

Rasgele Yapay Sinir Ağları : Dünden Bugüne

Tansu Küçüköncü

Danışman, Eskişehir

e-posta : Tansu.Kucukoncu@gmail.com

Özetçe

Bu çalışmada Erol Gelenbe tarafından geliştirilen Rasgele Yapay Sinir Ağı modelinin kuramsal gelişim, öğrenme algoritması, donanımla gerçekleştirme, ve uygulama çalışmaları araştırılıp derlenmiştir. Bu çalışmanın amacı, RYSA altyapısı oluşturulmasına yönelik olarak RYSA'yı tanıtmak ve RYSA çalışmalarına kılavuzluk etmektir. RYSA, özellikle tekrarlamalı bir yapıda kullanıldığında, standart sinir ağı modellerine kıyasla, organik sinir yapılarına daha yakındır, ve hesaplama yönünden daha elverişlidir.

1. Giriş

Rasgele Yapay Sinir Ağı (RYSA) modeli ve öğrenme algoritması hakkında detaylı bilgi, Küçüköncü ve Gebizlioğlu'nun bu kongredeki "Matematiksel Morfolojik İşlemlerin Rasgele Yapay Sinir Ağlarıyla Gerçekleşmesi" [83] başlıklı çalışmasında bulunabilir.

Yapay sinir ağları ve bağlantılı yöntemlerin ilişkili bellek [24], bilgisayar iletişimi, kombinatorik, eniyileme problemleri, sistem tanıma ve denetleme, fonksiyon yaklaşım, örüntü tanıma [9, 10], ve işaret işleme gibi, problemlerin açıkça tanımlanamadığı ya da formüleleştirilebilmesinin güç olduğu, doğrudan gerçek yaşamdaki mühendislik uygulamaları için güçlü gereçler olduğu kanıtlanmıştır. Yapay sinir ağlarının, diğer yöntemlere üstünlük sağlayan özellikleri vardır. Paralel mimarileri nedeniyle, hesaplamadaki pek çok güçlüğü aşabilirler. Örnek veriler üzerinde eğitildikleri için, yeni girdilerin işleniş sırasında da eğitimin devam etmesine izin vererek, girdi verilerindeki değişikliklere daha çok uyum sağlayabilirler. Yüksek bağlantı seviyesi, yapay sinir ağlarının kendiliğinden organize olabilmelerine olanak sağlar. Bu durum, verilerin yapısı önceden bilinmediğinde yarar sağlar. Yapay sinir ağlarıyla sinirsel biyolojik sistemler arasındaki benzerlik nedeniyle, bilinen biyolojik ağlar, yapay sinir ağlarının tasarımında kullanılabilir [35].

2. RYSA ile Formüllü Sinir Ağlarının Benzerlikleri

Bir *formüllü sinir ağı*, n sinirden oluşan bir kümedir. Her bir sinirin durumu, $y(i)$, bir *sigmoid* fonksiyonu, $y(i) = f(x(i))$, kullanılarak bulunur. Girdi imgesi,

$$x(i) = \sum_j w_{ji} \cdot y(j) - \theta_i, \quad (1)$$

ağdaki diğer sinirlerin durumlarının ağırlıklı toplamlarından oluşur. Burada, w_{ji} , ağırlıklar, θ_i ise, sinir gizil gücü için eşik değeridir. $f(\cdot)$ 'nin en basit biçimi, *birim basamak fonksiyonudur*.

Çok katmanlı formüllü sinir ağları, ileri beslemeli ağların bir alt kümesidir. İleri beslemeli ağları göz önünde bulundurduğumuzda, RYSA için $\lambda^+(i)$, ve $\lambda^-(i)$ 'nin çözümlerinin varlığı ve teklifi kolayca garantilenebilmektedir. Bu durumda,

RYSA ile formüllü ağ arasında kolayca ilişki kurabiliriz [22, 23, 24, 28].

$\lambda^+(i)$, sinirin eşik değerine, θ_i , karşılık gelmektedir. Çıktı olmayan sinirler için, $d(i) = 0$ 'dır. Eğer $w_{ij} > 0$ ise $w_{ij} \cdot r(i) \cdot p^+(i, j) = w_{ij}$ ile, eğer $w_{ij} < 0$ ise $w_{ij} \cdot r(i) \cdot p^-(i, j) = |w_{ij}|$ ile ifade edilir. Ateşleme sıklığı,

$$r(i) = \sum_j |w_{ij}| \quad (2)$$

'dır. Çıktı sinirleri içinse $d(i) = 1$, ve $r(i)$, atanan uygun bir değerdir.

Rasgele ağa, dış parametreleri uygulamak için, (+) imgelerin, sinirlere gelme sıklığı, $\Lambda(i)$, kullanılır. Formüllü sinir ağına dışarıdan gelen imgeler, 2 değerlikli olduğunda, 0 imgesi, $\Lambda(i) = 0$ yaparak, 1 imgesiyse, $\Lambda(i) = \Lambda$ yaparak ifade edilebilir. Λ değeri, çıktı sinirlerinde istenen etkileri yaratacak şekilde belirlenir. Böylece, RYSA'nın, çıktı sinirlerinin ateşleme sıklıkları ve (+) imgelerin geliş sıklıkları haricindeki, tüm parametreleri, formüllü ağın parametrelerine denk bir şekilde seçilebilir (bkz. Şekil 1).

Formüllü ağın durumu, $Y(y_1, \dots, y_n)$ ($y_i \in \{0, 1\}$), rasgele sinirlerin olasılıklarıyla ifade edilir.

$$z_i = \lim_{t \rightarrow \infty} P[k_i(t) > 0] \quad (3)$$

olmak üzere, y_i ile z_i ilişkilendirilebilir. Bu durumda, $y_i=0 \Leftrightarrow z_i < 1 - \alpha$, ve $y_i=1 \Leftrightarrow z_i \geq 1 - \alpha$ ifadelerini sağlayacak bir *kesme noktasına* gereksinim vardır.

Bu yöntem, ileri beslemeli olmayan herhangi bir sinir ağına da uygulanabilir. $d(i)$, aynı zamanda, biyolojik sinir ağlarında var olan *kaçak akımları* ifade etmek için kullanılabilir. Bu etki, dikkate alınmak istendiğinde, $r(i) \cdot d(i)$, i sinirinde elektrik gizil gücünün kaybı sıklığını verecektir.

Rasgele sinir ağlarının özellikleri, özetlenirse :

a) Biyofiziksel sinir ağlarındaki imgelerin iletilmesini, daha yakın bir şekilde temsil eder. Çünkü biyofiziksel sinir ağlarında imgeler, sürekli imgeler yerine, darbeler halinde dolaşırlar,

b) Hesaplama açısından etkindir,

c) Her sinir, basit bir şekilde bir sayaçla ifade edilebileceği için, benzetişiminin yapılması ve donanımla gerçekleştirilmesi kolaydır,

d) Sinir gizil-gücünü, dolayısıyla uyarılma seviyesini, iki değerlikli bir değişken yerine, bir tam sayı olarak ifade eder. Bu sayede, dizgenin durumu hakkında daha detaylı bilgi edinilebilir. Bir sinirin gizil-gücü pozitifse, ateşleme durumunda şeklinde yorumlanır.

2. Rasgele Yapay Sinir Ağı Çalışmaları

Gelenbe [22] tarafından RYSA modelinin geliştirilmesinin ardından, Gelenbe [23]'deki çalışmasında modelin ileri beslemeli olmadığı durumlarda da kararlı olabildiğinin koşullarına açıklık getirmiştir. Gelenbe and Stafylopatis [58], homojenlik, yani tüm sinirlerin aynı stokastik karakteristiğe sahip olması, söz konusu olduğunda modelin genel davranışını incelemiştir. RYSA öğrenme algoritmasının geliştirilmesinin [28, 29] ardından uygulamaya yönelik çalışmalar ortaya çıkmaya başlamıştır. Gelenbe and Halıcı [42] ve Bakırcıoğlu and Koçak [12], RYSA uygulamalarının bir kısmını gözden geçirmişlerdir.

RYSA modelinin hem ileri-beslemeli hem de tamamen tekrarlamalı mimaride kullanıldığı çeşitli uygulamalarda başarılı olduğu kanıtlanmıştır. Pek çok problemde, RYSA, eğitim için kullanılan veri seti, gerçek test verilerine göre küçük olduğunda bile, güçlü genelleştirme becerileri sergiler. Ağırlık güncelleme sürecindeki hesaplama kolaylığına bağlı olarak, modelde hızlı öğrenme elde edilir. RYSA ile bugüne dek yapılan uygulama çalışmaları özetlenecek olursa :

a) Görüntü işleme [4, 5, 8, 11, 34, 83, 85, 90] : bölütleme [86], hareketsiz görüntü sıkıştırma [13, 14, 15, 61, 62, 63, 64, 89], hareketli görüntü sıkıştırma [13, 14, 37, 64], gelişmiş görüntü büyütme [8, 11], algılayıcı görüntü birleştirme [11, 34, 79], biyomedikal görüntüleme [38], desen yaratma [4, 5], modelleme [83, 85], matematiksel morfoloji [83, 85], şekil analizi [82, 83],

b) Örüntü tanıma [9, 10, 82, 87] : manyetik rezonans görüntülerinin sınıflandırılması [38], otomatik hedef algılama [5, 8, 9], mayın bulma [1, 36, 45, 50, 79, 80], hatalı ürün bulma [79],

c) Eniyileme [30, 35, 47, 66],

d) İlişkili bellek [24, 27, 59, 60, 76, 77, 78, 84],

e) Ağlar [40, 46, 75, 81, 91],

f) Kuyruk kuramı [2, 20, 21, 31, 32, 33, 39, 41, 48, 49, 51, 54, 55, 56, 57, 73, 74],

g) Diğer : benzetişim [65], imge algılama ve sınıflama [43], imge işleme [19], fonksiyon yaklaşımlama [52, 53], matematiksel morfoloji [82], RYSA'nın donanımla gerçekleşmesi [6, 7, 16, 17, 18, 22, 71, 88].

4. RYSA Öğrenme Algoritmasıyla İlgili Çalışmalar

Gelenbe'nin tekrarlamalı rasgele ağ modeli için, geri sürüklenme tipinde [44, 84], karesel hata fonksiyonunun kademeli azalmasını kullanan bir öğrenme algoritması geliştirmesinin ardından, bu algoritmanın geliştirilmesi yönünde çeşitli çalışmalar yapılmıştır (bkz. [67, 85]). Halıcı [68], bir amaca ulaşmak için bir serileşmiş kararlar dizisine bir *destekli öğrenme* yöntemi uygulanmasını önermiştir. Burada serileşmiş kararların toplam maliyetinin eniyelenmesi hedeflenmektedir. Bu amaçla, RYSA, sağlanan bir *destek fonksiyonuyla* birlikte, sistemi modellemede kullanılır. Öğrenme yönteminin performansı, labirent öğrenme problemine uygulanarak sınanmıştır. Benzetişim sonuçları, sistemin performansının, büyük ölçüde, seçilen destek fonksiyonuna bağlı olduğunu göstermiştir. Destek fonksiyonu, *son zamanlarda oluş etkisi* dikkate alındığında, oldukça tatmin edici sonuçlar elde edilmiştir. Bu yaklaşım, ödüllendirmeye dayalıdır, ve durağan ortamda performansı iyidir. Fakat ortam durağan olmadığında, *tepkisizleşme*, dikkate alınması gereken önemli bir problem haline gelmektedir.

Halıcı [69]'de destekli öğrenme yöntemini, desteğin dahili tahminini dikkate alan bir ağırlık güncelleme kuralıyla genişletmiştir. Böylece, en yüksek ödüllü harekete bir şekilde

yönelimle sonuçlanan bir tepkisizleşme mümkün olmuştur. Genişletme, *ödüllü öğrenmeden, ödüllü/cezalı öğrenmeye* geçiş şeklinde olmuştur. Yöntemin davranışı, öğrenen özdeşlerde kullanılan doğrusal ağırlık güncelleme kuralıyla karşılaştırılmıştır. Benzetişim sonuçları, yeni yöntemin performansının doğrusal göre açık bir şekilde üstün olduğunu göstermiştir. Öğrenme aşamasında en iyi ödüle yönelme söz konusudur. Sistem, ortamdaki değişikliklere duyarlıdır. Böylece istenen tepkisizleşme elde edilebilmektedir. Halıcı [69, 70]'te önerilen yöntem, RYSA dışında desteğe dayalı diğer öğrenen özdeşler ve diğer akıllı sistemlerin öğretilmesinde de kullanılabilir.

Gelenbe'nin algoritmasındaki asıl hesaplama işi, bir $n \times n$ matrisin tersinin elde edilmesidir. Halıcı and Karaöz [72], bu matrisin tersinin bir doğrusal terimle yaklaşımını almış, ve bu yaklaşımli algoritmanın etkililiğini, tekrarlamalı RYSA kendiliğinden ilişkili bellek olarak kullanıldığında, sınamıştır. Bunun sonucunda, zaman alıcı ve sıkıcı hesaplamaları ortadan kaldırmak için, ters matrisin yerine doğrusal yaklaşımının başarılı bir şekilde kullanılabilirliği gözlenmiştir. Matrisin "norm"u, $\|A\|$, 1'den küçük olduğunda, ters matrisin yerine, bir seri açılım kullanılabilir. Ters matrisi yaklaşık olarak ifade etmek için seri açılımın ilk iki terimi kullanıldığında, hesaplamalar doğrusal hale gelir, ve bu sayede hesaplamalar kolaylaşır. Norm olarak, A, bir $n \times n$ matris olmak üzere,

$$\|A\| = \max_j \left(\sum_i A_{ij} \right) \quad (4)$$

kullanılmıştır. Çünkü

$$\sum_j w_{ij} \max_j \left(\frac{1}{r(i) + \lambda_{\min}} \right) < 1 \quad (5)$$

olduğunda, $\|A\| < 1$ koşulu sağlanmaktadır. Bu koşul, uygun λ_{\min} değeri seçilerek sağlanabilir.

$$\|W\| = \max_{1 \leq j \leq n} \sum_{i=1}^n \left| \frac{w_{ij}^+ - w_{ij}^- q_j}{r(i) + \sum_i q_i w_{ij} + \lambda(j)} \right| \quad (6)$$

Böylece,

$$\frac{\partial q_i}{\partial w^+(u, v)} = \gamma^+(u, v) q_u [I + W^1 + W^2 + \dots + W^m + \dots W^\infty] \quad (7)$$

$$\frac{\partial q_i}{\partial w^-(u, v)} = \gamma^-(u, v) q_u [I + W^1 + W^2 + \dots + W^m + \dots W^\infty] \quad (8)$$

olur. Zaman alıcı hesaplamalardan kaçınmak için, bu ifadelerin açılımının sadece ilk m terimi kullanılarak yaklaşımı alınabilir. m'nin büyük değerleriyle performansın artacağı beklenmekle birlikte, m=1 olduğunda hesaplamak oldukça kolaydır. Bu, bir doğrusal yaklaşıma yol açar :


$$\frac{\partial q_i}{\partial w^+(u, v)} = \gamma^+(u, v) q_u [I + W] \quad (9)$$

$$\frac{\partial q_i}{\partial w^-(u, v)} = \gamma^-(u, v) q_u [I + W] \quad (10)$$

Atalay [3], özellikle görüntü desenlerinin yeniden oluşturulmasında kullanılmak üzere, RYSA'nın öğrenmesi için bir karesel en iyileme yöntemi göstermiştir. Bunun genelleştirilebilmesinin mümkün olduğu düşünülmektedir. Önerilen algoritma, RYSA'daki sinirlerin durum eşitliklerinin bir doğrusal sistem biçiminde çözülmesine dayanır. Görüntü desenlerinin yeniden oluşturulması için sistem gereğinden fazla belirlenmiş hale gelir, ve çözüm *Kuhn-Tucker eniyileme koşullarıyla* verilir.

5. Sonuç

Bu çalışmada Erol Gelenbe tarafından geliştirilen Rasgele Yapay Sinir Ağı modelinin [22, 23, 25, 26, 29] ilk kez tanıtıldığı 1989 yılından bugüne kuramsal gelişim, öğrenme algoritması, donanımla gerçekleştirme, ve uygulama çalışmaları araştırılıp derlenmiştir. RYSA, özellikle tekrarlamalı bir yapıda kullanıldığında, standart sinir ağı modellerine kıyasla, organik sinir yapılarına daha yakındır, ve hesaplama yönünden daha elverişlidir. Uygulama alanlarının zenginliği cazibesini arttırmaktadır.



Şekil 1. RYSA modeli, etkileşimli gösterim [79].

6. Kaynaklar

[1] Abdelbaki, H., Gelenbe, E. and Kocak, T. 2005. Neural algorithms and energy measures for EMI based mine detection. *J. Differential Equations and Dynamical Systems (DEDS)*, vol.13, no.1, 63-86.

[2] Artalejo, J.R. 2000. G-networks : A versatile approach for work removal in queueing networks. *European J. of Operational Research*, 126, 233-249.

[3] Atalay, V. 1998. Learning by optimization in random neural networks. *Advances in Computer Sciences '98*, Gündükbay, U., Dayar, T., Gürsoy, A., Gelenbe, E. (ed.s), Proc. of the ISCIS '98 (13th), Antalya, Turkey, 143-148.

[4] Atalay, V. and Gelenbe, E. 1992. Parallel algorithm for colour texture generation using the random neural network model. *Int. J. of Pattern Recognition and Artificial Intelligence*, 6 (2), 437-446.

[5] Atalay, V., Gelenbe, E. and Yalabık, N. 1992. The random neural network for texture generation. *Int. J. of Pattern Recognition and Artificial Intelligence*, vol.6, no.1, 131-141.

[6] Aybay, I., Çerkez, C., Halıcı, U. and Badaroğlu, M. 1998. Hardware implementations of neural networks and the random neural network chip (RNNC). *Advances in Computer Sciences '98*, Gündükbay, U., Dayar, T., Gürsoy, A., Gelenbe, E. (ed.s), Proc. of the ISCIS '98 (13th), Antalya, Turkey, 157-161.

[7] Badaroğlu, M., Halıcı, U., Aybay, I. and Çerkez, C. 1997. Digital neural network chip for the random neural network model with programmable architecture. *Proc. of ISCIS '97*, Antalya, Turkey, 412-418.

[8] Bakırcıoğlu, H. and Gelenbe, E. 1997. Enhanced image enlargement with the random neural network. (unpublished).

[9] Bakırcıoğlu, H. and Gelenbe, E. 1998a. Feature-based RNN target recognition. (unpublished).

[10] Bakırcıoğlu, H. and Gelenbe, E. 1998b. Random neural network recognition of shaped objects in strong clutter. *Proc. of SPIE, App. of Art. Neural Networks in Image Proc. 3*, San Jose, California, 22-28.

[11] Bakırcıoğlu, H., Gelenbe, E. and Koçak, T. 1997. Image enhancement and fusion with the random neural network model. *Elektrik*, vol.5, no.1, 65-77.

[12] Bakırcıoğlu, H. and Koçak, T. 2000. Survey of random neural network applications. *European J. of Operations Research*, 126, 319-330.

[13] Cramer, C. 1998. Neural networks for image and video compression : A review. *European J. of Operational Research*, 108, 266-282.

[14] Cramer, C., Gelenbe, E. and Bakırcıoğlu, H. 1996. Low bit-rate video compression with neural networks and temporal subsampling. *Proceedings of the IEEE*, vol.84, no.10, 1529-1543.

[15] Cramer, C., Gelenbe, E. and Gelenbe, P. 1998. Image and video compression. *IEEE Potentials*, Feb-March.

[16] Çerkez, C., Aybay, I. and Halıcı, U. 1997a. A digital random neuron realization. *Proc. of the New Trends in Artificial Intelligence and Neural Networks Conf., TAINN '97*, 216-220, Ankara, Turkey.

[17] Çerkez, C., Aybay, I., and Halıcı, U. 1997b. A digital neuron realization for the random neural network model. *Proc. of IEEE IJCNN '97*, Houston, USA, 1000-1004.

[18] Çerkez, C., Aybay, I. ve Halıcı, U. 1997c. Sayısal bir nöron tasarımı. *Proc. of the 7th National Electrical Engineering Congress*, 51-54, Ankara, Turkey.

[19] Fourneau, J.-M. and Gelenbe, E. 1992. Random neural networks with multiple classes of signals. *Neural Networks : Advances and Applications - 2*, Gelenbe, E. (ed.), Elsevier Science Pub. Co., Amsterdam, 83-94.

[20] Fourneau, J.-M. and Gelenbe, E. 2004. Flow equivalence and stochastic equivalence in G-networks. *Computational Management Science*, vol.1(2), 179-192.

[21] Fourneau, J.-M., Kloul, L. and Verchere, D. 2000. Multiple class G-networks with list oriented deletions. *European J. of Operational Research*, 126, 250-272.

[22] Gelenbe, E. 1989. Random neural networks with negative and positive signals and product form solution. *Neural Computation*, vol.1, no.4, 502-511.

[23] Gelenbe, E. 1990. Stability of the random neural network model. *Neural Computation*, vol.2, no.2, 239-247.

[24] Gelenbe, E. 1991a. Distributed associative memory and the computation of membership functions. *Information Sciences*, vol.57-58, 171-180.

[25] Gelenbe, E. 1991b. Theory of the random neural network model. *Neural Networks : Advances and Applications*, Gelenbe, E. (ed.), North-Holland.

[26] Gelenbe, E. 1991c. Product-form queueing networks with negative and positive customers. *J. of Applied Probability*, 28, 656-663.

[27] Gelenbe, E. 1992. Generalised associative memory and the computation of membership functions. *Neural Networks : Advances and Applications - 2*, Gelenbe, E. (ed.), Elsevier Science Pub. Co., Amsterdam, 129-140.

[28] Gelenbe, E. 1993a. The random neural network model. *Elektrik*, vol.1, no.1, 27-46.

[29] Gelenbe, E. 1993b. Learning in the recurrent random neural network. *Neural Computation*, vol.5, no.1, 154-164.

[30] Gelenbe, E. 1993c. Hopfield energy of random nets. (unpublished).

[31] Gelenbe, E. 1993d. G-networks with triggered customer movement. *J. of Applied Probability*, 30, 742-748.

- [32] Gelenbe, E. 1993e. G-networks with signal and batch removal. *Probability in Engineering and Information Sciences*, 7, 335-342.
- [33] Gelenbe, E. 1994. G-networks : A unifying model for neural and queueing networks. *Annals of Operations Research*, 48, 433-461.
- [34] Gelenbe, E., Bakircioğlu, H. and Koçak, T. 1998. Image processing with the random neural network. *Proc. of SPIE, App. of Art. Neural Networks in Image Proc. 3*, San Jose, California, 22-28.
- [35] Gelenbe, E. and Batty, F. 1992. Minimum graph vertex covering with the random neural network. Balci, O., Sharda, R., Zenios, S. (ed.s). *Computer Science and Operations Research*, Pergamon Press, 139-147.
- [36] Gelenbe, E. and Cao, Y. 1998. Autonomous search for mines. *European J. of Operational Research*, 108, 319-333.
- [37] Gelenbe, E., Cramer, C. and Sungur, M. 1996. Traffic and Video Quality in Adaptive Neural Compression. *Multimedia Systems*, 4, 357-369.
- [38] Gelenbe, E., Feng, Y. and Khrishnan, K. 1996. Neural network methods for volumetric magnetic resonance imaging of the human brain. *Proceedings of the IEEE*, 84, 1488-1496.
- [39] Gelenbe, E. and Fourneau, J.-M. 2002. G-Networks with resets. *Performance Evaluation*, vol.49, 171-191.
- [40] Gelenbe, E., Ghanwani, A. and Srinivasan, V. 1997. Improved neural heuristics for multicast routing. *IEEE J. on Selected Areas in Communications*, vol.15, no.2, 147-155.
- [41] Gelenbe, E., Glynn, P. and Sigman, K. 1991. Queues with negative arrivals. *J. of Applied Probability*, 28, 245-250.
- [42] Gelenbe, E. and Halıcı, U. 1994. *The Random Neural Network*. (Preliminary Copy, unpublished, 234).
- [43] Gelenbe, E., Harmancı, K. and Krolik, J. 1998. Learning neural networks for detection and classification of synchronous recurrent transient signals. *Signal Processing*, 64 (3).
- [44] Gelenbe, E. and Hussain, K.F. 2002. Learning in the multiple class random neural network. *IEEE Trans. on Neural Networks*, vol.13, no.6, Nov., 1257-1267.
- [45] Gelenbe, E. and Koçak, T. 2000. Area-based results for mine detection. *IEEE Trans. on Geoscience and Remote Sensing*, vol.38, no.1, 12-24.
- [46] Gelenbe, E., Kotia, S. and Krauss, D. 1997. Call establishment overload in large ATM networks. *Performance Evaluation*, 31, 33-49.
- [47] Gelenbe, E., Koubi, V. and Pekergin, F. 1994. Dynamical random neural network approach to the travelling salesman problem. *Elektrik*, vol.2, no.1, 1-10.
- [48] Gelenbe, E. and Labeled, A. 1998. G-Networks with multiple classes of signals and positive customers. *European J. of Operation Research*, 108 (2), 293-305.
- [49] Gelenbe, E. and Labeled, A. 2000. The first decade of G-Networks. *European J. of Operation Research*, 126 (2), 231-232.
- [50] Gelenbe, E., Labeled, A. and Cao, Y. 1998. Autonomomus search for mines. *European J. of Operation Research*, 108 (2), 319-333.
- [51] Gelenbe, E., Labeled, A. and Shachnai, H. 2000. On G-Networks and resource allocation in multimedia systems. *European J. of Operation Research*, 126 (2), 308-318.
- [52] Gelenbe, E., Mao, Z.H. and Li, Y.D. 1998. Function approximation with spiken random networks. *IEEE Trans. on Neural Networks*, vol.10, no.1, 3-9.
- [53] Gelenbe, E., Mao, Z.-H. and Da-Li, Y. 2004. Function approximation by random neural networks with a bounded number of layers. *J. Differential Equations and Dynamical Systems*, vol.12(1 and 2), 143-170.
- [54] Gelenbe, E. and Mitriani, I. 1980. *Analysis and Synthesis of Computer Systems*. Academic Press, 239, London.
- [55] Gelenbe, E. and Pujolle, G. 1998. *Introduction to Networks of Queues*. (2nd ed.) Wiley, New York, 244.
- [56] Gelenbe, E. and Schassberger, R. 1992. Stability of G-networks. *Probability in Engineering and Information Sciences* 6, 271-276.
- [57] Gelenbe, E. and Shachnai, H. 2000. On G-networks and resource allocation in multimedia systems. *European J. of Operational Research*, 126, 308-318.
- [58] Gelenbe, E. and Stafylopatis, A. 1991. Global behaviour of homogeneous random neural systems. *Applied Math. Modelling*, 15, 535-541.
- [59] Gelenbe, E., Stafylopatis, A. and Likas, A. 1991a. An extended random network model with associative memory capabilities. *Proc. Int. Conf. on Artificial Neural Networks (ICANN'91)*, Helsinki.
- [60] Gelenbe, E., Stafylopatis, A. and Likas, A. 1991b. Associative memory operation of the random network model. *EHEI Rapport de Resherche*, no.91-3. Universite Rene Descartes.
- [61] Gelenbe, E. and Sungur, M. 1994a. Image compression with the random neural network. *Proc. of the Int. Conf. on Artificial Neural Networks*, North-Holland, Elsevier.
- [62] Gelenbe, E. and Sungur, M. 1994b. Random network learning and image compression. *Proc. of the Int. Conf. on Artificial Neural Networks*, 3396-3399.
- [63] Gelenbe, E. and Sungur, M. 1994c. Random nets and image compression. (unpublished).
- [64] Gelenbe, E., Sungur, M. and Cramer, C. 1994. Learning random networks for compression of still and moving images. (unpublished).
- [65] Gelenbe, E., Şeref, E. and Xu, Z. 2001. Simulation with learning agents. *Proceedings of the IEEE*, vol.89, no.2, 148-157.
- [66] Ghanwani, A. 1994. A Qualitative comparison of neural network models applied to the vertex covering problem. *Elektrik*. vol.2, no.1, 11-19.
- [67] Halıcı, U. 1995. Learning in mazes by random neural networks with recency effect. *Proc. of the 10th Int. Symp. on Computer and Information Sciences, ISCIS '95 (10th)*, 707-714, Kuşadası, Turkey.
- [68] Halıcı, U. 1997. Reinforcement learning in random neural networks for cascaded decisions. *Biosystems*, 40, 83-91.
- [69] Halıcı, U. 1998. Reward, punishment, and internal expectation for training the random neural network with reinforcement. *Advances in Computer Sciences '98, Gündükbay, U., Dayar, T., Gürsoy, A., Gelenbe, E. (ed.s), Proc. of the ISCIS '98 (13th)*, Antalya, Turkey, 162-169.
- [70] Halıcı, U. 2000. Reinforcement learning with internal expectation for the random neural network. *European J. of the Operational Research*, 126, 288-307.
- [71] Halıcı, U., Badaroğlu, M., Aybay, I. and Çerkez, C. 1997. A digital random neural network chip design. *Proc. of Neurel 97, Belgrade, Yugoslavia*, 77-83.
- [72] Halıcı, U. and Karaöz, E. 1998. A linear approximation for training recurrent random neural networks. *Advances in Computer Sciences '98, Gündükbay, U., Dayar, T., Gürsoy, A., Gelenbe, E. (ed.s), Proc. of the ISCIS '98 (13th)*, Antalya, Turkey, 149-156.
- [73] Harison, P.G. 1998. Response times in G-nets. *Advances in Computer and Information Sciences '98, Gündükbay, U. (ed.)*, IOS Press, 9-16.
- [74] Harison, P.G., Patel, N.M. and Pitel, E. 2000. Reliability modelling using G-queues. *European J. of Operational Research*, 126, 273-287.
- [75] Hey, L.A., Cheung, P.Y.K. and Gellman, M. 2005. FPGA based router for cognitive packet networks. *Proc. of 2005 IEEE Int. Conf. on Field-Programmable Technology*, 11-14 Dec., 331-332.

- [76] Hubert, C. 1992a. Autoassociative memory with the random neural network using Gelenbe's learning algorithm. *Neural Networks : Advances and Applications 2*, Gelenbe, E. (ed.), Elsevier Science Pub. Co., 1999-2014.
- [77] Hubert, C. 1992b. Supervised learning and retrieval of simple images with the random neural network. (unpublished).
- [78] Jo, S., Yin, J. and Mao, Z.-H. 2005. Random neural networks with state-dependent firing neurons. *IEEE Trans. on Neural Networks*, vol.16, no.4, July, 980-983.
- [79] Koçak, T. 2001. Applications of the Random Neural Network to Some Inverse Problems in Image Processing. PhD Dissertation, Duke University, ECE Dept., USA, 127.
- [80] Koçak, T. and Draper, M. 2006. A back-propagation neural network landmine detector using the Delta-technique and S-statistic. *Neural Processing Letters*, vol.23, no.1, Feb. 47-54.
- [81] Koçak, T., Seeber, J. and Terzioglu, H. 2003. Design and implementation of a random neural network routing engine. *IEEE Trans. on Neural Networks*, vol.14, no.5, Sept., 1128-1143.
- [82] Küçüköncü, T. 2007. Örüntü Tanıma Ve Görüntü Analizinde Rasgele Yapay Sinir Ağı Kullanımıyla Boolean Rasgele Kümelerin Modellenmesi. Doktora Tezi, Ankara Üniversitesi, FBE, 165.
- [83] Küçüköncü, T. ve Gebizlioğlu, Ö.L. 2007. Matematiksel Morfolojik İşlemlerin Rasgele Yapay Sinir Ağlarıyla Gerçeklenmesi. Elektrik-Elektronik-Bilgisayar Mühendisliği 12. Ulusal Kongresi, 14-18.Kasım.2007, Eskişehir.
- [84] Likas, A. and Stafylopatis, A. 1991. An investigation of the analogy between the random network and the Hopfield network. *Computer and Information Sciences 6*, (ed.s) Baray, M., Özgüç, B., Elsevier Science Publications, 849-857.
- [85] Likas, A. and Stafylopatis, A. 2000. Training the random neural network using quasi-Newton methods. *European J. of Operational Research*, 126, 331-339.
- [86] Lu, R. and Shen, Y. 2005. Image segmentation based on random neural network model and gabor filters. 27th Annual Int. Conf. of the Engineering in Medicine and Biology Society, 2005, IEEE-EMBS 2005, 01-04 Sept., 6464-6467.
- [87] Mokhtari, M. 1992. Storage and recognition methods for the random neural network. *Networks : Advances and Applications - 2*, Gelenbe, E. (ed.), Elsevier Science Pub. Co., Amsterdam.
- [88] Sungur, M. 1995. Towards a hardware implementation of random neural network. Proc. of the 10th Int. Symp. on Computer and Information Sciences, ISCIS '95 (10th), Kuşadası, Turkey, 747-753.
- [89] Sungur, M. 1998. Image compression using random neural networks. *Advances in Computer and Information Sciences*. Güdükbay, U., et. al (ed.s), IOS Press, 183-189.
- [90] Teke, A. and Atalay, V. 2004. Texture classification and retrieval using random neural network model. 6th IEEE Southwest Sym. on Image Analysis and Interpretation, 2004, 28-30 March, 109-113.
- [91] Terzioglu, H. and Kocak, T. 2004. A network processor for a learning based routing protocol. The 2nd Annual IEEE Northeast Workshop on Circuits and Systems, 2004, NEWCAS 2004, 20-23 June, 261-264.