

NÖROKONTROLÖRLER

Şeref SAĞIROĞLU¹, Mehmet ERLER²

¹Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Bölümü, 38039, Kayseri

²Erciyes Üniversitesi, Sivil Havacılık Yüksek Okulu, 38039, Kayseri

Özet: Kontrol sistemlerinde, problemlerin analitik çözümlerini klasik teknikler kullanarak elde etmek çok zordur. Bu makalede, kontrol problemlerini çözmede yeni bir yaklaşım olarak kullanılan hiyerarşik, çok katlı, model-referans ve kendi kendini ayarlayan (self-tuning) gibi nörokontrolörler araştırılmış olup birbirlerine ve klasik kontrol metodlarına göre avantajları ve dezavantajları ortaya konmuştur.

Anahtar kelimeler: Yapay Sinir Ağları, Nörokontrolörler

NEUROCONTROLLERS

Abstract: Solving control problems using analytical methods are difficult. In this paper, solving control problems using artificial neural networks as a new technique are presented. Hierarchical, multilayered, model-reference and self-tuning neurocontrollers are reviewed and compared to the classical methods with their advantages and disadvantages.

Keywords: Artificial neural networks, neurocontrollers

1. Giriş

Kontrol sistem teorisindeki gelişmelere paralel olarak, sanayide teknolojik olarak yeni uygulamalarda artış görülmüştür ve bunun sonucunda da endüstriyel alanda verimlilik artışı sağlanmıştır [1-6]. Günümüzde kontrol edilmesi istenilen sistemlerin çoğunun karmaşık yapıda olmaları ve sistem dinamiği konusundaki belirsizlikler kontrol sistem tasarımı zorlaştırmaktadır. Bir kontrol sistem tasarımının gerçekleştirilebilmesi için gerekli şartlardan biri sistem dinamiğinin bilinmesidir. Bu bilgi ya sistemin modelinin matematiksel olarak oluşturulmasıyla ya da sistemin çeşitli girişlere karşı gösterdiği tepkinin deneysel olarak elde edilmesiyle sağlanır. Dinamik modelin doğru olarak belirlenmesi de bazı sistemler için yeterli değildir. Sistemlerde meydana gelen dinamik değişiklikler kontrol sisteminin dinamiğini de değiştirebilmektedir.

Gelişen teknolojiyle birlikte sistemlerin karmaşıklığı artmakta, dolayısıyla sistemlerin matematiksel modellerinin oluşturulmasında güçlüklerle karşılaşmaktadır. Modellemenin gerçekleştirilmesi için deneysel olarak elde edilen ön bilginin ölçümündeki hatalardan dolayı güvenilirliği de kesin olamamaktadır. Bundan dolayıdır ki günümüzde yaygın olarak kullanılan klasik kontrol tekniklerinin yerine yeni tekniklerin geliştirilmesinde bir zaruriyet ortaya çıkmıştır [1,2,4].

Yapay sinir ağları (YSA), öğrenme kabiliyeti, kolaylıkla farklı problemlere uyarlanabilirliği, genelleme yapabilme yeteneği, daha az bilgiye gereksinim duyması, paralel yapılarından dolayı hızlı işlem yapabilmeleri ve kolayca gerçekleştirilebilmeleri sebebiyle çok farklı alana başarıyla uygulanmaktadır. Bundan dolayı, oldukça popülerdirler [7-11]. Karmaşık dinamik sistemlerin değişebilen yapıdaki dinamik koşullar altında verimli çalışmasını sağlamada nörokontrolörler yeni bakış açıları kazandırmışlardır [1-50].

Yukarıda açıklanan sebeplerden dolayı, daha az ön bilgiye ve daha çok değişen sistem dinamiğine karşı çalışma performansı belirli sınırlar içinde kalabilen kontrol sistemlerinin tasarımında yapay sinir ağları, öğrenme, hızlı işlem yapabilme, genelleme ve adaptasyon kabiliyeti, ve gürültüye karşı toleransı gibi özelliklerinden dolayı sıkça kullanılmaya başlanmıştır [7-12].

Bu çalışmada, bugün bir çok alanda uygulanmakta ve kullanılmakta olan nörokontrolörlerle ilgili bir araştırma yapılarak, bu konuda çalışmakta olan araştırmacılara karşılaştırma yapabilmeleri ve aynı zamanda yeni araştırmacılara da ışık tutacak yeni bir kaynak oluşturma hedeflenmiştir. Çok katlı, direkt olmayan, genel, özel ve hiyerarşik nörokontrolörler ile CMAC, model referans gibi diğer nörokontrolörler incelenmiş ve onların karşılaştırılması yapılmıştır.

2. Yapay Sinir Ağları (YSA) ve Kontrol

Yapay sinir ağları (YSA), temel olarak beynimizin matematiksel modellenmesi üzerine kurulmuştur [7,13]. YSA'ları basitçe açıklamak gerekirse, birçok işleme elemanlarının birbirleri arasındaki farklı bağlantı şekillerinden oluşur [7,13] ve her YSA'nın kendine özgü bir yapısı ve öğrenme şekli olabilir [7,8,12,13]. YSA'lar bağlantı şekillerine ve yapılarına göre sınıflandırılırlar [7,8]. Aslında YSA'ların sırrı, onların giriş ile çıkış arasında bir kodlama/haritalama oluşturmalarında, yani verilmiş olan bir giriş kümesine beklenen bir çıkış kümesi üretmelerindedir.

YSA'ların topolojisi, ileri-beslemeli ve geri-beslemeli olmak üzere ikiye ayrılabilir da [7] daha farklı sınıflandırmalar da vardır [13]. İleri beslemeli sinir ağı, giriş uzayı ile çıkış uzayı arasında statik haritalama yapar ve verilmiş bir zamandaki çıkış sadece o zamanda verilmiş bir girişin fonksiyonudur. Geri-beslemeli sinir ağına ise, bazı işlem elemanlarının çıkışı aynı işlem elemanlarına veya daha önceki katlardaki işlem elemanlarına geri beslenir. Bundan dolayı dinamik bir hafızaya sahip oldukları söylenir. Böyle bir sinir ağının çıkışı, kendi girişlerine ve daha önceki giriş ve çıkışlara bağlantılı olabilir.

Şekil 1'de dört girişli (X,Y,Z,T), bir çıkışlı ve iki ara katmana sahip bir çok katlı yapay sinir ağı şekli gösterilmiştir. Ağırlıklar, işleme elemanları (şekilde yuvarlak sembollerle gösterilmiştir) arasındaki iletişimi sağlarlar. İşleme elemanlarında kullanılan transfer fonksiyonları, türevi alınabilir fonksiyonlar olmalıdır. Tanjant hiperbolik fonksiyon (HT) buna bir örnek olarak verilebilir. Şekilde HT'ler ile LF'ler sırasıyla hiperbolik tanjant ve lineer aktivasyon fonksiyonlarını göstermektedirler.


YSA'lar aşağıdaki özelliklerinden dolayı çok değişik alanlara uygulanabilirler [8,13]. Bunları genel olarak, tecrübe (deneyim) neticesinde öğrenme, örneklerden genelleme yapma, gürültü filtreleme, hızlı çözüm sağlama ve doğrusal olmayan özelliğinden dolayı birçok probleme uygulanabilir olmaları ve adaptasyon kabiliyeti olarak sınıflandırılabilirler.

Yapay sinir ağlarının sistem kontrolündeki yerini ve önemini anlamak için bazı özelliklerinin bilinmesi gerekir. Bu özellikler;


1. YSA'ların yapısından kaynaklanan haritalama özelliğinden dolayı doğrusal olmayan kontrol sistemlerinin tanımlanmasında veya kimliklendirilmesinde kullanımı [3,14-17],
2. YSA'ya uygulanan girişlerin diğer katmanlar boyunca paralel olarak işlenmesinden dolayı diğer klasik yöntemlere göre daha kısa sürede işlemleri gerçekleştirebilmeleri [1,3,6,18],
3. Bir sistemin çalışması esnasında alınan verilerin kullanılmasıyla bir YSA'nın eğitilebilmesi, eğitilen ağların daha sonra kendilerine sunulan ve eğitim setinde bulunmayan verilere karşı da uygun cevabı kısa

sürede verebilme ve bundan dolayı da on-line kullanılabilme özelliğine sahip olmaları [2,3,8,13,19,20,21,22],

4. Mikroelektronik alanındaki gelişmeler sonucunda paralel işlem yapabilen tümdevreler ve özel amaçlı nörobilgisayarların üretilmesi [23-28,49],
5. Paket programların geliştirilmesiyle, YSA'ların birçok endüstriyel alana uygulanabilme kolaylığına sahip olmaları [23-28],
6. Birçok girişi işleme ile bu girişlere uygun çıkış üretebilme özelliğinden dolayı çok değişkenli sistemlere kolayca uygulanabilir olmaları [4,8,12,13,22],
7. Nitel ve nicel verilerin birlikte kullanılabilmelerine veya işlem yapılabilmesine imkan vermesi [8,12,13,21,29,30] ve
8. Diğer YSA modelleri ve yapay zeka teknikleriyle entegre olabilme özelliğine sahip olmaları [4,8,9,12,13,26,50], olarak özetlenebilir.



Şekil 1. Bir çok katlı YSA



Şekil 2. Genel bir nörokontrolör yapısı

3. Nörokontrolörlerde öğrenme yapıları

Kullanılan iki farklı öğrenme metodu mevcuttur. Bunlar örneklerden öğrenme (danışmanlı) ve gözlemlerden öğrenme (danışmansız) olarak sınıflandırılabilir [2]. Eğer öğrenme bazı örnekler üzerinden yapılıyorsa, bu bir danışmanlı öğrenmedir ve verilmiş bir grup örnekten genel bir yaklaşım elde edilerek farklı örnekleri de tanıyabilir. Burada öğrenme esnasında, sisteme sunulan örnekler bir danışman gibidir ve bu tip öğrenmeye, danışmanlı öğrenme denir.

Fiziksel sistemlerin dinamiği (bu bir manipulator olabilir) kısmen veya tamamen bilinmiyor olarak kabul edilebilir. Bir kontrolör, optimal bir kontrol için ihtiyaç duyulan bilinmeyen işlemi öğrenebilmelidir. Gerçek kontrol, öğrenilmiş olan bu işlem baz alınarak gerçekleştirilebilir. Öğretmen veya danışman, kontrolörün performansını değerlendirir ve performansı dereceli olarak arttıracak şekilde öğrenme işlemi yönlendirir. Danışmanlı öğrenme sistemi bazı kaynaklarda **off-line** öğrenme olarakta isimlendirilir. Eğitim işlemi sonlandırıldığında öğrenme işlemi de biter.

Gözlemlerden öğrenme (buna öğretmensiz öğrenme de denir) bir danışmansız öğrenmedir. Öğrenme esnasında özellikle belli gruplara ait örnekler bulunmaz. Danışmansız eğitim, diğer yaklaşımlardan farklı olarak öğrenme sistemiyle başarılıdır. Kontrolörün performansı bazı kurallara bağlı bir **kriter** tarafından dinamik sistemin çıkışında değerlendirilir. Bu öğrenmede, şayet öğrenme sistemi bir işlemi seçer ve cezalandırılmayan bir değerlendirme meydana gelirse, bu işlemin başarı yüzdesi düşer ve diğer bütün işlemleri seçme yüzdesi artar. İşlemlerdeki bu değişimler cezalandırma veya ödüllendirme olarak da bilinir [4].

Kontrolör, değerlendirme fonksiyonu tarafından her zaman aralığında yönlendirilen en iyi kontrol hareketini öğrenmesi için dizayn edilir. Bu tip öğrenmede, kontrolör bir eğiticiye gerek duymadan öğrenebilir ve bu tip

kontrolörlere **on-line** öğrenen sistemler de denir [8].

4. Nörokontrolörler

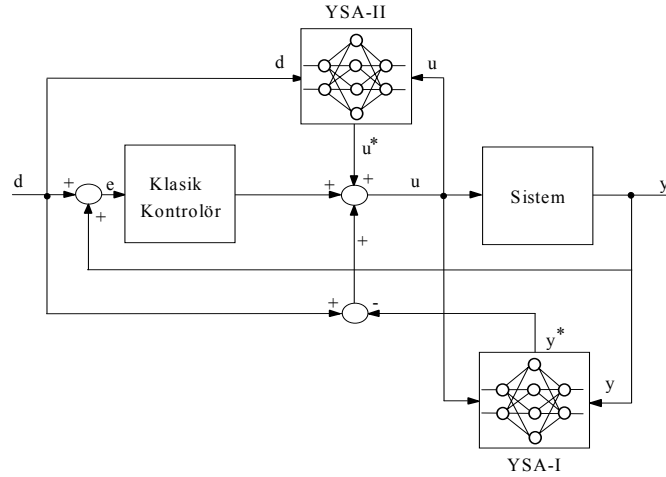
Sistemlerin adaptif, hızlı ve güvenilir kontrolü için yeni bir teknolojidir ve analiz veya modellemeye gerek duymaksızın kontrol algoritmasını öğrenme kabiliyeti, zor, karmaşık, ve doğrusal olmayan sistem uygulamaları için çok caziptir [2,4,8,32,35,36,48]. Aksi halde analiz, benzetim, modelleme ve kimliklendirme masraflıdır, ya pratik değildir ya da gerçek zaman işlemi yavaşdır [13,31,32].

Şekil 2 de genel bir nörokontrolör yapısı gösterilmiştir. Şekilde, önerilen adapte edilmiş nöro-yapı önceki bölümlerde açıklanmış avantajları bizlere sunar.

YSA'ların kontrol sistemlerinin tasarımında nasıl kullanılabileceği [34] gösterilmiştir. Geliştirilen nörokontrolör, hassas bir model veya parametre tayinine gerek duymamıştır. Nörokontrolörleri kendi aralarında sınıflandırmak mümkün olmasada farklı şekilde gruplandırmak mümkündür. Bu gruplandırma ileri veya geri beslemeli olmasının yanında, on-line ve off-line öğrenme, danışmanlı veya danışmansız olarak yapılabilir [2,3,12,35,36]. Bu çalışmada, literatürde mevcut bulunan nörokontrolörler gözden geçirilmiş olup kolay anlaşılması bakımından aşağıdaki gruplandırmaya tabi tutulmuşlardır.

4.1 Hiyerarşik Nörokontrolör (HN)

Bu kontrolör, Kawato [23,41] tarafından fizyolojik alandaki araştırma sonuçlarına dayanılarak oluşturulmuştur ve yapısı Şekil 3 de gösterilmiştir. Şekilde, d istenilen sistem çıkışı, u sistemin kontrol girişi ve y gerçek sistem çıkışıdır. u^* hesaplanan sistem girişi ve y^* nörokontrolörün (YSA-I) çıkışıdır.



Şekil 3. Hiyerarşik nörokontrolör

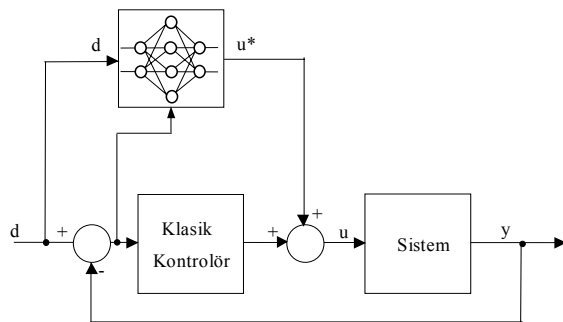
Sistemin üç çevrimden oluştuğu düşünülebilir. İlk çevrim, harici geribesleme olarak bilinen klasik geribesleme çevrimidir. Geribesleme kontrolü, istenilen sistem çıkışı d ve sensörlerle ölçülen gerçek sistem çıkışı y arasındaki e hatasına $e=d-y$ bağlıdır. Genellikle harici klasik geribesleme bir PD kontrolör ile gerçekleştirilir. İkinci çevrim, YSA-I ile bağlantılı yoldur. Bu sinir ağı sistem girişi u 'yu ve y çıkışını denetler ve sistem dinamiklerini öğrenir. Öğrenmeden sonra, sinir ağı sistem girişi u 'yu aldığı anda yaklaşık bir sistem çıkışı y^* 'ı verebilir. Bu anlamda, bu çevrim bir sistem dinamiklerini kimliklendirici olarak davranır. $d-y^*$ hatasına bağlı olarak bu çevrim, harici geribesleme çevriminde çok daha hızlı olan bir iç geribesleme çevrimi sağlar.

Sistemin üçüncü çevrimi, istenilen d çıkışı ve sistem girişi u 'yu denetleyen YSA-II'yi içerir ve bu ağ sistem ters dinamiklerini modellemek için kullanılmıştır. Öğrenmeden sonra ağ, istenilen çıkış komutu d 'yi aldığı anda, uygun sistem çıkışı u^* 'yü üretebilir. Hiyerarşik nörokontrolör sisteminde, sensör geribeslemesi esas olarak öğrenme katında etkindir ve sistemi kontrol etmek için bir klasik geribesleme işareti üretir. Sensör gecikmesinden ve küçük kabul edilebilir kontrol kazancından dolayı sistem cevabı yavaştır ve bu öğrenme katının hızını sınırlar. YSA-II ters dinamikleri öğrenirken, YSA-I sistem dinamiklerini öğrenir. Öğrenme sürerken dahili geribesleme ana kontrolör olarak harici geribeslemenin yerini alır. Sonra öğrenme sürerken ters dinamik kısmı iç geribesleme kontrolü ile yer değiştirir. Sonuç olarak sistem, ileri yön kontrolörü tarafından kontrol edilmiştir.

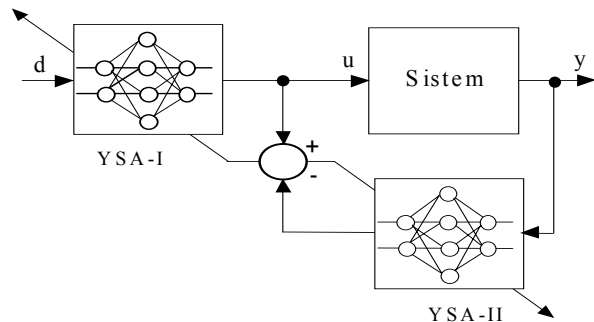
Geng ve Haynes [18] tarafından sunulan HN ile geliştirilen yapının hesaplama verimliliği, hızı ve uyarlanabilirliği gösterilmiştir. Yapısal HN [37] ise, gerçek zamanda robot kontrolü için birçok sensörden gelen veriyi işlemek ve gerçek zamanda çevresel değişimlere uyarlama kabiliyeti geliştirmekve gerekli öğrenmeyi sağlamak için kullanılmıştır. YSA'ların ilgi çekici özelliklerinden birisi de paralel bilgi işlemeye dayanan (gerçek zamanda çok sayıda verimli hareket ettirici komutları üretmek gibi) kollar, bacaklar ve bağlar gibi oldukça karmaşık sistemler (manipatörler) kontrol etme yeteneğidir. Son birkaç yıl içinde çoğu araştırmacı, serbest eklemler robotların kontrolü ve tasarımına yönelmişlerdir [29,30,38-40].

4.2 Çok Katmanlı Nörokontrolörler (ÇKN)

Çok katmanlı nörokontrolör esas olarak bir ileri yön kontrolördür [35]. Şekil 4'de böyle bir kontrol sistemi verilmiştir. Bu kontrol sisteminde, ileri yön ve klasik geribesleme kontrolü olmak üzere iki çeşit kontrol işlemi gerçekleştirilir.



Şekil 4. Çok katmanlı genel bir nörokontrolör



Şekil 5. Direkt olmayan yapı

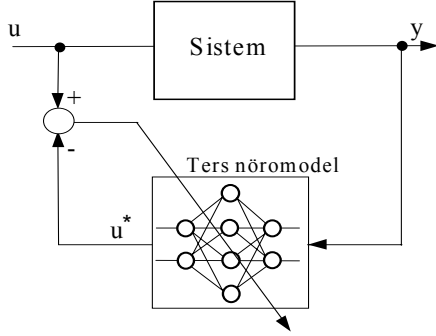
İleri yön kontrol işlemi bir nörokontrolör ile gerçekleştirilmiştir. İleri yön kontrolör eğitiminin amacı, istenilen ile gerçek sistem çıkışı arasındaki hatayı minimum yapmaktır. Bu hata geribesleme kontrolörü için giriştir. Bu tip nörokontrolörlerde direkt olmayan, genel ve özel olmak üzere üç tip öğrenme yapısı kullanılır. Bu yapılar aşağıda özetlenmiştir.

4.2.1 Direkt olmayan yapı

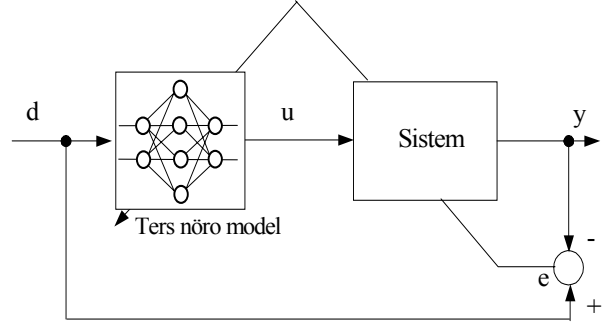
Bu tip nörokontrolörler, direkt olmayan öğrenme yapısı benzer iki sinir ağına sahiptir [35]. Şekil 5'de bu yapı gösterilmiştir. Bu yapıda, her ağ bir ters dinamik kimliklendirici olarak çalışır. Eğitimin hedefi istenilen d cevabından uygun sistem kontrol girişi u 'yu bulmaktır. Ağırlıklar, e hatasını minimum yapmak için I ve II nolu YSA çıkışları arasındaki hataya bağlı olarak değiştirilir.

4.2.2 Genel yapı

Bu tip bir yapıda Şekil 6 da gösterildiği gibi hata minimum yapılmaya çalışılır.



Şekil 6. Genel yapı



Şekil 7. Özel yapı

Ağ, sistem girişi ve çıkışı arasındaki hatayı minimum yapmak için eğitilir. Bu yapının başarısı, eğitim veri seti ile test veri setinin birbirine yakın olmasındadır. Bu başarılmazsa, buna bağlı olarak performansda düşüşler gözlemlenebilir [35].

4.2.3 Özel yapı

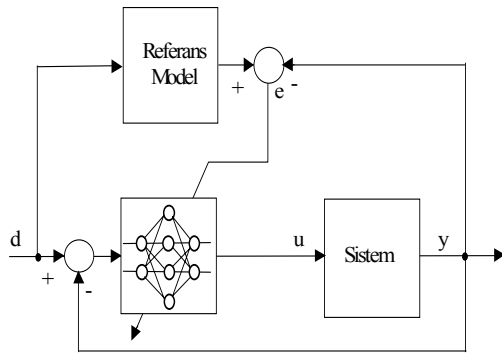
Çok katlı nörokontrolörlerde özel öğrenme yapısı Şekil 7 de gösterilmiştir. Bu yapıda istenilen çıkış ağ için girişdir. Buradaki hata, geri yayılım algoritması kullanılarak, istenilen çıkış ile gerçek çıkış arasındaki fark minimum yapılmaya çalışılır. Böylece iyi bir sistem çıkışı yanında, sistem girişinin uygun sahasını bilmeye gerek kalmaksızın istenilen çıkış bölgesinde de öğretim işlemi yapılabilir [35]. Bu yapıda sistem, ağı bir katı gibi davranır. Ağı eğitmek için, dinamik sistem modellerinden biri bilinmeli veya yapım için bazı yaklaşımlara sahip olunmalıdır.

4.3 Adaptif Nörokontrolörler

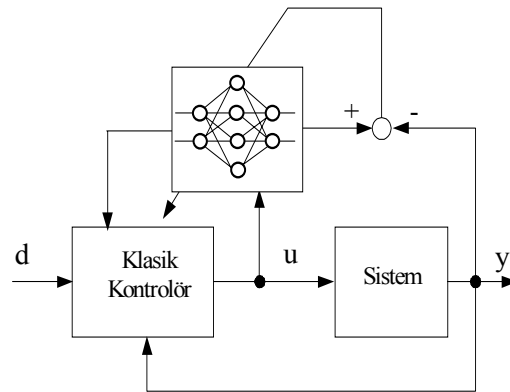
Bu tip kontrolörlerde, YSA'nın ağırlıkları on-line olarak değiştirilir. Böyle bir kontrolöre ihtiyaç duyulmasının sebebi, sistem parametrelerinin çevre etkileriyle sürekli olarak değişmesinden kaynaklanmaktadır. Bu tip kontrolörlerde, bir çok model ve kontrol yapısı seçmek mümkündür. Bir çok adaptif yapı mevcut olup bunlardan bazıları aşağıda özetlenmiştir [6,19,21,36,39,42].

4.3.1 Model-Referans Nörokontrolör

Bu kontrolör [19,42], tarafından tasarlanmış olup Şekil 8 de gösterilmiştir. Model referans kontrol sistemleri, sistem çıkışının model çıkışını takip etmesi için tasarlanmış kontrol sistemleridir. Adaptasyon işlemi tamamlandığında kontrol edilen sistemin özellikleri, arzu edilen modelin özelliklerine benzemektedir. Buradaki adaptif algoritma YSA algoritmalarıdır. Kullanılacak olan referans model, kontrol edilen sistemin arzu edilen davranışını sergiler. Referans model çıkışı ile sistem çıkışı karşılaştırılır. Bu karşılaştırma sonucunda referans model çıkışı ile sistem çıkışı arasındaki model hatası elde edilir. Elde edilen bu hata değerleri ise nörokontrolörü eğitmek için kullanılır. Burada standart geri yayılım algoritması, yapay sinir ağının arzu edilen çıkışı bilinmediği için kullanılmaz. Bunun için alternatif yapılar geliştirilmiştir [19].



Şekil 8. Model-Referans nörokontrolör



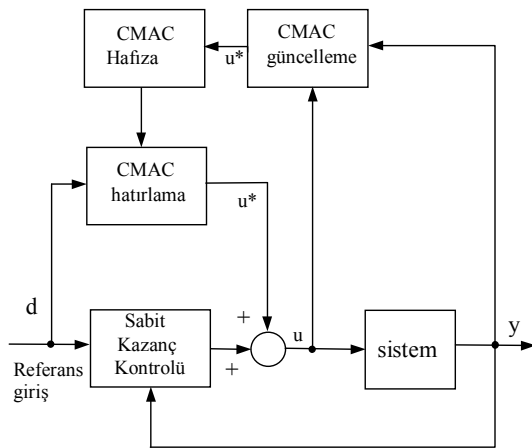
Şekil 9. Kendi kendini ayarlayan nörokontrolör

4.3.2 Kendi Kendini Ayarlayan (Self-Tuning) Nörokontrolör


Şekil 9'da bir kendi kendini ayarlayan bir nörokontrolörün şeması verilmiştir [43-45]. Burada sistem parametreleri ve klasik kontrolörün parametreleri on-line olarak YSA tarafından hesaplanır ve YSA sistem kimliklendirici olarak tasarlanmıştır.

4.3.3 CMAC (Cerebellar Model Articulation Control)

Albus [24,25] tarafından geliştirilmiş olan bu kontrolör bir çok alanda uygulaması bulunan temel kontrolörlerden biridir [20,26-28,46]. Bir sistemin kontrolünde CMAC öğrenme kuralını kullanarak devamlı iyi bir çözüm sağlanabileceği [46] nolu referansta göstermişlerdir.



Şekil 10. CMAC Nörokontrolör



Şekil 11. Hibrid nörokontrolör

Şekil 10'da bir CMAC nörokontrolörün blok diyagramı verilmiştir. CMAC, güncelleme, hafızlama ve hafıza modüllerinden oluşmaktadır. CMAC modülü, bir sabit kazançlı geribesleme kontrolörünün yardımıyla bir ters transfer fonksiyonunun eğitilmesi için kullanılır. Öğrenmeden sonra, CMAC temel kontrolör olacaktır. Bu kontrolörde, kontrol ve öğrenme aynı zamanda gerçekleştirilmektedir. Bu metodun dezavantajı, sistem için dizayn edilmiş sabit kazançlı bir kontrolöre ihtiyaç duymasındır.

4.3.4 Diğer Tip Nörokontrolörler

Şekil 11'de adapte edilen farklı bir kontrolör verilmiştir. Bu kontrolör, bir PD kontrolör ve bir sistemin ters dinamiğini modellemek için kullanılan geribeslemeli bir YSA kontrolörden oluşmuştur. YSA kontrolör, sistem değişikliklerine adapte olabilmesi için kontrol esnasında on-line olarak eğitilir. YSA kontrolör, şekilde gösterildiği gibi küçük değişikliklerle sistemin hatasına bağlı olarak geriyayılım algoritması kullanılarak eğitilir. Bir YSA ters model nörokontrolör [21] ile hibrid nörokontrolör [47] buna örnek olarak verilebilir. Geliştirilen nörokontrolörler ile, geri besleme işlemiyle modellemeyi kolaylaştıran dinamik hafıza sağlanması ve hibrid ara kat ile de lineer ve lineer olmayan modellerden oluşan gerçek sistemlerin modellenmesi başarıyla gerçekleştirilmiştir.

5. Sonuç ve Yorum

Nörokontrolörlerin ortak özellikleri, çok fazla kontrol algoritmalarına ihtiyaç duyulmadan kontrol işlemini gerçekleştirebilmeleri, öğrenme ile gerçek performansa erişebilmeleri, çok sayıda bilgiyi işleyebilmeleri, hızlı işlem yapabilme kabiliyetleri, gürültüye tolerans gösterme ve filtreleme yetenekleri, off-line eğitilip on-line olarak kullanılabilmesi, doğrusal olmayan yapıları ve gerekli ise on-line öğrenebilmeleri, nörokontrolörleri diğer kontrolörlerden ayıran başlıca özellikler olarak sıralanabilir [2,3,8,35,36,48].

YSA'ların kontrol sistemlerine uygulanmaları birçok önemli avantajlar sağlamaktadır. Bilimsel ve teknolojik olmak üzere her iki açıdan bakıldığında oldukça caziptir. Gerçekten de, bazı problemler için YSA'lar yeni bir teknik olarak karşımıza çıkmaktadır. Sistem dinamiklerini modelleme ve kontrol, YSA öğrenme algoritmalarının başarılı olduğu alanlardan birkaçıdır.

Nörokontrolörler kendi aralarında karşılaştırıldığında CMAC'ın kendi kendini ayarlayan nörokontrolörden ve model-referans kontrolörden daha hızlı ve gürültüye de daha fazla toleranslı olduğu ortaya konmuştur [47]. Aynı zamanda, CMAC'ın eğitilmesi için çok az bir zamana ihtiyaç duyulmasından dolayı da on-line eğitimde, kendi kendini ayarlayan nörokontrolörden, model-referans kontrolörden, çok katlı ağlardan ve hiyerarşik nörokontrolörden daha hızlıdır [36]. Klasik kontrolörler ile karşılaştırıldığında ise öğrenme özelliklerinin en güçlü özellik olarak ortaya çıktığı görülmüştür [48]. Giriş sinyallerine karşı nörokontrolörlerin performansı adaptif kontrolörlerden daha yüksektir. Hiyerarşik nörokontrolörler, sistem parametrelerinin belirli bir seviyeye kadar değişim göstermeleri durumunda bile iyi bir kontrol etme özelliğine sahiptirler [23,41].

Çok katlı nörokontrolörün ve hiyerarşik nörokontrolörlerin girişlerine arzu edilen sistem çıkışı uygulanır. Çok katlı nörokontrolörde, ileri beslemeli kontrolör, geri beslemeli kontrolörü dikkate almaksızın eğitilmesine rağmen, hiyerarşik nörokontrolörlerde ileri beslemeli kontrolör geri beslemeli kontrolörün yardımıyla çalışmaktadır.

Kaynaklar

1. Jin, Y., and Pipe, T., Neural Net Versus Control Theory, Int. J. Control, **12**, 1991.
2. Hunt, K.J., Sbarbaro, D., Zbikowski, R., and Gawthrop, P.J., Neural Networks for Control Systems-A Survey, Automatica, **28**, 1992.
3. Narendra, K. S., and Parthasarathy, K., Identification and Control Of Dynamical Systems Using Neural Networks, IEEE Transaction On Neural Networks, **1**, 1, pp.4-26, 1990.
4. Warwick, K., Irwin, G.W., Hunt, K.J., Neural Networks for Control and Systems, London:Peregrinus, 1992.

5. Jin, Y., and Pipe, T., Neural Net Versus Control Theory, *Int. J. Con. On Neural Networks*, Singapore, 2, pp.1548-1553, Nov. 1991.
6. Samad, T., Neural Networks for Control, *ISA, Advances in Instrumentation and Control*, **46**, 2, 1991.
7. Simpson, P.K. , *Artificial Neural Systems*, (Pergamon Press, Oxford), 1990.
8. Maren, A., Harston, C. and Pap, R., *Handbook of Neural Computing Applications*, (Academic Press, London) ISBN 0-12-471260-6, 1990.
9. Kocabas, S., A Review of Learning, *The Knowledge Engineering Review*, **6**, 3, 1990.
10. Widrow, B. and Lehr, M. A., 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation, *Proc. IEEE*, **78**, 9, pp1415-1442, 1990.
11. Lippmann, R. P., An Introduction to Computing with Neural Nets, *IEEE ASSP Magazine*, April, 1987.
12. Pham, D.T. and Liu, X. *Neural Networks for Identification, Prediction and Control*, Springer-Verlag, London, 1995.
13. Haykin, S., *Neural Networks: A Comprehensive Foundation*, New York, USA, Macmillan College Publishing Company, 1994.
14. Sagioglu, S. Identification Of Lineer Systems Using Multi-Layer Perceptrons, *Proceedings of ISCIS XI*, 2, pp.517-526, Antalya, Turkey, 6-8 November 1996.
15. Qin, S. H., Su, H. T., and McAvoy, T., Comparison Of Four Net Learning Methods For Dynamic System Identification, *IEEE Transaction On Neural Networks*, **3**, 1, pp.122-130, 1992.
16. Chen, S., Billings, S. A., and Grant, P. M., Non-lineer System Identification using Neural Networks, *Int. J. Control*, **51**, 6, 1990.
17. Chen, S., and Billings, Neural Network For Non-linear System Modelling And Identification, *Int. J. Control*, **56**, 21, 1992.
18. Geng, Z. and Haynes, L., Neural Network Solution For the Forward Kinematics Problem of a Stewart Platform, *Proc. IEEE Int. Conf. on Robotics and Automation*, Sacramento, California, pp.2650-2655, 1991.
19. Maeland, J. A. and B. Porter, Design of Model-Reference Neural Controllers using step-response Data, *IFAC Algorithms and Architectures for Real-Time Control*, Bangor, North Wales, UK, 1991.
20. Sagioglu, S., *Artificial Neural Networks in Robotic Applications*, *Int. J. of Mathematical and Computational Applications*, **3**, 2, 1998.
21. Pham, D.T and Yildirim, Ş., 'Control of the Trajectory of a Planar Robot Using Recurrent Hybrid Networks, *Int. Journal of Machine Tools&Manufacture: Design, Research and Application*, 1999.
22. Yildirim, Ş. and Sagioglu, Ş., Applications of Artificial Neural Networks in Robotic Systems: A Review Paper, *Int. J. of Mathematical and Computational Applications* Accepted for publication, 2000.
23. Kawato, M.Y., Furukawa, K., and Suzuki, R., A Hierarchical Neural Network Model for Control and Learning of Voluntary Movement, *Biol. Cybern.*, **57**, 1987.
24. Albus, J. S., A New Approach to Manipulator Control: Cerebellar Model Articulation Control (CMAC), *Trans. ASME, J. of Dynamisc Syst. Meas. And Contr.*, **97**, 220-227, 1975.
25. Albus, J. S. Data Storage in the Cerebellar Model Articulation Controller (CMAC), *Trans. ASME, J. of Dynamisc Syst. Meas. And Contr.*, **97**, 228-233, 1975.
26. Xu, L., Jiang, J.P. and Zhu, J., Supervised Learning Control of a Nonlinear Polymerisation Reactor Using the CMAC Neural Network for Knowledge Storage, *Proc. IEE, Part D*, **141**(1), pp.33-38, 1994.
27. Miller III, W T., Real-Time Application of Neural Networks for Sensor-Based Control of Robots with Vision, *IEEE Transaction on System, Man, and Cybernetics*, **19**, 4, pp.825-831, 1989.

28. Miller III, W. T., Box, B.A. and Whitney, E.C., Design and Implementation of a High Speed CMAC Neural Network Using Programmable CMOS logic Cell Arrays, *Advances in Neural Information Processing Systems 3*, (Eds) R.P. Lippmann, J.E. Moody, D.S. Touretzky, Morgan Kaufmann, San Mateo, California, pp.1022-1027, 1991.
29. Martinetz, T.M. and Schulten, K.J., Hierarchical Neural Net for Learning Control of a Robot's Arm and Gripper, *IJCNN, IEEE, INNS, Washington D.C.*, **2**, pp. 747-752, 1989.
30. Rabelo, L.C. and Avula, X.J.R., Hierarchical Neurocontroller Architecture for Intelligent Robotic Manipulation, *Proc. IEEE Int. Conf. on Robotics and Automation*, Sacramento, California, pp. 2656-2661, 1991.
31. Miller III, T.W., Sutton, R.S. and Werbos, P.J., (Eds.) *Neural Networks for Control*, (MIT, London), 1990.
32. Pourboghrat, F., Neuromorphic Controllers, *Proc. of the 28th IEEE Conference on Decision and Control*, Tampa, Florida, pp.1748-1749, 1989.
33. Guez, A and Ahmad, Z., Solution to The Inverse Kinematics Problem in Robotics by Neural Networks, *ICNN, IEEE, San Diego, California*, pp.617-624, 1988.
34. Miyamoto, H., Kawato, M., Setomaya, T. and Suzuki, R., Feedback-Error-Learning Neural Network for Trajectory Control of a Robotic Manipulator, *Neural Networks*, 1988.
35. Psaltis, D., Sideris, A. and Yamamura, A. A., A Multilayered Neural Network Controller, *IEEE Control Magazine*, 1988.
36. Miller III, T.W., Sutton, R.S. and Werbos, P.J., (Eds.) *Neural Networks for Control*, (Cambridge, MA:MIT Press), 1990.
37. Nagata, S., Sekiguchi, M. and Asakawa, K., Mobile Robot Control by a Structured Hierarchical Neural Network, *IEEE Control Systems Magazine*, 1990.
38. Fukuda, T., Shibata, T., Tokita, M. and Mitsuoka, T., Adaptation and Learning for Robotic Manipulator by Neural Network, *Proc. 29th IEEE Conference on Decision and Control*, Honolulu, HI, USA, pp.3283-3288, 1990.
39. Karakasoglu, A. and Sundareshan, M.K., Decentralized Variable Structure Control of Robotic Manipulators: Neural Computational Algorithm, *Proc. 29th Conf. on Decision and Control*, Honolulu, Hawaii, pp.3258-3259, 1990.
40. Xu, G., Scherrer, H.K. and Schweitzer, G., Application of Neural Networks on Robot Grippers, *IJCNN, IEEE, INNS, San Diego*, **3**, 1987.
41. Kawato, M.Y., Uno, Y., Isobe, M. and Suzuki, R., Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics, *IEEE Control System Magazine*, 1988.
42. Goldenthal, W and J. Farrell, Application of Neural Networks to Automatic Control, *Proc. AIAA Guidance, Navigation and Control Conference*, pp.1108-1112, Portland, August 1990.
43. Chen, F. C., Backpropagation Neural Networks for Nonlinear Self-tuning Adaptive Control, *IEEE Control Systems Magazine*, 1990.
44. Helferty, J.J. and Biswas, S., Neuromorphic Control as a Self-tuning Regulator, *Proc. 5th IEEE Int. Symp. On Intelligent Control*, Philadelphia, Pennsylvania, **1**, pp.506-511, 1990.
45. Chen, V. C. and Pao, Y., Learning Control with Neural Networks, *IEEE Int. Control on Robotics and Automation*, **3**, pp.1448-1453, 1989.
46. Wang, Y. F., and Sideris, A., Learning Convergence in the Cerebellar Model Articulation Controller, *IEEE Transaction On Neural Networks*, **3**, **1**, pp.115-121, 1992.
47. Kraft, L. K. And Campagna, D. P., A Comparison of CMAC Neural Network and Traditional Adaptive Control Systems, *1989 American Control Conference*, Pittsburg, PA, June 21-23, **1**, 884-889, 1989.

48. Bavarian, B., Introduction to Neural Networks for Intelligent Control, IEEE Control Systems Magazine, 2, pp.3-7, 1988.
49. Hong, R., State-Of-The-Art of Artificial Neural Networks and Applications to Mars Robots, Electro Int. Conf. Record, NY, 16, pp.568-573, 1991.
50. Yildirim, S., Control of Multi-legged Walking Robot Using Neural Network, Neural Network World, 9, 1-2, 1999.