

# İki Bacaklı Robot Hareket Kontrolünde Yapay Sinir Ağlarının Kullanımı

## The Use of Artificial Neural Networks in Bipedal Robot Motion Control

Burak Çatalbaş<sup>1</sup>, Bahadır Çatalbaş<sup>2</sup>, Ömer Morgül<sup>1</sup>

<sup>1</sup>Elektrik ve Elektronik Mühendisliği Bölümü  
İhsan Doğramacı Bilkent Üniversitesi, Ankara  
{catalbas},{morgul}@ee.bilkent.edu.tr

<sup>2</sup>Kontrol ve Otomasyon Mühendisliği Bölümü  
Yıldız Teknik Üniversitesi, İstanbul  
{bahadir.catalbas}@yildiz.edu.tr

### Özetçe

Yapay sinir ağı ile iki bacaklı robot hareketi kontrolünde kullanılan ağ mimarisi ve katmanlarının türü kontrolcü performansı üzerinde etkilidir. Bacaklı hareket kontrolünde yürüyüş başarısı ve hız kalıcı durum hatası önemli performans metrikleridir. Bu çalışmada farklı sinir ağı mimarilerinin ve katman türlerinin yürüyüş kontrolü üzerindeki etkisinin değerlendirilmesi amaçlanmıştır. Bu doğrultuda gizli katman sayısının ve türünün kontrolcü sinir ağı performansına etkisi benzetim ortamında incelenmiştir. Bu hedefle, bir merkezi örüntü üretici kullanılarak oluşturulan iki bacaklı hareket veri kümesiyle çeşitli sinir ağları eğitilmiştir. Sonrasında yapılan benzetim çalışmalarıyla tekrarlayan ve ileri beslemeli sinir ağı katmanlarının birlikte kullanıldığı bir sinir ağı ile hem yürüyüş başarısı hem de hız kalıcı durum hatası metriklerinde olumlu sonuç alınmıştır.

### Abstract

Network architecture and layer types in the artificial neural network used for two-legged robot motion control are effective on controller performance. Walking success and speed steady-state error are important performance metrics in legged motion control. In this study, it is aimed to evaluate the effect of different neural network architectures and layer types on walking control. To this end, various neural networks are trained on the two-legged motion dataset which is generated with a central pattern generator. With subsequent simulation studies, positive results were obtained in both walking success and speed steady-state error metrics with a neural network in which recurrent and feedforward neural network layers were used together.

### 1. Giriş

Bacaklı robotlar biyolojik karşılıklarına morfolojik benzerliklerinin sağladığı avantaj ile tekerlekli sistemlere kıyasla daha geniş hareket alanına ve çevik hareket kabiliyetine sahiptir [1–4].

Ancak bu yapıları onları doğrusal olmayan sistemler yaptığından kontrolcü geliştirmeyi kompleksleştirmektedir [5].

İki bacaklı robotların yürüyüş kontrolünde kütle merkezi (center of gravity) ve sıfır moment noktası (zero moment point) gibi klasik tekniklerden faydalanılabilmektedir [6, 7]. Ancak bu yöntemler kullanılarak oluşturulan eklem yörüngeleri takip edildiğinde bu yöntemlerin tanımları gereği getirilen yapay kısıtlar nedeniyle dizler bükük yürüyüş gibi doğal olmayan eklem yörüngeleri oluşabilmektedir [8]. Bunlara kıyasla bağlı diferansiyel denklemlerden oluşan merkezi örüntü üreticileriyle (central pattern generator) iki veya çok bacaklı robotlar için daha doğal yürüyüş örüntüleri oluşturulabilmektedir [9–12].

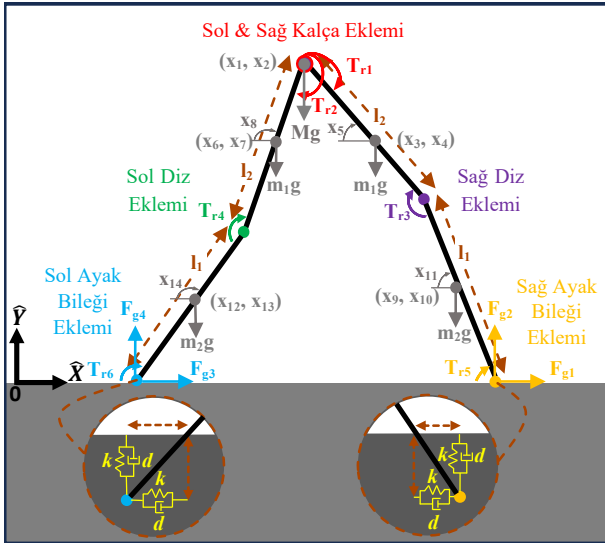
Makine öğrenmesi literatüründeki ilerlemeler ve yüksek hesaplama gücü sağlayan ekran kartlarının ulaşılabilir hale gelmesi sayesinde günümüzde yapay sinir ağları ile insan aktivite sınıflandırma, nesne takibi, canlı poz kestirimi, zaman serisi tahmini ve de hareket kontrolü yapılabilmektedir [13–18]. Bunlara ek olarak merkezi örüntü üreticilerine benzer şekilde yapay sinir ağı temelli kontrolcüler ile iki bacaklı hareketin doğal görünümlü kontrolünün yapılabileceği gösterilmiştir [19]. Merkezi örüntü üreticileriyle karşılaştırıldığında kontrolcü yapay sinir ağları daha geniş zemin eğimi aralığında ve daha engebeli zeminlerde yürüyüşü kontrol edilebilmektedir [20, 21]. Bunun yanı sıra yapay sinir ağları paralel ve seri-paralel mimariler ile iki bacaklı robot modeli için sistem tanılama işleminde kullanılabilir [22, 23].

Vadettiği potansiyel düşünüldüğünde yapay sinir ağı türü kontrolcü ile yürüyüş kontrolü araştırılması gereken bir konu olarak öne çıkmaktadır. Bu bağlamda bu tür kontrolcülerle iki bacaklı yürüyüş kontrolünde oluşan hız kalıcı durum hatasının incelenmesi ve hangi tür sinir ağı katmanlarının bu hatanın azaltılmasında kullanışlı olduğunun araştırılması önem arz etmektedir. Bu çalışmada farklı sinir ağı mimarilerinin ve katmanlarının hız kalıcı durum hatası üzerinde etkisi incelenmiştir.

### 2. Veri Kümesi Hazırlanması

Bu çalışmada merkezi örüntü üretici ile kontrol edilen iki bacaklı robot modelinden faydalanılmıştır [9]. Robot modeli Şekil

1’de gösterilmekte olup görselde kullanılan parametreler Tablo 1’de açıklanmıştır [9]. Robot modeli kütleli ikişer adet uyluk ve baldır uzuvlarıyla robotun gövdesinin üstünü temsil eden kalçada noktasal bir kütlelen oluşmaktadır. Robot modelinin uzaydaki konumu 6 elemanlı  $[x_1, x_2, x_5, x_8, x_{11}, x_{14}]$  genelleştirilmiş koordinat vektörü ile ifade edilebilmektedir. Robot modelinin her bir bacağı kalça, diz ve ayak bileği eklemlerinde üretilen toplam 6 tork ile sürülmektedir. Noktasal ayak modeli kullanılan bilek eklemleriyle zemin arasında temas olmadığında bilek ekleminde üretilen tork robot modelinin dinamiklerini etkilememektedir. Robotun ayaklarının zemin ile teması Şekil 1’de gösterildiği gibi dikey ve yatay eksenlerde birbirine paralel yay ve sönümleyici ile modellenmiştir. Kullanılan esnek zemin modelinin bir sonucu olarak robotun bir ayağı zemine temas etmediğinde robot modeli 5 eklemden üretilen tork ile kontrol edildikten sonra tahrikli (underactuated) bir sisteme dönüşmektedir. Bu çalışma kapsamında benzetim ortamında robot modeli diferansiyel denklemleri 10 KHz örnekleme frekansı ile Euler Metodu kullanılarak nümerik bir şekilde hesaplanmıştır.



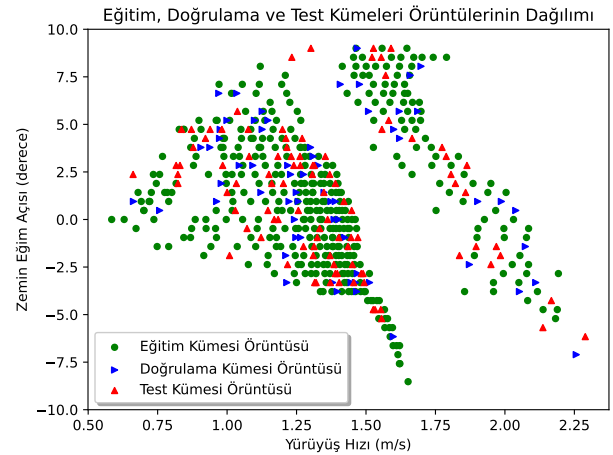
Şekil 1: İki ayaklı robot modeli eklemlerinin, uzuvlarının, uzuv açılarının ve yer ile etkileşim modelinin gösterimi

Tablo 1: Robot modelinde kullanılan terimlerin açıklamaları

Parametre	Tanım
$l_1, l_2$	alt ve üst bacak (baldır ve uyluk) uzuv boyu
$x_1, x_2$	kalçanın $\hat{X}$ ve $\hat{Y}$ eksenlerindeki konumu
$x_3, x_4$	sağ uyluğun $\hat{X}$ ve $\hat{Y}$ eksenlerindeki konumu
$x_6, x_7$	sol uyluğun $\hat{X}$ ve $\hat{Y}$ eksenlerindeki konumu
$x_9, x_{10}$	sağ baldırın $\hat{X}$ ve $\hat{Y}$ eksenlerindeki konumu
$x_{12}, x_{13}$	sol baldırın $\hat{X}$ ve $\hat{Y}$ eksenlerindeki konumu
$x_5, x_8, x_{11}, x_{14}$	uzuvların açıları
$M$	gövde kütlesi
$m_1, m_2$	üst ve alt bacak uzuvlarının kütlesi
$g$	yerçekimi ivmesi
$T_{r1}, T_{r2}, T_{r3}, T_{r4}, T_{r5}, T_{r6}$	tork değerleri ve yönleri
$k$	yay katsayısı
$d$	sönümleme katsayısı

Kontrolcü olarak kullanılan sinir ağı mimarileri ve katman türlerinin hız kalıcı durum hatasına etkisinin değerlendirilmesi hedeflendiğinden sinir ağlarının gözetimli öğrenme ile eğitilmesinin yeterli olacağına karar verilmiştir. Bu doğrultuda veri kümesinin oluşturulmasında [23]’de yapıldığı gibi parametreleri optimize edilen ve [9]’da sunulan merkezi örüntü üretici denklemlerinden faydalanılmıştır. Böylece optimize edilmiş merkezi örüntü üretici ile robot modeli daha geniş zemin eğim açısı aralığında başarılı yürüyüş gerçekleştirmektedir. Benzetim çalışmalarında modifiye edilmiş merkezi örüntü üretici diferansiyel denklemleri 10 KHz örnekleme frekansı ile 4. derece Runge Kutta metodu kullanılarak nümerik bir şekilde hesaplanmıştır.

Veri kümesi oluştururken [3, 10] aralığında eşit aralıklı 40 noktada hız uyarım değerinde ve  $[-9, 9]$  derece aralığında eşit aralıklı 39 noktada zemin eğiminde yürüyüş verisi toplanmıştır. Bu değişkenlerin 1560 adet ikili kombinasyonu için yapılan deneylerden 546 adedinde (%35’inde) 10 saniye yürüyüş gerçekleştirilmiştir. Elde edilen 546 yürüyüş örüntüsünün 384’ü (%70,33) eğitim, 64’ü (%11,72) doğrulama ve 98’i (%17,95) test kümelerini oluşturmak üzere Şekil 2’te gösterildiği gibi gruplanmıştır.



Şekil 2: Merkezi örüntü üretici ile üretilen yürüyüş örüntülerinin yürüyüş hızı ve zemin eğim açılarına göre dağılımı

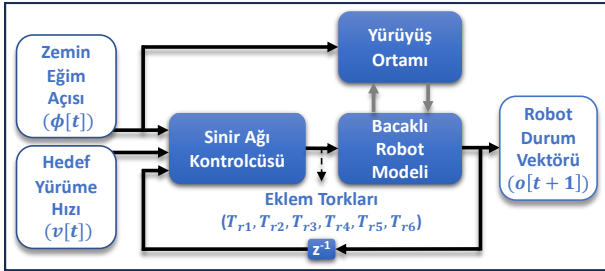
Yürüyüş örüntüleri sinir ağlarının eğitiminde kullanılmadan önce çeşitli ön işlemlerden geçirilmiştir. İlk olarak yürüyüş örüntülerinin örnekleme frekansı desimasyon işleminden geçirilip 10 KHz’den 100 Hz’e düşürülmüştür. Sonra tüm veri kümelerindeki başarılı yürüyüş örüntülerinin her bir özneliğinin alabileceği maksimum mutlak değerler bulunmuştur. Ardından veri kümelerindeki tüm örüntülerin öznelikleri bulunan maksimum mutlak değerlerin üç katına bölünmüştür. Böylece bütün veri kümelerinde öznelikler mutlak değerleri maksimum 1/3 olacak şekilde normalize edilmiştir. Sonra yürüyüş örüntülerindeki 6 eklem torku sinir ağı çıktısı olarak belirlenmiştir. Geriye kalan 12 geri besleme bağlantısı, 4 zemin tepki kuvveti, 10 uzuv konumu, 1 yürüyüş hız hedefi ve 1 zemin eğim açısı olmak üzere toplam 28 öznelik sinir ağı girdisi olarak seçilmiştir. Böylece her bir yürüyüş örüntüsü için 100 Hz örnekleme frekansı ile 10 saniye boyunca elde edilen 1000 zaman adımı uzunluğundaki girdi ve çıktı serileri aşağıda verilmiştir:

- 6 Sinir ağı çıktı serisi [Boyut: 6x1000]

- 6 Eklem torku ( $T_{r_i}, i = 1, \dots, 6$ )
- 28 Sinir ağı girdi serisi [Boyut: 28x1000]
  - 12 Geribesleme bağlantısı ( $Feed_i(x, \dot{x}), i = 1, \dots, 12$ ), bkz. [21]
  - 4 Zemin tepki kuvveti ( $F_{g_i}, i = 1, \dots, 4$ ), bkz. [21]
  - 10 Uzun konumu ( $x_1, x_2, x_3, x_4, x_6, x_7, x_9, x_{10}, x_{12}, x_{13}$ )
  - 1 Yürüyüş hız hedefi ( $v[t]$ )
  - 1 Zemin eğim açısı ( $\phi[t]$ )

### 3. Yapay Sinir Ağı Kontrolcüsü

İki bacaklı robot modeli ile yapay sinir ağının ilişkisi Şekil 3'te sunulan diyagramda gösterilmektedir. Kontrolcü zemin eğim açısını ve hedef yürüme hızı değerlerini referans girdiler olarak almaktadır. Bunlara ek olarak bir önceki zaman adımındaki robot modeli çıktı vektörünü ( $o[t]$ 'yi) oluşturan geri besleme bağlantılarını ( $Feed_i(x, \dot{x})$ ), zemin tepki kuvvetlerini ( $F_{g_i}$ ) ve uzun konumlarını ( $x_i$ ) da girdi olarak alır. Bu 28 girdi kontrolcü sinir ağı tarafından değerlendirilerek 6 adet eklem torku çıktısı oluşturulmaktadır. Ayrıntılı olarak sinir ağının girdileri veri kümesi oluşturulurken hesaplanan normalizasyon katsayısına bölünmekte, çıktıları da bu katsayı ile çarpılmaktadır. Daha sade ve anlaşılır bir anlatım için normalizasyon blokları Şekil 3'te gösterilmemiştir. Hesaplanan eklem torkları ile robot modelinin yürüyüşü kontrol edilmektedir.



Şekil 3: Sinir ağı kontrolcüsünün ve robot modelinin etkileşimi

Bu çalışmada kontrolcü olarak Şekil 4'te gösterildiği gibi son katmanı regresyon katmanı olan iki ve üç katmanlı yapay sinir ağları kullanılmıştır. Kontrolcü yapay sinir ağlarında çıkış katmanında her biri normalize edilmiş bir eklem torku değerini üretecek olan 6 adet doğrusal sinir modeli kullanılmıştır.

### 4. Kontrolcülerin Karşılaştırılması

Farklı problemlerde farklı türde sinir ağı katmanları kullanımı ile daha iyi performansa ulaşılabilir. Bunlara örnek olarak, nesne tespit problemlerinde evrimsel [14] ve zaman serisi kestirim problemlerinde tekrarlayan [17] katmanların kullanımı ile yüksek başarıya ulaşılması verilebilir.

Bu çalışmada kontrolcü olarak bir veya iki gizli katmana sahip 13 farklı sinir ağı mimarisi önerilmiştir. Bu sinir ağlarında kullanılan öğrenilebilir parametre sayısı ağırlık sayısı sütununda Tablo 2'de açıklanmıştır. Daha önceki çalışmalarımızda tekrarlayan sinir ağı katmanlarının yürüyüş kontrol probleminde ileri



Şekil 4: Değerlendirilen iki ve üç katmanlı sinir ağı mimarileri

beslemeli katmanlara kıyasla daha iyi performans gösterdiği görülmüştür [21, 23]. Bu nedenle öncelikle 50, 100 ve 200 Long Short-Term Memory (LSTM) tekrarlayan sinir modeli içeren bir gizli katmanlı sinir ağları test edilmiştir [24]. Sonrasında her katmanında 31 adet LSTM sinir modeli içeren iki gizli katmanlı sinir ağı denenmiştir. Bundan sonraki denemelerde 50 LSTM sinir modeli içeren tek gizli katmanlı sinir ağının parametre sayısını geçmeyecek şekilde diğer sinir ağları oluşturulmuştur. Bu şekilde oluşturulan Gated Recurrent Unit (GRU) sinir ağı katmanı ve hiperbolik tanjant (tanh) aktivasyon fonksiyonu kullanılan Elman Recurrent Neural Network (ERNN) sinir ağı katmanı içeren tek gizli katmana sahip sinir ağları test edilmiştir [25, 26]. Ardından bir katmanlı tekrarlayan sinir katmanı olan ve diğer katmanı tanh, ReLU [27], ELU [28] veya Leaky-ReLU [29] ileri beslemeli sinir katmanlarından oluşan iki gizli katmanlı sinir ağları denenmiştir.

Önerilen sinir ağları 0, 0,1 ve 0,5 değerlerindeki 3 farklı  $L_2$  regülasyon katsayısı [30] ve 0,001 öğrenme sabiti başlangıç değeri kullanılarak AdamW eniyileyicisi [31] ile her 100 epokta bir güncel sinir ağı parametreleri kaydedilerek 3000 epok boyunca eğitilmiştir. Ardından her 100 epokta bir kaydedilen sinir ağı parametreleri kullanılarak benzetim ortamında robot modeli eğitim, doğrulama ve test veri kümelerinde bulunan örüntülerin hedef yürüyüş hızları ve zemin eğim açısı şartlarında yürüyüş kontrolü gerçekleştirilmiştir.

Bu şartlar altında elde edilen yürüyüş başarıları ve hız kalıcı durum hatası yüzdeleri Tablo 2'de raporlanmıştır. Tablo 2 hazırlanırken sinir ağlarının eğitimleri boyunca öncelikle en yüksek doğrulama kümesi yürüyüş başarısına sahip olduğu kaydedilen eğitim adımında elde edilen sinir ağı parametreleri kullanılarak sonuçlar sunulmuştur. Eğer kaydedilen birden fazla eğitim adımında aynı maksimum doğrulama kümesi başarı oranına ulaşılmışsa bu eğitim adımlarında ulaşılan en yüksek eğitim kümesi başarılarını veren sinir ağı parametreleri kullanılarak sonuçlar sunulmuştur. Eğer bu oran da farklı eğitim adımları için aynı bulunursa bunlar arasından en düşük doğrulama kümesi hız kalıcı durum hatası veren sinir ağı parametreleri kullanılarak sonuçlar raporlanmıştır. Bu şartlar altında seçilen eğitim adımı Tablo 2'de epok sayısı sütununda açıklanmıştır.

### 5. Tartışma

Tablo 2 hazırlanırken öncelikle kullanılacak maksimum sinir ağı ağırlık sayısının belirlenmesi için LSTM sinir katmanı içeren tek gizli katmanlı sinir ağları 0, 0,1 ve 0,5  $L_2$  regülasyon

Tablo 2: Sinir ağı kontrolcülerinin yürüyüş kontrol performansları

Sinir Ağı Gizli Katman Mimarisi	Ağırlık Sayısı	$L_2$ Katsayısı	Epok Sayısı	Eğitim Kümesi		Doğrulama Kümesi		Test Kümesi	
				Yürüyüş Başarısı	Hız Kalıcı Durum Hatası	Yürüyüş Başarısı	Hız Kalıcı Durum Hatası	Yürüyüş Başarısı	Hız Kalıcı Durum Hatası
50 LSTM	16306	0	2400	%81,77	%6,62	%79,69	%6,25	%83,67	%5,24
		0,1	3000	%79,95	%5,69	%79,69	%5,71	%78,57	%6,59
		0,5	2800	%84,38	%9,44	%85,94	%9,01	%85,71	%8,87
100 LSTM	52606	0	2300	%77,86	%7,5	%78,12	%7,64	%78,57	%6,79
		0,1	1900	%87,24	%8,05	%84,38	%9,49	%86,73	%7,93
		0,5	500	%94,53	%14,65	%95,31	%13,13	%93,88	%12,82
200 LSTM	185206	0	1000	%68,75	%4,48	%75	%4,49	%74,49	%3,82
		0,1	1600	%74,74	%7,6	%78,12	%7,67	%75,51	%7,68
		0,5	1500	%77,86	%13	%81,25	%12,19	%83,67	%13,07
31 LSTM, 31 LSTM	15692	0	1900	%70,57	%9,96	%71,88	%9,69	%76,53	%9,69
		0,1	2100	%77,86	%7,66	%75	%6,03	%83,67	%6,76
		0,5	800	%94,27	%12,39	%90,62	%11,06	%94,9	%10,69
71 Tanh, 33 LSTM	16255	0	2000	%65,36	%5,26	%70,31	%5,13	%70,41	%5,59
		0,1	2800	%90,1	%9,78	%90,62	%8,64	%92,86	%8,89
		0,5	1300	%92,97	%13,56	%90,62	%11,97	%92,86	%11,94
71 LeakyReLU, 33 LSTM	16255	0	1600	%74,22	%6,64	%75	%5,75	%76,53	%5,74
		0,1	2700	%79,69	%13,32	%76,56	%14,95	%78,57	%14,57
		0,5	2700	%83,85	%10,16	%85,94	%10,1	%80,61	%9,86
43 LSTM, 74 LeakyReLU	16262	0	900	%76,56	%5,31	%79,69	%5,1	%78,57	%4,81
		0,1	700	%88,54	%10,98	%84,38	%9,53	%91,84	%10,6
		0,5	2400	%88,02	%12,14	%84,38	%13,98	%85,71	%11,73
<b>43 LSTM, 74 ReLU</b>	<b>16262</b>	<b>0</b>	<b>1100</b>	<b>%84,11</b>	<b>%4,19</b>	<b>%82,81</b>	<b>%3,84</b>	<b>%84,69</b>	<b>%3,16</b>
		0,1	1100	%84,38	%4,27	%85,94	%4,78	%85,71	%4,09
		0,5	2200	%92,45	%11,79	%92,19	%11,98	%92,86	%10,3
43 LSTM, 74 ELU	16262	0	500	%57,81	%6,83	%53,12	%8,6	%61,22	%7,2
		0,1	2900	%78,91	%13,89	%78,12	%12,89	%80,61	%13,18
		0,5	800	%84,38	%10,33	%89,06	%9,5	%84,69	%8,81
59 GRU	16113	0	400	%62,76	%7,19	%65,62	%6,1	%70,41	%5,37
		0,1	700	%70,31	%4,6	%70,31	%4,26	%77,55	%4,54
		0,5	2700	%73,96	%4,51	%65,62	%4,53	%75,51	%4,22
110 ERNN	16066	0	2800	%77,6	%17,38	%76,56	%16,5	%76,53	%17,21
		0,1	2500	%81,51	%5,26	%78,12	%4,74	%82,65	%4,76
		0,5	2000	%58,07	%21,88	%59,38	%16,85	%66,33	%18,24
83 ERNN, 74 ReLU	16045	0	1900	%71,09	%6,3	%68,75	%5,75	%76,53	%4,88
		0,1	1900	%77,34	%7,53	%87,5	%8,08	%82,65	%7,53
		0,5	2600	%68,49	%24,7	%70,31	%23,39	%74,49	%20,72
83 ERNN, 74 LeakyReLU	16045	0	1100	%70,05	%11,35	%75	%12,48	%70,41	%12,93
		0,1	2900	%77,86	%6,67	%78,12	%7	%79,59	%6,19
		0,5	2100	%79,69	%11,76	%79,69	%10,51	%84,69	%9,59

katsayılarıyla eğitilmiştir. Yapılan eğitimlerin Tablo 2'deki sonuçları incelendiğinde yürüyüş başarısı ile hız kalıcı durum hatası arasında genelde pozitif bir korelasyon olduğu görülmüştür. Diğer bir ifadeyle genelde yürüyüş başarısı artarken hız kalıcı durum hatasının da artma eğiliminde olduğu tespit edilmiştir. Örneğin  $L_2$  parametresi artarken yürüyüş başarısı ve hız kalıcı durum hatası genelde artma eğilimindedir. Buna karşın başarılı bir yürüyüşte kontrolcünün yüksek yürüyüş başarısı sağlarken düşük hız kalıcı durum hatasıyla çalışması gerekmektedir.

Bu kapsamda test veri kümesinde %80 ve üzeri yürüyüş ba-

şarısı ve aynı zamanda %6'dan daha düşük hız kalıcı durum hatası kriterlerini karşılayan sinir ağıları incelendiğinde, 0  $L_2$  regülarizasyon katsayısı ile eğitilen, tek gizli katmanında 50 LSTM sinir modeli bulunan ve toplamda 16306 öğrenilebilir parametre sayısına sahip sinir ağı başarılı bulunmuştur. Bundan sonra test edilen sinir ağıları bu parametre sayısını geçmeyecek şekilde tasarlanmıştır. Tek gizli katmanında 59 GRU sinir modeli içeren sinir ağının test kümesi hız kalıcı durum hatası 0,1 ve 0,5  $L_2$  regülarizasyon katsayıları ile yapılan eğitimlerde azalmıştır ancak 0,5  $L_2$  regülarizasyon katsayısı ile test kümesi yürüyüş ba-

şarı oranı da düşmüştür. Bu nedenle en iyi sonuç hem yürüyüş başarısını arttıran hem de hız kalıcı durum hatasını düşüren 0,1  $L_2$  regülarizasyon katsayısı ile elde edilmiştir. Benzer bir davranış tek gizli katmanında 110 ERNN sinir modeli bulunan sinir ağında da gözlemlenmiştir. Bu sinir ağı 0,1  $L_2$  regülarizasyon katsayısı ile en yüksek yürüyüş başarısına ve en düşük hız kalıcı durum hatasına ulaşmış olup 50 LSTM sinir modeli bulunan sinir ağından daha düşük hız kalıcı durum hatasına neden olunmuştur. Bunun ardından en az biri tekrarlayan katman olan iki gizli katmanlı sinir ağları test edilmiştir. Bunlar arasında sırası ile 43 ve 74 sinir modeli bulunan LSTM ve ReLU gizli katmanlarına sahip sinir ağı 0  $L_2$  regülarizasyon katsayısı ile test kümesinde %84,69 yürüyüş başarısına ve bütün eğitilen sinir ağları arasında en düşük kalıcı durum hatası oranı %3,16'ya ulaşmış olup, Tablo 2'de kalın harflerle işaretlenmiştir. Bu sinir ağının eğitim, doğrulama ve test veri kümelerindeki her örüntü için elde ettiği yürüyüş başarısı ve hız kalıcı durum hatası Şekil 5'te görselleştirilmiştir. Bundan sonra bu kontrolcü sinir ağı seçilen kontrolcü olarak isimlendirilecektir.

Tablo 2 incelendiğinde ikinci gizli katman olarak ileri beslemeli ReLU katmanı kullanımı ile ELU, LeakyReLU, Tanh ve LSTM katmanlarının kullanımından daha düşük hız kalıcı durum hatasına ulaşılmıştır. Her ne kadar her iki gizli katmanı da LSTM olan sinir ağı ile %94,9 ile en yüksek test kümesi yürüyüş başarısına ulaşılmış olsa da, beraberinde oluşan yüksek hız kalıcı durum hatası başta belirlenen kriterlere uymadığı için bu sinir ağı mimarisi başarısız bulunmuştur. Diğer bir ilgi çekici başarı da tek gizli katmanlı ERNN kullanılan sinir ağı ile elde edilmiştir. Ancak hem yürüyüş başarısı seçilen kontrolcünden daha düşük hem de hız kalıcı durum hatası seçilen kontrolcünden daha yüksek gerçekleşmiştir.

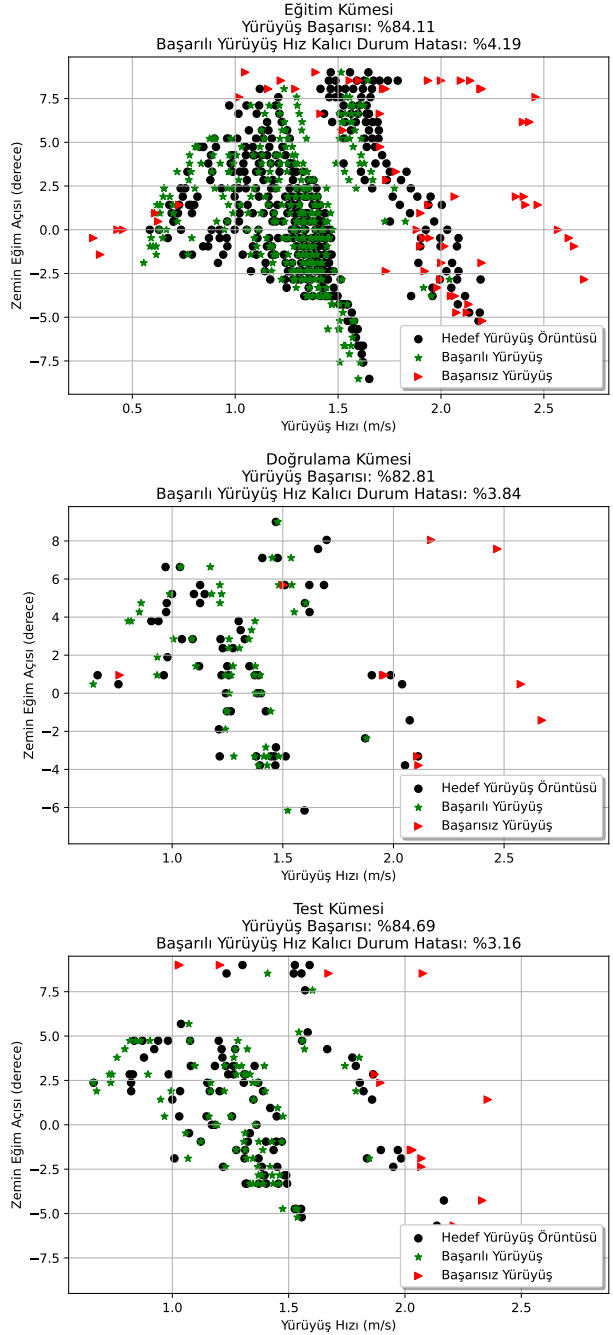
## 6. Sonuçlar

Bu çalışmada bir ve iki gizli katmanlı sinir ağlarının gözetimli öğrenmeyle eğitilip iki bacaklı yürüyüş kontrolünde ulaştığı yürüyüş başarısı ve hız kalıcı durum hatasıyla ağ mimarisi ve ağ katmanlarındaki sinir modelleri arasındaki ilişki incelenmiştir.

Tablo 2'de raporlanan sonuçlar incelendiğinde LSTM ve ERNN katmanlarının bacaklı yürüyüş kontrolünde GRU katmanlarından daha başarılı olduğu ve birden fazla gizli katmanlı sinir ağı mimarileriyle daha yüksek yürüyüş başarısına ve daha düşük hız kalıcı durum hatasına ulaşılabilceği görülmüştür. Benzer şekilde farklı ileri beslemeli sinir modelleri ile farklı yürüyüş başarısı oranlarına ve hız kalıcı durum hatalarına ulaşılmıştır. İkinci gizli katmanda ReLU sinir modeli kullanımı ELU, LeakyReLU, Tanh ve LSTM kullanımından daha başarılıdır.

Her ne kadar  $L_2$  regülarizasyonu kullanımı yürüyüş başarısında ve hız kalıcı durum hatasında genelde artışa neden olsa da bazı sinir ağlarında yürüyüş başarısı artarken hız kalıcı durum hatasının azaldığı durumlar da gözlemlenmiştir. Bu nedenle  $L_2$  regülarizasyonun burada faydalı olabileceği sonucuna varılmıştır.

Elde edilen sonuçlar yapay sinir ağları ile yürüyüş hızı kontrolü yapılabileceğini göstermektedir. Bu çalışmanın sinir ağlarının eğitiminde Dropout gibi daha ileri regülarizasyon tekniklerinin kullanımıyla, üç ve daha fazla katmanlı ağ mimarilerinin denenmesiyle ve farklı sinir modellerinin denenmesiyle genişletilmesinin faydalı olacağı değerlendirilmektedir.



Şekil 5: Seçilen kontrolcünün veri kümelerindeki örüntülerin girdilerine karşılık gerçekleştirdiği yürüyüş performansı

## 7. Teşekkür

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 120E104 numaralı proje kapsamında desteklenmiştir.

## 8. Kaynakça

- [1] U. Saranlı, M. Buehler, and D. E. Koditschek, "Rhex: A simple and highly mobile hexapod robot," *The Interna-*

- tional Journal of Robotics Research*, vol. 20, no. 7, pp. 616–631, 2001.
- [2] B. Katz, J. Di Carlo, and S. Kim, “Mini cheetah: A platform for pushing the limits of dynamic quadruped control,” in *2019 international conference on robotics and automation (ICRA)*. IEEE, 2019, pp. 6295–6301.
  - [3] S. Feng, X. Xinjilefu, C. G. Atkeson, and J. Kim, “Optimization based controller design and implementation for the atlas robot in the darpa robotics challenge finals,” in *2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids)*. IEEE, 2015, pp. 1028–1035.
  - [4] E. Guizzo, “By leaps and bounds: An exclusive look at how boston dynamics is redefining robot agility,” *IEEE Spectrum*, vol. 56, no. 12, pp. 34–39, 2019.
  - [5] P. Holmes, R. J. Full, D. Koditschek, and J. Guckenheimer, “The dynamics of legged locomotion: Models, analyses, and challenges,” *SIAM review*, vol. 48, no. 2, pp. 207–304, 2006.
  - [6] C. L. Shih, “Ascending and descending stairs for a biped robot,” *IEEE Transactions on Systems, Man and Cybernetics-Part A: Systems and Humans*, vol. 29, no. 3, pp. 255 – 268, 1999.
  - [7] K. Nishiwaki, S. Kagami, Y. Kuniyoshi, M. Inaba, and H. Inoue, “Online generation of humanoid walking motion based on a fast generation method of motion pattern that follows desired zmp,” in *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2002, pp. 2684 – 2689.
  - [8] S. Shigemi, A. Goswami, and P. Vadakkepat, “Asimo and humanoid robot research at honda,” *Humanoid robotics: A reference*, pp. 55–90, 2018.
  - [9] G. Taga, Y. Yamaguchi, and H. Shimizu, “Self-organized control of bipedal locomotion by neural oscillators in unpredictable environment,” *Biological cybernetics*, vol. 65, no. 3, pp. 147–159, 1991.
  - [10] A. J. Ijspeert, “Central pattern generators for locomotion control in animals and robots: A review,” *Neural Networks*, vol. 21, no. 4, pp. 642–653, 2008.
  - [11] C. P. Santos, N. Alves, and J. C. Moreno, “Biped locomotion control through a biomimetic cpg-based controller,” *Journal of Intelligent & Robotic Systems*, vol. 85, no. 1, pp. 47–70, 2017.
  - [12] C. Liu, J. Yang, K. An, and Q. Chen, “Rhythmic-reflex hybrid adaptive walking control of biped robot,” *Journal of Intelligent & Robotic Systems*, vol. 94, no. 3-4, pp. 603–619, 2019.
  - [13] B. Çatalbaş, B. Çatalbaş, and Ö. Morgül, “Human activity recognition with different artificial neural network based classifiers,” in *2017 25th Signal Processing and Communications Applications Conference (SIU)*, May 2017, pp. 1–4.
  - [14] P. Jiang, D. Ergu, F. Liu, Y. Cai, and B. Ma, “A review of yolo algorithm developments,” *Procedia Computer Science*, vol. 199, pp. 1066–1073, 2022.
  - [15] A. Toshev and C. Szegedy, “DeepPose: Human pose estimation via deep neural networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2014.
  - [16] A. Mathis, P. Mamidanna, K. M. Cury, T. Abe, V. N. Murthy, M. W. Mathis, and M. Bethge, “DeepLabcut: markerless pose estimation of user-defined body parts with deep learning,” *Nature neuroscience*, vol. 21, no. 9, pp. 1281–1289, 2018.
  - [17] S. Urolagin, N. Sharma, and T. K. Datta, “A combined architecture of multivariate lstm with mahalanobis and z-score transformations for oil price forecasting,” *Energy*, vol. 231, pp. 120963, 2021.
  - [18] F. L. Lewis, S. Jagannathan, and A. Yesildirak, *Neural network control of robot manipulators and non-linear systems*, CRC Press, 1998.
  - [19] B. Çatalbaş, “Recurrent neural network learning with an application to the control of legged locomotion,” M.S. thesis, Bilkent University, 2015.
  - [20] B. Çatalbaş and Ö. Morgül, “Tekrarlayan sinir ağları ile iki ayaklı robot hareket kontrolü,” in *2019 21. Otomatik Kontrol Ulusal Toplantısı TOK 2019*, 2019, pp. 270–277.
  - [21] B. Çatalbaş and Ö. Morgül, “Two-legged robot motion control with recurrent neural networks,” *Journal of Intelligent & Robotic Systems*, vol. 104, no. 4, pp. 59, 2022.
  - [22] B. Çatalbaş, B. Çatalbaş, and Ö. Morgül, “Two-legged robot system identification with artificial neural networks,” in *2020 28th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2020, pp. 1–4.
  - [23] B. Çatalbaş, *Control and system identification of legged locomotion with recurrent neural networks*, Ph.D. thesis, Bilkent University, 2022.
  - [24] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
  - [25] K. Cho, B. Van M., D. Bahdanau, and Y. Bengio, “On the properties of neural machine translation: Encoder-decoder approaches,” *arXiv preprint arXiv:1409.1259*, 2014.
  - [26] J. L. Elman, “Finding structure in time,” *Cognitive science*, vol. 14, no. 2, pp. 179–211, 1990.
  - [27] V. Nair and G. E. Hinton, “Rectified linear units improve restricted boltzmann machines,” in *Icml*, 2010.
  - [28] D.-A. Clevert, T. Unterthiner, and S. Hochreiter, “Fast and accurate deep network learning by exponential linear units (elus),” *arXiv preprint arXiv:1511.07289*, 2015.
  - [29] A. L. Maas, A. Y. Hannun, and A. Y. Ng, “Rectifier nonlinearities improve neural network acoustic models,” in *Proceedings of the 30th International Conference on Machine Learning (ICML)*, 2013.
  - [30] A. Krogh and J. A. Hertz, “A simple weight decay can improve generalization,” in *Advances in neural information processing systems*, 1992, pp. 950–957.
  - [31] I. Loshchilov and F. Hutter, “Decoupled weight decay regularization,” *arXiv preprint arXiv:1711.05101*, 2017.