



T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

GÖRÜNTÜ İŞLEME TEKNİKLERİ VE YAPAY ZEKA YÖNTEMLERİ KULLANARAK ATIKSU ARITMADA PERFORMANS ANALİZLERİNİN İNCELENMESİ

Halime BOZTOPRAK

DOKTORA TEZİ

Elektrik Elektronik Müh. Anabilim Dalını

Temmuz-2014
KONYA
Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I here by declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all materials and results that are not original to this work.

Halime BOZTOPRAK
02.07.2014

ÖZET

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİ VE YAPAY ZEKA YÖNTEMLERİ KULLANARAK ATIKSU ARITMADA PERFORMANS ANALİZLERİNİN İNCELENMESİ

Halime BOZTOPRAK

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Elektronik Müh. Anabilim Dalı

Danışman: Doç. Dr. Yüksel ÖZBAY

2014, 128 Sayfa

Jüri
Danışman Doç. Dr. Yüksel ÖZBAY
Doç. Dr. Halis ALTUN
Doç. Dr. Nihat YILMAZ
Yrd. Doç. Dr. Dünyamin GÜÇLÜ
Yrd. Doç. Dr. Murat CEYLAN

Çamur hacim indeksi (ÇHİ) atıksu arıtma tesislerinin performans takibinin yapılabilmesi için günlük olarak izlenmesi gereken bir parametredir. Bu parametrenin görüntü işleme ve yapay zekâ teknikleri kullanılarak tahmin edilmesi amaçlanmıştır. Bunun için aktif çamur numuneleri Konya Kentsel Atıksu Arıtma Tesisi aktif çamur ünitesinin havalandırma tankından alınmıştır. Mikroskoptan görüntüleri otomatik almak için motorlu XY platform ve kameralı bir sistem kurulmuştur. Her numuneden sistematik bir şekilde 49 (7x7) adet görüntü alınarak toplam 120 numune incelenmiştir. Bu işlemlerin kolay ve otomatik bir şekilde yapılabilmesi için kullanıcı arayüzü tasarlanmıştır. Alınan görüntülerin flok ve filament yapıları incelenmiş ve bu yapıların bölütlenmesinde dalgacık dönüşümü, uzaysal frekans ve hücresel sinir ağları (HSA) birlikte kullanarak yeni bir bölütleme yöntemi sunulmuştur. Bu yöntemde her bir görüntünün özelliğine göre HSA'nın iterasyon sayısı değiştirilmiştir. Farklı özelliklere sahip atıksu görüntülerinin, içeriğinden bağımsız olarak bölütlenmesi sağlanmıştır. Flok ve filamentleri doğru şekilde ve ayrı ayrı tespiti için bir dizi morfolojik işlemler uygulanmıştır. Ayrıca protozoaların aktif çamurda bulunmaları arıtma teknolojisi açısından önemli olduğundan protozoaların yerlerinin otomatik bulunmasında aktif kontur yöntemi kullanılmıştır. Flok ve filamentlerin morfolojik karakterizasyonu aktif çamur durumunun değerlendirilmesinde önemli bir rol oynadığından bunlara ait özellikler belirlenmiştir. Bu özelliklerin belirlenmesinde yoğunluk, şekilsel ve istatistiksel yaklaşımlardan yararlanılmıştır ve her güne ait veri seti oluşturulmuştur. Veriler rastgele karıştırılıp 5-kat çapraz doğrulama yöntemi ile eğitim ve test verileri elde edilmiştir. Bu eğitim ve test verileri yapay sinir ağına uygulanmıştır. YSA'nın ağırlıkları Levenberg-Marquardt, Genetik Algoritma ve ARI algoritması ile eğitilmiştir. Korelasyon katsayılarının ortalamaları LM-YSA, GA-YSA ve ARI-YSA için sırasıyla r=0.896, r=0.902 ve r=0.915 hesaplanmıştır. Elde edilen sonuçlar görüntü işleme ve yapay sinir ağlarının ÇHİ tahmininde başarılı bir yöntem olarak uygulanabileceğini göstermiştir.

Anahtar kelimeler: Çamur Hacim İndeksi, Dalgacık Dönüşümü, Flok-Filament Bölütleme, Genetik Algoritma, Hücresel Sinir Ağı, Otomatik Görüntü Yakalama, Yapay Arı Koloni Algoritması, Yapay Sinir Ağları.

ABSTRACT

Ph.D THESIS

INVESTIGATION OF THE PERFORMANCE ANALYSIS IN WASTEWATER TREATMENT USING IMAGE PROCESSING TECHNIQUES AND ARTIFICIAL INTELLIGENCE METHODS

Halime BOZTOPRAK

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELÇUK UNIVERSITY
THE DEGREE OF DOCTOR OF PHILOSOPHY
IN ELEKTRIC ELECTRONIC ENGINEERING

Advisor: Doç. Dr. Yüksel ÖZBAY

2014, 128 Pages

Jury
Advisor Doç. Dr. Yüksel ÖZBAY
Doç. Dr. Halis ALTUN
Doç. Dr. Nihat YILMAZ
Yrd. Doç. Dr. Dünyamin GÜÇLÜ
Yrd. Doç. Dr. Murat CEYLAN

The sludge volume index (SVI) is a required parameter to be monitored for the performance of wastewater treatment plants on a daily basis. This parameter was intended to be estimated using image processing and artificial intelligence techniques. For this, activated sludge samples was taken from the aeration tank of the activated sludge process in Konya Domestic Wastewater Treatment Plant. Motorized XY platform and camera system has been established to auto-scan the image from the microscope. 49 (7x7) images from every each sample has been scanned in a systematically. Total of 120 samples were examined. A user interface is designed for making this operation easily and automatically. Floc and filament structures of the images were examined. A new method was developed using cellular neural networks (CNN), spatial frequency and wavelet transform in segmentation of the activated sludge images. In this method, number of iterations of CNN was changed according to the properties of each image. The images with different characteristics of wastewater were segmented regardless of content. Then, a number of morphological operations are applied to correctly determine the floc and filaments separately. Furthermore, the active contour method is used to detect the location of protozoans which are important in the activated sludge. Morphological characterization of floc and filament plays an important role in the evaluation of activated sludge. Their morphological properties were determined. Density, shape and statistical approaches have been utilized to create a set of data for each day. The training and test data have been obtained by randomly mixed the data and applied 5-fold cross-validation method. This training and test data were applied artificial neural network. The weights of the neural network were trained with Levenberg-Marquardt, Genetic and Artificial Bee Colony algorithms. The averages of the correlation coefficients for LM-ANN, GA-ANN and ABC-ANN models were calculated as r=0.896, r=0.902 and r=0.915, respectively. The obtained results have shown that image processing and artificial neural networks can be applied as a successful method for prediction of SVI.

Keywords: Automatic Image Capture, Artificial Neural Networks, Artificial Bee Colony Algorithm, Cellular Neural Network, Floc-Filaments Segmentation, Genetic Algorithms, Sludge Volume Index, Wavelet Transform.

ÖNSÖZ

Bu tez çalışmalarımda bilgi ve tecrübesi ile yardımcı olan danışmanım Doç. Dr. Yüksel ÖZBAY'a teşekkürlerimi sunarım.

Çalışma verilerinin elde edilmesinde bana yardımcı olan Konya Kentsel Atıksu Arıtma Tesisi çalışanlarına teşekkür ederim.

Tezimin her aşamasında beni yalnız bırakmayan aileme sonsuz sevgi ve saygılarımı sunarım.

Halime BOZTOPRAK
KONYA-2014

İÇİNDEKİLER

TEZ BİLDİRİMİ ..... **vi**

ÖZET ..... **vii**

ABSTRACT ..... **viii**

ÖNSÖZ ..... **ix**

İÇİNDEKİLER ..... **vi**

SİMGELER VE KISALTMALAR ..... **ix**

1. GİRİŞ **1**

1.1. Çalışmanın Amacı ve Önemi 3
1.2. Çalışmanın Kapsamı ve Organizasyonu 4
1.3. Literatür Araştırması 5

2. ATIKSU ARITMA TESİSLERİ **10**

2.1. Fiziksel arıtma 11
2.2. Biyolojik arıtma 11
2.3. Aktif Çamur Sistemi ve Özellikleri 12
2.3.1. Çamur hacim indeksi 13
2.4. Aktif Çamur Tesislerinde Kabarma ve Köpük Oluşumu 16
2.5. Konya Kentsel Atıksu Arıtma Tesisinin Genel Yapısı 18

3. GÖRÜNTÜ İŞLEME TEKNİKLERİ **22**

3.1. Eşikleme 22
3.2. Filtreleme 22
3.2.1. Ortalama filtre 23
3.2.2. Ortanca filtre 23
3.2.3. Gaussian filtre 24
3.3. Morfolojik İşlemler 25
3.3.1. Genişleme 26
3.3.2. Aşınma 27
3.3.3. Açma ve kapama 28
3.3.4. Boşluk doldurma 29
3.4. Görüntü Bölütleme 29
3.5. Kenar Bulma Algoritmaları 31
3.5.1. Roberts operatörü 32
3.5.2. Sobel operatörü 32
3.5.3. Prewitt operatörü 33
3.6. Aktif Kontur Modeli 33

4. ÖZELLİK ÇIKARMA VE SINIFLANDIRMA 36

4.1. Özellik Çıkarma 36
4.1.1. Şekilsel özellikler 36
4.1.2. Yoğunluk tabanlı özellikler 38
4.1.3. Entropi 39
4.1.4. Gri seviye eş-oluşum matrisleri 39
4.1.5. Uzaysal frekans 41
4.1.6. İki boyutlu ayrık dalgacık dönüşümü 42
4.1.6.1. Dalgacıklar ve özellikleri 44
4.1.6.2. Haar dalgacık dönüşümü 44
4.1.6.3. Daubechies dalgacık dönüşümü 45
4.2. Sınıflandırma 45
4.2.1. Yapay sinir ağları 45
4.2.1.1. Yapay sinir ağlarının yapısı 46
4.2.1.2. Geriye yayılım algoritması 49
4.2.1.3. Levenberg-Marquardt öğrenme metodu 51
4.2.1.4. Geri yayılım algoritması ile YSA'nın eğitimi 52
4.2.2. Genetik algoritma 56
4.2.3. Yapay arı kolonisi algoritması 59
4.2.4. Hücresel sinir ağları 61
4.2.5. Performans kriterleri 65
4.2.5.1. Ortalama karesel hata 65
4.2.5.2. Korelasyon katsayısı 65

5. MİKROSKOBİK GÖRÜNTÜLERİN BÖLÜTLENMESİ 66

5.1. Görüntülerin Bölütlenmesinde Kullanılan Yöntem 66
5.1.1. İterasyon sayısının belirlenmesi 74
5.2. Flok ve Filamentlerin Bölütlenmesi 77

6. ÇAMUR HACİM İNDEKSİNİN TAHMİNİ 82

6.1. Sistemin Genel İşleyiş Adımları 82
6.2. Numunenin Hazırlanması 83
6.3. Görüntülerin Alınmasında Kullanılan Düzenek ve Özellikleri 84
6.4. Görüntü Alımı İçin Geliştirilen Yazılım 85
6.5. Görüntü Yakalama 86
6.6. Görüntülerin İşlenmesi 87
6.7. Veri Setinin Oluşturulması 90
6.8. Çamur Hacim İndeksinin Tahmininde Kullanılan Yapay Sinir Ağı 93
6.8.1. Çamur hacim indeksinin LM-YSA ile tahmini 96
6.8.2. Çamur hacim indeksinin GA-YSA ile tahmini 97
6.8.3. Çamur hacim indeksinin ARI-YSA ile tahmini 99
6.8.4. Yapay Çamur hacim indeksinin tahmin sonuçların karşılaştırılması 102

7. ATIKSULARDA PROTOZOA BELİRLENMESİ 103

7.1. Protozoaların Belirlenmesi 104
7.2. Bölgelerin Genişletilmesi ve Aktif Kontur Metodunun Uygulanması 107

8. SONUÇLAR VE ÖNERİLER 112

8.1. Sonuçlar 112
8.2. Öneriler 114

KAYNAKLAR 116

ÖZGEÇMİŞ 127

SİMGELER VE KISALTMALAR

Simgeler

σ	:	Sigma
∇	:	Gradyent operatörü
P	:	Pikselin tekrarlanma olasılığı
I	:	Parlaklık değeri,
M	:	Görüntüdeki piksel sayısı
L	:	En büyük parlaklık değeri
Λ	:	Öğrenme Katsayısı
α	:	Regresyon sabiti
r	:	Korelasyon katsayısı

Kısaltmalar

KOSKİ	:	Konya Su ve Kanalizasyon İdaresi
RMS	:	Karelerinin ortalamasının karekökü / root mean square
YSA	:	Yapay sinir ağları
HSA	:	Hücresel sinir ağları
BOİ	:	Biyolojik oksijen ihtiyacı
AKM	:	Askıda katı madde
8MTF	:	Motor kontrollü XY tarama platformu
ÇHİ	:	Çamur hacim indeksi
ADD	:	Ayrık dalgacık dönüşümü
LM	:	Levenberg-Marquardt geri yayılım algoritması
ARI	:	Yapay arı kolonisi algoritması
MSE	:	Ortalama karesel hata
SF	:	Uzaysal frekans
AR	:	Boy oranı
GA	:	Genetik algoritma
NG	:	YSA giriş katmanı düğüm sayısı
NA	:	YSA ara katman düğüm sayısı
NC	:	YSA çıkış katmanı düğüm sayısıdır.
KOİ	:	Kimyasal oksijen ihtiyacı
ÇKM	:	Çökebilir katı madde
UKM	:	Uçucu askıda katı madde
PSNR	:	Pik sinyal gürültü oranı (Peak to signal noise ratio)

1. GİRİŞ

Aktif çamur arıtma prosesi, evsel ve endüstriyel atıksuların arıtımında günümüzde en yaygın kullanılan biyolojik arıtma işlemidir. Arıtmanın işletim biçimi, tüm tesisin arıtma giderlerini belirlemesi açısından çok önemlidir. Uygun şartlar altında işletildiğinde, istenen arıtma veriminin sağlanması mümkün olacaktır. Fakat, uygun olmayan işletme koşulları proses verimini etkilemekte ve arıtma verimi istenilen düzeyde gerçekleşmemektedir (Güçlü, 2007).

Biyolojik atıksu arıtma tesisleri belirli tasarım kriterlerine göre projelendirilip uygulamaya konulmakla birlikte işletme aşamasında birçok problemlerle karşı karşıya kalmaktadır. Böylesine durumlar biyolojik atıksu arıtma tesislerinin işletilmesi sırasında hemen hemen her yıl ve dahası her mevsim dönüşlerinde karşımıza çıkmaktadır. Bu problemler çoğunlukla tüm dünyanın karşılaştığı oldukça yaygın problemlerdir. Bunların en meşhuru ve sürekli rastlanan tipi çamur kabarması ve köpük oluşumu problemleridir. Özellikle aktif çamur sistemlerinde inanılmaz kabarma ve köpük problemleri pek çok evsel ve endüstriyel tesislerde gündeme gelmektedir. Bunun sonucunda aktif çamurun taşmasına ve son çökeltim havuzunda da çökelmeme sebebiyle katı-sıvı ayırımı yapılamamaktadır. Probleme neden olan biyolojik parametrelerin özellikle flok yapısı ve filamentli mikroorganizmaların durumunun ortaya konmasının büyük önem taşıdığı vurgulanmaktadır (Övez, 2010).

Biyolojik arıtma sistemlerinde kabarma ve köpük problemi oluşmasının, pek çok bilinen ve bilinmeyen parametreyle ilişkili olduğu bilinmektedir. Filamentli mikroorganizmaların kontrolsüz çoğalmasına, flok yapıcı, serbest, askıda ve tutulu büyüme ve çoğalma gösteren pek çok diğer mikroorganizmanın ortadan kalkmasına veya aşırı çoğalmasına neden olabilecek yüzlerce parametre bilinmektedir. Bununla beraber, belli başlı ana parametreler içerisinde atıksu karakterizasyonu ve yapısı, nutrientlerin (azot ve fosfor) konsantrasyonu, çamur yaşı ve bekletme süresi, yağ ve gres miktarı, havalandırma havuzu içindeki çözünmüş oksijen değeri, sülfür konsantrasyonu, pH gibi parametrelerin birçok arıtma sisteminin kabarma ve köpük problemiyle karşı karşıya kalmasında önemli etkilere sahip olduğu vurgulanmıştır (Bitton, 1994; Jenkins ve ark., 1993). Bu parametreler her bir tesiste genelde zaman zaman kontrol dışına çıkabilmekte ve hangi parametrelerin bu problemli durumu tetiklediği tam olarak anlaşılamamaktadır. Bu parametrelerden birisinin veya birden fazlasının kontrol dışına çıkması (azlığında

veya çokluğunda) kabarma ve köpürme problemini teşvik edebilecek koşulları oluşturmasını sağlayabilmektedir. Ancak bu durumun oluşması açık kanıtlarla ortaya henüz konulamamıştır. Bahsedilen parametrelerin neden olabileceği söylenmekte, ancak hangi koşullarla beraber oluştuğu ortaya çıkarılamamaktadır. Bunların dışında ülkeden ülkeye, mevsimlere, meteorolojik değişikliklere ve coğrafik koşullara bağlı olarak farklı durumlar ortaya çıkabilmektedir. Bu durumlar genelde mühendislik açısından arıtma tesislerinin dizaynında pek de göz önüne alınan parametreler değildir. Doğal olarak bu parametrelerin değişkenliği kontrol edilebilecek durumda da değildir. Ancak canlı türlerinin çeşitliliğinin kontrolü ve ekosistemlerini kontrol eden parametrelerin sürekli değişiklik içerisinde bulunması dolayısıyla çok bilinmeyenli, neredeyse sonsuz parametrenin kontrolü anlamı taşımaktadır ki bu da pratikte neredeyse imkânsız ve çözümü mümkün olmayan problem haline gelmektedir. Bu durumda arıtma sistemleri için yapılan model çalışmaları da ancak belli sayıda parametreyi göz önüne almakta ve çok daha fazlasını göz ardı etmektedir. Bunun sonucunda biyolojik olarak neredeyse kontrolsüz bir sistem işletilmeye çalışılmakta ve sonuç olarak kabarma ve köpük probleminin ortaya çıkması kaçınılmaz olmaktadır (Övez, 2010).

Tür çeşitliliği arıtma sisteminin performansını ve problemlerin ortaya çıkmasını önemli derecede etkilemektedir. Tür çeşitliliği ve sayısı filamentli mikroorganizmaların sistemi kabarma ve köpük problemine götürüp götürmeyeceğini, katı-sıvı ayırımının olup olamayacağını belirlemektedir. Pek çok filamentli türü bilinmekle birlikte ülkemizde özellikle Gordonia spp. (Nocardia spp.) ve Microthrix parvicella türleri hem kabarma hem de köpük oluşturmaları bakımından öne çıkmaktadırlar. Bu türlerin birlikte bulunma durumlarında ise problem çok daha ciddi olarak gündeme gelmektedir. Bazı türler ise çok daha fazla sayılara ulaşmasına rağmen katı-sıvı ayırımında bu türlere kıyasla daha iyi sonuçlar verebilmektedirler. Bu durumda Jenkins'in ve Eikelboom'un filamentli mikroorganizma sayısı ve kabarma problemi ilişkili sınıflandırma için verdikleri değerleri fazlasıyla aştıkları halde çökelme problemi yaratmamaktadırlar (Jenkins ve ark., 1993; Eikelboom, 1977). Bu türlerin tek tek oluşturduğu problemler ciddi olsa da birden fazla türün birlikte olduğu sistemlerde çok daha ciddi, önlenmesi ve iyileştirilmesi çok daha zor olmaktadır (Övez, 2010). Mikroorganizma çeşitliliğinin belirlenmesi atıksuyun karakteri ile mikroorganizma kompozisyonu arasındaki ilişkinin belirlenmesini sağlayacaktır.

1.1. Çalışmanın Amacı ve Önemi

1900 başlarında uygulamaya konmuş aktif çamur sistemleri günümüze kadar büyük oranda uygulanmış, dünya çapında artık neredeyse sayısız denecek kadar evsel ve endüstriyel atıksuların arıtılmasında kullanılan aktif çamur arıtma, biyolojik arıtma sistemlerinin önemli bir kısmını oluşturmaktadır. Bu sistemler, özellikle organik madde ve askıda katı madde arıtımı ve uzaklaştırmasında dünyada yaygın bir şekilde kullanılmaktadır. Bu arıtma sistemleri yıllar içerisinde pek çok yeni konfigürasyonları ve proses uygulamaları ile sürekli gelişme göstermekle birlikte ilk geliştirildikleri ve uygulamaya konmalarından günümüze kadar geçen zaman içerisinde hemen hemen her birisinde ortaya çıkan en önemli problemlerden bir tanesi çamur kabarması ve köpük problemidir. Özellikle filamentli mikroorganizmaların neden olduğu kabarma problemi her bir biyolojik arıtma sisteminde ve daha sık ve ciddi bir problem olarak aktif çamur arıtma sistemlerinde periyodik olarak ortaya çıkmakta ve arıtma sistemlerinin performansını düşürerek işletim problemlerine neden olmaktadır. Oldukça maliyetli altyapı tesisleri olan arıtma sistemlerinin (burada özellikle aktif çamur sistemleri hedef alınmıştır) böylesine bir problemle aktif ve verimli kullanım ömürleri içerisinde defalarca bu probleme maruz kaldıkları bilinmektedir. Arıtma sistemi işleten operatörler ve mühendisler, uygulamalarda büyük problemler yaşamakta veya uygulamanın oldukça geç kalmasından dolayı problem yaşamaktadırlar. Bu problemin farkına varılması durumunda, zaten problem oldukça ilerlemiş, iyileştirilmesi ve önlenmesi ancak sistemin diğer bileşenlerinde yapılan değişiklik ve biyolojik parametre ve türlere yapılan zararlı uygulamalarla geçici olarak önlenebilmektedir (Övez, 2010).

Çamur kabarması ve köpük problemi, filamentli mikroorganizmaların genelde filamentli bakterilerin neden olduğu önemli bir biyolojik fazla çoğalma (filamentli mikroorganizma ve flok yapıcı organizmaların orantısızlığı) ve katı maddelerin (genelde flokların ve askıdaki katı maddelerin) fiziksel çökelme problemi (çökelmeme) oluşması durumudur. Literatürde verilen şekliyle bu problem filamentlerin sayısının fazla artması sonucunda birim hacimde yüzey alanının çok artması ve çamur yoğunluğunun suyun yoğunluğuna eşit veya daha az yoğunluğa ulaşması durumunda ortaya çıkmaktadır. Katı ve sıvı faz ayırımı yapılabilmesi normal gravitasyon çökelmesiyle mümkün olamamakta, katı-sıvı ayırımı hemen hemen hiç oluşmamaktadır. Bu durum imhoff hunisinde çökelme analizi ve çamur hacim indeksi (ÇHİ) analiziyle görülebilmektedir (Övez, 2010).

Atıksu arıtma tesislerinde verimin takip edilmesi için kritik çıkış parametresi olan ÇHİ günlük olarak izlenmesi gereken parametrelerdendir. ÇHİ hesaplanması geleneksel yöntemler ile yaklaşık 3 saatlik bir süre aldığı göz önünde bulundurulduğunda tahmin edilmesi ve buna göre prosesin yönetilmesi önem arz etmektedir.

Aktif çamur flokları, mikroorganizmalar, ölü hücreler, organik ve inorganik maddelerin karışımını içerir. Flok ve filamentlerin morfolojik karakterizasyonu aktif çamur durumunun değerlendirilmesinde önemli bir rol oynamaktadır.

Oluşan çamurlar her zaman için kolay kolay çökmez, ya doğru dürüst flok oluşmaz, ya da oluşan flok parçalanır, dağılır. Bu da arıtma verimini azaltır. ÇHİ değerlerinin genelde 100 ml/g değerinden küçük değerlerde çöktürme tankında sıvı-katı fazı ayırımı işleminde önemli bir problem ortaya çıkmamakta, çıkış suyu kalitesinde biyolojik oksijen ihtiyacı (BOİ) ve askıda katı madde (AKM) değerleri genelde arzulanan seviyeler de olmaktadır (Övez, 2010). Atıksu arıtımı konusunda sürekli olarak yeni teknolojiler geliştirilmekte ancak, bu teknolojilerin çoğu uygulamada teorikteki kadar başarılı olamamakta veya beklenen arıtım verimi alınamamaktadır.

Bu tez çalışmasında, görüntü işleme metotları ile yapay zekâ yöntemleri birlikte kullanarak atıksuların performansının izlenmesi amaçlanmıştır. Aktif çamur ünitesinden alınacak numunelerin flok ve filament yapıları incelenmiştir. Görüntü işleme ile elde edilen veriler, tesisten alınan klasik sonuçlar ile karşılaştırılmış ve su ve çamur kalitesi arasındaki bağlantılar araştırılıp, çamur ile ilgili önemli bir parametre olan ÇHİ değerinin tahmini yapılmıştır. Elde edilen sonuçlarla uygulamaya yönelik, kabul gören ve kompleks arıtma proseslerinde kullanılabilecek pratik değerlendirme araçları oluşturulması amaçlanmaktadır. Bu verinin tahmin edilebilmesi prosesin ayarlanabilmesini ve kabarma olaylarının tahmini sağlayacaktır. Aynı zamanda bu çalışmada, protozoaların yerlerinin hiçbir kullanıcı girişi olmadan otomatik olarak bulunması sağlanmıştır. Protozoaların floklarla çok benzer yapı göstermesi ve iç içe yer aldıklarından dolayı ayırt edilmeleri oldukça zordur. Aktif çamur sistemlerinde, protozoaların çıkış suyu kalitesi üzerinde öneme sahiptirler.

1.2. Çalışmanın Kapsamı ve Organizasyonu

Çalışma alanı olarak Konya Kentsel Atıksu Arıtma Tesisi seçilmiştir. Konya atıksularının arıtılarak insan ve çevre sağlığının korunması ile ülkemiz için büyük önemi

olan Tuz Gölü'nün korunması amacıyla 2005 yılında yapımına başlanan bu tesis, Haziran 2009 yılında tamamlanarak işletmeye alınmıştır. Konya Kentsel Atıksu Arıtma Tesisinde ileri biyolojik arıtma yöntemi uygulanmaktadır. Tesiste uygulanan arıtımın kademeleri; Fiziksel, biyolojik arıtma ve çamur susuzlaştırma şeklindedir.

Tez toplam sekiz bölümden oluşmakta ve aşağıdaki gibi organize edilmiştir:

Birinci bölümde, tez çalışmasının konusu, amacı ve önemi hakkında genel bilgi verilmiştir. Çalışmanın amacına uygun literatürdeki mevcut çalışmalara değinilmiştir.

İkinci bölümde, atıksuların arıtılması ve aktif çamur ünitesinde karşılaşılan problemlerden bahsedilmiştir. Konya Kentsel Atıksu Arıtma Tesisi hakkında bilgi verilmiştir.

Üçüncü bölümde, aktif kontur metodu, morfolojik işlemler, filtreleme gibi temel görüntü işleme tekniklerinden bahsedilmiştir.

Dördüncü bölümde, özellik çıkarma ve sınıflandırma yöntemleri anlatılmıştır. Yapay sinir ağları, genetik algoritma, arı algoritması hakkında bilgiler verilmiştir.

Beşinci bölümde, tesisten alınan mikroskobik görüntülerin bölütlenmesi için kullanılan yöntemler açıklanmıştır.

Altıncı bölümde, atıksu arıtma tesisinin proses kontrolü için yapay zeka teknolojilerinden faydalanılarak, görüntü işleme ile elde edilen parametrelerden, ÇHİ parametresi tahmin edilmiştir.

Yedinci bölümde, otomatik olarak protozoaların saptanması için bir görüntü işleme uygulaması geliştirilmiştir.

Sekizinci bölüm, tez çalışması ile ilgili genel sonuçları ve önerileri içermektedir.

1.3. Literatür Araştırması

Çevre mühendisliğinde arıtma proseslerinin görüntü işleme yöntemleri ile değerlendirilmesi ve modellenmesinin proses izleme ve kontrol yaklaşımlarında yeni açılımlar getireceği öngörülmektedir. Çamur hacim indeksinin görüntü işleme teknikleri kullanılarak tahmin edilmesinde son yıllarda gittikçe artmaktadır. Flokların morfolojik özelliklerini kullanarak elde edilen parametreler, kısmi en küçük kareler yöntemi ve YSA kullanarak ÇHİ tahmin çalışmaları yapılmıştır.

Literatürde genellikle flok ve filament yapıları görüntü işleme teknikleri ile incelenmiş ve bu şekilde aktif çamur hakkında bilgi elde edilmiştir. Nisar ve ark. (2012)

atıksu arıtma tesislerindeki aktif çamur flokların yapısını ve miktarını incelenmişlerdir. Elde edilen bu bilgilerin atıksu arıtma tesislerinde anormal olayların tahmininde yardımcı olabileceğini belirtmişlerdir. Ernst ve ark. 2006, Liwarska 2005, Boztoprak ve Özbay 2010, flok ve filamentli bakterilerin ayrıştırılması ve miktarlarının belirlenmesini görüntü işleme ile analiz etmişlerdir.

Grijspeerdt ve Verstraete (1997) çalışmalarında, aktif çamur çökelme özelliğini görüntü analizi ile incelemişlerdir. Flokların ortalama eşdeğer dairesel yarıçapı ile form faktör değerlerini kullanmışlardır. Çamurun çökelme özelliklerinin daha hassas olarak görüntü analiziyle elde edilebildiğini belirtmişlerdir.

Motta ve Amaral (2001) çalışmalarında, aktif çamur floklarının karakteristiklerini (eşdeğer yarıçapı ve fractal boyutu) ve filamentli bakterilerin uzunluklarını görüntü analizi ile incelemişlerdir. Flok özellikleri ile çamur hacim indeksi arasında bir ilişkinin kurulabildiğini, filamentli kabarma olaylarının ÇHİ'deki değişikliklerle ilişkili olduğunu göstermişlerdir. Önerilen metodun, kabarma olayların sınıflandırılması için nicel destek sağladığı belirtilmiştir.

Haliki ve ark. (2004) aktif çamur sistemlerinde kullanılan görüntü işleme uygulamalarıyla ilgili makaleleri incelemişlerdir. Görüntü işleme teknikleri flokların ve filamentli bakterilerin ölçümlerinde, kabarma olayların tahmininde ve flokların yerlerinin belirlenmesinde başarılı olduğu vurgulanmıştır.

Liwarska (2005) çalışmasında, mikroskobik incelemelerin gelişen teknolojisi sayesinde aktif çamurdaki organizmaların ve flok yapılarının ayrıntılı teşhisindeki önemini vurgulamıştır. Lazer tarayıcılı mikroskop ile mikrobiyal yapılar ve flok yapıları incelenmiştir.

Banadda ve ark. (2005) aktif çamur performansını değerlendirmede, aktif çamuru kimyasal olarak işlenmiş fabrika atığı sıvılardan ayırmak ve yoğunlaştırmak için sedimentasyon tankı kullanmışlardır. Filamentli kabarmanın erken teşhisi için görüntü analizi umut verici bir teknik olduğu belirtilmiştir. Hem floklar hem de filamentlilerin aktif çamur içinde tanımlanması ve karakterizasyonu için bir görüntü analizi metodu geliştirmişlerdir. Özellikle ÇHİ değerlerindeki artış ve azalışa göre kabarmayı önceden bilmeyi sağlayacak bir sistem oluşturmuşlardır.

Liwarska ve Bizukojc (2005) çalışmalarında, flok yapılarını incelemişler ve görüntü analizi ile aktif çamur flokların morfolojik parametrelerini hesaplamışlardır.

Biyolojik bozulma esnasında toplam askıda katı maddesi ile ortalama izdüşüm alanı (mean projected area) arasında lineer ilişki bulunmuştur.

Perez ve ark. (2006) üç farklı atıksu arıtma tesisinden alınan görüntülerden flok karakteristiklerini çıkarmışlardır. Bunlar; flokların eşdeğer yarıçapı, yuvarlaklık, gözenek özellikleri, fraktal boyutu gibi morfolojik parametrelerdir. Görüntü analizi için minumun 300 flok gerekli olduğu vurgulanmıştır. Flok ortalama boyutuna, dilusyonun (seyreltme) adımın önemli bir etkiye sahip olduğu, gözenek parametresi mikrobik kümelerin fraktal boyutuyla pozitif korelasyona sahip olduğu belirtilmiştir. Rika ve ark. (2007) çalışmalarında da aktif çamur yapısını yani flok ve filamentlerin özelliklerini, hızlı ve güvenilir karakterize etmek için görüntü işleme tekniklerini kullanmışlardır.

Mesquitaa ve ark. (2009) mikrobik kümelerin ve filamentli yapıların tanımlanması ve karakterize edilmesi için gereken aktif çamur dataların büyük bir çoğunluğunu, görüntü analizi ile elde etmişlerdir. Bu dataları kısmi en küçük kareler yöntemi kullanarak çamur çökelme özelliği ile serbest filamentli bakterilerin ve kümelerin boyutu, kümelerin morfolojik özellikleri arasında güçlü bir ilişki olduğunu belirtmişlerdir.

Mesquita ve ark. (2011a) çalışmalarında, aktif çamur prosesindeki anormaliklerin belirlenmesinde görüntü analizini kullanmışlardır. Görüntü işleme ile aktif çamur durumunu değerlendirmek ve gerçek zamanlı olarak aktif çamur atıksu arıtma sistemlerinin izlenmesinde oldukça umut verici olduğunu belirtmişlerdir.

Aktif çamur hacim İndeksinin tahmin edilmesinde görüntü işleme tekniklerinden de faydalanılmıştır. ÇHİ değerini tahmin ederek kabarma olaylarını incelemişlerdir (Rika ve ark., 2007). Han ve Qiao (2012 ve 2013) tahmin için yapay sinir ağlarını kullanmışlardır. Mesquita ve Dias (2009) flokların morfolojik özelliklerini kullanarak elde edilen 36 parametreyi, kısmi en küçük kareler yönteminde kullanarak aktif çamur sisteminin ÇHİ değerini tahmin etmişlerdir. Amaral ve ark. (2013) kısmi en küçük kareler analizi ile çamur hacim indeksi ve askıda katı madde parametrelerini tahmin etmişlerdir.

Mesquita ve ark. (2011b) görüntü analizi ile elde edilen parametreleri, aktif çamur sisteminde oluşabilecek çeşitli bozuklukları bulmak ve biyokütle karakterizasyonu için en önemli işlem parametreleri olan çamur hacim indeksi ve toplam askıda katı madde değerlerinin tahmininde bulunmuşlardır.

Ginoris ve Amaral (2007) aktif çamurdaki protozoa ve metazoa türlerin tanımlanmasında görüntü işleme, çok değişkenli istatistiksel teknikler ve yapay sinir

ağlarından faydalanmışlardır. Amaral ve ark. (2008) ise atıksularda çok sık bulunan kuyruklu protozoa türlerinin tanımlanmasında, yarı otomatik görüntü işleme ve çok değişkenli istatistiksel tekniklerini kullanmışlardır.

Yapay sinir ağların arıtma tesislerinde özellikle çevre verilerin tahmininde sıkça kullanılmıştır. Atıksu tesislerinin giriş çevre verileri kullanılarak çıkış çevre verileri tahmin edilmiştir. Civelekoğlu (2006) arıtma tesislerinin kontrolü için güvenilir ve sistematik değerlendirilme metotlarına ihtiyaç olduğunu belirtmiştir. Bu amaçla, arıtma proseslerine ait geçmişte elde edilen veriler, yapay zekâ metotları (yapay sinir ağları, adaptif ağ temelli bulanık çıkarım sistemi) ve çoklu istatistiksel yöntemleri (temel bileşen analizi ve çoklu lineer regresyon) ile değerlendirerek modellenmiştir.

Yılmaz (2009), atıksu arıtma tesisinin girişindeki günlük kimyasal oksijen ihtiyacı, günlük su debisi, günlük askıda katı madde, günlük toplam azot ve günlük toplam fosfor parametreleri girdi olarak kullanılarak günlük BOİ parametresini tahmin etmiştir. Ayrıca, en iyi sonucu veren modelin araştırılmasında çeşitli girdi kombinasyonları kullanılarak BOİ tahminleri yapılmıştır.

Oliveira-Esquerrel ve ark. (2002) biyolojik arıtım ünitelerini YSA ile modelledikleri çalışmalarında, değişkenler olarak giriş BOİ, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş debisini kullanmışlardır. İstatistiksel prensiplerin YSA model yapısında kullanılmasının model performansını önemli ölçüde arttırdığını belirtmişlerdir.

Pai ve ark. (2007) hastane atıksularının aktif çamur ile arıtıldığı bir tesisin YSA ile simülasyonunda AKM, BOİ, KOİ ve renk parametrelerini sistem parametresi olarak ele almışlardır. Mjalli ve ark. (2007)'de bir kentsel atıksu arıtma tesisinde KOİ, BOİ ve AKM değerlerinin çıkış suyundaki tahminini başarıyla yapmışlardır. Çınar (2005), evsel atıksu arıtma tesisi performansını BOİ, AKM ve fekal koliform parametreleri üzerinden izlemiş ve YSA modeliyle bu parametrelerin çıkış değerlerini tahmin etmiştir.

Hamed ve ark. (2004) evsel atıksu arıtma tesisine ait 10 aylık BOİ ve AKM verisi kullanılarak yaptıkları birkaç aşamalık eğitme sonucu tesisin bu parametreler bazında performansının doğru tahmin edilebildiğini göstermişlerdir.

Açıkalın ve ark. (2005) atıksu arıtma tesisi kirlilik parametrelerinden BOİ, KOİ ve AKM çıkış değerlerini tahmin etmek için YSA metodu kullanmışlardır. Model geliştirmede kullanılan veriler atıksu sıcaklığı, pH, ortalama debi, KOİ, BOİ ve AKM parametrelerinden oluşmaktadır. Adapazarı Kentsel Atıksu Arıtma Tesisi verilerini

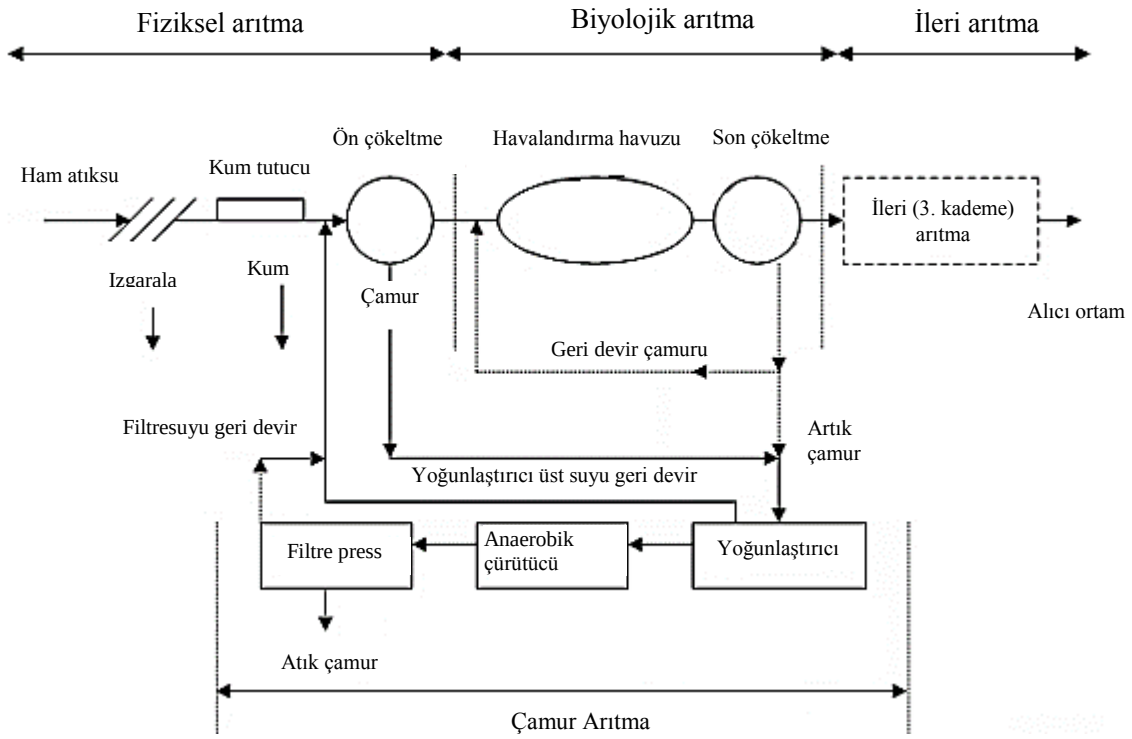
kullanılarak oluşturulan modellerden çok katmanlı algılayıcı modelinin, gerçek verilere oldukça iyi uyum sağladığı sonucuna ulaşmışlardır.

Yapay sinir ağlarının optimize edilmesinde genetik algoritmalar sıkça kullanılmaktadır. Ustun (2009) ileri beslemeli sinir ağlarındaki etkinlik fonksiyonlarının belirlenmesinde genetik algoritmalarını kullanmıştır. Blanco ve ark. (2001) recurrent sinir ağlarının eğitilmesinde kullanılan eğim algoritmaları yerine genetik programlama kullanarak ağ eğitimini gerçekleştirmişlerdir. Marwala (2007), markov zinciri tabanlı monte carlo tekniğini genetik programlamada kullanarak bayesian sinir ağının eğitilmesini gerçekleştirmiştir. Sexton ve Gupta (2000) sinir ağlarının eğitilmesinde genetik algoritmaları kullanmışlardır. Leung ve ark. (2003) ileri beslemeli sinir ağlarındaki bağlantı sayılarının optimize edilmesinde genetik algoritmalarını kullanmışlardır. Angeline ve ark. (1994) recurrent sinir ağının yapısal düzenlemesi ve bağlantı ağırlıklarının hesaplanmasında genetik algoritmaları kullanmışlardır. Pedrajas ve ark. (2006) recurrent sinir ağları için benzer bir çalışma gerçekleştirmişlerdir. Arifovica ve Gencay (2001) ileri beslemeli ağların düğüm sayısı katman sayısı gibi ağ yapısına yönelik parametrelerin belirlenmesinde genetik algoritmalarını kullanmışlardır.

Karaboğa ve Akay (2007) arı algoritmasını yapay sinir ağlarının eğitilmesinde kullanmışlardır. Arı algoritması ile elde edilen sonuçlar, farksal gelişim algoritması ve parçacık sürüsü optimizasyon algoritmaları ile karşılaştırılmıştır. Bu çalışma ile yapay sinir ağlarının eğitiminde ele aldıkları problemler için arı algoritmasının üstün bir performans sergilediğini göstermişlerdir. Baykasoglu ve ark. (2007) genelleştirilmiş atama problemleri için yapay arı kolonisi algoritmasını kullanmışlardır.

2. ATIKSU ARITMA TESİSLERİ

Atıksuların arıtma işlemi, mekanik, biyolojik ve kimyasal proseslerden oluşan arıtma kademelerinde gerçekleştirilir. Birinci kademe arıtma mekanik ve fiziksel proseslerden, ikinci kademe biyolojik proseslerden, üçüncü kademe ileri arıtma proseslerinden oluşur. Örnek bir atıksu arıtma tesisindeki işleyiş Şekil 2.1'de gösterilmektedir (Samsunlu, 2006).



Şekil 2.1. Atıksu arıtımı ve arıtma kademeleri (Samsunlu, 2006)

Atıksu arıtma yöntemleri birbirinden bağımsız değil, bir bütünün birbirini tamamlayan parçalarıdır. Arıtma işleminde hangi yöntem veya yöntemlerin kullanılacağı; arıtma işleminin hangi kademeye kadar sürdürülebileceği, deşarj yapılacak yüzeysel su için konulmuş su kalitesi limitlerine bağlıdır. Değişik karakterdeki atıksular için değişik arıtma yöntemleri kullanılabilir. Evsel atıksular için genelde fiziksel ve biyolojik arıtma yöntemleri tercih edilirken endüstriyel atıksuların arıtımı için kimyasal yöntemler kullanılmaktadır. Ancak, her üç yöntemin kullanıldığı arıtma sistemleri de mevcuttur. Atıksuyun, fiziksel, kimyasal ve biyolojik özelliklerinin bilinmesi, atıksuyun

toplanmasının, arıtılmasının ve deşarj edilmesinin planlanmasında ve yönetiminde önemlidir (Lin ve Lee, 2001).

2.1. Fiziksel arıtma

Atıksu içerisindeki özellikle katı maddelerin fiziksel işlemlerle atıksudan alınması amacı ile kullanılan proseslerdir. Atıksu içerisinde bulunan ve daha sonraki arıtma kademelerindeki işlemleri yavaşlatacak, engelleyecek ve ekipmanları bozacak özellikte, farklı boyutlardaki katı maddeler giderilir. Fiziksel arıtma birimleri aşağıdaki gibidir (Öztürk ve ark., 2006);

- Izgara / Elek / Öğütücü,
- Kum tutucu / Yağ tutucu,
- Ön çökeltme,
- Flotasyon (yüzdürme).

2.2. Biyolojik arıtma

Biyolojik arıtma, atıksu içerisindeki çözünmüş organik maddelerin bakteriyolojik faaliyetlerle ayrıştırılarak giderilmesi işlemidir. Bakterilerin arıtma işlemini gerçekleştirebilmeleri için pH, sıcaklık, çözünmüş oksijen, toksik maddeler gibi parametrelerin kontrol altında tutulması gerekmektedir. Çok sık kullanılan biyolojik prosesler (Öztürk ve ark., 2006);

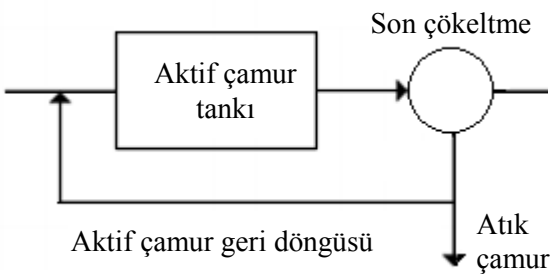
- Aktif çamur prosesleri,
- Havalandırmalı lagünler,
- Damlatmalı filtreler,
- Döner biyodiskler ve
- Stabilizasyon havuzlarıdır.

Bu proseslerin temel uygulamaları;

- Atıksuda özellikle BOİ veya KOİ olarak ölçülen organiklerin gideriminde,
- Nitrifikasyon,
- Denitrifikasyon,
- Fosfor giderimi,
- Atık stabilizasyonudur.

2.3. Aktif Çamur Sistemi ve Özellikleri

Aktif çamur prosesi 1914 yılında Ardern ve Lockett tarafından geliştirilmiştir. Aktif çamur arıtma prosesi, evsel ve endüstriyel atıksuların arıtımında günümüzde en yaygın kullanılan biyolojik arıtma prosesidir. Bu sistem; dengeleme, havalandırma, çöktürme ve dezenfeksiyon ünitelerinden oluşmaktadır. Aktif çamur koloidal çözünmüş maddelerin mikroorganizmalar ile çökebilir, biyolojik floklara dönüştürüldüğü prosestir ve bu proseste havalandırma havuzu içindeki mikroorganizmaların tutulması esastır. Biyolojik arıtma ünitesi havalandırma sonucu, organik maddelerin askıda büyüyen mikroorganizmalar tarafından parçalanması prensibiyle çalışır. Askıda büyüyen mikroorganizmalar suyun içerisinde bulunan organik maddeleri parçalayarak H_2O ve CO_2'ye çevirirler. Mikroorganizmaların organik maddeleri oksitlemesi sonucu organik maddeler ya okside olur ya da biyokütleye dönüşür. Havalandırma havuzundan gereken arıtma veriminin sağlanması amacıyla havuz içerisinde faaliyet gösteren mikroorganizma sayısını sabit bir değerde tutmak gerekmektedir. Bu nedenle biyokütlenin bir kısmı çöktürme kademesinde fazla çamur olarak sistemden atılırken diğer kısmı havalandırma bölümüne geri devrettirilir. Şekil 2.2'de biyolojik arıtma akış şeması gösterilmiştir (Şakar, 2009).



Şekil 2.2. Biyolojik arıtma akış şeması

Biyolojik arıtma tesislerinde en sık yaşanılan problemler ağırlıklı olarak çamur kabarması ve köpürmesidir. Çamur kabarması denilince akla gelen ilk unsur filamentli bakterilerin aşırı miktarda bulunmasıdır. Oysa aktif çamur dahilinde bir miktar filamentli bakteri bulunması flok oluşumu için oldukça faydalıdır. Filamentli bakteri eksikliği küçük, kolay parçalanabilen (toplu – iğne başı şeklinde) flok oluşmasına neden olur. Yaklaşık 20' ye yakın filamentli organizma türü vardır ve her biri arıtma tesisi işletilmesinde sorun yaşatabilir (Öztürk, 2007).

Aktif çamur organik ve inorganik maddeler içeren atıksu ile hem canlı hem de ölü organizmaların karışımıdır. İçinde çok değişik türde mikroorganizmalar bulunmaktadır. Organik madde cinsine, konsantrasyonuna ve diğer çevre faktörlerine (pH, sıcaklık, oksijen konsantrasyonu, toksik madde v.s.) bağlı olarak aktif çamur içindeki madde türleri değişmektedir. Aktif çamur içinde bakteri, fungus (mantar), protozoa, rotifer gibi türler çok yaygın olarak bulunan belli başlı mikroorganizmalardır (Öztürk, 2007).

Aktif çamur prosesine dayalı biyolojik arıtmalarda yetişen mikroorganizmalar tipik olarak, % 95 bakteri ve %5 ise yüksek mertebeli canlılardan (protozoa, rotifer, vb.) meydana gelir. Atıksuyun arıtımı esnasında organik maddeler mikroorganizmalar aracılığıyla parçalanmaktadır (Lin ve Lee, 2001; Dağ, 2002).

2.3.1. Çamur hacim indeksi

Çamur kabarması ve köpük problemi, genelde filamentli bakterilerin neden olduğu önemli bir biyolojik fazla çoğalma (filamentli mikroorganizma ve flok yapıcı organizmaların orantısızlığı) ve katı maddelerin (genelde flokların ve askıdaki katı maddelerin) fiziksel çökelme problemi (çökelmeme) oluşması durumudur. Literatürde verilen şekliyle bu problem filamentlerin sayısının fazla artması sonucunda birim hacimde yüzey alanının çok artması ve çamur yoğunluğunun suyun (süpernatantın) yoğunluğuna eşit veya daha az yoğunluğa ulaşması durumunda ortaya çıkmaktadır. Katı ve sıvı faz ayırımı yapılabilmesi normal gravitasyon çökelmesiyle mümkün olamamakta, katı-sıvı ayırımı hemen hemen hiç oluşmamaktadır. Bu durum imhoff hunisinde çökelme analizi ve çamur hacim indeksi analiziyle görülebilmektedir. Filamentli mikroorganizmaların normal bir flok yapısında olması gereken miktarlarıyla, problem oluşturmaya başladığı durumlardaki miktarları belirlenmiş ve flok başına düşen filament sayısı 5'ten fazla ise (mikroskop altında incelenen flok ta "sıklıkla her flokta 5 adetten fazla görünme") bu durum genelde kabarma ve köpük problemi ile özdeşleştirilmiştir. Bu sayılar flok başına belirtilen 5 adetin çok çok üzerine çıktığı ve 100'lerle ifade edilen miktarlara ulaşıldığı pek çok araştırmada analiz edilerek ifade edilmiştir (Jenkind ve ark., 1993). Bu arada flokların büyüklüğü ve makro düzey yapılarındaki farklılıklar da, çamur çökelmesi probleminin önemli parametrelerinin başında gelmektedir. Özellikle flokların küçük (≤150 μm), orta (150-500 μm) ve büyük (≥500 μm) boyutlarında olması, flok başına 1-5 filamentli mikroorganizma barındırması, zoogleal yapının "gevşek" veya

"sıkı" olması katı-sıvı ayırımında büyük önem taşımaktadır (Jenkind ve ark., 1993; Sezgin, ve ark., 1977).

Çamur hacim indeksi (ÇHİ) çamur flok yapısı ve çökelme özellikleri hakkında hızlı bilgi edinmek için kullanılan bir parametredir. Aktif çamur tesislerinde ÇHİ çamurun çökelmesini karakterize etmek için kullanılır ve değeri SM 2710 D standartlarına göre Eşitlik (2.1) ile hesaplanır (Eaton ve Franson, 2005);

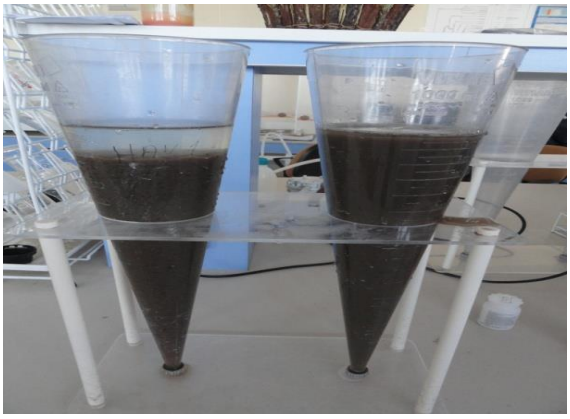
$$\text{ÇHİ (mL/g)} = \frac{\text{Çöken Çamur Hacmi}}{\text{AKM}} \text{x1000} \qquad (2.1)$$

Burada;
Çöken Çamur Hacmi: 30 dakika bekleme sonunda 1L çamurda mL cinsinden çöken çamurun hacmi.
AKM: Aynı aktif çamur örneğinde ölçülen askıda katı madde konsantrasyonu.

Aktif çamur tesislerinde çamur hacim indeksi sistemin performansını etkileyen önemli bir parametredir. Eğer ÇHİ değeri >150 mL/g ise çamur kabarması olduğu söylenir ve çamur çökelme problemi gözlenir. ÇHİ değerinin 50-100 mL/g arasında olması istenir (Mesquita ve ark., 2011b).

Çöken Çamur Hacmi: Belirli şartlar altında ve sürede bulunduğu kabın dibine çökelerek birikebilen ve genellikle sediment maddeleri, kaya zerreleri, çok ince kum, silt, çamur ve organik maddeleri ihtiva eden bir karışımdır. Çökelebilen katılar, evsel ve endüstriyel atıkların yanı sıra tuzlu ve yüzey sularında da tayin edilebilir. Metot belirli bir hacimdeki numunenin imhoff hunisin de belli bir zaman süresince bekletilerek dipte çökelen maddelerin ml/L olarak ifade edilmesi esasına dayanır (Peker, 2007).

Havalandırma tankından alınan 1 litrelik aktif çamur örneği iyice karıştırılarak imhoff hunisine doldurulur ve 30 dakika çamurun çökmesi için bekletilir. 30 dakika bekleme sonunda hunide sıkışan aktif çamur hacmi kaydedilir (SM 2710C) (Spellman, 2003). Şekil 2.3'de Konya Kentsel Atıksu Tesisinde kullanılan imhoff hunisinin görüntüsü verilmiştir.



Şekil 2.3. İmhoff hunisi (Konya Kentsel Atıksu Tesisi)

Askıda Katı Madde: Toplam Askıda Katı Madde, su numunesi içerisindeki çökebilen ve çökemeyen katı maddelerin toplamıdır. Sabit tartıma getirilmiş standart cam elyaf filtre kâğıdından süzülerek 103-105^{o}C'de kurutulmuş süzüntü kalıntısının ağırlığı AKM'yi ifade eder. Eğer askıda maddeler filtreyi tıkarsa ve süzmeyi uzatırsa bu durumda toplam katı ve toplam çözünmüş madde arasındaki fark, toplam askıda katı maddeyi verir. 105^{o}C'de CO_2'in kaybıyla bikarbonat karbonata dönüşür. Buharlaşmayla organik maddelerin kaybı çok azdır (Peker, 2007). Şekil 2.4'de Konya Kentsel Atıksu Tesisinde kullanılan kağıt filtreleri gösterilmiştir.



Şekil 2.4. Filtre kâğıtları (Konya Kentsel Atıksu Tesisi)

Filtrasyon düzeneği kurulduktan sonra 105^{o}C'de etüvde 1 saat bekletilip, desikatörde soğutulduktan sonra sabit tartımı alınmış filtre kâğıdı filtrasyon düzeneğine yerleştirilir. Şekil 2.5'de Konya Kentsel Atıksu Tesisinde kullanılan etüv ve desikatör içine konulmuş krozeler gösterilmiştir.



Şekil 2.5. Etüv ve desikatör içine konulmuş krözeler (Konya Kentsel Atıksu Tesisi)

Daha sonra çok iyi karıştırılmış belli (filtre kâğıdını kirliliğe bağlı olarak tıkamayacak hacimde) hacimdeki numune süzülür. Süzme işlemi bittikten sonra 2-3 dk. kadar vakuma devam edilir. Filtre kâğıdı pens yardımıyla dikkatlice etüvde bekletilerek darası alınmış cam bir tabla üzerine alınır ve 103-105^{o}C'de etüvde 1 saat kurutulmuştur. Desikatörde soğutularak tartma işlemi yapılmaktadır. Tartım sonuçları Eşitlik (2.2)'de verilen hesaplama yönteminde kullanılarak toplam askıda katı madde bulunur (SM 2540 D).

$$AKM(105℃, mg/L)=\frac{(A-B)\cdot 1000}{V} \qquad (2.2)$$

A= Filtre kâğıdı + kuru kalıntının tartımı,

B= Filtre kâğıdının tartımı,

V= Numune hacmi.

2.4. Aktif Çamur Tesislerinde Kabarma ve Köpük Oluşumu

Çamur kabarması aktif çamur prosesinin verimini etkileyen en önemli problemlerden biri olmuştur. Aktif çamur tesislerinde gözlenen çökelme problemleri aşağıda özetlenmiştir (Şahinkaya, 2007).

***Yumak oluşturmadan büyüme (Dispersed growth)*:** İyi işleyen bir arıtma tesisinde yumak oluşturmadan dağınık bulunan bakteriler, genellikle protozoalar tarafından tüketilir ve arıtılmış su oldukça temizdir. Eğer yumak oluşturmayan bakterilerin sayısı oldukça fazla ise, arıtımdan geçmiş su genellikle aşırı derecede bulanıktır. Bunun nedeni ise yumak oluşturma işleminden sorumlu bakterilerin sayısının

az olması veya bu işlevlerini yerine getirememeleridir. Bu tür çökelme problemi genellikle yüksek BOİ yüklemelerinde ve oksijenin yeterli olmaması durumunda gözlenebilir. Ayrıca, metal gibi toksik maddelerin varlığı da bu tür bir probleme neden olabilir (Şahinkaya, 2007).

Filamentli Olmayan Kabarma (Nonfilamentous bulking): Çamur kabarmasına, "zooglea kabarma" da denir ve aşırı miktarda hücre dışı polisakarit üretimi (Zooglea bakterileri tarafından) üretimi bu tür probleme neden olur. Çökelmeyi ve çamurun konsantre hale gelmesini engeller. Bu tür bir problem aktif çamur tesislerinde çok fazla gözlenmez ve genellikle havalandırma havuzuna az miktarda klor ilavesi ile giderilebilir. Bazı durumlarda, endüstriyel atıksularda azot miktarının yetersiz olması bu tür problemlere sebep olabilir. Ayrıca üretilen çamurun susuzlaştırılmasını da zorlaştırır (Şahinkaya, 2007).

Küçük ve ince Yumak Oluşumu (Pinpoint Floc formation): Bu tür ince yapıda yumak oluşumu; yumakların aktif çamur tesislerinde çökelmeden geçebilecek şekilde çok küçük parçalara bölünmesi nedeniyle oluşur. Daha önceki bölümlerde tartışıldığı gibi; filamentli bakteriler, yumaklara belkemiği vazifesi görerek, bakterileri bir arada tutar. Dolayısıyla, filamentli bakterilerin yeterli miktarda olmaması bu tür ince ve çökelmeyen yumakların oluşumuna neden olabilir (Şahinkaya, 2007).

Yüzen Çamur oluşumu (Rising sludge): Çökelme tankında denitrifikasyon nedeniyle çamur yüzme problemi oluşur. Özellikle çökelme havuzlarında yüksek bekleme zamanlarında, oksijen konsantrasyonu aşırı derecede düşer ve denitrifikasyon için uygun koşullar meydana gelir. Denitrifikasyon sonucu oluşan azot gazı, çamuru çökelme havuzunun üst tarafına kaldırır. Bu problem nedeniyle arıtma tesisi çıkışında su bulanık olur ve BOİ konsantrasyonu artar. Bu problemi gidermek için çökeltme tankında bekletme zamanı düşürülebilir (Şahinkaya, 2007).

Köpük Oluşumu: Bu problem Gordonia ve Microthrix türü bakterilerin havalandırma tankında aşırı derecede büyümesinden dolayı gerçekleşir. Aktif çamur tesislerinde gözlenen çamur problemleri Çizelge 2.1'de özetlenmiştir (Şahinkaya, 2007).

Çizelge 2.1. Aktif çamur tesislerinde gözlenen çamur problemlerinin sebepleri ve yol açtığı sorunlar (Şahinkaya, 2007).

Problem	**Problemin sebebi**	**Problemin etkisi**
Yumak oluşturmadan büyüme	Mikroorganizmalar yumak oluşturmaz	Bulanık çıkış ve zon halinde çamurun çökelmemesi
İpliksi olmayan kabarma	Aşırı derecede hücre dışı polimer üretimi	Çökelmenin kötü olması, çamurun sıkışmasının az olması, çamurun sudan ayrılamaması
Küçük ve ince yumak oluşumu	Küçük ve dağınık yumak oluşur. Az sayıda filamentli bakterinin olması nedenlerden en önemlisidir.	Düşük ÇHİ, bulanık çıkış suyu
Yüzen çamur oluşumu	Çökeltme tankında denitrifikasyon	Çökeltme tankı üzerinde çamur tabakası oluşur ve çamur çökmez.
Filamentli çamur kabarması	Aşırı derecede filamentli bakterilerin gelişmesi	Çok yüksek ÇHİ, temiz çıkış suyu, çamur iyi sıkışmaz ve çamur susuzlaştırılması zordur.
Köpük oluşumu	Arıtma tesisine aşırı derecede deterjan gelmesi, bazı bakterilerin aşırı büyümesi	Aktif çamur havalandırma havuzunda ve çökeltme tankında kalın bir köpük tabakası oluşur.

2.5. Konya Kentsel Atıksu Arıtma Tesisinin Genel Yapısı

Konya Su ve Kanalizasyon İdaresi (KOSKİ) Genel Müdürlüğü'nce Konya atıksularının arıtılarak insan ve çevre sağlığının korunması ile ülkemiz için büyük önemi olan Tuz Gölü'nün korunması amacıyla 2005 yılında yapımına başlanan Konya Kentsel Atıksu Arıtma Tesisi, Haziran 2009 yılında tamamlanarak işletmeye alınmıştır. Şekil 2.6'da Konya Kentsel Atıksu Arıtma Tesisi genel yerleşim planı gösterilmiştir (Küçükhemek, 2010).



Şekil 2.6. Konya Kentsel Atıksu Arıtma Tesisi genel yerleşim planı (Küçükhemek, 2010)

Konya Kentsel Atıksu Arıtma Tesisinde ileri biyolojik arıtma yöntemi uygulanmaktadır ve tesis 200.000 m^3/gün debi ve 1.000.000 eşdeğer nüfusa göre tasarlanmıştır. Tesiste arıtılmış atıksuların dezenfeksiyonu için ultraviyole dezenfeksiyon sistemi kurulmuştur. Tesiste arıtılan atıksuların potansiyel bir ilave su kaynağı olması nedeniyle, KOSKİ Genel Müdürlüğü 2007-2011 ve 2008-2010 Stratejik Planlarında "Atıksu Arıtma Tesislerinden elde edilen suyun tarımsal sulama suyu veya rekreasyon amaçlı kullanılması" hedeflenmiştir. Konya Kentsel Atıksu Arıtma Tesisinde arıtılan atıksuların üçüncül arıtma adı verilen daha ileri bir arıtmaya tabi tutularak kentsel yeşil alanlar için sulama suyu elde edilmesi projesinin ilk etabıdır. Bundan dolayı proje, yapımı tamamlanıp işletmeye alınan Konya Kentsel Atıksu Arıtma Tesisi Projesinin devamı konumundadır (Küçükhemek, 2010).

Konya Büyükşehir Belediyesi, KOSKİ Genel Müdürlüğü tarafından yürütülen Konya Kentsel Atıksu Arıtma Tesisi Projesinin I. kademesi, 200.000 m^3/gün debi ve 1.000.000 eşdeğer nüfusa 2015 yılına kadar hizmet edecek kapasiteye göre tasarlanmıştır. Tesis, I. kademe için karbon giderimi ve kısmi azot giderimine göre dizayn edilmiştir. Biyolojik arıtma sonrası çıkış suları ultraviyole dezenfeksiyon sisteminden geçirilerek deşarj edecektir. Çamur stabilizasyonu anaerobik çürütücülerde gerçekleştirilecek ve biyogazın kojenerasyon ünitesinde yakılmasıyla elde edilecek elektrik ve ısı enerjisi tesisin enerji ihtiyacı için kullanılacaktır. Tesisin ikinci kademesi (2030 yılı), 1.600.000 nüfusa hizmet verecek şekilde yeni ilave edilecek ünitelerle birlikte tesisin biyolojik kapasitesi 300.000 m^3/gün'e çıkarılacaktır. İkinci kademede tesiste karbon ve tam azot

giderimine ilave olarak fosfor giderim üniteleri de tesis edilerek AB standartlarında çıkış suyu elde edilecektir. Projenin yararları (Küçükhemek, 2010):

Çıkış suyunun deşarj edildiği Keçili Kanalı ile bu kanalın 122 km sonra ulaştığı Tuz Gölü ve çevresinde insan ve çevre sağlığının korunması ve iyileşmesinde önemli katkılar sağlanacaktır.

Yıllık 50 milyon m^3 (dezenfekte edilmiş) sulama suyu üretilmiş olacaktır. Anaerobik çürütücülerde üretilecek biyogazdan elde edilecek elektrik ve ısı enerjisi ile işletme maliyetlerinde önemli bir tasarruf yapılmış olacaktır. Tesisten çıkacak stabilize olmuş çamur tarımsal gübre veya toprak ıslahı amaçlı kullanılabilecektir.

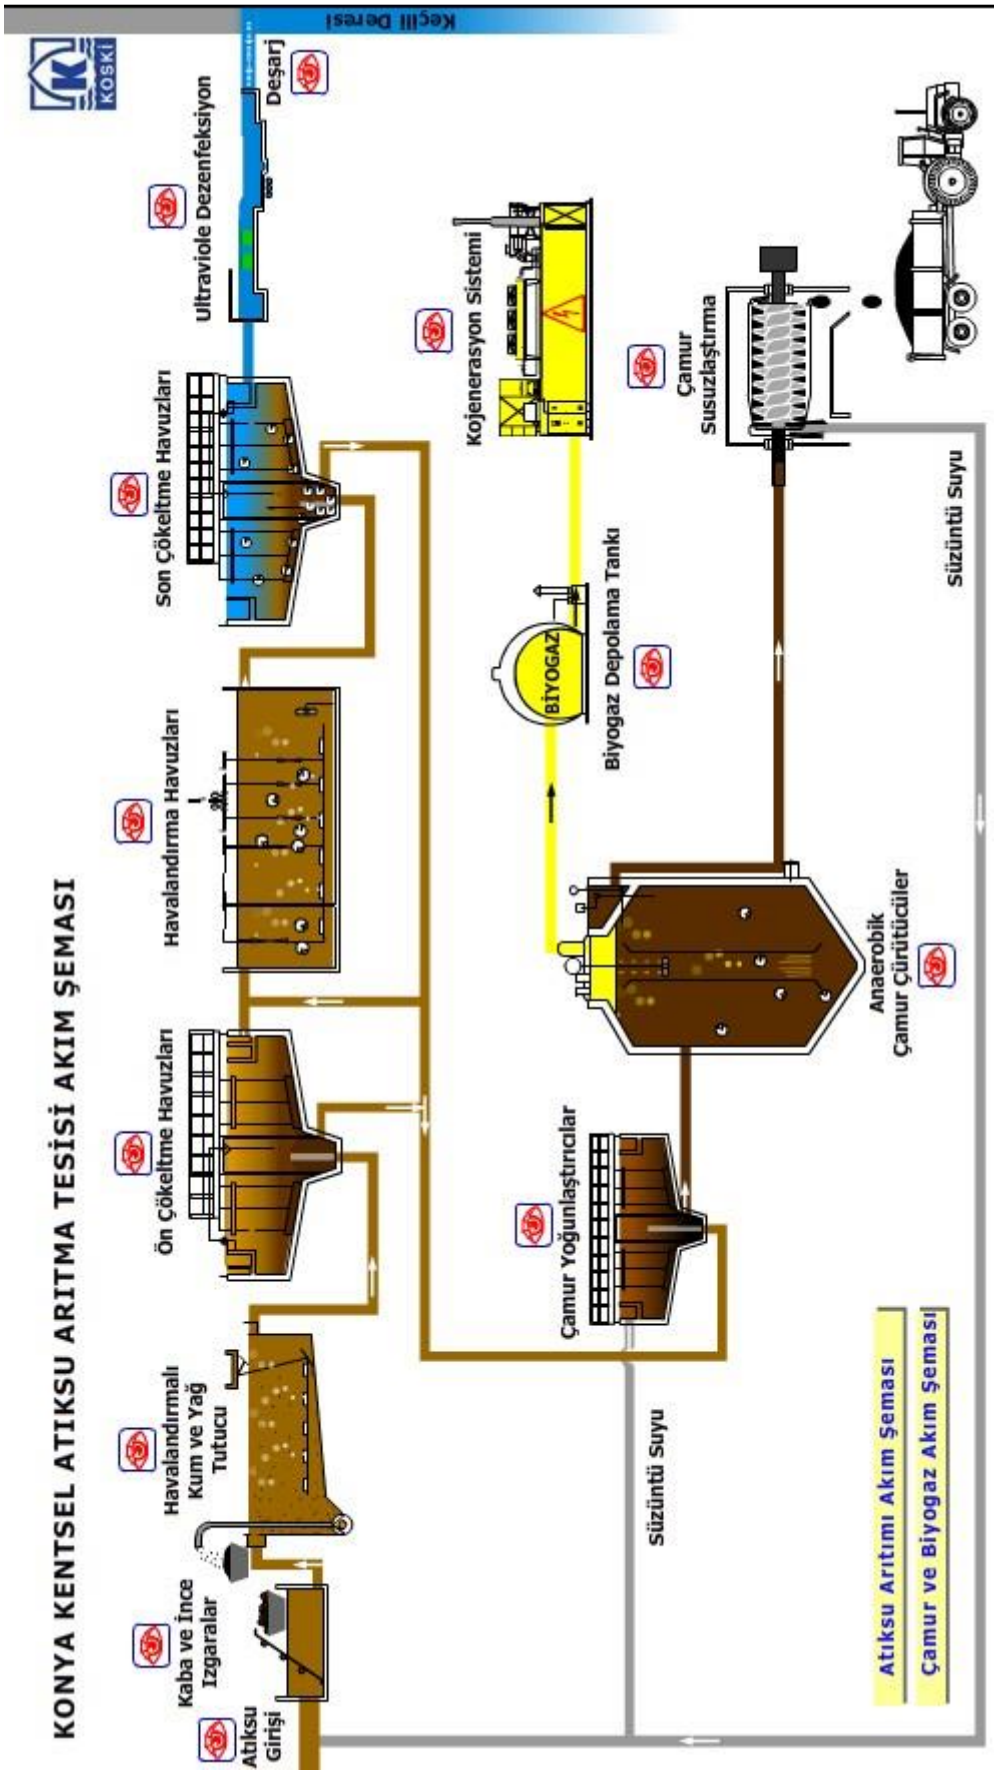
Tesisin giriş ve çıkış suyu kalite değerleri ve işletme verileri Çizelge 2.2'de, dizayn debileri ise Çizelge 2.3'de görülmektedir. Konya Kentsel İleri Biyolojik Atıksu Arıtma Tesisi proses akım şeması Şekil 2.7'de verilmiştir (Küçükhemek, 2010).

Çizelge 2.2. Konya Kentsel Atıksu Arıtma Tesisi giriş-çıkış su değerleri ve işletme verileri (Küçükhemek, 2010)

Parametre	**Giriş**	**Çıkış (I. Kademe)**
BOI_5, mg/L	320	< 20
KOI, mg/L	775	< 90
AKM, mg/L	295	< 20
TKN, mg/L	50	-
TP, mg/L	15	-
pH	6-9	6-9
Havalandırma Hattı Görüntü işleme numunelerinin alındığı ortam özellikleri		
Karışık sıvıdaki aktif çamur (mg/L)		7500
Çamur hacim indeksi ÇHİ, (ml/gr)		96
Çamur yaşı (gün)		11

Çizelge 2.3. Konya Kentsel Atıksu Arıtma Tesisi giriş ve çıkış suyu işletme verileri (Küçükhemek, 2010).

Parametre	**Birim**	**I. Kademe**	**II. Kademe**
Nüfus	kişi	1.000.000	1.600.000
Günlük ort. debi	m^3/gün	200.000	300.000
Maks. kuru hava debisi	m^3/gün	250.000	375.000
Pik debi	m^3/gün	400.000	600.000



Şekil 2.7. Konya Kentsel Atıksu Arıtma Tesisi proses akım şeması (Küçükhemek , 2010)

3. GÖRÜNTÜ İŞLEME TEKNİKLERİ

Görüntü işleme teknikleri ile sayısal görüntüler iyileştirilerek nesne tanıma, hedef tanıma gibi işlemler gerçekleştirilebilmektedir. Son derece güncel konularda uygulama alanı bulabilen görüntü işleme, teknolojinin gelişmesiyle artık çok daha hızlı olabilmekte ve bu sebeple fizik, sanat, biyomedikal, tıp, savunma sanayi ve otomobil sanayi gibi birçok alanda kullanılmaktadır. Görüntü işleme, amaca göre çeşitli işlemlerden oluşmaktadır.

3.1. Eşikleme

Görüntü işlemede kullanılan temel yöntemlerdendir ve bir görüntüyü parçalara ayırmanın en basit yollarından biridir. Eğer görüntüdeki ilgilenilen objelerin gri seviyesi biliniyorsa, ya da histogram yardımı ile tespit edilebiliyorsa, görüntü ilgilenilen detayı öne çıkarmak ve kalan detayları yok etmek için eşiklenebilir (Rangayyan, 2005). Eşikleme işlemi bir f görüntüsü üzerinde bütün pikselleri f(x,y) ile gösterecek olursak, bir T eşik değerine göre pikseller eğer arka plan üzerinde ise $f(x,y)<T$, değilse $f(x,y)\geq T$ olacaktır. Eşiklenmiş görüntü piksel değerleri g(x,y) Eşitlik (3.1) ile gösterilir (Gonzalez ve Woods, 2002).

$$g(x,y)=\begin{cases}1, & f(x,y)\geq T\\ 0, & f(x,y)<T\end{cases} \qquad (3.1)$$

Görüntüdeki piksellerin gri seviye değeri T eşik değerinden küçük ya da eşitse pikselin yeni değeri 0, büyükse 1 olarak alınır ve siyah-beyaz bir görüntü elde edilerek ikili forma çevrilir (Gonzalez ve Woods, 2002).

3.2. Filtreleme

Filtreleme, bir görüntünün iyileştirilmesi ya da değiştirilmesi amacıyla kullanılan komşuluk bölgesi (neighborhood) işlemlerine dayanan yöntemlerdir. Filtreler bir görüntüdeki istenen nesnelerin belirginleştirilmesi ya da bastırılması amacıyla kullanılırlar. Örneğin, alçak geçirgen bir filtre, benzer tonda homojen alanları

düzleştirerek, küçük detayları azaltıp sadeleştirmeye yarar. Yüksek geçirgen filtrelerse, ince detayları (kenar) belirginleştirir ve mümkün olduğu kadar çok detayı ortaya çıkararak netleştirir. Görüntü üzerine filtrelerin uygulanması; kontrastı arttırma, gürültü kaldırma, kenarlara vurgu yapma, bulma, şekli değiştirme gibi amaçlar içerir. Bir görüntü üzerinde doğrusal filtreleme konvolusyon ya da korelasyon operatörüyle uygulanır (Korkmaz, 2008). Filtreler çekirdek matris formundadır ve boyutları 3x3, 5x5, 7x7, 9x9, 11x11 şeklinde olabilir. Görüntüde elde edilmek istenen etkiye göre, değişik filtre maskeleri kullanılabilir (Özkan, 2010).

3.2.1. Ortalama filtre

Ortalama filtre özellikle gaussian tipi gürültü gidermede kullanılan alçak geçiren filtrelerdir ve görüntünün alt örneklenmesini ifade eder. Bir görüntüye, 3x3 boyutlu; h çekirdeği Eşitlik (3.2) kullanılarak konvolusyon işlemi uygulanırsa; görüntüde gürültü gideren bir alçak geçiren filtre elde edilmiş olur (Gonzales ve ark., 2004).

$$h = \frac{1}{9} \mathrm{x} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \qquad (3.2)$$

Ancak görüntüde düzleştirme etkisi sağlarken (smoothing), geniş çekirdek değerlerinde aşırı bulanıklaşmaya (blurring) neden olur.

3.2.2. Ortanca filtre

Düzgünleştirme metodunun en temel problemlerinden birisi, görüntü içerisindeki kenarların ve ayrıntıların zayıflamasıdır. Birçok alçak geçiren filtre uygulaması sonucunda gürültü büyük oranda süzülmekte fakat bulanıklaşmanın olması sonucu kenarlar ve ayrıntılar keskinliğini kaybetmektedir. Daha az bulanıklaşmaya karşılık gürültünün zayıflatılması için kullanılan alternatif bir yaklaşım median (ortanca) filtreleme metodudur. Buna göre median filtreleme işlemi, görüntüdeki her bir pikselin gri seviyesinin bu piksellerin komşuluğundaki gri seviyelerin toplamının ortalaması ile değil, median ile yer değiştirmesi mantığına göre çalışmaktadır. Eğer gürültünün etkisi çok büyük ise, o zaman bu filtreleme işlemi etkili olmaktadır (Gonzales ve ark. 2004).

Median filtre, piksellerdeki tuzbiber (salt-pepper) gürültüsünü, benek (speckle) ve dürtü (impulsive) gürültüsünü azaltmak için kullanılan doğrusal olmayan bir alçak geçiren filtre çeşitidir (Lim, 1990; Low, 1991; Schalkoff, 1989).

Seçilen filtre maskesinin tam ortasındaki hücre, görüntü içerisindeki her bir piksel üzerine gelecek şekilde median filtre kalıbı, iki boyutlu diziye aktarılmış olan sayısal görüntünün pikselleri üzerinde kaydırılır. Her bir kaydırma sonucunda kalıp içerisinde bulunan gri seviye değerleri küçükten büyüğe sıralanır. Sıralanan piksellerden ortadaki değer, çıkış piksel değeri olarak, görüntüde işlenen giriş piksel değerine atanır. Bu işlem, median filtre maskesinin, görüntüdeki bütün pikseller üzerine uygulanmasıyla tüm bir görüntü için gerçekleştirilir (Kızılkaya, 1997; Lim, 1990; Low, 1991; Schalkoff, 1989).

Kullanılan bir median filtrede çerçevenin büyüklüğü önemli bir parametredir. Çerçeve büyüklüğünün seçimi görüntünün içeriğine bağlıdır. Maskenin görüntü üzerine yerleştirilmesi durumunda, eğer maske içinde kalan gürültülü piksel sayısı kalıbın toplam piksel sayısının yarısına eşit veya daha fazla ise filtrenin performansı düşük olur. Bu nedenle optimal filtre boyutunu bulmak için, değişik boyutlarda median filtreler kullanarak elde edilen sonuçlara göre çerçeve boyutunu seçmek daha iyidir (Akar, 2006)

3.2.3. Gaussian filtre

Gauss dağılım fonksiyonu kullanılarak, standart sapmanın genişliğine bağlı bir çekirdek üretilir ve görüntüye uygulanırsa, görüntüde düzleştirme ve bulanıklık etkisi oluşturan alçak geçiren bir filtre elde edilmiş olur. Bulanıklık etkisini σ (sigma) belirler. Bu etkiyle beraber, tıpkı ortalama filtrelerde olduğu gibi taneli yapıdaki gürültüyü de kaldırır. Düzleştirme etkisi kuvvetli ve doğrusal difüzyon şeklindedir. 2B'lu gauss dağılımının Eşitlik (3.3) sayısal olarak kullanılmak üzere düzenlenmiş formülü Eşitlik (3.4)'de verilmiştir (Korkmaz, 2008).

$$G_\sigma(x,y) = \frac{1}{2\pi\sigma^2}\exp\left(-\frac{|x^2|+|y^2|}{2\sigma^2}\right) \tag{3.3}$$

$$G(i,j) = k*\exp\left(-\frac{i^2+j^2}{2\sigma^2}\right) \tag{3.4}$$

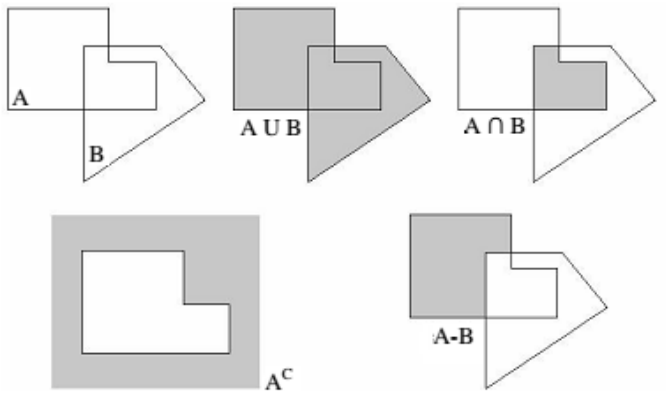
k; skaler bir sabittir ve görüntü yoğunluğunun ağırlık fonksiyonunun toplamından elde edilir. Bu değerler, k sabitine bölünerek normalizasyon sağlanır ve gaussian çekirdeği üretilir. Üretilen çekirdek, konvolusyonla orijinal görüntüye uygulanırsa, görüntüde doğrusal olarak, yön bağımsız (isotropik) difüzyonla düzleştirilmiş yeni görüntü elde edilir (Korkmaz, 2008).

3.3. Morfolojik İşlemler

Morfolojik işlemleri görüntünün objelerini belirgin haline dönüştürmek veya görüntünün objelerini ayırt etmek için kullanılmaktadır. Morfolojik işlemler gri seviyeli görüntülere veya ikili düzendeki görüntülere uygulanabilmektedir (Khan, 2013). İkili morfolojik operatörler görüntülerde eksik noktaların tamamlanması veya gürültü olarak nitelendirilebilen noktaların veya küçük nesnelerin kaldırılması gibi işlemlerde kullanılır. Bu işlemler matematiksel morfoloji ve küme teorisi kullanılarak gerçekleştirilir. Parmak izi tanımlamaları, hasar görmüş metinlerin yeniden oluşturulması, uydu görüntülerinin tamamlanması morfolojik işlemlerin kullanım alanlarından bazılarıdır (Arslan, 2011).

İkili görüntü yapısında, görüntü renk değerleri 1 bit ile ifade edilir. Dolayısıyla 2^1=2 renk değeri (0 siyah 1 beyazı ifade eder) sunar. Genellikle ‘0’ arka plan piksellerini, 1 de nesne piksellerini oluşturur. İkili görüntü yapısı görüntüdeki bazı özelikleri çıkarmak için kullanılabilir. 8 bit gri düzey görüntü ikili görüntü yapısına dönüştürüldükten sonra değişik işlemlere tabi tutularak istenen alan, kütle merkezi vb. nesneye ait özelikler görüntüden çıkartılabilir. Şekil 3.1’de ikili görüntü üzerinde uygulanan mantıksal işlemler aşağıdaki gibidir ve görüntü üzerinde gösterimi Şekil 3.1’de görülmektedir (Gonzalez ve ark., 2004).

$$\begin{aligned} &A \text{ or } B = A \cup B \\ &A \text{ and } B = A \cap B \\ &\text{not } A = A^c \\ &A \text{ and (not } B) = A - B \end{aligned} \tag{3.5}$$



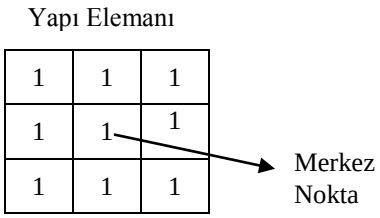
Şekil 3.1. İkili görüntü üzerinde uygulanan mantıksal işlemlerin gösterimi (Gonzales ve Woods, 2002)

Genişleme (dilation) ve aşınma (erosion), morfolojik işlemlerin temelidir ve birçok morfolojik teknik bu iki işleme dayanmaktadır.

3.3.1. Genişleme

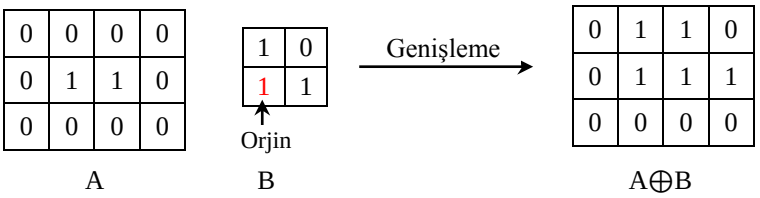
Genişleme işlemi temelde bir görüntüdeki nesneyi genişletmek veya kalınlaştırmak için kullanılır. Bu büyüme işleminin şeklini yapısal eleman tayin eder. Genişleme işleminin en basit uygulamalarından biri ikili görüntüdeki boşlukların kapatılmasıdır. $A \oplus B$ şeklinde gösterilen A'nın B ile genişleme işlemi matematiksel olarak Eşitlik (3.6) ile ifade edilebilir. Burada A ve B iki boyutlu tamsayı uzayının birer kümesidir. A ikili bir görüntü ve B elemanı "yapı elemanı (structuring element)" olarak belirtilen bir şablondur (Gonzales ve Woods, 2002; Acharya ve Ray, 2005).

$$A \oplus B = \left\{ z \middle| \left[\left(\hat{B} \right)_z \cap A \right] \subseteq A \right\} \tag{3.6}$$



Şekil 3.2. Yapı elemanı

Yapısal elemanın şekli elde edilecek sonucu belirler. Yapısal elemanı, baklava dilimi, disk, çizgi, kare, dikdörtgen gibi şekillerde tanımlanabilir veya bizim istediğimiz özel bir şekle sahip olabilir. Böylece nesne kenarları istenilen forma sokulabilir. Örneğin 3*3, 5*5 vb. bu matrisler görüntü üzerinde soldan sağa hareket ederler. Genişleme işlemini Şekil 3.3'deki gibi bir örnek ile açıklamak mümkündür (Gonzalez ve ark., 2004).



Şekil 3.3. Genişleme işlemi (Gonzalez ve ark., 2004).

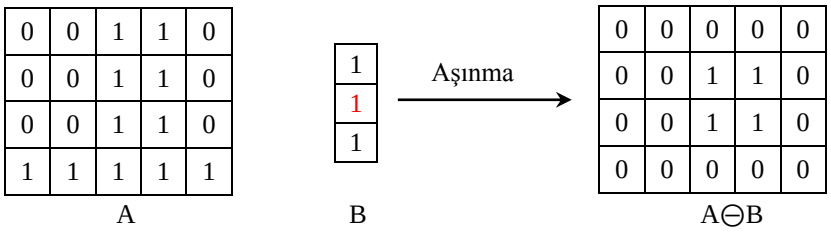
A genişleme işlemine tabi tutulacak olan ikili görüntü, B ise yapı elemanı olacak şekilde seçilir. Yapı elemanının orijini sırasıyla A'nın 1 olan her bir elemanı üzerine gelecek şekilde dolaştırılır. Bu esnada üzerine yapı elemanının 1 olan değeri karşılık gelen piksel değerleri 0 ise 1'e dönüştürülerek işlem yapılır. Sonuç olarak A⊕B genişletilmiş görüntüsü elde edilir (Gonzalez ve ark., 2004).

3.3.2. Aşınma

Aşınma (erosion) işlemi ise genişlemenin tersidir. Aşınma işlemi ile görüntüdeki bir nesneyi daraltma veya inceltme amaçlanır. Aşınma işlemi kullanılarak ikili görüntüdeki önemsiz ve küçük nesneler ortadan kaldırılabilir. A⊖B şeklinde gösterilen iki boyutlu tamsayı uzayının birer kümesi olan A'nın B ile aşınma işlemi matematiksel olarak Eşitlik (3.7)'de verilen ifade kullanılarak yapılabilir (Gonzales ve Woods, 2002; Acharya ve Ray, 2005).

$$A \ominus B = \{z | (B)_z \subseteq A\} \tag{3.7}$$

Aşınmada da genişlemede olduğu gibi aşınmanın şeklini yapısal eleman belirler.



Şekil 3.4. Aşınma işlemi (a)'da verilen görüntü (b)'de yapısal elemanı, (c)'de aşınma işlemi sonucu görülmektedir (Gonzalez ve ark., 2004)

A aşınma işlemine tabi tutulacak olan ikili görüntü, B ise yapı elemanı olarak seçilmiş olsun. A ikili görüntüsünün her bir pikseli üzerine B yapı elemanının orijini gelecek şekilde dolaştırılır ve yapı elemanın 1 olan tüm elemanları A'nın 1 olan elemanları ile eşleştiği noktalar 1 diğerleri 0 olacak şekilde işlem yapılır. Bu işlem sonucunda aşınmaya uğramış olan A⊖B görüntüsü elde edilmiş olur (Gonzalez ve ark., 2004).

3.3.3. Açma ve kapama

Pratikte genişleme ve aşınma işlemleri çoğunlukta beraber, değişik kombinasyonlarla kullanılırlar. Yani görüntü farklı veya aynı yapısal maske elemanlarıyla bir dizi genişleme ve/veya aşınma işlemlerine tabii tutulabilir. Aşınma işleminden sonra genişleme işlemi uygulanarak açma (opening) işlemi gerçekleştirilir. Açma işlemi ile görüntü içindeki küçük ve önemsiz nesneler ortadan kaldırılarak daha düzgün ve pürüzsüz bir görüntü elde edilir. Matematiksel olarak Eşitlik (3.8)'de verilen bağıntı ile ifade edilebilir (Gonzales ve Woods, 2002; Acharya ve Ray, 2005):

$$A \circ B = (A \ominus B) \oplus B \tag{3.8}$$

Kapama (Closing) işlemi görüntü işlemede yakın noktaların birleştirilmesi, şekildeki girintilerin veya çıkıntıların yok edilmesi gibi gereksinimlerde kullanılır. Kapama işleminde, öncelikle genişleme (dilation) işlemi yapılır. Daha sonra genişlemiş görüntüye aşınma işlemi uygulanarak kapama işlemi yapılır. Matematiksel olarak Eşitlik (3.9)'daki gibi ifade edilir. (Gonzales ve Woods, 2002; Acharya ve Ray, 2005).

$$A \bullet B = (A \oplus B) \ominus B \tag{3.9}$$

Kapama işlemi ise açmanın tersine kendisini aşınmanın takip ettiği bir genişleme işlemidir. Kapama işlemi de açmaya benzer olarak nesne sınırlarını yumuşatır. Açmadan farkı ise yapısal elemandan küçük olan girinti, kırık ve gözenekler kapatılır (Gonzales ve Woods, 2002; Acharya ve Ray, 2005).

3.3.4. Boşluk doldurma

Boşluk doldurma (Hole Filling) nesne içindeki boşlukların doldurulması için uygulanır. Öncelikle belirlenen iterasyon sayısı kadar genişleme işlemi yapılır. Daha sonra elde edilen sonuç 1 iterasyon aşınma işlemine tabi tutulur. Aşınma sonucu giriş görüntüsüyle lojik VE işlemine tabi tutulur. Aşınma ve lojik VE işlemi görüntü değişmeyinceye kadar uygulanır. Sonuç olarak, görüntünün içindeki boşluklar doldurulur (Gonzales ve Woods, 2002; Acharya ve Ray, 2005).

3.4. Görüntü Bölütleme

Görüntü bölütleme, görüntüdeki ilgili nesnenin arka plandan ayrıştırılması işlemidir. Amaç görüntüdeki piksellerden gerçek dünya da anlamlı bir nesneye karşılık gelecek kümeler oluşturulmasıdır. Bu işlem; yoğunluk, doku, gradient (eğim) veya benzeri bazı ölçülebilir özelliklerden faydalanılarak yapılabilir. Görüntü bölütleme, görüntü analizi ile ilgili bir problem olup görüntü işlemenin gösterim ve tanılama aşamalarına görüntüyü hazırlama işlemi olarak da tanımlanabilir. Görüntü içerisinde aynı parlaklıklara sahip nesne parçacıklarının belirlenmesi, sınıflandırma ve tanılama amacı için kullanılabilir. Ama tüm görüntülere uygulanabilecek genel bir bölütleme yöntemi yoktur ve bölütleme yöntemleri mükemmel değildir. Başka bir deyişle, görüntü iyileştirme ve onarma problemlerinde olduğu gibi görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin başarımları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik arz edecektir. Literatürde oldukça fazla bölütleme tekniği yer almaktadır (Fu ve Mui 1981, Haralick ve Shapiro 1985, Mitiche ve Aggarwal 1985, Pal ve Pal 1993, Bezdek ve ark. 1993, Clarke ve ark. 1995, Nixon ve Aguado 2002, Bezdek ve ark. 2005).

Bölütleme teknikleri aşağıdaki gibi sınıflandırılabilir (Bakman 2000, Gonzalez ve Woods 2002):

- Manuel, yarı-otomatik ve otomatik
- Piksel tabanlı (yerel metotlar) ve alan tabanlı (global metotlar)
- Manuel tarif, düşük-seviyeli bölütleme (eşikleme, alan geliştirme vb.) ve model tabanlı bölütleme (özellik haritalama teknikleri, dinamik programlama, kontur takibi vb.)
- Klasik (eşikleme, kenar tabanlı ve alan tabanlı teknikler), istatistiksel, bulanık ve sinir ağı teknikleri

Ortak kullanılan bölütleme teknikleri iki geniş kategoriye ayrılabilirler (Bankman, 2000):

- Verilen homojenite kriterine uygun alanlar arama esasına dayanan alan bölütleme teknikleri
- Farklı karakteristikler ile alanlar arasında sınırlar (kenarlar) arayan kenar tabanlı bölütleme teknikleri

Eşikleme bir ortak alan bölütleme metodudur. Bu teknikte bir eşik değeri seçilir ve görüntü piksel değerlerinin eşik değerinden büyük ya da küçük olmasına göre piksel grupları sınıflandırılır. Farklı eşikleme metotları vardır: Gri seviye histogramlarını temel alan global eşikleme, yerel özellikleri temel alan global metotlar, yerel eşik seçimi ve dinamik eşikleme.

Kümeleme algoritmaları, görüntüyü özellik uzayında birbirlerine oldukça benzerlik gösteren piksellerin kümelerine veya setlere ayıran alan bölütlemeyi kullanırlar. En basit işlem, her bir pikseli incelemek ve bu pikselleri, özelliklerini en iyi şekilde temsil eden kümeye dâhil etmektir. Alan geliştirme, önceden seçilmiş yakınlık kriterlerine göre görüntü değerleri birbirine yakın olan komşu pikselleri ya da alanları aynı segmente atayan diğer bir alan bölütleme algoritmasıdır.

Bölütleme neticesinde sadece aranan bölümlerin tutulması ve gereksiz kısımların görüntüden çıkarılması hedeflenir. İyi bölütlenmiş bir görüntünün özellikleri şu şekilde sıralanabilir (Özşen, 2004):

- Gri ton ya da doku gibi bir özellik açısından bölütlenmiş bir görüntüde düzenli ve türdeş bölgelerin elde edilmesi,
- Bölge içlerinin basit olması ve küçük delikler içermesi,
- Birbirine yakın fakat farklı bölgelerin düzgün oldukları özellik açısından farklı değerler alması,

- Bölge sınırlarının basit olması, girinti çıkıntı olmaması ve bölge sınırlarının uzamsal olarak doğru konumda bulunmasıdır.

3.5. Kenar Bulma Algoritmaları

Bir kenar, esas olarak iki farklı bölgeyi birbirinden ayıran sınırdır. Kenar bulma işlemi, bir görüntünün şiddet düzeyindeki belirgin lokal değişiklikleri tespit etme işlemidir (Acharya and Ray, 2005). Çoğu kenar bulma algoritmalarının amacı yerel türevleri hesaplamaktır. Kenarla yüksek bağlantılı benek değerleri değiştiğinde, yerel gradyan işlecin sonucu kenarın belirlenmesinde kullanılan yüksek değere sahiptir. Görüntü, f(x,y) şeklinde bir fonksiyon olarak ifade edildiğinden, görüntünün gradyanı Eşitlik (3.10) ile gösterilir (Acharya and Ray, 2005).

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} df/dx \\ df/dy \end{bmatrix} \tag{3.10}$$

Gradyanın boyu,

$$mag(\nabla f) = \sqrt{G^2+G^2} \tag{3.11}$$

ya da

$$mag(\nabla f) = |G_x|+|G_y| \tag{3.12}$$

şeklinde hesaplanır. Gradyanın yönü ise, Eşitlik (3.13) ile hesaplanır.

$$\theta(x,y) = \tan^{-1}\left(\frac{G_y}{G_x}\right) \tag{3.13}$$

Gradyan işlemi, biri x-yönündeki gradyanı, biri de y-yönündeki gradyanı hesaplamak için kullanılan iki maske gerektirmektedir. Görüntüde gradyan yaklaşık olarak,

$$G_x = f(i+1,j)- f(i,j)$$
$$G_y = f(i,j+1)- f(i,j) \tag{3.14}$$

şeklinde hesaplanabilir. Gradyan boyunu bulmak için aşağıdaki adımlar izlenir (Jahne, 2005) :

1. I görüntüsüne G_x ve G_y ile ayrı ayrı konvolüsyon işlemi uygula.
2. Ortaya çıkan iki görüntünün şiddet değerlerinin karesini al.
3. Görüntüleri topla.
4. Toplam görüntünün karekökünü al.

Pek çok araştırmacı tarafından türeve dayalı değişik kenar algılayıcılar geliştirilmiştir. Bunlardan en popülerleri, Roberts, Sobel, Prewitt ve Canny kenar algılayıcılarıdır. Her bir kenar algılayıcıda, verilen maskeler yardımı ile gradyan boyu hesaplanır. Eğer gradyan boyu belirli bir eşik değerinden yüksek ise, bir kenar algılandığı anlaşılır (Acharya and Ray, 2005).

3.5.1. Roberts operatörü

Roberts operatörü çapraz farkları hesaplamak için 2x2 lik komşulukları kullanır ve operatörün maskeleri Eşitlik (3.15) deki gibidir (Acharya and Ray, 2005).

$$\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \text{ ve } \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \tag{3.15}$$

Bu maskeler, sol üst elemanı işlenmekte olan piksel üzerine gelecek şekilde oturtulur. Bu iki maskenin mutlak değerlerinin toplamı ile gradyan boyu hesaplanır:

$$\text{mag}(\nabla f) = |f(i+1,j+1)-f(i,j)|+|f(i+1,j)-f(i,j+1)| \tag{3.16}$$

3.5.2. Sobel operatörü

3x3 lük komşulukları kullanan bir operatördür. Sobel operatörü konvolüsyon maskeleri Eşitlik (3.17) deki gibidir (Acharya and Ray, 2005).

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \text{ ve } \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \tag{3.17}$$

Bu iki maske görüntüye ayrı ayrı uygulanır, böylece G_x ve G_y değerleri aşağıdaki gibi bulunur.

$$G_x=[f(i-1,j-1)+2f(i-1,j)+f(i-1,j+1)]-[f(i+1,j-1)+2f(i+1,j)+f(i+1,j+1)]$$

$$G_y=[f(i-1,j-1)+2f(i,j-1)+f(i+1,j-1)]-[f(i-1,j+1)+2f(i,j+1)+f(i+1,j+1)] \quad (3.18)$$

Gradyan boyu, $|G_X| + |G_Y|$şeklinde hesaplanabilir.

3.5.3. Prewitt operatörü

Sobel Operatörüne benzemektedir. Farklı maske katsayıları vardır (Acharya and Ray, 2005).

$$\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \text{ ve } \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad (3.19)$$

Bir görüntüdeki kenarları bulmanın temel amacı, görüntü içerisinde istenilen detayları ortaya çıkarmak, istenmeyen detayları ise ortadan kaldırmaktır. Ayrıca görüntüye kenar bulma algoritmalarını uygulamak suretiyle görüntüdeki renk geçişlerini keskinleştirmek ve böylece görüntü içindeki objeleri ya da farklılıkları elde etmek mümkün olmaktadır. Görüntü keskinleştirme; elektronik baskı, medikal görüntüleme, endüstriyel muayene, güçlü silahların otomatik hedef tayini gibi pek çok alanda kullanılan bir görüntü işleme tekniğidir (Gonzales ve ark. 2004).

3.6. Aktif Kontur Modeli

İlk olarak Michael Kass, Adrew Witkin ve Demetri Terzopoulos tarafından ele alınmıştır ve 1988 yılında yayınlanarak literatüre girmiştir. Aktif kontur model (snake), bozulabilir modellerin (Deformable Models) özel bir durumudur. Bu yöntem Kass, Witkin, Terzoupulos tarafından 1988'de sunulduktan sonra pek çok uygulamada kullanılır hale gelmiş ve konuya farklı yaklaşımlar yapılmıştır (Kass ve ark., 1988). Orijinal aktif kontur modeller algoritmasında, snake geometrik olarak, görüntü düzleminde $(x,y) \in \Re$'de yerleşik, x ve y koordinat değerleriyle gösterilen bir parametrik konturdur. İki boyutlu bir kontur ifadesi; $s \in [0,1]$ (parametrik tanım kümesi elemanı) ve zamana bağımlı olmak üzere, $v(s) = (x(s), (y(s))^T$ şeklinde ifade edilir. Bir görüntüde

‘I(x,y)’, kontur özne şeklinin fonksiyonel olarak yazılımı Eşitlik (3.20)’de verildiği gibidir (Seker ve Eker, 2005).

$$E(v) = S(v)+P(v) \tag{3.20}$$

Fonksiyon kontur enerjisinin bir gösterimi olarak incelenir. Verilen fonksiyonun ilk terimi, iç deformasyon enerjisini (Eşitlik (3.21)), ikinci terim de görüntüye ait özellikleri (Eşitlik (3.22)) ifade eder. Algoritmada, bu enerjilerin dengelenmesi için uğraşılır.

$$S(v) = \int (w_1(s)\left|\frac{\partial v}{\partial s}\right|^2 + w_2(s)\left|\frac{\partial v}{\partial s}\right|^2)ds \tag{3.21}$$

İç enerji olarak adlandırılan S(v) konturun gerginlik ve esneklik bozulmalarıyla karakterize edilir. Kontur gerginliğini $w_1(s)$, katılığını da $w_2(s)$ kontrol eder.

$$P(v) = \int_0^1 P\big(v(s)\big)ds \tag{3.22}$$

Eşitlik (3.22)’de görüntü ile ilgilidir ve görüntü tarafından kontrol edilir. Algoritmayı çizgi ve kenarlar gibi görüntü detaylarına yönlendirir. Örneğin, bir görüntüde I(x,y), kontur seçilen kuvvet $P(x,y) = -c\left|\nabla\left[G_\sigma * I(x,y)\right]\right|$ tarafından, kenar yoğunluklarına doğru çekilecektir. Burada, c kuvvetin büyüklüğü, ∇ gradyent operatörü ve G_σ*I düzleştirme filtresi uygulandığını belirtir ve σ düzenlenen P’nin yerel minimasının uzamsal büyüklüğü ile tanımlanır. Uygulanan dış kuvvet, algoritmayı ilgilenilen bölgedeki en yakın yerel minimuma yönlendirir. Değişimlerin hesaplarla uyuşması yani kontur enerjisinin azaltılması Euler-Lagrange eşitliği ile çözümlenebilir (Seker ve Eker, 2005).

$$-\frac{\partial}{\partial s}\left(w_1\frac{\partial v}{\partial s}\right)+\frac{\partial^2}{\partial s^2}\left(w_2\frac{\partial^2 v}{\partial s^2}\right)+\nabla P\big(v(s,t)\big) = 0 \tag{3.23}$$

Aktif kontur model algoritmasında bu enerji minimizasyon probleminin çözümü, problemin de çözümü demektir. Eşitlik (3.23)’teki, x(s) ve y(s) için bağımsız olarak çözülebilen iki eşitlik haline getirilir. Uygulamada P ayrı bir fonksiyon olduğundan, bu eşitlikler analitik olarak çözülemez ve sayısal iteratif bir yöntemle çözüme gidilir. Ayrıca

algoritmada iç enerji dengede tutulmaya çalışılır. Algoritmada, gerginliği ve katılığı giderme manuel ya da otomatik olarak yapılabilir (McInerney ve Terzopoulos, 1996; Chan ve Vese, 2001). Bölütlemede kullanılan bu yöntemin bazı kısıtlamaları olduğundan, bu kısıtlamaların giderilmesi amacıyla geliştirilmiş birçok farklı yaklaşımı vardır. Çoklu düzey yaklaşımları, sonlu elemanlar yöntemi, düzey kümesi yaklaşımı ve gradyent vektör yaklaşımları gibi yöntemler sıralanabilir (Seker ve Eker, 2005).

4. ÖZELLİK ÇIKARMA VE SINIFLANDIRMA

4.1. Özellik Çıkarma

4.1.1. Şekilsel özellikler

- **Nesne Büyüklüğü (Alan) :** Nesnelerin büyüklüğü denince akla önce nesnenin alanı gelir. Piksel tabanlı bir görüntüleme sisteminde ise bu doğrudan cisme dâhil olan piksellerin sayılması ile elde edilir. Doğal olarak nesnelerin 2 boyutlu görüntülerinin gerçek görüntüleri ile eşleştirilmesi yapılırken mikroskobik incelemede cismin ancak dış çeperinin görünebildiği ve 3 boyutlu cisimlerin farklı yönlerden görülebileceği hesaba katılmalıdır. Ancak lam-lamel arası uzaklık belirli bir derinlik oluştursa da bunun minimum olduğu ve nesnelerin çoğunun yatay düzlemde görüldüğü varsayılmıştır. Şekil 4.1'de görüldüğü gibi bu durumda bir nesne için üç farklı alan bilgisi elde etmek mümkündür (Jain, 1989).



a) b) c)

Şekil 4.1. Farklı alan değerlendirmeleri a) net alan, b) içi dolu alan, c) çerçeveleyen (konveks) alan (Jain, 1989)

- **Çevre (Perimeter):** Bölgesinin çevre uzunluğudur (Jain, 1989).
- **Dışbükey Kabuk (Convex Hull):** Yaprak bölgesini çevreleyen en küçük dışbükey çokgendir (Govoreanu, 2004):
- **Dışmerkezlilik (Eccentricity):** Yaprak bölgesiyle aynı ikinci momente sahip elipsin dışmerkezliğinin sayısal büyüklüğü olarak ifade edilir (Math Works Inc., 2012). Odak mesafesi ve nesnenin o anda sahip olduğu elipsin en büyük eksen uzunluğu arasındaki orandır. Değeri 0 ile 1 arasında değişkenlik göstermektedir (Jahne, 2004).
- **Biçim katsayısı (Form Factor) :** Literatürde en sık kullanılan şekil özniteliği tanımlayıcılarından biridir. Biçim katsayısı Eşitlik (4.1) ile ifade edilmektedir (Govoreanu, 2004):

$$\text{Şekil Faktörü} = \frac{4\pi.(\text{Alan})}{(\text{Çevre})^2} \qquad (4.1)$$

- **Boy-En oranı (aspect ratio) :** (Govoreanu, 2004):

$$\text{Aspect Ratio (AR)} = 1+\frac{4}{\pi}\left(\frac{\text{Uzunluk}}{\text{Genişlik}}-1\right) \quad (4.2)$$

- **Gözenek (boşluk) miktarı:** Nesne içerisindeki boşluğun piksel miktarıdır.

$$\text{Gözenek} = \frac{\text{Dolu Alan}}{\text{Toplam Alan}} \quad (4.3)$$

- **Yuvarlaklık:** (Govoreanu, 2004):

$$\text{Yuvarlaklık} = \frac{4.(\text{Alan})}{\pi(\text{length})^2} \quad (4.4)$$

- **Kapsam (Extent):** Belirli bir bölge içerisindeki piksellerin, toplam çevreleyen dikdörtgenin içerisindeki piksellere oranını betimleyen sayısal değerdir. Nesnenin alanı ve sınır çerçevesinin alanı arasındaki orandır (Math Works Inc., 2012).

$$\text{Kapsam} = \frac{\text{Alan}}{\text{Çevreleyen dikdörtgenin alanı (bounding box)}} \quad (4.5)$$

- **Katılık (Solidity) :** Sağlamlık özelliği görüntü içinde etiketlenmiş nesnelerinin içerisinde yer alan boşluğun alana olan oranını ifade eder. Eşitlik (4.6)'da gibi ifade edilmektedir (Math Works Inc., 2012).

$$\text{Katılık} = \frac{\text{Alan}}{\text{Konveks alan}} \quad (4.6)$$

- **Eşdeğer dairesel yarıçap (De):** Alanı, karşılık gelen çap cinsinden ifade etmektir (Govoreanu, 2004):

$$\text{De} = \sqrt{\frac{4}{\pi}\text{Alan}} \quad (4.7)$$

Değişik şekillere sahip nesneler insan gözünü yanıltarak gerçek boyutla ilgili karar vermeyi zorlaştırabilir. Büyüklüklerin karşılaştırmasında basit ve kullanışlı bir parametre olarak karşımıza çıkmaktadır (Heijmans, 1994). Bunun yanında yuvarlaklık ölçütü olarak da kullanılabilir.

4.1.2. Yoğunluk tabanlı özellikler

- **Ortalama :** Bir alt karedeki bilgilerin ortalaması, o karenin genel parlaklık değerini verir ve Eşitlik (4.8)'deki gibi hesaplanır (Wu ve ark., 2008).

$$\bar{g} = \sum_{g=0}^{L-1} gP(g) = \sum_{r}\sum_{c} \frac{I(r,c)}{M} \qquad (4.8)$$

g: pikselin parlaklık değeri,
P(g) : g parlaklıklı pikselin tekrarlanma olasılığı,
I(r,c) : r,c kordinatlarındaki parlaklık değeri,
M: görüntüdeki piksel sayısı,
L: en büyük parlaklık değeridir.

- **Standart Sapma :** Standart sapma Eşitlik (4.9)'daki formülle hesaplanır (Wu ve ark., 2008):

$$\sigma_g = \sqrt{\sum_{g=0}^{L-1} (g-\bar{g})^2 \, P(g)} \qquad (4.9)$$

g: piksel değeri,
$\bar{g}$: piksellerdeki bilgilerin ortalama değeri,
P(g) : g pikselinin tekrarlanma olasılığıdır.

4.1.3. Entropi

Entropi kavramı, bir sistemin düzenliliğini ölçmek amacı ile termodinamik fiziğinde iyi bilinen bir kavramdır. İşaret/görüntü işlemede, özellikle de haberleşme sahasında ilk olarak Shannon kullanmıştır (Shannon, 1948). Entropi tabanlı kriterler verilen bir işaret/görüntü gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi ölçüm metodu durağan olmayan bir işaretin düzensizlik derecesini ölçmek için ideal bir araç olarak görünmektedir. Ayrıca, entropi kavramı bir olayın içerdiği bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır. Bu yönü ile görüntü içeriğinin ölçülmesinde de kullanılmaktadır. Bu, pek çok çalışmada netlik ölçüsü olarak kullanılır. Görüntünün gri seviyelerini kodlamak için kaç bite ihtiyaç duyulduğunu bulur. Piksel değerleri daha çok gri seviyeye yayıldıkça, entropinin değeri de artmaktadır (Gonzalez ve ark., 2003, Wu ve ark., 2008).

4.1.4. Gri seviye eş-oluşum matrisleri

Birinci derece öznitelikler sadece bir aydınlık değerinin görüntüde var oluşunu ve sıklığını gösterir. Çeşitli aydınlık değerinde piksellerin görüntüde birlikte konumlanması veya bir araya geliş sıklığı hakkında fikir edinmek için birliktelik (eş-oluşum) matrisleri görüntü üzerinde hesaplanır. Sıklık dağılımı ve birliktelik matrisi arasındaki farklılık şu şekilde açıklanabilir. Birliktelik matrisi, bir görüntüde belirli bir yönde ve uzaklıkta bir araya gelen piksel değerlerinin sıklık dağılımını gösteren bir matristir. Tek boyutlu sıklık dağılımı, diğer adıyla histogram, bir görüntüde belirli bir aydınlık şiddetinin ne kadar sıklıkla var olduğunu gösterirken, birliktelik matrisi belirli bir piksel ikilisinin ne sıklıkla var olduğunu gösterir. Sıklık dağılımı tek boyutlu bir veridir, birliktelik dağılımı iki boyutlu bir veridir. Sıklık dağılımı, görüntünün aydınlık değerlerinin tek başına varlığı hakkında bilgi verirken, birliktelik dağılımı görüntüde aydınlık değerlerinin birlikte yerleşimi hakkında bilgi verir. Birliktelik dağılımının verdiği bilgiler iki boyutlu yerleşim veya dizilimi gösteren bilgilerdir. Birliktelik matrisini tanımlayan ve bu matris üzerinden desen özelliklerinin hesaplanmasını öneren Haralick ve arkadaşları, bu matris için kendi makalelerinde griton yerleşimi bağımlılık matrisi adlandırmasını kullanmışlardır (Haralick ve ark.,1973).

Bir gri ton görüntünün N_x ve N_y pikselden oluşan dikdörtgen yapıda bir kesitten oluştuğunu varsayalım. Bu görüntüde, piksellere ait gri ton aydınlık değerleri N_g ayrı aydınlık düzeyinde örneklenmiş (bu düzeylerden en yakın olana atanmış) olsun. Matematiksel olarak birliktelik matrisi $P(i,j,d,0^o)$; yatay eksende (0^o yönünde) ve birbirlerine d adet piksel adımıyla tanımlı uzaklıkta komşuluğu olan i ve j aydınlık değerlerinde iki pikselin birlikte olma sayısı Eşitlik (4.10)'deki gibi tanımlanır (Haralick ve ark.,1973).

$$P(i,j,d,0^o) = \text{adet}\left\{(k,l),(m,n)\epsilon\left(N_g\times N_g\middle|(k-m)\right) = 0,\ |l-n| = d, I(k,l) = i, I(m,n) = j\right\} \tag{4.10}$$

Bu yaklaşımla oluşturulan birliktelik matrisi üzerinde $p(i, j) = P(i,j,d,0^o)/R$ olmak üzere (R normalleştirme sabitidir) aşağıda verilen desen öznitelikleri elde edilir.

$$\text{enerji} = \sum_{i=1}^{N_g}\sum_{j=1}^{N_g} p(i,j)^2 \tag{4.11}$$

$$\text{karşıtlık} = \sum_{n=0}^{N_g-1} n^2 \left\{\sum_{i=1}^{N_g}\sum_{j=1}^{N_g} p(i,j)\right\}, |i-j| = n \tag{4.12}$$

$$\text{ilinti} = \frac{\sum_{i=0}^{N_g-1}\sum_{j=0}^{N_g-1}(i,j) - \mu_x\mu_y}{\sigma_x\sigma_y} \tag{4.13}$$

$$\text{tekdüzelik} = \sum_{i=1}^{N_g}\sum_{j=1}^{N_g}\frac{1}{1+(i-j)^2}\ p(i,j) \tag{4.14}$$

İlinti hesaplamasında kullanılan μ_x, μ_y, σ_x ve σ_y sırasıyla $p_x(i)$ ve $p_y(j)$ olasılık dağılımlarından elde edilen ortalama ve standart sapma değerleridir. Bu dağılımların hesaplanması Eşitlik (4.15) ve (4.16)'de gösterilmiştir (Haralick ve ark., 1973).

$$p_x(i) = \sum_{j=1}^{N_g} P(i,j) \tag{4.15}$$

$$p_y(j) = \sum_{i=1}^{N_g} P(i,j) \tag{4.16}$$

4.1.5. Uzaysal frekans

Uzaysal frekans (SF) görüntüdeki toplam etkinlik seviyesini ölçer yani görüntüdeki piksel değerlerinin varyansını hesaplar (Eskicioglu ve ark., 1995). Başka bir ifadeyle yan yana duran iki piksel arasındaki farkı ölçer, bunun sonucunda da görüntünün netlik ölçüsüyle doğru orantılı bir değer ortaya çıkar. Boyutu N×M olan bir F görüntü için uzaysal frekans Eşitlik (4.17)'deki gibi tanımlanır (F(m,n), (m,n) konumundaki bir pikselin gri seviyesini ifade eder).

$$SF = \sqrt{(RF)^2+(CF)^2} \tag{4.17}$$

Burada RF satır frekansı;

$$RF = \sqrt{\frac{1}{MN}\sum_{m=1}^{M}\sum_{n=2}^{N}[F(m;n)- F(m,n-1)]^2} \tag{4.18}$$

CF ise sütun frekansıdır.

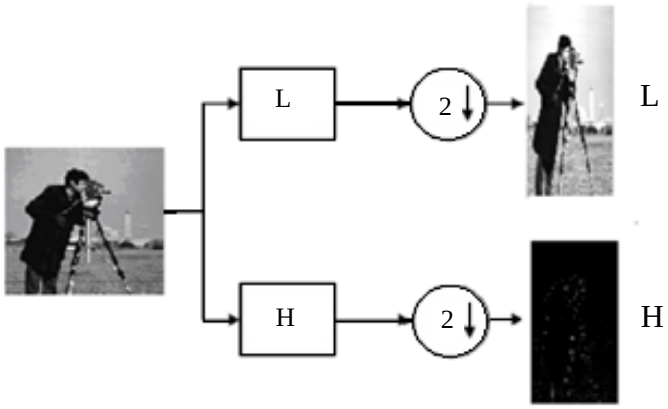
$$CF = \sqrt{\frac{1}{MN}\sum_{n=1}^{N}\sum_{m=2}^{M}[F(m;n)- F(m-1,n)]^2} \tag{4.19}$$

Görüntü bulanıklaştıkça uzaysal frekans değeri azalmakta olduğundan uzaysal frekans görüntü netliğini ölçmek için kullanılmıştır. Net görüntüdeki komşu piksel değerleri bir birinden daha uzak olmaktadırlar, yani sert bir geçiş sergilenmektedir.

Bulanık görüntüde ise bu tür geçişler daha yassı ve yumuşak olmaktadırlar (Aslantaş ve Pham, 2007).

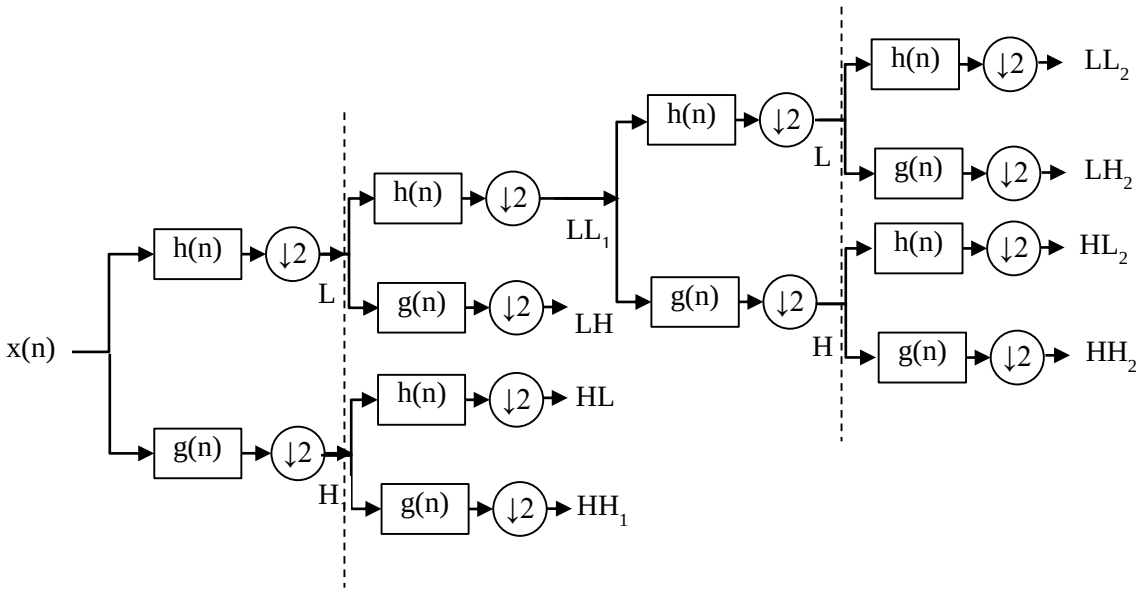
4.1.6. İki boyutlu ayrık dalgacık dönüşümü

Ayrık Dalgacık Dönüşümü (ADD), farklı kesim frekanslarında görüntünün sayısal olarak filtrelendiği bir yöntemdir. Sayısal filtreleme, ana dalgacık işlevinden elde edilen alçak ve yüksek geçiren süzgeç katsayılarının kullanılması ile yapılır. Görüntünün her bir satırı yüksek geçiren ve alçak-geçiren süzgeçten geçirilir. Her bir süzgecin çıkışı iki katsayısıyla aşağı-örneklenerek ara görüntüler olan L ve H'ın oluşumu sağlanır (Şekil 4.2) (Rajabli, 2005).



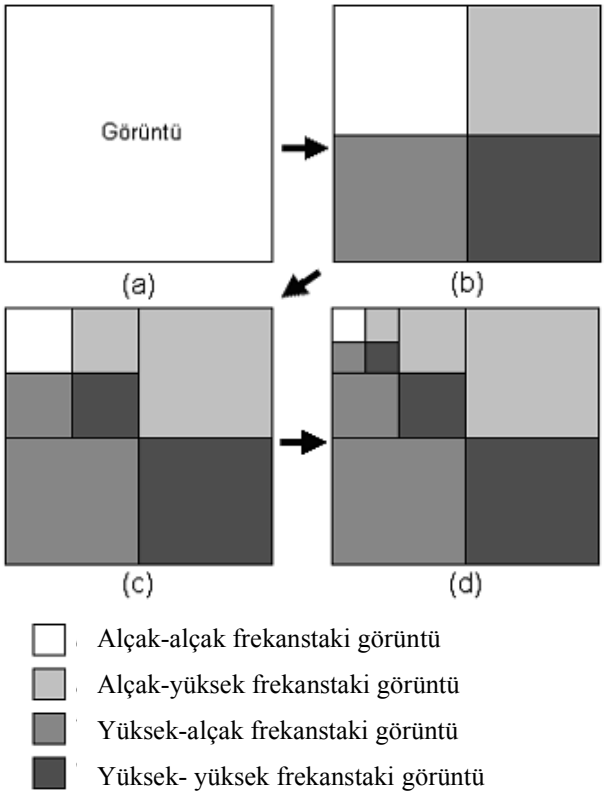
Şekil 4.2. İki boyutlu dalgacık dönüşümün ilk basamağı (Rajabli, 2005).

2 boyutlu görüntünün bir seviye ayrıştırılması ile LL, LH, HL ve HH alt bantları elde edilir. LL bandı yaklaşık görüntüye ilişkin katsayıları içerir. LH, HL ve HH ise yatay, dikey ve diagonal detay görüntülere ait katsayıları içerir. Dalgacık dönüşümünde bir sonraki seviye için ise LL bandına dalgacık dönüşümü uygulanır. Şekil 4.3'de 2 boyutlu bir görüntünün ayrık dalgacık dönüşümünün filtre bankası ile gerçeklenmesi verilmiştir (Dia ve ark., 2009).



Şekil 4.3. 2-Boyutlu Dalgacık Dönüşümünü (Dia ve ark., 2009).

Bir görüntüye dalgacık dönüşümü uygulanırken, görüntünün her satırı ve sütunu birer veri dizisi gibi düşünülecek olursa, önce tüm satırlara sonra tüm sütunlara dalgacık dönüşümü uygulanır. Şekil 4.4'de 3. seviye dalgacık dönüşümü için alt bant ayrıştırma şeması verilmiştir (Ceylan, 2009).



Şekil 4.4. Dalgacık dönüşümünün adımları 2 Boyutlu 3. Seviye ayrıştırma şeması (Ceylan, 2009)

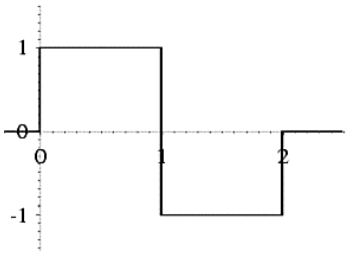
Dönüşümde kullanılacak olan bütün fonksiyonlar ana dalgacık tarafından üretildiği için, dalgacık dönüşümünün karakteristiğini ana dalgacık belirleyecektir. Bu yüzden uygulamalarda uygun dalgacık türünün seçilmesi büyük önem taşımaktadır. Dalgacık türü seçilirken dalgacığın şekline ve analiz edebilme yeteneğine bakılır (Gonzales ve Woods, 2002).

4.1.6.1. Dalgacıklar ve özellikleri

Dalgacık dönüşümüyle istenilen seviyede ayrışım yapılabilir. Çok seviyeli ayrışımda elde edilen detay (H) ve yaklaşık (L) katsayılarından yaklaşık katsayısı ile ayrışıma devam edilir ve bunun sonucunda yeniden L ve H işaretleri elde edilebilir. Ayrışım n seviyesine kadar yapılabilir.

4.1.6.2. Haar dalgacık dönüşümü

Haar dalgacığı ilk bilinen dalgacıktır. 1909 yılında Alfred Haar tarafından bulunmuştur (Şekil 4.5). Bu dönüşüm çeşidi aynı zamanda Daubechies D-2 dönüşümü olarak da bilinir. Mevcut dalgacık türleri içerisinde en basit olanıdır (Misiti, 1996).



Şekil 4.5. Haar dalgacığı (Misiti, 1996)

Haar dönüşümleri hem ayrılabilir hem de simetriktir. Haar dalgacığı Eşitlik (4.20) ile hesaplanır.

$$f(x)=\begin{cases}1 & 0 \le x < 1/2, \\ -1 & 1/2 \le x < 1, \\ 0 & \text{diğer}\end{cases} \qquad (4.20)$$

4.1.6.3. Daubechies dalgacık dönüşümü

Genellikle daubechies dalgacıkları en yüksek sayıda sönümleme momenti içerecek şekilde tasarlanmıştır. Daubechies dalgacık dönüşümlerinin D-2 ile D-20 arasında sadece çift sayılarda var olmak üzere çeşitli türleri mevcuttur. 2 den 20' ye kadar olan çift sayılar o dalgacık türünde kaç tane katsayı olduğunu belirtmektedir. Örneğin Haar dalgacığında (Daubechies D-2), bir tane sönümleme momenti bulunmaktadır. D-4 dalgacığı 2 tane momente sahiptir. Sönümleme momenti işaretin polinomsal olup olmadığı hakkında bilgi verir. Örneğin D-2 dalgacığı, tek momente sahiptir ve sabit bir işaret gibi tek dereceden bir polinoma kolaylıkla uygulanabilirdir. D-4 dalgacığı, ikinci dereceden bir polinoma uygulanabilir. Örneğin sabit veya doğrusal bir işarete uygulanabilir. D-6 dalgacığı üçüncü dereceden bir polinoma, örneğin sabit, lineer veya ikinci dereceden bir işarete uygulanabilmektedir (Misiti, 1996).

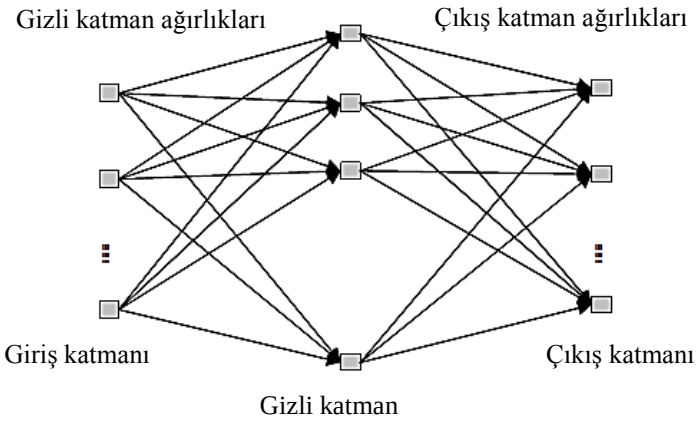
4.2. Sınıflandırma

4.2.1. Yapay sinir ağları

Yapay Sinir Ağları (YSA), insan beyninden yola çıkılarak geliştirilmiş, ağırlıklı bağlantılarla birbirine bağlı olan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. YSA, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır (Elmas, 2007). Yapay Sinir Ağları, olayların örneklerine bakarak onlardan ilgili olay hakkında genellemeler yapar, bilgi toplar, kendi deneyimlerini oluşturur ve daha sonra önceden hiç görmediği örnekler ile karşılaşınca öğrendiği bu bilgileri kullanarak o örnekler hakkında karar verebilmektedir (Öztemel, 2006). YSA herhangi bir ön şarta gerek duymaksızın lineer ve lineer olmayan modellere uygulanabilme yeteneğinin yanı sıra geleneksel olarak çözümü çok zor olan pek çok mühendislik probleminde alternatif bir yaklaşımdır.

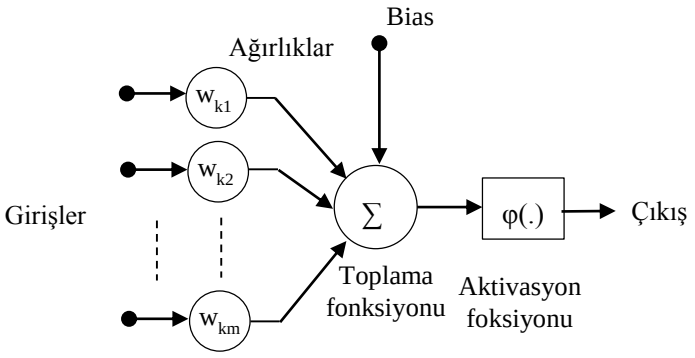
4.2.1.1. Yapay sinir ağlarının yapısı

YSA, yapay sinir düğümlerinin bir araya gelmesi sonucu oluşan yapılardır. Yapay sinir ağları üç ana bölümde incelenir; giriş, gizli ve çıkış katmanları. Şekil 4.6'da çok katmanlı bir yapay sinir ağı gösterilmiştir (Elmas, 2007).



Şekil 4.6. Çok katmanlı bir yapay sinir ağı (Elmas, 2007).

YSA elemanları ve bunlar arasındaki ilişkiler, Şekil 4.7'de gösterilmiştir (Öztemel, 2006). Bir yapay sinir hücresi girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere incelenmektedir.



Şekil 4.7. Yapay bir sinir düğüm yapısı (Haykin, 1999).

a) Girdiler

Giriş Katmanı: Yapay sinir ağına dış dünyadan girdiler bu katmana gelir. Bu katmanda, girdi sayısı kadar düğüm bulunmaktadır ve girdiler herhangi bir işleme uğramadan gizli katmana iletilmektedir. Giriş katmanındaki her bir düğümün birer adet girdisi ve çıktısı vardır. Ayrıca bu düğümler gizli katmandaki bütün düğümlere bağlıdır.

Girişler, bir yapay sinir düğümüne gelen bilgilerdir (x_1, x_2, x_3,…, x_N). Bu bilgiler dış ortamlardan ya da diğer sinir düğümlerinden gelebilir. Dış ortamlardan gelen bilgiler, ağın öğrenmesi istenen örneklerinden oluşmaktadır (Baş, 2006). Giriş değerleri, ağırlıkların belirlenmesinde ve dolayısı ile ağ eğitiminde önemli bir rol oynamaktadır (Altun ve ark., 2002).

Normalizasyon yapılan veriler yapay zekânın transfer karakteristiğine uygun ise elde edilen sonuçlar daha başarılıdır. YSA'nın logsig transfer fonksiyonu buna bir örnek olarak gösterilebilir. Özellikle YSA tabanlı çözüm arayışlarında transfer fonksiyonunun özel bir önemi vardır (Widrow 1990). Logsig transfer fonksiyonu, YSA uygulamalarındaki en yaygın kullanılan transfer fonksiyonudur ve verilerin normalizasyonunu -1 ile 1 veya (0-1 aralığı da uygundur) arasında olması mecburiyetini getirir (Vong, 2005).

Minimum-maksimum metodu: Bu metot özellikle literatürdeki mühendislik problemlerinde yaygın olarak kullanılır. Mühendislik çalışmalarında tıbbi veriler, görüntü verileri gibi veri setlerinde de yaygın olarak kullanılmaktadır. Minimum-maksimum modelinde yeni değerler Eşitlik (4.21)'den hesaplanabilir (Akdemir, 2009).

$$y=\left(y_{max}-y_{min}\right)*\frac{(x-x_{min})}{(x_{max}-x_{min})}+y_{min} \qquad (4.21)$$

Burada; x eski ve y yeni değer olmak üzere, x_{min} değeri veri içerisindeki minimum değeri, x_{mak} değeri maksimum değeri ve y_{max} ve y_{min} ise verinin taşınacağı aralığın alt ve üst değerlerini göstermektedir. Burada veri eğer 0 ile 1 arasına taşınmak isteniyorsa yukarıdaki ifade Eşitlik (4.22)'ye dönüşür.

$$y=\frac{(x-x_{min})}{(x_{max}-x_{min})} \qquad (4.22)$$

Bu metot veri setinin doğrusal bir transformasyonunu sağlar. Herhangi iki değer arasındaki fark ya da değerlerdeki büyüklüklerin orantısallığı değişmez. Sayısal veriler içerisinde negatif işaretli değerler olsa bile bu işaretler normalizasyon sonunda ortadan kalkar ve değerler pozitif işaretli hale gelirler (Akdemir, 2009).

b) Gizli Katmanlar

Giriş katmanından aldığı bilgiyi işleyerek bir sonraki katmana iletir. Gizli katman sayısı ve gizli katmandaki düğüm sayısı ağdan ağa değişebilir. Gizli katmanlardaki düğüm sayıları, girdi ve çıktı sayılarından bağımsızdır. Ayrıca birden fazla gizli katman varsa, bu katmanlardaki düğüm sayıları aynı olmayabilir. Gizli katman sayısı ve bu katmanlardaki düğüm sayısının artması, hesaplama karmaşıklığı ve süresini artırsa da YSA'nın daha karmaşık problemlerin çözümünde kullanılabilmesini sağlamaktadır.

c) Ağırlıklar

Düğümler arasındaki bağlantıların sayısal değerini ifade etmektedir. Bir düğüme gelen bilginin değerini ve düğüm üzerindeki etkisini gösterir (Öztemel, 2006). w_i, x_i girdisine karşılık gelen ağırlık değeri, N toplam girdi sayısı ve i, indis olmak üzere i=1..N' dir (w_1, w_2, w_3,..., w_N).

Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir (Elmas, 2007).

d) Toplama Fonksiyonu

Düğüme gelen girdileri ($X=x_1, x_2, x_3,\ldots, x_N$) ve ağırlıkları ($W= w_1, w_2, w_3,..., w_N$) kullanarak o düğümün net girdisinin hesaplanmasını sağlar. Toplama işlevi, sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamlarını eşik b_j değeri ile toplayarak aktivasyon fonksiyonuna göndermektedir.

e) Aktivasyon Fonksiyonu

Transfer, eşik veya işaret fonksiyonları olarak da adlandırılan aktivasyon fonksiyonları, düğümün davranışını belirleyen önemli unsurlardan biridir. Düğüme gelen net girdiyi işleyerek düğümün bu girdiye karşılık üreteceği çıktının belirlenmesini sağlar. Diğer bir ifadeyle düğümün çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla [-1, 1] veya [0, 1] arasındadır (Öztemel, 2006). Bilinen bazı aktivasyon fonksiyonları: Sigmoid, hiperbolik tanjant; doğrusal (lineer); adım (step) aktivasyon fonksiyonlarıdır.

f) Çıktılar

Gizli katmandan gelen bilgiyi işleyerek ve giriş katmanına gelen girdiye uygun olarak üretilen çıktıyı dış dünyaya gönderir. Çıkış katmanındaki düğüm sayısı birden büyük olabilir. Her bir düğüm bir önceki katmandaki bütün düğümlere bağlıdır. Her bir çıkış düğümlerinin bir adet çıktısı vardır (Kakıcı, 2009). Üretilen çıktı ya dış dünyaya, başka bir düğüme ya da kendisine girdi olarak gönderilebilir (Öztemel, 2006).

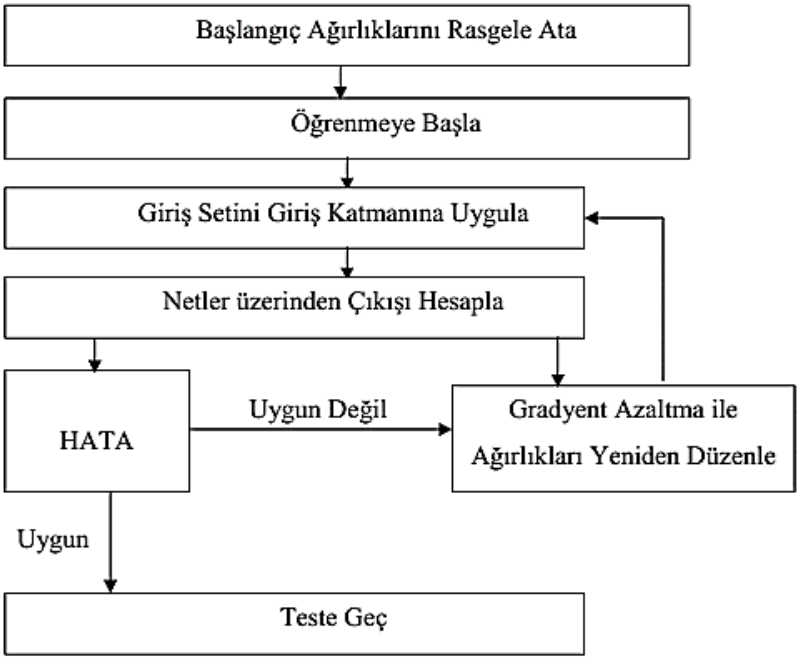
4.2.1.2. Geriye yayılım algoritması

Geri yayılım algoritması eğiticili öğrenmede kullanılan en genel algoritmadır. Basit olması ve iyi bir öğrenme kapasitesine sahip olması birçok alanda uygulanmasını sağlamıştır.

Uygulamalarda en yaygın kullanılan öğrenme algoritmasıdır. Anlaşılması kolay ve matematiksel olarak kolay ispatlanabilir olmasından dolayı en çok tercih edilen öğrenme algoritmasıdır. Bu algoritma hatayı çıkıştan girişe doğru azaltarak geldiğinden "Geriye Yayılım" adını almıştır MLP eğitmelerinde kullanılan en temel algoritmalardan biridir (Sağıroğlu ve ark. 2003; Rumelhart 1986).

Bu algoritmanın akış şeması Şekil 4.8'de verilmiştir (Akdemir, 2009). Bu algoritma ile i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ij}(t)$ değişikliği Eşitlik (4.23)'deki gibi hesaplanır.

$$\Delta w_{ji}(t)=\eta\delta_j x_i+\alpha\Delta w_{ji}(t-1) \qquad (4.23)$$



Şekil 4.8. Bir yapay sinir ağında geriye yayılım algoritmasının uygulaması (Akdemir, 2009)

Eşitlikte η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katmanındaki bir j nöronuna ait faktördür. Çıkış katı için bu faktör Eşitlik (4.24)'deki gibi ifade edilebilir.

$$\delta_j = \frac{\partial f}{\partial net_j}\left(y_j^{(t)} - y_j\right) \qquad (4.24)$$

Burada,

$net_j = \sum x_j w_{ji}$ ve $y_j^{(t)}$ ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki nöronlar için Eşitlik (4.25)'deki gibi ifade edilebilir.

$$\delta_j = \left[\frac{\partial f}{\partial net_j}\right]\sum w_{qi}\delta_q \qquad (4.25)$$

Ara katlardaki nöronlar için herhangi bir hedef çıkış olmadığından Eşitlik (4.24) yerine Eşitlik (4.25) kullanılır. Bu durumda çıkış katından başlayarak δ_j faktörü, bütün

katlardaki nöronlar için hesaplanır. Daha sonra Eşitlik (4.23)'deki eşitlikten ağırlıklar yeniden oluşturulur.

Bu bir kademeli olarak azalma algoritması olup, MLP yapılarını eğitmede kullanılan bir algoritmadır. Temelde istenilen çıkış ile ağ çıkışı arasındaki farkın ağırlıklara bağlı olarak düşürülmesi prensibine dayanır. Başarılı ve hızlı bir eğitim süreci için η ve α değerlerinin iyi ayarlanması gerekmektedir (Akdemir, 2009; Sağıroğlu ve ark., 2003).

4.2.1.3. Levenberg-Marquardt öğrenme metodu

Temel olarak bu algoritma maksimum komşuluk fikri üzerine kurulmuş en az kareler hesaplama metodudur (Levenberg, 1944). Genel olarak bu metot yavaş yakınsama problemi yaşamaz. Bunun en büyük nedeni bu metot Hessian matrisini kullanmadan 2. derece türevlendirilmiş değerlerden ağırlıkları hesaplar. Dolayısıyla Levenberg-Marquardt Metodu (LM) oldukça hızlı yakınsayan bir metot olarak karşımıza çıkar. Bununla birlikte rasgele atanan ilk başlangıç sayıları önemlidir (Akdemir, 2009).

E(w)'nin bir amaca yönelik hata değeri olduğunu varsayarsak m tane veri Eşitlik (4.26)'de verilir;

$$E(w)=\sum_{i=1}^{m} e_i^2 =\|f(w)\|^2 \qquad (4.26)$$

$$e_i^2(w)\equiv(y_i-yd_i)^2 \qquad (4.27)$$

Burada amaç fonksiyonu f (.) ve onun jakobiyeni J'nin bir noktada w bilindiği kabul edilir.

LM metodunda hedef, parametre vektörü w'nin E(w) minimum iken bulunmasıdır. Yeni vektör $w_{(k+1)}$, Eşitlik (4.28)'de gösterildiği gibi kabul edilen vektör w_k'dan hesaplanır.

$$w_{k+1}=w_k+\delta w_k \qquad (4.28)$$

δw_k Eşitlik (4.29) da verilmiştir.

$$\left(J_k^T J_k+\lambda I\right)\delta w_k=-J_k^T f(w_k) \qquad (4.29)$$

J_k: f'in w_k değerlendirilmiş Jakobyeni,

λ: Marquardt parametresi,

I: birim ya da tanımlama matrisidir.

Levenberg-Marquardt metodu aşağıdaki yönergeyi kullanır.

i. $E_{(wk)}$'yı hesapla
ii. Küçük bir λ değeri ile başla (0.01 gibi)
iii. δw_k için Eşitlik (4.29)'yı çöz ve $\delta w_{k+1} = w_k + \delta w_k$ değerinin hesapla
iv. Şayet $E(w_{k+} \delta w_k) \geq E(w_k)$ ise λ'yı 10 kat arttır ve iii'ye git
v. Şayet $E(w_{k+} \delta w_k) < E(w_k)$ ise λ'yı 10 kat azalt.
vi. $w_k : w_k \leftarrow w_{k+} \delta w_k$'yı güncelleştir ve adım iii'ye git.

Hedef çıkışı hesaplamak için bir MLP'nin LM metodu ile eğitilmesi w_0 değerlerinin atanması ile başlar. Bu atama ilk anda rastgele değerlerden oluşur. Daha sonra hatalarının karelerinin toplamını sıfır yapmak için metot uğraşır. Bu adımlama yukarıda bahsedildiği şekilde sürer (Akdemir, 2009).

4.2.1.4. Geri yayılım algoritması ile YSA'nın eğitimi

YSA'nın eğitilmesinde kullanılan öğrenme algoritmalarından biri olan geri yayılım algoritması, ileri beslemeli ve çok katmanlı bir ağ yapısı gerektirmektedir. Çok katmanlı bir geri yayılım ağı; bir giriş katmanı, bir çıkış katmanı ve en az bir gizli katmandan oluşur. Geri yayılım algoritması, danışmanlı öğrenme yöntemlerinden birisidir ve giriş katmanı – gizli katman, gizli katman – gizli katman ve gizli katman – çıkış katmanı arasındaki ağırlıkların, ağ çıkışında meydana gelen hataya bağlı olarak optimize edilmesini amaçlamaktadır. Giriş ve ilgili çıkış vektörü ağı eğitmek için kullanılır. Giriş vektörü, ağın giriş katmanına verildikten sonra ağırlıklar vasıtası ile aradaki gizli katmanlardan geçerek en sondaki çıkış katmanına ulaşır. Ağdaki her bir düğüm, kendisinde sonlanan ağırlık vektörlerinin aritmetiksel toplamını aldıktan sonra sonucu, kullanılan aktivasyon fonksiyonuna bağlı olarak kendinden sonraki katmanın tüm düğümlerine aktarır (Altun ve ark., 2002).

Giriş katmanına gelen girdiler herhangi bir işleme uğramaksızın gizli katmana ağırlıklar vasıtası ile iletilirler. Gizli katmana gelen net girdi toplama fonksiyonu yardımı ile hesaplanır, aktivasyon fonksiyonundan geçirilir. Böylece gizli katman çıkışları hesaplanır ve elde edilen çıkışlar çıkış katmanına iletilir. Eşitlik (4.30)'de, I giriş katmandaki düğüm sayısı, S gizli katmandaki düğüm sayısıdır. r giriş katmanındaki ilgili düğümün indisi, c gizli katmandaki ilgili düğümünün indisi olmak üzere r=1, 2, ..., I ve c=1, 2, …, S' dir. x_r, giriş katmanındaki r. düğümden gizli katmandaki c. düğüme gelen girdiyi, w_{rc} ise bu iki düğüm arasındaki ağırlığı, net_c gizli katmandaki c. düğüme gelen net girdiyi ifade etmektedir. Eşitlik (4.31)' de y_c, c. düğümün çıkışıdır, hesaplanmasında sigmoid aktivasyon fonksiyonu kullanılmıştır. Bu fonksiyonun türevi ise Eşitlik (4.32)' te verilmiştir (Öztemel, 2006).

$$net_c = \sum_{\substack{r=1,\\ c=1}}^{I,S} (w_{rc} x_r) \tag{4.30}$$

$$f(net_c) = \frac{1}{1+e^{-net_c}} = y_c \tag{4.31}$$

$$f'(net_c) = (y_c - y_c \times y_c) = y_c(1-y_c) \tag{4.32}$$

Gizli katman çıkışları ağırlıklar vasıtası ile çıkış katmanına iletilirler. Eşitlik (4.33)' de, O çıkış katmandaki düğüm sayısıdır. o çıkış katmanındaki ilgili düğümün indisi olmak üzere o=1, 2, ..., O' dur. w_{co} ise gizli katmandaki c. düğüm ile çıkış katmanındaki o. düğüm arasındaki ağırlığı, net_o çıkış katmanındaki o. düğüme gelen net girdiyi, Eşitlik (4.34)' de y_o ise o. düğümün çıkışını ifade etmektedir (Öztemel, 2006).

$$net_o = \sum_{\substack{o=1,\\ c=1}}^{S,O} (w_{co} x_c) \tag{4.33}$$

$$y_o = \frac{1}{1+e^{-net_o}} \tag{4.34}$$

Geri yayılım algoritmasında kullanılan karesel ortalama hata (MSE) hesabı Eşitlik (4.35)'de verilmiştir. Burada P değeri, toplam örnek sayısını p=1,2,3,..,P olmak üzere örnek indisini ifade etmektedir. Gerçek çıkış değeri y_{op} olan p. örneğin ağa gösterilmesi ile elde edilen çıkış değeri y_p'dir. Elde edilen hatanın geri yayılması ile ağırlıklar güncellenir. Ağırlıkların güncellenmesinde delta kuralı kullanılır. Gizli–çıkış katman ağırlıklarının güncellenmesinde (4.36), (4.37) ve (4.40) Eşitlikleri kullanılır. Giriş–gizli katman ağırlıklarının güncellemesi ise (4.38), (4.39) ve (4.41) Eşitlikleri ile yapılır (Batar, 2005; Sezer, 2008). λ, öğrenme katsayısı ve δ ise ilgili düğümün eğimidir.

$$\text{MSE=hata=}\frac{1}{2P}\sum_{p=1}^{P}(y_p\text{-}yo_p)^2 \tag{4.35}$$

$$\delta_c=\text{hata}\times y_o(1-y_o) \tag{4.36}$$

$$\Delta w_{co}=\lambda\times\delta_c\times y_c \tag{4.37}$$

$$\delta_r=w_{co}\times\delta_c\times y_c(1-y_c) \tag{4.38}$$

$$\Delta w_{rc}=\lambda\times\delta_r\times x_r \tag{4.39}$$

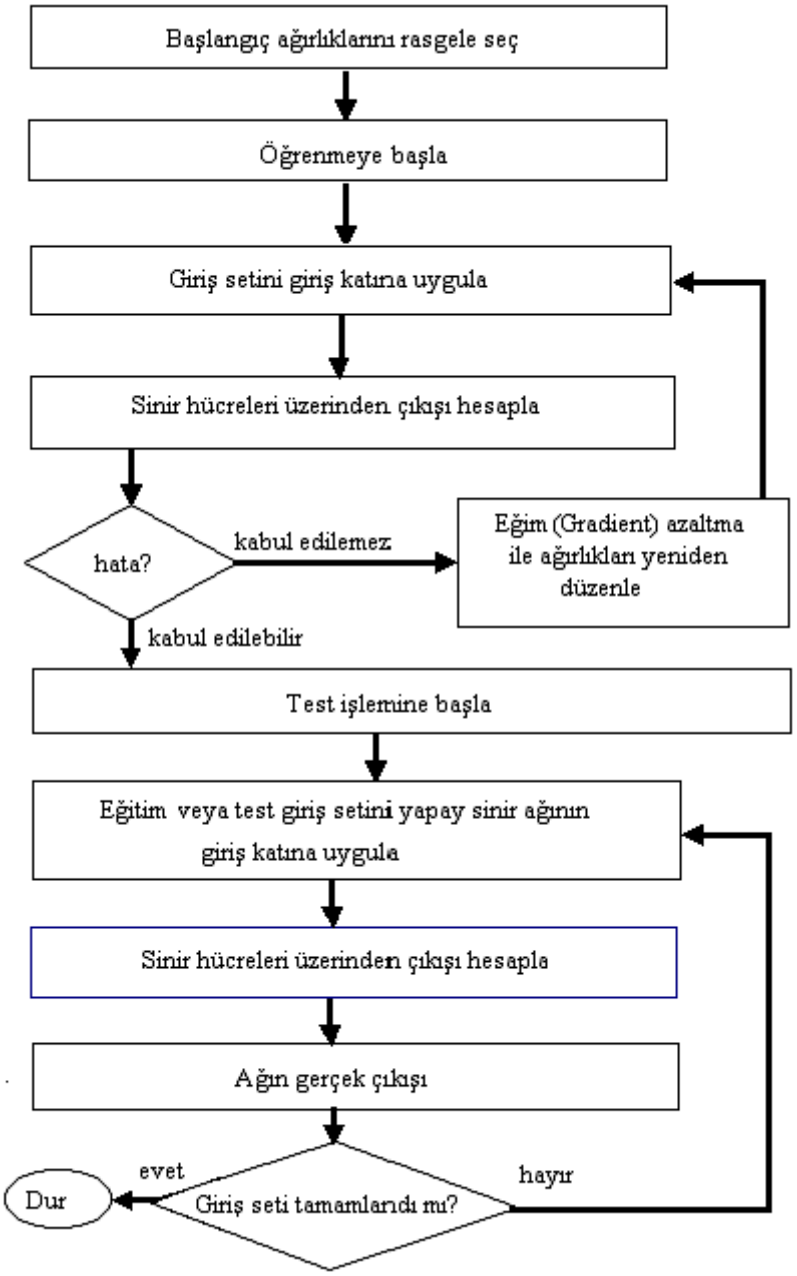
$$w_{co}(n+1)=w_{co}(n)+\Delta w_{co} \tag{4.40}$$

$$w_{rc}(n+1)=w_{rc}(n)+\Delta w_{rc} \tag{4.41}$$

Öğrenme Katsayısı (λ) : (4.37) ve (4.39) Eşitliklerinde kullanılan öğrenme katsayısı, ağırlıkların bir sonraki adımda hangi oranda değiştirileceğini gösterir. Öğrenme katsayısı küçük seçildiğinde, ağın sonuca ulaşması yavaşlar, büyük seçildiğinde ise ağ daha kısa sürede sonuca ulaşır. Ancak çok yüksek değer seçilmesi hesaplamalarda büyük salınımlara neden olur ve ağın optimum noktayı bulmasını engelleyebilir (Kulluk, 2009).

Delta Kuralı: En çok kullanılan öğrenme algoritmalarından birisidir. Beklenen çıktı ile ağın çıktısı arasındaki farkı (hata) azaltmak için düğümler arasındaki bağlantı değerlerinin (ağırlıkların) iterasyonla değiştirilmesi ilkesine dayanarak geliştirilmiştir. Ortalama karesel hatayı (MSE) en aza indirmek amaçlanmaktadır. Hata, çıkış katmanından giriş katmanına geri iletilerek azaltılmaktadır (Kulluk, 2009). Delta

öğrenme kuralını kullanan geri yayılım algoritmasının akış şeması Şekil 4.9'da verilmiştir (Sağıroğlu ve ark., 2003).



Şekil 4.9. Geri yayılım algoritması akış diyagramı (Sağıroğlu ve ark.,2003)

4.2.2. Genetik algoritma

Genetik algoritma, özellikle doğrusal olmayan, çok değişkenli, zor problemlerin çözümüne yönelik olarak geliştirilmiş, popülasyon temelli sezgisel bir yöntemdir (Goldberg, 1989; Michalewicz, 1992; Reeves, 1995).

Genetik Algoritmalarda Kullanılan Parametreler:

Çözümlerin Kodlanması: Bir problemin çözümü için genetik algoritma geliştirmenin ilk adımı, tüm çözümlerin aynı boyutlara sahip bitler dizisi biçiminde gösterilmesidir (Yeniay, 2001). Parametrelerin kodlanması, probleme özgü bilgilerin genetik algoritmanın kullanacağı şekle çevrilir (Jang, 1997).

İlk Popülasyonun Oluşturulması: Olası çözümlerin kodlandığı bir çözüm grubu oluşturulur. Çözüm grubu popülasyon, çözümlerin kodları da kromozom olarak adlandırılır. Genetik algoritmalarda ikili kodlama yöntemi ve çözümü aranan probleme bağlı olarak farklı kodlama yöntemleri de kullanılmaktadır (Goldberg, 1989).

Uygunluk Değerinin Hesaplanması: Bir kuşak oluşturulduktan sonraki ilk adım, popülasyondaki her üyenin uygunluk değerini hesaplama adımıdır. Örneğin, bir maksimizasyon problemi için i. üyenin uygunluk değeri f(i), genellikle o noktadaki amaç fonksiyonunun değeridir (Jang, 1997). Çözümü aranan her problem için bir uygunluk fonksiyonu mevcuttur. Verilen belirli bir kromozom için uygunluk fonksiyonu, o kromozomun temsil ettiği çözümün kullanımıyla veya yeteneğiyle orantılı olan sayısal bir uygunluk değeri verir. Bu bilgi, her kuşakta daha uygun çözümlerin seçiminde yol göstermektedir. Bir çözümün uygunluk değeri ne kadar yüksekse, yaşama ve çoğalma şansı o kadar fazladır ve bir sonraki kuşakta temsil edilme oranı da o kadar yüksektir (Yeniay, 2001).

Çoğalma İşleminin Uygulanması: Çoğalma operatöründe diziler, amaç fonksiyonuna göre kopyalanır ve iyi kalıtsal özellikleri gelecek kuşağa daha iyi aktaracak bireyler seçilir. Üreme operatörü yapay bir seçimdir. Dizileri uygunluk değerlerine göre kopyalama, daha yüksek uygunluk değerine sahip dizilerin, bir sonraki kuşaktaki bir veya daha fazla yavruya daha yüksek bir olasılıkla katkıda bulunması anlamına gelmektedir. Çoğalma, bireyleri seçme işleminden, seçilmiş bireyleri bir eşleme havuzuna kopyalama işleminden ve havuzda bireyleri çiftler halinde gruplara ayırma işleminden oluşur (Fığlalı ve ark., 2002). Uygunluk değerinin hesaplanması adımından sonra mevcut kuşaktan yeni

bir popülasyon yaratılmalıdır. Seçim işlemi, bir sonraki kuşak için yavru üretmek amacıyla hangi ailelerin yer alması gerektiğine karar vermektedir. Bu doğal seçimdeki en uygunun yaşaması durumuna benzerdir. Bu yöntemin amacı, ortalama uygunluğun üzerindeki değerlere çoğalma fırsatı tanımaktır. Bir dizinin kopyalanma şansı, uygunluk fonksiyonuyla hesaplanan dizinin uygunluk değerine bağlıdır (Jang, 1997). Seçim yöntemlerine rulet tekerleği seçimi, turnuva seçimi ve sıralama seçimi gibi seçim yöntemleri örnek verilebilir.

Çaprazlama İşleminin Uygulanması: Mevcut gen havuzunun potansiyelini araştırmak üzere, bir önceki kuşaktan daha iyi nitelikler içeren yeni kromozomlar yaratmak amacıyla çaprazlama operatörü kullanılmaktadır. Çaprazlama genellikle, verilen bir çaprazlama oranına eşit bir olasılıkla seçilen aile çeşitlerine uygulanmaktadır (Jang, 1997). Genetik algoritmanın performansını etkileyen önemli parametrelerden biri olan çaprazlama operatörü doğal popülasyonlardaki çaprazlamaya karşılık gelmektedir. Çoğalma işlemi sonucunda elde edilen yeni popülasyondan rastsal olarak iki kromozom seçilmekte ve karşılıklı çaprazlama işlemine tabi tutulmaktadır. Çaprazlama işleminde dizi uzunluğu L olmak üzere, $1 \leq k \leq$ L-1 aralığında k tamsayısı seçilmektedir. Bu tamsayı değerine göre dizi çaprazlamaya uğratılır. En basit çaprazlama yöntemi tek noktalı çaprazlama yöntemidir. Tek noktalı çaprazlama yapılabilmesi için her iki kromozomun da aynı gen uzunluğunda olması gerekir. İki noktalı çaprazlamada ise kromozom iki noktadan kesilir ve karşılıklı olarak pozisyonlar yer değiştirilir (Fığlalı, 2002).

Mutasyon İşleminin Uygulanması: Çaprazlama mevcut gen potansiyellerini araştırmak üzere kullanılır. Fakat popülasyon gerekli tüm kodlanmış bilgiyi içermez ise, çaprazlama tatmin edici bir çözüm üretemez. Bundan dolayı, mevcut kromozomlardan yeni kromozomlar üretme yeteneğine sahip bir operatör gerekmektedir. Bu görevi mutasyon gerçekleştirir. Yapay genetik sistemlerde mutasyon operatörü, bir daha elde edilemeyebilir iyi bir çözümün kaybına karşı koruma sağlamaktadır (Goldberg, 1989). İkili kodlama sisteminin kullanıldığı problemlerde mutasyon, düşük bir olasılık değeri altında bir bit değerini (0 veya 1 olabilir) diğer bit değerine dönüştürür. İkili kodlama sisteminin kullanılmadığı problemlerde ise daha farklı mutasyon yöntemleri kullanılmaktadır. Hangi yöntem kullanılırsa kullanılsın, mutasyonun genel amacı, genetik çeşitliliği sağlamak veya korumaktır (Braysy, 2001).

Yeni Kuşağın Oluşması ve Döngünün Durdurulması: Yeni kuşak çoğalma, çaprazlama ve mutasyon işlemlerinden sonra tanımlanmakta ve bir sonraki kuşağın ebeveynleri olmaktadırlar. Süreç yeni kuşakla çoğalma için belirlenen uygunluk ile devam eder. Bu süreç, önceden belirlenen kuşak sayısı kadar veya bir hedefe ulaşılıncaya kadar ya da başka bir durdurma kriteri sağlanana kadar devam eder (Yeo ve Agyel, 1998). İstenen hassasiyet derecesine göre de maksimum iterasyon sayısı belirlenebilmekte ve iterasyon bu sayıya ulaştığında döngü durdurulabilmektedir. Durdurma kriteri iterasyon sayısı olabileceği gibi hedeflenen uygunluk değeri de olabilmektedir (Fung ve ark., 2001).

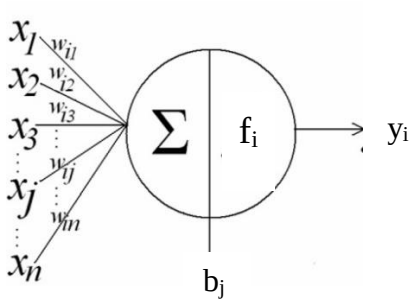
Genetik Algoritması ile Yapay Sinir Ağı Eğitimi: Klasik tekniklerin sahip olduğu erken yakınsama, lokal minimumlara takılma, hesaplama karmaşıklığının yüksek olması gibi dezavantajlar, yapay sinir ağları eğitiminde sezgisel yaklaşımların kullanımını ortaya çıkarmıştır. Bu çalışma kapsamında YSA ağırlık değerlerinin geri yayılım algoritması yerine GA ile tespiti çalışmasında toplam ağırlığın değerlerini temsil edecek bir yapı kurulmasıdır. GA da bu yapı her bir ağırlık için bir gen ve toplam ağırlık sayısınca genden oluşan bir kromozom ile temsil sağlanmaktadır. Örneğin 9 giriş 6 çıkışlı bir YSA modelinde 8 işlem elamanından oluşan tek katmanlı bir yapı tercih ettiğimizde eşik değerleri ile beraber; Toplam Ağırlık Sayısı= (9+1)*8 + (8+1)*6 = 134 olmaktadır. YSA modelindeki ara katman ve işlem elemanları sayıları değiştikçe temsil edilecek ağırlık sayısı da değişecektir.

Yapay sinir ağları nöron denilen aralarında bağların bulunduğu işlemci elemanlardan oluşmaktadır (Şekil 4.10). i. nörona ait çıkış Eşitlik (4.42) ile verilebilir (Karaboga ve Akay, 2007):

$$y_i = f_i\left(\sum_{j=1}^{n} w_{ij} x_j + b_i\right) \qquad (4.42)$$

y_i nöron çıkışı, x_j nörona ait j. giriş

w_{ij} nöron ve x_j giriş arasındaki bağlantı ağırlığı, b_i eşik (ya da bias) değeri ve f_i de transfer fonksiyonudur.



Şekil 4.10. Yapay sinir ağına ait işlemci birimi

Bu fonksiyon genelde sigmoid ya da gaussian gibi doğrusal olmayan tipte seçilmektedir. Genellikle adaptasyon network çıkışındaki E hatasının minimize edilmesiyle sağlanır. Hata fonksiyonu Eşitlik (4.43) ile verilir:

$$E(w(t))=\frac{1}{n}\sum_{j=1}^{n}\sum_{k=1}^{K}(o_k-d_k)^2 \qquad (4.43)$$

E(w(t)) t. iterasyondaki hata değeri, w(t) t. iterasyondaki ağırlıklar, d_k istenen çıkış, o_k w(t) ağırlıkları ile hesaplanan network çıkışıdır. Optimizasyon işlemi optimum w(t) ağırlık değerlerinin bulunarak E(w(t)) hata fonksiyonunun minimize edilmesidir.

Gelişim algoritmaları ile yapay sinir ağlarına ait ağırlık değerleri bireyler olarak düşünülür, çaprazlama, mutasyon gibi operatörlerle ağırlık matrisi değiştirilerek yapay sinir ağının ürettiği hata değeri minimize edilmeye çalışılır. Bu işlemler şu döngü ile verilebilir (Karaboğa ve Akay, 2007):

1. Çaprazlama ve mutasyon gibi operatörlerle bir sonraki ağırlıkları içeren popülasyonu üret,
2. Üretilen ağırlık değerleri ile tasarlanan yapay sinir ağının uygunluk değerini hesapla ve uygunluk temelli seçme işlemi uygula,
3. İstenen sonuç elde edilmişse dur, yoksa 1. adıma dön.

4.2.3. Yapay arı kolonisi algoritması

Karaboğa tarafından geliştirilen yapay arı kolonisi algoritması (artificial bee colony algorithm), meta sezgisel bir optimizasyon algoritmasıdır. Algoritma, arı sürülerinin zekâsından esinlenilerek geliştirilmiştir ve arı kolonilerinin yem arama davranışlarını taklit etmektedir. Algoritmada yem kaynakları olası çözümleri, yem

kaynaklarından taşınan yem miktarları çözümün uygunluğunu, arılar ise daha iyi sonuçlar arayan ajanları temsil etmektedir. Yöntem ilk olarak sayısal optimizasyon problemlerini çözmek için kullanılmış olsa da artık yapay sinir ağlarının, ağırlık katsayılarını hesaplayarak sınıflandırma problemlerinin çözümlerinde de kullanılmaktadır (Karaboğa ve Akay, 2007; Öztürk ve Karaboğa, 2007).

Diğer yapay zekâ tekniklerinde olduğu gibi; arı algoritmasının problem çözümünde kullanılması için öncelikli olarak problemin iyi analiz edilmesi ve algoritmanın temel işleyişine uygun modellemenin yapılması gerekir. Arı algoritmasında arılar; ele alınan probleme geçerli tam bir çözüm öneren değerler bütünüdür. Arılardan meydana gelen koloni ise alternatif çözüm kümesi olarak düşünülebilir. Ele alınan problemde bulunan alternatif çözümlerin değerlendirilmesinde kullanılacak amaç fonksiyonun belirlenmesi de en temel adımlardandır. Çözümün amaç fonksiyon değeri arı uygunluk değeri olarak nitelendirilmektedir (Düğenci, 2007).

Algoritma n adet arının çözüm uzayına rastgele yerleştirilmesi ile başlar. Sonrasında arıların uygunluk değerleri daha önceden belirlenen amaç fonksiyonu doğrultusunda hesaplanır. İterasyon sayısı bazında ya da arıların uygunluk değerlerinden istenilen kriteri sağlayan arının olup olmadığının ölçülmesi aşamasıdır. Bu aşamada durdurma kriteri sağlanır ise işlemlere son verilir aksi takdirde işlemlere devam edilir ve arılar uygunluk değerlerine göre sıralanır. Uygunluk değeri en yüksekten başlamak üzere, etrafında araştırma yapılacak arılar, araştırma bölge arısı olarak belirlenir. Aynı adımda araştırma bölgesi içerisindeki en iyi elit arı sayısı da bu bölge içerisinde yer alır.

Araştırma bölgesi arıları etrafına yeni izci arılar gönderilir. Bu aşamada arı algoritmasının temel felsefesini oluşturan; “besin aramada iyi kaynaklar bulmuş olan arıların etrafında daha iyi kaynaklar bulunabilir” yaklaşımından yola çıkarak çözüme yakın alternatiflerin etrafında araştırma derinleştirilir. Araştırma bölgesinde; elit arıların etrafına daha fazla olmak üzere, tüm arıların etrafına izci arılar gönderilir. Bu da elit arılar etrafında daha detaylı araştırma anlamına gelir. İzci arılarla birlikte bu yerel (lokal) araştırma da, arı algoritmasının temel kavramlarından bir tanesidir.

Bununla birlikte seçilen araştırma bölgelerinde, yerel (lokal search) araştırma devam ederken, diğer yanda da genel (global search) araştırmalar yapılır. Başka bölgelerde de çözümler aranır. Bu işlemde; başlangıç kolonisini oluşturmada olduğu gibi, araştırma bölgesi rasgele belirlenir. Arı algoritmasını güçlü kılan yönlerden biri de arama

yönteminin yerel bir çözümde takılıp kalması ve genel en iyi çözümü aramayı bırakma riskini azaltmaktadır (Düğenci, 2007).

Arı Algoritması ile Yapay Sinir Ağı Eğitimi: Yapay sinir ağı öğrenmesinde arı algoritmasının kullanımı, koloni tabanlı genetik algoritma kullanımına benzemektedir. Popülasyonu (koloni) oluşturan arılar yapay sinir ağı öğrenmesinde temel unsur olan ağırlık vektörünü temsil etmektedir. Her bir arı eşik değerleri dâhil tüm düğümler arası bağlantı ağırlıklarını içermektedir (Düğenci, 2007).

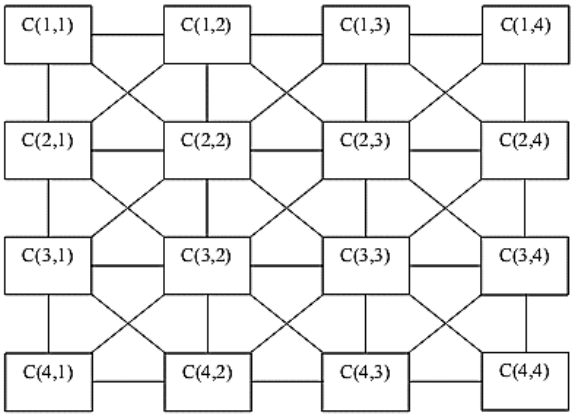
Arı algoritması ile rasgele başlangıç kolonisi oluşturulup uygunluk değerleri hesaplanır ve uygunluk değerlerine göre en iyiden en kötüye doğru sıralanır. Daha sonra önceden verilen araştırma bölgesi ve en iyi elit arı sayıları kullanılarak en iyi çözüm üreten arıların yakınlarına daha fazla diğer bölgelere daha az olmak üzere yeni arılar araştırmaya gönderilir. Burada hedef daha iyi çözümler üreten arıların yakın çevrelerinde daha verimli çözüm seçenekleri olabileceği sezgisi ile böyle bir yönteme başvurulmaktadır. Uygunluk değerlerine göre mevcut arıların çevrelerine yeni arılar atanması çevresine arı gönderilen arının temsil ettiği ağırlık vektörünün her bir bileşeni çevresinde (+ veya -) rasgele bir nokta belirlenerek yeni çözüm noktaları ile yeni ağırlık vektörü (yeni arı) oluşturulur. En iyi arılardan oluşan elit arıların çevresinde daha çok diğer bölge arıları çevresinde daha az, kalan araştırma bölgelerine de başlangıçta olduğu gibi rasgele gönderilen araştırma arıları ile yeni bir toplam çözüm kümesi oluşmuş olur bunlardan koloni araştırma arısı büyüklüğünde arı bir sonraki iterasyona devredilmekte ve yeni çözümler aranmasına istenilen durdurma kriteri sağlanıncaya kadar devam edilmektedir (Düğenci, 2007).

4.2.4. Hücresel sinir ağları

Hücresel Sinir Ağları (HSA), Chua ve Yang tarafından 1988 yılında önerilmiş olan bir mimaridir (Chua ve Yang, 1988a). Paralel sinyal işleme, sürekli-zaman dinamikleri ve gerçek zamanlı sinyal işleme gibi yapay sinir ağlarının önemli özelliklerini içinde barındırmaktadır. HSA'ların bir diğer önemli özelliği de sadece komşularıyla iletişim halinde bulunan analog sinyal işleyebilen düğüm yapısına sahip olmasıdır. Tüm hücrelerin birbirleriyle bağlantılı olmaları yerine sadece belli bir komşulukta bulunan hücrelerin birbirleriyle doğrudan, diğer hücrelerle ise dolaylı bağlantılı olması HSA devre

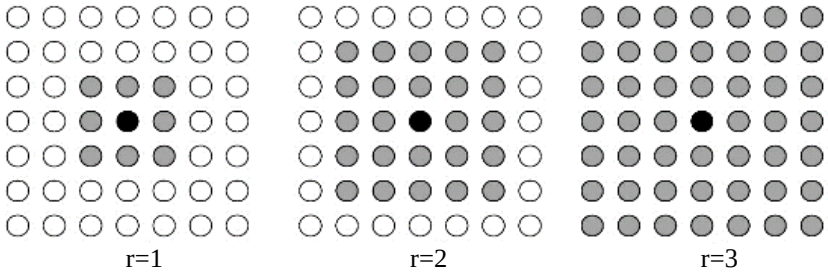
yapısının karmaşıklığını azaltmakta, enerji tüketimini düşürmektedir. Bu sayede diğer klasik yapay sinir ağları modellerine göre donanımsal gerçeklemesi daha kolaydır (Sevgen, 2009).

Standart HSA yapısı M (satır) x N (sütun) boyutundaki dikdörtgen hücreler dizisinden oluşmaktadır. i. satır, j. sütundaki düğüm C(i,j) ile ifade edilir. (i=1,2,3...M, j=1,2,3...N). Her düğüm sadece kendisine komşu olan hücrelerle bağlantılıdır ve komşu hücreler birbirleriyle direkt etkileşimdedir. Şekil 4.11'de her bir hücrenin sadece çevresindeki hücrelerle bağlantılı olduğu 4x4 boyutunda bir hücresel yapay sinir ağını göstermektedir (Chua ve Yang, 1988a).



Şekil 4.11. Standart HSA yapısı (Chua ve Yang, 1988a).

$S_r(i,j)$, bir hücrenin r yarıçaplı etki alanı (sphere influence) olarak adlandırılır. Burada r, bir pozitif tamsayı olmak üzere komşuluk derecesi olarak isimlendirilir. Hücresel sinir ağı tanımlanırken bu r değeri seçilir. Şekil 4.12, sırasıyla merkezde siyah ile gösterilen hücrenin r=1, r=2 ve r=3 komşuluklarını göstermektedir. r=1 komşuluğu için merkez hücrenin komşuları gri ile işaretlenmiş olan 8 hücredir ve 3×3 komşuluk olarak tanımlanır. Benzer şekilde r=2 komşuluk değeri, 5×5 komşuluk ve r=3 komşuluk değeri de 7×7 komşuluk olarak tanımlanabilir. Çoğu uygulamada r =1 yani 3x3 komşuluk kullanılır (Chua ve Yang, 1988a; Sevgen, 2009).



Şekil 4.12. Çeşitli r değerleri için komşuluklar (Chua ve Yang, 1988a).

Bir hücresel sinir ağında C(i,j) hücresinin r-komşuluğu aşağıdaki ifadeyle tanımlanabilir:

$$S_r(i,j)=\left\{ C(k,l)\Big|_{1\le k\le M,1\le 1\le N} \quad \max\{\,|k-i|,\,|l-j|\,\} \le r \right\} \tag{4.44}$$

Standart bir HSA matematiksel olarak aşağıdaki eşitlikle ifade edilebilir (Chua ve Yang, 1988a):

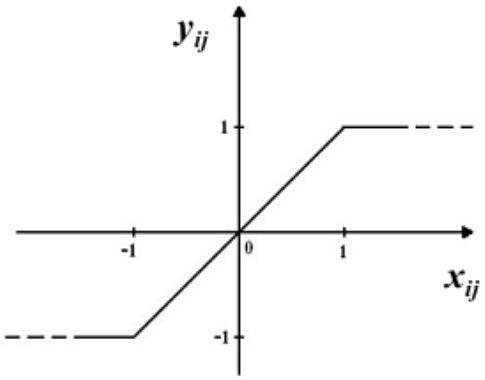
$$dx_{ij}(t)=-x_{ij}(t)+\sum_{C(k,l)\epsilon S_r(i,j)} A_{ij:k,l}y_{kl}(t)+\sum_{C(k,l)\epsilon S_r(i,j)} B_{ij:k,l}u_{kl}(t)+I_{ij} \tag{4.45}$$

$$y_{ij}=\frac{1}{2}\left|x_{ij}+1\right|-\frac{1}{2}\left|x_{ij}-1\right| \tag{4.46}$$

Eşitlik (4.44) ve Eşitlik (4.45)'de,

x_{kl}: C(i,j) hücresinin durum değişkeni,
y_{kl}: Etki alanı içerisindeki hücrelerin çıkışları,
u_{kl}; Etki alanı içerisindeki hücrelerin girişi,
I_{ij}: Eşik değeri,
A(i, j; k, l); Geri besleme operatörü,
B(i, j; k, l); Giriş (kontrol) operatörü, olarak ifade edilmektedir.

Çıkış fonksiyonu y_{ij}, lineer olmayan ve hücrenin çıkışını tanımlayan karakteristik parçalı (piece-wise) bir fonksiyondur. Şekil 4.13'de bu fonksiyon görülmektedir (Chua ve Yang, 1988b).



Şekil 4.13. HSA'nın karakteristik parçalı çıkış fonksiyonu (Chua ve Yang, 1988b).

A(i,j;k,l), B(i,j;k,l) ve I_{ij} parametreleri hücreler ve aralarındaki bağlantıları tanımlamaktadırlar. Bu parametreler şablon (template) olarak isimlendirilirler. Şablonlar değişik işlemlerin HSA üzerinde gerçekleştirilmelerini sağlamaktadırlar (Sevgen, 2009).

HSA hücrelerinin sadece komşularıyla bağlantılı olması devre yapısını oldukça basitleştirmesinin yanında başka bir önemli özelliği de A, B, I ifadelerinin uzayda değişmez (space invariant) olabilmesidir. Bu özellik sayesinde, A, B ve I ifadelerinin farklı değerler almasıyla değişik HSA işlemleri gerçekleştirmek mümkündür (Sevgen, 2009).

HSA'nın dinamik davranışı hücreler arası bağlantıların dolaylı olarak oranı sayılabilecek şablon katsayıları ile belirlenmektedir. Ağdaki herhangi bir düğüm komşu hücrelere bu şablon katsayılarının belirlediği oranda bağlanmaktadır. İstenen görüntü işlemenin yapılabilmesi ancak bu şablon katsayılarının değerlerinin uygun olarak ayarlanması ile sağlanabilir. r=1 yarıçap komşuluğunda yani 3x3 boyutlu genelleştirilmiş bir HSA hücresi, Şekil 4.14'te görüldüğü üzere, 19 adet reel sayı ile tanımlanabilmektedir. a_k geri besleme şablon katsayıları, b_k ileri besleme şablon katsayıları ve I eşik şablon katsayıları bir düğüm için şablon katsayılarını oluşturmaktadır.

I

Eşik Şablon Katsayısı

a_9	a_8	a_7
a_6	a_5	a_4
a_3	a_2	a_1

Geri Besleme Şablon Katsayısı

b_9	b_8	b_7
b_6	b_5	b_4
b_3	b_2	b_1

Kontrol Şablon Katsayısı.

Şekil 4.14. r=1 komşuluğundaki bir HSA için şablon katsayıları

4.2.5. Performans kriterleri

Yapılan çalışmanın değerlendirilmesi için veri türüne göre değerlendirme kriterleri kullanılır. Sınıflama ya da tahmin amaçlı veri setinde kullanılan değerlendirmeler birbirlerinden farklıdır (Akdemir, 2009).

4.2.5.1. Ortalama karesel hata

Ortalama karesel hata, "Mean Squared Error (MSE)" olarak verilmiştir. Bu formül hatanın kareleri toplamının ortalaması ile ifade edilir. MSE'nin literatürde oldukça yaygın ve geçerli bir kullanımı vardır. MSE Eşitlik (4.47)'den hesaplanabilir (Akdemir, 2009).

$$E_i=\frac{1}{n}\sum_{n=1}^{n}(T_{(i)}-P_{(i)})^2 \qquad (4.47)$$

Eşitlikte, P tahmin edilen veriyi, T ise hedeflenen veriyi sembolize etmektedir.

4.2.5.2. Korelasyon katsayısı

Korelasyon katsayısı (r), ölçüm değerleri ile model tahminleri arasında doğrusal bir ilişki olup olmadığını belirlemek amacıyla kullanılır. r değeri 0 ile 1 arasında değişmekte ve bu değerin 1'e yaklaşması model tahminleri ile ölçüm değerleri arasındaki bağımlılığın kuvvetli olduğu anlamına gelmektedir (Akdemir, 2009).

Bu değerlendirmede hedef 1'dir. 1 sayısına yaklaşılmasına bağlı olarak test değerleri ile hedeflenen değerlerin örtüştüğünü söylemek mümkündür. Korelasyon katsayısı aşağıdaki Eşitlik (4.48)'den hesaplanabilir (Doğan ve ark., 2008).

$$r=\frac{n\sum_{m=1}^{n} y_{pre,m}y_{mea,m}-(\sum_{m=1}^{n} y_{pre,m})(\sum_{m=1}^{n} y_{mea,m})}{\sqrt{[n\sum_{m=1}^{n} y_{pre,m}{}^2-\left(\sum_{m=1}^{n} y_{pre,m}\right)^2]x[n\sum_{m=1}^{n} y_{mea,m}{}^2)-(\sum_{m=1}^{n} y_{mea,m})^2]}} \qquad (4.48)$$

Eşitlikte $y_{pre,m}$ tahmin edilen değer, $y_{mea,\,m}$ ölçülen değer ve $y_{mea,\,m}$ ise ölçülen değerlerin ortalamasıdır. Bu eşitliği hataların karesinin ortalamaya uzaklığa oranı olarak açıklamak mümkündür (Akdemir, 2009).

5. MİKROSKOBİK GÖRÜNTÜLERİN BÖLÜTLENMESİ

Bölütleme, görüntü işlemenin en zor görevlerinden biridir ve bölütlemeyle ilgili standart bir yöntem yoktur. Karşılaşılan probleme göre bölütleme işlemi gerçekleştirilir. Görüntünün istenen parçalarına ayrılabilmesi için, ilgilenilen şeklin sınırlarının bulunması gerekir. Algoritmalar genellikle görüntülerin gürültü etkisi, aydınlatma ve büyüklüklerinin değişmesiyle farklı sonuç verebilirler. Dolayısıyla görüntülerin bölütlenmesi; görselleştirme, bilgisayar destekli tanı, teşhis ve morfolojik analiz uygulamalarının en önemli basamağıdır. Bölütlemede temel amaç, bir veya birden fazla karakteristik veya özelliğe uygun olarak görüntünün bölümlere (sınıflara veya alt kümelere) ayrılması işlemidir (Fu ve Mui 1981; Liang 1993; Suetens 1993; Bezdek ve ark. 1993; Clarke ve ark. 1995).

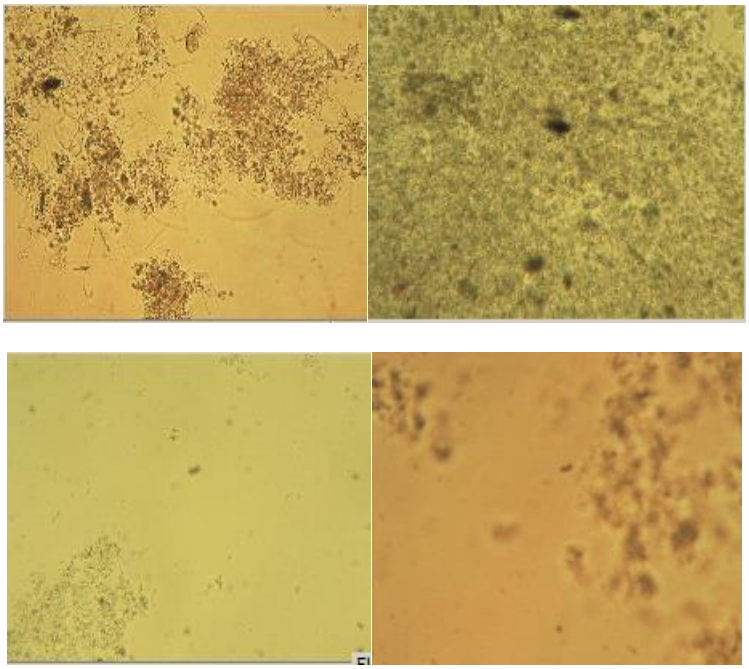
Bölütleme işlemi, görüntünün tipine ve çalışmanın amacına uygun olarak seçilerek gerçekleştirilmektedir. Her bir görüntünün sahip olduğu farklı karakteristik yapı sebebi ile adaptif doğrusal olmayan bölütleme metotlarının önemi ortaya çıkmıştır. Başka bir deyişle, görüntü iyileştirme ve onarma problemlerinde olduğu gibi görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin başarımları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik arz etmektedir.

Flokların büyüklüğü ve makro düzey yapılarındaki farklılıkları, çamur çökelmesi probleminin önemli parametrelerinin başında gelmektedir. Flokların küçük ve büyük boyutlarında olması, flok başına 1-5 filamentli mikroorganizma barındırması, yapının "gevşek" veya "sıkı" olması katı-sıvı ayırımında büyük önem taşımaktadır (Jenkind ve ark., 1993; Sezgin, ve ark., 1977). Özellikle filamentli mikroorganizmaların neden olduğu kabarma problemi her bir biyolojik arıtma sisteminde ve özellikle daha sık ve ciddi bir problem olarak aktif çamur arıtma sistemlerinde periyodik olarak ortaya çıkmakta ve arıtma sistemlerinin performansını düşürerek işletim problemlerine neden olmaktadır (Övez, 2010).

5.1. Görüntülerin Bölütlenmesinde Kullanılan Yöntem

Görüntüler, Konya Kentsel Atıksu Arıtma Tesisin aktif çamur ünitesinin havalandırma tankından alınmıştır. Şekil 5.1'de alınan bu görüntülere örnek gösterilmiştir. Şekil 5.1'de görüldüğü gibi floklar renk, yoğunluk ve doku gibi farklı

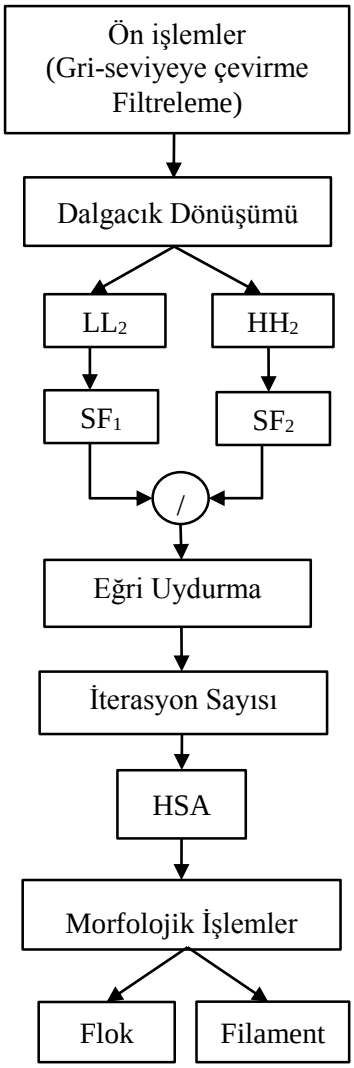
özelliklere sahip olabilmekte ve katmanlar halinde bulunmaktadırlar. Bir katmana göre netlik ayarlanırsa diğer katmandaki floklar bulanık görülecektir. Ve aynı zamanda otomatik odak ayarı yapamadığımızdan, elde edilen her bir görüntünün netliği farklı olabilmektedir. Dolayısıyla görüntünün netlik bilgisi için karşılaştırabileceğimiz referans bir görüntü yoktur. Bu sorunun üstesinden gelebilmek için görüntünün özelliğine göre değişen iterasyon değeri kullanılmıştır.



Şekil 5.1. Aktif çamur görüntüleri

Bunun için HSA ve dalgacık dönüşümünün birlikte kullanıldığı bir yöntem önerilmiştir. Bu yöntem ile görüntünün netlik ölçüsünü belirten bir parametre belirlemiştir. Bu parametrenin belirlenmesinde, dalgacık dönüşümü, uzaysal frekans, entropi ve kenar bilgileri kullanılarak HSA'nın iterasyon değeri güncellenmiştir. Bu denemeler sonucunda da dalgacık dönüşümü ve uzaysal frekansın birlikte kullanıldığı yöntem önerilmiştir (Boztoprak ve Özbay, 2013a).

Flok ve filamentlerin bölütlenmesinde uygulanan yöntemin işlem adımları Şekil 5.2'de verilmiştir. Alınan görüntüler öncelikle gri görüntüye çevrilmiş ve istenmeyen gürültülerin temizlenmesi için median filtre uygulanmıştır. Sonrasında bu görüntüye dalgacık dönüşümü uygulanmış ve LL_2, HH_2 alt bantları elde edilmiştir. Bu alt bantların SF değerleri hesaplanmıştır. Bu SF'ların birbirine oranı ile HSA'nın iterasyon sayısı arasındaki ilişki araştırılmıştır.

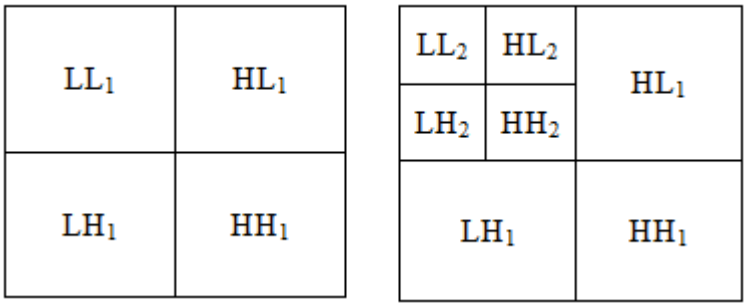


Şekil 5.2. Uygulanan bölütleme işleminin adımları

Dalgacık Dönüşümünün Görüntüye Uygulanması: Dalgacık dönüşümü görüntüye uygulanırken, görüntü iki boyutlu bir diziymiş gibi düşünülür. Yatay olarak tüm satırlara alçak geçiren filtre ve yüksek geçiren filtre sırayla uygulanır. Daha sonra aynı işlem düşey olarak tekrarlanır. Özet görüntü düşük frekanslı bölgede taşınmaktadır. Yüksek frekanslı bölgelerde ise daha ziyade gürültüler ve ani değişimler taşınmaktadır.

Dalgacık dönüşümü ile farklı ölçeklerde alçak-yüksek (LH), yüksek-alçak (HL), yüksek-yüksek (HH) uzaysal frekans bantlarına ve en küçük ölçekte alçak-alçak (LL) bandlar olmak üzere her bir görüntü 4 alt banda ayrıştırmaktadır. LL bandı orijinal görüntü bilgilerini, diğer bantlar ise filtre işlem yönlerine göre yön bilgileri içermektedirler. Ana görüntünün boyutları 128x128 piksel ise, iki seviye dalgacık

dönüşümü sonucunda alçak-alçak frekansa sahip görüntünün boyutları 32x32 olacaktır (Şekil 5.3).



(a) (b)

Şekil 5.3. Dalgacık katsayıların grafiksel anlatımı, a) tek seviyeli, b) iki seviyeli ayrıştırma

Bu çalışmada, Haar dalgacık filtresi kullanılarak ikinci seviyede ayrıştırma yapılmıştır. Bu ayrıştırma sonunda LL_2, HL_2, LH_2, HH_2 alt bantları elde edilmiştir. LL_2 ve HH_2 alt bant görüntüleri giriş görüntü ile aynı boyutta yeniden yapılandırılarak bir sonraki aşamada kullanılmıştır.

Uzaysal frekans, kenar bilgisi ve dalgacık dönüşümü, görüntü füzyonu, odak ayarlama ve netlik bilgisi çalışmalarında çok sık kullanılmışlardır (Li ve ark., 2001; Maddali ve ark., 2012; Bindu ve ark., 2012; Turgay ve ark., 2011; Jain ve ark., 2011; Bulatov, 2006). Hemen hemen hepsinde aynı görüntüden üç veya daha fazla görüntü alınarak, birbirleriyle karşılaştırılmış ve bu şekilde odak ayarı gerçekleştirilmiştir. Ama bu çalışmada farklı olarak, karşılaştırabilecek ikinci bir görüntü yoktur. Bu yüzden dalgacık dönüşümü ile geliştirilen yöntemin görüntü içeriğinden bağımsız olması amaçlanmıştır.

Uzaysal frekansın hesaplanması: Uzaysal frekans görüntüdeki piksel değerlerinin varyansını hesaplar. Yani yan yana duran iki piksel arasındaki farkın ne kadar büyük olduğunu ölçer, dolayısıyla görüntünün netlik ölçüsüyle doğru orantılı bir değer vermektedir. Orijinal görüntünün, LL_2 ve HH_2 alt bant görüntülerin uzaysal frekans değerleri (sırasıyla SF_{orj}, SF_1 ve SF_2) Eşitlik (5.1), (5.2) ve (5.3) kullanılarak hesaplanmıştır.

$$SF_{orj}=\sqrt{\left(RF_{orj}\right)^2+\left(CF_{orj}\right)^2} \tag{5.1}$$

$$SF_1=\sqrt{(RF_{LL})^2+(CF_{LL})^2} \tag{5.2}$$

$$SF_2=\sqrt{(RF_{HH})^2+(CF_{HH})^2} \quad (5.3)$$

SF_{orj}: orijinal görüntünün uzaysal frekansı,

SF_1: LL_2 alt bandının uzaysal frekansı,

SF_2: HH_2 alt bandının uzaysal frekansı,

RF ve CF görüntülerin satır ve sütun frekanslarıdır. Eşitlik (5.4) ve (5.5) ile hesaplanmıştır.

$$RF = \sqrt{\frac{1}{MN}\sum_{m=1}^{M}\sum_{n=2}^{N}[F(m;n)- F(m,n-1)]^2} \quad (5.4)$$

$$CF = \sqrt{\frac{1}{MN}\sum_{n=1}^{N}\sum_{m=2}^{M}[F(m;n)- F(m-1,n)]^2} \quad (5.5)$$

RF satır, CF ise sütun frekansıdır.

Daha sonra SF_1 ve SF_2 değerleri kullanılarak DSF ve S değerleri hesaplanmıştır.

$$DSF= SF_1 - SF_2 \quad (5.6)$$

$$S =SF_1 / SF_2 \quad (5.7)$$

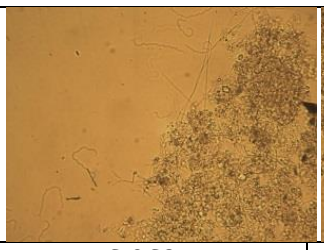
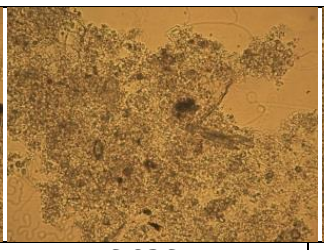
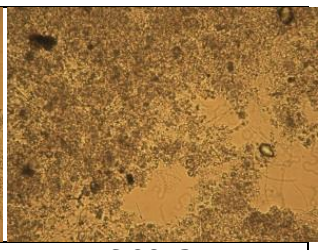
Bir görüntüdeki kenarlar, görüntü ile ilgili çok önemli bilgileri içerir. Çünkü bir görüntüdeki kenarlar, nesnelerin nerede bulunduğu, şekilleri ve ebatları hakkında bilgi verir. Kenar operatörü sayesinde görüntüdeki kenarlar tespit edilebilmektedir. Bu çalışmada prewitt kenar çıkarıcısı kullanılmıştır. Kenarları bulunan görüntülerden, netlik ölçüsü olarak belli bir sayısal değer elde edilmesi gerekir. Bunun için incelenen bölgede beyaz noktalar (kenar sayısı) sayılmıştır. Netice olarak incelenen bölgede beyaz noktaların sayısı, o bölgenin netliğini ifade edecektir. Doğal olarak görüntünün net kısımları daha çok kenarlara sahip olacağından, incelenen bölgede kenar sayısı o bölgenin netliğiyle doğru orantılı bir değer verecektir. Karşılaştırılabilir görüntülerden daha net olanlar daha çok kenar sayısına sahip olacakları beklenir.

Dalgacık dönüşümü ile elde edilen LL_2 ve HH_2 alt bantları için kenar bilgileri hesaplanmış ve sırasıyla Ea ve Ed kısaltmaları kullanılmıştır. Ve bunların birbirleriyle oranı Ead olarak tanımlanmıştır (Eşitlik (5.8)).

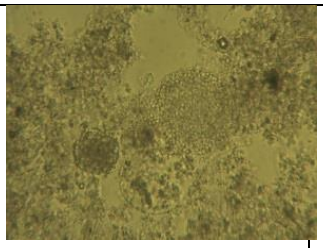
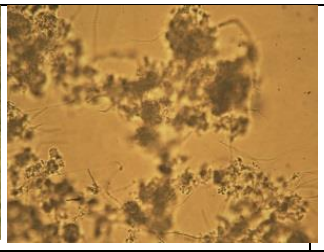
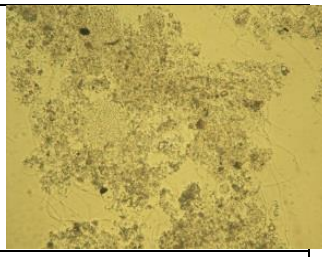
$$Ead = Ea / Ed \tag{5.8}$$

LL_2, HH_2 alt-bantları ile orijinal görüntülerden elde edilen SF_1, SF_2, SF_{orj}, Ead, E, DSF, ve S değerleri Çizelge 5.1, Çizelge 5.2 ve Çizelge 5.3'de gösterilmiştir. Bu değerler bulanık (Çizelge 5.3), normal (Çizelge 5.2), net (Çizelge 5.1) görüntülerle ve birbirleriyle karşılaştırılmıştır. Böylelikle hem net hem de bulanık görüntüler için içeriğinden bağımsız olarak, görüntünün netliği hakkında bilgi veren özellik araştırılmıştır. Bu çizelgelerde görüldüğü gibi net görüntülerde S değeri 1-1.4 arasında değişmektedir. Bulanık görüntülerde S değeri de artmaktadır. Entropi değeri hem net hem de bulanık görüntü için yaklaşık aynı değeri verebildiği görülmüştür. Kenar bilgisi entropiye göre daha iyi sonuç vermiştir, fakat net ve bulanık görüntüler arasındaki değerler birbirine çok yakındır. Bu karşılaştırmalar yaklaşık 200 atıksu görüntüsü üzerinde incelenmiştir (Boztoprak ve Özbay, 2013a).

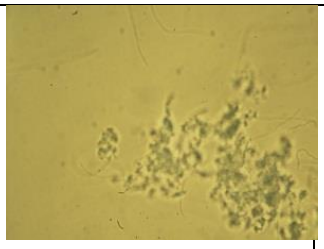
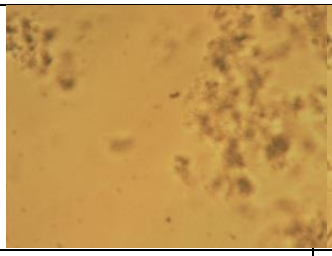
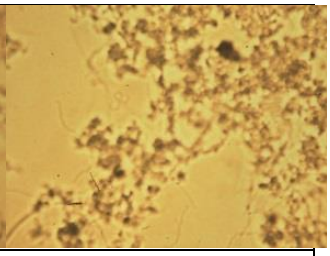
Çizelge 5.1. Net görüntüler için hesaplanan özelliklerin gösterilmesi.

Örnek Görüntüler			
Entropi	6.0691	6.8362	6.9853
SF_{orj}	1.1649e+04	1.7569e+04	1.7983e+04
SF_1	6.3078e+03	9.3706e+03	9.9786e+03
SF_2	4.9550e+03	7.2947e+03	7.4136e+03
DSF	1.3528e+03	2.0760e+03	2.5650e+03
$S= SF_1/SF_2$	1.2730	1.2846	1.3460
Ead= Ea/Ed	1.3768	1.3490	1.3897

Çizelge 5.2. Bulanıklık ve normal görüntüler için hesaplanan özelliklerin gösterilmesi

Örnek Görüntüler			
Entropi	6.1963	6.4759	6.3523
SF_{orj}	6.8788e+03	6.2796e+03	1.2248e+04
SF_1	5.6276e+03	6.3485e+03	6.9534e+03
SF_2	2.6827e+03	2.1895e+03	4.8641e+03
DSF	2.9449e+03	4.1590e+03	2.0893e+03
S= SF_1/SF_2	2.0978	2.8995	1.4295
Ead= Ea/Ed	1.4038	1.9451	1.4158

Çizelge 5.3. Çok bulanık görüntüler için hesaplanan özelliklerin gösterilmesi.

Örnek Görüntüler			
Entropi	5.3614	5.0802	6.3244
SF_{orj}	2.8158e+03	1.5877e+03	4.2816e+03
SF_1	3.4550e+03	2.0391e+03	6.0490e+03
SF_2	912.5774	464.5568	1.2589e+03
DSF	2.5424e+03	1.5745e+03	4.7901e+03
S= SF_1/SF_2	3.7859	4.3893	4.8052
Ead= Ea/Ed	1.8261	1.6983	2.1277

Görüntüler arasında en iyi ayırt edici SF_1 ve SF_2 arasındaki oran olan S değerinin verdiği görülmüştür. S değeri 1-1.4 arasında görüntünün netliğinin iyi olduğu, görüntü bulanıklaştıkça bu değerin arttığı gözlenmiştir. S değeri ne kadar çok yüksekse bulanıklık da o derecede artmaktadır.

Önerilen bu S yaklaşımının ayırt edici başarısını tespit edebilmek için bilinen görüntüler üzerinde objektif görüntü kalitesi ölçümü için kullanılan pik sinyal gürültü oranı (PSNR) (Hore ve Ziou, 2010) hesaplanarak bu S değeri ile karşılaştırılmıştır. Önce orijinal görüntüler kontrollü şekilde bozulmuş, daha sonra orijinal ve bozulmuş görüntülerin sinyal gürültü oranları mukayese edilmiştir. Görüntü olarak gri ölçekli 'Cameraman', 'Lena' ve 'Peppers' görüntüleri kullanılmıştır. Karşılaştırmak için

kullanılan PSNR kriteri 8 bitlik görüntüler için Eşitlik (5.9)'daki gibi tanımlanmaktadır. N×M büyüklüğündeki orijinal ve gürültülü görüntüler sırasıyla C ve ST ile gösterilmektedir (Ulutaş, 2012).

$$\mathrm{PSNR}=10\log_{10}\frac{255^2\mathrm{xNxM}}{\sum_{i=1}^{N}\sum_{j=1}^{M}\left(C_{ij}-ST_{ij}\right)^2} \tag{5.9}$$

Yüksek bir PSNR değeri daha yüksek görüntü kalitesini demektir. Düşük PSNR değeri ise görüntüler arasında yüksek sayısal farkı ifade eder. Çalışmada elde edilen sonuçlar Çizelge 5.4'de gösterilmiştir. PSNR değerinin yüksek olması iyiyken S değerinin düşük olması netliğin daha iyi olduğunu göstermektedir. PSNR değeri orijinal görüntüyle karşılaştırılarak hesaplanır. Orijinal görüntünün ideal görüntü olduğu kabul edilir. S değeri referans değeri olmadan bulunmaktadır. Orijinal görüntüde bulunan S değeri, görüntüye gürültü eklendikten sonra arttığı, iyileştirme işleminden sonra azaldığı Çizelge 5.4'de görülmektedir.

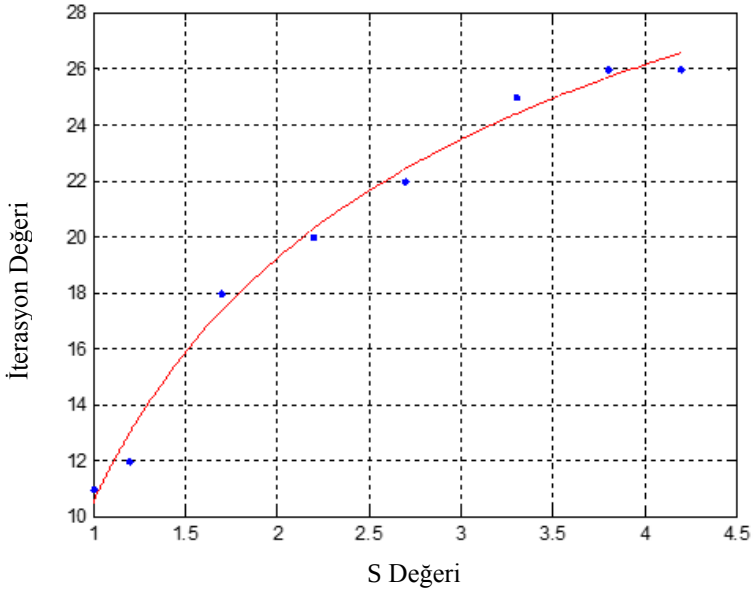
Çizelge 5.4'de görüldüğü gibi cameraman, lena ve peppers test görüntüleri üzerinde hareket gürültüsü, bulanıklık ve keskinleştirme işlemlerinden sonra yapılan karşılaştırma neticesinde S değeriyle görüntünün kalitesi hakkında yorum yapılabileceği görülmektedir. Böylece referans görüntü olmadan görüntülerin netliği hakkında bilgi elde edilebilmektedir. Elde edilen bu S değeri HSA'nın iterasyon değerinin hesaplanmasında kullanılmıştır. İterasyon değeri bölütleme sonucunu çok fazla etkilediğinden dolayı önemlidir.

Çizelge 5.4. Cameraman, Lena ve Peppers görüntülerin S ve PSNR değerleri

	Görüntüler	**S Değeri**	**PSNR Değeri**
Cameraman (256x256)	Orijinal görüntü	2.0903	-
	Hareket gürültüsü eklenmiş görüntü	3.5203	19.8642
	Bulanıklık eklenmiş görüntü	14.1384	18.9878
	Keskinleştirme yapılmış görüntü	1.1646	19.5906
Lena (256x256)	Orijinal görüntü	2.4061	-
	Hareket gürültüsü eklenmiş görüntü	3.8160	21.1862
	Bulanıklık eklenmiş görüntü	15.3463	19.6975
	Keskinleştirme yapılmış görüntü	1.2064	20.7449
Peppers (1200x1200)	Orijinal görüntü	5.1654	-
	Hareket gürültüsü eklenmiş görüntü	10.3359	33.6666
	Bulanıklık eklenmiş görüntü	17.2360	34.0125
	Keskinleştirme yapılmış görüntü	3.0954	41.5911

5.1.1. İterasyon sayısının belirlenmesi

Eşitlik (5.7) ile hesaplanan S değerine göre HSA'nın iterasyon sayısındaki değişme incelenmiş ve aralarındaki ilişki grafiksel olarak Şekil 5.4'de gösterilmiştir. Bu grafikte görüldüğü gibi bulanık görüntülerin bölütlenmesi için, yani S değeri artıkça, iterasyon sayısının artırılması gerekmektedir. Eğri uydurma algoritması ile bu mavi noktalardan geçen en yakın birinci dereceden polinoma ait katsayılar Eşitlik (5.10)'da verilmiştir.



Şekil 5.4. Görüntüden elde edilen S değerinin iterasyon değerine göre değişimi (Noktalar deneysel olarak belirlenen iterasyon sayısını, çizgi ise bu noktalardan geçen grafiği göstermektedir.)

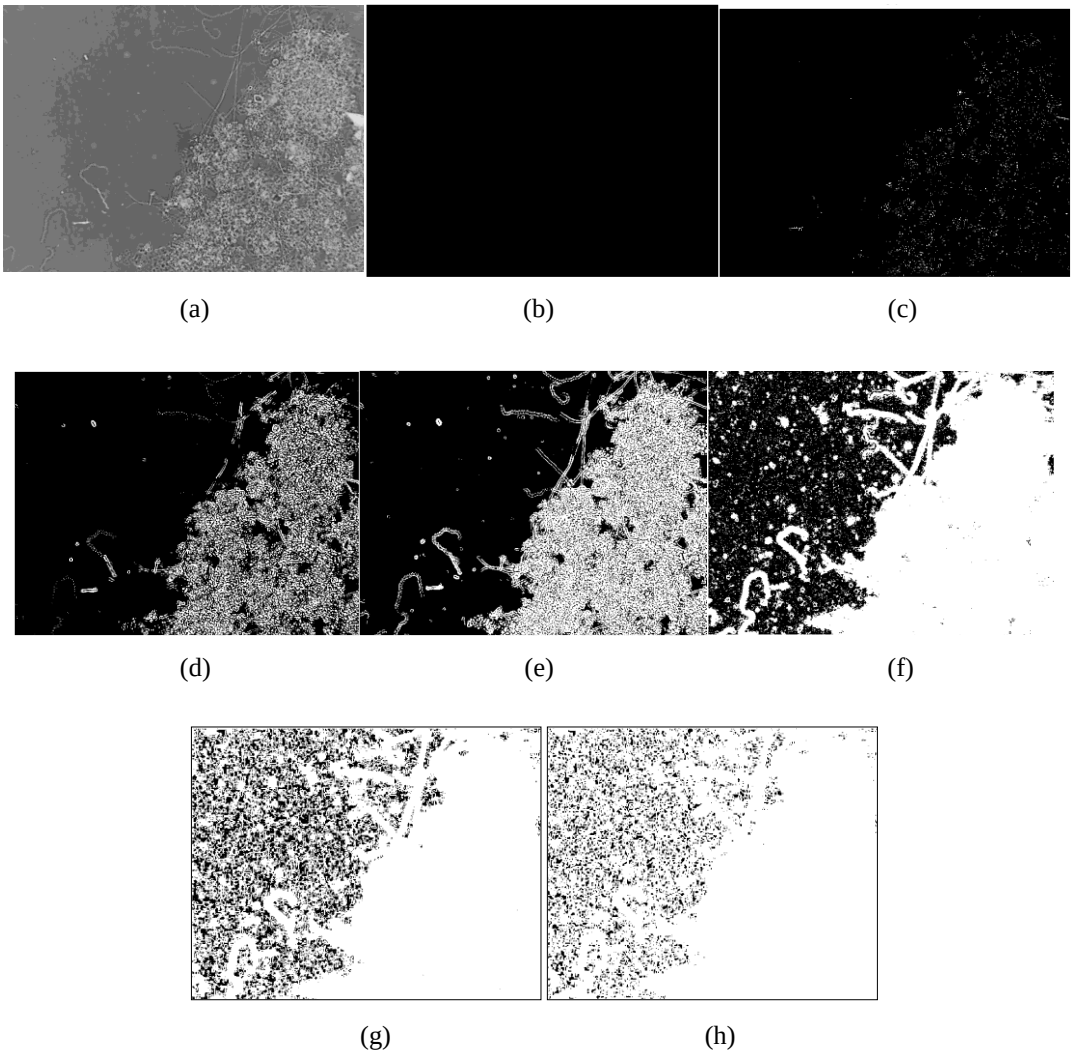
HSA için iterasyon sayısı Eşitlik (5.10) ile hesaplanır. S değeri Eşitlik (5.7)'de ifade edilmiştir.

$$y=-42.21*S-0.3343+52.68 \qquad (5.10)$$

Bu çalışmada kullanılan HSA ait Gradient şablonu (Fukuda ve ark., 1991) kullanılmıştır. HSA'nın zaman adım değeri 0.1 alınmıştır. İterasyon sayısı Eşitlik (5.10) ile hesaplanmıştır.

Şekil 5.5 (a)'da atıksu arıtma tesislerinde havalandırma havuzundan alınan bir mikroskop görüntüsü gösterilmiştir. İterasyon değerinin önemini vurgulamak için Şekil 5.5 (a)'daki görüntüye farklı iterasyon değerlerinde HSA işlemi uygulanmıştır. HSA'nın şablon katsayıları aynı, iterasyon değeri 5, 10, 15, 20, 30, 40 ve 50 için elde edilen çıkış

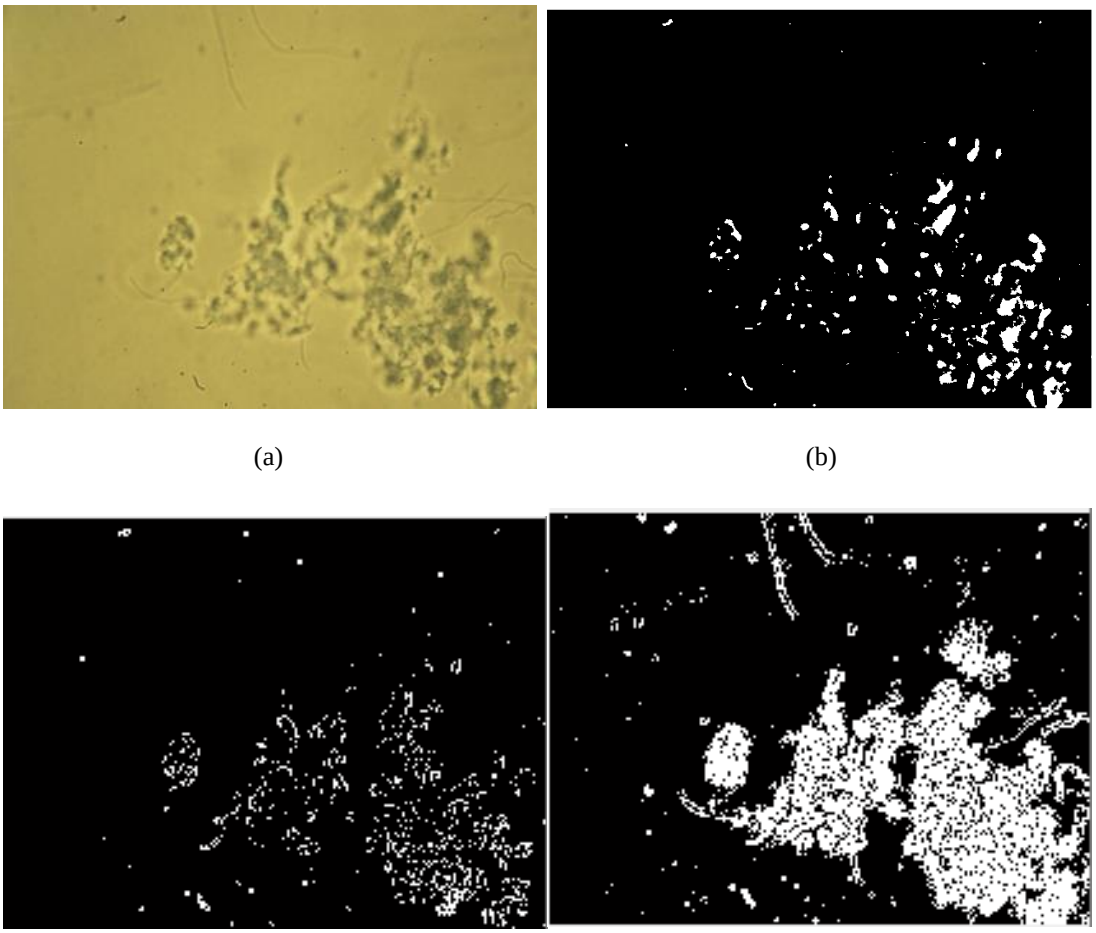
görüntüleri Şekil 5.5'de gösterilmiştir. Bu değerin az veya fazla olması bölütlemeyi başarısız kılmaktadır. Şekil 5.5'de görüldüğü gibi iterasyon değeri bölütleme sonucunu çok fazla etkilediğinden dolayı önemlidir. Şablon katsayıları sabit tutulduğunda iterasyon sayısının görüntünün özelliklerine göre belirlenmesi gerekmektedir (Boztoprak ve Özbay, 2013a).



Şekil 5.5. Farklı iterasyon (zaman) değerlerinde HSA çıkış görüntüsü, (a) 0, (b) 5, (c) 10, (d) 15, (e) 20, (f) 30, (g) 40 ve (h) 50 iterasyon değerleri için HSA çıkış görüntüleri.

Sabit iterasyon ve önerilen yöntemle hesaplanan iterasyon değeri kullanarak HSA ile elde edilen görüntüler, klasik eşikleme yöntemleriyle karşılaştırılmıştır. Sabit iterasyon değeri 15 alınmıştır. Şekil 5.6 ve Şekil 5.7'de (a) orijinal görüntüyü, (b) eşiklenmiş görüntüyü, (c) sabit iterasyon değerli HSA çıkışını (iterasyon: 15) ve (d) önerilen yöntemle hesaplanan iterasyon değeri ile elde edilen HSA çıkış görüntüleri

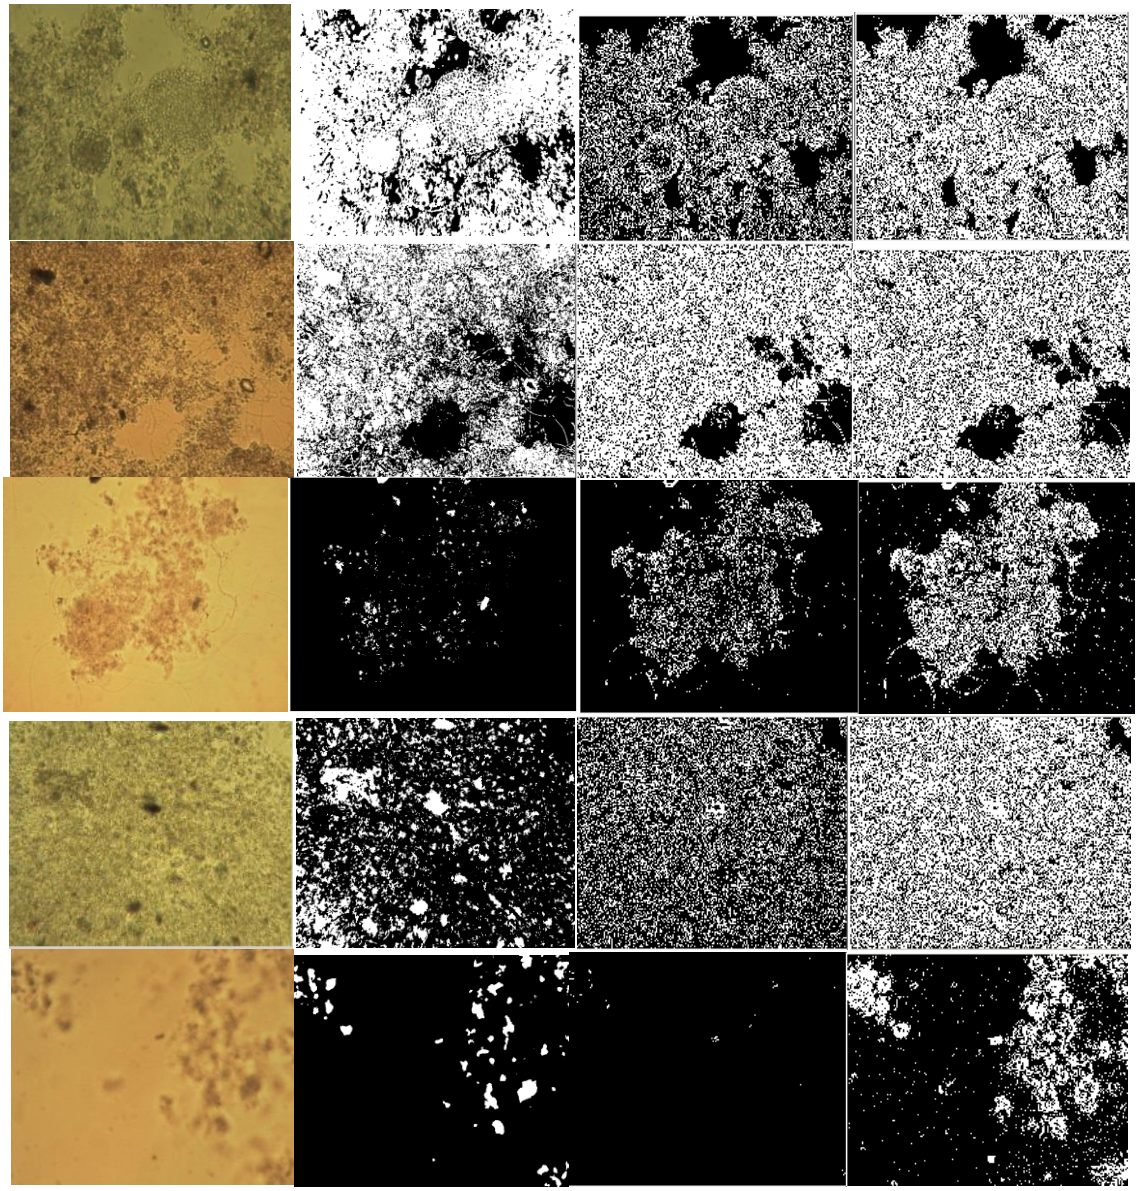
göstermektedir. Hem bulanık hem de net görüntülerde önerilen yöntemin flokların tespitinde oldukça başarılı olduğu görülmektedir. Klasik ya da sabit iterasyonlu HSA'nın bulanık görüntülerde flokları tam olarak tespit edemediği görülmüştür (Boztoprak ve Özbay, 2013a).



(a) (b)

(c) (d)

Şekil 5.6. (a) orijinal görüntü, (b) klasik metotla eşiklenmiş görüntü, (c) sabit iterasyon ile HSA çıkış görüntüsü (iterasyon: 15), (d) önerilen yöntemle hesaplanan iterasyon değeri ile elde edilen HSA çıkış görüntüsü.

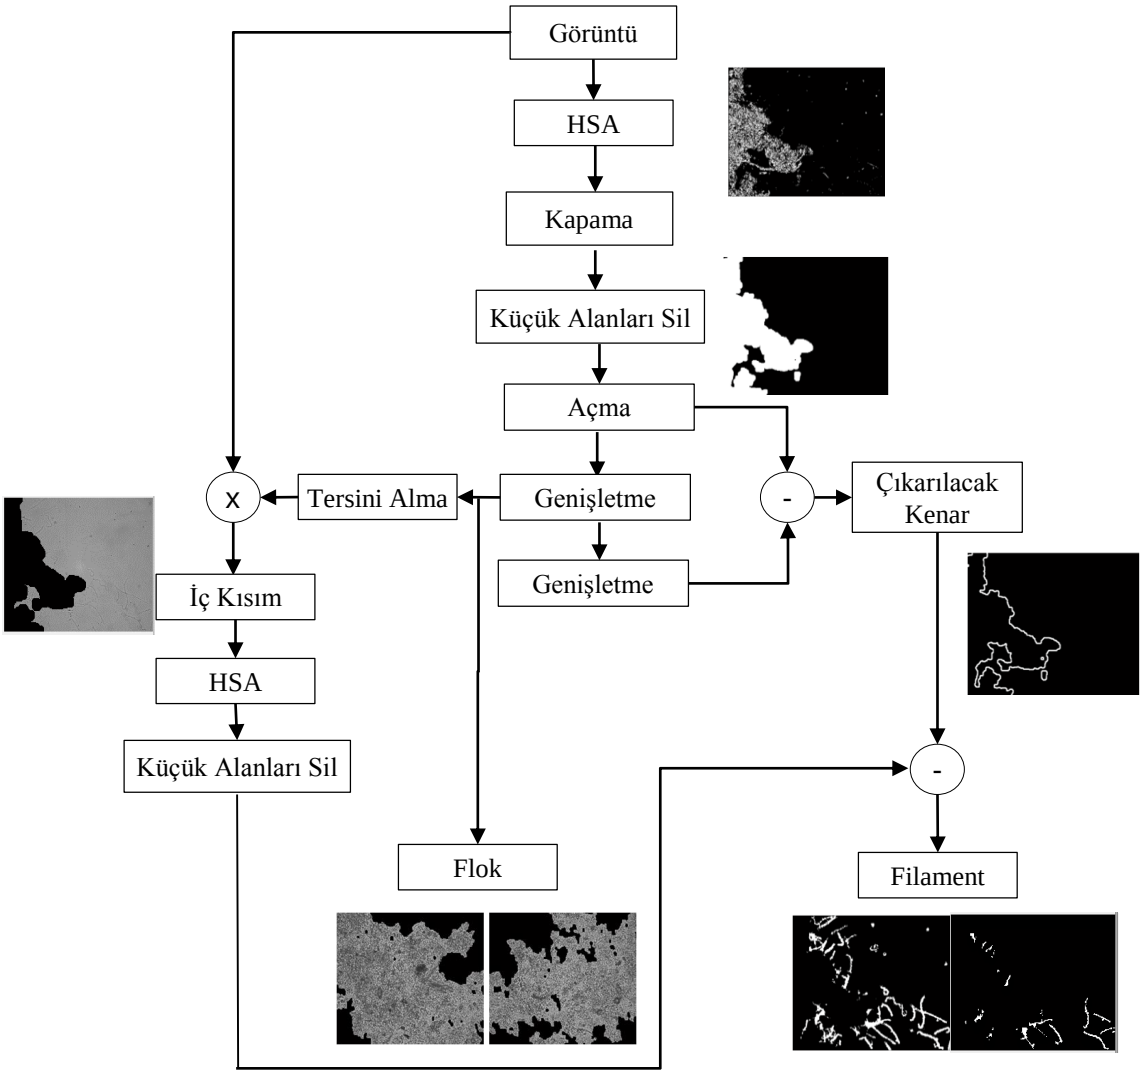


(a) (b) (c) (d)

Şekil 5.7. (a) orijinal görüntü, (b) klasik metodla eşiklenmiş görüntü, (c) sabit iterasyon ile HSA çıkış görüntüsü (iterasyon: 15), (d) önerilen yöntemle hesaplanan iterasyon değeri ile elde edilen HSA çıkış görüntüsü.

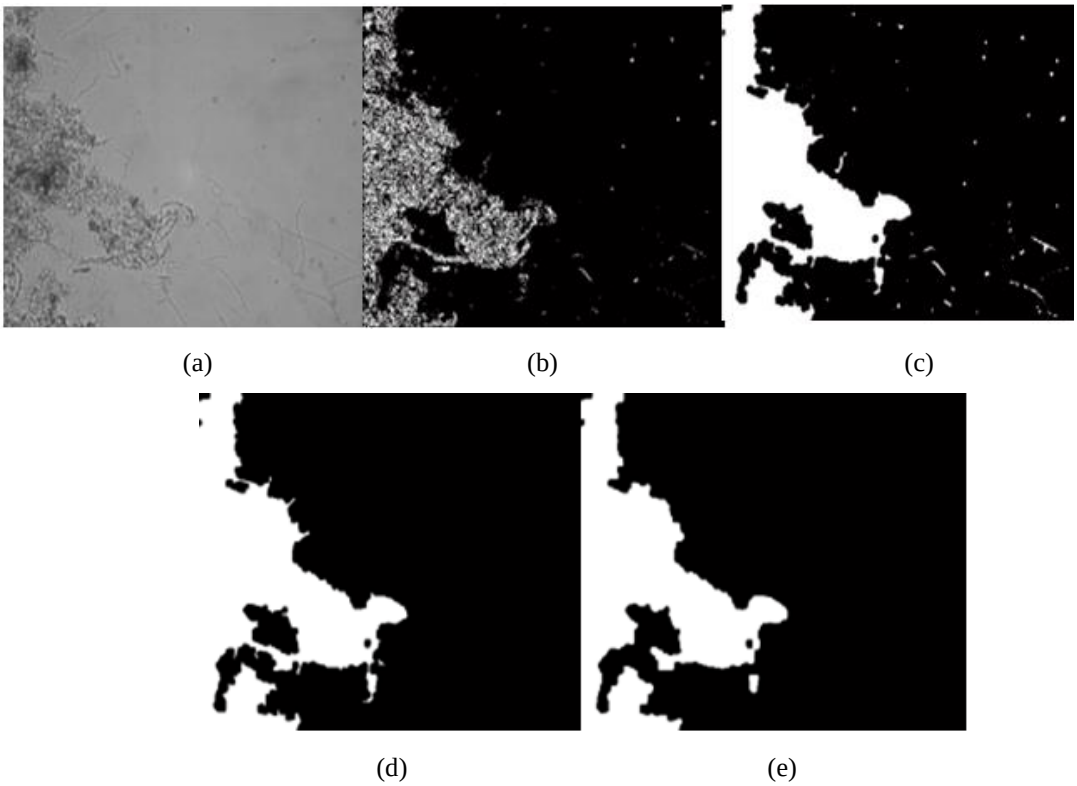
5.2. Flok ve Filamentlerin Bölütlenmesi

Bu tez çalışmasında flok ve filamentleri mümkün olduğunca doğru şekilde tespitini sağlamak adına bir dizi morfolojik işlemler uygulanmıştır (Şekil 5.8).

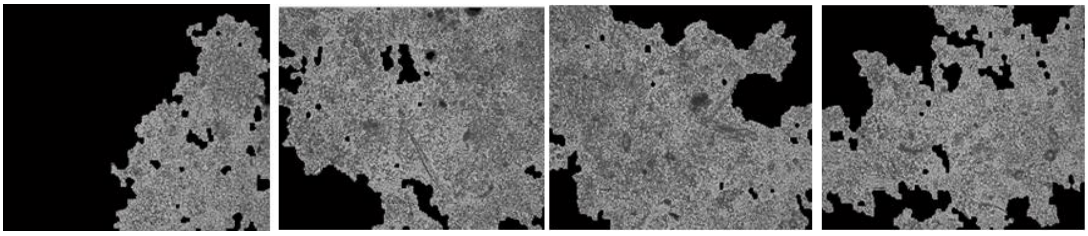


Şekil 5.8. Flok ve filamentlerin ayrıştırılması

İlk olarak, flokla birleşen filamentler görüntüden ayrıştırılmıştır. Bunun için HSA işleminden sonra elde edilen görüntüye, Şekil 5.9'da gösterildiği gibi sırasıyla kapama, küçük piksellerin çıkarılması, açma, genişletme işlemleri uygulanmıştır. Şekil 5.9 (a)'da gri skaladaki görüntü, (b)'de HSA işleminden sonra elde edilen görüntü gösterilmiştir. Şekil 5.9 (c)'de kapama işlemi uygulanmış görüntü, (d)'de küçük piksellerin silindiği görüntü ve (e)'de de açma ve genişletme işlemlerinin art arda uygulanmasıyla elde edilen görüntü gösterilmiştir. Bu işlemler sonunda, floklara bağlı filamentler görüntüden çıkarılmıştır. Bölütleme sonucu elde edilen flokların gri skalada görünümü Şekil 5.10'da gösterilmiştir.

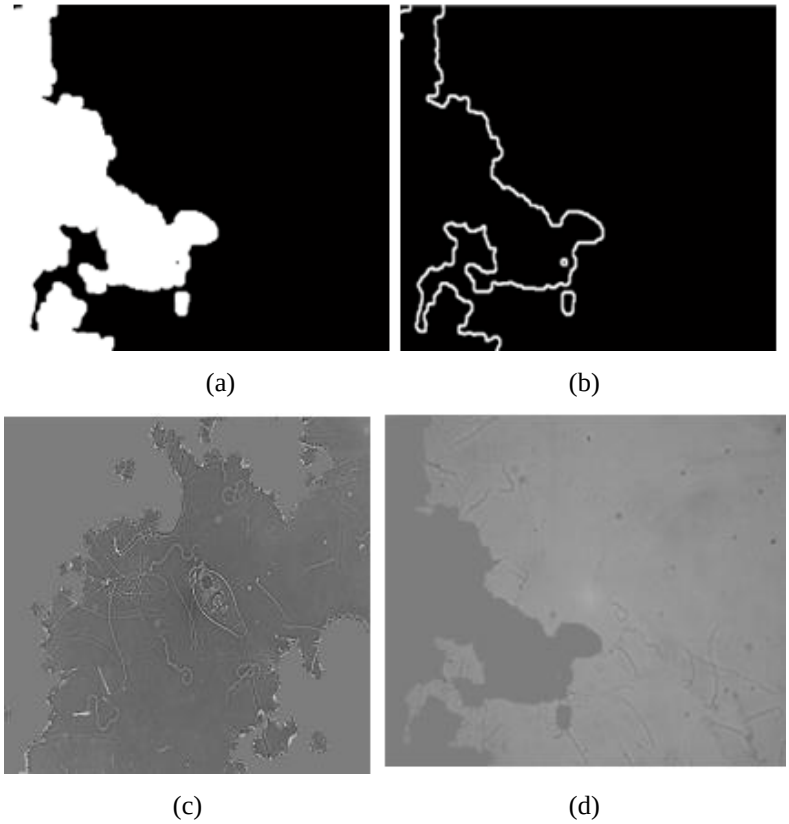


Şekil 5.9. Flok bölütleme (a) gri skalalı görüntü, (b) HSA işleminden sonra elde edilen görüntü, (c) kapama işlemi uygulanmış görüntü, (d) küçük piksellerin çıkarılması, (e) açma, genişletme ve doldurma işlemlerinin uygulanması ile elde edilen görüntü.



Şekil 5.10. Bölütlenmiş flokların gri skalada gösterimi

Flok ile filament bölütlenmesinde Şekil 5.11 (b)'de gösterilen geçiş kenar hattı ne flok nede filament yapısına dâhil edilemeyeceğinden bu bölge görüntüden çıkarılmıştır. Bunun için Şekil 5.9 (e)'deki görüntüden genişleme işlemi yapılan görüntü çıkarılmıştır. Elde edilen bu görüntü, orijinal görüntüden çıkarılmıştır. Böylelikle bu kenar geçişleri görüntüden çıkarılmıştır. Şekil 5.11 (c) ve (d)'de sırasıyla kenar geçişleri olan görüntü ile kenar hatları çıkartılmış görüntü gösterilmiştir.

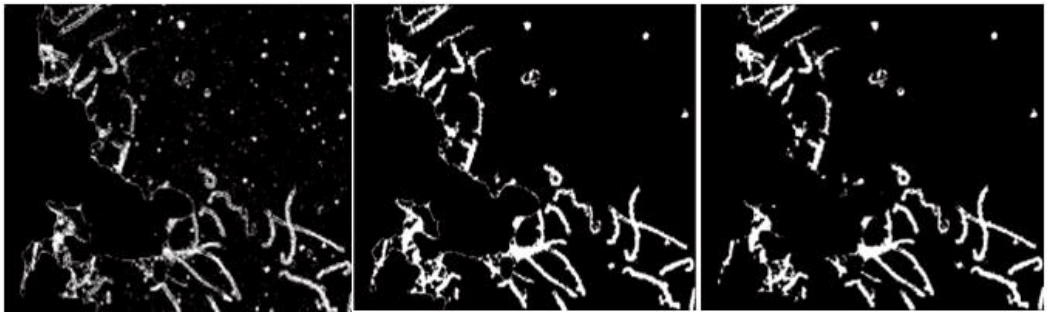


(a) (b)

(c) (d)

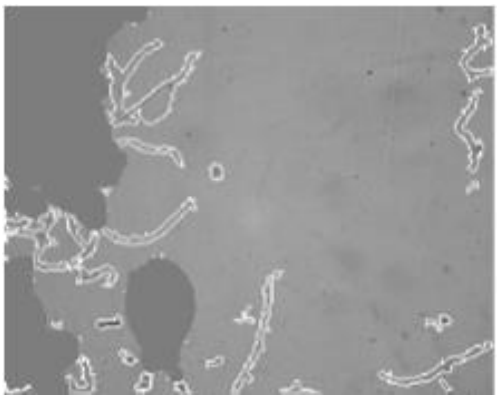
Şekil 5.11. HSA'dan sonra kenar hattının yok edilmesi, (a) bölütlenmiş flok görüntüsü, (b) çıkarılacak sınır bölge, (c) kenar hatları yok edilmemiş görüntü, (d) kenar hatları çıkartılmış görüntü

Filament Bölütleme: Küçük ve belirsiz filamentleri de tespit edebilmek için HSA'nın hesaplanan iterasyon sayısı %10 oranında artırılarak, Şekil 5.11 (d)'deki görüntüye (yani floklardan uzaklaştırılmış gri-skalalı görüntüye) uygulanmıştır (Şekil 5.12 (a)). Bu işlemden sonra gürültü olarak tanımlanabilecek ve filamentlere ait olmayan önemsiz pikseller ortadan kaldırılmıştır. Flokların bölütlemesinde olduğu gibi filament bölütlemesinde de kenar geçişleri görüntülerden çıkarılmıştır. Şekil 5.12 (b)'de küçük piksellerin oluşturduğu gürültülerinden temizlenen görüntü, (c)'de kenar hattının çıkarıldığı görüntü ve (d)'de elde edilen filamentler gösterilmiştir. Bölütleme sonucu elde edilen filamentlerin gri skalada görünümü Şekil 5.13'de gösterilmiştir.



(a) (b) (c)

Şekil 5.12. Filament bölütleme, (a) flokların çıkarıldığı görüntü, (b) küçük alanların silindiği görüntü ve (c) flok kenar hat çizgilerinin çıkarıldığı görüntü



Şekil 5.13. Belirlenen filamentlerin gösterimi

Alınan aktif çamur görüntüleri, flok ve filament yapılarına ayrı ayrı bölütlenmiştir. Her bir görüntünün sahip olduğu farklı özellikler sebebi ile değişen iterasyon sayısı kullanılmıştır. Aynı zamanda da görüntünün netlik bilgisi ölçülmüştür. Dolayısıyla flok ve filamentlerinin bölütlenmesi işleminde, görüntünün tipine ve çalışmanın amacına uygun olarak yeni bir yöntem önerilmiştir (Boztoprak ve Özbay, 2013a).

6. ÇAMUR HACİM İNDEKSİNİN TAHMİNİ

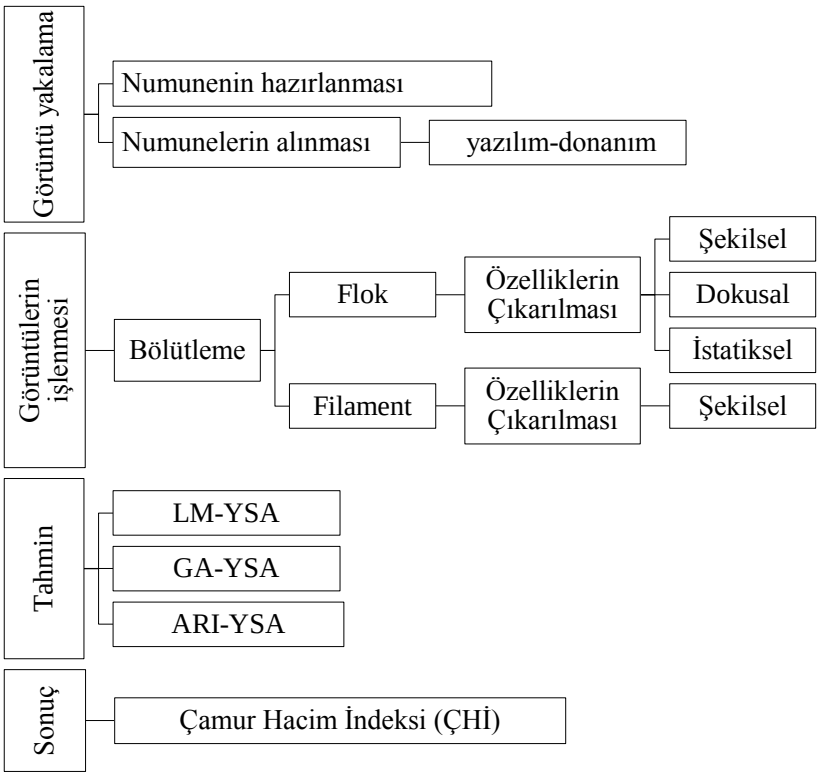
Çamur hacim indeksi (ÇHİ) flok yapısı ve çökelme özellikleri hakkında bilgi edinmek için kullanılmaktadır. Atıksu arıtma tesislerinde verimin takip edilmesi için kritik çıkış parametrelerinden olan ÇHİ günlük olarak izlenmesi gerekmektedir. ÇHİ değerinin geleneksel yöntemler ile hesaplanması yaklaşık 3 saat sürdüğü göz önünde bulundurulduğunda daha kısa sürede tahmin edilmesi ve buna göre prosesin yönetilmesi önem arz etmektedir.

Aktif çamur sistemlerinde özellikle kabarma ve köpük problemleri pek çok evsel ve endüstriyel tesislerde gündeme gelmektedir. Bunun sonucunda aktif çamurun taşmasına ve son çökeltim havuzunda da çökelmeme sebebiyle katı-sıvı ayırımı yapılamamaktadır. Probleme neden olan biyolojik parametrelerin, özellikle flok yapısı ve filamentli mikroorganizmaların durumunun ortaya konmasının büyük önem taşıdığı vurgulanmaktadır (Övez, 2010).

Bu bölüm, çamur hacim indeksi tahmini için geliştirilen sistemin adımları, görüntülerin alınmasında kullanılan tesisatın özellikleri, numunenin hazırlanması, programın genel görünümü, görüntülerin işlenmesi, flokların ayrımında kullanılacak özelliklerin belirlenmesi ve tahmin aşamalarından oluşmaktadır.

6.1. Sistemin Genel İşleyiş Adımları

Sistem genel işleyiş aşamaları Şekil 6.1'de gösterildiği gibi dört kısımdan oluşmaktadır. Bunlar; görüntü yakalama, görüntülerin işlenmesi, tahmin ve sonuç kısımlarıdır. Görüntü yakalama aşaması; numunelerin alınması, donanım ve bu donanıma uygun yazılımdan oluşmaktadır. Görüntü işleme aşamasında, flok ve filament yapıları ayrıştırılmış ve sonrasında bunlara ait morfolojik ve dokusal özellikler çıkarılmıştır. Çıkarılan bu özellikler YSA ile sınıflandırılarak çamur hacim indeksi tahmin edilmiştir. YSA'ların ağırlıkları, Levenberg-Marquardt, genetik ve arı algoritmaları ile eğitilmiştir. Sonuç olarak da ÇHİ değeri verilmiştir.



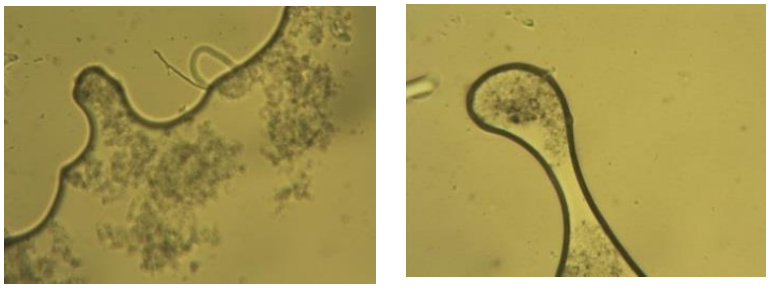
Şekil 6.1. Sistemin genel işleyiş adımları

6.2. Numunenin Hazırlanması

Atıksu arıtma tesisinde çalışanlar tarafından her gün düzenli olarak havalandırma havuzundan örnekler alınmaktadır. Bu örnekler laboratuvar ortamında günlük ölçümler için kullanılmaktadır. Bu alınan örnekten 1L kadarı imhoff hunisine konulmaktadır. Bu çalışmada mikroskopta incelenecek olan numuneler bu imhoff hunisinden alınmıştır. Numune alınmadan önce imhoff hunisi iyice karıştırılmıştır. Numunenin, huninin ortasından alınmasına dikkat edilmiştir. Hazırlanan numune lam üzerine yerleştirip sonra lamel ile kapatılmıştır.

Bu kapatma işleminden sonra bazen lamelin altında hava kabarcıkları oluşmaktadır. Oluşan bu hava kabarcıkları mikroskopta büyük parlak küreler olarak görülmektedir. Hava kabarcıkları lamelin lam üzerine yavaşça yerleştirilmesi yerine hızla ve yukarıdan kapatılmasından meydana gelmektedir. Hava kabarcığı olan bir numune hatalı olarak kabul edilmiştir ve yeni bir numune hazırlanmıştır. Hazırlanan numune motor kontrollü XY tarama platformun üzerine yerleştirilmiştir.

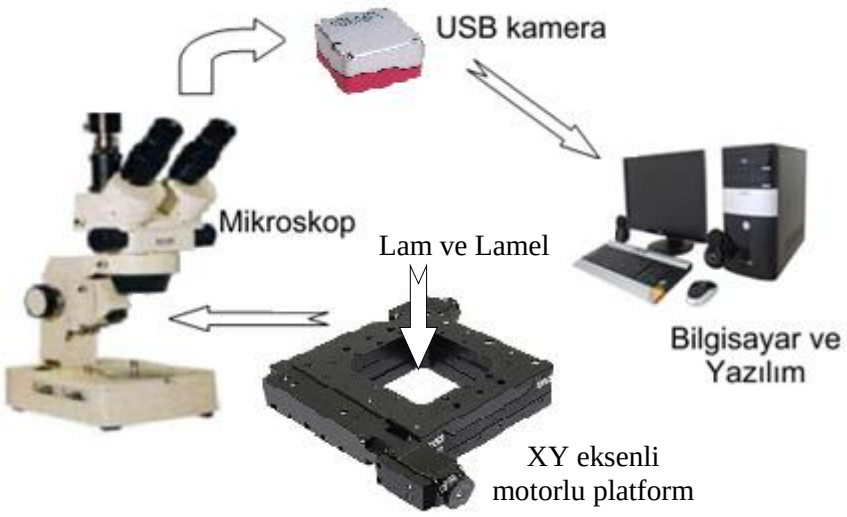
Yapılan denemelerde, lamdaki numunenin on dakika sonra bozulmaya başladığı gözlenmiştir. Şekil 6.2'de bozulmaya başlamış aktif çamur görüntüleri gösterilmiştir. Numuneleri hazırlama, odak ayarlama, tarama işlemleri ve görüntülerin alınması aşaması, bu süre içinde tamamlanmalıdır.



Şekil 6.2. Bozulan aktif çamur görüntüleri

6.3. Görüntülerin Alınmasında Kullanılan Düzenek ve Özellikleri

Motor kontrollü XY (8MTF) tarama platformu ile mikroskop kamerası (Moticam 2500) Motic AE21 mikroskobuna monte edilerek bilgisayarın USB portlarına bağlanmıştır. Konya Kentsel Atıksu Arıtma Tesisin laboratuvarında bulunan Motic AE21 inverted mikroskobu kullanılmıştır. Sistem donanımının genel görünüşü Şekil 6.3'de gösterilmiştir.



Şekil 6.3. Sistem donanımının genel görünüşü

Motorlu platformlar birçok farklı konfigürasyonlarda olabilmektedir, örneğin, XY, XYZ ve XYZ/r (dönme). Bu çalışmada motorlu XY tarama platformu (8MTF) kullanılmıştır. Bu platformlar yüksek doğruluk ve tekrarlanabilirlik gerekli olduğu uygulamalar için tasarlanmışlardır. Tarama aralığı 102 x 102 mm (4")'dir. USB arayüzü ve görüntü analizi için çeşitli mikroskop türleri için kullanılabilir özel konsollar ile PC kontrolü vardır. Bu motorlu tarama platformu USBhF-8SMC1 mikro sürücü (usb arabirim) ile kontrol edilmiştir. Bu motorlu platformlar, önceleri imkânsız olan veya son derece zaman alıcı işleri, platform sürüklenme olasılığını ortadan kaldırarak, sıralı görüntü toplamayı mümkün kılmaktadır.

XY platform ile odak ayarı yapmak oldukça zor ve zaman alıcıdır. Çünkü tarama aşamasında platformun ileri geri hareketi ile numunenin bazı bölümleri odak dışında kalabilmektedir. Dolayısıyla görüntü bulanık elde edilmektedir. Odak mekanizmasının, platformun her hareketinde ayarlanabilir olması gerekmektedir. Kullandığımız XY platformunda Z ekseni olmadığından, odak noktası otomatik olarak ayarlanamaz. Yani, her yerde net bir görüntü elde etmek mümkün olmayabilir.

6.4. Görüntü Alımı İçin Geliştirilen Yazılım

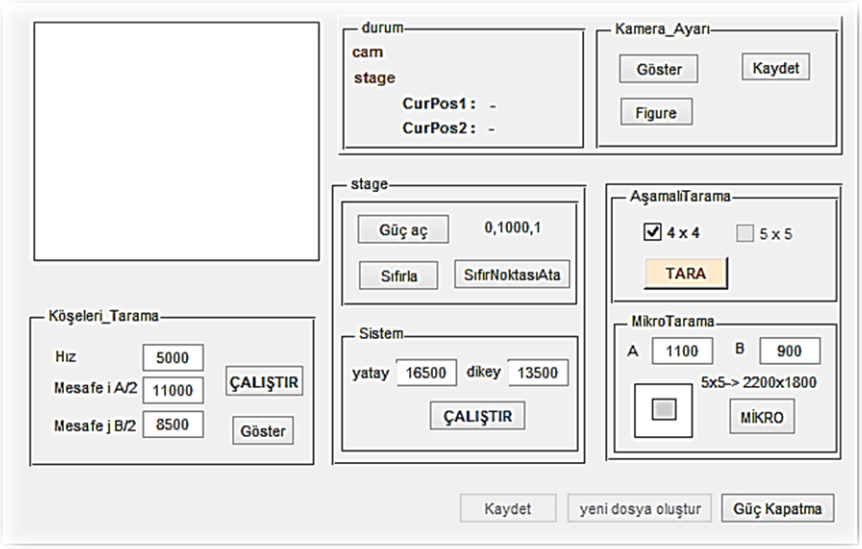
Görüntülerin sistematik ve otomatik olarak alınmasını ve işlenmesini sağlayacak bir sistemin kurulması için Matlab GUI'de kullanıcı arayüzü tasarlanmıştır (Şekil 6.4). Hem mikroskop kamerasının hem de motorlu platformun senkron bir biçimde çalışması sağlanmıştır.

Bu çalışmada numune üzerindeki alanın, sistematik bir şekilde ve bitişik olarak taranması amaçlanmıştır. Aynı zamanda farklı tarama seçenekleri de arayüze eklenmiştir. Örneğin; bitişik taranması yerine ekrandan girilen değer kadar atlanarak taranması gibi. Bu yazılım vasıtasıyla; hız ayarı, platformun ve kameranın mevcut konumu hakkında bilgi, alınma tarihine göre dosyalama, kareler şeklinde görüntü tarama, seçilen bir konumun etrafını atlamadan tarama işlemleri yapılabilir. Uygulama günlük mikroskop kullanıcılar için kullanımı kolay, aynı zamanda özel taramalar için ayarlamalar sunmaktadır.

Şekil 6.4'de görüldüğü arayüzdeki durum kısmı; kameranın bağlı olup olmadığını, platformun güçlerinin açık veya kapalı olma durumunu ve başlangıç koordinat bilgilerini göstermektedir. Çalıştır ve tarama düğmeleri geçerli ayarları kullanarak görüntülerin

yakalanmasını sağlamaktadır. Bu işlemler esnasında alınan görüntüler ana formun penceresinde görüntülenir ve platformun o anki koordinat bilgisi de gösterilmektedir.

Şekil 6.4'deki görüntü alma arayüz ile istenilen pozisyonlara ait görüntüler otomatik olarak alınmış ve program vasıtasıyla görüntülerin alındığı tarihli bir klasörün içine kaydedilmiştir. Her bir görüntü xy koordinat numaralarıyla jpg formatında saklanmaktadır.



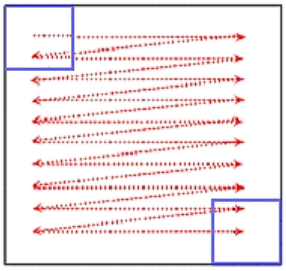
Şekil 6.4. Otomatik veri toplama için geliştirilmiş kullanıcı arayüzü

6.5. Görüntü Yakalama

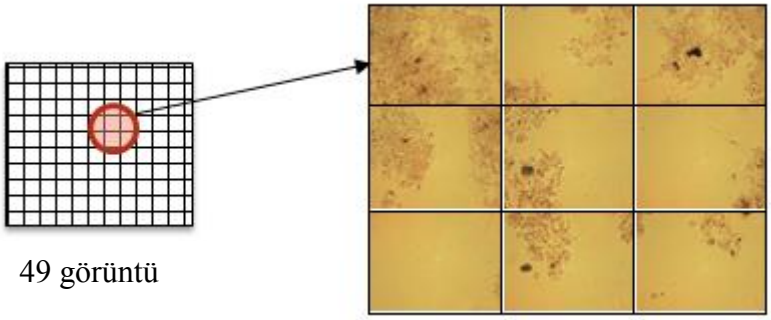
Literatürde yapılan çalışmalarda, bir numuneden 20 ile 200 arasında değişen sayıda görüntüler sistematik bir şekilde alınmıştır. Bu alınan görüntülerin flok yapıları incelenerek, görüntü işlemeyle elde edilen veriler ile bazı çevre verileri arasındaki ilişkiler araştırılmıştır (Motta ve ark., 2001; Perez ve ark., 2006; Jenne ve ark., 2007; Mesquita ve ark., 2009b). Numuneden alınacak görüntü sayısı tartışma konusu olmuştur. Mesquita ve arkadaşları her numuneden 30 adet görüntü alınmasının görüntü işleme ile elde edilen veriler ile klasik metotla bulunan değerler arasında ilişkinin bulunması için yeterli olduğunu belirtmişlerdir.

Hazırlanan numune, mikroskoba monte edilen motorlu tarama platformun üzerine uygun pozisyonda yerleştirilmiştir. Daha sonra yazılım arayüzü çalıştırılarak mikroskoptan odak ayarı yapılmıştır. Bu işlemin ardından, geliştirilen arayüz vasıtasıyla

numune sol üst köşeden başlayarak sağ alt köşeye kadar, Şekil 6.5'de gösterildiği gibi, belli bir alan, sistematik olarak taranmıştır. Toplamda her numuneden 49 görüntü alınmıştır. Görüntüler Motic AE21 mikroskop ve Moticam 1.3Mp dijital renkli kamera ile 1024x1280 çözünürlükte, 40x objektifte alınmıştır. Her bir numuneden görüntüler mozaik şeklinde (Şekil 6.6) yakalanmış, alınma tarihine göre otomatik olarak dosyalanmıştır. Görüntülerin taranması yaklaşık olarak 5 dk içinde tamamlanmaktadır.



Şekil 6.5. Numunelerin taranma şekli

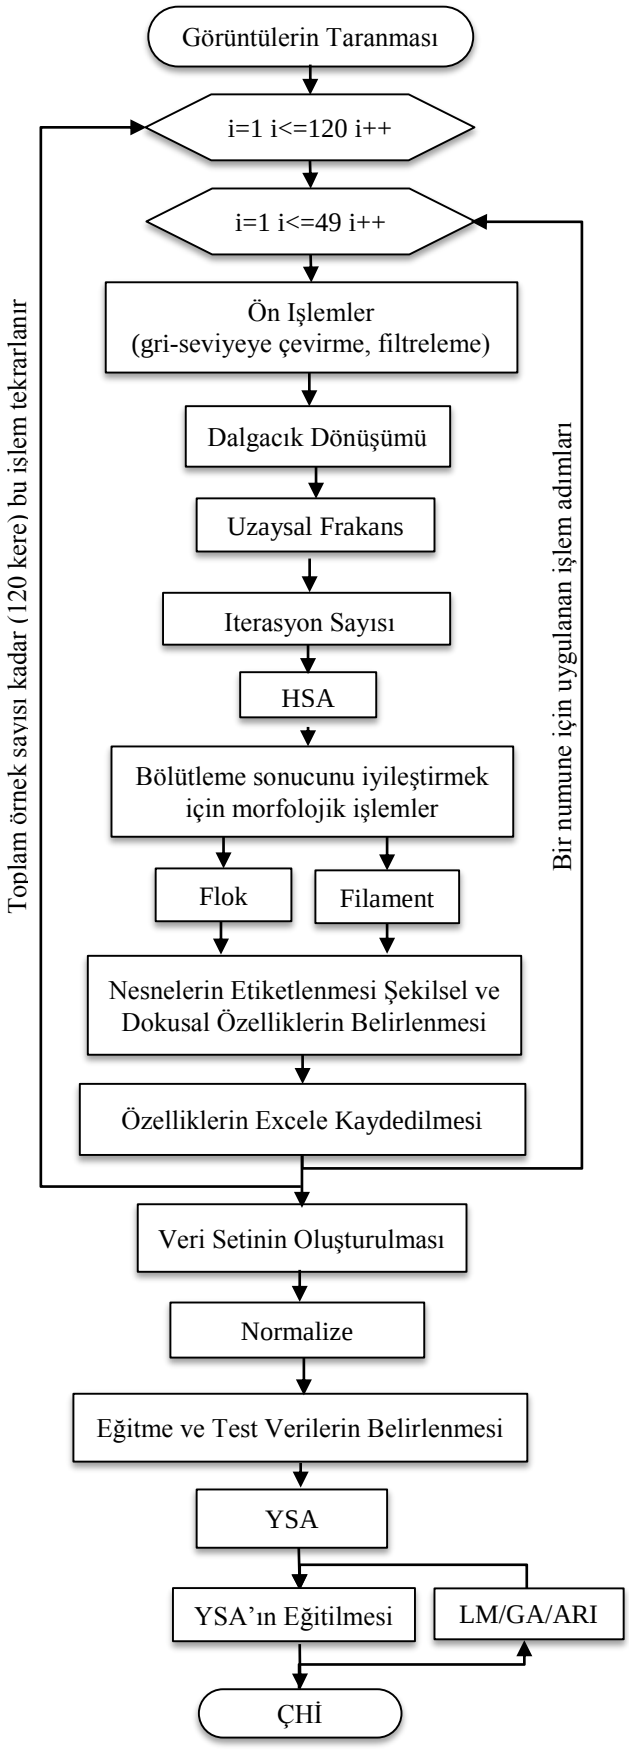


Şekil 6.6. Görüntü mozaiki

6.6. Görüntülerin İşlenmesi

Kaydedilen görüntüleri işlemek için tüm görüntüleri sırasıyla işleyen bir program yazılmıştır. 1 numuneden 49 görüntü olmak üzere 120 örnekten (gün) 49x120 toplam 5880 adet görüntünün işlenmesi gerekmektedir. Her görüntüden 33 adet özellik çıkarıldığı da dikkate alınırsa 5880x33 toplam 194040 boyutunda bir data söz konusudur.

Kaydedilen tüm görüntüler ardışık olarak işlenmiş ve elde edilen sonuçlar Excel formatında kaydedilmiştir. Görüntülerinin işlenmesi ve ÇHİ bulunmasında uygulanan yöntemlerin işlem adımları Şekil 6.7'de gösterilmiştir.



Şekil 6.7. Görüntülerin işlenmesi ve ÇHİ bulunmasında uygulanan adımlar

Alınan görüntüler öncelikle gri görüntüye çevrilmiş ve istenmeyen gürültülerin temizlenmesi için median filtre uygulanmıştır. Sonrasında bu görüntüye dalgacık dönüşümü uygulanmıştır. Bölütleme aşamasında, her bir görüntünün sahip olduğu farklı karakteristik yapı sebebi ile her görüntünün özelliğine göre değişen iterasyon değeri kullanılmıştır (Boztoprak ve Özbay, 2013a). Bunun için HSA ve dalgacık dönüşümünün birlikte kullanıldığı bir yöntem önerilmiştir. Bu yöntemde, görüntünün özelliğine göre değişen veya görüntünün netlik ölçüsünü belirten bir parametre belirlenmiştir. Bu parametrenin belirlenmesinde dalgacık dönüşümü ve uzaysal frekansın birlikte kullanıldığı bir yöntem önerilmiştir. Belirlenen bu parametrede HSA'nın iterasyon değerinin belirlenmesinde kullanılmıştır. Bu metot ile farklı özelliklere sahip atıksu görüntülerin, içeriğinden bağımsız olarak bölütlenmesi sağlanmıştır. Flok ve filamentleri mümkün olduğunca doğru şekilde tespitini sağlamak adına HSA işleminden sonra bir dizi morfolojik işlemler uygulanmıştır. Önerilen yöntemin ayrıntıları Bölüm 5'de verilmiştir.

Bölütleme sonrası elde edilen flok ve filamentlerin özellikleri çıkarılmıştır. Çok küçük flok alanlarının, flok yapısı hakkında bilgi vermesi oldukça zor olacağından çok küçük flokların dokusal özellikleri dikkate alınmamış, ama alan bilgisi toplam alana dâhil edilmiştir. Flokların hem morfolojik hem de dokusal özellikleri ayrı ayrı belirlenmiştir. Çünkü flokların yapısı katı-sıvı ayırımında büyük önem taşımaktadır (Jenkins ve ark., 1993; Sezgin, ve ark., 1977; Övez, 2010). Filamentlerin ise uzunluk bilgisi olarak alan bilgileri hesaplanmıştır.

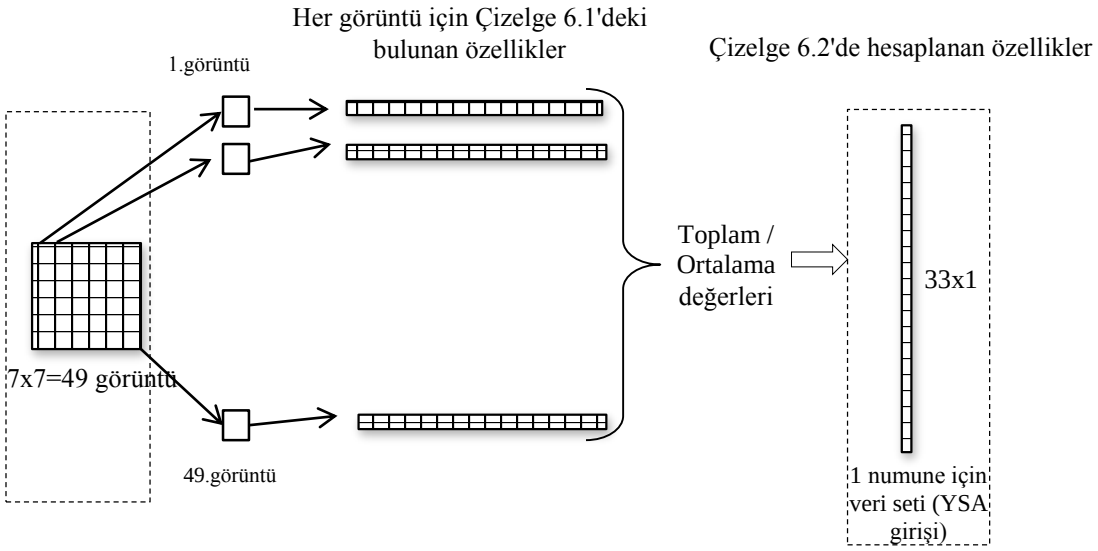
Flokların özelliklerinin belirlenmesinde yoğunluk tabanlı özellikler, şekilsel ve istatistiksel özelliklerden yararlanılmıştır. Hesaplanan bu özelliklerin listesi Çizelge 6.1'de gösterilmiştir ve bu özellikler bir matris olarak Excel ortamına aktarılmıştır. Görüntülerin kayıt tarihiyle oluşturulmuş sayfaya 1 numune için 49 görüntünün özellikleri program vasıtasıyla kaydedilmiştir. Bazı görüntülerde bir görüntü içinde ayrı ayrı birden fazla flok bölgesi vardır. Bu bölgelerin özellikleri ayrı ayrı hesaplanarak alt alta kaydedilmiştir.

Çizelge 6.1. Görüntülerden çıkarılan özellikler

	Veriler
1	Filament uzunluğu
2	Flok alanı
3	Nesnenin kenar piksellerinin sayısı
4	Şekil faktörü
5	Doldurulmuş alan
6	Boşluk miktarı
7	Boy oranı
8	Yuvarlaklık
9	Sağlamlık katılık
10	Dış merkezlilik
11	Kapsam
12	Eşdeğer dairesel yarıçap
13	Standart sapma
14	Ortalama değer
15	Giriş görüntüsünün entropi değeri
16	Flokların entropi değeri
17	Karşıtlık
18	İlinti (Karşılıklı ilişki)
19	Enerji
20	Tekdüzelik

6.7. Veri Setinin Oluşturulması

Görüntülerden elde edilen özelliklerin değerleri Excelde ayrı sütunlarda bulunmaktadır. 120 örnek olduğundan toplam 120 sayfa yer almaktadır. Her sayfanın en sonunda, her bir sütunun toplamları, ortalamaları ve standart sapmaları hesaplanmıştır. Şekil 6.8'de bir numune için bir veri setinin oluşturulması gösterilmiştir.



Şekil 6.8. Bir numuneden bir veri setinin oluşturulması

Flok, filament, doldurulmuş alan ve çevre bilgilerin toplamları, diğer özelliklerin ortalamaları dikkate alınarak Çizelge 6.2'de gösterilen özellikler hesaplanmıştır. Böylece her güne ait 33 özellikli veri seti oluşturulmuştur.

Çizelge 6.2. Veri setinin oluşturulmasında kullanılan özellikler

1	Toplam filament uzunluğu	Görüntü içerisinde yer alan nesnenin kapladığı alanı piksel bazında ifade edilmesi
2	Toplam flok alanı	
3	Toplam alan	Filament+Flok
4	Toplam çevre	Nesnenin kenar piksellerinin sayısı
5	Şekil faktörü	4*pi*alan/ Çevre^2
6	Toplam doldurulmuş alan	Boşlukları doldurulmuş olarak piksel bilgisi
7	Gözenek	Nesne içerisindeki deliğin piksel miktarıdır. Doldurulmuş alan/toplam alan
8	Boy oranı (AR)	AR=1+4* (uzunluk/genişlik-1) / pi
9	Yuvarlaklık	4*alan/ (pi*uzunluk^2)
10	Katılık	Sağlamlık, yoğunluk özelliği görüntü içinde etiketlenmiş nesnelerinin içerisinde yer alan boşluğun alana olan oranını ifade eder. Alan/Konveks alan.
11	Dış merkezlilik	Odak mesafesi ve nesnenin o anda sahip olduğu elipsin en büyük eksen uzunluğu arasındaki orandır.
12	Kapsam	Nesnenin alanı ve sınır çerçevesinin alanı arasındaki orandır. Alan / Bounding alan

13	Eşdeğer dairesel yarıçap	$De = \sqrt{\frac{4}{\pi} Alan}$
14	Standart sapma	$\sigma_g = \sqrt{\sum_{g=0}^{L-1} (g-\bar{g})^2 \, P(g)}$
15	Ortalama değer	$\bar{g} = \sum_{g=0}^{L-1} gP(g) = \sum_{r} \sum_{c} \frac{I(r,c)}{M}$
16	Giriş görüntüsünün entropi değeri	$Entropi = \sum_{g=0}^{L-1} P(g) \log_2[P(g)]$
17	Fokların entropi değeri	Flok görüntülerinin entropi değeri
18	Karşıtlık	$karşıtlık = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\}, \lvert i-j \rvert = n$
19	İlinti	$ilinti = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
20	Enerji	$enerji = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j)^2$
21	Tekdüzelik	$tekdüzelik = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} \, p(i,j)$
22	Toplam filament / toplam flok	
23	Toplam filament / toplam alan	
24	Toplam flok/ toplam alan	
25	Toplam toplam filament / doldurulmuş alan	
26	Toplam flok / toplam doldurulmuş alan	
27	Toplam gözenek / toplam flok	
28	Toplam gözenek / toplam alan	
29	Toplam gözenek / toplam filament	
30	Toplam çevre / toplam flok	
31	Toplam çevre / toplam filament	
32	Toplam çevre / toplam alan	
33	Toplam gözenek / toplam çevre	

Elde edilen veri setleri 33 giriş parametresi ile 120 adet örnek veriden oluşmaktadır. Hem giriş hem de çıkış veri setleri minimum-maksimum metodu kullanılarak -1, +1 aralığında normalize edilmiştir. 33 giriş parametresi kendi içinde ayrı ayrı, birbirlerinden bağımsız olarak normalize edilmiştir. Normalizasyon sonunda her bir

sütun ayrı ayrı normalize edildiği için her bir sütunun maksimum ve minimum değeri ayrı olmaktadır. Görüntü işlemeyle elde ettiğimiz bu veriler ile klasik yöntemlerle elde edilen ÇHİ değeri arasında bir YSA modeli oluşturulmuştur.

6.8. Çamur Hacim İndeksinin Tahmininde Kullanılan Yapay Sinir Ağı

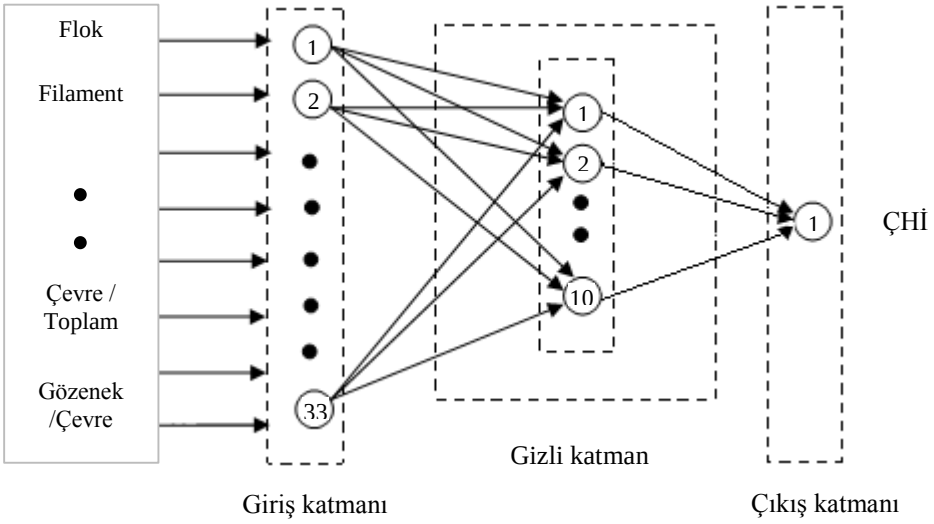
Bu çalışmada, 3 katmanlı bir yapay sinir ağı oluşturulmuş, öğrenme algoritması olarak geri yayılım algoritması kullanılmıştır. YSA modelinin girdi ve çıktı katmanlarındaki işlem elemanı sayıları problemin geometrisine bağlı olarak oluşmaktadır. YSA'nın girdi katmanında, incelenecek olan her bir veri için 33 adet, tek parametreli tahmin yapılacağı için çıkış katmanında bir düğüm bulunacaktır. Ancak gizli katman sayısının ve gizli katmanlardaki işlem elemanı sayılarının belirlenmesinde herhangi bir kural yoktur. Gizli katman sayısı ve bu katmanlardaki işlem elemanı sayıları, literatürdeki birçok çalışmada deneme ve yanılma yöntemi ile belirlenmiştir.

Geriye yayılım ağı eğitme fonksiyonu olarak oldukça hızlı yakınsayan bir metot olan Levenberg-Marquardt geri yayılım algoritması (trainlm) kullanılmıştır. Bütün düğümler için transfer fonksiyonu tansig ve başlangıç ağırlıkları rastgele seçilmiştir. Bir adet gizli katman seçilmiş ve bu tek gizli katmandaki işlem elemanı sayısının 5 ile 20 arasında değişen değerlerde olması durumunda YSA modelinin performansı belirlenmiştir (Çizelge 6.3). Hedef MSE değeri (durdurma kriteri) 0.001, öğrenme katsayısı 0.9 seçilmiştir. Gizli katmanın seçiminde 120 verinin %80'i eğitim, %20'si test olmak üzere kullanılmıştır. YSA ile elde edilen sonuçlarla, gözlenen veriler arasında ortalama karesel hata (MSE) ve korelasyon katsayısı (r) karşılaştırma kriteri olarak verilmiştir. Çizelge 6.3'de ara katmandaki eleman sayısına bağlı olarak MSE ve r değerleri gösterilmiştir.

YSA tabanlı performans değerlendirme modelinin gizli katmanlarının işlem elemanlarının sayısı, eğitim ve test seti için elde edilen iki kritere bağlı olarak seçilmiştir. Seçim yapılırken, eğitim ve test seti r değerlerinin birbirine yakınlığı ve 1' yakınlığı olan en uygun YSA modeli seçilmiştir (r=0.9155 ve MSE=0.0709). Bu nedenlerden dolayı, bu çalışmada gizli katman düğüm sayısı 10 seçilmiştir. Kullanılan YSA ağ modeli ağ topolojisi Şekil 6.9'da verilmiştir.

Çizelge 6.3. Gizli katmandaki düğüm sayısının belirlenmesi
(Eğitim ve test setinin MSE ve r değerleri)

	Eğitme		Test	
Ara kat nöron sayısı	**r**	**MSE**	**r**	**MSE**
5	**0.90**	0.051	**0.88**	0.05
6	**0.958**	0.024	**0.88**	0.15
8	**0.927**	0.033	**0.907**	0.08
10	**0.99**	0.011	**0.915**	0.07
12	**0.93**	0.029	**0.91**	0.14
15	**0.99**	0.010	**0.898**	0.12
20	**0.96**	0.013	**0.85**	0.13



Şekil 6.9. ÇHİ tahmin için geliştirilen YSA modeli ağ topolojisi

YSA'ların ağırlıkları, Levenberg-Marquardt, genetik ve arı algoritmalarıyla eğitilmiştir. Çalışma boyunca YSA modellemesi yaklaşımının birbirlerine göre üstünlüğünü görebilmek amacıyla aynı YSA mimarisi kullanılmıştır. 33:10:1 mimarisi için eğitilecek toplam ağırlık sayısı Eşitlik (6.1) ile hesaplanır (Düğenci, 2007).

$$\text{Toplam ağırlık sayısı} = (NG+1)*NA + (NA+1)*NC \qquad (6.1)$$

Burada;

NG = YSA giriş katmanı düğüm sayısı

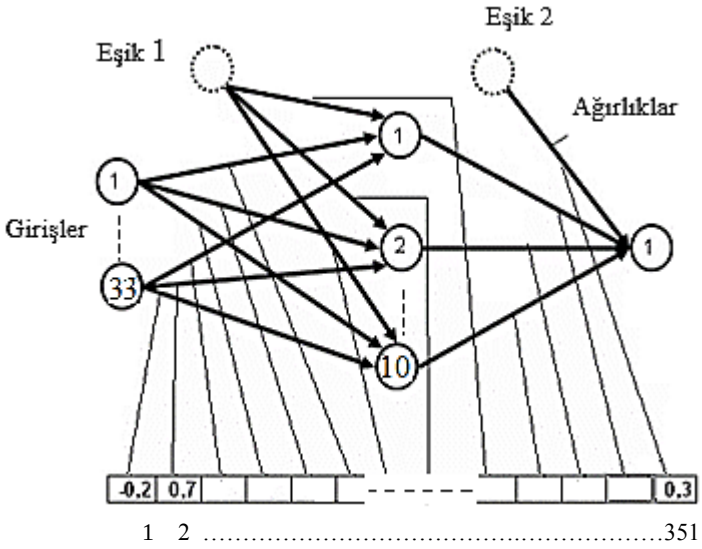
NA = YSA ara katman düğüm sayısı

NC = YSA çıkış katmanı düğüm sayısıdır.

Oluşturulan YSA yapısında 33 adet giriş, 10 adet gizli, 1 adet çıkış katmanı ve bias ağırlıkları dâhil olmak üzere optimize edilecek toplam ağırlık sayısı Eşiklik (6.2) ile 351 bulunmuştur.

Toplam Ağırlık Sayısı= (33+1)*10 + (10+1)*1 =351 (6.2)

Şekil 6.10'da bir YSA'ya ait ağırlıklarının temsili görsel olarak verilmektedir. YSA eğitimini hedef fonksiyon olarak düşünürsek 351 parametreli bir vektör ortaya çıkar. Aynı zamanda bu vektör hedef fonksiyonunun (YSA modülünün) giriş vektörüdür.



Şekil 6.10. YSA ağırlıkların 33:10:1 için temsili gösterimi

Yöntemlerin kıyaslamalı analizinde çapraz doğrulama yaklaşımı tercih edilmiştir. k-kat çapraz doğrulama ile mevcut verinin daha iyi kullanılması sağlanmaktadır.

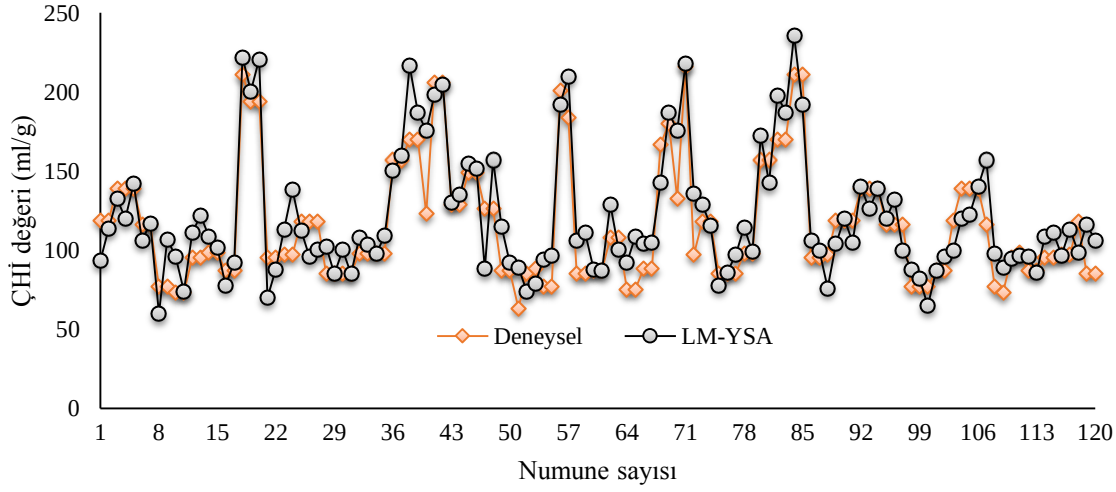
k-kat çapraz doğrulama (k-fold cross validation) yöntemi: Çapraz doğrulama da veriler eşit büyüklükte veya yaklaşık eşit büyüklükte k adet alt kümeye bölünür. Ağ k defa eğitilerek ve her seferinde farklı bir alt küme eğitim dışında bırakılır. Her eğitim sonrasında dışarıda bırakılan alt küme hata oranını bulmak için kullanılmaktadır. Dolayısıyla k defa eğitim ve sonrasında hata bulma sonucu elimizde k adet hata mevcut olur. Bu hataların ortalaması çapraz doğrulama hata oranını vermektedir. Birçok

sınıflama çalışmasında test sonuçlarının çok daha güvenilir ve belirleyici olabilmesi için araştırmacılar arasında k-kat (fold) çapraz doğrulama yaygın olarak kullanılır. Eğitimin rastgele örneklenmesi ile ilgili yanılgı başka bir deyişle önyargı, Kohavi'nin (1995) çalışmasında da belirtildiği gibi bu yöntem ile en aza indirilir. Bunun sebebi eğitim ve test verilerinin çapraz olarak değiştirilmesi yani aynı veri seti içerisinde eğitim ve test verilerinin farklı birleşimler şeklinde kullanılmasıdır (Yücelbaş, 2012).

6.8.1. Çamur hacim indeksinin LM-YSA ile tahmini

Giriş veri setindeki 33 parametre ile oluşturulan YSA modelinde çıkış katmanı, ÇHİ'yi temsil eden tek bir düğümden oluşmaktadır. Eğitim setinden örnekler tek tek gösterilerek ağın olayı öğrenmesi sağlanmıştır. Performans sonuçlarının geçerliliğini arttırmak için eğitim ve test verileri k-kat çapraz doğrulama yöntemi uygulanarak elde edilmiştir. Bu çalışmada 5-kat çapraz doğrulama kullanılmıştır.

Kendi içlerinde rastgele karıştırılmış olan 120 veri seti 5 parçaya ayrıştırılarak 5-kat çapraz doğrulama yöntemi uygulanmıştır. Her defasında 5 parçanın 1 parçası test için (24 adet veri) geriye kalan 4 parçası (96 adet veri) ise eğitim verisi için ayrılarak eğitim ve test aşamaları çalıştırılmıştır. Tüm bu işlemler 5 kere tekrarlanmış her çalıştırmada alınan sınıflama doğruluk sonuçları toplanarak 5'e bölünmüştür. Böylece ortalama bir sınıflama doğruluğu elde edilmiştir. Bu işlemler aynı şekilde bütün eğitmeler için yapılmıştır. LM-YSA ile bulunan çamur hacim indeksinin ortalama değerleri ile tesiste deneysel yöntemlerle ölçülen değerlerin çizimi Şekil 6.11'de gösterilmiştir.

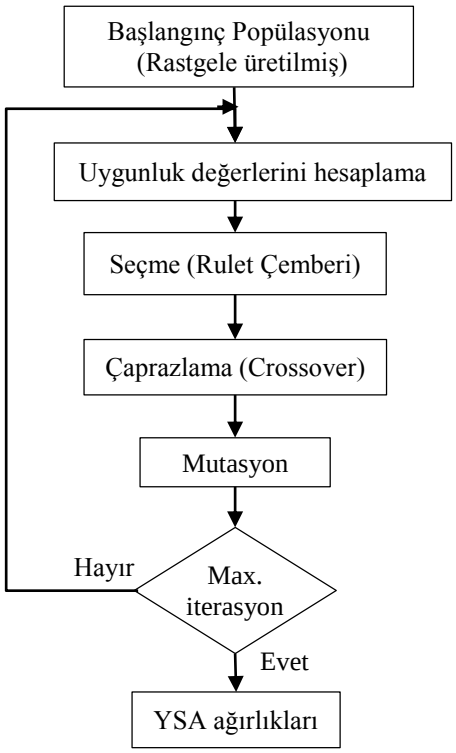


Şekil 6.11. Eğitim ve test veriler için ölçülen ve tahmin edilen ÇHİ değerlerin karşılaştırılması

6.8.2. Çamur hacim indeksinin GA-YSA ile tahmini

Genetik algoritmaların yapay sinir ağı öğrenmesinde kullanılması, öğrenmeyi sağlayan ağırlık değerlerinin genetik algoritma ile belirlenmesi şeklindedir. Her bir kromozom ağın ağırlık vektörünü temsil etmektedir.

Genetik algoritması ile YSA'nın eğitilmesi ve test edilmesi işlemlerinin yer aldığı akış şeması Şekil 6.12'de verilmiştir.



Şekil 6.12. Genetik algoritması akış diyagramı

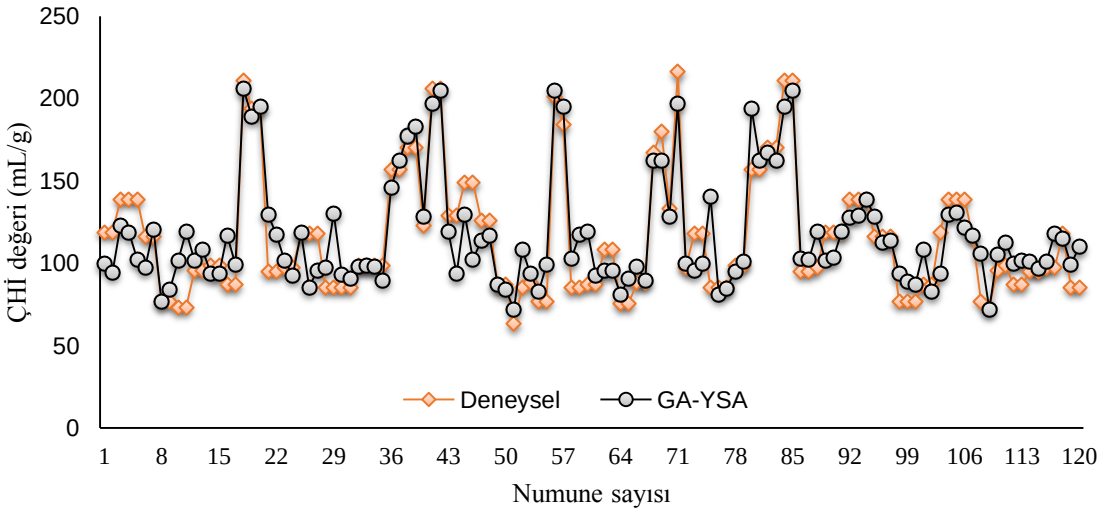
YSA'nın öğrenme işlemine, katmanlar arasındaki bağlantıların sayısal değerlerini tutan ağırlıkların rastgele oluşturulması ile başlanır. Eğitilecek toplam ağırlık sayısı 351'dir. Dolayısıyla problem için rastgele 351 kromozomlu popülasyon oluşturulur. Popülasyon büyüklüğü 20 seçilmiştir yani problem için 20 tane çözüm önerilmiştir. Oluşturulan popülasyonun temsil ettiği ağırlık değerleri mevcut yapay sinir ağı modeli üzerinde ileri doğru hesaplama ile ağ çıktıları hesaplanmaktadır. Çıktılar ile olması gereken değerler arasındaki farkı en aza indirmek temel amaç olup genetik algoritma uygunluk fonksiyonu olarak YSA çıktı hatası MSE kullanılmıştır. Popülasyondaki her bir kromozom için YSA modelinde yerine konularak MSE değeri hesaplanır.

Daha sonra seçme işlemi uygulanır. Seçim işlemi, bir sonraki kuşak için yavru üretmek amacıyla hangi ailelerin yer alması gerektiğine karar vermektedir. Bu doğal seçimdeki en uygunun yaşaması durumuna benzerdir. Rulet çemberi seçim metoduna göre her bireyin seçimle şansı, uyumluluk değeriyle orantılıdır. Uyumluluk değeri yüksek olan bireyin seçilerek yeni popülasyona eklenme olasılığı yüksektir. Ancak uyumluluk değeri düşük olanlarında seçilme olasılığı vardır.

Seçilmiş olan ebeveyn kromozomlar, 0.8 seçilen çaprazlama oranına göre yeni yavrular oluşturmak üzere çaprazlanırlar. Eğer çaprazlama uygulanmazsa bireyler atalarının tamamen kopyası olacaklardır. Çaprazlama genellikle, verilen bir çaprazlama oranına eşit bir olasılıkla seçilen aile çeşitlerine uygulanmaktadır.

Kromozom üzerindeki bazı stringlerin yerleri ile oynanarak belirli mutasyon oranına göre değişiklikler yapılır. Mutasyon oranı 0.02 olarak seçilmiştir. Oluşturulan yeni popülasyon eskileriyle yer değiştirilir. Programı bitirme şartı gerçekleşiyorsa program durdurulur ve popülasyondaki en iyi çözüm olarak alınır. Uygunluk değeri en yüksek arının temsil ettiği ağırlık değerleri YSA modelinde yerine konularak test sonucu kaydedilir.

Tüm bu işlemler 5 kere tekrarlanarak her çalıştırmada alınan sınıflama doğruluk sonuçlarının ortalaması alınmış ve böylece ortalama bir sınıflama doğruluğu elde edilmiştir. GA-YSA ile bulunan çamur hacim indeksinin ortalama değerleri ile tesiste deneysel yöntemlerle ölçülen değerlerin karşılaştırılması Şekil 6.13'deki görülmektedir.



Şekil 6.13. Eğitim ve test veriler için ölçülen ve tahmin edilen ÇHİ değerlerin karşılaştırılması

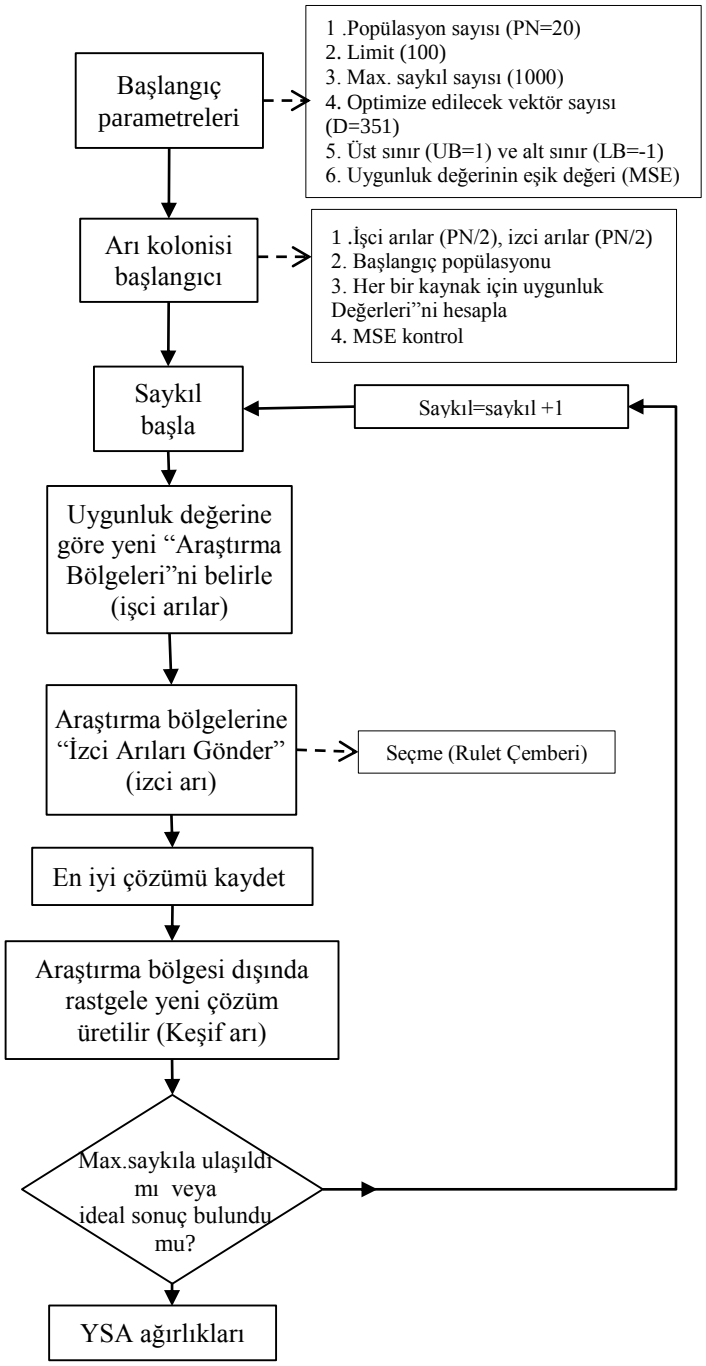
6.8.3. Çamur hacim indeksinin ARI-YSA ile tahmini

YSA' da öğrenme, katmanlar arası ağırlıkların en uygun duruma getirilmesi sürecidir ve bu bir optimizasyon işlemidir. Bu yüzden günümüzde kullanımı yaygınlaşmakta olan arı algoritması, YSA'nın eğitimi için tercih edilmiştir. Arı algoritması kullanarak YSA eğitimindeki amaç ağırlıkların en uygun şekilde hesaplanması, eğitim ve test aşamasında minimum hata ile çözüm elde edilmesidir. Arama uzayını yiyecek kaynakları olarak düşündüğümüzde bu modelde YSA'nın ağırlıkları arı algoritması için yiyecek kaynağı anlamına gelmektedir. Oluşturulacak YSA yapısında 33 adet giriş, 10 adet gizli katmanda, 1 adet çıkış katmanında olmak üzere optimize edilecek toplam (34x10+11) 351 adet ağırlık demektir. YSA eğitimini arı algoritması için hedef fonksiyon olarak düşünürsek 351 parametreli bir vektör ortaya çıkar.

Arı algoritması en iyi ağırlıkları bulmak için her bir çevrimde yiyecek kaynağının 2 katı kadar YSA ağını eldeki ağırlıklarla deneyecektir. Arı algoritmasında, limit değeri 100, kaynak sayısı 10; problemin boyutu 351 olarak belirlenmiştir. Koloni boyutu tüm problemler için 20 alınmıştır.

Arı algoritması ile YSA'nın eğitilmesi işlemlerinin yer aldığı akış şeması Şekil 6.14'de verilmiştir.

Başlangıç kolonisinin oluşturulması; her biri YSA modelindeki ağırlık sayısınca (351) değeri temsil eden arı ile koloni oluşturulmuştur. Arıların temsil ettiği başlangıç ağırlıkları rassal olarak -1 ile +1 arasında belirlenmiştir.



Şekil 6.14. Arı algoritması akış diyagramı

Uygunluk değerlerinin hesaplanması; bu aşamada arıların temsil ettiği ağırlık kombinasyonu ile YSA yöntemi ile ağ çıktıları ve oluşan hata hesaplanmaktadır. Arı uygunluk değeri YSA'nın çıktı hatası ile ölçülmüştür. Başlangıçta oluşturulan koloniler, YSA modelinde yerine konularak MSE değeri hesaplanmıştır.

Durdurma kriterinin kontrol edilmesi; belirlenen iterasyona ya da uygunluk değeri hesaplanmasından sonra istenilen hata performansına ulaşılmış ise algoritma durdurulur.

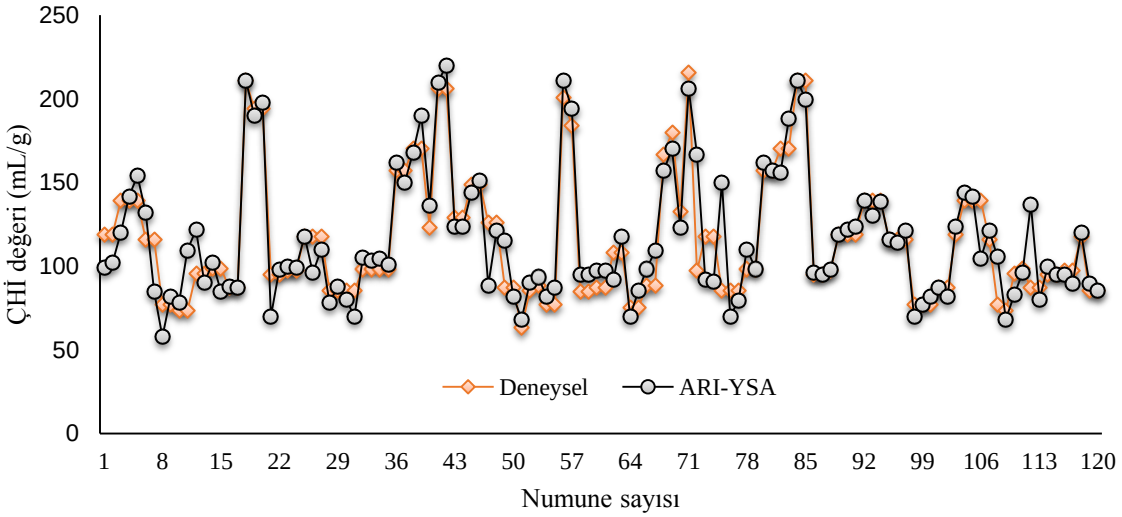
Araştırma bölgelerinin belirlenmesi; ölçülen uygunluk değerleri esas alınarak arılar uygunluk değerlerine göre en iyiden en kötüye doğru sıralanır ve önceden belirlenen araştırma bölgesi arıları ve onların içerisinden de en iyi arılar elit arı olarak belirlenir

İzci arıların araştırma bölgelerine gitmesi; bu aşamada seçilen araştırma gölgesine elit arıların etrafına daha çok olmak üzere arılar araştırmaya gönderilir. Her bir arı ağırlık sayısı kadar değeri temsil ettiğine göre her bir değerin +/- çevre kadar rasgele bir değer ilavesi ile ilgili ağırlığın yeni değeri bulunur. 351 ağırlıklı bir YSA modelinde çevre değeri de 0,1 olarak tanımlanmıştır. 351 farklı ağırlığın +/- 0.1 aralığında rassal bir değer ilavesi ile yeni 351 değer ve sonuç olarak da yeni bir arı elde edilir.

Rassal araştırmaya gönderilmesi; seçilen araştırma bölgesi dışında da araştırmalara devam etmek için bir kısım arıda rassal olarak yeni bölgelere gönderilmektedir. Bu adımda da başlangıç kolonisinde olduğu gibi YSA ağırlıkları rassal olarak belirlenmektedir. Bu adım ile yeni bir koloni oluşmuş olmaktadır. Daha sonra oluşan yeni kolonin uygunluk değerlerinin ölçülmesi aşamasına dönülmektedir.

Durdurma kriteri sağlanmış ise koloni içerisindeki uygunluk değeri en yüksek arı problem çözümü olarak ele alınır. Böylece YSA eğitim aşamasında belirlenmeye çalışılan en uygun ağırlık değerleri arı ile bulunmuştur. Uygunluk değeri en yüksek arının temsil ettiği ağırlık değerleri YSA modelinde yerine konularak test sonucu bulunur.

Eğitim ve test verilerinin ayrılması işleminde 5-katlı çapraz doğrulama yaklaşımı kullanıldığından tüm bu işlemler 5 kere tekrarlanmıştır. ARI-YSA ile bulunan çamur hacim indeksinin ortalama değerleri ile tesiste klasik yöntemlerle ölçülen değerlerin karşılaştırılması Şekil 6.15'deki görülmektedir.



Şekil 6.15. Eğitim ve test veriler için ölçülen ve tahmin edilen ÇHİ değerlerin karşılaştırılması

6.8.4. Yapay Çamur hacim indeksinin tahmin sonuçların karşılaştırılması

GA ve ARI optimizasyon tekniklerinden olup, YSA'ların eğitilmesinde bir çok çalışmada kullanılmıştır (Yeo ve Agyel 1996, Karaboğa ve Akay, 2007). GA'ın üstünlüğü bir ağı tam olarak optimize edebilme (ağ konfigürasyonu, aktivasyon fonksiyonu, ağırlıklar gibi) kabiliyetine sahip olmalarıdır. Mümkün çözümleri daha yavaş üretmeleri ise dezavantajlarıdır. Levenberg-Marquardt temelde maksimum komşuluk fikri üzerine kurulmuş bir en küçük kareler tahmin metodudur. Bu metot, genelde yavaş yakınsama problemlerinden etkilenmez yani hızlı yakınsar (Sağıroğlu ve ark., 2003).

Yapay sinir ağının ağırlıklarının LM, GA ve ARI yöntemleri kullanılarak 5-kat çapraz doğrulama ile eğitilmiş, eğitim ve test verileri için elde edilen ortalama MSE ve r değerleri Çizelge 6.4'de gösterilmiştir. ÇHİ parametresinin değeri %90 bir yakınlıkla tahmin edilmiştir.

Çizelge 6.4. Algoritmaların karşılaştırılması

Öğrenme Algoritmaları	**Eğitim**		**Test**	
	r	**MSE**	**r**	**MSE**
LM-YSA	0.997	0.00152	0.896	0.104
GA-YSA	0.973	0.04518	0.902	0.072
ARI-YSA	0.969	0.05292	0.915	0.094

7. ATIKSULARDA PROTOZOA BELİRLENMESİ

Günümüzde aktif çamur sistemlerinde, protozoaların çıkış suyu kalitesi üzerinde hayati öneme sahip organizmalar oldukları kabul edilen bir gerçektir (Curds, 1992; Sleigh, 1989; Laybourn-Parry, 1994; Şenler ve Yıldız, 2010). Aktif çamur sistemi ile çalışan arıtma tesislerinde protozoaların rolünü belirlemek amacıyla çeşitli çalışmalar yürütülmüştür (Curds, 1992; Curds, 1973). Bu çalışmalarda laboratuvar koşullarında geliştirilen arıtma modelleri protozoalı ve protozoasız olarak çalıştırılmış, çıkış suları analiz edilmiştir. Protozoasız olarak çalışan arıtma modellerinin tamamında düşük kaliteli, protozoalı çalışanların ise daha yüksek kaliteli çıkış suları ürettikleri görülmüştür. Daha sonra protozoasız çalışan ünitelere aktif çamur protozoaları aşılandığında çıkış suyu kalitesinde önemli iyileşmelerin olduğu gösterilmiştir (Şenler ve Yıldız, 2010).

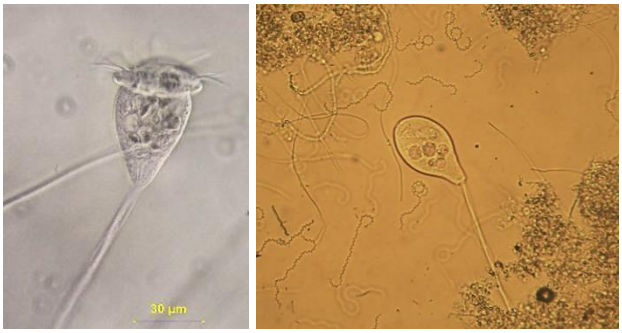
Aktif çamur sistemlerinin mikrobiyolojik açıdan değerlendirilmesi, her haliyle sistemin işletilmesi ve istenen verim parametrelerinin sağlanması ile doğrudan bağlantılıdır. Arıtma verimi açısından, sistemde bulunmaları ise arıtma teknolojisi açısından çok önemlidir. Aynı zamanda protozoaların bulunduğu floklar daha iyi çökelme özelliği gösterirler. Çökelmenin hızlı ve iyi olması arıtma veriminin de iyi olması demektir. Aktif çamur sürecinde belirli sayıda protozoanın bulunması, sürecin iyi çalıştığının ve kararlı durumda olduğunun bir göstergesidir (Şakar, 2009).

Protozoaların floklarla çok benzer yapı göstermesi ve iç içe yer aldıklarından dolayı ayırt edilmeleri oldukça zordur. Ginoris ve ark. (2007), Amaral ve ark. (2008) çalışmalarında görüntüde protozoayı içeren bölgenin seçilmesi suretiyle, protozoaları belirlemişlerdir.

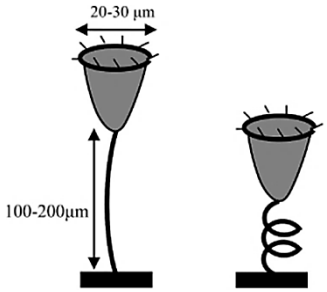
Bu çalışmada, protozoaların yerlerinin hiçbir kullanıcı girişi olmadan otomatik olarak bulunması amaçlanmıştır. Öncelikle protozoa içeren görüntüler ön işleme aşamasından geçirilmiştir. Kenar bulma algoritması kullanılarak kenar bölgeler belirlenmiştir. Elde edilen bu bölgelerin özellikleri belirlenmiş ve bu belirlenen özelliklere göre YSA protozoa olabilecek bölgeler için eğitilmiştir. Tüm kenarları tespit edilemeyen protozoalar için morfolojik işlemler uygulanmıştır. Sonrasında aktif kontur yardımıyla protozoanın sınırları belirlenmiştir.

7.1. Protozoaların Belirlenmesi

Atıksu arıtma tesisleri çeşitli protozoa gruplarını barındırırlar. Konya Kentsel Atıksu arıtma tesislerinde çoğunlukla rastladığımız protozoa türü Şekil 7.1'de gösterilen vorticella türü olmuştur. Bu protozoaların filamentli yapıya sahiptirler. Protozoalar hareket halinde olduklarından filament yapıları Şekil 7.2'de gösterildiği gibi kısalıp uzamaktadır.

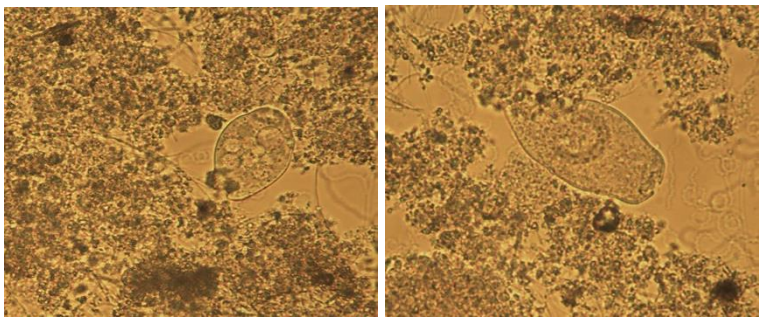


Şekil 7.1. Filamentli protozoalara örnek (vorticella)



Şekil 7.2. Vorticella

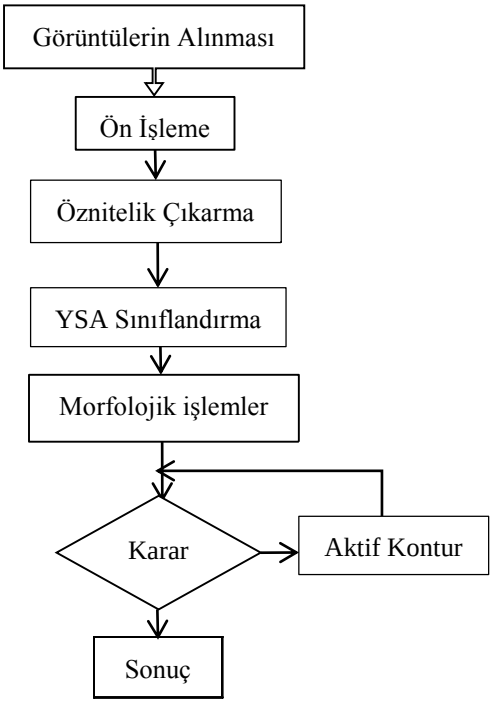
Atıksudan aldığımız Şekil 7.3'de görüldüğü gibi bazı görüntülerde filamentli yapısının fazla belli olmadığı veya flok yapının içinde kaybolduğu gözlenmiştir. Dolayısıyla ayrıştırmalarda filamentli yapı dikkate alınmamıştır.



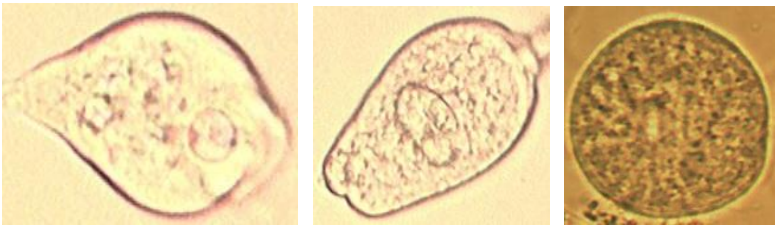
Şekil 7.3. Filamentli yapısının fazla belli olmadığı veya flok yapının içinde kaybolduğu görüntüler

Protozoalar (özellikle vorticella) incelendiğinde, genel olarak atıksudaki görüntülerinde tüm kenarları belirgin değildir. Paralele yakın iki kenarı genellikle çok belirginken orta ve kısa kenarları belirsizdir. Bu yüzden sadece kenar bilgisi kullanılarak bütün olarak protozoalar otomatik olarak elde edilememektedir. Genelde ufak noktalar ve boşluklardan oluşan bu bölgelerin birleştirilerek bir bütün halinde elde edilmesi için kapama işlemi uygulanabilir. Bu seferde protozoaların floklarla birleşmesine neden olmaktadır. Zaten bazı görüntülerde protozoaların floklarla iç içe yer alması söz konusudur. Dolayısıyla protozoaları morfolojik işlemle direk ayrıştırma pek mümkün olamamaktadır. Bu yüzden elde edilen kenarlara birleştirme işlemi uygulanmamıştır. Bu durumda da protozoaların ayrı ayrı elde edilmesi söz konusu olmaktadır. Bu sorunu çözmek için kenar bilgisinden protozoa olma özelliği içerenler YSA ile ayırt edilmiş, birleştirme işlemi bundan sonra uygulanmıştır.

Atıksu görüntülerinde protozoaların yerlerini bulmak için uygulanan işlemlerin akış şeması Şekil 7.4'de gösterilmiştir. Görüntüler, Konya Kentsel Atıksu Arıtma Tesisinin aktif çamur sisteminin havalandırma tankından, Motic AE21 Moticam, 1.3Mp dijital renkli kamera ile 1024x1280 çözünürlükte, 40x objektifte alınmıştır. Alınan görüntülerde rastlanan bazı protozoa görüntüleri Şekil 7.5'de gösterilmiştir (Boztoprak ve Özbay, 2012 ve 2013b).



Şekil 7.4. Protozoaların belirlenmesinde uygulanan adımlar

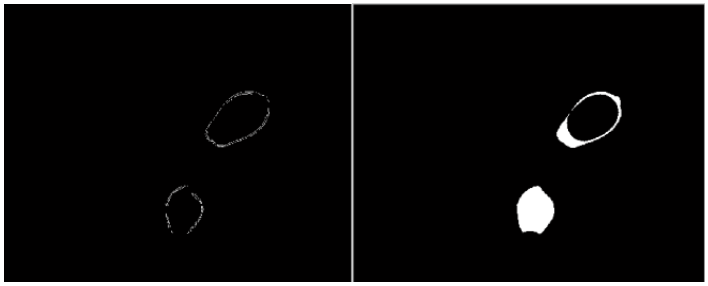


Şekil 7.5. Atıksu arıtma tesisinden rastlanan bazı protozoa görüntüleri

İlk olarak görüntüler önişleme aşamasından geçirilmiştir. Gri seviyeye dönüştürülen görüntü, histogram eşitleme ile iyileştirilmiştir. Sonra görüntüye ortalama filtresi uygulanarak bazı gürültüler elimine edilmiştir. Daha sonra elde edilen görüntüye prewitt kenar operatörü uygulanmıştır. Kenarları bulunan görüntüden çok ufak ve gürültü olabilecek küçük alanlar silinmiştir. Kalan her bölgenin ayrı ayrı özellikleri belirlenmiştir. Bu özelliklerin belirlenmesinde protozoaların genel özellikleri dikkate alınmıştır. Standart sapma, ortalama, entropi, alan, katılık (solidity), kapsam (extent), çevre/alan olmak üzere yedi görüntü parametresi belirlenmiştir. Bu özelliklerin her biri bütün bölgeler için hesaplanmıştır ve elde edilen bu bölgelerin özellikleri YSA'nın girişine uygulanmıştır (Boztoprak ve Özbay, 2012 ve 2013b).

Bu çalışmada üç katmanlı ileri beslemeli ağ mimarisi kullanılmıştır. YSA eğitimi standart eğitim algoritması olarak bilinen geriye yayılım eğitim algoritmasına göre çok hızlı sonuç veren Levenberg-Marquardt öğrenme algoritması kullanılarak yapılmıştır. Eğitilen ağ giriş katmanında 7, gizli katmanda 10 ve çıkış katmanında 1 düğüme sahiptir. Aktivasyon fonksiyonu olarak da sigmoid fonksiyonu kullanılmıştır. Öğrenme kuralı hata geri yayılımdır. Hata hesabı olarak hataların karelerinin ortalaması metodu kullanılmıştır. YSA giriş parametreleri görüntüden elde edilen; standart sapma, ortalama, entropi değeri, alan, katılık, kapsam (extent), çevre/alan verileridir. Bu veriler bir vektör halinde YSA'ya giriş olarak uygulanmıştır. Çıkış olarak aday protozoa bölgesi veya değil olarak sınıflandırılmıştır. YSA çıkışı 0 ve 1 şeklinde, 0; protozoa olamayacak bölgeyi, 1; aday protozoa bölgesini ifade etmektedir. Girdi katmanındaki veriler, YSA'ya uygulanmadan önce -1 ve 1 arasında normalize edilmiştir.

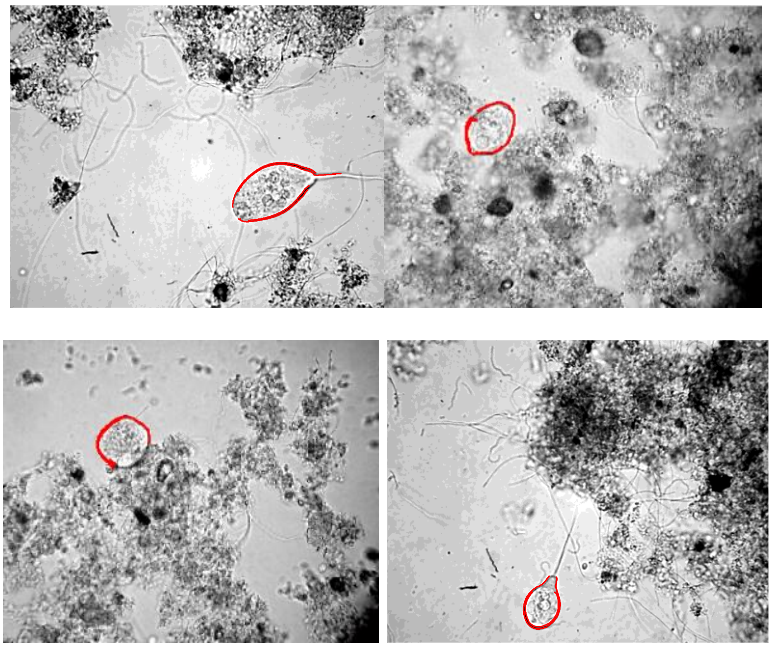
Yapay sinir ağları kullanarak elde edilen aday protozoa bölgeleri Şekil 7.6 (a)'da görüldüğü gibi tek bir görüntüde toplanmıştır. Protozoaların sayılarında otomatik olarak saptanabilmesi için bir kısmı veya parça parça elde edilen protozoaların bir bütün olarak elde edilmesi gerekmektedir. Bunun için morfolojik işlemler uygulanarak birleştirme ve doldurma işlemleri yapılmıştır (Şekil 7.6 (b)).



(a) (b)

Şekil 7.6. (a) Elde edilen aday protozoa bölgelerin tek bir görüntüde gösterilmesi, (b) birleştirme işleminin uygulanmasıyla elde edilen görüntü

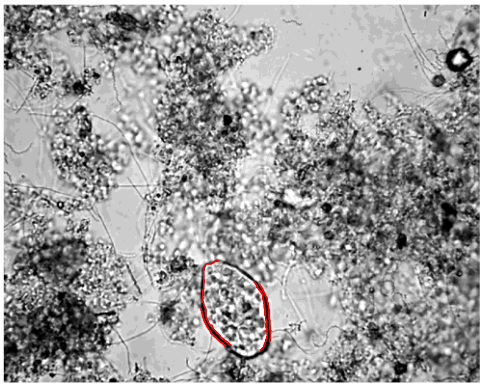
YSA ile elde edilen bölgelere doldurma ve birleştirme işleminden sonra protozoa olup olmadıklarına karar veren bir karar aşaması geliştirilmiştir. Bu karar aşamasında elde edilen bölgelerin elips, dairesel ve konveks alanları dikkate alınarak oluşturulmuştur. Protozoa olduğu belirlenen bölgelere örnek görüntüler Şekil 7.7'de gösterilmiştir.



Şekil 7.7. Belirlenen protozoa bölgeleri

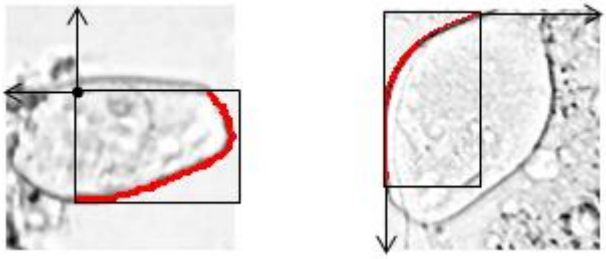
7.2. Bölgelerin Genişletilmesi ve Aktif Kontur Metodunun Uygulanması

Bazı durumlarda, Şekil 7.8'de gösterildiği gibi protozoaların sadece bir veya iki kenarı elde edilebilmektedir. Böyle elde edilen görüntülere, yani karar aşamasında protozoa olmadığına karar verilen bölgelere tekrar bir dizi işlem uygulanmıştır.



Şekil 7.8. Kenarları eksik belirlenen protozoanın gösterilmesi (Boztoprak ve Özbay, 2012 ve 2013b).

Dolayısıyla, elips veya dairesel olarak belirlenemeyen bölgeler, bölgelerin özelliklerine göre genişletilmiştir. Bu özellikler; bölgenin boyu, eni, maksimum eksen uzunluğu ve minimum eksen uzunluklarıdır. Bu bilgiler kullanılarak bölgeler Şekil 7.9'da gösterildiği gibi genişletilmiştir. Başlangıç noktasının değiştirilip değiştirilmeyeceği bölgenin yönelimine göre belirlenmiştir. Şekil 7.9 (a)'da başlangıç noktasının değiştirildiği görüntü, (b)'de başlangıç noktasının değiştirilmediği görüntü gösterilmiştir (Boztoprak ve Özbay, 2013b).



(a) (b)

Şekil 7.9. Orijinal görüntüden elde edilen bölgelerin genişletilmesi

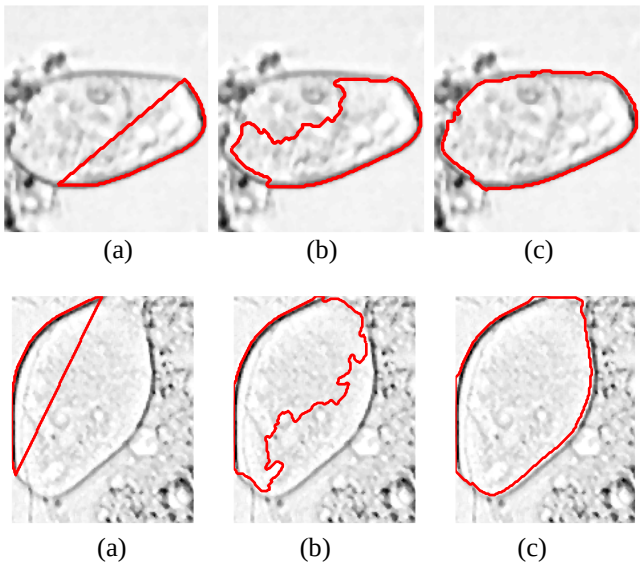
Aktif kontur yönteminin temel fikri kapalı eğrinin, yani kontörün, ilk maske (yuvarlak, kare vb. bir şekil) ile başlaması ve daha sonra görüntünün kısıtlamalarına göre genişleme ya da küçülme yaparak sonuca ulaşmasıdır. Bu model yöntemlerinin uygulanmasındaki ana tanımlamalar, çizginin başlangıcı ve bundan sonraki çözümün doğru yakınsanmasına bağlıdır. Doğru nesnenin sınırlarını belirtmek için ilk başta doğru nokta veya maske seçmek gerekmektedir. Genellikle bu noktalar el ile belirlenir daha sonra algoritma bu noktaları referans alarak çalışır ve gerekli bölütlemeyi otomatik olarak yapar. Bu modelin doğru çalışabilmesi için referans noktaları önemlidir.

Bu çalışmada, görüntünün konveks alanı kullanılarak (Şekil 7.10) başlangıç maskesinin yeri otomatik olarak belirlenmiştir (Boztoprak ve Özbay, 2012 ve 2013b). Aktif kontur yöntemi uygulanmadan önce görüntünün yumuşatılmasında ve önemsiz detayların kaldırılmasında gauss çekirdek filtresi kullanılmıştır. Bu da aktif kontur model algoritmasının daha düşük görüntü enerjili konumlara hareketini önlemekte ve daha belirgin detaylara yönelmesini sağlamaktadır. Şekil 7.11'deki konveks alanlar kullanarak Şekil 7.9'daki görüntülere Aktif kontur yöntemi uygulanmıştır (Bernard, 2012).



Şekil 7.10. Elde edilen bölgelerin konveks alanları

Şekil 7.11 (a)'da protozoa görüntüsüne uygulanan aktif konturun başlangıç durumu yani görüntünün konveks alanı, (b)'de 300 ve (c)'de 600 iterasyon ile elde edilen görüntüler gösterilmiştir (Boztoprak ve Özbay, 2012 ve 2013b).



Şekil 7.11. (a) Başlangıç durumu, (b) 300 ve (c) 600 iterasyon ile elde edilen görüntüler

Şekil 7.12'de 600 iterasyon ile elde edilen bölütlenmiş görüntüler gösterilmiştir. Böylelikle bir kısmı veya parça parça elde edilen protozoalar bir bütün olarak elde edilmiştir (Boztoprak ve Özbay, 2012 ve 2013b).



Şekil 7.12. Bölütlenmiş görüntüler

Çizelge 7.1'de 30 görüntü ele alınmış ve bu görüntülerden uygulanan yöntemle yaklaşık 200 bölge elde edilmiştir. YSA bunların 148 adetini protozoa olamayacağından elemiştir. Kalan 52 bölge karar aşamasında, konveks alanları elips veya dairesel olmayan 11 bölge protozoa olamayacağından elenmiş, doldurulmuş alan ve konveks alanının oranı 0.9'dan büyük olan 19 bölgenin protozoa olabileceği belirlenmiştir. Geriye kalan 12 bölge de aktif kontura gönderilmiştir. Aktif konturda iterasyon sayısının o bölge için fazla veya az gelmesinden dolayı 2 bölgenin ayrıştırılmasında başarısız olmuştur. Diğer 10 bölgelerin sınırları başarıyla belirlenmiştir. Aktif kontur işlemi sonrasında karar aşamasında elde edilen görüntü tekrar değerlendirilmiştir. Toplam protozoa sayısı 29 bulunmuştur. Görüntülerde gerçekte 27 adet protozoa olmasına rağmen, bu yöntemle 2 adet bölge hatalı olmak üzere 29 adet protozoa bölgesi saptanmıştır. Görüntüdeki protozoalar belirlenmiş ama iki adet protozoa olmayan bölge protozoa olarak bulunmuş ve sonuç olarak %93'lük bir başarı elde edilmiştir.

Çizelge 7.1. 30 görüntü için protozoa sayısının bulunması

Aşamalar	**Miktar**
Toplam görüntü sayısı	30
Bulunan bölge sayısı	200
YSA	
YSA da elenen kenar sayısı	148
Kalan kenar sayısı	52
Karar Aşaması	
Protozoa olan bölge sayısı	**19**
Protozoa olmayan bölge sayısı	11
Protozoa olabilir ama aktif konturla belirlenmesi gereken bölge sayısı	12
Aktif Kontur	
Sınırları belirlenen protozoalar	**10**
Sınırları belirlenemeyen	2
Toplam bulunan protozoa sayısı	**29**

Bu çalışmada, protozoaların otomatik olarak saptanması için bir görüntü işleme uygulaması geliştirilmiştir. Aktif konturda doğru nesnenin sınırlarını belirleyebilmek için ilk başta doğru maske seçmek önemlidir ve genellikle kullanıcıdan girilmesi istenir. Bu çalışmada görüntünün konveks alanı kullanılarak, başlangıç maskesinin ilk yeri otomatik olarak belirlenmiştir. Önerilen yöntemde, hiçbir ilgili bölge seçimi yapılmadan görüntü üzerinde işlemler otomatik olarak gerçekleştirilmiştir (Boztoprak ve Özbay, 2012 ve 2013b).

8. SONUÇLAR VE ÖNERİLER

8.1. Sonuçlar

Büyük maliyetlerle kurulan atıksu arıtma tesisleri için önemli bir parametre olan ÇHİ değerinin görüntü işleme ve yapay zekâ teknikleri kullanılarak tahmin edilmesi, çamurdaki filamentlilerin fazla çoğalmasını ve katı maddelerin fiziksel çökelme (çökelmeme) problemlerinin takibini sağlayacaktır. Eğer ÇHİ değeri >150 mL/g ise çamur kabarması ve dolayısıyla çamur çökelme problemi gözlenir. ÇHİ değerinin 50-100 mL/g arasında olması istenir. Sadece ÇHİ değeriyle çökelmeme probleminin neden kaynaklandığı bilinememektedir. Mikroskop altında aktif çamur görüntülerinin içinde mevcut olan filament ve flok yapısının incelenmesi gerekmektedir. Bu tezdeki önerilen metotla ÇHİ değerinin hesaplanmasıyla flok ve filamentlerin şekilsel, dokusal ve istatiksel bilgilerin de olması ÇHİ değerinin daha iyi anlaşılması sağlanacaktır. Çalışanların işini daha da kolaylaştırarak tesislerdeki olumsuz etki ve kayıplardan etkin bir şekilde bilgi sağlayacaktır. Deneysel çalışma gereksinimi minimuma indirgeneceğinden tesis işletme maliyetlerini büyük ölçüde azaltacaktır. Önerilen sistemin önemli bir özelliği de kullanıcı girişi gerektirmeden arıtma tesisin günlük işleyişinde, uzun süren çeşitli işlemleri otomatik hale getirerek çalışanların yaptığı işi hafifletmesidir. Bir deneyin hatalı olduğu düşünüldüğünde deneyin tekrarlanması gerektiğinden klasik yöntemlerle bu oldukça zaman alıcı ve maliyetli olacaktır.

Aktif çamur havalandırma tankından alınan numunelerden aktif çamur görüntülerini otomatik almak için motorlu XY platform ve mikroskop kameralı bir sistem kurulmuştur. Bu sistem için geliştirilen yazılım vasıtasıyla hem eşzamanlı çalışmaları hem de tarama için gerekli parametrelerin kontrolü sağlanmıştır. Her numuneden belli bir alan sıralı olarak taranarak 49 görüntü alınmıştır. Eylül 2011-Agustos 2012 tarihleri arasında tesis bir yıl boyunca takip edilmiş ve toplam 120 numune incelenmiştir. Görüntüleri alınma tarihi ile oluşturulan klasöre sırayla kaydedilmekte ve tüm görüntüler sırasıyla işlenmektedir. 49x120=5880 ve her bir görüntü için 33 parametre çıkarıldığı da düşünülürse 194040 veri söz konusudur. Elde edilen tüm veriler bir Excel dosyasına kaydedilmektedir. Otomatik görüntü yakalama ve sistematik bir şekilde numunenin taranması, kaydedilmesi önemli bir süreçtir ve sonraki aşamaların sonuçlarını etkileyecektir.

Alınan görüntülerin flok ve filament yapıları incelenmiş ve bu yapıların bölütlenmesinde yeni bir bölütleme yöntemi sunulmuştur. Bölütlemede HSA yapısı kullanılmış ve HSA'nın iterasyon değerinin önemi vurgulanmış ve sonuca etkisi gösterilerek yeni bir bakış acısı getirilmiştir. Önerilen yöntemde her bir görüntünün özelliğine göre HSA'nın iterasyon sayısı belirlenmiştir. İterasyon değerini belirlemek için dalgacık dönüşümü sonucu elde edilen LL_2, HH_2 alt-bant görüntülerinin SF değeri hesaplanmış ve bunların birbirine oranının görüntü üzerindeki etkisi araştırılmıştır. İçeriğinden bağımsız olarak, görüntünün netliği hakkında bilgi veren özellik bulunmuştur. Farklı özelliklere sahip atıksu görüntülerinin bölütlenmesi sağlanmıştır. Bulunan ayıt edici özellik aktif çamur görüntüleri dışında bilinen görüntülerde hesaplanarak görüntünün netliğini ölçen ve en çok kullanılan pik sinyal gürültü oranı (PSNR) değeriyle karşılaştırılmıştır. Bilinen test görüntüleri üzerinde yapılan deneysel çalışmalar neticesinde; önerilen yöntem ile görüntünün kalitesi hakkında yorum yapılabileceği görülmüştür.

Daha sonra flok ve filamentleri doğru şekilde ve ayrı ayrı tespitini sağlamak için bir dizi morfolojik işlemler uygulanmıştır. Flok ve filamentlere ait özellikler belirlenmiştir. Aktif çamur görüntülerinde genellikle morfolojik (şekilsel) ve istatiksel özellikler incelenmiştir. Bu tez çalışmasında görüntülerin dokusal özellikleri de kullanılmıştır. Her numuneye (güne) ait önce 20 özellik çıkarılmış ve bu özelliklerden 33 parametre hesaplanarak veri seti oluşturmuştur. Bu 33 parametre normalize edilerek YSA girişine uygulanmıştır. YSA ağırlıklarının eğitilmesinde birçok alanda kullanılan arı ve genetik algoritmaları, atıksu arıtma tesislerinden alınan görüntülere uygulanmıştır. 33:10:1 mimarisiyle yapay sinir ağının ağırlıkları Levenberg-Marquardt, genetik ve arı algoritmaları ile eğitilmiştir.

Bu tez çalışmasında, performans sonuçlarının geçerliliğini arttırmak için 5-kat çapraz onaylama metodu kullanılmıştır. Model tahmin sonuçları ile deneysel elde edilen ÇHİ parametresi arasında en iyi 0.915 korelasyon değeri elde edilmiştir. Literatürde görüntü işleme teknikleri kullanılarak tam ölçekli bir tesis için çamur hacim indeksinin tahmin edilmesi son zamanlarda artmaktadır. Amaral ve ark., (2013) laboratuvar ortamında aktif çamur filament, nokta floklar (pinpoint flocs), viscous kabarma, normal koşullar olmak üzere dört veri grubunda sınıflandırılarak ÇHİ değerini tahmin etmişlerdir. Sınıflandırılmamış verilere göre sınıflandırılan bu verilerin daha iyi tahmin yeteneğine sahip olduğunu belirtmişlerdir. Tahmin edilen ile ölçülen değerler arasında

0.98 korelasyon elde etmişlerdir. Amaral ve Ferreira (2005) tam ölçekli bir tesiste ÇHİ'nin tahmin edilen ve ölçülen değerler arasındaki korelasyon katsayısını 0.861 bulmuşlardır. Laboratuvar ölçekli deneylerde elde edilen sonuçlar, tam ölçekli bir tesis için aynı sonucu vermeyecektir. Han ve Qiao (2013) çalışmalarında, görüntü işleme teknikleri kullanmadan hiyerarşik yapay sinir ağları ile çözünmüş oksijen konsantrasyonu, asitlik-bazlık, kimyasal oksijen ihtiyacı ve biyokimyasal oksijen ihtiyacı verileri kullanılarak ÇHİ değerini %98 oranında tahmin etmişlerdir.

Atıksu arıtma tesisleri çeşitli protozoa gruplarını barındırırlar. Konya Kentsel Atıksu Arıtma Tesisinde çoğunlukla rastladığımız protozoa türü vorticella olmuştur. Protozoalar genellikle filamentli yapıya sahiptirler. Görüntülerde filamentli yapısının fazla belli olmadığı veya flok yapının içinde kaybolduğu gözlenmiştir. Dolayısıyla ayrıştırmalarda filamentli yapı dikkate alınmamıştır. Protozoaların floklarla çok benzer yapı göstermesi ve iç içe yer aldıklarından dolayı ayırt edilmeleri oldukça zordur. Literatürde görüntüdeki protozoayı içeren bölgenin seçilmesi suretiyle veya sadece ilgili bölge dikkate alınarak protozoalar belirlenmiştir. Bir kısmı veya parça parça elde edilen protozoaların bir bütün olarak elde edilmesi için morfolojik işlemlerle birlikte aktif kontur metodu kullanılmıştır. Görüntünün konveks alanı kullanılarak, aktif konturun başlangıç maskesinin ilk yeri otomatik olarak belirlenmiştir. Aktif kontur yardımıyla protozoanın sınırları belirlenmiştir. Önerilen yöntemde, hiçbir ilgili bölge seçimi yapılmadan görüntü üzerinde işlemler otomatik olarak gerçekleştirilmiştir.

Çevre mühendisliğinde arıtma proseslerinin görüntü işleme yöntemleri ile değerlendirilmesi ve modellenmesinin proses izleme ve kontrol yaklaşımlarında yeni açılımlar getireceği öngörülmektedir. Bu çalışma ile tam ölçekli bir tesis için aktif çamur sistemlerini izlemek, proses sorunların erken tanımlanması ve önlenmesi için otomatik görüntü analiz yöntemi uygulanabilirliği gösterilmiştir. Bu tez kapsamında oluşturulan modeller, bu alandaki eksikliklerin tamamlanmasına katkı sağlayabilecek ve pratik uygulama çalışmalarına yol gösterebilecektir.

8.2. Öneriler

Motorlu platformlar son derece zaman alıcı işleri platform sürüklenme olasılığını ortadan kaldırarak sıralı görüntü toplamaya imkân vermektedir. Yüksek doğruluk ve tekrarlanabilirlik gerekli olduğu uygulamalar için farklı konfigürasyonları mevcuttur. Bu

çalışmada kullanılan motorlu XY tarama platformunun tarama aralığı 102 x 102 mm (4")'dir. Tez çalışmasında kullanılan XY platformunda Z ekseni olmadığından, odak noktası otomatik olarak ayarlanamamıştır. Sonraki çalışmalarda XYZ veya XYZ/r kullanarak her yerde net bir görüntü elde edilebilir. Bunun yanında daha gelişmiş özelliklere sahip bir mikroskop kullanılarak aktif çamur görüntülerinde bulunan tür çeşitliliği bulunabilir ve baskın mikroorganizma türleri tespit edilebilir. Bakteri, protozoa ve metazoa türlerin tanımlamaları görüntü işlemeyle yapılabilir. Bir aktif çamur sistemi çok değişkenlidir ve içinde birçok mikroorganizma barındırmaktadır. Atıksu özelliklerine, çevresel koşullara, süreç tasarımına ve sürecin işletilme biçimine bağlı olarak baskın mikroorganizma türü değişecektir. Baskın mikroorganizma türleri belirlenerek arıtma tesisi işleyişi hakkında bilgi elde edilebilir. Her atıksuyun baskın türlerin farklı olabileceği bu farklılıkların atıksu arıtma tesisin performansına etkisi de araştırılabilir.

ÇHİ tahminde, referans değeri olarak klasik metotlarla ölçülen ÇHİ değeri alınmıştır. Bu değer ölçülürken hata yapılması olasıdır. Bu insan kaynaklı olabildiği gibi ölçüm cihaz hatalarından da kaynaklanabilir. Bu belirsizliği ortadan kaldırmak için aynı numuneden iki ayrı ÇHİ ölçümü yapılabilir. Böylelikle referans değeri daha doğru olacaktır. Sonraki aşamalarda gerçek zamanlı veya online sistemler için önemlidir.

Tesisten sabah saatlerinde numune alınmaktadır. Bunun yanında sabah, akşam ve gece saatlerinde numune alınarak sonuçlardaki değişim izlenebilir.

Bu çalışmada Konya Kentsel Atıksu Arıtma Tesisi yaklaşık bir yıl buyunca izlenmiştir. Tesis daha uzun süre (2-5 yıl) izlenerek mevsimlere göre arıtmanın performans değişimleri takip edilebilir. Aynı zamanda ÇHİ değeri yanında başka parametrelerin tahmini yapılabilirliği araştırılabilir. Başka atıksu arıtma tesislerinde de önerilen yöntemlerin uygulanabilirliği araştırılabilir. Her atıksu arıtma tesisindeki farklılıklar araştırılabilir.

Daha sonraki çalışmalarda görüntüler yerine video çekilebilir ve bu çekim esnasında görüntü üzerinde mikroorganizmaların, hareketli olan protozoaların anlık takibi yapılabilir. Çevre mühendisliğinde arıtma proseslerinin görüntü işleme yöntemleri ile değerlendirilmesi ve modellenmesinin proses izleme ve kontrol yaklaşımlarında yeni açılımlar getireceği öngörülmektedir. Böyle bir çalışma sonucunda elde edilecek yapılanma, atıksu arıtma tesislerinin işletiminde hem işletme kolaylığı hem de ekonomik açıdan uygun çözümler üretmekte faydalı olacaktır.

KAYNAKLAR

Acharya, T., Ray, A.K., 2005, *Image Processing: Principles and Applications*, John Wiley & Sons, Inc., New Jersey.

Açıkalın S., İleri R., Keleş R., 2005, Adapazarı kentsel atıksu arıtma tesisi çıkış suyu parametreleri ve verim değerlerinin yapay sinir ağları ile tahmin edilmesi, *Sakarya Universitesi, Muh. Fak.,* Sakarya.

Akar E.O., 2006, Tarihi görüntülerin kalitesinin görüntü işleme teknikleri kullanılarak artırılması, Yüksek Lisans, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü,* Konya.

Akdemir B., 2009, Tahmin uygulamalarında performans geliştirmek için kullanılan normalizasyon metotlarına yeni bir yaklaşım, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü,* Konya.

Altun, H., Eminoğlu U. ve Tezekici B. S., 2002, MLP Yapay sinir ağlarında öğrenme sürecinin aktivasyon fonksiyonu ve istatiksel değişim gösteren giriş verilerine bağımlılığı, *Elektrik, Elektronik ve Bilgisayar Mühendisliği Sempozyumu Eleco'2002,* Bursa.

Amaral A. L., Ferreira E. C., 2005, Activated sludge monitoring of a wastewater treatment plant using image analysis and partial least squares regression, *Analytica Chimica Acta*, 544 (2005) 246–253.

Amaral A. L., Ginoris Y. P., Nicolau A., Coelho M. A. Z., Ferreira E. C., 2008, Stalked protozoa identification by image analysis and multivariable statistical techniques, *Anal Bioanal Chem,* 391:1321–1325.

Amaral A. L., Mesquita D. P., Ferreira E. C., 2013, Automatic identification of activated sludge disturbances and assessment of operational parameters, *Chemosphere 91 (2013),* 705–710.

Angeline P. J., Saunders G. M., Pollack J. B., 1994, An evolutionary algorithm that constructs recurrent neural networks, *IEEE Transactions on Neural Networks,* 5(1), 54–65.

Arifovica J., Gencay R., 2001, Using genetic algorithms to select architecture of a feedforward artificial neural network, *Physica A,* 289(3-4), 574-594.

Arslan E., 2011, Hücresel sinir ağı sistemleri kullanarak hareketli nesnelerin görüntü işleme uygulamaları, Doktora tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü,* İstanbul.

Aslantas V., Pham D. T., 2007, Depth from automatic defocusing, *Optics Express* 15.3, 1011-1023.

Banadda E. N., Smets I. Y., Jenne R., Van Impe J. F., 2005, Predicting the anset of filamentous bulking in biological wastewaster treatment systems by exploiting image analysis information, *Bioprocess and Biosystems Engineering, 27*:339-348.

Bankman I. N., 2000, *Handbook of medical imaging, processing and analysis,* Academic Press.

Baş N., 2006, Yapay sinir ağları yaklaşımı ve bir uygulama, Yüksek Lisans Tezi, *Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü,* İstanbul.

Batar H., 2005, EEG işaretlerinin dalgacık analiz yöntemleri kullanılarak yapay sinir ağları ile sınıflandırılması, *Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü,* Kahramanmaraş.

Baykasoglu A., Özbakır L., Tapkan P., 2007, Artificial bee colony algorithm and ıts application to generalized assignment problem. *Swarm Intelligence: Focus on Ant and particle swarm optimization*, 113-144, Vienna-Austria.

Bernard O., 2012, *Creaseg software*, http://www.creatis.insalyon.fr/~bernard/creaseg, [Ziyaret Tarihi: Haziran 2012].

Bezdek J. C., Hall L. O., Clarke L. P., 1993, Review of MR image segmentation techniques using pattern recognition, Medical Physics, 20(4), 1033-1048.

Bezdek J. C., Keller J., Krisnapuram R., Pal, N. R., 2005, *Fuzzy models and algorithms for pattern recognition and image processing*, Springer.

Bindu C. H, Prasad K. S., 2012, Automatic scheme for fused medical image segmentation with nonsubsampled contourlet transform, *International Journal*, 3, 50-53.

Bitton G., 1994, *Wastewater Microbiology,* A John Wiley and Sons, Inc., Publication, Newyork.

Blanco A., Delgado M., Pegalajar M. C., 2001, A real-coded genetic algorithm for training recurrent neural Networks, Neural Networks, 14(1), 93-105.

Boztoprak H., Özbay Y., 2012, Görüntü işlemede aktif kontur ve YSA kullanarak atık sularda protozoa belirlenmesi, *Eleco'2012 Elektrik - Elektronik Ve Bilgisayar Mühendisliği Sempozyumu*, 29 Kasım - 01 Aralık 2012, Bursa.

Boztoprak H., Özbay Y., 2013a, A new method for segmentation of microscopic images on activated sludge, *Journal of Electrical Engineering & Computer Sciences*, DOI: 10.3906/elk-1307-9, (Accepted).

Boztoprak H., Özbay Y., 2013b, Detection of protozoa in wastewater using ANN and active contour in image processing, *Istanbul University - Journal of Electrical & Electronics Engineering IU-JEEE,* Cilt 13, Sayı 2.

Boztoprak H., Özbay Y., Güçlü D., Küçükhemek M., 2010, Determination of activated sludge floc characteristics using image processing, *International Sustainable Water and Wastewater Management Symposium, 26-28 October 2010, Konya*

Braysy O., 2001, Local search and variable neighborhood search algorithms for the vehicle routing problem with time windows, PhD Thesis, *Institute of Mathematical, University of Vaasa,* Finland.

Bulatov A., 2006, Çok odakli görüntü füzyonu, Yüksek Lisans Tezi, *Erciyes Üniversitesi Bilgisayar Mühendisliği,* Kayseri.

Ceylan M., 2009, Bilgisayar tomografili akciğer görüntülerinin değerlendirilmesinde kompleks değerli yenibir akıllı sistem tasarımı, Doktora Tezi, *Elektrik-Elektronik Mühendisliği,* Konya.

Chan T., Vese L., 2001, Active contours without edges, *IEEE Trans. Image Processing,* 10(2):266–277.

Chua L. O., Yang L., 1988a, Cellular neural networks: Theory, *IEEE Trans. Circuits Syst.*, 35, 1257–1272.

Chua L. O., Yang, L., 1988b, Cellular neural networks: applications, *IEEE Transaction on Circuits and Systems*, 35(10), 1273-1290.

Civelekoğlu G., 2006, Arıtma proseslerinin yapay zeka ve çoklu istatistiksel yöntemler ile modellenmesi, Doktora Tezi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta.

Clarke L. P., Velthuizen R. P., Camacho M. A., Heine J. J., Vaidyanathan M., Hall L. O., Thatcher R. W., Silbiger M. L., 1995, MRI segmentation: methods and applications, *Magnetic Resonance Imaging*, 5, 345-352.

Curds C. R., 1973, The role of protozoa in the activated – sludge process, *American Zoologist*, 13(1), 161-169.

Curds C. R., 1992, *Protozoa in the Water Industry*, Cambridge University Pres, U.K.

Çınar Ö., 2005, New tool for evaluation of performance of wastewater treatment plant: Artificial neural network, *Process biochemistry*, 40(9), 2980 - 2984.

Dağ C. M., 2002, *Çevre Mühendisliği Uygulamaları,* Chamber of Environmental Engineers, 63-74, Ankara.

Dia D., Zeghid M., Saidani T., Atri M., Bouallegue B., Machhout M., Tourki R., 2009, Multi-level discrete wavelet transform architecture design, *Proceedings of the World Congress on Engineering WCE*, 1:1-3.

Doğan E., Ateş A., Yılmaz E. C., Eren B., 2008, Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet Biochemical Oxygen Demand‖, Environmental Progress, 27(4), 439-446.

Düğenci M., 2007, Arı algoritması'nın yapay sinir ağı öğrenmesi için kullanımı ve atıksu arıtma tesis kontrolü uygulaması, Doktora Tezi, *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü,* Sakarya.

Eaton, A. D., Franson, M. A. H. (Eds.), 2005, *Standard methods for the examination of water & wastewater*, American Public Health Association, Washington, DC, USA.

Eikelboom D. H., 1977, Identification of filamentous organisms in bulking activated sludge, *Prog. Water Technol.,* 8, 153.

Elmas Ç., 2007, *Yapay Zeka Uygulamaları,* Seçkin Yayıncılık, Ankara.

Ernst B., Neser S., O'Brien E., Hoeger S. J., Dietrich D. R., 2006, Determination of the filamentous cyanobacteria Planktothrix rubescens in environmental water samples using an image processing system, *Harmful Algae,* 5, 281-289.

Eskicioglu A. M., Paul S. F., 1995, Image quality measures and their performance, *IEEE Transactions on Communications*, 43, 2959-2965.

Fığlalı A., Engin O., 2002, Genetik algoritmalarla akış tipi çizelgelemede üreme yöntemi optimizasyonu, *İTÜ Dergisi*, 1-6.

Fu K. S., Mui J. K., 1981, A survey on image segmentation, *Pattern Recognition,* 13(1), 3-16.

Fukuda S., Boros T., and Roska T., 1991, A new efficient analysis of thermographic images by using cellular neural networks, *Research report of the Analogical and Neural Computing Laboratory, Computer and Automation Research Institute, Hungarian Academy of Sciences (MTA SzTAKI)*, Budapest.

Fung R.Y.K., Tang J. ve Wang D., 2001, Extension of a hybridgenetic algorithm for nonlinear programming problems with equality and ınequality constraints, *Computers & Operations Research*, 29(3), 261-274.

Ginoris Y. P., Amaral A. L., Nicolau A., Coelho M. A. Z., Ferreira E. C., 2007, Development of an image analysis procedure for identifying protozoa and metazoa typical of activated sludge system, *Water Research,* 41, 2581– 2589.

Goldberg D. E., 1989, *Genetic algorithms in search, optimization and machine learning*, Addison-Wesley, USA.

Gonzalez R. C., ve Woods R.E., 2002, *Digital Image Processing*, 2nd Edition, Prentice Hall.

Gonzalez R. C., Woods R. E., Steven L. E., 2004, *Digital İmage Processing Using Matlab*, Prentice-Hall, New Jersey, 65-107, 334-474.

Govoreanu R., 2004, Activated sludge flocculation dynamics: on-line measurement methodology and modelling, Ph.D. Thesis, *Applied Biological Sciences: Environmental Technology.*

Grijspeerdt K., Verstraete W., 1997, Image analysis to estimate the settleability and concentration of activated sludge, *Wat. Res.,* 31(5), 1126-1134.

Güçlü D., 2007, Tam ölçekli kentsel atıksu arıtma tesislerinin bilgisayar programı kullanılarak modellenmesi ve arıtma performanslarının incelenmesi, Doktora Tezi, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü,* Konya.

Haliki A., Özdemir G., Uzel A., 2004, Aktif çamur sistemlerinde sorun yaratan filamentli mikroorganizmaların izolasyonu ve kontrol stratejileri üzerinde bir araştırma, *E. Ü. Journal of Fisheries & Aquatic Sciences Issue;* (3-4),275-207.

Hamed M. M., Khalafallah, M. G., Hassanien, E. A., 2004, Prediction of wastewater treatment plant performance using artificial neural networks, *Environ. Modell.Softw.,* 19, 919–928.

Han H. G., Qiao J. F., 2012, Prediction of activated sludge bulking based on a self-organizing RBF neural Network, *Journal of Process Control 22 (2012),* 1103–1112.

Han H., and Qiao J., 2013, Hierarchical neural network modeling approach to predict sludge volume, index of wastewater treatment process, *IEEE Transactıons On Control Systems Technology,* 21(6), 2423-2431.

Haralick R. M., Shanmugam K., Dinstein I. H., 1973, Textural features for image classification, *IEEE Trans. Sys. Man. Cyb.,* 3, 610–621.

Haralick R., M., Shapiro L. G., 1985, Survey: image segmentation techniques, *Comp. Vision Graph Image Proc*., 29, 100-132.

Haykın S., 1999, *Neural Networks: A Comprehensive Foundation*, 2. Ed. New Jersey: Prentice Hall.

Heijmans H., 1994, *Morphological Image Operators,* Academic Press, New York.

Hore A., Ziou D., 2010, Image quality metrics: PSNR vs. SSIM, International Conference on Pattern Recognition IEEE, 1051-4651/10, DOI 10.1109/ICPR.2010.579.

Jahne B., 2005, *Digital Image Processing,* Springer, Berlin.

Jahne B.,, 2004, *Practical Handbook on Image Processing for Scientific and Technical Applıcations*, Crc Press, Washington.

Jain A, Kanjalkar P. M, Kulkarni J. V., 2011, Estimation of image focus measure and restoration by Wavelet, *IEEE 4th Int. Conference on Intelligent Networks and Intelligent Systems (ICINIS), 1-3 November 2011*, 73-76, Kunming, China.

Jain A. K., 1989, Fundamentals of Digital Image Processing. Prentice Hall, London.

Jang J. S. R., 1997, *Neuro-Fuzzy And Soft Computing: A Computational Approach To Learning And Machine İntelligence,* Chapter 7: Derivative-Free Optimization, Prentice-Hall, USA, 173-196.

Jenkins D., Richard M.G., Daigger G. T., 1993, *Manuel On The Causes And Control Of Activated Sludge Bulking And Foaming,* 2.nd Edition, Lewis Publishers, Chelsea, Michigan.

Jenne R, Banadda E. N., Smets I, Deurinck J, Van Impe J., 2007, Detection of filamentous bulking problems: developing an image analysis system for sludge composition monitoring, *Microscopy and Microanalysis,* 13, 36-41.

Karaboga D., Akay B., 2007, Artificial bee colony (ABC) algorithm on training artificial neural networks, *15th. Signal Processing and Communications Applications SIU IEEE,* 1-4.

Kass M., Witkin A., Terzopoulos D., 1988, Snakes: active contour models, *International Journal of Computer Vision,* 1(4):321–331.

Khan A. A., 2013, Üniversite kampüsündeki araç plaka tanıma ve takibi için matematik ve algoritmik ilkeler, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü, Kahramanmaraş Sütçü İmam Üniversitesi,* Kahramanmaraş.

Kızılkaya A., 1997, Taranmış bozuk görüntülerin kalitelerinin yazılım teknikleri ile artırılması, PhD Thesis, *Pamukkale Üniversitesi,* Denizli.

Kohavi, R., 1995, A study of cross-validation and bootstrap for accuracy estimation and model selection, Proc. IJCAI'95 Conf.

Korkmaz N., 2008, Omurga şekil bozukluğu analiz ve teşhisine yönelik yazılım geliştirme, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Kulluk S., 2009, Karınca koloni optimizasyonu ile yapay sinir ağlarından kural çıkarımı, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü,* Kayseri.

Kutlar A., 2007, *Ekonometriye Giriş,* Nobel Yayıncılık, Ankara, 1-194.

Küçükhemek M., 2010, Konya Su Ve Kanalizasyon İdaresi (KOSKİ) Genel Müdürlüğü Konya Atıksu Arıtma Tesisinde arıtılmış atıksuların pilot ölçekte geri kazanımı ve alternatif bir su kaynağı olarak yeşil alan sulamasında yeniden kullanımı projesi.

Laybourn-Parry J., 1994. *A Functional Biology of Free-Living Protozoa,* London & Sydne,. UK, 218p.

Leung F. H., Lam F. H., Ling K. S. H., Tam P. K. S., 2003, Tuning of the structure and parameters of a neural network using an improved genetic algorithm, *IEEE Transactions on Neural Networks,* 14(1), 79-88.

Levenberg K., 1944, A Method for the Solution of Certain Non-Linear Problems in Least Squares, *Quarterly of Applied Mathematics,* 2, 164–168.

Li S., Kwok J. T., Wang Y., 2001, Combination of images with diverse focuses using the spatial frequency, *Information Fusion,* 2, 169-176.

Liang Z., 1993, Tissue classification and segmentation of MR images, *IEEE in Medicine and Biology,* 12(1), 81-85.

Lim, J. S., 1990, *Two Dimensional Signal and Image Processing,* New Jersey: Prentice Hall.

Lin, S. D., Lee, C., 2001, *Water and Wastewater Calculations Manual,* McGraw-Hill Inc., USA.

Liwarska E. B., 2005, Application of image analysis techniques in activated sludge wastewater treatment processes, *Biotechnology Letters* 27, 1427–1433.

Liwarska-Bizukojca E., Bizukojc M., 2005, Digital image analysis to estimate the influence of sodium dodecyl sulphate on activated sludge flocs, *Process Biochemistry,* 40(6), 2067–2072.

Low A., 1991, *Introductory Computer Vision and Image Processing*, McGraw-Hill Book C, London.

Maddali R., Prasad K. S., Bindu C. H., 2012, Discrete wavelet transform based medical ımage fusion using spatial frequency technique, *International Journal of Systems Algorithms & Applications*, 2, 2277-2677.

Marwala T., 2007, Bayesian training of neural networks using genetic programming, *Pattern Recognition Letters*, 28(12), 1452–1458.

Math Works Inc., 2012, Matlab R2012a documentation, http://www.mathworks.com/help/index.html [Erişim Tarihi: 12 Haziran].

McInerney T., Terzopoulos D., 1996, Deformable models in medical image analysis: a survey, *Medical Image Analysis*, 1(2), 91–108.

Mesquita D. P., Amaral A. L, Ferreira E. C., 2011a, Characterization of activated sludge abnormalities by image analysis and chemometric techniques, *Analytica Chimica Acta 2011*, 705, 235-242.

Mesquita D. P., Amaral A. L., Ferreira E. C., 2011b, Identifying different types of bulking in an activated sludge system through quantitative image analysis, *Chemosphere* 85, 643–652.

Mesquita D. P., Dias O., Amaral A. L., Ferreira E. C., 2009a, Monitoring of activated sludge settling ability through image analysis: validation on full-scale wastewater treatment plants, *Bioprocess Biosyst Eng.*, 32, 361–367.

Mesquita D. P., Diasa O., Diasa A. M .A., Amaral A. L., Ferreira E. C., 2009b, Correlation between sludge settling ability and image analysis information using partial least squares, *Analytica Chimica Acta,* 642, 94–101.

Michalewicz Z., 1992, *Genetic Algorithms + Data Structure = Evolution Programs*, Springer-Verlag, Berlin.

Misiti M., Misiti Y., Oppenheim G., Poggi J. M., 1996, Wavelet toolbox for use with matlab, The mathworks.

Mitiche A., Aggarwal J. K., 1985, Image segmentation by conventional and information-integrating techniques: a synopsis, *Image and Vision Computing*, 3(2), 50-62.

Mjalli F. S., Al-Asheh S., Alfadala H. E., 2007, Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, *Journal of environmental management*, *83*(3), 329-338.

Motta M. L. P. Amaral C., 2001, Characterisation of activated sludge by automated image analysis: validation on full-scale plants, *IFAC Computer Applications in Biotechnology*, Québec City-Canada.

Nisar H., Yong L. X., Ho Y. K., Voon Y. V., Siang S. C., 2012, Application of imaging techniques for monitoring flocs in activated sludge, *International Conference on Biomedical Engineering (ICoBE)*, 27-28 February, Penang-Malaysia.

Nixon M. S., Aguado A. S., 2002, *Feature Extraction And Image Processing*, Elsevier.

Oliveira-Esquerre1 K. P., Mori M., Bruns R. E., 2002, Simulation of an industrial wastewater treatment plant using artificial neural networks and principal components analysis, *Braz. J. Chem. Eng.*, 19(04), 365-370.

Orhunbilge N., 2000, *Uygulamalı Regresyon ve Korelasyon Analizi,* Avcıol Basım Yayın, İstanbul.

Ozturk C., Karaboga D., 2008, Classification by neural networks and clustering with artificial bee colony (ABC) algorithm, *In Sixth International Symposium on Intelligent and Manufacturing Systems Features, Strategies and Innovation*, Sakarya.

Övez S., 2010, Biyolojik atıksu arıtma tesisleri: kaçınılmaz sonuç çamur kabarma ve köpük problemi, *İTÜ XII. Endüstriyel Kirlenme Kontrolü Sempozyumu, 16-18 Haziran*, İstanbul.

Özkan M. V., 2010, Matlab görüntü işleme aracı kullanarak endometriozis hastalığının ultrason görüntülerğnde tespiti, Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ.

Özşen Ö., 2004, Mamogramlar üzerinde uygulanan görüntü işleme tekniklerinin incelenmesi, *Eleco`2004 Elektrik - Elektronik - Bilgisayar Mühendisliği Sempozyumu Ve Fuarı,* 8-12 Aralık, Bursa,

Öztemel E., 2006, *Yapay Sinir Ağları,* Papatya Yayıncılık, İstanbul.

Öztürk A., 2007, Filamentli bakterilerin sebep olduğu kabarma ve şişme problemleri, Yüksek Lisans Tezi, *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü,* Sakarya.

Öztürk İ., Timur H., Koşkan U., 2006, Atıksu arıtımının esasları evsel, endüstriyel atıksu arıtımı ve arıtma çamurlarının kontrolü, *Çevre ve Orman Bakanlığı*, Ankara.

Pai T. Y., Tsai Y. P., Loa H. M., Tsai C. H., Lin C. Y., 2007, Grey and neural network prediction of suspended solids and chemical oxygen demand in hospital wastewater treatment plant effluent, *Comput.Chem.Eng.*, 31, 1272–1281.

Pal, N. R., Pal, S. K., 1993, A review on image segmentation techniques, *Pattern Recognition,* 26(9), 1227-1249.

Pedrajas N. G., Boyer D. O., Martinez C. H., 2006, An alternative approach for neural network evolution with a genetic algorithm: Crossover by combinatorial optimization, *Neural Networks,* 19(4), 514–528.

Peker İ., 2007, *Çevre Mühendisliği Kimyası,* Birsen Yayınevi, Kayseri.

Perez Y. G., Leite S. G. F., Coelho M. A. Z., 2006, Activated sludge morphology characterization through an image analysis procedure, *Brazilian Journal of Chemical Engineering,* 23(30), 319-330, July- September.

Rajabli F., 2005, Darbantlı video iletişim sistemlerinde dalgacık dönüşümünün kullanılması, Yüksek Lisans Tezi, *Ankara Üniversitesi, Fen Bilimleri Enstitüsü,* Ankara.

Rangayyan R. M., 2005, *Biomedical Image Analysis,* CRC Press, Florida.

Reeves C. R., 1995, *Modern heuristic techniques for combinatorial problems,* McGraw-Hill Book Company Inc., Europe.

Rika J., Ephraim N. B., Ilse S., Jeroen D., and Jan V. I., 2007, Detection of filamentous bulking problems: developing an image analysis system for sludge composition monitoring, *Microscopy and Microanalysis*, 13, 36–41.

Rumelhart D. E., McClelland J. L., 1986, *Parallel distributed processing,* MIT Press, Cambridge, MA.

Sağıroğlu Ş., Beşdok E., Erler M., 2003, *Mühendislikte Yapay Zeka Uygulamaları I Yapay Sinir Ağları,* Ufuk Kitap Kırtasiye-Yayıncılık, Kayseri.

Samsunlu A., 2006, *Atık Suların Arıtılması,* Birsen Yayınevi, İstanbul, 193.

Schalkoff R. J., 1989, *Digital Image Processing and Computer Vision,* John Willey & Sons, Inc., Canada.

Seker D. Z., Eker O., 2005, Aktif kontur modeller ve düzey kümesi kullanarak çizgisel detayların yarı otomatik olarak çizilmesi, *10. Türkiye Harita Bilimsel ve Teknik Kurultayı,* 28 Mart-1 Nisan 2005, Ankara.

Sevgen S., 2009, Hücresel sinir ağları için kararlı şablon tasarımı ve görüntü işleme uygulamaları, İstanbul Üniversitesi Fen Bilimleri, Enstitüsü, Doktora Tezi, *Bilgisayar Mühendisliği Anabilim Dalı,* İstanbul.

Sexton R. S., Gupta J. N. D., 2000, Comparative evaluation of genetic algorithm and backpropagation for training neural Networks, *Information Sciences,* 129(1-4), 45-59.

Sezer E., 2008, Epilepsi teşhisi için EEG sinyal analizi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.

Sezgin M., Jenkins D., Parker D. S., 1977, A unified theory of filamentous activated sludge bulking, *J. Water Polln. Control Federation.*, 50, 362.

Shannon C. E., 1948, A mathematical theory of communication, *Bell System Technology Journal*, 27, 379-423.

Sleigh M. A., 1989, *Protozoa and Other Protists*, Edward Arnold, New York, 342p.

Spellman F. R., 2003, *Handbook of Water and Wastewater Treatment Plant Operations*, Lewis Publishers.

Suetens P., Bellon E., Vandermeulen D., Smet M., Marchal G., Nuyts J., Mortelman L., 1993, Image segmentation: methods and applications in diagnostic radiology and nuclear medicine, *European Journal of Radiology*, 17, 14-21.

Şahinkaya E., 2007, Çevre mikrobiyolojisi, ders notları, *Harran Üniversitesi, Mühendislik Fakültesi Çevre Mühendisliği Bölümü,* Şanlıurfa.

Şakar S., 2009, Çevre mikrobiyolojisi II ders notları, *Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Çevre Mühendisliği Bölümü*, İstanbul.

Şenler N. G. ve Yıldız İ., 2010, Tatlı su protozoonları ve önemi, *Derleme Dergisi*, 3(1), 7-16,

Tarı R., 1999, *Ekonometri*, Alfa Yayıncılık, İstanbul, 1-98.

Turgay E., Teke O., 2011, Autofocus method in thermal cameras based on image histogram, *IEEE 19th Conference on Signal Processing and Communications Applications (SIU)*, 20-22 April, Antalya, 462-465.

Ulutaş G., 2012, Gizli görüntü paylaşım şemalarının iyileştirilmesi ve geometri tabanlı yeni bir yöntemin tasarımı, Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.

Ustun O., 2009, Genetik algoritma kullanılarak ileri beslemeli bir sinir ağında etkinlik fonksiyonlarının belirlenmesi, *Pamukkale University Journal of Engineering Sciences, 15(3).*

Vong C. M., Wong P. K., Li Y. P., Ho C. M., 2005, Modelling of modern automotive petrol engine performance using support vector machines, *Journal of Zhejiang University SCIENCE*, J Zhejiang Univ, 6A(1), 1-8.

Widrow B., Lehr M. A., 1990, 30 years of adaptive neural networks: Perceptron, Madaline, and Backpropagation, *Proc. IEEE*, 78(9), 1415-1442.

Wu Q., Merchant F. A., Castleman K. R., 2008, *Microscope Image Processing*, Elsevier.

Yeniay Ö., 2001, An overview of genetic algorithms, *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 2(1), 37-49.

Yeo M. F. ve Agyel E. O., 1996, Optimising engineering problems using genetic algorithms, *Engineering Computations*, 15(2), 268-280.

Yılmaz E. C., 2009, Bir atıksu arıtma tesisinin girişindeki biyolojik oksijen ihtiyacının yapay sinir ağları kullanılarak modellenmesi, Yüksek Lisans Tezi, *Sakarya Üniversitesi Çevre Müh,* Sakarya.

Yücelbaş, C., 2012, Elipsoid Tanıma Çemberli Bir Yapay Bağışıklık Sistemi Tasarımı Ve Sınıflama Problemlerindeki Performans Analizi, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	**:**	HALİME BOZTOPRAK
Uyruğu	**:**	TC
Doğum Yeri ve Tarihi	**:**	SEYDİŞEHİR 02.04.1982
Telefon	**:**	
Faks	**:**	
e-mail	**:**	halimeboz@yahoo.com

EĞİTİM

Derece		**Adı, İlçe, İl**	**Bitirme Yılı**
Lise	:	Enis Şanlıoğlu Lisesi, Seydişehir, Konya	2000
Üniversite	:	Süleyman Demirel Üniversitesi, Isparta	2004
Yüksek Lisans	:	Süleyman Demirel Üniversitesi, Isparta	2007
Doktora	:	Selçuk Üniversitesi, Konya	2014

İŞ DENEYİMLERİ

Yıl	**Kurum**	**Görevi**

UZMANLIK ALANI

YABANCI DİLLER

İngilizce

YAYINLAR

Boztoprak H., Özbay Y., 2013, A new method for segmentation of microscopic images on activated sludge, *Journal of Electrical Engineering & Computer Sciences*, DOI: 10.3906/elk-1307-9, (Accepted), (Doktora tezinden yapılmıştır).

Boztoprak H., Özbay Y., 2013, Detection of protozoa in wastewater using ANN and active contour in image processing, *Istanbul University - Journal of Electrical & Electronics Engineering IU-JEEE,* Cilt 13, Sayı 2 (Doktora tezinden yapılmıştır).

Boztoprak H., Özbay Y., 2012, Görüntü işlemede aktif kontur ve YSA kullanarak atık sularda protozoa belirlenmesi, *Eleco'2012 Elektrik - Elektronik Ve Bilgisayar Mühendisliği Sempozyumu*, 29 Kasım - 01 Aralık 2012, Bursa (Doktora tezinden yapılmıştır).

Boztoprak H., Özbay Y., Güçlü D., Küçükhemek M., 2010, Determination of activated sludge floc characteristics using image processing, *International Sustainable Water and Wastewater Management Symposium, 26-28 October 2010, Konya* (Doktora tezinden yapılmıştır).

Boztoprak H., Çağlar M. F., Merdan M., 2007, Alternatif morfolojik bir yöntemle plaka yerini saptama, XII. Elektrik, *Elektronik, Bilgisayar, Biyomedikal Mühendisliği Ulusal Kongresi*, Eskişehir, Kasım 2007 (Yüksek Lisans tezinden yapılmıştır).