

The Probabilistic Prediction of Solar Energy Power Production Based on Time in Smart Grids

Mehmet DEMİRTAŞ^{1,*}, Nuran AKKOYUN², Emrah AKKOYUN³, İpek ÇETİNBAŞ⁴

¹Gazi University, Faculty of Technology, Department of Electrical and Electronics Engineering, 06500, Yenimahalle/Ankara

²Gazi University, Graduate School of Natural and Applied Sciences, Department of Electrical and Electronics Engineering, 06500, Yenimahalle/Ankara

³Middle East Technical University, Graduate School of Informatics, Department of Medical Informatics, 06800, Çankaya/Ankara

⁴Eskişehir Osmangazi University, Faculty of Engineering and Architecture, Department of Electrical and Electronics Engineering, 26480, Odunpazarı/Eskişehir

Graphical/Tabular Abstract

Article Info:

Received: 05/04/2019

Revision 18/05/2019

Accepted: 20/05/2019

Highlights

- Solar energy power production estimated.
- Using machine learning algorithms.
- Forecasting based on meteorological measurements.

Keywords

Smart Grid
Solar Energy
Prediction of Energy
Power
Machine Learning
Probabilistic
Programming

Population growth and energy resource based on fossil fuel depletion increase the demand for renewable energy resources, especially for solar energy in the world. Smart grids have been developed in order to meet the growing energy need in the form of an intelligent structure with renewable energy sources. One key goal of the smart grid initiatives, therefore, increases the ratio of the renewable energy within overall energy power generation. However, the integration of renewable energies into the grid, whose power generation is intermittent and uncontrollable, leads to a number of challenges. It is critical to determine which renewable source will be dispatched to satisfy the variety of customer demands, and predict the energy power in advance.

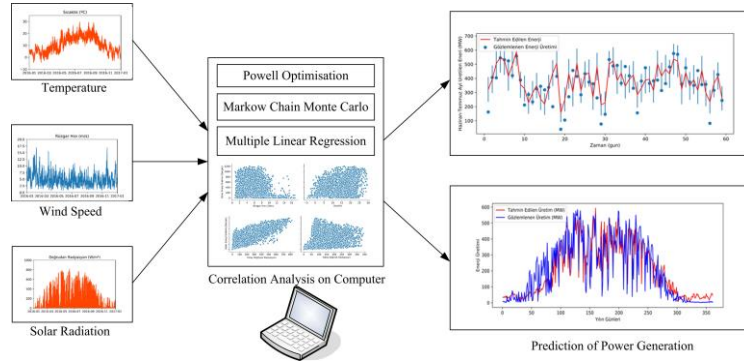


Figure A. Block schema of the system

Purpose: In this study, we aim to show that the energy generation could be modeled based on the weather measurements using the machine learning algorithms and the renewable energy production system oriented power generation could be, thus, predicted hourly.

Theory and Methods: The model was created by machine learning approaches and an energy production estimate was made. A variety of methods such as multiple linear regression, Powell optimization and probabilistic programming based on Markov Chain Monte Carlo simulations were used and their capability of predictions were compared to each other.

Results: The energy production is estimated with an accuracy of 80% with an analytical approach. Additionally, a probabilistic approach was used to predict the power associated with an uncertainty indicating the upper and lower limit of a power based on time.

Conclusion: The power generated from a solar plant could be predictable based on the weather measurements. In addition, it is considered that estimation algorithms will facilitate the integration of renewable energy systems into the existing grid and make the smart grid more widespread.



Akıllı Şebekelerde Güneş Enerjisi Üretiminin Zamana Bağlı Olasılıksal Tahmini

Mehmet DEMİRTAŞ^{1,*}, Nuran AKKOYUN², Emrah AKKOYUN³, İpek ÇETİNBAŞ⁴

¹Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 06500, Yenimahalle /Ankara

²Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Programı, 06500, Yenimahalle /Ankara

³Ortaođu Teknik Üniversitesi, Enformatik Enstitüsü, Sağlık Bilişimi Bölümü, 06800, Çankaya/Ankara

⁴Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 26480, Odunpazarı/Eskişehir

Öz

Dünyada hızlı nüfus artışı ve fosil yakıt kaynakları rezervlerinin azalışı ile birlikte özellikle güneş enerjisi olmak üzere yenilenebilir enerji kaynaklarına olan talep her geçen gün artmaktadır. Artan enerji ihtiyacını yenilenebilir enerji kaynakları ile akıllı bir yapı formunda karşılayabilmek için akıllı şebekeler geliştirilmiştir. Akıllı şebekelerin temel amaçlarından biri, enerji üretim sürecine yenilenebilir enerji kaynaklarının dâhil edilmesi ve kullanımının artırılmasıdır. Ancak, mevcut elektrik şebekesi sistemlerine kesintili enerji üretimi yapan ve kontrol edilemeyen yenilenebilir enerji kaynaklarının dâhil edilmesi beraberinde çeşitli zorlukları da getirmektedir. Değişken elektrik enerjisi talebinin hangi yenilenebilir kaynak tarafından ne zaman karşılanacağı belirlenmesi için enerji üretiminin önceden tahmin edilmesi bu zorlukların en önemlilerindedir. Bu sebeple bu çalışmada, atmosferik ölçümleri kullanarak yenilenebilir enerji üretim sistemlerine özgü ve saat bazlı enerji üretimini tahmin eden bir model geliştirilmiştir. Bu model makine öğrenmesi yaklaşımları ile oluşturulmuş ve enerji üretimi tahmini yapılmıştır. Çoklu doğrusal regresyon, Powell optimizasyonu ve Markov Chain Monte Carlo simülasyonlarına dayanan olasılıklı programlama gibi çeşitli yöntemler kullanılmış ve tahmin yetenekleri birbirleriyle karşılaştırılmıştır. Enerji üretimi analitik yaklaşımla %80 doğrulukla tahmin edilirken, olasılıksal yaklaşımla saat bazlı %95 güven aralığında üst ve alt limitini belirtecek şekilde başarılı tahmin edilmiştir. Bu çalışmada elde edilen sonuçlar makine öğrenmesi ile atmosferik veriler kullanılarak değişken enerji üretiminin önceden tahmin edilebileceğini göstermiştir. Ayrıca tahmin algoritmalarının, yenilenebilir enerji sistemlerinin mevcut şebekeye entegrasyonunu kolaylaştıracağı ve akıllı şebekeyi daha yaygın hale getireceği değerlendirilmektedir.

Makale Bilgisi

Başvuru: 05/04/2019

Düzeltilme: 18/05/2019

Kabul: 20/05/2019

Anahtar Kelimeler

Akıllı Şebeke
Güneş Enerjisi
Enerji Üretimi Tahmini
Makine Öğrenmesi
Olasılıksal Programlama

Keywords

Smart Grid
Solar Energy
Prediction of Energy
Power
Machine Learning
Probabilistic
Programming

The Probabilistic Prediction of Solar Energy Power Production Based on Time in Smart Grids

Abstract

Population growth and energy resource based on fossil fuel depletion increase the demand for renewable energy resources, especially for solar energy in the world. Smart grids have been developed in order to meet the growing energy need in the form of an intelligent structure with renewable energy sources. One key goal of the smart grid initiatives, therefore, increases the ratio of the renewable energy within overall energy power generation. However, the integration of renewable energies into the grid, whose power generation is intermittent and uncontrollable, leads to a number of challenges. It is critical to determine which renewable source will be dispatched to satisfy the variety of customer demands, and predict the energy power in advance. In this study, the energy generation could be modeled based on the weather measurements using the machine learning algorithms and the renewable energy production system oriented power generation could be, thus, predicted hourly. This model was created by machine learning approaches and an energy production estimate was made. A variety of methods such as multiple linear regression, Powell optimization and probabilistic programming based on Markov Chain Monte Carlo simulations were used and their capability of predictions were compared to each other. While energy production is estimated with an accuracy of 80% with an analytical approach, it has been predicted to be successful with a probabilistic approach, indicating the upper and lower limit of 95% confidence interval. These results show that the energy generation could be predictable based on

the weather measurements using machine-learning algorithms. In addition, it is considered that estimation algorithms will facilitate the integration of renewable energy systems into the existing grid and make the smart grid more widespread.

1. GİRİŞ (INTRODUCTION)

Günümüzde küresel ısınma, iklim değişikliği, kısıtlı fosil yakıt kaynakları, enerji maliyetleri ve çevre kirliliği gibi nedenlerden dolayı yenilenebilir enerji kaynaklarının önemi ve bu kaynaklara olan yatırımlar gün geçtikçe artmaktadır. Enerji üreticisi şirketler, kullanıcıların temel ihtiyaçlarını karşılamak için enerji hizmetini her ne kadar mevcut yapı üzerinden yürütseler de, fosil tabanlı enerji kaynaklarındaki sorunlar bu şirketleri enerji üretim yöntemlerini ve tüketim alışkanlıklarını tekrar değerlendirmeye zorlamıştır. Bu doğrultuda yenilenebilir kaynak kullanımı, enerji verimliliği, mevcut enerjinin etkin ve verimli kullanımı konusunda yeni pek çok araştırma yapılmıştır [1-3]. Yenilenebilir enerji kaynaklarının elde edilmesinin daha az maliyetli olması, dünyanın her yerinde kolay erişilebilmesi ve kaynak bakımından bol olması gibi nedenlerle, bu kaynakların kullanımının artırılması dünyada fosil yakıt bazlı üretime olan bağımlılığı azaltması açısından önemlidir [4].

Enerji ihtiyacı büyük oranda fosil yakıtlardan karşılanan ülkemizde 2018 yılının ilk altı ayı için Enerji ve Tabii Kaynaklar Bakanlığı tarafından yapılan analizde, yenilenebilir ve yenilenemez kaynaklar birlikte değerlendirildiğinde kurulu güç 87.139 MW seviyelerine ulaşmıştır. Kurulu güce en düşük katkıyı %1,3 ile jeotermal enerji yaparken en yüksek katkıyı ise %32 ile hidrolik enerji sağlamaktadır. Bunun haricinde doğalgazdan %26,4 kömürden %21,4, rüzgâr enerjisinden %7,7, güneş enerjisinden %5,4 ve diğer kaynaklardan ise %5,8 oranında faydalanılmıştır [5]. Enerji üretimine karşın Enerji İşleri Genel Müdürlüğü tarafından 2019 yılı Ocak ayı itibarıyla enerji tüketimi 9.254 kiloton eşdeğer petrol olarak açıklanmıştır. Enerji tüketimi doğalgaz, elektrik ve motorin olarak sırasıyla %60, %24 ve %12 oranlarında tüketilmiştir [6]. Bu sonuçlar incelendiğinde; dışa bağımlılık yaratan doğalgaz ve motorinin yüksek tüketim oranları göze çarpmaktadır. Buradan hareketle enerji üretiminde yerli ve yenilenebilir kaynakların kullanımı önem arz etmektedir.

Akıllı şebeke sistemlerinin temel amaçlarından biri, çevre dostu olan yenilenebilir enerji kaynaklarının kullanımını artırmak olup birçok ülke bu doğrultuda hedefler belirlemiştir. Örneğin, 2020 yılına kadar Kaliforniya'da enerji tüketiminin %33'ünün yenilenebilir enerji kaynaklarından üretilmesi hedeflenmektedir [7]. Ancak, yenilenebilir enerji kaynaklarının mevcut şebekelere dâhil edilmesinde, üretimin kesintili ve kontrol edilemez oluşu bir takım zorlukları da beraberinde getirmektedir. Mevcut elektrik şebekeleri tüketici kontrollü olarak ev ve binalarda istenildiği zaman istenildiği kadar enerji tüketimine izin verecek şekilde tasarlanmıştır. Elektrik enerjisi talebi sürekli izlenerek artan veya azalan ihtiyaç şebekeler üzerinden giderilmektedir. Binlerce binanın ve evin bir araya getirilmesi ile oluşan talep oldukça doğru ve kolayca tahmin edilebilmektedir. Böylece, günümüzdeki şebekelerde hangi kaynaktan ne zaman talebi karşılanacağı doğru olarak önceden başarılı bir şekilde tahmin edilebilmektedir. Ancak bu şebekeler, büyük ölçekte kontrol edilemeyen enerji üretimleri için tasarlanmamıştır [8].

Yenilenebilir enerji kaynaklarının mevcut şebekelere entegrasyonundaki temel problem, enerji üretim miktarının önceden belirlenememesi ve tahmin edilememesidir. Çünkü üretim, santralin bulunduğu yerdeki coğrafi özelliklere ve o günün meteorolojik koşullarına bağlı olarak değişmektedir. Özellikle küçük ölçekte dağınık üretim yapan ev ve binalarda üretimin tahmin edilebilecek olması, Amerika Birleşik Devletleri'ndeki pek çok eyalette olduğu gibi fazla üretimin de satılabileceği bir sisteme olanak sağlayabilecektir [9]. Enerji üretiminin tahmini, değişkenlere bağlı bir işlem olduğundan farklı analitik çözümlerle veya olasılıksal programlamalarla çözümlenebilmektedir. Literatürde geleneksel bir yaklaşımla Powell optimizasyonu [10] kullanılarak noktasal bir tahminleme yapılmış sonuçları çalışmada sunulmuştur. Ayrıca, aynı veri seti kullanılarak Bayesian yaklaşımla ön tanımlı ve belirli sınırlamalar dahilinde rastlantısal verilerin simülasyon ile üretilmesi [11] de yapılarak noktasal tahminin yanında belirsizliğinde modellendiği bir çözüm sunulmuş ve sonuçları gösterilmiştir.

Geleneksel olarak yapılan bu tahmin, verilen belirli bir zamanda üretimin herhangi bir güven aralığı verilmeksizin noktasal olarak tahmin edilmesidir. Zaman serileri analizleri [12], uzman sistemler [13],

yapay sinir ağları [14] ve çoklu doğrusal regresyon analizleri [15] geçmişte başarılı sonuçlar vermiş ve uygulanmış olan çalışmalardır. Bu tekniklerin yanı sıra, özellikle yapay zekâ alanında son zamanlarda ortaya çıkan yeni çözümler, enerji üretiminin tahmin edilmesinde de uygulanmıştır. 2012 yılında bu alanda yapılan çalışmaları destekleme kapsamında farklı algoritma ve yaklaşımların enerji üretimi tahminini için kullanılması ve herkese açık veri setlerinin oluşturulması amacıyla uluslararası bir yarışma düzenlenmiştir [16]. Bu yarışma endüstriyel veya akademik alanda çalışan araştırmacıların ilgisini çekmiştir. Çeşitli tekniklerin sunulması, verilerin ön analizi ve temizlenmesi, spesifik bir gün için tahmin yapılması, sıcaklığın tahmin edilmesi, hiyerarşik tahminleme ve vb. alanlarda çözümlerin sunulmasına olanak sağlamıştır [17]. Çoklu doğrusal regresyon analizleri, yapay ağlar ve rastlantısal tahminleme gibi teknikler bu yarışmada başarılı sonuçlar vermişlerdir [16].

Geleneksel çözümler, özellikle dağıtık enerji kaynaklarındaki üretimin ve tüketim talebinin sürekli değiştiği günümüzde beraberinde bazı zorluklarda getirmektedir. Belirli bir zamana ait üretimin noktasal olarak tahmin edilmesi, zamana bağlı değişen belirsizlik hakkında bilgi vermemektedir. Noktasal tahminin yanında o zamana ait sistem operatörleri açısından oldukça önemli olan belirsizliğin de tahmin edilmesi olasılıksal programlama ile yapılabilmektedir. Fonksiyona bağlı belirli bir zamana ait bir noktanın analitik olarak tahmin edilmesinden farklı olarak, aynı zamanda bir dağılım verilerek tahmin yapılmasını sağlamaktadır. Böylece, enerji sistemlerinde karar verme noktasında genel olarak daha cazip ve kapsamlı bir çözüm sunabilmektedir [18].

Bu çalışmada, güneş enerjisinden yapılacak enerji üretimi değişken meteorolojik koşullara ve radyasyon ölçümlerine göre modellenmiştir. Bu model aracılığıyla saatlik bazda enerji üretimi tahmini gerçekleştirilmiştir. Bu amaçla ikinci bölümde temel istatistik metotları, analitik çözüm için kullanılan optimizasyon yöntemi ve olasılıksal programlama ile güven aralığı verilerek enerji üretiminin yapılması açıklanmıştır. Üçüncü bölümde farklı yaklaşımlarla tahmin edilen enerji üretimi sonuçları verilmiş, zamana bağlı gerçek üretilen veriler ile kıyaslanarak performansları incelenmiştir. Son bölümde ise sonuçlar özetlenerek çalışmada karşılaşılan kısıtlar belirtilmiş ve gelecek çalışmalar için çözüm önerileri sunulmuştur.

2. MATERYAL ve METOD (MATERIAL and METHOD)

Bu bölüm çalışmada kullanılan boylamsal veri, istatistiksel analiz, doğrusal regresyon analizi ve olasılıksal programlamayı içermektedir. Olasılıksal programlama bölümünde model tanıtımı, model uydurma ve rastlantısal veri üretimi, sonsal analizi ve enerji üretimi tahmini verilmiştir. İlk olarak temel istatistik analiz metotları kullanılarak verinin zaman içindeki değişimi, ortalaması, standart sapması gibi bilgiler analiz edilmiştir. Devamında Sklearn kütüphanesi kullanılarak farklı ölçümlerin enerji üretimini hangi ölçüde etkilediği doğrusal regresyon analizi ile incelenmiştir. Ölçümlere ek olarak günün saat bilgisi de hesaba katılarak farklı bir yaklaşıma gidilmiştir. Önce optimizasyon ile bir tahmin yapılmış sonra olasılıksal programlama ile güven aralığı içerisinde bir tahminde bulunulmuştur. Optimizasyon ve olasılıksal programlamada bir Python kütüphanesi olan PyMC3 kullanılmıştır. Markov Chain Monte Carlo (MCMC) simülasyonu yöntemi ile veriler üretilmiş ve noktasal tahminleme yerine bir dağılım elde edilerek (normal dağılım) standart sapma ile tahmin yapılmıştır.

2.1. Boylamsal Veri (Longitudinal Data)


Bu çalışmada kullanılan veri seti, elektrik sistemleri üzerine çalışmalar yapan araştırmacılara açık olan OPSD projesi tarafından sağlanmıştır [19]. Ülkemizde enerji üretimi ile ilgili bir yıl boyunca düzenli ölçümlerin yapıldığı, beraberinde meteorolojik değerlerin olduğu bir güneş enerjisi santrali bulunmadığından tüm araştırmacılara açık olan bu veri seti kullanılmıştır. Ücretsiz ve açık bir platform sunan bu proje, dünyada enerji modellemesi üzerine yapılan çalışmaların ihtiyaç duydukları verileri, zaman serisi olarak üretilen enerji ve atmosfer ölçümleri şeklinde sunmaktadır. Toplam 37 Avrupa ülkesinden toplanan bu veriler, rüzgâr enerjisi ve güneş enerjisi gibi kullanılan teknolojilere veya geleneksel yöntemlere göre elde edilen enerji üretimini bir veri seti olarak, yine o tarihte yapılan ölçümleri bir başka veri seti şeklinde sunmaktadır. Bu veri setlerinden ülke olarak Hollanda'ya ait veri setleri seçilmiştir. Hollanda'da kurulu olan tüm güneş ve rüzgâr enerjisi kaynaklı santrallere ait 2016 ve 2017 yılları arasındaki saatlik enerji üretimleri veri seti olarak kullanılmıştır. Veri setinde hem güneş enerjisi hem de rüzgâr enerjisinden üretilen anlık enerji verileri vardır. Ancak rüzgâr enerjisinden üretilen enerjinin modellenmesi

kapsam dışı bırakılmıştır. Diğer taraftan yine aynı istasyona ait 2016 ve 2017 yıllarındaki rüzgâr hızı (m/s), sıcaklık ($^{\circ}\text{C}$), doğrusal radyasyon (W/m^2), dağınık radyasyon (W/m^2) ve ölçüm aralığı (gün/ay/yıl saat) verileri incelenmiştir. Her saat farklı zamanlarda yapılan pek çok ölçüm, ortalaması alınarak incelenecek şekilde veri analiz edilmiştir. Veriler her ne kadar araştırmacının kolayca çalışabilmesi için yapısal hale getirilse de veri setleri içerisinde enerji üretimine ya da atmosferik ölçümlere ait bazı değerlerde kayıplara rastlanmıştır. Modelleme yapılırken bu zaman aralıklarına ait eksik ölçümlerin performansı etkilememesi için veri setinden çıkartılması sağlanmıştır. Yıl bazında toplamda dört günlük verinin eksik olması ve çıkarılması ile 361 gün için, saat başı ve beş farklı ölçüm üzerinden toplamda 43.320 adet veri ile çalışılarak analiz yapılmıştır.

2.2. İstatistiksel Analiz (Statistical Analysis)

Ön işleme aşamasında, verinin temizlenmesi ve sadece modellemede kullanılacak ölçümlerin belirlenip diğerlerinin çıkartılması işlemi gerçekleştirilmektedir. Bu çalışmada açık kaynak kodlu olan ve geniş kütüphane desteğine sahip Python programlama dili kullanılmıştır. Dosya formatı olarak csv uzantılı dosyalar, Panda, numpy, matplotlib, seaborn ve MCMC kütüphaneleri kullanılarak vektör ve matrisler oluşturulmuş ve grafiklerle analiz edilmiştir. Korelasyon ve regresyon analizleri yapılmış, ortalama, medyan ve çeyrek değerleri incelenmiş, yapay zeka algoritmaları ile optimizasyon ve olasılıksal programlama yapılmıştır. Verilerin karakteristiği zaman serili çalışmalarda modelin performansı açısından oldukça önemlidir. 8.664 noktada bir yılda yapılan ölçümün hakkında bilgi sahibi olmak için veriler görselleştirilmiştir. Kuzey kutbuna yakın bir konumda yer alan Hollanda'nın mevsimsel ve gün içerisinde zamana bağlı üretiminin anlaşılması açısından önemlidir. Bu sürede yapılan diğer ölçümlerinde zaman içerisindeki değişimi zamana bağlı çizdirilerek analiz edilmiştir. Şekil 1'de sıcaklığın ve rüzgâr hızının zamana bağlı değişimi verilmiştir. Sıcaklık, 2016 yılı içerisinde -5°C ile 30°C dereceleri arasında değişmiş, yılın başında ve sonundaki kış aylarında eksi değerler görülürken yaz aylarında yüksek sıcaklıklar gözlenmiştir. Rüzgâr hızı ise sıcaklıkta olduğu gibi mevsimlere bağlı anlamlı bir değişim göstermemiş, 2 m/s ile 17 m/s hızları arasında değişmiştir.

Ölçümlerin birbirleri ile olan korelasyonu da oldukça önemlidir. Bağımlı değişkenleri belirleyip yüksek düzeyde bağımlılık gösteren ölçümleri temizlemek için ikili korelasyon analizi yapılmış ve grafiksel analiz elde edilmiştir. Ayrıca, yapılan korelasyon testlerinin istatistiksel olarak anlamlı olup olmadığını anlamak için p değeri 0,05 olarak seçilmiştir. Elde edilen korelasyon katsayıları, p değerlerine de bakılarak incelenmiş ve tümü 0,05 değerinden küçük olduğundan istatistiksel olarak anlamlı kabul edilmiştir ($p < 0.05$). Santralin toplam üretimini oluşturan veriler, ortalama, standart sapma, birinci ve üçüncü çeyrek değerlerine bakılarak hesaplanmıştır. Bunun yanında günün her saati yıl boyunca alınan ölçümlerle analiz edilmiş, benzer hesaplamalar yapılarak mevsimsel değişimin enerji üretimindeki etkisi analiz edilmiştir. Saate bağlı santral enerji üretimi kutu grafiği kullanılarak incelenmiştir. Ayrıca, bu ölçümlerin histogramı çizilerek dağılımları analiz edilmiştir. Bu, günün hangi saatinde günlere bağlı olarak nasıl bir üretim yapıldığını göstermesi açısından da önemlidir. Son olarak, tüm enerji üretimi güne bağlı dağılım grafiği çizilerek özellikleri belirlenmiştir.



Şekil 1. Hollanda'da yer alan santrale ait mevsimsel meteorolojik ölçümler

2.3. Doğrusal Regresyon Analizi (Linear Regression Analysis)

Enerji üretimine etki eden meteorolojik ölçümlerin doğrusal bir regresyon fonksiyonu ile tahmin edilmesi bu bölümde uygulanmıştır. Sklearn kütüphanesi kullanılarak sıcaklık, doğrusal ve dağınık radyasyon ölçümleri ile enerji üretiminin tahmin edilmesi için bir fonksiyon belirlenmiştir. Eşitlik 1’de belirlenen bu fonksiyon ve Eşitlik 2’de ise β vektörü verilmiştir.

$$f: R^n \rightarrow R, \gamma \sim f(x) = \beta^T x + \beta_0 \quad (1)$$

$$\beta = (\beta_1, \dots, \dots, \beta_n) \in R^n \quad (2)$$

Eşitlik 1’de gösterilen doğrusal denklemde y değeri bağımlı değişkeni, x değeri bağımsız değişkenleri yani ölçümleri, n bağımsız değişken sayısını ve R_n ise vektörel uzayı tanımlamaktadır. Eşitlik 2’de verilen β vektörü sıcaklık, doğrusal radyasyon ve dağınık radyasyonu ifade eden her bir x değişkeni için tanımlanmış katsayıyı ifade eder. Eşitlik 3’de tanımlanan ortalama karesel hata değerini minimize edecek parametreleri bulmak amaçlanmıştır.

$$\operatorname{argmin}_{\beta, \beta_0} \frac{1}{N} \sum_{i=1}^N (y_i - \beta^T x_i - \beta_0)^2 \quad (3)$$

Algoritmanın en küçük kareler yöntemi analiz performansını değerlendirmek için sklearn kütüphanesi kullanılmıştır. İlk etapta veri beş gruba ayrılmış, bu gruplardan dört tanesi modeli oluşturmak için algoritmayı eğitmede, kalan bir tanesi ise modelin tahmin edilmesinde test amaçlı kullanılmıştır. Bu çalışma farklı veri setleri ile beş kez tekrarlanarak bu deneylerin ortalama performans ölçümleri alınmış ve doğrulama işlemi yapılmıştır.

2.4. Olasılıksal Programlama (Probabilistic Programming)

Temel bir regresyon eğrisi tanımı yukarıda yapılmış olup bir veriye en uygun olan regresyon eğrisinin sıradan en küçük kareler yöntemi veya maksimum olabilirlik ile elde edilmişinden bahsedilmiştir. Bu bölümde ise aynı regresyon eğrisi Bayesian yaklaşımla olasılıksal olarak ele alınıp Eşitlik 1’de verilen formül Eşitlik 4’te olasılıksal dağılımlar gözetilerek düzenlenmiştir.

$$\gamma \sim N(X\beta, \sigma^2) \quad (4)$$

Eşitlik 4’e göre, zamana bağlı enerji üretimi normal dağılıma uygun şekilde rastlantısal sayılardan oluşan bir vektör olarak tanımlanmaktadır. Bu dağılımın ortalaması, Eşitlik 1’de verilen doğrusal regresyon fonksiyonu ile σ^2 kadar varyans hata payı ile yeniden formüle edilmiştir. Böylece, Bayesian tahmin edilme kullanılarak temelde benzer modele sahip olmasına rağmen iki noktada büyük avantaj sağlanmıştır. Birinci avantajı, hangi tahmin edicinin daha önemli olduğu ve hata oranının ne olabileceği gibi sahip olunan tecrübeler ön bilgi olarak modele dâhil edilerek performansın artırılabilmesidir. İkinci avantajı ise sadece tek bir tahminde bulunmak yerine her bir tahminin beraberinde bir olasılık değeri de sunması ve sonucun daha iyi değerlendirilmesine olanak sağlamasıdır. Örneğin, varyansı yüksek bir sonsal dağılımı, tahmin edilmede geniş aralık vereceğinden sunacağı bilgi sınırlı olabilecektir.

2.4.1. Model Tanımı (Model Specification)

Bu çalışmada kullanılan Bayesian doğrusal regresyon modeli, normal dağılıma sahip parametreler ile tanımlanmıştır. Normal dağılıma sahip sonuç γ değerleri, sıcaklık, doğrusal ve dağınık radyasyon tahmin edicilerinin bir doğrusal fonksiyonu olarak beklenen değer μ ve gözlemsel hata oranı olan σ ile Eşitlik 5-6’da tanımlanmıştır.

$$\gamma \sim N(\mu, \sigma^2) \quad (5)$$

$$\mu = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 \quad (6)$$

α değeri kesişim noktasını, β değerleri katsayıları ve X değerleri ise tahmin edicileri belirlemektedir. Bayesian bir model oluşturulduğundan modeldeki bilinmeyen değerler Eşitlik 7-9’da geniş bir varyans (zayıf bilgi) ile normal dağılımda verilmiştir. Gözlemsel hata oranı ise farklı olarak yarı normal dağılımla verilerek değerinin sıfırdan düşük olmasının önüne geçilmiştir.

$$\alpha \sim N(0, 10) \quad (7)$$

$$\beta \sim N(0, 10) \quad (8)$$

$$\sigma \sim |N(0, 100)| \quad (9)$$

Açık kaynak kodlu olan Python programlama dilinin PyMC3 kütüphanesi bu çalışmada kullanılmıştır. İstatistikte sıkça kullanılan R programlama diline benzeyen notasyonu ile kolayca istatistik dışından gelen araştırmacılar için modellenen bir ortam sağlamaktadır. Bayesian doğrusal modelde, her bir katsayı ve gözlemsel hata oranı stokastik rastlantısal değişkenlerdir. Bu değişkenler stokastik olarak adlandırılır çünkü değerleri bir nevi ebeveynleri tarafından rastlantısal olarak belirlenmektedir. Modelin gözlemsel stokastik olarak tanımlanan üretilecek örneklem uzayının uyacağı olasılıksal dağılım belirlenmiştir. Modele doğrudan elde olan gözlemsel veri verilir ve herhangi bir veri uydurma algoritmasında değişmeyecek değer olarak belirtilir. Böylece örneklem oluşturulacak verinin, tek bir değer yerine ortalaması tahmin edicilerin doğrusal bir fonksiyonu olan ve hata oranı varyans olarak tanımlanan normal dağılıma sahip bir vektör olması sağlanmıştır.

2.4.2. Model Uydurma ve Rastlantısal Veri Üretimi (Model Fitting and Random Sampling)

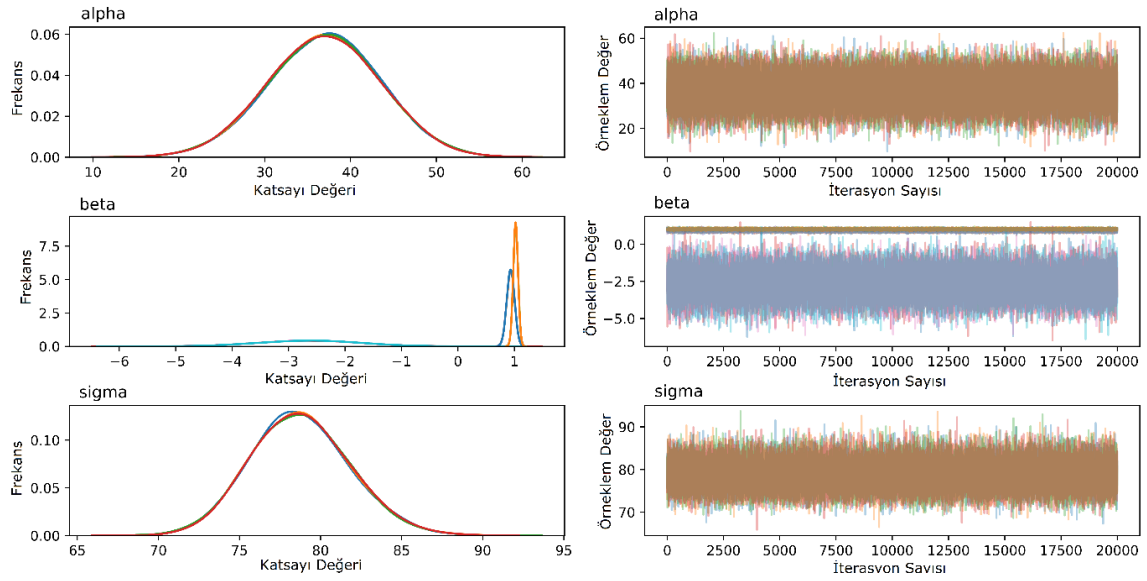
Model tanımından sonraki adım modelde belirtilen ve bilinmeyen değişkenlerin sonsal tahmin edilmesinin gerçekleştirilmesidir. Aslında, sonsal tahmin edilme analitik olarak hesaplanabilir ancak bu modellerin karmaşık olduğu yapılarda pek mümkün değildir. Bu nedenle model parametrelerinin tahmin edilmesi bir optimizasyon yöntemi olan en çok sonsal kestirici ve bir simülasyon yöntemi olan MCMC örneklemlemesi olmak üzere iki farklı yaklaşımla yapılmıştır. En çok sonsal kestirici, sonsal dağılımının modunu bulmakta kullanılan bir tahmin edicidir ve genelde numerik optimizasyon yöntemleri ile hesaplanır. Bu nedenle genelde hızlı ve kolaydır. Ancak, modelde katsayılar ve hata oranı gibi bilinmeyen değişkenler için sadece noktasal bir tahmin edilme verir ve mod eğer dağılımı düzgün tanımlamıyorsa önyargı hassastır. Ayrıca, genel olarak yeterli görünen lokal optimumları bulmada iyidir. PyMC3 kütüphanesi birden fazla optimizasyon yöntemi ile bu tahmin edilmeyi yapabilmektedir. Bu çalışmada Powell Optimizasyon yöntemi kullanılarak tahmin edilme yapılmıştır. En çok sonsal kestirici yaklaşımının dezavantajlarının üstesinden gelmek için örnekleme yaklaşımı da çalışmada kullanılmıştır. Bir simülasyon tabanlı yaklaşım olan MCMC kullanılarak belirli kıstaslara uyan Markov zinciri değerleri sonsal dağılımına uygun üretilmiştir. PyMC3 kütüphanesi Metropolis-Hasting gibi pek çok veri üretim algoritmasını desteklese de bu çalışmada hızlı olması, süreli değişkenlerde iyi olması ve hızlı yakınsama avantajları nedeniyle No-U-Turn Sampler (NUTS) algoritması seçilmiştir. Böylece her bir bilinmeyen değer için 40.000 örneklem yapacak şekilde bir veri objesinin izlerinin oluşturulması sağlanmıştır.

2.4.3. Sonsal Analiz (Posterior Analysis)

PyMC3 kütüphanesi, üretilen örneklem için aynı zamanda grafik çizdirme ve özetleme fonksiyonlarına da sahiptir. Şekil 2'de her bir stokastik bilinmeyen değişkenler için üretilen verilerin dağılımları yumuşatılmış histogram ile ilk sütunda ve her bir iterasyonda aldıkları değerler ise ikinci sütunda çizilmiştir. Doğrusal modelde tanımlı olan kesim noktası alpha ilk satırda, üç farklı katsayı olan beta değeri ikinci satırda ve gözlemsel hata oranı olan sigma ise üçüncü satırda verilmiştir. Her bir dağılıma ait ortalama ve standart sapma parametreleri elde edilerek sonsal dağılım tahmin edilmiştir.

2.4.4. Enerji Üretimi Tahmini (Prediction of Power Generation)

Bayesian doğrusal regresyon modeli ile sonsal tahmin edilmesi yapılan değerler kullanılarak herhangi bir zamanda o santrale ait enerji üretimi belirli bir güven aralığı ile yapılabilmektedir. Bu çalışmada meteorolojik verilere ve enerji üretimine ek olarak zaman değeri de hesaba katılarak yılın herhangi bir gününe ve saatine uygun olasılıksal tahmin yapılmıştır. Belirlenen herhangi bir gün ve saat için enerji üretimi belirli bir yüzde ile tahmin edilmiştir. Günün her saatinde enerji üretimi aynı olmadığı gibi gün içerisinde belirli bir zaman aralığında belirgin enerji üretimi yapılmaktadır. Örnek olarak alınan ülkenin kuzeyinde yer alan örnek santralde ise kışın geceler uzun olmakta, yazın ise gündüzler uzun geçmektedir. Bu nedenle günün her saati kendi içerisinde gruplandırılmıştır ve her bir saat için 361 örneklem ile enerji üretim vektörü oluşturulmuştur. Yılın 4 günü ise ölçümlerin sağlıklı olmayışı nedeniyle çıkartılmıştır. Örneğin saat 09.00'da enerji üretimi tahmini yapılacaksa o yıl içerisinde sadece 09.00'da yapılan üretim verileri kullanılarak bir sonraki yıl için, yılın istenilen gününe ve meteorolojik ölçümlere göre enerji üretiminin miktarı olasılıksal olarak elde edilmiştir.




Şekil 2. Bilinmeyen değişkenlerin dağılımı

3. BULGULAR ve TARTIŞMA (RESULTS and DISCUSSION)

3.1. Verinin Görselleştirilmesi ve Regresyon Analizi (Data Visualization and Regression Analysis)

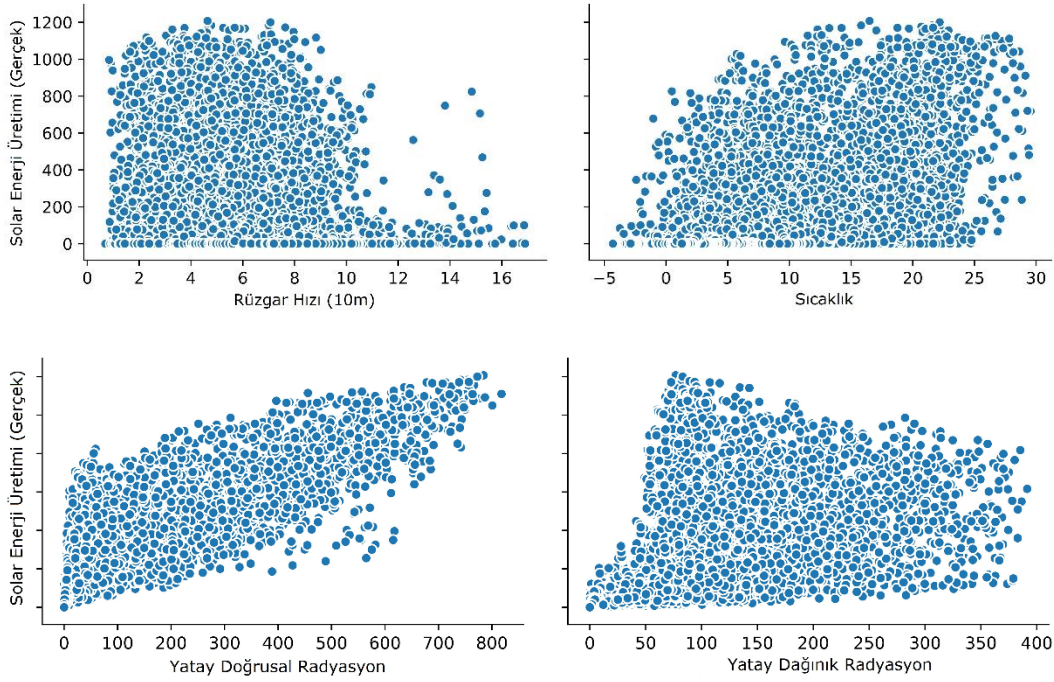
Güneş enerjisi santralinden 1 yıl boyunca saat başı alınan ölçümler model oluşturmadan ve üretim tahmini yapılmadan önce özelliklerinin belirlenmesi açısından öncelikle görselleştirilmiş ve temel istatistik yöntemleri ile analiz edilmiştir. Şekil 3’de bir yıllık enerji üretimi ve doğrusal radyasyonun değişimi verilmiştir. Şekilde görüldüğü üzere enerji üretimi yılın başında ve sonunda azalmıştır. Mayıs ve Ekim aylarında enerji üretimi artmıştır. Doğrusal radyasyon incelendiğinde de benzer bir eğilim görülmektedir. Yılın ortalarında oldukça yüksek olan doğrusal radyasyon yılın başı ve sonunda düşmektedir. Bu eğriler enerji üretiminin radyasyon ölçümü ile bağlantılı olabileceğini göstermektedir. Bunların dışında gerek enerji üretimi gerekse radyasyon ölçümlerinde analizi zorlaştıracak ani değer ölçüm değişimleri bulunmaktadır. Örneğin Nisan sonunda 800 W/m^2 olarak ölçülen radyasyon mayıs ayının başında ani bir düşüş yaşamış ve 100 W/m^2 olarak ölçülmüştür. Bu durum, enerji üretimi ile doğrudan radyasyonun korele olmasına rağmen oluşması veri setlerindeki gürültülerden, ölçümlerin tek bir santrale değil ülkede kurulu olan tüm santrallerden alınmasından kaynaklıdır. Bu nedenle tüm santrallerden yapılan ölçümlerden kaynaklı belirsizlikler, olasılıksal yaklaşımla da zamana bağlı olarak modellenmiş ve çalışmada gösterilmiştir.



a) Enerji üretimi

b) Doğrudan radyasyon

Şekil 3. Günlere bağlı enerji üretimi ve doğrudan radyasyon



Şekil 4. Enerji üretimi ve meteorolojik ölçümler arasındaki korelasyon analizi

Enerji üretimi farklı meteorolojik ölçümlere göre değişmektedir. Şekil 4'te enerji üretimi ve meteorolojik ölçümler arasındaki korelasyon analizi verilmiştir. Her bir ölçümle korelasyon analizine bakılarak enerji üretimini etkileyecek ölçümler analiz edilmiştir. Benzer şekilde regresyon analizi de yapılmış, enerji üretimi sırasıyla rüzgâr hızı, sıcaklık, doğrusal ve dağınık radyasyon ölçümleri ile 0,014, 0,44, 0,89 ve 0,65 olarak bulunmuştur ($p < 0,05$). Bu sonuçlar rüzgâr hızının bu santral için enerji üretiminde bağıntılı olmadığını ancak sıcaklık ve radyasyon ölçümlerinin korelasyonunun yüksek olduğunu göstermiştir. Bu nedenle enerji üretimi hesaplanırken regresyon analizinde rüzgâr hızı hesaba katılmamış, diğer üç ölçümün bir fonksiyonu olarak model oluşturulmuştur. Bu çalışmada rüzgârın hissedilen sıcaklığa olan etkisi göz ardı edilmiş, modellemeye dâhil edilmemiştir.

3.2. Doğrusal Regresyon Analizi (Linear Regression Analysis)

Doğrusal regresyon analizi için Sklearn Kütüphanesi kullanılmış, her bir ölçümün katsayısı hesaplanmıştır. Eşitlik 10'da enerji üretiminin hesaplanması verilmiştir. Bu eşitliğe göre enerji üretimine sıcaklık negatif şekilde etki etmiştir. Doğrusal ve dolaylı radyasyon üretimi artıran etmenler olmuş, doğrusal radyasyon dolaylı radyasyona göre daha enerji üretiminde pozitif etkisi olmuştur.

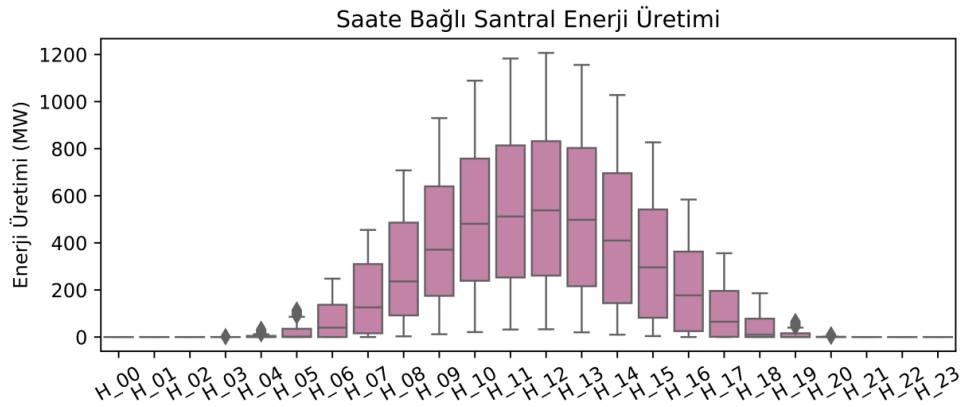
$$\text{Enerji Üretimi} = 43 - 3,63 \times \text{Sıcaklık} + 1,34 \times \text{Doğrusal Radyasyon} + 0,98 \times \text{Dolaylı Radyasyon} \quad (10)$$

Modelin performansını değerlendirmek için veri seti beş parçaya bölünmüş ve yapılan her bir testte ortalama doğruluk %80 olarak hesaplanmıştır. Doğrusal regresyon analizinin performansının yüksek çıkmasının nedenlerinden biri enerji üretiminin günün yarısında sıfır veya sıfıra yakın olmasıdır. Verinin büyük bir kısmında radyasyon değerlerinin sıfır olmasından kaynaklı geceleri üretim de sıfır olarak çıkmakta ve model bu tahmin edilme de başarılı sonuç vermektedir. Ancak, santralin aktif olarak enerji ürettiği zamandaki üretimin ne kadar olacağını tahmin edilme de bu kadar başarılı sonuç vermeyecektir. Çünkü günün hangi saatinde bu ölçümün yapıldığı bu modelde göz ardı edilmiştir. Bu nedenle model zaman bilgisini de hesaba katacak şekilde daha ileri seviyede oluşturulmuştur.

Tablo 1'de bir yıl boyunca yapılan ölçümlerin o saate göre gruplandırılarak ortalaması gösterilmiştir. Üretim beklendiği üzere günün ortasında yükselmiş, en fazla üretim saat 12.00'da ölçülmüştür. Belirgin enerji üretimi ise saat 07.00'da başlamış ve 18.00 gibi sonlanmıştır. Rüzgâr hızı yılın her saatinde istikrarlı seyretmiştir. Sıcaklıkta yaz mevsimlerinde artış göstermiş ama ortalama olarak eksili değerlere ulaşmamıştır.

Tablo 1. Saate göre ortalama ölçümler

Zaman (Saat)	Enerji Üretimi (MW)	Rüzgâr Hızı (m/s)	Sıcaklık (°C)	Doğrusal Radyasyon (W/m ²)	Dağımsal Radyasyon (W/m ²)
00.00	0,0	4,6	8,7	0,0	0,0
02.00	0,0	4,6	8,3	0,0	0,0
04.00	4,5	4,6	8,0	0,1	0,7
06.00	73,3	4,7	8,4	19,4	34,0
08.00	290,5	5,1	10,0	114,7	101,5
10.00	504,8	5,4	12,0	235,4	153,4
12.00	552,4	5,6	13,2	271,1	170,0
14.00	431,5	5,4	13,3	209,3	147,4
16.00	205,3	5,1	12,5	104,3	95,1
18.00	41,7	4,7	11,2	22,0	41,3
20.00	1,2	4,5	9,8	0,3	2,2
22.00	0,0	4,6	9,2	0,0	0,0

**Şekil 5.** Saate bağlı enerji üretim değişimi

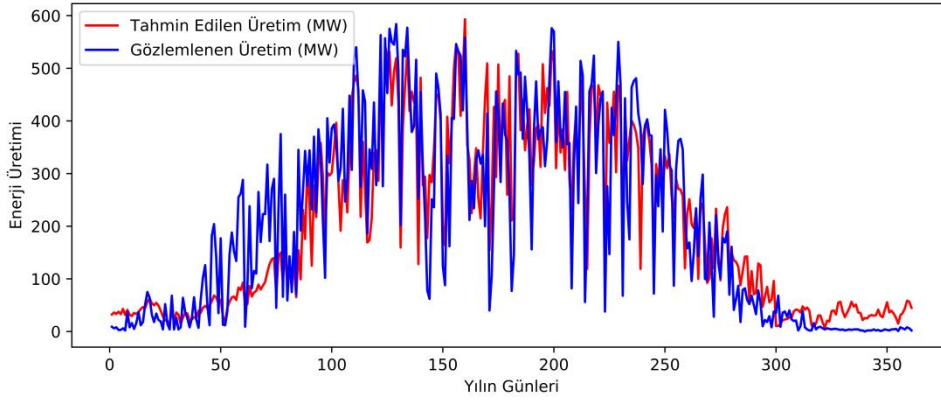
Şekil 5’te saate bağlı enerji üretim değişimi verilmiştir. Gün içerisindeki her bir saat, şekilde “H_” ön eki ile gösterilmiştir. Enerji üretimi yılın her saatinde büyük değişkenlikler göstermektedir. Örneğin öğlen saat 12.00’da en yüksek enerji üretimi 1MW’ı geçerken 0 olarak ölçüldüğü zamanlarda görülmüştür. Bu değerler uç değer olarak nitelendirilse bile 1. ve 3. çeyrek ölçümleri arasında ortalama 500 kW’lık bir fark bulunmaktadır. Ölçüm yapılan santral için yaz ve kış üretimleri için günün aynı saatinde oldukça büyük farklılıklar olduğunu göstermektedir. Bu değer tüm saatler için geçerli olup modellemeyi zorlaştırmaktadır. Bu sebeple tahmin ederken güven aralığını da sunmak önemlidir.

3.3. En Çok Sonsal Kestirici ile Tahmin (Maximum a Posteriori Estimation)

Doğrusal regresyon analizinde olduğu gibi noktasal bir tahmin edilme vermektedir. Normal dağılıma sahip örneklemelere en uygun doğrusal fonksiyonun katsayıları belirlenmiş ve bu katsayılar üzerinden tahmin edilme yapılmıştır. Farklı olarak zaman bilgisi de hesaba katılarak zamana bağlı bir enerji üretimi noktasal olarak yapılmıştır. Tablo 2’de farklı zamanlarda seçilen üç farklı saat için tahmin edilme fonksiyonu katsayıları, gözlemsel hata ve performansı verilmiştir.

Tablo 2. Saate bağlı tahmin edilme fonksiyonu katsayıları, gözlemsel hata ve performansı

Zaman (Saat)	Alpha	Beta0	Beta1	Beta2	Sigma	Performans
09.00	109,90	-6,49	0,80	1,41	57,01	0,84
11.00	106,81	-0,78	0,52	1,34	52,25	0,85
16.00	53,47	-3,91	0,94	1,04	36,04	0,90



Şekil 6. Zamana bağlı gerçek ve tahmin edilen enerji üretimi

Tablo 2’de görüldüğü üzere her bir saatin kendi içerisinde tahmin edilme fonksiyonu elde edilen gözlemlere göre uyarlanarak oluşturulmuştur. Böylece günün herhangi bir saatinde, o saatte yılın tüm ölçümleri sadece baz alınarak bir model oluşturulmuş, diğer saatlerin bilgisi dışarıda bırakılmıştır. Tabloda doğrusal regresyon katsayıları yanında gözlemsel hata oranı ve o modelin performans ölçüsü de gözlemlenen ve tahmin edilen ölçümlerin regresyon analizi sonucu hesaplanmasıyla verilmiştir. Buna göre saat 16.00’da yapılan hata oranı diğerlerine göre daha düşüktür. Buda modelin veriye ne kadar iyi uyum sağladığını göstermektedir. Bu nedenle de performansı en yüksek saat 16.00 çıkmıştır. Bu durum Şekil 5’te verilen enerji dağılım grafiği ile değerlendirildiğinde de tutarlı olduğu görülmüştür. Çünkü enerji değişimi seçilen bu üç saat içerisinde en düşük olan saat 16.00’dır. Şekil 6’da bir yıl boyunca santralde üretilen ve gözlemlenen enerji üretimi verilmiştir. Şekilden görüldüğü üzere yıl içerisinde olduğu gibi hafta içerisinde birbirini takip eden günlerde bile ciddi değişimler gözlemlenmektedir. Buna göre meteorolojik ölçümler kullanılarak elde edilen doğrusal regresyon modelinde yapılan tahminler ile gerçek üretim verilerinin örtüşmesi modelin başarısını göstermesi açısından önemlidir.


3.4. Rastlantısal Veri Üretme ile Tahmin (Prediction with Random Sampling)

Zamana bağlı yapılan tahmin edilme de enerji üretimi noktasal tahmin edilme ile verilmiştir. Her ne kadar günün saatine özgü bir model geliştirilmiş olsa da herhangi bir gün için yapılan tahminde herhangi bir güven aralığı verilmemiştir. Bu, özellikle tahmin edilmesi zor olan modellerde bir eksikliklerdir. Bu nedenle simülasyon tabanlı bir yaklaşımla bu kuralları sağlayan vektörel bir veri seti üretilmiş ve bu veri seti kullanılarak parametre tahmini yapılmıştır. Böylece, noktasal tahmin yerine dağılım oluşturularak tahmin model tarafından yapılmıştır.

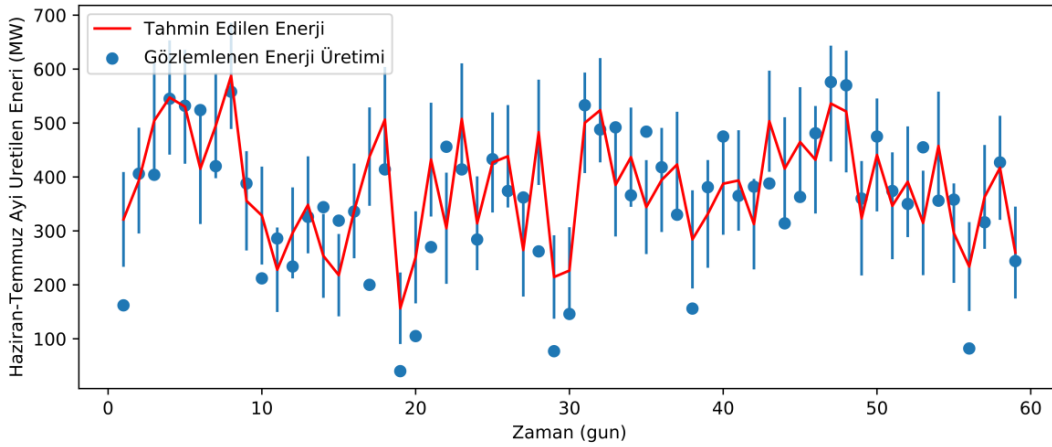
Olasılıksal bilinmeyen değişkenlerin sonsal parametrelerinin tahmini Tablo 3’te verilmiştir. Olasılıksal dağılıma sahip bir tahmin edilme fonksiyonu tahmin edilme yaparken güven aralığına bağlı olarak üst ve alt limiti olan tahmin gerçekleştirilmektedir. Şekil 7’de buna örnek bir tahmin gösterilmiştir. Grafikteki kırmızı ve turuncu dikey çizgiler sırasıyla %95 ve %68 güven aralıklarında olması beklenen enerji üretim miktarları aralıklarını belirlemektedir. Ortalama 355 KW enerji üretimi 82 KW standart sapma ile tahmin edilmiştir. Gözlemlenen enerji üretimi 388 KW olan bir santralde meteorolojik veriler kullanılarak yapılan tahmin şu şekildedir: %68 olasılıkla saat 16.00’da 160. günde enerji üretimi 437 kW ile 272 kW arasında olacaktır. %95 olasılıkla ise bu aralık 520 kW ile 190 kW aralığında değişmektedir. Her iki olasılıkla da enerji üretimi başarılı bir şekilde tahmin edilebilmiştir. Her bir güvenlik aralığı da olasılıksal dağılım fonksiyonu ile birlikte verilmiştir.

Tablo 3. Olasılıksal bilinmeyen değişkenlerin sonsal parametrelerin tahmin edilmesi

Değişkenler	Ortalama	Standart sapma	MC Hata
Alpha	36,85	6,44	0,03
Beta0	-2,66	0,89	0,00
Beta1	0,93	0,07	0,00
Beta2	1,02	0,04	0,00
Sigma	78,69	2,99	0,01



Şekil 7. Saat 16.00'da 160. günde üretilecek enerjinin tahmini



Şekil 8. Mayıs-Haziran ayları enerji üretiminin %95 güven aralığında olasılıksal tahmini ve beklenen değerleri

Şekil 8'de ise 152. ve 211. günler arasında yapılan ölçümler ve tahmin edilme sonuçları verilmiştir. Birbirini takip eden günler arasında hızlı bir değişim mevcuttur. Tahmin edilen enerji, modelin o gün için yaptığı tahmin edilmenin ortalamasını vermektedir. Bu bakımdan maksimum sonsal analizi ile tahmin edilmeye benzemektedir. Gözlemlenen enerji üretimi ise %95 güven aralığında alabileceği enerji üretimini üst ve alt limitler şeklinde göstermiştir. Grafik incelendiğinde noktaların pek çoğu bu mavi çizgiler arasına düşmektedir.

4. SONUÇ ve KISITLAR (CONCLUSIONS and LIMITATIONS)

Bu çalışmada seçilen bir ülkeye ait meteorolojik ve enerji üretim verileri değerlendirilmiştir. Toplamda 361 gün için, saat başı, 5 farklı ölçüm üzerinden 43.320 veri üzerinde çalışılarak analiz yapılmıştır. Panda, numpy, matplotlib, seaborn ve MCMC gibi farklı kütüphaneler kullanılarak vektör ve matrisler oluşturulmuş ve grafiklerle analiz edilmiştir. Korelasyon ve regresyon analizleri yapılmış, ortalama, medyan ve çeyrek değerleri incelenmiş, yapay zeka algoritmaları ile optimizasyon ve olasılıksal programlama yapılmıştır. Basit regresyon modeli ile sadece meteorolojik ölçümler gözetilerek bir tahmin edilme ile başlanmış, zaman ekseninin üretimde önemli olduğu gösterilerek veriler saat bazlı gruplandırılarak optimizasyon ve olasılıksal programlama ile analiz edilmiştir. Böylece, akıllı şebekeler için oldukça önemli olan kısa süre sonrası saat bazlı tahmin etmek mümkün olabilmektedir. Bu çalışmada karşılaşılan en büyük kısıt, zamana bağlı enerji üretimi ve atmosferik ölçümleri içeren uzun zamanlı yapısal

boylamsal bir verinin olmayışıdır. Bu çalışmada araştırmacılar için açık ve ücretsiz bir platform sunan OPSD projesi üzerinden Hollanda için hazırlanmış veri setleri kullanılmıştır. Tek bir santral yerine tüm ülkede kurulu olan santrallerden alınan toplam enerji üretimi ve ülke genelinde yapılan meteorolojik ölçümler kullanılarak bir model oluşturulmuştur. Santral özeli yerine ülke genelinde yapılan ölçümlerle oluşturulan veriler standart sapmayı artırmış ve tahmin edilme aralığını yükselmesine neden olmuştur. Bunun yerine ileride ülkemizde kurulu bir güneş enerjisi santrali ve meteorolojik istasyon üzerinden toplanacak enerji üretim verileri ve hava durumuna ait ölçümler birleştirilerek oluşturulacak veri seti, modelin çok daha doğru ve az sapma ile tahmin edilebilmesine olanak sağlayacaktır. Sadece dört özellikle belirtilen atmosferik ölçüm verisi bulut kapalılık oranı, yağış durumu, nem ve çığ gibi bilgileri içermemektedir. Bu bilgilerinde veri setinde olması daha iyi bir modellemeye olanak sağlayacaktır. Ayrıca, veri toplama frekansı 1 saat olarak veri setinde belirlenmiştir. 15 dakika aralıklarla toplanan verilerin özellikle saat bazlı tahminlerde performansı artırıcı etkisi olacaktır. Çalışma 1 yıllık veri üzerinde yapılmıştır. Mevsimsel özelliklerinde dâhil edilerek 5 yıl ve üzeri boylamsal bir veri seti üzerinde çalışma yapılması tahminin daha doğru sonuçlar elde edilmesini sağlayabilecektir.

KAYNAKLAR (REFERENCES)

- [1] A. Sağbaş, B. Başbuğ, Sürdürülebilir Kalkınma Ekseninde Enerji Verimliliği Uygulamaları: Türkiye Değerlendirmesi, *European Journal of Engineering and Applied Sciences*, 1 (2018) 41-48.
- [2] İ. Çetinbaş, B. Tamyürek, M. Demirtaş, Eskişehir Osmangazi Üniversitesi Kampüsünde Elektrik Tüketim Maliyetinin Azaltılmasına Yönelik FV Üretim Ve Enerji Depolama Biriminden Oluşan Bir Mikro Şebekenin Optimal Tasarımı, *EMO Bilimsel Dergi*, 8 (2018) 33-38.
- [3] G. Arslan, B. Bayhan, K. Yaman, Mersin / Türkiye için Ölçülen Global Güneş Işınımının Yapay Sinir Ağları ile Tahmin Edilmesi ve Yaygın Işınım Modelleri ile Karşılaştırılması, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7 (2019) 225-235.
- [4] S. K. H. Chow, E. W. M. Lee, D. H. W. Li, Short-Term Prediction of Photovoltaic Energy Generation by Intelligent Approach, *Energy and Buildings*, 55 (2012) 660-667.
- [5] Elektrik, Web Adresi: <https://www.enerji.gov.tr/tr-TR/Sayfalar/Elektrik>, Erişim Tarihi: 01.04.2019.
- [6] Ocak 2019 Aylık Enerji İstatistikleri Raporu-01, Web Adresi: <https://www.eigm.gov.tr/File/?path=ROOT%2f4%2fDocuments%2f%C4%B0statistik%20Raporu%2f2019%20Ocak%20Ay%C4%B1%20Enerji%20Raporu.pdf>, Erişim Tarihi: 01.04.2019.
- [7] State of California Executive Order S-21-09, Web Adresi: <http://gov.ca.gov/executive-order/13269>, Erişim Tarihi: 30.03.2019.
- [8] N. Sharma, P. Sharma, D. Irwin, P. Shenoy, Predicting Solar Generation From Weather Forecasts Using Machine Learning, 2011 IEEE International Conference on Smart Grid Communications (SmartGridComm), (2011) 528-533.
- [9] J. Rose, S. Chapman, Freeing the Grid Best and Worst Practices in State Net Metering Policies and Interconnection Procedures: 2009 Edition. New York, NY: Network for New Energy Choices. Accessed Apr; 2009 Apr; 11:2013.
- [10] M. J. D. Powell, A fast algorithm for nonlinearly constrained optimization calculations, *Numerical Analysis*, (1978) 144-157.
- [11] J. Salvatier, T.V. Wiecki, C. Fonnesbeck, Probabilistic programming in Python using PyMC3, *PeerJ Computer Science*, 10.7717/peerj-cs.55, (2016).
- [12] N. Amjady, Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability, *IEEE Transactions on Power Systems*, 16 (2001) 498-505.

- [13] S. Rahman, R. Bhatnagar, An Expert System Based Algorithm for Short Term Load Forecast, *IEEE Transactions on Power Systems*, 3 (1988) 392-399.
- [14] H. S. Hippert, C. E. Pedreira, Souza R.C. Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, *IEEE Transactions on Power Systems*, 16 (2001) 44-55.
- [15] C. Kang, Q. Xia, B. Zhang, Review of Power System Load Forecasting and its Development, *Automation of Electric Power Systems*, 28 (2004) 1-11.
- [16] T. Hong, P. Pinson, S. Fan, Global Energy Forecasting Competition 2012, *International Journal of Forecasting*, 30 (2014) 357-363.
- [17] Q. Chang, Y. Wang, X. Lu, D. Shi, H. Li, J. Duan, Z. Wang, Probabilistic Load Forecasting Via Point Forecast Feature Integration, *arXiv preprint arXiv:1903.10684*, (2019).
- [18] T. Hong, S. Fan, Probabilistic Electric Load Forecasting: A Tutorial Review. *International Journal of Forecasting*, 32 (2016) 914-938.
- [19] OPSP: Open Power System Data; A Free and Open Data Platform for Power System Modelling, Web Adresi: <http://open-power-system-data.org/>, Erişim Tarihi: 30.03.2019.