



The Use of Radial-Based Artificial Neural Networks in Modelling Drying Kinetics[#]

Adil Koray Yıldız^{1,a,*}, Muhammed Taşova^{2,b}, Hakan Polatcı^{2,c}

¹Department of Biosystem Engineering, Faculty of Engineering and Architecture, Yozgat Bozok University, 66900 Yozgat, Turkey

²Department of Biosystem Engineering, Faculty of Agriculture, Tokat Gaziosmanpaşa University, 60240 Tokat, Turkey

*Corresponding author

ARTICLE INFO	ABSTRACT
[#]This study was presented as an oral presentation at the 1st International Congress of the Turkish Journal of Agriculture - Food Science and Technology (Antalya, TURJAF 2019) <i>Research Article</i> Received : 25/11/2019 Accepted : 29/11/2019 Keywords: Drying Modeling Radial based network Artificial neural networks Drying Kinetics	Drying method is preferred in agricultural products since it provides advantages in many processes such as increasing the strength of products, transporting and storing. It is necessary to estimate the drying behavior of the products in order to achieve the best drying without reducing the product quality. For this reason, many numerical drying models have been developed to estimate the drying kinetics of the products. Recently, artificial neural networks have been widely used for the development of these models. Artificial neural networks are mathematical models that work in a similar way to natural neuron cells. Radial based artificial neural networks are radial based activation functions in the transition to the hidden layer unlike other networks. In this study, modeling of drying kinetics with radial based networks was investigated. For the experiment, red hot pepper (<i>Capsicum annuum</i> L.) was dipped in boiled water and microwave pretreatments and, then dried in the oven at 65°C. The absorbable moisture values were calculated during the drying period. The radial based artificial neural network models were trained with the drying time values as input and the absorbable moisture values as output. The study was carried out with two data sets including all data and only the average. In trainings with all data, R value of the best model was calculated as 0.9566. R was calculated as 0.9998 with average data.

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 8(2): 511-514, 2020

Radyal Tabanlı Yapay Sinir Ağlarının Kurutma Kinetiğinin Modellenmesinde Kullanımı

MAKALE BİLGİSİ	ÖZ
<i>Araştırma Makalesi</i> Geliş : 25/11/2019 Kabul : 29/11/2019 Anahtar Kelimeler: Kurutma Modelleme Radyal tabanlı ağ Yapay sinir ağları Kurutma Kinetiği	Ürünlerin dayanımını artırma, taşıma ve depolama gibi birçok işlemde avantaj sağladığı için tarımsal ürünlerde kurutma yöntemi tercih edilmektedir. Ürün kalitesini düşürmeden en iyi şekilde kurutma işleminin yapılabilmesi için ürünlerin kuruma davranışını tahmin etmek gereklidir. Bu nedenle ürünlerin kuruma kinetiğinin tahmini için birçok sayısal kuruma modeli geliştirilmiştir. Son zamanlarda bu modellerin geliştirilmesi için yapay sinir ağları yaygın olarak kullanılmaktadır. Yapay sinir ağları, doğal sinir hücrelerine benzer şekilde çalışan matematiksel modellerdir. Radyal tabanlı yapay sinir ağları ise diğer ağlardan farklı olarak gizli katmana geçişte radyal tabanlı aktivasyon fonksiyonları bulunduran ağlardır. Bu çalışmada, kurutma kinetiğinin radyal tabanlı ağlar ile modellenmesi araştırılmıştır. Deney çalışması için kırmızı acı bibere (<i>Capsicum annuum</i> L.) kaynamış suya bandırma ve mikrodalga ön işlemleri uygulanarak etüvde 65°C sıcaklıkta kurutulmuştur. Kuruma süresince alınabilir nem oranı değerleri hesaplanmış ve kuruma süresi değerleri giriş, uzaklaştırılabilir nem oranı değerleri ise çıkış olacak şekilde Radyal Tabanlı Yapay Sinir Ağ modelleri eğitilmiştir. Tüm veri ve aynı sürelerde ölçülen değerlerin ortalamasıyla oluşturulan ortalama veri ayrı ayrı denenmiştir. Tüm veri ile olan eğitimlerde R değeri 0,9566; ortalama ile olanlarda 0,9998 olarak hesaplanmıştır.

^a adilkoray.yildiz@bozok.edu.tr

^b <https://orcid.org/0000-0002-6472-5276>

^c muhammed.tasova@gop.edu.tr

^d <https://orcid.org/0000-0001-5025-0807>

^e hakan.polatci@gop.edu.tr

^f <https://orcid.org/0000-0002-2071-2086>



Giriş

Kurutma; meyve, sebze ve otların muhafazası için uygulanan en eski yöntemlerden birisidir. Kurutma işlemi ile üründen nem uzaklaştığı için raf ömürleri uzamakta, taşıma işlemlerinde kolaylık ve depolama için ise daha az yer kaplayan ürünler elde edilmesi açısından önemlidir (Dandamrongrak ve ark., 2002; Ando ve ark., 2019). Bunun yanında, ürünün nem içeriği azaldığı için mikrobik oluşum engellenmekte ve ürünlerin fiziksel, kimyasal ve biyolojik özelliklerindeki değişiklikler de azalmaktadır (Sanjairaj, ve ark., 2012). Birçok kurutma yöntemi bulunmaktadır. Bunların başında geleneksel doğal kurutma yöntemi gelmektedir. Bu yöntemin enerji ve iş gücü açısından oldukça avantajlı olduğu bilinmekle beraber, temiz olmayan son ürün ve uzun kuruma süresi gibi dezavantajları da vardır (Göztok ve İçier, 2017). Yapay konvektif kurutma yöntemlerinde ise doğal kurutma yöntemlerindeki olumsuzluklar ortadan kalmakta ve daha kısa sürede kuru ürün elde edilebilmektedir (Azoubel ve ark., 2010; Ozuna ve ark., 2014). Bununla beraber etkili kurutma için ürünlere kurutulmadan önce bazı fiziksel ve/veya kimyasal ön işlemler uygulanabilmektedir. Yapılacak ön işlemler üründe homojen bir şekilde ısıнын dağılmasını dolayısıyla kalite özelliklerini korumada avantaj sağlamakta aynı zamanda gereksiz uzun kuruma süreleri ve büzüşme gibi durumların da önüne geçilmesine katkı sağlamaktadır (Salim ve ark., 2016). Kurutma yönteminin iyi belirlenmesi ürünün renk, kuruma süresi ve biyoaktif madde gibi kalite kriterleri açısından çok önemlidir. Bu sebeple kurutmanın kontrol altında yapılması hem ürünün besin değerlerinde oluşan kaybın azaltılması hem de sağlıklı bir şekilde bozulmadan depolanabilmesi için önem arz etmektedir. Kurutmanın kontrol altında yapılması için ürünlerin kuruma davranışlarının tahmin edilebilmesi gerekir. Bunu sağlamanın bir yolu kuruma eğrileri oluşturmak ve kuruma süreleri hakkında bilgi edinebilmek için matematiksel modelleri kullanmaktır (Akpınar, 2006; Doymaz, 2009; Fan ve ark., 2014; Amiri Chayjan ve ark., 2015; Salim ve ark., 2016). Kullanılan bu deneysel modeller kurutma işlemlerinin kontrol edilmesinin yanında, kurutucuların iyileştirilmesinde veya yeni bir kurutucunun tasarımında kullanılabilmektedir.

Yapay Sinir Ağları (YSA) doğal sinir hücrelerinin çalışma prensiplerinden ilham alınarak geliştirilmiş “öğrenebilen” matematiksel modellerdir. YSA’lar nöron denilen sinir hücrelerinin birbiri ile olan ilişkilerine benzer ilişkiler kuran fonksiyonlar ağıdır. Son zamanlarda bilgisayar teknolojilerinin gelişimine paralel olarak birçok alanda yaygınlaşmışlardır (Akkaya, 2007). Bilim ve mühendislikte, özellikle regresyon ve sınıflandırma problemleri için doğru ve hızlı çözümler vermektedirler. Kurutma teknolojileri açısından YSA’lar kurutma kinetiğinin modellenmesi, kurutucu tasarım ve optimizasyonu, süreç kontrolü, enerji kontrolü gibi birçok amaçla kullanılmaktadır (Yıldız ve ark. 2013). Örneğin Erentürk ve ark. (2004) yaptıkları kurutma çalışmasında geliştirdikleri YSA modelinin regresyon analizini yapmışlardır. Yıldız ve ark. (2015) Muz meyvesinin farklı dilim kalınlıklarında ve farklı kurutma şartlarındaki

kurutma kinetiğini YSA ile modellemişlerdir. Radyal tabanlı yapay sinir ağları (RTYSA) ise diğer ağlardan farklı olarak gizli katmana geçişte radyal tabanlı aktivasyon fonksiyonları bulunduran ağlardır (Okkan ve Dalkılıç, 2012).

Bu çalışmada farklı ön işlemler uygulanan kırmızı biber örnekleri kurutulmuş ve belirli zaman aralıklarında uzaklaştırılabilir nem oranları hesaplanmıştır. Zaman ve nem oranları kullanılarak RTYSA modelleri eğitilmiş kurutma kinetiğini en iyi tahmin eden ağ belirlenerek RTYSA’nın kurutma kinetiğinin modellenmesindeki başarısı araştırılmıştır.

Materyal ve Metot

Çalışmada kurutma materyali olarak kırmızı acı biber (*Capsicum annuum L.*) seçilmiştir. Kırmızı acı biber taze veya kurutulmuş olarak yaygın bir şekilde kullanılmaktadır. Biber raf ömrü kısa olan bir ürün olup hasat edildikten sonra uygun koşullarda işlenmez veya hızlı tüketilmez ise usun süre dayanım göstermemektedir. Bu nedenle önemli bir kurutma ürünüdür.

Ürünün başlangıç nem içeriğini belirlenmek için ortalama 25 ± 2 g örnek, 70°C ’de ağırlık değişimi sabitlenene kadar kurutulmuştur (Yağcıoğlu, 1999). Nem içeriği belirlendikten sonra taze kırmızı acı biber örnekleri ön işlemlerden geçirilmiştir. Kurutma işlemine başlamadan önce kaynamış suda sırasıyla 1, 3 ve 5’er dakika ve mikrodalga fırında (MD-GD23; Vestel, İstanbul) 360 W güç değerinde sırasıyla 1, 2 ve 3’er dakika sürelerinde bekletme ön uygulamaları yapılmıştır.

Ön işlem yapılmış örnekler 3’er tekrerrör olmak üzere etüvde (ST-120; Şimşek Labortechnik, Ankara) kabin iç sıcaklığı 65°C ’ye ayarlanmış bir kurutma ortamında kurutma işlemleri gerçekleştirilmiştir. Kurutma işleminde örneklerin son nem içerikleri yaş baza göre %10-%15 nem seviyelerine kadar kurutulmuştur. Ürünlerin süreye bağlı ağırlık değişimini tespit edebilmek için örnekler onar dakika aralıklarla çıkartılarak 0,01 g hassasiyetindeki terazi ile tartılmış ve uzaklaştırılabilir nem oranı (Mr) Eşitlik 1’ deki formüle göre hesaplanmıştır (Haq ve ark., 2015).


$$Mr = (M - M_e) / (M_0 - M_e) \quad (1)$$

Eşitlikte M anlık, M_0 ilk ve M_e ise denge durumundaki ürün nem içeriklerini göstermektedir. Sonuç olan Mr ise uzaklaştırılabilir nem oranıdır.

Mr değerleri çıkış, hesaplandığı andaki dakika cinsinden kuruma süresi giriş olacak şekilde iki veri hazırlanmıştır. İlkinde tüm Mr değerleri veriye dahil edilip aynı olanlar silinmiştir. İkincisi aynı ölçüm zamanlarındaki tekrerrörlerin ortalaması alınarak her ölçüm zamanı için tek Mr değeri olacak şekilde hazırlanmıştır.

RTYSA yapısı, diğer yapay sinir ağlarından farklı olarak eğitim sürecinde belirlenmektedir. Eğitimin her bir devrinde gizli katmana radyal aktivasyon fonksiyonuna sahip bir nöron eklenir. Nöron sayısı en fazla örnek sayısı

kadar olabilir. Çıkış katmanında ise doğrusal fonksiyona sahip çıkış sayısı kadar nöron olur. Bu çalışmada tek Mr değeri için bir nöron bulunmaktadır. Eğitim durdurma kriteri olarak hata eşiği sıfır seçilmiştir. Yani hata sıfırlanana veya örnek sayısı kadar nöron eklenene kadar eğitim devam etmiştir. Diğer bir eğitim parametresi olan yayılma katsayısı yinelemeli olarak artırılmış ve eğitim başarısına göre belirlenmiştir. Şekil 1’de yinelemeli eğitimin nasıl yapıldığı gösterilmiştir.



Şekil 1 En başarılı ağ için araştırma algoritması
Figure 1 Research algorithm for the most successful network

İki veri de %70 eğitim, %15 doğrulama ve %15 test seti olacak şekilde rasgele ayrılmıştır. Her bir yinelemede dağılım katsayısı bir artırılıp yeni bir ağ, eğitim seti ile eğitilmiştir. Elde edilen ağ ile doğrulama seti tahmin edilmiş, tahminler ile setteki Mr değerleri karşılaştırılarak R değerleri hesaplanmıştır. Doğrulama seti için en yüksek R değerini veren ağ en başarılı olarak seçilmiştir. Bu ağ ile eğitimin hiçbir aşamasında kullanılmayan test seti tahmin edilmiş, bu tahmin sonucunda hesaplanan R değeri ağın nihai başarısı olarak belirlenmiştir. Başta belirlenen her iki veri için de (tümü ve ortalama değerler) aynı işlem tekrarlanarak en başarılı ağ modeli bulunmuştur.

Bulgular


Kurutma denemeleri en uzun 140 dakika sürmüştür. Kurutma başlangıcından itibaren alınan ölçümler ile 196 benzersiz örnek elde edilmiştir. Tüm veri için 138 eğitim, 29’ar adet doğrulama ve test seti ayrılmıştır. Ortalama veri için 3’er doğrulama ve test, 9 eğitim olmak üzere toplam 15 örnek oluşturulmuştur. Her iki veri için yayılma katsayısı 0’dan 100’e birer artırılarak RTYSA modelleri eğitilmiş ve her bir model için doğrulama seti ile R değerleri hesaplanmıştır. Şekil 2A’daki grafikte tüm veri için Şekil 2B’dekinde ise ortalama veri için elde edilen sonuçlar görülmektedir.

Tüm veri için doğrulama R değeri 0,9532 olan 80 yayılma katsayılı ağ seçilmiştir. Ağ katmanında 138 nöron vardır (Şekil 3A). Ortalama veri ile yapılan eğitimlerde ise yayılma katsayısı 27 seçilen ağda R değeri 0,9998 olarak elde edilmiştir. Şekil 3B’de görüldüğü gibi bu ağ 9 radyal nörona sahiptir.


Çizelge 1’de iki her iki veri için elde edilen en başarılı iki ağın özellikleri ve doğrulama, test ve tüm veri seti ile hesaplanan R değerleri verilmiştir.

Tüm veri ile eğitilen ağ 138 nöronlu iken ortalama veri ile eğitilen 9 nöronlu olmuştur. Nöron sayısının artması karmaşıklığı dolayısıyla gerekli belleği arttırmaktadır. En başarılı RTYSA modelleri ile eğitim, doğrulama ve test setlerinin tümünün tahmini yapıldığında elde edilen R grafikleri tüm veri için Şekil 4A ve ortalama veri için Şekil 4B’de verilmiştir.

Şekil 5’te bu modellerle çizdirilen kuruma eğrileri görülmektedir. Hata farkına rağmen her iki RTYSA modeli için de kuruma eğrileri benzerlik göstermektedir.




Şekil 2 Doğrulama seti R değeri sonuçları A: Tüm veri için, B: Ortalama veri için
Figure 2 R value results for validation set A: For all data B: For average data




Şekil 3 Eğitilen en başarılı ağ yapıları A: Tüm veri için B: Ortalama veri için

Figure 3 Most successful trained network structures A: For all data B: For average data



Şekil 4 En başarılı RTYSA R grafikleri A: Tüm veri için B: Ortalama veri için

Figure 4 Most successful RBANN R graphs A: For all data B: For average data



Şekil 5 Modellerle oluşturulan kuruma eğrileri
Figure 5 Drying curves created by models

Çizelge 1. Her iki veri için en iyi ağların özellik ve R değeri hesaplamaları

Table 1. Property and R-value calculations of the best networks for both data

Veri	Tüm	Ortalama
Nöron sayısı	138	9
Yayılma	80	27
R		
Doğrulama	0,9532	0,9998
Tümü	0,9594	0,9995
Test	0,9566	0,9998

Sonuç ve Tartışma

RTYSA ile kurutma kinetiği ortalama Mr değerleri ile oluşturulan veri kullanılarak R değeri 0,99 üstünde olacak şekilde başarılı modellenebilmiştir. Daha çok örnek sayısı olmasına rağmen tüm veri ile yapılan çalışmalarda R değerleri 0,95-0,96 aralığında hesaplanmıştır. YSA eğitimi de kullanılan veri setinde örneğin artışı daha başarılı ağlar eğitilmesini sağlamaktadır (Alpaydın, 2010). Daha fazla örnek olmasına rağmen tüm veri ile elde edilen ağın ortalama ile elde edilen kadar başarılı olamamasının nedeni örneklerde aynı girişler için birçok farklı çıkış değerlerinin bulunmasıdır (Bknz. Şekil 4A).

Salim ve ark. (2016) da belirttiği gibi farklı ön işlemler uygulandığında örneklerin kuruma karakterleri de değişmiştir ve aynı kuruma sürelerinde farklı Mr değerleri hesaplanmıştır. Bu durum elde edilen ağlarda hatanın artmasına sebep olmuştur. Yıldız vd. (2015) çalışmasına benzer olarak kategorize edilmiş ön işlemler sayısallaştırılarak modele bir giriş olarak verilirse aynı girişe farklı çıkışlar oluşması sorunu giderilmiş olacaktır. Bu sayede geliştirilmiş daha başarılı RTYSA eğitilmesi mümkün olacaktır.

Kaynaklar

Ando Y, Hagiwara S, Nabetani H, Sotome I, Okunishi T, Okadome H, Orikasa T, Tagawa A. 2019. Effects of prefreezing on the drying characteristics, structural formation and mechanical properties of microwave-vacuum dried apple. *Journal of Food Engineering*. 244:170-177.

Akkaya G. 2007. Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları. Atatürk Üniversitesi Ziraat Fakültesi Dergisi. 38(2):195-202.

Akpınar EK. 2006. Mathematical modelling of thin layer drying process under open sun of some aromatic plants. *Journal of Food Engineering*. 77:864–870.

Alpaydın E. 2010. Introduction to machine learning. The MIT Press. Cambridge.

Amiri CR, Kaveh M, Khayati S. 2015. Modeling Drying Characteristics of Hawthorn Fruit under Microwave-Convective Conditions. *J. Food Process. Preserv.* 39:239–253. <https://doi.org/10.1111/jfpp.12226>

Azoubel PM, Baima MDAM, Amorim MDR, Oliveira SSB. 2010. Effect of ultrasound on banana cv Pacovan drying kinetics. *Journal of Food Engineering*. 97(2):194-198.

Dandamrongrak R, Young G, Mason R. 2002. Evaluation of various pre-treatments for the dehydration of banana and selection of suitable drying models. *J. Food Eng.* 55:139–46. [https://doi.org/10.1016/S0260-8774\(02\)00028-6](https://doi.org/10.1016/S0260-8774(02)00028-6)

Doymaz I. 2009. Mathematical modelling of thin-layer drying of kiwifruit slices. *J. Food Process.* 33:145–160.

Erentürk K, Erentürk S, Tabil LG. 2004. A comparative study for the estimation of dynamical drying behavior of *Echinacea angustifolia*: Regression analysis and neural network. *Computer and Electronics in Agriculture*. 45:71–90. <https://doi.org/10.1016/j.compag.2004.06.002>

Fan K, Chen L, He J, Yan F. 2015. Characterization of Thin Layer Hot Air Drying of Sweet Potatoes (*Ipomoea batatas* L.) Slices. *J. Food Process. Preserv.* 39:1361–1371. <https://doi.org/10.1111/jfpp.12355>

Göztok SP, İçier F. 2017. Karbon Fiber Destekli Kabin Kurutucuda Farklı Sıcaklıklarda Elma Dilimlerinin Kurutulmasının İncelenmesi: Kurutma Karakteristikleri ve Performans Değerlendirmesi. *Akademik Gıda*. 15(4):355-367.

Haq R, Kumar P, Prasad K. 2015. *Journal of Food Processing and Preservation*. doi: 10.1111/jfpp.12785.

Okkan U, Dalkılıç HY. 2012. Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi. *İMO Tek. Dergi*. 379:5957–5966.

Ozuna C, Alvarez-Arenas TG, Riera E, Carcel JA, Garcia-Perez JV. 2014. Influence of material structure on air-borne ultrasonic application in drying. *Ultrasonics Sonochemistry*. 21(3):1235-1243.

Salim NSMD, Gariépy Y, Raghavan V. 2016. Hot air drying and microwave-assisted hot air drying of broccoli stalk slices (*Brassica oleracea* L. var. *Italica*). *Journal Food Process. Preservation*, 10.1111/jfpp.12905. Viyaja

Sanjairaj V, Iniyan S, Goic R. 2012. A review of solar drying technologies. *Renew. Sustain. Energy Rev.* 16:2652–2670. <https://doi.org/10.1016/j.rser.2012.01.007>

Yağcıoğlu A. 1999. Tarımsal Ürünleri Kurutma Tekniği. Ege Üniversitesi ziraat fakültesi yayınları No: 536. Bornova, İzmir.

Yıldız AK, Tarhan S, Özgüven MM. 2013. Tarımda Yapay Zekâ Uygulamaları. 28. Ulusal Tarımsal Mekanizasyon Kongresi 4-6 Eylül. Konya. 191–196.

Yıldız AK, Polatci H, Uçun H. 2015. Farklı Kurutma Şartlarında Muz (*Musa cavendishii*) Meyvesinin Kurutulması ve Kurutma Kinetiğinin Yapay Sinir Ağları ile Modellenmesi. *Tarım Makinaları Bilimi Dergisi*. 11:173–178.