Farklı Yapay Sinir Ağı Temelli Sınıflandırıcılar ile İnsan Hareketi Tanımlama

Human Activity Recognition with Different Artificial Neural Network Based Classifiers

Burak Çatalbaş, Bahadır Çatalbaş, Ömer Morgül
Elektrik ve Elektronik Mühendisliği Bölümü
Bilkent Üniversitesi
Ankara, Türkiye
{catalbas,cbahadir,morgul}@ee.bilkent.edu.tr

Özetçe —İnsan Hareketi Tanımlanması, taşıdığı önem ve sınırlı öznetelik vektörü ile yüksek sınıflandırma oranlarına ulaşmasında karşılaşılan zorluk nedeniyle popüler bir araştırma konusudur. Bireylerin hareket ölçülebilirliğinin akıllı telefonların içinde gömülü bulunan atalet ölçüm birimleri sayesinde artması ile birlikte, bu alanda toplanan veri miktarı artmakta ve daha başarılı sınıflandırıcıların tasarlanabilmesine imkan sağlanmaktadır. Yapay sinir ağları, konvansiyonel sınıflandırıcılara göre sınıflandırma sorunlarında daha iyi performans sergileyebilmektedir. Bu çalışmada, Irvine Kaliforniya Üniversitesi (UCI) veri setine yapay sinir ağı temelli bir sınıflandırıcı önermek için çeşitli yapay sinir ağı yapıları denenmiş olup, bu sınıflandırıcılar ile elde edilen başarı oranları literatürdeki aynı veri kümesi için bulunan sonuçlarla karşılaştırılmıştır.

Anahtar Kelimeler—*insan hareketi tanımlama; yapay sinir ağları; kümeleyici; sınıflandırıcı.*

Abstract—Human Activity Recognition is a popular topic of research, with the importance it carries and its limited feature vector, to reach high success rates because of the difficulty faced in classification. With the increase of movement measurability for individuals via inertia measuring units embedded inside the smartphones, the data amount increases which lets new classifiers to be designed with higher success in this field. Artificial neural networks can perform better at such classification problems in comparison to conventional classifiers. In this work, various artificial neural networks have been tried to form a classifier for the University of California (UCI) Human Activity Recognition dataset and resulting success rates for those classifiers are compared with existing results for same dataset in the literature.

Keywords—*human activity recognition; artificial neural networks; clustering; classifier.*

I. GİRİŞ VE MOTİVASYON

Gelişen teknoloji ve akıllı telefonlara erişimin dünya çapında artışı ile makine öğrenmesi alanında kullanılan veri miktarında büyük bir artış gözlemlenmektedir. Bu tip telefonlarda bulunan ivmeölçer ve jiroskop içeren atalet ölçüm birimleri sayesinde insan hareketleri eskisine kıyasla daha hızlı, kolay ve sağlıklı şekilde takip edilebilmektedir. Bu durum tıbbi, askeri

ve benzeri birçok alanda hareket takip edici ve anlamlandırıcı sistemlerden faydalanmayı kaçınılmaz hale getirmiştir.

Bu potansiyel karşısında sınıflandırma teknikleri de doğal olarak gelişim göstermektedir. Klasik Destek Vektör Makineleri ve benzeri sınıflandırıcı sistemlerin yanı sıra artan hesaplama gücü sayesinde yapay sinir ağları, k-en yakın komşu gibi algoritmalar pratik olarak bu tip veri setlerine uygulanabilir hale gelmiştir [1]. Bununla birlikte spesifik olarak yapay sinir ağları bazı örüntü tanımlama problemlerinde diğer metotlara kıyasla daha başarılı sonuçlara ulaşabilmektedir [2].

Bu çalışmada üzerine çok sayıda çalışma yapılmış UCI İnsan Hareketi Tanımlama veri setine yapay sinir ağı temelli birbirinden farklı yapıya sahip sınıflandırıcılar uygulanmıştır. Bu sınıflandırıcılar Tek Katmanlı Ön-beslemeli Yapay Sinir Ağı, Çift Katmanlı Ön-beslemeli Yapay Sinir Ağı, ve Rezervuar İçeren Çift Katmanlı Ön-beslemeli Yapay Sinir Ağı temelli sınıflandırıcılardır. Tüm sınıflandırıcılar için veri üreticisi tarafından ayrılan test kümesi üzerinde ölçülen başarı oranları literatürde var olan sonuçlar ile kıyaslanmıştır.

II. VERİ SETİ VE VAROLAN LİTERATÜR

A. Veri Seti

Veriler insanın 6 farklı hareketinden oluşmaktadır (yürüme, merdivenden yukarı yürüme, merdiven aşağı yürüme, oturma, durma, yatma). 19-48 yaş aralığındaki 30 kişi tarafından yapılan bu hareketler 50 Hertz frekansında Samsung marka Galaxy S II model akıllı telefonun atalet ölçüm birimi tarafından örneklenmiş olup, bu örneklerden 561 tane ön işlemden geçirilmiş özneteliğe sahip 7352 adet örüntü içeren eğitim örnekleme ve 2947 adet örüntü içeren test örnekleme oluşturulmuştur [3].

B. Literatürdeki Sonuçlar

Veri seti oluşturulduğu tarihten beri çeşitli tekniklerle analiz edilmeye çalışılmış, birbirinden farklı öğrenme mantığına sahip sınıflandırıcı ve kümelendiricilerin eğitilmesinde ve test edilmesinde kullanılmıştır. Bu veri setinde edinilen en başarılı sınıflandırıcı sonuçlarından biri Bire-Bir Destek Vektör Makinesi bazlı bir öğrenim tekniğine sahip sınıflandırıcı tarafından alınmıştır. B. Romera Paredes ve meslektaşları tarafından uygulanan bu metotla test setinde %96,4 gibi bir sınıflandırma

başarısı elde edilmiştir [4]. Bu değere yakın sonuç veren başka bir yöntem ise %96,23 başarı oranına ulaşmıştır [5]. Anılan iki sınıflandırıcı 2013'te düzenlenen İnsan Hareketi Tanımlama yarışmasında en yakın sınıflandırıcıdan %1,5-2 farkla en başarılı çözümler olmuşlardır [6]. Ayrıca aynı çalışmada bulunan Bire-Tüm Destek Vektör Makinesi bazlı öğrenim tekniğine dayalı başka bir sınıflandırıcı aynı veri seti üzerinde %93,72 ve k-en yakın komşu modellenli bir diğer sınıflandırıcı ise %90,6 oranında başarı elde etmiştir [4]. Veri setini elde eden ekibin uyguladığı çok-sınıflı Destek Vektör Makinesi ise %90 üzerinde başarı elde edememiştir [7]. Sonuç olarak bu veri seti üzerinde birçok sınıflandırıcı tasarlanmış olup, farklı başarı yüzdelere sahip sonuçlar rapor edilmiştir.

III. KULLANILAN METOTLAR

Yapılan çalışmada sırasıyla tek katmanlı ön-beslemeli, çift katmanlı ön-beslemeli ve rezervuar içeren çift katmanlı ön-beslemeli sinir ağına dayalı sınıflandırıcılar kullanılmıştır.

A. Yapay Sinir Ağlarının Yapısı ve Eğitim Yöntemleri

Yapay sinir ağları 20. yüzyıla uzanan bir tarihe sahiptir. Biyolojik sinir ağlarını taklit etme amaçlayan çalışmalarda önemli bir adım, 1943'te bilim adamları Pitts ve McCulloch tarafından basitleştirilmiş bir sinir modelinin öne sürülmesi olmuştur [8]. Bunu Frank Rosenblatt'ın Algılayıcı (Perceptron) ve sonra oluşturulan Çok Katmanlı Algılayıcı (Multilayer Perceptron) sinir ağı modelleri takip etmiştir [9].

Yapay sinir ağlarının eğitiminde Gradyan Alçalma (Gradient Descent) benzeri metotlar kullanılmaktadır. Gradyan Alçalma prensibiyle çalışan Geri Yayılma (Backpropagation) metodunun geliştirilmesiyle çok katmanlı sinir ağları sınıflandırmada öncüllerinden daha başarılı olabilmektedir [9].

Bu çalışmada eşik (threshold) terimi içermeyen sinir ağının eğitimi, çıkış katmanındaki i siniri için aşağıdaki denklemlere göre olmaktadır. Öncelikle (1)'de gösterildiği gibi var olan bağlantı ağırlığı değerleri (w_{ij}) ile girdi değerleri (x_j) çarpılarak ağırlıklı toplam (y_i) oluşturulmakta ve (2)'de görüldüğü üzere bu değer doğrusal olmayan bir fonksiyon olan hiperbolik tanjanttan ($\tanh(\cdot)$) geçirilerek sinirin asıl çıktı değeri (o_i) bulunmaktadır. Bu değer istenilen çıktı değeri (d_i) ile karşılaştırılıp, hata miktarı (3)'te verildiği gibi bulunmakta, bu hatanın kısmi türevine (4) ve öğrenme sabitine (η) göre hesaplanan güncelleme değeri (5)'te gösterildiği gibi sinirin eski bağlantı ağırlığı değerlerine eklenerek yeni bağlantı ağırlıkları bulunur.

$$y_i = \sum_{j=1}^N w_{ij} x_j \quad (1)$$

$$o_i = \tanh(y_i) \quad i = 1, 2, \dots, N \quad (2)$$

$$E = \sum_i (d_i - o_i)^2 \quad (3)$$

$$\frac{\partial E}{\partial w_{ij}} = -2(d_i - o_i) \tanh'(y_i) x_j(t) \quad (4)$$

$$w_{ij} = w_{ij} + \Delta w_{ij} = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \quad (5)$$

Denklemler (1)-(5) ile Tek Katmanlı Yapay Sinir Ağları (Single Layer Neural Networks) eğitilebilmektedir. Bu çalışmada bu yöntem kullanılarak eğitilen tek katmanlı ön-beslemeli sinir ağı modeli Şekil 1' de gösterilmiştir.

Bu yöntemden farklı olarak, Çok Katmanlı Sinir Ağlarında (Multi Layer Neural Networks) çıkış katmanı dışındaki katmanların eğitimi Geri Yayılma prensibi ile yapılabilmektedir. Bu çalışmada bu yöntem kullanılarak eğitilen iki katmanlı ön-beslemeli sinir ağı modeli Şekil 2'de gösterilmiştir.

Rezervuar içeren Ön-Beslemeli Yapay Sinir Ağlarında sadece çıkış katmanı eğitilmektedir [9]. Bu eğitim yapılırken kullanılan çıkış katmanının genişletilmiş girdi değerleri Tek Katmanlı Yapay Sinir Ağlarından farklı olarak, asıl girdi değerleri ile istenen boyuttaki rastgele matrisin çarpılması ve doğrusal olmayan bir fonksiyondan geçirilmesi ile belirlenir. Sonuç olarak bu çalışmada kullanılan söz konusu yapı ile Çok Katmanlı Sinir Ağları arasındaki farklılık, Şekil 2'de belirtilen W_1 katmanının ağırlık matrisinin eğitilmemesinden ibarettir.

Şekil 1: Tek katmanlı sinir ağı kullanan sınıflandırıcı yapısı.

Spesifik olarak bahsettiğimiz bu modeller dışında hem ikiden fazla katman içeren ön-beslemeli yapay sinir ağları ve benzeri yöntemlerle hem de rezervuar içeren tekrarlı yapay sinir ağları ile sınıflandırıcılar oluşturulabilmektedir [10].

B. Eğitim ve Test Uygulamaları

Tek katmanlı ön-beslemeli yapay sinir ağı ile yapılan çalışmada 6 çıkış katmanı siniri kullanılmıştır. Bu sinirlerin teşkil ettiği yapay sinir ağındaki bağlantılar eğitimin başlangıcında 0.01 standart sapma ile rastgele olarak Gaussian dağılımından, 561x6 bir matris olarak oluşturulmuştur. Çift

Şekil 2: İki katmanlı sinir ağı kullanan sınıflandırıcı yapısı.

katmanlı ön-beslemeli yapay sinir ağı ise iki tane matris ile temsil edilmekte, ancak N parametresiyle anılan gizli sinir sayısı istenildiği gibi değiştirilebildiği için matris boyutları gizli katman için $561 \times N$, çıkış katmanı için $N \times 6$ olmaktadır. Tek katmanlı sinir ağı ile yapılan çalışmadaki dağılım ile başlatılan bu matrisler Gradyan Alçalma ve Geri Yayılma yöntemleri ile eğitilir. Rezervuar içeren ön-beslemeli yapay sinir ağlarında ise çift katmanlı yapay sinir ağı modelinden farklı olarak sadece çıkış katmanı eğitilmekte, diğer katman ise eğitilmemekte ve her zaman başlangıç koşullarında bırakılmaktadır. Bu çalışmadaki tüm sinir ağlarında aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmaktadır.

Eğitim en uygun olduğu düşünülen 330000 kere tekrar edilen bir döngüden oluşmaktadır. Her döngüde 6 sınıf içeren toplam 6969 tane eğitim örneğinden birer örnek, sınıf sırasıyla -her sınıf içinden rastgele olmak üzere- yapay sinir ağına sokulmakta, çıkan sonuca göre ise yapay sinir ağının çıkış katmanı sinirleri öğrenim oranına göre Gradyan Alçalma mantığına göre eğitilmektedir. Eğer gizli katman sinirlerinin de eğitilmesi gerekiyor ise eğitim Geri Yayılma yöntemi ile yapılır. Böylece yapay sinir ağındaki bağlantı ağırlıkları, her sınıfa eşit ağırlıkla olmak üzere eğitilmektedir. Ayrıca eğitimdeki her 100 döngü sonrasında 383 tane örneklemden oluşan ve eğitimde kullanılmayan bir doğrulama seti yapay sinir ağına girdi olarak verilmekte ve sınıflandırma başarıları ile karşılık gelen bağlantı matrisi kaydedilmektedir. Eğitim sonunda doğrulama setinde en yüksek başarıya sahip bağlantı matrisi saklanmaktadır.

Test aşaması eğitilmiş yapay sinir ağının 6 sınıfa ait toplam 2947 adet örnek içeren test seti üzerindeki genel ve sınıf bazındaki sınıflandırma başarı oranlarının hesaplanmasından oluşmaktadır. Bu başarı oranları hesaplanırken 6 çıktı sinirinin en yüksek tepki vereninin numarası ile bu tepkiye sebep olan girdi örneğinin etiket numarasının aynı olması beklenmektedir. Son olarak bu test örneklemini için yapılan sınıflandırmayı belirten karışıklık matrisi oluşturulmaktadır.

IV. SONUÇLAR

A. Eğitim Şartlarının Sonuçlar Üzerindeki Etkileri

Çalışmalarda farklı yapay sinir ağı tipleri, doğrulama örneklemini genişlikleri ve eğitim döngü sayıları gibi eğitim şartları denenmiştir. Ayrı ayrı incelemek gerekirse, sinir ağı tipi dışındaki eğitim şartlarının yapay sinir ağının başarısına etkisi şöyle gerçekleşmiştir:

- Doğrulama örneklemini eğitim için verilen örneklem içinden alınmış ve iki örneklem tüm çalışma boyunca ayrı tutulmuştur. İlk olarak 184 örnek içeren bir doğrulama seti kullanılmış ve bu sette %100 başarı elde edilmesi sebebiyle doğrulama seti büyüklüğü 383 örneğe çıkarılmıştır.
- Eğitim seti için döngü sayısı olarak seçilen 100000, 330000 ve 500000 sayıları arasında yapılan kıyaslamalara göre, 500000 döngü kullanılarak yapılan çeşitli denemelerde en başarılı doğrulama seti sonuçları 50000. ve 400000. döngülerin arasında dağılmıştır. Bu sebepten dolayı başarı ve eğitim zamanı bakımından daha verimli olacağı düşünülen 330000 döngü sayısında karar kılınmıştır.

B. Eğitim, Doğrulama ve Test Setinde Alınan Sonuçlar

Eğitim setinde alınan sonuçlar, 330000 döngüde kullanılan örneklerin başarılı ve başarısız sınıflandırılmalarının sayılması ile bulunmuştur. Doğrulama setindeki başarıya göre test setini sınıflandıracak bağlantı matrisi seçilmektedir.

Yapay sinir ağlarının eğitiminde kullanılan öğrenim sabiti, L2 regülazasyon katsayısı ve gizli katmandaki sinir sayısı parametreleri için farklı değerler kullanılmış olup en yüksek başarıya sahip olan kombinasyonlarının test seti üzerindeki sınıflandırma başarıları tek katmanlı ön-beslemeli sinir ağları için Tablo I'de, çift katmanlı ön-beslemeli sinir ağları için Tablo II'de ve rezervuar içeren çift katmanlı ön-beslemeli sinir ağları için Tablo III'de verilmiştir.

Gizli katmandaki sinir sayısının artması rezervuar içeren ön-beslemeli ağlarda performans artışına sağlarken çift katmanlı ön-beslemeli ağlarda başarı oranlarını düşürmüştür. Buna ek olarak her iki tip ağda da L2 regülazasyonu katsayısının artması halinde sınıflandırma başarısında düşüş görülebilmektedir. Büyük öğrenim sabiti kullanılması tek katmanlı ön-beslemeli sinir ağındaki sınıflandırma performansına olumsuz etki ederken, diğerlerinde sınıflandırma başarıları ile öğrenim sabiti arasında önemli bir korelasyon tespit edilememiştir. Ancak öğrenme sabitinin aşırı uyma (overfitting) problemine yol açtığı bazı durumlar da tablolarda görülebilir.

TABLO I: Tek katmanlı ön-beslemeli sinir ağlarının sınıflandırmadaki başarı oranları. η : öğrenme sabiti

Sabitler	Başarı Oranları
$\eta = 1,25 \cdot 10^{-4}$	%96,06
$\eta = 5 \cdot 10^{-4}$	%95,08
$\eta = 1,25 \cdot 10^{-3}$	%94,81

Bu çalışmada ulaşılan en yüksek başarı, rezervuar içeren çift katmanlı yapay sinir ağı ile elde edilmiştir. Tablo 4 ve 5'de

TABLO II: İki katmanlı ön-beslemeli sinir ağlarının sınıflandırmadaki başarı oranları. η : öğrenme sabiti, λ : L2 regülarizasyon sabiti, N : Gizli katman sinir sayısı

Sabitler		Başarı Oranları	
		$N=500$	$N=1000$
$\lambda = 0$	$\eta = 1,25 \cdot 10^{-4}$	%95,49	%93,45
	$\eta = 1,25 \cdot 10^{-3}$	%84,97	%78,55
$\lambda = 0,005$	$\eta = 1,25 \cdot 10^{-4}$	%93,32	%92,81
	$\eta = 1,25 \cdot 10^{-3}$	%79,23	%80,35

TABLO III: Rezervuar içeren iki katmanlı ön-beslemeli sinir ağlarının sınıflandırmadaki başarı oranları. η : öğrenme sabiti, λ : L2 regülarizasyon sabiti, N : Gizli katman sinir sayısı

Sabitler		Başarı Oranları		
		$N=200$	$N=561$	$N=1000$
$\lambda = 0$	$\eta = 1,25 \cdot 10^{-4}$	%94,47	%95,96	%95,11
	$\eta = 5 \cdot 10^{-4}$	%93,55	%95,28	%96,03
	$\eta = 1,25 \cdot 10^{-3}$	%95,22	%95,39	%96,2
	$\eta = 1,25 \cdot 10^{-2}$	%93,65	%94,60	%95,35
$\lambda = 0,005$	$\eta = 1,25 \cdot 10^{-4}$	%94,47	%95,35	%94,27
	$\eta = 5 \cdot 10^{-4}$	%94,1	%95,18	%95,28
	$\eta = 1,25 \cdot 10^{-3}$	%94,2	%94,94	%94,88
	$\eta = 1,25 \cdot 10^{-2}$	%91,48	%93,28	%91,72
$\lambda = 0,05$	$\eta = 1,25 \cdot 10^{-4}$	%93,96	%94,4	%95,89
	$\eta = 5 \cdot 10^{-4}$	%94,3	%91,99	%94,84
	$\eta = 1,25 \cdot 10^{-3}$	%89,48	%94,33	%91,41
	$\eta = 1,25 \cdot 10^{-2}$	%91,21	%89,45	%91,79

bu sinir ağına ait sınıf bazlı başarı oranları ve karışıklık matrisi sırasıyla verilmiştir. Bahsedilen yapay sinir ağında 1000 gizli rezervuar ve 6 çıkış katmanı siniri bulunmakta olup, eğitim $1,25 \cdot 10^{-3}$ öğrenme sabiti ile L2 regülarizasyon kullanılmadan yapılmıştır. En başarısız yapay sinir ağı ise 1000 gizli sinire sahip, $1,25 \cdot 10^{-3}$ öğrenme sabiti ile eğitilen ve L2 regülarizasyon kullanılmayan çift katmanlı ön-beslemeli yapay sinir ağı olmuştur. Bu durumun oluşmasında yapay sinir ağındaki eğitilen bağlantı sayısının artmasının aşırı uymaya (overfitting) sebebiyet vermiş olması ihtimali üzerinde durulmaktadır.

TABLO IV: En yüksek başarıyı sağlayan sinir ağının eğitim, doğrulama ve test setlerindeki hareket bazlı başarı oranları.

Aktivite Sınıfı	Başarı Oranları		
	Eğitim Seti	Doğrulama Seti	Test Seti
Yürüme	%97,51	%100	%98,79
Yukarı Yürüme	%96,37	%100	%97,66
Aşağı Yürüme	%97,88	%98,39	%94,29
Oturma	%88,74	%96,77	%91,04
Ayakta Durma	%79,87	%96,61	%94,92
Yatma	%98,25	%100	%100
Toplam	%92,34	%98,69	%96,2

C. Çalışmada Varılan Sonuçların Değerlendirilmesi

Çalışma sonunda elde edilen en başarılı sınıflandırıcı olan rezervuar içeren çift katmanlı ön-beslemeli sinir ağı, test setinde %96,2 gibi yüksek bir başarıya ulaşmıştır. Bu veri setine

TABLO V: Karışıklık matrisi test setindeki örneklemden oluşturulmuştur. Matriste satırlar örneklemin gerçek sınıfını, sütunlar sınıflandırıcı tarafından atanılan sınıfı göstermektedir. Esas köşegen doğru atanan örneklem sayısını göstermektedir.

Sınıf	Yürüme	Yukarı Yürüme	Aşağı Yürüme	Oturma	Ayakta Durma	Yatma
Yürüme	490	3	3	0	0	0
Yukarı Yürüme	10	460	1	0	0	0
Aşağı Yürüme	4	20	396	0	0	0
Oturma	0	4	0	447	37	3
Ayakta Durma	1	0	0	26	505	0
Yatma	0	0	0	0	0	537

ait, literatürde bulunabilen en yüksek başarı oranı %96,4'tür. Böylece bu çalışmada tasarlanan yapay sinir ağı temelli sınıflandırıcı, 2013 yılında bu veri seti ile düzenlenen yarışmada önerilen tüm sınıflandırıcılar arasında ilk 3'e girebilecek bir başarı oranına ulaşmıştır [6]. Çalışma genelinde sabit tutulan doğrulama setinin değişken hale getirilmesi ve oto-kodlayıcı gibi eğitim öncesinde öznitelik çıkarımı yapılmasını sağlayan metotların kullanılması ile bu veri setinde edinilen %96,2 başarı oranının üzerine çıkabilecek bir sınıflandırıcının oluşturulabileceği düşünülmektedir.

BİLGİLENDİRME

Yazarlardan Bahadır Çatalbaş Türkiye Bilimsel ve Teknolojik Araştırma Kurumuna (TÜBİTAK) verilen değerli finansal destek için teşekkür eder.

KAYNAKLAR

- [1] B. Çatalbaş, B. Yücesoy, G. Seçer, and M. Aslan, "A comparative study of classification methods for fall detection," in *2014 22nd Signal Processing and Communications Applications Conference (SIU)*, pp. 1315–1318, April 2014.
- [2] N. Srivastava, G. E. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting.," *Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [3] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "A public domain dataset for human activity recognition using smartphones," in *21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2013*, 2013.
- [4] B. Romera-Paredes, M. S. Aung, and N. Bianchi-Berthouze, "A one-vs-one classifier ensemble with majority voting for activity recognition," in *ESANN 2013 proceedings, 21st European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, pp. 443–448, 2013.
- [5] M. Kästner, M. Strickert, T. Villmann, and S.-G. Mittweida, "A sparse kernelized matrix learning vector quantization model for human activity recognition.," in *ESANN*, 2013.
- [6] J. L. Reyes-Ortiz, A. Ghio, X. Parra, D. Anguita, J. Cabestany, and A. Catala, "Human activity and motion disorder recognition: towards smarter interactive cognitive environments.," in *ESANN*, Citeseer, 2013.
- [7] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine," in *International Workshop on Ambient Assisted Living*, pp. 216–223, Springer, 2012.
- [8] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115–133, 1943.
- [9] F. Grezes, *Reservoir Computing*. PhD thesis, The City University of New York, 2014.
- [10] K. Kirby, "Context dynamics in neural sequential learning," in *Proc. Florida AI Research Symposium*, pp. 66–70, 1991.