

Dalgacık Dönüşümü ile Beton Basınç Dayanım Tahmininin İyileştirilmesi

Ersin NAMLI^{a*}, Halil İbrahim ERDAL^b, Hamit ERDAL^c

^a İstanbul Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği, İstanbul, Türkiye

^b Türk İşbirliği ve Koordinasyon Ajansı (TİKA), Ankara, Türkiye

^c Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum, Türkiye

(Geliş / Received : 08.02.2016 ; Kabul / Accepted : 25.07.2016)

ÖZ

Betonun basınç dayanımının tahmini araştırmacılar tarafından son yıllarda artan bir hızla ele alınmaktadır. Bu konuda geleneksel istatistiksel tahmin yaklaşım ve yöntemlerinin terk edilerek gelişmiş tahmin yaklaşım ve metodolojileri kullanılmaya başlanmıştır. Bu çalışmada farklı karışım oranları kullanılarak Beton basınç dayanımının tahmininde Yapay Sinir Ağları (YSA) yöntemi ile Dalgacık Dönüşümü Yapay Sinir Ağları (DDYSA) yöntemlerinin tahmin performansları karşılaştırılmış ve veri setini ayırarak tahmin için daha kararlı duruma getiren Dalgacık Dönüşümünün (DD) tahmin performanslarının iyileşmeye/kötüleşmesine etkisi araştırılmıştır. Bu kapsamda veri seti dört farklı şekilde eğitilmiş ve on altı farklı test çalışması gerçekleştirilmiştir. Gerçekleştirilen testler neticesinde DD'nin geleneksel YSA'ya oranla daha tatmin edici tahmin sonuçları verdiği görülmüştür. Sonuç olarak DD'nin araştırmacılar ve beton üreticileri tarafından beton basınç dayanım tahmininde etkin bir yöntem olarak kullanılabilmesi sonucuna varılmıştır.

Anahtar kelimeler: Beton Basınç Dayanımı, Yapay Sinir Ağları, Dalgacık Dönüşümü.

Improving Prediction Accuracy of Concrete Compressive Strength via Wavelet Transform

ABSTRACT

In recent years, Compressive strength prediction of concrete is being studied with an increasing speed by researchers. Instead of traditional statistical techniques, advanced prediction methods are being used in this area of study. In this study artificial neural network (ANN) and wavelet transform artificial neural network (WTANN) methods' prediction performances were compared on compressive strength of concrete with different mixture ratios and additionally effect of wavelet transform which decomposes dataset into subsets for a stationary situation for prediction was presented. Within this scope dataset trained in four different ways and sixteen different tests performed. The results of tests performed, WTANN achieves higher prediction performance in comparison with ANN. Hence, it's proved that WT could be used by researchers as an effective predictive tool for concrete compressive strength

Keywords: Concrete Compressive Strength, Artificial Neural Networks, Wavelet Transform

1. GİRİŞ (INTRODUCTION)

Beton dayanım testleri için gerekli deneysel çalışmalar yüklü miktarda malzeme, ekipman, işgücü ve finansal kaynak gerektireceğinden, önceden elde edilen veriler ve tahmin başarısı test edilmiş makine öğrenmesi yöntemleri kullanılarak tüm bu kaynak israflarının önüne geçilebilir.

Literatürde beton basınç dayanımının tahmin edilmesinde en fazla YSA kullanıldığı gözlenmiştir [1,2,3,4]. Yeh [3] Yüksek Performanslı Beton (YPB) basınç dayanımı tahmini için geleneksel istatistiksel yöntemlerden regresyon analizi (regression analysis) ile YSA'ların tahmin başarısını karşılaştırdığı çalışmasında YSA'ların üstünlüğünü raporlamıştır. Benzer şekilde Atıcı [5]'da YSA'ların çoklu regresyon analizi (multiple

regression analysis)'ne üstünlüğünü ortaya koymuştur. Çoklu regresyon analizi ile bir YSA modeli olan özdüzenleyici haritalar (self organization feature map, SOFM)'ın karşılaştırdığı bir diğer çalışmada Nikoo vd. [6] tarafından yapılmıştır. Yazarlar SOFM'un üstünlüğünü raporlamıştır.

İlerleyen yıllarda yapılan beton dayanımı tahminlemesi çalışmalarında giderek geleneksel istatistiksel yöntemlerin terk edildiği ve farklı makine öğrenmesi yöntemlerinin tahmin performanslarının karşılaştırıldığı veya hibrit yeni modellerin ağırlık kazandığı tespit edilmiştir. Fazel-Zarandi vd. [7] YPB basınç dayanımı tahmini için bulanık sinir ağları (fuzzy neural networks) ve polinomial sinir ağları (polynomial neural networks)'nın birleşiminden oluşan bir bulanık polinomial sinir ağı modeli önermiştir. Yeh ve Lien [8]'de karar ağacı (decision tree; operation tree) ve genetik algoritmalar (genetic algorithm)'ın kullanıldığı bir hibrit genetik karar ağacı (genetic operation tree) modeli geliştirmiştir.

*Sorumlu Yazar (Corresponding Author)

e-posta: enamli@istanbul.edu.tr

Digital Object Identifier (DOI) : 10.2339/2016.19.4 471-480

Cheng vd. [9] bulanık mantık (fuzzy logic, FL), ağırlıklı destek vektör malineleri (wSVM) ve hızlı dağılık genetik algoritmalar (fast messy genetik algorithms, fmGA)'ın kullanıldığı bir hibrit evrimsel bulanık destek vektör makinası çıkarımsal modeli (evolutionary fuzzy support vector machine inference model for time series data, EFSIMT) önermiştir. Chou vd. [10] beş farklı makine öğrenmesi yöntemini (YSA, DVM, çoklu regresyon analizi ve 2 farklı birleşik öğrenme modeli (çok katlı regresyon ağaçları (multiple additive regression trees, MART) ve torbalama regresyon ağaçları (bagging regression trees, BRT)) karşılaştırmalı ve hibrit olarak kullandıkları çalışmalarında hibrit modellerinin tahmin başarısının üstünlüğünü vurgulamıştır. Cheng vd. [11] genetik ağırlıklı piramit karar ağacı (genetic weighted pyramid operation tree, GWPOT) modeli önermiş ve geliştirilen modelin başarısı YSA, DVM ile evrimsel destek vektör makinesi çıkarımsal modeli (evolutionary support vector machine inference model, ESIM) ile karşılaştırmıştır ve çalışmada önerilen modelin üstünlüğü rapor edilmiştir. Literatürde dalgacık dönüşümünün ses [12], dil [13] ve el hareketi tanıma [14], elektrik yükü [15] ve rüzgar gücü tahmini [16], hava kirliliğinin analizi [17], borsa tahmini [18], nehir debisi tahmini [19], hata analizi [20], pirinç hasadı zamanı [21], uyku apnesinin sınıflandırılması [22] gibi birçok disiplinde yaygın olarak kullanılmasına rağmen inşaat mühendisliği [23, 24] ve özellikle beton basınç dayanımı tahmininde [25] sınırlı çalışmada kullanıldığı tespit edilmiştir. Yukarıda sayılan çalışmaların tamamında dalgacık dönüşümünün tahmin başarılarını artırdığı ortaya koyulmuştur.

Bu çalışmada; insan beyninin biyolojik sinir sisteminin çalışma şeklinin simüle edilmesiyle bilgi işleme fonksiyonundan esinlenerek geliştirilen YSA'lar, beton basınç dayanımı tahminlemesinde kullanılmış ve DD'nin tahmin başarısına etkisi araştırılmıştır.

Çalışmanın ikinci bölümünde uygulanan yöntem ve prosedürler açıklanmış, üçüncü bölümde test çalışmaları sonucunda elde edilen bulgular paylaşılarak önceki çalışmalarla karşılaştırılmış ve genel bir değerlendirmenin yapıldığı sonuç bölümüyle çalışma tamamlanmıştır.

2. YÖNTEM VE PROSEDÜRLER (METHODS AND PROCEDURES)

Bu bölümde öncelikle, çalışmada kullanılan yöntemler tanıtılacak daha sonra uygulanan prosedürler açıklanacaktır.

2.1. Yapay Sinir Ağları (Artificial Neural Networks)

YSA'lar insan beyninin biyolojik sinir sisteminin çalışma şekli ve bilgiyi işlem fonksiyonundan esinlenerek geliştirilmiştir. Basit bir sinir ağı modeli olan ilk YSA modeli 1943'de, W. McCulloch ve W. Pitts tarafından geliştirilmiştir[6]. 1948'de Wiener'in "Cybernetics" adlı eserini, 1949 yılında Hebb'in yapay sinir ağının ilinti sayısının değiştirilmesiyle öğrenme arasında ilişki kuran "Hebb Kuralı" izlemiştir. 1957'de F. Rosenblatt'ın tek

katmanlı, eğitilebilen ve tek çıkışlı bir ağ modeli olan Perceptron'u geliştirmesinden sonra, YSA çalışmaları hız kazanmıştır [26,27,28].

Dünyada bilinen pek çok şirket ve kuruluş, karşılaştıkları problemlerin çözümünde profesyonel YSA tabanlı programlardan yararlanmaktadır. Bu şirketlerden bazıları; Bank of America, Boeing, BP, Dell, NASA, Phillip Morris, Pfizer, Xerox ve Volvo'dur [28].

YSA'da girdi değerleri ile çıktı değerleri arasındaki fark denklem(1)'de ki hata fonksiyonu ile elde edilir [12,26,28] (d_j : hedeflenen sonuç, o_j : gerçekleşen sonuç)[29].

$$E_p = \frac{1}{2} \sum_j (d_j^p - o_j^p)^2 \quad (1)$$

Ağırlıkları yeniden düzenlemek için hata fonksiyonunun farkı kullanılır.

$$\Delta^p w_{ji} = -n \left(\frac{\partial E^p}{\partial w_{ji}} \right) \quad (2)$$

Burada "öğrenme oranı" η parametresi herhangi bir değer seçilebilir. Ağırlıkların yeniden düzenlenmesi

$$w_{ij}(t+1) \cong w_{ij}(t) + n \delta_j i_i \quad (3)$$

şeklinde yapılır. Burada $w_{ij}(t)$: ağırlık, i_i : i düğümünün sonuç değeri olabileceği gibi bir giriş, δ_j : j düğümünün hata terimi de olabilir. Bir çıkış düğümü için hata terimi (δ_j);

$$\delta_j \cong o_j(1 - o_j)(d_j - o_j) \quad (4)$$

olarak elde edilir. j düğümü bir gizli düğüm ise hata terimi (δ_j);

$$\delta_j \cong o_j(1 - o_j) \sum_k \delta_k w_{jk} \quad (5)$$

olarak düzenlenir. Bir "moment" teriminin (α) eklenmesi ile ağırlık değişimleri üzerine etki yapılabilir.

$$w_{ij}(t+1) \cong w_{ij}(t) + n(d_j - o_j)i_i + \alpha(w_{ij}(t) - w_{ij}(t-1)) \quad (6)$$

2.2. Dalgacık Dönüşümü (Wavelet Transform)

Dalgacık dönüşümü bir zaman serisini farklı frekans seviyelerindeki farklı alt serilere ayrıştırır. Ayrıştırılan alt kümeler daha yerleşik bir davranış içerisinde oldukları için daha güçlü bir tahmin imkânı sağlarlar [25]. DD, "anne dalgacık" olarak adlandırılan özgül fonksiyonun $\psi(t)$ dönüştürülmesi ve genişletilmesiyle sinyalin aile fonksiyonlarına $\psi_{a,b}(t)$ ayrılmasıdır [30,31]. Grossman ve Morlet (1984), sismik sinyalleri, sonlu süreli ve titreşimli bir sinyalin farklı zaman bazındaki şekilleriyle birleştirerek sürekli dalgacık dönüşümünü (SDD) uygulama alanına geçirmişlerdir [32,33].

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} y \left(\frac{t-b}{a} \right) \quad (7)$$

Denklemden a ve b genişletme ve dönüştürme parametreleridir.

Ayrık dalgacık dönüşümü (ADD) ise bir sinyale temel matematiksel fonksiyonlar doğrultusunda ulaşmayı amaçlamaktadır [34] ve $\psi_{a,b}(t)$ dalgacığının ayrıştırılmasıyla SDD'den türetilir. En çok kullanılan ayrıştırma yöntemi denklemde görülen ikili (dyadic) ayrıştırma [35,36]:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{2^j}} y \left(\frac{t-2^j k}{2^j} \right) \quad (8)$$

DD'nin Fourier dönüşümüne göre avantajlı dönüşümün frekans ve zaman bazlı ölçeklendirilebilir olmasıdır [37,38].

2.3. Prosedürler (Procedures)

Bu çalışmada Yeh [39] tarafından oluşturulan ve 17 farklı laboratuvarında yapılan 1030 örneklik beton dayanım testleri neticesinde elde edilen veri seti kullanılmıştır. Veri setinde 8 farklı değişken kullanılmıştır. Bu değişkenler ve değişkenlere ait temel istatistikleri gösteren Çizelge 1'de görüldüğü gibidir.

Çizelge 1. Beton bileşenleri (Concrete components).

Girdiler	Birim	Min.	Maks.	Ort.	Varyans
Çimento	kg/m ³	102.0	540.0	281.2	10921.5
Yüksek Fırın Cürufu	kg/m ³	11.0	359.4	107.3	3829.6
Uçucu Kül	kg/m ³	24.5	200.1	83.9	1599.1
Su	kg/m ³	121.8	247.0	181.6	593.1
Süperplastikleştirici	kg/m ³	1.7	32.2	8.5	16.3
Kaba Agregası	kg/m ³	801.0	1,145.0	972.9	6045.7
İnce Agregası	kg/m ³	594.0	992.6	773.6	6428.2
Numune Bekleme Süresi	gün	1.0	365.0	45.7	3990.5
Beton Basınç Dayanımı	MPa	2.3	82.6	35.8	279.1

Çalışmada yöntemlerin eğitim ve test aşamaları için ikisi k-kümelikli çapraz-geçerlilik, diğer ikisi de rassal ayırma yönteminin kullanıldığı 4 model oluşturulmuştur (Model-1: 10 kümelikli çapraz-geçerlilik, Model-2: 5 kümelikli çapraz-geçerlilik, Model-3: %90 rassal ayırma, Model-4: %80 rassal ayırma).

Açık kaynak kodlu WEKA 3.7.7. programıyla önce YSA ve DDYSA yöntemiyle en iyi sonucu ortaya çıkaracak parametrelerin bulunması amacıyla η ve α için 0.2, 0.3 ve 0.4; h için 5 ve 10 değerleri sırasıyla 500 ve 1000 iterasyon sayıları (T) ile denenecek şekilde bir test prosedürü geliştirilmiştir.

Çizelge 2, 3 ve 4'de bahsi geçen 4 model için iterasyon sayısı ve h değerlerinin sabit; η ve α değerlerinin sırasıyla 0.2, 0.3, 0.4 değerlerini almasına göre 9 deney sonucunu gösteren 16'şar adet test çalışması yapılmıştır.

Yapılan tahminlerin başarı kriteri olarak determinasyon katsayısı (coefficient of determination, R^2), ortalama mutlak hata (mean absolute error, MAE) ve ortalama hata karesinin kökü (root mean square error, RMSE) alınmıştır. Ele alınan problem için aşağıda sunulan denklemlerde ifade edilen o_i ve t_i sırasıyla yöntemin tahmin sonuçlarını ve gerçekleşen değerleri göstermektedir. N ise gözlem değerini ifade etmektedir [27].

Bağımlı değişkendeki toplam değişimin % kaçının bağımsız değişkenler tarafından açıklandığını bulmak için regresyon analizinde R^2 'den yararlanılır. R^2 değeri 0 ile 1 arasında bir değer alır. Değer 0'a yaklaşırsa modelin veriye uyum göstermediği veya bağımsız değişkenlerin bağımlı değişkendeki değişmeyi açıklayamadığı, 1'e yaklaşırsa bağımlı değişkendeki değişimin bağımlı değişkenler tarafından iyi açıklandığını gösterir.

$$R^2 = \left(1 - \frac{\sum_{i=1}^N (o_i - t_i)^2}{\sum_{i=1}^N (o_i - \bar{o}_i)^2} \right)^2 \quad (9)$$

MAE, tahmin değerleri ile gerçekleşen tahmin değerleri arasındaki mutlak hatayı sorgular. MAE değeri ne kadar sıfıra yaklaşırsa, modelinin tahmin yeteneğinin o kadar iyi olduğu sonucu çıkar.

$$MAE = \frac{1}{N} \sum_{i=1}^I |o_i - t_i| \quad (10)$$

RMSE, tahmin değerleri ile gerçekleşen tahmin değerleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. RMSE'nin sıfıra yaklaşması modelin tahmin performansının artması anlamına gelir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - t_i)^2}{N}} \quad (11)$$

3. BULGULAR (FINDINGS)

Determinasyon katsayısı (R^2) performans ölçütü sonuçlarına göre 4 modelde de dalgacık dönüşümünün

sonuçlarda ciddi iyileşme sağladığı görülmektedir (Çizelge 2.).

Model-2 (5 kümeli çapraz-geçerlilik)'de en kötü R² değerlerinde 2.3% ile 10.2%; en iyi R² değerlerin de

Çizelge 2. YSA ve DDYSA yöntemleriyle elde edilen R² sonuçları (R² results obtained by ANN and WANN).

Modeller	Test Çalışmaları ($\eta=0.2, 0.3, 0.4;$ $\alpha=0.2, 0.3, 0.4$)	YSA			DDYSA			İyileşme (%)		
		Eİ	EK	ORT	Eİ	EK	ORT	Eİ	EK	ORT
Model-1 10 Kümeli Çapraz-geçerlilik	TÇ-1 (T= 500 h=10)	0.8301	0.6068	0.7462	0.8458	0.7781	0.8199	1.9%	28.2%	9.9%
	TÇ-2 (T=1000 h=10)	0.8281	0.6137	0.7294	0.8567	0.7375	0.8164	3.5%	20.2%	11.9%
	TÇ-3 (T=1000 h=5)	0.7980	0.6750	0.7416	0.8266	0.7482	0.7930	3.6%	10.8%	6.9%
	TÇ-4 (T=500 h=5)	0.7983	0.6677	0.7441	0.8228	0.7557	0.7857	3.1%	13.2%	5.6%
	TÇ-5 (T= 500 h=10)	0.8458	0.7560	0.8007	0.8662	0.8312	0.8484	2.4%	9.9%	6.0%
Model-2 5 Kümeli Çapraz-geçerlilik	TÇ-6 (T=1000 h=10)	0.8493	0.7453	0.7900	0.8768	0.8212	0.8505	3.2%	10.2%	7.7%
	TÇ-7 (T=1000 h=5)	0.8451	0.7300	0.7888	0.8591	0.7465	0.8175	1.7%	2.3%	3.6%
	TÇ-8 (T=500 h=5)	0.8407	0.7683	0.7997	0.8521	0.7914	0.8269	1.4%	3.0%	3.4%
	TÇ-9 (T= 500 h=10)	0.9143	0.8429	0.8834	0.9378	0.9164	0.9264	2.6%	8.7%	4.9%
Model-3 %90 Rassal ayırma	TÇ-10 (T=1000 h=10)	0.9149	0.8553	0.8893	0.9442	0.8955	0.9300	3.2%	4.7%	4.6%
	TÇ-11 (T=1000 h=5)	0.9099	0.8378	0.8709	0.9120	0.9025	0.9070	0.2%	7.7%	4.1%
	TÇ-12 (T=500 h=5)	0.9078	0.8367	0.8669	0.9124	0.9012	0.9066	0.5%	7.7%	4.6%
	TÇ-13 (T= 500 h=10)	0.8938	0.6670	0.7960	0.9120	0.8940	0.9045	2.0%	34.0%	13.6%
Model-4 %80 Rassal ayırma	TÇ-14 (T=1000 h=10)	0.8921	0.6665	0.7878	0.9260	0.8879	0.9100	3.8%	33.2%	15.5%
	TÇ-15 (T=1000 h=5)	0.8921	0.7344	0.8472	0.9046	0.8860	0.8940	1.4%	20.6%	5.5%
	TÇ-16 (T=500 h=5)	0.8898	0.7422	0.8435	0.9012	0.8851	0.8938	1.3%	19.3%	6.0%

Model-1 (10 kümeli çapraz-geçerlilik) için test çalışması (TÇ) 1, 2, 3 ve 4 incelendiğinde YSA ve DDYSA yöntemleri için en iyi R² değerleri karşılaştırıldığında 1.9% ile 3.6% arasında iyileşme sağlandığı gözlenmiştir. En kötü R² değerleri karşılaştırıldığı zaman iyileşme oranlarının çok daha çarpıcı olarak 10.8% ile 28.2% arasında olduğu görülmüştür.

1.7% ile 3.2% ve ortalama sonuçlarda 3.4% ile 7.7% arasında iyileşme sağlandığı görülmüştür.

Model-3 (%90 rassal ayırma)'de en kötü, en iyi ve ortalama değerlerindeki iyileşmeler sırasıyla 4.7% ile 8.7%; 0.2% ile 3.2% ve 4.1% ile 4.9% arasında sağlanmıştır.

Çizelge 3. Modellere göre YSA ve DDYSA yöntemleriyle elde edilen R² sonuçları (R² results obtained by ANN and WANN according to the models).

	YSA			DDYSA			Improvement (%)		
	Eİ	EK	ORT	Eİ	EK	ORT	Eİ	EK	ORT
Model-1	0.8301	0.6068	0.7403	0.8567	0.7375	0.8038	3.2%	21.5%	8.6%
Model-2	0.8493	0.7300	0.7948	0.8768	0.7465	0.8358	3.2%	2.3%	5.2%
Model-3	0.9149	0.8367	0.8776	0.9442	0.8955	0.9175	3.2%	7.0%	4.5%
Model-4	0.8938	0.6665	0.8186	0.9260	0.8851	0.9006	3.6%	32.8%	10.0%

Son model olan Model-4 (%80 rassal ayırma)'de en kötü R² değerlerindeki iyileşmelerin son derece dikkate değer olarak 19.3% ile 34.0% arasında olduğu hesaplanmıştır. En iyi R² değerleri ve ortalama değerlerde, sırasıyla 1.3% ile 3.8% ve 5.5% ile 15.5% arasında iyileşmeler elde edilmiştir.

iyi (MAE: 4.97) ve en kötü (MAE: 7.25) sonuçlar sırasıyla TÇ-2 ve TÇ-4'de elde edilmiştir. Model-1 için YSA ve DDYSA ile elde edilen en iyi, en kötü ve ortalama sonuçlarda sırasıyla 11.5%, 28.0% ve 19.8% iyileşme sağlanmıştır (Çizelge 5.).

Model-2'de en iyi, en kötü ve ortalama değerlerdeki

Çizelge 4. YSA ve DDYSA yöntemleriyle elde edilen MAE sonuçları (MAE results obtained by ANN and WANN).

Modeller	Test Çalışmaları ($\eta=0.2, 0.3, 0.4;$ $\alpha=0.2, 0.3, 0.4$)	YSA			DDYSA			İyileşme (%)		
		EK	Eİ	ORT	EK	Eİ	ORT	EK	Eİ	ORT
Model-1 10 Kümeli Çapraz-geçerlilik	TÇ-1 (T= 500 h=10)	9.37	5.54	6.98	6.45	5.18	5.76	45.2%	6.9%	21.2%
	TÇ-2 (T=1000 h=10)	9.37	5.55	7.24	6.39	4.97	5.72	46.6%	11.6%	26.5%
	TÇ-3 (T=1000 h=5)	8.44	6.04	7.28	7.32	5.42	6.26	15.3%	11.5%	16.3%
	TÇ-4 (T=500 h=5)	8.80	6.01	7.31	7.25	5.51	6.32	21.4%	9.0%	15.7%
	TÇ-5 (T= 500 h=10)	6.53	4.98	5.83	5.41	4.66	5.00	20.8%	7.0%	16.7%
Model-2 5 Kümeli Çapraz-geçerlilik	TÇ-6 (T=1000 h=10)	6.39	4.90	5.70	5.44	4.37	4.92	17.6%	12.2%	16.0%
	TÇ-7 (T=1000 h=5)	6.29	5.06	5.82	5.93	4.85	5.24	6.1%	4.4%	11.0%
	TÇ-8 (T=500 h=5)	6.27	5.22	5.85	5.82	4.89	5.26	7.6%	6.7%	11.3%
	TÇ-9 (T= 500 h=10)	8.59	4.12	5.76	4.68	4.08	4.32	83.4%	1.0%	33.3%
Model-3 %90 Rassal ayırma	TÇ-10 (T=1000 h=10)	8.22	4.07	5.62	4.49	3.87	4.16	83.3%	5.1%	35.0%
	TÇ-11 (T=1000 h=5)	6.90	5.26	5.96	4.93	4.40	4.66	39.9%	19.4%	28.0%
	TÇ-12 (T=500 h=5)	6.97	5.43	6.14	5.08	4.39	4.68	37.2%	23.7%	31.2%
	TÇ-13 (T= 500 h=10)	9.42	4.58	6.72	4.29	3.86	4.15	119.5%	18.6%	62.0%
Model-4 %80 Rassal ayırma	TÇ-14 (T=1000 h=10)	9.48	4.65	6.77	4.29	3.71	4.09	120.7%	25.5%	65.3%
	TÇ-15 (T=1000 h=5)	7.44	4.42	5.43	5.38	4.25	4.80	38.3%	3.9%	13.1%
	TÇ-16 (T=500 h=5)	7.42	4.46	5.49	5.57	4.34	4.88	33.2%	2.6%	12.4%

MAE performans ölçütü sonuçlarına göre 4 model için 16 test çalışmasından elde edilen iyileşme oranları Çizelge 4.'de sunulmuştur.

Buna göre Model-1'de en iyi sonuçlarda 6.9% ile 11.6%, en kötü sonuçlarda 15.3% ile 46.6% ve ortalama sonuçlarda 15.7% ile 26.5% arasında iyileşme olduğu saptanmıştır. Model-1'de YSA ile en iyi (MAE: 5.54) ve en kötü (MAE: 9.37) sonuçlar TÇ-1'de, DDYSA ile en

iyileşmeler ise sırasıyla 4.4% ile 12.2%; 6.1% ile 20.8% ve 11.0% ile 16.7% şeklinde gerçekleşmiştir. Model-2'de YSA (4.90) ve DDYSA (4.37) ile en iyi sonuçlar TÇ-6'da elde edilmiştir. YSA ile en kötü sonuç TÇ-5 (6.53)'de, DDYSA ile en kötü sonuç TÇ-7 (5.93)'de sağlanmıştır. Buna göre YSA ve DDYSA ile elde edilen en kötü, en iyi ve ortalama sonuçlarda sırasıyla 10.1%, 12.2% ve 13.7% iyileşme sağlanmıştır (Çizelge 5.).

Çizelge 5. Modellere göre YSA ve DDYSA yöntemleriyle elde edilen MAE sonuçları (MAE results obtained by ANN and WANN according to the models).

	YSA			DDYSA			Improvement (%)		
	EK	Eİ	ORT	EK	Eİ	ORT	EK	Eİ	ORT
Model-1	9.37	5.54	7.20	7.32	4.97	6.02	28.0%	11.5%	19.8%
Model-2	6.53	4.90	5.80	5.93	4.37	5.10	10.1%	12.2%	13.7%
Model-3	8.59	4.07	5.87	5.08	3.87	4.46	69.1%	5.1%	31.8%
Model-4	9.48	4.42	6.10	5.57	3.71	4.48	70.1%	19.1%	36.2%

3. ve 4. Modeller için en iyi MAE değerlerindeki iyileşmeler sırasıyla 1.0% ile 23.7% ve 2.6% ile 25.5%; en kötü MAE değerlerindeki iyileşmeler sırasıyla 37.2% ile 83.4% ve 33.2% ile 120.7% son olarak ortalama MAE değerlerindeki iyileşmeler sırasıyla 28.0% ile 35.0% ve 12.4% ile 65.3% arasında gerçekleşmiştir. Model-3'de YSA (MAE: 4.07) ve DDYSA (MAE: 3.87) ile en iyi sonuçlar TÇ-10'da, YSA ile en kötü sonuç (MAE: 8.59)TÇ-9'da ve DDYSA ile en kötü sonuç (MAE: 5.08) TÇ-12'de elde edilmiştir.

Model-4 için ise YSA ve DDYSA ile en iyi sonuçlar (YSA-MAE: 4.42, DDYSA-MAE: 3.71) sırasıyla TÇ-15 ve TÇ-14'de, en kötü sonuçlar (YSA-MAE:9.48, DDYSA-MAE: 5.57) yine sırasıyla TÇ-14 ve TÇ-16'da elde edilmiştir.

4 Model için 16 test çalışmasından elde edilen RMSE performans ölçütü sonuçları Çizelge 6.'da sunulmuştur.

Çizelge 6. YSA ve DDYSA yöntemleriyle elde edilen RMSE sonuçları (RMSE results obtained by ANN and WANN).

Modeller	Test Çalışmaları ($\eta=0.2, 0.3, 0.4$; $\alpha=0.2, 0.3, 0.4$)	YSA			DDYSA			İyileşme (%)		
		EK	Eİ	ORT	EK	Eİ	ORT	EK	Eİ	ORT
Model-1 10 Kümeli Çapraz-geçerlilik	TÇ-1 (T= 500 h=10)	11.92	7.13	8.92	8.48	6.82	7.56	40.6%	4.4%	18.0%
	TÇ-2 (T=1000 h=10)	11.97	7.17	9.35	9.27	6.62	7.64	29.1%	8.2%	22.4%
	TÇ-3 (T=1000 h=5)	11.06	7.85	9.39	9.32	7.24	8.16	18.7%	8.5%	15.1%
	TÇ-4 (T=500 h=5)	11.45	7.79	9.38	9.25	7.27	8.30	23.7%	7.2%	13.0%
	TÇ-5 (T= 500 h=10)	8.57	6.61	7.68	6.99	6.17	6.58	22.5%	7.3%	16.7%
Model-2 5 Kümeli Çapraz-geçerlilik	TÇ-6 (T=1000 h=10)	8.62	6.60	7.80	7.23	5.92	6.54	19.1%	11.4%	19.2%
	TÇ-7 (T=1000 h=5)	8.83	6.67	7.78	8.88	6.39	7.28	-0.5%	4.4%	6.9%
	TÇ-8 (T=500 h=5)	8.11	6.81	7.60	7.84	6.52	7.08	3.4%	4.4%	7.4%
	TÇ-9 (T= 500 h=10)	10.36	5.27	7.18	5.90	4.94	5.33	75.5%	6.7%	34.6%
Model-3 %90 Rassal ayırma	TÇ-10 (T=1000 h=10)	10.00	5.22	7.01	5.96	4.70	5.22	67.7%	11.0%	34.4%
	TÇ-11 (T=1000 h=5)	8.39	6.33	7.31	5.98	5.49	5.75	40.5%	15.4%	27.3%
	TÇ-12 (T=500 h=5)	8.61	6.64	7.52	6.09	5.46	5.77	41.4%	21.6%	30.3%
	TÇ-13 (T= 500 h=10)	11.47	5.98	8.31	5.71	5.25	5.45	100.8%	14.0%	52.4%
Model-4 %80 Rassal ayırma	TÇ-14 (T=1000 h=10)	11.58	6.07	8.53	5.87	4.85	5.34	97.3%	25.3%	59.8%
	TÇ-15 (T=1000 h=5)	11.55	5.71	7.30	6.96	5.48	6.20	65.9%	4.3%	17.8%
	TÇ-16 (T=500 h=5)	11.22	5.82	7.37	7.10	5.67	6.25	57.9%	2.6%	17.9%

1, 2, 3 ve 4. Modeller için RMSE performans ölçütüne göre en iyi iyileşme oranları sırasıyla 4.4% ile 8.5%; 4.4% ile 11.4%; 6.7% ile 21.6% ve 4.3% ile 25.3% aralıklarında gerçekleşmiştir. En kötü RMSE değerleri için iyileşme oranları aralığı 1, 2, 3 ve 4. modeller için sırasıyla 18.7% ile 40.6%; -0.5% ile 22.5%; 40.5% ile 75.5% ve 57.9% ile 100.8% aralıklarında gerçekleşmiştir. Burada Model-2'de, TÇ-15 için 0.5%'lik bir kötüleşme olduğu görülmüştür. Bu değer tüm çalışma boyunca elde edilen tek olumsuz değerdir.

Model-1'de YSA ile en iyi (RMSE: 7.13) ve en kötü (RMSE: 11.97) sonuçlar sırasıyla TÇ-1 ve 2'den, DDYSA ile en iyi (RMSE: 6.62) ve en kötü (RMSE: 9.32) sonuçlar ise sırasıyla TÇ-2 ve 3'den elde edilmiştir (Çizelge 3.). Bu sonuçlar ışığında Model-1'de DDYSA ile en iyi, en kötü ve ortalama sonuçlarda sırasıyla 7.6%, 28.5% ve 17.0% iyileşmeler sağlanmıştır (Çizelge 6.).

Model-2'de YSA ve DDYSA ile hem en iyi, hem de en kötü sonuçlar TÇ-6 (YSA-RMSE: 6.60, 8.83; DDYSA-RMSE: 5.92, 8.88)'den elde edilmiştir (Çizelge 3.). Böylece en iyi, en kötü ve ortalama sonuçlarda ki değişim sırasıyla 11.4%, -0.5% ve 12.3% olarak gerçekleşmiştir (Çizelge 6.).

Model-3'de YSA ve DDYSA ile en iyi sonuçlar TÇ-10 (YSA-RMSE:5.22, DDYSA-RMSE: 4.70)'dan, YSA ile en kötü sonuç (RMSE: 10.36) TÇ-9'dan ve DDYSA ile

iyi sonuç (RMSE: 4.85) TÇ-14'den, YSA ile en kötü sonuç (RMSE: 11.58) TÇ-14'den elde edilirken, DDYSA ile en kötü sonuç (RMSE: 7.10) TÇ-16'dan elde edilmiştir. Dolayısıyla en iyi, en kötü ve ortalama değerlerdeki iyileşmeler sırasıyla 17.8%, 63.0% ve 35.6% olarak gerçekleşmiştir (Çizelge 7.).

4 model 16 ampirik çalışma sonucunda 3 performans ölçütüne göre DDYSA ile YSA'dan daha iyi tahmin performansı elde edilmiştir. YSA ve DDYSA ile R² performans ölçütüne göre en iyi sonuçlar Model-3 (YSA: 0.9149, DDYSA: 0.9442)'den, en kötü sonuçlar ise Model-1 (YSA: 0.6068, DDYSA: 0.7375)'den elde edilmiştir (Çizelge 4.). R² performans ölçütüne göre DDYSA ile en iyi, en kötü ve ortalama sonuçlarda sırasıyla 3.2%, 21.5% ve 8.6% iyileşme sağlandığı görülmüştür (Çizelge 7.).

MAE performans ölçütüne göre YSA ile en iyi (MAE: 4.07) ve en kötü (MAE: 9.48) sonuçlar sırası ile Model-3 ve Model-4'den elde edilirken, DDYSA ile en iyi (MAE: 3.87) ve en kötü (MAE: 7.32) sonuçlar sırası ile Model-3 ve Model-1'den elde edilmiştir (Çizelge 5.).

RMSE performans ölçütüne göre YSA ve DDYSA ile en iyi (YSA:5.22, DDYSA:4.70) sonuçlar Model-3'den, en kötü (YSA:11.97, DDYSA: 9.32) sonuçlar ise Model-1'den elde edilmiştir (Çizelge 6.).

MAE ve RMSE sonuçlarına göre en iyi, en kötü ve

Çizelge 7. Modellere göre YSA ve DDYSA yöntemleriyle elde edilen RMSE sonuçları (RMSE results obtained by ANN and WANN according to the models).

	YSA			DDYSA			Improvement (%)		
	EK	Eİ	ORT	EK	Eİ	ORT	EK	Eİ	ORT
Model-1	11.97	7.13	9.26	9.32	6.62	7.91	28.5%	7.6%	17.0%
Model-2	8.83	6.60	7.72	8.88	5.92	6.87	-0.5%	11.4%	12.3%
Model-3	10.36	5.22	7.25	6.09	4.70	5.52	70.1%	11.0%	31.5%
Model-4	11.58	5.71	7.88	7.10	4.85	5.81	63.0%	17.8%	35.6%

Çizelge 8: Performans ölçütlerine göre çözüm sonuçları (Solution results according to performance criteria).

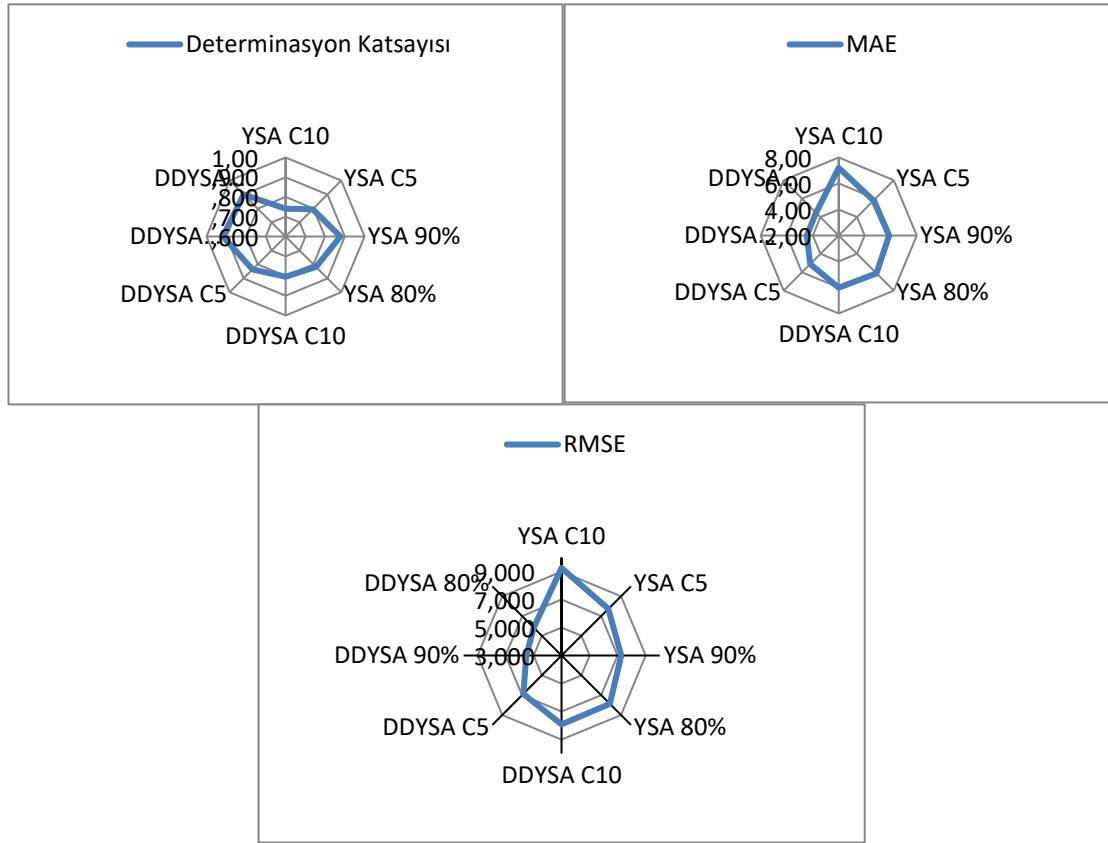
	YSA			DDYSA			Improvement (%)		
	EK	Eİ	ORT	EK	Eİ	ORT	EK	Eİ	ORT
R ²	0.6068	0.9149	0.8078	0.7375	0.9442	0.8644	21.5%	3.2%	8.6%
MAE	9.48	4.07	6.24	7.32	3.87	5.01	29.5%	9.6%	24.5%
RMSE	11.97	5.22	8.03	9.32	4.70	6.53	28.5%	11.0%	23.0%

en kötü sonuç (RMSE: 6.09) TÇ-12'den elde edilmiştir. Sonuç olarak bu modelde ki en iyi, en kötü ve ortalama değerlerdeki iyileşmeler sırasıyla 11.0%, 70.1% ve 31.5% olarak gerçekleşmiştir (Çizelge 6.).

Son model olan Model-4'de YSA ile en iyi sonuç (RMSE: 5.71)TÇ-15'den elde edilirken, DDYSA ile en

ortalama değerlerdeki iyileşmelerin sırası ile 9.6%, 29.5%, 24.5% ve 11.0%, 28.5%, 23.0% olduğu hesaplanmıştır (Çizelge 8.).

İstatistiksel performans ölçütüne göre elde edilen ortalama değerlerin grafik gösterimleri karşılaştırmalı olarak Şekil 1.'de sunulmuştur.



Şekil 1. İstatistiksel performans ölçütüne göre elde edilen ortalama değerlerin grafik gösterimleri (Graphical representation of average values obtained by statistical performance criteria).

Elde edilen sonuçlar aynı veri setinin farklı büyüklüklerinin kullanıldığı daha önceki çalışmalarla karşılaştırıldığında, YSA ile benzer sonuçlar elde edilmiş fakat DDYSA yöntemiyle önceki çalışmalardan daha yüksek tahmin başarısı elde edilmiştir. Literatürde, aynı veri seti kullanılarak yapılan çalışmaların bulguları Çizelge 9.'da sunulmuştur.

DDYSA'ların tahmin performansının YSA'dan daha iyi olduğu görülmüştür.

Sonuç olarak; dalgacık dönüşümünün genelde çok boyutlu doğrusal olmayan tahmin problemlerinde, özelde ise YPB'nin basınç dayanımının tahmin edilmesinde etkin bir yaklaşım olduğu ve yöntemin araştırma laboratuvarları ve beton üreticileri tarafından kullanılabilceği sonucuna varılmıştır.

Çizelge 9. Önceki Çalışmaların Bulguları (Findings of the previous studies).

Önceki Çalışmalar	Yöntemler	Veri seti büyüklüğü	(R ²)
Yeh [3]	YSA	727	0.8354
Chou vd. [10]	YSA	1030	0.8263
Erdal vd. [36]	YSA	1030	0.9088
	DDYSA		0.9397
Erdal [28]	YSA	1030	0.7379

4. SONUÇLAR (CONCLUSION)

Bu çalışmada YPB'nin basınç dayanımının tahmin edilmesi için YSA ve DDYSA yöntemleriyle karşılaştırmalı bir analiz gerçekleştirilmiştir. Bu kapsamda 17 farklı laboratuvarda yapılan 1030 örneklik beton dayanım değerleri ile 8 farklı değişken ve verinin eğitim ile test verisi olarak ayrılması için 4 farklı model kullanılmıştır. Her iki yöntemle yapılan tahminler sonucunda; tutarlılık ve tahmin gücü açısından

KAYNAKLAR (REFERENCES)

- Hong-Guang, N., and Ji-Zong, W., Prediction of Compressive Strength of Concrete by Neural Networks, *Cement and Concrete Research*. 30: 1245-1250, (2000).
- Seyhan, A. T., Tayfur, G., Karakurt, M., Tanoğlu, M., Artificial Neural Network (YSA) Prediction of Compressive Strength of VARTM Processed Polymer Composites, *Computational Materials Science*. 34: 99-105, (2005).

3. Yeh, I. C., Modeling of Strength of High-Performance Concrete Using Artificial Neural Networks, *Cement and Concrete Research*, 28: 1797-1808, (1998).
4. Topcu, I. B., and Saridemir, M., Prediction of Compressive Strength of Concrete Containing Fly Ash Using Artificial Neural Networks and Fuzzy Logic, *Computational Materials Science*, 41: 305–311, (2008).
5. Atıcı, U., Prediction of the Strength of Mineral Admixture Concrete Using Multivariable Regression Analysis and An Artificial Neural Network. *Expert Systems with Applications*. 38: 9609–9618, (2011).
6. Nikoo, M., Zarfam, P., and Sayahpour, H., Determination of Compressive Strength of Concrete Using Self Organization Feature Map (SOFM), *Engineering with Computers*, 1-9, (2013).
7. Fazel-Zarandi, M. H., Türksen, I. B., Sobhani, J., and Ramezani-pour, A. A., Fuzzy polynomial Neural Networks for Approximation of the Compressive Strength of Concrete, *Appl. Soft Comput.*, 8(1): 488-498, (2008).
8. Yeh, I.C., and Lien, L-C., Knowledge Discovery of Concrete Material Using Genetic Operation Trees, *Expert Systems with Applications*, 36: 5807–5812, (2009).
9. Cheng, M-Y., Peng, H-S., Wu, Y-W., and Chen, T-L., Estimate at Completion for Construction Projects Using Evolutionary Support Vector Machine Inference Model, *Automation in Construction*. 19: 619–629, (2010).
10. Chou, J. S., Chiu, C. K., Farfoura, M., and Al-Taharwa, I., Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on A Comparison of Data-mining Techniques, *Journal of Computing In Civil Engineering*, 25: 242-253, (2011).
11. Cheng, M-Y., Firdausi, P. M., and Prayogo, D., High-performance Concrete Compressive Strength Prediction using Genetic Weighted Pyramid Operation Tree (GW POT), *Engineering Applications of Artificial Intelligence*. 29: 104–113, (2014).
12. Xing, Y. F., Wang, Y. S., Shi, L., Guo, H., & Chen, H., Sound quality recognition using optimal wavelet-packet transform and artificial neural network methods, *Mechanical Systems and Signal Processing*, 66: 875-892, (2016).
13. Karami, A., Zanj, B., & Sarkaleh, A. K., Persian sign language (PSL) recognition using wavelet transform and neural networks, *Expert Systems with Applications*, 38(3): 2661-2667, (2011).
14. Manea, S.M., Kambilib, R.A., Kazic, F.S., & Singhc, N.M., Hand Motion Recognition From Single Channel Surface EMG Using Wavelet & Artificial Neural Network, *Procedia Computer Science*, 49: 58-65, (2015).
15. Chaturvedi, D. K., Sinha, A. P., & Malik, O. P., Short term load forecast using fuzzy logic and wavelet transform integrated generalized neural network, *International Journal of Electrical Power & Energy Systems*, 67: 230-237, (2015).
16. Catalão, J. P. S., Pousinho, H. M. I., & Mendes, V. M. F., Short-term wind power forecasting in Portugal by neural networks and wavelet transform, *Renewable Energy*, 36(4): 1245-1251, (2011).
17. Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L., & Wang, J., Artificial neural networks forecasting of PM 2.5 pollution using air mass trajectory based geographic model and wavelet transformation, *Atmospheric Environment*, 107: 118-128, (2015).
18. Hsieh, T. J., Hsiao, H. F., & Yeh, W. C., Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm, *Applied soft computing*, 11(2): 2510-2525, (2011).
19. Kalteh, A. M., Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform, *Computers & Geosciences*, 54: 1-8, (2013).
20. Jamil, M., Kalam, A., Ansari, A. Q., & Rizwan, M., Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line, *Applied Soft Computing*, 19: 322-332, (2014).
21. Chen, C. F., Chen, C. R., Son, N. T., & Chang, L. Y., Delineating rice cropping activities from MODIS data using wavelet transform and artificial neural networks in the Lower Mekong countries, *Agriculture, ecosystems & environment*, 162: 127-137, (2012).
22. Tagluk, M. E., Akin, M., & Sezgin, N., Classification of sleep apnea by using wavelet transform and artificial neural networks, *Expert Systems with Applications*, 37(2): 1600-1607, (2010).
23. Wang, N., & Adeli, H., Self-constructing wavelet neural network algorithm for nonlinear control of large structures, *Engineering Applications of Artificial Intelligence*, 41: 249-258, (2015).
24. Liu, S., Du, C., Mou, J., Martua, L., Zhang, J., & Lewis, F. L., Diagnosis of structural cracks using wavelet transform and neural networks, *NDT & E International*, 54: 9-18, (2013).
25. Tascikaraoglu A, Sanandaji BM, Poola K, Varaiya P. Exploiting sparsity of interconnections in spatio-temporal wind speed forecasting using Wavelet Transform, *Applied Energy*, 165(1): 735-747, (2016).
26. Aydoğmuş, H.Y., Ekinçi, A., Erdal, H.İ. & Erdal, H., Optimizing the monthly crude oil price forecasting accuracy via bagging ensemble models, *Journal of Economics and International Finance*, 7(5): 127-136, (2015).
27. Aydogmus, H.Y., Erdal, H.İ., Karakurt, O., Namli, E., Turkan, Y.S. & Erdal, H. A comparative assessment of bagging ensemble models for modeling concrete slump flow, *Computers and Concrete*, 16(5): 741-757, (2015).
28. Erdal, H., Makine Öğrenmesi Yöntemlerinin İnşaat Sektörüne Katkısı: Basınç Dayanımı Tahminlemesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 21(3), 109-114, (2015).
29. Öztemel, E., Yapay Sinir Ağları, İstanbul, *Papatya Yayınılık*, (2003).
30. Haşiloğlu, A. S., & Bayramoğlu, M., A New Windowing Technique in Texture Classification, *Anadolu Üniversitesi Bilim Ve Teknoloji Dergisi*, (2001).
31. Meyer Y. Wavelets-algorithms and applications, *Wavelets-Algorithms and applications Society for Industrial and Applied Mathematics Translation.*, 142 p., (1993).
32. Gholizadeh, S., & Samavati, O. A., Structural optimization by wavelet transforms and neural networks. *Applied Mathematical Modelling*, 35(2): 915-929, (2011).
33. Grossmann A, Morlet J. Decomposition of Hardy functions into square integrable wavelets of constant shape, *SIAM journal on mathematical analysis*, 15(4): 723-36, (1984).
34. Kilic N, Gorgel P, Ucan ON, Sertbas A. Mammographic mass detection using wavelets as input to neural networks, *Journal of medical systems*, 34(6): 1083-1088, (2010),
35. Saravanan N, Ramachandran KI. Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural

- network (ANN). *Expert Systems with Applications*, 30; 37(6): 4168-81, (2010).
36. Erdal HI, Karakurt O, Namli E. High performance concrete compressive strength forecasting using ensemble models based on discrete wavelet transform. *Engineering Applications of Artificial Intelligence*, 30; 26(4): 1246-54, (2013).
37. Küçük M, Ağırlioğlu N. Dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmesi, *İtüdergisi/d.*, 29; 5(2): (2011).
38. Chalus P, Walter S, Ulmschneider M., Combined wavelet transform-artificial neural network use in tablet active content determination by near-infrared spectroscopy. *Analytica chimica acta.*, 22; 591(2): 219-24, (2007).
39. Yeh, I. C., UCI Machine Learning Repository, *University of california*, [http://archive.ics.uci.edu/ml/datasets/Concrete + Compressive+Strength](http://archive.ics.uci.edu/ml/datasets/Concrete+Compressive+Strength), (2014).