



**BİR HAVA ISITMALI GÜNEŞ KOLLEKTÖRÜNÜN ENERJİ VERİMİNİN
MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE MODELLENMESİ**

İBRAHİM HAKKI SAYAN

YÜKSEK LİSANS TEZİ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DR. ÖĞR. ÜYESİ MEHMET DAŞ

Ağustos - 2022

Her hakkı saklıdır



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**BİR HAVA ISITMALI GÜNEŞ KOLLEKTÖRÜNÜN ENERJİ
VERİMİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE
MODELLENMESİ**

YÜKSEK LİSANS TEZİ

İbrahim Hakkı SAYAN

Danışman: Dr. Öğr. Üyesi Mehmet DAŞ

TOKAT- 2022

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Mehmet DAŞ danışmanlığında hazırlamış olduğum “Bir Hava Isıtmalı Güneş Kollektörünün Enerji Veriminin Makine Öğrenmesi Algoritmaları İle Modellenmesi” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

31/08/2022

İBRAHİM HAKKI SAYAN

.....



ÖNSÖZ

Yapmış olduğum tez çalışması sürecinde bilgi ve tecrübelerinden faydalandığım ve her konuda yardımcı olan danışman hocam Dr. Öğr. Üyesi Mehmet DAŞ'a teşekkürlerimi bir borç bilirim. Makine öğrenmesi aşamasında yardımcı olan Dr. Öğr. Üyesi Kamil Neyfel ÇERÇİ hocama, öğrenci arkadaşım makine yüksek mühendisi Necat TABAK'a, teşekkür ederim. Ayrıca hayatımın her döneminde desteklerini hiçbir zaman eksik etmeyen aileme teşekkür ederim.

İbrahim Hakkı SAYAN

31 Ağustos 2022

ÖZET
BİR HAVA ISITMALI GÜNEŞ KOLLEKTÖRÜNÜN ENERJİ VERİMİNİN MAKİNE
ÖĞRENMESİ ALGORİTMALARI İLE MODELLENMESİ

İbrahim Hakkı SAYAN
Yüksek Lisans, Eğitim Programları ve Öğretim Bilim Dalı
Tez Danışmanı: Dr. Öğr. Üyesi Mehmet DAŞ
Ağustos, 2022 xii + 43 sayfa

Enerji üretiminde kullanılan fosil yakıtların maliyet-talep artışı ve çevreye olan olumsuz etkileri nedeniyle günümüzde araştırmacılar insanlığın geleceği için sürdürülebilir farklı enerji kaynaklarını araştırma ihtiyacı duymuştur. Bu sebeple güneş enerjisinin temiz ve yenilenebilir bir enerji kaynağı olarak kullanımı giderek artış göstermiştir. Güneş'ten fayda sağlamak için çalışması ısı eşanjörü şeklinde olan güneş kollektörlerinin kullanımı yaygındır. Ayrıca güneş enerjisinde verilerin enerji sistemlerinin analizi ve değerlendirilmesinde kullanılması, doğru tahmin edilmesi ve faydalı modellerin oluşturulmasına yönelik çalışmalar son yıllarda artış göstermiştir. Güneş kollektörlerinde veri analizinde dünyanın farklı yerlerinde kullanılan en yaygın yöntem makine öğrenmesidir. Makine öğrenimi algoritmaları, esnek ve parametrik olmayan modelleme araçlarıdır. Karmaşık problemlerde oldukça etkilidir. Tahmin, sınıflandırma, kümeleme gibi birçok probleme çözüm bulabilmektedir. Bu tez, havalı güneş kollektörünün (HGK) termodinamiğin 1. Yasası ile elde edilen enerji verimliliği değeri için bir makine öğrenme algoritması ile faydalı bir model sunmaktadır. Bu model için pace regresyon, yapay sinir ağı, karar ağacı ve destek vektör makine algoritmaları kullanılmıştır. Pace regresyon sayesinde HGK'nın termal performansı matematiksel bir eşitlik ile ifade edilmiştir. Daha önce deneysel çalışması yapılmış bir HGK'nın enerji verim değerleri %3 doğruluk ile karar ağacı algoritması tarafından modellenmiştir. Elde edilen modellerin doğruluk sonuçları, makine öğrenmesi algoritmaları ile üretilen enerji denklemlerinin farklı tip güneş kolektörlerinde de kullanılabilme potansiyeline sahip olabileceği göstermektedir.

Anahtar Kelimeler: Güneş Enerjisi, Havalı Güneş Kollektörü, Enerji verimi, Makine Öğrenmesi Algoritmaları, Pace Regresyon, Elastic.Net Regresyon

ABSTRACT
**MODELING THE ENERGY EFFICIENCY OF AN AIR HEATED SOLAR
COLLECTOR WITH MACHINE LEARNING ALGORITHMS**

Ibrahim Hakki SAYAN
Master's Thesis, Division of Curriculum, and Instruction
Advisor: Assit.Prof.Dr. Mehmet DAŞ
August, 2022, xii+ 43 pages

Increases in the cost-demand of fossil fuels used in energy production and environmental concerns have led people to alternative energy sources. The use of solar energy as a clean and renewable energy source has gradually increased. It is widespread to use solar collectors working as heat exchangers to benefit from solar energy. In addition, studies on the use of data in solar energy in the analysis and evaluation of energy systems, their accurate estimation, and the creation of utility models have increased in recent years. Machine learning is the most common method used in different parts of the world in data analysis in solar collectors. Machine learning algorithms are flexible and non-parametric modeling tools. It is quite effective in complex problems. It can find solutions to many problems such as estimation, classification, and clustering. This thesis presents a useful model with a machine learning algorithm for the energy efficiency value obtained by the 1st Law of Thermodynamics of the solar air collector (HGK). The pace regression, artificial neural network, decision tree, and support vector machine algorithms were used for this model. Thanks to Pace regression, the thermal performance of HGK is expressed with a mathematical equation. The energy efficiency values of an HGK, which have been experimentally studied before, are modeled by the decision tree algorithm with 3% accuracy. The accuracy results of the models obtained show that the energy equations produced by machine learning algorithms may have the potential to be used in different types of solar collectors.

Keywords: Solar Energy, Air Solar Collector, Energy efficiency, Machine Learning Algorithms, Pace Regression, Elastic.Net Regression

İÇİNDEKİLER

	<u>Sayfa</u>
ETİK SÖZLEŞME	i
JÜRİ KABUL ve ONAY	ii
ÖNSÖZ	iii
ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ŞEKİL LİSTESİ.....	vii
TABLO LİSTESİ.....	viii
SİMGELER ve KISALTMALAR.....	ix
1. GİRİŞ	1
1.1. Pasif Güneş Enerjisi Sistemleri.....	1
1.1.1. Ürün kurutma ve seralar	2
1.1.2. Su damıtma sistemleri	3
1.2. Aktif Güneş Enerjisi Sistemleri	4
1.2.1 Isı enerjisi üretimi.....	4
1.2.2. Yüksek sıcaklıklı güneş enerjisi sistemleri.....	8
2. LİTERATÜR ÖZETLERİ	12
3. MATERYAL ve YÖNTEM.....	17
3.1. Havalı Güneş Kollektörleri	17
3.2. Deneysel Kurulum	18
3.3.Deneysel Prosedür	20
3.4. Enerji Analizi	21
3.5. Yapay Zeka	21
3.5.1. Yapay sinir ağları	22
3.5.2. Regresyon analizi ve karar ağacı	25
3.5.3. Destek vektör makinesi	27
3.5.4. Doğrusal destek vektör regresyon	27
3.5.5. Doğrusal olmayan destek vektör regresyon	28
3.5.6. Pace regresyon.....	30
4. BULGULAR	33
5. SONUÇ ve ÖNERİLER.....	38
6. KAYNAKLAR	39

ŞEKİL LİSTESİ

<u>Şekil</u>	Sayfa
Şekil 1. 1 Güneş altında ve serada gıda kurutma	3
Şekil 1.2. Güneş enerjili su arıtma sistemi.....	4
Şekil 1.3. Sulu ve havalı güneş kolektörleri	8
Şekil 1.4. Parabolik oluklu güneş kolektörü	9
Şekil 1.5. Merkezi alıcı ve çanak tip güneş kolektör sistemleri	10
Şekil 3.1. HGK komponentleri	18
Şekil 3.2. A-HGK detayı, B- Deneysel görünüm	19
Şekil 3.3. Sıcaklık ve ısıtım değerlerinin zaman ile değişimi.....	21
Şekil 3.4. YSA yapısı.....	24
Şekil 3.5. Dört boyutlu özellik uzayına sahip üç sınıftan oluşan karar ağacı yapısı.....	26
Şekil 4.1. DVM algoritması ve deneysel enerji verim değerlerinin karşılaştırılması.....	33
Şekil 4.2. YSA algoritması ve deneysel enerji verim değerlerinin karşılaştırılması.....	34
Şekil 4.3. KA algoritması ve deneysel enerji verim değerlerinin karşılaştırılması	35
Şekil 4.4. KA algoritması ağaç yapısı.....	35
Şekil 4.5. Pace regresyon ve deneysel enerji verim değerlerinin karşılaştırılması.....	36

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 3.1. V tipi HGK teknik özellikleri	20
Tablo 3.2. Deneylerde kullanılmış ölçüm cihazları	20
Tablo 3.3. DVM’de kullanılan temel kernel fonksiyonları ve parametreleri	29
Tablo 4.1. KA algoritması Lineer Model denklemleri	36
Tablo 4.2. Tahminsel yapay zekâ modellerinin hata analiz sonuçları	37

SİMGELER ve KISALTMALAR

Simgeler	Açıklama
A	Alan (m^2)
C_p	Sabit basınçta özgül ısı ($kJ/kg.K$)
I	Yüzeye gelen toplan ısıtım miktarı (W/m^2)
$\dot{m}$	Kütleli debi (kg/s)
Q	Birim zamanda ısı geiři miktarı (W)
T	Sıcaklık (K)
η	Verim
ρ	Yoğunluk (kg/m^3)

Kisaltmalar	Açıklama
YSA	Yapay sinir ağı
KA	Karar ağacı
DVM	Destek vektör makinesi
PR	Pace regresyon

1. GİRİŞ

Enerji, insanlığın varoluşundan bugüne kadar özellikle teknoloji çağı olan günümüzde, insanların oluşturduğu tüm medeniyetlerde olduğu gibi toplumların sosyal ve ekonomik olarak ilerlemesinde önemli bir yere sahiptir. Dünya nüfusunun artışı ile enerji ihtiyacı da artmaktadır (Liu ve diğerleri., 2022). Teknolojik gelişimlere bağlı olarak ve yaşam standartlarının artışıyla bireysel enerji tüketimi artmaktadır. Dünyada enerji ihtiyacının karşılanması için çevreci, ekonomik ve sürdürülebilir enerji kaynaklarının araştırılması ve kullanımı konusunda araştırmalar son yıllarda daha da atmaktadır. Bu enerji kaynaklarından ilk sırada yer alan güneş enerjisidir. Yapılan çalışmalar dünyada enerji gereksinimi önümüzdeki yıllarda artacağını ortaya koymaktadır (Ihoume ve diğerleri., 2022).

Son yıllarda artan enerji ihtiyacının karşılanabilmesi için alternatif enerji kaynaklarının araştırılması üzerine araştırmaların sayısı gün geçtikçe artmaktadır. Güneş enerjisi sahip olduğu potansiyelden dolayı üzerine en çok araştırma yapılan yenilenebilir enerji kaynağıdır. Güneşten dünyaya gelen enerjinin düşük bir oranı bile dünyanın ihtiyacı olan toplam enerjiyi karşılamaktadır. Yapılan araştırmalar da gelecekte dünyada enerji talebinin çok fazla olacağı ve fosil kaynakların bu ihtiyacı karşılamayacağı öngörülmektedir (Dong ve diğerleri., 2021).

Dünyanın enerji ihtiyacının hızla artması gelecekte ortaya çıkacak enerji talebi için güvenilir, uygun maliyetli ve yenilenebilir enerji kaynaklarına yönelmek önem taşımaktadır. Diğer yenilenebilir enerji kaynakları arasında güneş enerjisi, enerji krizinde uzun vadeli sorunları yönetmek için umut verici ve düşük maliyetli olarak kullanılabilen bir enerji kaynağıdır. Güneş enerjisi endüstrisi, diğer yenilenebilir enerji kaynaklarına kıyasla kullanılabilirlik, maliyet etkinliği, erişilebilirlik, kapasite ve verimlilik açısından üstün olduğundan gelecekteki enerji talebi için kesinlikle en iyi seçenek olacaktır (Arslan and Aktaş, 2020).

Güneşten dünyaya gelen güneş enerjisi miktarı 1.78×10^{14} kW olarak bilinmektedir. Bu miktar dünyada ihtiyaç duyulan toplam enerji miktarının yaklaşık 20 katını

karşılayabilecek potansiyeldedir. Ülkemiz orta kuşak ikliminde bulunduğu için Güneşten ısınım şiddeti ve güneşlenme süresi olarak verimli bir coğrafyada bulunmaktadır. Türkiye aylık toplam ortalama güneş enerji miktarı 3.6 kWh/m²-gün'dür ve güneşlenme süresi 7.2 saat/gün'dür (Alıç and Daş, 2020).

Güneş enerjisinden genel olarak kolektörler aracılığı ile fayda sağlanmaktadır. Bu kolektörler genelde basit bileşenlerden oluşmaktadır. Bunlar, saydam cam örtü, absorban plaka, kolektör kasası ve kolektör yalıtımı şeklinde dört kısımdan oluşmaktadır (Chauhan ve diğerleri., 2018).

Güneş enerjisi sistemleri iki ana gruba ayrılabilir;

1. Pasif Sistemler

- Ürün kurutma ve seralar
- Su damıtma sistemleri

2. Aktif Sistemler

- Isı üreten sistemler
- Elektrik üreten sistemler

1.1. Pasif Güneş Enerjisi Sistemleri

Pasif sistemler güneş ışınlarından herhangi bir ara ekipman olmadan doğrudan kullanılırlar. Genel olarak güneş enerjisini doğrudan toplayarak alan sistemlerin hepsi pasif sistemler olarak isimlendirilir.

1.1.1. Ürün kurutma ve seralar

Bu sistemler daha çok tarımsal alanda güneş enerjisi pasif yapıda kullanılmaktadır. Sistem içerisindeki hava hareketi koşullandırılması ile aktif bileşenlerle de kurutma


işlemi yapılabilir. Genellikle geleneksel ürün kurutma işlemi yapmaktadır. Şekil 1 de Pasif bir sistem için güneş enerjisi ile serada ve açık havada kurutma örnekleri gösterilmiştir (Chauhan ve Kumar, 2018).



Şekil 1. 1 Güneş altında ve serada gıda kurutma (Chauhan ve Kumar, 2018).

1.1.2. Su damıtma sistemleri

Bu sistemlerde arıtma yapılacak kirli su havuzu üzerine belirli bir eğime sahip cam yüzeyle kapatılması ile sistem içerisinde güneşten alınan ısıyı ile buharlaşan su sistemdeki kapaklar ve kanallar aracılığı ile yoğunlaşması sonucunda toplanır. Bu sistemler genellikle temiz su bulunmayan bölgelerde kullanılmaktadır. Gelecekte insanlığın ve dünyanın temiz su sorunu için kullanılabilecek bu sistemlerin daha yaygın kullanılması yapılan çalışmalarla hedeflenmektedir. Şekil 2 de güneş enerjili bir su arıtma sistemi ve güneş yardımı ile su buharlaştırılmış ve damıtma işlemiyle arıtılması verilmiştir (Higgins ve diğerleri., 2018).



Şekil 1. 2 Güneş enerjili su arıtma sistemi (Higgins ve diğerleri., 2018).

1.2. Aktif Güneş Enerjisi Sistemleri

Bu sistemde güneş enerji kollektörleri vasıtasıyla güneşten gelen ışınlardan kollektör içerisindeki akışkana aktarılması ile kullanım sağlanmaktadır.

1.2.1 Isı enerjisi üretimi

Düşük sıcaklık için kullanılan güneş enerjisi sistemleridir. Sistem üzerine gelen güneş ışınlarından daha fazla yararlanmak için ışınlar dik gelecek şekilde ayarlanan sistemlerdir. Genellikle sistem açısı kullanılacak bölgenin coğrafi yapısına veya arazi yapısına göre bu açı belirlenmektedir. Bu sistemlerde kollektör yüzeyine gelen ışınlardan elde edilen ısı enerjisi sistemin içerisindeki akışkana aktarılması ile sıcak su veya sıcak hava elde edilir. Kollektör yapısı genel olarak cam yüzey, absorber plaka, yalıtım malzemesi, kollektör kasası gibi bileşenlerden oluşmaktadır. Düzlemsel kollektörler dünyanın birçok yerinde yaygın olarak ısı enerjisi elde etmek için kullanılır. Kollektör Sistemi güneşten aldığı ışınlardan kollektör yüzeyinden absorber plakaya aktararak

kollektör içerisinde bulunan akışkana (su, hava) aktarması ile ısı enerjisi elde etmektedir.

Düzlemsel kollektörler birçok uygulama alanı bulunmaktadır (Serdar Öksüz, 2014).

Düşük sıcaklık uygulamaları;


- Sıcak su elde edilmesi
- Binaların iklimlendirilmesi
- Seracılıkta
- Ziraî ürünlerde kurutulması
- Yüzme havuzu ısıtılması
- Deniz suyundan içme suyu elde edilmesi
- Tuz üretimi
- Sulama
- Toprak solarizasyonu
- Güneş enerji ile pişirme

gibi yaygın kullanım alanları vardır.

Güneş kollektörleri genel sınıflandırılması Şekil 1.3.'te gösterilmiştir.

Şekil 1.3'te güneş kollektörleri; Sabit kollektörler ve Odaklanabilen kollektörler olmak üzere ikiye ayrılır (Keçel, 2015).


Odaklanabilen kollektörler; parabolik, lineer, parabolik oluklu ve merkez alıcılar olmak üzere sınıflara ayrılırlar. Sabit kollektörler; düzlemsel ve vakumlu tüplü olarak ikiye ayrılır. Düzlemsel kollektörler ise sistemdeki akışkana bağlı olarak sıvılı ve havalı güneş kollektörü olarak ikiye ayrılır (Gülmez, 2020).



Şekil 1. 3 Güneş Kollektörlerinin Sınıflandırılması


Güneş kollektörleri; Yüzeye gelen güneş ışınımı ile sistem içerisine aktarılması ile enerji elde edilmesi için tasarlanan sistemlerdir. Kollektörde güneşten gelen ışınımın sisteme aktarılması için en önemli kısım absorber plakadır. Bu plakalar farklı iletken kat sayısına sahip malzemelerden bakır, alüminyum, paslanmaz çelik gibi malzemelerden yapılmaktadır.

Şekil 1.4'te Akışkanı su olan HGK ve akışkanı hava olan HGK şematiği verilmiştir. Güneşten gelen ışınım geçirgen yüzey ve absorban yüzey arasından geçen akışkanı ısıtarak kollektörden çıkış yapıp sistem dışına ya da kullanım alanına atılmaktadır.



Şekil 1. 4. Su Akışkanlı ve Hava Akışkanlı Güneş Kollektörü


Güneş kolektörlerinin en yaygın kullanım şekli düzlemsel güneş kolektörleridir. Güneşten gelen ışınlamalar bu kolektörler aracılığı ile kolektör içerisinde bulunan akışkana ısının aktarılması ile fayda sağlanmaktadır. Şekil 1.5’de bu sistemlerin görseli verilmiştir. Bu sistemler imalat kolaylığı, ekonomik olması ve ucuz olmasından dolayı tercih edilmektedir. Düzlemsel kolektörlerin genel yapısı saydam örtü, taşıyıcı boru, absorban plaka, plaka içerisindeki kanalların ısı kaybının engellemek için kullanılan yalıtım malzemeleri ve kolektör kasasından oluşmaktadır (Sancar ve Bulut, 2021).



Şekil 1. 5. Güneş Kollektör Sistemi Bileşenleri

Düzlemsel kolektörlerde basit yapılı olanlar 70°C sıcaklık değerleri elde edilirken, gelişmiş yapılı kolektörlerde ise 90°C gibi yüksek sıcaklık değerleri elde edilmektedir. Bu sistemler verimleri yüksek olduğu için özellikle sıcak su veya sıcak hava elde


edilmesi gibi ticari alanlarda yaygın kullanımları vardır. Şekil 1.6’da sulu ve havalı güneş kolektörlerine ait fotoğraflar verilmiştir (Hassan ve diğerleri., 2020; Lizama-Tzec ve diğerleri., 2019). Toplam kurulu güneş kolektörü alanı tüm dünyada yaklaşık 30 milyon m² gibi bir değerdir. Güneşten en çok faydalanan ülkeler sırasıyla ABD, Japonya, Avustralya ve Yunanistan’dır.



Şekil 1. 6. Sulu ve havalı güneş kolektörleri (Hassan ve diğerleri., 2020; Lizama-Tzec ve diğerleri., 2019)


1.2.2. Yüksek sıcaklıklı güneş enerjisi sistemleri

Parabolik oluklu tip güneş kolektörleri, kolektör merkezinde yatay olarak konumlandırılmış bir boru vasıtasıyla güneşten gelen ışınlamalar kolektör merkezinde yatay olarak konumlandırılmış boru içerisindeki akışkana kolektörün yatay olarak merkezinde toplanan ışınlamaların iletimi ile kazanç sağlanması prensibine dayalı olarak çalışmaktadır. Bu sistemler güneşin doğu-batı yönünde hareketini doğrusal olarak takip edecek şekilde tasarlanır. Bu kolektörlerde genel olarak 350-400°C gibi sıcaklıklar elde edildiği için yüksek sıcaklıklar uygulamalarında kullanılmaktadır. Şekil 1.7 de parabolik güneş kolektörü verilmiştir (Rezaeian ve diğerleri., 2021).



Şekil 1. 4. Parabolik oluklu güneş kolektörü (Rezaeian ve diğerleri., 2021)

Parabolik güneş kolektörleri, eksenel olarak güneşi takip etmesinden dolayı güneşten gelen ışınimleri ve güneşlenme süresinden yüksek düzeyde yararlanabilmektedir.



Şekil 1. 8. Yoğunlaştırıcı Güneş Enerji Sistemi Şematiği

Yoğunlaştırıcı sistemlerin genel şematiği Şekil 1.8’de verilmiştir. Güneşten gelen ışınlımlar güneş kollektörü yüzeyinde yoğunlaştırılarak bu enerjiyi toplayan alıcıda birleşir ve kullanım alanına aktarımı sağlanarak fayda sağlanır. Bu sistemlerden elektrik üretimi ve buhar elde edilmesi için kullanılmaktadırlar.

Merkezi Alıcı Sistemler: Her biri tekil olarak odaklama yapan ve heliostat olarak adlandırılan aynalar yardımıyla oluşturulan alandan, alıcı olarak tasarlanan yüksek bir noktadaki kuleye montajlanmış ısı eşanjörüne yoğun olarak yansıtılması ile elektrik üretimi sağlanmaktadır. Merkezi alıcılı tip ve çanak tip güneş kollektör sistemleri Şekil 1.9’da gösterilmiştir (Zılanlı, 2013).



Şekil 1. 9. Merkezi alıcı ve çanak tip güneş kollektör sistemleri

Güneş enerjisi doğal enerji kaynakları içerisinde tarih boyunca en çok kullanıma sahip enerji kaynağıdır. Son zamanlarda güneşin dünyaya sağladığı sürekli enerji ve çevreye zararının olmaması da kullanımının araştırılması açısından öne çıkan en belirgin özelliğidir. Bu durum güneş enerjisinin birçok alanda uygulamalar yapılması ile kullanımını sağlanmaktadır. Bilgi ve teknoloji çağı olan günümüzde analizler sonucunda elde edilen verilerin ve sistemlerin doğru bir şekilde önceden tahmin edilmesi deneysel olarak yapılacak çalışmaların maliyetlerini düşürmek açısından büyük önem taşımaktadır. Birçok uygulama alanında yapılan analizler içerisinde yaygın olarak kullanılan makine öğrenmesi algoritmalarıdır. Özellikle büyük ölçekli ve karmaşık veriler söz konusu olduğunda analizlerde insan faktörü yeterli olmamaktadır.

Bu noktada makine öğrenme algoritmaları hesaplamalarda çelişkiyi giderme ve karar verme adımımda daha iyi sonuçlar elde etmemizi sağlamaktadır.

Güneş, günlük yaşantımızda ve insan hayatının büyük bir kısmına etkisi olan çevreci ve maliyeti düşük bir enerji kaynağıdır. Güneşin dünyaya sağlamış olduğu enerji çeşitli şekillerde ısı ve elektrik üretimi gibi bireysel ve endüstriyel olarak kullanılmaktadır.

Dünyada ve ülkemizde güneş enerjiden çoğunluklar güneş kollektörleri kullanılarak yararlanılmaktadır. Son zamanlarda özellikle hava ısıtımali güneş enerjisi sistemleri bireysel olarak evlerde, tarımsal ürün kurutmada ve endüstriyel alanlarda kullanılabilmektedir. HGK'ların termal performansı düşük olması nedeniyle yaygın kullanıma sahip değildir. Son zamanlar HGK'ların termal performansını artırıcı birçok Ar-ge ve bilimsel çalışmalar yapılmaktadır. HGK'ların termal performansları için faydalı bir model üretilmesi yapılan bu çalışmalar için hem zamandan tasarruf hem de bir doğrulama kriteri sunabilir.

Bu tez çalışmasının amacı, bir hava ısıtımali güneş kolektörünün (HGK) enerji verimini makine öğrenmesi algoritmaları ile modelleyerek faydalı bir matematiksel eşitlik üretmektir. Bu eşitlik için HGK'nın bulunduğu ortam şartları göz önüne alınmıştır. Böylelikle bu konu hakkında çalışan araştırmacılar için faydalı bir eşitlik elde edilmesi beklenmektedir

Bu tez çalışmasında bir düzlemsel HGK için yapay zekâ yöntemleri kullanılarak faydalı enerji modeli oluşturulmuştur. Bu model sayesinde çevre sıcaklığı ve güneş radyasyon değerleri gibi çevresel faktörlerle HGK'nın termal performansı matematiksel eşitlikler ile belirlenmiştir. Farklı tip HGK'lar için uygulanabilecek olan bu eşitlik sayesinde HGK'nın termal performansı hakkında bir ön bilgi elde edilecektir.

2. LİTERATÜR ÖZETLERİ

Literatürde havalı güneş kolektörleri (HGK) ile alakalı deneysel birçok değerli çalışmalar yapılmıştır. Bu çalışmalar içerisinde HGK'nın bazı deneysel parametreleri yapay zekâ yöntemleri ile modellenmiş ve tahmin edilmiştir. Bu bölümden öncelikle HGK ile alakalı deneysel çalışmaları incelenmiş ve kısaca literatür özetleri aşağıda yazılmıştır.

Machi ve diğerleri, üçgen entegre kanatlı çift geçişli bir HGK'nın performansını deneysel olarak araştırmışlardır. Aynı tasarıma sahip kanatlı ve kanatsız iki kolektör test edilerek kolektörün ısı verimini karşılaştırmışlardır. Kolektörün hava kütle akış hızının termal performans üzerindeki etkisini, çeşitli çevresel koşullar altında araştırmışlardır. Sonuç olarak kanatlı kolektör boyunca sıcaklık farkının her zaman daha yüksek olduğunu ve giriş ve çıkış sıcaklığı arasındaki daha yüksek değişim sıcaklığının daha yüksek faydalı ısıya yol açtığını bulmuşlardır. Kanatlı kolektörün günlük termal verimliliğinin %56,57, %59,41 ve %61,42 değerlerinde iken kanatsız toplayıcı için %51,04, %53,28 ve %57,08 olduğunu hesaplamışlardır (Machi ve diğerleri., 2022).

Darıcı çalışmasında, zorlanmış taşınımlı tek geçişli havalı bir güneş kolektörü tasarlayarak deneysel olarak Konya ili iklim koşullarında incelemiştir. Deneyler hava koşulları açık, üç farklı kütleli debi ve farklı günlerde yapmıştır. Deneysel veriler aracılığı ile ısıtım değerleri, hava giriş, çıkış, cam örtü, emici plaka sıcaklıkları ve kolektöre ait ısı verimleri gün içerisinde saatlik değişimleri incelemiştir. Sonuç olarak, havanın kolektörde kütleli debideki artış nedeni ile çıkış sıcaklığının azaldığını, ısı veriminin kolektör için arttığını belirtmiştir. Ayrıca HGK içerisindeki havanın kütle debisinin artışı ile havaya kazandırılan faydalı ısı enerji ve kolektör veriminin arttığını hesaplamıştır. 0,069 kg/s hava debisi için öğle saatlerinde kolektör en yüksek ısı verimi %76 bulmuştur. Deneylerin yapıldığı HGK için üç farklı kütle debisi ile ortalama ısı verimi %52 olarak belirlemiştir (Darıcı, 2020).

Özgen ve Dayan, çalışmalarında farklı engellere sahip yutucu yüzeyi havalı bir güneş kolektörünün tasarımını yapmışlardır. Havalı güneş kolektörün yutucu yüzeyi, bulaşık telleri kullanılarak gözenekler oluşturmuştur. Deneyler, hava kütleli debi 0,05 kg/s ve 0,025 kg/s alınmıştır. Çalışmada en uygun debi 0,05 kg/s olarak bulmuşlardır. Kolektör verim hesabı için giriş, çıkış, yutucu yüzey, çevre sıcaklıkları ve güneş ışıyım değeri ölçülmüştür. Kolektör yüzeyinin pürüzlülük oranı arttıkça verimin arttığını gözlemlenmiştir. Farklı yutucu yüzeyler için verim %23 ile %74 arasında bulmuşlardır. Kolektörde debi artışı ile veriminde arttığını ifade etmişlerdir (Özgen, 2021).

Yıldırım çalışmasında yutucu yüzeyi pürüzlendirilmiş V-kanatçıklı bir havalı güneş kolektörünün termal ve termohidrolik veriminin araştırması sayısal olarak ve farklı pürüzlülük parametrelerinin etkisini incelemiştir. Yutucu yüzey yapısı pürüzlülük oranı arttıkça termal ve termohidrolik verimin artışı gözlemlenmiştir. Düzlemsel yutucu yüzey kullanımına göre V-kanatçıklı yutucu yüzey için farklı Reynolds sayılarında, %65 ile %165 oranında termal verimin artarken, termohidrolik verimi %67 ile %165 arasında artırdığını hesaplamıştır (Yıldırım, 2019).

Özkaya ve arkadaşları çalışmalarında havalı güneş kolektörünün verimini üzerine deneysel olarak çalışma yapmışlardır. Üç farklı hava debisi için farklı gün ve sıcaklık değeri için Kolektörü incelemiştir. Kolektör için giriş-çıkış, yutucu plaka ve çevre sıcaklıkları ve güneş ışıyım değeri ölçmüşlerdir. Deney sonuçlarından elde edilen verilere göre kolektör verimi hava hızlarında artış yapıldığında arttığını gözlemiştir. HGK da enerji verim değeri; 1,3 m/s, 1,4 m/s, 1,5 m/s hava hızları için sırasıyla %73,11 %76,75 ve %82,83 olarak bulmuşlardır (Özkaya ve diğeri., 2007).

Fuik ve Dutkowski pasif havalı güneş kolektörleri üzerinde dalga benzeri tabanlara sahip iki soğurucu yüzey tasarımı gerçekleştirmiş ve bu tasarımların uygulanmasının termal verimlilik üzerindeki etkisi araştırmışlardır. Soğurucu yüzey tasarımları, siyah boya ile kaplanmış dalga şekilli alüminyum levhadan oluşan üç panelden oluşmuştur. Termal verimlilik açısından en iyi performans gösteren tasarımın, levha tersine çevrilmeyen dalga benzeri tabanlara sahip yutucu plakalı HGK olduğunu tespit

etmişleridir. Işınım $I = 756 \text{ W/m}^2$ için, tersine çevrilmeyen levha dalga benzeri yutucu plakalı HGK'nın termal verimliliğini $\eta = \%73,8$ 'e eşit olarak, aynı ışıınım için ters çevrilen kolektörün verimliliği $\eta = \%58$ ve düz plakalı kolektörün $\eta = \%46$ değerine eşit olduğunu hesaplamışlardır (Fiuk ve Dutkowski, 2019).

Literatürde HGK deneysel çalışmalarında termal verim, çıkış sıcaklığı, ekserji verim değeri gibi bazı parametreler yapay zekâ yöntemleri yardımı ile tahmin edilmiştir. Bu çalışmalardan bazılarının kısaca özetleri aşağıda verilmiştir.

Altıntaş ve diğ. , Deneysel olarak bir HGK'nın düz yutucu plakası üzerine konik yaylar yerleştirmiş ve HGK'nın performansını incelenmişlerdir. Bu amaçla yutucu plaka yüzeyine konik yaylar sabitlenerek düzenek kurulmuştur. HGK'nın performansı deneysel olarak incelenmiştir. Deneylerde kolektör giriş ve çıkış, yutucu plaka, kolektör kasası dış yüzey, saydam örtü sıcaklıklarını ile global radyasyon, havanın çıkış hızını ölçmüşlerdir. Yaptıkları ölçümlere dayalı olarak HGK'nın ısı verim değerini hesaplamışlardır. Deneysel verileri kullanarak veri seti oluşturmuşlar ve bu setleri kullanarak yapay sinir ağları (YSA) yapıları oluşturmuşlardır. Bu ağ yapıları yardımı ile HGK'nın ısı verim değerlerini ve havanın kolektörden çıkış sıcaklık değerini başarılı bir şekilde tahmin etmişlerdir (Altıntaş Volkan, Akgül B. Mehmet, 2015).

Daş ve Akpınar, sabit ve hareketli iki HGK'nın enerji verim değerini tahmin etmek için YSA yöntemini kullanmışlardır. YSA ağ yapısını oluştururken deneysel veriler içerisinde güneş ışıınımı, kolektör giriş-çıkış sıcaklıkları, yutucu plaka sıcaklık değerlerini ve hava hızı değerlerini giriş parametresi olarak kullanmışlardır. Bu veriler yardımı ile YSA da HGK'nın enerji verimini $\%96$ doğruluk ile tahmin etmişlerdir (Daş ve Akpınar, 2018).

Ghritlahre ve arkadaşları, deneysel girdi parametreleri ile YSA kullanılarak HGK'nın termal performansını tahmin etmişlerdir. Bu amacı tamamlamak için, pürüzlü (yay şekilli tel nervür) ve düz kanal kullanılarak iki farklı tip HGK geliştirmişlerdir. Deneysel parametreleri kullanılarak HGK'nın termal verimini 0.99387 ± 0.00012 hata değeri ile tahmin etmişlerdir. Buna ek olarak, en hassas giriş parametresini bulmak için

hassasiyet analizi yapmış ve havanın kütle debisinin en etkili giriş parametresi olduğunu gözlemlemişlerdir (Ghritlahre ve diğerleri., 2020).

Ghritlahre ve Verma, çalışmalarında bir HGK'nın ısı verimliliğini tahmin etmek için üç farklı yapay zekâ tahmin tekniğini uygulamışlardır. Bu amaçla grup veri işleme yöntemi (GMDH), yapay sinir ağı (YSA) ve çoklu doğrusal regresyon (MLR) modellerini kullanmışlardır. Tüm modellerde ortam sıcaklığı, rüzgâr hızı, bağıl nem, sıvı giriş sıcaklığı, sıvı ortalama sıcaklığı, kütle debisi, levha sıcaklığı, rüzgâr yönü, güneş şiddeti ve güneş yüksekliği olmak üzere on farklı değişken türünü bağımsız değişkenler olarak seçmişlerdir. HGK'nın termal verimi tahmini için kullanılan GMDH, ANN ve MLR tekniklerin, sırasıyla 0.98977, 0.99981 ve 0.97693 korelasyon katsayısı (R) değerleriyle doğru bir şekilde modelleme yaptıklarını göstermişlerdir (Ghritlahre ve Verma, 2021).

Benli çalışmasında, iki farklı yüzey şekilli HGK imal edilmiş ve deneysel olarak incelemiştir. HGK'ların yutucu yüzeylerini oluklu ve trapez şeklinde seçmiştir. Deneyleri, Elâzığ'ın hâkim hava koşullarında Ekim ayında 09.00-17.00 saatleri arasında gerçekleştirmiştir. HGK'nın termal performanslarını tahmin etmek için geri yayılım algoritmasına dayalı bir ileri beslemeli sinir ağı geliştirilmiştir. HGK'nın termal verim değerini 0.9985 R² doğruluğu ile tahmin etmiştir (Benli, 2013).

Çakmak ve Yıldız, çalışmalarında HGK'lı bir gıda kurutma sisteminde kurutma hızı tahmini için İleri Beslemeli Sinir Ağlarını (FNN'ler) kullanmışlardır. Geliştirdikleri kurutma sisteminde özellikle genişletilmiş yüzeyli güneş hava kolektörü, Faz Değiştirme Malzemesi (PCM) içeren güneş hava kolektörü ve girdap elemanlı kurutma odası yer almıştır. Sonuç olarak kurutma hızı parametresini 0.0019 RMSE hata oranı ile FNN kullanarak tahmin etmişlerdir (Çakmak ve Yıldız, 2011).

Esen ve arkadaşları çalışmalarında, yapay sinir ağı (YSA) ve dalgacık sinir ağı (WNN) modellerini kullanarak bir HGK'nın çıkış sıcaklığı ve verim değerlerinin modelleme çalışmasını gerçekleştirmişlerdir. Farklı sinir ağı modellerinin (YSA ve WNN) tahmin yeteneklerini değerlendirmişlerdir. HGK'nın çıkış sıcaklığı ve verim değerlerini YSA kullanarak 0.0094 RMSE hata oranı ile WNN kullanarak 0.0126 RMSE hata oranı ile modellemişlerdir (Esen ve diğerleri., 2009).

Shetty ve diğerleri, HGK'nın çapraz akışlı dairesel delikli bir soğurucu plakasının termo- hidrolik performansını tahmin etmek için YSA Çok Katmanlı Algılayıcı (ÇKA) modeli kullanmışlardır. YSA tarafından tahmin edilen sonuçlar, deneysel analizden elde edilen değerlerle karşılaştırmışlardır. YSA sonuçlarını üretmek için 45 adet eğitim, 9 adet test ve 9 adet doğrulama için olmak üzere 64 veri seti analiz etmişlerdir. YSA verilerini ÇKA dan alınan verilerle karşılaştırmışlar ve YSA tarafından tahmin edilen verilerin ÇKA yönteminden elde edilen verilere göre %2.22 daha iyi olduğu bulmuşlardır (Shetty ve diğerleri., 2021).

Chaibi ve arkadaşları, bir fotovoltaiik/termal (PVT) HGK sisteminin elektriksel ve termal verimliliklerini tahmin etmek için YSA yöntemini kullanmışlardır. Geliştirdikleri YSA modeli, elektriksel ve termal verimliliği tahmin etmede sırasıyla %0,0078 ve %3,3607 MAE hata değeri gösterdiğini belirtmişlerdir. Elektriksel verimlilik değerini, termal verimlilikten daha yüksek bir doğrulukla tahmin edilebilmişlerdir (Chaibi ve diğerleri., 2021).

Son olarak bu tez çalışmasında deneysel verilerinin kullanıldığı Saydam, Çerçi ve Hürdoğan'ın yapmış olduğu HGK çıkış sıcaklığı modellemesi çalışmasında Saydam ve arkadaşları V tipi emici plaka yüzey geometrisine sahip çift geçişli havalı bir güneş kolektörü tasarlamış, imal etmiş ve kolektörün performansı Osmaniye ili iklim koşullarında deneysel olarak incelemişlerdir. HGK'nın deneysel olarak elde edilen kolektör çıkış sıcaklığını, üç farklı Yapay Sinir Ağı modeli kullanılarak tahmin etmişlerdir. Çalışma sonucunda kolektör giriş ve çıkış sıcaklığı arasında maksimum 36,07°C'lik bir fark olduğu tespit etmişlerdir. Isıl verim deney süresince maksimum %71,42 değerine ulaşmış olduğunu ve ortalama ısıl verim ise %56,21 olduğunu göstermişlerdir. YSA-2 modeli kullanarak HGK çıkış sıcaklık değerini 0.9934 R² hata değeri ile tahmin etmişlerdir (SAYDAM ve diğerleri., 2021).

3. MATERYAL ve YÖNTEM

Bu tez çalışmasında uygulanacak yöntem ve esaslar ise şu şekildedir;

1- Literatürde bulunan düzlemsel güneş kolektörleri için elde edilen deneysel verileri ile hesaplanacak ısı performans belirleme yöntemleri.

2- Yapay zekâ ile modelleme yöntemleri.


Literatürde daha önce deneysel çalışması Saydam vd. tarafından deneysel çalışması yapılmış olan bir V tipi yutucu plakalı HGK'nın deneysel verileri (Saydam ve diğerleri., 2021) kullanılarak HGK enerji verimi için yapay zekâ modelleri elde edilmiştir. Yapay zekâ yöntemleri olarak, pace regresyon, yapay sinir ağı, karar ağacı ve destek vektör makinesi algoritmaları kullanılmıştır. Bu yöntemle ile HGK'nın enerji verim değerleri modellenmiş ve pace regresyon ile HGK enerji verim değerini hesaplayabilen bir matematiksel eşitlik elde edilmiştir.

3.1. Havalı Güneş Kolektörleri

Diğer bir deyişle güneşli hava ısıtıcılarıdır. Genel olarak basit bir yapıya sahip olan kolektörlerdir. Yaygın olarak kullanılmaktadır. Ekonomik olmaları ve imalatları da basit olan cihazlardır (Machi ve diğerleri., 2022). Havalı güneş kolektörleri, farklı destek ekipmanları ile zirai ürün kurutmalarında binaların ısıtılmasında ve endüstriyel alanlarda ön ısıtma gibi işlemlerinde kullanılmaktadır. HGK'lar düşük sıcaklık uygulamalarında da kullanımı yaygındır. En basit haliyle Bir HGK cam örtü, yutucu plaka, hava geçiren plakalar ve kolektör kasasından meydana gelmektedir. (Darıcı, 2020). HGK'ların tasarımı ve bakımı kolaydır. Diğer kolektör tiplerine göre Korozyon ve sızıntı problemleri daha azdır. Şekil 3.1'de düz ve kanatçıklı tip emici plakalı HGK tasarımları verilmiştir (Gedik ve diğerleri., 2008).

Kullanım yeri olarak, havalı Güneş kolektörleri genellikle tarımsal ürünlerin kurutulmasında, bir alanının ısıtılmasında, endüstriyel işlemler (kâğıt, tekstil vb.) ve sera ısıtılması gibi alanlarda kullanılmaktadır (Gedik ve diğerleri., 2008).


Genel olarak bütün kolektörlerin temelinde kullanım amacına göre güneş enerjisinden maksimum fayda sağlama, kayıpları en aza indirmeye ve maliyeti olabildiğince düşürmektir.



Şekil 3.1. HGK komponentleri (Tuncer, 2018)

3.2. Deneysel Kurulum

Şekil 3.2’de, deney seti için daha önce dizayn edilen V tipi çift geçişli havalı güneş kolektörüne ait çizim ve deneysel görünümü verilmiştir [Kaynak]. Tablo 3.1 ’de ebatları ısı transferi verilen kolektörde kullanılan malzemeler; kolektör kasası şeffaf pleksi levhadan imal edilmiş ve oluşabilecek ısı kayıplarını engellemek için kasanın alt ve yan taraflara gelen yüzeylerinde cam yünü döşenerek alüminyumla kaplanmıştır. Isı transferinin iyileştirilmesi açısından havanın kolektör içerisinden daha uzun süre dolaşım sağlayabilmesi için mevcut alüminyum plaka üzerine V şeklinde alüminyumdan yapılmış oluklu kanatçıklar montajlanmıştır. Kolektör yüzeyi ve üzerindeki bağlantılarda oluşabilecek hava kaçaklarına karşı sızdırmazlık için sikonla işlem yapılarak sızdırmazlık sağlanmıştır. Güneş ışınlarını absorbe etmesi ve Kolektör yüzeyindeki ışınlardan daha fazla yararlanabilmek için yutucu plaka ve kolektör içi kısımlarına alkit reçine esaslı siyah mat renk kolektör boyası uygulanmıştır.



A



B

Şekil 3.2. A-HGK detayı, B- Deneysel görünüm

Yapılan çalışmaya ait deneysel veriler için kullanılan ölçüm cihazları Tablo 3.2’de verilmiştir.

Tablo 3.1. V tipi HGK teknik özellikleri (Saydam ve diğerleri., 2021)


Yutucu plaka tipi	V
Geçirgen üst örtü	Tek cam
Kasa boyutu	190x90x10 cm
İzolasyon malzemesi	Cam yünü, sızdırmazlık için silikon
Yutucu plaka	Alkit reçine esaslı siyah mat renk kollektör boyası siyah mat boyalı alüminyum sac
Kasa malzemesi	2 mm sac

Tablo 3.2. Deneylerde kullanılmış ölçüm cihazları (Saydam ve diğerleri., 2021)

Cihaz Ölçüm yaptığı değişkenler	Cihaz marka ve tipi	Hassasiyet oranı
Sıcaklık	COLE PARMER K tipi Isıl Eleman Çifti	0,1 °C
Rölatif nem	EPLUSE nem ölçer	%2-3
Hava hızı	TESTO 435 hava hızı ölçüm probu	0,1 m/s
Işınım	TRITEC ışınım sensörü	%±5
Veri kayıt	IOTECH PD3001	16 bit

3.3.Deneysel Prosedür

Deneyler saat 07:15 -18:00 arasında yapılmıştır. Kollektör girişi hava kütle debisi 0,034 kg/s olarak sabit alınmıştır. Dış ortam hava akışkanı deney süresince kullanılmıştır. Sistemde kullanılan hava akışkanı hızı 3,1 m/s olarak sabit alınmıştır ve kollektör dışına atılmıştır (Saydam vd. , 2021). Şekil 3.3’te kollektör giriş (dış hava)-çıkış sıcaklıkları, (ΔT) sıcaklık farkı ve ışıınının zamana bağlı olarak gün içerisindeki değişimi verilmiştir (SAYDAM ve diğerleri., 2021). Deney başlangıcında yaklaşık %80 civarında olan rölatif nemin dış ortamın ısınması ile birlikte %26’lık oranlara kadar düşmüştür.



Şekil 3.3. Sıcaklık ve ısıtım değerlerinin zaman ile değişimi (Saydam ve diğerleri., 2021)

3.4. Enerji Analizi

Termodinamiğin birinci yasası, enerjini korunumu olarak bilinmektedir. Tabiatı var olan en temel yasa olarak nitelendirilebilir. Enerjiye sahip herhangi bir sistemin çevresi ile temas halinde olması durumunda sistemin kaybettiği enerjinin çevresi ile kazandığı enerji miktarlarının eşit olması gereklidir. Burada enerji farklı formlarda ısı ya da elde ettiği iş ile geçiş yapabilir (Akpınar ve Koçyiğit, 2010).

Havalı güneş kolektörü emici plaka yüzeyi V şeklinde dizayn edilen deney sisteminde, panel içerisinden geçen havaya aktarılan faydalı enerji için yapılacak hesaplama Eşitlik 1 verilmiştir.

$$\dot{Q} = \dot{m} \cdot C_p \cdot (T_g - T_c) \quad (1)$$

Verilen bu eşitlikte;

$\dot{m}$: Kollektörde akışkan olarak kullanılan hava için kütle debisini (kg/s),

C_p : Havaya ait özgül ısı (J/kg.K),

T_g : Giriş sıcaklığı (°C),

T_c : Çıkış sıcaklığı, ifade etmektedir.

Havanın sahip olduğu kütle debisi için Eşitlik 2 ile hesaplanmıştır.

$$\dot{m} = \rho V A_c \quad (2)$$

Eşitlik 2 için;

ρ : hava yoğunluğu (kg/m³),

V : hava hızını (m/s),

A_c : ise kolektör çıkışı kesit alanını (m²) olarak ifade etmektedir.

Termodinamiğin 1. Kanunundan güneş kolektörün ısı verimi, η_c ise Eşitlik 3'e göre hesaplanmıştır.

$$\eta_c = \frac{\dot{m} \cdot C_p \cdot (T_g - T_c)}{I \cdot A} \quad (3)$$

3.5. Yapay Zekâ

Yapay zekâ yöntemleri içerisinde en çok kullanılan makine öğrenmesidir. Yapısal olarak öğrenebilen elde edilen veriler için mantıksal tahminler yapabilen bilgisayarda algoritmalarıyla çözümler ortaya koyan analizlerin genel adıdır. Temelde elde edilen verilerden referans alınan modellerle örnekler oluşturulur. Teknolojik olarak çok fazla verinin işlendiği günümüz koşullarında insan faktörüyle bu verilerin işlenmesi mümkün olmamaktadır. Bundan dolayı problemin çözümü için elde edilen verilerin makine öğrenme program algoritmalarının eğitilerek bilgisayar ortamında çözümlemeler yapmak suretiyle sonuca ulaşması hedeflenmektedir (Alpay ve Erdem, 2018).

Makine Öğrenme algoritmaları:

Gözetimli (Supervised Learning) ve gözetimsiz (Unsupervised Learning) öğrenme olarak 2 guruba ayrılır (Karaağaç ve diğerleri., 2021).

Gözetimli öğrenme (Supervised learning); Bu yöntemde, “label” eğitim verisi (etiket) bilgisi içermektedir. Yapılacak çözümler için sonuçları bilinen veriler aracılığı ile model geliştirilir. Böylelikle temel alınan model sayesinde veriler içerisinde etiket olarak karşılığı olmayan verilere ait sonuçların tahmini amaçlanmaktadır (Biswas ve diğerleri., 2021).

Mevcut araştırmalarda kullanılan gözetimli öğrenme algoritma modülleri:

- k-Nearest Neighbors (KNN): En Yakın Komşuluk
- Artificial Neural Network (ANN):Yapay Sinir Ağları
- Support Vector Machine (SVM):Destek Vektör Makinaları
- Decision Trees (DTs):Karar Ağaçları
- Logistic Regression: Lojistik Regresyon

Beş şekilde sıralamak mümkündür.

Gözetimsiz öğrenme (Unsupervised learning); bu öğrenme modülünde ise label yani etiket bilgisi yoktur. Saklı ilişkilerin veya grupların ortaya çıkarılması için veri setinden elde edilen bileşenler referans alınarak sonuçlar elde edilmesi amaçlanır (Aggarwal ve diğerleri., 2018).

En çok kullanılan gözetimsiz öğrenme algoritmaları:


- Clustering: Kümeleme
- Association Rules Birliktelik Kuralları
- Principal Component Analysis (PCA):Temel Bileşen Analizi

Üç şekilde sıralanabilir.

3.5.1. Yapay sinir ağıları

Yapay sinir ağıları (YSA); Tanımlamak gerekirse insan beyninin sahip olduğu potansiyele benzer algoritmalar oluşturularak aynı mantıkta modellenmesi sonucu ortaya çıkmaktadır. YSA, referans olarak bazı değerlere dayanarak girdi verilerinin çıktı verileri arasında belirli eş noktalara fonksiyonlar aracılığı ile bağlanması durumudur (Ghritlahre ve diğerleri., 2020). Yapay sinir ağıları, genel olarak örüntüyü tanımak, tahminlerde bulunmak, sınıflara ayırmak vb. elde edilen verilerle çok geniş alanlarda uygulamalar yapılmaktadır. İnsanlar gibi yapay sinir ağlarında mantıksal olarak elde edilen örneklerle öğrenmeyi geliştirmektedir. Bundan dolayı eğitim ve test kümesi olarak elde edilen veriler, iki kısma ayrılır (Gill ve diğerleri., 2019).

Deneysel veriler ile hesaplanmış HGK enerji verim değerleri tahmini için YSA'da kullanılan ağ, model toplam olarak 5 katmandan oluşmaktadır. Modele ait girdiler katmanı, 3 girdi için 3 nöron, birinci gizli olan katman için 6 nöron, ikinci olan gizli katman için 6 nöron, çıktı katmanını için 1 nöron ve çıktı için ise sadece tek bir nöron içermektedir. YSA için oluşturulan modele ait yapı Şekil 5.1'de verilmiştir.



Şekil 3. 4. YSA yapısı

YSA'ya ait kullanılan ağ için; çevre sıcaklığı °C ($T_{\text{çevre}}$), panel çıkış sıcaklığı °C ($T_{\text{çıkış}}$), ve güneş ışınlam W/m^2 (I) değerleri giriş verisi olarak seçilmiştir. Çıkış verisi olarak enerji verimi (η) seçilmiştir.

3.5.2. Regresyon analizi ve karar ağacı


Doğrusal regresyon analizi için belirtilmek istenen değişkene kıyasla, değişkenlerin daha kolay ve hızlı bir şekilde saptanabilmesi için belirtilen değişkeni tahmin edebilmek için bir model oluşturulur (Çerçi ve Hürdoğan, 2020). Basit doğrusal regresyon (simple linear regression) Bilinen ve normal olarak dağılan sayısal verileri mevcut bir değişkenden ile bilinmeyen ve aralarında ilişki olan bir başka değer normal olarak dağılan sayısal değişkeni tahmin için uygulanarak sonuca ulaşılır. Çoklu doğrusal regresyon” (multiple linear regression) ise birden fazla değişken aracılığı ile sadece bir değişkeni tahmin etmek için modelleme yapılması olarak tanımlanır (Taheri ve diğerleri., 2021). Çoklu doğrusal regresyona ait sayısal ifade Eşitlik 4’de verilmiştir (Ahmad ve diğerleri., 2018).

$$Y_i = (b_0 + b_1X_1 + b_2X_2 + \dots b_nX_n) + e_i \quad (4)$$

Bu eşitlikte Y bağımlı bir değişken, b_0 , regresyon eğrisi y eksenini kesin nokta, b_1 elde edilen ilk tahminine ait değişkeninin X_1 katsayısını, b_2 ise ikinci tahmin için gerekli değişkeninin X_2 katsayısını, e_i ise i’inci denek için Y’nin tahmin edilen değeri ile gözlenen değer arasındaki farkı ifade etmektedir (Biswas ve diğerleri., 2021).

Karar ağaçları (KA), Özellikle son zamanlarda üzerine çalışma yapılan ve literatürde yaygın bir şekilde kullanımı olan bir örüntü ve sınıflandırma tanımlama algoritmasıdır. Genel olarak bu yöntemin çok fazla kullanılmasının en önemli sebebi ise oluşturulacak ağaç yapısında kullanılacak kuralların anlaşılır ve yalın bir şekilde olmasıdır. Bu sınıflandırma işleminin gerçekleşmesi için KA’da birçok aşama veya ardışık olarak yaklaşımların kullanımı sağlanmaktadır (E. Alic ve diğerleri., 2019). Bir KA’nın Şekil 5.2’de görüldüğü üzere genel olarak yapısı düğüm, dal ve yaprak olmak üzere üç temel

bölümden oluşur. Bu yapıda her bir nitelik için (Hava hızı, Sıcaklık vb.) parametreler bir düğüm olarak temsil edilir. Ağaç yapısının diğer elemanlarını dallar ve yapraklar temsil eder. Ağaçtaki en son kısmı yapraklar ve en üst kısım kök olarak isimlendirilir. Yapraklar ve Kök aralığında kalan bölümler ise dal şeklinde ifade edilir (Çerçi ve Daş, 2019). Diğer bir ifadeyle bir ağaç yapısı için; verileri içeren kısım için kök düğümü, iç düğümler (dallar) ve uç düğümlerden (yapraklar) olarak oluşur. Bir KA yapısı oluşturulmasında temel prensip eğitim verilerine ait özel nitelik bilgileri vasıtasıyla verilere ilişkin birtakım sorular sorulması aracılığı ile ve elde edilen cevaplar doğrultusunda çıktı verileri ile en kısa sürede sonuca gidilmesi şeklinde ifade edilebilir. KA sorularına aldığı cevapları toplaması ile karar kuralları oluşturulur. Ağacın ilk düğüm olarak ifade edilen kök düğüm kısmında elde edilecek verilerin sınıflara ayrılarak ve ağaç yapısı oluşturulması için sorular sorulur ve bu yapıda işlem dalları olmayan düğümler ya da yapraklar bulunana kadar devam etmesi sağlanır (Alic ve diğerleri., 2019).



Şekil 3. 5. Dört boyutlu özellik uzayına sahip üç sınıftan oluşan karar ağacı yapısı (Alic ve diğerleri., 2019)

KA'ya ait kullanılan ağ için; çevre sıcaklığı °C ($T_{\text{çevre}}$), panel çıkış sıcaklığı °C ($T_{\text{çıkış}}$), ve güneş ışınlam W/m^2 (I) değerleri giriş verisi olarak seçilmiştir. Çıkış verisi olarak enerji verimi (η) seçilmiştir.

3.5.3. Destek vektör makinesi

Kernel tabanlı bir araç olan destek vektör makinesi (DVM) sınıflandırma ve regresyon yapmak için kullanılan en iyi sistemlerden biridir (Cao ve diğerleri., 2022). Vapnik tarafından geliştirilmiş bir öğrenme stratejisi olan bu sistem makineli öğrenme algoritmasındaki referanslara bağlı ilkelere dayanarak geliştirilmiş güçlü bir yöntemdir. Genel olarak makinelerin regresyon problem çözümlerinde Smola ve Schölkopf tarafından kapsamlı bir şekilde çalışmalar yapılmıştır (Schölkopf, 2003; Vapnik, V., 1995). Gerekli eğitim için örneklemeler $[(x_i - y_i)]_{i=1}^N = 1$ şeklinde verilmiş olursa. Yapılacak regresyon için problemlere yanıt olarak değişken $y_i \in \{+1, -1\}$ ifadesi yerine $y_i \in \mathbb{R}$ olarak tanımlanmaktadır.

3.5.4. Doğrusal destek vektör regresyon

ε -duyarsız (ε -insensitive) destek vektör regresyonda, (ε -DVR) için amaç gerekli olan tüm eğitim verileri için gerçekleşecek yanıt değişkeni olan y_i 'ler için maksimum ε sapmaya sahip olan olasılıklar için en düz yapıya sahip $f(x)$ fonksiyonunu elde etmektir. Elde edilen sonuçlara bağlı hatalar eğer ε 'dan küçük ise ve olduğu sürece önemsenmeyecek, Diğer taraftan bu değerden büyük olacak sapma durumlarında ise sonuç kabul edilmeyecek (Taheri ve diğerleri., 2021).

Öncelikle ilk durum için ele alınacak f fonksiyonu Eşitlik 5'te verildiği şekilde ifade edilir:

$$f(x) = \mathbf{w} \cdot \mathbf{x} + b, \mathbf{w} \in \mathbb{R}^D, b \in \mathbb{R} \quad (5)$$

$\mathbf{w}$ 'nin küçük bir değerde olması durumu ise Eşitlik (5.2) ile verilen fonksiyon yapısının düz olduğu anlamına gelmektedir. Bunu sağlamanın diğer bir yolu da $\|\mathbf{w}\|^2$ normunun daha minimize ederek sonuç elde etmektir. Konveks için optimizasyon problemine ait sayısal yapı Eşitlik 6'da verilmiştir:

$$\begin{aligned} \min \frac{1}{2} \|\mathbf{w}\|^2 \\ y_i - (\mathbf{w} \cdot \mathbf{x}_i + b) \leq \varepsilon \\ (\mathbf{w} \cdot \mathbf{x}_i + b) - y_i \leq \varepsilon \end{aligned} \quad (6)$$

Eşitlik 6'da $\mathbf{w}$ ağırlıkları için $\mathbf{x}_i$ örnekleri doğrusal olan kombinasyonu şeklinde ifade edilmektedir. Böylece destek vektörlerinin sadece sayısına bağlı olarak fonksiyon kompleksliği şeklinde temsil edilen fonksiyonun kompleksliği, girdiler için kullanılan örneklerin boyutundan bağımsız bir şekilde olacaktır. Diğer taraftan $\mathbf{x}_i$ örneklerin çarpımı olarak ifade edilir.

3.5.5. Doğrusal olmayan destek vektör regresyon

Bu regresyon özellik uzayına haritalandırması amacıyla destek vektörün nonlineer durum genelleştirilmesi için $\mathbf{x}_i$ örnekleri $\Phi: \mathbb{R}^D \mapsto \mathcal{H}$ fonksiyonu aracılığı ile destek vektörün kullandığı algoritmaları sadece $\mathbf{x}_i$ örneklerinin iç çarpımlarına bağlı olarak Φ fonksiyonunu bilmemize ihtiyaç duymadan hesaplama için $k(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ fonksiyonunu yeterli olacak. Gerekli Optimizasyon problemi için Eşitlik 7 'de verilmiştir (Qi ve diğerleri., 2013).

$$\begin{aligned} \max \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) k(\mathbf{x}_i, \mathbf{x}_j) - \varepsilon \sum_{i=1}^N (\alpha_i^+ - \alpha_i^-) - \sum_{i=1}^N y_i (\alpha_i^+ - \alpha_i^-) \\ \sum_{i=1}^N (\alpha_i^+ - \alpha_i^-) = 0 \quad 0 \leq \alpha_i^+ - \alpha_i^- \leq c \end{aligned} \quad (7)$$

Ağırlıklar ve tahmin fonksiyonu aşağıdaki Eşitlik (8-9) ile yazılır:

$$\mathbf{w} = \sum_{i=1}^N (\alpha_j^+ - \alpha_j^-) \phi(x_i) \quad (8)$$

$$f(x) = \sum_{i=1}^N (\alpha_j^+ - \alpha_j^-) k(x_i, x_j) + b \quad (9)$$

Bu regresyon $\mathbf{w}$ için ağırlıkları açık olarak elde etmediği için doğrusal durumdan farklıdır. Bu özelliği ile birlikte lineer olmayan yapıda optimizasyon problemi veri girişi için elde edilen uzaydan farklı olarak özellik uzayında en düz yapıya sahip fonksiyon elde edilir (Wagner ve diğerleri., 2005).

Sayısal ifade olarak destek vektör makineleri bir Kernel (çekirdek) fonksiyonu yardımıyla $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ doğrusal olmayan dönüşümler aracılığı ile yüksek boyutlarda doğrusal olarak ayırım yapar. Ayrılmayan iki sınıflı bir problem için çözüme ait karar kuralı Kernel fonksiyonu aracılığı ile doğrusal olarak Eşitlik 10 ile yazılabilir (Das ve Akpınar, 2018).

$$f(x) = \text{sign} \left(\sum_i a_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (10)$$

DVM ile gerçekleştirilecek sınıflandırmalar için ele alınacak Kernel fonksiyonu ve bunun için parametrelerin belirlenmesi esastır. Tablo 3.3’de literatürde Kernel fonksiyonu için; Polinom, Pearson VII (PUK) fonksiyonu formül ve parametreler verilmiştir. Tablodan anlaşılabacağı üzere Kernel fonksiyonlarının her biri için parametrelerin bazıları kullanıcı tarafından belirlenecek şekilde olmalıdır.

Tablo 3.3. DVM’de kullanılan temel kernel fonksiyonları ve parametreleri

Kernel Fonksiyonu	Formüller	Parametreler
-------------------	-----------	--------------

Polinom Kerneli	$K(x, y) = ((x.y) + 1)^d$	d: Polinom derecesi
Pearson VII (PUK) Kerneli	$K(x, y) = \frac{1}{\left[1 + \left(\frac{2 \cdot \sqrt{\ x - y\ ^2 \sqrt{2^{(1/\omega)} - 1}}}{\sigma}\right)^2\right]^\omega}$	ω, σ : Pearson genişliği parametreleri

DVM'ye ait kullanılan ağ için; çevre sıcaklığı °C ($T_{\text{çevre}}$), panel çıkış sıcaklığı °C ($T_{\text{çıkış}}$), ve güneş ışınlam W/m^2 (I) değerleri giriş verisi olarak seçilmiştir. Çıkış verisi olarak enerji verimi (η) seçilmiştir.

3.5.6. Pace regresyon

Bu regresyonda bir bağımlı değişken ya da bir veya daha fazla bağımsız değişken arasında oluşturulan ilişki, matematiksel olarak doğrusal regresyon ile modellenebilir. Böylece bu model ile bilinen ve bilinmeyen parametreler arasında bağlantı kurulabilmektedir. Giriş deneysel veriler ve kullanıcı tarafından seçilen senaryolar ile regresyon modeli oluşturulur ve bu veriler eğitim için kullanılır (Mancuhan, 2020).

$n > p$ olduğu varsayıldığında, p katsayılı ve n veri noktasına (örnek sayısı) sahip bir doğrusal regresyon aşağıdaki Eşitlik 11 gibi yazılabilir:

$$\begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_n \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{pmatrix} \quad (11)$$

burada ε_n standart hatadır, β_n (sabit) tahmin edilecek parametredir, $x_n = (x_{n1}, x_{n2}, \dots, x_{np})$ n'inci diziyi temsil eden p özelliklerinin vektörüdür ve y_n tahmin edilen değerdir.

PACE (Projection Adjustment by Contribution Estimation) regresyon algoritması, benzeşik modellerin birbirini referans olarak alınması aracılığı ile doğrusal yapıda olan modellere uyması amaçlanacak şekilde inceleyen yeni bir yaklaşımdır. Regresyon

analizindeki oluşturulacak temel fikir, veri kümesi olarak belirlenen girdiler için fonsiyonun doğrusal hale getirilerek modellenmesi amaçlanır. Küçük karelerin tahmin edilebilirliği özellik olarak daha basit ve sağlam bir teorik gerçekliğe sahiptir. Ancak geliştirilen modeller ikna edici düzeyde değildir. PACE regresyonu, en küçük kareler yardımı ile her bir değişkenin etkisini değerlendirilerek, genel olarak elde edilen regresyonların katkılarını tahminsel olarak belirlemek ve istatistiksel birtakım temeller geliştirmek ve küme analizleri kullanarak geliştirir (Meshram ve diğerleri., 2021).

Pace regresyonunu Wang ve Witten tarafından geliştirilmiştir. Yüksek boyutlu veriler işlenirken diğer regresyon modellerine kıyasla daha iyi performans sergilemektedir (Wang ve Witten, 1997). PACE1 ila PACE6 olmak üzere altı farklı yapıda regresyon prosedürü geliştirilmiştir. Bu prosedürler verilerden elde edilen değişkenlerin etkilerinin dağılımını tahmin etmeyi sağlayan ve bunlardan elde edilen sonuçlarla modellemeleri geliştirmek amacıyla kullanan bir fikrin paylaşımı olarak adlandırılır. Prosedür olarak ilk dört regresyon için, OLS (sıradan en küçük kare) kendisi de dâhil olacak şekilde alt kümeler seçimini kullandı. PACE 5 ise daha çok Ampirik Bayes (EB) olarak belirlenen yöntemdi. Regresyonların diğer lineer formlarında olduğu gibi, herhangi bir parametre için yapılacak modelleme PACE regresyon OLS ve Ampirik Bayes yöntemi, Eşitlik 12 formatındaki özelliklerin lineer bir kombinasyonuydu olarak verilmiştir (Wang ve Witten, 2002).

$$\text{Modellenen Parametre} = \alpha_1 \times A_i + \alpha_2 \times B_i + \alpha_3 \times C_i + \alpha_4 \times D_i + \alpha_5 \times E_i$$

(12)

Denklem 12'de modellenen parametreler için girdi parametreleri A, B, C, D, E gibi ifadelerdir. Pace regresyon yöntemleri ile elde edilen parametreleri etkileyen ağırlık katsayısı α_i değerleridir. Elde edilecek model için özelliklerin doğrusal bir şekilde kombinasyonlar oluşturulması önemli bir kriterdir. Böylelikle daha basit bir modelleme tasarımı ile hesaplamalarda gerekli süre kısaltılabilir.

Bu çalışmada bir havalı güneş kollektörüne ait enerji verim değerleri (η) tahminsel modeli için YSA, KA, DVM Pace regresyon kullanılarak tahminsel modeller

oluşturulmuştur. Tahminsel model oluşturmada MATLAB2016a yazılımı kullanılmıştır. Hava ısıtılmalı kollektör verim değerleri tahminsel modelleri için toplam 176 adet veri kullanılmıştır. Bu verilerin 123 adedi eğitim için 53 adedi test için kullanılmıştır. Test ve eğitim dataları random olarak atanmıştır.

Oluşturulan tahminsel modellerin doğruluğu belirlemek için ortalama mutlak hata (MAE) ve kök ortalama karesel hata (RMSE) analizleri yapılmıştır. Analizlerin matematiksel ifadeleri Eşitlik 13-14’de verilmiştir.

$$MAE = \left(\left| \frac{A_n - P_n}{A_n} \right| \right) \quad (13)$$


$$RMSE = \sqrt{\frac{(P_1 - A_1)^2 + \dots + (P_n - A_n)^2}{n}} \quad (14)$$

Eşitlik 13 ve 14 de A_n değerler gerçek deneysel değerleri, P_n değerleri ise tahminsel değerleri temsil etmektedir.

4. BULGULAR

Sunulan bu tez çalışmasında Saydam vd. tarafından deneysel araştırması daha önceden yapılmış ve literatürde makale haline getirilmiş bir çalışmadaki (Saydam ve diğ., 2021). HGK'nın deneysel verileri kullanılarak veri seti oluşturulmuştur. Oluşturulan veri setinde HGK enerji verim değerleri için makine öğrenmesi algoritmaları kullanılarak modellemeler yapılmıştır. Saydam vd. tarafından yapılan çalışmadaki deneysel veriler ile makine öğrenmesi algoritmaları modellerinin sonuçları karşılaştırılmıştır.


Şekil 4.1 de destek vektör makinesi (DVM) algoritmasında kullanılan Poly ve PUK kernel fonksiyonları ile elde edilen enerji verim değerleri ile deneysel hesaplanan enerji verim değerleri karşılaştırılmıştır. Şekil 4.1. de görüleceği üzere PUK kernel ile elde edilen enerji verim değerleri deneysel değerlere daha uyum göstermiştir. Poly kernel ile deneysel enerji verim değerleri arasında % MAE hata değerlerinin ortalaması %6 iken, PUK kernel ile deneysel enerji verim değerleri arasındaki %MAE hata değerlerinin ortalaması %3.8'dir. MAE hata değerlerine göre en az hata değerine sahip enerji verim değeri modellenmesi PUK kernel fonksiyonu ile elde edilmiştir.




Şekil 4.1. DVM algoritması ve deneysel enerji verim değerlerinin karşılaştırılması

Şekil 4.2. de yapay sinir ağı (YSA) algoritması kullanılarak elde edilen enerji verim değerleri ile deneysel hesaplanan enerji verim değerleri karşılaştırılmıştır. Şekil 4.2. de görüleceği üzere YSA ile elde edilen enerji verim değerleri deneysel değerlere uyum göstermiştir. YSA ile deneysel enerji verim değerleri arasındaki %MAE hata değerlerinin ortalaması %9.5'dir. Bu hata değeri %10 un altında olduğu için literatürde kabul edilebilir bir hata değeridir. Literatürde yapılan için YSA modellemelerinin ortalama hata değerleri (%MAE) %10 dur. Bu değer altındaki hata değerine sahip modeller düşük hata oranına sahip model olarak kabul edilebilir.

Şekil 4.3. de karar ağacı (KA) algoritması kullanılarak elde edilen enerji verim değerleri ile deneysel hesaplanan enerji verim değerleri karşılaştırılmıştır. Şekil 4.3. de görüleceği üzere KA ile elde edilen enerji verim değerleri deneysel değerlere uyum göstermiştir. KA ile deneysel enerji verim değerleri arasındaki %MAE hata değerlerinin ortalaması %3.1'dir.




Şekil 4.2. YSA algoritması ve deneysel enerji verim değerlerinin karşılaştırılması



Şekil 4.3. KA algoritması ve deneysel enerji verim değerlerinin karşılaştırılması

Şekil 4.4.'de KA algoritmasının karar kurallarını oluştururken kullandığı ağaç yapısı gösterilmiştir. Ağaç kökü güneş ışınlam (I) değerleridir. Bu değerlere göre 1 adet karar

kuralı (LM-1) oluşturulmuştur. Işınım değerlerine göre çevre sıcaklığına bağlı ($T_{\text{çevre}}$) olarak 4 adet karar kuralı (LM-2,3,4) oluşturulmuştur. Bu kuralların denklemleri Tablo 4.1.'de gösterilmiştir. KA algoritması ile rastgele oluşturulan ağaç yapısındaki denklemlere göre enerji verim değeri tahmin edilmiştir.




Şekil 4.4. KA algoritması ağaç yapısı

Tablo 4.4. KA algoritması Lineer Model denklemleri

LM-1
$\eta = 0.0143 * T_{\text{çevre}} + 0.0008 * I + 0.6475$
LM-2
$\eta = 0.0019 * T_{\text{çıkış}} - 0.0268 * T_{\text{çevre}} + 0.0001 * I + 1.1755$
LM-3
$\eta = 0.0019 * T_{\text{çıkış}} - 0.0293 * T_{\text{çevre}} + 0.0001 * I + 1.2378$
LM-4
$\eta = 0.0038 * T_{\text{çıkış}} - 0.0232 * T_{\text{çevre}} + 0.0001 * I + 0.9346$

Şekil 4.5. de Pace regresyon algoritması kullanılarak elde edilen enerji verim değerleri ile deneysel hesaplanan enerji verim değerleri karşılaştırılmıştır. Şekil 4.4. de görüleceği üzere Pace ile elde edilen enerji verim değerleri deneysel değerlere uyum göstermiştir. Pace ile deneysel enerji verim değerleri arasındaki %MAE hata değerlerinin ortalaması %5.5'tir.



Şekil 4.5. Pace regresyon ve deneysel enerji verim değerlerinin karşılaştırılması

Pace regresyon sonucu enerji verim değerlerini giriş parametresi olan çevre sıcaklığı, kollektör çıkış sıcaklığı ve güneş ışınlıma değerlerine göre ifade edebilen bir matematiksel denklem elde edilmiştir. Bu denklem sayesinde %3 hata ile deneysel enerji verim değerleri hesaplanabilmektedir. Bu denklem Eşitlik 15 olarak aşağıda verilmiştir.

$$\eta = 0.1061 + -0.0331 * T_{\text{çevre}} + 0.0464 * T_{\text{çıkış}} + -0.0018 * I \quad (15)$$

Hava ısıtılmalı güneş kollektörü enerji verim değeri için yapılan yapay zekâ modellerinin hata değerleri Tablo 4.2.'de verilmiştir. Tablo 4.2' ye göre en az hata değerine ve dolayısıyla deneysel enerji verim değerlerine en yakın olan model KA ile yapılan modeldir.

Tablo 4.5. Tahminsel yapay zekâ modellerinin hata analiz sonuçları

Model	MAE	RMSE
-------	-----	------

YSA	0.095	0.1
KA	0.0308	0.0601
DVM (Poly)	0.0566	0.0991
DVM (PUK)	0.038	0.094
PACE	0.0554	0.0727



5. SONUÇ ve ÖNERİLER

Sunulan tez çalışmasında bir HGK'nın deneysel veriler ile hesaplanmış enerji verim değerleri, yapay sinir ağı, karar ağacı, destek vektör makinesi ve pace regresyon dan oluşan makine öğrenmesi algoritmaları ile modellenmiştir. Model sonuçları ile deneysel sonuçlar karşılaştırılmıştır. Ayrıca çalışmanın önemli bir sonucu olan ve pace regresyon yardımı enerji verim değerlerini hesaplayabilen basit bir doğrusal matematiksel denklem elde edilmiştir. Bu denklem ile (Eşitlik15) hava ısıtmalı bir düzlemsel güneş kollektörünün enerji verim değeri %5 hata ile hesaplanabilmektedir. Enerji verim değeri için oluşturulan yapay zekâ modellerinin sonuçları aşağıda verilmiştir.

- Yapay sinir ağı algoritması kullanılarak HGK'nın enerji verim değerleri %9 ortalama bağıl hata ile ve 0.1 kök ortalama karesel hata ile modellenmiştir.

- Karar ağacı algoritması kullanılarak enerji verim değerleri %3 hata değeri ile deneysel değerlere yaklaşmıştır.
- Destek vektör makinesi algoritması ile modellenen enerji verim değerlerinin hata oranları PUK kernelde %3.8 , Poly kernelde %5 olarak elde edilmiştir.
- Pace regresyon ile enerji verim değeri için matematiksel bir eşitlik elde edilmiş ve bu eşitlik ile enerji verim değeri %5 hata ile belirlenmiştir.
- Makine öğrenmesi algoritmaları içerisinde deneysel değerlere en iyi benzerlik gösteren model karar ağacı algoritması ile elde edilmiştir.

Yapılan çalışmada toplam 176 adet veriden oluşan bir set kullanılmıştır. Veri setindeki veri sayısı arttırılarak daha az hata değerine sahip modeller elde edilebilir. Ayrıca farklı makine öğrenmesi algoritmaları kullanılarak daha hassas sonuçlara ulaşılabilir.

6. KAYNAKLAR

- Aggarwal, G., Sabharwal, S., Nagpal, S., 2018. Theoretical and Empirical Validation of Coupling Metrics for Object-Oriented Data Warehouse Design. Arab. J. Sci. Eng. 43, 675–691.
- Ahmad, M.W., Reynolds, J., Rezgui, Y., 2018. Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. J. Clean. Prod. 203, 810–821.
- Akpınar, E.K., Koçyiğit, F., 2010. Energy and exergy analysis of a new flat-plate solar air heater having different obstacles on absorber plates. Appl. Energy 87, 3438–3450.
- Alıç, E., Daş, M., 2020. Trapez Yutucu Plaklı Bir Havalı Güneş Kolektörünün Deneysel Tasarımı ve Sayısal Analizi. Eur. J. Sci. Technol. 78–88.
- Alic, E., Das, M., Kaska, O., 2019. Heat flux estimation at pool boiling processes with computational intelligence methods. Processes 7.
- Alic, Erdem, Das, M., Kaska, O., 2019. Heat flux estimation at pool boiling processes with computational intelligence methods. Processes 7, 1–16.
- Alpay, Ö., Erdem, E., 2018. Seralarda Isıtma Mikta rının Yumuşak Hesaplama Teknikleri Kullanılarak Belirlenmesi 30, 203–213.

- Altıntaş Volkan, Akgül B. Mehmet, 2015. Yutucu plaka üzerine konik yayların yerleştirildiği güneş enerjili hava kollektörünün ısı verim analizi ve yapay sinir ağları ile modellenmesi.
- Arslan, E., Aktaş, M., 2020. 4E analysis of infrared-convective dryer powered solar photovoltaic thermal collector. *Sol. Energy* 208, 46–57.
- Benli, H., 2013. Determination of thermal performance calculation of two different types solar air collectors with the use of artificial neural networks. *Int. J. Heat Mass Transf.* 60, 1–7.
- Biswas, N.K., Banerjee, S., Biswas, U., Ghosh, U., 2021. An approach towards development of new linear regression prediction model for reduced energy consumption and SLA violation in the domain of green cloud computing. *Sustain. Energy Technol. Assessments* 45, 101087.
- Çakmak, G., Yıldız, C., 2011. The prediction of seedy grape drying rate using a neural network method. *Comput. Electron. Agric.* 75, 132–138.
- Cao, Y., Kamrani, E., Mirzaei, S., Khandakar, A., Vaferi, B., 2022. Electrical efficiency of the photovoltaic/thermal collectors cooled by nanofluids: Machine learning simulation and optimization by evolutionary algorithm. *Energy Reports* 8, 24–36.
- Çerçi, K.N., Daş, M., 2019. Modeling of heat transfer coefficient in solar greenhouse type drying systems. *Sustain.* 11.
- Çerçi, K.N., Hürdoğan, E., 2020. Comparative study of multiple linear regression (MLR) and artificial neural network (ANN) techniques to model a solid desiccant wheel. *Int. Commun. Heat Mass Transf.* 116.
- Chaibi, Y., Malvoni, M., El Rhafiki, T., Kousksou, T., Zeraouli, Y., 2021. Artificial neural-network based model to forecast the electrical and thermal efficiencies of PVT air collector systems. *Clean. Eng. Technol.* 4, 100132.
- Chauhan, P.S., Kumar, A., 2018. Thermal modeling and drying kinetics of gooseberry drying inside north wall insulated greenhouse dryer. *Appl. Therm. Eng.* 130, 587–597.
- Chauhan, P.S., Kumar, A., Nuntadusit, C., Banout, J., 2018. Thermal modeling and drying kinetics of bitter melon flakes drying in modified greenhouse dryer. *Renew. Energy* 118, 799–813.
- Darıcı, S., 2020. Design, manufacture and thermal analysis of a single pass solar air collector at different mass flow rates. *J. Fac. Eng. Archit. Gazi Univ.* 35, 1187–1197.
- Daş, M., Akpınar, E., 2018. Sabit ve Hareketli Hava ile Isıtılan Güneş Kollektörlerinin Isıl Verimliliklerinin Karşılaştırılması ve Yapay Sinir Ağları ile Modellenmesi 30, 41–46.
- Das, M., Akpınar, E.K., 2018. Investigation of pear drying performance by different methods and regression of convective heat transfer coefficient with support vector machine. *Appl. Sci.* 8.
- Dong, Z., Liu, P., Xiao, H., Liu, Z., Liu, W., 2021. A study on heat transfer enhancement for solar air heaters with ripple surface. *Renew. Energy* 172, 477–487.
- Esen, H., Ozgen, F., Esen, M., Sengur, A., 2009. Artificial neural network and wavelet neural network approaches for modelling of a solar air heater. *Expert Syst. Appl.* 36, 11240–11248.
- Fiuk, J.J., Dutkowski, K., 2019. Experimental investigations on thermal efficiency of a

- prototype passive solar air collector with wavelike baffles. *Sol. Energy* 188, 495–506.
- Gedik, E.K., Keçeba, A., Etem, Ş., Öz, S., Makine, E., Teknik, E., Üniversitesi, A.K., 2008. Effect To the Performance of Different Type Absorber Plates on the Solar Air Collectors. *J. Fac. Eng. Arch. Gazi Univ* 23, 777–784.
- Ghritlahre, H.K., Chandrakar, P., Ahmad, A., 2020. Application of ANN model to predict the performance of solar air heater using relevant input parameters. *Sustain. Energy Technol. Assessments* 40.
- Ghritlahre, H.K., Verma, M., 2021. Accurate prediction of exergetic efficiency of solar air heaters using various predicting methods. *J. Clean. Prod.* 288.
- Gill, J., Singh, J., Ohunakin, O.S., Adelekan, D.S., 2019. ANN approach for irreversibility analysis of vapor compression refrigeration system using R134a/LPG blend as replacement of R134a. *J. Therm. Anal. Calorim.* 135, 2495–2511.
- Gülin, Z.A., 2013. Stirling Çevrimi Kullanan Çanak Tipi Yoğunlaştırıcı Güç Sistemlerinin İncelenmesi Ve Model Bir Sistemin Tasarlanması. Yüksek Lisans Tezi. Hacettepe Üniversitesi.
- Gülmez, B., 2020. PürüzlüYüzeylerin Kollektör Verimi Etkisinin Sayısal olarak İncelenmesi.Yüksek Lisans Tezi. Manisa Celal Bayar Üniversitesi.
- Hassan, H., Abo-Elfadl, S., El-Dosoky, M.F., 2020. An experimental investigation of the performance of new design of solar air heater (tubular). *Renew. Energy* 151,
- Higgins, M.W., Shakeel Rahaan, A.R., Devarapalli, R.R., Shelke, M. V., Jha, N., 2018. Carbon fabric based solar steam generation for waste water treatment. *Sol. Energy* 159, 800–810.
- Ihoume, I., Tadili, R., Arbaoui, N., Bazgaou, A., Idrissi, A., Benchrif, M., Fatnassi, H., 2022. Performance study of a sustainable solar heating system based on a copper coil water to air heat exchanger for greenhouse heating. *Sol. Energy* 232, 128–138.
- Karaağaç, M.O., Ergün, A., Ağbulut, Ü., Gürel, A.E., Ceylan, İ., 2021. Experimental analysis of CPV/T solar dryer with nano-enhanced PCM and prediction of drying parameters using ANN and SVM algorithms. *Sol. Energy* 218, 57–67.
- Keçel, S., 2015. Sabit T Ve Takip Sistemi Güneş Kollektörleri Nüfus İzleme Solar Collectors With Computational Fluid Dynamics 1, 77–98.
- Liu, Y., Tan, C., Jin, Y., Ma, S., 2022. Heat collection performance analysis of corrugated flat plate collector: An experimental study. *Renew. Energy* 181, 1–9.
- Lizama-Tzec, F.I., Herrera-Zamora, D.M., Arés-Muzio, O., Gómez-Espinoza, V.H., Santos-González, I., Cetina-Dorantes, M., Vega-Poot, A.G., García-Valladares, O., Oskam, G., 2019. Electrodeposition of selective coatings based on black nickel for flat-plate solar water heaters. *Sol. Energy* 194, 302–310.
- Machi, M.H., Al-Neama, M.A., Buzás, J., Farkas, I., 2022. Energy-based performance analysis of a double pass solar air collector integrated to triangular shaped fins. *Int. J. Energy Environ. Eng.* 13, 219–229.
- Mancuhan, E., 2020. Comparative evaluation of a two-stage refrigeration system with flash intercooling using different refrigerants. *Therm. Sci.* 24, 815–830.
- Meshram, S.G., Safari, M.J.S., Khosravi, K., Meshram, C., 2021. Iterative classifier optimizer-based pace regression and random forest hybrid models for suspended sediment load prediction. *Environ. Sci. Pollut. Res.* 28, 11637–11649.
- Özgen, F., Esen M, Esen, H., 2009. Experimental investigation of thermal performance of a double-flow solar air heater having aluminium cans *Renewable Energy* 34,11.

- Özkaya, M.G., Kirba, İ.Ş., 2007. Haval ı Güne ş Kollektörünün Performansının Deneyisel Olarak İncelenmesi Solar Air Collector Performance Which Determined Experimentally 253–256.
- Qi, Z., Tian, Y., Shi, Y., 2013. Robust twin support vector machine for pattern classification. Pattern Recognit. 46, 305–316.
- Rezaeian, M., Shafiey Dehaj, M., Zamani Mohiabadi, M., Salarmofrad, M., Shamsi, S., 2021. Experimental investigation into a parabolic solar collector with direct flow evacuated tube. Appl. Therm. Eng. 189.
- Sancar İbrahim, B.H., 2021. Mahal Isıtmasında Kullanılan Haval ı Güne ş Kollektörleri ve Adıyaman Şartlarında Performansının İncelenmesi. 47, 124–134.
- Saydam, D.B., Çerçi, K.N., Hürdoğan, E., 2021. Tipi Haval ı Bir Güne ş Kolektörünün Isıl Performansının Deneyisel Olarak İncelenmesi Ve YapaSinir Ağları İle Modellenmesi. Mühendislik Bilim. ve Tasarım Derg. 9, 1212–1223.
- Schölkopf, B., 2003. An Introduction to Support Vector Machines, Recent Advances and Trends in Nonparametric Statistics.
- Serdar Öksüz, 2014. Güne ş Enerjisi Sistemleri Temel Prensipler 66.
- Shetty, S.P., Nayak, S., Kumar, S., Vasudeva Karanth, K., 2021. Thermo-hydraulic performance prediction of a solar air heater with circular perforated absorber plate using Artificial Neural Network. Therm. Sci. Eng. Prog. 23, 100886.
- Taheri, S., Brodie, G., Gupta, D., 2021. Optimised ANN and SVR models for online prediction of moisture content and temperature of lentil seeds in a microwave fluidised bed dryer. Comput. Electron. Agric. 182, 106003.
- Tuncer, Z., 2018. Yeni Geliştirilen Haval ı Güne ş Kollektörünün Enerji Ve Ekserji Parametrelerinin Belirlenmesi. Yüksek Lisans Tezi. Dicle Üniversitesi.
- Vapnik, V., C.C., 1995. Support-Vector Networks. Mach. Learn. 20.
- Wagner, M., Adamczak, R., Porollo, A., Meller, J., 2005. Linear regression models for solvent accessibility prediction in proteins. J. Comput. Biol. 12, 355–369.
- Wang, Y., Witten, I.H., 2002. Modeling for optimal probability prediction. Proc. Ninet. Int. Conf. Mach. Learn. 650–657.
- Wang, Y., Witten, I.H., 1997. Induction of model trees for predicting continuous classes. Proc. 9th Eur. Conf. Mach. Learn. Poster Pap.
- Yıldırım, C., 2019. V-Kanatçık Kullanımının Haval ı Güne ş Kollektörlerinde Termal ve Termohidrolik Verime Etkisinin Parametrik Analizi. Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Derg. 34, 23–32.

