

### **Güneş Işınımı Tahmininde Ayrıştırma-Birleştirme Öğrenme Yaklaşımı**

Ardan Hüseyin EŞLİK<sup>1\*</sup>, Emre AKARSLAN<sup>1</sup>, Fatih Onur HOCAOĞLU<sup>1</sup>

**ÖZET:** Güneş enerjisi sistemlerinden elde edilecek elektrik enerjisi miktarı büyük oranda güneş ışınım değerine bağlı olarak değişmektedir. Bir güneş enerji sisteminin tasarımı ve planlaması, ışınım değerinin bilinmesi ile mümkündür. Güneş ışınım şiddetinin gün içerisinde yüksek değişkenlik gösteren bir yapıya sahip olması nedeniyle tek bir tahmin modeli kullanılarak bu değişimlerin yakalanması oldukça güçtür. Bu bağlamda, son yıllarda araştırmacılar tarafından tekli modellerin sınırlamalarının üstesinden gelmek ve öngörme hassasiyetini artırmak için farklı hibrit modeller ve yaklaşımlar önerilmiştir. Bu çalışmada, güneş ışınım şiddeti verilerinin tahmininde hibrit bir yaklaşım olan Ayrıştırma-Birleştirme öğrenme yaklaşımı kullanılarak yöntemin uygulanabilirliği ve performansı araştırılmıştır. Ayrıca ileriye yönelik güneş ışınımı tahminlerinin zaman çözünürlüğünün artırılması amaçlanmıştır. Bu kapsamda Afyon Kocatepe Üniversitesi, Güneş ve Rüzgâr Enerjisi Uygulama ve Araştırma Merkezi bünyesinde yer alan bir piranometre ile saatlik olarak ölçülmüş bir yıllık güneş ışınım verisi kullanılarak 15 günlük güneş ışınımı değeri saatlik olarak tahmin edilmiştir. Öğrenme yaklaşımında ayrıştırma işlemi için Ampirik Kip Ayrışımı (AKA), bireysel tahminler için ise En Küçük Kareler Destek Vektör Regresyon (EKK-DVR) yöntemleri kullanılmıştır. EKK-DVR modellerinin en uygun parametre değerleri grid arama algoritması ve 5 katlamalı çapraz doğrulama yöntemleri kullanılarak belirlenmiştir. Çalışmadan elde edilen sonuçlar Ayrıştırma-Birleştirme öğrenme yaklaşımının güneş ışınım verilerinin tahmininde başarılı olduğunu göstermiştir.

**Anahtar Kelimeler:** Güneş ışınımı tahmini, ayrıştırma-birleştirme öğrenme yaklaşımı, ampirik kip ayrışımı (AKA), en küçük kareler destek vektör makineleri (EKK-DVR)

### **Decomposition-Ensemble Learning Approach in Solar Radiation Forecasting**

**ABSTRACT:** The amount of electrical energy to be obtained from solar energy systems varies greatly depending on the solar radiation value. The design and planning of a solar energy system are possible by knowing the radiation value. Since solar radiation intensity has a highly variable structure throughout the day, it is very difficult to capture these changes using a single prediction model. In this context, in recent years, different hybrid models and approaches have been proposed by researchers to overcome the limitations of single models and increase predictive accuracy. In this study, the applicability and performance of the method were investigated by using the Decomposition-Ensemble learning approach, which is a hybrid approach to the estimation of solar radiation intensity data. In addition, it is aimed to increase the time resolution of forwarding solar radiation forecasts. In this context, 15-day solar radiation value was forecasted hourly, using an annual solar radiation data measured hourly with a pyranometer located within Afyon Kocatepe University, Solar and Wind Energy Application and Research Center. In the learning approach, Empirical Mode Decomposition (EMD) method is used for decomposition and Least Squares Support Vector Regression (LS-SVR) method is used for individual predictions. The most appropriate parameter values of LS-SVR models were determined by using a grid search algorithm and 5 fold cross-validation methods. The results obtained from the study showed that the Decomposition-Ensemble learning approach is successful in estimating solar radiation data.

**Keywords:** Solar radiation forecasting, decomposition-ensemble learning approach, empirical mode decomposition (EMD), least squares support vector machines (LS-SVM)

<sup>1</sup>Ardan Hüseyin EŞLİK (Orcid ID: 0000-0002-3495-8490), Emre AKARSLAN (Orcid ID: 0000-0002-5918-7266), Fatih Onur HOCAOĞLU (Orcid ID: 0000-0002-3640-7676), Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, Afyonkarahisar, Türkiye

\*Sorumlu Yazar/Corresponding Author: Ardan Hüseyin EŞLİK, e-mail: aheslik@aku.edu.tr

## GİRİŞ

Enerji, bir ülkenin kalkınmasında ve arzu edilen gelişmişlik düzeyine ulaşmasında rol oynayan önemli bir faktördür. Gelişmiş ülkelerin gelişmelerini sürdürülebilir kılma, gelişmekte olan ülkelerin ise gelişmiş ülkeler seviyesine ulaşma istekleri, enerjiyi sürekli bir ihtiyaç haline getirmektedir. Teknolojinin gelişmesi, artan nüfus ve sanayileşme ile birlikte ihtiyaç duyulan enerji miktarı da her geçen gün artmaktadır. Türkiye, enerji ihtiyacının önemli bir bölümünü petrol, doğalgaz, kömür gibi fosil yakıtlardan karşılamaktadır. Enerji tüketiminin yaklaşık %60'ını ithal enerji kaynaklarından temin eden ülkemiz, 2015 yılında enerji talebini karşılamak için yaklaşık 60 milyar dolar harcamıştır ve enerji maliyetleri de artmaya devam etmektedir (Kok ve Benli, 2017). Artan maliyetlerin ülke ekonomisinde oluşturduğu yükün yanında, fosil yakıt kaynaklarının sınırlı olması ve enerji kaynağı olarak kullanımlarına bağlı çevreye vermiş oldukları hava kirliliği, küresel ısınma, iklim değişikliği gibi zararlar temiz ve sürdürülebilir enerji kaynaklarına duyulan ihtiyacı net bir şekilde ortaya koymaktadır (Koç ve ark., 2018).

Güneş enerjisi, hayatımızın kaçınılmaz bir parçası haline gelen, en önemli yenilenebilir enerji kaynaklarından biridir (Eroğlu, 2018). Yenilenebilir enerjiye duyulan ihtiyaçla birlikte dünyada ve ülkemizde son yıllarda artan güneş enerjisi kullanımı, güneş enerjisinden en efektif şekilde yararlanma ihtiyacını da beraberinde getirmiştir. Güneş enerjisini elektrik enerjisine dönüştürmekte kullanılan fotovoltaik panellerin anlık güç çıkışı, büyük oranda güneş ışınım değerine bağlıdır. Güneş ışınım değerinin gün, saat ve atmosferik şartlara göre büyük oranda değişkenlik göstermesi, güneş enerjisini kesikli ve değişken özelliklere sahip yenilenebilir enerji kaynağı haline getirmektedir (Behrang ve ark., 2010; Dong ve ark., 2013). Bu değişkenlikler, voltaj dalgalanmaları, yerel güç kalitesi ve kararlılık sorunları gibi bir dizi başka sorunu da beraberinde getirerek güneş enerjisi üretiminin güvenilirliğini azaltmakta ve kurulması planlanan elektrik şebekesinin entegrasyon maliyetlerini de arttırmaktadır (Chu ve ark., 2013). Güneş enerjisinin sahip olduğu bu karakteristik yapı itibarıyla, bir bölgeye kurulması planlanan güneş enerji sisteminin tasarımı, optimizasyonu, performans değerlendirmelerinin yapılabilmesi ve güvenli, uygun maliyetli bir elektrik tedarik sistemi oluşturabilmesi için güneş ışınım değerinin bilinmesine ihtiyaç duyulmaktadır (Trapero ve ark., 2015). Bu nedenle mevcut verileri kullanarak, güneş ışınım şiddetini en doğru şekilde tahmin edebilecek modeller geliştirilmesi büyük önem arz etmektedir.

Günümüze kadar güneş ışınımı tahmini popüler araştırma konularından biri olmuştur ve araştırmalar sonucunda uygulanabilir ve sonuçları tatmin edici birçok yöntem ortaya konmuştur. Literatürde güneş ışınımı tahmini için regresyon analizi (Trapero ve ark., 2015), otoregresif model (AR) (Bracale ve ark., 2013), otoregresif hareketli ortalamalar model (ARMA) (Voyant ve ark., 2012), çok boyutlu doğrusal tahmin filtreleri (Akarslan ve ark., 2014), en küçük mutlak daralma ve seçme operatörü (LASSO) (Yang ve ark., 2015) gibi doğrusal ve bulanık mantık teorisi (Chen S. ve ark., 2013), dalgacık analizi (Mellit ve ark., 2006), adaptif sinirsel bulanık çıkarım sistemi (ANFIS) (Moghaddamnia ve ark., 2009), gizli markov modeli (Hocaoğlu, 2011), Angstrom–Prescott modeli (Mecibah ve ark., 2014) gibi doğrusal olmayan birçok modelleme yöntemi kullanılmıştır.

Yapay zekâ ve veri madenciliği alanındaki gelişmelerle birlikte güneş ışınımı tahmininde makine öğrenmesi yöntemlerinin kullanımı oldukça popüler hale gelmiştir. Yapay sinir ağları kullanılarak aylık (Alsina ve ark., 2016), günlük (Piri ve ark., 2015; Belaid ve Mellit, 2016; Lazarevska, 2016; Karasu ve ark., 2017), saatlik (Yadav ve Chandel, 2014; Hocaoğlu ve Serttas, 2017; Karasu ve Altan, 2019) güneş ışınımı tahminleri gerçekleştirilmiştir. Bir diğer makine öğrenmesi yöntemi olan destek vektör makinelerinin, yapay sinir ağlarına kıyasla üstün genelleme kabiliyetleri sayesinde sınıflandırma ve

regresyon problemlerinin çözümünde daha başarılı sonuçlar göstermesi, (Li ve ark., 2009; Mokhtarzad ve ark., 2017; Meenal ve Selvakumar, 2018) güneş ışınım tahmininde kullanımını yaygınlaştırmıştır. Chen vd. (Chen JL. ve ark., 2013) Çin'deki günlük küresel güneş ışınım değerini tahmin etmek için güneş ışığı süresini kullanan destek vektör makinesi uygulaması sunmuşlardır. Farklı girdi özellikleri kullanan yedi destek vektör makinesi modeli ve beş ampirik güneş temelli model, Çin'in Liaoning eyaletinden elde edilen meteorolojik veriler kullanılarak eğitilmiştir. Tüm destek vektör makinesi modellerinin ampirik modellerden önemli ölçüde iyi performans gösterdiği belirlenmiştir. Belaid vd. (Belaid ve Mellit, 2016) destek vektör makinelerini kullanarak günlük ve ortalama aylık güneş radyasyonu tahminini gerçekleştirmişlerdir. Ölçülen ortam sıcaklıklarının, hesaplanan maksimum güneşlenme süresinin ve hesaplanan dünya dışı güneş radyasyonunun farklı kombinasyonları modelin eğitim sürecinde kullanılmıştır. Elde edilen sonuçlar incelendiğinde tahmin sonuçlarının gözlenen değerlere oldukça yakın olduğu gözlenmiştir. Guermoui vd. (Guermoui ve ark., 2020) günlük olarak güneş ışınımını tahmin etmek amacıyla girdi olarak yalnızca sıcaklık değerini kullanan iki farklı destek vektör makinesinden oluşan yeni bir yaklaşım önermişlerdir. Destek vektör makinelerinden ilki yatay küresel güneş radyasyonunu tahmin etmekte kullanılırken, ikincisi ilk modelin ürettiği hatayı tahmin etmekte kullanılmıştır. Önerilen yaklaşım Cezayir bölgesi için değerlendirilmiş ve geleneksel tek model yaklaşımlarına göre daha başarılı sonuçlar elde edilmiştir. Yao vd. (Yao ve ark., 2018) güneş ışınımı tahmini için iki farklı destek vektör makinesi modelini içeren bir yaklaşım geliştirmiştir. Bu yaklaşımda birinci modelin eğitiminde geleneksel meteorolojik veriler kullanılırken, ikinci modelde geleneksel verilere ek olarak hava kalitesi endeksi kullanılmıştır. Hava kalitesi endeksi girdisi kullanılarak eğitilen modelin birinci modele oranla genellikle daha iyi sonuçlar verdiği gözlenmiştir.

Son zamanlarda araştırmacılar, yukarıda örnekleri verilmiş olan yapay sinir ağları, destek vektör makineleri gibi tek tahmin modeline sahip çalışmalara, farklı yöntemlerin avantajlarını en üst düzeye çıkarmak ve böylelikle tahmin başarısını arttırabilmek amacıyla farklı algoritmalar ekleyerek hibrit yöntemler ve öğrenme yaklaşımları geliştirmişlerdir. Geliştirilen bu yaklaşımlar ve yöntemlerle birlikte, orijinal güneş ışınımı zaman serisi, önışleme algoritmaları kullanılarak daha kolay modellenebilecek bir dizi sabit bileşene ayrıştırılmış, ardından her bileşen için tahmin modelleri bileşenlerin özelliklerine göre oluşturulmuştur (Cao ve Cao, 2006; Alvanitopoulos ve ark., 2014; Monjoly ve ark., 2017; Li ve ark., 2018; Altan ve ark., 2019). Teorik ve deneysel sonuçlar, hibrit yöntemler ve öğrenme yaklaşımlarının tahmin performansını etkili bir şekilde iyileştirebileceğini göstermektedir (Ji ve Chee, 2011; Sun ve ark., 2018).

Bu çalışmanın amacı; doğrusal olmayan dinamiklere sahip güneş ışınımı zaman serilerinin tahmininde ayırıştırma-birleştirme öğrenme yaklaşımının uygulanabilirliğinin ve performansının araştırılmasıdır. Bu amaç doğrultusunda Afyon Kocatepe Üniversitesinde ölçülen 1 yıllık güneş ışınım verisi kullanılarak 15 günlük güneş ışınım verisi saatlik olarak tahmin edilmiştir. Öğrenme yaklaşımında ayırıştırma algoritması olarak ampirik kip ayrışımı (AKA), bireysel tahminler için ise en küçük kareler destek vektör regresyonu (EKK-DVR) yöntemleri kullanılmıştır. EKK-DVR modelleri için en uygun parametre değerleri 5 katlamalı çapraz doğrulama yöntemi ve grid arama algoritması kullanılarak belirlenmiştir. Söz konusu modellerin oluşturulması ve çalıştırılmasında MATLAB R2018b yazılımından yararlanılmıştır. Elde edilen sonuçlar, ayırıştırma-birleştirme öğrenme yaklaşımının güneş ışınımı tahmininde başarılı bir şekilde kullanılabileceğini göstermiştir.


Makalenin organizasyonu şu şekilde planlanmıştır: ilk olarak materyal ve yöntem başlığı altında; kullanılan veri, ayırıştırma-birleştirme öğrenme yaklaşımı, ampirik kip ayrışımı ve en küçük kareler destek vektör makineleri açıklanmıştır. Ardından bulgular ve tartışmalar başlığı altında; veri hazırlama

süreci, değerlendirme kriterleri ve yapılan deneysel çalışmalardan bahsedilmiştir. Son olarak yapılan deneysel çalışmalara ait analiz sonucuna yer verilmiştir.

## MATERYAL VE METOT

### Kullanılan Veri

Bu çalışmada kullanılan güneş ışınımı verileri 1 Ocak 2013 ve 31 Aralık 2013 tarihleri arasında Afyon Kocatepe Üniversitesi yerleşkesinde konumlandırılan Kipp&Zonen marka CMP-6 model bir pıranometre ile saatlik olarak ölçülmüş ve kaydedilmiştir. Bu pıranometre,  $5-20 \mu\text{VW}^{-1}\text{m}^2$  ölçme hassasiyetine ve 64 ısıl çift bileşenlerini algılayabilen bir yapıya sahiptir. Şekil 1’de çalışmada kullanılan bir yıllık veriler sunulmuştur. Afyonkarahisar iline ait 1 yıllık saatlik güneş ışınım değerleri incelendiğinde, güneş ışınım değerlerinin belirli bir trend veya değişime sahip olmadığı, bununla birlikte farklı nedenlere bağlı olarak beklenmedik değişimler gözlenebildiği görülmektedir. Dolayısıyla güneş ışınımı değişimini modellemek oldukça karmaşık bir problem olmakla birlikte, doğrusal olmayan yöntemlere ihtiyaç duyulmaktadır.




Şekil 1. 1 Ocak 2013 ve 31 Aralık 2013 tarihleri arasında saatlik olarak ölçülen Afyon güneş ışınım verisi

### Ayırıştırma – Birleştirme Öğrenme Yaklaşımı

Bir olaya ilişkin gözlem değerlerinin zamana göre sıralanmasıyla oluşturulan dizilere zaman serisi adı verilmektedir. Güneş ışınımı, rüzgâr hızı gibi doğrusal ve durağan olmayan bir yapıya sahip zaman serilerinin modellenmesi oldukça karmaşık bir problemdir. Bu problemi basitleştirmek ve tahmin başarısını arttırabilmek amacıyla Huang vd. (Huang ve ark., 1998) tarafından parçala ve fethet mantığına sahip, ayırıştırma-birleştirme öğrenme yaklaşımı önerilmiştir. Önerilen bu yaklaşım ile, modellenmesi güç olabilecek zaman serileri alt bileşenlere parçalanmakta ve tekrar birleştirilmektedir. Bu makalede de kullanılan yaklaşım 3 ana adımdan oluşmaktadır. Şekil 2’de ilgili öğrenme yaklaşımına ait akış diyagramı verilmiştir.

1. Ayırıştırma: Seçilen ayırıştırma algoritması kullanılarak, zaman serisi kendisini oluşturan daha anlamlı, modellenmesi ve analizi nispeten daha kolay alt bileşenlere ayrıştırılır.
2. Bireysel Tahmin: Ayırıştırma sonucu ortaya çıkan alt bileşenler seçilen makine öğrenmesi yöntemi kullanılarak modellenir ve tahmin sonuçları elde edilir.
3. Birleştirme: Son aşama olan birleştirme aşamasında bireysel tahmin sonuçları kullanılarak nihai tahmin sonucu elde edilir.



Şekil 2. Çalışmada Kullanılan Ayırıştırma-Birleştirme öğrenme yaklaşımı akış diyagramı

Literatürde ayırıştırma-birleştirme öğrenme yaklaşımında kullanılan farklı birçok ayırıştırma algoritması ve tahmin yöntemi bulunmaktadır. Bu makalede, ayırıştırma algoritması olarak Ampirik Kip Ayrışımı yöntemi, tahmin ve modelleme için ise En Küçük Kareler Destek Vektör Makineleri tercih edilmiştir.

### Ampirik Kip Ayrışımı (AKA)

Huang vd. tarafından önerilen Ampirik Kip Ayrışımı (AKA), sinyali, kendisini oluşturan İçsel Kip Fonksiyonları'na (İKF) ve artık bileşene ayırıştıran bir sinyal ayırıştırma yöntemidir. Bir salınının İKF olarak adlandırılabilmesi için; yerel minimum ve maksimum noktaları sayısının birbirine eşit veya aralarındaki farkın en fazla bir olması, ayrıca alt ve üst zarfların ortalamalarının her noktada sıfır olması gerekmektedir (Huang ve ark.,1998).

AKA'yı diğer ayırıştırma yöntemlerinden ayıran en büyük fark sinyalin özelliğine bakmaksızın, herhangi bir ön bilgi gerektirmeden bileşenlerine ayırıştırabilmesidir. AKA yöntemi ile İKF ve artık bileşene ayırıştırma algoritması aşağıdaki gibidir; (Rato ve ark., 2008)

1. İlk olarak ayırıştırılmak istenen sinyal  $x(t)$  içerisindeki tüm yerel maksimum  $M_i$ ,  $i = 1,2, \dots$  ve minimum  $m_k$ ,  $k = 1,2, \dots$  noktaları bulunur.
2. Bulunan yerel maksimum ve minimum noktaları kübik interpolasyon yöntemiyle birleştirilerek alt  $m(t)$ ,  $f_m(m_k, t)$  ve üst  $M_t$ ,  $f_M = (M_i, t)$  zarflar elde edilir.
3. Alt ve üst zarfların ortalamaları bulunur,  $e(t) = (M(t) + m(t))/2$ .
4. Elde edilen alt ve üst zarfların ortalaması sinyalden çıkartılır,  $h(t) = x(t) - e(t)$ .
5.  $h(t)$  sinyalinin İKF olma şartlarını sağlayıp sağlamadığı kontrol edilir. Şartlar sağlanıyorsa  $\phi_i(t) = h(t)$  olur ve 6. adıma geçilir. Aksi takdirde  $x(t) = h(t)$  olur ve 1. adıma dönlür.
6. İKF,  $\phi_i(t)$ , elde edildikten sonra sinyalden çıkartılır  $x(t) = x(t) - \phi_i(t)$ , ve  $x(t)$  birden fazla yerel minimum veya maksimum noktası içeriyorsa adım 1'e dönlür. Aksi takdirde artık bileşen  $r(t)$  (sabit, monoton artan veya azalan sinyal) elde edilmiş olur ve ayırıştırma sonlandırılır.

AKA algoritması sonrası sinyal kendisini oluşturan n adet İKF ve artık bileşene ayrıştırılmış olur.

$$x(t) = \sum_{i=1}^n \varphi_i(t) + r(t) \quad (1)$$

Asıl sinyalden elde edilen tüm İKF'ler farklı frekans aralıklarına sahiptir ve bu nedenle sinyalin farklı detaylarını vurgulayabilirler. AKA yönteminin diğer yöntemlere göre temel avantajı, temel fonksiyonun, önceden belirlenmiş bir sabit temel fonksiyondan ziyade doğrudan orijinal sinyalden türetilmesidir. Özellikle doğrusal ve durağan olmayan sinyallerin analizi için kullanımı oldukça uygundur (Sun ve ark., 2018).

### En Küçük Kareler Destek Vektör Makineleri (EKK-DVM)

Sınıflandırma ve regresyon problemlerinin çözümünde kullanılan Destek Vektör Makineleri (DVM), ilk olarak Vapnik vd. tarafından önerilmiş bir makine öğrenmesi yöntemidir. (Vapnik, 2013) Yapısal risk minimizasyonu ve istatistiksel öğrenme teorisine dayanan çalışma ilkesi sayesinde, geleneksel makine öğrenmesi yöntemlerinde karşılaşılan düşük yakınsama oranı, yerel minimuma takılma ve aşırı doyum (overfitting) gibi sorunlarla karşılaşmaz (Lu ve ark., 2002).

DVM'i diğer makine öğrenmesi yöntemlerine göre avantajlı kılan bu özelliklerine rağmen, büyük ölçekli verilerde, hesaplama yükünün beraberinde getirdiği yavaşlama sorunu çözüm sürecini oldukça uzatmaktadır. Bu sıkıntının önüne geçebilmek amacıyla Suykens vd. tarafından En Küçük Kareler Destek Vektör Makineleri (EKK-DVM) önerilmiştir (Suykens ve ark., 2002). En Küçük Kareler Destek Vektör Makineleri regresyon problemlerinin çözümünde kullanıldığı takdirde En Küçük Kareler Destek Vektör Regresyon (EKK-DVR) olarak adlandırılabilir.

Destek vektör regresyon (DVR) yöntemi, verinin haritalama fonksiyonu kullanarak girdi uzayından daha yüksek boyutlu bir uzaya taşınıp, bu uzayda doğrusal regresyon uygulanması esasına dayanır ve şu şekilde formüle edilebilir; (Sun ve ark., 2018)

$$f(x) = w^T \varphi(x) + b \quad (2)$$

$\varphi(x)$  doğrusal olmayan haritalama fonksiyonu,  $f(x)$  tahmin değeri,  $w^T$  ve  $b$  ağırlıklardır. 2 nolu eşitliği optimizasyon problemine çevirirsek;

$$\min \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{t=1}^T (\xi_t - \xi_t^*) \quad (3)$$

$$\begin{cases} w^T \varphi(x_t) + b - y_t \leq \varepsilon + \xi_t, (t = 1, 2, \dots, T) \\ y_t - (w^T \varphi(x_t) + b) \leq \varepsilon + \xi_t^*, (t = 1, 2, \dots, T) \\ \xi_t, \xi_t^* \geq 0 \end{cases} \quad (4)$$

$\gamma$  model kompleksliğini ve eğitim hatasını dengeleyen düzenleme faktörüdür.  $\xi_t$  ve  $\xi_t^*$  parametreleri ise aylak değişkenleri (slack variable) ifade etmektedir. Bu DVM optimizasyon problemini çözmek yukarıda bahsedildiği gibi zaman alıcı olacağı için EKK-DVR kullanılarak problem;

$$\min \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{t=1}^T (e_t^2) \quad (5)$$

$$y_t = w^T \varphi(x_t) + b + e_t, (t = 1, 2, \dots, T) \quad (6)$$

Şekline dönüştürülür.  $e_t$  parametresi t. veri için gerçek ve hesaplanan çıktı arasındaki hatayı belirtir. (Sun ve ark., 2018) (Genç, 2018)

EKK-DVR’de kullanılabilecek birçok haritalama fonksiyonu bulunmaktadır. Bu çalışmada diğer haritalama fonksiyonlarına oranla parametreleri nispeten daha kolay ayarlanabilen, eğitim verilerini sonsuz uzayda doğrusal olmayan şekilde haritalandırabilen ve literatürdeki çalışmalarda oldukça sık kullanılan Gaussian RBF radyal tabanlı haritalama fonksiyonu (Gaussian RBF) tercih edilmiştir. Gaussian radyal tabanlı haritalama fonksiyonuna ait denklem eşitlik 7’de verilmiştir (Genç, 2018).

$$K(x, x_t) = \exp\left(-\frac{\|x - x_t\|^2}{\sigma^2}\right) \quad (7)$$

Burada  $\sigma^2$  radyal tabanlı harita fonksiyonun genişliğini ifade etmektedir. Özetle, EKK-DVR modellemesinde eşitlik 5’de verilen düzenleme faktörü  $\gamma$  (gama) ve eşitlik 7’de verilen Gaussian radyal tabanlı haritalama fonksiyonunun genişlik parametresi  $\sigma^2$  (sigma) olmak üzere iki adet kalibre edilmesi gereken parametre bulunmaktadır. Bu parametre değerlerinin artırılıp azaltılmasıyla modelin daha doğrusal veya daha kompleks bir yapıya sahip olması sağlanabilmektedir. Bu nedenle zaman serisinin yapısına en uygun modelin oluşturulabilmesi için parametre değerlerinin en optimal şekilde belirlenmesi büyük önem arz etmektedir. Gerçekleştirilen çalışmada en uygun parametre değerlerinin bulunması için 5 katlamalı çapraz doğrulama yöntemi ve grid arama algoritması kullanılmıştır. Ayrıca EKK-DVR modeli Pelckmans ve arkadaşları tarafından geliştirilen EKK-DVM Matlab araç kutusu kullanılarak oluşturulmuştur. (Pelckmans ve ark., 2002)

## BULGULAR VE TARTIŞMA

Bu bölümde, Ayırıştırma - Birleştirme öğrenme yaklaşımının uygulanabilirliği ve performansı, ölçülen güneş ışınım şiddeti verileri kullanılarak matlab ortamında test edilmiştir. İlk olarak veri hazırlama ve değerlendirme kriterlerine, ardından deney sonuçlarına yer verilmiştir.

### Veri Hazırlama ve Değerlendirme Kriterleri

Öğrenme yaklaşımının performansını arttırabilmek ve veriyi ayırıştırma ve modelleme sürecine hazır hale getirebilmek için güneş ışınım verisi birtakım ön işlemlerden geçirilmiştir. İlk olarak; 1 Ocak 2013 ile 31 Aralık 2013 tarihleri arasında saatlik olarak ölçülen 8760 güneş ışınım gözlem değerini içeren veri setinden, güneş ışınım değerinin sıfır olduğu değerler (güneşin bulunmadığı saatlere ait ışınım değerleri) çıkartılmıştır ve veri seti 4235 değere indirgenmiştir. Bu değerlerin veri setinden çıkartılmasıyla, ayırıştırma ve modelleme sürecinde işlem yükünün hafifletilmesi ve performansın arttırılması hedeflenmiştir. İkincil olarak veri seti, eğitim verisi ve test verisi olmak üzere iki sınıfa ayrılmıştır. Bu kapsamda, 1 Ocak 2013 ve 16 Aralık 2013 tarihleri arasında gözlenen 4100 güneş ışınım değeri ayırıştırma ve modelleme süreçlerinde kullanılmıştır. 17 Aralık 2013 ve 31 Aralık 2013 tarihleri arasında ölçülen 135 güneş ışınım gözlem değeri ise test verisi olarak ayrılmış ve eğitime dahil edilmemiştir.

Ayırıştırma – Birleştirme öğrenme yaklaşımının performansının değerlendirilmesinde, Ortalama Hata Kare Kökü (Root Mean Square Error - RMSE) hata ölçüt kriteri kullanılmıştır. RMSE, makine öğrenmesi modelinin tahmin ettiği değer ile gerçek değer arasındaki uzaklığın hesaplanmasında sıklıkla kullanılan hata ölçüt kriteridir. Eşitlik 8. de RMSE ‘ye ait formül verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{N}} \quad (8)$$


Burada  $y_n$  zaman serisinde n. zamandaki gözlenen gerçek değeri,  $\hat{y}_n$  ise tahmin edilen değeri ifade etmektedir. İlgili formül kullanılarak test verisi üzerinde gerçekleştirilen deneylerde her bir gözlem noktası için gerçek değer ile bulunan tahmin değeri arasındaki fark hesaplanarak toplam hata değerine ulaşılmıştır. Bu sayede yöntemin performansı değerlendirilmiştir.

### Deneysel Sonuçları

Güneş ışınımı şiddeti verilerinin 15 günlük saatlik tahminini gerçekleştirebilmek amacıyla, eğitim verisi, ilk olarak öğrenme yaklaşımının ilk basamağı olan ayırıştırma işlemine tabi tutulmuştur. Literatürde zaman serilerini bileşenlerine ayırıştırmakta sıklıkla kullanılan fourier analizi, doğrusal olmayan bir sistemin doğrusal sistemlere indirilmesi mantığına dayanmaktadır. Bu yöntem matematiksel olarak oldukça geçerli olmasına rağmen zaman serisinin yüksek doğrusal olmayan dinamiklere sahip olması durumunda etkin çalışmamaktadır. Zaman serilerinin bileşenlerine ayırıştırılmasında kullanılan bir diğer ayırıştırma yöntemi dalgacık analizi ise ayarlanabilir pencere kullanılarak fourier analizi yapılmasını ifade etmektedir. İlgili bu yöntemler durağan olmayan zaman serilerinde kullanılmasına rağmen doğrusal ayırıştırma prensibine dayanmaktadırlar ve taban fonksiyonu seçimi gerektirmektedirler. (Huang ve ark., 1998) AKA yöntemi, zaman serisinin dinamik özelliklerinden bağımsız olarak, herhangi bir ön bilgi gerektirmeden zaman serisini bileşenlerine kolayca ayırıştırabilmektedir. Güneş ışınımı zaman serilerinin doğrusal ve durağan olmayan yapısının göz önünde bulundurulması ve herhangi bir ön bilgiye ihtiyaç duyulmaması nedeniyle çalışmamızda ayırıştırma işlemi için AKA ayırıştırma algoritması tercih edilmiştir. Matlab R2018b yazılımı kullanılarak gerçekleştirilen AKA ayırıştırma algoritması sonrası, eğitim verisine ait asıl sinyal, kendisini oluşturan 10 İKF ve artık bileşene ayırıştırılmıştır. Şekil 3'te gösterilen AKA ayırıştırma algoritması sonucu oluşan İKF'ler incelendiğinde, her bir İKF'nin farklı frekans bilgileri içerdiği ve sinyalin farklı karakteristik özelliklerini yansıttığı görülebilmektedir. Ayrıca asıl sinyalden daha az karmaşıklığa sahip İKF'lerin elde edilmesiyle birlikte, doğrusal ve durağan olmayan yapıya sahip zaman serisi modellenmesi gibi oldukça güç olabilecek bir problem, nispeten daha basit çözülebilecek problemler haline getirilmiştir.

Ayırıştırma işlemi sonucunda ortaya çıkan İKF'lerin modellenmesi ve bireysel tahminlerinin yapılabilmesi için EKK-DVR makine öğrenmesi yöntemi kullanılmıştır. İlgili modellerin matlab ortamında oluşturulmasında EKK-DVM Matlab araç kutusundan faydalanılmıştır. Bu yöntemde; her bir İKF'nin modellenmesinde, ayarlanması gereken parametre sayısının diğer haritalama fonksiyonlarına göre az olması ve literatürde oldukça yaygın şekilde kullanılması nedeniyle Gaussian RBF haritalama fonksiyonu tercih edilmiştir. EKK-DVR parametrelerinin, regresyon tahmin doğruluğu üzerinde büyük etkisi bulunmasından dolayı, en uygun parametre değerlerinin bulunması başarılı tahminler üretebilmek için oldukça kritik öneme sahiptir. (Lu ve ark., 2009). Bu nedenle yapmış olduğumuz çalışmada eğitim verisinde en az hatayı üreten gama ( $\gamma$ ) ve sigma ( $\sigma^2$ ) değerlerinin bulunabilmesi için 5 katlamalı çapraz doğrulama yöntemi ve grid arama algoritması kullanılmıştır. Grid arama algoritması, belirli aralıklarda bulunan tüm ( $\gamma, \sigma^2$ ) çiftlerini deneyerek en iyi çapraz doğruluk derecesine sahip çifti bulmayı amaçlamaktadır. 5 katlamalı çapraz doğrulama yöntemi ile grid arama algoritması sonucu bulunan ve Çizelge 1'de sayısal olarak verilen  $\gamma$  ve  $\sigma^2$  parametre değerleri kullanılarak her bir İKF ayrı ayrı modellenmiş ve eğitimleri gerçekleştirilmiştir. Eğitilen modellerden elde edilen gelecek 15 güne ait 135 saatlik tahmin sonuçları toplanarak nihai tahmin sonucuna ulaşılmıştır. Elde edilen tahmin sonuçları ve eğitime dahil edilmeyen 17 Aralık 2013 ve 31 Aralık 2013 tarihlerine ait 135 güneş ışınımı test verisi kullanılarak hesaplanan RMSE hata ölçütü değeri 145.157 W m<sup>-2</sup> olarak bulunmuştur.





Şekil 3. Ampirik Kip Ayrışımı sonucunda oluşan İçsel Kip Fonksiyonları (İKF)

Çizelge 1. 5 katlamalı çapraz doğrulama yöntemi ve grid arama algoritması kullanılarak bulunan  $\gamma$  ve  $\sigma^2$  değerleri

İKF	Gama ( $\gamma$ )	Sigma( $\sigma^2$ )
1	15.154	5.229
2	1 596.943	15.012
3	147 689.608	52.308
4	106 220 773.470	116.009
5	4 137 548.035	10.724
6	157 348 544.841	3.665
7	698 561 532.728	0.422
8	4 309 188.157	0.057
9	7 306 008.629	0.022
10	46 785 808.536	0.002

RMSE hata ölçütü değerinin küçük olması, tahmin edilen değer gerçeğe daha yakın olduğunu göstermektedir. Bu nedenle çalışmalarda RMSE hata değerinin oldukça küçük olması istenmektedir. Güneş ışınımı tahmininde, tahmin edilmek istenen zaman ufku arttıkça başarılı tahminler yapmak zorlaşmaktadır. Geleneksel olarak kullanılan birçok yöntemde, yüksek çözünürlüklü ve uzun periyotlu başarılı tahminler yapmak pek mümkün değildir. Bununla birlikte, güneş ışınımı zaman serisinin sahip olduğu doğrusal ve durağan olmayan yapı çalışmamızda ele aldığımız problemin güçlüğünü ortaya koymaktadır. Bu problem karşısında Ayırıştırma – Birleştirme öğrenme yaklaşımı kullanılarak güneş ışınımı zaman serisi kendisini oluşturan alt bileşenlerine ayrıştırılmıştır ve elde edilen her bir bileşen kendi karakterine uygun şekilde modellenmiştir. Bu sayede karmaşık ve çözümü güç olan problem, çözümü nispeten daha kolay parçalara indirgenmiştir. Ayrıca 17 Aralık 2013 ve 31 Aralık 2013 tarihleri arasında bulunan 15 günün saatlik olarak tahminini ele alınan problemin zorluğu düşünüldüğünde  $145.157 \text{ Wm}^{-2}$  RMSE değeri gibi kabul edilebilir bir hata oranıyla gerçekleştirebilmiştir.

## SONUÇ

Bu makalede, güneş ışınımının saatlik bir zaman vektörü şeklinde tahmini için Ayırıştırma-Birleştirme öğrenme yaklaşımına sahip bir uygulama gerçekleştirilmiş ve yöntemin performansı, uygulanabilirliği incelenmiştir. Bu sayede sadece tek bir saat sonraki ışınım değerinin tahmini yerine 135 saat ilerisine kadar saatlik tahmin yapılabilmektedir. İnceleme için Afyon Kocatepe Üniversitesine yerleştirilmiş bir piranometre aracılığıyla saatlik olarak toplanan bir yıllık güneş ışınım verisi kullanılmıştır. Öğrenme yaklaşımının ilk adımı olan ayırıştırma algoritması için AKA, modelleme ve tahmin için ise EKK-DVR makine öğrenmesi yöntemi tercih edilmiştir. EKK-DVR yönteminde bulunan parametrelerin en uygun değerleri grid arama algoritması ve 5 katlamalı çapraz doğrulama yöntemi kullanılarak hesaplanmıştır. Yaklaşımın tahmin doğruluğu RMSE değerlendirme kriteri kullanılarak ölçülmüştür ve RMSE hata ölçütü değeri  $145.157 \text{ Wm}^{-2}$  olarak bulunmuştur.

Güneş ışınım tahmininde, tahmin edilecek ışınım değerinin uzaklığı ile tahmin zorluğunun doğru orantılı olarak arttığı düşünüldüğünde, çalışmamızda gerçekleştirdiğimiz 17 Aralık 2013 ve 31 Aralık 2013 tarihleri arasında bulunan 15 günün saatlik olarak tahmininin oldukça güç bir problem olduğu görülebilmektedir. Deney sonuçları incelendiğinde, çalışmamızda kullanılan Ayırıştırma-Birleştirme yaklaşımının makul bir hata değeriyle başarılı bir sonuç verdiği gözlenmiştir. Bu nedenle, güneş ışınım şiddeti tahmini ve benzeri çalışmalarda kullanılabilir bir yöntem olduğu sonucuna varılmıştır. İleriki çalışmalarda, öğrenme yaklaşımının farklı yöntemler kullanılarak uygulanması ve sonuçlarının incelenmesi planlanmaktadır.

## KAYNAKLAR

- Akarşlan E, Hocoğlu FO, Edizkan R, 2014. A novel M-D (multi-dimensional) linear prediction filter approach for hourly solar radiation forecasting. *Energy*, 73, 978–986. <https://doi.org/10.1016/j.energy.2014.06.113>
- Alsina EF, Bortolini M, Gamberi M, Regattieri A, 2016. Artificial neural network optimisation for monthly average daily global solar radiation prediction. *Energy Conversion and Management*, 120, 320–329. <https://doi.org/10.1016/j.enconman.2016.04.101>
- Altan A, Karasu S, Bekiros S, 2019. Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques. *Chaos, Solitons and Fractals*, 126, 325–336. <https://doi.org/10.1016/j.chaos.2019.07.011>
- Alvanitopoulos PF, Andreadis I, Georgoulas N, Zervakis M, Nikolaidis N, 2014. Solar radiation prediction model based on Empirical Mode Decomposition. *IST 2014 - 2014 IEEE International Conference on Imaging Systems and Techniques, Proceedings*, 161–166. <https://doi.org/10.1109/IST.2014.6958466>

- Behrang MA, Assareh E, Ghanbarzadeh A, Noghrehabadi AR, 2010. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. *Solar Energy*, 84(8), 1468–1480. <https://doi.org/10.1016/j.solener.2010.05.009>
- Belaid S, Mellit A, 2016. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. *Energy Conversion and Management*, 118, 105–118. <https://doi.org/10.1016/j.enconman.2016.03.082>
- Bracale A, Caramia P, Carpinelli G, Di Fazio AR, Ferruzzi G, 2013. A Bayesian method for Short-Term probabilistic forecasting of photovoltaic generation in smart grid operation and control. *Energies*, 6(2), 733–747. <https://doi.org/10.3390/en6020733>
- Cao JC, Cao SH, 2006. Study of forecasting solar irradiance using neural networks with preprocessing sample data by wavelet analysis. *Energy*, 31(15), 3435–3445. <https://doi.org/10.1016/j.energy.2006.04.001>
- Chen JL, Li GS, Wu SJ, 2013. Assessing the potential of support vector machine for estimating daily solar radiation using sunshine duration. *Energy Conversion and Management*, 75, 311–318. <https://doi.org/10.1016/j.enconman.2013.06.034>
- Chen S, Gooi HB, Wang MQ, 2013. Solar radiation forecast based on fuzzy logic and neural networks. *Renewable Energy*, 60, 195–201. <https://doi.org/10.1016/j.renene.2013.05.011>
- Chu Y, Pedro HTC, Coimbra CFM, 2013. Hybrid intra-hour DNI forecasts with sky image processing enhanced by stochastic learning. *Solar Energy*, 98(PC), 592–603. <https://doi.org/10.1016/j.solener.2013.10.020>
- Dong Z, Yang D, Reindl T, Walsh WM, 2013. Short-term solar irradiance forecasting using exponential smoothing state space model. *Energy*, 55, 1104–1113. <https://doi.org/10.1016/j.energy.2013.04.027>
- Eroğlu H, 2018. The Suitability Map Determination for Solar Power Plants: A Case Study. *Journal of the Institute of Science and Technology*, 8(4), 97–106. <https://doi.org/10.21597/jist.430615>
- Genç, A. 2018. Denim Kumaşın Laminasyon Teknikleriyle Fonksiyonelleştirilmesinin Araştırılması, İnönü Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi (Basılmış). <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Guermoui M, Abdelaziz R, Gairaa K, Djemoui L, Benkaciali S, 2020. New temperature-based predicting model for global solar radiation using support vector regression. *International Journal of Ambient Energy*, 1–11. <https://doi.org/10.1080/01430750.2019.1708792>
- Hocaoğlu FO, 2011. Stochastic approach for daily solar radiation modeling. *Solar Energy*, 85(2), 278–287. <https://doi.org/10.1016/j.solener.2010.12.003>
- Hocaoğlu FO, Serttas F, 2017. A novel hybrid (Mycielski-Markov) model for hourly solar radiation forecasting. *Renewable Energy*, 108, 635–643. <https://doi.org/10.1016/j.renene.2016.08.058>
- Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, Liu HH, 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995. <https://doi.org/10.1098/rspa.1998.0193>
- Ji W, Chee KC, 2011. Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN. *Solar Energy*, 85(5), 808–817. <https://doi.org/10.1016/j.solener.2011.01.013>
- Karasu S, Altan A, 2019. Recognition Model for Solar Radiation Time Series based on Random Forest with Feature Selection Approach. *ELECO 2019 - 11th International Conference on Electrical and Electronics Engineering*, 8–11. <https://doi.org/10.23919/ELECO47770.2019.8990664>
- Karasu S, Altan A, Sarac Z, Hacıoğlu R, 2017. PREDICTION OF SOLAR RADIATION BASED ON MACHINE LEARNING METHODS. In *The Journal of Cognitive Systems*, 2(1), 16-20. [www.dergipark.gov.tr/jcs](http://www.dergipark.gov.tr/jcs)
- Koç A, Yağlı H, Koç Y, Uğurlu İ, 2018. Dünyada ve Türkiye’de Enerji Görünümünün Genel Değerlendirilmesi. In *Mühendis ve Makina*, 59 (692) , 86-114. <https://dergipark.org.tr/pub/muhendismakina/issue/48388/614281>

- Kok B, Benli H, 2017. Energy diversity and nuclear energy for sustainable development in Turkey. *Renewable Energy*, 111, 870–877. <https://doi.org/10.1016/j.renene.2017.05.001>
- Lazarevska E, 2016. Neural network approach based on convex incremental learning machine for prediction of diffuse solar radiation. *International Congress on Ultra Modern Telecommunications and Control Systems and Workshops*, 2016-December, 29–36. <https://doi.org/10.1109/ICUMT.2016.7765228>
- Li FF, Wang SY, Wei JH, 2018. Long term rolling prediction model for solar radiation combining empirical mode decomposition (EMD) and artificial neural network (ANN) techniques. *Journal of Renewable and Sustainable Energy*, 10(1), 013704. <https://doi.org/10.1063/1.4999240>
- Li Q, Meng Q, Cai J, Yoshino H, Mochida A, 2009. Predicting hourly cooling load in the building: A comparison of support vector machine and different artificial neural networks. *Energy Conversion and Management*, 50(1), 90–96. <https://doi.org/10.1016/j.enconman.2008.08.033>
- Lu CJ, Lee TS, Chiu CC, 2009. Financial time series forecasting using independent component analysis and support vector regression. *Decision Support Systems*, 47(2), 115–125. <https://doi.org/10.1016/j.dss.2009.02.001>
- Lu W, Wang W, Leung AYT, Lo SM, Yuen RKK, Xu Z, Fan H, 2002. Air pollutant parameter forecasting using support vector machines. *Proceedings of the International Joint Conference on Neural Networks*, 1, 630–635. <https://doi.org/10.1109/ijcnn.2002.1005545>
- Mecibah MS, Boukelia TE, Tahtah R, Gairaa K, 2014. Introducing the best model for estimation the monthly mean daily global solar radiation on a horizontal surface (Case study: Algeria). *Renewable and Sustainable Energy Reviews*, Vol. 36, pp. 194–202. <https://doi.org/10.1016/j.rser.2014.04.054>
- Meenal R, Selvakumar AI, 2018. Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. *Renewable Energy*, 121, 324–343. <https://doi.org/10.1016/j.renene.2017.12.005>
- Mellit A, Benhanem M, Kalogirou SA, 2006. An adaptive wavelet-network model for forecasting daily total solar-radiation. *Applied Energy*, 83(7), 705–722. <https://doi.org/10.1016/j.apenergy.2005.06.003>
- Moghaddamnia A, Remesan R, Kashani MH, Mohammadi M, Han D, Piri J, 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS Models-with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71(8–9), 975–982. <https://doi.org/10.1016/j.jastp.2009.04.009>
- Mokhtarzad M, Eskandari F, Jamshidi VN, Arabasadi A, 2017. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environmental Earth Sciences*, 76(21), 1–10. <https://doi.org/10.1007/s12665-017-7064-0>
- Monjoly S, André M, Calif R, Soubdhan T, 2017. Hourly forecasting of global solar radiation based on multiscale decomposition methods: A hybrid approach. *Energy*, 119, 288–298. <https://doi.org/10.1016/j.energy.2016.11.061>
- Pelckmans K, Suykens JA, Van Gestel T, De Brabanter J, Lukas L, Hamers B, Vandewalle J, (2002). LS-SVMlab: a matlab/c toolbox for least squares support vector machines. *Tutorial. KULeuven-ESAT. Leuven, Belgium*, 142(1–2).
- Piri J, Shamshirband S, Petković D, Tong CW, Rehman MHU, 2015. Prediction of the solar radiation on the Earth using support vector regression technique. *Infrared Physics and Technology*, 68, 179–185. <https://doi.org/10.1016/j.infrared.2014.12.006>
- Rato RT, Ortigueira MD, Batista AG, 2008. On the HHT, its problems, and some solutions. *Mechanical Systems and Signal Processing*, 22(6), 1374–1394. <https://doi.org/10.1016/j.ymsp.2007.11.028>
- Sun S, Wang S, Zhang G, Zheng J, 2018. A decomposition-clustering-ensemble learning approach for solar radiation forecasting. *Solar Energy*, 163, 189–199. <https://doi.org/10.1016/j.solener.2018.02.006>
- Suykens JAK, Van GT, Brabanter JD, Moor BD, Vandewalle J, 2002. *Least Squares Support Vector Machines*. World Scientific, Singapore. Singapore: World Scientific Pub. Co.

- Trapero JR, Kourentzes N, Martin A, 2015. Short-term solar irradiation forecasting based on dynamic harmonic regression. *Energy*, 84, 289–295. <https://doi.org/10.1016/j.energy.2015.02.100>
- Vapnik V, 2013. *The nature of statistical learning theory*. Springer science & business media.
- Voyant C, Muselli M, Paoli C, Nivet ML, 2012. Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. *Energy*, 39(1), 341–355. <https://doi.org/10.1016/j.energy.2012.01.006>
- Yadav AK, Chandel SS, 2014. Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*, Vol. 33, pp. 772–781. <https://doi.org/10.1016/j.rser.2013.08.055>
- Yang D, Ye Z, Lim LHI, Dong Z, 2015. Very short term irradiance forecasting using the lasso. *Solar Energy*, 114, 314–326. <https://doi.org/10.1016/j.solener.2015.01.016>
- Yao W, Zhang C, Hao H, Wang X, Li X, 2018. A support vector machine approach to estimate global solar radiation with the influence of fog and haze. *Renewable Energy*, 128, 155–162. <https://doi.org/10.1016/j.renene.2018.05.069>