

# Nano-Kaplamalı Camların Elektriksel Özelliklerinin Derin Sinir Ağları İle Tahmininde Hiper Parametrelerin Performansı

## Performance of Hyperparameters in Prediction with Deep Neural Networks of Electrical Properties of Nano-Coated Glasses

Hale YENGİNER  
Elektrik-Elektronik Mühendisliği,  
ATASAREN Enstitüsü  
Milli Savunma Üniversitesi  
İstanbul, TÜRKİYE  
hyenginer@msu.edu.tr

Sinem ERASLAN  
Şişecam Bilim Teknoloji ve Tasarım  
Merkezi  
Şişecam A.Ş.  
Kocaeli, TÜRKİYE  
seraslan@sisecam.com

Batuhan GÜNDOĞDU  
Department of Radiology,  
University of Chicago  
IL, USA  
gundogdu@uchicago.edu

Hayriye KORKMAZ  
Elektrik-Elektronik Mühendisliği,  
Teknoloji Fakültesi  
Marmara Üniversitesi  
İstanbul, TÜRKİYE  
hkorkmaz@marmara.edu.tr

**Özetçe**— Nano-kaplamalı camlar, sanayi, ulaşım ve mimari yapılar olmak üzere farklı alanlarda yaygın olarak kullanılmaktadırlar. Bu camlar çeşitli ince film kaplama uygulamaları ile elde edilmelerinin ardından ikincil işlem olarak nitelendirilen ısı işlem sürecine (temperleme, bükme vb.) maruz bırakılmaktadırlar. Bahsi geçen bu iki aşamalı sürecin her ikisi de ortaya çıkan ürünün elektriksel ve mekanik özelliklerinin değişimine yol açmaktadır. Birinci aşamanın sonucunda elde edilen geçirgenlik, kaplamalı yüzey yansımaya ile kaplamasız yüzey yansımaya değerleri gibi elektriksel özellikler, analitik yöntemler ile hesaplanabilirken; ikinci aşamanın kaotik yapısı, bu parametrelerin benzer yöntemler ile hesaplanmasına izin vermemektedir. Bu yüzden bu çalışmada, mimari yapıların dış cephesinde kullanılmak amacıyla üretilmiş olan nano-kaplamalı cam türünün elektriksel özelliklerinin tahminine yönelik çok girişli-çok çıkışlı bir derin sinir ağı yapısı tasarlanmış; 64 farklı kaplama türüne sahip veri seti gürlü eklemeye tekniği ile genişletilmiş ve tahmin başarısında hiper parametrelerin performansları karşılaştırılmıştır. Ağ yapısının performansı Ortalama Mutlak Hata (OMH), Ortalama Karesel Hata (OKH) ve determinasyon katsayısı ( $R^2$ ) metrikleriyle ölçülmüştür. Tasarlanan ağ yapısı, 16 numune üzerinde test edilmiş ve elde edilen sonuçlara göre, en iyi performansın genişletilmiş veri seti kullanılarak Adadelata öğrenme algoritması ile ReLU aktivasyon fonksiyonunun bir arada kullanıldığı deneyde olduğu gözlemlenmiştir.

**Anahtar Kelimeler**—ince film kaplama; derin sinir ağları; yapay öğrenme.

**Abstract**— Nano-coated glasses are widely used in different fields such as industry, transportation and architectural structures. After these glasses are obtained by various thin film coating applications, they are subjected to the heat treatment process (tempering, bending, etc.), which is considered as a secondary process. Both of these two-stage processes lead to


changes in the electrical and mechanical properties of the final product. While electrical properties such as transmittance, coated surface reflection and uncoated surface reflection values obtained as a result of the first stage can be calculated by analytical methods; the chaotic nature of the second stage does not allow these parameters to be calculated with similar methods. Therefore, in this study, a multi-input-multi-output deep neural network structure was designed for the estimation of the electrical properties of the nano-coated glass type produced for commercial use in architectural fields. Moreover, The dataset with 64 different coating types was augmented by adding noise technique and the performances of the hyperparameters in prediction success were compared. The performance of the network structure was measured by the mean absolute error, mean squared error, and coefficient of determination metrics. The designed network structure was tested on 16 samples and according to the results obtained, it was observed that the best performance was achieved with the Adadelata learning algorithm and ReLU activation function on the augmented data set.

**Keywords**—thin film coating; deep neural networks; machine learning.

### I. GİRİŞ

Nano-kaplamalı camlar, optik (reflektif/antireflektif kaplama, ince film polarizörler vb.), opto-elektronik (foton dedektörleri, fotovoltaj aygıtlar, ince film göstergeler), mikro-elektronik (yarıiletkenler) gibi alanlarda geniş bir yelpazede kullanılmaktadırlar [1]. Çok katmanlı yapıya sahip bu kaplamalı camların geçirgenlik, yansımaya, soğurma gibi elektriksel davranışları ile sertlik gibi mekanik özellikleri; kaplamada yer alan katmanların malzeme tipi, özelliği, kalınlığı ve dizilim sırası ile doğrudan ilişkilidir [2]. Şekil 1’de detaylı yapısı verilen bu camlar, ilk adımda altlık malzeme

üzerine ince film kaplama teknolojileri kullanılarak, ikinci adımda ise mekanik dayanıklılıklarının artırılması ve güvenlik açısından kırılma davranışlarının değiştirilmesi amacıyla ısıtma işlemine tabi tutularak kullanıma hazır hale getirilmektedirler. İki aşamalı bu sürecin birinci aşamasının sonucunda elde edilen geçirgenlik, kaplamalı yüzey yansıma ile kaplamasız yüzey yansımadan oluşan elektriksel özellikleri, analitik yöntemler ile hesaplanabilmektedir. Ancak ikinci adımın kaotik yapısı, bu parametrelerin benzer yöntemler ile hesaplanmasına izin vermemektedir ve analitik metotlar burada kullanılamamaktadır [3]. Dolayısıyla bu süreç deneme-yanılma şeklinde yürütülmekte ve bu durum işletmeler için zaman ve maliyet kayıplarına sebep olmaktadır.



Şekil 1. Nano-Kaplamalı Camın Detaylı Yapısı

Literatürde ince film kaplama, cam ve yapay öğrenme anahtar kelimelerinin birlikte geçtiği mevcut çalışmalar incelendiğinde, bu çalışmaların çoğunlukla ısıtma işlemi öncesine süreci öncesine ait parametrelerin kestirimine ve optimizasyonuna odaklandığı görülmüştür. Ancak bu sürecin analitik yöntemlerle çözümlenebilmesi ve verilen giriş parametrelerine göre çıkışta geçirgenlik, iletim, yansıma, soğurma gibi elektriksel davranış özelliklerine ait değerleri hesaplayan paket programların [4] da mevcut olması sebebiyle, mevcut çalışmalar burada odaklanılan problemin çözümünde yetersiz kalmaktadırlar.

Cassar ve ark. çok bileşenli oksit camların geçiş sıcaklığı tahmini için 55150 inorganik cam örneğinin bulunduğu veri setini kullanarak yapay sinir ağı eğitimi gerçekleştirmişlerdir. Veriler, SciGlass 7.12 veri tabanından alınmış olup; tahmin başarısı % 95 olarak belirtilmiştir [5].

Khorasani ve ark. optik lenslerdeki renk sapmasını belirten parametrelerden biri olan Abbe sayısının tahminine yönelik gerçekleştirdikleri çalışmada, INTERGLAD veri tabanında yer alan yüksek kırılma indisine sahip 879 adet cama ait değerleri kullanmışlardır. Bu çalışmada çoklu doğrusal regresyon ve ridge regresyon yöntemlerini uygulamış ve  $R^2$  değerini, çoklu doğrusal regresyon yöntemi için 0.944 ve kernel ridge regresyon yöntemi için ise 0.996 olarak elde etmişlerdir [6].

Cassar ve ark. optik cam tasarımına yönelik genetik algoritma (GA) tabanlı model geliştirmişlerdir. Bu amaçla SciGlass veri tabanından oksitli camlara ait geçiş sıcaklığı ve kırılma indisi verilerini elde ettikten sonra bu özellikler için sinir ağları ile tahmin modelleri oluşturmuşlardır. Ardından GA kullanarak 1.7 ve daha yüksek kırılma indisi ile 500 °C ve daha düşük cam geçiş sıcaklığına sahip camların bileşen bilgilerini araştırmışlardır. Yazarlar birleştirilmiş algoritmaların ürettiği sonuçlardan örnek seçtikleri iki cam bileşiminin laboratuvar ortamında üretimini

gerçekleştirmişler, sonuçların uyum içerisinde olduğunu göstermişler ve geliştirdikleri tasarımın cam gelişimine katkı sağlayarak, deneme-yanılma hatalarını azalttığını belirtmişlerdir [7].

Khorasani ve ark. çok katmanlı algılayıcılar kullanarak titanyum ince film tabakaların sertliğinin tahmin edilmesini ele almışlardır. Bu amaçla, kimyasal ve fiziksel buhar biriktirme işlemleri sırasında elde edilen deneysel verileri kullanmışlardır. Geri yayılım algoritması kullanarak oluşturdukları modelin %0.035 hata değeri ile yüksek başarı sağladıklarını söylemişlerdir [8].

Shen ve ark. yarı iletken ince filmlerin özelliklerini tahmin etmek için sinir ağlarına dayalı bir yöntem sunmuşlardır. İnce film özelliklerinin imalat sürecindeki kontrol parametrelerine göre kestirimini mümkün olduğunu; ancak modelin iyileştirilmesi için daha fazla verinin toplanması gerektiğini belirtmişlerdir [9].

Jiang ve ark. çok katmanlı optik film tasarımında optik özellikler özelinde katman kalınlıklarının optimizasyonunda Derin Q Ağı (Deep Q Network) metodunu önermişlerdir. GA ile Q öğrenme yöntemlerinin performans kıyaslamalarını yaptıkları bu çalışmada, derin Q yönteminin daha iyi sonuçlar ürettiğini söylemişlerdir [10].

Rabady ve ark. optik girişim filmlerinde optimal kalınlıkların bulunmasına yönelik yaptıkları çalışmada GA, iğne metodunu ve Parçacık Sürüsü Optimizasyonunu (PSO) kullanmışlardır. Bu çalışmada gerçekleştirilen deneylerde yansıma parametresi nezdinde en iyi sonucun PSO algoritması ile sağlandığını belirtmişlerdir [11].

Bishnoi ve ark. silikat camların yoğunluğu ve oksit bileşenlerinin mol yüzdeleri ile Young modül parametresinin tahmin edilmesi üzerine hazırladıkları çalışmada INTERGLAD Ver.7 veri tabanından elde edilen verileri kullanmışlardır. Gauss Süreç Regresyonu yöntemini kullanarak oluşturdukları modelde 0.925  $R^2$  değeriyle yüksek performans elde ettiklerini vurgulamışlardır [12].

Jiang ve ark. seçici solar soğurucu kalınlığının optimizasyon süresinin iyileştirmesi için pekiştirmeli öğrenme yöntemlerinden derin Q öğrenme tabanlı algoritmayı önermişlerdir. Başarı yüzdesi belirtilmeyen bu çalışmada, optimizasyon süre maliyetinin 20 dakika olarak belirtilmişlerdir [13].

Akça ve ark. ise bu çalışmayla aynı problemi ele aldıkları bir başka çalışmada, lineer regresyon ve YSA yöntemlerini kullanarak düşük hata ve yüksek genelleme yeteneği elde edebilmişlerdir [3]. Burada önerilen çalışma ile [3] nolu çalışma arasındaki temel farklılık, veri seti içerisinde değişken kaplama kalınlıklarına yer verilmemesi ve dalga boyu bazındaki değerlerin giriş parametresi olarak kullanılmış olmasıdır.

Sonuç olarak nano kaplamalı camların ısıtma işlemi sonrası parametrelerin tahminine yönelik, [3] nolu çalışmadan başka bir çalışmaya rastlanılmamıştır.

Bu bildiride sunulan çalışmada, nano boyutlu kaplamalı camların üretim öncesinde belirlenen ve ısıtma işlemi sonrasında beklenen elektriksel özelliklere sahip olması için; başlangıç giriş koşullarını tahmin edebilecek çok girişli-çok çıkışlı bir derin sinir ağı yapısı önerilmiştir.

Çalışmanın geri kalan kısmı aşağıdaki şekilde düzenlenmiştir: Bölüm II' de kullanılan veri seti ve

yöntemlerden bahsedilmiştir. Bölüm III' te gerçekleştirilen deneylerin performansları değerlendirilmiştir. Bölüm IV' te ise sonuçlar tartışılmış, yorumlanmış ve gelecekteki çalışmalardan bahsedilmiştir.

## II. YÖNTEM

Bu çalışmada, Türkiye Şişe ve Cam Fabrikaları Bilim Teknoloji ve Tasarım Merkezi bünyesinde mimari kullanıma yönelik geliştirilen nano kaplamalı camlar arasından seçilen tek bir grubun spektrofotometre ölçüm sonuçları kullanılmıştır. Bu gruba ait veri seti, farklı katman sayısına (11 den 14 e kadar ) ve dizilim türlerine sahip 64 cam numunesinin görünür dalga boyu (D) aralığındaki (380-980 nm) ısıt işlem öncesi (İİÖ) ve sonrası (İİS) olmak üzere geçirgenlik (G), kaplamalı yüzey yansımaya (KYY) ve kaplamasız yüzey yansımaya (KsYY) gibi elektriksel özelliklerine ait değerleri içermektedir.

Veri setinde, 64 numuneye ait 121 farklı dalga boyu değeri için (380 nm den 980 nm ye kadar 5 nm artım aralığı ile) yukarıda belirtilen 3 adet elektriksel özellik mevcuttur. Bu değerlerin tahmin edilmeye çalışıldığı bu çalışmada, çıkışın yüksek boyutta bir değer alması nedeniyle Şekil 2' de yer alan çok-girişli ve çok-çıkışlı derin sinir ağı yapısı kullanılmıştır. Veri setinin %75'i eğitim ve %25'i de test seti olarak ayrılmıştır. Girdi boyutu (121x4) olan bu modelde kayıp/yitim fonksiyonu olarak OMH kullanılmış ve performans iyileştirme yöntemlerinden düğüm seyreltme (dropout) metodu kullanılmıştır. Gerçekleştirilen deneyler sonrasında öğrenme oranı (learning rate) 0,01; düğüm seyreltme oranı 0,1

ve eğitim yineleme (epoch) sayısı 1k olarak belirlenmiştir. Aşırı öğrenmenin önüne geçmek için Gauss dağılımına sahip değerler dizisinin eğitim verilerine eklenmesiyle (gürültü ekleme-noise injection) veri setinin genişletilmesi sağlanmıştır. Bu sayede veri setinde 64 olan örneklem sayısı 208' e çıkarılmıştır.

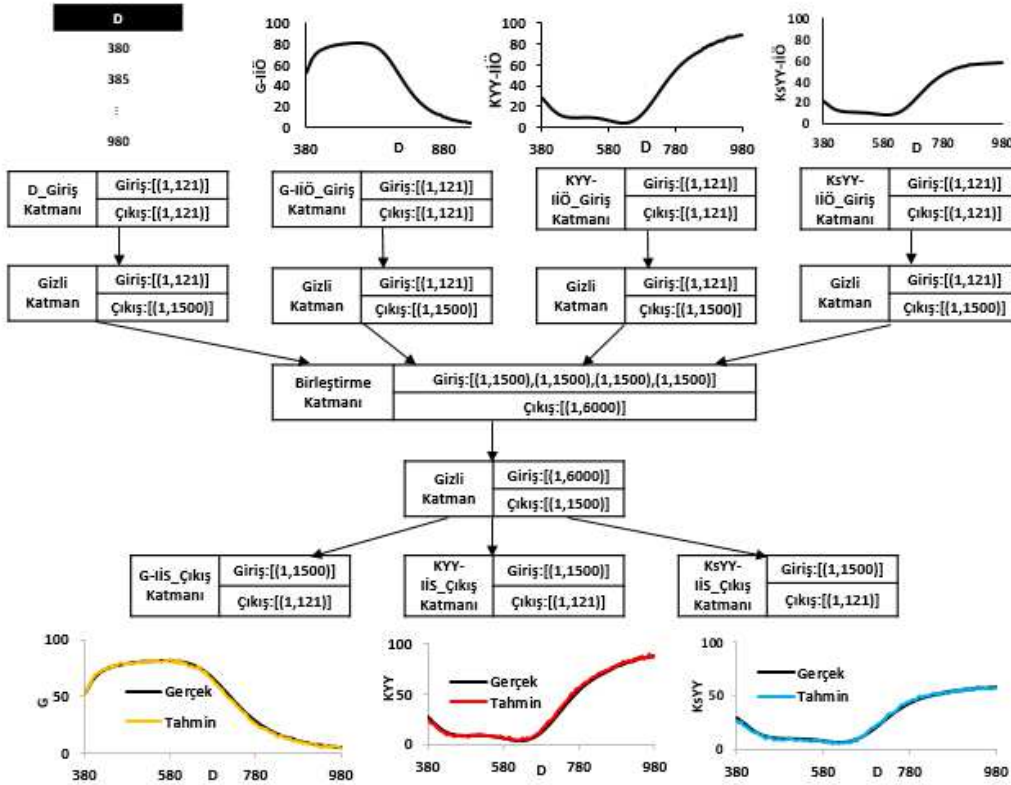
Çok-girişli ve çok-çıkışlı derin sinir ağına eğitiminde hatayı minimize etmek için gradyan iniş tabanlı 7 farklı öğrenme algoritması uygulanmıştır.

Modelin geçerliliği OMH (Denklem 1), KOH (Denklem 2) ve  $R^2$  (Denklem 3) ölçütleri ile değerlendirilmiştir. OMH ve KOH ölçütleri iki numune arasındaki ölçümlerin mutlak ve kareköksel olarak birbirinden ne kadar uzak olduğunu belirlemede kullanılırken;  $R^2$  ölçütü ise verilerin eğriye hangi ölçüde uyduğunu belirlemede kullanılmaktadır. Burada n, ölçüm sayısını;  $y_i$  ölçüm değerini;  $\hat{y}_i$  tahmin değerini ve  $\bar{y}_i$  ise ölçümlerin ortalama değerini göstermektedir.

$$OMH = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

$$KOH = \frac{1}{n} \sum_{i=1}^n \sqrt{y_i - \hat{y}_i} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3)$$



Şekil 2. Çok-Girişli Çok-Çıkışlı Ağ Yapısı

### III. DENEYSEL SONUÇLAR

Tasarlanan çok-girişli çok-çıkışlı derin sinir ağı yapısında deney seti olarak Veri Seti-I (gürültü eklenmemiş) ve Veri Seti-II (gürültü eklenerek genişletilmiş) kullanılmıştır. Her biri için 7 farklı öğrenme algoritması ile sızıntı doğrultulmuş birim (leakyReLU), ReLU, sigmoid ve hiperbolik tanjant (tanh) aktivasyon fonksiyonları kullanılarak deneyler gerçekleştirilmiş ve test seti performans sonuçları sırasıyla Tablo I, II, III, IV, V, VI ve VII' de verilmiştir. En yüksek performans sonuçları yeşil renk ile vurgulanmıştır. Farklı öğrenme algoritması ve aktivasyon fonksiyonu kombinasyonlarının kullanımı sonucunda farklı başarı değerleri elde edilmiştir. Tahmin performansındaki bu değişimlerin nedeni, temin edilen ölçümlerin çeşitlilik (farklı katman sayısı, dizilimi vb. özelliklere sahip numuneler) arz etmesinden kaynaklanmaktadır.

Adadelta öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo I' de sunulmuştur. En iyi performans Veri Seti-II kullanılarak ReLU aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

Adagrad öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo II' de sunulmuştur. En iyi performans Veri Seti-II kullanılarak tanh aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

Adadelta	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
LeakyReLU	3.53	4.42	0.97	2.24	2.89	0.98
ReLU	4.15	5.22	0.96	2	2.49	0.99
sigmoid	4.96	6.24	0.93	4.53	5.72	0.94
tanh	4.96	6.24	0.93	4.55	5.74	0.94

Tablo I. Adadelta Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

Adagrad	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	3.2	4	0.97	2.9	3.66	0.98
ReLU	3.48	4.22	0.97	3.5	4.2	0.97
sigmoid	4.87	6.12	0.93	2.88	3.63	0.98
tanh	4.96	6.23	0.93	2.88	3.59	0.98

Tablo II. Adagrad Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

Adamax öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo III' te sunulmuştur. En iyi performans Veri Seti-II kullanılarak ReLU aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

Adamax	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	4.25	5.48	0.94	3.27	4.19	0.97
ReLU	2.67	3.33	0.98	2.11	2.5	0.99
sigmoid	5.01	6.24	0.93	4.48	5.6	0.94
tanh	4.89	6.16	0.93	4.35	5.51	0.94

Tablo III. Adamax Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

Adam öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo IV' de sunulmuştur. En iyi performans Veri Seti-II kullanılarak ReLU aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

Adam	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	12.81	16.01	0.75	3.83	4.78	0.97
ReLU	4.35	5.26	0.95	2.72	3.38	0.98
sigmoid	4.83	6.13	0.93	4.36	5.5	0.94
tanh	5.01	6.33	0.92	4.76	5.89	0.94

Tablo IV. Adam Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

Nadam öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo V' te sunulmuştur. En iyi performans Veri Seti-II kullanılarak leakyReLU aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

Nadam	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	3.71	4.72	0.96	3.61	4.5	0.96
ReLU	5.13	6.41	0.93	3.93	4.8	0.96
sigmoid	5.22	6.69	0.92	4.79	5.91	0.94
tanh	5.22	6.73	0.92	4.99	6.13	0.94

Tablo V. Nadam Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

RMSProp öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerlere Tablo VI' da yer verilmiştir. En iyi performans Veri Seti-II kullanılarak sigmoid aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

RMSProp	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	9.63	12.17	0.87	7.62	9.18	0.87
ReLU	5.71	7.19	0.91	5.26	6.56	0.94
sigmoid	5.19	6.66	0.92	4.59	5.74	0.94
tanh	6.06	7.42	0.9	7.62	9.18	0.87

Tablo VI. RMSProp Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

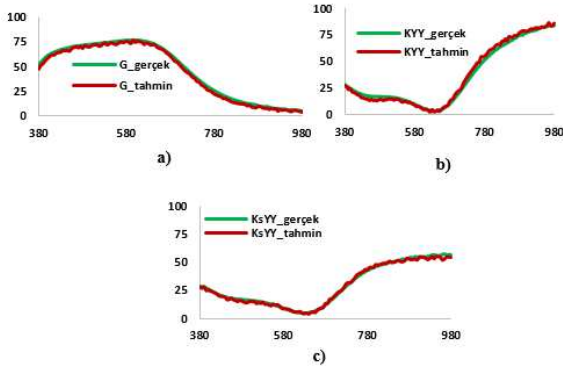
SGD öğrenme algoritması kullanılarak elde edilen test sonuçlarının yer aldığı değerler Tablo VII’de gösterilmiştir. En iyi performans Veri Seti-II kullanılarak leakyReLU aktivasyon fonksiyonunun uygulandığı deneyde gözlemlenmiştir.

SGD	Veri Seti-I			Veri Seti-II		
	OMH	KOH	R2	OMH	KOH	R2
leakyReLU	6.84	8.82	0.92	4.12	5.43	0.96
ReLU	5.02	6.26	6.26	4.52	5.65	0.94
sigmoid	4.96	6.24	0.93	4.29	5.42	0.95
tanh	4.96	6.24	0.93	4.45	5.6	0.94

Tablo VII. SGD Öğrenme Algoritması ile Elde Edilen Test Seti Sonuçları

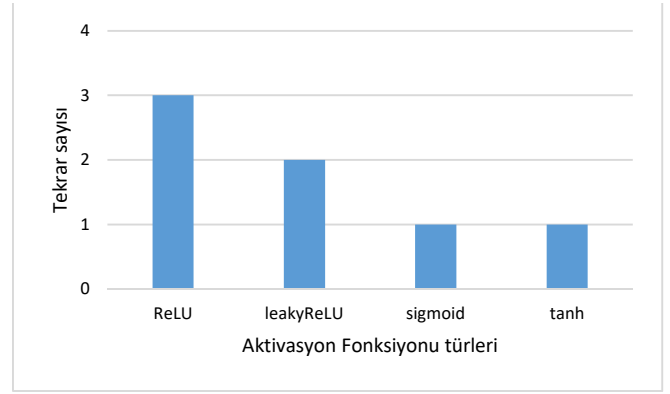
#### IV. SONUÇLAR

Her bir veri seti için, 7 farklı öğrenme algoritması ve 4 farklı aktivasyon fonksiyonu birlikte kullanılarak toplam 28 adet deney yapılmıştır. Gerçekleştirilen bu deneylere ait test sonuçları incelendiğinde, veri setini genişletmenin tasarlanan ağ yapısının performans metriklerini iyileştirdiği görülmüştür. En yüksek başarımlar Veri Seti-II kullanılarak Adadelta öğrenme algoritması ile ReLU aktivasyon fonksiyonunun bir arada kullanıldığı deneyde gözlemlenmiştir. Bahsedilen deneylerde elde edilen en yüksek başarımlara ait örnek bir test numunesi için sonuçlar Şekil 3’te verilmiştir.



Şekil 3. En yüksek başarımları gösteren deney için örnek test numunesine ait özelliklerin karşılaştırılması a) Geçirgenlik b) Kaplamalı yüzey yansımaya c) Kaplamsız yüzey yansımaya

Bu çalışmada Veri Seti II kullanılarak yapılan deneylerde, uygulanan öğrenme algoritmalarına göre kullanılan 4 farklı aktivasyon fonksiyonuna ait başarı kıyaslamalarının yer aldığı grafik, Şekil 4’te görülmektedir. Bu şekilden de anlaşıldığı gibi en yüksek başarımların tekrarı, ele alınan konu başlığının temelde bir kestirim problemi olması ve çoklu giriş karşılık çoklu çıkışın tahmin edilmek istenmesinden dolayı ReLU fonksiyonunun uygulandığı deneylerde gözlemlenmektedir.



Şekil 4. Aktivasyon fonksiyonlarının en yüksek başarımları gösterme tekrarı sayısı

Gelecekteki çalışmalarda, farklı alanlarda kullanım amacı ile üretilmiş nano-kaplamalı cam grup türleri için de derin sinir ağı tasarımlarının gerçekleştirilmesi planlanmaktadır. Nihai hedef ise tüm nano-kaplamalı cam grupları için tek bir model geliştirilmesidir.

#### TEŞEKKÜR

Bu çalışma, TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) ve Şişecam tarafından 2244 Sanayi Doktora Programı kapsamında 118C067 numaralı proje ile desteklenmektedir.

#### KAYNAKÇA

- [1] Chopra, Kasturi. Thin film device applications. Springer Science & Business Media, 2012.
- [2] Frey, Hartmut, and Hamid R. Khan, eds. Handbook of thin film technology. Berlin: Springer, 2015.
- [3] Akça, Benan, Sinem Eraslan, and Batuhan Gündoğdu. "Neural Network Based Modeling of Chaotic Processes in Glass Technologies." 2019 27th Signal Processing and Communications Applications Conference (SIU). IEEE, 2019.
- [4] "Hardware and software for optical spectroscopy", <https://wtheiss.com> (Erişim Tarihi 04.06.2023)
- [5] Cassar, Daniel R., Andre CPLF de Carvalho, and Edgar D. Zanotto. "Predicting glass transition temperatures using neural networks." Acta Materialia 159 (2018): 249-256.
- [6] Tokuda, Yomei, et al. "Data-driven design of glasses with desirable optical properties using statistical regression." AIP Advances 10.10 (2020): 105110.
- [7] Cassar, Daniel R., Gisele G. Santos, and Edgar D. Zanotto. "Designing optical glasses by machine learning coupled with a genetic algorithm." Ceramics International 47.8 (2021): 10555-10564.
- [8] Khorasani, Amir, et al. "CVD and PVD coating process modelling by using artificial neural networks." Artificial Intelligence Research 1.1 (2012): 46-54.
- [9] The estimation of thin film properties by neural network. source: Automation, Control and Intelligent Systems, 2016, 4.2.
- [10] Jiang, Anqing, Osamu Yoshie, and Liang Yao Chen. "A new multilayer optical film optimal method based on deep q-learning." arXiv preprint arXiv:1812.02873 (2018).
- [11] Rabady, Rabi I., and Almahdi Ababneh. "Global optimal design of optical multilayer thin-film filters using particle swarm optimization." Optik 125.1 (2014): 548-553.
- [12] Bishnoi, Suresh, et al. "Predicting Young's modulus of oxide glasses with sparse datasets using machine learning." Journal of Non-Crystalline Solids 524 (2019): 119643.
- [13] Jiang, Anqing, Yoshie Osamu, and Liangyao Chen. "Multilayer optical thin film design with deep Q learning." Scientific reports 10.1 (2020): 1-7.