

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GENETİK ALGORİTMALAR İLE YAPAY SİNİR
AĞLARININ EĞİTİMİ VE ELEKTRONİK BURUN
VERİLERİNE UYGULANMASI**

YÜKSEK LİSANS TEZİ

Kadriye CANPOLAT

Enstitü Anabilim Dalı : **BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**
Tez Danışmanı : **Prof. Dr. Nejat YUMUŞAK**

Haziran 2018

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

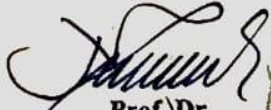
**GENETİK ALGORİTMALAR İLE YAPAY SİNİR
AĞLARININ EĞİTİMİ VE ELEKTRONİK BURUN
VERİLERİNE UYGULANMASI**

YÜKSEK LİSANS TEZİ


Kadriye CANPOLAT

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM
MÜHENDİSLİĞİ**

Bu tez 01 / 06 / 2018 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.


Prof. Dr.
Nejat YUMUŞAK
Jüri Başkanı


Prof. Dr.
Celal ÇEKEN
Üye


Dr. Öğr. Üyesi
Amani YAHYAOUİ
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Kadriye CANPOLAT

01.06.2018

TEŐEKKÜR

Yüksek lisans eğitiminin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Prof. Dr. Nejat YUMUŐAK'a teşekkürlerimi sunarım.

Elektronik burun verilerinin temini ve düzeni konusundaki desteklerinden ötürü TÜBİTAK Gaz Sensörleri Laboratuvarından Dr. Cihat TAŐALTIN'a ve Viyana Üniversitesi Gaz Sensörleri Laboratuvarı sorumlusu Prof. Dr. Peter Lieberzeit'e teşekkür ederim.

Hayatımın her anında beni sonuna kadar destekleyen çok kıymetli annem, babam ve abime, çalışmamı gerçekleştirdiğim dönemde dünyaya gelen kızım Elif Sare'ye ve değerli eşim Onur CANPOLAT'a sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ.....	vii
ÖZET.....	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
ELEKTRONİK BURUN	4
2.1. Elektronik Burun ile İnsan Burnunun Karşılaştırılması	4
2.2. Sensörler ve Temel Elemanları.....	4
2.3. Elektronik Burun.....	5
BÖLÜM 3.	
YSA.....	8
3.1. YSA'nın Sınıflandırılması	11
3.1.1. Yapılarına göre yapay sinir ağları	12
3.1.2. Öğrenme şekline göre yapay sinir ağları.....	12
3.1.3. Öğrenme zamanına göre yapay sinir ağları.....	13
3.2. Geri Yayılım Algoritması	14
3.2.1. İleri doğru hesaplama	14
3.2.2. Geri yayılım algoritması	15

BÖLÜM 4.

GENETİK ALGORİTMALAR	18
4.1. GA'nın Avantajları	20
4.2. GA'nın Geleneksel Yöntemlerden Farkları	21
4.3. GA ile İlgili Temel Kavramlar	21
4.3.1. Uygunluk fonksiyonu	22
4.3.2. Gen	22
4.3.3. Kromozom	22
4.3.4. Popülasyon	22
4.3.5. Seçilim	23
4.3.5.1. Rulet tekniği	23
4.3.5.2. Oran (rank) tekniği	23
4.3.5.3. Turnuva tekniği	23
4.3.6. Çaprazlama	24
4.3.6.1. Tek noktalı çaprazlama	24
4.3.6.2. Çift noktalı çaprazlama	24
4.3.6.3. Çok noktalı çaprazlama	25
4.3.6.4. Rastgele çaprazlama	25
4.3.7. Mutasyon	25

BÖLÜM 5.

UYGULAMA	27
5.1. Veri Setinin Oluşturulması	27
5.2. Gaz Sensör Sistemi	27
5.3. Deneysel Ölçümler	29
5.4. Kullanılan YSA Modelinin Yapısı	31
5.5. Kromozom Yapısı	33
5.6. Uygulamada Kullanılan Yazılım	33
5.7. Uygulamada Kullanılan Yazılımın Süreçleri	34

BÖLÜM 6.	
ELDE EDİLEN BULGULAR	49
BÖLÜM 7.	
SONUÇ VE ÖNERİLER	53
KAYNAKLAR	54
ÖZGEÇMİŞ	61

SİMGELER VE KISALTMALAR LİSTESİ

AC	: Aseton – kloroform ikili gaz karışımı
CO	: Karbon monoksit
GA	: Genetik algoritma
GY	: Geri yayılım algoritması
H ₂ S	: Hidrojen sülfid
MC	: Metanol – kloroform ikili gaz karışımı
NH ₃	: Amonyak
NO ₂	: Azot dioksit
QCM	: Kuvars kristal mikrobals
YSA	: Yapay sinir ağıları

ŞEKİLLER LİSTESİ

Şekil 3.1. Basit nöron yapısı	9
Şekil 3.2. YSA modeli	9
Şekil 4.1. Genetik algoritma akış diyagramı	20
Şekil 5.1. Gaz sensör sistemi	28
Şekil 5.2. İkili gazların karışım oranları.....	29
Şekil 5.3. Sensörlerin MC ve AC ikili gaz karışımlarına verdikleri tepki	30
Şekil 5.4. Elektronik burun ile elde edilen veri seti örneği.....	30
Şekil 5.5. Uygulamada kullanılan YSA Yapısı.....	32
Şekil 5.6. Kromozom yapısı.....	33
Şekil 5.7. Uygulama ana ekranı	34
Şekil 5.8. Yazılımın akış şeması	35
Şekil 5.9. Kromozomların uygunluk fonksiyonlarının hesabı	37
Şekil 5.10. Çaprazlama akış şeması	40
Şekil 5.11. Seçilim akış şeması	41
Şekil 5.12. Rulet tekniği akış şeması	42
Şekil 5.13. Rank yöntemi akış şeması.....	43
Şekil 5.14. Turnuva tekniği akış şeması.....	43
Şekil 5.15. Çaprazlama işlemi için seçilen 300. ve 800. kromozomlar	44
Şekil 5.16. Lopus seçimi	44
Şekil 5.17. Çaprazlama işlemi.....	45
Şekil 5.18. Çaprazlama işlemi sonucunda oluşan yeni çocuk kromozomlar	45
Şekil 5.19. Mutasyon akış şeması	46
Şekil 5.20. Mutasyona uğrayacak genin seçimi	47
Şekil 6.1. GA ile eğitilen YSA modellerinin test verilerine ait MSE değerleri.....	51
Şekil 6.2. GY ile eğitilen YSA modellerinin test verilerine ait MSE değerleri.....	51
Şekil 6.3. Test verileri ile elde edilen çıktılarının karşılaştırılması.....	52

TABLolar LİSTESİ

Tablo 1.1. Elektronik burun konusunda yapılan bazı çalışmalar	2
Tablo 1.2. YSA konusunda yapılan bazı çalışmalar	3
Tablo 1.3. GA konusunda yapılan bazı çalışmalar	3
Tablo 2.1. İnsan burnu ve elektronik burunun 4 farklı gazı algılama sınırları.....	7
Tablo 3.1. Aktivasyon fonksiyonu çeşitleri	11
Tablo 4.1. Tek noktalı çaprazlama	24
Tablo 4.2. Çift noktalı çaprazlama	24
Tablo 4.3. Çok noktalı çaprazlama	25
Tablo 4.4. Rastgele çaprazlama	25
Tablo 5.1. Sensörlere ait detaylar	28
Tablo 6.1. Genetik algoritma parametreleri	49
Tablo 6.2. Geri yayılım algoritma parametreleri	49
Tablo 6.3. Genetik algoritma için hata değerleri.....	50
Tablo 6.4. Geri yayılım algoritması için hata değerleri	50

ÖZET

Anahtar kelimeler: Yapay sinir ađları, genetik algoritma, elektronik burun

Elektronik burun, insan ya da diđer canlıların burunlarının yaptıđı görevi yapan elektronik bir aygıttır. Yapısında bulunan sensörler yardımıyla birbirinden farklı yüzlerce kokuyu ayırt edebilmekte ve sınıflandırabilmektedir. Elektronik burun insan burnunun alamadıđı kokuları bile alabildiđi bu beceriyi, kokuların kendisine daha önceden öğretilmesi sayesinde kazanmıştır. Bu öğrenme, yapay sinir ađları (YSA) yardımıyla gerçekleştirilebilmektedir. Ancak yapay sinir ađlarında genellikle kullanılan geri yayılım algoritması, zaman zaman verilerin eğitim sırasında ezberlenmesine sebep olmaktadır. Bu durum, YSA'dan istenilen performansın alınmasını engellemektedir. O nedenle bu çalışmada; geri yayılım algoritmasının olumsuz etkilerinden arınmak için yapay sinir ađları genetik algoritmalar (GA) ile eğitilmiştir. GA, yeteri kadar süresi olursa en iyi sonucu garanti edebilmektedir. En iyi sonucun elde edilemediđi durumlarda ise, en iyi sonuca çok yakın çözümlere ulaşabilmektedir. Elektronik burun koku verilerinin kullanıldıđı çalışmada, 7 farklı YSA modeli oluşturulmuş, genetik algoritma ile eğitilerek birçok test yapılmış ve içlerinden en iyi çözümü veren model seçilmiştir. Yapılan bu testler sonucunda yapay sinir ađının genetik algoritmayla eğitilmesi ile elde edilen sonuçların, geri yayılımla eğitilmesi ile elde edilen sonuçlara göre daha iyi olduđu görülmüştür.

TRAINING OF ARTIFICIAL NEURAL NETWORKS WITH GENETIC ALGORITHMS AND APPLICATION TO ELECTRONIC NOSE DATA

SUMMARY

Keywords: Artificial neural networks, genetic algorithm, electronic nose

Electronic nose is an electronic device that does the job of humans or other creatures' noses. With the help of sensors in the structure, hundreds of different odors can be distinguished and classified. Electronic nose can even sense the odors that human nose cannot sense. The electronic nose has won this skill which owing to the smells have already been taught to it. This learning can be performed with artificial neural networks (ANN). However, the backpropagation algorithm, which is usually used in artificial neural networks, sometimes causes the data to be memorized during training. This prevents the desired performance from ANN. For this reason, in this study; artificial neural networks are trained by genetic algorithms (GA) to avoid the negative effects of backpropagation algorithm. GA can guarantee the best result or very close results to best result if it has enough time. In this study, which uses odor data of electronic nose, 7 different ANN models are developed and trained by genetic algorithm, many tests are performed and the best model is determined. As a result of these tests, it is seen that the results obtained by training the artificial neural network with genetic algorithm are better than the results obtained by training with back propagation algorithm.

BÖLÜM 1. GİRİŞ

Elektronik burun insan burnu model alınarak geliştirilmiş bir cihazdır. Fakat insan burnunun hiç algılayamadığı kokular bulunmaktadır veya insan burnu belli bir süre sonra kokuya alışmış olmasından dolayı kokuyu algılayamamaktadır. Ayrıca insan burnunun aldığı koku kişiden kişiye değişiklik gösterebilir yani subjektiftir. Elektronik burun ise insan burnunun algılayamadığı kokuları algılayabilir. Aynı kokuyu tekrar tekrar alıp aynı sonucu üretebilir. Girdi verileri değişmediği sürece alınan sonuç değişkenlik göstermez [1].

Literatür taraması yapıldığında bu konuyla ilgili gıda sektörü, ilaç sektörü, tıp sektörü, tarım sektörü, kozmetik sektörü, güvenlik sektörü gibi çeşitli alanlarda elektronik burun ile ilgili birçok çalışma olduğu görülmektedir. Bu da konunun güncelliğini koruduğunu gözler önüne sermektedir. Elektronik burun konusunda yıllara göre yapılan çalışmalar, Tablo 1.1.'de gösterilmiştir.

Elektronik burunda, birçok sensör bulunmaktadır. Bu sensörler aracılığıyla elektronik burun aldığı koku verisinin sayısal hale gelmesini sağlamaktadır. Elde edilen bu veriler belli yöntemler kullanılarak incelenebilir ve sınıflandırılabilir [2]. Bu çalışmada elektronik burun ile elde edilen koku verilerini sınıflandırmak için yapay sinir ağı (YSA) ve genetik algoritma (GA) yöntemleri kullanılmıştır. YSA, karmaşık problemlerin çözümünde sıklıkla kullanılan başarılı bir tekniktir [3]. Literatürdeki çalışmalar incelendiğinde, YSA konusunda uzun yıllardır çalışıldığı ve konunun pek çok alanda uygulandığına rastlanmaktadır. YSA konusunda yapılan bazı çalışmalar yıllarına göre, Tablo 1.2.'de gösterilmiştir.

Genetik algoritmalar, genetik bilimini temel almış, evrimsel algoritmaların öncülerinden olan bir sezgisel yöntemdir [4]. Genetik algoritma bir anda birçok

çözümü dikkate aldığı için en iyi sonuca çok yakın sonuçlar elde edebilmektedir. Ancak, yapay sinir ağlarının geri yayılım ile eğitilmesinde geri yayılım algoritmasının deterministik olmasından dolayı sezgisel olarak hareket edilememesi durumu oluşmaktadır. Bu durum, ağın lokal minimumlara takılarak veya eğitim verilerini ezberleyerek en iyi sonuçtan uzaklaşmasına sebep olabilmektedir. Bu ihtimalleri ortadan kaldırmak için eğitim kısmında genetik algoritma kullanılması tercih edilmiştir. Böylelikle GA ile deterministik yöntemlerden kaynaklanabilecek sorunlar ortadan kaldırılarak geri yayılım algoritmasına göre daha başarılı sonuçlar elde edilmiştir. Literatür incelendiğinde, gerek GA gerekse de GA ile eğitilmiş YSA modellerinin kullanıldığı çalışmalar görülmektedir. Konuyla ilgili literatür özeti Tablo 1.3.'te sunulmuştur.

Tablo 1.1. Elektronik burun konusunda yapılan bazı çalışmalar

Yazar	Konu	Yıl	Kaynak
Moncrieff	Mekanik burun	1961	[5]
Wilkens ve Hartman	Koklama süreci için elektronik burun	1964	[6]
Buck ve ark.	Metal yüzeylerindeki kimyasalların tespiti	1965	[7]
Dravnieks ve Trotter	Elektronik burun kavramı	1965	[8]
Persaud ve Dodd	Kokuyu sınıflandıran elektronik burun	1982	[9]
Ping	Şeker hastalığının belirlenmesi	1996	[10]
Ryabtsev ve ark.	Kalp hastalıkları ve zihinsel hastalıklarda	1999	[11]
Phillips	Siroz hastalığının belirlenmesi	1999	[12]
Paulsson ve ark.	Nefes ile alkol seviyesinin incelenmesi	1999	[13]
Nakamoto ve ark.	İnsanın ter kokusunun incelenmesi	2000	[14]
Aizawa ve ark.	Serumdaki troponema pallidumun incelenmesi	2001	[15]
Spangler ve ark.	Su kirliliğinin incelenmesi	2001	[16]
Dutta	Bakterilerin sınıflandırılması	2002	[17]
Fend	Nefes kokusunun incelenmesi	2003	[18]
Fu	İnsanlardaki virüsün saptanması	2004	[19]
Monge ve ark.	Jellerin incelenmesi	2004	[20]
Boholt ve ark.	Bitkilerdeki kokuların incelenmesi	2005	[21]
Özmen ve ark.	Zehirli gazların belirlenmesi	2006	[22]
Saraoğlu	Koku tanı sistemi ve uygulama alanları	2008	[1]
Tran ve ark.	Akciğer kanseri hastalarının nefes analizi	2010	[23]
Rodriguez	Aromaların değerlendirilmesi	2010	[24]
Musatov	Etin kalitesinin belirlenmesi	2010	[25]
Zhou ve Wang	Hasarlı bitkilerin belirlenmesi	2011	[26]
Xiao ve ark.	Likör aroma bileşenlerinin sınıflandırılması	2014	[27]
Versari ve ark.	Şarap kalitesinin analizi	2014	[28]
Dymerski ve ark.	Bal tiplerinin sınıflandırılması	2014	[29]
Deshmukh	Kağıt endüstrisi koku yoğunluğu incelenmesi	2014	[30]
Gupta ve ark.	Kemometrik yaklaşım ile sınıflandırma	2015	[31]
Pizzoni ve ark.	Yiyeceklerin değerlendirilmesi	2015	[32]
Kablan	Çayların sınıflandırılması	2018	[33]

Tablo 1.2. YSA konusunda yapılan bazı çalışmalar

Yazar	Konu	Yıl	Kaynak
Cevoli ve ark., Gursoy ve ark.	Bazı peynir türlerinin YSA ile sınıflandırılması	2011 2009	[34] [35]
Pavlou ve ark.	Tüberkülozun YSA ile belirlenmesi	2004	[36]
Dhanarajan ve ark., Ghaedi ve ark.	YSA ile parçacık sürü optimizasyonunun birlikte kullanımı	2014 2014	[37] [38]
Özmen ve ark.	YSA ile gaz karışımlarının bileşiminin bulunması	2006	[22]
Mumyakmaz ve ark.	3D numune alanı için gaz karışımlarının konsantrasyonlarını tahmin etme	2008	[39]
Gülbağ ve Temurtas	İkili gaz karışımlarının sınıflandırılması	2006	[40]
Gordillo-Ruiz ve ark.	Kadmiyum, nikel ve çinko adsorpsiyonu	2017	[41]
Yan ve ark.	Enfeksiyon tespitinde parçacık sürü optimizasyonu ile destek vektör makinelerinin birlikte kullanımı	2012	[42]
Al-Bastaki ve ark.	Parfüm kokusunun YSA ile sınıflandırılması	2009	[43]
Banerjee ve ark.	Fıstık ve badem kabuğundan iyon adsorpsiyonu	2017	[44]
Kuvendziev ve ark.	Cd(II) iyonunun YSA ile incelenmesi	2015	[45]

Tablo 1.3. GA konusunda yapılan bazı çalışmalar

Yazar	Konu	Yıl	Kaynak
Ekicioğlu	YSA yapısının GA ile belirlenmesi	2011	[46]
Hacioğlu	GA ile YSA'nın birlikte kullanımı	2004	[47]
Zalzala ve ark.	Robot uygulamalarında GA kullanımı	1997	[48]
Koza ve ark.	Sıralama ağlarının GA ile geliştirilmesi	1998	[49]
Küçükkoç	GA ile montaj hattı dengeleme	2011	[4]
Guha ve ark.	GA'nın YSA ile sentezi	1992	[50]
Çeyrekoğlu	GA ile araç rotalama	2017	[51]
Guo ve ark.	Bir nükleer santralin giriş değişkenlerinin seçiminin GA ile yapılması	1992	[52]
Gupta ve Sexton, Potter	YSA'nın GA ile eğitimi	1999 1992	[53] [54]
Freitas	Veri madenciliğinde GA kullanımı	2009	[55]
Feringer ve ark.	Uydu konumlandırma GA kullanımı	2009	[56]
Condgon	Tıp ve biyoloji alanında GA kullanımı	2008	[57]
Bolat ve ark.	Mühendislik uygulamalarında GA kullanımı	2004	[58]
Kulluk	GA ile tesis yerleşimi	2003	[59]

Bu çalışmada elektronik burun verileri kullanılarak bir veri seti elde edilmiştir. Veri seti eğitim ve test veri seti olmak üzere iki gruba ayrılmıştır. Yedi farklı YSA modeli tasarlanmıştır. Tasarlanan YSA modelleri GA ve geri yayılım algoritmasıyla eğitilip test edilmiştir. YSA'ların eğitim aşamasında GA kullanıldığı durumlarda, geri yayılım algoritması kullanıldığı durumlara göre daha iyi sonuçlar elde edilmiştir.

BÖLÜM 2. ELEKTRONİK BURUN

2.1. Elektronik Burun ile İnsan Burnunun Karşılaştırılması

İnsan burnu bazı zamanlar aldığı kokunun neye ait olduğunu o nesneyi görmediğinde çok zor algılayabilmektedir. İnsan burnu kokuları algılamak duygusal davranmaktadır. Elektronik burun ise kokunun nasıl koktuğunu dikkate almadan yalnızca kokuyu algılamaktadır. Elektronik burunda duygusal tepkinin olmaması olumsuz bir durum değildir. İnsan burnu için koklamanın çok zor olduğu kokuları, örneğin gıda sektöründe kullanılmayacak besinlerin kokularını ayırt etmek için elektronik burunlar rahatlıkla kullanılabilir [60].

Elektronik burun insan burnuna yardım edebilen bir ürün olarak görülmez. Elektronik burun ve insan burnu arasındaki bağlantı kamera ve göz arasındaki bağlantı gibi düşünülmelidir. Yani insanların kendilerini model alıp tasarladığı bu yapay ürünler aslının yerine geçmesi şeklinde düşünülmemelidir.

2.2. Sensörler ve Temel Elemanları

İnsanlar dış ortamı algılayabilmek için duyu organlarını kullanmaktadırlar. İnsanlara ait bu işlemi bilgisayar ortamına taşıyabilmek için tasarlanan yapay ürünlerde duyu organlarının işlevini sensörler yerine getirmektedir. Dış ortamdan gelen bir uyarı canlılarda duyu organları vasıtasıyla kimyasal prensipler kullanılarak algılanırken; kimyasal veya fiziksel uyarının yer aldığı form, tasarlanan sensörler aracılığı ile genel olarak işlenmesi kolay olduğundan dolayı elektriksel olan işarete çevrilerek algılanmaktadır [60].

Sensörler bazı özellikler göz önünde bulundurularak sınıflandırılırlar. Sensörlerin sınıflandırılmasında dikkate alınan hususlar aşağıdaki gibidir [2];

- Sensörün özellikleri (duyarlılık vb.)
- Üretilirken kullanılan malzeme (iletken vb.)
- Algıladıkları uyarı (koku, ısı vb.)
- Algılama işlemi sırasında kullanılan çevrim mekanizması (ısı optik vb.)
- Kullanıldığı alanlar (otomotiv vb.)
- Çalışma ortamındaki sıcaklık (düşük sıcaklık vb.)

Bir sensörde yer alan ana elemanlar ise aşağıda belirtildiği gibidir [2];

- Uyarıcı
- Süzgeç
- Algılayıcı madde
- Uyarıcı işaret
- Dönüştürücü
- İşaret işleyici
- Kaydedici

Fakat yukarıdaki ana elemanların hepsi her sensörde yer almayabilir. Ya da kullanılan sensör sistemi akıllı ise yukarıdaki elemanların yanı sıra sensör tarafından bulunan verileri işlemek için sensör sisteminde mikroişlemci de yer almaktadır.

2.3. Elektronik Burun

Dış ortamdaki kokuyu algılayan, algılama sonucu elde ettiği kimyasal içeriği sinyallere çeviren, sonrasında da kendisinde önceden var olan kokuları sınıflandıran, ilk karşılaştığı kokuları da tanımlayıp elektrik sinyallerine dönüştüren bir sisteme elektronik burun denir. [61], [62]. Günümüzde, tıp, savunma sanayi, otomotiv sanayi, gıda ve kozmetik sektörleri başta olmak üzere pek çok farklı alanda elektronik burunlar kullanılmaktadır [33].

Buruna ait çalışma sisteminin 1-0 kuralına göre olduğu düşünülüp, o nedenle elektronik bir devreye benzetilmektedir. Burun dış ortamdaki kokuyu aldıktan sonra burunda yer alan herhangi bir alıcı tarafından bu kokuya karşı bir uyarı oluşur veya oluşmaz. Sonuç olarak kokunun algılanması teorik olarak 10010...00 olarak ifade edilebilir [2].

İnsan burnu model alınarak tasarlanan bir koku algılama sisteminde yer alan bileşenler [33], [2];

- Gaz sensörleri,
- Örüntü tanıma,
- Elektronik devredir.

Koku algılama sisteminde yer alan sensörlerdeki seçicilik özelliği çok çeşitlidir. Yani tepki verebildiği kimyasal bileşik sayısı çok fazladır. Bu özelliği tek bir koku algılanması gerektiği durumlar için olumsuz bir özellik olarak dursa da, birbirinden farklı kokulara sahip birçok bileşenin bir araya gelerek oluşturduğu bir ürünün incelenmesi gerektiği durumlarda çok büyük avantaj olmaktadır [60].

Koku algılama sistemi tarafından algılanan kimyasal karışım, sistemde yer alan birden fazla sensörden uyarı almaktadır. Kimyasal karışımın aldığı bu uyarılar genellikle birbirinden farklılık gösterir. Sistemde yer alan sensörler tarafından kimyasal karışıma ait buhar koklandığında bu kokuya ait bir veri seti oluşur. Örüntü tanıma aracılığıyla; elde edilen veri seti daha önceden elde bulunan veri setiyle farklı yöntemler kullanılarak kıyaslanır. Bu şekilde algılanan kokuları tanımlamaya çalışan sisteme elektronik burun adı verilmektedir [2].

Koku algılama sistemi çok çeşitli uygulama alanlarına sahiptir. Bunlardan bazıları [60], [62];

- Askeri çalışmalar
- Endüstri uygulamaları,

- Farmakolojik çalışmalar, (ilaç bilimi)
- Gıda sektörü,
- Sağlık ve hastalık teşhisi,
- Kalite kontrol,
- Kapalı ortamlardaki havanın kontrolü,
- Güvenlik ile ilgili çalışmalar,
- Çevre ile ilgili çalışmalardır.

Bu ve daha birçok uygulama alanlarında koku algılama sistemi olarak insan burnu daha çok kullanılmaktadır. Buradaki uygulama alanlarında yapılmakta olan çalışmaların maliyeti çok fazladır. Bu çalışmalarda yer alan uzman kişiler çalışma saatlerini kısa tutmakta; ayrıca fiziksel ve zihinsel olarak yorgunluğu, alınan sonucun sadece o kişiye ait olması ve çalışma ortamında tehlikeli olan maddelerin bulunması gibi zorluklar ortaya çıkabilmektedir [2].

İnsanlar çok fazla sayıda kokuyu algılayabilirken elektronik burunların algılayabildikleri kokular sınırlıdır. İnsan burnunun ve elektronik burnun duyarlılığıyla ilgili bir bilgi sahibi olmak için; hem elektronik burun hem de insan burnu ile her ikisi için aynı gazlar kullanılarak çalışma yapıp bu gazlar için algılamalarındaki limitler kıyaslanabilir. Bazı gazlar için algılama sınırları Tablo 2.1.'de gösterilmiştir [60].

Tablo 2.1. İnsan burnu ve elektronik burunun 4 farklı gazı algılama sınırları (ppm)

Gaz	İnsan burnu	Elektronik burun
NH_3	3	50
NO_2	3	5
H_2S	0,14	10
CO	∞	30

Yukarıdaki tablo incelendiğinde örneğin, CO gazı insan burnu tarafından algılanamamaktadır fakat H_2S gazına karşı insan burnu elektronik burundaki sensörlere göre daha çok duyarlıdır denilebilir.

BÖLÜM 3. YSA


YSA, insan beyni model alınarak, öğrenme işlevinin sayısal olarak gerçekleştirilmesi için yapılan çalışmalar sonucu keşfedilmiştir. Bundan dolayı konuyla ilgili ilk çalışmalar beyinde bulunan nöronların işlevinin bilgisayar ortamında gerçekleştirilmesi ile ilgili olmuştur ve bilgisayar ile ilgili gelişmeler zamanla arttıkça bu konu geliştirilip çeşitli alanda uygulanmaya başlamıştır [63].

İnsan beyni taklit edilerek tasarlanan bu modeller, bilgisayar sistemleri hızla gelişmekte ve gerçekleştirilecek işlemlerin süreleri gittikçe kısalmasına rağmen insan beyninin yanında çok basit kalmaktadır. Ancak YSA'lar sağladığı yapısal model ve diğer avantajları nedeniyle her geçen gün daha fazla alanda uygulanmaya devam etmektedir [63].

YSA insan beyni model alınarak tasarlandığı için ilk olarak insan beyninin çalışma şekli anlaşılmalıdır. İnsan beyinde milyarlarca sinir hücresi bulunmaktadır. Nöronların kendileri arasında yaptıkları bağlantı sayısı ise trilyonları bulmaktadır. Sinir hücresinde duyu organları aracılığı ile girdiler alınmaktadır. Duyu organlarından alınan sinyaller, sinirler aracılığı ile işlenip aralarında aktarım yapılarak merkezi sinir sistemine ulaştırılmaktadır. Merkezi sinir sistemine ulaşan sinyaller yorumlanarak tepki sinyalleri üretilir. Üretilen tepki sinyalleri yine sinirler aracılığıyla gerekli organlara ulaştırılır. Bu şekilde duyu organlarından alınan girdi verileri tepkilerin gerçekleşeceği organlara sinir sistemi aracılığı ile ulaştırılmış olur [63].

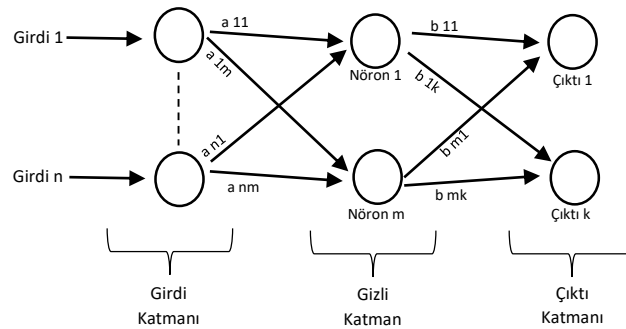
Nöronlar biyolojik sinir sisteminin en önemli parçasıdır. Şekil 3.1.'de görüldüğü üzere bağlantılar, çekirdek, akson ve dendrit olmak üzere 4 önemli parçadan meydana gelmektedir. Dendritler nöronun uç kısmında yer alır ve aldığı sinyalleri çekirdeğe ulaştırır. Çekirdek ise dendrit aracılığı ile kendine gelen sinyalleri toplayıp aksona

ulaştırır. Akson ise kendine gelen tüm sinyalleri işleyip bağlantılara aktarır. Son olarak sinyaller bağlantılardan başka nöronlara aktarılır [63].



Şekil 3.1. Basit nöron yapısı

İnsan beynindeki sinir hücresi, temel olarak YSA'da yer alan bir hücreye kıyasla oldukça karmaşıktır [64]. Yapay sinir ağında Şekil 3.2.'de görüldüğü üzere bir girdi katmanı, bir gizli katman bir de çıktı katmanı olmak üzere 3 katman bulunmaktadır [2]. Gizli katman tek katmandan oluşmak zorunda değildir. YSA'da girdiler, nöronlar ve ağırlıklarla işlenerek çıktılar elde edilir [65].



Şekil 3.2. YSA modeli [2]

Yapay sinir ağları doğrusal değildir. Yani girdilerden birinde herhangi bir değişiklik olduğunda çıktılar yalnızca o değişime orantılı olarak değişmez [65].

YSA'da alınan girdiler sisteme dağıtıldığından dolayı hata toleransı vardır. Yani YSA'nın yapısında herhangi bir elemandaki hata YSA'nın doğru çıktı elde etmesini fazla etkilemez. YSA'da doğru çıktı elde edebilmek için en uygun şekilde tasarlanması gerekir. Yani bağlantılar ve ağırlıkların doğru bir biçimde ayarlanması gerekir. YSA'da en uygun tasarım yapıldıktan sonra doğru çıktıları elde etmek için ağırlıklar YSA'nın kendisi tarafından güncellenmektedir [65].

YSA'ya öncelikle öğrenebilmesi için veri setinin bir kısmı verilir. Bu veri seti kullanılarak YSA tarafından en uygun ağırlıklar belirlenmektedir. YSA'da öğrenme işlemi tamamlandıktan sonra eğitim esnasında YSA'ya verilmeyen geri kalan veri seti için de istenilen çıktılar YSA tarafından elde edilebilmektedir.

Yapay sinir ağının bölümleri [63];

- Girdi: Nörona dışarıdan ya da başka hücreden gelebilen veridir.
- Ağırlık: YSA'ya gelen veriler nörona iletilmeden önce iki nöron arasındaki bağlantının ağırlığıyla çarpılır ve sonra nörona iletilir.
- Toplam Fonksiyonu: YSA'da ki nörona, ağırlıklar ile etkileşime girerek iletilen girdileri birleştirerek o nörona ait net girdi değeri hesaplanır. En iyi toplam fonksiyonu seçmek için yöntemler yoktur. Genel olarak deneme yoluyla seçilir. Toplam fonksiyonu YSA'yı tasarlayan kişiye bağlı olarak değişiklik gösterebilir. Bazı toplam fonksiyonları;
 - a. Toplam: Girdi değerleri ağırlıklarla çarpılarak bulunan veriler toplanır ve Net değerler bulunur.
 - b. Çarpım: Girdi değerleri ağırlıklarla çarpılarak bulunan veriler çarpılır ve Net değerler bulunur.
 - c. Maksimum: Girdi değerleri ağırlıklarla çarpılarak bulunan veriler arasından maksimum olanı Net değer olarak alınır.
 - d. Minimum: Girdi değerleri ağırlıklarla çarpılarak bulunan veriler arasından minimum olanı Net değer olarak alınır.

- e. **Çoğunluk:** Girdi değerleri ağırlıklarla çarpılarak bulunan veriler pozitif ve negatif olarak ayrılarak kaç adet oldukları hesaplanır. Hangisi sayı olarak daha çok ise onun sayısı olan Net değer olarak alınır.
 - f. **Kümülatif Toplam:** Gelen bilgilerin ağırlıklı toplanması ve net girdiyi hesaplayabilmek için önceden hücreye gelmiş bilgilere hesaplanan yeni değerlerin eklenmesi işlemleri gerçekleştirilir.
- **Aktivasyon Fonksiyonu:** nörona ait net değer işlenir ve o nörona ait çıktı değeri belirlenir. Genel olarak doğrusal değildir. YSA'yı doğrusal yapmayan, aktivasyon fonksiyonunun doğrusal olmayışıdır. Genelde sigmoid kullanılır. Aktivasyon fonksiyonu çeşitlerinin bazıları Tablo 3.1.'de gösterilmiştir.

Tablo 3.1. Aktivasyon fonksiyonu çeşitleri

Fonksiyon	Açıklama	Formül
Lineer	Doğrusal olan problemlerin çözümünde kullanılır.	$F_{Net} = K * Net$ (K sabit sayı)
Adım	Öncelikle eşik olarak bir değer seçilir. Net değer seçilen eşikten küçük ya da büyük oluşuna göre nöronun çıktı değeri 0 ya da 1 olur.	$F_{Net} = \begin{cases} 0, & Net \leq Eşik \\ 1, & Net > Eşik \end{cases}$
Sigmoid	Türevi alınabilen ve sürekli olan bir aktivasyon fonksiyonudur. Her değer için 0 ve 1 aralığında olacak şekilde çıktı üretir.	$F_{Net} = \frac{1}{1 + e^{-Net}}$
Tanjant Hiperbolik	Sigmoid aktivasyon fonksiyonu ile benzerlik gösterir. Sigmoid' de çıkış verileri 0-1 aralığındadır. Tanjant hiperbolikte ise çıkış verileri -1-1 aralığındadır.	$F_{Net} = \frac{e^{-Net} + e^{Net}}{e^{Net} - e^{-Net}}$
Eşik Değeri	Nörona ait çıktı değeri, Net değer 0 veya 0'dan küçük ise 0, 0 ve 1 aralığındaysa net değer kendisi, 1 ya da 1'den büyükse de 1'dir.	$F_{Net} = \begin{cases} 0, & Net \leq 0 \\ Net, & 0 < Net < 1 \\ 1, & Net \geq 1 \end{cases}$
Sinüs	Olayların dağılımının sinüs fonksiyonuna uygun olduğu durumlarda kullanılır.	$F_{Net} = Sin(Net)$

- **Çıktı:** Aktivasyon fonksiyonunun işlemlerinin ardından çıkan değere çıktı adı verilmektedir. Çıktı, problemi tasarlayanın kararına göre yeniden ağın içerisinde de kullanılabilir.

3.1. YSA'nın Sınıflandırılması

Literatürdeki pek çok çalışma incelendiğinde, yapay sinir ağlarının genellikle yapılarına, öğrenme şekline ve öğrenme zamanına göre sınıflandırıldığı görülmektedir [63].

3.1.1. Yapılarına göre yapay sinir ağıları

YSA yapısında bulundurduğu nöronlar arasındaki bağlantıya göre iki kategoride incelenebilir.

- İleri Beslemeli YSA: Nöronların giriş katmanından çıkış katmanına doğru belirli bir düzen içerisinde olduğu YSA'dır. Bir katmanın sadece kendisinden bir ilerideki katman ile arasında bağlantı vardır. Ağa gelen girdi verileri sırayla giriş, ara(gizli) ve çıkış katmanında işlemlere uğrayarak YSA'dan çıkar.
- Geri Beslemeli YSA: İleri beslemeli YSA'nın tersine, bir nöronun çıktığı verisi sadece kendisinden bir ilerideki nöronun girdisi değildir. Kendisinden önce ya da aynı katmanda yer alan nörona da girdi olabilir. Geri beslemeli YSA'nın değişken yapısı bu özelliği ile sağlanmaktadır. Bu ağ yapısında, bağlantıların bağlantısına göre aynı YSA'dan farklı yapıda bir YSA elde edilebilir.

3.1.2. Öğrenme şekline göre yapay sinir ağıları

YSA'nın gelen girdi verilerine göre doğru çıktı verebilmesi, öğrenebilmesi sayesinde gerçekleşir. YSA öğrenmesinin de çeşitli yöntemleri bulunmaktadır. YSA öğrenme yöntemlerine göre üç grupta incelenir [63].

- Danışmanlı Öğrenme: Öğrenme işlemi sırasında YSA'ya gelen her girdi değeri ile birlikte o girdi değerine ait çıktı verisi de YSA'ya gönderilir. YSA, gelen girdi değerlerine ait çıktı verilerini üretebilmek için ağırlık güncellemesi yapar. YSA'nın ürettiği çıktı verileri ile olması gereken çıktı verileri arasında olan hata değeri hesaplanır ve YSA'ya ait ağırlık değerlerinin güncellenmesi hesaplanan hata değerine göre yapılır. Ağırlık güncellemesinde kullanılan hata değeri hesaplanırken YSA'nın ürettiği çıktı verileri ile olması gereken çıktı verilerinin farkları bulunur ve bulunan bu fark değerine göre her nöron için hata değeri hesaplanır. Sonrasında her nörona gelen ağırlık verileri yenilenir.
- Danışmansız Öğrenme: Danışmansız öğrenmede ağ, kendisine daha önceden hiç gösterilmemiş verileri tahmin eder. YSA'ya öğrenme işlemi sadece girdi değerleri verilir. Olması gereken çıktı değerleriyle ilgili hiçbir veri

verilmez. YSA aldığı girdi değerlerine göre sınıflandırma yaparak kurallar oluşturur. YSA, ağırlıkları; özellikleri aynı olan veriler ayırt edebilecek şekilde ayarlayarak öğrenmeyi tamamlar.

- Destekleyici Öğrenme: Destekleyici öğrenmede, ağda gerçekleşen her iterasyon bitiminde elde edilen sonucun iyi mi kötü mü olduğuyula alakalı bilgiye ulaşılır. YSA ulaşılan bilgiler ışığında ağırlıklarını günceller. Bu şekilde YSA sadece girdi verileriyle hem öğrenme işlemini yapar hem de sonuç çıkarır. YSA bir karar verip uyguladığında bu kararın doğru ya da yanlış olduğunu o an bilememesine rağmen bu kararı uygular. Eğer görevi bittiğinde YSA'nın aldığı kararlar ile istenilen sonuca ulaşıldıysa YSA aldığı kararların doğru kararlar olduğunu kabul edecektir ve daha sonrasında bu görevi tekrar yapacağı zamanda benzer kararları doğru karar diye değerlendirip uygulayacaktır.

3.1.3. Öğrenme zamanına göre yapay sinir ağları

YSA, öğrenme zamanı dikkate alındığında statik öğrenme ve dinamik öğrenme diye iki grupta incelenir [63].

- Statik Öğrenme: Bu öğrenme türüyle çalışan YSA'ların eğitimleri, kullanmaya başlamadan önce verilmektedir. Eğitimleri sona erdikten sonra YSA'lar istenildiği gibi kullanmaya başlanabilir. Yalnız YSA'daki ağırlıklar, YSA kullanmaya başladıktan sonra işlem bitene kadar hiç değişmez.
- Dinamik Öğrenme: Dinamik öğrenme türünde yer alan kurallar, YSA'nın yapması gereken tüm işlemlerini bitirirken aynı zamanda öğrenme işlevini de devam ettireceği şekilde tasarlanmıştır. Eğitim işlevi sona erdiğinde de YSA'nın sonraki çalışmalarında elde edilen çıktıların kabul edilmesine göre YSA mevcut ağırlıklarını güncelleyerek çalışmasını devam ettirir.

3.2. Geri Yayılım Algoritması

Geri yayılım algoritmasında öncelikle girdiden çıktıya doğru bir hesaplama yapılması gerekmektedir [2].

3.2.1. İleri doğru hesaplama

Bu işlemde eğitim setinde yer alan örneklerden bir tanesi seçilir. Seçilen örnek veri, kullanılacak olan YSA'da girdi katmanına verilir. Girdi verileri girdi katmanında yer alan ağırlıklar ile çarpılarak net değer elde edilir. Bu net değer aşağıdaki eşitlik (Denklem 3.1) kullanılarak hesaplanmaktadır [66].

$$NET_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i \quad (3.1)$$

Yukarıdaki denklemde, NET_j^a girdi katmanı için girdi değerlerinin, ara katman için ise ara katmanda yer alan nöronların çıktı değerleri ile ağırlıkların çarpılıp toplam fonksiyonu ile birleştirilerek elde edilen değeri ifade etmektedir. A_{kj} değeri ilgili nörona ait ağırlık değerini ζ_k^i ise, ilgili nörona ait çıktı değerini (Eğer girdi katmanıysa girdi verileri) göstermektedir.

Bulunan net değer seçilen aktivasyon fonksiyonunda işleme tabi tutularak ara çıktı değer bulunur. Ara çıktı değerleri, ara katman ile çıktı katmanı arasındaki ağırlıklarla çarpılarak çıktı net değer bulunur. Hesaplanan net değerler de aktivasyon fonksiyonunda işleme tabi tutulur ve aşağıdaki denklem yardımıyla (Denklem 3.2) YSA'nın çıktı değeri bulunur. Denklemde yer alan β_j^a nörona ait eşik değeridir. ζ_j^a ise, ilgili nörona ait çıktı değeridir.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (3.2)$$

3.2.2. Geri yayılım algoritması

Geri yayılım algoritması kullanılan ağda nöronlara ait eşik değerleri ve ağırlıklar ilk önce rastgele seçilir. Bu seçim yapılırken rasgele seçilecek bir aralık belirlenebilir. İleri doğru hesaplama ile bulunan çıktı değerleri ile olması gereken çıktı değerleri arasındaki fark hesaplanarak hata değeri bulunur [66].

Her iterasyonun sonunda aşağıdaki denklem (Denklem 3.3) kullanılarak hata değeri hesaplanır.

$$E_m = B_m - \zeta_m \quad (3.3)$$

Burada, E_m iterasyona ait hata değeri, B_m olması gereken çıktı değeri ve ζ_m hesaplanan çıktı değerini ifade etmektedir.

Eğitimde kullanılan bütün verilerin ağa verildiği durum ise epoch'tur. Epoch'a ait hatanın hesaplanması için gerçekleşen iterasyonlara ait hatalarının karelerinin toplam değeri hesaplanır (Denklem 3.4 ve 3.5) [66].

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (3.4)$$

$$\text{Epoch'a ait hata değeri} = \frac{TH}{\text{Veri Sayısı}} \quad (3.5)$$

Burada, TH iterasyonlara ait hataların karelerinin toplamı, veri sayısı ise eğitim setindeki toplam veri sayısını ifade etmektedir.

Bu işlemler tüm epoch'lar için tamamlandığında en son bulunan hata YSA'ya ait hatadır. Eğitimin başarılı olarak kabul edilmesi için YSA'ya ait hatanın sifıra çok yakın bir değer olması gerekmektedir.

İterasyonlarda hesaplanan hata değerleri eğer kabul edilebilecek hata değerinden büyükse ağırlık değerleri ile nöronlara ait eşik değerleri yenilenerek tekrar ileri doğru hesaplama yapılır ve yeni ağırlık değerleri için tekrar hata değeri hesaplanır.

Öncelikle çıktı ile gizli katman arasında yer alan ağırlıklar yenilenir. Bu ağırlıkların yenilenmesinin olması için öncesinde ağırlıklardaki değişimin ne kadar olacağını hesaplanması gerekir. Bu hesaplama aşağıdaki denklemler yardımıyla gerçekleştirilir (Denklem 3.6). Ağırlıklar için değişim miktarları hesaplanırken tüm iterasyonların öğrenme katsayısı ile momentum katsayısı dikkate alınır. Öğrenme katsayısı ne kadar büyük olursa öğrenme o derece hızlı olur. Daha iyi sonuçlar elde etmek için öğrenmenin hızlı değil yavaş olması istenir o nedenle küçük değerler verilir. Geri yayılım algoritmasının olumsuz yanlarından biri olan YSA'nın lokal minimuma düşmesini engelleyebilmek için ise momentum katsayısı kullanılır. Bu nedenle YSA'nın lokal minimuma düşmemesi için momentum katsayısına genelde büyük değerler verilir [66].

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + a \Delta A_{jm}^a(t-1)$$

$$\delta_m = f'(NET) E_m \quad (3.6)$$

Burada, $\Delta A_{jm}^a(t)$ ilgili ağırlığın değişim miktarını, a momentum katsayısını, λ öğrenme katsayısını, δ_m ilgili çıktının hatasını, ζ_j^a çıktı değerini ve $\Delta A_{jm}^a(t-1)$ ise bir önceki ağırlık değişim miktarını göstermektedir. Denklemde yer alan f , aktivasyon fonksiyonunu ifade eder. Aktivasyon fonksiyonu olarak sigmoid tercih edilirse aşağıdaki formül (Denklem 3.7) kullanılır.

$$\delta_m = \zeta_m (1 - \zeta_m) \cdot E_m \quad (3.7)$$

Ağırlıkların değişim miktarlarının ne kadar olacağı belirlendikten sonra ağırlıklar (Denklem 3.8) kullanılarak yenilenir.

$$A_{jm}^a = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.8)$$

Burada, A_{jm}^a ilgili ağırlığın yeni değeri, $A_{jm}^a(t-1)$ ise ilgili ağırlığın önceki değerini göstermektedir.

Eşik değerlerinin değişim miktarları belirlendikten sonra eşik değerleri de aşağıdaki denklem grubu kullanılarak (Denklem 3.9) yenilenir.

$$\Delta\beta_m^c(t) = \lambda\delta_m + a\Delta\beta_m^c(t-1)$$

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (3.9)$$

Burada, $\Delta\beta_m^c(t)$ ilgili eşik değerinin değişim miktarını, $\Delta\beta_m^c(t-1)$ bir önceki eşik değerinin değişim miktarını, $\beta_m^c(t)$ ilgili eşik değeri için yeni değeri ve $\beta_m^c(t-1)$ ise ilgili eşik değerine ait önceki değeri ifade etmektedir.

Denklem 3.8 ve Denklem 3.9 formülleri kullanılarak girdilerle gizli katman arasında yer alan ağırlık değerleri de yenilenir. Formülde yer alan çıktılar bu işlem sırasında gizli katmanın çıktı değerlerini ifade etmektedir. Ağırlıkların ne kadar değişeceği ise aşağıdaki denklem seti (Denklem 3.10) ile belirlenir [2].

$$\Delta A_{kj}^i(t) = \lambda\delta_j^a \zeta_k^i + a\Delta A_{kj}^i(t-1)$$

$$\delta_m = f'(NET) \sum_m \delta_m A_{jm}^a$$

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (3.10)$$

Burada, $\Delta A_{kj}^i(t)$ ilgili ağırlığın değişim miktarını, δ_j^a ise hata terimini, ζ_k^i gizli katmandaki ilgili nöronun çıktı değerini, $\Delta A_{kj}^i(t-1)$ ise ilgili ağırlığın önceki değerini göstermektedir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu seçilirse hata değeri Denklem 3.10'daki üçüncü denklem ile hesaplanır.

Geri yayılım algoritması yukarıdaki kısımda anlaşılacağı üzere lokal minimuma takılma, eğitim verilerini ezberleme gibi birçok olumsuzluklarla karşılaşılmasına sebep olabilir. Bu olumsuzluklar gerçekleştiğinde ise optimum çözümden oldukça uzaklaşmış olur.

BÖLÜM 4. GENETİK ALGORİTMALAR

Genetik algoritma (GA), ilk kez 1975 yılında ortaya çıkan bir kavramdır. Tıp alanındaki genetik biliminden esinlenilerek pek çok farklı alandaki problemlerin çözülmesi amaçlanmıştır. Tıpkı genetik biliminde olduğu gibi, kromozom, gen, çaprazlama, mutasyon gibi kavramlar kullanılmaktadır. Matematiksel olarak modellenmesi ve çözümü çok zor olan problemlerin çözümünde etkili ve verimli bir sezgisel yöntemdir. Optimum çözümü bulduğunu garanti edemese de optimuma çok yakın çözümler bulabilmektedir. Rassal bir başlangıç çözümüyle çözüme başlar ve bu sayede optimum çözüme yaklaşık çözümler üretebilir. Başlangıçta rastgele seçilen çözümün üzerinde çaprazlama ve mutasyon işlemleri yaparak her adımda daha iyi bir çözümle devam eder.

Genetik biliminde temel unsur iyilerin hayatta kalıp kötülerin yok olmasıdır. GA'da da bu prensip esas alınarak iyi nesiller oluşturulması ve bu sayede daha iyi çözümlerin elde edilmesi için uğraşmaktadır. Her yeni iterasyonda, bir önceki neslin anne ve baba bireylerinden yeni bireyler oluşturulur. Oluşturulan bu yeni bireyler, anne ve babasının iyi genlerini alabileceği gibi kötü genlerini de alabilmektedir. Ancak GA'da en iyinin hayatına devam edebilmesi amaçlandığı için böyle bireyler uzun süre varlık gösteremezler. En iyinin bulunabilmesi için de GA'da çaprazlama ve mutasyon gibi operatörler kullanılmaktadır [51].

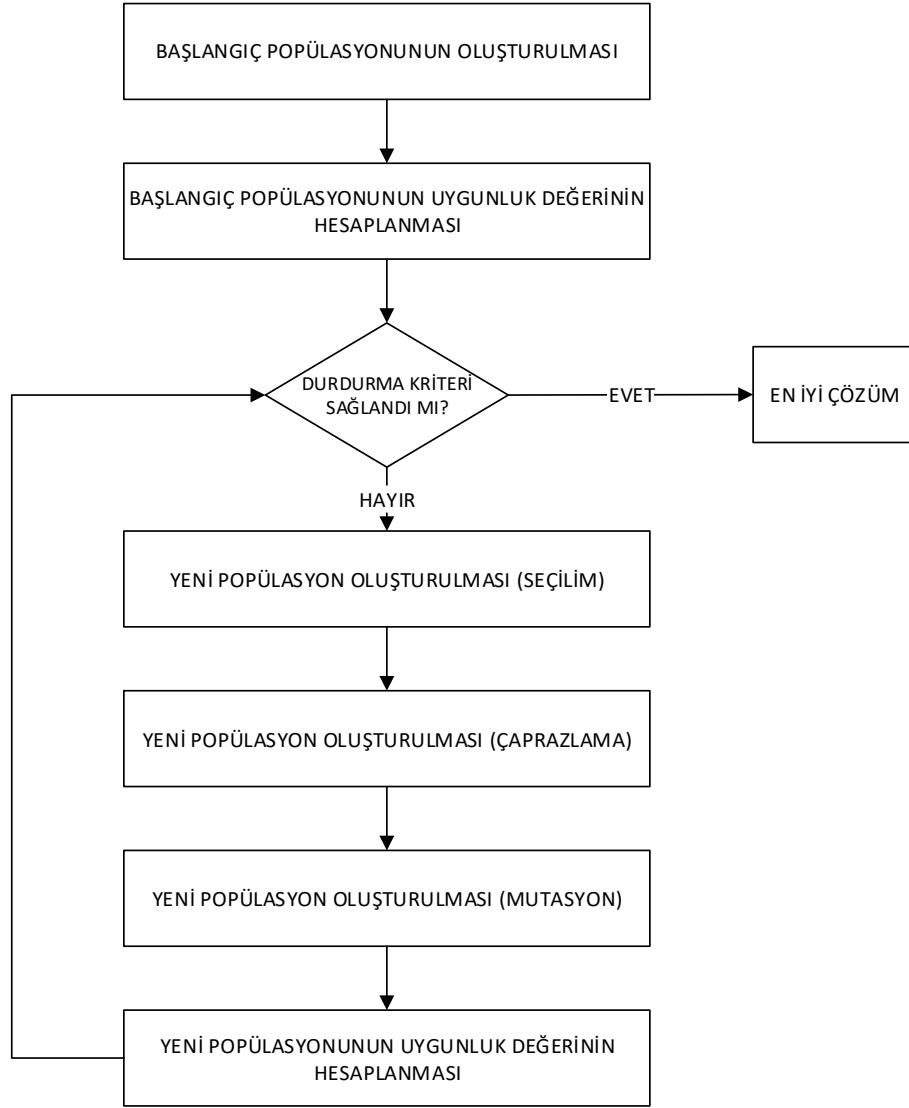
GA'da bir problem ile ilgili parametreler genlerle temsil edilmektedir. Genler bir araya gelerek kromozomları oluşturur. GA'da her bir popülasyon, kromozomlar ile ifade edilmektedir. Amaç fonksiyonu belirli kısıtlar altında optimize edilmeye çalışılmaktadır. Her iterasyonda, genlerin yeri ya da sırası değiştirilerek daha iyi bir kromozom elde edilmeye çalışılır. Her iterasyon, genetik bilimindeki yeni nesil

yaratmaya benzer. Her yeni nesil, çaprazlama ve mutasyon işlemleri sonucunda hayatta kalanların bir araya getirilmesi ile elde edilmektedir [67].

GA'nın ilk adımı, çözüm aday adayları bireylerden oluşan bir havuzun meydana getirilmesidir. Bu havuz başlangıçta rassal olarak oluşturulmaktadır. Havuzdaki unsurların her birine kromozom, kromozomların her bir elemanına ise gen adı verilmektedir. Herhangi bir problemin ifade ediliş biçimi, çözümün uzun ya da kısalığı, çözümün başarı oranı gibi sonuçlar başlangıçtaki kromozomların nasıl tasarlandığı ile doğrudan ilişkilidir [46].

Genetik Algoritma, sezgisel bir optimizasyon yöntemidir. Çözüm uzayındaki tüm noktaları denediğinden dolayı, optimum çözüme ulaşamayabilir. Genetik algoritmaların buna rağmen bu kadar tercih edilmesinin sebeplerinden biri ise pek çok yöntemle göre çok kısa bir sürede optimuma çok yakın sonuçlar üretebilmesidir. Ayrıca değişen şartlara adaptasyonu çok yüksektir ve bu sayede daha önceden bir bilgisinin olmadığı olaylara ait bilgileri toplayıp öğrenebilir [68].

GA'da ilk olarak bir başlangıç popülasyonu belirlenir. Problemin amacına göre oluşturulmuş uygunluk fonksiyonu üzerinden mevcut popülasyonun her bireyi için uygunluk değeri hesaplanır. Bu uygunluk değerlerinden biri, önceden belirlenen durdurma kriterini sağlıyorsa en iyi çözümdür. Aksi halde, yeni bir popülasyon oluşturulması gerekir. Mevcut popülasyonun iyi bireyleri bir sonraki nesile aktarılır. Daha sonra, daha fazla çeşitlilik amacıyla çaprazlama ve mutasyon operatörleri kullanılır. Ardından, yeni popülasyonun uygunluk değerleri hesaplanır. Bu döngü durdurma kriteri sağlanıncaya kadar devam eder. Durdurma kriteri, belirli bir nesil sayısına ya da uygunluk değerine ulaşılması gibi kriterler olabilir ve karar verici tarafından belirlenir. Genetik algoritmanın işleyişi Şekil 4.1.'de gösterildiği gibidir.



Şekil 4.1. Genetik algoritma akış diyagramı

4.1. GA'nın Avantajları

GA, çok değişkenli optimizasyon gibi modellenmesi çok zor problemlerin çözümünde sıklıkla kullanılan bir yöntemdir [69]. Başlangıçta rassal olarak seçilmiş bir popülasyonla yani içerisinde birden fazla çözüm içeren bir kümeyle arama yapmaya başlar. Bu avantajı sayesinde, klasik optimizasyon yöntemlerine benzememektedir. Başlangıç aramasının ardından, seçilim, çaprazlama ve mutasyon gibi operatörleri kullanarak optimum çözüme ulaşmayı amaçlar [70].

Genetik Algoritmaların en önemli avantajlarından birisi, pek çok çözüm içeren bir uzay içerisinde arama yaparak en iyi çözümü seçebilmesidir [71]. Genel olarak GA'nın avantajları aşağıdaki gibidir [72]:

- Parametre optimizasyonuna imkân verir.
- Türev ya da integral gibi karmaşık matematik bilgileri gerektirmez.
- Maliyet fonksiyonu araştırmasında çeşitlilik sunar.
- Çok sayıda parametre ile çalışabilir.
- Aynı anda farklı bilgisayarlar üzerinden çalıştırılabilir.
- Yerel minimum ya da yerel maksimuma düşmeden karmaşık pek çok problemin optimum ya da optimuma yakın çözümünü bulabilir.
- Her zaman tek bir çözüm bulmayabilir. Bazı durumlarda birden fazla parametrenin çözümlerini de bulmaya olanak sağlar.

4.2. GA'nın Geleneksel Yöntemlerden Farkları

Goldberg'e göre, GA'nın diğer geleneksel yöntemlerden farkları şöyle sıralanabilir [70]:

- GA, problem parametrelerinin kendisiyle değil, kodlanış biçimiyle ilgilenmektedir.
- Tek bir yerden arama yapmak yerine bir uzay içerisinde arama yapar.
- Ne yaptığı ile ilgili bilgiler sunmamasına rağmen nasıl yaptığını bilmesinden ötürü bir kör arama yöntemi olarak nitelendirilebilir.
- Bir GA'nın ne kadar verimli çalışacağını önceden bilebilmek mümkün değildir. Ancak olasılık teorisi kullanılarak hesaplanabilmesi mümkündür.

4.3. GA ile İlgili Temel Kavramlar

Genetik algoritma, içerisinde çeşitli kavramlar barındıran sezgisel bir algoritmadır. GA kullanılırken bilinmesi gereken bazı temel kavramlar bulunmaktadır.

4.3.1. Uygunluk fonksiyonu

Uygunluk fonksiyonu, genetik algorithmada problemin yapısına göre deęişiklik gösteren bir fonksiyondur. Bu fonksiyonun doęru tanımlanması, direkt olarak problemin çözüm performansını etkilemektedir. Kromozomların, problemin çözümü açısından ne derece uygun olduklarını göstermektedir [73]. Nesillerin oluşumu aşamasında başvurulmuş önemli bir fonksiyondur. Hangi bireylerin hayatta kalıp hangilerinin eleneceğini bu fonksiyonda aldıkları deęerler belirlemektedir.

4.3.2. Gen

Kromozomun en küçük elemanına gen adı verilir. Genetik algoritmanın bilgi sahibi olan en küçük elemanıdır. Algoritmayı hazırlayan kişinin nasıl tanımlayacağına göre yapısı ve içerięi deęişiklik gösterebilir.

4.3.3. Kromozom

Genlerin bir araya gelmesi ile oluşur. GA ile ilgili çözümün bütün bilgilerini içermektedir. Bu yönüyle GA'nın yapı taşı sayılabilir. Problemin çözümü için doęru tanımlanmış olması son derece önem taşımaktadır. Problemin doęruluęunu direkt olarak etkilemektedir.

4.3.4. Popülasyon

Kromozomların bir araya gelmesi ile oluşur. Bir popülasyonda kaç kromozom olacağı problemi programlayan tarafından istenildięi kadar belirlenebilir. Ancak, popülasyon büyüklüęü GA'nın çalışma performansını etkileyebilir [74]. Genetik algoritma ilerledikçe, popülasyondaki kromozomlar deęişebilir ancak kaç kromozom olduęu deęişmez.

4.3.5. Seçilim

Genetik algoritma iterasyonları sırasında iyi bireylerin seçilerek kötü bireylerin yok olması işlemidir. Bir sonraki nesil için hangi bireylerin kullanılacağı belirlenmektedir. İlk olarak belirlenen oranda elitizm yapılarak popülasyonda yer alan iyi bireyler yeni topluma aktarılır. Daha sonra çaprazlama işleminin gerçekleşeceği kromozomları belirlemek için seçim işlemi gerçekleştirilir. Seçim işlemi rulet tekniği, oran (rank) tekniği, turnuva tekniği gibi pek çok farklı şekilde gerçekleştirilebilir. Bu tekniklerin tamamında iyi bireylerin bir sonraki nesle aktarılması olasılığının artırılması amaçlanmaktadır.

4.3.5.1. Rulet tekniği

Bu teknikte her birey, uygunluk fonksiyonu değerine göre pasta grafiğinden bir dilime sahip olmaktadır. Uygunluk değeri iyi olan bireyin grafikteki dilimi de büyüktür. Dolayısıyla, iyi uygunluk değerine sahip bireylerin seçilme olasılığı daha yüksek olmaktadır. Bu teknikte, uygunluk değeri kötü olan bireylerin de seçilme ihtimali az da olsa vardır [46].

4.3.5.2. Oran (rank) tekniği

Bu teknikte, N kromozumlu bir popülasyonda en iyi uygunluk değerine sahip bireye N , en kötü bireye ise 1 değeri verilir ve seçim yeni değerlere göre gerçekleştirilir [51].

4.3.5.3. Turnuva tekniği

Bu teknikte, istenen sayıda birey rassal olarak seçilir ve bu bireyler arasından uygunluk değerlerine göre seçim yapılır. En iyi uygunluk değerine sahip birey seçilir ve bu işlem çaprazlanacak diğer bireyin de aynı şekilde belirlenmesi ile tamamlanmış olur. Bu teknikte, uygunluk değeri kötü olan bireylerin seçilme olasılığı yoktur [46].

4.3.6. Çaprazlama

GA'da bir iterasyon sırasında, kromozomlar arasında gerçekleştirilen ve yeni kromozomlar elde edilmesini amaçlayan bir işlemdir. Daha önceki çözümler içerisinden oluşan ve kendisini meydana getiren kromozomlara ait bazı özellikler taşıyan yeni kromozomlar oluşturulur. Çaprazlama ile oluşturulan kromozomlar bir sonraki nesil için daha iyi çözümler elde edilmesine yardımcı olur. Çaprazlamada, kromozomlar arasında gen takası gerçekleştirilmektedir.

4.3.6.1. Tek noktalı çaprazlama

Çaprazlanacak kromozomlar seçildikten sonra, bu kromozomlarda bir çaprazlama noktası belirlenir. Daha sonra, iki kromozomda da bu noktanın sağı ya da solundaki kısımlar takas edilir [75]. Tek noktalı çaprazlamaya örnek olarak Tablo 4.1. incelenebilir.

Tablo 4.1. Tek noktalı çaprazlama

Çaprazlama Öncesi Bireyler	Çaprazlama Sonrası Bireyler
1 0 0 1 1 0 1 0	1 0 0 1 1 0 0 1
1 1 1 0 1 0 0 1	1 1 1 0 1 0 1 0

4.3.6.2. Çift noktalı çaprazlama

Kromozomlar üzerinde iki farklı nokta belirlenerek, bu iki nokta arasında kalan kısımların takas edilmesi ile gerçekleştirilen çaprazlama tekniğidir [75]. Tablo 4.2.'de bu durum gösterilmektedir.

Tablo 4.2. Çift noktalı çaprazlama

Çaprazlama Öncesi Bireyler	Çaprazlama Sonrası Bireyler
1 0 0 1 1 0 1 0	1 0 1 0 1 0 1 0
1 1 1 0 1 0 0 1	1 1 0 1 1 0 0 1

4.3.6.3. Çok noktalı çaprazlama

İkiden daha fazla nokta belirlenerek yapılan çaprazlama tekniğidir [51]. Tablo 4.3.'da çok noktalı çaprazlama ile ilgili bir örnek gösterilmiştir.

Tablo 4.3. Çok noktalı çaprazlama

Çaprazlama Öncesi Bireyler	Çaprazlama Sonrası Bireyler
1 0 0 1 1 0 1 0	1 1 1 1 1 0 0 0
1 1 1 0 1 0 0 1	1 0 0 0 1 0 1 1

4.3.6.4. Rastgele çaprazlama

Kromozomlar arasında rastgele şekilde çaprazlama yapılmasıdır [51]. Örneğin, her hane için yazı-tura atılır ve gelen sonuca göre çaprazlama yapılıp yapılmayacağına karar verilir. Rastgele çaprazlama örneği Tablo 4.4.'te belirtilmiştir.

Tablo 4.4. Rastgele çaprazlama

Çaprazlama Öncesi Bireyler	Çaprazlama Sonrası Bireyler
1 0 0 1 1 0 1 0	1 0 1 0 1 0 0 0
1 1 1 0 1 0 0 1	1 1 0 1 1 0 1 1

4.3.7. Mutasyon

Genetik algoritmada, çaprazlama işleminden sonra mutasyon işlemi gerçekleştirilmektedir. Çaprazlama sonucunda oluşan popülasyonun, gerekli tüm bilgileri içermediği durumlarda mutasyon yeni kromozomlar üretilmesini sağlayarak çaprazlamadan kaynaklanan sorunun giderilmesine yardımcı olur [75]. Popülasyonda çeşitlilik sağlamak ve iyi çözümlerin kaybını önlemek amacıyla mutasyon operatörü kullanılabilir. Ancak mutasyon oranı çok yüksek tutulmamalıdır. Gereğinden yüksek mutasyon oranı, problemin yapısının bozulmasına neden olabilir.

Mutasyon işlemi, kromozomların yapısını değiştirerek genetik algoritmanın en iyi çözümü araması sırasında çözüm havuzunu genişletmektedir [51]. Bu işlem, bazen

algoritmanın daha kötü çözümlere yönlendirilmesine neden olurken bazen de hızlıca çok daha iyi bir çözüme geçilmesini sağlayabilir. Mutasyonda, kromozom üzerindeki mutasyona uğrayacak nokta ya da noktalar farklı şekillerde seçilebilir. 0 ve 1'lerden oluşan bir kromozom yapısında 0 değerini 1 yaparak mutasyon işlemi gerçekleştirilebilir. Problemin yapısı gereği farklı şekillerde kodlanması gereken kromozomlar için ise farklı mutasyon teknikleri kullanılabilir. Tek noktadan mutasyon yapılabileceği gibi birden fazla gen için de mutasyon yapılması mümkündür.

BÖLÜM 5. UYGULAMA

Bu çalışmada yapay sinir ağı genetik algoritma kullanılarak eğitilmiştir. Veri seti olarak elektronik burun ile elde edilen koku verileri kullanılmıştır. Uygulamada elde edilen koku verileri sınıflandırılmaktadır.

YSA'nın eğitilmesi karmaşık bir problemdir. Geleneksel olarak bu problem geri yayılım algoritmasıyla çözülmektedir. Fakat geri yayılım algoritmasıyla çözüldüğünde lokal minimuma takılma veya veri setini ezberleme gibi sorunlar ortaya çıkabilir. O nedenle YSA'nın eğitim kısmında bu sorunları ortadan kaldırabilmek için çoğunlukla sezgisel algoritmalar kullanılmaktadır. Genellikle de sezgisel algoritmalar ile geri yayılım algoritmasına kıyasla daha başarılı sonuçlar elde edilmektedir. Bu çalışmada da YSA'nın eğitim aşamasında sezgisel algoritmalarından biri olan genetik algoritma kullanılmıştır. YSA'nın eğitim kısmında genetik algoritmanın kullanılmasındaki amaç ise optimuma daha yakın sonuçlar elde etmektir.

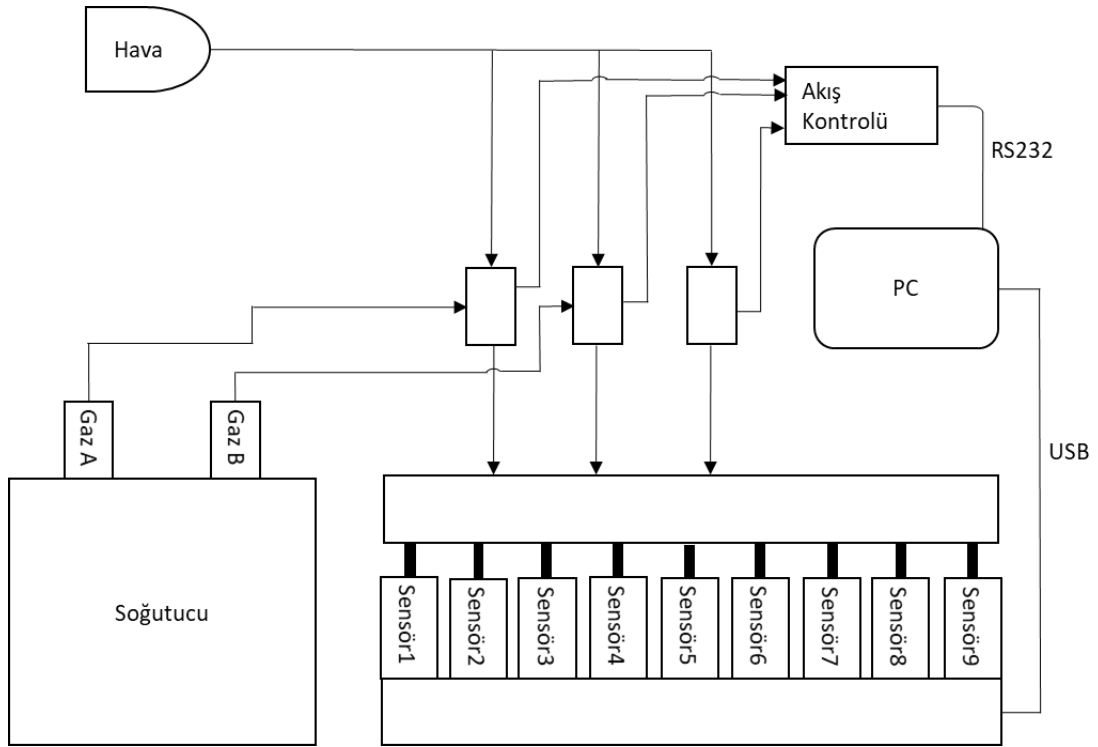
5.1. Veri Setinin Oluşturulması

Uygulamada koku verileri kullanılarak sınıflandırma yapılmıştır. Dış ortamdan koku verileri elektronik burun aracılığı ile alınmıştır. Dış ortamdaki kokunun algılanması ise elektronik burunda yer alan gaz sensör sistemi ile sağlanmıştır.

5.2. Gaz Sensör Sistemi

Bir QCM (Quartz Crystal Microbalance), metal elektrotları her iki yüzeye yerleştirilmiş ince bir dilim kuvars kristali içeren elektromekanik bir osilatördür (elektromanyetik dalgalar yayan bir cihaz). Analitik ile ilişkili olarak, QCM elektrotlarına yerleştirilen kimyasal duyarlı bir malzeme, Sauerbrey denkleminde

verilen adsorbe edilmiş kütleye karşılık gelen salınımda bir frekans düşüşü oluşturur. Bu çalışmada QCM sensörleri kullanılmıştır, çünkü kalibrasyon gerektirmeyen ve kompleks karışımların ayırımı için güvenilir sistemlerin gereksinimlerini karşılamak için büyük yeteneğe sahiptir. İkili gaz karışımlarının ölçümlerini yapmak için Dokuz QCM sensörlü bir ölçüm sistemi kullanılmıştır. Yüksek algılama oranına ulaşmak için, sistem, sensör dizisi ile birleştirilmelidir.



Şekil 5.1. Gaz sensör sistemi

Tablo 5.1. Sensörlere ait detaylar


Sensör	Kod	Materyal ismi
Sensör1	Kırmızı	Faber Castell S
Sensör2	316	03 - 302
Sensör3	318	03 - 502
Sensör4	Siyah	Schneider OHP S PERMANENT 220
Sensör5	Lacivert	Schneider OHP S PERMANENT 224
Sensör6	Yeşil	Faber Castell S
Sensör7	326	03 - 602
Sensör8	328	00 - 300
Sensör9	330	00 - 200

Şekil 5.1.'de gösterilen ölçüm sistemi, tek gazların ikili gaz karışımları oluşturmak üzere karıştırılmasını sağlayan bir akış kontrol cihazına sahiptir. Sistem tarafından belirli miktarlarda A ve B gazlarının karıştırılmasından sonra, ikili gazın sensörlere

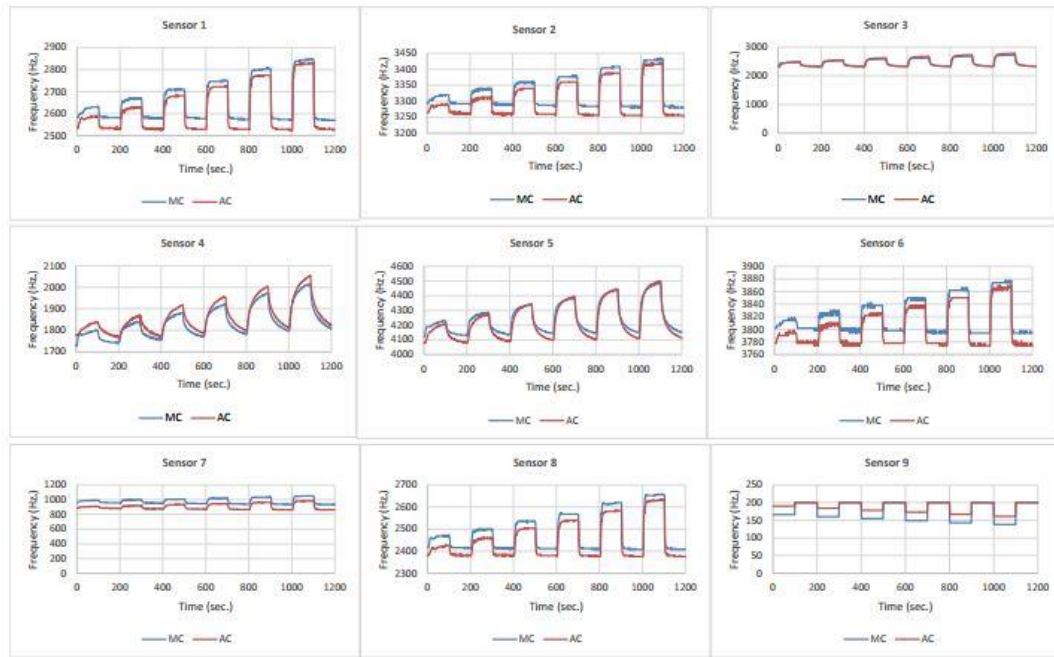
taşıması için saf hava, borulardan beslenir. Bu gaz karışımının sensörlerinin algılanışı bilgisayarlar tarafından kaydedilir. A ve B gazları, bir soğutucu yardımıyla herhangi bir istenen sıcaklıkta sensörlere aktarılabilir.

5.3. Deneysel Ölçümler

Şekil 5.1.'de gösterilen cihaz, belirli konsantrasyonlarda aseton, metanol ve kloroformun ikili gaz karışımlarını sağlamak için kullanılır ve sensörler, ilgili verileri toplamak için kullanılır. İkili gaz karışımları sensör dizisine verildiğinde, her sensör, 8 sensör için 22 kHz, 1 sensör için 23 kHz (S4) olan temel rezonans frekansına kaydırarak benzersiz bir şekilde cevap verir. Farklı kompozitlerle kaplanmış sensörler göz önüne alındığında, her sensörün farklı bir davranışı vardır, bu nedenle bir gaz karışımına tepkiler farklı olacaktır. Temel frekansa olan mesafeler hesaba katılır. QCM sensör dizilimindeki kompozit malzemeler Tablo 5.1.'de verilmektedir. Kütle ve sıvının yoğunluğunda ve kalınlığında meydana gelen değişiklikler de ölçülen rezonans frekansını etkiler, bu nedenle tüm sensörlerin baz rezonans frekansını sabit tutmak güvenilir ölçümler almak için önemlidir. Her bir karışımdaki gaz konsantrasyonlarını elde etmek için bir gazın konsantrasyonu, diğer gazın konsantrasyonunu sabit tutulurken 1000 ppm'den 6000 ppm'e kadar 1000 ppm'er artırılarak değiştirilir (Şekil 5.2.). 1000 ppm artışlarla 1000 ppm'den 6000 ppm'e çıkan değerler, her iterasyonda sabit olarak alınır. İkili gaz karışımı, -15°C cam tüp içerisinde tutulur ve ölçümler 200 saniye sürer. Bu periyotun 100 saniyesinde gaz karışımı sensörlere beslenirken, son 100 saniyede sensörler saf hava ile temizlenir.



Şekil 5.2. İkili gazların karışım oranları



Şekil 5.3. Sensörlerin MC ve AC ikili gaz karışımlarına verdikleri tepki

Gaz sensör sisteminde bulunan dokuz adet sensörün karışımlara verdikleri tepki Şekil 5.3.'te gösterilmiştir. Uygulama için elde edilen veri setinin bir kısmı ise Şekil 5.4.'te gösterilmiştir.

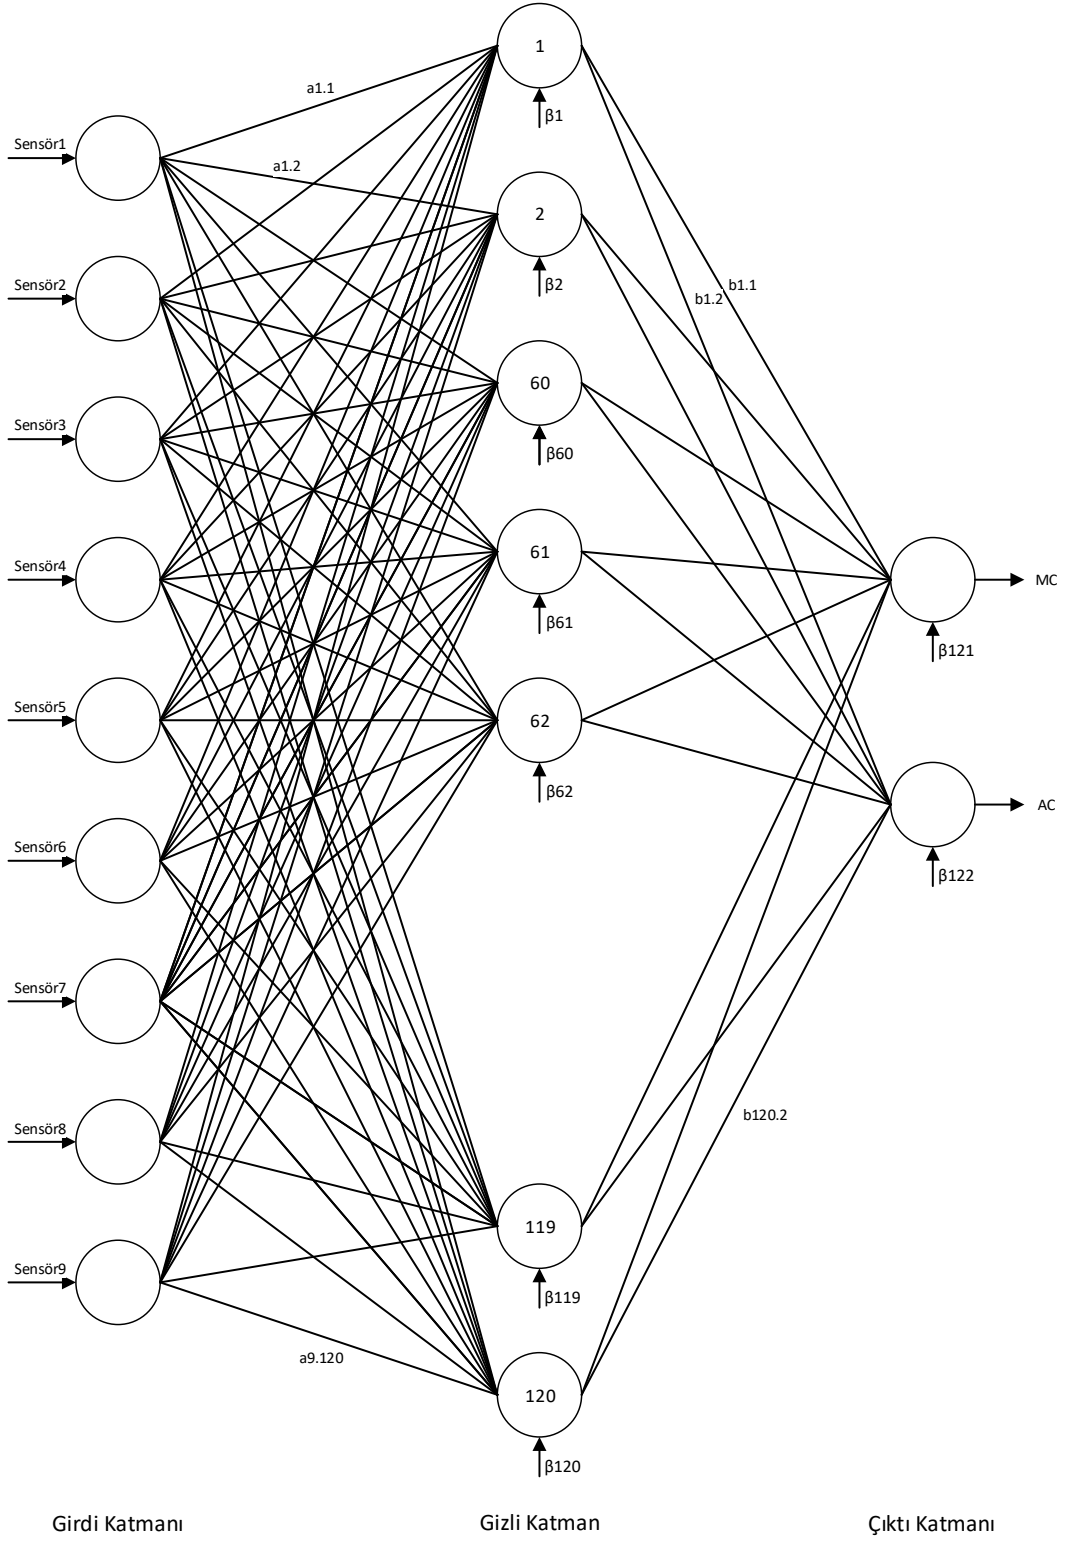
Sensor1	Sensor2	Sensor3	Sensor4	Sensor5	Sensor6	Sensor7	Sensor8	Sensor9	AC	MC
2586	3288	2478	1836	4204	3794	906	2424	190	1	0
2634	3320	2478	1800	4228	3818	990	2472	166	0	1
2630	3312	2550	1864	4268	3810	918	2460	184	1	0
2670	3340	2530	1840	4288	3830	998	2500	160	0	1
2682	3340	2626	1916	4340	3826	934	2504	178	1	0
2714	3360	2578	1880	4336	3842	1010	2536	155	0	1

Şekil 5.4. Elektronik burun ile elde edilen veri seti örneği

AC, Kloroform gazının sabit olduğu, aseton gazının sabit aralıklarla arttırıldığı durumdaki ikili gaz karışımı ile bulunan veriye verilen sınıf adıdır. MC ise kloroform gazının sabit olduğu, metanol gazının ise sabit aralıklarla arttırıldığı durumdaki ikili gaz karışımı ile bulunan veriye verilen sınıfın adıdır [76]. Bu sensörler, Türkiye'de Kocaeli'nin Gebze ilçesinde bulunan Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) laboratuvar ortamında geliştirilmektedir. Sensörlerin teknik detayları Tablo 5.1.'de verilmektedir.

5.4. Kullanılan YSA Modelinin Yapısı

Koku verilerinin elde edilmesinde kullanılan elektronik burunda yer alan gaz sensör sistemindeki sensör sayısı dokuz olduğundan uygulamada kullanılmak için tasarlanan YSA modelindeki girdi sayısı da dokuzdur. Daha iyi sonuç elde etmek için birbirinden farklı yedi YSA modeli tasarlanmıştır. Hangisinin daha iyi sonuçlar verdiği test edilerek en iyi sonucu veren YSA modeli seçilmiştir. Seçilen YSA modeli Şekil 5.5.'te gösterilmiştir. Bu YSA modelinde bir girdi katmanı, bir gizli katman ve birde çıktı katmanı yer almaktadır. Gizli katmandaki nöron sayısı 120 adettir. Uygulamada kullanılan koku verilerini sınıflandırma yaparken 2 adet sınıf olduğundan çıktı katmanında da çıktı sayısı iki adettir. YSA'ya verilen verinin hangi sınıfa ait olduğu ilgili sınıfa ait çıktının 1, diğer sınıfa ait çıktının ise 0 olduğu durumla anlaşılmaktadır [76].



Şekil 5.5. Uygulamada kullanılan YSA Yapısı

5.5. Kromozom Yapısı

Uygulamadaki kromozom yapısı Şekil 5.6.'da gösterilmiştir. Kromozomda yer alan genlerde, YSA'daki ağırlık değerleri ve β değerleri bulunmaktadır. Şekil 5.6.'da gösterilen kromozomda yer alan a2.1, YSA'nın ikinci girdisi ile ara katmandaki birinci nöron arasındaki ağırlık değerini ifade etmektedir. β_1 ise ara katmanda yer alan birinci nörona ait β değerini ifade etmektedir.

a1.1	a2.1	...	a9.1	β_1	...	a1.120	a2.120	...	a9.120	β_{120}	b1.1	b2.1	...	b120.1	β_{121}	b1.2	b2.2	...	b120.2	β_{122}
------	------	-----	------	-----------	-----	--------	--------	-----	--------	---------------	------	------	-----	--------	---------------	------	------	-----	--------	---------------

Şekil 5.6. Kromozom yapısı

5.6. Uygulamada Kullanılan Yazılım

Uygulama için C # programlama dili kullanılarak bir yazılım geliştirilmiştir. Yazılımın açılış ekranı Şekil 5.7.'de gösterilmiştir. Yazılımda genetik algoritma sekmesinde kromozom sayısı, iterasyon sayısı, çaprazlama oranı, mutasyon oranı, seçkincilik oranı ve seçim türü; yapay sinir ağı sekmesinde ise uygulamada kullanılacak veri setinin girdi sayısı ve çıktı sayısı, eğitim seti oranı, YSA'nın gizli katmandaki nöron sayısı, YSA'da yer alan ağırlıkların minimum ve maksimum değerleri ile YSA'da yer alan eşik değerlerinin minimum ve maksimum değerleri kullanıcıdan alınır.

Gerekli parametreler girildikten sonra YSA'nın genetik algoritma ile eğitimi sonucu ağırlıkları bulabilmek için yazılımın ana ekranında ki ağırlıkları bul butonuna basılır. Yazılım arka tarafta YSA'nın genetik ile eğitimini tamamladıktan sonra en iyi kromozomu yani en düşük hata oranına sahip kromozomu ve ona ait hata oranını ara yüzdeki Sonuçlar kısmına yazdırır.

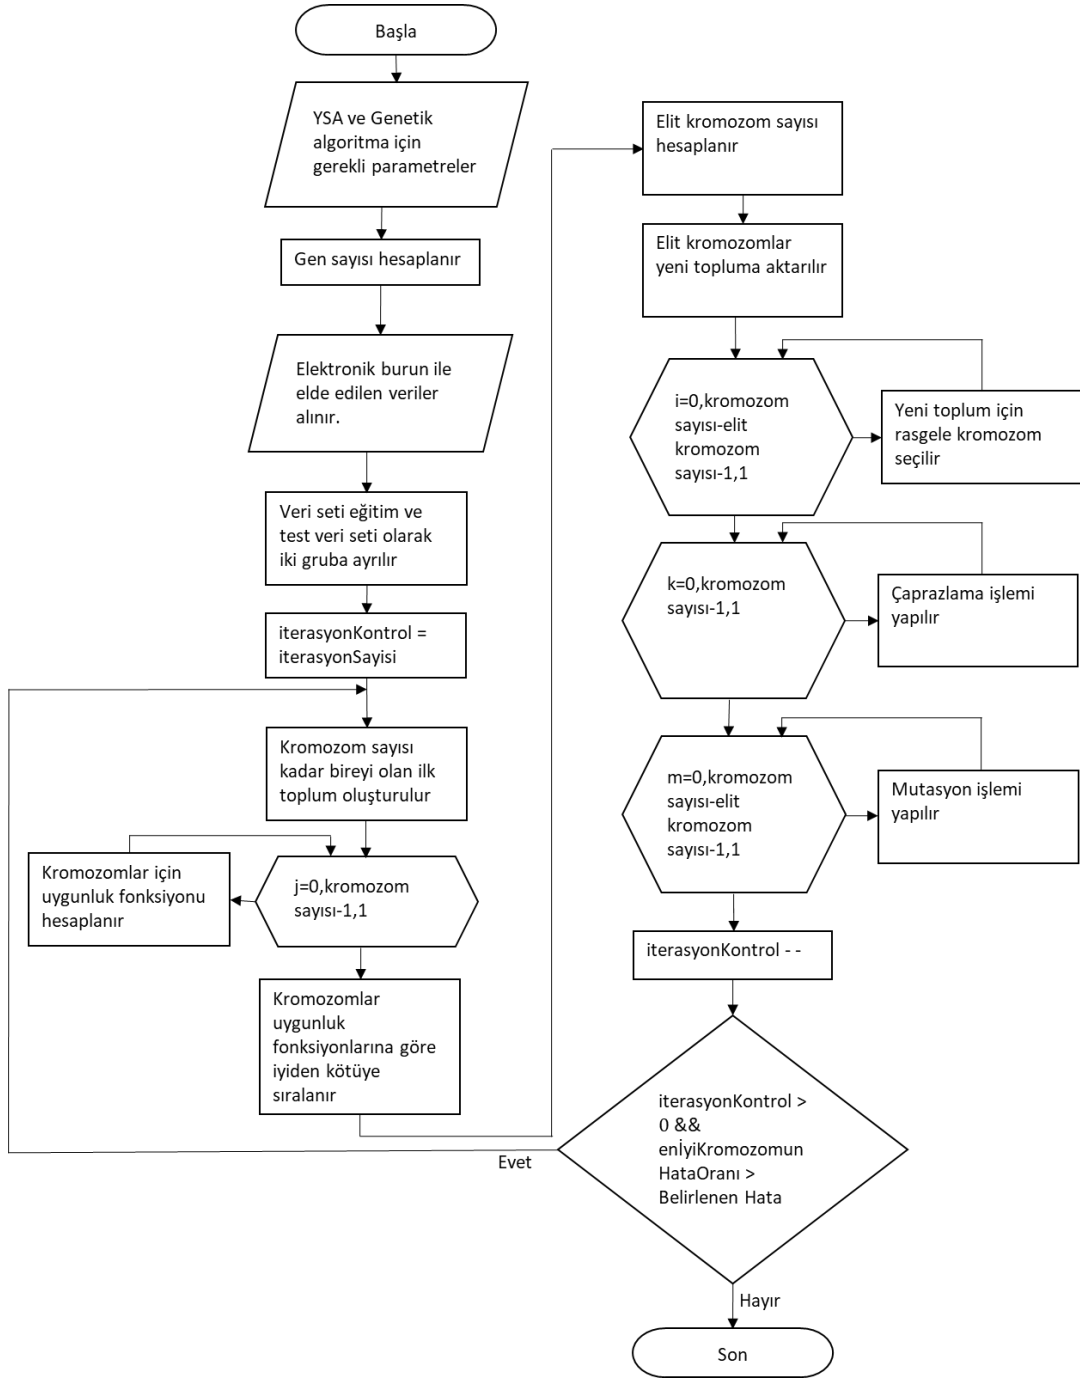
Grafikler butonuna basıldığında iterasyon-MSE grafiği ile belirlenen ağırlıklar için test verilerinin başarı grafiği gösterilmektedir.

Test Veri Sonuçlarını Excele Aktar butonuna basıldığında ise belirlenen ağırlıklar kullanılarak YSA'ya test verileri verildiğinde elde edilen çıktılar MS Office Excel'e yazdırılır.

Şekil 5.7. Uygulama ana ekranı

5.7. Uygulamada Kullanılan Yazılımın Süreçleri

Uygulamada kullanılan yazılımın nasıl çalıştığına dair süreç, Şekil 5.8.'de adım adım detaylı bir biçimde gösterilmiştir.



Şekil 5.8. Yazılımın akış şeması

Birinci adımda YSA ve GA için gerekli parametreler ana ekran ile kullanıcıdan alınır.

YSA için gerekli parametreler;

- Girdi sayısı,
- Çıktı sayısı,

- Eğitim seti oranı,
- Ara katmandaki nöron sayısı,
- Ağırlıkların alabileceği minimum değer,
- Ağırlıkların alabileceği maximum değer,
- Eşik değerinin alabileceği minimum değer,
- Eşik değerinin alabileceği maximum değer.

GA için gerekli parametreler;

- Kromozom sayısı,
- İterasyon sayısı,
- Çaprazlama oranı,
- Mutasyon oranı,
- Seçkincilik oranı,
- Seçilim türü.

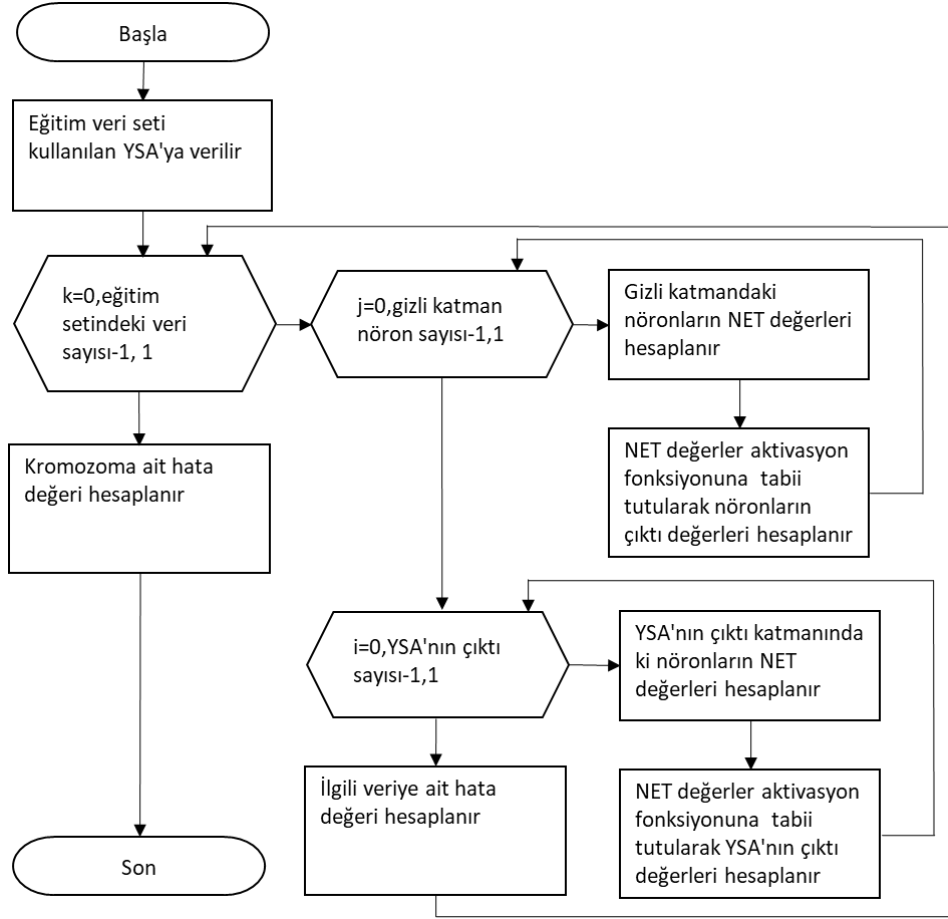
İkinci adımda gen sayısı hesaplanmaktadır. Gen sayısı aşağıdaki formül (Denklem 5.1) yardımıyla hesaplanır.

$$\begin{aligned} \text{Gen sayısı} = & \text{Girdi sayısı} * \text{ara katmandaki nöron sayısı} + \\ & \text{ara katmandaki nöron sayısı} + \text{çıktı sayısı} * \\ & \text{ara katmandaki nöron sayısı} + \text{çıktı sayısı} \end{aligned} \quad (5.1)$$

$$\text{Gen sayısı} = 9*120+120+2*120+2=1442 \text{ gen}$$

Üçüncü adımda elektronik burun ile elde edilen koku verileri uygulamaya alınır. Alınan koku verileri eğitim veri seti ve test veri seti olarak ayarlanır. Dördüncü adımda kullanıcının ana ekrandan girdiği kromozom sayısı kadar kromozom üretilir. Yani toplum oluşturulur. Bir kromozom için, hesaplanan gen sayısı kadar rasgele sayı üretilir. Rasgele sayı üretilirken üretilen sayının, ağırlıklar ve eşik değer için ana ekrandan alınan sınırlar aralığında olmasına dikkat edilir. Bu işlem istenilen kromozom sayısı kadar tekrar edilir.

Beşinci adımda, Oluşturulan kromozomların her biri için uygunluk fonksiyonu değeri hesaplanır. Akış şeması Şekil 5.9.'da gösterilmiştir.



Şekil 5.9. Kromozomların uygunluk fonksiyonlarının hesabı

Uygulamadaki uygunluk fonksiyonu YSA'ya koku verisi verilmesinin ardından ilgili kromozomdaki ağırlık ve eşik değerleri ile işleme girdiğinde oluşan hata oranı olarak belirlenmiştir. Yani kromozomların hangisinin uygunluk fonksiyonu daha düşükse o daha iyi bir kromozom olarak düşünülmektedir. Ara katmandaki tüm nöronlar için net değer ve çıktı değeri aşağıdaki iki formül (Denklem 5.2 ve Denklem 5.3) ile hesaplanır.

$$Net_{ara1} = a_{1.1} * girdi_1 + a_{2.1} * girdi_2 + \dots + a_{9.1} * girdi_9 + \beta_1 \quad (5.2)$$

$$\text{Çıktı}_{ara1} = 1 / (1 + e^{-Net_{ara1}}) \quad (5.3)$$

Burada, Net_{ara1} ara katmandaki 1. nöronun net değerini, $Çıktı_{ara1}$ ise, ara katmandaki 1. Nöronun çıktı değerini ifade etmektedir.

$$Net_{ÇıktıH1} = Çıktı_{ara1} * b_{1.1} + Çıktı_{ara2} * b_{2.1} + \dots + Çıktı_{ara120} * b_{120.1} + \beta_{121} \quad (5.4)$$

$$Çıktı_{h1} = 1 / (1 + e^{-Net_{ÇıktıH1}}) \quad (5.5)$$

Burada, $Net_{ÇıktıH1}$ YSA'nın birinci çıktısına ait hesaplanan net değerini, $Çıktı_{h1}$ ise YSA'nın hesaplanan birinci çıktı değerini ifade etmektedir. Yukarıdaki Denklem 5.4 ve Denklem 5.5 ile YSA'nın tüm çıktı değerleri için net ve çıktı değerleri hesaplanır. Uygulamada kullanılan YSA modelinde 2 çıktı yer aldığından 2 çıktı için net ve çıktı değerleri hesaplanmıştır.

$$Hata_{orn1} = ((Çıktı_{h1} - Çıktı_1)^2 + (Çıktı_{h2} - Çıktı_2)^2) / 2 \quad (5.6)$$

Ardından, Denklem 5.6 yardımıyla, YSA'ya verilen tüm eğitim seti verileri için yukarıdaki hesaplamalar tekrarlanarak her örneğe ait hata oranı hesaplanır. Burada, $Çıktı_1$ olması gereken birinci çıktı değeri yani veri setindeki birinci çıktı değerini, $Hata_{orn1}$ ise YSA'ya verilen eğitim setindeki 1. örnek için hata değerini ifade etmektedir. Toplumda yer alan tüm kromozomlar için bu işlemler tekrarlanarak her kromozoma ait uygunluk fonksiyon değeri yani hata değeri hesaplanır.

Altıncı adımda ise, toplumdaki kromozomlar uygunluk fonksiyonuna göre iyiden kötüye doğru sıralanır. Yani hata değeri küçükten büyüğe olacak şekilde sıralama yapılır. Ardından yedinci adıma geçilir ve seçkincilik işlemi gerçekleştirilir. Kullanıcı tarafından ara yüzden girilen seçkincilik oranı ile kromozom sayısı çarpılarak çıkan değer kadar kromozom uygunluk fonksiyonuna göre sıralanmış olan kromozomlardan yeni topluma hiçbir işleme girmeden aktarılır. Böylece iyi kromozomların kaybedilmeden bir sonraki nesle aktarımı sağlanmış olur. Ayrıca genetik operatörler yardımıyla elit kromozomlardan daha iyi çocuk kromozomlar elde edilmesinin yolu açılmış olur. Aktarılan elit kromozom sayısı aşağıdaki formül (Denklem 5.7) ile belirlenir.

Yeni topluma aktarılan elit kromozom sayısı = Toplumdaki kromozom sayısı * seçkincilik oranı (5.7)

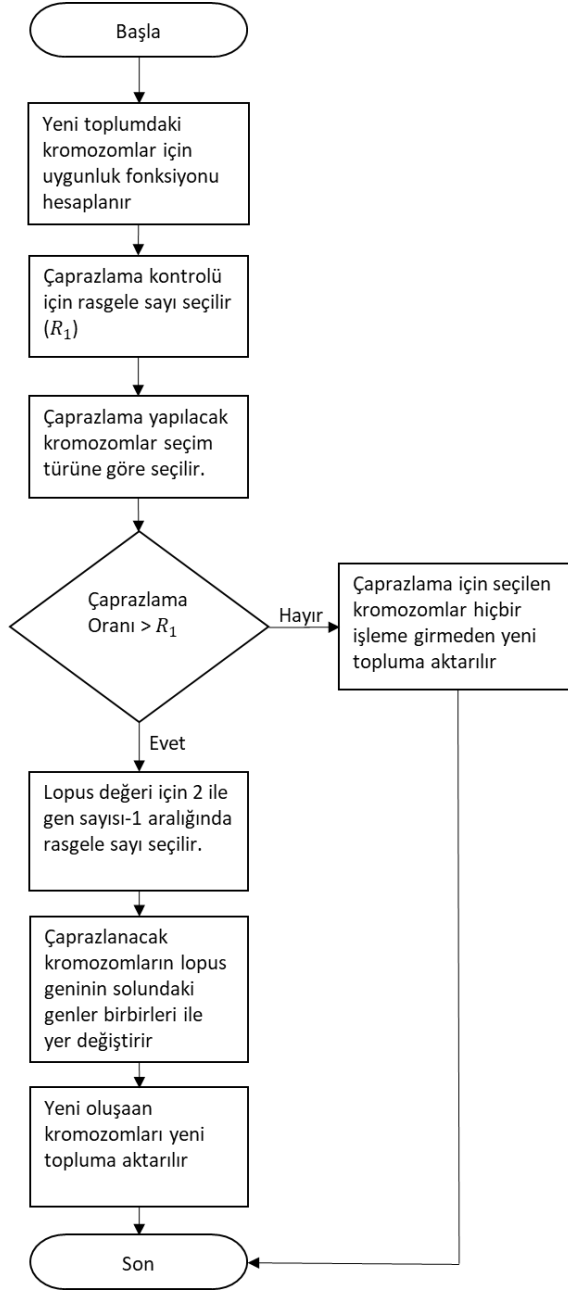
Örneğin, kromozom sayısı 1000 ve seçkincilik oranı 0.1 olursa; yeni topluma aktarılan elit kromozom sayısı $1000 * 0.1 = 100$ kromozom olur.

Sekizinci adımda, toplumda yer alan kromozomlardan rasgele seçilerek yeni toplum oluşturulur. Bir ile kromozom sayısı arasında rasgele sayı seçilir. Toplumda yer alan o numaralı kromozom yeni topluma aktarılır. Yalnız oluşturulan ilk toplumdaki kromozom sırasına bakılarak seçilir. Yani uygunluk fonksiyonuna göre sıralanmış kromozomlar bu işlemde dikkate alınmaz. Yeni toplum için seçilecek kromozom sayısı aşağıdaki formül (Denklem 5.8) yardımıyla belirlenir.

Yeni topluma aktarmak için seçilecek kromozom sayısı =
Toplumda yer alan kromozom sayısı – elit kromozom sayısı (5.8)

Örneğin, kromozom sayısı 1000 ve seçkincilik oranı 0.1 olursa; yeni topluma aktarılan elit kromozom sayısı $1000 * 0.1 = 100$ kromozom olur. Yeni topluma aktarmak için seçilecek kromozom sayısı ise $1000 - 100 = 900$ olur. Yani bu işlem 900 kere tekrarlanır.

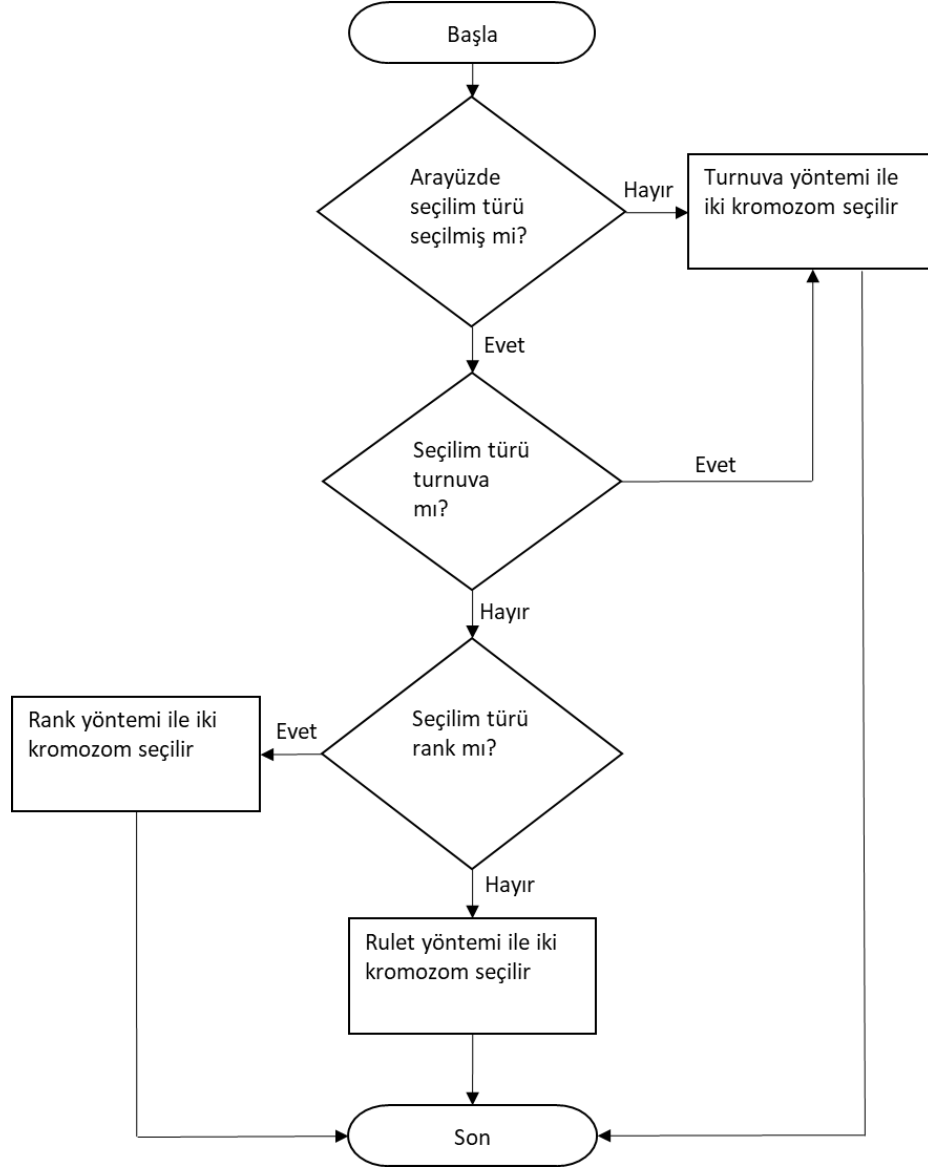
Dokuzuncu adımda, çaprazlama işlemi yapılır. Çaprazlama işlemi uygulamada tek noktalı çaprazlama yöntemine göre gerçekleştirilmiştir. Akış şeması Şekil 5.10.'da gösterilmiştir.



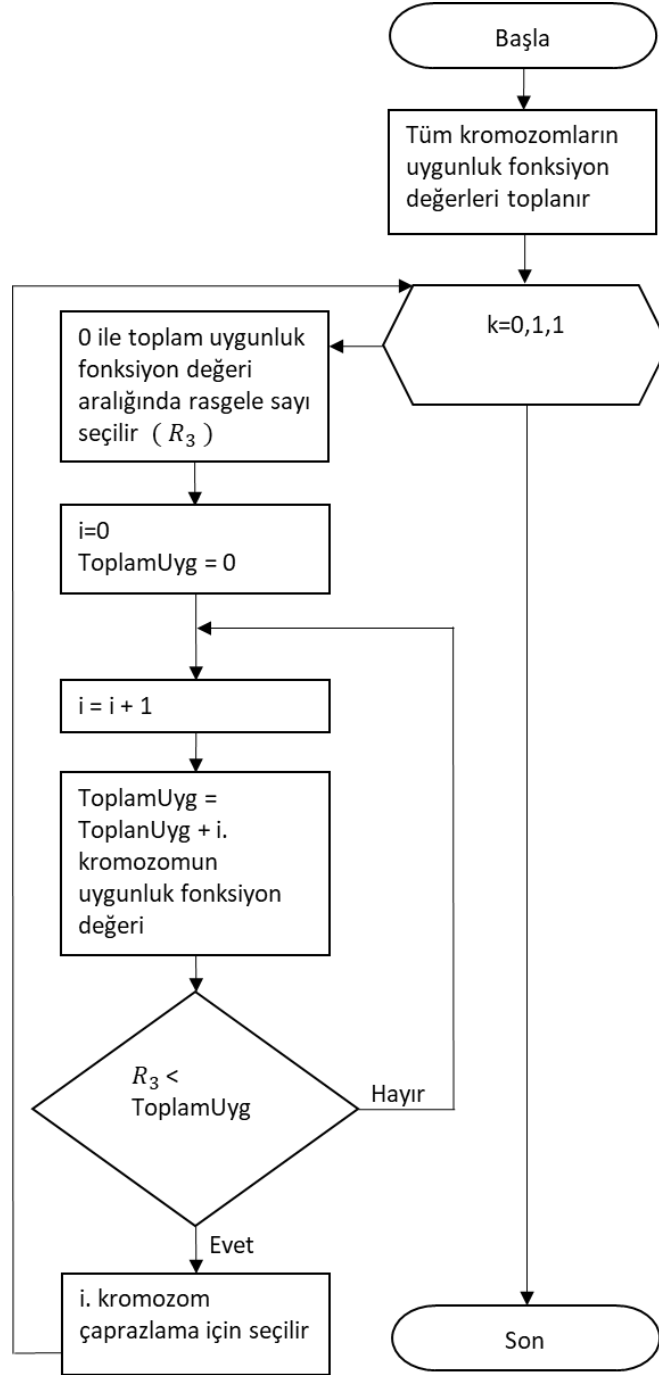
Şekil 5.10. Çaprazlama akış şeması

Şekil 5.10.'da görüleceği üzere önce yeni toplumda yer alan kromozomların uygunluk fonksiyonları hesaplanır. Daha sonra, çaprazlama işleminin olup olmayacağını belirlemek amacıyla sıfır ile bir arasında olacak şekilde rasgele bir sayı seçilir. Ardından, kullanıcının ana ekrandan girdiği seçim türüne göre çaprazlama işlemine girecek olan kromozomlar seçilir. Kullanıcı tarafından seçim türü rank olarak seçilirse seçim rank yöntemine göre, rulet seçilirse rulet yöntemine göre, turnuva seçilirse ya da seçim türü ile ilgili bir seçim yapılmazsa turnuva yöntemine göre seçim yapılmaktadır. Seçilime ait akış şeması Şekil 5.11.'de gösterilmiştir. Rulet

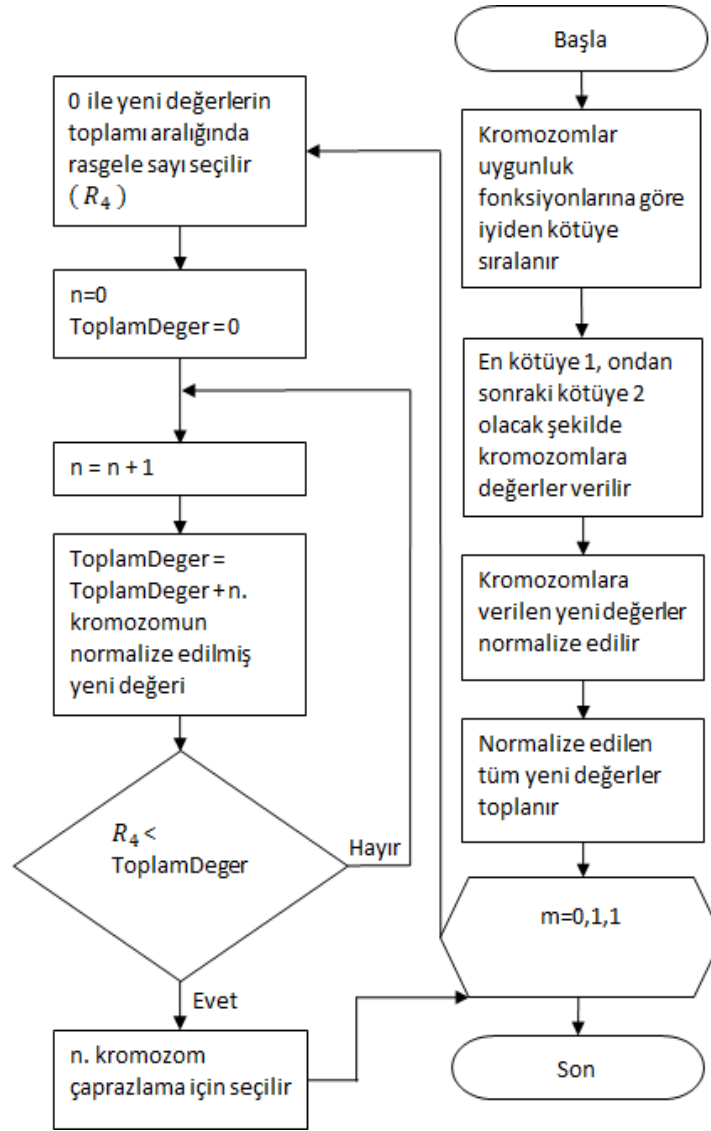
yöntemi Şekil 5.12.'de, rank yöntemi ise Şekil 5.13.'te gösterilmiştir. Turnuva yöntemine ait akış şeması ise Şekil 5.14'te gösterilmiştir.



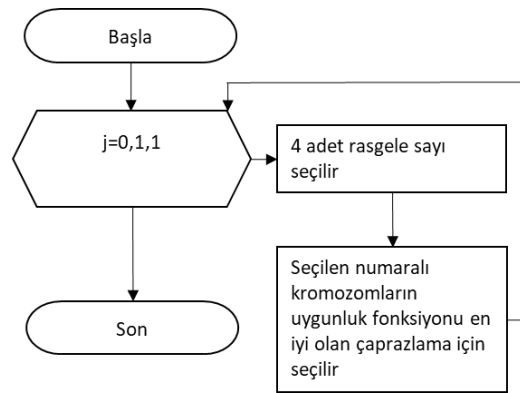
Şekil 5.11. Seçilim akış şeması



Şekil 5.12. Rulet tekniği akış şeması



Şekil 5.13. Rank yöntemi akış şeması



Şekil 5.14. Turnuva tekniği akış şeması

Eğer, kullanıcı seçim türünü belirtmediyse turnuva yöntemine göre seçim yapılır. Turnuva yönteminde ise 4 adet rasgele sayı seçilir. Toplumda yer alan o numaralı kromozomların uygunluk fonksiyonlarına göre hangisi en iyi ise o çaprazlama işlemine girecek olan birinci kromozom olarak seçilir. Bu işlem ikinci kez tekrarlanarak çaprazlama işlemine girecek olan ikinci kromozom seçilir. Seçim işlemi tamamlandıktan sonra, seçilen kromozomların 300. ve 800. kromozom oldukları varsayılırsa çaprazlama işlemi bu iki kromozom arasında gerçekleşecek demektir (Şekil 5.15.).

Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{300.1.1}$	$a_{300.2.1}$	$a_{300.3.1}$	$a_{300.4.1}$	$a_{300.5.1}$...	$\beta_{300.122}$

Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{800.1.1}$	$a_{800.2.1}$	$a_{800.3.1}$	$a_{800.4.1}$	$a_{800.5.1}$...	$\beta_{800.122}$

Şekil 5.15. Çaprazlama işlemi için seçilen 300. ve 800. kromozomlar

Lopus değerini belirlemek için yani kromozomlarda çaprazlama işleminin hangi genden olacağını belirlemek için 2 ile gen sayısı-1 arasında olacak şekilde rasgele bir sayı seçilir. Çaprazlama işlemine girecek olan kromozomlar, o numaralı genden çaprazlama işlemine tabi tutulur. Örneğin, gen sayısı 1442 olduğuna göre; rasgele seçilen sayı ise 4 olarak varsayılırsa Lopus seçiminin nasıl olacağı Şekil 5.16.'da gösterilmiştir.

Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{1.1}$	$a_{2.1}$	$a_{3.1}$	$a_{4.1}$	$a_{5.1}$...	β_{122}

Lopus

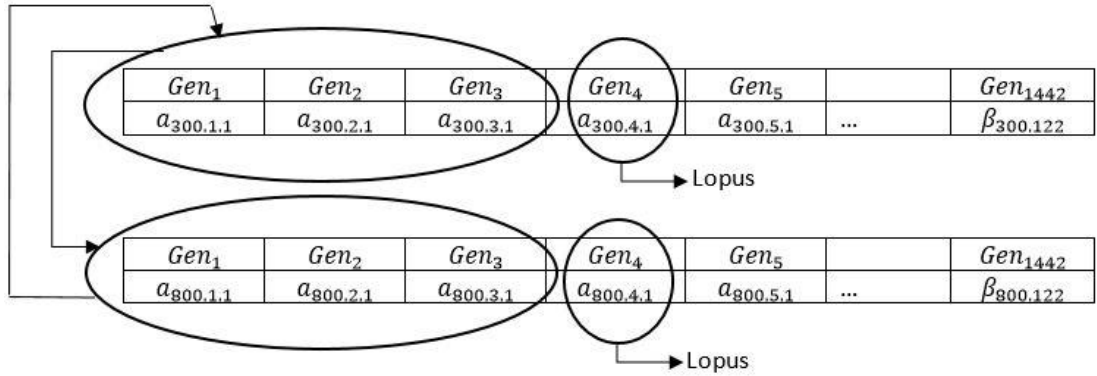
Şekil 5.16. Lopus seçimi

Onuncu adımda daha önce seçilen rasgele sayı ile kullanıcının ana ekrandan girdiği çaprazlama oranı karşılaştırılır. Eğer çaprazlama oranı rasgele seçilen sayıdan büyükse çaprazlama işlemi gerçekleştirilip elde edilen yeni iki çocuk kromozom yeni topluma

aktarılır. Eğer çaprazlama oranı rasgele seçilen sayıdan küçükse çaprazlama için seçilen iki kromozom çaprazlama olmadan yeni topluma aktarılır.

Örneğin, çaprazlama oranının 0,85 ve rasgele seçilen sayının 0,4 olduğu varsayılırsa; $0,85 > 0,4$ olduğundan Şekil 5.15.'te yer alan kromozomlar arasında çaprazlama gerçekleşir. Şekil 5.17.'de gösterildiği gibi birinci kromozomun lopus geninin solunda kalan genler ikinci kromozoma geçerken, ikinci kromozomun lopus geninin solunda kalan kısım ise birinci kromozoma geçer. Sonuçta yeni kromozomlar oluşur (Şekil 5.18.).

$a_{300.2.1}$ = Üç yüzüncü kromozomun ikinci gen değeridir. Yani YSA'da yer alan ikinci giriş verisi ile ara katmanda yer alan birinci nöron arasındaki bağlantıya ait ağırlığın üç yüzüncü kromozomdaki değeridir.



Şekil 5.17. Çaprazlama işlemi

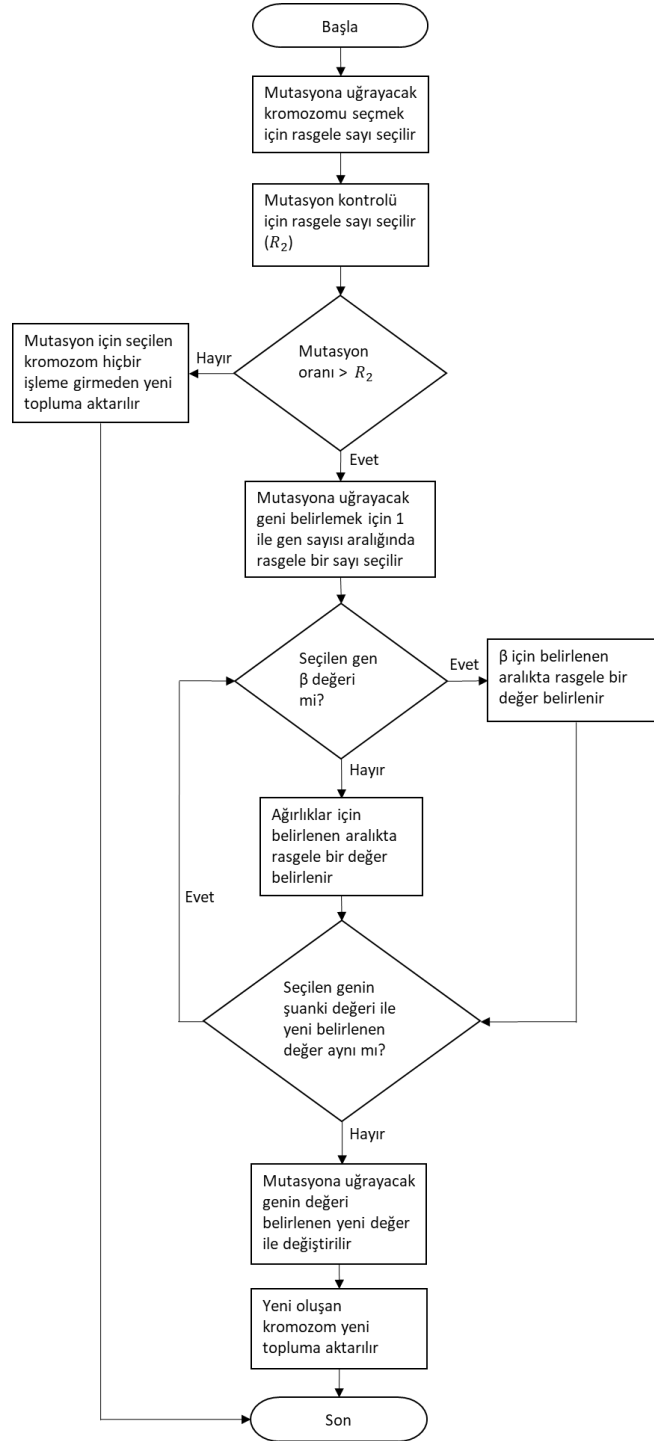
Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{800.1.1}$	$a_{800.2.1}$	$a_{800.3.1}$	$a_{300.4.1}$	$a_{300.5.1}$...	$\beta_{300.122}$

Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{300.1.1}$	$a_{300.2.1}$	$a_{300.3.1}$	$a_{800.4.1}$	$a_{800.5.1}$...	$\beta_{800.122}$

Şekil 5.18. Çaprazlama işlemi sonucunda oluşan yeni çocuk kromozomlar

Örneğin, çaprazlama oranı 0,85 ve rasgele seçilen sayı 0,9 olduğu varsayılırsa; Şekil 5.15.'te gösterilen kromozomlar hiçbir işleme tabi tutulmadan olduğu gibi yeni topluma aktarılır.

On birinci adımda ise mutasyon işlemi yapılır. Mutasyon işlemi uygulamada değer değiştirme yöntemine göre gerçekleştirilmiştir. Akış şeması Şekil 5.19.'da gösterilmiştir.



Şekil 5.19. Mutasyon akış şeması

Bu adımda öncelikle mutasyona uğrayacak kromozomu seçmek için rasgele sayı seçilir. Sonra mutasyon işleminin olup olmayacağına karar vermek için rasgele sayı seçilir. Kullanıcı tarafından ana ekrandan girilen mutasyon oranı ile seçilen rasgele sayı karşılaştırılır. Eğer mutasyon oranı rasgele sayıdan büyükse mutasyon gerçekleştirilir. Eğer mutasyon oranı rasgele sayıdan küçükse mutasyon işlemi gerçekleşmez. O kromozom aynı şekilde kalır ve yeni topluma aynı şekilde aktarılmış olur. Mutasyon işlemi gerçekleştirilecek ise mutasyona uğrayacak geni seçmek için 1 ile gen sayısı arasında rasgele sayı seçilir. Yani 1 ile 1442 arasında olacak şekilde rasgele sayı seçilir.

Kromozom için seçilen rasgele sayı = 200, gen için seçilen rasgele sayının 3 olduğu varsayılırsa 200 numaralı kromozomun üçüncü geninde mutasyon işlemi gerçekleşecek demektir (Şekil 5.20.).

$a_{200.3.1}$ = İki yüzüncü kromozomun üçüncü gen değeridir. Yani YSA'da yer alan üçüncü giriş verisi ile ara katmanda yer alan birinci nöron arasında ki bağlantıya ait ağırlığın iki yüzüncü kromozomdaki değeridir.

$a_{200.3.1} = 0.02$ olarak varsayılırsa mutasyon işlemi sonrası bu genin değeri 0.02'den farklı bir değer alacaktır.

Gen_1	Gen_2	Gen_3	Gen_4	Gen_5	...	Gen_{1442}
$a_{200.1.1}$	$a_{200.2.1}$	$a_{200.3.1} = 0.02$	$a_{200.4.1}$	$a_{200.5.1}$...	$\beta_{200.122}$

→ Mutasyona uğrayacak gen

Şekil 5.20. Mutasyona uğrayacak genin seçimi

Mutasyona uğrayacak gen seçildikten sonra mutasyon işlemine tabi tutulacak gen için yeni bir değer belirlenir. Mutasyon işlemi için seçilen gendeki değer β değeri olup olmadığına bakılır. Eğer β değeri ise β için kullanıcının ana ekrandan girdiği aralıkta olacak şekilde rasgele bir değer belirlenir. Eğer seçilen gen β değeri değil de herhangi bir ağırlık değeri ise kullanıcının ağırlıklar için ana ekrandan girdiği aralıkta olacak şekilde rasgele bir değer belirlenir.

Varsayım olarak daha önce mutasyona uğrayacak gen 3 olarak belirlenmişti. Kromozomda yer alan üçüncü gende ağırlık değeri yer aldığından kullanıcının ağırlıklar için ana ekrandan girdiği aralıkta bir yeni değer belirlenir. Gen için belirlenen yeni değer o genin şuan ki değeri ile karşılaştırılır. Eğer aynı değer ise önceki adıma geri dönülerek gen için tekrar bir yeni değer belirlenir. Değer farklı ise mutasyona uğrayacak genin değeri belirlenen yeni değer ile değiştirilir.

Son adım olan on ikinci adımda ise durdurma kriteri sağlanana kadar beşinci adımdan itibaren işlemler tekrarlanır. Uygulamada durdurma kriteri en iyi kromozoma ait uygunluk fonksiyon değerinin belirlenen değerden küçük olması ya da iterasyon sayısının tamamlanması olarak belirlenmiştir.

BÖLÜM 6. ELDE EDİLEN BULGULAR

Elektronik burun aracılığı ile elde edilen veri setinin %75'i eğitim için, % 25'i ise test için kullanılmak üzere iki gruba ayrılmıştır. Genetik algoritma ve geri yayılım algoritması ile aynı eğitim veri seti kullanılarak YSA'nın eğitim işlemi gerçekleştirilmiştir. İki eğitim sonucunda YSA için elde edilen iki farklı ağırlık ve β değerleri için ayrı ayrı aynı test verileri YSA'ya verilip eğitimin ne kadar başarılı olduğu test edilmiştir. Genetik algoritma ile YSA eğitilirken kullanılan parametreler Tablo 6.1.'de, geri yayılım algoritması ile YSA eğitilirken kullanılan parametreler ise Tablo 6.2.'da gösterilmiştir.

Tablo 6.1. Genetik algoritma parametreleri

Parametre	Değeri / Aralığı
Çaprazlama Oranı	0,85
Değer aralıkları	[-10,10]
Toplumdaki kromozom sayısı	1000
İterasyon sayısı	200
Mutasyon oranı	0,001

Tablo 6.2. Geri yayılım algoritma parametreleri

Parametre	Değeri / Aralığı
Öğrenme katsayısı	0,2
Ağırlık değer aralıkları	[-1,1]
Eşik değer aralıkları	[-1,1]
Momentum	0,8
Epoch	500

Uygulamada daha iyi çözüm elde edebilmek için yedi YSA tasarlanmış ve test edilmiştir. Tasarlanan YSA'da gizli katmanda yer alan nöronların sayısı başlangıçta 20 olarak belirlenmiş ve 20'şer olarak arttırılmıştır. En son gizli katmanında 140 nöron olan YSA test edilip arttırılma durdurulmuştur. YSA geri yayılım algoritması ile eğitilirken epoch sayısı 500 olarak belirlenmiştir. Genetik algoritma ile eğitilirken ise iterasyon sayısı 200 olarak belirlenmiştir. Hata değerleri gizli katmandaki nöron sayısı

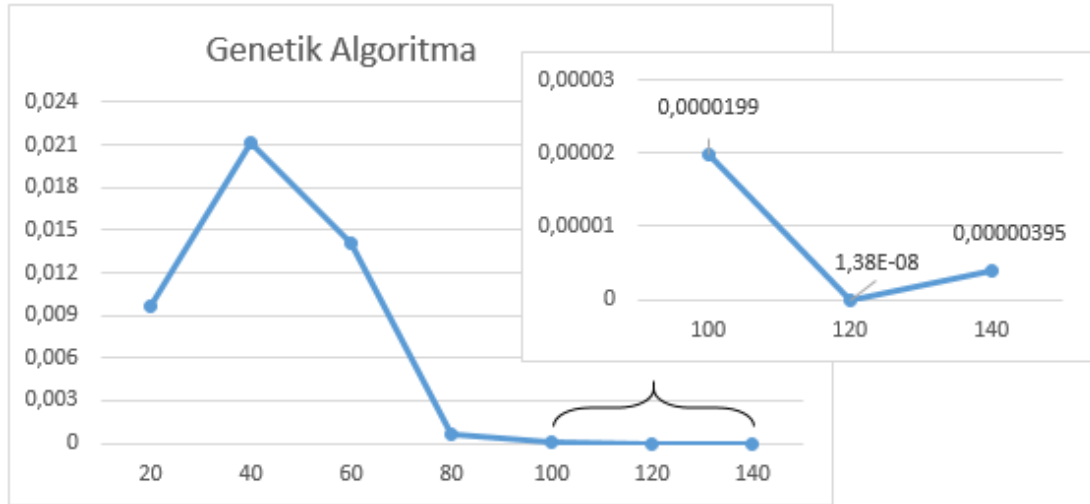
120 olduktan sonra artış göstermeye başlamıştır. Bu nedenle gizli katmandaki nöron sayısı 140'a ulaştıktan sonra farklı bir YSA düşünülmemiştir. Geri yayılım algoritmasında test verileri için en iyi çözüm gizli katmandaki nöron sayısının 20 olduğu YSA'da elde edilmiştir. Eğitimi genetik algoritma ile gerçekleşen YSA yapılarında test verileri için elde edilen en iyi çözüm gizli katmandaki nöron sayısının 120 olduğu YSA'da elde edilmiştir. Eğitimin genetik algoritma ve nöron sayısının 120 olduğu durumda test verileri için elde edilen çözümdeki hata değerine, geri yayılım algoritması ile eğitilen hiçbir durumda ulaşamamıştır. Tasarlanan yedi YSA'nın eğitimi sonucunda minimum hata 2.25E-09 olarak elde edilmiştir. Test verisinde ise buna yakın olarak 1,376E-08 hata değeri elde edilerek aynı başarı elde edilmiştir. Genetik algoritma ve geri yayılım algoritması ile elde edilen test verisi hata değerleri sırasıyla Tablo 6.3. ve Tablo 6.4.'te gösterilmiştir.

Tablo 6.3. Genetik algoritma için hata değerleri

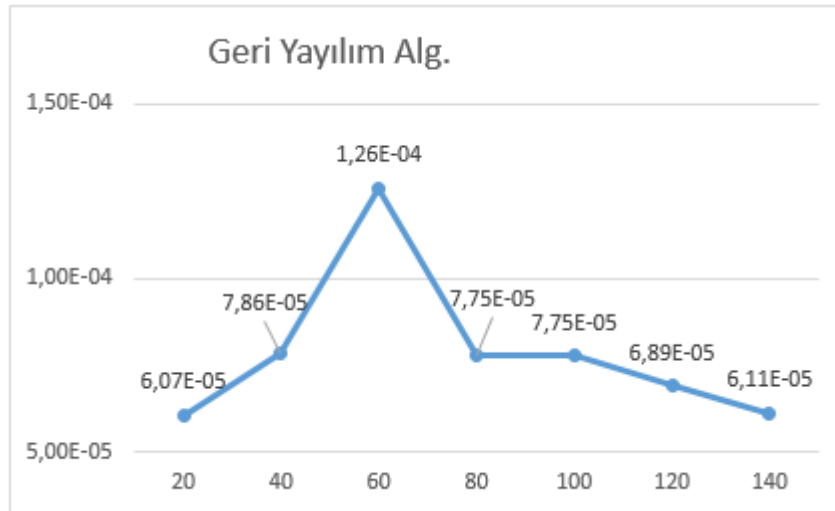
Gizli katmandaki nöron sayısı	MSE
20	9.64E-03
40	2.12E-02
60	1.41E-02
80	6.13E-04
100	1.99E-05
120	1.376E-08
140	3.95E-06

Tablo 6.4. Geri yayılım algoritması için hata değerleri

Gizli katmandaki nöron sayısı	MSE
20	6.065E-05
40	7.855E-05
60	1.26E-04
80	7.74E-05
100	7.735E-05
120	6.89E-05
140	6.11E-05




Şekil 6.1. GA ile eğitilen YSA modellerinin test verilerine ait MSE değerleri



Şekil 6.2. GY ile eğitilen YSA modellerinin test verilerine ait MSE değerleri

Şekil 6.1.'de GA ile eğitilen YSA modellerinin test verileri için elde edilen MSE değerleri yer almaktadır. Şekil 6.2.'de ise, GY ile eğitilen YSA modellerinin test verileri için elde edilen MSE değerleri yer almaktadır. Şekil 6.1. ve Şekil 6.2.'de yer alan grafiklerde x eksenini gizli katmanda yer alan nöron sayılarını ifade ederken, y eksenini ise MSE değerlerini ifade etmektedir. Şekil 6.1.'de yer alan grafiğin sağ tarafında, x ekseninin 100 ile 140 arasındaki olan değerleri için büyütülmüş kısım yer almaktadır. Bu büyütülmüş kısımda en düşük hata değerinin, gizli katmandaki nöron sayısının 120 olduğu durumda gerçekleştiği belirtilmiştir. Şekil 6.1. ve Şekil 6.2.'de görüldüğü üzere GA ile eğitilen YSA modellerinde elde edilen en düşük hata değerine GY ile eğitilen hiçbir YSA modelinde ulaşamamıştır.

Test verileri için genetik algoritma ve geri yayılım algoritması ile üretilen çıktılarla olması gereken çıktılardan bir arada gösterildiği grafik Şekil 6.3.'te verilmektedir. Grafikte AC ile MC için ayrı olarak gösterilmiştir. Şekil 6.3.'te verilen grafiklerde, olması gereken çıktı mavi, genetik algoritma ile elde edilen çıktı yeşil, geri yayılım algoritması ile elde edilen çıktı ise kırmızı ile gösterilmiştir. Genetik algoritma ile elde edilen çıktının olması gereken çıktı ile çok yakın olduğu grafiklerde görülmektedir.



Şekil 6.3. Test verileri ile elde edilen çıktıların karşılaştırılması

BÖLÜM 7. SONUÇ VE ÖNERİLER

Bu çalışmada kullanılan veri seti, 9 tane QCM gaz sensörü içeren sensör dizisine, AC ve MC gaz karışımlarının verilmesi sonucunda oluşan verilerin toplanması sonucunda oluşturulmuştur. Kullanılan bu veriler %75 eğitim veri seti ve %25 test veri seti şeklinde rasgele olacak şekilde iki gruba ayrılmıştır. Oluşturulan YSA modelleri aynı eğitim seti kullanılarak hem geri yayılım algoritması hem de genetik algoritma ile eğitilmiştir. Kullanılan bu YSA'larda eğitim veri seti dışında test veri seti olarak ayrılan ve YSA'nın daha önce görmediği veriler işlenerek başarıları test edilmiştir. Yedi farklı YSA tasarlanarak hepsi ayrı ayrı genetik algoritma ve geri yayılım algoritması ile eğitilerek test edilmiştir. Eğitimi genetik algoritma gerçekleşen YSA modellerinde, eğitimi geri yayılım algoritması ile gerçekleşen YSA modellerine göre daha iyi sonuçlar elde edilmiştir. Geri yayılım algoritması ile eğitilen YSA modelleri kullanıldığında en düşük hata oranı $6.065E-05$ elde edilmişken, GA ile eğitilen YSA modelleri kullanıldığında ise hata oranı en düşük $1.376E-08$ elde edilmiştir. Elde edilen iyi sonuçlar, genetik algoritma ile eğitilen YSA ve verilerin alınmasında kullanılan gaz sensörleri kullanılarak solvent yapısında yer alan ve insanlar için tehlikeli olan gazların farklı ölçülerde karıştırılarak hazırlanan karışımın başarılı olacak şekilde sınıflandırmasının yapılabildiğini ve gazların tehlike seviyeleri ile ilgili bu konuda işe yarayabilecek bilgilerin elde edilebileceğini göstermiştir.

Bu çalışmada sezgisel algoritmalarından genetik algoritma ile YSA eğitimi yapılmış olup geleneksel yöntem olan geri yayılım algoritmasına göre daha iyi sonuçla elde edilmiştir. Bu çalışmayı geliştirmek için gelecek çalışmalarda YSA'nın eğitiminde parçacık sürüsü optimizasyonu, yapay arı koloni algoritması gibi diğer sezgisel algoritmalar kullanılıp kıyaslama yapılarak daha iyi sonuçlar veren başka bir sezgisel algoritma tespit edilebilir. Ayrıca YSA yapısında birden fazla gizli katman olan çeşitli YSA modelleri tasarlanıp test edilerek daha iyi sonuçlar elde edilebilir.

KAYNAKLAR

- [1] Saraođlu, H.M., Elektronik Burun Teknolojisi ve Uygulama Alanları, presented at the X. Akademik Biliřim Konferansı, Akademik Biliřim Dergisi, 2008.
- [2] Adak, M.F., Elektronik Burun Verilerinin Yapay Zeka Tabanlı Algoritmalarla Sınıflandırılması, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 2016.
- [3] Davraz, M., Kiliñarslan, ř., Ceylan, H., Predicting the Poisson Ratio of Lightweight Concretes using Artificial Neural Network, Acta Physica Polonica A, Volume 128, Number 2B, ISSN 0587-4246, 2015.
- [4] Küçükkoç, İ., Karışık Modelli Montaj Hattı Dengeleme Problemleri ve Genetik Algoritmalar ile Bir Uygulama, Yüksek Lisans Tezi, Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, 2011.
- [5] Moncrieff, R.W., An instrument for measuring and classifying odors, Journal of Applied Physiology, Volume 16, Number 4, ISSN 8750-7587, 1961.
- [6] Wilkens, W.F., Hartman, J.D., An Electronic Analog for the Olfactory Processes, Annals of the New York Academy of Sciences, Volume 116, ISSN 0077-8923, 1964.
- [7] Buck, T.M., Allen, F.G., Dalton, J.V., Detection of Chemical Species by Surface Effects on Metals and Semiconductors. 1965.
- [8] Dravnieks, A., Trotter, P.J., Polar vapour detector based on thermal modulation of contact potential, Journal of Scientific Instruments, Volume 42, Number 8, ISSN 0950-7671, 1965.
- [9] Persaud, K., Dodd, G., Analysis of discrimination mechanisms in the mammalian olfactory system using a model nose, Nature, Volume 299, Number 5881, ISSN 1476-4687, 1982.
- [10] Ping, W., Yi, T., Haibao, X., Farong, S., A novel method for diabetes diagnosis based on electronic nose | Paper presented at Biosensors '96, Bangkok, May 1996.1, Biosensors and Bioelectronics, Volume 12, Number 9, ISSN 0956-5663, 1997.

- [11] Ryabtsev, S.V., Shaposhnick, A.V., Lukin, A.N., Domashevskaya, E.P., Application of semiconductor gas sensors for medical diagnostics, *Sensors and Actuators B: Chemical*, Volume 59, Number 1, ISSN 0925-4005, 1999.
- [12] Phillips, M., Breath test for the detection of various diseases, 12-Jan-1999.
- [13] Paulsson, N.J.P., Winquist, F., Analysis of breath alcohol with a multisensor array: instrumental setup, characterization and evaluation, *Forensic Science International*, Volume 105, Number 2, ISSN 0379-0738, 1999.
- [14] Nakamoto, T., Iguchi, A., Moriizumi, T., Vapor supply method in odor sensing system and analysis of transient sensor responses, *Sensors and Actuators B: Chemical*, Volume 71, Number 3, ISSN 0925-4005, 2000.
- [15] Aizawa, H., Kurosawa, S., Tanaka, M., Yoshimoto, M., Miyake, J., Tanaka, H., Rapid diagnosis of *Treponema pallidum* in serum using latex piezoelectric immunoassay, *Analytica Chimica Acta*, Volume 437, Number 2, ISSN 0003-2670, 2001.
- [16] Spangler, B.D., Wilkinson, E.A., Murphy, J.T., Tyler, B.J., Comparison of the Spreeta® surface plasmon resonance sensor and a quartz crystal microbalance for detection of *Escherichia coli* heat-labile enterotoxin, *Analytica Chimica Acta*, Volume 444, Number 1, ISSN 0003-2670, 2001.
- [17] Dutta, R., Hines, E.L., Gardner, J.W., Boilot, P., Bacteria classification using Cyranose 320 electronic nose, *BioMedical Engineering OnLine*, Volume 1, ISSN 1475-925X, 2002.
- [18] Fend, R., Bessant, C., Williams, A.J., Woodman, A.C., Monitoring haemodialysis using electronic nose and chemometrics, *Biosensors and Bioelectronics*, Volume 19, Number 12, ISSN 0956-5663, 2004.
- [19] Fu, W., Huang, Q., Wang, J., Liu, M., Huang, J., Chen, B., Detection of Human Papilloma Virus with Piezoelectric Quartz Crystal Genesensors, Volume 42, 2004.
- [20] Monge, M.E., Bulone, D., Giacomazza, D., Bernik, D.L., Negri, R.M., Detection of flavour release from pectin gels using electronic noses, *Sensors and Actuators B: Chemical*, Volume 101, Number 1, ISSN 0925-4005, 2004.
- [21] Boholt, K., Andreasen, K., den Berg, F., Hansen, T., A new method for measuring emission of odour from a rendering plant using the Danish Odour Sensor System (DOSS) artificial nose, *Sensors and Actuators B: Chemical*, Volume 106, Number 1, ISSN 0925-4005, 2005.
- [22] Özmen, A., Tekce, F., Ebeoğlu, M.A., Taşaltın, 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: Chemical*, Volume 115, Number 1, ISSN 0925-4005, 2006.

- [23] Tran, V.H., Chan, H.P., Thurston, M., Jackson, P., Lewis, C., Yates, D., Bell, G., Thomas, P.S., Breath Analysis of Lung Cancer Patients Using an Electronic Nose Detection System, *IEEE Sensors Journal*, Volume 10, Number 9, ISSN 1530-437X, 2010.
- [24] Rodriguez, S.D., Monge, M.E., Olivieri, A.C., Negri, R.M., Bernik, D.L., Time dependence of the aroma pattern emitted by an encapsulated essence studied by means of electronic noses and chemometric analysis, *Food Research International*, Volume 43, Number 3, ISSN 0963-9969, 2010.
- [25] Musatov, V.Y., Sysoev, V.V., Sommer, M., Kiselev, I., Assessment of meat freshness with metal oxide sensor microarray electronic nose: A practical approach, *Sensors and Actuators B: Chemical*, Volume 144, Number 1, ISSN 0925-4005, 2010.
- [26] Zhou, B., Wang, J., Discrimination of different types damage of rice plants by electronic nose, *Biosystems Engineering*, Volume 109, Number 4, ISSN 1537-5110, 2011.
- [27] Xiao, Z., Yu, D., Niu, Y., Chen, F., Song, S., Zhu, J., Zhu, G., Characterization of aroma compounds of Chinese famous liquors by gas chromatography–mass spectrometry and flash GC electronic-nose, *Journal of Chromatography B*, Volume 945–946, ISSN 1570-0232, 2014.
- [28] Versari, A., Laurie, V.F., Ricci, A., Laghi, L., Parpinello, G.P., Progress in authentication, typification and traceability of grapes and wines by chemometric approaches, *Food Research International*, Volume 60, ISSN 0963-9969, 2014.
- [29] Dymerski, T., Gębicki, J., Wardencki, W., Namieśnik, J., Application of an electronic nose instrument to fast classification of Polish honey types, *Sensors (Basel, Switzerland)*, Volume 14, Number 6, ISSN 1424-8220, 2014.
- [30] Deshmukh, S., Jana, A., Bhattacharyya, N., Bandyopadhyay, R., Pandey, R.A., Quantitative determination of pulp and paper industry emissions and associated odor intensity in methyl mercaptan equivalent using electronic nose, *Atmospheric Environment*, Volume 82, ISSN 1352-2310, 2014.
- [31] Gupta, S., Variyar, P.S., Sharma, A., Application of mass spectrometry based electronic nose and chemometrics for fingerprinting radiation treatment, *Radiation Physics and Chemistry*, Volume 106, ISSN 0969-806X, 2015.
- [32] Pizzoni, D., Compagnone, D., Di Natale, C., D'Alessandro, N., Pittia, P., Evaluation of aroma release of gummy candies added with strawberry flavours by gas-chromatography/mass-spectrometry and gas sensors arrays, *Journal of Food Engineering*, Volume 167, ISSN 0260-8774, 2015.

- [33] Kablan, Y., Elektronik Burun ile Farklı Kalitedeki Doğu Karadeniz Çaylarının Sınıflandırılması, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2018.
- [34] Cevoli, C., Cerretani, L., Gori, A., Caboni, M.F., Gallina Toschi, T., Fabbri, A., Classification of Pecorino cheeses using electronic nose combined with artificial neural network and comparison with GC–MS analysis of volatile compounds, *Food Chemistry*, Volume 129, Number 3, ISSN 0308-8146, 2011.
- [35] Gursoy, O., Somervuo, P., Alatosava, T., Preliminary study of ion mobility based electronic nose MGD-1 for discrimination of hard cheeses, *Journal of Food Engineering*, Volume 92, Number 2, ISSN 0260-8774, 2009.
- [36] Pavlou, A.K., Magan, N., Jones, J.M., Brown, J., Klatser, P., Turner, A.P.F., Detection of *Mycobacterium tuberculosis* (TB) in vitro and in situ using an electronic nose in combination with a neural network system, *Biosensors & Bioelectronics*, Volume 20, Number 3, ISSN 0956-5663, 2004.
- [37] Dhanarajan, G., Mandal, M., Sen, R., A combined artificial neural network modeling–particle swarm optimization strategy for improved production of marine bacterial lipopeptide from food waste, *Biochemical Engineering Journal*, Volume 84, ISSN 1369-703X, 2014.
- [38] Ghaedi, M., Ghaedi, A.M., Ansari, A., Mohammadi, F., Vafaei, A., Artificial neural network and particle swarm optimization for removal of methyl orange by gold nanoparticles loaded on activated carbon and Tamarisk, *Spectrochimica Acta. Part A, Molecular and Biomolecular Spectroscopy*, Volume 132, ISSN 1873-3557, 2014.
- [39] Mumyakmaz, B., Özmen, A., Ebeoğlu, M.A., Taşaltın, C., Predicting gas concentrations of ternary gas mixtures for a predefined 3D sample space, *Sensors and Actuators B: Chemical*, Volume 128, Number 2, ISSN 0925-4005, 2008.
- [40] Gulbag, A., Temurtas, F., A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro-fuzzy inference systems, *Sensors and Actuators B: Chemical*, Volume 115, Number 1, ISSN 0925-4005, 2006.
- [41] Gordillo-Ruíz, F.A., Sánchez-Ruíz, F.J., Mendoza-Castillo, D.I., Reynel-Ávila, H.E., Bonilla-Petriciolet, A., Dynamic fuzzy neural network for simulating the fixed-bed adsorption of cadmium, nickel, and zinc on bone char, *International Journal of Environmental Science and Technology*, ISSN 1735-1472, 1735-2630, 2017.
- [42] Yan, J., Tian, F., Feng, J., Jia, P., He, Q., Shen, Y., A PSO-SVM Method for Parameters and Sensor Array Optimization in Wound Infection Detection based on Electronic Nose, *Journal of Computers*, Volume 7, Number 11, ISSN 1796-203X, 2012.

- [43] Al-Bastaki, Y., An Artificial Neural Networks-Based on-Line Monitoring Odor Sensing System, *J. Comput. Sci*, Volume 5, Number 11, 2009.
- [44] Banerjee, M., Bar, N., Basu, R.K., Das, S.K., Comparative study of adsorptive removal of Cr(VI) ion from aqueous solution in fixed bed column by peanut shell and almond shell using empirical models and ANN, *Environmental Science and Pollution Research International*, Volume 24, Number 11, ISSN 1614-7499, 2017.
- [45] Kuvendziev, S., Marinkovski, M., Lisichkov, K., Paunović, P., Artificial Neural Network Modeling of Cd(II) Ions Adsorption on Nano-porous Inorganic Sorbents, in *Nanoscience Advances in CBRN Agents Detection, Information and Energy Security*, p. 469–476, 2015.
- [46] Ekicioğlu, Z., Paralel Mekanizmaların Çalışma Uzayı Analizinde Kullanılan Yapay Sinir Ağı Yapısının Genetik Algoritmalar ile Belirlenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2011.
- [47] Hacıoğlu, A., Yapay Sinir Ağı ile Güçlendirilmiş Genetik Algoritma ve Tersten Kanat Profili Dizayını, *Havacılık ve Uzay Teknolojileri Dergisi*, Volume 1, Number 3, 2004.
- [48] Zalzala, A.M.S., Ang, M.C., Chen, M., Rana, A.S., Wang, Q., Evolutionary algorithms for robotic systems: principles and implementations, in *Genetic algorithms in engineering systems*, Volume 8, London, 1997.
- [49] Koza, J.R., Bennett, F.H., Hutchings, J.L., Bade, S.L., Keane, M.A., Andre, D., Evolving sorting networks using genetic programming and the rapidly reconfigurable Xilinx 6216 field-programmable gate array, in *Conference Record of the Thirty-First Asilomar Conference on Signals, Systems and Computers (Cat. No.97CB36136)*, Volume 1, p. 404–410, 1997.
- [50] Guha, A., Harp, S.A., Samad, T., United States Patent: 5140530 - Genetic algorithm synthesis of neural networks, 5140530, 1992.
- [51] Çeyrekoğlu, S., Araç Rotalama Problemine Genetik Algoritma Yaklaşımı ve Örnek Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, 2017.
- [52] Guo, Z., Uhrig, R.E., Using genetic algorithms to select inputs for neural networks, in *COGANN-92: International Workshop on Combinations of Genetic Algorithms and Neural Networks*, p. 223–234, 1992.
- [53] Gupta, J.N.D., Sexton, R.S., Comparing backpropagation with a genetic algorithm for neural network training, *Omega*, Volume 27, Number 6, ISSN 0305-0483, 1999.
- [54] Potter, M.A., A genetic cascade-correlation learning algorithm, in *COGANN-92: International Workshop on Combinations of Genetic Algorithms and Neural Networks*, p. 123–133, 1992.

- [55] Freitas, A.A., A Genetic Programming Framework for Two Data Mining Tasks: Classification and Generalized Rule Induction, in Genetic Programming 1997: Proc 2nd Annual Conf, p. 96–101, 2009.
- [56] Ferringer, M.P., Spencer, D.B., Reed, P., Many-objective reconfiguration of operational satellite constellations with the Large-Cluster Epsilon Non-dominated Sorting Genetic Algorithm-II, in 2009 IEEE Congress on Evolutionary Computation, p. 340–349, 2009.
- [57] Congdon, C.B., Aman, J.C., Nava, G.M., Gaskins, H.R., Mattingly, C.J., An evaluation of information content as a metric for the inference of putative conserved noncoding regions in DNA sequences using a genetic algorithms approach, IEEE/ACM transactions on computational biology and bioinformatics, Volume 5, Number 1, ISSN 1545-5963, 2008.
- [58] Bolat, B., Erol, K.O., Erdem, C., Genetic Algorithms in Engineering Applications and the Function of Operators, Journal of Engineering and Natural Sciences, Number 4, 2004.
- [59] Kulluk, S., Tesis yerleşimi problemlerinde genetik algoritmalar ve bir paralel genetik algoritma uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 2003.
- [60] Efe, A.A., Elektronik Burun Teknolojisi ve Örnek Uygulaması, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 2006.
- [61] Senyücel, N., Zararlı Kokuları Algılayıp İnternet Üzerinden İleten Elektronik Burun Tasarımı, Doktora Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, 2013.
- [62] Tozlu, B.H., Elektronik Burunla Çay Fermantasyonu Denetimi, Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2014.
- [63] Çayıroğlu, İ., İleri Algoritma Analizi.
- [64] Ünal, M., Sinyal İşleme ve Genetik-Yapay Sinir Ağları ile Rulman Arızalarının Teşhisi, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, 2014.
- [65] Elveren, E., Genetik Algoritmaları Yapay Sinir Ağları Kullanılarak Tüberküloz Hastalığının Teşhisi, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 2009.
- [66] Öztemel, E., Yapay Sinir Ağları. 2003.
- [67] Angeline, P.J., Evolution Revolution: An Introduction to the Special Track on Genetic and Evolutionary Programming, IEEE Expert: Intelligent Systems and Their Applications, Volume 10, Number 3, ISSN 0885-9000, 1995.
- [68] Cunkaş, M., Genetik Algoritmalar ve Uygulamaları. 2006.

- [69] Mazumder, P., Rudnick, E., Genetic Algorithms for VLSI Design, Layout and Test Automation, 1 edition. Upper Saddle River, NJ, 1998.
- [70] Goldberg, D.E., Genetic Algorithms in Search, Optimization, and Machine Learning, Choice Reviews Online, Volume 27, Number 02, ISSN 0009-4978, 1523-8253, 1989.
- [71] Biroğul, S., Genetik Algoritma Yaklaşımıyla Atölye Çizelgeleme, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 2005.
- [72] Şeker, Ş., Araç Rotalama Problemleri ve Zaman Pencere Stokastik Araç Rotalama Problemine Genetik Algoritma Yaklaşımı, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2007.
- [73] Düğenci, M., Genetik Algoritmalarla Permütasyon Tipi İş Sıralama, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, 1996.
- [74] Duman, C., Genetik Algoritma ile Tesis Yerleşimi Tasarımı ve Bir Uygulama, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2007.
- [75] Özen, B., Dairesel Anten Dizilerinin Genetik Algoritma ile Tasarımı, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 2015.
- [76] Adak, M.F., Canpolat, K., Yumusak, N., Genetik Algoritma Kullanan Yapay Sinir Ağları ile İkili Gaz Karışımlarının Sınıflandırılması, 4th International Symposium on Innovative Technologies in Engineering and Science, 2016.

ÖZGEÇMİŞ

Kadriye CANPOLAT, 1991 yılının Kasım ayında Sakarya'da dünyaya gelmiştir. İlk ve orta öğretimini Sakarya'da tamamladıktan sonra Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nü kazanmıştır. 2010 yılında ise çift anadal programı ile Bilgisayar Mühendisliği Bölümü'nün de eğitimine başlamıştır. 2013 yılında iki bölümden de mezun olmuştur. Mezuniyetinden sonra 2018 yılına kadar Sakarya Üniversitesi Bilgisayar Araştırma ve Uygulama Merkezi'nde Yazılım Mühendisi olarak görev yapmıştır. Yüksek lisans eğitimine Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Ana Bilim Dalı ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı'nda devam etmektedir. 2018 yılının mart ayından itibaren ise Sakarya Üniversitesi bünyesinde Öğretim Görevlisi olarak görev yapmaktadır.