



**YAPAY SİNİR AĞLARI ALGORİTMALARI İLE PVP NANOLİFLERİN
ÇAPLARININ TAHMİNİ**

YÜKSEK LİSANS TEZİ

Süleyman KARABULUT

Danışman
Dr. Öğr. Üyesi İsmail YILDIZ

NANOBİLİM VE NANO TEKNOLOJİ ANABİLİM DALI

Ocak 2023

Bu tez çalışması 20.FEN.BİL.31 numaralı proje ile BAPK tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**YAPAY SİNİR AĞLARI ALGORİTMALARI İLE PVP
NANOLİFLERİN ÇAPLARININ TAHMİNİ**

Süleyman KARABULUT

Danışman

Dr. Öğr. Üyesi İsmail YILDIZ

NANOBİLİM VE NANO TEKNOLOJİ ANABİLİM DALI

Ocak 2023

TEZ ONAY SAYFASI

Süleyman KARABULUT tarafından hazırlanan “Yapay Sinir Ağları Algoritmaları ile PVP Nanoliflerin Çaplarının Tahmini” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 09/01/2023 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü Nanobilim ve Nano Teknoloji Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi İsmail YILDIZ

		İmza
Başkan	: Prof. Dr. Atilla EVCİN Afyon Kocatepe Üniversitesi Mühendislik Fakültesi
Üye	: Dr. Öğr. Üyesi İsmail YILDIZ Afyon Kocatepe Üniversitesi İncehisar MYO
Üye	: Dr. Öğr. Üyesi Mehmet BİLEN Mehmet Akif Üniversitesi Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
...../...../..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

09.01.2023

Süleyman KARABULUT

ÖZET

Yüksek Lisans Tezi

YAPAY SİNİR AĞLARI ALGORİTMALARI İLE PVP NANOLİFLERİN ÇAPLARININ TAHMİNİ

Süleyman KARABULUT

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Nanobilim ve Nano Teknoloji Anabilim Dalı

Danışman: Dr. Öğr. Üyesi İsmail YILDIZ

Bu araştırmada, Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi ile elektroçirime yöntemi kullanılarak nanolifler üretilmiş, üretilen nanoliflerin akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değeri kullanılarak veri seti oluşturulmuştur. Nanoliflerin analizi taramalı elektron mikroskobu (SEM) ile çapı Fibraquant programı ile saptanmıştır. Laboratuvar ortamında gerçekleştirilen geleneksel test ve test yöntemleri zaman almakta ve maliyetli olmaktadır. Geleceğe yönelik tahmin ve analizler, geçmişte yapılan gözlem sonucunda elde edilen değerler ile oluşturulan modeller aracılığıyla gerçekleştirmektedir. Yapay Sinir Ağları (YSA) ve Derin Öğrenme Algoritmaları günümüzde tahmin alanında oldukça kullanılan bir yöntem haline gelmiştir. Bu çalışmada, Yapay Sinir Ağları algoritmaları nanoliflerin çaplarının tahmin edilmesi için kullanılmıştır. Yapay Sinir Ağları ve Derin Öğrenme algoritmalarıyla nanoliflerin çapını etkileyen 4 adet bağımsız değişken girdi değişkeni olarak, nanolif çap değerleri çıktı değişkeni olarak belirlenerek modeller oluşturulmuş, bu modellerden ortaya çıkan sonuçlar literatürle karşılaştırılmıştır. Çalışma, nanoliflerin çaplarının ölçümü uygulamalarında Yapay Sinir Ağlarının ve Derin Öğrenme algoritmalarının uygulanabileceğini göstermiştir. Veri miktarının küçük olması nedeniyle Yapay Sinir Ağı modelinin Derin Öğrenme modeline göre daha başarılı olduğu belirlenmiştir.

2023, vi + 75

Anahtar Kelimeler: Nanolif, Yapay Sinir Ağları, Derin Öğrenme, Polimer

ABSTRACT

M.Sc. Thesis

ESTIMATION OF DIAMETERS OF PVP NANOFIBERS WITH ARTIFICIAL NEURAL NETWORKS ALGORITHMS

Student Süleyman KARABULUT

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Nanoscience and Nanotechnology

Supervisor: Asist. Prof. İsmail YILDIZ

Nanofibers are manufactured with Polyvinylpyrrolidone (PVP) polymer, water and alcohol solution and using electrospinning process in this research, data set is created with using flow rate for nanofibers which are manufactured, with using needle point, distance between plate and using applied voltage value. Analysis of nanofibers is determined with scanning electron microscope, diameter is determined with Fibraquant schedule. It takes a long time to make traditional test process in laboratory and also their cost is really too high. Estimation and analysis for future are estimated with obtained values which are result of remark in past and help of created models. Artificial neural networks and deep learning algorithms are process which are fairly used in estimation space nowadays. In this study, artificial neural networks and deep learning algorithms are used for guessing diameter of nanofibers. With Artificial Neural Networks and Deep Learning algorithms, 4 independent variables affecting the diameter of nanofibers were determined as input variables and nanofiber diameter values were determined as output variables, and the results obtained from these models were compared with the literature. Study shows that artificial neural networks and deep learning algorithms can be practised at applications for measuring diameters of nanofibers. Because of small amount for data, it is determined that model for artificial neural network is more successful than deep learning model.

2023, vi + 75

Keywords: Nanofiber, Artificial Neural Networks, Deep Learning, Polymer

TEŐEKKÜR

Tez alıŐmasının konusu, yapılan deneysel alıŐmalarla ilgili her tŒrlŒ desteęin saęlanması, ortaya ıkan sonuların yorumlanmasından, deęerlendirilmesi ve yazma aŐamasına kadar verdięi katkılardan dolayı tez danıŐmanım Sayın Dr. Őęr. Őyesi İsmail YILDIZ, baŐta araŐtırma olmak ũzere yazım sŒresince de yardımlarını esirgemeyen Sayın Prof. Dr. Atilla EVCİN'e, her konuda yardımcı olan hocalarıma ve arkadaşlarıma teŐekkŒr ederim.

Ayrıca araŐtırmamın baŐından beri maddi ve manevi desteklerinden dolayı aileme teŐekkŒr ederim.

SŒleyman KARABULUT
Afyonkarahisar, 2023

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	ix
RESİMLER DİZİNİ	x
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ.....	4
2.1. Nanoteknolojinin Tanımı ve Kullanım Alanları	4
2.2. Nanoteknolojinin Özellikleri	5
2.3. Nanoteknolojinin Tarihi	5
2.4. Nanoteknolojide Uygulama Alanları.....	10
2.4.1. Malzeme ve İmalat Sektörü	11
2.4.2. Elektronik ve Bilgisayar Teknolojileri	11
2.4.3. Havacılık ve Uzay Çalışmaları	13
2.4.4. Tıp ve Sağlık Sektörü	13
2.4.5. Enerji ve Çevre	15
2.4.6. Gıda ve Tarım.....	15
2.4.7. Savunma Sanayi ve Güvenlik.....	17
2.5. Üretim Yöntemleri	17
2.5.1. Yukarıdan Aşağıya Doğru (Top Down)	18
2.5.2. Aşağıdan Yukarıya Doğru (Bottom Up)	18
2.6. Nanolifler ve uygulama alanları	19
2.6.1. Nanolif Üretme Yöntemleri.....	20
2.6.1.1. Çekim prosesi (Drawing).....	21
2.6.1.2. Şablon Sentezi (Template synthesis)	21
2.6.1.3. Faz Ayırma (Phase separation)	22
2.6.1.4. Kendiliğinden Düzenlenme (Self assembly)	22
2.6.1.5. Meltblowing Yöntemi ile Nanolif Üretimi	22
2.6.1.6. Fibrilasyon Yöntemi	23

2.6.1.7. Bikomponent Yöntemi ile Nanolif Üretimi	24
2.6.1.8. Spunbond	24
2.6.1.9. Elektrolif Çekim Yöntemi (Electrospinning)	24
2.7. Elektrospinning Yöntemini Etkileyen Parametreler.....	26
2.7.1. Çözelti parametreleri	26
2.7.1.1. Konsantrasyon	26
2.7.1.2. Moleküler ağırlık	27
2.7.1.3. Viskozite	27
2.7.1.4. Yüzey Gerilimi	27
2.7.2. Proses parametreleri	28
2.7.2.1. Voltaj	28
2.7.2.2. Akış Hızı	28
2.7.2.3. Toplayıcı	29
2.7.2.4. Toplayıcı Plaka ile Şırınga Ucu Arasındaki Mesafe.....	29
2.8. Yapay Sinir Ağları.....	29
2.8.1. Yapay Sinir Ağları Tarihi	31
2.8.2. Yapay Sinir Ağları Mimarisi	32
2.8.3. Yapay Sinir Ağlarının Yapısı	36
2.8.3.1. Tek Katmanlı Ağ	36
2.8.3.2. Çok Katmanlı Yapay Sinir Ağları	37
2.8.3.3. İleri Beslemeli Yapay Sinir Ağları	37
2.8.3.4. Geri Beslemeli Yapay Sinir Ağları	38
2.8.4. Yapay Sinir Ağının Eğitimi	39
2.9. Derin Öğrenme (Deep Learning)	40
2.9.1. Derin öğrenme Mimarileri.....	42
2.9.1.1. Multilayer Perceptron Neural Network (MLPNN).....	42
2.9.1.2. Backpropagation	43
2.9.1.3. Convolutional Neural Network (ConvNet/CNN)	44
2.9.1.4. Recurrent Neural Network (RNN).....	46
2.9.1.5. Long Short-Term Memory (LSTM)	47
2.9.1.6. Generative Adversarial Network (GAN).....	48
2.9.1.7. Restricted Boltzmann Machine (RBM)	49
2.9.1.8. Deep Belief Network (DBN)	50
3. MATERYAL ve METOT.....	52

3.1. Çalışmalar İçin Kullanılan Malzemeler	52
3.1.1. SEM (Scanning Electron Microscope)	52
3.1.2. Geliştirici Kit	52
3.1.3. Fibraquant Programı	53
3.1.4. Matlab Programı	53
3.1.5. Google Colab	53
3.1.6. Python ve Keras	54
3.2. Yapay Sinir Ağları.....	54
3.2.1 Verilerin İşlenmesi	54
3.2.2 Modelin Oluşturulması	56
3.2.3 Yapay Sinir Ağının Eğitimi ve Testi	56
3.3. Derin Öğrenme	58
3.3.1 Verilerin İşlenmesi	58
3.3.2 Modelin Oluşturulması ve Eğitilmesi.....	59
3.3.2.1 Model-1	59
3.3.2.2 Model-2.....	60
4. BULGULAR.....	62
4.1. Yapay Sinir Ağları Sonuçların Test Edilmesi ve Değerlendirilmesi	62
4.2. Derin Öğrenme Sonuçların Test Edilmesi ve Değerlendirilmesi.....	63
5. TARTIŞMA ve SONUÇ	66
6. KAYNAKLAR.....	68
ÖZGEÇMİŞ.....	75

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

C	Karbon
Xe	Xenon
ZnO	Çinko oksit
MoS ₂	Molibden disülfür

Kısaltmalar

PVP	Polivinilpirolidon
YSA	Yapay Sinir Ağları
SEM	Scanning Electron Microscope
AFM	Atomic Force Microscope
STM	Taramalı Tünellemeli Mikroskopu
ADALINE	Adaptive Linear Neuron
RELU	Rectified Linear Unit
MLPNN	Multilayer Perceptron Neural Network
RMSE	Kök Ortalama Kare Hatası
CNN	Convolutional Neural Network
MLP	Multi Layer Perceptron
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
GAN	Generative Adversarial Network
RBM	Restricted Boltzmann Machine
DBN	Deep Belief Network

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 19'uncu yüzyıldan günümüze sanayi devrimleri	6
Şekil 2.2 Nanometre ölçülerinde üretilen transistör	12
Şekil 2.3 Top-Down ve Bottom-Up Yaklaşımlarının Gösterimi	17
Şekil 2.4 Nanolif Üretim Teknikleri	21
Şekil 2.5 Meltblowing yöntemi ile üretilen lifler	23
Şekil 2.6 Elektrospinning düzeneğinde liflerin oluşumu	25
Şekil 2.7 Elektrospinning deney düzeneği	26
Şekil 2.8 Yapay Sinir Hücresi	32
Şekil 2.9 Yapay Sinir Ağları Katmanları	36
Şekil 2.10 Tek Katmanlı Ağ Modeli	36
Şekil 2.11 Çok Katmanlı YSA Modeli.....	37
Şekil 2.12 İleri Beslemeli Yapay Sinir Ağları.....	38
Şekil 2.13 Geri Beslemeli Yapay Sinir Ağları	39
Şekil 2.14 Multilayer Perceptron Neural Network Modeli	42
Şekil 2.15 Backpropagation Neural Network Modeli	44
Şekil 2.16 Convolutional Neural Network	45
Şekil 2.17 Recurrent Neural Network	46
Şekil 2.18 Long Short-Term Memory	47
Şekil 2.19 Generative Adversarial Network.....	48
Şekil 2.20 Restricted Boltzmann Machine	49
Şekil 2.21 Deep Belief Network	50
Şekil 3.1 Laboratuvar ortamında elde edilen nanolifler	54
Şekil 4.1 Eğitim, doğrulama ve test kümelerine ilişkin hata performansları	62
Şekil 4.2 Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon grafiği .	63
Şekil 4.3 Model-1	64
Şekil 4.4 Derin Öğrenme Modeli-2.....	64

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Nanoteknolojideki Gelişmeler	10
Çizelge 2.2 Toplama Fonksiyonu Türleri.....	33
Çizelge 2.3 Transfer Fonksiyonları	35
Çizelge 3.1 Fibrquant Yazılımı ile elde edilen veriler.....	55
Çizelge 3.2 Ham Veriler.....	55
Çizelge 4.1 Ölçülen gerçek değerler ile tahmin edilen değerler	65



RESİMLER DİZİNİ

	Sayfa
Resim 2.1 Lycurgus Cup.....	7
Resim 2.2 Derin Öğrenme.....	40
Resim 3.1 LEO 1430 VP model SEM cihazı.....	52
Resim 3.2 NVIDIA Jetson Nano Developer Kit.....	52
Resim 3.3 Oluşturulan YSA Modeli	57
Resim 3.4 Yapay Sinir Ağı	57



1. GİRİŞ

Yeryüzündeki bilgi miktarının her geçen gün katlanarak arttığı günümüzde çok hızlı bir şekilde ilerleyen Bilgi Teknolojileri (IT) paralelinde endüstriyel alanlarda da elde edilen veri miktarında da büyük bir ilerleme sağlanmıştır. Elde edilen bu verilerin analizinin yapılmasına ve değerlendirilmesine zaman geçtikçe daha fazla ihtiyaç duyulmaktadır. Bu ihtiyaçlara yönelik olarak iş dünyasında veri madenciliği uygulama alanları geniş bir alana yayılmıştır.

Veri madenciliği (data mining), sahip olunan verilerden anlamlı bilgi çıkarmaya imkân sağlayan, çeşitli sektörlerde başarıyla kullanılan bir veri işleme yöntemidir. Veri madenciliği kısaca; veri toplama, veriyi ön işleme, modelleme ve değerlendirme aşamaları olarak nitelendirilir. Veri; veri ambarlarından, veri tabanlarından ve veri saklayabilen her ortamdan sağlanabilmektedir. Veriyi toplama veri madenciliği çalışmalarında son derece önemlidir. Çünkü toplanan veri, aranan bilgiyi anlamlı hale getirecek bir yapıda olmalıdır (Ertem, 2022).

Veri madenciliği, araştırma yapılan konuyla ilgili olarak faydalı bilginin elde edilmesini ve büyük veri kümeleri içinden geleceğe yönelik tahminler yürütülmesini sağlayan, istatistik, matematik gibi disiplinlerin birlikte kullanıldığı yöntemlerle elde bulunan veri yığınlarından karar sürecine destek olan üstü kapalı, net olmayan, hakkında önceden bilgi bulunmayan fakat potansiyel olarak anlamlı bilginin çıkarılması sağlayan bir yöntemdir. Veri madenciliği kavramının geniş bir kullanıcı kitlesine ulaşmasında ve araştırma alanına kullanılmasında, veri madenciliği yöntemleri ile veri madenciliğinde kullanılan algoritmaların, yazılımlarla bilgisayar ortamında kolayca uygulanabilmesinin önemli bir rol aldığı, bilginin artan önemi ile birlikte veri madenciliğinin daha fazla önem arz ettiği görülmektedir (Erken, 2017).

Veri tek başına anlam içermemekle birlikte, verinin işlenmesine imkân sağlayacak veri depolama ve veri analiz yöntemlerinin ilerlemesiyle, veriden anlamlı çıkarımlar sağlayarak, iş süreçlerinde daha etkin kararlar alınabilecektir. Böylece, tüketicinin taleplerini hızlı ve doğru bir biçimde karşılayabilecek mal/hizmetler geliştirilebilecek,

işletmenin maliyetlerinin azaltılması ve diğer işletmelere karşı rekabet avantajı sağlanabilecektir. Bu sebeple, eğitimden sağlık sektörüne, tarımdan finansa ve bilişimden ulaştırmaya kadar pek çok alanda veri madenciliği giderek yaygınlaşmaktadır (Ersöz 2019).

Yapay sinir ağları (YSA), sınıflandırmadan modellemeye, veri ilişkilendirmeden yorumlamaya kadar, kümeleme, kontrol ve optimizasyona kadar birçok farklı alanlarda kullanılırken, geleceğe yönelik değerlerin tahmini kullanıldığı önemli alanlardan biri olarak karşımıza çıkmaktadır. Yapay Sinir Ağları (YSA), insan beyninin özelliklerini taklit ederek, öğrenme metodu ile yeni bilgiler üretilme ve keşfetme yeteneklerine herhangi bir destek olmaksızın otomatik şekilde gerçekleştirmek için geliştirilen bir yöntemdir.

Bir makine öğrenmesi çeşidi olan Derin Öğrenme (Deep Learning), çok katmanlı yapay sinir ağlarını kullanan bir yapay zekâ yöntemidir. Derin öğrenme, bir veri setiyle sonuçların tahminini sağlayacak olan yapay zekanın eğitilmesi işlemine imkân vermektedir.

Derin öğrenme teknikleri köklerini Yapay Sinir Ağları (YSA)'dan almaktadır. Üst düzey soyut kavramları modellemeyi amaç edinen algoritmalarından oluşan Derin öğrenme farklı düzeydeki ve katmanlardaki öğrenmeyi kullanmaktadır. Tasarımında insan beynini taklit eden, örüntüleri tanıma ve hatanın en küçüklemesine dayanan bir yöntemdir. Son zamanlarda popüler hale gelen derin öğrenme çalışmalarının temelini Yapay Sinir Ağları oluşturmaktadır (Sevinç 2021). Derin öğrenme algoritmaları ile yapılan çalışmalarda yüksek doğruluk oranı sonuçlar elde edilmesi derin öğrenmenin bu tezde ulaşılmak istenen sonuç doğru tahmin oluşturacak bir yöntem olarak değerlendirilmiştir.

Temel bilimsel yöntemler, teknoloji, eğitim, araştırma ve üretim yöntemlerinin gün geçtikçe gelişmesi yeni ve faydalı ürünler ile ileri teknolojilerin gelişmesini sağlamaktadır. Bu yeni teknoloji, eğitimden endüstriye kadar birçok ortak çalışma alanını bir araya getirmektedir. Bu sayede farklı teknolojilerin meydana çıktığı görülmektedir. Farklı disiplinlerin iş birliği sağlamasıyla ileri teknolojilerin ortaya

çıkması kaçınılmazdır. Nanoteknoloji ortaya çıkan yeni teknolojilerden birisidir.

Günümüzde yeni bir teknoloji devrimi olarak algılanan Nanoteknoloji, 1-100 nanometre (nm) boyutlardaki maddeleri anlamak, kontrol etmek ve atomik ölçülerde incelenerek işlevsel hale getirilmesi olarak tanımlanmaktadır (Ersöz vd. 2018). Maddelerin üzerinde esnek işlemlerin gerçekleştirilmesine imkân sağlayan nanoteknoloji, maddeleri atomik düzeyde incelemektedir.

Malzeme bilimi, matematik, fizik başta olmak üzere birçok alanda kullanıldığı görülen nanoteknoloji uygulamaları ile katma değeri yüksek, yeni ve eşsiz özelliklere sahip ürünlerin üretilmesine olanak sağlamaktadır (Sevinç 2017).

Endüstrinin birçok alanında kullanılan nanoteknoloji veri madenciliği tekniklerinde ele alınmış, Yapay Sinir Ağlarına ve Derin Öğrenme yöntemlerinde sınırlı sayıda araştırmalar yapıldığı görülmüştür. Bu çalışmada, Yapay Sinir Ağları algoritmaları nanoliflerin çaplarının tahmin edilmesi amacıyla kullanılmıştır. Yapay Sinir Ağları ve Derin Öğrenme yöntemleri ile girdi değişkeni olarak nanoliflerin çapını etkileyen 4 adet bağımsız değişken, çıktı değişkeni olarak ise nanolif çap değerleri belirlenerek modeller oluşturulmuş, modellerden elde edilen tahmin değerleri gerçek değerler ile karşılaştırılmıştır. Çalışma, nanoliflerin çaplarının ölçümü uygulamalarında Yapay Sinir Ağlarının ve Derin Öğrenme algoritmalarının uygulanabileceğini göstermiştir.

Tezin akışı şu şekilde planlanmıştır: 2'nci bölümde nanoteknoloji ile nanolifler hakkında genel bilgiler verilerek, nanoliflerin üretim süreci ve Yapay Sinir Ağları ve Derin Öğrenme yöntemleri anlatılmıştır. Bölüm 3'te tez kapsamında kullanılan malzemeler ve uygulanan Yapay Sinir Ağı ve Derin Öğrenme yöntemlerinden bahsedilerek veri seti, normalizasyon işlemleri, modellerin hazırlanması ve eğitilmesi süreçlerinden bahsedilmiştir. Bölüm 4'te oluşturulan modeller ve elde edilen sonuçlar ve modellerin değerlendirilmeleri yapılmıştır. Bölüm 5'te elde edilen sonuçlarının Veri Madenciliği yöntemlerinden Yapay Sinir Ağları ve Derin Öğrenme yöntemleri ile tahmin edilebilirliği üzerine öneriler geliştirilmiştir.

2. LİTERATÜR BİLGİLERİ

2.1. Nanoteknolojinin Tanımı ve Kullanım Alanları

Nanoteknoloji, yeni nesil malzemelerin geliştirilmesi, bilimsel arařtırmalar ve incelemelerin nano ölçülerde yapılması şeklinde tanımlanmaktadır. Nanoteknoloji, Yunanca'dan dilimize geçmiş bir kelimedir. Bir uzunluk birimini ifade eden nanometre 10^{-9} metreye eşittir (Yıldırım 2018). Yunanca "nanos" sözcüğünden türetilen nano terimi, "cüce" veya "küçük" anlamına gelmektedir (Aluya 2015). Nano kelimesi nanometreyi ifade ederken, malzemelerin mekanik, termal, elektrik, manyetik, optik ve estetik gibi özelliklerine etki eden, metrenin milyarda biri ölçüğündeki uzunluk ölçüsü olarak tanımlanmaktadır (Schodek vd. 2009) Teknoloji terimi ise Yunanca sistemli olarak işlem yapma manasına gelen technikos ile bilim anlamına gelen logia kelimelerinden türemiştir. Nitekim nanoteknoloji atom boyutlarında sistemli bir şekilde işlem yapma bilimi olarak tanımlanmıştır.

Son yıllarda insanların günlük hayatında uygulamalarıyla daha fazla yerini almaya başlayan nanoteknoloji "maddenin düzenlenmesi, kontrolü ve yeniden yapılandırılması" şeklinde genel olarak ifade edilmektedir. Yapılan bilimsel arařtırmalar göz önüne alındığında 21. yüzyılda birçok alanda etkili olacak farklı bir teknoloji olarak ortaya çıkmaktadır.

1-100 nanometre boyutlardaki maddelerin anlamak, kontrol etmek ve atomik boyutlarda incelenerek işlevsel hale getirilerek tanımlanan ve günümüzde yeni bir teknoloji devrimi olarak algılanan nanoteknoloji, günümüzde yaşantımıza hızla dahil olmaktadır. Son yıllarda reklam panolarında, sosyal medya ve televizyonlarda sıklıkla leke tutmayan kumaşlar, çizilmeyen yüzeyler, renk deęiřtiren boyalar, yaşlanma karşıtı kozmetik ürünler ve daha niceleri nanoteknolojik ürünler olarak dikkatimizi çekmektedir. (Ersöz vd. 2018). 1 nanometre (nm) ile 100 nanometre (nm) arasındaki yapıları içeren bir teknoloji olan nanoteknoloji, dięer bir tabirle maddenin 1 ila 100 nm arasındaki davranışlarını anlama ve kontrol etme bilimidir. Fiziksel miktarın milyarda biri olarak tanımlanan "Nano" kelimesi, nano boyutlarındaki maddelerin uygulama aralığı 1-100 nm arasında olduğunu göstermektedir (Tolochko 2009).

Nanoteknoloji kullanılarak bilimsel alanlarda yeni materyaller geliştirilmekte, bu materyallerde (10^{-9}) nanometre ölçeğinde boyutlarda küçültme, fiziksel ve kimyasal özellikleri değiştirerek yeni uygulamalarda kullanılabilir (Rashidi vd. 2011).

2.2. Nanoteknolojinin Özellikleri

Nanoteknolojiye ait bir takım önemli özellikleri şöyle sıralanmaktadır: (TÜSİAD 2008)

- Nanoteknoloji, daha önce kullanım alanı olmayan yeni ürün gruplarının geliştirilmesi için imkanlarının oluşturulması ve endüstride yeni ürünler ve süreçler geliştirmemize olanak sağlayan, toplum üzerinde geniş ve beklenmeyen etkileri olan alanlar teknolojisidir.

- Nanoteknoloji, yeni üretim süreçlerine hitap etmesi ve daha yüksek standartlara sahip ve düşük maliyetlerde ürünlerin üretilmesini sağlaması sebebiyle, eski bir geçmişe sahip üretim yöntemlerinin yerine geçerek ve bunların ilerleyen aşamalarda demode olmalarına yol açarak geleneksel alanı bozmaktadır. Nanoteknoloji ile birlikte, mevcut ürün ve üretim süreçlerden farklı ürünler ve prosesler meydana çıkmakta ve firmalarda diğer firmalarla rekabet edebilmek ve varlığını sürdürebilmek için bunlara uyum sağlamak zorundadırlar.


- Nanoteknoloji hızlı bir şekilde ilerleyen birçok disiplini içeren bilimsel ve teknolojik alandır. Malzeme bilimi, bilgisayar ve elektrik, matematik, fizik, biyoloji, kimya, tıp, eczacılık, uzay ve tarım gibi birçok bilimsel alanda kullanım yeri bulunan nanoteknolojide disiplinler arasındaki ayrılığın keskin bir şekilde belli olmadığı bir teknolojidir.

- Sanayileşme ile beraber güçlü ve gelişmiş ülke yönetimleri nanoteknolojik çalışmaların desteklenmesi amacıyla kaynak ayırmakta, ekonomik fırsatların yeni değerlere dönüştürüldüğü sistemde dünya çapındaki girişimcilerle bazı büyük firmaların da nanoteknoloji alanına yatırım yapmaları nanoteknolojinin evrensel olduğunu göstermektedir.

2.3. Nanoteknolojinin Tarihi

Geçmişten günümüze insanlığın refahını artıran bilim ve teknolojiler incelendiğinde (Bakınız Şekil 2.1), hayatımızın birçok alanında hissetmeye başladığımız

nanoteknolojinin yeni bir endüstri ve enformasyon devrimi olarak 21. yüzyıla damgasını vuracağı, kısa zamanda bir ülkeye ait nanoteknoloji düzeyinin o ülkenin gücünün bir ölçüsü olabileceği, öncelikle malzeme biliminde ve biyoteknoloji alanlarında gelişeceği, elektronik, spintronik ve moleküler elektronikte yoğun bir şekilde ağırlığını hissettireceği öngörülmektedir (İnt. Kyn. 1).



Şekil 2.1 19'uncu yüzyıldan günümüze sanayi devrimleri

Modern nanobilimin ve nanoteknolojinin yeni bir çalışma alanı olarak nitelendirilmesine rağmen nanomalzemelerin asırlardır kullanıldığı görülmektedir. Nitekim, milattan sonra (MS) IV. yüzyılda Romalıların ürettiği özel bir bardakta (Lycurgus Cup, Bakınız Resim 2.1), koloidal altın ve gümüş nanopartikülleri ihtiya eden dikroik cam kullanıldığı, bu bardağın dışarıdan gelen ışıkla yeşil görüldüğü, içeriden gelen ışıkta kırmızı renk verdiği tespit edilmiştir (Bryksa ve Yada 2012). VI-XVII'nci asırlar arasında seramik ve cam malzemelerin üretiminde altın klorür, gümüş ve bakır nanopartikülleri, diğer metallerin klorürleri ile oksitlerinin nanopartikülleri kullanılmıştır. Michael Faraday tarafından 1857 yılında belirli bir ışıklandırma şartlarında farklı renklerde çözeltiler yayan “yakut” renkli altın nanotaneçikler içeren koloidal çözelti keşfedilmiştir (Zor 2016).



Resim 2.1 Lycurgus Cup

İncelendiğinde tarih boyunca çeşitli ürünlerde kullanıldığı ortaya çıkan nanoteknoloji ile ilgili ilk kavramlar, Amerikalı ünlü fizikçi Dr. Richard Feynman'ın 1959 senesinde California Teknik Enstitüsünde gerçekleştirilen toplantıdaki “There’s Plenty of Room at the Bottom-Tabanda bol miktarda yer var” adlı konuşmasına dayanmaktadır. Dr. Richard Feynman yaptığı bu konuşmada bilgilerin küçük ölçülerde depolanmasından, atomik boyutlarda yazmak ve okumaktan, bilgisayarların minyatür hale getirilmesinden, atom ve molekül boyutlarındaki üretimin yeni buluşlar ortaya çıkaracağını bildirmiş, fakat net bir şekilde nanoteknoloji terimini kullanmamıştır (Özak ve Özkan 2013).

Feynmann 1959'da yaptığı konuşmasında özetle şunları öngörmüştür (Erkoç 2007):

- 24 ciltten oluşan Brittanica Ansiklopedisinin bir toplu iğne ucuna yazılması
- Mikron boyuta sahip bilgi
- Görüntü çözünürlüğü gelişmiş elektron mikroskobu
- Muhteşem biyolojik sistem
- Bilgisayarları minyatürize etmek
- Buharlaştırma yolu ile minyatürizasyon
- Yağlama sorunları
- Yüzlerce minik el

- Atomların düzenlenmesi
- Küçük bir dünyadaki atomlar

Richard Phillips Feynman ünlü konuşmasında “Brittanica ansiklopedisinin 24 cildini bir toplu iğne başına yazılabileceğini” vurgulayarak, nanoteknolojinin kavram ve uygulamalarını ilk kez meydana çıkarmıştır (Menceloğlu ve Kırcı 2008).

1974 yılında Tokyo Bilim Üniversite’sinde Temel Nano-Teknoloji Konseptleri konulu makalede Japon bilim adamı Norio Taniguchi, nanometre ölçeğinde üretimi gerçekleştirilen yarı iletken süreçleri “nanoteknoloji” olarak tanımlayarak bu terimi dile ilk olarak dile getirmiştir. Bu makalede Norio Taniguchi: "Atom ya da molekül ayırma, birleştirme, bozma sürecine nanoteknoloji denir" ifadesiyle nanoteknolojiyi tanımlamaktadır (İnt. Kyn. 2).

Norio Taniguchi nanoteknoloji terimini kullandıktan 7 yıl sonra IBM tarafından icat edilen yüzeyleri atomik düzeyde görüntülemek için kullanılan taramalı tünelleme mikroskobu ile Ksenon atomlarını dizerek firma logosu nano ölçülerde oluşturulmuştur. 1986’daki çok yüksek çözünürlüğe sahip bir taramalı kuvvet mikroskobu olan atomik kuvvet mikroskobunun icat edilmesiyle ile nano ölçekte görüntüleme, ölçme ve malzeme işleme olanağı yaratılmıştır (Körözlü 2016).

1986 yılında K. Eric Drexler, Massachusetts Teknoloji Enstitüsü’nde yayımlanan “Engines of Creation: The Coming Era of Nanotechnology-Motorların Yaratılışı: Nanoteknolojinin Yaklaşan Çağı” adlı kitabında, tüm canlı hücrelere sahip yapılardan daha küçük olması, mevcut makinelere kıyasla güçlü ve hafif, kendisini kopyalayabilen, nano boyutta makineler imal edilebileceğinden bahsetmiştir (İnt. Kyn. 3).

Nanoteknoloji tarihindeki bir diğer dönüm noktası, Rice Üniversitesindeki çalışmalarıyla Richard Smalley liderliğindeki araştırmacıların 60 karbon atomunun simetrik bir şekilde yerleştirilmesi ile elde edilen futbol topuna benzeyen “fullerene” moleküllerinin geliştirmesiyle olmuştur. 1996 yılında Nobel Kimya ödülünü alan araştırmacıların keşfi olan molekül, bir nanometre ölçüsünde, çelikten daha sert, plastikten daha hafif, elektriği ve ısıyı geçiren bir yapıya sahipti (Özdoğan vd. 2006).

1985 yılında Japon fizikçi Sumino Iijima tarafından icat edilen karbon nanotüpleri, 1991 yılında üretilmeye başlanmıştır.

Nanoteknolojinin Tarihsel Gelişimi;

1959: Richard Feynman'ın nanobilim ve nanoteknolojinin başlangıcı sayılabilecek meşhur konuşması,

1974: İlk moleküler elektronik aygıt için Aviram ve Seiden tarafından için patent alınması,

1981: G.K. Binnig ve H. Rohrer tarafından atomların tek tek görüntüsünün alınması amacıyla Taramalı Tünellemeli Mikroskopu (STM) icadı,

1985: R. Curl Jr. , H. Kroto, R. Smalley tarafından Karbon 60(C60) 'ın keşfedilmesi,

1987: İletkenliğin kuantum özelliğinin ilk kez gözlenmesi ve T.A. Fulton ve G.J. Dolan tarafından ilk kez elektron transistörünün yapılması,

1988: W. De Grado ve çalışma arkadaşları tarafından yapay protein yapılması,

1989: IBM logosunun nikel bir yüzeyin üstünde bulunan xenon (35 Xe atomu) atomlarının yerlerinin yeniden düzenlenerek yazılması,

1991: Lijima'nın çok duvarlı karbon nanotüpleri keşfetmesi,

1993: Lijima ve Bethune tarafından tek duvarlı karbon nanotüplerin keşfi,

1997: N. Seeman tarafından DNA molekülü kullanılarak nanomekanik aygıt yapılması,

1997: İlk kez nanotüp kullanılıp elektrik akımının ölçülmesi,

1998: C.Dekker ve çalışma arkadaşları tarafından TUBEFET yapılması,

1999: M. Reed ve J.M. Tour tarafından ilk organik molekül ile elektronik anahtarı yapılması,

2001: ZnO nanotel lazerinin yapılması,

2002: Süper örgü nanoteller yapılması,

2005: Dört tekerleğe sahip nano araba modelinin hareket ettirilmesi (İnt. Kyn. 4).

Nanoteknoloji alanındaki gelişmeleri dört dönem halinde gruplandırmak mümkündür (Çizelge 2.1);

Çizelge 2.1 Nanoteknolojideki Gelişmeler

Dönem	Periyot	Tema	Gelişimin Önde Gelen Uygulamaları
1. Dönem	2001 Öncesi	Pasif	Yukarıdan aşağıya yaklaşım, nano yapıları metal, polimer, seramik, Katalizör, mikroelektromekanik sistemler
2. Dönem	2001-2005	Aktif nanoteknoloji	Aşağıdan yukarıya yaklaşım, adaptif nanoyapı, güneş pilleri, transistör ve diyotlar, sensörler, tanı için testler, nanoelektromekanik sistemler
3. Dönem	2005-2010	Nanosistem teknolojisi	Biyomimetik nanoyapı, yeni terapötikler, hedeflenmiş ilaç dağıtımı, nanoçipler, tarım
4. Dönem	2010 sonrası	Moleküler nanosistemler	Atom manipülasyonları ve nano ölçekli tasarım mimarisi

2.4. Nanoteknolojide Uygulama Alanları

21. yüzyılın en önemli gelişmeleri arasında yer alan nanoteknoloji, günümüzde de birçok alanda insan yaşamını daha kolay hale getiren uygulamalar ile karşımıza çıkmaktadır. Nanoteknoloji ile boyutları azalan malzeme ve aygıtlara baktığımızda maliyetin arttığını gözlemlenmekle birlikte nano ölçülerde malzeme ve aygıtların üretimleri sürecinde birtakım zorluklarla karşılaşmaktadır. Nano ölçülerde malzemelerin ve aygıtların üretimi için günümüzde kullanılan üretim teknolojileri

yerine nano üretimi gerçekleştirme yeteneğine sahip nanoteknolojilere diğer bir deyişle yeni nano üretim metotlarının geliştirilmesine ihtiyaç duyulmaktadır. Bu sistemler ile elde edilen aygıt ve malzemeler, daha dayanıklı ve hafif, üretimi sırasında daha az enerji ihtiyacı, hurda malzeme oluşmasının engellenmesi gibi özelliklere ulaşabilecektir.

Günden güne şaşırtıcı bir şekilde yeni uygulama alanları ile karşımıza çıkan nanoteknolojiyi belirli alanlarla sınırlamak uygun değildir. Günümüzde nanoteknolojinin, malzeme ve üretim, tıp ve sağlık, biyoteknoloji, elektronik ve bilgisayar, uzay ve havacılık, çevre ve enerji, tarım, bilim ve eğitim, savunma başlıkları altında incelendiği görülmektedir. Bunların dışında da birçok uygulamayla karşılaşılmaktadır (Uldrich ve Newbeyrry 2005).

2.4.1. Malzeme ve İmalat Sektörü


Nano ölçülerde malzeme daha fonksiyonel, daha dayanıklı olabilmekte ve daha hızlı işlemler gerçekleştirilebilmekte, bunlara ilave olarak enerji daha az kullanılmakta ve kapladığı yer daha az olmaktadır. Atomik ve moleküler ölçülerde elde edilen malzemeler, geleneksel üretim yöntemleri üretimi gerçekleştirilen malzemelere göre daha sağlam ve hafif malzemelerin üretilmesini sağlayarak endüstriler için önemli hale gelmektedir (Özdoğan vd. 2006). Nano imalatta, nano boyuttaki malzemelerin daha hafif ve sağlam, programlanabilir malzemelerden oluşması; malzemenin daha az kullanılması, üretim sürecinde daha az enerjiye ihtiyaç duyması, atıl malzeme oluşmaması gibi avantajların elde edilmesini sağlamaktadır. Üretim sürecinde yeniden işlenmeye ihtiyaç duyulmadan, istenilen şekilde nano yapıda metal, seramik, polimer malzemeler; nano boyutta parçacıklardan yapılan boya ve boyar maddelerin kullanılması ile geliştirilen baskı yöntemleri; nano boyutta kaplanan kesme aletleri, elektronik, kimyasal uygulamalar bunlara örnek teşkil etmektedir (Erkoç 2007).

2.4.2. Elektronik ve Bilgisayar Teknolojileri

Maliyeti düşük ve yüksek performansa sahip malzeme ve cihazların üretilmesi için kullanılan nanoteknoloji uygulamaları, bilişim teknolojileri ve elektronik alanında

sağlanan yeniliklere büyük katkı sağlamış ve sağlamaya devam etmektedir. Günümüzde nanoteknoloji ile daha büyük ve fazla miktarda bilgiyi işleyen ve depolayabilen daha hızlı, küçük taşınabilir sistemler geliştirilmiştir. Bilgisayar teknolojisinin ilerlemesinde önemli bir yere sahip olan tüm modern bilgisayarları etkinleştiren temel anahtarlar yani transistörler buna örnek olarak verilebilmektedir. Transistörler bilgisayarlar, akıllı telefonlar ve televizyonlar gibi her gün kullandığımız bütün elektronik cihazların temelini oluşturmaktadır (Ersöz vd. 2018).

21'inci yüzyılın başında transistör boyutu 130 ile 250 nanometre arasında ölçülürken, 2016 yılında Lawrence Berkeley Ulusal Laboratuvarı'nda yapılan çalışmada “karbon nanotüpler” ve “molybdenum disulfide (MoS_2)” kullanılarak 1 nanometre boyutunda bir transistör yapılmış, yapılan bu transistör şimdiye kadar yapılmış en küçük transistör (Bakınız Şekil 2.2) olarak değerlendirilmiştir (Desai vd. 2016).



Şekil 2.2 Nanometre ölçülerinde üretilen transistör

Milyonlarca elektronun yaptığı işleri yalnızca tek elektronun hareketi ile nano boyuttaki transistorlerde, bilgi işleme gerçekleştirilebilmektedir. Bunun sonucunda enerjiden yüksek oranda tasarruf edilebilirken boyut olarak küçük olduğundan milyarlarca transistorün bir santimetre kareye sığdırılabilmesi mümkün olabilmektedir. Daha küçük, hızlı ve daha iyi transistörler, bilgisayarların tüm belleğinin tek bir minik çipte (yonga)

saklayabilecek, bilgisayarlar daha hızlı çalıştırılabilir ve verimi daha fazla arttırılacaktır. Günümüzde klasik teknoloji ile oluşturulan bilgisayarlara göre nanoteknoloji ürünü bilgisayarların, boyut olarak daha küçük lakin hızının ve kapasitesinin daha yüksek olması ve daha az enerji tüketmesi, nanoölçekte elektronik devre elemanlarının üretilmesiyle sağlanabilecektir (Ersöz vd. 2018).

2.4.3. Havacılık ve Uzay Çalışmaları

Nanoteknolojinin havacılıkta ve uzay çalışmalarında uygulanması ile kullanılan malzemeler için ağırlık azaltılarak düşük maliyet oluşması sağlanmıştır. Nanotüplerin çekme direncinin çok iyi olması nedeniyle atmosfere seviyesine kadar çıkabilen yapılar tasarlanmıştır. Bunun neticesinde uzay araştırmalarına yönelik çalışmaların önünün açılması gerçekleşmiş ve fırlatma maliyetleri de azalmıştır. Daha temiz ve çevre kirliliğine duyarlı ulaşım sistemlerin oluşturulmasında nano malzemeler ile nano kompozitlerin önemli bir yeri olacaktır (Özdoğan 2006).

Nanoteknoloji kullanılarak üretilen malzeme ve aygıtların kullanılması uzay seyahatlerinde ihtiyaç duyulan, ağırlığı ve hacmi bakımından üretimi kısıtlı olan yakıtın bu sahadaki yaşanan zorluklarına birtakım çözümler sağlayacaktır. Nano yapıları malzemelerin çok daha sağlam ve hafif, sıcaklığa karşı daha fazla dayanıklı olması nedeniyle roket ve uzay istasyonları oluşturmakta önemli rol sahibidir. Uygulamaların daha az enerji ihtiyacı ve radyasyona karşı dayanımı fazla olan, işlem gücü yüksek bilgisayarların yapılması sonucu uzay araçlarında kullanılabilir mikro boyuttaki alet, algılayıcı ve nano yapıya sahip ısıya dayanıklı kaplama malzemelerin olması muhtemeldir (Erkoç 2007).

2.4.4 Tıp ve Sağlık Sektörü

Sağlık sektöründe birçok probleme çözüm yaratan nanoteknolojinin, kullanım alanlarında yaşanan artışa paralel şekilde giderek önemini arttırmaktadır. Sağlık alanında yapılan nanoteknolojik araştırmalar ve çalışmalar neticesinde, hastalıklara tanı konulması ve tedavilerde önemli ölçülerde üstünlüklerin ve avantajların sağlanması

beklenmektedir. Yapılan çalışmalar neticesinde büyük moleküllü partiküllerin canlıların vücut yapılarından dışarı atıldığı gözlemlenmiş, nano ölçülere sahip partiküllerin ise hücreler tarafından kabul gördüğü ve emiliminin gerçekleştiği görülmüştür (Tüylek 2016).

Nanoteknoloji ile yaşayan sistemlerde moleküler seviyelerde müdahale etme olanağı mümkün olabilecektir. Yeni tanı ve tedavi yöntemlerinin gelişmesi, yaşayan organizmalar ile etkileşimde bulunabilecek ölçülerde araçların tasarlanması ile sağlanabilecektir. Sadece hastalığın mevcut olduğu ve/veya dağıldığı bölgelere ulaşarak ilaç veren araçlar ve cihazlar, insan vücudunda hareket eden teşhis araçları, nanoteknolojinin tıp ve sağlık alanındaki yaşanabilecek uygulama örneklerindedir (Özdoğan vd. 2006). Nanoteknoloji kapsamında geliştirilen nanostent, kalp rahatsızlığı bulunan insanların tedavi süreçlerine yardım etmekte ve kan pıhtılaşmasını önlemektedir. Nanoteknoloji sayesinde geliştirilen ürünlerin kullanılması ile ilaçların hedef dokulara ve hücrelere taşınması, hasta dokuların onarılabilmesi, tıkanan damarların açılabilmesi mümkün olmaktadır (Kuruca 2012).

Tıbbi tekstil elemanlarından yapay böbrek, akciğer ve karaciğerlerde kanın filtrelenmesi maksadı ile kullanılan cihazlardır. Yapay karaciğerler, kan plazmasının temizlenmesini, yapay akciğerler ise sahip olduğu gaz değiştirici ile kanda oluşan karbondioksitin uzaklaştırılmasını ve ihtiyaç duyulan oksijenin temin edilmesini sağlamaktadırlar. Filtreleme ve gaz değiştirme işlemleri için nanolifler ve mikrolif membranlar kullanılmaktadır. Yapay böbrekler ise vücuda dışarıdan bağlanıp hemodiyaliz filtresi ile kanın temizlenmesini gerçekleştirmektedir (Lee vd. 2007).

Yeni nanoteknoloji uygulamalarının ortaya çıkması ve polimerik ilaç verilmesi konusunda daha fazla yetenek ve bilgi kazanılmasıyla, bağışıklık sisteminin tanıyabildiği tümör proteinlerini içeren sentetik polimer nanoparçacıklardan oluşan nano aşı alanı hızla gelişmektedir. Bu nano aşular kişinin kanserle kendi kendine mücadele etmesine yardım etmektedir (Luo vd. 2017).

2.4.5. Enerji ve Çevre

Enerjinin verimli kullanılması, depolanması ve üretilmesinde nanoteknolojinin uygulamaları kullanıldığı gibi çevreyi kirleten materyallerin tespitinde ve temizlenmesinde de nanoteknoloji uygulamalarından faydalanılmaktadır. Temiz içme suyu ve hava sağlamak, yeni enerji kaynakları geliştirmek ve aynı zamanda zararlı ve toksik maddeleri yaşadığımız çevreden arındırmak gibi uygulamaları mevcut olan nanoteknoloji, sürdürülebilir bir çevre yaratılmasına yardımcı olacak potansiyeldedir. (Ersöz vd. 2018).

Nanoteknoloji kullanılarak 15 ile 20 nanometre genişliğinde olan nanopartiküllerin geçmesini engelleyecek şekilde üretilen su filtreleri, nano boyutlu parçacıkları tanıyabilmekte, bu nano boyuttaki virüsleri ve bakterileri yok etme özelliğine sahiptir. Böylelikle düşük maliyette portatif su arıtma sistemleri gelişmekte, içme suyu kalitesinin artırılması mümkün olmaktadır (Yan vd. 2016).

Nano malzemeler kullanılarak laboratuvar şartlarında güneş pillerinin verimleri % 40'lara kadar arttırılmış, bu güneş pillerinin polimer ve kumaş gibi bükülebilir malzemeler üzerinde imal edilmesi sağlanmış, yakıt pillerine ait ebatlar küçültülerek yeni uygulama alanları için kapılar aralanmıştır. Nanokompozit malzemelerin kullanılarak çok küçük hacimlere hidrojen depolanabilmekte, hafif ve dayanıklı rüzgâr türbini kanatları üretilmektedir (Şahin 2019).

2.4.6. Gıda ve Tarım

Birçok doğal gıda nano boyutta bileşenler içermekte olup özellikleri yapılarına göre belirlenmektedir. Gıdaların en önemli hammaddelerinden (proteinler, nişastalar ve yağlar) normal gıda işleme sırasında nanometre ve mikrometre ölçeklerinde yapısal değişikliklere uğrarlar. Gıdalarda doğal olarak oluşan nanoyapıların araştırılması, esas olarak gıdanın fonksiyonel davranışını iyileştirmek için tasarlanmıştır. Nano ölçekte gıda malzemeleri ve gıda işleme anlayışı, yeni ve geliştirilmiş gıda ürünleri yaratmak için önemlidir. Dahası, nanoteknoloji gıda potansiyeli için sınırsız görünmektedir (Sekhon 2010).

Gıdaların üretilmesinde, işlenmesinde ve ambalajlanmasında nanoteknoloji tekniklerinin kullanılması nano gıda olarak ifade edilmektedir. Bu teknikle, gıdaların nanomakineler tarafından üretilmesi veya modifiye edilmesi söz konusu değildir. Gıda nanoteknolojisi, basit bir şekilde ifade edilecek olursa gıda sektöründeki nanobilim uygulamalarını kapsamaktadır. Daha net bir şekilde ise nano bilim ve mühendislik uygulamaları ile gıda yapıların, dokuların ve kalitesinin üzerinde yeni atılımlar ve uygulamalar geliştirmek şeklinde tanımlanmaktadır. Bir başka deyişle nano gıda; yetiştirme, üretme, işleme ve paketlenme sürecinde nanoteknoloji tekniklerin ve araçların kullanılmasıyla ilgilidir (Erdem ve Gülel 2015).

Nano ölçekte gıda malzemeleri ve gıda işleme anlayışı, yeni ve geliştirilmiş gıda ürünleri yaratmak için önemlidir. Dahası, nanoteknolojinin gıda potansiyeli sınırsız görünmektedir. Gıda endüstrisinde nanoteknoloji, ambalajdaki bakterileri tespit etmek veya daha güçlü tatlar ve renklendiriciler üretmek de dahil olmak üzere potansiyel kullanımları araştırıldığından üreticileri heyecanlandırmaktadır. Günümüzde, herhangi bir tür nanoteknoloji kullanan gıda ürünlerinin sayısı nispeten azdır. Nanoteknoloji, gıda sisteminde; raf ömrü boyunca gıda dokusu, tadı, işlenebilirliği ve stabilitesinde yenilik üretebileceği için gıda bilimini olumlu bir şekilde etkileme potansiyeline sahip olacağı ve devrim yaratabileceği düşünülmektedir (Rao 2009).

'Nanofood' terimi, nanoteknoloji teknikleri veya araçları kullanılarak yetiştirilen, üretilen, işlenen veya ambalajlanan veya üretilen nanomalzemelerin eklendiği gıdaları açıklamaktadır. Nanofood, aslen nano ölçekte doğal olarak birçok gıda yapısı bulunduğu için yüzyıllardır gıda işlemenin bir parçası olmuştur. Nanofood'un amacı gıda güvenliğini artırmak, beslenme ve lezzeti arttırmak ve maliyetleri düşürmektir (Bouman 2003).

Yakın gelecekte tarımsal gıda alanının gelişmesini sağlayacak en önemli teknoloji olması beklenen nanoteknoloji, günümüzdeki modern tarımın en önemli araçlarından birisi olmuştur. Nanoteknoloji tarım alanında; tarımsal ve gıdasal üretim sistemlerinde, ve mahsullerin veriminin artırılmasında, yeni agrokimyasal maddelerin

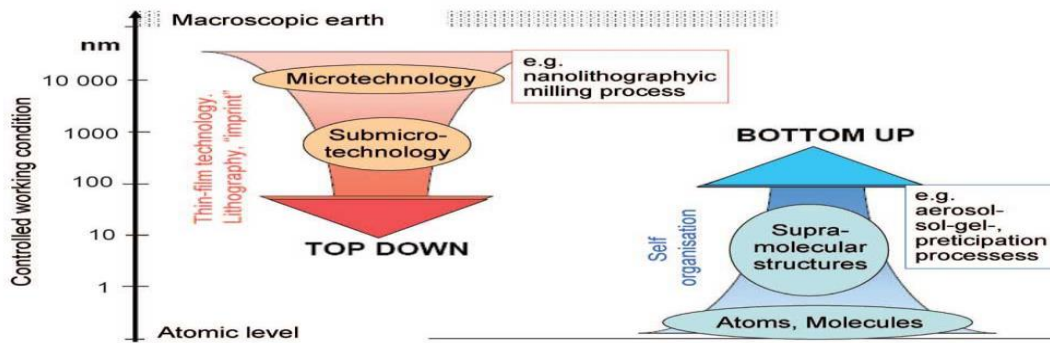
sentezlenmesinde ve yeni dağıtım mekanizmalarının oluşturulmasında, bu alanlarda yaşanan hastalıkların tanı ve tedavi uygulamalarında, pestisit kullanımının azaltılmasında, moleküler ve hücrel çalışmalarda yeni ve kullanışlı araçların geliştirilmesinde, patojenlerin tespitinde, çevre korunmasında ve bütün bu alanlarda kullanılacak yeni malzemeler geliştirmede, ürünlerin verimlerinin ve besin değerinin artırılmasında ve yeni katma değeri yüksek ürünlerin üretilmesi gibi uygulama alanları bulabilecektir (Sekhon 2014, Tarafdar vd. 2013).

2.4.7. Savunma Sanayi ve Güvenlik

Geliştirilmesinin asıl amacı insanlar için fayda yaratması düşünülen nanoteknoloji uygulamaları, askerî alanda uygulama alanlarının yaygın hale gelmesi ile insanlığın karşısına tehdit olacak şekilde çıkabilecektir. Bu durum hem nanoteknolojik gelişmelere yönelik farkındalık oluşmasına hem de bununla beraber güvenlik kaygıları yaratmasına paralel nanoteknolojideki çalışmaların hızlı bir şekilde ilerlemesine sebep olabilecektir (Yusuf, 2019). Nanoteknolojideki gelişmeler, gelecekteki askeri personelin, onun kullanacağı malzemenin ve gelecekteki savaşların üzerinde önemli etkiler yaratacaktır. Özellikle bu teknolojiler, yüksek algılama kabiliyetine sahip biyolojik ve kimyasal sensörler, çoklu sensörler ve analiz sistemleri, analitik mikrosistemler gibi gerek duyulan malzemelerin geliştirilmesine imkân yaratacaktır.

2.5. Üretim Yöntemleri

Nano yapıların elde edilmesinde Aşağıdan Yukarıya (Bottom-Up) ve Yukarıdan Aşağıya (Top Down) olarak isimlendirilen 2 genel yöntem (Şekil 2.3) bulunmaktadır.



Şekil 2.3 Top-Down ve Bottom-Up Yaklaşımlarının Gösterimi

2.5.1. Yukarıdan Aşağıya Doğru (Top Down)

Nanomalzemelerin üretimi sürecinde uzun bir zaman ihtiyacı olan, genelde düşük maliyetli bir şekilde nanomalzeme elde edilemeyen üretim yöntemidir. Yüksek miktarda nanomalzemenin üretimi gerçekleştirilecekse Yukarıdan Aşağıya Doğru (Top Down) yöntemi uygun olmayacaktır. Bu yöntem, fiziksel üretim uygulamaları için en uygun olan yöntem olarak karşımıza çıkmaktadır. Top Down yöntemi ile günümüzde kullanım yeri bulunan büyük boyutlu malzemelerin nano boyutlara indirgenmesi suretiyle nano yapıya sahip malzemenin üretilmesi sağlanmaktadır. Bu işlemleri gerçekleştirilebilmek maksadıyla dışarıdan mekaniksel ve kimyasal işlemlere tabi tutmak ve yüksek miktarlarda enerji uygulamak gerekmektedir. Bu yöntem aynı zamanda fiziksel üretim yöntemi olarak adlandırılmanın yanı sıra mekanik, yüksek enerji, ısı ve kimyasal işlemler ve doğal yöntemler şeklinde de adlandırılmaktadır (Wolfgang 2004).

Top Down yöntemi, elektro patlama, mekanik aşındırma, dağlama, ısı (termik) yöntem, dönen soğuk yüzeyde katılaştırma, gaz atomizörü, yüksek enerji, litografi, yüksek ultraviyole gibi yöntemler sonrası elde edilmektedir (Hosokawa 2007).

2.5.2. Aşağıdan Yukarıya Doğru (Bottom Up)

Parçaların birleştirilmesi işlemi şeklinde ifade edilen Aşağıdan Yukarıya Doğru (Bottom Up) üretim yönteminde, nano boyuttaki nano yapılara ulaşmak için atom ve molekül yapılarının üzerinde işlemler yapılır. Yeni nanomalzeme elde etmek için nano boyuttaki yapıların atom ve molekül yapıları kimyasal reaksiyona tabi tutulur (Wolfgang 2004).

Genelde doğal haldeki malzemeler için kullanılan bu üretim yönteminde nanomalzemelerin diğer üretim yöntemlerine göre çok daha düşük bir maliyetle edilmesi mümkün olmaktadır. Doğadaki örnek sayısı oldukça fazla olan bu üretim yönteminin kimya ve biyoloji alanlarındaki faaliyetler şeklinde görülmektedir. Aşağıdan Yukarıya Doğru (Bottom Up) üretim metodunun oluş ve davranış şeklinin

laboratuvardaki ortamdan üretilecek tarafa yönlendirilmesi çok daha kolay gerçekleşmektedir.

Aşağıdan yukarıya olan üretim yöntemleri aşağıdaki üretim yöntemlerini kullanmaktadır;

- Asal gaz yoğunlaştırma,
- Alev sentezi,
- Kimyasal buhar biriktirme,
- Moleküler huzme,
- Atom çökmesi,
- Yanma,
- Kimyasal sentez,
- Elektro-patlama,
- Lazer tedavisi,
- Sol-jel
- Sprey ayırma z (Hosokawa 2007).

2.6. Nanolifler ve uygulama alanları

Nanolifler, çapı 1 ile 100 nanometre aralığında olan lifler olarak tanımlanmaktadır. Nanolifler, ilaç ve gen dağıtımı, hücre ve kanser tedavisi, doku mühendisliği ve rejeneratif tıp gibi çeşitli biyomedikal uygulamalarda yaygın olarak kullanılmaktadır. Nanolifler, geniş yüzey alanına ve esnekliğe sahip, yüksek porozite, küçük gözenek boyutları, aksenal mukavemet, kuantum hapsetme etkileri ile geniş ve farklı uygulama alanlarında kendisine yer bulmuştur (Ramalingam ve Ramakrishna 2017).

En fazla bir mikron çapa sahip, polimer ya da seramikler kullanılarak mikrometre altı boyutlarda üretimi yapılan nanoliflerin çap aralığı mikrometre ile nanometre arasında değişmektedir. Nanoliflerin diğer 1D yapılara kıyasla kolay bir şekilde üretilebilmeleri mümkün olduğundan, diğer yapılara nazaran çeşitli uygulamalarda yüksek verim elde edilerek kullanılabilir. Çekme kalıp, faz ayrılması, kendi kendine oluşum ve elektroçirime gibi yöntemlerin uygulanması ile polimer, metal, seramik tabanlı lifler üretilebilmektedir (Yalçın 2020).

Yüksek moleküler oryantasyona sahip olan nanolifler boyutlarının küçük olmasından dolayı taşıdığı yapısal kusurlar daha azdır, bunun sonucunda daha iyi mekanik özelliklere, çaplarının küçük olması nedeniyle yüksek yüzey/hacim oranlarına veya yüksek yüzey/kütle oranlarının yanı sıra yüksek yüzey alanına sahiplerdir (Kut ve Güneşoğlu 2005).

Nanofiberlerden meydana getirilen yapıların, yüksek yüzey alan özelliği, mukavemet, ağırlık gibi özellikleri, birçok malzemeyle karma bir şekilde uygulamaları, filtrasyon membran yapımından doku mühendisliğine, savunma sanayinden ve biyomedikal malzemelere kadar birçok sektörde kullanılmasının önemli nedenlerindedir. Nanofiberler ile güçlendirilen kompozit malzemeler birçok alanda araştırmacılar için yol gösterici olmaktadır (Keskinates 2017).

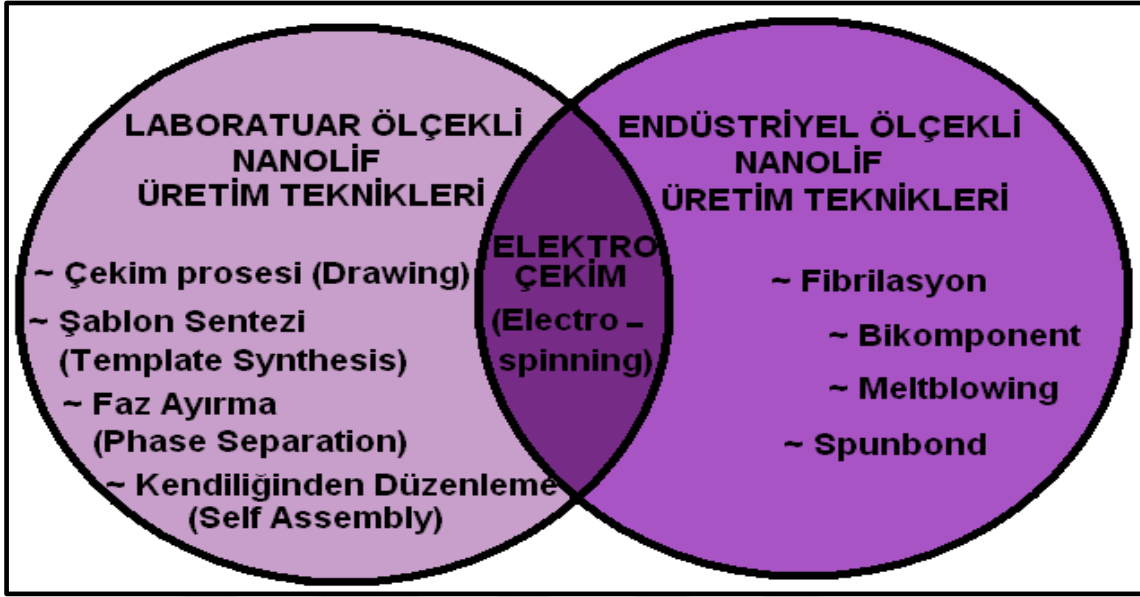
Nanoliflerin Avantajları (İnt. Kyn. 5);

- Spesifik yüzey alanına (yüzey alanı/birim kütle), yüksek uzunluk/çap oranına, biyolojik (biomimicking) taklit potansiyeline ve yüksek mekanik özellikler ile esnekliğe sahip olmaları,
- Mikroorganizma ve küçük parçacık geçişlerine karşı iyi bir bariyer olmaları,
- Birim ağırlığında yüksek mukavemet göstermeleri,
- Nano boyutlardaki bileşenlerin çok yüksek yüzey alanına sahip olmaları ve yüksek nem veya buhar geçiş oranı sağlamaları,
- Direkt yüzey kaplamalarında fonksiyonel davranışlar sergilemeleri,
- Kimyasal bileşimi değiştirilmeden, nanometre ölçülerinde maddenin; erime sıcaklığının, mıknatıslanmasının, şarj kapasitesinin değiştirilebilmesi,
- Biyolojik sistemlerde yeni tür yaratılabilmesi
- Nano ölçülerde, düşük yüzey gerilimi ve yerel elektromanyetik etki sonucu nano yapı malzemelerin daha dayanıklı yapılabilmesi,

2.6.1. Nanolif Üretim Yöntemleri

Nanoliflerin üretimi için farklı teknik mevcut olup bunlardan bir kısmı laboratuvar ölçekteki üretim teknikleri bir kısmı da endüstriyel ölçekli nanolif üretim teknikleridir.

Şekil 2.4'te laboratuvar ve endüstriyel ölçekteki üretim teknikleri gösterilmiştir.



Şekil 2.4 Nanolif Üretim Teknikleri

- Günümüzde nanolif üretiminde kullanılan yöntemler;
- Melt blowing
- Santrifüj elektro çekim
- Bikomponent
- Fibrilasyon,
- Elektro çekim (electrospinning).

2.6.1.1. Çekim prosesi (Drawing)

Çekim; kimyasal liflerin üretimi için kullanılan metotlarından birisi olan kuru çekim yönteminin moleküler seviyede uygulaması olarak tanımlanmaktadır. Bu yöntemle 2-100 nm ölçülerinde lif çaplarına sahip nanolif üretiminin gerçekleştirilmesi ve tek tek ve uzun nanoliflerin elde edilmesi mümkündür (Şenol vd. 2005).

2.6.1.2. Şablon Sentezi (Template synthesis)

Bu yöntemle, bir şablon veya kalıp aracılığıyla 3-15 nm ölçüleri arasında nanoliflerin

üretimi gerçekleştirilebilmektedir. Proseste, fibril veya tüp şeklindeki nanoliflerin üretiminde, nano gözeneğe sahip bir membran şablon olarak kullanılmaktadır (Şenol vd. 2005). Şablon sentezi yöntemi ile, elektrik iletkenliğine sahip çeşitli hammaddelerden tüp ve fibriller elde etmek mümkündür. Bu yöntem ile kullanılarak sürekli ve tek tek nanolifler elde etmek mümkün değildir. Farklı şablonların kullanılmasıyla farklı çaplara sahip nanolifler elde edilebilmektedir. Klasik polimerlerin nanolif yapıya sahip olmaları ile sınırlı olup laboratuvar ölçeğinde bir tekniktir (Hatiboğlu 2006).

2.6.1.3. Faz Ayırma (Phase separation)

Faz ayırma, sentetik veya doğal olarak oluşan malzemelere uygulanabilen basit bir tekniktir. Faz ayrımının altında yatan ilke, iki veya daha fazla polimerin farklı çözünürlüklerinin kullanılmasını içerir, böylece bunlar kendi çözücülerine ayrılır. Ayrılan polimer, bir mandrel çevresinde oluşturulabilir, böylece bir vasküler aşı görevi görebilen boru şeklinde bir yapı oluşturulur. Termal olarak indüklenen faz ayrımı (TIPS), polimer çözücünden ayrılırken sıcaklığın düşürülmesini içerirken, difüzyonla indüklenen faz ayrımı (DIPS), polimer solventi süzmek için bir antisolvent banyosuna batırmayı içerir. Faz ayrımı, hem hücre infiltrasyonunu hem de damar mekaniğini etkiledikleri için vasküler greft başarısı için kritik faktörler olan iskele kalınlığı ve gözenekliliği üzerinde ek kontrol sağlar (Hatiboğlu 2006).


2.6.1.4. Kendiliğinden Düzenlenme (Self assembly)

Küçük moleküllerden basit blokların kurulması ile nano ölçekte lif elde edilmesi esasına dayanmaktadır. Bu yöntemin kullanımıyla, üretilen liflere ait çap değerleri 7-100 nm arasında değişmektedir (İnt. Kyn. 6). Bu teknikte, insan müdahalesine gereksinim duymadan komponentler istenilen şekil ve yapılarda otonom bir şekilde organize olmaktadır. Kendiliğinden düzenlenme tekniği standart laboratuvar ekipmanlarına ihtiyaç duyar. Kendiliğinden düzenlenme tekniği, fazla zaman alan bir teknik olup yalnızca polimer olan belirli malzemeleri nanolif olarak dönüştürebilen, laboratuvar ölçeği ile sınırlı bir yöntemdir (Hatiboğlu 2006).

2.6.1.5. Meltblowing Yöntemi ile Nanolif Üretimi

Meltblown ile üretim yöntemi, küçük çaplara sahip liflerin üretimi maksadıyla yaygın

olarak kullanılan bir yöntemdir. Meltblown yöntemi ile nanolif üretim tekniğinde yüksek hızlı sıcak havayla filamentler düzelerden fibrilli bir tülbent oluşturmak üzere çekim işlemine tabi tutulurlar. Polimer ile olarak ekstrüderden daha sonra da pompa vasıtasıyla filtrelerden geçerek üretilecek bölgede homojen bir karışım sağlanması için iletilir. Düzeden geçerken çok yüksek basınçta sıcak bir şekilde hava verilerek ortaya çıkan filamentler incelenerek hareketli banda, soğutma işlemi müteakip kalender silindirden sarıcıya sarılırlar (Bakınız Şekil 2.5). Meltblowing Yönteminin avantajı düşük gramaja sahip olması ve üretilen fiberlerin çaplarının doğru orantılı olmasıdır (Şeyda 2007).



Şekil 2.5 Meltblowing yöntemi ile üretilen lifler

2.6.1.6. Fibrilasyon Yöntemi

Selülozik liflerin çok ince lifler halinde fibrilasyon işlemi ile nanofiber üretim yöntemidir. Zaman alıcı bir süreçte, çözünme, jelleşme ve farklı çözücülerin kullanılması ile üretim, dondurma ve nano gözenekli köpük oluşturacak biçimde kurutmayı içermektedir. Fibrilasyon Yöntemi ile üretilen fiberler orta düzeyde mukavemet özelliklerine sahiptir (Şenol vd. 2005).

Fibrilasyon işlemine tabi tutularak selülozik liflerden ince, hidrofilye ve mikro gözenekli yapıda elde edilen yüzeyler, mikrobiyolojik alanda, filtrelerin üretiminde, kağıt yapımında kullanılmaktadırlar (Yener 2010).

2.6.1.7. Bikomponent Yöntemi ile Nanolif Üretimi

Bikomponent yöntemi, iki polimerin aynı düzeden püskürtülmesi ile iki polimeri de içeren bir filament üretimi şeklinde tanımlanabilir (Hatiboğlu 2006). Kompozit, konjuge ve hetero lifler olarak da bilinen bikomponent lifler, lif uzunluğu boyunca iki malzemenin gereksinimlerinin tek bir lifte karşılanması amacıyla tasarlanmıştır. Bu yöntem ile nihai kullanım yerine göre, uygun kesit seçiminin yapılmasıyla özel liflerin üretimi mümkündür. İki polimer bileşene ait viskozite, soğutma oranı ve yüzey gerilimi bikomponent liflerin elde edilmesi ve özellikleri için kritiktir. İstenilen lif kesitini elde etmek için her bir komponente ait viskozitelerin benzer olması gerekmektedir. Soğutma oranı; her bir komponentin oryantasyonunu, yüzey gerilimi; iki komponentin adhezyonunu ile son lif kesit yüzeyini belirlemektedir (Dasdemir vd. 2012).

2.6.1.8. Spunbond


Meltblowing yöntemine teknik olarak çok benzeyen Spunbond yönteminin farkı, filamentlerin inceltmesi amacıyla kullanılan havanın hacmi ve sıcaklığı ile alakalıdır. İki yöntem arasındaki bu fark, elde edilen liflerin fiziksel özelliklerini de doğrudan etkiler. Meltblowing tekniğinde yüksek miktarda hava kullanılarak, hava akımı ile lifler gerdirilip inceltilmekte, Spunbond yönteminde ise polimerin soğuması ve katılaştıktan sonra germe uygulanmasıdır. Elde edilen liflerin kalın olmasının nedeni, üretimleri sırasında liflere bir germenin etki etmemesidir. Meltblown yöntemi ile elde edilen liflerde liflerin çap ölçüleri 2 mikronu geçmezken, spunbond yöntemi ile elde edilen liflerde bu ölçüler 20 mikrona kadar çıkabilmektedir (Süpüren vd. 2007b).

2.6.1.9. Elektrolif Çekim Yöntemi (Electrospinning)


Elektrolif Çekim Yöntemi (Electrospinning) yöntemi akışkanlar dinamiği, polimer kimyası, temel fizik, elektrik fiziği, makine ve tekstil mühendisliği gibi birçok disiplini içeren multi disiplinler bir yöntem olarak bilinmektedir. Elektrolif Çekim Yöntemi, minimum ekipmana ihtiyaç duyması, oldukça ince lif çaplarının oluşumuna imkân vermesi ve farklı polimerler ile çalışılabilmesi gibi avantajlara sahip nanolif üretim yöntemidir. Belli akışkanlık ve düşük debilerde sıvılara kilovolt boyutlarında voltaj uygulanması ile akışkan sıvıyı nano ölçeklerde liflere dönüştürme işlemi elektrolif

çekim olarak tanımlanmaktadır. Polimer esaslı nanoliflerin üretimi için polimer çözeltisi veya polimer eriyiği kullanılmaktadır. Belirli bir debi ile enjektörün uç kısmına gelen çözelti, yüzey gerilimi etkisiyle küresel bir damlacık oluşturmaktadır. Daha sonra elektriksel kuvvetlerin etkisi ile konik (Taylor konisi) şeklini alarak belli bir mesafede bulunan topraklanmış toplayıcıya nanolif olarak ulaştırılmaktadır. Eriyik kullanılan üretim sistemlerinden nanolif elde edilmesi için sistem basit bir şekilde kurulamazken, çözelti kullanılan elektro üretim sistemleri ise basit olarak kurulabilmektedir. Çünkü polimer granüllerin, akışkan hale gelebilmeleri için uygun viskozitede sıcaklık yoluyla eritilmiş olmaları gerekmektedir (Beypazar 2013).

Bu yöntem fazla bir maliyeti olmayan, ucuz bir yöntem olup, diğer üretim yöntemlerinden farkı bir boyutlu (1D) nano yapıların istenilen uzunluk ve kolaylıkla elde edilebilmesini sağlamaktadır. Nanolif üretim hızının yüksek olduğu bu yöntemde liflerin üretimi esnasında lif çapının kontrolü mümkün olabilmektedir. Elektrolif Çekim Yöntemi ile üretilen lifler oldukça karmaşık yüzeylere kaplanabilmektedirler. Çeşitli polimerlere uygulanabilen Elektrolif Çekim Yöntemi (Bakınız Şekil 2.6) ile elde edilen fiberler, nano boyutlara ve yüksek yüzey alanına sahiptirler (Esfahani vd. 2017).



Şekil 2.6 Elektrosinning düzeneğinde liflerin oluşumu



Şekil 2.7 Elektrosinning deney düzeneği

Elektro çekim yöntemi (Şekil 2.7) kullanılarak elde edilen nano lifler yaygın olarak ilaçların kapsüllenmesi, izolasyon, membran üretimi, kontrollü yapışma ve salınma, elektro-manyetik sistemler, medikal ürün alanlarında kullanılmaktadır.

2.7. Elektrosinning Yöntemini Etkileyen Parametreler

Ucuz ve basit şekilde nanolif üretimi sağlanabilen elektro çekim yöntemi, kontrol edilmesi açısından oldukça güç bir prosestir. Bu prosese etki eden parametreler; çözelti Parametreleri, İşlem Parametreleri ve Ortam Parametreleri olarak incelemek mümkündür (Cengiz vd. 2006).

2.7.1. Çözelti parametreleri

Proses ve oluşan liflerin morfolojisine etki eden en önemli parametre polimer çözeltisinin özellikleridir. Çözelti konsantrasyonu lifin yüzeyinde çoklukla rastlanılan boncuklu yapının oluşmasında önemli bir rol oynamaktadır. Çözeltinin viskozitesi ve elektriksel gerilim de lif çaplarının yapısı üzerinde etkilidirler (Ramakrishna vd. 2005).

2.7.1.1. Konsantrasyon

Elektrosinning yöntemi ile lif elde edilmesini etkileyen önemli parametrelerden biri de polimer çözeltisine ait konsantrasyondur. Çözelti konsantrasyonunun çok düşük, uygun

değerin altında, uygun değerde ve uygun değer üzerinde olmasına göre etkisi değerlendirilmektedir. Çok düşük konsantrasyonda polimerik mikro (nano) partiküller, uygun değer altında olan konsantrasyonda boncuklu ve lifli karışık bir yapı, uygun konsantrasyon değerinde düzgün nanolifler elde edilebilirken uygun değer üzerinde olan konsantrasyonlarda ise nanolif yerine heliks şekilli mikro şeritler oluşmaktadır (Li, ve Wang 2013). Konsantrasyon artışı ile lif çapı arttığından düşük konsantrasyonlardaki boncuklu yapıdan ve yüksek konsantrasyonlardaki büyük çaplı lif oluşumundan kaçınmak amacıyla uygun konsantrasyon belirlenmelidir (Bhardwaj ve Kundu 2010).

2.7.1.2. Moleküler ağırlık

Elektrospinning yöntemi ile lif elde etmek için çözelti oluşturulurken kullanılan polimere ait molekül ağırlığı lif oluşumunda etkili olmaktadır. Polimerin molekül ağırlığının artmasıyla yapısındaki uzun polimer zincirleri çözeltinin viskozitesine etki etmektedir. Düşük molekül ağırlıklı çözeltilerde molekül ağırlığı arttıkça fiberin yapısında boncuklu yapı kalmayacak, pürüzsüzleşecektir. Molekül ağırlığının daha da artması ile mikro şeritli yapılar oluşacaktır (Koski vd. 2004).

2.7.1.3. Viskozite

Bir akışkanın akmaya karşı gösterdiği direncin ölçüsü viskozite olarak tanımlanmaktadır. Elektrospinning yöntemine uygun viskozitede çözeltinin hazırlanmalıdır. Düşük viskozitede, lif morfolojisinde yüzey gerilimi baskındır. Çok düşük viskoziteye sahip çözeltilerde lif oluşumu gözlemlenmezken, lifler yerine damlacıklar oluşur, viskozitenin çok yüksek olması ise iğnenin ucunun tıkanmasına ve üretimin gerçekleşmemesine neden olmaktadır (Lim vd. 2010).

2.7.1.4. Yüzey Gerilimi

Bir sıvının yüzeyinde esnek bir tabaka gibi davranışlar göstermesiyle ortaya çıkan etki olarak tanımlanan yüzey gerilimi önemli bir faktör olarak değerlendirilmektedir. Serbest çözücü moleküllerinin konsantrasyonu yüzey gerilimi etkisi ile olarak yüksek olduğunda, çözücü moleküller eğilimi bir araya toplanma ve küresel bir şekle dönüşme

yönünde artacak, polimer jetinin toplayıcı plakaya doğru ilerlemesiyle yüzey gerilimi jet boyunca boncukların oluşmasını sağlayacaktır. Çözücü ile polimer molekülleri arasındaki daha fazla etkileşim yüksek viskozite manasına gelmektedir. Bu durumda yüklerin etkisiyle çözeltilinin gerilmesi, çözücü moleküllerinin karmaşık polimer moleküllerine yayılmasını ve yüzey geriliminin etkisiyle çözücü moleküllerinin bir araya toplanma eğiliminin azalmasını sağlayacaktır (Ramakrishna vd. 2005).

2.7.2. Proses parametreleri

Elektro çekim prosesini etkileyen önemli parametreden birisi de polimer jeti üzerinde etkisi olan dış etkenlerdir. Bu dış etkenler; polimer çözeltilisine uygulanan voltaj, akış hızı, çözeltilinin sıcaklığı, toplayıcının tipi ve çapı ile düze-toplayıcı arasındaki mesafe olarak bilinmektedir (Ramakrishna vd. 2005).

2.7.2.1. Voltaj

Polimer çözeltilisine uygulanan voltaj elektrospinning prosesinde en önemli parametredir. Liflerin elde edilmesi için bir voltaj değerine ihtiyaç duyulmaktadır. Çözeltilinin elektriksel olarak yüklenmesi, toplayıcı levhaya doğru jet şeklinde ilerlemesi ve elektrostatik kuvvetlerin oluşması uygulanan yüksek voltaj ile sağlanmaktadır. Uygulanan bu voltajın lif çaplarında ve elde edilen elektrik alan üzerinde etkisi büyüktür. Yüksek voltaj uygulanması, daha fazla miktarda yük polimer jetinin ivme kazanmasına, elektrik alanının artmasına ve jetin daha çok gerilmesine neden olacak, lif çapının azalmasıyla aynı zamanda çözücünün hızlı bir şekilde buharlaşmasına neden olarak daha kuru liflerin elde edilmesi sağlanacaktır (Deitzel vd. 2001)

2.7.2.2. Akış Hızı

Elektrospinning prosesine etki eden parametreler bir diğeri de şırınga içerisinde bulunan çözeltilinin pompalama ünitesinden nozüle doğru akış hızıdır. Birim zamanda çözeltiliden life dönüşen miktarın belirlemede akış hızı önemli bir rol oynamaktadır. Düşük akış hızı kullanılması ile polimer çözeltilisinin yüklü hale gelebilmesi için yeterli zaman elde edilecek, akış hızının yüksek kullanılması durumunda ise polimer çözeltilisinin tam yüklü hale olmamasından dolayı boncuklanma görülen çapı daha kalın fiber yapılar meydana

gelecektir (Buchko vd. 1999).

2.7.2.3. Toplayıcı

Elektrospinning yönteminde toplayıcı, fiberlerin birikmesiyle oluşan tabakayı ifade etmektedir. Hareketli ve sabit olarak mevcut olan toplayıcılara ait levhalarının, liflerin yapısına olan etkisi yapılan çalışmalarda görülmektedir. Alüminyum folyolar, en geniş kullanılan toplayıcı levhalar olmakla birlikte, metal ızgara, dönen tambur ve dönen ızgaralarda gibi toplayıcı tipleri bulunmaktadır (Dörtler 2018).

Toplayıcı plakaların, nanoliflerin elde edilmesinde ve diziliminde son yapı üzerinde önemli bir etkisi bulunmaktadır. Toplayıcı plakada farklı sistemlerin oluşturulması; paralel olarak dizilmiş liflerin elde edilmesi, liflerde kristalinite ve mukavemet artışının sağlanması, liflerin daha hızlı ve farklı yapılarda eş zamanlı üretilmesi, daha geniş bir alanda liflerin toplanması gibi nedenlere dayanmaktadır (İpek vd. 2017).

2.7.2.4. Toplayıcı Plaka ile Şırınga Ucu Arasındaki Mesafe

Toplayıcı plaka ile şırınga ucunun arasındaki mesafe Elektrospinning işlemine etki eden diğer faktörlerden biridir. Toplayıcı plaka ile şırınga ucunun arasındaki mesafe, çözeltinin jet oluşturacağı şekilde ayarlanmalı ve çözücünün buharlaştırılarak uzaklaşmasını sağlamalıdır (Bhardwaj ve Kundu 2010). Toplayıcı ve nozül arasındaki mesafenin çok kısa tutulması, fiberin toplayıcıya ulaştıktan sonra kurumak için çok zamanı kalmayacağından kalın ve birbirine yapışık halde fiber görüntülerinin elde edilmesine, toplayıcı ile nozül arasındaki mesafenin çok uzun tutulması, fiberin yapılarında boncuklanma görülmesine neden olabilecektir. Toplayıcı ile nozül arasındaki mesafenin kullanılan çözelti için optimum değerde ayarlanması gereklidir (Yuan vd. 2004).

2.8. Yapay Sinir Ağları

Yapay zekâ, bir bilgisayar ya da bilgisayar tarafından desteklenen bir makinenin, genel olarak insana özgü niteliklerin, çözüm yaratma, anlama, anlam çıkartma, genelleme ve önceki tecrübelerinden öğrenme gibi yüksek mantık süreçlerine ilişkin görevleri

gerçekleştirme yeteneği olarak ifade edilmektedir (Nabiyev 2012). Yapay zekanın alt bileşenlerinden olan Yapay Sinir Ağları (YSA), insan beyninin çalışma prensiplerinden esinlenerek öğrenme yoluyla yeni bilgilerin elde edilmesi, yaratma ve keşfedebilme gibi yetenekleri ile başka bir desteğe ihtiyaç duymadan otomatik olarak üretmek için geliştirilen bilgisayar sistemleri olarak nitelendirilmektedir (Öztemel 2012).

YSA, sayısal bilgilere çalışma, bilgi saklama, bilgiyi kullanarak öğrenme ve görmediği örnekler hakkında bilgi üretme, sınıflandırma ve şekil tamamlama gibi niteliklere sahiptir. YSA'ların, günümüzde finanstan, pazarlamaya ve çeşitli mühendislik alanlarına kadar geniş bir kullanım yeri bulunmaktadır (Ağyar 2015).

Genel olarak sınıflandırma, modelleme ve tahmin uygulamalarında kullanılan YSA'lar ayrıca; çok boyutlu, gürültülü, karmaşık, kesinliği olmayan, eksik, hatalı ve hata olasılığı yüksek sensor verilerinin olduğu ve problem çözümü için matematiksel modellerin ve algoritmaların bulunmadığı, yalnızca örneklerin mevcut olduğu durumlarda geniş bir kullanım alanına sahip olduğu görülmektedir. YSA'nın temel özellikleri aşağıdaki gibi sıralanabilir (Öztemel 2012);

- Temel işlevi bilgisayarlar öğrenmesini sağlamak olan YSA'lar, olayları öğrenerek benzer durumlar karşısında mantıklı karar üretmeye çalışırlar.
- Örneklerin kullanılmasıyla öğrenen YSA'nın olayları öğrenerek doğru tahminde bulunabilmesi için o olayla alakalı örnekler belirlenmelidir. YSA'lar bu örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe ulaşırlar.
- YSA'nın kullanılması için veriler eğitim ve test kümesi olarak ayrılıp eğitilmesi ve test edilmesi gerekmektedir. Eğitim için ayrılan eğitim kümesi ile ağın eğitimi sağlanır. Ağın bütün örneklerle doğru yanıtlar vermeye başlamasıyla eğitim işinin tamamlandığı anlaşılmış olur. Ağ, eğer test kümesinde bulunan verilere kabul edilebilir sınırın üstünde doğru cevaplar veriyorsa ağın performansının iyi olduğu kabul edilir ve kullanıma alınır.
- YSA'lar görülmemiş örneklere ilişkin bilgi üretebilir, algılamaya yönelik olaylarda kullanılabilir, ilişkilendirme ve sınıflandırma yapabilirler.
- Eksik bilgi ile çalışabilirler.
- Kendi kendini organize ederler, öğrenebilme kabiliyetleri bulunmaktadır.

- Eksik bilgiyle çalışabilme yetenekleri, hata toleranslarının olduğunu gösterir.
- Bir hatanın ortaya çıkması ile ağın büyük bir hata ile birden bozulmaması dereceli bozulma göstergesidir.
- YSA'da bilgiler ağa dağılmış halde tutulur. Ağ bilgisine karşılık olarak hücrelerin bağlantı ve ağırlık dereceleri geldiği için tek bir bağlantı çoğunlukla kullanılmamaktadır.
- Sadece sayısal bilgi ile çalışırlar.

Yapay Sinir Ağının sakıncaları aşağıdaki gibidir:

- Ağın yapısı genel olarak deneme-yanılma yöntemi ile belirlendiğinden, bu işlemin uzun sürmesi sebebiyle ortaya çıkan probleme göre bir ağ yapısı bulmak zordur.
- Problem için uygun olan bir ağ yapısı seçilemezse, çözüme ulaşamama veya düşük performanslı çözümlerle karşılaşmak mümkündür. Diğer bir taraftan ulaşılan çözümün en iyi çözüm olduğu garanti değildir.
- Bazı ağlarda, ağın parametre değerlerinin kullanıcı tecrübesine bağlı olması, bir kurala göre belirlenmediğinden çözüme ulaşmada sorunlar yaşanabilmektedir.
- YSA'ların çalışabilmesi için sadece sayısal veriler kullanıldığından problem sayısal değerlere çevrilmelidir.
- Ağın eğitim süresinin bitirileceği zaman net değildir.
- Eğitim sonrasında elde edilen hata toleransının belirli bir değer altında olması eğitim sürecinin yeterli olduğunu gösterir (Elmas 2004).

2.8.1. Yapay Sinir Ağları Tarihi

Yapay Sinir Ağı modeli ilk olarak 1943 yılında Warren McCulloch ve Walter Pitts tarafından yapılan bir makale ile ifade edilmiştir (İnt. Kyn. 7).

1949 yılında Hebb, tarafından geliştirilen Hebbian öğrenme kuralı, YSA'nın bağlantı sayısının değiştirilmesi ile öğrenmenin gerçekleşebileceğinin öngörmektedir (Öztemel 2015).

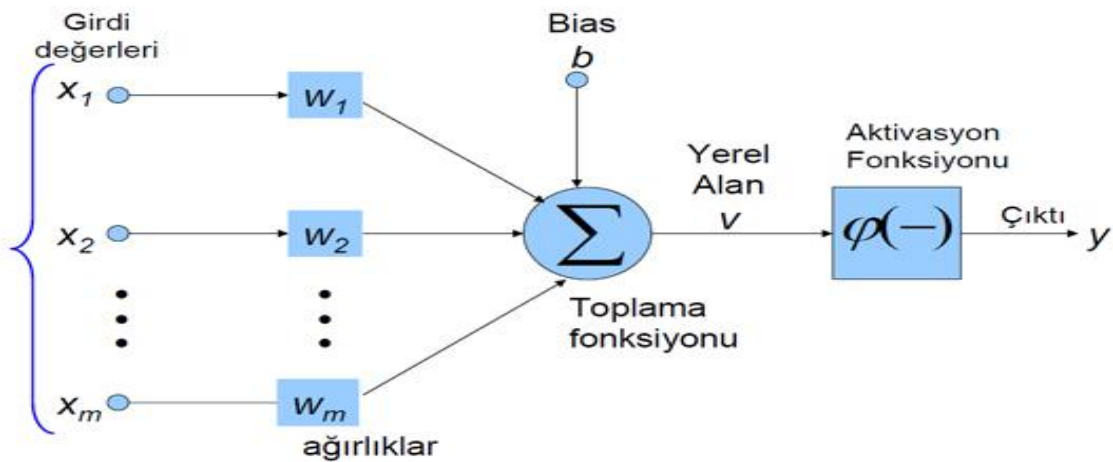
Rosenblatt (1958) tarafından Perceptron (algılayıcı), örüntü (şekil) tanıma maksadıyla

geliştirilmiş olan tek katmandan oluşan, eğitilebilen ve tek çıkışa sahip olan bir yapay sinir ağı, YSA alanındaki çalışmaları hızlandırmıştır. YSA çalışmalarında devrim niteliğinde bir gelişme olan çok katmanlı sinir ağlarının temelini oluşturması açısından Perceptron'un geliştirilmesi tarihi bir önem taşımaktadır (Yücesoy 2011).

YSA'nın mühendislik uygulamaları için başlangıcı 1959 yılında Bernard Widrow ve Marcian Hoff tarafından geliştirilen ADALINE (Adaptive Linear Neuron) modeli kabul edilmiştir. ADALINE'nin gerçek dünya problemlerine uygulanması ile ilk YSA olma özelliğini kazanmıştır. 1970'lerin sonlarına doğru Fukushima, şekil ve örüntü tanıma amaçlı geliştirilen NEOCOGNITRON modelini tanıtmıştır. 1982-1984 yılları arasında Hopfield'ın yapmış olduğu çalışmalar YSA'nın genelleştirilebileceğinin ve çözümü zor problemlere çözüm üretebileceğinin göstergesi olmuştur. Bunun neticesinde, Hinton ve ekibinin geliştirmiş olduğu Boltzman Makinesi'nin doğmasına sebep olmuştur. 1988 yılında, Broomhead ve Lowe özellikle filtreleme konusundaki başarılı sonuçlara ulaştıkları radyal tabanlı fonksiyonlar modelini (Radial Basis Functions RBF) geliştirmişler (Elmas 2012).

2.8.2. Yapay Sinir Ağları Mimarisi

YSA'lar yapay sinir hücrelerinden oluşmaktadır. Yapısal olarak bir yapay sinir hücresi biyolojik sinir hücrelerinden esinlenerek oluşturulmuştur. Girdiler, ağırlıklar, toplama ve aktivasyon fonksiyonu ile çıkışlar biyolojik sinir hücresini oluşturmaktadır (Bakınız Şekil 2.8).



Şekil 2.8 Yapay Sinir Hücresi

Girdiler (X_1, X_2, \dots, X_m): Bir yapay sinir hücresine çevreden gelen bilgiler girdilerdir. Bu bilgiler giriş olarak yapay sinir hücrelerine gönderilmektedir.

Ağırlıklar (W_1, W_2, \dots, W_3), yapay sinir hücresine gönderilen girdilerin sinir üzerindeki etkisini belirleyen katsayılar ağırlıklardır. Her bir girdinin kendisine ait ağırlığı bulunmaktadır (Çuhadar 2006).

Toplam Fonksiyonu: Bu fonksiyon ile bir hücreye gelen net girdi hesaplanmaktadır. Geniş bir alanda kullanılan, ağırlıklı toplamı bulma fonksiyonunda, basit bir yapıya sahip girdi değerleri ve ağırlıklarının çarpımı toplanarak bir aktivasyon fonksiyonuna gönderilmekte ve sonuç elde edilmektedir. Formülasyonu Denklem’de yer almaktadır.

$$NET = \sum_i^n X_i W_i$$

Bu denklemde X girdileri, W ağırlık değerini, n ise bir hücreye gelen toplam girdi sayısını ifade etmektedir. Literatürde karşılaşılan toplama fonksiyonu türleri fonksiyonları Çizelge 2.2’deki gibidir.

Çizelge 2.2 Toplama Fonksiyonu Türleri

Net Giriş	Açıklama
Çarpım $NET = \prod_i G_i A_i$	Ağırlık değerleri girdilerle çarpılmasıyla bulunan değerlerin birbirleri ile çarpılması ile NET girdi hesaplanmaktadır.
Maksimum $NET = \text{Max}(G_i A_i)_{i = 1 \dots N}$	N adet girdi içinden ağırlıklar ile çarpılıp en büyük olan yapay sinir hücresinin NET girdisi olarak girdisi ortaya çıkmaktadır..
Minimum $NET = \text{Min}(G_i A_i)_{i = 1 \dots N}$	N adet girdi içinden ağırlıklar ile çarpılıp en küçüğü yapay sinir hücresinin NET girdisi olarak girdisi ortaya çıkmaktadır.

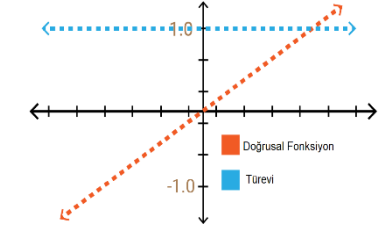
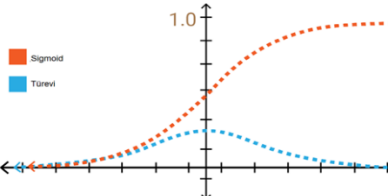
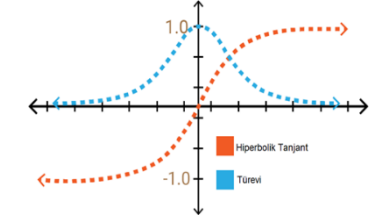
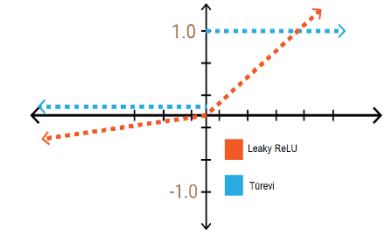
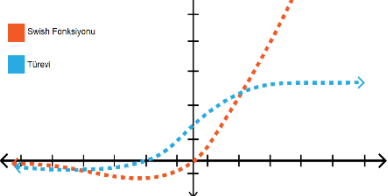
<p>Çoğunluk</p> $NET = \sum_i sng(G_i A_i)$	<p>N adet girdi içinden ağırlıklar ile çarpılıp pozitif ve negatif olanların sayısı bulunarak, büyük olan sayı hücrenin NET girdisi olarak kabul edilmektedir.</p>
<p>Tarihli Toplam</p> $NET = Net(Eski) + \sum G_i A_i$	<p>Hücreye gelen bilgiler ağırlıklı olarak toplanarak önceden gelen bilgilere eklenir. Bu şekilde hücrenin net girdisi bulunmaktadır.</p>

Aktivasyon fonksiyonu; Sinir düğümlerine ulaşan giriş sinyallerini işleyerek nöronun çıkış sinyallerini belirleyen, verilerin yapılarını öğrenerek anlamlı sonuçlar oluşturan ve transfer fonksiyonu olarak da adlandırılan fonksiyondur. YSA'da veri ve probleme göre çeşitli aktivasyon fonksiyonları kullanılmaktadır. Aktivasyon fonksiyonunda YSA'nın çoğu zaman doğrusal olmayışından dolayı çoğunlukla lineer olmayan bir fonksiyon seçilmektedir (Şenocak ve Kahveci 2016). Doğrusal fonksiyonların tercih edilmesindeki neden, girdinin çıktı ile doğru orantılı olmasından kaynaklanmaktadır. Bu durum ilk YSA denemelerinde başarısız sonuçların elde edilmesindeki en önemli nedenlerinden birisidir (Yücesoy 2011).

Toplama fonksiyonu ile elde edilen çıktı Aktivasyon Fonksiyonuna gönderir, kullanılan aktivasyon fonksiyonuna göre aldığı değeri bir algoritmayla genellikle [-1,1] veya [0,1] arasında olan gerçek bir çıktıya dönüştürür.

Çizelge 2.3'de literatürde en çok kullanılan transfer fonksiyonlarından Lineer Aktivasyon Fonksiyonu, Sigmoid Fonksiyonu, Hiperbolik Tanjant Fonksiyonu, Relu Fonksiyonu ve Swish fonksiyonu görülmektedir.

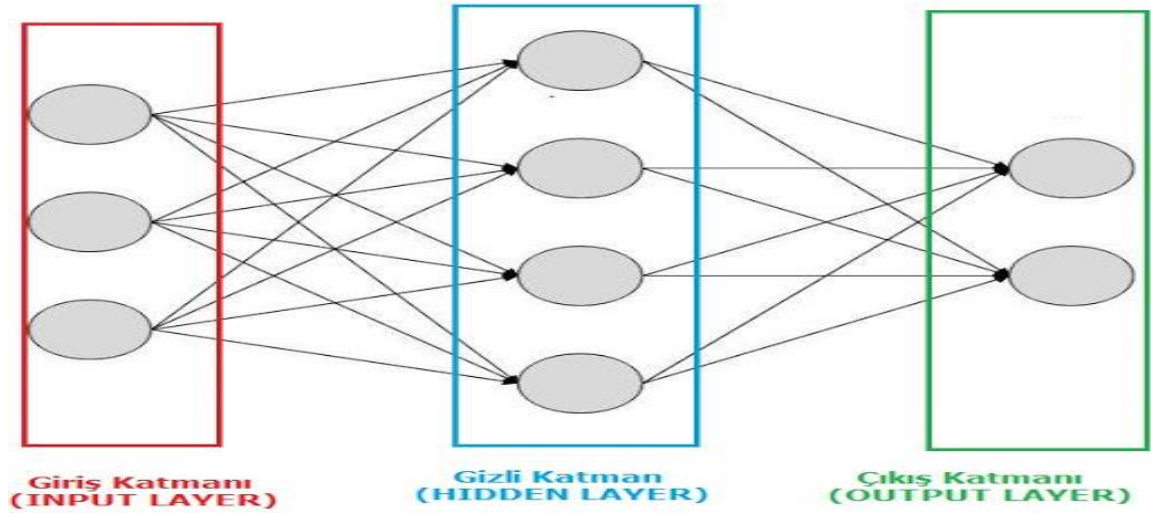
Çizelge 2.3 Transfer Fonksiyonları

Aktivasyon Fonksiyonları	Grafik [1]	Açıklaması
<p>Lineer aktivasyon fonksiyonu</p>		<p>$f(x) = x$ Aralık $(-\infty, \infty)$</p>
<p>Sigmoid Fonksiyonu</p>		<p>$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$ Aralık $(0,1)$</p>
<p>Hiperbolik Tanjant Fonksiyonu</p>		<p>$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ Aralık $(-1,1)$</p>
<p>ReLU (Rectified Linear Unit) Fonksiyonu</p>		<p>$f(x) = \begin{cases} 0 & \text{için } x < 0 \\ x & \text{için } x \geq 0 \end{cases}$ Aralık $[0, \infty)$</p>
<p>Swish (A Self-Gated/Kendinden Geçitli) Fonksiyonu</p>		<p>$f(x) = 2x\sigma(\beta x) \begin{cases} \beta = 0 & \text{için } f(x) = x \\ \beta \rightarrow \infty & \text{için } f(x) = 2\max(0, x) \end{cases}$ Aralık $(-\infty, \infty)$</p>

Transfer fonksiyonu ile elde edilen sonuç genel olarak işlem elemanının yani nöron'un çıktısıdır.

2.8.3. Yapay Sinir Ağlarının Yapısı

Giriş, Ara (Gizli) ve Çıkış Katmanı olarak üç ana katmanda izlenen YSA, yapay sinir hücrelerinin birbiri ile bağlanması sonucunda oluşan yapılardır. Ağa, girdi katmanı aracılığı ile iletilen bilgiler ara katmanlarda işlenir, işlenen bilgiler çıktı katmanına gönderilirler. Burada bilgi işlemede ifade edilen, ağa gelen bilgilerin ağa ait ağırlık değerlerinin kullanılmasıyla çıktıya dönüştürülmesi işlemidir. Ağırlıkların doğru değerlere sahip olması, ağın girdileri için doğru çıktıları üretebilmesinde çok önemlidir. Ağ, birden çok nöron ve gizli katmana sahipse çok katmanlı (multilayer), tek bir katmana sahipse tek katmanlı (single layer) olarak nitelendirilmektedir (İnt. Kyn. 8).



Şekil 2.9 Yapay Sinir Ağları Katmanları

2.8.3.1. Tek Katmanlı Ağ

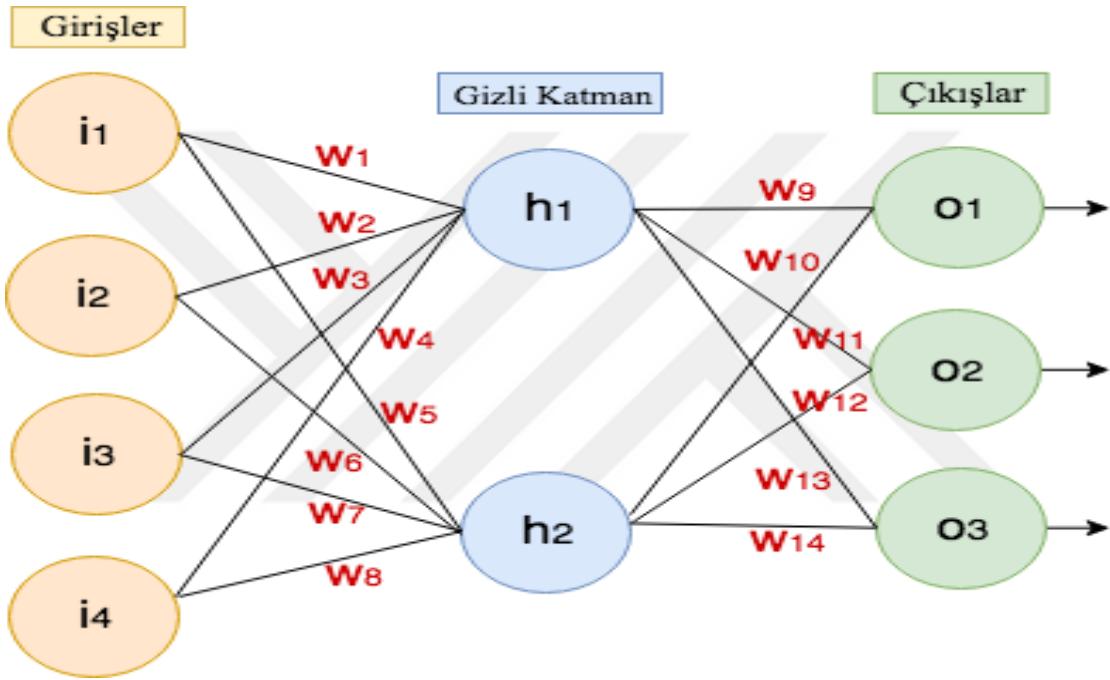
Tek katmanlı YSA'lar yalnızca girdi ve çıktı katmanlarından oluşmaktadır. Çıktı üniteleri bütün girdi ünitelerine (X) bağlanmakta ve her bağlantıya ait bir ağırlık (W) bulunmaktadır. Doğrusal olmayan problemlerde tercih edilmemektedir (İnt. Kyn. 9).



Şekil 2.10 Tek Katmanlı Ağ Modeli

2.8.3.2. Çok Katmanlı Yapay Sinir Ağları

Giriş katmanı ve çıkış katmanları ile gizli (hidden) katmanlarından oluşan çok katmanlı YSA'lar (Bakınız Şekil 2.11), karmaşık problemler için çözüm elde etmek amacıyla ve doğrusal olmayan problemlerde kullanılmaktadır. Birden çok girdi ve gizli katmana sahiptirler. Problemin akışına göre gizli katman sayısının artırılabilmesi veya azaltılabilmesi mümkündür. Gizli katmanlar, problem yapısına göre farklı fonksiyonlarla işlenerek çıktı katmanına iletilmesini sağlamaktadır (İnt. Kyn. 9).




Şekil 2.11 Çok Katmanlı YSA Modeli

2.8.3.3. İleri Beslemeli Yapay Sinir Ağları

YSA'lar, yapısal olarak, İleri Beslemeli (Feedforward) YSA'lar ve Geri Beslemeli (Feedback) YSA'lar olmak üzere iki ayrı şekilde sınıflandırılmışlardır. İleri beslemeli YSA'da (Şekil 2.12), hücreler katmanlar şeklinde düzenlenmiş, bir katmanda bulunan hücreye ait çıkışlar bir sonraki katmana ağırlıklar üzerinden giriş olarak verilmiştir. Çevreden elde edilen bilgiler, giriş katmanında herhangi bir değişikliğe uğratılmadan ara yani gizli katmandaki hücrelere iletilmektedir. Bilgi, ara ve çıkış katmanında işlenerek ağın çıkışı belirlenmektedir. İleri beslemeli YSA'lar sahip olduğu bu yapısı ile, doğrusal olmayan statik bir işlevi gerçekleştirmektedir. Bu tipteki YSA'ların


eğitiminde etkin olarak en çok bilinen algoritma olan ve şekil tanıma, sinyal işleme ve sınıflandırma gibi problemler uygulanan geriye yayılım öğrenme algoritması kullanılmaktadır. YSA'ya, örnekler ile örneklerden elde edilmesi gereken çıktılar yani beklenen çıktılar verilmektedir. Burada ağ problem uzayını temsil eden bir çözüm uzayı üretmek için kendisine verilen örnekleri kullanarak genellemeler yapar, gösterilen benzer örnekler için bu çözüm uzayı sonuçlar ve çözümler üretebilir (Öztemel 2012).



Şekil 2.12 İleri Beslemeli Yapay Sinir Ağları

2.8.3.4. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli YSA'da, en az bir hücreye ait çıkış kendisine veya diğer hücelere giriş olarak verilmekte, genel olarak geri besleme bir geciktirme elemanı üzerinden gerçekleştirilmektedir. Burada ortaya çıkan geri besleme, bir katman içinde yer alan hücreler arasında veya farklı katmanlar arasındaki hücrelerle olabilmektedir. Bu yapıyla doğrusal olmayan dinamik bir davranış gösteren geri beslemeli YSA'lar, geri beslemenin yapıldığı şekle göre farklı davranış ve yapılaraya sahip olabilmektedir. Şekil 2.13'de iki katmanlı, çıkış katmanlarından giriş katmanına doğru geri besleme yapabilen bir YSA yapısı gösterilmektedir (İnt. Kyn. 10).



Şekil 2.13 Geri Beslemeli Yapay Sinir Ağları

2.8.4. Yapay Sinir Ağının Eğitimi

Belirli bir probleme yönelik olarak bir ağın yapılandırılmasını müteakip ağın eğitim işlemine geçilir. Elde bulunan verilerin ağa sunulmasıyla ağın öğrenmesi sağlanır. Ağın bağlantı ağırlıkları problem türü ve kullanılan ağın yapısına göre daha önce belirlenen öğrenme kuralının kullanılması ile değiştirilebilmektedir. Ağırlık değerlerinin belirlenmesi ağa gösterilen örneklerin doğru çıktı üretmesi için önemlidir. Genelde başlangıç ağırlık değerleri rassal olarak seçilmektedir. Ağın eğitimi için kullanılan veri seti Eğitim Seti olarak ifade edilmektedir. Ağın eğitimi süresince aynı eğitim setinin defalarca ağa verilmesiyle ağırlıklar en uygun seviyeye getirilmektedir. Eğitim setinin tümünün ağa gösterilmesi olarak ifade edilen İterasyon (Epoch), genelde eğitim sürelerini ölçmede değerlendirilmektedir. YSA'nın eğitimini tamamlanmasından sonra öğrenme performansını ölçmek maksadıyla yapılan denemeler ağın test edilmesi şeklinde ifade edilmektedir. Bazı paket programlarda ağın eğitimi gerçekleştirilirken diğer bir yandan da Doğrulama Seti (Validation Set) ile ağın her iterasyonda ne kadar öğrendiği test edilmekte ve öğrenim ölçütü olarak doğrulama setine ait hata değerleri kullanılmaktadır. Eğitim setini oluşturan verilerle hedeflenen başarı sağlanmışsa ağ, daha önceden kullanmadığı verilerle test edilmektedir. Burada, test işleminin

gerçekleştirildiği veri seti Test Seti olarak adlandırılmaktadır. Ağın ağırlık değerleri test işlemi gerçekleştirilirken değiştirilememektedir. Örnekler ağa gösterilerek ve ağın eğitiminden sonunda elde edilen ağırlık değerleri kullanarak, ağın daha önceden görmediği bu örnekler için çıktılarının üretilmesi sağlanmaktadır. Üretilen bu çıktılara ait doğruluk dereceleri ağın öğrenmesi hakkında bilgiler verecek, sonucun iyi olması eğitimin performansının o kadar iyi olacağını ifade edecektir. Test seti ile hedeflenen sonuçlara ulaşırsa ağın eğitimi tamamlanmış olacaktır (Bayır 2006).

2.9. Derin Öğrenme (Deep Learning)

Bilgisayarın veya bilgisayar tarafından kontrol edilen bir robotun çeşitli faaliyetlerinin zeki canlılara benzer şekilde yerine getirmesi kabiliyeti yapay zekâ, tecrübe ile veri yığımından otomatik şekilde öğrenen ve otonom davranışlar sergileyen bilgisayar algoritmalarının oluşturulması Makine Öğrenmesi olarak tanımlanmaktadır, Derin öğrenme (Deep Learning) ise günümüzde kullanımı yaygınlaşan yapay zekâ ve makine öğrenmesi alanlarının önemli bir alt bölümüdür. Genel olarak, Yapay Sinir Ağları çalışmaları üzerine geliştirilen Derin Öğrenme yöntemlerinin YSA'lardan farkı, YSA'ların fazla sayıda gizli nöron ve katmanlar üzerine kurulu olmasıdır. (Ravi vd. 2017)



Resim 2.2 Derin Öğrenme

Makine öğrenmesinin bir sınıfı olan derin öğrenme, özellik çıkarma ve dönüştürmede

çok sayıda doğrusal olmayan işlem birimi katmanı kullanmakta, her ardışık katman, önceki katmanda bulunan çıktı işlemini girdi olarak almaktadır (Deng ve Yu 2014)

Derin öğrenme, verinin sahip olduğu yapıya göre filtreleme yapmak amacıyla hangi parametreye hangi ağırlığın verileceğinin kendisinin keşfetmesidir. Derin öğrenme algoritması da YSA'lar gibi veri esaslı öğrenme gerçekleştirmektedir. Öğrenme süreci, standart makine öğrenmesi algoritmalarında bulunan tek bir matematiksel modele değil sinirsel ağ şeklinde ifade edilen ağ diyagramlarına benzer yapıda geliştirilmiş hesaplamalarla sağlanmaktadır. Veriye dayalı öğrenme gerçekleştirmesinden dolayı her derin öğrenme algoritması bir makine öğrenmesi algoritması olarak nitelendirilmektedir. Makine öğrenmesinin bir türü olan Derin Öğrenme, yüksek bilgi işleme gücüyle ve büyük veri kümeleriyle birlikte katmanlı YSA'ların güçlü matematiksel modeller oluşturabildiği bir makine öğrenimi alt kümesidir (İnt. Kyn. 11).

Derin öğrenmenin sahip olduğu yapı, verilerin birden çok özellik seviyesinin veya temsillerinin öğrenilmesine dayanmaktadır. Üst düzey özelliklerinin, alt düzey özelliklerden türetildiği hiyerarşik yapı, soyutlamanın farklı seviyelerine karşılık gelen birden fazla temsil seviyesini öğrenmektedir (Bengio 2009).


Derin öğrenmenin kullanıldığı uygulamalardan bazıları şunlardır (İnt. Kyn. 12);

- Örüntü tanıma ve doğal dil işleme,
- Görüntülerin tanınması ve işlenmesi,
- Otomatik çeviri,
- Duygu analizi,
- Soruları yanıtlamak için sistem,
- Nesnelerin Sınıflandırılması ve Tespiti,
- Makineye Göre El Yazısı Oluşturma,
- Otomatik metin oluşturma,
- Siyah Beyaz görüntülerin renklendirilmesi.

2.9.1. Derin öğrenme Mimarileri

2.9.1.1. Multilayer Perceptron Neural Network (MLPNN)

Derin öğrenme için sağlam bir giriş görevi gören çok katmanlı algılayıcı belirlenen bir girdi setini kullanarak bir dizi çıktı elde etmek için iki adede kadar gizli katmanın olduğu ileri beslemeli denetimli bir öğrenme algoritması kullanılmaktadır (Bakınız Şekil 2.14). Ağ, yönlendirilen bir grafikte birden çok nöron katmanını birbirine bağlayarak sinyal düğümlerden bir yönde geçmektedir. Çıkış vektörü, girdilerin ve ileri beslemeli hesaplama akışındaki rastgele ağırlık seçiminin göz önüne alınmasıyla hesaplanmaktadır. Modelin eğitimi, eğitim veri setindeki girdi ve çıktı arasında bulunan bağımlılıkların öğrenmesi amacıyla gerçekleştirilir. Belirli bir girdi için çıktı olması gerekenler arasındaki hata miktarı hesaplanmakta ve eğitim, çıktı katmanındaki hatayı azaltmak için ağırlıkların (weights) ve bias'ın ayarlanmasını içermektedir. Geriye doğru giden gizli katmanlar için işlem tekrarlanır. Geri yayılım, hataya göre ağırlık ve bias ayarlamalarını yapmak için kullanılmaktadır. Hatanın kendisi, kök ortalama kare hatası (RMSE) dâhil olduğu çeşitli yollarla da ölçülebilmektedir (İnt. Kyn. 12).



Şekil 2.14 Multilayer Perceptron Neural Network Modeli

Sağladığı Yararlar: MLPNN'ler, çeşitli parametrelerin bulunduğu karmaşık sorunların çözümünde ve veri noktalarının sınıflandırmasında kullanılabilir, doğrusal olmayan şekilde ayrılabilir.


Multilayer Perceptron Neural Network (MLPNN), aşağıda belirtilen durumlarda olduğu gibi sorunların çözümü için kullanılabilir:

- Görüntünün doğrulanmasında ve yeniden yapılandırılmasında,
- Konuşma tanımda,
- Makine çevirisinde,
- Verilerin sınıflandırmasında
- Birçok parametre bulunan e-ticaret işlemlerinde

2.9.1.2. Backpropagation

Makine Öğrenmesi algoritmalarından ve aynı zamanda Derin Öğrenmenin en basit sinir ağları modellerin biri olan Backpropagation (Bakınız Şekil 2.15), delta kuralı veya gradyan iniş olarak isimlendirilen bir tekniğin kullanılması ile ağırlık alanında ortaya çıkabilecek hata fonksiyonu gibi değerleri minimuma indirmektedir. Hata fonksiyonunu minimum yapan ağırlıkların öğrenme problemi için bir çözüm olduğu düşünülmektedir (İnt. Kyn. 12).

Başlangıç olarak bir sinir ağı, verilerin okunması amacıyla ilk değerleri rastgele verilmiş ağırlıklar ve biaslardan oluşmaktadır. Ağırlıklar ve bias değerleri aracılığı ile bir sinir ağının verileri yorumlanması gerçekleştirilmektedir. Tahmin katmanındaki hatalar, yapılacak tahminlerin düşük hata değerlerine ulaşması amacıyla ağırlıkları ve biasları ayarlamak üzere ağ üzerinden geri gönderilmektedir. Bir nöronun hata katkısı, algoritmanın, delta kuralı veya gradyan iniş optimizasyonu olarak adlandırılan bir tekniği kullanması ile hesaplanmaktadır. Çıkış katmanındaki hatanın azaltılması için nöronların ağırlığı ayarlanmaktadır. Sinir ağının katmanları sırayla çalışması, her katmandaki türevlerin bulunması önceki ve sonraki katmanlarla kıyaslandığında parametreler için her katmandaki hata değişiminin bir ilişkisini kurmaktadır (İnt. Kyn. 12).



Şekil 2.15 Backpropagation Neural Network Modeli

Sağladığı Yararlar: Geri yayılım, geliştiricilerin hata noktalarının ağırlıklara nasıl katkıda bulunduğunu bilmelerini sağlar. Hataya elverişli projelerde iyi çalışmalarını nedeniyle ve derin sinir ağlarını eğitilmeleri için kullanılmaktadır.

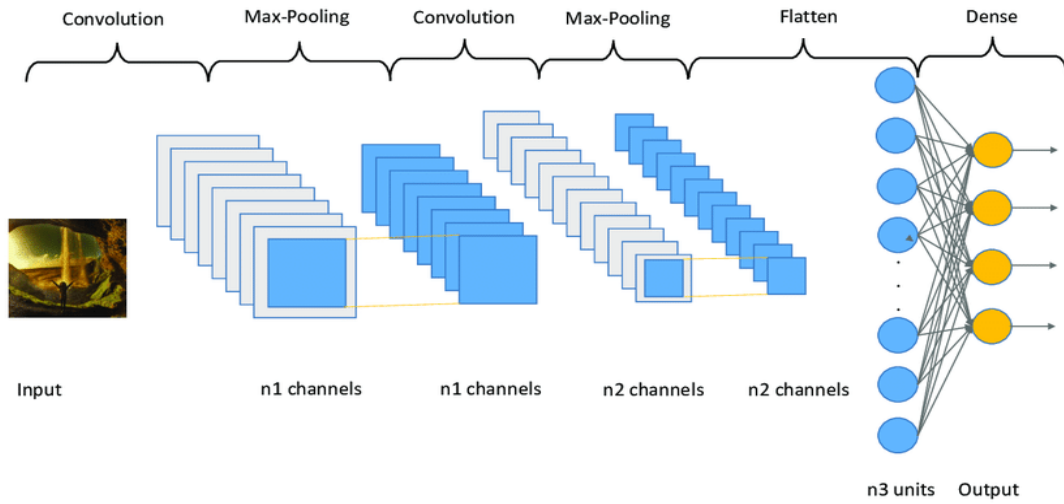
Backpropagation, veri madenciliğinde ve makine öğreniminde tahmin doğruluklarının artırılması amacıyla görüntü ve konuşma tanımada, sonuçların çabuk bir şekilde hesaplanmasına ihtiyaç duyulan çalışmalarda kullanılmaktadır (İnt. Kyn. 12).

2.9.1.3. Convolutional Neural Network (ConvNet/CNN)

Çok katmanlı algılayıcıların (Multi Layer Perceptron-MLP) bir türü olan Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN) yani evrişimli sinir ağları, bir veya birden çok konvolüsyonel katmandan, alt örnekleme (subsampling) katmanından ve bunun ardından standart çok katmanlı bir sinir ağına benzer bir veya birden fazla tamamen bağlı katmandan meydana gelmektedir (LeCun vd. 2015).

Genel olarak görüntü sınıflandırması için görsel verilerde kullanılan CNN, denetimli öğrenmede ve verilerin analizini yapmak için algılayıcıları kullanan çok katmanlı, ileri beslemeli bir sinir ağıdır. Derin Öğrenme algoritması olan CNN, bir girdi görüntüsünü

alabilmekte, görüntüdeki çeşitli yönlere/nesnelere önem (öğrenilebilir ağırlıklar ve önyargılar) atayabilmekte ve birini diğerinden ayırt edebilmektedir. Diğer sınıflandırma algoritmalarıyla kıyaslandığında ConvNet için gereken ön işleme daha düşüktür. İlkel yöntemlerin uygulanmasında filtreler elle tasarlanırken, yeterli eğitimin verilmesiyle ConvNet'lerin bu filtreleme ve özellikleri öğrenme yeteneğine sahip olacaktır. ConvNet'in mimarisi (Bakınız Şekil 2.16), insan beynindeki nöronların bağlantı modeline benzemektedir. Bireysel nöronlar, uyarılara yalnızca alıcı alan olarak bilinen görme alanının sınırlı bir bölgesinde yanıt vermektedir. Bu tür alanların bir koleksiyonu, tüm görsel alanı kapsayacak şekilde örtüşür (İnt. Kyn. 12).



Şekil 2.16 Convolutional Neural Network

Sağladığı Yararlar: Tanıma konusunda etkili olan ve yüksek oranda uyarlanabilen CNN algoritması, daha az eğitim parametresinin olduğunda ve geri yayılımla birleştirildiğinde ölçeklenebildiği için eğitimi de kolaydır.

Convolution Neural Network-CNN;


- Görüntünün işlenmesi, tanıma ve sınıflandırmasında,
- Video tanımda,
- Doğal dil işlemede,
- Desen tanımda,

- Öneri motorlarında,
- Tıbbi görüntü analizinde kullanılmaktadır.

2.9.1.4. Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) birimler arasında bulunan bağlantıların yönlendirilmiş bir döngü oluşturduğu YSA sınıfı olarak bilinmektedir. Bu döngüyle, dinamik zamansal davranış sergilemesine olanak veren bir ağ iç durumu oluşturulmuştur. Recurrent Neural Network (RNN)'ler ileri beslemeli sinir ağların aksine, kendi giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilmektedirler (Mikolov 2010). Recurrent Neural Network (RNN)'deki ana düşünce sıralı bilgilerin kullanılmasıdır. Görüntü tabanına sahip verilerde tüm girdi veya çıktıların birbirinden bağımsız olduğu varsayılmaktadır.

Bu ağlar çıktının daha önceden yapılan hesaplamalarına bağlı olan uygulamalar için daha uygundur. Her adımda aynı ağırlıkların paylaşıldığı yinelemeli derin sinir ağları, sıralı gerçekleşen olayları ezberleyebilir, zaman bağımlılığının modellenmesini sağlama özelliğine sahiptir. Doğal dil işleme uygulamalarında sık olarak kullanılmakta olan bu yöntem birçok uygulamada başarı sağlamıştır. Eğimin sıfır olmasından ve aniden yükselmesi gibi yaşanan problemler sebebiyle öğrenmede sorunlar yaşanabilmektedir (Umut vd. 2019).



Şekil 2.17 Recurrent Neural Network

Sağladığı Yararlar: Çeşitli uygulamalarda kullanılan RNN'ler sıralı ve zamansal

verilerin işlenmesinden başka tahmin problemlerindeki bağlamı da öğrenebilmektedir. Recurrent Neural Network (RNN);

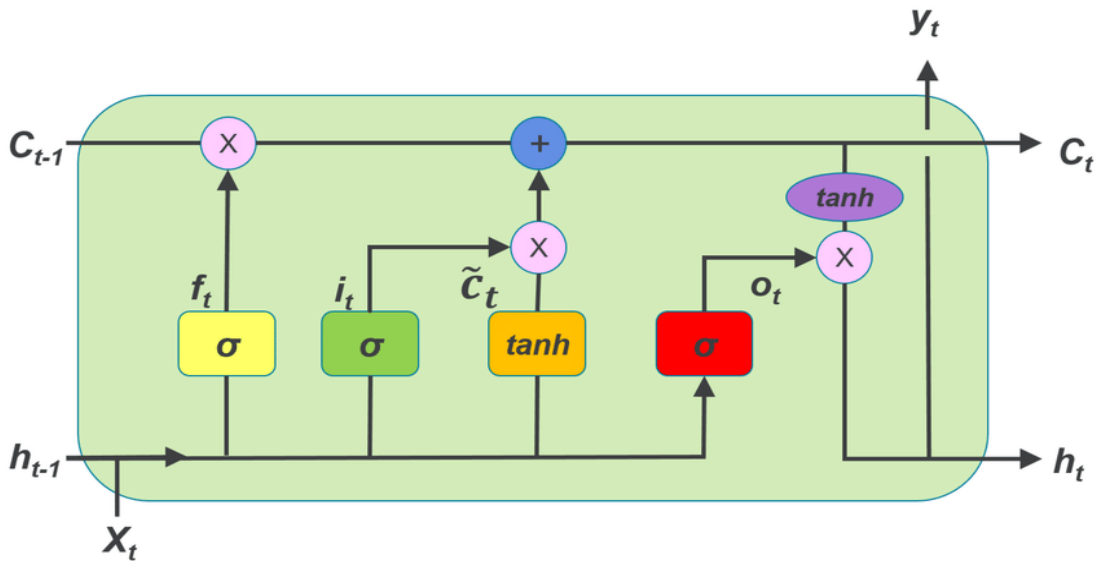
- Duygu sınıflandırmada,
- Resim yazısında,
- Konuşma tanımada,
- Doğal dil işlemede,
- Makine çevirisinde,
- Arama tahmininde ve video sınıflandırmasında kullanılmaktadır (İnt. Kyn.

12).

2.9.1.5. Long Short-Term Memory (LSTM)

Long Short-Term Memory Algoritması, ağırlıkların güncellenmesini sağlayan gradyanları kararsız hale getirmeden, derin tekrarlayan ağların eğitilmesi için imkan veren RNN türüdür. Desenler, verileri seçip geri çağırma ya da silme yeteneğiyle daha uzun süreler için bellekte saklanabilmektedir.

Long Short-Term Memory (LSTM Şekil 2.18) mimarisinin sahip olduğu bağlantılar; giriş, unutma ve çıkış olmak üzere 3 kapıdan, blok girişi, sabit hata döngüsü, çıkış aktivasyon fonksiyonundan ve gözetlemeden oluşmaktadır (Greff 2015).



Şekil 2.18 Long Short-Term Memory

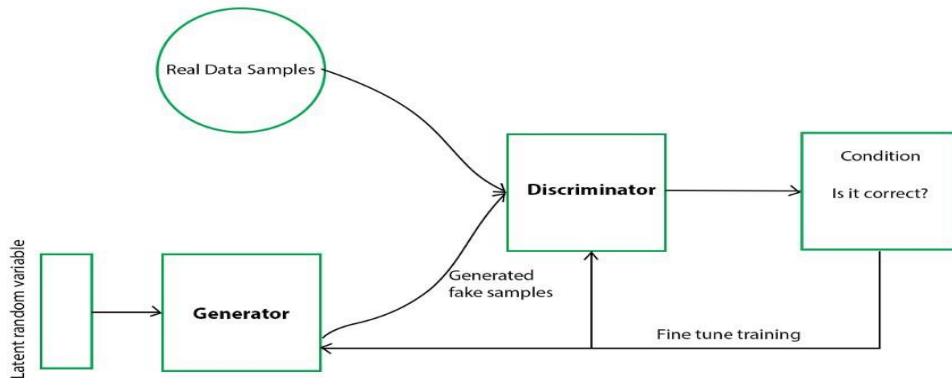
Sağladığı Yararlar: Zaman serisi verilerine dayalı olarak sınıflandırma işlemleri ve tahminler için en uygun olan LSTM algoritması; çeşitli problemlerin çözümü için gelişmiş sonuçlar sunmaktadır. Bunlar, veri bilimciler tarafından büyük yığınlanmış ağları kullanarak derin modellerin oluşturmasına ve makine öğreniminde karmaşık sıralı sorunları daha verimli bir halde incelemesine imkân tanımaktadır.

Long Short-Term Memory (LSTM);

- Görüntü ve videolara altyazı koymak amacıyla
- Dil çevirisinde ve modellemede,
- Duygu analizinde,
- Borsa tahminlerinde kullanılmaktadır (İnt. Kyn. 12).

2.9.1.6. Generative Adversarial Network (GAN)

Generative Adversarial Network (GAN) modelleri genel olarak mimarilerinde biri üretici diğeri ayırıcı olmak üzere iki farklı derin ağa sahiptir. Bu ağlar çekişmeli olarak çalışmakta, üretici ağ, giriş olarak aldığı gürültü vektörüne ait eğitim kümesinde bulunan gerçek görüntülere benzetmeyi amaçlarken, ayırıcı ağ, sentetik üretilmiş görüntülerle (sahte) ve gerçek eğitim görüntülerin birbirinden ayırt edilmesine çalışmaktadır (Goodfellow 2016).



Şekil 2.19 Generative Adversarial Network

Sağladığı Yararlar: Generative Adversarial Network (GAN), belirli bir veri kümesinde bulunan varyasyonları yakalayabilmekte, kopyalayabilmekte, bir görüntü veri kümesinden görüntülerle yüksek kaliteli veriler oluşturabilmektedirler.

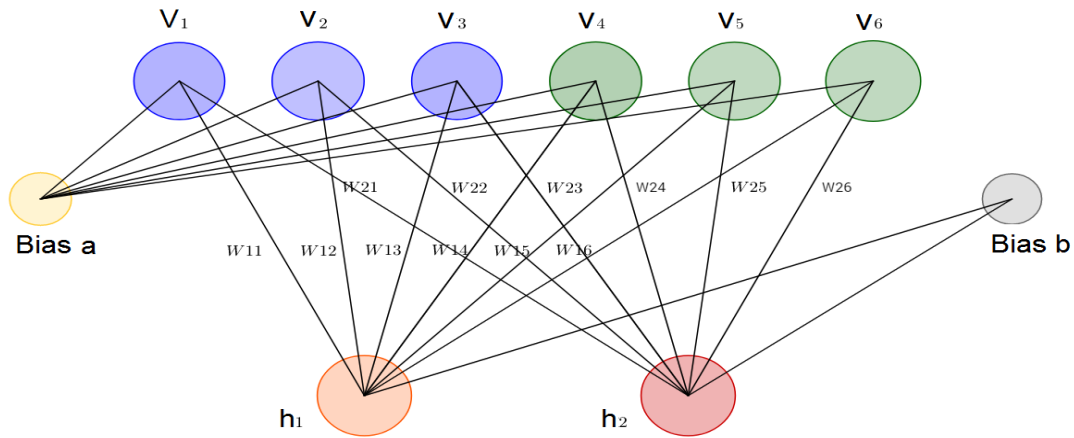
Generative Adversarial Network (GAN);

- Siber güvenlikte,
- Sağlıkta tanı koymada,
- Doğal dil işlemede,
- Konuşma işlemede kullanılmaktadır (İnt. Kyn. 12).

2.9.1.7. Restricted Boltzmann Machine (RBM)

Boltzmann makinesi, girdi seti üzerinden bir olasılık dağılımı öğrenebilen üretken bir stokastik YSA'dır.

Ağ, bir görünür birim katmanından, bir gizli birim katmanından ve tüm görünür ve gizli birimlere bağlı bir bias biriminden oluşmaktadır. Tarafsız bir şekilde örnekler vermenin bir yolu olarak gizli birimler bağımsız şekildedir. İkili grafikteki nöronların simetrik bir bağlantısı bulunmaktadır. Bununla birlikte, bir grup içindeki düğümler arasında bağlantı yoktur (İnt. Kyn. 12).



Şekil 2.20 Restricted Boltzmann Machine


Sağladığı Yararlar: Boltzman makinesi, tasarım esnekliği gibi enerji temelli öğrenmenin avantajlarını sunmaktadır. Olasılıklı ve olasılıklı olmayan istatistiksel modeller için yararlı olmasıyla birlikte, kolay öğrenmede bağlantıyı kısıtlamaktadır. Sınıflandırma, regresyon ve üretken modellerle kullanılmaktadır.

Restricted Boltzmann Machine (RBM);

- Öneri sistemlerinde,
- Filtrelemelerde,
- Özellik öğreniminde,
- Boyutsal küçülmede,
- Konu modellemede kullanılmaktadır (İnt. Kyn. 12).

2.9.1.8. Deep Belief Network (DBN)

Kısıtlı Boltzmann Makinesi (KBM) bileşimi olan Deep Belief Network, her bir alt ağız gizli katmanı bir sonraki için görünür katman işlevi görmektedir. Bu yapı ağız denetimli veya denetimsiz şekilde eğitilmesine imkân sağlamaktadır. Ağız başlatılması için katman açgözlü öğrenme stratejisi önerilmektedir. En yüksek olasılığa sahip bilgilerin çıkarımı yapılmaktadır. Başlangıçtaki prosedürü ve örnekleme nedeniyle eğitim aşaması hesaplama açısından pahalıdır (Hinton ve Salakhutdinov 2006).



Şekil 2.21 Deep Belief Network

Sağladığı Yararlar: Deep Belief Network (DBN) enerji temelli öğrenme sunmakta ve etiketlenmemiş verilerden yararlanabilmektedir.

Deep Belief Network (DBN);

- Görüntü ve yüz tanıma,
 - Video dizisi tanıma,
 - Hareket yakalama verilerinde,
 - Yüksek çözünürlüğe sahip uydu görüntüsü verilerinin sınıflandırılmasında
- kullanılmaktadır (İnt. Kyn. 12).




3. MATERYAL ve METOT

3.1. Çalışmalar İçin Kullanılan Malzemeler

3.1.1. SEM (Scanning Electron Microscope)

Elde edilen nanolif analizlerinin gerçekleştirilmesi sürecinde Afyon Kocatepe Üniversitesi Teknoloji Uygulama ve Araştırma Merkezi'nde bulunan LEO 1430 VP model SEM cihazı kullanılmıştır.



Resim 3.1 LEO 1430 VP model SEM cihazı.

3.1.2. Geliştirici Kit

Yapay zekâ algoritmalarının çalıştırılabilmesi için küçük NVIDIA Jetson Nano Developer Kit bilgisayar kullanılmıştır.



Resim 3.2 NVIDIA Jetson Nano Developer Kit

3.1.3. Fibraquant Programı

Laboratuvar ortamındaki SEM görüntülerinden Fibraquant uygulaması ile nanoliflerin yapı, çap ve dağılımı elde edilmiştir. Fibraquant, SEM cihazından alınan görüntüler üzerinden nanolif çaplarının otomatik veya manuel olarak seçilmesini gerçekleştirmekte, nanoliflere ait çap büyüklüklerinin, ortalamalarının, standart sapmalarının ve medyan değerlerinin hesaplanmasını sağlamakta, aynı zamanda nanolif çaplarının dağılımlarını sütun grafiği şeklinde sergilemektedir. Çalışmada Fibraquant programı ile nanolif çaplarının belirlenmesi otomatik olarak seçilmiş ve gerekli veriler temin edilmiştir.

3.1.4. Matlab Programı

Çalışmada veri seti olarak laboratuvar ortamında yapılan deneylere ait deneysel veriler kullanılmıştır. Laboratuvar ortamında gerçekleştirilen ölçümler sonucu elde edilen verilere kullanılarak veri seti oluşturulmuştur. Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi, akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değeri Yapay Sinir Ağının ve Derin Öğrenme Algoritmasının giriş değişkenleri olarak, nanolif çapı çıkış olarak kullanılacaktır.

Matlab uygulaması algoritma geliştirilmesi, veri analizi, verilerin görsel hale getirilmesi ve sayısal işlemlerin yapılması için tasarlanan, kullanılması kolay olan, etkileşimli bir çevrede işleyen yüksek seviyeli bir hesaplama dilidir. Matlab Neural Network Toolbox, Matlab için geliştirilen YSA'ların tasarlanmasını, gerçekleştirilmesini, görselleştirilmesini ve simülasyonunu sağlayan bir araçtır (Arı ve Berberler 2017).

3.1.5. Google Colab

Google Research tarafından sunulan bir ürün olan Colaboratory ("Colab"), makine öğrenimi, veri analizi ve eğitim için tarayıcı üzerinden rastgele Python kodu yazıp yürütebilen, kullanım için kurulum ihtiyacı olmayan ve GPU'lar gibi bilgi işlem kaynaklarına ücretsiz erişim olanağına sahip bir Jupyter not defteri hizmetidir. Kodlar, hesapta özel bir sanal makinede yürütülmektedir (İnt. Kyn. 13). Colab, yapay zeka,

derin öğrenme, data analizi gibi işlemleri kolaylaştırırken 16 gb'a kadar GPU desteği sunmakta ve bir çok fonksiyonu hazır bir biçimde bulundurmaktadır.


3.1.6. Python ve Keras

Python, web uygulamalarının oluşturulması ve sistem yönetiminde önemli rol alma, veri analizleri ve makine öğreniminde kullanılan önemli bir dildir. Keras, derin öğrenme için yazılmış bir python kütüphanesidir (Int Kyn. 14). Derin öğrenme modelinin geliştirilmesi, eğitilmesi, test edilmesi ve çıkarım işlemleri Python dilinde Keras, matplotlib, numpy, pandas, seaborn, tensorflow, kütüphaneleri kullanılarak modellerin tanımlanması ve eğitilmesi sağlanmıştır.

3.2. Yapay Sinir Ağları

3.2.1 Verilerin İşlenmesi

Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi üzerinden elektroçizme yöntemiyle elde edilen nanoliflerin mikroyapı analizleri LEO 1430 VP model SEM (Taramalı Elektron Mikroskop) cihazı aracılığıyla yapılmıştır. Nanoliflere ait SEM görüntüleri Şekil 3.1'de verilmiştir.



Şekil 3.1 Laboratuvar ortamında elde edilen nanolifler

Laboratuvar ortamında SEM cihazından alınan nanolif görüntülerinden Fibraquant yazılımı ile veriler sayısal hale getirilmiştir. Fibraquant yazılımı ile elde edilen bilgiler Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Fibraquant Yazılımı ile elde edilen veriler

Fiber Diameter (μm)	Position (μm)		Fiber Orientation ($^{\circ}$)
	X	Y	
0,253	38,163	45,871	53,131
0,253	38,837	47,303	53,131
0,253	33,698	36,436	53,131
0,253	22,409	58,087	126,870
0,258	22,367	12,258	78,691
0,362	39,511	48,693	71,565
0,391	52,843	50,330	42,710
0,396	51,895	48,567	63,435
0,425	13,100	3,875	90,000
0,429	21,019	9,225	81,870

Bu veriler Matlab programı ile çözülmeye önce veri tutarsızlıklarını önlemek için tüm veriler normalize edilerek veri tekrarı en aza indirilmiş, giriş verilerinin tümü [0,1] aralığına indirgenmiştir. MATLAB programında Workspace kısmına normalize edilen eğitim girdi ve çıktı verileri girilmiş, normalizasyon işleminin tamamlanmasından sonra kullanılacak olan Matlab uygulamasında tahmin edilmeye çalışılmıştır. Öğrenme modelinde kullanılan ham veriler Çizelge 3.2’de verilmiştir.

Çizelge 3.2 Ham Veriler

Yoğunluk	Akış Hızı	Mesafe	Voltaj	Sonuç
1	0,1	6	10	0,906
1	0,1	6	10	1,015
1	0,1	6	15	0,567
1	0,1	6	15	0,596
1	0,1	7	20	0,409
1	0,1	7	25	0,192
1	1	8	30	0,248
1	1	8	30	0,176
1	1	8	30	0,215

3.2.2 Modelin Oluřturulması

YSA'lar, aęa girilen bilgilerden faydalanarak bu bilgilere ait ıktı deęerlerini tahmin etmeye alıřmaktadır. alıřmada kullanılacak olan YSA modeli, ileri beslemeli geri yayılım aęıdır. Tahmin alıřmalarında ok kullanılıyor olması ve doęrusal olmayan modellerdeki tahmin bařarısı bu yapay sinir aęının tercih edilmesinde nemli bir unsurdur.

Modeli oluřtururken nanolif apını etkileyecek faktrler belirlenmiřtir. Nanolif apının tahmin edilmesinde kullanılacak yapay sinir aęının eęitilmesi iin veri setinde bulunan girdi deęiřkenleri Polivinilpirolidon (PVP) polimer, su ve alkol ozeltisi, akıř hızı, ięne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj deęeri ve ıktı olarak nanolif apı olarak belirlenmiřtir. Modelde 4 adet girdi 1 adet ıktı ve tek ara katman kullanılmıřtır.

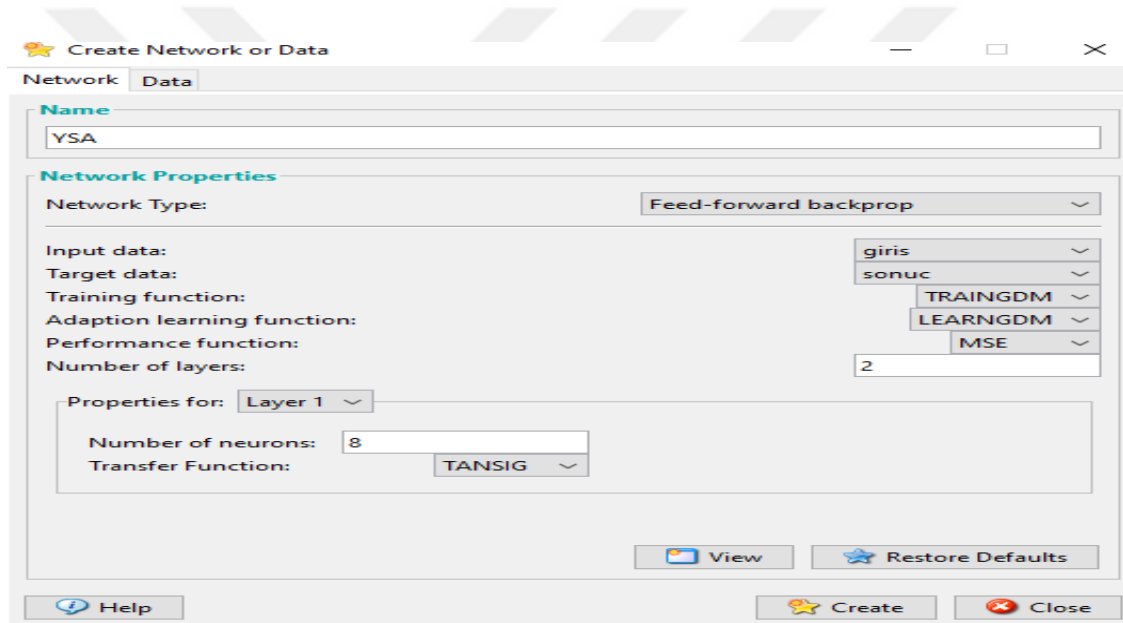
Veri setinden girdi verilerinin belirlendikten sonra mteakip ařama modelin eęitiminin gerekleřeceęi ařamadır. Modelin eęitimine geilmeden nce modele ait girdi deęiřkenleri, gizli katmanlar ve ıktı deęiřkenleri ile katman sayıları tanımlamaları yapılmıřtır. Birok deneme yapılarak tahmin sonularını etkileyen hcre sayısı, momentum katsayısı ve ęrenme katsayısı deęerleri belirlenmeye alıřılmıřtır. Yapılan denemeler sonucunda ęrenme katsayısı 0.9, momentum katsayısı 0.8, hcre sayısı 2 olarak belirlenmiřtir. Aęın tipi İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop), giriř katmanında baęımsız deęiřken olarak polimer, su ve alkol ozeltisi, akıř hızı, ięne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj deęeri, gizli katman sayısı bir, aktivasyon fonksiyonu Hiperbolik Tanjant, ıktı katmanında baęımlı deęiřken olarak nanolif apı, aktivasyon fonksiyonu Hiperbolik Tanjant ve performans fonksiyonu olarak da Ortalama Hata Kareleri (Mean Squared Errors,MSE) kullanılmıřtır.

3.2.3 Yapay Sinir Aęının Eęitimi ve Testi

Aęın eęitilmesi iin programında bulunan Neural Network uygulaması kullanılmıřtır. alıřma kapsamında Yapay Sinir Aęları ile ilgili olarak yapılacak alıřmalar iin

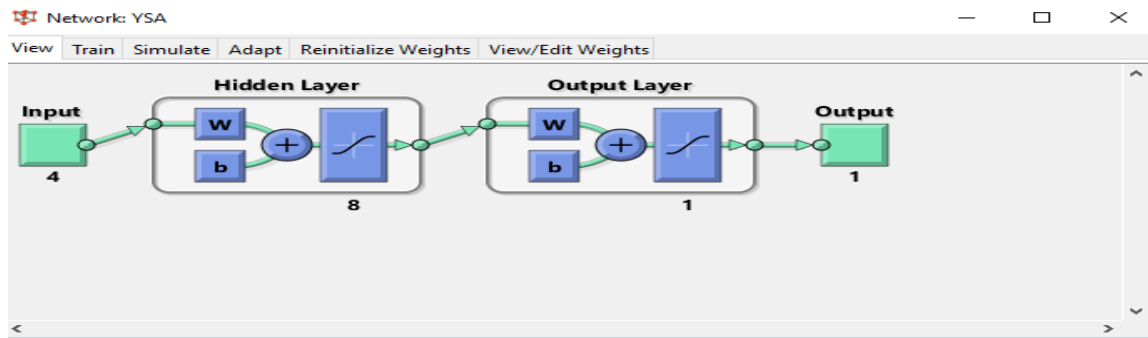
MATLAB R2021A yer alan yapay sinir ağıları alt modülü olan Matlab Neural Network Toolbox kullanılmıştır. Veri setinde bulunan ve normalizasyon işlemi yapılan Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi, akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değerleri (giriş) 'input', sonuçlar ise (sonuç) 'target' olarak belirlenmiştir.

Oluşturulacak YSA için ağın tipi, eğitim girdisi (input data)-çıktı verisi (target data), eğitim ve öğrenme için algoritmalar, performans fonksiyonu, katman, gizli hücre, nöron sayısı ve aktivasyon fonksiyonu tercihleri yapılmış ve Resim 3.3'deki YSA modeli oluşturulmuştur.



Resim 3.3 Oluşturulan YSA Modeli

Oluşturulan yapay sinir ağı modeline ait görüntü Resim 3.4'de yer almaktadır.



Resim 3.4 Yapay Sinir Ağı

Bu aşamada “Train” sekmesinde altında bulunan ve öğrenme performansını etkileyen momentum, öğrenme ve çevrim sayısı değerlerinin seçimi yapılarak YSA'nın eğitimi başlatılmıştır.

Eğitim, elde bulunan veri seti için MSE fonksiyonunu minimize eden ağırlık değerlerinin bulunmasıdır. Bu aşamada eğitim seti ile birlikte doğrulama seti de ağı sunulmakta ve en küçük hata düzeyine ulaşılmaya çalışılmaktadır. Eğitim sonucunda eğitim, doğrulama ve test kümelerine ilişkin hata değerleri incelendiğinde 1250 iterasyon sonucunda en uygun sonuca ulaşılmıştır.

3.3. Derin Öğrenme

Tahminleme çalışmalarında modelin eğitilmesi, test edilmesi ve geleceğe yönelik tahmin yapmak amacıyla Google Colab arayüzü üzerinde çalışılmıştır. Derin öğrenme için geliştirilen, farklı özelliklerde bulunan ve derin öğrenme çalışmalarını daha kolay hale getiren hazır kütüphaneler bulunmaktadır. Python programlama dili ile kullanabilecek derin öğrenme kütüphanelerinden matplotlib, numpy, pandas, seaborn, tensorflow, keras kütüphaneleri kullanılmıştır.

3.3.1 Verilerin İşlenmesi

Derin öğrenme için öncelikle tüm öğrenme işlemimizin yapıldığı veri seti oluşturulmuştur. Çalışmada, derin öğrenme mimarisi yardımıyla nanoliflerin çaplarının tahmini yapmak amacıyla girdi değişkeni olarak Polivinilpirolidon (PVP) polimer, su ve alkol çözeltisi, akış hızı, iğne ucu ve toplayıcı plaka arası mesafe ile uygulanan voltaj değeri kullanılmıştır. İlk olarak programın verileri okuyabilmesi için Excel dosyası .csv'ye (virgülle ayrılmış değerler dosyası) formatında düzenlenmiş, matplotlib, numpy, pandas, seaborn kütüphaneleri import edilerek pandas kütüphanesi yardımı ile veri setinin arayüz programında okunması sağlanmıştır.

```
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import seaborn as sns
adres = "Veri.data"
```

```
sutunlar = ['Yoğunluk', 'Hız', 'Mesafe', 'Voltaj', 'Sonuç']
veriseti = pd.read_csv(adres, names=sutunlar, skipinitialspace=True, na_values="?", comment="#", sep=";")
```

Veri seti satır ve sütun bazında incelenmiş, tanımlanmayan, boş ya da sayısal değer ifade etmeyen satırlar tespit edilmeye çalışılmış, boş ve eksik satır olmadığı görülmüştür.

```
veriseti.head(5)
veriseti.tail(5)
veriseti.isna().sum()
```

Ağ yapılandırılırken değerlendirmeye devam etmek için veriler eğitim ve doğrulama verileri olmak üzere veri setlerine ayırmak gereklidir. Veri setinin eğitim ve test verileri olarak ayrılması için pandas kütüphanesinin sample fonksiyonu kullanılmış, veri setinin %80'i eğitim, kalan % 20'si test kümesi olarak belirlenmiştir.

```
train_set = veriseti.sample(frac=0.8, random_state=0)
test_set = veriseti.drop(train_set.index)
```

Verileri eğitime uygun hale getirilmesi için veri setinin hangi algoritmaya uygun olduğu incelenmiştir.

```
train_set.columns
sns.pairplot(train_set[['Yoğunluk', 'Hız', 'Mesafe', 'Voltaj']])
print(train_set.describe().transpose())
```

	count	mean	std	min	25%	50%	75%	max
Yoğunluk	634.0	1.000000	0.000000	1.000	1.000	1.0000	1.0	1.000
Hız	634.0	0.645110	0.440181	0.100	0.100	1.0000	1.0	1.000
Mesafe	634.0	7.022082	0.821984	6.000	6.000	7.0000	8.0	8.000
Voltaj	634.0	20.165615	7.182743	10.000	15.000	20.0000	25.0	30.000

3.3.2 Modelin Oluşturulması ve Eğitilmesi

3.3.2.1 Model-1

Model oluştururken ilk olarak bir derin öğrenme kütüphanesi olan tensorflow kütüphanesi eklenmiş, normalleştirme katmanı ile normalizasyon işlemi

gerçekleştirilmiştir.

```
import tensorflow as tf
from tensorflow.keras import layers
normalizer = layers.experimental.preprocessing.Normalization(axis=-1)
normalizer.adapt(train_set)
```

Girdi ile çıktının doğru orantılı olmasından dolayı bir sinir hücresine sahip basit doğrusal model oluşturulmuştur.

```
dogrusal_model = tf.keras.Sequential([
    normalizer,
    layers.Dense(1)])
```

Model hatalarını gösterecek hata fonksiyonları derlenmiş, tahminler ile doğru hedeflerin arasındaki farkın mutlak değeri olan Ortalama Mutlak Hata 'MAE' olarak tanımlanmıştır.

```
dogrusal_model.compile(loss = "mean_absolute_error", optimizer = tf.
keras.optimizers.Adam(learning_rate= 0.1))
```

Oluşturulan doğrusal modelin 100 epoch ve eğitim setinin %20'sini doğrulama olarak belirlendikten sonra modelin eğitimi gerçekleştirilmiştir.

```
history = dogrusal_model.fit(train_set, train_labels, epochs=100, validation_split=0.2, verbose=0)
plt.plot(history["loss"], label="egitim hatasi")
plt.plot(history["val_loss"], label="dogruluk hatasi")
plt.legend()
plt.show()
```

3.3.2.2 Model-2

64 sinir hücresi ve negatif tamsayılarda işlem yapmayan relu aktivasyon fonksiyonu ile iki gizli katman ile çıkış katmanı eklenerek tahmin modeli oluşturulup modelin eğitimi gerçekleştirilmiştir.

```
derin_model = tf.keras.Sequential([
```


```
normalizer,  
layers.Dense(64,activation='relu'),  
layers.Dense(64,activation='relu'),  
layers.Dense(1)])  
derin_model.compile(loss = "mean_absolute_error",optimizer = tf.keras.optimizers.Adam(learning_rate= 0.001))  
history = derin_model.fit(train_set,train_labels,epochs=100,validation_split=0.2,verbose=0)  
history = history.history  
plt.figure()  
plt.title("Derin Model")  
plt.plot(history["loss"],label="egitim hatasi")  
plt.plot(history["val_loss"],label="dogruluk hatasi")  
plt.legend()  
plt.show()
```



4. BULGULAR

4.1. Yapay Sinir Ağları Sonuçlarının Test Edilmesi ve Değerlendirilmesi

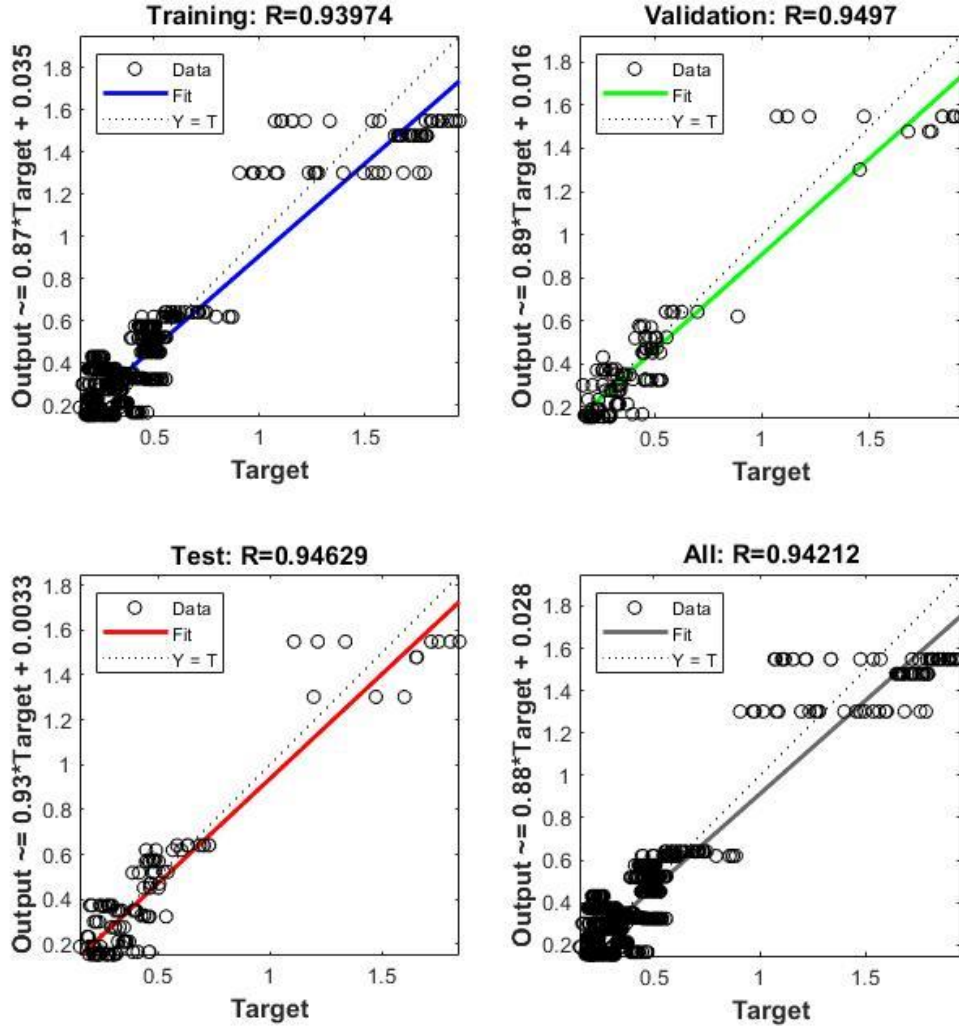
YSA'nın eğitimi tamamlandıktan sonra iterasyonlardaki Eğitim, Doğrulama ve Test kümelerindeki hata değerlerine ait değişimi gösteren grafik Şekil 4.1'deki grafik elde edilmiştir. Grafik incelendiğinde ağıın eğitiminde en iyi performans, 257. iterasyonda elde edilmiştir.



Şekil 4.1 Eğitim, doğrulama ve test kümelerine ilişkin hata performansları

YSA'nın eğitimde; MSE hata oranını ve R ise eğitimin ne kadar iyi olduğunu göstermektedir. Momemtum ve öğrenme katsayısı ile çevrim sayısı gibi öğrenmenin performansına etki eden parametreler seçilerek nöron sayısı deneme yanılma yolu ile belirlenmiş, MSE oranının minimum R oranının maximum seviyede ve %90 üzerinde olması hedeflenmiştir. Öğrenmenin tamamlanmasından sonra elde edilen regresyon grafiği Şekil 4.2'de gösterilmektedir. Regresyon grafiği incelendiğinde en yüksek değer 0.9497 ile test kümesine ait olduğu, 0.9462 ile öğrenme işleminin başarılı olduğu,

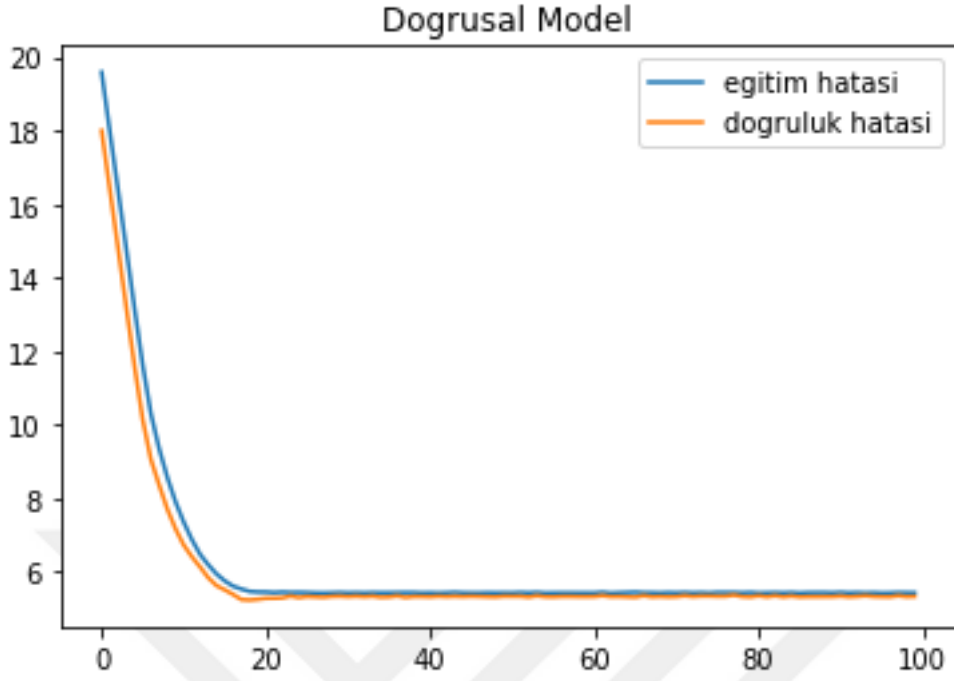
belirlenen deęişkenlerin 0.94 oranında nanoliflerin aplarını etkiledięi grlmektedir. Sistemin herhangi bir ezberleme yapıp yapmadıęına baktıęımızda eęitim R oranı ile test doęruluk oranı arasındaki farkın yksek olmadığı, dolayısıyla bir ezberleme yapmadıęı deęerlendirilmektedir.



Şekil 4.2 Matlab'ta ęrenme, doęrulama ve test kmelerine ilişkin regresyon grafięi

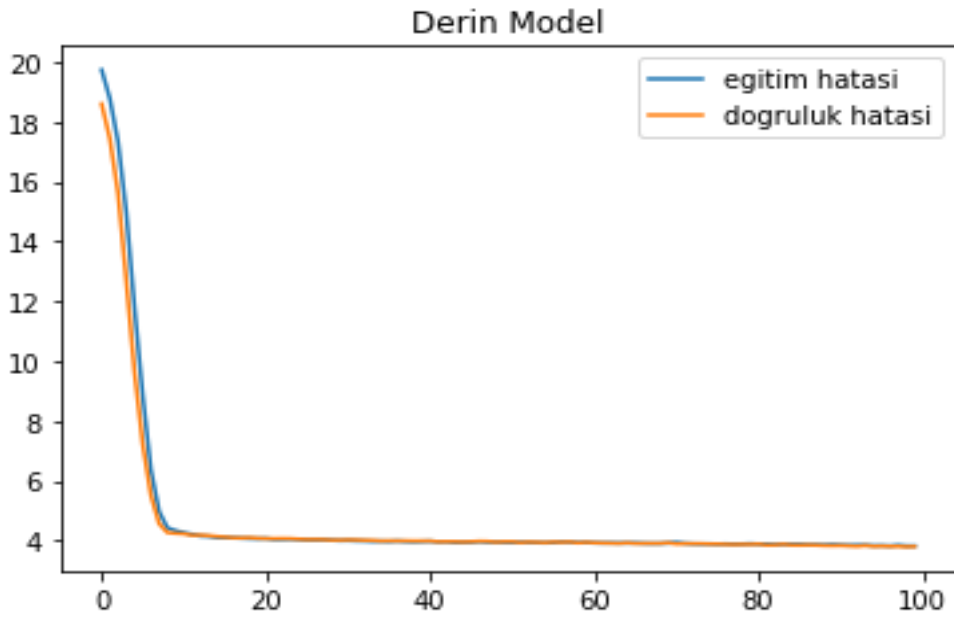
4.2. Derin ęrenme Sonuların Test Edilmesi ve Deęerlendirilmesi

Model-1'de eęitim hatası ve doęruluk hatasına grafik Şekil 4.3'de grlmektedir. Grafik incelendięinde Ortalama Hata 20'nin zerinde olmakla birlikte her ęrenme adımında loss deęerinde dşşler yaşınmış 4.7246'da sabit kalıp hata deęeri minimum dzeye gelmiş, ortalama tahmin deęerine yaklaştıęı grlmüştr.



Şekil 4.3 Model-1

Model-2’de eğitim hatası ve doğruluk hatasına grafik Şekil 4.4’de görülmektedir. Grafik incelendiğinde her öğrenme adımında loss değerinde düşüşler yaşandığı, 3.8696’da sabit kalıp hata değeri minimum düzeye geldiği ve ortalama tahmin değerine yaklaştığı görülmüştür.



Şekil 4.4 Derin Öğrenme Modeli-2

Her iki modelde aşırı öğrenme gerçekleşmemiş, iki modelinde iyi bir öğrenme gerçekleştirdiği, 2'nci modelde öğrenme modelinin daha iyi bir öğrenme gerçekleştirdiği görülmüştür. Daha iyi bir tahmin değerine ulaşmak için 2'nci modelin kullanılması uygun olacaktır. Başarı değerlerinin test aşamasında her iki model test edilmiştir.

```
sonuc = dogrusal_model.evaluate(test_set,test_labels)
sonuc2 = derin_model.evaluate(test_set,test_labels)
print(test_labels[:5])
print(derin_model.predict(test_set[:5]))
print(dogrusal_model.predict(test_set[:5]))
```

Yapay Sinir Ağları ve Derin Öğrenme ile yapılan tahmin sonuçlarının bir kısmı Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1 Ölçülen gerçek değerler ile tahmin edilen değerler

Ölçülen Değer	Tahmin (YSA)	Tahmin (DL)	Hata (YSA)	Hata (DL)
1,269	1,3018	1,1375	-0,0328	0,1315
1,455	1,4789	1,2821	-0,0239	0,1729
1,757	1,5483	1,789	0,2087	-0,032
0,573	0,6407	0,5429	-0,0677	0,0301
0,59	0,5684	0,5409	0,0216	0,0491
0,794	0,7529	0,6109	0,0411	0,1831
0,148	0,1546	0,1917	-0,0066	-0,0437
0,149	0,1529	0,1917	-0,0039	-0,0427
0,154	0,1521	0,2115	0,0019	-0,0575

5. TARTIŞMA ve SONUÇ

Tahmin, kesin bir süreç olmamakla birlikte, birtakım verilere dayanarak, gelecekteki bir olayın nasıl olacağını önceden öngörülmesidir. Tahmin modellemesi, karar vermede etkin bir rol oynamasından dolayı birçok alanda kullanılmaktadır. Yapay sinir ağları birçok alanda tahmin modellemesi için kullanılan yöntemlerden biri olmakla birlikte Derin Öğrenme algoritmaları da tahmin modeli geliştirmekte kullanılmaktadır. Bu kapsamda yapay sinir ağları ve derin öğrenme yöntemleri incelenmiş, uygulama alanları ve mimarileri tanıtılmıştır. Yapılan uygulamada YSA ve derin öğrenme modeli kullanılarak nanoliflerin çaplarının tahminine yönelik tahmin modelleri geliştirilmiştir.

Yapay Sinir Ağları ve Derin öğrenme algoritmalarını kullanarak nanolif çaplarının tahmini yapan bir uygulama örneği olarak yapılan çalışmada, laboratuvar ortamında elde edilen nanoliflerin SEM görüntülerinden derlenen ve normalizasyon işlemine tabi tutulan bir veri setinin modellerdeki sonuçları kıyaslanmış, nanolif çaplarını tahmin etmek için derin öğrenme ve yapay sinir ağları modellerinin performansı incelenmiştir. Çalışmada nanoliflerin çapını etkileyen 4 adet bağımsız değişken girdi değişkeni olarak, nanolif çap değerleri ise çıktı değişkeni olarak kullanılmıştır.

Yapılan çalışmanın başarısını ölçebilmek için ölçülen değerlerle Yapay Sinir Ağları ve Derin Öğrenmeden elde edilen tahmin sonuçları ile karşılaştırılmıştır. Yapay Sinir Ağı ve Derin Öğrenme modelinin ve tahmin işleminin eğitim, test ve doğrulama aşamalarındaki yüksek regresyon ve düşük MSE (Ortalama Hata Kareleri) değerleri başarılı bir şekilde gerçekleştiğini göstermiştir. Uygulama neticesinde eğitim ve hata grafikleri incelendiğinde, amaçlanan öğrenmenin gerçekleştirildiği görülmektedir.

Derin öğrenme ve yapay sinir ağları modeller ile gerçekleştirilen tahminde modellerin yüksek doğruluk ile tahmin gerçekleştirdiği belirlenmiştir. Derin Öğrenme yöntemleri yapay sinir ağlarının (YSA) yapısal olarak daha karmaşık halidir. Veri miktarının küçük olması nedeniyle Yapay Sinir Ağı modelinin Derin Öğrenme modeline göre daha başarılı olduğu değerlendirilmektedir.

Yapılan çalışma sonucunda bulunan sonuçlar; Yapay Sinir Ağları ve derin öğrenme

yöntemlerinin tahmin becerisi yüksek araçlar olarak görülmektedir. Nanoliflerin çaplarının belirlenmesinde laboratuvar ortamında kullanılan deney materyalleri üretimi önemli bir maliyet oluşturmaktadır. Yapay Sinir Ağları ve derin öğrenme yöntemlerinin yüksek tahmin becerisinden dolayı, geliştirilecek daha iyi modeller ile halihazırda yapılan testlerden daha az sayıda test yapmak, yüksek doğrulukta istenilen sonuçlara ulaşmak mümkün olabilecektir. Bu durum laboratuvar ortamında yapılan test maliyetlerin azalmasına imkân sağlayacaktır.



6. KAYNAKLAR

- Ağyar, Z, 2015, Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama, Mühendis ve Makine, 56(662), 22-23.
- Aluya, J, 2015, Nanotechnology Implications and Global Leadership Perspectives. Energy Sources, Part B: Economics, Planning, and Policy, 10(1), 31-37.44
- Arı, A, Berberler M E, 2017, Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı, Acta Infologica , 1 (2) , 55-73.
- Bayır, F, 2006, Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 122s, İstanbul,
- Bengio Y, 2009, Learning Deep Architectures for AI, Found. Trends® Mach. Learn., vol. 2, no. 1, pp. 1–127.
- Beypazar Ö, 2013, Nanolif Üretiminde Çap Kontrolü, Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 86s, Tekirdağ.
- Bhardwaj N, Kundu S C, 2010, Electrospinning: A Fascinating Fiber Fabrication Technique Biotechnology Advances, 28(3), 325-347.
- Bouman, H, 2003, Release on Command: Bio-switch. Newsletter of TNO Nutrition and Food Research, 4-5.
- Bryksa B C, Yada R Y, 2012, Nanotechnology: The Word is New But The Concept is Old. An Overview of The Science and Technology in Food and Food Products at The Nanoscale Level, International Journal of Food Studies 1 (2), 188-210.
- Cengiz F, Krucinska I, Göktepe F, Glinscinska E, Chrzanowski M, 2006, Elektro Lif Çekim (Electrospinning) Yönteminde Proses Parametrelerinin Nano Lif Özellikleri Üzerindeki Etkilerinin İncelenmesi, Tekstil Maraton, 4:20-25.
- Çuhadar M, 2006, Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Doktora Tezi, 188s, Isparta.
- Dasdemir M, Maze B, Anantharamaiah N, Pourdeyhimi, B, 2012, Influence of polymer

type, composition, and interface on the structural and mechanical properties of core/sheath type bicomponent nonwoven fibers, *Journal of Materials Science*, 47(16), 5955-5969.

Deitzel J M, Kleinmeyer J, Harris D, Becktan N C, 2001, The Effect of Processing Variables on the Morphology of Electrospun Nanofibers and Textiles. *Polymer*, 42:261–272, 2001.

Deng L, Yu D, 2014, Deep Learning: Methods and Applications, *Found Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387.

Desai S B, Madhvapathy S R, Sachid A B, Llinas J P, Wang Q, Ahn G H, Javey A, 2016, MoS₂ Transistors with 1-Nanometer Gate Lengths, *Science*, 354(6308), 99-102.

Dörtler A, 2018, Elektrosinning Yöntemiyle B₂O₃ (Bor Oksit) ve B₄C (Bor Karbür) Nanofiber Sentezi ve Kompozitlerinin Hazırlanması, Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 76s, Antalya.

Elmas Ç, (2012), Yapay Zeka Uygulamaları, Yapay Sinir Ağları-Bulanık Mantık-Genetik Algoritma, Seçkin Yayınevi, 424, Ankara.

Elmas Ç, 2004, Yapay Zekâ, *Popüler Bilim*, Sayı:124.

Erdem S, Gülel G T, 2015, Gıda Endüstrisinde Nanoteknoloji Uygulamaları, *Etlük Veteriner Mikrobiyoloji Dergisi*, 26(2), 52-57.

Erken Ş, 2017, Veri Madenciliği Yöntemleri ve Optimizasyona Dayalı Modeller Üzerine Bir Araştırma ve Bir Uygulaması, Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 106s, İzmir.

Erkoç Ş, 2007, Nanobilim ve Nanoteknoloji (2 b.). Ankara: ODTÜ Geliştirme Vakfı Yayıncılık ve İletişim A.Ş.

Ersöz F, 2019, Veri Madenciliği Teknikleri ve Uygulamaları (3. Baskı ed.), Seçkin Yayınevi, 303, Ankara.

Ersöz M, Işıtan A, Balaban M, 2018, Nanoteknoloji 1: Nanoteknolojinin Temelleri, 274s, Denizli.

Ertem M, 2022, Bir Savunma Sanayi Firmasında Depo Bölgesi Atama Sisteminin Veri

- Madenciligi ve Makine Öğrenme Yaklaşımlarıyla İyileştirilmesi, Avrupa Bilim ve Teknoloji Dergisi, (34), 501-506.
- Esfahani H, Jose R, Ramakrishna S, 2017, Electrospun Ceramic Nanofiber Mats Today: Synthesis, Properties, and Applications, Materials, 10 (11): 1238.
- Goodfellow I, 2016, Nips 2016 tutorial: Generative Adversarial Networks, arXiv preprint arXiv:1701.00160.
- Greff K, Srivastava R K, Koutník J, Steunebrink B R, Schmidhuber J, 2015, LSTM: A Search Space Odyssey.
- Hatiboğlu B, 2006, Mechanical Properties of Individual Polymeric Micro and Nano Fibers Using Atomic Force Microscopy (AFM), M.Sc. Thesis, North Carolina State University, p.1-128.
- Hinton, G E, Salakhutdinov R R, 2006, Reducing the Dimensionality of Data With Neural Networks, Science, 313(5786), 504– 507.
- Hosokawa M, 2007, “Nanoparticle technology handbook”, Elsevier, 622s, Amsterdam.
- İpek M, Canbolat M, 2017, Farklı Tipteki Toplayıcı Plakaların Elektrostatik Çekim ile Elde Edilen Nanoliflerin Morfolojisi Üzerine Etkilerinin Araştırılması, Science and Engineering Journal of Fırat University, 29(1), 161-170.
- Keskinateş M, 2017, Farklı Fonksiyonel Gruplara Sahip Kaliksaren Temelli Poliakrilonitril Nanofiberlerin Sentezi ve Protein Adsorpsiyon Çalışmaları, Karamanoğlu Mehmetbey Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 130s, Karaman.
- Koski A, Yim K, Shivkumar S, 2004, Effect of Molecular Weight on Fibrous PVA Produced by Electrospinning. Materials Letters, 58 (3-4): 493-497.
- Körözlü N, 2016, Bilim ve Teknolojinin Geleceği Nanoteknoloji. Ayrıntı Dergisi, 4(S 39), 27-30.
- Kuruca B., 2012, Nanotıp ve Nanoteknoloji, Net Bilim Dergisi, 14 (1): 17-23.
- Kut D, Güneşoğlu C, 2005, Nanoteknoloji ve Tekstil Sektöründeki Uygulamaları. Tekstil&Teknik, Şubat, 224-230.
- LeCun Y, Bengio Y, Hinton C, 2015, Deep Learning, Nature, vol. 521, pp. 436–444.

- Lee K H, Kim D J, and Min B G, 2007, Polymeric Nanofiber Webbased Artificial Renal Microfluidic Chip, *Biomed Microdevices*. 9:435–442.
- Li Z, Wang C, 2013, *One-Dimensional Nanostructures: Electrospinning Technique and Unique Nanofibers*. Berlin, Heidelberg: Springer.
- Lim Y, Gwon H, Jeun J, Nho C., 2010, Preparation of Cellulose-Based Nanofibers Using Electrospinning. Research Gate, DOI: 10.5772/8153.
- Luo M, Wang H, Wang Z, Cai H, Lu Z, Li Y, Gao J, 2017, A Sting-Activating Nanovaccine For Cancer Immunotherapy. *Nature Nanotechnology*, 12(7), 648-654.
- Mencelođlu Y, Kırca M, 2008, Uluslararası Rekabet Stratejileri: Nanoteknoloji ve Türkiye, Yayın No: TÜSİAD-T/2008-11/474.
- Mikolov T, Recurrent neural network based language model, in *Interspeech*.
- Nabiyev, V V, 2016, *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi (5. Baskı)* Ankara: Seçkin Yayıncılık.
- Özak, S T, Özkan P, 2013, Nanotechnology and Dentistry. *European Journal of Dentistry*, 7(01), 145-151.
- Özdođan E, Demir A, Seventekin N, 2006, Nanoteknoloji ve Tekstil Uygulamaları. *Tekstil ve Konfeksiyon*, 16(3), 160-168.
- Özer Y, 2019, Nanoteknoloji'nin Askerî Uygulamaları Üzerine Bir Deđerlendirme, *Güvenlik Bilimleri Dergisi*, 33-52.
- Öztemel E, 2012, *Yapay Sinir Ağları*, Papatya Yayıncılık, 232, İstanbul.
- Öztemel, E, 2015, *Yapay Sinir Ağları*, 3.Cilt, Papatya Yayıncılık, 232, İstanbul.
- Ramalingam M, Ramakrishna S, 2017, Introduction to Nanofiber Composites. In *Nanofiber Composites for Biomedical Applications*, USA: Elsevier, 3-26.
- Rao M A, 2009, Nanoscale Particles in Food and Food Packaging, *Journal of food Science* 74.9 (2009): viii-viii.
- Rashidi L, Khosravi-Darani K, 2011, The Applications of Nanotechnology in Food Industry, *Critical Reviews in Food Science* 51 (8), 723-730.

- Ravi D, Wong C, Deligianni F, Berthelot M, Andreu-Perez J, Lo B, Yang G Z, 2017, "Deep Learning for Health Informatics". IEEE Journal of Biomedical and Health Informatics 21(1), 4-21.
- Schodek D L, Ferreira P, Ashby M F, 2009, Nanomaterials, Nanotechnologies and Design: An Introduction for Engineers and Architects. Butterworth-Heinemann.
- Sekhon B S, 2010, "Food nanotechnology–an overview." Nanotechnology, science and applications 3:1.
- Sekhon B S, 2014, Nanotechnology in Agri-Food Production: An Overview. Nanotechnology Science and Applications 7:31-53.
- Sevinç A, Kaya B, 2021, "Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneği, Journal of Computer Science, 217-225.
- Sevinç E, 2017, "Nanoteknoloji İnovasyon Sistemi: Türkiye Tekstil Sektörü Örneği, Anadolu Üniversitesi Sosyal Bilimler Dergisi, 19(2), 23-48.
- Süpüren G, Kanat Z, Çay A, Kırıcı T, 2007, "Nanolifler (Bölüm 2), Tekstil ve Konfeksiyon Dergisi, 2:83-89.
- Şahin O Z, 2019, "Nanoteknolojik Ürünlerin Giydirme Cephe Sektörü Bağlamında Araştırılması, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi,85s, Balıkesir.
- Şenocak F, Kahveci H, 2016, "Gün Öncesi Piyasasında PTF Dönemsel Ağırlıklı Fiyat Ortalama Tahmini, Dokuz Eylül Üniversitesi, Mühendislik Fakültesi Fen ve Mühendislik Dergisi , 23 (67) , 93-105.
- Şenol F, Tayyar E, Doğan G, 2005. "Nanolifler ve Uygulama Alanları. Tekstil Maraton, 15(78), 20 - 27.
- Şeyda C, 2007, "Nanoteknoloji ve Tekstilde Uygulama Alanları, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 182s, Adana.
- Tarafdar J C, Sharma S, Raliya R, 2013, "Nanotechnology: Interdisciplinary science of applications, African Journal of Biotechnology 12 (3), 219-226.
- Tolochko N K, 2009, "History of Nanotechnology. In: Kharkin, V., Bai, C., Awadelkarim, O.O, Kapitsa, S. (Eds.), Nanoscience and Nanotechnology.

- UNESCO, Oxford, UK, EOLSS, Encyclopedia for Life Support Systems.
- TÜSİAD, 2008, Uluslararası Rekabet Stratejileri: Nanoteknoloji ve Türkiye, Türkiye Rekabet Stratejileri Dizisi-11, TÜSİAD Yayınları, İstanbul, 2008, s. 30.
- Tüylek Z, 2016, Küçük şeylerin hikâyesi: Nanomalzeme, Nevşehir Bilim ve Teknoloji Dergisi, 5(2), 130-141.
- Uldrich J, Newbeyrry D, 2005, Nanoteknoloji Gelecekteki İşlerinizi Nasıl Değiştirecek, Sıradaki Büyük şey Aslında Çok Küçük,(Çev. Tolga Alıcı), İstanbul, Ledo Yayınları.
- Umut K, Yılmaz A, Dikmen Y, 2019, Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri, Avrupa Bilim ve Teknoloji Dergisi, (16), 792-808.
- Wolfgang F K, 2004, Nanotechnology: an Introduction to Nanostructuring Techniques”, Wiley-VCH, 272s, Weinheim.
- Yalçın M, 2020, Elektroçirime Yöntemi ve Nanofiber Üretimi, Türkiye'de Mühendislik ve Fen Bilimlerinde Akademik Araştırmalar, 47.
- Yan J, Han L, Gao W, Xue S, Chen M, 2016, Biochar Supported Nanoscale Zero Valentiron Compositeused as Persulfate Activator for Removing Trichloroethylene, Bioresour Techn. 175:269-274.
- Yener F, 2010, Klasik ve İğnesiz Elektrosinning Yöntemleriyle Elde Edilen Nano Liflerin Kıyaslanması ve Bu Yöntemlerdeki Sistem Parametrelerinin Lif Üzerindeki Etkileri, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 54s, Kahramanmaraş.
- Yıldırım N, 2018, Nanoteknoloji ve Geleceğin Çevreci Polimeri Nanoselüloz. Ormancılık Araştırma Dergisi, 5(2), 185-195.
- Yuan X, Zhang Y, Dong C, Sheng J, 2004, Morphology of Ultrafine Polysulfone Fibers Prepared by Electrosinning. Polymer International, 53 (11): 1704-1710.
- Yücesoy M, 2011, Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, 155s, Yüksek Lisans Tezi.
- Zor E, 2016, Grafen Tabanlı Modifiye Elektrotların Kiral Yapıları Ayırt Etme

Özelliklerinin İncelenmesi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü,
Doktora Tezi, 156s, Konya.

İnternet Kaynakları

- 1- https://www.mfa.gov.tr/unam-_malzeme-bilimi-ve-nanoteknoloji-enstitusu_-nanobilim-ve-nanoteknolojide-turkiye_nin-bir-mukemmeliyet-merkezi-.tr.mfa,
01.06.2022
- 2- <http://nanoturkiye.blogspot.com/2008/02/nano-101-nanoteknolojinin-tarihi.html>,
01.06.2022
- 3- <https://nano.aku.edu.tr/2016/05/12/nano-4/>, 01.06.2022
- 4- <https://www.kuark.org/2011/05/nanoteknolojinin-tarihi/>, 01.06.2022
- 5- <https://tekstilbilgi.net/nanolifler-ve-ozellikleri.html> , 07.06.2022
- 6- https://documen.site/download/elektrospinning-elektro-ekim-yntemi_pdf,
07.06.2022
- 7- <http://kod5.org/yapay-sinir-aglari-ysa-nedir/> 07.06.2022
- 8- <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/>
08.06.2022
- 9- <https://www.gtech.com.tr/yapay-sinir-aglari-ve-uygulamalari-1/> 08.06.2022
- 10- <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> 08.06.2022
- 11- <https://ckk.com.tr/ders/ML.html> / 09.06.2022
- 12- <https://alitunacanor.medium.com/derin-%C3%B6%C4%9Frenme-y%C3%B6ntemleri-ve-uygulamalar%C4%B1-1ce215de40e8> / 09.06.2022
- 13- <https://research.google.com/colaboratory/intl/tr/faq.html> / 08.06.2022
- 14- <https://bilginc.com/tr/blog/158/python-nedir-python-hakkinda-hersey> (15.06.2022)