

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KAUÇUK BİLEŞİKLERİNİN MEKANİK ÖZELLİKLERİNİN
YAPAY ZEKA TEKNİKLERİ İLE TAHMİN EDİLMESİ VE
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

Furkan TİTİZ

Endüstri Mühendisliği Anabilim Dalı

MART 2023

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KAUÇUK BİLEŞİKLERİNİN MEKANİK ÖZELLİKLERİNİN
YAPAY ZEKA TEKNİKLERİ İLE TAHMİN EDİLMESİ VE
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

Furkan TİTİZ

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Alper KİRAZ

MART 2023

Furkan Titiz tarafından hazırlanan “Kauçuk Bileşiklerinin Mekanik Özelliklerinin Yapay Zeka Teknikleri ile Tahmin Edilmesi ve Karşılaştırmalı Analizi” adlı tez çalışması 29.03.2023 tarihinde aşağıdaki jüri tarafından oy birliği/~~oy çokluğu~~ ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı **Endüstri Mühendisliği** Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Doç. Dr. Merve CENGİZ TOKLU Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Alper KIRAZ (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Caner ERDEN Sakarya Uygulamalı Bilimler Üniversitesi	

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “KAUÇUK BİLEŞİKLERİNİN MEKANİK ÖZELLİKLERİNİN YAPAY ZEKA TEKNİKLERİ İLE TAHMİN EDİLMESİ VE KARŞILAŞTIRMALI ANALİZİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

29/03/2023

Furkan Titiz





Canim aileme...



TEŐEKKÖR

Yüksek lisans eğitimin boyunca desteęini esirgemeyen aileme, Yüksek Lisans Tezi yazım sürecinde beni yönlendiren değerli danışmanım Doç. Dr. Alper KİRAZ'a ve bu çalışmanın hazırlanmasında benden desteęini esirgemeyen Yüksek Endüstri Mühendisi Zeynep URUK AKIN'a ve Ceren BAŐARAN'a teşekkürlerimi sunarım.



Furkan Titiz



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR.....	ix
İÇİNDEKİLER	xi
KISALTMALAR.....	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
SUMMARY	xxiii
1. GİRİŞ.....	1
1.1. Tezin Kapsamı.....	2
1.2. Tezin Amacı	2
1.3. Literatür Araştırması	3
2. KAÜÇUK KİMYASI VE ÖZELİKLERİ.....	9
2.1. Kauçuk Bileşiklerini Oluşturan Hammaddeler	9
2.1.1. Doğal kauçuk	9
2.1.2. Sentetik kauçuklar.....	10
2.1.2.1. Stiren bütadien kauçuk.....	10
2.1.2.2. Bütil kauçuk	10
2.1.2.3. Bütadien kauçuk.....	11
2.1.2.4. Nitril kauçuk.....	11
2.1.2.5. Neopren	11
2.1.2.6. Poliizopren	11
2.1.2.7. Etilen Propilen Dien Monomer	12
2.1.2.8. Kloropen kauçuk	12
2.1.2.9. Klorobutil ve bromobutil.....	12
2.1.3. Dolgular	12
2.1.3.1. Karbon siyahı	13
2.1.3.2. Silika	13
2.1.4. Proses kolaylaştırıcılar	13
2.1.5. Vulkanizasyon ajanları.....	14
2.1.6. Vulkanizasyon hızlandırıcıları	14
2.1.7. Vulkanizasyon aktivatörleri	14
2.1.8. Geciktiriciler ve vulkanizasyon inhibitörleri	15
2.1.9. Antidegradantlar.....	15
2.2. Kauçuk Bileşik Hazırlama.....	15
2.2.1. Banbury	16
2.2.2. Kauçuk karışımların mekanik özellikleri	16
2.2.2.1. Sertlik	16

2.2.2.2. Aşınma	17
2.2.2.3. Çekme mukavemeti.....	17
2.2.2.4. Yırtılma mukavemeti.....	17
3. YÖNTEM.....	19
3.1. Yapay Sinir Ağları (YSA).....	19
3.2. Karar Ağaçları	25
3.2.1. Karar ağaçlarında temel kavramlar	26
3.2.1.1. Düğümler.....	26
3.2.1.2. Dallar.....	27
3.2.1.3. Bölme	27
3.2.1.4. Durdurma	27
3.2.2. Karar ağacı algoritmaları ve CART algoritması	28
3.3. Topluluk Öğrenimi	30
3.3.1. Bagging (torbalama) algoritması.....	30
3.3.2. Boosted (artırma) algoritması.....	31
4. ARAŞTIRMA BULGULARI	33
5. SONUÇ VE ÖNERİLER	51
KAYNAKLAR.....	53
ÖZGEÇMİŞ.....	57

KISALTMALAR

ACN	: Akrilonitril
ÇDR	: Çoklu Doğrusal Regresyon
DSA	: Derin Sinir Ağı
DVMR	: Destek Vektör Makine Regresyonu
GİR	: Gauss İlerleme Regresyonu
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MBT	: Merkezi Bileşik Tasarım
MSE	: Ortalama Hata Karesi
PSI	: Pounds Per Square Inch
RMSE	: Kök Ortalama Kare Hata
RO	: Rastgele Orman
SBR	: Stiren Bütadien Kauçuk
TÖ	: Topluluk Öğrenimi
YSA	: Yapay Sinir Ağı



SİMGELER

R^2 : Çoklu belirlilik katsayısı

$^{\circ}\text{C}$: Celsius

$\ln$: Logaritma

e : Euler Sayısı

Δ : Delta

α : Alfa





TABLO LİSTESİ

Sayfa

Tablo 3.1. Biyolojik sinir sisteminde yer alan elemanların yapay sinir ağlarında karşılıkları [26].....	21
Tablo 3.2. Bagging algoritmasının sözde kodu	31
Tablo 3.3. AdaBoost algoritmasının sözde kodu.....	32
Tablo 4.1. Sertlik özelliği için normallik testi sonucu.....	34
Tablo 4.2. Çekme mukavemeti özelliği için normallik testi sonucu	35
Tablo 4.3. Kopma uzama özelliği için normallik testi sonucu	35
Tablo 4.4. Yırtılma mukavemeti özelliği için normallik testi sonucu.....	36
Tablo 4.5. Kauçuk bileşiklerin mekanik özellikleri için normallik testi sonuçları ...	36
Tablo 4.6. Her bir mekanik özellik için yapılan korelasyon testi sonucu	37
Tablo 4.7. Sertlik için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi	39
Tablo 4.8. Çekme mukavemeti için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi.....	39
Tablo 4.9. Yırtılma mukavemeti için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi.....	40
Tablo 4.10. Sertlik özelliği için gizli katman ve nöron sayısının belirlenmesi	41
Tablo 4.11. Çekme mukavemeti için gizli katman ve nöron sayısının belirlenmesi.	41
Tablo 4.12. Yırtılma mukavemeti için gizli katman ve nöron sayısının belirlenmesi	42
Tablo 4.13. Mekanik özellikler için belirlenen yapay sinir ağı parametreleri.....	42
Tablo 4.14. Yapay sinir ağlarının ortalama MSE ve R^2 tahmin performansı.....	43
Tablo 4.15. Yapay sinir ağlarının ortalama R^2 tahmin performanslarının standart sapması.....	43
Tablo 4.16. Regresyon ağaçları ortalama MSE-MAPE değerleri	44
Tablo 4.17. Regresyon ağaçları için hesaplanan R^2 ve R^2 değerlerine ait standart sapmalar	45
Tablo 4.18. Ağaç toplulukları ile yapılan tahminlemelerin MSE ve MAPE performansları	47
Tablo 4.19. Ağaç toplulukları tekniğinin ortalama R^2 değerleri ve bu değerlere ait standart sapmalar.....	48
Tablo 4.20. Tahminlemede kullanılan 3 farklı yapay zekâ tekniğinin R^2 performanslarının karşılaştırılması.....	49



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. Biyolojik sinir hücresi ve YSA [26].	20
Şekil 3.2. Geri yayımlı YSA örneği [26]	22
Şekil 3.3. Yapay sinir ağları genel yapısı [27]	22
Şekil 3.4. Geri yayımlı YSA [25]	24
Şekil 3.5. Geri yayılım algoritmasının hesaplanan hatayı yayma yönü [27]	25
Şekil 3.6. Bir karar ağacı modeli örneği [28]	26
Şekil 4.1. Uygulamada kullanılacak girdiler, yapay zekâ teknikleri ve planlanan çıktı sonuçları	33
Şekil 4.2. Sertlik özelliği değerlerine ait histogram grafiği	34
Şekil 4.3. Çekme mukavemeti özelliği değerlerine ait histogram grafiği	35
Şekil 4.4. Kopma uzama özelliği değerlerine ait histogram grafiği	36
Şekil 4.5. Yapay sinir ağı ile tahminleme akış şeması	38
Şekil 4.6. Regresyon ağaçları ile tahminleme akış şeması	43
Şekil 4.7. Ağaç toplulukları yöntemi için akış şeması	46



KAUÇUK BİLEŞİKLERİNİN MEKANİK ÖZELLİKLERİNİN YAPAY ZEKA TEKNİKLERİ İLE TAHMİN EDİLMESİ VE KARŞILAŞTIRMALI ANALİZİ

ÖZET

Kauçuk, keşfedildiği 15. yüzyıldan bu yana endüstride ve günlük yaşantıda farklı alanlarda sıklıkla kullanılan bir malzeme olmuştur. Elastik yapısı, aşınmaya karşı direnci, su geçirmez özelliği sayesinde kauçuk, modern yaşamda farklı sektörler için hayati bir öneme sahiptir. Lastik üretiminde, kayış ve conta üretiminde, konveyör bant üretiminde yoğun olarak kullanılan kauçuk, farklı dolgu malzemeleri, kimyasallar ve proses kolaylaştırıcılar ile bileşik haline getirilip, işlenerek hizmete sunulur. Kullanılacağı alanın gereksinimlerini karşılaması önemli olduğu için, kauçuk bileşik üretiminin başlangıcından sonuna kadar bir dizi gereksinim testleri yapılır. Yapılan bu testler ile kauçuk bileşiklerinin reolojik ve mekanik özellikleri belirlenir. Kauçuk bileşiklerinin mekanik özellikleri, zaman alıcı ve pahalı laboratuvar çalışmaları ile belirlenir. Öte yandan günümüzde oldukça popüler olan yapay zekâ yaklaşımları, herhangi bir numuneye veya laboratuvar deneyine ihtiyaç duymadan, kauçukların mekanik özelliklerini saniyeler içerisinde tahmin etmek için kullanılabilir.

Bu çalışmada, kauçuğun mekanik özelliklerinden olan sertliği, çekme mukavemetini, kopma uzamayı ve kauçuk bileşiklerinin yırtılma mukavemeti test değerlerini tahmin etmek için yapay sinir ağları, regresyon ağaçları ve topluluk öğrenimi teknikleri kullanılmıştır. Kauçuk bileşiklerinin, proses parametreleri ve hammadde bileşimleri, bu çalışmada seçilen yapay zekâ tekniklerinde girdi olarak kullanılmıştır. Veri seti 76 farklı kauçuk bileşiği formülasyonundan oluşmaktadır. 76 farklı kauçuk bileşiği formülasyonu ve test değerleri üzerinde normallik testi yapılmıştır. Daha sonrasında veri setinde girdi olarak yer alan 29 hammadde kg ağırlıkları ve dk cinsinden proses süreleri ele alınarak test değerleri üzerindeki korelasyon ilişkisine bakılmıştır. Sertlik, çekme mukavemeti ve yırtılma mukavemeti test değerleri üzerinde anlamlı değişikliğe yol açan hammaddeler belirlenirken, kopma uzama test değerleri üzerinde hiçbir hammadde ve proses süresinin anlamlı bir değişikliğe yol açmadığı görülmüştür. Mekanik özelliklerin test değerleri üzerinde anlamlı olarak belirlenen hammaddeler her bir mekanik özellik için seçilerek veri seti her mekanik özellik için ayrı olarak oluşturulmuştur.

Oluşturulan veri setleri, yapay sinir ağları, regresyon ağaçları ve topluluk öğrenimi yöntemlerinden olan ağaç topluluklarında girdi ve çıktı verileri olarak kullanılmıştır. Her bir yapay zeka tekniğinde oluşturulan modellerin performansını karşılaştırmak için ortalama hata karesi (MSE), ortalama mutlak yüzde hatası (MAPE) ve çoklu belirlilik katsayısı (R^2) değerleri hesaplanmıştır. Hesaplanan bu değerler sonucunda ağaç toplulukları modellerinin sertlik, çekme mukavemeti ve yırtılma mukavemeti test değerlerini tüm veri seti için $R^2 = 0,99$ olarak tahmin ettiği görülmüştür ve değerin 1'e yakın olması tahminin güçlü olduğunu göstermiştir.

Regresyon ağaçları ise sertlik için $R^2 = 0.96$, çekme mukavemeti için $R^2 = 0.98$ ve yırtılma mukavemeti için $R^2 = 0.97$ olarak hesaplanmıştır. Yapay sinir ağları ise belirlenen girdi ve çıktı değerleri ile başarılı olarak kabul edilebilecek bir R^2 değeri bizlere sunmamaktadır. Çalışmanın sonucunda kauçuk bileşiklerin mekanik test özelliklerinin tahmininde ağaç toplulukları ve regresyon ağaçlarının kullanılabileceği görülmüştür.



A COMPARATIVE STUDY WITH ARTIFICIAL INTELLIGENCE TECHNIQUES TO ESTIMATE MECHANICAL PROPERTIES OF RUBBER COMPOUNDS

SUMMARY

Since its discovery in the 15th century, rubber has been a material that is frequently used in different fields in industry and daily life. Thanks to its elastic structure, resistance to abrasion and waterproof feature, rubber has a vital importance for different sectors in modern life. processed and put into service. Since it is important that it meets the requirements of the area in which it will be used, a series of requirements tests are performed from the beginning to the end of rubber compound production. With these tests, the rheological and mechanical properties of rubber compounds are determined. The mechanical properties of rubber compounds are determined by time-consuming and expensive laboratory work. On the other hand, artificial intelligence approaches, which are very popular today, can be used to predict the mechanical properties of rubbers in seconds, without the need for any samples or laboratory experiments.

In this study, the test values of the mechanical properties of rubber and the parameters used to control the quality and process standards of rubber products produced in the industry, the hardness, tensile strength, elongation and tear strength of rubber compounds, which are measured with test devices suitable for use in the laboratory and expected to take place in the predetermined test intervals, are determined. Artificial intelligence techniques such as artificial neural networks, regression trees and ensemble learning, which are very popular today, have been used to predict predictions.

The process time parameters in minutes, including the mixing times of the rubber compounds of the rubber products that form a part of the tire industry such as motorcycle tires, bicycle tires, agricultural agricultural vehicles tires in the industry, called Banbury, and the weights in kilograms of the raw materials used in the production of these rubber compounds, the artificial Artificial neural networks, regression trees and ensemble learning techniques, which are among the intelligence techniques, are used as algorithm input dataset. The dataset consists of 76 different rubber compound formulations used in tire production. After the dataset was prepared as input, a normality test was performed on the compounds and test values in 76 different rubber compound formulations in order to create correct analyzes in correlation analysis. Then, by considering the 29 raw material kg weights and the process times in minutes as input in the data set, the correlation relationship of the mechanical properties of each of the raw material and process parameters on the test values was examined in order to determine the raw materials and process times to be selected for use in artificial intelligence techniques.

As a result of the correlation analysis, while the raw materials that cause significant changes on the hardness, tensile strength and tear strength test values were determined, it was seen that the process parameters did not cause a significant change on these test values. It was observed that no raw material and process time did not cause a significant change on the Tensile elongation test values, which is another selected mechanical property. The raw materials that were determined to cause a significant change on the test values of the mechanical properties were handled and used to create the data set for hardness, tensile strength and tear strength. In this way, the data set, which is provided as input to the artificial intelligence techniques to be predicted, has been prepared with data that creates a meaningful change on the test values. For one of the mechanical properties, elongation, this mechanical property was not considered in the estimation, as it was seen that it did not cause a significant change on any raw material and process parameter.

The datasets created for stiffness, tensile strength and tear strength were first used for prediction in artificial neural networks. The algorithm parameters to be used in each mechanical feature of the artificial neural networks to be used in the study were determined. First, the learning algorithm and transfer function of the artificial neural networks to be used in the prediction of mechanical properties are determined. Levenberg-Marquart, Bayesian Networks and Scaled Conjugate Gradient learning algorithms and tan-sigmoid, log-sigmoid and radial basis functions, which are transfer functions, were tested in artificial neural networks created with empirically determined hidden layer and 5 neurons. According to the estimation results, learning algorithm and transfer function were determined separately for hardness, tensile strength and tear strength. While making these determinations, each artificial neural network was run 50 times and the mean squared error (MSE) and mean absolute percentage error (MAPE) values of the data used as test data in the estimation were examined. By comparing these values, the learning algorithm and transfer function were determined for each mechanical property to be estimated. After the learning algorithm and transfer functions are determined, in order to determine the number of hidden layers that will provide the best prediction performance in the artificial neural networks and the number of neurons in each layer, hypothetically 1-layer artificial neural networks with 5, 10, 20 neurons, respectively, and 2-layer and artificial neural networks have been created in a way that each layer will have 5, 10 and 20 neurons, respectively. Each artificial neural network created was run 50 times. MSE and MAPE values are considered to compare the prediction performances of the operated networks. The best performing hidden layer and neuron numbers from these values were determined for each mechanical property. With the learning algorithm, transfer function, number of hidden layers and number of neurons determined for each mechanical property, artificial neural networks were created for mechanical properties and predictions were made by running 50 times. For the regression trees technique, data sets prepared for each mechanical property were used as inputs. In order to test the number of leaves that will achieve the best prediction performance for each mechanical property, regression tree models with 4 leaves, 12 leaves and 36 leaves were created, respectively, and MSE, MAPE and multiple coefficient of determination (R^2) values were obtained by running 50 times.

The tree ensemble method, which is one of the ensemble learning methods, is very similar to the regression trees.

For each mechanical feature, models with 4, 12, and 36 leaves were created, as in the number of leaves regression trees, respectively, which will provide the best performance for each mechanical feature. Estimation was made by running the models created with the number of leaves 50 times and MSE, MAPE and R² values were checked to measure the results of the prediction performance.

MSE, MAPE and R² values are discussed to compare the performance of the models created in each artificial intelligence technique. As a result of these calculated values, it was seen that the tree assemblage models estimated the hardness, tensile strength and tear strength test values as R² = 0.99 for the whole data set, and the value close to 1 showed that the estimation was strong. Regression trees were calculated as R² = 0.96 for hardness, R² = 0.98 for tensile strength and R² = 0.97 for tear strength. Artificial neural networks, on the other hand, do not offer us an R² value that can be considered successful with the determined input and output values. As a result of the study, it was seen that tree assemblages and regression trees could be used to predict the mechanical test properties of rubber compounds.



1. GİRİŞ

1800'lü yılların ortalarında, kauçuk, Avrupalı araştırmacılar tarafından keşfedilmiş ve üretimi yapılmaya başlanmıştır. Bu keşif ile kauçuk üretimi büyük ölçüde artmıştır ve kauçuk, çeşitli alanlarda kullanılmaya başlanmıştır. Kauçuğun en yoğun kullanım alanı, lastik üretimi olmuştur. Lastikler, otomobil, bisiklet ve diğer taşıtların tekerleklerinde kullanılmaktadır ve esnek yapıları ile yol koşullarına kendilerini adapte edebilmektedirler. Kauçuk, ayrıca şişme botlar, balonlar, kayışlar, contalar ve diğer çeşitli ürünlerin üretiminde de kullanılmaktadır. Günümüzde, kauçuk üretimi hala önemli bir sektör olup, özellikle Brezilya, Endonezya ve Malezya gibi tropikal iklimlere sahip ülkelerde büyük miktarlarda üretilmektedir.

Kauçuğun, esneklik ve yumuşaklık özellikleri onu popüler bir malzeme yapmıştır. Kauçuğun esneklik özelliği, aşınmaya ve deforme olmaya karşı dayanıklı olmasını sağlar. Ayrıca, kauçuk, yüksek gerilme koşullarında bile esnek kalabilir ve eski haline dönebilir. Kauçuk, aynı zamanda yüksek sıvı geçirgenlik özelliğine de sahiptir. Bu özellik, kauçuğun su, gaz ve diğer sıvıları emmesine ve bunları tutmasına olanak verir.

Kauçuk, ısıya ve ışığa da dayanıklıdır. Kauçuğun ısıya dayanıklılığı, çeşitli sıcaklık koşullarında kullanılabilirliğini sağlar. Işığa dayanıklılığı ise, güneş ışığı gibi yüksek ışığa maruz kalınan koşullarda kauçuğun bozulmamasını sağlar. Kauçuk, sürtünme katsayısı ve elastik modül gibi özelliklerine göre de sınıflandırılmaktadır. Bu özellikler, kauçuğun endüstride ve hizmet sektöründe kullanım alanlarını ve uygulamalarını belirlemektedir. Kauçuğun reolojik ve mekanik olarak 2 alt kategoride incelenen spesifik özellikleri bulunmaktadır. Bu özellikleri, bir dizi test süreçleri ile laboratuvar ortamlarında belirlenir. Bu laboratuvar çalışmaları uzun ve maliyetli test süreçlerini içerir. Günümüzde oldukça popüler olan yapay zekâ teknikleri ile herhangi bir numuneye veya laboratuvar testine ihtiyaç duymadan, hızlı bir şekilde kauçuk bileşiklerinin mekanik özellikleri tahmin edilebilir.

Bu çalışmada, kauçuğun hammadde bileşimleri ve kauçuğun işleme parametreleri girdi olarak kullanarak kauçuk bileşiklerinin mekanik özelliklerinden olan sertliğinin, çekme mukavemetinin ve yırtılma mukavemetinin tahmin edilmesi için yapay sinir ağları (YSA), regresyon ağaçları ve ağaç toplulukları teknikleri kullanılmıştır.

1.1. Tezin Kapsamı

Bu çalışmada, lastik üretiminde kullanılan kauçuk bileşik formülasyonlarının, bileşikte kullanılan her bir hammaddenin kilogram ağırlığı ve proses parametreleri girdi, bu kauçuk bileşiklerinin mekanik test özelliklerinin (sertlik, çekme mukavemeti, kopma-uzama ve yırtılma mukavemeti) değerleri ise çıktı olarak ele alınarak, istatistiksel analiz sonucunda her bir mekanik özellik için girdi değişkenleri belirlenmiştir, yapay zeka tekniklerinden olan YSA, regresyon ağaçları ve topluluk öğrenmesi kullanılarak MATLAB programında mekanik test özelliklerinin değeri tahmin edilmiştir.

1.2. Tezin Amacı

Kauçuk endüstrisinde, üretilen ürünlerin mekanik özelliklerinin, ürünün hizmet edeceği alan göz önüne alınarak belirlenmiş belirli test değerleri aralığına sahip olması gereklidir. Bu test değerleri, bir takım pahalı test cihazı ve uzun süren laboratuvar çalışmalarını gerektirir. Hazırlanan bu çalışmanın amacı, günümüzde oldukça popüler olan yapay zeka tekniklerinden YSA, regresyon ağacı ve topluluk öğrenmesi kullanılarak, pahalı ve uzun süren laboratuvar çalışmaları ile elde edilen kauçuk bileşiklerin mekanik özellik değerlerinin daha hızlı ve az maliyetli şekilde tahmin edilmesi ve kullanılan yapay zeka tekniklerinin istatistiksel hata türlerinden ortalama mutlak yüzde hata (MAPE), ortalama hata karesi (MSE) ve çoklu belirlilik katsayısı (R^2), kullanılarak performanslarının karşılaştırılmasıdır.

1.3. Literatür Araştırması

Literatür incelendiğinde, kauçuk alanında yapay zekâ tekniklerinin kullanıldığı çalışmalar mevcuttur. Çalışmalar ana başlıklar ele alınarak incelendiğinde, yapay zekâ tekniklerinden YSA, karar ağaçları ve topluluk öğrenimi gibi metotların altında toplanmaktadır.

Vijayabaskar ve ark. [1] tarafından 2005 yılında yayınlanan bu çalışmada nitril kauçuk, kükürt/hızlandırıcı ve elektron ışını radyasyonundan oluşan karışık bir çapraz bağlama sistemi kullanarak farklı kauçuk formülasyonları tasarlanmıştır. Deneysel sonuçlara dayanarak, kauçuğun mekanik özelliklerini ve hacim oranını simüle etmek için bir YSA oluşturulmuştur. Öngörülen sonuçlar, başka bir matematiksel model kullanılarak doğrulanmıştır. Oluşturulan YSA tamamen farklı bir SBR sistemi ile doğrulanmıştır. Çalışmada, üç katmanlı bir geriye yayılım algoritması kullanılmıştır. Üç çıktı değişkeni dikkate alınmıştır. Bunlar kauçuğun mekanik özelliklerinden olan %100 modülüs, çekme mukavemeti ve kopma-uzamadır. 25 kauçuk karışım reçetesi seçilerek formülasyonlar, Taguchi istatistiksel tekniği esas alınarak tasarlanmıştır. Tahminin doğruluğunu artırmak için veri seti 37 bileşik grubuna çıkartılmıştır ve 3 çıktı tahmin edilmiştir. Çıktı sonuçları, farklı 16 bileşik grubu YSA'da kullanılarak doğrulanmıştır. Tahmin kalitesinin, eğitim verisi arttıkça arttığı gözlemlenmiştir. YSA'nın, nitril kauçuk vulkanizatları için kauçuğun çekme mukavemetini, %100 modülüsünü, kopma-uzamasını ve hacim oranını doğru bir şekilde tahmin ettiği gösterilmiştir.

Sresungsuwan ve Hansupalak [2], 2012 yılında yayınladıkları çalışmalarında, uyumlu polistiren/kauçuk karışımı için greft polimerizasyon koşullarını mekanik özelliklerle (çekme mukavemeti ve aşınma) ilişkilendirmek için Merkezi Bileşik Tasarım (MBT) ve YSA yaklaşımları kullanılmıştır. Bununla birlikte, tahmin korelasyonları, düşük kök ortalama kare hata (RMSE) değerleri, R^2 ve grafik görselleştirme ile doğrulanan MBT yaklaşımı yerine, bir geri yayılma besleme ileri algoritması ile YSA yaklaşımı tarafından yeterli doğrulukla elde edildiği belirtilmiştir. YSA modelini en iyi performansla kullanarak çeşitli reaksiyon koşullarında çekme dayanımının simülasyon sonuçlarının literatür ile uyumlu olduğu gösterilmiştir fakat aşınma kaybının simülasyon sonuçlarının büyük deneysel hata nedeniyle literatür ile tam olarak tutarlı

olmadığı ve bu nedenle yeniden doğrulanması gerektiği bildirilmiştir. MBT ve YSA Çalışmasında Kullanılan Emülsiyon Kopolimerizasyonu ve Deneysel Yanıtlar için MBT verisetinden elde edilen regresyon analizi ile hesaplanan R^2 , çekme mukavemeti için 0,44, aşınma için 0,70 iken, YSA ile R^2 , çekme mukavemeti için 0,84 ve aşınma için 0,74 olarak bulunmuştur. YSA sonucunda RMSE değeri çekme mukavemeti için 0,0899, aşınma için 0,0919 olarak hesaplanmıştır.

Xiang ve ark. [3], 2014 yılında yayınladıkları çalışmada doğal kauçuk kompozitlerinin yorulma özelliğini tahmin etmek için bir geri yayılım YSA modeli kurulmuştur. Girdi değişkenleri olarak doğal kauçuk kompozitlerin mekanik özellikleri (%100 modülüs, çekme mukavemeti, kopma-uzama) ve viskoelastisite özelliği (%7 gerinimde tan d), çıktı değişkeni olarak yorulma özelliği (çekme-yorulma ömrü) kullanılmıştır. YSA, MATLAB 7.0 Neural Network Tools kullanılarak oluşturulmuştur. Gizli katmandaki nöron sayısı ampirik bir formül ile belirlenmiş olup, 9 nöron olarak hesaplanmıştır. YSA'da Levenberg-Marquardt algoritması kullanılmıştır, veriler [-1,1] aralığında normalleştirilmiştir. 23 adet eğitim verisi, 3 adet doğrulama verisi kullanılmıştır. Ortalama eğitim doğruluğu %93,5 olarak bulunmuştur. Doğrulama verilerinin tahmin doğrulukları ortalama %97,3 olarak hesaplanmıştır.

Wang ve ark. [4], 2013 yılında yayınladıkları çalışmalarında SBR bazlı kauçuk kompozitlerin aşınma ve altı mekanik özelliğine (shore A sertlik, %100 modülüs, %300 modülüs, çekme mukavemeti, kopma-uzama ve yırtılma dayanımı) ilişkin 20 set örnek verisine dayalı olarak, bir SBR tabanlı kauçuğun aşınma ve bu altı mekanik özelliğinden oluşan YSA modelini MATLAB 7.0 yazılımı ile oluşturmuşlardır. Ağ eğitim hatasına göre gizli katman nöron sayısı, eğitim fonksiyonları, öğrenme fonksiyonları ve performans fonksiyonları optimize edilmiştir. Deneysel değer ile tahmin edilen değer karşılaştırıldığında, YSA modeli için tahmin doğruluğu %96 olarak belirtilmiştir.

Joo ve ark. [5] tarafından 2022 yılında yayınlanan çalışmada üç makine öğrenimi yöntemi kullanılarak polipropilen kompozitlerinin fiziksel özelliklerini tahmin etmek için üç model geliştirilmiştir. Bunlar; çoklu doğrusal regresyon(ÇDR), derin sinir ağı (DSA) ve rastgele orman (RO) algoritmasıdır. Geliştirilen modelleri doğrulamak için 811 kauçuk karışımının endüstriyel verileri elde edilmiştir.

Üç model daha sonra dokuz vaka çalışmasında polipropilen kompozitlerinin eğilme mukavemetini, erime indeksini ve çekme mukavemetini tahmin etmek için kullanılmıştır. Öngörücü performans sonuçları, kompozitlerin fiziksel özelliklerine göre farklılık göstermiştir. ÇDR'li eğilme mukavemeti ve erime indeksi tahmin modelleri, 0.9291 ve 0.9406'lık en yüksek R^2 değerlerine sahiptir. DSA'li çekme mukavemeti modelinin, 0.9587 ile en yüksek R^2 değerine ulaştığı gösterilmiştir.

Rużiak ve ark. [6], 2018 yılında yayınlanan çalışmalarında yaşlanan kauçuk karışımlarının karakterizasyonu ve kimyasal bileşimine göre mekanik özelliklerin tahmin edilmesi için YSA kullanılmıştır. Yapılan çalışmada kauçuk bileşiminin çekme mukavemeti ve %100 modülüs test özellikleri değerlendirilmiştir. YSA uygulaması, tüm tahminler için değeri 0,93'ten yüksek olan istatistiksel fonksiyon RMSE ve R^2 ile test edilmiştir. Çekme mukavemeti için RMSE ve R^2 değeri yaşlanmadan önce sırası ile 0,080 ve 0,938 olarak hesaplanmıştır. Yaşlanmadan sonra ise RMSE ve R^2 değeri sırası ile 0,112 ve 0,970 olarak hesaplanmıştır. %100 modülüs için RMSE ve R^2 değeri yaşlanmadan önce 0,042 ve 0,958 olarak hesaplanmıştır. Yaşlanmadan sonra ise RMSE ve R^2 değeri sırası ile 0,051 ve 0,936 olarak hesaplanmıştır.

Pang ve ark. [7], 2020 yılında yayınlanan çalışmalarında makine öğrenimi teknikleri kullanarak, ortogonal olarak tasarlanmış 27 kauçuk kompozit örneğine dayanarak, lastik sırtı kompozitlerinin çeşitli özellikleri ile dolgu sistemi arasındaki ilişkinin keşfedilmesine odaklanmışlardır. ÇDR, YSA, destek vektör makine regresyonu (DVMR) ve sınıflandırma/regresyon ağacı gibi dört farklı makine öğrenme algoritması kullanarak karbon nanotüp dozajı, silika dozajı ve toplam dolgu eşdeğerinden elde edilen doğal kauçuk nanokompozitlerinin gerilme mukavemetini ve Shore A sertliğini tahmin etmişlerdir. Sonuçlar, ÇDR'nin en küçük tahmin hatalarına sahip olduğunu (<%5) göstermişlerdir. Çalışmada öngörülen değerlerin, deneysel sonuçlarla iyi bir uyum içinde olup, yerleşik ÇDR modellerinin, lastik sırtı kompozitlerinin özelliklerinin tahmini ve tasarımı için kullanılabileceği gösterilmiştir.

Martinez ve ark. [8] tarafından 2014 yılında yayınlanan bu çalışmada, kauçuk karışımlarının ilgili üç fiziksel özelliğini (%100 modülüs, Shore A sertlik ve çekme mukavemeti) tahmin etmek için bazı modeller makine öğrenimi yöntemleriyle

oluşturulmuştur ve ardından değerlendirilmiştir. Modelleri oluşturmak için doğrusal regresyon, YSA, destek vektör makinesi ve regresyon ağaçları kullanılmıştır. Mekanik özelliklerin tahmini için modeller karşılaştırıldığında; çekme mukavemeti için en iyi model YSA olarak belirtilmiştir ve $RMSE = \%16,94$ olarak hesaplanmıştır, $\%100$ modülüs için en iyi model DVMR olarak belirtilmiştir ve $RMSE = \%11,76$ olarak hesaplanmıştır. Shore A sertlik için en iyi model YSA olarak belirtilmiştir ve $RMSE$ değeri $\%24,47$ olarak hesaplanmıştır.

Literatürde topluluk öğrenimi algoritmasının kullanımına beton karışımları ile ilgili çalışmalarda da yer verildiği görülmüştür.

Kumar ve ark. [9] tarafından 2022 yılında yapılan bu çalışmada, hafif betonun basınç dayanımını tahmin etmek için GİR, DVMR, topluluk öğrenimi (TÖ) ve optimize edilmiş GİR, DVMR ve TÖ gibi makine öğrenimi algoritmaları kullanılmıştır. Bulgular, bu çalışmada kullanılan optimize edilmiş GİR modelinin $R = 0,9803$ ile en yüksek doğruluğa sahip olduğunu ortaya koymuştur. Ek olarak, optimize edilmiş DVMR ve GİR modellerinin, sırasıyla 0,9777 ve 0,9740 R değerleri ile iyi performans gösterdiği belirtilmiştir.

Ullah ve ark. [10], 2022 yılında yayınlanan çalışmalarında, bir DVMR ve modifiye edilmiş bir topluluk öğrenicisi olan torbalama, artırma ve RO kullanarak hafif betonun basınç dayanımını tahmin etmeyi amaçlamışlardır. Bu amaçla, hafif betonun basınç dayanımını tahmin etmek için karışım tasarım bileşenlerinin, kum içeriğinin, su-çimento oranının ve köpük hacminin seçildiği yayınlanmış literatürden 191 veri noktasından oluşan bir veritabanı toplanmıştır. Geliştirilen makine öğrenmesi modellerinin performansını değerlendirmek için 10-K katlanmış çapraz doğrulama yöntemi ve farklı istatistiksel hata ve regresyon araçları (ortalama mutlak hata (MAE), $RMSE$ ve R^2) kullanılmıştır. Modifiye topluluk öğrenicisinin, $MAE = 1,84$ Mpa ve $RMSE = 2,52$ MPa'nın en düşük istatistiksel hata değerleriyle birlikte $R^2 = 0,96$ 'lık güçlü bir korelasyon sağlayarak tüm modellerden daha iyi performans gösterdiği belirtilmiştir.

Literatür incelendiğinde, kauçuk bileşiklerin mekanik özelliklerinin tahmini için doğrusal regresyon ve yapay zekâ tekniklerinin kullanıldığı görülmüştür. Bu teknikler kullanılırken girdi verisi olarak çoğunlukla kauçuk bileşik formülasyonları kullanılmıştır. Bu çalışmada kauçuk bileşik formülasyonlarına ek olarak, proses süreleri de girdi verisi olarak kullanılmıştır. Ayrıca, yapay sinir ağlarının yanı sıra, regresyon ağaçları ve ağaç toplulukları algoritması da aynı çalışmada kullanılarak, bu yapay zekâ tekniklerinin kauçuk bileşiklerin mekanik özelliklerinin tahminindeki performansları karşılaştırılmıştır. Literatüre, kauçuk bileşiklerin maliyetli ve uzun süren labarotuvan çalışmaları ile ölçülen test değerlerinin, yapay zeka teknikleri arasından, tahminlemede sıklıkla kullanılan yapay sinir ağlarının kullanılarak saniyeler içerisinde belirlenebileceği, ayrıca yine yapay zeka tekniklerinden olan regresyon ağaçları ve literatürde kauçuk bileşiklerin mekanik özellik tahminlemede daha önce karşılaşılmayan bir teknik olan topluluk öğrenimi ile yapay sinir ağları kullanılarak tahmin edilen kauçuğun mekanik özelliklerinin farklı tahmin algoritmaları ile de yapay sinir ağlarından daha yüksek tahmin performansı elde edilebileceğinin gösterilmesi amaçlanmıştır.



2. KAÜÇUK KİMYASI VE ÖZELİKLERİ

2.1. Kauçuk Bileşiklerini Oluşturan Hammaddeler

Lastik ve diğer ürünlerin üretiminde kullanılan kauçuk bileşiklerinde çeşitli hammaddeler kullanılmaktadır. Üretilecek olan kauçuk ürünlerin, kullanım amacına göre kauçuk bileşeninde kullanılacak olan kauçuk çeşitleri belirlenir. Doğal ve sentetik olmak üzere iki tür kauçuk çeşidi bulunmaktadır. Kauçuk bileşiklerinde yaygın bir şekilde dolgu malzemesi olarak karbon bazlı ya da silika bazlı hammaddeler kullanılmaktadır. Bileşik hazırlama sürecinde karıştırıcı mikserde proses kolaylaştırıcı olarak petrol türevi yağlar kullanılmaktadır. Nihai kauçuk ürünlerin, kullanım alanına göre kauçuk bileşiklerine farklı kimyasal ve mekanik özellikler kazandırmak, istenilen test değerlerini sağlamak ve kauçuk bileşiklerinin üretim sürecinde gerekli kimyasal tepkimelerin gerçekleşmesi amacı ile çeşitli kimyasallar kullanılmaktadır.

2.1.1. Doğal kauçuk

Doğal kauçuk, ağırlıklı olarak Hevea brasiliensis ağacının lateksinden üretilir. Doğal kauçuğun stereodüzenliliği nedeniyle, polimer zincirleri kendiliğinden kristalitler olarak bir araya toplanabilir. Doğal kauçuğun kristalleşme hızı -25°C 'de saklandığında maksimum değerlere ulaşır. Mayalar, İnkalar ve Aztekler arasında doğal kauçuk kullanımı, İspanyolların Orta ve Güney Amerika uygarlıklarını yıkmasına kadar devam etmiştir. Doğal kauçuk esas olarak top yapımında kullanılmıştır. İngiltere'de kimyager Joseph Priestley, kurşun kalem izlerinin lastikle silinebileceğini fark etmiştir. Bu durum, Priestly'nin bu malzemeye atıfta bulunmak için "kauçuk" kelimesini kullanmasına neden olmuştur [11].

Yaygın olarak kullanılan elastomerler karşılaştırıldığında doğal kauçuğun çekme ve yırtılma mukavemeti daha yüksektir. Doğal kauçuk ayrıca stres altında SBR'ye göre daha düşük ısı oluşumuna sahiptir, bu da daha düşük ıslak yol tutuşu ve daha düşük yuvarlanma direnci sağlamaktadır [12].

2.1.2. Sentetik kauçuklar

Doğal kauçuğun başarılı bir şekilde endüstride uygulanmasından ve ticari başarısından sonra, diğer sentetik polimerlerin geliştirilmesiyle birlikte, sentetik kauçukların geliştirilmesi için çaba gösterilmiştir.

Petrol ve türevlerinden elde edilen sentetik kauçuklar, kauçuk endüstrisinin hızla gelişmesinde büyük rol oynamışlardır. Ayrıca sentetik olarak elde edilen farklı karakterizasyona sahip kauçuklar, sanayide ve endüstride farklı alanlarda vazgeçilmez bir mühendislik malzemesi olmuşlardır.

2.1.2.1. Stiren bütadien kauçuk

Stiren bütadien kauçuk (SBR), yaklaşık %23 stiren içeren bir stiren ve bütadien kopolimerini belirtir. En büyük hacimli üretim ile en yaygın kullanılan sentetik elastomerdir. Suda bir emülsiyon olarak veya solüsyonda anyonik olarak serbest radikal polimerizasyonu yoluyla sentezlenir. Emülsiyon polimerizasyonunda, emülgatör genellikle bir yağ asidi veya bir kolofan asididir. İlki, daha az yapışma ve daha az lekelenme ile daha hızlı sertleşen bir kauçuk verir [13].

SBR, doğal kauçuğun yapışkanlığından yoksundur. Daha düşük yoğunluğa sahiptir ve doğal kauçuktan daha iyi akar, akışı iyileştirmek için doğal kauçuk ile karıştırılabilmektedir. SBR, günümüzde hafif kamyon lastikleri de dahil olmak üzere otomobil lastikleri için kullanılmaktadır. Eski lastikleri kaplayan birçok şirket, kaplamaları da üretmek için herhangi bir stiren-bütadien kauçuk kaplama kullanmaktadır. Diğer bariz kullanımlar arasında kimya endüstrileri için kayışlar ve hortumlar, klor alkali endüstrileri için contalar ve kalıplanmış ebonit bileşenleri bulunmaktadır [14].

2.1.2.2. Bütil kauçuk

Bütil kauçuk, küçük bir yüzde izopren içeren bir izobütilen kopolimeridir. Bütil kauçuk, beklenmedik derecede düşük esnekliğe sahiptir. Bütil kauçuk büyük ölçüde doymuş olduğu için mükemmel eskime kararlılığına sahiptir. Bütil kauçuğun bir diğer öne çıkan özelliği de gazlara karşı düşük geçirgenliğidir. Bu nedenle, iç lastiklerde ve lastik astarlarında yaygın olarak kullanılır. Bütil kauçuğun bromlu bütil kauçuk ve klorlu bütil kauçuk modifikasyonları da mevcuttur [13].

2.1.2.3. Bütadien kauçuk

Kullanılan bütadien kauçuklarının çoğu, çok yüksek bir cis-1,4 konfigürasyonu ile polimerize edilmiş çözeltidir. Bütadien kauçuğun mukavemeti çok düşüktür ve işlenmesi çok zordur. Yollardaki lastiklerin aşınma mekanizması, kuru veya ıslak cevher parçacıklarına maruz kalan kauçuğunkinden biraz farklı olsa da bütadien kauçuk en yaygın olarak doğal kauçuk veya SBR ile harmanlanır. Genellikle 50 ila 80 Shore A aralığında sertlik verecek dolgu maddelerine sahip bileşiklerde doğal kauçuk veya SBR ile harmanlandığında, bütadien kauçuğun aşınma direncini, ısıyla yaşlanmayı, esnekliği, geri dönüş direncini, yorulma direncini ve düşük sıcaklık esnekliğini geliştirir [14].

2.1.2.4. Nitril kauçuk

Basit nitril elastomerler, akrilonitril (ACN) ve bütadien monomerin kopolimerleridir, oran 18/82 ila 50/50 arasındadır. Belirli bir monomer oranına sahip belirli bir nitril kauçuğun derecesinin seçiminin temeli, genellikle yağ/solvent direncinin yanı sıra nihai vulkanizatta gerekli olan düşük sıcaklık performansına bağlıdır. Daha yüksek ACN, daha iyi yağ direnci sağlar, ancak düşük sıcaklık özellikleri daha zayıftır. ACN içeriği arttıkça, çekme mukavemeti ve sertlik artarken, esneklik ve sıkıştırma direnci azalır [14].

2.1.2.5. Neopren

Polikloropren bazlı kauçuğun ticari adı olan neopren kauçuk, bir bütadien türevidir. Neopren, hava koşullarına ve yağa olduğu kadar solventlere, ozona, oksijene ve ısıya karşı da oldukça dirençlidir. Öncelikle kablo kılıfları, kayışlar, hortumlar ve contalar gibi mekanik ve otomotiv ürünlerinde kullanılır, ayrıca bazı yapıştırıcılar için de önemli bir katkı maddesidir [15].

2.1.2.6. Poliizopren

Sentetik poliizopren hem anyonik olarak hem de Ziegler-Natta polimerizasyonu ile üretilir. Her iki poliizopren türü de doğal kauçuktan daha az ham kuvvete ve yapışkanlığa sahiptir. Poliizopren bileşikleri, benzer şekilde formüle edilmiş doğal kauçuk bileşimlerine göre daha düşük modüle ve daha yüksek kopma uzamaya sahiptir [13].

2.1.2.7. Etilen Propilen Dien Monomer

Sentetik bir kauçuk türü olan etilen propilen dien monomer (EPDM), propilen, etilen ve vulkanizasyon amaçlı doymamış üçüncü bir monomer içerir. Ağırlıkça %40 ila %80 arasında değişen etilen içeriği ile EPDM, çoğunlukla ticari amaçlar için kullanılır. Etilen miktarı arttıkça, polimer kristallliği de artar. Tersine, etilen içeriği azaldıkça ve propilen içeriği arttıkça, polimer daha amorf hale gelir. Bu nedenle, ağırlıkça %62 veya daha fazla etilen içeren EPDM yarı kristalli olarak sınıflandırılırken, %62'den az etilen içeriği içeren EPDM amorf olarak sınıflandırılır [16].

2.1.2.8. Kloropen kauçuk

Kloropren, oda sıcaklığında karakteristik bir eter benzeri kokuya sahip, yanıcı, renksiz bir sıvıdır. Suda az çözünür ve organik çözücülerde daha fazla çözünür. Doğal olarak meydana geldiği tespit edilmemiştir. Kloropren çok kararsızdır ve havada oksijen ve diğer bileşiklerle reaksiyona girerek epoksitler, peroksitler ve diğer tehlikeli bileşikler oluşturur [15].

2.1.2.9. Klorobutil ve bromobutil

Bu iki kauçuk, bütilin halojenlenmesiyle hazırlanır. Halojenasyon kütleme reaktivitesini artırır. Sonuç olarak, vulkanizasyon oranlarında iyileşme meydana gelir ve bu da bütilden daha iyi özellikler sağlar. Bu iki kauçuk, bütıl kauçuktan daha düşük gaz geçirgenliğine, daha iyi hava ve ozon direncine, kimyasallara karşı daha iyi dirence, daha iyi ısı direncine, diğer kauçuklara daha iyi yapışmaya sahiptir. Klorobutil ve Bromobutil vulkanizatları, butil kauçuk ile hemen hemen aynı yerlerde kullanılır. Kayışlar, hortumları ve tank astarları gibi birçok uygulamada butil kauçuğun yerini almışlardır [14].

2.1.3. Dolgular

Kauçuğun işlenmesi aşamasında, kauçuk bileşiğe istenilen özellikleri kazandırmak, bileşiğin üretim maliyetini düşürmek ve bileşiğe renk vermek amacı ile dolgu maddeleri kullanılır. Bu maddelerden kullanımı en yaygın olanları, karbon siyahı ve silikadır.

2.1.3.1. Karbon siyahı

Karbon siyahı, yüksek takviye kabiliyeti nedeniyle kauçuk endüstrisinde takviye dolgu maddesi olarak yaygın şekilde kullanılır. Yüzeyinde düşük oranda diğer hidrokarbon veya oksijen içeren grupların mevcudiyeti ile karbondan oluşur. Nispeten polar olmayan yüzey, kauçuk bileşiminde yaygın olarak kullanılan hidrokarbon kauçuğu ile uyumludur. Karbon siyahı, karbon siyahı üretmek için kullanılan yöntemler nedeniyle kopmuş karbon-karbon bağlarından kaynaklanan sınırlı sayıda kimyasal olarak aktif bölgeye sahiptir. Bununla birlikte, genel amaçlı kauçukların çoğunda takviye için oksijen komplekslerinin varlığı gerekli değildir. Takviye edici aktivite, temel olarak, kauçuğun karbon siyahı yüzeyi üzerine mekanik olarak kenetlenmesine, dolgu maddesi ve kauçuk içindeki karbon atomları arasındaki serbest radikal etkileşimler nedeniyle kauçuğun dolgu yüzeyi üzerinde kimyasal soğurulmasına ve aralarındaki Van der Waal kuvvetlerine atfedilir. Karbon siyahı, tanecik boyutlarına göre sınıflandırılmaktadır. Yaygın olarak kauçuk bileşiklerinde N220, N330 ve N550 olarak isimlendirilen karbon siyahları kullanılmaktadır [17].

2.1.3.2. Silika

Beyaz karbon siyahı olarak adlandırılan silika dolgu maddesi, 1990'lı yıllardan beri lastik karışımlarında kullanılmaktadır. Silika, karbon siyahı ile güçlendirilmiş bileşiklere kıyasla kauçuk bileşiğinin özelliklerini geliştirir. Islak yüzey kavrama, aşınma direnci ve yuvarlanma direncinde karbon siyahına kıyasla gelişmeler görülebilir. Ayrıca bileşiğin gerilme ve yırtılma mukavemetini de artırır. Silikanın birincil parçacıkları silikon ve oksit atomlarından oluşur. Silika partiküllerinin yüzeyinde silanol gruplarının bulunması, silis yüzeyini hidrofilik hale getirir. Hidrofiliklik ayrıca silikayı hidrofobik elastomerlerde karışmaz hale getirir. Bu nedenle silika, silanlar adı verilen bağlayıcı maddelerle birlikte kullanılmaktadır. Silanlar, silika parçacığının etrafında karbon ve kükürt içeren bir kabuk oluşturarak, silisin hidrofilik karakterini daha hidrofobik hale getirir [12].

2.1.4. Proses kolaylaştırıcılar

Kauçuk karışımlarının formülasyonları dolayısıyla yüksek dolgu maddesi yüklenmesi gerektiğinde, yağ, tipik olarak proses kolaylaştırıcı olarak kullanılan bir maddedir.

Ek olarak proses kolaylaştırıcılar, lastik sırtı hamurları için ıslak yol tutuşu geliştirme gibi başka avantajlar da sunmaktadırlar. Yağların çoğu parafinik, naftenik veya aromatik tiptedir. Aromatikler son zamanlarda yakın çevre incelemelerini kendisine çekmiştir [18].

Mineral yağlar, ham petrolün rafine edilmesiyle elde edilen yüksek kaynama noktalı fraksiyonlardır. Yağlar esas olarak halka yapılarından oluşur. Sahip oldukları baskın halka yapılarına göre doymamış (aromatikler), doymuş (naftenler) ve doymuş yan zincirlere (parafinler) olarak sınıflandırılırlar. Yağ seçimi büyük ölçüde elastomer ile uyumluluğa bağlıdır [19].

2.1.5. Vulkanizasyon ajanları

Polimer zincirleri arasında çapraz bağlar oluşturabilen malzemeler genel olarak vulkanize edici maddeler olarak sınıflandırılırlar.

Elementel kükürt, kauçuk endüstrisinde en yaygın olarak kullanılan vulkanizasyon maddesidir ve bir dereceye kadar doymamışlık içeren elastomerlerde etkilidir. Öğütülmüş kükürt en yaygın şekilde kullanılır ve genellikle eşkenar dörtgen kükürt veya kauçuk üreticilerinin kükürdü olarak anılır. 115 °C'lık bir erime noktasına sahiptir ve elastomerlerde sınırlı bir dereceye kadar çözünür [19].

2.1.6. Vulkanizasyon hızlandırıcıları

İşlevleri, normalde yavaş olan kauçuk-kükürt reaksiyonunu hızlandırmak, vulkanizasyon oranını artırmak ve üretkenliği artırmaktır. Hızlandırıcılar türlerine göre organik ve inorganik olmak üzere iki ana sınıfa ayrılır. Organik hızlandırıcılar, kauçuk endüstrisinin bel kemiği olarak kabul edilebilir. Kireç ve diğer kurşun bileşikleri ile magnezya gibi inorganik hızlandırıcılar, organik hızlandırıcıların kullanılmaya başlanmasından önce yaygın olarak kullanılmaktaydı. Hala esas olarak sert kauçuk veya ebonit ürünleri üretmek için kullanılmaktadırlar [14].

2.1.7. Vulkanizasyon aktivatörleri

Aktivatörlerin etkisi, vulkanizasyon sisteminin çapraz bağlama etkinliğini artırmaktır. Çinko oksit hem kükürt hem de kükürt verici vulkanizasyonda en yaygın kullanılan aktivatördür. Kurşun oksit, kükürt vulkanizasyonu için etkili bir aktivatördür ancak pahalı ve zehirlidir, bu nedenle nadiren kullanılır.

Bir vulkanizasyon aktivatörü olarak çinko oksit, yağ asitlerinin mevcudiyetini gerektirir, böylece çinkoyu kauçukta çözünür bir forma dönüştürür. Stearik asit en yaygın kullanılan yağ asididir ancak laurik asit ile değiştirilebilir. Yağ asitleri ayrıca dolgu maddelerinin ve kimyasalların geliştirilmiş dağılımı ile birlikte gelişmiş bileşik işleme özellikleri sağlar [19].

2.1.8. Geciktiriciler ve vulkanizasyon inhibitörleri

Vulkanizasyon geciktiriciler ve inhibitörleri, kauçuk işleme güvenliğini artırmanın bir yolu olarak kauçuk bileşiklerinde uzun yıllardır kullanılmaktadır. Bir vulkanizasyon geciktirici, karıştırma süresini artırarak işleme güvenliğini artırır, ancak aynı zamanda vulkanizasyon hızını da yavaşlatır. Bununla birlikte, bu azaltılmış vulkanizasyon hızı genellikle istenmeyen bir etkidir. Öte yandan, gerçek vulkanizasyon inhibitörleri, vulkanizasyon hızı üzerinde herhangi bir olumsuz etkiye sahip olmadan, yanık güvenliğini artırır [19].

2.1.9. Antidegradantlar

Elastomer bazlı ürünler, kullanımları sırasında gerekli tasarım özelliklerinde geri dönüşü olmayan değişikliklere maruz kalır. Oksijen, ozon, ısı, ışık ve mekanik deformasyon gibi bir dizi etkenin neden olduğu bu değişikliklere toplu olarak yaşlanma denir. Mekanik özelliklerdeki bir kayba ek olarak, yüzey görünümünde performansa zarar vermese de görünümü bozan değişiklikler meydana gelebilir. Bu zararlı değişikliklerle mücadele etmek için, genellikle topluca bozulma önleyiciler olarak anılan katkı maddeleri kullanılır. Tipik olarak antidegradantların kauçuk karışım reçetelerinde uygulama seviyeleri 1-4 phr mertebesindedir. Antidegradantlar, antioksidanlar ve antiozonantlar olarak kategorize edilmektedir [19].

2.2. Kauçuk Bileşik Hazırlama

Kauçuğun birleştirilmesi, vulkanizasyondan sonra nihai ürünler haline getirildiğinde hizmette etkili bir şekilde performans göstermesi gereken kauçuk bileşiklerin geliştirilmesidir. Aynı zamanda bileşikler, fabrikada fazla zorlanmadan ve minimum maliyetle işlenebilecek özellikte olmalıdır. Tüm bileşiklerin en basiti, yani kauçuk ve vulkanizasyon maddesi, çoğu mühendislik ve endüstriyel uygulamada çok az kullanılır.

Bununla birlikte, kullanılabilir bileşikler yapmak için temel bir yapı olarak kabul edilebilir. Kullanılabilir bir ürün yapmak için baz kauçuğun vulkanizasyon maddesine ek olarak çeşitli bileşenlerle karıştırılması gerekir. Karıştırılmamış ve vulkanize edilmemiş kauçuk, çoğu kauçuk ürününde herhangi bir kullanım için uygun değildir. Kauçuk ürünlerin kalitesi, dayanıklılığı ve daha uzun hizmet ömrü, yalnızca kauçuk birleştirme ve vulkanizasyon pratik bilimi ile mümkündür [14].

2.2.1. Banbury

Banbury ve yoğurucu karıştırıcılar çeşitli boyutlarda mevcuttur ve karışımların parçalanarak karıştırılması için kullanılır. Parçalanarak karıştırılan karışım daha sonra merdaneli değirmene aktarılır ve işlenir. Banbury kapasitesi genellikle hazne hacim boyutuna göre belirlenir. Boyut birkaç yüz santimetre küpten 800 litreye kadar değişir. Banbury'ler farklı türde karıştırma rotorları ile donatılmıştır. Buradaki ana tasarım değişkeni, dönüşe göre kanat sayısı ve bıçak açısıdır. Banbury'nin arkasına besleme portları ekleyerek birden fazla sıvı beslemesi mümkündür. Bu sıvılar, proses kolaylaştırıcılar olarak adlandırılan yağlardır. Bileşik formülasyonlarında yer alan dolgu maddeleri için silo mekanizmaları tasarlanır ve banburyye beslenmesi sağlanır. Banbury karıştırıcısından, iyice karıştırılmış karışım, hazneyi eğerek ünitenin altından veya bir yanından boşaltılır [20].

2.2.2. Kauçuk karışımların mekanik özellikleri

Kauçuk bileşiklerin, hizmet edeceği kullanım alanlarında, kullanım amacını istenilen ölçütler karşılayabilmesi adına, önceden belirlenmiş malzeme karakterizasyonunu sağlaması gereklidir. Bu karakterizasyon ölçüme tabiidir ve birtakım testler ile bu karakterizasyon değerleri belirlenir. Kauçuğun kimyasal ve mekanik karakterizasyonunu belirleyen çeşitli özellikleri bulunmaktadır. Kauçuk bileşiklerin, sertlik, aşınma, çekme kopma ve yırtılma mukavemeti gibi mekanik davranışları, kauçuk karışımların mekanik özellikleri olarak adlandırılır.

2.2.2.1. Sertlik

Kauçuğa uygulanan sertlik, kauçuğu delmeyen koşullar altında girintiye karşı direnç olarak tanımlanır. Sertliği ölçmek için tasarlanmış farklı enstrümanlar genellikle ölçek uç noktalarının tanımı, girinti noktasının şekli ve boyutu, uygulanan toplam yük, yük uygulama hızı ve süresi gibi sebepler ile birbirleriyle uymamaktadırlar.

Sertlik, kauçuğun bir özelliğidir ve temel birimler yerine genellikle alet parametreleri cinsinden ifade edilir. Sertlik Shore A birimi ile ifade edilir [21].

2.2.2.2. Aşınma

Aşınma direnci, kauçuğun yalnızca laboratuvar testleriyle eksik değeriendirilebilen bir özelliğidir. Özellikle lastik-diş aşınmasına uygulandığında, bu tür testlerin iyi bilinen geçerlilik eksikliğinin üç ana nedeni aşağıdaki gibi gösterilebilir:

- 1) Normal aşınma sürecinin herhangi bir ivmesi, yeni aşınma mekanizmalarını devreye sokar, böylece orijinal mekanizma gerçekten değeriendirilmez.
- 2) Bir laboratuvar aşındırıcı yüzeyinin sabit keskinliğini korumak ve aynı anda aşınmış kauçuğu çalışma yüzeyinden çıkarmak için tatmin edici bir yöntem bulunmamıştır.
- 3) Bağlı aşınma derecesi, test koşullarının ciddiyetine bağlıdır. [21].

2.2.2.3. Çekme mukavemeti

Kauçuğun fiziksel testi genellikle numuneye bir kuvvet uygulanmasını ve ortaya çıkan deformasyonun ölçülmesini veya tersine bir deformasyonun uygulanmasını ve gerekli kuvvetin ölçülmesini içerir. Çekme ve kopma olarak iki yaygın deformasyon modu bulunmaktadır. Test sonuçları numune geometrisinden bağımsız bir şekilde ifade edilmelidir. Bu amaçla gerilme ve gerinim kavramları kullanılmaktadır. Stres, birim kesit alanı başına kuvvettir [21]. Gerinim, çekme testlerinde birim orijinal uzunluk başına deformasyon veya kopma testlerinde temas yüzeyleri arasındaki birim mesafe başına deformasyondur. Stres genellikle geleneksel birimlerde inç kare başına pound (psi) veya SI birimlerinde pascal (Pa) olarak ifade edilir [21].

2.2.2.4. Yırtılma mukavemeti

Yırtılma mukavemeti, ilk yırtılmanın büyümesine veya "yırtılma direncine" mukavemet kabiliyetini belirlemektir. Bir kauçuk bileşiğın yırtılma mukavemetinin değeri, genellikle yırtılmayı tamamlamak için gereken kuvvet olarak kabul edilir. Bu özellik, kasıtlı olarak veya başka şekilde kısmi bir kopmaya maruz kalabilen esnek malzemeler kullanılan alanlar için belirleyici rol oynamaktadır.



3. YÖNTEM

3.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insanda yer alan biyolojik sinir ağlarını taklit eden sentetik yapılardır. 1980'lerde hızla geliştirilmişlerdir ve 1990'lardan beri endüstride yaygın olarak kullanılmaktadırlar. Yapay sinir ağlarının yaygın kullanımı, görüntü ve ses tanıma, tahmin ve kestirim, tıp, haberleşme ve üretim yönetimi alanlarındadır [22, 23].

McCulloch ve Pitts 1943 yılında biyolojik nörona dayanan ilk nöron modelini oluşturdular ve nöronların mantıksal işlemler gerçekleştirebildiklerini gösterdiler. Hebb, 1949'da bağlı ve paralel sinir ağlar ile birlikte ağırlıklar için güncelleme kuralları önerdi. Rosenblatt, 1958'de temel problemleri tanımlayabilen ve mantıksal hesaplamalar yapabilen algı modelini yarattı [24].

Bir YSA, karmaşık giriş/çıkış ilişkilerini yakalayabilen ve temsil edebilen güçlü bir veri modelleme aracıdır. Sinir ağı teknolojisinin gelişmesi için motivasyon, insan beyni tarafından yapılanlara benzer akıllı görevleri yerine getirebilecek yapay bir sistem uygulama arzusundan kaynaklanıyordu. YSA, insan beynine aşağıdaki iki şekilde benzer:

- 1) Bir YSA, öğrenme yoluyla bilgi edinir.
- 2) Bir YSA'nın bilgisi, sinaptik ağırlıklar olarak bilinen nöron bağlantı güçleri içinde depolanır.


Yapay sinir ağlarının gerçek gücü ve avantajları hem doğrusal hem de doğrusal olmayan ilişkileri doğrudan modellenen verilerden temsil etme yeteneğinde yatmaktadır. Geleneksel doğrusal modeller, doğrusal olmayan özellikler içeren gerçek modelleme verileri söz konusu olduğunda yetersizdir [25].

Bir YSA modeli, belirli bir veri kümesinden verilerin özelliklerine veya veriler arasındaki ilişkilere bir eşleme üretmek için ayarlanabilen bir yapıdır. Model, belirli bir kaynaktan giriş olarak bir veri seti kullanılarak ayarlanır veya eğitilir ve genellikle eğitim kümesi olarak adlandırılır.

Başarılı bir eğitimden sonra, YSA aynı veya benzer kaynaklardan gelen yeni veriler üzerinde sınıflandırma, tahmin veya simülasyon gerçekleştirebilecektir [25].

YSA, beyin gibi biyolojik sinir sistemlerinin bilgiyi işleme şeklinden ilham alan bir bilgi işlem paradigmasıdır. Bu paradigmanın temel unsuru, bilgi işlem sisteminin yeni yapısıdır. Belirli problemleri çözmek için birlikte çalışan çok sayıda birbirine bağlı işlem elemanından (nöron) oluşur. YSA'lar, insanlar gibi, örnek olarak öğrenirler. Bir YSA, bir öğrenme süreci aracılığıyla desen tanıma veya veri sınıflandırma gibi belirli bir uygulama için yapılandırılır. Biyolojik sistemlerde öğrenme, nöronlar arasında var olan sinaptik bağlantılara ayarlamalar ekler [25].

Yapay sinir ağları, biyolojik sinir ağlarının bir taklidi olarak tasarlanmıştır. Şekil 3.1'de bu durum ifade edilmiştir.



Şekil 3.1. Biyolojik sinir hücresi ve YSA [26].


Biyolojik sinir ağlarında yer alan elemanların, yapay sinir ağlarında yer alan karşılıkları bulunmaktadır [26]. Tablo 3.1'de biyolojik sinir sisteminde yer alan elemanların, yapay sinir ağlarında yer alan karşılıkları gösterilmiştir.

Tablo 3.1. Biyolojik sinir sisteminde yer alan elemanların yapay sinir ağlarında karşılıkları [26].

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Sinapslar	Ağırlıklar
Aksonlar	Yapay Nöron Çıkışı


YSA'nın en yaygın şekli bir ileri besleme ağıdır. Ağ döngülerden arındırılmıştır ve veriler girişten çıkışa kadar yalnızca bir yönde işlenebilir. Geri yayılım, çok katmanlı ağlarda en sık kullanılan eğitim tekniğidir. Algoritma, düğüm bağlantılarının ağırlıklarını ve düğümlerin önyargılarını, bilinen giriş ve çıkış değerlerini içeren eğitim verilerine göre hesaplar. Tahmini çıktı değeri, önceden belirlenmiş bir hata işlevine göre hata değerini hesaplamak için tam olanla karşılaştırılır. Bu bilgiler, hata işlevinin değerini düşürmek için ağırlıkları ve önyargıları uygun şekilde güncellemek üzere ağ üzerinden geri gönderilir. Bu yordam, eğitim verileri kullanılarak hata değeri yeterince küçülene ve öğrenmenin tamamlandığını gösteren doğrulama verileriyle doğrulanana kadar tekrarlanır. Daha sonra, ağ bağımsız bir test verisi ile test edilir [24].

Geri yayımlı YSA en az üç katmandan oluşur. Bunlar bir giriş katmanı, en az bir ara gizli katman ve bir çıkış katmanıdır. Geri yayılım ağındaki bağlantı ağırlıkları tek yönlüdür. Tipik olarak, giriş birimleri, gizli katmandaki birimlere tamamen bağlı giriş birimleri ve çıkış katmanındaki birimlere tamamen bağlı gizli birimler ile ileri besleme tarzında bağlanır. Bir giriş deseni, bir geri yayılma ağı döngüye alındığında, araya giren girişten gizliye ve gizliden çıkışa ağırlıkları boyunca çıkış birimlerine doğru yayılır. Şekil 3.2'de geri yayımlı YSA örneği gösterilmiştir.



Şekil 3.2. Geri yayımlı YSA örneği [26]

i ve j ; giriş katmanının ve gizli katmanın düğüm sayısıdır. X_i dış dünyadan gelen giriş verileridir. x_i transfer fonksiyonu tarafından işlenip dönüştürülen giriş verileridir. H_j , gizli katmanın çıktısıdır. O , YSA çıktısı ve Y ise beklenen değerdir. e , çıkış değeri ile beklenen değer arasındaki hatadır. Şekil 3.3'te yapay sinir ağlarının genel bir yapısı gösterilmiştir.



Şekil 3.3. Yapay sinir ağları genel yapısı [27]

Yapay sinir ağlarında yaygın olarak kullanılan transfer fonksiyonlarından olan Doğrusal Fonksiyon Denklem 3.1’de, Adım/İşaret Fonksiyonu Denklem 3.2’de, Eşik Fonksiyonu Denklem 3.3’te, Sigmoid ve Hiperbolik Tanjant Fonksiyonu ise Denklem 3.4 ve 3.5’de gösterilmiştir.

$$\text{Doğrusal Fonksiyon: } F(s) = s \quad (3.1)$$

$$\text{Adım/İşaret Fonksiyonu: } y = F(s) = \begin{cases} 1 & s > 0 \\ -1 & s \leq 0 \end{cases} \quad (3.2)$$

$$\text{Eşik Fonksiyonu: } y = F(s) = \begin{cases} 1 & s > \theta \\ 0 & s \leq \theta \end{cases} \quad (3.3)$$

$$\text{Sigmoid Fonksiyonu: } y = F(s) = \frac{1}{1+e^{-s}} \quad (3.4)$$

$$\text{Hiperbolik Tanjant Fonksiyonu: } y = F(s) = \frac{e^s + e^{-s}}{e^s - e^{-s}} \quad (3.5)$$

Geri yayımlı öğrenme algoritmalarının belirli proses adımları vardır. Bu adımlar yayılma ve ağırlık güncellemesi olarak iki aşamaya ayrılır.


İlk aşama yayılma prosesini içerir. Her yayılma şu süreçleri izler;

Bir eğitim modelinin girdisinin ileriye doğru yayılması, yayılımın çıkış aktivasyonlarını oluşturmak için YSA üzerinden verilir. Çıktı aktivasyonlarının geri yayılması, tüm çıktılarının ve gizli nöronların deltalarını üretmek için eğitim modelinin hedefini kullanarak sinir ağı boyunca yayılım göstermesi.

İkinci aşamada ise, her ağırlık sinapsı için ağırlık güncellemesi yapılır. Bu güncellemeler yapılırken; Ağırlığın gradyanının elde edilmesi için giriş aktivasyonu ve çıkış deltası çarpılır. Ağırlıktan bir oran ekleyerek ağırlık gradyan yönüne getirilir.

Bu oran öğrenmenin hızını ve kalitesini etkiler; buna öğrenme oranı denir. Bir ağırlığın gradyanının işareti, hatanın nerede arttığını belirtir; bu nedenle ağırlığın ters yönde güncellenmesi gerekir. İlk aşama ve ikinci aşama, ağırlık performansı tatmin edici olana kadar tekrarlanır [25].

Şekil 3.4.'te, geri yayımlı bir YSA modellenmiştir.




Şekil 3.4. Geri yayımlı YSA [25]

- 1) Bir katmandaki bir nöronun çıkışı, bir sonraki katmandaki tüm nöronlara taşınır.
- 2) Her nöronun kendi giriş ağırlıkları vardır.
- 3) Giriş katmanının ağırlıklarının her giriş için 1 olduğu varsayılır (sabit). Başka bir deyişle, giriş değerleri değiştirilmez.
- 4) Sinir ağının çıkışı, giriş katmanına giriş değerleri uygulanarak, her nöronun çıktısının giriş olarak aşağıdaki katmana geçirilmesiyle elde edilir.
- 5) Geri Yayımlı Sinir Ağı'nın en az bir giriş katmanına ve bir çıkış katmanına sahip olmalıdır. Sıfır veya daha fazla gizli katmana sahip olabilir.

Giriş katmanındaki nöronların sayısı, mevcut olası girdi sayısına göre belirlenir. Çıkış katmanındaki nöronların sayısı, istenen çıktıların sayısına bağlıdır. Gizli katmanların sayısı ve her gizli katmandaki nöronların sayısı önceden iyi tanımlanamaz ve ağ yapılandırmasına ve veri türüne göre değişebilir. Genellikle gizli bir katmanın eklenmesi, ağın daha karmaşık desenleri öğrenmesine izin verebilir, ancak aynı zamanda performansını düşürür. Bir ağ yapılandırmasının tek bir gizli katmanı olabilir, ancak ağ iyi öğrenmiyorsa ilave gizli katmanlar eklenebilir [25].

Şekil 3.5'te geri yayılım algoritmasının hesaplanan hatayı yayma yönü gösterilmiştir.



Şekil 3.5. Geri yayılım algoritmasının hesaplanan hatayı yayma yönü [27]

F_x giriş katmanı, F_y gizli katmanı, F_z çıkış katmanı olmak üzere; v giriş katmanı ve gizli katmanı arasındaki ağırlık katsayısı, w ise gizli katmanı ve çıkış katmanı arasındaki ağırlık katsayısıdır. F_y gizli katmanındaki ve F_z çıkış katmanındaki değerleri ifade etmektedir.


$$F_x \rightarrow v \rightarrow F_y \rightarrow w \rightarrow F_z$$

3.2. Karar Ağaçları

İlk olarak 1960'larda tanıtılan karar ağaçları, veri madenciliği için en etkili yöntemlerden biridir; çeşitli disiplinlerde yaygın olarak kullanılmıştır çünkü kullanımı kolaydır, belirsizlikten arındırılmıştır ve eksik değerlerin varlığında bile sağlamdırlar. Hem ayrık hem de sürekli değişkenler, hedef değişkenler veya bağımsız değişkenler olarak kullanılabilir [28].

3.2.1. Karar ağaçlarında temel kavramlar

Şekil 3.6’da tek bir ikili hedef değişken Y (0 veya 1) ve 0 ile 1 arasında değişen iki sürekli değişken, X_1 ve X_2 içeren basit bir karar ağacı modelini göstermektedir. Bir karar ağacı modelinin ana bileşenleri düğümler ve dallardır ve bir model oluşturmanın en önemli adımları bölme, durdurma ve budamadır [28].



Şekil 3.6. Bir karar ağacı modeli örneği [28]

3.2.1.1. Düğümler

Karar ağaçlarında üç tür düğüm vardır.

- (a) Karar düğümü olarak da adlandırılan kök düğüm, tüm kayıtların birbirini dışlayan iki veya daha fazla alt kümeye bölünmesiyle sonuçlanacak bir seçimi temsil eder.
- (b) Şans düğümleri olarak da adlandırılan iç düğümler, ağaç yapısının o noktasında mevcut olan olası seçeneklerden birini temsil eder; düğümün üst kenarı üst düğüme, alt kenarı ise alt düğümlerine veya yaprak düğümlerine bağlanır.
- (c) Son düğümler olarak da adlandırılan yaprak düğümleri, kararların veya olayların bir kombinasyonunun nihai sonucunu temsil eder [28].

3.2.1.2. Dallar

Dallar, kök düğümlerden ve iç düğümlerden kaynaklanan tesadüfi sonuçları veya oluşumları temsil eder. Bir karar ağacı modeli, dalların hiyerarşisi kullanılarak oluşturulur. Kök düğümden iç düğümlere ve yaprak düğüme giden her yol, bir sınıflandırma karar kuralını temsil eder. Bu karar ağacı yolları 'eğer-o zaman' kuralları olarak da temsil edilebilir [28].

3.2.1.3. Bölme

Üst düğümleri hedef değişkenin daha saf alt düğümlerine bölmek için yalnızca hedef değişkenle ilgili giriş değişkenleri kullanılır. Hem ayrık giriş değişkenleri hem de sürekli giriş değişkenleri (iki veya daha fazla kategoriye daraltılmış) kullanılabilir. Modeli oluştururken önce en önemli giriş değişkenlerini tanımlamalı ve ardından kök düğümdeki ve sonraki iç düğümlerdeki kayıtları bu değişkenlerin durumuna göre iki veya daha fazla kategoriye veya 'bölmeye' bölünmelidir. Ortaya çıkan alt düğümlerin 'saflık' derecesi ile ilgili özellikler farklı potansiyel giriş değişkenleri arasında seçim yapmak için kullanılır. Bu özellikler entropi, Gini endeksi, sınıflandırma hatası, bilgi kazancı ve kazanç oranını içerir [28].

Bu bölme prosedürü, önceden belirlenmiş homojenlik veya durdurma kriterleri karşılanana kadar devam eder. Çoğu durumda, karar ağacı modelini oluşturmak için tüm potansiyel giriş değişkenleri kullanılmaz ve bazı durumlarda belirli bir giriş değişkeni karar ağacının farklı düzeylerinde birden çok kez kullanılabilir [28].

3.2.1.4. Durdurma

Karmaşıklık ve sağlamlık, istatistiksel bir model oluştururken aynı anda göz önünde bulundurulması gereken modellerin rekabet eden özellikleridir. Bir model ne kadar karmaşık olursa, gelecekteki kayıtları tahmin etmek için kullanıldığında o kadar az güvenilir olacaktır. Aşırı bir durum, her yaprak düğümündeki kayıtları %100 saf hale getirecek kadar geniş yayılan çok karmaşık bir karar ağacı modeli oluşturmaktır (yani, tüm kayıtların hedef sonucu vardır). Böyle bir karar ağacı mevcut gözlemlere aşırı derecede uyacak ve her yaprakta çok az kayıt bulunacaktır, bu nedenle gelecekteki vakaları güvenilir bir şekilde tahmin edemez ve bu nedenle zayıf genellenebilirliğe sahip olur. Bunun olmasını önlemek için, modelin aşırı karmaşık hale gelmesini önlemek için bir karar ağacı oluştururken durdurma kuralları uygulanmalıdır [28].

Durdurma kurallarında kullanılan yaygın parametreler şunlardır:

- (a) Bir yapraktaki minimum kayıt sayısı;
- (b) Bölünmeden önce bir düğümdeki minimum kayıt sayısı;
- (c) Kök düğümden herhangi bir yaprağın derinliği (yani adım sayısı).

Durdurma parametreleri, analizin amacına ve kullanılan veri kümesinin özelliklerine göre seçilmelidir. Genel bir kural olarak, Berry ve Linoff, bir yaprak düğümündeki kayıtların hedef oranını tam eğitim veri kümesinin %0,25 ila %1,00'i arasında olacak şekilde ayarlayarak aşırı uydurma ve yetersiz sığdırma durumlarından kaçınmayı önerir [28].

İki tür budama vardır:

- 1) Ön budama (ileri budama)
- 2) Budama sonrası (geriye doğru budama)

Ön budama, önemli olmayan dalların oluşumunu önlemek için Ki-kare testleri veya çoklu karşılaştırma ayarlama yöntemlerini kullanır. Budama sonrası, doğrulama veri kümesine uygulandığında genel sınıflandırmanın doğruluğunu artıracak şekilde dalları kaldırmak için tam bir karar ağacı oluşturulduktan sonra kullanılır [28].

3.2.2. Karar ağacı algoritmaları ve CART algoritması

J. R. Quinlan tarafından tanımlanan ID3 algoritması, niteliklerle ilişkili bilgi kazanımına dayanarak bir sonraki nitelikleri seçen açgözlü bir algoritmadır. En yüksek bilgi kazancına veya en büyük entropi azalmasına sahip öznitelik, geçerli düğüm için test özniteliği olarak seçilir. En popüler algoritma olan C4.5, ID3'ün halefidir. C4.5, ID3'te bir dizi iyileştirme yapmıştır. C4.5, özellik seçim ölçüsü olarak kazanç oranını kullanır. Ayrıca C4.5 hem ayrık hem de sürekli özniteliği işleyebilir [29].

Breiman tarafından önerilen CART algoritması, kavramsal olarak ID3'ünkiyle aynıdır. CART'taki değişkenin seçiminde kullanılan safsızlık ölçüsü Gini endeksidir. Hedef değişken nominal ise, sınıflandırma ağacı oluşturur ve sürekli değerli sayısal hedef değişken için regresyon ağacı oluşturur. CHAID, ağaç yapımı için Ki-kare olasılık testini iki şekilde kullanır. İlk olarak, tahmindeki seviyelerin birleştirilip birleştirilemeyeceğini belirler.

Tüm tahminci seviyeleri en küçük anlamlı formlarına sıkıştırıldıktan sonra, bağımlı değişken seviyeleri arasında ayırım yapmada en önemli tahminciyi belirler [29].

CART, sınıflandırma ve regresyon ağaçları anlamına gelir ve 1984 yılında Breiman tarafından tanıtılmıştır. Hem sınıflandırmalar hem de regresyon ağaçları oluşturur. CART tarafından sınıflandırma ağacı yapısı, özniteliklerin ikili bölünmesine dayanır. Bölme niteliğini seçerken gini indeksi bölme ölçüsünü kullanır. En iyi bölme noktasını belirlemede gini indeksi, symgini vb. gibi birçok tek değişkenli bölme kriteri kullanır ve veriler en iyi bölme noktasını belirlemek için her düğümde saklanır. Regresyon analizi sırasında doğrusal kombinasyon bölme kriterleri kullanılır [30].

Karar ağaçları içinde iki farklı metodoloji ayırt edilebilir: Sınıflandırma Ağaçları ve Regresyon Ağaçları. Karar ağacını indüklemek için, veri kümesinden özyinelemeli bölünme ve çoklu regresyonlar gerçekleştirilir. Kök düğümünden, ağacın bir kuralının her iç düğümündeki veri bölme işlemi, daha önce belirtilen bir durdurma koşuluna ulaşılan kadar yinelenir. Uç düğümlerin veya yaprakların her biri, kendisine yalnızca o düğümde geçerli olan basit bir regresyon modeli ilişirmiştir. Ağacın indüksiyon işlemi tamamlandıktan sonra, yapısal karmaşıklığını azaltarak ağacın genelleme kapasitesini geliştirmek amacıyla budama uygulanabilir. Düğümlerdeki vaka sayısı budama kriteri olarak alınabilir. Karar ağacının indüksiyonu ilk önce optimal bölme ölçüm vektörlerinin seçilmesini içerir. İşlem, bağımlı özelliği veya üst düğümü (kök), alt düğümlerin üst düğümünden 'daha saf' olduğu ikili parçalara bölerek başlar. Bu süreç boyunca, karar ağacı, ortaya çıkan ağacın 'saflığını' en üst düzeye çıkaran en uygun bölünmeyi bulmak için tüm aday bölmeleri araştırır [31].

$$\Delta i(s, t) = i(t) - p_L i(t_L) - p_R i(t_R) \quad (3.6)$$

Denklem 3.6'da s, t düğümünde bölünmeye aday olan düğümdür ve t düğümü, p_L oranı ile sol alt düğüm t_L 'ye s ile bölünür ve $p_R \cdot i(t)$ oranıyla sağ alt düğüm t_R , bölünmeden önce bir safsızlık ölçüsüdür, $i(t_L)$ ve $i(t_R)$ bölünmeden sonra safsızlık ölçümleridir, $\Delta i(s, t)$, bölünmelerden kaynaklanan safsızlıktaki azalmayı ölçer. Kirliliği ölçmek için birçok yaklaşım vardır. En sık görülenlerden bazıları kazanç oranı, Gini indeksi ve Ki-karedir. En yaygın önlem Gini endeksidir. Gini endeksi, $i(t)$:

$$I_G(t_{X(x_i)}) = 1 - \sum_{j=1}^m f(t_{X(x_i), j})^2 \quad (3.7)$$

Denklem 3.7’de, $f(t_{X(x_i)}, j)$, j ’yi t düğümü olarak bırakmak için x_i değerine sahip örneklerin oranıdır. Karar ağacı bölme kriteri, en düşük Gini safsızlık indeksine sahip niteliğin seçilmesine dayanır [31].

3.3. Topluluk Öğrenimi

Topluluk öğrenimi, birden fazla makine öğrencisinin aynı problemi çözmek için eğitildiği bir makine öğrenmesi tekniğidir. Topluluk yöntemleri bir dizi hipotez oluşturmaya ve bunları kullanmak üzere birleştirmeye çalışır. Bir topluluktan oluşan öğrencilere genellikle temel öğrenciler denir. 1990 yılında Hansen ve Salamon, benzer şekilde yapılandırılmış YSA’lardan oluşan bir topluluk kullanılarak bir YSA’nın genelleme performansının geliştirilebileceğini göstermiştir. Schapire, muhtemelen yaklaşık olarak doğru anlamda güçlü bir sınıflandırıcının, AdaBoost algoritmaları paketinin selefi olan Boosting aracılığıyla zayıf sınıflandırıcıların birleştirilmesiyle üretilbileceğini kanıtlamıştır. Bir topluluğun genelleme yeteneği genellikle tek bir öğrencinininkinden çok daha güçlüdür, bu da topluluk yöntemlerini çok çekici kılar. Uygulamada, iyi bir topluluğa ulaşmak için iki gerekli koşulun (doğruluk ve çeşitlilik) yerine getirilmesi gerekir [32].

3.3.1. Bagging (torbalama) algoritması

Bagging en eski topluluk öğrenimi algoritmalarından biridir. Aynı zamanda iyi bir performansla uygulanması en sezgisel ve en basit olanlardan biridir. Etiketlemede çeşitlilik, eğitim verilerinin önyüklenmiş kopyaları kullanılarak elde edilir. Her eğitim verisi alt kümesi, aynı türde farklı bir temel öğrenciyi eğitmek için kullanılır. Bagging algoritmasının sözde kodu Tablo 3.2’de gösterilmiştir. Bagging, mevcut veriler sınırlı boyutta olduğunda özellikle çekicidir. Her alt kümede yeterli eğitim örneği olduğundan emin olmak için, örneklerin nispeten büyük bölümleri (%75-100) her bir alt kümeye çekilir. Bu, tek tek eğitim alt kümelerinin önemli ölçüde çakışmasına neden olur, aynı örneklerin çoğu alt kümede görünür ve bazı örnekler belirli bir alt kümede birden çok kez görünür. Bu senaryoda çeşitliliği sağlamak için, nispeten dengesiz bir temel öğrenci kullanılır, böylece farklı eğitim veri kümelerindeki küçük karışıklıklar için yeterince farklı karar sınırları elde edilebilir [32].

Tablo 3.2. Bagging algoritmasının sözde kodu

Girdi: Veri seti $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$;
Temel öğrenme algoritması L ;
Öğrenme turlarının sayısı T .
İşlem:
For $t = 1, 2, \dots, T$:
 $D_t = Bootstrap(D)$; D 'den bir önyükleme örneği oluştur
 $h_t = L(D_t)$ Önyükleme örneği sonunda bir temel öğrenici h_t eğitin.
Çıktı: $H(x) = \operatorname{argmax}_{y \in Y} \sum_{t=1}^T 1(y = h_t(x))$ $1(\alpha)$ 'nın değeri, α doğruysa 1, aksi takdirde 0'dır.

3.3.2. Boosted (artırma) algoritması

Boosted bir yöntem ailesini kapsar. Bagging'in aksine Boosted, eğitim veri kümesindeki örnekleri sırayla yeniden ağırlıklandırarak farklı temel öğreniciler oluşturur. Önceki temel öğrenici tarafından yanlış sınıflandırılan her örnek, bir sonraki eğitim turunda daha büyük bir ağırlık kazanacaktır. Boosted algoritmasının temel fikri, bir temel öğreniciyi eğitim veri kümesinin değiştirilmiş sürümlerine tekrar tekrar uygulamak ve böylece önceden tanımlanmış sayıda yineleme için bir dizi temel öğrenici üretmektir. Başlangıç olarak, tüm örnekler tekdüze ağırlıklarla başlatılır. Bu başlatmadan sonra, her yükseltme yinelemesi ağırlıklı eğitim verilerine bir temel öğreniciye uyar. Hata hesaplanır ve yanlış sınıflandırılmış örnekler daha yüksek ağırlıklar alırken doğru sınıflandırılmış örneklerin ağırlığı düşürülür. Boosted algoritması tarafından elde edilen son model, kendi performanslarına göre ağırlıklandırılmış birkaç temel öğrencinin doğrusal bir kombinasyonudur. Boosted algoritmalarının birkaç versiyonu olmasına rağmen, en yaygın kullanılanı AdaBoost olarak bilinen algoritmadır. AdaBoost algoritmasının sözde kodu Tablo 3.3.'te verilmiştir [32].

Tablo 3.3. AdaBoost algoritmasının sözde kodu

Girdi: Veri seti $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$;

Temel öğrenme algoritması L ;

Öğrenme turlarının sayısı T

İşlem:

$D_1(i) = 1/m$ Ağırlık dağılımını başlat

For $t = 1, 2, \dots, T$:

$h_t = L(D, D_t)$; D_t dağılımını kullanarak D 'den temel bir
öğrenci h_t eğit

$\varepsilon_t = \Pr_{i \sim D_t}[h_t(x_i) \neq y_i]$ h_t 'nin hatasını ölç

$\alpha_t = \frac{1}{2} \ln \frac{1-\varepsilon_t}{\varepsilon_t}$; h_t 'nin ağırlığını belirle

$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times f(x) = \begin{cases} \exp(-\alpha_t), & \text{if } h_t(x_i) = y_i \\ \exp(\alpha_t), & \text{if } h_t(x_i) \neq y_i \end{cases}$ Dağıtımı güncelle,

burada Z_t normalleştirme faktörüdür ve D_{t+1} 'in bir dağıtım sonu olmasını sağlar.

$$= \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t}$$


Çıktı: $H(x) = \text{sign}(f(x)) = \text{sign} \sum_{t=1}^T \alpha_t h_t(x)$

4. ARAŞTIRMA BULGULARI

Bu bölümde, kauçuk bileşiklerinin proses parametreleri ve hammadde girdi ağırlıkları (kg) kullanılarak, kauçuk bileşiklerin mekanik özelliklerinin tahmin edilmesi için yapay zekâ teknikleri modelleri önerilmiştir. Önerilen YSA, regresyon ağaçları ve ağaç toplulukları yaklaşımlarının sonuçlarının, tahminlemede ne kadar etkili olduğunu görmek için hesaplamalı bir çalışma yapılmıştır. Algoritmalar MATLAB R2023a kullanılarak oluşturulmuştur, 16 GB RAM ve Intel i5 11400 H CPU'ya sahip bir bilgisayarda test edilmiştir.

Kauçuk bileşiklerin karıştırıldığı Dalian CanMade marka Banbury, 2 kanatlı tangential bıçak tipine sahiptir, değişken devirli servo motor ile kauçuk bileşiklerini karıştırmaktadır. Motor 5-40 rpm çalışma aralığına sahiptir. 20 Mpa çalışma basıncına, 1500 L proses yağı tankına, 10°C ile 150°C proses çalışma sıcaklığı aralığına sahiptir.

Şekil 4.1’de uygulamada kullanılan girdiler, yapay zekâ teknikleri ve planlanan çıktı sonuçları gösterilmiştir.



Şekil 4.1. Uygulamada kullanılacak girdiler, yapay zekâ teknikleri ve planlanan çıktı sonuçları

Veri setinde 76 farklı tipte çeşitli lastiklerin üretiminde kullanılan kauçuk bileşikleri yer almaktadır. Her bir bileşikte kullanılan hammadde ağırlıkları (kg) ve proses süreleri (dk), kauçuğun dört farklı mekanik özelliği için veri setinin bütünü oluşturulmaktadır.


Veri seti hazırlandıktan sonra, test değerleri ile girdi verisini oluşturan hammadde ağırlıklarının ve proses sürelerinin, mekanik özellikler üzerindeki anlamlılığını hesaplamak için, mekanik özellik değerleri için normallik testleri yapılmıştır. Her bir mekanik özellik için ayrı ayrı normallik testi yapılmıştır. Normallik testleri IBM SPSS Statistic 29 programında yapılmıştır. Örneklem sayısı 50 adedin üzerinde olduğu için, test sonucunun değerlendirilmesinde Kolmogorov – Smirnov test sonucu dikkate alınmıştır. Tablo 4.1’de Sertlik özelliği için normallik testi sonuçları verilmiştir.

Tablo 4.1. Sertlik özelliği için normallik testi sonucu

Sertlik	Tests of Normality					
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
	0.119	76	<u>0.010</u>	0.953	76	0

Sig. değerinin 0,05 değerinden büyük olduğu durumlarda verinin normal dağıldığı, 0,05 değerinden küçük olduğu durumlarda verinin normal dağılmadığı göz önüne alınarak, sertlik özelliğinin test sonuçlarının normal dağılmadığı görülmüştür.

Şekil 4.2.’de Sertlik özelliğinin test değerlerine ait histogram grafiği verilmiştir.



Şekil 4.2. Sertlik özelliği değerlerine ait histogram grafiği


Tablo 4.2’de Çekme mukavemetine ait test değerlerinin normallik testi sonucu verilmiştir.

Tablo 4.2. Çekme mukavemeti özelliği için normallik testi sonucu

Çekme Mukavemeti	Tests of Normality					
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
	0.080	76	<u>.200*</u>	0.964	76	0.031

Çekme mukavemeti özelliği için yapılan normallik testi sonucunda, Kolmogorov – Smirnov test sonucu 0,05 değerinden büyük olduğu için, verilerin normal dağıldığı görülmüştür.

Şekil 4.3.’te Çekme mukavemeti için histogram grafiği verilmiştir.



Şekil 4.3. Çekme mukavemeti özelliği değerlerine ait histogram grafiği


Tablo 4.3’te Kopma uzama test değerleri için normallik testi sonucu verilmiştir.

Tablo 4.3. Kopma uzama özelliği için normallik testi sonucu

Kopma Uzama	Tests of Normality					
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
	0.121	76	<u>0.008</u>	0.929	76	0.000

Kopma uzama özelliği için yapılan normallik testi sonucunda, Kolmogorov – Smirnov test sonucu 0,05 değerinden küçük olduğu için, verilerin normal dağılmadığı görülmüştür.

Şekil 4.4'te Kopma uzama değerlerine ait histogram grafiği verilmiştir.



Şekil 4.4. Kopma uzama özelliği değerlerine ait histogram grafiği

Tablo 4.4'te Yırtılma mukavemeti test değerleri için normallik testi sonucu verilmiştir.

Tablo 4.4. Yırtılma mukavemeti özelliği için normallik testi sonucu

Yırtılma Mukavemeti	Tests of Normality					
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
	0.133	76	<u>0.002</u>	0.928	76	0.000

Yırtılma mukavemeti özelliği için yapılan normallik testi sonucunda, Kolmogorov – Smirnov test sonucu 0,05 değerinden küçük olduğu için, verilerin normal dağılmadığı görülmüştür.

Dört özellik için yapılan normallik testi sonucu özet olarak Tablo 4.5'te verilmiştir.

Tablo 4.5. Kauçuk bileşiklerin mekanik özellikleri için normallik testi sonuçları

Mekanik Özellik	Dağılım Özelliği
Sertlik	Normal Dağılım Yok
Çekme Mukavemeti	Normal Dağılım
Kopma Uzama	Normal Dağılım Yok
Yırtılma Mukavemeti	Normal Dağılım Yok

Kauçuğun dört farklı mekanik özelliği için normallik testi sonucuna göre, her bir mekanik özellik için, 29 farklı hammadde ve 2 farklı proses süresi ile her bir mekanik özellik için ayrı ayrı korelasyon testi yapılmıştır. Normal dağılım gösteren test özelliği için korelasyon testinde korelasyon katsayısı olarak Pearson kullanılırken, normal dağılım göstermeyen test özellikler için Spearman korelasyon katsayısı kullanılmıştır.

Her bir mekanik özellik için yapılan korelasyon testi sonucunda, her bir özellik üzerinde anlamlı bir değişiklik oluşturan girdi değişkenleri belirlenmiştir. Anlamlı bir değişiklik gösteren girdi değişkenleri belirlenirken, SPSS test sonucunda Sig. (2-tailed) değeri göz önüne alınmıştır. Sig. (2-tailed) değeri, her bir girdi değişkeni, her bir mekanik özellik için 0,05 değerinde küçük ise girdi değişkeninin test değeri üzerinde anlamlı bir değişikliği sahip olduğu, 0,05 değerinde büyük ise girdi değişkeninin test değeri üzerinde anlamlı bir değişikliği sahip olmadığı belirlenmiştir. Tablo 4.6.'da korelasyon testi sonucuna göre her bir mekanik özellik için, yapay zeka tekniklerinde kullanılacak girdi değişkenleri belirlenmiştir.


Tablo 4.6. Her bir mekanik özellik için yapılan korelasyon testi sonucu

Mekanik Özellik	Test Değerleri Üzerinde Anlamlı Değişiklik Gösteren Hammadde Girdi Sayısı	Test Değerleri Üzerinde Anlamlı Değişiklik Gösteren Proses Süresi Sayısı
Sertlik	4	0
Çekme Mukavemeti	2	0
Kopma Uzama	0	0
Yırtılma Mukavemeti	4	0

Korelasyon testi sonucuna göre her bir mekanik özellik için, yapay zeka tekniklerinde kullanılacak girdi değişkenleri belirlenmiştir. Sertlik özelliği için, 4 farklı hammadde girdi değişkeninin, test değerleri üzerinde anlamlı olduğu belirlenirken, 2 farklı proses süresinden herhangi birinin sertlik test değerleri üzerinde anlamlı olmadığı görülmüştür. Çekme mukavemeti özelliği için, 2 farklı hammadde girdi değişkeninin test değerleri üzerinde anlamlı olduğu belirlenmiştir. Kopma uzama için, 29 farklı hammadde ve 2 farklı proses süre girdisinden hiçbirinin test değerlerinde anlamlı bir etki oluşturmadığı görülmüştür.

Yırtılma mukavemeti özelliği için 4 farklı hammadde girdi değişkeninin test değerleri üzerinde anlamlı bir değişiklik gösterdiği belirlenirken, herhangi bir proses süresinin test değerleri üzerinde anlamlı bir değişiklik göstermediği görülmüştür.

Mekanik özellikler üzerinde anlamlı değişiklik gösteren hammaddelerin girdi ağırlıkları ile her bir mekanik özellik için veri setleri oluşturulmuştur. Çıktı verisi olarak mekanik özelliklerin test sonucu değerleri kullanılmıştır.



Şekil 4.5. Yapay sinir ağı ile tahminleme akış şeması

Yapay sinir ağlarında kullanılacak transfer fonksiyonu ve öğrenme algoritması için 1 gizli katmana sahip 5 nöronlu bir rassal yapay sinir ağı tasarlanmıştır. Tasarlanan yapay sinir ağlarında 76 kauçuk karışım reçete verisinin %70'i öğrenme verisi, %15'i doğrulama verisi ve %15'i test verisi olarak rassal şekilde ayrılmıştır. Her bir mekanik özellik için ayrı ayrı çalıştırmalar yapılmıştır. Tüm transfer fonksiyonları ve öğrenme algoritmaları için 50 kez çalıştırma yapılmıştır. Değerlendirme ölçütü olarak test verilerinin MSE ve MAPE değerleri karşılaştırılmıştır.

Tablo 4.7’de sertlik özelliği için öğrenme algoritması ve transfer fonksiyonun belirlenmesi için oluşturulan yapay sinir ağlarının MSE ve MAPE değerleri verilmiştir.

Tablo 4.7. Sertlik için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi

Transfer Fonksiyonu	Sertlik					
	Levenberg- Marquardt		Bayes Ağları		Ölçeklendirilmiş Eşlenik Gradyan	
	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
Tan-Sigmoid	43.04	8.19	31.55	7.17	37.39	7.74
Radial basis	137.18	9.40	32.01	7.22	37.67	7.78
Log-Sigmoid	41.85	8.07	<u>31.19</u>	<u>7.14</u>	34.23	7.50

Tablo 4.8’de çekme mukavemeti özelliği için öğrenme algoritması ve transfer fonksiyonun belirlenmesi için oluşturulan yapay sinir ağlarının MSE ve MAPE değerleri verilmiştir.

Tablo 4.8. Çekme mukavemeti için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi

Transfer Fonksiyonu	Çekme Mukavemeti					
	Levenberg- Marquardt		Bayes Ağları		Ölçeklendirilmiş Eşlenik Gradyan	
	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
Tan-Sigmoid	1308.45	23.98	<u>945.21</u>	<u>22.09</u>	1100.38	23.58
Radial basis	1619.84	26.28	945.30	22.10	1076.86	23.21
Log-Sigmoid	1510.59	25.83	949.57	22.19	1061.10	23.10

Tablo 4.9’da yırtılma mukavemeti özelliği için öğrenme algoritması ve transfer fonksiyonun belirlenmesi için oluşturulan yapay sinir ağlarının MSE ve MAPE değerleri verilmiştir.

Tablo 4.9. Yırtılma mukavemeti için öğrenme algoritmasının ve transfer fonksiyonunun belirlenmesi

Transfer Fonksiyonu	Yırtılma Mukavemeti					
	Levenberg- Marquardt		Bayes Ağları		Ölçeklendirilmiş Eşlenik Gradyan	
	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
Tan-Sigmoid	163.53	19.92	95.89	18.13	102.56	18.72
Radial basis	137.58	19.49	<u>95.56</u>	<u>18.12</u>	105.22	18.17
Log-Sigmoid	172.08	20.68	96.15	18.17	97.99	18.45

Sertlik özelliği için öğrenme algoritması Bayes ağları, transfer fonksiyonu Log-sigmoid olan yapay sinir ağı en iyi tahmin performansını göstermiştir. Çekme mukavemeti için ise öğrenme algoritması olarak Bayes ağları, transfer fonksiyonu Tan-sigmoid olan yapay sinir ağı en iyi tahmin performansını göstermiştir. Yırtılma mukavemeti için öğrenme algoritması olarak Bayes ağları, transfer fonksiyonu olarak radyal tabanlı transfer fonksiyonu olan radial basis en iyi tahmin performansını göstermiştir.

Mekanik özellikler için transfer fonksiyonu ve öğrenme algoritması belirlendikten sonra, gizli katman sayısı ve nöron sayısının belirlenmesi için literatürde kesin bir yöntem olmamasından dolayı, deneme yanılma yolu ile varsayımsal olarak 5 – 10 – 20 nöronlu ve 1 gizli katman – 2 gizli katmana sahip yapay sinir ağları oluşturulmuştur. Her bir mekanik özellik için ayrı ayrı yapay sinir ağları çalıştırılmıştır ve test verilerinin MSE ve MAPE değerleri göz önüne alınarak tahmin performansları değerlendirilmiştir.

Tablo 4.10’da sertlik özelliğinin gizli katman sayısı ve nöron sayısının belirlenmesi için oluşturulan yapay sinir ağlarının tahmin performansları gösterilmiştir.

Tablo 4.10. Sertlik özelliği için gizli katman ve nöron sayısının belirlenmesi

Bayes Ağları - Log Sigmoid - Sertlik						
Nöron	5		10		20	
Gizli Katman	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
1	28.91	6.71	28.36	6.62	<u>27.81</u>	<u>6.61</u>
2	27.83	6.71	30.52	6.85	30.69	7.13

Tablo 4.11’de çekme mukavemeti özelliğinin gizli katman sayısı ve nöron sayısının belirlenmesi için oluşturulan yapay sinir ağlarının tahmin performansları gösterilmiştir.

Tablo 4.11. Çekme mukavemeti için gizli katman ve nöron sayısının belirlenmesi

Bayes Ağları - Tan Sigmoid - Çekme Mukavemeti						
Nöron	5		10		20	
Gizli Katman	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
1	945.21	22.09	995.79	23.96	1122.28	23.56
2	<u>940.88</u>	<u>22.08</u>	1152.37	26.31	1228.54	26.24

Tablo 4.12’de yırtılma mukavemeti özelliğinin gizli katman sayısı ve nöron sayısının belirlenmesi için oluşturulan yapay sinir ağlarının tahmin performansları gösterilmiştir.

Tablo 4.12. Yırtılma mukavemeti için gizli katman ve nöron sayısının belirlenmesi

Bayes Ağları - Radial Basis - Yırtılma Mukavemeti						
Nöron	5		10		20	
Gizli Katman	Test MSE	Test MAPE	Test MSE	Test MAPE	Test MSE	Test MAPE
1	99.60	18.38	103.71	19.59	103.90	19.33
2	108.82	20.27	109.98	19.50	110.14	20.34

Her bir mekanik özellik için belirlenen transfer fonksiyonu, öğrenme algoritması, gizli katman sayısı ve nöron sayısı Tablo 4.13’te verilmiştir.

Tablo 4.13. Mekanik özellikler için belirlenen yapay sinir ağı parametreleri

Mekanik Özellik	Transfer Fonksiyonu	Öğrenme Algoritması	Gizli Katman Sayısı	Nöron Sayısı
Sertlik	Bayes Ağları	Log-Sigmoid	1	20
Çekme Mukavemeti	Bayes Ağları	Tan-Sigmoid	2	5 - 5
Yırtılma Mukavemeti	Bayes Ağları	Radial basis	1	5

Mekanik özellikler için belirlenen yapay sinir ağı parametrelerinden sonra, bu parametreler ile her bir mekanik özellik için yapay sinir ağları oluşturulmuş ve Tablo 4.14 ile Tablo 4.15’te öğrenme – eğitim – test - tüm veriler için ortalama MSE ile R^2 değerleri ile birlikte standart sapmaları hesaplanmıştır.

Tablo 4.14. Yapay sinir ağlarının ortalama MSE ve R^2 tahmin performansı


Özellik	Eğitim MSE	Test MSE	Tüm MSE	Eğitim R^2	Test R^2	Tüm R^2
Sertlik	24.57	27.85	25.04	0.48	0.39	0.47
Çekme Mukavemeti	907.76	940.88	912.55	0.47	0.35	0.46
Yırtılma Mukavemeti	72.89	99.60	76.75	0.57	0.26	0.53

Tablo 4.15. Yapay sinir ağlarının ortalama R^2 tahmin performanslarının standart sapması

Özellik	Eğitim R^2	Test R^2	Tüm R^2
Sertlik	0.04	0.26	0.01
Çekme Mukavemeti	0.02	0.19	0.01
Yırtılma Mukavemeti	0.05	0.28	0.02

Her bir mekanik özellik için yapay sinir ağlarından sonra, regresyon ağaçları yöntemi ile tahminleme yapılmış ve tahmin performansının değerlendirilmesi için 50 çalıştırma için ortalama MSE, MAPE ve R^2 değerleri hesaplanmıştır.

Şekil 4.6.'da regresyon ağaçları ile yapılan tahminlemenin adımları gösterilmiştir.

**Şekil 4.6.** Regresyon ağaçları ile tahminleme akış şeması

Tablo 4.16’da her bir mekanik özellik için regresyon ağaçları ile yapılan tahminlerin eğitim, doğrulama, test ve tüm veri seti için MSE ve MAPE değerleri hesaplanmıştır. Doğrulama için çapraz doğrulama yöntemi kullanılmıştır. Her bir tip ağaç için 50 kez çalıştırma yapılmıştır. Tip olarak verilen yaprak sayısındaki amaç, modelin yanıt esnekliğini kontrol etmektir. Oldukça esnek bir yanıt fonksiyonu için yaprak sayısı minimum 4, orta düzeyde esnek bir yanıt fonksiyonu için yaprak sayısı minimum 12 ve kaba bir esneklikte yanıt fonksiyonu için yaprak sayısı minimum 36 olarak belirlenmiştir. Regresyon ağaçları ve ağaç topluluklarında yaprak sayısı minimum yaprak sayılarını karşılayacak şekilde seçilmiştir.

Tablo 4.16. Regresyon ağaçları ortalama MSE-MAPE değerleri

Özellik	Tip	Yaprak Sayısı	Eğitim MSE	Doğrulama MSE	Test MSE	Tüm MSE	Eğitim MAPE	Test MAPE	Tüm MAPE
Sertlik	İyi	4	1.98	3.83	3.22	2.22	0.75	1.00	0.79
	Orta	12	5.15	9.18	5.84	5.26	2.35	2.41	2.36
	Kaba	36	31.44	33.22	31.30	31.93	7.48	7.30	7.45
Çekme Mukavemeti	İyi	4	36.87	76.15	61.31	40.40	3.98	5.19	4.15
	Orta	12	124.92	202.74	157.65	129.65	8.54	9.77	8.72
	Kaba	36	1097.03	1132.53	1165.82	1106.99	25.71	27.07	25.91
Yırtılma Mukavemeti	İyi	4	4.42	9.63	5.88	4.63	3.12	3.71	3.21
	Orta	12	16.34	28.42	18.32	16.62	6.96	7.43	7.03
	Kaba	36	106.88	110.83	101.55	106.11	19.99	19.72	19.95


Tablo 4.17’de, Tablo 4.16’da yer alan MSE ve MAPE değerlerine ait R^2 değerleri ve bu değerlere ait standart sapmalar gösterilmiştir.

Tablo 4.17. Regresyon ağaçları için hesaplanan R^2 ve R^2 değerlerine ait standart sapmalar

Özellik	Tip	Yaprak Sayısı	Ortalama R^2			Standart Sapma		
			Eğitim R^2	Test R^2	Tüm R^2	Eğitim R^2	Test R^2	Tüm R^2
Sertlik	İyi	4	0.96	0.96	<u>0.96</u>	0.01	0.06	0.01
	Orta	12	0.91	0.94	0.91	0.02	0.07	0.01
	Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
Çekme Mukavemeti	İyi	4	0.98	0.97	<u>0.98</u>	0.00	0.04	0.01
	Orta	12	0.94	0.93	0.94	0.01	0.06	0.00
	Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
Yırtılma Mukavemeti	İyi	4	0.97	0.98	<u>0.97</u>	0.01	0.02	0.00
	Orta	12	0.92	0.93	0.92	0.02	0.03	0.02
	Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00

Regresyon ağaçları ile her bir mekanik özellik için tahminleme yapıldıktan sonra, Ağaç toplulukları yöntemleri ile algoritmalar oluşturulmuş ve her bir mekanik özellik için tahminlemeler yapılmıştır. Ağaç topluluklarında, regresyon ağaçlarına ek olarak iki farklı algoritma ile (Bagged ve Boosted) mekanik özellikler ve farklı yaprak sayıları için 50 kez çalıştırma yapılmıştır. Matlab, Bagged için Random Forest algoritmasını kullanırken, Boosted için Freidman’ın en küçük kareler için gradyan artırma stratejisini kullanır. Tahminleme yapılırken çapraz doğrulama yöntemi kullanılmıştır.

Şekil 4.7’de Ağaç toplulukları ile yapılan tahminleme çalışmasına ait akış şeması verilmiştir.



Şekil 4.7. Ağaç toplulukları yöntemi için akış şeması

Tablo 4.18’de Ağaç toplulukları ile yapılan tahminlemelere ait ortalama R^2 ve MAPE değerleri verilmiştir.

Tablo 4.18. Ağaç toplulukları ile yapılan tahminlemelerin MSE ve MAPE performansları

Özellik	Tip	Yaprak Sayısı	Eğitim MSE	Doğrulama MSE	Test MSE	Tüm MSE	Eğitim MAPE	Test MAPE	Tüm MAPE
Sertlik	İyi	4	3.65	8.33	6.61	4.08	1.82	2.56	1.93
	Bagged	Orta	12	9.21	13.89	11.03	9.48	3.17	3.22
		Kaba	36	32.06	33.24	31.40	31.96	7.48	7.46
	İyi	4	0.00	5.29	4.11	0.59	0.02	1.84	0.28
	Boosted	Orta	12	1.14	10.06	7.42	2.05	1.20	1.47
		Kaba	36	32.04	33.22	31.30	31.93	7.48	7.45
Çekme Mukavemeti	İyi	4	180.58	300.25	280.85	195.09	9.51	12.29	9.91
	Bagged	Orta	12	402.71	534.20	480.84	414.02	14.48	14.73
		Kaba	36	1097.60	1133.56	1171.23	1108.26	25.71	25.91
	İyi	4	0.11	79.42	42.76	6.29	0.10	4.00	0.67
	Boosted	Orta	12	32.57	150.55	138.17	47.85	3.44	4.15
		Kaba	36	1097.03	1132.53	1165.82	1106.99	25.71	27.07
Yırtılma Mukavemeti	İyi	4	12.60	25.87	17.10	13.25	5.43	6.45	5.58
	Bagged	Orta	12	33.42	45.01	35.29	33.69	9.62	10.13
		Kaba	36	106.98	111.05	102.16	106.28	19.99	19.77
	İyi	4	0.22	9.96	3.93	0.76	0.21	2.53	0.55
	Boosted	Orta	12	7.27	18.65	15.85	8.51	4.10	4.48
		Kaba	36	106.88	110.83	101.55	106.11	19.99	19.72

Tablo 4.19’da, Tablo 4.18’de verilen değerlere ait R^2 değerleri ve bu değerlere ait standart sapmalar verilmiştir.

Tablo 4.19. Ağaç toplulukları tekniğinin ortalama R^2 değerleri ve bu değerlere ait standart sapmalar

Özellik	Tip	Ortalama R2				Standart Sapma			
		Yaprak Sayısı	Eğitim R ²	Test R ²	Tüm R ²	Eğitim R ²	Test R ²	Tüm R ²	
Sertlik	Bagged	İyi	4	0.95	0.92	0.94	0.01	0.05	0.01
		Orta	12	0.88	0.87	0.88	0.02	0.07	0.02
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
	Boosted	İyi	4	1.00	0.95	<u>0.99</u>	0.00	0.05	0.01
		Orta	12	0.98	0.91	0.96	0.01	0.06	0.01
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
Çekme Mukavemeti	Bagged	İyi	4	0.95	0.90	0.94	0.01	0.04	0.01
		Orta	12	0.91	0.87	0.90	0.02	0.06	0.02
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
	Boosted	İyi	4	0.99	0.96	<u>0.99</u>	0.01	0.05	0.01
		Orta	12	0.98	0.92	0.97	0.01	0.05	0.01
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
Yırtılma Mukavemeti	Bagged	İyi	4	0.95	0.94	0.95	0.01	0.03	0.01
		Orta	12	0.89	0.87	0.89	0.01	0.07	0.03
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00
	Boosted	İyi	4	0.99	0.98	<u>0.99</u>	0.00	0.01	0.00
		Orta	12	0.96	0.94	0.95	0.01	0.03	0.01
		Kaba	36	0.00	0.00	0.00	0.00	0.00	0.00

Tablo 4.20’de, her bir mekanik özellik için kullanılan yapay zeka tekniklerine ait en iyi tahmin performansı gösteren Tüm R^2 ortalama değerlerinin birbirleri ile karşılaştırma tablosu verilmiştir.

Tablo 4.20. Tahminlemede kullanılan 3 farklı yapay zekâ tekniğinin R^2 performanslarının karşılaştırılması

Mekanik Özellik	Yapay Sinir Ağları	Regresyon Ağaçları	Ağaç Toplulukları
Sertlik	0.474	0.961	<u>0.988</u>
Çekme Mukavemeti	0.464	0.978	<u>0.997</u>
Yırtılma Mukavemeti	0.533	0.970	<u>0.989</u>

Ağaç toplulukları yönteminin, yapay sinir ağları ve regresyon ağaçları yöntemine kıyasla daha iyi performans gösterdiği görülmüştür. Regresyon ağaçları ise Ağaç topluluklarına yakın bir tahmin performansı göstermiştir. Yapay sinir ağlarının tahmin performansı ise diğer iki performansın yanında düşük kalmıştır.



5. SONUÇ VE ÖNERİLER

Bu çalışmada, günümüzde endüstride sıklıkla kullanılan kauçuk bileşiklerinin, karakterizasyonunu ve niteliğini gösteren, pahalı ve farklı türde ekipmanlar gerektiren labarotuar testleri ile belirlenen ve günümüzde oldukça popüler olan yapay zekâ tekniklerine kıyasla daha uzun süren kauçuk bileşiklerin mekanik özelliklerini belirlemek için yapay zekâ teknikleri önerilmiştir. Yapay zekâ teknikleri arasında yer alan, sınıflandırma ve tahminlemede kullanılan popüler tekniklerden olan YSA, regresyon ağaçları ve ağaç toplulukları teknikleri bu çalışmada mekanik özelliklerin tahminlemede kullanılmıştır. Algoritmaların giriş değişkenleri, yoğun olarak lastik üretiminde kullanılan farklı kauçuk bileşiklerinin ve proses koşullarının formülasyonları olarak belirlenmiştir. Kauçuk çeşitlerinin miktarları ve kauçuk bileşiklerindeki tüm kimyasallar, dolgu malzemeleri ve proses kolaylaştırıcı yağların kilogram cinsinden miktarları bileşik formülasyonlarında kullanılmıştır. Proses koşulları, ana kademe ve son kademe için kauçuk bileşiklerinin dakika cinsinden karıştırma süreleri olarak belirlenmiştir. Sertlik, çekme mukavemeti, kopma uzama ve yırtılma mukavemeti bu çalışmada tahmin edilen mekanik özelliklerdendir. Yapay zekâ tekniklerinde kullanılmak üzere bir veri seti hazırlanmıştır. Bu veri setine 76 farklı tipte kauçuk bileşiği formülasyonu dahil edilmiştir ve bunlar sırasıyla %70, %15, %15 oranlarıyla eğitim, doğrulama ve test verileri olarak rastgele üç gruba ayrılmıştır. Önerilen tekniklerde kullanılmak üzere veri seti üzerinde normallik testi ve korelasyon testi yapılmıştır ve 29 hammadde ile 2 farklı proses süresinin mekanik özellikler üzerindeki etkisi incelenmiştir. İncelemeler neticesinde kopma uzama mekanik özelliği üzerinde 29 hammadde ve 2 farklı proses süresinin etkili olmadığı görülmüştür. Diğer 3 mekanik özellik için, etkili olan hammadde girdi değişkenleri belirlenerek veri seti hazırlanmıştır ve yapay zeka tekniklerinde veri seti olarak kullanılmıştır. Çalışmanın sonunda elde edilen sonuçlar MAPE, MSE ve R^2 değeri olarak ifade edilmiştir ve her bir yapay zekâ tekniği için ayrı ayrı sunulmuştur. Sertlik, çekme mukavemeti ve yırtılma mukavemeti için en iyi performans gösteren tekniklerin R^2 değerleri hepsi için 0.99 olarak bulunmuştur.

Regresyon ağaçlarının ve ağaç topluluklarının tahmin performansları, YSA tahmin sonuçlarını iyileştirir; bu da bu tekniklerin mekanik özellikleri tahmin etmek için kauçuk endüstrisi literatürüne dahil edilmesinin önemini göstermiştir.

Gelecekte, bu çalışmanın tahmin performansı göz önüne alınarak, yapay zekâ teknikleri ile tersine tahminleme yapılarak, kauçuk bileşiklerinde istenilen mekanik özellikler, bu tekniklerde girdi olarak kullanılarak, kauçuk bileşik formülasyonlarının ve proses sürelerinin tahminlemesi yapılabilir. Bu tahminleme ile, hazırlanması uzun zaman alan ve deneyler gerektiren kauçuk bileşik formülasyon tasarımları ve bileşik oluşturmanın önemli bir adımı olan karıştırma süreleri saniyeler içinde tahmin edilerek, kauçuk üretiminin zaman alan başlangıç adımları kısaltılabilir.



KAYNAKLAR

- [1] Vijayabaskar V., Gupta R., Chakrabarti P.P., Bhowmick A.K. (2006). Prediction of Properties of Rubber by Using Artificial Neural Networks. *Journal of Applied Polymer Science*, 100, 2227–2237.
- [2] Sresungsuan N., Hansupalak N. (2013). Prediction of Mechanical Properties of Compatibilized Styrene/Natural Rubber Blend By Using Reaction Conditions: Central Composite Design vs. Artificial Neural Networks. *Journal of Applied Polymer Science*, 127(1), 356 -365.
- [3] Xiang K.L., Xiang P.Y., Wu Y.P. (2014). Prediction of The Fatigue Life of Natural Rubber Composites by Artificial Neural Network Approaches. *Materials and Design*, 57, 180 -185.
- [4] Wang B., Ma J.H., Wu Y.P. (2013). Application of Artificial Neural Network in Prediction of Abrasion of Rubber Composites. *Materials and Design*, 49, 802 -807.
- [5] Joo, C., Park, H., Kwon, H., Lim, J., Shin, E., Cho, H., Kim, J. (2022). Machine Learning Approach to Predict Physical Properties of Polypropylene Composites: Application of MLR, DNN, and Random Forest to Industrial Data. *Materials & Design*, 49, 802-807.
- [6] Ružiak I., Košťál P., Jančíková Z., Gajtanská M., Krišťák L., Kopal I., and Polakovič P. (2018). Artificial Neural Networks Prediction of Rubber Mechanical Properties in Aged and Nonaged State. *Improved Performance of Materials*, 72, 27–35.
- [7] Pang S., Luo J., and Wu Y. (2020). Properties Prediction and Design of Tire Tread Composites Using Machine Learning. *Macromolecular Theory and Simulations*, 29(3), 1900063.
- [8] Fernandez-Martinez, R., Hernandez, R., Ibarretxe, J., Jimbert, P., Iturrondobeitia, M., Guraya-Díez, T. (2014). Modeling of the Mechanical Properties of Carbon-black Reinforced Rubber Blends by Machine Learning Techniques. *Applied Mechanics and Materials*, 627, 97-100.
- [9] Kumar, A., Arora, H. C., Kapoor, R. N., Mohammed, M. A., Kumar, K., Majumdar, A., Thinnukool, O. (2022). Compressive Strength Prediction of Lightweight Concrete: Machine Learning Models. *Sustainability*, 14, 2404.
- [10] Ullah, H.S., Khushnood, R.A., Farooq, F., Ahmad, J., Vatin, N.I., Ewais, D.Y.Z. (2022). Prediction of Compressive Strength of Sustainable Foam Concrete Using Individual and Ensemble Machine Learning Approaches. *Materials*, 15(9), 3166.

- [11] Azar, F. A. N. (2017). *Determination of the effect of accelerator type and accelerator/sulfur ratio on the vulcanization kinetics and aging properties of natural rubber/chloroprene-based rubber compounds* [Doktora tezi]. Hacettepe Üniversitesi.
- [12] Heino, H. (2020). *Effect of mixing equipment scale-up on the rubber compound properties* [Yüksek lisans tezi]. Tampere University.
- [13] Düşmezkalender, H. Y. (2011). *Experimental characterization of rubber polymer* [Yüksek lisans tezi]. İstanbul Teknik Üniversitesi.
- [14] Chandrasekaran, V. C. (2010). Rubbers and their relevant properties for the chemical and mineral processing industries. *Rubber as a Construction Material for Corrosion Protection: A Comprehensive Guide for Process Equipment Designers* (1. Baskı, ss. 79-107) içinde. Scrivener Publishing LLC.
- [15] Harbison, R.D., Bourgeois, M.M., Johnson, G.T. (2015). *Hamilton & Hardy's Industrial Toxicology* (6. Baskı). John Wiley & Sons Inc.
- [16] Dalgakıran, E. (2010). *Continuous compounding of silica loaded rubber in a twin-screw extruder* [Yüksek lisans tezi]. İstanbul Teknik Üniversitesi.
- [17] Kaewsakul, W. (2013). *Silica-reinforced natural rubber for low rolling resistance, energy-saving tires: aspects of mixing, formulation and compatibilization* [Doktora tezi]. University of Twente.
- [18] Evans, M.S. (2002). *Tyre compounding for improved performance* (1. Baskı). iSmithers Rapra Publishing.
- [19] De, S.K., White, J. R., (2001). *Rubber technologist's handbook*. Rapra Technology Limited.
- [20] Patel, P. R., (2011). *Compounding and processing of plastic/rubber blends*. In Encyclopedia of Polymer Blends.
- [21] Morton, M., (1987). *Rubber technology* (3. Baskı). Springer Dordrecht.
- [22] Veri Bilimi Okulu (10 Aralık 2022). Yapay Sinir Ağları. www.veribilimiokulu.com/yapay-sinir-aglari.
- [23] Tufféry, S. (2011). *Data Mining and Statistics for Decision Making* (1. Baskı). John Wiley & Sons, Ltd.
- [24] Uruk, Z., Kiraz, A., Deniz, V. (2022). A Comparison of Machine Learning Methods to Predict Rheometric Properties of Rubber Compounds. *Journal of Rubber Research*, 25, 265–277.
- [25] Baboo, S., Shereef, K. I. (2010). An Efficient Weather Forecasting System Using Artificial Neural Network. *International Journal of Environmental Science and Development*, 1(4), 321-326.
- [26] Öztürk, K., Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- [27] Oruç, E.N. (2021). *Yapay sinir ağları kullanılarak kısa süreli güneş enerjisi tahmini* [Yüksek lisans tezi]. İstanbul Teknik Üniversitesi.

- [28] Song, Y. Y., Lu, Y. (2015). Decision Tree Methods: Applications for Classification and Prediction. *Shanghai Archives of Psychiatry*, 27(2), 130-135.
- [29] Kabra, R.R., Bichkar, R. S. (2011). Performance Prediction of Engineering Students Using Desicion Trees. *International Journal of Computer Applications*, 36(11), 8-12.
- [30] Priyama, A., Abhijeeta, Guptaa, R., Ratheeb, A., Srivastavab, S. (2013). Comparative Analysis of Decision Tree Classification Algorithms. *International Journal of Current Engineering and Technology*, 3(2), 334-337.
- [31] Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., Chica-Rivas, M. (2015). Machine Learning Predictive Models for Mineral Prospectivity: An Evaluation of Neural Networks, Random Forest, Regression Trees and Support Vector Machines. *Ore Geology Reviews*, 71, 804–818.
- [32] Wang, G., Hao, J., Ma, J., & Jiang, H. (2011). A Comparative Assessment of Ensemble Learning for Credit Scoring. *Expert Systems with Applications*, 38(1), 223–230.



ÖZGEÇMİŞ

Ad-Soyadı : Furkan TİTİZ

ÖĞRENİM DURUMU:

- Lisans** : 2019, Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- Yükseklisans** : 2023, Sakarya Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2020-2021 yılları arasında Billas Lastik fabrikasında Planlama Mühendisi olarak çalıştı.
- 2021 yılından itibaren Maysan Mando fabrikasında Malzeme Planlama Mühendisi olarak çalışma hayatı devam etmektedir.

TEZDEN TÜRETİLEN ESERLER:

- Titiz, F., Uruk, Z. ve Kiraz, A. 2023. A Comparative Study of Artificial Intelligence Techniques to Estimate Mechanical Properties of Rubber Compounds, *Journal of Intelligent Systems: Theory and Applications*. (Değerlendirmede).