

Esnek üstyapılarda mekanik özelliklerin yapay sinir ağları kullanılarak geri-hesaplanması

Ahmet Burak GÖKTEPE, Emine AĞAR, Abdullah Hilmi LAV*

İTÜ İnşaat Fakültesi, İnşaat Mühendisliği Bölümü, 34469, Ayazağa, İstanbul

Özet

Esnek üstyapıların performans değerlendirmesi için, genel olarak tahribatsız deney metotları tercih edilmektedir. Tahribatsız deney metotları içerisinde en çok tercih edilen, Düşen Ağırlık Deflektometresi (FWD) yöntemidir. Bu yöntem ile, yol üzerindeki çok sayıda yerde, uygulanan yük sebebi ile meydana gelen zamana bağlı defleksiyon değerleri kaydedilir. Uygulamada, FWD deneyi ile elde edilen defleksiyon değerleri ve geri-hesaplama programları kullanılarak, üstyapı tabakalarına ait mekanik özellikler hesaplanır. Fakat, bu programlar, parametre tanımlama algoritmaları kullanmakta ve bu da zaman kaybına neden olmaktadır. Bu çalışmada, FWD testinden elde edilen defleksiyonları kullanarak, esnek üstyapı tabakalarındaki mekanik özellikleri yapay sinir ağları ile geri-hesaplayan bir model geliştirilmiştir. Sonuçlar, modelin hassasiyetinin son derece yüksek olduğunu ve gerçek-zamanlı geri-hesaplama yapılabilmeyle olanak sağladığını göstermiştir.

Anahtar Kelimeler: *Düşen Ağırlık Deflektometresi, geri-hesaplama, yapay sinir ağları*

Backcalculation of mechanical properties of flexible pavements using neural networks

Abstract

Performance evaluation of flexible pavements is usually performed using nondestructive testing methods. Basic advantage of nondestructive testing methods is that it's possible to obtain pavement performance data by these methods without resulting any damage to the pavement system. Of all nondestructive testing methods, Falling Weight Deflectometer (FWD) is the most popular technique. Falling Weight Deflectometer, measures time-domain deflections from numerous road sections emerging by the applied impulse load. The common way for the evaluation of FWD results is to backcalculate the mechanical properties with the help of backcalculation software. However, these software utilize parameter identification routines, which are quite time consuming and computationally expensive. Under the way of this, in this study, a neural network model was developed to backcalculate mechanical properties of flexible pavement layers in order to shorten the processing time. For the development of optimal neural network model, the effects of network's architecture and learning parameters were comprehensively examined. The results indicated that, both network's architecture and learning parameters significantly affect the neural network's performance. Consequently, the accuracy of developed neural network model is successful and the model enables real-time backcalculation opportunity that is crucial for highway engineers working on pavement evaluation studies and developing pavement maintenance strategies.

Keywords: *Falling Weight Deflectometer, backcalculation, neural networks.*

*Yazışmaların yapılacağı yazar: Abdullah Hilmi LAV. lav@itu.edu.tr; Tel: (212) 285 65 35.

Bu makale, birinci yazar tarafından İTÜ İnşaat Fakültesi'nde tamamlanmış olan "Backcalculation of mechanical properties of flexible pavements using neural networks" adlı doktora tezinden hazırlanmıştır. Makale metni 22.03.2004 tarihinde dergiye ulaşılmış, 13.05.2004 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.08.2005 tarihine kadar dergiye gönderilmelidir.

Giriş

Esnek yol üstyapılarının performans değerlendirilmesi, genel olarak iki amaç için yapılmaktadır. Bunlardan birincisi, mevcut üst yapının fiziki durumu hakkında bilgi vermektir. Böylelikle, uygun bakım ve onarım programı seçilir. İkincisi, inşaatı yeni tamamlanmış bir üst yapının kontrolünü gerçekleştirmektir. Bu yapısal kontrol için, üstyapıya zarar vermemesi ve kolay uygulanabilirliği nedeni ile, tahribatsız deney metotları (NDT) yaygın olarak tercih edilmektedir. Tahribatsız deney metotları içerisinde en çok kullanılanı, Düşen Ağırlık Deflektometresi (FWD) yöntemidir. Bu yöntem ile, üst yapının bir çok bölgesinde, uygulanan yükler sebebi ile oluşan zamana bağlı defleksiyon değerleri ölçülmektedir. Uygulamada, FWD testinden elde edilen defleksiyon değerleri, geri-hesaplama programları yardımı ile, üstyapı tabakalarına ait mekanik özelliklerin (elastisite modülü ve Poisson oranı) belirlenmesi için kullanılır. Fakat, bu programlar, parametre tanımlama algoritmaları kullanarak optimizasyon yapmaktadır ve bu da, işlemsel zorluğa ve zaman kaybına neden olmaktadır.

Diğer yandan, yapay zekanın popüler bir dalı olan yapay sinir ağları, son derece karmaşık ve doğrusal olmayan davranışları kolay bir şekilde öğrenebilmekte ve öğrenme işlemi tamamlandıktan sonra, fonksiyonel bir yaklaşım gibi sonuca gerçek-zamanlı olarak ulaşılabilir. (Fu, 1994; Bose ve Liang, 1996; Haykin, 1999; Principe vd., 2000; Kecman, 2001).

Bu çalışmada, FWD testinden elde edilen defleksiyon değerlerini kullanarak, yol tabakalarındaki mekanik özellikleri yapay sinir ağları yardımı ile geri-hesaplayabilen bir model geliştirilmiştir. Elde edilen sonuçlar, modelin hassasiyetinin yüksek olduğunu ve modelin gerçek-zamanlı geri-hesaplama yapılabilmesine olanak sağladığını göstermiştir. Bu imkan, karar verici durumunda olan üstyapı mühendislerine önemli bir zaman avantajı kazandıracak ve ciddi bir hesap kolaylığı sağlayacaktır.

Tahribatsız deney metotları ve Düşen Ağırlık Deflektometresi

Karayolu mühendisleri, mevcut bir yolun üst yapısı ile ilgili yapısal analiz yaparken iki temel soruya cevap ararlar:

- Üstyapı, beklenen trafik yükleri altında ne kadar bir süre daha hizmet verebilecektir?
- Bu üstyapı için en uygun bakım-onarım ve yeniden inşaat stratejileri nelerdir?


Bu soruların cevabı, malzeme özellikleri, mekanik modelleme, istatistiksel değerlendirme ve ekonomik analizin birbirleri ile etkileşim içerisinde olduğu bir optimizasyon problemidir. Bunun için, ilk aşamada, üstyapı tabakalarına ait temel özellikler, mekanik bir model yardımı ile belirlenir ve kaplamanın maruz kalacağı yükleme koşulları öngörülür. Sonra, ekonomik kriterler de dikkate alınarak optimum çözüme ulaşılır. Bu süreçte, en önemli noktalardan birisi temel mekanik özelliklerin belirlenmesidir. Tahribatsız deney (NDT) metotları, mekanik özelliklerin belirlenmesinde en çok tercih edilen yöntemdir. Çünkü, bu yöntemde, üst yapıya herhangi bir fiziksel zarar verilmez ve sonuçlar hızlı bir şekilde elde edilir.

NDT metotları kullanılarak, yol üst yapısını oluşturan tabakalara ait malzeme özellikleri, düşük şekil değiştirme seviyelerinde ölçülebilir. NDT yöntemlerinde kullanılan temel prensip, belirli bir yükleme altında, kaplama yüzeyinde meydana gelen defleksiyon değerleri ile kaplama sisteminin yapısal dayanımının ters orantılı olduğudur. Bu kurala tek istisna, Yüzey Dalgalarının Spektral Analizi (SASW) yöntemidir. SASW yönteminde, tabakalara ait kayma modüllerini bulmak için, Rayleigh dalgalarının hızlarından yararlanılır (Nazarian ve Stoke, 1989).

Defleksiyon esaslı NDT metotları arasındaki temel fark, uygulanan yüklemenin özellikleri ve oluşan defleksiyonların ölçüm yerleridir. Genel olarak, statik, dinamik sürekli ve dinamik geçici (süreksiz) yüklemeler uygulanmaktadır. Statik yükleme ile çalışan cihazlara örnek olarak, Bankelman kirişi ve La Croix deflektometresi

verilebilir. Sürekli dinamik durumda, yükleme sıfırdan başlar, maksimum değere çıkar ve tekrar sıfır değerine düşer. Bu, kaplamanın üzerinden geçen bir aracın yaptığı etkiye benzer ve yüklemenin periyodu geçen aracın hızına bağlıdır. Bu tür deney metodlarına, “Dynalect”, “Road Rater” ve WES vibratörü örnek verilebilir. Son olarak, dinamik geçici yüklemelerde, kaplama yüzeyine bir darbe yükü uygulanır ve yükün uygulama yerinden farklı uzaklıktaki ve bir eksen üzerinde bulunan noktadaki defleksiyon değerleri zamana bağlı olarak kayıt edilir. Kayıt edilen defleksiyon değerlerinin maksimumları seçilerek defleksiyon çanağı (eğrisi) elde edilir. Düşen ağırlık deflektometresi (FWD) yönteminde bu prensip kullanılır.

NDT metotları arasında en çok tercih edileni, Düşen Ağırlık Deflektometresi (FWD)’dir. Geçici yükleme esasına göre çalışan FWD deneyinde, belirli bir ağırlık, uygulanmak istenilen etki seviyesine göre belirli bir yükseklikten kaplama yüzeyine düşürülür. Yükleme (6.7 kN ile 156 kN arasında), dairesel bir plaka ile yapılır ve kaplama yüzeyi ile plaka arasında lastik bir conta bulunur (ani darbe etkisinin azaltılması için). Yüklemenin yapıldığı yerden belirli uzaklıklardaki defleksiyonlar, bir kiriş üzerinde bulunan jeofonlar (genellikle yedi adet) yardımı ile ölçülür. Yükleme belirli bir frekansta ve zaman aralığında yapılır. Yükleme, sinüzoidal bir biçimde uygulanır ve frekansı 0.025sn^{-1} ile 0.030sn^{-1} arasında değişir (Stolle, 1991). Şekil 1’de tipik bir FWD defleksiyon kaydı ve defleksiyon çanağı görülmektedir.



Şekil 1. Tipik bir FWD defleksiyon grafiği

Statik yükleme yöntemleri, trafik yüklerini doğru olarak benzeştiremediği için, dinamik yükleme yöntemlerine alternatif değildir ve daha başarısız

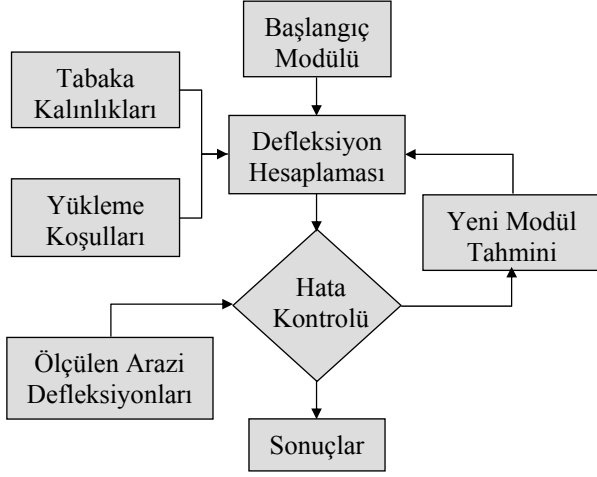
sonuçlar vermektedir. Dinamik yüklemeler arasında, geçici dinamik yükleme (FWD yöntemi), sürekli dinamik yükleme yöntemine göre çoğunlukla tercih edilir ve aşağıdaki avantajlara sahiptir:

- Statik bir ön-yüklemeye ihtiyaç duymazlar ve yüklemeler daha düşük ağırlıklar ile yapılır. Sonuç olarak, yüksek ağırlıklı trafik yükleri, küçük ağırlıklar uygulanarak benzeştirilebilir (Hoffman ve Thompson, 1982; Meier, 1995).
- FWD tarafından uygulanan darbe etkisi, yük uygulama süreleri çok farklı olsa bile, standart dingil yüklerinin oluşturduğu etkiye son derece yakındır ve diğer NDT yöntemlerinden daha başarılı sonuçlar vermektedir (Hoffman ve Thompson, 1982; Tholen vd., 1985; Sebaaly vd., 1985; Bentsen, 1989; Zhou, 2000; Tawfiq, vd., 2000).
- FWD yöntemi ile, gerçek zamanlı ve diğer yöntemlere göre daha fazla veri elde etmek mümkündür (Meier, 1995).

Esnek üst yapılarda geri-hesaplama

Geri-hesaplama problemleri, aynı zamanda *parametre tanımlama problemleri* olarak da bilinirler ve bir çok mühendislik probleminin çözümünde kullanılırlar. Temel olarak, bilinen bir ilişkinin, ters yönlü olarak ifade edilmesi işlemidir. Geri-hesaplama problemi, aynı zamanda, bir optimizasyon problemidir ve bilinen giriş-çıkış değerlerine ait en uygun model parametrelerinin belirlenmesini amaçlar.

Yol üst yapıları için kullanılan geri-hesaplama işlemi ise, deflektometreler tarafından ölçülen kaplama yüzey defleksiyonlarının mekanik analizidir. Geri-hesaplama yapılırken, arazide ölçülen defleksiyon değerleri, tahmini tabaka boyutlarını ve özelliklerini kullanan bir üst yapı analiz programı ile elde edilen defleksiyon değerleri ile iteratif olarak eşitlenmeye çalışılır. Sonuçta, elde edilen rijitliklerin (modüllerin), arazideki üst yapı tabakalarına ait rijitlikler olduğu kabul edilir (Lytton, 1989). Bu işleme ait akış diyagramı, Şekil 2’de verilmektedir:

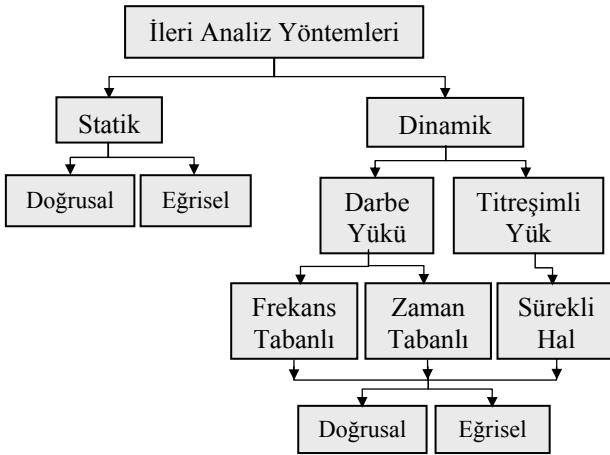


Şekil 2. Klasik geri-hesaplama akış diyagramı

Geri-hesaplama işlemi, iki kısımdan oluşur:

- İleri analiz (defleksiyon hesaplaması)
- Hata düzeltme algoritması (hata hesaplaması ve yeni modül tahmini)

Geri-hesaplamanın başarısı için, ileri hesaplama modelinin doğru sonuçlar üretebilmesi çok önemlidir. Çünkü, hata değeri ne kadar az olursa olsun, sistemin performansı, kullanılan giriş-çıkış değerlerinin doğruluğuna bağlıdır. İleri yönlü kaplama performans analizinde kullanılan tüm modeller Şekil 3'te verilmektedir (Lytton, 1989; Uzan, 1994).



Şekil 3. İleri analiz yöntemleri

İleri hesaplama yöntemleri, genel olarak, statik ve dinamik olarak ikiye ayrılır. Statik analizlerde, yükleme zamandan bağımsızdır ve malzemelerin

viskoelastik özellikleri ihmal edilir. Ayrıca, statik analizlerde, en alttaki tabaka yarı-sonsuz kabul edilir ve hesaplamalar tabakalı elastik teori yöntemine göre yapılır. Halbuki, bu durum, taban zemini tabakasının, 15.00m-20.00m kalınlığından daha az olması halinde geçerlidir. Eğer, bu tabakanın kalınlığı daha fazla ise, hesaplanan defleksiyonlardaki hata miktarı %20 seviyelerine ulaşabilir (Roesset ve Shao, 1985; Chang, vd., 1992). Dinamik analizlerde ise, bu olumsuz etki söz konusu değildir ve daha gerçekçi sonuçlar elde etmek mümkündür. Ancak, dinamik analizler, Green fonksiyonu çözümü, Fourier dönüşümleri ve dinamik sonlu elemanlar gibi hesap yöntemlerinin kullanılmasını gerektirir ve bu nedenle büyük zaman ve işlem ihtiyacı doğar.

Diğer yandan, her iki (statik ve dinamik) analiz yönteminde de, malzeme gerilme-şekil değiştirme özellikleri, doğrusal veya eğrisel olarak hesaba katılabilir. Doğrusal olmayan kabul, gerek asfalt, gerekse granüler malzemelerin gerçek davranışlarına yakın modelleyebildiği için, daha hassas sonuçlar verebilir (Uzan ve Scullion, 1990; Uzan, 1994). Ancak bu yöntem, analizlerdeki hesap yükünü ve karmaşıklığı son derece arttırmaktadır.

Sonuç olarak, dinamik etkiler ve doğrusal olmayan malzeme davranışları daha gerçekçi sonuç verebilmesine rağmen, gerekli verilerin elde edilmesindeki, uygun modellerin kurulmasındaki ve hesaplamalardaki zorluklar gözönüne alındığında, statik doğrusal analizler genellikle tercih edilmektedir.

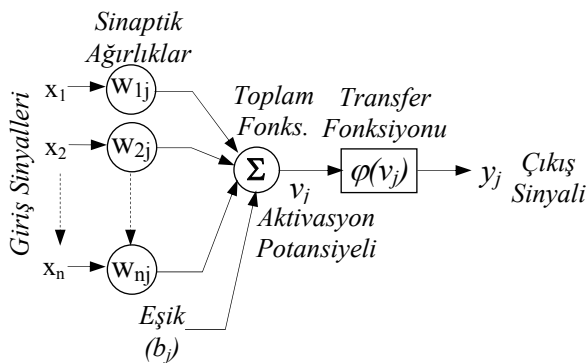
Yapay sinir ağları

Yapay sinir ağları (YSA), insan beynindeki nöronların meydana getirdiği ve öğrenme işlemini gerçekleştiren paralel ağ yapısını taklit ederek, bu sisteme benzeyen zeki programlar tasarlamayı hedefleyen bir yöntemdir. YSA yöntemi, modelleme, simülasyon, öğrenme, tanımlama ve tahmin yapma gibi bir çok uygulama alanında başarı ile kullanılmaktadır.

Bir nöron (sinir hücresi), *dendrit* ve *akson* ismi verilen iki ana kısımdan oluşur. Dendrit, bir

nöron ile diğerinin bağlantısını gerçekleştiren kısımdır ve farklı nöronların dendritlerini birbirlerine bağlayan bölgelere *sinaps* denir. Nöronlar arası elektriksel ve kimyasal sinyal iletimi, bu bağlantı bölgelerinden sinyal geçişleri ile gerçekleşir. Aksonlar ise, dal şeklindeki uzun geçiş yapılarıdır. İşleyiş olarak, bir nöronun sinapslar üzerinden aldığı toplam ileti, bir eşik değerinden yüksek ise, nöron, bu toplam iletiyi akson boyunca diğer ucuna iletir ve buradaki diğer sinaps yardımı ile başka bir nörona aktarır. Sinapslar, artırıcı veya azaltıcı etkili olabilir. Arttırıcı etkili sinapslar, diğer nörondan alınan toplam iletileri büyütür; diğer yandan, azaltıcı etkili sinapslar gelen iletiler toplamını küçültür. Özetle, bir nöron, bir dizi giriş sinyali alır ve bu sinyalleri işleyerek (arttırarak veya azaltarak) çıkış sinyali olarak diğer bir nörona iletir. Beyin içerisinde, birbirine *paralel olarak* bağlı ve yukarıda anlatılan mekanizmaya benzer bir sistem ile çalışan yaklaşık 100 milyar nöron bulunmaktadır (Ross, 1995; Kecman, 2001; Sagiroglu vd., 2003).

Yukarıda kısaca anlatılan sinirsel yapıyı örnek alan yapay nöron ise, dendrit yerine toplama fonksiyonu, hücre gövdesi yerine transfer fonksiyonu ve sinapslar yerine ağırlıklar kullanılmaktadır. Kısaca, *yapay bir nöron*, ağırlıklar, toplama fonksiyonu ve transfer fonksiyonundan oluşmaktadır. Şekil 4'te yapay bir nöron yapısı verilmektedir (Haykin, 1999).



Şekil 4. Yapay nöron modeli

Yapay nöron, diğer nöronlardan gelen iletileri (ağırlıklar ile giriş sinyallerinin çarpımı) toplar, bir eşik değeri ile karşılaştırarak aktivasyon

potansiyelini hesaplar ve bu potansiyeli transfer fonksiyonundan geçirerek çıkış sinyali üretir. Bunun fonksiyonel ifadesi ise aşağıdaki gibidir:

$$y_k = F(v_j) = F\left(\sum_{i=1}^n x_i w_{ij} - b_j\right) \quad (1)$$


burada, x_i giriş sinyalini, w_{ij} sinaptik ağırlığı, b_j kutuplama değerini (eşik değerinin negatif işaretlisi), v_j aktivasyon potansiyelini, y_k çıkış sinyalini, n önceki katmandaki (giriş sinyali gönderen) nöron sayısını ve k ise işlem yapılan nöronun kaçınıcı nöron olduğunu belirtmektedir.

Sinaptik ağırlıkların pozitif olması artırıcı etkiyi, negatif olması ise azaltıcı etkiyi ifade eder. Eşik değeri ise, toplanan iletilerin bir seviye ile karşılaştırılmasını ve eğer bu seviyeden büyük ise pozitif, küçük ise negatif aktivasyon potansiyeli gönderilmesini sağlamaktadır. Son olarak, transfer (aktivasyon) fonksiyonu, aktivasyon potansiyelini normalize etmekte ve istenilen aralığa ($[0,1]$ veya $[-1,1]$) göre ölçeklemektedir. Diğer bir deyişle, transfer fonksiyonu, nöronun çıkış genliğini istenilen değerler arasında sınırlar ve nöronların oluşturduğu sinir ağının yakınsamasını sağlar. Yaygın olarak, *doğrusal*, *basamak*, *sigmoid* ve *hiperbolik tanjant* transfer fonksiyonları kullanılmaktadır (Demuth ve Beale, 2000).

Yapay sinir ağları ise, çok sayıda nöronun birbirleri ile paralel olarak bağlanması ile oluşan yapılardır. Öğrenilmesi istenilen hedef değerlerine yakınsamak için, bağlantıların ve kutuplama değerlerinin nasıl bir yöntem ile değiştirileceği, öğrenme algoritması tarafından belirlenir. Diğer yandan, yapay sinir ağları yapıları, genel olarak iki türlüdür: *ileri beslemeli* ve *geri beslemeli*. İleri beslemeli ağlarda, nöronlar ara katmanlara ayrılır ve iletiler, bir katmandaki nöronlardan, bir sonraki katmandaki nöronlara doğru yapılır. Aynı katmandaki nöronlar arası bağlantı bulunmaz. Bu tür ağların en popüler olanı, çok katmanlı perseptronlardır (MLP). Geri beslemeli ağlarda ise, iletiler hem ileri hem de geri yönlü olabilir ve nöronların çıkış sinyalleri, kendi giriş birimlerini veya önceki katmanları geri-besleyebilirler. Böylece, bir

çıkış sinyali, hem o anki girişleri hem de önceki girişleri dinamik bir şekilde yansıtılabilmektedir. Bu tür ağlara, Hopfield ağları örnek verilebilir (Haykin, 1999; Principe vd., 2000; Sagiroglu vd., 2003).

Çok katmanlı perseptronlar (MLP), yapay sinir ağlarının en çok kullanılan türüdür ve giriş katmanı, ara katman(lar) ve çıkış katmanından oluşur. Her katmanda, bir veya daha fazla nöron vardır ve her katmandaki nöronlar, diğer katmandaki nöronlara paralel bağlıdır (Şekil 5).



Şekil 5. Çok katmanlı perseptron (MLP)

MLP'daki sinyal (bilgi) akışı ileri yönlüdür ve ilk olarak, çıkış katmanına gelen değerler ile hedeflenen değerler arasındaki farklılık (hata miktarı) hesaplanır. Bunu takiben, bulunan hata miktarı geri doğru yayılarak (ağırlıklar ve kutuplanma değerleri değiştirilerek) giriş katmanına ulaşılır. Daha sonra, MLP, yeni ağırlıklar ile tekrar ileri beslemeli olarak sinyalleri iletir ve yeni hata miktarını hesaplar. Bu ileri besleme ve geri yayılma işlemi, çıkış katmanındaki hata miktarı belirli bir limit değerinin altında kalana kadar devam eder. Geri yayılma sırasında serbest değişkenlerin değişimi, öğrenme algoritmasına bağlıdır.

MLP öğrenme algoritmaları içinde en popüler olanı, geri-yayılım algoritmasıdır (Rumelhart ve McClelland, 1986). Bu algoritma, *Widrow-Hoff (delta) öğrenme kuralını* kullanır ve azalan hata eğimi (gradyanı) optimizasyon tekniğini uygular (Widrow ve Hoff, 1960). Geri-yayılım algoritmasında, hata enerjisi, *en küçük kareler* yöntemi ile hesaplanır ve çıkış katmanındaki nöronların hepsine ait genel bir hata değerini ifade eder.

Genel olarak, bu işlem bir minimizasyon problemidir ve ağırlıklardaki $[\Delta w_{ji}(n)]$ iteratif düzeltmeler, hata enerjisinin miktarı ile orantılıdır. Geri-yayılım algoritmasında, ağırlık değişimi (düzeltmesi) aşağıdaki formül kullanılarak hesaplanır:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (2)$$

burada, Δw_{ji} ağırlık düzeltmesini, η öğrenme katsayısını, δ_j bir nörona ait yerel hata eğimini (gradyanı), y_i çıkış sinyalini ve n işlem yapılan nöronu ifade etmektedir. Bu formüldeki yerel gradyan (δ_j), çıkış katmanı için:

$$\delta_j(n) = [t_j(n) - y_j(n)] \varphi_j'[v_j(n)] \quad (3)$$

formülü ile hesaplanır. Burada, t_j hedef vektörünü tanımlamaktadır. Diğer yandan, ara katmanlar için yerel gradyan:

$$\delta_j(n) = \varphi_j'[v_j(n)] \sum_k \delta_k(n) w_{kj}(n) \quad (4)$$

bağıntısı ile bulunur. Burada, k bir ilerideki katmanın numarasını ifade etmektedir.

Bu algoritmada, ağırlık uzayındaki gradyan azalınının yönü çok önemlidir ve ağırlıklar, düzeltmelerin yapıldığı *en hızlı azalma yönü* ile orantılıdır. Temelde, hata enerjisini, ağırlık değerlerini değiştirerek minimize edecek bir yön (azalan gradyan) belirlenmesi esasına dayanır (Rumelhart ve McClelland, 1986).

Bu algoritmada, öğrenme katsayısının (η) seçimi de oldukça önemlidir ve değeri $[0,1]$ aralığında değişir. Eğer, η çok küçük ise, ağırlık düzeltmelerinin yapıldığı yakınsama doğrultusu eğriseldir ve karmaşık bir davranışın modellenmesine daha uygundur. Bunu tersine, η büyük ise, yakınsama doğrultusu çok salınım yapar. Bu sebeple, basit problemler için daha yüksek η katsayıları tercih edilir.

Azalan gradyan öğrenme yöntemi, bazı problemlerde yerel minimum noktalara yakınsayabilir

ve global minimuma ulaşamaz. Bu sorunun çözümü için ise, *momentum katsayısı* mevcut modele eklenmiş ve *genelleştirilmiş delta öğrenme kuralı* (momentum terimli geri-yayımlı algoritması) geliştirilmiştir (Rumelhart ve McClelland, 1986). Momentum katsayısının ilave edilmesi ile, Denklem 2, aşağıdaki şekilde yeniden yazılır:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (5)$$

burada, α momentum katsayısını göstermektedir ve $[0, 1)$ aralığında değerler alabilmektedir. Bu katsayı, yakınsama doğrultusunun aşağı yönlerde daha hızlı ilerlemesini ve global minimuma ulaşılmasını sağlar (Jacobs, 1988).

Yapay sinir ağları ile esnek üstyapılarda geri-hesaplama

Yol üstyapıları için yapay sinir ağları kullanılarak gerçekleştirilen ilk geri-hesaplama örneği yüzey dalgalarının spektral analizi (SASW) yöntemi ile elde edilen sonuçlar kullanılarak yapılmıştır (Meier ve Rix, 1993). Bu çalışmada, Rayleigh dalga hızları kullanarak, kayma dalgası hızlarını ve tabaka kalınlıklarını geri-hesaplayabilen bir ağ tasarlanmıştır.

FWD testi verileri kullanılarak üstyapı mekanik özelliklerinin yapay sinir ağları ile geri-hesaplanması ilk olarak 1994 senesinde gerçekleştirilmiştir (Meier ve Rix, 1994). Bu çalışmada, geliştirilen YSA, lineer elastik analiz ile oluşturulmuş sentetik bir veri tabanı ile eğitilmiştir. Bu çalışmadan bir sene sonra, elastodinamik analiz ile hesaplanmış bir veritabanı kullanılarak aynı model tekrar eğitilmiştir (Meier ve Rix, 1995).

Tutumluer ve Meier (1996), granüler temel tabakası verileri ile eğitilmiş bir YSA modeli önermişlerdir. Ayrıca, YSA'nın deney sonuçlarına benzer değerler için çok başarılı olduğu, fakat, bu aralığın dışındakiler için başarılı olmadığı sonucuna varmışlardır.

Tutumluer ve Seyhan (1998), temel granüler tabakasının kayma modüllerini, üç eksenli deney

verileri kullanarak geri-hesaplayabilen bir sinir ağı geliştirilmiştir.

Kim ve diğerleri (2000), FWD ve laboratuvar deneyleri ile elde ettikleri verileri kullanarak, mekanik özelliklerin geri-hesaplandığı başka bir sinir ağı geliştirilmişlerdir. Bu modelde, ana kayaya mesafe de modül değerleri ile birlikte geri-hesaplanabilmektedir.

Sinir ağları ile farklı bir geri-hesaplama yaklaşımı da, Saltan ve diğerleri (2002) tarafından önerilmiştir. Bu çalışmada, FWD defleksiyonları kullanılarak, kaplama modülleri yerine, tasarımda kullanılacak kaplama kalınlıkları geri-hesaplanmıştır.

Literatürde mevcut olan örneklerin hemen hemen hepsinde *genelleştirilmiş delta öğrenme kuralı* kullanılmıştır ve geri-hesaplama modeli için seçilen ağ yapıları ve öğrenme parametreleri için çok kapsamlı bir analiz gerçekleştirilmemiştir. Fakat, bir YSA'nın performansı, önemli ölçüde ağ mimarisine bağlıdır ve en uygun ağın tasarımı, ağ parametrelerinin de içerildiği kapsamlı bir çalışmaya gerektirir.

Bu çalışmada önerilen YSA ile geri-hesaplama modeli

Bu çalışmada, farklı ağ mimarilerinin ve öğrenme parametrelerinin içerildiği 65 farklı YSA geliştirilmiştir. Sonuçta, ağ mimarisinin ve öğrenme parametrelerinin performans üzerindeki etkisi değerlendirilerek en uygun ağ yapısı önerilmiştir.

Geliştirilen YSA modelleri, FWD defleksiyon değerleri ile tabaka kalınlıklarını giriş verisi olarak almakta ve tabakalara ait elastisite modüllerini çıkış parametresi olarak elde etmektedir. Esasında, Poisson oranı, kaplama tabakalarına ait temel mekanik özelliklerden biridir; fakat, Poisson oranının etkisinin elastisite modülüne oranla çok düşük olması ve belirlenmesindeki güçlükler sebebi ile bir çok analizde sabit alınmaktadır (Lytton, 1989; Uzan, 1994; Kim vd., 2000). Bu sebeple, Poisson oranı her tabaka için sabit (0.35) kabul edilmiştir.

Sentetik veritabanı, lineer elastik teori kullanılarak KENLAYER (Huang, 1993) bilgisayar programı yardımı ile elde edilmiştir. Eğitim veritabanı için 1101 ve deneme veritabanı için 339 sentetik veri kümesi kullanılmıştır. Tablo 1’de, tüm verilere (eğitime ve deneme aşamalarında kullanılacak) ait istatistiksel bilgiler verilmiştir.

Tablo 1. Eğitim verileri istatistikleri

Tabaka	Kalınlık (cm)	Elastisite Modülü (MPa)	Poisson Oranı
Asfalt	5 - 20	1000 - 15000	0.350
Temel	15 - 50	35 - 300	0.350
Taban Zemini	∞	30 - 200	0.350
Ortalama (Asfalt)	12.459	7291	-
Ortalama (Temel)	32.705	162	-
Ortalama (Tb. Zm)	-	114	-
Std Sapma (Asfalt)	5.621	4837	-
Std Sapma (Temel)	11.492	108	-
Std Sapma (Tb. Zm)	-	70	-

Modellerde ağ tipi olarak, ileri beslemeli geri yayımlı çok-katmanlı perseptron, öğrenme algoritması için ise, geliştirilmiş delta öğrenme kuralı seçilmiştir. YSA ile ilgili eğitim ve deneme işlemleri MATLAB paket programı ile gerçekleştirilmiştir. Ayrıca, ağ bağlantıları, *tam bağlı* olarak belirlenmiştir ve enerji fonksiyonu olarak, *hataların karelerinin ortalaması (MSE)* fonksiyonu kullanılmıştır. Bu fonksiyonun ifadesi aşağıdaki gibidir:

$$MSE = \frac{1}{mN} \sum_{k=1}^N \sum_{j=1}^m (y_j^k - t_j^k)^2 \quad (6)$$

burada, m, çıkış katmanındaki nöron sayısını; N, eğitim örnekleri sayısını temsil etmektedir. Bu çalışmada, transfer fonksiyonu olarak “*logistic sigmoid*” fonksiyonu seçilmiştir:

$$y_j(n) = \frac{1}{1 + e^{-v_j(n)}} \quad (7)$$

Modellerde, logistic sigmoid fonksiyonu tercih edildiği için, eğitim ve deneme veri kümeleri [0,1] aralığına normalize edilmiştir. Normalizasyon

yapılmasının sebebi, bu transfer fonksiyonunun [-6, 6] aralığındaki giriş verileri için ayırt edilebilir çıktılar üretebilmesidir. Bu aralığın dışındaki girişler için, eşit çıktılar (0 veya 1) elde edilmektedir ve işlem yapılan nöronun yakınsaması imkansız hale gelmektedir (Demuth ve Beale, 2000; Flood ve Kartam, 1998; Pearl, 1988). Normalizasyon işlemi, aşağıdaki eşitlik ile gerçekleştirilmiştir:

$$X_{yeni} = \frac{X - x_{min}}{x_{maks} - x_{min}} \quad (8)$$

burada, X_{yeni} normalize edilmiş değeri, X ilk değeri, x_{maks} maksimum değeri, x_{min} minimum değeri ifade etmektedir.

Modellerde, en fazla iki ara katman kullanılmıştır. Tek katmanlı ağlarda en fazla 500 nöron, çift katmanlı ağlarda ise, en çok 100’er nöron kullanılmıştır. Daha fazla, nöron ve katman kullanılması, işlem yükü ve modeli gereğinden fazla karmaşıklaştıracağı için tercih edilmemiştir. Tablo 2’de geliştirilen YSA modellerine ait sonuç görülmektedir.

Tablodan da görülebileceği gibi, ağların eğitim aşamasında, iki ağ mimarisi diğerlerine göre daha başarılı olmuştur. Bunlar, (9 x 70 x 3) ve (9 x 500 x 3) ağlarıdır. Sonuçlar, ağ mimarisi seçimi için, tek ara katmanın daha uygun olduğunu ve ilave ara katmana gerek olmadığını göstermektedir. Ara katmanda bulunan nöron sayısı arttıkça, performansta artış gözlenmiştir. Şekil 6’da, artan nöron sayısının (tek katmanlı ağlar ve eşit ağ parametreleri için) performans üzerindeki etkisi görülmektedir. Ayrıca, yapılan regresyon analizi sonucu, aşağıdaki üstel bağıntının bu ilişkiye uyduğu tespit edilmiştir:

$$y = 0.0672 x^{-0.1342} \quad (9)$$

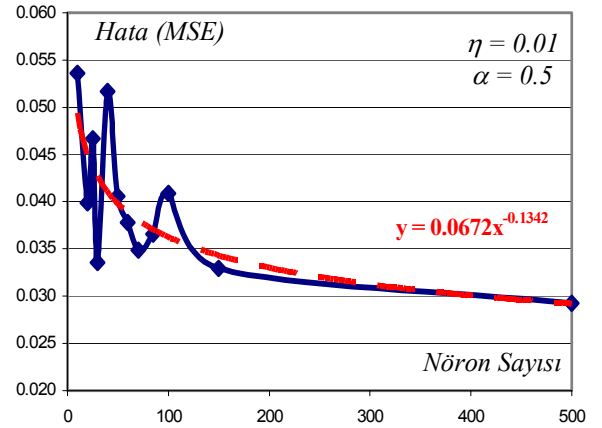
Burada, y ortalama kareler cinsinden hata miktarını, x ise nöron sayısını ifade etmektedir. Diğer yandan, başarılı ağ mimarilerinin her biri için, öğrenme algoritması parametrelerinin değişiminin performans üzerindeki etkileri de incelenmiştir. Sonuçta, öğrenme oranı ve momentum katsayısı, daha yüksek değerler için genelde daha iyi sonuçlar vermiştir (Şekil 7).

Tablo 2. YSA eğitim sonuçları

Mimari	η	α	Epok	Hata (MSE)	Mimari	η	α	Epok	Hata (MSE)
9 x 10 x 3	0.01	0.5	10 000	0.0536362	9 x 50 x 60 x 3	0.01	0.5	10 000	0.0322528
9 x 10 x 10 x 3	0.01	0.5	10 000	0.0365444	9 x 60 x 3	0.01	0.5	10 000	0.0377914
9 x 10 x 20 x 3	0.01	0.5	10 000	0.0397039	9 x 60 x 60 x 3	0.01	0.5	10 000	0.0347667
9 x 10 x 30 x 3	0.01	0.5	10 000	0.0390349	9 x 70 x 3	0.01	0.5	10 000	0.0348898
9 x 10 x 40 x 3	0.01	0.5	10 000	0.0474786	9 x 70 x 3	0.01	0.9	10 000	0.0377035
9 x 10 x 50 x 3	0.01	0.5	10 000	0.0380859	9 x 70 x 3	0.01	0.2	10 000	0.0377044
9 x 20 x 3	0.01	0.5	10 000	0.0398903	9 x 70 x 3	0.1	0.5	10 000	0.030873
9 x 20 x 20 x 3	0.01	0.5	10 000	0.0390357	9 x 70 x 3	0.001	0.5	10 000	0.0463084
9 x 20 x 30 x 3	0.01	0.5	10 000	0.0352517	9 x 70 x 3	0.1	0.9	10 000	0.0308723
9 x 20 x 40 x 3	0.01	0.5	10 000	0.0357364	9 x 70 x 3	0.2	0.9	10 000	0.0284714
9 x 25 x 3	0.01	0.5	10 000	0.0466709	9 x 70 x 3	0.2	0.01	10 000	0.0272548
9 x 25 x 3	0.01	0.9	10 000	0.0466808	9 x 70 x 3	0.5	0.9	10 000	0.0243165
9 x 30 x 3	0.01	0.5	10 000	0.0335351	9 x 70 x 3	0.9	0.9	10 000	0.0207233
9 x 30 x 3	0.01	0.9	10 000	0.0335351	9 x 70 x 3	0.9	0.9	500 000	0.0043274
9 x 30 x 3	0.01	0.2	10 000	0.0335352	9 x 70 x 70 x 3	0.01	0.5	10 000	0.0312657
9 x 30 x 3	0.1	0.5	10 000	0.030599	9 x 85 x 3	0.01	0.5	10 000	0.0365687
9 x 30 x 3	0.001	0.5	10 000	0.0528019	9 x 100 x 3	0.01	0.5	10 000	0.0408807
9 x 30 x 3	0.1	0.9	10 000	0.0305968	9 x 85 x 3	0.01	0.5	10 000	0.0365687
9 x 30 x 3	0.2	0.9	10 000	0.0294521	9 x 100 x 3	0.01	0.5	10 000	0.0408807
9 x 30 x 3	0.2	0.01	10 000	0.0294567	9 x 100 x 3	0.01	0.9	10 000	0.0356869
9 x 30 x 3	0.5	0.9	10 000	0.0274016	9 x 100 x 100 x 3	0.01	0.5	10 000	0.034578
9 x 30 x 3	0.9	0.9	10 000	0.0257671	9 x 150 x 3	0.01	0.5	10 000	0.032934
9 x 35 x 3	0.9	0.9	10 000	0.103305	9 x 150 x 3	0.01	0.9	10 000	0.0312105
9 x 30 x 30 x 3	0.01	0.5	10 000	0.0371111	9 x 500 x 3	0.01	0.5	10 000	0.0292255
9 x 30 x 40 x 3	0.01	0.5	10 000	0.0384606	9 x 500 x 3	0.01	0.9	10 000	0.0294604
9 x 30 x 50 x 3	0.01	0.5	10 000	0.033659	9 x 500 x 3	0.01	0.2	10 000	0.0294529
9 x 40 x 3	0.01	0.5	10 000	0.0516768	9 x 500 x 3	0.1	0.5	10 000	0.030599
9 x 40 x 3	0.01	0.9	10 000	0.0343077	9 x 500 x 3	0.001	0.5	10 000	0.0321076
9 x 40 x 40 x 3	0.01	0.5	10 000	0.0358787	9 x 500 x 3	0.2	0.001	10 000	0.0128294
9 x 40 x 50 x 3	0.01	0.5	10 000	0.0367707	9 x 500 x 3	0.2	0.9	10 000	0.0294521
9 x 40 x 60 x 3	0.01	0.5	10 000	0.0369209	9 x 500 x 3	0.2	0.01	10 000	0.018676
9 x 50 x 3	0.01	0.5	10 000	0.040609	9 x 500 x 3	0.5	0.9	10 000	0.0143016
9 x 50 x 3	0.01	0.9	10 000	0.038264	9 x 500 x 3	0.9	0.9	10 000	0.0115853
9 x 50 x 50 x 3	0.01	0.5	10 000	0.0349027					


Böylece, bu problem için en uygun değerlerin her iki parametre için de 0.9 olduğuna karar verilmiştir. Bu durum, öğrenme sırasındaki yeni ağırlık değişimlerinin, önceki ağırlık değerine çok yakın olduğu ve gradyanın etkisinin oldukça az olduğu sonucunu doğurmaktadır (Şekil 7).

Bir YSA'da, eğitim veri kümesi için ileri beslemenin bir kez yapılmasına epok (epoch) denmektedir. Bu çalışmada, epok sayısının öğrenme üzerindeki etkisini görmek ve optimum epok sayısına karar vermek için, başarılı olan ağlar içinden seçilen bir tanesi (9 x 70 x 3), 500000




Şekil 6. Ara katman nöron sayısının etkisi


(a) 9 x 70 x 3'lük YSA



(b) 9 x 500 x 3'lük YSA



Şekil 7. Ağ parametrelerinin (η ve α) performans üzerine etkisi



Şekil 8. Epok sayısının 9x70x3'lük YSA öğrenmesi üzerindeki etkisi

epoka kadar eğitilmiştir. Ayrıca, artan epok sayısı ile performansın ciddi bir şekilde arttığı, fakat 200000 epoktan sonra, performans artış eğiminin gittikçe azaldığı gözlenmiştir. Sonuç olarak, bu model için, 500000'lik bir epok büyüklüğü yeterli bulunmuştur (Şekil 8).

Son olarak, 500 000 epok için eğitilen modelin (9 x 70 x 3) deneme kümesi sonuçları da oldukça başarılıdır (Şekil 8). Deneme kümesi için hata değeri, 0.003781 olarak bulunmuştur. Sonuç olarak, geliştirilen model, eğitim işlemi de hiç karşılaşmadığı veriler için de oldukça başarılı olmuştur.

Sonuçlar

Bu çalışmada, YSA metodolojisi kullanılarak esnek üstyapıların geri-hesaplanması gerçekleştirilmiştir. Elde edilen performans değerleri oldukça yüksektir.

YSA'nın performansı, ağ mimarisinden önemli ölçüde etkilenmektedir. Bu çalışmada ele alınan geri-hesaplama problemi için en uygun ağ yapısı, (9 x 70 x 3) ve (9 x 500 x 3) olarak bulunmuştur.

Ağ parametrelerinin etkisi, ağ mimarisinin etkisine göre daha azdır. Bu çalışmada, bu problem için optimum öğrenme ve momentum katsayıları 0.9 olarak önerilmektedir. Ayrıca, 500000'lik bir epok büyüklüğünün, bu model için yeterli olduğu sonucuna varılmıştır.

YSA, bir davranışı öğrendikten sonra, belirlenen serbest değişkenleri kullanarak, yeni giriş değerleri için sonuç üretebilmektedir. Bu anlamda, bir fonksiyon gibi görev yapmaktadırlar. Bunun sonucu olarak, YSA yöntemi, gerçek-zamanlı olarak esnek üstyapıların mekanik özelliklerinin geri-hesaplanabilmesini mümkün kılmaktadır.

Gerçek-zamanlı geri hesaplama yapılabilmesi, yol mühendisliği açısından çok önemlidir. Çünkü, incelenen bir yoldan alınan çok sayıda verinin analizi oldukça uzun zaman almaktadır. Bu ise, hem iş gücü kaybına, hem de karar verme aşamasında gecikmelere yol açmaktadır.

Bu model, gerçek-zamanlı analiz yeteneği sayesinde, yeni tamamlanan üstyapıların kalite kontrolünde de kullanılabilir. Çünkü, standart yöntemler, hızlı karar verme ve değerlendirme süreci gerektiren kalite-kontrol uygulamaları için uygun değildir.

Kaynaklar

- Bose, N.K. ve Liang, P., (1996). Neural Network Fundamentals with Graphs, McGraw-Hill Int. Ed., 478.
- Bentsen,R.A., Bush, A.J. ve Harrison, J.(1989). Evaluation of NDT Equipment for Airfield Pavements, *Technical Record GL-89-3*, U.S. AEWES, Vicksburg, MS, 390.
- Chang,D.,Kang,Y,Roesset,J ve Stokoe,K (1992) Effect of Depth to Bedrock on Deflection Basins with Dynaflect and FWD Test, Record No: **1355**, TRB, 8-16.

- Demuth, H., ve Beale, M., (2000). Neural network toolbox for use with MATLAB, User's Guide, Math Works, Inc., USA, 822.
- Flood, I. ve Kartam, N., (1998). Artificial Neural Networks for Civil Engineers ASCE Press, 277.
- Fu, L., (1994). Neural Networks in Computer Intelligence, McGraw-Hill Int. Ed., USA, 460.
- Haykin, S., (1999). Neural Networks: A Compreh. Foundation. Prentice-Hall NJ, 842.
- Hoffman, M.S. ve Thompson, M.R., (1982). Backcalc. nonl. resilient moduli from deflection data, Record No: **852**, TRB, DC., 42-51.
- Huang, Y. H., (1993). Pavement analysis and design, Prentice Hall, NJ, 803.
- Jacobs, R.A., (1988). Increased rates of convergence through learning rate adapt., *Neural Networks*, **1**, 295-307.
- Kecman, V., (2001). Learning and soft computing, MIT Press, MA, USA, 541.
- Kim, Y.R., Xu, B., ve Kim, Y., (2000). A new backcalculation procedure based on dispersion analysis of FWD time history deflect. and surface wave measurements using ANNs, ASTM STP **1375**, PA.
- Lytton R.L., (1989). Backcalculation of layer moduli- state of the art. ASTM STP **1026**, PA., 7-38.
- LeCun, Y., (1993). Efficient learning and second-order methods, *A Tutorial at NIPS 93*, ATT Bell Labs, Denver, UK, 27.
- Meier, R.W., ve Rix, G.J., (1993). An initial study of surface wave inversion using artificial neural networks, *Geotechnical Testing Journal*, ASTM , **16**, 425-432.
- Meier, R. W. ve Rix, G.J., (1994). Backcalc. of flexible pavement moduli using artificial neural networks, Record No: **1448**, TRB, DC., 75-82.
- Meier, R.W., (1995). Backcalculation of Flexible Pavement Moduli from FWD Data Using ANNs, PhD Dissertation Georgia Institute of Technology, Atlanta, 239.
- Meier, R.W. ve Rix, G.J., (1995). Backcalc. of flexible pavement moduli from dynamic deflection basins using ANNs, Record No: **1473**, TRB, DC., 72-81.
- Nazarian, S. ve Stokoe, K.H., (1989). NDT evaluation of pavements by surface wave method, ASTM STP **1026**, PA., 119-137.
- Pearl, J., (1988). Probabilistic Reasoning in Intelligent Sys. 2nd Ed, Pearl Press, UK., 552.
- Principle, J.C., Euliano, N.R., Lefebvre, W., (2000). Neural and adaptive systems, John Wiley & Sons, Inc., USA, 656.
- Roesset, J.M., ve Shao, K., (1985). Dynamic Interpretation of Dynaflect and FWD Tests, Annual Meeting of the TRB, DC., USA.
- Rumelhart, D.E. ve McClelland, J.L., (1986). *Parallel Distributed Processing*, **1**, MIT Press, MA.
- Saltan, M., Tigdemir, M., Karasahin, M. (2002). ANN application for flexible pavement thickness modeling, *Turkish Journal of Engineering and Environmental Science*, TÜBİTAK, **26**, 243-248.
- Sebaaly, B., Davies, T.G., ve Mamlouk, M., (1985). Dynamics of FWD, ASCE, *Journal Of Transportation Engineering*, **111**, 6, 618-632.
- Stolle, D. F., (1991). Modeling of dynamic response of pavements to impact loading. *Computers and Geotechnics*, **11**, 1, 83-94.
- Ross, T.J. (1995). Fuzzy Logic with Engineering Applications, McGraw- Hill Co., USA, 600.
- Sagiroglu, S., Besdok, E., ve Erler, M., (2003). Mühendislikte yapay zeka uygulamaları, Ufuk Kitap Yayıncılık, İstanbul, 426.
- Tawfiq, K., Armaghani, J., Sobanjo, J., (2000). Seismic pavement analyzer and FWD for pavement evaluation, ASTM STP **1375**, PA.
- Tholen, O., Sharma, J. ve Terrel, R.L., (1985). Comparison of FWD with Other Deflection Testing Devices. Record No: **1007**, TRB, DC., 20-26.
- Tutumluer, E. ve Seyhan, U., (1998). NN Modeling of Anisotropic Aggregate Behavior from Repeat Load Triaxial Tests, Record No: **1615**, TRB, D.C.
- Uzan, J., ve Scullion, T., (1990). Verification of Backcalculation Procedures, *Proc. 3rd Int. Conf. on Bearing Capacity of Roads and Airfields*, Norway, **1**, 447-458.
- Uzan, J., (1994). Advanced Backcalculation Techniques, ASTM STP **1198**, PA, 3-37.
- Widrow, B. ve Hoff, M.E., (1960). Adaptive switching circuits, 1960 IRE WESCON Convention Record, New York IRE, 96-100.
- Zhou, H., (2000). Comparison of backcalc. and laboratory measured moduli on ac and granular base layer materials, ASTM STP **1375**, PA, 161-172.