

**UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA
CAMPUS VITÓRIA DA CONQUISTA
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

ALEKSANDER SANTOS SOUSA

**RECONHECIMENTO FACIAL PARA CONTROLE E ACESSO A AMBIENTES
COMPARTILHADOS COM BASE EM REDES NEURAIS SEM PESOS**

**VITÓRIA DA CONQUISTA
DEZEMBRO / 2022**

ALEKSANDER SANTOS SOUSA

**RECONHECIMENTO FACIAL PARA CONTROLE E ACESSO A AMBIENTES
COMPARTILHADOS COM BASE EM REDES NEURAIS SEM PESOS**

Trabalho de Conclusão de Curso apresentado ao Curso de Ciência da Computação da Universidade Estadual do Sudoeste da Bahia (UESB), como requisito para aprovação na Disciplina Trabalho Supervisionado II e requisito parcial para a obtenção do título de Cientista da Computação.

Orientando: Aleksander Santos Sousa

Orientador: Prof. Dr. José Carlos Martins Oliveira

VITÓRIA DA CONQUISTA

DEZEMBRO / 2022

ALEKSANDER SANTOS SOUSA

**RECONHECIMENTO FACIAL PARA CONTROLE E ACESSO A AMBIENTES
COMPARTILHADOS COM BASE EM REDES NEURAIIS SEM PESOS**

Trabalho de Conclusão de Curso apresentado ao Curso de Ciência da Computação da Universidade Estadual do Sudoeste da Bahia (UESB), como requisito para aprovação na Disciplina Trabalho Supervisionado II e requisito parcial para obtenção do título de Cientista da Computação.

Este trabalho foi defendido e aprovado pela banca em 30/03/2023.

BANCA EXAMINADORA

Prof. Dr. José Carlos Martins Oliveira – UESB
Orientador

Prof. Dr. Geraldo Pereira Rocha Filho – UESB
Avaliador

Prof. Dr. Hélio Santos Lopes – UESB
Avaliador

Dedico este trabalho aos meus pais, que
não pouparam esforços para que eu
pudesse concluir meus estudos.

AGRADECIMENTOS

Agradeço aos meus pais, por todo o zelo e dedicação que sempre despenderam comigo. Aos meus amigos que me acompanharam durante esta jornada, e à minha então namorada por todo apoio oferecido.

RESUMO

Com a necessidade de controlar o fluxo de pessoas a determinados ambientes, discute-se a necessidade do controle e do acesso de pessoas a ambientes compartilhados, a exemplo: condomínios, teatros, cinemas, eventos privativos, dentre outros. Para isso, as redes neurais artificiais são uma vertente do aprendizado de máquina (machine learning) inspirada no comportamento do cérebro humano e muito utilizadas na solução de problemas na área da inteligência artificial. Nas referências das redes neurais, existem duas abordagens básicas: as redes neurais com pesos e a sem pesos. As redes neurais sem pesos são uma alternativa que utiliza um modelo de neurônios baseado na memória de acesso aleatório. O presente trabalho consiste na apresentação de um modelo neural sem pesos capaz de realizar o reconhecimento facial a partir de imagens do rosto propondo uma arquitetura de rede que melhor se encaixe para o problema proposto, dentro das configurações que foram estudadas. Foram separados quatro conjuntos de imagens para treinamento e testes da rede e foi proposto um modelo que melhor se adequou para a resolução do caso estudado. Obteve-se um percentual de 78,05% de assertividade na primeira tentativa de reconhecimento.

Palavras-chave: ambientes compartilhados; redes neurais artificiais; redes neurais artificiais sem pesos; reconhecimento facial.

ABSTRACT

With the need to control the flow of people to certain environments, the need to control and access people to shared environments, for example: condominiums, theaters, cinemas, private events, among others, is discussed. For this, artificial neural networks are a branch of machine learning inspired by the behavior of the human brain and widely used in solving problems in the area of artificial intelligence. In the neural network references, there are two basic approaches: weighted and unweighted neural networks. Unweighted neural networks are an alternative that uses a model of neurons based on random access memory. The present work consists of presenting a neural model without weights capable of performing facial recognition from face images, proposing a network architecture that best fits the standard problem, within the configurations that were tried. Four sets of images were separated for training and testing the network and a model that best suited to the resolution of the case studied was proposed. A percentage of 78.05% of assertiveness was obtained in the first recognition attempt.

Keywords: shared environments; artificial neural networks; artificial neural networks without weights; facial recognition.

LISTA DE ILUSTRAÇÕES

Figura 1: Modelo de neurônio de McCulloch-Pitts	22
Figura 2: Modelo da rede RAM básica	23
Figura 3: Modelo de Nó RAM	24
Figura 4: Representação esquemática de um discriminador	25
Figura 5: Representação esquemática da rede WiSARD	25
Figura 6: Grau de confiança de um discriminador com <i>bleaching</i> percentual	28
Figura 7: Representação esquemática do sistema.	30
Figura 8: Imagens extraídas da base de dados utilizada antes da binarização.	32
Figura 9: Imagem com sub-janelas de 4X4 pixels.	32

LISTA DE TABELAS

Tabela 1 – Número de neurônios por conjuntos de teste.	34
Tabela 2 – Porcentagem de acertos por tipo de rede na primeira tentativa.	36
Tabela 3 – Resultados obtidos com a rede WP para o conjunto FACE_A_AP	44
Tabela 4 – Resultados obtidos com a rede WP para o conjunto FACE_B_AP	45
Tabela 5 – Resultados obtidos com a rede WP para o conjunto FACE_A_SP	47
Tabela 6 – Resultados obtidos com a rede WP para o conjunto FACE_B_SP	48
Tabela 7 – Resultados obtidos com a rede WBS para o conjunto FACE_A_AP	50
Tabela 8 – Resultados obtidos com a rede WBS para o conjunto FACE_B_AP	52
Tabela 9 – Resultados obtidos com a rede WBS para o conjunto FACE_A_SP	53
Tabela 10 – Resultados obtidos com a rede WBS para o conjunto FACE_B_SP	55
Tabela 11 – Resultados obtidos com a rede WBP para o conjunto FACE_A_AP	57
Tabela 12 – Resultados obtidos com a rede WBP para o conjunto FACE_B_AP	58
Tabela 13 – Resultados obtidos com a rede WBP para o conjunto FACE_A_SP	60
Tabela 14 – Resultados obtidos com a rede WBP para o conjunto FACE_B_SP	61

LISTA DE ABREVIATURAS E SIGLAS

WiSARD	Wilkie, Stonham and Aleksander's Recognition Device
WP	WiSARD padrão
WBS	WiSARD com <i>bleaching</i> simples
WBP	WiSARD com <i>bleaching</i> percentual
FACE_A_AP	Face com todos os pixels e limiar adaptativo
FACE_B_AP	Face com todos os pixels e limiar padrão
FACE_A_SP	Face com redução de pixels e limiar adaptativo
FACE_B_SP	Face com redução de pixels e limiar padrão
RAM	Memória de Acesso Aleatório (<i>Random Access Memory</i>)

SUMÁRIO

1 Introdução.....	11
1.1 Contextualização do Problema.....	12
1.2 Trabalhos Relacionados	14
1.3 Objetivos	15
1.3.1 Objetivo Geral	15
1.3.2 Objetivos Específicos	15
1.4 Metodologia para o Desenvolvimento do Trabalho	16
1.5 Organização do Trabalho	17
2 Fundamentação Teórica	18
2.1 Sistema para Controle de Acesso a Ambientes Compartilhados	18
2.2 Redes Neurais Artificiais	19
2.2.1 Redes Neurais com Pesos	20
2.2.2 Redes Neurais Sem Peso	21
2.2.3 Rede WiSARD.....	23
2.2.3.1 Treinamento da Rede WiSARD.....	24
2.2.3.2 Teste da Rede WiSARD.....	25
2.2.3.3 Capacidade Computacional da Rede WiSARD.....	26
2.2.3.4 Técnicas de Refinamento.....	26
3 Sistema de Reconhecimento Facial Proposto com base nas Redes Neurais Sem Peso	29
3.1 Pré-processamento das Imagens.....	30
3.1.1 Separação dos Conjuntos de Imagens.....	30
3.1.2 Codificação das Imagens	30
3.2 Modelo Neural Utilizado	32
4 Apresentação e Análise dos Experimentos Realizados e dos Resultados Obtidos.....	34
4.1 Descrição dos Experimentos.....	34
4.2 Análise dos Resultados	35

4.3 Arquitetura Final Proposta.....	36
4.4 Limitações da Arquitetura Final Proposta.....	36
5 Considerações Finais	38
5.1 Trabalhos Futuros	39
Referências	40
APÊNDICE A – Resultados dos testes	43

1 INTRODUÇÃO

Com o crescente avanço e difusão das tecnologias, seus usos em diferentes aplicações tornam-se imprescindíveis na vida das pessoas e nos processos de tratamento e análise de dados, em especial nos processos de supervisão e controle (ALVES, 2020). Com isso, o uso de sistemas computacionais cada vez mais complexos e baseados nos princípios da inteligência artificial tem se mostrado recorrentes em todos os setores econômicos e produtivos – com aplicações por meios de computadores de mesa, notebooks ou celulares (ALVES, 2020).

Neste contexto, o volume de dados em tramitação pela internet e suas funcionalidades com as tecnologias atuais é gigantesco e crescente em muitas aplicações. Com o exposto, a análise manual de dados torna-se ineficiente, permitindo aos sistemas ditos “inteligentes” tornarem-se promissores na resolução desses problemas (CAVALCANTI, 2022). Planejados e desenvolvidos por estudiosos da área de inteligência artificial, com capacidade de aprendizado e versatilidade suficientes para resolver problemas complexos, essas tecnologias conseguem processar grandes volumes de dados, tratá-los e gerar informações úteis às atividades econômicas e aos seres humanos (CAVALCANTI, 2022). Assim, os sistemas computacionais considerados inteligentes têm importância significativa na vida das pessoas e vão desde as análises de dados simples a questões complexas, a exemplo para aplicações onde a segurança é um fator de grande relevância (REVOREDO, 2021).

Nesta temática, discute-se a necessidade do controle e do acesso de pessoas a ambientes compartilhados com limitações de acesso, a exemplo: condomínios, teatros, cinemas, eventos privativos, dentre outros (CAROLINE, 2022). Neste conjunto de circunstâncias, os sistemas inteligentes desempenham um papel importante de forma otimizada, que anteriormente era feito manualmente (CAVALCANTI, 2022). Como parte destes sistemas, encontram-se as Redes Neurais Artificiais (RNA) que desempenham um papel de destaque dentre os sistemas considerados inteligentes. Neste contexto, este trabalho visa abordar o uso de RNA no controle e acesso de pessoas a ambientes compartilhados, como o reconhecimento facial como forma de identificação e autenticação, focando-se nas Redes Neurais Sem Pesos (RNSP).

As RNSP constituem-se numa abordagem diferente das redes neurais convencionais, mais conhecidas como redes neurais com pesos. Essas RNSP utilizam memórias RAM (*Random Access Memories*, memórias de acesso randômico) para implementação e funcionamento. Foram propostas, inicialmente, por Aleksander (1967), tendo seu funcionamento ditado por “memórias” dentro dos neurônios, em forma de tabelas verdade. O uso deste tipo de abordagem traz algumas vantagens em relação ao modelo com pesos, como: semelhança com os sistemas digitais convencionais (OLIVEIRA, 2018, p.11); algoritmos de aprendizagem rápidos e flexíveis (OLIVEIRA, 2018, p.11); precisão e consistência nos resultados, sem a necessidade de geração de resíduos e retreinamento das redes; capacidade natural de generalização (OLIVEIRA, 2018, p.11, apud CLARKSON et. al., 1992); habilidades de aproximadores universais de funções contínuas (OLIVEIRA, 2018, p.11, apud Gorse et al., 1997); e principalmente o grande potencial das RNSP para o reconhecimento e a classificação de padrões (OLIVEIRA, 2018, p.11, apud LUDERMIR et al., 1999).

1.1 CONTEXTUALIZAÇÃO DO PROBLEMA

Devido à natureza de determinados ambientes compartilhados, é necessário controlar o fluxo de pessoas, permitindo ou não o acesso das mesmas. Isso se deve ao fato de que tais locais são privados de alguma maneira, podendo apenas frequentar ou adentrá-los apenas com pessoas com autorização. Assim, o escopo deste trabalho trata da parte da segurança a ambientes ou lugares que podem ser compartilhados por pessoas, mas que requer uma segurança necessária para o controle e o acesso a esses ambientes.

Segundo Marcondes (2020), sistemas de controle de acesso são, na maioria, sistemas computacionais utilizados em ambientes específicos, onde o acesso e, em alguns casos, até mesmo o fluxo de pessoas, precisa ser controlado. Com a pessoa tendo seu acesso autenticado e autorizado pelo sistema, ela consegue acessar determinados espaços na sua totalidade ou parcialidade. Existem inúmeros exemplos de ambientes restritos que podem ou não serem compartilhados, tais como:

condomínios, teatros, cinemas, eventos restritos, ou até mesmo laboratórios ou um espaço com arquivos confidenciais.

Neste contexto, esses sistemas têm como objetivo principal a segurança de pessoas que convivem ou acessam ambientes compartilhados. De acordo com Marcondes (2020) A principal função do sistema de controle de acesso é assegurar que todas as pessoas, objetos e informações estejam em um ambiente tranquilo, controlado e seguro.

Como o objetivo principal é a segurança, de acordo com a Segware (2022), alguns modelos desses sistemas podem conter algumas falhas, como: controle por senha, onde a senha é impessoal e pode ser facilmente repassada a terceiros sem autorização; ou a biometria, onde o sistema pode apresentar falhas comuns, ou até pode sofrer fraudes. Os dados podem ser hackeados ou alterados digitalmente. Com essas possíveis falhas, este trabalho propõe desenvolver um sistema de reconhecimento facial utilizando-se de redes neurais artificiais sem pesos como um módulo para um sistema de controle e acessos a esses tipos de ambientes e/ou lugares.

Com a implementação do sistema proposto, visa-se um aumento na segurança de ambientes fechados ou de acesso privado, servindo assim até como auxiliador para possíveis investigações futuras de natureza criminal. Também, se espera uma maior facilidade na identificação de pessoas em um curto intervalo de tempo, dado a natureza da construção do modelo de Rede Neural que será proposto nos capítulos subsequentes. Um sistema deste porte poderá servir para diversas finalidades, tais como: controle de acesso a presídios; compras de ingressos de show; onde uma ideia de aplicação seria cadastrar as informações necessárias para autenticação no ato de compra, e no local fazer a validação via sistema, evitando assim impressão desnecessária de ingressos físicos.

Além do que já foi discutido, há o cenário de pandemia do coronavírus (COVID 19), embora mais estável atualmente, ainda exerce risco à saúde das pessoas. O

número de mortos já ultrapassa seiscentos e oitenta mil pessoas no Brasil (CORONAVÍRUS BRASIL, 2022). Visando, também, diminuir a disseminação do vírus na sociedade, este tipo de sistema cumpre seu papel com excelência, pois apenas com uma câmera é possível manter o controle de acesso de forma segura e objetiva, sem o toque a uma mesma superfície para o reconhecimento de digitais, punho ou palma da mão.

Outro ponto a ser considerado é o de que esta aplicação consegue realizar essa validação e verificação apenas com um cadastro prévio das informações necessárias para tal, algo que pode ser realizado, a depender da implementação utilizada, no conforto de casa ou de qualquer lugar através do aparelho celular, por exemplo. Conforme a CNN Brasil (2022), o Brasil tem mais de um smartphone por habitante.

Dado a natureza descritiva deste trabalho, este sistema ainda pode ajudar o engajamento de pesquisas teóricas a respeito das redes neurais sem peso e suas aplicações em diferentes âmbitos, pois além do sistema proposto, o mesmo será feito levando-se em conta qual a melhor abordagem destas redes neurais a ser utilizada, algo de natureza inovadora na literatura sobre o uso das redes neurais artificiais, diante da escassez de trabalhos com estas finalidades.

1.2 TRABALHOS RELACIONADOS

Dentro do reconhecimento de imagens e de padrões existem inúmeros trabalhos relacionados, visto que este é um problema clássico das RNSP (MACHADO, 2017, p.44).

Em Araújo (2011), é apresentado um sistema baseado na rede WiSARD, denominado RWiSARD, para propor uma solução de reconhecimento facial para redes neurais sem peso com imagens em escalas de cinza com um padrão de entrada real e não apenas binário. Na arquitetura da rede RWiSARD, o nó RAM contém um valor escalar para cada endereço, e o tamanho ocupado por esse valor pode variar

de acordo com a implementação, afetando a precisão das operações da rede em troca da eficiência da memória.

Em Machado (2017), é apresentada uma análise entre as redes neurais sem pesos e as redes neurais artificiais convencionais utilizando-se do reconhecimento facial e de padrões para testes e experimentos, apresentando técnicas de pré-processamento de imagens e adição de ruído nos conjuntos de treinamento as arquiteturas de redes sem pesos do tipo MPLN também estudadas no trabalho.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Propor um sistema de reconhecimento facial com base em redes neurais artificiais sem pesos para controle e acesso a ambientes compartilhados.

1.3.2 Objetivos Específicos

- ✓ revisar os sistemas de supervisão e controle na literatura;
- ✓ revisar os modelos computacionais com foco nas redes neurais sem peso;
- ✓ propor um sistema de reconhecimento facial para controle e acesso a ambientes compartilhados;
- ✓ estruturar as bases de dados usadas nos treinamentos e testes do sistema proposto;
- ✓ implementar em linguagem de programação o sistema proposto, considerando o pré-processamento das imagens e o processamento dessas imagens pré-processadas nos modelos neurais sem pesos usados;
- ✓ avaliar de forma comparativa e reflexiva os resultados obtidos com os treinamentos e testes executados com os modelos sem pesos e as bases de dados utilizadas;
- ✓ propor uma arquitetura final do sistema que melhor se adequa para a aplicação apresentada no objetivo geral deste trabalho.

1.4 METODOLOGIA PARA O DESENVOLVIMENTO DO TRABALHO

A pesquisa desenvolvida seguiu um caráter bibliográfico e experimental, pois buscou o levantamento e análise crítica dos documentos publicados sobre o tema pesquisado com intuito de atualizar, desenvolver o conhecimento e contribuir com a realização da pesquisa. (SOUSA, 2021; OLIVEIRA, 2021; ALVES, 2021, p.67, apud BOCCATO, 2006). Além disso, visou a verificação de hipóteses com as implementações e experimentos realizados, e apresentação e análise dos resultados obtidos. (BARROS, 2014; BRIDGET, 2015; CATHY, 2015).

Para treinar a rede neural do sistema proposto, desenvolvido com redes neurais sem peso, foi necessário conseguir uma base de dados para treinamento e teste. Diferente das redes neurais com pesos, há escassez de ferramentas para treinamento e testes das bases de dados, por isso foi necessário propor e implementar um sistema autoral para o reconhecimento dos padrões representativos das faces usadas para composição das bases de dados. As bases de dados foram constituídas por imagens utilizadas da literatura relacionada a reconhecimento facial (AT&T, 2001). As imagens utilizadas foram convertidas em padrões binários, adequados para o uso nos modelos neurais sem pesos, cujos neurônios são memórias RAM, descritos na seção 3. Foi utilizada a linguagem de programação Python para o tratamento das imagens foram utilizados dois métodos de binarização: um que aplica um limiar padrão e outro que aplica um limiar adaptativo, ambos descritos de forma mais detalhada na seção 3.

O sistema de rede neural desenvolvido seguiu modelos de engenharia de software. Com os resultados obtidos com os treinamentos e testes realizados, foram realizadas comparações dos modelos neurais sem pesos usados para, finalmente, propor o modelo que melhor se adequou para a aplicação investigada.

1.5 ORGANIZAÇÃO DO TRABALHO

Além deste capítulo introdutório, este Trabalho de Conclusão de Curso (TCC) contém mais quatro capítulos. Ao longo de todo o texto, as siglas em português são definidas ao final entre parênteses e as siglas em inglês são definidas ao final entre parênteses com sua tradução sendo separada por uma vírgula da representação em inglês. As palavras em inglês estão descritas em itálico. Os capítulos estão divididos como segue:

No capítulo 2 são apresentados os fundamentos teóricos utilizados neste TCC. Para isso, é apresentada uma revisão da literatura sobre os sistemas de supervisão, controle e acesso e também uma revisão sobre as redes neurais artificiais, com foco nas redes neurais sem peso, descrevendo suas características, funcionalidades e capacidade computacional.

O capítulo 3 descreve o sistema neural sem pesos em termos de estrutura e funcionalidades e apresenta também os aspectos de implementação. Além disso, são apresentadas a metodologia utilizada para o pré-processamento e codificação das imagens e os modelos e arquiteturas de redes neurais usados nos treinamentos e testes com as bases de dados definidas, após o pré-processamento das imagens.

O capítulo 4 apresenta uma análise do comportamento do modelo proposto, exibindo os resultados dos testes e uma discussão comparativa e reflexiva sobre os resultados obtidos.

No capítulo 5 são apresentadas as considerações finais do trabalho proposto e desenvolvido, com foco nos pontos positivos e negativos e apresenta também as proposições para a continuidade das pesquisas sobre o recolhimento facial com uso das redes neurais sem pesos.

2 FUNDAMENTAÇÃO TEÓRICA

Para uma boa convivência em ambientes compartilhados, é necessário medidas de controle do fluxo de pessoas que entram e saem desses ambientes. Para isso, é fundamental investir em mecanismos que garantam a segurança de pessoas e patrimônios em espaços individuais e coletivos. Dentre os diversos métodos de segurança observados na literatura, este trabalho focou num Sistema de Controle de Acesso (SCA), inicialmente estudado por Marie Van Brittan Brown em 1966, com uso de redes neurais na base de reconhecimento de padrões para o sistema proposto.

2.1 SISTEMA PARA CONTROLE DE ACESSO A AMBIENTES COMPARTILHADOS

De acordo com Marcondes (2020) o Sistema de Controle de Acesso é um conjunto ordenado de elementos (hardware, software e suporte humano) que se encontram interligados e que interagem entre si, com a função de gerenciar o acesso a espaços pré-determinados. Outra definição segundo Topdata: controle de acesso é uma solução que se aplica a regras de segurança para permitir ou bloquear a entrada de pessoas a locais restritos. O sistema consiste na identificação da pessoa, na verificação das regras definidas, e na autorização ou bloqueio do acesso.

O uso do SCA tem se tornado cada vez mais comum. Para garantir a segurança e integridade de pessoas e bens em residências, condomínios, academias, empresas, instituições de ensino, dentre outros locais onde se tem um fluxo elevado de pessoas com entradas controladas. De acordo com Coradini (2020), um sistema moderno deve contar com uma autenticação multifatorial robusta e que não interrompa o fluxo de trabalho nem a produtividade dos usuários, e, de acordo com a Ib Tecnologia, um sistema eficiente de controle deve ter a capacidade de identificar cada ponto por meio de equipamentos instalados em campo e combinar esse local físico à data e à hora para criar uma agenda de autorizações para cada usuário.

Esse tipo de sistema pode ser aberto ou fechado, o qual refere-se aqui aos bancos de dados, que podem ser abertos ou fechados, de forma que se define aberto como: transações, nomes e números de identificação públicos e fechado com este tipo de dado sendo privado. Um SCA não deve ser aberto, de modo a aumentar a probabilidade de problemas de segurança, mas também não deve ser totalmente

fechado, pois às vezes é necessário criar protocolos de acesso às informações, visto que isto serve para proteger a integridade dos dados.

Quando se cita este tipo de sistema, também é necessário falar sobre os fatores de autenticação, que, segundo Coradini (2020), são divididos em: O que sei: o conhecimento que a pessoa possui, a exemplo de um código PIN, uma senha ou um padrão; O que tenho: a identificação que um indivíduo possui para certificar que é ele, como uma credencial física ou virtual. O que sou: as características corporais únicas da pessoa que são utilizadas para verificar a identidade. Para aumentar o nível de segurança, os sistemas modernos implementam vários fatores de autenticação nos pontos de acesso, combinando ‘o que tenho’ com ‘o que sei’ e ‘o que sou’.

2.2 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são modelos do aprendizado de máquina (*machine learning*) inspiradas no comportamento do cérebro humano e usadas em aplicações nas mais diversas áreas do conhecimento para resolver problemas da área de inteligência artificial. Elas foram inspiradas nas ligações entre neurônios do cérebro, e na transmissão de sinais através das conexões neurais.

A estrutura básica de uma rede neural é: um nó, também chamado de nodo, neurônio ou neurônio artificial, que pode ou não estar interconectado a outros nós; uma camada de entrada, zero ou mais camadas intermediárias e uma camada de saída.

De maneira formal, Vasconcellos (2019) define uma rede neural como uma estrutura conexionista, na qual o processamento é distribuído por unidades densamente interligadas. Já Oliveira (2018) apud Hecht-Nielsen (1990) define uma RNA como uma estrutura com processamento de informação distribuída e paralela na forma de um grafo direcionado, com as seguintes sub definições e restrições: (a) os nodos do grafo são unidades de processamento denominadas de neurônios; (b) as arestas são denominadas de “conexões/sinapses”, com sinais numa única direção; (c) cada unidade de processamento pode receber qualquer número de conexões de entrada, e também possuir qualquer número de conexões de saída, desde que os sinais nas conexões de saída sejam os mesmos; (d) as unidades de processamento podem ter memória local; (e) cada unidade de processamento possui uma função de

transferência, a qual pode usar os valores armazenados na memória local e os sinais de entrada para produzir o sinal das saídas da unidade de processamento; e (f) os sinais de entrada para uma rede neural são conexões do ambiente externo ou de realimentação. As saídas da rede para o mundo externo são conexões que deixam a rede.

As RNA costumam operar em duas etapas, sendo elas: a etapa de aprendizagem, que ocorre quando um determinado padrão de dados é apresentado à rede, onde a mesma processa esses dados de forma a “entender” aquele padrão; e a fase de uso ou de testagem, que é quando se apresenta à rede padrões e ela vai tentar reconhecê-los com base no que “aprendeu” na etapa de aprendizagem. Na fase de teste, é possível apresentar padrões que não foram submetidos na etapa de aprendizagem, então a rede classifica esse padrão com base no que foi aprendido, gerando uma saída similar à que é gerada na fase de aprendizagem. Essa capacidade de reconhecimento a partir de dados pré-processados é chamada de generalização. Os critérios de similaridade definem como os exemplos de aprendizagem são semelhantes aos itens vistos pela primeira vez e devem fazer parte do processo de aprendizagem.

2.2.1 Redes Neurais com Pesos

De acordo com Haykin (2007) um neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma rede neural.

Em 1943, W. McCulloch e W. Pitts propuseram um modelo matemático de um neurônio artificial que tinha por objetivo simular o comportamento de um neurônio biológico. Neste modelo, o neurônio tem apenas dois estados em um dado instante de tempo: ele está ativo ou inativo, desta forma pode ser implementado como um dispositivo binário, gerando saídas de valor booleano (verdadeiro ou falso). As informações são armazenadas em pesos associados às conexões entre os neurônios. Na Figura 01 tem-se um modelo de neurônio com pesos, representado pela equação $v_k = \sum w_{ki} x_i + b_k$, indo de $i = 1$ até n , que representa um produto escalar entre o vetor de pesos e o número de entradas. Então é aplicada a função de ativação, de

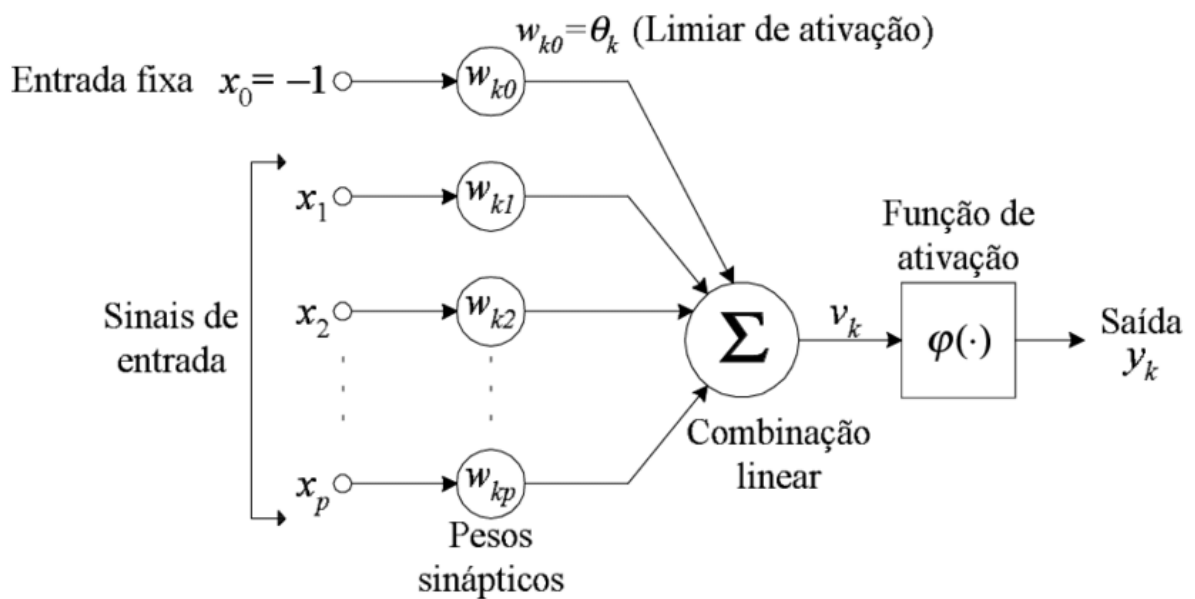
forma que o valor do somatório é então comparado a um limiar de ativação w_{k0} e sai 1, se $v_k > w_{k0}$ ou 0, caso contrário.

Figura 01: Modelo de neurônio de McCulloch-Pitts (Fernandes, 1999).

Os neurônios de uma rede neural com pesos são conectados através de links, que tem um determinado peso atrelado a eles, que afetará positivamente ou negativamente o seu disparo. Quando um neurônio dispara, gera um sinal que será usado pelo neurônio conectado a ele, então um neurônio determina a saída que produz (positivo ou negativo).

2.2.2 Redes Neurais Sem Peso

Devido às dificuldades enfrentadas no momento da implementação de



neurônios do tipo McCulloch-Pitts (McCulloch e Pitts, 1943), em 1965, Igor Aleksander propôs um modelo de neurônio totalmente digital baseado no dispositivo de armazenamento de memória principal RAM, que posteriormente ficou mais conhecido como neurônio sem pesos.

As Redes Neurais Sem Pesos (RNSP) são uma alternativa que utiliza um modelo de neurônios baseado na memória RAM. De acordo com Machado (2017), uma RNSP é baseada em neurônios artificiais que possuem entradas e saídas binárias e sem pesos nas conexões entre seus neurônios. O conhecimento de um neurônio de uma RNSP é armazenado em uma look-up table (tabela verdade), a qual

pode ser implementada utilizando memórias de acesso aleatório (RAM) disponíveis no mercado, ao contrário das RNA com pesos, com definição na seção 2.2.1, modificando seu conteúdo para o aprendizado. Neste tipo de abordagem só existem as etapas de treinamento e teste, este último também chamado de validação, pois não é necessário que exista a etapa de validação como ocorre nas RNA com pesos. Isto se deve ao fato de que as RNSP produzem sempre o mesmo resultado durante a etapa de treinamento (OLIVEIRA, 2018, p.11).

O treinamento é caracterizado pelo ato de apresentar aos neurônios RAM um padrão binário m , que é definido pela binarização dos padrões de entrada utilizando algum tipo critério que acomodar melhor o problema a ser resolvido, de tal forma que cada neurônio é responsável por aprender uma subparte deste padrão, chamada de tupla, com tamanho n fixo para todos os neurônios, sendo que m/n tem que ser um número inteiro. Este nó ou nodo RAM, como também é chamado, tem endereços de memória de tamanho 2^n que são gerados pelo tamanho da tupla. A validação da rede é feita logo após o treinamento.




Figura 2: Modelo da rede RAM básica (Oliveira, 2018, apud Oliveira et al., 2017).

Um nodo RAM com p entradas tem 2^p posições de memória, endereçadas pelos p bits do vetor $w = \{w_1, w_2, \dots, w_p\}$. Um sinal binário $I = \{I_1, I_2, \dots, I_p\}$ nas linhas de entrada acessa apenas uma dessas locações, aquela para a qual $w = I$. Se a rede estiver em processo de aprendizado o valor de q é igual a 1 e o conteúdo acessado pelas p linhas de entrada é modificado para o valor desejado (0 ou 1), fornecido pelo terminal d . O conteúdo $C[a]$ em todas as locações de memórias, sendo o endereço acessado pelo padrão I , é inicializado com o valor 0 (zero). Na fase de teste, o bit armazenado na posição de memória $C[a]$ é a saída da RAM $r = C[a]$, definida pela função identidade f . Se o valor encontrado na posição de memória $C[a]$

for 0, significa que o último aprendizado ocorrido foi 0 ou que aquele endereço não foi acessado durante o treinamento (OLIVEIRA, 2018). Um nó de um RNSP não é capaz de generalizar devido ao fato de que ele só aprende a cadeia de bits definida pela tupla relacionada, ou seja, apenas com dados em que foi treinado (OLIVEIRA, 2018).

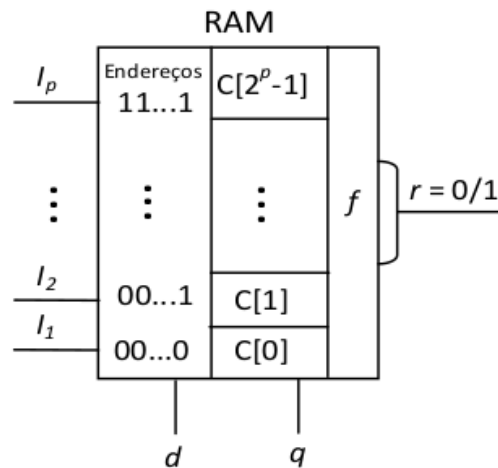


Figura 3: Modelo de Nó RAM (Oliveira, 2018, apud Oliveira et al., 2017).

2.2.3 Rede WiSARD

A abreviação WiSARD corresponde às iniciais das palavras **W**ilkie, **S**tonham and **A**leksander's **R**ecognition **D**evice. A RNSP WiSARD não possui inspiração no modelo do neurônio biológico, e corresponde a um conjunto de duas ou mais RNSP, cujos neurônios são também tabelas verdade, implementadas na memória de acesso randômico (RAM), de forma que modifica o seu conteúdo para o reconhecimento de padrões.

A RNSP não é capaz de generalizar com apenas um único neurônio, como ocorre na abordagem com pesos, mas, segundo Machado (2017), a generalização é possível com dois ou mais neurônios. Para se utilizar da capacidade de generalização, a rede WiSARD utiliza-se do conceito de discriminador, que é uma estrutura definida da seguinte forma: um discriminador consiste em uma rede de uma única camada com M neurônios RAM de N entradas cada. Desse modo, um discriminador com M neurônios será capaz de aprender e reconhecer um subconjunto de um padrão com tamanho $N \times M$. Cada neurônio é conectado a uma parte do padrão de entrada, denominada tupla, aprendendo apenas parte dela durante a fase de treinamento. Na

fase de teste, a saída de um discriminador para um padrão é um número binário com M bits, o qual corresponde à saída dos k neurônios da rede. Este número de M bits é processado por um dispositivo soma dor, dando como saída o número dos M neurônios RAM que reconheceram a tupla correspondente àquele padrão de entrada (MACHADO, 2017, p.30).

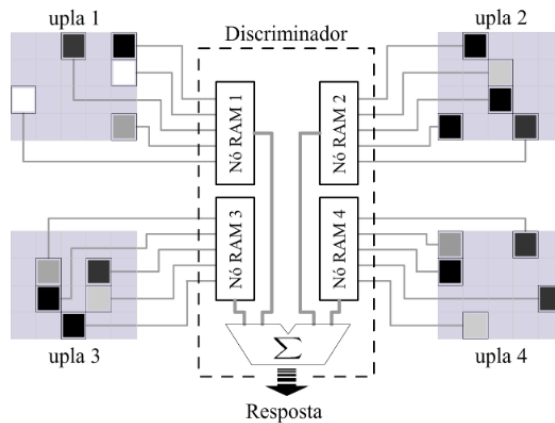


Figura 4: Representação esquemática de um discriminador (Araújo, 2011).

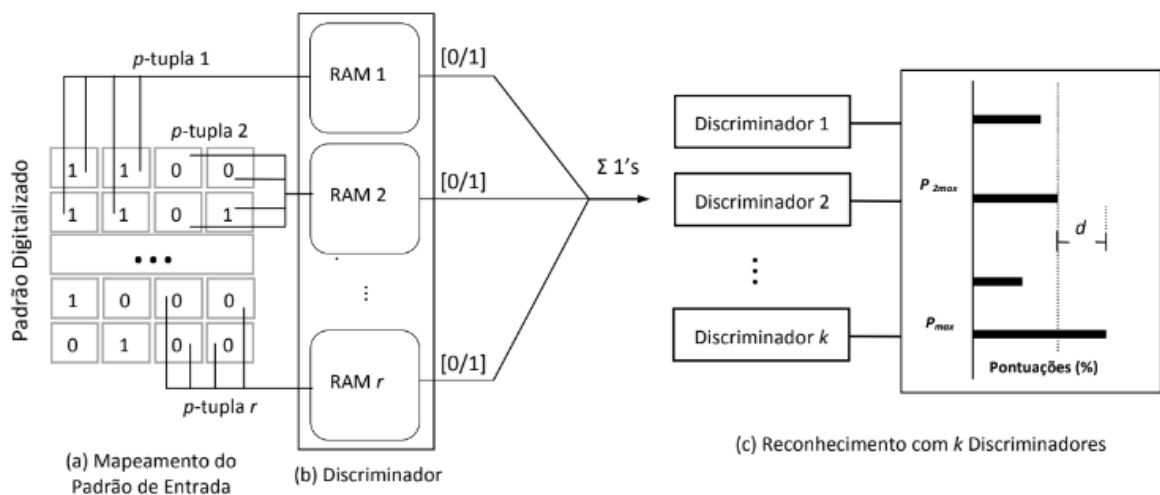


Figura 5: Representação esquemática da rede WiSARD (Oliveira, 2018).

2.2.3.1 Treinamento da Rede WiSARD

Na etapa de treinamento, os endereços de cada nó RAM são inicializados com um valor binário 0, dado o fato de que ainda não foram treinados. Subsequentemente, apresenta-se um conjunto de bits que representa uma classe à rede, e então cria-se uma partição de n -tuplas, sendo cada tupla mapeada de forma sequencial com uma

porção da cadeia de bits equivalente ao tamanho da mesma. O número de nós agrupados por cada discriminador é definido pelo tamanho do padrão de entrada dividido pelo tamanho especificado para a tupla.

Junto ao padrão binário apresentado é necessário apresentar também um identificador de classe ao discriminador, para que se possa controlar a relação padrão X discriminador, desta forma indicando a qual conjunto de nós RAM serão apresentados o subconjunto de entrada em questão, assim apenas os nodos relacionados à respectiva classe serão treinados. Isto é necessário pois a entrada é apresentada a todo o conjunto de discriminadores. Após um endereço de memória de um dos nós ser acessado, o valor armazenado naquele endereço muda de 0 para 1, indicando o acesso. Este processo é feito para cada nodo pertencente a classe que está sendo treinada.

2.2.3.2 Teste da Rede WiSARD

Durante esta etapa, mantêm-se as mesmas configurações definidas no treinamento da rede, vide o tamanho das tuplas e o tamanho do padrão de entrada. É então apresentado um padrão desconhecido pela rede junto ao identificador do discriminador e segue-se o mesmo processo de endereçamento de treinamento. Durante o endereçamento, os nós respectivos de cada classe são acessados e então verifica-se o valor armazenado. A saída é 1 quando o neurônio foi capaz de discernir que a tupla referente àquele padrão pertence à classe que foi treinada e 0 caso contrário.

Para se obter o resultado da validação, cada discriminador irá gerar o total de acessos com saída 1 de seus respectivos nodos através de um somador. O discriminador que obtiver a maior quantidade de nodos com resposta 1 será declarado o vencedor e então o padrão será relacionado como pertencente àquela classe. Em caso de empate, é escolhido aleatoriamente um discriminador entre os que obtiveram maior pontuação.

2.2.3.3 Capacidade Computacional da Rede WiSARD

A Rede WiSARD permite a construção de algoritmos flexíveis e de rápido aprendizado, pois há independência mútua entre os nós quando os dados de entrada da rede são modificados (MOREIRA; EBECKEN, 2013, p.105). Como os neurônios são implementados utilizando memórias RAM, esta rede consegue contornar o problema da impossibilidade de implementação da função *Exclusive OR* pelo modelo de neurônio de McCulloch e Pitts – o perceptron, além de apresentar a vantagem de ser treinada em um tempo muito curto (MOREIRA; EBECKEN, 2013, p.105).

Segundo Araújo (2011), o treinamento da rede WiSARD e a classificação de uma imagem utilizando-se a rede tem complexidade de ordem linear. Como definido na seção 2.2.2, um nó RAM tem 2^n posições de memória alocadas, o que, segundo Araújo (2011), compromete a viabilidade desse modelo para um n muito grande. Araújo (2011) também diz que experimentos práticos no entanto mostraram que n de até 16 geralmente é suficiente para qualquer aplicação.

2.2.3.4 Técnicas de Refinamento

Quando se lida com redes neurais, pode-se ocorrer um efeito chamado *overtraining*, que acontece quando a rede é treinada excessivamente. Uma rede com *overtraining* aprende muito com os dados de treinamento e é ruim em generalizar esse conhecimento. Nas redes RAM, esse comportamento ocorre quando vários endereços de nós são acessados durante o treinamento, mudando seu valor armazenado para 1. De acordo com Carvalho et al. (2013): se o conjunto de treinamento tiver muitos padrões, a maioria das posições RAM tendem a ser acessadas e mudadas para 1, o que significa que os discriminadores RAM produzirão altos valores de saída para qualquer padrão de entrada, aumentando assim a probabilidade de obter empates durante a fase classificatória. Esse efeito é chamado de saturação dos neurônios RAM e prejudica as capacidades de generalização da rede. Dado este fato, técnicas de refinamento são utilizadas para reduzir a aleatoriedade de escolha de discriminadores em caso de empate, obtendo-se assim uma maior confiabilidade de resposta da rede.

Carvalho et al. (2013) apresenta três tipos de técnicas de *bleaching* (numa tradução, aproxima-se de refinamento): *sequential bleaching* (bleaching simples), *confidence bleaching* (bleaching percentual) e *binary bleaching* (*b-bleaching*).

O *bleaching* simples armazena um número inteiro no endereço do nó RAM acessado, incrementando em 1 o seu valor para cada acesso e utilizando um *threshold* (limiar) b para determinar a saída do discriminador. São comparadas as saídas s de cada discriminador e aqueles que tiverem resultado $s \geq b$ tem seu valor de memória definido para 1 enquanto os que tiverem resultado $s < b$ para 0 (CARVALHO et al., 2013). Começando com $b = 0$ e incrementando seu valor a cada vez que ocorrer um empate, é possível escolher o discriminador com uma maior taxa de acerto. Caso b não possa mais ser incrementado, ou seja, todos os discriminadores pontuam 0, ocorre a escolha aleatória.

O *bleaching* percentual funciona de forma parecida com o simples, com a diferença de que é utilizado, além do limiar, o grau de confiança de um discriminador, que é dado pela equação:

$$y(r) = \begin{cases} 1 & \text{se } \frac{C[a]}{nt(D_i)} > \frac{\text{Bleaching convencional}(\beta)}{nt(D_{hf})} \\ 0 & \text{caso contrário} \end{cases}$$

Figura 6: Grau de confiança de um discriminador com *bleaching* percentual (Oliveira, 2018).

onde a saída y de um RAM r é definida por: $C[a]$ é o conteúdo do endereço acessado pelo padrão de entrada I , $nt(D_i)$ é o número de treinamentos do discriminador i contendo $C[a]$, com $1 \leq i \leq k$ (k é quantidade de discriminadores com r RAM cada), $\beta = 0,1,2,\dots$, são os possíveis valores para o *bleaching* convencional e $nt(D_{hf})$ é o número de treinamentos realizados pelo discriminador referente à classe com maior número de padrões (OLIVEIRA, 2018).

Por fim, o *binary bleaching* realiza uma busca binária em $b, b \in [1, b_{max}]$ onde b_{max} é o maior valor do somatório de posições de memória de um discriminador (CARVALHO et al., 2013).

Ainda segundo Oliveira, técnicas de *bleaching* também podem ser usadas para aliviar a saturação de endereços de memória. Para isso, com base em um limiar, os conteúdos dos endereços de memória menos usados são gradualmente apagados. Os endereços removidos estão associados a padrões que possuem poucas representações ou não pertencem às classes aprendidas pelo discriminador de

referência. Nesse caso, o limiar representa a frequência mínima de gravação na qual o conteúdo armazenado não é apagado.

3 SISTEMA DE RECONHECIMENTO FACIAL PROPOSTO COM BASE NAS REDES NEURAI SEM PESO

O sistema proposto tem como objetivo o reconhecimento facial e para isto se utiliza das RNSP. Ele é dividido em três etapas: captura das imagens, pré-processamento das imagens e reconhecimento facial. Na Figura 7, percebe-se como estas etapas estão conectadas, seguindo uma ordem cronológica de avanço a começar pela captura das imagens. Nesta primeira etapa, seu funcionamento se dá em duas formas e em dois momentos diferentes, sendo estes, respectivamente: treinamento e teste da rede. Na etapa de treinamento, a coleta das imagens pode ser realizada de maneiras diferentes, a exemplo, utilizando-se do celular para tirar autorretratos; já na etapa de testes, a coleta ocorre no local de implementação do sistema, se utilizando de câmeras, e também já exibe a saída da rede neural, indicando ou não o reconhecimento facial. Como não é de interesse deste trabalho abordar detalhadamente a etapa de captura das imagens, serão descritas com mais detalhes apenas as etapas de pré-processamento, nas seções 3.1 e 3.2; e de modelo neural, na seção 3.3.




Figura 7: Representação esquemática do sistema.

Os experimentos apresentados neste trabalho utilizam-se do *ORL dataset*, um conjunto de imagens da face disponibilizada pela AT&T Laboratories Cambridge, onde são disponibilizados 410 conjuntos, com 41 pessoas, sendo 10 imagens de cada uma, em escalas de cinza. Para a escolha dessa base de dados foram consideradas as seguintes características: variação de luminância, ângulos e qualidade. Para se ter uma noção mais próxima à realidade essas características são necessárias dado o

contexto da aplicação, pois usuários podem tirar fotos em diferentes ângulos e condições de iluminação e com diferentes dispositivos.

3.1 PRÉ-PROCESSAMENTO DAS IMAGENS

Para o tratamento de imagens foi utilizada a linguagem de programação Python, pois a mesma disponibiliza diversas bibliotecas e métodos para se lidar com inteligência artificial e processamento de imagens, tornando o desenvolvimento mais rápido e produtivo. Como não é de interesse deste trabalho abordar em detalhes as funções utilizadas da linguagem, serão dadas apenas explicações superficiais de como funcionam. Os modelos neurais foram alimentados com os próprios pixels das imagens utilizadas, passando apenas pelo processo de binarização necessário.

A seção 3.1.1 descreve como foi feita a separação dos conjuntos de imagens. A seção 3.1.2 aborda como foi realizada a codificação. Ademais, na seção 3.3 será descrito a arquitetura do modelo neural proposto para realização dos treinamentos e testes.

3.1.1 SEPARAÇÃO DOS CONJUNTOS DE IMAGENS

Para se avaliar o comportamento da rede, foram criados quatro conjuntos: FACE_A_AP, FACE_B_AP, FACE_A_SP, FACE_B_SP, sendo estes, respectivamente: a face com *threshold* adaptativo sem redução, face com *threshold* padrão sem redução de pixels, face com *threshold* adaptativo com redução de pixels e face com *threshold* padrão com redução de pixels. Para os conjuntos FACE_A_SP e FACE_B_SP a redução de pixels foi feita em janelas de 4x4 pixels cada.

3.1.2 CODIFICAÇÃO DAS IMAGENS

Como etapa inicial, tem-se dois tipos que foram introduzidos na seção anterior: o *threshold* (limiar) adaptativo, que é definido por uma soma ponderada gaussiana dos valores dos pixels vizinhos menos uma constante C , utilizando-se da função *adaptiveThreshold* da biblioteca *opencv*, e o *threshold* padrão, onde se é definido um valor base, que neste caso foi adotado a média de luminância da imagem, onde cada pixel é comparado a este valor e o resultado é 0 caso o valor de luminância do pixel for menor que a média e 1 se for maior ou igual. Aqui, utiliza-se a função *threshold*

também da biblioteca *opencv*. É esperado que o limiar adaptativo obtenha uma maior performance dado a sua natureza. Na Figura 4 é visualmente notório ao olho humano que esta técnica reproduz mais detalhadamente as características da imagem original.

Para a etapa final do processo de codificação foram utilizados dois padrões de binarização: um em que se aproveita todos os pixels da imagem e outro onde se aproveita uma porção dos mesmos. Como consequência desse processo, é esperado que o padrão binário resultante contenha menos informações, visto que uma porção de pixels foi mesclada.




Figura 8: Imagens extraídas da base de dados utilizada antes da binarização.




Figura 9: Imagem com sub-janelas de 4X4 pixels.

Na Figura 8, tem-se: (a) imagem antes da binarização, (b) após binarização com limiar adaptativo, (c) imagem antes da binarização, (d) imagem após binarização com limiar padrão; e na Figura 9, tem-se: (a) imagem após binarização com limiar adaptativo e segmentação de 4x4 pixels e (b) imagem após binarização com limiar padrão e segmentação de 4x4 pixels. Após o processo de binarização da imagem, foram criados oito arquivos csv contendo a identificação do padrão binário e o código binário que representa a imagem, sendo quatro para treinamento e quatro para testes, cada um guardando as informações dos conjuntos de imagens respectivos.

3.2 MODELO NEURAL UTILIZADO

A rede neural sem pesos possui uma única camada para n discriminadores. As pessoas são representadas pelos discriminadores, ou seja, existe um discriminador por pessoa. Visto que as experiências foram realizadas com 41 pessoas, a rede não se limita a esta quantidade, ou seja, sempre que uma nova pessoa for adicionada ao conjunto de dados será automaticamente criado um novo discriminador para representá-la. A este comportamento, dá-se o nome de *AutoWiSARD*, devido à sua capacidade de auto organização a partir das condições em que a rede está imersa, neste caso, os conjuntos de dados.

Segundo Machado (2017), “[...] muitas aplicações de RNA para problemas de reconhecimento de imagens utilizam de técnicas de pré-processamento da imagem antes que esta seja alimentada à rede”, e estas foram adotadas aqui para se estudar o comportamento da rede em diferentes cenários, conforme discutido na seção 3.1. Tendo passado a etapa do processamento de imagens, os padrões de entrada foram criados e então apresentados à rede, cada imagem associada ao seu identificador. Os arquivos .csv, descritos na seção anterior, gerados na etapa de pré-processamento das imagens, servem como alimentação para a rede, criando-se uma estrutura, a nível de código, da seguinte forma: uma classe definida para representar a Rede WiSARD que é composta por x discriminadores, os quais são compostos por y neurônios, que por sua vez são compostos por z memórias, as quais contém os endereço RAM ao qual são associadas, conforme descrito na seção 2; e o conteúdo que eles armazenam.

Como descrito na seção 2.2.1 existe uma relação direta entre o tamanho da tupla, tamanho do padrão de entrada e o número de neurônios da rede, este último ficando implícito pela equação: $M = P / N$, onde o M é o número de neurônios, P o tamanho do padrão de entrada e N o tamanho da tupla. Na Tabela 1 tem um exemplo das configurações para os conjuntos de testes. Neste capítulo não estão definidas todas as configurações, pois serão testados vários tamanhos de tupla diferentes. Este processo será descrito com mais detalhes no próximo capítulo.

Tabela 1: Número de neurônios por conjuntos de teste.

Conjunto	Tamanho do padrão de entrada (bits)	Tamanho da tupla	Quantidade de neurônios
FACE_A_AP	10304	4	2576
FACE_B_AP	10304	7	1472
FACE_A_SP	2576	2	1288
FACE_B_SP	2576	4	644

4 APRESENTAÇÃO E ANÁLISE DOS EXPERIMENTOS REALIZADOS E DOS RESULTADOS OBTIDOS

Neste capítulo são descritos os experimentos e resultados obtidos para o modelo neural descrito no capítulo anterior. A Avaliação se dá utilizando um sistema autoral proposto para treinamento e testes da rede neural sem pesos. Este experimento consistiu em treinar três arquiteturas diferentes, implementando-se, também, as técnicas de refinamento fundamentadas no capítulo 2, com os quatro conjuntos de imagens descritos no capítulo anterior, empregando estas redes para identificar os indivíduos nas imagens.

4.1 DESCRIÇÃO DOS EXPERIMENTOS

Com o objetivo de destacar a configuração de rede com maior capacidade de reconhecimento dentre as citadas no capítulo 3, os experimentos abordados neste capítulo têm como base os 4 conjuntos de imagens que foram criados utilizando-se de diferentes técnicas de codificação, explicadas nas seções 3.1 e 3.2. Para estabelecer os experimentos, foram treinados e testados 3 tipos de configurações de redes neurais: WiSARD padrão (WP), WiSARD com *bleaching* simples (WBS) e WiSARD com *bleaching* percentual (WBP), cada uma descrita de maneira mais detalhada no capítulo 2. A porcentagem de acertos da rede é definida pela equação a seguir: $P = (T_d * 100) / N$, onde P é a porcentagem, T_d o número total de acertos e N a quantidade de imagens testadas, ou seja, a média aritmética. Quando se apresenta um padrão de entrada a rede que corresponde a uma imagem, apresenta-se também o seu identificador, desta forma T_d é calculado quando o identificador do discriminador elegido pela rede é igual ao identificador da imagem apresentada. Também serão utilizados como parâmetros métricos a porcentagem de acerto de cada discriminador.

Com uma quantidade de 41 pessoas e com 10 imagens para cada, temos um total de 410 imagens sendo apresentadas a cada uma das redes aqui discutidas, sendo 5 definidas para treinamento e 5 para validação, assim ficando 205 o total de treinamento e 205 o total de validação, com uma divisão de 50%, sendo esta apresentando o melhor resultado após vários testes. Foram feitos 10 ensaios para cada conjunto, cada um com um tamanho de tupla diferente, com o objetivo de

encontrar o tamanho ideal para este caso de uso específico, totalizando 40 ensaios para cada configuração.

4.2 ANÁLISE DOS RESULTADOS

Na tabela 2 constam os resultados obtidos em cada configuração para os conjuntos específicos. Rede WP significa WiSARD Padrão, a WBS WiSARD com *Bleaching* Simples e a WBP WiSARD com *Bleaching* Percentual. Foram exibidos apenas os resultados com maior assertividade.

Tabela 2: Porcentagem de acertos por tipo de rede na primeira tentativa.

Conjunto	Rede WP (%)	Rede WBS (%)	Rede WBP (%)	Nº entradas
FACE_A_AP	67,32	67,32	67,32	4
FACE_B_AP	78,05	78,05	78,05	7
FACE_A_SP	70,24	70,73	70,73	4
FACE_B_SP	75,66	76,1	76,1	4

Como visto na Tabela 2, a maior taxa de acerto ocorreu nas três configurações. Segundo Carvalho et al. (2013,) pode-se inferir que isso acontece devido a uma baixa ou nenhuma quantidade de empates, visto que o *bleaching* simples garante uma assertividade maior quando se ocorre empates, conseguindo assim escolher o discriminador com a maior probabilidade. Como a taxa de acerto da Rede WBP foi idêntica à WBS, é possível dizer que não houve saturação dos endereços de memória e o treinamento ocorreu de forma homogênea, pois quando isso ocorre o *bleaching* percentual consegue “equilibrar” a quantidade de acessos na memória, diminuindo, assim, a saturação; como diz Oliveira (2018).

Analisando agora as redes WP e WBS, percebe-se uma melhora da rede WBS em relação à outra com os conjuntos FACE_A_SP e FACE_B_SP. Isto se deve ao

fato de aumentarem o número de empates de discriminadores, onde o uso do *bleaching* consegue ter um maior poder de discernimento. Esse aumento de empates provavelmente é consequência da redução de bits, fazendo a imagem perder detalhes que seriam definidores para o reconhecimento. É importante ressaltar aqui que o conjunto com a maior taxa de acerto foi o FACE_B_AP, que utiliza o limiar padrão, contrariando assim o esperado. Ainda neste contexto, os conjuntos com pixels reduzidos tiveram uma performance significativamente maior que o conjunto FACE_A_AP, chegando a 8,34% de diferença comparado ao conjunto FACE_B_SP. Nota-se também que o nível de descrição das imagens que o padrão de entrada exerce, influencia de forma direta na eficácia do reconhecimento da rede, pois os conjuntos com pixels reduzidos tiveram uma maior performance comparados aos conjuntos sem redução.

4.3 ARQUITETURA FINAL PROPOSTA

Tendo em vista os resultados obtidos na seção anterior, como obteve-se um empate do maior resultado com as três configurações estudadas, propõe-se o uso da Rede WBP, dado a sua capacidade de desempate e de remover saturação dos endereços de memória durante a fase de treinamento.

Consistindo de 41 discriminadores e um padrão de entrada de 10304 bits, cada discriminador representa um indivíduo. A arquitetura conta com um número de entradas de tamanho 7 para cada neurônio, totalizando assim 1472 neurônios por discriminador, tendo cada neurônio 128 endereços de memória associados. Como descrito no capítulo 3, esta arquitetura é uma *AutoWiSARD*, podendo acomodar quantos indivíduos forem necessários, criando automaticamente um discriminador para cada.

4.4 LIMITAÇÕES DA ARQUITETURA FINAL PROPOSTA

Tendo em vista a análise dos resultados e os experimentos realizados, percebe-se que a Rede WiSARD é bastante sensível ao padrão de entrada, podendo ter drásticas alterações de resultados. Além disso, soma-se a limitação do padrão de entrada ser binário, o que pode ocasionar em uma representação não muito fiel às imagens. Quanto ao banco de faces utilizado, tem-se apenas um número de dez

imagens por pessoa, o que pode ocasionar em uma baixa capacidade de generalização devido a falta de amostras para treinamento. Quanto aos resultados obtidos, percebe-se que uma taxa de 78,05% de assertividade na primeira tentativa de reconhecimento pode ser considerada baixa a depender da necessidade.

5 CONSIDERAÇÕES FINAIS

O presente trabalho abordou o uso de redes neurais sem peso aplicadas no reconhecimento facial com propósito de aplicação para o controle e acesso a ambientes compartilhados. Foram definidas três configurações de rede e quatro conjuntos de imagens para avaliar seus comportamentos, a fim de demonstrar qual configuração teria o melhor desempenho quando aplicada ao problema proposto.

Utilizando-se do *dataset* ORL, foram feitas várias rodadas de ensaios, chegando ao resultado de que qualquer uma das 3 configurações definidas pode ser escolhida para a aplicação final deste Trabalho Final de Curso, com base no banco de imagens definido. Dado a natureza descritiva, comparativa e empírica aqui explícitas, pode-se notar confirmações e negações com respeito à revisão da literatura feita. A primeira delas é em relação à funcionalidade das técnicas de refinamento, obtendo-se os resultados esperados, conforme descrito no capítulo 4. Adicionalmente, tem-se uma contradição referente às técnicas de codificação adotadas, a saber: a redução do número de pixels e o limiar padrão, ambos descritos nos capítulos 3 e 4. É possível concluir também que, não apenas o funcionamento natural da rede, mas também a representatividade dos padrões binários de entrada referente a base de dados de estudo, seja ela imagens, que é o caso deste trabalho, ou qualquer outro objeto de estudo, impacta positiva ou negativamente nos resultados de assertividade da rede, dado que os conjuntos com pixels reduzidos tiveram uma maior performance comparados aos conjuntos sem redução.

Por fim, como as três configurações de rede estudadas obtiveram os mesmos resultados com os quatro conjuntos de imagens, propôs-se a utilização da configuração WBP, visto que foi-se confirmada a eficácia da técnica de *bleaching* percentual. Dada a maior porcentagem de acerto, 78,05% a cada tentativa de reconhecimento, deve-se considerar onde, como e qual equipamento será utilizado desde o momento da coleta de imagens até o treinamento e validação da rede, além do número médio de tentativas de reconhecimento; avaliando-se se essa margem de erro inicial é ou não aceitável.

5.1 TRABALHOS FUTUROS

Para a continuidade deste trabalho, é proposto a utilização de outros modelos de neurônios sem pesos, além do uso de mais sensores (câmeras) para a captura das imagens, visto que pode-se ter um estudo mais completo para as redes neurais sem pesos. Por fim, propõe-se um pré-processamento de imagens diferente, utilizando-se de marcos faciais para o reconhecimento, como os olhos, nariz e boca. Com essas propostas, é possível comparar futuros trabalhos a este para um melhor estudo da capacidade das RNSP.

REFERÊNCIAS

ALVES, Priscila Mello. Inteligência Artificial e Redes Neurais. **IPEA**, 11 de jun. de 2020. Disponível em: <https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/106-inteligencia-artificial-e-redes-neurais>. Acesso em 06 de abr. de 2023.

ARAÚJO, Leandro de Almeida. RWiSARD: Um modelo de rede neural sem peso para reconhecimento e classificação de imagens em escalas de cinza. **UFRJ**, RJ, maio/2011. Disponível em: https://www.cos.ufrj.br/~rfarias/dissertations/LeandroAraujo_Master.pdf. Acesso em: 22/11/2022.

AT&T Laboratories Cambridge, 2001. Disponível em: <http://cam-orl.co.uk/facedatabase.html>. Acesso em 17 de abr. de 2023.

BARROS, A. J. P; LEHFELD, N. A. de S. **Fundamentos de metodologia**: um guia para a Iniciação científica. 2. ed. ampliada. São Paulo: Makron Books, 2000.

BRIDGET, Somekh; CATHY, Lewin. **Teoria e métodos de pesquisa social**. RJ: Editora Vozes, 2015.

Brasil tem mais smartphones que habitantes, aponta FGV. **CNN Brasil**, 2022. Disponível em: <https://www.cnnbrasil.com.br/business/brasil-tem-mais-smartphones-que-habitantes-aponta-fgv/>. Acesso em 06 de jun. de 2022.

Carlos. CONTROLE DE ACESSO: O QUE É E QUAL SEU OBJETIVO?. **Ib Tecnologia**, 2022. Disponível em: <https://www.ibtecnologia.com.br/blog/controle-de-acesso-o-que-e-e-qual-seu-objetivo>. Acesso em 06 de jun. 2022.

CAROLINE, Giselle. A importância do controle de acesso nas empresas, 2022. Disponível em: <https://wehandle.com.br/a-importancia-do-controle-de-acesso-nas-empresas/>. Acesso em 06 de abr. de 2023.

CAVALCANTI, Leo. Inteligência artificial na análise de dados: como usar na sua gestão? **Linkana**, 27 mai. de 2022. Disponível em: <https://www.linkana.com/blog/inteligencia-artificial-na-analise-de-dados/>. Acesso em 06 de abr. de 2023.

CONTROLE DE ACESSO. **Topdata**, 2021. Disponível em: <https://www.topdata.com.br/controle-de-acesso>. Acesso em 06 de jun. de 2022.

CORADINI, Rogério. Como é um sistema moderno de controle de acesso? **Digital Security**, 2020. Disponível em: <https://revistadigitalsecurity.com.br/como-e-um-sistema-moderno-de-controle-de-acesso>. Acesso em 03 de jun. de 2022.

FACHIN, Odília. **Fundamentos de Metodologia**. 5. ed. SP: Editora Saraiva, 2006.

FERNANDES, Marcelo. (1999). **Redes Neurais Artificiais Aplicadas à Detecção Inteligente de Sinais**. UFRS, RS.

FURTADO VASCONCELLOS, Maria Inês. **Redes Neurais Artificiais: Uma Abordagem Para Sala de Aula**. PR: Atena Editora, 2019.

HAYKIN, Simon. **Redes Neurais: princípios e práticas**. 2. ed. SP: Bookman, 2007.

MACHADO, Tarso Mesquita. Projeto Dedicado de Redes Neurais Sem Peso Baseadas em Neurônios de Lógica Probabilística Multi-valorada. **UERJ**, RJ, p. 26, agosto/2017. Disponível em: https://www.pel.uerj.br/bancodissertacoes/Dissertacao_Tarso_Machado.pdf. Acesso em: 06, jun. de 2022.

MARCONDES, José Sérgio. Sistema de Controle de Acesso: O que é? Definições e como funciona. **Gestão segurança privada**, 2020. Disponível em: <https://gestaodesegurancaprivada.com.br/sistema-controle-de-acesso-definicoes-como-funciona/>. Acesso em 03 de jun. de 2022.

MOREIRA, Rodrigo da Silva; EBECKEN, Nelson Francisco Favilla. Aplicação da Rede Neural Sem Peso WiSARD para o Rastreamento de Alvos de Superfície no Mar. **Journey of the Brazilian Computational Intelligence Society**, Rio de Janeiro, v. 11, n. 2, pp. 103-122, 2013. Disponível em: https://www.researchgate.net/publication/267451074_Aplicacao_da_Rede_Neural_Sem_Peso_Wisard_para_o_Rastreamento_de_Alvos_de_Superficie_no_Mar. Acesso em: 18 de abr. de 2023.

OLIVEIRA, José Carlos Martins. Detecção e Diagnósticos de falhas em processos dinâmicos com redes neurais sem pesos. **UFBA**, BA, abril/2018.

Painel de casos de doença pelo coronavírus 2019 (COVID-19) no Brasil pelo Ministério da Saúde. **CORONAVÍRUS BRASIL**, 2022. Disponível em: <https://covid.saude.gov.br/>. Acesso em 06 de jun. de 2022.

REVOREDO, Tatiana. O papel da inteligência artificial na cibersegurança. **Próximo nível**. 02 de dez. de 2021. Disponível em: <https://proximonivel.embratel.com.br/o-papel-da-inteligencia-artificial-na-ciberseguranca/>. Acesso em: 06 de abr. de 2023.

Segware. O que é controle de acesso e para que serve? **Segware**, 17 de set. de 2020. Disponível em: <https://www.segware.com/post/o-que-e-controle-de-acesso-e-para-que-serve>. Acesso em 06 de abr. de 2023.

Segware. Um guia completo sobre Controle de Acesso. **Segware** 20 de dez. de 2022. Disponível em: <https://www.segware.com/post/guia-controle-de-acesso>. Acesso em 13 de abr. de 2023.

SOUSA, A. S.; OLIVEIRA, S. O.; ALVES, L. H. A pesquisa bibliográfica: princípios e fundamentos. **Cadernos da FUCAMP**, Monte Carmelo, v.20, n.43, p.64-83, fev. de 2021. Disponível em: <https://revistas.fucamp.edu.br/index.php/cadernos/article/view/2336>. Acesso em: 27/04/2023.

APÊNDICE A – RESULTADOS DOS TESTES

Tabela 3: Resultados obtidos com a rede WP para o conjunto FACE_A_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	80
Pessoa 5	10	40
Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	20
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	80
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	80
Pessoa 19	10	40
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100
Pessoa 23	10	100
Pessoa 24	10	100

Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	80
Pessoa 29	10	80
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	60
Pessoa 34	10	40
Pessoa 35	10	100
Pessoa 36	10	20
Pessoa 37	10	80
Pessoa 38	10	40
Pessoa 39	10	60
Pessoa 40	10	60
Pessoa 41	10	100

Tabela 4: Resultados obtidos com a rede WP para o conjunto FACE_B_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	100
Pessoa 5	10	40
Pessoa 6	10	100
Pessoa 7	10	80

Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	100
Pessoa 12	10	80
Pessoa 13	10	80
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	60
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	100
Pessoa 23	10	80
Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	100
Pessoa 30	10	80
Pessoa 31	10	80
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	60
Pessoa 35	10	80

Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60
Pessoa 40	10	100
Pessoa 41	10	100

Tabela 5: Resultados obtidos com a rede WP para o conjunto FACE_A_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	60
Pessoa 5	10	60
Pessoa 6	10	100
Pessoa 7	10	100
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	60
Pessoa 16	10	60
Pessoa 17	10	0
Pessoa 18	10	100

Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100
Pessoa 23	10	80
Pessoa 24	10	100
Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	60
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	80
Pessoa 35	10	60
Pessoa 36	10	60
Pessoa 37	10	80
Pessoa 38	10	80
Pessoa 39	10	40
Pessoa 40	10	40
Pessoa 41	10	100

Tabela 6: Resultados obtidos com a rede WP para o conjunto FACE_B_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100

Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	100
Pessoa 5	10	40
Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	70
Pessoa 11	10	60
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	60
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	80
Pessoa 23	10	100
Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	80
Pessoa 29	10	100

Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	100
Pessoa 34	10	100
Pessoa 35	10	80
Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60
Pessoa 40	10	80
Pessoa 41	10	100

Tabela 7: Resultados obtidos com a rede WBS para o conjunto FACE_A_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	80
Pessoa 5	10	40
Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	20
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100

Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	80
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	80
Pessoa 19	10	40
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100
Pessoa 23	10	100
Pessoa 24	10	100
Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	80
Pessoa 29	10	80
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	60
Pessoa 34	10	40
Pessoa 35	10	100
Pessoa 36	10	20
Pessoa 37	10	80
Pessoa 38	10	40
Pessoa 39	10	60
Pessoa 40	10	60

Pessoa 41	10	100
-----------	----	-----

Tabela 8: Resultados obtidos com a rede WBS para o conjunto FACE_B_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	100
Pessoa 5	10	40
Pessoa 6	10	100
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	100
Pessoa 12	10	80
Pessoa 13	10	80
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	60
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	100
Pessoa 23	10	80

Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	100
Pessoa 30	10	80
Pessoa 31	10	80
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	60
Pessoa 35	10	80
Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60
Pessoa 40	10	100
Pessoa 41	10	100

Tabela 9: Resultados obtidos com a rede WBS para o conjunto FACE_A_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	70
Pessoa 5	10	60
Pessoa 6	10	100

Pessoa 7	10	100
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	60
Pessoa 16	10	60
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100
Pessoa 23	10	80
Pessoa 24	10	100
Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	60
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	80

Pessoa 35	10	60
Pessoa 36	10	60
Pessoa 37	10	80
Pessoa 38	10	80
Pessoa 39	10	40
Pessoa 40	10	40
Pessoa 41	10	100

Tabela 10: Resultados obtidos com a rede WBS para o conjunto FACE_B_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100
Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	100
Pessoa 5	10	40
Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	60
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	60
Pessoa 17	10	0

Pessoa 18	10	100
Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	80
Pessoa 23	10	100
Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	80
Pessoa 29	10	100
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	100
Pessoa 34	10	100
Pessoa 35	10	80
Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60
Pessoa 40	10	80
Pessoa 41	10	100

Tabela 11: Resultados obtidos com a rede WBP para o conjunto FACE_A_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
----------------------	---------------------------	---------------------------------------

Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	80
Pessoa 5	10	40
Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	20
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	80
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	80
Pessoa 19	10	40
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100
Pessoa 23	10	100
Pessoa 24	10	100
Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	80

Pessoa 29	10	80
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	60
Pessoa 34	10	40
Pessoa 35	10	100
Pessoa 36	10	20
Pessoa 37	10	80
Pessoa 38	10	40
Pessoa 39	10	60
Pessoa 40	10	60
Pessoa 41	10	100

Tabela 12: Resultados obtidos com a rede WBP para o conjunto FACE_B_AP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100
Pessoa 2	10	100
Pessoa 3	10	80
Pessoa 4	10	100
Pessoa 5	10	40
Pessoa 6	10	100
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	100

Pessoa 12	10	80
Pessoa 13	10	80
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	40
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	60
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	100
Pessoa 23	10	80
Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	100
Pessoa 30	10	80
Pessoa 31	10	80
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	60
Pessoa 35	10	80
Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60

Pessoa 40	10	100
Pessoa 41	10	100

Tabela 13: Resultados obtidos com a rede WBP para o conjunto FACE_A_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	60
Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	70
Pessoa 5	10	60
Pessoa 6	10	100
Pessoa 7	10	100
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	80
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	60
Pessoa 16	10	60
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	80
Pessoa 22	10	100

Pessoa 23	10	80
Pessoa 24	10	100
Pessoa 25	10	100
Pessoa 26	10	60
Pessoa 27	10	20
Pessoa 28	10	100
Pessoa 29	10	60
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	40
Pessoa 33	10	100
Pessoa 34	10	80
Pessoa 35	10	60
Pessoa 36	10	60
Pessoa 37	10	80
Pessoa 38	10	80
Pessoa 39	10	40
Pessoa 40	10	40
Pessoa 41	10	100

Tabela 14: Resultados obtidos com a rede WBP para o conjunto FACE_B_SP

Discriminador	Número de amostras	Média aritmética de acerto (%)
Pessoa 1	10	100
Pessoa 2	10	100
Pessoa 3	10	40
Pessoa 4	10	100
Pessoa 5	10	40

Pessoa 6	10	80
Pessoa 7	10	80
Pessoa 8	10	100
Pessoa 9	10	40
Pessoa 10	10	80
Pessoa 11	10	60
Pessoa 12	10	100
Pessoa 13	10	60
Pessoa 14	10	0
Pessoa 15	10	100
Pessoa 16	10	60
Pessoa 17	10	0
Pessoa 18	10	100
Pessoa 19	10	80
Pessoa 20	10	100
Pessoa 21	10	100
Pessoa 22	10	80
Pessoa 23	10	100
Pessoa 24	10	100
Pessoa 25	10	80
Pessoa 26	10	80
Pessoa 27	10	20
Pessoa 28	10	80
Pessoa 29	10	100
Pessoa 30	10	80
Pessoa 31	10	40
Pessoa 32	10	60
Pessoa 33	10	100

Pessoa 34	10	100
Pessoa 35	10	80
Pessoa 36	10	60
Pessoa 37	10	100
Pessoa 38	10	100
Pessoa 39	10	60
Pessoa 40	10	80
Pessoa 41	10	100