



## Turbo kompresörlerin çalışma hızını etkileyen faktörlerin makine öğrenmesi yöntemleri kullanılarak modellenmesi

### Modelling of the factors affecting the working speed of turbo compressors using machine learning methods

Sema Atasever<sup>1,\*</sup> , Uğur Sorgucu<sup>2</sup> 

<sup>1</sup> Nevşehir Hacı Bektaş Veli Üniversitesi, Bilgisayar Mühendisliği Bölümü, 50300, Nevşehir Türkiye

<sup>2</sup> Nevşehir Hacı Bektaş Veli Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 50300, Nevşehir Türkiye

#### Öz

Günümüzde nüfus artışı ile sanayi ve konutlara yönelik doğal gaz tüketim talebinin artması sonucunda, talebin az olduğu zamanlarda doğal gazın yeraltında depolanması ve çok olduğu zamanlarda ise depolardan kullanımının sağlanabilmesine yönelik hem ülkemizde hem de dünyada çeşitli projelerin planlanması yapılmıştır. Planlanan bu projeler vasıtasıyla doğal gaz talebindeki mevsimsel dalgalanmaların önlenmesi hedeflenmektedir. Tuz mağaralarında yeraltı doğal gaz depolaması için turbo kompresörler kullanılmaktadır. Turbo kompresörler doğal gazı yüksek basınçlara çıkarabilen önemli makinalardandır. Bu çalışma kapsamında bahsedilen turbo kompresörlerin çalışma hızını etkileyen faktörlerden akış, hat basıncı ve kuyu başı basıncının kompresör devrinin tahmini için makine öğrenmesi yöntemleri ile modellenmesi gerçekleştirilmiştir. 42 makine öğrenmesi modelinin denendiği çalışmadan elde edilen deneysel sonuçlara göre kompresör devrinin tahmininde Decision Tree Regressor (DT) algoritması 0.99 R<sup>2</sup>, 11.29 RMSE ve 0.01 (sn) çalışma zamanı ile en iyi sonucu veren algoritma olmuştur.

**Anahtar kelimeler:** Makine Öğrenmesi, Decision Tree Regressor, Yer altı doğal gaz depolaması, Turbo Kompresörler

#### 1 Giriş

Diğer fosil yakıtlara göre daha fazla çevre dostu olan doğal gaz, enerji ihtiyacının karşılanması noktasında sıklıkla ve yaygın bir şekilde kullanılan petrol türevi bir enerji türüdür. Uluslararası Enerji Ajansı (International Energy Agency, IEA) uzmanları 2035 yılında doğalgazın ikinci en büyük enerji kaynağı olacağı ve toplam enerji içindeki payının %25'e kadar artabileceğini tahmin etmektedir [1]. Doğalgaz üretimi sabitken, doğal gaz kaynaklarının kullanımı mevsime göre güçlü dalgalanmalar göstermektedir. Günümüzde nüfus artışı ile sanayi ve konutlara yönelik doğal gaz tüketim talebinin artması sonucunda, mevsimsel etkilerden kaynaklanan arz/talep uyumsuzluğunu dengelemek için, talebin az olduğu zamanlarda doğal gazın yeraltında depolanması ve çok olduğu zamanlarda ise depolardan kullanımının

#### Abstract

Due to the increasing demand for natural gas in industries and households caused by population growth, various projects have been planned both in our country and globally to store natural gas underground during periods of low demand and utilize it from storage during high-demand periods. It is aimed to prevent seasonal fluctuations in natural gas demand through these planned projects. Turbo compressors are used for underground natural gas storage in salt caves. Turbo compressors are significant machines capable of raising natural gas to high pressures. Within the scope of this study, machine learning methods were used to model the factors affecting the operating speed of the mentioned turbo compressors for predicting the compressor speed, including flow, line pressure, and wellhead pressure. According to the experimental results obtained from the study, where 42 machine learning models were tested, the Decision Tree Regressor (DT) algorithm provided the best results for predicting the compressor speed with an R<sup>2</sup> value of 0.99, RMSE of 11.29, and a runtime of 0.01 seconds.

**Keywords:** Machine Learning, Decision Tree Regressor, Underground natural gas storage, Turbo Compressors

sağlanabilmesine yönelik hem ülkemizde hem de dünyada çeşitli projelerin planlanması yapılmıştır. IEA verilerine göre ülkemiz; yeni gaz keşifleri, boru hatları, LNG terminalleri ve artan depolama yoluyla gaz tedarik seçeneklerini genişleterek büyük bir ilerleme kaydetmiştir [2].


Doğal gaz arzında diğer ülkelere bağımlı olan ülkemiz (doğal gazın yaklaşık %99'u ithal edilmektedir) için doğal gazın depolanması büyük önem arz etmektedir [3]. Yer altı gaz depolaması (Underground Gas Storage, UGS) diye isimlendirilen yöntemler yaklaşık yüzyıldır etkili bir şekilde kullanılmaktadır [4]. Tuz mağarası gaz depolaması da bahsedilen yöntemlerden biridir ve doğal gazın kaya tuzu mağaralarında yeraltında depolanması uzun yıllardır araştırma konusu olmuştur [5]. Yeraltı tuz mağarası, petrol, gaz ve basınçlı hava gibi güç kaynaklarının depolanması için en iyi yerlerden biri olarak kabul edilmektedir [6]. Planlanan

\* Sorumlu yazar / Corresponding author, e-posta / e-mail: sema@nevsehir.edu.tr (S. Atasever)

Geliş / Received: 22.02.2023 Kabul / Accepted: 16.10.2023 Yayımlanma / Published: 15.01.2024

doi: 10.28948/ngumuh.1254415

bu projeler vasıtasıyla konut sektöründeki doğal gaz talebinin artmasına bağlı olarak gelecekte meydana gelecek mevsimsel dalgalanmaların önlenmesi hedeflenmektedir [7]. Ülkemizde de yeraltı doğalgaz depolama tesisi projeleri bulunmaktadır. Ancak ilgili tesislerin stratejik öneme haiz olmaları sebebiyle, tesislere ilişkin kapasite, lokasyon ve kullanılan teknolojiye ilişkin detaylı bilginin bu makale kapsamında yer almayacaktır.



Şekil 1. Yeraltı doğal gaz depolama tesisi çeşitleri [8]

Renksiz, kokusuz, gaz halinde bir hidrokarbon olan doğal gaz birkaç farklı şekilde depolanabilir. En yaygın olarak üç tip tesiste basınç altında yeraltında tutulur. Bu yeraltı tesisleri, petrol ve/veya doğal gaz sahalarında, akiferlerde (aquifers) ve tuz mağarası oluşumlarında tükenmiş rezervuarlardır (Şekil 1). Doğal gaz ayrıca yer üstü tanklarda sıvı veya gaz halinde depolanır [8]. Türkiye jeoloji açısından oldukça şanslı bir yapıdadır. Nitekim tuz oyuklarında depolama yapılabildiği gibi tükenmiş rezervuar yöntemiyle depolama yapmak için de uygun lokasyonlar bulunmaktadır [1].


Tuz mağaralarında yeraltı doğal gaz depolaması için, bir veya birden fazla sondaj kuyusu kullanılarak, yaklaşık 1000 metre derinlikte bulunan geniş yer altı doğal tuz yapısındaki tuz birikintilerinin bir bölümünün kontrollü olarak tatlı su ile eritilmesi (leaching) ve tuzlu suların dışarı pompalanması yoluyla yavaş yavaş yer altı gaz depolama mağaraları denilen kavernalar (cavern) oluşturulur [4][7]. Dünyada 74 adet tuz mağarası (UGS) vardır. Bir tuz mağarası, kendi kendini iyileştirme özellikleri ve son derece düşük

geçirgenlik oranı nedeniyle gaz veya petrol depolaması için mükemmel bir seçimdir [7]. Bu mağaralarda doğal gaz depolayabilmek için, yaygın olarak turbo kompresörlere ihtiyaç duyulmaktadır. [9] Turbo kompresörler doğalgazı yüksek basınçlara çıkarabilen önemli makinalardandır. Turbo kompresörleri türbin ve santrifüj kompresör olarak iki kısımda inceleyebiliriz. Türbin kısmında aksel kompresör vasıtasıyla hava ortalama olarak atmosfer basıncına yakın bir değerle yani yaklaşık 1 bar ile aksel kompresörün girişine çekilir. Aksel kompresörde rotor kanatları havaya hız kazandırır daha sonra hava stator kanadına geçer. Stator kanadı bir difüzör gibi davranır rotor kanadına ters olarak konumlandırıldığı için havanın hızını azaltır ve basıncını artırır. Hava yaklaşık 13 bara yükseltilir ve yanma odasına basınçlı bir şekilde hava gönderilir. Yanma odasında yakıt olarak kullanılan doğalgaz yaklaşık olarak 32 bar (tipik boru hattı basınçları 40 bar ile 100 bar arasındadır [10]) ile yanma odasına gönderilir. Yakıt ve hava yanma odasında karışarak 2 adet ateşleme trafosu yardımıyla ateşlenir. Yanma odasından çıkan yüksek enerji ve basınç, basınç türbinini döndürür. Türbine bağlı olan şaft yardımıyla bu yüksek enerji mekanik enerjiye dönüşür. Şaft dişli kutusuyla santrifüj kompresöre bağlıdır. Santrifüj kompresör temel impeller ve difüzör olmak üzere iki temel elemandan oluşur. Basınçlandırılmak istenilen doğalgaz, impeller sayesinde merkezkaç kuvvetiyle döndürülerek doğalgaza yüksek dönme enerjisi kazandırır. Difüzöre gönderilen doğalgazın, difüzörde daralan bir kanal yardımıyla hızı yavaşlatılır. Böylece yavaşlayan doğalgaz basınçlandırılmış olur.

Günümüzde yakıt enerjisini mekanik enerjiye çeviren gaz türbinleri, enerji üretimi, ulaşım, petrokimya ve çeşitli endüstriyel işleme sistemlerinin ayrılmaz parçalarıdır [11]. Kompresörün çalışması için sıkıştırılmış havanın türbin gözeneklerinde (nozullarında), çıkış şaftı ile bir jeneratöre aktarılması gerekmektedir. Ardından, akış kompresörü sayesinde aksel veya radyal bir ivme sağlanarak makinenin içerisinde sıkıştırılmış hava elde edilir. Sıkıştırılmış havanın yanması için, yakıt ile karışması gerekmektedir. Bu işlem de yanma odasında gerçekleşir. Yanma odası çıkışında yüksek hız kazanan hava, yön değiştirerek türbin rotorunun dönmelerini sağlar [12].

En basit haliyle, kompresyon etkisi dönerek ilerleyen havanın kazandığı kinetik enerji yüklenmesi olarak söylenebilir. Havanın turbo kompresör içinde hızlanması ve sonrasında bir bölgede yığılması ile bir önceki adımda kazandığı enerji basınç etkisine dönüşür. Basit dinamik ilkeleriyle çalışan turbo kompresörlerde, hava hızı arttıkça basınç da artmaktadır. Bu anlamda hava akış hızı ile turbo basıncı arasında doğru orantı olduğu da söylenebilir. Hızla ve dönerek ilerleyen havayı bir basınçla ilerleten elemana impeller denir. Turbo kompresörlerin içinde içten yanmalı motorlardaki gibi basınç düzenleyici piston tipi mekanik sürme elemanları yoktur [9].

Kavernalar ortalama olarak yer altında 1150 metre ile 1450 metre arasında oluşturulmaktadır. Yer altındaki tuz tabakaları eritilerek kavernalar oluşturulur. Yer altındaki tuzu eritmek için yüksek oranda suya ihtiyaç vardır. Su santrifüj pompalar yardımıyla yüksek basınca ulaşana kadar basınçlandırılır.



Şekil 2. Kompresörlerin çalışma hızını etkileyen akış (std m<sup>3</sup>/h), hat basıncı ve kuyubaşı basıncına ait dağılım grafiği

Daha sonra basınçlandırılan su tuzun üzerine gönderilerek tuz tabakası eritilir. Eriyen tuz tabakası sondaj yardımıyla yeryüzüne çıkartılır. Boşalan tuz tabakasının yerine ise doğalgaz basılır. Kavernanın içindeki doğalgaz basıncı 66 bar ile 200 bar arasında değişmektedir (tipik olarak 100 bar ile 200 bar arasındaki nihai depolama basıncına kadar sıkıştırılması gerekir [10]). Fakat en az 66 bar değerindeki doğalgazın kavernada sürekli durması gerekmektedir. Bu 66 bar değerindeki kavernada sürekli bulunması gereken gaz yastık (base, cushion) gazı denilmektedir. Yastık gazı kavernadan çekilip ana hatta verilmeye başlanırsa kavernada çökmeler oluşmaktadır. Tuz mağaraları, çalışma gazı kapasitelerine göre çok yüksek geri çekme ve enjeksiyon oranları sağlar. Yastık gaz gereksinimleri ise nispeten düşüktür [8].

Tuz mağaraları ile ilgili çok sayıda araştırma yapılmıştır:

Li ve arkadaşları [4], yüksek oranda çözünmeyen tuz oluşumlarında gaz depolama için tuz mağarası için (salt cavern leaching) matematiksel modeli ile ilgili bilimsel bir rapor hazırlamışlardır. Çalışmalarında tuz mağarası

gelişimini tahmin etmek için matematiksel bir model oluşturarak çözünmeyen tortuların mağaranın gelişimi üzerindeki etkilerini araştırmışlardır. Sonuçta önerdikleri modelin mağara tabanı ve çatısının şekil tahmininde doğru sonuçlar verdiğini belirtmişlerdir.

Wang ve arkadaşları [6], çalışmalarında, tuz mağarası gaz deposunun şeklini ve boyutunu tasarlamak için kullanılan yeni bir model önermişlerdir. Önerdikleri yeni modelde mağara tasarımı alt ve üst yapılar olmak üzere iki kısma ayrılmıştır. Ayrıca kaya tuzunun gaz basıncı, sürtünme açısı ve kohezyonunun mağara stabilitesi üzerindeki etkilerini tartışmışlardır. Sonuçta yeni önerdikleri tuz mağarası gazı deposunun, aynı koşullar altında hacim yakınsama, yer değiştirme, plastik hacim oranı, güvenlik faktörü ve etkili gerinim açısından mevcut tuz mağarası şekline daha önemli avantajlara sahip olduğunu belirtmişlerdir.

Wanyan ve arkadaşları [13], Jiangsu'daki Jintan gaz deposunun tasarım deneyimine ve saha uygulamasına dayalı olarak tasarım konseptini tamamen güncellemişlerdir.

Güncellenen tasarım konseptine dayalı olarak, saha değerlendirmesi, mağara tasarımı ve kontrolü, stabilite değerlendirmesi, depolama kapasitesi, parametre tasarımı, eski mağara taraması ve kullanımı ve gaz depolama işletimi ve izlemesinde beş temel teknoloji önermişlerdir. Sonuç olarak, araştırma sonuçlarının, tuz mağarası yeraltı gaz depolama inşaat programının tasarımı ve mühendislik uygulaması için rehberlik sağladığı gibi, benzer gaz depolarının inşası için de teorik ve teknik destek sağlayacağını belirtmişlerdir.

Bu çalışma, enerji sektöründeki mevsimsel enerji talebi dalgalanmaları ile mücadele etmek için doğal gazın yeraltı depolamasında kullanılan turbo kompresörlerin önemini vurgulamaktadır. Bu sayede turbo kompresörlerin çalışma hızını etkileyen faktörlerin makine öğrenmesi yöntemleri kullanılarak yenilikçi bir yaklaşım ile modellenebileceği gösterilmiştir. Ayrıca, turbo kompresörlerin çalışma hızını etkileyen faktörlerin makine öğrenmesi yöntemleriyle modellenmesi, enerji verimliliği ve endüstriyel süreçlerde önemli bir ilerleme sağlayabilir. Bu çalışma, geleneksel yöntemlerin ötesine geçerek veri analitiği ve yapay zekâ algoritmalarını kullanarak daha hassas tahminler sunar. Bu yenilikçi yaklaşım, enerji maliyetlerini azaltma, üretkenliği artırma ve çevresel etkileri minimize etme potansiyeline sahiptir. Ayrıca, bu çalışma turbo kompresörlerin daha iyi anlaşılmasına katkıda bulunarak endüstriyel proseslerin daha güvenli ve verimli hale getirilmesine yardımcı olabilir, böylece literatüre önemli bir katkı sunar.

Kompresörlerin çalışma hızını etkileyen faktörler akış (std m<sup>3</sup>/h), hat basıncı ve kuyubaşı basıncıdır. Bu çalışma kapsamında bahsedilen faktörler kullanılarak kompresör devrinin (Round Per Minute, RPM) tahmininin makine öğrenmesi yöntemleri ile modellenmesi gerçekleştirilecektir.

Turbo kompresörler yer altı doğal gaz depolama tesislerinde kullanılan hayati öneme sahip makinelerdir. Doğal gazın etkili depolama ve dağıtım için gerekli olan yüksek basınçlara yükseltilmesinde önemli bir rol oynarlar. Bu çalışma, turbo kompresörlerin çalışma hızını etkileyen faktörleri tahmin etmek için makine öğrenmesi yöntemlerinin, özellikle de DT algoritmasının kullanılmasına olanak sağlamaktadır. Modellemeye elde edilen analiz sonuçları sistem süreçleri ve dinamikleri hakkında önemli bilgiler sağlayabilir. Bu açıdan, böylesine önemli tesislerdeki proseslerin makine öğrenmesi yöntemleri kullanılarak modellenmesi, bakım maliyetinin ve makine arızasının azalmasına ve operatör güvenliğinin artmasına yardımcı olacaktır.

Bu çalışmadaki temel fark ve yenilik, yeraltı doğal gaz depolaması için turbo kompresörlerin çalışmasını modellemek amacıyla 42 farklı makine öğrenimi algoritmasının uygunluğunun araştırılmasında yatmaktadır. Makine öğrenimi algoritmalarının karşılaştırmalı testleri sonucunda, yüksek doğruluk oranı ve düşük çalışma süresine sahip olan DT algoritmasının bu problem için en uygun model seçilmesi, bu çalışmayı diğerlerinden farklı kılmaktadır.

## 2 Materyal ve metod

### 2.1 Veri

Bu çalışmada, Türkiye’de faaliyet gösteren bir yeraltı doğalgaz depolama tesisine ait 18.02.2002-11.05.2022 tarihleri arasında ölçülen 50 adet veri kullanılmıştır. Rastgele bir şekilde, verilerin %80’i eğitim için, %20’si ise modelin doğruluğunu değerlendirmek için test veri seti olarak kullanılmıştır.

Kavernadaki basınç, kuyubaşı basıncı ile aynı değere sahiptir. Kavernadaki yani kuyubaşındaki basınç ne kadar yüksek olursa kompresörün çalışma devrini akış oranını gerçekleştirmek için arttırmak gerekir. Kompresör çıkışındaki basınç değeri arttıkça kompresör zorlanır. Kavernadaki basınç değeri azaldıkça kompresör çıkışındaki basınç değeri de azalacağından kompresör daha rahat çalışmaya başlar ve aynı akış değeri için kompresör daha düşük hızlarda akış oranını gerçekleştirir.

Bir diğer önemli parametre olan hat basıncı ana iletim hattındaki basıncı ifade eder. Genel olarak hat basıncı 40 bar ile 75 bar arasında bir değere sahip olmalıdır. Hat basıncı çok fazla düşerse iletim hattının sonundaki hatlara doğru basınç değeri düşeceğinden gaz akış oranı düşmektedir. Hat basıncı aynı zamanda kompresör giriş basıncını da ifade etmektedir.

### 2.2 Yöntem

Modellerin eğitim ve test süreçleri, 42 farklı makine öğrenimi regresyon modelini karşılaştırmak için hızlı bir yaklaşım sunan açık kaynak kodlu bir Python kütüphanesi olan Lazy Predict kullanılarak gerçekleştirilmiştir. Lazy Predict birçok temel model oluşturmaya yardımcı olan ve herhangi bir parametre ayarlaması gerekmeden hangi modellerin daha iyi çalıştığını anlamaya yardımcı olan bir kütüphanedir [14].

#### 2.2.1 Değerlendirme

Modellerin değerlendirilmesinde yaygın olarak kullanılan R<sup>2</sup> ve Root Mean Squared Error (RMSE) değerleri kullanılmıştır.

Determinasyon katsayısı (coefficient of determination) (genellikle R<sup>2</sup> olarak gösterilir), varyans analizi ve regresyon analizinde kullanılan bir kavramdır. R<sup>2</sup>’nin alacağı değer aralığı kullanılan modelin uygunluğuna bağlıdır; doğrusal en küçük kareler regresyon modelleri gibi standart durumlarda 0 ile 1 arasında bulunurlar. Determinasyon katsayısı hesaplanırken aşağıdaki denklem kullanılır (Denklem 1) [15]:

$$R^2 = 1 - \frac{\sum_i^n (y_i^{\text{gerçek}} - y_i^{\text{tahmin}})^2}{\sum_i^n (y_i^{\text{gerçek}} - \text{ortalama}(y_{\text{gerçek}}))^2} \quad (1)$$

Çeşitli disiplinlerde kullanılan mutlak hata ölçüsü olan RMSE hesaplanırken aşağıdaki denklem kullanılır (Denklem 2) [16]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i^{\text{tahmin}} - y_i^{\text{gerçek}})^2} \quad (2)$$



### 2.2.2 Makine öğrenimi algoritmaları

Makine öğrenimi üç ayrı şekilde sınıflandırılır: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) [17]. Bu çalışmada, turbo kompresörlerin kompresör devrini tahmin etmek için denetimli öğrenme kullanılmıştır. Denetimli öğrenme, eğitim için etiketli verileri (ör. akış, basınç vb.) kullanır ve verilerden bir işlev çıkarır. Kompresör devrini tahmin etmek için Lazypredict kütüphanesi kullanılarak toplam 42 regresyon modelinin performansı karşılaştırılmıştır. En iyi sonucu veren ilk beş model **Tablo 1**'de listelenmiştir.

**Tablo 1.** En iyi sonucu veren ilk beş model

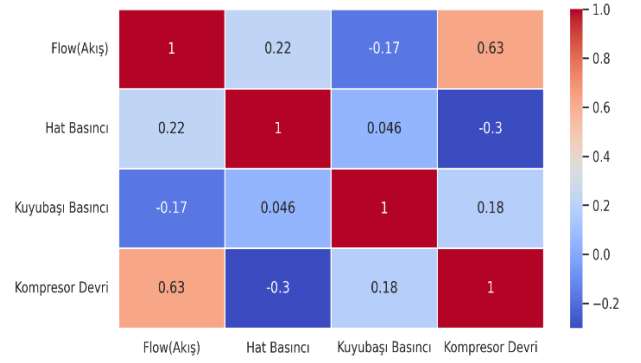
Model	R <sup>2</sup>	RMSE	Çalışma Zamanı (sn)
DT	0.99	11.29	0.01
GradientBoostingRegressor (GB)	0.95	23.40	0.05
AdaBoostRegressor (AB)	0.95	24.67	0.10
ExtraTreesRegressor (ET)	0.92	30.04	0.08
RandomForestRegressor (RF)	0.88	37.47	0.15

**Tablo 1** model sonuçlarının performansını listelemektedir. Tabloya göre en başarılı yöntem DT algoritması olmuştur. Bu modelleri performans anlamında diğer modellerden öne çıkaran hususlar, modellerin aşağıdaki özelliklerinden kaynaklanıyor olabilir:

- DT'nin, verilerdeki karmaşık doğrusal olmayan modelleri yakalama konusundaki üstünlüğü ve bunları, doğrusal ilişkilerin kısıtlayıcı varsayımı olmadan regresyon görevi için uygun hale getirmesi [18].
- Topluluk öğrenme (Ensemble Learning) yöntemlerinin genellikle tek bir modelden daha iyi performans sağladığı göz önüne alındığında [19], GB, AB, ET ve RF'nin ortak özelliklerinin popüler topluluk öğrenme yöntemleri olmaları.


#### 2.2.2.1 Karar ağaçları (DT)

Bu yaklaşım, makine öğrenimi, veri madenciliği ve istatistikte kullanılan tahmine dayalı modelleme tekniklerinden biri olan karar ağacı öğrenmesi veya karar ağaçlarının tümevarımı olarak da bilinir. Karar ağacı, sınıflandırma ve regresyon için yaygın olarak kullanılan bir modeldir ve bir karara varmak için evet veya hayır soruları sormaya devam ettikçe öğrenir. Ağaç modellerinde, hedef parametresi ayrık bir değerler kümesi alacaksa sınıflandırma ağaçları (classification trees), hedef değişkeni sürekli değerler alacaksa regresyon ağaçları (regression trees) olarak adlandırılır. Karar ağaçları, yaygın olarak kullanılan diğer makine öğrenme teknikleri arasında anlaşılır ve basit olarak değerlendirilmektedir [17], [20].




**Şekil 3.** Niceliksel değişkenler arasındaki korelasyon sonuçları


**Şekil 3** korelasyon sonuçlarını göstermektedir. Kırmızı renk pozitif, mavi renk ise negatif korelasyon olduğunu göstermektedir. Renk ne kadar koyu olursa korelasyon da o kadar güçlü demektir. Şekle göre akış ile kompresör devri arasında (0.63) pozitif anlamlı bir ilişki olduğu görülmektedir. **Şekil 4** model sonuçlarını göstermektedir. Şekle göre (0.99) R<sup>2</sup> değerine göre en iyi sonucu veren model DT algoritması olmuştur. **Şekil 5** modellerin RMSE hata değerlerini göstermektedir. DT için RMSE değeri 11.29 olarak bulunmuştur. **Şekil 6** model sonuçlarının çalışma zamanlarını göstermektedir. DT 0.01 saniye ile en hızlı regresyon modellerinden biri olmuştur ve bu haliyle oldukça hızlı yanıt veren bir algoritma olduğu söylenebilir.



**Şekil 4.** Model sonuçlarının R<sup>2</sup> değerleri açısından karşılaştırılması



Şekil 5. Model sonuçlarının RMSE değerleri açısından karşılaştırılması



Şekil 6. Model sonuçlarının zaman kriteri bakımından karşılaştırılması

### 3 Sonuç

Teknolojik gelişmelere paralel olarak artan enerji ihtiyacını karşılayan önemli enerji kaynaklarından biri olan doğal gazın yer altı tuz mağaralarında depolanması enerji arz ve talebini dengelemenin önemli yollarından biridir. Doğal gaz depolama tesislerinde doğal gaz depolama için kullanılan önemli makinelerden biri olan turbo kompresörlerin çalışma hızını etkileyen faktörlerin doğru bir şekilde modellenmesi ise oldukça karmaşık bir prosese sahip olan doğalgaz depolama tesisleri için önem arz etmektedir.

Bu çalışmada turbo kompresörlerin çalışma hızını etkileyen faktörlerden akış (std m<sup>3</sup>/h), hat basıncı ve kuyubaşı basıncının kompresör devrinin tahmininde makine öğrenmesi yöntemleri ile modellenmesi gerçekleştirilmiştir. 42 makine öğrenmesi modelinin denendiği çalışmadan elde edilen deneysel sonuçlara göre kompresör devrinin tahmininde DT algoritması 0.99 R<sup>2</sup>, 11.29 RMSE ve 0.01 (sn) çalışma zamanı ile en iyi sonucu veren algoritma olmuştur.

### Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

### Benzerlik oranı (iThenticate): % 11

### Kaynaklar

- [1] G. Sagnalıyeva. Değirmenköy yeraltı gaz depolama sahasının modellenmesi. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2016.
- [2] Turkey 2021 Energy Policy Review. Erişim: 29 Eylül 2023. Erişim adresi: [https://iea.blob.core.windows.net/assets/cc499a7b-b72a-466c-88de-d792a9daff44/Turkey\\_2021\\_Energy\\_Policy\\_Review.pdf](https://iea.blob.core.windows.net/assets/cc499a7b-b72a-466c-88de-d792a9daff44/Turkey_2021_Energy_Policy_Review.pdf)
- [3] E. M. Orhan. Designing a system for natural gas storage facilities in salt caverns. Yüksek Lisans Tezi, Ankara Yıldırım Beyazıt Üniversitesi Fen Bilimleri Enstitüsü, Türkiye 2020.
- [4] J. Li, X. Shi, C. Yang, Y. Li, T. Wang, ve H. Ma, Mathematical model of salt cavern leaching for gas storage in high-insoluble salt formations. Sci Rep, 8, 1, 1-12, 2018. <https://doi.org/10.1038/s41598-017-18546-w>
- [5] K. Khaledi, E. Mahmoudi, M. Datcheva, ve T. Schanz, Analysis of compressed air storage caverns in rock salt considering thermo-mechanical cyclic loading. Environ Earth Sci, 75, 15, 1-17, 2016. <https://doi.org/10.1007/s12665-016-5970-1>
- [6] T. Wang, X. Yan, H. Yang, X. Yang, T. Jiang, ve S. Zhao, A new shape design method of salt cavern used as underground gas storage. Appl Energy, 104, 50-61, 2013. <https://doi.org/10.1016/j.apenergy.2012.11.037>
- [7] Tuzgözü yeraltı doğal gaz depolama tesisi çevresel etki değerlendirme raporu. Erişim: 29 Eylül 2023. Erişim adresi: <https://www.botas.gov.tr/uploads/dosya/Yoneticisi/214299-1.pdf>

- [8] The Basics of Underground Natural Gas Storage. Erişim: 29 Eylül 2023. Erişim adresi: <https://www.eia.gov/naturalgas/storage/basics/>
- [9] Turbo Kompresörler. Erişim: 29 Eylül 2023. Erişim adresi: <http://joycompressor.com/turbokompresorler.html>
- [10] R. Kurz ve K. Brun, Assessment of compressors in gas storage applications. J Eng Gas Turbine Power, 132, 6, 2010. DOI: 10.1115/1.4000147
- [11] M. T. Schobeiri, Gas turbine design, components and system design integration: Second revised and enhanced edition. Springer Nature, 2019. DOI: 10.1007/978-3-319-58378-5
- [12] R. Özgür, Kombine Çevrim santrallerinde performans izleme yöntemleri. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2011.
- [13] Q. Wanyan, G. Ding, Y. Zhao, K. Li, J. Deng, ve Y. Zheng, Key technologies for salt-cavern underground gas storage construction and evaluation and their application. Natural Gas Industry B, 5, 6, 623-630, 2018. <https://doi.org/10.1016/j.ngib.2018.11.011>
- [14] Lazy Predict. Erişim: 29 Eylül 2023. Erişim adresi: <https://pypi.org/project/lazypredict/>
- [15] A. Di Bucchianico, Coefficient of determination ( $R^2$ ). Encyclopedia of statistics in quality and reliability, 1, 2008. <https://doi.org/10.1002/9780470061572.eqr173>
- [16] W. Wang ve Y. Lu, Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model. IOP Conference series: Materials science and engineering, 2018, 12049. DOI 10.1088/1757-899X/324/1/012049
- [17] J. Hong vd., Development and evaluation of the combined machine learning models for the prediction of dam inflow. Water (Basel), 12, 10, 2927, 2020. <https://doi.org/10.3390/w12102927>
- [18] S. Bishnoi ve B. K. Hooda, Decision Tree Algorithms and their Applicability in Agriculture for Classification. Journal of Experimental Agriculture International, 44, 7, 20-27, 2022. DOI: 10.9734/JEAI/2022/v44i730833
- [19] X. Zhu, J. Hu, T. Xiao, S. Huang, Y. Wen, ve D. Shang, An interpretable stacking ensemble learning framework based on multi-dimensional data for real-time prediction of drug concentration: The example of olanzapine. Front Pharmacol, 13, 975855, 2022. <https://doi.org/10.3389/fphar.2022.975855>
- [20] Z. H. Kilimci, Ensemble Regression-Based Gold Price (XAU/USD) Prediction. Journal of Emerging Computer Technologies, 2, 1, 7-12.

