

ENDÜSTRİYEL TAŞIYICI SİSTEMLERİN YAPAY SİNİR AĞLARI İLE ANALİZİ

İlyas KACAR

Makina Mühendisliği Bölümü
Mühendislik-Mimarlık Fakültesi
Niğde Üniversitesi, 51200, Niğde
e-posta: ikacar@gmail.com

Anahtar sözcükler: Endüstriyel Taşıyıcı Sistemler, Modelleme, Yapay Sinir Ağları


ABSTRACT

Industrial lifting devices are generally used for packaging, handling, storage, and transporting of the raw materials and products in industrial systems. This paper presents artificial neural network technique for industrial forklifts. In this study, an application for an ANN model to predict forces in joining of forklift is investigated using a model under different working conditions. Proposed model results are compared against the ANN-based model. Results indicate that neural networks may be reliably used for forklift systems in order to improve equipment performance.

1. GİRİŞ

Forkliftler malzemeleri taşımak, çekmek, itmek, götürmek, yukarı kaldırmak, sıralamak için kullanılmaktadırlar. Şekil 1 de çok yaygın olarak kullanılan bir forkliftin detayları verilmiştir. Forkliftlerin mafsal noktalarındaki hareketlerinin ve kuvvet dağılımlarının bilinmesi ve optimizasyonu forkliftin performansı açısından oldukça önemlidir. Ayrıca iş makinasının kullanımı esnasında en sık rastlanan iş kazalarından biri de operatörün yükün kaldırılması esnasında kararlılık üçgeni dışına çıkılacak derecede dengesiz bir yük dağılımı oluşturmasıdır [1]. Bu problem kullanım esnasında iş güvenliği açısından önemli bir kriter olmaktadır. Eğer kritik mafsal noktalarına gelecek yükler önceden tahmin edilebilirse muhtemel kazaların önüne geçilmiş olacaktır. Fakat problem oldukça karmaşık olup analizlerinde sıkıntılarla karşılaşılmaktadır. Son yıllarda araştırmacıların büyük bir çoğunluğunun üzerinde çalıştığı yapay sinir ağı tekniği, pek çok problemin analizinde başarı ile kullanılmış, özellikle mühendislik sahasında klasik çözüm metodlarının yeterli olmadığı durumlarda alternatif çözüm önerileri sağlamıştır [2].

Lennox ve arkadaşları [3] benzin motorlu endüstriyel sistemlere sinir ağı yöntemi uygulayarak, ağın kontrol ve proses takibini iyileştirdiğini bulmuşlardır.



Şekil-1. Forkliftlerin genel olarak yapısı [4]

Endüstriyel alanda yapılan çalışmalarda, çalışma ortamını ve güvenliğini iyileştirme amaçlı olarak, Horberry ve arkadaşları [5]; taşıt ve yayaları içeren insan merkezli tasarımları ele almışlar, taşıyıcı makineleri de içeren bir trafikte potansiyel tehlikeleri önleme konusunda olumlu sonuçlar elde etmişlerdir.

Han-Kee Jang ve Du-Yoon Kook [6] endüstriyel taşıyıcının başlangıç hareketinin ve sürüş kalitesinin artırılması amaçlı olarak 5 ayrı taşıyıcı üzerinde ve farklı yük değerlerinde sürüş doğrultusundaki şoklar, dikey ve yalpalama titreşimlerinden oluşan parametreleri deneysel olarak incelemişlerdir.

Verschoore ve arkadaşları [7] oluşturdukları simülasyon modelde endüstriyel taşıyıcıların farklı koltuk ve lastik şartlarındaki sürüş konforunu, yol profilini de değerlendirerek simüle ve test etmişlerdir.

Yapay sinir ağlarının endüstriyel alanda uygulamaları yeni bir konu olup, Chauhan ve Dave [8] güç aktarma sistemlerinin güvenliğini tahmin etmede yapay sinir ağı tekniğinin verimliliğini incelemiştir.

Dias ve arkadaşları [9] genel olarak kontrol ve şablonların-desenlerin tanınmasında kullanılabilecek yapay sinir ağları konusunda ticari çalışma yaparak entegre devre üretmişlerdir.

Cavaleria ve arkadaşlarının [10] otomotiv sektöründe fren balatalarının üretiminde birim maliyetin

tahmininde kullandığı parametrik ve yapay sinir ağı iki ayrı yaklaşımın ikisini de ürün geliştirme aşamasında uygulayarak karşılaştırma yapmışlardır. Bu alanda ağı klasik yöntemle göre alternatif geçerli sonuçlar verdiğini belirtmişlerdir.

Bu tekniğin iş makinaları üzerinde uygulanması ise yeni bir konu olup, literatürde henüz bu metot ile kontrol ve otomasyon optimizasyonu çalışmalarına rastlanmamıştır. Çalışmamızda taşıyıcının güvenli, ekonomik ve daha uzun ömürlü kullanım imkanı sağlanması amaçlanmıştır.

Çalışmada forkliftin mafsallı noktalarına gelen yükler benzetim yoluyla elde edilerek bu değerler, oluşturulan yapay sinir ağının eğitilmesinde ve test edilmesinde kullanılmıştır. Ayrıca eğitilen ağı farklı girişler uygulandığında alınacak çıkış değerleri de simülasyondan elde edilen değerlerle kıyaslamalı olarak tartışma bölümünde değerlendirilmiştir.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin temel birimi olan nöronlara (sinir hücrelerine) benzer olarak teşkil edilen yapay hücrelerin farklı topoloji ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir.

McCulloch ve Pitts [11] yaptıkları çalışmalar sonunda, bir hücreye N tane ağırlıklandırılmış giriş parametresi girmekte ve hücre, sonucu lineer olmayan bir fonksiyondan geçirmektedir. Herhangi bir katmandaki j nci hücreye gelen toplam giriş, önceki katmandaki hücrelerin y_i çıkışlarının (ilk katman için girişlerin) bağlantılar üzerindeki w_{ij} ağırlıkları ile hesaplanmış bir ağırlıklı toplamı olmaktadır. Matematiksel olarak;

$$net_j = \sum_i y_i w_{ij} \quad (1)$$

şeklinde ifade edilmektedir. Katmanları oluşturan hücre çıkışları, ağırlıklanan girişlerin bir eşik değerden çıkartılıp lineer olmayan bir fonksiyondan geçirilmesiyle hesaplanmaktadır. Bu durum;

$$f(net_j) = \frac{1}{1 + \exp\left(-\sum_i y_i w_{ij}\right)} \quad (2)$$

denklemleri ile ifade edilmektedir. Ön gerilim ifadesi de denkleme dahil edildiğinde genel halde;

$$f(net_j) = f(yw + b) \quad (3)$$

şeklinde yazılabilmektedir. Burada $f(net)$ hücre için tanımlanmış aktivasyon fonksiyonu, w hücreler arası ağırlıklar, y giriş vektörleri, b ise ağ ön gerilimleridir.

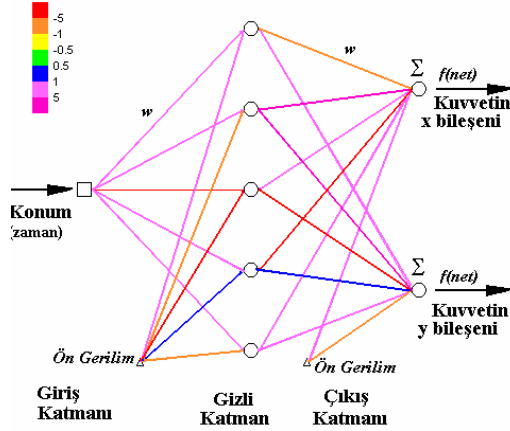
Ağda, her bir katmana ait hücreye toplam giriş bir alt katmandaki hücre çıkışlarının ağırlıklandırılması ile elde edilir. Hücre çıkışları ise o hücre için tanımlanmış

aktivasyon fonksiyonuna bağlı olarak elde edilmektedir.

Geri yayılım algoritması ile eğitilen çok katmanlı yapay sinir ağı tipi (Multi-Layer Perceptron-MLP), genellikle tercih edilen bir mimari olup çalışmamızda da giriş katmanında 1 düğüm, gizli katmanda 5 düğüm ve çıkış katmanında da 2 düğüm olacak şekilde teşkil edilmiştir. Çıkış düğümleri modelin belirtilen noktalarındaki kuvvet değerlerini göstermektedir. Gizli katmandaki düğüm sayısı modelden elde edilen eğitim setine uygun olması nedeni ile genel olarak 5-7 arasında değiştirilmiştir.

Giriş ve çıkış katmanlarının arasında mevcut gizli katmanlar lineer olmayan davranışları dolayısıyla sinir ağının toplam davranışının kaynağı olmaktadır. Giriş ve çıkış katmanlarındaki hücre sayıları ele alınan problemin gereklerine göre belirlenmiş olup, ancak gizli katman veya katmanlardaki hücrelerin doğru sayısı optimallik açısından farklı değerlerde kullanılmıştır.


Ağların tamamı bilgisayar üzerinde benzetimi yapılan yazılımlardır ve topolojisi Şekil 2 de gösterilmektedir. Şekilde üç katmanlı 1-7-2 düzenine sahip bir MLP sinir ağı yapısı gösterilmiştir.



Şekil-2. Kuvvet dağılımı için oluşturulan 1-7-2 yapısındaki ağ topolojisi (Şekildeki ölçek ağırlıkların birbirlerine göre durumlarını göstermektedir).

Bu MLP modeli ağ, özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Birçok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.

Gizli katmanda hiperbolik tanjant transfer fonksiyonu kullanılmıştır. Bu aktivasyon fonksiyonu için hücre giriş-çıkış ifadesi (2)'de ve kullandığımız aktivasyon fonksiyonu Şekil 3 te verilmektedir.



Şekil-3. Çalışmada kullanılan hiperbolik tanjant aktivasyon fonksiyonu

Geriye yayılma algoritması esasen çok katmanlı ağların eğitiminde kullanılan öğreticili bir öğrenme algoritmasıdır. Giriş katman-saklı katman ve saklı katman-çıkış katmanları arasında mevcut olan ağırlıklı bağlantıların, w_{ih} ve w_{ho} , ağ çıkışında oluşan hataya bağlı olarak optimize edilmesi amaçlanmaktadır. Giriş ve ilgili çıkış vektörü, ağı eğitmek için kullanılmaktadır. Örüntüyü belirleyen giriş vektörü ağın ilk katmanına verildikten sonra aradaki gizli katmanlardan geçerek en sondaki çıkış katmanına ağırlıklar yardımı ile ulaşır. Ağdaki her bir hücre, kendisinde sonlanan ağırlık vektörlerinin aritmetiksel toplamını aldıktan sonra sonucu kendinden sonraki katmanın tüm hücrelerine, kullandığımız aktivasyon fonksiyonuna bağlı olarak aktarmaktadır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmaktadır. Ağırlıkların yenilenmesi i inci girdi ile j nci hücre için;

$$w_{ij} = w_{ij} + \Delta w_{ij} \quad (4)$$

ile ifade edilir. İfadede Δw_{ij} terimi ağırlıkların yenilenme değerini belirtmektedir. Her bir k ncı girdi-çıkış örnek çifti için ağırlık değişimi;

$$\Delta w_{ji}(t) = \alpha (T_i^k - O_i^k) x_j^k \quad (5)$$

ile ifade edilir. Burada T_i istenen hedef çıktı, O_i gerçek çıktı, α öğrenme oranı ve x_j ise j nci ağ girdisidir. Herhangi bir k ncı tabakadaki örnek çifti için toplam hata ve ortalama hata fonksiyonu için geri yayılım algoritmasında ortalama kare hatası olarak bilinen hata ölçütü kullanılabilir.

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (6a)$$

$$E = \frac{1}{2P} \sum_p \sum_j (T_j - O_j)^2 \quad (6b)$$

Hataların karesi alınarak beklenen değerden uzak olan çıkış değerlerinin toplam hatayı oluşturması sağlanmaktadır. Hatayı minimum yapmak amacı ile hatanın ağırlıklara olan bağımlılığı hesaplanır ve gradiente bağlı olarak ağırlıklar hatayı düşürecek şekilde yenilenmektedir. Rumelhart [12] tarafından, ağın yakınsamaması durumunda β momentum terimini de

işerecek şekilde ağırlıkların ayarlanması ile formül aşağıdaki şekilde genelleştirilmiştir:

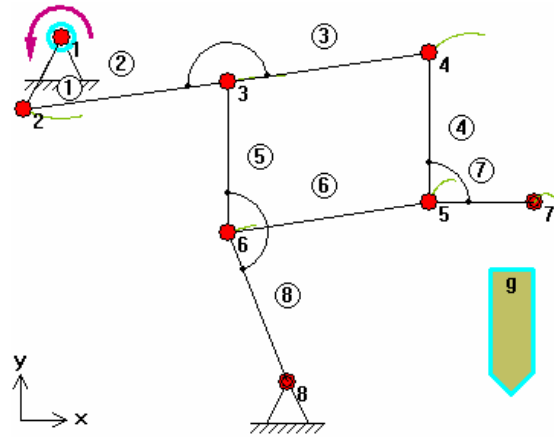
$$\Delta w_{ji}(t+1) = \alpha \delta_i^k O_j^k + \beta \Delta w_{ij}(t) \quad (7)$$

Burada β momentum terimi, δ_i^k eğitim setindeki k . örnek çifti için i . hücrenin hata değeridir ve kullanılan eşik fonksiyonunun türevini içeren bir terimdir. Bu nedenle eşik fonksiyonu ağırlıklandırılmış girdi toplamları ile hesaplanmış net girdiyi alarak, işlem elemanlarının çıktısını belirleyen ve türevlenebilir olması tercih sebebi olan bir fonksiyondur. Bu ifadelerden yapay sinir ağında giriş değerlerinin, ağırlıklı bağlantıların belirlenmesinde ve dolayısı ile sinir ağı eğitiminde önemli bir rol oynadığı görülmektedir.

3. NÜMERİK MODELLEME ve METODOLOJİ


Bu çalışmada forklift için Şekil 4 de görülen kinematik model oluşturulmuştur. İncelenen noktalar model üzerinde 5 ve 6 mafsalları olarak belirtilmiş olup, 1 numaralı uzuv tahrik uzvunu göstermektedir. Bu modelden elde edilen değerler yapay sinir ağı için eğitim ve test kümeleri olarak kullanılmıştır. Bu model üzerinde 7 noktası, ataşman olarak adlandırılan yük tutucu kısımdır ve yük bu noktaya uygulanmaktadır.

İş makinasının takip ettiği yörünge ve yük dağılımı itibarı ile özellikle 5 ve 6 noktalarına x ve y doğrultularında gelen kuvvetin zamana göre değişimi simüle edilmiştir. Modelin 5 ve 6 noktaları dışındaki noktalarında, kuvvetin dağılımı birbirine yakın değerlerde olduğundan dolayı, öncelikli olarak bu noktalar incelenmiştir. Yapay sinir ağları için eğitim ve test kümesi olacak değişik kuvvet değerleri, modelin bu mafsalları üzerinde yapılan nümerik çalışma ile elde edilmiştir.



Şekil-4. Analiz edilen forklift mekanizması

Çalışmamız modelin mafsal noktasında yapılan analiz ve değerlendirme çalışmasıdır. Modelde tahrik uzvu 1 numaralı eleman üzerinde olup uygulanan tahrik torku Şekil 5 te görüldüğü gibi lineerdir. Hareketin tamamı 72 eş parçaya ayrılmıştır. Bu değerler sinir ağına giriş değerleri olarak kullanılan değerlerdir. Hareketin 72 adımı için her konuma ait zaman dilimi 1 sn olarak alınmıştır. Hareket adımı, zaman dilimi olarak yorumlanabilmektedir.




Şekil-5. Simüle edilen tork değişimi

Nümerik model kullanılarak elde edilen değerler geri yayılım algoritması ve hiperbolik tanjant aktivasyon fonksiyonuna sahip yapay sinir ağına eğitilmiş ve test edilmiştir. Uygulama QwikNet [13] yazılımı kullanılarak gerçekleştirilmiştir. Forklift modelinin oluşturulmasında ve sayısal analizinde SAM 3.0 [14] programı kullanılmıştır.

4. SONUÇLAR ve TARTIŞMA

Forklift modeli üzerinden elde edilen zamana bağlı kuvvet bileşenleri $F_3(x)$, $F_3(y)$, $F_6(x)$ ve $F_6(y)$ 'nin değerleri Şekil 6 da görülmektedir. $F_3(x)$ ve $F_3(y)$ sırası ile modelin 5 noktasına gelen yük kuvvetinin yatay ve dikey bileşenleridir. Aynı şekilde, $F_6(x)$ ve $F_6(y)$ bileşenleri de sırası ile modelin 6 noktasına gelen yük kuvvetinin yatay ve dikey bileşenleridir




Şekil-6. 5 ve 6 noktasındaki kuvvetin x ve y bileşenlerinin zamana göre değişimi.

Modelden elde edilen değerler, iş makinasının ataşmanına uygulanan 1 ve 10 birimlik yük olmak üzere iki farklı kütle değerlerinden elde edilmiştir.


Ağ çok katmanlı bir yapay sinir ağı modeli (multilayer perceptron-MLP) dir. Giriş elemanlarının sayısı 72 şablondur. Çalışmada aşağıdaki ağ değişkenleri kullanılmış olup, sonuç değerleri de bu ağı verilen parametreler vasıtası ile eğitilip test edilmesi ile elde edilmiştir.

Giriş data seti=72
Gizli katman sayısı=1
Gizli düğümler =5-7 arası değişken
Çıkış düğümleri 2
Çıkış eşiği 0.99
Öğrenme hızı $\eta=0.1$
Momentum $\alpha=0.1$
Öğrenme eşiği 0.0001

5 noktası için x ve y doğrultularındaki, sinir ağından elde edilen çıkış değerlerinin 72 adet eğitim şablonuna göre grafikleri Şekil 7 de ve 6 noktası için elde edilen değerler de Şekil 8 deki gibi olmaktadır.



Şekil-7. 5 noktasındaki 72 adet eğitim şablonuna (zaman aralıkları) göre, sinir ağından elde edilen çıkış değerleri



Şekil-8. 6 noktasındaki 72 adet eğitim şablonuna (zaman aralıkları) göre, sinir ağından elde edilen çıkış değerleri

Grafiklerden de anlaşılacağı üzere sinir ağı oluşturduğu tahmin değerleri (Şekil 7-8), simülasyon değerleri (Şekil 6) ile uyumlu olmaktadır. Böylece de bu ağ modelinin, bu tip iş makinalarının çalışma

güvenliği ve performansı açısından önerilebilir bir uygulama olduğu açıkça görülmektedir. Bu çalışmada ve diğer uygulamalarda görüldüğü gibi yapay sinir ağlarının en önemli faydalarından birisi de; yeni durumlara adaptasyon edilebilmeleri ve sonradan veri girişini kabul etmeleridir. Kullanılan metot ve yapılan kabul ne olursa olsun, sayılar tasarım aşamasında sadece bir fikir vermek için vardır ve asıl problem sistemin gerçekteki davranışının tam olarak anlaşılmasıdır.

5. SONUÇ

Önerilen geri yayımlı ağ, iş makinalarında mafsal noktalarına gelen yükün tahmininde kullanılmıştır. Veriler model üzerinde yapılan simülasyon sonucunda elde edilen verilerdir. Ağ, zamana bağlı kuvvet değişimlerinin tahmininde faydalı olmuştur. Ağ farklı yük değerleri için eğitilip test edilmiştir.

Ağ topolojisinde yapılacak küçük değişiklikler veya modelin daha kompleks konfigürasyonları ile farklı yüklenme şartlarına sahip iş makinalarının analizi yapılabileceğinden dolayı, çalışma daha kapsamlı uygulamalar için geliştirilebilir. Buna rağmen çalıştığımız modelin incelemesini yaptığımız mafsal noktalarındaki yük dağılımı, yapay sinir ağı tarafından başarılı bir şekilde eğitilip test edilmiştir.

KAYNAKLAR

- [1] William J. Becker, William C. Stephenson, Powered Industrial Trucks (Fork Lifts): OSHA Standard 1910.1781, OCCUPATIONAL SAFETY AND HEALTH ACT, Florida Cooperative Extension Service, University of Florida, Fact Sheet AE-202, 1993.
- [2] M.Y. Rafiq, G. Bugmann, D.J. Easterbrook, Neural Network Design for Engineering Application, COMPUTERS AND STRUCTURES, Vol 79 Iss pp 1541-1552, 2001.
- [3] B. Lennox, Gary A. Montague, Andy M. Frith, Chris Gent, Vic Bevan, Industrial Application of Neural Networks- An Investigation, JOURNAL OF PROCESS CONTROL, Vol 11, pp 497-507, 2001.

[4] SAMPLE DAILY CHECKLISTS FOR POWERED INDUSTRIAL TRUCKS, The Revised OSHA Standard for Powered Industrial Truck Training, Occupational Safety & Health Administration, 1996.

[5] T. Horberry, Tore J Larsson, Ian Johnston, John Lambert, Forklift Safety, Traffic Engineering and Intelligent Transport Systems: a Case Study, APPLIED ERGONOMICS, Vol 35, pp 575-581, 2004.

[6] H. Jang, Du-Yoon Kook, Objective Measurement of The Start-Motion Quality of A Forklift Truck, APPLIED ERGONOMICS, Vol 35, pp 467-473, 2004.

[7] R. Verschoore, J.G. Pieters, I.V. Pollet, Measurements and Simulation On The Comfort of Forklifts, JOURNAL OF SOUND AND VIBRATION, Vol 266 pp 585-599, 2003.

[8] S. Chauhan, M.P. Dave, ANN for Transmission System Static Security Assessment, ELECTRICAL POWER AND ENERGY SYSTEMS, Vol 24, pp 867-873, 2002.

[9] Fernando Morgado Dias, Ana Antunesa, Alexandre Manuel Mota, Artificial Neural Networks: a Review of Commercial Hardware, Vol 17, pp 945-952, 2004.

[10] Sergio Cavalieria, Paolo Maccarroneb, Roberto Pintoa, Parametric vs. Neural Networkmodels for the Estimation of Production Costs: a Case Study in the Automotive Industry, INT. J. PRODUCTION ECONOMICS, Vol 91, pp 165-177, 2004.

[11] McCullogh W.S., Pitts W., A Logical Calculus of Ideas Imminent in Pervous Activity., BULL. MATH., BIOPHYSICS, Vol 5, pp 115-33., 1943.

[12] Rumelhart, DE., Hinton, GE., and Williams, R J., Learning Internal Representation by Error Propagation. in Parallel Distributed Processing : Explorations in the Microstructures of Cognition, MIT Press, Cambridge, MA., 1986.

[13] QwikNet v2.23, Copyright (C) 1996-1999 Craig Jensen, <http://www.kagi.com/cjensen>

[14] Sam v3.0 for Windows, Copyright (C) 1995-1997, Artas Engineering Software, <http://www.pi.net/~artas/home.html>