



## Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi

### Market Clearing Price Prediction With Artificial Neural Networks

Akın Ertaylan <sup>1\*</sup>, Özlem Aktaş <sup>2</sup>, Yunus Doğan <sup>3</sup>

<sup>1</sup> Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği, İzmir, TÜRKİYE (\*)

<sup>2,3</sup> Dokuz Eylül Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği, İzmir, TÜRKİYE

Sorumlu Yazar / Corresponding Author \*: [akin.ertaylan@ceng.deu.edu.tr](mailto:akin.ertaylan@ceng.deu.edu.tr)(\*)

Geliş Tarihi / Received: 07.06.2020

Kabul Tarihi / Accepted: 15.10.2020

Araştırma Makalesi/Research Article

DOI:10.21205/deufmd.2021236708

*Atıf şekli/How to cite:* ERTAYLAN, A., AKTAŞ, O., DOĞAN, Y.(2021). Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi. DEUFMD, 23(67), 93-105.

#### Öz

Türkiye Elektrik Piyasası geçmişten günümüze kadar birçok süreç değişikliğine uğramıştır. Bu değişimler sonucunda elektrik piyasası saatlik oluşan enerjiyi bu alandaki paydaşlarına, serbest tüketici sözleşmelerine ilaveten ertesi gün için enerji satış ve alış yapma durumu sağlayarak, paydaşların kendi durumlarını stabil durumda tutmaları adına takip ettiği bir yöntem kurulmuştur. Bu sisteme Gün Öncesi Piyasası (GÖP) denilmektedir ve burada belirlenen fiyata da Piyasa Takas Fiyatı (PTF) denilmektedir. Bu çalışmada yapay zekânın alt dallarından biri olan yapay sinir ağları ile piyasa takas fiyatı tahmini yapılmıştır. Projede bağımsız parametre olarak 10 adet özellik kullanılmıştır. Sinir ağlarında farklı modeller oluşturulmuş ve en iyi sonuç araştırılmıştır. Farklı modellerde farklı ara katmanlar kullanılmıştır. Doğruluk kıstası olarak da MPE kullanılmış ve 0.10 değeri elde edilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağları, PTF, Regresyon, Enerji Tüketimi, Fiyat Tahmini

#### Abstract

Turkey Electricity Market has undergone many changes to the present process in the past. As a result of these changes, the electricity market has created a method that the hourly energy is followed by the stakeholders in this field in order to keep their own status stable by providing energy sales and purchases for the next day in addition to the free consumer contracts. This system is called Pre Day Market (PDM) and the price determined here is called Market Clearing Price (MCP). In this study, the market clearing price estimation was made with artificial neural networks, one of the sub-branches of artificial intelligence. In the project, 10 features were used as independent parameters. Different models have been created in neural networks and the best result has been investigated. Different intermediate layers are used in different models. MPE was used as the criterion of accuracy and 0.10 was obtained.

**Keywords:** Artificial Neural Networks, Market Clearing Price (MCP), Regression, Energy Consumption, Price Prediction

#### 1.Giriş

Gelişen teknoloji ile elektrik enerjisi, günümüzde bir numaralı enerji kaynağı haline

gelmiş olup her geçen gün bu enerjiye duyulan ihtiyaç artmaktadır. Elektrik enerjisi üretildiği gibi tüketilmesi gereken bir enerji kaynağı olduğundan dolayı henüz depolanma gibi bir

şansı da bulunmamaktadır. Üretildiği gibi tüketilen bir enerji türüdür. Bu özelliğinden dolayı da enerji politikasını etkilemektedir.

2000'li yılların başından bu yana diğer Avrupa ülkelerinde olduğu gibi Türkiye'de de Elektrik Piyasasında özelleşme ve serbestleşme süreçleri yaşanmaktadır. Bu nedenle elektrik pazarı günden güne daha rekabetçi ve hummalı bir alan haline gelmiştir. Paydaşlar arasındaki çekişmenin yükselmesi sonucunda elektrik sektöründeki hareketleri akıllıca araştırıp sonuçları tahminlemek ihtiyaç haline dönüşmüştür.

Bu doğrultuda elektrik fiyatının tahmini, çekişmeli pazar şartlarında önemli kârlar sağlamaktadır. İster üretim, ister tüketim, gerekse işletme veya sanayi ihtiyaçlarını gidermek amacıyla piyasaya katılan tüm paydaşların ekonomik verimliliğini geliştirmek ve kârlarını arttırmak için elektrik fiyatını minimum kayıpla kestirmek zorundadırlar. Elektrik piyasasındaki süreçlerin değişkenliğinden dolayı ücret kestirimi yapan modellerinde günümüze uyarlanması gerekmektedir.

Günümüzde fiyat tahminlemeleri uzman kişiler tarafından yapılmasının yanı sıra makine öğrenmesi modelleri kullanılarak da gerçekleştirilebilmektedir. Bu proje de Piyasa Takas Fiyatının (PTF) yapay sinir ağları ile tahminleme çalışması yapılmıştır. Proje kodlanmadan önce literatür araştırılması yapılmış, benzer konularda daha önce yazılmış makaleler okunmuş ve modelleri incelenmiştir.

A. Dalgın [1] yaptığı çalışmada yapay sinir ağlarını kullanarak PTF tahminlemesi yapmış ve MAPE kıstasında 5,21 bir başarı elde etmiştir. Fakat veri seti üzerinde yapılan herhangi bir ön işleme hakkında bilgi verilmemiştir. İ. Pençe ve arkadaşları [2] 2017 - 2023 yılları için Türkiye sanayi elektrik enerjisi tüketimini yapay sinir ağlarını kullanarak tahminlemişlerdir. Çalışmada giriş parametresi olarak sadece yıl bilgisine yer verilmiştir. H. Karacan ve arkadaşları [3] geliştirdiği programda elektrik talep tahmininde bulunmuştur. Bu

tahmini ise sadece basit regresyon ve çoklu regresyon metotlarını kullanarak gerçekleştirmiştir. Bu çalışmada diğer makalelere nazaran veri, ön işleme aşamalarından geçirilmiş daha sonrasında test ve eğitim olmak üzere ikiye ayrılmıştır. Ardından yapay öğrenme modeli oluşturulup tahminleme işlemi yapılmıştır. V.Gümüş ve arkadaşları [4] aylık ortalama buharlaşmayı kestirmek adına Bulanık Mantık Yapay Sinir Ağı, Yapay Sinir Ağı yöntemleri kullanılmıştır. Çıktılar incelendiğinde kullanılan yöntemlerin başarılı sonuçlar verdiği gözlemlenmiştir. Özellikle ANFIS yönteminin altı girdili kombinasyonu, diğer modellerden daha başarılı bir sonucu olduğu gözlemlenmiştir. A. Es ve arkadaşları [5] nöral ağ yöntemiyle Türkiye'ye ait elektrik enerjisi miktarını tahminlemiştir. Tahminleme çalışmasında veri seti olarak 1970-2010 yılları arasındaki nüfus, gayri safi yurtiçi hâsıla, ihracat, bina yüz ölçümü, ithalat ve taşıt sayısı bağımsız değişken olarak kullanılmıştır. C. Toker ve arkadaşı [6] kısa vadeli elektrik ihtiyacı miktarının tahmini için bir metot önermiş ve bu metodun doğruluğunu sınamak için modelden çıkan sonuçları gerçek değerlerle karşılaştırmıştır. Kestirim modelinde yer alan veri seti sıcaklık, gerçekleşen elektrik tüketimi, tarih bilgisi, ışıma günleri ve diğer gerekli meteorolojik etkenlerdir. B. Başoğlu ve arkadaşları [7] Türkiye'ye ait mevsimsel ve piyasa şartlarını göz önüne alınarak, uzman sistemler ve nöral ağ metodunun birlikte kullanıldığı, kısa süreli elektrik miktarı ihtiyacını yüksek yüzdeyle tahminleyen hibrit yöntem geliştirmişlerdir. A. Çayır ve arkadaşları [8] İngiltere'nin Londra şehrindeki belirli bir bölgede bulunan 30 farklı eve ait yaklaşık 3 yıllık elektrik tüketimini veri kümesi olarak kullanmış ve kısa vadeli tüketim tahmini yapan modeli makine öğrenmesi algoritmaları ile oluşturmayı amaçlanmıştır. Çalışmada kullanılan veriler İngiltere'nin Londra şehrinde akıllı sayaç enerji tüketimi (Smart Meter Energy Consumption) veri kümesine aittir. En düşük mutlak hata kayıp skorunu veren model seçilmiş deneyler bu modeller ile gerçekleştirilmiştir. Y. Kocadayı ve arkadaşları [9] TR81 (Bartın, Karabük, Zonguldak) alanının

yıllık elektrik enerjisi tüketimini nöral ağ metoduyla (YSA) tahmin etmiştir. Çalışmada enerji tüketim tahmini yapılırken veri seti olarak ihracat, nüfus, ithalat ve binalara ait yüzey alanı bilgileri kullanılmıştır.

Çalışmanın diğer içerikleri şu şekildedir:

İkinci bölümde neural network üzerine konu anlatılımı yapılmıştır. Üçüncü kısımda veri seti hakkında bilgi verilmiştir. Dördüncü bölümünde tahmin modeli hakkında açıklama yapılmıştır. Beşinci bölümde bulgular açıklanmıştır. Altıncı bölümde sonuçlar ve önerilere yer verilmiştir. Son bölümde ise kaynaklar listelenmiştir.

## 2. Metodoloji

Yapay Sinir Ağları, insanın en önemli organı olan beyne ait çalışma sistemini benimseyerek beynin hatırlama, karar verme, öğrenme, genelleme yaparak yeni bilgiler keşfetme gibi ana fonksiyonlarını yerine getirmek için geliştirilen algoritmalarıdır. Kısacası YSA biyolojik sinir sistemlerini taklit eden bilgisayar programlarıdır[11].

Yapay sinir ağlarının geliştirilme ve kullanılma amacı ise veri ilişkilendirme, optimizasyon, tanıma, sınıflandırma ve geleceğe yönelik tahminler yapmaktır. Bu işlemler temel cebir yöntemleri ile yapılması kolay olmadığı için matematiksel olarak yapılabilmektedir. Bu nedenle yapay sinir ağları birçok alanda aktif olarak kullanılmaktadır.

Yapay sinir ağların yapısı insan sinir sisteminden temel alınarak oluşturulmuştur. Biyolojik sinir sisteminin temeli olan sinir hücresinin yapısı dört ana bölümden oluşmaktadır; çekirdek, akson, dendrit, ve bağlantı. Dendritler nöronların sınır kısmında bulunan ve bitki kökü görüntüsüne sahip olan bir yapısı bulunmaktadır. Dendritlerin amacı komşu sinir hücrelerinden gelen sinyalleri çekirdeğe göndermektir. Çekirdek ise dendritten gelen sinyalleri toplayarak aksone iletmektedir. Akson ise toplanan sinyalleri işleyerek nöronun diğer kısmında bulunan

bağlantılara iletmektedir. Bağlantılar da yeni oluşan sinyalleri hücrelere iletmektedir. Yapay sinir ağların çalışma mantığı biyolojik sinir hücreleri gibidir.

İ. Çayıroğlu [12] bir yapay sinir hücresinin beş bölümden oluştuğunu açıklamaktadır. Bunlar;

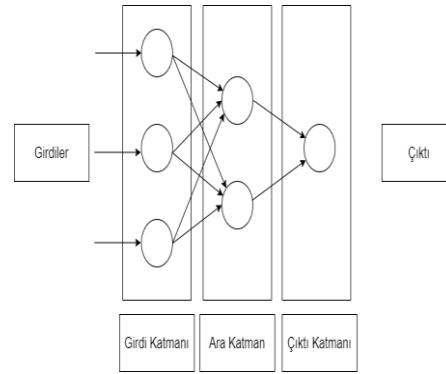
Girdiler

Ağırlıklar

Birleştirme Fonksiyonu (Toplama Fonksiyonu)

Loss (Kayıp) ve Aktivasyon Fonksiyonu

Çıktılar



Şekil 1. Yapay Sinir Ağı

Bir nöron kendisine gelen sinyalleri, bağlantılı olduğu nöronların ağırlıkları ile çarparak toplar ve bu toplam değerine varsa bias terimini de ekleyerek elde edilen sonucu tanımlanmış aktivasyon fonksiyonuna iletir. Aşağıdaki denklemde yapay sinir ağlarının genel formülü verilmiştir.

$$y = w * x + b \quad (1)$$

### 2.1. Girdiler

Girdiler sinir hücrelerine gelen bilgilerdir ve yapay sinir hücrelerine ilk olarak dış dünyadan gelir daha sonrasında diğer katmanlardaki hücrelere iletilir.

### 2.2. Ağırlıklar

Yapay sinir ağlarındaki hücrelere gelen girdiler geldikleri bağlantıların ağırlığıyla çarpıldıktan

sonra ulaşmaktadır. Bu yöntemle girdilerin çıktı verileri üzerindeki tesiri ayarlanabilmektedir. Girdilerle çarpılan ağırlık değerleri pozitif veya negatif olabileceği gibi sıfır da olabilir. Ağırlığın sıfır olması durumunda girdilerin çıktılar üzerinde hiçbir tesiri bulunmamaktadır.

### 2.3. Toplama fonksiyonu


Toplama metodu ağırlıklarla çarpılmış olarak gelen girdi verilerinin toplamını alarak, o nöronun net girdisini hesaplayan metottur. Bir modelde kullanılacak olan optimum toplama metodunu belirleyen bir sistem bulunmamaktadır. Literatürde çoğunlukla test edilerek ve karşılaştırma yapılarak toplama fonksiyonu seçilmektedir.

### 2.4. Aktivasyon ve loss fonksiyonu

Aktivasyon metodu sinir düğümlerine ulaşan girdiyi işleyerek nöronun çıktısını belirleyen fonksiyondur. Transfer fonksiyonu olarak da adlandırılabilir. Aktivasyon metodu çoğunlukla lineer olmayan bir fonksiyon seçilmektedir. Bunun nedeni yapay sinir ağlarının çoğu zaman doğrusal olmayışından kaynaklanmaktadır [12]. Aktivasyon metodu belirlenirken önem verilmesi gereken ayrı bir nokta ise fonksiyona ait türevinin kolay alınabilir olmasıdır. Türevin kolay alınabilir olması hem işlem hızını arttırmaktadır hem de bilgisayarları daha az yormaktadır. Son günlerde çok katmanlı sinir ağ modellerinde genel olarak kullanılan aktivasyon fonksiyonu Sigmoid fonksiyonudur. Aşağıda temel olarak kullanılan aktivasyon fonksiyonları hakkında bilgi verilmiştir.

#### 2.4.1. Basamak fonksiyonu

Basamak fonksiyonu binary değer alan bir fonksiyondur. Bu nedenle sınıflandırma amacıyla kullanılır ve genellikle çıkış katmanlarında tercih edilir. Gizli katmanlarda türevi sıfır olduğu için kullanılmamaktadır. Gelen net girdinin sıfırdan büyük veya düşük olması durumuna göre nöronun sonucu 1 ya da 0 değerini alır.




Şekil 2. Step fonksiyon ve türevi

$$f(x) = \begin{cases} 1 & \text{eğer } x > 0 \\ 0 & \text{eğer } x \leq 0 \end{cases} \quad (2)$$

#### 2.4.2. Doğrusal (lineer) fonksiyon

Doğrusal problemleri çözmek amacıyla modelin doğasına aykırı olmayan bir aktivasyon fonksiyonu seçilebilir. Doğrusal fonksiyondan gelen sonuç, sabit bir katsayı ile çarpılarak nöronun çıktısı olarak belirlenir [2-12,20]. Fakat doğrusal fonksiyonun dezavantajı bulunmaktadır. Fonksiyonun türevi sabittir. Türevi sabit çıkan sistemlerde öğrenme yoktur.



Şekil 3. Lineer fonksiyon ve türevi


$$f(x) = x * c \quad (3)$$

#### 2.4.3. Sigmoid fonksiyonu

Sigmoid metodu kesikli olmayan ve türevi kolay hesaplanabilir bir fonksiyondur. Lineer olmayan ve sınıflandırma uygulamalarında en sık kullanılan fonksiyondur. Sigmoid

fonksiyonu her girdi verisi göre 0 ve 1 arasında sonuç üretmektedir [2-12,20].

İyi bir sınıflayıcı fonksiyon olmasına rağmen ufak bir dezavantajı da bulunmaktadır. Fonksiyon grafiğinde,  $f(x)$  değerleri  $x$ 'teki değişimlere çok az tepki vermektedir. Bu bölgelerde türev değerleri çok düşük olur ve 0'a yakınsar. Türevin sifıra yakınsaması öğrenmeyi durdurmaktadır.




Şekil 4. Sigmoid fonksiyon ve türevi

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

#### 2.4.4. Tanjant hiperbolik fonksiyon

Hiperbolik tanjant metodu, sigmoid metoduna benzeyen bir fonksiyon türüdür. Sigmoid metodunda çıkış sonuçları 0 ile 1 arasında değişirken hiperbolik tanjant metodunda çıkış sonuçları -1 ile 1 arasında yer almaktadır [2-12,20]. Bu fonksiyonunun sigmoid fonksiyonuna göre avantajlı olduğu durum türev sonucudur.




Şekil 5. Hiperbolik tanjant ve türevi

$$f(x) = \frac{e^x + e^{-x}}{e^x - e^{-x}} \quad (5)$$

#### 2.4.5. ReLU (Rectified Linear Unit) fonksiyonu

Fonksiyona gelen verilerin sifıra küçük eşit olması durumunda sonuç 0, sifır ile bir arasında olması durumunda ise kendisini veren sonuçları üretir. Sıfırdan küçük değerlerde sonucun 0 olması ağı hızlı çalıştırmaktadır. Hesaplama yükünün sigmoid ve hiperbolik tanjant fonksiyonlarına göre daha az olması çok katmanlı ağlarda daha fazla tercih edilebilir olmasına olanak sağlamaktadır.



Şekil 6. RELU fonksiyonu ve türevi

$$f(x) = \begin{cases} x & \text{eğer } x > 0 \\ 0 & \text{eğer } x \leq 0 \end{cases} \quad (6)$$

#### 2.4.6. Softmax fonksiyonu

Sigmoid fonksiyonu ile benzer yapıdadır ve aynı amaçla kullanılır. Sınıflandırma problemlerinde kullanıldığı zaman oldukça iyi bir performans sergiler. En önemli farkı ikiden fazla sınıflandırma gerektiren durumlarda yapay sinir ağlarının çıkış katmanında kullanılmaktadır. Girdinin belirli sınıfa ait olma olasılığını 0 ile 1 arasında değerler üreterek belirlenmesini sağlamaktadır. Yani olasılıksal bir sonuç geriye döndürülmektedir. En yüksek olasılığa sahip sınıf sonuç olarak dönmektedir.

Loss fonksiyonu yapay sinir ağlarına ait bir modelin hata oranını ve aynı zamanda başarısını ölçen fonksiyondur [13]. Loss


fonksiyonu genel olarak çıkış katmanında tanımlanmaktadır. Bu fonksiyonun temel olarak yaptığı iş modelin yaptığı tahminin, gerçek değerden ne kadar farklı olduğunu hesaplamaktır. Gerçek değer ile tahmin değerinin aynı olduğu durumda loss değeri 0 olacaktır. İyi bir modele ait loss değeri 0'a yakınsayan bir değer olmalıdır.

### 2.5.Hücrenin Çıktısı

Hücreye ait aktivasyon fonksiyonu sonucu nöronun çıktı sonucu olmaktadır. Çıktı değeri gerekirse yapay sinir ağlarının sonuç değeri olarak kullanılır ya da diğer katmanlara girdi olarak iletilerek tekrar ağı içinde kullanılır.

Yapay sinir ağları katmanlı bir yapıya sahiptir. Birçok ara katmanı olabileceği gibi giriş katmanı direkt çıkış katmanına da bağlanabilir. Yapay sinir ağlarında derinlik genelde ara katman sayısı ile ölçülmektedir. Her katmanın kendine ait nöron ve aktivasyon fonksiyonları bulunmaktadır. Sinir ağları genellikle 3 adet ayrı katmandan oluşmaktadır. Bu katmanlar; Giriş Katmanı, Gizli (Ara) Katman ve Çıkış Katmanıdır.

Giriş katmanı; bağımsız değişkenlere ait giriş (başlangıç) verilerinin geldiği katmandır. Bu katmanda giriş sayısı (bağımsız değişken) kadar hücre bulunmaktadır.



Şekil 7. Yapay sinir ağlarına ait katmanlar

Gizli Katman; Giriş katmanı ile çıkış katmanı arasındaki katmanlardır. Katman sayısı ve üzerindeki nöron sayısı problemde probleme değişebilmektedir. Katman sayısı hesaplama karmaşıklığına etki eden bir faktördür ve çok olması durumunda hesaplama süresini de arttırmış olur. Karmaşık problemlerde genelde katman sayıları ve katmanlardaki nöron sayıları fazladır. Bu durum çalışma zamanını negatif etkilese de doğru kurulmuş bir ağda başarı oranını arttırmaktadır [2-12,29].

Çıkış Katmanı; ara katmandan ulaşan veriyi hesaplamakta ve model doğrultusunda üretilen veriyi sonuç olarak döndürülmesini sağlayan katmandır (Şekil 7).

### 3. Veri Seti

Projede kullanılan veri seti EPİAŞ'ın sitesinden indirilerek oluşturulmuştur. Kaynaklar bölümünde her kolon için link paylaşılmıştır. Veri setindeki bağımsız değişkenler literatür araştırması kapsamında okunan makalelerden baz alınarak seçilmiştir. Veri setinin güncel olması adına 01.01.2019 – 31.12.2019 tarihleri arasındaki her saat için veri bulunmaktadır. Veri setinde bulunan değişkenler aşağıdaki gibidir:

Tarih: 01.01.2019

Saat: 00.00

PTF (TL/MWh): 100,38

(01.01.2019 saat 00.00 'deki PTF fiyatı)

Bir Gün Önceki PTF(TL/MWh) : 275

(31.12.2018 saat 00.00 'deki PTF fiyatı)

Bir Hafta Önceki PTF(TL/MWh) : 258,43 (25.12.2018 saat 00.00 'deki PTF fiyatı)

Üretim Miktarı (MWh) : 27.326,18

(01.01.2019 saat 00.00 'deki Üretilen enerji kwh)

Tüketim Miktarı(MWh) : 27.399,64

(01.01.2019 saat 00.00 'deki Tüketilen enerji kwh)

Gaz Referans Fiyatı: 1.586,87

(01.01.2019 tarihindeki Doğal gaz birim fiyatı)

Gün Sınıfı: Güne ait nominal değer.

(1-Pazartesi, 2-Salı , ... , 7-Pazar )

Ramazan Ayı: 0-1

(01.01.2019 günü ramazan ayına ait bir gün mü?)


Bayram: 0-1

(01.01.2019 günü bayram ayına ait bir gün mü?)

Veri setinde yukarıdaki kolonları içeren 8760 satır veri bulunmaktadır. PTF kolonunda tek tük kayıp veriler bulunmaktadır. Her kolona ait maksimum, minimum ve ortalama değerler aşağıdadır.

PTF\_max = 500  
 PTF\_min = 0  
 PTF\_mean = 260.320  
 DPTF\_max = 500  
 DPTF\_min = 0  
 DTF\_mean = 260.320  
 HPTF\_max = 500  
 HPTF\_min = 0  
 HPTF\_mean = 260.320  
 Üretim\_max = 45.291,06  
 Üretim\_min = 18.115,35  
 Üretim\_mean = 33.083,983  
 Tüketim\_max = 45.346,05  
 Tüketim\_min = 18.203,66  
 Tüketim\_mean = 33.156,041  
 GRF\_max = 1.675,01  
 GRF\_min = 1.399,18  
 GRF\_mean = 1.479,856

Veri setindeki PTF değerleri ağırlıklı olarak 300-400 arasında yer almaktadır. Bu durum veri setinin normal dağılıma uygun olmadığını göstermektedir. Gece yarısından sonra açıklanan PTF değerleri diğer örneklere göre çok düşük kalmaktadır. Bu durum nedeniyle PTF değerlerinde aykırı elemanlar oluşmuştur. Veri ön işleme kısmında bu değerler veri setinden çıkartılarak devam edilmiştir (Şekil 8).



Şekil 8. PTF Değerlerinin Dağılımı

#### 4.Uygulama

Bu bölümde projede yapılan çalışma detaylandırılmıştır. Projede ilk önce veri seti içerisindeki her alan dataframelere ayrılmıştır. Daha sonrasında veri ön işleme çalışmalarına başlanmıştır. PTF alanı bağımlı değişken diğer alanlar ise bağımsız değişkendir.

##### 4.1.Verİ Ön İşleme Aşaması

Öncelikle sayısal değer içeren her alan için kayıp değer kontrolü yapılmıştır. Sıfır olan örnekler tespit edilip bu örnekler kendi kolonundaki değişkenlerine ait ortalama değer ile doldurulmuştur.

Daha sonrasında ptf alanının dağılımı incelenmiş ve normal dağılımdan gelmediği tespit edilmiştir. Ardından aykırı değer kontrolü yapılmıştır. Aykırı değer kontrolünde uç değerler yöntemi kullanılmıştır. Birinci çeyrek değer ve üçüncü çeyrek değer elde edilip farkı hesaplanmıştır. Ardından alt ve üst değer hesaplanmıştır. Alt değer ve üst değer arasında kalmayan her ptf değeri ve bu değere ait bağımsız değişkenler veri setinden çıkarılmıştır.

$$IQR = Q3 - Q1 \quad (7)$$

$$Alt \ Değer = Q1 - 1.5 \times IQR \quad (8)$$

$$Üst \ Değer = Q1 + 1.5 \times IQR \quad (9)$$

Yapay sinir ağları 0 ile 1 arasındaki değerleri öğrenmede daha başarılı olduğu gözlemlenmiştir. Bu nedenle sayısal değer içeren her kolon ölçeklendirilmiştir. Ölçeklendirme işleminde her kolonun kendine ait maksimum minimum değerleri kullanılmıştır. Aşağıdaki formül ile değerler sıfır ve bir aralığına dönüştürülmüştür.

$$f(x) = \frac{x - min}{max - min} \quad (10)$$

Bu işlemlerden sonra encoding işlemleri yapılmıştır. Tarih, Saat ve Gün sınıfı sayısal değerden çok sınıf değeri için kullanılmaktadır. Bu yüzden bu alanlara encoding işlemi uygulanmıştır. Tarih değerleri encoding işlemi

sonucunda 12 kolon, saat kolunu encoding sonunda 24 kolon ve gün sınıfı ise 7 kolona çıkmıştır.

Bu işlemle birlikte veri ön işleme aşamaları bitmiştir. Bu işlemler sonunda toplamda 50 adet bağımsız değişkene sahip bir veri oluşmuştur. Bu veri seti eğitim ve test olmak üzere iki kısma ayrılmıştır. Veri setinin % 20'si test % 80'i ise eğitim için kullanılmıştır.

#### 4.2. Model Uygulamaları

Veri ön işleme aşamalarından sonra yapay sinir ağ modelleri kurulmuştur. Çalışmada 5 farklı model test edilmiştir. Modellerin ara katman ve nöron sayıları değiştirilerek en başarılı olan model seçilmiştir.

İlk modelde 6 katman bulunmaktadır. Giriş katmanında 50 nöron kullanılmıştır. Diğer katmanlarda nöron sayısı yarıya bölünerek ilerletilmiştir. Bu katmanlarda aktivasyon enerjisi olarak relu kullanılmıştır. Çıkış katmanında ise 1 nöron bulunmakta ve aktivasyon fonksiyonu lineer'dir.

İkinci modelde 11 katman bulunmaktadır. Giriş katmanında 100 nöron kullanılmıştır. Diğer katmanlarda nöron sayısı onar onar azaltılarak oluşturulmuştur. Bu katmanlarda aktivasyon enerjisi olarak relu kullanılmıştır. Çıkış katmanında ise 1 nöron bulunmakta ve aktivasyon fonksiyonu lineer'dir.

Üçüncü modelde 8 katman bulunmaktadır ve görünüm olarak altıgeni anımsatmaktadır. Giriş katmanında 50 nöron kullanılmıştır. 2. ve 6. katmanlarda nöron sayısı 75'tir. 3. 4. ve 5. katmanlarda 100 nöron kullanılmıştır. Bu katmanlarda aktivasyon enerjisi olarak relu kullanılmıştır. Çıkış katmanında ise 1 nöron bulunmakta ve aktivasyon fonksiyonu lineer'dir. Dördüncü modelde 4 katman bulunmaktadır.

Giriş katmanında 50 nöron kullanılmıştır. Diğer katmanlarda nöron sayısı karekök alınarak ilerletilmiştir. Bu katmanlarda aktivasyon

enerjisi olarak relu kullanılmıştır. Çıkış katmanında ise 1 nöron bulunmakta ve aktivasyon fonksiyonu lineer'dir. Son modelde ise 7 katman bulunmaktadır ve görünüm olarak normal dağılım grafiğini anımsatmaktadır. Giriş ve çıkış katmanında 1 nöron bulunmaktadır. 2. ve 6. katmanda 10 adet nöron bulunmaktadır. 3. ve 5. katmanda 35 adet nöron bulunmaktadır. 4. katmanda 50 adet nöron bulunmaktadır. Çıkış katmanında aktivasyon fonksiyonu lineer diğer katmanlarda relu fonksiyonu kullanılmıştır (Tablo 1).

Tablo1. Model Açıklaması

Model	Katman	Nöron Sayıları	Aktivasyon Enerjisi
Model 1	6	50-25-12-5-2-1	Relu
Model 2	11	100-90-80-70-60-50-40-30-20-10-1	Relu
Model 3	8	50-75-100-100-100-75-50-1	Relu
Model 4	4	50-7-2-1	Relu
Model 5	7	1-10-35-50-35-10-1	Relu

Projede performans kıstası olarak iki metot kullanılmıştır. Bunlardan ilki ortalama karekök hata (MSE) ve ortalama mutlak hatadır (MAE).

Ortalama mutlak hata iki farklı değişken arasındaki farkın ölçüsüdür. MAE, gerçek değer ile tahmin edilen değer arasındaki ortalama dikey mesafedir. MAE değeri sifra yakınsayan modeller daha iyi performans gösterir. N örnek sayısını, e ise gerçek değer ile tahmini değer arasındaki farkı ifade etmektedir.

$$f(x) = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (11)$$

$$f(x) = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (12)$$




MSE, bir makine öğrenmesi modelinin, tahminleme yapan modelin performansını ölçmede kullanılır ve her zaman pozitif

değerlidir. MSE değeri sıfıra yakın olan modellerin daha iyi bir performans gösterdiği söylenebilir.


## 5.Bulgular

Bu bölümde daha önce bahsedilen 5 farklı modelin sonuçlarına ve neden-sonuç ilişkisine yer verilmiştir. Grafikteki mavi noktalar tahminleri kırmızı noktalar ise gerçek değerleri temsil etmektedir.

Birinci modelde MAE 0.07 ve MSE 0.10 bulunmuştur. Model 100 adım ilerletilmiştir. İlk adımda kayıp 0.245'ten başlamış ve son adımda 0.087'ye kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 362 değer bulunmaktadır. 1.Model 0,8 seviyesindeki ptf değerlerini tahmin etmede başarılı olup uç değerlerde yetersiz kalmaktadır. İkinci modelde MAE 0.07 ve MSE 0.11 bulunmuştur. Model 100 adım ilerletilmiştir. İlk adımda kayıp 0.218'den başlamış ve son adımda 0.039'a kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 317 değer bulunmaktadır. Bu model 1. modele göre daha başarılıdır. 0,8 ve 0,9 seviyesindeki ptf değerlerini daha başarılı bir şekilde tahmin etmektedir. Nispeten uç değerlerde daha başarılıdır (Şekil 9).




Şekil 9. Model 1 sonuç



Şekil 10. Model 2 sonuç


İlk adımda kayıp 0.218'den başlamış ve son adımda 0.039'a kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 317 değer bulunmaktadır. Bu model 1. modele göre daha başarılıdır. 0,8 ve 0,9 seviyesindeki ptf değerlerini daha başarılı bir şekilde tahmin etmektedir. Nispeten uç değerlerde daha başarılıdır (Şekil 10).



Şekil 11. Model 3 sonuç


Üçüncü modelde MAE 0.07 ve MSE 0.11 bulunmuştur. Model 100 adım ilerletilmiştir. İlk adımda kayıp 0.987'den başlamış ve son adımda 0.005'e kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 311 değer bulunmaktadır. 0,7 ve 0,9 seviyesindeki ptf değerleri daha başarılı bir şekilde tahmin etmektedir. Aynı zamanda uç değerlerde en başarılı model bu modeldir (Şekil 11).

Dördüncü modelde MAE 0.07 ve MSE 0.10 bulunmuştur. Model 100 adım ilerletilmiştir. İlk adımda kayıp 0.206'dan başlamış ve son adımda 0.009'a kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 335 değer bulunmaktadır. Uç değer tahminlerinde başarısız bir performans sergilemektedir (Şekil 12).



Şekil 12. Model 4 sonuç

Son modelde MAE 0.07 ve MSE 0.11 bulunmuştur. Model 100 adım ilerletilmiştir. İlk adımda kayıp 0.223'ten başlamış ve son adımda 0.010'a kadar düşmüştür. Tahmin ile gerçek değer arasındaki farkı 0.10'dan büyük olan 365 değer bulunmaktadır. 5. Model 0,9 yakınsayan ptf değerlerini tahminlemede başarılı olurken uç değerlerde yine başarısız bir model olmuştur (Şekil 12).



Şekil 13. Model 5 sonuç

Tablo 2. Model Sonuçları

Model	İlk Loss Değeri	Son Loss Değeri	0.10'dan Büyük Değer	MAE	MSE
Model 1	0.245	0.087	362	0.07	0.10
Model 2	0.218	0.039	317	0.07	0.11
Model 3	0.987	0.005	311	0.07	0.11
Model 4	0.206	0.009	335	0.07	0.11
Model 5	0.223	0.010	365	0.07	0.10

Katman ve nöron sayıları dikkate alındığında gizli katmanlardaki nöron sayısı tahmin kalitesini etkilemektedir (Tablo 2). 3. ve 5. modelde 0,7 ve 0,9 seviyesinde değerlerin tahminlemesi daha tutarlıdır. Bunun yanı sıra nöron sayılarındaki parabolik azalış öğrenme kalitesini azaltmaktadır.

Model 4'te karesel olarak bir azalma varken model 1'de yarı yarıya azalma bulunmaktadır. Bu 2 modelde de 0,7 – 0,9 değerleri model 2'ye nazaran daha kötüdür. Model 3 diğer modellere göre görünüm olarak daha simetrik bir yapıdadır.

Diğer dört model üçgen görünümünde iken model 3 altıgen bir yapıya sahiptir. Bu durum öğrenme ve tahminleme performansını etkilemiş olarak görünmektedir. Özellikle model 3 uç değerleri tahminlemede diğer dört modele göre üstün durumdadır.

Modellerin sonuçları birbirine çok yakındır. Bariz bir fark bulunmamaktadır. Fakat yine de üç numaralı model diğer modellerden ayrılmaktadır.

Öğrenme kaybı arasındaki gelişim en çok bu modelde bulunmaktadır. Bunun yanı sıra gerçek değer ile tahmin edilen değer arasındaki farklar göz önüne alındığında 0.10'dan büyük olan değerler bu modelde daha az bulunmaktadır.

Bu özelliklerinden dolayı model 3 diğerlerinden ayrılmıştır. Model için sahip olduğu toplam nöron sayısı model iki ile eşit olup diğer modellere göre daha fazladır. Bu durum nöron sayısının katmanlardaki dağılımı öğrenmede etkili olduğunu göstermektedir.

## 6.Sonuç ve Öneriler

Bu çalışmada, gün öncesi piyasa takas fiyatının tahminleme çalışması yapılmıştır. Tahminleme çalışmasında yapay sinir ağları kullanılmıştır. Çalışmada ptf tahmini yapılırken bağımsız değişken olarak tarih, saat, bir gün önceki ptf değeri, bir hafta önceki ptf değeri, toplam tüketim miktarı, toplam üretim miktarı, gaz

referans fiyatı, gün sınıfı, bayram ve ramazan günleri kullanılmıştır.

Toplanan veri içerisinde 01.01.2019 - 31.12.2019 tarihleri arasındaki her saat için değerler bulunmaktadır. Veri seti ön işlemeden geçirilmiş daha sonrasında eğitim ve test olmak üzere iki parçaya ayrılmıştır. Tahminleme çalışmasında beş farklı model oluşturulmuştur.

Bu modeller katman sayısı ve içerdikleri nöron sayılarına göre farklılıklar göstermektedir. Çalışmada performans kıstası olarak MAE ve MSE kullanılmıştır.

MSA, MSE ve kayıp fonksiyonları incelendiğinde benzer sonuçlar görülmektedir. Fakat üç numaralı model bilgi kaybı fonksiyonu ve gerçek değer ile tahmini değer arasındaki mutlak farklar göz önüne alındığında 0.10'dan büyük değerler daha az olmaktadır. Bu nedenle model 3 en iyi model seçilmiştir.

Gelecek çalışma hakkında 2 adet düşünce bulunmaktadır. Bunlardan ilki ptf dağılımında az olan verilerin artırılmasıdır. Model sonuçları incelendiğinde ptf değerlerinin bir kısmı 0,4 seviyesinde toplandığı görülmektedir.

Modeller bu seviyeyi tahminlemede zorlanmaktadır. Bunun nedeni benzer verilerin az olmasıdır. Bu örnekteki veriler artırıldığında tahmin sonuçları da daha sağlıklı olacaktır. Diğer düşünce ise bağımsız değişken sayısının artırılmasıdır. Literatür araştırması yapılırken elektrik tüketiminde sıcaklık, basınç ve nem değerlerinin de etkili olduğu belirtilmiştir.

01.01.2019 - 31.12.2019 tarihleri arasında ve her saat için bu değerler veri setine eklendiğinde tahmin değerleri kuvvetlenecektir. İklim ve basınç değerlerinin eklenmesi model 3'ün başarı oranını daha da arttıracaktır.

Bu yöntem ile gün öncesi fiyatını önceden tahminlemek enerji sektöründe bulunan firmalara ticari planlamalar açısından fayda sağlayacaktır.

## Kaynakça

- [1] Dalgın A. 2017. Türkiye Gün Öncesi Piyasası Elektrik Fiyat Tahmini, İstanbul Teknik Üniversitesi, Enerji Bilim ve Teknoloji Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.
- [2] Pençe İ., Kalkan A., Çeşmeli M. 2019. Türkiye Sanayi Elektrik Enerjisi Tüketiminin 2017-2023 dönemi için Yapay Sinir Ağları ile Tahmini. DOI: 10.31200/makuubd.538878.
- [3] Karacan H., Karacan C. 2016. Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi. DOI: 10.15317/Scitech.2016320514.
- [4] Gümüş V., Şimşek O., Soyda N., Aköz M., Yenigün K. 2016. Adana istasyonunda buharlaşmanın farklı yapay zekâ yöntemleri ile tahmini. VIII. Ulusal Hidroloji Kongresi – 2015. 310-318.
- [5] Es A., Kalender F., Hamzaçebi C. 2014. Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini. Gazi Üniv. Müh. Mim. Fak. Der. Cilt 29, No 3, 495-504, 2014.
- [6] Toker C., Korkmaz O. 2012. Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi.
- [7] Başoğlu B., Bulut M. 2016. Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. Journal of the Faculty of Engineering and Architecture of Gazi University 32:2 (2017) 575-583.
- [8] Çayır A., Yenidoğan I., Dağ H. 2018. Konutların Günlük Elektrik Güç Tüketimi Tahmini İçin Uygun Model Seçimi. Fırat Üniv. Müh. Bil. Dergisi 30(3), 15-21, 2018.
- [9] Kocadayı Y., Erkaymaz O., Uzun R. 2017. Yapay Sinir Ağları ile Tr81 Bölgesi Yıllık Elektrik Enerjisi Tüketiminin Tahmini. ISSN: 2587-0742. Bilge International Journal of Science and Technology Research 2017, 1(Special Issue): 59-64.
- [10] Hamzaçebi C., Kutay F. 2004. Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketimini 2010 Yılına Kadar Tahmini. Gazi Üniv. Müh. Mim. Fak. Der. Cilt 19, No 3, 227-233, 2004.
- [11] Çayiroğlu İ. İleri Algoritma Analizi. <http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf> ( Erişim Tarihi: 18.05.2020).
- [12] Şenocak F., Kahveci H. 2016. Gün Öncesi Piyasasında PTF Dönemsel Ağırlıklı Fiyat Ortalama Tahmini.
- [13] Çarkacı N. 2017. Derin Öğrenme Uygulamalarında Temel Kavramlar. <https://www.linkedin.com/pulse/derin-%C3%B6%C4%9Frenme-uygulamalar%C4%B1nda-temel-kavramlar-skorve-%C3%A7arkac%C4%B1> ( Erişim Tarihi: 18.05.2020).
- [14] Sinecan M., Kaya B., Yıldız Ö. 2017. Aydın İlinde İnsan Sağlığını Birincil Dereceden Etkileyen Hava Değişkenlerine Yönelik Yapay Sinir Ağı Tabanlı Erken Uyarı Modeli . DOI: 10.29109/http-gujsc-gazi-edu-tr.304938.
- [15] Yıldırım D., Cemek B., Küçüktopçu E. 2019. Bulanık Yapay Sinir Ağları ve Çok Katmanlı Yapay Sinir Ağları ile Günlük Buharlaşma Tahmini. Toprak Su Dergisi-2019. 24-31.
- [16] O.Gök, C. Yıldız, M. Şekkeli, Yapay Sinir Ağları Kullanarak Kısa Dönem Güneş Enerjisi Santrali Üretim Tahmini: Kahramanmaraş Örnek Çalışması, 2019.
- [17] Şeker A., Diri B., Balık H. 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. ISSN: 2149-4916. Gazi Mühendislik Bilimleri Dergisi 3 (3). (2017) 47-64.
- [18] Ekinci F. 2019. Ysa ve Anfis Tekniklerine Dayalı Enerji Tüketim Tahmin Yöntemlerinin Karşılaştırılması. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 7 (2019) 1029-1044.
- [19] Çevik H. 2013. Türkiye'nin Kısa Dönem Elektrik Yük Tahmini. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya.
- [20] Bıcıl İ. 2015. Elektrik Piyasasında Fiyatlandırma ve Türkiye Elektrik Piyasası Fiyat Tahmini. Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü İktisat Anabilim Dalı, Doktora Tezi, Balıkesir.
- [21] Öksüz S. 2019. Yapay Sinir Ağları ile Denizli İli Mesken Aboneleri Elektrik Tüketim Tahmini. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Denizli.
- [22] Gök A., Yıldız C., Şekkeli M. 2019. Yapay Sinir Ağları Kullanarak Kısa Dönem Güneş Enerjisi Santrali Üretim Tahmini: Kahramanmaraş Örnek Çalışması. Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi ISSN: 2667-8764 , 1(2), 186-195 , 2019
- [23] Çam S., Kılıç S. 2018. Altın Fiyatı Günlük Getirilerinin Yapay Sinir Ağları Algoritması ve Markov Zincirleri Modelleri ile Tahmini. DOI: 10.18092/ulikidince.347048 . UIİİD-IJEAS, 2018 (18. EYİ Özel Sayısı):681-694 ISSN 1307-9832
- [24] Ünal S., Çınar G., Karaman İ., Yurttakal A. 2016 . Yapay Sinir Ağları Yönetimi ile Burs Analizi. EEB 2016 Elektrik-Elektronik Ve Bilgisayar Sempozyumu 11-13 Mayıs 2016.
- [25] Boltürk E. 2013. Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Programı, Yüksek Lisans Tezi, İstanbul.
- [26] Şenol Ü., Musayev Z. 2017. Rüzgâr Enerjisinden Elektrik Üretimine Yapay Sinir Ağları İle Tahmini. Bilge Uluslararası Fen ve Teknoloji Araştırmaları Dergisi 1(1), 23-31, 2017
- [27] Biçer A. 2018. Enerji Talep Tahminine Yönelik Program Geliştirme ve Bir Bölge İçin Uygulaması. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği, Yenilebilir Enerji Sistemleri Anabilim Dalı. Yüksek Lisans Tezi. Afyon.
- [28] Aslan Y., Yaşar C., Nalbant A, 2003. Kütahya İlinin Yapay Sinir Ağları Kullanılarak Elektrik Puant Yük Tahmini . D:P:Ü Fen Bilimleri Enstitüsü Dergisi 11.Sayı, ISSN-1302-3055
- [29] Özden S., Öztürk A. 2018. Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini. DOI: 10.17671/gazibtd.404250. Bilişim Teknolojileri Dergisi, Cilt: 11, Sayı: 3, Temmuz 2018
- [30] Kılıç E., Özbacı Ü., Özçalık H. 2012. Lineer Olmayan Dinamik Sistemlerin Yapay Sinir Ağları ile Modellenmesinde MLP ve RBF Yapılarının Karşılaştırılması. ELECO '2012 Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu, 29 Kasım - 01 Aralık 2012.
- [31] Pınarbaşı M. 2009. Elektrik Enerji Sistemlerinde Talep Tahmin Yöntemleri ve Yapay Sinir Ağları

- Uygulaması. İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.
- [32] Cantürk S. 2018. Bir Rüzgâr Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Üretim Tahmini. Hacettepe Üniversitesi Temiz-Tükenmez Enerjiler Anabilim Dalı, Yüksek Lisans Tezi, Ankara
- [33] Makas Y. 2016. Yapay Sinir Ağlarıyla Hidroelektrik Enerji Üretiminin Çok Dönemli Tahmini. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 2016, C.21, S.3, s.757-772.
- [34] Veri Seti: PTF  
<https://seffaflik.epias.com.tr/transparency/piyasalar/gop/ptf.xhtml> ( Erişim Tarihi: 18.05.2020).
- [35] Veri Seti: GRF  
<https://seffaflik.epias.com.tr/transparency/dogalgaz/stp/stp-grf.xhtml> ( Erişim Tarihi: 18.05.2020).
- [36] Veri Seti: Toplam Üretim  
<https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml> ( Erişim Tarihi: 18.05.2020).
- [37] Veri Seti: Toplam Tüketim  
<https://seffaflik.epias.com.tr/transparency/tuketim/gerceklesen-tuketim/gercek-zamanli-tuketim.xhtml> ( Erişim Tarihi: 18.05.2020).