

Tuş Vuruşa Dayalı Biyometrik Doğrulama

Keystroke Dynamics Based Biometric Authentication

Hasan Alp Boz

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi
Sabancı Üniversitesi
İstanbul, Türkiye
bozhasan@sabanciuniv.edu

Mert Gürkan

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi
Sabancı Üniversitesi
İstanbul, Türkiye
mertgurkan@sabanciuniv.edu

Berrin Yanıkoğlu

Mühendislik ve Doğa Bilimleri Fakültesi Mühendislik ve Doğa Bilimleri Fakültesi
Sabancı Üniversitesi
İstanbul, Türkiye
berrin@sabanciuniv.edu

Özetçe—Tuş vuruşu dinamikleri, kullanıcıların dijital cihazlardaki yazma davranışlarına göre kullanıcı kimlik doğrulaması yapmayı amaçlar. Tuş vuruşu dinamikleri, kullanıcı oturumlarından elde edilen serbest metne dayalı sürekli kimlik doğrulama için kullanılabilir. Bu çalışmada, zamanlama ve bölgesel özniteliklerin performansı, serbest metin veri kümesinde çeşitli makine öğrenme teknikleri ile test edilmiştir. Sınıflandırma problemi için en temsili öznitelik setini elde etmek için yönlü çizge, tutma süresi ve klavye mesafesine dayalı öznitelikler çıkarılmış ve farklı yapılandırılmalarda kullanılmıştır. Sonuçlar, dikkat mekanizmasına sahip çok katmanlı yapay sinir ağı modelinin, %0.13 FAR ve %2.5 FRR ile en iyi değerlendirme metriklerini verdiğini göstermektedir. Ek olarak, geliştirilen öznitelikler ve modeller sabit metin ile oluşturulmuş veri seti ile de test edilmiştir. Elde edilen sonuçlar oluşturulan öznitelik uzayının serbest metinler üzerindeki sınıflandırma problemine daha uygun olduğunu göstermektedir.

Anahtar Kelimeler—Biyometrik, Tuş Vuruşu Dinamikleri, Örüntü Tanıma

Abstract—Keystroke dynamics aims to perform user authentication based on users' typing behaviour on digital devices. Keystroke dynamics can be used for continuous authentication that is based on free-text obtained from users' sessions. In this study, performance of timing and regional features are tested with a variety of machine learning techniques on a free-text dataset. Di-graph, hold time and keyboard distance based features are extracted and utilized in different configurations to obtain the most representative feature set for the classification problem. The results show that the MLP model with attention mechanism yields the best evaluation metrics, with 0.13% FAR and 2.5% FRR. In addition, the developed features and models were tested with a static-text dataset. The obtained results show that the generated feature space is more suitable for the classification problem on free-text.

Index Terms—Biometrics, Keystroke Dynamics, Pattern Recognition

I. GİRİŞ

Biyometri bazlı kimlik doğrulama sistemleri bireylerin kendilerine özgü olan biyolojik ve davranışsal özniteliklerini tanımlama ve doğrulama işlemleri için kullanmayı amaçlar. Bu ekseninde, tuş vuruşu dinamikleri (*keystroke dynamics*) bazlı sistemler ise kullanıcıların klavye, sayısal tuş takımı ve dokunmatik ekran gibi dijital cihazlara girdi verme dinamiklerini,

ritmini ve zamanlama bilgisini, tanımlama ve doğrulama için kullanmayı amaçlayan davranışsal biyometrik sistemleridir. Kullanıcıların uzaktan kimlik doğrulama işlemine sokulabileceği tuş vuruşu dinamikleri çalışmaları basit bir yazılım ile gerçekleştirilebilir.

Şifre, PIN kodu gibi sabit metin üzerinden ilerleyen, kullanıcıların oturum açma işleme sırasında olmak kaydıyla tek sefer kimliklerinin doğrulandığı, tuş vuruşu dinamikleri çalışmalarına [1]–[3] ek olarak, oturum açma işlemi sonrasında kullanıcıların herhangi bir müdahaleye maruz kalmaksızın yazdıkları serbest metinden çıkarılan örüntülerine bağlı sürekli olarak doğrulandığı tuş vuruşu dinamikleri çalışmaları da mevcuttur [4]–[6]. Böylece, oturum süresince işlemlerin kimliği doğrulanan kullanıcı tarafından yapıldığına emin olunur.

Bu çalışmada, sürekli kimlik doğrulama amacıyla serbest metinlerden elde edilen çoklu öznitelik kümelerini, dikkat mekanizması içeren derin öğrenme ağına girdi olarak veren bir model mimarisi önerilmiştir. Ek olarak, önerilen öznitelik kümesi sabit metin üzerinde de değerlendirilmiştir.

II. İLGİLİ ÇALIŞMALAR

Tuş vuruşu dinamikleri çalışmalarında bir metnin özniteliklerini çıkarmak için tuşların bireysel ve kendi aralarındaki vuruş sürelerinden, yönlü çizgelerden (*di-graphs*) faydalanılır. Figür 1'de görülebileceği üzere, bir tuşa basış ve çekiş anı arasındaki zaman farkı *kalış süresi* (*dwell time*) olarak adlandırılır [7]. Ek olarak, birbirini takip eden iki ya da daha fazla tuşun arasındaki vuruş dinamiklerini saklayan özniteliklere *uçuş süresi* (*flight time*) adı verilir [7].

80'li yıllardan itibaren araştırmacılar farklı kullanıcılardan birden fazla oturumda toplanan sabit metinleri karakterler arasındaki yönlü çizgeler ile ifade edip, kullanıcıları tanımlamak ve doğrulamak için hipotez testi ve uzaklık bazlı istatistiksel metotlar [8], [9] ve makine öğrenmesi üstüne kurulu sınıflandırma metotları [10], [11] mevcuttur. Yönlü çizge öznitelikleri karar ağaçlarına girdi olarak verilerek %9.62 Hatalı Ret Oranı (*False Rejection Rate (FRR)*) ve %0.88 Hatalı Kabul Oranı (*False Acceptance Rate (FAR)*) elde etmiştir [10].

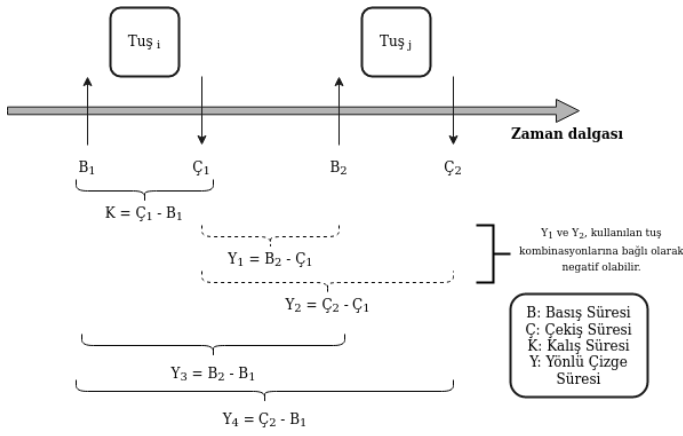


Fig. 1. Tuş Vuruşu Öznitelik Çıkarımı.

Serbest metin bazlı tuş vuruş dinamikleri çalışmaları [12]–[14] yakın zamanda ivme kazanmıştır. Yönlü çizge özniteliklerini elde etmek için genel yaklaşım karakterler arasındaki zaman farklarının özet bilgisini vermektir [7]. Bu bağlamda, iki farklı oturumdan elde edilen serbest metinlerdeki eşleşen yönlü çizgelerin eşleştirme aşamasında kullanılarak %5 FRR %0.005 FAR elde edilmiştir [15].

Derin öğrenme metotlarındaki başarımların artışı tuş vuruşu dinamikleri çalışmalarını da etkilemiştir. Serbest metinden elde edilen yönlü çizge özniteliklerinin CNN+RNN üzerine kurulu bir ağa girdi olarak verildiği çalışmalar mevcuttur [16]. Böylece, CNN ile yerel öznitelikler elde edilirken, RNN yapısı zaman eksenini üzerindeki ilişkileri öğrenmiş ve %1.95 FRR, %4.12 FAR elde edilmiştir. Dikkat mekanizması üzerine kurulu derin öğrenme modelleri ise gelişime açık bir durumdadır.

III. YÖNTEMLER

A. Veri Setleri

Projede, serbest yazı veri seti olarak LASER-2012 [17] veri seti kullanılmıştır. Bahsedilen veri setinde 20 katılımcı bulunmaktadır. Katılımcılardan oturumlara bağlı olarak üzere iki farklı türde görevler verilmiştir. Bu görev türlerinden ilki, ekranda görüntülenen metinlerin klavye aracılığı ile tekrarlanmasıdır. İkinci görev türünde ise, sorulan açık uçlu sorular için kullanıcılardan cevap oluşturmaları beklenmiştir. İki farklı görevden toplanan verinin birlikte kullanılmasının sınıflandırma performansına etkisi oldukça az olduğu için, bu çalışmada da kullanıcıların iki farklı görevlerinden gelen veri setleri arasında ayırım yapılmamıştır [17]. Veri setinde tek tuş vuruşu ve bu tuş vuruşuna ait nitelikler bulunması ile birlikte iki tuş vuruşu arasında geçen süreye ait nitelikler de bulunmaktadır. Veri seti yazım süresince kullanıcıların tuş vuruşları arasındaki süre belirtilecek şekilde düzenlenmiştir.

Sabit yazı verisi için ise CMU Keystroke Benchmark [18] veri setinden faydalanılmıştır. Bahsi geçen veri seti 51 katılımcının önceden belirlenen bir parola sekansını tekrarlı bir şekilde yazmalarını istenerek hazırlanmıştır. Veri seti, her katılımcının aynı parolayı 400 kez yazması ile hazırlanmıştır. Bununla birlikte, veri setinde kullanıcıların anonim kimlik




Fig. 2. Klavyenin üç alana ayrımı.

bilgileri, sabit parolanın yazıldığı oturum bilgisi ve yazım süresince elde edilen tuş vuruş nitelikleri bulunmaktadır. Elde edilen tuş vuruş nitelikleri karşılık gelen tuşların kalış ve uçuş süreleri olacak şekilde temsil edilmiştir.

B. Öznitelik Çıkarımı

Serbest yazı tuş vuruşu öznitelikleri çıkarımı için klavye üzerinde bulunan 58 farklı tuşlardan oluşturulabilecek tüm ikili tuş vuruş yönlü çizgeleri (*digraph*) dikkate alınmıştır. Katılımcıların her oturumu bir örnek olarak düşünülüp, her oturum için tuş vuruş yönlü çizgeleri için belirtilen sürelerin ortalaması alınmıştır. Dolayısıyla, kullanıcıların her oturumları için $58 * 58 = 3364$ adet yönlü çizge özniteliği üretilmiştir.

Figür 1’te de görülebileceği gibi yönlü çizge öznitelikleri, ardışık iki tuş arasındaki farklı basış ve çekiş süre kombinasyonları kullanılarak 4 farklı şekilde üretilebilir. Bu yöntemler Figür 1’de Y_1, Y_2, Y_3, Y_4 yönlü çizgeleri olarak gösterilmiştir. Bu çalışmada yönlü çizgeler ardışık tuş vuruşlarının basış süreleri arasındaki zaman farkı (Y_3) baz alınarak hesaplanmıştır.

Yönlü çizge özniteliklerine ek olarak, klavye tuşları ve bu tuşların vuruş süreleri tekil olarak da değerlendirilip 58 adet öznitelik daha üretilmiştir. Bu öznitelikler kullanıcıların tuş vuruşlarındaki kalış süreleri (*hold time*) olup (Figür 1’te K harfi ile ifade edilen), yönlü çizge özniteliklerinde olduğu gibi, kullanıcıların farklı tuş kalış süreleri de her tuş tekrarında toplanıp oturum sonrası o tuşun toplam tekrar etme sayısına bölünerek ortalaması alınmıştır.

Son olarak üretilen öznitelikler klavye uzaklık öznitelikleri olarak adlandırılabilir. Bu öznitelik grubunda iki farklı metot ile öznitelik uzayı genişletilmiştir. İlk olarak klavye sol el, sağ el ve boşluk tuşu (*spacebar*) olmak üzere ve Figür 2’de olduğu gibi 3 bölgeye ayrılmış ve kullanıcıların oturumlar esnasında tuşlanmış olduğu yönlü çizgeler bu bölgeler üzerinden incelenmiştir. Bu işlemin sonucunda ortaya çıkacak öznitelikler *LL, LR, LS, RL, RR, RS, SL* ve *SR* olarak adlandırılmış ve ardışık boşluk tuşu girdisi bulunmadığından *SS* özniteliği oluşturulamıştır. Yönlü çizge ve tuş kalış özniteliklerinde yapıldığı gibi bu özniteliklerin de her örnek için ortalamaları alınmıştır. İkincil olarak, daha önceki bir tuş vuruşu dinamikleri çalışması baz alınarak, yönlü çizgelerde birbirini takip eden tuşların arasındaki mesafelere esas alınarak bir öznitelik çıkarımı yapılmıştır [12]. Bu bağlamda, yönlü çizgelerdeki iki tuş arasındaki Chebyshev uzaklığı hesaplanıp aynı mesafede bulunan yönlü çizgeler bir arada olacak şekilde gruplanmıştır. Önceki özniteliklerde uygulandığı gibi,

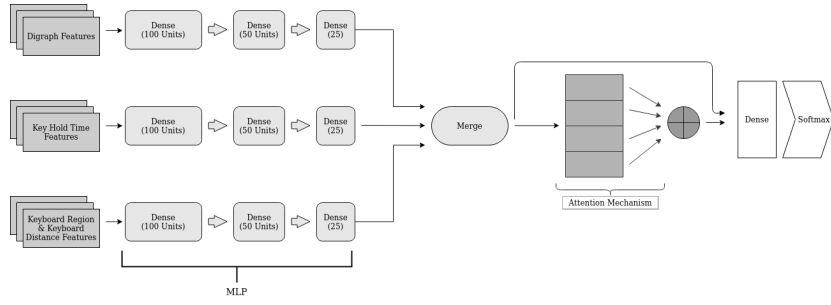


Fig. 3. Dikkat Mekanizması ile oluşturulan Yapay Sinir Ağ Modeli.

bu özniteliklerin de her oturum sonrası ortalama değerleri asıl değerler olarak kabul edilmiştir.

Chebyshev uzaklığı formülü aşağıda gösterilmiştir:

$$d_{ij} = \max_k \|x_{ik} - x_{jk}\|$$

Yukarıda belirtildiği gibi oluşabilecek tüm yönlü çizge öznitelik sayısının çok fazla olması ve bazı ikili tuş sekanslarının kullanıcıların istenilen metinleri yazarken hiç kullanılmaması, bu öznitelik grubu için bir boyut düşürme işleminin gerekliliğini doğurmuştur. Gereken öznitelik boyutu düşürme sağlanabilmesi için yönlü çizge öznitelik sayısı $58 * 58$ 'den 75 öznitelige düşürülmüştür. Bu işlem oluşan yönlü çizge öznitelikleri en sık tekrar edenden en az tekrar edene olacak şekilde sıralandıktan sonra, en çok tekrar eden yönlü çizgelerden farklı seçimler yapıp oluşturulan geçiş kümesi üzerindeki performansları göz önünde bulundurularak yapılmıştır. Farklı öznitelik sayısı seçimleri arasında en sık tekrar edilen 75 yönlü çizge öznitelik sayısı en başarılı sonuçlar ürettiği için daha sonra oluşturulacak tüm makine öğrenmesi modellerinde yönlü çizge bilgisini temsil etmesi için bu 75 öznitelik kullanılmıştır.

Sabit yazı veri seti için öznitelik üretme sürecinin serbest yazı veri seti için öznitelik üretme sürecine çokça benzediği belirtilmelidir. Sabit yazı veri seti için de yukarıda ifade edilen farklı öznitelik üretme metodlarının tamamı kullanılmıştır. Kullanılan veri seti oluşturma sürecinde kullanıcılardan yazılması istenen parola girdisi kısa ve sabit bir dizgi olduğu için oluşabilecek ikili yönlü çizgelerin sayısı sınırlıdır. Bu nedenle, klavyede bulunan tüm ikili tuş çizgelerden oluşacak bir öznitelik kümesi yerine sabit parolanın yazılması esnasında oluşacak 10 adet yönlü çizge özniteliği kullanılmıştır. Benzer şekilde, tuş kalış süresi öznitelik kümesi de sabit dizginin yazılması sonucu ortaya çıkacak öznitelikler ile oluşturulmuştur.

C. Kimlik Doğrulama Metodu

Oluşturulan öznitelik uzayı ile optimum sınıflandırma modelinin bulunması için çeşitli sınıflandırma algoritmaları veri seti üzerinde test edilmiştir. Farklı kullanıcıların her oturumları bir örnek olarak ele alınıp, sınıflandırma modellerine öznitelik uzayı sunulduktan sonra kullanıcı kimliklerinin tahmini beklenmiştir. Makine öğrenmesi modelleri

öncelikle sadece yönlü çizge öznitelikleri ile test edilmiş, daha sonra yönlü çizge, tuş kalış ve klavye uzaklığı baz alınarak oluşturulan öznitelikler ile birlikte de test edilmiştir. Kullanılan sınıflandırma modelleri *Rassal Orman Algoritması (Random Forest)*, *Çok Katmanlı Yapay Sinir Ağları (Multilayer Perceptron)* ve *Dikkat Mekanizması (Attention Mechanism)* ile oluşturulan çok katmanlı yapay sinir ağlarıdır [19].

Dikkat mekanizmasının yapay sinir ağ modeline eklenmesindeki temel amaç, sıralı bir formatta olan tuş vuruşu verisinin altında yatan öznitelik ilişkilerinin yapay sinir ağ modellerine tanıtılmasıdır. Aşağıda dikkat mekanizması ile oluşturulan yapay sinir ağ modelinin şeması gösterilmektedir. Oluşturulan yapay sinir ağ modelleri 3 tamamen bağlı (*dense*) katman ile oluşturulup Dikkat Mekanizması tamamen bağlı katmanlar sonrasında eklenmiştir. Dikkat mekanizması ile oluşturulan ağ modelinin şeması Figure 3'den görülebilir.

IV. DENEY SONUÇLARI

Tablo I'den de görülebileceği gibi en iyi FAR ve FRR sonuçları dikkat mekanizmasından da yararlanan yapay sinir ağ modeli ile elde edilmiştir.

TABLO I
SERBEST YAZI İLE TEST EDİLEN MAKİNE ÖĞRENMESİ MODELLERİNİN PERFORMANS METRİKLERİ.

Model	Öznitelik Kümesi	FAR	FRR	F1-Skoru
Rassal Orman	D	0.49%	9.43%	90.56
	D + K + KD	0.41%	7.54%	92.45
Çok Katmanlı Yapay Sinir Ağı	D	1.38%	26.25%	71.14
	KD	1.57%	30.00%	65.62
	K	0.42%	8.12%	91.40
	D + K	0.23%	4.37%	97.26
	D + K + KD	0.16%	3.125%	98.09
Dikkat Mekanizması + Çok Katmanlı Yapay Sinir Ağı	D	1.15%	21.87%	77.20
	KD	1.57%	30.00%	69.13
	K	0.42%	8.12%	93.74
	D + K	0.16%	3.125%	95.60
	D + K + KD	0.13%	2.5%	96.09

D: Yönlü Çizge öznitelikleri, K: Kalış öznitelikleri, KD: Klavye uzaklığı bazlı öznitelikler.

Aynı modeller sabit yazı veri setine uygulandıklarında, en iyi FAR ve FRR metrikleri yönlü çizge ve tuş kalış öznitelikleri kullanılarak eğitilen rassal orman modeli ile elde edilmiştir. Sabit veri setinde katılımcı ve katılımcıların tamamladıkları oturum sayıları fazla olduğundan örnek sayısı artmış ve bu nedenle oluşturulan yapay sinir ağ modelleri daha düşük döngü sayısı (*epoch*) ile denenebilmiştir. Serbest yazı için oluşturulan sinir ağ modelleri 1000 döngü ile test edilmişken, bu sayı sabit yazı veri seti için 50'ye düşürülmüştür. Sabit

yazı veri seti üzerinde test edilen modellerin değerlendirme metrikleri Tablo II'den incelenebilir.

TABLO II
SABIT YAZI İLE TEST EDİLEN MAKİNE ÖĞRENME SİSTEMLERİNİN
PERFORMANS METRİKLERİ.

Model	Öznitelik Kümesi	FAR	FRR	F1-Skoru
Rassal Orman	D + K	0.13%	6.6%	93.34
	D + K + KD	0.15%	7.7%	92.23
Çok Katmanlı Yapay Sinir Ağı (50 Döngü)	D	0.75%	37.71%	61.58
	KD	0.9%	45.09%	53.43
	K	0.78%	39.17%	59.9
	D + K	0.33%	16.97%	83.52
	D + K + KD	0.35%	17.55%	83.19
Dikkat Mekanizması + Çok Katmanlı Yapay Sinir Ağı (50 Döngü)	D	0.74%	37.28%	62.49
	KD	0.91%	45.88%	53.31
	K	0.76%	38.32%	61.27
	D + K	0.37%	18.87%	81.17
	D + K + KD	0.33%	16.63%	84.23

D: Yönlü Çizge öznitelikleri, K: Kalış öznitelikleri, KD: Klavye uzaklığı bazlı öznitelikler.

V. SONUÇLAR

Serbest yazı veri seti üzerinden elde edilen test sonuçları incelendiğinde dikkat mekanizmasının da içerdiği yapay sinir ağı modelinin en iyi değerlendirme metriklerine ulaştığı (0.13% FAR ve 2.5% FRR) görülebilir. Bu sonuçlar oluşturulan modelin devamlı ve serbest şekilde yazı girdisi girilen tuş vurumu kimlik doğrulama sistemleri için uygun olduğunu göstermektedir. Serbest yazı veri seti için diğer modellerle elde edilen test sonuçları da tuş kalış ve klavye uzaklığı özniteliklerinin de sınıflandırma problemi için önemli olduklarını göstermiştir.

Serbest yazı seti için elde edilen bulguların aksine, sabit veri setinde klavye uzaklığı öznitelikleri oluşturulan makine öğrenmesi modellerinin sınıflandırma performansını düşürmüştür. Bu sonuç sabit yazı veri seti için gerekli olan yazım görevinin çok kısa olması ve bu özniteliklerin anlamlılıklarının azalması ile açıklanabilir. Serbest yazı veri seti için hazırlanan öznitelik metodların aynı tuş vuruşlarının ve yönlü çizgelerin çokça gözlemlenmesine dayanması, bu metodları kullanan yapay sinir ağı modellerinin sabit yazı veri setinde yeteri kadar başarılı olmamasına neden olmuştur. Bu veri setinde en başarılı değerlendirme metrikleri (%0.13 FAR ve %6.6 FRR) rassal orman modeli ile elde edilmiştir.

KAYNAKLAR

- [1] R. Giot and A. Rocha, "Siamese networks for static keystroke dynamics authentication," in *IEEE International Workshop on Information Forensics and Security*, 2019.
- [2] S. Krishnamoorthy, L. Rueda, S. Saad, and H. Elmiligi, "Identification of user behavioral biometrics for authentication using keystroke dynamics and machine learning," in *Proceedings of the 2018 2nd International Conference on Biometric Engineering and Applications*. ACM, 2018, pp. 50–57.
- [3] C. Jadhav, S. Kulkarni, S. Shelar, K. Shinde, and N. V. Dharwadkar, "Biometric authentication using keystroke dynamics," in *2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*. IEEE, 2017, pp. 870–875.
- [4] S. Singh and K. Arya, "Key classification: a new approach in free text keystroke authentication system," in *2011 Third Pacific-Asia Conference on Circuits, Communications and System (PACCS)*. IEEE, 2011, pp. 1–5.
- [5] A. A. Ahmed and I. Traore, "Biometric recognition based on free-text keystroke dynamics," *IEEE Transactions on Cybernetics*, vol. 44, no. 4, pp. 458–472, 2013.

- [6] A. Messerman, T. Mustafić, S. A. Camtepe, and S. Albayrak, "Continuous and non-intrusive identity verification in real-time environments based on free-text keystroke dynamics," in *2011 International Joint Conference on Biometrics (IJCB)*. IEEE, 2011, pp. 1–8.
- [7] P. S. Teh, A. B. J. Teoh, and S. Yue, "A survey of keystroke dynamics biometrics," *The Scientific World Journal*, vol. 2013, 2013.
- [8] R. Joyce and G. Gupta, "Identity authentication based on keystroke latencies," *Communications of the ACM*, vol. 33, no. 2, pp. 168–176, 1990.
- [9] D. Song, P. Venable, and A. Perrig, "User recognition by keystroke latency pattern analysis," *Retrieved on*, vol. 19, 1997.
- [10] Y. Sheng, V. V. Phoha, and S. M. Rovnyak, "A parallel decision tree-based method for user authentication based on keystroke patterns," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 35, no. 4, pp. 826–833, 2005.
- [11] Z. Syed, S. Banerjee, Q. Cheng, and B. Cukic, "Effects of user habituation in keystroke dynamics on password security policy," in *2011 IEEE 13th International Symposium on High-Assurance Systems Engineering*. IEEE, 2011, pp. 352–359.
- [12] A. Alsultan, K. Warwick, and H. Wei, "Improving the performance of free-text keystroke dynamics authentication by fusion," *Applied Soft Computing*, vol. 70, pp. 1024–1033, 2018.
- [13] B. Li, H. Sun, Y. Gao, V. V. Phoha, and Z. Jin, "Enhanced free-text keystroke continuous authentication based on dynamics of wrist motion," in *2017 IEEE Workshop on Information Forensics and Security (WIFS)*. IEEE, 2017, pp. 1–6.
- [14] B. Ayotte, M. K. Banavar, D. Hou, and S. Schuckers, "Fast and accurate continuous user authentication by fusion of instance-based, free-text keystroke dynamics," in *2019 International Conference of the Biometrics Special Interest Group (BIOSIG)*. IEEE, 2019, pp. 1–6.
- [15] D. Gunetti and C. Picardi, "Keystroke analysis of free text," *ACM Transactions on Information and System Security (TISSEC)*, vol. 8, no. 3, pp. 312–347, 2005.
- [16] L. Xiaofeng, Z. Shengfei, and Y. Shengwei, "Continuous authentication by free-text keystroke based on CNN plus RNN," *Procedia Computer Science*, vol. 147, pp. 314–318, 2019.
- [17] K. Killourhy and R. Maxion, "Free vs. transcribed text for keystroke-dynamics evaluations," *07 2012*, pp. 1–8.
- [18] —, "Comparing anomaly-detection algorithms for keystroke dynamics," *08 2009*, pp. 125 – 134.
- [19] D. Bahdanau, K. Cho, and Y. Bengio, "Neural machine translation by jointly learning to align and translate," in *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*, 2015.