

PV Fabrikalarında Modül Hattı IV Data Verilerinin Yapay Zekâ Modelleri Kullanılarak Sınıflandırılması

İrfan YILMAZ¹, Murat ŞİMŞEK²

¹Yazılım Mühendisliği / Fen Bilimleri Enstitüsü, Ostim Teknik Üniversitesi, Türkiye

²Yapay Zeka Mühendisliği, Ostim Teknik Üniversitesi, Türkiye

¹irfaanyilmaaz@gmail.com Başlıca yazarın mail adresi

(Geliş Tarihi: 26 Nisan 2023, Kabul Tarihi: 04 May 2023)

(DOI: 10.59287/ijanser.2023.7.4.561)

ATIF/REFERENCE: Yılmaz, İ. & Şimşek, M. (2023). PV Fabrikalarında Modül Hattı IV Data Verilerinin Yapay Zekâ Modelleri Kullanılarak Sınıflandırılması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(4), 89-94.

Özet – Ülkelerin sanayi devrimiyle birlikte başlayan ekonomik kalkınma yarışı, teknolojik gelişmeler, nüfus artışı, insanların daha konforlu yaşam arzusu gibi nedenlerden dolayı özellikle son 50 yılda enerji tüketimi hızla artmıştır. Elektrik enerjisi açısından ise, sanayilere her geçen gün yeni tesislerin eklenmesi ve evlerde kullanılan elektrik enerjisinin sürekli artması, yeni enerji üretim tesislerinin kurulma ihtiyacını doğurmaktadır. Güneş enerjisi elektrik santrallerinin kurulması, bu enerji ihtiyaçlarının karşılanması açısından önem arz etmektedir. Birçok ülkede PV elektrik üretimi santrallerinin kurumları ilk dönemlerini yaşamaktadır. Ayrıca PV sistemler için doğru bir hata tespit yeteneği, işletme maliyetlerini ve bir arıza nedeniyle oluşabilecek devre dışı kalma sürelerini azaltarak PV sistemin verimliliğini artırabilir. Bu çalışmada, PV sistemler için bir hata tespit yöntemi önerilmiştir. Önerilen yöntem, topluluk öğrenmesi temelli bir modelin PV sistemlerdeki hataları sınıflandırmak amacıyla kullanılmasına dayanmaktadır. Bu faktörler göz önüne alınarak, güneş pillerinden üretilen elektrik enerjisinin kalitesi önemli ölçüde artırılabilir.

Bu çalışmada Modül Hattında üretilen paneller ortalama %98 A Class oranında üretilmektedir. IV makinesinde sınıflandırılan ve son kararı operator sağladığı kalite verimliliğini makine öğrenmesiyle ve hata oranını, verimlilik değerlerini kontrol edebilmektir. Bu proje ile hedeflenen bu ortalamaya etki eden faktörleri belirleyip, bu parametrelerin iyileştirilmesini, 6 sigma prensibi için gerekli olan istatistiksel araçları elde edilmesi, proses ve kalite süreçlerini optimize edilmesi, girdi değişkenleri ile çıktı değişkenlerinin arasındaki ilişkinin 6 sigmada sebep-sonuç ve neden-etki yapılarındaki tepkisini ölçülmesi, kalite sınıflarının testlerden sonra belirlenebileceği bir istatistiksel model kurulması, böylelikle %98 A Class kalite üretim oranının, daha yüksek bir seviyeye çıkarılması amaçlanmaktadır.

Anahtar Kelimeler – Yapay Zeka, Makine Öğrenmesi, Solar Enerji, PV-Fotovoltaik, Enerji Kalitesi

I. GİRİŞ

Günümüzde tüketilen enerjinin yaklaşık %90'nını kömür, petrol, doğalgaz gibi fosil kaynaklar oluşturmaktadır. Fosil kaynakların rezervlerinin

sınırlı olması, küresel ısınma, asit yağmurları vb. çevre ve insan sağlığına zararlı ve olumsuz etkileri nedeniyle, güneş enerjisi (basta PV sistemler olmak üzere) ve rüzgâr enerjisi gibi yenilenebilir enerji

kaynaklarına yönelmiş ve günümüzde bu tip enerji kaynaklarının kullanımı artmıştır. Bu gelişmelerin doğal bir sonucu olarak, ticari anlamda fotovoltaik enerji dönüşümüne olan ilgi ve buna bağlı olarak bu amaca yönelik cihazları üreten işletmelerin sayısı da artmıştır [1,2].

Kullanımdaki bu artışa rağmen, fotovoltaik yöntemle elektrik üretimi, henüz büyük miktarlardaki elektrik üretimi için diğer yöntemlerle rekabet edebilecek düzeyde değildir [3]. Sürekli elektriksel yük artımı güç sistemlerini kararlılık limitine yakın noktalarda çalışmaya zorlamakta ve elektrik enerji sistemlerinde önemli sorunlara yol açmaktadır [4]. Bu sınırların aşağı seviyelere çekilmesi için yeni elektrik üretim tesislerine ihtiyaç duyulmaktadır. Ayrıca, dünyadaki ve ülkemizdeki ekonomik gelişmeler, yaygın teknoloji kullanımı ve nüfus artışı nedeniyle daha fazla enerji ihtiyacı ortaya çıkmaktadır. Bu yüzden ekonomik büyüme ve sosyal gelişim için enerji önemli bir unsur haline gelmiştir [5].

Bu enerji ihtiyaçlarını karşılamak için ülkemiz yeterli doğal fosil enerji kaynaklarına sahip değildir. Bu durum, yeni enerji üretim tesislerinin nükleer ve güneş enerjisi gibi farklı kaynaklara yönelmeye yol açmaktadır. Yıl boyunca ülkemiz sürekli güneşlenme ve yoğun ışımaya sahip olduğu için [6], PV güneş elektrik santralleri bu sorunların aşılması için önemli bir enerji üretim kaynağı olarak görülebilir. PV güneş santrallerinde enerji üretimi için en önemli eleman güneş panelleridir. PV panellerde enerji kalitesini etkileyen faktörler; yüksek güneş ışınımı değerleri, güneş açısı, rüzgâr yönü ve hızı, sıcaklık, nem, hava kirliliği, güneş panelinin yüzeyinin temizliği, kullanılan PV panelin yarı iletken yapısı ve PV verimlilik oranıdır [4,6,7].

Bu çalışmada, Kalyon PV’de üretilen paneller ortalama %98 A Class oranında üretilmektedir. Bu proje ile hedeflenen bu ortalamaya etki eden faktörleri belirleyip, bu parametrelerin iyileştirilmesini sağlamaktır. Böylelikle %98 A Class kalite üretim oranının, daha yüksek bir seviyeye çıkarılması amaçlanmaktadır

II. MATERYAL VE YÖNTEM

Bu çalışmada Şekil-1 de gösterilen adımlar uygulanmıştır.

A. IV makinesinin verilerinin toplanması ve yöntem seçimi

Modül üretim fabrikasında güç ölçümü yapan IV makinesi verileri ile elde edilen çıktıların, kalite çalışanlarının manuel olarak verdiği kayıtlar kullanılarak yapılmıştır.

B. Veri Toplama

Bu çalışmada kullanılan veriler Kalyon PV Güneş Enerji Üretim AŞ tarafından panel üretim hattında IV Data olarak adlandırılan operasyonda IoT ile MES sistemi üzerinden toplanan verileri kullanılmıştır. Bu çalışmada 1 haftalık girdiler ile 1.212.859 kayıt kullanılmıştır. Öznitelikler ve açıklamaları Tablo 1’de gösterilmiştir.

Tablo 1. Veri seti öznitelikleri

No	Öznitelik	Açıklama
1	InstanceName	Kalite Değerlendirme İsmi
2	User	Kullanıcı / Değerlendiren
3	MeasStat	Değerlendirilme Durumu
4	MachStat	İşlem Durumu
5	Snr	Seri Barkod Numarası
6	Voc	Gerilim Değeri
7	Isc	Akım Değeri
8	Pmax	Güç Değeri
9	Vpmax	Maksimum Gerilim Değeri
10	Ipmax	Maksimum Akım Değeri
11	Rs	Direnç
12	Rsh	Direnç Aralığı
13	FF	Esneklik Değeri
14	Eff	Efektif Değeri
15	Tdut	Td Verimlilik
16	Tmc	Tm Verimlilik
17	Gavg	G Ortalama Değeri
18	LTI	Öğrenim Araçları Birlikte Çalışabilirliği
19	Class	Makine Kalite Sınıflandırması
20	ClassBin	Kullanıcı Kalite Sınıflandırması

C. Verilerin Temizlenmesi

Verilerin temizlenmesi adımı, aykırı değerler ile gürültülü değerlerin tespitinin yapılmasıdır. Bu tür veriler modellerin başarısını olumsuz etkileyeceğinden veri setinden

çıkartılmalıdır. Makine tarafından voltaj değeri okunmayan veriler çalışmada herhangi bir sapmaya neden olmaması için 202.344 adet kayıt silinmiştir.

Bu çalışmada kullanılan 1.212.859 adet veriler kontrol edilerek Cell Power değeri bu kayıtlardan 202.344 adet kayıt eksik ve okunmamış veriler içerdiğinden çıkarılmıştır. Temizleme sonrası 1.010.515 kayıt üzerinden analizler yapılmıştır.

D. Verinin Sayısallaştırılması

Veri, kategorik ve sayısal veriler olarak iki başlık altında incelenmektedir. Örneğin bir kişinin eğitim durumu, medeni durumu, unvanı, rütbesi, bedeni (S, M, L, XL, XXL) ve cinsiyeti gibi bilgiler kategorik veri olarak karşımıza çıkarken yine o kişinin yaşı, boyu, kilosu, günlük/aylık/yıllık alışveriş harcamaları gibi bilgiler ise sayısal değer olarak değerlendirilir.

Bu çalışmada sadece Grade özneliği için sayısallaştırma işlemi yapılmıştır.

Tablo 2. Kalite Sayısallaştırılması

Kalite Değer	Kalite Sayısal
A	1
B	2
C	3

E. Normalizasyon

Öznitelikler yapay zeka modellerine verilmeden önce normalizasyon işlemi uygulanarak özniteliklerin değer değişim aralığı 0-1 aralığına getirilmiştir.

Normalizasyon işlemi için kullanılan formül Eşitlik-1 de gösterilmiştir.

$$N(x_i) = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Normalizasyon işlemine yapmadan önce özniteliklerimizin minimum, maksimum ve ortalama değerleri hesaplanarak Tablo-3 de gösterilmiştir.

Tablo 3. Özniteliklerin min, max ve ortalama değerleri

No	Öznitelik	Min	Max	Ortalama
1	CTM	107.7	93.9	13.8
2	Cell Power	6	5	1
3	Cell Eff	22.7	20.7	2
4	Grade	3	1	2
5	Voc	50	33	17
6	Temperature	32	17	15
7	VMPP	46	26	20
8	Power Level	400	380	20
9	Class	3	1	2

Elde edilen çok sayıda verinin küçükten büyüğe, 0 (sıfır) ile 1 (bir) arasına yayılması yöntemidir. Birimleri birbirinden farklı pek çok verinin, normalize edilerek kendi içinde karşılaştırılmasını sağlayan bir yöntemdir. Özniteliklerin veri değişim aralıkları incelendiğinde birbirinden oldukça farklı olduğu görülmektedir. Bu tür bir durumda kurulacak yapay zeka modelinin başarısını etkileyeceğinden özniteliklerin aynı değer aralığına getirilmesi önemlidir.

Bu çalışmada Min Max Normalizasyon yöntemi kullanılmıştır.

F. Yapay Zeka Modellerinin Uygulanması

Bu çalışmada veri eğitimi, WEKA yazılımı kullanılmıştır. Weka Explorer v3.8.6, makine öğrenimi amacıyla Waikato Üniversitesinde geliştirilmiş ve "Waikato Environment for Knowledge Analysis" kelimelerinin baş harflerinden oluşmuş yazılımın ismidir. Günümüzde yaygın kullanımı olan çoğu makine öğrenimi algoritmalarını ve metotlarını içermektedir.

Veri eğitimi, WEKA yazılımı üzerinden, Random Forest, Random Tree, Multilayer Perceptron ve KNN algoritmaları kullanılarak Cross Validation 10Fold Test options seçeneği uygulanmıştır [19].

G. Rastgele Orman Algoritması

Rastgele Orman Algoritması, amaca uygun olarak; belirlenen ağaç sayısından meydana gelen sınıflandırma ve regresyon ağaç topluluklarından oluşmaktadır. Rastgele orman, her girdi vektöründen bağımsız olarak örneklenen rastgele bir vektör

kullanılarak oluşturulan ağaçların kombinasyonundan oluşur. Bu çalışma için kullanılan rastgele orman, bir ağacı büyütme için rastgele seçilen özelliklerin birleşiminden oluşturulmuştur. Bir sınıflandırıcı olarak rastgele orman sınıflandırma için bir “güçlü değişkenler” alt kümesi kullanarak örtük bir özelliğe seçimi gerçekleştirir ve bu durum yüksek boyutlu veriler üzerinde üstün performansa yol açar [21].

H. Karar Ağaçları Algoritması

Karar Ağaçları Algoritması, sınıfları bilinen örnek veriden tümevarım yöntemiyle öğrenilen ağaç şekilli bir karar yapısı çeşididir. Bir karar ağacı, basit karar verme adımları uygulanarak, büyük miktarlardaki kayıtları, çok küçük kayıt gruplarına bölerek kullanılan bir yapıdır. Her başarılı bölme işlemiyle, sonuç grupların üyeleri bir değeriyle çok daha benzer hale gelmektedir. Büyük veri tabanlarının kullanıldığı pek çok sınıflama probleminde ve karmaşık ya da hata içeren bilgilerde karar ağaçları yararlı bir çözüm olmaktadır. Tahmin edici ve tanımlayıcı özelliklere sahip olan karar ağaçları, Veri Madenciliğinde kuruluşların kolay olması, yorumlarının kolay olması, veri tabanı sistemlerine kolayca entegre edilebilmeleri, güvenilirliklerinin daha iyi olması nedenleri ile sınıflandırma modelleri içerisinde en yaygın kullanıma sahip olan bir tekniktir [22].

i. KNN Algoritması

KNN en yakın komşu algoritması olarak bilinir. KNN sınıflandırıcısı, etiketli veri seti üzerinden sınıflandırılacak X örneğine en yakın ‘K’ tanesini belirleyerek sınıflandırma yapar. K değeri kadar eleman incelenir. Bir değer geldiğinde en yakın K kadar eleman alınarak gelen değer arasındaki uzaklık hesaplanır. Uzaklık hesaplama işlemi genelde Öklid fonksiyonu kullanılır. Yapılan Öklid uzaklığı hesabında en yakın değere sahip K tane elemanın sınıfına bakılıp en çok hangi sınıfta eleman mevcutsa ona göre sınıflama yapar[23].

J. Çok Katmanlı Algılayıcılar Algoritması

Çok katmanlı algılayıcılar (Multilayer Perceptron), olarak adlandırılan basit sinir hücreleri

ağdır. Perceptron birçok değeri girdi olarak alıp tek bir çıktı üretir. Çıktıyı oluştururken girdi ağırlıklarına uygun olarak bir lineer kombinasyon oluşturulur ve bazı lineer olmayan etkinleştirme fonksiyonu yoluyla çıktılara yerleştirilir. Matematiksel olarak elverişli oldukları için genelde bu fonksiyonlar kullanılır. Bu yapı çok katmanlı perceptrons ağırları güçlü ve doğrusal olmayan eşleştirmeleri modellemeyi sağlar. Sınırlı sayıda eşleştirme olanak sağladığı için tek perceptron kullanışlı bir yöntem değildir. Çok katmanlı perceptron girdi, gizli ve çıktı katmanlarından oluşur. İşlemler ağda adım adım yürütülür [24]. Şekil-1’de modellerin kurulması sırasında uygulanan adımlar yer almaktadır.



Şekil 1. Modellerin kurulması sırasında uygulanan adımlar

III. BULGULAR

Üretim hatlarında kalite sınıflandırmanın kalite sorumluları tarafından gözle ve manuel olarak müdahale edilmesinden kaynaklı hata tespitleri edinilmiştir. Bu tespitlerin çeşitli departmanların ve satış sonrasında etkilerine olumsuz etkileri ile karşılaşılmıştır. Endüstri 4.0 dünyasında yaşanan manuel sınıflandırmanın otomasyonla süreçlerinin destekleri beraberinde iyileştirme etkilerini ortaya koymaktadır.

IV. TARTIŞMA

Araştırma ve çalışma bulgularına göre üretim fabrikalarında mevcut panellerin içerisinde hataya yer verebilecek kalite sınıflandırma hatası nedeniyle günlük üretim kalite oranında olumsuz bir etki yarattığı ve bu sürecin iyileştirilmesi ile üretim etkilerini pozitif yönde etkilediğini tespit ettik. Bununla beraber karşılaştığımız nitelikli personellerin yetiştirilmesi de çok önemli bir yer almaktadır. Güneş enerji üretiminde hammadde kalitesinin tüm süreçlerinde etkileri büyüktür. Bu etkilerin sonuçlarının nihai karar aşamasında güç sınıflandırmasında etkisi büyük bir oran tutmaktadır. Beklentiyi karşılayan bir tespit olduğu görülmektedir. Yapılan analizler de hatalı verilen

kararların önüne geçilmesiyle hammaddenin toplam verimlilik oranına göre kalitenin iv güç değerine etkisi büyük bir şekilde doğrudan etkisi sağlanmalıdır. Bulgular sonucunda iv değerinin otomasyon sürecinde işlenmesi uyumlu olduğu tespit edilmiştir. Bu çalışmadan sonra yapılması gereken çalışma makine öğrenmesi ile makine sınıflandırmasına uygunluk ve uygulanabilirlik seviyesini ölçme olacaktır. Bu çalışma ile hata tipleri ve güç farklılıklarının öğrenilmesi ile en minimum sapma ile güç sınıflandırması ve kümelenme oluşturmaktır.

V. SONUÇLAR

Bu çalışmada kullanılan veriler Kalyon PV Güneş Enerji Üretim AŞ tarafından üretim hattında IV Data olarak adlandırılan operasyon tarafından toplanan verileri kullanılmıştır. Veriler MES (Manufacturing Executing System) olarak adlandırılan üretim yönetim sistemi tarafından makinelerden IOT olarak toplanmaktadır.

Bu çalışmada 1.010.515 adet satır veriden ve 1 adet çıkış değerinden faydalanarak, kullanılan modellerde en yüksek başarıyı Random Forest Modeli ile %99,32 sonucu elde edilmiştir.

TEŞEKKÜR

Araştırma uygulama aşamasında yardımlarını esirgemeyen Kalyon PV Bilgi Teknolojileri Müdürü Şevket AYGÜMÜŞ beyefendiye, araştırma her aşamasında yardımlarını esirgemeyen değerli öğretim danışmanım Dr. Öğr. Üyesi Murat ŞİMŞEK beyefendiye teşekkürlerimi borç bilirim.

KAYNAKLAR

[1] T, S., & R, P. (2015). Maximum Solar Power Generation through Optimization of Tilt Solar Angles of Solar Panels by Heuristic Technique. *IJIREICE*,3(4),43–49.

[2] Muntasser, M. A., Bara, M. F., Quadri, H. A., El-Tarabelsi, R., & La-azebi, I. F. (2000). Photovoltaic marketing in developing countries. *Applied Energy*, 65(1–4), 67–72.

[3] Li, D. H. W., Cheung, G. H. W., & Lam, J. C. (2005). Analysis of the operational performance and efficiency characteristic for photovoltaic system in Hong Kong. *Energy Conversion and Management*, 46(7–8),1107–1118.

[4] Wiszniewski, Andrzej. (2007). New Criteria of Voltage Stability Margin for the Purpose of Load Shedding. *Power Delivery*, IEEE Transactions on. 22. 1367 - 1371. 10.1109/TPWRD.2006.886772.

[5] Han, J., Kamber, M., & Pei, J. (2011). *Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems)*.

[6] A., B. N., & A., A. D. (2014). Studies of Contingencies in Power Systems through a Geometric Parameterization Technique, Part II: Performance Evaluation. *World Journal Control Science and Engineering*, 2(1), 25–34.

[7] Diaf, S., Notton, G., Belhamel, M., Haddadi, M., & Louche, A. (2008). Design and techno-economical optimization for hybrid PV/wind system under various meteorological conditions. *Applied Energy*, 85(10),968–987.

[8] Kaldellis, J. K., Kapsali, M., & Kavadias, K. A. (2014). Temperature and wind speed impact on the efficiency of PV installations. Experience obtained from outdoor measurements in Greece. *Renewable Energy*,66,612–624.

[9] Makrides, George & Zinsser, Bastian & Phinikarides, Alexander & Schubert, Markus & Georghiou, George. (2012). Temperature and thermal annealing effects on different PV technologies. *Renewable Energy*. 43. 407-417. 10.1016/j.renene.2011.11.046.

[10] Gupta, B., Sonkar, N., Singh Bhalavi, B., & Edla, P. J. (2013). Design, Construction and Effectiveness Analysis of Hybrid Automatic Solar Tracking System for Amorphous and Crystalline Solar Cells. *American Journal of Engineering Research (AJER)*, 02(10), 221–228.

[11] Ghazi, S., & Ip, K. (2014). The effect of weather conditions on the efficiency of PV panels in the southeast of UK. *Renewable Energy*, 69, 50–59.

[12] Kaldellis, John & Kokala, A.. (2010). Quantifying the decrease of the photovoltaic panels' energy yield due to phenomena of natural air pollution disposal. *Energy*.35.4862-869.10.1016/j.energy.2010.09.002.

[13] KÖSE, E. (2018). Fotovoltaik Sistemlerin Sıcaklığa Bağlı Enerji Verimliliği Performansının Analiz Edilmesi. *Dünya Multidisipliner Araştırmalar Dergisi*,2018(2),39–53.

[14] Basaran, Kivanç & Çetin, Numan & Çelik, Hakan. (2011). Ruzgar-Gunes Hibrid Güç Sistemi Tasarımı ve Uygulaması (Wind-Solar Hybrid Power System Design and Implementation).

[15] M. G. Villalva, J. R. Gazoli and E. R. Filho, "Modeling and circuit-based simulation of photovoltaic arrays," 2009 Brazilian Power Electronics Conference, 2009, pp. 1244-1254, doi: 10.1109/COBEP.2009.5347680.

[16] AKBULUT, A., & DİKİCİ, A. (2004). ELAZIĞ İLİ'NİN RÜZGAR VE GÜNEŞ ENERJİSİ POTANSİYELİ. *Fırat Üniversitesi Doğu Araştırmaları Dergisi*, 2(2), 42–47.

[17] ALCAN, Y., DEMİR, M., & DUMAN, S. (2018). Sinop İlinin Güneş Enerjisinden Elektrik Üretim Potansiyelinin Ülkemiz Ve Almanya İle Karşılaştırarak İncelenmesi. *El-Cezeri Fen ve Mühendislik Dergisi*, 5(1), 35–44.

[18] Ju, Z., Lin, Y., Chen, B., Wu, H., Chen, M., & Xu, Q. (2022). Electromagnetic radiation induced non-chaotic behaviors in a Wilson neuron model. *Chinese Journal of Physics*, 77, 214–222.

[19] B. M. Patil, D. Toshniwal and R. C. Joshi, "Predicting Burn Patient Survivability Using Decision Tree In WEKA Environment," 2009 IEEE International Advance Computing Conference, 2009, pp. 1353-1356, doi:10.1109/IADCC.2009.4809213.

- [20] KÖSE, E. (2018). Fotovoltaik Sistemlerin Sıcaklığa Bağlı Enerji Verimliliği Performansının Analiz Edilmesi. *Dünya Multidisipliner Araştırmalar Dergisi*, 2018(2), 39–53.
- [21] Zhou, Q., Lan, W., Zhou, Y., & Mo, G. (2020). *Effectiveness Evaluation of Anti-bird Devices based on Random Forest Algorithm; Effectiveness Evaluation of Anti-bird Devices based on Random Forest Algorithm*.
- [22] Wang, Z. Y., Lu, C., & Zhou, B. (2018). Fault diagnosis for rotary machinery with selective ensemble neural networks. *Mechanical Systems and Signal Processing*, 113, 112–130.
- [23] Yiğit, E., Özkaya, U., Öztürk, Ş., Singh, D., & Gritli, H. (2021). Automatic detection of power quality disturbance using convolutional neural network structure with gated recurrent unit. *Mobile Information Systems*, 2021, 1-11.
- [24] Pierro, M., Bucci, F., de Felice, M., Maggioni, E., Moser, D., Perotto, A., Spada, F., & Cornaro, C. (2016).