

## Halojensiz ve alev geciktiricili (HFFR) polimerik kompozit kılıflı kablo kopma uzaması test sonuçlarının makine öğrenmesi yöntemleri kullanılarak tahmin edilmesi

### Prediction of halogen-free and flame retardant (HFFR) polymeric composite sheathed cable elongation test results using machine learning methods

İsmail KIYICI<sup>1</sup>, İbrahim DORUK<sup>2\*</sup>, Emre ÇOMAK<sup>3</sup>, Murat KAÇAMAZ<sup>1</sup>, Ragıp Onur BAKLAN<sup>1</sup>

<sup>1</sup>Seval Kablo, AR-GE Merkezi, Denizli, Türkiye.

ismailkiyici@sevalkablo.com, muratkacamaz@sevalkablo.com, onurbaklan@sevalkablo.com

<sup>2</sup>Makine ve Metal Teknolojileri Bölümü, Aydın Meslek Yüksekokulu, Aydın Adnan Menderes Üniversitesi, Aydın Türkiye.  
ibrahim.doruk@adu.edu.tr

<sup>3</sup>Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Burdur Mehmet Akif Ersoy Üniversitesi, Burdur, Türkiye.  
ecomak@mehmetakif.edu.tr

Geliş Tarihi/Received: 12.04.2021

Düzeltilme Tarihi/Revision: 04.09.2021

doi: 10.5505/pajes.2021.76824

Kabul Tarihi/Accepted: 07.10.2021

Araştırma Makalesi/Research Article

#### Öz

Son zamanlarda yapay zekâ (YZ) tekniklerinin farklı alanlarda kullanımı ile ilgili artan bir ilgi vardır. Bu çalışmada, halojen içermeyen alev geciktiricili (HFFR) kablolarda, kablo kılıf malzemelerinin mekanik özelliklerinden olan kopma uzamasının tahmin edilmesinde farklı makine öğrenmesi algoritmalarının (MÖA) kullanımı amaçlanmıştır. Geliştirilen tahmin modellerinde kullanılmak amacı ile numunelere çekme deneyi uygulanmış, yüzde uzama değerleri tespit edilmiştir. Elde edilen deney sonuçları farklı yapay zekâ tahmin modellerinde kullanılmıştır. HFFR kablo numunelerinden elde edilen sınırlı sayıda veri ile destek vektör makinesi (DVM), yapay sinir ağları (YSA) yöntemlerinin mutlak yüzdesel hataları oldukça kabul edilebilir seviyede elde edilmiştir. Bu metotlar ile elde edilen tahminler, ek olarak MS Excel programı ile regresyon analizi yapılarak elde edilen tahminlerin verileri ile karşılaştırılmıştır. Elde edilen istatistiksel sonuçlara göre, bu alanda DVM ve YSA'nın kullanımı ile başarılı tahmin oranı %87,5, gerçekleştirilen tahminler için başarı oranı ortalama %92 elde edilmiştir. Bu alanda MÖA'nın kullanılması, deneme yanılma yöntemi ile yapılan üretimlerde oluşan belirsizliği büyük oranda sonlandıracak ve başarısız üretim oranını azaltacaktır.

**Anahtar kelimeler:** Makine öğrenmesi, Yapay sinir ağları, Destek vektör makinesi, Regresyon, HFFR kablo, Polimerik kompozit.

#### Abstract

Recently, there has been an increasing interest in the use of artificial intelligence techniques in different fields. In this work is aimed to use different machine learning algorithms (MLA) to predict the elongation at break from the mechanical properties of cable sheath materials in halogen-free flame retardant (HFFR) cables. In order to be used in the developed prediction models, tensile test was applied to the samples and the percent elongation values were determined. Obtained experimental results were used in different artificial intelligence prediction models. Absolute percentage errors of support vector machine (SVM) and artificial neural network (ANN) methods were obtained at a quite acceptable level with a limited number of data obtained from HFFR cable samples. The estimations obtained by these methods were compared with the data of the estimations obtained by performing regression analysis with the MS Excel program. According to the statistical results, with the use of SVM and ANN in this area, the successful prediction rate was 87.5%, and the average success rate for the predictions made was 92%. The use of MLA in this area will largely end the uncertainty in the trial and error production and reduce the rate of unsuccessful production.

**Keywords:** Machine learning, Artificial neural network, Support vector machine, Regression, HFFR cable, Polymeric composite.

## 1 Giriş

Elektrik kabloları; enerji, telekom, haberleşme, alarm ve anten vb. alanlarda güç aktarımı ve veri transferi için kullanılırlar. Elektrik kabloları, bakır veya alüminyum iletken etrafına polimer malzemenin kaplanması ile üretilir. Bu yalıtkan polimer malzemenin cinsi, kaplama kalınlığı ve şekli kablounun kullanım yeri ve çalışma gerilimine göre değişkenlik gösterir.

Kablo yalıtım malzemesi olarak kullanılan polimer bazı malzemenin kablo ekstrüderlerinde iletken etrafına kaplanması işlemi ekstrüzyon olarak bilinmektedir. Plastik ekstrüzyonunu etkileyen bazı unsurlar bulunmaktadır. Bunlar; hammadde kalitesi, ekstrüder tasarımı ve ekstrüder üretim parametreleridir. Makine tasarımı ve hammadde kalitesi

fabrika koşullarında sabit olarak kabul edilirse geriye iyileştirilebilecek üretim parametreleri kalmaktadır.

Kabloların kullanım yeri ve amacına göre elektriksel, fiziksel ve kimyasal dayanımları vardır ve bunlar uluslararası standartlar ile belirlenir. Standartları sağlayıp sağlamadığının tespiti için test edilmesi gerekmektedir. Bu testleri; elektrik, yangın, kimyasal ve mekaniksel olarak gruplandırabiliriz. Bu test sonuçları hammadde kalitesine ve kabloların üretim parametrelerine bağlıdır. Bu parametreler günümüzde kablo üreticileri tarafından deneme yanılma yöntemiyle belirlenmektedir [1].

Her endüstri alanında olduğu gibi kablo endüstrisindeki rekabet göz önüne alındığında, ekstrüzyon için üretim parametrelerinin belirlenmesinde deneme yanılma yaklaşımını kullanmak artık verimli değildir. Ayrıca bazen denemeler

\*Yazışılan yazar/Corresponding author

tamamen olumsuz olarak sonuçlanmaktadır. Çünkü ortaya çıkacak sonuç kablo yalıtım malzemesinin optimizasyonu olmaksızın üretim sorumlusunun geçmiş deneyimlerine dayalı tahminlere bağlıdır. Bu durum kalite sorunlarına, yüksek maliyete, zaman ve enerji kaybına neden olmaktadır.

İşlemdaki parametre ayarları genellikle referanslara veya el kitaplarına göre seçilir. Daha sonra, istenen çıktıyı elde etmek için deneme yanılma çalışmaları gerekir. İstatistiksel ve optimizasyon teknikleri kullanılırsa, daha düşük üretim maliyeti, daha kısa geliştirme süresi, kusurlarda azalma ve verimlilikte artış elde edilebilir [2].

Bileşimi optimize etmenin yolu, kompozit bileşenlerinin bitmiş ürününün fiziksel ve mekanik özellikleri üzerindeki etkisini araştırmak ve ardından optimum bileşimi seçmektir. Kompozitlerin bileşenleri ile ortaya çıkan özellikler arasındaki ilişki doğrusal değildir [3]. Kablo üretimi de, süreç boyunca dinamik bir davranış sergilediği için doğrusal olmayan tipte bir süreç olarak sınıflandırılabilir [4].

PVC polimerik filmlerin çekme mukavemeti, süneklik ve yoğunluk özellikleri Yapay Sinir Ağları (YSA) ile başarı ile tahmin edilebilmektedir [2],[3]. Yapılan diğer çalışmalarda YSA ile öngörülmesi kontrol modeli kablo et kalınlıklarının kontrolünde kullanılmıştır [5],[6]. Adesanya ve diğ. Çok katmanlı YSA modeline Bayesian düzenleme eğitim algoritması uygulanarak polietilen kablo üretim hatlarında ekstrüzyon proses parametrelerinin tahmini üzerine çalışılmıştır. Ayrıca, PVC termoplastik kablo ekstrüzyonunun proses parametrelerini tahmin etmek için YSA üzerinde denetimli öğrenme metodu ile Levenberg Marquardt eğitim algoritması kullanılmıştır [8]. YSA, en yakın komşu regresyonu, karar ağacı gibi farklı MÖA ile polimer filmlerin mekanik özellikleri tahmin edilmiştir [9]. En yakın komşu regresyonu, doğrusal regresyon ve Destek Vektör Makinası (DVM) yöntemleri kullanılarak ekstrüzyon ile üretilmiş bir tüpün iç ve dış çapları tahmininde kullanılmıştır ve geopolymerler üzerinde YSA yöntemi ile basınç dayanımı tahmin edilmiştir [10],[11]. Nguyen ve diğ. Kompozitler de dahil farklı yapı malzemelerinin mekanik özelliklerinin ve yangın performansının belirlenmesi için standart ve ampirik yöntemler yerine YSA ve regresyon yöntemleri kullanılmıştır.

Bu makale, Yapay Zekanın bir dalı olan Makine Öğrenmesi yöntemlerinden olan Yapay Sinir Ağı ve Destek Vektör Makinesi ile Yapı Malzemeleri Yönetmeliği'ne (CPR) uygun halojen içermeyen ve alev geciktiricili (HFFR) kablo üretiminin doğrusal olmayan hammadde parametrelerinin modellenerek kablo mekanik özelliklerinin üretim öncesinde tahmini ve iyileştirilmesi üzerine yeni bir yöntem sunmaktadır.

Çalışmada elde edilen ilk veriler ve sonuçlar özet bildiri olarak ICENTE 2020'de sunulmuştur [13]. Bu çalışmada, özet bildiriye sunulandan farklı olarak veri seti artırılmış ve daha yüksek tahmin başarısı elde edilmiştir. Ayrıca aynı hammaddelerin farklı oranlarda kullanıldığı farklı bir ürün için de deney sonucu tahmini eklenmiştir. Bu tahminlerin performansını kıyaslamak için DVM ve YSA'ya ek olarak MS Excel üzerinden regresyon ile tahmin işlemi yapılmıştır.

## 2 Malzeme ve metot

### 2.1 Kablo ekstrüzyonu

Ekstrüzyon işlemi, bir ucunda besleme hunisi olan ve hammaddenin belirli bir sıcaklık ve basınç altında vida boyunca hareket ettirildiği ve bir kalıptan dışarı itildiği bir üretim tekniğidir. Ekstrüzyon, gıda, metal, cam ve plastiklerin

endüstriyel koşullarda istenilen şekillerde üretilmesini sağlayan bir yöntemdir. Ekstrüzyon; paketlenme, kutu, şişe, kablo ve çeşitli araç gereç parçalarının üretilmesinde kullanılır. Ekstrüzyon işlemi oldukça karmaşık üretim parametreleri olan yüksek miktarda enerji tüketen, yüksek hızlarda ve yüksek üretim kapasitesine sahiptir.

Polimerik malzemeler; yüksek sıcaklık ve kimyasallara karşı dirençli, iletken olmama, yüksek netlik, yeniden işlenebilirlik, düşük maliyet vb. gibi özelliklere sahiptir. Genellikle, polimer ekstrüzyonu öngörülemez bir işlemdir ve bu nedenle doğadaki dalgalanmalara oldukça yatkındır. Dahası, işlem parametreleri birbirine karmaşık bir şekilde bağlıdır ve bu nedenle ayarlanması ve kontrol edilmesi zordur [14].

Kablo imalatında iletken polimer malzeme ekstrüzyon ile kaplanarak elektriksel yalıtıklık sağlanır. Kablonun kullanım yerine göre değişen bu yalıtık izolasyon plastiğinin üretim parametreleri kablo üreticileri tarafından deneme yanılma yöntemiyle iyileştirilerek günümüze kadar gelmiştir.

### 2.2 Halojen içermeyen alev geciktiricili kablo imalatı


Tesisat ve enerji kabloların dış kısmında kullanılan plastik yalıtık malzemeler olası bir yangın durumunda hem yangının ilerlemesine neden olur hem de ortaya çıkan zehirli gazlar canlılara ve binaya zarar verir.

Özel bir kablo türü olan halojen içermeyen ve alev geciktiricili kabloların kılıf malzemesinin üretiminde kullanılan hammaddeler halojen madde içermez ve alev geciktirici katkı maddeleri içerir. Halojenler, periyodik tablonun 7A grubunda bulunan (Örn: F, Cl, Br) ametallerdir. PVC kabloların aksine, HFFR kablolar yandığında zehirli gaz ortaya çıkmaz, sadece su ve karbondioksit oluşur. Yangın esnasında düşük duman yoğunluğu özelliği ile zehirlenmelere neden olmaz ve görüş kabiliyeti azalmadığı için tahliye daha kolay gerçekleşir. HFFR kablolar alışveriş merkezi, hastane, otel, sinema, metro, ofis gibi iç mekanlarda ve yangın güvenliğini sağlayacak alarm, ikaz, iklimlendirme, asansör sistemlerinde kullanılır.

Yangın esnasında alevler her ne kadar çok yüksek sıcaklık değerlerine ulaşsa da "ölümlerin büyük bir çoğunluğunun ise dumanla oluşan gaz zehirlenmelerinden kaynaklandığı saptanmıştır. Avrupa'da her sene, yangın nedeniyle oluşan gaz ve dumandan dolayı yaklaşık 30.000 kişi hayatını kaybetmektedir. Yine yapılan istatistiksel araştırmalarda, yangın esnasında zehirli gazların etkilerinden dolayı ölenlerin, yanarak ölenlerin oranından iki kat fazla olduğu belirlenmiştir" [15].

### 2.3 Kablo mekanik özelliklerinin belirlenmesi

Kablo kılıfının mekaniksel testleri uluslararası kablo üreticileri ve ülkelerin standart belirleme kuruluşları tarafından kabul görmüş International Electrotechnical Commission tarafından IEC 60811-1-1 standardı ile belirlenmiştir [16]. Bu standart numune alma ve test metodunu belirlemektedir. Kablo iletken ve yalıtık kısımları Şekil 1'de belirtildiği gibi numune kablo kılıfından boylamasına alınır.




Şekil 1. Kablodan numune alma (IEC 60811-1-1).

Figure 1. Taking samples from cable (IEC 60811-1-1).

İlgili standartta belirtilen ölçülere sahip numune aparat ile çıkarılacaktır. Bu numune 75 mm uzunluğunda, 1 mm kalınlığında, eni 12.5 mm ve orta bölgedeki ince kısmının eni 4 mm'dir.

Kablodan alınan numunenin ölçüleri IEC 60811-1-1 standardında belirtilmiş olup Şekil 2'de görsel olarak tanımlanmıştır. Örnek bir kaşık numune Şekil 3'te görülmektedir.



Şekil 2. Numune ölçüleri (IEC 60811-1-1).

Figure 2. Sample dimensions (IEC 60811-1-1).



Şekil 3. Numune.

Figure 3. Sample.

Kablodan alınan numunelerin mekanik özellikleri, Şekil 4'te görülen Zwick Roell Z050 test makinasında uzama ve mukavemet testleri ile karakterize edildi. Ölçüm yapılacak her bir kablodan farklı yerlerinden alınan 10 numune ile testler gerçekleştirildi. Numune boyutları standartta belirtildiği gibi kaşık (halter veya dambıl) şeklinde kablo üzerinden numune hazırlama cihazı yardımıyla alındı.



Şekil 4. Zwick test cihazında test

Figure 4. Testing at Zwick test machine

### 2.3.1 Yüzde kopma uzaması

Kopma noktasında deney parçasının referans uzunluğundaki artışın, gerilmemiş deney parçasının referans uzunluğunun yüzdesi olarak ifadesi olup Eşitlik (1)'de verilen formül ile bulunur.

$$\Delta L = \frac{L_{(sonra)} - L_{(önce)}}{L_{(önce)}} * \%100 \quad (1)$$

$L_{(önce)}$  : Numunenin test öncesi boyu,

$L_{(sonra)}$  : Numunenin test sonrası boyu.

### 2.4 Test yöntemi ve sonuçlarının değerlendirilmesi

Çekme deneyleri Seval Kablo Ar-Ge Merkezi'nde bulunan Zwick Roell Z050 çekme cihazında gerçekleştirilmiştir. Çekme mukavemeti ve yüzde kopma uzaması için kaydedilen test sonuçlarından anlamlı sonuçlar almak, önceki ve sonraki testler ile değerlendirmek için sonuçların ortanca (median) değerleri alınmıştır.

### 2.5 Çalışmada kullanılan makine öğrenmesi metotları

Araştırmacılar, özellikle mekanik olarak doğru bir şekilde yorumlanamayan doğrusal olmayan bir süreçle uğraşırken, hassaslık ve doğruluk gerektiren süreçlerle başa çıkmak için yeni bir yöntem olarak yapay zekayı keşfettiler. Yapay zeka yöntemlerinin doğrusal olmayan herhangi bir sürekli fonksiyona yaklaşabilmektedir [4].

#### 2.5.1 Yapay sinir ağları

"Tıpkı insan beyninde bulunan nöronlarda olduğu gibi yapay sinir ağları öğrenme becerisine sahiptir. İnsan beyninde öğrenme işlemi tekrarlanan olaylar sonrasında nöronlar arasındaki sinaps bağlantılarının güçlenmesi, zayıflaması veya başka nöronlarla yeni bağlantılar kurması ile gerçekleşir. YSA bu durumu taklit ederek girdi olarak sunulan verilerin zaman içerisinde nöronlar arasındaki bağlantı ağırlıklarını değiştirerek öğrenme faaliyetini en az hatayla gerçekleştirmeye çalışır"[17].

YSA ile ilgili teknikler, yapı ve biyolojik aktivite arasındaki ilişkilerin modellenmesi, bileşik sınıflarının sınıflandırılması, ilaç hedeflerinin belirlenmesi, çeşitli fiziko-kimyasal özelliklerin tahmin edilmesi gibi veri analizi için kimyasal çalışmalarda 2000'li yıllardan günümüze kadar giderek daha fazla kullanılmaktadır. YSA tekniklerinin kimyasal problemlerde temel amacı, örneklerden öğrenmeye dayalı karmaşık girdi-çıkış ilişkileri için modeller oluşturarak bu modelleri tahmin çalışmalarında kullanmaktır [18]. YSA, daha genel olarak örüntü tanıma, zaman serisi tahmini, sınıflandırma ve fonksiyona yakınsama gibi problemlerin çözümünde kullanılır [19].

Eşitlik (2) ve (3) kullanılarak, öncelikle giriş verisi a vektör şeklinde ifade edilip w ağırlık vektörü ile çarpılır. Bu çarpımların toplamı değerine de bağlantı ağırlığı eklenerek ağırlıklı toplam hesaplanır. Sonra ağırlıklı toplam değeri etkinleştirme fonksiyonuna giriş olarak alınır ve fonksiyonunun verdiği değer, Yapay Sinir Hücresi (YSH)'nin çıkış değeri olarak ifade edilir.

$$in_j = \sum_{i=1}^n w_{ij} a_i + w_{0j} \quad (2)$$

$$a_j = g(in_j) \quad (3)$$

Çok sayıda YSH'nin belirli bir düzende bir araya getirilmesiyle YSA oluşturulur. Bu düzene YSA mimarisi denir. YSA'nın giriş verilerine göre öğrenme faaliyetini yerine getirebilmesi için, w ağırlık değerlerini değiştirerek problem çözümüne en uygun w değerlerine ulaşması gerekir. Bu işlem YSA'nın öğrenme algoritması olarak bilinir. YSA'nın başarısı, YSA mimarisi ve YSA öğrenme algoritmasına bağlı olarak değişmektedir [20].

#### 2.5.2 Destek vektör makineleri

DVM yöntemi Cortes ve Vapnik tarafından 1995 yılında sınıflandırma türü problemlerin çözümü için tasarlanmıştır [21]. Alternatif yöntemlere göre artıları; küçük veri

kümeleriyle, doğrusal olmayan verilerle ve yüksek boyutlu verilerle daha başarılı çalışabilmektedir [22].

$$w^T \cdot x + b = 0 \quad (4)$$

DVM Eşitlik (4)'te verilen ayırıcı düzlemi kurar. Bu düzlem iki sınıfı birbirlerinden ayıran yapıdır. Giriş veri kümesi  $(x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)$  şeklinde ifade edilir. Burada  $x$  giriş değerlerini içeren vektör,  $y$  -1 veya +1 değerini alan sınıf etiketi ve  $L$  veri sayısıdır. Eşitlik (4) ile gösterilebilen çok sayıda düzlem mevcuttur. İki sınıf etiketi arasında etiketsiz bölge bulunur. DVM çok sayıda düzlem arasında bu etiketsiz bölgenin genişliğini en büyük yapacak düzlemi bulur.

DVM istatistiksel öğrenme teorisine dayanmaktadır ve doğrusal olarak ayrılabilir nesnelere sınıflandırılması için tanımlanmıştır [23]. Ancak, çekirdek (*kernel*) fonksiyonlarını kullanarak doğrusal olmayan uzaydan çok boyutlu doğrusal uzaya geçiş yapar ve böylece doğrusal olmayan problemleri de çözebilir. DVM sınıflandırmada kullanılmasının yanı sıra sürekli bir tahmin işlemi gerçekleştirerek sınıflandırma probleminin bir genellemesini oluşturduğu için regresyon işlemine uyum sağlar.

Bu çalışmada kullanacağımız iki yöntemden biri olan Sequential Minimal Optimisation (SMO) yaklaşımı, DVM yönteminde regresyon işlemi uygulayan bir algoritmadır. SMO, esas itibarıyla DVM kullanan bir algoritmadır. SMO algoritması, ortak optimizasyon için kullanılan mevcut iki dizini temel olarak düzeltir [24],[25].

### 2.5.3 Regresyon

Regresyon, bir ya da daha çok değişken arasındaki ilişkiyi belirlemek ve bunu matematiksel olarak tanımlayabilmek için kullanılan istatistiksel bir yöntemdir. Bu yöntem ile önceki verilerden elde edilen regresyon denklemi tahmin edilmek istenen verilere uygulanarak tahmini bir çıkış elde edilebilir. Regresyon denklemi için kullanılan denklem Eşitlik (5)'de görülmektedir. [26]-[28].

$$Y = \beta_0 + \beta_1 \cdot X_1 + \dots + \beta_n \cdot X_n \quad (5)$$

### 2.6 Uygulanan metot

Üç farklı metot ile yapılan tahminlerde, iki farklı karakteristikte olan formüllerde ayrı ayrı sekiz deneyin sonuçları ve üretim parametreleri kullanılmıştır. Elde bulunan kısıtlı veri nedeniyle MÖA'larında tahmin için kullanılan genel yaklaşımdan farklı bir yol izlenmiştir. Tahmin edilecek deney hariç diğer yedi deney ve üretim verileri ele alınarak tahmin gerçekleştirilmiştir. Üç yöntem için de, uygulanan sekiz tahminde elde bulunan sekiz deney ve üretim verisinden sıralı olarak biri MÖA'sının öğrenme aşamasında eğitim verisi olarak kullanılmamış, test verisi olarak kullanılmıştır. Böylece, test verisi oranı 1/8'dir.

Her iki formül için oluşturulan veri setlerinde ki deney sonuçları aynı anda üretilen kablunun farklı noktalarından alınan 10'ar adet farklı numune için yapılan test sonuçlarının ortanca değeridir. Her iki formül denemesi içinde kendi içlerinde 8'er adet deneme yapılmıştır ve dolayısıyla her iki formül denemesi için de 80'er adet olmak üzere bu makalede yer alan test sonuçlarının oluşması için toplam 160 adet deney yapılmıştır.

Bu çalışmada üretimde kullanılan hammadde miktarlarına min-max normalizasyon metodu uygulanmış ve veri seti değerleri 0 ile 1 arasında normalize edilmiştir ve Tablo 1'de verilmiştir. Böylece hammadde verilerinin gizliliği sağlanarak paylaşılmıştır. Üretim parametreleri Eşitlik (6) ile normalize edilmiştir.

$$Z_{(i)} = \frac{X_{(i)} - X_{(min)}}{X_{(max)} - X_{(min)}} \quad (6)$$

$Z_{(i)}$  : Normalize edilmiş sayı,

$X_{(i)}$  : Normalize olacak sayı,


$X_{(min)}$  : Veri setindeki bulunan en küçük sayı,

$X_{(max)}$  : Veri setinde bulunan en büyük sayı.

Normalize edilen değerlerden oluşturulan veri seti Weka programı ile YSA ve DVM yöntemleri ile analiz edilerek tahmin çalışması yürütülmüştür. Test sonuçlarını WEKA programında tahmin edebilmek için ARFF (Attribute Relation File Format) uzantılı dosya içine veriler kayıt edilmiştir.

Sonrasında eğitim ve test verileri kullanılarak WEKA programında DVM metodu kullanılarak SMOreg kütüphanesi ve polynomial kernel fonksiyonu ile Formül-1 (F-1) ve Formül-2 (F-2) için uzama değerleri tahmin edilmiştir.

F-1 için WEKA programında YSA yönteminde MLP (Multi Layer Perceptron) tekniği ile öğrenme oranı (learning rate) 0.5, momentum 0.3, 12 girişli, gizli katmanda 7 hücreli, tek çıkışı olan ve eğitim sayısı (training time) 500 olan bir YSA kullanılarak sonuçlar tahmin edilmiştir. Aktivasyon fonksiyonu için Eşitlik (7) ile belirtilen sigmoid fonksiyon kullanılmıştır. Oluşturulan YSA Şekil 5'te görülmektedir.




Şekil 5. F-1 için tahmin de kullanılan YSA.

Figure 5. ANN used in prediction for F-1.

F-2 için WEKA programında YSA yönteminde MLP (Multi Layer Perceptron) tekniği ile öğrenme oranı (learning rate) 0.5, momentum 0.5, 8 girişli, gizli katmanda 4 hücreli, tek çıkışı olan ve eğitim sayısı (training time) 500 olan bir YSA kullanılarak sonuçlar tahmin edilmiştir. Aktivasyon fonksiyonu için Eşitlik (7) ile belirtilen sigmoid fonksiyon kullanılmıştır. Oluşturulan YSA Şekil 6'da görülmektedir.





Şekil 6. F-2 için tahmin de kullanılan YSA.

Figure 6. ANN used in prediction for F-2.

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (7)$$

Regresyon işlemi aynı giriş ve çıkış verileri ile MS Excel programı aracılığıyla uygulanmıştır elde edilen değerler Eşitlik (5)'de belirtilen regresyon denklemi ile hesaplanarak tahmin değerleri bulunmuştur.

Üç yöntem (DVM, YSA ve Regresyon) ve iki formül (F-1 ve F-2) için yapılan tahminlerin başarısı literatürde de kabul gören MAPE (Mean Absolute Percentage Error) değerleri Eşitlik (8) ile hesaplanarak karşılaştırılmıştır.

$$MAPE = \frac{|P_{(gerçek)} - P_{(tahmin)}|}{P_{(gerçek)}} * \%100 \quad (8)$$

MAPE : Mean Absolute Percentage Error,

$P_{(gerçek)}$  : Ölçülen değer,

$P_{(tahmin)}$  : Tahmin edilen değer.

MAPE değeri hesaplandığında ortaya çıkan mutlak yüzdesel hata %10 ve daha düşük olduğunda tahmin başarısı çok iyi olarak değerlendirilir. Hata %10 ve %20 arasında ise tahmin başarısı iyi olarak değerlendirilir [29].

Tablo 1'de, F-1 için giriş verisi olarak kullanılacak hammadde parametreleri A'dan M'ye kadar isimlendirilmiştir ve 8 farklı deneme için verilerin normalize edilmiş hali görülmektedir.

Tablo 1. F-1 için normalize edilmiş giriş verileri.

Table 1. Normalized input data for F-1.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	0.66	0	0.54	0.59	0	1	0.15	0.84	1	0	0	0	0
2	1	0	0.54	0	0.9	0.36	0.14	0.84	1	1	0	0	0
3	0	0.65	1	0.5	0	0.29	0	1	0.65	0.9	1	0	0
4	0.38	0.53	0	0.5	0	0.86	0	1	0.65	0	1	0	0
5	0.19	0.53	0	0.33	1	0.86	0	1	0.65	0	1	0	0
6	0	0.53	0	0.33	0	0.64	0	0	0.65	0	0	1	0
7	0	1	0	0	0	0	1	0	0.65	0	0	0	1
8	0	0.53	0	1	0	1	0	0	0	0	0	0	0

Tablo 2'de, F-2 için giriş verisi olarak kullanılacak hammadde parametreleri A'dan H'ye kadar isimlendirilmiştir ve 8 farklı deneme için verilerin normalize edilmiş hali görülmektedir.

Tablo 2. F-2 için normalize edilmiş giriş verileri.

Table 2. Normalized input data for F-2.

	A	B	C	D	E	F	G	H
1	0	1	1	1	1	0	0	1
2	0	0	0	1	0.5	0	0.5	1
3	0	1	1	1	1	1	0	0.875
4	0.93	1	1	1	1	0	0	0.18
5	0.72	1	0	1	0.5	0.4	1	0
6	0.93	0	1	0	0.5	0	1	0.18
7	1	0	0	1	0	0.4	1	0
8	0	0	1	0	0.5	0	1	0.18

Tablo 3'te, F-1 için gerçekleştirilen deney ve tahmin sonuçları görülmektedir.

Tablo 4'te, F-2 için gerçekleştirilen deney ve tahmin sonuçları görülmektedir.

Tablo 3. F-1 için ölçülen ve tahmin edilen % uzama değerleri.

Table 3. Measured and predicted % elongation results for F-1.

% Kopma Uzama Deneyi						
Deney Sonucu	DVM		YSA		Regresyon	
	Tahmin	MAPE	Tahmin	MAPE	Tahmin	MAPE
180	166.7	7.39	173.2	3.78	163.5	9.17
130	159.7	22.84	162.2	24.77	155	19.23
160	163.7	2.33	164.2	2.62	136.9	14.44
180	173.2	3.77	174.7	2.94	166.1	7.72
150	156.4	4.24	162.2	8.13	169.1	12.73
170	160.8	5.39	165.4	2.71	198.9	17.00
160	165.1	3.20	174.7	9.19	214.1	33.81
160	188.3	17.69	181.8	13.63	207.9	29.94

Tablo 4. F-2 için ölçülen ve tahmin edilen % uzama değerleri.

Table 4. Measured and predicted % elongation results for F-2.

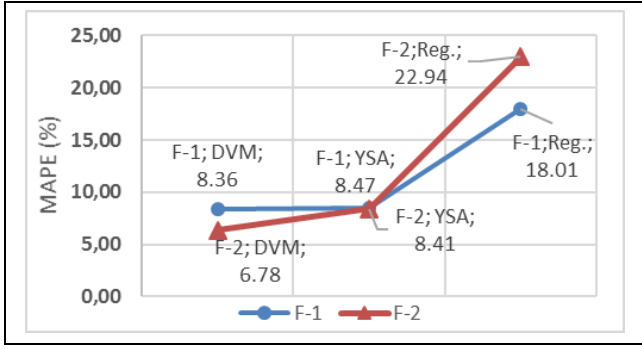
% Kopma Uzama Deneyi						
Deney Sonucu	DVM		YSA		Regresyon	
	Tahmin	MAPE	Tahmin	MAPE	Tahmin	MAPE
300	268.9	10.37	290.2	3.27	251.6	16.14
250	280.4	12.17	306.7	22.68	312.2	24.87
270	274.8	1.79	272.1	0.78	401.5	48.71
280	274.6	1.92	300.6	7.36	288.9	3.17
250	278.5	11.40	284.3	13.72	357.7	43.08
290	310.0	6.90	310	6.90	310.0	6.90
280	271.0	3.22	262.8	6.14	184.3	34.17
310	290.0	6.45	290.0	6.45	290.0	6.45

Tablo 5'te ve Şekil 7'de DVM, YSA ve Regresyon yöntemleri ile tahmin edilen uzama değerlerinin F-1 ve F-2 için ortalama MAPE değerleri görülmektedir.

Tablo 5. Üç farklı yöntem ile F-1 ve F-2 için tahmin edilen uzama değerlerinin MAPE değeri.

Table 5. MAPE of predicted elongation values for F1 and F2 by three different methods.

% Kopma Uzama Deneyi Toplam Ortalama MAPE			
Formül/Yöntem	DVM	YSA	Regresyon
1. Formül	8.36	8.47	18.01
2. Formül	6.78	8.41	22.94



Şekil 7. Üç farklı yöntem ile F-1 ve F-2 için tahmin edilen uzama değerlerinin MAPE karşılaştırılması.

Figure 7. MAPE comparison of the estimated elongation values for F-1 and F-2 with three different methods.

### 3 Sonuçlar

Bu çalışmada, HFFR kabloların doğrusal özellik göstermeyen yüzde kopma uzaması değeri Zwick Roell Z050 test makinesi ile ölçülmüştür. Daha sonra bu ölçülen gerçek test sonuçlarının literatürde yaygın bir şekilde kullanılan YSA ve DVM yöntemleri aracılığıyla modellenmesi amaçlanmıştır. Bazı testlerde YSA, DVM'ne göre daha küçük hata çıktısı vermesine rağmen, tüm testler üzerinde genel bir değerlendirme yapıldığında DVM'nin YSA'na göre daha az hata çıktısı verdiği Tablo 5'te görülmüştür. Bunun sebebi DVM'nin yapısından kaynaklanmaktadır. Çünkü DVM yapısı gereği eğitim verilerinin küçük bir kısmıyla bütün eğitim verilerini modellemekte ve genelleme yapabilmektedir. Uygulamada kullandığımız testlerin sayısı çok olmadığı için sonuçların bu şekilde çıkması normaldir. Hem DVM hem de YSA çeşitli eğitim parametreleri ile modellenmektedir. Bu parametreler değiştirildiğinde hata oranları da bir miktar değişecektir.

Gerçekleştirilen tahminler bütün olarak değerlendirildiğinde, iki formül için kullanılan üç tahmin yönteminde elde edilen MAPE değerlerine göre DVM ve YSA tahminleri, MS Excel ile gerçekleştirilen regresyon ile tahmine göre oldukça başarılıdır. DVM ve YSA yöntemleri ele alındığında, F-1 ve F-2 için toplamda 16 deney tahmini yapılmıştır. Bu 16 deney için MAPE değeri %20 ve üzeri olarak gerçekleşen sadece iki tahmin bulunmaktadır. Her bir formül için yapılan tahminler kendi içinde değerlendirildiğinde, MAPE değeri %20'yi geçen tahmin sayısı; F-1 için 1, F-2 için ise 1'dir. Literatüre göre başarılı olarak değerlendirilecek tahmin sayısı, deneyleri bir bütün olarak ele aldığımızda 14/16'dır. Böylece sonuç olarak, iki formül için DVM ve YSA yöntemleri kullanılarak gerçekleştirilen tüm tahminlerden sayıca ortalama %87.5'i başarılıdır ve ortalama tahmin başarısı ise %92'dir.

Makine Öğrenmesi yöntemlerinin HFFR kabloların üretim parametrelerinin belirlenmesi alanında kullanılması, geleneksel deneme yanılma yöntemlerine ve MS Excel ile gerçekleştirilen Regresyon'a kıyasla daha iyi, güvenilir ve optimum sonuçlar vermektedir. Bu yüzden Makine Öğrenmesi yöntemlerinin tek başına veya sapmaların azaltılması için farklı algoritma ve yöntemlerin birlikte kombine edilmiş hali önümüzdeki yıllarda kablo sektöründe daha çok kullanılacağı düşünülmektedir.

### 4 Conclusions

In this study, nonlinear percent elongation at break of HFFR cables was measured by Zwick Roell Z050 testing machine.

Then, it is aimed to model these measured real test results through ANN and SVM methods, which are widely used in the literature. Although ANN gives smaller error output than SVM in some tests, it is seen in Table 5 that SVM gives less error output than ANN when a general evaluation is made on all tests. Because, due to its structure, SVM can model and generalize all training data with a small part of the training data. Since the number of tests we use in the application is not many, it is normal for the results to come out in this way. Of course, both SVM and ANN are modeled with a variety of training parameters. Error rates will change slightly when these parameters are changed.

When the estimations made are evaluated as a whole, the SVM and ANN estimations according to the MAPE values obtained in the three estimation methods used for the two formulas are quite successful compared to the estimation with the regression performed with MS Excel. Considering the SVM and ANN methods, a total of 16 experimental predictions were made for F-1 and F-2. For these 16 experiments, there are only two predictions that come true with a MAPE of 20% or more. When the estimates made for each formula are evaluated within themselves, the number of predictions whose MAPE value exceeds 20%; It is 1 for F-1 and 1 for F-2. According to the literature, the number of predictions to be considered successful is 14/16 when we consider the experiments as a whole. Thus, as a result, an average of 87.5% of all predictions made using SVM and ANN methods for the two formulas are successful, and the average prediction success is 92%.

The use of Machine Learning methods in the field of determining the production parameters of HFFR cables gives better, reliable and optimum results compared to traditional trial and error methods and Regression with MS Excel. Therefore, it is thought that Machine Learning methods will be used more in the cable industry in the coming years, either alone or in combination with different algorithms and methods to reduce deviations.

### 5 Teşekkür

Bu çalışma Seval Kablo AR-GE Merkezi'nde gerçekleştirilmiş olup Seval Kablo öz kaynakları tarafından desteklenmiştir. Desteklerinden dolayı Seval Kablo'ya teşekkür ederiz.

### 6 Yazar katkı beyanı

Gerçekleştirilen çalışmada İsmail KIYICI araştırma fikrinin belirlenmesi ve deney numunelerinin hazırlanması ve testlerin yapılması başlıklarında; İbrahim DORUK literatür taraması ve değerlendirilmesi ile yazım ve içerik denetimi başlıklarında; Emre ÇOMAK sonuçların değerlendirilmesi ve içerik uygunluğunun değerlendirilmesi başlıklarında; Murat KAÇAMAZ kullanılan malzemelerin ve deney numunelerinin temin edilmesi başlıklarında; Ragıp Onur BAKLAN ise deney numunelerinin üretiminde ve test sonuçlarının değerlendirilmesinde katkı sunmuşlardır.

### 7 Etik kurul onayı ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur".  
"Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır".

## 8 Kaynaklar

- [1] Hyvärinen M, Jabeen R, Kärki T. "The modelling of extrusion processes for polymers-a review". *Polymers*, 12(6), 1306-1320, 2020.
- [2] Altarazi S, Allaf R, Alhindawi F. "Machine learning models for predicting and classifying the tensile strength of polymeric films fabricated via different production processes". *Materials*, 12(9), 1475-1489, 2019.
- [3] Altarazi S, Ammouri M, Hijazi A. "Artificial neural network modeling to evaluate polyvinylchloride composites' properties". *Computational Materials Science*, 153, 1-9, 2018.
- [4] Noor RAM, Ahmad Z, Don MM, Uzir MH. "Modelling and control of different types of polymerization processes using neural networks technique: A review". *The Canadian Journal of Chemical Engineering*, 88, 1065-1084, 2010.
- [5] Çırak B. Tel Kaplama Prosesinin Yapay Sinir Ağları (YSA) İle Modellenmesi ve Öngörülü Kontrol Modeli (MPC) ile Kontrolü. Doktora Tezi, Sakarya Üniversitesi, Sakarya, Türkiye, 2010.
- [6] Çırak B, Kozan R. "Prediction of the coating thickness of wire coating extrusion processes using artificial neural network (ANN)". *Modern Applied Science*, 3(7), 52-66, 2009.
- [7] Adesanya A, Abdulkareem A, Adesina LM. "Predicting extrusion process parameters in Nigeria cable manufacturing industry using artificial neural network". *Heliyon*, 2020.  
<https://doi.org/10.1016/j.heliyon.2020.e04289>.
- [8] Abdulkareem A, Adesanya A, Mutalub AL, Awelewa A. "Predicting extrusion process parameters in Nigeria cable industry for polyethylene cable insulation using artificial neural network". *Journal of Theoretical and Applied Information Technology*, 98(23), 3770-3782, 2020.
- [9] Khayyami S. Predicting Mechanical Properties of Polymer Films After Extrusion Coating Using Supervised Machine Learning Algorithms. MSc Thesis, Lund University, Lund, Sweden, 2019.
- [10] García V, Picón LR, Sánchez JS, Mendez L. "Using regression models for predicting the product quality in a tubing extrusion process". *Journal of Intelligent Manufacturing*, 30(6), 2535-2544, 2019.
- [11] Yadollahi MM, Benli A, Demirboğa R. "Prediction of compressive strength of geopolymer composites using an artificial neural network". *Materials Research Innovations*, 19(6), 453-458, 2015.
- [12] Nguyen HT, Nguyen KTQ, Le TC, Zhang G. "Review on the use of artificial intelligence to predict fire performance of construction materials and their flame retardancy". *Molecules*, 26(4), 1022-1050, 2021.
- [13] Kiyıcı İ, Doruk İ, Kaçamaz M, Baklan RO, Çomak E. "Prediction of cable mechanical properties using machine learning methods for production of halogen-free and flame retardant(hffr) cables". *International Conference on Engineering Technologies 2020*, Konya, Turkey, 19-21 November 2020.
- [14] Abeykoon C, Kelly AL, Vera-Sorroche J, Brown CE, Coates PD, Deng J, Li K, Harkin-Jones E, Price M. "Process efficiency in polymer extrusion: Correlation between the energy demand and melt thermal stability". *Applied Energy*, 135, 560-571, 2014.
- [15] Kök F. "Yangında açığa çıkan gazların, insan sağlığına vereceği zararın engellenmesi". *Ulusal Çevre Bilimleri Araştırma Dergisi*, 3(2), 83-94, 2020.
- [16] International Electrotechnical Commission. "Common Test Methods for Insulating And Sheathing Materials of Electric and Optical Cables". New York, USA, International Standart, 60811-1-1, 2001.
- [17] Kiyıcı İ. Akıllı, Otonom ve Korumalı Priz. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, Türkiye, 2019.
- [18] Maltarollo VG, Honório KM, Silva ABF. *Applications of Artificial Neural Networks in Chemical problems*. Editor: Kenji S. Artificial Neural Networks-Architectures and Applications, 204-220, Rejika, Croatia, IntechOpen Publishing, 2013.
- [19] Anderson JA. *An Introduction to Neural Networks*. 1<sup>st</sup> ed. New Delhi, India, Prentice-Hall of India Private Limited, 2006.
- [20] Beheshti Z, Shamsuddin S, Beheshti E, Yuhaziz S. "Enhancement of artificial neural network learning using centripetal accelerated particle swarm optimization for medical diseases diagnosis". *Soft Computing*, 18(11), 2253-2270, 2014.
- [21] Vapnik V. "An overview of statistical learning theory." *IEEE Transactions on Neural Networks*, 10(5), 988-999, 1995.
- [22] Jiaohui X, Wen T, Tingshun L. "Predicting fan blade icing by using particle swarm optimization and support vector machine algorithm". *Computers & Electrical Engineering*, 87, 1-11, 2020.
- [23] Chen N, Lu W, Yang J, Li G. *Support Vector Machine in Chemistry*. 1<sup>st</sup> ed. Singapore, Singapore, World Scientific Publishing Company, 2004.
- [24] Shevade S, Keerthi S, Bhattacharyya C, Murthy K. "Improvements to the SMO algorithm for SVM regression". *IEEE Transactions on Neural Networks*, 11(5), 1188-1193, 2000.
- [25] Smola AJ, Scholkopf B. "A tutorial on support vector regression". *Statistics and Computing*, 14(3), 199-222, 2004.
- [26] Başak H, Baday Ş. "Küreselleştirilmiş orta karbonlu bir çeliğin işlenmesinde, kesme parametrelerinin kesme kuvvetleri ve yüzey pürüzlülüğüne etkilerinin regresyon analizi ile modellenmesi". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22(4), 253-258, 2016.
- [27] Özden C, Acı Ç. "Makine öğrenmesi yöntemleri ile yaralanmalı trafik kazalarının analizi: Adana örneği". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 266-275, 2018.
- [28] Montgomery DC, Peck EA, Vining GG. *Introduction to Linear Regression Analysis*. 6<sup>th</sup> ed. New York, USA, John Wiley& Sons, 2021.
- [29] Lewis CD. *Industrial and Business Forecasting Methods*. 1<sup>st</sup> ed. London, England, Butterworths Publishing, 1982.