

## Hane Halkı Elektrik Kullanımının Makine Öğrenme Algoritmalarıyla Analizi (Analysis of Household Electricity Usage Using Machine Learning Algorithms)

Gökhan Turan

\* Akdeniz Üniversitesi, Bilgisayar Mühendisliği Bölümü, Türkiye

### Özet

Günümüz bilgi çağında veriler, kuruluşlar için her zamankinden daha değerli olduğunu ortaya çıkardı. Makine öğrenimi ve derin öğrenme yaklaşımlarını geçmiş verilere uygulayarak, artık daha bilinçli kararlar almamıza ve gelecekte gerçekleşmesi muhtemel olaylarla yüzleşmek için en iyi stratejileri benimsememize yardımcı olan çığır açan yeni iç görüler elde edebiliyoruz.

Bu makalede Fransa'da bulunan akıllı bir evin sensörlerinden toplanan 4 yıllık elektrik enerjisi tüketimi verileri, makine öğrenmesi algoritmaları yardımıyla incelenmiştir. Bu çalışmada, öncelikle keşifçi veri analitiği yöntemleri ile veri analiz edilmiş, veri üzerinde ön işlemlerle verinin makine öğrenme algoritmaları için en uygun hale getirilmesi sağlanmış, ardından kodlamasız (no-code) yaklaşımı kullanan Knime aracı ile farklı makine öğrenme algoritmaları test edilmiştir. Bu aşamada denenen, Doğrusal Regresyon, Gradyan Destekli Ağaç Regresyon, Basit Ağaç Regresyon ve Ağaç Topluluğu Regresyon analizleri yapılmış, başarıları karşılaştırılmış ve keşifçi veri analitiği sonuçları sunulmuştur. Çalışmanın ikinci aşamasında ise otomatik makine öğrenmesi (AutoML) ve açıklanabilir yapay zeka (XAI) yaklaşımlarını kullanan OptiScorer aracı ile de skor sonuçları çalışılmış ve iki aşamanın da çıktıları karşılaştırılarak sunulmuştur.

Çalışma sonunda elektrik tüketimi konusunda elde edilen sonuçların, elektrik tüketimi tahminlemesi konusunda kullanılabileceği ve bu konudaki diğer çalışmalara fayda sağlayabileceği umulmaktadır.

**Anahtar Kelimeler:** Elektrik Tüketimi Tahmini, Python, Knime, Makine Öğrenmesi

## Summary

In today's information age, data has revealed that it is more valuable than ever for organizations. By applying machine learning and deep learning approaches to historical data, we are now able to gain groundbreaking new insights that help us make more informed decisions and adopt the best strategies to face possible future events.

In this article, 4-year electrical energy consumption data collected from the sensors of a smart house in France has been analyzed with the help of machine learning algorithms. In this study, firstly, data was analyzed with exploratory data analytics methods, the data was optimized for machine learning algorithms with pre-processing on the data, and then different machine learning algorithms were tested with the Knime tool, which uses the no-code approach. At this stage, Linear Regression, Gradient Supported Tree Regression, Simple Tree Regression and Tree Community Regression analyzes were performed, their success was compared and the results of exploratory data analytics were presented. In the second phase of the study, the score results were studied with the OptiScorer tool, which uses automatic machine learning (AutoML) and explainable artificial intelligence (XAI) approaches, and the outputs of all two phases were compared.

At the end of the study, it is hoped that the results obtained on electricity consumption can be used in electricity consumption estimation and can benefit other studies on this subject.

**Keywords:** *Electricity Consumption Prediction, Python, Knime, Machine Learning*

---

## 1. Giriş

Akıllı elektrik ölçüm teknolojilerinin geliştirilmesiyle, günlük ve saatlik olarak büyük miktarlarda tüketim verisi toplanabilir ve bu verilerin makine öğrenme algoritmalarıyla analizleri yapılabilir. Tüketimi bilmek, tüketicilerin enerji taleplerini daha iyi anlamaları ve kontrol etmeleri için çok yararlıdır. Enerji tüketimi tahmini, elektrik talep yönetimini ve hizmet yükü planlamasını basitleştirir [1]. Bireysel ev düzeyinde elektrik kullanımı, kullanıcıların yaşam tarzına, doluluk davranışına, bina özelliklerine, hava durumuna ve takvim bilgilerine bağlı olduğu için yüksek değişkenlik gösterebilir. Uygun tahmin yöntemleri, tahmin aralığı, tahmin süresi, zaman serilerinin özellikleri ve zaman serilerinin boyutu gibi çeşitli faktörlere bakarak dikkate alınır [2].

Akıllı evden toplanan verilerin analizlerine başlamadan, dünya genelindeki tüketilen güç ve hanelerde güç tüketen sebepler hakkında da fikir sahibi olmamız faydalı olabilir. Dünyada en çok elektrik enerjisi tüketen ülke 6,510 TWh tüketim ile Çin'dir [3].

Ölçümlerimizin alındığı evin konumu olan Fransa ise 437 TWh ile 10. sırada yer alıyor. Evin içerisinde elektrik tüketen cihazlar olarak gözlemlersek, en çok elektrik tüketimi iklimlendirme sistemleri ve su ısıtma için harcıyor [4]. Bir sonraki kısımda belirtilen iklimlendirme sistemleri ve su ısıtma ölçümlerini toplayan "sub\_metering\_3" isimli sensör, bu sebepten dolayı en fazla güç tüketiminin gözlemlendiği veri kümesi olmalıdır ve nitekim sonuçlar da öyledir. Gelecek verilerin makine öğrenmesi ile tahminleri, elektrik tüketimine etkisinin yüksek olmasından dolayı iklimlendirme sistemleri üzerinden yapılacaktır.

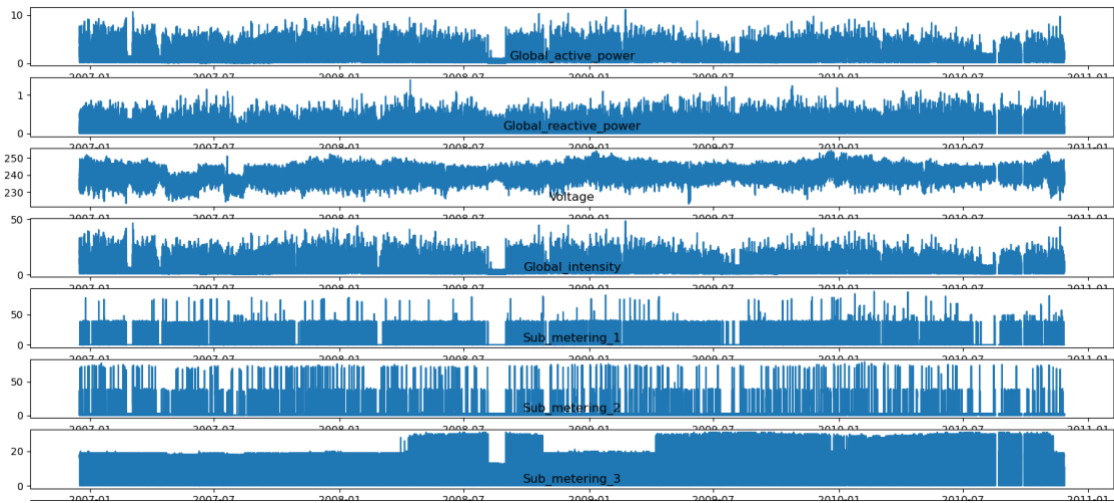
## 2. Veri Kümesi

İnceleyeceğimiz veri kümesi olan ‘Household Power Consumption’ [5], dört yıl boyunca tek bir hanenin elektrik tüketimini tanımlayan çok değişkenli bir zaman serisi veri kümesidir. Bu arşiv, Sceaux'da (Paris, Fransa'dan 7km) bulunan bir evden toplanan 2075259 adet ölçümü içerir. Veriler Aralık 2006 ile Kasım 2010 arasında, hane halkı içerisindeki güç tüketimi gözlemleri her dakika olacak şekilde toplanmıştır. Tarihin ve saatin yanı sıra yedi değişkenden oluşan çok değişkenli bir dizidir, bunlar:

- global\_active\_power: Hane halkı tarafından tüketilen toplam aktif güç (kilovat).
- global\_reactive\_power: Hane halkı tarafından tüketilen toplam reaktif güç (kilovat).
- voltage: Ortalama voltaj (volt).
- global\_intensity: Ortalama akım şiddeti (amper).
- sub\_metering\_1: Mutfak için aktif enerji (vat-saat aktif enerji).
- sub\_metering\_2: Çamaşırhane için aktif enerji (vat-saat aktif enerji).
- sub\_metering\_3: İklim kontrol sistemleri ve su ısıtıcı için aktif enerji (vat-saat aktif enerji).

Veriler ‘.csv’ dosya biçiminde toplandıktan sonra, farklı enerji ölçümlerini temsil eden 7 sütun ölçümden oluştuğunu gözlemliyoruz. Veriler, satırların yaklaşık %1,25'inde (yaklaşık 82 gün) eksik değerlere sahip. Eksik değerlerin sayısının, veri tabanının boyutuna göre nispeten küçük olduğunu söyleyebiliriz. Dolayısıyla, bu eksik değerleri görmezden gelirse modelimize herhangi bir zarar vermez.

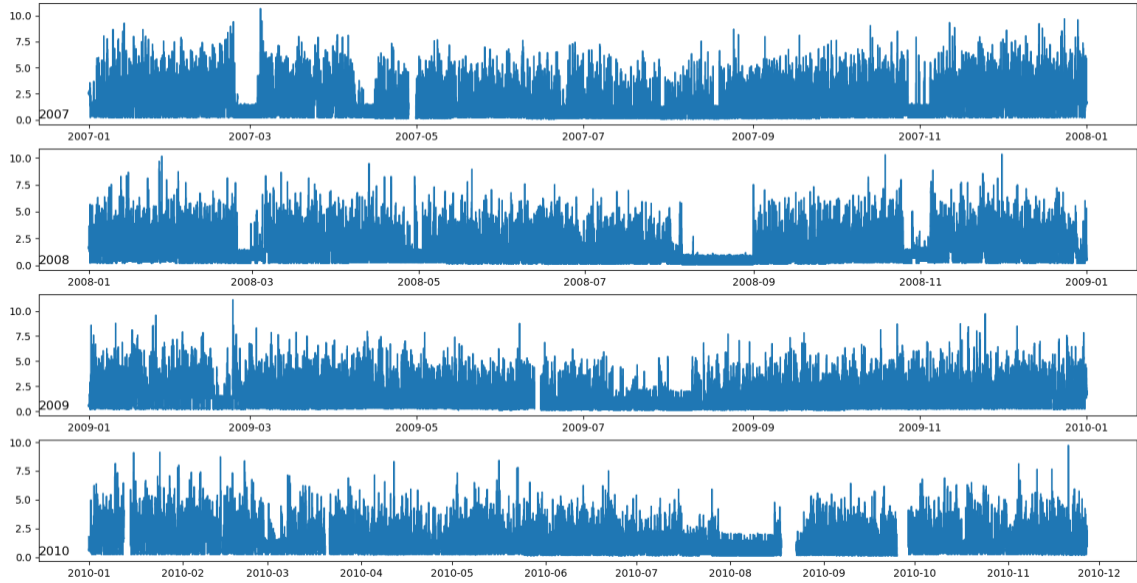
Verileri incelerken bazı tutarlı kalıpların, önemli eğilimlerin var olup olmadığı, var ise ne ile bağlantılı olduğunu gözlemleyebilmemiz için en rahat yöntemlerden birisi veriyi görselleştirmektir. Aşağıda gösterildiği gibi, yedi değişkenin her biri için ayrı bir grafik oluşturarak başlanabilir.



Çizgi Grafiği 1 Tüm Veriler

Çizgi Grafiği 1'deki ‘Global active power’ parametresinde oluşan sivri uçları görebiliyoruz. Bunlar gece-gündüz, hafta sonu ve içi olarak kullanım oranları değişikliklerini gösteriyor olabilirler fakat bu ölçekteki en önemli etken mevsim değişiklikleridir. Bazı zamanlarda verilerin sıfıra çok yakın olduğunu gözlemliyoruz. Gözlemin sıfıra yakın olduğu zaman aralıklarında, evde kimsenin bulunmadığı çıkarımlarında bulunabiliriz.

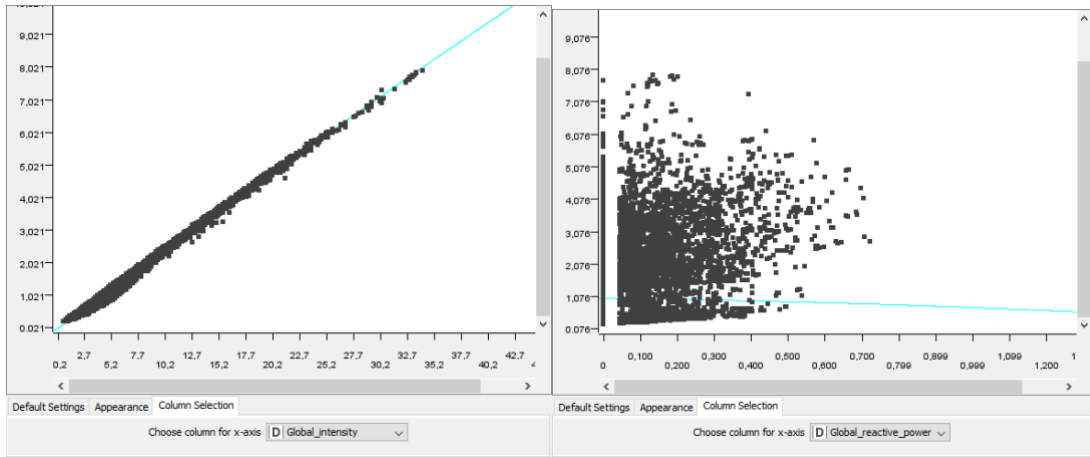
‘Sub metering 3’ parametresinde ise belirli bir zamandan sonra sabit bir artış gözlemlenmektedir. Bu tarihte yeni bir cihaz kullanılmaya başlanmış olabilir, mevsimlerin sıcaklık farkları sebebiyle bu değişken dahilindeki cihazların kullanım miktarları değişmiş olabilir ya da aynı sebepten dolayı kullanım profillerinde değişikliğe gidilmiş olabilir. Çizgi Grafiği 2'de, ‘Aktif Güç’ verilerinin analizleri daha yakından gözlemlenebilir.

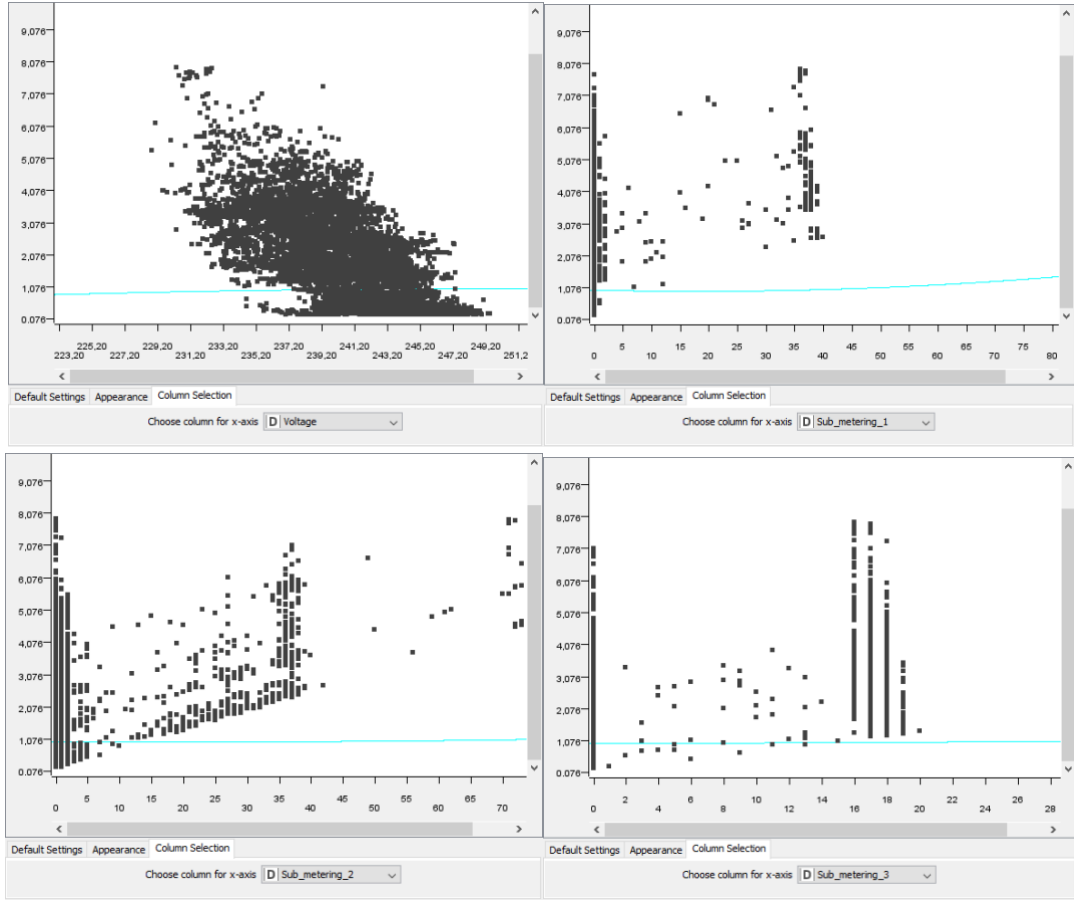


Çizgi Grafiği 2 Küresel Aktif Güç Grafiği

### 3. Keşifçi Veri Analitiği (Exploratory Data Analysis)

Bu kısımda Knime aracımızı kullanarak, evdeki sensör verileri üzerinden veri ön işleme ve makine öğrenmesi aşamalarına dair keşifçi analizler yapılmıştır. Başlangıç olarak veri kümesindeki öznitelikler grafiğe döktükten sonra istatistik değerleri incelenmiştir. Sonra da makine öğrenmesi ve istatistiksel algoritmalarla detaylı analizleri yapılmış ve veri üzerinde keşifçi çıkarımlarda bulunulmuştur.





Sensör Verileri

#### 4. Knime Analizleri

KNIME kullanıcıların görsel olarak veri akışları (veya hatları) oluşturmalarını, seçilen veya tüm analizleri adımlarının gerçekleştirilmesini daha sonra modelleri, sonuçları ve etkileşimli görünümünün incelenmesini sağlar. KNIME Java ile yazılmış ve Eclipse tabanlı kurulmuştur ve ek işlevsellik sağlayan eklentileri eklemek için uzantı mekanizmasını kullanmaktadır. Çekirdek sürüm zaten veri entegrasyonu (Dosya giriş / çıkışı, JDBC ile tüm yaygın veritabanı yönetim sistemlerini destekleyen veritabanı düğümleri), veri dönüşümü (filtre, dönüştürücü, birleştirici) yanı sıra veri analizi ve görselleştirme için yaygın olarak kullanılan yöntemler için yüzlerce modül içermektedir. Ücretsiz Rapor Tasarımcısı uzantısıyla, KNIME iş akışları, veri kümelerinden doc, ppt, xls, pdf ve diğerleri gibi belge formatlarına rapor şablonları oluşturabilmektedir [8].

Bir veri ön işleme olan Temel Bileşen Analizi (PCA) ile veriler makine öğrenme algoritmalarına başlamadan önce düzenlendi. Noktalardan çizgiye olan ortalama kare mesafesini en aza indiren çizgi, en iyi uyan çizgi olarak tanımlanır [9]. Tanıma, sınıflandırma, görüntü sıkıştırma alanlarında kullanılan yararlı bir istatistiksel tekniktir. Temel amacı yüksek boyutlu verilerde en yüksek varyans ile veri setini tutmak ancak bunu yaparken boyut indirgemeyi sağlamak olan bir tekniktir. Fazla boyutlu verilerdeki genel özellikleri bularak boyut sayısının azaltılmasını, verinin sıkıştırılmasını sağlar. Boyut azalmasıyla bazı özelliklerin kaybedileceği kesindir; fakat amaçlanan, bu kaybolan özelliklerin popülasyon hakkında çok az bilgi içeriyor olmasıdır. Bu yöntem, yüksek korelasyonlu değişkenleri bir araya getirerek, verilerdeki en çok varyasyonu oluşturan “temel bileşenler” olarak adlandırılan daha az sayıda yapay değişken kümesi oluşturur [10].

Öznitelik	Minimum	Ortalama	Maksimum	Std. Sapma	Eğrilik	Kurtosis	Histogram
Global aktif güç	0,076	1,0916	11,122	1,0573	1,7862	4,2187	
Global reaktif güç	0,0	0,1237	1,39	0,1127	1,2619	2,6056	
Voltaj	223,2	240,8399	254,15	3,24	-0,3267	0,7247	
Global yoğunluk	0,2	4,6278	48,4	4,4444	1,8491	4,6012	
Sub_metering_1	0,0	1,1219	88	6,153	5,9445	35,643	
Sub_metering_2	0,0	1,2985	80	5,822	7,0906	57,9073	
Sub_metering_3	0,0	6,4584	31	8,4372	0,7247	-1,2822	

Tablo 1 Sensörlerin İstatistik Verileri

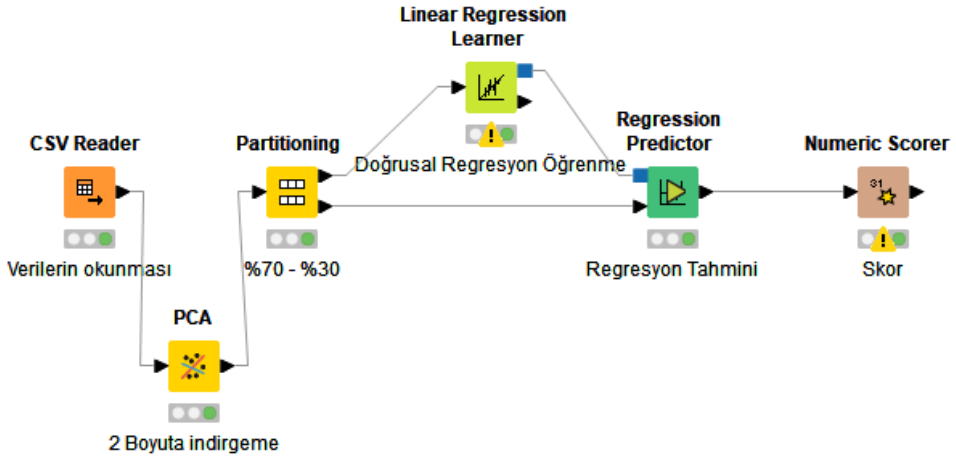
Verilerden gördüğümüz üzere, en çok elektrik tüketimi “sub\_metering\_3” olan iklimlendirme sistemleridir. Bundan sonraki analizlerde parametre olarak “sub\_metering\_3” seçilecektir. Makine öğrenme algoritmalarındaki ezberleme (overfitting) riskinin önüne geçmek için veriyi %70-%30 rastgele şekilde öğrenme ve test kümeleri olarak bölümlendirilmiştir.

Çalışmanın bu aşamasında, veri seti incelenerek ve dört yıl içinde bir hanede elektrik enerjisi tüketiminin tüm değişkenlerini araştırılarak, gelecekteki talebi belirli bir doğrulukla tahmin etmeye yarayan bazı kalıplar çıkarılmış, mevsimsel özellikler ve diğer önemli bilgiler bulunmuştur.

Örneğin, çalışmanın bu aşamasından sonra artık aşağıdaki değerlerin tahmin edilmesi mümkün hale gelmiştir:

- Ertesi gün için aktif enerji tüketimi
- Önümüzdeki hafta için aktif enerji tüketimi
- Önümüzdeki ay için aktif enerji tüketimi
- Önümüzdeki yıl için aktif enerji tüketimi

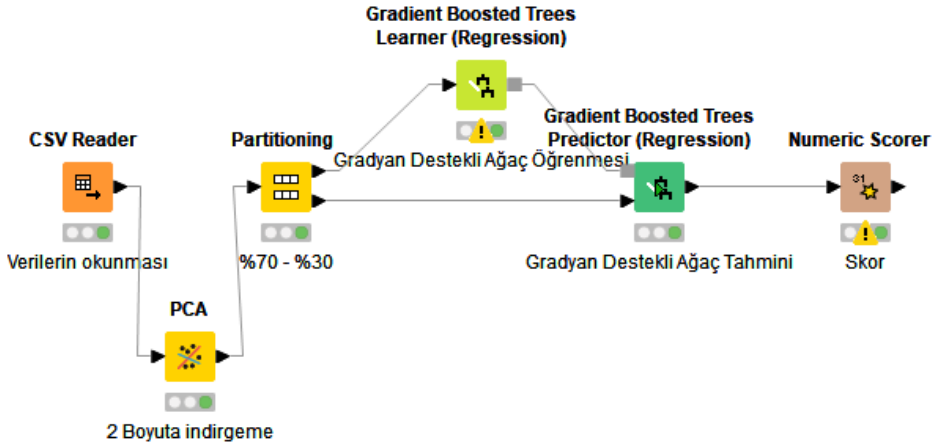
#### 4.1 Knime ile Doğrusal Regresyon



Knime Şekil 1 Doğrusal Regresyon

Regresyon, bağımsız sayısal değişkenlerin değerlerine dayalı olarak bağımlı bir değişkenin değerini tahmin etmek için kullanılan bir tekniktir. Birden fazla regresyon biçimi vardır. Doğrusal regresyon, tahmin ediciler ve hedef özellikler arasındaki istatistiksel ilişkiyi en iyi temsil eden bir çizgi bulmaya çalışır [11].

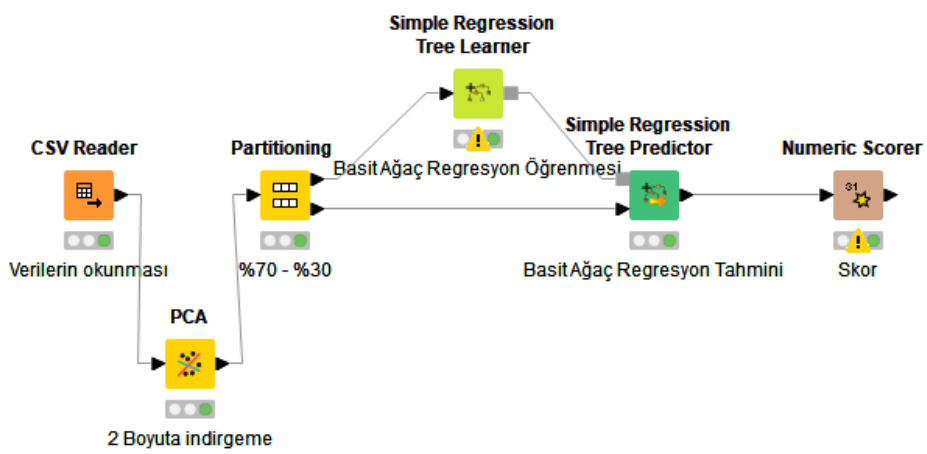
#### 4.2 Knime ile Gradyan Destekli Ağaç (Regresyon)



Knime Şekil 2 Gradyan Destekli Ağaç

Gradyan artırma, tipik olarak karar ağaçları gibi zayıf tahmin modelleri topluluğu şeklinde bir tahmin modeli üreten, regresyon ve sınıflandırma problemleri için bir makine öğrenme tekniğidir. Modeli, diğer hızlandırma yöntemlerinin yaptığı gibi aşama bazında oluşturur ve keyfi bir türevlenebilir kayıp fonksiyonunun optimizasyonuna izin vererek geliştirir [12].

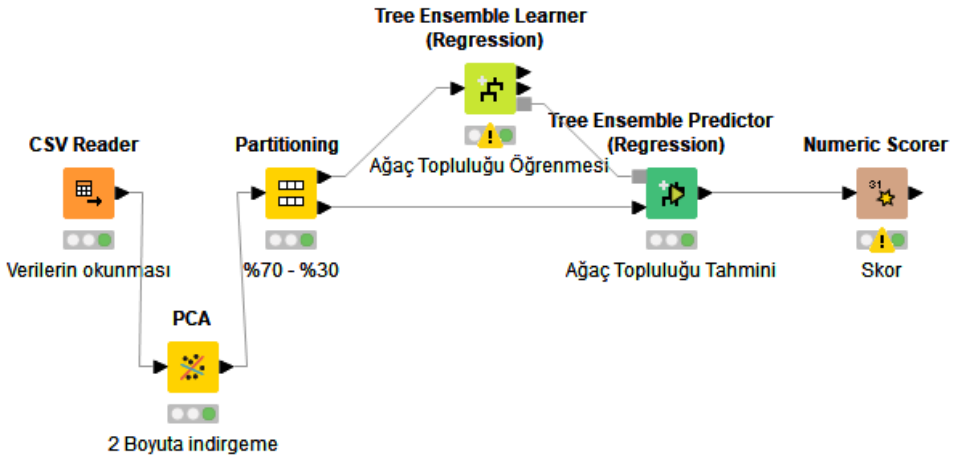
### 4.3 Knime ile Basit Regresyon Ağacı



Knime Şekil 3 Basit Regresyon Ağacı

Bir regresyon ağacı, öznitelik değerlerinin alt kümelerine karşılık gelen özniteliklere, kenarlara karşılık gelen ve öznitelik alanından sürekli hedef değerine eşleyen işlemlere karşılık gelen uç düğümlerden (yapraklar) oluşan dahili düğümlerden oluşur. En basit ve en popüler işlem sabit bir işlemdir. Diğer bir popüler işlem, bir öznitelik alt kümesinin doğrusal bir işlevidir. Bir ağaç kökünde başlayan ve bir ağaç yaprağında biten her yol, bir regresyon kuralına karşılık gelir [13].

### 4.4 Knime ile Ağaç Topluluğu (Regresyon)



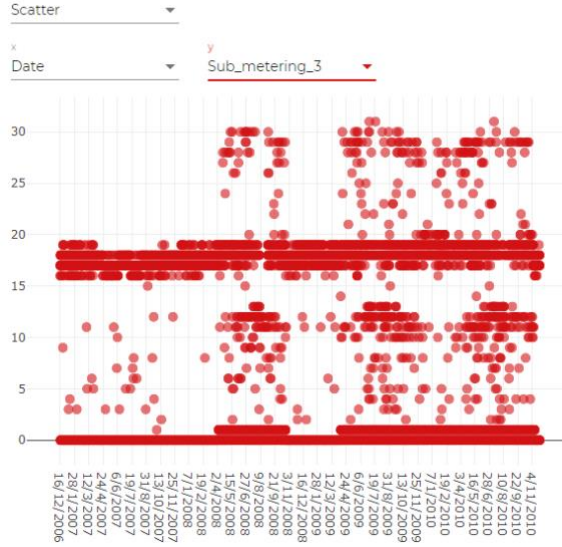
Knime Şekil 4 Ağaç Topluluğu Regresyon

Topluluk yöntemlerinde, tek başına kurucu öğrenme algoritmalarının herhangi birinden elde edilebilecek olandan daha iyi tahmin performansı elde etmek için çoklu öğrenme algoritmaları kullanır. Genellikle sonsuz olan istatistiksel mekanikteki istatistiksel bir topluluğun aksine, bir makine öğrenimi topluluğu yalnızca somut bir sonlu alternatif model kümesinden oluşur, ancak tipik olarak bu alternatifler arasında çok daha esnek bir yapının var olmasına izin verir [14]. Ayrıca tahmin edilen sonuçlar pozitif ya da sıfır değerlerini almaktadır. Bu da elektrik tahmini konusunda, bizi eksi (-) değer üretme yanlışıdan kurtarır.



## 5 AutoML ve Açıklanabilir Yapay Zeka

OptiWisdom çatısı altındaki üç ana motordan biri olan Optiscorer Engine, yapay zekaya dayanarak birçok alanda skorlama yapabilir. OptiScorer, içerdiği skorlama ve sıralama algoritmalarıyla dijitalleşebilen bütün varlıklar üzerinde çalışabilmektedir. Çalışma alanları müşteri skorlama, müşteri kaybı tahmini, dolandırıcılık riski skorlama, borç tahsilatı skorlama, çalışan performansı skorlama ve risk skorlamadır [15]. OptiWisdom 1 dağılım grafiğinde, makalemizde incelediğimiz parametrenin “sub\_metering\_3” tarihe göre dağılım grafiği gösterilmiştir.



OptiWisdom 1 dağılım grafiği

AutoML, oldukça basit bir şekilde planlamayı destekleyen ve kullanıcıların ince ayar yapmasına ya da tekrar modelleme yapmasına gerek duymadığı makine öğrenme modellerinin uygulanmasına ve gelişmesine olanak tanıyan otomatik özellikli, algoritma seçim ve uygulama sürecidir.

İndeks	Skor
1/1/2007	6.735191813671037
1/1/2008	5.56631519087286
1/1/2009	-5.187225210334893
1/1/2010	7.070566486405844
1/10/2007	-10.248609951460837
1/10/2008	8.050260962463684
1/10/2009	6.973508727007605
1/10/2010	7.034057411449421
1/11/2007	7.665845398399806
1/11/2008	7.488466474110064
1/11/2009	-20.520879589573273
1/11/2010	6.2077802405536024
1/12/2007	-14.156318808300663
1/12/2008	5.624890968905095
1/12/2009	6.045307893549934
1/2/2007	-12.118745963164061
1/2/2008	6.211176199648208
1/2/2009	5.90553413193708
1/2/2010	-11.078043797789475

Tablo 2 OptiWisdom İndeks Skorlamaları

## 6. Skor Sonuçları

4 farklı makine öğrenmesi algoritması veri setimize uygulandı. Doğrusal ve Gradyan Destekli Ağaç Regresyonunda negatif tahminler de gözlemlendi. Tahmin edilen sonuçların skorlaması Tablo 2'de listelenmiştir.

Skor	Doğrusal Regresyon	Gradyan Destekli Ağaç	Basit Ağaç Regresyon	Ağaç Topluluğu	OptiScorer
R <sup>2</sup>	0,567	0,689	0,581	0,766	0,96
Ortalama Mutlak Hata	4,203	1,891	2,127	2,001	0,726
Ortalama Karesel Hata	30,828	22,16	29,793	16,115	1,809
Karekök Ortalama Hata	5,552	4,707	5,458	4,014	1,345
Hız	Hızlı	Yavaş	Normal	Yavaş	Yavaş

Tablo 3 Skor sonuçları

Skor	Doğrusal Regresyon	Gradyan Destekli Ağaç	Basit Ağaç Regresyon	Ağaç Topluluğu	OptiScorer
R <sup>2</sup>	0.998	0.998	0.981	1.0	1.0
Ortalama Mutlak Hata	0.25	0.111	0.234	0.048	0.086
Ortalama Karesel Hata	0.109	0.175	1.35	0.018	0.041
Karekök Ortalama Hata	0.33	0.418	1.162	0.136	0.202

Tablo 4 PCA ön işlemeden sonra skor sonuçları

Tahmin edilen sonuçlara baktığımızda ve skorları incelediğimizde en verimli olanın, yavaş da olsa Ağaç Topluluğu Regresyon modeli olduğu gözlemlendi. Ayrıca istenmeyen değerler olan negatif sonuçlar bu modelimizde bulunmamaktadır. Bu da modelimizi yavaş olmasına rağmen en verimli model kılar.

## 7. Sonuç

Bu çalışmada, dört yıl boyunca tek bir evin elektrik kullanımını tanımlayan hane halkı elektrik tüketimi veri setinin analizleri incelenmiş ve gelecekteki enerji tüketimi talebini en doğru şekilde tahmin eden makine öğrenmesi modeli çalışılmıştır. Tüketim miktarlarının bilinmesi, tüketiciler için olduğu kadar enerji tedarikçileri için de büyük önem taşımaktadır. Veri ön işleme yöntemlerinden biri olan PCA (Temel Bileşen Analizi) kullanılmıştır ve kullanıldıktan sonra yüksek oranda artan doğruluk oranları gözlemlenmiştir. Knime kullanarak yaptığımız modellerde en doğru sonuçları veren Ağaç Topluluğu Regresyon modeli olarak bulunmuştur. Optiscorer sonuçları da veri ön işlemeden sonra çok yüksek doğruluk oranları vermiştir.

Enerji tüketim verilerinin analiz edilmesi, enerji satış şirketlerinde gelecekteki olası tüketimi tahmin etmek ve elektrik enerjisi piyasasındaki elektrik üniteleri için maliyetleri uygulamak için de yararlıdır. Çalışmaya devam edilmesi durumunda diğer evlerden de alınan veriler incelenip, genel bir yargıya varılabilir ve bu veri analizleri elektrik tedarikçilerine veya ev sahiplerine sunulabilir.

## Kaynakça

- [1] C. Nichiforov, I. Stamatescu, I. Făgărășan and G. Stamatescu, "Energy consumption forecasting using ARIMA and neural network models," 2017 5th International Symposium on Electrical and Electronics Engineering (ISEEE), Galati, 2017, pp. 1-4, doi: 10.1109/ISEEE.2017.8170657.
- [2] Individual Household Electric Power Consumption Forecasting using Machine Learning Algorithms Bulunabilir link:[https://www.researchgate.net/publication/335911657\\_Individual\\_Household\\_Electric\\_Power\\_Consumption\\_For\\_ecaasting\\_using\\_Machine\\_Learning\\_Algorithms-](https://www.researchgate.net/publication/335911657_Individual_Household_Electric_Power_Consumption_For_ecaasting_using_Machine_Learning_Algorithms-)
- [3] "World Power consumption | Electricity consumption | Enerdata", Yearbook.enerdata.net, 2020. Bulunabilir link: <https://yearbook.enerdata.net/electricity/electricity-domestic-consumption-data.html>
- [4] "Electricity use in homes - U.S. Energy Information Administration (EIA)", Eia.gov, 2020. Bulunabilir link: <https://www.eia.gov/energyexplained/use-of-energy/electricity-use-in-homes.php>
- [5] "UCI Machine Learning Repository: Individual household electric power consumption Data Set", Archive.ics.uci.edu, Bulunabilir link: <https://archive.ics.uci.edu/ml/datasets/individual+household+electric+power+consumption>
- [6] J. Brownlee, "How to Develop Multi-Step LSTM Time Series Forecasting Models for Power Usage", Machine Learning Mastery, Bulunabilir link: <https://machinelearningmastery.com/how-to-develop-lstm-models-for-multi-step-time-series-forecasting-of-household-power-consumption/>
- [7] F. Mahia, A. R. Dey, M. A. Masud and M. S. Mahmud, "Forecasting Electricity Consumption using ARIMA Model," 2019 International Conference on Sustainable Technologies for Industry 4.0 (STI), Dhaka, Bangladesh, 2019, pp. 1-6, doi: 10.1109/STI47673.2019.9068076.
- [8] Beisken, S., Meinl, T., Wiswedel, B. et al. KNIME-CDK: Workflow-driven cheminformatics. BMC Bioinformatics 14, 257 (2013). <https://doi.org/10.1186/1471-2105-14-257>
- [9] Daniel Granato, Jânio S. Santos, Graziela B. Escher, Bruno L. Ferreira, Rubén M. Maggio, Use of principal component analysis (PCA) and hierarchical cluster analysis (HCA) for multivariate association between bioactive compounds and functional properties in foods: A critical perspective, 2018, pp. 83-90 <https://doi.org/10.1016/j.tifs.2017.12.006>.
- [10] PCA (Principal Component Analysis) Temel Bileşenler Analizi Bulunabilir link: <https://medium.com/@gulcanogundur/pca-principal-component-analysis-temel-bile%5C%9Fenler-analizi-bf9098751c62>
- [11] Linear Regression Bulunabilir link: [https://en.wikipedia.org/wiki/Linear\\_regression](https://en.wikipedia.org/wiki/Linear_regression)
- [12] Gradient Boosted Tree Bulunabilir link: [https://en.wikipedia.org/wiki/Gradient\\_boosting#Gradient\\_tree\\_boosting](https://en.wikipedia.org/wiki/Gradient_boosting#Gradient_tree_boosting)

- [13] Simple Regression Tree Bulunabilir link: [https://en.wikipedia.org/wiki/Simple\\_linear\\_regression](https://en.wikipedia.org/wiki/Simple_linear_regression)
- [14] Yuyan Wang, Dujuan Wang, Xin Ye, Yanzhang Wang, Yunqiang Yin, Yaochu Jin, A tree ensemble-based two-stage model for advanced-stage colorectal cancer survival prediction, 2019, pp. 106-124, <https://doi.org/10.1016/j.ins.2018.09.046>.
- [15] Bulunabilir link: <https://www.optiscorer.com/>
- [16] J. Brownlee, "How to Develop Convolutional Neural Networks for Multi-Step Time Series Forecasting", Machine Learning Mastery. Bulunabilir link: <https://machinelearningmastery.com/how-to-develop-convolutional-neural-networks-for-multi-step-time-series-forecasting/>
- [17] L. Jiang, S. Luo and J. Li, "An Approach of Household Power Appliance Monitoring Based on Machine Learning," *2012 Fifth International Conference on Intelligent Computation Technology and Automation*, Zhangjiajie, Hunan, 2012, pp. 577-580, doi: 10.1109/ICICTA.2012.151.
- [18] Şadi Evren Şeker, "OptiScorer: Otomatik Makine Öğrenmesi ile Skorlama", YBSAnsiklopedi 2020 v.8, is.1 , pp: 10-24