

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

M. Levent KOÇ*

Can E. BALAS**

Abdussamet ARSLAN***

ÖZ

Yapay sinir ağları, karmaşık sistemlerin modellenmesinde son yıllarda yaygın olarak kullanılan bir yapay zeka tekniğidir ve insan beynindeki biyolojik sinir hücrelerinin basitleştirilmiş olarak modellenmesine dayanmaktadır. Taş dolgu dalgakıranların tasarımında yaygın olarak kullanılan Van der Meer denklemleri hidrolik model deneylerinin sonuçlarından elde edilmiş ve deney verilerini ortalama olarak ifade edebilen denklemlerdir ve bu nedenle tasarım aşamasında önemli bir değişkenlik ve belirsizlik kaynağı olarak yapının güvenilirliğini etkilemektedirler. Taş dolgu kıyı yapılarının ön tasarımı için Van der Meer deney verilerini içeren bir "tasarım yapay sinir ağı" geliştirilmiş ve Mersin Yat Limanı ön tasarımı için uygulanmıştır. Elde edilen sonuçlar, ileri beslemeli denetimli sinir ağlarının Van der Meer denklemlerine kıyasla daha yüksek bir modelleme yeteneği gösterebileceğini ortaya koymuştur. Deterministik yöntemler yerine doğrusal olmayan yapay zeka tekniklerinin uygulanması ve bu sayede belirsizliklerin azaltılması ya da işlenebilmesi, taş dolgu dalgakıranların karmaşık modellere gereksinim duyulmadan tasarlanmasını sağlamıştır.

Anahtar Sözcükler: Yapay zeka, taş dolgu dalgakıran, yapay sinir ağı

ABSTRACT

Preliminary Design of Rubble Mound Breakwaters by Using Artificial Neural Networks

A neural network is an artificial intelligence technique used in complex systems. It is based on the simplified simulation of biological neurons in human brain. Van der Meer equations are utilized for the design of rubble mound breakwaters. Van der Meer equations are the most commonly utilized empirical equations for the preliminary design of rubble mound breakwaters. However, since these equations only represent the mean value of hydraulic model tests, there exists significant uncertainties and variations in the design. In order to

Not: Bu yazı

- Yayın Kurulu'na 28.04.2003 günü ulaşmıştır.
- 31 Aralık 2004 gününe kadar tartışmaya açıktır.

* Cumhuriyet Üniversitesi, İnşaat Mühendisliği Bölümü, Sivas - mkoc@cumhuriyet.edu.tr

** Gazi Üniversitesi, İnşaat Mühendisliği Bölümü, Ankara - cbalas@gazi.edu.tr

*** Gazi Üniversitesi, İnşaat Mühendisliği Bölümü, Ankara - aarslan@gazi.edu.tr

pre-design of rubble mound breakwaters, “artificial neural networks for design” were established and applied preliminary design of Mersin Yacht Harbour. The results showed that neural networks have a better performance in the ability of modelling than Van der Meer equations. Artificial neural networks can handle more accurately the uncertainties inherent in the design of rubble mound breakwaters than deterministic design; hence the need of complex models generally used for the design has been significantly decreased.

Key Words: Artificial intelligence, breakwaters, artificial neural networks

1. GİRİŞ

İnsan düşüncesini ve davranışını taklit edebilen sistemlerin geliştirilmesine yönelik çalışmaların tümü yapay zeka olarak tanımlanabilir. Yapay zeka teknikleri, birbirinden tümüyle farklı uygulamalar olmasına karşın, belirsizlikler üzerine kurulan sistemler olması bu tekniklerin ortak yönü olarak değerlendirilebilir. Başka bir deyişle, klasik yöntemlerde ortaya çıkan belirsizlikler istenmeyen ve ayrıca değerlendirilmesi gereken durumlarken; yapay zeka teknikleri belirsizlikleri içeren ve işleyen uygulamalardır. Yapay zeka uygulamalarından/tekniklerinden olan yapay sinir ağları (artificial neural networks) biyolojik sinir hücrelerinin basitleştirilmiş olarak modellenmesi yardımıyla öğrenebilen sistemlerin geliştirilmesinde kullanılan uygulamalardır ve farklı mühendislik alanlarında olduğu kadar inşaat mühendisliğinin değişik alanlarında da [1,2] son yıllarda yaygın olarak kullanılmaktadır.

Mühendislik problemlerindeki belirsizliklerin kaynağı, model ve modelin içerdiği parametreler olup sözkonusu belirsizlikler genellikle olasılık teorisi ve istatistiksel yöntemler yardımıyla gözönüne alınmaktadır. Belirsizlikler altında ortaya çıkacak başarısızlıklar (risk) ise güvenilirlik analizi yardımıyla belirlenmektedir. Özellikle karmaşık ve modelleme olanaklarının zor olduğu birçok mühendislik probleminin çözümünde, geliştirilen modelin yetersiz olması önemli bir belirsizlik nedeni olmakla birlikte çözüm sırasında yapılacak kabuller veya basitleştirmeler de belirsizliği arttıran faktörlerdir. Bir mühendislik yapısının tasarımında karşılaşılan belirsizlikler, istatistiksel yöntemler yardımıyla gözönüne alınmasına karşılık modelin içerdiği parametrelerin rassal değişken olması da başka bir belirsizlik kaynağı olarak verilebilir: Bu tür yöntemlerde, tasarım değişkenleri belirli olasılık dağılımları ile ifade edilmesine karşın değişkenlere ait istatistiksel bilgilerin yetersiz olması ve çoğunlukla ortalama ve standart sapma değerleriyle sınırlı kalması belirsizliğe neden olabilmektedir. Dolayısıyla, yüksek derecede belirsizlik gösteren (karmaşık) mühendislik problemlerinin çözümünde belirsizliklerin azaltılmasına ve değerlendirilmesine yönelik klasik yaklaşımlar, çoğunlukla daha karmaşık ve zaman-maliyet açısından ekonomik olmayan çözümlere neden olabilmektedir.

Yapay sinir ağları, yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır. Sınıflandırma, kümeleme, regresyon ve zaman serilerinin tahmini gibi değişik alanlarda kullanılan yapay sinir ağları uygulamalarının en büyük avantajı, karmaşık modellere gereksinim duyulmaksızın yalnızca ağın eğitilmesi yoluyla problemlere çözüm getirebilmesidir. Bu nedenle, yapay zeka tekniklerinin, belirsizlikler gözönüne alındığında, klasik yöntemlerin sağlayamayacağı avantajlara sahip olduğu söylenebilir.

Taş dolgu dalgakıranlar, deniz mühendisliğinde yüksek maliyete ve Türkiye’de en çok hasar olasılığına sahip yapılardır, ayrıca dayanım ve olası yük değerlerine bağlı yoğun belirsizlikler içerirler. Kıyı yapıları, ön tasarım aşamasında genellikle yarı-deneysel denklemler yardımıyla [3,4] deterministik olarak tasarlanmakta ancak belirsizlik aralıkları gözönüne alınmamaktadır. Bu nedenle tasarım sırasında belirsizliklerin de dikkate alındığı istatistiksel yöntemlerden yararlanılması zorunludur [5]. Tasarım aşamasında kullanılan eşitliklerde belirsizlik nedeni geniş bir değer aralığının (değişkenliğin) eşitlik içerisinde ortalama değerlerle ifade edilmesidir; ayrıca, tasarım parametreleri olan yük ve dayanım değişkenleri de diğer belirsizlik kaynaklarını oluşturmaktadır [6]. Tasarım aşamasında belirsizliğin kara yapılarına oranla taş dolgu dalgakıranlarda çok daha yüksek olması yapay sinir ağlarının, kıyı yapılarının tasarımına uygulanmasını zorunlu hale getirmektedir. Belirsizliklerin gözönüne alınmasında, istatistiksel yöntemlerle birlikte [7,8,9,10] yapay sinir ağlarının da kullanılması, yüksek maliyetli olan bu yapıların daha ekonomik ve daha emniyetli bir şekilde tasarımına katkıda bulunacaktır.

Son yıllarda, birçok mühendislik probleminin çözümünde kullanılan yapay sinir ağları, taş dolgu dalgakıranların tasarımı üzerine yapılan tek çalışmada [11], taş dolgu dalgakıranlar için denge (stabilite) analizi amacıyla kullanılmıştır. Çalışmada ileri beslemeli denetimli (multi layer feed forward) bir yapay sinir ağı kullanılmış ve Van der Meer’in model deneylerinden elde edilen verilerle eğitilmiştir. Çalışmanın amacı, stabilite sayısının ve hasar seviyesinin tahminidir. Stabilite sayısının tahmininde, permeabilite katsayısı, hasar seviyesi, Iribarren sayısı ve dalga sayısı ağı girdileri olarak alınmıştır. Tahmin edilen değerlerin model deneylerinden elde edilen değerlerle uyumlu olduğu gözlenmiş ancak yapay sinir ağların performansı Van der Meer denklemlerine kıyasla düşük bulunmuştur.

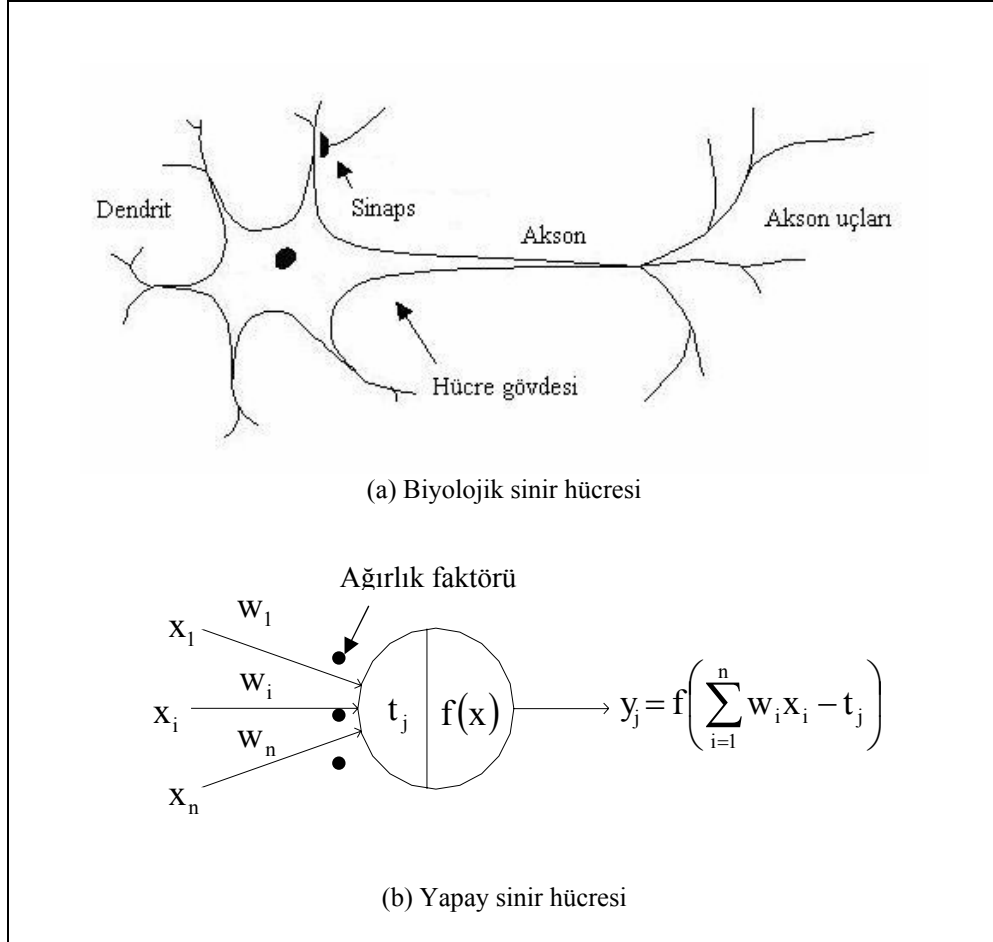
Bu çalışmada, Türkiye’deki ilk uygulamalardan biri olmak üzere, yapay sinir ağları, taş dolgu dalgakıranların stabilite sayılarının tahmininde kullanılmıştır. Yapay sinir ağlarının eğitilme aşamasında veri tabanları rassal değişken (noise) ilave edilmesi ve Esas Bileşen Analizi (Principal Component Analysis) olmak üzere katışık (hybrid) yaklaşımlar denenmiştir. Elde edilen sonuçlar yapay sinir ağlarının karmaşık modellere gereksinim duyulmadan taş dolgu dalgakıranların stabilite sayılarının tahmininde kullanılabileceğini ve literatürde yer alan çalışmadan [11], farklı olarak Van der Meer denklemlerinden daha yüksek bir modelleme yeteneği gösterebileceğini ortaya koymuştur. Ayrıca, ağına tasarıma yönelik olarak kullanılması amaçlanmış ve eğitilen yapay sinir ağı ile Mersin Yat Limanı ana dalgakıranı ön tasarımı yapılmıştır.

2. YAPAY SİNİR AĞLARI

Biyolojik sinir ağlarının temel elemanı sinir hücreleridir ve insan beyninin korteks kısmında yer alan nöron (sinir hücresi) sayısı yaklaşık olarak 10^{11} olup her hücre sayısı, 1000-10000 arasında değişen başka hücrelerle karşılıklı ilişki içerisindedir. Bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve akson’dur [12]. Sinir hücresine (Şekil 1.a) diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücrelere aksonlarla iletilir; uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar. Sinaptik boşluk içinde yer alan “sinaptik kesecikler” gelen uyarımların diğer hücrelere dendritler aracılığıyla geçmesini koşullayan elemanlardır. Sinaptik boşluğa, “sinaptik kesecikler” tarafından sağlanan nöro-iletken maddenin dolması uyarımların diğer hücrelere

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

geçişini koşullar. Hürelere gelen uyarımlarla uyumlu olarak hürelere arasındaki mevcut sinaptik ilişkilerin deęişimi veya hürelere arasında yeni sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir.



Şekil 1. Biyolojik ve yapay sinir hücresi

Yapay sinir ağları esas olarak biyolojik nöronların basitleştirilmiş bir şekilde matematiksel olarak modellenmesine dayanmaktadır [13,14]. Biyolojik ve yapay sinir hücreleri arasındaki benzeşim (Şekil 1), hürelere arasındaki bağlantılar (hücreye gelen ve hücreden çıkan uyarımlar) akson ve dendritlere; ağırlık faktörleri (w_i) sinapslara ve sınır değerler (t_j) hücre içi kararlılık haline karşılık gelecek şekilde oluşturulmaktadır (Şekil 3.1.b): Yapay sinir hücresinde, ağırlık faktörünün etkisine bağlı olarak (w_1, w_2, \dots, w_n) hücreye gelen uyarımlar (x_1, x_2, \dots, x_n) hücre içi denge durumu veya sınır değeri (t_j) de dikkate alınarak doğrusal olmayan bir aktivasyon fonksiyonu $f(\cdot)$ yardımıyla çıktı şeklinde uyarımlara (y_j) dönüştürülür (Şekil 1.b). Yapay sinir hücrelerinin genellikle katmanlı bir yapı gösterecek biçimde birbirine bağlanmasıyla yapay sinir ağları meydana getirilir ve yapay

sinir hücreleri arasında kurulan bağlantılara ait ağırlık faktörlerinin, uyarımlarla uyumlu olacak şekilde değiştirilmesi benzer şekilde biyolojik “öğrenme” sürecine karşılık gelir.

Yapay sinir ağırları insan beyninin öğrenme, düşünme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır ve kullanım amaçlarına göre değişik tiplerde yapay sinir ağırları bulunmaktadır. Sınıflandırma, kümeleme, modelleme ve tahmin gibi değişik işlemlerde kullanılan yapay sinir ağırlarının [15] en büyük avantajları doğrusal olmayan sistemleri modelleyebilmesi; bilgiyi paralel olarak işleyebilmesi ve yeni durumlara uyum sağlayabilme yeteneği olarak verilebilir. Yapay sinir ağırları genel olarak ağ yapısına göre ileri beslemeli ve geri beslemeli yapay sinir ağırları; eğitime algoritmalarına bağlı olarak ise denetimli ve denetimsiz yapay sinir ağırları olarak sınıflandırılabilir. İleri beslemeli denetimli yapay sinir ağırları en yaygın kullanılan yapay sinir ağırlarıdır [16].

Girdi, çıktı ve bir veya daha çok ara katmanlardan oluşan ileri beslemeli denetimli yapay sinir ağırları, girdi ve çıktı katmanları arasında tek doğrultuda aktivasyon gösteren sinir ağırlarıdır ve aynı katman üzerinde bulunan hücreler arasında da herhangi bir ilişki yoktur. Ara katmandaki hücre sayısını belirleyen farklı yaklaşımlar olmasına karşın [17] genel olarak hücre sayısı deneme-yanılma yoluyla belirlenmektedir. Şekil 2’de tek ara katmanlı ileri beslemeli denetimli bir sinir ağı örneği olarak verilmiştir. Burada, yapay sinir ağının girdi vektörü $\mathbf{x}=(x_1,x_2,x_k)$, kullanılarak elde edilen ara katman çıktı vektörü $\mathbf{h}=(h_1,h_2,h_3,h_s)$ çıktı katmanında işlendikten sonra çıktı vektörüne $\mathbf{y}=(y_1,y_2,y_z)$ dönüştürülür ve gözönüne alınan tüm girdi vektörleri $\mathbf{X}=[\mathbf{x}(1),\dots,\mathbf{x}(N)]$ için çıktı vektörleri $\mathbf{Y}=[\mathbf{y}(1),\dots,\mathbf{y}(N)]$, N: girdi ve çıktı vektörlerinin sayısı olmak üzere aşağıdaki şekilde hesaplanır:

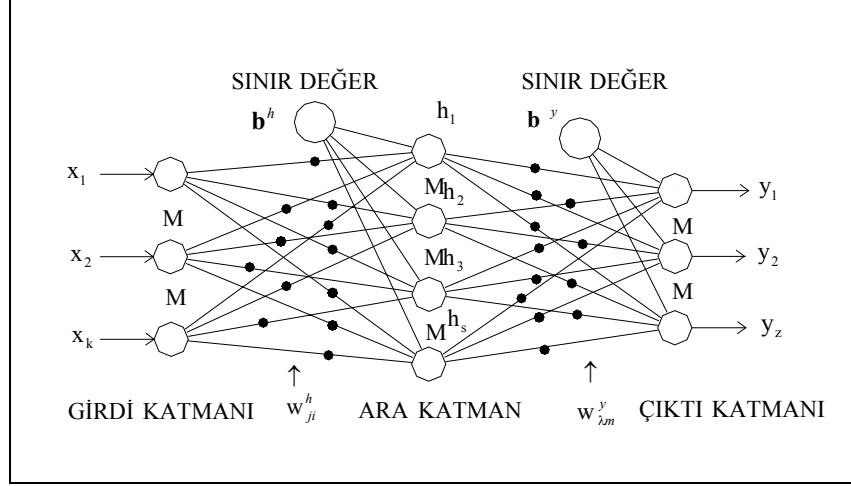
$$\mathbf{Y} = \varphi(\mathbf{W}^y [\psi(\mathbf{W}^h \mathbf{X} + \mathbf{b}^h)] + \mathbf{b}^y) \quad (1)$$

Denklem (1)’de $\varphi(\cdot)$: çıktı katmanına ait hücreler için aktivasyon fonksiyonu, $\psi(\cdot)$: ara katmana ait hücreler için aktivasyon fonksiyonu, \mathbf{b}^h : ara katmandaki hücrelere ait sınır değer vektörü, \mathbf{b}^y : çıktı katmanındaki hücrelere ait sınır değer vektörü, \mathbf{W}^y : ara katman ile çıktı katmanı arasındaki bağlantılar için ağırlık faktörleri, \mathbf{W}^h : ara katman ile girdi katmanı arasındaki bağlantılar için ağırlık faktörleri olarak alınmış olup sözkonusu ağırlık faktörleri aşağıdaki şekillerde tanımlanmıştır (Şekil 2):

$$\mathbf{W}^h = \begin{bmatrix} w_{11}^h & \dots & w_{1i}^h & \dots & w_{1k}^h \\ \dots & \dots & \dots & \dots & \dots \\ w_{j1}^h & \dots & w_{ji}^h & \dots & w_{jk}^h \\ \dots & \dots & \dots & \dots & \dots \\ w_{s1}^h & \dots & w_{si}^h & \dots & w_{sk}^h \end{bmatrix} \quad j = 1, \dots, s; \quad i = 1, \dots, k \quad (2)$$

$$\mathbf{W}^y = \begin{bmatrix} w_{11}^y & \dots & w_{1m}^y & \dots & w_{1s}^y \\ \dots & \dots & \dots & \dots & \dots \\ w_{\lambda 1}^y & \dots & w_{\lambda m}^y & \dots & w_{\lambda s}^y \\ \dots & \dots & \dots & \dots & \dots \\ w_{z1}^y & \dots & w_{zm}^y & \dots & w_{zs}^y \end{bmatrix} \quad \lambda = 1, \dots, z; \quad m = 1, \dots, s \quad (3)$$

Yapay sinir ağırları uygulamaları genellikle eğitime ve test olmak üzere iki aşamada oluşturulur. Eğitime aşaması, katmanlar arasındaki ağırlık faktörlerinin ve sınır değerlerin bir eğitime algoritması yardımıyla hata seviyesi kabul edilebilir bir düzeye gelinceye kadar iteratif olarak düzeltilmesinden meydana gelir; ağırlık faktörlerindeki değişim, öğrenme olarak da tanımlanabilir. Test aşamasında ise eğitime aşamasında kullanılmayan girdi ve çıktı verileri kullanılarak ağın performansı ölçülür. Değişik eğitime algoritmaları olmakla birlikte momentum katsayılı gradyan azalma ve konjuge gradyan eğitime algoritmaları yaygın kullanılan eğitime algoritmalarına örnek olarak verilebilir [16,18].



Şekil 2. İleri beslemeli denetimli yapay sinir ağı

Momentum katsayılı gradyen azalma algoritması, performans indeksinin (hata fonksiyonunun) minimizasyonuna dayanır ve ağırlık faktörleri, performans indeksi gradyeninin negatif doğrultusunda hareket edilmesiyle iteratif olarak düzeltilir :

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \eta \nabla J(\mathbf{w}) + \alpha \Delta \mathbf{w}(k-1) \quad (4)$$

Burada, \mathbf{w} : vektörel olarak ağırlık faktörü, k : iterasyon sayısı, η : öğrenme oranı, α : momentum katsayısı ve $\nabla J(\mathbf{w})$: performans indeksinin gradyenidir. Performans indeksinin gradyeni ise ∇E : karesel hata fonksiyonunun gradyeni, N : girdi ve çıktı vektörlerinin sayısı ve z : çıktı katmanındaki hücre sayısı olmak üzere vektörel olarak Şekil 3.2'de verilen yapay sinir ağı için aşağıdaki şekillerde ifade edilir:

$$\nabla J(\mathbf{w}) = \frac{1}{zN} \sum_{n=1}^N \nabla E(\mathbf{w}, n) \quad (5)$$

$$\nabla E(\mathbf{w}, n) = \left[\frac{\partial E}{\partial w_{11}^h} \Lambda \quad \frac{\partial E}{\partial w_{ji}^h} \quad \frac{\partial E}{\partial w_{11}^y} \Lambda \quad \frac{\partial E}{\partial w_{lm}^y} \right] \quad (6)$$

Öğrenme oranı ve momentum katsayısının seçilmesinde değişik yaklaşımlar olmasına karşın [19] bu katsayılar, genellikle 0-1 arasında değerler alacak şekilde deneme-yanılma yoluyla seçilmektedir.

3. TAŞ DOLGU DALGAKIRANLARIN YAPAY SİNİR AĞLARI İLE ÖN TASARIMI

Türkiye'de, malzeme açısından ekonomik olmaları nedeniyle yaygın olarak tercih edilen kıyı yapıları taş dolgu dalgakıranlardır ve yüksek maliyete sahip bu yapılarda, farklı hasar biçimleri ile karşılaşılmasına karşın en önemli hasar biçimi koruma tabakasında kayma veya oyulma şeklinde meydana gelen hasarlardır [20]. Taş dolgu dalgakıranların

tasarımında karşılaşılan belirsizlikler, yük ve dayanım değişkenlerinin yanısıra tasarım sırasında kullanılan deneysel eşitliklerden de kaynaklanmaktadır. Belirsizlik faktörleri, yapının tasarım ömrü içinde gerçekleşebilecek hasar riskinin yanında güvenilirlik seviyesini de etkilemektedirler. Taş dolgu dalgakıranların içerdiği yüksek derecedeki belirsizlikler dikkate alındığında, belirsizlikler üzerine kurulan yapay sinir ağları, istatistiksel yöntemlerle birlikte, bu yapıların tasarımında kullanılacak alternatif yaklaşımlardan birini oluşturmaktadır. Bu çalışmada, yapay sinir ağları, taş dolgu dalgakıranların tasarımına iki farklı aşamada uygulanmıştır: Birinci aşamada deterministik tasarıma alternatif olarak yapay sinir ağları tek başına uygulanırken; ikinci aşamada, yapay sinir ağlarının eğitilmesinde esas olarak, mevcut veri tabanının düzenlenmesi ve Esas Bileşen Analizi olmak üzere katışık yaklaşımlar denenmiştir. Elde edilen sonuçlara bağlı olarak yapay sinir ağlarının performansı (modelleyebilme yeteneği), Mersin Yat Limanı anadalgakıranı ön tasarımı örneğinde, deterministik yaklaşımla karşılaştırılarak değerlendirilmiştir. Burada amaç, yüksek maliyet gerektiren taş dolgu dalgakıranların daha ekonomik ve daha emniyetli olarak tasarımında, yapay zeka tekniklerinin kullanılma olanaklarının araştırılması olmuştur.

3.1. Taş Dolgu Dalgakıranlarda Deterministik Tasarım

Yüksek maliyete sahip taş dolgu dalgakıranlarda en önemli hasar şeklini koruma tabakasında ortaya çıkacak hasarlar oluşturmaktadır. Koruma tabakasının tasarımında, genellikle yük ve dayanım değişkenleri arasındaki statik denge durumunu ifade eden Hudson ve Van der Meer denklemleri kullanılmaktadır [3,4]. Ancak, taş dolgu dalgakıranların tasarımında yaygın olarak kullanılan Van der Meer denklemleri hidrolik model deneylerinin sonuçlarından elde edilmiş ve deney verilerini ortalama olarak ifade edebilen eşitliklerdir ve bu nedenle tasarım aşamasında karşılaşılan önemli belirsizlik kaynaklarıdır. Van der Meer denklemleri, Hudson denkleminin, [3] düzenli dalga koşullarını yansıtmaması yanında dalga dönemi, geçirgenlik gibi parametreleri ihmal etmesi nedeniyle daha gelişmiş bir özellik göstermektedir ve model deneylerinden elde edilen sonuçlara bağlı olarak Van der Meer tarafından sıçrayarak ve yansıyarak kırılan dalga durumları için sırasıyla aşağıdaki şekillerde verilmiştir [4]:

$$N_s = [6.2P^{0.18} \left(\frac{S}{\sqrt{N_f}}\right)^{0.2}] / \sqrt{\varepsilon_m} \quad \varepsilon_m < \varepsilon_c \quad (7)$$

$$N_s = 1.0P^{-0.13} \left(\frac{S}{\sqrt{N_f}}\right)^{0.2} \sqrt{\cot \theta} \varepsilon_m^P \quad \varepsilon_m \geq \varepsilon_c \quad (8)$$

$$\varepsilon_m = \frac{\tan \theta}{\sqrt{2\pi H_s / gT_m^2}} \quad (9)$$

$$\varepsilon_c = (6.2P^{0.31} \sqrt{\tan \theta})^{1/(P+0.5)} \quad (10)$$

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

Burada, $N_s = \frac{H_s}{\Delta D_{n50}}$ ve $S = \frac{A}{D_{n50}^2}$ olup N_s : stabilite sayısı, P : dalgakıranın

permeabilite katsayısı, S : hasar seviyesi, N_f : fırtınadaki dalga sayısı, ε_m : boyutsuz Iribarren parametresi, ε_c : boyutsuz Iribarren parametresinin kritik değeri, θ : koruma tabakasının eğim açısı, H_s : dalgakıran topuğundaki belirgin dalga yüksekliği, Δ : koruma tabakası taşının göreceli yoğunluğu, D_{n50} : koruma tabakası taşının çapı, A : dalgakıran kesitindeki hasar alanı, g_g : yerçekimi ivmesi, T_m : ortalama dalga dönemi (periyodu) olarak alınmıştır. Türkiye'de dalgakıran projelerinin ön projelendirme aşamalarında yaygın olarak kabul edilen hasar seviyesi Hudson denkleminin kullanılması halinde % 0-5 (hasar meydana gelmemesi durumu) arasında değişir ve koruma tabakası, köşeli ve pürüzlü ocak taşlarının rassal olarak iki tabaka halinde yerleştirilmesi ile elde edilir. Bu hasar aralığı Van der Meer denklemleri için hasar seviyesinin $S=2$ olması haline karşılık gelmektedir. Hudson denklemi için % 5-10, 10-15, 15-20, 20-30, 30-40 ve 40-50 aralıklarında verilen hasar seviyeleri ise Van der Meer denklemleri için sırasıyla 6, 10, 14, 20, 28 ve 36 olarak verilen hasar seviyelerine karşılık gelmektedir [4].

3.2. Taş Dolgu Dalgakıranlarda Yapay Sinir Ağları ile Tasarım

Bu çalışmada, taş dolgu dalgakıranlar için stabilite sayısı, sıçrayarak ve yansıyarak kırılan dalga durumları için yapay sinir ağları yardımıyla tahmin edilmiş ve ağın yapısı P , S , N , $\cot \theta$ ve ε_m değerleri girdi, N_s değerleri ise çıktı olacak şekilde düzenlenmiştir. Değişkenlerin değer aralıkları, Van der Meer [4] tarafından yapılan hidrolik model deneylerine ait veri tabanına bağlı olarak saptanmış ve Çizelge 1'de verilmiştir.

Çizelge 1. Van der Meer denklemlerindeki değişkenlerin değer aralıkları

Değişken	Maksimum	Minimum
Permeabilite katsayısı (P)	0,60	0,10
Eğim (Cot θ)	6,00	1,50
Stabilite sayısı (N_s)	4,30	0,80
Iribarren sayısı (ε_m)	7,60	0,70
Hasar seviyesi (S)	46,40	0,30
Dalga sayısı (N)	3000	1000

Ağın eğitime ve test edilme aşamasında Van der Meer (Van der Meer, 1988) tarafından yapılan hidrolik model deneylerine ait toplam 554 veri kümesinin yaklaşık % 20'si, değişkenlerin aldığı maksimum ve minimum değerleri kapsayacak şekilde (Çizelge 1), eğitime geri kalan kısmı ise test aşamasında kullanılmıştır. Her iki aşama için de veriler rassal olarak ve dalga spektrumunun PM (Pierson Moskowitz) olduğu durumlar dikkate alınarak seçilmişlerdir. Eğitime aşamasında, momentum katsayılı gradyan azalma eğitime algoritması kullanılmış; ara katmanlardaki hücre sayısı dört ve eğitime parametreleri olan öğrenme oranı ve momentum katsayısı sırasıyla 0,3 ve 0,6 olarak belirlenmiştir. Aktivasyon fonksiyonları, ara katmanlarda sigmoidal; çıktı katmanlarında lineer olup hata fonksiyonu karesel hataların ortalaması olarak alınmıştır. Uygun ağ yapısı (x_k, h_s, y_z) ve ortalama karesel hata (KH) değerinin iterasyon sayısına bağlı değişimi, k: girdi katmanındaki hücre sayısı, s: ara katmandaki hücre sayısı ve z: çıktı katmanındaki hücre sayısı olmak üzere Çizelge 2'de

özetlenmiştir. Test sonuçları korelasyon katsayıları (R) ile birlikte dağılım diyagramı halinde Şekil 3’de verilmiştir. Stabilite sayıları, toplam veri kümesi için Van der Meer denklemleri kullanılarak da hesaplanmış ve sonuçlar dağılım diyagramı şeklinde, dalga sayılarına bağlı olarak, Şekil 4-5’te verilmiştir.

Çizelge 2. İleri beslemeli denetimli sinir ağı için eğitime aşamasına ait sonuçlar


Ağın Yapısı	İterasyon Sayısı	KH
$x_5h_4y_1$	100	0,0171
$x_5h_4y_1$	300	0,0104
$x_5h_4y_1$	500	0,0091
$x_5h_4y_1$	1000	0,0086

Test aşamasında, ileri beslemeli denetimli sinir ağı ($x_5h_4y_1$) kullanılarak tahmin edilen değerlerle deney sonuçları arasındaki korelasyon ($R=0,804$) Van der Meer denklemleri ile tahmin edilen stabilite sayılarının korelasyonu ($R=0,891$) mertebesindedir. Ancak, ağ yapısı kadar kullanılan veri tabanları da yapay sinir ağlarının performansını etkileyen faktörlerdir ve girdilerin istatistiksel anlamda birbirinden bağımsız (decorrelate) olarak örneğin Esas Bileşen Analizi (Principal Component Analysis) ile yeni bir koordinat düzleminde tanımlanması [21,22] yapay sinir ağlarının modelleme yeteneğini artırabilmektedir. Bu nedenle mevcut veri tabanı, PCA (Principal Component Analysis) yardımıyla yeniden düzenlenmiş ve eğitime işlemi tekrarlanmıştır.


Esas Bileşen Analizi (EBA) çok değişkenli veri kümelerinin analizinde kullanılan istatistiksel bir doğrusal veri dönüştürme yöntemidir [23]. Bu yöntemle gözönüne alınan veri kümesi, gerçek değişkenlere bağlı olarak tanımlanan esas bileşenlerle (principal components) tanımlanır ve esas bileşenler birbirine dik düzlemler olmak üzere gerçek değişkenlerin doğrusal kombinasyonlarına karşılık gelir. Mevcut değişkenlerin yeni değişkenlere dönüştürülmesi (esas bileşenler) işlemi kısaca varyans en büyükleme olup esas bileşenler, girdi vektörlerine (gerçek değişkenlere) ait kovaryans matrisinin birbirine dik (orthogonal) özvektörlerinden oluşmaktadır. Esas bileşenler önem derecelerine göre adlandırılırlar ve birinci mertebeden esas bileşenin gerçek değişkenlerin sahip olduğu ilişkiyi en büyük varyans değerine bağlı olarak açıkladığı söylenebilir; daha yüksek mertebeden esas bileşenler ise azalan varyans değerlerine göre sıralanırlar. İnsan beyninin uyarımları (girdileri) birbirinden bağımsız olarak ve en önemli uyarımlar üzerinde odaklanarak algılamak zorunda olması [24] esas bileşen analizi ile yapay sinir ağlarının birlikte kullanılmasının temelini oluşturmaktadır. Esas bileşen analizi ile girdi vektörlerinin boyutunun azaltılması ve değişkenlerin birbirinden bağımsız olarak tanımlanması yapay sinir ağlarının genelleme yeteneğini artırabilmektedir. Yapay sinir ağlarının performanslarını artırmak için kullanılan başka bir yaklaşım da eğitime aşamasında kullanılan veri tabanına rassal değişken (noise) ilave edilmesidir [25].

İleri beslemeli denetimli sinir ağının eğitime ve test aşamasında kullanılan girdi vektörlerinin oluşturduğu veri tabanı için (P, S, N, $\cot \theta$ ve ϵ_m) yapılan Esas Bileşen Analizi sonucunda veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımının geniş bir aralıkta değiştiği (Şekil 6); ağırlık faktörleri dikkate alındığında birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi olduğu (Çizelge 3); ilk dört esas bileşenin ise toplam değişimin (varyansın) % 100’e yakın kısmını açıkladığı (Şekil 7) saptanmıştır.


Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı



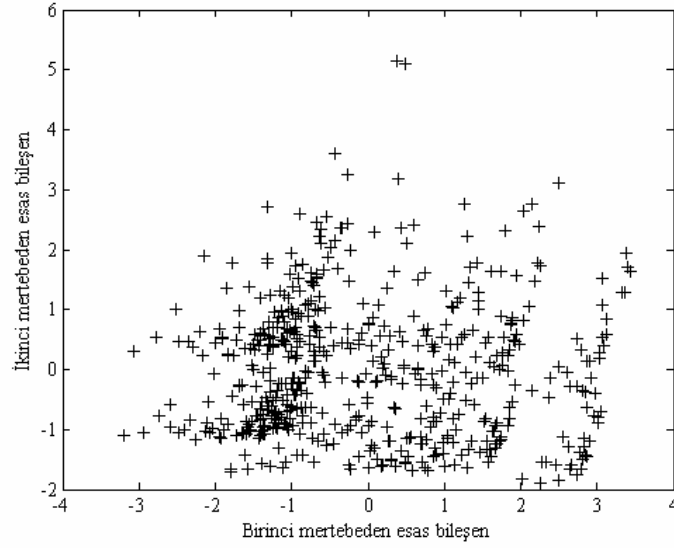
Şekil 3. İleri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı



Şekil 4. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı (N=1000)



Şekil 5. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı (N=3000)

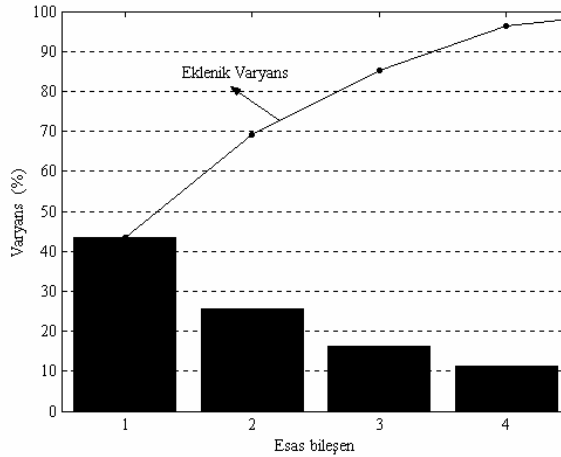


Şekil 6. Girdi vektörlerinin oluşturduğu veri tabanına ait verilerin birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı

Çizelge 3. Esas bileşenler için gerçek değişkenlere bağlı ağırlık faktörleri

Esas Bileşen	Ağırlık faktörü				
	P	Cot θ	ϵ_m	S	N
1	-0,511	0,629	-0,545	0,206	0,049
2	0,225	-0,138	-0,054	0,675	0,686
3	-0,474	0,073	0,422	-0,435	0,633
4	0,514	0,024	-0,541	-0,554	0,353

Esas bileşenler, gerçek değişkenlere bağlı olarak üretilen birbirinden bağımsız sentetik değişkenlerdir ve ağırlık faktörleri, esas bileşenlerle gerçek değişkenler arasındaki korelasyonu ifade etmekte, ayrıca değişkenlerin kendi aralarındaki ilişkiyi de göstermektedir. Birinci mertebeden esas bileşen, en büyük varyans değerine sahip olduğu için, gerçek veriler arasındaki ilişkiyi en yüksek derecede açıkladığı kabul edilen bileşendir. Örneğin, Çizelge 3’de görüldüğü gibi birinci mertebeden esas bileşen üzerinde dalga sayısının etkisi ihmal edilebilecek seviyelerdedir ve artı değerli ağırlık faktörlerine sahip değişkenlerle (Cot θ , S) ağırlık faktörlerinin eksi değerler aldığı değişkenler arasında (P, ϵ_m) ters yönlü bir ilişkinin varlığı gözlenmektedir. Bu nedenle birinci mertebeden esas bileşen genel olarak, artı ve eksi değerli ağırlık faktörlerine sahip değişkenler gurubu arasındaki göreceli oransal ilişkiyi yansıtmaktadır. İkinci mertebeden esas bileşenin, eksi değerler alan ağırlık faktörlerinin etkisi düşük olduğu için ihmal edilmesi halinde, permeabilite katsayısında, hasar seviyesinde ve dalga sayısındaki toplam değişkenliği ifade ettiği görülmektedir. Üçüncü mertebeden esas bileşen, koruma tabakası eğiminin (Cot θ) ağırlık faktörü küçük olduğundan ihmal edilmesi durumunda, Iribarren ve dalga sayısını, hasar seviyesine ve permeabilite katsayısına oranla daha fazla yansıtmaktadır. Esas bileşenler varyans en büyüklemesini ifade ettiğinden, ilk üç mertebedeki esas bileşenlerin eklenik olarak toplam varyansı, Şekil 7’de yaklaşık olarak değişkenliğin % 90’lık kısmını açıklamaktadır.



Şekil 7. Esas bileşenlere ait varyans değerleri

İleri beslemeli denetimli yapay sinir ağlarının performansını etkileyen faktörlerden biri de veri tabanlarının aynı girdilere karşılık farklı çıktılara sahip olmasıdır [26]. Bu nedenle, çalışmada kullanılan hidrolik model deneylerine ait toplam veri kümesi, aynı girdiler aynı çıktılar verecek şekilde yeniden düzenlenmiştir. Veri kümesinde aynı girdilere ait farklı çıktılarının gözlenmesinin nedeni özellikle farklı dalga sayısının 1000 ve 3000 olması durumlarında girdi değerlerinin (P, S, N, $\cot \theta$ ve ε_m) değişmesine karşılık çıktı değerlerinin (N_s) aynı kalması olmuştur. Bu durumda olan veri gruplarından (girdi vektörleri) yalnızca biri rassal olarak seçilmiş ve ağı eğitime ve test aşamasında kullanılan veri tabanı aynı girdiler aynı çıktılara sahip olacak şekilde yeniden belirlenmiştir. Düzenlenmiş veri kümesi toplam 166 veri kümesinden oluşmuş ve toplam veri kümesine ait istatistik bilgiler Çizelge 4’de; düzenlenmiş veri kümesinin istatistik özellikleri ise Çizelge 5’de özetlenmiştir. Düzenlenmiş veri kümesi için de yapılan Esas Bileşen Analizi düzenlenmemiş veri kümesi için elde edilen sonuçlarla benzer şekilde, veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımının geniş bir aralıkta değiştiğini ve birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi olduğunu göstermiştir.

Çizelge 4. Toplam veri kümesine ait istatistik özellikler

Değişken	P	Cot θ	N_s	ε_m	S	N
Maksimum	0,1	6,0	4,3	7,6	46,4	3000
Minimum	0,6	1,5	0,8	0,7	0,3	1000
Ortalama	0,3	2,9	2,2	3,0	7,1	2000
Standart Sapma	0,2	1,3	0,6	1,4	6,4	1009

Çizelge 5. Düzenlenmiş veri kümesine ait istatistik özellikler

Değişken	P	Cot θ	N_s	ε_m	S	N
Maksimum	0,1	6,0	4,3	7,6	30,8	3000
Minimum	0,6	1,5	0,8	0,7	0,3	1000
Ortalama	0,3	3,0	2,3	2,9	7,6	1998
Standart Sapma	0,2	1,3	0,7	1,5	6,3	1030

Düzenlenmiş veri kümesi ile eğitime aşamasında kullanılan veri özelliklerine bağlı olarak dört farklı ileri beslemeli ağ oluşturulmuştur. Oluşturulan bu ağların ara katmanlarında bipolar sigmoidal; çıktı katmanlarında lineer aktivasyon fonksiyonları kullanılmıştır. Hata fonksiyonu karesel hataların ortalaması olarak alınmıştır. Eğitime aşamasında momentum katsayılı gradyan azalma algoritması kullanılmış ve öğrenme oranları sabit alınmamış ve her iterasyonda (adaptive learning rate) hata fonksiyonunun değerine bağlı olarak değiştirilmiştir. Öğrenme oranları için başlangıç değeri 0,001 olarak alınmıştır. İlk aşamada, düzenlenmiş veri kümesinin yaklaşık % 54 oranındaki gerçek kısmına ortalaması sıfır ve standart sapması 0,13 olan normal dağılımlı rassal değişken (noise) ilave edilmiş ve bu veri grubu, gerçek veri grubuna ilave edilerek eğitime aşamasında kullanılan girdi vektörü sayısı iki katına (188) çıkarılmıştır. Gerçek veri kümesinin yaklaşık % 46 oranındaki kısmı ise ağı test edilme aşamasında kullanılmıştır. Bu aşamaya ait uygun ağ yapısı (x_k, h_s, y_z), momentum katsayısı, iterasyon sayısı ve karesel hataların ortalaması (KH) ve test aşamasına ait korelasyon katsayısı Çizelge 6’da birinci satırda verilmiştir. Test sonucuna ait dağılım diyagramı ise Şekil 8’de verilmiştir. Stabilite sayıları, test veri kümesi

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı


için Van der Meer denklemleri kullanılarak da hesaplanmış ve dağılım diyagramı korelasyon katsayısı (0,930) ile birlikte Şekil 9'da verilmiştir.

İkinci aşamada eğitime aşamasında kullanılan veri tabanı aynı şekilde oluşturulmuş ancak ağın girdileri P, S, $\cot \theta$ ve ϵ_m değerlerinden meydana getirilmiş ve dalga sayısı (N) değerleri kullanılmamıştır. Bu aşamaya ait uygun ağ yapısı ve diğer parametreler Çizelge 6'de ikinci satırda verilmiştir. Üçüncü aşamada, ağların eğitilmesinde gerçek değerlerin yerine ilk beş esas bileşen; dördüncü aşamada ise ilk dört esas bileşen kullanılmış ve bu aşamalar sırasıyla Çizelge 6'nin üçüncü ve dördüncü satırlarında özetlenmiştir. Üçüncü ve dördüncü aşamalarda, düzenlenmiş veri tabanının yaklaşık % 60 oranındaki kısmı ağların eğitilmesinde geri kalan kısmı test edilmesinde kullanılmıştır. Bütün aşamalarda oluşturulan yapay sinir ağları korelasyon katsayıları dikkate alındığında yüksek performans göstermekle birlikte özellikle birinci aşamaya ait yapay sinir ağı literatürde yer alan [11] çalışmadan farklı olarak Van der Meer denklemleriyle aynı oranda yüksek performans göstermiştir.


Çizelge 6. Düzenlenmiş veri kümeleri ve esas bileşenler kullanılarak oluşturulan ileri beslemeli denetimli yapay sinir ağlarının eğitime aşamasına ait sonuçlar

Girdi vektörü	Veri sayısı	Ağ yapısı	Momentum katsayısı	İterasyon sayısı	KH	R
Gerçek veri + rassal değişken (P, S, N, $\cot \theta$ ve ϵ_m)	188	$x_5h_4y_1$	0,6	3000	0,0207	0,936
Gerçek veri + rassal değişken (P, S, $\cot \theta$ ve ϵ_m)	188	$x_5h_4y_1$	0,5	3000	0,033	0,927
EBA+ YSA (İlk beş esas bileşen)	100	$x_5h_5y_1$	0,7	1000	0,0217	0,928
EBA+YSA (İlk dört esas bileşen)	100	$x_4h_5y_1$	0,6	1000	0,0284	0,906

Çizelge 6'da verilen sonuçlar genel olarak değerlendirildiğinde en yüksek korelasyonlu tahminler yapay sinir ağının girdi değerlerine rassal değişken ilave edilmesi halinde gözlenmiştir. Girdi vektörlerine rassal değişken ilave edilmesinin, yapay sinir ağlarının eğitime aşamasında ağırlık faktörlerine bağlı olarak tanımlanan hata fonksiyonunun optimizasyonu (minimizasyonu) sırasında yersel minimum noktalardan kaçınmayı sağladığı bilinmektedir. Ancak, gradyen azalma eğitime algoritmasının değişen öğrenme oranlarıyla yapılması ve mevcut eğitime veri kümesinin rassal değişken ilave edilerek artırılması da ağın performansını artıran faktörler olmuştur. Bu aşamaya ait tahminler (Şekil 8) aynı koşullarda Van der Meer denklemlerine (Şekil 9) göre yüksek korelasyon katsayısı vermiştir. Yapay sinir ağının girdi değerlerinin dalga sayısını içermemesi durumunda da yüksek kabul edilebilecek korelasyon katsayısına ulaşılması, dalga sayısının düşük etkisini ortaya koyan Esas Bileşen Analizinin sonuçları ile uyumludur. Ayrıca, ilk dört ve beş esas



Şekil 8. Düzenlenmiş veri tabanı ile eğitilen (gerçek veri + rassal değişken) ve girdileri P , S , $\cot \theta$, N ve ε_m değerlerinden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı



Şekil 9. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

bileşenin girdi olarak kullanılması yine yüksek korelasyonlu sonuçlar vermiştir. Burada, birbirinden bağımsız girdi vektörlerinin (esas bileşenlerin) yapay sinir ağına verilmesi başka bir deyişle değişkenlerin önem derecelerine göre (en büyük varyans değerleriyle) tanımlanması verilerin işlenmesini kolaylaştırmış ve yapay sinir ağının genelleme yeteneğini artırmıştır.

En yüksek korelasyonlu tahminler veren yapay sinir ağının tasarım parametrelerinin değişimleri karşısındaki davranışları Van der Meer denklemleri de dikkate alınarak bir örnekle değerlendirilmiştir. Bütün sistemler için diğer tasarım parametreleri sabit iken, belirgin dalga yüksekliğinin 2,5 m; 5,5 m ve 8,5 m olması halinde stabilite sayılarının hasar seviyesine bağlı değişimi belirlenmiş; daha sonra $\cot \theta$ değerlerinin, diğer tasarım parametreleri sabit iken, 4,0 ve 6,0 olması durumunda stabilite sayılarının hasar seviyesine bağlı değişimleri saptanmıştır. $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8,0$ sn ve $H_s=2,5$ m değerleri için, yapay sinir ağı ile tahmin edilen stabilite sayısı değerleri Van der Meer denklemlerine kıyasla daha yüksek değerler vermiş; (Çizelge 7) maksimum fark, hasar seviyesinin yaklaşık $S=10$ olduğu durum için, yaklaşık % 12 seviyesinde iken minimum fark yaklaşık % 2 düzeyinde hasar seviyesinin yaklaşık $S=2$ olması durumu için gözlenmiştir (Şekil 10). Yukarıda belirtilen koşullarda aynı işlemler belirgin dalga yüksekliğinin 5,5 m ve 8,5 m olması durumları için de yapılmış sonuçlar Çizelge 7’de özetlenmiştir. Yapay sinir ağına ait tahminlerin Van der Meer denklemleri ile karşılaştırılması ayrıca her iki durum için Şekil 10-11’de verilmiştir. Yapay sinir ağı ile tahmin edilen stabilite sayıları Van der Meer denklemleri ile hesaplanan değerlerle korelasyon katsayılarına (R) bağlı olarak karşılaştırıldığında, gözönüne alınan bütün tasarım durumlarında Van der Meer denklemlerine yakın eğilimler gösterdiği gözlenmiştir. Genel olarak, yapay sinir ağları ile yapılan tahminler Van der Meer denklemlerine kıyasla düşük hasar seviyelerinde küçük farklar gösterirken hasar seviyesindeki artışlarla daha büyük farklar gözlenmiştir.

Çizelge 7. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minimum)	S (Hasar)	R
Yapay Sinir Ağı ($H_s=2,5$ m)	12,147	9,668	2,058	2,040	0,976
Yapay Sinir Ağı ($H_s=5,5$ m)	15,384	24	-11,407	1,809	0,998
Yapay Sinir Ağı ($H_s=8,5$ m)	17,021	24	-15,279	1,809	0,996

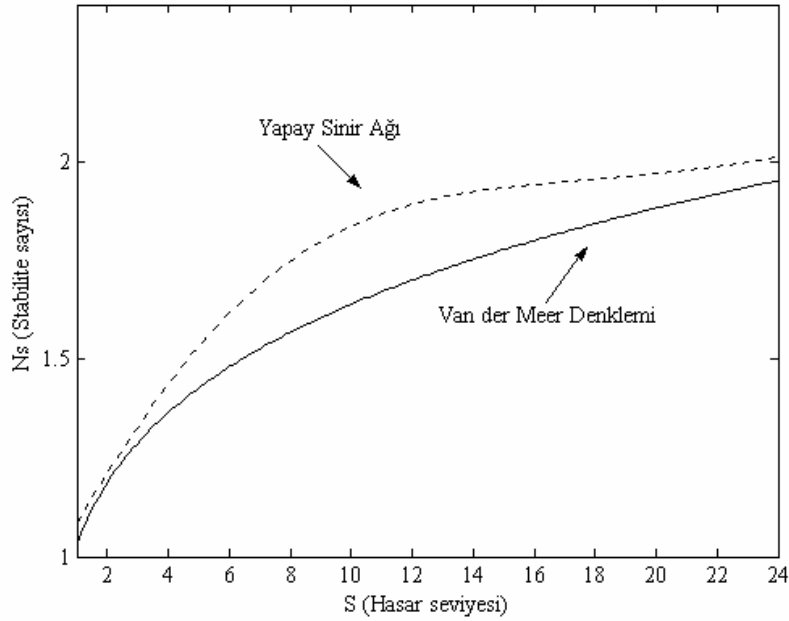
Stabilite sayılarının tahminine yönelik olarak oluşturulan yapay sinir ağı uygulamaları, $P=0,1$; $N=3000$; $T=8,0$ sn ve $H_s=2,5$ m değerleri için yukarıda belirtilen işlemlere ilave olarak eğim ($\cot \theta$) değerlerinin 4,0 ve 6,0 olması durumu için de yapılmış sonuçlar Çizelge 8’de verilmiştir. Bu aşamada da, korelasyon katsayılarına bağlı olarak yapay sinir ağlarının Van der Meer denklemlerine yakın eğilimlere sahip olduğu gözlenmektedir. Tasarım parametrelerinin değişimi karşısındaki davranışlarına bağlı olarak yapay sinir ağının, Van der Meer denklemleri ile birbirine çok yakın davranışlar sergilediği gözlenmektedir. Her iki yaklaşımın karşılaştırılmasında korelasyon katsayılarının çok yüksek değerler aldığı (Çizelge 8) söylenebilir. Örnek olarak, koruma tabakası eğiminin ($\cot \theta$) 4,0; permeabilite katsayısının (P) 0,1; belirgin dalga yüksekliğinin (H_s) 2,5 m, dalga sayısının (N) 3000 ve

dalga periyodunun (T) 8,0 sn olduğu durumda, Van der Meer denklemleri ve yapay sınır ağı ile elde edilen stabilite sayılarının uyumu Şekil 11’de gözlenmektedir.

Van der Meer denklemleri ile yapay sınır ağları genel olarak, karşılaştırıldığında belirgin farklılık, bütün tasarım koşullarında, özellikle hasar seviyesinin artmasıyla Van der Meer denklemleri ve yapay sınır ağları ile elde edilen stabilite sayıları arasındaki farkın artışı şeklinde gözlenmiştir. S=1 ve S=2, Hudson denkleminde % (0-5) aralığındaki yapıda hasar oluşmaması durumunu yansıtmaktadır ve Türkiye’de uygulamada en çok seçilen tasarım değerleridir. Bu hasar aralığında yapay sınır ağı Van der Meer denklemlerine daha yakın bir davranış sergilemiştir.

Çizelge 8. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minimum)	S (Hasar)	R
Yapay Sınır Ağı (Cot $\theta=4,0$)	4,357	13,713	-4,546	2,271	0,996
Yapay Sınır Ağı (Cot $\theta=6,0$)	17,473	1	3,867	5,623	0,987

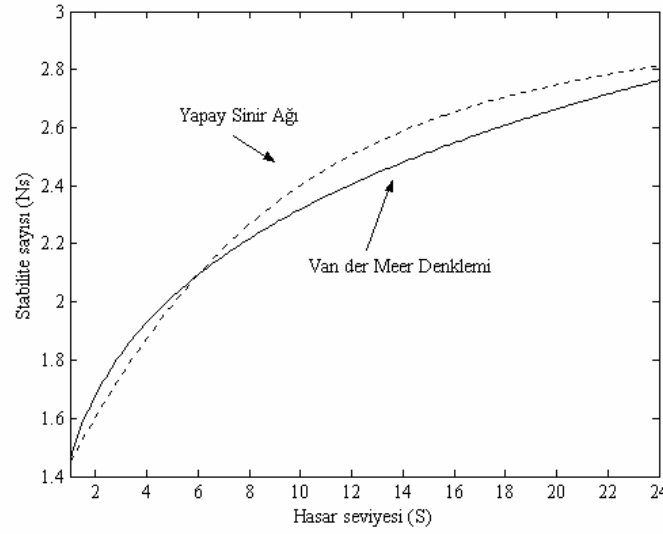


Şekil 10. Yapay sınır ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)

Yukarıda verilen karşılaştırmalara ilave olarak yapay sınır ağı ile Van der Meer denklemleri tasarım parametrelerine bağlı olarak da karşılaştırılmıştır. Sırasıyla stabilite sayıları (N_s) ile permeabilite katsayısı (P), Iribarren sayısı (ϵ_m), dalga sayısı (N) ve eğim (cot θ) arasındaki

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

ilişki diğer parametreler sabit iken belirlenmiştir. Genel olarak sözkonu parametrelerle stabilite sayıları arasında Van der Meer denklemleri ve yapay sinir ağları birbirine yakın davranışlar göstermiştir: Örneğin, Iribarren sayısının 3,5 ve daha küçük olduğu durumlarda yapay sinir ağı ile elde edilen stabilite sayıları daha küçük değerler alırken, Iribarren sayısının 3,5 ve daha büyük değerlerinde ise Van der Meer denklemleri daha küçük stabilite sayıları vermiştir (Şekil 12).

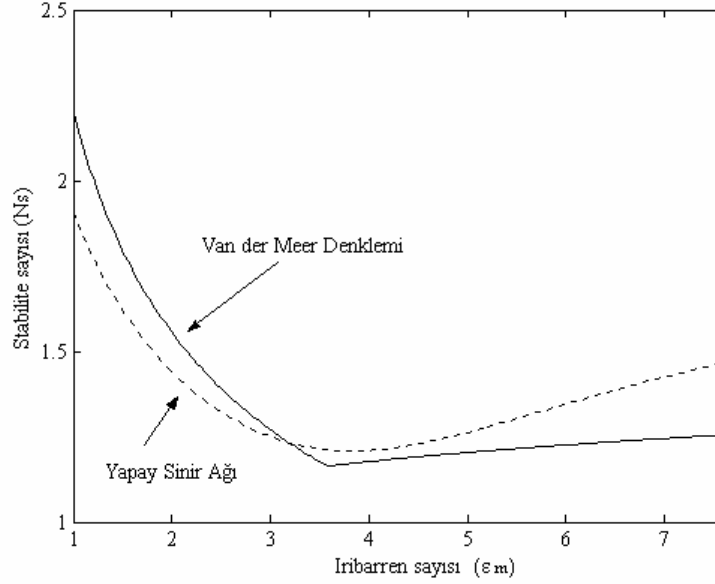


Şekil 11. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)

Tasarım parametrelerinin her aşamada sabitlenmesi aynı koşulları sağlayan yeterli sayıda deney verisine ulaşılmasını engellediğinden, Şekil 12’de örnek olarak verilen **sonuçlar** gerçek stabilite sayılarının noktalanması ile desteklenememiştir. Bu nedenle, yapay sinir ağının eğitime ya da test aşamasında kullanılmayan ve Van der Meer [4] tarafından verilen deney verilerinden rassal olarak seçilen ve toplam 20 girdi vektöründen oluşan veri grubundan (Çizelge 9) yararlanılarak her iki yaklaşım istatistiksel parametrelere bağlı olarak karşılaştırılmıştır: İki farklı biçimde belirlenen stabilite sayılarına ait ortalama, standart sapma ve değişim katsayısından oluşan istatistiksel parametreler ile korelasyon katsayıları dikkate alındığında, yapay sinir ağına ait sonuçların gerçek veri grubunu istatistiksel olarak daha fazla temsil ettiği gözlenmiştir (Çizelge 10).

Çizelge 9. Rassal olarak seçilen deney verilerine ait değişim aralıkları

Değişken	Maksimum	Minimum
Permeabilite katsayısı (P)	0,60	0,10
Eğim (Cot θ)	6,00	2,00
Stabilite sayısı (N_s)	4,30	1,20
Iribarren sayısı (ϵ_m)	6,10	0,80
Hasar seviyesi (S)	29,1	1,20
Dalga sayısı (N)	3000	1000



Şekil 12. İrribarren sayısı (ϵ_m) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $P=0,1$; $S=2,0$; $N=2000$)

Çizelge 10. Yapay sinir ağı ve Van der Meer denklemleri kullanılarak belirlenen stabilite sayıları ile deney verilerine ait stabilite sayıları için istatistiki parametrelerin değişimi

Model	Ortalama	Standart sapma	Değişim katsayısı	R
Gerçek veri	2,305	0,748	0,324	-
VDM	2,323	0,603	0,259	0,947
YSA	2,316	0,756	0,326	0,968

Mersin yat limanı ana dalgakıranına ait koruma tabakası için stabilite sayısı Van der Meer denklemlerine ilave olarak eğitilen yapay sinir ağı kullanılarak belirlenmiştir. Tasarım sırasında gözönüne alınacak belirgin dalga yüksekliği ve periyodu değerleri farklı yinleme süreleri için, Fisher Tippet Tip I (Gumbel) olasılık dağılımı kullanılarak belirlenmiş olup dalga periyodlarının hesaplanmasında bölge için kabul edilebilen $H_0/L_0=0.042$ eşitliğinden yararlanılmıştır. Eğim değeri ($\cot \theta$), dalga sayısı (N) sırasıyla 2,5 ve 2000 olarak alınmıştır [6]. Hesaplanan belirgin dalga yükseklikleri ve periyodları, yinleme sürelerine bağlı olarak Çizelge 11’de verilmiştir. Nominal taş çapları (D_{n50}) ve ağırlıkları (W) iki farklı hasar seviyesinde ve 25, 50 ve 100 yıllık yinleme süreleri için Van der Meer denklemi ve en yüksek performansa (korelasyon katsayılarına) sahip yapay sinir ağı kullanılarak hesaplanmış ve sonuçlar Çizelge 12’de özetlenmiştir.

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

Çizelge 11. Mersin yat limanı tasarımı için hesaplanmış farklı yineleme sürelerine ait belirgin dalga yüksekliği ve periyodları

Yineleme Süresi (T _r)	25	50	100
Belirgin Dalga yüksekliği (H _s) (m)	4,543	4,982	5,418
Dalga Periyodu (T) (sn)	8,327	8,720	9,094


Her iki yaklaşımla elde edilen sonuçlar karşılaştırıldığında, Van der Meer denklemleri ile yapay sinir ağları iki farklı hasar seviyesinde (S=2 ve S=10) birbirine yakın sonuçlar. Hasar seviyesinin S=2,0 olması halinde Van der Meer denklemleri ile yapay sinir ağları kullanılarak belirlenen taş çapları arasındaki maksimum fark yineleme süresininin 100 yıl olduğu durumda sırasıyla % 5,4 ve % 10 olup (Şekil 13); hasar seviyesinin S=10 olması halinde bu oranlar % 2,17 ve % 15,9 olarak hesaplanmıştır (Çizelge 12).

Çizelge 12. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları

Model	S=2		S=10	
	D _{n50} (m)	W (ton)	D _{n50} (m)	W (ton)
Yapay Sinir Ağı (YSA) (T _r =25 yıl)	1,307	6,027	0,982	2,562
Van der Meer Denklemi (VDM) (T _r =25 yıl)	1,381	7,111	1,004	2,737
Yapay Sinir Ağı (YSA) (T _r =50 yıl)	1,433	7,951	1,077	3,380
Van der Meer Denklemi (VDM) (T _r =50 yıl)	1,514	9,380	1,101	3,611
Yapay Sinir Ağı (YSA) (T _r =100 yıl)	1,558	10,228	1,172	4,348
Van der Meer Denklemi (VDM) (T _r =100 yıl)	1,647	12,067	1,198	4,645

Mersin Yat Limanı için seçilen ekonomik ömür L=50 yıl olup [6] bu süre için hesaplanan taş çapları ve ağırlıkları Çizelge 12'de verilmiştir. Hasar seviyesinin S=2 değerinde Van der Meer denklemi yapay sinir ağına kıyasla yaklaşık % 5,0 oranında daha yüksek taş çapları verirken; hasar seviyesinin S=10 olması bu fark yaklaşık % 2,0 olmuştur (Şekil 13). Düşük (S=2) ve yüksek (S=10) hasar seviyeleri için hesaplanan taş ağırlıkları arasındaki fark, yapay sinir ağı kullanıldığında yaklaşık % 25, Van der Meer denklemi kullanıldığında yaklaşık % 27 olmuştur. Taş ağırlıkları açısından, her iki yaklaşım arasında S=10 hasar seviyesi için yaklaşık % 7'lik bir fark bulunmaktadır. Hasar seviyesinin seçimi, taş dolgu dalgakıranların maliyetini değişik biçimlerde etkilediği için önemlidir. Hasar seviyesinin düşük seviyelerde seçilmesi yapının ilk maliyetini artırırken; yüksek hasar seviyeleri

yapının bakım ve onarım maliyetlerinde artışa neden olmaktadır. Yinelenme süresinin seçimi ise, kıyı yapısı ve koruduğu tesis (nükleer santral, endüstri limanı, yat limanı, deniz deşarjı, balıkçı barınağı vb.) için kabul edilen risk düzeyinin bir fonksiyonudur. Bu nedenle, ön tasarım aşamasında maliyet ve risk optimizasyonu ile taş çaplarının belirlenmesi yapının ekonomik ve emniyetli olarak tasarlanmasını sağlayacaktır. Yüksek derecede belirsizlik içeren taş dolgu dalgakıranların tasarımında, deterministik yaklaşım yerine doğrusal olmayan yapay sinir ağlarının kullanılması karşılaşılan belirsizliklerin işlenebilmesi veya kaynaklarının belirlenerek istatistiki olarak azaltılması [27] yoluyla kıyı yapılarının daha ekonomik ve güvenli olarak tasarlanabilmesine katkıda bulunmakta ve karmaşık modellere gereksinim duyulmadan modelleyebilme olanağı sağlamaktadır.



Şekil 13. Mersin Yat Limanı için Van der Meer Denklemleri ve yapay sinir ağı ile belirlenen nominal taş çaplarının yineleme sürelerine bağlı değişimi

4. SONUÇ VE ÖNERİLER

İnsan gibi davranabilen ve düşünebilen sistemlerin geliştirilmesine yönelik çalışmaların tümünü temsil eden yapay zeka, gelişimini sürdüren yeni bir disiplin olup kullanım amacına ve yerine göre değişik uygulama alanları ya da tekniklerden meydana gelmektedir. Yapay zeka teknikleri, karmaşık başka bir deyişle yüksek derecede belirsizlikler içeren sistemlerin modellenmesi amacıyla birçok mühendislik dalında yaygın olarak kullanılmasına karşın kıyı mühendisliği alanında henüz yeterli kullanım alanı bulamamıştır. Bu çalışmada, yapay zeka tekniklerinden olan yapay sinir ağları, taş dolgu dalgakıranların ön tasarıma yönelik olarak uygulanmıştır. Tasarlanan ve eğitilen ileri beslemeli denetimli sinir ağları, dalgakıran stabilite sayısını ayrıntılı matematiksel modellere ihtiyaç duyulmaksızın, karmaşık sistemler olmalarına rağmen, başarıyla modelleyebilmiş ve Mersin yat limanı ana dalgakıranı ön tasarımı için uygulanmıştır.

Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı

İleri beslemeli denetimli sinir ağlarının eğitilmesinde mevcut veri tabanının doğrudan kullanılması halinde, yapay sinir ağlarının tahmin yeteneği Van der Meer denklemlerine oranla düşük bulunmuştur. Ancak, eğitime aşamasında kullanılan veri tabanına rassal değişken ilave (noise) edilmesi korelasyon katsayıları dikkate alındığında, ağların tahmin yeteneğini önemli oranlarda artırmıştır. Rassal değişken ilave edilmesi ile, literatürde yer alan çalışmadan (Mase et. al., 1995) farklı olarak Van der Meer denklemleriyle aynı oranda yüksek korelasyon katsayılarına sahip tahminler elde edilmiştir.

İleri beslemeli denetimli sinir ağının eğitime ve test aşamasında kullanılan girdi vektörlerinin oluşturduğu veri tabanı için Esas Bileşen Analizi yürütülmüştür. Veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı geniş bir aralıkta değişmektedir. Ağırlık faktörleri dikkate alındığında birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi vardır. İlk dört esas bileşen toplam değişimin (varyansın) % 100'e yakın kısmını açıklamaktadır. Yapay sinir ağlarının eğitime aşamasında, girdi vektörlerinin ilk beş ve ilk dört esas bileşenden oluşması yapay sinir ağlarının tahmin yeteneğini belirgin ölçüde artırmaktadır. Dalga sayısı gözönüne alınmadan permeabilite katsayısı, eğim, Iribarren sayısı ve hasar seviyesi değerleri ile eğitilen yapay sinir ağına ait test sonuçları (tahmin edilen stabilite sayıları) gözönüne alınan gerçek stabilite sayıları ile yüksek korelasyon göstermektedir.

Oluşturulan yapay sinir ağının davranışı, diğer tasarım parameterleri sabit iken belirgin dalga yüksekliğinin ve eğimin değişmesi halinde hasar seviyesine ve stabilite sayısına bağlı olarak Van der Meer denklemleri ile karşılaştırılmıştır: Genel olarak, yapay sinir ağı ile tahmin edilen stabilite sayıları düşük hasar seviyelerinde küçük farklar göstermiştir. Yapay sinir ağları ve Van der Meer denklemleri ile elde edilen stabilite sayıları arasındaki ilişki korelasyon katsayıları dikkate alındığında birbirine yakın eğilimlere sahiptir. Mersin Yat Limanı ana dalgakıranı için yapılan ön tasarım örneği dikkate alındığında, yapay sinir ağı, taş çapları açısından Van der Meer denklemlerine yakın sonuçlar vermiştir. Hasar seviyesinin seçimi, taş dolgu dalgakıranların maliyetini değişik biçimlerde etkilediği için önemlidir: Hasar seviyesinin düşük seviyelerde seçilmesi yapının ilk maliyetini artırırken; yüksek hasar seviyeleri yapının bakım ve onarım maliyetlerinde artışa neden olmaktadır.

Bu çalışmada, taş dolgu kıyı yapılarının ön tasarımı için Van der Meer deney verilerini içeren bir "tasarım yapay sinir ağı" geliştirilerek, bu ağın mühendislik uygulamalarındaki kullanılabilirliği gerçekleştirilmiştir. Yapay sinir ağlarının kıyı mühendisliği alanında yaygın olarak kullanımı ve bu çerçevede elde edilecek deneyimler, bu tekniklerin kıyı mühendisliği problemlerinin çözümünde sağlayacağı yararların daha açık bir şekilde değerlendirilebilmesini sağlayacaktır. Yüksek derecede belirsizlik içeren taş dolgu dalgakıranların, deterministik yöntemler yerine doğrusal olmayan yapay sinir ağlarıyla tasarlanması, karşılaşılan belirsizliklerin azaltılması yoluyla bu yapıların karmaşık modellere gereksinim duyulmadan modellenebilmesine olanak sağlamıştır. Yapay sinir ağı, deterministik tasarımla (Van der Meer denklemleri) aynı düzeyde tahmin yeteneği göstermiş olup bu çerçevede yapılacak çalışmalarda, ağlarının eğitilme ve test aşamalarında değişik model deneylerinden elde edilecek verilerin kullanılması sonuçların geliştirilmesinde yararlı olacaktır.

SEMBOLLER

A : Dalgakıran kesitindeki hasar alanı

\mathbf{b}^h : Ara katmandaki hücelere ait sınır değer vektörü

\mathbf{b}^y	: Çıktı katmanındaki hücelere ait sınır değer vektörü
D_{n50}	: koruma tabakası taşının çapı
g_g	: Yerçekimi ivmesi
\mathbf{h}	: Yapay sinir ağının ara katman çıktı vektörü
H_s	: Dalgakıran topuğundaki belirgin dalga yüksekliği
K	: İterasyon sayısı
N	: Girdi ve çıktı vektörlerinin sayısı
N_f	: Fırtınadaki dalga sayısı
N_s	: Stabilite sayısı
P	: Dalgakıranın permeabilite katsayısı
S	: Hasar seviyesi
t_j	:Sınır değer
T_m	:Ortalama dalga dönemi (periyodu)
VDM	: Van der Meer denklemi
\mathbf{W}	: Vektörel olarak ağırlık faktörü
w_n	: Ağırlık faktörü
\mathbf{W}^y	: Ara katman ile çıktı katmanı arasındaki bağlantılar için ağırlık faktörleri
\mathbf{W}^h	: Ara katman ile girdi katmanı arasındaki bağlantılar için ağırlık faktörleri
\mathbf{x}	: Yapay sinir ağının girdi vektörü
x_n	: Hücreye gelen uyarım
YSA	: Yapay sinir ağı
\mathbf{Y}	: Yapay sinir ağının çıktı vektörü
z	: Çıktı katmanındaki hücre sayısı
α	: Momentum katsayısı
Δ	: Koruma tabakası taşının göreceli yoğunluğu
ϵ_c	: Boyutsuz Iribarren parametresinin kritik değeri
ϵ_m	: Boyutsuz Iribarren parametresi
η	: Öğrenme oranı
θ	: Koruma tabakasının eğim açısı
$\varphi(\cdot)$: Çıktı katmanına ait hücreler için aktivasyon fonksiyonu
$\psi(\cdot)$: Ara katmana ait hücreler için aktivasyon fonksiyonu
∇E	: Karesel hata fonksiyonunun gradyeni
$\nabla J(\mathbf{w})$: Performans indeksinin gradyeni

Kaynaklar

- [1] CCP., 1993, Neural Networks and Combinatorial Optimization in Structural Engineering, Civil-Comp Limited, s 165, Meigle Printers Ltd., Scotland.
- [2] Pham, D. T., Pham, P. T. N., 1999, Artificial Intelligence in Engineering, International Journal of Machine Tools and Manufacture, 39, 937-949.
- [3] Hudson, R. Y., 1953, Wave Forces on Breakwaters, Transactions of the American Society of Civil Engineers, ASCE, 11B, USA.
- [4] Van der Meer, J. W., 1988, Rock Slopes and Gravel Beaches Under Wave Attack, Delft Hydraulics Publication, No. 396, Delft, The Netherlands.

- [5] Balas, C.E., Balas, L., 2002, Risk Assessment of Some Revetments in Southwest Wales, United Kingdom, *Journal of Waterway, Port, Coastal and Ocean Engineering*, 128(5).
- [6] Balas, C.E., 1998, A Risk Management Model for Coastal Projects, Unpublished Ph.D. Thesis, The Graduate School of Natural and Applied Sciences, Middle East Technical University, Ankara, Turkey.
- [7] Balas C.E., Ergin A., Yüçemen S.M., 1995, Comparison of the Reliability-Based and Deterministic Design Procedures for Rubble Mound Breakwaters, *Proceedings of the Second International Conference on the Mediterranean Coastal Environment (MEDCOAST 95)*, 3, 1767-1782, 24-27 November, Tarragona, Spain.
- [8] Ergin A., Balas C.E., 1998, Implementation of a Reliability-Based Design Model in Turkey, *Proceedings of the 17th International Conference on Offshore Mechanics and Arctic Engineering*, *Proceedings on CD-ROM - Paper No: 98-1351*, 5-9 July 1998, Lisbon, Portugal.
- [9] Ergin A., Balas C.E., 1997, Failure Mode Response Functions in Reliability-Based Design of Rubble Mound Breakwaters, *Proceedings of the Seventh International Offshore and Polar Engineering Conference, ISOPE'97,3*, 861-868, 25-30 May, Honolulu, U.S.A.
- [10] Balas C.E., Ergin A., A., 1997, Reliability-Based Risk Assessment Model for Coastal Projects, *Proceedings of the Third International Conference on the Mediterranean Coastal Environment (MEDCOAST'97)*, 2, 943-955, 11-14 November, Qawra, Malta.
- [11] Mase, H., Sakamoto, M., Sakai, T., 1995, Neural Network for Stability Analysis of Rubble Mound Breakwaters, *Journal of Waterway, Port, Coastal and Ocean Engineering*, 121 (6), 294-299.
- [12] Harvey, R. L., 1994, *Neural Network Principles*, Prentice-Hall Inc., s 197, New Jersey.
- [13] Kirkegaard, P.H., ve Rytter, A., 1993, The Use of Neural Networks For A Damage Detection and Location in a Steel Member, *Neural Networks and Combinatorial Optimization in Civil and Structural Engineering*, 1-9, Migne Press, UK.
- [14] Kröse, B., Van der Smagt, P., 1996, *An Introduction to Neural Networks*, The University of Amsterdam, s 135 Amsterdam.
- [15] Kalagirou, S. A., 1999, Applications of Neural Networks in Energy Systems, *Energy Conversion and Management*, 40, 1073-1087.
- [16] Svozil, D., Kvasnicka, V., Pospichal, J., 1997, Introduction to Multilayer Feed Forward Neural Net, *Chemometrics and Intelligent Laboratory Systems.*, 39, 43-62.
- [17] Walczak, S., Cerpa, N., 1999, Heuristic Principles for the Design of Artificial Neural Networks, *Information and Software Technology*, 41, 107-117.
- [18] Golden, R. M., 1996, *Mathematical Methods for Neural Network Analysis and Design*, Massachusetts Institute of Technology Press., s 419, USA.
- [19] Basherr, I.A., Hajmeer, M., 2000, Artificial Neural Networks: Fundamentals, Computing, Design, and Application., *Journal of Microbiological Methods*, 43, 3-31.
- [20] Burcharth, H. F., 1992, Reliability Evaluation of a Structure at Sea, *Proc., Short Course on Design and Reliability of a Coastal Structures: Structural Integrity*, A. Lamberti, ed., Tecnoprint Snc, Venice, Italy, 511-545.
- [21] Olofsson, T., Anderson, S., Östin, R., 1998, A Method for Predicting the Annual Building Heating Demand Based on Limited Performance Data, *Energy and Buildings*, 18, 101-108.

- [22] Choi, D. J., Park, H., 2001, A Hybrid Artificial Neural Network as a Software Sensor for Optimal Control of a Wastewater Treatment Process, *Water Research*, 35(16), 3959-3967.
- [23] Dunteman, G. H., 1989, *Principal Component Analysis*, Sage Publications, Sage University Paper (69), s 96, Newbury Park.
- [24] Schittenkopf, C., Deco, G., Brauer, W., 1997, Two Strategies to Avoid Overfitting in Feedforward Networks, *Neural Networks*, 10 (3), 505-516.
- [25] Patterson, D. W., 1996., *Artificial Neural Networks Theory and Applications*, Prentice Hall International Editions, s 477, Korea.
- [26] Skapura, D. M., 1996, *Building Neural Networks*, Addison-Wesley Publishing Company, s 286, New York.
- [27] Ang, A. H. S., Tang, W. H., 1975, *Probability Concepts in Engineering Planning and Design*, John Wiley and Sons, Vol. II., USA.