



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE QUIXADÁ
CURSO DE GRADUAÇÃO EM REDES DE COMPUTADORES

MATHEUS VINÍCIUS FERNANDES BARROS

***DYNAMIC TIME WARPING* COMO MÉTRICA DE SIMILARIDADE ENTRE OS
GESTOS DE USUÁRIOS DE *SMARTPHONES* COM FINALIDADE DE VALIDAÇÃO
DE IDENTIDADE**

QUIXADÁ
2024

MATHEUS VINÍCIUS FERNANDES BARROS

DYNAMIC TIME WARPING COMO MÉTRICA DE SIMILARIDADE ENTRE OS GESTOS
DE USUÁRIOS DE *SMARTPHONES* COM FINALIDADE DE VALIDAÇÃO DE
IDENTIDADE

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Redes de Computadores do Campus de Quixadá da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de Tecnólogo em Redes de Computadores.

Orientador: Prof. Dr. Arthur de Castro Callado

QUIXADÁ

2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

B279d Barros, Matheus Vinícius Fernandes.

Dynamic time warping como métrica de similaridade entre os gestos de usuários de smartphones com finalidade de validação de identidade. / Matheus Vinícius Fernandes Barros. – 2024.
75 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá, Curso de Redes de Computadores, Quixadá, 2024.

Orientação: Prof. Dr. Arthur de Castro Callado..

1. segurança da informação. 2. smatphones. 3. dynamic time warping. 4. aprendizado de máquina. 5. comparação de séries temporais. I. Título.

CDD 004.6

MATHEUS VINÍCIUS FERNANDES BARROS

DYNAMIC TIME WARPING COMO MÉTRICA DE SIMILARIDADE ENTRE OS GESTOS
DE USUÁRIOS DE *SMARTPHONES* COM FINALIDADE DE VALIDAÇÃO DE
IDENTIDADE

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Redes de Computadores do Campus de Quixadá da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de Tecnólogo em Redes de Computadores.

Aprovada em: 26 de Setembro de 2024

BANCA EXAMINADORA

Prof. Dr. Arthur de Castro Callado (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Me. Marcos Dantas Ortiz
Universidade Federal do Ceará (UFC)

Prof. Dr. João Marcelo Uchôa de Alencar
Universidade Federal do Ceará (UFC)

Prof. Dr. Sidartha Azevedo Lobo de Carvalho
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço à minha pequena e não tradicional família — mãe, avó e prima — por todo o apoio que me deram, por acreditarem em mim e por me incentivarem. Agradeço em especial a minha mãe, por ser um exemplo de esforço e dedicação aos estudos, e à minha avó, que com sua enorme determinação e ternura me proporcionou um ambiente para florescer e prosperar.

Agradeço também ao meu orientador, Professor Doutor Arthur de Castro Callado, que não desistiu de mim mesmo nos momentos mais sombrios dessa longa jornada. Sua insistência em mim é em grande parte o motivo pelo qual consegui chegar aqui.

Igualmente agradeço aos meus amigos, sem exceção, mas um nome vem com mais força a minha mente: Marcos Paulo, que com seu apoio e ouvidos abertos foi capaz de me incentivar durante os momentos em que tudo parecia estar indo mal. Cada um de vocês, meus amigos, contribuiu para este resultado, por isso, muito obrigado.

Por fim, agradeço às instituições e pessoas que disponibilizaram recursos e informações essenciais para a realização desta pesquisa. Sem a colaboração de todos, este trabalho não teria sido possível.

RESUMO

Este trabalho visa avaliar o impacto de métricas geradas com auxílio do algoritmo *Dynamique Time Warping* em modelos de detecção de anomalias treinados para autenticar um usuário móvel por fator de inerência através da interação do mesmo com uma tela de *smartphone*. A pesquisa foi realizada através da coleta dos dados de 33 usuários que se dispuseram a interagir com uma aplicação móvel, desenvolvida para este trabalho com objetivo de maximizar o número de gestos de deslize efetuados pelo usuário durante a coleta. A partir dos dados coletados, dois modelos de *Isolation Forest* foram treinados, um de referência que não usou as métricas de *Dynamique Time Warping* e outro que as usou. Os resultados indicaram melhora absoluta de 3,725%, o que representa uma melhora relativa de 8,40%, do modelo na tarefa de classificar gestos de intrusos como anômalos. O trabalho tem contribuição para a área de segurança de dispositivos e aplicações móveis, já que propõe uma melhoria a um método de autenticação. Por consequência, também contribui com a segurança dos usuários de *smartphones* que já são mais de 68% da população global.

Palavras-chave: segurança da informação; *smartphones*; dynamic time warping; aprendizado de máquina; comparação de séries temporais.

ABSTRACT

This work aims to evaluate the impact of metrics generated with the help of the Dynamic Time Warping algorithm on anomaly detection models trained to authenticate a mobile user through an inherited factor based on their interaction with a smartphone screen. The research was conducted through data collection from 33 users who agreed to interact with a mobile application developed for this work, aiming to maximize the number of swipe gestures performed by the user during the collection process. From the collected data, two Isolation Forest models were trained: one reference model that did not use Dynamic Time Warping metrics and another that did. The results indicated an absolute improvement of 3.725%, which represents a relative improvement of 8.40% in the model's task of classifying intruder gestures as anomalous. This work contributes to the field of device and mobile application security, as it proposes an enhancement to an authentication method focused on smartphones. Consequently, it also contributes to the security of smartphone users, who make up over 68% of the global population.

Keywords: information security; smartphones; dynamic time warping; machine learning; time series comparison.

LISTA DE ILUSTRAÇÕES

Figura 1 – Os dados do gestos dos usuários carregados em um Dataframe do Pandas . . .	25
Figura 2 – Os dados dos pontos dos gestos carregados em um Dataframe do Pandas . . .	26
Figura 3 – Tela de <i>login</i> da aplicação	27
Figura 4 – Tela de instruções da aplicação	29
Figura 5 – Tela dos cartões exibindo a frente do cartão	30
Figura 6 – Tela dos cartões exibindo o verso do cartão	31
Figura 7 – <i>Scatter Plot</i> do número de pontos por gesto ordenados de maneira crescente	32
Figura 8 – Histograma do número de pontos por gesto	32
Figura 9 – Plot das coordenadas dos gestos	33
Figura 10 – Comparação ponto a ponto de séries temporais	34
Figura 11 – Matriz de distância e matriz de custo com o caminho de menor custo	35
Figura 12 – Diagrama representando a separação dos dados	39
Figura 13 – Trecho do código que treinou os modelos de Isolations Forest	41
Figura 14 – Matriz de Confusão Agregada dos Modelos que utilizaram DTW como métrica	44
Figura 15 – Matriz de Confusão Agregada dos Modelos que não utilizaram DTW como métrica	46

LISTA DE TABELAS

Tabela 1 – Quadro comparativo entre os trabalhos relacionados e este.	23
Tabela 2 – Tabela combinada dos resultados dos modelos que usaram DTW	43
Tabela 3 – Tabela combinada dos resultados dos modelos que usaram DTW	45

LISTA DE ABREVIATURAS E SIGLAS

PII	<i>Personally Identifiable Information</i>
LGPD	Lei Geral de Proteção de Dados
GDPR	<i>General Data Protection Regulation</i>
TOTP	<i>time-based one-time password</i>
DTW	<i>Dynamic Time Warping</i>
CIA	Confidentiality, Integrity, Accessibility
HOTP	<i>hash-based one-time password</i>
DHS	<i>The Department of Homeland Security</i>
ANN	<i>Artificial Neural Network</i>
CPANN	<i>Counter Propagation Artificial Neural Network</i>
ANIA	<i>Average Number of Impostor Actions</i>
ANGA	<i>Average Number of Genuine Actions</i>
FMR	<i>False Match Rate</i>
FNMR	<i>False Non Match Rate</i>
FAR	<i>False Accept Rate</i>
FRR	<i>False Reject Rate</i>
OSVM	<i>One-Class Support Vector Machine</i>
CA	Autenticação Contínua
CE	Autenticação Estática
API	<i>Application Programming Interface</i>
APK	<i>Android Application Pack</i>
TCLE	<i>Termo de Consentimento Livre e Esclarecido</i>
CSV	<i>Comma Separated Values</i>
KNN	<i>K-Nearest Neighbors</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivos	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Autenticação	16
2.1.1	<i>Fraude identidade</i>	17
2.2	Fatores de Autenticação	17
2.2.1	<i>Algo que você sabe</i>	18
2.2.2	<i>Algo que você tem</i>	18
2.2.3	<i>Algo que você é</i>	18
2.3	<i>Dynamic Time Warping</i>	19
2.4	Isolation Forest	19
3	TRABALHOS RELACIONADOS	21
3.1	Swipe Gesture based Continuous Authentication for Mobile Devices	21
3.2	User Authentication via Touch Pattern Recognition based on Isolation Forest	21
3.3	Continuous Authentication of Smartphone Users via Swipes and Taps Analysis	22
3.4	Análise Comparativa	23
4	METODOLOGIA	24
4.1	Estruturação do Conjunto de Dados	24
4.2	Implementação do Aplicativo de Aquisição de Dados	26
4.2.1	<i>Interação com a aplicação</i>	26
4.2.2	<i>Fluxo do usuário na aplicação</i>	28
4.3	Coleta do Conjunto de Dados	28
4.4	Análise exploratória e remoção de outliers	30
4.5	Algoritmo DTW e o Pré-cálculo das Distâncias	34
4.5.1	<i>DTW modificado</i>	35
4.5.2	<i>Pré-Cálculo das distâncias</i>	36
4.6	Extração de características dos gestos	36

4.7	Detecção de Anomalias: Algoritmo, Modelos por Usuário e Requisitos da Divisão dos Dados de Treino e Teste	37
4.7.1	<i>O Algoritmo Escolhido</i>	37
4.7.2	<i>Número de modelos por usuário</i>	38
4.7.3	<i>Divisão dos dados</i>	38
4.8	Acrescendo as informações do DTW ao conjunto de dados	38
4.9	Treinamento dos Modelos e Teste dos Modelos	40
4.9.1	<i>Treinamento dos Modelos de Referência</i>	40
4.9.2	<i>Testes dos Modelos</i>	41
4.10	Análise dos Treinamentos	41
5	RESULTADOS	43
5.1	O Modelo de Referência	45
5.2	A Comparação dos Modelos	45
6	CONCLUSÕES E TRABALHOS FUTUROS	47
6.1	Limitações do Trabalho	47
6.2	47
	REFERÊNCIAS	49
	APÊNDICES	51
	APÊNDICE A–RESULTADOS INDIVIDUAIS DOS MODELOS	51
	APÊNDICE B–CÓDIGO PYTHON PARA GERAR MÉTRICAS PARA A ANÁLISE DE RESULTADO	72
	APÊNDICE C–TERMO DE CONSENTIMENTO LIVRE E ESCLA- RECIDO	74

1 INTRODUÇÃO

Nas últimas décadas houve forte expansão no uso de tecnologias de comunicação móvel. Como pode ser visto em (Kemp, 2023), em 2022, 68% da população mundial possui *smartphones*, o que representou um crescimento de 3,2% em relação ao ano de 2021. Segundo Dolan (2022), já em 2021 73,3% do tempo gasto com dispositivos móveis, nos Estados Unidos, foi em *smartphones*.

A adesão massiva aos *smartphones* é acompanhada da adesão a aplicativos de troca de mensagens, *internet banking*, gestão de negócios, entre outros serviços que contêm *Personally Identifiable Information* (PII). A manipulação de dados sensíveis do usuário faz as empresas por trás destes serviços reforçarem suas políticas de autenticação e autorização de usuários para garantir a confidencialidade e a integridade dos dados de seus clientes.

Falhas relacionadas a esses dois pilares da segurança da informação trazem riscos não somente aos usuários que podem ser vítimas de fraude, mas também às empresas que correm riscos à imagem e podem ter também riscos de *compliance* por estar em desacordo com legislações locais como a Lei Geral de Proteção de Dados (LGPD) e a *General Data Protection Regulation* (GDPR)

As citadas autenticação e autorização cumprem papel fundamental nos produtos fornecidos. A autorização se trata de definir o que um usuário tem permissão de fazer no sistema, isso pode variar conforme o sistema e o tipo de usuário, por exemplo: dois usuários em uma rede social podem ver as fotos um do outro, entretanto somente o dono da foto poderia editar sua legenda ou excluí-la. Essa regra parece promissora, porém dificultaria o trabalho de moderação da plataforma, que seria incapaz de excluir fotos que infrinjam leis e políticas de uso do sistema. É possível então compreender que a autorização é mais complexa do que parece a primeira vista e também que é essencial dentro de qualquer sistema que tenha múltiplos usuários.

Antes, porém que seja avaliada a autorização de um usuário é necessário avaliar se este é quem diz ser. A esse passo é dado o nome de autenticação, pois é nele em que autenticamos a veracidade da identidade e propriedade da identidade clamada pelo usuário. Usualmente utilizamos senhas como fator de autenticação, e tentamos atribuir maior confiança a este fator aumentando sua complexidade. Porém, já é sabido por profissionais e pesquisadores da segurança que múltiplos fatores, mesmo com baixa complexidade são mais seguros que um único fator mais complexo. Por exemplo, uma senha de 6 dígitos associada a um *time-based one-time password* (TOTP) é mais segura que uma senha de 16 dígitos, mesmo que a segunda

seja exponencialmente mais difícil de quebrar do que a primeira.

Segundo Grassi *et al.* (2020), a autenticação digital é o processo de validação de um ou mais autenticadores utilizados para alegar identidade digital. Ainda segundo o mesmo, autenticador é algo que quem alega uma identidade possui ou controla. Cada autenticador utiliza um ou mais fatores de autenticação. São três os fatores: fator de conhecimento (o que você sabe), fator de posse (o que você possui), fator de inerência (o que você é). Além disso, existem discussões a respeito de fator de localização (onde você está), fator de tempo (que horas são), e fator comportamental (algo que você faz). Porém, estes três últimos são apenas controles de segurança ou podem ser enquadrados em alguma das três primeiras categorias de fatores, não sendo fatores por si.

A respeito do fator comportamental, por exemplo, podemos ler em (Kamelia *et al.*, 2018) que biometria pode ser definida como características físicas e comportamentais que podem ser utilizadas para verificar uma identidade. Por essa definição de padrões biométricos, incluindo os comportamentais, se tratam de um autenticador e seu fator de autenticação é da categoria *Inherence*, ou seja, "o que você é".

Os fatores citados são comumente utilizados no dia-a-dia dos usuários, porém nos últimos anos a biometria com o uso de impressões digitais tem se expandido. Aplicações como os já citados *internet banking* e tela de bloqueio dos *smartphones* tem esta opção. Entretanto, outros padrões de biometria menos comuns como identificação facial também podem ser utilizados em algumas aplicações.

Podemos ver por tanto que há uma ampla gama de fatores e cabe a quem implementa os dispositivos e sistemas decida pelo seu uso. Essa decisão é geralmente feita baseada em prós e contras, também baseia-se nas limitações dos dispositivos e usuários. Podemos citar como exemplos de motivos para evitar fatores os seguintes problemas: no caso dos leitores de digital o uso de luva, mãos sujas, feridas podem acabar dificultando ou impossibilitando a leitura, além disso, há a necessidade de um componente extra no dispositivo o que resulta em aumento de preço; no caso do reconhecimento facial, baixa iluminação, sensores de baixa qualidade, uso de imagens, pessoas parecidas ou gêmeas pode inviabilizar o uso desta tecnologia de autenticação.

Além dos problemas citados, cada um dos fatores de autenticação terá seus próprios motivos para ser evitado, tornando cada fator mais adequado para cada dispositivo, sistema, situação e usuário. Portanto, mesmo com tantas escolhas já disponíveis ainda é necessário buscar por novos métodos de autenticação que sejam confiáveis e tornem a experiência de uso agradável

e que se adequem ao caso de uso. Padrões comportamentais, por exemplo, exigem do usuário apenas que eles hajam naturalmente, sem interferências na sua experiência de uso.

Em um contexto em que, como já foi citado, há uma forte expansão dos usuários de *smartphones* o fator biométrico-comportamental chama atenção por poder ser avaliado em praticamente qualquer usuário é a sua interação com as telas sensíveis ao toque. Além de não serem intrusivos como uma imagem do rosto, esse padrão pode ser lido em qualquer dispositivo com telas *touchscreen*.

Trabalhos como os de Filippov *et al.* (2018) e Mondal e Bours (2015) exploram formas de autenticar usuários de dispositivos móveis baseados na interação dos mesmos com telas sensíveis ao toque. Ambos os trabalhos mostraram resultados positivos em relação à autenticação por meio dos gestos captados pela tela. O que demonstra ser bastante promissor para que esse fator continue sendo explorado.

Percebemos, entretanto, quem em ambos os casos os gestos do usuário da tela são avaliados levando em consideração majoritariamente seus metadados, como duração, vetor e velocidade, mas os formatos dos gestos em si não são levados em conta. O que nos leva a questionar se a adição da informação de similaridade entre os gestos poderia ser positiva para os resultados do fator de autenticação.

O questionamento nos fez refletir acerca de como poderíamos comparar a similaridade do formato dos gestos. Refletindo acerca do tópico, pudemos perceber que os dados gerados por telas sensíveis ao toque a partir dos gestos do usuário são coordenadas que podem ser representadas no plano cartesiano. Além das coordenadas, que estão compreendidas no plano bidimensional, podemos ainda compreender que estas variam conforme o tempo, fazendo assim com que os dados sejam séries temporais. Essa perspectiva traz uma luz ao tema, já que novas formas de análise passam a ser possíveis.

Algoritmos como o *Dynamic Time Warping* (DTW) são utilizados para comparar as formas de séries temporais o que permite a identificação de comandos de voz. Além de outras aplicações como em (Souza *et al.*, 2009) que o utilizou para analisar a forma de assinaturas e fazer sua verificação, o que tem certo grau de semelhança com os gestos, que podem ser pensados individualmente como pequenas assinaturas. Notamos, portanto, que é promissor o uso do algoritmo de DTW como meio para gerar métricas de similaridade entre os gestos.

O algoritmo DTW compara duas séries temporais ao tentar fazer o *match* de cada um dos pontos das duas séries, tentando achar o ponto da série B que melhor se adequa a um ponto

na série A. O algoritmo gera uma matriz de custos, que no final é percorrida saindo da célula (1,1) até a célula (N,M), sendo N e M o tamanho das séries temporais, pelo caminho com menor custo, a soma dos custos do menor caminho entre o ponto inicial e final das matrizes é o custo total do *match* entre duas séries, que no final precisa apenas ser normalizado. A normalização é feita dividindo o custo total por N vezes M.

Seria possível adicionar essa informação a um algoritmo de detecção de anomalia comparando um novo gesto aos gestos conhecidos do usuário, dessa forma poderíamos entender o quanto um novo gesto se distancia em média dos gestos daquele usuário, além disso, com a adição do desvio padrão poderíamos também entender se ele se distancia igualmente de todos os pontos ou se existe um pequeno conjunto de gestos conhecidos daquele usuário que está fazendo a média se distorcer.

O baixo número de artigos sobre o tema faz com que ainda haja muitas possibilidades de melhora no uso do gesto dos usuários para a autenticação digital dos mesmos. Este trabalho tem por objetivo o uso de DTW para comparar os gestos conhecidos de um usuário autêntico a novos gestos e usar a média das pontuações geradas como métrica de auxílio à autenticação do usuário por meio de gestos em telas sensíveis ao toque como prova de identidade.

1.1 Objetivos

O objetivo geral deste trabalho é avaliar o valor resultante do caminho menos custoso gerado através do algoritmo DTW como métrica para a avaliação do gesto do usuário como fator de autenticação biométrica em *smartphones*. Com o trabalho esperamos contribuir para a segurança dos usuários de *smartphones*, assim como das empresas que estão por trás dos dispositivos e sistemas usados por este usuário. Como objetivos específicos esperamos:

1. Criação de uma base de dados de gestos de usuários a ser publicada de maneira livre.
2. Desenvolver uma aplicação móvel de código aberto para referência de futuros pesquisadores e desenvolvedores.

2 FUNDAMENTAÇÃO TEÓRICA

Este trabalho tem como área de estudo segurança, dispositivos móveis e algoritmos. Alguns dos termos e ideias aqui citados são de áreas específicas, por tanto, neste capítulo são feitas introduções aos tópicos fundamentais para a compreensão do trabalho. O capítulo está dividido em seções que se organizam da seguinte forma: Autenticação e Fatores de Autenticação; Biometria; *Dynamic Time Warping*; *Isolation Forest*.

2.1 Autenticação

A autenticação é parte fundamental da segurança da informação, já que é por meio dela que podemos garantir um usuário ter permissão para executar uma ação. O processo de autenticação pode ser utilizada tanto por humanos, quanto por máquinas e processos.

Um exemplo é um sistema de *e-commerce* que verifica o pagamento de uma compra no sistema bancário. O sistema bancário deve garantir que apenas os indivíduos autorizados possam acessar e alterar essa informação. Caso contrário, um agente malicioso poderia acessar a informação para identificar padrão de consumo ou mesmo capacidade financeira de um determinado cliente do *e-commerce*. A mesma necessidade se mostra no caso do pagamento, já que o próprio cliente não deve ser capaz de se passar por um *gateway*, por exemplo, para alterar o estado do pagamento para efetuado mesmo sem ter pago.

Outro caso em que autenticação se mostra muito importante é no de contabilização do uso de recursos. Em caso de redes e serviços em que cada cliente tem cota de uso de um determinado recurso é necessário saber de quem se trata o usuário no momento do uso para contabilizar e alterar o valor da cota disponível para aquele usuário. Um exemplo são os serviços de telefonia que tem ligações ou internet limitada.

Podemos resumir esses exemplos em três pilares que os sistemas prezam por manter, sendo o primeiro a confidencialidade, o segundo a integridade e o terceiro a disponibilidade. Estes pilares são também conhecidos pela sigla Confidentiality, Integrity, Accessibility (CIA), que Boonkrong (2021), descreve da seguinte forma: confidencialidade, os dados são acessados e manipulados apenas por aqueles que tem a devida autorização; integridade, os dados são confiáveis e estão livres de manipulação indesejada e/ou inesperada; disponibilidade, os sujeitos que possuem autorização de acesso, ou superior, aos dados devem ser capazes de acessá-los quando houver necessidade e isto de maneira prática. Logo, a validação da identidade é um

passo fundamental para a garantia destes pilares.

2.1.1 Fraude identidade

A fraude de identidade, de acordo com o site Malwarebytes¹, é um crime em que dados de uma pessoa são usados sem sua autorização e pode resultar em perdas financeiras, cometimento de crimes no nome de quem teve sua identidade roubada, dentre outras consequências negativas.

De acordo com o artigo (Cointelegraph, 2023) em 2022 foram registradas 3.879.869 tentativas de fraude de identidade no Brasil. Quando consultamos o Serasa Experian em 28 de agosto de 2024, já haviam sido identificadas mais de 20 milhões de tentativas de fraude de identidade, o que representa um crescimento de mais de 5 vezes. Sendo assim, é possível afirmar que há um crescimento na tentativa de burlar os meios de autenticação disponíveis no mercado.

Conforme o Serasa² explica em sua página, as fraudes são identificadas por análise de documentos, biometria facial, *facematch* e análise das bases de cadastro para identificar divergências de dados.

2.2 Fatores de Autenticação

Para validar a identidade de um solicitante (entidade que está tentando se identificar), o autenticador (entidade responsável pela autenticação) precisa receber provas da identidade alegada. Essas provas são conhecidas como fatores de autenticação.

Conforme descrito no segundo capítulo de (Wilson; Hingnikar, 2019), durante o processo de criação de uma conta é associada a identidade do usuário. Neste mesmo processo também pode ser definido o fator ou fatores de autenticação que serão usados futuramente para a validação da identidade associada. Logo, tão importante quanto cadastrar sua identidade é cadastrar os métodos de comprová-la.

Como citado anteriormente, existem três principais categorias para os fatores de autenticação, os mesmos são brevemente explicados nas três subseções seguintes.

¹ <https://www.malwarebytes.com/cybersecurity/basics/identity-fraud>

² <https://www.serasaexperian.com.br/fraudometro/>

2.2.1 *Algo que você sabe*

Esta é a categoria em que se enquadram as senhas, mas qualquer conhecimento que apenas o possuidor da identidade tenha acesso também é válido. Por exemplo, perguntas a respeito da infância, ideia de nome para futuros filhos ou número de bits disponíveis logo após a primeira inicialização do sistema, no caso de máquinas, poderiam ser informações utilizadas como fator de autenticação.

2.2.2 *Algo que você tem*

A posse de um objeto também pode ser usada para autenticar um usuário. Em tempos antigos isso seria como ter um brasão real, ou atualmente a chave que destranca a porta. Com a tecnologia surgiram outras formas de autenticação por posse, como os *tokens* bancários. A tecnologia de *tokens* de autenticação pode funcionar de forma síncrona ou assíncrona, ambas gerando senhas de uso único conhecidas por TOTP e *hash-based one-time password* (HOTP), respectivamente.

Além disso, algumas organizações estão utilizando dispositivos não especializados, como *smartphones* para fazer a autenticação por posse. Nesse caso, podem ser enviados códigos de segurança para o número cadastrado ou um pedido de permissão surgirá no respectivo aplicativo usado para autenticação.

2.2.3 *Algo que você é*

Dados sobre o usuário que são únicos ou raramente iguais, como os dados biométricos, sendo estes dados únicos e muitas vezes complexos de forjar.

Biometria é definida como “[...]uma característica biológica (anatômica ou fisiológica) e comportamental mensurável que possa ser utilizada para reconhecimento automatizado” (DHS, 2021, tradução livre). *The Department of Homeland Security* (DHS), se trata do departamento de segurança nacional do governo estadunidense.

Existem diferentes formas de biometria, como, por exemplo, de medidas anatômicas, temos padrão da digital, formato da mão, padrão das íris e reconhecimento facial. Além destes, existem os padrões comportamentais como tempo entre interações, duração da sessão, velocidade de movimento, ou formato do gesto em uma tela sensível ao toque.

2.3 *Dynamic Time Warping*

O algoritmo DTW é capaz de fazer a combinação de pontos de séries temporais de maneira não linear, ou seja, é possível comparar amostras que tenham flutuação temporal entre os mesmo acontecimentos.

Um exemplo disso seriam carros de corrida em um circuito fechado, mesmo sendo o mesmo trajeto a aceleração, velocidade média e tempo final podem variar a cada volta. Entretanto, os trechos rápidos e lentos do trajeto se mantém, logo, os gráficos são similares, por mais que o tempo possa ser mais curto ou mais longo entre cada evento monitorado.

A função do DTW é fazer a comparação ponto a ponto de cada série temporal, além disso, levar também em consideração as combinações mais próximas. Portanto, um pico de velocidade, no exemplo de uma corrida, no começo da pista pode ser igual a um pico de velocidade no meio da pista, porém por as velocidades próximas a essa região do gráfico serem diferentes o algoritmo consegue entender qual a melhor combinação entre os gráficos de duas voltas.

Tudo isso é feito numa matriz de tamanho N por M, sendo N e M o tamanho das séries temporais. Como o próprio nome sugere, o DTW é um algoritmo de programação dinâmica, o que garante que cálculos redundantes não sejam refeitos durante sua execução. O resultado da execução é o custo de associação entre as séries temporais, que dita quão próximas são estas. Quanto menor o custo, mais parecidas são as séries.

Este algoritmo é bem conhecido e estudado como pode ser visto em (Sakoe; Chiba, 1978) e existem implementações abertas como (Kamper, 2021). Seu uso é bastante comum para reconhecimento de palavras faladas, já que é possível variar a velocidade e ênfase em cada trecho da fala. O algoritmo também tem se popularizado para análise de séries temporais na área de *data science*.

2.4 *Isolation Forest*

O algoritmo Isolation Forest é um algoritmo de aprendizado de máquina especializado em detecção de anomalias, como descrito no trabalho de Filippov *et al.* (2018). O método baseia-se na premissa de que uma anomalia é mais fácil de ser isolada do que uma ocorrência comum do evento que está sendo analisado.

O algoritmo consiste na construção de múltiplas árvores de isolamento, que têm

como objetivo criar pontos de divisão no conjunto de dados, permitindo a posterior detecção de anomalias. A ideia de que anomalias são facilmente isoladas se aplica aqui, pois o número de divisões necessárias para isolar uma instância é a métrica usada pelo algoritmo para prever se um dado é ou não uma anomalia.

O Isolation Forest considera as profundidades de isolamento de todas as suas árvores para classificar um valor como anômalo ou não. A pontuação resultante varia entre 0 e 1; quanto mais próximo de 1, maior a probabilidade de que a instância seja uma anomalia.

3 TRABALHOS RELACIONADOS

Nesta seção são brevemente resumidos os trabalhos que tiveram maior influência e contribuição para a escrita deste trabalho. Em seguida fazemos uma breve comparação das obras.

3.1 *Swipe Gesture based Continuous Authentication for Mobile Devices*

No trabalho de Mondal e Bours (2015) é explicada a necessidade de trazer mais segurança aos dispositivos móveis. Os autores propõem então um sistema de autenticação contínua baseada em gestos *swipe*, que se tratam dos gestos de arrastar, como os comumente feitos em telas que permitem rolagem.

Três situações foram propostas no texto, sendo elas: sistema interno, onde classificador tem conhecimento dos padrões de gestos dos impostores; combinação de sistemas, nesse caso o classificador conhecia parte dos impostores; sistema externo, nenhum dado dos impostores foi usado para treinar o classificador.

Foram feitos dois classificadores usando *Artificial Neural Network* (ANN) e *Counter Propagation Artificial Neural Network* (CPANN). Os resultados destes foram usados para calcular um *score* de confiança que por sua vez foi repassado para um *trust model*.

Trust model se trata de um modelo que avalia as ações do usuário em vista o comportamento de um usuário autêntico. O modelo recebe um *score* de confiança a cada novo gesto e calcula a confiança que o sistema tem no usuário. O sistema tem nível de confiança mínimo, caso o usuário faça múltiplas ações suspeitas uma nova validação é requisitada.

O sistema foi avaliando utilizando *Average Number of Impostor Actions* (ANIA), *Average Number of Genuine Actions* (ANGA), *False Match Rate* (FMR) e *False Non Match Rate* (FNMR). Os resultados foram promissores, mostrando poucos falsos positivos, mesmo no sistema em que o classificador não conhecia o impostor. O maior valor de ANIA foi identificado na situação em que o sistema conhecia os impostores.

3.2 *User Authentication via Touch Pattern Recognition based on Isolation Forest*

Em seu trabalho, Filippov *et al.* (2018) parte da ideia de que cada usuário tem padrões únicos de gesto para propor um método de autenticação contínua. A sua proposta usa o algoritmo *Isolation Forest* e um *trust model* para manter o usuário constantemente autenticado.

O autor desenvolveu um aplicativo capaz de capturar os movimentos dos usuários,

enquadrados em sete categorias diferentes. O conjunto de dados foi coletado de vinte usuários ao longo de um mês. Apesar disso, apenas um foi utilizado como “legítimo” e foram coletados vinte vezes mais dados deste do que dos outros.

Segundo o autor, os *taps*, que são cliques únicos na tela, são os gestos mais comuns, porém têm o menor valor de informação. Em segundo lugar vem a categoria de gestos de rolagem de baixo para cima, movimento utilizado em páginas com rolagem. Essa segunda categoria foi a de gestos utilizados para montagem do conjunto de dados.

Um total de oito características em relação ao movimento foram detectadas e usadas para treinar uma *Isolation Forest* e depois o resultado, normal ou anômalo, passado para um *trust model*. Este por sua vez se tratava de um algoritmo bastante simples que quando a confiança chegava a zero pedia uma nova autenticação. A confiança do sistema foi medida como um número natural que recebia +1 quando o movimento era normal e -1 quando o movimento fosse anômalo, os autores também delimitaram um valor máximo que poderia ser alcançado.

O autor explica que sistemas de autenticação costumam utilizar métricas como *False Accept Rate* (FAR) e *False Reject Rate* (FRR) para desempenho, porém no caso de autenticação contínua ANIA e ANGA eram mais informativos. Os resultados mostraram que com um *trust model* com confiança máxima de 6 houve melhor desempenho. Neste caso, o sistema teve ANIA e ANGA de respectivamente 7 e 981, resultado considerado como aceitável pelos autores, tendo em vista que um usuário comum faz cerca de 2617 ações por dia, o que representaria 2 ou 3 pedidos de revalidação da identidade.

3.3 Continuous Authentication of Smartphone Users via Swipes and Taps Analysis

Em (Garbuz *et al.*, 2019) os autores ressaltam a necessidade de métodos de autenticação que tragam segurança sem causar incômodo ao usuário. Para isso é proposto um modelo de autenticação contínua que coleta dados dos gestos do usuário para autenticá-los continuamente.

No trabalho, o autor coletou gestos dos usuários em duas sessões com seis meses de intervalo. A coleta consistia na utilização de um aplicativo para *iphones* em que era mostrada a logomarca de uma empresa de carros e em seguida era pedido para que o usuário achasse o nome da marca em uma lista com o nome de diversas marcas.

O autor coletou os dados da tela, do acelerômetro e do giroscópio. Esses dados foram usados para treinar oito modelos, dois para gestos de deslize na tela, sendo um para deslizes para cima e outro para baixo, os outros 6 modelos eram para gestos do tipo toque. O algoritmo

utilizado foi o *One-Class Support Vector Machine* (OSVM), que por se tratar de um algoritmo de detecção de anomalia precisou ser retreinado para cada usuário.

No trabalho os gestos do tipo toque foram utilizados apesar de terem pouquíssimo valor para autenticação, como outros trabalhos reforçam. Entretanto, como este trabalho utiliza os acelerômetros e os giroscópios do dispositivo, é possível extrair mais informações do gesto.

O autor reportou resultados promissores, com o usuário sendo bloqueado a cada 116 gestos e um impostor bloqueado em apenas 3 gestos. Entretanto, o autor também chama atenção para os fatores externos que podem influenciar os resultados. Por conta do uso dos outros sensores, giroscópio e acelerômetro, a coleta de dados de um usuário em movimento poderia trazer resultados diferentes ao experimento, já que nesse caso a tela seria o único sensor não influenciado.

O trabalho em questão se diferencia deste, pois faz uso de outros sensores que não a tela do dispositivo, além disso, precisou treinar diferentes modelos para cada tipo de gesto, enquanto este trabalho se propõe a treinar um único modelo genérico.

3.4 Análise Comparativa

Por fim, encerramos o capítulo com a análise comparativa entre os trabalhos relacionados e este trabalho, como pode ser visto na Tabela 1. Comparamos segundo os seguintes critérios: Conjunto de Dados Autoral, se os dados utilizados foram coletados pelos próprios autores ou se se tratava de um conjunto coletado por terceiros; Continuidade da Autenticação, distinto por Autenticação Contínua (CA) ou Autenticação Estática (CE), os modelos contínuos levam múltiplos gestos em consideração para afirmar se um usuário é ou não autêntico, diferente dos modelos estáticos, que não utilizam esse contexto; modelo de classificação genérico, ou seja, era capaz de analisar qualquer tipo de gesto; uso do DTW, uso do algoritmo como métrica na autenticação.

Tabela 1 – Quadro comparativo entre os trabalhos relacionados e este.

Trabalho	Dados Autorais	Tipo de Autenticação	Modelo Genérico	Uso do DTW
(Mondal; Bours, 2015)	Não	Contínua	Sim	Não
(Filippov <i>et al.</i> , 2018)	Sim	Contínua	Sim	Não
(Garbuz <i>et al.</i> , 2019)	Sim	Contínua	Não	Não
Este Trabalho	Sim	Estática	Não	Sim

Fonte: O autor

4 METODOLOGIA

Para que pudesse ser feita a experimentação do algoritmo DTW como métrica de similaridade entre os gestos de usuários de dispositivos móveis com finalidade de validação de identidade, precisamos desenvolver uma série de passos para coleta e processamento de dados de usuários reais. Os passos são descritos nesse capítulo e as seções estão divididas em: Estruturação do Conjunto de Dados; Implementação do Aplicativo de Aquisição de Dados; Aquisição do Conjunto de Dados; Análise dos Dados; Algoritmo DTW; Testes de Validação de Identidade; Análise dos resultados.

4.1 Estruturação do Conjunto de Dados

Para decidir quais dados deveriam ser coletados e em sequência saber como estruturá-los, foi utilizado como base o trabalho de Filippov *et al.* (2018), em que o autor afirma ter coletado ou extraído as seguintes características:

- Duração do gesto;
- Velocidade média;
- Tamanho médio do ponto de contato com a tela;
- Distância do gesto;
- Vetor absoluto de direção do gesto;
- Coordenada do vetor de direção;
- Coordenadas X e Y iniciais do gesto;
- Coordenadas X e Y finais do gesto.

Para este trabalho, por estarmos utilizando Flutter¹ para o desenvolvimento da aplicação, não pudemos coletar o tamanho médio do ponto de contato com a tela, já que não havia à época da pesquisa a implementação de qualquer biblioteca que pudesse ser acoplada ao *framework* retornando este dado. O Flutter é um *Framework* do Google, baseado em Dart², linguagem de programação da mesma empresa.

O *Framework* em questão é pensado para desenvolvimento em múltiplas plataformas, desde sistemas embarcados, como uma central multimídia de um carro, até *smatphones* e televisores conectados, em inglês *Smart TVs*. Por sua abrangência de dispositivos o *Framework* acaba por não implementar todas as funcionalidades nativas de um dispositivo específico, por

¹ <https://flutter.dev/>

² <https://dart.dev/>

isso não conseguimos coletar o tamanho médio do ponto de contato com a tela, já que apesar de ser possível de fazê-lo nativamente em dispositivos que utilizem sistema operacional Android, não há uma implementação da interface nativa desta funcionalidade para Flutter.

Como a maioria dos dados citados foram extraídos de dados brutos, foi necessário avaliar quais seriam estes dados brutos que pudessem nos dar uma riqueza de detalhes como esta. Além disso, precisou-se levar em consideração outro fator, pois o algoritmo DTW compara os valores de séries temporais para aferir sua similaridade, portanto cada um dos pontos do gesto também precisaria ser armazenado. Após análise cuidadosa foi concluído que precisaríamos coletar:

- Tempo do início do gesto;
- Tempo do fim do gesto;
- Todas as coordenadas X e Y coletadas pelo aparelho durante a ocorrência do gesto.

Além disso, um identificador do usuário, do dispositivo e do gesto também foram guardados. Para otimizar o armazenamento dos dados, foi decidido que eles seriam separados em duas tabelas. A primeira tabela, chamada de gestos, que continha: os tempos, inicial e final, de cada gesto e os identificadores do gesto, do dispositivo e do usuário. A segunda tabela, chamada de pontos, continha: as coordenadas de cada ponto no eixo X e Y do plano cartesiano; o identificador do gesto ao qual aquele ponto pertencia; o identificador do próprio ponto. É possível ver nas Figuras 1 e 2 os conjuntos de dados já carregados em memória.

Figura 1 – Os dados do gestos dos usuários carregados em um Dataframe do Pandas

```
gestures.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 7338 entries, 0 to 7337
Data columns (total 5 columns):
#   Column          Non-Null Count  Dtype
---  -
0   id               7338 non-null   int64
1   gesture_start    7338 non-null   object
2   gesture_end      7338 non-null   object
3   device_id        7338 non-null   object
4   user_id          7338 non-null   object
dtypes: int64(1), object(4)
memory usage: 286.8+ KB
```

Fonte: O autor

Outros sensores poderiam ser explorados e seus dados coletados, como fez Garbuz *et al.* (2019), entretanto, conforme é citado no próprio trabalho da autora, a adição desses dados pode trazer imprecisões, quando o usuário se movimenta.

Figura 2 – Os dados dos pontos dos gestos carregados em um Dataframe do Pandas

```
points.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 250107 entries, 0 to 250106
Data columns (total 4 columns):
#   Column      Non-Null Count  Dtype
---  -
0   x_coordinate 250107 non-null  float64
1   y_coordinate 250107 non-null  float64
2   gestureID    250107 non-null  int64
3   id           250107 non-null  int64
dtypes: float64(2), int64(2)
memory usage: 7.6 MB
```

Fonte: O autor

4.2 Implementação do Aplicativo de Aquisição de Dados

Por se tratar de uma base de dados bastante específica, decidiu-se coletar uma base de dados autoral. Para isso, precisávamos de uma aplicação que pudesse fornecer ao usuário alguma tarefa a ser executada enquanto coletava os dados das interações do usuário com a tela do dispositivo, assim como foi feito no trabalho (Garbuz *et al.*, 2019).

Foi desenvolvida então uma aplicação de *flashcards*, similar ao Anki³, programa bastante difundido entre estudantes de diversas áreas. Os *flashcards* são cartões que de um lado é apresentado um conceito, seja por meio de uma frase, uma imagem ou uma única palavra, no verso do cartão está o conteúdo que o estudante deve associar ao conceito da frente do cartão.

O objetivo do estudante é lembrar do conteúdo sem a necessidade de virar o cartão, usando o verso apenas para confirmar sua resposta ou para revisar o conteúdo caso não o lembre. Sempre que um cartão é revisado, ele volta para a pilha de cartões em uma posição que pode ser definida por se o estudante obteve ou não sucesso em lembrar do conteúdo em seu verso.

No caso da aplicação que desenvolvemos, o conjunto de cartões era fixo e se tratava de palavras comuns da língua inglesa que em seu verso estavam traduzidas para o português. Assim sendo, o usuário deveria ver a palavra em inglês e lembrar-se da mesma em português.

4.2.1 Interação com a aplicação

Trabalhos com o de Filippov *et al.* (2018) e Garbuz *et al.* (2019) afirmam que gesto do tipo *swipe*, gestos de deslize, são os que trazem maior quantidade de informação, por tanto são mais valiosos para a tarefa de autenticação de usuários. Por tanto, optamos por fazer toda a

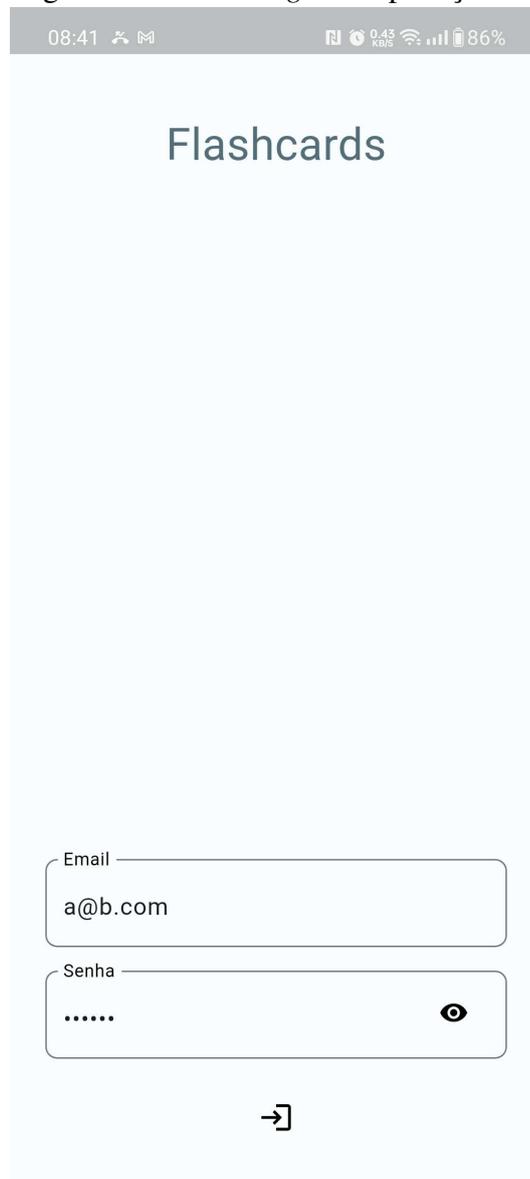
³ <https://apps.ankiweb.net/>

interação do usuário com os cartões ser feita por gestos desse tipo.

Os gestos e suas funcionalidades eram respectivamente:

- Deslize para a direita/esquerda: virava o cartão para ver seu verso ou voltar para sua frente.
- Deslize para cima: marcava o cartão como “lembrado” e o colocava de volta no fundo da pilha
- Deslize para baixo: marcava o cartão como “não lembrado” e o colocava no meio da pilha, para que o usuário pudesse revê-lo mais tarde e fixar o conteúdo.

Figura 3 – Tela de *login* da aplicação



Fonte: O autor

4.2.2 Fluxo do usuário na aplicação

O fluxo do usuário na aplicação consistia em:

- Tela de *login*: A fim de que os usuários utilizassem a aplicação apenas no momento da coleta e também para evitar que usuários não convidados para a coleta acabassem comprometendo os dados, foi implementado um sistema de autenticação baseado no Supabase⁴, serviço de nuvem que possibilita uso dessa função sem necessidade de desenvolver uma *Application Programming Interface* (API) própria. A tela de *login* pode ser vista na Figura 3.
- Tela de instruções: explicava ao usuário como utilizar o aplicativo, tinha por objetivo evitar erros e frustrações do usuário durante o uso. A tela de instruções pode ser vista na Figura 4.
- Tela dos cartões: A tela onde o usuário poderia finalmente interagir com os cartões. Apenas essa tela coletava os dados do usuário da interação do usuário. A tela dos cartões pode ser vista na Figura 5 com um cartão de frente e na Figura 6 com o verso do cartão.

4.3 Coleta do Conjunto de Dados

Para a coleta dos dados a aplicação foi enviada para um total de 33 usuários, tanto por meio de *Android Application Pack* (APK) quanto por meio da *Play Store*. As coletas foram feitas de maneira remota, porém o autor se pôs a disposição para tirar dúvidas durante todo o período do teste.

Vale que para acessar a tela dos cartões, onde os dados eram coletados, o usuário deveria aceitar o *Termo de Consentimento Livre e Esclarecido* (TCLE), que pode ser lido no apêndice C.

Como os usuários poderiam acessar a aplicação apenas por meio de *login* foi possível fazer o controle de quando as coletas estavam sendo feitas, garantindo assim que o mesmo usuário não tivesse seus dados coletados em dois momentos diferentes. Além disso, era pedido aos usuários que buscassem atingir a marca de 100 cartões aprendidos ou revisados, entretanto, não havia qualquer tipo de mecanismo que forçasse o usuário, também era informado ao mesmo que este era apenas um valor ideal, mas que ele poderia abandonar a coleta a qualquer momento.

Por fim, após o *logout* o usuário era removido da base de autenticação e o mesmo

⁴ <https://supabase.com/>

Figura 4 – Tela de instruções da aplicação

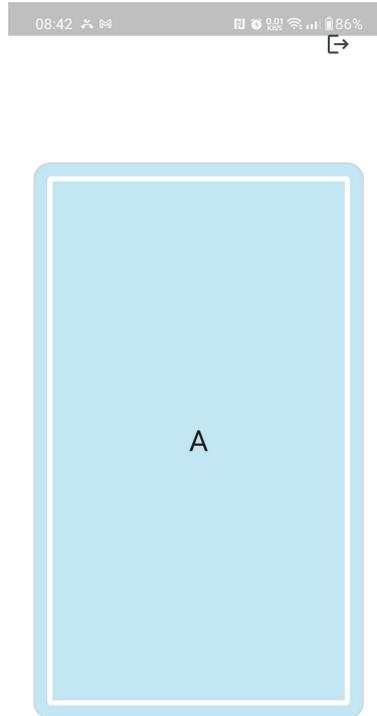


Fonte: O autor

não poderia voltar a utilizar a aplicação.

No total, foram coletados 7338 gestos de 33 usuários, o que resultou em 250.107 pontos, armazenados em um banco de dados relacional provido também pela plataforma Supabase. O perfil dos usuários eram homens e mulheres entre 18 e 34 anos na data da coleta. No final da coleta, os dados de ambas as tabelas foram exportados como *Comma Separated Values* (CSV). As tabelas tinham respectivamente 830,8kB e 7,1MB.

Figura 5 – Tela dos cartões exibindo a frente do cartão



Fonte: O autor

4.4 Análise exploratória e remoção de *outliers*

Após os dados coletados e exportados, os mesmos foram carregados no Jupyter Notebook⁵, *software* comumente utilizado para análise de dados com a linguagem Python. Para carregá-los em memória foi utilizada a biblioteca Pandas⁶, também comumente utilizada para análise de dados. Já com os dados devidamente carregados em um *Dataframe*, espécie de tabela própria da biblioteca Pandas, começou-se a exploração dos dados.

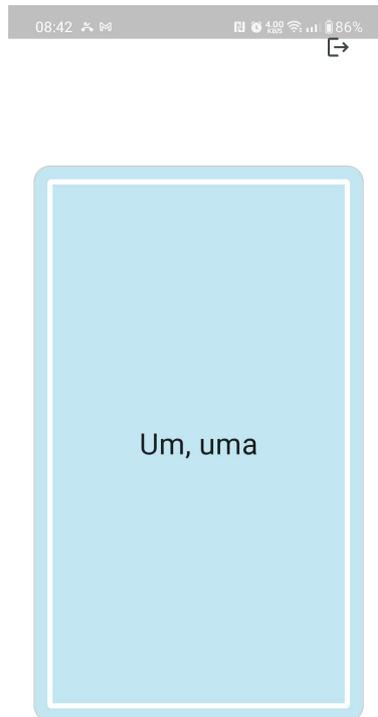
Primeiramente verificamos que os dados realmente estavam no formato que esperávamos. Para isso observamos as primeiras linhas de ambos os *Dataframes*.

Com a confirmação de que os dados realmente estavam como esperávamos, removemos os dados do usuário de teste, utilizado pelo autor durante o desenvolvimento da aplicação. Esses dados foram removidos, pois não se tratavam de gestos de uso da aplicação, mas sim gestos de testes das funcionalidades da aplicação, sem qualquer comprometimento com a tarefa proposta aos usuários reais.

⁵ <https://jupyter.org/>

⁶ <https://pandas.pydata.org/>

Figura 6 – Tela dos cartões exibindo o verso do cartão



Fonte: O autor

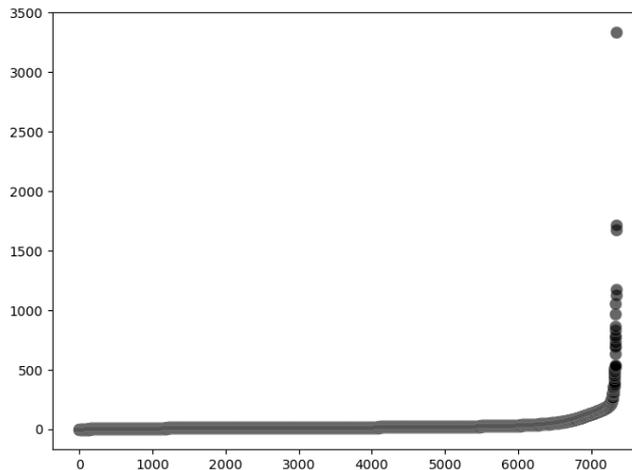
Em seguida, criamos alguns gráficos, o que facilitou a visualização. O primeiro gráfico se trata do número de pontos de cada um dos gestos ordenados de forma crescente, ele pode ser visto na Figura 7. O número de pontos do gesto se trata da quantidade de coordenadas coletadas pela tela do dispositivo durante o período em o gesto ocorreu, ou seja durante o período em que houve contato com a tela.

Como podemos analisar na Figura 7 existem gestos com número de pontos que aparentam se distanciar do padrão da curva. Em seguida fizemos o histograma do número de pontos por gesto, que pode ser visto na Figura 8.

As Figuras 7 e 8 mostra a existência de *outliers*, gestos que fogem do padrão do conjunto de dados coletados. Baseados nisso resolvemos remover os *outliers* utilizando a técnica de *z-score*. Para isso utilizamos a biblioteca SciPy⁷ que conta com funções de estatística, incluindo o cálculo de *z-score* de uma lista de valores, utilizada por nós. Depois disso removemos todos os valores com pontuação absoluta maior ou igual a 3, já que 99,73% das ocorrências de um evento se encontram dentro da janela de valores entre mais e menos três desvios padrão da

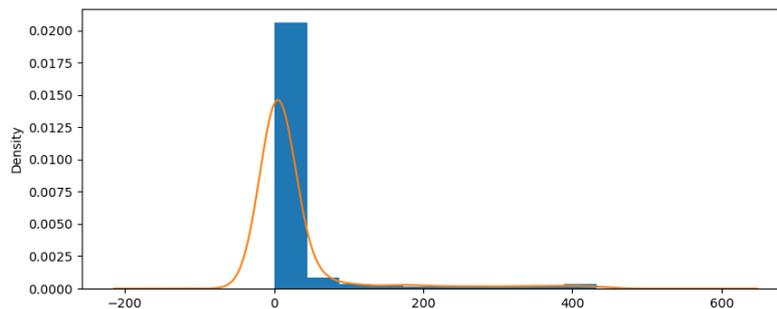
⁷ <https://scipy.org/>

Figura 7 – *Scatter Plot* do número de pontos por gesto ordenados de maneira crescente



Fonte: O autor

Figura 8 – Histograma do número de pontos por gesto



Fonte: O autor

média.

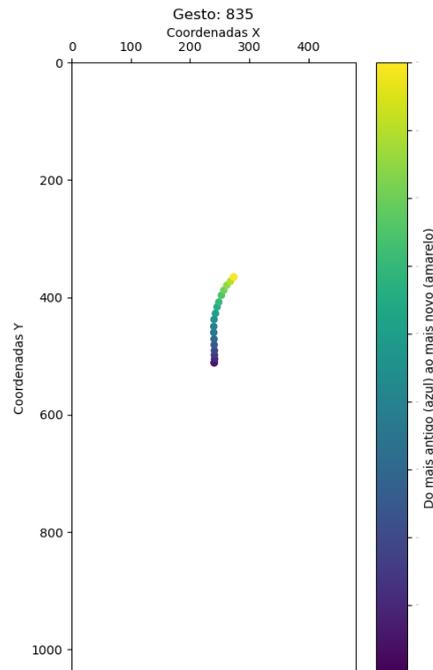
Também removemos os gestos com menos que 4 pontos, já que esses gestos pouco se diferem de gestos do tipo *tap* não poderíamos afirmar que não se tratam de casos em que o usuário apenas tentou tocar na tela, mas acabou deslizando o dedo por engano.

Com essas três remoções de dados reduzimos nossos dados de 7338 gestos para 7080 gestos que posteriormente foram utilizados para treinamento e teste dos modelos, passos que serão descritos a seguir.

Além disso, também tentamos entender os gestos em si, para isso foram analisados os desenhos de alguns dos gestos, como pode ser visto na Figura 9. Que é a representação de todos os pontos de um gesto, posicionados nas suas respectivas coordenadas. Além disso, os pontos azuis são os mais antigos, os primeiros a serem coletados, e os amarelos os mais recentes.

Notamos então que os gestos nossos gestos, que vale ressaltar são todos do tipo

Figura 9 – Plot das coordenadas dos gestos



Fonte: O autor

deslize, poderiam se enquadrar em oito categorias, que são:

- Deslize para cima;
- Deslize para baixo;
- Deslize para a esquerda;
- Deslize para a direita;
- Deslize para a diagonal superior direita;
- Deslize para a diagonal inferior direita;
- Deslize para a diagonal superior esquerda;
- Deslize para a diagonal inferior esquerda.

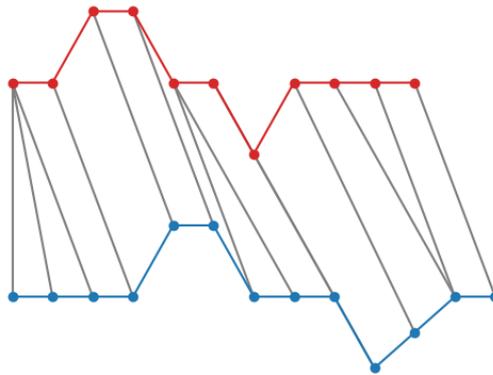
Isso nos fez perceber que a direção e o sentido no qual o movimento ocorria poderia ser uma informação valiosa para os nossos modelos, já que mesmo que de um mesmo usuário, dois gestos poderiam se mostrar bastante distintos apenas por terem direções diferentes. Isso se deve à anatomia das nossas mãos e de como seguramos os dispositivos, como pode ser visto em (Ingram, 2016). Outra coisa que pudemos notar é que nem todos os usuários haviam realizado gestos em cada um dos oito sentidos.

4.5 Algoritmo DTW e o Pré-cálculo das Distâncias

Em seu GitHub, Kamper (2021), disponibiliza uma implementação deste algoritmo em Python, portanto, para evitar erros de implementação e facilitar alterações na forma como o algoritmo compara dois pontos, resolvemos utilizá-la. Este reuso se mostrou mais promissor do que implementar a nossa ou utilizar uma implementação de alguma biblioteca de aprendizado de máquina a qual não teríamos acesso ao código.

O algoritmo DTW faz a comparação ponto a ponto das séries temporais que este recebe como *input*. Esta comparação pode variar conforme o tipo de dado. A Figura 10 mostra a combinação dos pontos de duas séries temporais associados através do algoritmo, o custo dessas associações, que como poderemos ver a seguir se trata de uma distância, será utilizado como parâmetro para definirmos se um gesto é anômalo ou não.

Figura 10 – Comparação ponto a ponto de séries temporais

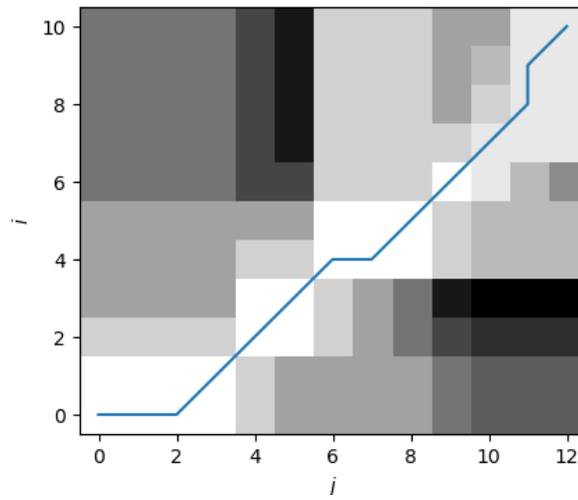


Fonte: (Kamper, 2021)

O algoritmo usa uma matriz de tamanho N por M , chamada matriz de custo, sendo N e M os tamanhos das séries temporais. Nesta matriz, em cada posição (I, J) , sendo $\{I|I \in N\}$ e $\{J|J \in M\}$, é calculada a diferença absoluta entre os valores de I e J e somado o menor entre os valores das três seguintes casas vizinhas: $(I-1, J)$; $(I, J-1)$; $(I-1, J-1)$. Caso a casa vizinha não exista é utilizado infinito para substituí-la. No caso do primeiro passo do algoritmo, em que não há células vizinhas, é considerada apenas a diferença absoluta. Algumas implementações podem utilizar também uma matriz de distância absoluta, este é o caso do algoritmo usado neste trabalho.

A partir da matriz de custos é calculado então o caminho com menor custo entre o ponto inicial, com I e J sendo ambos 1, e final, sendo I e J respectivamente M e N , da matriz, como pode ser visto na Figura 11. Isso pode ser feito partindo da posição (I, J) e seguindo para o seu menor vizinho entre $(I-1, J)$, $(I, J-1)$ e $(I-1, J-1)$.

Figura 11 – Matriz de distância e matriz de custo com o caminho de menor custo



Fonte: (Kamper, 2021)

Por fim, somado os custos do caminho de menor custo, podemos ter um parâmetro para saber quão próximas duas séries temporais são uma da outra. Entretanto, surge um problema, pois séries temporais maiores tem também caminhos maiores, o que é claro se pensarmos que o tamanho da matriz de onde o caminho é gerado é proporcional ao tamanho das séries. Caminhos maiores podem ter valor absoluto maior, mesmo que seus custos sejam em média menores, por isso para um valor final mais representativo da similaridade entre as séries temporais, amenizando o fator do seu tamanho dividimos a soma dos custos do caminho de menor custo por $N+M$, servindo assim para normalizar os valores. Assim, o resultado do algoritmo pode ser descrito como a distância normalizada do menor caminho na matriz de custos.

4.5.1 DTW modificado

Nossa única alteração na implementação proposta em (Kamper, 2021) é como calculamos a distância entre os pontos de duas séries temporais, já que na implementação original o autor apenas subtraía o valor do ponto da série temporal A do valor do ponto da série temporal B.

Já nós, por termos pontos no plano cartesiano, optamos pela distância euclidiana entre os pontos, obtida seguindo a fórmula $d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$.

Nas seções à frente explicaremos como o valor normalizado da soma do caminho de menor custo foi utilizado para auxílio da validação de identidade do usuário.

4.5.2 Pré-Cálculo das distâncias

Como já citado na seção 4.4 finalizamos nosso conjunto de dados com 7080 gestos a serem analisados, como estes gestos seriam comparados mutuamente para obter as distâncias no futuro, optou-se por pré-calculando os valores das comparações entre todos os gestos.

O processo por completo fez 50.126.400 de comparações entre gestos, e levou 117.832,91 segundos ou 32,73 horas para ser processada por completo, o que gerou como resultado uma tabela de 401 megabytes.

Durante o restante da pesquisa, quando precisamos do valor da comparação entre dois gestos, apenas usamos o valor pré-calculado que armazenamos na matriz. Isso nos poupou bastante tempo já que os cálculos não tinham que ser refeitos em caso de mudanças de trechos de código que precisassem do valor.

4.6 Extração de características dos gestos

Já com os dados devidamente tratados, como descrito anteriormente, começamos a extração de dados para obter as características descritas na seção 4.1. Mesmo que focando na identificação de gestos de um usuário específico, os modelos utilizaram as mesmas características. Portanto, todas as características extraídas foram feitas em conjunto, para todos os usuários. Apenas as métricas geradas por DTW foram calculadas em grupos específicos, separados por tipo de gesto e por usuário.

Tratamos primeiramente a duração do tempo, que foi obtida utilizando o tempo inicial e final, armazenado para cada elemento da tabela de gestos.

Em seguida, as coordenadas X e Y iniciais e finais de cada gesto foram obtidas buscando os pontos do gesto em questão na tabela de pontos. Como os identificadores dos pontos eram números naturais crescentes, foi simples ordená-los para pegar o primeiro e o último ponto.

A próxima característica foi a distância total do gesto que calculamos somando as distâncias entre pontos consecutivos. Dessa característica, dividida pela duração, obtivemos a

velocidade média do gesto.

As coordenadas do vetor de direção foram obtidas calculando as diferenças de posição dos gestos no eixo X e Y entre o começo e o fim do gesto. A magnitude desse vetor é a raiz quadrada desses valores ao quadrado.

Assim, completamos a extração de todas as características propostas inicialmente.

Decidimos, entretanto, extrair mais uma característica dos gestos, a sua direção, entretanto no lugar de usar valores numéricos, como as coordenadas, que já extraímos, usamos etiquetas que representavam cada uma das oito possibilidades, que já foram abordadas na seção 4.4. Dessa forma, concluímos nossa extração de características.

4.7 Detecção de Anomalias: Algoritmo, Modelos por Usuário e Requisitos da Divisão dos Dados de Treino e Teste

Nesta seção debateremos a decisão do algoritmo a ser utilizado para a tarefa, bem como o número de modelos treinados por usuários e como nossas decisões impactaram a forma de divisão dos dados entre treino e teste.

Antes de aprofundarmos os tópicos anteriormente citados, é importante explicar que este trabalho se limita a autenticação estática, já que o objetivo é avaliar o ganho de desempenho trazido pelo uso de métricas fruto de DTW e esta avaliação é possível sem que se implementem modelos de autenticação contínua, já que estes se baseiam em modelos de autenticação estática e esta será avaliada.

4.7.1 O Algoritmo Escolhido

Os resultados da comparação de DTW são distâncias, como já dito anteriormente (seção 4.5), o que pode guiar um leitor desatento a imaginar que sua aplicação seria mais fácil em um algoritmo como o *K-Nearest Neighbors* (KNN). Entretanto, como a tarefa proposta é a de identificar se um gesto é de um usuário ou de um intruso, não é razoável esperar que tenhamos referências de gestos de todos os possíveis invasores, por isso o modelo deve ser capaz de lidar com uma base de dados de treino constituída apenas de gestos do usuário legítimo.

Portanto, a tarefa que estamos enfrentando aqui se trata, na verdade, de detecção de anomalias. Os trabalhos relacionados usam a mesma estratégia: Filippov *et al.* (2018) utilizou o algoritmo *Isolation Forest* e Garbuz *et al.* (2019) utilizou um OSVM. Por termos tomado por base

as características utilizadas no primeiro trabalho, por estarem melhor explicitadas, resolvemos também utilizar o mesmo algoritmo (*Isolation Forest*). Entretanto, é válido ressaltar que outros algoritmos, sejam de detecção de anomalias ou de classificação com uma única classe seriam adequados.

4.7.2 Número de modelos por usuário

Como discutido anteriormente (seção 4.4), os gestos de deslize de um usuário podem variar grandemente entre si pela direção e sentido que são executados. Por isso decidimos que para cada tipo de gesto do usuário iríamos treinar um modelo. Sendo assim a etapa de classificação se divide em duas, primeiro é classificada a direção do gesto, depois o modelo treinado para aquele tipo de gesto seria aplicado. Vale lembrar que essa informação já havia sido obtida em uma etapa anterior e que nem todos os usuários efetuaram gestos em todas as direções, portanto nem todos os usuários tinham modelos treinados para cada uma das oito direções. Essa informação também será considerada ao avaliarmos os modelos.

4.7.3 Divisão dos dados

Devidos às características citadas, cada modelo deveria ser treinado apenas com dados de apenas um gesto de um usuário. Por isso seguimos os seguintes passos:

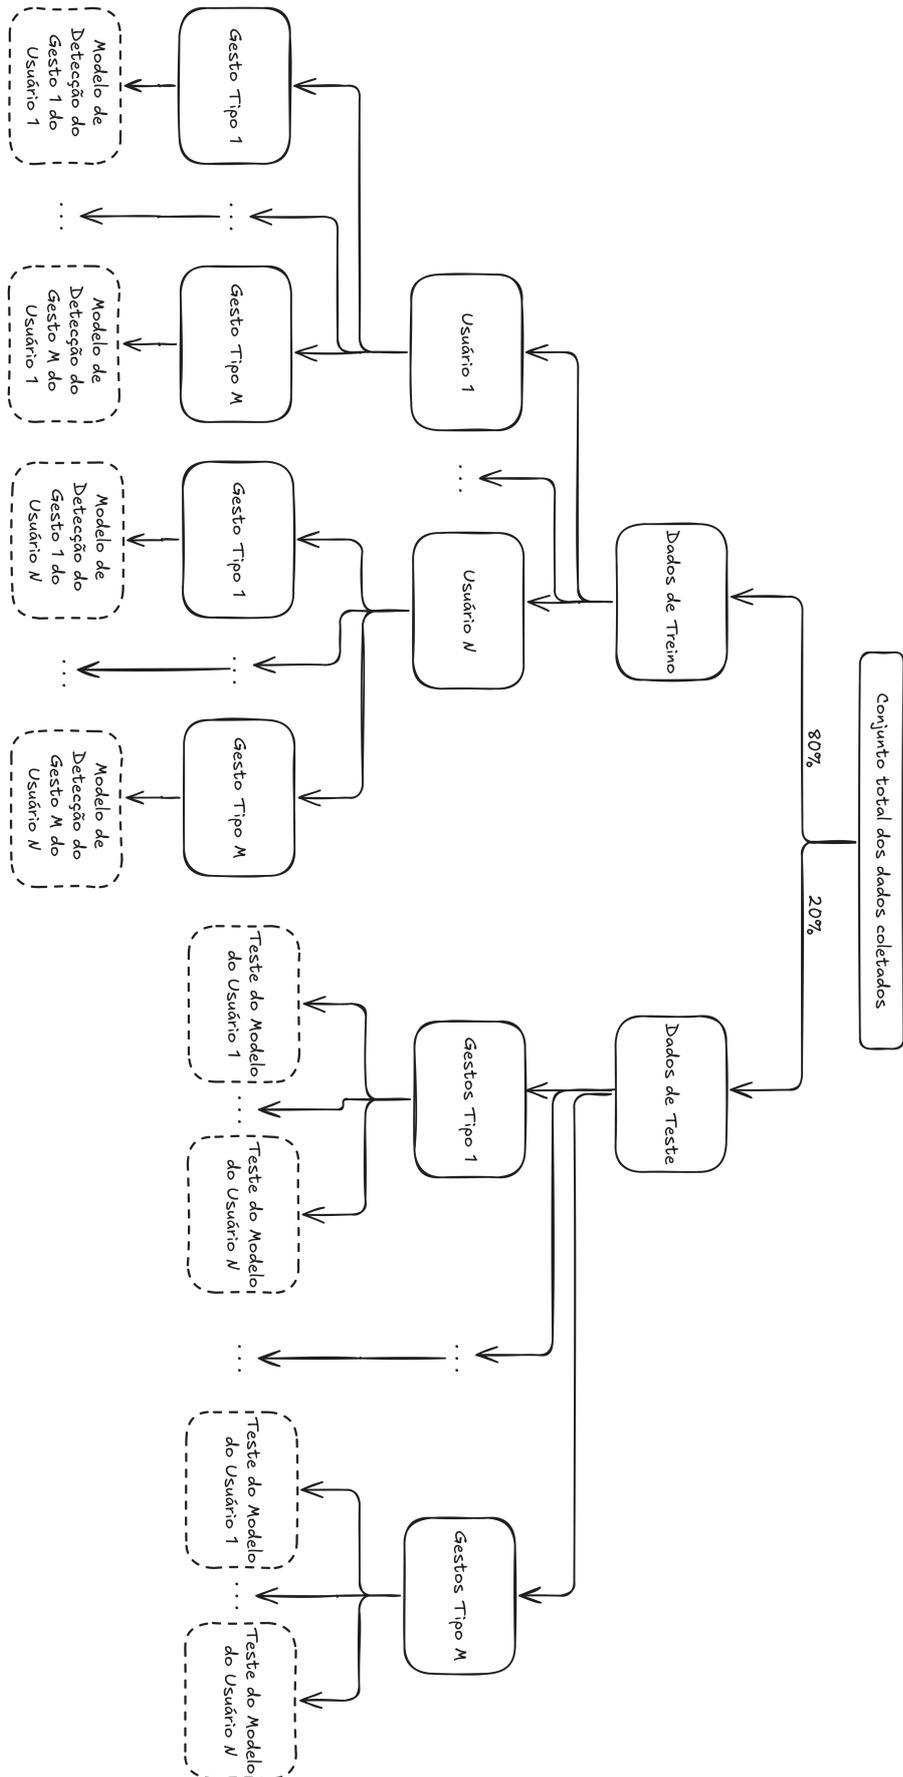
1. Separamos os dados que tínhamos por usuário, já que alguns usuários tinham mais gestos registrados que outros;
2. Para cada usuário, separamos 80% dos dados para treino e 20% para teste;
3. Dentro dos dados de treino fizemos uma nova divisão, agora por sentido do gesto;
4. Os dados de teste foram novamente misturados independente de usuário;
5. Os dados de teste foram separados por tipo de gesto, para que modelos treinados em um sentido classificassem gestos no mesmo sentido, porém de diversos usuários.

Utilizamos a divisão de 80% para treino e 20% para teste por ser amplamente difundida na literatura. O diagrama que ilustra a divisão dos dados está contido na Figura 12.

4.8 Acrescendo as informações do DTW ao conjunto de dados

Para adicionar as distâncias do DTW ao treinamento fizemos o seguinte, para cada um dos gestos contidos em um conjunto de dados, seriam calculadas as médias de distância

Figura 12 – Diagrama representando a separação dos dados



Fonte: O autor

DTW entre o gesto em questão e os membros daquele conjunto de dados. Então, por exemplo, suponha um conjunto total de dados do usuário A, lembre-se que para cada usuário os dados de treinamento são divididos por sentido do movimento, então vamos pegar o conjunto de dados que contém o gesto de deslizamentos para cima pertencentes ao usuário A. Esse conjunto de dados irá treinar um modelo, logo para cada um de seus elementos nós calcularemos a média das distâncias DTW entre ele e os demais membros desse mesmo grupo, essa média será uma nova característica extraída e será adicionada àquele gesto. Além disso, adicionamos também o desvio padrão dessa média.

Sendo assim, cada gesto de treino carrega consigo a média e o desvio padrão das distâncias dele para os outros elementos daquele conjunto de treino.

No caso de um novo gesto a ser testado será calculada a média e o desvio padrão da distância dele para cada um dos elementos de treino do modelo. No mundo real, isso se traduziria em calcular estas métricas entre um novo gesto a ser validado e os gestos já conhecidos daquele mesmo usuário. A ideia é que o algoritmo de detecção de anomalias, treinado com métricas calculadas apenas entre gestos reais do usuário, detectaria métricas que se distanciassem dessas.

Vale lembrar que essas métricas não são os únicos parâmetros a serem considerados pelo modelo, já que as características descritas na seção 4.4 também serão levadas em consideração.

4.9 Treinamento dos Modelos e Teste dos Modelos

Os modelos foram treinados como descrito nas seções anteriores. Não foram usados quaisquer tipos de parâmetros especiais no seu treinamento, seguindo apenas o que é recomendado na própria documentação. A implementação do algoritmo *Isolation Forest* escolhido foi a da biblioteca Scikit-learn⁸. Na Figura 13 pode ser vista a função que realizou o treinamento para cada um dos usuários e modelos.

4.9.1 Treinamento dos Modelos de Referência

Para verificar se houve melhora no desempenho ao adicionar as distâncias de DTW ao processo de detecção de anomalias treinamos também um modelo que não contou com estes dados para que no fim possamos compará-los.

⁸ <https://scikit-learn.org/stable/index.html>

Figura 13 – Trecho do código que treinou os modelos de Isolations Forest

```

features = ['start_x', 'start_y', 'end_x', 'end_y',
            'direction_vector_x', 'direction_vector_y',
            'direction_vector_magnitude', 'total_length',
            'average_speed', 'duration', 'media_distancias', 'desvio_padrao_distancias']

modelos_isolation_forest = {}

def treinar_isolation_forest_por_usuario(datasets_divididos):
    for usuario, tipos_gesto in datasets_divididos.items():
        modelos_isolation_forest[usuario] = {}

        for tipo_gesto, (X_tipo, y_tipo) in tipos_gesto.items():
            print(f"Treinando Isolation Forest para o usuário {usuario}, gesto {tipo_gesto}...")

            X_train_gesto = X_tipo[features]

            if len(X_train_gesto) > 0:
                isolation_forest = IsolationForest(n_estimators=100, contamination=0.1, random_state=42)
                isolation_forest.fit(X_train_gesto)

                modelos_isolation_forest[usuario][tipo_gesto] = isolation_forest
            else:
                print(f"Sem dados suficientes para treinar para o gesto {tipo_gesto} do usuário {usuario}.")

```

Fonte: O autor

4.9.2 Testes dos Modelos

Para testar os modelos utilizamos os conjuntos de dados divididos por sentido do gesto, logo fomos de modelo em modelo aplicando-o sobre conjunto de dados de teste correspondente ao sentido do gesto que aquele modelo havia sido treinado. As predições feitas por cada modelo foram armazenadas para análise posterior.

4.10 Análise dos Treinamentos

Para a análise dos resultados, comparamos a lista de predição de cada um dos modelos aos valores reais. Para cada um dos modelos foi feito um processo em que se substituiu os identificadores reais de usuário dos gestos por 1, caso o identificador fosse igual ao do usuário cujos dados foram usados para treinar o modelo, e 0 caso contrário.

Já no caso das predições a implementação em questão retorna -1 para ocorrências consideradas anômalas e 1 para ocorrências normais. Substituímos -1 por 0 para adequar ao mesmo padrão escolhido para os dados do conjunto de teste.

Por tanto, ao analisar os resultados de um modelo treinado para o usuário A todos as ocorrências de gestos daquele usuário no conjunto de teste seriam marcadas como 1 e as demais como zero, assim como as predições de gestos normais também foram marcados como 1 e os anormais como 0.

A análise dos resultados se fez utilizando a função *classification_report* da biblioteca Scikit-learn. Além disso, também foi utiliza a matriz de confusão. Os valores foram calculados

para cada um dos modelos por se tratarem de muitos modelos, também foram feitas versões agregadas de ambas as métricas para cada tipo de gesto, tendo assim a métrica dos modelos para cada tipo de gesto. No final também foi feito o aglomerado total com todos os modelos para termos uma visão geral de como estes se comportaram.

5 RESULTADOS

Como explicado na seção 4.10, os resultados de cada um dos modelos foi armazenado. Entretanto, o resultado é demasiadamente grande para ser que seja analisado de maneira individual os resultados de cada modelo, como pode ser visto no apêndice A.

Como foi dito, resolvemos unificar os relatórios de desempenho em uma única tabela. Para isso pensamos em fazer a média de cada um dos campos, a não ser dos campos da coluna *support* onde faríamos a soma para representar quantas vezes os modelos tiveram que lidar com a classe de dado em questão.

Isso se mostrou inefetivo já que em muitos casos o modelo havia predito apenas uma das classes, o que nos faz com que a função *classification_report* se comporte de maneira equívoca. Portanto, preferimos fazer a soma das matrizes de confusão e reproduzir os valores da função *classification_report* através de uma função que os calcula, que está exposta no Apêndice B.

Há um desbalanceamento acentuado entre as classes analisadas, portanto, levaremos em consideração principalmente o *recall* já que esse é capaz de avaliar quão bom é o desempenho do modelo em uma classe, sem levar em consideração a outra, o que é ideal para as classes desbalanceadas que temos.

Portanto, para uma avaliação geral de como foi o desempenho dos modelos, optamos por fazer a análise da tabela dos valores agregados. Com isso obtivemos a Tabela 2 e a matriz de confusão mostrada na Figura 14.

Tabela 2 – Tabela combinada dos resultados dos modelos que usaram DTW

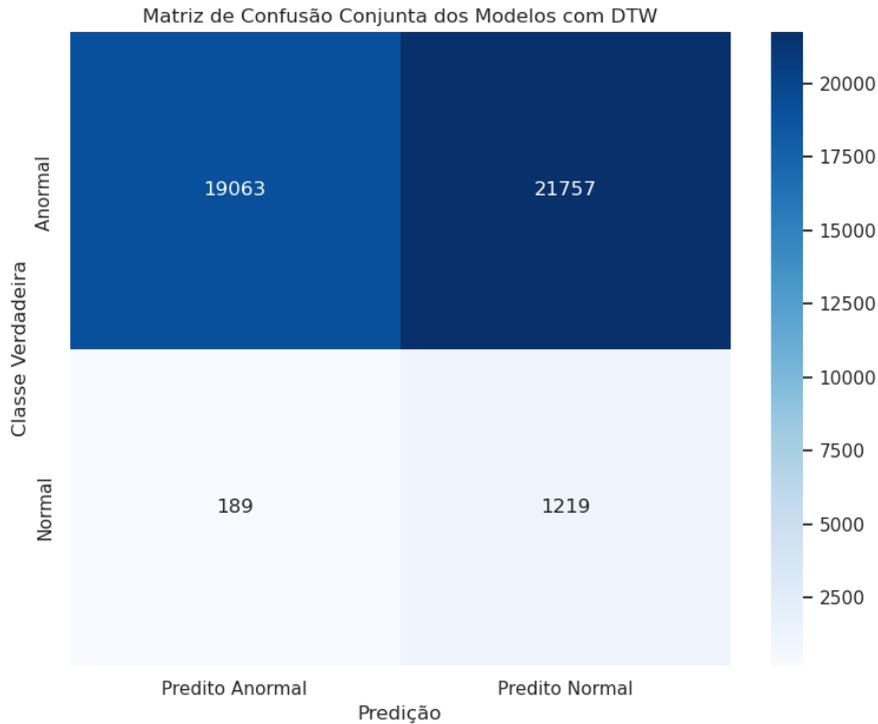
	precision	recall	f1-score	support
0	0.990183	0.467001	0.634672	40820
1	0.053055	0.865767	0.099984	1408
accuracy			0.480297	42228
macro avg	0.521619	0.666384	0.367328	42228
weighted avg	0.958936	0.480297	0.616844	42228

Fonte: O autor

Na Tabela 2 0 representa os gestos de intrusos, ou seja, gestos que deveriam ter sido considerados anômalos pelos modelos, já 1 representam os gestos autênticos.

Como podemos compreender a partir dos dados, os modelos se saíram bem em relação aos gestos do usuário real. Em mais de 86% dos casos o modelo foi capaz de classificar

Figura 14 – Matriz de Confusão Agregada dos Modelos que utilizaram DTW como métrica



Fonte: O autor

um gesto do usuário como sendo normal, o que por consequência significa que menos de 13% dos gestos de um usuário seriam interpretados como sendo anômalos. Por outro lado, podemos perceber que o *recall* dos gestos de invasores teve um desempenho abaixo dos 50%, o que nos mostra que na maior parte do tempo um invasor poderia se passar por um usuário legítimo.

Quanto à precisão dos modelos, o resultado parece animador quando vemos que a média ponderada das precisões ultrapassa 95% entretanto o valor desse resultado é baixo, já que esta métrica é fortemente afetada pelo desbalanceamento das classes. Isso se mostra quando vemos que o *recall* é de apenas 46%, ou seja, na maior parte das vezes o modelo prediz corretamente um gesto como anormal. Entretanto, como podemos ver na Figura 14 a quantidade de gestos de intrusos é tão maior que mesmo que o *recall* fosse reduzido a 2% o número de gestos anormais detectados ainda seria 4,3 vezes maior que o número de gestos autênticos detectados erroneamente como anormais, o que neste caso hipotético representaria uma precisão de 81%. Sendo assim, a precisão por si só não é de grande valor em nossa análise.

A média ponderada f1-score ponderado, que é a média harmônica entre a precisão e o *recall*, atingiu a marca de 61% demonstrando que de maneira geral, considerando tanto gestos

anômalos quanto gestos autênticos, o modelo foi capaz de detectar anomalias com bastante robustez.

5.1 O Modelo de Referência

Como dito no capítulo 4 treinamos também um modelo que não utilizou qualquer métrica relacionada às distâncias providas pelo DTW. A obtenção destes resultados seguiu a mesma metodologia que a seguida no modelo com DTW. O relatório de desempenho agregado desses modelos pode ser visto na Tabela 3 e sua matriz de confusão pode ser vista na Figura 15.

Tabela 3 – Tabela combinada dos resultados dos modelos que usaram DTW

	precision	recall	f1-score	support
0	0.989919	0.428197	0.597808	40820
1	0.050059	0.87358	0.094692	1408
accuracy			0.443047	42228
macro avg	0.519989	0.650888	0.34625	42228
weighted avg	0.958581	0.443047	0.581032	42228

Fonte: O autor

5.2 A Comparação dos Modelos

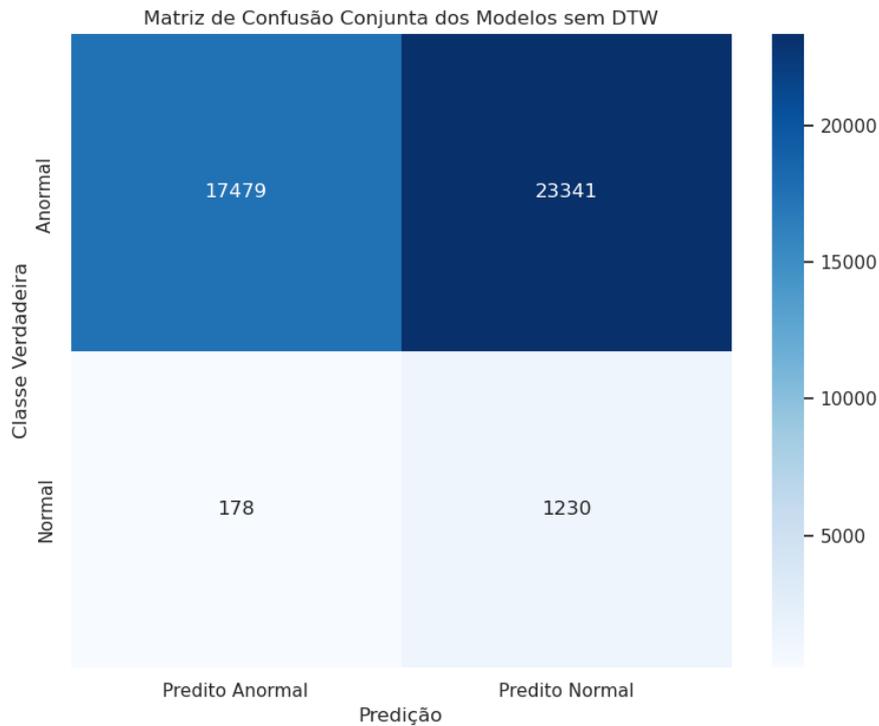
Com a comparação entre os modelos notamos que a adição das métricas geradas pelo DTW piorou o *recall* dos gestos do usuário, enquanto os modelos sem as métricas classificaram erroneamente 178 gestos do usuário, os modelos que usaram as métricas erraram 189 vezes. Isso representou uma piora de 0,7813% com a inserção das métricas.

Em contraponto à piora no *recall* dos gestos autênticos, houve uma melhora no *recall* dos gestos de intrusos, o que significou que na média o modelo começou a detectar como anômalo com maior frequência os gestos não autênticos. A melhora foi de 3,8804%, valor 4,97 vezes maior do que a piora na predição dos gestos do usuário autêntico.

No mundo real, isso significaria que um sistema que implementasse os modelos se tornaria mais difícil de usar por um usuário autêntico, mas no processo aumentariam a dificuldade para intrusos quase cinco vezes mais do que aumentou para o usuário real.

Ao analisarmos a média ponderada dos *recalls* notamos uma melhora absoluta de 3,725% das detecções do modelo sem o uso das métricas geradas com DTW para o modelo que as usou. O que, apesar de ainda manter o *recall* abaixo de 50% de acertos, representa um

Figura 15 – Matriz de Confusão Agregada dos Modelos que não utilizaram DTW como métrica



Fonte: O autor

aumento relativo de 8,40% em relação ao seu antigo valor.

É possível também notar melhora em outras métricas de desempenho do modelo como precisão de f1-score, entretanto como já foi dito anteriormente estas métricas são muito afetadas pelo desbalanceamento, então não tem tanto valor quanto o *recall*.

Outro fato a ser levado em consideração na análise é que na maior parte do tempo é esperado que os gestos analisados sejam legítimos, com gestos anômalos tendo baixa ocorrência. Portanto, na maior parte do tempo os modelos com DTW, apesar de serem menos efetivos que os sem, continuam tendo um acerto de mais de 86%.

Como consequência, espera-se que os gestos de um intruso ocorram com menor frequência, por tanto, melhorar a capacidade de detectá-los com maior precisão se mostra de extrema importância.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho foi capaz, então, de concluir que a aplicação do uso de métricas geradas pelo algoritmo DTW como parâmetros para modelos de um algoritmo de detecção de anomalias é capaz de melhorar o desempenho dos modelos na detecção de gestos anômalos. Apesar disso, houve leve decréscimo de desempenho da classificação de gestos pertencentes ao usuário autêntico.

Haja vista que os sistemas propostos em trabalhos relacionados como os de (Mondal; Bours, 2015), (Filippov *et al.*, 2018) e (Garbuz *et al.*, 2019) são baseados em autenticação contínua, a leve piora na classificação de gestos do usuário poderia ser suprida por um melhor balanceamento nos *scores* atribuídos a gestos anômalos. Essa calibração se mostraria principalmente efetiva em casos de gestos anômalos seguidos, já que a capacidade aumentada de classificar gestos de intrusos como anômalos faria com que gestos seguidos tivessem ainda maior probabilidade de se tratar de um intruso.

6.1 Limitações do Trabalho

Nosso trabalho apresentou limitações que podem ter impactado os resultados da pesquisa. Este é o caso do baixo número de usuários. Outro fator é o tipo de *smartphone* utilizado pelos usuários, como não os levamos em consideração, em grande parte por não termos uma base grande suficiente de usuários para separá-los em grupos, é possível que os dispositivos por serem diferentes tenham impacto sobre a capacidade dos modelos de detectar gestos anômalos.

6.2

Sugestões para Pesquisas Futuras Para futuras pesquisas, que sejam testados outros métodos de agrupamento de gestos que não pela direção do mesmo. É possível que um modelo de aprendizado de máquina não supervisionado, capaz de agrupar os gestos do usuário, fosse capaz de gerar grupos de gestos melhores para treinar os modelos. Assim, no lugar de treinar até oito modelos por usuário, que era o nosso teto, o algoritmo teria maior liberdade para decidir quantos modelos seriam necessários para detectar anomalias baseado nos gestos conhecidos daquele usuário.

Outro caminho válido a se tomar em trabalhos futuros é a análise de outros algoritmos que, assim como o DTW, sejam capazes de avaliar a similaridade entre os gestos, sejam esses

algoritmos focados em séries temporais, ou algoritmos capazes de avaliar formatos de figuras geométricas, já que os gestos também podem ser encarados por essa perspectiva. Ainda sobre variações dos algoritmos utilizados pode também ser estudado o impacto das métricas sobre outros algoritmos de detecção de anomalias, como OSVM.

Também propomos como melhorias para futuras pesquisas que ao calcularem as distâncias entre gestos com o algoritmo DTW as coordenadas dos gestos fossem normalizadas, assim o algoritmo teria maior capacidade de comparar o formato dos gestos, sem levar em consideração a distância na tela que eles aconteceram. Isso talvez possa reduzir o impacto do tipo de dispositivo sobre os modelos e aumentaria o valor do custo atribuído pelo algoritmo.

A avaliação de um modelo de autenticação contínua também deve ser estudado, junto a isso o impacto no consumo computacional e energético do dispositivo causado por esse processo também é algo a ser avaliado.

Por fim, propomos que sejam analisadas outras formas de utilizar os valores do algoritmo DTW que não por meio da média das distâncias e desvio padrão da amostra com os dados de treino.

REFERÊNCIAS

BOONKRONG, S. **Authentication and Access Control: Practical Cryptography Methods and Tools**. [S. l.]: Apress, 2021. ISBN 978-1-4842-6569-7.

COINTELEGRAPH. **R\$ 103 bilhões roubados: Brasil é o 2º país que mais sofre crimes cibernéticos na América Latina**. 2023. Disponível em: <https://exame.com/future-of-money/r-103-bilhoes-roubados-brasil-e-o-2o-pais-que-mais-sofre-crimes-ciberneticos-na-america-latina/>. Acesso em: 28 ago. 2024.

DHS. **Biometrics**. 2021. Disponível em: <https://www.dhs.gov/biometrics>. Acesso em: 02 jul. 2022.

DOLAN, S. **How mobile users spend their time on their smartphones in 2022**. 2022. Disponível em: <https://www.insiderintelligence.com/insights/mobile-users-smartphone-usage>.

FILIPPOV, A. I.; IUZBASHEV, A. V.; KURNEV, A. S. User authentication via touch pattern recognition based on isolation forest. In: **2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus)**. [S. l.: s. n.], 2018. p. 1485–1489.

GARBUZ, A.; EPISHKINA, A.; KOGOS, K. Continuous authentication of smartphone users via swipes and taps analysis. **2019 European Intelligence and Security Informatics Conference (EISIC)**, p. 48–53, 2019.

GRASSI, P. A.; GARCIA, M. E.; FENTON, J. L. **NIST Special Publication 800-63-3, Digital Identity Guidelines**. [S. l.], 2020.

INGRAM, S. **The Thumb Zone: Designing For Mobile Users**. 2016. Disponível em: <https://www.smashingmagazine.com/2016/09/the-thumb-zone-designing-for-mobile-users/>. Acesso em: 16 sep. 2024.

KAMELIA, L.; HAMIDI, E. A. D.; DARMALAKSANA, W.; NUGRAHA, A. Real-time online attendance system based on fingerprint and gps in the smartphone. In: **2018 4th International Conference on Wireless and Telematics (ICWT)**. [S. l.: s. n.], 2018. p. 1–4.

KAMPER, H. **lecture_dtw_notebook**. 2021. Disponível em: https://github.com/kamperh/lecture_dtw_notebook.

KEMP, S. **Mobile cellular subscriptions**. 2023. Disponível em: <https://datareportal.com/reports/digital-2023-global-overview-report>. Acesso em: 14 ago. 2024.

MONDAL, S.; BOURS, P. Swipe gesture based continuous authentication for mobile devices. In: **2015 International Conference on Biometrics (ICB)**. [S. l.: s. n.], 2015. p. 458–465.

SAKOE, H.; CHIBA, S. Dynamic programming algorithm optimization for spoken word recognition. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 26, n. 1, p. 43–49, 1978.

SOUZA, C. F. S.; PANTOJA, C. E. P.; SOUZA, F. C. M. Verificação de assinaturas offline utilizando dynamic time warping. In: **Anais do 9. Congresso Brasileiro de Redes Neurais**. Ouro Preto, MG: SBRN, 2009. p. 1–5.

WILSON, Y.; HINGNIKAR, A. **Solving Identity Management in Modern Applications: Demystifying OAuth 2.0, OpenID Connect, and SAML 2.0.** [S. l.]: Apress, 2019. ISBN 978-1-4842-5094-5.

APÊNDICE A – RESULTADOS INDIVIDUAIS DOS MODELOS

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: 1-1

	precision	recall	f1-score	support
0	0.986755	0.752525	0.853868	198
1	0.155172	0.818182	0.260870	11
accuracy			0.755981	209
macro avg	0.570964	0.785354	0.557369	209
weighted avg	0.942987	0.755981	0.822658	209

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: 11

	precision	recall	f1-score	support
0	0.978142	0.383298	0.550769	467
1	0.150442	0.927273	0.258883	55
accuracy			0.440613	522
macro avg	0.564292	0.655285	0.404826	522
weighted avg	0.890932	0.440613	0.520015	522

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: 01

	precision	recall	f1-score	support
0	0.944444	0.739130	0.829268	23
1	0.500000	0.857143	0.631579	7
accuracy			0.766667	30
macro avg	0.722222	0.798137	0.730424	30
weighted avg	0.840741	0.766667	0.783141	30

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: 0-1

	precision	recall	f1-score	support
0	0.933333	0.474576	0.629213	59
1	0.261905	0.846154	0.400000	13
accuracy			0.541667	72
macro avg	0.597619	0.660365	0.514607	72
weighted avg	0.812103	0.541667	0.587828	72

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: -11

	precision	recall	f1-score	support
0	0.976744	0.865979	0.918033	97
1	0.350000	0.777778	0.482759	9
accuracy			0.858491	106
macro avg	0.663372	0.821879	0.700396	106
weighted avg	0.923530	0.858491	0.881076	106

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.189274	0.318302	317
1	0.015326	1.000000	0.030189	4
accuracy			0.199377	321
macro avg	0.507663	0.594637	0.174246	321
weighted avg	0.987730	0.199377	0.314712	321

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.779070	0.875817	86
1	0.269231	1.000000	0.424242	7
accuracy			0.795699	93
macro avg	0.634615	0.889535	0.650030	93
weighted avg	0.944996	0.795699	0.841828	93

Usuário: d8f70ead-3545-49bb-9c85-d1060954a4ea, Tipo
de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	63
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	63
macro avg	0.000000	0.000000	0.000000	63
weighted avg	0.000000	0.000000	0.000000	63

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: 1-1

	precision	recall	f1-score	support
0	0.993827	0.870270	0.927954	185
1	0.489362	0.958333	0.647887	24
accuracy			0.880383	209
macro avg	0.741594	0.914302	0.787921	209
weighted avg	0.935898	0.880383	0.895793	209

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: 11

	precision	recall	f1-score	support
0	0.989390	0.746000	0.850627	500
1	0.124138	0.818182	0.215569	22
accuracy			0.749042	522
macro avg	0.556764	0.782091	0.533098	522
weighted avg	0.952923	0.749042	0.823862	522

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.857605	0.923345	309
1	0.214286	1.000000	0.352941	12
accuracy			0.862928	321
macro avg	0.607143	0.928803	0.638143	321
weighted avg	0.970628	0.862928	0.902021	321

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: -11

	precision	recall	f1-score	support
0	0.987952	0.872340	0.926554	94
1	0.478261	0.916667	0.628571	12
accuracy			0.877358	106
macro avg	0.733106	0.894504	0.777563	106
weighted avg	0.930251	0.877358	0.892820	106

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: 10

	precision	recall	f1-score	support
0	0.985075	0.750000	0.851613	88
1	0.153846	0.800000	0.258065	5
accuracy			0.752688	93
macro avg	0.569460	0.775000	0.554839	93
weighted avg	0.940385	0.752688	0.819702	93

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.805970	0.892562	67
1	0.277778	1.000000	0.434783	5
accuracy			0.819444	72
macro avg	0.638889	0.902985	0.663672	72
weighted avg	0.949846	0.819444	0.860772	72

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.800000	0.888889	30
1	0.000000	0.000000	0.000000	0
accuracy			0.800000	30
macro avg	0.500000	0.400000	0.444444	30
weighted avg	1.000000	0.800000	0.888889	30

Usuário: 2a2a3614-6d8b-4ee5-b9fa-23d056b0e81a, Tipo
de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	62
1	0.015873	1.000000	0.031250	1
accuracy			0.015873	63
macro avg	0.007937	0.500000	0.015625	63
weighted avg	0.000252	0.015873	0.000496	63

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo
de Gesto: 11

	precision	recall	f1-score	support
0	0.993421	0.904192	0.946708	501
1	0.272727	0.857143	0.413793	21
accuracy			0.902299	522
macro avg	0.633074	0.880667	0.680251	522
weighted avg	0.964428	0.902299	0.925269	522

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo
de Gesto: -1-1

	precision	recall	f1-score	support
0	0.995050	0.676768	0.805611	297
1	0.193277	0.958333	0.321678	24
accuracy			0.697819	321
macro avg	0.594163	0.817551	0.563645	321
weighted avg	0.935104	0.697819	0.769429	321

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo
de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo
de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.244019	0.392308	209
1	0.000000	0.000000	0.000000	0
accuracy			0.244019	209
macro avg	0.500000	0.122010	0.196154	209
weighted avg	1.000000	0.244019	0.392308	209

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo
de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	106
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	106
macro avg	0.000000	0.000000	0.000000	106
weighted avg	0.000000	0.000000	0.000000	106

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.965517	0.800000	0.875000	70
1	0.000000	0.000000	0.000000	2
accuracy			0.777778	72
macro avg	0.482759	0.400000	0.437500	72
weighted avg	0.938697	0.777778	0.850694	72

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.714286	0.833333	63
1	0.000000	0.000000	0.000000	0
accuracy			0.714286	63
macro avg	0.500000	0.357143	0.416667	63
weighted avg	1.000000	0.714286	0.833333	63

Usuário: 7500de4f-daf4-4678-bc65-f9851c9d3270, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.075269	0.140000	93
1	0.000000	0.000000	0.000000	0
accuracy			0.075269	93
macro avg	0.500000	0.037634	0.070000	93
weighted avg	1.000000	0.075269	0.140000	93

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.952381	0.588235	0.727273	68
1	0.066667	0.500000	0.117647	4
accuracy			0.583333	72
macro avg	0.509524	0.544118	0.422460	72
weighted avg	0.903175	0.583333	0.693405	72

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.122568	0.218371	514
1	0.017429	1.000000	0.034261	8
accuracy			0.136015	522
macro avg	0.508715	0.561284	0.126316	522
weighted avg	0.984941	0.136015	0.215549	522

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.971631	0.744565	0.843077	184
1	0.308824	0.840000	0.451613	25
accuracy			0.755981	209
macro avg	0.640227	0.792283	0.647345	209
weighted avg	0.892348	0.755981	0.796251	209

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.996063	0.795597	0.884615	318
1	0.029851	0.666667	0.057143	3
accuracy			0.794393	321
macro avg	0.512957	0.731132	0.470879	321
weighted avg	0.987033	0.794393	0.876882	321

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.180328	0.305556	61
1	0.038462	1.000000	0.074074	2
accuracy			0.206349	63
macro avg	0.519231	0.590164	0.189815	63
weighted avg	0.969475	0.206349	0.298207	63

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.179245	0.304000	106
1	0.000000	0.000000	0.000000	0
accuracy			0.179245	106
macro avg	0.500000	0.089623	0.152000	106
weighted avg	1.000000	0.179245	0.304000	106

Usuário: 56ea2b38-3b80-49b9-a185-cc18c69ed47, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	92
1	0.010753	1.000000	0.021277	1
accuracy			0.010753	93
macro avg	0.005376	0.500000	0.010638	93
weighted avg	0.000116	0.010753	0.000229	93

Usuário: 56ea2b38-3b80-49b9-a185-cce18c69ed47, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.982143	0.350318	0.516432	314
1	0.023923	0.714286	0.046296	7
accuracy			0.358255	321
macro avg	0.503033	0.532302	0.281364	321
weighted avg	0.961247	0.358255	0.506180	321

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	91
1	0.021505	1.000000	0.042105	2
accuracy			0.021505	93
macro avg	0.010753	0.500000	0.021053	93
weighted avg	0.000462	0.021505	0.000905	93

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.155039	0.268456	516
1	0.013575	1.000000	0.026786	6
accuracy			0.164751	522
macro avg	0.506787	0.577519	0.147621	522
weighted avg	0.988662	0.164751	0.265679	522

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.066667	0.125000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.066667	30
macro avg	0.500000	0.033333	0.062500	30
weighted avg	1.000000	0.066667	0.125000	30

Usuário: 5b735f99-1cf1-47be-a3fa-395a535d4809, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	62
1	0.015873	1.000000	0.031250	1
accuracy			0.015873	63
macro avg	0.007937	0.500000	0.015625	63
weighted avg	0.000252	0.015873	0.000496	63

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.974790	0.393220	0.560386	295
1	0.113861	0.884615	0.201754	26
accuracy			0.433022	321
macro avg	0.544326	0.638918	0.381070	321
weighted avg	0.905057	0.433022	0.531338	321

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.764706	0.866667	102
1	0.142857	1.000000	0.250000	4
accuracy			0.773585	106
macro avg	0.571429	0.882353	0.558333	106
weighted avg	0.967655	0.773585	0.843396	106

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.975610	0.714286	0.824742	56
1	0.272727	0.857143	0.413793	7
accuracy			0.730159	63
macro avg	0.624169	0.785714	0.619268	63
weighted avg	0.897512	0.730159	0.779081	63

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.942029	0.970149	207
1	0.142857	1.000000	0.250000	2
accuracy			0.942584	209
macro avg	0.571429	0.971014	0.610075	209
weighted avg	0.991798	0.942584	0.963258	209

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.010753	0.021277	93
1	0.000000	0.000000	0.000000	0
accuracy			0.010753	93
macro avg	0.500000	0.005376	0.010638	93
weighted avg	1.000000	0.010753	0.021277	93

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.985507	0.132554	0.233677	513
1	0.017660	0.888889	0.034632	9
accuracy			0.145594	522
macro avg	0.501584	0.510721	0.134155	522
weighted avg	0.968820	0.145594	0.230245	522

Usuário: 458e8455-d6f7-4a85-85f5-a20868cd258f, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.983051	0.802768	0.883810	289
1	0.329412	0.875000	0.478632	32
accuracy			0.809969	321
macro avg	0.656231	0.838884	0.681221	321
weighted avg	0.917891	0.809969	0.843418	321

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.285714	0.444444	91
1	0.029851	1.000000	0.057971	2
accuracy			0.301075	93
macro avg	0.514925	0.642857	0.251208	93
weighted avg	0.979137	0.301075	0.436133	93

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.992647	0.688776	0.813253	196
1	0.164384	0.923077	0.279070	13
accuracy			0.703349	209
macro avg	0.578515	0.805926	0.546161	209
weighted avg	0.941128	0.703349	0.780026	209

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.703704	0.826087	27
1	0.272727	1.000000	0.428571	3
accuracy			0.733333	30
macro avg	0.636364	0.851852	0.627329	30
weighted avg	0.927273	0.733333	0.786335	30

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.968750	0.311245	0.471125	498
1	0.052486	0.791667	0.098446	24
accuracy			0.333333	522
macro avg	0.510618	0.551456	0.284785	522
weighted avg	0.926623	0.333333	0.453990	522

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.888889	0.326531	0.477612	49
1	0.266667	0.857143	0.406780	14
accuracy			0.444444	63
macro avg	0.577778	0.591837	0.442196	63
weighted avg	0.750617	0.444444	0.461871	63

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.978261	0.483871	0.647482	93
1	0.200000	0.923077	0.328767	13
accuracy			0.537736	106
macro avg	0.589130	0.703474	0.488125	106
weighted avg	0.882814	0.537736	0.608394	106

Usuário: dcc682d7-551a-4d78-884f-a4e8051aeb0a, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.101449	0.184211	69
1	0.046154	1.000000	0.088235	3
accuracy			0.138889	72
macro avg	0.523077	0.550725	0.136223	72
weighted avg	0.960256	0.138889	0.180212	72

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.987952	0.652087	0.785629	503
1	0.078947	0.789474	0.143541	19
accuracy			0.657088	522
macro avg	0.533450	0.720781	0.464585	522
weighted avg	0.954865	0.657088	0.762258	522

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.978723	0.294872	0.453202	312
1	0.030837	0.777778	0.059322	9
accuracy			0.308411	321
macro avg	0.504780	0.536325	0.256262	321
weighted avg	0.952147	0.308411	0.442159	321

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.977273	0.651515	0.781818	66
1	0.178571	0.833333	0.294118	6
accuracy			0.666667	72
macro avg	0.577922	0.742424	0.537968	72
weighted avg	0.910714	0.666667	0.741176	72

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.798077	0.887701	208
1	0.023256	1.000000	0.045455	1
accuracy			0.799043	209
macro avg	0.511628	0.899038	0.466578	209
weighted avg	0.995327	0.799043	0.883671	209

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.962963	0.456140	0.619048	57
1	0.138889	0.833333	0.238095	6
accuracy			0.492063	63
macro avg	0.550926	0.644737	0.428571	63
weighted avg	0.884480	0.492063	0.582766	63

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.985915	0.686275	0.809249	102
1	0.085714	0.750000	0.153846	4
accuracy			0.688679	106
macro avg	0.535815	0.718137	0.481547	106
weighted avg	0.951946	0.688679	0.784516	106

Usuário: 1e03ce4d-6877-4c23-b181-c31b47c97d99, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.857143	0.230769	0.363636	26
1	0.130435	0.750000	0.222222	4
accuracy			0.300000	30
macro avg	0.493789	0.490385	0.292929	30
weighted avg	0.760248	0.300000	0.344781	30

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.972414	0.473154	0.636569	298
1	0.107955	0.826087	0.190955	23
accuracy			0.498442	321
macro avg	0.540184	0.649621	0.413762	321
weighted avg	0.910474	0.498442	0.604640	321

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.603448	0.752688	58
1	0.178571	1.000000	0.303030	5
accuracy			0.634921	63
macro avg	0.589286	0.801724	0.527859	63
weighted avg	0.934807	0.634921	0.717001	63

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.995338	0.832359	0.906582	513
1	0.075269	0.777778	0.137255	9
accuracy			0.831418	522
macro avg	0.535303	0.805068	0.521918	522
weighted avg	0.979475	0.831418	0.893317	522

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.975000	0.428571	0.595420	91
1	0.018868	0.500000	0.036364	2
accuracy			0.430108	93
macro avg	0.496934	0.464286	0.315892	93
weighted avg	0.954438	0.430108	0.583397	93

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.981132	0.776119	0.866667	67
1	0.210526	0.800000	0.333333	5
accuracy			0.777778	72
macro avg	0.595829	0.788060	0.600000	72
weighted avg	0.927618	0.777778	0.829630	72

Usuário: 439f215b-b2a9-4c89-9b53-4bbb4030601b, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	208
1	0.004785	1.000000	0.009524	1
accuracy			0.004785	209
macro avg	0.002392	0.500000	0.004762	209
weighted avg	0.000023	0.004785	0.000046	209

Usuário: 5fc9013f-f7d0-4385-be7f-55dce3346c09, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.995868	0.479125	0.646980	503
1	0.064286	0.947368	0.120401	19
accuracy			0.496169	522
macro avg	0.530077	0.713247	0.383691	522
weighted avg	0.961960	0.496169	0.627813	522

Usuário: 5fc9013f-f7d0-4385-be7f-55dce3346c09, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.981395	0.694079	0.813102	304
1	0.122642	0.764706	0.211382	17
accuracy			0.697819	321
macro avg	0.552018	0.729392	0.512242	321
weighted avg	0.935916	0.697819	0.781235	321

Usuário: 5fc9013f-f7d0-4385-be7f-55dce3346c09, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.800000	0.888889	205
1	0.088889	1.000000	0.163265	4
accuracy			0.803828	209
macro avg	0.544444	0.900000	0.526077	209
weighted avg	0.982562	0.803828	0.875001	209

Usuário: 5fc9013f-f7d0-4385-be7f-55dce3346c09, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.283582	0.441860	67
1	0.094340	1.000000	0.172414	5
accuracy			0.333333	72
macro avg	0.547170	0.641791	0.307137	72
weighted avg	0.937107	0.333333	0.423149	72

Usuário: 5fc9013f-f7d0-4385-be7f-55dce3346c09, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.337209	0.504348	86
1	0.109375	1.000000	0.197183	7
accuracy			0.387097	93
macro avg	0.554688	0.668605	0.350765	93
weighted avg	0.932964	0.387097	0.481228	93

Usuário: 79048984-d4b7-4dda-b907-f910af11c440, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.983607	0.697674	0.816327	86
1	0.187500	0.857143	0.307692	7
accuracy			0.709677	93
macro avg	0.585553	0.777409	0.562009	93
weighted avg	0.923685	0.709677	0.778042	93

Usuário: 79048984-d4b7-4dda-b907-f910af11c440, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.994737	0.769857	0.867968	491
1	0.204225	0.935484	0.335260	31
accuracy			0.779693	522
macro avg	0.599481	0.852671	0.601614	522
weighted avg	0.947791	0.779693	0.836332	522

Usuário: 79048984-d4b7-4dda-b907-f910af11c440, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.503125	0.669439	320
1	0.006250	1.000000	0.012422	1
accuracy			0.504673	321
macro avg	0.503125	0.751563	0.340931	321
weighted avg	0.996904	0.504673	0.667392	321

Usuário: 79048984-d4b7-4dda-b907-f910af11c440, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.987097	0.757426	0.857143	202
1	0.092593	0.714286	0.163934	7
accuracy			0.755981	209
macro avg	0.539845	0.735856	0.510539	209
weighted avg	0.957137	0.755981	0.833925	209

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.993711	0.628231	0.769793	503
1	0.083333	0.894737	0.152466	19
accuracy			0.637931	522
macro avg	0.538522	0.761484	0.461130	522
weighted avg	0.960574	0.637931	0.747323	522

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.242857	0.390805	70
1	0.036364	1.000000	0.070175	2
accuracy			0.263889	72
macro avg	0.518182	0.621429	0.230490	72
weighted avg	0.973232	0.263889	0.381898	72

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.700000	0.823529	20
1	0.625000	1.000000	0.769231	10
accuracy			0.800000	30
macro avg	0.812500	0.850000	0.796380	30
weighted avg	0.875000	0.800000	0.805430	30

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.943396	0.970874	106
1	0.000000	0.000000	0.000000	0
accuracy			0.943396	106
macro avg	0.500000	0.471698	0.485437	106
weighted avg	1.000000	0.943396	0.970874	106

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.978723	0.779661	0.867925	59
1	0.187500	0.750000	0.300000	4
accuracy			0.777778	63
macro avg	0.583112	0.764831	0.583962	63
weighted avg	0.928487	0.777778	0.831866	63

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.996491	0.904459	0.948247	314
1	0.166667	0.857143	0.279070	7
accuracy			0.903427	321
macro avg	0.581579	0.880801	0.613658	321
weighted avg	0.978395	0.903427	0.933654	321

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.388889	0.560000	90
1	0.051724	1.000000	0.098361	3
accuracy			0.408602	93
macro avg	0.525862	0.694444	0.329180	93
weighted avg	0.969410	0.408602	0.545108	93

Usuário: a471aeef-bfbb-4f61-88f1-82e34c208ed6, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	209
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	209
macro avg	0.000000	0.000000	0.000000	209
weighted avg	0.000000	0.000000	0.000000	209

Usuário: f5d5927e-b53a-4a58-bc94-b47371218f47, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.997642	0.835968	0.909677	506
1	0.153061	0.937500	0.263158	16
accuracy			0.839080	522
macro avg	0.575351	0.886734	0.586418	522
weighted avg	0.971754	0.839080	0.889861	522

Usuário: f5d5927e-b53a-4a58-bc94-b47371218f47, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.347826	0.516129	92
1	0.016393	1.000000	0.032258	1
accuracy			0.354839	93
macro avg	0.508197	0.673913	0.274194	93
weighted avg	0.989424	0.354839	0.510926	93

Usuário: f5d5927e-b53a-4a58-bc94-b47371218f47, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.994949	0.951691	0.972840	207
1	0.090909	0.500000	0.153846	2
accuracy			0.947368	209
macro avg	0.542929	0.725845	0.563343	209
weighted avg	0.986298	0.947368	0.965002	209

Usuário: f5d5927e-b53a-4a58-bc94-b47371218f47, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	321
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	321
macro avg	0.000000	0.000000	0.000000	321
weighted avg	0.000000	0.000000	0.000000	321

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.981013	0.856354	0.914454	181
1	0.490196	0.892857	0.632911	28
accuracy			0.861244	209
macro avg	0.735604	0.874605	0.773683	209
weighted avg	0.915257	0.861244	0.876736	209

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.969697	0.316832	0.477612	101
1	0.054795	0.800000	0.102564	5
accuracy			0.339623	106
macro avg	0.512246	0.558416	0.290088	106
weighted avg	0.926541	0.339623	0.459921	106

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.913043	0.041176	0.078799	510
1	0.020040	0.833333	0.039139	12
accuracy			0.059387	522
macro avg	0.466542	0.437255	0.058969	522
weighted avg	0.892515	0.059387	0.077888	522

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	93
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	93
macro avg	0.000000	0.000000	0.000000	93
weighted avg	0.000000	0.000000	0.000000	93

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.206897	0.342857	58
1	0.098039	1.000000	0.178571	5
accuracy			0.269841	63
macro avg	0.549020	0.603448	0.260714	63
weighted avg	0.928416	0.269841	0.329819	63

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	66
1	0.083333	1.000000	0.153846	6
accuracy			0.083333	72
macro avg	0.041667	0.500000	0.076923	72
weighted avg	0.006944	0.083333	0.012821	72

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.985915	0.438871	0.607375	319
1	0.000000	0.000000	0.000000	2
accuracy			0.436137	321
macro avg	0.492958	0.219436	0.303688	321
weighted avg	0.979773	0.436137	0.603591	321

Usuário: 38166dce-dc6c-46b9-a52a-2981d2f7e0f6, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.551724	0.711111	29
1	0.071429	1.000000	0.133333	1
accuracy			0.566667	30
macro avg	0.535714	0.775862	0.422222	30
weighted avg	0.969048	0.566667	0.691852	30

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.975610	0.203046	0.336134	197
1	0.065476	0.916667	0.122222	12
accuracy			0.244019	209
macro avg	0.520543	0.559856	0.229178	209
weighted avg	0.923353	0.244019	0.323852	209

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.896552	0.282609	0.429752	92
1	0.142857	0.785714	0.241758	14
accuracy			0.349057	106
macro avg	0.519704	0.534161	0.335755	106
weighted avg	0.797007	0.349057	0.404923	106

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.977612	0.261477	0.412598	501
1	0.046392	0.857143	0.088020	21
accuracy			0.285441	522
macro avg	0.512002	0.559310	0.250309	522
weighted avg	0.940149	0.285441	0.399541	522

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.264151	0.417910	318
1	0.012658	1.000000	0.025000	3
accuracy			0.271028	321
macro avg	0.506329	0.632075	0.221455	321
weighted avg	0.990773	0.271028	0.414238	321

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.098361	0.179104	61
1	0.035088	1.000000	0.067797	2
accuracy			0.126984	63
macro avg	0.517544	0.549180	0.123451	63
weighted avg	0.969368	0.126984	0.175571	63

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.928571	0.185714	0.309524	70
1	0.017241	0.500000	0.033333	2
accuracy			0.194444	72
macro avg	0.472906	0.342857	0.171429	72
weighted avg	0.903257	0.194444	0.301852	72

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	28
1	0.066667	1.000000	0.125000	2
accuracy			0.066667	30
macro avg	0.033333	0.500000	0.062500	30
weighted avg	0.004444	0.066667	0.008333	30

Usuário: ebc55ed9-a5a3-44c6-96ce-134ecdecc935, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.741935	0.851852	93
1	0.000000	0.000000	0.000000	0
accuracy			0.741935	93
macro avg	0.500000	0.370968	0.425926	93
weighted avg	1.000000	0.741935	0.851852	93

Usuário: ca8bdf11-8cf2-4699-bcf9-f49f76599d02, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.972000	0.812709	0.885246	299
1	0.211268	0.681818	0.322581	22
accuracy			0.803738	321
macro avg	0.591634	0.747264	0.603913	321
weighted avg	0.919863	0.803738	0.846683	321

Usuário: ca8bdf11-8cf2-4699-bcf9-f49f76599d02, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.289157	0.448598	83
1	0.144928	1.000000	0.253165	10
accuracy			0.365591	93
macro avg	0.572464	0.644578	0.350881	93
weighted avg	0.908057	0.365591	0.427584	93

Usuário: ca8bdf11-8cf2-4699-bcf9-f49f76599d02, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.994318	0.680934	0.808314	514
1	0.035294	0.750000	0.067416	8
accuracy			0.681992	522
macro avg	0.514806	0.715467	0.437865	522
weighted avg	0.979620	0.681992	0.796959	522

Usuário: ca8bdf11-8cf2-4699-bcf9-f49f76599d02, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.605634	0.754386	71
1	0.034483	1.000000	0.066667	1
accuracy			0.611111	72
macro avg	0.517241	0.802817	0.410526	72
weighted avg	0.986590	0.611111	0.744834	72

Usuário: ca8bdf11-8cf2-4699-bcf9-f49f76599d02, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	209
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	209
macro avg	0.000000	0.000000	0.000000	209
weighted avg	0.000000	0.000000	0.000000	209

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.982993	0.932258	0.956954	310
1	0.222222	0.545455	0.315789	11
accuracy			0.919003	321
macro avg	0.602608	0.738856	0.636372	321
weighted avg	0.956923	0.919003	0.934982	321

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.736328	0.848144	512
1	0.068966	1.000000	0.129032	10
accuracy			0.741379	522
macro avg	0.534483	0.868164	0.488588	522
weighted avg	0.982164	0.741379	0.834368	522

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.974026	0.862069	0.914634	87
1	0.250000	0.666667	0.363636	6
accuracy			0.849462	93
macro avg	0.612013	0.764368	0.639135	93
weighted avg	0.927315	0.849462	0.879086	93

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.995122	0.980769	0.987893	208
1	0.000000	0.000000	0.000000	1
accuracy			0.976077	209
macro avg	0.497561	0.490385	0.493947	209
weighted avg	0.990361	0.976077	0.983167	209

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.650794	0.788462	63
1	0.000000	0.000000	0.000000	0
accuracy			0.650794	63
macro avg	0.500000	0.325397	0.394231	63
weighted avg	1.000000	0.650794	0.788462	63

Usuário: 2302454b-73f8-4ae1-85b3-4a75d383cf7c, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	105
1	0.009434	1.000000	0.018692	1
accuracy			0.009434	106
macro avg	0.004717	0.500000	0.009346	106
weighted avg	0.000089	0.009434	0.000176	106

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.972222	0.357143	0.522388	196
1	0.080292	0.846154	0.146667	13
accuracy			0.387560	209
macro avg	0.526257	0.601648	0.334527	209
weighted avg	0.916743	0.387560	0.499018	209

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.010870	0.021505	92
1	0.010870	1.000000	0.021505	1
accuracy			0.021505	93
macro avg	0.505435	0.505435	0.021505	93
weighted avg	0.989364	0.021505	0.021505	93

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.017476	0.034351	515
1	0.013645	1.000000	0.026923	7
accuracy			0.030651	522
macro avg	0.506823	0.508738	0.030637	522
weighted avg	0.986773	0.030651	0.034252	522

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.961165	0.316294	0.475962	313
1	0.018349	0.500000	0.035398	8
accuracy			0.320872	321
macro avg	0.489757	0.408147	0.255680	321
weighted avg	0.937668	0.320872	0.464982	321

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.928571	0.191176	0.317073	68
1	0.051724	0.750000	0.096774	4
accuracy			0.222222	72
macro avg	0.490148	0.470588	0.206924	72
weighted avg	0.879858	0.222222	0.304834	72

Usuário: d9b89773-5133-44a4-adb0-01a33f78286b, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.975309	0.766990	0.858696	103
1	0.040000	0.333333	0.071429	3
accuracy			0.754717	106
macro avg	0.507654	0.550162	0.465062	106
weighted avg	0.948838	0.754717	0.836415	106

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.962733	0.310621	0.469697	499
1	0.047091	0.739130	0.088542	23
accuracy			0.329502	522
macro avg	0.504912	0.524876	0.279119	522
weighted avg	0.922389	0.329502	0.452903	522

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.996124	0.805643	0.890815	319
1	0.015873	0.500000	0.030769	2
accuracy			0.803738	321
macro avg	0.505999	0.652821	0.460792	321
weighted avg	0.990017	0.803738	0.885456	321

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	102
1	0.037736	1.000000	0.072727	4
accuracy			0.037736	106
macro avg	0.018868	0.500000	0.036364	106
weighted avg	0.001424	0.037736	0.002744	106

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.082927	0.153153	205
1	0.020833	1.000000	0.040816	4
accuracy			0.100478	209
macro avg	0.510417	0.541463	0.096985	209
weighted avg	0.981260	0.100478	0.151003	209

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	89
1	0.043011	1.000000	0.082474	4
accuracy			0.043011	93
macro avg	0.021505	0.500000	0.041237	93
weighted avg	0.001850	0.043011	0.003547	93

Usuário: d0986e7d-ac6e-40e6-ad7a-176ded91f687, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.451613	0.622222	62
1	0.028571	1.000000	0.055556	1
accuracy			0.460317	63
macro avg	0.514286	0.725806	0.338889	63
weighted avg	0.984580	0.460317	0.613228	63

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.997468	0.774067	0.871681	509
1	0.094488	0.923077	0.171429	13
accuracy			0.777778	522
macro avg	0.545978	0.848572	0.521555	522
weighted avg	0.974980	0.777778	0.854242	522

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.949438	0.590909	0.728448	286
1	0.181818	0.742857	0.292135	35
accuracy			0.607477	321
macro avg	0.565628	0.666883	0.510292	321
weighted avg	0.865741	0.607477	0.680875	321

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.706522	0.828025	92
1	0.035714	1.000000	0.068966	1
accuracy			0.709677	93
macro avg	0.517857	0.853261	0.448495	93
weighted avg	0.989631	0.709677	0.819864	93

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	209
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	209
macro avg	0.000000	0.000000	0.000000	209
weighted avg	0.000000	0.000000	0.000000	209

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.066667	0.125000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.066667	30
macro avg	0.500000	0.033333	0.062500	30
weighted avg	1.000000	0.066667	0.125000	30

Usuário: 700e685a-16c5-4327-a515-4288f228442e, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	63
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	63
macro avg	0.000000	0.000000	0.000000	63
weighted avg	0.000000	0.000000	0.000000	63

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.995305	0.675159	0.804554	314
1	0.055556	0.857143	0.104348	7
accuracy			0.679128	321
macro avg	0.525430	0.766151	0.454451	321
weighted avg	0.974812	0.679128	0.789285	321

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	93
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	93
macro avg	0.000000	0.000000	0.000000	93
weighted avg	0.000000	0.000000	0.000000	93

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.994475	0.348162	0.515759	517
1	0.011730	0.800000	0.023121	5
accuracy			0.352490	522
macro avg	0.503103	0.574081	0.269440	522
weighted avg	0.985062	0.352490	0.511041	522

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.185714	0.313253	70
1	0.033898	1.000000	0.065574	2
accuracy			0.208333	72
macro avg	0.516949	0.592857	0.189413	72
weighted avg	0.973164	0.208333	0.306373	72

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	63
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	63
macro avg	0.000000	0.000000	0.000000	63
weighted avg	0.000000	0.000000	0.000000	63

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.004831	0.009615	207
1	0.009615	1.000000	0.019048	2
accuracy			0.014354	209
macro avg	0.504808	0.502415	0.014332	209
weighted avg	0.990523	0.014354	0.009706	209

Usuário: 026fc9b9-4849-40ca-9423-018dbb927c4c, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	104
1	0.018868	1.000000	0.037037	2
accuracy			0.018868	106
macro avg	0.009434	0.500000	0.018519	106
weighted avg	0.000356	0.018868	0.000699	106

Usuário: 0728273c-4580-4776-9870-3e9823148dca, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.976608	0.349372	0.514638	478
1	0.113960	0.909091	0.202532	44
accuracy			0.396552	522
macro avg	0.545284	0.629232	0.358585	522
weighted avg	0.903895	0.396552	0.488330	522

Usuário: 0728273c-4580-4776-9870-3e9823148dca, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.956522	0.550000	0.698413	80
1	0.234043	0.846154	0.366667	13
accuracy			0.591398	93
macro avg	0.595282	0.698077	0.532540	93
weighted avg	0.855530	0.591398	0.652040	93

Usuário: 0728273c-4580-4776-9870-3e9823148dca, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.994819	0.941176	0.967254	204
1	0.250000	0.800000	0.380952	5
accuracy			0.937799	209
macro avg	0.622409	0.870588	0.674103	209
weighted avg	0.977000	0.937799	0.953228	209

Usuário: 0728273c-4580-4776-9870-3e9823148dca, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.864780	0.927487	318
1	0.065217	1.000000	0.122449	3
accuracy			0.866044	321
macro avg	0.532609	0.932390	0.524968	321
weighted avg	0.991264	0.866044	0.919964	321

Usuário: 0728273c-4580-4776-9870-3e9823148dca, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	106
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	106
macro avg	0.000000	0.000000	0.000000	106
weighted avg	0.000000	0.000000	0.000000	106

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.583333	0.736842	72
1	0.000000	0.000000	0.000000	0
accuracy			0.583333	72
macro avg	0.500000	0.291667	0.368421	72
weighted avg	1.000000	0.583333	0.736842	72

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.995671	0.793103	0.882917	290
1	0.333333	0.967742	0.495868	31
accuracy			0.809969	321
macro avg	0.664502	0.880423	0.689393	321
weighted avg	0.931707	0.809969	0.845539	321

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.977778	0.500000	0.661654	88
1	0.083333	0.800000	0.150943	5
accuracy			0.516129	93
macro avg	0.530556	0.650000	0.406299	93
weighted avg	0.929689	0.516129	0.634197	93

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.995413	0.429703	0.600277	505
1	0.052632	0.941176	0.099688	17
accuracy			0.446360	522
macro avg	0.524022	0.685440	0.349983	522
weighted avg	0.964709	0.446360	0.583974	522

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.779904	0.876344	209
1	0.000000	0.000000	0.000000	0
accuracy			0.779904	209
macro avg	0.500000	0.389952	0.438172	209
weighted avg	1.000000	0.779904	0.876344	209

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: 48816897-50cb-471e-a5cc-e9f601b20bd5, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	62
1	0.015873	1.000000	0.031250	1
accuracy			0.015873	63
macro avg	0.007937	0.500000	0.015625	63
weighted avg	0.000252	0.015873	0.000496	63

Usuário: 3730a594-b771-4038-8024-0c5e9878edaa, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.995951	0.957198	0.976190	514
1	0.214286	0.750000	0.333333	8
accuracy			0.954023	522
macro avg	0.605119	0.853599	0.654762	522
weighted avg	0.983972	0.954023	0.966338	522

Usuário: 3730a594-b771-4038-8024-0c5e9878edaa, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.979592	0.888889	0.932039	54
1	0.571429	0.888889	0.695652	9
accuracy			0.888889	63
macro avg	0.775510	0.888889	0.813846	63
weighted avg	0.921283	0.888889	0.898269	63

Usuário: 3730a594-b771-4038-8024-0c5e9878edaa, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.905660	0.950495	318
1	0.090909	1.000000	0.166667	3
accuracy			0.906542	321
macro avg	0.545455	0.952830	0.558581	321
weighted avg	0.991504	0.906542	0.943170	321

Usuário: b22117a7-7607-4fc3-98e8-a6d1e76d94ac, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.500000	0.015385	0.029851	65
1	0.085714	0.857143	0.155844	7
accuracy			0.097222	72
macro avg	0.292857	0.436264	0.092847	72
weighted avg	0.459722	0.097222	0.042100	72

Usuário: b22117a7-7607-4fc3-98e8-a6d1e76d94ac, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.997647	0.823301	0.902128	515
1	0.061856	0.857143	0.115385	7
accuracy			0.823755	522
macro avg	0.529751	0.840222	0.508756	522
weighted avg	0.985098	0.823755	0.891577	522

Usuário: b22117a7-7607-4fc3-98e8-a6d1e76d94ac, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.991803	0.593137	0.742331	204
1	0.045977	0.800000	0.086957	5
accuracy			0.598086	209
macro avg	0.518890	0.696569	0.414644	209
weighted avg	0.969176	0.598086	0.726652	209

Usuário: b22117a7-7607-4fc3-98e8-a6d1e76d94ac, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.227273	0.370370	88
1	0.068493	1.000000	0.128205	5
accuracy			0.268817	93
macro avg	0.534247	0.613636	0.249288	93
weighted avg	0.949919	0.268817	0.357351	93

Usuário: b22117a7-7607-4fc3-98e8-a6d1e76d94ac, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.295597	0.456311	318
1	0.013216	1.000000	0.026087	3
accuracy			0.302181	321
macro avg	0.506608	0.647799	0.241199	321
weighted avg	0.990778	0.302181	0.452290	321

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.422680	0.594203	97
1	0.138462	1.000000	0.243243	9
accuracy			0.471698	106
macro avg	0.569231	0.711340	0.418723	106
weighted avg	0.926851	0.471698	0.564404	106

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.980519	0.483974	0.648069	312
1	0.035928	0.666667	0.068182	9
accuracy			0.489097	321
macro avg	0.508224	0.575321	0.358125	321
weighted avg	0.954036	0.489097	0.631810	321

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.984848	0.256410	0.406886	507
1	0.033333	0.866667	0.064198	15
accuracy			0.273946	522
macro avg	0.509091	0.561538	0.235542	522
weighted avg	0.957506	0.273946	0.397038	522

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	209
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	209
macro avg	0.000000	0.000000	0.000000	209
weighted avg	0.000000	0.000000	0.000000	209

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	29
1	0.033333	1.000000	0.064516	1
accuracy			0.033333	30
macro avg	0.016667	0.500000	0.032258	30
weighted avg	0.001111	0.033333	0.002151	30

Usuário: 38553b72-9a28-4853-ba60-39ebd1a14629, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.083333	0.153846	72
1	0.000000	0.000000	0.000000	0
accuracy			0.083333	72
macro avg	0.500000	0.041667	0.076923	72
weighted avg	1.000000	0.083333	0.153846	72

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.053763	0.102041	93
1	0.000000	0.000000	0.000000	0
accuracy			0.053763	93
macro avg	0.500000	0.026882	0.051020	93
weighted avg	1.000000	0.053763	0.102041	93

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.974359	0.073359	0.136445	518
1	0.006211	0.750000	0.012320	4
accuracy			0.078544	522
macro avg	0.490285	0.411680	0.074383	522
weighted avg	0.966940	0.078544	0.135494	522

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.465190	0.634989	316
1	0.028736	1.000000	0.055866	5
accuracy			0.473520	321
macro avg	0.514368	0.732595	0.345428	321
weighted avg	0.984871	0.473520	0.625969	321

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.339623	0.507042	106
1	0.000000	0.000000	0.000000	0
accuracy			0.339623	106
macro avg	0.500000	0.169811	0.253521	106
weighted avg	1.000000	0.339623	0.507042	106

Usuário: 34655fd6-5d3e-44c8-a143-a95e578d33a1, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	61
1	0.031746	1.000000	0.061538	2
accuracy			0.031746	63
macro avg	0.015873	0.500000	0.030769	63
weighted avg	0.001008	0.031746	0.001954	63

Usuário: 6f356100-2449-40db-abbb-0413cedebe82, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.929412	0.963415	0.946108	82
1	0.857143	0.750000	0.800000	24
accuracy			0.915094	106
macro avg	0.893277	0.856707	0.873054	106
weighted avg	0.913049	0.915094	0.913027	106

Usuário: 6f356100-2449-40db-abbb-0413cedebe82, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.923077	0.960000	182
1	0.658537	1.000000	0.794118	27
accuracy			0.933014	209
macro avg	0.829268	0.961538	0.877059	209
weighted avg	0.955888	0.933014	0.938570	209

Usuário: 6f356100-2449-40db-abbb-0413cedebe82, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.262500	0.415842	320
1	0.004219	1.000000	0.008403	1
accuracy			0.264798	321
macro avg	0.502110	0.631250	0.212122	321
weighted avg	0.996898	0.264798	0.414572	321

Usuário: 6f356100-2449-40db-abbb-0413cedebe82, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.950000	0.311475	0.469136	61
1	0.023256	0.500000	0.044444	2
accuracy			0.317460	63
macro avg	0.486628	0.405738	0.256790	63
weighted avg	0.920580	0.317460	0.455654	63

Usuário: 6f356100-2449-40db-abbb-0413cedebe82, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.342857	0.510638	70
1	0.041667	1.000000	0.080000	2
accuracy			0.361111	72
macro avg	0.520833	0.671429	0.295319	72
weighted avg	0.973380	0.361111	0.498676	72

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: 01

	precision	recall	f1-score	support
0	1.000000	0.166667	0.285714	30
1	0.000000	0.000000	0.000000	0
accuracy			0.166667	30
macro avg	0.500000	0.083333	0.142857	30
weighted avg	1.000000	0.166667	0.285714	30

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.077220	0.143369	518
1	0.008299	1.000000	0.016461	4
accuracy			0.084291	522
macro avg	0.504149	0.538610	0.079915	522
weighted avg	0.992401	0.084291	0.142397	522

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.197492	0.329843	319
1	0.007752	1.000000	0.015385	2
accuracy			0.202492	321
macro avg	0.503876	0.598746	0.172614	321
weighted avg	0.993818	0.202492	0.327884	321

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	0.983607	0.845070	0.909091	71
1	0.000000	0.000000	0.000000	1
accuracy			0.833333	72
macro avg	0.491803	0.422535	0.454545	72
weighted avg	0.969945	0.833333	0.896465	72

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	63
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	63
macro avg	0.000000	0.000000	0.000000	63
weighted avg	0.000000	0.000000	0.000000	63

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.104762	0.189655	105
1	0.010526	1.000000	0.020833	1
accuracy			0.113208	106
macro avg	0.505263	0.552381	0.105244	106
weighted avg	0.990665	0.113208	0.188063	106

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	205
1	0.019139	1.000000	0.037559	4
accuracy			0.019139	209
macro avg	0.009569	0.500000	0.018779	209
weighted avg	0.000366	0.019139	0.000719	209

Usuário: 48a92d8e-dc8c-4d2f-bf70-aaf1c7df357c, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	93
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	93
macro avg	0.000000	0.000000	0.000000	93
weighted avg	0.000000	0.000000	0.000000	93

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	0.996835	0.990566	0.993691	318
1	0.400000	0.666667	0.500000	3
accuracy			0.987539	321
macro avg	0.698418	0.828616	0.746845	321
weighted avg	0.991258	0.987539	0.989077	321

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.997849	0.916996	0.955716	506
1	0.263158	0.937500	0.410959	16
accuracy			0.917625	522
macro avg	0.630504	0.927248	0.683337	522
weighted avg	0.975330	0.917625	0.939018	522

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.994819	0.960000	0.977099	200
1	0.500000	0.888889	0.640000	9
accuracy			0.956938	209
macro avg	0.747409	0.924444	0.808550	209
weighted avg	0.973511	0.956938	0.962583	209

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	0.975904	0.920455	0.947368	88
1	0.300000	0.600000	0.400000	5
accuracy			0.903226	93
macro avg	0.637952	0.760227	0.673684	93
weighted avg	0.939565	0.903226	0.917940	93

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: 0-1

	precision	recall	f1-score	support
0	1.000000	0.958333	0.978723	72
1	0.000000	0.000000	0.000000	0
accuracy			0.958333	72
macro avg	0.500000	0.479167	0.489362	72
weighted avg	1.000000	0.958333	0.978723	72

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: -10

	precision	recall	f1-score	support
0	1.000000	0.063492	0.119403	63
1	0.000000	0.000000	0.000000	0
accuracy			0.063492	63
macro avg	0.500000	0.031746	0.059701	63
weighted avg	1.000000	0.063492	0.119403	63

Usuário: a0c1911f-3b66-4a49-8b90-f2c0cd21d79d, Tipo de Gesto: -11

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	106
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	106
macro avg	0.000000	0.000000	0.000000	106
weighted avg	0.000000	0.000000	0.000000	106

Usuário: a2729b41-a4fc-4ba8-98d5-4b89ed70050b, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.989648	0.977505	0.983539	489
1	0.717949	0.848485	0.777778	33
accuracy			0.969349	522
macro avg	0.853798	0.912995	0.880658	522
weighted avg	0.972472	0.969349	0.970531	522

Usuário: a2729b41-a4fc-4ba8-98d5-4b89ed70050b, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.213166	0.351421	319
1	0.007905	1.000000	0.015686	2
accuracy			0.218069	321
macro avg	0.503953	0.606583	0.183554	321
weighted avg	0.993819	0.218069	0.349329	321

Usuário: a2729b41-a4fc-4ba8-98d5-4b89ed70050b, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	209
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	209
macro avg	0.000000	0.000000	0.000000	209
weighted avg	0.000000	0.000000	0.000000	209

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo de Gesto: 11

	precision	recall	f1-score	support
0	0.986928	0.298419	0.458270	506
1	0.037940	0.875000	0.072727	16
accuracy			0.316092	522
macro avg	0.512434	0.586709	0.265499	522
weighted avg	0.957840	0.316092	0.446453	522

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo de Gesto: 10

	precision	recall	f1-score	support
0	1.000000	0.613636	0.760563	88
1	0.128205	1.000000	0.227273	5
accuracy			0.634409	93
macro avg	0.564103	0.806818	0.493918	93
weighted avg	0.953129	0.634409	0.731892	93

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo de Gesto: -1-1

	precision	recall	f1-score	support
0	1.000000	0.056250	0.106509	320
1	0.003300	1.000000	0.006579	1
accuracy			0.059190	321
macro avg	0.501650	0.528125	0.056544	321
weighted avg	0.996895	0.059190	0.106198	321

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo de Gesto: 1-1

	precision	recall	f1-score	support
0	0.980392	0.247525	0.395257	202
1	0.037975	0.857143	0.072727	7
accuracy			0.267943	209
macro avg	0.509183	0.552334	0.233992	209
weighted avg	0.948828	0.267943	0.384454	209

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo
de Gesto: 01

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	30
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	30
macro avg	0.000000	0.000000	0.000000	30
weighted avg	0.000000	0.000000	0.000000	30

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo
de Gesto: -11

	precision	recall	f1-score	support
0	1.000000	0.009434	0.018692	106
1	0.000000	0.000000	0.000000	0
accuracy			0.009434	106
macro avg	0.500000	0.004717	0.009346	106
weighted avg	1.000000	0.009434	0.018692	106

Usuário: 812aa782-91b2-4915-8804-ecf70666a7cd, Tipo
de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: -1-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	318
1	0.009346	1.000000	0.018519	3
accuracy			0.009346	321
macro avg	0.004673	0.500000	0.009259	321
weighted avg	0.000087	0.009346	0.000173	321

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: 1-1

	precision	recall	f1-score	support
0	1.000000	0.004808	0.009569	208
1	0.004808	1.000000	0.009569	1
accuracy			0.009569	209
macro avg	0.502404	0.502404	0.009569	209
weighted avg	0.995238	0.009569	0.009569	209

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: 11

	precision	recall	f1-score	support
0	1.000000	0.802303	0.890309	521
1	0.009615	1.000000	0.019048	1
accuracy			0.802682	522
macro avg	0.504808	0.901152	0.454678	522
weighted avg	0.998103	0.802682	0.888640	522

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: 0-1

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	72
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	72
macro avg	0.000000	0.000000	0.000000	72
weighted avg	0.000000	0.000000	0.000000	72

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: -10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	63
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	63
macro avg	0.000000	0.000000	0.000000	63
weighted avg	0.000000	0.000000	0.000000	63

Usuário: 169474d7-82e2-4145-a19f-42bbcb3d5afe, Tipo
de Gesto: 10

	precision	recall	f1-score	support
0	0.000000	0.000000	0.000000	93
1	0.000000	0.000000	0.000000	0
accuracy			0.000000	93
macro avg	0.000000	0.000000	0.000000	93
weighted avg	0.000000	0.000000	0.000000	93

APÊNDICE B – CÓDIGO PYTHON PARA GERAR MÉTRICAS PARA A ANÁLISE DE RESULTADO

O código a seguir, escrito em Python, foi usado para coletar as métricas baseado nos gestos coletados dos usuários.

```
1 def calcular_metricas_da_matriz_de_confusao(matriz_confusao
2 ):
3
4     TN, FP, FN, TP = matriz_confusao.ravel()
5
6     precision_0 = TN / (TN + FN) if (TN + FN) > 0 else 0.0
7     recall_0 = TN / (TN + FP) if (TN + FP) > 0 else 0.0
8     f1_0 = 2 * (precision_0 * recall_0) / (precision_0 +
9         recall_0) if (precision_0 + recall_0) > 0 else 0.0
10    support_0 = TN + FP
11
12    precision_1 = TP / (TP + FP) if (TP + FP) > 0 else 0.0
13    recall_1 = TP / (TP + FN) if (TP + FN) > 0 else 0.0
14    f1_1 = 2 * (precision_1 * recall_1) / (precision_1 +
15        recall_1) if (precision_1 + recall_1) > 0 else 0.0
16    support_1 = TP + FN
17
18    accuracy = (TP + TN) / (TP + TN + FP + FN)
19
20    relatorio = {
21        '0': {
22            'precision': precision_0,
23            'recall': recall_0,
24            'f1-score': f1_0,
25            'support': support_0
26        },
27        '1': {
28            'precision': precision_1,
```

```
25         'recall': recall_1,
26         'f1-score': f1_1,
27         'support': support_1
28     },
29     'accuracy': accuracy,
30     'macro avg': {
31         'precision': np.mean([precision_0, precision_1
32             ]),
33         'recall': np.mean([recall_0, recall_1]),
34         'f1-score': np.mean([f1_0, f1_1]),
35         'support': support_0 + support_1
36     },
37     'weighted avg': {
38         'precision': (precision_0 * support_0 +
39             precision_1 * support_1) / (support_0 +
40             support_1),
41         'recall': (recall_0 * support_0 + recall_1 *
42             support_1) / (support_0 + support_1),
43         'f1-score': (f1_0 * support_0 + f1_1 *
44             support_1) / (support_0 + support_1),
45         'support': support_0 + support_1
46     }
47 }

48 return relatorio

49 relatorio = calcular_metricas_da_matriz_de_confusao(
50     matriz_confusao_total)
```

APÊNDICE C – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)

Você está sendo convidado(a) como voluntário(a) a participar da pesquisa: “USO DE DYNAMIC TIME WARPING NA VALIDAÇÃO DE IDENTIDADE DE USUÁRIOS DE SMARTPHONES”, que tem como objetivo avaliar o uso de Dynamic Time Warping para validação de identidade. Você não deve participar contra a sua vontade. Leia atentamente as informações abaixo e faça qualquer pergunta que desejar, para que todos os procedimentos desta pesquisa sejam esclarecidos.

Participação no estudo – A sua participação no estudo será voluntária e consiste em utilizar o aplicativo "Flashcards" de maneira individual, em um dispositivo móvel, preferencialmente um smartphone, com o objetivo de atingir a pontuação de 100 cartas. Todo o processo de uso deve durar em torno de 15 minutos. Os gestos capturados pela tela do dispositivo móvel serão armazenados.

Riscos e benefícios – A pesquisa não apresenta riscos substanciais para os participantes. Ainda assim, estes podem apresentar fadiga ou desinteresse ao utilizar o aplicativo. Por isso, o participante pode interromper o uso a qualquer momento, mesmo antes de atingir a pontuação sugerida. Como benefícios, o participante terá a possibilidade de aprender e revisar vocabulário em inglês, além do mais estará contribuindo com a área de segurança da informação já que seus dados serão utilizados para responder perguntas da área.

Sigilo e privacidade – A sua privacidade é prioridade e será respeitada. Durante o uso do aplicativo nenhum dado que possa identificar o usuário será coletado. Além disso, os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados.

Autonomia – Você pode se recusar a participar do estudo ou retirar seu consentimento a qualquer momento, sem precisar justificar. Não haverá qualquer penalidade ou perda de benefícios ao retirar-se da pesquisa. Para retirar o seu consentimento, basta solicitar durante o convite de participação da entrevista ou pelo email ou telefone informados ao final deste documento.

Remuneração – Não haverá despesas pessoais em qualquer fase da pesquisa, nem compensação financeira relacionada à sua participação.

Declaração de responsabilidade – Os pesquisadores responsáveis, Matheus Vinícius Fernandes Barros, graduando da Universidade Federal do Ceará, campus de Quixadá, declara cumprir as exigências da RESOLUÇÃO Nº 466, DE 12 DE DEZEMBRO DE 2012, e suas

complementares, do Conselho Nacional de Saúde, que trata dos cuidados éticos de pesquisas científicas envolvendo pessoas.

Contato – Em caso de dúvidas, solicitações ou notificação de acontecimentos não previstos, você poderá contatar o pesquisador responsáveis, pelo e-mail matheusvinciusf@alu.ufc.br.