



PYTHON PROGRAMLAMA DİLİNDE REGRESYON,  
XG BOOST VE YAPAY SİNİR AĞLARI İLE ELEKTRİK BİRİM  
FİYAT TAHMİNLEMESİ

Yazılım Mühendisliği Ana Bilim Dalı

Dönem Projesi

İLKNUR CEREN COŞKUN

Y220240043

PROJE DANIŞMANI: VAHİDE BULUT

ŞUBAT 2024

## ÖZET

Günümüzde teknolojinin gelişimiyle ve ülkelerin büyümesi ile birlikte enerji ihtiyacı hızla artmaktadır. Bu artış ise üretim santrallerinin artışı ve dağıtım, perakende şirketlerinin görev ve sorumluluklarında artışa sebep olmuştur. Günlük, Haftalık ve Aylık bazda perakende şirketleri tüketim öngörülerini belirlemektedir ve taleplerini system işletmecisi EPIAŞ üzerinden tüketim talebinde bulunur. Bunun yanı sıra üretim şirketleri ise üretebileceği potansiyel elektrik tahminlemesini aynı sistem üzerinden oluşturur. Gün Öncesi Piyasasında Arz ve taleplerin eşleşmesi ile birlikte bir sonraki gün için PTF olarak adlandırılan “Piyasa Takas Fiyatı” belirlenir. Bu çalışmada Makine Öğrenmesi yöntemleri kullanılarak elektrik birim fiyatı olan PTF fiyatının tahminlemesi yapılacaktır.

Anahtar Kelimeler: Elektrik Birim Fiyatı, PTF, Elektrik Üretim, Elektrik Dağıtım, Elektrik Perakende

## **ABSTRACT**

Nowadays, with the development of technology and the growth of countries, the need for energy is increasing rapidly. This increase has led to an increase in the number of production plants and an increase in the duties and responsibilities of distribution and retail companies. Retail companies determine their consumption forecasts on a daily, weekly and monthly basis and submit their demands through the system operator EPIAŞ. In addition, production companies estimate the potential electricity they can produce through the same system. With the matching of supply and demands in the Day Ahead Market, the "Market Clearing Price", called PTF, is determined for the next day. In this study, PTF price, which is the unit price of electricity, will be estimated using Machine Learning methods.

Key Words: Electricity Unit Price, PTF, Electricity Generation, Electricity Distribution, Electricity

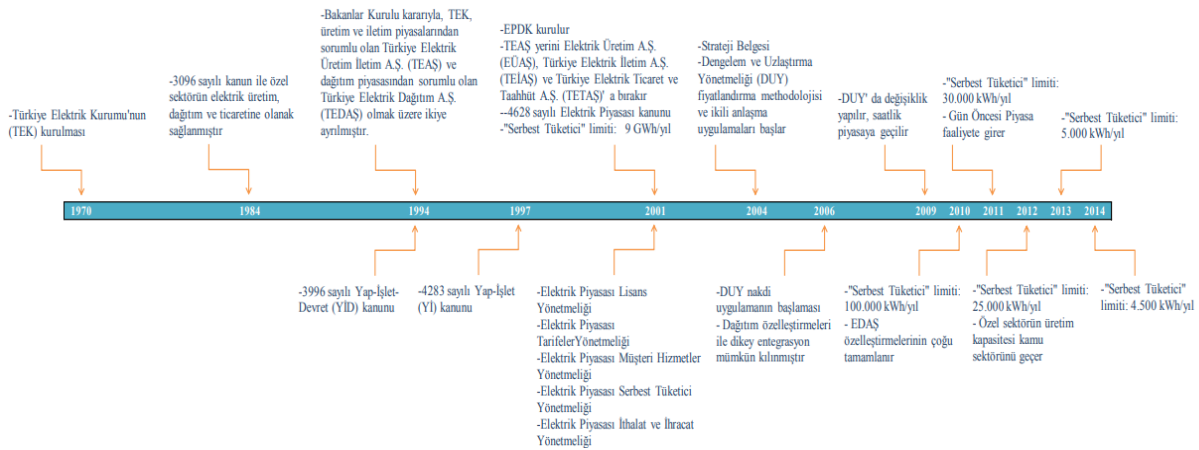
## İÇİNDEKİLER

ÖZET .....	2
ABSTRACT .....	3
1. GİRİŞ .....	5
2. METODOLOJİ .....	7
2.1 Çoklu Regresyon .....	7
2.2 XGBoost .....	8
2.3 Yapay Sinir Ağları .....	9
3. VERİ SETİ .....	10
4. UYGULAMA VE SONUÇ .....	11
REFERANSLAR .....	14

## 1. GİRİŞ

Türkiye'de elektrik piyasasının değişimi, son yıllarda önemli gelişmelere tanıklık etmiştir. Başlangıçta, kamu tarafından kontrol edilen ve tekelleşmiş bir yapıya sahip olan sektör, sürdürülebilirlik sorunları, verimlilik eksiklikleri ve rekabetin azlığı gibi zorluklarla karşı karşıya kalmıştır. [1]

Türkiyede elektrik sektöründeki yapısal değişiklik 2001 yılında Elektrik Piyasası Kanunu'nun Kabul edilmesiyle başlamıştır. Bu dönüşüm ile birlikte sektördeki özelleştirme faaliyetleri hız artmış, rekabet teşvik edilmiş ve bağımsız düzenleyici kurumlar kurulmuştur.[1] Elektrik piyasasının takas fiyatı, enerji piyasalarındaki elektrik tüketimi ve üretimi arasındaki dengenin sağlanmasında kritik bir rol oynar ve genellikle spot piyasalarda belirlenir. Bu fiyat, çeşitli etmenler tarafından etkilenen dinamik bir yapıya sahiptir. Piyasada anlık talep ve arz koşulları, tüketim ve üretim kapasiteleri, iletim altyapısı durumu, enerji talebinin zaman içindeki değişimleri gibi ana faktörler, takas fiyatının belirlenmesinde belirleyici rol oynar. Bu bağlamda, piyasa işletme şirketleri piyasadaki dengeyi sağlamak ve adil bir fiyat oluşumunu temin etmek adına çeşitli önlemler alırlar. Bu önlemler arasında, rezerv kapasitesi kullanımı, fiyat sınırları belirleme ve dengesizlik fiyatları uygulama gibi yöntemler bulunmaktadır. Sonuç olarak, elektrik piyasası takas fiyatı, enerji piyasasının işleyişinde merkezi bir rol oynar ve piyasadaki tüketici ve üretici davranışlarını etkiler. [2]



Şekil 1: Türkiye elektrik piyasası regülasyon süreci [3]

Günlük olarak kullanılan elektrik enerjisi, 2-15 yıl gibi uzun vadeli santral yatırımlarının hayata geçirilmesi ile üretilmektedir. Yatırımcı, yatırım kararından sonra, yakıt anlaşması tesis etmekte ve günümüzden 1 yıl öncesinde bakım planı ve yakıt alımını yapmaktadır. Yatırımcının bu ihtiyaçlarına cevap veren ve uzun vadede arz güvenliği açısından yeni üretim yatırımlarını teşvik edecek, fiyat istikrarı ve uzun vadeli fiziki veya finansal ikili anlaşmaların yapıldığı “ikili anlaşmalar piyasası” ve “vadeli işlemler (türev) piyasası”, piyasa tasarımının temel parçalarıdır. Kısa vadeli piyasa mekanizması, ikili anlaşmaları tamamlayıcı nitelikte olup, dengeleme mekanizması olarak ta adlandırılmaktadır. Kısa vadeli piyasa mekanizması, gün öncesi piyasası ve dengeleme piyasasını kapsamaktadır [4]. Türkiye elektrik piyasası yapısı Şekil 2’de gösterilmiştir.



Şekil 2: Türkiye elektrik piyasası piyasası[3]

Türkiye elektrik piyasasında yer alan Gün Öncesi Planlama kapsamında Piyasa Takas Fiyatının hesaplanması ve talimat alacak olan tekliflerin belirlenmesi elektronik ortamda bir optimizasyon aracı kullanılarak ve manuel müdahale olmaksızın gerçekleştirilir. Optimizasyon aracının temel çalışma prensibi, sistemi her bir gün için 24 saatin toplamını göz önünde bulundurarak en düşük maliyetle en etkili şekilde dengeye getirerek, belirlenen üretim ve sistem kısıtları dahilinde, günün her saati için kabul edilecek teklif setinin belirlenmesini sağlamaktır [5]


## 2. METODOLOJİ

Makine öğrenmesi, bilgisayar sistemlerinin algoritmalar ve istatistiksel modeller aracılığıyla veri analizi yaparak belirli bir görevi gerçekleştirmek için otomatik olarak öğrenme yeteneğine sahip olduğu bir yapay zeka alt dalıdır. Bu disiplin, bilgisayarların deneyimlerinden öğrenmelerine ve belirli bir görevde performanslarını zamanla artırmalarına olanak tanır. Makine öğrenmesi, veri madenciliği, desen tanıma, doğal dil işleme ve yapay zeka gibi birçok alanda kullanılmaktadır. [6]

Bu proje çalışması esnasında Makine Öğrenmesi sınıflandırma yöntemlerinden olan Regresyon, XGBoost ve Yapay Sinir Ağları modelleri yardımıyla veri seti incelenecektir.

### 2.1 Çoklu Regresyon

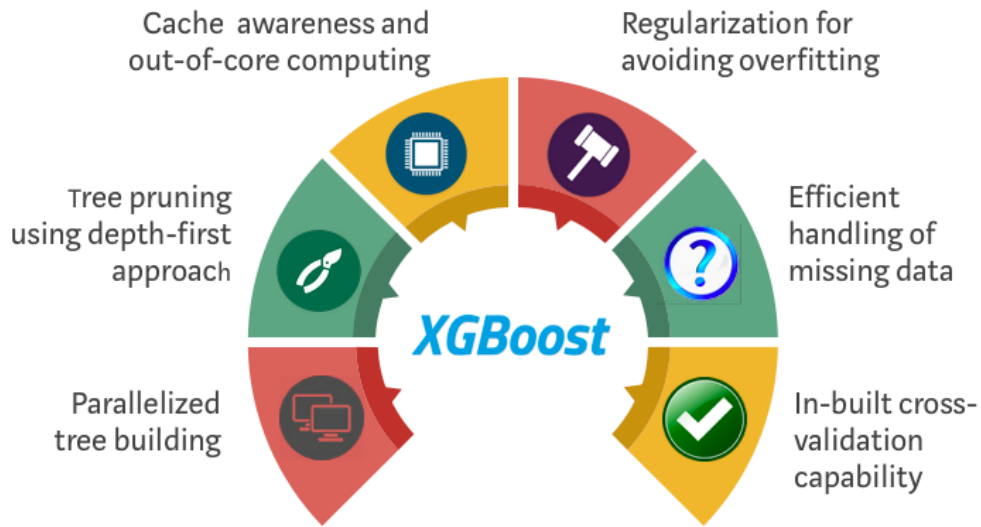
Çoklu regresyon, istatistiksel ve makine öğrenmesi alanlarında kullanılan bir analiz yöntemidir. Bu yöntem, bağımlı bir değişkenin birden fazla bağımsız değişkenle ilişkisini modellemek için kullanılır. Çoklu regresyon analizi, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini tahmin etmek, bu etkilerin önemini değerlendirmek ve modelin genel performansını değerlendirmek amacıyla kullanılır. Bu analiz yöntemi, özellikle karmaşık ilişkilerin olduğu veri setlerinde kullanılarak gelecekteki değerleri tahmin etme veya değişkenler arasındaki ilişkileri anlama sürecinde yardımcı olur.[6]



Şekil 3: Çoklu regresyon modeli[9]

## 2.2 XGBoost

XGBoost gelişimi, 2016 yılında Tianqi Chen ve Carlos Guestrin tarafından geliştirilen bir makine öğrenimi algoritması olarak başladı. Bu algoritma, gradient boosting yöntemlerinin bir türü olarak karşımıza çıktı. Geleneksel gradient boosting yöntemlerinin aksine, XGBoost, hesaplama verimliliği, modelin genel performansı ve ölçeklenebilirlik açısından önemli gelişmeler sunuyordu. [7]




Şekil 4: XGBoost Modeli [10]

XG Boost'un gelişimi, karar ağaçlarını bir araya getirerek karmaşık ilişkileri modelleme yeteneği üzerine odaklanmıştır. Bu, hata fonksiyonunun gradyanını minimize ederek ardışık olarak güçlü tahminler elde etmek için zayıf öğrenenleri birleştirmek suretiyle gerçekleştirilir. Ayrıca, XGBoost'un paralel hesaplama yetenekleri ve hızlı eğitim süreleri, özellikle büyük veri setlerinde etkili bir şekilde kullanılmasını sağlamıştır.[7]

XGBoost, başlangıçta özellikle yapısal olmayan veri setlerinde ve endüstriyel uygulamalarda kullanılmaya başlandı. Ancak, hızlı bir şekilde popülerlik kazanarak, birçok makine öğrenimi yarışmasında başarılı sonuçlar elde edildi ve endüstriyel alanda geniş bir kullanıcı kitlesi tarafından benimsendi. Geliştiriciler, kullanıcı geri bildirimlerini dikkate alarak algoritmanın



performansını ve işlevselliğini sürekli olarak iyileştirmeye devam etmektedirler.



Şekil 5: XGBoost Modeli [11]

### 2.3 Yapay Sinir Ağları


Yapay sinir ağları (YSA'lar), biyolojik sinir sistemlerinden esinlenen, karmaşık işlevleri öğrenmek ve genelleştirmek için kullanılan bir makine öğrenimi modelidir. Yapay sinir ağlarının gelişimi, 1940'larda McCulloch-Pitts modeliyle başlamıştır. Bu model, biyolojik sinir hücrelerinin basit birer matematiksel modelini sunarak sinir ağlarının temel prensiplerini tanımlamıştır.

Bunu takiben, 1950'lerde ve 1960'larda Frank Rosenblatt'ın Perceptron algoritması ve adaptif lineer elemanlar gibi erken yapay sinir ağı modelleri geliştirildi. Ancak, bu erken dönem modelleri tek katmanlı yapıya sahipti ve karmaşık problemleri çözmekte sınırlıydı.

Yapay sinir ağlarının modern gelişimi, 1980'lerin sonlarından itibaren artan işlem gücü ve veri miktarıyla birlikte hız kazandı. Özellikle, geri yayılım algoritması gibi yeni eğitim yöntemleri ve çok katmanlı yapıdaki derin öğrenme modellerinin geliştirilmesi, yapay sinir ağlarının derinlemesine ve karmaşık problemleri çözme yeteneğini artırdı.

Yapay sinir ağlarının gelişimi, özellikle 2010'larda büyük bir ivme kazandı. Bu dönemde, derin öğrenme yöntemleri, büyük veri setlerinden otomatik özellik öğrenme yeteneği ve daha etkili

hesaplama yöntemleriyle birleştiginde çığır açıcı sonuçlar elde edildi. Görüntü tanıma, doğal dil işleme, oyun stratejisi ve diğer birçok alanda yapay sinir ağları, insan seviyesinde performans göstermeye başladı.[8]



Şekil 6: Yapay sinir ağları modeli [12]


Günümüzde, yapay sinir ağları alanı, sürekli olarak yeni ve yenilikçi modellerin geliştirilmesiyle dinamik bir şekilde ilerlemektedir. Derin öğrenme ve yapay sinir ağları, birçok endüstriyel ve bilimsel alanda çeşitli uygulamalara sahiptir ve bu alandaki araştırma ve geliştirmeler devam etmektedir.

### 3. VERİ SETİ

Proje esnasında PTF değerini tahminleyebilmek için kullanılacak veri seti piyasa işletmecisi EPIAŞ platformundan indirilmiştir. Veri setinde yer alması gereken bağımsız değişkenler literatür taraması sonrası belirlenmiştir. Elektrik birim fiyatı Türkiye piyasasında savaş, salgın hastalıklar, siyasi krizler vb birçok dış etmeden daha etkilendiğinden bu etmenlerin nispeten daha az yaşandığı 2011-2013 yılları arasındaki PTF fiyatı incelenmiştir. Veri setinde 10272 satır ve 4 sütundan oluşmaktadır.

#### 4. UYGULAMA VE SONUÇ

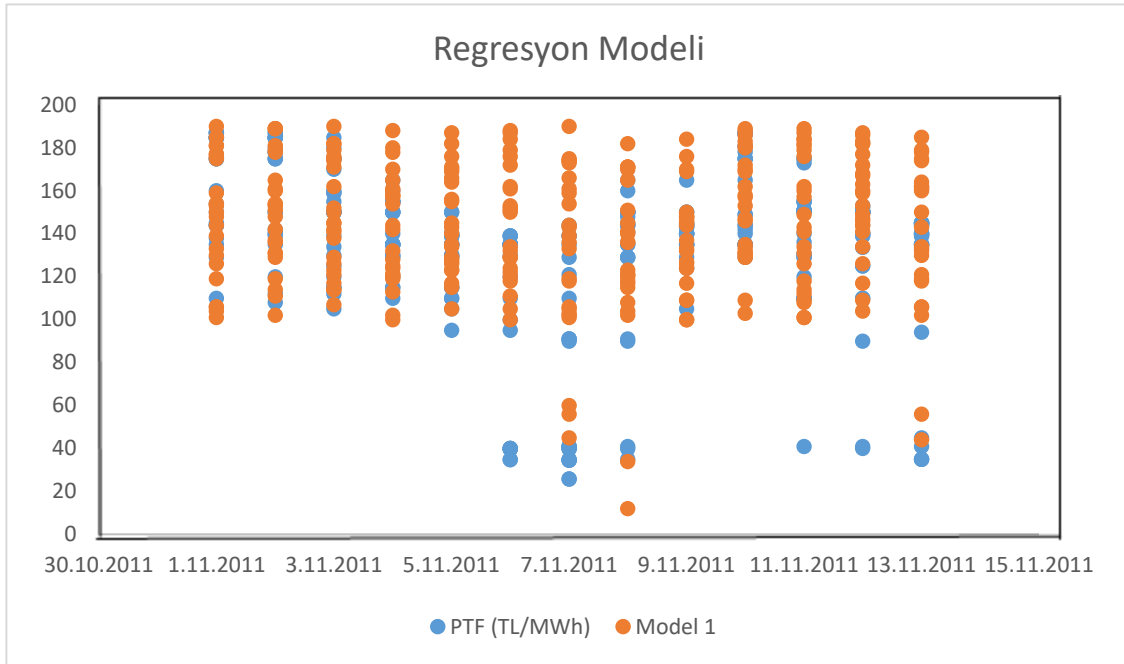
Çalışma kapsamında kullanılan veriler, EPIAŞ Şeffaflık Platformundan sağlanmış olup 2011-2013 yılları arası gün öncesi piyasasında saatlik piyasa takas verileri ve her bir üretim kaynağının saatlik üretim değerlerini kapsamaktadır. Aşağıdaki grafik oluşturulurken 2011-2013 yılları arasından random örneklemeler seçilmiştir. Grafikten de anlaşılacağı gibi aykırı değerler veri setimizde mevcuttur. Bu aykırı değerler tahminleme veri setimizi bozmaması adına temizlenmiştir.



Şekil 7: Veri seti yıllık dağılım


Elimizdeki PTF fiyatlarını içeren veri seti lineer olarak değişmediğinden zaman serisinde lineer regresyon modeli yerine çoklu regresyon modeli tercih edilmiştir. Model ilk olarak

Çoklu Regresyon ile incelenmiştir. Elde edilen çıktıda ise fiyatın daha stabil gittiği dönemlerde model tutarlı ilerlerken keskin düşüş noktalarında modelin başarısız sonuçlar verdiği tespit edilmiştir. Bu bölgeler tüm modellerde kırmızı ile işaretlenmiştir.



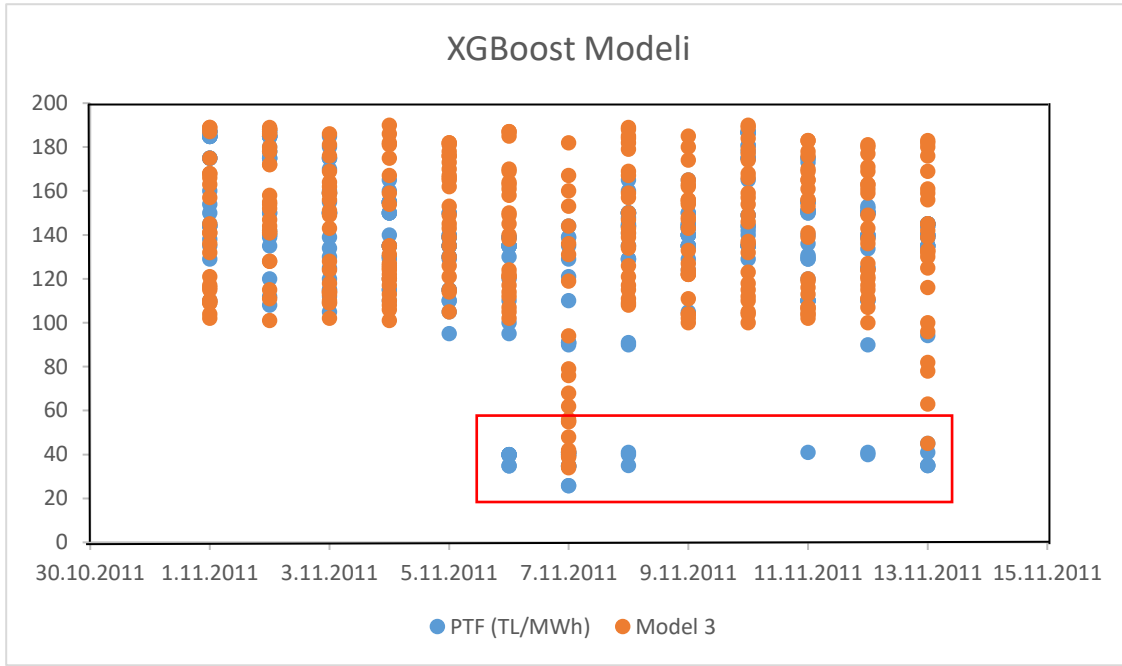
Şekil 8: Regresyon modeli sonuç

Yapay Sinir Ağları yönteminde ise regresyon modeline benzer şekilde linner değişmeyen zaman serilerinde gerçek değeri yakalayabilirken ani değişim ve düşüş noktalarında model başarısız sonuçlar vermektedir. İki model karşılaştırıldığında ise regresyon modelinde YSA modeline kıyasla daha başarılı sonuçlar elde edilmiştir.



Şekil 9: YSA Modeli Sonuç

XGBoost yük tahminleme gününü daha yüksek olması ve daha hızlı çalışan bir model olması bakımından bu veri seti için uygun bir model olarak görülmüştür. Elde edilen model çıktısı incelendiğinde PTF fiyatı linner ilerleyen zaman aralıkları için başarılı sonuçlar verdiği görülmüştür. Buna ek olarak XGBoost modelinde Regresyon ve YSA modellerinin aksine PTF nin sert düşüş yaşadığı noktalarda daha yakın test sonuçları elde edildiği görülmüştür.



Şekil 10: XGBoost modeli sonuç

Her üç model birbiri ile karşılaştırıldığında hem çalışma hızı hem de model çıktısı göz önünde bulundurularak XGBoost Modelinin en başarılı sonuçları verdiği söylenebilir.

## REFERANSLAR

- [1] TEİAŞ, Yük Tevzi Merkezi Raporları
- [2] Zenginobuz, Ü. (t.y), “Elektrik Sektöründe Özelleştirme, Rekabet ve Regülasyon”
- [3] Ünal, O. (2007), Elektrik Piyasası Oluşumu, Ankara Bürosu Dergisi, Güz 2007
- [4] Topuz, G. (2013), Enerji Bilim ve Teknolojileri Özel Konular, Ders Notları
- [5] EPDK, (t.y), “Gün Öncesi Planlamada Sistem Marjinal Fiyatının Belirlenmesi ile Sistem Satış ve Sistem Alış Talimatlarının Oluşmasına İlişkin Metodoloji”
- [6] Lv, J., Zheng, X., Pawlak, M., Mo, W., & Miskowicz, M. (2021). Very short-term probabilistic wind power prediction using sparse machine learning and nonparametric density estimation algorithms. *Renewable Energy*, 177, 181-192
- [7] Bitirgen, K., & Filik, Ü.B. (2020). Electricity Price Forecasting based on XGBoost and ARIMA Algorithms. *BSEU Journal of Engineering Research and Technology*, 1, 1.
- [8] Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Marmara Üniversitesi Açık Arşiv Sistemi*, 10(39), 101-115.
- [9] Briolat, B., Pachet, F. (2017). Deep Learning Techniques for Music Generation – Sarbonne Universtiy
- [10] Morde, V.: XGBoost Algorithm: Long May She Reign!  
<https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>. Accessed 20 Aug 2019
- [11] Abnave A, (2024). Explorşng the Magical Word with Adaboost,  
<https://medium.com/@pratikabnave97/exploring-the-magical-world-with-adaboost-50be868c8200>
- [12] Facundo Brea, b, Juan M. Gimenez, c, V'ictor D. Fachinotti, (2017). Prediction of wind pressure coefficients on building surfaces using Artificial Neural Networks