

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞI VE BULANIK MANTIK TABANLI
ALGORİTMALAR İLE UÇUCU ORGANİK BİLEŞİKLERİN
MİKTARSAL TAYİNİ**

DOKTORA TEZİ

Elektronik Yük. Müh. Ali GÜLBAĞ

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK

Tez Danışmanı : Yrd. Doç. Dr. Fevzullah TEMURTAŞ

Temmuz 2006

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞI VE BULANIK MANTIK TABANLI
ALGORİTMALAR İLE UÇUCU ORGANİK BİLEŞİKLERİN
MİKTARSAL TAYİNİ**

DOKTORA TEZİ

Elektronik Yük. Müh. Ali GÜLBAĞ

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK MÜH.

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 07 / 07 / 2006 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

Prof.Dr. Etem KÖKLÜKAYA
Jüri Başkanı

Doç.Dr. Bekir ÇAKIR
Jüri Üyesi

Doç.Dr. Nejat YUMUŞAK
Jüri Üyesi

Yrd.Doç.Dr. Fevzullah TEMURTAŞ
Jüri Üyesi

Yrd.Doç.Dr. Mehmet Zeki BİLGİN
Jüri Üyesi

TEŞEKKÜR

Tezimin hazırlık aşamasında bana en büyük desteği ve yardımı sağlayan danışman hocam Yrd.Doç.Dr. Fevzullah Temurtaş'a, akademik rehberlikleri, destek ve önerileri için doktora tez izleme komitemde de yer alan Prof.Dr. Etem Köklükaya'ya ve Doç.Dr. Nejat Yumuşak'a, ayrıca Doç.Dr. İsmihan Yusubov'a ve Arş.Gör. Uğur Erkin Kocamaz'a teşekkür ederim.

Tezde kullandığım sensörlerin hazırlanmasında, ölçüm sisteminin kullanılmasında desteklerini gördüğüm, TÜBİTAK Marmara Araştırma Merkezi Malzeme Enstitüsü Sensör Test Laboratuvarı'ndan Prof.Dr. Z. Ziya Öztürk'e, Araştırmacı Cihat Taşaltın'a ve değerli çalışanlarına teşekkür ederim.

Bu tez çalışması, Sakarya Üniversitesi Bilimsel Araştırma Projeleri Komisyonu Başkanlığı tarafından 06-FBD-007 proje numarasıyla desteklenmiştir. Bu desteklerinden dolayı teşekkür ederim.

Ayrıca tüm eğitim hayatım boyunca beni teşvik eden, maddi ve manevi her türlü yardımı sağlayan aileme teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ	vii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xiii
ÖZET	xiv
SUMMARY	xv

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

YAPAY ZEKA	12
2.1. Yapay Sinir Ağları (YSA)	13
2.1.1. Yapay sinir ağlarının tarihçesi	14
2.1.2. Biyolojik sinir hücreleri ve YSA	16
2.1.3. Aktivasyon fonksiyonları	18
2.1.4. YSA'nın temel özellikleri	19
2.1.5. Yapay sinir ağı modelleri	20
2.1.6. Çok katmanlı ağlar	22
2.1.6.1. Çok katmanlı ağı eğitilmesi	24

2.1.6.2. Çok katmanlı ağın çalışma prosedürü	27
2.1.7. Radyal tabanlı yapay sinir ağları	28
2.1.8. Olasılıksal yapay sinir ağları (PNN)	30
2.1.9. Sezgisel ve ileri seviyeli eğitim algoritmalar	31
2.1.9.1. Adaptif öğrenme katsayısı	31
2.1.9.2. Newton metodu	32
2.1.9.3. Gauss-Newton metodu	33
2.1.9.4. Levenberg-Marquardt algoritması	35
2.1.9.5. Esnek yayılım algoritması	37
2.1.9.6. Eşleştirmeli eğitim algoritmaları	38
2.2. Bulanık Mantık	42
2.2.1. Üyelik fonksiyonu ve türleri	43
2.2.2. Bulanık kümelerde işlemler	46
2.2.3. Bulanık mantığa dayalı sistemlerin temel yapısı	46
2.2.3.1. Bulanıklaştırma	47
2.2.3.2. Bulanık mantık kural tabanı	47
2.2.3.3. Bulanık mantık çıkarım yöntemleri	48
2.2.3.4. Berraklaştırma	51
2.2.4. Uyarlamalı sinirsel bulanık çıkarım sistemleri (ANFIS)	51
 BÖLÜM 3.	
PİEZOELEKTRİK KRİSTAL SENSÖRLER VE KAPLAMA YÖNTEMLERİ ...	55
3.1. Kuartz Kristal Rezonatörün Kütle Duyarlılığı ve Gaz Sensörü Olarak Kullanımı	58
3.2. Kaplama Yöntemleri	64
3.2.1. LB kaplama metodu	64

3.2.2. Smearing metodu	65
3.2.3. Jetsprey (Airbrush) metodu	66
 BÖLÜM 4.	
ÖLÇÜM SİSTEMİ VE SENSÖR DİZİSİ	68
4.1. Sensör Dizisi	68
4.2. Algılayıcı Kimyasal Kaplama Malzemesi	69
4.3. Ölçüm Düzeneği	71
 BÖLÜM 5.	
UYGULAMA VE SONUÇLAR	77
5.1. ANFIS Yapısı Kullanılarak Keton-Klorlu Bileşik Gaz Karışımının Miktarsal Tayini	78
5.2. Genel Ağ Topolojisini Belirlemek için Keton-Klorlu Bileşik Gaz Karışımı Uygulaması	82
5.3. Keton-Klorlu Bileşik Gaz Karışımı için Sezgisel ve İleri Seviyeli Algoritmaların Performanslarının Karşılaştırılması	94
5.4. Alifatik ve Aromatik Gaz Karışımı için Radyal Temelli Yapay Sinir Ağı Uygulaması	100
5.5. Keton-Klorlu Bileşik Gaz Karışımı için Zaman Gecikmeli (Tapped Time Delay) YSA Uygulaması	107
5.6. Keton-Klorlu Bileşik Gaz Karışımı için Sensör Cevaplarının Eğim Bilgisinin Kullanıldığı YSA Uygulaması	113
5.7. Yedi Farklı İkili Gaz Karışımının Niteliksel ve Niceliksel Olarak Sınıflandırılması	119

BÖLÜM 6.

TARTIŞMA VE ÖNERİLER	123
KAYNAKLAR	131
EKLER	136
ÖZGEÇMİŞ	149

SİMGELER VE KISALTMALAR LİSTESİ

ANFIS	: Uyarlamalı sinirsel bulanık çıkarım sistemleri
ART	: Adaptif rezonans teorisi
BÇS	: Bulanık çıkarım sistemleri
CG	: Conjugate-Gradient
$E(W,n)$	: Toplam karesel hata
FET	: Alan etkili transduser
GA	: Genetik algoritma
GRNN	: Genel regresyon ağları
IDT	: Interdigital transducer
$J(W)$	: Ortalama karesel hata
LB	: Langmuir Blodget
LM	: Levenberg-Marquardt
LVQ	: Learning vector quantization
Max	: Maksimum
Min	: Minimum
MLP	: Çok katmanlı algılayıcılar
MOS	: Metal-yalıtkan-yarıiletken yapı
MOSFET	: Metal oksit yarıiletken alan etkili transistör
PDF	: İstatistiksel yoğunluk fonksiyonu
PNN	: Olasılıksal yapay sinir ağları
ppm	: Parts per million
QCM	: Kuartz kristal mikrobals
QCR	: Kuartz kristal rezonatör
QN	:Quasi-Newton
RBF	: Radial basis function
RBNN	: Radyal tabanlı yapay sinir ağları

RP	: Esnek yayılım (Resilient Propagation)
SAW	: Surface acoustic wave
SBK	: Sinirsel bulanık kombinasyonlar
SiO ₂	: Kuartz
SOM	: Kendi kendine öğrenme nitelik haritaları (Self organizing map)
TSM	: Kalınlık makaslama modu (Thickness Shear Mode)
YSA	: Yapay sinir ağları
μ	: Üyelik derecesi
α	: Momentum katsayısı
Δf	: Frekans kayması
η	: Öğrenme katsayısı
σ	: Standart sapma

ŞEKİLLER LİSTESİ

Şekil 2.1. Bir nöronun YSA modeli	13
Şekil 2.2. Biyolojik sinir hücresinin yapısı	17
Şekil 2.3. Yapay sinir modeli	17
Şekil 2.4. Lineer aktivasyon fonksiyonu	18
Şekil 2.5. Sigmoid aktivasyon fonksiyonu	18
Şekil 2.6. Tan-sigmoid aktivasyon fonksiyonu	19
Şekil 2.7. Çok katmanlı ağ yapısı	23
Şekil 2.8. Üç katmanlı yapay sinir ağı	24
Şekil 2.9. Radyal tabanlı ağın, gizli katman işlem elemanının yapısı	29
Şekil 2.10. Üçgen üyelik fonksiyonu	44
Şekil 2.11. Trapez üyelik fonksiyonu	44
Şekil 2.12. Çan biçimli üyelik fonksiyonu	45
Şekil 2.13. Ortamın sıcaklığını gösteren üyelik fonksiyonları	46
Şekil 2.14. Bulanık küme tabanlı bir sistemin genel yapısı	46
Şekil 2.15. Mamdani bulanık çıkarım yöntemi	49
Şekil 2.16. Sugeno bulanık çıkarım yöntemi	50
Şekil 2.17. ANFIS mimarisi	52
Şekil 3.1. Kuartz kristal rezonatörün yapısı	55
Şekil 3.2. Rezonans durumunda bulunan TSM rezonatörün eşdeğer elektrik devresi	57
Şekil 3.3a. LB metodu için tasarlanan molekülün şematik gösterimi	65

Şekil 3.3b. Moleküllerin su yüzeyinde dizilişinin şematik gösterimi	65
Şekil 3.4. Smearing kaplama sisteminin şematik gösterimi	66
Şekil 3.5. Jetsprey kaplama sistemi	67
Şekil 4.1. Sensör dizisi	69
Şekil 4.2. Ölçüm düzeneği	71
Şekil 4.3. Sensör dizisinin asetona verdiği tepki	74
Şekil 4.4. Sensör dizisinin trikloretilene verdiği tepki	74
Şekil 4.5. Sensör dizisinin benzene verdiği tepki	75
Şekil 4.6. Sensör dizisinin hekzana verdiği tepki	75
Şekil 4.7. Sensör dizisinin metanole verdiği tepki	76
Şekil 5.1. Üyelik fonksiyonu sayısı 3 olması durumunda Zaman-MSE ilişkisi: (a) ANFIS1 için (Trikloretilen), (b) ANFIS2 için (Aseton)	78
Şekil 5.2. Aseton için 4 üyelik fonksiyonu ve 4 sensör verisi kullanıldığı durumdaki eğitim grafiği	79
Şekil 5.3. Aseton için 5 üyelik fonksiyonu ve 4 sensör verisi kullanıldığı durumdaki eğitim grafiği	80
Şekil 5.4. Aseton için 6 üyelik fonksiyonu ve 3 sensör verisi kullanıldığı durumdaki eğitim grafiği	80
Şekil 5.5. Aseton için 7 üyelik fonksiyonu ve 3 sensör verisi kullanıldığı durumdaki eğitim grafiği	81
Şekil 5.6. Sensörlerin, trikloretilenin sabit (1000 ppm), asetonun değişen (0, 1000, 2000, 3000, 4000, 5000 ppm) konsantrasyon değerleri için oluşturulan gaz karışımına verdiği tepkiler: (a) Sensör1 için, (b) Sensör2 için, (c) Sensör3 için, (d) Sensör4 için, (e) Sensör5 için	83
Şekil 5.7. Sensörlerin trikloretilen-aseton gaz karımına olan duyarlılıkları: (a) Sensör1'in duyarlılığı, (b) Sensör2'nin duyarlılığı, (c) Sensör3'ün duyarlılığı, (d) Sensör 4'ün duyarlılığı, (e) Sensör 5'in duyarlılığı	84

Şekil 5.8. Trikloretillen-aseton gaz karışımı için kullanılan çok katmanlı ağ yapısı	85
Şekil 5.9. Birinci başlangıç şartı için MSE-Zaman grafiği	91
Şekil 5.10. İkinci başlangıç şartı için MSE-Zaman grafiği	92
Şekil 5.11. Üçüncü başlangıç şartı için MSE-Zaman grafiği	92
Şekil 5.12. Dördüncü başlangıç şartı için MSE-Zaman grafiği	93
Şekil 5.13. Beşinci başlangıç şartı için MSE-Zaman grafiği	93
Şekil 5.14. Değişik eğitim algoritmalarının performanslarının değerlendirilmesinde kullanılan ağ yapısı	94
Şekil 5.15. Standart geri yayılım algoritması için eğitim ve test setinin MSE-Zaman grafiği	95
Şekil 5.16. Esnek yayılım algoritması için eğitim ve test setinin MSE-Zaman grafiği	95
Şekil 5.17. Conjugate-gradient algoritması için eğitim ve test setinin MSE-Zaman grafiği	96
Şekil 5.18. Quasi-Newton algoritması için eğitim ve test setinin MSE-Zaman grafiği	97
Şekil 5.19. Levenberg-Marquardt algoritması için eğitim ve test setinin MSE-Zaman grafiği	98
Şekil 5.20. Sensörlerin, benzenin sabit (3000 ppm), n-hekzanın değişen (0, 1000, 2000, 3000, 4000, 5000 ppm) konsantrasyon değerleri için oluşturulan gaz karışımına verdiği tepkiler: (a) Sensör1 için, (b) Sensör2 için, (c) Sensör3 için, (d) Sensör4 için, (e) Sensör5 için	101
Şekil 5.21. Sensörlerin benzen-n-hekzan gaz karımına olan duyarlılıkları: (a) Sensör1'in duyarlılığı, (b) Sensör2'nin duyarlılığı, (c) Sensör3'ün duyarlılığı, (d) Sensör4'ün duyarlılığı, (e) Sensör5'in duyarlılığı	102
Şekil 5.22. Radyal temelli ağın yapısı	103

Şekil 5.23. Eğitim ve test setinin MSE-Zaman grafiği	103
Şekil 5.24. Azaltılmış eğitim seti için eğitim ve test setinin MSE-Zaman grafiği ...	104
Şekil 5.25. Levenberg-Marquardt algoritması için MSE-Zaman grafiği	105
Şekil 5.26. Standart geri yalınım algoritması için MSE-Zaman grafiği	105
Şekil 5.27. Zaman gecikmeli ağ yapısı	108
Şekil 5.28. 10 nörona sahip gizli katman için eğitim performansı	109
Şekil 5.29. 30 nörona sahip gizli katman için eğitim performansı	109
Şekil 5.30. 50 nörona sahip gizli katman için eğitim performansı	110
Şekil 5.31. 7 tane geciktirilmiş giriş seti için eğitim performansı	111
Şekil 5.32. Eğitim ve test setinin MSE-Zaman grafiği	111
Şekil 5.33. Sensör cevabının ve eğiminin kullanıldığı yapay sinir ağı modeli	114
Şekil 5.34. Trikloretillen sabit 1000 ppm, aseton 0, 1000, 2000, 3000, 4000, 5000 ppm gaz karışımına Sensör4'ün verdiği cevaplar: (a) ölçüm verisi, (b) temizleme fazı çıkartılmış veri, (c) orijine indirgenmiş veri, (d) indirgenmiş veri ve eğim bilgisi	115
Şekil 5.35. Eğitim ve test seti için MSE'nin zamanla değişimi	116
Şekil 5.36. Performans analizi için sensör cevabının bölgelere ayrılması	117
Şekil 5.37. Gaz karışımlarını ayırt eden sistemin arayüzü: (a) Hesapla butonuna basılmadan önce, (b) Hesapla butonuna basıldıktan sonra	122

TABLÖLER LİSTESİ

Tablo 4.1. Örnek analit maddeleri	72
Tablo 4.2. Örnek analitlerin Antonie katsayıları	73
Tablo 5.1. Değişik türdeki ANFIS yapılarının test seti için performans değerlendirmesi	81
Tablo 5.2. Birinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi	86
Tablo 5.3. İkinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi	87
Tablo 5.4. Üçüncü başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi	88
Tablo 5.5. Dördüncü başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi	89
Tablo 5.6. Beşinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi	90
Tablo 5.7. Eğitim algoritmalarının performans değerlendirme	98
Tablo 5.8. Gaz karışımı için gerçek ve tahmini değerler	99
Tablo 5.9. Değişik ağ yapılarının performans değerlendirme	106
Tablo 5.10. Zaman gecikmeli ağı performans değerlendirme	112
Tablo 5.11. Kullanılan yapay sinir ağlarının performans değerlendirme	118
Tablo 5.12. Gaz karışımları ve niteliksel sınıflama için karışım indeksleri	119
Tablo 5.13. Niceliksel sınıflandırmada kullanılan ağ yapıları ve gazların test performansları	121
Tablo 6.1. İleri beslemeli YSA yapıları ile ANFIS'in performans bakımından karşılaştırılması	124

ÖZET

Anahtar Kelimeler: Uçucu Organik Bileşikler, Yapay Sinir Ağları, Miktersal Tayin, Kuartz Kristal Sensör, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemleri, Olasılıksal Sinir Ağları.

Bazı uçucu organik bileşiklere belirli seviyelerin üzerinde maruz kalındığında insan sağlığı ve çevre açısından tehlike arz ettiği bilinmektedir. Bu uçucu organik bileşikler esasen aromatikler, alifatikler, ketonlar, klorlu bileşikler ve alkoller olarak gruplandırılmaktadır. Adı geçen grupları temsilen bu tezde aromatiklerden benzen, alifatiklerden hekzan, ketonlardan aseton, klorlu bileşiklerden trikloretilen ve alkollerden metanol seçilmiştir. Kuartz kristal sensörlerden oluşan bir sensör dizisi kullanılarak seçilen gazların değişik ikili karışımlarının konsantrasyona bağlı frekans cevapları ölçülmüştür. Bu sensörler, kuartz kristallerin yüzeyleri uçucu organik bileşiklere duyarlı olan ftalosiyanın ve oksim maddeleriyle kaplanarak hazırlanmıştır. Ölçümler sonucunda elde edilmiş frekans cevapları, farklı tipte yapay sinir ağları (YSA) ve uyarlamalı sinirsel bulanık çıkarım sistemleri (Adaptive Neuro Fuzzy Inference Systems-ANFIS) ile ikili gaz karışımlarının sınıflandırılması ve miktersal tayini için kullanılmıştır. Bu amaçla ölçümler sonucu elde edilen frekans cevapları geçici ve sürekli hal cevapları olarak gruplandırılmıştır. Geçici hal cevaplarının sınıflandırma ve miktersal tayin için kullanılmasında zaman gecikmeli YSA yapılarının yanı sıra, ayrıca cevapların eğim bilgisini de içeren ileri beslemeli YSA yapıları da uygulanmıştır. Sürekli hal cevapları kullanılarak gerçekleştirilen sınıflandırma ve miktersal tayin için ise ileri beslemeli YSA, radial temelli YSA ve ANFIS kullanılmıştır. YSA'ların eğitilmesinde geri yayılım ve sezgisel ve ileri seviyeli algoritmalar, ANFIS'in eğitilmesinde ise en küçük kareler yöntemi ve geri yayılım algoritması kullanılmıştır. Ayrıca, sürekli hal cevapları kullanılarak yedi farklı çeşit ikili gaz karışımının niteliksel sınıflandırılması olasılıksal sinir ağları (Probabilistic Neural Network-PNN) ve niceliksel sınıflandırılması ileri beslemeli ağlar yardımıyla gerçekleştirilmiştir. Sonuç olarak, tezde kullanılmış olan YSA tipleri ve ANFIS uygulamalarının gazların sınıflandırılması ve miktersal tayininde yüksek performans sergilediği gözlenmiştir.

QUANTITATIVE DETERMINATION OF VOLATILE ORGANIC COMPOUNDS BY USING ARTIFICIAL NEURAL NETWORK AND FUZZY LOGIC BASED ALGORITHM

SUMMARY

Keywords: Volatile Organic Compounds, Artificial Neural Networks, Quantitative Analysis, Quartz Crystal Sensor, Adaptive Neuro-Fuzzy Inference Systems, Probabilistic Neural Networks.

It's widely known that some volatile organic compounds (VOCs) exposed more than specific levels have harmful effects on human health and environment. Fundamentally, these VOCs are grouped as aromatics, aliphatics, ketones, chlorinated compounds and alcohols. In this thesis, for representation of expressed groups, benzene in aromatics, hexane in aliphatics, acetone in ketones, trichloroethylene in chlorinated compounds and methanol in alcohols were selected. The frequency responses versus concentration for the various mixtures of the selected gases were measured by using a sensor array composed of quartz crystal resonators (QCRs). These sensors were produced by coating their surfaces with phthalocyanines and oximes which were sensitive to the VOCs. Frequency responses that were obtained through measurements were used for classification and quantification of binary gas mixtures performing different kinds of artificial neural networks (ANNs) and adaptive neuro-fuzzy inference systems (ANFIS). For this purpose, frequency responses that were obtained through measurements were grouped as the steady state and transient responses. In the using of the transient responses for the classifications and quantifications, besides the time tapped delay ANN, the feed-forward ANN that also takes account of responses' slope data, were applied. And, in the performing of the steady state responses for the classifications and quantifications, the feed-forward ANN, radial based ANN and ANFIS were used. In the training of the ANNs, the back propagation and heuristic algorithms, and in the training of ANFIS, the least squares method and back propagation algorithm were performed. Furthermore, the qualitative classifications of seven different types of binary gas mixtures were realized by using probabilistic neural network (PNN) and feed-forward ANN with the steady state responses. Consequently, it was observed that ANN types and ANFIS applications used in this thesis have shown high performance for classification and quantification of gases.

BÖLÜM 1. GİRİŞ

Kimyasal sensörler, kimyasal bir girişı elektrikselse ya da optik sinyale çeviren aygıtlardır. İnsan sağılıının ve çevrenin korunması amacıyla bazı kimyasal maddelerin niceliklerinin algılanması ve sınıflandırılması için kimyasal sensör tasarımlarının yapılması, günümüzde devam etmekte olan ve disiplinler arası çalışma gerektiren önemli bir konudur. Özellikle bu çalışma kapsamında olan uçucu organik bileşiklere, belirli seviyelerin üzerinde uzun süre maruz kalındığında insan sağılığı açısından zararlı etkileri mevcuttur. Uçucu organik bileşiklerin kullanıldığı her alanda aynı etkiler söz konusudur. Çalışılan ortamda uçucu gazların konsantrasyonu kontrol altında tutulmalı, her zaman konsantrasyon değeri bilinmeli, konsantrasyon değeri insan sağılığını tehdit eden seviyelere ulaştığında gerekli ikazlar yapılmalı ve gereken önlemler alınmalıdır [1].

Uçucu organik bileşikler esasen aromatikler, alifatikler, ketonlar, klorlu bileşikler ve alkoller olarak gruplandırılmaktadır. Bu tez çalışmasında bu grupları temsilen, aromatikler grubundan benzen, alifatikler grubundan hekzan, ketonlar grubundan aseton, klorlu bileşikler grubundan trikloretilen ve alkoller grubundan metanol ele alınmıştır. Bu uçucu organik bileşiklerin bazı temel özellikleri, olumsuz etkileri ve eşik değeri aşağıda verilmiştir.

Benzen; plastik, reçine, naylon, boya, deterjan vb. yapımında kullanılan, suda az miktarda çözünen, kolayca buharlaşabilen, renksiz ve oldukça yanıcı bir bileşiktir. Ham petrolde, benzinde ve sigara dumanında doğal olarak bulunur. Ayrıca orman yangınları sonucunda da oluşur. Endüstride en çok kullanılan kimyasallar arasındadır. Su ve topraktan havaya geçebilir. Havadaki benzen ise yağmur ve karla tekrar toprağı düşer. Yüksek miktarlarda maruz kalındığında kalp atışlarında hızlanma, baş ağrısı, mide bulantısı, bilinç kaybı hatta ölüme sebebiyet verebilir. Uzun süre teneffüs edildiğinde kırmızı kan hücrelerinde azalma ve anemi görülür.

Bağıışıklık sistemini olumsuz etkiler. Kanserojen etkisinin olduđu söylenmiştir. Benzenin çalışma ortamında bulunabilecek maksimum miktarı 1 ppm olarak tespit edilmiştir [2].

Hekzan; yapıştırıcı, ayakkabı ve deri endüstrisi, bitkisel yağların ayrıştırılmasında kullanılan, ham petrolden üretilen, oldukça yanıcı (hatta patlayıcı), kolayca buharlaşabilen, renksiz bir bileşiktir. Saf hekzandan esasen laboratuarlarda faydalanılır. Endüstride kullanılan hekzan ise çözücü olarak bilinen diğerkimyasallarla birlikte değerlendirilir. Toprağıa düştüğünde daha sızmadan çoğı buharlaşır. Petrolde bulunduğundan herkes az miktarda maruz kalır. Kanserojen etkisinin olduğuna dair net bir bilgi yoktur. Yüksek seviyelerde teneffüs edildiğinde, sinir sisteminde bozukluklara, el ve ayak kaslarında zayıflığıa, sürekli maruz kalındığında ise el ve ayaklarda felce sebebiyet verebilir. Hekzanın çalışma ortamında bulunabilecek maksimum miktarı 500 ppm olarak tespit edilmiştir [3].

Aseton; plastik, boya, fiber ve diğerkimyasalların yapımında kullanılan, kolayca buharlaşabilen, suda çözünen, yanıcı, renksiz bir bileşiktir. Endüstride çözücü olarak yaygın biçimde kullanılır. Eksoz ve sigara dumanında doğal olarak bulunur. Atmosferden suya ve toprağıa, su ve topraktan da havaya kolayca geçebilir. Maruz kalındığında dolaşım sistemi yoluyla tüm organlara ulaşır. Yüksek miktarlarda teneffüs edildiğinde veya yutulduğunda burun, akciğerk ve gözde tahribat, kalp atışlarında hızlanma, midede bulantı, bilinç kaybı ve koma hali oluşturabilir. Uluslar arası kanser araştırma merkezi (IARC) asetonun, uzun periyotta kanserojen etkisinin olduğunu belirtmemiştir. Asetonun çalışma ortamında bulunabilecek maksimum miktarı 1000 ppm olarak tespit edilmiştir [4].

Trikloretilen; yapıştırıcılarda, boya sökücülerde, metal yüzeylerin temizlenmesinde kullanılan, yanıcı olmayan, renksiz bir bileşiktir. Doğada doğal halde bulunmaz. Bununla birlikte, üretim sonucunda oluşankimyasal atıklardan yeraltı ve yerüstü sularına karışabilir. Yüzeydeki sulardan kolayca buharlaşarak havaya karışabilir, fakat topraktan kolayca buharlaşmaz. Uzun süre teneffüs edildiğinde veya içildiğinde kronik kalp hastalıklarına, bilinç kaybına, böbrek, karaciğerk ve sinir sisteminde tahribata, hatta ölüme yol açabilir. Hayvanlar üzerinde yapılan çalışmalara göre,

yüksek ölçüde maruz kalındığında böbrek, karaciğer ve akciğer kanserine sebebiyet verdiği gözlemlenmiştir. İnsanlar üzerinde yapılan çalışmalarda ise kanser vakalarının arttığı bildirilmiştir. Trikloretilenin çalışma ortamında bulunabilecek maksimum miktarı 100 ppm olarak tespit edilmiştir [5].

Metanol; çeşitli solventler, boya çıkarıcı, vernik, antifriz sıvıları, kolonya ve ispirto gibi ürünlerin üretiminde kullanılan, karakteristik kokusu olan yanıcı renksiz bir sıvıdır. Teneffüs edilmesi, ağız yoluyla alınması veya deri ile teması durumunda zehirlidir. Ağız yoluyla alınması ölümcül olabilir. Maruz kalındığında göze, böbreğe, kalbe ve karaciğere zarar verebilir. Sürekli veya çok miktara maruz kalındığında hatta körlüğe neden olabilir [6]. Çalışma ortamında bulunabilecek maksimum miktarı 200 ppm, 6000 ppm seviyesi ise sağlığı ve/veya yaşamı tehdit edeci düzey olarak belirtilmektedir [7].

Özellikle bilimsel araştırmalarda kimyasal gaz analizi için gaz kromatografisi, kütle spektrometresi, iyon kromatografisi gibi analitik yöntemlere başvurulur. Uçucu organik bileşiklerin ölçülmesi için halen kullanılmakta olan yöntem, örneklerin toplanması ve gaz-sıvı faz kromatografi tekniği kullanarak karakterize edilmesi şeklindedir. Analitik yöntemlerde örnek hazırlama ve ölçüm süreleri uzundur. Ayrıca sistemin kullanılması ve sonuçların yorumlanması uzmanlık gerektirir. Hassasiyet ve seçicilik bakımından analitik cihazlara göre oldukça düşük seviyelerde olmasına karşın günümüz teknolojisi ile laboratuvar ortamının dışında da kullanılabilen, küçük boyutlu, kolay kullanımlı, düşük maliyetli kimyasal sensörlere olan ihtiyaç giderek artmaktadır. Bu yöntemlerle karşılaştırıldığında, kimyasal gaz sensörlerinin örnek hazırlama, ölçüm ve geri dönüşüm süreleri oldukça kısadır. Ayrıca sistemin kullanılması ve sonuçların yorumlanması da bir uzmanlık gerektirmemektedir [8].

Birçok endüstri kolunda (özellikle kimya ve boya endüstrisi) zararlı, zehirli, yanıcı, patlayıcı gaz kaçağı riski her zaman vardır. Böyle bir gaz kaçağı can kayıplarına, sakatlanmalara, yangınlara ve patlamalara neden olabilmektedir. Gaz kaçağı olasılıklarına karşı önlemlerin zamanında alınabilmesi için gaz çeşit ve konsantrasyonlarının bir kimyasal gaz sensörü ile sürekli olarak gözlenmesi gerekmektedir. Bir arıza veya tehlike anında, kimyasal gaz sensörü, durumu

göstermesinin yanı sıra, uygun bir düzenele otomatik olarak gaz akışını kesebilir [8].

Kimyasal gaz sensörlerinin bazı uygulama alanları şunlardır: Petro-kimya/boya, kozmetik, otomotiv, gıda/içecek, ev gereçleri, sağlık/ilaç, tarım, çevre, savunma ve güvenlik. Bu alanlarda yanıcı/patlayıcı gaz kontrolleri, gıda maddelerinin raf ömrü ve kalite analizleri, hava ve su kirliliği ölçümleri, mayın ve patlayıcı maddelerin bulunması, topluma açık yerlerin güvenliğinin sağlanması gibi işlevler gerçekleştirilmektedir.

Kimyasal sensörler, elektrokimyasal temelli sensörler, yarıiletken temelli sensörler (MOSFET, IDT, Chem-FET), osilasyonlu kütle algılayıcı sensörler (QCM, SAW), optik temelli sensörler, katalitik veya kalorimetrik temelli sensörler şeklinde olabilir. Bu kimyasal sensör tipleri metal oksitler, iletken polimerler, seramikler, katalitler, zarlar, cam elyafı, ısı çiftler, iyon seçici elektrotlar gibi malzemelere dayanmaktadır [8].

Kimyasal sensörler bir arayüzey ve transduserden oluşur. Kimyasal sensörlerin en önemli kısmı olan algılayıcı malzeme, hangi gazı algılayacağını belirleyen önemli bir unsurdur. Uygun bir şekilde algılayıcı madde seçimiyle istenilen bir gazın algılanması mümkündür.

Bu tez çalışmasında, algılayıcı malzeme olarak ftalosiyanın ve oksim gibi büyük moleküllü kimyasallar kullanılmıştır. Bu kimyasallar, ısı ve kimyasal kararlılıkları, ince filmlerinin kolay hazırlanabilmesi, yakın infrared bölgede yüksek soğurma bandına sahip olmaları, kolay çözülebilen katkılanmış türevleri ve elektriksel özelliklerinin katkılama ile büyük oranda değiştirilebilmesi gibi özelliklerinden dolayı yaygın olarak çalışılan organik yarıiletken malzemelerdir [9,10].

Kimyasal sensörlerle ilgili olarak iki alanda çalışmalar yürütülmektedir. Bunlardan birincisi yüksek algılama özelliğine sahip sensör tasarımı çalışmaları, ikincisi ise sensör dizileri üzerinde yapılan çalışmalardır. İlk alandaki çalışmalar, önemli sensör parametreleri olan duyarlık ve seçiciliğin, sensörlerin yaşlanma, tekrar üretilebilme,

cevap zamanı ve ortam etkilerinden (sıcaklık, nem) kaynaklanan kararlılık düzeyinin iyileştirilmesine yönelik, diğer alandaki çalışmalar ise tek bir sensörle uçucu organik bileşiklerin tam seçicilikle algılanması mümkün olmadığı için farklı tip sensörlerden oluşan sensör dizileri ve veri işleme tekniklerine yöneliktir [11].

Sensörlerden alınacak olan tepkiler, değişik türdeki gazların farklı konsantrasyonlarına kompleks bir şekilde bağlıdır. Genellikle sensörler, bir analit için tam bir seçicilik sağlamamakta ve farklı analitlere değişik tepkiler verebilmektedir. Bu problemin aşılabilmesi ve diğer cevaplardan aranan cevabın doğru bir biçimde ayırt edilebilmesi maksadıyla çeşitli yöntemlere başvurulur. Eldeki veri setinin türüne, büyüklüğüne, ulaşılmak istenen bilginin türüne (nicel, nitel) bağlı olarak çeşitli “Veri İşleme Metotları” ve “Örüntü Tanıma Teknikleri” yöntemleri kullanılır [8]. Bu yöntemler, istatistiksel çok bileşenli analiz metotları olan “Temel Bileşen Analizi”, “Kümeleme Analizi”, “Ayırma Fonksiyon Analizi” ve yapay zeka teknikleri olan “Yapay Sinir Ağları”, “Bulanık Mantık”, “Genetik Algoritmalar” dır.

Bu tezin çalışma alanında, ikili gaz karışımlarının analizi için çoğunlukla yapay sinir ağları kullanılmaktadır. Bu konuda yapılmış çalışmaların bir özeti aşağıda verilmiştir;

Sriyudthsak, Lertnimitthum, ve Nakpeerayut’un çalışmasında [12] üç adet TGS tipi yarıiletken sensör kullanılmış, sensörlerin yükselme zamanı (rise time), pik zamanı (peek time) ve düşüş zamanı (fall time) karakteristiklerinden faydalanılarak uçucu organik bileşiklerden olan etilalkol, aseton, amonyak, asetaldehit ve suyun sınıflandırması yapılmıştır. Genellikle sensör cevaplarının pik zamanı karakteristiği kullanılır, bu çalışmada ise diğer karakteristiklerin de kullanımı ile olumlu sonuçlar alındığından bahsedilmiştir. Burada kullanılan yapay sinir ağı ileri beslemeli, 9 giriş, 36 gizli ve 5 çıkış katmanlı yapısıyla sınıflandırma işlemini gerçekleştirmektedir. Yapay sinir ağının çıkışlarından sadece bir tanesi 1, diğerleri 0 değerini göstermek suretiyle ilgili uçucu organik bileşiği temsil etmektedir.

Taurino, Distanto, Siciliano, ve Vasanelli’nin çalışmasında [13] metal-oksit mikrosensör dizisi kullanılarak atmosferde bulunabilen aseton, hekzanal ve 2-

pentanonun niteliksel sınıflandırması yapılmış ve 2-pentanon-hekzanal'ın düşük konsantrasyonlarından oluşturulan gaz karışımlarının miktarsal olarak belirlenmesi amaçlanmıştır. Sınıflama ve kümeleme için lineer tekniklerinden olan temel bileşen analizi (Principal Component Analysis-PCA) ve lineer olmayan tekniklerden biri olan yapay sinir ağları tercih edilmiştir. Miktersal sınıflandırma işlemi için niteliksel sınıflandırmada kullanılan çok katmanlı algılayıcılar ve radyal temelli yapay sinir ağları ile elde edilen sonuçlardan faydalanılmıştır. Geriye yayılım eğitim algoritmasının kullanıldığı çok katmanlı algılayıcıların, radyal temelli ağlara göre daha iyi sonuçlar verdiği gösterilmiştir. Genellikle ön işlemeye tabi tutulmuş verilerle çalışmalar yapılmaktadır. Bu çalışmada ise ham verilerin kullanılmasının daha iyi kümeleme işlemini gerçekleştirdiğinden bahsedilmiştir.

Llobet, Brezmes, Vilanova, Sueiras ve Correig'nin çalışmasında [14] gazların miktarsal tayini için yarıiletken gaz sensörlerinin hem sürekli hem de geçici hal cevaplarını kullanmışlardır. Daha açık ifadeyle, 4 adet metal-oksit gaz sensöründen oluşan sensör dizisi ve örüntü işleme tekniklerinden yararlanarak 25, 50 ve 100 ppm konsantrasyonlarında olabilen etanol, toluen ve o-xylene gazlarından birini miktarsal olarak sınıflandırmışlardır. Bu arada sensör tepkilerinin sadece dinamik kısmının kullanılmasının seçiciliği arttırdığı temel bileşen analizi ile gösterilmiştir. Çalışmanın ilk aşamasında, bu gazların niteliksel sınıflandırması için geriye yayılım ile eğitilmiş ileri beslemeli ağlar kullanılmıştır. Bu aşamada, sensörlerin sadece sürekli hal cevaplarının kullanılması durumunda doğru sınıflama kabiliyetinin %66, geçici hal cevaplarının da kullanılması durumunda ise %100 sınıflama yapıldığı belirlenmiştir. Çalışmanın niceliksel sınıflandırma süreci olan ikinci aşamasında sensörlerin sadece sürekli hal cevaplarından faydalanılmış ve her bir gaz için birer yapay sinir ağı modeli kullanmak suretiyle gazların 25, 50 veya 100 ppm konsantrasyon değerlerini ayırt edecek şekilde miktarsal tayin gerçekleştirilmiştir. Miktersal tahminde, toluen için %84, etanol ve o-xylene'de ise %100 başarı elde edilmiştir.

Penza ve Cassano'nun çalışmasında [15] 433.92 MHz.'de salınım yapan SAW (Surface Acoustic Wave) sensör dizisi kullanılarak konsantrasyonları 20-140 ppm değerleri arasında değişen metanol ve 5-70 ppm değerleri arasında değişen 2-propanol'dan oluşan ikili gaz karışımında hangi gazın veya gazların olduğu tespit

edilmiştir. Bu çalışmada, özellik çıkartımı (feature extraction) için lineer örüntü işleme tekniklerinden olan temel bileşen analizi (PCA) ve örüntü sınıflama yöntemlerinden olan yapay sinir ağları kombine edilmiştir. İleri beslemeli yapıya sahip yapay sinir ağlarının girişlerine, hem normalize edilmiş sensör verileri, hem de PCA'den elde edilen 2 temel bileşen uygulanmıştır. Sonuç olarak metanol için (0,9-0,01), 2-propanol için (0,01-0,9) ve metanol-2-propanol karışımı için (0,9-0,9) eşik değerleri kullanılarak %100 sınıflama başarısı elde edilmiştir.

Getino, Horrillo, Gutierrez, Ares, Robla, Garcia, ve Sayago'nun çalışmasında [16] temel bileşen analizi (PCA) ve yapay sinir ağları kullanılarak alifatik, aromatik ve klorlu bileşik gibi uçucu organik bileşiklerin, tekli gaz sınıflandırılması yapılmış, ikili gaz karışımlarının sınıflandırılmasında ise çok değişkenli regresyon metotları kullanılmıştır. Bu arada sensörlerin seçicilik kabiliyetini arttırmak için değişik örüntü tanıma algoritmalarının kullanılabileceğinden ve en çok kullanılan yöntemler olarak PCA ve en küçük kareler yönteminden bahsedilmiştir. 15 adet metal-oksit gaz sensörü kullanılan çalışmada, sensör cevaplarının lineer olmamasından dolayı lineer regresyon yöntemlerinin yerine, yapay sinir ağları kullanılarak 6 adet tekli gaz sınıflandırması yapılmıştır. Yapay sinir ağlarıyla %71 sınıflama başarısına ulaşıldığı ancak ağ topolojisini değiştirerek daha iyi sonuçlar elde edilebileceği vurgulanmış, ayrıca bilinmeyen konsantrasyondaki gaz karışımlarının miktarsal tahmini çalışmalarının sürdürüldüğü bildirilmiştir.

Özmen, Tekce, Ebeoğlu, Taşaltın ve Öztürk'ün çalışmasında [17] altı adet QCM (Quartz Crystal Microbalance) tipi gaz sensörlerinden oluşturulan sensör dizisi kullanılarak, üç farklı ikili gaz karışımındaki her bir gazın miktarsal tahmini, geriye yayılım algoritmasını kullanan yapay sinir ağlarıyla gerçekleştirilmiştir. Karışım olarak etanol-aseton, etanol-trikloretilen ve aseton-trikloretilen alınmıştır. Karışımları oluşturan gazların konsantrasyon değerleri, 250-3300 ppm aralığında seçilmiştir. Sensör dizisinden edinilen dijital sinyaller, sliding window algoritmasıyla ön işlemeye tabi tutulmuş ve [0,1] aralığına normalize edilmiştir. Bu verilerin %84'ü yapay sinir ağlarının eğitim aşamasında, geriye kalanı ise test aşamasında kullanılmıştır. İkili gaz karışımındaki birinci çıkıştaki hata miktarı %15,5, ikinci çıkıştaki ise %5,7 ve buna göre ortalama hata %10,6 olarak bulunmuştur. Çalışmada,

birinci çıkıştaki hata, beklenenden fazla olduğundan, bunun giderilmesi için ölçümler alınırken gaz miktarlarındaki artışların lineer yapılması ve yapay sinir ağlarının eğitiminde kullanılan verilerin çok sayıda alınmasının gerekliliği vurgulanmıştır.

Bu tez çalışmasında, farklı tipte yapay sinir ağları (YSA) ve uyarlamalı sinirsel bulanık çıkarım sistemleri (Adaptive Neuro Fuzzy Inference Systems-ANFIS) kullanılarak ikili uçucu organik gaz karışımlarının sınıflandırılması ve miktarsal tayini gerçekleştirilmiştir. Çalışmanın deneysel ölçüm aşamasında kuartz kristal sensörlerden oluşan bir sensör dizisi kullanılarak seçilen gazların yedi farklı ikili karışımlarının konsantrasyona bağlı frekans cevapları ölçülmüştür. Bu sensörler, kuartz kristallerin yüzeyleri uçucu organik bileşiklere duyarlı olan ftalosiyanın ve oksim maddeleriyle kaplanarak hazırlanmıştır. Ölçümler sonucunda elde edilmiş frekans cevapları, YSA yapıları ve uyarlamalı sinirsel bulanık çıkarım sistemleri için eğitim ve test setleri olarak düzenlenmiştir. Bu amaçla ölçümler sonucu elde edilen frekans cevapları geçici ve sürekli hal cevapları olarak gruplandırılmıştır.

Kimyasal sensörlerle ilgili olarak yürütülen çalışma alanlarından birisi de yukarıda belirtildiği gibi veri işleme teknikleridir. Bu teknikler genellikle sensörlerin sürekli hal cevaplarını kullanmaktadır [18-24]. İleri beslemeli YSA yapıları, kimyasal gaz ve kokuların miktarsal belirlenmesinde sergilediği başarılarıyla diğer geleneksel veri işleme metodlarının yerini almakta olduğu söylenebilir. Gaz sensör dizilerinin analizinde YSA kullanımı, geleneksel veri işleme yöntemlerine göre uyarlanabilirlik, gürültü toleransı, vb. açılardan çeşitli avantajlar sağlamaktadır [18-21,25]. YSA'ların yanı sıra, bulanık çıkarım sistemleri (BÇS) ve değişik türden sinirsel bulanık kombinasyonlar (SBK) da lineer olmayan verileri oldukça iyi bir şekilde ele alabildiği ve gürültüye karşı yeterince gürbüz olduğu için, universal yakınsayıcılar olarak kullanılmaktadırlar [22]. Son on-onbeş yıl boyunca YSA, gaz sensör dizileri için veri işlemede oldukça başarılı ve yaygın bir şekilde uygulanmıştır. Öte yandan, literatürde sadece konsantrasyon tahmini için birkaç basit bulanık modelleme örnekleri bulunmaktadır. Bunlar da miktarsal sınıflandırma problemini çözme değil, sadece konsantrasyon tahminini amaçlayan standart bulanık mantık uygulamalarıdır [1,11,23,24]. Buna karşılık bulanık mantık yaklaşımının ileride daha geniş uygulama alanı bulacağını destekleyen bir faktör, bulanık çıkarım

mekanizmasının kompleks lineer olmayan sistemlerin çözümünde düşük maliyetli mikrokontrolörlere uyarlanabilmesidir [26-28].

Gaz karışımlarının miktarsal sınıflandırılması yüzlerce bulanık kural ve üyelik fonksiyonu parametresi gerektirdiğinden, bulanık çıkarım sistemleri için oldukça karmaşık bir problem olarak algılanır. Çok karmaşık olan problemler için üyelik fonksiyonlarının parametrelerinin ve bulanık kuralların belirlenmesi oldukça zordur [26]. Diğer yandan, uyarlamalı sinirsel bulanık çıkarım sistemleri (Adaptive Neuro-Fuzzy Inference Systems-ANFIS) üyelik fonksiyonlarının parametrelerinin ve bulanık kuralların belirlenmesinde alternatif kolay bir yol sağlamaktadır [26,29]. ANFIS metodunda Sugeno tip çıkarım sisteminin [30] üyelik fonksiyonlarının parametrelerinin ve bulanık kuralların belirlenmesi amacı ile gerçekleştirilen eğitim için en küçük kareler ve geriye yayılım yöntemlerinin kombinasyonu olan hibrit öğrenme algoritması veya tek başına geriye yayılım algoritması kullanılır [31].

Bu tez çalışmasının birinci aşamasında, gaz sensörlerinin sürekli hal cevapları ile yapılan ikili gaz karışımlarının sınıflandırma ve miktarsal tayini için ANFIS yapısı önerilmiş ve sonuçlar YSA yapıları ile karşılaştırılmıştır. ANFIS'in bu iş için uygulanabilirliği gösterilmiştir.

Yukarıda da belirtildiği gibi ileri beslemeli YSA yapıları kimyasal gaz ve kokuların miktarsal belirlenmesinde yaygın bir şekilde başarı ile uygulanmaktadır. Ancak, genellikle literatürde YSA eğitimi için geçerli bir neden gösterilmeksizin standart geri yayılım algoritması tercih edilmektedir. Geri yayılım algoritmasının [32], ileri beslemeli YSA'ların eğitilmesinde güçlü bir araç olduğu bilinmektedir. Fakat ağırlıkların güncellenmesinde hata fonksiyoneline bağlı olarak gradiyen yöntemi kullanıldığından yavaş yakınsama ve yerel minimumlara takılma problemi mevcuttur [33,34]. Bu problemle ilgili olarak değişik algoritmalar tasarlanmış ve birçok araştırmacı çeşitli konularda ileri beslemeli YSA'nın eğitim algoritmaları üzerine karşılaştırmalı çalışmalar yapmışlardır [35–41].

Bu tez çalışmasının ikinci aşamasında, bu tip sezgisel ve ileri seviyeli algoritmalarından olan momentumlu geriye yayılım, adaptif öğrenme katsayılı geriye

yayılım [35], esnek geriye yayılım (RP) [35–38], Fletcher–Reeves conjugate-gradient (CG) [35,39] algoritma türleri, aynı zamanda Broyden, Fletcher, Goldfarb ve Shanno quasi-Newton (QN) algoritmaları [35,40] ve Levenberg–Marquardt (LM) algoritması [35,41] karşılaştırma amacı ile kullanılmış ve önerilmiştir. Aynı zamanda ikili gaz karışımlarının miktarsal tayininde kullanılan bu eğitim algoritmalarının avantaj ve dezavantajlarının saptanmasına çalışılmıştır.

İleri beslemeleli ağların eğitimi genellikle zaman alıcı bir proses olmakla birlikte, ileri seviyeli eğitim algoritmalarının kullanımı da işlem karmaşıklığını artırabilmektedir. Radyal temelli sinir ağları (radial basis function-RBF) ise eğitim zamanını ve eğitimle ilgili yapılan analizleri oldukça azaltmaktadır. Radyal temelli sinir ağları birçok sınıflandırma probleminde, kullanımındaki kolaylık açısından ileri beslemeli ağlara kıyasla daha uygundur. Ne yazık ki, radyal temelli sinir ağlarının boyutunun, eğitimde kullanılan örnek sayısı ile orantılı olarak artması, bu yapının büyük boyutlu problemlerde kullanılmasını zorlaştırmaktadır.

Bu tez çalışmasının üçüncü aşamasında ise, büyük boyutlu problemleri çözmek için kullanılacak radyal temelli sinir ağlarının boyutunun çok fazla büyümesini engelleyebilecek bir metot önerilmiştir. Genellikle radyal temelli sinir ağları gizli katmanında aktivasyon fonksiyonu olarak ana parametreleri aritmetik ortalama ve standart sapma olan Gaussian fonksiyonu kullanmaktadır. Normal dağılımın yoğunluk fonksiyonunun Gaussian fonksiyonu olduğu bilinmektedir. Çalışmanın bu aşamasında, kararlı hal frekans cevaplarına uygun değişkenin, normal dağılım kuralına uygunluğundan yola çıkarak, bu ölçüm değerleri dağılımının parametrelerinin, ölçüm değerleri yerine eğitim örnekleri olarak kullanılması ve böylelikle eğitim verilerinin sayısını azaltmakla radyal temelli sinir ağının boyutunun küçültülmesi önerilmiştir.

Yüksek algılama özelliğine sahip sensör tasarımı çalışmaları sırasında rastlanan önemli problemlerden birisi de yukarıda belirtildiği gibi yavaş cevap zamanıdır [25]. Genellikle gazların konsantrasyon tahmini için sensörlerin sürekli hal cevaplarından faydalanılmaktadır [18-24]. Sensörlerin geçici hal cevapları ölçümün başlangıcında çok hızlı bir değişim gösterir. Yani, bu cevaplar eğrisinin eğim değerleri başlangıçta

daha büyüktür ve zamanla azalmaktadır. Bu cevap eğrisinin belirli bir zaman periyoduna karşılık gelen kısmı bir zaman dizisi olarak algılanabilir. Geçici hal cevaplarının oluşturduğu bu zaman dizisi sensör cevabının eğimi ve eğilimi hakkında ilave bilgi sağlamaktadır [26]. Bu bilgi sayesinde sensörler kararlı hal cevap bölgesine ulaşmadan önce karışımdaki her bir gazın miktarsal tayini gerçekleştirilebilir. Böylece geçici hal cevaplarının oluşturduğu zaman dizisi kullanılarak konsantrasyon tahmini süresi kısaltılabilir ve belirli bir ölçüde yavaş cevap zamanı problemi çözüme kavuşturulmuş olur.

Bu amaçla, çalışmanın dördüncü aşamasında, gaz sensörlerinin geçici hal cevaplarından oluşan zaman dizisi ile yapılan sınıflandırma ve miktarsal tayinde iki tip YSA yapısı önerilmiş ve sonuçlar karşılaştırılmıştır. Bunların ilki olan zaman gecikmeli YSA yapısı, geçici hal cevaplarından oluşan zaman dizilerini kullanmaktadır. Diğer ileri beslemeli YSA yapısı ise geçici hal cevabının yanı sıra, bunların eğim bilgisini de hesaba katmaktadır.

Yapılan literatür taramalarında, çok sayıda ikili gaz karışımlarının hem niteliksel hem de miktarsal sınıflandırılmasını bir arada içeren çalışmalara pek rastlanmamıştır. Bu nedenle, çalışmanın beşinci aşamasında, sensörlerin sürekli hal cevapları kullanılarak, yedi farklı ikili gaz karışımının niteliksel sınıflandırılması olasılıksal sinir ağları (Probabilistic Neural Network-PNN), niceliksel sınıflandırılması ise yalnızca ileri beslemeli ağlar yardımıyla gerçekleştirilen bir paket oluşturulmuştur.

BÖLÜM 2. YAPAY ZEKA

Yapay zekanın amacı, insanın zekasını bilgisayar aracılığı ile taklit etmek, bu anlamda belli bir ölçüde bilgisayarlara öğrenme yeteneği kazandırabilmektir. Bu şekilde yapay zeka çoğunlukla insanın düşünme yeteneğini, beynin çalışma modelini veya doğanın biyolojik seçim metodunu modellemeye çalışan yöntemlerden oluşur. Yapay zeka yöntemlerinin başlıcalarını uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritmalar oluşturur.

Uzman sistemler kısaca bir kural tabanlı sistem olarak nitelendirilebilir. Burada oluşturulan kurallar bir uzmanın görüşü veya tecrübesine dayandırılarak oluşturulur. Oluşturulan bu kurallardan, insanın neden-sonuç ilişkisine bağlı kalarak bir sonuca varması gibi mantıksal işlemler sonucunda bir çıkarım yapılır. Uzman sistemler kısaca, çözümü kesin belli olmayan problem tipleri için bazı algoritmik olmayan uzmanlıkları somutlaştıran bilgi uygulamalarıdır.

Bulanık mantık da bir kural tabanlı sistem olarak düşünülebilir. Fakat burada nitelendirmeler, uzman sistemlerden farklı olarak kesin değildir. Bir insanın günlük hayatta yaptığı nitelemelerin büyük çoğunluğu da kesin değildir. Bulanık mantık bu şekilde kural tabanının günlük hayatta kullanılan kesin olamayan kelimelerle oluşturulmasına imkan sağlar. Bulanık mantığın en güçlü tarafı var olan bir uzman bilgisinin kullanılmasıdır. Bu durum uzman bilgisinin tam olarak elde edilemediği durumlarda ise büyük bir dezavantaj oluşturur.


Beynin öğrenme kapasitesi, nöronlar ve bunların birbiri ile olan bağlantısına bağlıdır. Yapay sinir ağları, adından da anlaşılacağı gibi, beynin çok basit bir nöron modelinin benzetimidir. Bu şekilde elde edilen ağ ile öğrenme olayı gerçekleşir [42].

Genetik algoritma, doğanın kullanmış olduğu biyolojik seçim modelini benzeterek çözüm arayan bir optimal arama algoritmasıdır. Genetik algoritma (GA) süreci doğal evrime benzetilir. Bu nedenle üreme (Reproduction), çaprazlama (Crossover), mutasyon (Mutation) gibi doğal evrimde kullanılan operatörleri içerir. Genetik algoritma doğrudan parametrelerle değil, kodlanmış parametre dizisiyle çalışır. Bu, kullanıcıya problemleri bir değişken optimizasyon problemi gibi çözmesine imkan verir.

Bu tez çalışmasında, miktarsal sınıflandırma problemi için en uygun yapay zeka teknikleri yapay sinir ağları ve bulanık mantık olacağı düşünülerek bu teknikler üzerinde yoğunlaşmıştır.

2.1. Yapay Sinir Ağları (YSA)

İnsan beyni nöron adı verilen sinir hücreleri ve bunlar arasındaki bağlantılardan oluşan karmaşık bir sistemdir. İnsan beyinde yaklaşık 100 milyar nöron ve nöron başına düşen bağlantı sayısının da ortalama birkaç bin olduğu düşünülürse, insan beyni karmaşık bir ağa benzetilebilir. Nöronlar bu bağlantılar sayesinde birbirleriyle iletişim kurarlar.



Şekil 2.1. Bir nöronun YSA modeli

YSA algoritmaları, insan sinir sistemi mimarisinden esinlenerek geliştirilmiştir. Ancak, beynin çalışma sistemiyle ilgili bilgilerin kısıtlı olması ve bu tür çalışmalara yol gösterememesi, araştırmacıları mevcut biyolojik bilgilerden farklılaşarak bazı yararlı fonksiyonlar bulmaya itmiştir. Günümüzde çok sayıda YSA modelleri

geliştirilmiştir. Bu modellerin geliştirilmesinde biyolojik sinir sistemlerinin prensiplerinden ve mühendislik biliminin imkanlarından faydalanılmıştır.

YSA'lar doğrusal olmayan sistemlerin kontrolünde ve modellenmesinde büyük kolaylıklar sağlamaktadırlar. Son yıllarda başta mühendislik olmak üzere pek çok bilim dalında karmaşık problemlere çözümler üretmeleri YSA'lara olan ilgiyi arttırmıştır. Çeşitli meslek gruplarında çalışma yapanlar YSA'ları kendi uzmanlık alanlarına taşıyarak, bu alanda kullanacakları uygulamaları ve yöntemleri arar hale gelmişlerdir. Bu ilgi, teorik ve uygulama alanlarındaki başarılarla daha da pekişmiştir.

YSA'ları klasik teknikler kullanarak modellenmesi imkansız veya çok zor olan sistemlerin modellenmesinde oldukça etkilidirler. Bilinen model kontrol algoritmaları yerine YSA'lar, istenen sistem performansını gerçekleştirebilen bir kontrol şemasını öğrenebilmek için uygun ağırlık bağlantılarıyla kendi kendilerini biçimlendirirler.

Kontrol problemi dinamik sistemin bir veya daha fazla değişkenini, belirlenen sınırlar içinde tutmayla ilgili analiz ve sentezlerdir. Kontrolör yapısını belirleme ve sistem çıkışıyla istenen çıkış arasındaki hatayı minimize etmek için parametrelerin ayarlanması kontrol probleminin bir parçasıdır. Yapay sinir ağları, verilen giriş-çıkış çiftlerinden ağırlık parametrelerini ayarlama temeline dayanır.

YSA'lar, lineer olmayan, sisteme ait bilginin tam olmadığı veya hatalı olduğu sistemlerde çözüme ulaşmak için uygundur. YSA'ların en önemli dezavantajı ise var olan bir uzman bilgisinin problem çözümüne aktarılmasındaki zorluktur. YSA kullanım alanları; kontrol ve sistem tanımlama, görüntü ve ses tanıma, tahmin ve kestirim, arıza analizi, tıp, haberleşme, trafik, üretim yönetimi olarak sayılabilir.

2.1.1. Yapay sinir ağlarının tarihçesi


İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. 1980 yılında beynin fonksiyonları hakkında bilgi veren ilk eser yayınlanmıştır. 1940'tan önceki

yıllarda bazı bilim adamlarının yapay sinir ağı kavramı üzerinde çalıştıkları bilinmektedir. Fakat bu çalışmaların mühendislik değeri olduğu söylenemez. 1940'lı yıllardan sonra Hebb, McCulloch ve Pitts gibi bilim adamları yapılan araştırmaları mühendislik alanlarına kaydırmaya ve günümüzdeki yapay sinir ağlarının temellerini oluşturmaya başlamışlar ve ilk yapay sinir hücresinin yapısını oluşturmuşlardır. Yapay sinir ağları ile her türlü mantıksal ifadeyi formülize etmenin mümkün olduğunu göstermişlerdir. Hücrelerin birbiriyle paralel çalışması gerektiği fikrini ortaya atarak öğrenme kurallarının belirlemeye başlamışlardır. 1949 yılında Donald Hebb, yapay hücrelerden oluşan bir yapay sinir ağının değerlerini değiştiren bir öğrenme kuralını geliştirmiş; "Hebbian öğrenme" kuralı denilen bu kural günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır. 1950'li yıllarda çalışmalar daha açık bir şekilde fark edilmiş ve 1951 yılında ilk neuro-bilgisayar üretilmiştir. Silicon teknolojinin geliştirilmesi ile bu çalışmalar 1960'lı yıllarda oldukça önemli gelişmelere neden olmuştur. 1954 yılında Farley ve Clark tarafından rassal ağlar ile adaptif tepki üretme kavramı ortaya atılmış ve bu kavram daha sonraları 1958 yılında Rosenblatt ve 1961 yılında Caianiello tarafından geliştirilmiştir. Özellikle Rosenblatt tarafından geliştirilen algılayıcı model (perceptron) yapay sinir ağları tarihinde önemli bir gelişmeye öncülük etmiştir. Çünkü bu model, daha sonraları geliştirilecek ve yapay sinir ağlarında devrim niteliğinde olacak olan çok katmanlı algılayıcıların temelini oluşturmaktadır. Benzer şekilde Widrow ve Hoff ADALINE (ADaptive LInear NEuron) modelini ortaya atmıştır. Daha sonraki yapay sinir ağları modellerinin gelişmesine katkıda bulunmuş bir çalışmadır. Adaptif öğrenmenin de temellerinden olan ve 1970'li yılların sonlarına doğru ortaya çıkan MADALINE modelleri bu çalışmaların neticesinde ortaya çıkmıştır. 1956 yılında "Yapay Zeka" kavramı ortaya atılmış ve bilim dünyasında kabul görmüştür. 1960'lı yılların sonunda yapay sinir ağı çalışmaları duraklama devrine girmiştir. Çalışmalar öyle kesilmiştir ki, XOR problemi çözülünceye kadar dikkatleri yapay sinir ağına çekmek mümkün olmamıştır. Çalışmaların 1969 yılında sekteye uğraması ve gerekli finansal desteklerin kesilmesine rağmen bazı bilim adamları çalışmalarına devam etmişlerdir. Özellikle Amari, Anderson, Cooper, Fukushima, Grossberg, Kohonen ve Hopfield gibi araştırmacıların çalışmaları 1980'li yıllara gelindiğinde meyvelerini vermeye başlamış ve yapay sinir ağlarındaki sessizlik sona ermiştir. Kohonen 1982 yılında "kendi kendine öğrenme nitelik haritaları (self-organizing feature maps-SOM)"

konusundaki çalışmasını yayınlamıştır. Grossberg, yapay sinir ağlarının psikolojik mantıksallığı ve mühendislik uygulamalarındaki kolaylığını göstermiş; Carpenter ile Adaptif Rezonans Teorisini (ART) geliştirmiştir. Bu öğretmensiz öğrenme konusunda zamanının geliştirilmiş en karmaşık yapay sinir ağı olmuştur. 1970’li yılların sonlarına doğru Fukushima görsel şekil ve örüntü tanıma amaçlı geliştirdiği NEOCOGNITRON modelini tanıtmıştır. Rumelhart ve arkadaşlarının paralel programlama konusundaki çalışmaları sonucunda çok katmanlı algılayıcıların bulunması yapay sinir ağlarının tarihsel gelişimi bakımından çok önemli bir adım olmuştur. XOR problemi çok katmanlı algılayıcıların bulunması ile çözülmüş ve yapay sinir ağlarının çalışmadığını söyleyen bütün tezler çürütülmüştür. 1986’da Rumelhard “Parallel Distributed Processing” grubuyla ileri beslemeli modellerde yeni bir öğrenme modeli oluşturarak hatanın geriye yayılması anlamına gelen “Back Propagation” algoritmasını geliştirmiştir. 1988’de Broomhead ve Lowe, Radyal temelli fonksiyonlar (Radial Basis Functions-RBF) modelini geliştirmişler ve bu ağın çok katmanlı algılayıcılara alternatif olarak geliştirildiğini belirtmişlerdir. Daha sonra Specht bu ağların daha gelişmiş şekli olan Probabilistik (PNN) ve Genel Regresyon Ağlarını (GRNN) geliştirmiştir [43].

2.1.2. Biyolojik sinir hücreleri ve YSA


Biyolojik sinir ağları, beynimizde bulunan milyonlarca sinir hücresinden oluşur. Sinirler birbirleriyle bağlanarak fonksiyonlarını meydana getirirler. Duyu organlarından gelen bilgiler sinir sistemi sayesinde beyine taşınır ve beynin oluşturduğu kararları vücudun organlarına iletir. Şekil 2.2’de gösterildiği gibi sinir hücresi sinapslar, soma, akson ve dendritlerden oluşur. Sinapslar, sinir hücreleri arasındaki elektriksel sinyallerin geçişini sağlayan boşluklardır. Bu sinyaller somaya giderler. Burada işleme tabi tutulduktan sonra oluşan elektriksel sinyal akson yardımıyla dendritlere gönderilir. Yapay sinir ağları biyolojik sinirlerin bu özelliklerinden yararlanılarak geliştirilmiştir.



Şekil 2.2. Biyolojik sinir hücresinin yapısı

Biyolojik sinir ağlarında olduğu gibi yapay sinir ağları da yapay sinir hücrelerinden oluşur. Yapay sinir hücresine her biri diğer sinirlerin çıkışlarını göstermek üzere bir girişler kümesi uygulanmıştır. Her bir giriş ise biyolojik sinirdeki sinaptik dayanımla benzer olarak ağırlıklarla çarpılmıştır. Bütün bu ağırlıklı girişler ise nöronun aktivasyon düzeyini belirlemek için toplanmıştır.

$$\begin{aligned}
 Y_{NET} &= w_1 x_1 + w_2 x_2 + \dots + w_n x_n \\
 &= \sum_{j=1}^n w_j x_j
 \end{aligned}
 \tag{2.1}$$



Şekil 2.3. Yapay sinir modeli


Burada $x_1, x_2, \dots, x_n$ nöron girişleridir. Her bir nöron girişi toplama işlemine girmeden önce $w_1, w_2, \dots, w_n$ ağırlıkları ile çarpılmaktadır. Toplam olarak, girişler X vektörü

ile, ağırlıklar ise W vektörü ile gösterilebilir. Bu durumda Denklem (2.1), vektör notasyonu ile Denklem (2.2)'deki gibi gösterilebilir.


$$Y_{NET} = \vec{W} \cdot \vec{X} \quad (2.2)$$

2.1.3. Aktivasyon fonksiyonları


Transfer veya aktivasyon fonksiyonları, öğrenme eğrisi olarak da adlandırılmaktadır. Aktivasyon fonksiyonları bir YSA'da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla $[0,1]$ veya $[-1,1]$ arasındadır. Ayrıca, yapay sinir ağına bir kutuplama bias değeri uygulanarak aktivasyon fonksiyonu artırılabilir. YSA'larda kullanılacak olan fonksiyonların türevi alınabilir ve süreklilik arz etmesi gerekmektedir. YSA'nın kullanım amacına uygun olarak tek ya da çift kutuplu aktivasyon fonksiyonları kullanılabilir. Lineer veya doğrusal olmayan transfer fonksiyonlarının YSA'larda kullanılması karmaşık problemlere uygulanmasını sağlamıştır. En çok kullanılan aktivasyon fonksiyonları aşağıda gösterilmiştir.



Şekil 2.4. Lineer aktivasyon fonksiyonu



Şekil 2.5. Sigmoid aktivasyon fonksiyonu



Şekil 2.6. Tan-sigmoid aktivasyon fonksiyonu

2.1.4. YSA'nın temel özellikleri

Genellikle bilgi işleme teknikleri seri yapıya sahip olmasına karşın yapay sinir ağları paralel yapıya sahiptirler. Bilgi, katmanlar arasında paralel olarak işlendiğinden işlem hızı yüksektir. Ayrıca, yapay sinir ağındaki işlem elemanlarındaki bir eksiklik ya da işlevini yerine getirememesi durumu hasıl olduğunda, seri yapıya sahip bilgi işleme tekniklerindeki gibi, proses sekteye uğramayacak ve durumu telafi edebilecektir.

Diğer bilgi işleme yöntemlerinde probleme has algoritmaların geliştirilmesi gerekirken yapay sinir ağlarında, elde edilen nitel veya nicel verilerle öğrenme gerçekleştirilebilir. Sistemin davranışı, işlem elemanları arasındaki bağlantılarda saklanır. Bu öğrenme neticesinde ağ, daha önceden sunulmamış girişlere uygun sonuçlar üretebilmektedir.

Yapay sinir ağlarında her bir işlem elemanı problemin tümüyle ilgilenmek yerine kendilerine tahsis edilen müstakil işleri yapmakla yükümlüdür. İşlem elemanları çok basit işlemleri yapmalarına rağmen görev paylaşımı, çok zor problemlerin çözümünü kolaylaştırmaktadır.

Problemlerdeki giriş uzayının geniş olabileceğini düşünürsek, işlem elemanlarındaki lineer olmayan aktivasyon fonksiyonu sayesinde, hem küçük değerlerdeki hem de yüksek değerlerdeki giriş sinyalleri işlenebilmektedir.

2.1.5. Yapay sinir ağı modelleri

Yapay sinir ağları, genel olarak ağın yapısına göre; ileri beslemeli (feed-forward) ve geri beslemeli (feed-back) olarak ikiye, öğrenme kuralına göre; Hebb, Hopfield, Delta ve Kohonen olmak üzere dörde, öğrenme algoritmasına göre; danışmanlı, danışmansız ve takviyeli olmak üzere üçe ve uygulamaya göre de; off-line ve on-line olmak üzere ikiye ayrılabilir. Ayrıca ağırlık matrislerinin simetrik veya asimetrik oluşuna, ağırlık matrisi değerlerinin sabit veya değişken oluşuna, ağda yer alan düğümlerin özelliklerine, kullanılan aktivasyon fonksiyonlarının deterministik veya stokastik oluşuna göre de sınıflandırılabilir. İleri beslemeli ağlar genellikle örüntü tanıma problemlerinde, geri beslemeli ağlar da optimizasyon problemlerinde yaygın olarak kullanılmaktadır.

İleri beslemeli bir ağda, işlem elemanları genellikle katmanlara ayrılmıştır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İşlem elemanları bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak çok katmanlı algılayıcılar (Multilayered Perceptrons-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir. Bu ağlar statik ağlar olarak bilinirler.

Bir geri beslemeli sinir ağı, çıkış ve/veya ara katman çıkışlarını, giriş katmanına veya önceki ara katmanlara geri beslediği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamıştır. Bu ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir.

Öğrenme kuralına göre yapay sinir ağları; Hebb, Hopfield, Delta ve Kohonen olmak üzere dört kısımda incelenebilir:

Hebb kuralının temelinde, “bir nöron diğer bir nörondan giriş alıyorsa ve her iki nöron da aktif ise (matematiksel olarak aynı işarete sahipse), nöronlar arasındaki ağırlıklar kuvvetlendirilir” prensibi vardır.

Hopfield kuralı, zayıflatma veya kuvvetlendirme büyüklüğü dışında Hebb kuralına benzerdir. Eğer istenilen çıkış ve girişin her ikisi aktif veya her ikisi de aktif değilse, öğrenme oranı tarafından, bağlantı ağırlığı artırılır, diğer durumlarda ise azaltılır.

Delta kuralı, en çok kullanılan öğrenme algoritmalarından biridir. Bu kural, nöronun gerçek çıkışı ile istenilen çıkış değerleri arasındaki farkı azaltan, giriş bağlantılarını güçlendiren ve sürekli olarak değiştiren bir düşünceye dayanmaktadır. Bu kural, ortalama karesel hatayı bağlantı ağırlık değerlerinin değiştirilmesiyle düşürme prensibine dayanır. Hata, aynı anda bir katmandan bir önceki katmanlara geri yayılarak azaltılır. Bu kural geri yayılım olarak da bilinir.

Kohonen kuralında, nöronlar öğrenmek için yarışır, kazanan nöronun ağırlıkları güncellenir. En büyük çıkışa sahip işlemci nöron kazanır, bu nöron komşularını uyarma ve yasaklama kapasitesine sahiptir.

Öğrenme algoritmasına göre yapay sinir ağı; danışmanlı, danışmansız ve takviyeli olmak üzere üç kısımda incelenebilir:

Danışmanlı öğrenmede, öğrenme aşamasında YSA'ya, ne öğrenmesi gerektiği örnek bir çıkışla bildirilir. İstenilen çıkış ile gerçek çıkış arasındaki farka (hata) göre, nöronlar arası bağlantıların ağırlığı, en uygun çıkış elde etmek için bir öğrenme algoritmasıyla düzenlenir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri yayılım algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.

Danışmansız öğrenmede, girişe verilen örnekten elde edilen çıkış bilgisine göre, ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmasında, istenilen çıkış değerinin bilinmesine gerek yoktur. Uygulanan girişe göre, bu giriş verileri arasındaki matematiksel ilişkiye göre bağlantı ağırlıkları ayarlanır. Grossberg

tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.

Takviyeli öğrenme kuralı, danışmanlı öğrenme algoritmasının özel bir formudur. Bu algortmada, giriş değerlerine karşı istenilen çıkış değerinin bilinmesine gerek yoktur. YSA'ya bir hedef verilmemekte fakat elde edilen çıkışın verilen girişe karşılık uygunluğunu değerlendiren bir kriter kullanılmaktadır. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya Genetik algoritma, takviyeli öğrenmeye örnektir.

Uygulamaya göre de yapay sinir ağları; off-line ve on-line olmak üzere iki kısımda incelenebilir:


Ağların çoğu için off-line çalışma modu kullanılır. Bu yaklaşımda ağ, farklı bir ortamda eğitilir. Eğitimin sonucunda, elde edilen ağırlıklar ile ağı yapısı, daha sonra on-line uygulamalarda kullanılabilir. Bu aşamada hiçbir öğrenme algoritması kullanılmaz sadece mevcut ağ parametreleri kullanılarak ileri yönde bir hesaplama yapılarak çıkış hesaplanır.

On-line veya gerçek zamanlı öğrenmede, sistem üzerinde bir öğrenme algoritması ve bu yapıyı destekleyen donanım ve yazılımlar mevcuttur. Bu yaklaşım daha çok farklı uygulamaların sıkça kullanıldığı ve öğretilecek sistemin devamlı olarak farklı davranışlar sergilediği uygulamalarda kullanılır [44].

2.1.6. Çok katmanlı ağlar

Yapay sinir ağlarının ilk modellerinden olan tek katmanlı algılayıcı modellerinin en temel özelliği doğrusal problemleri çözebilme yetenekleridir. Bu tip ağlarla doğrusal olmayan problemler öğrenilememektedir. Bu sorunu çözmek için çok katmanlı ağlar geliştirilmiştir. Rumelhart ve arkadaşları tarafından geliştirilen bu modele hata yayma modeli veya geriye yayılım modeli denmektedir. Bu model delta öğrenme kuralını kullanmaktadır. Çok katmanlı ağların yapısı Şekil 2.7'de gösterildiği gibidir.

Çok katmanlı ağlar ileri beslemelidir ve giriş, gizli ve çıkış olmak üzere üç katmana sahiptirler. Giriş ve çıkış katmanları, sinyaller için aynı sayıda sinirlere sahiptir. Gizli katman sayısı için genel olarak bir ölçüt yoktur ve genellikle deneme yanılma ile bulunur.




Şekil 2.7. Çok katmanlı ağ yapısı

Girdi katmanında herhangi bir bilgi işleme olmaz. Girdi katmanındaki her işlem elemanı, bir sonraki gizli katmanda bulunan her işlem elemanı ile bağlantılıdır. Gizli katman, girdi katmanından gelen bilgileri işleyerek çıkış katmanına gönderir. Yine, gizli katmandaki her işlem elemanı, çıkış katmanındaki bütün işlem elemanlarıyla bağlantılıdır. Birden fazla gizli katman olabilir. Çıkış katmanı, gizli katmandan gelen bilgileri işleyerek çıktıları dış dünyaya iletir.

Çok katmanlı ağlar danışmanlı öğrenme prensibine göre çalışır. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Çok katmanlı ağın öğrenme kuralı en küçük kareler yöntemine dayalı delta öğrenme kuralının genelleştirilmiş halidir. O nedenle öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denir. Bu kural iki safhadan oluşur. İlki, ağın çıktısının hesaplandığı ileri doğru hesaplama kısmı, ikincisi ise ağırlıkların değiştirildiği geriye doğru hesaplama kısmıdır.

2.1.6.1. Çok katmanlı ağı eğitilmesi

Katman sayısının fazla olması iyi olmakla beraber hesapsal yükü üssel bir biçimde arttıracığından pratikte genel olarak üç katmanlı ağlar kullanılır. Üç katmanlı bir ağın genel yapısı Şekil 2.8’de gösterilmiştir.



Şekil 2.8. Üç katmanlı yapay sinir ağı

Ara katman çıkışları,

$$\bar{O}_{pk} = f(\bar{b}_k + \sum_{n=1}^N \bar{w}_{kn} x_{pn}) \quad p=1, \dots, P \quad k=1, \dots, K \quad (2.3)$$

Çıkış katmanı, gizli katman çıkışlarını kullanır. Çıkış katmanı çıkışları,

$$O_{pm} = f(b_m + \sum_{k=1}^K w_{mk} \bar{O}_{pk}) \quad p=1, \dots, P \quad m=1, \dots, M \quad (2.4)$$

Herhangi bir veri için hata,

$$E_p = \frac{1}{2} \sum_{m=1}^M (y_{pm} - O_{pm})^2 \quad (2.5)$$

Bütün verileri kapsayan toplam hata,

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M (y_{pm} - O_{pm})^2 \quad (2.6)$$

Çıktı katmanıyla gizli katman arasındaki ağırlık düzeltme miktarları,

$$\begin{aligned} \Delta w_{mk}(t+1) &= -\eta \frac{\partial E}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) \\ &= -\eta \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) = \eta \delta_{pm} \bar{O}_{pk} + \alpha \Delta w_{mk}(t) \end{aligned} \quad (2.7)$$

$$\begin{aligned} \Delta b_m(t+1) &= -\eta \frac{\partial E}{\partial b_m} + \alpha \Delta b_m(t) \\ &= -\eta \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial b_m} + \alpha \Delta b_m(t) = \eta \delta_{pm} + \alpha \Delta b_m(t) \end{aligned} \quad (2.8)$$

Girdi katmanıyla gizli katman arasındaki ağırlık düzeltme miktarları,

$$\begin{aligned} \Delta \bar{w}_{kn}(t+1) &= -\eta \frac{\partial E}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) = \eta \bar{\delta}_{pk} x_{pn} + \alpha \Delta \bar{w}_{kn}(t) \end{aligned} \quad (2.9)$$

$$\begin{aligned} \Delta \bar{b}_k(t+1) &= -\eta \frac{\partial E}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) = \eta \bar{\delta}_{pk} + \alpha \Delta \bar{b}_k(t) \end{aligned} \quad (2.10)$$

Düzeltilme miktarlarının ağırlıklara ilavesi ile ağırlık ve biasların bir sonraki değerleri,

$$\begin{aligned} w_{mk}(t+1) &= w_{mk}(t) + \Delta w_{mk}(t+1) \\ b_m(t+1) &= b_m(t) + \Delta b_m(t+1) \end{aligned} \quad (2.11)$$

$$\begin{aligned} \bar{w}_{kn}(t+1) &= \bar{w}_{kn}(t) + \Delta \bar{w}_{kn}(t+1) \\ \bar{b}_k(t+1) &= \bar{b}_k(t) + \Delta \bar{b}_k(t+1) \end{aligned} \quad (2.12)$$

Gizli ve çıkış katmanında sigmoid transfer fonksiyonu kullanılması durumunda,

$$\begin{aligned} \delta_{pm} &= O_{pm}(1-O_{pm})(y_{pm}-O_{pm}) \\ \bar{\delta}_{pk} &= \bar{O}_{pk}(1-\bar{O}_{pk}) \sum_{m=1}^M \delta_{pm} w_{mk}(t) \end{aligned} \quad (2.13)$$

olarak bulunur.

Yukarıdaki formüllerde kullanılan η öğrenme katsayısı ne kadar büyük olursa ağırlıklardaki değişiklikler de o oranda büyük olmaktadır. Pratik uygulamalar için osilasyona sebep olmayacak en büyük öğrenme katsayısının seçilmesi, öğrenmenin daha hızlı olmasını sağlayacaktır. Osilasyona sebep olmadan öğrenme hızını artırmanın bir yolu, genel delta kuralına bir momentum terimi (α) eklemektir. Bu metot özellikle hata yüzeyini bir minimuma indirgeyen keskin inişler için yararlıdır. Keskin inişte yapılan bir hızlı ilerleme bu minimum düzeyde osilasyonlara sebep olabilir. Buna karşı alınacak önlem küçük adımlarla ilerlemektir. Fakat bu da o keskin iniş boyunca işlemin çok yavaşlamasına sebep olur. Eklenen momentum terimi o bölgedeki keskinliği filtreleyerek daha hızlı olarak ağırlıkların değiştirilmesine olanak verir.

2.1.6.2. Çok katmanlı ağıın çalışma prosedürü

Çok katmanlı ağların çalışması şu adımları içermektedir:

- Örneklerin toplanması: Ağıın çözmesi istenilen olay için daha önce gerçekleşmiş örneklerin bulunması adımıdır. Ağıın eğitilmesi için örnekler toplandığı gibi ağıın test edilmesi için de örneklerin toplanması gerekmektedir. Ağıın eğitilmesi sırasında test seti ağa hiç gösterilmez. Eğitim setindeki örnekler tek tek gösterilerek ağıın olayı öğrenmesi sağlanır. Ağ olayı öğrendikten sonra test setindeki örnekler gösterilerek ağıın performansı ölçülür. Hiç görmediği örnekler karşısındaki başarısı ağıın iyi öğrenip öğrenmediğini ortaya koymaktadır.
- Ağıın topolojik yapısının belirlenmesi: Öğrenilmesi istenen olay için oluşturulacak ağıın topolojik yapısı belirlenir. Kaç tane girdi elemanı, kaç tane gizli katman, her gizli katmanda kaç tane işlem elemanı ve kaç tane çıktı elemanı olması gerektiği bu adımda belirlenmektedir.
- Öğrenme parametrelerinin belirlenmesi: Ağıın öğrenme katsayısı, işlem elemanlarının aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenmektedir.
- Ağırlıkların başlangıç değerlerinin atanması: İşlem elemanlarını birbirine bağlayan ağırlık değerlerinin ve eşik değer ünitesi ağırlıklarının başlangıç değerlerinin atanması yapılır. Başlangıçta genellikle rasgele değerler atanır. Daha sonra ağ uygun değerleri öğrenme sırasında kendisi belirler.
- Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi: Ağıın öğrenmeye başlaması ve yukarıda anlatılan öğrenme kuralına uygun olarak ağırlıkları değiştirmesi için ağa örnekler belirli bir düzeneğe göre gösterilir.
- Öğrenme sırasında ileri hesaplamaların yapılması: Yukarıda anlatıldığı şekilde sunulan girdi için ağıın çıktı değeri hesaplanır.

- Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması: Ağın ürettiği hata değerleri bu adımda hesaplanır.

- Ağırlıkların değiştirilmesi: Yukarıda anlatıldığı gibi geri hesaplama yöntemi uygulanarak üretilen hatanın azalması için ağırlıkların değiştirilmesi yapılır.


Yukarıdaki adımlara, çok katmanlı ağın öğrenmesi tamamlanıncaya, yani gerçekleşen çıktılar ile beklenen çıktılar arasındaki hatalar kabul edilir düzeye gelinceye kadar devam edilir. Ağın öğrenmesi için bir durdurma kriterinin olması gerekmektedir. Bu ise genellikle üretilen hatanın belirli bir düzeyin altına düşmesi olarak alınmaktadır [43].

2.1.7. Radyal tabanlı yapay sinir ağları

Bölüm 2.1.6’da anlatılan çok katmanlı ağlarda, gizli katmandaki işlem elemanlarının aktivasyon fonksiyonları türevleri alınabilen ve girilen değerlere göre sürekli artan türdendir. Bunlar büyük değerlere büyük, küçüklere de küçük işlemci değerleri atayan matematik fonksiyonlarıdır. Bu tür işlemciler bir kümelemenin veya sınıflandırmanın bulunmaması durumlarında kullanılırlar. Ancak verilerde bazı kümelenmelerin bulunması durumunda gizli katmandaki işlem elemanlarının da böyle bir yapıya sahip olması beklenir. Bu tür kümeleme işlemlerine pratikte sık rastlanır. Bu nedenle önceden kümelenmiş verilerle çalışabilen radyal tabanlı yapay sinir ağları (RBNN) geliştirilmiştir [45]. Bu tip ağlarda gizli katmandaki işlem elemanları, girişlerin ağırlıklandırılmış şeklini kullanmamakta ve gizli katmandaki işlem elemanlarının çıkışları, yapay sinir ağı girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir. Radyal tabanlı yapay sinir ağlarının en genel anlamıyla radyal olarak simetrik olan gizli katman işlem elemanları içeren bir yapıdadır.

Radyal olarak simetrik olan gizli katman işlem elemanı için üç bileşen vardır. İlki giriş uzayındaki bir merkez vektörüdür. Bu vektör, giriş ve gizli katman arasındaki ağırlık vektörü olarak saklanır. İkincisi, bir giriş vektörünün merkezden ne kadar uzak olduğunu belirlemek için uzaklık ölçütüdür. Tipik olarak bu ölçüt standart öglit

uzaklığı olarak alınır. Sonuncusu ise, tek değişkenli olan ve uzaklık fonksiyon çıkışını giriş olarak alan işlem elemanının çıkış değerini belirleyen bir aktivasyon fonksiyonu yapısıdır. Diğer bir ifadeyle gizli katman işlem elemanı çıkışı, sadece merkezle giriş vektörü arasındaki uzaklığın bir fonksiyonudur ve çok değişkenli enterpolasyon yaklaşımlarında kullanılan yapay sinir ağı yapılarındandır. İlk katmandaki işlem elemanları girişlerin ağırlıklandırılmış şeklini kullanmaz. İlk katmandaki işlem elemanlarının çıkışları, yapay sinir ağı girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenir. Radyal tabanlı yapay sinir ağı yapılarının son katmanı lineerdir ve ilk katmanın çıkışlarından ağırlıklandırılmış toplam çıkışı üretir.



Şekil 2.9. Radyal tabanlı ağı, gizli katman işlem elemanının yapısı

Genellikle uygulamalarda kullanılan radyal tabanlı ağların yapısı, Moody ve Darken tarafından önerilmiştir. Bu yapıda, gizli katman işlem elemanları, lineer aktivasyon fonksiyonuna sahip çıkış katmanına bütünüyle bağlantılıdır.

İşlem elemanının çıkışı,

$$I_k = \|x - c_k\| = \sqrt{\sum_{i=1}^N (x_i - c_{ki})^2} \quad k = 1, 2, 3, \dots, N \quad (2.14)$$

Nöron çıkışı ise,

$$v_k = e^{-\frac{I_k^2}{\sigma_k^2}} \quad \text{ile ifade edilir.} \quad (2.15)$$

x çok boyutlu giriş vektörü, c giriş vektörü ile aynı boyutta olan merkez vektörünü, σ ise standart sapma değeridir. Gizli katmana işlem elemanlarının eğitilmesi için c_k ağırlıkları ile σ_k genişliklerinin belirlenmesi gerekmektedir.

Radyal tabanlı yapay sinir ağları, çok katmanlı algılayıcı ağlardan daha hızlı öğrenir. Fakat artan girişle, çok yüksek boyutlu radyal tabanlı yapay sinir ağlarına ihtiyaç duyulur. Bu yapılar genellikle sistem modelleme, tahmin ve sınıflandırma gibi problemlerin çözümleri için kullanılırlar.

2.1.8. Olasılıksal yapay sinir ağları (PNN)

Bir diğer ileri beslemeli ağ yapısı ise olasılıksal sinir ağıdır (PNN). Giriş katmanına ek olarak PNN’de iki gizli katman ve bir çıkış katmanı daha bulunmaktadır. Hatanın geriye yayılımı algoritmasıyla eğitilen ileri beslemeli bir ağdan en temel farkı, PNN’nin eğitim setini sadece bir eğitme adımında kullanmasıdır.

PNN bir Bayes-Parzen sınıflandırıcıdır. Bu yaklaşım son çeyrek asra damgasını vurmasına rağmen, temelleri 1960’lara dayanmaktadır. İlk defa Spech tarafından çok sayıda basit işleme uygulanmıştır. Daha sonra paralel işlem gören çok katmanlı ağlara da uygulanmıştır.

Olasılıksal sinir ağlarında bir nörondaki aktivasyon fonksiyonu, eğitim örneklerine dayanan istatistiksel yoğunluk fonksiyonundan (PDF) hesaplanarak türetilmiştir. PNN’nin topolojisini oluşturan katmanlar şöyle şekillendirilirler:

Giriş katmanı m boyutlu giriş vektörü uygulanmak üzere m nörona sahiptir. İlk katman her giriş örneği için bir model oluşturur. İkinci saklı katman her sınıf için bir toplama işlemi gerçekleştirir. Her toplama işlemi bir önceki katmandaki çıkışlardan bir toplam belirlemek amacıyla kullanılır. Çıkış katmanı, toplamın çıkışlarından en yüksek olasılığı seçerek karar kuralını uygulamak için oluşturulan katmandır. Bu karar katmanı “kazanan alır” ağları ile kurulabilir [46].

2.1.9. Sezgisel ve ileri seviyeli eğitim algoritmalar

Geri yayılım öğrenme kuralı en genel anlamıyla, her bir katmandaki toplam karesel hatanın gradyeninin tahminine dayalı, gradyen azaltım algoritmasıdır.

$$\Delta W(n) = -\eta \nabla E(n) = \eta \delta(n) X^T(n) \quad (2.16)$$

Bu algoritma 2 sebepten dolayı yavaş işler:

- Her bir iterasyonda ortalama karesel hatayı ($J(W)$) minimize etmek için toplam karesel hatayı ($E(W,n)$) kullanır. Ortalama karesel hatanın gradyeni, toplam karesel hatanın gradyeninden iyi bir şekilde tahmin edilemez. Bundan dolayı daha fazla iterasyona gereksinim duyar.
- Birinci mertebe minimizasyon algoritması olduğundan, birinci mertebeden türevlerden oluşur (gradyen). Oysa hızlı algoritmalar ikinci mertebeden türevleri (Hessian matrisi) de içerirler.

Algoritmanın yapısından dolayı, yerel minimumlara takılma eğilimindedir. Bir momentum terimi eklenmesiyle iyileştirme yapılabilir:

Ağırlıkların değişim miktarı,

$$\Delta W(n) = \eta \delta(n) X^T(n) + \alpha \Delta W(n-1), 0 < \alpha < 1 \quad (2.17)$$

olarak bulunur. Bu parametrenin eklenmesi algoritmaya, alçak geçiren filtre özelliği kazandırır.

2.1.9.1. Adaptif öğrenme katsayısı

Yakınsama hızını arttırmanın bir yolu da değişken öğrenme katsayısı kullanmaktır. Bu algoritmanın temelinde, ortama karesel hatanın değişim oranını gözlemlenmesi

vardır. Eğer ortalama karesel hatada (J) azalma varsa, ∇J negatiftir. Bu durumda öğrenme katsayısı doğrusal olarak artırılır,

$$\eta(n+1) = \eta(n) + a, \quad a > 0 \quad (2.18)$$

Eğer hata arttıysa ($\nabla J > 0$), öğrenme katsayısı oransal olarak azaltılır,

$$\eta(n+1) = b.\eta(n), \quad 0 < b < 1 \quad (2.19)$$

Öğrenme katsayısındaki artış neticesinde öğrenme, kararlı halden uzaklaşmaya başlar ve hata fonksiyonu artar. Bundan dolayı öğrenme katsayısının hızlı bir biçimde azaltılması önemlidir [44].

2.1.9.2. Newton metodu

Newton'un minimizasyon metodu, performans kriterinin ikinci türevlerinden yararlanılması esasına dayalıdır. Performans fonksiyonunun (ortalama karesel hata) Taylor serisine açılımı,

$$J(W_{n+1}) = J(W) + \Delta W \cdot \nabla J + \frac{1}{2} \Delta W \cdot H \cdot \Delta W^T + \dots \quad (2.20)$$

$J(W_{n+1})$ 'i minimize etmek için gradyeni alınır ve sıfıra eşitlenirse,

$$\nabla J(W_{n+1}) = \nabla J + \Delta W \cdot H + \dots = 0 \quad (2.21)$$

ve yüksek mertebeli terimler ihmal edilirse,

$$\Delta W = -\nabla J \cdot H^{-1} \text{ olur.} \quad (2.22)$$

Denklem (2.22)'nin, Hessian'ının tersiyle modifiye edilmiş olan J 'nin gradyeni sayesinde, daha iyi ağırlık güncellemesi yaptığı söylenebilir. Hessian matrisi, ağırlık

vektörlerinin yakın civarında, performans fonksiyonunun yüzeyinin şekli hakkında ek bir bilgi içerir.

Newton'un metodu, Conjugate-Gradient algoritmalarından (Bkz. Bölüm 2.1.9.6) daha hızlıdır. Buna karşılık, Hessian matrisinin tersinin hesaplanması dolayısıyla nispeten daha karmaşıktır.

Bir çok spesifik algoritmanın temelinde Newton'un metodu vardır. En hızlı ve en popüler olan Levenberg-Marquardt algoritmasının orijininde de Gauss-Newton metodu vardır [44].

2.1.9.3. Gauss-Newton metodu

Tüm ağırlıklar satır vektörü olarak düşünülürse,

$$W = [W_1 \dots W_j \dots W_k] \quad (2.23)$$

Anlık hata da sütun vektörü olarak düşünülürse,

$$e(W, n) = d(n) - y(n) = [\varepsilon_1 \dots \varepsilon_k \dots \varepsilon_m]^T \quad (2.24)$$

Anlık performans fonksiyonu $E(W, n)$, hataların karelerinin toplamıdır,

$$E(W, n) = \frac{1}{2} \cdot \sum_{k=1}^m \varepsilon_k^2(n) = \frac{1}{2} \cdot \varepsilon(n) \cdot \varepsilon^T(n) \quad (2.25)$$

Toplam performans $J(W)$ (Ortalama karesel hata),

$$J(W) = \frac{1}{M} \cdot \sum_{n=1}^N E(W, n), \quad M = mN \quad \text{olur.} \quad (2.26)$$

Anlık hatanın birinci türevleri düşünülürse, anlık gradyen vektörünün j . bileşeni,

$$\begin{aligned} [\nabla E(W, n)]_j &= \frac{\partial E(W, n)}{\partial W_j} = \sum_{k=1}^m \varepsilon_k(W) \cdot \frac{\partial \varepsilon_k(W)}{\partial W_j} \\ &= \varepsilon^T(W) \cdot \left[\frac{\partial \varepsilon_1(W)}{\partial W_j} \dots \frac{\partial \varepsilon_M(W)}{\partial W_j} \right]^T \end{aligned} \quad (2.27)$$

olarak bulunur.

Eşitlik (2.27), gradyen için matrisel formda genelleştirilirse,

$$\nabla E(W, n) = \varepsilon^T(W, n) \cdot J(W, n) \text{ olur.} \quad (2.28)$$

$$\text{Eşitlik (2.28)'de } J(W, n) = \begin{pmatrix} \frac{\partial \varepsilon_1(W)}{\partial W_1} & \dots & \frac{\partial \varepsilon_1(W)}{\partial W_k} \\ \vdots & & \vdots \\ \frac{\partial \varepsilon_m(W)}{\partial W_1} & \dots & \frac{\partial \varepsilon_m(W)}{\partial W_k} \end{pmatrix} \text{ birinci mertebeden türevleri}$$

içeren Jacobian matrisidir.

Anlık performans fonksiyonunun Hessian matrisini bulmak için Eşitlik (2.28)'den faydalanılırsa,

$$\nabla^2 E(W, n) = \frac{\partial}{\partial W} (\varepsilon^T(W) \cdot J(W)) \text{ olur.} \quad (2.29)$$

Daha kolay anlaşılması bakımından, Hessian matrisinin k,j bileşeni hesaplanırsa,

$$[\nabla^2 E(W,n)]_{k,j} = \frac{\partial^2 E(W)}{\partial W_k \partial W_j} = \sum_{i=1}^M \left(\frac{\partial \varepsilon_i}{\partial W_k} \cdot \frac{\partial \varepsilon_i}{\partial W_j} + \frac{\varepsilon_i \cdot \partial^2 \varepsilon_i}{\partial W_k \partial W_j} \right)$$

$$= \left[\frac{\partial \varepsilon_1}{\partial W_k} \dots \frac{\partial \varepsilon_M}{\partial W_k} \right] \cdot \begin{bmatrix} \frac{\partial \varepsilon_1}{\partial W_j} \\ \vdots \\ \frac{\partial \varepsilon_M}{\partial W_j} \end{bmatrix} + \varepsilon^T \cdot \frac{\partial^2 \varepsilon_i}{\partial W_k \partial W_j} \quad (2.30)$$

Eşitlik (2.30) matrisel formda genelleştirilirse,

$$\nabla^2 E(W) = J^T(W) \cdot J(W) + \varepsilon^T(W) \cdot R(W), \quad R(W) = \left\{ \frac{\partial^2 \varepsilon_i}{\partial W_k \partial W_j} \right\} \quad (2.31)$$

Hata küçük olduğundan $\varepsilon^T(W) \cdot R(W)$ terimi ihmal edildiğinde Gauss-Newton metodu elde edilir [44],

$$H(W,n) = \nabla^2 E(W,n) \approx J^T(W,n) \cdot J(W,n) \quad (2.32)$$

Ağırlık değişim miktarını Eşitlik (2.22)'den yararlanılarak bulunabilir,

$$\Delta W(n) = -\varepsilon^T(n) \cdot J(n) \cdot (J^T(n) \cdot J(n))^{-1} \quad (2.33)$$

2.1.9.4. Levenberg-Marquardt algoritması

Temel olarak bu algoritma, maksimum komşuluk fikri üzerine kurulmuş bir en küçük kareler hesaplama metodudur. Bu algoritma, Gauss-Newton ve Steepest-Descent (Geri Yayılım) algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını ortadan kaldırır. Genel olarak bu metot yavaş yakınsama problemlerinden etkilenmez.

Gauss-Newton metodunda karşılaşılan problemlerden biri yaklaşık Hessian matrisinin tersinin hesaplanamaması durumudur. Bu problemin üstesinden gelmek için Levenberg-Marquardt algoritmasında Hessian matrisine küçük bir μ sabiti eklenir,

$$H(W) = J^T(W).J(W) + \mu I \quad (2.34)$$

Burada, $H(W)$ Hessian matrisi, $J(W)$ Jacobian matrisi, I birim matris ve μ de küçük bir sabit sayıdır. Ağırlıkların güncellenmesi Gauss-Newton metodunun ufak bir modifikasyonuyla aşağıdaki gibi hesaplanır,

$$\Delta W = -\varepsilon^T(W).J(W).(J^T(W).J(W) + \mu I)^{-1} \quad (2.35)$$

Bu algoritmanın çalışması şu şekilde özetlenebilir:

- (i) Performans fonksiyonu hesaplanır,
- (ii) Küçük bir μ değeriyle başlanır ($\mu=0.01$),
- (iii) ΔW hesaplanarak, performans fonksiyonunun bir sonraki değeri hesaplanır,
- (iv) Performans fonksiyonunun bir sonraki değeri, şimdiki değerinden büyükse μ 10 kat artırılır,
- (v)) Performans fonksiyonunun bir sonraki değeri, şimdiki değerinden küçükse μ 10 kat azaltılır,
- (vi) Ağırlıklar güncellenir ve (iii) adımına gidilir.

Kısaca, ağırlıklara başlangıç değerleri atanır ve hataların karelerinin toplamının hesaplanmasıyla devam edilir. Her hata terimi, hedef çıkış ile gerçek çıkış arasındaki farkın karesini ifade eder. Bütün veri seti için hata terimlerinin tamamının elde edilmesiyle, ağırlık vektörü (i)'den (v)'e kadar olan Levenberg-Marquardt metodu adımlarının uygulanmasıyla adaptasyon sağlanır [44].

2.1.9.5. Esnek yayılım (Resilient Propagation) algoritması

Çok katmanlı algılayıcılarda, genellikle ara katmanlarda sigmoid transfer fonksiyonu kullanılır. Sonsuz genişlikteki bir aralıkta yer alan giriş değerlerini sınırlı bir aralığa sıkıştırıldığı için bu fonksiyonlar sıkıştırıcı fonksiyonlar olarak adlandırılmaktadır. Sigmoid fonksiyonlarının eğimleri, çok büyük giriş değerleri için sıfıra yakınsayacak şekilde karakterize edilirler. Bu ise ağırlık ve bias değerleri henüz optimum değerlere erişmemişken çok katmanlı YSA'da sigmoid transfer fonksiyonlarının kullanılmasından dolayı eğitim değerinin çok yavaş değişebilme olasılığı karşısında, yüksek eğitim azaltma ile öğrenmede problemlere neden olur [44].

Bu öğrenme algoritmasının amacı kısmi türevlerin olumsuz etkilerini öğrenme sürecinden uzaklaştırmaktır. Bu algoritma Riedmiller ve Braun tarafından 1993 yılında geliştirilmiştir. Ağırlıkların güncelleştirme yönü için sadece türevlerin işaretleri kullanılır. Ağırlıkların güncelleştirilmesinde türev değerinin alınmaması bu algoritmayı diğerlerinden ayıran en önemli özelliktir. Bu özelliği esnek yayılıma, hızlı çözüme ulaşma yeteneği kazandırmıştır.

Ağırlıkların değişimi, her adımda hata fonksiyonu $E(k)$ 'nin ağırlık değişim değeri $A_{ji}(k)$ 'nın bulunmasıyla başarılır. Ağırlıkların değişimi ise,

$$\Delta W_{ji}(k) = \begin{cases} -A_{ji}(k), & \text{Eğer } B(k) > 0 \\ +A_{ji}(k), & \text{Eğer } B(k) < 0 \\ 0, & \text{Aksi halde} \end{cases} \quad (2.36)$$

ile hesaplanır. Burada $B(k) = \frac{\partial E}{\partial W_{ji}}(k)$ ile hesaplanır. $A_{ji}(k)$ ise,

$$A_{ji}(k) = \begin{cases} \eta A_{ji}(k-1), & \text{Eğer } B(k-1).B(k) > 0 \\ \mu A_{ji}(k-1), & \text{Eğer } B(k-1).B(k) < 0 \\ A_{ji}(k-1), & \text{Aksi halde} \end{cases} \quad (2.37)$$

Burada $B(k-1) = \frac{\partial E}{\partial W_{ji}}(k-1)$, η ve μ sırasıyla $0 < \mu < 1 < \eta$ arasında artma ve azaltma faktörleridir.

Ardışık iki iterasyonda, performans fonksiyonu ile türev işaretleri aynı ise her bir ağırlık ve bias değeri için güncelleme faktörü değeri, birden büyük bir katsayı ile çarpılır. Eğer farklı işaretler söz konusu ise güncelleme faktörü değeri birden küçük bir katsayı faktörü kadar azaltılır. Türev değeri sıfır ise güncelleme değeri sabit kalır. Ağırlıklar salınım yaptığında, ağırlık değişimi azalacaktır. Eğer ağırlıklar birkaç iterasyon boyunca aynı yönde değişim gösterirse ağırlık değişimi artar. Bu öğrenme algoritması genel olarak standart yüksek eğim azaltma algoritmalarından çok hızlıdır. Hafızada eski değerlerin saklanması gerektirmez.

2.1.9.6. Eşleştirmeli eğim (Conjugate-Gradient) algoritmaları

Geri yayılım algoritması ağırlık değerlerini, eğimin negatifi yönünde dengeler. Bu doğrultu eğimin hızla düştüğü doğrultu olarak bilinir. Bu doğrultuda performans fonksiyonu da hızla düşer. Performans fonksiyonundaki hızlı düşüş, ağırlık hızla yakınsamasını sağlamayabilir. Conjugate-Gradient algoritmalarında, eğim azaltım yöntemindeki doğrultulardan genellikle daha hızlı yakınsayan eşleştirme doğrultularındaki bir arama işlemi yapılır [44].

Eğim azaltımlı öğrenme algoritmalarında global minimuma doğru olan ağırlık güncellemesindeki adım oranını belirleyen bir öğrenme oranı parametresi kullanılmaktadır. Eşleştirmeli eğim algoritmasında adım boyutu, her bir iterasyonda yeniden güncellenir. Performans fonksiyonunun o doğrultu boyunca minimize edileceği adım boyutunu belirlemek için, eşleştirmeli eğim doğrultusu boyunca bir arama gerçekleştirilir.

Literatürde mevcut olan eşleştirmeli eğim algoritmalarının farklı varyasyonları aşağıda özetlenmiştir.

Fletcher-Reeves eşleştirmeli eğim algoritmalarında ilk iterasyon, negatif eğim değeriyle belirlenen doğrultuda arama işlemiyle başlar,

$$p_0 = -g_0 \quad (2.38)$$

Mevcut arama doğrultusu boyunca gidilecek optimum mesafenin belirlenmesi için bir doğrultu araması gerçekleştirilir,

$$X_{k+1} = X_k + \alpha_k p_k \quad (2.39)$$

Daha sonra bir önceki arama doğrultusuyla eşleştirilmek üzere yeni arama doğrultusu belirlenir. Yeni arama doğrultusunun belirlenmesinde uygulanan genel yöntem bir önceki arama doğrultusu ile yeni eğim arama doğrultusunu doğrusal olarak birleştirmektir,

$$p_k = g_k + \beta_k p_{k-1} \quad (2.40)$$

Burada β_k skaler değeri p_k ve p_{k-1} doğrultularının Hessian matrisine (performans fonksiyonunun ikinci mertebeden türevleri) göre birbirine eşleştirmeli olacak şekilde seçilmesiyle elde edilir.

Fletcher-Reeves'in β_k için önerdiği güncelleme yaklaşımı Eşitlik (2.41)'de verilmiştir.

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad (2.41)$$

Bu ise mevcut eğimin norm karesinin bir önceki eğimin norm karesine oranıdır. Eşleştirmeli eğim algoritmaları genel olarak değişken değerli öğrenme oranına sahip geri yayılım algoritmalarından daha hızlıdır. Genellikle sonucun problemde farklı olabilmesine karşın esnek öğrenmeden de hızlı oldukları

söylenebilir. Eşleştirmeli öğrenme algoritmaları basit algoritmalara nazaran çok daha az hafızaya ihtiyaç duyarlar. Çok sayıda ağırlığın söz konusu olduğu YSA yapılarında kullanımları son derece uygundur.

Polak-Ribiere eşleştirmeli eğim algoritmasında, her bir iterasyondaki arama doğrultusu Fletcher-Reeves yöntemindeki Eşitlik (2.40) ile aynıdır. Bu denklemdeki β_k ifadesi,

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{g_{k-1}^T g_{k-1}} \quad (2.42)$$

olarak değiştirilerek, bir önceki iterasyondaki eğim değişiminin mevcut iterasyondaki yeni eğim değeriyle olan iç çarpımının önceki eğimin norm karesiyle bölümü ile elde edilir. Önceki yöntemden daha fazla hesaplamaya ihtiyaç olmasına rağmen performans olarak hangisinin daha iyi olduğunu söylemek zordur. Bu yöntemin hafıza ihtiyacı Fletcher-Reeves yönteminden oldukça fazladır.

Tüm eşleştirmeli eğim algoritmalarında arama doğrultusu, periyodik olarak eğimin negatif olarak oluşturulur. Normalde, algoritma iterasyon sayısı, ağ parametre sayısına (ağırlık ve bias) eşit olduğu zaman standart ilk değere dönme noktası oluşur. Bununla beraber eğitimin etkinliğini artırabilecek başka geri döndürme yöntemleri de mevcuttur. Powell-Beale yöntemi bunlardan biridir. Bu yöntemde eğer bir önceki eğim değeriyle o andaki eğim değeri arasında çok az ortogonalite varsa geri başlatım işlevi gerçekleşir. Bu koşul,

$$\left| g_{k-1}^T g_k \right| \geq 0.2 \|g_k\|^2 \quad (2.43)$$

eşitliği ile test edilir. Bu koşulun sağlanması durumunda arama doğrultusu eğimin negatifine geri döndürülür. Powell-Beale öğrenme algoritması bazı problemlerde Polak-Ribiere'den daha iyi sonuç verebilmektedir. Fakat algoritmanın hafıza ihtiyacı Polak-Ribiere'den biraz daha fazladır.

Eşleştirmeli eğim algoritmaları her bir iterasyonda doğrultu arama işlemi gerektirmektedir. Bu işlem, her bir arama işleminde ağ giriş verilerine karşı ağın ürettiği çıkışların hesaplanmasını gerektirdiği için işlemsel olarak yoğundur. Moller tarafından geliştirilen Ölçeklendirilmiş Eşleştirmeli Eğim Algoritması zaman alıcı bir arama işleminden kaçınacak şekilde dizayn edilmiştir. Eşleştirmeli eğim algoritmasıyla Levenberg-Marquardt algoritmasında kullanılan model güvenilir alan yönteminin birleştirilmesidir. Adım büyüklüğü,

$$\alpha_k = -\frac{p_k^T g_k}{p_k^T A_k p_k + \lambda_k \|p_k\|^2} \quad (2.44)$$

ile belirlenir. Ölçekleme parametresi λ 'nın yeteri kadar büyük seçilmesiyle Hessian matrisinin pozitif tanımlı olması sağlanır. Bu parametrenin optimal değeri iterasyondan iterasyona değişir. Bu parametrenin değeri büyüdükçe öğrenme oranı (adım büyüklüğü) küçülür. Bu yöntem model-güvenilir bölge olarak adlandırılır. Çünkü model sadece mevcut arama noktası etrafındaki küçük bir bölgede etkin olarak güvenilirdir. Güven bölgesinin büyüklüğü λ parametresiyle kontrol edilir. Eğer $\lambda = 0$ ise ağırlık vektörü arama doğrultusu boyunca minimum doğru yaklaşır ve hata fonksiyonu kuadratik bir fonksiyonla ifade edilebilir ve payda pozitif olur. Eğer bu şartlar sağlanmazsa λ değerinin uygun olarak arttırılması gerekmektedir. İlk olarak Hessian matrisinin pozitif tanımlı olmaması durumunda eşitlik, $-p_k^T A_k p_k$ terimine bölünür. Yerel kuadratik yakınsamanın doğruluğu,

$$\Delta_k = \frac{E(W_k) - E(W_k + \alpha_k p_k)}{E(W_k) - (E(W_k) + \alpha_k p_k^T g_k + \frac{1}{2} \alpha_k^2 p_k^T g_k)} \quad \text{ile belirlenir.} \quad (2.45)$$

Eğer, Eşitlik (2.45)'te bulunan değer 1'e yakınsarsa yakınsama iyidir ve λ değeri azaltılabilirken tersi bir durumda λ değeri arttırılabilir. λ_k değeri Eşitlik (2.46)'daki şartlara göre güncellenebilir,

$$\begin{aligned}
\Delta_k > 0.75 \text{ ise } \lambda_{k+1} &= \frac{\lambda}{2} \\
\Delta_k < 0.25 \text{ ise } \lambda_{k+1} &= 4\lambda_k \\
\text{veya} \quad \lambda_{k+1} &= \lambda_k
\end{aligned} \tag{2.46}$$

Eğer $\Delta_k < 0$ ise hatada bir artış olacak ve ağırlıklar güncellenmeyecektir. Bunun yerine Δ_k değerlendirilir. Sonunda algoritma yeterince geniş bir λ_k değeri için eğimin negatifi yönünde küçük bir adım ilerleyeceği için hata azaltımı elde edilecektir. Birbirini izleyen her bir ağırlık güncellemesinden sonra Eşitlik (2.46)'daki payda artışının pozitif olmasını sağlayan λ_k 'nin artırılma aşamaları ve yerel eğim yakınsamasının doğruluğuna uygun olarak λ_k 'nin güncellenmesi uygulanacaktır. Bu öğrenme algoritmasında bir doğru üzerinde arama işlemi bulunmadığından hesap yükü azdır. Buna karşın iterasyon sayısı diğer eşleştirmeli eğim algoritmalarından daha fazladır. Hafıza ihtiyacı Fletcher-Reeves ile yaklaşık aynıdır [44].

2.2. Bulanık Mantık

Bulanık mantık kavramı, ilk olarak 1965 yılında L.Zadeh tarafından kullanılmıştır. Bulanık mantık kavramı genel olarak insanın düşünme biçimini modellemeye çalışır. Bulanıklığın, genel olarak kesinlik içermeyen bilgiyi başka bir deyişle belirsizliği ifade ettiği söylenebilir. Bulanık mantık ise, sözel değişkenler kullanarak kesinlikler yerine belirsizliklerle çalışan bir yapay zeka tekniği olarak tanımlanabilir. Sözel bir değişkenin tipik değeri örneğin, “sıcak” veya “soğuk” gibi sözcüklerle ifade edilir ve bulanık kümelerin üyelik fonksiyonları ile temsil edilir. Bulanık mantığın klasik matematiksel yöntemlerden farkı, kesinliklerle çalışmaması ve niteliksel tanımlamalara olanak sağlamasıdır. Belirsizliklerin matematiksel olarak ifade edilebilmesi, karmaşık sistemlerin modellenmesine bulanık mantığın getirdiği en büyük kolaylık olarak değerlendirilir [47].

Klasik küme kavramında bir üye, bir kümenin üyesidir veya üyesi değildir. Bulanık mantık, bulanık küme teorisine dayanmaktadır. Bulanık küme teorisi genel bir matematiksel yaklaşımdır. Bu yaklaşım ile çözülmesi güç olan problemler genel bir


yapıya kavuşturularak daha kolay bir sonuca gidilir. Bulanık küme teorisi, bilinen klasik küme teorisinin genel halidir. Bulanık mantık kavramında bir üyenin bir kümenin üyesi olup olmadığı üyelik fonksiyonları ile belirlenir. Bu kavram ile bulanık mantığın kullandığı çıkarım yöntemleri kullanılarak olaylar hakkında yorum yapmaya çalışılır. Buradan, bulanık kümelerin nesnel değil öznel olduğu sonucu çıkarılabilir. Bulanık küme teorisi kısmi üyeliğe izin veren bir mantık sistemidir. Yani bir kümenin tam üyeliği ile o kümenin üyesi olmama durumları arasında derece derece geçişine izin verir. Verilen bir elemanın bir kümede kısmi üyeliğinin bulunması demek, aynı zamanda bu elemanın bu kümenin üyesi olmama durumunun da kısmen başlaması demektir. Çünkü bulanık küme teorisi, hem tam üyeliğe hem de hiç üye olmamaya izin verir. İşte bundan dolayı bulanık küme teorisi, klasik küme teorisinin genelleştirilmiş bir halidir denilebilir [11].

2.2.1. Üyelik fonksiyonu ve türleri

Bulanık kümedeki nesnenin üyelik derecesi, öznel olarak tanımlı üyelik fonksiyonuyla verilir. Bir nesnenin üyelik derecesinin değeri 0 ile 1 arasında değişir. Burada 1'in değeri tam üyeliği gösterir, 0'a yakın değer ise bulanık kümedeki nesne üyeliğinin zayıf olduğunu belirtir. Dolayısıyla değeri 0 olan nesne bulanık kümenin üyesi değildir.

Bulanık mantık terminolojisinde sıklıkla kullanılan üyelik fonksiyonu türleri; üçgen, trapez ve çan biçimli üyelik fonksiyonlarıdır.


Üçgen üyelik fonksiyonunun matematiksel ifadesi $\{a,b,c\}$ parametreleriyle Eşitlik (2.47)'deki gibi tanımlanmaktadır. Şekil 2.10'da üçgen üyelik fonksiyonu ve parametreleri görülmektedir.



Şekil 2.10. Üçgen üyelik fonksiyonu

$$f(x, a, b, c) = \begin{cases} 0 & , x \leq a \\ \frac{x-a}{b-a} & , a \leq x \leq b \\ \frac{c-x}{c-b} & , b \leq x \leq c \\ 0 & , c \leq x \end{cases} \quad (2.47)$$


Trapez üyelik fonksiyonunun matematiksel ifadesi $\{a, b, c, d\}$ parametreleri ile Eşitlik (2.48)'deki gibi tanımlanmaktadır. Şekil 2.11'de trapez üyelik fonksiyonu ve parametreleri görülmektedir.



Şekil 2.11. Trapez üyelik fonksiyonu

$$f(x, a, b, c) = \begin{cases} 0 & , x \leq a \\ \frac{x-a}{b-a} & , a \leq x \leq b \\ 1 & , b \leq x \leq c \\ \frac{d-x}{d-c} & , c \leq x \leq d \\ 0 & , d \leq x \end{cases} \quad (2.48)$$

Çan biçimli üyelik fonksiyonunun matematiksel ifadesi $\{a, b, c\}$ parametreleri ile Eşitlik (2.49)'daki gibi tanımlanmaktadır. Şekil 2.12'de çan biçimli üyelik fonksiyonu ve parametreleri görülmektedir.




Şekil 2.12. Çan biçimli üyelik fonksiyonu

$$f(x, a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (2.49)$$

Eşitlik (2.49)'da b pozitif seçilir ve a 'ya bağlı olarak çapraz geçiş noktalarının eğimleri değişir, c ve a parametreleri sırası ile üyelik fonksiyonunun merkez noktasını ve genişliğini belirler.

Bir x noktasının, A bulanık kümesindeki üyelik derecesi $\mu_A(x)$ ile gösterilir. $\mu_A(x)=1$ konumu x 'in A bulanık kümesine ait kesin bir elemanı olduğunu gösterir. $\mu_A(x)=0$ konumu ise, x 'in A bulanık kümenin dışında olduğunu gösterir. $0 < \mu_A(x) < 1$ arasındaki her değer, x 'in A bulanık kümesinin belirsiz bir değeridir. Örneğin bir ortamın sıcaklığı “Soğuk”, “Ilık” ve “Sıcak” dilsel ifadeleriyle Şekil 2.13'teki gibi tanımlanabilir. Eğer ortamın sıcaklığı -20°C ise sıcaklık, “Soğuk” bulanık kümesine girecektir. Ortamın sıcaklığı 21°C ise sıcaklık, “Ilık” bulanık kümesine 0,6 oranında aynı zamanda “Sıcak” bulanık kümesine 0,2 oranında üye olacaktır.



Şekil 2.13. Ortamın sıcaklığını gösteren üyelik fonksiyonları

2.2.2. Bulanık kümelerde işlemler

A ve B, iki bulanık küme olduğu varsayılın. μ_A 'yı A'nın ve μ_B 'yi de B'nin üyelik fonksiyonları olduğunu kabul edildiğinde bulanık kümeler için birleşim, kesişim ve değil küme işlemleri aşağıdaki şekilde tanımlanır:

Birleşim:

$$\mu_{A \cup B}(x) = \max \{ \mu_A(x), \mu_B(x) \} \quad (2.50)$$

Kesişim:


$$\mu_{A \cap B}(x) = \min \{ \mu_A(x), \mu_B(x) \} \quad (2.51)$$

Değil:

$$\mu_{\ominus}(x) = \{ 1 - \mu_A(x) \} \quad (2.52)$$

2.2.3. Bulanık mantığa dayalı sistemlerin temel yapısı

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



Şekil 2.14. Bulanık küme tabanlı bir sistemin genel yapısı

Bulanıklaştırma birimi, giriş bilgilerini önceden belirlenmiş üyelik fonksiyonlarını kullanarak uygun sözel değerlerden oluşan bulanık ifadelerle dönüştürür. Kural tabanı, uzman kişinin kontrol yöntemini “Eğer-İse” (If-Then) kuralları şeklinde ifade eden, bulanık kurallar kümesinden oluşur. Çıkarım ünitesi, bulanıklaştırıcı çıkışı kural tabanındaki bulanık kurallar ile eşleştirir ve bulanık uygulamayı gerçekleştirecek uygun bir yorumlama yaptıktan sonra bulanık bir kontrol davranışına karar verir. Berraklaştırıcı, kontrol edilen sisteme uygulayabilmek için sayısal kontrol işaretine çevirir. Bulanık mantık kontrolörünün tasarımıadaki en önemli sorun, bulanık mantık kuralları ve uygun üyelik fonksiyonlarının tanımlanmasıdır [48].

2.2.3.1. Bulanıklaştırma

Bulanık sistemlerde, sözel değişkenlerin tipik değerleri bulanık alt kümelerle temsil edilir ve her alt küme bir üyelik fonksiyonu ile ifade edilir. Örneğin, elemanları x olan evrensel bir X kümesinin, A bulanık alt kümesine aitliği üyelik fonksiyonları ile belirlenir ve $\mu_A(x)$ üyelik fonksiyonu olmak üzere aşağıdaki şekilde ifade edilir,

$$\mu_A(x):X \rightarrow [0,1]$$

Üyelik fonksiyonunun değeri, x için A bulanık alt kümesine aitlik derecesini verir ve böylece bulanık kümeler yardımıyla, klasik küme teorisinin aksine, kısmi üyelik dereceleri tanımlanabilmektedir. Üyelik fonksiyonları genellikle üçgen, trapez ve çan biçimli olarak seçilmektedir (Bkz. Bölüm 2.2.1).

2.2.3.2. Bulanık mantık kural tabanı

Bulanık bir sistem çoğunlukla birçok kuralı içeren bir kural tabanına sahiptir. Sistem içinde yer alan bulanık kuralların tümü ise bulanık kural tabanını meydana getirir. Bir bulanık kural A ve B , sırasıyla E ve F evrensel kümelerinde bulanık kümeler olarak tanımlanan sözel değerlerse $x \in E$ ve $y \in F$ olmak üzere genel olarak şu şekildedir:

Eğer $x \in A$ ise, O halde $y \in B$ 'dir.

Bulanık kuralın ilk kısmında yer alan sözel değişken sayısının birden fazla olması durumunda değişkene ait ifade VE ya da VEYA operatörleri kullanılarak birbirine bağlanır; aynı operatörler kuralları birbirine bağlamakta da kullanılan operatörlerdir.

2.2.3.3. Bulanık mantık çıkarım yöntemleri


Bulanık çıkarım sisteminin temel yapısı üç kısımdan oluşur: Bulanık kuralların seçimini içeren “kural tabanı”, bulanık kurallarda kullanılan üyelik fonksiyonlarının bilgilerini içeren “veri tabanı” ve kurallar doğrultusunda verilen koşullara bağlı olarak çıkışları belirleyen “yargılama mekanizması”. Literatürde en çok Mamdani ve Sugeno bulanık çıkarım sistemlerinin bahsi geçmektedir.

Mamdani bulanık çıkarım sisteminde; A_i, B_i, C_i sırasıyla $i=1,2$, $e \in E$, $f \in F$ ve $g \in G$ için E, F ve G 'de tanımlanmak üzere iki tane bulanık denetim kuralı aşağıdaki gibi ifade edilebilir;

Eğer $e \in A_1$ ve $f \in B_1$ ise $g \in C_1$

Eğer $e \in A_2$ ve $f \in B_2$ ise $g \in C_2$

Sözel değişkenler (e, f ve g) arasındaki ilişki genelleştirilmiş bulanık ilişkiye bağlı olarak ve maksimum-minimum operatörleri kullanılarak tanımlanır.



Şekil 2.15. Mamdani bulanık çıkarım yöntemi

Her bir kuralın koşul kısmında minimum operatörü ve iki kuralı birleştirmek için de maksimum operatörü kullanılmış ve bu durum Şekil 2.15'te özetlenmiştir.

Temel bulanık çıkarım sistemi, bulanık veya kesin girişleri alabilir fakat çıkışlar daima bulanık kümelerdir. Bazen, özellikle bulanık çıkarım sisteminin denetleyici olarak kullanıldığı durumlarda, kesin çıkışlara gereksinim vardır. Bu nedenle, kesin bir değer çıkartmak için bir berraklaştırma yöntemine ihtiyaç duyulmaktadır.

Sugeno bulanık çıkartım sistemi, Takagi, Sugeno ve Kang tarafından [30], verilen giriş-çıkış veri kümelerinden bulanık kuralların oluşturulması yaklaşımı için önerilen bir yöntemdir. Sugeno bulanık çıkartım sisteminde kullanılan bulanık kural yapısı aşağıdaki gibi ifade edilebilir;

Eğer $e \in A$ ve $f \in B$ ise $g = f(e, f)$

Burada A ve B , koşul kısmının bulanık kümeleri, $g = f(e, f)$ ise sonuç kısmının kesin çıkış değeridir. $f(e, f)$, giriş değerleri e ve f olan bir polinomdur ve birinci dereceden


ise bulanık çıkartım sistemi "birinci derece Sugeno bulanık modeli", eğer $f(e,f)$ sabit bir değer ise "sıfırıncı derece Sugeno bulanık modeli" olarak adlandırılır.

İki tane bulanık “Eğer-O Halde” kuralı bulunan, birinci dereceden Sugeno bulanık modeli için tipik kural kümesi aşağıdaki gibi ifade edilebilir;

Eğer e A_1 ve f B_1 ise $g_1 = p_1 e + q_1 f + r_1$

Eğer e A_2 ve f B_2 ise $g_2 = p_2 e + q_2 f + r_2$

Şekil 2.16'da birinci derece Sugeno bulanık modeli için bulanık yargılama işlem basamakları iki kurala dayalı olarak verilmektedir. Her bir kuralın kesin çıkışı vardır ve sonuçta çıkış, ağırlıklı ortalama ile hesaplanır. Bu yöntemde sonuç kesin değer olduğu için berraklaştırma işlemine gerek kalmaz.



Şekil 2.16. Sugeno bulanık çıkarım yöntemi

2.2.3.4. Berraklaştırma


Pek çok pratik uygulamada, denetim komutu kesin bir değer olarak verilir. Bundan dolayı, bulanık çıkarım sonucunu berraklaştırmak gerekir. Berraklaştırma, elde edilmiş bir bulanık denetim etkinliğinde olasılık dağılımını en iyi gösteren, bulanık olmayan denetim etkinliği elde etme sürecidir. Ancak, iyi bir durulama stratejisi seçmek için sistematik bir işlem yoktur ve bundan dolayı uygulamanın özelliklerini dikkate alan bir yöntem seçilmesi gerekir [49].

Literatürde birçok berraklaştırma yöntemi önerilmektedir. Bunlardan en sık kullanılanları; en büyüklerin ortası yöntemi, ağırlık merkezi yöntemi, ortalamaların merkezi yöntemi ve alan merkezi yöntemleridir.

2.2.4. Uyarlamalı sinirsel bulanık çıkarım sistemleri (ANFIS)

ANFIS (Adaptive Neuro-Fuzzy Inference Systems) yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden oluşmuştur [50].

Sugeno bulanık modeli için bulanık yargılama işlem basamakları iki kurala dayalı olarak Şekil 2.16'da verilmişti. Bu yapıya karşılık gelen ANFIS yapısı Şekil 2.17'de verilmektedir. Burada, l katmanındaki i düğümünün çıkışı $O_{l,i}$ olarak gösterilmiştir.



Şekil 2.17. ANFIS mimarisi

Katman 1:

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

$$O_{1,i} = \mu_{A_i}(e), i=1,2 \text{ ya da } O_{1,i} = \mu_{B_{i-2}}(f), i=3,4 \text{ 't'ür.}$$

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

Katman 2:

Bu katmandaki her bir düğüm, kendisine gelen sinyalleri çarpımını çıkış olarak veren Π ile etiketlenmiş sabit bir düğümdür.

$$O_{2,i} = w_i = \mu_{A_i}(e) \cdot \mu_{B_i}(f) \quad (2.53)$$

Bu katmanda bulanık AND işlemini gerçekleştiren herhangi bir düğüm fonksiyonu kullanılabilir.

Katman 3:

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

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (2.54)$$

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

Katman 4:

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

$$O_{4,i} = \bar{w}_i g_i = \bar{w}_i (p_i e + q_i f + r_i) \quad (2.55)$$

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

Katman 5:

Bu katmanda toplam çıkışı hesaplamak üzere, kendisine gelen sinyallerin tümünü toplayan, sabit, tek bir düğüm yer alır.

$$O_{5,i} = \sum_i \bar{w}_i g_i \quad (2.56)$$

Böylece, tamamıyla Sugeno bulanık modelinin işleyişine sahip, adaptif bir ağ yapısı inşa edilmiş olur [51].


ANFIS ağına ait parametrelerin güncellenmesinde genellikle hibrit öğrenme algoritması kullanılır. Hibrit öğrenme algoritmasında, ANFIS ağ yapısına ait

parametreler, giriş ve çıkış parametreleri olarak iki kısımda ele alınır. Hibrit algoritmanın ilk aşaması ya da ileri yön geçişi ile ANFIS ağına ait giriş parametreleri, ikinci aşamada ya da geri yön geçişinde ise ağın sonuç parametreleri güncellenir. İlk aşamada en küçük kareler yöntemi, ikinci aşamada ise geri yalınım yöntemi kullanılır.

BÖLÜM 3. PİEZOELEKTRİK KRİSTAL SENSÖRLER VE KAPLAMA YÖNTEMLERİ

Bu bölümde transduser olarak kullanılan QCR (Quartz Crystal Resonator) ve kaplama yöntemleri hakkında bilgi verilecektir.

Kuartz kristal rezonatör (QCR), elektriksel enerjiyi mekanik enerjiye çeviren transduserdir. Kuartz kristal mikrobals (QCM) olarak da bilinen kuartz kristal rezonatör her iki yüzeyinde de eşit yarıçaplı dairesel elektrotlar bulunan AT-kesim ince bir kuartz malzemeden oluşur. Şekil 3.1’de tipik bir kuartz kristal rezonatörün yapısı gösterilmiştir.



Şekil 3.1. Kuartz kristal rezonatörün yapısı

Piezoelektrik malzemelerin kararlı, yüksek çıkış genliğine, sıcaklıktan ve nemden etkilenmeme, kolay şekil alma gibi özelliklere sahip olmaları istenilir. Bu özelliklerden en önemlisi ise kararlılıktır. En kararlı piezoelektrik ve ferroelektrik olmayan malzemelerden birisi de kuartzdır (SiO_2). Oda sıcaklığında düşük sıcaklık katsayısına sahip kuartz malzemeler, çıkışları çok küçük olmalarına rağmen, kararlı olmaları nedeniyle osilatörlerde ve sensör uygulamalarında sıkça kullanılır [8].


Piezoelektrik etki bütün maddelerde görülmemektedir. Simetrik yük dağılımına sahip maddeler, piezoelektrik özelliğe sahip değildirler.

Titreşim yapan tüm sistemler gibi QCR'ler de birçok titreşim modunda titreşir. Çoğu zaman QCR'nin tek bir modda titreşmesi istenir. İstenen modun seçilip diğer tüm modların bastırılması için kristalin uygun doğrultuda kesilmiş olması gerekir. Bununla birlikte kuartzın ve elektrotların geometrisi de titreşim modunu etkileyen faktörlerdendir. Sensör uygulamalarında seçilen titreşim modu, kuartzın üzerindeki kütleye en fazla duyarlı mod olan kalınlık-shear moddur. Kalınlık-shear modda titreşmesi istenen bir kuartz malzemenin AT veya BT kesilmiş olması gerekir. AT kesilmiş bir kuartz malzeme; kalınlığı y eksenini doğrultusunda uzunluğu x eksenini doğrultusunda saat ibresinin tersi yönünde $35^{\circ} 15'$ döndürülmüş bir tabakayı temsil eder. Bu bölgede oluşan akustik dalgalar kristal yüzeyine dik doğrultuda hareket eden enine dalgalardır. Elektrotlar bir AC gerilim kaynağına bağlanacak olursa kuartz, gerilim kaynağının frekansında titreşimler yapar. Gerilim kaynağının frekansı kuartzın mekaniksel rezonans frekansına eşit olduğunda kuartzda oluşan akustik dalgaların genliği maksimum değerine ulaşır.

Titreşim hareketi yapan bir sistemin elektriksel özelliklerinin incelenebilmesi için bu sistemin bir elektrik devresi ile temsil edilmesi gerekir. TSM (kalınlık makaslama modu) rezonatör için temsili devre Şekil 3.2'de verilmiştir. Butterworth-Van Dyke eşdeğer devresi olarak bilinen bu devrenin elemanları her biri, rezonans durumunda bulunan TSM rezonatörün bir fiziksel özelliğini temsil eder [52].

Eşdeğer devre üzerindeki elemanlar:

L_q indüktansı kuartzın kütlesini, C_q kapasitörü kuartzın esnekliğini, R_q direnci iç sürtünmelerden dolayı kaybolan enerjiyi ifade eder. C_0^* kapasitörü ise ölçüm sisteminden kaynaklanan parasitik kapasite C_p ile kuartzın iki elektrot arasında bulunmasından kaynaklanan statik C_0 kapasitesinden oluşur [11].



Şekil 3.2 Rezonans durumunda bulunan TSM rezonatörün eşdeğer elektrik devresi

$$C_0^* = \frac{\varepsilon_{22} A}{h_s} \quad (3.1)$$

$$C_q = \frac{8K^2 C_0}{(N\pi)^2} \quad (3.2)$$

$$L_q = \frac{1}{\omega_s^2 C_q} \quad (3.3)$$

$$R_q = \frac{\eta_q}{\mu_q C_q} \quad (3.4)$$

$$f_s = \frac{1}{2\pi \sqrt{L_q C_q}} \quad (3.5)$$

Bu eşitliklerde A metal elektrotların yüzey alanını, h_s kuartzın kalınlığını, K kuartzın elektromekanik kuplaj katsayısını, ε_{22} kuartzın dielektrik katsayısını, μ_q kuartzın sertliğini, η_q kuartzın viskozitesini, $\omega_s = 2\pi f_s$ olmak üzere f_s seri rezonans frekansını göstermektedir.

3.1. Kuartz Kristal Rezonatörün Kütle Duyarlılığı ve Gaz Sensörü Olarak Kullanımı

Kuartz kristal rezonatörlerinin kimyasal sensör olarak kullanımı 1964 yılında King ile başlar [53]. O yıllarda King, ilk olarak gaz kromatografisinde dedektör olarak kimyasal bir film ile kaplanmış rezonans frekansında titreşen kuartz kristalleri kullanmıştır. Daha sonra aynı yöntem, takip eden yıllarda sıvı kromatografiye de uygulanmıştır.

Kristaldeki parçacık yer değiştirmesi U_x aşağıdaki gibi verilir,

$$U_x(y,t) = (Ae^{iky} + Be^{-iky})e^{j\omega t} \quad (3.6)$$

Burada A ve B sabitler, $\omega = 2\pi f$ olup açısal frekans, k da dalga sayısıdır. Kalınlık shear modda titreşen bir QCM'nin rezonans frekansı kuartz malzemenin boyutları ve metal elektrotların kütlesi (kalınlığı) tarafından belirlenir. Böyle bir QCM için rezonans şartı shear dalganın kuartz içindeki tam bir gidiş-gelişinde kat ettiği yoldan belirlenebilir. Şöyle ki dalganın üst elektrottan başladığı düşünülürse, dalga kuartz kristali geçtikten sonra alt yüzeyden $\phi = \pi$ kadarlık bir faz kaymasıyla yansır. Yansıyan dalga üst yüzeye ulaştığında tekrar bir $\phi = \pi$ kadarlık faz kayması ile yansıyacaktır. Böylece dalganın tam bir gidiş-gelişte gördüğü toplam faz kayması 2ϕ 'dir. Toplam faz kayması 2π 'nin tam katlarına eşit ise gelen ve yansıyan dalgalar yapıcı girişim oluşturur ve bu durumda kristal rezonanstadır. Bu durum,

$$h_s = \frac{N\lambda}{2} \quad \text{veya} \quad (3.7)$$

$$f = \frac{N\nu_s}{2h_s} \quad (3.8)$$

ile verilen rezonans şartına götürür. Burada h_s kuartz malzemenin kalınlığı, N tamsayı, λ shear dalganın dalgaboyu ν_s de shear dalganın kuartz içindeki hızı olup Eşitlik (3.9)'daki gibi verilir.

$$v_s = \left(\frac{\mu_q}{\rho_q} \right)^{\frac{1}{2}} \quad (3.9)$$

Burada μ_q kuartzın shear stiffnessi ρ_q da kütle yoğunluğudur. Denklem (3.8) açıkça göstermektedir ki kuartz malzemenin kalınlığı akustik dalga boyunun yarısının tam katlarına eşit olduğu zaman rezonansa ulaşılır. Kuartz yüzeyindeki metal elektrotlardan dolayı elektrotlu bölge ile elektrotsuz bölgeler farklı rezonans frekansına sahiptirler. Elektrotlu bölgedeki rezonans frekansı elektrotsuz bölgedeki rezonans frekansından küçüktür. Metal elektrotların kalınlığı arttıkça bölgeler arasındaki frekans farkı da artar. Denklem (3.8)'den görülebileceği gibi bir QCM N 'nin değişik değerlerine karşılık gelen birçok rezonans durumuna uyarılabilir. Ancak çalışmalar göstermektedir ki yüzey elektrotları ile ancak N 'nin tek sayı değerlerine karşılık gelen rezonans durumları elde edilebilir [11]. Bu rezonans koşulu, QCM için rezonans durumunda parçacık yer değiştirmesinin dağılımını hesaplama imkanı verir. QCM havada veya vakumda çalıştırıldığında, kristalin yüzeyleri gerilme tensöründen (stresden) bağımsız sınır olarak düşünülebilir. Bu kristalin alt ve üst yüzeylerinde $\partial U_x / \partial y = 0$ olmasını gerektirir. Bu sınır koşulunun Denklem (3.6)'ya uygulanması ile kristaldeki shear yerdeğiştirme profili,

$$U_x(y,t) = U_{x0} \cos(k_N y) e^{i\omega t} \quad (3.10)$$

olarak elde edilir. Burada U_{x0} yüzeydeki parçacık yer değiştirme genliği, $k = N\pi/h$ 'dir. Denklem (3.10) maksimumları kristal yüzeyinde olan bir duran shear dalgalar ailesini temsil eder. Bu çalışma moduna kalınlık shear mod denmesinin nedeni shear yer değiştirmesinin kuartzın kalınlığı boyunca değişmesinden dolayıdır.

Kristal yüzeyindeki parçacık yer değiştirmesinin maksimum olduğu kalınlık makaslama modu, yüzeydeki kütle değişimlerine oldukça duyarlıdır. Kristal yüzeyine kuvvetli olarak bağlanan kütle, kristal yüzeyi ile birlikte senkronize olarak hareket eder. Kristal yüzeyindeki kütle artışı QCM'nin rezonans frekansını etkiler.

Yüzeydeki kütle artışı ile rezonans frekansındaki değişim arasındaki ilişki Rayleigh [11] prensibinden çıkarılabilir. Rayleigh prensibi; mekanik bir sistemde rezonansın maksimum kinetik enerji U_k 'nın maksimum potansiyel enerji U_p tarafından tam olarak dengelendiği frekansta elde edilebileceğini söyler. Bu prensip enerjinin kinetik ve potansiyel enerji arasında periyodik olarak değişmesinin bir sonucudur. Kalınlık shear modda titreşen sonsuz kalınlıklı olduğu varsayılan bir kuartz kristalde parçacık yer değiştirmesi tüm kristal yüzeyi boyunca düzgün olarak dağılmıştır [11]. Dolayısıyla sonsuz kalınlıklı kuartz için rezonatorün kütle duyarlılığı tüm aygıt yüzeyi boyunca sabit olarak kabul edilebilir. Sonsuz kalınlıklı kuartz kristal yüzeyinde ideal (yeterince ince ve kuvvetli bağlanmış) bir kütle tabakasının yığılması sistemin kinetik enerjisini artırırken potansiyel enerjisinde bir değişikliğe neden olmaz. Rayleigh hipotezi kristal yüzeyinde bir kütle yığılması olduğu zaman rezonans frekansının, kinetik ve potansiyel enerjiyi dengelemek için değişmesini gerektirir. Kalınlık shear modda titreşen bir rezonatörde maksimum kinetik enerji yoğunluğu (Birim yüzey alanı başına enerji) parçacık hızının maksimum yer değiştirmenin ise sıfır olduğu anda elde edilir. Bu enerji,

$$U_k = \frac{\omega^2}{2} \left(\rho_s U_{x0}^2 + \rho_q \int_0^h |U_x(y)|^2 dy \right) \quad (3.11)$$

ile verilir. Burada, ρ_s kütle tabakasının birim alanının alansal kütle yoğunluğu (kütle/alan) ρ_q da kuartz malzemenin birim alanının hacimsel kütle yoğunluğudur (kütle/hacim).

Denklem (3.10), Denklem (3.11)'de yerine yazılırsa maksimum kinetik enerji yoğunluğu U_k ,

$$U_k = \frac{\omega^2 U_{x0}^2}{2} \left(\rho_s + \frac{\rho_p h_s}{2} \right) \text{ olarak bulunur.} \quad (3.12)$$

Kalınlık shear modda titreşen bir QCM’de maksimum potansiyel enerji yoğunluğu U_p parçacık hızının sıfır yer değiştirmenin ise maksimum olduğu anda elde edilir. Bu maksimum potansiyel enerji yoğunluğu U_p ,

$$U_p = \frac{\mu_q k^2 U_{x0}^2 h_1}{2} \int_0^1 \sin^2(ky) dy \quad (3.13.a)$$

$$= \frac{\mu_q k^2 U_{x0}^2 h_s}{4} \quad (3.13.b)$$

olarak verilir. Denklem (3.12) ve Denklem (3.13) rezonans frekansı ω ile yüzey kütle yoğunluğu ρ_s arasındaki ilişkiyi verir. Bu ilişki,

$$\left(\frac{\omega_0}{\omega} \right)^2 = 1 + \frac{2\rho_s}{h_s \rho_q} \quad (3.14)$$

olarak bulunur. Burada $\omega_0 = (N\pi/h_s) \left(\mu_q / \rho_q \right)^{1/2}$ olup rezonatörün yüzeyinde kütle yığılmasının olmadığı durumdaki rezonans frekansıdır. $\rho_s \ll h_s \rho_q$ olması durumunda Denklem (3.14),

$$\frac{\Delta f}{f_0} = - \frac{\rho_s}{h_s \rho_q} \quad (3.15)$$

ifadesine indirgenir. Denklem (3.15) göstermektedir ki rezonans frekansındaki değişim oranı kütle tabakasının neden olduğu kütle değişim oranına eşittir. Bu ifade, ilave olunan kütle tabakasının kuartzın kütlesine oranı %2 den küçük olduğu sürece geçerlidir. Denklem (3.12), (3.13) ve (3.15)’in birleştirilmesiyle QCM’nin rezonans frekansındaki değişim Δf ,

$$\Delta f = -C_f \Delta m \quad (3.16)$$

olarak bulunur. Burada Δm ilave olunan kütle, C_f de sonsuz kalınlıktaki kuartz tabakanın duyarlık sabiti olup Denklem (3.17) ile verilir,

$$C_f = \frac{f_0^2}{\rho_q N_{AT}} \quad (3.17)$$

Burada f_0 kuartzın rezonans frekansı, ρ_q kuartzın yoğunluğu (2649 kg/m^3), N_{AT} de AT kesilmiş kuartz için frekans sabitidir ve kuartzın kalınlığı doğrultusunda yayılan shear horizontal dalgalar için dalga hızının yarısına eşittir [11]. Kalınlığı rezonans dalga boyunun yarısına eşit kuartz kristal için N_{AT} ,

$$N_{AT} = \frac{v}{2} = 2h_s f_0 \quad (3.18)$$

ile verilir. Denklem (3.16) Sauerbrey denklemi olarak bilinir.

Ancak, sonlu kalınlıklı kuartz kristal için parçacık yer değiştirmesi genliği QCM sensör yüzeyi boyunca düzgün bir dağılım göstermez. Bu durumda QCM'in kütle duyarlılığı diferansiyel kütle duyarlılığının integrali alınarak bulunur. Sonlu kalınlıklı kuartz kristal için, yüzeydeki kütle ilavesi sonucu rezonans frekansındaki değişim Δf ,

$$\Delta f = -S_f(r, \theta) \Delta m(r, \theta) \quad (3.19)$$

ile verilir. Burada $\Delta m(r, \theta)$ ilave edilen kütle, $S_f(r, \theta)$ da kütle duyarlık fonksiyonu olup,

$$S_f(r, \theta) = \frac{|U_l(r, \theta)|^2}{\int_0^\infty \int_0^{2\pi} r |U_l(r, \theta)|^2 d\theta dr} C_f \quad (3.20)$$

ile verilir. Denklem (3.20)'de $U_l(r, \theta)$ QCM yüzeyi boyunca parçacık yer değiştirme fonksiyonudur. Temel rezonans frekansında çalıştırılan QCM için parçacık yer değiştirme genliği değişmezdir. Dolayısıyla temel rezonans frekansında çalıştırılan QCM için duyarlık (sensitivity) fonksiyonu $S_f(r)$,

$$S_f = \frac{|U_I(r)|^2}{2\pi \int_0^{\infty} r |U_I(r)|^2 dr} C_f \quad (3.21)$$

ile verilir. Burada C_f Sauerbrey sensitivite sabiti olup birimi $\text{Hz.m}^2/\text{kg}$ 'dır.

Denklem (3.21)'den görülebileceği gibi duyarlık (sensitivity) fonksiyonu radyal doğrultudaki parçacık yer değiştirme genliği ile orantılıdır. Parçacık yer değiştirme genliği radyal doğrultu boyunca değiştiği için duyarlık fonksiyonu da QCM'nin yüzeyinde radyal doğrultu boyunca değişecektir.

Bazı pratik uygulamalar için, QCM sensör yüzeyindeki özellikle bir bölgedeki yüzey alan kütle duyarlığının bilinmesi gerekir. Mesela kütle ilavesinin çok küçük olması veya QCM yüzeyinin belli bir bölgesine ince film kaplanması durumunda yüzey alan kütle duyarlığının bilinmesi gerekir. Bu durumda yüzey alan kütle duyarlığı diferansiyel kütle duyarlığının ilgilenilen alan üzerinden integrali alınarak bulunur. Yüzey alan kütle duyarlığı S_{alan} Denklem (3.22)'de verilmiştir,

$$S_{alan} = \int_{r_1}^{r_2} S_f 2\pi r dr \quad (3.22)$$

Sonuç olarak bir analitin algılanabilmesi maksadıyla, bir piezoelektrik kuartz kristalin yüzeyi genellikle ilgili analite karşı duyarlı, seçici uygun bir kimyasal algılayıcı tabaka ile ince bir film halinde kaplanır. Analit moleküllerinin kuartz kristal yüzeyindeki bu kimyasal algılayıcı tabaka tarafından ad/absorplanması sonucu kuartz kristalin kütledeki değişim, yukarıda da bahsedildiği üzere rezonans frekansında bir değişime neden olur. Kısaca analitin kütle/konsantrasyonuna bağlı olarak rezonans frekansı değişir. Kuartz kristal yüzeyinde biriken kütle miktarı çok küçük olduğu için, bu metoda “mikro-gravimetrik” veya “mikro-balans” teknik de denilmektedir [54,55]. Bu metot özellikle hidrokarbonlar, alkoller ve aromalar gibi nispeten büyük moleküllerin dedeksiyonuna elverişlidir.


3.2. Kaplama Yöntemleri

Daha önceki bölümlerde QCM transduserlerin bir kimyasal ara yüzey ile kaplanarak gaz sensörü olarak kullanılabileceğini söylenildi. QCM'lerin gaz sensör özellikleri üzerine kaplanan filmin kimyasal ve fiziksel özelliklerinin yanı sıra film hazırlama yöntemlerine de doğrudan bağlıdır [56]. Özellikle elde edilen filmin yüzey üzerindeki homojenliğinin ve kalınlığının duyarlılığın en yüksek olduğu noktada olması istenen bir durumdur. Bu sebeple kaplanmak istenen molekülün yapısı da dikkate alınarak uygun kaplama teknikleri seçilmeli veya geliştirilmelidir. Bu sebeple çeşitli film hazırlama metotları geliştirilmiştir. Bu metotlardan başlıcaları LB (Langmuir Blodget), spin coating, smearing, vakum sublimasyon gibi yöntemlerdir. Özellikle son yıllarda kimyasal malzemenin transduser üzerine kontrollü olarak sprey edilmesi esasına dayanan airbrush metodu da önemli bir kaplama yöntemidir. Homojen film elde etmeyi amaçlayan bu yöntemlerin uygulanabilmesi film malzemesinin fiziksel ve/veya kimyasal özelliklerine bağlıdır. Özellikle ftalosiyanın ve oksim gibi bazı çözücülerde çok iyi çözünebilen popüler sensör malzemeleri için yukarıda bahsedilen metotlardan bazılarını uygulamak mümkündür. En popüler olan metotlar smearing ve LB'dir. Ancak unutulmaması gereken önemli bir nokta LB metodu ile film elde etmek için film malzemesinin özel olarak tasarlanmış olması gerekir [57].

3.2.1. LB (Langmuir Blodget) kaplama metodu

Önemli bir film kaplama metodu olan LB metodu su yüzeyinde bazı sıvıların (yağ vs.) kalmasından esinlenerek ortaya atılmış bir yöntemdir. Bu konuda yayımlanmış bilinen en eski bilimsel makale, 1774 yılında Benjamin Franklin tarafından Royal Society isimli dergide yayımlanmıştır [58]. Bu metot 1972 yılında mikroelektronik alanında metal-yalıtkan-yarıiletken (MOS) ve Field Effect Transduserlerde (FET) uygulama alanı bulmuştur [57]. Kimyasal ara yüzeyli gaz sensör teknolojisi açısından önemli bir yere sahip olan LB metodu ile tek tabaka film elde etmek mümkün olmaktadır. Ancak LB metodunun uygulanabilmesi için filmi hazırlanacak kimyasal malzemenin uygun tasarlanmış olması gerekmektedir. Şekil 3.3'te gösterildiği gibi polar hidrofilik bir ana grup ve hidrofobik bir kuyruk olarak ifade

edilen bir yapıdan ibarettir. Bu yapıya en iyi örnek yağ asitleridir. Su yüzeyine spreylenen malzeme ana grup ve kuyruk olarak isimlendirilen bölgeler belli yönelimlere yönelecek şekilde su yüzeyinde yerlerini alırlar. Bu yönelim; ana grup su yüzeyinde kuyruk tarafı ise su yüzeyi üstünde kalacak şekilde su yüzeyine dizilirler [56].



Şekil 3.3a. LB metodu için tasarlanan molekülün şematik gösterimi

b. Moleküllerin su yüzeyinde dizilişinin şematik gösterimi

Eğer Hidrofilik grup çok ağır ise materyal su içine dağılıbilir. Eğer Hidrofobik grup ağır ise elde edilen film tek tabaka olmayacaktır.

LB metodunun kullanıldığı sistem ise üç temel parçadan meydana gelmektedir. Bu temel parçalar:


1. Yüzeye yayılmış olan molekülleri belli hızda hareket ettiren bir bariyer.
2. Bu hareketin kontrollü olması için yüzey basıncını kontrol eden bir transducer.
3. Film kaplanacak yüzeyin hareketinin kontrol eden sistemden meydana gelir.

Film kaplanacak yüzey, yatay veya dikey hareket ettirilerek iki farklı yöntemle kaplanabilir.

3.2.2. Smearing metodu

Kimyasal ara yüzeyli gaz sensör teknolojisinde önemli bir yere sahip olan kaplama metodlarından birisi de smearing yöntemi olarak bilinen yöntemdir. Bu yöntem, kaplama maddesinin kaplanacak yüzeye sürülmesi veya damlatılması ile

gerçekleştirilir. Özellikle LB, spin coating gibi kaplama materyalinde belli özelliklerin bulunmasını şart koşmayan bu yöntem sensör çalışmalarında genellikle tercih edilmiştir [59-61]. Yöntemin en önemli bölümü, kaplama yapılacak kimyasal malzemenin bir çözücü içinde çözünebilir olmasıdır. Çözültiden alınan bir miktar çözünmüş madde transduser üzerine bırakılır ve çözücünün uçması sağlanır. Çözücünün yüzeyden uçurulması ile film hazırlanmış olur. Bu metotla hazırlanan filmlerden alınan sonuçlar kimyasalın sensör özellikleri hakkında bilgi vermekle birlikte, cevap kalitesi hakkında bir bilgi vermekten uzaktır. Kolay uygulanabilir olmasının dışında elde edilen filmin homojenliği, kalınlığı gibi faktörlerin denetimi zordur. En önemli faktörlerden birisi de film kalitesinin filmi hazırlayan kişiye göre değişim gösterebilmesidir.



Şekil 3.4. Smearing kaplama sisteminin şematik gösterimi


3.2.3. Jetsprey (Airbrush) metodu

Önemli kaplama metotlarından biri de jetsprey yöntemidir. Bu yöntemde, çözücü içinde çözünmüş kimyasal algılayıcı madde yüzeye belli bir gaz yardımıyla kontrollü bir şekilde spreyl edilir. Kimyasal malzemede belirli özelliklerin bulunmasını şart koşmayan bu yöntemle kimyasal çözücülerde çözünebilen maddelerden bu yöntemle ince film elde edilebilmektedir [56].

Yöntemde temel olan, uçucu bir çözücüde çözünen kaplama malzemesinin bir taşıyıcı gaz ile yüzeye püskürtülmesidir. Yöntemde madde miktarının kolay denetlenmesi, homojen kalınlıkta kaplama elde edilmesi, yüzeydeki filmin

özelliklerini kolayca değiştirebilme gibi kolaylıklar sağlamaktadır. Ayrıca yöntemde bir osiloskop veya frekansmetre yardımıyla yüzeydeki kaplama kalınlığı Δf izlenerek hassas biçimde tayin edilebilmektedir [56].

Şekil 3.5'te verilen Jetsprey olarak isimlendirilen bu yöntem Tübitak MAM Kimya Bölümü bünyesinde Gaz Sensör Prototipi Geliştirme Projesi [62] kapsamında geliştirilmiştir.



Şekil 3.5. Jetsprey kaplama sistemi [8]

BÖLÜM 4. ÖLÇÜM SİSTEMİ VE SENSÖR DİZİSİ

Bu bölümde algılayıcı kimyasal maddelerle kaplanan kuartz kristal transduserlerin gaz algılama özelliklerinin test edildiği deneysel düzenek ve kullanılan sensör dizisinden bahsedilecektir.

4.1. Sensör Dizisi

Bu çalışmada, kimyasal maddelerin buharlarının/kokularının algılanması, tanımlanması ve sınıflandırması maksadıyla algılayıcı eleman olarak biri referans olmak üzere on adet kuartz kristal rezonatörden (QCR) oluşturulan sensör dizisi kullanılmıştır. Algılayıcı elemanlar olan kuartz kristallerin yüzeyleri, çeşitli algılayıcı kimyasal maddeler ile kaplanmıştır.


Algılayıcı eleman olarak kullanılan QCR'ler, "Kalınlık Makaslama Modunda" (TSM: Thickness Shear Mode) salınan (10 MHz), her iki yüzeyinde eşit çaplı (4mm) simetrik, dairesel, metal (Ag) elektrotlar bulunan, AT-kesim ($35^{\circ}15'$), ince piezoelektrik kuartz kristallerden oluşmaktadır. AT-kesim QCR'lerin seçilmesinin nedeni, çıkışlarının zayıf olmasına rağmen sıcaklık ve nem karşısında kararlı olmaları, titreşim modu olarak TSM'nin seçilmesinin nedeni ise, bu modda AT-kesim QCR'lerin yüzeylerindeki kütle değişimlerine karşı daha duyarlı olmalarıdır [56].

Sensör dizisinde referans olarak kullanılan kuartz kristali, ortamdaki algılanmak istenen analit ile etkileşmesinin önlenmesi maksadıyla kendi metal kılıfına konulmuştur. Diğer sensörlerin ölçüm sonuçları, referans sensörünün ölçüm değeri baz alınarak, yani onun değerinden çıkarılarak hesaplanır. Böylece bir bakıma

sensörlerde gerilim, frekans, sıcaklık vb. gibi değişim nedenleriyle oluşabilecek hatalar kısmen telafi edilmiş olur [8].

Kullanılan kuartz kristallerin rezonans frekansları, üretildikleri çalışma frekansından ± 4 Hz değişebilmektedir.

Bu çalışmada algılayıcı kimyasal maddeler ile kaplanan kuartz kristallerinden oluşan 9 adet sensör ve referans sensörü Şekil 4.1’de gösterilen, dış ortamdan iyi bir şekilde izole edilmiş kapalı bir muhafaza içerisine yerleştirilmiş ve muhafazanın herhangi bir yerinden gaz kaçağı olmamasına özen gösterilmiştir.



Şekil 4.1. Sensör dizisi [8]

4.2. Algılayıcı Kimyasal Kaplama Malzemesi

Sensör özelliği gösteren birçok molekül kimyasal algılayıcı film olarak kullanılabilir. Özellikle kaplama malzemesinin kaplanabilir ve gaz molekülleri ile etkileşimleri sonunda kimyasal bir bozulmaya uğramadan kalabilmesi, ölçülmek istenen gaz molekülleri ortamdan uzaklaştırıldığı zaman tekrar

eski haline gelebilmesi (reversible olması) aranan bir durumdur. Bununla birlikte belli gazlara duyarlı ve bunun dışındaki gazlardan fazla etkilenmemesi önemli parametreler arasındadır [56].

Yukarıda anlatılan özellikleri gösterebilen moleküller algılayıcı film olarak kullanılabilir. Bu tip moleküller genellikle ftalosiyanın ve oksim olarak bilinen büyük yapıli moleküllerdir.


Algılayıcı kimyasal madde kaplama yöntemi olarak Bölüm 3.2.3'te anlatılan Jetsprey metodu kullanılmıştır. Bu metot algılayıcı eleman üzerine kimyasal maddelerin kontrollü bir biçimde homojen olarak kaplanmasına, tekrarlı olarak aynı kalitede kaplamaların yapılabilmesine imkan tanımaktadır [56].

Kaplama işlemine başlanmadan önce algılayıcı kimyasal kaplama maddeleri, iyi bir çözücü ve uçucu olan kloroform içerisinde karıştırılarak çözülmüştür. Kaplama maddesi ve kloroform karışımı, cam bir hazneye bir pipetle konularak, Jetsprey kaplama düzeneğine yerleştirilmiştir. Kaplama karışımının kuartz kristal yüzeyine püskürtülmesinde azot (N_2) gazı kullanılmıştır. Azot gazının kullanılmasının nedeni, oksijen gibi oksitlenmelere sebep olmamasıdır. Kaplama karışımının içinde bulunan kılcal borunun yukarıdaki ağzının üzerinden azot gazının püskürtülmesi ile karışımdan kılcal boru yardımıyla yukarı doğru çekilen kaplama maddesi, azot gazı ile beraber kuartz kristali yüzeyine taşınarak kaplama işlemi gerçekleştirilmiştir. Kaplama işleminden sonra kuartz kristali yüzeyine taşınmış olan kloroform buharlaşmaktadır [8].

Kuartz kristalinin yüzeyi bir madde ile kaplandığı için çalışma frekansı kaymaktadır. Kaplama işlemi esnasında, osilatör ve frekansmetre yardımı ile kuartz kristalinin ilk çalışma frekansından (f_0) olan negatif yöndeki kayması ($-\Delta f$) takip edilmiştir. Bu frekans kayması, kuartz kristali yüzeyindeki kaplama maddesi miktarı ile bağlantılıdır. Kuartz kristalinin ön yüzeyi 11 KHz'lik bir frekans kayması sağlayıncaya kadar kaplama işlemine devam edilmiş; ön yüzey kaplandıktan sonra aynı işlem arka yüzeye de uygulanmıştır. Böylece kuartz kristallerin her iki yüzeyi de aynı miktarda kimyasal madde ile kaplanmıştır.

4.3. Ölçüm Düzeneği

Oluşturulan sensör dizisindeki QCR'ler, her 6 saniyede bir frekans farklarından (Δf) oluşan veri setlerini seri port üzerinden bilgisayar ortamına aktaran devreye bağlanarak Şekil 4.2'deki ölçüm düzeneği kullanılmıştır (Ölçüm düzeneği için yapılan yazılım EK-A'da verilmiştir).



Şekil 4.2. Ölçüm düzeneği [8]

Dört ayrı kanala ayrılan hava, akış kontrolörlerinden (flow controller) belli debilerle geçirilmektedir. Bu kanallardan üç tanesi yıkama şişesi içinde sıvı halde bulunan maddelere gitmektedir. Diğer kanal ise istenilen konsantrasyonun sağlanması için yıkama şişesinden çıkan kanallarla karışmaktadır. Bu karışım sonunda ise istenilen konsantrasyonda ve debide gaz elde edilmiş olmaktadır. İstenilen konsantrasyonun sağlanmasındaki bir başka faktör olan yıkama şişesindeki sıvının sıcaklığıdır. Özellikle sensör çalışmalarında kullanılan gazların çoğu ölçülmek istenen gazın sıvısından elde edilebilmektedir. Bu işlem için sıcaklığa bağlı olarak bazı sıvıların atmosfer basıncı altında kaç ppm (parts per million) olabileceğini söyleyebilen Antoine kanunundan faydalanılmaktadır. Antoine kanununa göre sıcaklığa bağlı olarak sıvının buhar basıncı Eşitlik (4.1)'deki gibidir [56].

$$\text{Log } P = A - \frac{B}{(t + C)} \quad (4.1)$$

Burada A, B, C ilgilenilen sıvı için sabitlerdir t ise santigrad derece cinsinden gaz sıvısının bulunduğu ortamın sıcaklığıdır [56]. P ise torr biriminden ilgilenilen gazın kısmi basıncını ifade eder.

Buhar basıncının birimi paskal birimine çevrilip 10 ile çarpılması ise ilgilenilen gaz için ortamda kaç ppm olduğu bulunmuş olmaktadır.

Gaz numunesi ölçülmek üzere sensör test odasına girmekte ve burada kuartz kristal sensörler tarafından algılanarak egzoz vasıtası ile ortam dışına atılmaktadır.

Bu çalışmada kullanılan analitler Tablo 4.1’de verilmiştir.

Tablo 4.1. Örnek analit maddeleri

I	UÇUCU KLORLU BİLEŞİKLER
1	Trikloretilen (Trichloroethylene)
II	AROMATİKLER
2	Benzen (Benzene)
III	ALİFATİKLER
3	n-Hekzan (n-Hexane)
IV	KETONLAR
4	Aseton (Acetone)
V	ALKOLLER
5	Metanol (Methanol)

Örnek analitler, Şekil 4.2’deki gibi bir gaz yıkama şişesine konulmuştur. Ölçüm süresince gaz yıkama şişesindeki analit, metanol dolu “dewar kabı” içerisinde tutulmuştur. Analiti istenen konsantrasyon seviyesinde elde edebilmek maksadıyla, analitin sıcaklığı (t_{analit}) dewar kabta bulunan bir termostat ile ayarlanmıştır.


Örnek analitler için “Antonie Eşitliğinin” katsayıları (A, B, C) Tablo 4.2’de verilmiştir.

Tablo 4.2. Örnek analitlerin Antonie katsayıları


ANTONIE KATSAYILARI			
ANALİT	A	B	C
Trikloretilen	7,02808	1315,04	230
Benzen	6,90656	1211,083	220,79
Hekzan	6,87024	1168,20	224,21
Aseton	7,23157	1277,03	237,33
Metanol	8,0724	1574,99	238,87

Bu katsayılar kullanılarak ölçülecek olan analitin konsantrasyon seviyesi (ppm) hesaplanır.


Sensör dizisi, geri dönüşümün sağlanması için 10 dakika süresince sadece kuru hava, ardından 10 dakika süresince kuru havayla taşınan her bir analitin zamanla artırılan belli (500, 1000, 2000,..., 10000 ppm) konsantrasyon seviyelerine dönüşümlü bir şekilde maruz bırakılarak ölçümler gerçekleştirilmiştir. Farklı analitlerin ve konsantrasyonlarının, dizideki kuartz kristalleri yüzeyindeki farklı algılayıcı kimyasal tabakalar tarafından değişik oranlarda ad/absorplanmasına bağlı olarak, QCR'lerin rezonans frekans değerleri değişik oranlarda kaymaktadır. Kuartz kristallerin kayan frekansları, referans sensörünün ölçülen frekansından çıkarılmak suretiyle, dizideki her bir sensörün frekans farkları (Δf), her 6 saniyede bir seri port üzerinden bilgisayar ortamına aktarılarak veri setleri elde edilmiştir. Elde edilen bu veri setleri değerlendirilerek her bir sensörün, doyum bölgesi, lineer olduğu bölge ve gazlara olan duyarlılıkları tespit edilmiştir.




Şekil 4.3. Sensör dizisinin asetona verdiği tepki




Şekil 4.4. Sensör dizisinin trikloretilene verdiği tepki



Şekil 4.5. Sensör dizisinin benzene verdiği tepki



Şekil 4.6. Sensör dizisinin hekzana verdiği tepki



Şekil 4.7. Sensör dizisinin metanole verdiği tepki

Dokuz sensörün tepkileri incelendiğinde S5, S6, S7 ve S8 sensörlerinin bu beş gazda fazla duyarlı olmadığı tespit edilmiştir. Ayrıca trikloretilenin 7000 ppm konsantrasyon değerinde, sensörler doyum bölgesine geçmektedir. Bu çalışmada ikili gaz karışımları kullanılacağından, her bir gaz için 5000 ppm, toplam gaz karışımı için de 10000 ppm konsantrasyon değerinin üstüne çıkılmamıştır. İlk olarak her bir gazın 1000, 2000, 3000, 4000, 5000 ppm konsantrasyon değerleri oluşturulmuş, daha sonra da bir gazın konsantrasyonu sabit tutularak (1000,2000, ..., veya 5000 ppm) diğer gazın tüm konsantrasyon değerleri (1000,2000,..., ve 5000 ppm) karıştırılıp sensörlere uygulanmıştır.

BÖLÜM 5. UYGULAMA VE SONUÇLAR

Bir yapay sinir ağının veya uyarlamalı sinirsel bulanık çıkarım sisteminin, bir karışımdaki uçucu organik bileşiklerin miktarlarını tayin edebilmesi için öncelikle deneysel çalışma neticesinde elde edilecek ölçüm sonuçlarının toplanması gerekir. Daha sonra bu ölçüm verileriyle ağın eğitilmesi işlemine geçilir. Yapay sinir ağlarının genel çalışma prensibi, bir girdi setini alarak onları çıktı setine çevirmek olarak açıklanabilir. Bunun için ağın kendine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi yani eğitilmesi gereklidir. Eğitim işlemi, eldeki veriler ağa tek tek gösterilir ve ağın kendi mekanizmalarını çalıştırarak veriler arasındaki ilişkiyi belirlemesi beklenir. Ağı eğitmek için, elde bulunan veriler iki ayrı sete bölünür. Birisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Ağ bütün örneklerle, kabul edilebilir bir hata ile doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış olur. Daha sonra, önceden hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Bu işleme ağın test edilmesi denilmektedir. Elde edilen çıktıların doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir. Eğer ağın hiç görmediği örnekler karşısındaki performansı yetersiz olursa o zaman ağı yeniden eğitmek veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işlem, ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder [43].


Ağın performansını test etmek için Eşitlik (5.1)'de verilen ortalama bağıl mutlak hata kullanılmıştır;

$$E(RAE) = \frac{1}{n_{test}} \sum_{n_{test}} \left(\left| \frac{PPM_{tahmin} - PPM_{gercek}}{PPM_{gercek}} \right| \right) \quad \forall PPM_{gercek} \neq 0 \quad (5.1)$$

Eşitlik (5.1)'de, PPM_{tahmin} tahmin edilen konsantrasyon değerini, PPM_{gercek} gerçek konsantrasyon değerini ve n_{test} test setinde bulunan veri sayısını temsil etmektedir.


5.1. ANFIS Yapısı Kullanılarak Keton-Klorlu Bileşik Gaz Karışımının Miktersal Tayini

ANFIS mimarisi (Bkz. Bölüm 2.2.4) tek çıkışlı olduğundan, ikili gaz karışımındaki analitlerin miktarlarını tayin edebilmek için 2 adet ANFIS yapısı kullanılmış ve bu yapılar aynı anda çalıştırılmıştır. Kullanılacak olan kuralları, ANFIS yapısı kendisi ürettiğinden, değişiklik yapılabilecek parametreler, üyelik fonksiyonların türü ve sayısıdır. Üyelik fonksiyonunun gaussisan, üçgen veya diğer üyelik fonksiyonlarının olması durumunda performansta çok büyük değişiklikler olmamakla birlikte gaussian tipi üyelik fonksiyonunun kullanılmasına karar verilmiştir. Performansı etkileyen en önemli parametrenin, kullanılan üyelik fonksiyonunun sayısı olduğu görülmüştür. İlk yapılan denemede her iki ANFIS yapısı için de üyelik fonksiyonu sayısı 3 seçilmiştir. Şekil 5.1'de her iki ANFIS yapısı için, Zaman-MSE ilişkisi, eğitim ve test seti için verilmiştir.




Şekil 5.1. Üyelik fonksiyonu sayısı 3 olması durumunda Zaman-MSE ilişkisi: (a) ANFIS1 için (Trikloretilen), (b) ANFIS2 için (Aseton)

Şekil 5.1'den görüldüğü gibi trikloretilen için amaçlanan yakınsama (1.10^{-6}) sağlanmıştır fakat aseton için sağlanamamıştır. Aseton için, üyelik fonksiyonunun sayısını arttırılarak daha iyi bir yakınsama hedeflenmiştir. 4 üyelik fonksiyonu kullanıldığında işlem süresi çok uzun olduğundan, asetona en iyi tepki veren 4 sensör kullanılarak ANFIS yapısı oluşturulmuştur. Trikloretilen için ANFIS yapısı, ilk haliyle muhafaza edilmiştir. Bu durumda aseton için elde edilen yakınsama grafiği Şekil 5.2'de gösterilmiştir.




Şekil 5.2. Aseton için 4 üyelik fonksiyonu ve 4 sensör verisi kullanıldığı durumdaki eğitim grafiği

Aseton için, 4 sensör verisinin ve üyelik fonksiyonu sayısının 4 kullanılması durumunda yakınsamanın biraz daha iyileştiği Şekil 5.2'den görülmektedir. Yine 4 sensör verisi kullanıp, üyelik fonksiyonu sayısı 5 alındığında ise aseton için yakınsamanın biraz daha iyileştiği Şekil 5.3'ten görülmektedir.




Şekil 5.3. Aseton için 5 üyelik fonksiyonu ve 4 sensör verisi kullanıldığı durumdaki eğitim grafiği

Şekil 5.3'ten görüldüğü gibi aseton için yakınsama önceki durumlara göre biraz daha iyidir. Fakat çok daha uzun zaman almaktadır. Hedeflenen, trikloretilende olduğu gibi asetonda da amaçlanan yakınsamayı (1.10^{-6}) sağlamak olduğundan, asetonun üyelik fonksiyonu sayısı bir arttırılarak 6 alınmış ve işlem süresi de dikkate alınarak kullanılan sensör verisi üçe düşürülmüştür. Bu durum Şekil 5.4'te gösterilmiştir.



Şekil 5.4. Aseton için 6 üyelik fonksiyonu ve 3 sensör verisi kullanıldığı durumdaki eğitim grafiği

Şekil 5.4 incelendiğinde, yakınsamanın bir önceki duruma göre biraz kötüleştiği görülmüştür. Bunun sebebi de daha az sayıda sensör verisi kullanılmasıdır. Bu durumu telafi etmek için üyelik fonksiyonu sayısı bir arttırılıp 7 alındığında aseton için yakınsama grafiği Şekil 5.5'te gösterilmiştir.



Şekil 5.5. Aseton için 7 üyelik fonksiyonu ve 3 sensör verisi kullanıldığı durumdaki eğitim grafiği

Tüm bu grafikler değerlendirildiğinde, üyelik fonksiyonlarının sayısı artırıldığında ortalama karesel hatanın düştüğü gözlenmiştir. Ancak, üyelik fonksiyonlarının sayısı artırıldığında eğitim süresi katlanarak arttığından, daha az duyarlı sensörler elimine edilerek üyelik fonksiyonu sayısının artırılması yöntemi seçilmiştir. Performans değerlendirmesi Tablo 5.1’de verilmiştir.

Tablo 5.1. Değişik türdeki ANFIS yapılarının test seti için performans değerlendirmesi

ANFIS Yapısı	[3 3 3 3 3]	[3 3 3 3 3]	[3 3 3 3 3]	[3 3 3 3 3]	[3 3 3 3 3]
Performans	[3 3 3 3 3]	[4 4 4 4]	[5 5 5 5]	[6 6 6]	[7 7 7]
Eğitim Süresi (sn.)	3126	2830	8965	2110	2950
MSE(Trikloretilen)	$1,52.10^{-6}$	$1,52.10^{-6}$	$1,52.10^{-6}$	$1,52.10^{-6}$	$1,52.10^{-6}$
MSE(Aseton)	$1,29.10^{-4}$	$9,87.10^{-5}$	$7,64.10^{-5}$	$9,68.10^{-5}$	$7,31.10^{-5}$
Trikloretilen için RAE (%)	0,158	0,158	0,158	0,158	0,158
Aseton için RAE (%)	2,264	1,93	1,46	1,64	1,47
Ortalama RAE (%)	1,21	1,04	0,80	0,89	0,81

Aynı miktarda sensör verisi kullanılması durumunda üyelik fonksiyonları sayısının artırılması performansta iyileşme meydana getirmektedir. Fakat daha az sayıda sensör verisi kullanılmak istenirse, iyi bir performans elde edebilmek için, üyelik


fonksiyonlarının sayısının önceki duruma göre daha fazla sayıda olması gerekmektedir.

ANFIS'in genelleme kabiliyetinin, diğer sezgisel ve ileri seviyeli algoritmalara göre çok yüksek olduğu görülmektedir. Yapay sinir ağlarında, ağın eğitim setini ezberlemesi çok sık karşılaşılan bir durumdur. Bu yapının en önemli özelliği; hem eğitim seti hem de test seti için MSE-Zaman ilişkisinin bir paralellik arz etmesidir. Performans olarak da iyi sonuçlar elde edilmiştir.

5.2. Genel Ağ Topolojisi Belirlemek için Keton–Klorlu Bileşik Gaz Karışımı Uygulaması


Ağın bir olayı öğrenmesi, o olay için en doğru yapay sinir ağı modelini seçmekle mümkündür. Şu ana kadar birçok yapay sinir ağı modeli geliştirilmiştir. Bir yapay sinir ağını; ağın topolojisi, kullanılan aktivasyon fonksiyonu ve öğrenme kuralı karakterize eder. Çalışmalar esnasında esasen çok katmanlı algılayıcı yapısı kullanılmıştır. Yapay sinir ağını karakterize etmek için bir dizi eğitim işlemi yapılmış ve ağın topolojik yapısı belirlenmiştir. Ayrıca ağın eğitime başlarken katmanlar arasındaki ağırlıklar rasgele atandığından başlangıç şartlarının ağın performansına etkisi de incelenmiştir.

Ölçüm sisteminden 9 sensör verisi elde edilmesine rağmen Bölüm 4.3'te anlatılan sebeplerden dolayı en iyi tepki veren 5 sensör seçilmiştir. Örnek olması bakımından sensörlerin, trikloretilenin sabit 1000 ppm, asetonun 0, 1000, 2000, 3000, 4000, 5000 ppm değişen değerleri için oluşturulan gaz karışımlarına verdiği tepkiler Şekil 5.6'da gösterilmiştir.




Şekil 5.6. Sensörlerin, trikloretilenin sabit (1000 ppm), asetonun değişen (0, 1000, 2000, 3000, 4000, 5000 ppm) konsantrasyon değerleri için oluşturulan gaz karışımına verdiği tepkiler: (a) Sensör1 için, (b) Sensör2 için, (c) Sensör3 için, (d) Sensör4 için, (e) Sensör5 için

Sensörlerin trikloretilen-aseton gaz karışımına olan duyarlılıkları Şekil 5.7’de verilmiştir.



Şekil 5.7. Sensörlerin trikloretilen-aseton gaz karımına olan duyarlılıkları: (a) Sensör1'in duyarlılığı, (b) Sensör2'nin duyarlılığı, (c) Sensör3'ün duyarlılığı, (d) Sensör4'ün duyarlılığı, (e) Sensör5'in duyarlılığı

Trikloretilen-aseton gaz karışımı için kullanılan çok katmanlı ağ yapısı Şekil 5.8’de verilmiştir.



Şekil 5.8. Trikloretillen-aseton gaz karışımı için kullanılan çok katmanlı ağ yapısı

Ketonlar gurubundan aseton ve klorlu organik bileşikler gurubundan trikloretillenden oluşan ikili gaz karışımı için yapılan çalışmanın elde edilen verileri Tablo 5.2-5.6’da verilmiştir. Bu tablolarda farklı başlangıç şartları altında gizli katman işlem elemanı sayısı ile aktivasyon fonksiyonunun etkisi; ortalama karesel hata (MSE), iterasyon sayısı, eğitim süresi, ortalama bağıl mutlak hata ve test seti hatasının minimum olduğu nokta bakımından gösterilmiştir. Ağın eğitiminde Levenberg–Marquardt eğitim algoritması kullanılmıştır (Bkz. Bölüm 2.1.9.4).

Yapay sinir ağının eğitimi sırasında durdurma kriteri olarak ortalama karesel hata (MSE) değeri 1.10^{-6} olarak seçilmiştir. Ayrıca, ağın bu değere yakınsayamayıp durağanlaştığı bölgede de eğitim sonlandırılmıştır. Ağın örnekleri ezberlediği bölgeye girmemesi için önlem alınmış ve test seti hatasının minimum olduğu noktadaki ağın parametreleri de kaydedilmiştir.

Tablo 5.2. Birinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonunun etkisi

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Lineer Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	953	10000	1,02E-04	2,25	56	700	1,20E-04	2,34
20	1618	10000	1,65E-05	1,31	324	2150	4,79E-05	1,12
30	2490	10000	2,14E-06	2,08	351	1500	5,06E-05	1,26
40	1915	4954	1,00E-06	2,84	155	400	5,10E-05	1,01
50	1565	2791	9,98E-07	1,61	305	550	5,86E-05	1,03
60	2728	3138	9,97E-07	1,90	468	550	5,26E-05	1,03
70	2657	2400	9,94E-07	1,17	600	550	5,03E-05	0,97
80	3349	2398	9,96E-07	1,17	691	500	5,28E-05	1,01
90	3924	2130	9,97E-07	1,32	994	550	4,64E-05	0,98
100	5133	2249	9,97E-07	1,34	1349	600	5,29E-05	0,96

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış katmanında Sigmoid Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	867	10000	0,00012	2,44	113	1350	1,76E-04	2,48
20	1572	10000	9,70E-06	0,97	374	2450	4,50E-05	1,10
30	2335	10000	6,11E-06	1,28	83	350	7,98E-05	1,55
40	428	1024	1,00E-06	1,15	135	350	3,63E-05	0,87
50	1575	2817	9,99E-07	1,25	467	850	4,37E-05	0,88
60	1187	1351	9,81E-07	1,43	461	550	4,21E-05	0,80
70	1525	1360	9,98E-07	1,10	492	450	4,33E-05	0,88
80	1744	1228	9,97E-07	0,98	888	650	4,57E-05	0,77
90	2201	1176	9,99E-07	0,70	1806	1000	3,27E-05	0,58
100	2758	1207	9,99E-07	0,82	990	450	4,12E-05	0,86

Tablo 5.2’den görüldüğü gibi 10, 20 ve 30 gizli katman nöron sayısı, bu problemin çözümünde uygun yakınsamayı sağlayamamıştır. Ağın çıkışında sigmoid aktivasyon fonksiyonunun kullanılması durumunda test seti hatasının, lineer aktivasyon fonksiyonu kullanılması durumuna göre daha düşük seviyelerde olduğu görülmektedir. Bu başlangıç şartı için, 90 gizli katman nöron sayısına sahip ve çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ağ yapısı uygundur.

Tablo 5.3. İkinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonunun etkisi

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Lineer Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	933,89	10000	1,19E-04	2,12	119	1500	1,34E-04	2,13
20	1635	10000	2,57E-05	1,39	82	550	5,76E-05	1,30
30	2272	10000	2,84E-06	1,69	105	450	4,77E-05	1,03
40	1375	3497	1,00E-06	1,79	235	600	4,83E-05	0,96
50	1257	2210	9,97E-07	1,75	363	650	4,83E-05	0,98
60	2317	2690	9,97E-07	1,36	510	600	5,58E-05	1,05
70	2386	2150	9,96E-07	1,45	710	650	4,64E-05	0,90
80	2688	1911	9,97E-07	1,45	690	500	4,51E-05	0,91
90	4537	2464	1,00E-06	1,35	1184	650	4,95E-05	0,90
100	5672	2485	9,95E-07	1,28	1584	700	4,87E-05	0,97

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Sigmoid Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	426	10000	3,04E-04	3,64	44	500	3,29E-04	3,65
20	1532	10000	2,00E-05	1,37	576	3800	5,95E-05	1,33
30	1153	5000	3,19E-06	1,25	112	500	4,67E-05	0,95
40	1804	4663	9,98E-07	2,20	525	1350	4,25E-05	0,96
50	1137	2004	9,96E-07	1,24	663	1200	2,91E-05	0,73
60	1671	1925	9,91E-07	1,01	382	450	4,28E-05	0,88
70	1113	962	9,96E-07	1,02	606	550	4,07E-05	0,79
80	1932	1349	9,95E-07	1,01	688	500	4,19E-05	0,80
90	2735	1459	9,99E-07	0,92	995	550	3,88E-05	0,78
100	5204	2300	1,00E-06	0,97	2450	1100	3,89E-05	0,78

Tablo 5.3'ten görüldüğü gibi 10, 20 ve 30 gizli katman nöron sayısı, bu problemin çözümünde uygun yakınsamayı sağlayamamıştır. Ağın çıkışında sigmoid aktivasyon fonksiyonunun kullanılması durumunda test seti hatasının, lineer aktivasyon fonksiyonu kullanılması durumuna göre daha düşük seviyelerde olduğu görülmektedir. Bu başlangıç şartı için, 50 gizli katman nöron sayısına sahip ve çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ağ yapısı uygundur.

Tablo 5.4. Üçüncü başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonunun etkisi

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Lineer Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	420	10000	1,60E-04	2,4292	78	950	1,84E-04	2,4168
20	1771	10000	2,01E-05	1,2962	180	1200	5,22E-05	1,1523
30	2292	10000	3,70E-06	1,1668	162	700	4,65E-05	1,0421
40	1696	4410	1,00E-06	2,0061	269	700	5,30E-05	0,9811
50	1112	1975	1,00E-06	2,1032	303	550	5,29E-05	0,9291
60	1770	2054	9,96E-07	1,6792	506	600	4,65E-05	0,9554
70	2530	2291	9,94E-07	1,6053	984	900	4,77E-05	0,9237
80	3183	2297	1,00E-06	1,4852	1155	850	4,95E-05	0,9197
90	4029	2165	9,96E-07	1,6477	1266	700	4,38E-05	0,8793
100	5538	2432	9,97E-07	1,3321	1347	600	5,25E-05	1,0255

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Sigmoid Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	403	5000	2,19E-04	3,1464	403	5000	2,55E-04	3,1464
20	1495	10000	2,78E-05	1,2114	546	3600	5,74E-05	1,1668
30	2283	10000	1,13E-06	1,2662	1138	4950	3,27E-05	0,7642
40	603	1507	9,99E-07	1,2831	172	450	4,16E-05	0,9809
50	1050	1859	1,00E-06	0,6457	987	1800	4,33E-05	0,6492
60	1451	1660	9,99E-07	1,1032	464	550	4,79E-05	0,8642
70	1488	1355	9,93E-07	0,8320	373	350	4,69E-05	0,8717
80	1637	1153	9,98E-07	1,0984	614	450	4,28E-05	0,8204
90	2155	1153	9,96E-07	0,7029	1713	950	3,44E-05	0,6835
100	2850	1244	9,97E-07	1,0135	887	400	4,57E-05	0,9126

Tablo 5.4'ten görüldüğü gibi 10, 20 ve 30 gizli katman nöron sayısı, bu problemin çözümünde uygun yakınsamayı sağlayamamıştır. Ağın çıkışında sigmoid aktivasyon fonksiyonunun kullanılması durumunda test seti hatasının, lineer aktivasyon fonksiyonu kullanılması durumuna göre daha düşük seviyelerde olduğu görülmektedir. Bu başlangıç şartı için, çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ve 30 gizli katman nöron sayısına sahip ağ yapısının test seti hatası en düşükse de eğitim işleminin tamamlanamaması dolayısıyla, 50 gizli katman nöron

sayısına sahip ve çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ağ yapısının kullanılması daha uygundur.

Tablo 5.5. Dördüncü başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonun etkisi

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Lineer Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	817	10000	1,60E-04	2,4291	78	950	1,84E-04	2,4168
20	1763	10000	2,01E-05	1,2962	179	1200	5,22E-05	1,1523
30	2288	10000	3,70E-06	1,3626	160	700	4,65E-05	1,0421
40	1692	4410	1,00E-06	2,0061	267	700	5,30E-05	0,9811
50	1105	1975	1,00E-06	2,1032	300	550	5,29E-05	0,9291
60	1763	2054	9,96E-07	1,6792	504	600	4,65E-05	0,9554
70	2488	2291	9,94E-07	1,6053	966	900	4,77E-05	0,9237
80	3193	2297	1,00E-06	1,4852	1164	850	4,95E-05	0,9197
90	4316	2348	9,99E-07	1,4351	1275	700	4,53E-05	0,8839
100	7537	3361	9,97E-07	1,2804	1561	700	4,76E-05	0,9511

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Sigmoid Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	761	10000	2,19E-04	3,1435	516	6900	2,55E-04	3,1444
20	1508	10000	2,78E-05	1,2114	543	3600	5,74E-05	1,1668
30	2270	10000	1,13E-06	1,2616	1135	4950	4,27E-05	0,7642
40	604	1507	9,99E-07	1,2831	171	450	4,16E-05	0,9809
50	1046	1859	1,00E-06	0,6457	983	1800	4,33E-05	0,6492
60	1442	1660	9,99E-07	1,1032	462	550	4,79E-05	0,8642
70	1483	1355	9,93E-07	0,8320	372	350	4,69E-05	0,8717
80	1626	1153	9,98E-07	1,0984	611	450	4,28E-05	0,8204
90	2132	1149	9,97E-07	0,7794	894	500	3,91E-05	0,8485
100	2470	1086	9,95E-07	0,9020	1097	500	4,24E-05	0,8000

Tablo 5.5'ten görüldüğü gibi 10, 20 ve 30 gizli katman nöron sayısı, bu problemin çözümünde uygun yakınsamayı sağlayamamıştır. Ağın çıkışında sigmoid aktivasyon fonksiyonunun kullanılması durumunda test seti hatasının, lineer aktivasyon fonksiyonu kullanılması durumuna göre daha düşük seviyelerde olduğu

görülmektedir. Bu başlangıç şartı için, 50 gizli katman nöron sayısına sahip ve çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ağ yapısı uygundur.

Tablo 5.6. Beşinci başlangıç şartı için nöron sayısının ve aktivasyon fonksiyonunun etkisi


Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Lineer Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	903	10000	1,60E-04	2,4291	80	950	1,84E-04	2,4168
20	2169	10000	2,27E-05	1,4761	157	1000	5,67E-05	1,2516
30	2344	10000	1,72E-06	2,4979	186	800	4,67E-05	0,9584
40	1851	4736	9,99E-07	1,3654	235	600	4,64E-05	1,0155
50	1642	2940	9,98E-07	2,0344	465	850	5,21E-05	1,0095
60	2471	2847	9,99E-07	1,8953	470	550	5,53E-05	1,1677
70	2960	2650	9,96E-07	1,2341	545	500	5,06E-05	1,0104
80	3381	2421	9,94E-07	1,3044	755	550	5,01E-05	0,9861
90	4459	2456	9,99E-07	1,4734	1433	800	5,14E-05	0,9211
100	5021	2205	9,93E-07	1,6245	1234	550	5,08E-05	0,9449

Gizli Katman Nöron Sayısı	Gizli Katmanda Sigmoid, Çıkış Katmanında Sigmoid Aktivasyon Fonksiyonu							
	Eğitim Seti İçin İstenilen Hata Düzeyine Geline Durum				Test Seti Hatasının Minimum Olduğu Durum			
	Süre (Sn)	İterasyon	MSE	RAE(%)	Süre (Sn)	İterasyon	MSE	RAE(%)
10	831	10000	2,19E-04	3,1435	568	6900	2,55E-04	3,1444
20	1605	10000	1,49E-05	2,1237	187	1300	4,09E-05	1,0437
30	2640	10000	1,32E-06	2,1924	107	450	5,45E-05	1,1195
40	1000	2549	1,00E-06	2,1496	135	350	3,91E-05	0,8353
50	882	1526	9,91E-07	0,8150	278	500	4,06E-05	0,7802
60	1279	1454	1,00E-06	0,7876	340	400	4,04E-05	0,7544
70	1392	1249	9,98E-07	0,9583	427	400	3,99E-05	0,8442
80	1857	1331	9,96E-07	0,9319	537	400	4,47E-05	0,8745
90	3571	1962	9,99E-07	0,9152	1220	720	7,11E-05	0,9913
100	2494	1178	9,91E-07	0,7108	1896	850	2,97E-05	0,6722


Tablo 5.6'dan görüldüğü gibi 10, 20 ve 30 gizli katman nöron sayısı, bu problemin çözümünde uygun yakınsamayı sağlayamamıştır. Ağın çıkışında sigmoid aktivasyon fonksiyonunun kullanılması durumunda test seti hatasının, lineer aktivasyon fonksiyonu kullanılması durumuna göre daha düşük seviyelerde olduğu

görülmektedir. Bu başlangıç şartı için, 100 gizli katman nöron sayısına sahip ve çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı ağ yapısı uygundur.


Tablo 5.2-5.6'dan edinilen bilgilerin ışığında ikili gaz karışımındaki her bir gazın konsantrasyon tahminine yönelik olarak; çıkışında sigmoid aktivasyon fonksiyonunun kullanıldığı 50, 80 veya 90 gizli katman nöron sayısına sahip ağ yapısının uygun olduğu görülmektedir. Eğitim seti ve test setinin ortalama karesel hatasının zamanla değişimi incelenerek daha kapsamlı bilgiler elde edilebilir. Şekil 5.9-5.13'te ağın gizli katmanında sigmoid, çıkış katmanında da sigmoid aktivasyon fonksiyonu kullanılması durumunda eğitim ve test setinin MSE-zaman ilişkisi, gizli katmanda kullanılan farklı sayıdaki nöron sayısına (50,80,90) bağlı olarak verilmiştir.




Şekil 5.9. Birinci başlangıç şartı için MSE-Zaman grafiği




Şekil 5.10. İkinci başlangıç şartı için MSE-Zaman grafiği



Şekil 5.11. Üçüncü başlangıç şartı için MSE-Zaman grafiği



Şekil 5.12. Dördüncü başlangıç şartı için MSE-Zaman grafiği



Şekil 5.13. Beşinci başlangıç şartı için MSE-Zaman grafiği


Bu beş başlangıç şartı göz önüne alındığında, çıkış katmanında sigmoid aktivasyon fonksiyonunun kullanıldığı 50 gizli katman nöron sayısına sahip ağ yapısı; eğitim süresi, ortalama karesel hata (MSE) ve ortalama bağıl mutlak hata (RAE) bakımından en uygun olanıdır. Ayrıca ağın çok fazla eğitilmesi durumunda

performansta düşme yaşandığından test seti hatasının en düşük olduğu noktada eğitimi durdurmak fayda sağlamıştır. Böylece, ağın eğitim setini ezberlemesinin önüne geçilmiştir. Çok katmanlı algılayıcılarla yapılacak diğer çalışmalarda bu ağ topolojisi baz alınmıştır.

5.3. Keton–Klorlu Bileşik Gaz Karışımı için Sezgisel ve İleri Seviyeli Algoritmaların Performanslarının Karşılaştırılması


Bu kısımda, Bölüm 2.1’de bahsedilen eğitim algoritmaları, keton-klorlu organik bileşik gaz karışımı için karşılaştırmalı olarak verilmiştir.

Ölçüm sisteminden elde edilen verilerden, eğitim seti için 280, test seti için 560 örnekleme alınmış ve ileri beslemeli çok katmanlı ağ yapısı üzerinde, değişik eğitim algoritmalarının performansları değerlendirilmiştir. Ön işleme tekniği olarak, veriler 0,1-0,9 arasına normalize edilmiştir. Eğitim aşamasında, yeterince büyük olması bakımından maksimum iterasyon sayısı 100000 olarak belirlenmiştir. Standart geri yayılım algoritmasında yakınsama yavaş olduğundan 300000 iterasyona kadar gidilmiştir. Amaçlanan ortalama karesel hata (MSE) 1.10^{-6} ’dır. Levenberg-Marquardt eğitim algoritmasında, amaçlanan MSE’ye daha önce ulaşıldığından eğitim işlemi daha maksimum iterasyona ulaşılmadan sonlandırılmıştır. Kullanılan ileri beslemeli ağın yapısı Şekil 5.14’te verilmiştir.




Şekil 5.14. Değişik eğitim algoritmalarının performanslarının değerlendirilmesinde kullanılan ağ yapısı

Standart geri yayılım (Back Propagation) ve esnek yayılım (Resilient Propagation) algoritmaları kullanılarak ağın eğitimi yapıldığında, her iki algoritmanın da amaçlanan MSE'ye ulaşamadığını ve esnek yayılımın standart geri yayılım algoritmasına göre daha hızlı olduğu Şekil 5.15 ve Şekil 5.16'dan görülmektedir.




Şekil 5.15. Standart geri yayılım algoritması için eğitim ve test setinin MSE-Zaman grafiği



Şekil 5.16. Esnek yayılım algoritması için eğitim ve test setinin MSE-Zaman grafiği

Şekil 5.15 ve Şekil 5.16'dan görüldüğü gibi ortalama karesel hatanın değişimi, eğitim ve test seti için benzerdir. Bu durum genel olarak, ağıın eğitim setini öğrendiğinin yani ezberlemediğinin bir göstergesidir. Dolayısıyla ağıın genelleme kabiliyeti yüksektir. Bu şekilde eğitilen yapay sinir ağıları, eğitimde kullanılmamış olan test setine de iyi cevaplar verirler. Şayet ağı ezber yapmaya başlarsa, ağıın olayı genelleme kabiliyeti azalır ve performansı düşer. Bu iki öğrenme algoritması için de amaçlanan yakınsama sağlanamadığından ağıın performansı düşüktür.


Conjugate-gradient algoritması kullanılarak ağıın eğitimi yapıldığında, standart geri yayılım ve esnek yayılıma göre bu algoritmanın daha iyi olduğunu söylenebilir. Eğitimin sonunda amaçlanan yakınsama şartı sağlanamamıştır. Test setinin ortalama karesel hatasının, yaklaşık 10^{-4} 'e ulaştığı bölgeden sonra, eğitim setinin ortalama karesel hatasına göre daha yavaş azaldığı Şekil 5.17'den görülmektedir. Bu noktadan sonra ağıın, eğitim setini ezberlemeye başladığı anlaşılmaktadır.



Şekil 5.17. Conjugate-gradient algoritması için eğitim ve test setinin MSE-Zaman grafiği


Quasi-Newton algoritması kullanılarak ağıın eğitimi yapıldığında, amaçlanan yakınsama yaklaşık olarak sağlanmıştır. 100000 iterasyon için eğitim süresinin, standart geri yayılım, esnek yayılım ve conjugate-gradient algoritmalarına göre çok

daha fazla olduğunu Şekil 5.18’den görülmektedir. Bunun sebebi, Bölüm 2.1.9.2’de bahsedildiği gibi yaklaşık Hessian matrisinin tersinin hesaplanmasının uzun sürmesindendir. Conjugate-gradient algoritmasında olduğu gibi, test setinin ortalama karesel hatası yaklaşık 10^{-4} ’ten sonra, eğitim setinin ortalama karesel hatasına göre daha yavaş azalmaktadır. Bu noktadan sonra ağı, eğitim setini ezberlemeye başladığı anlaşılmaktadır.



Şekil 5.18. Quasi-Newton algoritması için eğitim ve test setinin MSE-Zaman grafiği

Yapılacak çalışmalara temel teşkil edecek ağ yapısının tayini aşamasında (Bkz. Bölüm 5.2) kullanılan Levenberg-Marquardt algoritmasının, yukarıda bahsi geçen tüm algoritmalar arasında, eğitim süresi ve amaçlanan yakınsama bakımından en iyi sonucu verdiği Şekil 5.19’dan görülmektedir. Amaçlanan yakınsamaya yaklaşık 1000 saniyede ulaşılmıştır. Her bir iterasyon için eğitim süresi fazla olmasına rağmen, yakınsama şartına daha kısa zamanda ulaşılmıştır. Bu algorithmada da ezberlemenin olduğunu görülmektedir.



Şekil 5.19. Levenberg-Marquardt algoritması için eğitim ve test setinin MSE-Zaman grafiği

Ağın, eğitim setini ezberlemeye başlaması demek, genelleme yeteneğinin azalması demek olduğundan, test setinin ortalama karesel hatasının minimum olduğu noktadaki ağın parametreleri kaydedilmiş ve maksimum iterasyon sayısına ulaşan ağ yapısıyla, performans ve eğitim süresi bakımından karşılaştırmalı olarak Tablo 5.7’de özetlenmiştir.

Tablo 5.7. Eğitim algoritmalarının performans değerlendirmesi

Algoritma Performans		Standart Geri Yayılım	Esnek Yayılım	Conjugate- Gradient	Quasi- Newton	Levenberg- Marquardt
Eğitim	MSE (eğitim)	$1,20 \cdot 10^{-3}$	$2,00 \cdot 10^{-4}$	$3,80 \cdot 10^{-5}$	$3,00 \cdot 10^{-6}$	$1,00 \cdot 10^{-6}$
	Ortalama RAE (%)	6,365	2,815	1,05	0,745	0,645
	Süre (sn.)	19980	3332	6488	22748	1050
Test (Optimum)	MSE (test)	$1,19 \cdot 10^{-3}$	$2,10 \cdot 10^{-4}$	$5,70 \cdot 10^{-5}$	$3,70 \cdot 10^{-5}$	$4,33 \cdot 10^{-5}$
	RAE (%) {Trikloretillen}	1,21	0,98	0,2	0,22	0,11
	RAE (%) {Aseton}	11,52	4,6	1,9	1,59	1,19
	Ortalama RAE (%)	6,365	2,79	1,05	0,905	0,65
	Süre (sn.)	19980	3316	6456	5245	987

İkili gaz karışımındaki her bir gazın miktarsal olarak belirlenmesinde; eğitim süresi, MSE ve RAE bakımından en iyi eğitim algoritmasının Levenberg-Marquardt algoritması olduğu söylenebilir.

Trikloretilenin sabit konsantrasyonda tutulduğu (5000 ppm), asetonun da değişen konsantrasyonlarındaki (1000, 2000, ..., 5000 ppm) gaz karışımlarına, Levenberg-Marquardt eğitim algoritmasını kullanan ağın ürettiği tahmini ve gerçek konsantrasyon değerleri Tablo 5.8’de verilmiştir.


Tablo 5.8. Gaz karışımı için gerçek ve tahmini değerler

GERÇEK DEĞERLER		TAHMİNİ DEĞERLER	
Trikloretilen (PPM)	Aseton (PPM)	Trikloretilen (PPM)	Aseton (PPM)
5000	1000	5002,3	1005,7
5000	1000	4999,5	1003,1
5000	1000	5000,8	1036,6
5000	2000	4986,2	1978,9
5000	2000	4994,3	1996,5
5000	2000	4996,2	1988,3
5000	3000	4998,6	3000,7
5000	3000	4997,2	3001,6
5000	3000	4995,8	3000,4
5000	4000	5002	3998,1
5000	4000	4999,8	3997,4
5000	4000	4998,5	4025,9
5000	5000	5000,9	5069,1
5000	5000	5001,9	5068,4
5000	5000	5001,7	4950,8

5.4. Alifatik ve Aromatik Gaz Karışımı için Radyal Temelli Yapay Sinir Ağı Uygulaması


Bu çalışmada ikili gaz karışımındaki (benzen ve n-hekzan karışımı) her bir gazın konsantrasyonunun miktarsal tayini, radyal temelli yapay sinir ağları (Bkz. Bölüm 2.1.7) kullanılarak gerçekleştirilmiştir. Radyal temelli ağlar, ileri beslemeli ve tek gizli katmana sahiptirler. Gizli katmandaki işlem elemanlarının sayısı eğitim setindeki örnek sayısı kadardır. Dolayısıyla eğitim setinin büyük olması durumunda ağın topolojik yapısı da büyük olacaktır. Bu çalışmada ayrıca, ağın topolojik yapısını küçültmek için bir yöntem önerilmiştir.

Kullanılan 5 sensörün, benzenin sabit 3000 ppm, n-hekzanın da 0, 1000, 2000, 3000, 4000, 5000 ppm değişen konsantrasyon değerleri için oluşturulan gaz karışımlarına verdiği tepkiler Şekil 5.20’de verilmiştir.




Şekil 5.20. Sensörlerin, benzenin sabit (3000 ppm), n-hekzanın değişen (0, 1000, 2000, 3000, 4000, 5000 ppm) konsantrasyon değerleri için oluşturulan gaz karışımına verdiği tepkiler: (a) Sensör1 için, (b) Sensör2 için, (c) Sensör3 için, (d) Sensör4 için, (e) Sensör5 için

Sensörlerin benzen-n-hekzan gaz karışımına olan duyarlılıkları Şekil 5.21’de verilmiştir.




Şekil 5.21. Sensörlerin benzen-n-hekzan gaz karımına olan duyarlılıkları: (a) Sensör1'in duyarlılığı, (b) Sensör2'nin duyarlılığı, (c) Sensör3'ün duyarlılığı, (d) Sensör4'ün duyarlılığı, (e) Sensör5'in duyarlılığı

Kullanılan radyal temelli ağın şematik gösterimi Şekil 5.22'deki gibidir.




Şekil 5.22. Radyal temelli ağın yapısı

Radyal temelli ağın eğitimi için kullanılan eğitim seti 490, test seti ise 735 örnekten oluşturulmuştur. Dağılım (Spread) faktörü, değişik denemelerden sonra 0,04 olarak belirlenmiştir. Elde edilen frekans kaymaları 0,1-0,9 arasına normalize edilmiştir. Ağın eğitilmesi aşamasında eğitim ve test setinin ortalama karesel hatasının zamanla değişimi Şekil 5.23'te verilmiştir.



Şekil 5.23. Eğitim ve test setinin MSE-Zaman grafiği

Şekil 5.23'ten görüldüğü gibi amaçlana yakınsama (1.10^{-6}) eğitim seti için sağlanmıştır. Test setinin ortalama karesel hatası 8.10^{-6} dolaylarındadır. Eğitim 88 saniyede tamamlanmıştır. Gizli katmanda 425 tane işlem elemanı kullanılmıştır. Ağın topolojik yapısı oldukça büyüktür. Radyal temelli ağlarda gizli katmanda genellikle çan eğrisi biçiminde olan radyal fonksiyonlar kullanılır. Buradan hareketle ağın topolojik yapısını küçültmek için her bir gaz karışımı (35 karışım) için eğitim setindeki verilerin ortalaması ve standart sapması dikkate alınarak eğitim seti tekrardan oluşturulmuştur. Her bir gaz karışımı için tüm veriler yerine; standart sapma, standart sapma ile ortalamanın toplamı ve standart sapma ile ortalamanın farkı kullanılmıştır. Böylece 490 veriden oluşan eğitim seti 105'e indirgenmiştir. 105 eğitim verisi ve 735 test verisi için ağın eğitimi yapılmış ve ortalama karesel hatanın zamanla değişimi Şekil 5.24'te verilmiştir.




Şekil 5.24. Azaltılmış eğitim seti için eğitim ve test setinin MSE-Zaman grafiği


Yukarıdaki grafikten görüldüğü gibi amaçlanan yakınsama (1.10^{-6}) eğitim seti için sağlanmıştır. Test setinin ortalama karesel hatası ise 8.10^{-5} dolaylarındadır. Eğitim yaklaşık 1,5 saniyede tamamlanmıştır. Gizli katmanda 105 tane işlem elemanı kullanılmış ve bu suretle ağın topolojik yapısı yaklaşık %75 oranında düşürülmüştür.

Momentumlu standart geri yayılım algoritması ve daha önceki kısımlarda güçlü bir eğitim algoritması olduğu tespit edilen Levenberg-Marquardt algoritması ile de

eğitim işlemi yapılmış (Bkz. Şekil 5.25, Şekil 5.26) ve performans değerlendirmesi Tablo 5.9’da karşılaştırmalı olarak verilmiştir.



Şekil 5.25. Levenberg-Marquardt algoritması için MSE-Zaman grafiği



Şekil 5.26. Standart geri yalınım algoritması için MSE-Zaman grafiği

Tablo 5.9. Değişik ağ yapılarının performans değerlendirmesi

Eğitim Algoritması Performans	Standart Geri Yayılım	Levenberg-Marquard	Radyal Temelli Ağ	
			Azaltılmış eğitim seti	Tüm eğitim seti
Eğitim setindeki örnek sayısı	490	490	105	490
Test setindeki örnek sayısı	735	735	735	735
Ağ Topolojisi	5-50-2	5-50-2	5-105-2	5-425-2
İterasyon Sayısı	150000	1765	105	425
Eğitim Süresi (sn.)	3463	596	1,4	88
E(RAE) % (Benzen)	3,33	0,11	1,26	0,21
E(RAE) % (Hekzan)	7,32	0,89	1,78	0,49
E(RAE) % (Ortalama)	5,32	0,5	1,52	0,35

Momentumlu standart geri yayılım algoritmasında, ağın eğitim işlemi diğer algoritmalarla göre çok daha uzun sürmüştür ve amaçlanan yakınsama şartı sağlanamamıştır.

Levenberg-Marquardt eğitim algoritmasında ikinci derece türevlere dayalı Hessian matrisi hesaplandığından dolayı, eğitim süresi radyal temelli ağa göre çok daha uzun sürmüştür fakat amaçlanan yakınsama şartı sağlanmıştır.

Tüm eğitim setinin kullanıldığı radyal temelli ağın performansı diğer tüm algoritmalarla göre daha iyidir. Fakat ağın topolojik yapısı oldukça büyüktür. Radyal temelli ağın bu eksikliğini gidermek için önerilen azaltılmış eğitim setine sahip radyal temelli ağın, eğitim süresi ve ağ topolojisi oldukça makul değerlere sahiptir. Performans bakımından da momentumlu standart geri yayılım algoritmasına göre çok daha iyi sonuç verdiği görülmüştür.

Benzen için performans ölçütünün, n-hekzana göre çok daha iyi olduğu Tablo 5.9'dan görülebilir. Duyarlılık grafikleri (Bkz. Şekil 5.21) incelendiğinde, sensörlerin

benzene karşı daha duyarlı olduğu ve sensör cevaplarının performans ölçütü üzerinde direkt olarak etkili olduğu söylenebilir.


5.5. Keton–Klorlu Bileşik Gaz Karışımı için Zaman Gecikmeli (Tapped Time Delay) YSA Uygulaması

Bu çalışmada ikili gaz karışımındaki (trikloretilen ve aseton karışımı) her bir gazın konsantrasyonunun miktarsal tayini, zaman gecikmeli yapay sinir ağı kullanılarak gerçekleştirilmiştir. Bu ağ, ileri beslemeli ve çok katmanlı algılayıcı yapısındadır. Daha önceki uygulamalardan farklı olarak eğitim ve test seti, sensörlerin sürekli hal cevaplarının yanı sıra geçici hal cevaplarını da içermektedir. Sensörlerin hem şimdiki hem de geçmiş frekans kayma değerleri ağın girişine uygulanmıştır. Daha fazla sayıda sensör cevaplarının geçmiş değerlerinin kullanılması, geçici hal sensör cevaplarının karakteristiği hakkında daha fazla bilgi vereceği düşünülerek 2, 4 veya 7 zaman gecikmeli sensör cevapları ağın girişine uygulanmıştır. Beş sensör kullanıldığından ağa uygulanan giriş sayısı; 2 gecikmeli için 15 ($5+5*2=15$), 4 gecikmeli için 25 ($5+5*4=25$) ve 7 gecikmeli için 40 ($5+5*7=40$)'tır. Gizli katmanda kullanılacak optimum nöron sayısını belirlemek için 10, 30 ve 50 nörona sahip gizli katman yapıları denenmiştir. Ağın çıkış katmanının da ise, her bir gazın konsantrasyonunu gösteren iki nöron bulunmaktadır.

Kullanılan gaz karışımı için ayrı ayrı iki ölçüm yapılmıştır. Beş sensörün sürekli hal ve geçici hal cevaplarından elde edilen 2100 adet veri, ağın eğitim ve test proseslerinde kullanılmıştır. Bu veriler 0,1-0,9 arasına normalize edilmek suretiyle ön işlemeye tabi tutulmuştur. Ağın eğitimini durdurma kriteri olarak, ortalama karesel hata değeri 10^{-6} ve maksimum eğitim zamanı 20000 saniye olarak belirlenmiştir.


Şekil 5.27'den görüldüğü gibi, 5 sensörün frekans kayma değerleri ($\Delta f_1(n), \dots, \Delta f_5(n)$) ve k (2, 4 veya 7) adet geciktirilmiş değerleri ağın giriş

katmanına uygulanmıştır. Ağın gizli katmanında N (10, 30 veya 50) adet nöron ve çıkış katmanında da 2 adet nöron bulunmaktadır.




Şekil 5.27. Zaman gecikmeli ağ yapısı

Şekil 5.28'den görüldüğü gibi 10 gizli katman nöron sayısına sahip ağ yapısı hedeflenen yakınsamayı (10^{-6}) sağlayamamıştır. Zaman gecikme miktarlarının artırılmasıyla ortalama karesel hata $2 \cdot 10^{-5}$ dolaylarına kadar düşmektedir.




Şekil 5.28. 10 nörona sahip gizli katman için eğitim performansı

Şekil 5.29'dan görüldüğü gibi 30 gizli katman nöron sayısına sahip ağ yapısı hedeflenen yakınsamayı (10^{-6}) sağlayamamıştır. Zaman gecikme miktarlarının artırılmasıyla ortalama karesel hata $8 \cdot 10^{-6}$ dolaylarına kadar düşmektedir.




Şekil 5.29. 30 nörona sahip gizli katman için eğitim performansı

Şekil 5.30'dan görüldüğü gibi 50 gizli katman nöron sayısına sahip ağ yapısı, hedeflenen yakınsamayı (10^{-6}) 7 tane geciktirilmiş giriş seti için yaklaşık olarak sağlamıştır.




Şekil 5.30. 50 nörona sahip gizli katman için eğitim performansı

Eğitim performans grafikleri incelendiğinde, nöron sayısının sabit tutulup geciktirilmiş giriş sayısı arttırıldığında ortalama karesel hatanın düştüğü görülebilir. Ayrıca nöron sayısının arttırılmasıyla da aynı etki gözlenmektedir. Bu etki, 7 tane geciktirilmiş giriş için Şekil 5.31'de gösterilmiştir.



Şekil 5.31. 7 tane geciktirilmiş giriş seti için eğitim performansı

En iyi yakınsamanın, 7 tane geciktirilmiş giriş ve 50 gizli katman nöron sayısına sahip ağ yapısında sağlandığı söylenebilir. Bu ağ yapısı için eğitim ve test setinin MSE-Zaman grafiği Şekil 5.32’de verilmiştir.



Şekil 5.32. Eğitim ve test setinin MSE-Zaman grafiği

Test setinin ortalama karesel hatasının 10^{-4} olduğu noktadan sonra, eğitim setinin ortalama karesel hatasına göre daha yavaş yakınsadığı ve 10^{-5} civarında da neredeyse sabit olduğu Şekil 5.32’den görülmektedir. Bu durum, ağı eğitim setini ezberlemeye başladığını gösterir. Dolayısıyla ağı genelleme yapabilme kabiliyeti azalmaktadır. Bunun önüne geçebilmek için, test setinin ortalama karesel hatasının minimum olduğu noktadaki eğitilmiş ağ yapısı kaydedilmiş ve Tablo 5.10’da verilen performans değerleri hesaplanmıştır.

Tablo 5.10. Zaman gecikmeli ağı performans değerlendirmesi

Ağ Yapısı Performans	2 Gecikmeli			4 Gecikmeli			7 Gecikmeli		
	15-10-2	15-30-2	15-50-2	25-10-2	25-30-2	25-50-2	40-10-2	40-30-2	40-50-2
Trikloretilen için RAE (%)	4,4	1,61	0,91	3,25	0,77	0,48	1,8	0,55	0,33
Aseton için RAE (%)	8,38	2,36	1,37	6,67	1,75	1,04	4	0,92	0,99
Ortalama RAE (%)	6,4	2,02	1,14	4,96	1,26	0,76	2,9	0,74	0,66
Eğitim Zamanı (sn.)	674	10191	12239	971	12876	14283	1678	15234	17147

Daha önce yapılan çalışmalarda sensörlerin sürekli hal karakteristiklerinden yararlanılıyordu. Sensörlerin sürekli hal bölgesine gelmeleri birkaç dakika aldığından, ağı tahmin süresi de dakikalar mertebesindeydi. Bu çalışmada ise, sensörlerin geçici hal bölgeleri de dikkate alındığından, ağı tahmin süresi saniyeler mertebesinde dir.

Zaman gecikmeli yapay sinir ağlarında eğitim süresi biraz uzun olmasına rağmen tahmin süresi kısadır. Bu ağ yapısı yardımıyla, sensörler sürekli hal bölgesine girmeden, gaz karışımına ait konsantrasyon tahmini yapılabilmektedir.

5.6. Keton–Klorlu Bileşik Gaz Karışımı için Sensör Cevaplarının Eğim Bilgisinin Kullanıldığı YSA Uygulaması

İkili gaz karışımındaki (trikloretilen ve aseton karışımı) her bir gazın miktarsal tahmini, sensörlerin sürekli hal-geçici hal cevapları ve bu cevaplardan elde edilen eğim bilgileri kullanılarak yapılmıştır. Ayrıca ağın topolojisi ve performansı, önceki uygulamalarla karşılaştırmalı olarak verilmiştir.


Bu çalışmada üç farklı yapay sinir ağı yapısı kullanılmıştır. İlk ağ yapısı, Bölüm 5.3'te kullanılan yapay sinir ağıdır: Sensörlerin sürekli hal cevapları ve ileri beslemeli yapay sinir ağı modeli kullanılmıştır. İkinci ağ yapısı, Bölüm 5.5'te kullanılan yapay sinir ağıdır: Sensörlerin sürekli hal-geçici hal cevaplarının kullanıldığı ve bu cevapların belli bir zaman gecikmesiyle ağa uygulandığı zaman gecikmeli (time tapped delay) yapay sinir ağı modelidir. Bu çalışmanın odak noktası olan, üçüncü ağ yapısı ise, sensörlerin sürekli hal-geçici hal cevapları ve bu cevaplardan elde edilen eğim bilgilerinin kullanıldığı ileri beslemeli ağ modelidir.

Gazların miktarsal sınıflandırılması yapılırken genellikle sürekli hal cevapları kullanılmasına rağmen, QCM sensörlerin cevap sürelerinin uzun olmasından dolayı sensörlerin geçici hal cevaplarının kullanılması ön plana çıkmaya başlamıştır. Sensörlere gaz uygulandığında, ölçümün başlangıç aşamasında sensörlerin verdiği geçici hal cevapları hızlı bir şekilde değişim gösterir. Dolayısıyla bu geçici hal cevaplarının eğimi başlangıçta en büyük değerine ulaşır ve zamanla azalmaya başlar. Sürekli hal bölgesine girildiğinde ise sifıra yakınsar. Sürekli hal cevabı ile kıyaslandığında, geçici hal cevabı ve ek olarak eğim bilgisinin kullanılması gaz karışımındaki her bir gazın konsantrasyon değerinin tahmin süresini epeyce kısaltmıştır [63]. Özetle, sürekli hal rejimine girilmeden konsantrasyon tahmini yapılmıştır.

Geçici hal bölgesinde bir nokta göz önüne alındığında, eğim bilgisi; bu nokta ve 7 birim zaman öncesindeki nokta kullanılarak hesaplanmıştır. 7 birim zaman gecikmesi


alınmasının nedeni ise zaman gecikmeli yapay sinir ağı modeli ile bir kıyaslama yapmak içindir.

Kullanılan yapay sinir ağının modeli Şekil 5.33'te gösterildiği gibi ileri beslemeli ve çok katmanlı bir ağ yapısındadır. Girdi katmanına $\Delta f_1, \Delta f_2, \dots, \Delta f_5$ ile gösterilen sensörlerin frekans kaymaları ve bu frekans kaymalarına ait olan $S\Delta f_1, S\Delta f_2, \dots, S\Delta f_5$ ile gösterilen eğim bilgileri uygulanmıştır. Ara katmanda, önceki çalışmalarda olduğu gibi 50 işlem elemanı, çıktı katmanında ise gaz karışımındaki her bir gazın konsantrasyonunu göstermesi bakımından 2 işlem elemanı kullanılmıştır. Bölüm 5.3'te, sensörlerin sürekli hal cevaplarının eğitimi aşamasında en hızlı ve en doğru sonucu veren algoritma Levenberg-Marquardt algoritması olduğundan çalışmada bu algoritma kullanılmıştır.



Şekil 5.33. Sensör cevabının ve eğiminin kullanıldığı yapay sinir ağı modeli

Yapay sinir ağının eğitimi ve test aşamasında kullanılacak veriler için iki ayrı ölçüm yapılmıştır. Eğitim verileri hazırlanırken, sensörlerin sürekli hal ve geçici hal cevaplarından temizleme fazı çıkarılmış, elde edilen veriler, frekans kaymalarını bulmak için orijine çekilmiştir. Bu frekans kaymalarından da yola çıkarak eğim bilgisi hesaplanmıştır. Bu aşamalar Şekil 5.34'te gösterilmiştir.




Şekil 5.34. Trikloretilen sabit 1000 ppm, aseton 0, 1000, 2000, 3000, 4000, 5000 ppm gaz karışımına Sensör4'ün verdiği cevaplar: (a) ölçüm verisi, (b) temizleme fazı çıkartılmış veri, (c) orijine indirgenmiş veri, (d) indirgenmiş veri ve eğim bilgisi

Sensörlerin frekans kaymalarından elde edilen eğim bilgisinin hesaplanması, Eşitlik (5.2)'de gösterilmiştir.

$$S\Delta f(t) = \begin{cases} \frac{\Delta f(t) - \Delta f(t - n^*t_s)}{n^*t_s}, & 0 \leq S\Delta f(t) \\ 0, & S\Delta f(t) < 0 \end{cases} \quad (5.2)$$

Eşitlik (5.2)'de $\Delta f(t)$; t zamanındaki sensörün frekans kaymasını, $\Delta f(t - n * t_s)$; $\Delta f(t)$ 'nin n . geçmiş değerini, t_s (2 sn.); örnekleme zamanını göstermektedir. Bu çalışmada n değeri 7 olarak alınmıştır. Bu nedenle her bir konsantrasyonun ilk eğim değerinin hesaplanması için 8 ölçüm süresinin (t_s) geçmesi gerekmektedir. Yani ilk eğim bilgisi 16 sn. ($8 * t_s$) sonra elde edilir.

Sensörlerin frekans kaymalarının ve eğim bilgilerinin kullanıldığı yapay sinir ağının eğitim sürecinde, durdurma kriteri olarak ortalama karesel hata (MSE) değeri 10^{-6} ve maksimum eğitim süresi 30000 sn. seçilmiştir. Performans değerlendirme kriteri olarak ise ortalama bağıl mutlak hata (E(RAE)) kullanılmıştır (MSE, tek başına hatanın dağılımı hakkında bilgi içermez). Ağın eğitimi sırasında, eğitim ve test seti için, MSE'nin zamana bağlı grafiği Şekil 5.35'te gösterilmiştir.




Şekil 5.35. Eğitim ve test seti için MSE'nin zamanla değişimi

Şekil 5.35 incelendiğinde, test setinin ortalama karesel hatası (MSE), 10^{-4} civarına düştüğünde eğitim setine göre daha yavaş azaldığı görülmektedir. Hatta MSE değeri, 10^{-4} ile 10^{-5} arasında hemen hemen sabit kalmaktadır. Bu durum yapay sinir ağının eğitim setini ezberlemeye başladığını gösterir. Test setinin MSE değeri minimum değerine ulaştığında optimum ağ yapısı belirlenmiştir. Böylece ağın, eğitim setini

ezberlemesinin önüne geçilmiş ve genelleme kabiliyetinin yüksek olması sağlanmıştır.

Yapay sinir ağının performans değerlendirmesi yapılırken, sensör cevabı Şekil 5.36'dan görüldüğü gibi dört kısma bölünmüştür. 4 numaralı bölge (ki sensör cevabı olarak bilinir) her ölçüm fazından yaklaşık 12 sn. sonra başlamaktadır. 3 numaralı bölge, 4 numaralı bölgenin başladığı noktadan yaklaşık 120 sn. sonra başlamaktadır. 2 numaralı bölge, 3 numaralı bölgenin başladığı noktadan yaklaşık 120sn. sonra başlamaktadır ve 1 numaralı bölge, 2 numaralı bölgenin başladığı noktadan yaklaşık 160 sn. sonra başlamaktadır.



Şekil 5.36. Performans analizi için sensör cevabının bölgelere ayrılması

Sensörlerin sürekli hal-geçici hal frekans kaymalarının ve eğim bilgilerinin yapay sinir ağına giriş olarak verildiği ağ yapısı (NN3), Bölüm 5.3'te verilen sürekli hal frekans kaymalarının ağına girişine uygulandığı ağ yapısı (NN1) ve Bölüm 5.5'te verilen sürekli hal-geçici hal frekans kaymaları ve yedi geçmiş değerinin ağına girişine uygulandığı zaman gecikmeli yapay sinir ağ yapısının (NN2), Şekil 5.36'da gösterilen bölgeler için performans değerlendirmesi Tablo 5.11'de verilmiştir.

Tablo 5.11. Kullanılan yapay sinir ağlarının performans değerlendirmesi

Ağ Türü	NN1	NN2			NN3		
Performans							
Performans Değerlendirmesinin Yapıldığı Bölgeler	1	4	3	2	4	3	2
E(RAE) (Trikloretilen) %	0,11	0,44	0,41	0,4	0,18	0,14	0,12
E(RAE) (Aseton) %	1,19	1,09	1,03	1,01	1,23	1,13	1,06
Ortalama E(RAE) %	0,65	0,76	0,72	0,71	0,71	0,63	0,59
Yaklaşık Tahmin Süresi (sn.)	414	28	148	268	28	148	268
Test Seti için Minimum MSE ($\times 10^{-4}$)	0,43	0,17			0,22		
Ağ Topolojisi	5-50-2	40-50-2			10-50-2		
Ağın sahip olduğu ağırlık sayısı	402	2152			652		

NN1: Sensörlerin sürekli kal frekans kaymalarının kullanıldığı ağ yapısı

NN2: Sensörlerin sürekli hal-geçici hal frekans kaymalarının ve yedi geçmiş değerinin kullanıldığı ağ yapısı

NN3: Sürekli hal-geçici hal frekans kaymalarının ve eğim bilgilerinin kullanıldığı ağ yapısı

Tüm yapay sinir ağı modellerinde Levenberg-Marquardt eğitim algoritması kullanılmasına rağmen NN1 en hızlı yakınsamayı ve en düşük ortalama karesel hatayı (MSE) vermiştir. Bunun sebebi, NN1'in ağ topolojisinin daha küçük olması ve daha az eğitim verisi kullanıyor olmasıdır. Fakat NN2 ve NN3'ün test performansı NN1'den daha iyidir.

Kullanılan QCM sensörlerin sürekli hal bölgelerine erişme süreleri yaklaşık 250-300 sn. kadardır. NN1 ancak bu süreden sonra tahmin yapabilme yeteneğine sahiptir. NN2 ve NN3 ise sensörlerin sürekli rejime ulaşmalarından çok önce gazların miktarsal tahminini yapabilmektedir.

NN2 ve NN3'ün eğitim süreleri NN1'e göre çok daha fazladır fakat tahmin süreleri çok daha kısadır. Miktersal sınıflandırma yapılan bir sistem düşünüldüğünde tahmin süresi, eğitim süresinden çok daha önemli bir parametredir.

NN2 ve NN3'ün performansları incelendiğinde NN3'ün performansının bir parça daha iyi olduğu görülür. NN2 40 giriş verisi (her bir sensörün kendi cevabı ve yedi geçmiş cevabı), NN3 ise 10 giriş verisi (her bir sensörün kendi cevabı ve eğim

bilgisi) kullanmasına rağmen, NN3 beklenenin aksine daha iyi sonuç vermiştir. Bunun sebebi, NN3 için eğim değerleri hesaplanırken eksi işarete sahip eğim değerlerinin filtrelenmiş olmasıdır. Çünkü eksi eğim bilgisi, sensör cevap karakteristiğine aykırıdır.

Performans olarak NN3'ün NN2'ye göre daha iyi olmasının yanında, ağıın topolojik yapısının da çok daha küçük olduğu görülmektedir.

Eğim bilgisinin kullanıldığı yapay sinir ağı modelinin, zaman gecikmeli yapay sinir ağı modeline bir alternatif olduğu söylenebilir.

5.7. Yedi Farklı İkili Gaz Karışımının Niteliksel ve Niceliksel Olarak Sınıflandırılması

Bu çalışmanın ilk aşamasında, bir istatistiksel yapay sinir ağı modeli olan olasılıksal yapay sinir ağları (Probabilistic Neural Network - PNN) kullanılarak belirlenmiş yedi farklı ikili gaz karışımının niteliksel sınıflandırması yapılmıştır. İkinci aşamasında ise, bu ikili gaz karışımlarının her biri için çok katmanlı ve ileri beslemeli yapay sinir ağları kullanılarak bu gazların niceliksel sınıflandırması yapılmıştır. Daha sonra bu iki aşama birleştirilerek, bu yedi farklı ikili gaz karışımını, hem niteliksel hem de niceliksel olarak sınıflandırmasını yapabilen bir sistem oluşturulmuştur. Tablo 5.12'de hangi ikili gaz karışımlarının kullanıldığı ve niteliksel sınıflandırma için karışım indeksleri verilmiştir.

Tablo 5.12. Gaz karışımları ve niteliksel sınıflama için karışım indeksleri

Gaz Karışımları	Karışım İndeksleri
Benzen-Trikloretilen	1
Trikloretilen-Aseton	2
Trikloretilen-Hekzan	3
Trikloretilen-Metanol	4
Hekzan- Metanol	5
Benzen- Hekzan	6
Metanol-Benzen	7

Gaz karışımlarının hem nitel hem de nicel sınıflandırılmasında sensörlerin sürekli hal cevapları esas alınmıştır. Her bir gaz karışımı için iki ölçüm yapılmıştır. Bu ölçümlerden biri yapay sinir ağının eğitimi diğeri ise test aşamasında kullanılmıştır.

Karışımların nitel sınıflandırmasını yapan olasılıksal yapay sinir ağı (PNN) modeli, 1960 adet eğitim verisiyle eğitilmiş ve 3920 adet test verisiyle test edilmiştir. Ağın çıktısı, karışım indeksini göstermektedir. Ağın eğitimi birkaç dakika içerisinde tamamlanmıştır. Ağ, tüm eğitim setini doğru olarak sınıflandırmış, test setinde ise sadece 5 yanlış sınıflandırma yapmıştır. Bu sonuç, ağın genelleme kabiliyetinin yüksek olduğunu göstermektedir.


Gaz karışımlarının miktarsal sınıflandırması, her bir gaz karışımı için ayrı ayrı yapılmıştır. Çok katmanlı ve ileri beslemeli ağ yapıları kullanılmıştır. Karışımdaki gazlardan her biri 0, 1000, 2000,..., 5000 ppm oranlarında karıştırılarak, 35 farklı konsantrasyon değeri oluşturulmuştur. Her bir konsantrasyon değeri için, 8'i eğitim setinde 16'sı ise test setinde kullanılmak üzere örneklemeler alınmıştır. Dolayısıyla her bir ikili gaz karışımının eğitim seti 280, test seti ise 560 örneklenmiş veriden oluşmaktadır. Performans ölçütü olarak kullanılan ortalama bağıl mutlak hata (E(RAE)) değeri yaklaşık %1 civarında olacak şekilde ağların topolojik yapısı belirlenmiş ve eğitimi tamamlanmıştır.

Niceliksel (miktarsal) sınıflandırmada kullanılan yapay sinir ağlarının topolojileri, eğitim süreleri ve karışımı oluşturan her bir gazın test performansı Tablo 5.13'te verilmiştir.


Tablo 5.13. Niceliksel sınıflandırmada kullanılan ağ yapıları ve gazların test performansları

Karışım İndeksi	Ağ yapısı (Girdi-Gizli-Çıktı Katmanı)	Ağın Eğitim Süresi (sn)	Performans(E(RAE)) %		
			1.Gaz	2.Gaz	Ort.
1	5-20-20-2	405	1,07	0,34	0,71
2	5-50-2	1050	0,11	1,19	0,65
3	5-25-25-25-2	2254	0,11	1,67	0,89
4	4-25-35-2	2250	0,07	2,05	1,06
5	4-15-15-15-2	107	0,49	1,38	0,94
6	5-50-2	233	1,1	0,76	0,93
7	5-50-2	119	0,64	0,35	0,5

7 farklı ikili gaz karışımının niteliksel ve miktarsal sınıflandırılması bir çatı altında toplanarak, bir grafik arayüz ile kullanıcıya sunulmuştur (Yapılan MATLAB yazılımı EK-B’de verilmiştir). Kullanıcı, bu gazların ayırt edilmesinde kullanılan 5 sensöre ait bilgiyi bu arayüz vasıtasıyla girdiğinde, hangi ikili gaz karışımı olduğunu ve bu ikili gaz karışımını oluşturan her bir gazın miktarını yine bu arayüzden görebilmektedir. Şekil 5.37a’da gösterilen arayüzden 5 sensöre ait frekans kaymaları girilir (veya arayüzdeki “TEST DOSYALARI” sekmesinden test edilmek istenen gaz karışımının verilerini içeren dosya seçilebilir) ve “Hesapla” butonuna basılır. Girilen frekans kaymalarının, gerçekte 5000 ppm benzen ve 2000 ppm trikloretilen gaz karışımına ait olduğu düşünülürse, “Hesapla” butonuna basıldığında yapay sinir ağının tahmin ettiği sonuç Şekil 5.37b’den görülebilir.



(a)



(b)

Şekil 5.37. Gaz karışımlarını ayırt eden sistemin arayüzü: (a) Hesapla butonuna basılmadan önce, (b) Hesapla butonuna basıldıktan sonra

BÖLÜM 6. TARTIŞMA VE ÖNERİLER

Bu tez çalışmasında, farklı tipte yapay sinir ağları (YSA) ve uyarlamalı sinirsel bulanık çıkarım sistemleri (Adaptive Neuro Fuzzy Inference Systems-ANFIS) kullanılarak ikili uçucu organik gaz karışımlarının sınıflandırılması ve miktarsal tayini gerçekleştirilmiştir. Kuartz kristal sensörlerden oluşan sensör dizisi kullanılarak elde edilmiş frekans cevapları, YSA yapıları ve uyarlamalı sinirsel bulanık çıkarım sistemleri için, eğitim ve test setleri olarak düzenlenmiştir. Bu amaçla ölçümler sonucu elde edilen frekans cevapları geçici ve sürekli hal cevapları olarak gruplandırılmıştır.

Bu tez çalışmasının birinci aşamasında, gaz sensörlerinin sürekli hal cevapları ile yapılan ikili gaz karışımlarının sınıflandırma ve miktarsal tayini için ANFIS yapısı önerilmiş ve sonuçlar YSA yapıları ile karşılaştırılmıştır. ANFIS'in bu iş için uygulanabilirliği gösterilmiştir.

ANFIS yapısı için gerçekleştirilen çalışmalarla ilgili Şekil 5.1-5.5'teki grafikler değerlendirildiğinde görülebileceği gibi, aynı miktarda sensör verisi kullanılması durumunda üyelik fonksiyonları sayısının artırılması performansta iyileşme meydana getirmektedir. Fakat daha az sayıda sensör verisi kullanılmak istenirse, iyi bir performans elde edebilmek için, üyelik fonksiyonlarının sayısının önceki duruma göre daha fazla sayıda olması gerekmektedir.

Bu tez çalışmasının ikinci aşamasında, sezgisel ve ileri seviyeli algoritmalar karşılaştırma amacı ile ileri beslemeli YSA yapılarının eğitimi için kullanılmıştır. Bu amaç ile öncelikle uygun yapay sinir ağını karakterize etmek için bir dizi eğitim işlemi yapılmış ve ağın topolojik yapısı belirlenmiştir. Ayrıca ağın eğitime başlarken katmanlar arasındaki ağırlıklar rasgele atandığından başlangıç şartlarının ağın performansına etkisi de incelenmiştir. Bu çalışmalar sonucunda, çıkışında

sigmoid aktivasyon fonksiyonunun kullanıldığı 50 gizli katman nöron sayısına sahip ağ yapısı; eğitim süresi, ortalama karesel hata (MSE) ve ortalama bağıl mutlak hata (RAE) bakımından en uygunu bulunmuştur. Ayrıca ağın çok fazla eğitilmesi durumunda performansta düşme yaşandığından test seti hatasının en düşük olduğu noktada eğitimi durdurmak fayda sağlamıştır. Böylece ağın eğitim setini ezberlemesinin önüne geçilmiştir. Çok katmanlı YSA'lar ile yapılan diğer çalışmalarda bu ağ topolojisi baz alınmıştır.

Şekil 5.15-5.19'dan ve Tablo 5.7'den de görülebileceği gibi ikili gaz karışımındaki her bir gazın miktarsal olarak belirlenmesinde; eğitim süresi, MSE ve RAE bakımından en iyi eğitim algoritması, Levenberg-Marquardt algoritması olarak bulunmuştur. Bu algoritmayı performans olarak sırası ile quasi-Newton, conjugate-gradient, esnek yayılım ve standart geri yayılım algoritmaları izlemektedir.

İleri beslemeli YSA yapılarında kullanılan eğitim algoritmaları ile optimum ANFIS yapısının performanslarını karşılaştırmak amacı ile sonuçlar Tablo 6.1'de özetlenmiştir. Optimum eğitilmiş ANFIS yapısı test setinin minimum MSE değerine bağlı olarak seçilmiştir.

Tablo 6.1. İleri beslemeli YSA yapıları ile ANFIS'in performans bakımından karşılaştırılması

ALGORİTMA PERFORMANS		YAPAY SİNİR AĞLARI					ANFIS
		Standart Geri Yayılım	Esnek Yayılım	Conjugate-Gradient	Quasi-Newton	Levenberg-Marquardt	TCE için 3, AST için 4 üyelik fonksiyonlu
Eğitim	MSE (eğitim)	1,20E-03	2,00E-04	3,80E-05	3,00E-06	1,00E-06	2,90E-5
	Ortalama RAE (%)	6,365	2,815	1,05	0,745	0,645	0,809
	Süre (sn.)	19980	3332	6488	22748	1050	8965
Test (Optimum)	MSE (test)	1,19E-03	2,10E-04	5,70E-05	3,70E-05	4,33E-05	3,89E-5
	RAE (%) {Trikloretilen}	1,21	0,98	0,2	0,22	0,11	0,158
	RAE (%) {Aseton}	11,52	4,6	1,9	1,59	1,19	1,46
	Ortalama RAE (%)	6,365	2,79	1,05	0,905	0,65	0,809
	Süre (sn.)	19980	3316	6456	5245	987	5080

Tablo 6.1'den, ANFIS yapısının sonuçlarının, standart geri yayılım, esnek geri yayılım ve conjugate-gradient algoritmalarının sonuçlarından daha iyi olduğu görülmektedir. ANFIS'in eğitim sürecinde MSE değeri 10^{-4} 'ün altına inmesine rağmen yapının eğitim setini ezberlemesi durumu gözlenmemiştir.

ANFIS yapısının eğitim performansının QN ve LM algoritmalarınınkinden daha düşük olmasına rağmen, ANFIS'in test performansının, bu algoritmaların test performanslarına benzer olduğu görülmektedir. Hatta LM ve QN algoritmalarında ezberleme etkisi gözlemlenmesine rağmen ANFIS'te bu etki görülmemektedir.

Bu tez çalışmasının üçüncü aşamasında ise, büyük boyutlu problemleri çözmek için kullanılacak radyal temelli sinir ağlarının boyutunun çok fazla büyümesini engelleyebilecek bir metot önerilmiştir. Çalışmanın bu aşamasında, kararlı hal frekans cevaplarına uygun değişkenin, normal dağılım kuralına uygunluğundan yola çıkarak, bu ölçüm değerleri dağılımının parametrelerinin, ölçüm değerleri yerine eğitim örnekleri olarak kullanılması ve böylelikle eğitim verilerinin sayısını azaltmakla radyal temelli sinir ağının boyutunun küçültülmesi sağlanmıştır.

Yukarıda da özetlendiği gibi LM algoritması, ikili gaz karışımlarının miktarsal sınıflandırılması için ileri beslemeli YSA'ların eğitiminde en hızlı algoritma olduğundan, radial temelli ağlarla karşılaştırma maksadıyla bu algoritma ve bunun yanı sıra, literatürde en çok tercih edilen standart geri yayılım algoritması da kullanılmıştır.

Tüm eğitim setinin kullanıldığı radial temelli ağın performansı diğer tüm algoritmalara göre daha iyidir. Fakat ağın topolojik yapısı oldukça büyüktür. Bunun yanı sıra radial temelli ağın bu eksikliğini gidermek için önerilen azaltılmış eğitim setine sahip radial temelli ağın, eğitim süresi ve ağ topolojisi oldukça makul değerlere sahip hale getirilmiştir. Performans bakımından da LM algoritmasına yakın ve momentumlu standart geri yayılım algoritmasına göre çok daha iyi sonuç vermiştir. Eğitim süresi bakımından da ileri beslemeli YSA için en hızlı algoritma olan LM algoritmasından oldukça hızlıdır. Ama, radial temelli ağın boyutu

küçültülmesine rağmen hala ileri beslemeli YSA'nın boyutundan biraz büyük kalmaktadır.

Tez çalışmasının dördüncü aşamasında, gaz sensörlerinin geçici hal cevaplarından oluşan zaman dizisi ile yapılan sınıflandırma ve miktarsal tayinde, iki tip YSA yapısı önerilmiş ve sonuçlar karşılaştırılmıştır. Bunların ilki olan zaman gecikmeli YSA yapısında, geçici hal cevaplarından oluşan zaman dizileri kullanılmıştır. Kullanılan diğer ileri beslemeli YSA yapısı ise, geçici hal cevabının yanı sıra, bunların eğitim bilgisini de hesaba katmıştır. Bu aşamada çalışılan bütün ileri beslemeli YSA yapılarının eğitiminde en hızlı algortima olan LM algoritması tercih edilmiştir. Eğitimler YSA yapılarının ezberlemeye başladığı noktalara kadar götürülmüştür.

Daha önce yapılan çalışmalarda sensörlerin sürekli hal karakteristiklerinden yararlanılıyordu. Sensörlerin sürekli hal bölgesine gelmeleri birkaç dakika aldığından, ağı tahmin süresi de dakikalar mertebesindeydi. Bu çalışmada ise, sensörlerin geçici hal bölgeleri de dikkate alındığından, ağı tahmin süresi saniyeler mertebesindeydi. Bu eğitim işlemi YSA yapısına, bir problem için genelleme kabiliyeti kazandırır ve bu genelleme yeteneğini kazanan yapay sinir ağı, artık bu problem için uygun tahminler yapabilir.

Zaman gecikmeli yapay sinir ağlarında eğitim süresi biraz uzun olmasına rağmen tahmin süresi kısadır. Bu aşamada kullanılan her iki YSA yapısında da sensörler sürekli hal bölgesine girmeden, gaz karışımına ait konsantrasyon tahmini yapılabilmektedir.

Şekil 5.36'dan da görülebileceği gibi, kullanılan QCM sensörlerin sürekli hal bölgelerine erişme süreleri yaklaşık 250-300 sn. kadardır. Sürekli hal cevabını kullanan YSA yapısı ancak bu süreden sonra tahmin yapabilme yeteneğine sahiptir. Zaman gecikmeli YSA ve eğitim bilgisini hesaba katan YSA yapıları ise sensörlerin sürekli rejime ulaşmalarından çok önce gazların miktarsal tahminini yapabilmektedir. Zaman gecikmeli YSA ve eğitim bilgisini hesaba katan YSA yapılarının eğitim süreleri, sürekli hal cevabını kullanan YSA yapısına göre çok daha fazladır, fakat

tahmin süreleri çok daha kısadır. Miktersal sınıflandırma yapılan bir sistem düşünöldüğünde tahmin süresi eğitim süresinden çok daha önemli bir parametredir.

Tablo 5.11'den, zaman gecikmeli YSA ve eğitim bilgisini hesaba katan YSA yapılarının performansları incelendiğinde eğitim bilgisini hesaba katan YSA yapısının performansının bir parça daha iyi olduđu görölür. Zaman gecikmeli YSA 40 giriş verisi (her bir sensörün kendi cevabı ve yedi geçmiş cevabı), eğitim bilgisini hesaba katan YSA yapısı ise 10 giriş verisi (her bir sensörün kendi cevabı ve eğitim bilgisi) kullanmasına rağmen, eğitim bilgisini hesaba katan YSA yapısı beklenenin aksine daha iyi sonuç vermiştir. Bunun sebebi, eğitim bilgisini hesaba katan YSA yapısı için eğitim değeri hesaplanırken eksi işarete sahip eğitim değeriinin filtrelenmiş olmasıdır. Çünkü eksi eğitim bilgisi, sensör cevap karakteristiğine aykırıdır.

Performans olarak eğitim bilgisini hesaba katan YSA yapısı, zaman gecikmeli YSA'ya göre daha iyi olmasının yanında, ağın topolojik yapısının da çok daha küçük olduđu görölmektedir. Eğitim bilgisinin kullanıldığı yapay sinir ağı modelinin, zaman gecikmeli yapay sinir ağı modeline bir alternatif olduđu söylenebilir.

Yapılan literatür taramalarında, çok sayıda gaz karışımlarının hem niteliksel, hem de miktersal sınıflandırılmasını içeren çalışmalara pek rastlanmamıştır. Bu nedenle, çalışmanın beşinci aşamasında, sürekli hal cevapları kullanılarak, yedi farklı ikili gaz karışımının niteliksel sınıflandırılması olasılıksal sinir ağıları (Probabilistic Neural Network-PNN), niceliksel sınıflandırılması ise yalnızca ileri beslemeli ağılar yardımıyla gerçekleştirilen bir paket oluşturulmuştur.

Çalışmanın bu aşamasında, 7 farklı ikili gaz karışımının (Bkz. Tablo 5.12) niteliksel ve miktersal sınıflandırılması bir çatı altında toplanarak, bir grafik arayüz ile kullanıcıya sunulmuştur. Kullanıcı, bu gazların ayırt edilmesinde kullanılan 5 sensöre ait bilgiyi bu arayüz vasıtasıyla girdiğinde, hangi ikili gaz karışımı olduğunu ve bu ikili gaz karışımını oluşturan her bir gazın miktarını yine bu arayüzden görebilmektedir.

Karışımları niteliksel olarak sınıflandıran olasılıksal yapay sinir ağı (PNN) modeli, 1960 adet eğitim verisiyle eğitilmiş ve 3920 adet test verisiyle test edilmiştir. Ağın eğitimi birkaç dakika içerisinde tamamlanmıştır ve çıktısı karışımın indeksini (Bkz. Tablo 5.12) göstermektedir. Bu süreçte, tüm eğitim seti doğru olarak sınıflandırılmış, test setinde ise sadece 5 yanlış sınıflandırma yapılmıştır ki, bu sonuç da ağın genelleme kabiliyetinin yüksek olduğunu göstermektedir. Bu karışımları miktarsal olarak sınıflandıran ileri beslemeli ağların performansları (Bkz. Tablo 5.13) ise %1'in altında olmakla, yeterli düzeydedir.

Sonuç olarak ikili uçucu organik gaz karışımlarının miktarsal tayininde;

Standart geri yayılım algoritması diğer eğitim algoritmaları ile kıyaslandığında en yavaş ve tahmin sonuçları bakımından da daha az tatmin edici olanıdır. Fakat ortalama karesel hatanın birinci dereceden türevlerini kullandığından dolayı YSA'lara en kolay uygulanabilenidir.

Esnek yayılım algoritması, standart geri yayılım algoritmasından daha yavaş fakat tahmin sonuçları bakımından daha iyidir. Ağdaki ağırlıkların değişimi, hatanın gradyeninin işareti göz önünde tutularak yapıldığından YSA'lara kolaylıkla uygulanabilir fakat diğer ileri seviyeli algoritmalarla kıyaslandığında daha düşük performans sergilemektedir.

Conjugate-gradient algoritması, standart ve esnek yayılımdan daha hızlı ve tahmin sonuçları bakımından da daha iyi olanıdır. Conjugate-gradient algoritmalarında, genellikle daha hızlı yakınsayan eşleştirme doğrultularında bazı arama işlemleri yapıldığından YSA'lara uygulanabilirliği daha zor olmaktadır.

Quasi-Newton algoritmasının yakınsama performansı, standart geri yayılım, esnek geri yayılım ve conjugate-gradient algoritmalarınınkinden daha iyidir. Bu algoritma ikinci dereceden türevleri (Hessian matrisi) ve ters matris işlemlerini kullandığından YSA'lara uygulanabilirliği diğer algoritmalarla göre daha güçlüdür.

Levenberg–Marquardt algoritması, test edilen algoritmalar arasında en hızlı yakınsamayı ve en iyi tahmin sonuçlarını veren algoritmadır. Quasi-Newton algoritması hariç, diğer algoritmalar ile kıyaslandığında YSA'lara uygulanabilirliği daha zordur. Bunun sebebi, quasi-Newton algoritmasında olduğu gibi bu algoritmanın da Hessian matrisinin tersini kullanıyor olmasıdır.

ANFIS yapısının tahmin sonuçları; standart geri yayılım, esnek geri yayılım ve conjugate-gradient algoritmalarından çok daha iyi, quasi-Newton algoritmasından biraz daha iyi, Levenberg–Marquardt algoritmasından ise biraz daha kötüdür.

ANFIS ikinci mertebelen türev matrislerinin tersini kullanmaz. Bu nedenle ANFIS yapısının hesaplama karmaşıklığı quasi-Newton ve Levenberg–Marquardt algoritmalarından daha düşüktür. Dolayısıyla ikili gaz karışımlarının miktarsal sınıflandırılmasında bu algoritmaları kullanan YSA'lara göre uygulanabilirliği çok daha kolaydır. Tezde ANFIS yapısının genelleme yeteneğinin, ikili uçucu organik bileşiklerin miktarsal tayini işinde YSA yapılarından daha iyi olduğu gösterilmiştir.

Radyal temelli ağların işlem karmaşıklığı çok katmanlı ağların eğitilmesinde kullanılan LM algoritmasına göre çok daha düşüktür ve gaz karışımlarının miktarsal tahmininde daha uygulanabilir bir yapıya sahiptir. Bu ağların çok katmanlı YSA'lara göre daha fazla sayıda nörona gereksinimi vardır. Bunun sebebi, eğitimde kullanılacak örnek sayısının artmasıyla birlikte ağın boyutunun da büyümesidir. Bu büyümeyi engellemek amacıyla, her bir karışım için ölçümler sonucu elde edilen frekans kaymalarının ortalama ve standart sapma değerlerinden oluşturulan azaltılmış eğitim seti kullanılmıştır ki, bu da ağın topolojik yapısında büyük oranda küçülme sağlamıştır. Sonuçta en hızlı yakınsama performansı, azaltılmış eğitim setini kullanan radyal temelli ağlar ile sağlandığı görülmüştür.

Bu çalışmada QCM sensörlerin sürekli hal bölgelerine erişme süreleri (cevap süreleri) yaklaşık 250-300 sn. olmasına rağmen, sürekli hal cevaplarını kullanan yapıların aksine zaman gecikmeli YSA ve eğitim bilgisini hesaba katan YSA yapıları, sensörlerin sürekli rejime ulaşmalarından çok daha önce gazların miktarsal tahminini yapabilmektedir.

İleriye yönelik çalışmalar olarak aşağıdaki konular önerilebilir:

Prensip olarak bu çalışma, diğer ikili gaz karışımlarının ve çok sayıda gazın karışımlarının da incelenmesi için genişletilebilir.

Çalışmanın sonuç ve yöntemlerinden aroma sınıflandırılmasına dayalı olarak gıdaların kalitesinin tespiti açısından gıda sanayiinde yararlanılabilir.

Koku ile saptanılacak hastalıkların incelenmesi ve teşhisinde de bu çalışmanın metotlarından faydalanılabilir.

İleriki aşamalarda, daha düşük konsantrasyondaki uçucu organik bileşiklerin miktarsal olarak sınıflandırılmasına çalışılmasında insan ve çevre sağlığı açısından fayda sağlayacağı düşünülmektedir.

Erken uyarı amaçlı taşınabilir cihazların tasarımı aşamasında, tezde kullanılmış olan yapay zeka tekniklerinden faydalanılabilir. Bu teknikler kapsamında kullanılan ağ yapılarının boyutlarının küçültülmesi, bu sistemlerin donanım olarak gerçekleşmesini daha ekonomik ve daha basit hale getireceği düşünüldüğünden bu tür yapıların uygunluğu, cihaz tasarımı aşamasında ayrıca incelenmelidir.

KAYNAKLAR

- [1]. ÇALIŞKAN, E., Using Fuzzy Inference System and Artificial Neural Network Based Algorithms for Gas Concentration Estimation, Yüksek Lisans Tezi, Sakarya Üniversitesi, Mayıs 2004.
- [2]. Agency for Toxic Substances and Disease Registry (ATSDR), Toxicological Profile for benzene, U.S. Department of Health and Human Services, Public Health Service, Atlanta, GA, 1997.
- [3]. Agency for Toxic Substances and Disease Registry (ATSDR), Toxicological Profile for n-hexane, U.S. Department of Health and Human Services, Public Health Service, Atlanta, GA, 1999.
- [4]. Agency for Toxic Substances and Disease Registry (ATSDR), Toxicological Profile for Acetone, U.S. Department of Health and Human Services, Public Health Service, Atlanta, GA, 1994.
- [5]. Agency for Toxic Substances and Disease Registry (ATSDR), Managing Hazardous Materials Incidents, Medical Management Guidelines for Acute Chemical Exposures: Trichloroethylene (TCE), Vol. III, U.S. Department of Health and Human Services, Public Health Service, Atlanta, GA, 2003.
- [6]. http://www.tapdk.gov.tr/alkol/dokuman/mspd_guvenlik_bilgi_formu.doc
- [7]. Türk Farmakoloji Derneği Bülteni, Sayı:84 Nisan-Haziran 2005.
- [8]. ESEN, N., Uçucu Organik Bileşiklerin QCM Sensör Dizisi ile Algılanarak Diskriminant Analiziyle Tanımlanması ve Sınıflandırılması, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara, 2004.
- [9]. SADAOKA, Y., MATSUGUCHI, M., SAKAI, Y., MORI, Y., Effect of Crystal Form on the conductance in oxidative gases of Metal free and some Metal Phthalocyanines, Sensors and Actuators B 4 (1991) 495-498.
- [10]. SHILBUB, S.I., GOULD, R.D., Frequency dependence of electronic conduction parameters in evaporated thin films of cobalt phthalocyanine, Thin Solid Films 254 (1995) 187-193.
- [11]. TEMURTAŞ, F., Kimyasal sensör dizilerinde yapay sinir ağları ve bulanık mantık uygulamaları: Gazların sınıflandırılması ve gaz konsantrasyonlarının belirlenmesi, Doktora tezi, Sakarya Üniversitesi, 2000.

- [12]. SRIYUDTHSAK, M. LERTNIMITTHUM, N. NAKPEERAYUTH, S., Novel technique using response characteristics to identify volatile organic compounds, *Solid State Sensors and Actuators* 2 (1997) 967-970.
- [13]. TAURINO, A.M., DISTANTE, C., SICILIANO, P., VASANELLI, L., Quantitative and qualitative analysis of VOCs mixtures by means of a microsenors array and different evaluation methods, *Sensors and Actuators B: Chemical* 93 (2003) 117–125.
- [14]. LLOBET, E., BREZMES, J., VILANOVA, X., SUEIRAS, J.E., CORREIG, X., Qualitative and quantitative analysis of volatile organic compounds using transient and steady-state responses of a thick-film tin oxide gas sensor array, *Sensors and Actuators B* 41 (1997) 13-21.
- [15]. PENZA, M., CASSANO, G., Application of principal component analysis and artificial neural networks to recognize the individual VOCs of methanol/2-propanol in a binary mixture by SAW multi-sensor array, *Sensors and Actuators B* 89 (2003) 269-284.
- [16]. GETINO, J., HORRILLO, M.C., GUTIERREZ, J., ARES, L., ROBLA, J.I., GARCIA, C., SAYAGO, I., Analysis of VOCs with a tin oxide sensor array, *Sensors and Actuators B* 43 (1997) 200–205.
- [17]. ÖZMEN, A., TEKCE, F., EBEOĞLU, M.A., TAŞALTIN, C., ÖZTÜRK, Z.Z., Finding the composition of gas mixtures by a phthalocyanine-coated QCM sensor array and an artificial neural network, *Sensors and Actuators B* 115 (2006) 450–454.
- [18]. TEMURTAS, F., TASALTIN, C., TEMURTAS, H., YUMUSAK, N., OZTURK, Z.Z., Fuzzy logic and neural network applications on the gas sensor data: concentration estimation, *Lect. Notes Comput. Sci.* 2869 (2003) 179–186.
- [19]. YANG, B., CAROTTA, M.C., FAGLIA, G., FERRONI, M., GUIDI, V., MARTINELLI, G., SBERVEGLIERI, G., Quantification of H₂O and NO₂ using gas sensor arrays and an artificial neural network, *Sens. Actuators B* 43 (1997) 235–238.
- [20]. SZCZUREK, A., SZECOWKA, P.M., LICZNERSKI, B.W., Application of sensor array and neural networks for quantification of organic solvent vapours in air, *Sens. Actuators B* 58 (1999) 427–432.
- [21]. PARDO, M., FAGLIA, G., SBERVEGLIERI, G., CORTE, M., MASULLI, F., RIANI, M., A time delay neural network for estimation of gas concentrations in a mixture, *Sens. Actuators B* 65 (2000) 267–269.
- [22]. SUNDIC, T., MARCO, S., PERERA, A., PARDO, A., HAHN, S., BARSAN, N., WEIMAR, U., Fuzzy inference system for sensor array calibration: prediction of CO and CH₄ levels in variable humidity conditions, *Chemom. Intell. Lab. Syst.* 64 (2003) 103–122.

- [23]. YEA, B., OSAKI, T., SUGAHARA, K., KONISHI, R., The concentration estimation of inflammable gases with a semiconductor gas sensor utilizing neural networks and fuzzy inference, *Sens. Actuators B* 41 (1997) 121–129.
- [24]. YEA, B., OSAKI, T., SUGAHARA, K., KONISHI, R., Improvement of concentration estimation algorithm for inflammable gases utilizing fuzzy rule based neural networks, *Sens. Actuators B* 56 (1999) 181–188.
- [25]. VAHINGER, S., GOPEL, W., in: GOPEL, W., HENSE, S., ZEMEL, S.N. (Eds.), *Multi-Component Analysis in Chemical Sensing in Sensors: A Comprehensive Survey*, vol.2, no.1, p.192, VCH, Weinheim, New York, 1991.
- [26]. GULBAG, A., TEMURTAS, F., A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro fuzzy inference systems, *Sens. Actuators B*, 115 (2006) 252–262.
- [27]. TEMURTAS, F., GULBAG, A., YUMUSAK, N., A Study on Neural Networks using Taylor Series Expansion of Sigmoid Activation Function, *The International Conference on Computational Science and its Applications*, LNCS, 3046 (2004) 389–397.
- [28]. GULBAG, A., TEMURTAS, F., An Intelligent Gas Concentration Estimation System using Neural Network Implemented Microcontroller, *LECT NOTES ARTIF INT*, 3339 (2004) 1206–1212.
- [29]. TEMURTAS, F., Fast detection of the hazardous organic gases in the ambient air using adaptive neuro-fuzzy inference systems, *Int. J. Environ. Poll.*, in pres.
- [30]. TAKAGI, T., SUGENO, M., Fuzzy identification of systems and its applications to modeling and control, *IEEE Trans. Syst. Man Cybernetics* 15 (1985) 116–132.
- [31]. JANG, J.-S.R., SUN, C.-T., MIZUTANI, E., *Neuro Fuzzy and Soft Computing*, Prentice Hall, Upper Sillade River, NJ 07458, 1997, pp. 335–345.
- [32]. RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., Learning internal representations by error propagation, in: Rumelhart, D.E., McClelland, J.L. (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol.1, pp. 318–362, MIT Press, Cambridge, MA, 1986.
- [33]. GORI, M., TESI, A., On the problem of local minima in back propagation, *IEEE Trans. Pattern Anal. Machine Intell.* 14 (1992) 76–85.
- [34]. RICHARD, P.B., Fast training algorithms for multi-layer neural nets, *IEEE Trans. Neural Netw.* 2 (1991) 346–354.
- [35]. HAGAN, M.T., DEMUTH, H.B., BEALE, M.H., *Neural Network Design*, PWS Publishing, Boston, MA, 1996.


- [36]. RIEDMILLER, M., Advanced supervised learning in multilayer perceptrons-from back propagation to adaptive learning algorithms, *Int. J. Comput. Standards Interfaces, Special Issue on Neural Networks* 5 (1994) 8.
- [37]. RIEDMILLER, M., BRAUN, H., A direct adaptive method for faster back propagation learning: The RPROP algorithm, in: *Proceedings of the IEEE International Conference on Neural Networks*, p.586, San Francisco, CA, March 28, 1993.
- [38]. SAGIROGLU, S., BESDOK, E., ERLER, M., Control chart pattern recognition using artificial neural networks, *Turk. J. Elect. Eng.* 8 (2000) 137–146.
- [39]. FLETCHER, R., REEVES, C.M., Function minimization by conjugate gradients, *Comput. J.* 7 (1964) 149–154.
- [40]. DENNIS, J.E., SCHNABEL, R.B., *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, Prentice-Hall, Englewood Cliffs, NJ, 1983.
- [41]. HAGAN, M.T., MENHAJ, M., Training feed forward networks with the Marquardt algorithm, *IEEE Trans. Neural Netw.* 5 (1994) 989–993.
- [42]. TEKTAŞ, M., AKBAŞ, A., TOPUZ, V., Yapay zeka tekniklerinin trafik kontrolünde kullanılması üzerine bir inceleme, *Uluslararası Trafik ve Yol Güvenliği Kongresi ve Fuarı*, Ankara, 2002.
- [43]. ÖZTEMEL, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, 2003.
- [44]. SAĞIROĞLU, Ş., BEŞDOK, E., ERLER, M., *Mühendislikte Yapay Zeka Uygulamaları-I*, *Ufuk Kitap Kırtasiye-Yayıncılık Tic.Ltd.*, 2003.
- [45]. ŞEN, Z., *Yapay Sinir Ağları İlkeleri*, *Su Vakfı Yayınları*, 2004.
- [46]. AVCI, M., YILDIRIM, T., Classification of Escherichia Coli Bacteria by Artificial Neural Networks, *IEEE International Symposium on Intelligent Systems Vol III*, Sf. 16-20, Varna, Bulgaristan, 2002.
- [47]. KOÇ, M.L., Taş dolgu Dalgakıranların Yapay Sinir ağları, *Bulanık Mantık Sistemleri ve Genetik Algoritma ile Ön Tasarımı ve Güvenirlik Analizi*, *Doktora Tezi*, Gazi Üniversitesi, 2002.
- [48]. LIN, C.T., LEE, C.S.G., *IEEE Transactions on Fuzzy System, Reinforcement structure/parameter learning for neural-network-based fuzzy logic control systems* 2 (1) 46-63, 1994.
- [49]. BAYKAL, N., BEYAN, T., *Bulanık Mantık İlke ve Temelleri*, *Bıçaklar Kitabevi*, 2004.

- [50]. TSOUKALAS, L.H., UHRIG, R.E., Fuzzy And Neural Approaches in Engineering, Jhon Wiley & Sons Inc, New York, 1996.
- [51]. ÖZÇALIK, H.R., UYGUR, A.F., Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi, KSÜ Fen ve Mühendislik Dergisi 6 (1) 2003.
- [52]. ALTINDAL, A., Organik Yarıiletken Filmlerin Karakterizasyonu ve Gaz Sensörü olarak uygulanması, Doktora tezi, Marmara Üniversitesi, 1999.
- [53]. GÖPEL, W. ,Sensors And Actuators B, New materials and transducers for chemical sensors, Vol:18, Issue :3, Pages:1-21, 1994.
- [54]. TAŞALTIN, C., GÜREK, a., EBEOĞLU, M.A., ÖZTÜRK, Z.Z., AHSEN, V., Uçucu Organik Bileşiklerin QCM ile Algılanması, TFD-21 Fizik Kongresi, S.D.Ü., Isparta, 11-14 Eylül 2002.
- [55]. TAŞALTIN, C., TEMURTAŞ, F., GÜROL, İ., EBEOĞLU, M.A., ÖZTÜRK, Z.Z., AHSEN, V., Quartz Kristal Rezonatör Gaz Sensörlerinde Algılayıcı Film Kaplama Parametrelerinin Gaz Algılama Özelliklerine Etkisi, TFD-18 Fizik Kongresi, Ç.Ü., Adana, 25-28 Ekim 1999.
- [56]. TAŞALTIN, C., Quartz Kristal Mikrobals (QCM) ve Interdigital Transducer(IDT)'lerde Arayüzey Film Preparasyon Parametrelerinin Gaz Algılama Özelliklerine Etkisinin İncelenmesi, Yüksek Lisans Tezi, Marmara Üniversitesi, 2000.
- [57]. GÖPEL, W., HESSE, J. J., ZEMEL, N., Sensors Vol:2 Chapter:13 WCH Germany, 1989.
- [58]. FRANKLIN, B., Philosophical Tranactions of the Royal Society 64 (1774) 445.
- [59]. ZHOU, X.C., NG, S.C., CHAN, H.S.O., LI, S.F.Y., Detection of organic amines in liquid with chemically coated quartz crystal microbalance devices, Sensors and Actuators B 42 (1997) 137-144.
- [60]. HAUNG, M., SCHIERBOUM, K., GUGLITZ, G., GÖPEL, W., Chemical sensors based upon polysiloxanes: comparison between optical, quartz microbalance, calorimetric, and capacitance sensors, Sensors and Actuators B, 11 (1993) 383-391.
- [61]. SULEIMAN, A., GUILBAULT, G.G, Analytica Chimica Acta, A coated piezoelectric crystal detector for phosgene, 162 (1984) 97-102.
- [62]. EBEOĞLU, M.A., ÖZTÜRK, Z.Z., TAŞALTIN, C., TEMURTAŞ, F., Teknik Rapor, Gaz Sensör Prototipi Geliştirme Projesi, TÜBİTAK MAM, 1999.
- [63]. GULBAG, A., TEMURTAS, F., A study on transient and steady state sensor data for identification of individual gas concentrations in their gas mixtures, Sens. Actuators B, Basım aşamasında.

EKLER

EK-A. Ölçüm Sistemi İçin Yazılan Program

Bu kısımda ölçüm sistemini kontrol eden yazılım ile ilgili ayrıntılar verilmiştir. Bu yazılım iki form ve bir modülden oluşmaktadır. İlk olarak kaç ikili gaz ölçümü yapılacağı Şekil A.1’de gösterilen form ile kullanıcıdan alınmaktadır.



Şekil A.1. Ölçüm sayısının girildiği form

Daha sonra, sensör frekans kaymalarının hangi dosyaya kaydedileceği, gaz ve yıkama sürelerinin ne olacağı, gaz karışımının kaç konsantrasyon değeri için yapılacağı ve akış kontrolörlerinin debilerinin ne olması gerektiği Şekil A.2’de gösterilen form ile kullanıcıdan alınmaktadır.

Gaz Test

GAZ TEST PROGRAMI

1. Dosya İsmi .TXT

Gaz ve Yıkama Süresi (dk.)

Menü Sayısı

1. MENÜ

1. Flowmetre

2. Flowmetre

3. Flowmetre

4. Flowmetre

Şekil A.2. Ölçüm ile ilgili parametrelerin girildiği form

Şekil A.2'deki bilgilerin girilmesinin ardından Şekil A.3'teki form ekrana gelmektedir. Bu form sayesinde sensörlerin frekans kaymaları, hangi ölçümün yapıldığı ve ölçüm zamanı gibi bilgiler izlenebilmekte, aynı zamanda dosyaya kaydedilmektedir.

Gaz Test

GAZ TEST PROGRAMI

SENSÖR CEVAPLARI

1. Sensör

2. Sensör

3. Sensör

4. Sensör

5. Sensör

6. Sensör

7. Sensör

8. Sensör

9. Sensör

Dosya İsmi:

Menü:

Saniye:

Flowmetreler

1. Flowmetre:

2. Flowmetre:

3. Flowmetre:

4. Flowmetre:

Şekil A.3. Sensör frekans kaymalarının izlendiği form

Şekil A.2'deki formun (Form1) Visula Basic kodları aşağıda verimiştir;

Public t, menus, sayici

```
Private Sub Command1_Click()
    menusay(sayici) = Val(Text3.Text)
    gaz(sayici) = Val(Text2.Text)
    dos$(sayici) = Text1.Text
    menus = menus + 1
    If (menus <> (menusay(sayici) + 1)) Then

        Label12.Caption = menus + 1
        qdeb(menus, 1, sayici) = Text4.Text
        qdeb(menus, 2, sayici) = Text5.Text
        qdeb(menus, 3, sayici) = Text6.Text
        qdeb(menus, 4, sayici) = Text7.Text

        Text4.Text = ""
        Text5.Text = ""
        Text6.Text = ""
        Text7.Text = ""
        Text4.SetFocus
    End If
    If (menus = menusay(sayici)) Then

        sayici = sayici + 1
        Text4.Text = ""
        Text5.Text = ""
        Text6.Text = ""
        Text7.Text = ""
        Text1.Text = ""
        Text2.Text = ""
        Text3.Text = ""
        Text1.SetFocus
        menus = 0
        Label12.Caption = menus + 1

        If (sayici = Val(sayi) + 1) Then
            Form2.Show
            Form1.Hide
        End If
        Label8.Caption = sayici
    End If
End Sub

Private Sub Command2_Click()
    End
End Sub
```

```

Private Sub Form_KeyPress(KeyAscii As Integer)
    If KeyAscii = 13 Then
        SendKeys "{tab}"
    ElseIf KeyAscii = 27 Then
        SendKeys "+{tab}"
    End If
End Sub

```

```

Private Sub Form_Load()
    sayi = InputBox("Ölçüm Sayısı")
    sayi = Val(sayi)
    menus = 0
    sayici = 1
    Label8.Caption = sayici
    Label12.Caption = menus + 1
End Sub

```

Akış kontrolörüyle (MKS Sistemi) ilgili ayarlamalar ve sensör cevaplarının bir txt dosyaya kaydedilmesi işlemleri Şekil A.3'teki form (Form2) vasıtasıyla olmaktadır. Form 2'ye ait Visual Basic kodları aşağıda verilmiştir;

```

Public sayac, mns, tim, tim2

```

```

Private Sub Command1_Click()
    MSComm2.Output = "OF 1" & Chr$(13)
    MSComm2.Output = "OF 2" & Chr$(13)
    MSComm2.Output = "OF 3" & Chr$(13)
    MSComm2.Output = "OF 4" & Chr$(13)
    MSComm2.Output = "KE" & Chr$(13)
    MSComm2.PortOpen = False
    Close #sayac
End
End Sub

```

```

Private Sub Form_Load()
    MSComm2.PortOpen = True
    MSComm1.PortOpen = True

    For ll = 1 To 16
        qb(ll) = 0
    Next

    tim = 0
    tim2 = 0
    mns = 1
    sayac = 1
    MSComm2.Output = "KD" & Chr$(13)

```

```

MSComm2.Output = "RA 1 9" & Chr$(13)
MSComm2.Output = "RA 2 3" & Chr$(13)
MSComm2.Output = "RA 3 6" & Chr$(13)
MSComm2.Output = "RA 4 6" & Chr$(13)
MSComm2.Output = "OF 1" & Chr$(13)
MSComm2.Output = "OF 2" & Chr$(13)
MSComm2.Output = "OF 3" & Chr$(13)
MSComm2.Output = "OF 4" & Chr$(13)

```

```

Open "" & dos$(sayac) & ".txt" For Output As #2
Text10.Text = "" & dos$(sayac) & ".txt"
Text11.Text = Str(mns) & "/" & menusay(sayac)
Text13.Text = Str(qdeb(mns, 1, sayac))
Text14.Text = Str(qdeb(mns, 2, sayac))
Text15.Text = Str(qdeb(mns, 3, sayac))
Text16.Text = Str(qdeb(mns, 4, sayac))

```

End Sub

Private Sub Timer1_Timer()

```

tim = tim + 1
tim2 = tim2 + 1

```

```

If (tim * 6 <= gaz(sayac) * 60 * menusay(sayac)) Then
    Text12.Text = Str(6 * tim)

```

```

If qdeb(mns, 1, sayac) = 0 Then
    MSComm2.Output = "OF 1" & Chr$(13)

```

Else

```

    MSComm2.Output = "ON 1" & Chr$(13)
    MSComm2.Output = "FS 1 " & Str(qdeb(mns, 1, sayac)) & Chr$(13)

```

End If

```

Text13.Text = Str(qdeb(mns, 1, sayac))

```

```

If qdeb(mns, 2, sayac) = 0 Then
    MSComm2.Output = "OF 2" & Chr$(13)

```

Else

```

    MSComm2.Output = "ON 2" & Chr$(13)
    MSComm2.Output = "FS 2 " & Str(qdeb(mns, 2, sayac) * 100) & Chr$(13)

```

End If

```

Text14.Text = Str(qdeb(mns, 2, sayac))

```

```

If qdeb(mns, 3, sayac) = 0 Then
    MSComm2.Output = "OF 3" & Chr$(13)

```

Else

```

    MSComm2.Output = "ON 3" & Chr$(13)
    MSComm2.Output = "FS 3 " & Str(qdeb(mns, 3, sayac) * 10) & Chr$(13)

```

```

End If
Text15.Text = Str(qdeb(mns, 3, sayac))

If qdeb(mns, 4, sayac) = 0 Then
    MSComm2.Output = "OF 4" & Chr$(13)
Else
    MSComm2.Output = "ON 4" & Chr$(13)
    MSComm2.Output = "FS 4 " & Str(qdeb(mns, 4, sayac) * 10) & Chr$(13)
End If

Text16.Text = Str(qdeb(mns, 4, sayac))

For x = 1 To MSComm1.InBufferCount
    If MSComm1.InBufferCount <> 0 Then
        ja = Asc(MSComm1.Input)
        If ja = 128 Then

            Asc (MSComm1.Input)
            Asc (MSComm1.Input)

            Asc (MSComm1.Input)
            Asc (MSComm1.Input)
            Asc (MSComm1.Input)
            Asc (MSComm1.Input)
        Else
            If ja = 144 Or ja = 145 Then
                Asc (MSComm1.Input)
                Asc (MSComm1.Input)
                Asc (MSComm1.Input)
                Asc (MSComm1.Input)
            End If
        End If
    End If

    If (ja > 128) And (ja < 138) Then
        kop1 = Asc(MSComm1.Input)
        kop2 = Asc(MSComm1.Input)
        kop3 = Asc(MSComm1.Input)
        kop4 = Asc(MSComm1.Input)
        If kop4 >= 8 Then
            qb(ja - 128) = kop1 * 2 + kop2 * 32 + kop3 * 512 + kop4 *
            256 * 32 - 131071
        End If
    Else
        qb(ja - 128) = kop1 * 2 + kop2 * 32 + kop3 * 512 + kop4 *
        256 * 32
    End If
End If

```

```

Else
    If ja = 255 Then
        Asc (MSComm1.Input)

        'MsgBox ("255 geldi")
        Text1.Text = Str(qb(1))
        Text2.Text = Str(qb(2))
        Text3.Text = Str(qb(3))
        Text4.Text = Str(qb(4))
        Text5.Text = Str(qb(5))
        Text6.Text = Str(qb(6))
        Text7.Text = Str(qb(7))
        Text8.Text = Str(qb(8))
        Text9.Text = Str(qb(9))

        Print #sayac + 1, 6 * tim, qb(1), qb(2), qb(3), qb(4), qb(5), qb(6),
        qb(7), qb(8), qb(9), qdeb(mns, 1, sayac), qdeb(mns, 2, sayac),
        qdeb(mns, 3, sayac), qdeb(mns, 4, sayac), mns

        End If
    End If
End If
Next

End If

If (tim2 * 6 >= gaz(sayac) * 60) Then
    tim2 = 0
    mns = mns + 1
    Text11.Text = Str(mns) & "/" & menusay(sayac)
    Text13.Text = Str(qdeb(mns, 1, sayac))
    Text14.Text = Str(qdeb(mns, 2, sayac))
    Text15.Text = Str(qdeb(mns, 3, sayac))
    Text16.Text = Str(qdeb(mns, 4, sayac))

End If

If (tim * 6 >= gaz(sayac) * 60 * menusay(sayac)) Then
    Close #2
    sayac = sayac + 1

    If sayac < sayi + 1 Then
        Open " " & dos$(sayac) & ".txt" For Output As #sayac + 1
        MSComm2.Output = "OF 1" & Chr$(13)
        MSComm2.Output = "OF 2" & Chr$(13)
        MSComm2.Output = "OF 3" & Chr$(13)
        MSComm2.Output = "OF 4" & Chr$(13)
        Text10.Text = "" & dos$(sayac) & ".txt"
    
```

```

End If
tim = 0
tim2 = 0
mns = 1
Text11.Text = Str(mns) & "/" & menusay(sayac)
Text12.Text = Str(6 * tim)
Text13.Text = Str(qdeb(mns, 1, sayac))
Text14.Text = Str(qdeb(mns, 2, sayac))
Text15.Text = Str(qdeb(mns, 3, sayac))
Text16.Text = Str(qdeb(mns, 4, sayac))

If sayac = sayi + 1 Then
    MSComm2.Output = "OF 1" & Chr$(13)
    MSComm2.Output = "OF 2" & Chr$(13)
    MSComm2.Output = "OF 3" & Chr$(13)
    MSComm2.Output = "OF 4" & Chr$(13)
    MSComm2.Output = "KE" & Chr$(13)
    MSComm2.PortOpen = False
    MSComm1.PortOpen = False
    Close #sayac
End
End If
End If
End Sub

```

Genel tanımlamaların yapıldığı modül aşağıdaki gibidir;

```

Global menusay(1 To 20) As Byte
Global sayi
Global qdeb(1 To 100, 1 To 4, 1 To 20) As Integer
Global gaz(1 To 20)
Global dos$(1 To 20)
Global qb(1 To 16)

```

EK-B. Yedi Tane İkili Gaz Karışımının Niteliksel ve Niceliksel Sınıflandırmasının Yapıldığı Matlab Programı

Ana Program (gorsel.m)

```
%formun oluşturulduğu kısım
xx=figure;
set(xx,'position',[232 248 467 420]);
set(xx,'name','Gaz Karışımı ve Oranları');

f = uimenu('Label','Dosya Aç');
uimenu(f,'Label','Benzen-TCE','Callback','indeks(2);');
uimenu(f,'Label','TCE-Aseton','Callback','indeks(3);');
uimenu(f,'Label','TCE-Hekzan','Callback','indeks(4);');
uimenu(f,'Label','TCE-Metanol','Callback','indeks(5);');
uimenu(f,'Label','Hekzan-Metanol','Callback','indeks(6);');
uimenu(f,'Label','Benzen-Hekzan','Callback','indeks(7);');
uimenu(f,'Label','Metanol-Benzen','Callback','indeks(8);');
uimenu(f,'Label','Çıkış','Callback','exit','Separator','on','Accelerator','Q');

hp = uipanel('Title','Gaz Karışımı ve PPM Değerleri','FontSize',12,...
'BackgroundColor','white','Position',[.03 0.15 .67 .67],'backgroundcolor','cyan');

h2 = uicontrol('Style','text','String','5 Sensör verisini giriniz:',...
'Position',[15 350 100 30],'backgroundcolor','cyan');

%sensör verilerinin girildiği text kutucuğu
h3 = uicontrol('Style','edit','horizontalalignment','left','String','',...
'Position',[125 350 200 30]);

%karışımı oluşturan gazların gösterildiği text kutuları
h7 = uicontrol('Style','edit','String','', 'Position',[32 290 70 30]);
h17 = uicontrol('Style','text','String','-','Position',[105 300 10 10],...
'backgroundcolor','cyan');
h8 = uicontrol('Style','edit','String','', 'Position',[120 290 70 30]);

%karışım oranlarının gösterildiği text kutuları
h5 = uicontrol('Style','text','String','',...
'Position',[22 250 100 30],'backgroundcolor','cyan');
h6 = uicontrol('Style','text','String','',...
'Position',[102 250 100 30],'backgroundcolor','cyan');

%panel_2
hp1 = uipanel('parent',hp,'Title','Sensörlerin Frekans Kaymaları (Hz.)',
'FontSize',12,'BackgroundColor','white','Position',[0.005 .01 .99 .67],
'backgroundcolor','cyan');
```

```
h11 = uicontrol('Style','text','String','Sensor_1 Sensor_2 Sensor_3 Sensor_4
Sensor_5','Position',[40 155 50 75],'backgroundcolor','cyan');
```

```
%sensörlerin frekans kaymalarının gösterildiği text kutuları
```

```
h12 = uicontrol('Style','edit','String',' ','Position',[90 215 55 15]);
h13 = uicontrol('Style','edit','String',' ','Position',[90 202 55 15]);
h14 = uicontrol('Style','edit','String',' ','Position',[90 189 55 15]);
h15 = uicontrol('Style','edit','String',' ','Position',[90 175 55 15]);
h16 = uicontrol('Style','edit','String',' ','Position',[90 163 55 15]);
```

```
%hesaplama butonu
```

```
h1 = uicontrol('Style','pushbutton','String','Hesapla','Position',[340 350 50 30],...
'callback','programgorsel');
```

Test Dosyalarını Açmaya Yarayan Program (indeks.m)

```
% test edilmek istenen gaz karışımlarının bir txt editörde açılmasını sağlayan
```

```
%program
```

```
function []= indeks(x)
```

```
    if x==2
```

```
        winopen('egtmtestbtce\testbtce.txt');
```

```
    end
```

```
    if x==3
```

```
        winopen('egtmtesttceast\testtceast.txt');
```

```
    end
```

```
    if x==4
```

```
        winopen('egtmtesttceh\testtceh.txt');
```

```
    end
```

```
    if x==5
```

```
        winopen('egtmtesttceatnp\testtceatnp.txt');
```

```
    end
```

```
    if x==6
```

```
        winopen('egtmtesthznmtnp\testhznmtnp.txt');
```

```
    end
```

```
    if x==7
```

```
        winopen('egtmtestbenhek\testbenhek.txt');
```

```
    end
```

```
    if x==8
```

```
        winopen('egtmtestmtnbzn\testmtnbzn.txt');
```

```
    end
```

```
end
```

Hesapla Butonuna Basıldığı Zaman İşleyen Program (programgorsel.m)

%Hesapla butonuna basıldıktan sonra yapılan niteliksel ve niceliksel sınıflama kısmı

```
%niteliksel sınıflamayı yapan ağ yapısı workspace'e yükleniyor
load netpnn7x;
%sensörlerin frekans kaymaları alınıyor
val=get(h3,'string');
    if numel(val)==0
        break;
    end
s=str2num(val);
set(h3,'string','');
s=s';
%niteliksel sınıflama yapılıyor
x=sim(net,[s(1);s(2);s(4);s(5)]);
Yc = vec2ind(x);
    set(h12,'string',s(1));
    set(h13,'string',s(2));
    set(h14,'string',s(3));
    set(h15,'string',s(4));
    set(h16,'string',s(5));

%niteliksel sınıflandırma sonucuna göre ilgili karışımın ağ yapısı workspace'e
%yükleniyor
if Yc==2
    load 'egtmtestbtce\net50ss';
    tdata=tramnmx(s,minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','Benzen');
    set(h8,'string','TCE');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));

elseif Yc==3
    load 'egtmtesttceast\net50ss';
    tdata=tramnmx(s,minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','TCE');
    set(h8,'string','Aseton');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));
```

```

elseif Yc==4
    load 'egtmtesttceh\net50ss';
    tdata=tramnmx([s(1);s(2);s(4);s(5)],minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','TCE');
    set(h8,'string','Hekzan');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));

elseif Yc==5
    load 'egtmtesttcemtnp\net50ss';
    tdata=tramnmx([s(1);s(2);s(4);s(5)],minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','TCE');
    set(h8,'string','Metanol');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));

elseif Yc==6
    load 'egtntesthznmtnp\net50ss';
    tdata=tramnmx([s(1);s(2);s(4);s(5)],minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','Hekzan');
    set(h8,'string','Metanol');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));

elseif Yc==7
    load 'egttestbenhek\net50ss';
    tdata=tramnmx(s,minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','Benzen');
    set(h8,'string','Hekzan');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));

```

```
elseif Yc==8
    load 'egttestmtnbzn\net50ss';
    tdata=tramnmx(s,minp,maxp);
    simdata=sim(net,tdata);
    gdata=abs(postmnmx(simdata,mint,maxt));

    %niceliksel sınıflamanın sonucu ekrana basılıyor
    set(h7,'string','Metanol');
    set(h8,'string','Benzen');
    set(h5,'string',gdata(1));
    set(h6,'string',gdata(2));
end
```

ÖZGEÇMİŞ

1977 yılında Sakarya’da doğdu. Lise eğitimini 1994 yılında Sakarya Atatürk Lisesi’nde tamamladı. 1998 yılında Sakarya Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünden mezun oldu. 2000 yılında Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim dalında yüksek lisansını tamamlayarak, 2002 yılında aynı Enstitüde doktora eğitimine başladı. 1999 yılından bu yana Sakarya Üniversitesi Bilgisayar Mühendisliği Bölümünde Araştırma Görevlisi olarak görev yapmaktadır.