

T.C.
AKDENİZ ÜNİVERSİTESİ



**BAZI TÜRK LİNYİTLERİNİN KISA-ELEMENTEL DEĞERLERİ
KULLANILARAK MASERAL DAĞILIMLARININ BELİRLENMESİ**

Gökhan ALABAŞ

FEN BİLİMLERİ ENSTİTÜSÜ

JEOLOJİ MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ŞUBAT 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ



**BAZI TÜRK LİNYİTLERİNİN KISA-ELEMENTEL DEĞERLERİ
KULLANILARAK MASERAL DAĞILIMLARININ BELİRLENMESİ**

Gökhan ALABAŞ

FEN BİLİMLERİ ENSTİTÜSÜ

JEOLJİ MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ŞUBAT 2025

ANTALYA

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

**BAZI TÜRK LİNYİTLERİNİN KISA-ELEMENTEL DEĞERLERİ
KULLANILARAK MASERAL DAĞILIMLARININ BELİRLENMESİ**

**Gökhan ALABAŞ
JEOLJİ MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BAZI TÜRK LİNYİTLERİNİN KISA-ELEMENTEL DEĞERLERİ
KULLANILARAK MASERAL DAĞILIMLARININ BELİRLENMESİ**



Gökhan ALABAŞ

JEOLOJİ MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Bu tez 10/02/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Doç. Dr. Selin KARADİREK (Danışman)

Prof. Dr. Mehmet ALTUNSOY

Prof. Dr. Nazan YALÇIN ERİK

ÖZET

BAZI TÜRK LİNYİTLERİNİN KISA-ELEMENTEL DEĞERLERİ KULLANILARAK MASERAL DAĞILIMLARININ BELİRLENMESİ

Gökhan ALABAŞ

Yüksek Lisans Tezi, Jeoloji Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Selin KARADİREK

Şubat 2025; 85 sayfa

Kömür, dünya genelinde önemli enerji kaynaklarından biridir. Ülkemizde ise özellikle linyit kömürü rezervlerinin büyük bir öneme sahip olduğu bilinmektedir. Araştırmalar fosil yakıtlardan, petrolün ve doğal gazın dünyadaki rezervlerinin kömüre kıyasla daha erken tükeneyeceğini göstermektedir. Kömür bu kadar önemli bir maden olmasına karşın karakterize edilmesi yüksek maliyete sebebiyet veren ve uzmanlık gerektiren süreçlerden geçmektedir. Bu nedenle, yapay zekâ tabanlı yöntemlerle analiz süreçlerini kolaylaştırmak ve daha düşük maliyetlerle yüksek doğrulukta sonuçlar elde etmek büyük önem taşımaktadır.

Bu çalışma, yapay sinir ağlarını laboratuvar analizlerine alternatif bir yöntem olarak sunmayı hedeflemiştir. Türkiye kömürlerinin kısa ve elementel analiz değerlerinden yola çıkılarak yapay sinir ağları yardımı ile maseral dağılımlarının belirlenmesini hedeflemiştir. Maseral dağılımlarının belirlenmesi, kömürün kalite parametrelerinin ve çökelim ortamı özelliklerinin belirlenmesinde rol oynamaktadır. Bu bağlamda, çalışmada Türkiye bazı linyit kömürlerinin fiziksel ve kimyasal özellikleri incelenmiş, literatürde yer alan kısa ve elementel analiz verileri temel alınmıştır. Elde edilen veriler ise yapay sinir ağları ve optimizasyon teknikleri kullanılarak analiz edilmiştir.

Yapay sinir ağını eğitmek için 232 adet linyit kömürü verisi kullanılmıştır. Bu veriler ile Matlab yazılımı kullanılarak ileri yönlü çok katmanlı algılayıcı, kaskad ileri yönlü algılayıcı ve Python dili kullanılarak Bayes hiper-parametre optimizasyonu teknikleri kullanılmıştır. Regresyon analizi, hata metrikleri ve diğer istatistiksel yöntemlerle yapay sinir ağlarının tahmin gücü değerlendirilmiştir. Alınan veriler farklı gizli nöron sayıları ile denenmiş en iyi sonucun alınabileceği nöron katmanı seçilmiştir.

Sonuç olarak ileri yönlü çok katmanlı algılayıcı, daha karmaşık verilerde etkili olurken, kaskad ileri yönlü algılayıcı daha basit ve az sayıda katmanın gerektiği durumlarda öne çıkmıştır. Bayes optimizasyonu ise az veri ile de olsa hiper-parametre ayarlamalarında daha hassas sonuçlarda verimli olduğu görülmüştür. Üç algoritma arasında en iyi sonucu Bayes optimizasyonu vermiş ikinci olarak ise ileri yönlü çok katmanlı algılayıcı olduğu görülmüştür.

Sonucun maksimum verimlilikte olması için kullanılan veriler literatür kaynaklı ise doğruluğu arttırmak için veri seti sayısı artırılmasının doğru bir yaklaşım olabileceği

sonucuna varılmıştır. Bu şekilde girilen ve tahmin verileri, “ $x=y$ ” doğru eksenini için en yakın değerleri elde edebilecek ve minimum hataya ulaşmanın mümkün olabileceği sonucuna varılmıştır.

ANAHTAR KELİMELEER: Bayes optimizasyonu, Çok katmanlı, Hiper-parametre, İleri Yönlü, Kaskad ileri yönlü algılayıcı, Kömür, Linyit, Maseral, Regresyon, Yapay sinir ağıları

JÜRİ: Doç. Dr. Selin KARADİREK

Prof. Dr. Mehmet ALTUNSOY

Prof. Dr. Nazan YALÇIN ERİK



ABSTRACT

DETERMINATION OF MACERAL DISTRIBUTIONS USING PROXIMATE AND ULTIMATE ANALYSIS OF SOME TURKISH LIGNITES

Gökhan ALABAŞ

Master's Thesis, Department of Geological Engineering

Supervisor: Assoc. Prof. Dr. Selin KARADİREK

February 2025; 85 pages

Coal is one of the most significant energy resources worldwide. In our country, lignite coal reserves are known to hold particular importance. Research indicates that fossil fuel reserves of oil and natural gas will deplete sooner than coal on a global scale. Despite its critical role, coal characterization involves costly and expertise-demanding processes. Therefore, employing artificial intelligence-based methods to streamline analysis processes and achieve high-accuracy results at lower costs is of great importance.

This study aims to introduce artificial neural networks as an alternative method to laboratory analyses. The research focuses on determining the maceral distributions of Turkish coals based on proximate and ultimate analysis values using artificial neural networks. Identifying maceral distributions plays a crucial role in assessing coal quality parameters and depositional environment characteristics. In this context, the study examines the physical and chemical properties of certain Turkish lignite coals, utilizing proximate and ultimate analysis data available in the literature. The obtained data were analyzed using artificial neural networks and optimization techniques.

A total of 232 lignite coal data points were used to train the artificial neural network. These data were processed using MATLAB software for feedforward multilayer perceptron and cascade forward neural networks, while Bayesian hyperparameter optimization techniques were implemented in Python. The predictive performance of artificial neural networks was evaluated through regression analysis, error metrics, and other statistical methods. The data were tested with different numbers of hidden neurons, and the optimal neuron layer configuration yielding the best results was selected.

As a result, the feedforward multilayer perceptron demonstrated superior performance for complex datasets, whereas the cascade forward neural network was more effective in cases requiring simpler architectures with fewer layers. Bayesian optimization, on the other hand, proved to be efficient in hyperparameter tuning, even with limited data, by yielding more precise results. Among the three algorithms, Bayesian optimization produced the most accurate predictions, followed by the feedforward multilayer perceptron.

To maximize efficiency, increasing the dataset size when using literature-based data is suggested as a means to enhance accuracy. This approach ensures that both input

and predicted values align closely with the “x=y” reference line, thereby minimizing errors to an optimal level.

KEYWORDS: Artificial neural networks, Bayesian optimization, Cascade forward perceptron, Coal, Forward, Hyper-parameter, Lignite, Maceral, Multilayer, Regression

COMMITTEE: Assoc. Prof. Dr. Selin KARADİREK

Prof. Dr. Mehmet ALTUNSOY

Prof. Dr. Nazan YALÇIN ERİK



ÖNSÖZ

Enerji, nüfus artışı, elektrik, ulaşım, ısınma ve teknolojik gelişmeler ile insanoğlunun en temel gereksinimlerinden biri haline gelmiştir. Bu gereksinimleri karşılayacak olan yeraltı kaynaklarından biri olan kömür dünyada oldukça yaygın bir kullanıma ve güçlü ekonomik etkiye sahiptir. 2023 yılında, kömür dünyada enerji tüketiminde %26,5'lik payla petrolden sonra ikinci sırada yer almıştır (ETKB 2024). Elektrik üretiminde ise %35,1'lik payla ilk sırada yer almıştır (ETKB 2024). Ayrıca araştırmalar fosil yakıtlardan, petrolün 39 yıl ve doğal gazın 63 yıl sonra dünyadaki rezervlerinin tükeneceğini göstermekte, kömür rezervlerinin ise 215 yıl daha yeterli olacağını göstermektedir (Schobert ve Song 2002). Talep miktarının bu kadar yüksek olması gelecekte göreceği değerin dahada artması gibi sebeplerde eklendiğinde arama ve çıkarma maliyetlerinin artması ile kendini göstermekte sonucunda ise maliyeti düşürmeye ve zamandan kazanmaya yönelik alternatif yollar aranmaktadır.

Teknolojik gelişmelerin etkisiyle, yapay zekâ algoritmalarının kullanımı 1980'lerden itibaren Avrupa'da, 2000'li yıllardan sonra ise ülkemizde önem kazanmış ve özellikle kömür ile diğer değerli madenlerin keşfi ve kalite sınıflamasında önemli bir rol oynamaya başlamıştır. Oluşturulan istatistiki algoritma düzenleri belirli verileri kullanarak matematik tabanlı sonuçlara ulaşmaktadır. Sonuçlar istatistiki olarak formülize edilip gelecek çalışmalar için yüksek verimlilik ile tahminler yapılabilmesini sağlamaktadır. Bu çalışmada ise Tuncalı vd. (2002)'nin tersiyer linyit kömürleri ile ilgili MTA envanterinden yararlanılarak kısa ve elementel analizler ile oluşturulan veri setleri ile maseral içerikleri tahmin edilmesi ve bu yönde özgün bir çalışma ortaya koyarak gelecek çalışmalar için öncü olması istenmiştir. Türkiye'nin kömür rezervlerinin bilimsel olarak değerlendirilmesi, enerji verimliliğinin artırılmasına katkı sağlayacak sonucunda ise sürdürülebilir ve verimli maden faaliyetlerinin önü açılacağı düşünülmektedir.

Bu çalışma sırasında benden değerli desteklerini esirgemeyen ve sabrı ile yol gösteren aynı zamanda danışmanım Doç. Dr. Selin Karadirek'e; yapay sinir ağları ve algoritmalar konusunda bilgi ve deneyimiyle yardımlarını esirgemeyen Arş. Gör. Buğra Güzel'e sonsuz teşekkürlerimi sunarım. Tez yazım sürecinde yapay sinir ağları ile ilgili katkılarından dolayı ikinci danışmanım Doç. Dr. Mustafa Şeker'e de ayrıca teşekkür ederim. Son olarak ise sevgili eşim Arş. Gör. Dr. Begüm Fulya Adızel Alabaş'a çalışmamda bilgi ve deneyimiyle; hayatımda ise varlığı ile beni her zaman desteklediği ve yanımda olduğu için teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ.....	v
AKADEMİK BEYAN.....	viii
SİMGELER VE KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ.....	xix
1. GİRİŞ.....	1
1.1.Çalışmanın Amacı.....	4
2. KAYNAK TARAMASI.....	5
2.1. Kömür Kavramı ve Oluşumu.....	5
2.2. Kömürlerin Kalite Parametreleri.....	7
2.2.1. Kömürlerin fiziksel özellikleri.....	7
2.2.2. Kömürlerin kimyasal özellikleri.....	8
2.2.3. Maseraller.....	10
2.3. Yapay Sinir Ağları.....	13
2.4. Kaynak Taraması.....	19
3. MATERYAL VE METOT.....	22
3.1. Bazı Türk Linyitlerinin Veri Seti.....	22
3.2.Yapay Sinir Ağı Çalışması.....	26
3.2.1. İleri yönlü çok katmanlı algılayıcı.....	27
3.2.2. Kaskad ileri yönlü algılayıcı ağı (KİYA).....	28
3.2.3. Bayes hiper-parametre optimizasyon yöntemi (BO).....	29
4. BULGULAR VE TARTIŞMA.....	33
5. SONUÇLAR.....	41
6. KAYNAKLAR.....	43
7. EKLER.....	49
EK-1.....	49
EK-2.....	53
EK-3.....	57
EK-4.....	61

EK-5	64
EK-6	68
EK-7	72
EK-8	76
EK-9	79
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Bazı Türk Linyitlerinin Kısa-Elementel Değerleri Kullanılarak Maseral Dağılımlarının Belirlenmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

26/02/2025

Gökhan ALABAŞ

İmzası

SİMGELER VE KISALTMALAR

Simgeler

%	: Yüzde
e	: Euler sayısı
Σ	: Toplam sembolü
\geq	: Küçük eşittir işareti
\leq	: Büyük eşittir işareti
$>$: Küçüktür işareti
$<$: Büyüktür işareti
=	: Eşittir
∞	: Sonsuz

Kısaltmalar

A	: Kül
AFT	: Alternatif Faktör Teorisi
ASTM	: American Society for Testing and Materials
BO	: Bayes Optimizasyonu
C	: Karbon
CH ₃	: Metil Grubu
CH ₄	: Metan
cm ³	: Santimetreküp
CO	: Karbonmonoksit
CO ₂	: Karbondioksit
COOH	: Karboksilik asit
ÇDR	: Çoklu Doğrusal Regresyon
ÇKA	: Çok Katmanlı Algılayıcı

ÇLR : Çoklu Lojistik Regresyon
DSA : Derin Sinir Ağı
EV : Eğitim Verisi
G : Girdiler
g : Gram
GİP : Gene İfade Programı
GK : Gizli Katman
GP : Genetik Programlama
GS : Gauss Süreci
GSR : Gauss Süreç Regresyonu
H : Hidrojen
H₂O : Su
HGI : Hardgrove Öğütülebilirlik İndeksi
HKB : Havada kurutulmuş baz
Hm : Hüminit
İn : İnertinit
İYÇK : İleri Yönlü Çok Katmanlı
KB : Kuru baz
Kcal : Kilokalori
KD : Kalorifik değer
Kg : Kilogram
KİYA : Kaskad İleri Yönlü Algılayıcı
KKB : Kuru külsüz baz
Lp : Liptinit
LSTM : Uzun kısa süreli bellek
m : Metre

M : Nem

MEA-YSA : Modifiye Edilmiş Ağırlıklı Sinir Ağı

MTA : Maden Tetkik Arama

N : Azot

O : Oksijen

OCH₃ : Metoksil grubu

OH⁻ : Hidroksit

OKH : Ortalama Kare Hatası

OKHK: Ortalama Kare Hatası Karekökü

OMH : Ortalama Mutlak Hata

R : Regresyon

R² : R-kare

R_{max} : Vitrinit maksimum yansıma

R_r : Yansıtma

R_e : Eğitim Regresyon Değeri

R_v : Regresyon Doğrulama Değeri

R_t : Test Regresyon Değeri

S : Kükürt

SC : Sabit Karbon

SO₂ : Kükürtdioksit

SO₄ : Sülfat

SSA : Sığ Sinir Ağı

SVR : Destek Vektör Regresyonu

TKİ : Türkiye Kömür İşletmeleri

ÜKD : Üst Kalorifik Değer

vb : Ve benzeri

vd : Ve diđerleri
VM : Uçucu Madde
W : Ađırlıklar
YSA : Yapay Sinir Ađları



ŞEKİLLER DİZİNİ

Şekil 1.1. Türkiye linyit sahaları (Saygılı 2017).....	3
Şekil 2.1. Altı giriş iki gizli katman ve bir çıkış verisinden oluşan İleri yönlü çok katmanlı ağ yapısı örneği	15
Şekil 3.1. İleri yönlü YSA'nın beş katmanlı nöronu	26
Şekil 3.2. Tez kapsamında on giriş parametresine üç çıkış uzantılı İYKÇ ağ yapısı	27
Şekil 3.3. Tez kapsamında on giriş parametresine üç çıkış uzantılı KIYA ağ yapısı	28
Şekil 3.4. Tez kapsamında on giriş parametresi, iki gizli katman ve üç çıkış uzantılı BO ağ yapısı.....	29
Şekil 4.1. İleri yönlü çok katmanlı algılayıcıda 200 eğitim verisi ve 20 gizli katman için 32 test verisinin 32 tahmin verisi ile kıyaslandığı grafik	35
Şekil 4.2. 200 eğitim verisi ve 20 gizli katman için ortalama kare hatasının en iyi sonucu verdiği noktanın grafiği	35
Şekil 4.3. 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. $R_{EĞİTİM}$ (a): Eğitim regresyon grafiği; $R_{DOĞRULAMA}$ (b): Hata doğrulama regresyon grafiği; R_{TEST} (c): Test verileri regresyon grafiği; $R_{TOP.ORT.}$ (d): Ortalama regresyon grafiği	36
Şekil 4.4. BO eğitim ve doğruya kaybı grafiği	38
Şekil 4.5. BO ile hesaplanan hüminit maserali eğitim (a) ve test (b) verileri için regresyon grafikleri	38
Şekil 4.6. BO ile hesaplanan liptinit maserali eğitim (a) ve test (b) verileri için regresyon grafikleri	38
Şekil 4.7. BO ile hesaplanan inertinit maserali eğitim (a) ve test (b) verileri için regresyon grafikleri	39
Şekil 7. 1. İleri yönlü çok katmanlı algılayıcıda 150 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	49
Şekil 7.2. İleri yönlü çok katmanlı algılayıcıda 150 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	49
Şekil 7.3. İleri yönlü çok katmanlı algılayıcıda 150 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	50

Şekil 7.4. İleri yönlü çok katmanlı algoritmada 150 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	50
Şekil 7.5. İleri yönlü çok katmanlı algoritmada 150 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	51
Şekil 7.6. İleri yönlü çok katmanlı algoritmada 150 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	51
Şekil 7.7. İleri yönlü çok katmanlı algoritmada 150 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	52
Şekil 7.8. İleri yönlü algoritmada 150 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	52
Şekil 7.9. İleri yönlü çok katmanlı algoritmada 170 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	53
Şekil 7.10. İleri yönlü çok katmanlı algoritmada 170 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	53
Şekil 7.11. İleri yönlü çok katmanlı algoritmada 170 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	54
Şekil 7.12. İleri yönlü çok katmanlı algoritmada 170 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	54
Şekil 7.13. İleri yönlü çok katmanlı algoritmada 170 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	55
Şekil 7.14. İleri yönlü çok katmanlı algoritmada 170 eğitim verisi ve 30 gizli katman için regresyon değerleri a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	55
Şekil 7.15. İleri yönlü çok katmanlı algoritmada 170 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	56

Şekil 7.16. İleri yönlü çok katmanlı algoritmada 170 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	56
Şekil 7.17. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	57
Şekil 7.18. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	57
Şekil 7.19. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	58
Şekil 7.20. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	58
Şekil 7.21. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	59
Şekil 7.22. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	59
Şekil 7.23. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	60
Şekil 7.24. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	60
Şekil 7.25. İleri yönlü çok katmanlı algoritmada 210 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	61
Şekil 7.26. İleri yönlü çok katmanlı algoritmada 210 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği	61
Şekil 7.27. İleri yönlü çok katmanlı algoritmada 210 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir.....	62

- Şekil 7.28.** İleri yönlü çok katmanlı algoritmada 210 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 62
- Şekil 7.29.** İleri yönlü çok katmanlı algoritmada 210 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir..... 63
- Şekil 7.30.** İleri yönlü çok katmanlı algoritmada 210 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 63
- Şekil 7.31.** Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 64
- Şekil 7.32.** Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 64
- Şekil 7.33.** Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 65
- Şekil 7.34.** Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 65
- Şekil 7.35.** Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 66
- Şekil 7.36.** Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 66
- Şekil 7.37.** Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 67
- Şekil 7.38.** Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 67
- Şekil 7.39.** Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 68

- Şekil 7.40.** Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 68
- Şekil 7.41.** Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 69
- Şekil 7.42.** Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 69
- Şekil 7.43.** Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 70
- Şekil 7.44.** Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 70
- Şekil 7.45.** Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 71
- Şekil 7.46.** Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 71
- Şekil 7.47.** Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 72
- Şekil 7.48.** Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 72
- Şekil 7.49.** Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 73
- Şekil 7.50.** Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği 73
- Şekil 7.51.** Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir 74

- Şekil 7.52.** Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği74
- Şekil 7.53.** Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir75
- Şekil 7.54.** Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği75
- Şekil 7.55.** Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir76
- Şekil 7.56.** Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği76
- Şekil 7.57.** Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir77
- Şekil 7.58.** Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği77
- Şekil 7.59.** Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir78
- Şekil 7.60.** Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği78

ÇİZELGELER DİZİNİ

Çizelge 1.1. Türkiye linyit sahaları ve toplam rezervleri (MTA 2023).....	1
Çizelge 2.1. Kömürlerin ASTM sınıflaması (ASTM 1983)	5
Çizelge 2.2. Kısa analizlerde kullanılan bazlar (Ward 1984)	9
Çizelge 2.3. Elementel analizler yapılırken kullanılan bazlar (Ward 1984).....	9
Çizelge 2.4. Linyit ve alt bitümlü kömürlerde maseral grupları, maseral alt grupları, maseraller ve maseral tipleri (Stach vd. 1982; Sykorova vd. 2004)	12
Çizelge 3.1. Tez için kullanılan verilerin 150; 170; 200; 210 giriş verisi baz alındığında minimum maksimum ve ortalama değerleri	24
Çizelge 3.2. Tez için kullanılan verilerin 82; 62; 32; 22 test verisi baz alındığında minimum maksimum ve ortalama değerleri	25
Çizelge 4.1. İYÇK ağ yapısına uygun olarak çalışılan setlerin hata oranları	33
Çizelge 4.2. KİYA ağ yapısına uygun olarak çalışılan setlerin hata oranları	34
Çizelge 4.3. BO hiper-parametre tanımlama yöntemi için çalışılan setlerin hata oranları	37
Çizelge 4.4. Tez kapsamında yapılan BO ve İYÇK (en iyi sonuç veren veri seti) Onifade vd. (2021) yılında yaptıkları çalışma ile OMH verileri.....	39
Çizelge 7.1. Türkiye'deki bazı linyit kömürlerinin analiz verileri (Tuncalı vd. 2002) ..	79

1. GİRİŞ

Dünyada ve ülkemizde nüfus artışı, teknolojik gelişmeler gibi etmenlerin sonucu olarak enerji talebinin artması doğal kaynaklarının önemi artırmıştır. Bu kaynakların büyük bir çoğunluğunu ise fosil yakıtlar (petrol, kömür, bitümlü şeyl) oluşturmaktadır. Bu enerji kaynakları içerisinde önemli bir yere sahip olan kömür ise dünyada yaygın olarak bulunması, üretilmesi ve görünür rezervlerin şu an ki üretim seviyeleri göz önüne alındığında diğer fosil yakıtlardan daha uzun ömürlü oluşu, ekonomik kararlılığı, taşınmasının kolaylığı, depolamasının rahatlığı, kullanıcı arzının diğer yakıtlara göre ucuzluğu ve sürekliliği gibi özellikleriyle de vazgeçilmez bir enerji kaynağı olmuştur (King vd. 1936).

Kömür, karakterize edilmesi zor olan son derece karmaşık, heterojen bir sedimanter kayadır. Kömür rezervlerinin üretim için hazırlanması ve üretilmesinde jeolojik ve ekonomik kriterler birinci derecede önem taşımaktadır (Falcon 1989). Termik santraller vasıtasıyla elektrik üretimi başta olmak üzere metalurjik süreçlerde, gazlaştırmada, çimento endüstrilerinde, yüksek değerli tarım ürünlerine biyolojik dönüşümde, endüstriyel kimyasallarda hammadde olarak kullanılmaktadır (Ward 1984).

Ülkemizde kömürü %20 ile doğalgaz, %16 ile hidrolik, %14,8 ile nükleer, %8,8 ile petrol ve %2,3 ile diğer kaynaklar izlemektedir (MTA 2023). Türkiye’de MTA’nın (2023) verilerine göre 1,53 milyar ton Karbonifer taşkömürü rezervleri bulunmaktadır. Başlıca taşkömürü yatağı, kalınlığı 0,7 m ile 10 m arasında değişen çok sayıda damarın bulunduğu kuzey kıyısındaki Zonguldak Kömür Sahası’dır. Ayrıca taşkömürü sahası olarak Türkiye’nin güneyinde yer alan Pamucak Yaylası kömürlerini de söyleyebiliriz (Turhan ve Batur 1974). Söz konusu bölgelerde kömür, düşük kül ve kükürt içerikli bitümlüdür. Buna kıyasla Türkiye’de toplam linyit rezervi ise özel işletmeler ile 20,533 milyar tondur (Çizelge 1.1). Linyit kömür sahasının daha geniş bir alana yayılmış olması sebebiyle literatürde daha geniş bir yer tutmaktadır.

Çizelge 1.1. Türkiye linyit sahaları ve toplam rezervleri (MTA 2023)

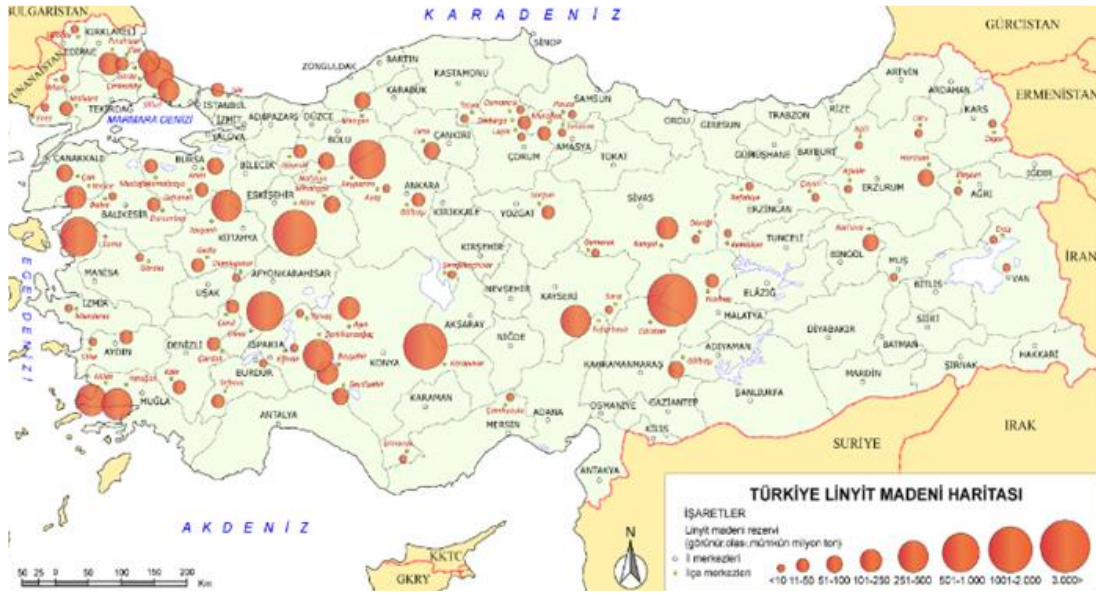
Linyit Kömür Sahaları	Toplam Rezerv/Ton
Afşin-Elbistan	4.642.340.000
Afşin-Elbistan (MTA)	515.000.000
Manisa-Soma	861.450.000
Adana-Tufanbeyli	429.549.000
Adıyaman-Gölbaşı	57.142.000
Bingöl-Karlıova	88.884.000
Ankara-Beypazarı	498.000.000
Afyon-Dinar-Dombayova	941.500.000
Bolu-Mengen	142.757.000
Muğla-Milas	750.214.000
Çankırı-Orta	123.165.000

(Devamı arkada)

Çizelge 1.1.'in devamı

Çanakkale-Çan	92.483.000
Kütahya-Tunçbilek	317.732.000
Kütahya-Seyitömer	198.666.000
Sivas-Kangal	202.607.000
Kütahya-Gediz	23.945.000
Tekirdağ-Çerkezköy	573.600.000
Tekirdağ-Çerkezköy	573.600.000
Tekirdağ-Malkara	1.563.300.000
Tekirdağ-Saray	141.175.000
Amasya-Yeniçeltek	19.791.000
Yozgat-Sorgun	13.206.000
Bolu-Göynük	43.454.000
Çorum-Dodurga	38.500.000
Konya-Karapınar	1.832.000.000
Konya (Beyşehir-Seydişehir)	348.000.000
Bolu (salıp.-Merkez)	98.000.000
İstanbul (Silivri)	1.100.000.000
Eskişehir (Alpu)	1.453.000.000
Eskişehir (Koyunağılı)	57.430.000
Muş-Merkez	400.000.000
Edirne	850.000.000
Bursa (Keleş-Orhaneli)	85.000.000
Balıkesir	34.000.000
Ankara (Gölbaşı)	48.000.000
Diğerleri	1.950.000.000
TOPLAM	20.533.890.000

Türkiye’de Paleojen-Neojen linyit havzaları Batı ve Orta Anadolu’da mevcuttur (Şekil 1.1). Daha eski Eosen linyitleri kuzeyde, kalınlığı 6 m'ye kadar olan damarlar şeklinde gelişmişlerdir. Daha genç Oligosen ve Miyosen linyitleri sırasıyla ülkenin kuzeybatısında ve batısında bulunur (Birön 1997). Oligosen, çok sayıda ince damarla karakterize edilirken, Miyosen linyitleri, Alpagut-Dodurga Havzası'nda ve güneybatı Türkiye'deki Turgut Kömür Sahası'nda kalınlığı 25 m'ye kadar olan damarlarla daha büyük yatakları oluşturur. Orta ve doğu Türkiye'de, Pliyosen yatakları, ortalama 40 m kalınlığında bir veya iki damara sahip büyük linyit kaynakları içerir. Afşin-Elbistan'daki en büyük açık ocak işletmesi, kalınlığı 5–58 m arasında değişen bir damarı işletmektedir (TKİ 2011).



Şekil 1.1. Türkiye linyit sahaları (Saygılı 2017)

Kömür kalitesi üç temel, bağımsız faktörün bir fonksiyonudur: kömür derecesi, maseral dağılımı, mineraller ve organik olarak ilişkili elementleri içeren inorganik bileşenler (Hower vd. 1996). Taylor vd. (1998) ise kömürün iki sınıf malzemedan oluştuğu söylemektedir: biri organik bileşenler veya maseraller, diğeri ise bir dizi mineral ve diğeri inorganik bileşenler, diğeri bir deyişle mineral maddedir.

Ülkemizde mevcut ve potansiyel kömür rezervlerinin kullanılabilirliğini bilmek ve artırabilmek için kömür kalite parametrelerinin belirlenmesi gerekmektedir. Kalite kıyaslaması yapılırken kömür ilk çıkarıldığında ve laboratuvar ortamında belirli analizlere tabi tutulmaktadır. Bu süreçleri kısaltmak ve maliyetleri düşürmek için yeni ve yaratıcı fikirlere ihtiyaç duyulmuştur. Bunun sonucu olarak da bilim insanları çalışmalarında alternatif yöntemler araştırmaya başlamıştır. Gelişen teknoloji ile incelenen yapı ile insan beyni model alınmıştır. Beyindeki nöronların iletim yapısından esinlenerek, bu yapıyı temsil eden matematiksel bir model geliştirilmeye çalışılmıştır. Sinir hücrelerinin iletimi süzgeç olarak kullanılmış çapraz iletim modelleri algoritmalar halinde yazılarak tatmin edici sonuçlar elde edilmiştir (Ersoy ve Karal 2012). Yapay sinir ağı (YSA) olarak tanımlanan bu süreç, daha önce tanıdığı örüntülerden öğrenme yeteneğine sahiptir. Ağ, yeterli sayıda örnek veri seti ile eğitildikten sonra, önceki öğrenmelerine dayanarak, benzer örüntüdeki yeni giriş veri setiyle ilgili çıktı hakkında tahminlerde bulunabilir (Öztemel 2003). Çok disiplinli doğası nedeniyle YSA, araştırmacılar, planlamacılar, tasarımcılar vb. arasında işlerini başarmak için etkili bir araç olarak popüler hale gelmiştir. Bu uygulamalar, YSA'nın birçok karmaşık parametrenin süreci ve sonuçları etkilediği, süreç ve sonuçların tam olarak anlaşılmadığı ve geçmiş veya deneysel verilerin mevcut olduğu problemlerin çözümünde üstünlüğe sahip olduğunu göstermektedir. Bu gelişmeler doğrultusunda, kompleks yapısı nedeniyle uzmanlık ve maliyet gerektiren kömürün bu alanda değerlendirilmesi bu sebeplerle önem arz etmektedir.

1.1.Çalışmanın Amacı

Birincil enerji kaynaklarından olan kömürün kalite parametrelerini belirleyebilmek ve ortamsal yorumlar yapabilmek için kısa analiz, elementel analiz ve organik bileşenleri (maseraller) gibi çeşitli parametrelerinin derinlemesine incelenmesi gerekir. Bu çalışmada yapay sinir ağları (YSA) ve optimizasyon teknikleri kullanılarak Türkiye linyit kömürlerinin maseral dağılımlarının kısa ve elementel analizler ile belirlenmesi amaçlanmıştır. YSA, maseral analizinin laboratuvar yöntemlerine alternatif bir yaklaşım sağlayabilir dolayısıyla YSA, laboratuvar sonuçlarının doğrulanması ve çapraz kontrolü için daha iyi bir tamamlayıcı olabilmektedir.

Ülkemizin linyit rezervleri, bitümlü kömürlere kıyasla daha geniş alanlara yayılmış ve daha fazla rezerve sahiptir (MTA 2023). Bu kadar geniş alana yayılmış olması da literatürde daha geniş bir kapsamda yer almasına sebebiyet vermiştir. Bunun bir sonucu olarak da detaylı araştırma konusunda daha çeşitli ve tutarlı veriler elde edilmesine olanak sağlamıştır. Verilerin tutarlı olması için veri çeşitliliğinin önemi, geniş bir literatüre ihtiyaç duyulması, linyit kömürlerinin çalışmaya konu olmasına sebebiyet vermiştir. Çünkü yapılan çalışmada veri ne kadar fazla ise tutarlılık o kadar iyi olacak ve daha verimli sonuçlar almamıza olanak sağlayacaktır.

Kömürde kısa ve elementel analizlerinden elde edilen verilerin belirlenmesi, petrografik çalışmalarla maserallerin tanımlanmasına ve konsantrasyonlarının belirlenmesine kıyasla daha basit ve kolay bir süreçtir. Bu çalışmada da belirli bir maseral türünü tanımlamak ve kesin sonuçlar için doğru tespitin yapılması amaçlanmaktadır. Bu nedenle, yapay sinir ağı ve optimizasyonu ile kısa ve elementel analiz verileri kullanılarak maseral dağılımları tahmin edilmesi için çalışma yapılmıştır. Bu yaklaşımın performansını ve uygunluğunu değerlendirmek amacıyla, YSA tahminleri regresyon katsayısı (R), ortalama kare hata (OKH), ortalama mutlak hata (OMH) ve R-kare (R^2) gibi çeşitli metrikler kullanılarak analiz edilmiştir

2. KAYNAK TARAMASI

2.1. Kömür Kavramı ve Oluşumu

Kömür, yanabilen bir sedimanter organik kayaç olup, başlıca karbon, hidrojen, oksijen ve az miktarda kükürt gibi elemanlardan oluşan, katmanlı tortul çökeller arasında bulunan koyu renkli, karbon bakımından zengin bir kayaçtır (Murchison 1987). Siyah, koyu gri veya kahverengi-siyah renkli, parlak veya mat bir katı fosil yakıt ve aynı zamanda sedimanter bir kayadır (Ünalın 2010). Çoğunlukla lignoselülozik esaslı, değişik oranlarda organik ve inorganik bileşenler içeren, farklı fiziksel ve kimyasal özelliklere sahip, biyolojik ve jeolojik süreçler sonucu oluşan bir materyaldir. Organik yapısı C, H, O ve az miktarda da kükürt ve azottan oluşmakta iken inorganik yapısı, nem ve mineralleri içermektedir (Walker 1999). Yapısal olarak içerdiği organik madde miktarına ve barındırdığı mineral maddenin türüne göre, kömürlü kil, kömürlü şist gibi isimler verilmektedir (Taylor vd. 1998). Organik olgunluklarına göre kömürler linyit, alt bitümlü kömür, bitümlü kömür ve antrasit sınıflamalarına ayrılırlar (Çizelge 2.1).

Çizelge 2.1. Kömürlerin ASTM sınıflaması (ASTM 1983)

Kömür Sınıfı	Kömür Alt Sınıfı	Sabit Karbon (%)*		Uçucu Madde (%)*		Isıl Değer (%)*	
		≥	<	>	≥	≥	<
Antrasit	Meta-Antrasit	98	-	-	2	7780	-
	Antrasit	92	98	2	-	7780	-
	Yarı-Antrasit	86	92	8	14	7780	-
Bitümlü Kömürler	Düşük Uçuculu	78	86	14	22	7780	-
	Orta Uçuculu	69	78	22	31	7780	-
	Yüksek Uçuculu A	-	69	31	-	7780	-
	Yüksek Uçuculu B	-	69	31	-	7220	7780
	Yüksek Uçuculu C	-	69	31	-	5835	7220
Alt Bitümlü Kömürler	Alt Bitümlü A	-	69	31	-	5835	6390
	Alt Bitümlü B	-	69	31	-	5275	5835
	Alt Bitümlü C	-	69	31	-	4610	5275
Linyit	Linyit A	-	69	31	-	3500	4610
	Linyit B	-	69	31	-	-	3500

*Kuru ve mineral madde içermeyen baza göre

Kömürleşmede temel olan iki evreden bahsedilebilir bunlar biyokimyasal (turbalaşma) evre ve jeokimyasal (kömürleşme) evresidir (Ünalın, 2010). Kömür oluşumu için çok rutubetli, tropikal iklime sahip, su ile büyüyen bitkilerin bulunduğu ortama aynı zamanda havza ve bataklıklara ihtiyaç vardır (Miura vd. 1989). Birinci aşama olan turbalaşma esnasında bitkiler üst üste yığılarak gittikçe kalınlaşan tabakaları oluştururlar ve bitkilerin hava ile teması sonucunda bozunmalarını önlemek için üzerlerinin yeterli miktarlarda su ile örtülmesi gereklidir (Miura vd. 1989). Bitki artıklarının bataklık ortamında bakteriler tarafından biyokimyasal bozunmaya uğraması sonucu, hümik asit ve türevleri oluşur ardından organik kütlede aromatikliği artar (Mendez vd. 2003). Bozunma durduğunda karbon içeriği genellikle %40-50'den %60'ın üzerine çıkarken oksijen içeriği de azalır. Ayrıca bu aşamada, bataklık suyunda bulunan inorganik maddeler bitki artıklarının arasına girer. Böylece turba yapısına benzer yapıya dönüşen bitki artıkları zamanla yer kabuğunun derinliklerine çöker. Çok sayıda ve farklı türlerdeki bitkilerden meydana gelen kömür, heterojen bir yapı oluşturur (Schapiro ve Gray 1970).

Turba oluşumunda tektonik hareketler, üst katmanların basıncı, orojenez ve iklim koşullarının stabil olması önemli faktörlerdir. Bugün yeryüzünde kilometrelerce alana yayılmış kömür kaynaklarının bulunuyor olmasına neden olarak bu geniş alanlar boyunca iklimin değişmemiş olması gösterilmektedir (Schapiro ve Gray 1970). Turbanın kimyasal olarak kömüre dönüşmesi çok karmaşık bir süreçtir. İlk kademede oluşan turbanın su ve çamurla tamamen kaplanmasıyla ikinci kademe başlar ve bundan sonraki kademede tamamen organik olan kütlede yoğunlaşarak sertleşmesi, su içeriğini kaybetmesi, bir miktar uçucu maddenin uzaklaşması ve gaz moleküllerinin sıkışarak sıvılaşması gibi tepkimeleri gerçekleştirir. Bu tepkimeler ile -OH, -COOH, -OCH₃ ve -CH₃ grupları ayrılır (Choudhury vd. 2008). Tepkimeler ardı sıra devam edecek şekilde kömür üretilinceye kadar devam eder ve milyonlarca yıl sonra sıcaklık ve basıncın etkisiyle linyit meydana gelir ardından linyitin kömürleşme derecesi yükselir ve alt bitümlü kömürler oluşur. Zamanla bu süreçlerin devam etmesi ile bitümlü kömür ve daha sonra da antrasit oluşur (Ünalın 2010).

Kömür kapsadığı organik maddenin özelliğine göre, hümik ve sapropelik olmak üzere iki grup halinde bulunmaktadır (Ünalın 2010). Hümik kömürler, bataklıkta bir yığılım oluşturacak şekilde biriken cansız büyük ve küçük boy damarlı bitkilerin önce bakterilerin etkisiyle turbaya dönüşmesi ve sonraki gömülme nedeniyle artan yer sıcaklığının etkisi altında turbanın kömürleşmesi sonucu oluşan ve gömülme miktarına göre sırasıyla linyit, alt bitümlü kömür, taşkömürü, yarı antrasit ve antrasit gibi isimler alan, genellikle parlak ve bantlı kömürlerdir (Berkowitz 1979). Sapropelik kömürler ise deniz, göl, lagün gibi belli bir su derinliği olan havzaların oksijensiz tabanında biriken ve ardından gömülen sapropelin (organik madde kapsayan çamur), yine yer sıcaklığının etkisi altında kömürleşmesi ile oluşan mat ve bantlı yapısı olmayan kömürlerdir (Ünalın 2010).

2.2. Kömürlerin Kalite Parametreleri

2.2.1. Kömürlerin fiziksel özellikleri

Kömürlerin fiziksel özellikleri, kömürün türüne, oluşum koşullarına ve bileşimindeki maddelere bağlı olarak değişiklik gösterir. Özellikle, ticari kullanım için değerlendirme yapılırken birkaç fiziksel özelliğin (örneğin, yoğunluk, sertlik, öğütülebilirlik gibi) belirlenmesi gereklidir. Genel olarak kömürlerin fiziksel özellikleri aşağıdaki şekilde sıralanabilir:

Gözeneklilik (porozite), kömürler tamamen masif bir yapıya sahip olmayıp, boyutları birkaç mikron ile birkaç milimetre arasında değişen boşluklar içerirler (Larry 2002). Gözeneklilik, kömürleşme derecesine bağlı olarak değişmektedir. Gözenekli yapı su tutmaya yatkın olduğu için kömürün orijinal nem miktarına da bağlıdır. Yani genç kömürlerin gözenekliliği yüksektir. Yüksek gözenekli kömürler çabuk okside olabilen kömürlerdir (Ünalın 2010).

Kömürlerin gaz emme (absorbe) özelliği, ilk önce kömürleşme derecesine daha sonra özgül yüzeyine bağlıdır. Özgül yüzey arttıkça gaz emme özelliği artmaktadır. Kömürleşme derecesi arttıkça emilen gaz miktarı artar. Oda sıcaklığında bir kömürün gaz emme özelliği; su, alkol, benzen, hekzan gibi sıvıların buharlarını emmesini sağlar (Larry 2002).

Bir kömürün yoğunluğu, kömürleşme derecesinin (karbon ve uçucu madde miktarı, nemliliğinin ve kül miktarının) bir fonksiyonudur (Thomas 2013). Genellikle karbon miktarı %60'tan %96'ya kadar artarken, yoğunlukta 1,2'den 1,7 g/cm³'e kadar yükselir. Linyitlerin yoğunluğu 1-1.3g/cm³ arasındadır (Larry 2002). Bir kömür damarının ekonomik değerlendirmesi yapılırken kömürün külsüz olarak yoğunluğu kullanılmaktadır. Kömür rezervlerinin hesaplanması için hacim birimlerinin kütle birimlerine dönüştürülmesinde önemli bir faktördür (Thomas 2013).

Sertlik, kömürün karbon miktarı ve uçucu madde miktarına bağlı olduğu için kömürleşme derecesinin belirlenmesi, damarların saptanması ve korelasyonu için önemlidir. Genel bir sınıflama yapmak mümkün olmamakla birlikte linyitlerin en yumuşak, antrasitlerin ise en sert oldukları kanısı yaygın bir görüştür. Sertlik, mohs ölçeğinden ziyade belirli yük altında bir iz bırakıcının kömür üzerinde meydana getirdiği izin alanının ölçülmesi ile hesaplanmaktadır. Kömürün sertliği, ekonomik yönden önem taşıyan ufalanma ve öğütme özelliklerine etki yapar (Thomas 2013).

Ufalanabilirlik, kömürleri öğütebilmek için aranan bir özellik gibi düşünülse de aslında kömürlerin daha küçük parçalara ayrılmasına yol açar ve yüzey alanını arttırarak kömürün daha hızlı oksitlenmesine neden olur (Thomas 2013). Ufalanabilirlik, kömürün kimyasal-fiziksel özellikleri ve içerdiği bileşiklere bağlıdır.

Öğütülebilirlik, kömürün sertlik, mukavemet ve kırılabilirlik gibi fiziksel özelliklerine bağlıdır. Bu özellik, kömür toz yakıt olarak kullanıldığında önem taşır (Thomas 2013). Kömürün sertliği arttıkça, öğütülebilirliği azalmaktadır.

Yansıtma (Refleksiyon), kömürlerin ışığı yansıtma özellikleri doğrudan doğruya

kömürleşme derecesine bağlıdır. Yansıtma indeksi, kömürleşme derecesiyle doğru orantılıdır. Son zamanlarda yansıtma değeri, kömürleşme derecesini belirlemek için en çok kullanılan parametredir (Tongur 2010). Yansıtma değerleri kömür havzalarındaki problemlerin çözümünde, kömür damarlarının korelasyonunda kullanılmaktadır.

2.2.2. Kömürlerin kimyasal özellikleri

Kömürlerin kimyasal özellikleri, bileşiminde bulunan elementler, yapı ve oluşum sürecine bağlı olarak değişir. Basit bir ifadeyle, kömürün nem (yüzey nemi ve bünye nemi), saf kömür (organik madde miktarı) ve mineral maddeden (kömür yandığında kül üreten mevcut inorganik malzeme miktarı) oluştuğu söylenebilir (Ünalın 2010). Kömürlerin oksidasyon, çözücülerde erime, hidrojenasyon, koklaşma gibi temel kimyasal özellikleri vardır. Kömürlerin kimyasal özellikleri belirlenirken genellikle kısa ve elementel analizlerden yararlanılmaktadır.

Kısa (Proximate) analiz, nem, uçucu madde, sabit karbon ve kül miktarlarını belirleyen analizdir. Bu, tüm kömür analizlerinin en temelidir ve kömürün pratik kullanımında büyük önem taşır. Testler büyük ölçüde kullanılan prosedüre bağlıdır ve farklı süreler ve sıcaklıklar kullanılarak farklı sonuçlar elde edilir (Thomas 2013). Bu nedenle, kullanılan prosedürü önemlidir.

Elementel (Ultimate) analiz, kömürdeki kimyasal elementlerin yani karbon, hidrojen, oksijen, azot ve kükürtün belirlenmesidir. Ayrıca, kömürün kullanılabilirliğine doğrudan etkisi olan bu elementlerin miktarlarının hesaplanması da gereklidir. Bunlar kükürt, klor ve fosfor formlarını ve kömürün mineral madde içeriğini ve seçilen eser elementleri oluşturan bu elementlerin analizini içerebilir (Thomas 2013).

Kömürde nem, kül, uçucu madde, sabit karbon ve elementlerin (C, H, O, N, S) özelliği ve analitik verilerin sunulduğu bazı anlamak önemlidir (Thomas 2013). Ayrıca kimyasal özelliklerin belirlenmesinde kullanılan analizler yapılırken hangi bazda kullanılacağına belirtilmesi yanlış yorumlamaların yapılmaması için önemlidir. Kömürlerde baz denildiğinde, kömürün içinde bulunduğu ortam koşullarına kendini uyarladığı durum anlaşılır (Çizelge 2.2, 2.3). Baz türleri aşağıda belirtilmiştir.

Alındığı gibi (As-received): Kömür örneğinin laboratuvar geldiği haliyle, yeraltında ocakta, mostrada veyahut stok sahasındaki halidir (Ward 1984).

Havada kurutulmuş baz (Air-dry basis): Bir kömür örneğinin, laboratuvar ortamına konulduktan sonra, art arda yapılan üçten fazla tartımda kütlelerinin değişmediği halidir (Ward 1984).

Kuru baz (Dry basis): Gerçekte bulunmayan ama deneyler sonucunda kömürün toplam nem içeriğinin sıfır olduğu, kömürü sadece organik ve inorganik partiküllerden oluşmuş bir nesne olarak kabul edilen hipotetik baz türüdür (Ward 1984).

Kuru külsüz baz (Ash-free dry basis): Kömürün toplam nem ve külü içeriğinin sıfır kabul edildiği hipotetik bazdır (Ward 1984).

Çizelge 2.2. Kısa analizlerde kullanılan bazlar (Ward 1984)

Kısa Analiz			
Nem	Kül	Uçucu Madde	Sabit Karbon
Alındığı gibi	Alındığı gibi	Alındığı gibi	Alındığı gibi
Havada kurutulmuş	Havada kurutulmuş	Havada kurutulmuş	Havada kurutulmuş
	Kuru baz	Kuru baz	Kuru baz
		Kuru külsüz baz	Kuru külsüz baz

Çizelge 2.3. Elementel analizler yapılırken kullanılan bazlar (Ward 1984)

Elementel Analiz				
C (ağırlıkça,%)	H (ağırlıkça,%)	N (ağırlıkça,%)	O (ağırlıkça,%)	S (ağırlıkça,%)
Alındığı gibi	Alındığı gibi	Alındığı gibi	Alındığı gibi	Alındığı gibi
Havada kurutulmuş	Havada kurutulmuş	Havada kurutulmuş	Havada kurutulmuş	Havada kurutulmuş
Kuru baz	Kuru baz	Kuru baz	Kuru baz	Kuru baz
Kuru külsüz baz	Kuru külsüz baz	Kuru külsüz baz	Kuru külsüz baz	Kuru külsüz baz

2.2.2.1. Kısa analizler

Kömür ilk çıkarıldığı zaman kömür kalitesini belirleme, genel özellikleri ile tanımlama işlemleri için bazı temel analizlere tabi tutulur. Bu analiz türüne ise kısa analiz denir. Bu analiz sonucunda dünya genelinde kabul edilen ASTM D-3172 standartlarına göre sınıflandırma yapılır (Thomas 2013). Bu analizler dört ana başlıkta toplanabilir.

Nem: Üç çeşit kömür nemi mevcuttur. Kömür ilk çıkarıldığında üzerinde bulunan sıvı katmanı yüzey nemi, kömüre dışarıdan katılan sudur. Higroskopik nem ise kömür kütleindeki partiküller içine sızmış, yer yer boşluklarında bulunan sudur (Hower ve Wild 1988).

Kül: Kömürün külü, yakma işleminden arta kalan yanıcı olmayan inorganik kalıntıdır. Bu, inorganik maddelerden yüksek sıcaklıkta uçucu olan bileşiklerin (CO₂, SO₂ ve H₂O gibi) uzaklaşmasıyla geriye kalan maddeyi temsil eder (Thomas 2013). Yüksek kül içeriği tercih edilen bir özellik değildir. Yakma sonrası atık problemleri açığa çıkarır.

Uçucu Madde: Nem dışında yüksek sıcaklıkta serbestleşen maddelerin tamamıdır. CO, CO₂, SO₄, CH₄ bu uçuculara örnek gösterilebilir. Bunlar organik maddelerden veya inorganik maddelerden türeyebilirler (Thomas 2013).

Sabit Karbon: Kömürdeki uçucu maddeler uzaklaştırıldıktan sonra arta kalan malzemede bulunan karbondur. Bu kömürün organik bileşiklerinin bozunma artıklarını temsil eder ve az miktarda N, S, H ve olasılıkla oksijeni de içerir (Thomas 2013).

2.2.2.2. Elementel analizler

Sahada yapılan kısa analizler sonrası laboratuvar ortamında yapılan elementel analiz kömürün temel bileşiminin mutlak bir değerlendirmesidir. Kömür örneklerinin yanma gazlarının analiz edilmesiyle gerçekleştirilir (Pollock vd. 2000). Kömürün organik yapısını büyük ölçüde oluşturan, karbon, hidrojen, azot ve kükürt gibi elementlerin miktarları tespit edilir. ASTM D-3176 sınıflaması esas alınarak, kökenine bakılmaksızın kömürün yüzdesel oranda karbon, hidrojen, oksijen, azot, kükürt ve kül bileşimini ifade eder (Thomas 2013).

Karbon ve Hidrojen: Bunlar kömür yandığında CO₂ ve H₂O olarak açığa çıkar ve birlikte belirlenir. Bununla birlikte, CO₂ mevcut karbonat minerallerinden serbest kalabilir ve H₂O kil minerallerinden veya havada kurutulmuş kömürdeki doğal nemden ya da her ikisinden de elde edilebilir (Larry 2002)

Azot: Kömürün nitrojen içeriği özellikle atmosferik kirlilik açısından önemlidir. Kömürün yanması üzerine azot, baca gazı olarak salınabilen ve böylece atmosferi kirleten oksitlerin oluşmasına yardımcı olur ve bu nedenle azot oranı düşük kömürler endüstri tarafından daha fazla tercih edilir (Larry 2002).

Kükürt: Kömürün nihai analizinde sadece toplam kükürt içeriği belirlenir, ancak birçok durumda her bir formdaki göreceli kükürt miktarı gereklidir. Bu ayrı bir analiz olarak gerçekleştirilir (Larry 2002).

Oksijen: Kömürdeki organik ve inorganik bileşiklerin birçoğunun yanı sıra nem içeriğinin de bir bileşenidir. Kömür oksitlendiğinde, oksijen oksitlerde, hidroksitlerde ve sülfat minerallerinin yanı sıra oksitlenmiş organik maddelerde de bulunabilir (Thomas 2013).

2.2.3. Maseraller

Kömürün heterojen bir kayaç olması, bir dizi farklı bitki türünden oluşan bileşenlerin yanı sıra algler, mantarlar ve bakterilerden elde edilen organik maddelerden oluşmasından kaynaklanmaktadır. Buna ek olarak, heterojenlik, bu bileşenlerin gömülmeden önce ve diyajenez ve kömürleşme sırasında değiştirilme derecesi ve şeklindeki farklılıklardan kaynaklanmaktadır (Stopes 1935). Kömür üstten aydınlatmalı floresan mikroskobu altında incelendiğinde veya elektron mikroskobu kullanıldığında yapısal olarak incelenmesi mümkün olabilmektedir. Mikroskop altında, organik maddenin tek tek bileşenleri veya parçaları tanınabilir. Bu parçalar maseral olarak adlandırılır (Stopes 1935). Her maseral grup bir dizi farklı maseral tip içerir. Bunlar renk, şekil, yansıtıcılık ve yapı temelinde gruplandırılır (Taylor vd. 1998). Üç ana maseral grubunun farklı kaynaklardan türediği bilinmektedir Maseraller, organik yapıya moleküler düzeyde bağlı veya başka bir şekilde gömülü inorganik maddeler içerebilir. Bu inorganik maddeler, kömürün inorganik kısmının büyük bölümünü oluşturan farklı mineral fazlarından farklıdır (Taylor vd. 1998).

Kömürde maseral dağılımı, kömürün organik bileşenlerinin ve yapısının incelenmesi için kullanılan önemli bir değerlendirmedir. Maserel dağılımı, kömürün kalite parametrelerinin ve çevresel etkilerini değerlendirmek için önemli kıstaslardan biri olarak kullanılır (Zhu 2008). Ayrıca, kömürün hangi amaçlarla daha uygun olduğunu belirlemek için de önemlidir. Kömürün kalitesini ve enerji içeriğini değerlendirmenin yanı sıra oluşum sürecini yorumlamak için de önemlidir. Bu da sanayi ve enerji sektörlerinde kömürün daha verimli kullanılmasına yardımcı olur.

Maseraller, kömürün organik bileşenlerini oluşturan farklı türdeki karbonlu maddelerdir. Genellikle üç ana maseral grubu vardır.

Hüminit/Vitrinit maseral grubu, kömürün en yaygın maserali olup, yüksek karbon içeriğine sahiptir (Çizelge 2.4). Üstten yansıtımlı mikroskopta rengi koyu ila orta gri arasındadır. Ölçülen yansıtma değeri (R_r) ~0,2 ile %0,4 arasında değişir (Cohen vd. 1987). Üst yansıtma sınırı, düşük dereceli kömür ile orta dereceli kömürü ayıran yansıtma değeri olarak alınmıştır. Genel olarak hüminit izotropiktir. Selüloz kalıntıları mevcutsa anizotropi (çift yansıtma) meydana gelir (Given ve Dyrkacz 1988). İletilen ışıktaki daha kolay görülebilen bu olgu, selülozun tanımlanması için kullanılır. Yüksek dereceli kömürler için vitrinit sınıflandırılması kullanılır. Odundaki ligno-selüloz biyopolimerlerinin mikrobiyal ve termal olarak değiştirilmiş kalıntılarını temsil ettiği düşünülmektedir (Taylor vd. 1998).

Alt hüminit maserallerinden telohüminit, çeşitli düzeylerde görülebilen korunmuş bozulmamış bitkisel hücre yapılarına sahip maserallerden ve koyu renkli liptinit ile daha açık renkli inertinit maseralleri arasında yansıtma gösteren izole hücrelerden oluşan maseral alt grubudur (Jacob 1970). Detrohüminit ise, liptinit ve inertinit maserallerinin yansıtma değerleri arasında kalan ince hümitik parçalardan oluşan, amorf hümitik madde ile çimentolanmış olabilen maseral grubu hüminitin bir alt grubudur. Gevşek bir şekilde paketlenmiş hücre parçaları veya diğer hümitik bitki artıklarından oluşan kömürlerden oluşur. Jelleşmeye bağlı olarak, detrohüminit maseraller atrinit (jelleşmemiş) ve densinit (jelleşmiş) olmak üzere alt bölümlere ayrılır. Her iki maseralin dokusundaki farklılıklar, üstten aydınlatmalı elektron mikroskobu ile daha ayrıntılı olarak belirlenebilir (Taylor vd. 1998). Jelohüminit, hüminit maseral grubu içerisinde gri renkli, yapısız, homojen hüminit yansıtımlı maddelerden oluşan bir maseral alt grubunu ifade eder. Yoğun jelleşmiş bitki dokularından ve yapısı yansıyan ışıktaki tanınmayan hümitik kalıntılardan türemiş olabilir. Ayrıca çökelmiş hümitik kolloidlerden de türemiş olabilir (Sykorova vd. 2004). Üçüncü bir türetme, bitkilerin kendileri tarafından oluşturulan birincil flobafenik hücre dolgularından (çoğunlukla gymnosperm odununda) kaynaklanır (Malan 1965).

Çizelge 2.4. Linyit ve alt bitümlü kömürlerde maseral grupları, maseral alt grupları, maseraller ve maseral tipleri (Stach vd. 1982; Sykorova vd. 2004)

Maseral Grubu	Maseral Alt Grubu	Maseraller	Maseral Tipi
Hüminit	Telohüminit	Tekstinit	Tekstoülminit Eu-ülminit
		Ülminit	
	Detrohüminit	Atrinit	
		Densinit	
	Gelohüminit	Gelinit	Levigelinit Porigelinit Filobafinit Psödo-filobafinit
		Korpohüminit	
Liptinit		Sporinit	
		Kütinit	
		Resinit	
		Süberinit	
		Alginit	
		Fluorinit	
		Bitüminit	
		Eksudatinit	
		Liptodetrinit	
		Sporongium	
İnertinit		Füsinit	
		Semifüsinit	
		Makrinit	
		Mikrinit	
		Sklerotinit (Funginit)	
		İnertodetrinit	

Liptinit maseral grubu, bitkisel kökenli olup, daha düşük karbon içeriğine sahip ve genellikle daha fazla hidrojen ve oksijen içerir. Parlatılmış kesitte çok koyu gri renk veya floresans ışık altında parlak sarı renk ile karakterize edilir (Pickel vd. 2017). Liptinit, kömürün yanma özelliklerini etkileyebilir. Spor ve polenlerin iskelet/kabuk yapısından (sporinit) türetilen küçük parçacıklar ve yaprak dokularının dış tabakasını veya kütikülünü (kütinit) temsil eden uzun, ince bantların yanı sıra çeşitli reçine gövdeleri (rezinit) ve alglar(alginit) bulunur (Pickel vd. 2017). Kömürdeki liptinit maserallerinin vasküler bitkilerin lipid bakımından zengin fraksiyonlarından kaynaklandığı düşünülmektedir (Taylor vd. 1998). Dokunun ligno-selülozundan kaynaklanması nedeniyle yüksek aromatik karbon ve oksijen içeriğine sahiptir (Goodarzi 1985).

İnertinit maseral grubu, genellikle mineral ve organik olmayan bileşenleri içerir. Paleozoik döneme ait, özellikle Gondwana kömürleri, Mezozoik ve Tersiyer kömürlerine kıyasla daha fazla inertinit içermektedir (Shearer vd.1995). İnertinit maseralleri, hüminit ve liptinit ile aynı bitki kaynak malzemelerinden kaynaklanır, ancak kaynak malzemeler yanma gibi oksidasyon süreçleriyle metamorfizmaya uğramıştır (Goodarzi 1985). Yanma süreçleri ile gerçekleşen karbonlaşma nedeniyle diğer maseral gruplarından daha yüksek karbon içeriğine sahiptir. İnertinit maseralleri ya hiç floresans özellik göstermez ya da vitrinit maserallerine kıyasla daha düşük floresansa sahiptir. Hücresel yapıların şekli ve korunma derecesi, inertinit maserallerinin kökenine ve çökelme sonrası geçirdiği süreçlere bağlı olarak değişiklik gösterir (Alpern ve Lemos 1970). Farklı maseral grupları, kökenlerindeki farklılıkları yansıtan farklı kimyasal bileşimlere sahiptir (Taylor vd. 1998).

Kömürde yansıtımlı mikroskopta füzinit maserali mercekler, bantlar halinde bulunur. Füzinit, su veya hava yoluyla bataklığa veya tortul havzaya taşınmış olabilir (Stach vd. 1982) ancak yerinde yanma yoluyla da oluşmuş olabilir (Goodarzi 1985). Grimsi beyazdan sarımsı beyaza doğru kayan yansıtma değeri nispeten yüksektir, ancak kömürleşme derecesi ile paralel şekilde de artar (Alpern ve Lemos 1970). Semifüzinit yansıtımlı mikroskopta hüminitten daha açık bir griye sahip bileşendir. Semifüzinit yansıtma değeri, turba aşamasından önce veya sırasında öncüllerinin dehidratasyon ve oksidasyon derecesiyle ve ayrıca kömürleşme derecesi ile artar (Diessel 1992). Semifüzinit genellikle düzensiz anizotropi gösterir. Makrinit ise tabakaya dik olarak kesilmiş kesitlerde görüntülendiğinde spesifik bir kütle veya bantlar veya mercekler şeklinde görünebilir. Karakteristik bir şekle sahip değildir. Yapısı ve yansıtıcılığı bakımından semifüzinite benzeyebilir (Smith ve Cook 1980). İnertodetrinit bir dereceye kadar füzinitleşmeye tabi tutulmuş çeşitli fitogenetik öncüllere sahiptir: Bitki hücre duvarları veya içerikleri, ayrılmış dokulardan (Taylor vd. 1998), oksitlenmiş sporlar ve mantar kalıntısı olan bileşenlere kadar. İnertodetrinitin birçok parçacığı turbalıktaveya çevresinde çıkan orman yangınlarından kalan kalıntılardır (Goodarzi 1985).

2.3. Yapay Sinir Ağları

Turing makineleriyle temeli atılan yapay zekâ teknolojisi her geçen gün daha fazla gelişmektedir ve yeni ticari sistemler ortaya çıkarmakta ve sistemlerin fonksiyonel özellikleri artmaktadır (Öztemel, 2003). Bunun bir sonucu olarak yeni ürünler ortaya çıkmakta ve daha çok günlük hayatta kendisini göstermektedir. Otomasyon sistemleri de yapay zekâ teknolojisi ile donatılarak bilgisayarın karar verme gücünden faydalanılmaktadır.

Yapay zekâ teknolojisi üzerinde en fazla araştırma yapılan konu “Yapay Sinir Ağları”dır. Yapay sinir ağları, temelde tamamen insan beyni örneklenerek geliştirilmiş bir teknolojidir. Yapay bir sinir hücresi, biyolojik bir sinir hücresinin temel davranışlarından esinlenen matematiksel modeli ortaya koyan bir algoritma veya fiziksel araç olarak tanımlanabilir (Öztemel 2003). Yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır.

Basit bir sinir ağı, uygun eğitimden sonra yeni bir girdi örüntüsü sunulduğunda benzerlikleri tanıyabilir ve çıktı örüntüsünü tahmin edebilir (Graupe 2007). Belirli bir girdi daha önce hiç bilinmese bile girdilerdeki benzerlikleri tespit edebilir. Bu özellik, özellikle girdi verileri eksik olduğunda, mükemmel interpolasyon yeteneklerine izin verir (Kosko 1994). Sinir ağları, oto korelasyon, çok değişkenli regresyon, doğrusal regresyon, trigonometrik ve diğer istatistiksel analiz teknikleri için doğrudan bir ikame olarak kullanılabilir (Kosko 1994). Veriler bir sinir ağı kullanılarak analiz edildiğinde, daha önce uzman olmayan biri için belirgin olmayan önemli tahmin örüntülerini tespit etmek mümkündür (Graupe 2007). Böylece, sinir ağı belli sayıda eğitim verisi eğittikten sonra bir uzman gibi davranabilir. Belirli bir ağ, üç temel bileşen kullanılarak tanımlanabilir: transfer fonksiyonu, ağ mimarisi ve öğrenme yasası (Simpson 1990). Çözülecek probleme bağlı olarak bu bileşenler tanımlanmalıdır. Donanım olarak elektronik devrelerle veya bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir (Graupe 2007).

Biyolojik sinir hücresinin tanımından hareket ederek, yapay bir sinir hücresinin diğer sinir hücrelerinden aldığı sinyalleri bünyesinde topladığını ve toplam sinyal birikiminin belli bir eşiği aştığı anda, bu yapay sinir hücresinin kendi sinyalini bir başka sinir hücresine ilettiği ifade edilmektedir (Haykin 1999). Yapay nöronlar basit bir şekilde kümelendirilmektedir. Bu kümelendirme tabakalar halinde yapılmaktadır ve daha sonra bu tabakalar bir diğerine ilişkilendirilmektedir. Temel olarak, tüm yapay sinir ağları benzer bir yapıya sahiptir. Bu yapıda, bazı nöronlar girdileri almak için bazı nöronlar ise çıktılarını iletmek için dış mekân ile bağlantılı haldedirler. Geri kalan tüm nöronlar ise gizli tabakalardadırlar, yani sadece ağ içinde bağlantıları vardır (Haykin 1999)

Yapay sinir ağlarının günümüzde en yaygın olarak kullanılan modeli çok katmanlı algılayıcı (ÇKA) ağlarıdır. Bu ağlar, özellikle mühendislik problemlerinin %95'ine çözüm üretebilecek niteliktedir. ÇKA ağları ikili değer problemini (örneğin, 0-1, doğru-yanlış) çözebilmek için yapılan çalışmalar neticesinde ortaya çıkmıştır (Graupe 2007). ÇKA modelinde geriye yayılım algoritması kullanılmaktadır. Bu algoritma ara katman içeren yapay sinir ağlarında kullanılan güçlü bir öğrenme algoritmasıdır (Şen 2004). Bu ağlar 3 katmandan oluşurlar (Şekil 2.1).

Girdi katmanı: Verinin dahil olduğu fakat henüz hiçbir işleme dahil olmadığı katmandır (Haykin 1999).

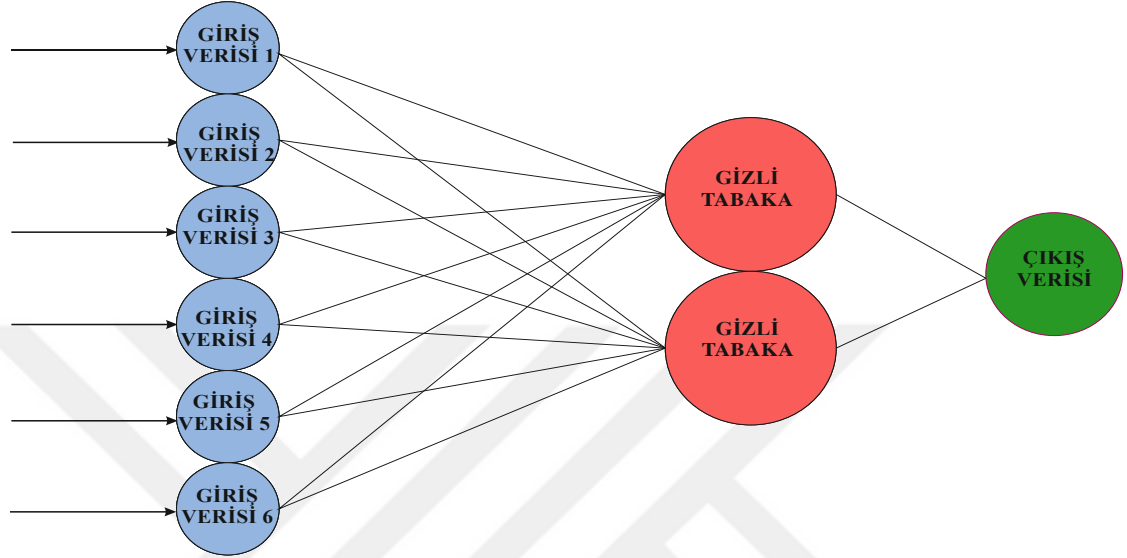
Ara katmanlar: Girdi katmanından gelen veriler işlenir. Bir adet ara katman ile birçok problemi çözmek mümkündür. Eğer ağın öğrenmesi istenilen problemin içindeki karmaşıklık artarsa birden fazla sayıda ara katman da kullanılabilir (Haykin 1999).

Çıktı katmanı: Ara katmandan gelen bilgileri işleyerek ağa girdi katmanından sunulan girdi için ağın ürettiği çıktıyı bulur (Haykin 1999).

Girdi ve çıktı durumuna göre ara katmanın belirleyicisi olarak sayılabilecek ağırlık katmanları ve gizli katmanlar artırılabilir veya azaltılabilir. Bu tamamen deneme ve yanılma sonucu karar verilebilecek bir durumdur. Yapay sinir hücrelerinin çalışması sırasında aktif üç temel katmanın yanı sıra iki temel bileşen mevcuttur. Bunlar;

Ağırlık fonksiyonu: Her nöron, kendisine gelen girdiler üzerinde belirli ağırlıklar uygular. Her nöron için, ağırlıklar ve girdi değerleri çarpılıp toplanır (Graupe 2007).

Aktivasyon fonksiyonu: Toplama sonucuna bir aktivasyon fonksiyonu uygulanır. Bu fonksiyon, nöronun çıkış değerini belirlemeye yardımcı olur. Aktif hale gelmeyen nöronlar, çıkış katmanına geçmez (Gülbağ 2006).



Şekil 2.1. Altı giriş iki gizli katman ve bir çıkış verisinden oluşan İleri yönlü çok katmanlı ağ yapısı örneği

YSA oluştururken her veri çeşidine ve yoğunluğuna uygun olarak algoritma oluşturulmuştur. ÇKA en çok kullanılan ağ yapısı olmasının yanı sıra birçok alt algoritmaya sahiptir. Zaman içinde kullanım kolaylığına ve doğruluk oranına göre uygulanan algoritmalar geliştirilmiştir. Literatürde kullanılan ve doğruluk konusunda başarılı sonuçlar vermiş algoritmalar;

İleri yönlü çok katmanlı algılayıcı (İYÇK): Bu algoritma, modelin girdi verileri ile beklenen sonuçlar arasında daha iyi bir ilişki kurmasına yardımcı olur. Her aşamada, ağın daha doğru tahminler yapabilmesi için gerekirse daha fazla gizli katman veya nöron eklenebilir (Deore 2021). İleri yönlü çok katmanlı algılayıcılar, özellikle sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılır. Hatanın minimize edilmesi amacıyla ağırlıklar, geri yayılım algoritması kullanılarak güncellenir. Bu işlem, model yeterince iyi öğrenene kadar tekrar edilir (İşeri ve Karlık 2009).

Kaskad ileri yönlü algılayıcı (KİYA): Belirli bir giriş sinyalini işlemek için birden fazla katman (veya aşama) kullanarak çalışan sistemlerdir. Kaskad yapısının avantajı, her bir katmanın bağımsız olarak optimize edilebilmesi ve belirli işlevlerin daha etkin bir şekilde gerçekleştirilmesidir. Örneğin, ses işleme veya görüntü tanıma gibi karmaşık görevlerde, her katman belirli bir özellik veya yönü vurgulayabilir (Fahlman ve Lebiere 1990).

Modifiye edilmiş ağırlıklı sinir ağı (MEA-YSA): Bu kavram, sinir ağlarının geliştirilmiş bir versiyonunu ifade eder ve belirli bir problemin çözümünde daha iyi

performans sağlamayı hedefler. MEA-YSA, genellikle çok katmanlı bir yapıya sahiptir ve her katmanda farklı sayıda nöron içerebilir. Nöronlar, girdileri işleyerek çıktılar üretir. Ağırlıklar, her nöronun çıktısının, girdilere olan katkısını belirler. MEA-YSA'da, gelen verilere göre ağırlıklar modifiye edilerek daha hassas ve doğru bir öğrenme süreci sağlanır. Sinir ağları, öğrenme sürecinde hata terimlerini minimize ederek günceller. MEA-YSA, bu yöntemi kullanarak, ağırlıkları ve önyargıları optimize eder. Geleneksel hesaplama yöntemlerinin ötesinde, belirsizlik ve yaklaşık hesaplama gibi durumları ele almak için yumuşak hesaplama adı verilen bir yöntem kullanılır. Bu yöntem esnek ve etkili çözümler sunabilir (Bishop ve Nasrabadi 2006).

Çoklu Doğrusal Regresyon (ÇDR): Bir bağımlı değişkenin birden fazla bağımsız değişken kullanılarak tahmin edilmesi için kullanılan istatistiksel bir tekniktir. ÇDR, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi modellemek için doğrusal bir fonksiyon kullanır (Bengio vd. 2017). Regresyon katsayıları, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini temsil eder. Her bir bağımsız değişkenin etkisi, katsayıların büyüklüğüne bağlıdır. ÇDR modelinin başarısını değerlendirmek için genellikle R-kare değeri kullanılır. Bu değer, modelin açıklayıcılığını gösterir ve 0 ile 1 arasında değişir. R-kare değerinin 1'e yaklaşması modelin daha iyi tahminlerde bulunduğu anlamına gelir (Bishop ve Nasrabadi 2006).

Çoklu Lojistik Regresyon (ÇLR): Birden fazla bağımsız değişken kullanarak bir bağımlı değişkenin genellikle ikili sonuçlarını tahmin etmeye yönelik istatistiksel bir tekniktir. ÇLR, özellikle bağımlı değişkenin iki veya daha fazla kategorisi olduğunda kullanılır. Regresyon katsayıları, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini ifade eder. Katsayıların pozitif ya da negatif olması, ilgili değişkenin olayın gerçekleşme olasılığı üzerindeki etkisini gösterir. Sonuçların olasılığını tahmin ederken, oran dönüşümünü kullanır. Oran, belirli bir olayın gerçekleşme olasılığının gerçekleşmeme olasılığına oranıdır (Bishop ve Nasrabadi 2006).

Hiper-parametre optimizasyon yöntemi ise son yıllarda sıkça kullanılan YSA yöntemlerindedir. Hiper-parametreler, modelin öğrenim sürecini ve çıktısını etkileyen önceden belirlenmiş değerlerdir. Seçim dışarıdan optimizasyon müdahalesi ile veya elden insan tarafından seçilerek yapılabilir. Yanlış hiper-parametre seçimi modelin kötü sonuçlar çıkarmasına neden olabilir. Model eğitimi başlamadan önce ayarlanırlar (Yu ve Zhu 2020). Optimizasyon ile seçim yapılan hiper-parametreler:

Öğrenme oranı (Learning rate), gradyan iniş yöntemlerinde kullanılan bir parametredir. Bu parametreler ağ ağırlığını güncellemek için kullanılır. Öğrenme hızı parametresinin belirli seviyeden küçük olması gradyan iniş yönteminin yavaş yakınsamasına sebep olabilirken, parametrenin büyük olması ise yakınsamadan uzaklaşmasına sebep olabilmektedir (Çarkacı 2018).

Dönem/Era (Epoch), modelin kullanılan veri seti üzerinden kaç kez çalışacağını belirler. Bir demet, bir veya birden fazla yığılımdan oluşabilir. İleri ve geri yönde tüm ağ üzerinden geçmesiyle gerçekleşir (Brownlee 2018). Eğitim sırasında verinin kaç kez işleneceğini kontrol eder. Fazla dönem uygulanırsa aşırı öğrenme (overfitting); Az dönem uygulanırsa yetersiz öğrenme (underfitting) gerçekleşebilir.

Demet Sayısı (Batch), eğitim sırasında modelin aynı anda işlediği örnek sayısını belirler. Küçük batch boyutları: Daha doğru gradyan tahmini ama daha uzun eğitim

süresi. Büyük batch boyutları: Daha hızlı eğitim ama daha düşük genelleme performansı. Modelden kaynaklı hata yeterince küçük değer almaya kadar öğrenme algoritmasının çalışmasına izin verilir (Çarkacı 2018).

Aktivasyon Fonksiyonu: Her katmanda kullanılan aktivasyon fonksiyonu (ör. ReLU, Sigmoid, Tanh) modelin davranışını değiştirir. Modelin öğrenme kapasitesini ve doğruluğunu doğrudan etkiler. Sigmoid Fonksiyonu, çıktıyı bir olasılık gibi yorumlamak için idealdir (örneğin, lojistik regresyonda). Küçük ve büyük giriş değerlerini “0” ve “1” aralığında sıkıştırır (Çarkacı 2018). Doğrusal olmayan bir fonksiyon olduğu için karmaşık ilişkileri öğrenebilir. Olasılık tabanlı sınıflandırmalar için uygundur. Fakat çok büyük veya çok küçük giriş değerlerinde türevinin değeri sıfıra yaklaşır, bu da derin ağlarda öğrenmeyi yavaşlatır. Tanh (Hiperbolik Tanjant) Fonksiyonu, sigmoid fonksiyonuna benzer ancak çıktı aralığı “-1” ile “1” arasında olduğu için negatif girişler negatif, pozitif girişler pozitif çıkış üretir (Brownlee 2018). Simetrik çıktılar sunar, bu da gradyan optimizasyonunu kolaylaştırır. Fakat derin ağlarda performansı sınırlı kalabilir. ReLU (Rectified Linear Unit) Fonksiyonunda ise pozitif giriş değerlerini olduğu gibi geçirir, negatif girişleri ise sıfır kabul eder “0” ve “ ∞ ” arasındadır. Hesaplama açısından oldukça basittir. Gradyan kaybolma problemini azaltır, çünkü pozitif girişler için türev sabittir. Fakat girişlerin bir kısmı negatif olursa, bu nöronlar tamamen etkisiz hale gelebilir yani türev sıfır olabilir (Senapati 2018).

Optimizasyon Fonksiyonu: Derin öğrenme modellerini optimize etmek için kullanılan optimizasyon algoritmalarıdır. Her biri gradyan temelli optimizasyonun farklı yönlerini ele alır ve belirli durumlar için avantajlar sunar. Bu fonksiyonlardan SGD yöntemi basit ve etkili; genelde sabit öğrenme hızında çalışır. Küçük veri setleri ve hızlı prototipleme için uygundur. RMSprop fonksiyonu ise daha stabil bir öğrenme süreci için, özellikle derin ağlarda adaptif öğrenme hızını kontrol eder. ADAM fonksiyonu momentum ve adaptif hızın birleşimi sayesinde çoğu durumda güçlü bir performans sergiler. Derin öğrenmede genellikle varsayılan seçimdir (Türkoğlu vd. 2021).

Her bir optimizasyon için elle ya da mevcut yöntemlerle seçim yapılabilir. Bu seçimler doğru bir nöron oluşumu için oldukça önemlidir. Birçok farklı yöntemle hiper-parametre seçim yöntemi mevcuttur:

Kafes Arama (Grid Search): Belirli bir hiper-parametre kümesi üzerinde tüm olasılıkları dener. Her hiper-parametre için bir aralık veya değer seti belirlenir ve tüm kombinasyonlar test edilerek modelin performansı ölçülür (Ayuya 2021).

Rastgele Arama (Random Search): Belirli bir hiper-parametre uzayından rastgele örnekler alarak deneme yapar. Daha az hesaplama ile daha geniş bir alanı keşfetme imkânı sunar (Senapati 2018).

Anahtarlama Optimizasyonu: Çeşitli hiper-parametre kombinasyonlarını aynı anda denemek için kaynakları akılcıca tahsis eder. Başlangıçta birçok deneme gerçekleştirir ve en az performansı gösterenleri eler.

Evrimsel Optimizasyon: Hiper-parametrelerin optimize edilmesi için genetik algoritmalar kullanır. Farklı popülasyonların ve nesillerin çaprazlamasıyla en iyi sonuçları bulmaya çalışır. Genetik Programlama (GP), bilgisayar bilimlerinde kullanılan bir evrimsel hesaplama tekniğidir. Bu yöntem, doğal seçim ve genetik mekanizmaları

taklit ederek çözümler veya programlar üretmeyi amaçlar (Türkoğlu vd. 2021). GP belirli bir problemi çözmek için en iyi algoritmaları veya çözümleri bulmak için kullanılan bir süreçtir. Problemi temsil eden bir dizi bireyden oluşan bir popülasyon yaratılır. Her birey, fonksiyonlar ve değişkenlerden oluşan bir ağaç yapısıyla temsil edilir. Her bireyin ne kadar iyi bir çözüm sunduğu, belirli bir uygunluk fonksiyonu kullanılarak değerlendirilir (Ali ve Hanbay 2018). Seçim, çaprazlama ve mutasyon evrelerinden oluşur.

Bayes Optimizasyonu (BO): Hiper-parametrelerin dağılımını modelleyerek, hedef fonksiyonu en yüksek doğrulukla tahmin etmeye çalışır. Geçmiş deneyimden öğrenerek daha az deneme ile daha iyi sonuçlar elde etmeye çalışır. Bunun için Bayes teoremini kullanan bir yaklaşımdır. Bayes teoremi ise bir olayın koşullu olasılığını hesaplamak için kullanılır. BO geçmiş değerlendirme sonuçlarına dayanarak bir vekil fonksiyon oluşturur ve sonraki her bir girişim önceki denemelerin değerlerine bağlı olarak yapılır. Öncül fonksiyon en iyi hiper parametre seti seçilene kadar bir sonraki deneme için güncellenir. Bayes optimizasyon algoritmasında birçok olasılık modeli kullanılmasına rağmen en yaygın olanı Gauss Teoremi'dir (Yu ve Zhu 2020).

Gauss Teoreminde, Bir fonksiyon ayarlanırken, yüksek olasılıklara sahip tüm olası fonksiyonlar üzerinden bir olasılık dağılımı belirlenir. Bu yaklaşım gauss süreci tarafından gerçekleşir (Yperman ve Becker 2016). Sonsuz sayıda temel fonksiyona sahip Bayes doğrusal regresyona eşdeğerdir (Seeger 2004). Gauss teoremi, tahminlerdeki belirsizliğin ölçülmesine izin veren, Bayes optimizasyonu için gayet uygun bir öncü modelidir (Yu ve Zhu 2020). Uygulamalarda deneme yanılma yöntemi ile sonsuz sayıda deneme yapılamayacağı için, hiper-parametre optimizasyonu yöntemleri, hiper-parametre dediğimiz sonsuz değer alabilecek ağ değişkenlerinin (Öğrenme Oranı, Nöron Sayıları vb.) en iyi kombinasyonlarını bulmaya çalışarak en iyi sonuca en hızlı şekilde ulaşmaya yardımcı olur.

Genel olarak üç adımdan oluşur. Birincisi, genellikle Gauss süreci (GS) modellenmesi kullanılarak ölçülen verilere dayalı olarak amaç ve kısıtlayıcı işlevlerin istatistiksel bir vekil modelinin oluşturulmasıdır. İkinci adım, optimizasyon hedeflerine ulaşmak için girdi alanındaki potansiyel gelecekteki ölçümlerin görece "değerini" tanımlayan GS modeline dayalı bir edinim işlevinin tanımlanmasıdır. Son adım, edinim işlevini en üst düzeye çıkaran ve böylece optimizasyon hedeflerine yönelik en fazla değeri sağlaması öngörülen noktayı çözümler (Yu ve Zhu 2020). Son aşamada seçilen noktalar, mevcut bilgilere dayanarak hangi noktaların test edileceğini belirlemek üzere değerlendirilir. Bu fonksiyon, keşif (exploration) ve sömürü (exploitation) arasındaki dengeyi sağlamaya çalışır (Seeger 2004).

Diğer optimizasyon algoritmalarına benzer şekilde, Bayes optimizasyonu algoritmaları gözlemlenecek gelecekteki noktalar hakkında karar vermeye başlamak için en az bir başlangıç noktası gerektirir. Başlangıç noktaları genellikle parametre uzayının yerel bir bölgesinde rastgele örneklenen noktalar veya nesnel uç noktasına yakın olduğu bilinen önceden seçilmiş noktalar kullanılarak seçilir (Seeger 2004). Alternatif olarak, doğrudan geçmiş veri kümelerinden veya önceki optimizasyon çalışmalarından veri eklemek de mümkündür.

2.4. Kaynak Taraması

Kömür, organik maddenin petrografik yapı taşı olarak adlandırılan maseraller, mineraller ve inorganik elementlerin bir araya gelmesinden oluşan organik bir kayaç olarak tanımlanabilir. Kömürün fiziksel özellikleri kömürleşme derecesine göre değişkenlik gösterir. Kömürün temel bileşimi karbon (C), hidrojen (H) ve oksijen (O), az miktarda azot (N) ve kükürt (S) ile ana bileşenlerden oluşmaktadır. Kömürün kimyasal bileşimi, kısa ve elementel analizi ile tanımlanır. Kömürleşme sürecinin derecesine göre genel olarak turba, linyit, taşkömürü ve antrasit olarak sınıflandırılır. Günümüzde bu parametreleri belirlemek oldukça masraflı olması yanı sıra ciddi bir uzmanlık gerektirmektedir. Bu sebeple YSA ile kurulan algoritmalar istatistiki olarak formülize edildiğinden ciddi bir zaman ve bütçe tasarrufu sağlayabilmektedir.

YSA ile ilgili çalışmalar uzun yıllardır süre gelen algoritmalar gelişmesine olanak sağlamıştır. Kömürler üzerine ilk olarak 1989'da yapılan YSA çalışması günümüzde oldukça gelişmiştir. Aşağıda bu bağlamda çalışılan literatür işlenmiştir.

Takahashi ve Sasaki (1989), dağılım modelinden bazı sabit aralıklarla yansıma ölçümü yaparak maserallerin tanımlanması için otomatik analiz önermişlerdir.

Ravi ve Reddy (1999), bulanık çok kriterli karar verme modelini kullanarak Hindistan'ın koklaşabilir ve koklaşmayan kömürlerinin endüstriyel kullanım için sınıflandırılmasını önermişlerdir. Hindistan kömürünün sabit karbon, uçucu madde, nem içeriği ve kül içeriğini tahmin etmek için kullanmışlardır. Bu parametreleri, mevcut literatüre dayanarak, veri aralığı üzerinde bulanık kümeler olarak değerlendirmişlerdir.

Vasconcelos (1999), Dünya kömürlerinin maseral analizlerinin mekansal dağılımını araştırmış ve tüm dünyadaki kömürler için vitrinit, liptinit, inertinit verilerine dayanarak farklı kategoriler arasındaki sınır değerleri belirlemiştir.

Kalkreuth vd. (2004), vitrinit yansıma ve çoklu maserallerin floresan değişimi analizlerini birleştirerek, Brezilya'daki Parana Havzası Permien kömürlerinde vitrinitlerin organik kimyasal yapısı hakkında fikir veren bir teknik önermişlerdir.

Parikh vd. (2005), kısa (proximate) analizinden kömürün üst ısıl değerini hesaplamıştır.

Khandelwal ve Singh (2010), çalışmalarında kömürün kısa ve elementel analizini de dahil ederek yapay sinir ağı kullanarak Hint kömürlerindeki maseral konsantrasyonunu tahmin edilmiştir. Bu yaklaşımın uygunluğunu araştırmak için YSA'nın tahminleri aynı zamanda geleneksel çok değişkenli regresyon analizi ile de karşılaştırılmıştır. YSA ile ölçülen ve tahmin edilen maseraller arasındaki belirleme katsayısının çok değişkenli regresyon analizi ile tahminine göre oldukça yüksek olduğu ve ortalama mutlak yüzde hatasının çok olduğu bulunmuştur.

Chelgani vd. (2010), çok değişkenli regresyon ve yapay sinir ağı yöntemlerini kullanarak vitrinit maksimum yansıma (R_{max}) ve üst kalorifik değerlerini (ÜKD) tahmin etmek için Kentucky kömürlerinin elementel analiz, kısa ve petrografik analizlerinden elde edilen sonuçları kullanmışlardır. ÜKD ve R_{max} 'ı eşzamanlı olarak tahmin eden 2-5-

4–2 düzenlemeli YSA yönteminden elde edilen sonuçlar, bağımsız bir test veri seti için sırasıyla 0,84 ve 0,90 R^2 değerleri göstermiştir.

Erik ve Yılmaz (2010) kömürlerin üst kalorifik değerini (GCV) tahmin etmek için yapay sinir ağları ve uyarlanabilir nöro-bulanık çıkarım sistemi gibi bazı esnek hesaplama tekniklerinin kullanımı açıklamışlar ve çoklu regresyon geleneksel istatistiksel modeliyle karşılaştırmışlardır. Oluşturulan modellerinin GCV'yi tahmin etmek için yüksek performans gösterdiğini tespit etmişlerdir.

Yılmaz vd. (2010), kömürlerin üst kalorifik değerini (GCV) tahmini için çok katmanlı algılayıcı, radyal baz fonksiyonu ve hibrit türevlerini kullanarak yapay sinir ağlarının farklı öğrenme algoritmalarının kıyaslamışlardır. Tüm modeller GCV'yi tahmin etmede yüksek performans gösterdiğini göstermişlerdir. Çalışmada YSA'ların dört farklı algoritması neredeyse aynı tahmin yeteneğine sahip olsa da çok katmanlı algılayıcının doğruluğu diğer modellere göre nispeten daha yüksek olduğu sonucuna varmışlardır.

Onifade vd. (2021), kömürdeki organik ve inorganik bileşenlerin dağılımı ve bunların kömürün yanması üzerindeki etkilerini kapsamlı bir şekilde incelenmişlerdir. Bu çalışmada, Witbank kömür sahası örneklerinden elde edilen maseral ve toplam mineral madde miktarı, çok girişli tek çıkışlı white box yapay sinir ağı (MEA-YSA), gene ifade programı (GİP), çoklu doğrusal regresyon (ÇDR) ve çoklu doğrusal olmayan regresyon (ÇLR) kullanılarak tahmin edilmeye çalışılmıştır. MEA-YSA'ın, diğer üç modele göre en düşük fark ve en yüksek verimlilik ve bileşik istatistiksel göstergelerle daha güvenilir bir tahmin modeli sunduğu sonucuna varmışlardır.

Akkaya (2021) çalışmasında, kısa analiz verilerini kullanarak kömür elementel bileşenlerinin tahmini için yeni açık ve örtülü modeller geliştirilmiştir. Örtülü tabanlı YSA ve Rastgele Orman (Random Forest) modellerinin açık tabanlı Lineer olmayan regresyon modellerine göre daha iyi sonuçlar verebileceğini, YSA tabanlı modellerin ise karbon, hidrojen ve oksijen içerikleri için R^2 'nin sırasıyla 0,9915, 0,9151 ve 0,9817 olduğu en iyi tahmin performanslarına sahip olduğunu göstermiştir.

Jo vd. (2022) çalışmalarında girdi parametresi olarak kısa analiz değerlerini kullanan bir yapay sinir ağı kullanarak Güney Kore'deki kömürle çalışan elektrik santrallerinde kullanılan 104 termal kömürün elementel bileşimlerini tahmin etmeyi amaçlamışlardır. Sonuç olarak, kısa analiz değerinin elementlerin kompozisyonunu nasıl etkilediğini niteliksel olarak analiz etmişler, buna göre oran hesaplamışlar ve Güney Kore enerji santrallerinden elde edilen verilere dayanarak termal kömürün elementel bileşimini tahmin etmede gelişmiş ve etkili bir yaklaşım sunmuşlardır.

Büyükkanber (2022), Türkiye, Ukrayna, Rusya, Kolombiya, Güney Afrika, Finlandiya ve ABD'nin turba, linyit, taşkömürü, antrasit kömür numuneleri ile asfaltit, petrokok ve biyokütleden elde edilen yarı kok numunelerini kullanarak çoklu lineer regresyon, karar ağacı, random forest ve yapay sinir ağları yöntemleri ile üst ısı değerlerinin tahmini yapılmıştır. Random forest yönteminin tahmin performansını kontrol etmek için yapay sinir ağı, karar ağacı ve çoklu doğrusal regresyon yöntemleri de test edilmiş ve uyumlu sonuçlar bulmuştur.

Lawal vd. (2023), kömür külünün başlangıç deformasyon sıcaklığını, yumuşama

sıcaklığını, yarım küre sıcaklığını ve akışkan sıcaklığını tahmin etmek için farklı kömür sahalarından alınan kömür örneklerini kullanarak AFT tahmin modelleri geliştirmeyi amaçlamışlardır. Bunun için yapay sinir ağı (YSA), gauss süreç regresyonu (GSR) ve destek vektör regresyonu (SVR), bu modellemede kullanılan üç makine öğrenme aracını kullanmışlardır. Sonuç olarak, AFT tahmin modelleri, YSA modelinin Deformasyon sıcaklığı, yumuşama sıcaklığı, yarım küre sıcaklığı ve akışkan sıcaklığının GPR ve SVR göre daha yeterli ve güvenilir bir şekilde tahmin ettiğini tespit etmişlerdir.

Lawal vd. (2024) Güney Afrika'daki üç kömür sahasına ait kömürlerin nem, uçucu madde, kül içeriği, sabit karbon, toplam kükürt, kalorifik değer verileri kullanılarak Hardgrove Öğütülebilirlik İndeksi'ni (HGI) tahmin etmek için Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (SVR) ve Uzun Kısa Süreli Bellek (LSTM) modellerinin karşılaştırmalı bir analizini sunmaktadır. Çalışmanın bulgularına göre, ANN modelleri tüm kömür sahaları için en etkili tahmin performansını sergilemiş, SVR modelleri ikinci sırada yer almış ve LSTM modelleri en düşük performansı göstermiştir.

Yang vd. (2024) yirmi bir kömür numunesine ait parametrelere dayanarak, TG eğrisi algoritma ile optimize edilmiş bir sinir ağı modeli kullanmışlardır. Uçucu madde, nem, kül içeriği, sabit karbon, hidrojen içeriği, nitrojen içeriği ve kükürt içeriği parametreleri kullanılmıştır. Sonucunda farklı kömür türlerinin piroliz mekanizmalarının daha iyi anlaşılmasına katkıda bulunmuşlardır.

Wang vd. (2024) kömür damarı geçirgenliğini tahmin etmek için bir geri yayılım sinir ağını bütünleştiren bir hibrit sinir ağı tahmin modeli geliştirilmişlerdir. Modelin öğrenme hızını ve doğruluğunu artırmak için ek momentum ve değişken öğrenme hızı algoritmaları kullanılmış ve gizli katman düğümlerinin sayısı ve transfer fonksiyonu da dahil olmak üzere model yapısı optimize edilmiştir.

3. MATERYAL VE METOT

Türkiye linyit kömürlerinin YSA algoritması ile kısa ve elementel analizlerin öğrenme prosesinden geçirildikten sonra maseral dağılım tespitinin yapılmasını baz alan bu tez çalışması iki bölümden oluşmaktadır.

3.1. Bazı Türk Linyitlerinin Veri Seti

Veri setlerinin oluşturulabilmesi için Tuncalı vd. (2002)'nin hazırlamış oldukları Maden Tetkik Arama (MTA)'nın yayınladığı çalışmadan yararlanılmıştır. Tez bünyesinde veri setine uygun olan toplam 232 adet veri kullanılmıştır. Kullanılan veriler Çizelge 3.1 ve Çizelge 3.2'de sırasıyla eğitim ve test verileri minimum, maksimum ve ortalama değerleri alınarak paylaşılmış olup, veri seti EK-9'da verilmiştir. Taranan literatürde verilerin belirli bazlardaki özellikleri alınmış veri seti bu doğrultuda oluşturulmuştur. Ülkemizde geniş bir yayılıma ve çalışma alanına sahip linyit yatakları baz alınarak çok sayıda deneysel kömür verileri literatürden elde edilmiştir. Girdi verisi olarak kömürlerin C, H, O, N, S'den oluşan elementel analiz verileri, yanması sonucu açığa çıkan ısı miktarını ifade eden kalorifik değeri ve kül, uçucu madde, sabit karbon, nem değerlerinden oluşan kısa analiz verileri kullanılmıştır.

Kısa analiz nem içeriği, uçucu madde içeriği, kül içeriği ve sabit karbon gibi parametrelerden oluşur. İlk üç parametre laboratuvarında yapılan deneylerle belirlenir ve ardından sabit karbon aşağıdaki formül kullanılarak gravimetrik olarak hesaplanır.

$$\text{Sabit Karbon (C)} = 100 - \text{Nem} + \text{Uçucu Madde} + \text{Kül}$$

Kalorifik değer yukarıdaki değerlerde kullanılarak ayrıca ölçülür ve hesaplanır. Kömür kalitesinin genel bir değerlendirmesi, kısa analiz tarafından sağlanan verilere dayanarak yapılabilir. Kömürün elementel analizi karbon, hidrojen, oksijen, kükürt ve azot oranlarının tahminini içerir. Karbon, hidrojen, azot ve kükürt miktarı doğrudan belirlenir ve oksijen miktarı aşağıdaki formülle elde edilir.

$$\text{Oksijen (O)} = 100 - \text{Karbon} + \text{Hidrojen} + \text{Azot} + \text{Kükürt}$$

Kömürdeki maseral türlerini ve miktarlarını analiz etmek için genellikle ince kesitler yerine parlatılmış yüzeyler kullanılır. Bunun nedeni, kömürün ince kesitlerinin hazırlanmasının oldukça zor olmasıdır. Bu tür parlatılmış yüzeyler, yansıma mikroskobu kullanılarak incelenir. Yansıma mikroskobu genellikle opak örneklerin analizinde kullanılır ve kömür, mikroskop altında çoğunlukla gri tonlarında görünür. Kömürleşme derecesi, maserallerin mikroskobik görünümünü doğrudan etkiler. Kömür petrografisi, kömürün farklı fiziksel ve kimyasal özelliklere sahip maserallerden oluştuğu fikrine dayanır ve bu maserallerin varlığı, kömürün yanma ve dönüşüm süreçlerindeki davranışını belirler.

Morfoloji ve ışık altında yansıma, maseralleri ve maseral gruplarını mikroskop altında ayıran ana özelliklerdir. Maseraller görünümünün yanı sıra birçok farklı fiziksel ve kimyasal özelliğe de sahiptirler. Maserallerin özellikleri, kömürleşme derecesi veya olgunlaşmanın bir fonksiyonu olarak değişir. Yapılan çalışmada veri setleri maseral değerleri ile alınmıştır. Alınan veriler kıyaslama için kullanılmıştır. 232 adet veri için

sırasıyla 150 eğitim seti, 170 eğitim seti, 200 eğitim seti, 210 eğitim seti alınmış kalan veriler ise test amaçlı ayrılmıştır. Bir diğer yöntem olarak ise Python dili kullanılarak yapılan çalışmada Bayes optimizasyonu ile iki gizli katmanlı birinci ve ikinci gizli katmanların nöron sayıları 10 ile 200 arasında seçim yapılan hiper-parametre optimizasyon yöntemi kullanılmıştır. Bayes tarafından öğrenme oranı 10^{-5} ile 10^{-2} arasında, aktivasyon fonksiyonları ise ReLU, tanh, sigmoid arasından seçilmiştir. Optimizasyon fonksiyonları olarak ise ADAM, Rmsprop, SGD arasından seçim Bayes ile optimize edilmiştir.



Cizelge 3.1. Tez için kullanılan verilerin 150; 170; 200; 210 giriş verisi baz alındığında minimum maksimum ve ortalama değerleri

Giriş Verileri		Kısa (Proximate) Analiz				KD (kcal/kg)	Elementel (Ultimate) Analiz					Maseral Analizi (%)		
		M (%)	A (%)	VM (%)	SC (%)		C (%)	H (%)	N (%)	O (%)	S (%)	Hm	Lp	İn
		HKB	KB	KB	KB		KB	KKB	KKB	KKB	KKB			
150 Giriş Verisi	Min. Değer	1,2	6,6	18,8	4,4	1146,24	17,2	1,3	0,1	3,08	0,05	72,26	2,20	1,02
	Ort. Değer	7,69	27,91	36,06	35,95	4459,7	64,57	4,78	1,79	19,34	3,79	86,54	7,34	6,11
	Maks. Değer	15,37	71,1	49,61	52,4	6590,88	89,67	5,92	8,01	33,75	14,46	95,60	19,28	23,27
170 Giriş Verisi	Min. Değer	1,2	6,6	17,9	3,8	716,4	13,2	1	0,1	3,08	0,02	72,26	2,20	1,02
	Ort. Değer	7,65	28,47	36,06	35,41	4410,35	64,23	4,78	1,72	19,58	3,76	86,48	7,44	6,09
	Maks. Değer	15,37	76,3	49,61	52,4	6590,88	89,67	5,92	8,01	34,93	25,95	95,60	19,28	23,27
200 Giriş Verisi	Min. Değer	1,2	6,6	17,9	0,32	716,4	13,2	1	0,1	3,08	0,02	69,8	2,20	0,6
	Ort. Değer	8,84	27,55	38,66	33,79	4440,9	64,04	5,09	1,74	19,99	4,09	86,21	7,90	5,89
	Maks. Değer	24,15	76,3	74,75	52,4	6590,88	89,67	10	8,01	34,93	25,95	95,60	22,8	23,27
210 Giriş Verisi	Min. Değer	1,2	6,6	17,9	0,32	716,4	13,2	1	0,1	3,08	0,02	69,8	2,20	0,6
	Ort. Değer	8,73	27,70	38,49	33,82	4427,89	64,16	5,09	1,74	20,11	4,09	86,20	7,86	5,94
	Maks. Değer	24,15	76,3	74,75	52,4	6590,88	89,67	10	8,01	34,93	25,95	95,60	22,8	23,27

*M: Nem, A: Kül, VM: Uçucu Madde, SC: Sabit Karbon, KD: Kalorifik Değer, C: Karbon, H: Hidrojen, O: Oksijen, N: Azot, S: Kükürt
 *HKB: Havada Kuru Baz, KB: Kuru Baz, KKB: Kuru Külsüz Baz
 *Hm: Hüminit, Lp: Liptinit, İn: İntertinit
 **Kısa analiz verileri ağırlıkça yüzde olarak; elementel analiz verileri ise hacimce yüzde olarak hesaplanmıştır

Çizelge 3.2. Tez için kullanılan verilerin 82; 62; 32; 22 test verisi baz alındığında minimum maksimum ve ortalama değerleri

Test Verileri		Kısa (Proximate) Analiz				KD (Kcal/kg)	Elementel (Ultimate) Analiz					Maseral Analizi (%)		
		M (%)	A (%)	VM (%)	SC (%)		C (%)	H (%)	N (%)	O (%)	S (%)	Hm	Lp	İn
		HKB	KB	KB	KB	KB	KKB	KKB	KKB	KKB	KKB			
82 Test Verisi	Min. Değer	0,66	6,12	17,9	0,32	716,4	13,2	1	0,32	4,53	0,02	69,05	2,60	0,6
	Ort. Değer	10,49	27,48	43,22	29,48	4328,56	64,31	5,60	1,62	22,26	4,40	84,69	8,85	6,46
	Maks. Değer	24,15	76,3	74,75	51,82	6343	83,48	10	3,6	36,39	25,95	94,81	22,8	21,43
62 Test Verisi	Min. Değer	0,66	6,12	23,43	0,32	1777	52,88	3,96	0,32	4,53	0,08	69,05	2,60	0,6
	Ort. Değer	11,45	25,87	45,51	28,85	4413,13	65,12	5,86	1,76	22,60	4,66	84,21	9,11	6,684
	Maks. Değer	24,15	58	74,75	51,82	6343	83,48	10	3,6	36,39	11,38	94,81	22,8	21,43
32 Test Verisi	Min. Değer	0,66	6,12	23,43	13,99	1777	52,88	3,96	0,32	4,53	0,08	69,05	2,60	2,60
	Ort. Değer	7,71	28,56	38,56	32,97	4288,21	67,28	4,96	1,68	22,47	3,61	83,88	7,69	8,43
	Maks. Değer	13,92	58	51,08	51,82	6343	83,48	6,06	3,6	36,39	11,38	94,81	11,29	21,43
22 Test Verisi	Min. Değer	0,66	6,12	28,01	13,99	1777	52,88	3,96	0,32	4,53	0,08	69,05	3,61	4,49
	Ort. Değer	8,2	33,39	41,92	24,69	3587	62,78	5,41	1,54	27,87	2,4	88,31	3,90	7,79
	Maks. Değer	13,92	58	47,52	51,82	6343	83,48	6,06	2,83	36,39	11,38	89,41	11,29	21,43

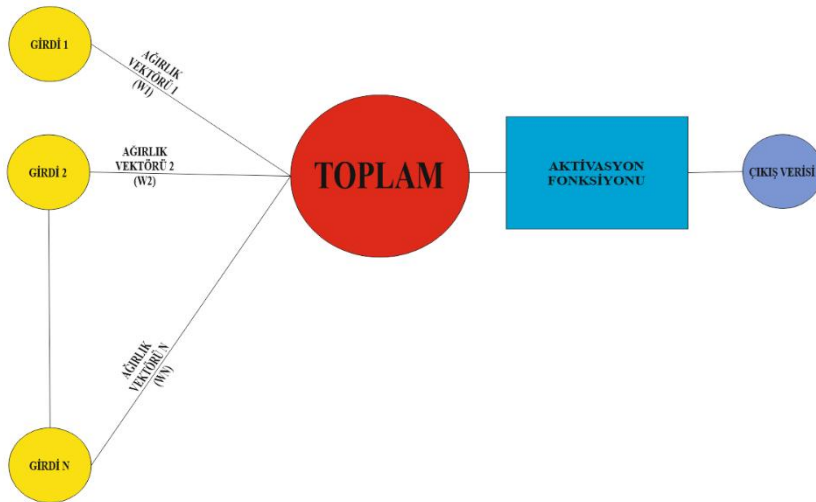
*M: Nem, A: Kül, VM: Uçucu Madde, SC: Sabit Karbon, KD: Kalorifik Değer, C: Karbon, H: Hidrojen, O: Oksijen, N: Azot, S: Kükürt
 *HKB: Havada Kuru Baz, KB: Kuru Baz, KKB: Kuru Külsüz Baz
 *Hm: Hüminit, Lp: Liptinit, İn: İnertinit
 **Kısa analiz verileri ağırlıkça yüzde olarak; elementel analiz verileri ise hacimce yüzde olarak hesaplanmıştır

3.2.Yapay Sinir Ağı Çalışması

YSA insan beyninin çalışmasından esinlenerek geliştirilmiştir. YSA' nın temel çalışma yapısı beynindeki sinir hücrelerinin çalışma yapısını taklit etme prensibine dayanır (Basheer ve Hajmeer 2000; Graupe 2007). Çeşitli işlem birimlerini kapsamlı bir şekilde birbirine bağlayarak gerçekleştirilen karmaşık bir ağ ile çalışma, ezberleme, muhakeme etme ve depolama gibi süreçlerde bir insan beyninin çalışma şeklini taklit etmeye çalışır. Bu taklit edilen yapının bilgisayar sistemlerine uygulanabilirliği sonucunda veri işleme uygulamalarında yaygın olarak kullanılmaktadır. YSA kendisine verilen örnekleri kullanarak öğrenme işlemi gerçekleştirmektedir (Khatip ve Elmenreich 2016; Basheer ve Hajmeer 2000).

Bu çalışmada maseral tahmini için kullanılan YSA modeli, ileri yönlü çok katmanlı algılayıcı (İYÇK) ağ yapısı ve Fahlman ve Lebiere'nin 1990 yılında geliştirdiği "Kaskad Korelasyon" mimarisine sahip YSA modeli (Fahlman ve Lebiere 1990) kullanılarak tasarlanmıştır. Matlab istatistik programı kullanılarak analizi yapılan iki ağ yapısı 232 adet veri için sırasıyla 150 eğitim seti (ax), 170 eğitim seti (bx), 200 eğitim seti (cx), 210 eğitim seti (dx) alınmış kalan veriler ise test amaçlı ayrılmıştır. Sırasıyla ax için 10, 20, 30 ve 40; bx için 10, 20, 30 ve 40; cx için 10, 20, 30 ve 40; dx için ise 10, 20 ve 30 gizli katman kullanılarak test edilmiş elde edilen sonuçlar karşılaştırılmıştır.

YSA'yı oluşturan yapay sinir hücrelerinin (nöronların) genel yapısı; girdiler (G), ağırlıklar (w_x), toplam (birleştirme) fonksiyonu, aktivasyon (transfer) fonksiyonu ve çıkış (tahmin parametresi) olmak üzere beş ana bileşenden oluşur (Şekil 3.1). Her bir girdi kendi ağırlık fonksiyonu ile çarpılarak toplanır. Elde edilen toplam sonucu oluşturmak için aktivasyon fonksiyonu ile işleme tabi tutulur ve çıkış değeri alınır.




Şekil 3.1. İleri yönlü YSA'nın beş katmanlı nöronu

Hiper-parametre yöntemi için ise Kaggle platformu üzerinde Python programlama dili kullanarak işlemler gerçekleştirilmiştir. Önce Bayes optimizasyonu uygulanarak 5 temel hiper-parametrenin optimizasyonu için seçim gerçekleştirilmiş, ardından optimize edilmiş ağ ile eğitim yapılmıştır. Veri sayısının az olmasından dolayı %80 eğitim seti için %20 test seti seçilerek uygulanmıştır.

3.2.1. İleri yönlü çok katmanlı algılayıcı

Tez kapsamında giriş verileri olarak kısa ve elementel analizler kullanılmıştır. Şekil 3.2 de gösterildiği gibi giriş verileri olarak kömürün hacmen yüzdesel kısa analiz verileri, elementel analiz verileri, kalorifik değeri baz alınmaktadır. Çıkış verisi olarak ise hüminit, liptinit ve inertinit değer tahminleri yer almaktadır.



Şekil 3.2. Tez kapsamında on giriş parametresine üç çıkış uzantılı İYKÇ ağ yapısı

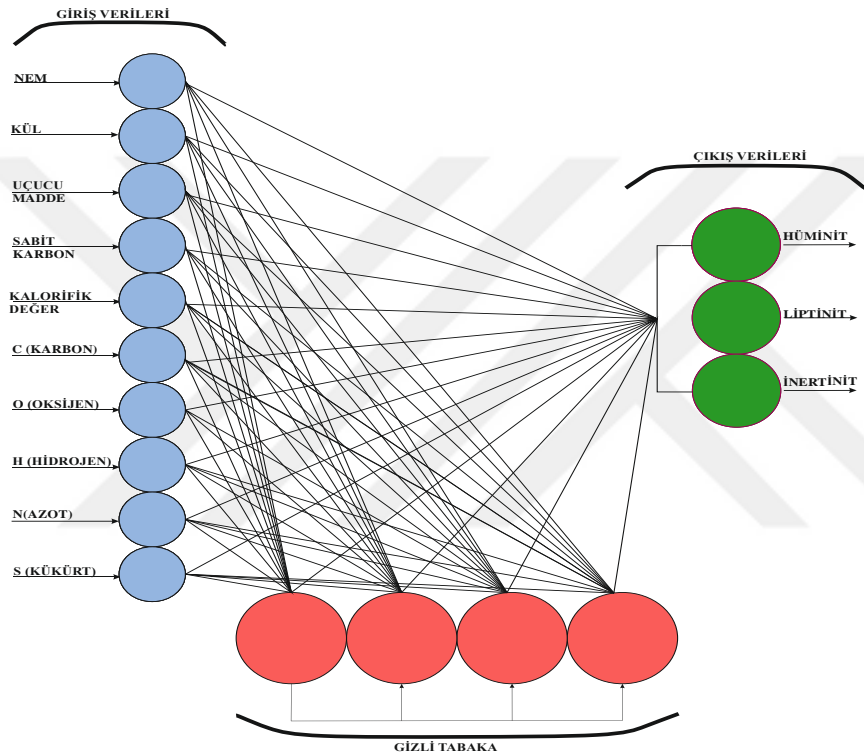
Giriş ve çıkış verileri dışında aktive edecek bir fonksiyona ve öğrenme algoritması gereklidir. Aktivasyon fonksiyonu olarak Levenberg-Marquardt YSA algoritmasından “Lojistik Sigmoid Fonksiyonu” seçilmiştir. Levenberg-Marquardt YSA algoritmasında az sayıda parametre ile minimum hata oranı elde edilebildiğinden sıklıkla kullanılan öğrenme algoritmalarındandır (Kızrak 2019). Lojistik sigmoid fonksiyonu ise yapay sinir ağlarında aktivasyon fonksiyonu olarak yer almaktadır. “S” şeklinde bir eğri oluşturur ve bu eğri 0 ile 1 arasında olasılık değerleri sunar (Kızrak 2019). Verilerin olasılık değerlerini belirleme yeteneği, özellikle lojistik regresyon analizlerinde önemli bir rol oynamaktadır. Ayrıca, fonksiyonun aidiyeti ve şeklinin öğrenme aşamasında adaptif değişiklikler yapabilmesi, çağdaş veri analizi tekniklerinde kritik bir unsur haline gelmiştir. Nöronlar için transfer fonksiyonu denklem 3.1’deki gibi lojistik sigmoid fonksiyon ($f(z_i)$) olarak ifade edilebilir. Denklem 3.2 ifadesinde; z_i girişlerin toplam ağırlığını ifade etmektedir. x_j ifadesi j. nöronun direkt olarak gelen sinyaldir. w_{ij} j. nöronun i. nörona direkt olarak bağlanan ağırlıkları tanımlamaktadır (Graupe 2007).

$$f(z_i) = \frac{1}{1+e^{-z_i}} \quad (3.1)$$

$$z_i = \sum_{j=1}^n w_{i,j}x_j + \beta_i \quad (3.2)$$

3.2.2. Kaskad ileri yönlü algılayıcı ağı (KIYA)

Kaskad korelasyon mimarisine sahip YSA modeli Fahlman ve Lebiere tarafından geliştirilmiştir (Fahlman ve Lebiere 1990). Bu mimari yapının iki temel avantajı vardır. İlk olarak, bu mimari yapısında çok sayıda test verisinin olmasına gerek yoktur. İkinci olarak da çok katmanlı karmaşık problemlerin çözümünde ve yorumlanmasında oldukça yetenekli ve hızlıdır. On giriş, dört ara katman ve üç çıkışa sahip Kaskad ileri yönlü algılayıcı YSA modeli Şekil 3.3'te sunulmuştur. Bu yapıda eşik fonksiyonu, transfer fonksiyonu olarak kullanılır ve çıkışlar ikili kod sistemine uygun olarak sınıflandırma ile belirlenir. YSA çıkışı (3.3) denklemi ile tanımlanır (Abid ve Hamami 2018).



Şekil 3.3. Tez kapsamında on giriş parametresine üç çıkış uzantılı KIYA ağı yapısı

$$y_j = \theta \left\{ \sum_{i=0}^n w_i^0 \cdot x_{ij} + \min[m, 1] \left[\sum_{k=1}^m w_{n+k}^0 \cdot \theta \left(\sum_{i=0}^{n+k-1} w_i^k \cdot x_{ij} \right) \right] \right\} \quad (3.3)$$

Yapay sinir ağları otomatik korelasyon, çok değişkenli regresyon, doğrusal regresyon, trigonometrik ve diğer istatistiksel analiz tekniklerinin yerine doğrudan kullanılabilir. Veriler bir sinir ağı kullanılarak analiz edildiğinde, daha önce uzman olmayan birinin göremediği önemli öngörü kalıplarını tespit etmek mümkün oluyor.

Böylece sinir ağı bir uzman gibi hareket edebilir. Kömür kalitesi kömürleşme derecesi, organik petrografi ve inorganik jeokimya olmak üzere üç temel bağımsız faktörün bir fonksiyonudur. Daha sonra kömürün kalitesi, her biri diğer temel

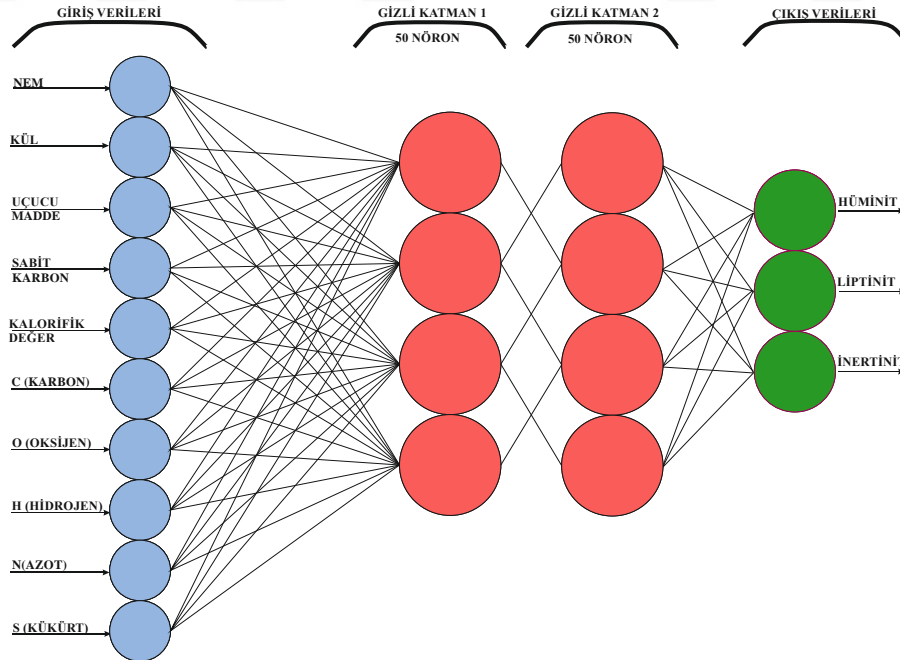
parametrelerin her birinden büyük ölçüde bağımsız olan bir dizi parametre ile aşağıda belirtilen şekilde ifade edilmiştir.

3.2.3. Bayes hiper-parametre optimizasyon yöntemi (BO)

Bayes optimizasyonu (BO) zorlu, değerlendirilmesi pahalı hedeflerin örnek açısından verimli optimizasyonu için özellikle uygun olan yinelemeli, model tabanlı bir optimizasyon algoritmasıdır (Yu ve Zhu 2020). Özellikle yüksek maliyetli fonksiyonları optimize etmek için kullanılan bir yöntemdir. Genellikle, makine öğrenimi modellerinin hiper-parametrelerini ayarlamak üzere uygulanan yöntemlerden biridir. Bu yöntem, önceki denemelerin sonuçlarından yararlanarak daha akıllı tahminler yapar ve böylece daha az deneme ile daha iyi sonuçlar elde edilmesini sağlar. Hiper-parametre arama alanının dağılımına dayalı olarak daha akıllıca seçimler yapar. Yapılan denemelerden elde edilen bilgiler ile sonraki denemeleri optimize ederek en iyi sonuçları sunmayı hedefler. Gauss teoremi Bayes optimizasyonunun (Denklemler 3.4) belkemiğidir (Yu ve Zhu 2020). Bu süreçler, bilinmeyen bir fonksiyonun dağılımını tahmin etmek için kullanılır (Yperman ve Becker 2016).

$$P(A|B) = P(B|A) * \frac{P(A)}{P(B)} \quad (3.4)$$

Bu denklemde (3.4), $P(A)$ koşullu bir olasılık olmak üzere A için marjinal olasılık adı verilir. Çünkü B olayı hakkında önceden herhangi bir bilgiyi içermemektedir. $P(A|B)$ terimi verilmiş B için A 'nın koşullu olasılığıdır. $P(B|A)$ terimi verilmiş A için B 'nin koşullu olasılığıdır. $P(B)$ normalleştirme sabitidir. $P(A|B)$ ifadesi zincir olasılık kuralı kullanılarak ifade edilir (Nadiroğlu 2022).



Şekil 3.4. Tez kapsamında on giriş parametresi, iki gizli katman ve üç çıkış uzantılı BO ağ yapısı

Süreç sırasında, bir optimizasyon kriteri karşılanana kadar tekrarlanır. BO'nun ek bir yararı, optimizasyon süreci sırasında oluşturulan ve eğitilen modelin optimizasyon bağlamı dışında da kullanılabilmesidir. Model hızlandırıcı parametrelerine yönelik nesnel fonksiyon hassasiyetleri hakkında bilgi sağlayabilir, hızlandırıcının diğer modellerine hızlı yürütülen bir vekil olarak entegre edilebilir veya eleman hizalama hataları gibi ışın hattının bilinmeyen parametrelerini tanımlamak için kullanılabilir (Ülker 2017). Bayes optimizasyonu örnekleme sürecinin bir sonucu olarak, bu modeller genellikle parametre uzayının en yüksek ilgi gören bölgelerinde, yani optimum parametre kümelerine yakın parametre uzayı bölgelerinde en doğrudur (Nadiroğlu 2022).

Bu tez kapsamında yapılan çalışmada hiper-parametre optimizasyon yöntemi Kaggle platformu üzerinden Python program dili kullanılarak gerçekleştirilmiştir. Matlab programında kullanılan 232 adet veri işlenmiştir. Veri sayısının ilgili hesaplama için az sayıda olması sebebiyle %80 eğitim verisi kullanılırken %20 test verisi olarak ayrılmıştır. Bu ağ yapısında Bayes optimizasyonu ile bunların en iyi kombinasyonunu bulup iki gizli katmanlı bir ağdan oluşan birim yapısı oluşturulmuştur. Ardından tüm veriyi bu optimize ettiğimiz ağ ile eğitip sonuç alınmıştır. Yapılan çalışmada Bayes optimizasyonu ile birinci ve ikinci gizli katmanların nöron sayıları 10 ile 200 arasında seçim yapılmıştır. Öğrenme oranı 10^{-5} ile 10^{-2} arasında seçilirken, aktivasyon fonksiyonları relu, tanh, sigmoid arasından seçilmiştir. Optimizasyon fonksiyonları olarak ise ADAM, Rmsprop, SGD arasından Bayes tarafından en uygun olanı seçilmiştir.

Giriş verileri için ölçeklendirme yapılırken “Standard Skaler” yöntemi kullanılmıştır. Bu ölçeklendirme yöntemi, veri setindeki her bir öznitelik değerini ortalamayı sıfır ve standart sapmayı bir olacak şekilde yeniden ölçeklendiren bir ön seçim tekniğidir. Bu işlem, öğrenme algoritmalarının daha etkili çalışmasını sağlayarak veri setindeki farklı ölçeklerin etkisini azaltır (Bishop ve Nasrabadi 2006). Aynı zamanda, standardizasyon süreci, ortalama değerini 0, standart sapmanın ise 1 olmasını hedefler ve bu sayede verilerin dağılımını normale yakınlaştırır. Standard Skaler, her bir öznitelik değerini ölçeklendirmek için kullanılır. İşlem sonucunda, verilerin ortalaması 0, standart sapması ise 1 olur. Bu teknik, farklı ölçeklerdeki özniteliklerin etkisini minimize ederek öğrenme algoritmalarının performansını artırır (Bishop ve Nasrabadi 2006). Aykırı değerlere karşı duyarlıdır ve bu durum verilerin doğru bir şekilde işlenmesini engelleyebilir. Standardizasyon, verilerin normal dağılıma daha yakın bir hale gelmesini sağlar. Her bir değer için ortalama ve standart sapmaya göre normalize edilmesini içerir. Bu yöntem, özellikle makine öğrenmesi uygulamalarında yaygın olarak kullanılmaktadır (Bishop ve Nasrabadi 2006). Çıkış parametreleri için ise “Min-Max Normalizasyonu” yöntemi kullanılmıştır. Bu yöntem, farklı aralıklarda ifade edilen verileri 0 ile 1 arasında dönüştürerek standartlaştırır. Normalizasyon işlemi, verilerin minimum ve maksimum değerlerine dayanarak gerçekleştirilir; böylece tüm veriler belirli bir ölçek içine yerleştirilir. Bu yöntem, özellikle makine öğrenimi modellerinde daha iyi performans sağlamak için önemlidir (Adeyemo vd. 2018).

3.2.4. Hata ve kontrol yöntemleri

Algoritma tanımlama ve eğitim tamamlandıktan sonra hata kontrol ve verimlilik aşamasına geçiş yapılabilir. Çalışma kapsamında kullanılan hata kontrol yöntemleri aşağıda belirtildiği gibidir.

Ortalama Kare Hatası (OKH), bir modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplayan bir hata ölçüsüdür. OKH, modelin performansını değerlendirmede sıkça kullanılır; daha düşük OKH değerleri, modelin daha iyi bir tahmin yaptığı anlamına gelir. OKH formülü denklem 3.5'te gösterildiği gibidir (Hodson 2022).

$$\text{Ortalama Kare Hatası} = \frac{\sum_{t=1}^n (u)^2}{n} \quad (3.5)$$

Ortalama Mutlak Hata (OMH), bir veri setindeki gerçek değerler ile tahmin edilen değerler arasındaki mutlak hata değerlerinin ortalamasını hesaplayan bir istatistiksel ölçüttür. OMH, hata terimlerinin toplamının, veri setinin eleman sayısına bölünmesiyle elde edilir. Bu ölçüm, tahmin doğruluğunu değerlendirmek için sıkça kullanılır. OMH, eşleştirilmiş gözlemler arasındaki hataları ölçen bir istatistik terimidir. Bu kavram, gözlemlenen değerler ile tahmin edilen değerler arasındaki farkları değerlendirirken kullanılır. Ortalama mutlak hata, istatistiksel analizlerde sıkça kullanılmakta ve veri analizi süreçlerinde önemli bir rol oynamaktadır. OMH formülü denklem 3.6'te gösterildiği gibidir (Chai ve Draxier 2014).

$$\text{Hatanın Mutlak Ortalaması} = \frac{\sum_{t=1}^n |u|_t}{n} \quad (3.6)$$

Ortalama Kare Hatası karekökü (OKHK), bir modelin tahminleri ile gerçek değerler arasındaki hatanın ölçümüdür. OKHK, ortalama kare hatası değerinin karekökünün alınmasıyla hesaplanır ve genellikle model performansını değerlendirmek için kullanılır. OKHK, OKH'dan daha fazla tercih edilir çünkü sonuçları daha anlamlı ve karşılaştırılabilir hâle getirir. Hedef değer ile aynı birimde ölçülür ve tahminlerin doğruluğunu değerlendirmek için yaygın bir metrik olarak kabul edilir. OKHK 'nın düşüklüğü, modelin tahmin gücünün yüksek olduğunu gösterir. Hata kareleri ortalamasının karekökü, modelin genel hata oranını değerlendirirken kullanılır. OKHK formülü denklem 3.7'da gösterildiği gibidir (Hodson 2022).

$$\text{Ortalama Kare Hatası Karekökü} = \sqrt{\frac{\sum_{t=1}^n (u)^2}{n}} \quad (3.7)$$

Ortalama Mutlak Yüzde Hata (OMYH), tahmin doğruluğunun ölçülmesi için kullanılır ve gözlemlenen veri ile modelin belirlediği değerler arasındaki ilişkiyi yansıtır. OMYH, tahminin ne kadar uzakta olduğunu yüzde olarak ifade etmesi sayesinde, farklı makine öğrenmesi uygulamalarında yaygın olarak kullanılır. Ayrıca, yüksek ve düşük değerleri tahmin doğruluğu üzerindeki etkilerini anlamak için dikkate alınması gereken önemli bir metriktir. Gözlemlenen veri değerleriyle modelin tahminleri arasındaki farkı yüzde formunda sunar. OMYH formülü denklem 3.8'da gösterildiği gibidir (Hodson 2022).

$$\text{Ortalama Mutlak Yüzde Hata} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (3.8)$$

R-kare (R^2), istatistiksel analizde kullanılan bir ölçüdür ve genellikle regresyon modellerinin başarısını değerlendirmek için kullanılır. Bir regresyon modelinin bağımsız değişkenin (x) bağımlı değişken (y) üzerindeki etkinin ne kadar uygun olduğunu anlatır. Veri sayısı ise “ n ” olarak denklem 3.9’da verilmiştir. R-kare değeri 0 ile 1 arasında değişir; 1’e çok yakın bir değer, modelin verileri çok iyi açıkladığını gösterirken, 0’a yakın bir değer uyumun oldukça zayıf olduğunu belirtir. R-kare, tahmin hatalarının ne kadarını ortadan kaldırdığını ifade eder (Hodson 2022).

$$R - \text{Kare} = \left(\frac{(n\sum xy - (\sum x)(\sum y))}{\sqrt{n\sum x^2 - (\sum x)^2} * \sqrt{n\sum y^2 - (\sum y)^2}} \right)^2 \quad (3.9)$$

4. BULGULAR VE TARTIŞMA

Bu çalışmada, YSA algoritmaları ve optimizasyon teknikleri ile Türkiye linyit kömürlerinin maseral dağılımlarının kısa ve elementel analizler ile istatistiksel olarak tahmin edilebileceğini göstermek amaçlanmıştır. Hüminit, liptinit ve inertinit tahmini için oluşturulan, çalışmaya uygun bazda 232 adet veri kullanılmıştır. Bu veriler istatistiksel programlar yardımıyla işlenmiş bulgular aşağıda belirtilmiştir

4.1. Yapay Sinir Ağları ile Maseral Dağılım Tahmini

Matlab Programı yardımıyla İYÇK ve KİYA ağ algoritmaları 210, 200, 170, 150 eğitim verisi olacak şekilde dörder farklı set hazırlanmıştır. Bu setler Çizelge 4.1-4.2’de belirtildiği üzere farklı gizli katmanlar üzerinde denenmiş YSA alt teknikleri kullanılarak eğitilmiştir. Eğitim fonksiyonu olarak, her iki ağ yapısında da Levenberg-Marquardt Fonksiyonu, aktivasyon fonksiyonu olarak da Sigmoid Fonksiyonu seçilmiştir. Sinir ağının eğitimi için on giriş parametresine üç çıkış parametresi olacak şekilde, her parametre seti için gizli katman miktarı değiştirilerek doğruluk oranları arasındaki oransal farklar tespit edilmeye çalışılmıştır. Hata tespit ve karşılaştırma parametreleri OKH, OMH, OKHK, OMYH olarak seçilmiştir. İYÇK algoritması hata verileri Çizelge 4.1’de incelendiğinde en iyi sonucu 200 eğitim seti üzerinden 20 gizli katmanın olduğu veri olduğu görülmektedir. Benzer şekilde KİYA algoritması Çizelge 4.2’de görüldüğü üzere 150 eğitim seti üzerinden 10 gizli katmanın en iyi sonuçları verdiği görülmektedir.

Çizelge 4.1. İYÇK ağ yapısına uygun olarak çalışılan setlerin hata oranları

İYÇK		MHO			OKH			OKHK			OMY			
					Matlab Ortalama	Hesaplanan								
		Hm	Lp	İn		Hm	Lp	İn	Hm	Lp	İn	Hm	Lp	İn
150 E. V.	10 G.K.	5,45	2,75	3,84	~7	54,7	13,2	27,5	7,4	3,6	5,2	6,5	35,8	115,0
	20 G.K.	5,83	3,16	5,08	~20	57,0	15,7	40,5	7,5	4,0	6,4	7,1	43,9	98,2
	30 G.K.	9,88	4,83	3,71	~15	254,3	73,3	26,2	15,9	8,6	5,1	12,0	51,2	87,9
	40 G.K.	8,23	4,83	4,95	~40	121,8	45,0	41,4	11,0	6,7	6,4	9,7	66,4	143,0
170 E. V.	10 G.K.	4,6	3,11	2,58	~8	40,0	17,0	12,9	6,3	4,1	3,6	2,2	19,4	14,5
	20 G.K.	4,17	2,92	3,15	~6	30,4	15,2	16,8	5,5	3,9	4,1	2,3	19,5	17,0
	30 G.K.	8,52	3,58	6,88	~15	170,3	23,7	114,4	13,1	4,9	10,7	2,7	21,3	21,3
	40 G.K.	10,07	5,74	3,76	~20	220,5	71,5	25,9	14,8	8,5	5,1	2,7	24,8	16,6
200 E. V.	10 G.K.	4,17	2,06	2,64	~6	30,6	6,7	15,0	5,5	2,6	3,9	5,1	37,3	32,0
	20 G.K.	3,46	2,11	2,45	~10	24,1	7,0	12,6	4,9	2,6	3,6	4,3	38,1	28,3
	30 G.K.	5,22	2,80	4,47	~35	47,3	12,4	35,7	6,9	3,5	6,0	6,5	50,6	47,4
	40 G.K.	7,04	5,15	3,9	~35	94,7	40,3	31,7	9,7	6,3	5,6	8,5	76,8	49,4
210 E. V.	10 G.K.	3,62	2,3	3,08	~20	25,7	8,9	19,3	5,1	3,0	4,4	4,6	38,7	35,9
	20 G.K.	4,3	2,3	2,84	~10	31,2	7,9	17,6	5,6	2,8	4,2	5,4	38,2	27,6
	30 G.K.	6,63	4,37	3,05	~50	73,1	28,4	15,5	8,6	5,3	3,9	8,2	68,4	40,4

Yapılan çalışmada KİYA ve İYÇK gizli katmanların artırılmasının hata verilerinin yükselmesine sebebiyet verdiği görülmektedir. Yüksek gizli katmanın eğitim


setine pozitif katkı yapmadığı; benzer şekilde çok düşük olmasının da her sette iyi olmadığı Çizelge 4.1 ve 4.2’de görülmektedir. Onifade vd. (2021)’nin yaptıkları bir çalışmada 63 bitümlü kömür örneği için %70 oranında eğitim seti ayırmışlar ve başarılı sonuçlar elde etmişlerdir. Çalışma bünyesinde de en iyi sonuçları KİYA’da %65 eğitim seti (150 eğitim verisi) ve on gizli katman ile alındığı görülmektedir. Fakat İYÇK ağ yapısında %80 eğitim setinin (200 eğitim verisi) daha uygun olduğu görülmüştür. Akkaya (2021) ise çalışmasında 6277 kömür örneği üzerinde %85 oranında eğitim seti (5277 eğitim verisi) kullanmayı tercih etmiş, çalışma sonuçlarının ise Onifade vd. (2021)’nin yaptığı ile bu çalışmadaki optimizasyon değerlerinin altında kaldığı R-Kare sonuçlarında görülmüştür. Eğitim verisinin sayısının gizli katmanla paralellik göstermediği görülmektedir. Set doğruluğu deneme yanılma yoluyla en doğru tercihin hangisi olduğunu göstereceği görülmüştür. 150 veri seri altına inildiğinde sonuçların oldukça kötü olduğu görüldüğü için alt sınır; 210 veri seti ise benzer sebeple üst sınır olarak kabul edilmiştir. Gizli katmandaki nöronlar yine benzer şekilde pik nokta sınır alınarak seçilmiştir.

Çizelge 4.2. KİYA ağ yapısına uygun olarak çalışılan setlerin hata oranları

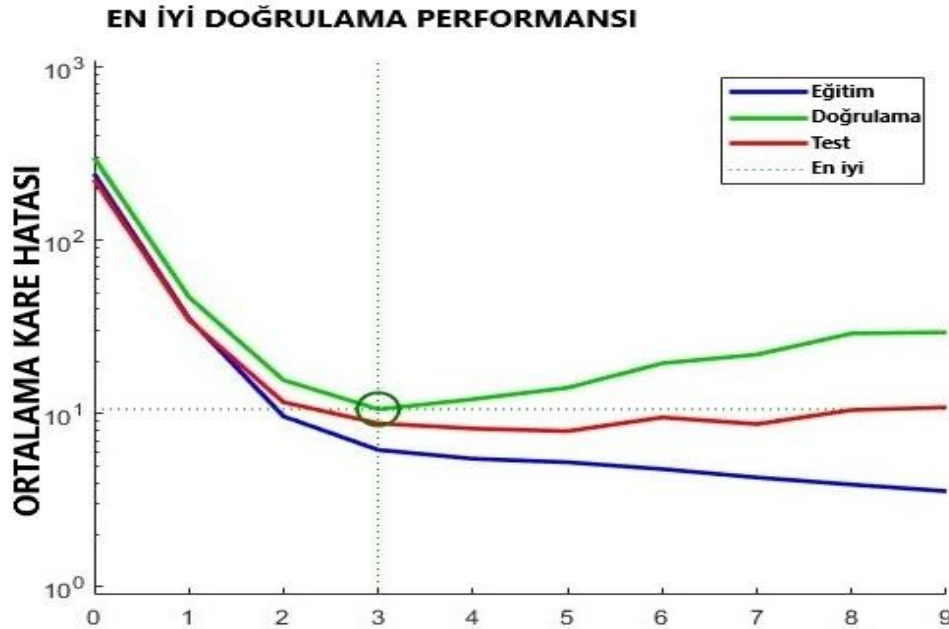
KİYA		MHO			OKH				OKHK			OMY		
		Hm	Lp	In	Matlab Ortalama	Hesaplanan			Hm	Lp	In	Hm	Lp	In
						Hm	Lp	In						
150 E. V.	10 G.K.	4,4	2,2	3,3	~12	34,9	7,3	21,2	5,9	2,7	4,6	5,5	31,1	32,8
	20 G.K.	4,6	2,6	2,8	~12	38,7	9,8	17,6	6,2	3,1	4,2	5,8	38,9	25,0
	30 G.K.	7,2	4,9	6,9	~55	33,8	6,6	20,8	5,8	2,6	4,6	4,4	27,3	25,7
	40 G.K.	4,4	2,8	2,5	~50	29,9	10,8	12,7	5,5	3,3	3,6	5,4	46,4	29,8
170 E. V.	10 G.K.	4,8	2,9	2,9	~11	41,7	14,1	17,8	6,5	3,8	4,2	5,9	47,5	33,8
	20 G.K.	4,9	3,0	3,2	~18	44,1	12,6	18,6	6,6	3,5	4,3	6,1	50,0	36,0
	30 G.K.	4,5	2,7	3,5	~18	36,2	12,6	22,0	6,0	3,6	4,7	5,5	52,9	39,2
	40 G.K.	6,0	4,5	3,2	~15	62,6	39,9	21,4	7,9	6,3	4,6	3,0	23,7	17,3
200 E. V.	10 G.K.	5,9	4,5	8,4	~19	60,0	45,8	170,3	7,7	6,8	13,1	3,1	22,8	19,9
	20 G.K.	5,0	4,8	2,6	~19	45,4	51,8	12,7	6,7	7,2	3,6	2,5	23,4	15,3
	30 G.K.	8,7	5,1	8,1	~19	148,9	66,9	164,3	12,2	8,2	12,8	3,1	21,2	21,2
	40 G.K.	5,0	3,3	3,7	~20	45,4	20,9	30,9	6,7	4,6	5,6	6,1	44,4	96,7
210 E. V.	10 G.K.	8,0	5,7	5,0	~9	148,9	81,9	45,1	12,2	9,0	6,7	9,4	68,3	150,0
	20 G.K.	9,3	5,5	5,6	~20	144,5	56,2	50,5	12,0	7,5	7,1	11,0	63,6	144,2
	30 G.K.	9,6	5,5	5,3	~15	155,2	53,6	54,0	12,5	7,3	7,3	11,3	70,4	154,2

İki algoritmanın benzer koşullarda en iyi sonucu veren yapısının İYÇK olduğu görülmüştür. İlgili yapının Matlab üzerinden işlenen hata, regresyon ve doğrulama değer grafikleri Şekil 4.1-4.3’te verilmiştir. Şekil 4.1’de 32 adet tahmin verisinin aynı sayıda test verisi ile hüminit, liptinit ve inertinit çıkış verilerinin kıyaslandığı grafikler gösterilmiştir. Şekil 4.2’de aynı veri seti için ortalama kare hatasının Matlab programında verdiği en iyi sonucu gösterdiği grafik işlenmiştir. Şekilde “x” koordinat düzleminde 9 adet döngüden 3. döngüde en iyi sonucu verdiğini göstermektedir. Şekil 4.3’te gösterilen

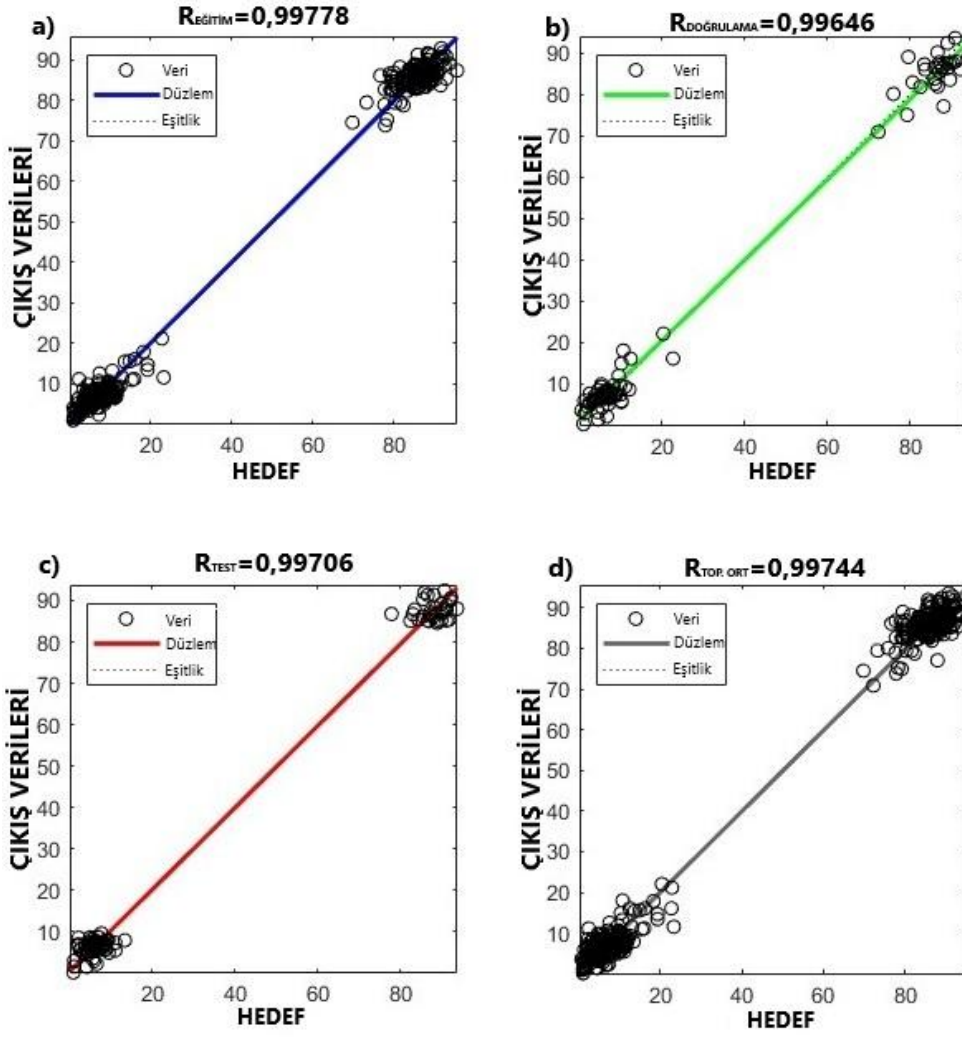
verilerde regresyon değerleri $R_e=\%99,7$ $R_v=\%99,6$ $R_t=\%99,7$ olduğu görülmekte buna istinaden eğitim ve test verisinin uyumlu olduğu söylenebilmektedir.



Şekil 4.1. İleri yönlü çok katmanlı algılayıcıda 200 eğitim verisi ve 20 gizli katman için 32 test verisinin 32 tahmin verisi ile kıyaslandığı grafik



Şekil 4.2. 200 eğitim verisi ve 20 gizli katman için ortalama kare hatasının en iyi sonucu verdiği noktanın grafiği



Şekil 4.3. 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. $R_{EĞİTİM}$ (a): Eğitim regresyon grafiği; $R_{DOĞRULAMA}$ (b): Hata doğrulama regresyon grafiği; R_{TEST} (c): Test verileri regresyon grafiği; $R_{TOP.ORT}$ (d): Ortalama regresyon grafiği

Şekil 4.3.'de görüleceği üzere 200 eğitim verisi için regresyon analizi verilmiştir. İlgili analiz verilerinin R-Kare hata ayıklama verileri ise hüminit için %57, liptinit için %53, inertinit için ise %44 olarak hesaplanmıştır.

Çalışmada yer alan İYÇK ve KİYA ağ algoritmaları 210, 200, 170, 150 eğitim verisi olacak şekilde 10, 20, 30, 40 gizli katman ile gerçekleştirilmiştir. Çalışmaların Matlab programından alınan grafikleri sırasıyla EK1-EK4 ve EK5-EK8'de ayrıntılı bir şekilde verilmiştir.

4.2. Bayes Optimizasyon Algoritması ile Maseral Dağılım Tahmini

Diğer algoritmalarda olduğu gibi 232 adet veri ile yapılan çalışmada Python kullanılarak önce Bayes optimizasyonu ile 5 parametrenin optimizasyonu yapılmış, ardından bu optimum sonuçlarla 1 giriş, 1 çıkış ve 2 gizli katmanı bulunan bir ağ oluşturulmuştur. Sonrasında bu ağ ile eğitim ve maseral tahmini yapılmıştır. Çalışmada ülkemizde daha geniş bir literatürde yer alması sebebiyle linyit kömürü tercih edilmiştir.

Giriş için “Standard Skaler” ölçeklendirilmesi kullanılmış olup çıkış verileri için ise “Min-Max Normalizasyonu” kullanılmıştır. Öğrenme oranı 10^{-5} ile 10^{-2} aralığındadır. Bu oran bütün ağı kapsar. Ağın aktivasyon fonksiyonu olarak ReLU fonksiyonu Bayes optimizasyonu tarafından en uygun fonksiyon olarak seçilmiştir. ReLU, giriş değeri pozitifse bu değeri olduğu gibi çıkışa verir; eğer negatifse çıkış 0 olarak alınır. Optimizasyon fonksiyonu ise RMSprop fonksiyonu olarak seçilmiştir. Eğitim ve test verilerinin normalizasyon sonucu hata verileri Çizelge 4.3’te Python programı üzerinden çıkan R-kare grafikleri ise Şekil 4.5-4.7’de verilmiştir. Çizilen doğrusal eksen (X=Y eksen) tahmin ve gerçek verinin eşit olduğu çizgiyi temsil etmektedir. Hüminit, liptinit ve inertinit maseralleri için R-kare değerleri 1 değerine ne kadar yakın olursa sonuç o kadar doğrudur. Bu şekillerde verinin %80’i oranında kullanılan eğitim verisi ile gerçek veri; %20 oranında kullanılan test verisi ile gerçek veri arasındaki uyum tespit edilmeye çalışılmıştır.

Çalışmada veriler birinci gizli katman 10 ile 200 arasında refere edilmiş 190 adet nöron alınmıştır. İkinci gizli katmanda ise yine 10 ile 200 arasında refere edilmiş 93 adet seçilmiştir. Öğrenme oranı 3×10^{-3} olarak alınmış olup aktivasyon fonksiyonu olarak en iyi sonucu ReLU fonksiyonu vermiştir. ReLU (4.1) derin öğrenme ve makine öğrenimi alanında yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Özellikle bilgisayarla görme ve konuşma tanıma gibi uygulamalarda etkili bir performans sergilemektedir. ReLU’nun matematiksel ifadesi, giriş değerinin sıfırdan büyükse kendisi, değilse sıfır olup, bu özellik onu basit ama etkili bir seçim haline getirmektedir (Bishop ve Nasrabadi 2006).

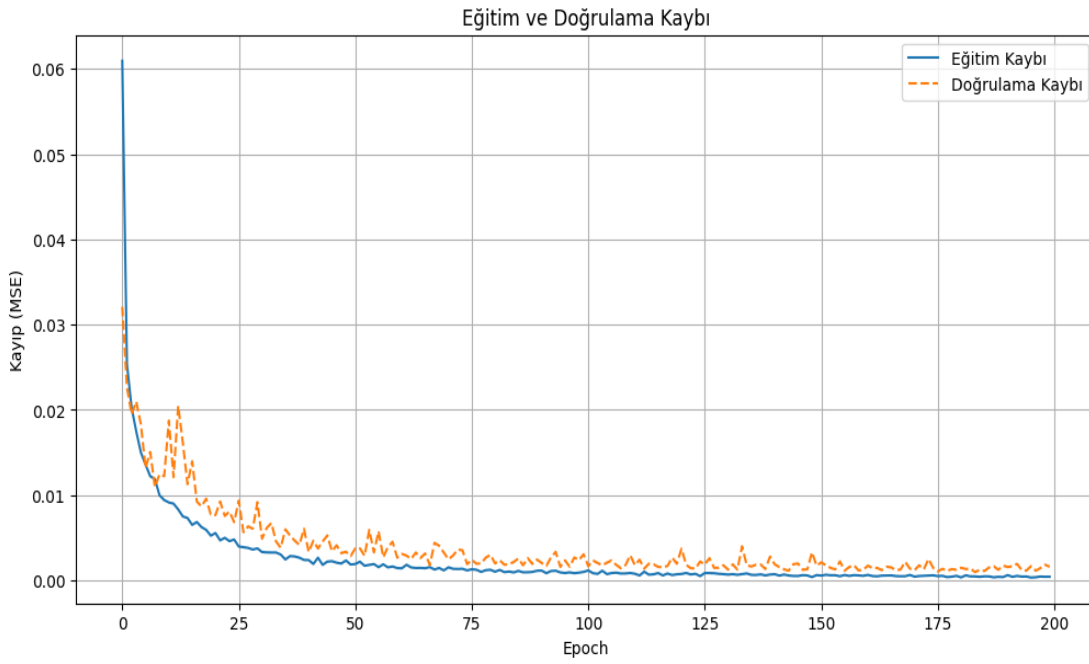
$$\text{ReLu}(x) = \max(0, x) = \frac{x+|x|}{2} \rightarrow \begin{cases} x & x > 0 \text{ ise} \\ 0 & x \leq 0 \text{ ise} \end{cases} \quad (4.1)$$

Bayes optimizasyonu tarafından optimizasyon fonksiyonları arasından ise en iyi sonucu veren RMSprop fonksiyonunu vermiştir.

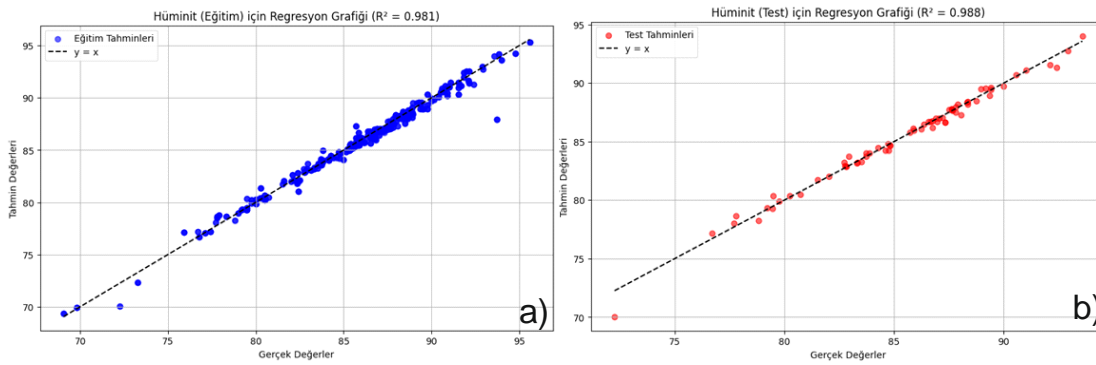
Çizelge 4.3. BO hiper-parametre tanımlama yöntemi için çalışılan setlerin hata oranları

BO	R-Kare		Ortalama Mutlak Hata		Ortalama Kare Hatası		Ortalama Kare Hatası Karekökü		Ortalama Mutlak Hata Yüzdesi	
	Eğitim Verisi	Test Verisi	Eğitim Verisi	Test Verisi	Eğitim Verisi	Test Verisi	Eğitim Verisi	Test Verisi	Eğitim Verisi	Test Verisi
Hüminit	0,981	0,988	0,366	0,295	0,364	0,196	0,603	0,443	0,43%	0,43%
Liptinit	0,963	0,961	0,373	0,338	0,37	0,344	0,608	0,587	5,49%	4,61%
İnertinit	0,962	0,911	0,271	0,355	0,378	0,735	0,615	0,857	7,11%	4,61%

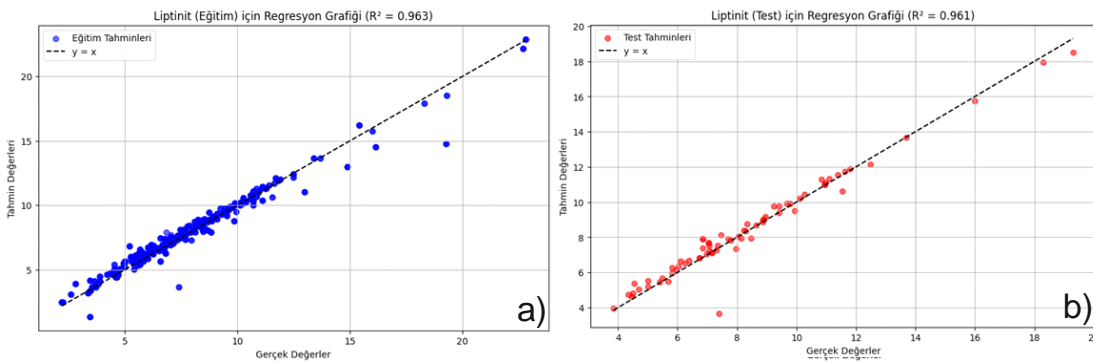
Bu çalışma üzerindeki diğer algoritmaların ve literatür üzerinde yer alan çalışmaların ortalama eğitim ve test verisi ortalama yüzdesi %75-80 arasında verimli olabileceği görülmüştür. BO’da da benzer şekilde %80 eğitim verisi kullanılmıştır. Bayes optimizasyonu için Python yazılımında çıkan doğrulama grafiği Şekil 4.4’te paylaşılmıştır.



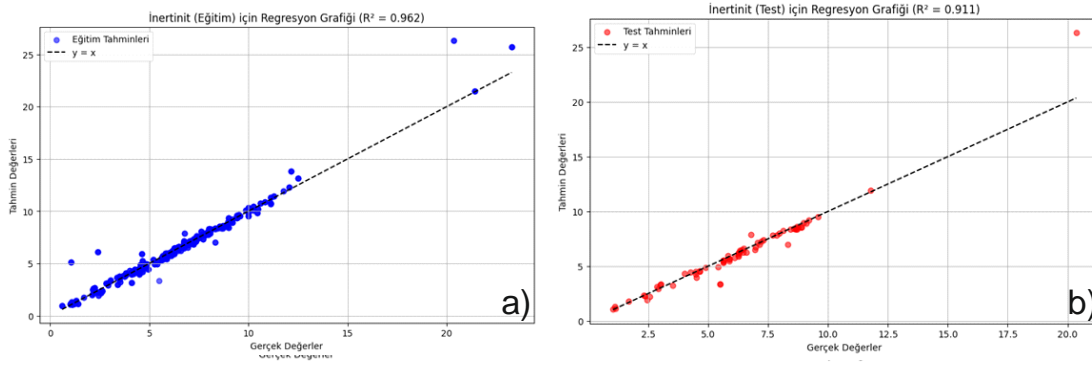
Şekil 4.4. BO eğitim ve doğrulama kaybı grafiği



Şekil 4.5. BO ile hesaplanan hüminit maseralı eğitim (a) ve test (b) verileri için regresyon grafikleri



Şekil 4.6. BO ile hesaplanan liptinit maseralı eğitim (a) ve test (b) verileri için regresyon grafikleri



Şekil 4.7. BO ile hesaplanan inertinit maserali eğitim (a) ve test (b) verileri için regresyon grafikleri

Çalışmanın geneline bakılacak olursa, linyit kömürü maseral dağılımlarının çözümlenmesi bitümlü kömürlere kıyasla daha zor olması yani vitrinit ve hüminit arasındaki küçük nüanslar; maserallerden liptinit ve inertinit arasındaki yakın değerlerin birleşimi ile YSA eğitimi açısından tutarsızlıklar yaratabilmesi olasıdır. Literatürde yapılan çalışmalarda bitümlü kömürler tercih edilmiş ve az veri ile de olsa iyi sonuçlar elde edilebilmiştir (Onifade vd. 2021, Khandelwal vd. 2017). Veri setinin benzer olmasına rağmen yüksek miktarda veri kullanan çalışmalarda (Akkaya 2021) bunu kanıtlar niteliktedir. Verinin artırılmasının ve/veya veri işleme yöntemi ile çoğaltılması bu tip sorunların çözümünde rol oynayabileceği düşünülmektedir. Veri sayısının fazla olması aynı zamanda tutarsızlıkları da ortadan kaldıracaktır. Çünkü her tutarsızlık ardından onu toparlayabilecek yüzlerce veri kümesi mevcut olacaktır.

Çizelge 4.4. Tez kapsamında yapılan BO ve İYÇK (en iyi sonuç veren veri seti) Onifade vd. (2021) yılında yaptıkları çalışma ile OMH verileri

		MEA-YSA	GİP	ÇDR	ÇNR	BO	İYÇK
Hüminit	Eğitim Verisi	0,065	1,847	3,018	4,794	0,366	4,9
	Test Verisi	0,091	4,595	3,914	4,910	0,295	
Liptinit	Eğitim Verisi	0,03537	1,0916	3,6296	2,5642	0,373	2,6
	Test Verisi	0,02004	4,5882	2,5391	1,2338	0,338	
İnertinit	Eğitim Verisi	0,44521	3,3369	4,5022	7,4513	0,271	3,6
	Test Verisi	0,37014	9,1623	6,2046	7,9006	0,355	

Çalışmada KIYA ve İYÇK verileri “Kara Kutu” olarak adlandırılan ve ağırlık vektörleri ile aktivasyon fonksiyonuna dış müdahaleye izin vermeyen ağ yapısı kullanılmıştır. Dış müdahalenin olmamasının objektiflik açısından önemli olduğu düşünülmektedir. Ağırlık fonksiyonlarının veriye göre ayarlanıyor olması sabit bir ağ yapısı kullanarak her çalışma için yeniden karakterize edilmesine ihtiyaç olacağından bu çalışmada amacına uygun olmayacağı düşünülmüştür. Fakat Onifade vd. (2021) yaptığı çalışmada dört farklı YSA modelini deneyerek en verimli çalışmaya ulaşmak hedeflenmiştir. Bu ağlar, Modifiye edilmiş ağırlıklı YSA (MEA-YSA), Gen İfade Programlama (GİP), Çoklu Doğrusal Regresyon (ÇDR), Çoklu Numerik Regresyon (ÇNR)’dır. Kullandıkları ağlar arasında en iyi sonucu “Beyaz Kutu” olarak bilinen ağ içinde müdahale imkânı veren MEA-YSA vermiştir. Adapte edilebilirliği dışında

sonuçları konusunda tatmin edici olabileceği görülmüştür. Çizelge 4.4'te görülebileceği üzere yapılan iki çalışmanın da bulguları ve Onifade vd. (2021) tarafından yaptığı çalışma OMH baz alınarak kıyaslama için paylaşılmıştır.

Klasik çalışmalara alternatif olarak geliştirilen ve güzel sonuçlar elde edilen hibrit yöntemlerde mevcuttur. Bilinen ya da türetilen ağ yapıları çalışmaya direk olarak etki edemeyeceği bilirse de diğer ağ yapıları ile kullanılarak ortak bir çalışma ağı kurulabilmektedir. Bu çalışma bünyesinde İYKÇ ve KİYA ağ yapılarında hibrit bir ağ yapısı kurulmamış seçim insan tarafından manuel olarak yapılmıştır. Fakat işlem yükünün fazla olduğu durumlarda binlerce veriyi insan gözü kısa sürede tarayamayacağı için yararlı bir uygulama olabileceği düşünülmektedir. Buna örnek olarak Khandelwal vd. (2017) yaptıkları çalışmada emperyalist rekabetçi algoritma (ERA) ve yapay sinir ağı (YSA) temelinde Hindistan kömürlerinin maserallerinin konsantrasyonunun tahminini konusunu işlemişler ve hibrit bir ağ yapısı elde etmişlerdir. Çalışmada ERA'nın, eğer sorusu ile hareket eden bir uygulama olmasına rağmen YSA yapısıyla mükemmel uyum sağladığını ve tek YSA yapısından daha iyi bir sonuç alındığını göstermişlerdir.

Bu tez, Türkiye'nin bazı linyit rezervlerinin maseral dağılımlarının yapay sinir ağları kullanılarak belirlenmesini ve bu sayede kömür karakterizasyonuna yenilikçi bir yaklaşım getirilmesini konu almaktadır. Veri setinde kullanılan maseral dağılımlarının mikroskopta göz ile tespiti yapılan işlemler olması sebebiyle, yanlış tanımlamaların olması farklı değerlendirmelere sebep olabilmektedir. İYKÇ çalışmasında da en iyi sonucu veren set ile regresyon analizleri çok iyi sonuç verse de R-Kare analizi istenen verimlilikte olmaması tolerans miktarı düşük olan analizin sonucunu etkilediği düşünülmektedir. Daha fazla veri ile formülize edilen test verilerinde grafik aralığı daralacağından hata ayıklama sonuçlarını olumlu yönde etkileyeceği tahmin edilmektedir. YSA'nın bu alandaki potansiyelini inceleyen çalışma hem maliyeti düşürecek hem de analiz süreçlerini hızlandıracaktır. Ayrıca YSA tekniklerinin jeoloji ve enerji sektöründeki uygulama potansiyelini göstermiştir. Maserel analizi gibi karmaşık ve uzmanlık gerektiren bir alanın, YSA tabanlı yöntemlerle daha etkili bir şekilde gerçekleştirilebileceği kanıtlanmıştır.

5. SONUÇLAR

Çalışma kapsamında, Türkiye'deki bazı linyit kömürlerinden elde edilen kısa ve elementel analiz verileri temel alınmıştır. Bu veriler, maseral grupları (hüminit, liptinit, inertinit) arasındaki dağılımı tahmin etmek için çeşitli YSA modelleriyle analiz edilmiştir. Kullanılan YSA teknikleri arasında "İleri Yönlü Çok Katmanlı Algılayıcı", "Kaskad İleri Yönlü Algılayıcı" ve "Bayes Hiper-parametre Optimizasyonu" yer almıştır. Modellerin performansı, hata metrikleri (ortalama kare hata, R-kare) ve regresyon analizi gibi istatistiksel yöntemlerle değerlendirilmiş ve sonuçlar aşağıda sıralanmıştır.

Matlab programı üzerinde yapılan çalışmada İYÇK ve KİYA ağ algoritmaları arasında en iyi sonucu İYÇK; 200 adet eğitim verisinin ve 20 adet gizli katmanın kullanıldığı çalışmada vermiştir. Literatürde bulunan diğer çalışmalarla kıyaslandığında da %75-80 arası alınan eğitim setinin daha verimli olduğu görülmüştür. Gizli katman ise 10-20 arası en iyi potansiyel sonucu vermiştir.

Python programlama dili ile yapılan çalışmada beş farklı hiper-parametrenin Bayes ile optimize edilmesinde en iyi sonucun gizli katmanlardaki nöron sayısı sırasıyla 190 ve 93 olarak seçilmiş öğrenme oranı 3×10^{-3} olarak optimize edilmiştir. Aktivasyon fonksiyonu olarak en iyi sonucu ReLU fonksiyonu verirken; optimizasyon fonksiyonu olarak ise RMSProp fonksiyonu en iyi sonucu verdiği Bayes tarafından teslim edilmiştir. Eğitim ve test seti arasındaki oran diğer ağ algoritmalarında olduğu gibi %80 ideal limitinde kalarak tespitinin doğru olduğunu kanıtlar niteliktedir.

Yapılan analizler, YSA modellerinin maseral dağılımlarını yüksek doğruluk oranlarıyla tahmin edebildiğini göstermiştir. Daha çok veri seti ile bu doğruluk oranının artırılabilmesi tespit edilmiştir. YSA'nın laboratuvar yöntemlerine etkili bir alternatif sunduğunu ortaya koymaktadır. Kömürün petrografik özelliklerini anlamada önemli bir yenilikçi adım olabileceği görülmüş ve geliştirilebilirliğinin önünün açık olduğu görülmüştür.

İleri yönlü çok katmanlı algılayıcı, daha karmaşık verilerde etkili olurken, kaskad ileri yönlü algılayıcı daha basit ve az sayıda katmanın gerektiği durumlarda öne çıkmıştır. Bayes Optimizasyonu ise az veri ile de olsa hiper-parametre ayarlamalarında daha hassas sonuçlar elde edilmesini sağlamıştır ve diğer YSA yöntemlerine göre daha etkin kullanılabilmesi düşünülmektedir. Ayrıca İYKÇ ve KİYA'da algoritma düzenleri ve seçimler insan eli ile yapıldığından hata oranı yükselebilmektedir, Bayes Optimizasyonu ise seçimleri kendi algoritma seçenekleri üzerinden yine kendi karar vermiş ve en iyi sonucu elde etmek için daha fazla olasılık üzerinden değerlendirme yapabilmektedir. Sonucun maksimum verimlilikte olması için kullanılan veriler literatür kaynaklı ise doğruluğu arttırmak için veri seti sayısı artırılmasının doğru bir yaklaşım olabileceği sonucuna varılmıştır. Bu şekilde girilen ve tahmin verileri için maksimum eğitim doğruluğu ve minimum hata sonucu elde edileceği tespit edilmiştir.

Geleneksel yöntemlerin aksine, bu teknikler, geniş çapta veri setlerinin analiz edilmesine imkân tanıyarak, maliyet ve zaman avantajı ile teşviki de beraberinde getirecektir. YSA yöntemleri ile elde edilen sonuçların doğruluğu, genellikle veri setinin kalitesine ve çeşitliliğine bağlıdır. Bu çalışma, literatürdeki veri setlerinden elde edilen bilgilere dayanması nedeniyle geniş çapta bir genelleme yapabilme kapasitesine sahiptir. Ancak, bu yöntemlerin saha verileriyle doğrulanması gerekliliği de belirtilmiştir. Bunlara

ek olarak kömürlü istifin özelliđi, yaşı, analiz yapılan laboratuvar başlıca deđişkenleri bile önem taşımaktadır. Bu nedenle yapılacak çalışmalar için tüm bu özelliklerin aynı olmasına hassas ölçüm için önemlidir.

Gelecekte, saha çalışmaları ile elde edilen veri setlerinin YSA ile analiz edilmesi, bu yöntemlerin doğruluđunu daha da artırabilir. Ayrıca, farklı kömür türleri ve daha geniş veri setleriyle benzer çalışmalar yapılmasının da önü bu çalışma ile açılabilceđi düşünölmektedir.



6. KAYNAKLAR

- Abid, F. and Hamami, L. 2018. A survey of neural network based automated systems for human chromosome classification. *Artificial Intelligence Review*, 49: 41-56.
- Adeyemo, A., Wimmer, H. and Powell, L. 2018. Effects of normalization techniques on logistic regression in data science. In Proceedings of the Conference on Information Systems Applied Research, 2167: 1508.
- Akkaya, A.V. 2021. Predicting coal elemental components from proximate analysis: Explicit versus implicit nonlinear models. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 43: 1825–1837.
- Ali, A.R.I. ve Hanbay, D. 2018. Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(3): 1395-1408.
- Alpern, B. and Lemos, M. 1970. CR Academie Science, Paris, 271: 1-956.
- ASTM (American Society For Testing And Materials). 1983. Annual book of ASTM standards, Gaseous Fuels; Coal and Coke (D-388, D-2798- 79, D-3172-73, D-2799-72, D-3174-82, D-3175-82): 1916 Race Street, Philadelphia, PA.
- Ayuya, C. 2021. Using Grid Search to Optimize Hyperparameters. <https://www.section.io/engineering-education/grid-search/> [Son erişim tarihi: 22.12.2024].
- Basheer, I.A. and Hajmeer, M. 2000. Artificial neural networks: fundamentals, computing, design, and Application. *Journal of Microbiological Methods*, 43: 3-31.
- Bengio, Y., Goodfellow, I. and Courville, A. 2017. Deep learning, MIT press, Cambridge, MA, USA, pp 692.
- Berkowitz, N. 1979. An introduction to coal technology, Academic Press, United Kingdom, 350 p.
- Birön, C. 1997. Türkiye Enerji Sorununda Linyitin Yeri. *Scientific Mining Journal*, 16(3): 22-30.
- Bishop, C.M., and Nasrabadi, N.M. 2006. Pattern recognition and machine learning. Springer, New York, 4(4)738 p.
- Brownlee, J., 2018. Difference Between a Batch and an Epoch in a Neural Network. <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/> [Son erişim tarihi: 02.12.2024].
- Büyükkamber, K. 2022. Farklı katı yakıt türlerinin üst ısıl değerlerinin çoklu lineer regresyon, karar ağacı, random forest ve yapay sinir ağları yöntemleriyle belirlenmesi. Yüksek Lisans tezi, İstanbul Teknik Üniversitesi, İstanbul, 69 s.
- Chai, T. and Draxler, R.R. 2014. Root mean square error (RMSE) or mean absolute error (MAE). *Geoscientific model development discussions*, 7(1): 1525-1534.
- Chelgani, S.C., Mesroghli, S.H. and Hower, J.C. 2010. Simultaneous prediction of coal rank parameters based on ultimate analysis using regression and artificial neural network. *International Journal of Coal Geology*, 83: 31–34.

- Choudhury, N. Biswas, S. Sarkar, P. Kumar, M. Ghosal, S. and Mitra, T. 2008. Influence of rank and macerals on the burnout behaviour of pulverized Indian coal. *International Journal of Coal Geology*, 74:145–153.
- Cohen, A.D., Spackman, W. and Raymond, R. 1987. Interpreting the characteristics of coal seams from chemical, physical and petrographic studies of peat deposits. In: Scott, A.C. (Ed.), *Coal and Coal-Bearing Strata: Recent Advances*. Geol. Soc. Spec. Publ. 32, pp. 107–125.
- Çarkacı, N., 2018. Derin Öğrenme Uygulamalarında En Sık kullanılan Hiper-parametreler. <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-ensik-kullanilanhiper-parametreler-ece8e9125c> [Son erişim tarihi: 04.11.2024].
- Deore, S. 2021. What do you mean by Forward Propagation in ANN? <https://medium.com/analytics-vidhya/what-do-you-mean-by-forwardpropagation-in-ann-9a89c80dac1b> [Son erişim tarihi: 19.11.2024].
- Diessel, C.F.K. 1992. *Coal-bearing depositional systems*. Springer, Heidelberg, Berlin, pp.721.
- Erik, N.Y. and Yılmaz, I. 2011. On the use of conventional and soft computing models for prediction of gross calorific value (GCV) of coal. *International Journal of Coal Preparation and Utilization*, 31(1): 32-59.
- Ersoy, E. ve Karal, Ö. 2012. Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2): 188-205.
- ETKB (Enerji ve Tabii Kaynaklar Bakanlığı) 2024. Kömür <https://enerji.gov.tr/bilgimerkezi-tabii-kaynaklar-komur> [Son erişim tarihi: 01.02.2024].
- Fahlman, S.E., Lebiere F.F. 1990. The Cascade-Correlation Learning Architecture. *Advances in Neural Information System*, 2: 524–532.
- Falcon, R.M.S. 1989. Macro and micro factors affecting coal seam quality and distribution in Southern African with particular reference to the No. 2 seam, Witbank coalfield, South Africa. *International Journal of Coal Geology*, 12: 681-731.
- Given, P.H. and Dyrkacz, G. 1988. The nature and origins of coal macerals. In: Yqrqm, Y. (Ed.), *New Trends in Coal Science*, NATO Scientific Affairs Division. Kluwer Academic Publishing, Dordrecht-Boston-London, pp. 53– 72.
- Goodarzi, F. 1985. Optically anisotropic fragments in a western Canadian subbituminous coal. *Fuel*, 64(9): 1294-1300.
- Graupe, D. 2007. *Principles of artificial neural networks*, (2nd Edition), advanced series on circuits and systems, 6, World Scientific Publishing Co. Pte. Ltd.
- Gülbağ, A. 2006. Yapay sinir ağı ve bulanık mantık tabanlı algoritmalar ile uçucu organik bileşiklerin miktarsal tayini. Yüksek lisans tezi, Sakarya Üniversitesi, Sakarya, 148 s.
- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation Second Edition*, Prentice Hall, New Jersey, pp. 823.

- Hodson, T.O. 2022. Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development Discussions*, 1-10.
- Hower, J.C. and Wild, G.D. 1988. Relationship between hardgrove grindability index and petrographic composition for high volatile bituminous coals from Kentucky. *Journal of Coal Quality*, 7: 122- 126.
- Hower, J.C., Rathbone, R.F., Wild, G. D. and Davis, A. 1996. Observations on the use of vitrinite maximum reflectance versus vitrinite random reflectance for high volatile bituminous coals. *Journal of Coal Quality*, 1-13.
- İşeri, A. and Karlık, B. 2009. An artificial neural networks approach on automobile pricing. *Expert Systems with Applications*, 36(2): 2155-2160.
- Jacob, H. 1970. Neuere Untersuchungen zur Frage der biochemischen Inkohlungsprozesses. C.R. 6e Congr. Intern. Strat. Ge'ol. Carbonife're, 3: 1009–1021.
- Jo, J., Lee, D.G. Kim, J., Lee, B.H. and Jeon, C.H. 2022. Improved ANN-Based Approach Using Relative Impact for the Prediction of Thermal Coal Elemental Composition Using Proximate Analysis. *ACS Omega*, 7: 29734-29746.
- Kalkreuth, W., Sherwood, N., Cioccarri, G., Correa da Silva, M., Zhong, N., et al. 2004. The application of FAMM (Fluorescence Alteration of Multiple Macerals) analyses for evaluating rank of Parana Basin coals. Brazil. *International Journal of Coal Geology*, 57:165–185.
- Khandelwal, M. and Singh, T.N. 2010. Prediction of macerals contents of Indian coals from proximate and ultimate analyses using artificial neural networks. *Fuel*, 89: 101–1109.
- Khandelwal, M., Mahdiyar, A., Armaghani, D. J., Singh, T. N., Fahimifar, A. and Faradonbeh, R. S. 2017. An expert system based on hybrid ICA-ANN technique to estimate macerals contents of Indian coals. *Environmental Earth Sciences*, 76: 1-14.
- Khatip, T. and Elmenreich, W. 2016. Modelling of Photovoltaic Systems Using Matlab. John Willey and Sons, Inc, p. 3.
- Kızrak, A. 2019. Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması. <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd> [Son erişim tarihi: 19.11.2024].
- King, J.G., Maries, M.B. and Crossley, H.E., 1936. Formulas for the calculation of coal analyses to a basis of coal substance free from mineral matter. *Journal of the Society of Chemical Industry*, 55: 277– 281.
- Kosko, B. 1994. Neural networks and fuzzy systems: a dynamical systems approach to grmachine intelligence. New Delhi, Prentice-Hall of India, India, p. 12–7.
- Larry, P. 2002. Coal geology - 2nd edition. John Wiley and Sons Publication. West Sussex, England, p 457.

- Lawal, A. I., Bada, S. O. and Onifade, M. 2024. Prediction of HGI of South African coalfields: a comparative application of ANN, SVR and LSTM models. *International Journal of Coal Preparation and Utilization*, 1-17.
- Lawal, A.I., Onifade, M., Bada, S.O., Shivute, A.P. and Abdulsalam, J. 2023. Prediction of Thermal Coal Ash Behavior of South African Coals: Comparative Applications of ANN, GPR, and SVR. *Natural Resources Research*, 32: 1399-1413.
- Malan, O. 1965. Zur Problematik der quantitativen Petrographischen Braunkohlenanalyse. *Freiberger Forschungsh.*, 189:185– 201.
- Mendez, L.B., Borrego, A.G., Martinez-Tarazona, M.R. and Mene´ndez, R. 2003. Influence of petrographic and mineral matter composition of coal particles on their combustion reactivity. *Fuel*, 82: 1875–1882.
- Miura K, Hashimoto K and Silveston PL 1989. Factors affecting the reactivity of coal chars during gasification, and indices representing reactivity. *Fuel*, 68: 1461–1475.
- MTA, 2023. <https://www.mta.gov.tr/v3.0/arastirmalar/komur-arama-arastirmalari> [Son erişim tarihi: 11.10.2024].
- Murchison, D. G. 1987. Recent advances in organic petrology and organic geochemistry: an overview with some reference to oil from coal. *Geological Society of Special Publication*, 32: 257-302
- Nadiroğlu, Z. 2022. Bayes optimizasyon yöntemi kullanılarak evrimsel sınır ağlarında hiper parametre optimizasyonu. Yüksek lisans tezi, Yüzüncü yıl Üniversitesi, Van, 56 s.
- Onifade, M., Lawal, A.I., Abdulsalam, J., Genc, B., Bada, S., Said, K.O. and Gbadamosi, A.R. 2021. Development of multiple soft computing models for estimating organic and inorganic constituents in coal. *International Journal of Mining Science and Technology*, 31: 483–494.
- Öztemel, E. 2003. Yapay sinir ağları. Papatya Yayıncılık, İstanbul, 232 s.
- Parikh, J., Channiwala, S.A. and Ghosal, G.K. 2005. A correlation for calculating HHV from proximate analysis of solid fuels. *Fuel*, 84: 487–494.
- Pickel, W., Kus, J., Flores, D., Kalaitzidis, S., Christanis, K., Cardott, B. J. and Wagner, N. 2017. Classification of liptinite–ICCP System 1994. *International Journal of Coal Geology*, 169: 40-61.
- Pollock, S.M., Goodarzi, F. and Riediger, C.L. 2000. Mineralogical and elemental variation of coal from Alberta, Canada: an example from the No. 2 seam, Genesee Mine. *International Journal of Coal Geology*, 43: 259– 286.
- Ravi, V. and Reddy, P.J. 1999. Ranking of Indian coals via fuzzy multi attribute decision making. *Fuzzy Sets System*, 103: 369–377.
- Saygılı, R. 2017. <http://cografyaharita.com/haritalarim/4turkiye-linyit-madeni-haritasi.png> [Son erişim tarihi: 02.12.2024].
- Schapiro, J. and Gray, S. 1970. Vitrinite content and coke strength, 50(1): 41-52.

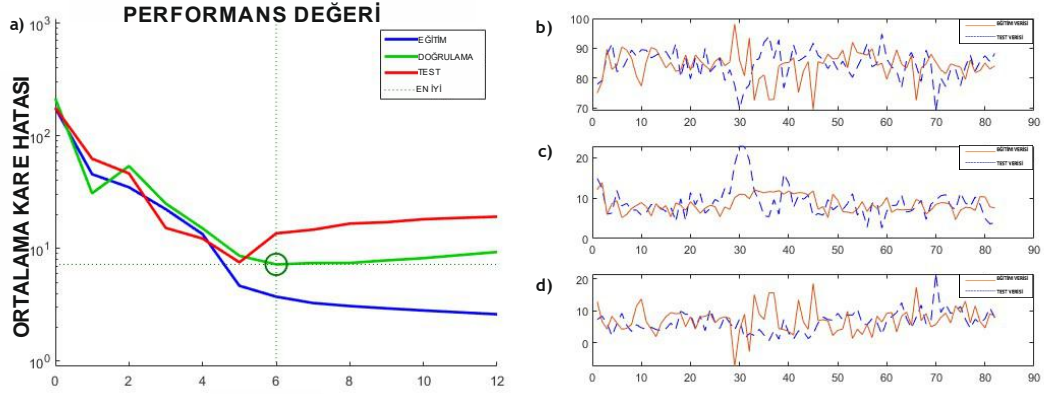
- Schobert, H.H. and Song, C., 2002. Chemicals and Materials from Coal in The 21st century, *Fuel*, 81: 15-32.
- Seeger, M. 2004. Gaussian processes for machine learning. *International journal of neural systems*, 14(2): 69-106.
- Senapati, D. 2018. Grid Search vs Random Search. <https://medium.com/@senapati.dipak97/grid-search-vs-randomsearchd34c92946318>. [Son erişim tarihi: 01.12.2024].
- Shearer, J.C., Moore, T.A. and Demchuk, T.D. 1995. Delineation of the distinctive nature of Tertiary coal beds. *International Journal of Coal Geology*, 28(2-4): 71-98.
- Simpson, P.K. 1990. Artificial neural system: foundation, paradigms, applications and implementations. Pergamon, New York, pp. 209.
- Smith, G.C. and Cook, A.C. 1980. Coalification paths of exinite, vitrinite and inertinite. *Fuel*, 59(9): 641-646.
- Stach, E., Mackowsky, M.T., Teichmüller, M., Taylor, G., Chandra, D. and Teichmüller, R. 1982. Coal Petrology, Borntrager, Berlin, 3 rd ed., 535 pp.
- Stopes, M.C. 1935. The classification of coals. *Nature*, 136(3427): 20-33.
- Sykorova I., Pickel W., Christanis K., Wolf M., Taylor G.H. and Flores D. 2004. Classification of huminite—ICCP System 1994. *International Journal of Coal Geology*, 62: 85– 106.
- Şen, Z. 2004. Yapay sinir ağları ilkeleri. Su Vakfı Yayınları, İstanbul, ss. 183.
- Takahashi, R. and Sasaki, M. 1989. Automatic macerals analysis of low-rank coal (brown coal). *International Journal of Coal Geology*, 14: 103–118.
- Taylor, G.H., Teichmüller, M., Davis, A., Diessel, C.F.K., Littke, R. and Robert, P. 1998. Organic petrology. Stuttgart, Berlin: Gebrüder Borntraeger, pp 704.
- Thomas, L.P. 2013. Coal resources and reserves. In *The coal handbook: towards cleaner production*, Woodhead Publishing, pp. 80-106.
- Tongur, S. 2010. Konya ve çevresi linyitlerinin aktifleştirilmesi ve organik bileşiklerin adsorpsiyonunda kullanılabilirliğinin araştırılması. Doktora tezi, Selçuk Üniversitesi, Konya, 220 s.
- Tuncalı, E., Çiftci, B., Yavuz, N., Toprak, S., Köker, A., Gencer, Z., Ayçık, H. ve Şahin, N. 2002. Türkiye tersiyer kömürlerinin kimyasal ve teknolojik özellikleri. Maden Teknik Arama Genel Müdürlüğü, Ankara, 402 s.
- Turhan K., Batur O. 1974. Pamucak yaylası ve güneyinin jeoloji raporu ve kömür imkanları. Maden Tetkik Arama Genel Müdürlüğü, Ankara.
- Türkiye Kömür İşletmeleri (TKİ). 2011. Kömür Sektör Raporu 2011, Ankara. Türkoğlu, M., Hanbay, K., Sivrikaya, I. S. ve Hanbay, D. 2021. Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1): 334-345.
- Ülker, E. 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3): 85-10.

- Ünalın, G. 2010. Kömür jeolojisi. Maden Tetkik ve Arama Genel Müdürlüğü, Ankara, 556 s.
- Vasconcelos, L. 1999. The petrographic composition of world coals: Statistical results obtained from a literature survey with reference to coal type (maceral composition). *International Journal of Coal Geology*, 40: 27–59.
- Walker, S 1999. Cayirhan challenge, World Mining Equipment; Journal Volume: 23; Journal Issue: 10; Other Information, Oxford United Kingdom.
- Wang, J., Zhao, M., Wang, B., Wang, Y., Yang, G., Ma, T., and Xu, J. 2024. Prediction of Coal Seam Permeability by Hybrid Neural Network Prediction Model. *Journal of Energy Engineering, China*, 150(4), 04024021.
- Ward, C.R. 1984. Coal Geology and Coal Technology. Blackwell, London.
- Yang, W., Wang, S., Wu, J., Chen, W. and Tian, Z. 2024. A low-light image enhancement method for personnel safety monitoring in underground coal mines. *Complex and Intelligent Systems*, 1-14.
- Yılmaz, I., Erik, N.Y., and Kaynar, O. 2010. Different types of learning algorithms of artificial neural network (ANN) models for prediction of gross calorific value (GCV) of coals. *Scientific Research and Essays*, 5(16): 2242-2249.
- Yperman, J. and Becker, T. 2016. Bayesian optimization of hyper-parameters in reservoir computing. Preprint at <https://doi.org/10.48550/arXiv.1611.05193> [Son erişim tarihi: 01.12.2024].
- Yu, T. and Zhu, H. 2020. Hyper-parameter optimization: A review of algorithms and applications. <https://doi.org/10.48550/arXiv.2111.05193> [Son erişim tarihi: 01.12.2024].
- Zhu, Y.H., 2008. Coal Chemistry. Chemical Industry Press, Beijing.129-137.

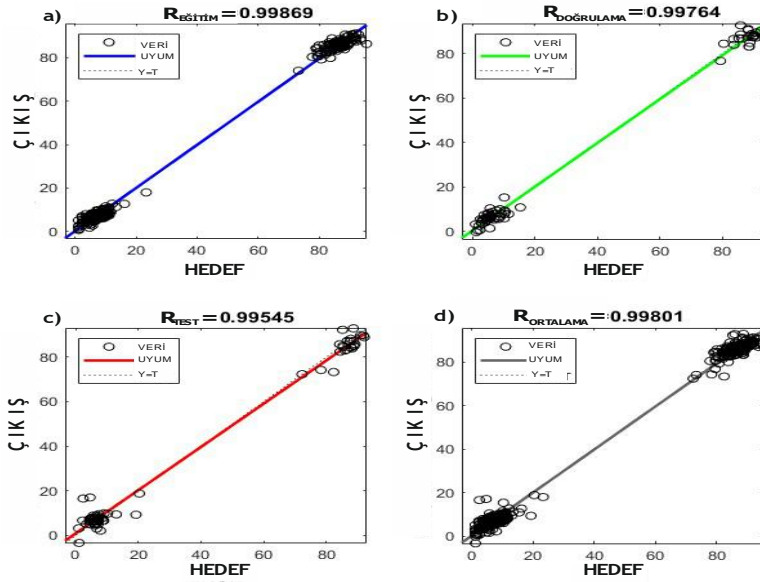
7. EKLER

EK-1

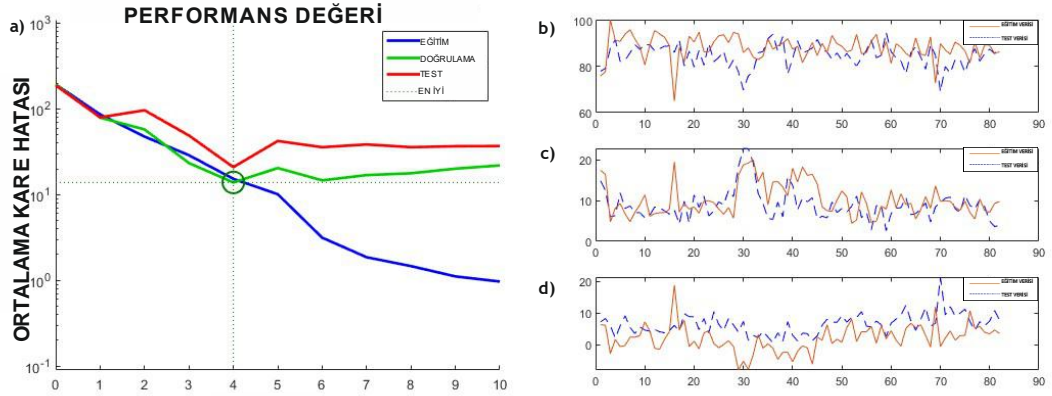
İleri yönlü çok katmanlı algılayıcı algoritması ile 150 giriş verisi ve 82 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30, 40 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.1- 7.8. 'de verilmiştir.



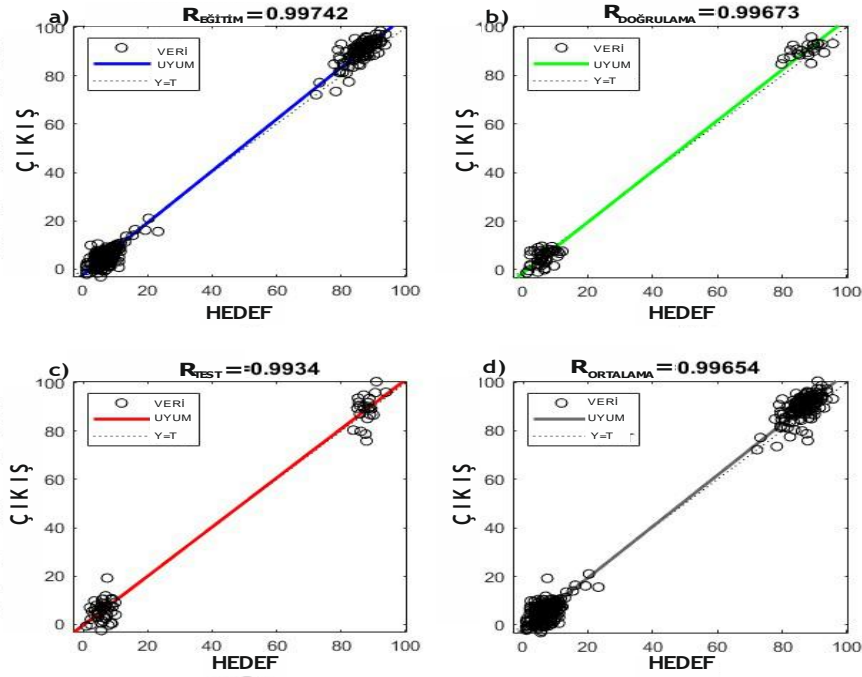
Şekil 7. 1. İleri yönlü çok katmanlı algoritmada 150 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



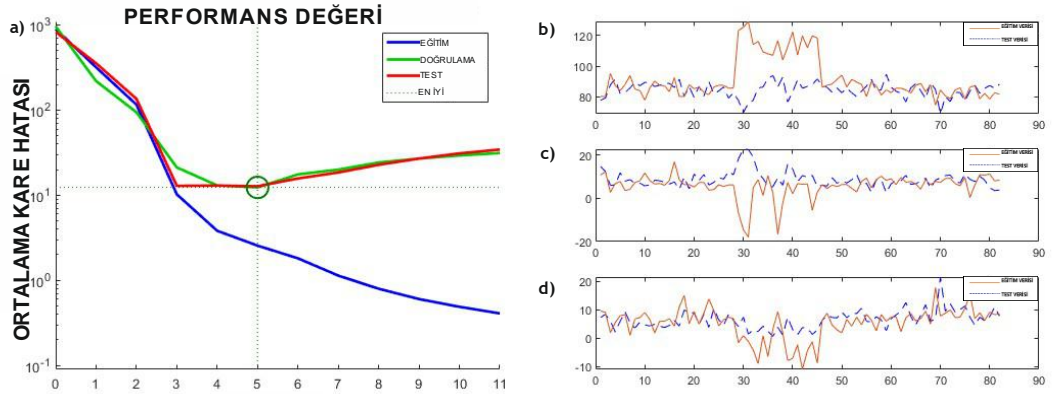
Şekil 7.2. İleri yönlü çok katmanlı algoritmada 150 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



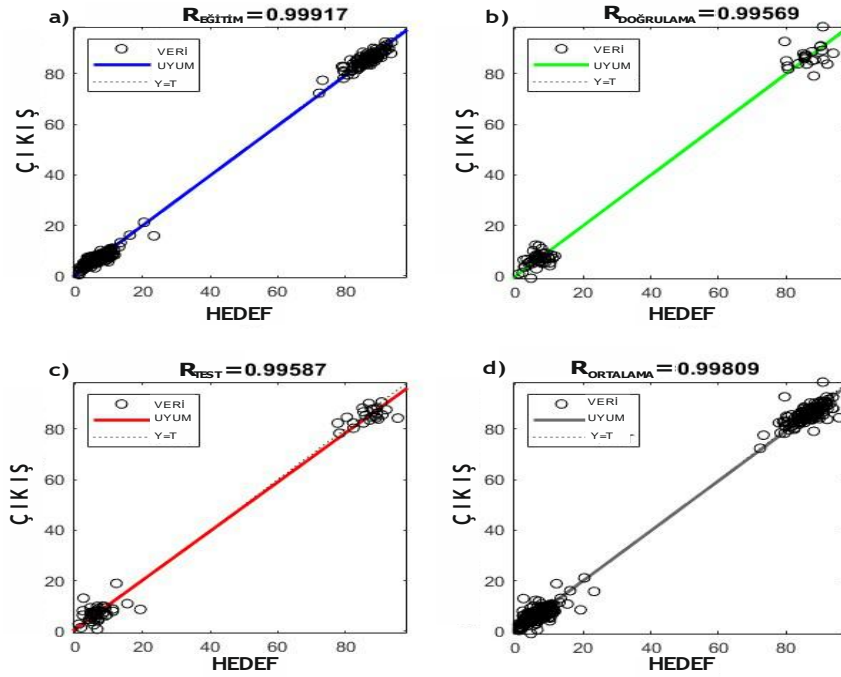
Şekil 7.3. İleri yönlü çok katmanlı algoritmda 150 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) lıptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



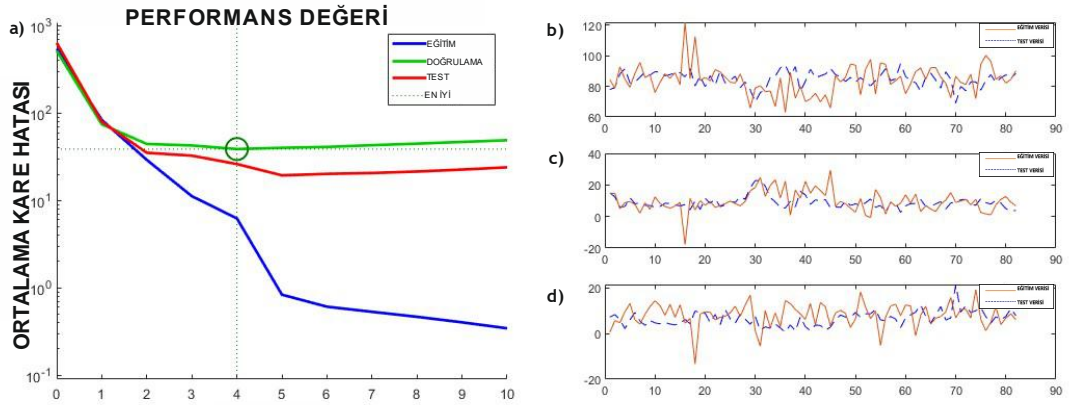
Şekil 7.4. İleri yönlü çok katmanlı algoritmda 150 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



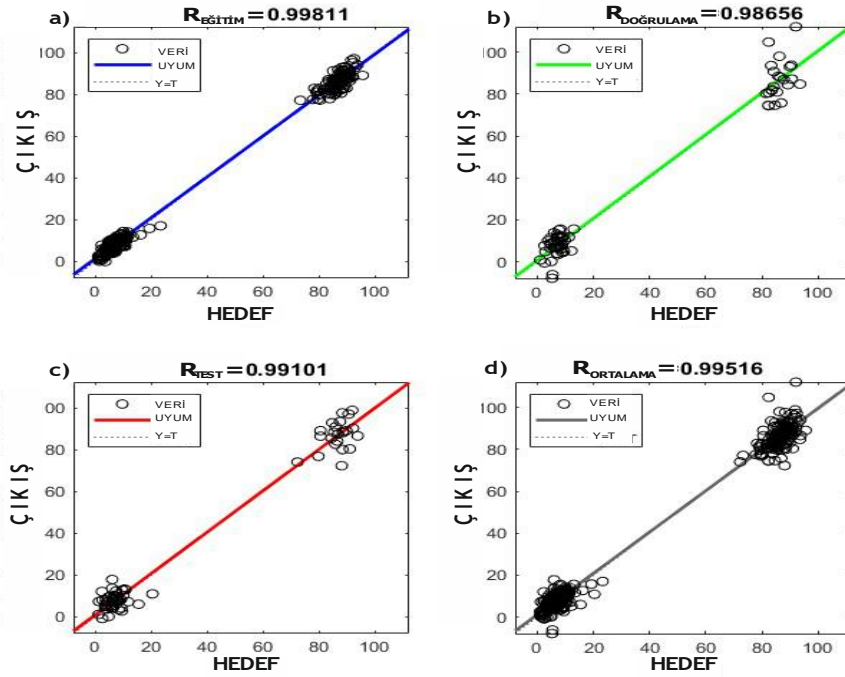
Şekil 7.5. İleri yönlü çok katmanlı algoritmada 150 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminit c) lipinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



Şekil 7.6. İleri yönlü çok katmanlı algoritmada 150 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



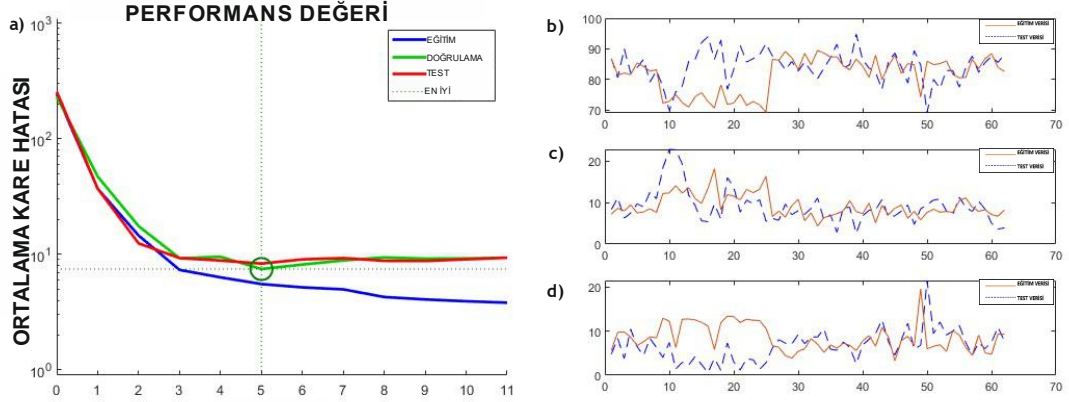
Şekil 7.7. İleri yönlü çok katmanlı algoritmada 150 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) lityum d) inertin maserali için gerçek ve tahmin verisi grafiğidir



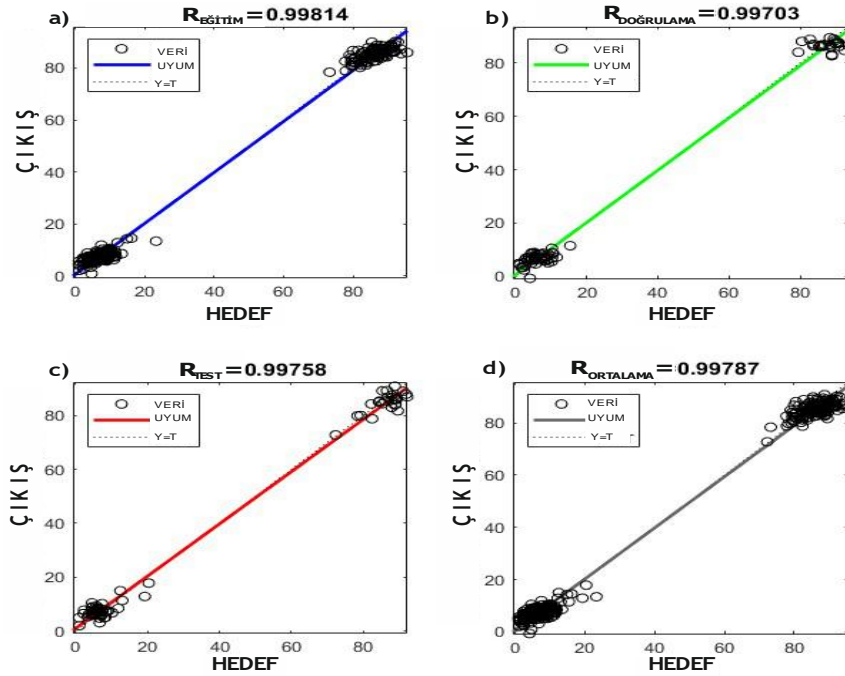
Şekil 7.8. İleri yönlü algoritmadaki 150 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-2

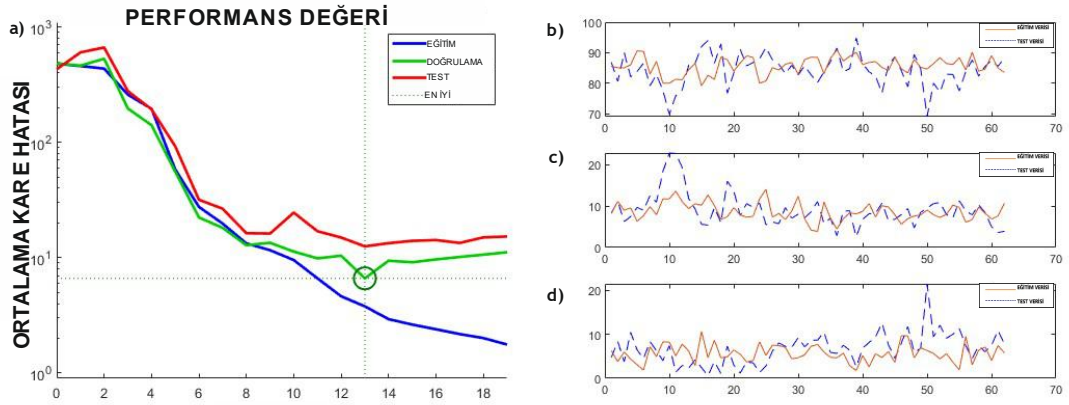
İleri yönlü çok katmanlı algılayıcı algoritması ile 170 giriş verisi ve 62 test verisi kullanılarak yapılan model için **sırasıyla 10, 20, 30, 40** adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.9.- 7.16. 'da verilmiştir.



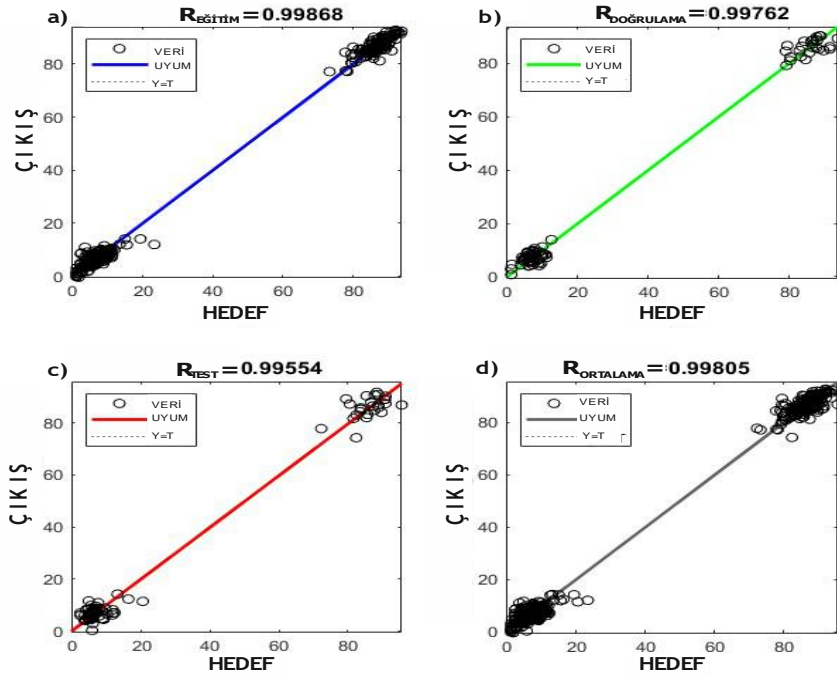
Şekil 7.9. İleri yönlü çok katmanlı algılayıcı algoritması için 170 eğitim verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



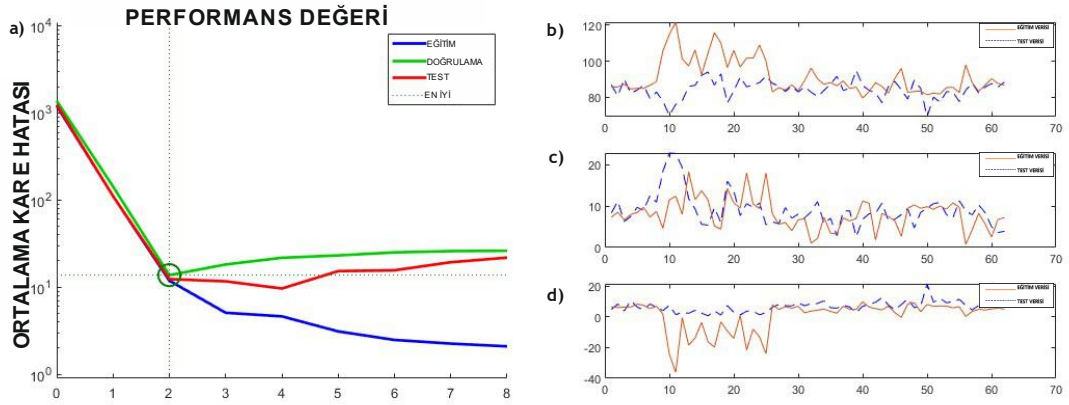
Şekil 7.10. İleri yönlü çok katmanlı algılayıcı algoritması için 170 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



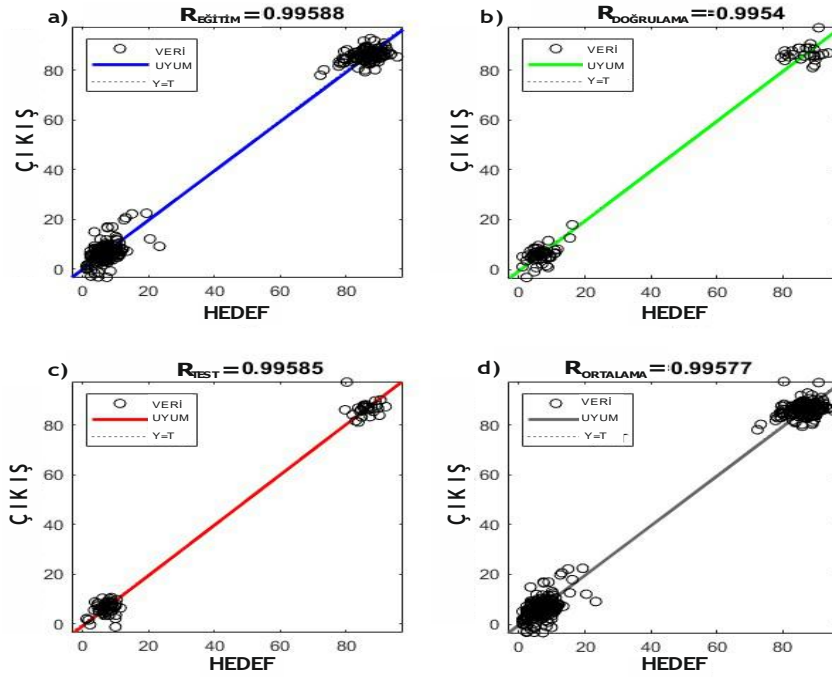
Şekil 7.11. İleri yönlü çok katmanlı algoritmda 170 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



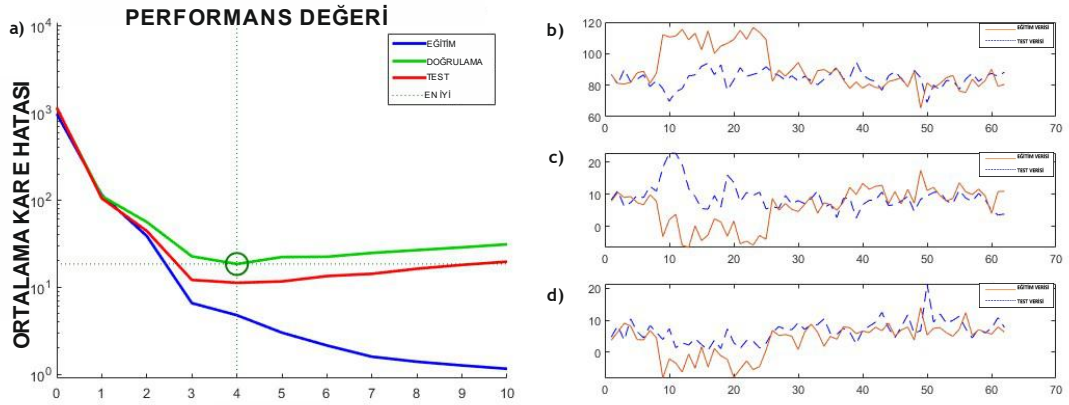
Şekil 7.12. İleri yönlü çok katmanlı algoritmda 170 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



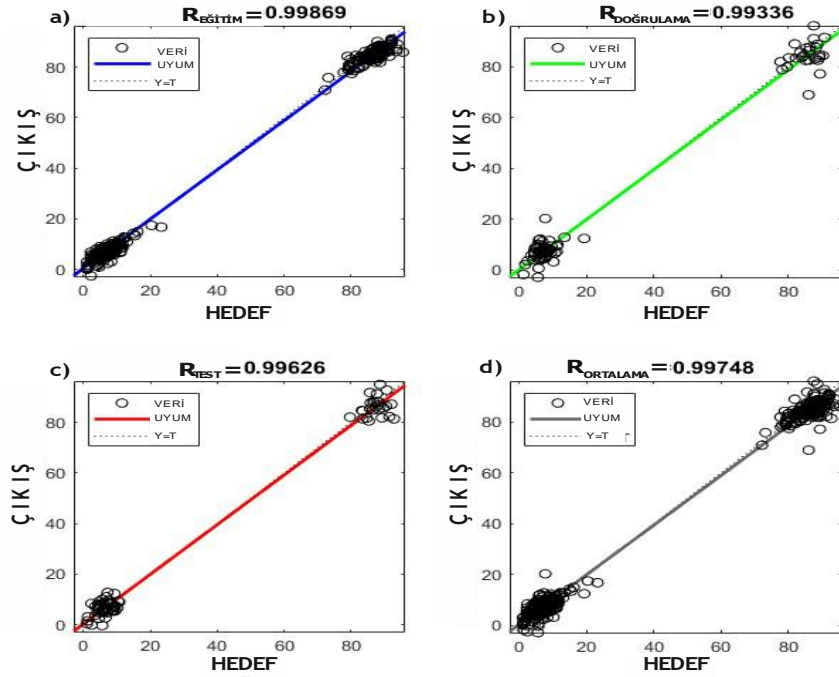
Şekil 7.13. İleri yönlü çok katmanlı algoritmda 170 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseraleri için gerçek ve tahmin verisi grafiğidir



Şekil 7.14. İleri yönlü çok katmanlı algoritmda 170 eğitim verisi ve 30 gizli katman için regresyon değerleri a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



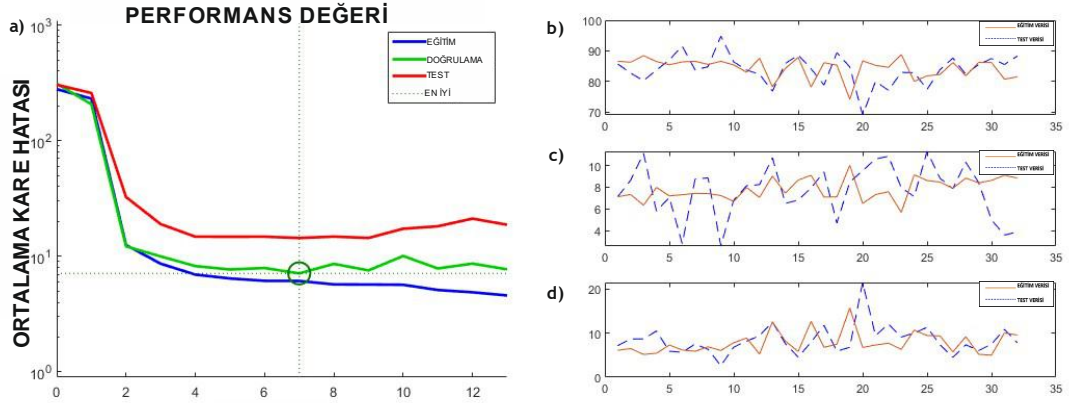
Şekil 7.15. İleri yönlü çok katmanlı algoritmda 170 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



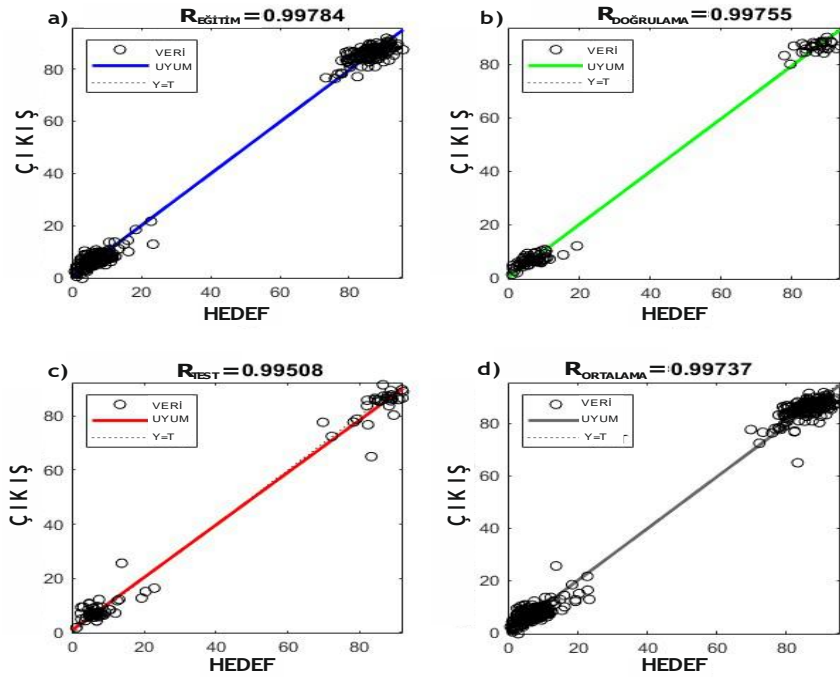
Şekil 7.16. İleri yönlü çok katmanlı algoritmda 170 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-3

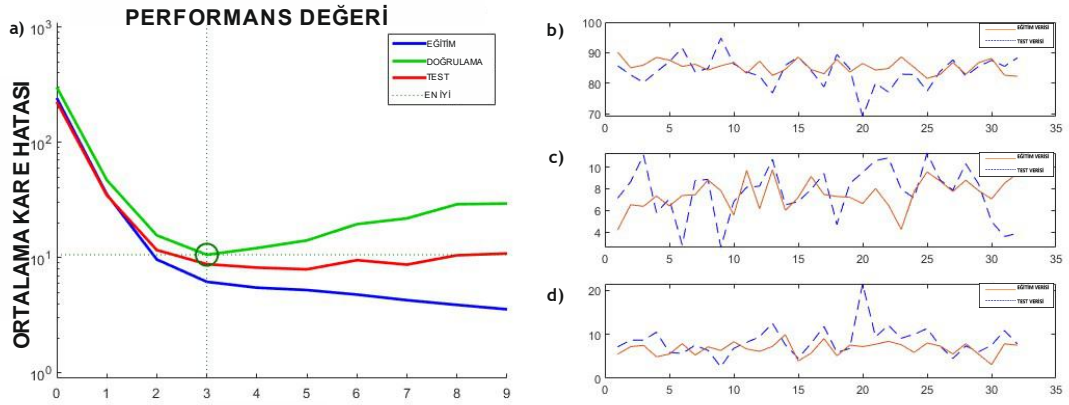
İleri yönlü çok katmanlı algılayıcı algoritması ile 200 giriş verisi ve 32 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30, 40 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.17.-7.24.'da verilmiştir.



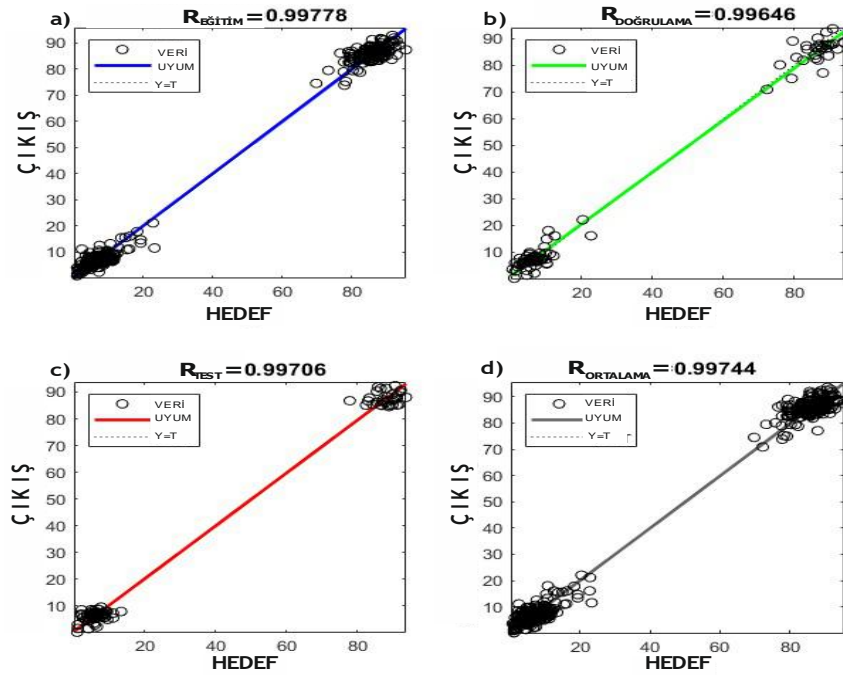
Şekil 7.17. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



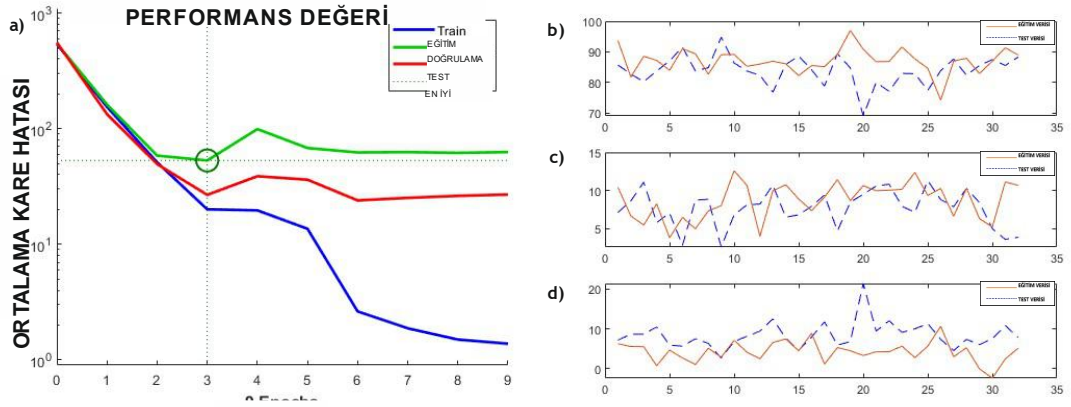
Şekil 7.18. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



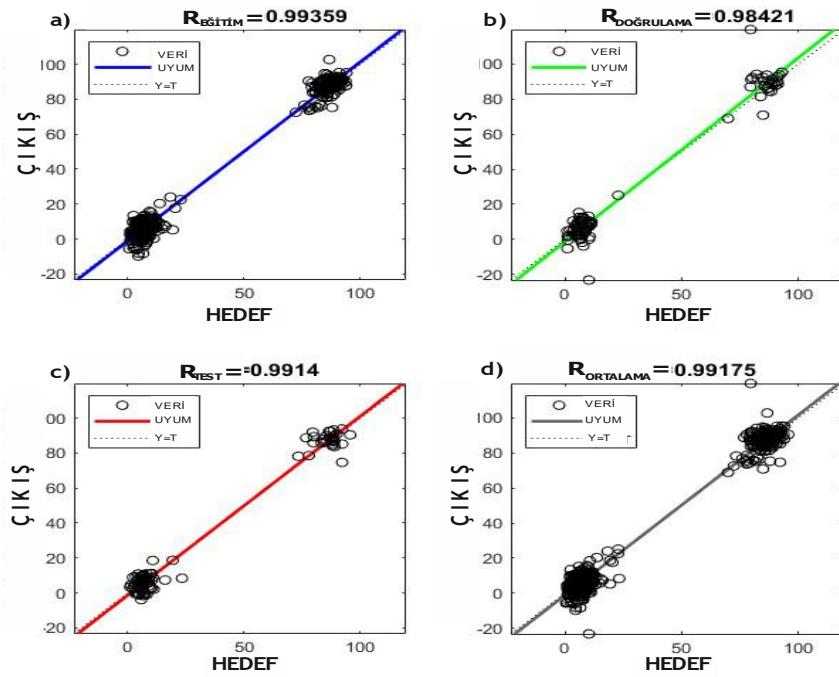
Şekil 7.19. İleri yönlü çok katmanlı algoritmda 200 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



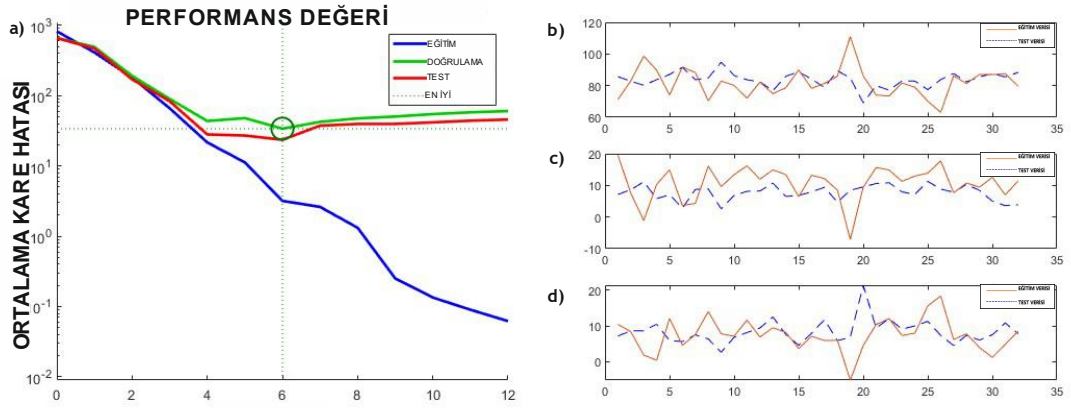
Şekil 7.20. İleri yönlü çok katmanlı algoritmda 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



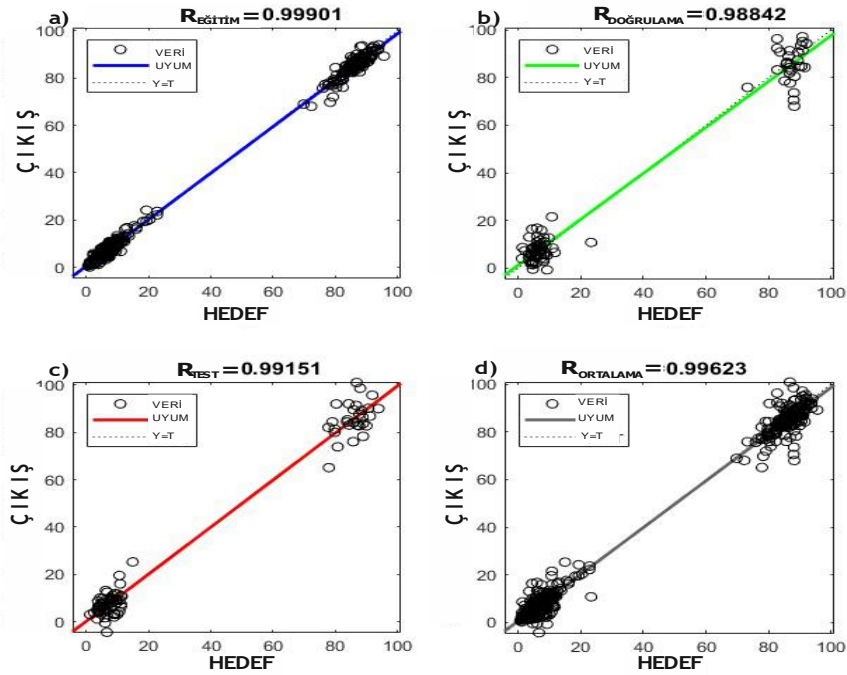
Şekil 7.21. İleri yönlü çok katmanlı algoritmada 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



Şekil 7.22. İleri yönlü çok katmanlı algoritmada 200 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



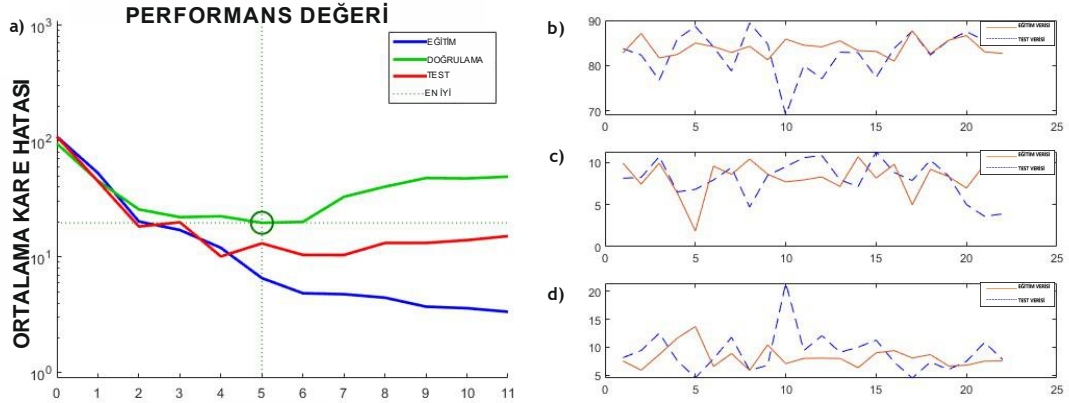
Şekil 7.23. İleri yönlü çok katmanlı algoritmda 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hümunit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



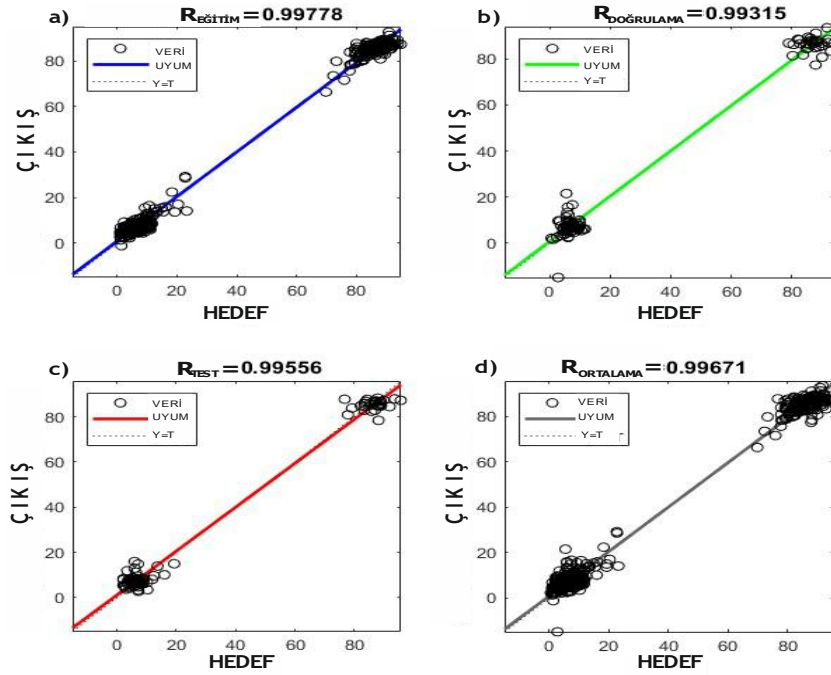
Şekil 7.24. İleri yönlü çok katmanlı algoritmda 200 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-4

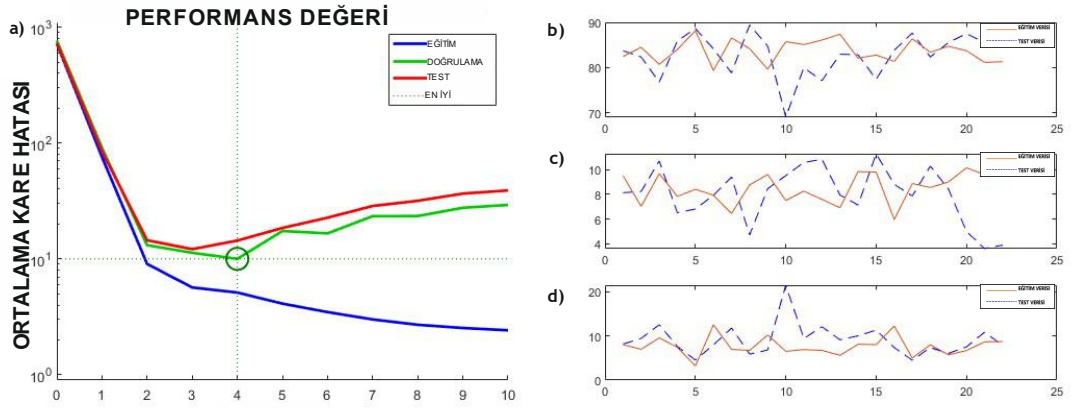
İleri yönlü çok katmanlı algılayıcı algoritması ile 210 giriş verisi ve 32 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.25-7.30'da verilmiştir.



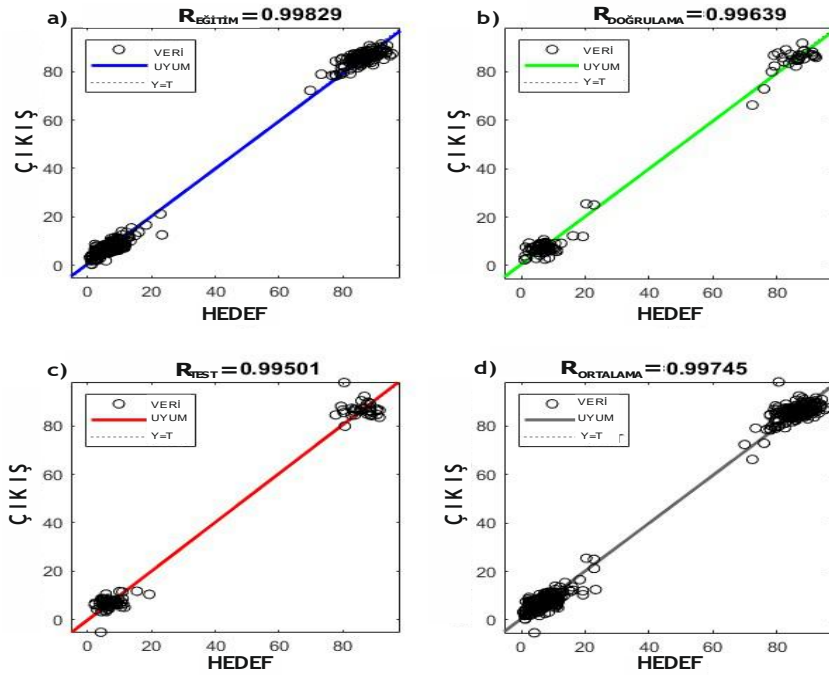
Şekil 7.25. İleri yönlü çok katmanlı algoritmada 210 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



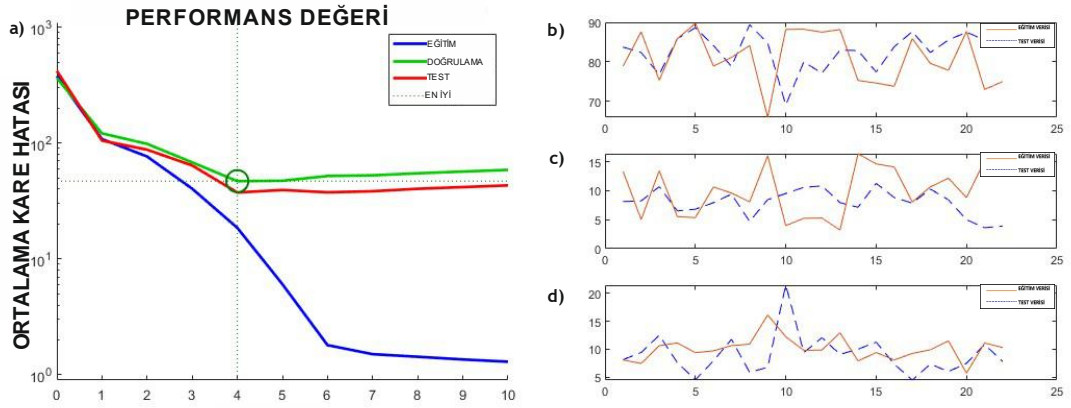
Şekil 7.26. İleri yönlü çok katmanlı algoritmada 210 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



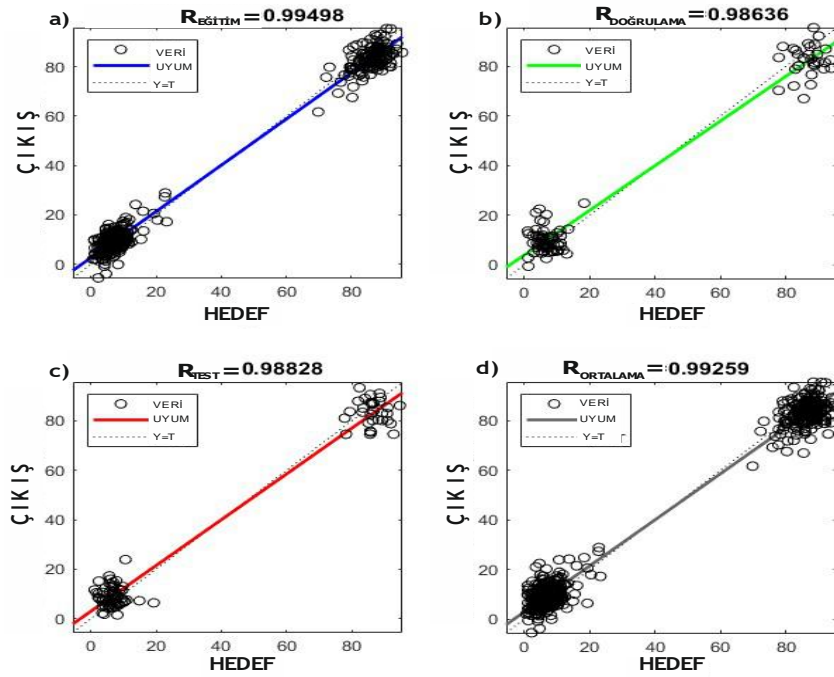
Şekil 7.27. İleri yönlü çok katmanlı algoritmda 210 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



Şekil 7.28. İleri yönlü çok katmanlı algoritmda 210 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



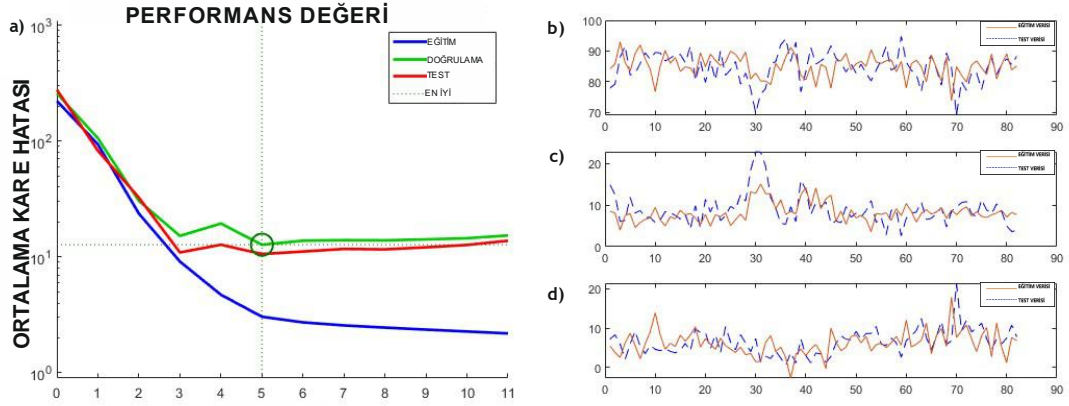
Şekil 7.29. İleri yönlü çok katmanlı algoritmda 210 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinite d) inertinite maserali için gerçek ve tahmin verisi grafiğidir



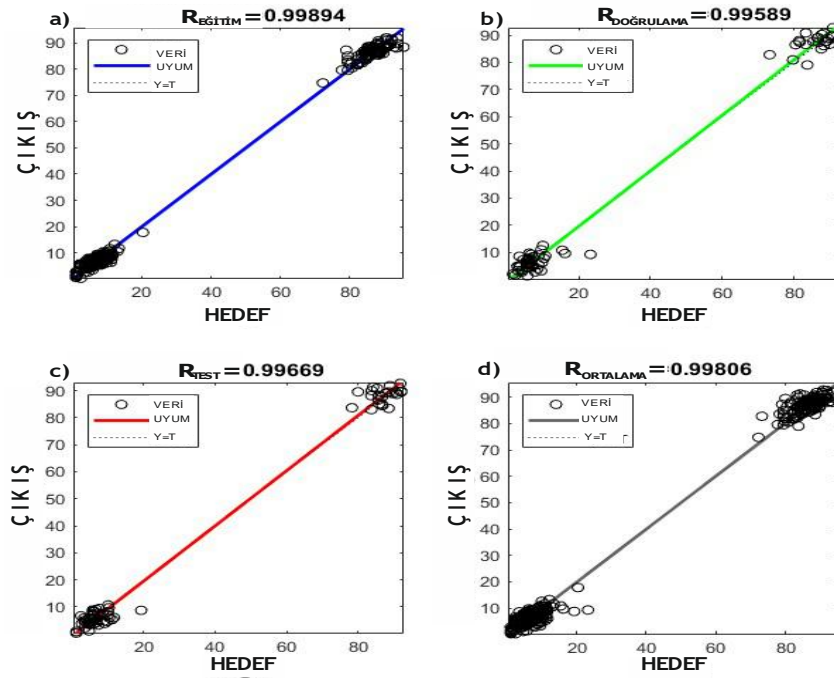
Şekil 7.30. İleri yönlü çok katmanlı algoritmda 210 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-5

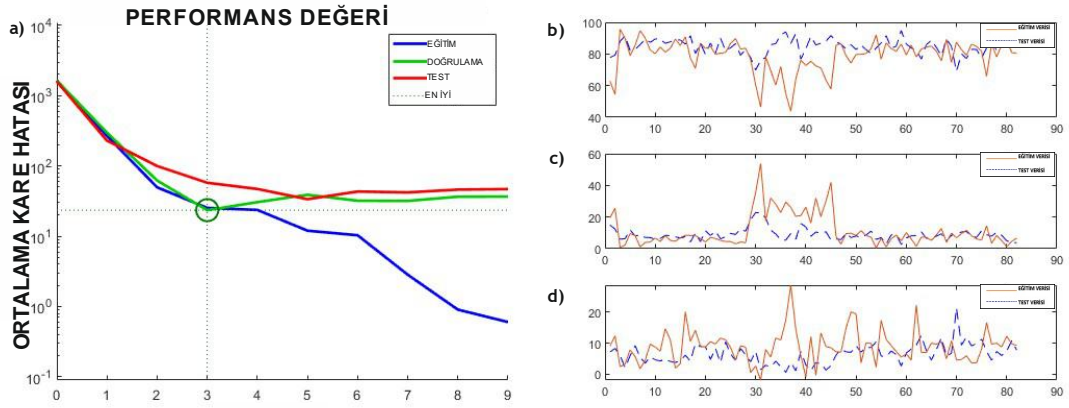
Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 82 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30, 40 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.31-7.38 'da verilmiştir.



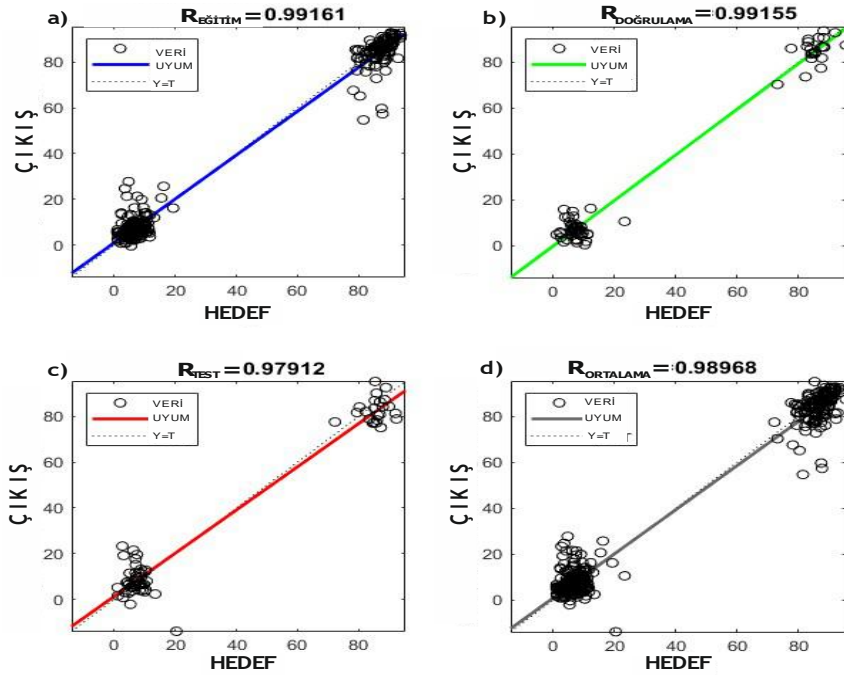
Şekil 7.31. Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



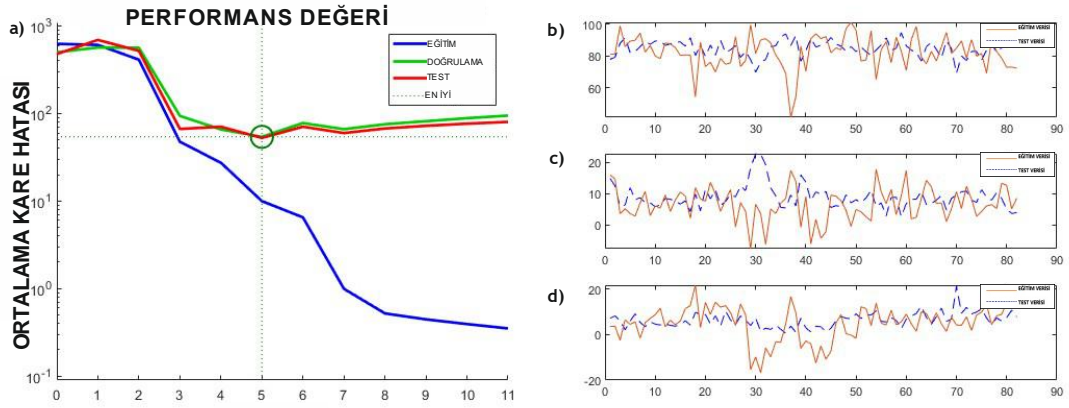
Şekil 7.32. Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



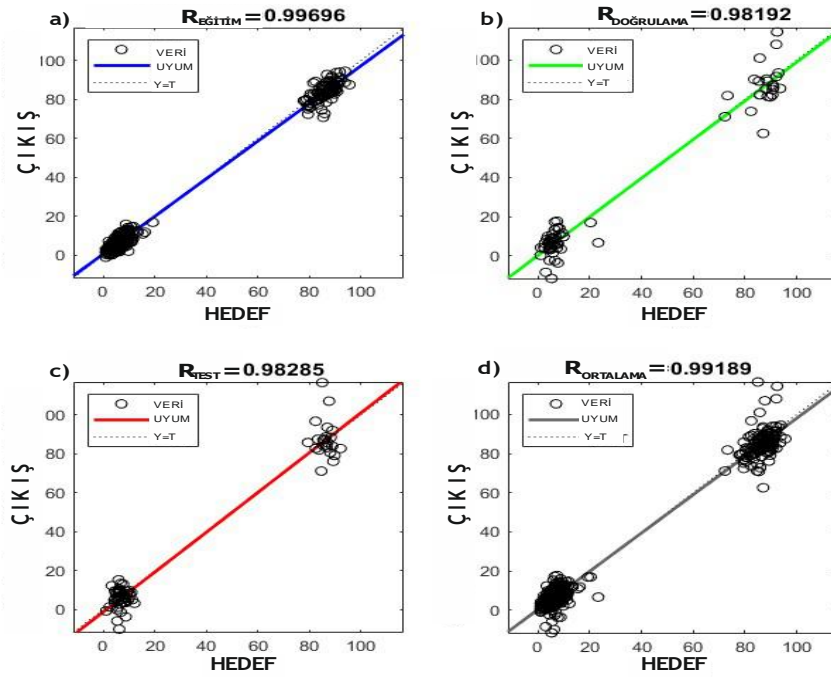
Şekil 7.33. Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



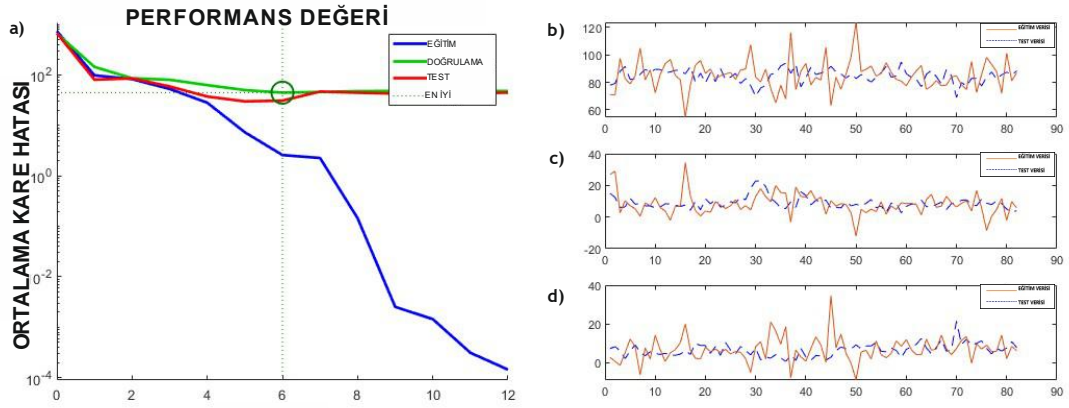
Şekil 7.34. Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



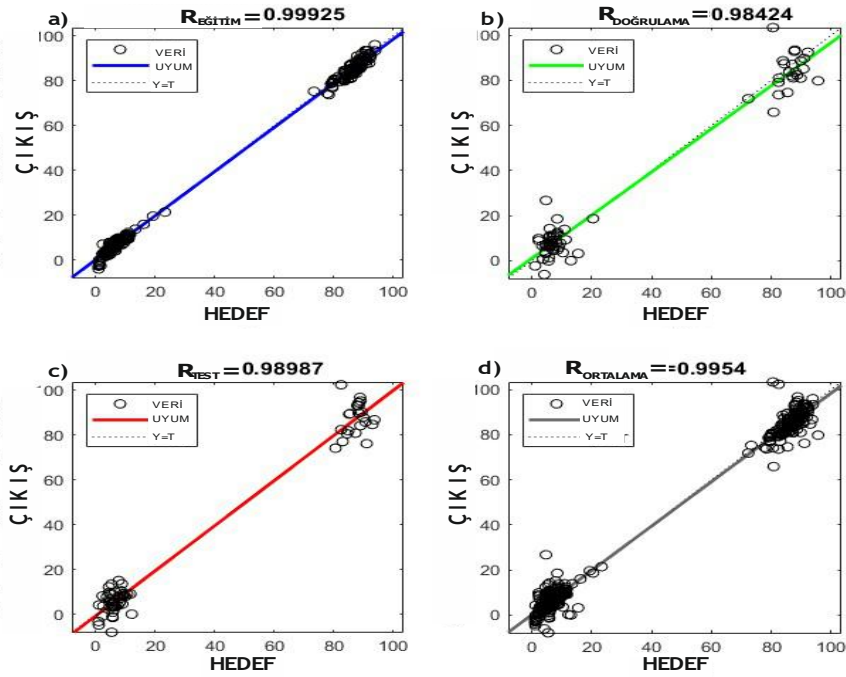
Şekil 7.35. Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



Şekil 7.36. Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



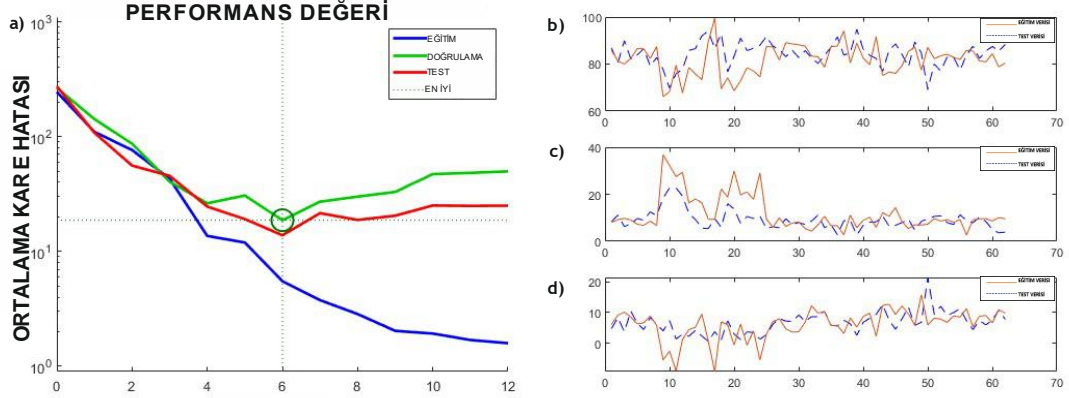
Şekil 7.37. Kaskad ileri yönlü algılayıcı algoritması ile 150 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



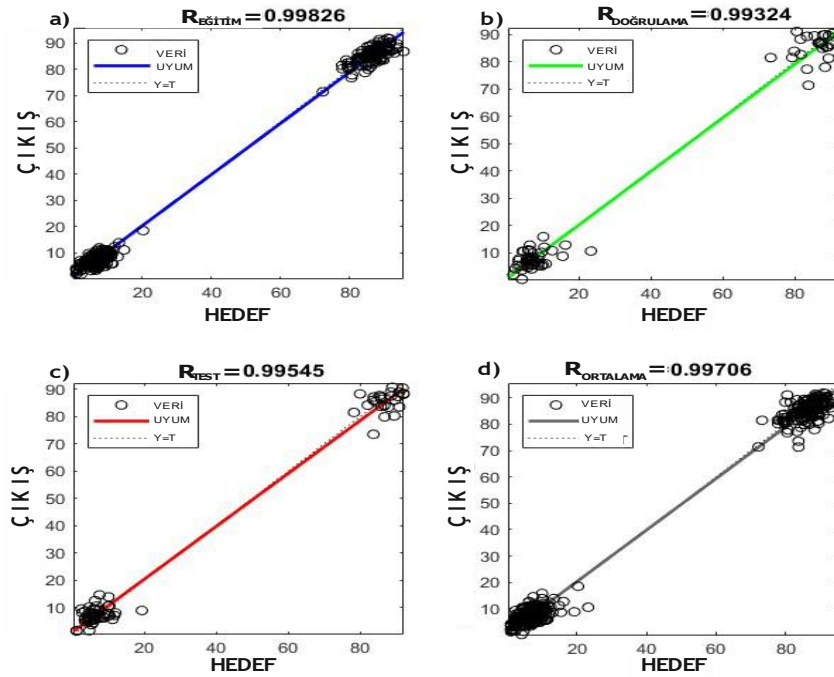
Şekil 7.38. Kaskad ileri yönlü algılayıcı algoritması ile 150 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-6

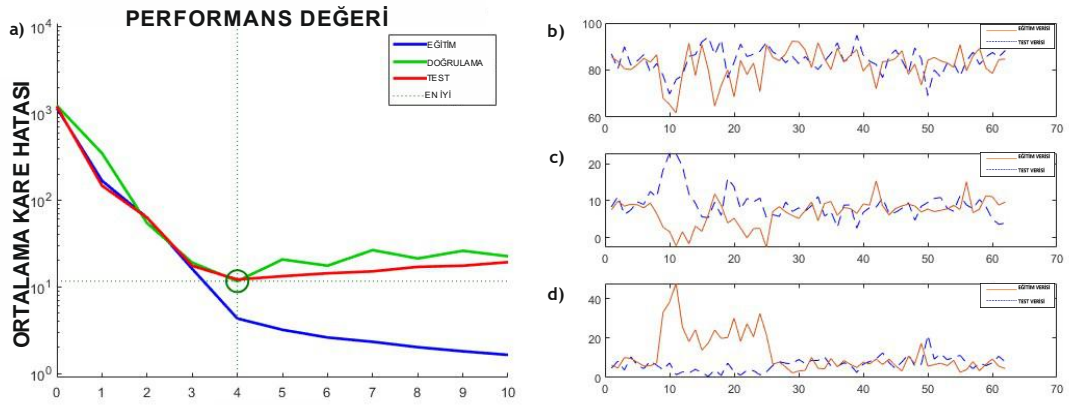
Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 62 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30, 40 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.39-7.46'da verilmiştir



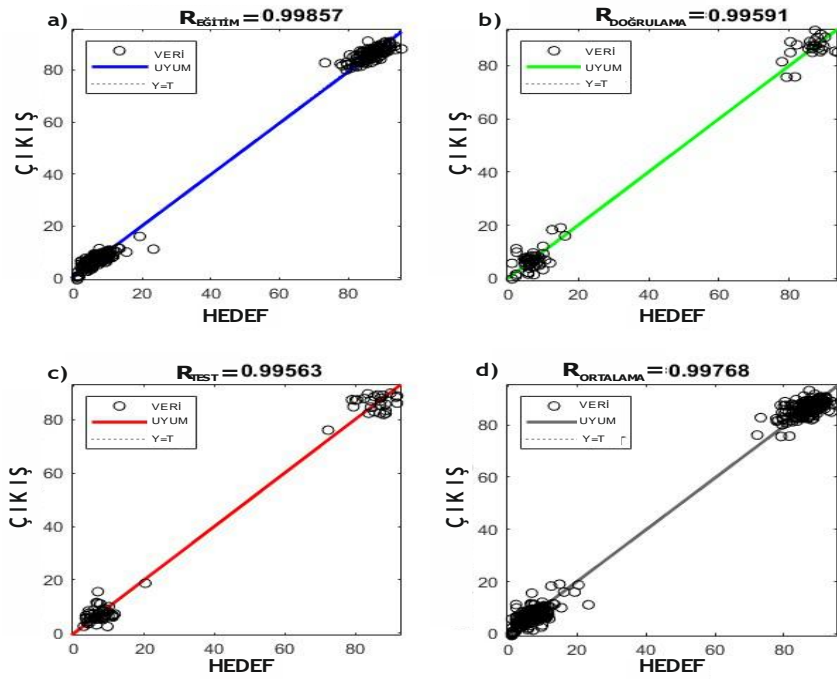
Şekil 7.39. Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



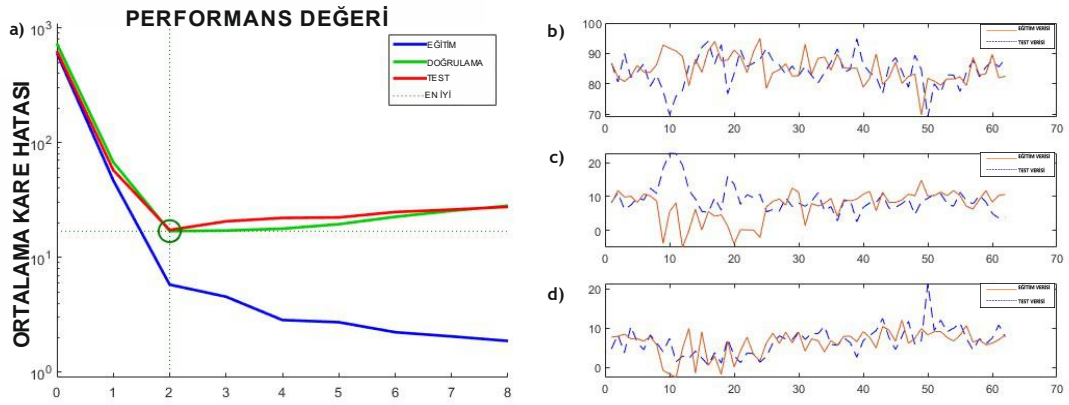
Şekil 7.40. Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



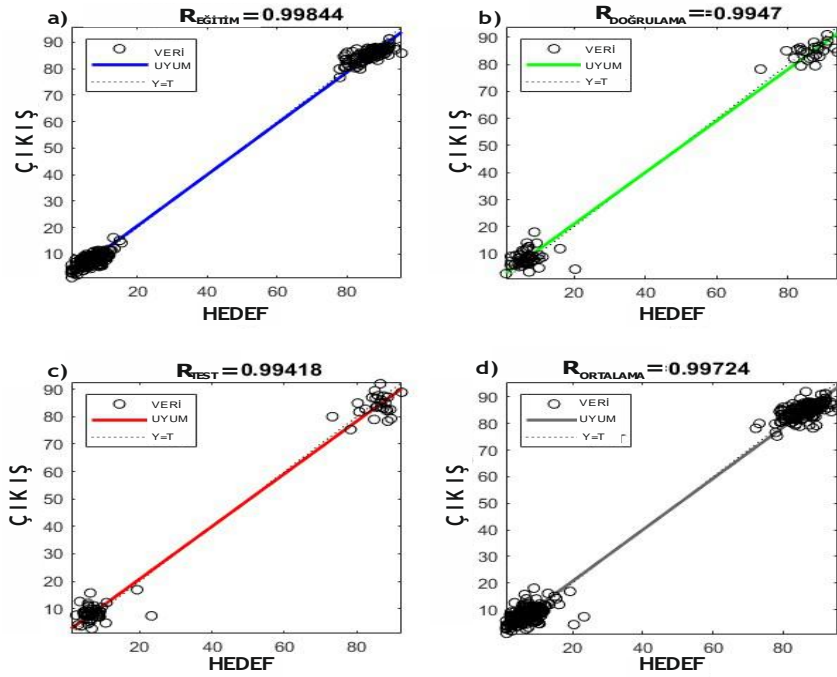
Şekil 7.41. Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



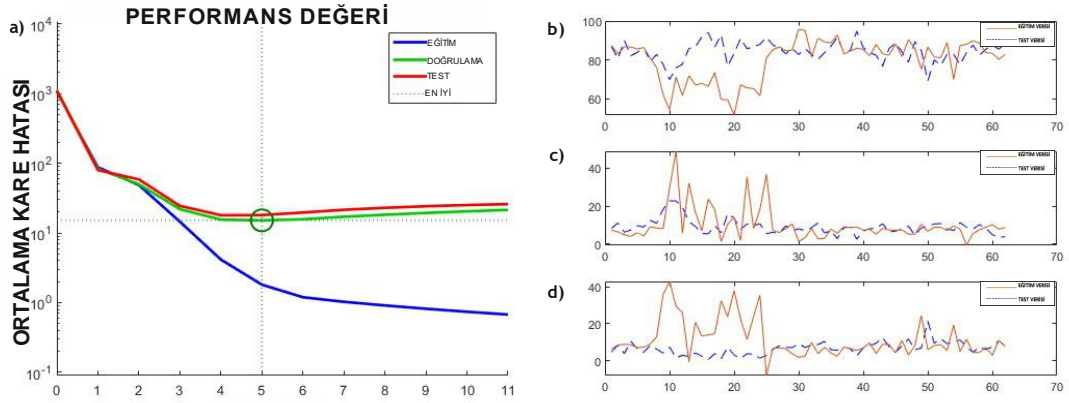
Şekil 7.42. Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



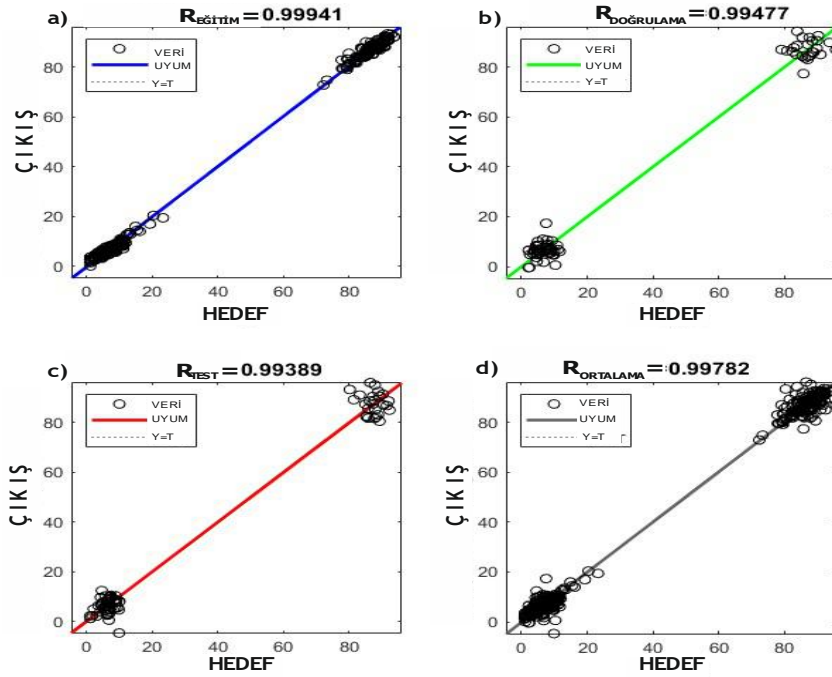
Şekil 7.43. Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



Şekil 7.44. Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



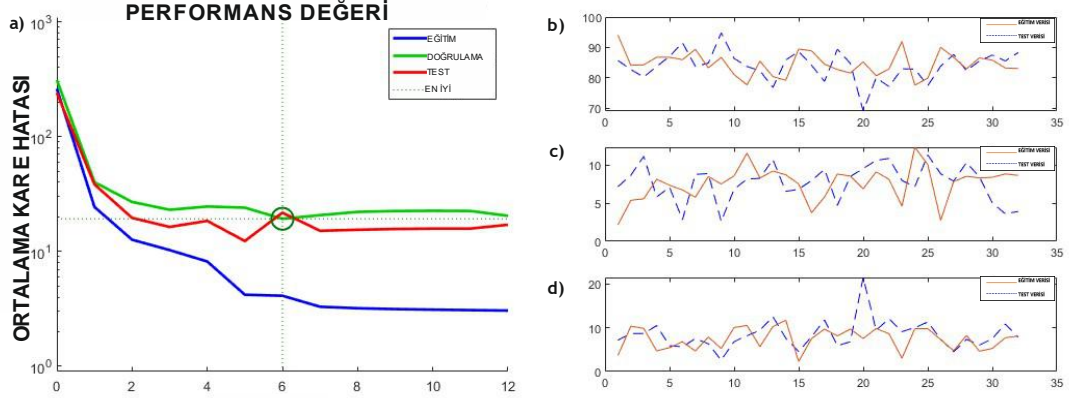
Şekil 7.45. Kaskad ileri yönlü algılayıcı algoritması ile 170 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



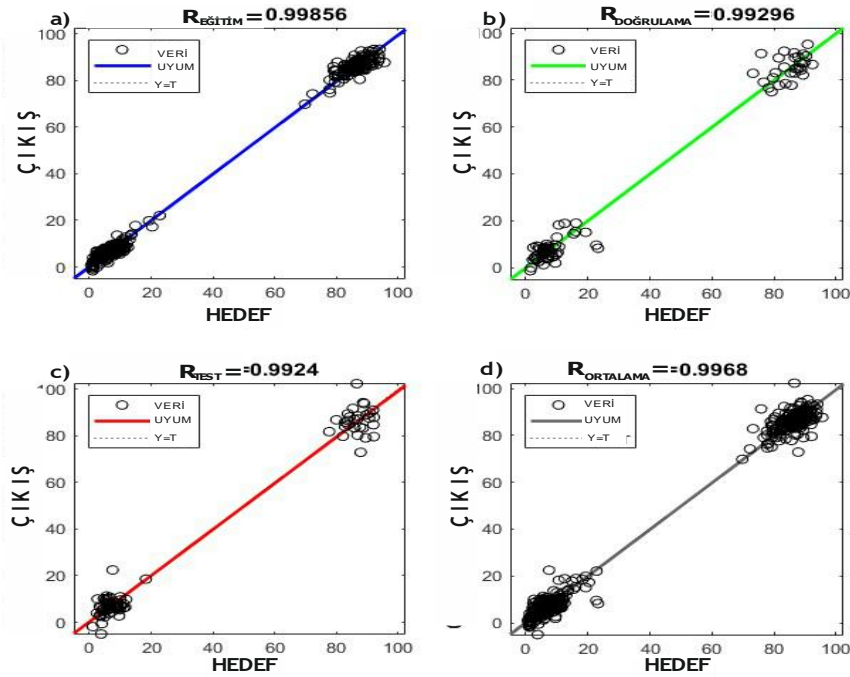
Şekil 7.46. Kaskad ileri yönlü algılayıcı algoritması ile 170 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-7

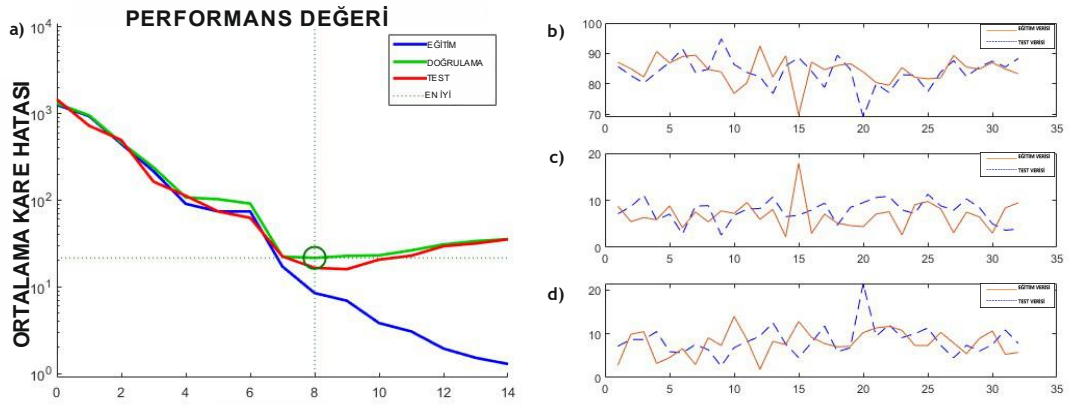
Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 32 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30, 40 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.47 -7.54 'da verilmiştir



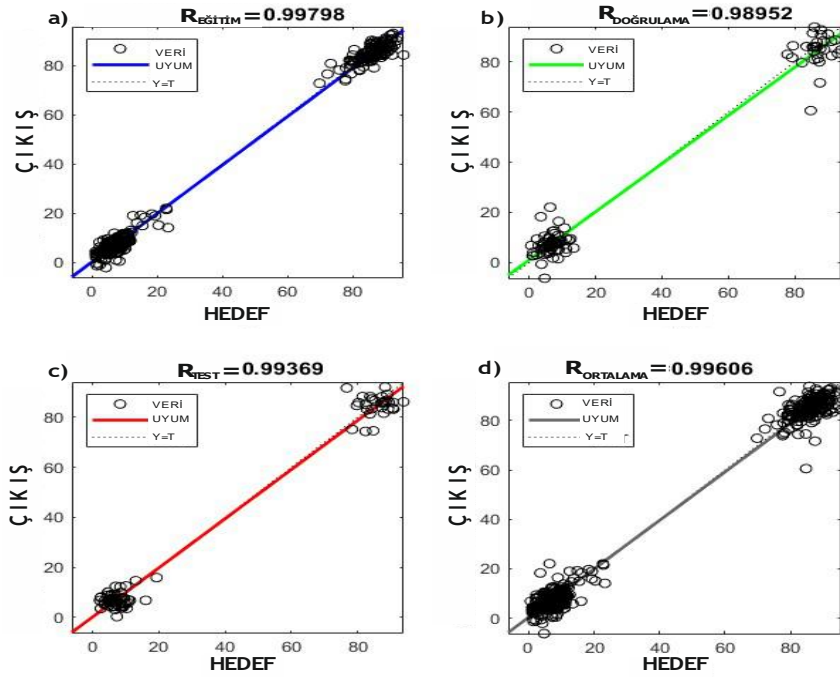
Şekil 7.47. Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



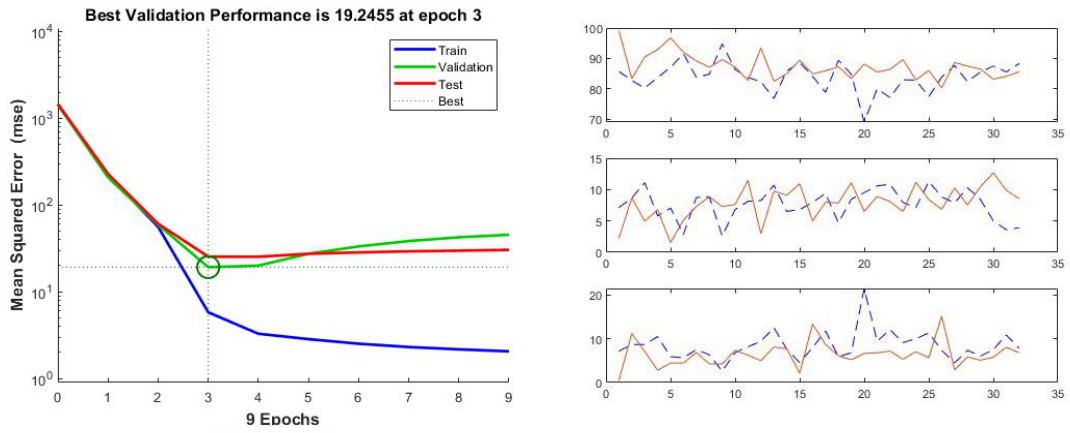
Şekil 7.48. Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



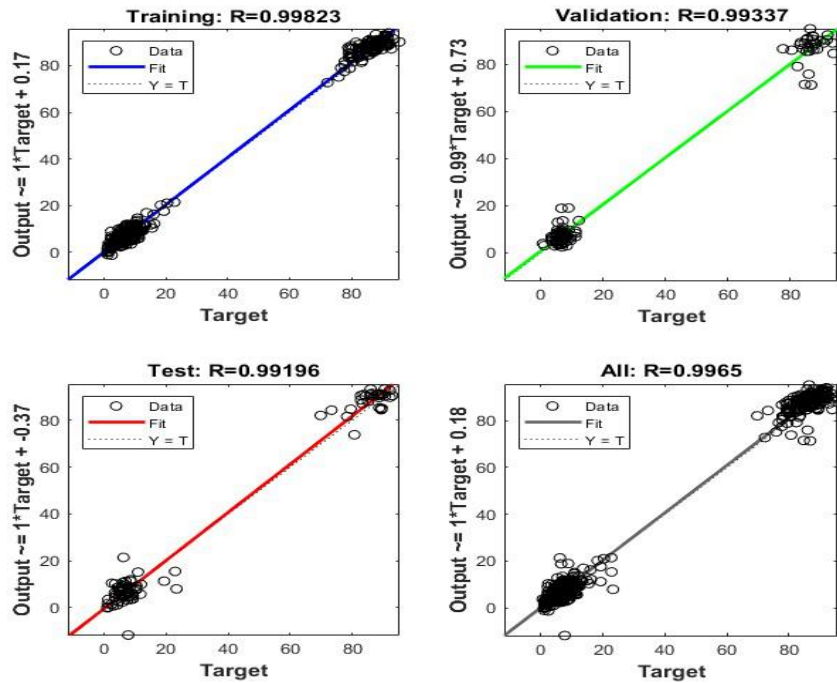
Şekil 7.49. Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



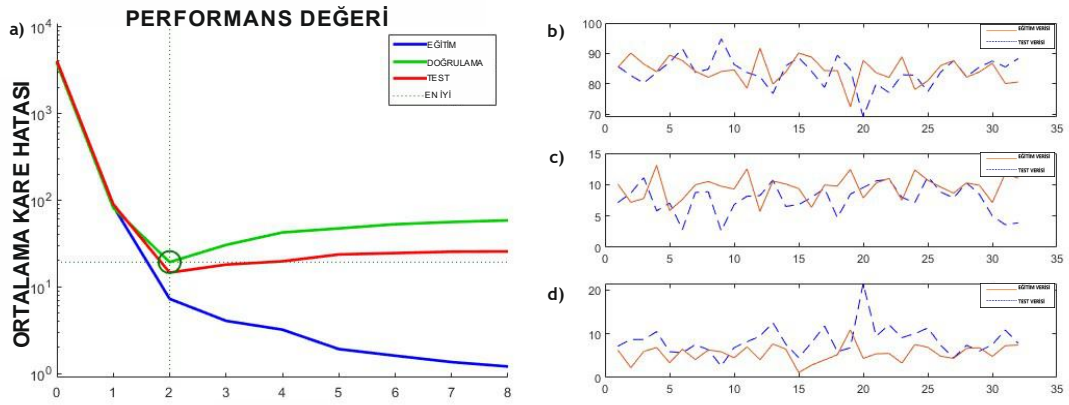
Şekil 7.50. Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



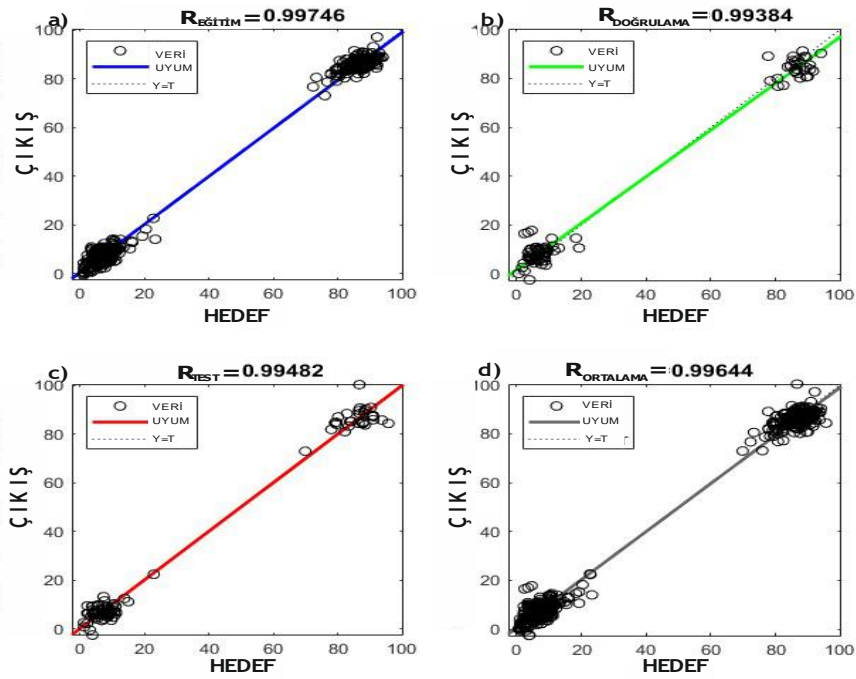
Şekil 7.51. Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) lityum d) inertite maserale için gerçek ve tahmin verisi grafiğidir



Şekil 7.52. Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



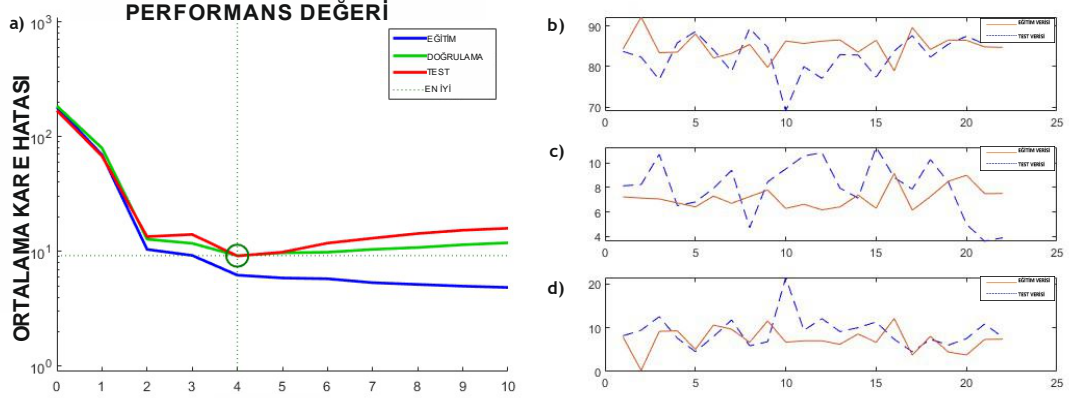
Şekil 7.53. Kaskad ileri yönlü algılayıcı algoritması ile 200 giriş verisi ve 40 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



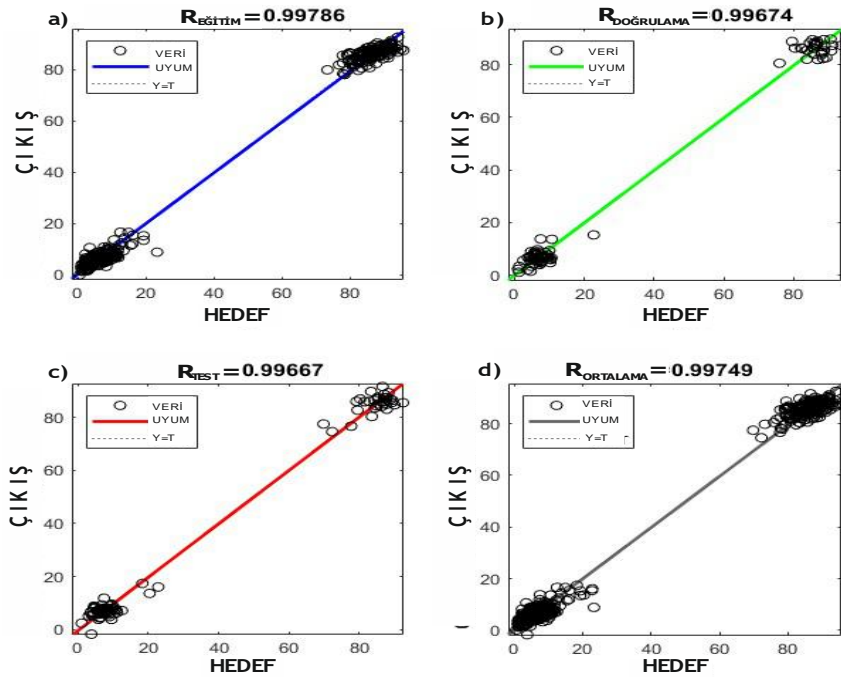
Şekil 7.54. Kaskad ileri yönlü algılayıcı algoritması ile 200 eğitim verisi ve 40 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-8

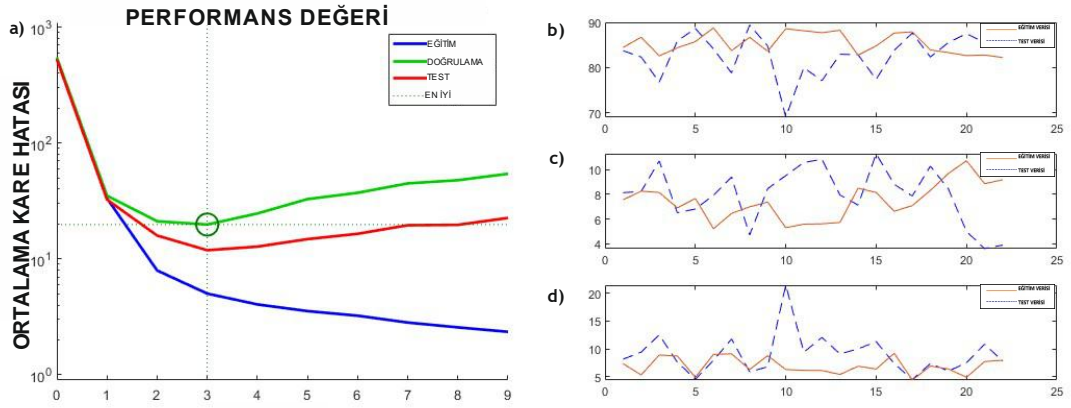
Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 22 test verisi kullanılarak yapılan model için sırasıyla 10, 20, 30 adet gizli katman kullanılarak MATLAB üzerinden alınan, görünen ile tahmin verisi kıyaslaması, ortalama kare hatası grafiği ve regresyon grafikleri Şekil 7.55 -7.60 'da verilmiştir



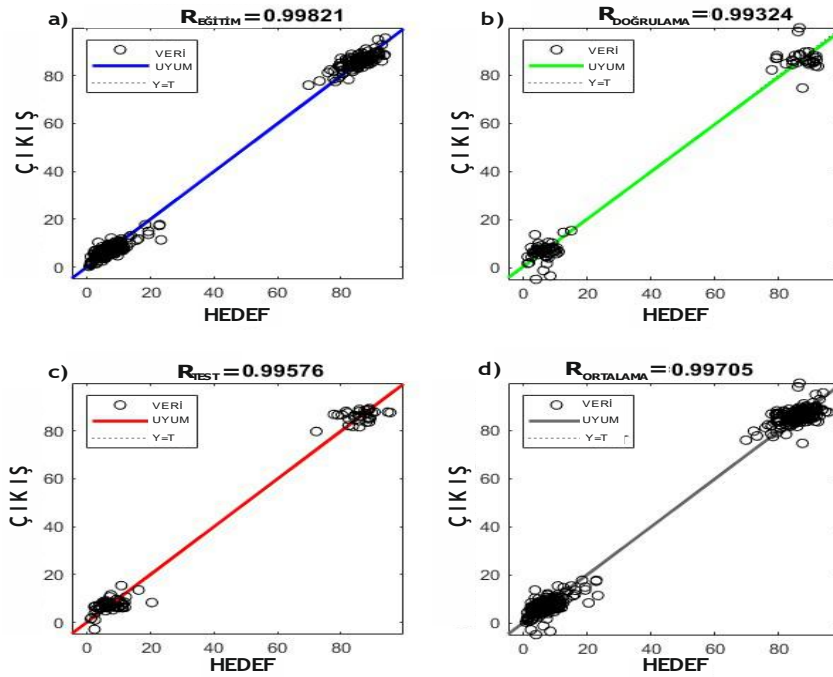
Şekil 7.55. Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 10 gizli katman için a) Ortalama kare hatası b) hüminit c) liptinit d) inertinit maserali için gerçek ve tahmin verisi grafiğidir



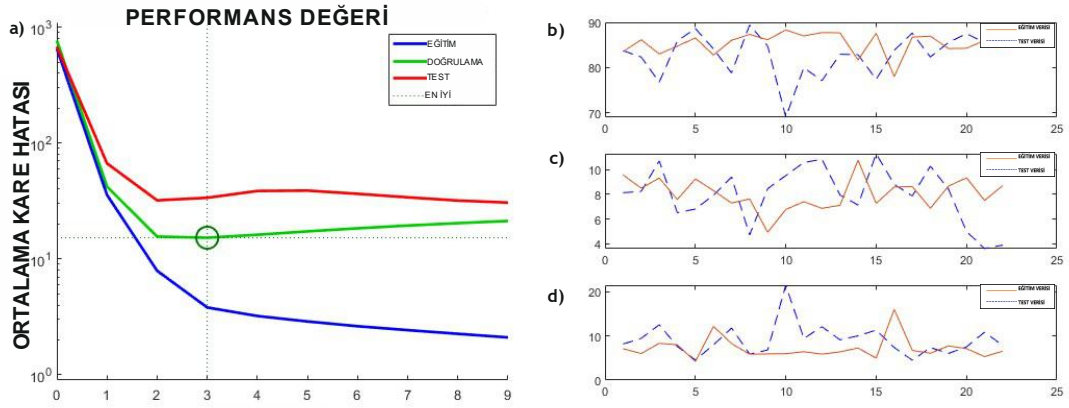
Şekil 7.56. Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 10 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



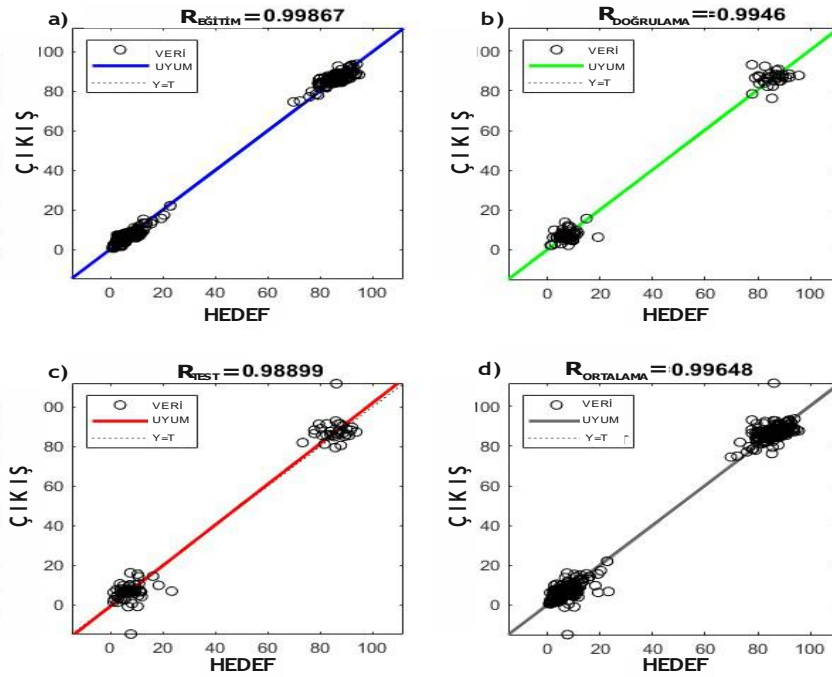
Şekil 7.57. Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 20 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



Şekil 7.58. Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 20 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği



Şekil 7.59. Kaskad ileri yönlü algılayıcı algoritması ile 210 giriş verisi ve 30 gizli katman için a) Ortalama kare hatası b) hüminite c) liptinit d) inertinit maseralı için gerçek ve tahmin verisi grafiğidir



Şekil 7.60. Kaskad ileri yönlü algılayıcı algoritması ile 210 eğitim verisi ve 30 gizli katman için regresyon değerleri. a): Eğitim regresyon grafiği; b): Hata doğrulama regresyon grafiği; c) Test verileri regresyon grafiği; d): Ortalama regresyon grafiği

EK-9

Çizelge 7.1. Türkiye'deki bazı linyit kömürlerinin analiz verileri (Tuncalı vd. 2002)

Linyit Sahaları	Kısa Analiz (%)				Kalorifik Değer (kcal/kg)	Elementel Analiz (%)					Maseral Analizi (%)			Yaş
	Nem	Kül	Uçucu Madde	Sabit Karbon		C (%)	H (%)	N (%)	O (%)	S (%)	Hüminit	Liptinit	İnertinit	
	Havada Kuru Baz	Kuru Baz	Kuru Baz	Kuru Baz		Kuru Külsüz Baz	Kuru Külsüz Baz	Kuru Külsüz Baz	Kuru Külsüz Baz	Kuru Külsüz Baz				
Edirne	9,20	31,75	35,06	33,19	3958,00	66,31	5,16	2,26	14,50	11,77	86,25	5,00	8,75	E. Oligosen
Edirne	12,40	31,45	36,07	32,48	3962,00	63,66	5,46	1,52	26,71	2,65	86,52	6,74	6,74	E. Oligosen
Edirne	11,60	14,31	43,27	42,42	5139,00	66,13	5,24	1,93	26,58	0,12	91,86	3,49	4,65	E. Oligosen
Edirne	8,00	15,11	36,00	48,89	5642,00	71,20	5,22	1,65	21,01	0,92	91,86	4,65	3,49	E. Oligosen
Edirne	11,60	35,79	29,47	34,74	4007,00	68,60	5,36	1,74	20,83	3,47	89,77	5,68	4,55	E. Oligosen
Edirne	9,60	37,72	28,75	33,53	3762,00	67,50	5,33	1,50	20,63	5,04	90,91	3,90	5,19	E. Oligosen
Edirne	9,06	28,15	33,81	38,04	4420,00	69,24	4,87	2,79	17,62	5,48	87,21	5,81	6,98	E. Oligosen
Edirne	11,69	16,62	38,11	45,27	5051,00	69,65	4,52	2,50	22,28	1,05	88,76	6,74	4,49	E. Oligosen
Edirne	8,23	29,69	33,16	37,15	4282,00	67,56	4,84	3,08	19,69	4,83	84,15	8,54	7,32	E. Oligosen
Edirne	7,89	31,36	30,36	38,28	4135,00	68,79	4,56	2,34	20,91	3,40	86,75	6,02	7,23	E. Oligosen
Edirne	7,92	25,72	34,61	39,67	4626,00	69,59	4,90	2,81	18,77	3,93	79,01	9,88	11,11	E. Oligosen
Edirne	8,44	25,48	32,84	41,68	4261,00	68,42	5,55	5,24	15,97	4,82	80,72	10,84	8,43	E. Oligosen
Edirne	8,31	22,18	33,93	43,89	4860,00	70,01	4,75	4,93	15,48	4,83	80,52	11,69	7,79	E. Oligosen
Edirne	7,65	48,78	25,37	25,85	2852,00	64,69	5,13	2,13	26,73	1,32	79,49	11,54	8,97	E. Oligosen
Edirne	7,65	42,75	29,53	27,72	3260,00	64,95	4,82	1,87	26,89	1,47	79,76	10,71	9,52	E. Oligosen
Edirne	8,44	34,50	30,80	34,70	3976,00	69,10	5,34	1,48	22,32	1,76	83,53	9,41	7,06	E. Oligosen
Edirne	9,63	28,91	30,30	40,79	4309,00	70,98	5,01	5,57	18,06	0,38	86,05	6,98	6,98	E. Oligosen
Edirne	8,64	38,42	28,13	33,45	3639,00	68,49	5,15	1,48	24,58	0,30	82,35	8,24	9,41	E. Oligosen
Edirne	12,19	20,87	30,25	48,88	5852,00	70,61	4,59	5,01	19,38	0,41	90,80	4,60	4,60	E. Oligosen
Edirne	15,37	15,81	31,90	52,29	5133,00	68,56	4,59	1,88	21,88	3,09	86,52	6,74	6,74	E. Oligosen
Edirne	6,52	36,87	26,50	36,63	3919,00	70,62	4,95	1,60	20,44	2,39	87,80	6,10	6,10	E. Oligosen
Edirne	7,65	19,98	34,36	45,66	5319,00	76,01	5,22	1,94	15,69	1,14	83,33	7,14	9,52	E. Oligosen
Edirne	12,31	19,66	41,25	39,09	4791,00	68,50	4,61	1,77	24,27	0,85	82,93	8,54	8,54	E. Oligosen
Edirne	11,67	19,18	42,41	38,41	4738,00	67,22	4,66	1,37	26,49	0,26	77,78	11,11	11,11	E. Oligosen
İstanbul	7,60	17,53	44,40	38,07	4779,00	63,07	5,45	0,59	22,94	7,95	91,01	2,25	6,74	E. Oligosen
İstanbul	8,40	13,16	49,61	37,23	5535,00	68,32	5,53	0,79	25,28	0,08	86,90	5,95	7,14	E. Oligosen
İstanbul	10,20	12,69	44,59	42,72	5333,00	67,82	5,47	0,66	25,34	0,71	85,14	8,11	6,76	E. Oligosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Istanbul	12,20	12,81	48,91	38,28	4517,00	60,13	4,62	1,27	24,74	9,24	83,82	10,29	5,88	Miyosen
Kırklareli	8,20	14,93	45,64	39,43	5048,00	63,38	5,51	1,02	28,10	1,99	81,52	9,78	8,70	E. Oligosen
Kırklareli	9,40	25,55	41,35	33,10	4343,00	62,85	5,49	0,49	25,78	5,39	87,91	5,49	6,59	E. Oligosen
Kırklareli	8,80	25,22	41,39	33,39	4028,00	63,34	5,53	1,03	17,49	12,61	92,94	4,71	2,35	E. Oligosen
Kırklareli	14,00	18,86	45,01	36,13	5111,00	71,45	5,23	2,22	17,63	3,47	87,67	6,85	5,48	E. Oligosen
Tekirdağ	6,60	13,66	48,69	37,65	4916,00	64,11	5,47	1,12	29,06	0,24	88,10	5,95	5,95	E. Oligosen
Tekirdağ	8,20	24,65	40,96	34,39	4172,00	62,24	5,51	1,00	21,18	10,07	85,23	6,82	7,95	E. Oligosen
Tekirdağ	11,20	31,35	32,59	36,06	4102,00	67,42	5,27	2,41	22,38	2,52	87,65	4,94	7,41	E. Oligosen
Tekirdağ	14,40	14,77	37,61	47,62	5435,00	69,69	5,18	2,36	17,60	5,17	90,91	3,41	5,68	E. Oligosen
Tekirdağ	14,40	24,87	34,86	40,27	4614,00	69,51	5,21	2,63	20,61	2,04	87,80	3,66	8,54	E. Oligosen
Tekirdağ	13,20	28,00	34,41	37,59	4474,00	67,39	5,15	2,35	23,50	1,61	88,51	3,45	8,05	E. Oligosen
Tekirdağ	15,20	20,43	32,71	46,86	5188,00	72,07	5,14	2,09	18,55	2,15	92,13	4,49	3,37	E. Oligosen
Tekirdağ	9,20	23,48	38,28	38,24	4938,00	69,88	5,38	2,07	20,77	1,90	86,75	6,02	7,23	E. Oligosen
Tekirdağ	10,40	34,91	32,42	32,67	3925,00	65,53	5,40	1,75	25,58	1,74	89,77	4,55	5,68	E. Oligosen
Tekirdağ	9,20	24,26	35,29	40,45	4673,00	68,81	5,18	1,89	21,59	2,53	95,60	2,20	2,20	E. Oligosen
Tekirdağ	7,20	14,98	37,91	47,11	5381,00	68,76	5,22	2,12	23,03	0,87	92,13	3,37	4,49	E. Oligosen
Tekirdağ	11,20	19,26	38,21	42,53	4978,00	67,07	5,20	1,25	23,79	2,69	90,59	3,53	5,88	E. Oligosen
Tekirdağ	9,60	22,95	37,50	39,55	4757,00	66,20	5,30	1,46	25,42	1,62	86,36	5,68	7,95	E. Oligosen
Tekirdağ	14,00	15,95	39,22	44,83	5232,00	67,71	5,19	1,49	23,85	1,76	90,80	4,60	4,60	E. Oligosen
Tekirdağ	10,40	22,08	34,15	43,77	4913,00	69,55	5,16	1,17	22,88	1,24	86,54	5,77	7,69	E. Oligosen
Tekirdağ	10,00	22,61	34,03	43,36	4811,00	68,51	5,17	1,68	19,04	5,60	91,01	4,49	4,49	E. Oligosen
Tekirdağ	8,13	10,22	40,98	48,80	5760,00	71,15	4,97	1,33	20,49	2,06	88,37	5,81	5,81	E. Oligosen
Tekirdağ	11,20	11,59	36,28	52,13	5503,00	70,83	4,57	1,54	21,54	1,52	89,77	5,68	4,55	E. Oligosen
Tekirdağ	9,41	24,30	32,67	42,67	4638,00	69,69	4,62	1,76	22,85	1,08	82,02	10,11	7,87	E. Oligosen
Balıkesir	7,20	22,18	36,76	41,06	5061,00	69,23	5,44	1,12	23,94	0,27	90,91	5,68	3,41	G. Miyosen
Balıkesir	8,60	26,15	33,72	40,13	4738,00	71,63	5,39	0,88	22,05	0,05	87,06	8,24	4,71	G. Miyosen
Balıkesir	7,40	12,59	39,76	47,65	5920,00	73,08	5,44	1,48	17,13	2,87	93,75	5,21	1,04	G. Miyosen
Balıkesir	8,20	43,77	29,79	26,44	3188,00	65,28	5,42	0,48	26,19	2,63	80,30	9,09	10,61	G. Miyosen
Balıkesir	4,40	43,31	26,50	30,19	3456,00	67,32	5,50	1,72	21,42	4,04	85,92	8,45	5,63	G. Miyosen
Balıkesir	6,80	27,48	33,39	39,13	4679,00	70,13	5,03	1,83	12,76	10,25	86,96	4,35	8,70	G. Miyosen
Balıkesir	10,00	30,08	35,40	34,52	4299,00	68,81	5,37	1,46	22,34	2,02	84,29	7,14	8,57	G. Miyosen
Balıkesir	4,40	45,66	25,08	29,26	3395,00	68,18	4,83	4,27	13,56	9,16	88,57	5,71	5,71	G. Miyosen
Balıkesir	1,60	34,47	24,09	41,44	4986,00	71,22	5,38	4,33	11,56	7,51	88,06	7,46	4,48	G. Miyosen
Balıkesir	8,40	30,79	34,37	34,84	4129,00	65,28	4,56	3,53	19,63	7,00	89,29	5,95	4,76	G. Miyosen
Balıkesir	7,20	32,68	34,01	33,31	4309,00	71,59	5,06	2,34	17,81	3,20	85,71	7,79	6,49	G. Miyosen
Balıkesir	5,40	19,76	42,76	37,48	4329,00	61,20	4,32	0,29	26,62	7,57	83,75	6,25	10,00	G. Miyosen
Bursa	10,20	10,13	46,33	43,54	5425,00	71,61	4,97	3,02	18,05	2,35	88,76	5,62	5,62	E. Miyosen
Bursa	11,40	36,66	32,54	30,80	4021,00	68,98	5,52	0,80	24,02	0,68	84,62	7,69	7,69	G. Miyosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Bursa	8,20	31,97	36,93	31,10	4155,00	67,77	5,56	0,77	22,90	3,00	85,39	5,62	8,99	E. Miyosen
Bursa	6,00	48,78	26,60	24,62	2935,00	62,73	5,30	1,41	24,87	5,69	85,39	5,62	8,99	E. Miyosen
Bursa	6,40	50,75	26,60	22,65	2765,00	62,28	5,31	1,24	27,38	3,79	88,71	4,84	6,45	E. Miyosen
Bursa	5,60	22,29	36,80	40,91	4969,00	69,62	4,87	1,83	19,30	4,38	89,47	5,26	5,26	E. Miyosen
Çanakkale	6,40	18,77	39,23	42,00	5234,00	68,41	5,10	1,99	21,79	2,71	93,59	3,85	2,56	G. Miyosen
Çanakkale	9,20	16,91	39,70	43,39	5243,00	69,18	4,64	4,21	16,33	5,64	88,37	5,81	5,81	G. Miyosen
Çanakkale	9,60	12,54	42,87	44,59	5638,00	71,12	4,68	2,63	19,27	2,30	93,83	3,70	2,47	G. Miyosen
Çanakkale	8,80	15,73	40,09	44,18	5518,00	69,98	4,67	2,76	13,95	8,64	87,80	7,32	4,88	G. Miyosen
Çanakkale	6,00	21,30	36,86	41,84	5248,00	70,56	5,10	3,33	14,22	6,79	84,42	9,09	6,49	G. Miyosen
Çanakkale	3,61	39,37	33,30	27,33	3335,00	62,51	5,07	0,65	20,84	10,93	84,72	8,33	6,94	G. Miyosen
Yalova	9,74	34,89	41,21	23,90	3402,00	89,67	4,83	1,91	3,08	0,51	83,56	9,59	6,85	E. Miyosen
Afyon	12,02	18,93	42,96	38,11	4554,00	83,88	5,50	1,37	3,97	5,28	84,81	8,86	6,33	E. Miyosen
Afyon	13,77	29,60	38,15	32,25	3891,00	62,99	4,65	1,30	24,65	6,41	83,54	8,86	7,59	E. Miyosen
Aydın	8,40	29,86	38,10	32,04	4213,00	66,27	4,75	2,27	17,85	8,86	84,71	9,41	5,88	E. Miyosen
Aydın	4,00	23,33	38,42	38,25	5430,00	73,18	5,43	1,54	18,22	1,63	90,41	5,48	4,11	E. Miyosen
Aydın	7,60	22,51	37,85	39,64	4886,00	67,72	5,25	1,55	22,85	2,63	85,88	8,24	5,88	E. Miyosen
Aydın	11,20	19,84	42,63	37,53	4781,00	66,02	5,20	1,08	26,12	1,58	85,92	8,45	5,63	E. Miyosen
Aydın	8,80	13,93	42,48	43,59	4755,00	63,27	3,95	0,87	27,63	4,28	83,75	6,25	10,00	E. Miyosen
Aydın	2,00	26,42	34,21	39,37	5376,00	74,04	5,73	1,19	5,82	13,19	85,00	8,75	6,25	E. Miyosen
Aydın	7,60	35,48	34,16	30,36	3741,00	64,89	5,42	1,58	24,98	3,13	82,50	11,25	6,25	E. Miyosen
Aydın	12,00	13,22	41,93	44,85	5678,00	59,84	4,37	1,73	33,75	0,31	85,71	6,59	7,69	E. Miyosen
Aydın	5,00	41,46	28,86	29,68	3527,00	66,57	5,39	1,55	25,57	0,92	87,23	5,32	7,45	E. Miyosen
Aydın	9,00	19,97	37,91	42,12	5058,00	69,34	4,87	2,10	18,02	5,67	80,00	8,89	11,11	E. Miyosen
Denizli	6,00	44,40	33,85	21,75	3259,00	66,74	5,17	2,20	20,13	5,76	88,24	7,35	4,41	E. Miyosen
Denizli	8,00	34,20	34,96	30,84	4118,00	71,56	5,27	1,30	7,41	14,46	82,43	8,11	9,46	E. Miyosen
Denizli	8,40	18,54	43,05	38,41	4679,00	63,53	5,12	1,31	25,43	4,61	88,37	6,98	4,65	E. Miyosen
Denizli	8,80	23,05	42,54	34,41	4423,00	64,69	5,09	0,88	21,79	7,55	88,75	5,00	6,25	E. Miyosen
Denizli	8,80	20,35	41,10	38,55	4561,00	64,54	4,85	0,92	24,56	5,13	85,37	7,32	7,32	E. Miyosen
Denizli	11,20	21,48	44,09	34,43	4645,00	64,05	4,95	1,03	24,14	5,83	87,64	6,74	5,62	E. Miyosen
Denizli	7,60	37,00	41,61	21,39	3699,00	64,10	5,48	0,98	19,99	9,45	79,49	10,26	10,26	E. Miyosen
Denizli	4,80	50,63	25,35	24,02	2742,00	63,36	5,66	1,06	21,85	8,07	87,50	6,25	6,25	E. Miyosen
Denizli	12,00	22,05	39,69	38,26	4623,00	64,37	5,20	1,87	23,55	5,01	84,27	8,99	6,74	Miyosen
Denizli	14,00	38,63	36,78	24,59	3483,00	64,84	4,70	2,05	22,58	5,83	85,71	7,79	6,49	Miyosen
İzmir	1,60	51,45	22,44	26,11	3420,00	71,11	4,21	2,20	10,62	11,86	92,11	5,26	2,63	E. Miyosen
Kütahya	1,60	27,20	27,09	45,71	5322,00	75,52	4,97	4,19	3,38	11,94	86,84	6,58	6,58	E. Miyosen
Kütahya	1,20	21,63	35,37	43,00	5804,00	73,64	5,41	1,56	8,22	11,17	92,42	4,55	3,03	E. Miyosen
Kütahya	7,60	52,12	25,52	22,36	2799,00	68,74	5,92	1,24	21,85	2,25	87,01	6,49	6,49	E. Miyosen
Kütahya	10,40	40,74	34,84	24,42	3351,00	62,90	5,42	1,39	26,47	3,82	85,92	7,04	7,04	E. Miyosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Kütahya	13,20	23,85	38,79	37,36	4718,00	69,26	4,95	1,74	22,79	1,26	87,36	8,05	4,60	E. Miyosen
Kütahya	8,40	46,02	33,89	20,09	2987,00	62,29	5,34	3,44	28,01	0,92	85,39	6,74	7,87	E. Miyosen
Kütahya	9,20	39,10	33,06	27,84	3504,00	63,85	5,08	1,70	25,07	4,30	85,33	6,67	8,00	E. Miyosen
Kütahya	10,40	14,82	43,05	42,13	5217,00	67,53	4,94	2,40	20,50	4,63	88,37	5,81	5,81	E. Miyosen
Kütahya	9,60	25,31	40,27	34,42	4520,00	65,98	5,20	2,53	23,15	3,14	86,76	7,35	5,88	E. Miyosen
Kütahya	10,00	22,00	41,68	36,32	4604,00	64,86	5,13	2,41	23,91	3,69	90,70	4,65	4,65	E. Miyosen
Kütahya	7,20	30,02	33,15	36,83	4295,00	66,20	5,05	2,62	17,03	9,10	85,88	7,06	7,06	E. Miyosen
Kütahya	7,20	26,86	34,44	38,70	4469,00	67,25	4,76	2,06	18,90	7,03	88,76	5,62	5,62	E. Miyosen
Kütahya	8,80	22,97	38,56	38,47	4890,00	69,41	4,87	2,61	18,82	4,29	89,19	5,41	5,41	E. Miyosen
Kütahya	7,20	25,86	36,37	37,77	4807,00	69,53	5,38	2,60	19,95	2,54	83,72	11,63	4,65	E. Miyosen
Kütahya	7,60	21,87	36,71	41,42	5461,00	75,50	5,47	2,37	15,71	0,95	85,37	9,76	4,88	E. Miyosen
Kütahya	1,60	39,77	23,10	37,13	4522,00	72,82	5,47	3,58	10,88	7,25	88,61	7,59	3,80	E. Miyosen
Kütahya	5,82	9,79	42,40	47,81	5627,00	67,40	4,30	1,22	23,71	3,37	83,33	10,26	6,41	E. Miyosen
Kütahya	3,14	42,71	38,64	18,65	3069,00	60,37	3,77	1,39	30,32	4,15	82,43	5,41	12,16	E. Miyosen
Kütahya	5,80	25,19	34,02	40,79	4816,00	73,48	4,90	2,00	17,53	2,09	88,89	6,17	4,94	E. Miyosen
Kütahya	2,86	31,66	31,25	37,09	4354,00	70,91	4,84	2,44	17,52	4,29	87,65	6,17	6,17	E. Miyosen
Kütahya	6,88	16,33	42,38	41,29	5196,00	69,73	4,66	1,71	19,69	4,21	83,54	7,59	8,86	E. Miyosen
Kütahya	6,72	16,00	41,38	42,62	5074,00	69,70	4,66	1,60	20,80	3,24	79,45	10,96	9,59	E. Miyosen
Kütahya	2,61	26,84	32,63	40,53	5014,00	76,46	4,95	2,75	14,84	1,00	86,75	6,02	7,23	E. Miyosen
Kütahya	2,29	21,93	36,60	41,47	5378,00	77,18	5,23	2,84	12,30	2,45	85,37	8,54	6,10	E. Miyosen
Kütahya	1,69	59,38	23,30	17,32	2411,00	70,60	5,11	8,01	8,12	8,16	79,49	10,26	10,26	E. Miyosen
Manisa	3,14	63,30	24,00	12,70	2101,44	23,10	2,20	0,60	4,90	5,90	87,85	7,49	4,66	E. Miyosen
Manisa	3,32	46,80	36,10	17,10	2650,68	33,50	2,00	0,80	15,10	1,80	73,27	3,46	23,27	E. Miyosen
Manisa	3,19	47,80	33,10	19,10	1599,96	26,80	1,30	0,50	22,80	0,80	72,26	7,39	20,36	E. Miyosen
Manisa	4,43	18,20	38,00	43,80	5587,92	60,00	3,90	1,20	15,20	1,50	90,57	8,30	1,14	E. Miyosen
Manisa	3,88	7,00	40,60	52,40	6471,48	69,50	5,00	1,40	15,90	1,20	92,13	6,85	1,02	E. Miyosen
Manisa	6,11	20,40	36,60	43,00	5396,88	58,70	4,40	0,10	13,50	2,00	88,67	10,22	1,11	E. Miyosen
Manisa	3,22	6,60	42,30	51,10	6495,36	69,60	5,20	1,30	16,00	1,30	88,32	10,64	1,04	E. Miyosen
Manisa	2,26	17,30	39,70	43,00	5755,08	60,70	5,10	1,10	14,40	1,40	85,43	13,40	1,17	E. Miyosen
Manisa	5,00	6,70	42,00	51,30	6590,88	70,00	5,20	1,30	15,40	1,40	90,53	8,44	1,03	E. Miyosen
Manisa	5,80	7,60	42,50	49,90	6519,24	69,40	5,10	1,20	15,40	1,30	88,96	9,95	1,09	E. Miyosen
Manisa	5,69	11,80	42,50	45,70	6041,64	64,50	4,70	1,10	15,90	2,00	89,42	8,90	1,68	E. Miyosen
Manisa	5,60	11,10	42,40	46,50	5946,12	65,00	4,60	0,10	17,10	1,20	91,53	7,19	1,28	E. Miyosen
Manisa	2,21	19,30	39,60	41,10	5587,92	59,60	4,30	0,10	14,10	1,70	88,32	9,25	2,43	E. Miyosen
Manisa	2,25	36,00	36,20	27,80	3892,44	44,00	3,10	0,70	14,90	1,30	88,96	8,86	2,18	E. Miyosen
Manisa	3,79	26,00	39,90	34,10	4704,36	52,10	3,40	0,90	16,40	1,20	89,99	7,15	2,86	E. Miyosen
Manisa	2,20	41,50	33,50	25,00	3629,76	40,10	2,70	0,70	13,50	1,50	85,78	10,13	4,08	E. Miyosen
Manisa	3,00	38,50	35,80	25,70	3677,52	42,30	2,70	0,70	14,50	1,30	88,89	5,29	5,82	E. Miyosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Manisa	3,00	29,50	38,00	32,50	4561,08	50,60	3,40	0,10	14,10	1,40	90,17	7,68	2,15	E. Miyosen
Manisa	5,80	54,40	35,30	10,30	1910,40	25,50	1,90	0,70	16,40	1,10	82,38	13,00	4,63	E. Miyosen
Manisa	3,00	65,80	29,80	4,40	1146,24	18,00	1,30	0,50	13,50	0,90	78,31	19,28	2,41	E. Miyosen
Manisa	5,00	71,10	18,80	10,10	1289,52	17,20	1,70	0,50	8,00	1,50	81,60	16,16	2,25	E. Miyosen
Manisa	5,60	52,60	29,60	17,80	3032,76	31,90	2,20	0,80	5,50	7,00	80,49	15,41	4,10	E. Miyosen
Manisa	5,60	47,60	40,40	12,00	2961,12	34,80	2,20	0,80	8,60	6,00	87,55	8,95	3,50	E. Miyosen
Manisa	6,12	31,40	36,70	31,90	4441,68	49,60	3,10	1,20	13,40	1,30	87,30	7,03	5,68	E. Miyosen
Manisa	6,00	31,30	33,10	35,60	4584,96	50,10	3,40	1,10	13,10	1,00	88,40	10,37	1,23	E. Miyosen
Manisa	2,67	45,80	31,00	23,20	3247,68	37,00	2,60	0,80	12,90	0,90	85,83	9,93	4,23	E. Miyosen
Manisa	2,82	72,20	24,00	3,80	740,28	14,00	1,20	0,40	11,50	0,70	77,90	14,88	7,22	E. Miyosen
Manisa	2,97	76,30	17,90	5,80	716,40	13,20	1,00	0,40	8,40	0,70	79,21	12,48	8,32	E. Miyosen
Manisa	9,20	15,54	38,02	46,44	5796,00	70,67	5,33	2,03	21,25	0,72	87,95	6,02	6,02	E. Miyosen
Manisa	5,80	27,38	37,22	35,40	4564,00	68,26	5,47	0,73	25,04	0,50	91,58	6,32	2,11	E. Miyosen
Manisa	9,60	28,15	40,22	31,63	4517,00	69,53	4,87	0,60	20,79	4,21	82,14	11,90	5,95	E. Miyosen
Manisa	8,40	24,17	37,19	38,64	4520,00	65,58	5,49	0,60	22,16	6,17	82,76	8,05	9,20	E. Miyosen
Manisa	8,00	6,95	41,52	51,53	6044,00	70,37	5,12	1,04	22,86	0,62	85,87	8,70	5,43	E. Miyosen
Manisa	7,60	21,58	38,50	39,92	4819,00	66,96	5,15	2,08	22,94	2,87	89,41	7,06	3,53	E. Miyosen
Manisa	5,20	32,13	38,77	29,10	4148,00	67,19	5,04	0,99	26,55	0,23	87,32	7,04	5,63	E. Miyosen
Manisa	9,20	28,25	40,35	31,40	4090,00	66,19	4,70	1,01	28,08	0,02	89,53	5,81	4,65	E. Miyosen
Manisa	7,40	45,76	28,61	25,63	3152,00	66,13	5,47	0,64	23,92	3,84	89,36	6,38	4,26	E. Miyosen
Manisa	8,00	13,76	41,38	44,86	5859,00	71,89	5,26	1,54	14,26	7,05	86,75	8,43	4,82	E. Miyosen
Manisa	7,60	29,88	39,34	30,78	4909,00	74,13	5,09	1,93	14,02	4,83	87,67	8,22	4,11	E. Miyosen
Manisa	8,00	20,95	38,17	40,88	4942,00	68,57	5,43	1,33	23,74	0,93	88,75	7,50	3,75	E. Miyosen
Manisa	8,40	19,10	39,80	41,10	4825,00	68,83	5,14	1,09	24,79	0,15	88,89	6,67	4,44	E. Miyosen
Manisa	6,40	47,69	28,48	23,83	2734,00	61,01	4,70	2,35	5,99	25,95	86,15	7,69	6,15	E. Miyosen
Manisa	6,00	42,70	31,86	25,44	3156,00	62,77	5,68	1,49	28,95	1,11	91,55	4,23	4,23	E. Miyosen
Muğla	7,40	55,81	31,62	12,57	2041,00	57,92	5,52	0,98	34,93	0,65	80,28	9,86	9,86	E. Miyosen
Muğla	10,40	15,07	43,84	41,09	5342,00	67,06	4,77	1,20	21,40	5,57	86,67	4,44	8,89	E. Miyosen
Muğla	8,60	30,16	43,02	26,82	3895,00	63,11	5,50	0,80	25,83	4,76	79,75	11,39	8,86	E. Miyosen
Muğla	10,00	20,48	41,68	37,84	5075,00	69,14	5,31	1,96	18,16	5,43	86,90	8,33	4,76	E. Miyosen
Muğla	9,00	31,04	44,05	24,91	3785,00	62,95	5,42	2,04	28,29	1,30	80,56	11,11	8,33	E. Miyosen
Muğla	8,60	23,37	48,65	27,98	4189,00	60,82	5,43	0,60	29,70	3,45	90,00	6,25	3,75	E. Miyosen
Muğla	10,20	24,87	48,89	26,24	4287,00	62,93	5,41	0,73	25,42	5,51	82,09	7,46	10,45	E. Miyosen
Muğla	11,80	20,06	45,59	34,35	4577,00	64,81	5,42	1,70	22,82	5,25	83,87	9,68	6,45	E. Miyosen
Muğla	11,40	23,31	44,82	31,87	4567,00	65,34	5,18	2,49	24,75	2,24	86,57	8,96	4,48	E. Miyosen
Muğla	9,20	32,42	42,75	24,83	3828,00	62,70	5,48	1,60	26,25	3,97	79,17	12,50	8,33	E. Miyosen
Muğla	13,60	31,20	41,40	27,40	4157,00	65,01	5,55	1,93	24,49	3,02	82,81	10,94	6,25	E. Miyosen
Muğla	19,88	17,02	60,25	22,73	5112,24	62,31	9,77	1,95	21,18	4,79	77,70	18,30	4,00	Miyosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Muğla	19,88	24,25	64,65	11,10	4065,04	59,48	9,49	2,05	25,81	3,17	69,80	22,80	7,40	Miyosen
Muğla	22,74	31,16	60,89	7,95	4234,02	53,96	10,00	2,49	31,29	2,26	75,90	22,70	1,40	Miyosen
Muğla	20,07	13,97	58,74	27,29	4762,38	62,33	8,46	1,75	19,50	7,96	77,80	19,30	2,90	Miyosen
Muğla	23,07	15,13	64,20	20,67	4676,70	63,64	7,16	1,68	17,78	9,74	85,90	11,80	2,30	Miyosen
Muğla	20,07	20,10	61,40	18,50	4483,92	58,07	7,49	1,48	27,56	5,40	86,50	9,30	4,20	Miyosen
Muğla	22,84	13,15	55,08	31,77	4767,14	63,38	6,68	2,08	18,98	8,88	92,00	5,60	2,40	Miyosen
Muğla	17,44	27,71	58,32	13,97	4636,24	58,38	6,72	1,70	25,12	8,08	94,00	5,40	0,60	Miyosen
Muğla	13,35	45,20	54,48	0,32	4198,32	55,29	7,90	2,16	27,60	7,05	86,60	9,60	3,80	Miyosen
Muğla	18,24	20,22	54,63	25,15	4312,56	54,59	7,60	1,62	30,25	5,94	92,90	6,00	1,10	Miyosen
Muğla	22,85	17,23	56,33	26,44	4664,80	63,29	7,36	2,80	20,11	6,44	76,70	16,00	7,30	Miyosen
Muğla	24,15	21,62	59,11	19,27	4386,34	60,53	9,04	2,03	23,40	5,00	83,30	13,70	3,00	Miyosen
Muğla	19,88	14,07	56,94	28,99	4933,74	62,59	7,38	1,63	21,09	7,31	91,10	7,70	1,20	Miyosen
Muğla	23,78	17,89	66,31	15,80	4698,12	64,00	8,14	2,32	18,25	7,29	85,70	10,60	3,70	Miyosen
Muğla	19,53	19,69	58,04	22,27	4831,40	61,49	7,46	1,96	20,94	8,15	86,80	9,70	3,50	Miyosen
Muğla	18,49	26,87	61,87	11,26	4762,38	61,82	9,24	2,44	20,05	6,45	88,00	10,70	1,30	Miyosen
Muğla	22,38	20,67	68,34	10,99	4564,84	60,01	6,54	1,76	21,35	10,34	91,70	5,50	2,80	Miyosen
Uşak	10,80	20,80	40,80	38,31	4584,00	64,78	4,69	1,50	23,72	5,31	87,65	6,17	6,17	E. Miyosen
Amasya	3,50	34,96	29,78	35,26	4252,00	76,10	4,97	2,88	14,70	1,35	86,21	5,75	8,05	Eosen
Bolu	7,69	14,94	40,63	44,43	5353,00	68,70	5,18	1,55	15,13	9,44	83,13	9,64	7,23	Eosen
Bolu	3,93	13,91	45,98	40,11	5877,00	71,12	5,49	1,50	12,71	9,18	85,88	7,06	7,06	Eosen
Bolu	8,65	12,64	51,08	36,28	5804,00	69,76	5,23	1,58	13,82	9,61	82,76	8,05	9,20	Eosen
Bolu	5,56	16,95	41,15	41,90	4861,00	59,63	5,48	1,67	32,17	1,05	85,71	7,14	7,14	Miyosen
Kastamonu	7,58	51,76	23,43	24,81	2494,00	58,03	4,78	1,77	28,73	6,69	82,72	8,64	8,64	Eosen
Kastamonu	7,42	32,32	30,24	37,44	3927,00	62,85	4,88	1,20	21,60	9,47	80,25	11,11	8,64	Eosen
Çorum	5,74	17,93	40,06	42,01	4999,00	67,84	5,40	3,60	23,05	0,11	83,72	5,81	10,47	Miyosen
Çorum	2,30	48,93	28,50	22,57	3095,00	67,66	5,57	1,80	16,79	8,18	87,06	7,06	5,88	Miyosen
Çankırı	2,74	27,91	33,08	39,01	4619,00	70,10	4,56	1,68	20,13	3,53	91,55	2,82	5,63	Miyosen
Ankara	9,00	39,20	33,32	27,48	3736,00	69,19	5,64	2,68	17,04	5,45	83,75	8,75	7,50	Miyosen
Tokat	5,06	28,29	41,68	30,03	4310,00	70,62	4,77	1,85	19,90	2,86	84,81	8,86	6,33	Eosen
Eskişehir	7,22	26,33	37,91	35,76	4754,00	71,34	5,21	1,46	20,52	1,47	94,81	2,60	2,60	Miyosen
Konya	13,35	16,34	41,82	41,84	4878,00	68,55	4,51	0,59	24,76	1,59	86,36	6,82	6,82	E. Miyosen
Konya	10,81	28,12	45,95	25,93	4162,00	65,59	4,94	1,84	23,70	3,93	83,72	8,14	8,14	Pliyosen
Nevşehir	2,64	43,03	28,07	28,90	3961,00	71,36	6,06	1,24	9,96	11,38	82,35	8,24	9,41	Oligosen
Sivas	7,70	33,48	43,80	22,72	3506,00	61,69	4,84	1,82	27,61	4,04	76,79	10,71	12,50	E. Pliyosen
Sivas	8,12	18,99	39,63	41,38	4549,00	65,66	4,03	1,79	24,52	4,00	85,87	6,52	7,61	E. Miyosen
Yozgat	3,87	6,12	42,06	51,82	6343,00	76,79	4,74	2,15	14,89	1,43	88,64	6,82	4,55	Eosen
Adana	6,06	45,93	35,56	18,51	2453,00	54,26	4,90	1,79	30,70	8,35	84,13	7,94	7,94	Pliyosen
Mersin	13,92	33,20	34,76	32,04	3795,00	65,36	4,26	0,99	22,76	6,63	78,82	9,41	11,76	E. Miyosen

(Devamı arkada)

Çizelge 7.1.'in devamı

Burdur	12,40	16,37	47,52	36,11	4969,00	66,41	5,12	1,64	24,24	2,59	89,41	4,71	5,88	Miyosen
Isparta	10,28	33,26	46,88	19,86	3595,00	61,02	3,96	0,32	34,53	0,17	84,75	8,47	6,78	Miyosen
Karaman	12,44	17,39	41,80	40,81	5147,00	69,97	4,44	1,31	21,09	3,19	69,05	9,52	21,43	E. Miyosen
Karaman	10,17	22,20	41,38	36,42	4770,00	71,31	4,52	1,20	20,21	2,76	80,00	10,59	9,41	E. Miyosen
Karaman	10,81	22,77	38,35	38,88	4571,00	71,49	4,54	1,64	21,77	0,56	77,11	10,84	12,05	E. Miyosen
Karaman	12,05	8,94	42,18	48,88	5591,00	71,53	4,45	1,39	22,16	0,47	82,95	7,95	9,09	E. Miyosen
Adıyaman	13,40	28,55	44,65	26,80	3971,00	63,48	5,09	2,29	27,41	1,73	82,86	7,14	10,00	Pliyosen
Ağrı	7,18	36,63	42,29	24,08	3747,00	68,12	5,13	1,40	24,53	0,82	77,42	11,29	11,29	Pliyosen
Erzurum	5,80	58,00	28,01	13,99	1777,00	52,88	5,01	1,97	36,39	3,75	83,82	8,82	7,35	Pliyosen
Erzurum	3,29	20,12	36,59	43,29	5466,00	77,07	4,88	1,54	14,92	1,59	87,64	7,87	4,49	Oligosen
Erzurum	6,39	30,39	41,17	28,44	3939,00	65,95	4,88	1,38	27,71	0,08	82,35	10,29	7,35	Pliyosen
Erzurum	3,04	23,43	35,80	40,77	5214,00	76,08	5,44	2,83	12,72	2,93	85,54	8,43	6,02	E. Miyosen
Erzurum	0,66	29,69	31,49	38,82	5372,00	83,48	5,50	2,46	4,53	4,03	87,50	5,00	7,50	E. Miyosen
Kahramanmaraş	10,60	33,80	40,49	25,71	3549,00	62,28	5,49	1,15	28,73	2,35	85,54	3,61	10,84	Pliyosen
Kahramanmaraş	8,20	33,39	41,92	24,69	3587,00	62,78	5,41	1,54	27,87	2,40	88,31	3,90	7,79	Pliyosen

ÖZGEÇMİŞ

Gökhan ALABAŞ

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2022-2025	Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği Anabilim Dalı, Antalya
Lisans	Hacettepe Üniversitesi
2009-2014	Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Ankara