



**İSTANBUL MEDENİYET
ÜNİVERSİTESİ**

FEN BİLİMLERİ ENSTİTÜSÜ
MÜHENDİSLİK YÖNETİMİ ANABİLİM DALI

**OECD ÜLKELERİNDEKİ CO₂ EMİSYONUNUN MAKİNE
ÖĞRENMESİ İLE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

Evin GARİP

Haziran-2017



**İSTANBUL MEDENİYET
ÜNİVERSİTESİ**

FEN BİLİMLERİ ENSTİTÜSÜ
MÜHENDİSLİK YÖNETİMİ ANABİLİM DALI

**OECD ÜLKELERİNDEKİ CO₂ EMİSYONUNUN MAKİNE
ÖĞRENMESİ İLE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

Evin GARİP

Danışman:

Yrd. Doç. Dr. Ayşe Betül OKTAY

Haziran-2017

ONAY

İstanbul Medeniyet Üniversitesi, Fen Bilimleri Enstitüsü'nde yüksek lisans öğrencisi olan Evin GARİP'in hazırladığı ve jüri önünde savunduğu "OECD Ülkelerindeki CO₂ Emisyonunun Makine Öğrenmesi İle Tahmin Edilmesi" başlıklı tez başarılı kabul edilmiştir.

JÜRİ ÜYELERİ

İMZA

Tez Danışmanı:

Yrd. Doç. Dr. Ayşe Betül OKTAY

İstanbul Medeniyet Üniversitesi

Üyeler:

Yrd. Doç. Dr. Ulaş VURAL

İstanbul Medeniyet Üniversitesi

Yrd. Doç. Dr. Tarkan AYDIN

Bahçeşehir Üniversitesi

ETİK İLKELERE UYGUNLUK BEYANI

İstanbul Medeniyet Üniversitesi Fen Bilimler Enstitüsü bünyesinde hazırladığım bu Yüksek Lisans tezinin bizzat tarafımdan ve kendi sözcüklerimle yazılmış orijinal bir çalışma olduğunu ve bu tezde;

- 1- Çeşitli yazarların çalışmalarından faydalandığımda bu çalışmaların ilgili bölümlerini doğru ve net biçimde göstererek yazarlara açık biçimde atıfta bulunduğumu;
- 2- Yazdığım metinlerin tamamı ya da sadece bir kısmı, daha önce herhangi bir yerde yayımlanmışsa bunu da açıkça ifade ederek gösterdiğimi;
- 3- Alıntılanan başkalarına ait tüm verileri (tablo, grafik, şekil vb. de dahil olmak üzere) atıflarla belirttiğimi;
- 4- Başka yazarların kendi kelimeleriyle alıntıladığım metinlerini kaynak göstererek atıfta bulunduğum gibi, yine başka yazarlara ait olup fakat kendi sözcüklerimle ifade ettiğim hususları da istisnasız olarak kaynak göstererek belirttiğimi,

beyan ve bu etik ilkeleri ihlal etmiş olmam halinde bütün sonuçlarına katlanacağımı kabul ederim.

Evin GARİP

ÖNSÖZ

Lisansüstü eğitimim boyunca ve tez çalışmamda, her zaman bizlere çok değerli bilgi ve görüşlerinden yararlanma imkânı sağlayan, rehberliği ve yardımlarıyla bana yol gösteren danışman hocam Sayın Yrd. Doç. Dr. Ayşe Betül Oktay'a, teşekkür ve şükranlarımı sunarım.

Yine yüksek lisans eğitimim süresince üzerimde emeği olan ve bilgilerini bizimle paylaşan Mühendislik Yönetimi Ana Bilim Dalı hocalarıma teşekkürlerimi sunarım. Ayrıca, bu günlere gelene kadar ve tüm lisansüstü çalışmam süresince, büyük özverilerde bulunarak bana sabır ve anlayış gösteren sevgili aileme sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ONAY	i
ETİK İLKELERE UYGUNLUK BEYANI.....	ii
ÖNSÖZ.....	iii
İÇİNDEKİLER	iv
ŞEKİL LİSTESİ.....	vi
KISALTMALAR	viii
TABLO LİSTESİ	ix
ÖZET.....	x
ABSTRACT	xi
1. GİRİŞ	1
1.1. Literatür Taraması.....	5
2. SERA GAZLARI	11
2.1. Atmosferin Yapısı.....	11
2.2. Atmosferin Sera Etkisi	12
2.3. Sera Gazı Kaynakları ve İklim Değişikliği	13
2.4. Sera Gazları Ve Sera Etkisine Katkıları.....	16
2.4.1. Karbondioksit (CO ₂)	16
2.4.2. Metan (CH ₄)	17
2.4.3. Nitröz Oksit (N ₂ O)	18
2.4.4. FloroKarbon Gazları (F Gazlar).....	18
2.5. Sera Gazı İstatistikleri.....	18
2.6. İklim Değişikliğinin Sonuçları.....	20
2.7. İklim Değişikliğinin Türkiye Üzerine Etkisi.....	22
2.8. Türkiye Sera Gazı İstatistikleri	22
3. MAKİNE ÖĞRENMESİ İLE TAHMİNDE BULUNMA	24
3.1. Makine Öğrenmesi.....	24

3.2. Makine Öğrenmesi Uygulama Alanları	25
3.3. Makine Öğrenmesi Tipleri	25
3.4. Makine Öğrenmesi İle Tahmin Yapma	26
3.4.1. M5P	27
3.4.2. Destek Vektör Makineleri	30
3.4.3. Yapay Sinir Ağları	32
3.4.3.1. Yapay Sinir Ağı Hücresi	33
3.4.3.2. Yapay Sinir Ağı	36
3.4.3.3. Çok Katmanlı Algılayıcılar	37
4. METOTLARIN VERİYE UYGULANMASI.....	39
4.1. OECD Ülkeleri Verileri	39
4.2. Tahminler İçin Performans Metrikleri	41
4.2.1. Ortalama Mutlak Hata (MAE)	41
4.2.2. Ortalama Mutlak Yüzde Hata (MAPE).....	41
4.2.3. Ortalama Hata Karesi (MSE).....	42
4.2.4. Ortalama Hata Karesinin Kökü (RMSE)	42
4.3. Uygulama	42
4.3.1. Türkiye İçin CO ₂ Emisyon Tahmini.....	42
4.3.2. A.B.D	46
4.3.3. İngiltere	48
4.3.4. Japonya	51
4.3.5. Güney Kore	53
4.3.6. Almanya	55
4.3.7. İtalya	58
4.3.8. Kanada	60
4.3.9. Avustralya	62
4.3.10. Meksika.....	64
5. SONUÇLAR VE TARTIŞMA	68

ŞEKİL LİSTESİ

Şekil 1.	Sera Gazı Salınım Kaynakları	13
Şekil 2.	Son Yüzyılda Yaşanan Sıcaklık Değişimi	15
Şekil 3.	Sera Gazları Artışı (IPCC, 2014)	15
Şekil 4.	Karbondioksit Yoğunluğu (Kocak,2017).....	16
Şekil 5.	MÖ 8000 -2015 Arası CO ₂ Değişimi (EPA, 2017).....	17
Şekil 6.	Sera Gazı Kaynakları (IPCC, 2014).....	19
Şekil 7.	OECD Sera Gazı Emisyon Kaynakları (IEA, 2017).....	19
Şekil 8.	OECD Enerji Kullanımı ve CO ₂ Emisyonu (IEA, 2017).....	20
Şekil 9.	Ortalama Deniz Seviyesi Artışı (NASA, 2017)	21
Şekil 10.	Türkiye Sektörel Sera Gazı Emisyon Oranları (TÜİK, 2017)	23
Şekil 11.	Türkiye Sektörel CO ₂ Emisyonu (TÜİK, 2017).....	23
Şekil 12.	Basit Karar Ağacı Yapısı (Türkoğlu, 2007)	27
Şekil 13.	Karar Ağacı Modeli (Sezer, 2008)	29
Şekil 14.	a) Doğrusal Ayrılabilen Örnekler b) Doğrusal Olarak Ayrılmayan Örneklemeler (Akar Ö. , 2013)	31
Şekil 15.	Destek Vektörler ve En Büyük Düzlem (Akar Ö. , 2013)	31
Şekil 16.	Yapay Sinir Ağı Hücresi (Uslu, 2017).....	33
Şekil 17.	YSA Hücresi Girdiler Toplamı (Öztemel, 2003).....	34
Şekil 18.	Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı Mimarisi (Yurtoğlu, 2005).....	36
Şekil 19.	Çok Katmanlı Algılayıcı (Elmas, 2007).....	37
Şekil 20.	Dünya ve OECD Ekonomik Durumu (IEA, 2017)	39
Şekil 21.	2014 Yılı OECD CO ₂ Emisyon Sıralaması (IEA, 2017)	40
Şekil 22.	Türkiye CO ₂ Emisyonu (BP, 2014).....	44
Şekil 23.	Enerji Kaynağına Göre Türkiye Enerji Profili (BP, 2014).....	44
Şekil 24.	YSA Gerçek Değer-Tahmin Edilen Değer Verileri	45
Şekil 25.	Enerji Kaynağına Göre A.B.D. Enerji Profili (BP, 2014).....	46
Şekil 26.	A.B.D. CO ₂ Emisyonu (BP, 2014).....	47
Şekil 27.	A.B.D. Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	48

Şekil 28.	İngiltere CO ₂ Emisyonu (BP, 2014).....	49
Şekil 29.	Enerji Kaynağına Göre A.B.D. Enerji Profili (BP, 2014).....	49
Şekil 30.	İngiltere Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	50
Şekil 31.	Enerji Kaynağına Göre Japonya Enerji Profili (BP, 2014)	51
Şekil 32.	Japonya CO ₂ Emisyonu (BP, 2014)	51
Şekil 33.	Japonya Gerçek Değer-Tahmin Edilen CO ₂ Değerleri	53
Şekil 34.	Enerji Kaynağına Göre G. Kore Enerji Profili (BP, 2014)	53
Şekil 35.	G. Kore CO ₂ Emisyonu (BP, 2014)	54
Şekil 36.	G. Kore Gerçek Değer-Tahmin Edilen Değer CO ₂ Değerleri.....	55
Şekil 37.	Enerji Kaynağına Göre Almanya Enerji Profili (BP, 2014).....	56
Şekil 38.	Almanya Sürdürülebilir Enerji Kullanımı (BP, 2014)	56
Şekil 39.	Almanya CO ₂ Emisyonu (BP, 2014).....	57
Şekil 40.	Almanya Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	58
Şekil 41.	Enerji Kaynağına Göre İtalya Enerji Profili (BP, 2014)	58
Şekil 42.	İtalya CO ₂ Emisyonu (BP, 2014)	59
Şekil 43.	İtalya Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	60
Şekil 44.	Enerji Kaynağına Göre Kanada Enerji Profili (BP, 2014).....	61
Şekil 45.	Kanada CO ₂ Emisyonu (BP, 2014)	61
Şekil 46.	Kanada Gerçek Değer-Tahmin Edilen CO ₂ Değerleri	62
Şekil 47.	Enerji Kaynağına Göre Avustralya Enerji Profili (BP, 2014).....	63
Şekil 48.	Avustralya CO ₂ Emisyonu (BP, 2014).....	63
Şekil 49.	Avustralya Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	64
Şekil 50.	Enerji Kaynağına Göre Meksika Enerji Profili (BP, 2014)	65
Şekil 51.	Meksika CO ₂ Emisyonu (BP, 2014).....	66
Şekil 52.	Meksika Gerçek Değer-Tahmin Edilen CO ₂ Değerleri.....	67

KISALTMALAR

BM	: Birleşmiş Milletler
CH₄	: Metan
CO₂	: Karbondioksit
DVM	: Destek Vektör Makinaları
EPA	: Amerika Birleşik Devletleri Çevre Koruma Ajansı
IEA	: Uluslararası Enerji Ajansı
IPCC	: Hükümetler arası İklim Değişikliği Paneli
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MSE	: Ortalama Hata Karesi
M5P	: M5 Model Ağacı
N₂O	: Nitröz Oksit
RMSE	: Ortalama Hata Karesinin Kökü
YSA	: Yapay Sinir Ağları

TABLO LİSTESİ

Tablo 1.	Yapay Sinir Hücresi –Gerçek Sinir Hücresi Karşılığı	34
Tablo 2.	Türkiye'nin 1965–2014 Enerji Profili	43
Tablo 3.	Türkiye CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	45
Tablo 4.	A.B.D CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	47
Tablo 5.	İngiltere CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	50
Tablo 6.	Japonya CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	52
Tablo 7.	Güney Kore CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	54
Tablo 8.	Almanya CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	57
Tablo 9.	İtalya CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	59
Tablo 10.	Kanada CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	62
Tablo 11.	Avustralya CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	64
Tablo 12.	Meksika CO ₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları.....	66

ÖZET

21. yüzyılın en büyük problemlerinden biri yaşadığımız küresel ısınma ve buna bağlı olarak meydana gelen iklim değişikliğidir. İnsan kaynaklı iklim değişikliği olgusu sanayi devriminde insanların enerji elde etmek için fosil yakıtları kullanmasıyla ve dünya atmosferindeki sera gazı konsantrasyonunu değiştirmeye başlamasıyla ortaya çıkmıştır. Dünya ekonomileri günümüzde %65 oranında fosil yakıtlara dayamaktadır. Enerji elde etmek için fosil yakıtların kullanımı, en önemli sera gazı olan ve küresel ısınmadan %80 oranında sorumlu olan CO₂ emisyonuna yol açmaktadır. Bu nedenle, ülkelerin CO₂ emisyonlarının takip edilmesi ve gelecek yılların CO₂ emisyonlarının planlanması çevre için önem arz etmektedir.

Bu tezde, bazı OECD ülkelerindeki CO₂ emisyonları makine öğrenmesi yöntemleri ile tahmin edilmiştir. Klasik istatistiksel zaman serisi metotları yerine, yapay zekânın alt dalı olan makine öğrenmesi yöntemleri ile tahminler yapılmış ve zamanın yanında yıllık petrol, doğal gaz, nükleer, sürdürülebilir ve hidro elektrik enerji kullanım miktarları ile CO₂ salınımı tahmin edilmiştir. Literatürde farklı alanlar için tahminlerde başarılı sonuçlar verdiği bilinen makine öğrenme metotlarından M5P, çok katmanlı algılayıcı ve destek vektör makinesi yöntemleri kullanılarak CO₂ emisyonu tahmin edilmiştir. 34 adet Ekonomik İşbirliği ve Kalkınma Örgütü (OECD) ülkelerinden yüksek CO₂ salınımına sahip ülkelere A.B.D, Japonya, Kanada, Avustralya, Güney Kore, Almanya, İtalya, Fransa, Türkiye ve Meksika için tahminler gerçekleştirilmiştir. Bu metotların sonuçları farklı metriklere göre karşılaştırılmış ve performans değerlerine bakıldığında destek vektör makinesinin CO₂ tahmininde oldukça başarılı sonuçlar ürettiği görülmüştür.

Anahtar Kelimeler: CO₂ emisyonu tahmini, OECD, destek vektör makineleri, M5P, yapay sinir ağları, çok katmanlı algılayıcılar

ABSTRACT

One of the biggest problems we are facing with in the 21th Century is global warming. Climate change, that is result of global warming, is another important problem. Human generated climate change has started with the industrial revolution that took place in 1850s because human began to consume so much fossil-based energy sources that change the atmospheric concentration of the greenhouse gases. Nowadays, 65% of the world energy still relies on the fossil fuels. In the atmosphere, fossil based fuels increase CO₂ emission which is the most important greenhouse gas and responsible of 80% of the global warming. Therefore, it is crucial for countries to monitor the CO₂ emissions and plan the future emissions by forecasting.

In this thesis, the CO₂ emission is forecasted with machine learning methods. Instead of the classical statistical time series methods, machine learning methods which are the subdivision of artificial intelligence are employed. Not only the time information, but also the yearly petroleum, nuclear, natural gases, hydroelectric, and renewable energy consumptions of the OECD countries are used to forecast the CO₂ emissions. The popular machine learning methods in the literature like multilayer perceptron, support vector machines, and random M5P are employed for the forecasts.

10 OECD countries which are known with their high level of CO₂ emissions like USA, Germany, Japan, South Korea, Australia, Canada, England, Italy, Turkey and Mexico chosen among the 34 OECD countries for forecasting. The forecasting results are compared according to the performance metrics and it is found out that DVM is quite successful in forecasting CO₂.

Key Words: Forecasting CO₂ emission, OECD, support vector machine, M5P, artificial intelligence, multilayer perceptron

1. GİRİŞ

Atmosfer yerküreyi saran gazlardan oluşan ve iklim olaylarının meydana geldiği katmandır. Atmosferin yapısındaki gazların yaklaşık %78'i azot, %21'i oksijen, %0,9'u argon, %0,03'ü karbondioksittir (CO₂). Bunlarının yanında az miktarda neon, kripton, ksenon ve helyum gibi soy gazlar da atmosferde bulunmaktadır. Bu dengenin tarih boyunca değişmesi, 1850 sanayi inkılabına kadar doğal nedenlerle olmuştur. Sanayi devriminden sonra ise, atmosferin yapısı insanoğlunun ısınma, ulaşım ve endüstriyel faaliyetlerde bulunurken kullandıkları çeşitli yakıtlar sonucunda değişmeye başlamıştır. Atmosferin yapısında bulunan gazlar yaşamamız için gerekli fotosentez ve solunum olayları dışında, sera etkisinden dolayı dünyadaki yaşamın şu anki düzende olmasını sağlamaktadır. Sera etkisi, atmosferdeki gazların yeryüzündeki ısının bir kısmını tutarak, ısı kaybına engel olmasıdır. Sera gazları, sera etkisinden sorumlu, hem doğal, hem de insan kaynaklı gazlar olup, atmosferdeki kızıl ötesi radyasyonu emen ve ısıyı tekrar yayan gazlardır. Doğal sera gazları en büyük sera etkisine sahip olan su buharı, CO₂, metan (CH₄), diazotmonooksit (N₂O), ozon (O₃) ve endüstriyel üretim sonucu ortaya çıkan çıkan Hidroflorokarbon (HFC), Perflorokarbon (PFC), Sülfürhekzaflorid'dir (SF₆).

Sera gazlarının miktarının artması ile birlikte küresel ısınma olgusu bir süreden beri bilim çevrelerince tartışılan bir konu olmuştur. Bu durum uzun süre tartışılmış ve Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (BMİDÇS, 2017) ile Birleşmiş Milletler tarafından iklimin insan eliyle değiştiği ilk defa 1992 yılında kabul edilmiştir.

21. yüzyılın en büyük problemlerinden biri insan kaynaklı olduğu bilim çevrelerince kabul edilen yaşanmakta olan küresel ısınma ve buna bağlı olarak gelişen iklim değişikliğidir. İklim değişikliği dünya üzerindeki tüm canlı hayatın varoluş şeklini değiştirecek şekilde yaşanan büyük bir değişimdir. Mevsimlerin uzunlukları ve sıcaklık ortalamaları değişmiştir. Buna bağlı olarak bitkilerin hasat zamanı verimlilikleri değişmiştir. Bazı ülkelerde -özellikle sahra altı Afrika'sında-

kuraklıklar görülmektedir. Isınma olayları buharlaşmayı etkilemekte ve kuralığa neden olmaktadır. Kuraklık açlığı ve susuzluğu beraberinde getirmektedir. Bu da su ve ekonomik kaynaklı sorunlara yol açmaktadır. Sıcak hava dalgaları büyük tayfunlara ve fırtınalara neden olmaktadır. Kuzey kutup ve güney kutbunda buzul tabakalarında büyük çapta erimeler tespit edilmiştir. Bu, kurulu olan yaban hayatın dengesini değiştirmekle pek çok türün soyu tükenme noktasına gelmiştir. Buzul erimelerinin sürmesi okyanus seviyelerinde artışa neden olmaktadır (Climate Change, 2017). Dünya Meteoroloji Organizasyonu tarafından yapılan açıklamaya göre her yıl okyanus seviyeleri 3 mm kadar artmaktadır. Bu seviye artışı 20. yüzyılda gerçekleşen yıllık ortalama 1,6 mm seviyesinin yaklaşık 2 katıdır. Atmosferdeki CO₂ değer artışı okyanuslarda çözünen CO₂ miktarını artırmaktadır. Deniz ve okyanus sularının asitliğinin artması suda yaşayan bitkiler, hayvanlar ve tek hücrelilerin kurulu dengesini değiştirmektedir. Deniz ürünlerinde meydana gelen değişimler insan beslenmesini de etkilemektedir (IEA 2015 Raporu, 2017).

İklim değişikliklerinin gelecekte insanlığa büyük çevresel felaketler, açlık, savaş, susuzluğa neden olma potansiyeli yüksektir. Bu nedenle, iklim değişikliğini tetikleyen faktörlerin analiz edilmesi ve planlamasının yapılması sadece Türkiye için değil tüm dünya için çok önemlidir. Bu tezde, iklim değişikliğine neden olan sera gazlarından CO₂ emisyonunun tahmin edilmesi hedeflenmiştir. Tahminler, seçilen 10 Ekonomik İşbirliği ve Kalkınma Örgütü (OECD) ülkesi için gerçekleştirilmiştir.

OECD dünyada pazar ekonomisine ve demokratik yapıya sahip 34 ülkenin bir araya gelerek oluşturduğu bir topluluktur. OECD ülkeleri genel anlamda çok büyük ekonomilere sahip olmaları ve yaşam standartlarının yüksek olmasından dolayı yüksek miktarda enerjiye ihtiyaç duymaktadırlar. Isınma, barınma, tarım ulaşım, aydınlanma için gerekli olan enerji hala büyük oranda fosil yakıtlardan elde edilmektedir. Bu fosil yakıtlarda enerji amaçlı tüketilirken önemli bir sera gazı olan ve yaşanan küresel ısınmadan %80 oranında sorumlu tutulan CO₂ ve diğer sera gazları atmosfere karışır. 2014 yılı OECD ülkeleri içerisindeki CO₂ emisyonu sektörel bazlı incelendiğinde, CO₂ emisyonunun %42'si elektrik ve ısınma, %29'u ulaşım amaçlı, %12'si de endüstri sektöründen, %8'i konut kullanımlarından, %4'ü hizmet sektöründen %7'si ise farklı kullanımlardan ortaya çıkmaktadır. Toplam

Temel Enerji Kaynağı (TPES) açısından incelendiğinde, OECD ülkelerinin temel enerji ihtiyacı petrolden sağlanmaktadır. OECD ülkelerinde temel enerji kaynağı

%36 ile petrol, daha sonra %25 ile doğalgaz, %19 ile kömür ve %20'lik bir enerji kaynağı da (nükleer, hidroelektrik, rüzgâr ve güneş enerjisi) ile sağlamaktadır. Öte yandan enerji kaynağı CO₂ emisyon oranlarına bakıldığında CO₂ emisyonunun %40'ı petrolden, %33'ü kömürden, % 25'i ise doğal gazdan kaynaklanmaktadır.

OECD gibi yüksek enerji tüketimine sahip birliklerin enerji tüketimi CO₂ salınımı arasındaki ilişkinin incelenmesi hayati bir önem taşımaktadır. Elde edilen CO₂ tahminleri iklim senaryolarında kullanılabilir, politikacıların karar almasında ve küresel iklim protokollerinin uygulanmasında kullanılabilir.

Yapay zekâ çalışmaları günümüzde birçok farklı problem tipi için sınıflandırma, ilişkilendirme ve tahmin etmede kullanılmakta ve başarılı sonuçlar üretmektedir. Makine öğrenmesi, yapay zekâ sistemlerinin alt kümesi olup, bilgisayarların dışarıdan programlanmadan iş yapabilmesini öngörür. Bilgisayar, çeşitli fonksiyonları ve istatistiksel metotları kullanarak veriden sonuçlar çıkartır. İnsan makineden edindiği bilgiyi sımayabilir ve anlamsız bilgiler üretiliyorsa makine uzmanın işlediği veriler insan uzman tarafından tekrar düzenlenerek öğrenme işi tekrar başlatılabilir. Makine öğrenmesi metotları veriler ve veriye karşılık gelen sonuçlar arasındaki ilişkiyi bulmaya çalışırlar. O nedenle, deneme yapılmadan eldeki veriye uygun makine öğrenme metodunu söyleyebilmek mümkün değildir. Eldeki veri ne kadar çok olursa bu veride ne kadar çok yöntem uygulanırsa en uygun yöntemi bulmak mümkün olur. Makine öğrenmesi uygulamaları deprem analizinde, kalite kontrol süreçlerinde, akıllı sağlık sistemlerinde, reklam ve promosyon çalışmalarında, kredi risk analizinde, sigortacılık işlemlerinde, metin uygulamalarında, ses ve görüntü tanınmasında kullanılabilir (Yılmaz ve Volkan, 2012).

Bu tezde, seçilen ülkeler için makine öğrenmesi metotlarıyla farklı tiplerdeki enerji tüketimi miktarları kullanılarak CO₂ emisyonu tahmini yapılmıştır. Literatürde, klasik zaman seri yöntemleri ile ülkelerin CO₂ emisyonu miktarlarını tahmin eden istatistiksel yöntemler bulunmaktadır. İstatistiksel zaman serisi yöntemleri karmaşıktır ve verinin değişimini zamana bağlı olarak modellerler. Makine

öğrenmesi metotları ise, zamana bağlı geçmiş verileri öğrenerek tahminde bulunurlar. İstatistiksel modeller matematiksel yönden karmaşık olup, birçok ekstra parametre kullanırken, makine öğrenmesi metotları ise öğrendiği bilgilerden daha anlaşılır tahminler yapmaktadırlar.

CO₂ tahmini için literatürde, başarılı sonuçlar ürettiği bilinen 3 farklı makine öğrenmesi metodu kullanılmıştır. Bunlar: yapay sinir ağlarının bir türü olan çok katmanlı algılayıcılar, Destek Vektör Makinesi (DVM) ve M5P metotlarıdır. Çok katmanlı algılayıcılar, Yapay Sinir Ağlarının (YSA) bir çeşididir. Birçok YSA hücresi bir araya gelerek çok katmanlı bir yapı oluşturur. YSA hücreleri öğrenme esnasında sonucu bilinen bir problemi bulur gibi ağırlık değerlerini değiştirerek kendilerini optimize etmektedirler M5P, birçok karar ağacının matematiksel denklemlerle oluşturulması esasına dayanır. Karar ağaçlarında, her düğümde özniteliklerin karşılaştırması ile bir sonuç ortaya çıkar. DVM ise, veriyi daha yüksek bir boyuta taşıyarak oluşturacağı bir hiperdüzlem ile iki sınıfı birbirinden ayırma prensibini esas alır. Hiperdüzlem eğitim kümesindeki örnekler olan uzaklığı optimize ederek bulunmaktadır.

Bu tezde, 1965–2014 yılları arasındaki yıllık enerji tüketim verileri ve CO₂ emisyon miktarları kullanılmıştır. Verinin %80'lik kısmı eğitim için, kalan %20'lik veri de test amacıyla kullanılmıştır. Birçok metodun uygulandığı ve alınan tahmin sonuçlarının karşılaştırılması gerektiği durumlarda metod sonuçlarını karşılaştırmak amacıyla performans değerlendirme metrikleri kullanılmaktadır. Performans metrikleri test verisindeki tahmin edilen değerlerin gerçek değere ne kadar yakın olduğu esasına dayanır. Kullanılan 3 metottan başarı oranı Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Mutlak Hata (MAE), Ortalama Hatanın Karekökü (RMSE) ve Ortalama Hatanın Karesi (MSE) gibi istatistik kökenli fonksiyonlarla karşılaştırılmıştır.

34 OECD ülkesinden CO₂ emisyon oranlarının yüksekliğiyle bilinen A.B.D, Japonya, Kanada, Avustralya, Güney Kore, Almaya, İtalya, İngiltere, Türkiye ve Meksika seçilerek, bu ülkelerin CO₂ emisyonları tahmini edilmiştir. Bu ülkelerde enerji üretimi amaçlı tüketilen petrol, kömür, doğalgaz, nükleer enerji, hidroelektrik ve sürdürülebilir enerji miktarlarıyla yıllık salınan CO₂ değeri arasındaki ilişki

seçilen makine öğrenme metotlarından M5P, DVM ve çok katmanlı algılayıcılar ile analiz edilmiş ve tahmin sonuçları karşılaştırılmıştır.

Tezin ikinci bölümünde iklim değişikliği, küresel ısınma ve bu durumun CO₂ ile olan ilişkisi anlatılmıştır. OECD ülkelerinin enerji kaynaklarından yararlanma şekillerine değinilmiş ve Türkiye açısından sera gazları ve bilhassa CO₂ sürüm değerlerine yer verilmiştir.

Tezin üçüncü bölümünde tezde kullanılan makine öğrenmesi metotları açıklanmıştır. YSA, M5P ve DVM metotları ayrıntılı şekilde açıklanmıştır.

Tezin dördüncü bölümünde 1965–2014 yılı enerji tüketim miktarları ile CO₂ emisyon miktarlarına çok katmanlı algılayıcı, destek vektör makinesi yöntemi ve M5P öğrenme metotları uygulanması sonucu bulunan değerler ve değerlendirme sonuçları verilmiş ve metotların performansları karşılaştırılmıştır. Ayrıca makine öğrenme metotlarının performans değerlendirme kriterleri olan MAPE, MAE, RMSE ve MSE metriklerine de değinilmiştir.

Tezin beşinci bölümünde ise uygulanan makine öğrenme metotlarının sonuçları değerlendirilmiştir.

1.1. Literatür Taraması

Literatürde, CO₂ emisyon tahmini için birçok çalışma yapılmıştır. Bu çalışmaların birçoğu gri metot ya da panel yöntemleri gibi istatistiksel yöntemler ile CO₂ emisyonunu tahmin etmektedir.

Say ve Yücel (2006) toplam enerji tüketimi ile CO₂ emisyonu arasındaki ilişkiyi analiz etmişlerdir. 1970–2002 yılları arasındaki Türkiye enerji piyasası verileri incelenip, Türkiye için toplam enerji tüketimi (TET) modeli oluşturulmuştur. Bu modelin en önemli iki bileşeni ekonomik büyüme ve nüfus artışıdır. Bu iki değişken arasında regresyon ilişkisi kurulmuştur daha sonra toplam enerji tüketiminden yola çıkarak CO₂ emisyonu tahmininde bulunulmuştur. Bu çalışmayla regresyon analizi metodu ile TET verileri kullanılarak CO₂ tahmini yapılabileceği gösterilmiştir.

Yamanoğlu (2006) ise 1990,2000 ve 2004 CO₂ emisyonu değerlerini Türkiye, tüm dünya ve OECD ülkeleri açısından değerlendirmiştir. Ayrıca iktisadi araçlar

kullanılarak emisyon oranlarının düşürülmeye çalışmasını önermiştir. Önerileri emisyon vergileri, karbon vergileri, sürdürülebilir enerjinin teşvikidir.

Sözen (2007) yapay sinir ağları kullanarak CO₂ tahmininde bulunmuştur. Sektörel olarak oluşan CO₂ emisyonları için denklemler kurulmuş ve gelecek için CO₂ emisyonu tahmininde bulunmuştur. MAPE değerleri toplam sera gazı için 0,1471; SO₂ için 0,0667; NO₂ için 0,1819 ve CO₂ için 0,1246 yüzde hata oranı ile bulunmuştur.

Shih ve Tsokos (2008) çalışmalarında 1981–2003 yılları arasındaki aylık CO₂ emisyon verilerini ve Amerika Birleşik Devletlerinin CO₂ emisyon verilerini kullanarak zaman serisi ARİMA metoduyla atmosferik CO₂ ve Amerika Birleşik Devletinin CO₂ emisyonunu tahmininde bulunmuşlardır. Öncelikle güvenilir verilere ulaşmaya çalışmış ve sadece doğruluklarından emin oldukları verileri kullanmışlardır. ABD CO₂ emisyonunun, sürekli tekrar eden bir seri olduğunu ama dünya atmosferindeki CO₂ miktarının yükselen bir trend izlediğini görmüşlerdir. Atmosferik CO₂ değeri için MSE performans değerini 0,0846; A.B.D için CO₂ MSE değerini 8,081 olarak elde etmişlerdir.

Köne ve Büke (2010) çalışmalarında öncelikle sera gazı emisyonlarına bakarak CO₂ emisyonun %60'nın enerji sektörü kaynaklı olduğunu ve dünyanın 25 ülkesinin toplam CO₂ emisyonunun %82'sinden sorumlu olduğunu görmüşlerdir. Oranlarına bakarak en çok emisyonun enerji sektörü tarafından üretildiğini IAEA'dan alınan 1971–2007 arasındaki verilerle enerji üretiminde bulunurken en çok CO₂ salınmasına sebep olan ilk 25 ülke tespit edilmiştir. Veriler analiz edildiğinde verisinde belli bir trend olmayan ülkeler tespit edilmiş ve elenmiştir. Geriye kalan 11 ülke için trend analizi yöntemiyle CO₂ tahmininde bulunulmuştur. 11 ülkeye yüksek büyüme senaryosu ve düşük büyüme senaryosu uygulanarak iki durumda oluşacak CO₂ emisyon değerleri tahmin edilmiştir.

Akçasoy, Önder ve Güven (2010) çalışmalarında, Türkiye'nin 2010 CO₂ salınımı tahmininde bulunmuşlardır. Kullanılan metot verideki trend üzerinden yapılan tahmindir, yapılan çalışmada 2010 yılı için Türkiye CO₂ yayılımını 536 milyon ton olarak bulmuştur.

Pao ve Tsai (2011) ise Brezilya'nın enerji tüketimi, ekonomik büyümesinin ve bu iki etkenin sera gazları ile olan ilişkisini incelemiştir. Çalışmalarında gelir artışının önce çevre kirliliğini artırdığını sonra çevre için yapılan yatırımlarla çevre kirliliğinin azaldığını göstermişlerdir. Brezilya'nın enerji verimliliğini artırması durumunda çevreye zarar vermeden ekonomik büyümesini artırabileceğini önermişlerdir. Gayri safi milli hâsıla, CO₂ emisyonu ve enerji tüketimi verilerine ARİMA ve Grey metodu uygulayarak 2008–2013 yılları için tahminde bulunmuşlardır. İki metodun da MAPE değeri %3'ten küçük olduğu için iki metot da başarılı olarak değerlendirilmiştir.

Arı ve Zeren (2011) ise CO₂ emisyonu ve ekonomik büyüme arasındaki ilişkiyi panel veri analizi ile Akdeniz ülkeleri için incelemiştir. Çalışmalarında ekonomik büyümenin ilk aşamalarında CO₂ emisyonunun enerjinin yoğun kullanılmasıyla artacağını ancak belli bir gelir seviyesinden sonra ekonomik büyüme devam ederken CO₂ emisyonunun azalacağını, daha sonra ise, CO₂ emisyonunun gelirdeki artışla birlikte tekrar artacağını göstermişlerdir. Çünkü N şeklinde bir EKC fonksiyonu, yüksek gelir düzeylerinde bile CO₂'tin gelirle birlikte artabileceği anlamına gelmektedir. Diğer taraftan enerji ve nüfus yoğunluğunun tahmin edildiği gibi CO₂ emisyonu ile pozitif ilişkili olduğu görülmüştür.

Cui, Zhu, Bao ve Liu (2005) kaotik zaman serilerine destek vektör makineleri algoritmalarını uygulayarak tahminlerin yapılabileceğini göstermişlerdir. Böylece t zaman eğrisi üzerinde bir sonraki süreç için başarılı tahminlerin yapılabileceği ispatlanmıştır

Aslanoğlu ve Aydınalp (2012), 2012–2020 yılları arası var olan ve planlanan elektrik üretimi ve elektrik üretimine bağlı CO₂ emisyonu bölgesel olarak belirlemiştir. CO₂ emisyonlarının belirlenmesi için mevcut ve planlanan santrallerin elektrik üretimi ve yakıt tüketim verileri, emisyon faktörleri, yakıt alt ısıl değerleri, ortalama termodinamik verimleri ve elektrik talep tahmin değerleri kullanılmıştır. İlk olarak mevcut santrallere ait yakıt tüketimine bağlı CO₂ emisyonu ve yakıt bazında özel emisyon faktörleri belirlenmiştir. İkinci olarak planlanan santrallere ait CO₂ emisyonu tahmin edilmiştir. 2020 yılı itibariyle Türkiye toplam elektrik üretiminin 377 TWh ve elektrik elde edilmesi sonucu oluşan CO₂ emisyonununun 194 milyon ton olacağı öngörülmüştür ayrıca termik santrallerin CO₂ emisyonu sonucu Adapazarı,

İkitelli, İzmir, Keban ve Seyhan bölgelerinde yüksek oranda çevre kirliliği olacağı da tahmin edilmektedir.

Yılmaz ve Yılmaz (2013) ise 1990 ve 2009 yılları arasındaki CO₂ salınım verilerini kullanarak 2010–2020 yılları için CO₂ salınım değerleri için tahminde bulunmuşlardır. Çalışmalarında Gri tahmin metodunu tercih etmelerinin nedeni daha az veriye ihtiyaç duyması ve yapay sinir ağları ve sezgisel öğrenme metotlarına göre daha kolay olmasıdır. Yapılan tahminlerin ortalama yüzde hatası %5,54 olarak bulunmuştur.

Baareh (2013) çalışmasında temel enerji tüketimi, petrol tüketimi, doğal gaz tüketimi ve kömür tüketimi verilerini kullanarak yapay sinir ağlarıyla CO₂ tahmininde bulunmuştur. 1982–2000 yılları arasındaki veriler ağız öğrenmesi için, 2003–2010 yılları arasındaki veriler ise öğrenilen YSA metodunun test edilmesi için kullanılmıştır. Sonuçlar oldukça başarı olarak değerlendirilmiştir. Ortalama göreceli hata değeri 0,0078 olarak bulunmuştur.

Lotfalipour, Falahi ve Bastam (2013) çalışmalarında İran CO₂ emisyonunu ARİMA ve Grey metoduyla tahmin edip elde edilen tahmin sonuçlarını kıyaslamışlardır. 1965–2010 yılı arasındaki veriler modelin geliştirilmesi için kullanılmış daha sonra 2010–2020 yılları içinde tahminlerde bulunmuşlardır. RMSE, MAE ve MAPE performans metrikleri iki metodun kıyaslanmasında kullanılmıştır. Grey metodu mutlak yüzde hata oranı MAPE değeri, ARİMA metodu MAPE değerinden daha düşük çıkmıştır böylece Grey Metodunun daha iyi sonuçlar verdiği anlaşılmıştır. Grey metoduna göre 2020 yılı için İran'ın CO₂ emisyon miktarı 925,68 milyon ton olarak hesaplanmıştır.

Wu, Liu, Liu, Fang ve Xu (2014) çalışmalarında BRICS Ülkeleri (Brezilya, Rusya, Hindistan, Çin ve Güney Afrika) için 2004–2010 yılları arası CO₂ emisyonunu tahmin etmeye çalışmışlardır. Çalışmalarında ekonomik büyüme, CO₂ emisyonu, şehir nüfusu ve enerji tüketimi değişkenleri kullanılarak tahmin modeli oluşturulmuştur. Ekonomik büyüme Rusya ve Brezilya'da CO₂ emisyonunu düşürürken Hindistan, Çin ve Güney Afrika'da CO₂ emisyonu artmıştır. Öte yandan şehirleşme ve enerji tüketiminin artması tüm ülkelerde CO₂ emisyonunun arttırdığı görülmüştür.

Saleh, Dzakiyullah ve Nugroho (2015), DVM metodunu kullanarak CO₂ tahmininde bulunmuşlardır. Girdi verileri olarak üretim süreçlerinde tüketilen kömür ve elektrik kullanılmıştır. Verilerin %90'ı modelin öğrenilmesi %10'u ise modelin test edilmesi için kullanılmıştır. Modelin RMSE değeri 0,004 olarak hesaplanmıştır. RMSE değerinin 0'dan düşük olması DVM'nin iyi bir tahmin aracı olduğunu göstermekte ve yapılan tahminlerin oldukça başarılı sonuçlar verdiğini göz önüne sermektedir

Ergün ve Atay (2015) çalışmalarında, 1980–2010 yılları arasında OECD ülkelerinde CO₂ emisyonu, elektrik tüketimi ve ekonomik büyüme arasında ilişki olup olmadığını araştırmışlardır. Panel eş bütünleşme testleri sonucunda 30 OECD ülkesinde CO₂ emisyonu, Gayri Safi Yurtiçi Hâsıla (GSYH) ve elektrik tüketimi arasında eş bütünleşme ilişkisi olduğu sonucuna varmışlardır. Uzun dönem tahminlerde 30 OECD ülkesinin çoğunluğunda elektrik tüketimi ve CO₂ emisyonu bağlantının olduğu görülmüştür. Ayrıca, CO₂ emisyonu ve ekonomik büyüme arasında Çevresel Kuznets Eğrisi (ÇKE) hipotezini destekleyen sonuçlar elde edilmiştir. Son olarak Panel Vektör Hata Düzeltme Modeli (VECM) sonuçları 30 OECD ülkesinde kısa dönemde GSYH ile CO₂ emisyonu arasında tek yönlü nedensellik ilişkisi olduğunu ve GSYH ile elektrik tüketimi arasında çift yönlü nedensellik ilişkisi olduğunu göstermiştir.

Pabuççu ve Bayramoğlu (2016) tarafından gerçekleştirilen çalışmada CO₂ emisyon kaynağı olarak enerji üretimi, tüketimi endüstriyel üretim ve seyahat amaçlı enerji kullanımı olarak belirlemişlerdir. Nüfus, gayri safi milli hâsıla, enerji üretimi, tüketimi ve ulaşım için kullanılan enerji miktarı ve CO₂ salınım miktarları yapay sinir ağları ile AB–28 ülkeleri ve Türkiye için analiz edilerek 2020, 2025 ve 2030 yılları için CO₂ tahmininde bulunulmuştur. Sonuç olarak sırayla 740,33 mton, 1039,32 mton ve 122,13 mton CO₂ salınımı yapılacağı ön görülmüştür.

Çeliksaş, Bicil ve Türköz (2017) Türkiye’de 1986–2013 yılları için yıllık kullanılan fosil yakıt ve CO₂ emisyonları arasındaki ilişkiden yola çıkarak üretimde farklı fosil yakıt seçimi senaryolarına dayalı CO₂ emisyonu tahminlerinde bulunmuşlardır. Farklı üretim senaryolarına göre emisyondaki değişimleri hesaplamak için Türkiye’de elektrik üretimi Box-Jenkins metodolojisi ile tahmin edilmiş ve üretim projeksiyonu kullanılarak farklı yakıt bileşimi senaryoları altında CO₂ emisyonları

hesaplanmıřtır. Buna gre elektrik retiminde mevcut durumun devamı, kmre alternatif olarak doęal gaz kullanımı, kmrden yenilenebilir enerjiye geiř gibi alternatif senaryoların CO₂ emisyonunu nasıl deęiřtirdięi alıřmalarında gsterilmiřtir.

2. SERA GAZLARI

2.1. Atmosferin Yapısı

Atmosfer yerküreyi saran gazlardan oluşan ve iklim olaylarının meydana geldiği katmandır. Atmosferin yapısındaki gazlar: yaklaşık %78 azot, %21 oksijen, %0,9 argon, %0,03 kadar karbondioksit ve çok az olarak da neon, kripton, ksenon ve helyum gibi soy gazlarıdır. Bu gazlar, ayrıca miktarı coğrafi bölge, deniz ve göl kenarlarına yakınlık ve sıcaklığa bağlı olarak değişen miktarda su buharı içerir. Su buharı nem ve gaz kümeleri olan bulutlar halinde bulunur. Kirlenme ve rüzgâr durumuna ve volkanik hareketliliklere göre atmosfere toz halinde katı maddeler, küller ve diğer kirlenici gazlarla atmosfer konsantrasyonu oluşmuştur.

Dünyanın jeolojik yapısıyla, element ve gazların değişimiyle beraber atmosfer de değişim geçirmiştir. Volkanik hareketler atmosferdeki SO_2 ve NO_2 gibi gazların artmasına ve oksijenli solunumun başlaması atmosferde O_2 miktarının artmasına neden olmuştur. Bununla beraber, bu etmenler hep doğal etmenlerdir. Güneşten gelen radyo aktif enerji ise hem dünyadaki yaşamın biçimlenmesinde hem de atmosferdeki gaz miktarı üzerinde etkiye sahiptir. Güneş enerjisiyle beraber su buharlaşmış buharlaşan su molekülleri ilkel atmosfer dediğimiz dönemde güneş enerjisiyle su molekülleri oksijen ve hidrojene ayrılmıştır. Ağır oksijen molekülleri atmosferde kalırken hidrojen molekülleri uzaya yayılmıştır (Koçak, 2017).

Güneşin dünyaya gelen enerjisi nedeniyle yaşam üzerinde çok büyük etkisi bulunmaktadır. Bu enerji miktarı dünya ekseninde meydana gelen değişimler, güneş lekeleri, volkanik patlamalar, dünya yörüngesinde meydana gelen değişimlerle değişmektedir. Güneş dünyanın hem ısı hem de ışık kaynağıdır. Güneşten gelen ısı enerjisinin dünya üzerinde tutulup şuan ki anlamda yaşamın dünyada var olması atmosferin doğal sera etkisiyle mümkün olmaktadır. Fransız matematikçi Jean Fourier 1927'de atmosferin sera gibi çalıştığını ortaya çıkaran ilk bilim adamıdır (Tekin,

2011). Daha sonra 1960 ta Jhon Tyndall kızıl ötesi ışınları emen gazların su buharı, karbondioksit ve metan gazı olduğunu ortaya çıkarmıştır (Shih ve Tsokos, 2008).

2.2. Atmosferin Sera Etkisi

Güneş ışınları, atmosferdeki gazları geçerek yer küreye ve su küreye kadar ulaşır. Atmosferdeki bazı gazlar sera gazı olarak tanımlanır ve bu gazlar gelen ısıyı tutarlar. Bu şekilde, dünya yüzeyinde bir denge söz konusu olur. Deniz sıcaklıkları, nehir sıcaklıkları gündüz ve gece farklarıyla çok büyük değişimlere uğramazlar; bu şekilde atmosfer hem bir izolasyon yapmış olur hem de güneş enerjisini soğurarak yeryüzünün ısınmasını sağlamış olur. Bu etkiye sera etkisi adı verilmektedir (Andrews ve Jelley, 2007).

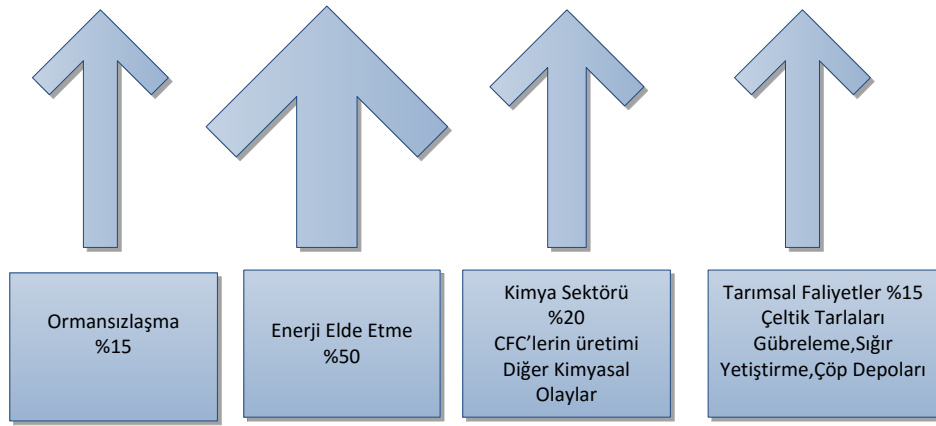
Güneşten gelen ışınların %31'i atmosferdeki aerosollerden ve bulut ve kutup buzullarından uzaya geri yansır. Işınların %69'u ise yerküre hava küre ve su küre tarafından soğrulur ve uzun dalgalı yer ışınımı olarak atmosfere geri yansıtılır. Atmosferdeki sera gazları yansıyan enerjiyi soğurarak tekrar yeryüzüne yayarlar. Böylece dünya olması gerektiğinden daha fazla ışınmış olur. Dünya yüzeyinin -15 santigrat derece olması beklenirken sera etkisiyle 18 santigrat derece civarında seyrederek (Houghton, 2004).

Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (BMİDÇS, 2017) sera gazlarının tanımı şu şekilde yapılmıştır: “Sera gazları, hem doğal, hem de insan kaynaklı olup atmosferdeki kızıl ötesi radyasyonu emen ve tekrar yayan gaz oluşumlarıdır”. Bu tanımla, atmosferin yapısında doğal faaliyetler sonucu oluşan sera gazlarının yanı sıra insan faaliyetleri sonucunda ortaya çıkan ve atmosfere yayılan sera gazlarının varlığından bahsedilmiştir.

Doğal sera gazları en büyük sera etkisine sahip olan su buharı, karbondioksit (CO₂), metan (CH₄), diazotmonooksit (N₂O), ozon (O₃) ve endüstriyel üretim sonucu ortaya çıkan Hidroflorokarbon (HFC), Perflorokarbon (PFC), Sülfürhekzaflorid (SF₆) dir (Türkeş, 2008).

2.3. Sera Gazı Kaynakları ve İklim Değişikliği

Fosil yakıtların kullanımı (büyük oranda CO₂ ve diğer sera gazlarının artışı), orman alanlarının tahrip edilmesi (CO₂ artışı), artan nüfusun besin kaynaklarının karşılanması amacıyla hayvan sürülerinin artırılması (CH₄ alınımı artışı), tarım alanlarında verimi artırmak için nitratlı gübre kullanımının artması (N₂O artışı), soğutucu ve klimalarda kullanılan CFC gazlarının artışı atmosferdeki sera gazı konsantrasyonunu insan faaliyetleri sonucu artırmıştır. Atmosferde sera gazları oranının artması sera etkisinin artmasına yol açmakta bu da kendini tüm dünya yüzeyinde iklim değişikliği şeklinde göstermektedir. Şekil 1'de sera gazı salınım kaynakları (Özcan ve Kayman, 2008) gösterilmiştir.



Şekil 1. Sera Gazı Salınım Kaynakları

Uzun yıllar boyunca dünyanın iklim değişiminde insanın oynadığı rol sorgulanmıştır. Son yüzyıllık iklim değişimleriyle şimdiki veriler karşılaştırıldığında, bir iklim değişiminin yaşandığı ve küresel bir ısınma sürecinden geçildiği aşikârdır. Küresel ısınma dünya sıcaklık ortalamalarının artması şeklinde tanımlanabilir. Artan sıcaklıklarda dünya ikliminde değişimlere yol açmaktadır. Soğuk enlemlerde sıcaklık yükselmesi, deniz suyu sıcaklıklarının artarak termik basınç noktalarını değiştirmesi, sıcak su akımlarının genel özelliklerinin değişmesi gibi birbirini değiştiren etkiler silsilesi meydana gelmektedir. Bu değişimler iklim değişikliği olarak tanımlanabilir (Özcan ve Kayman, 2008).

Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (United Nations Framework Convention on Climate Change-UNFCCC) birinci maddesinde iklim değişikliği şu şekilde tanımlanmıştır: “Karşılaştırılabilir dönemler boyunca gözlemlenmiş doğal iklim değişkenliğine ek olarak ortaya çıkmış ve küresel atmosfer bileşiminde farklılıklar yaratan, doğrudan veya dolaylı olarak insan faaliyetlerine bağlı bir değişiklik” (BMİDÇS, 2017). Birleşmiş milletler çerçeve sözleşmesiyle son iki yüzyıllık dönemde dünya ikliminde meydana gelen değişimlerde insan faaliyetlerinin sonucu olarak ortaya çıktığı kabul edilmiştir.

2013 IPCC raporuna göre 197 uluslararası bilimsel organizasyon iklim değişikliğinin insan aktiviteleri sonucunda gerçekleştiğinden artık kabul etmişlerdir.


Bilim adamları buzullarda sıkışan gazları analiz ederek, tortu katmanlarında bulunan fosiller inceleyerek geçmiş jeolojik dönemlerde yaşanan iklim değişikliklerini analiz edebilmektedirler. Antarktika kıtasında 2004 yılında yapılan EPICA projesine göre sera gazları oranı atmosferde son 440.000 yılın en yüksek seviyesindedir (Mercan, 2013).

Yaşanan sıcaklık değişimlerinin ve iklim değişikliğine dair tüm diğer bulguların araştırılması için Dünya Meteoroloji Örgütü ve Birleşmiş Milletler Çevre Programının aracılığıyla Hükümetler arası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change -IPCC) kurulmuş ve alanında uzman bilim adamlarıyla 1990, 1995, 2001, 2007 ve 2014’te bilimsel deney raporları yayınlanmıştır. IPCC kapsamında yaklaşık 1300 bilim adamı çalışmaktadır.

IPCC tarafından 2001 yılında insan faktörünün yaşanan iklim değişimindeki oranı %60 gibi büyük bir oran kabul edilmiştir. Yine IPCC 2001 raporuna göre son 50 yılda gözlemlenen iklim değişikliklerinin çok büyük bir yüzdesi insan faaliyetleri sonucu yaşanan iklim değişikliklerine işaret etmektedir (Çabuk, 2011).


BM tarafından Rio De Janeiro’da düzenlenen 1992 İklim Değişikliği konferansı ile iklim değişikliği konusunda ilk uluslararası adım atılmış ve iklim değişimi resmîyet kazanmıştır. Bu sözleşmeye Türkiye 24 Mayıs 2004’te dâhil olmuştur.

Şekil 2’de görüldüğü üzere M.S. 1000 ile M.S. 1860 arasında doğrusal bir yol izlemeyen sıcaklık inişler ve çıkışlarla devam ederken 1860 yılından sonra sürekli bir artış göstermeye başlamıştır (Ledley, Sundquist, Killen, Hall ve Killen, 2017).



Şekil 2. Son Yüzyılda Yaşanan Sıcaklık Değişimi

20. yüzyılda ortalama sıcaklık miktarı, 0,6+ 0,2 derece kadar zaten değişmiştir. IPCC küresel sıcaklığın 1900–2100 yılları arasında 1,4–5,8 santigrat derece kadar artacağını tahmin etmektedir (Andrews ve Jelley, 2007).




Şekil 3. Sera Gazları Artışı (IPCC, 2014)

Şekil 3'te metan (CH₄), CO₂ ve nitroz oksit (N₂O) gibi 3 önemli sera gazının atmosferdeki konsantrasyon miktarları verilmiştir. Sanayi devrimiyle beraber üç önemli sera gazı miktarı önemli ölçüde artmıştır. 2000'li yıllarla beraber CO₂'nin daha çok arttığı görülmektedir.

2.4. Sera Gazları Ve Sera Etkisine Katkıları

2.4.1. Karbondioksit (CO₂)

Karbondioksit, küresel ısınmada en önemli paya sahip gazdır. Geçtiğimiz yüzyıllarda atmosferdeki oranı %0,03 iken günümüzde bu oran %0,04'e çıkmıştır (Koçak, 2017).

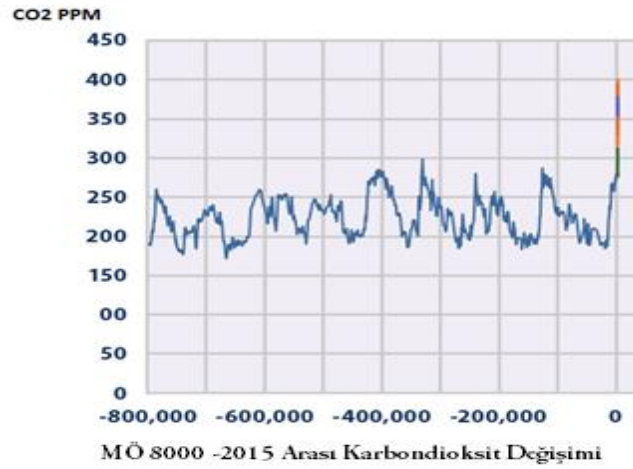


Şekil 4. Karbondioksit Yoğunluğu (Koçak, 2017)

Doğadaki en büyük CO₂ deposu okyanuslardır. Okyanuslar CO₂'nin %50'sini çözülmüş olarak bulundurmaktadırlar. CO₂ fosil yakıtların tüketilmesi ve canlıların solunum faaliyetleriyle atmosfere karışır (Yamanoğlu, 2006). CO₂ sera gazı olmasının yanında fotosentez için de gerekli bir gazdır. Bitkiler, planktonlar ve diğer fotosentez yapan canlılar karbondioksiti bağlayarak diğer tüm canlılar için gerekli besini üretirler ve bizimde dâhil olduğumuz oksijenli solunum yapan canlılar içinde gerekli olan O₂'yi üretirler. Bu döngü karbon döngüsünün bir parçasıdır. IPCC tarafından 2014'te yapılan hesaplara göre CO₂ yıllık ortalama 2 ppm oranında artmaktadır.

Fosil yakıtlarının yakılması ya da biokütlenin yakıt olarak kullanılmasında CO₂ salınır. Örnek olarak arazi genişletme sırasında ormanların yakılması veya bazı endüstri faaliyetleri sonucu atmosfere CO₂ salınması da verilebilir (IPCC, 2001).

En önemli sera gazı toplam sera gazı içinde %80 gibi bir miktara gelen CO₂'dir. Küresel ısınma üzerinde etkili olan sera gazları arasında en önemli sırayı almaktadır (Koçak, 2017). Atmosferdeki kalma miktarı 5 yıl ile 200 yıl arasında değişmektedir (IPCC, 2001). Şekil 5'te MÖ 800 yıllarından günümüze kadar olan sürede atmosferdeki CO₂ miktarı gösterilmiştir (EPA, 2017). Yıl 0'da görülen turuncu çizgi, 0'dan günümüze CO₂ miktarının projeksiyonudur. Bu, bize CO₂ miktarının yaklaşık iki katına çıktığını göstermektedir.



Şekil 5. MÖ 8000 -2015 Arası CO₂ Değişimi (EPA, 2017)

2.4.2. Metan (CH₄)

CH₄ organik atıkların oksijensiz ortamda ayrışması sonucunda atmosfere doğal olarak katılmaktadır. Fakat artık bu doğal denge bozulmuş insan nüfusunun artmasıyla sanayi ve endüstriyel üretimlerle, çöp yığınları ve bataklıklarla atmosfere eskiye oranla daha yüksek yüzdelerde metan gazı karışmaktadır. Metan moleküllerinin küresel ısınmaya katkısı CO₂'den 63 kat daha yüksek olsa da atmosferdeki ömrü kısa olduğundan sera etkisine katkısı yaklaşık %13 olarak hesaplanmaktadır (Yamanoğlu, 2006). Atmosferde kalma ömrü 12–14 yıl olarak değişmektedir (IPCC, 2001).

2.4.3. Nitröz Oksit (N₂O)


Egzoz gazları, fosil yakıtlar ve tarımda kullanılan gübreler azot oksitlerin kaynağını oluşturur. Küresel ısınmaya katkısı yaklaşık %5 olarak hesaplanmıştır. Atmosferde kalma ömrü 114 yıl olabilmektedir (IPCC, 2001).

2.4.4. FloroKarbon Gazları (F Gazlar)

F gazların doğal kaynakları bulunmamaktadır. Tamamen endüstriyel olarak üretilmektedirler. Buzdolabı, klima ve spreylere karışmaktadır. Bu gazlar CFC, PFC, SF₆ gazları bu gaz kümesi içinde tanımlayabiliriz. Sera etkisine katkısı %22 seviyesindedir. 1995 yılında Montreal Protokolü ile florlu gazların kullanımını önemli ölçüde azaltılmıştır. Atmosferde kalma ömürleri 45 yıldan 240 yıla kadar değişmektedir (IPCC, 2001).


2.5. Sera Gazı İstatistikleri

IPCC 2014 raporuna göre 2010 verilerine göre CO₂ %75'lik bir paya sahiptir. Emisyonun %65'i endüstriyel işlemler ve fosil yakıt kullanımından kaynaklanmaktadır. %11'lik CO₂ emisyonu ormansızlaştırma, toprak kullanımı ve çiftçilik faaliyetlerinden kaynaklanmaktadır. %16'lık CH₄ gazı tarımsal faaliyetlerden, çöp kaynaklarından, enerji kullanımı ve biokütle enerji kullanımından kaynaklanmaktadır. %6'lık N₂O fosil yakıt kullanımı, tarımsal faaliyetler, gübre üretiminden kaynaklanmaktadır. %2'lik F-gazları soğutma cihazlarında kullanılan gazlar, endüstriyel işlemlerden kaynaklanmaktadır. Sera gazlarının IPCC 2014 raporuna göre 2010'da emisyon oranları Şekil 6'da verilmiştir.



Şekil 6. Sera Gazı Kaynakları (IPCC, 2014)

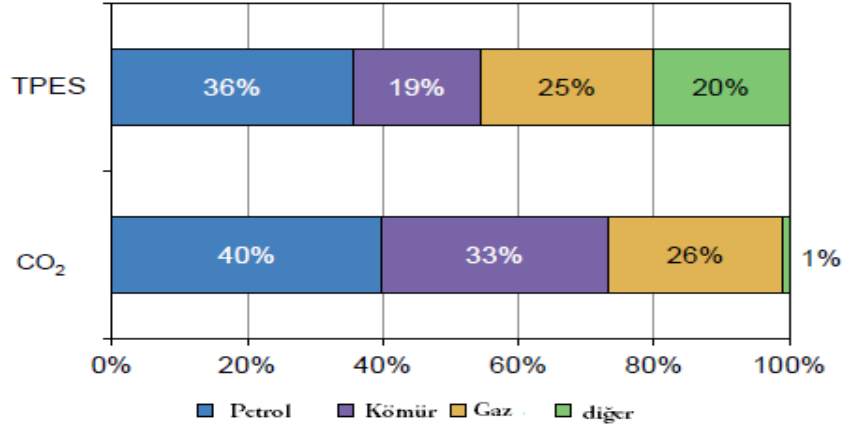
2014 yılı OECD ülkeleri içerisindeki CO₂ emisyonu, sektörel bazlı incelendiğinde CO₂ emisyonunun %42'si Elektrik ve ısınma,%29'u ulaşım amaçlı, %12'si de endüstri sektöründen% 8'i konut kullanımlarından, %4'ü hizmet sektöründen % 7'si ise farklı kullanımlardan ortaya çıkmaktadır (Şekil 7).



Şekil 7. OECD Sera Gazı Emisyon Kaynakları (IEA, 2017)

Toplam Temel Enerji Kaynağı (TPES) açısından incelediğimizde OECD ülkelerinin temel enerji ihtiyacı petrolden sağlanmaktadır. Şekil 8'den de anlaşılacağı üzere OECD ülkelerinde temel enerji kaynağı %36 ile petrol daha sonra %25 ile doğal gaz,

%19 ile kömür ve %20'lik bir enerji kaynağı da (nükleer, hidroelektrik, rüzgâr ve güneş enerjisi) ile sağlamaktadır. Öte yandan, enerji kaynağı CO₂ emisyon oranlarına bakıldığında CO₂ emisyonunun %40'ı petrolden %33'ü kömürden %25'i ise doğal gazdan kaynaklanmıştır. Diğer diye adlandırdığımız enerjiler %20'lik bir enerji ihtiyacını karşılamalarına rağmen %1 CO₂ emisyonunda bulunmuşlardır.



Şekil 8. OECD Enerji Kullanımı ve CO₂ Emisyonu (IEA, 2017)

2.6. İklim Değişikliğinin Sonuçları

IPC 2014 raporlarına göre son 50 yıldan beri iklim üzerinde belirgin değişimler tespit edilmiştir. Raporlara göre görülmekte olan ve görülen olayların sonuçlarına bağlı olarak çeşitli senaryolar oluşturulmuştur. Bu rapora göre:

- Çok sıcak ve çok soğuk kışlar gözlemlenmektedir. Karalar ve denizler arasındaki sıcaklık farkları artıkça daha güçlü tayfunlar ve kasırgalar oluşmaktadır.
- Küresel ısınmayla daha fazla sıcak hava dalgası, kar fırtınası ve sağanak yağış olaylarının görülme sıklığı artmıştır.
- Yeryüzünde buzul tabakalarında büyük çapta erimeler tespit edilmiştir. Buzul erimleri sürerken okyanus seviyeleri de buna bağlı olarak artmaktadır. Dünya Meteoroloji Organizasyonu tarafından yapılan açıklamaya göre her yıl okyanus seviyeleri 3 mm kadar artmaktadır. Bu seviye artışı 20. yüzyılda

geçekleşen yıllık ortalama 1,6 mm seviyesinin yaklaşık 2 katıdır. IPCC yayınladığı 2013 raporuna göre 1950 yılından beri görülen buzul erimelerinin % 95'i insan aktiviteleri sonucunda gerçekleşmiştir (IPCC, 2014).



Şekil 9. Ortalama Deniz Seviyesi Artışı (NASA, 2017)

IPCC 2014 Raporuna göre sanayii devriminden beri (1850) okyanusların asit oranı %25 oranında artmıştır. Bu oran okyanus rifleri ve okyanuslardaki tüm yaşamı tehdit etmektedir. Suyun asitliğinin artması sudaki ekosistemleri tehdit etmekte ve tüm canlılarda değişimlere yol açmaktadır.

Karalarda yaşayan hayvanlar daha yükseklere doğru göç etmektedirler. Buna bağlı olarak ve sıcaklık değişimleriyle tüm türlerde yeni adaptasyonlar gerçekleşmekte dünya üzerindeki yayılımları değişmektedir. İklim değişikliklerinin bu hızda gerçekleşmesi türlerin yok olmasıyla sonuçlanabilecektir. Ayrıca 20. Yüzyıldan beri kuşlarda tespit edildiğine göre kuşların üreme sezonları daha erken olacak şekilde değişmiştir. Bu değişim ağaçların çiçeklenmeye başlama zamanlarında da görülmektedir (EPA, 2017).

Sıcaklık artışları bakteri ve virüslerin dağılımını, çoğalmasını görüldüğü alanların değişmesine neden olmaktadır. Malarya, humma ve astım vakalarında artışlar gözlenmektedir (EPA, 2017).

Gıda sorunu sıcaklık artışı ve tarım arazilerinin yükselen sular altında kalması düşük enlemlerde açlığa, kıtlığa ve susuzluğa sebep olabilecektir. Değişen ekonomik dengeler olumsuz etkilenen az gelişmiş ülkelere çok gelişmiş ülkelere göç


dalgasına neden olabilecektir. Ayrıca düşük rakımlı adalar ve özellikle de okyanuslardaki mercan adalarındaki yerleşimler, doğrudan su altında kalma tehlikesiyle karşı karşıya kalabilecektir (EPA, 2017).

2.7. İklim Değişikliğinin Türkiye Üzerine Etkisi

IPCC 2007'nin sera gazları trendlerini inceleyerek yaptığı projeksiyonlarda 2030 yılında Türkiye sıcaklık ortalama kışın 2 °C, yazın ise 2–3 °C artabilir (IPCC, 2007). Kışlarda yağışlar az da olsa artarken kurak yazlar yaşanabilir. Yine aynı senaryoya göre Akdeniz havzasındaki deniz suyu yüksekliği 12–18 cm yükselebilir. Buzul erimeleri de sürdükçe 2050 yılından 35–65 cm deniz yükselebilir. Bu durumda verimli ovalar deniz suları altında kalabilir. Kar yağışlarında 1987 yılından beri önemli azalmalar görülmektedir. Kar yağışının azalması tarımı ve bitki örtüsünü çok olumsuz etkilemektedir. Bu da artan nüfusu hem su hem de besin anlamında zorlukların beklediği anlamına gelmektedir. Artan nüfusla beraber ormansızlaşma, yaşanan sıcak hava dalgalarıyla beraber orman yangınlarının artması muhtemeldir. Orta Doğu ve Kuzey Afrika iklimlerinin Türkiye üzerinde de etkin olmaya başlayacağı öngörülmektedir (Türkeş, 2008).


2.8. Türkiye Sera Gazı İstatistikleri

TÜİK sera gazı envanterine göre 2014 yılında sera gazı emisyonu 467,6 mton petrol eşdeğeri olmuştur. Emisyonlarda en büyük payı %72,5 ile enerji kaynaklı emisyonlar etkili olmuştur. %13,4 endüstriyel işlemler, %10,6 ile ürün kullanımı %3,5 ile tarımsal emisyonlardır (Şekil 10). Türkiye'nin sera gazı salınımını oluşturmaktadır. Bu veriler ışığında 1990 yılına göre Türkiye'deki sera gazı düşmek yerine %125 artış kaydetmiştir (TÜİK, 2017).



Şekil 10. Türkiye Sektörel Sera Gazı Emisyon Oranları (TÜİK, 2017)

TÜİK 2014 raporuna göre “2014 yılında CO₂ emisyonlarının %85,2’si enerjiden,% 14,6’sı endüstriyel işlemlerden, %0,2’si tarımsal faaliyetler neticesinde emisyonlar gerçekleşti. CH₄ emisyonlarının %54,3’ü tarımsal faaliyetlerden, %25’i atıktan, %20,5’i enerjiden, %0,2’si ise endüstriyel işlemler ve ürün kullanımından kaynaklandı. N₂O emisyonlarının %75,9’u tarımsal faaliyetlerden, %8,3’ü enerjiden, %8’i atıktan, %7,8’i ise endüstriyel işlemler ve ürün kullanımından kaynaklandı.” (TÜİK, 2017).



Şekil 11. Türkiye Sektörel CO₂ Emisyonu (TÜİK, 2017)

3. MAKİNE ÖĞRENMESİ İLE TAHMİNDE BULUNMA

3.1. Makine Öğrenmesi

Makine öğrenmesi, ortamdan elde edilen verileri ve deneyimleri kullanarak yeni modeller üreten algoritmaları tanımlayan genel bir addır. Makine öğrenmesi altında bilgisayarların öğrenmesini sağlayan birçok farklı türde algoritmalar bulunmaktadır. Bilgisayarlar, çeşitli fonksiyonları ve istatistiksel metotları kullanarak öğrenilen veriden bir model çıkartır ve bu modele göre yeni verileri tahmin edebilir, kestirim ya da sınıflandırma yapabilirler.

Literatürde, birçok farklı makine öğrenmesi metodu bulunmaktadır. Bu metotlar, verinin tipine göre farklı başarımlar göstermektedir. Bu nedenle, bir makine öğrenmesi metodunun diğerlerinden üstün olduğunu söylemek zordur. Günümüzde, makine öğrenmesi deprem analizinde, otomasyon sistemlerinde, kalite kontrol süreçlerinde, reklam ve promosyon çalışmalarında, kredi risk analizinde, tıbbi analizlerde, bilgisayar destekli tanı sistemlerinde, sigortacılık işlemlerinde, karakter tanımda, ses ve görüntü tanınması gibi birçok alanda kullanılmaktadır.

Makine öğrenmesinde üç temel aşama vardır. Bunlar:

- Verinin hazırlanması: İlk safha doğru verilerin hazırlanmasıdır ve doğru sonuçlara ulaşmak için veriler büyük bir titizlikle hazırlanmalıdır. Bu aşamada, uç değerlerin bulunması, verinin normalize edilmesi gibi işlemlerle veriler işlenmeye hazır hale getirilmektedir. Problemlerin tiplerine göre hem numerik hem de sembolik (nominal) verilerle işlem yapılabilmektedir.
- Eğitim: İkinci safha en uygun modelin bulunması ve ilk aşamada hazırlanan verinin bu model ile eğitilmesidir. İlk olarak probleme uygun bir makine öğrenmesi metodu seçilir ve verilerden eğitim ile en uygun model oluşturulur. Uygun modeli bulabilmek için olabildiğince çok model kurulup

denenmelidir. Eğitim kümesindeki verinin bir kısmı ayrılarak, model üzerinde doğrulama işlemi yapılarak modelin uygun olup olmadığına karar verilir.

- Test: Son safha ise performans testinin yapılmasıdır. Bunun için modeli oluşturmakta kullanılan eğitim verisi dışında kalan verilerle oluşturulan model kullanılarak test yapılır. Bu veriye test kümesi adı verilir. Test işlemi yapılırken doğruluk oranı, yanlış pozitif bulunan örnek sayısı, doğru pozitif bulunan örnek sayısı gibi metriklerle test kümesi ile makine öğrenmesinin performansı ölçülür.

3.2. Makine Öğrenmesi Uygulama Alanları

Günümüzde, yapay zekâ sistemlerine duyulan ihtiyacın artmasıyla birçok alanda makine öğrenmesi algoritmaları kullanılmaktadır: ticaret, bankacılık ve finans, bilim ve mühendislik, eğitim, internet, sağlık, metin ve dil işleme, güvenlik, oyun gibi. Bu çalışmalarda elimizdeki var olan toplanmış veriler üzerinde makine öğrenmesi yöntemleri uygulanarak gizli örüntüler bulma, tahmin etme ve verinin sınıflandırılması yapılmaktadır.

Üretim sistemleri analizleri, kalite süreç kontrolleri, deprem analizi, hastalık ön tanı sistemleri, sağlık risk analizleri, satış değerlendirmeleri, müşteri profili değerlendirmeleri, portföy yönetimi işlemleri, hisse senedi değerlendirme tahminleri gibi pek çok alanda makine öğrenme algoritmalarından yararlanılmaktadır.

3.3. Makine Öğrenmesi Tipleri

Makine öğrenmesi teknik anlamda istatistik alanında kullanılan yöntemlere dayanır. İstatistik alanında kullanılan yöntemler temel alınarak dijital ortamdaki büyük veriler üzerine uygulanır (Çakır, 2005). Literatürde temel olarak verinin yapısına ve probleme göre 3 farklı tipte makine öğrenmesi metodu bulunmaktadır:

- Denetimli Öğrenme: Eğitim verilerini kullanarak makinenin bir fonksiyon üretmesi şeklinde modellenen makine öğrenme tekniğidir. Girdiler ve çıktılar arasındaki ilişkiyi bir fonksiyonla ilişkilendirilir. Regresyon ve sınıflandırma denetimli öğrenme çeşididir.
- Denetimsiz Öğrenme: Denetimsiz öğrenmede veri örneklerinin etiket bilgisi yoktur. Uygulamanın elinde sadece girdi olarak kullanılacak veriler bulunur. Girdilerin uzaklık, benzerlik gibi metriklere göre kümeler öğrenilir ve bu şekilde kümeleme yapılır (Alpaydın, 2004).
- Takviyeli Öğrenme: Sisteme beklenen sonucun tam olarak verilemediği durumlar için geçerlidir. Sistemin ürettiği sonuçlar için “doğru/yanlış” şeklinde geri besleme verilir ve sistem bu şekilde adım adım modeli öğrenir. Bu öğrenme şekli de takviyeli (reinforcement) öğrenme adıyla anılır.

Bu üç temel öğrenme çeşidinin yanında yarı-denetimli öğrenme de bulunmaktadır. Burada, denetimli ve denetimsiz öğrenme beraber kullanılır. (Chapelle ve Schölkopf, 2006). Yarı-Denetimli öğrenme, uygun sınıflama veya fonksiyonu bulmak için sınıflandırılmış ve sınıflandırılmamış veriler kullanılır. Sınıflandırılmış örneklemin büyüklüğü, sınıflandırılmamış örnekleme göre daha azdır. Tüm etiketlenmemiş verileri de etiketlemek zordur. Bu sebeplerden dolayı yarı-denetimli öğrenme kullanışlı bir yöntemdir.

3.4. Makine Öğrenmesi İle Tahmin Yapma

Zaman serisi belirli bir zaman periyodu içinde düzenli olarak toplanmış veri kümesi olarak tanımlanabilir. Mesela, 1900–2000 yılları arasındaki yıllık yağış miktarı örnek bir zaman serisidir. Zaman serilerini modellemek için birçok farklı teknik vardır: Doğrusal, doğrusal olmayan, parametrik, parametrik olmayan, tek değişkenli, çok değişkenli gibi. Zaman serisi analizi için modelleme yaparken genellikle veride kırılma ve değişme olan yerler göz önüne alınır. Bu sezon değişiklikleri, uzun zamanlı trendler veya ani değişimlerden dolayı olabilir.

Makine öğrenmesi sınıflandırma, regresyon, kümeleme gibi işlemler için kullanılmakla beraber zaman-serisi analizi için de sıklıkla kullanılmaktadır. Makine

öğrenmesi ve zaman serileri geçmişten gelen bilgiler doğrultusunda yeni tahminler yapmaya çalışır. Bu makine öğrenmesinde denetimli öğrenme çeşididir.

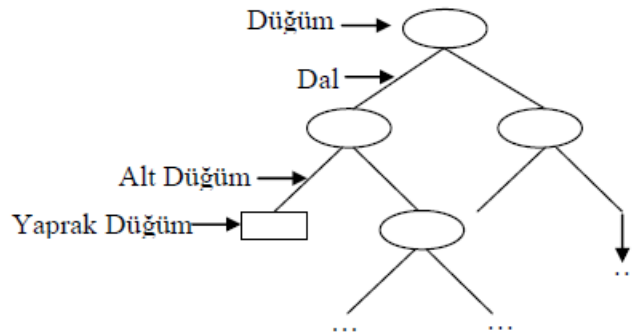
Literatürde birçok farklı alan için klasik zaman serisi analizi ve makine öğrenmesi metotlarını karşılaştıran çalışmalar yapılmıştır (Türkoğlu, 2007). Bu tezde başarılı sonuçlar verdiği bilinen makine öğrenmesi metotlarından M5P, DVM ve YSA kullanılarak zaman-serisi analizi yapılmıştır.

3.4.1. M5P

M5P, karar ağaçları yönteminden türeyen bir metottur. Birçok karar ağacının oluşturulması ve sonuçlarının birleştirilmesi ile sınıflandırma, regresyon gibi işlemler için kullanılmaktadır.

Karar ağaçları tahminde bulunma ihtiyaçlarında yoğunlukla kullanılan kullanışlı ve basit bir metottur. Karar ağacı algoritmalarında kesin sonuç ifade edilir ve kuralın oluşturulma şekli açıktır. Ayrıca diğer metotlara üstünlüğü karar ağaçlarının daha anlaşılır yapıda olmasıdır (Mitchell, 2009).

Karar ağaçları adını aldığı yapılar gibi kök, gövde ve yapraklardan oluşur. Kökünden başlayıp dallanıp yaprakla sona eren bir analiz metodu söz konusudur. Kök en baştaki yapı, yaprak ise kendisinden sonra her hangi bir yapı gelmeyen düğümdür. Karar ağaçları adından da anlaşılacağı gibi karar düğümleri, dallar ve yapraklardan meydana gelmektedir. Karar düğümleri olarak belirtilen kısımlarda veri kaybı gerçekleşmeden veri dallara ayrılır (Özekes, 2003). Basit bir karar ağacı şeması Şekil 12'deki şekilde gibidir.



Şekil 12. Basit Karar Ağacı Yapısı (Türkoğlu, 2007)

Karar ağaçları algoritmasında öncelikle eğitim kümesinden karar ağacının oluşturulması gerekmektedir. Karar ağaçlarının oluşturulmasında C4.5, CART, Chaid, ID3 gibi farklı metotlar kullanılabilir. Bu metotların birbirlerinden farkı bilgi kazanımını ölçerken kullandıkları yöntemlerin birbirlerinden farklı olmasıdır. Bir karar ağacının oluşturulması en temel olarak şöyledir:

- Eğitim kümesi E olsun.
- E kümesindeki örnekleri en iyi ayıran öznitelik k entropiye göre belirlenir. k ağacın yeni bir düğümünü oluşturur.
- k 'nin çocuk düğümlere ait alt veri kümesinin örnekleri bulunur.
- Her alt veri kümesi için
 - o Örneklerin hepsi aynı sınıfa aitse
 - o Örnekleri bölecek nitelik kalmamışsa
 - o Kalan niteliklerin değerini taşıyan örnek yoksa işlemi sonlandır.
- Diğer durumda alt veri kümesini ayırmak için, ikinci adıma dönülerek entropiye göre yeni düğüm k bulunur.

Karar ağacı oluşurken hangi özniteliğin seçileceğinin entropiye göre dir. Entropi, rastgeleliği, belirsizliği ve beklenmeyen durumun ortaya çıkma olasılığını gösterir. Karar ağacında en yüksek bilgi kazanımını veren öznitelik seçilir.

Entropi şu şekilde hesaplanır. Mesela S kümesi, $i = \{1, \dots, m\}$ olmak üzere C_i sınıfından s_i satır içersin. Burada bilgi kazanımı I şu şekilde hesaplanır:

$$I(s_1, s_2, \dots, s_m) = - \sum_{i=1}^m \frac{s_i}{s} \log_2 \frac{s_i}{s} \quad (1)$$

Bir A değişkenin $\{a_1, a_2, \dots, a_v\}$ değerleri ile düzensizliği $E(A)$ (entropi)

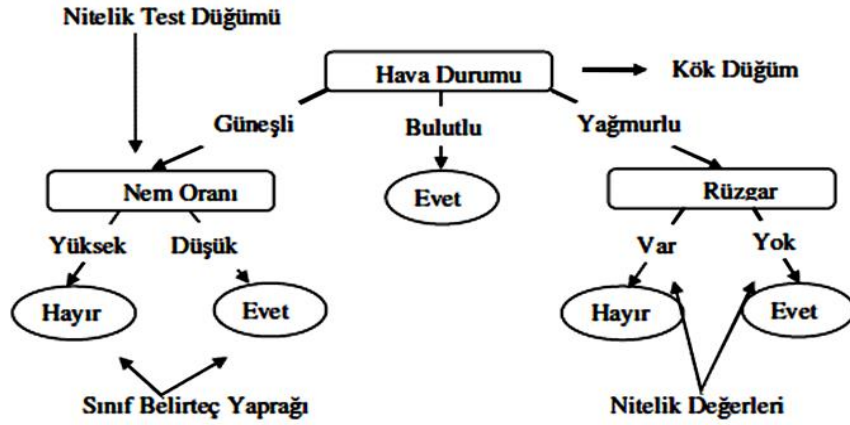
$$E(A) = \sum_{j=1}^v \frac{s_{1j} + \dots + s_{mj}}{s} I(s_{1j}, \dots, s_{mj}) \quad (2)$$

A değişkeni kullanılarak ağacın dallanmasıyla kazanılan bilgi Kazanç (A) ise şu şekilde hesaplanır:

$$Kazanç(A) = I(s_1, s_2, \dots, s_m) - E(A) \quad (3)$$

Karar ağacı oluşturulduktan sonra, kökte bulunan veriden yaprağa doğru bir yol izlenir. Aşama aşama düğümlerde testler yapılarak sorulara cevap aranır. Belirli bir sınıfın olduğu dal ucuna yaprak konur. Ağacın kökü ve düğümleri bir soruyla etiketlenir. Sorular cevaplanıp bir karara varıldıkça dal ucuna bir yaprak konur. Kökteki sorun dallara bölünür ve küçültülüp parçalarına ayrılmış olur. Sorun ağaç metodu ile çözülemezse dahi bu metotla sorun daha anlaşılır hale getirilmiş olur. Karar ağaçları genelde tahmin, kümeleme ve sınıflandırma sorunlarının çözümünde kullanılır.

Problemler karmaşıklaştıkça ve öznelilik sayısı arttıkça düğüm sayılarında artmaktadır. Böyle bir ağacın kavranması güç olduğundan bu ağacın budanması gerekebilir. Karar ağaçlarında yaprak sayısı kadar kural vardır.



Şekil 13. Karar Ağacı Modeli (Sezer, 2008)

Rastgele orman yöntemi karar ağaçlarının daha gelişmiş bir türü olup, eğitim kümesi için birçok karar ağacı oluşturup, bunların sonuçlarını birleştirme prensibiyle çalışmaktadır.

M5P, her bir karar ağacının girdi vektöründen bağımsız olarak örneklenmesi ile üretildiği ağaçlar topluluğudur M5 algoritmasının geliştirilmesi ile oluşturulmuştur. Bu bir topluluk öğrenme metodu olup, sürekli devam eden değişkenleri tahmin etmek için geliştirilmiştir. M5 algoritmasının avantajı diğer ağaç modelleri sınıflandırma amacıyla kullanılırken M5'te ağaçların matematik denklemleri şeklinde

oluşturularak tahmin işlemlerinde etkin olarak kullanılabilmesidir. M5 karar ağaçları 3 aşamada gerçekleştirilir.

- Ağacın geliştirilmesi
- Geliştirilen ağacın bulanması
- Geliştirilen ağacın düzleştirilmesi

M5 ağacı oluşturulurken hedeflenen SDR (Standart Deviasyon Redüksiyonu) değerinin maksimum hale getirilmesidir.

$$SDR: Sd(T) - \sum_i \frac{|T_i|}{|T|} X Sd(T_i) \quad (4)$$

T: Şartları

T_i: i durumundaki şartları

Sd (T): T'nin Standart Deviasyonu

Sd (T_i): T_i Standart Hata Deviasyonu

M tane karar ağacı inşa edilir, daha sonra aşırı öğrenmeleri engellemek için budama işlemi yapılır. Budama işleminde karar ağacındaki değişkenler teker teker kaldırılarak düğümler çözülür daha sonra düzleştirme işlemi yapılır.


M5P algoritması Wang ve Witten tarafından M5 öğrenme metodunun geliştirilmesi ile elde edilmiştir. Böylece, eksik bilgiler ile karar ağaçları oluşturulmuştur

3.4.2. Destek Vektör Makineleri

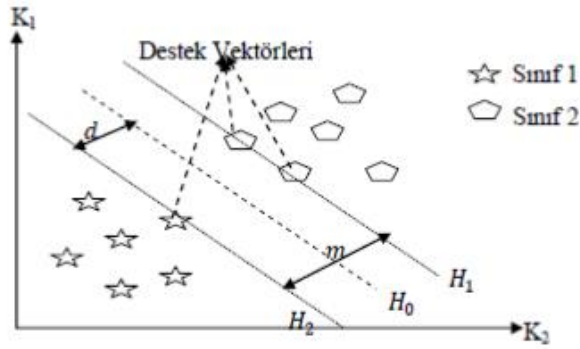
Vapnik tarafından geliştirilen DVM parametrik olmayan makine öğrenme metotlarından olup sınıflandırma amacıyla kullanılır (Vapnik, 1995). Farklı özniteliklere sahip öğrenme kümeleri en uygun düzlemlerle birbirinden ayrılarak sınıflandırılma yapılır.

DVM, temeli istatistiksel öğrenme kuramına dayandırılarak geliştirilen sınıflandırma, regresyon, tanıma ve aykırı değerler belirleme işlemleri için kullanılan danışmanlı öğrenme yöntemidir (Vapnik, 1995).

Bu yöntemle lineer ve lineer olmayan verileri sınıflandırmak mümkündür. Eğer sınıflar doğrusal olarak ayrılabilirse bu yöntem kolaylıkla uygulanmaktadır. Verileri lineer olarak ayırmak mümkün değilse veriler daha yüksek boyutlu uzaya taşınarak çekirdek fonksiyonları kullanılarak sınıflandırma o uzayda yapılır.



Şekil 14. a) Doğrusal Ayrılabilen Örnekler b) Doğrusal Olarak Ayrılmayan Örneklemeler (Akar Ö. , 2013)



Şekil 15. Destek Vektörleri ve En Büyük Düzlem (Akar Ö. , 2013)

Şekil 14'teki gibi K_1 ve K_2 özniteliklerine sahip nesnelerin sınıflandırılması yapılmıştır. H_1 ve H_2 düzlemler üzerindeki destek vektörleridir. İki sınıf arasında pek çok farklı hiperdüzlem çizilebilir. DVM ile hedef iki sınıf arasındaki hiperdüzleme uzaklığı en yakın örneğin uzaklığını maksimum yapan hiperdüzlemin bulunması hedeflenir. Hiperdüzlem bulmak için farklı optimizasyon yöntemleri mevcuttur.

Şekil 15'teki gibi H_1 ve H_2 düzlemleri arasındaki mesafenin tam ortasından H_0 vektörü gösterilmiştir. H_0 düzlemi sınıf 1 ve sınıf 2'yi birbirinden ayıran hiper düzlemdir. Sınıflandırma bu nedenle H_0 düzlemine göre yapılır.

H_0 düzleminin denklemi:

$$H_0 = WX + b = 0 \quad (5)$$

Bu denklemdeki W , ağırlık vektörüdür. $W = \{w_1, w_2, \dots, w_n\}$ olmak üzere n niteliklerin sayısıdır. b sabit bir sayıdır ve X ise eğitim veri kümesindeki nitelikleri karşılar. İki sınıf ayrılmak istediği için:

$$H_0 = w_1x_1 + w_2x_2 + b = 0 \quad (6)$$

$H_0 < 0$ ve $H_0 > 0$ durumuna göre ayırma işlemi gerçekleşir.

Sınıf1 = -1 ve Sınıf2 = 1 olduğuna göre H_1 ve H_2 doğrularının formülleridir.

$$H_1 = wx + b = -1 \quad (7)$$

$$H_2 = wx + b = 1 \quad (8)$$

Hiperdüzlemin altında kalan örnekler,

$$wx + b < -1 \quad (9)$$

Hiperdüzlemin üstünde kalan örnekler,

$$wx + b > 1$$

İki hiperdüzlem arasındaki mesafe,

$$m = 2/||w|| \quad (11)$$

n destek vektörlerinin sayısı, $x_r, y_r = 1$ sınıfına ait destek vektör ve $y_s, x_s = -1$ sınıfına ait destek vektörüdür. Buna göre karar kuralı

$$f(x) = \text{sign} \sum_{i=1}^n \alpha_i xy(xx_i) + b \quad (12)$$

şeklindedir (Tso ve Mather, 2009).

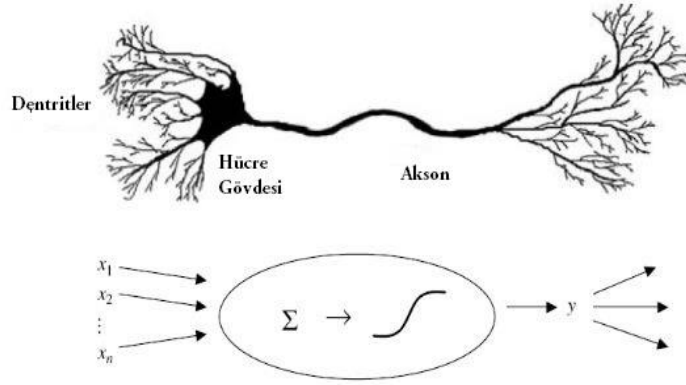
3.4.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), yapay zekâ geliştirmenin alt yollarından biri olarak ortaya çıkmış bir yazılım modellemesidir (Sezer, 2008). YSA, öğrenebilen sistemlerin alt

yapısını oluşturmaktadır. YSA'lar örnek olaylarla eğitilerek deneyim kazanırlar ve daha sonra benzer olaylar için çıktılar sunarlar ya da benzer olaylar üzerinde kendi başlarına çalışırlar.

3.4.3.1. Yapay Sinir Ağı Hücresi

Bir yapay sinir hücresi tıpkı bir nöron gibi girişler, ağırlıklar, toplama fonksiyonu ve son olarak girdinin çıktığı veren kısmından oluşur. YSA hücresinin çıkış verebilmesi için girişlerin iç eşik değeri aşması gerekmektedir. Bir beyin hücresi nöron gibi gelen tüm girdiler alınır, toplanan işaret gücü eşik değeri aşacaksa aksona iletilir. Aksondan diğer nörona iletilir. Hücrenin kayıtlarındaki bilgilerin gelen giriş bilgilerine göre güncellenmesi öğrenmedir. Nöronlar gibi YSA hücreleri bir araya gelerek program katmanları oluştururlar. Hücre girişine gelen veriler toplanarak öğrenme esnasında oluşturulan aktivasyon fonksiyonundan geçirilir. Şekil 16'da nöronun YSA hücresi karşılığı verilmiştir. Bu metaforla yapay zeka daha anlaşılır hale getirilmeye çalışılmıştır.




Şekil 16. Yapay Sinir Ağı Hücresi (Uslu, 2017)

Tablo 1. Yapay Sinir Hücresi –Gerçek Sinir Hücresi Karşılığı

Gerçek sinir hücresi	YSA karşılığı
Nöron	İşlemci Eleman
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Nöron Çıkışı
Sinapslar	Ağırlıklar

Girdiler öğrenme maksadıyla dış ortamdan YSA'ya verilen verilerdir. Ağırlıklar ise girdi olarak kullanılacak olan verilerin matematiksel katsayısıdır. Öğrenme süresince değiştirilerek en iyileme işlemi yapılmaktadır.



Şekil 17. YSA Hücresi Girdiler Toplamı (Öztemel, 2003)

Toplama işlemi ile bir nörona giren girdiler toplanır. Çarpma, toplama, en küçük ya da en büyük gibi normalizasyon işlemi de toplama fonksiyonu olabilir. YSA'daki hücrelerin hepsinde aynı fonksiyonun kullanılması zorunlu değildir (Öztemel, 2003).

x_i girdi, w_i ise ağırlık olmak üzere bir nörondaki toplama işlemi yapılır ve eşik değeri (\emptyset) toplamaya dahil edilmektedir. “s” çıktıdır.

$$s = \sum x_i \cdot w_i \cdot a + \emptyset \quad (13)$$

Eşik değeri girişlerden bağımsız olduğu için bütün girişlerin sıfır olması durumunda çıkış değerinin sıfır değil de eşik değerine eşit olduğu görülür ki bu da, belirtilen

şartlar altında nöron çıkışının sıfır olması zorunluluğunu ortadan kaldırır. Eşik değerinin kullanımı, toplama fonksiyonuna +1 ya da -1 değerine sahip sabit bir girişin ağırlığına sahip bir bağlantı ile eklendiği seklinde yorumlanır (Öztemel, 2003).

Aktivasyon fonksiyonu girdiyi işler ve YSA hücrelerinin çıkışını belirler. Genelde doğrusal değildirler ve “ öğrenme eğrileri” olarak da adlandırılırlar. İlk yapay sinir ağları fonksiyonları genelde doğrusal seçilmişlerdir bu nedenle deneyler başarısızlıkla sonuçlanmıştır (Minsky ve Papert, 1969). YSA'nın durumuna göre tek veya çift yönlü aktivasyon fonksiyonları kullanılabilir.

Doğrusal fonksiyon, basamak fonksiyonu, kutuplamalı basamak fonksiyonu, parçalı doğrusal fonksiyon, sigmoid tipi fonksiyon, tanjant hiperbolik tipi fonksiyonlar aktivasyon fonksiyonlarına örnektir.

Çıkış İşlevi $y=f(v)$ aktivasyon fonksiyonunun dış dünyaya ya da bir sonraki sinir hücresine iletilecek şekilde verilen işlevdir.

YSA hücrelerinin özellikleri şu şekilde tanımlanabilir:


- Doğrusal Olmama: Yapay sinir hücreleri doğrusal değildir. Aktivasyon fonksiyonları doğrusal olmadığından doğrusal olmayan problemlerde YSA hücreleri ile çözebilir (Saraç, 2004).
- Eksik Bilgiler İle Çalışabilirler: Klasik algoritmaların aksine eksik bilgiyle de sonuç verirler. Eğer bilgi sorunun çözülmesinde önemliyse ağın doğru cevap üretmesi ya da yaklaşık değer vermesi güçleşir.
- Uyarlanabilirlik: Yapay sinir ağları, üzerinde çalıştıkları probleme göre ağırlıklarını değiştirebilirler. Eğitim süresince ağırlık bilgilerini güncellerler.
- Parametre Sayısında Sınırlama Yoktur: Sayısız değişken ile çalışabilirler. YSA dezavantajı geniş veri setlerine ihtiyaç duymamalarıdır. Veri setleri ne kadar geniş olursa ağ performansı o kadar yüksek olur ve doğru sonuca daha çok yaklaşılır.
- Hata Toleransı: YSA, çok sayıda hücrenin bir araya gelmesinden oluştuğundan bilgi yapının tamamına dağılmış durumdadır. Hücrelerin bir

kısımının çalışmayı durdurması ağın bilgi üretmesini engellemez. Geleneksel yöntemlere göre hata toleransları daha yüksektir.

- Paralel İşlem Yapabilme: Geleneksel bilgi işlem yöntemlerinde seri işlemler söz konusudur. Yani bir işlem başlar biter ve ikinci işlem başlar. Paralel işlem özelliğiyle çalışan YSA'daysa aynı anda birçok katmanda işlem yapılabilmektedir. Bu şekilde etkisiz hale gelen hücre işlemi başka hücrelerce tolere edilebilir (Saraç, 2004).

4.4.3.2. Yapay Sinir Ağı

Yapay sinir ağlarını oluşturan hücreler bir araya gelerek yapay sinir ağını oluştururlar. Burada modellenen biyolojik bir sinir ağı yapısıdır. Bazı nöronlar girdileri almak için diğerleri de çıktılarını vermek için dışarıyla bağlantı halindedirler. Arada bulunan kısım ise gizli bölüm olarak adlandırılmaktadır (Yurtoğlu, 2005).



Şekil 18. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı Mimarisi (Yurtoğlu, 2005)


Şekil 18'de bir yapay sinir ağı gösterilmiştir. Girdi tabakasındaki hücreler girdiyi aynen alır ve sonraki nöronlara iletirler. Gizli tabaka, tek tabaka olabileceği gibi birden fazla katmanlı da olabilir. Karmaşık yapılar genelde çok katmalı yapıya sahiptirler. Çıktı tabakası ise gizli tabakalardan meydana gelen işlenmiş bilgileri dış ortama ileten tabakadır.

YSA hücreleri arasındaki ağırlık değerlerinin en iyilenecek şekilde kendini güncellemesine YSA'nın eğitilmesi işlemi denir. En başta rastgele ağırlık değerleri kullanılmaktadır. Amaç girdisi ve çıktısı belli olan problem için doğru katsayıların üretilmesidir. Girdiler ve çıktılara YSA eğitim seti adı verilir. YSA'da ağırlıkların değiştirilmesi seçilen öğrenme kuralına göre yapılır. Bir YSA'nın öğrenme işlemi bittikten sonra öğrenmenin gerçekleşip gerçekleşmediğini anlamak için test veri setinden kullanılmamış örnekler seçilerek ağın doğru çıktı üretip üretmediği test edilir. Test işlemi sırasında ağın ağırlık değerleri değiştirilmez. Elde edilen çıktıların doğruluğu YSA'nın performansı hakkında bilgi verir.

YSA'nın Boltzman makineleri, oto-kodlayıcılar, ileri beslemeli yapay sinir ağları, Kohonen ağlar gibi birçok çeşidi mevcuttur. Bu tezde çok katmanlı algılayıcılar ile tahminler yapılmıştır.

4.4.3.3. Çok Katmanlı Algılayıcılar

Birçok YSA hücresi bir araya gelerek çok katmanlı ve çok hücreli bir mimari oluşturur. Böyle bir mimaride nöronlar doğrusal değildirler. Genelde sigmoid fonksiyonu kullanılır. Çok fazla bağlantı söz konusu olduğundan ağ çok büyük verileri işleyebilir.



Şekil 19. Çok Katmanlı Algılayıcı (Elmas, 2007)

Girdi katmanı, sinir ağına dışarıdan gelen giriş değerlerini ara katmana yönlendirir. Giriş katmanında bilgi değişime uğramadan ara katmana iletilmektedir. Girdi katmanındaki YSA hücreleri elemanı bir sonraki katmanda bulunan YSA

hücrelerine bağlıdır. Ara katmanın görevi bilgiyi işleyerek bir sonraki katmana iletmektir. Bir ÇKA da birden fazla ara katman olabilir. Ara katmandaki her hücre bir sonraki katmandaki diğer tüm hücrelere bağlıdır. Çıktı katmanı ise ara katmandan gelen verileri işleyerek ağın ürettiği çıktıları sinir ağı çıkışlarına gönderir. ÇKA ağları öğretmenli öğrenme yöntemi ile çalışırlar. Yani; bu ağlara eğitim sırasında hem giriş değerleri hem de çıkış değerleri verilir. ÇKA öğrenme kuralı Delta öğrenme kuralının genelleştirilmesiyle elde edilmiştir. ÇKA şu şekilde çalışır: örnekler toplanır, ağın topolojik yapısı anlaşılmasına çalışılır, öğrenme öznitelikleri seçilir, öz ağırlıkların başlangıç değerleri seçilir, öğrenme setinden örnekler seçilerek ağ eğitilir, beklenen çıktı ile gerçek sonuç kıyaslanarak ağırlıklar güncellenir (Elmas, 2007).


4. METOTLARIN VERİYE UYGULANMASI

4.1. OECD Ülkeleri Verileri

Türkiye'nin kurucu üyelerinden olduğu OECD (Organisation for Economic Cooperation and Development) 34 ülkeden oluşan piyasa ekonomisine ve demokratik yapıya sahip ülkelerin ekonomik işbirliği için bir araya geldiği uluslararası bir örgüttür.

Üyeleri: A.B.D., Almanya, Avustralya, Avusturya, Belçika, Çek Cumhuriyeti, Danimarka, Estonya, Finlandiya, Fransa, Hollanda, İngiltere, İrlanda, İspanya, İsrail, İsveç, İsviçre, İtalya, İzlanda, Japonya, Kanada, Kore, Lüksemburg, Macaristan, Meksika, Norveç, Polonya, Portekiz, Slovakya, Slovenya, Şili, Türkiye, Yeni Zelanda, Yunanistan'dır.


2013 verilerine göre OECD ülkeleri dünya nüfusunun %18'ine, GDP'nin %47'sine sahiptirler. Aynı zamanda dünyadaki toplam temel enerji tüketiminin %40'ı bu grup ülkeler tarafından yapılmaktadır (Şekil 20).



Şekil 20. Dünya ve OECD Ekonomik Durumu(IEA, 2017)

IEA 2015 raporuna bakıldığında OECD ülkeleri içinde en çok CO₂ salımında bulunan ülkelerin ABD, Japonya, Almanya, İngiltere, İtalya, Avusturalya, Kanada, Meksika Güney Kore ve Türkiye olduğu görülmektedir. Bu ülkelerin emisyonun

tahmin edilmesi çevre politikaları açısından önemlidir. Dolayısıyla, bu tezde bu ülkeler için CO₂ emisyon tahmini yapılmıştır. Şekil 21’de ülkelerin CO₂ emisyonları gösterilmiştir.



Şekil 21. 2014 Yılı OECD CO₂ Emisyon Sıralaması (IEA, 2017)

Küresel ısınmanın son yüzyılda atmosferde artan CO₂ miktarıyla ilişkili olduğu IPCC (Intergovernmental Panel on Climate Change) raporlarıyla kabul edilmiştir. OECD ve dünyada hala temel enerji kaynağı olarak büyük oranda fosil yakıtlar olan petrol, kömür ve doğal gaza dayanmakla beraber, hidroelektrik enerji, nükleer enerji ve gelişmekte olan sürdürülebilir enerji kullanılmaktadır.

BP (British Petroleum)’un her yıl hazırlamakta olduğu ve çevrimiçi olarak internetten ulaşılabilen 2015 Dünya Enerji Durumu Çalışma Kitabı’nı kullanarak 1964–2015 yılı enerji tüketim verileri ve yıllık salınan CO₂ miktarı verilerine ulaşıldı (BP, 2014). Kullanılan enerji kaynaklarının tam verimle yanması sonucu oluşabilecek CO₂ miktarı yıllık CO₂ emisyonu olarak verilmiştir. Doğru verilere ulaşıldıktan sonra verinin %80’i eğitim amaçlı %20’si ise test amaçlı olarak bölünerek veriye çok katmanlı algılayıcı, MSP ve DVM makine öğrenme metotları uygulanmıştır.

4.2. Tahminler İçin Performans Metrikleri

Tahminler yapıldıktan sonra makine öğrenmesi metotlarının veri seti üzerindeki tahmin başarılarının sayısallaştırılması gereklidir. Bu amaçlarla performans metrikleri geliştirilmiştir. Ortalama Mutlak Hata (MAE), Ortalama Hata Karesi (MSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Hata Karesinin Kökü (RMSE) gibi istatistiksel fonksiyonlar uygulanan makine öğrenme metotlarının performans değerlendirilmesinde kullanılmışlardır.

Tahmin performans değerlendirmesinde en çok kullanılan fonksiyonlar genelde MAPE ve MSE'dir. Fakat diğer iki değerlendirme ölçütünün çalışmada bulunması ilerde yapılacak çalışmaların elde edilen sonuçlarla kıyaslanmasını sağlayacaktır. Lewis (1982), MAPE değerleri %10'un altında olan tahminleri "çok iyi" olarak değerlendirmiştir.

4.2.1. Ortalama Mutlak Hata (MAE)

Ortalama Mutlak Hata (Mean Absolute Error) istatistik biliminde çok kullanılan bir performans fonksiyonudur. Tahmin edilen değer ile gerçek değerler arasındaki farkın mutlak değerinin tüm seri için bulunup sapma değerlerinin ortalaması alınarak performans değeri bulunur.

$$MAE = \frac{1}{n} \sum_{i=1}^n AE \quad (14)$$

$$AE = |G_d - T_d| \quad (15)$$

G_d = Gerçek Değer

T_d = Tahmin Edilen Değer

4.2.2. Ortalama Mutlak Yüzde Hata (MAPE)

MAPE (Mean Absolute Percentage Error) hassas ölçümlerde kullanılan bir performans fonksiyonudur. Büyük verilerin kullanıldığı hassasiyet işlemlerinde yüzde olarak bilgi verir.

$$MAPE = \left(\frac{1}{n} \sum_{i=0}^n \left(\left| \frac{GerçekDeğer - TahminEdilenDeğer}{GerçekDeğer} \right| \right) \right) * 100 \quad (16)$$

4.2.3. Ortalama Hata Karesi (MSE)

Ortalama hata karesi (Mean Squared Error) tüm yapılan sapmaların kareleri toplanarak bulunan değerlerin ortalamasının bulunmasıyla performans analizi yapılır. Böylece negatif değerler pozitif değerleri nötrlememiş olur. Hatanın sıfıra yaklaşması istenen çıkış değerine yakın çıkış değeri elde edilmiş olması demektir. Burada G_d , istenen çıkış değerini; T_d ise sistem tarafından hesaplanan çıkış değerini ifade eder. N ise çıkış sayısını belirtmektedir. İleri beslemeli ağlarda genellikle ortalama karesel hata (Mean Square Error - MSE) performans fonksiyonu olarak kullanılır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Gd - Td)^2 \quad (17)$$

G_d =Gerçek Değer

T_d =Tahmin Edilen Değer

4.2.4. Ortalama Hata Karesinin Kökü (RMSE)

Ortalama hata karesinin kökü (Root Mean Squared Error) çok kullanılan performans ölçütlerindedir. Şu şekilde hesaplanmaktadır:

$$RMSE = \sqrt{\left(\frac{1}{N} \sum_{i=0}^n AE\right) AE = (Gd - Td)^2} \quad (18)$$

G_d =Gerçek Değer,

T_d =Tahmin Edilen Değer

4.3. Uygulama

4.3.1. Türkiye İçin CO₂ Emisyon Tahmini


Türkiye, OECD ülkeleri içerisinde son 10 yılda enerji talep artışının en hızlı gerçekleştiği ülke durumundadır. Yapılan projeksiyonlarda bu talep hızının devam edeceği görülmektedir. Avrupa Birliği'nin enerji talep artış oranı %1,6 iken aynı dönem için Türkiye enerji talep artış oranı %4,6 olmuştur (EMO, 2017). 2014 yılında yaklaşık olarak 125 milyon ton petrol eşdeğeri enerji talebi olmuştur. 2023 yılında bu enerji talebinin 218 milyon ton petrol eşdeğeri olacağı tahmin edilmektedir. Birincil enerji kaynağı %35'i doğal gaz, %28,5'i kömür, %27'si petrol, %7'si hidroelektrik

ve %2,5'i diđer yenilenebilir kaynaklardan elde edilmektedir. Türkiye enerji ihtiyacının %25'i lke iinden %75'i ise ithal edilerek sađlanmaktadır (Enerji Bakanlıđı, 2017). Enerji talebinin yođun olması ve geliřmekte olan bir lke olması nedeniyle CO₂ emisyonunun tahmin edilmesi nemli bir husus arz etmektedir.


BP 2015 alıřma kitabına gre Türkiye'nin enerji profili Őekil 23'teki gibidir. Türkiye, CO₂ emisyonunu azaltma aısından en temel uluslararası strateji belgelerinden olan Birleřmiř Milletler İklim Deđiřikliđi ereve Szleřmesi'ni imzalamıřtır ve bu szleřme dođrultusunda CO₂ emisyonunun azaltılması iin yapılması gerekenler kararlařtırılmıřtır (BMİDS, 2017).

Tablo 2. Türkiye'nin 1965–2014 Enerji Profili

	<i>Birimi</i>	<i>Minimum</i>	<i>Maksimum</i>	<i>Ortalama</i>
<i>Zaman</i>	yıl	1965	2014	1989
<i>Petrol</i>	mton	4,5	33,8	21,6
<i>Dođal Gaz</i>	mton	0	43,7	10,0
<i>Kmr</i>	mton	3,6	35,9	15,65
<i>HidroElektrik</i>	mton	0,5	13,4	5,3
<i>Yenilenebilir</i>	mton	0	0,9	0,085
<i>Poplasyon</i>	milyon	34	78	55
<i>CO₂ Salınımı</i>	mton	29,9	348,5	151,52



Şekil 22. Türkiye CO₂ Emisyonu (BP, 2014)



Şekil 23. Enerji Kaynağına Göre Türkiye Enerji Profili (BP, 2014)

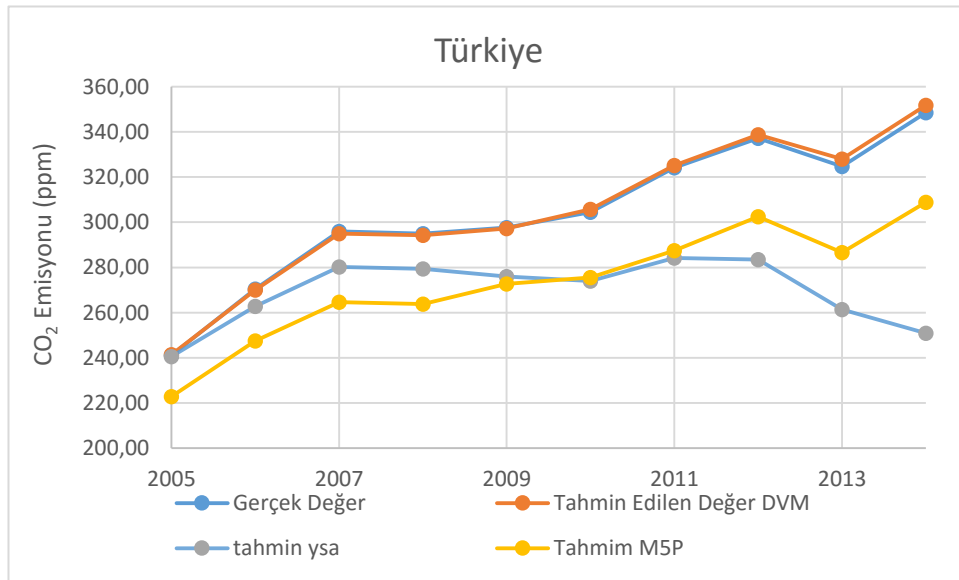
Enerji profiline bakıldığında doğal gaz tüketimi 1987 yılında başlamasına rağmen hızla artmış ve 2009 yılından sonra tüketimi petrolü geçmiştir. Türkiye’de şu an için aktif olan herhangi bir nükleer santral olmadığından kullanılan nükleer enerji miktarı 0’dır. Kömür daha çok termik santrallerde elektrik üretiminde kullanılmaktadır. Kömürün CO₂ emisyonuna katkısı çok olmasına rağmen kullanımı bazı yıllarda düşmüştür fakat kömür kullanımının hala artmakta olduğu görülmektedir.

1965–2014 yılları arasındaki enerji verilerine (mton) ve CO₂ emisyonuna (mton) M5P, YSA (çok katmanlı algılayıcı) ve DVM metodu uygulandı. Verinin %80’i öğrenme, %20’si test amaçlı kullanıldı. Makine öğrenme metodlarının başarımlarını anlamak için MAPE, MSE, RMSE ve MAE metrikleri sonuçları Tablo 3’te verilmiştir.

Tablo 3. Türkiye CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	43,239	13,41	53,57	2849,3
DVM	1,3	0,4	1,67	2,81
M5P	30	9,97	31,35	982


Tablo 3’e göre tahminlerde DVM %0,4 MAPE değeriyle diğer iki metoda kıyasla düşük bir hata yüzde oranı vermiştir. Şekil 24’te test verilerinin gerçek değerlerini (kırmızı) ve tahmin edilen CO₂ emisyon değerlerini (mavi ile) gösterilmektedir. Grafik incelendiğinde DVM gerçek değerler ile neredeyse birebir tahminler yapmıştır. M5P artma ve azalma trendlerini başarılı öngörmüş fakat daha düşük değerler tahmin etmiştir. YSA ise 2012’den sonra emisyonun azalacağını öngörmüştür fakat 2014’te gerçek emisyon değeri bir önceki yıla göre artmıştır.




Şekil 24. Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.2. A.B.D

A.B.D, dünyanın ikinci en büyük enerji tüketim değerlerine ve buna bağlı olarak OECD ülkeleri içinde 2014 verilerine göre büyük CO₂ emisyon değerine sahiptir. Enerji elde edilmesinde kömür ve petrolün çok kullanılması ayrıca sürdürülebilir enerji kaynaklarından çok yararlanılmamasından ötürü CO₂ emisyonu yükselen bir trend izlemektedir.



Şekil 25. Enerji Kaynağına Göre A.B.D. Enerji Profili (BP, 2014)



Şekil 26. A.B.D. CO₂ Emisyonu (BP, 2014)


Verilerin %20'si test, %80'i öğrenme amacıyla kullanılmıştır. Tablo 4'te görüldüğü üzere DVM %0,363 MAPE değeriyle en küçük hata yüzdesi oranına sahip metot olmuştur. MAPE değerinin sıfırdan küçük çıkması DVM'nin oldukça iyi tahminde bulunduğunu göstermektedir.

Tablo 4. A.B.D CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	35,2004	0,576	38,024	1445,8
DVM	21,7849	0,363	26,330	677,58
M5P	100	1.67	139.85	1955

Şekil 27'de test verilerinin gerçek değerlerini (kırmızı) ve tahmin edilen CO₂ emisyon değerlerini (mavi) göstermektedir. Tahminler incelendiğinde 2009 yılına kadar tüm metotların başarılı bir şekilde tahmin yaptığı görülmektedir. YSA ve


DVM diğer yılları da başarılı tahmin ederken, M5P ise gerçek değerlerden daha düşük değerler tahmin etmiştir.




Şekil 27. A.B.D. Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.3. İngiltere

İngiltere yüksek CO₂ emisyon miktarına sahip OECD ülkelerinden birisidir. İngiltere'nin Şekil 29'daki Enerji Kaynağı grafiğine bakıldığında özellikle kömür kullanımı çok büyük oranda düştüğü görülmektedir. Petrol kullanımında da yavaş bir trendle düşüş söz konudur. Kömür ve petrol gibi CO₂ emisyonu üzerinde çok etkili iki fosil yakıtın düşmesine bağlı olarak CO₂ emisyonu düşme göstermektedir.



Şekil 28. İngiltere CO₂ Emisyonu (BP, 2014)




Şekil 29. Enerji Kaynağına Göre İngiltere. Enerji Profili (BP, 2014)

Tablo 5. İngiltere CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	42,75	8,38	56,23	3161
DVM	49,51	9,65	62,85	3950
M5P	37,9	7,36	47,32	2239,29


Tablo 5'teki performans metriği değerlendirme tablosuna bakıldığında M5P'nin %7,36 gibi bir oranla en düşük hata yüzdesini verdiği görülmektedir. Diğer ülkelerde daha düşük MAPE oranları varken, İngiltere için nispeten daha başarısız tahminler yapılmıştır. Hiçbir metot aslında İngiltere'deki emisyondaki aşırı düşüşü öngörüp tahmin edememiştir. Sürdürülebilir enerji kullanım miktarlarının eğitim kümesinde yeterince olmaması nedeniyle düşüş trendinin öğrenilemediği söylenebilir.




Şekil 30. İngiltere Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.4. Japonya

Japonya dünyanın üçüncü büyük ekonomisi ve OECD ülkeleri arasında yüksek CO₂ emisyonuna sahip ülkelerinden biridir. Petrol tüketiminde gözle görülür bir düşüş trendi yaşanmaktadır. Öte yandan kömür tüketimi artmaya devam etmektedir.



Şekil 31. Enerji Kaynağına Göre Japonya Enerji Profili (BP, 2014)



Şekil 32. Japonya CO₂ Emisyonu (BP, 2014)


Japonya enerji verilerine bakıldığında nükleer enerjinin 1978–2010 aralığında enerji tüketiminde önemli pay sahibi olduğu görülmektedir. Fakat 2011 yılına geldiğinde yaşanan nükleer tehlikeden sonra santrallerin kapatıldığı ve nükleer enerjinin 2013 yılında tamamen devreden çıkartıldığı görülmektedir. 2009–2011 aralığında tüm enerji tüketim miktarında düşüş yaşanmıştır. MAPE 0,232 ile hata yüzdesiyle DVM metodu diğer iki metoda göre daha iyi tahmin sonuçları vermiştir.

Şekil 33'te tahmin yapılan 2005–2014 yılları için gerçek değerler ve tahminler gösterilmiştir. 2011 yılındaki deprem ve tetiklediği tsunami sonrasında nükleer santral patlaması da gösterilmektedir.

Tablo 6. Japonya CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	10,413	0,782	12,077	145,861
DVM	3,038	0,232	4,21	17,723
M5P	10,49	0,78	12,4	153


Şekil 33 incelendiğinde, tsunami olana kadar olan 2009'a kadar metotların başarılı bir şekilde tahmin yaptığı görülmektedir. 2011–2014 yılları arasında DVM daha başarılı tahmin sonuçları üretmiştir. M5P daha düşük tahminler üretirken, YSA ise daha yüksek tahminler üretmiştir. DVM'nin Japonya için CO₂ emisyonu tahmin etmede oldukça başarılı olduğu gözlemlenmektedir.




Şekil 33. Japonya Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.5. Güney Kore

Güney Kore, dünyanın 8. büyük ekonomisi olmasının yanı sıra OECD ülkeleri arasında yüksek CO₂ emisyonuna sahip ülkelerden biridir. G. Kore enerji talebinin büyük kısmını petrolden ve kömürden karşılamaktadır. Geçtiğimiz son üç yıl içerisinde de yenilenebilir enerji miktarında da gözle görülür bir artış yaşanmamıştır.



Şekil 34. Enerji Kaynağına Göre G. Kore Enerji Profili (BP, 2014)




Şekil 35. G. Kore CO₂ Emisyonu (BP, 2014)

Tahminler için yine 1965–2004 arasındaki veriler eğitim, 2005–2014 yılları ise test amaçlı kullanılmıştır. Tablo 7’de hata metrikleri verilmiştir. Makine öğrenme metodlarının performans değerlendirmelerine bakıldığında DVM’nin 0,52 MAPE değeriyle en düşük hata yüzde oranını verdiği görülmektedir. Şekil 36’da yapılan tahminler ve gerçek değerlerin yıllar içindeki grafiği gösterilmiştir.

Tablo 7. Güney Kore CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	40,68	5,48	53,8	2897,4
DVM	3,67	0,52	4,18	17,49
M5P	89	12,72	92,58	8572


Şekil 36’da DVM ile yapılan tahmin edilen değer (kırmızı)-gerçek değer (mavi) ile gösterilmiştir. Grafik incelendiğinde, DVM methodu gerçek değerlerle neredeyse birebir benzer sonuçları üretmiştir. 3,67 MAE hatası DVM’nin Güney Kore gibi sürekli artış gösteren trendlerde başarı ile uygulanabileceğini göstermiştir. M5P ise değerleri tahmin ederken, artma-azalma trendini başarılı olarak öngörse de daha yüksek değerler tahmin etmiştir. Bu nedenle, hata oranları M5P için daha yüksek çıkmıştır.




Şekil 36. G. Kore Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.6. Almanya


Dünyanın büyük ekonomilerinden olması ve Avrupa OECD ülkeleri arasında büyük ekonomiye sahip olması nedeniyle CO₂ emisyonun da katkısı önemlidir. 2001'den 2014 yılına kadar olan süreçte Şekil 38'de görüldüğü üzere sürdürülebilir enerjisini %500 oranında artırmıştır. Petrol kullanımının azaldığı görülmektedir. Kömür kullanımında da zamana bağlı olarak azalma söz konusudur. CO₂ emisyonunda düşen bir trend söz konusudur.



Şekil 37. Enerji Kaynağına Göre Almanya Enerji Profili (BP, 2014)



Şekil 38. Almanya Sürdürülebilir Enerji Kullanımı (BP, 2014)




Şekil 39. Almanya CO₂ Emisyonu (BP, 2014)

Makine öğrenmesi performans başarımlarına bakıldığında M5P metodunun diğer metotlara göre başarılı olduğu görülmektedir. M5P metodunun MAPE değeri 0,019 olarak çıkmıştır. DVM de oldukça başarılı sonuçlar üretmiştir ve MAPE hatası 0,3 olarak bulunmuştur. YSA ise daha yüksek değerler tahmin ettiği için 3,41 MAPE hatasına sahiptir.

Tablo 8. Almanya CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	28,01	3,41	38,31	1468,3
DVM	2,5	0,3	3,01	9,08
M5P	0,16	0,019	0,2	0,004


Şekil 40 incelendiği zaman YSA'nın 2007 yılından sonrası için daha yüksek değerler tahmin ettiği görülmüştür. Bu nedenle YSA'nın hata oranları oldukça yüksektir. M5P ve YSA ise çok başarılı tahmin sonuçları üretmiştir.




Şekil 40. Almanya Gerçek Değer-Tahmin Edilen Değerleri

4.3.7. İtalya

Avrupa ve dünyadaki büyük ekonomilerden biri olan İtalya'da enerji kaynaklarında petrol önemli bir paya sahiptir. Kömür enerjisinde zamanla azalan bir trend görülmektedir (Şekil 41). Son yıllarda kömür ve doğalgaz kullanımları bariz bir şekilde azalırken, yenilenebilir enerji kullanımı artmıştır. Şekil 42'de CO₂ emisyonuna bakıldığında yavaş bir ivmeyle azaldığı görülmektedir.



Şekil 41. Enerji Kaynağına Göre İtalya Enerji Profili (BP, 2014)



Şekil 42. İtalya CO₂ Emisyonu (BP, 2014)


Tablo 9. İtalya CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	30,54	7,77	41,22	1699
DVM	9,57	2,45	13,17	173,63
M5P	15,88	3,38	18,62	347,15

DVM metodunun MAPE değerinin %2,45 olarak en küçük hata yüzdesi oranına sahip olduğu görülmektedir. YSA ise tüm hata oranları için oldukça fazla değerler üretmiştir.

Şekil 43'te gerçek değerler ve yapılan tahminler için grafik verilmiştir. Grafiğe bakıldığı zaman 2010 yılı hariç emisyon oranları her sene bir önceki seneye göre düşüş göstermiştir. 2014 yılındaki düşüşten dolayı emisyon değerini hiçbir metot doğru tahmin edememiştir. Eğitim kümesinde böyle ciddi bir düşüş olmadığı göz


önüne alındığı zaman, M5P ve DVM'nin yine de başarılı tahminler yaptığı söylenebilir. YSA ise daha yüksek değerler tahmininde bulunmuştur.



Şekil 43. İtalya Gerçek Değer-Tahmin Edilen CO₂ Değerleri


4.3.8. Kanada

Kanada, OECD ölçeğinde ve dünya ölçeğinde büyük ekonomiye sahip ülkelerden biridir. Şekil 44'te temel enerji kaynaklarının kullanımı gösterilmiştir. Grafik incelendiğinde petrol, hidroelektrik ve doğalgaz kullanım oranlarının son yıllarda birbirlerine yaklaştığı, yenilenebilir enerjinin de son yıllarda arttığı görülmektedir.



Şekil 44. Enerji Kaynağına Göre Kanada Enerji Profili (BP, 2014)

Hidroelektrik, petrol ve doğal gaz en çok tüketilen enerji kaynaklarıdır. CO₂ emisyon trendi artan bir şekilde devam etmektedir.




Şekil 45. Kanada CO₂ Emisyonu (BP, 2014)

Makine öğrenme metotları performans metriklerine bakıldığında DVM metodunun diğer 2 metoda göre en düşük MAPE 0,85 hata yüzdesine sahip olduğu görülmektedir. YSA ise DVM'den daha kötü olmakla beraber, %2,066 hata oranı ile yine de başarılı tahminler yapabirmiştir. M5P ise yaklaşık yüzde 5 gibi bir hata oranına sahiptir. Diğer iki metot kadar başarılı tahminler yapamamıştır.

Tablo 10. Kanada CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	12,71	2,066	15,64	244,65
DVM	5,288	0,85	6,20	38,47
M5P	30,68	4,97	33	1142,06


Şekil 46'daki tahmin-gerçek değer grafiğinde de görüleceği gibi tahminler oldukça gerçek değere yakındır. DVM metodu Kanada için çok başarılı tahmin sonuçları üretmiştir. YSA, düşüşün olmadığı 2008 yılına kadar başarılı tahminler yapmıştır fakat 2008 yılından itibaren daha yüksek değerler tahmin etmiştir. M5P'nin tahmin değerleri ise hep gerçek değerden daha fazla olmuştur.



Şekil 46. Kanada Gerçek Değer-Tahmin Edilen CO₂ Değerleri


4.3.9. Avustralya

Asya bölgesi OECD ülkeleri arasında yüksek enerji tüketimine ve gelişmiş bir ekonomiye sahiptir. OECD ülkelerinden en çok kömür tüketen ülkedir bunun sebebi değerli kömür rezervlerine sahip olmasıdır.



Şekil 47. Enerji Kaynağına Göre Avustralya Enerji Profili (BP, 2014)

2009 yılına kadar kömür başta olmak üzere yüksek düzeyde petrol tüketimi de söz konusudur. 2009 yılından sonra kömür ve petrol tüketimi azalmaya başlamıştır. Buna bağlı olarak CO₂ emisyon oranında azalma görülmeye başlamıştır.




Şekil 48. Avustralya CO₂ Emisyonu (BP, 2014)

Aşağıdaki tablodan görüldüğü gibi M5P metodu %1 MAPE değeri ile en küçük hata yüzdesi oranını vermiştir. YSA ise en yüksek tahmin hata oranlarını vermiştir. MAPE değerleri incelendiğinde M5P ve DVM birbirlerine yakındır. YSA da %2,4 MAPE hatasıyla tahmin yapmıştır.

Tablo 11. Avustralya CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	9,7	2,4	11,84	151,67
DVM	4,41	1,13	5,47	29,36
M5P	3,94	1	4,9	24

Şekil 49’da her üç metodun 2005–2014 yılları için yaptığı tahmin sonuçları gösterilmiştir. Yıllık, artma ve azalma trendlerini her üç metot da başarılı bir şekilde tahmin etmiştir. Fakat YSA diğer iki metoda göre daha düşük tahminler yapmıştır. Emisyon oranı 2008 yılından itibaren düşmeye başlamıştır ve metotlar eğitim verisinde böyle bir düşüş trendi öğrenmemesine rağmen, yine de düşüşü öngörmüşlerdir.




Şekil 49. Avustralya Gerçek Değer-Tahmin Edilen CO₂ Değerleri

4.3.10. Meksika


Meksika, 2014 verilerine göre en çok CO₂ salınımında bulunan on ülke arasındadır. Enerji ihtiyacı büyük oranda petrole ve doğal gazdan sağlanmaktadır. Şekil 50’de

Meksika'nın enerji kaynaklarının yıllar bazında mton cinsinden değerleri verilmiştir. Şekil 50'de görüldüğü üzere 2010 yılına kadar petrol ve doğalgaz kullanımı artmıştır.



Şekil 50. Enerji Kaynağına Göre Meksika Enerji Profili (BP, 2014)

Şekil 51'de ise Meksika'nın yıllık CO₂ emisyon miktarları verilmiştir. Grafik incelendiğinde emisyonun 1977–1983 yıllarında oldukça hızlı arttığı, zaman zaman azalmalar olsa da genel olarak artış gösterdiği görülmektedir.




Şekil 51. Meksika CO₂ Emisyonu (BP, 2014)

Başarı metriklerine bakıldığında DVM metodu 1,4 MAPE değeriyle diğer iki metoda göre düşük hata yüzdesi vermiştir. YSA'nın ürettiği değerler de oldukça gerçek değerlere yakındır. DVM'nin MAPE hata oranı YSA'dan sadece yüzde 0,21 daha azdır. M5P'nin tahmin değerleri ise, diğer iki metottan biraz daha fazladır.

Tablo 12. Meksika CO₂ Emisyonu Makine Öğrenmesi Performans Değerlendirmesi Sonuçları

	MAE	MAPE	RMSE	MSE
YSA	7,9	1,61	8,8	77
DVM	7,8	1,4	8,79	77
M5P	8,73	3,75	10,39	108,02

Şekil 52'de DVM metoduyla tahmin edilen değerler (mavi) ve gerçek değerler gösterilmiştir. Şekilde görüldüğü üzere M5P, CO₂ trendini diğer iki metod kadar başarılı tahmin edememiştir. Bu, M5P algoritmasının doğrusal regresyon ile tahmin yapması, fakat diğer iki metodun doğrusal olmayan ilişkiyi öğrenebilmesi ile açıklanabilir.



Şekil 52. Meksika Gerçek Değer-Tahmin Edilen CO₂ Değerleri

5. SONUÇLAR VE TARTIŞMA

CO₂ emisyon artışının altında yatan neden dünyanın enerji ihtiyacına olan talebinin gün geçtikçe artmasıdır. Temel enerji kaynakları petrol, doğal gaz ve kömür gibi fosil yakıtların dışında nükleer enerji, hidro elektrik enerjisi ve sürdürülebilir enerjidir. Endüstri devrimiyle fosil yakıtların fazla kullanılması ile birlikte iklim değişikliğine sebep olan en önemli sera gazlarından CO₂ salınımı son yüzyılda iki katına çıkmıştır. CO₂ salınımının bu şekilde artışı çok büyük bir sorun olan küresel ısınmanın yanında ilerleyen yıllarda su savaşları, göçler gibi çok daha büyük sorunlara neden olabilir. Bu nedenlerle, ülkelerin CO₂ salınımlarını düşürmek için çeşitli planlamalar yapılmalıdır.

Ülkelerin tümü için tahmin yapan bir sistem ortaya koymak mümkün değildir çünkü ülkelerin enerji kaynakları, üretim seviyeleri, popülasyonları vs. birbirinden çok farklıdır. Bu nedenle, ülkelerdeki CO₂ emisyonları için ayrı modeller kurulması daha uygundur. Bu tezde OECD ülkelerinden CO₂ emisyonu en fazla olan ülkeler seçilmiştir. Bu seçilen 10 ülke, A.B.D, İngiltere, Japonya, Güney Kore, Almanya, İtalya, Kanada, Avusturalya, Meksika ve Türkiye'dir. Bu ülkelerin 1965–2014 yılları arasında yıllık enerji kullanım verileri ve CO₂ emisyon miktarları bu tezde kullanılmıştır.

CO₂ emisyonlarını planlarken geleceğe dönük çeşitli istatistiksel yöntemlerle projeksiyonlar yapılmaktadır. Literatürde klasik istatistiksel yöntemlerle CO₂ salınımı tahmini yapan birçok çalışma vardır. Bu tezde ise CO₂ emisyonunu tahmin etmek amacıyla makine öğrenmesi metotları kullanılmış ve tahmin başarısına göre metotlar karşılaştırılmıştır. Makine öğrenmesi metotlarının bir avantajı tahmin yaparken kolay bir şekilde başka öznitelikleri de kullanabilmektir. CO₂ salınımını tahmin etmek için yıllık CO₂ emisyonunun yanı sıra yıllık petrol, doğal gaz, nükleer, sürdürülebilir ve hidro elektrik enerji kullanım miktarları da kullanılmıştır.

Temel enerji kaynağı olarak adlandırdığımız enerji tüketimleri ve yıllık oluşan CO₂ emisyon verileri seçilen üç makine öğrenme metoduyla tahmin edilmiştir. M5P,

destek vektör makinesi ve yapay sinir ağıları metoduna dayanan çok katmanlı algılayıcılar kullanılan makine öğrenme metodlarıdır. 1965–2014 yılları arasındaki verinin %80'i metodun eğitilmesi için kullanılmış, verinin %20'si ise öğrenilen metodun testi için kullanılmıştır.

Yapılan tahminler sonucunda, DVM makine öğrenme metodunun 10 ülkeden 7'sinde oldukça başarılı tahminlerde bulunduğu görülmüştür. İngiltere, Almanya ve Avustralya içinse M5P makine öğrenme metodunun diğer iki metoda göre başarılı olduğu görülmüştür. Öte yandan, diğer 7 ülkede (ABD, Japonya, İtalya, Kanada, Güney Kore, Türkiye ve Meksika) DVM'nin YSA ve M5P'ye göre daha başarılı olduğu anlaşılmıştır. DVM'nin en iyi tahminini MAPE 0,232 değeri ile Japonya için yaptığı görülmektedir. En iyi M5P tahmin değerinin ise 0,019 MAPE değeriyle Almanya için yapıldığı görülmektedir. Almanya'da çok iyi bir tahmin performansı görülmüştür. Avustralya'ya bakıldığında DVM MAPE değerinin 1,13 M5P MAPE değerinin 1 olduğu görülmektedir. İki metod da oldukça başarılı tahminler yapmalarının yanı sıra değerleri de birbirine neredeyse aynıdır. Aynı şekilde en yüksek DVM MAPE değerinin %9,65 ile İngiltere için yapıldığı görülmüştür. %9.65 değerinin iyi bir tahmin yüzdesi olduğu görülmektedir. Bu da gerek DVM'nin gerek M5P'nin CO₂ projeksiyonunun da kullanılabilmesi anlamına gelmektedir.

ABD, Japonya, İtalya gibi ülkelerde sadece son birkaç yılda CO₂ emisyonu oranlarında düşüş olmuştur. Bu düşüş olan yıllar, eğitim kümesinde olmayıp sadece test verisinde bulunmaktadır. Sistem düşüşle ilgili olarak daha önce eğitilmemesine rağmen DVM enerji kullanımı ile ilgili tahminleri başarı ile yapmıştır.

Türkiye'ye bakıldığında CO₂ emisyonunun her sene artmıştır. Bununla birlikte hidroelektrik dışında diğer enerji türleri de artmıştır. DVM metodunun MAPE değeri 0,4 olarak çıkmıştır. Bu oldukça düşük bir hata oranı olup, DVM'nin kullanımı ile Türkiye'nin CO₂ salınımının hesaplanmasının mümkün olduğu görülmektedir.

KAYNAKÇA

- Akar, Ö. ve Güngör, O. (2010). Rastgele Orman Sınıflandırıcısı İle Arazi Kullanım Alanlarının Belirlenmesi. 3. Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu, (s. 142–152). Kocaeli.
- Akçasoy, K. , Önder, F. ve Güven, S. (2010, Eylül 12). Statistical Evaluation of Greenhouse Gas Emissions of Turkey between the years of 1970 -2010. İnternet Sitesi :
https://www.researchgate.net/publication/237249925_STATISTICAL_EVALUATION_OF_GREENHOUSE_GAS_EMISSIONS_OF_TURKEY_BETWEEN_THE_YEARS_OF_1970_AND_2010
- Alpaydın, E. (2004). Introduction To Machine Learning. London: The MIT Pres.
- Andrews, J. ve Jelley, N. (2007). Energy Science Principles, Technologies and Impacts. London: Oxford University Press.
- Arı, A. ve Zeren, F. (2011). CO₂ Emisyonu ve Ekonomik Büyüme: Panel Veri Analizi. Yönetim ve Ekonomi, 18(2), s. 37–47.
- Aslanoğlu, Y. ve Aydınalp, M. (2012). Elektrik Üretimine Bağlı Karbondioksit Emisyonunun Bölgesel Olarak Belirlenmesi Ve Uzun Dönem Tahmini (Yüksek lisans tezi). Hacettepe Üniversitesi/ Çevre Mühendisliği, Ankara.
- Baareh, A. K. (2013). Solving the Carbon Dioxide Emission Estimation Problem: An Artificial Neural Network Model. Journal of Software Engineering and Applications, 338–342.
- BMİDÇS. (2017, Haziran 6). Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi. Çevre ve Şehircilik Bakanlığı Sitesi:
http://iklim.cob.gov.tr/iklim/Files/Mevzuat/BM_iklimcerceve.pdf

- BP. (2014). Statistical Review Of World Energy. BP internet Sitesi:
<http://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html>
- Breiman, L. ve Cutler, A. (2011, Eylül 12). Random Forests. Berkley University internet Sitesi:
http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm
- Chapelle, O. ve Schölkopf, B. (2006). Semi-supervised Learning. Cambridge: MIT Press.
- Chen, T. ve Wang, Y. C. (2011, Haziran 2015). A fuzzy-Neural Approach For Global CO₂ Concentration Forecasting. Journal of Applied Research and Technology, s. 364–373.
- Climate Change. (2017, Haziran 6). www.epa.gov internet sitesi
<https://www.epa.gov/climate-indicators/oceans>.
- Cui, W.-Z. Zhu, C.-C. Bao, W.-X. ve Liu, J.-H. (2005, May). Chaotic Time Series Prediction Using Mean-Field Theory For Support Vector Machine. Chinese Physics, s. 300–321.
- Çabuk, S. (2011). Küresel Isınmaya Yol Açan Sera Gazı Emisyonlarındaki Artış ile Mücadelede İktisadi Araçların Rolünün Değerlendirilmesi (Yüksek lisans tezi). Ankara Üniversitesi/Sosyal Bilimler Enstitüsü, Ankara.
- Çakır, M. (2005). Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makine Öğrenmesi Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analizi (Uzmanlık tezi). Türkiye Cumhuriyet Merkez Bankası/İstatistik Genel Müdürlüğü, Ankara.
- Çeliktaş, H. Bıcıl, M. ve Türköz, K. (2017, Haziran 6). Türkiye’de Enerji Üretiminde Fosil Yakıt Kullanımı ve CO₂ Emisyonu İlişkisi: Bir Senaryo Analizi.
doi:10.22440/EconWorld. WP.2017.002
- Elmas, Ç. (2007). Yapay Zeka Uygulamaları. Ankara, Seçkin Yayıncılık.

- EMO. (2017, Haziran 6). Türkiye'nin ve Dünya'nın Enerji Profili. Yıldız Teknik Üniversitesi internet sitesi:
<http://www.yildiz.edu.tr/~okincay/dersnotu/EnerjiProfili.pdf>
- Enerji Bakanlığı. (2017, Haziran 6). Türkiye'nin Enerji Stratejisi. T.C Enerji Bakanlığı internet sitesi: http://www.mfa.gov.tr/turkiye_nin-enerji-stratejisi.tr.mfa
- EPA. (2017, Haziran 6). Climate Change Indicators. www.epa.gov:
<https://www.epa.gov/climate-indicators/climate-change-indicators-climate-forcing>
- EPA. (2017, Haziran 6). EPA. United States Environmental Protection Agency internet Sitesi: <https://www.epa.gov/climate-indicators/climate-change-indicators-atmospheric-concentrations-greenhouse-gases>
- Ergün, S. ve Atay, M. (2015, Haziran). OECD Ülkelerinde CO₂ Emisyonu, Elektrik Tüketimi ve Büyüme İlişkisi. Dergi Park(45). doi:10.18070/euiibfd.89737
- Houghton, J. T. (2004). Global Warming: The Complete Briefing. London: Cambridge University Press.
- IEA 2015 Raporu. (2017, Haziran 6). International Energy Agency internet sitesi: http://www.iea.org/media/statistics/Recent_Trends_in_the_OECD.pdf
- IEA. (2017). IEA 2015 Raporu. International Energy Agency. International Energy Agency internet sitesi:
http://www.iea.org/media/statistics/Recent_Trends_in_the_OECD.pdf
- IPCC. (2001, Haziran 6). IPCC. Intergovernmental Panel on Climate Change internet sitesi: https://www.ipcc.ch/ipccreports/tar/wg1/pdf/WG1_TAR-FRONT.PDF
- IPCC. (2007, Haziran 6). Intergovernmental Panel on Climate Change. Intergovernmental Panel on Climate Change internet sitesi:
https://www.ipcc.ch/publications_and_data/publications_ipcc_fourth_assessment_report_synthesis_report.htm
- IPCC. (2014, Haziran 6). IPCC. Intergovernmental Panel on Climate Change internet Sitesi: <http://www.ipcc.ch/report/ar5/index.shtml>

- Koçak, K. (2017, Mayıs 20). Kasım Koçak. İstanbul Teknik Üniversitesi internet sitesi: <http://web.itu.edu.tr/~kkocak/koken.pdf>
- Köne, A. C. ve Büke, T. (2010). Forecasting Of CO₂ Emissions From Fuel Combustion Using Trend Analysis. *Renewable and Sustainable Energy Reviews Science Direct*, 2906–2915.
- Ledley, T. Sundquist, E. Killen, T. Hall, D. ve Killen, T. (2017, Haziran 6). Climate Change and Greenhouse Gases. NASA internet sitesi: <https://ntrs.nasa.gov/search.jsp?R=19990109667>
- Lewis, C. (1982). *Industrial and Business Forecasting Methods*. Londra: Butterworths Publishing.
- Lotfalipour, M. R., Falahi, M. A. ve Bastam, M. (2013). Prediction of CO₂ Emissions in Iran using Grey and ARIMA Models. *EconJournals*, 2146–4553.
- Mercan, M. (2013). Türkiye İçin Alternatif Mitigasyon Politikası Uygulamalarının Ekonomik Analizi: Genel Denge Analizi (Yüksek lisans tezi). Adnan Menderes Üniversitesi / Sosyal Bilimler Enstitüsü, Aydın.
- Minsky, M. ve Papert, S. (1969). *Perceptrons*. London: MIT Press.
- Mitchell, T. (2009). *Machine Learning*. New York: McGraw-Hill Companies.
- NASA. (2017, Haziran 6). Global Climate Change. NASA internet sitesi: <https://climate.nasa.gov/vital-signs/sea-level/>
- NOAA. (2017, Haziran 6). Earth System Lab. NOAA internet sitesi: <https://www.esrl.noaa.gov/gmd/ccgg/trends/>
- Özcan, E. ve Kayman, S. K. (2008). Enerji Tüketimindeki Değişimin Küresel Isınmaya Etkisi ve ABD, AB Ülkeleri, Japonya, Çin ve Türkiye'deki Karşılaştırması: 1980–2004 (Yüksek lisans tezi). Ege Üniversitesi / İİBF, İzmir.
- Özekes, S. (2003, Haziran 6). Data Mining Models and Application Areas. *Istanbul Commerce University Journal of Science*, s. 65–82.
- Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.

- Pao, H. ve Tsai, C. (2011). Forecasting The CO₂ Emissions, Energy Consumption, And Economic Growth in Brazil. *Energy*, 2450–2458.
- Papuçcu, H. ve Bayramoğlu, T. (2016). Yapay Sinir Ağları ile CO₂ Tahmini: Türkiye Örneği. *İktisadi İdari Bilimler Dergisi*, 18, s. 762–778.
- Saleh, C. Dzakiyullah, N. ve Nugroho, J. (2015). Carbon Dioxide Emission Prediction Using Support Vector Machine. *IOP Conferance. IOP Publishing*. doi:10.1088/1757-899X/114/1/012148
- Saraç, T. (2004). Yapay Sinir Ağları Seminer Projesi (Basılmamış Seminer Projesi). Gazi Üniversitesi/ Endüstri Mühendisliği Bölümü, Ankara.
- Say, N. ve Yücel, M. (2006, December). Energy Consumption and CO₂ Emissions in Turkey: Empirical Analysis and Future Projection Based on An Economic Growth. *Energy Policy*, 18, s. 3870–3876.
- Sezer, Ü. (2008). Karar Ağaçlarının Birliktelik Kuralları İle İyileştirilmesi (Yüksek lisans tezi). Kocaeli Üniversitesi/ Mühendislik Fakültesi, Kocaeli.
- Shih, S. ve Tsokos, C. (2008). Prediction Models for Carbon dioxide Emissions and the Atmosphere. *The International Neural Journal*, 16.
- Sozen, A. G. (2007, December). Forecasting Based on Sectoral Energy Consumption of GHGs in Turkey and Mitigation Policies. *Energy Policy*, 12, s. 6491-6505.
- Tekin, A. (2011). Enerji Üretimi Kullanımının Çevreye Olan Etkileri Üzerine Bir Araştırma (Yüksek lisans tezi). Ege Üniversitesi/Sosyal Bilimler Enstitüsü, İzmir.
- Tokel, A. (2017, Mayıs 20). Haber Bülteni. TÜİK internet sitesi: <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=21582>
- Tso, B. ve Mather, P. M. (2009). *Classification Methods For Remotely Sensed Data*. New York City: CRC Press.
- TÜİK. (2017, Haziran 6). Sera Gazı Envanteri 2014. TÜİK internet sitesi: <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=21582>
- Türkeş, M. (2008). İklim Değişikliğiyle Savaşım, Kyoto Protokolü ve Türkiye. *Mülkiye Dergisi*, 32(259), s. 101–131.

- Türkoğlu, İ. (2007, Aralık). Karar Ağaçları Ve Fraktal Analiz Kullanarak Histopatolojik İmgelerin Sınıflandırılması. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 22(4), s. 753–758.
- Uslu, M. (2017, Haziran 6). Yapay Sinir Ağları Kod 5 internet sitesi <http://kod5.org/yapay-sinir-aglari-ysa-nedir>
- Vapnik, V. (1995). The Nature of Statistical Learning Theory. New York: SpringerVerlag.
- Wu, L., Liu, S., Liu, D., Fang, Z. ve Xu, H. (2014). Forecasting CO₂ Emissions in The BRICS (Brazil, Russia, India, China, And South Africa) Countries Using A Novel Multi-Variable Grey Model. Energy (Vol 15), 489–495.
- Yamanoğlu, G. (2006, Mayıs 20). Türkiye’de Küresel Isınmaya Yol Açan Sera Gazı Emisyonlarındaki Artış İle Mücadelede İktisadi Araçların Rolü (Yüksek lisans tezi). Ankara Üniversitesi/Sosyal Bilimler Enstitüsü, Ankara. Ankara Üniversitesi Açık Arşiv: <http://acikarsiv.ankara.edu.tr/browse/1309/>
- Yılmaz, V. ve Güngör, O. (2012). Görüntü Kaynaştırma Yöntemlerinde Performans Analizi (Yüksek lisans tezi). Karadeniz Teknik Üniversitesi/ Harita Mühendisliği, Trabzon.
- Yılmaz, H. ve Yılmaz, M. (2013). Forecasting CO₂ Emissions For Turkey By Using The Grey Method. Journal of Engineering and Natural Sciences, s. 141–148.
- Yurtoğlu, H. (2005, Şubat). Yapay Sinir Ağları Metodolojisinde Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği (Uzmanlık tezi). Devlet Planlama Teşkilatı/Stratejik Araştırmalar, Ankara.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Evin GARİP

Uyruğu: T.C.

Doğum Tarihi ve Yeri: 27 Eylül 1983, Tunceli

Elektronik Posta: evingarip62@hotmail.com

EĞİTİM

Derece	Kurum	Mezuniyet yılı
Lisans	Süleyman Demirel Üniversitesi Elektronik ve Haberleşme Mühendisliği	2009
Yüksek Lisans	İstanbul Medeniyet Üniversitesi Fen Bilimleri Enstitüsü Mühendislik Yönetimi Ana Bilim Dalı Mühendislik Yönetimi	2017

İŞ TECRÜBESİ

Tarih	Kurum	Görev
2010–2012	Horiba Company Japonya	Ar-Ge Mühendisi
2012–Halen	IMU, Öğrenci İşleri Daire Bşk.	Mühendis

YABANCI DİLLER

İleri düzeyde İngilizce