

## BAKTERİ BÜYÜMESİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

O. Akpolat\*

\*Muğla Sıtkı Koçman Üniversitesi, Fen Fakültesi, Kimya Bölümü, 48000 Muğla

### ÖZET

Yapay zeka yaklaşımlarından olan yapay sinir ağlarının bazı modelleri ve bulanık programlama optimizasyon amaçlı kullanılabilir. Günümüzde pek çok alanda yapay zeka teknolojisi ürünleri boy gösterirken özellikle otomasyon sistemleri yapay zeka teknolojisi ile donatılarak bilgisayarların hesaplama ve değerlendirme güçlerine karar verme gücü de eklenmiştir. Yapay sinir ağlarında bilgisayarın öğrenmesi sağlanmakta ve makine öğrenmesi kısmen de olsa canlı düşünce sistemine analogi (benzeşim) kurularak zaman içinde davranışların iyileştirilmesi temeline dayanmaktadır. Temel bilimlerde modelleme ve optimizasyonunda ölçülen iki büyüklük arasındaki korelasyonlar çok önemlidir ve bunlar kuramsal açıdan polinomial olarak ilişkilendirilebilir. Ancak non lineer ilişkileri içeren bu tür karmaşık ifadelerin çözümlenmesinde farklı bir yol olarak Yapay Sinir Ağları (Artificial Neural Network - ANN) tekniği kullanılabilir. Bu çalışmada da deneysel olarak elde edilen bir bakteri büyüme eğrisinin yapay sinir ağları çok katmanlı algılayıcı modelinde geri hesaplama yöntemiyle bulunan benzeşim eğrisi çizilmiştir. Kullanılan yapay sinir ağ modelinde farklı kazanç ve iterasyon değerlerinde çalışılmış ve bu koşullarda elde edilen eğri uyum katsayıları optimize edilmiştir.

**Anahtar kelimeler:** Bakteri, Büyüme, Yapay Sinir Ağları, Modelleme, Simulasyon, Optimizasyon

## MODELING OF BACTERIA GROWING WITH ARTIFICIAL NEURAL NETWORKS

O. Akpolat\*

\*Muğla Sıtkı Koçman University, Faculty of Science, Chemistry Department, 48000 Muğla, Turkey

### ABSTRACT

Artificial intelligence approach which is one of the artificial neural networks and fuzzy programming in some models can be used for optimization purposes. Today, in many areas of artificial intelligence technology products which have been appearing, especially in automation systems equipped with artificial intelligence technology to power the computer calculation and assessment of decision-making power is also included. Computer learning and machine learning in artificial neural networks are provided partly and made analogy to living systems of thought (affinity) and defined as the treatment of established behavior over time. In basic science modeling and optimization is very important correlations between two sizes measured and it could be associated with them as polynomial from a theoretical perspective. However, in the analysis of complex expressions containing non-linear relationships a different way such as Artificial Neural Networks (Artificial Neural Network - ANN) technique could be used. In this study empirically derived growth curve of a bacterial artificial was simulated using by neural network model of multi-layered with error back propagation technique. Used in the neural network model was studied in different gain and iteration values and these conditions have been optimized by the coefficient of the curve fitting.

**Keywords:** Bacteria, Growth, Artificial Neural Networks, Modelling, Simulation, Optimization

### 1. GİRİŞ

Bilgisayarların insanlar gibi düşünmesini sağlamak için yoğun çabalar sürdürülmektedir. Bu işlevi yerine getirecek yazılımlar ve bu yazılımlar için uygun mikroişlemci tasarımları geliştirilmekte olup bu özelliklere sahip yazılım algoritmalarının yer aldığı temel bilim alanı yapay zeka araştırmalarından oluşmaktadır. Bu araştırmaların alt dalları

uzman sistemler, bulanık mantık, genetik algoritmalar ve yapay sinir ağları gibi çalışma alanlarından oluşmaktadır. Bunlardan yapay sinir ağları, insan beyninden esinlenerek geliştirilmiş, bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi işletme belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Başka bir deyişle biyolojik sinir ağlarını taklit eden

bilgisayar programlarıdır. Yapay sinir ağları geleneksel yetenekler gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağlar öğrenmenin yanısıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptirler. Yapay sinir ağlarının başlıca uygulama alanları sınıflandırma, tahminleme ve modelleme olarak ele alınabilir. (1,2,3,4)

Bu çerçevede yararlanılan sezgisel algoritmalar herhangi bir amaca ulaşmak ya da hedefe varmak için çeşitli alternatif hareketlerden etkili olanla karar verebilmek için tanımlanan kriterler ve bilgisayar algoritmaları ağıdır. Bunlar çözüm uzayında çözüme yakınsaması ispat edilemeyen yöntemler olup yakınsama özelliğine sahiptirler ancak kesin çözüm yerine onun yakınındaki bir çözümü garanti edebilirler. Bu tür yöntemlere gereksinim duyulmasının en büyük nedeni matematiksel algoritmaların karmaşıklığı yerine daha basit olmaları, kesin çözüm bulma işlemlerinin tanımlanamadığı problemlere uygun olmaları, öğrenme amaçlı ve kesin çözüm bulma işleminin bir parçası olmalarıdır. Basitliği, çözüm kalitesi ve çözümlene zamanı bir algoritmanın değerlendirilmesi için başlıca kriterlerdir. Bu nedenle bütün algoritmalarda olduğu gibi sezgisel algoritmalar için de bu kriterler çok önemlidir ve başlangıç değerlerine bağlı olarak bölgesel optimum çözümleri üretilirken bu da önem kazanmaktadır. Bunların yanında insan makine etkileşimine yatkınlıkları ve ısı bir işlem olan soğumanın doğal adımları, bir soyun genetik yapısındaki iyileşme ya da bir karınca kolonisinin bir hedefe en kısa sürede varmasında grubun üyelerinin diğerleri için iz olarak bıraktıkları bir kokunun algılanması gibi olay akışının optimize edilebilmesini sağlayan mekanizmaları esas almasının, matematiksel olarak ifade edilememesi gibi güçlükler içeren olayların optimizasyonunda büyük kolaylıklar getirdiği de unutulmamalıdır. (5,6,7)

Yapılan çalışmalara bakıldığında, yapay zeka uygulamaları çerçevesinde yapay sinir ağları kullanımının kimya, biyokimya, fizik, biyoteknoloji, biyomedikal ve tıp gibi temel alanlarda kantitatif analizlerin sonuçlarının değerlendirilmesi, malzeme davranışlarının incelenmesi, deneysel tasarım sonuçlarının istatistiksel değerlendirilmesi için modellenmesi, deneysel çalışmalarda alınan verilerin sonuçlarla ilişkilendirilmesinde kümeleme analizlerinin yapılarak sonuçların gruplandırılması, verilerin simulasyonunda

istatistiksel metotlarla yapılan eğri uydurma analizlerindeki doğrusal ve doğrusal olmayan çözümlenmelerde, tanı ve tedavi yöntemlerinin geliştirilmesinde daha etkin sonuçlara ulaşmada yararlanılabileceği anlaşılmaktadır. (8,9,10,11,12,13)


Yapay zeka yaklaşımlarından olan yapay sinir ağlarının bazı modelleri ve bulanık programlama da optimizasyon amaçlı kullanılabilir. Günümüzde pek çok alanda yapay zeka teknolojisi ürünleri boy gösterirken özellikle otomasyon sistemleri yapay zeka teknolojisi ile donatılarak bilgisayarların hesaplama ve değerlendirme güçlerine karar verme gücü de eklenmiştir. Böylece sistemlerin fonksiyonel özellikleri artırılmakta zeki etmenler yaşamda daha fazla yerini almaktadır. Bunlardan yapay sinir ağları bilgisayarın öğrenmesini sağlamaktadır. Makine öğrenmesi kısmen de olsa canlı düşünce sistemine anoloji (benzeşim) kurularak zaman içinde davranışların iyileştirilmesi olarak tanımlanmaktadır. Bunun için değişik öğrenme paradigmaları geliştirilmiştir ve bu paradigmlar başlıca 3 strateji üzerine kurulmuştur. Bunlar:

1. Öğretmenli öğrenme
2. Destekli öğrenme
3. Öğretmensiz öğrenme

Bu stratejilere dayanarak geliştirilmiş öğrenme kuralları vardır ve bu kurallara dayanarak hazırlanan yapay zeka algoritmaları kullanılmaktadır. Bu modellerden en basiti sadece girdi ve çıktı katmanlarından oluşan ve girdi çıktı ilişkisinin doğrusal olduğu tek katmanlı algılayıcıdır (X and Y). Eğer girdi çıktı ilişkisi doğrusal değilse çok katmanlı algılayıcılar kullanılmalıdır (X and Y ya da X or Y). Burada örnek olarak çok katmanlı geriye doğru hesaplamalı yapay sinir ağ modeli üzerinde durulacaktır. (6,7,8)

Modellemede ve optimizasyonunda ölçülen iki büyüklük arasındaki korelasyonlar çok önemlidir. Örneğin bir biyokimyasal reaksiyonda substrat konsantrasyonu ( $\text{kg ton}^{-1}$ ) ile spesifik büyüme hızı ( $\text{h}^{-1}$ ) arasındaki ilişki kuramsal açıdan polinomial olarak ilişkilendirilebilir. Ancak non lineer ilişkileri içeren bu tür karmaşık ifadelerin çözümlenmesinde farklı bir yol olarak Yapay Sinir Ağları (Artificial Neural Network - ANN) tekniği kullanılabilir. Bu tekniğin daha iyi anlaşılması için 2 düğümlü açık ve 5 düğümlü kapalı olmak üzere iki tabakalı bir giriş ve giriş verilerinin değerlendirilip

sonuçlandırıldığı tek düğümlü bir çıkıştan oluşan üç tabakalı bir ileri beslemeli ağdan oluşan network Şekil 1'de verilmiştir. (6,7,8)



Şekil 1 Çok katmanlı yapay sinir ağ modeli

Bağımlı değişkeni  $x$  ağırlıkları  $w$  olarak göstermek üzere giriş tabakasında ortalama sinyal denklemi:

$$S_i = w_i x_i$$

olarak yazılır. Çözümlemede düğüm noktaları için sigmoidal tip cevap (response) fonksiyonu  $f(S_i)$  kullanılır.

$$x_h = 1 / 1 + \exp(-S_i)$$

Çıkış düğümü ise fonksiyonel olarak basitçe aşağıdaki gibi yazılır.

$$y = S_h = w_h x_h = w_h / 1 + \exp(-S_i) \text{ veya}$$

$$y = S_h = w_h x_h = w_h / 1 + \exp(-w_i x_i)$$

Giriş ve çıkış sinyal vektörleri arasındaki ilişkinin değerlendirilmesindeki kriterler:

1. İfadenin doğruluk derecesi ile Kazanç/Maliyet oranı ve

2. Pratik çalışmalarda kullanım kolaylığı'dır.

Ağın çalışmasında kullanılan tekniklerden en tanınmış ve basit olanı geri hesaplamada hatayı azaltma tekniği olarak adlandırılır ve burada hatayı en küçük kareler yöntemine göre minimize etmek amaçlanır.

$$Err = y_{data} - y \text{ ve } K = (y_{data} - y)^2 \rightarrow \min$$

Parametrelerin kısmi türevleri alınarak:

$$\partial K / \partial w = 0$$

$$\partial K / \partial w = c \text{ Err } \partial y / \partial w = 0 \text{ Burada } c \neq 0 \text{ dır.}$$

$$\partial y / \partial w_h = x_h \text{ ve } \partial y / \partial w_i = w_h x_h^2 x_i \exp(-w_i x_i)$$

yazılır. Buradan da kazanç vektörü

$$w_{h,new} = w_{h,old} + \text{gain} * \text{Err} * \partial y / \partial w_h$$

$$w_{i,new} = w_{i,old} + \text{gain} * \text{Err} * \partial y / \partial w_i$$

olarak tanımlanmış olur ve bu yeni tanımlarla hesaplama zinciri tekrarlanır.

Bu çalışmada da ; deneysel olarak elde edilen bir bakteri büyüme eğrisinin yapay sinir ağları çok katmanlı algılayıcı modelinde geri hesaplama yöntemiyle bulunan benzeşim eğrisi çizilmiştir. Bunun için MATLAB yazılımı

kullanılarak hazırlanan programın adımları ve sonuçları ayrıntılı olarak verilmiştir. (6,14,15)

## 2. YÖNTEM

Yapılan çalışmada, ele alınan bakterinin çoğalması sırasında deneysel olarak substrat tüketimi ölçülmüş ve ölçülen bu tüketim verileri esas alınarak bakterinin büyüme eğrisinin yapay sinir ağları çok katmanlı algılayıcı modelinde geri hesaplama yöntemiyle benzeşim eğrisinin çizilebilmesi için bir algoritma hazırlanmıştır. Yazılan bilgisayar programının adımları aşağıda ayrıntılı olarak verilmiş ve çizilen benzeşim (simulasyon) eğrisi Şekil 2'de gösterilmiştir.

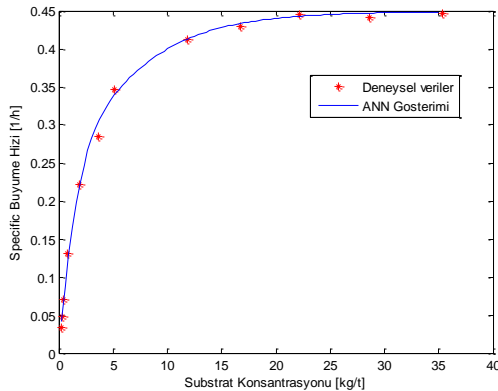
% **m\_File:**

```
% -----
clear all, clf, close all, whitebg('white'), figure(1);
% Substrat data vektörü ve Spesifik büyüme
hızının aranması
xt=[0.20957 0.30298 0.42411 0.82361 1.87652
3.62351 5.10987 11.84821 ...
16.72711 22.15191 28.64951 35.33921];
yt=[0.03415 0.04819 0.07031 0.13080 0.22123
0.28497 0.34649 0.41197 ...
0.42900 0.44582 0.44182 0.44691];
xint=[min(xt) max(xt)]; nx=length(xt);
plot(xt,yt,'r*'), hold on % Deneysel sonuçların
çizimi
% -----
% Başlangıç koşulları
ni=1; % Düğüm sayısı
nh=5; % Saklı tabakadaki düğüm sayısı
nitera=60000; % Maksimum iterasyon sayısı
rand('state',sum(100*clock)); % Başlangıç için
rastgele sayı üretimi
tim=cputime;
% -----
gain=0.06; % Kazanç faktörü
wi=(rand(ni+1,nh)-0.5); % Başlangıç ağırlıklarının
rastgele seçimi
wh=(rand(nh,1)-0.5);
nd=length(xt);
% -----
% Ağ çalışma iterasyonu
for i=0:nitera % Çalışma loop u
% Ağa rastgele giriş vektörü seçilmesi
j=ceil(nd*rand(1));
xi=[xt(j) 1];
xh=1./(1+exp(-(xi*wi)));
y=xh*wh;
% Giriş için modellenen hatanın hesaplanması
% yt(j);
err=yt(j)-y;
% Error back-propagation:
% Bir: Gradyentlerin bulunması
dwh=xh';
```

```

dwi=(xh'*(1.0-xh').*wh*xi)';
% İki: ağırlıkların değiştirilmesi
wh=wh+gain*err*dwh;
wi=wi+gain*err*dwi;
end;% loop un sonu
% -----
% Sonuçların sunumu
% Biten ağ hesaplarının değerlendirilmesi
dx=(xint(2)-xint(1))/100;
for isz=1:100
inc=(isz-1)*dx;
xn(isz)=xint(1)+inc;
xi=[xn(isz) 1.0];
xh=1./(1+exp(-(xi*wi)));
yn(isz)=xh*wh;
end;% isz loop
% Hesaplanan sonuçların çizimi
plot(xn,yn)
xlabel('Substrat Konsantrasyonu [kg/t]')
ylabel('Specific Buyume Hizi [1/h]')
legend('Deneysel veriler','ANN Gosterimi',0)
time=cputime-tim;
fprintf('Cpu time needed %6.1f seconds \n\n',time);
% -----
% Uyum Katsayısı
for i=1:nx
xtt=xt(i); ytt=yt(i);
for j=1:nn
if xtt>=xn(j) ynt(i)=yn(j);
end
end
end
TSS = sum((yt-mean(yt)).^2);
RSS = sum((yt-ynt).^2);
Rsquared = (1 - RSS/TSS)
% -----

```



**Şekil 2** Deneysel olarak elde edilen bir bakteri büyüme eğrisinin yapay sinir ağları çok katmanlı algılayıcı modeli kullanılarak geri hesaplama yöntemiyle bulunması (Kazanç:03, İterasyon:60000) (6)

Yararlanılan yapay sinir ağ modelinde performans açısından incelenmek üzere ağın

çalışması sırasında farklı kazanç ve iterasyon değerlerinde çalışılmış olup elde edilen eğri uyum katsayıları Tablo 1 'de sunulmuştur.

**Tablo 1** Çalışılan yapay sinir ağ modelinde farklı kazanç ve iterasyon değerlerinde elde edilen eğri uyum katsayıları

Kazanç	İterasyon	Uyum
0.3	600	0.9587
0.6	600	0.9648
0.9	600	0.9766
0.3	6000	0.9819
0.6	6000	0.9841
0.9	6000	0.9818
0.3	60000	0.9859
0.6	60000	0.9877
0.9	60000	0.9854

### 3 SONUÇLAR

Bu çalışmada; deneysel olarak elde edilen bir bakteri büyüme eğrisinin yapay sinir ağları çok katmanlı algılayıcı modelinde geri hesaplama yöntemiyle bulunan benzeşim eğrisi çizilmiştir. Kullanılan yapay sinir ağ modelinde farklı kazanç ve iterasyon değerlerinde çalışılmış ve bu koşullarda edilen eğri uyum katsayıları bulunmuştur. Kazanç katsayısının 0.6 ve iterasyonun 60000 olduğu durumda ağın performansı en yüksek değerine ulaşmakta ve 0.99'a yakın bulunan bu değer yeterince uygun kabul edilebilmektedir. Yapay sinir ağlarının görünen bu başarısının yanında, önermenin karmaşık hatta imkansız olduğu durumlar için, doğrudan bir model içermemesi pek çok alanda kullanılabilirlik açısından umut vadetmektedir.

### 4. KAYNAKLAR

- [1] Ören T., Üney T., Çölkesen R. (Editörler), (2006), Türkiye Bilişim Ansiklopedisi T.B.V., Papatya Yayıncılık.
- [2] Elmas, Ç., (2010), Yapay Zeka Uygulamaları, Seçkin Yay. San. Tic. Ve A.Ş.
- [3] Karaboğa, D., (2004), Yapay Zeka Optimizasyon Algoritmaları, Atlas Yay. Dağ. Ltd. Şirketi.
- [4] Öztemel, E., (2006), Yapay Sinir Ağları, Papatya Yayıncılık.
- [5] Jenson, V.G., Jeffreys, G.V., (1977), Mathematical Methods in Chemical Engineering, Academic Press.

- [6] Lübbert, A., Simutis, R., Volk, N., Galvanuskas, V., (2000), Biochemical Process Optimization and Control. Hands-on Course, Martin Luther University, Germany.
- [7] Bailey, J. E., Ollis, D. F., (1986), Biochemical Engineering Fundamentals, McGRAW HILL.
- [8] Kieran, P., Beroviç, M., (Edit.), (2001), Bioprocess Enginneering Course Notes, The European Federation of Biotechnology.
- [9] Dinç, E.; Üstündag, Ö., (2010), Quantitative Analysis of Hydrochlorothiazide And Losartan Potassium in A Binary Mixture by Artificial Neural Network, **FABAD Journal of Pharmaceutical Sciences** [35.3](#) (Sep): 133-141.
- [10] Türközü, M., Tosun, H., (2008), Harran Kili Şişme Potansiyelinin belirlenmesinde Yapay Sinir Ağları ve Çoklu Regresyon Modellerinin Kullanımı, Eng&Arch.Fac. Eskisehir Osmangazi University, Vol. .XXI, No:1.
- [11] Doblea,P., Sandercocka, M., Pasquiera, E. D., Petocz, P., Rouxa, C., Dawson, M., (2003), Classification of premium and regular gasoline by gas chromatography/mass spectrometry, principal component, Forensic Science International,132, 26–39.
- [12] D'Archivio, A., Giannitto, A., Maggi, M. A., Ruggieri, F., (2012), Cross-column retention prediction in reversed-phase high-performance liquid chromatography by artificial neural network modeling, *Analytica Chimica Acta*, Volume 717, 2 March 2012, Pages 52–60.
- [13] Richi, N., Jain, Lakhmi, J., & Ting, B., (2001) Artificial neural networks in biomedical engineering: a review. In *Asia-Pacific Conference on Advance Computation*.
- [14] Gündoğdu, Ö., Kopmaz, O., Ceviz, M.A., (2003), Mühendislik ve Fen Uygulamaları İle MATLAB, Paradigma Akademi.
- [15] Arifoğlu, U., (2005), MATLAB 7.04 SIMULINK ve MÜHENDİSLİK UYGULAMALARI, Alfa Ltd..