

Cilt: 1 Sayı: 2 sh. 1-12 Nisan 1999

GERİYE YAYILMA YAPAY SINIR AĞI KULLANILARAK YANAL SU ALMA YAPISINA YÖNELECEK OLAN SÜRÜNTÜ MADDESİ ORANININ BULUNMASI

(DETERMINATION OF RATIO OF BED LOAD ENTERING INTO LATERAL INTAKE USING BACKPROPAGATION NEURAL NETWORK)

Ahmet BAYLAR* , M. Emin EMİROĞLU* , Abdussamet ARSLAN**

*** Fırat Üniversitesi, İnşaat Müh. Bölümü, Elazığ**

**** Gazi Üniversitesi, İnşaat Müh. Bölümü, Ankara**

Özet / ABSTRACT

Geçen bir kaç yıl içerisinde, inşaat mühendisliğindeki bilgisayarlı hesaplamalarda Yapay Zeka uygulamaları ilk sırayı almıştır. Bu uygulamalar genellikle uzman sistemleri içermektedir. Bu makalede değişik bir Yapay Zeka yaklaşımı olan yapay sinir ağlarına (YSA) değinilmiş ve bir uygulama sunulmuştur. Yapay sinir ağları lineer olmayan bir yapıya sahiptir. Bu durum YSA ları her alana uygulanabilir hale getirmiştir. Sonuçlara çok kısa zamanda yaklaşımdaki etkinliği diğer yaklaşım metotlarına göre onu bir tercih sebebi yapmıştır.

Bu çalışmada, dolu gövdeli bağlamalarda ayırma duvarının etkisi dikkate alınarak yan al su alma yapısına yönelecek olan sürüntü maddesi oranı geriye yayılma yapay sinir ağı yöntemi ile tespit edilmiştir. Problemin eğitim setinde DSİ (1989) tarafından yapılan deneysel veriler kullanılmıştır. Problemin değişkenleri ağa normalizasyon tekniği ile tanıtılmıştır. Eğitilen YSA, daha önce eğitim sırasında kullanılmayan deney verileri ile test edildiğinde sonuçların oldukça uygun olduğu görülmüştür. Bu çalışma, yapay sinir ağı hesaplamalarının inşaat mühendisliğinde karar verme ve tasarım için alternatif bir çözüm olduğunu ortaya koymaktadır.

In the past few years computation on Civil Engineering has been concentrated primarily on artificial intelligence (AI) applications, which generally consider expert systems. This article deals with a different AI approach using the benefits of Neural networks and presents its usefulness on an application. Artificial neural networks have nonlinear performance and by this a satisfactory approachment to the results in a very short time, even in the learning phase of procedure can be achieved. This capability makes it preferable according to the other approaching methods.

In this study, ratio of bed load entering into lateral intake at weirs is determined by a backpropagation Neural Network method. The training sets in the application of the Neural Network are performed by means of experimental results provided by DSİ (1989). Variables concerning the problem are introduced to the Neural Network by normalization technique. After Neural Network is trained, it is observed that the results were satisfactory on the previously unused data in the training sets. This research work showed clearly that the

Neural Network computation is an reasonable alternative solution for decision making and design criterias in the field of Civil Engineering.

ANAHTAR KELİMELER / KEYWORDS :

Yapay zeka, Yapay sinir ağıları, Sürüntü maddesi, Bağlama, Yanal su alma yapısı / Artificial intelligence, Neural Networks, Bed load, Weir, Lateral intake

1. GİRİŞ

İnsanlar varoluşundan beri hep doğayı taklit etme gereksinimi duymuştur ve hâ lâ duymaktadır. Bu gereksinim insanın yaratılışında varolan öğrenme ihtiyacından kaynaklanmaktadır. Taklit etme olayının en yeni ürünlerinden biri olan yapay sinir ağıları, insan beyninin çalışma prensibini kendine model edinmiş, yapay sistemlerdir.

Von Neuman mimarisi kullanan klasik anlamdaki bilgisayarlar tecrübeye ve gözleme dayalı problemleri çözmekte yetersiz kalmaktadır. Bu tür bilgisayarların verileri seri olarak işleyip sonuca ulaştırmaları bu yetersizlikteki en büyük etkidir. Bu durum bilim adamlarını insan gibi tecrübeye dayanarak, problem çözme yeteneğine sahip bilgisayarlar yapmaya veya programlama teknikleri geliştirmeye zorlamıştır. Yapay sinir ağıları, problemi parçalara ayırarak, bu parçaları kendi içerisindeki her bir nöron vasıtası ile işleyip bir sonuca varmakta ve bu sonucu kendisine bağlanan diğer nöronlara giriş değeri olarak göndermektedir. Sistem bu hiyerarşi içerisinde çalışarak problemi çözmektedir.

Yapay sinir ağıları üzerine yapılan araştırmalar hem yazılım hem de donanım üzerine devam etmektedir. Günümüzde yapay sinir ağıları: ekonomi, iktisat, endüstri mühendisliğinde, otomasyonda, elektronik mühendisliğinde, elektronik devre tasarımında, bilgisayar mühendisliğinde, tıp alanında, çeşitli zeka problemlerinin çözümünde, optik algılamada, nesne tanımlama gibi birçok konuda uygulama alanı bulmuştur.

İnşaat mühendisliğinde Uzman Sistemler konusunda yeterli sayılabilecek derecede uygulama mevcut olmasına rağmen, Yapay Zekanın diğer bir dalı olan yapay sinir ağıları üzerine henüz kapsamlı bir çalışma yapılmamıştır (Arslan ve İnce, 1995). Oysa inşaat mühendisliğinde diğer mühendislik dallarının birçoğunda olduğu gibi tasarımda tecrübenin önemli derecede etken olduğu türden problemlerle sıklıkla karşılaşmaktadır. Bu durumda da gerçek çözümden uzaklaşan değerler elde edilmektedir.

İnşaat mühendisliği problemlerinin bir diğer özelliği çok gerçekli karar verme durumudur. Yani problemin çözümü için birden çok kabul edilebilir metodun bulunmasıdır. Bu tür durumlarda kesin veri isteyip ona göre kesin sonuç isteyen problemlerin çözümü zorlaşmaktadır. Ancak yapay sinir ağıları kullanarak bu tür problemlere daha gerçekçi bir şekilde yaklaşmak mümkündür.

Akarsulardan suyun alınması ile ilgili olarak, bağlama ile kabartılan suyun, sürüntü maddesi içermeden kanallara iletilmesi, su almada önemli bir sorunu oluşturmaktadır. Söz konusu katı madde kısa zamanda, iletim kanallarının dolmasına neden olduğu gibi, hidroelektrik santrallarda ise türbinlerin aşınmasını ve su kuvveti tesisinin kısa sürede devreden çıkmasını beraberinde getirmektedir. Ayrıca, su alma yapılarında olan kumlanmalar sürekli su almaya olanak vermemektedir. Bu çalışmada, dolu gövdeli bağlamalarda ayırma duvarının etkisi dikkate alınarak yanal su alma yapısına yönelecek olan sürüntü maddesi oranı yapay sinir

ağları kullanılarak belirlenmeye çalışılmıştır. YSA modeli, DSİ (1989) tarafından yapılan deneysel verilerden faydalanılarak eğitilmiştir.


Literatürde, çok çeşitli sayıda yapay sinir ağı modeli rapor edilmektedir. Bunların her birinin diğerine göre farklı problemlerde avantaj veya dezavantajları mevcuttur. Geri yayılma sinir ağları en çok kullanılan ağ tipi olmaktadır. Bu araştırmanın konusu olan probleme en uygun ağ tipi olduğuna karar verilmiş ve bu nedenle çalışmada C++ bilgisayar dili kullanılarak Arslan ve İnce (1995) tarafından hazırlanan geri yayımlı sinir ağı programı NETICE (Neural nETwork In Civil Engineering) kullanılmıştır. Program, halihazırda sadece IBM uyumlu kişisel bilgisayarda kullanılabilir. NETICE programı kullanıcıya veri girişlerinde oldukça kolay bir kullanım sağlamaktadır. Giriş nöronlarının sayısı, saklı tabaka ve nöron sayıları, ve çıkış nöron sayıları kolaylıkla girilebilmektedir. Ayrıca bias'ın durumu ve öğrenme oranı değiştirilebilmektedir. Program yapısı herhangi bir alanda uygulama yapılabilmesini sağlayacak şekilde tasarlanmıştır da, NETICE' nin esas geliştirilme amacı çeşitli inşaat mühendisliği problemlerini çözmektir.

2. YAPAY SINİR AĞLARI

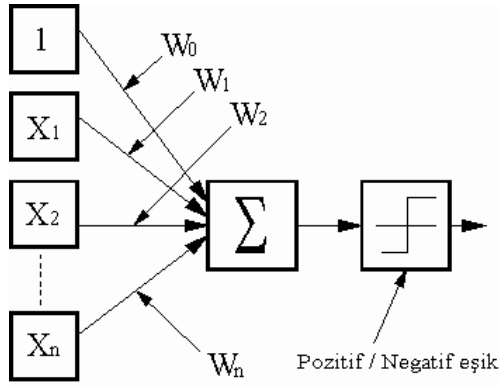
En genel anlamda sinir ağları, insan beynindeki nöronlara benzer olarak meydana getirilen yapay nöronların değişik bağlantı geometrisi ile birbirlerine bağlanmasıyla oluşan kompleks sistemlerdir. Şekil 1.'de bir biyolojik sinir hücresi görülmektedir. Biyolojik nöron, bir çekirdek, gövde ve iki türlü uzantıdan oluşmaktadır. Bunlardan kısa ve dallanmış olan Dendrit giriş bilgilerini alır, uzun ve tek olan akson ise çıkış bilgilerini diğer nöronlara taşır. Akson ve Dendritin birleşim yerine Sinaps adı verilir. Bunlar nöronlardan aldığı sinyalleri değerlendirirler ve eşik değeri üzerinde bir giriş varsa bir sonraki hücreye iletirler.

Yapay sinir ağı teknolojisi hesaplamalarda tamamen farklı bir yaklaşım getirmektedir. Yapay sinir ağları, paralel hesaplama tekniğinin bütün avantajlarını kullanabilen ve algoritmik olmayan bir metottur. Belirli bir problemi, programlama yerine direkt olarak mevcut örnekler üzerinden eğitilerek öğrenirler. Ayrıca yapay sinir ağları, klasik bilgisayar belleği gibi belirli bilgileri belirli yerlerde saklama yerine, öz şeklindeki bilgileri nöronlar arasındaki bağlantılar üzerindeki ağırlık değerleri ile ağ üzerine dağıtarak saklarlar.

Matematiksel olarak modellendirilmiş biyolojik bir nöron Şekil 2.'de görülmektedir. Bu tür nöronlar Mc Culloch-Pits nöronu olarak bilinirler. Bunlar ağın her bir işlem birimini temsil ederler ve birbirleriyle bağlanarak ağı oluştururlar. Her bir nöron basit bir anahtar görevi yapar ve şiddetine göre gelen sinyali ya söndürür ya da iletir. Böylece ağ içerisindeki her bir nöronun belli bir yükü olur.



Şekil 1. Tipik bir biyolojik nöron



Şekil 2. Bir biyolojik nöronun matematiksel modellenmesi

Her nöron gelen sinyalin seviyesine göre açık yada kapalı duruma geçerek basit bir tetikleyici görev üstlenir. Bu işlemleri yaparken nöronlar giriş bilgilerini ağırlandırarak bunları lineer toplar ve bir eşik, lineer veya non-lineer bir fonksiyonda işleyerek çıktısını verir. Bu çıktıyı hücreye bağlantısı olan diğer nöronlar giriş bilgileri olarak alırlar.

Ağ hesaplamaları öğrenme ve hatırlama olmak üzere iki safhadan oluşmaktadır.

A - Öğrenme: Yapay sinir ağları insan zekası gibi örneklerle eğitilirler. Ağlar ne kadar çok örnekle eğitilirse problem üzerindeki teşhisi o kadar doğru olur. Yapay sinir ağlarında iki türlü öğrenme mevcuttur.

a - Denetimli Öğrenme: Ağa örneğe ait hem giriş değerleri hem de çıkış değerleri sunulur ve her iterasyonda örneğe ait çıkış değerleriyle ağ çıkış değeri karşılaştırılarak ağın hatası bulunur. Bu hata kabul edilebilir dereceye indirilene kadar, yapay sinir ağı nöronlar arasındaki ağırlıkları değiştirerek (adapte ederek) iterasyona devam eder. Bazı tip ağlarda ise ağın enerjisi hesaplanır ve bu enerjiyi minimize eden ağırlık grubu, istenen ağırlık grubu olarak kabul edilir.

b - Denetimsiz Öğrenme: Bu tür öğrenmede ağa sadece giriş veri grubu sunulur ve ağdan bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde kendisini uygun ağırlıklarla düzenlemesi istenir.

B - Hatırlama: Ağın öğrenmesi sonucu elde edilen ağırlık grubu kullanılarak ağa belirli bir probleme ait giriş değerleri verilir ve bu probleme çözüm getirmesi istenir.

Yapay sinir ağları yapı olarak iki ana gruba ayrılır.


a - İleri Beslemeli Yapay Sinir Ağları: En genel halde giriş tabakası, saklı tabaka ve çıkış tabakası olmak üzere üç tabakalı bir yapıya sahiptirler. Bu tür ağ yapısında nöronlar arka arkaya beslenirler. Öğrenme aşamasında girdi modelleri ağın giriş terminallerine sunulur. Birinci tabakadaki nöronlar çıktılarını hesaplarlar bir sonraki tabakaya girdi değeri olarak gönderirler. Sırasıyla her bir tabaka aynı işlemi yapar. En uç tabakanın çıktı değerleri de işlemi sonuçlandırır.

b - Geri Beslemeli Yapay Sinir Ağları: Bu tür ağlarda diğerlerinin aksine, tabakalar arasındaki bağlantıya ilave olarak tabakadaki her bir nöron da birbirleriyle bağlantılıdır. En popüler geri beslemeli ağ tiplerinden biri olan Kohonen (1987) ağları, kendi kendini organize

edebilen, kullanımı zor olmasına karşın çok güçlü ve hızlıdır. Denetlenmemiş öğrenme kullanılır. Hopfield (1985) ağı ise ağı enerjisini minimize eder ve bu durumda ağda meydana gelen değişiklikleri analiz ederek ağırlıkları adapte eder. Bu yüzden daha çok optimizasyon problemlerinde kullanılırlar.

c - Geri Yayılma Yapay Sinir Ağı: Geri yayılma terimi gerçekte yapay sinir ağı için özel bir öğrenme kuralıdır. Ancak, genellikle geri yayılma algoritması kullanılan sinir ağı mimarisi olarak algılanır. Geri yayılmalı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Geri yayılmalı yapay sinir ağlarında aynı tabakadaki nöronlar arasında bağlantı mevcut değildir. Ancak, tabakadaki her bir nöron bir ileri tabakadaki her bir nörona ayrı ayrı bağlıdır ve bunların giriş değerlerini verir. Bu tür yapay sinir ağı denetimli öğrenme kuralını kullanırlar. Buna göre hem giriş hem de çıkış verilerinin mutlaka bilinmesi gerekir.

Bir geri yayılmalı sinir ağı işlem üniteleri en az üç tabakadan meydana gelir. Bunlar, Şekil 3.'te görüldüğü gibi bir giriş tabakası, saklı tabaka ve bir çıkış tabakasıdır.



Şekil 3. Geri yayılmalı yapay sinir ağı genel yapısı

Giriş tabakası, giriş veri gruplarının ağa sunulduğu terminallerdir. Bu tabakadaki nöron sayısı, A, giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Burada veri işlenmeden bir sonraki tabakaya yani saklı tabakaya geçer.

Saklı tabaka, ağı temel işlevini gören tabakadır. Bazı uygulamalarda ağda birden fazla saklı tabaka bulunabilir. Saklı tabaka sayısı ve tabakalardaki nöron sayısı, B, probleme göre değişir, tamamen ağ tasarımcısının kontrolündedir ve onun tecrübesine bağlıdır. Bu tabaka girdi tabakasından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki tabakaya iletir. Bu tabakada gereğinden az sayıda nöron kullanılması giriş verilerine göre daha az hassas çıkış elde edilmesine sebep olur. Aynı şekilde, gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkar.

Çıkış tabakası, ağı en uç tabakasıdır. Saklı tabakadan aldığı veriyi ağı kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış tabakasındaki nöron sayısı, C, ağa sunulan her verinin çıkış sayısı kadardır. Bu tabakadan elde edilen değerler yapay sinir ağı söz konusu problem için çıkış değerleridir.

İleri besleme safhasında, giriş tabakasındaki nöronlar, veri değerlerini doğrudan saklı tabakaya iletirler. Saklı tabakadaki her bir nöron kendi giriş değerlerini ağırlandırarak toplam değer hesap ederler ve bunları bir taşıma fonksiyonu ile işleyerek bir ileri tabakaya veya doğrudan çıkış tabakasına iletirler. Tabakalar arasındaki ağırlıklar başlangıçta rasgele küçük rakamlardan seçilir.

Çıkış tabakasındaki, her bir nöron ağırlıklandırılmış değeri hesaplandıktan sonra, bu değer yine taşıma fonksiyonu ile işlenerek sinir ağının ilk çıkış değeri hesaplanmış olur. Bu değer istenen çıkış değeri ile karşılaştırılarak mevcut hata hesaplanır ve hata minimize edilmeye çalışılır. Hata değeri belirli bir mertebeye ininceye kadar iterasyon işlemine devam edilir ve böylece ağıın eğitim aşaması tamamlanmış olur. Tabakalar arası bağlantılardaki ağırlık değerleri eğitimi tamamlanmış ağdan alınarak deneme safhasında kullanılmak üzere saklanır.

İleri besleme safhasında i'inci tabakadaki çıkış değerleri uygun ağırlıklar (W_{ij}) ile çarpılır ve bu saklı tabakaya giriş değeri olarak sunulur. O_i , i'inci tabakadaki her nöronun çıkış değeri bir ileri tabaka olan j tabakasının bir nöronundaki toplam giriş değeri,

$$I_{j,m} = \frac{-\sum_{i=1}^{i-1} w_{ij} a_i^m}{\sum_{i=1}^n w_{ij} a_i^{m-1}} \dots\dots\dots(1)$$

olarak ifade edilir, ve j tabakasının bir nöronundaki çıkış değeri ise,

$$O_j = f_j (X_j) \dots\dots\dots(2)$$

şeklinindedir. Burada f_j taşıma fonksiyonu olarak adlandırılır. Genellikle lineer olmayan veri iletimini sağlamak üzere taşıma fonksiyonu olarak bir sigmoidal fonksiyon kullanılır.

$$f_j = \frac{1}{1 + e^{(-\lambda X_j)}} \dots\dots\dots(3)$$

Burada 1 , taşıma fonksiyonunun şekli kontrol eden bir sabittir. Daha sonra yukarıda detaylandırıldığı gibi sinir ağı çıkışı hesaplanır ve bu çıkış eğitim aşamasında kullanılan gerçek çıkış değeri ile karşılaştırılır. k'inci çıkış tabakasındaki herhangi bir nörondaki hata,

$$e_k = t_k - O_k \dots\dots\dots(4)$$

olarak hesaplanır. Burada t_k geçerli çıkış değerini, O_k ise ağ çıkış değerini göstermektedir. Toplam hata fonksiyonu ise aşağıdaki gibidir.

$$E = \frac{1}{2} \sum_k (t_k - O_k)^2 \dots\dots\dots(5)$$

Geriye yayılma ağlarının kendine has bir öğrenme kuralı vardır. Bu kurala genelleştirilmiş delta kuralı adı verilir. Çok tabakalı bir geriye yayılmalı ağının delta kuralı ile eğitilmesi iterif bir işlemdir. Delta kuralı olarak adlandırılmış kuralın kullanılması ile, ağırlıkların fark değerleri,

$$D W_{kj} = b \cdot d_k \cdot O_j \dots\dots\dots(6)$$

şeklinde ifade edilir. Burada, b , öğrenme oranı parametresi, d_k ise k 'inci tabakadaki bir nöronun hata değeridir.

Geriye yayılmalı yapay sinir ağlarının öğrenme aşaması ile ilgili daha detaylı bilgi Rumelhardt (1987) de bulunabilir. Diğer taraftan ağın daha hassas sonuçlar elde etmesi için, bias adı verilen ve daima girdi değeri 1 olan ve dolayısıyla bir önceki tabakayla bağlantısı olmayan nöronlar da kullanılabilir.

3. YANAL SU ALMA YAPILI DOLU GÖVDELİ BAĞLAMALARDA AYIRMA DUVARININ SÜRÜNTÜ MADDESİNE ETKİSİ

Sulama sistemlerinin ve kanal tipi hidroelektrik santrallerin en önemli yapısı, her iki işletme hali için, gerekli olan suyu akarsudan iletim kanalına çeviren bağlamalardır. Bu tür yapılar, nehir suyunu kabartarak, su alma yapısı yardımıyla iletim kanalına çevirir. Su alma yapıları, karşıdan su alma, alttan su alma ve yanal su alma türünde projelendirilmektedir. Dağ akarsularında uygulanan alttan su alma, büyük eğimli akarsularda iyi sonuçlar veren karşıdan su alma sistemleri, yanal su alma yapılarına göre ülkemizde çok daha az uygulama bulmaktadır.


Ülkemizde su alma yapılarının çoğunu yanal su alma yapıları oluşturmaktadır. Bu yapılarda, sürüntü maddesi sorunu, arazi bitki örtüsü zayıf ve akarsuların eğimlerinin büyük olması nedeni ile önemli bir şekilde kendini göstermektedir. Yanal su alma yapılarında, az sürüntü maddesi içeren su almak için, su alma yapısı ve kapağın konumu, eşik yüksekliği, bağlamanın tipi ve yeri, kılavuz seddeleri, çakıl geçidi gibi etkenlerin yanında; çakıl geçidi ile bağlamayı ayıran ayırma duvarının da büyük önemi bulunmaktadır (DSİ, 1989).

Yanal su alma tipli dolu gövdeli bağlamalar ile ilgili projeler incelendiğinde, ayırma duvarının konumu ve boyutları ile ilgili olmak üzere birbirinden çok farklı düzenlemeler olduğu görülmektedir. DSİ (1989) tarafından yapılan bir çalışmada ayırma duvarının konumu ve boyutlarının, su alma yapısına girecek sürüntü maddesine etkisi incelenmiş ve bu yapının konum ve boyutlarına, bu yönden açıklık getirilmeye çalışılmıştır.

Bu çalışmada, yapılan bazı yaklaşımlarla, olayda etkenliği az olduğu belirlenen bazı parametreler elimine edildikten sonra, su alma oranı, ayırma duvarının uzunluğu ve ayrıca duvar konumunu parametre olarak alan deneyler yapılmıştır.

Deneyler 1/20 ölçekli, sabit tabanlı distorsiyonsuz bir model üzerinde yürütülmüştür. Bu deneyler için, sürekli katı madde vermeyi sağlayan, bir düzenek geliştirilmiştir. Deneyler, çeşitli su alma oranları, çeşitli uzunluktaki ayırma duvarlarının, çeşitli konumları için yürütülmüş ve her deney sonunda, su alma yapısında biriken sürüntü maddesi miktarı ölçülmüştür.

Şekil 4.'de görüldüğü gibi q ile su alma yapısı ekseninin akım doğrultusu ile yaptığı açı gösterilirse membadan gelen Q debisi, su alma yapısından giren Q_A ve bağlamadan geçen debi Q_B 'ye ayrılacaktır. Aynı şekilde membadan gelen sürüntü maddesi Q_S ise Q_{SA} ve Q_{SB} kısımlarına ayrılır (DSİ, 1989).



Şekil 4. Yanal su alma yapısı


Rocha (1970), Thoma (1923), Bulle (1926), Benini (1955) ve diğer araştırmacıların yaptıkları araştırmalarında su alma yapısı q açısının sürüntü maddesi oranına büyük etkisinin bulunmadığını belirtmişlerdir. Bu nedenle araştırmada $q = 90^\circ$ alınarak bir alternatif incelenmiştir. $q < 90^\circ$ olduğu zamanlar, özellikle $q < 30^\circ$ durumlarında yanar su alma yapısı karşıdan almali tipe dönüşmektedir. Yapılan araştırmalarda karşıdan almali tiplerde ayırma duvarı fonksiyonunun olmadığı sonucu çıkmıştır (Bursalı ve Orhon, 1978).

4. YANAL SU ALMA YAPISINA YÖNELECEK OLAN SÜRÜNTÜ MADDESİ ORANIN YSA İLE BULUNMASI

Çalışmada, bu konuda yapılmakta olan araştırmaların ilk aşaması olarak geriye yayılma (backpropagation) öğrenme kuralı ile ağa yanar su alma yapılı dolu gövdeli bağlamalarda ayırma duvarının etkisi dikkate alınarak su alma yapısına yönelecek sürüntü maddesi oranı değişimi öğretilmiştir. Çalışmanın aşamaları aşağıda özetlenmiştir.

4.1. Ağı Eğiten Modellerin Elde Edilmesi

Problemin YSA ile modellenmesinde ilk olarak çıkış nöronunda yer alacak veri/veriler belirlenir. Su alma yapısına yönelecek olan sürüntü maddesi oranı istenildiğine göre, çıkış tabakasında deneylerden elde edilen sürüntü maddesi oranı (Q_{SA}/Q_S), tek bir nöronla temsil edilecektir. Bu çıkış nöronunun alacağı değeri etkileyebilecek veriler ise giriş nöronuna yerleştirilecektir. Kısa bir araştırma sonrasında, giriş verileri olarak Q , h' , h , h_A , L_G , a , d_A , L_G/h ve Q_A/Q değerleri kullanılması uygun görülmüştür. Q mambadan gelen debi, h' savak yükü, h mambadaki su yüksekliği, h_A su alma yapısı mansap derinliği, L_G ayırma duvarı uzunluğu, a ayırma duvarı ekseninin akım yönü ile yaptığı açı, d_A su alma yapısı kapağının açılma yüksekliği, L_G/h ayırma duvarı uzunluk oranı ve Q_A/Q su alma oranıdır. Saklı tabaka sayısı doğrusal olmayan değişkenlerin derecesi ile ilgilidir; bu yüzden, bu problemde bir adet saklı tabaka yeterli görülmüş ve nöron sayısı on bir alınmıştır (Şekil 5).



Şekil 5. 9:11:1 Ağ mimarisine göre çok tabakalı ağ

4.2. Yapay Sinir Ağının Eğitilmesi

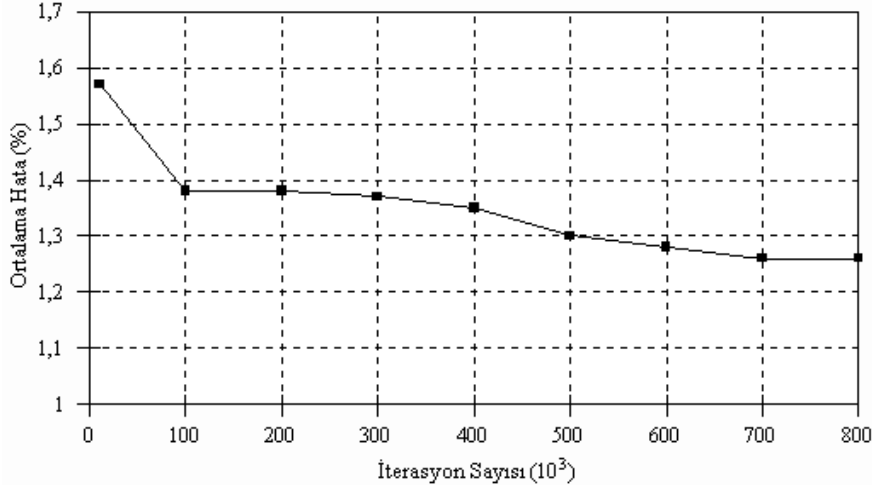
Yapay sinir ağlarının problemlere yaklaşımı insan zekası gibi tamamen edinilen tecrübeye dayanmaktadır. Ağ yeterli sayıda veri grubu ile eğitildiğinde en uygun öğrenme sağlanabilmektedir. YSA'nın eğitilmesi için gerekli veriler, DSİ (1989) tarafından yapılan "Yanal Su Alma Yapılı Dolu Gövdeli Bağlamalarda Ayrırma Duvarının Sürüntü Maddesine Etkisi" adlı çalışmadan alınmıştır. Eğitime işlemi için, bu çalışmada bulunan 193 adet deney verisinden 181'i kullanılmıştır. Eğitime işlemi sırasında bu veriler ağa binlerce defa tanıtılacak (iterasyon) ve böylece YSA'nın, 9 adet giriş ve 1 adet çıkış nöronu arasındaki bağ ağırlıklarını ayarlayarak, giriş-çıkış verileri arasında bir ilişki kurması sağlanacaktır.

Sinir ağında adaptasyon için,

$$f(X) = \frac{1}{1 + e^{-X}} \dots\dots\dots(7)$$

şeklinde sigmoidal bir fonksiyon kullanılmıştır. Sigmoidal fonksiyonunu kullandığımızdan dolayı, verilerin ağa girilmeden önce 0-1 arasında normalize edilmesi gereklidir. Bunun için her bir değişken, o değişkenin alabileceği maksimum değere veya maksimuma yakın bir değere bölünerek 0-1 arasında bir sayı elde edilebilir. YSA dan elde edilecek çıkışlarda, veri girişi sırasında daha önce kullanılmış bölen ile çarpılarak normalizasyon işlemi tersine çevrilir.

Ağ çıktısındaki hatayı minimize etmek için geri yayımlı ağların adaptasyonunda kullanılan genelleştirilmiş delta kuralı uygulanmıştır. Çalışma boyunca öğrenme oranı 0.50 ve momentum ise 0.90 olarak alınmıştır. Eğitim hatasının iterasyon sayısına bağlı değişimi Şekil 6.'da verilmiştir. Şekil 6.'da görüldüğü gibi eğitim sırasında elde edilen değerlerin ortalama hata yüzdeleri oldukça küçük mertebelere sahiptir ve iterasyon sayısının daha da artırılmasının, hatanın azalmasına önemli bir etkisi yoktur.



Şekil 6. Eğitim hatasının iterasyon sayısına bağlı değişimi

4.3. Sinir Ağının Denenmesi

Eğitim işlemi tamamlandıktan sonra eğitilmiş YSA'nın test edilmesi işlemine geçilir. Çizelge 1.'de görüldüğü gibi test işlemi sırasında, daha önce ağın eğitiminde kullanılmayan 12 adet deney verisi kullanılmıştır. Deneysel olarak ve YSA modelinden elde edilen Q_{SA}/Q_S değerleri karşılaştırılmıştır. Bu karşılaştırmalardan görüldüğü gibi, sinir ağı sonuçları iyi bir yaklaşım göstermektedir. Eğitim aşamasında daha çok sayıda iterasyon yapılarak hata oranı daha da aşağılara çekilebilir. Ancak, bu çalışmada geri yayılma sinir ağı kullanıldığından bu tip ağların genel özelliği olarak iterasyon işlemi çok uzun olmaktadır.

Sonuçların incelenmesinden görülmektedir ki; doğal olarak eğitim seti için öğrenme oldukça yüksek olmaktadır, ancak YSA dan test numuneleri için de aynı performansı göstermesi beklenemez. Test sırasında YSA modellemesinden elde edilen hata yüzdeleri ortalaması % 7.91 olmaktadır. Eğitim aşamasında az sayıda veri grupları kullanılması, bu sonucun ortaya çıkmasına neden olmuştur. Daha fazla veri grupları ile yapılan sinir ağı eğitiminde bu farkın azalacağı söylenebilir. İnşaat mühendisliğindeki bir çok problem için bu mertebedeki bir yaklaşım yeterli görülmektedir.

Geri yayımlı yapay sinir ağları, öğrenme aşamasında uzun zaman ve çok sayıda veriye gereksinim duyarlar. Ağın eğitim aşaması iyi bir kişisel bilgisayarda saatler almasına karşın, hatırlama aşamasında, yani ağ hesaplama için kullanıldığında, klasik bir programdan çok daha hızlı çalışmaktadır.

Çizelge 1. Test işlemine ait deneysel sonuçlar ile YSA modeline ait sonuçlar

No	Q (m ³ /s)	h' (m)	h (m)	h _A (m)	L _G (m)	a (°)	d _A (m)	L _G /H	Q _A /Q	Q _{SA} /Q _S	
										Deney YSA	
	0.04176	0.0791	0.272	0.130	0.000	0	0.050	0.00	0.0740	0.653	0.687 (5.21)
	0.04176	0.0791	0.271	0.129	0.280	5	0.050	1.03	0.0740	0.403	0.403 (0.00)
	0.04176	0.0791	0.272	0.129	0.745	20	0.050	2.75	0.0740	0.014	0.017 (21.43)
	0.06037	0.1006	0.283	0.132	0.205	0	0.027	0.72	0.0506	0.257	0.272 (5.84)
	0.06037	0.1006	0.283	0.132	0.350	5	0.027	1.24	0.0506	0.104	0.106 (1.92)
	0.06037	0.1006	0.282	0.132	0.480	15	0.027	1.70	0.0506	0.030	0.032 (6.67)
	0.07901	0.1198	0.293	0.129	0.070	0	0.025	0.24	0.0384	0.195	0.205 (5.13)
	0.07901	0.1198	0.293	0.138	0.140	10	0.025	0.48	0.0384	0.132	0.147 (11.36)
	0.07901	0.1198	0.293	0.132	0.280	15	0.025	0.96	0.0384	0.063	0.050 (20.63)
	0.11627	0.1536	0.309	0.130	0.070	0	0.015	0.23	0.0256	0.076	0.066 (13.16)
	0.11627	0.1536	0.309	0.130	0.140	5	0.015	0.45	0.0256	0.056	0.058 (3.57)
	0.11627	0.1536	0.309	0.130	0.280	10	0.015	0.91	0.0256	0.021	0.021 (0.00)
Ortalama Hata (%)										7.91	

5. Sonuç ve Tartışma

Sunulan çalışma, bu konuda yapılacak bir seri araştırmanın ilk adımını teşkil etmektedir. Bu nedenle başarılı bir şekilde uygulama yapılmış olması oldukça önem taşımaktadır.

Bu çalışma göstermiştir ki, NETICE birçok inşaat mühendisliği problemini çözebilecek kapasitededir. Önemle vurgulanması gereken bir diğer üstünlük ise aynı sinir ağı modeli ile hemen her türlü problemin çözülmesine olanak sağlanmasıdır. Konvansiyonel programlama tekniklerinde her tür problem için ayrı bir bilgisayar programına gereksinim duyulmasına karşılık, yapay sinir ağı modelinde problemin türüne göre ağ, sadece nöron sayısı ve ağırlıkların değişimine ihtiyaç göstermektedir.

Yapay sinir ağlarının mühendislik problemlerindeki en önemli üstünlüğü ise hesaplamaları direkt olarak deney sonuçlarını kullanarak öğrenmesi ve yapmasıdır. Diğer önemli üstünlüğü ise dağınık veya yetersiz veri olan problemlerde, ve tanımlanmış teorisi olmayan türden problemlerde kullanılması ve bu tür problemlerde doğruya yakın çözüm vermesidir.

6. KAYNAKLAR

Adeli, H. (1996) : Innovative Computing in Civil Engineering. Bahrain, "Proc. of the 2nd Inter. Conf. in Civil Eng. on Comp. App. Research and Practice", Vol. 1, 1-5.

Aleksander, I. ; Morton, H. (1990) : "An Introduction to Neural Computing". London, Chapman and Hall.

Arslan, A. (1992) : İnşaat Mühendisliğinde Uzman Sistem Uygulamaları. İstanbul, İ.T.Ü. İnşaat Fakültesi, "İnşaat Mühendisliğinde Bilgisayar Kullanımı III. Sempozyumu", 15-19 Haziran 1992.

Arslan, A. ; Ince, R. (1994a) : The Neural Network Based Analysis of Size Effect in Concrete Fracture. "Am. Soc. Civ. Engr.", Eng. Mech. Div.

Arslan, A. ; Ince, R. (1994b) : A Neural Network Application on Design of R.C. Flat Slabs. Athens, Greece, "The Second Int. Conf. on Computational Technology", 30th August-1st Sept. 1994b.

Arslan, A. ; İnce, R. (1995) : Geriye Yayılma Yapay Sinir Ağı Kullanılarak Betonarme Kolonların Tasarımı. "DOĞA Mühendislik ve Çevre Bilimleri Dergisi", 19, 127-135.

Benini, G. (1955) : "Sull'angelo die presa di una derivazione". L'energia Elettrica, No: 9, Vol: 32, 20.

Bresloff, P. C. ; Weir, D. J. (1991) : Neural Networks. "GEC Journal of Research", Vol. 8, No. 3.

Bulle, H. (1926) : "Untersuchungen über die Geschiebeableitung bei der Spaltung von Wasserläufen". Diss. T. H. Karlsruhe 242.

Bursalı, S. ; Orhon, M. (1978) : "Su Alma Yapısı Model Çalışması Raporu". Ankara, DSİ Araştırma ve Geliştirme Dairesi Başkanlığı, Yayın No: Hİ 683, 1-37.

Dere, Y., ; Kaltaklı, M.Y. (1997) : İnşaat Mühendisliğinde Yapay Sinir Ağları Uygulamaları. Ankara, "İnşaat Mühendisliğinde Gelişmeler, III. Teknik Kongre", 15-16 Eylül 1997, ODTÜ, 407-416.

DSİ (1989) : "Yanal Su Alma Yapılı Dolu Gövdeli Bağlamalarda Ayrırma Duvarının Sürüntü Maddesine Etkisi". Ankara, T.C. Bayındırlık ve İskan Bakanlığı DSİ Teknik Araştırma ve Kalite Kontrol Dairesi Başkanlığı, Yayın No. Hİ-774.

Hetch, Nielsen, R. (1989) : Theory of the Backpropagation Neural Network. Washington, D. C., "Int. Conf. on Neural Networks", Vol.1, 593-605.

Hopfield, J.J. ; Tank, D.W. (1985) : Neural Networks' Computation of Decisions in Optimization Problems. "Biological Cybernetics", No.52, 141-152.

Kohonen, T. (1987) : State of the Art in Neural Computing. "Int. Conf. on AI", pp. 1-79, 1-90.

Melsa, P. J. W. (1989) : "Neural Networks: A Conceptual Overview". Report TRC-88-08, Tellabs Research Center.

Moselhi, O. (1996) : Neural Networks' Applications in Civil Engineering. Bahrain, "Proc. of the 2nd Inter. Conf. in Civil Eng. on Comp. App. Research and Practice", Vol. 1, 7-14.

Rich, E., Knight, K. (1991) : "Artificial Intelligence". Singapore, Mc. Graw-Hill, pp. 487-528,

Rocha, F. (1970) : "Wasserableitung aus Flüssen mit Sedimentbewegung". Mitteilungen des Franzius Instituts für Grund-und Wasserbau Heft 35 Eigenverlag des Franziusinstituts für Grund-und wasserbau der TU Hannover Helf: 35 87.

Rumelhardt, D. E. et al. (1987) : "Parallel Distributed Processing, Explorations in the Microstructure of Cognition". Vol. 1, MIT Press.

Thoma, H. (1923) : "Geschiebebewegung in wasserdurchströmten Gerinnen und die Ausbildung der Kanaleinläufe bei Wasserkraftanlagen". Veröffentlichungen der mittlere Isar A.G. Modellversuche Teil 3 134.