

Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi

Mahmut FIRAT*

Mahmud GÜNGÖR**

ÖZET

Son yıllarda, inşaat mühendisliğindeki bilgisayarlı hesaplamalarda yapay zeka uygulamaları ilk sırayı almıştır. Bu uygulamalar genellikle uzman sistemleri içermektedir. Bu makalede yapay sinir ağlarına değinilmiş ve bir uygulama yapılmıştır. Sonuçlara çok kısa zamanda yaklaşımadaki etkinliği diğer yaklaşım metotlarına göre tercih edilmesine neden olmuştur. Ülkemizde çeşitli nedenlerle meydana gelen erozyon olayı sonucu, katı madde taşınımının, toprak ve su kaynaklarının geliştirilmesine olan olumsuz etkilerinin büyük boyutlara ulaştığı bilinen bir geçektir. Bu çalışmada, akarsular tarafından taşınan askı maddesi miktarı ileri beslemeli yapay sinir ağları ile tespit edilmiştir. Problemin eğitim ve test setinde EİE (Elektrik İşleri Etüt İdaresi) tarafından yapılan askı maddesi ölçümleri kullanılmıştır.

ABSTRACT

Determination of Carried Suspended Sediment Concentration and Amount by Artificial Neural Networks

Computation on Civil Engineering has concentrated primarily on artificial intelligence applications in the past few years. These applications generally involve expert systems. This article deals Neural Networks and applications were presented. It quickly gives results in test phase in short time. It is a preferable method among the other approaching methods. In Turkey, sedimentation which is the natural result of erosion occurring by different factors is known having an adverse effect on development of soil and water resources. In this study, the suspended sediment amount carried by stream is determined by the feed forward neural network method. The training sets for the problem were generated through sediment measurements which have been performed by EIE.

Not: Bu yazı

- Yayın Kurulu'na 19.07.2002 günü ulaşmıştır.
- 30 Eylül 2004 gününe kadar tartışmaya açıktır.

* Pamukkale Üniversitesi, İnşaat Mühendisliği Bölümü, Denizli - mfrat@pamukkale.edu.tr

** Pamukkale Üniversitesi, İnşaat Mühendisliği Bölümü, Denizli - mgungor@pamukkale.edu.tr

1. GİRİŞ

Canlı hücrelerin en önemli özelliği, kimyevi potansiyel enerjiyi kendi organize yapılarını korumak için gerekli diğer enerji şekillerine çevirebilmeleridir. Her hücre entropisinin artmasına yani dağılmasına mani olmak için enerji sarf etmek zorundadır. Çevredeki değişiklikleri, bunların kendi üzerine tesir derecesini, yani, düzenini, dengesini, ne dereceye kadar bozabileceğini bilmesi, gerekli ayarlamaları yapması, bu ayarlamaların da ne dereceye kadar hedefe uygun olduğunu ölçmesi ve gereken düzeltmelerde bulunması, kısaca çevreye uyumunu sağlaması, canlılığını devam ettirebilmesi için bir “Haber Alma-Karar Verme- İcra” sistemine ihtiyaç vardır. İşte sinir sistemi denilen fevkalade farklılaşmış canlı doku bu önemli vazifeyi yerine getirmektedir, [12].

Bu nedenlerle bilim adamları beynin yaptığı bu işlemleri yapabilecek bilgisayarlar ve neticede robotlar yapmak için yapay zeka konusunda çalışmaya başlamışlardır. Bilgisayar teknolojisinin günümüze kadarki aşamalarında da görülen hep daha mükemmelere ulaşma arzusudur. Bilim adamları vardıkları mükemmeliyetin son noktasını hep tabiatta bulmuş ve kendilerine tabiatta var olanları örnek olarak seçmişlerdir. İşte bilgisayar teknolojisinde de ulaşılmak istenen nokta insan beyninin gerçekleştirdiği fonksiyonları ve işlevleri yerine getirebilen bir yazılım ortaya koymaktır. Bunun başlıca nedeni insan beyninin; düşünme, var olan bilgi ve tecrübelerden sonuç çıkarma, karar verme gibi işlemleri yerine getirebilmesi ve bunları mili hatta nano saniyeler mertebesinde gerçekleştirme becerisidir.

Yapay sinir ağları üzerine yapılan araştırmalar hem yazılım hem de donanım üzerinedir. Günümüzde yapay sinir ağları; ekonomi, iktisat, endüstri mühendisliğinde, otomasyonda, elektronik mühendisliğinde, elektronik devre tasarımında, bilgisayar mühendisliğinde, tıp alanında, çeşitli zeka problemlerinin çözümünde, optik algılama gibi bir çok alanda kullanılmıştır. Ancak İnşaat mühendisliği alanında yeterli sayılabilecek kadar uygulama alanı olmasına rağmen, yapay sinir ağları üzerine henüz kapsamlı bir çalışma yapılmamıştır, [3].

Ülkemizde askı maddesi miktarının ölçülmesi, EİE ve DSİ tarafından yapılmaktadır. 1996 yılı itibariyle 105 adet gözlem istasyonunda askı maddesi ölçümleri yapılmakta ve her gözlem süresi boyunca belirlenen ölçüm sonuçlarına göre askı maddesi anahtar eğrileri çizilmektedir. Bu anahtar eğrileri, askı maddesi miktarı (ton/gün), askı maddesi konsantrasyon PPM ile bu örneklerin alındığı anda ölçülen akarsu debisi (m^3/s) değerlerinin logaritmik dönüşümleri kullanılarak çizilmektedir.

Yapılan bu çalışmada Büyük Menderes havzasındaki 706 nolu gözlem istasyonundaki askı maddesi miktarı ve konsantrasyonu hem EİE tarafından geliştirilen anahtar eğrileri ile hem de yapay sinir ağları ile hesaplanmış ve birbirleriyle karşılaştırılmıştır.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağı, insan beyni gibi biyolojik sinir sisteminden ilham edilen bir bilgi işlem paradigmasıdır. Bu paradigmanın anahtar elemanı, bilgi işlem sisteminin yapısıdır, [22]. Belirli problemleri uyum içinde çözmek için işlem elemanları arasında yüksek sayıda bağlantı oluşturulur. Yapay sinir ağları insanlar gibi örneklerle öğrenir. Bir yapay sinir ağı, öğrenme işleme içerisinde veri sınıflandırma, veya numune tanıma gibi kesin (belirli) uygulama için şekillendirilir. Öğrenme, sinirler arasında var olan bağlantılarda biyolojik sinirlerdeki kuralları gerektirir.

Kohonen; yapay nöral ağların adaptif elemanların yoğun bir şekilde paralel olarak bağlanmasıyla oluşan ve gerçek dünyadaki cisimlerle aynen biyolojik sinir sisteminin yaptığı gibi ilişkide bulunabilmeleri için hiyerarşik organizasyonları düzenlenmiş yapılar olduğuna dikkat çeker [21].

2.1. İnsanda Sinir Sistemi

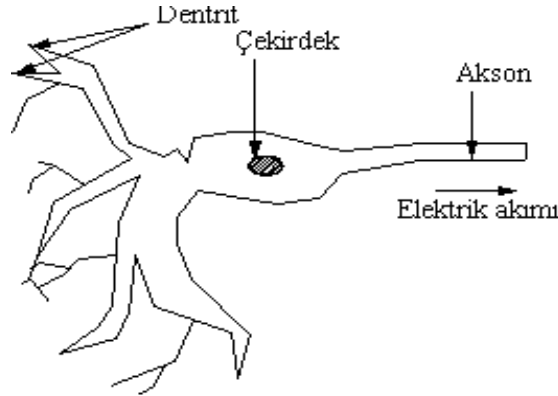
Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinde ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür.

Tepki sinirleri (effector) ise, beyin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 1’ de bir sinir sisteminin blok gösterimi verilmiştir.



Şekil 1. Biyolojik sinir sisteminin blok gösterimi

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresi (nöron) dur. Sinir hücresi; hücre gövdesi, dendritler ve aksonlar olmak üzere 3 bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur, [14].



Şekil 2. Nöronun biyolojik modeli

Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi

Yapay sinir ağlarının işleyişi de buna benzer olarak gelişmektedir. 1940 yılında McCulloch ve Pitts nöronun, mantık sistemlerinde basit eşdeğer yapısıyla modellenebileceğini ortaya atmışlardır [12].

Bu amaçla yaptıkları çalışmalar sonunda Şekil 2’de görüldüğü gibi bir yapay nöron modeli geliştirmişlerdir. Bu modele göre, bir nöron N tane ağırlıklandırılmış girişi toplamakta, bir eşik değeri bu toplamdan çıkartıp sonucu lineer olmayan bir fonksiyondan geçirmektedir.

2.2. Matematik Sinir Yapısı (Nöronun Matematik Modeli)

Nöronlar sinir ağlarını oluşturan, tek başlarına ele alındıklarında çok basit bir işleve sahip işlemcilerdir. Bir nöron yapısı içerisinde üç ana bölüm bulunur. Bunlar sırasıyla sinapslar, toplayıcı ve aktivasyon fonksiyonudur.

Şekil 3 de bir nöronun matematiksel modeli gösterilmektedir. Bu şekilden de görüleceği gibi, nöron girdileri sinaptik bağıntılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır. (1) denkleminde ağırlıklı toplamın oluşturulması, (2) denkleminde ise nöron çıkışının hesaplanması verilmektedir.

$$S = w_1 \cdot u_1 + w_2 \cdot u_2 + w_3 \cdot u_3 \dots \dots \dots + w_n \cdot u_n - \theta = \sum_{i=1}^n w_i \cdot u_i - \theta \quad (1)$$

$$O = \psi(S) \quad (2)$$

S ; Toplam fonksiyonu

u_i ; Giriş fonksiyonu

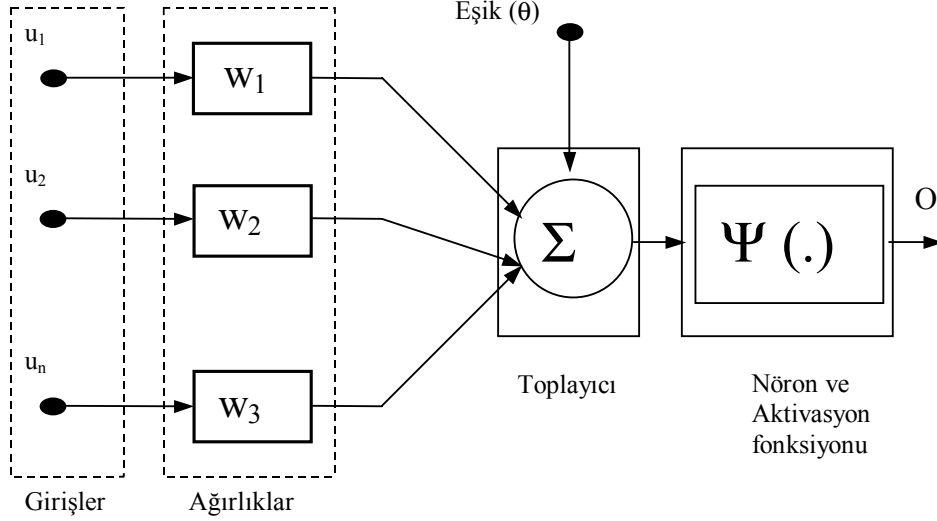
w_i ; Ağırlıklandırma faktörü

O ; Çıkış fonksiyonu

$\Psi(S)$; Aktivasyon fonksiyonu

θ ; Eşik değeri

Her bir girdideki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişimin genliği, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon fonksiyonunun tipine bağlıdır. Eşik değerinin kullanımı, pratikte (-1) ya da (+1) değerine sahip sabit bir girdinin (θ) ağırlığına sahip bir bağıntı ile toplayıcıya girdiği şeklinde ele alınır, [15].



Şekil 3. Nöronun matematik modeli

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. Yapay sinir ağları hesaplamaları öğrenme ve hatırlama olmak üzere iki safhadan oluşur.

2.3. Öğrenme

Yapay sinir ağları insan zekası gibi örneklerle eğitilirler. Ağlar ne kadar çok örnekle eğitilirse problem üzerindeki teşhisi o kadar doğru olur, [4]. Eğitime belirli kabul edilebilir bir hata ile yapılır. Bir yapay sinir ağında öğrenme ağırlık matrisinde değişme olarak düşünülür. Öğrenme genel olarak iki grup içinde kategorize edilir. Bunlar denetimli öğrenme ve denetimsiz öğrenme olarak verilebilir.

2.3.1. Denetimli Öğrenme

Denetimli öğrenme, giriş vektörlerinin data setini ve ağı eğitmek için çıkış vektörlerinin cevabını kullanır. Ağırlık matrisi, toplam ağ hatasının kabul edilebilir hatadan daha büyük olduğu sürece güncelleştirilir.

Örneğe ait çıkış değeri ile ağ çıkış değeri karşılaştırılarak ağı hatası bulunur. Bu hata kabul edilebilir seviyeye gelinceye kadar, yapay sinir ağı nöronlar arasındaki ağırlıkları değiştirerek iterasyona devam edilir. Ağı eğitilmesine olanak sağlayan data setine “eğitim seti” denir. Bir ağı eğitilmesi sırasında, bağlantı ağırlıklarını ayırmadan çoğu zaman data setinin aynısı işlenir.

2.3.2. Denetimsiz Öğrenme

Bu tür öğrenmede, ağa sadece giriş veri grubu verilir, çıkış değerleri verilmez. Ağdan bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde kendisini uygun ağırlıklarla düzenlemesi istenir, [9]. Bu eğitimde nöron ağının ortam ile karşılıklı ilişkisi minimuma indirilir.

2.4. Hatırlama

Ağın öğrenmesi sonucu elde edilen ağırlık grubu kullanılarak ağ belirli bir probleme ait giriş değerleri verilir ve bu probleme çözüm getirmesi istenir. Burada verilen giriş değerleri daha önceden ağa verilmeyen değerler olmalıdır.

2.5. Yapay Sinir Ağlarının Yapıları

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir, [15].

2.5.1. İleri Beslemeli Sinir Ağ Yapıları

İleri beslemeli yapay sinir ağlarının en tipik şekli nöron modeli oluşturulan katmanların ardışık biçimde bir araya getirilmesi sonucu kurulabilir. İleri beslemeli YSA' da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. Aşağıdaki şekilde gösterildiği gibi girdilerin uygulandığı katmana giriş katmanı, çıkışların alındığı katmana çıkış katmanı denir ve bu katmana dış dünyadan erişebilir. Giriş ve çıkış katmanlarının arasında gizli katmanlar bulunur. Giriş ve çıkış katmanlarındaki nöron sayıları ele alınan problemin gereklerine göre belirlenir. Dolayısıyla gizli katman sayısındaki ve bu katmanların nöron sayısındaki belirsizlikleri aşabilmenin tek yolu deneme yanılma yöntemidir, [4].


Giriş katmanı

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

Saklı katman

Ağın temel işlevini gören tabakadır. Bazı uygulamalarda ağda birden fazla saklı tabaka bulunabilir. Saklı tabaka sayısı ve tabakalardaki nöron sayısı 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.



Şekil 4. İleri beslemeli sinir ağ yapısı

Çıkış katmanı

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

İleri besleme safhasında, giriş tabakasındaki nöronlar, veri değerlerini doğrudan saklı tabakaya iletir. 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 rasgele küçük rakamlardan seçilir.

2.5.2. Hatayı Geriye Yayma Algoritması

Bir sinir ağı, ağın mimarisi, bir nörondaki aktivasyon fonksiyonu ve eğitim algoritması ile karakterize edilir. Çok tabakalı sinir ağlarının eğitimi için genellikle kullanılan eğitim algoritması hatayı geriye yayma (Back Propagation) algoritmasıdır,[2,3,4]. Türevi alınabilir aktivasyon fonksiyonu ile herhangi bir ileri beslemeli sinir ağları için kullanılabilir. Eğer toplam hata fonksiyonu gibi ağ çıkışlarının her bir için de bir hata fonksiyonu tanımlarsak, hata fonksiyonu, ağırlıkların diferansiyel fonksiyonu olur. Bu

Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi

nedenle ağırlıklar ile hatanın türev değerini bulabiliriz. Bu teknik, Rumelhart, Hinton ve Williams tarafından geliştirilmiştir.


Bu türevler, eğim düşümü yada optimizasyon metodu ile minimum hata fonksiyonunun ağırlıklarını bulmak için kullanılabilir. Hata fonksiyonunun türev değeri için kullanılan algoritma hatayı ağ içerisinde geriye doğru yaydığı için “hatayı geriye yayma” algoritması olarak bilinir, [13]

Yapay sinir ağlarının parametrelerinin güncellenmesi için literatürde en çok kullanılan yöntem hatayı geriye yayma yöntemidir. Ses tanıma problemlerinden nonlinear sistem tanılama ve denetimi problemlerine kadar yapay sinir ağları ile çözüm üretilen bir çok alanda başarı ile kullanılan bu yöntem, quadratik bir maliyet fonksiyonunun zaman içerisinde, ağ parametrelerinin uyarlanması ile minimizasyonuna dayanmaktadır.

2.5.3. Sigmoid Tipi Aktivasyon Fonksiyonu

Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda kullanılır. Geriye yayma modeli her yerde diferansiyeli alınabilen aktivasyon fonksiyonu gerektirir, [22]. Grafiği aşağıda verilen sigmoid tipli aktivasyon fonksiyonu türevi alınabilir, ve sürekli problemlerin çözümünde kullanılmaktadır. Sigmoid tipi aktivasyon fonksiyonunun denklemi aşağıdaki gibidir.

$$\Psi_1(S) = \frac{1}{1 + e^{-S}} \quad (3)$$



Şekil 5. Sigmoid tipli aktivasyon fonksiyonu

Burada ağırlık değerleri ile ağırlıklandırılarak aktivasyon fonksiyonundan geçirilerek çıkış değerleri hesaplandıktan sonra, elde edilen bu çıkış değerleri bizim gerçek sonuçları ile karşılaştırılır. Böylelikle ağırlık hesapladığı değer ile gerçek sonuç arasındaki hata değeri bulunur. Bu hata değerini de aşağıdaki gibi hesaplarız. Belirli bir giriş değeri için istenen nöron cevabı (d), bu girdi için nöronun üretmiş olduğu cevap (o) ile gösterilsin ve hata ölçütü ;

$$e = d - o \quad (4)$$

olarak tanımlansın. Eğitim düşün yönteminin temeli (4) aşağıdaki denklemi ile verilen ve (J_r) sembolü ile gösterilen maliyet fonksiyonunun kurulmasına ve bu fonksiyonun, nöron parametrelerinin uyarlanması ile minimize edilmesine dayanır.

$$J_r = \frac{1}{2} \cdot (d - o)^2 = \frac{1}{2} \cdot e^2. \quad (5)$$

Geriye yayma algoritmasının kendisine özgü bir öğrenme kuralı vardır. Bu kurala Delta kuralı denir. Bu kuralın kullanılması ile, ağırlıkların farkı hesaplanır.

Çıkış tabakası için ağırlık değerlerinin değişimleri,

$$\Delta W_{ji} = \eta \cdot \delta_j \cdot O_i \quad (6)$$

$$\delta_j = (d_j - o_j) \cdot \Psi'(net_j) \quad (7)$$

burada; (η); öğrenme derecesi (0 ve 1 arasında)

Gizli tabakalar için ağırlık değerlerini değişimi,

$$\Delta W_{ji} = \eta \cdot \delta_j \cdot O_i \quad (8)$$

$$\delta_j = \sum_k (\delta_k \cdot W_{kj}) \cdot f'(net_j) \quad (9)$$

Değişen değerlere göre ağırlıkların güncellenmesi,

$$W_{ij}^{yeni} = W_{ij}^{eski} + \Delta W_{ij} \quad (10)$$

Bu adımlar toplam hata kabul edilebilir değere gelinceye kadar tekrarlanır.

3. AKARSULARDA KATI MADDE HAREKETİ VE DEBİ İLE İLİŞKİSİ

Katı madde taşınımı ile tarla ziraatı yapılan alanlar verimsizleşmekte ve aynı zamanda baraj haznelerinin dolmasına neden olmaktadır. Bu daneler suyun bulanıklılığını artırarak kalitesini düşürdükleri için gerek endüstride, gerek günlük hayatta kullanılan sularda bu danelerin yüzdesi belli sınırları aşmamalıdır,[6]. Akarsuların taşıdığı danelerin başka zararları da vardır. Taşınmakta olan iri daneler köprü ayaklarını, bağlama yüzlerini ve kaplamalı kanalları aşındırabilir. Çok eğimli akarsularda taşınan iri kayalar akarsu üzerinde yapılacak yapılara zarar verebilir. İnce daneler de su kuvveti tesislerinin türbinlerini ve pompalarını yüksek hızlarla çarpmaları sonunda aşındırabilirler.

Akarsuların taşıdığı katı maddeler, akım hızının dane hareketini sağlayan kritik hızın altına düştüğü yerlerde yığılırlar. Yığılma yersel olarak köprü ayaklarının arkasındaki su bölgelerinde de meydana gelebilir. Yığılma sonunda da problemler ortaya çıkabilir. Ülkemizde akarsuların su rejimleri düzensiz olduğundan ve akarsu eğimleri fazla olduğu için taşınan katı madde miktarı oldukça fazladır, [6]

Bu nedenle bu bölgelerde barajların bir çoğunda katı madde birikme problemi oldukça önem taşımaktadır. Yığılma sonunda baraj haznelerinin biriktirme kapasitelerini azaltmaktadır. Ayrıca tarım toprakları üzerinde yığılan daneler toprağın verimini azaltır. Baraj haznesine katı madde taşınımını tamamıyla önlemek mümkün değildir. Ancak akarsu havzasını ağaçlandırmak ve teraslama ile yani havza düzenlemesiyle akarsuyun taşıdığı katı madde miktarı azaltılabilir, [8]

Bir akarsuyun taşıdığı katı madde miktarı, akarsuyun debisine, taban eğimine ve zamana bağlı olarak değişmektedir. Akarsuyun katı madde taşıma gücü, akım hızının azaldığı yerlerde azalacaktır ve böylece katı madde o bölgelerde yığılacaktır.

Akım içine yerleştirilen köprü ayağı, köprü kenar ayağı ve mahmuzlar gibi yapıların bulunduğu daraltılmış kesitlerde türbülans şiddetinin artması ile, katı madde taşınımı ve bu ikisinin karşılıklı etkileşimi sonucunda, akarsuyun yerel katı madde taşıma kapasitesi artar, bunun sonucunda da yerel oyulma başlamış olur, [17,18,19]

Bir akarsu kesitinden geçmekte olan katı madde miktarını belirlemek için en doğru, fakat aynı zamanda zor ve pahalı bir yol, akarsuda ölçümler yapmaktır. Bilindiği gibi daneler iki farklı şekilde hareket eder: sürüntü hareketi ve askı hareketi. Bu iki hareket şekli için ölçme metodları değişiktir. Bazı akarsularda, kanalın dar bir kesitinde hız ve türbülansın artmasıyla bütün daneler askı haline geçer bu durumda askı maddesini ölçmek mümkün olmaktadır.

Numune alma sayısı askı maddesi konsantrasyonuna bağlıdır. Numune, taşkın döneminin çeşitli devrelerinde alınır. Çünkü maksimum askı maddesi konsantrasyonu maksimum debiye ulaşmadan önce meydana gelir.

Güvenilir bir sonuç elde etmek için büyük bir bölgede taşkın sırasında yeterli sayıda numune (10 ila 20) alınmalıdır. Numune alma işlemi kritik şartlarda, yani debi maksimum iken daha sık yapılmalıdır

Bu çalışmada Büyük Menderes Havzasında yer alan 706 nolu Büyük Menderes Nehri – Aydın Köprü istasyonunda, akarsu ile taşınan askı maddesi miktarı ve askı maddesi konsantrasyonunun belirlenmesinde Yapay Sinir Ağları kullanılmıştır. Büyük Menderes Havzasında bulunan ve EİE tarafından işletilen 706 nolu gözlem istasyonunun yeri ve özellikleri aşağıda verilmiştir.

Tablo1. 706 nolu akım ve askı maddesi gözlem istasyonunun yeri ve özellikleri

İstasyon No	İstasyon Adı	İstasyon Yeri	Net Drenaj Alanı (km ²)	Askı Maddesi Gözlem Yılları	Ortalama Akım (m ³ /s)
706	Büyük Menderes Aydın-Köprü	Aydın-Muğla asfaltı üzerinde Aydın'a 8 km uzaklıktaki köprüde	7130	1985-1990	70,432 (25 yıllık)

4. ASKI MADDESİ VE SEDİMENT KONSANTRASYONUNUN YAPAY SİNİR AĞI İLE BELİRLENMESİ

Askı maddesi miktarının ve sediment konsantrasyonunun akarsuyun debisiyle değiştiği bilinmektedir.

4.1. Ağın Eğitilmesinde Kullanılan Model

Yapay sinir ağları insanlar gibi örnekler ile eğitildikleri için yeterli sayıda veri grubunun kullanılması ile çok iyi sonuçlar elde edilmektedir. Ağı eğitirken gerekli veriler EİE tarafından Büyük Menderes Havzası 706 nolu gözlem istasyonunda yapılan ölçümlerden alınmıştır.

Eğitim için 90 adet veriden 85 adeti kullanılmıştır. Model oluşturulurken 1 giriş ve 1 adet çıkış düğümü arasında en uygun sonucu elde etmek için ağırlıklar ve gizli tabaka sayısı ve düğüm sayısı deneme yanılma ile bulunmuştur.

4.2. Ağın Eğitilmesi

Yapay sinir ağının eğitilmesinde ,


$$f(S) = \frac{1}{1 + e^{-S}} \quad (11)$$

şeklinde sigmoid bir fonksiyon kullanılmıştır. Sigmoid fonksiyonun özelliğinden dolayı, veriler ağa verilmeden önce 0-1 arasında normalize edilmelidir. Yapılan bu çalışmada giriş veri değeri olarak akarsu debisi, çıkış değerleri olarak askı maddesi konsantrasyonu ve askı maddesi miktarı kullanılmıştır.

Bu parametrelerin her birinin maksimum ve minimum değerleri bulunarak aradaki değerler (0-1) arasında normalize edilmiştir. Buna bağlı olarak yapay sinir ağlarının üreteceği sonuçlar da 0-1 arasında olacaktır. Bu durumda normalize işlemi tersine çevrilerek çıkışlar bulunur. Ayrıca yapılan bu çalışmada yapay sinir ağ yapısı olarak ileri beslemeli sinir ağı, öğrenme tipi olarak denetimli öğrenme, hatayı minimize etmek içinde hatayı geriye yayma algoritması kullanılmıştır. Yapay sinir ağının eğitimi sırasında gizli tabaka sayısı 3 seçilmiş ve bu tabakalardaki düğüm sayıları sırasıyla (10 7) alınmıştır. Ayrıca öğrenme derecesi (0,4), momentum katsayısı (0,7) ve iterasyon sayısı 7800 alınmıştır. Seçilen bu mimariye

Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi

ağın eğitiminden sonra hata değerinin iterasyon sayısına göre değişiminin grafiği aşağıda verilmiştir.



Şekil 7. Ortalama hata yüzdesinin iterasyon sayısı ile değişimi

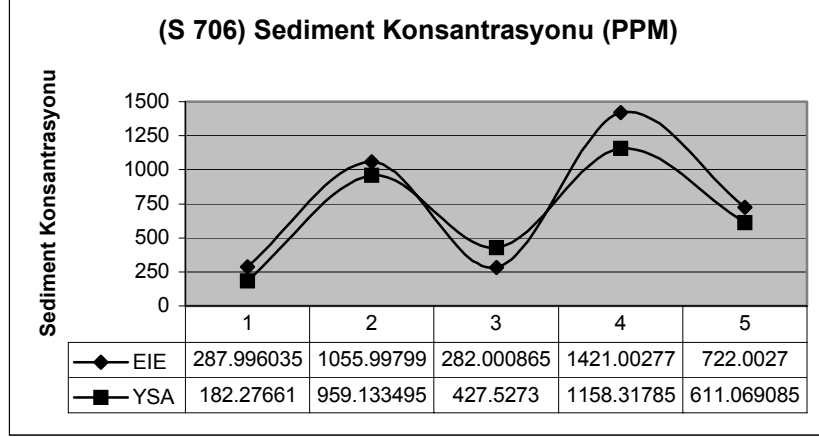
4.3. Sinir Ağının Denenmesi

Yapay sinir ağlarının eğitiminde istenen hata sınırına ulaşıldıktan sonra Yapay Sinir Ağlarının test edilmesi işlemine geçildi. Bu test işlemine daha önceden hiç denenmemiş numuneler kullanılmıştır. Verilerin alındığı gözlem istasyonunda 90 adet veri grubundan 85 adeti eğitim için kullanılmış geri kalan 5 adet veri grubu test aşamasında kullanılmıştır.

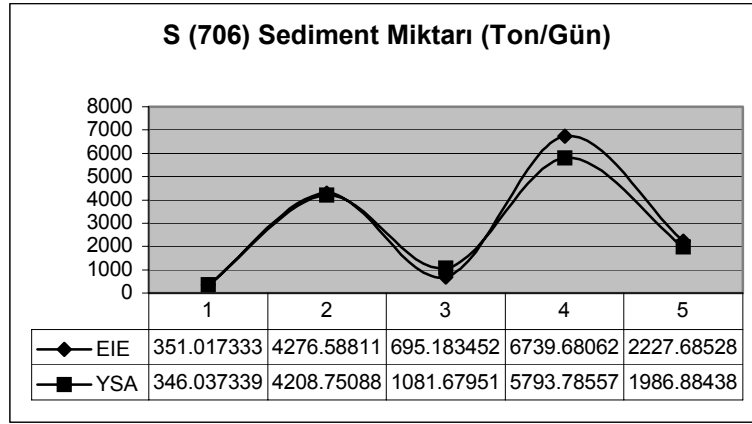
Eğitim aşamasında elde mevcut olan veri sayısının azlığı ve veriler arasında salınımların fazla olmasından dolayı yapay sinir ağlarının ürettiği sonuçlar ile EİE ölçümleri arasında farklılıklar çıkmaktadır. Ancak aralarında fazla salınım olmayan veri grupları kullanıldığı zaman daha iyi sonuçlar elde edilecektir. Yapılan bu çalışmada eğitimden sonra Yapay Sinir Ağlarının test sonuçları aşağıdaki tabloda verilmiştir.

Tablo.4.1 EİE ile YSA sonuçlarının karşılaştırılması

Debi (m ³ /s)	EİE ölçümleri		Yapay Sinir Ağ Çıktıları		Aradaki Fark	
	Sediment Kons.	Taşınan Sediment Miktarı (Ton /gün)	Sediment Konsantrasyonu	Taşınan Sediment Miktarı	Sediment kon. Farkı (%)	Taşınan Sediment Farkı (%)
14,102	288	351	182,276	346,04	0,36	0,014
16,100	1055	4276,58	959,133	4208,75	0,091	0,015
38,668	282	695,18	427,52	1081,68	0,51	0,55
54,895	1421	6739,7	1158,32	5793,68	0,18	0,14
35,711	722	2227,7	611,04	1986,88	0,15	0,10
			Ortalama Hata		0,26	0,16




Şekil 8. Sediment konsantrasyonu için YSA ve EIE sonuçlarının karşılaştırılması



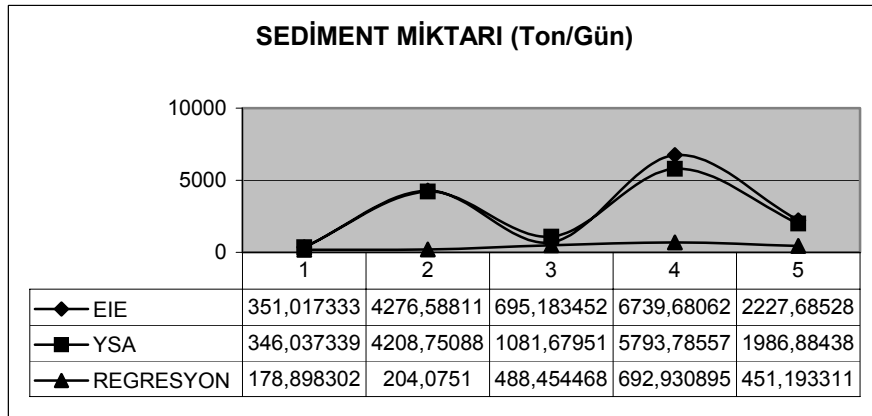
Şekil 9. Sediment miktarı için YSA ve EIE sonuçlarının karşılaştırılması

Burada yapay sinir ağları ile EIE karşılaştırılmalı sonuçlarından da görüldüğü gibi yapay sinir ağları, EIE ölçüm sonuçlarına oldukça yakın sonuçlar vermiştir. Ayrıca regresyon analizi yapılarak her üç sonucun grafiği aşağıdaki gibi verilmiştir.

Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi



Şekil 10. Sediment miktarı için YSA , EIE ve REGRESYON ANALİZİ sonuçlarının karşılaştırılması



Şekil 11. Sediment Konsantrasyonu için YSA , EIE ve REGRESYON ANALİZİ sonuçlarının karşılaştırılması

5. SONUÇ VE TARTIŞMA

Akarsuların taşımış olduğu askı maddesi miktarı, akarsuyun taban eğimine, topografyasına, akarsuyun debisine, zamana ve bölgenin iklim şartlarına bağlı olarak değişir. Ayrıca akarsu üzerinde yapılacak olan yapıların da askı maddesi taşınımına etkisi vardır. Taşınan bu katı maddeler gerek bu akarsu üzerinde yapılacak olan su yapılarına gerekse sulama sırasında taşındığı araziye verimsizleştirmektedir. Bu nedenle taşınan katı madde miktarının bilinmesi oldukça önem taşımaktadır. Ayrıca bir akarsu üzerine yapılacak bir barajın tasarımında taşınacak olan katı madde miktarı iyi bir şekilde hesaplanmalıdır. Ancak askı maddesi miktarı, zamanla değişen çok sayıda parametreye bağlı olduğu için formüllerle ifade edilmesi oldukça güçtür. Bu durumda devreye yapay sinir ağları girmektedir. Yapay sinir ağları belirli bir problemi çözmek için örnekleri kullandığı için fazla bir bilgiye ihtiyaç duymaz.

Yapılan bu çalışmada sadece akarsu debisi göz önüne alınarak askı maddesi konsantrasyonu ve askı maddesi miktarı yapay sinir ağları ile hesaplanmış ve kullanılan veri grupları arasında oldukça fazla farklılıklar olmasına rağmen iyi bir sonuç elde edilmiştir. Yapay sinir ağları ile çözüm yaparken veri grupları kullanılan aktivasyon fonksiyonunun tipine göre normalize edilerek eğitim aşamasına geçilmiştir. Eğitim sırasında en uygun sonucu elde edene kadar ağın mimarisi, öğrenme derecesi ve momentum katsayısı deneme yanılma yoluyla bulunmuştur. Ayrıca eğitim sırasında öğrenme derecesini küçük seçtiğimizde ağın yavaş öğrendiği fakat daha iyi sonuçlar elde edildiği görülmüştür. Eğitim tamamlandıktan sonra daha önceden eğitim sırasında kullanılmayan veri grupları ile test işlemine geçilmiştir. Test işlemlerinin EIE ile karşılaştırmalı sonuçları bir önceki bölümde verilmiştir. Grafiklerden de görüleceği gibi veri grupları arasında fazla salınım olmasına rağmen iyi sonuçlar elde edilmiştir. Ayrıca yapılan regresyon analizi sonuçlarından da görüldüğü gibi yapay sinir ağları regresyon analizine göre daha iyi sonuçlar vermiştir.

Yapay sinir ağları hesaplamalara tamamen farklı bir yaklaşım getirmektedir. Yani belirli bir problemi çözmek için programlama yerine direkt olarak mevcut örnekleri kullanır ve ne kadar fazla örnekle eğitilirse problemin çözümündeki teşhisi o kadar doğru olur. İnşaat mühendisliği alanında yapay sinir ağlarının bir çok uygulama alanı olmasına rağmen maalesef şu ana kadar fazla bir çalışma yapılmamıştır. Ancak yapay sinir ağları kullanılarak inşaat mühendisliği alanında bir çok çalışma yapılabilir.

Kaynaklar

- [1] Arslan, A., İnce, R., Yapı Mühendisliğinde Yapay Sinir Ağları ve Uygulama Potansiyeli, İnşaat Mühendisliğinde Bilgisayar Kullanımı IV Sempozyumu, İ.T.Ü. İnşaat Fakültesi, 219-228, İstanbul, 1994
- [2] Arslan, A., İnce, R., The Neural Network Based Design of Edge Supported Reinforced Concrete Slabs, Artificial Intelligence and Object Oriented Approaches For Structural Engineering, 91-97, Scotland, 1994
- [3] Arslan, A., İnce, R., Geriye Yayılma Sinir Ağı Kullanılarak Betonarme Kolonların Tasarımı, Tr. Journal of Engineering and Environmental Sciences, Vol 19, 127-135, 1995
- [4] Arslan, A., İnce, R., The Neural Network Approximation to The Size Effect in Fracture of Cementitious Materials, Engineering Fracture Mechanics, Vol 54, No 2, 249-261, 1996
- [5] Baylar, A., Emiroğlu, M.E., Arslan, A., Beton Ağırlık Barajların Statik ve Dinamik Karakteristiklerinin Yapay Sinir Ağları ile Belirlenmesi, DSİ Teknik Bülteni, Sayı 90, 35-49, Ankara, 1998
- [6] Baylar, A., Emiroğlu, M.E., Arslan, A., Geriye Yayılma Yapay Sinir Ağı Kullanılarak Yanal Su Alma Yapısına Yönelecek Olan Sürüntü Maddesi Oranının Bulunması, DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi, Cilt. 1, Sayı 2, 1-11, 1999
- [7] Baylar, A., Kaya, N., Emiroğlu, M. E., Akarsu Debisi ile Askı Maddesi Miktarı Arasındaki İlişkinin Yapay Sinir Ağlarıyla Belirlenmesi, Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, Sayı 11 (2), 105-116, 1999
- [8] Bayazıt, M., Hareketli Tabanlı Akımların Hidroliği, İTÜ İnşaat Fakültesi Matbaası, İstanbul, 1971

- [9] Bressloff, P. C., Weir, D. J., Neural Networks, Gec Journal of Research, Vol 8, No 3, 151-169, 1991
- [10] Bulşen, A., Hava Kirliliđi Parametrelerinin Yapay Sinir Ağları ile Geleceđe dönük Tahminleri, Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimler Enstitüsü, Yüksek Lisans Tezi, 1998
- [11] Chen, H. M., Qi, G. Z., Yang, J. C. S., Amini, F., Neural Network for Structural Dynamic Model İdentification , Journal of Engineerin Mechanics, 1377-1381, 1995
- [12] Civalek, Ö., Dairesel Plakların Nöro-Fuzzy Tekniđi ile Analizi, DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi, Cilt. 1, Sayı 2, 13-31, 1999
- [13] Dađlı, C.H., Artificial Neural Networks for İntelligent Manufacturing, Yöneylem Araştırma Dergisi, 6, 1-25, Türkiye, 1994
- [14] Demir, Y.K., Yapay Sinir Ağları ile Ulaştırma Taleplerinin Modellenmesi, İTÜ Fen Bilimleri Enstitüsü, Yüksek Lisans tezi, İstanbul, 1997
- [15] Efe, M., Kaynak, O., Yapay Sinir Ağları ve Uygulamaları (1. Basım), Boğaziçi Üniversitesi, 148 s, İstanbul, 2000
- [16] Güngör, M., Akarsularda Katı Madde Taşınımı, Pamukkale Üniversitesi Mühendislik Fakültesi, Erozyonla Mücadele Haftası, Toprak Erozyonu ve Denetimi Etkinlikleri Programı, 21-25 Kasım 1994, Denizli .
- [17] Güngör, M., Akarsu Kıvrımlarına Yerleştiren Köprü Kenar Ayakları Etrafında Meydana Gelen Yerel Oyulma Derinliđinin Araştırılması, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, İstanbul, 1997
- [18] Güngör, M., Üç, S., Doğrusal Eksenli Akarsularda Yerel Oyulma Derinliđi İle Köprü Ayađı Genişliđinin İlişkisi, Harran Üniversitesi Mühendislik Fakültesi, Gap 2. Mühendislik Kongresi, 21-23 Mayıs 1998, Urfa.
- [19] Haque, M. E., Sudhakar, K.V., Artificial Neural Networks Back Propagation Prediction Model for Fracture Toughness in Microally Steel, İnternational Journal of Fatigue, Vol 24, 1003-1010, 2002
- [20] Hong, N.K., Chang, S.P., Lee, S.C., Development of Artificial Neural Networks Based Preliminary Structural Design Systems for Cable Stayed Bridges, Advances in Engineering, Vol 33, 85-96, 2002
- [21] Jang, J.S. R., Sun, C.T., Mizutani, E., Neuro-Fuzzy and Soft Computing, Prentice Hall, ISBN 0-13-261066-3, 607 s, United States of America, 1997
- [22] Kang, H. T., Yoon, C.J., Neural Network Approaches to Aid Simple Truss Design Problems, Microcomputers in Civil Engineering, Vol 9, 211-218, 1994
- [23] Murat, Y.Ş., Prediction of Traffic Volumes in Bosphorus Bridge wing Artificial Neural Network, Proceedings of the 11th Mini-EURO conference on Artificial Intelligence in Transportation System and Science and 7th EURO-working Group meeting on Transportation, Helsinki University of Technology, Espoo, Finland, paper no XLIII, August 2-6, 1999
- [24] Serhadlıođlu, G., Yapay Sinir Ağlarının Teknik Analizinde Kullanımı ve Bir Uygulama, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 1998
- [25] Ünalđı, N., Yapay Sinir Ağları ve Uygulamaları, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 1993
- [26] Yun, C.B., Yi, J.H., Bahng, E.Y., Joint Damage Assessment of Framed Structures Using A Neural Network Technique, Engineering Structures, Vol 23, 425-435, 2001.