conference,*** 2009.

[143] Abraham, A.; i-Miner: a Web usage mining framework using hierarchical intelligent systems Dept. of Comput. Sci., Oklahoma State Univ., Tulsa, OK, USA Fuzzy Systems, FUZZ' 03., ***the 12th IEEE International Conference***, 2003.

[144] K. W. Wong, P. M. Wong, T. D. Gedeon and C. C. Fung Rainfall prediction model using soft computing technique Soft Computing - A Fusion of Foundations, Methodologies and Applications Volume 7, ***Springer-Verlag,*** Number 6, 434-438, DOI: 10.1007/s00500-002-0232-4.

[145] Yeo, A. C., & Smith, K., An integrated data mining approach to premium pricing for the automobile insurance industry, In A. Shapiro & L. Jain (Eds.), Intelligent and Other Computational Techniques in Insurance: Theory and Applications (pp. 199-227), Singapore, ***World Scientific Press***, 2003.

[146] Yeo, A. C., & Smith, K. (). 'Implementing a data mining solution for an automobile insurance company: Reconciling theoretical benefits with practical considerations. In M. Khosrow-Pour (Ed.), Annals of Cases on Information Technology (pp. 63-73). Hershey, PA, USA, ***Idea Group Publishing***, 2003.

[147] Yeo, A. C., Smith, K., Willis, R. J., & Brooks, M. 'A comparison of soft computing and traditional approaches for risk classification and claim cost prediction in the automobile insurance industry. In L. Reznik & V. Kreinovich (Eds.), Soft Computing in Measurement and Information Acquisition (pp. 249-261), Berlin, Germany, ***Springer-Verlag***, 2003.

[148] Yeo, A. C., Smith, K. A., Willis, R. J., and Brooks, M., "Using Neural Networks to Model Premium Price Sensitivity of Automobile Insurance Customers", in Smith, K. A. and Gupta, J. N. D (eds.), Neural Networks in Business: Techniques and Applications, ***Idea Group Publishing***, Hershey, Pennsylvania, Chapter 3, pp. 41-54, 2002.

[149] Using adaptive network-based fuzzy inference system to forecast automobile sales Wang, Fu-Kwun; Chang, Ku-Kuang; Tzeng, Chih-Wei. Expert Systems with Applications (0957-4174) AVol.38,Iss.8;p.10587-10593, ***Science Direct,*** 2011

[150] Automotive fault diagnosis - part II: a distributed agent diagnostic system Murphey, Y.L.; Crossman, J.A.; ZhiHang Chen; Cardillo, J. Vehicular Technology, IEEE Transactions (0018-9545), Vol.52,Iss.4;p.1076-1098, ***IEEE/IET Electronic Library (IEL)***, 2003.

[151] Fault Prediction Using Artificial Neural Network and Fuzzy Logic Virk, S.M.; Muhammad, A.; Martinez-Enriquez, A.M. Artificial Intelligence,. MICAI '08. Seventh Mexican International Conference (978-0-7695-3441-1), p.149-154, ***IEEE/IET Electronic Library (IEL)***, 2008.

[152] Neuro-Fuzzy-Regression Algorithm for Improved Prediction of Manufacturing Lead Time with Machine Breakdowns S.M. Asadzadeh, A. Azadeh, A. Ziaeifar. Concurrent Engineering December., Vol.19,Iss.4;p.269 – 281, ***SAGE Journals Online***, 2011.

[153] WITT Stephen F. ve WITT Christine, *Modeling and Forecasting Demand in Tourism*, **Academic Press**, London, 1992.

[154] Lewis C.D. Industrial and Business Forecasting Methods, ***Butterworths Publishing***, 1982.

[155] Cho, V., A comparison of Three Different Approaches to Tourist Arrival Forecasting, ***Tourism Management***, 24 (3): 323-330, 2003.

EKLER

Ek1 : SOM Ağının Eğitilmiş Referans Ağırlık Vektörleri :

Columns 1 through 6

0.0001	0.0001	0.0001	0.0001	0.0001	0.9770
0.0001	0.0001	0.0001	0.0001	0.0001	0.7401
0.2938	0.2938	0.2938	0.0995	0.0001	0.0061
0.9944	0.9943	0.9943	0.6031	0.0001	0.0003
0.9990	0.9990	0.9990	0.8196	0.0001	0.0001
0.3100	0.3100	0.3100	0.3096	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.6712
0.0001	0.0001	0.0001	0.0001	0.0001	0.0005
0.4574	0.2301	0.2301	0.0775	0.0379	0.0001
0.7486	0.5523	0.5523	0.3359	0.0327	0.0001
0.2638	0.2638	0.2638	0.2011	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0094
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.1285	0.0001	0.0001	0.0001	0.0213	0.0001
0.5510	0.0969	0.0969	0.0002	0.0756	0.0001
0.2882	0.1327	0.1327	0.0001	0.0259	0.0001
0.0484	0.0484	0.0484	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0820	0.0001	0.0001	0.0001	0.0136	0.0001
0.1680	0.0503	0.0503	0.0001	0.0196	0.0001
0.0664	0.0664	0.0664	0.0001	0.0001	0.0001
0.0002	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001

0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001

Columns 7 through 12

0.0001	0.0001	0.9883	0.0001	0.9312	0.0001
0.2425	0.0001	0.7487	0.0001	0.9480	0.0001
0.6982	0.0001	0.0061	0.0012	0.7049	0.0030
0.0001	0.0023	0.0003	0.0034	0.0003	0.4033
0.0001	0.0005	0.0001	0.0007	0.0001	0.7255
0.0001	0.5765	0.0001	0.6306	0.0001	0.4809
0.2200	0.0001	0.6789	0.0932	0.9528	0.0932
0.9990	0.0001	0.0005	0.0003	0.9996	0.0003
0.5411	0.0001	0.0001	0.0003	0.5413	0.0006
0.0001	0.0002	0.0001	0.0002	0.0001	0.2683
0.0001	0.4006	0.0001	0.4360	0.0001	0.3380
0.0001	0.7779	0.0001	0.8489	0.0001	0.2500
0.0010	0.0001	0.0094	0.6905	0.6729	0.6634
0.2944	0.0001	0.0001	0.1867	0.4294	0.1250
0.3068	0.0001	0.0001	0.0538	0.3175	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0002
0.0001	0.0261	0.0001	0.0261	0.0001	0.0261
0.0001	0.3280	0.0001	0.3554	0.0001	0.1248
0.0001	0.0001	0.0001	0.2374	0.1629	0.1506

0.0001	0.0001	0.0001	0.0800	0.0144	0.0001
0.0001	0.0001	0.0001	0.0343	0.0068	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0261	0.0001	0.0261	0.0001	0.0261
0.0001	0.0354	0.0001	0.0354	0.0001	0.0354
0.0003	0.0001	0.0001	0.0191	0.0003	0.0001
0.0001	0.0001	0.0001	0.0448	0.0074	0.0001
0.0001	0.0001	0.0001	0.0257	0.0051	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001

Columns 13 through 18

0.9815	0.0001	0.0001	0.0001	0.0001	0.0001
0.9595	0.0001	0.2425	0.0001	0.0001	0.0001
0.6293	0.0011	0.6993	0.0011	0.0011	0.0011
0.0004	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.9632	0.0932	0.3131	0.0932	0.0932	0.0932
0.8905	0.0003	0.9992	0.0003	0.0003	0.0003
0.4823	0.0003	0.5413	0.0003	0.0003	0.0003
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.6732	0.6634	0.6643	0.6634	0.6634	0.9896

0.3871	0.1250	0.4192	0.1250	0.1250	0.2495
0.2734	0.0001	0.3068	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.1506	0.1506	0.1506	0.1506	0.1506	0.4507
0.0001	0.0001	0.0001	0.0001	0.0001	0.0878
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0002	0.0001	0.0002
0.0002	0.0001	0.0003	0.0001	0.0001	0.2295
0.0001	0.0001	0.0001	0.0001	0.0001	0.0901
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.1610	0.1511	0.1610
0.0001	0.0001	0.0001	0.1388	0.1303	0.1388
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.1391	0.1305	0.1391
0.0001	0.0001	0.0001	0.2596	0.2436	0.2596
0.0001	0.0001	0.0001	0.1257	0.1180	0.1257

Columns 19 through 24

0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.2425	0.0001	0.0001	0.0001	0.0001
0.0011	0.6982	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0002	0.0001	0.0002
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0932	0.2200	0.0001	0.0001	0.0001	0.0001

0.0003	0.9990	0.0001	0.0001	0.0001	0.0001
0.0003	0.5411	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.6634	0.0010	0.0001	0.0001	0.0001	0.0001
0.1250	0.2944	0.0001	0.0001	0.0001	0.0001
0.0001	0.3068	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.1506	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0444	0.0519	0.0001	0.0519
0.0001	0.0001	0.0417	0.0488	0.0001	0.0488
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0003	0.6543	0.7697	0.7694	0.7698
0.0001	0.0001	0.3046	0.4200	0.3047	0.3889
0.0001	0.0001	0.0624	0.1572	0.0001	0.1677
0.0001	0.0001	0.0385	0.0957	0.0001	0.1350
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.7719	0.9999	0.9077	0.9538
0.0001	0.0001	0.3453	0.6147	0.3455	0.5970
0.0001	0.0001	0.0418	0.2162	0.0001	0.2730
0.0001	0.0001	0.0001	0.0686	0.0001	0.1216
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001

Columns 25 through 30

0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0002	0.0001	0.0001	0.0003	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0002	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0416
0.0001	0.0001	0.0001	0.0892	0.0001	0.0433
0.0001	0.0001	0.0001	0.1582	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0500
0.0001	0.0001	0.0001	0.0603	0.0001	0.0587
0.0001	0.0001	0.0557	0.1134	0.0001	0.0277
0.0001	0.0001	0.0800	0.0817	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0003	0.0001	0.0001	0.0002	0.0003
0.7698	0.0001	0.0001	0.0001	0.0001	0.0001
0.3358	0.0001	0.0001	0.0001	0.0001	0.0302
0.1094	0.0001	0.0418	0.0426	0.0001	0.0208
0.1081	0.0001	0.1027	0.0523	0.0001	0.0001
0.0001	0.3201	0.0800	0.0001	0.0803	0.0001
0.0001	0.3450	0.0001	0.0001	0.0691	0.3798
0.9538	0.0001	0.0001	0.0001	0.0001	0.0001

0.5610	0.0001	0.0001	0.0001	0.0001	0.0001
0.2633	0.0001	0.0558	0.0001	0.0001	0.0001
0.1459	0.2764	0.0692	0.0001	0.0692	0.0001
0.0001	0.5804	0.0001	0.0001	0.1291	0.3553
0.0001	0.3750	0.0001	0.0001	0.0626	0.6879

Columns 31 through 36

0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0002	0.0001	0.0001	0.0002	0.0001	0.0002
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0002	0.0001	0.0002
0.0526	0.0001	0.0001	0.0001	0.0001	0.0001
0.1924	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.0001	0.0001	0.0001
0.0001	0.0001	0.0001	0.1047	0.0001	0.0977
0.0400	0.0001	0.0001	0.1501	0.0001	0.1402
0.3161	0.0001	0.0001	0.0001	0.0001	0.0001
0.6450	0.0001	0.0001	0.0001	0.0001	0.0003
0.0001	0.0001	0.7694	0.7694	0.0001	0.0001

0.0001	0.0001	0.3047	0.3047	0.0001	0.0001
0.0001	0.0001	0.0001	0.0787	0.0001	0.0734
0.0001	0.0001	0.0001	0.1929	0.0001	0.1801
0.0400	0.0001	0.0001	0.1501	0.0001	0.1402
0.1721	0.0693	0.0001	0.0693	0.0429	0.3711
0.0001	0.0001	0.9077	0.9077	0.0001	0.0001
0.0001	0.0001	0.3455	0.3455	0.0001	0.0001
0.0001	0.0001	0.0001	0.1047	0.0001	0.0978
0.0001	0.0001	0.0001	0.1298	0.0001	0.1212
0.0001	0.0648	0.0001	0.0648	0.0401	0.3471
0.0001	0.1254	0.0001	0.1254	0.0776	0.6720

Column 37

0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0001
0.0106
0.0110
0.0001
0.0526
0.1634
0.0127

0.0149

0.0071

0.0400

0.2763

0.5372

0.0001

0.0077

0.0053

0.0001

0.4402

0.8619

0.0001

0.0001

0.0001

0.3455

0.9917

0.9840

Ek2 : SOM Ağının Başlangıç Referans Ağırlık Vektörleri

Columns 1 through 6

-0.5286	0.1240	0.1240	0.0984	-0.1543	0.0669
-0.5510	0.1068	0.1068	0.0876	-0.1552	0.3246
-0.5734	0.0897	0.0897	0.0769	-0.1561	0.5823
-0.5957	0.0726	0.0726	0.0661	-0.1570	0.8400
-0.6181	0.0555	0.0555	0.0554	-0.1578	1.0977
-0.6405	0.0384	0.0384	0.0447	-0.1587	1.3553
-0.4883	0.1568	0.1568	0.1212	-0.1531	0.0732
-0.5107	0.1397	0.1397	0.1105	-0.1540	0.3309
-0.5331	0.1226	0.1226	0.0997	-0.1548	0.5886
-0.5555	0.1055	0.1055	0.0890	-0.1557	0.8463
-0.5779	0.0883	0.0883	0.0782	-0.1566	1.1040
-0.6003	0.0712	0.0712	0.0675	-0.1575	1.3617
-0.4257	0.2068	0.2068	0.1548	-0.1510	-0.1781
-0.4481	0.1897	0.1897	0.1440	-0.1519	0.0796
-0.4705	0.1725	0.1725	0.1333	-0.1527	0.3373
-0.4929	0.1554	0.1554	0.1226	-0.1536	0.5949
-0.5153	0.1383	0.1383	0.1118	-0.1545	0.8526
-0.5376	0.1212	0.1212	0.1011	-0.1554	1.1103
-0.3855	0.2396	0.2396	0.1776	-0.1497	-0.1718
-0.4079	0.2225	0.2225	0.1669	-0.1506	0.0859
-0.4302	0.2054	0.2054	0.1561	-0.1515	0.3436
-0.4526	0.1883	0.1883	0.1454	-0.1524	0.6013
-0.4750	0.1712	0.1712	0.1346	-0.1533	0.8590
-0.4974	0.1540	0.1540	0.1239	-0.1541	1.1167
-0.3229	0.2896	0.2896	0.2112	-0.1476	-0.4231
-0.3452	0.2725	0.2725	0.2004	-0.1485	-0.1655
-0.3676	0.2554	0.2554	0.1897	-0.1494	0.0922
-0.3900	0.2382	0.2382	0.1790	-0.1503	0.3499
-0.4124	0.2211	0.2211	0.1682	-0.1511	0.6076

-0.4348	0.2040	0.2040	0.1575	-0.1520	0.8653
-0.2826	0.3224	0.3224	0.2340	-0.1464	-0.4168
-0.3050	0.3053	0.3053	0.2233	-0.1473	-0.1591
-0.3274	0.2882	0.2882	0.2125	-0.1482	0.0986
-0.3498	0.2711	0.2711	0.2018	-0.1490	0.3563
-0.3722	0.2540	0.2540	0.1911	-0.1499	0.6139
-0.3945	0.2369	0.2369	0.1803	-0.1508	0.8716

Columns 7 through 12

-0.2602	0.1591	0.0296	0.2903	-0.1444	0.3499
-0.2025	0.1475	0.2900	0.3025	0.1860	0.3640
-0.1449	0.1359	0.5503	0.3147	0.5163	0.3782
-0.0872	0.1243	0.8107	0.3269	0.8467	0.3923
-0.0296	0.1127	1.0710	0.3391	1.1770	0.4065
0.0281	0.1010	1.3314	0.3513	1.5074	0.4206
-0.2483	0.1823	0.0361	0.3356	-0.1092	0.3931
-0.1906	0.1707	0.2964	0.3478	0.2212	0.4073
-0.1330	0.1591	0.5568	0.3600	0.5515	0.4214
-0.0753	0.1475	0.8171	0.3722	0.8819	0.4356
-0.0177	0.1359	1.0775	0.3844	1.2122	0.4497
0.0400	0.1243	1.3378	0.3966	1.5426	0.4639
-0.2940	0.2171	-0.2179	0.3687	-0.4044	0.4222
-0.2363	0.2055	0.0425	0.3809	-0.0740	0.4364
-0.1787	0.1939	0.3029	0.3931	0.2564	0.4505
-0.1210	0.1823	0.5632	0.4053	0.5867	0.4647
-0.0634	0.1707	0.8236	0.4175	0.9171	0.4788
-0.0057	0.1591	1.0839	0.4297	1.2475	0.4930
-0.2821	0.2403	-0.2114	0.4140	-0.3691	0.4655
-0.2244	0.2287	0.0489	0.4262	-0.0388	0.4796
-0.1668	0.2171	0.3093	0.4384	0.2916	0.4938
-0.1091	0.2055	0.5697	0.4506	0.6219	0.5079
-0.0515	0.1939	0.8300	0.4628	0.9523	0.5221

0.0062	0.1823	1.0904	0.4750	1.2827	0.5362
-0.3278	0.2751	-0.4653	0.4471	-0.6643	0.4946
-0.2701	0.2635	-0.2050	0.4593	-0.3339	0.5087
-0.2125	0.2519	0.0554	0.4715	-0.0036	0.5229
-0.1548	0.2403	0.3157	0.4837	0.3268	0.5370
-0.0972	0.2287	0.5761	0.4959	0.6572	0.5512
-0.0395	0.2171	0.8365	0.5081	0.9875	0.5653
-0.3159	0.2983	-0.4589	0.4924	-0.6291	0.5378
-0.2582	0.2867	-0.1985	0.5046	-0.2987	0.5520
-0.2006	0.2751	0.0618	0.5168	0.0316	0.5661
-0.1429	0.2635	0.3222	0.5290	0.3620	0.5803
-0.0852	0.2519	0.5826	0.5412	0.6924	0.5944
-0.0276	0.2403	0.8429	0.5534	1.0227	0.6086

Columns 13 through 18

0.1554	0.0518	-0.2085	0.2219	0.2308	0.5383
0.4935	0.0784	-0.1243	0.2405	0.2498	0.5530
0.8317	0.1049	-0.0400	0.2591	0.2689	0.5676
1.1698	0.1315	0.0442	0.2777	0.2880	0.5823
1.5080	0.1581	0.1284	0.2963	0.3070	0.5969
1.8461	0.1846	0.2126	0.3148	0.3261	0.6116
0.1891	0.0686	-0.1797	0.2672	0.2745	0.5916
0.5273	0.0952	-0.0955	0.2858	0.2935	0.6062
0.8654	0.1217	-0.0113	0.3044	0.3126	0.6209
1.2036	0.1483	0.0729	0.3230	0.3316	0.6355
1.5418	0.1749	0.1571	0.3416	0.3507	0.6502
1.8799	0.2014	0.2413	0.3602	0.3697	0.6649
-0.1152	0.0589	-0.2352	0.2940	0.2991	0.6302
0.2229	0.0854	-0.1510	0.3125	0.3181	0.6448
0.5611	0.1120	-0.0668	0.3311	0.3372	0.6595
0.8992	0.1385	0.0174	0.3497	0.3562	0.6741
1.2374	0.1651	0.1016	0.3683	0.3753	0.6888

1.5755	0.1916	0.1858	0.3869	0.3943	0.7035
-0.0814	0.0756	-0.2065	0.3393	0.3427	0.6834
0.2567	0.1022	-0.1223	0.3579	0.3618	0.6981
0.5949	0.1288	-0.0381	0.3765	0.3808	0.7127
0.9330	0.1553	0.0461	0.3950	0.3999	0.7274
1.2712	0.1819	0.1303	0.4136	0.4189	0.7421
1.6093	0.2084	0.2145	0.4322	0.4380	0.7567
-0.3858	0.0659	-0.2620	0.3660	0.3673	0.7220
-0.0477	0.0924	-0.1778	0.3846	0.3864	0.7367
0.2905	0.1190	-0.0936	0.4032	0.4054	0.7513
0.6286	0.1456	-0.0094	0.4218	0.4245	0.7660
0.9668	0.1721	0.0748	0.4404	0.4436	0.7806
1.3050	0.1987	0.1590	0.4589	0.4626	0.7953
-0.3520	0.0827	-0.2333	0.4113	0.4110	0.7753
-0.0139	0.1092	-0.1491	0.4299	0.4301	0.7899
0.3243	0.1358	-0.0649	0.4485	0.4491	0.8046
0.6624	0.1623	0.0193	0.4671	0.4682	0.8192
1.0006	0.1889	0.1036	0.4857	0.4872	0.8339
1.3387	0.2155	0.1878	0.5043	0.5063	0.8486

Columns 19 through 24

0.0518	-0.2602	0.9147	1.0594	1.2049	1.1798
0.0784	-0.2025	0.8102	0.9215	1.0878	1.0410
0.1049	-0.1449	0.7057	0.7837	0.9708	0.9021
0.1315	-0.0872	0.6012	0.6458	0.8537	0.7633
0.1581	-0.0296	0.4967	0.5079	0.7367	0.6245
0.1846	0.0281	0.3922	0.3700	0.6197	0.4857
0.0686	-0.2483	0.6857	0.7727	0.9415	0.8936
0.0952	-0.1906	0.5812	0.6348	0.8245	0.7548
0.1217	-0.1330	0.4767	0.4969	0.7074	0.6160
0.1483	-0.0753	0.3722	0.3590	0.5904	0.4771
0.1749	-0.0177	0.2677	0.2212	0.4734	0.3383

0.2014	0.0400	0.1632	0.0833	0.3563	0.1995
0.0589	-0.2940	0.5612	0.6238	0.7952	0.7462
0.0854	-0.2363	0.4567	0.4859	0.6782	0.6074
0.1120	-0.1787	0.3522	0.3480	0.5611	0.4686
0.1385	-0.1210	0.2477	0.2102	0.4441	0.3298
0.1651	-0.0634	0.1432	0.0723	0.3270	0.1910
0.1916	-0.0057	0.0387	-0.0656	0.2100	0.0521
0.0756	-0.2821	0.3322	0.3370	0.5319	0.4601
0.1022	-0.2244	0.2277	0.1992	0.4148	0.3212
0.1288	-0.1668	0.1232	0.0613	0.2978	0.1824
0.1553	-0.1091	0.0187	-0.0766	0.1807	0.0436
0.1819	-0.0515	-0.0858	-0.2145	0.0637	-0.0952
0.2084	0.0062	-0.1903	-0.3524	-0.0533	-0.2340
0.0659	-0.3278	0.2077	0.1882	0.3855	0.3127
0.0924	-0.2701	0.1032	0.0503	0.2685	0.1739
0.1190	-0.2125	-0.0013	-0.0876	0.1515	0.0351
0.1456	-0.1548	-0.1058	-0.2255	0.0344	-0.1038
0.1721	-0.0972	-0.2103	-0.3634	-0.0826	-0.2426
0.1987	-0.0395	-0.3148	-0.5012	-0.1997	-0.3814
0.0827	-0.3159	-0.0213	-0.0986	0.1222	0.0265
0.1092	-0.2582	-0.1258	-0.2365	0.0052	-0.1123
0.1358	-0.2006	-0.2303	-0.3744	-0.1119	-0.2511
0.1623	-0.1429	-0.3348	-0.5122	-0.2289	-0.3899
0.1889	-0.0852	-0.4393	-0.6501	-0.3460	-0.5287
0.2155	-0.0276	-0.5438	-0.7880	-0.4630	-0.6676

Columns 25 through 30

1.2147	1.0435	-0.0265	-0.3202	0.1850	0.6152
1.0781	1.0114	-0.0307	-0.3233	0.1814	0.5715
0.9415	0.9793	-0.0349	-0.3263	0.1777	0.5277
0.8049	0.9472	-0.0391	-0.3294	0.1740	0.4839
0.6684	0.9151	-0.0433	-0.3324	0.1703	0.4402

0.5318	0.8830	-0.0475	-0.3355	0.1666	0.3964
0.9286	1.0993	-0.0245	-0.3166	0.1985	0.6873
0.7920	1.0672	-0.0287	-0.3196	0.1948	0.6436
0.6555	1.0352	-0.0329	-0.3227	0.1911	0.5998
0.5189	1.0031	-0.0371	-0.3258	0.1874	0.5561
0.3823	0.9710	-0.0413	-0.3288	0.1837	0.5123
0.2457	0.9389	-0.0455	-0.3319	0.1800	0.4685
0.7791	1.1873	-0.0183	-0.3099	0.2155	0.8032
0.6425	1.1552	-0.0225	-0.3130	0.2119	0.7595
0.5060	1.1231	-0.0267	-0.3160	0.2082	0.7157
0.3694	1.0910	-0.0309	-0.3191	0.2045	0.6719
0.2328	1.0589	-0.0351	-0.3221	0.2008	0.6282
0.0962	1.0268	-0.0393	-0.3252	0.1971	0.5844
0.4931	1.2431	-0.0163	-0.3063	0.2290	0.8753
0.3565	1.2110	-0.0205	-0.3093	0.2253	0.8316
0.2199	1.1789	-0.0247	-0.3124	0.2216	0.7878
0.0833	1.1468	-0.0289	-0.3155	0.2179	0.7441
-0.0533	1.1147	-0.0331	-0.3185	0.2142	0.7003
-0.1898	1.0826	-0.0373	-0.3216	0.2106	0.6565
0.3436	1.3310	-0.0101	-0.2996	0.2461	0.9912
0.2070	1.2989	-0.0143	-0.3027	0.2424	0.9474
0.0704	1.2668	-0.0185	-0.3057	0.2387	0.9037
-0.0662	1.2347	-0.0227	-0.3088	0.2350	0.8599
-0.2027	1.2026	-0.0269	-0.3118	0.2313	0.8162
-0.3393	1.1706	-0.0311	-0.3149	0.2277	0.7724
0.0575	1.3869	-0.0081	-0.2960	0.2595	1.0633
-0.0791	1.3548	-0.0123	-0.2990	0.2558	1.0196
-0.2157	1.3227	-0.0165	-0.3021	0.2521	0.9758
-0.3522	1.2906	-0.0207	-0.3052	0.2484	0.9320
-0.4888	1.2585	-0.0249	-0.3082	0.2447	0.8883
-0.6254	1.2264	-0.0291	-0.3113	0.2411	0.8445

Columns 31 through 36

-0.8499	0.1544	1.2049	1.6163	0.1718	1.0967
-0.8610	0.1431	1.0878	1.4793	0.1647	1.0473
-0.8721	0.1318	0.9708	1.3423	0.1577	0.9979
-0.8833	0.1206	0.8537	1.2053	0.1506	0.9484
-0.8944	0.1093	0.7367	1.0684	0.1435	0.8990
-0.9055	0.0980	0.6197	0.9314	0.1365	0.8496
-0.8306	0.1630	0.9415	1.3644	0.1772	1.1680
-0.8417	0.1518	0.8245	1.2274	0.1702	1.1186
-0.8528	0.1405	0.7074	1.0904	0.1631	1.0691
-0.8640	0.1293	0.5904	0.9534	0.1561	1.0197
-0.8751	0.1180	0.4734	0.8165	0.1490	0.9703
-0.8862	0.1067	0.3563	0.6795	0.1419	0.9208
-0.8002	0.1830	0.7952	1.2495	0.1898	1.2887
-0.8113	0.1717	0.6782	1.1125	0.1827	1.2393
-0.8224	0.1605	0.5611	0.9755	0.1756	1.1899
-0.8336	0.1492	0.4441	0.8385	0.1686	1.1404
-0.8447	0.1379	0.3270	0.7015	0.1615	1.0910
-0.8558	0.1267	0.2100	0.5645	0.1544	1.0416
-0.7809	0.1917	0.5319	0.9976	0.1952	1.3600
-0.7920	0.1804	0.4148	0.8606	0.1882	1.3106
-0.8032	0.1691	0.2978	0.7236	0.1811	1.2611
-0.8143	0.1579	0.1807	0.5866	0.1740	1.2117
-0.8254	0.1466	0.0637	0.4496	0.1670	1.1623
-0.8365	0.1353	-0.0533	0.3126	0.1599	1.1128
-0.7505	0.2116	0.3855	0.8827	0.2077	1.4807
-0.7616	0.2003	0.2685	0.7457	0.2007	1.4313
-0.7727	0.1891	0.1515	0.6087	0.1936	1.3819
-0.7839	0.1778	0.0344	0.4717	0.1865	1.3324
-0.7950	0.1666	-0.0826	0.3347	0.1795	1.2830
-0.8061	0.1553	-0.1997	0.1977	0.1724	1.2336
-0.7312	0.2203	0.1222	0.6308	0.2132	1.5520

-0.7423	0.2090	0.0052	0.4938	0.2061	1.5026
-0.7535	0.1978	-0.1119	0.3568	0.1991	1.4532
-0.7646	0.1865	-0.2289	0.2198	0.1920	1.4037
-0.7757	0.1752	-0.3460	0.0828	0.1849	1.3543
-0.7868	0.1640	-0.4630	-0.0542	0.1779	1.3049

Column 37

1.0820
1.0059
0.9299
0.8538
0.7778
0.7017
1.2289
1.1529
1.0768
1.0008
0.9247
0.8487
1.4519
1.3759
1.2998
1.2238
1.1477
1.0717
1.5989
1.5228
1.4468
1.3707
1.2947
1.2187
1.8219

1.7458

1.6698

1.5937

1.5177

1.4417

1.9688

1.8928

1.8167

1.7407

1.6647

1.5886

Ek 3: SOM Çıktı Izgara Yapılarının Kümeleme Performansı

Araç No	SMTS Arıza Teşhisi	6x6 Hücreler	6x6 Hatalı Kümeleme	5x5 Hücreler	5x5 Hatalı Kümeleme	4x4 Hücreler	4x4 Hatalı Kümeleme	7x7 Hücreler
1	MOTOR ÇALIŞMA	20		6	x	6		11
2	FRENLER	27		6	x	11		48
3	MOTOR ÇALIŞMA	20		6	x	6		11
4	MOTOR ÇALIŞMA	20		6	x	6		11
5	FRENLER	27		6	x	11		48
6	VİTES KUTUSU/KAVRAMA/AKS	20	x	6		6	x	11
7	FRENLER	27		6	x	11		40
8	DİREKSİYON	23		6	x	6	x	10
9	VİTES KUTUSU/KAVRAMA/AKS	20	x	6		6	x	11
10	SÜSPANSİYON/SÜRÜŞ	20	x	6	x	6	x	10
11	AKÜ ŞARJ	16		6	x	6	x	32
12	AKÜ ŞARJ	16		6	x	6	x	32
13	FRENLER	27		6	x	11		48
14	FRENLER	27		6	x	11		48
15	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
16	MOTOR/SOĞUTMA/YAĞLAMA	19		6	x	6	x	34
17	MOTOR ÇALIŞMA	19	x	6	x	6		27
18	MOTOR/SOĞUTMA/YAĞLAMA	19		6	x	6	x	34
19	MOTOR ÇALIŞMA	20		6	x	6		11
20	FRENLER	27		6	x	11		48
21	MOTOR ÇALIŞMA	20		6	x	6		11
22	DİREKSİYON	23		6	x	6	x	10
23	MOTOR ÇALIŞMA	20		6	x	6		11
24	AKÜ ŞARJ	16		6	x	6	x	32
25	FRENLER	27		6	x	11		48
26	VİTES KUTUSU/KAVRAMA/AKS	20	x	6		6	x	11
27	DİREKSİYON	23		6	x	6	x	10
28	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
29	MOTOR ÇALIŞMA	12		22		6		19
30	DİREKSİYON	23		6	x	6	x	10
31	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
32	FRENLER	33		24		11		21
33	MOTOR ÇALIŞMA	18		6	x	6		25
34	FRENLER	33		24		11		21
35	AKÜ ŞARJ	17		6	x	6	x	3
36	FRENLER	33		24		11		21
37	FRENLER	33		24		11		21
38	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
39	MOTOR ÇALIŞMA	12		22		6		19
40	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
41	MOTOR ÇALIŞMA	12		22		6		24
42	FRENLER	32		24		11		20
43	VİTES KUTUSU/KAVRAMA/AKS	20	x	6		6	x	11
44	AKÜ ŞARJ	28	x	6		6	x	18
45	AKÜ ŞARJ	17		6	x	6	x	3

46	FRENLER	32		24		11		20
47	MOTOR/SOĞUTMA/YAĞLAMA	35	x	20		16		26
48	AKÜ ŞARJ	17		6	x	6	x	3
49	AKÜ ŞARJ	17		6	x	6	x	3
50	AKÜ ŞARJ	17		6	x	6	x	3
51	YAKIT SİSTEMİ	21		6	x	6	x	15
52	YAKIT SİSTEMİ	21		6	x	6	x	15
53	MOTOR ÇALIŞMA	12		22		6		5
54	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
55	FRENLER	33		6	x	11		28
56	FRENLER	33		24		11		21
57	MOTOR ÇALIŞMA	12		22		6		19
58	MOTOR ÇALIŞMA	12		22		6		19
59	MOTOR ÇALIŞMA	18		6	x	6		25
60	FRENLER	33		24		11		21
61	MOTOR/SOĞUTMA/YAĞLAMA	35	x	20		16		26
62	MOTOR/SOĞUTMA/YAĞLAMA	35	x	20		16		26
63	DİREKSİYON	24		21		6	x	4
64	MOTOR ÇALIŞMA	12		22		6		19
65	DİREKSİYON	24		21		12	x	31
66	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
67	FRENLER	33		24		11		21
68	MOTOR ÇALIŞMA	12		22		6		24
69	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
70	AKÜ ŞARJ	4		25		15		36
71	MOTOR/SOĞUTMA/YAĞLAMA	35	x	20		16		26
72	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	18
73	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
74	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
75	DİREKSİYON	24		21		12	x	31
76	FRENLER	31		11		5		12
77	MOTOR ÇALIŞMA	12		22		6		19
78	AKÜ ŞARJ	4		25		15		36
79	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
80	MOTOR ÇALIŞMA	1		2		8		8
81	MOTOR ÇALIŞMA	1		2		8		8
82	FRENLER	31		12		13		12
83	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	17
84	MOTOR ÇALIŞMA	1		2		8		8
85	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	17
86	MOTOR ÇALIŞMA	1		2		8		8
87	FRENLER	31		12		13		12
88	MOTOR ÇALIŞMA	1		2		8		8
89	VİTES KUTUSU/KAVRAMA/AKS	28		6		6	x	17
90	FRENLER	31		12		13		12
91	MOTOR ÇALIŞMA	1		2		8		8
92	AKÜ ŞARJ	4		23		15		36
93	DİREKSİYON	24		21		12	x	31
94	MOTOR ÇALIŞMA	1		2		3		8
95	MOTOR ÇALIŞMA	1		2		8		8
96	AKÜ ŞARJ	5		23		15		43
97	SÜSPANSİYON/SÜRÜŞ	35		17		12		16
98	MOTOR ÇALIŞMA	1		2		8		8
99	FRENLER	31		12		13		12
100	FRENLER	31		12		13		12

101	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
102	MOTOR ÇALIŞMA	1		2		8		8
103	FRENLER	31		12		13		12
104	MOTOR ÇALIŞMA	1		2		8		8
105	MOTOR ÇALIŞMA	1		2		8		8
106	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
107	AKÜ ŞARJ	5		23		15		43
108	AKÜ ŞARJ	5		23		15		43
109	MOTOR ÇALIŞMA	1		2		7		9
110	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
111	MOTOR ÇALIŞMA	1		2		8		8
112	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
113	MOTOR ÇALIŞMA	1		2		8		8
114	FRENLER	31		12		13		12
115	FRENLER	31		12		13		12
116	AKÜ ŞARJ	5		23		15		43
117	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
118	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
119	FRENLER	31		11		5		12
120	MOTOR ÇALIŞMA	1		2		8		8
121	MOTOR ÇALIŞMA	1		2		7		9
122	MOTOR ÇALIŞMA	1		2		7		9
123	MOTOR ÇALIŞMA	1		2		7		9
124	MOTOR ÇALIŞMA	1		2		4		2
125	MOTOR ÇALIŞMA	1		2		4		2
126	MOTOR ÇALIŞMA	1		2		3		8
127	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
128	VİTES KUTUSU/KAVRAMA/AKS	36		8		14		39
129	VİTES KUTUSU/KAVRAMA/AKS	36		7		14		45
130	MOTOR ÇALIŞMA	8		5		2		1
131	VİTES KUTUSU/KAVRAMA/AKS	36		3		10		38
132	MOTOR ÇALIŞMA	8		5		2		1
133	MOTOR ÇALIŞMA	8		5		2		1
134	MOTOR ÇALIŞMA	8		4		2		1
135	MOTOR ÇALIŞMA	8		5		2		1
136	MOTOR ÇALIŞMA	8		5		2		1
137	VİTES KUTUSU/KAVRAMA/AKS	36		3		10		38
138	MOTOR ÇALIŞMA	8		5		2		1
139	MOTOR ÇALIŞMA	13		1		1		13
140	MOTOR ÇALIŞMA	13		1		1		13
141	MOTOR ÇALIŞMA	13		1		1		13

Ek 4 Müşteri Şikayet Matrisi cildin arka kapağındaki CD’ de sunulmuştur.

ÖZGEÇMİŞ

1979 yılında Kocaeli' nde doğdu. İlk öğrenimini Kocaeli' nin Kandıra ilçesinde, orta ve lise öğrenimini ise Ankara' da tamamladı. 1995 yılında girdiği Gazi Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü' nden 2000 yılında Endüstri Mühendisi olarak mezun oldu. 2002-2003 yılları arasında, Amerika Birleşik Devletleri, Delaware Eyaleti, Goldey-Beacom College İş Yönetimi Anabilim Dalı' nda Yüksek Lisans Öğrenimini tamamladı. 2004-2009 yılları arasında Ford Otosan Gölcük fabrikasında mühendis olarak çalıştı. 2009-2010 yılları arasında askerliğini tamamladı. 2011 yılından itibaren Minipay Interactive' in kurucu ortağı olarak çalışmaktadır.