Makine Öğrenimi Kullanımıyla Kendini Süren Araba Simülasyonu

Proje Ekibi: Gökçe Önen
Danışman: Prof. Dr. Efendi Nasiboğlu

Amaç

Bu projede, simülasyon ortamında tasarlanan araçların, hız ve uzaklık sensörü bilgilerini kullanarak engellerden aktif olarak kaçınmalarını ve yerleştirildikleri pisti kat etmelerini sağlayacak bir eğitim modeli oluşturmak amaçlanmıştır.

Hedefler

Araçların simülasyonunda, mümkün olduğunca gerçeğe yakın sonuçlar elde etmek hedeflenmiştir. Bunu gerçekleştirmek için araca ve piste gerçekçi fizik hesaplamaları ve parametreleri eklenmiştir.
Bunlar:

- Pist yüzeyi (asfalt) sürtünmesi katsayısı
- Araç lastik sürtünmesi katsayısı
- Araç ivme, hız, moment, eylemsizlik hesaplamaları
- Motor torku
- Motor eylemsizliği
- Araç patinajı, savrulması
- Yerçekimi
- Direksiyon dönüş hızı (sağ, sol)

Otonomluğun sağlanması için aracın sensörlerinden aldığı verileri (37 adet: 1 hız, 36 uzaklık sensörü) işleyip çıktı olarak direksiyonun döndürülmesi gereken yönü ve gaz/fren pedalının basılması gereken miktarı (1: tam gaz, fren boşta; 0: gaz ve fren boşta; -1: tam fren, gaz boşta vb.) verecek bir yapay sinir ağı tasarlanmıştır. Bu yapay sinir ağının eğitiminin genetik algoritma ile gerçekleştirilmesi hedeflenmiştir.

Tasarım

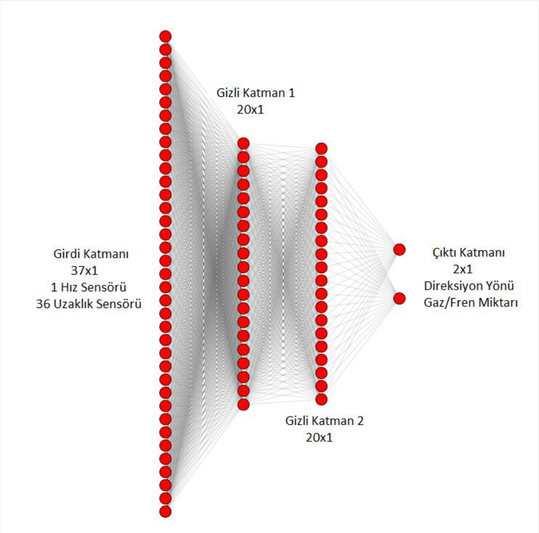

Yapay Sinir Ağı Topolojisi

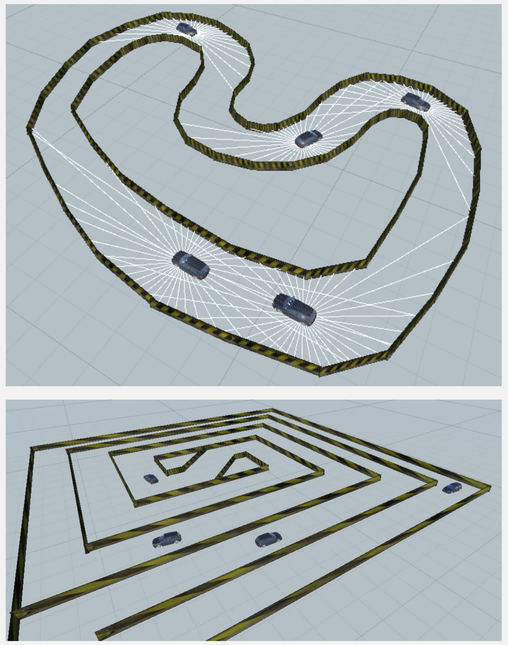

Eğitim Pistlerinden Görüntüler

Sonuç ve Öneriler

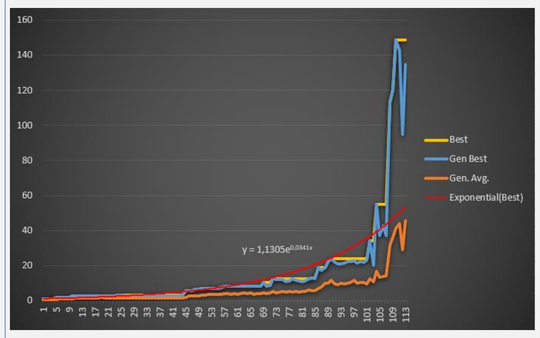

Eğitim Sonuçları
Y: Fitness değerleri
X: Nesil sayısı
Best: O nesle kadar elde edilen en iyi fitness
Gen. Best: Neslin en iyi fitness değeri
Gen. Avg.: Nesil ortalama fitness değeri
Exponetial Best: Best değerlerinin üstel regresyon ile yaklaşımı

Uygulanan eğitim sonucunda elde edilen sürücü yapay sinir ağı, bilinmeyen ortamlarda engellerden kaçınarak hareketini başarılı bir şekilde sürdürebilmektedir.
Araç, turu sırasında piste eklenen engellerden de kaçınarak dinamik ortamlarda da başarı göstermiştir.
Aracın genetik algoritmayla eğitimi, sürekli ileri giden bir süreç değildir. Her ne kadar her neslin en iyileri elitizmle bir sonraki nesle kalıtılsa da neslin ortalama ve en iyi uygunluk değerleri azalma gösterebilmektedir. Bunun sebebi, simülasyon içerisindeki rastgeleliklerdir (Time.DeltaTime, pürüzlü yüzeyler, lastik sürtünmeleri vb.). Gerçek hayat koşullarına daha uygun olması amacıyla bu parametrelerdeki rastgelelikler sistemde tutulmuştur. Öte yandan, bu etkileri kontrol altında tutmak amacıyla 'batch training' yöntemi kullanılmıştır.

Uygulama

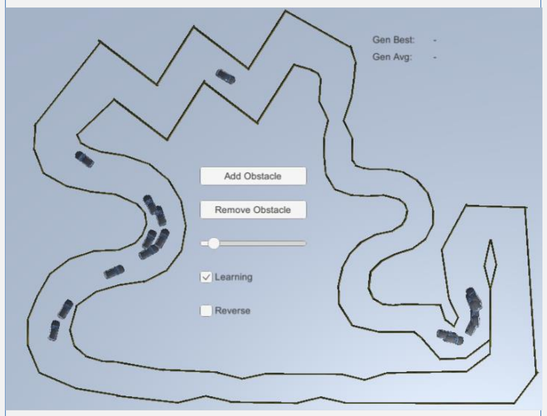

Uygulama Eğitim Görseli

Kaynakça

- Montana, D. J., & Davis, L. (1989, August). Training Feedforward Neural Networks Using Genetic Algorithms. In *IJCAI* (Vol. 89, pp. 762-767).
- Schaffer, J. D., Whitley, D., & Eshelman, L. J. (1992, June). Combinations of genetic algorithms and neural networks: A survey of the state of the art. In *Combinations of Genetic Algorithms and Neural Networks, 1992., COGANN-92. International Workshop on* (pp. 1-37). IEEE.
- Whitley, D. (1988). Applying genetic algorithms to neural network problems: A preliminary report. *Unpublished manuscript*.
- Whitley, D., Starkweather, T., & Bogart, C. (1990). Genetic algorithms and neural networks: Optimizing connections and connectivity. *Parallel computing*, *14*(3), 347-361.
- Whitley, D. (1989, June). Applying genetic algorithms to neural network learning. In *Proceedings of the Seventh Conference (AISB89) on Artificial Intelligence and Simulation of Behaviour*(pp. 137-144). Morgan Kaufmann Publishers Inc..
- Weiß, G. (1990). *Combining neural and evolutionary learning: Aspects and approaches*. Inst. für Informatik.
- http://www.aforgenet.com/framework/features/neural_networks.html
- https://assetstore.unity.com/packages/tools/physics/arcade-car-physics-119484