



Yıkanmış Türk Linyit Kömürlerinin Üst Isıl Değerinin Destek Vektör Regresyonu ile Tahmini

Mustafa Açıkkar^{1*}, Osman Sivrikaya²

¹ Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık ve Uzay Mühendisliği Bölümü, Adana, Türkiye (ORCID: 0000-0001-8888-4987)

² Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Maden Mühendisliği Bölümü, Adana, Türkiye (ORCID: 0000-0001-8146-5747)

(İlk Geliş Tarihi 4 Kasım 2019 ve Kabul Tarihi 22 Şubat 2020)

(DOI: 10.31590/ejosat.642676)

ATIF/REFERENCE: Açıkkar, M., & Sivrikaya, O. (2020). Yıkanmış Türk Linyit Kömürlerinin Üst Isıl Değerinin Destek Vektör Regresyonu ile Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (18), 16-24.

Öz

Bu çalışmada yıkanmış Türk linyit kömürlerinin üst ısıl değeri (GCV), makine öğrenmesi yöntemleri ile kömür numunelerinin kuru baz kısa analiz sonuçları kullanılarak tahmin edilmiştir. Laboratuvar kömür analiz sonuçlarından elde edilen kül (A), uçucu madde (VM), kükürt (S) ve GCV değişkenleri kullanılarak veri kümesi oluşturulmuştur. Veri kümesine, Destek Vektör Regresyonu (SVR) ile Çok Katmanlı Algılayıcı (MLP), Genel Regresyon Sinir Ağı (GRNN) ve Radyal Temelli Fonksiyon Sinir Ağı (RBFN) olmak üzere üç farklı Yapay Sinir Ağı (ANN) uygulanarak GCV tahmin modelleri geliştirilmiştir. Geliştirilen modellerin performans genelleştirme kabiliyeti 10-katlı çapraz-doğrulama kullanılarak sağlanmış ve modellerin tahmin doğruluğu, performans ölçütleri Çoklu Korelasyon Katsayısı (R), Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) kullanılarak hesaplanmıştır. Sonuçlar, GCV tahmini için, tüm modeller arasında SVR tabanlı modelin ANN tabanlı modellere göre biraz daha iyi, ANN tabanlı modeller arasında ise RBFN tabanlı modelin MLP ve GRNN tabanlı modellere göre daha iyi performans gösterdiğini ortaya koymuştur.

Anahtar Kelimeler: Üst ısıl değer, destek vektör regresyonu, çok katmanlı algılayıcı, genel regresyon sinir ağı, radyal temelli fonksiyon sinir ağı

Prediction of Gross Calorific Value of Washed Turkish Lignite Coals with Support Vector Regression

Abstract

In this study, the gross calorific value (GCV) of washed Turkish lignite coals was predicted by using dry-basis proximate analysis data of coal samples with machine learning methods. The data set was generated by using ash (A), volatile matter (VM), sulfur (S) and GCV variables obtained from the analysis results. The GCV prediction models were developed by applying Support Vector Regression (SVR) and three different Artificial Neural Networks (ANNs), namely Multi-Layer Perceptron (MLP), General Regression Neural Network (GRNN) and Radial Basis Function Neural Network (RBFN), separately to the data set. The generalization capability of the developed models was ensured by using 10-fold cross-validation, and the prediction accuracy of the models was calculated by using performance metrics Multiple Correlation Coefficient (R), Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE). For GCV prediction, the results reveal that the SVR-based model performed slightly better than the ANN-based models and among the ANN-based models, the RBFN-based model performed better than MLP- and GRNN-based models.

* Sorumlu Yazar: Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Havacılık ve Uzay Bilimleri Fakültesi, Havacılık ve Uzay Mühendisliği Bölümü, Adana, Türkiye, ORCID: 0000-0001-8888-4987, macikkar@atu.edu.tr

Keywords: Gross calorific value, support vector regression, multi-layer perceptron, general regression neural network, radial basis function neural network.

1. Giriş

Son yıllarda gelişen teknoloji ile birlikte dünya enerji tüketim ihtiyacı hızla artmaktadır. Buna bağlı olarak enerji ihtiyacını karşılamak üzere farklı enerji üretim yöntemleri uygulanmaktadır. Enerji üretimi konvansiyonel ve yenilikçi yöntemler ile yapılabilmektedir. Her ne kadar yenilikçi ve yenilenebilir enerji üretim yöntemleri ön plana çıkarılmaya çalışılsa da konvansiyonel yöntemlerden olan fosil yakıtlardan enerji üretimi hala dünya enerji üretiminin önemli bir kısmını karşılamaktadır (Sivrikaya, 2014).

Kömür, organik kökenli fosil bir yakıt olarak ısınma amaçlı ve enerji üretiminde en çok kullanılan kaynaklardan birisidir. Tüm çevresel çekincelere rağmen dünyadaki yüksek kömür rezervleri, teminindeki kolaylıklar ve kullanımındaki ekonomik avantajlar nedeniyle enerji üretiminde kömür kullanımı devam etmektedir. Kömürün son yıllardaki enerji üretimi incelendiğinde yakın gelecekte de kullanımı devam edeceği öngörülebilir (W. Chen & Xu, 2010; Tan, Zhang, Xia, Fang, & Chen, 2015). Dolayısıyla kömür kullanımından kaynaklı çevresel zararları azaltmak için hem akademik hem endüstriyel çapta temiz kömür üretimi çalışmaları yapılmaktadır.

Temiz kömür üretiminde düşük kaliteli kömürler direk kullanıma uygun olmadıkları ve çevresel zararları minimize etmek için üretimden sonra lavvarlarda yıkama işlemine tabi tutulurlar. Kömür yıkama işleminde düşük kaliteli linyit kömürlerinin kül yapıcı mineral maddeleri bazı teknikler ile kömürden uzaklaştırılarak kalitesi nispeten yükseltilmiş temiz yıkanmış kömür elde edilir (Nasir, Kucerik, & Mahmood, 2012; Tozsın, Acar, & Sivrikaya, 2018; Xia, Xie, & Peng, 2015). Bu tür çalışmalar neticesinde elde edilen kömürlerin kullanımı hem ekonomik hem de çevresel açıdan daha uygundur.

Kömürlerin kullanım alanlarına uygunluklarını belirlemek amacıyla uluslararası kabul görmüş standart test yöntemleri uygulanarak kömür kalitesi belirlenir. Bu yöntemler temel olarak iki ana gruba ayrılır. Birincisi kısa kömür analizi, diğeri ise kömür elementel analizidir. Kömürün nem (M), kül (A), uçucu madde (VM), sabit karbon (FC) ve ısı değerleri kısa analiz ile belirlenir. Hidrojen (H), azot (N), kükürt (S), karbon (C) ve oksijen (O) içerikleri ise elementel analiz ile belirlenir (Akkaya, 2009; Patel et al., 2007). Ancak S elementel analiz sırasında belirlenen bir değişken olduğu halde, çevreye olan etkisi dolayısıyla kömür kısa analiz sırasında da belirlenir. Kömürün enerji kaynağı olarak kullanımında en önemli özelliği ısı değeridir. Kömürün enerji potansiyelini belirlemek, verimli bir kullanım alanı bulmak, fiyatını belirlemek ve termal sistemleri kömüre uygun şekilde tasarlayıp işletmek için kömürün üst ısı değerinin doğru bir şekilde belirlenmesi gerekir (Akkaya, 2009). Kömüre ait üst ısı değeri (GCV) karmaşık bir bomba kalorimetresi standart testi ile laboratuvarında belirlenebilir. Ancak, kömür üst ısı değeri, diğer kömür özelliklerine bağlı olarak değişen bir türev özelliğidir. Bu nedenle, kömürün üst ısı değeri nem, kül ve uçucu madde değerleri kullanılarak tahmin edilebilir.

Bulanık mantık, yapay sinir ağları, genetik algoritmalar ve sinirsel bulanık sistemler gibi makine öğrenmesi yöntemleri, genellikle daha yüksek teknoloji ürünlerinin tasarımında kullanılmakla birlikte şu anda farklı bilim dallarında ve teknolojilerde kullanılmaktadır ve popülerlikleri giderek artmaktadır (Yılmaz, Erik, & Kaynar, 2010). Bu teknikler genellikle tahmin çalışmalarında kullanılmaktadır. Bazı araştırmacılar, kömür özellikleri ve üst ısı değerleri arasındaki ilişkileri ya kısa analiz sonuçlarını kullanarak ya da elementel analiz sonuçlarını ya da bunların kombinasyonlarını kullanarak araştırmışlardır (Açıkkar & Sivrikaya, 2018b; Akhtar, Sheikh, & Munir, 2017; Akkaya, 2009; Channiwala & Parikh, 2002; Chelgani, Mesroghli, & Hower, 2010; Feng, Zhang, Zhang, & Wen, 2015; Majumder, Jain, Banerjee, & Barnwal, 2008; Matin & Chelgani, 2016; Mazumdar, 2000; Mesroghli, Jorjani, & Chehreh Chelgani, 2009; Ozbayoglu, Ozbayoglu, & Ozbayoglu, 2010; Parikh, Channiwala, & Ghosal, 2005; Patel et al., 2007; Tan et al., 2015; Wen, Jian, & Wang, 2017; Yalçın Erik & Yılmaz, 2011).

Bu çalışmada Manisa-Soma linyit kömür havzasından üretilen 3672 yıkanmış kömür numunesinin kuru baz kısa analiz sonuçlarından elde edilen veri kümesi GCV'nin tahmininde kullanılmıştır. Veri kümesine, GCV tahmin modeli oluşturmak için, Destek Vektör Regresyonu (SVR) ile Çok Katmanlı Algılayıcı (MLP), Genel Regresyon Sinir Ağı (GRNN) ve Radyal Temelli Fonksiyon Sinir Ağı (RBFN) dâhil olmak üzere üç farklı Yapay Sinir Ağı (ANN) uygulanmıştır. Geliştirilen tahmin modellerinin genelleme kabiliyeti 10-katlı çapraz-doğrulama kullanılarak sağlanmıştır. Modellerinin tahmin doğruluğunu karşılaştırmak için performans ölçütleri olarak Çoklu Korelasyon Katsayısı (R), Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) kullanılmıştır.

2. Materyal ve Metot

2.1. Veri Kümesi

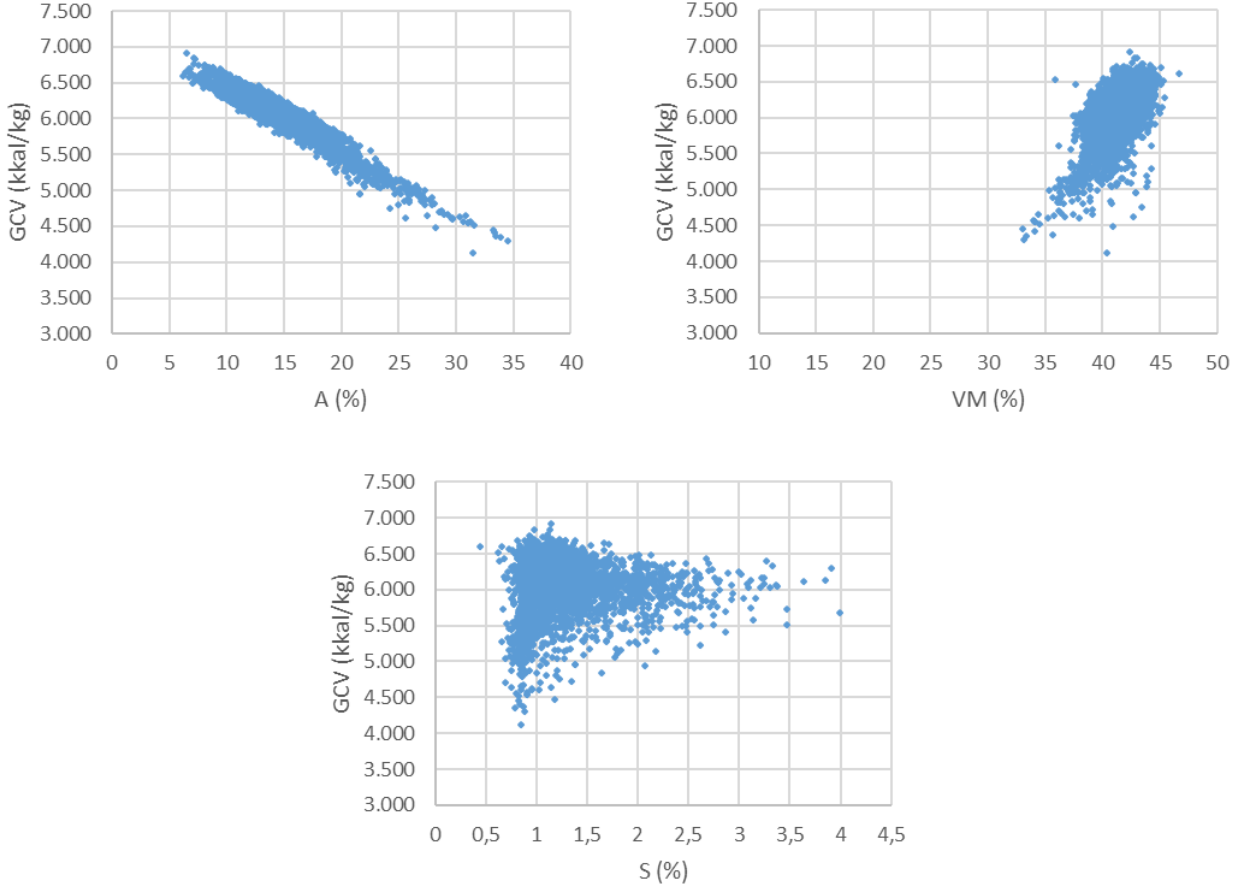
Bu çalışmada kullanılan veriler, Ocak 2016 - Mart 2017 tarihleri arasında Manisa-Soma linyit kömür havzasından üretilen linyit kömürlerinin laboratuvar analiz sonuçlarından elde edilmiştir. Kömür analizleri Türkiye Kömür İşletmeleri'ne (TKİ) bağlı Ege Linyit İşletmeleri Genel Müdürlüğü Akredite Laboratuvarlarında ASTM, ISO ve TSE standartlarına uygun olarak yapılmıştır.

Veri kümesi, 3672 yıkanmış kömür numunesinin kuru baz kısa analiz sonuçlarından elde edilen A, VM, S ve GCV değişkenleri kullanılarak oluşturulmuştur. Bu veri kümesi için A, VM ve S tahmin edici değişkenler olarak ve GCV hedef değişken olarak seçilmiştir.

Tablo 1 veri setinin tanımlayıcı istatistiklerini, Şekil 1 ise hedef değişkenin her bir tahmin edici değişkene göre dağılım grafiklerini göstermektedir.

Tablo 1. Veri setinin tanımlayıcı istatistikleri

Kategori	Değişken Adı	En Küçük Değer	En Büyük Değer	Ortalama \pm Standart Sapma.
Tahmin Edici Değişkenler	A (%)	6,15	34,47	14,66 \pm 3,74
	VM (%)	32,99	46,68	41,16 \pm 1,55
	S (%)	0,44	3,99	1,29 \pm 0,39
Hedef Değişken	GCV (kkal/kg)	4124,81	6918,67	6054,02 \pm 357,02



Şekil 1. Hedef değişkenin tahmin edici değişkenlerine göre dağılım grafikleri

2.2. Metodoloji

Bu çalışmada, 3672 kömür numunesinin analiz sonuçlarından elde edilen ve bölüm 2.1.'de ayrıntılı olarak açıklanan veri kümesi deneysel amaçlar için kullanılmıştır. Veri kümesine, SVR'nin yanında MLP, GRNN ve RBFN olmak üzere üç farklı ANN de uygulanarak, 4 farklı GCV tahmin modeli geliştirilmiştir. Geliştirilen SVR tabanlı modelin tahmin performansı ANN tabanlı modellerinin tahmin performansları ile karşılaştırılmıştır. GCV tahmininde, bahsedilen makine öğrenmesi yöntemlerinin seçilmesi birkaç temel faktöre dayanmaktadır. Literatürde, farklı problemler için SVR'nin diğer regresyon yöntemlerine üstünlüğünü gösteren birçok çalışma (Abut, Akay, & George, 2016; Akande, Owolabi, Twaha, & Olatunji, 2014; Quej, Almorox, Arnaldo, & Saito, 2017) yapılmıştır. Ayrıca, kömürün GCV'sini tahmin etmek için farklı veri kümeleri ve veri modelleri ile SVR'yi kullanan bazı çalışmalar da bulunmaktadır (Feng et al., 2015; Fu, 2016; Hadavandi, Hower, & Chelgani, 2017; Qi, Luo, Wei, & Fu, 2019; Tan et al., 2015). Diğer yandan, ANN'ler farklı alanlarda gerçek dünyada problemlerini çözmek için yaygın olarak kullanılmaktadır (Açıkkar & Sivrikaya, 2018b; Huang, Liu, & Ren, 2018; Ren & Gao, 2011). Bu çalışmada daha önce ifade edildiği üzere SVR ile karşılaştırma yapmak amacıyla GCV tahmininde üç tip ANN, yani MLP, GRNN ve RBFN kullanılmıştır. MLP en iyi bilinen ve en sık kullanılan bir ANN yöntemidir. Ek olarak, GRNN ve RBFN diğer popüler ANN yöntemlerinden olup birçok alanda (Arliansyah & Hartono, 2015; Heydari, Garcia, Keynia, Bisegna, & Santoli, 2019; Ren & Gao, 2011) ve kısa analiz sonuçlarından kömürlerin GCV tahmininde de başarıyla kullanılmıştır (Açıkkar & Sivrikaya, 2018b, 2018a).

Geliştirilen tüm modellerin tahmin performansları R, RMSE, MAE ve MAPE kullanılarak hesaplanmıştır. Bu performans ölçütlerinin formülleri Denklem (1) - (4) ile gösterilmiştir.

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (Y_i - Y'_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - Y'_i|}{Y_i} \quad (4)$$

Denklem (1) - (4)'te, analiz ile belirlenen GCV değeri Y , tahmin edilen GCV değeri Y' , GCV'nin analiz ile belirlenen değerlerinin ortalaması ise \bar{Y} ile gösterilmektedir ve test alt kümesindeki örneklerin sayısı n olarak verilmiştir.

Sunulan sonuçların kararlılığını ve güvenilirliğini güçlendirmek için veri setine 10-katlı çapraz-doğrulama uygulanmıştır. Tahmin modellerinin performansının geliştirilmesi için kullanılan k -katlı çapraz-doğrulamada, özgün veri kümesi rastgele k tane eşit büyüklükte alt kümelere ayrılır. Elde edilen k tane alt kümeden, tek bir alt küme test kümesi ve geri kalan $k-1$ alt küme eğitim kümesi olarak kullanılır. Bu işlem k kez tekrarlandığında, k tane alt kümenin her biri test kümesi olarak bir kez kullanılır. Böylece tüm örneklerin hem eğitim hem de test kümesinde kullanılması sağlanır.

Her GCV tahmin modeli için veri setine 10-katlı çapraz-doğrulama uygulanarak yukarıda formülleri verilen performans ölçütleri her bir kat için ayrı ayrı hesaplanmıştır. Elde edilen tüm katlara ait sonuçların ortalaması alınarak performans ölçütlerinin nihai değeri elde edilmiştir.

Bu çalışma kapsamında yapılan tüm deneyler (tahmin modellerinin geliştirilmesi ve sonuçların elde edilmesi), yaygın olarak kullanılan çeşitli makine öğrenme yöntemleri oluşturabilen bir tahmin modelleme yazılımı olan DTREG kullanılarak gerçekleştirilmiştir (Sherrod, 2014).

2.2. SVR Tabanlı Tahmin Modelleri

Destek Vektör Makinaları (SVM), sınıflandırma ve regresyon için kullanılan eğitici istatistiksel öğrenme yöntemlerinden biridir. Vapnik (Vapnik, 1995) tarafından geliştirilen SVM, birçok etkin özelliğe sahip olması ve doğrusal olmayan problemleri çözmeye iyi performans sağlaması nedeniyle popülerlik kazanmıştır. SVM ilk olarak sınıflandırma problemlerini çözmek için tasarlanmış olsa da, regresyon problemlerini çözmek için yeniden yapılandırılmıştır (Vapnik, Golowich, & Smola, 1997). Bu yöntem ise Destek Vektör Regresyonu (SVR) olarak adlandırılmıştır (Açıkkar, Akay, Aktürk, & Güleç, 2013).

SVR tabanlı modelin tahmin performansı doğrudan SVR parametrelerinin değerleri ile ilgilidir. Epsilon değeri (ϵ), kapasite değeri (C), çekirdek fonksiyon türü ve varsa çekirdek fonksiyonun parametresi dikkatli bir şekilde belirlenmelidir. Çekirdek fonksiyon türünü seçmek ve bu fonksiyonun en uygun parametre değerlerini belirlemek SVR tabanlı modeller oluşturmak için çok önemlidir (Baydaroğlu & Koçak, 2014). SVR'de yaygın olarak kullanılan çekirdek fonksiyonları genellikle doğrusal, polinom, radyal temelli fonksiyon (RBF) ve sigmoid olarak dört kategori altında toplanabilir. Literatürde, diğer çekirdek fonksiyonları ile karşılaştırıldığında, RBF çekirdek fonksiyonu daha tatmin edici sonuçlar ürettiği için sıklıkla kullanılmıştır (Abut et al., 2016; Campbell, 2002; Kavzoglu & Colkesen, 2009). Bu nedenle, bu çalışmada, çekirdek fonksiyonu olarak RBF seçilmiştir. Ancak RBF çekirdek fonksiyonunun γ parametresi de optimize edilmelidir. Sonuç olarak, verilen regresyon problemi için, tatmin edici düzeyde tahmin doğruluğu sağlayan SVR tabanlı modeller geliştirmek için en uygun C , ϵ ve γ değerleri belirlenmelidir.

SVR'nin tahmin doğruluğu, parametrelerin seçimine karşı çok hassastır ve bu parametrelerin istenen değerlerini elde etmek için matematiksel bir modele dayanan bir kural ya da formül yoktur. Bu amaçla, SVR tabanlı modellerde kullanılan parametrelerin en uygun değerlerini bulmak için etkili bir arama algoritması gerekir, böylece en üst düzeyde model performansı elde edilebilir. Izgara arama (GS) (Hsu, Chang, & Lin, 2003), SVR parametrelerini optimize etmek için yaygın olarak kullanılan algoritmalarından biridir. Her parametrenin önceden tanımlanmış bir değer aralığı vardır ve bu aralık logaritmik bir ölçekte eşit olarak adım sayısına bölünür. GS, her parametrenin tüm değerlerinin kombinasyonlarından elde edilen ve (C , ϵ , γ) üçlüsünden oluşan her bir parametre kümesini bir kez dener. Bu arama işleminin sonunda, en yüksek doğruluğu sağlayan parametre kümesi en uygun küme olarak kabul edilir.

SVR tabanlı tahmin modelinde kullanılan parametrelerin değer aralığı ve adım sayısı Tablo 2'te gösterilmektedir.

Tablo 2. SVR tabanlı tahmin modeli için kullanılan parametrelerin değer aralığı ve adım sayısı

Regresyon Yöntemi	Parametre	Değer Aralığı	Adım Sayısı
SVR	C	[0.1, 5000]	15
	ϵ	[0.0001, 100]	
	γ	[0.001, 50]	

2.4. ANN Tabanlı Tahmin Modelleri

Yapay Sinir Ağları (ANN), girdi ve çıktı verileri arasındaki karmaşık ve doğrusal olmayan ilişkileri belirleyebilen esnek bir matematiksel yapıdır. ANN'ler farklı alanlarda birçok zor sorunu çözmek için yaygın olarak uygulanmıştır. Problemlerin fonksiyon

yaklaşımını modellemek için birçok ANN türü vardır. Bu çalışmada önerilen GCV tahmin modellerinin kullanılabilirliğini doğrulamak için ANN yöntemlerinden MLP, GRNN ve RBFN kullanılmıştır.

2.4.1. MLP Tabanlı Tahmin Modelleri

Bir giriş katmanından, bir veya daha fazla gizli katmandan ve bir çıkış katmanından oluşan MLP, ANN yöntemleri arasında esnek, genel amaçlı ve en çok kullanılan bir ağıdır (Açıkkar & Sivrikaya, 2018b). Her gizli katmandaki en uygun nöron sayısını bulmak, MLP'nin çözümlenmesi gereken en önemli konularından biridir. Eğer yetersiz veya gereğinden fazla sayıda nöron kullanılıyorsa, oluşturulan ağ verileri modelleyemez ve beklenen performans elde edilemez. Tahmin probleminin türüne ve karmaşıklığına göre değişiklik gösteren gizli katmandaki nöron sayısını belirlemek için teorik bir yaklaşım yoktur (Abut et al., 2016).

Bu çalışmada, MLP ağı bir gizli katman kullanılarak oluşturulmuştur. Gizli katman transfer fonksiyonu olarak lojistik fonksiyon, çıkış katmanı transfer fonksiyonu olarak doğrusal fonksiyon kullanılmıştır. MLP ağının eğitim yöntemi, ölçeklenmiş eşlenik gradyan algoritmasıdır. Gizli katmandaki en uygun nöron sayısı, Tablo 3'te verilen nöron sayısı aralığında yer alan her bir değer kullanılarak geliştirilen modellerin tahmin performanslarının karşılaştırılmasıyla bulunmuştur. Bu yaklaşım, birçok model oluşturulması sebebi ile zaman alıcı bir işlem olsa da, en uygun nöron sayısını bulmak için oldukça etkili bir yöntemdir.

2.4.2. GRNN Tabanlı Tahmin Modelleri

Bellek tabanlı bir ağ olan GRNN bir giriş katmanı, bir desen katmanı, bir toplama katmanı ve bir çıkış katmanı olmak üzere dört katmandan oluşur. GRNN tek geçişli bir öğrenme algoritmasına dayalı olarak tasarlanmış olup ve eğitim verilerinin hatasını öğrenmek için geri yayılım algoritmasına ihtiyaç duymaz (Specht, 1991). Girdi katmanı ile desen katmanı birbirine tam bağlanır ve desen katmanı üzerindeki her düğüm çekirdek fonksiyonu olarak da bilinen bir RBF'yi temsil eder (Ren & Gao, 2011). Farklı RBF tipleri mevcut olmasına rağmen, en yaygın çekirdek fonksiyonu Gauss fonksiyonudur. Gauss fonksiyonunun genişliği, fonksiyonun yumuşaklığını kontrol eden bir parametredir ve yumuşatma faktörü (σ) olarak adlandırılır (Ren & Gao, 2011).

Bu çalışmada, desen katmanındaki her düğüm için en uygun yumuşatma faktörü, her model için bir yinelemeli işlem kullanılarak belirlenmiş ve Tablo 3'te gösterilen yumuşatma faktörünün değerlerini kullanan farklı ağların tahmin performansları karşılaştırılarak bulunmuştur.

2.4.3. RBFN Tabanlı Tahmin Modelleri

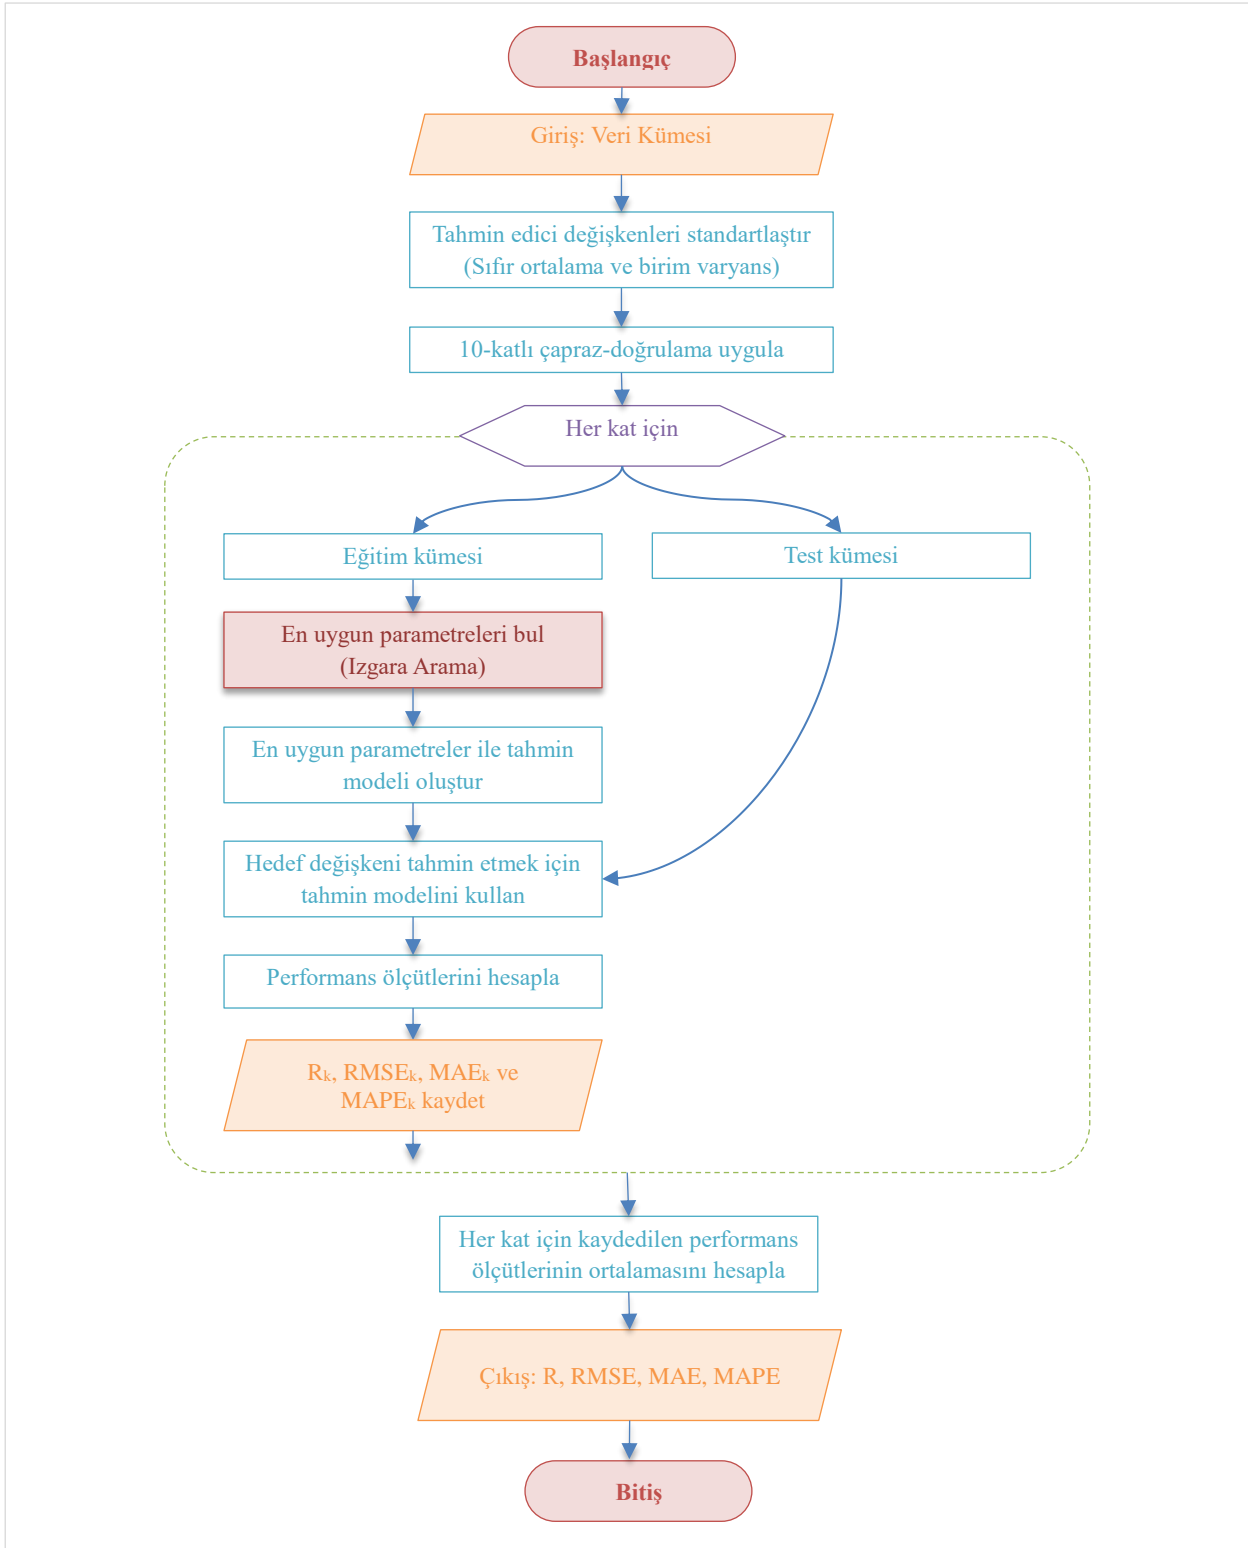
RBFN, bir giriş katmanı, bir gizli katman ve bir çıkış katmanı olmak üzere üç katmandan oluşan çok katmanlı ileri beslemeli sinir ağının özel bir durumu olmasının yanı sıra düğüm özellikleri ve öğrenme algoritması açısından farklılık göstermektedir (Arliansyah & Hartono, 2015). Gizli katmandaki nöronlar, çıkışları nöronun merkezinden uzaklıkla ters orantılı olan RBF transfer fonksiyonlarını içerir. RBFN modelinin eğitim aşamasında; gizli katmandaki nöronların sayısı, her gizli katmandaki RBF fonksiyonunun merkez noktası, her boyuttaki her RBF fonksiyonunun yarıçapı ve çıkış katmanına geçilirken RBF fonksiyonunun çıkışına uygulanan ağırlıklar olmak üzere dört farklı parametre belirlenir (Sherrod, 2014).

Bu çalışmada, MLP ağında olduğu gibi, gizli katmandaki en uygun nöron sayısı, Tablo 4'te verilen nöron sayısı aralığında yer alan her bir değer kullanılarak oluşturulan ağların tahmin performanslarının karşılaştırılmasıyla bulunmuştur. RBFN modelinin eğitim yöntemi olarak Sheng Chen ve ark. (S. Chen, Hong, & Harris, 2005) tarafından geliştirilen algoritma kullanılmıştır. Bu yöntem, her nöron için en uygun merkez noktalarını belirler ve evrimsel bir yaklaşımla yayılır. Ridge regresyonu, gizli katmanı nöronları ile çıkış katmanı nöronları arasındaki en uygun ağırlıkların hesaplanması için kullanılır. Genelleştirilmiş tahmin hatasını en aza indiren en uygun düzenleme parametresi (Lambda), Mark Orr (Orr, 1996) tarafından geliştirilen yinelemeli bir yöntem ile hesaplanmıştır (Sherrod, 2014).

Tablo 3, MLP, GRNN ve RBFN tabanlı tahmin modellerinin parametrelerinin değerini/değer aralıklarını göstermektedir. Bu çalışma kapsamında sunulan regresyona dayalı tahmin modellerinin akış şeması Şekil 2'de gösterilmiştir.

Tablo 3. ANN tabanlı tahmin modelleri için kullanılan parametrelerin değerleri/değer aralıkları

Regresyon Yöntemi	Parametre	Değer/Değer Aralığı
MLP	Gizli katmandaki nöron sayısı	[2, 25]
	Gizli katman transfer fonksiyonu	Lojistik
	Çıkış katmanı transfer fonksiyonu	Doğrusal
	Eğitim yöntemi	Ölçeklenmiş eşlenik gradyan
GRNN	Çekirdek fonksiyonu	Gauss
	Yumuşatma faktörü (σ) / Adım sayısı	[0.0001, 10] / 20
RBFN	Çekirdek fonksiyonu	Gauss
	Gizli katmandaki maksimum nöron sayısı	150
	Her boyuttaki her RBF fonksiyonunun yarıçapı	[0.01, 300]
	Düzenleme parametresi (Lambda)	[0.001, 8]
	Eğitim yöntemi	Ortogonal ileri seçim (S. Chen et al., 2005)



Şekil 2. GCV tahmin modellerinin akış şeması

3. Araştırma Sonuçları ve Tartışma

Makine öğrenmesi yöntemlerinden SVR, MLP, GRNN ve RBFN kullanılarak linyit kömürlerine ait kısa analiz sonucunda elde edilen A, VM, S değerleri ile GCV tahmin modelleri oluşturulmuştur. Geliştirilen tahmin modellerinin performanslarını değerlendirmek ve karşılaştırmak amacıyla performans ölçütleri olan R, RMSE, MAE ve MAPE hesaplanmıştır. Oluşturulan tahmin modellerinin performans ölçütlerinin değerleri Tablo 4’de verilmiştir.

Tablo 4. Regresyon tabanlı tahmin modellerinin performans ölçütleri

Regresyon Yöntemi	R	RMSE (kkal/kg)	MAE (kkal/kg)	MAPE (%)
SVR	0,9940	87,50	65,87	1,19
MLP	0,9926	96,51	77,51	1,38
GRNN	0,9933	91,85	69,01	1,26
RBFN	0,9938	88,27	66,27	1,21

Tablo 4’de verilen tüm tahmin modellerine ait performans ölçütlerinin değerleri incelendiğinde, GCV tahmininde SVR tabanlı tahmin modelinin en başarılı tahmin modeli olduğu görülmüştür. Bu modelin performans ölçütleri R, RMSE, MAE ve MAPE değerleri ise sırasıyla 0,9940, 87,50 kkal/kg, 65,87 kkal/kg ve %1,19’dır. Geliştirilen tahmin modelleri tahmin performansına göre sıralandığında en iyiden en kötüye doğru SVR, RBFN, GRNN ve MLP olduğu tespit edilmiştir.

Bu çalışmada elde edilen GCV tahmin modellerinin sonuçları ile literatürde önerilen benzer çalışmaların sonuçları arasında aşağıda belirtilen üç nedenden dolayı doğrudan ve ayrıntılı karşılaştırma yapmak mümkün olamamıştır. İlk olarak, her çalışmada farklı makine öğrenmesi yöntemleri ve farklı veri doğrulama yöntemleri kullanılmaktadır. İkincisi, her çalışma, farklı sayıda örnek içeren ve analiz türüne göre farklı tahmin edici değişkenleri olan farklı veri kümeleri kullanılmaktadır. Son olarak, GCV tahmini için oluşturulan her veri seti, örneğin kömürün kalitesi ve kömürün çıkarıldığı bölge gibi farklı veri özelliklerine sahip olabilmektedir.

Ancak bu çalışmada kullanılan veri kümesi Açıkkar ve Sivrikaya tarafından yapılan diğer bir çalışmada (Açıkkar & Sivrikaya, 2018a) kullanılan veri kümesinin sadece yıkanmış kömür örneklerini içeren bir alt kümesidir. Ayrıca söz konusu çalışmada 6875 kömür örneğine ait kısa analiz sonuçlarından oluşturulmuş veri kümesine MLP, GRNN ve RBFN uygulanmıştır. Geliştirilen ANN tabanlı tahmin modelleri arasında en başarılı model GRNN tabanlı model olup modelin R, RMSE ve MAPE değerleri sırasıyla 0,9840, 201,69 kkal/kg ve %2,97 olarak bulunmuştur. Bu çalışmada ise ANN tabanlı tahmin modelleri arasında RBFN tabanlı model ile en iyi tahmin doğruluğu sağlanmış olup modelin R, RMSE ve MAPE değerleri sırasıyla 0,9938, 88,27 kkal/kg ve %1,21’dir. Bu iki çalışma performans ölçütlerinden RMSE değerine göre karşılaştırıldığında bu çalışmada elde edilen RMSE değeri %56,23 oranında daha düşüktür. Bu bağlamda yüksek kalitedeki kömür örneklerinin oluşturduğu veri kümesinin tahmin edici değişkenlerinin ve hedef değişkeninin nispeten daha dar değişim aralığına sahip olmasından dolayı, bu çalışmada elde edilen tahmin sonuçlarının daha tutarlı olduğu değerlendirilmektedir.

4. Sonuç

Bu çalışmanın amacı, yıkanmış Türk linyit kömürlerinin GCV tahmini için yeni SVR tabanlı tahmin modeli geliştirmektir. SVR tabanlı tahmin modelinin performansını ortaya koymak ve karşılaştırma yapmak amacıyla ise ANN yöntemlerinden MLP, GRNN ve RBFN kullanılarak tahmin modelleri oluşturulmuştur. TKİ’den alınan 3672 kömür örneğine ait kuru baz kısa analiz sonuçları veri setini oluşturmak için kullanılmıştır. Sonuçların genelleştirilmesi 10-katlı çapraz-doğrulama ile sağlanmış, tahmin modellerinin performansı R, RMSE, MAE ve MAPE değerleri hesaplanarak belirlenmiştir.

Sonuçlar, GCV tahmini için, tüm modeller arasında SVR tabanlı modelin ANN tabanlı modellere göre biraz daha iyi, ANN tabanlı modeller arasında ise RBFN tabanlı modelin MLP ve GRNN tabanlı modellere göre daha iyi performans gösterdiğini ortaya koymuştur. Ancak SVR ile RBFN tabanlı tahmin modelleri karşılaştırıldığında modellerin tahmin başarısı birbirlerine oldukça yakın olduğu gözlemlenmiştir. Bu çalışmada önerilen tüm modellerin sonuçları göz önüne alındığında ise, bu veri kümesi üzerinde GCV tahmini için kullanılan regresyon yöntemlerinin performans sıralaması, azalan sıra ile SVR, RBFN, GRNN ve MLP olduğu görülmektedir.

Sonuç olarak, bu çalışma yıkanmış Türk linyit kömürlerinin GCV’lerinin SVR kullanarak kısa analiz sonuçlarından yüksek tahmin doğruluğu ile verimli bir şekilde tahmin edilebileceğini göstermiştir.

Teşekkür

Bu çalışma Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi Bilimsel Araştırma Projesi Birimi tarafından finansal olarak desteklenmiştir (Proje Numarası: 17119001).

Bu çalışmada kullanılan kömür analiz verileri Türkiye Kömür İşletmeleri (TKİ) tarafından sağlanmıştır.

Kaynakça

- Abut, F., Akay, M. F., & George, J. (2016). Developing new VO₂max prediction models from maximal, submaximal and questionnaire variables using support vector machines combined with feature selection. *Computers in Biology and Medicine*, 79(October), 182–192. <https://doi.org/10.1016/j.combiomed.2016.10.018>
- Açıkkar, M., Akay, M. F., Aktürk, E., & Güleç, M. (2013). Intelligent regression techniques for non-exercise prediction of VO₂max. 2013 21st Signal Processing and Communications Applications Conference, SIU 2013. <https://doi.org/10.1109/SIU.2013.6531534>
- Açıkkar, M., & Sivrikaya, O. (2018a). Artificial neural networks for estimation of the gross calorific value of Turkish lignite coals. 3rd International Mediterranean Science and Engineering Congress (IMSEC 2018), 1075–1079.

- Açıkkar, M., & Sivrikaya, O. (2018b). Prediction of gross calorific value of coal based on proximate analysis using multiple linear regression and artificial neural networks. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(5), 2541–2552. <https://doi.org/10.3906/elk-1802-50>
- Akande, K. O., Owolabi, T. O., Twaha, S., & Olatunji, S. O. (2014). Performance Comparison of SVM and ANN in Predicting Compressive Strength of Concrete. In *IOSR Journal of Computer Engineering* (Vol. 16). <https://doi.org/10.9790/0661-16518894>
- Akhtar, J., Sheikh, N., & Munir, S. (2017). Linear regression-based correlations for estimation of high heating values of Pakistani lignite coals. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 39(10), 1063–1070. <https://doi.org/10.1080/15567036.2017.1289283>
- Akkaya, A. V. (2009). Proximate analysis based multiple regression models for higher heating value estimation of low rank coals. *Fuel Processing Technology*, 90(2), 165–170. <https://doi.org/10.1016/j.fuproc.2008.08.016>
- Arliansyah, J., & Hartono, Y. (2015). Trip Attraction Model Using Radial Basis Function Neural Networks. *Procedia Engineering*, 125, 445–451. <https://doi.org/10.1016/J.PROENG.2015.11.117>
- Baydaroglu, Ö., & Koçak, K. (2014). SVR-based prediction of evaporation combined with chaotic approach. *Journal of Hydrology*, 508, 356–363. <https://doi.org/10.1016/J.JHYDROL.2013.11.008>
- Campbell, C. (2002). Kernel methods: a survey of current techniques. In *Neurocomputing* (Vol. 48). Retrieved from www.elsevier.com/locate/neucom
- Channiwala, S. A., & Parikh, P. P. (2002). A unified correlation for estimating HHV of solid, liquid and gaseous fuels. *Fuel*, 81(8), 1051–1063. [https://doi.org/10.1016/S0016-2361\(01\)00131-4](https://doi.org/10.1016/S0016-2361(01)00131-4)
- Chelgani, S. C., Mesroghli, S., & 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(1), 31–34. <https://doi.org/10.1016/j.coal.2010.03.004>
- Chen, S., Hong, X., & Harris, C. J. (2005). Orthogonal Forward Selection for Constructing the Radial Basis Function Network with Tunable Nodes. https://doi.org/10.1007/11538059_81
- Chen, W., & Xu, R. (2010). Clean coal technology development in China. *Energy Policy*, 38(5), 2123–2130. <https://doi.org/10.1016/j.enpol.2009.06.003>
- Feng, Q., Zhang, J., Zhang, X., & Wen, S. (2015). Proximate analysis based prediction of gross calorific value of coals: A comparison of support vector machine, alternating conditional expectation and artificial neural network. *Fuel Processing Technology*, 129, 120–129. <https://doi.org/10.1016/j.fuproc.2014.09.001>
- Fu, J. (2016). Application of SVM in the estimation of GCV of coal and a comparison study of the accuracy and robustness of SVM. 2016 International Conference on Management Science and Engineering (ICMSE), 553–560. <https://doi.org/10.1109/ICMSE.2016.8365486>
- Hadavandi, E., Hower, J. C., & Chelgani, S. Chehreh. (2017). Modeling of gross calorific value based on coal properties by support vector regression method. *Earth Syst. Environ.*, 3(1), 37. <https://doi.org/10.1007/s40808-017-0270-7>
- Heydari, A., Garcia, D. A., Keynia, F., Bisegna, F., & Santoli, L. De. (2019). Renewable Energies Generation and Carbon Dioxide Emission Forecasting in Microgrids and National Grids using GRNN-GWO Methodology. *Energy Procedia*, 159, 154–159. <https://doi.org/10.1016/j.egypro.2018.12.044>
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2003). A Practical Guide to Support Vector Classification. Retrieved from <http://www.csie.ntu.edu.tw/~cjlin>
- Huang, X., Liu, X., & Ren, Y. (2018). Enterprise credit risk evaluation based on neural network algorithm. *Cognitive Systems Research*, 52, 317–324. <https://doi.org/10.1016/J.COGSYS.2018.07.023>
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352–359. <https://doi.org/10.1016/J.JAG.2009.06.002>
- Majumder, A. K., Jain, R., Banerjee, P., & Barnwal, J. P. (2008). Development of a new proximate analysis based correlation to predict calorific value of coal. *Fuel*, 87(13–14), 3077–3081. <https://doi.org/10.1016/j.fuel.2008.04.008>
- Matin, S. S., & Chelgani, S. C. (2016). Estimation of coal gross calorific value based on various analyses by random forest method. *Fuel*, 177, 274–278. <https://doi.org/10.1016/j.fuel.2016.03.031>
- Mazumdar, B. K. (2000). Theoretical oxygen requirement for coal combustion: relationship with its calorific value. *Fuel*, 79(11), 1413–1419. [https://doi.org/10.1016/S0016-2361\(99\)00272-0](https://doi.org/10.1016/S0016-2361(99)00272-0)
- Mesroghli, S., Jorjani, E., & Chehreh Chelgani, S. (2009). Estimation of gross calorific value based on coal analysis using regression and artificial neural networks. *International Journal of Coal Geology*, 79(1–2), 49–54. <https://doi.org/10.1016/j.coal.2009.04.002>
- Nasir, S., Kucerik, J., & Mahmood, Z. (2012). A study on the washability of the Azad Kashmir (Pakistan) coalfield. *Fuel Processing Technology*, 99, 75–81. <https://doi.org/10.1016/j.fuproc.2012.02.003>
- Orr, M. J. L. (1996). Introduction to Radial Basis Function Networks. Centre for Cognitive Science, University of Edinburgh, Scotland.
- Ozbayoglu, A. M., Ozbayoglu, M. E., & Ozbayoglu, G. (2010). Regression techniques and neural network for the estimation of gross calorific value of turkish coals. *XIIIth International Mineral Processing Symposium*, 1175–1180. Nevşehir, Türkiye.
- Parikh, J., Channiwala, S. A., & Ghosal, G. K. (2005). A correlation for calculating HHV from proximate analysis of solid fuels. *Fuel*, 84(5), 487–494. <https://doi.org/10.1016/j.fuel.2004.10.010>
- Patel, S. U., Jeevan Kumar, B., Badhe, Y. P., Sharma, B. K., Saha, S., Biswas, S., ... Kulkarni, B. D. (2007). Estimation of gross calorific value of coals using artificial neural networks. *Fuel*, 86(3), 334–344. <https://doi.org/10.1016/j.fuel.2006.07.036>
- Qi, M., Luo, H., Wei, P., & Fu, Z. (2019). Estimation of low calorific value of blended coals based on support vector regression and sensitivity analysis in coal-fired power plants. *Fuel*, 236, 1400–1407. <https://doi.org/10.1016/j.fuel.2018.09.117>

- Quej, V. H., Almorox, J., Arnaldo, J. A., & Saito, L. (2017). ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. *Journal of Atmospheric and Solar-Terrestrial Physics*, 155, 62–70. <https://doi.org/10.1016/J.JASTP.2017.02.002>
- Ren, S., & Gao, L. (2011). Combining artificial neural networks with data fusion to analyze overlapping spectra of nitroaniline isomers. *Chemometrics and Intelligent Laboratory Systems*, 107(2), 276–282. <https://doi.org/10.1016/j.chemolab.2011.04.012>
- Sherrod, P. H. (2014). DTREG Predictive Modeling Software. Retrieved from www.dtreg.com
- Sivrikaya, O. (2014). Cleaning study of a low-rank lignite with DMS, Reichert spiral and flotation. *Fuel*, 119, 252–258. <https://doi.org/10.1016/j.fuel.2013.11.061>
- Specht, D. F. (1991). A General Regression Neural Network. *IEEE Transactions on Neural Networks*, 2(6), 568–576. <https://doi.org/10.1109/72.97934>
- Tan, P., Zhang, C., Xia, J., Fang, Q. Y., & Chen, G. (2015). Estimation of higher heating value of coal based on proximate analysis using support vector regression. *Fuel Processing Technology*, 138, 298–304. <https://doi.org/10.1016/j.fuproc.2015.06.013>
- Tozsin, G., Acar, C., & Sivrikaya, O. (2018). Evaluation of a Turkish Lignite Coal Cleaning by Conventional and Enhanced Gravity Separation Techniques. *International Journal of Coal Preparation and Utilization*, 38(3), 135–148. <https://doi.org/10.1080/19392699.2016.1209191>
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. New York: Springer-Verlag.
- Vapnik, V., Golowich, S. E., & Smola, A. (1997). Support vector method for function approximation, regression estimation, and signal processing. *Annual Conference on Neural Information Processing Systems (NIPS)*, 281–287. https://doi.org/10.1007/978-3-642-33311-8_5
- Wen, X., Jian, S., & Wang, J. (2017). Prediction models of calorific value of coal based on wavelet neural networks. *Fuel*, 199, 512–522. <https://doi.org/10.1016/j.fuel.2017.03.012>
- Xia, W., Xie, G., & Peng, Y. (2015, June 1). Recent advances in beneficiation for low rank coals. *Powder Technology*, Vol. 277, pp. 206–221. <https://doi.org/10.1016/j.powtec.2015.03.003>
- Yalçın Erik, N., & 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. <https://doi.org/10.1080/19392699.2010.534683>
- Yılmaz, I., Erik, N. Y., & 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.