

Trabalho de Conclusão de Curso

Local Binary Convolutional Neural Network

para Reconhecimento de
Expressões Faciais de Emoções Básicas

Orientador: D.Sc. Alberto Torres Angonese

ALEXANDRA RAIBOLT



Sumário

- Introdução;
 - Motivação;
 - Justificativa;
 - Objetivos;
- Fundamentação Teórica;
 - Redes Neurais Convolucionais;
 - Padrão Binário Local;
 - Reformulação do LBP através de filtros convolucionais;

Sumário

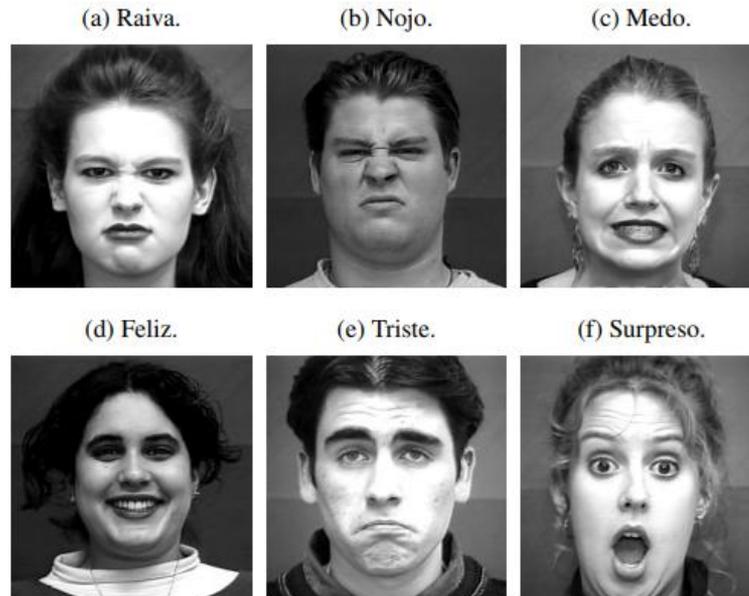
- Implementação;
 - Base de imagens;
 - Pré-processamento;
 - Formato .pkl;
 - Codificação *One-Hot*;
 - Rede Neural Convolutacional Binária Local;
- Experimentos e Resultados;
- Considerações Finais;
 - Trabalhos Futuros.

Introdução

- As expressões faciais são um meio de comunicação não verbal durante o processo de comunicação, que fornece informações de um indivíduo sobre suas intenções, desejos, objetivos, estado de espírito, etc.;
- Seis emoções básicas ou universais (Raiva, Nojo, Medo, Alegria, Tristeza, Surpresa.), foram foco de estudo de Ekman, e consideradas por ele como sendo as emoções comuns aos seres humanos, independente de fatores culturais.

Introdução

Figura 1: As seis expressões faciais de emoções básicas.



Fonte: Adaptado de [1, 2].

Introdução

- Nas relações interpessoais dos seres humanos realizar a tarefa de reconhecimento de objetos, reconhecimento facial, reconhecimento de expressões faciais torna-se uma tarefa fácil e corriqueira;
- Entretanto, computacionalmente tal tarefa apresenta um alto grau de complexidade.

Introdução

- Devido à grande necessidade encontrada na interação robô-humano por sistemas de reconhecimento automatizados, reconhecimento automatizado de objetos, facial, e de expressões faciais torna-se um importante desafio no campo da Visão Computacional;
- Pois dispõe de incontáveis aplicações do mundo real, como robótica Assistiva, gerenciamento de estoque, sistema de vigilância, controle automático de acesso, detecção de transtornos mentais, autenticação, etc.

Introdução

- O crescente estudo de Aprendizado de Máquina e Reconhecimento de Padrões nas últimas duas décadas para solucionar tarefas de Visão Computacional, conduziu pesquisas em busca de técnicas de extração de recursos de imagens;
- Dentre estas pesquisas, algumas técnicas apresentam bons resultados no processo de extração de características e padrões de classificação em imagens de faces para o reconhecimento e classificação de expressões faciais, como é o caso de: SVM, Redes Bayesianas e CNN.

Motivação

- As arquiteturas de CNN vêm conquistando espaço em desafios de reconhecimento e classificação de imagens a partir do ano de 2012 no desafio Imagenet;
- Seus resultados as tornam estado-da-arte para a resolução de problemas na área de Visão Computacional;
- Entretanto, um problema ainda enfrentado ao treinar tais arquiteturas, está relacionado ao poder computacional necessário, onde, torna-se um recurso caro, ou até mesmo indisponível;
- Em contrapartida, a arquitetura do LBCNN [3] demonstra um desempenho computacional eficiente, com sua complexidade computacional reduzida em comparação a outras arquiteturas de CNN.

Justificativa

- A partir de pesquisas realizadas em 2017 pela Federação Internacional de Robótica [4, 5] é possível observar que:
 - (1) Há uma discrepância na comparação do Brasil com outros países, como por exemplo aspectos socioeconômicos, ao fato de países desenvolvidos investirem no seu desenvolvimento tecnológico, apoiando financeiramente a educação e a pesquisa, enquanto no Brasil há déficits no apoio e investimento no desenvolvimento educacional, científico e tecnológico do país.

Justificativa

- (2) Existe uma carência de tecnologias voltadas para o desenvolvimento de soluções para a robótica Assistiva, além de aplicações de resgate e segurança;
- Portanto, devido a carência tecnologia de uma produção brasileira de robôs industriais e robôs de serviços, se faz necessário o estudo de métodos e técnicas que contribuam de alguma forma para suprir tal carência;
- No caso deste trabalho, temos como objeto de estudo a análise de expressões faciais de emoções básicas através do uso de uma adaptação de arquitetura de CNN - o LBCNN - que aplicada a plataformas robóticas autônomas possa trazer valor acadêmico e científico para a comunidade acadêmica brasileira além de atender demandas da sociedade em vários aspectos, tais como: auxílio doméstico e engenharia de defesa.

Objetivos

- Implementação de um sistema, capaz de realizar a tarefa de reconhecimento e classificação de expressões faciais básicas utilizando como extrator de características uma adaptação do LBCNN;
- Validação e análise entre os resultados obtidos (precisão de classificação, consumo computacional, etc.) em comparação a uma CNN tradicional.

Fundamentação Teórica

- Conceitos teóricos que dão embasamento para o desenvolvimento deste trabalho:
 - Redes Neurais Convolucionais;
 - Padrão Binário Local;
 - Reformulação do LBP através de filtros convolucionais.

Redes Neurais Convolucionais

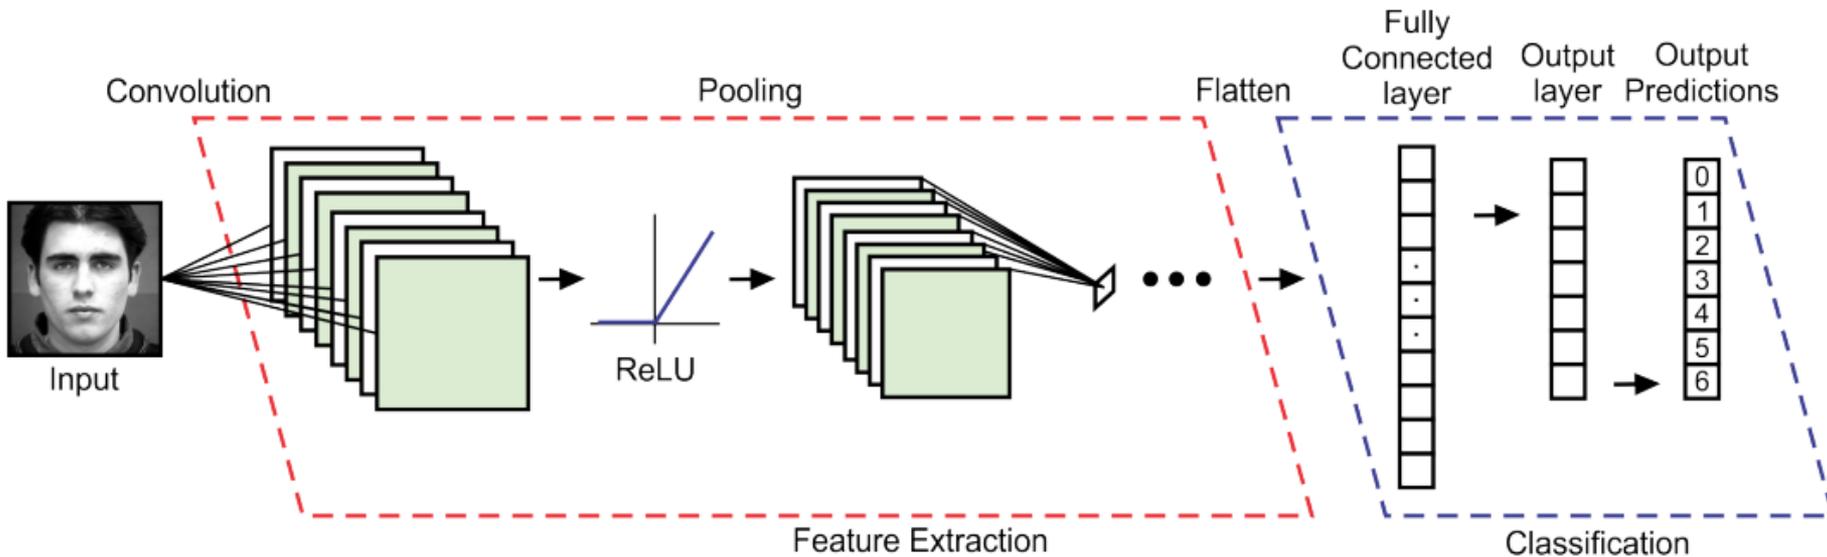
- Uma CNN pode ser caracterizada como sendo uma NN de múltiplas camadas onde primariamente faz-se a suposição de que os dados de entrada sejam imagens;
- Uma arquitetura básica de CNN pode ser dividida nas camadas listadas abaixo:

Redes Neurais Convolucionais

- Camada de Entrada;
- Camada de Convolução;
- Camada ReLU;
- Camada de Subamostragem;
- Camada de Flatten;
- Camada totalmente conectada.

Redes Neurais Convolucionais

Figura 4: Arquitetura básica do modelo CNN.



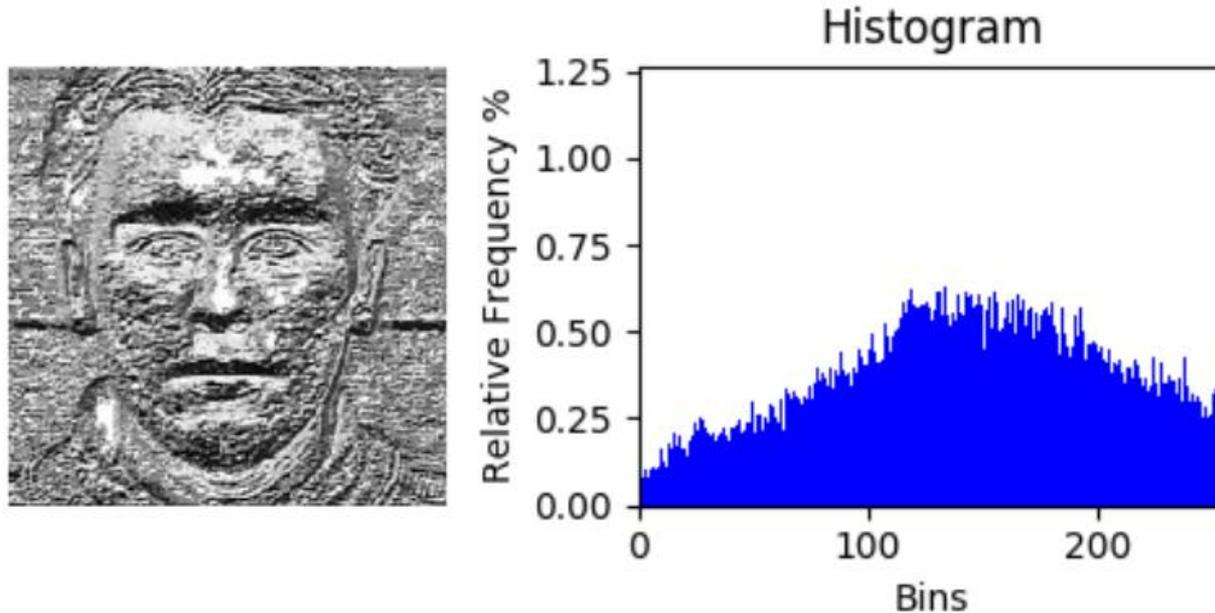
Fonte: Adaptado de [6].

Padrão Binário Local

- LBP é um tipo de descritor de textura simples e eficiente, usado para reconhecimento e classificação de padrões de imagens com texturas;
- Após diversas etapas, é então gerada o LBP resultante;
- Onde, posteriormente é calculado o histograma de intensidade dos pixels da imagem LBP resultante então gerada;
- Onde, o histograma 256-dimensional pode ser processado com algoritmos de ML (como por exemplo SVM) para realizar tarefas de análise de texturas e classificação de imagens.

Padrão Binário Local

Figura 7: Histograma de intensidade dos pixels.



Fonte: Elaborado pela autora.

Reformulação do LBP através de filtros convolucionais

- Para reformular o LBP através de filtros convolucionais e atingir o mesmo objetivo, é aplicada uma convolução de toda a imagem com 8 filtros convolucionais de tamanho 3x3, seguida de um operador de binarização não-linear, neste caso, a função Heaviside:

$$H(x) = \frac{1 + \text{sgn}(x)}{2}$$

Reformulação do LBP através de filtros convolucionais

- Onde $sgn(x)$ se refere a função sinal, portanto, podemos obter a seguinte equação:

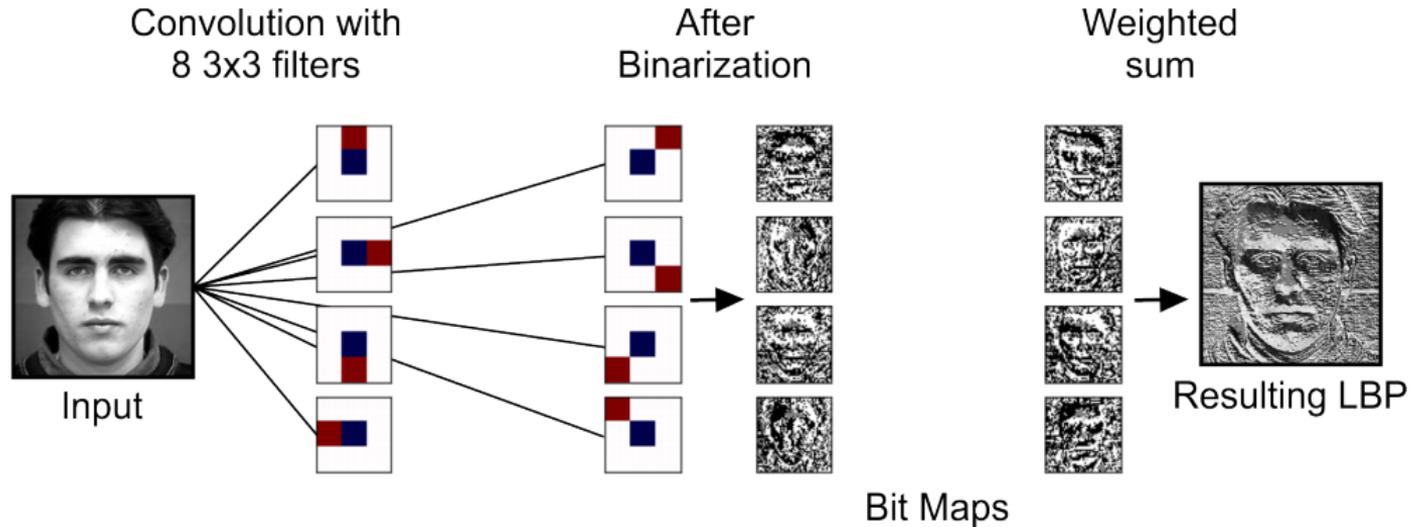
$$H(x) = \begin{cases} 0, & x < 0 \\ \frac{1}{2}, & x = 0 \\ 1, & x > 0 \end{cases}$$

Reformulação do LBP através de filtros convolucionais

- Em seguida é realizada uma soma ponderada dos 8 bit maps usando um vetor de pesos pré-definidos, $v = [2^7, 2^6, 2^5, 2^4, 2^3, 2^2, 2^1, 2^0]$, onde são então extraídos os recursos LBP;
- A Figura 8 a seguir ilustra todo este processo descrito acima:

Reformulação do LBP através de filtros convolucionais

Figura 8: Reformulação do LBP através de filtros convolucionais.



Fonte: Adaptado de [3].

Reformulação do LBP através de filtros convolucionais

- Como mostrado na Figura 8, os filtros de intensidade vermelha indicam que o filtro terá uma resposta positiva aos pixels pretos nas imagens de entrada (1), enquanto os filtros de intensidade azul indicam que o filtro terá uma resposta negativa aos pixels pretos nas imagens de entrada (-1).

Implementação

- A adaptação do LBCNN proposta neste trabalho, bem como o pré-processamento das bases de imagens utilizadas, foi implementada em Python utilizando o framework TensorFlow em uma arquitetura baseada em GPU;
- Todos os experimentos realizados foram processados por meio de uma instância de máquina virtual de alto desempenho na infraestrutura do Google - Google Compute Engine (GCE) – um componente Infraestrutura como Serviço (em inglês, *Infrastructure as a Service* - IaaS).

Implementação

- O GCE é um recurso disponível na plataforma Google Cloud Platform (GCP);
- A instância de máquina virtual on demand é composta por uma GPU NVIDIA® Tesla® K80 com memória da GPU de 12GB GDDR5 e 8 vCPUs disponíveis, além de 16 GB de memória RAM e 50GB de HD e é acessada por meio da interface de linha de comandos.

Implementação

- Todos os experimentos foram realizados através da versão gratuita estendida do Google Cloud Platform por 12 meses;
- Onde ao criar uma conta na plataforma, é inserido um crédito de \$ 300,00 dólares que poderá ser utilizado em todos os serviços oferecidos pela plataforma.

Implementação



GPU -

Memória 12 GB de RAM

Armazenamento 500 GB de HD

Tempo gasto* 16 horas**




GPU NVIDIA® GeForce® GTX 460 com memória de GPU de 1GB GDDR5.

Memória 8 GB de RAM

Armazenamento 500 GB de HD

Tempo gasto* 6 horas**



GPU NVIDIA® Tesla® K80 com memória da GPU de 12GB GDDR5 e 8 vCPUs disponíveis.

Memória 16 GB de RAM

Armazenamento 50 GB de HD

Tempo gasto* 46 minutos**

*Etapa de treinamento. **Em média.

Base de imagens

- Foram utilizadas três bases de imagens públicas de expressão facial: JAFFE, Extended CK+, e FER-2013;
- As três bases de imagens possuem as seis expressões faciais básicas apresentadas, e neutro, logo, formando sete emoções a serem classificadas pelo nosso modelo de LBCNN.

Base de imagens

Figura 9: Amostras presentes nas três bases de imagens.



Fonte: Adaptado de [7, 8, 9, 10].


Pré-processamento

- Devido à natureza escassa das bases de imagens utilizadas neste trabalho, aplicamos o processo de Data Augmentation;
- Processo este que é aplicado ao conjunto de treinamento com a finalidade de gerar sub-amostras diferentes para cada imagem.

Figura 10: Resultado do processo de Data Augmentation.

(a) Imagem de entrada.

(b) Sub-amostras.



Fonte: Elaborado pela autora.

Formato .pkl

- Pickle ou pickling (processo de serialização) é o termo empregado para o método de conversão aplicado a qualquer tipo de estrutura de objetos em Python para byte streams (0s e 1s);
- Na linguagem Python, existem diferentes módulos para a serialização de dados, Pickle é um deles;
- As vantagens em executar a serialização de dados está na possibilidade de salvar dados complexos, além da geração de algum nível de segurança de dados (mesmo que pequeno), uma vez que os dados serializados tornam-se quase ilegíveis.

Codificação One-Hot

- A codificação One-Hot é uma codificação de estados que consiste em gerar n vetores binários para n valores numéricos que representam cada um dos rótulos categóricos;
- Codificação necessária, pois:
 - (1) As CNNs não operam diretamente com rótulos categóricos;
 - (2) E a utilização de valores numéricos para representar rótulos categóricos em algoritmos de ML não é considerado como sendo uma boa prática, pois é possível que estes valores gerados possam prejudicar e influenciar a efetividade do algoritmo através do processo de aprendizado.

Codificação One-Hot

Tabela 1: Valores Numéricos x Codificação One-Hot.

Valores Numéricos	Codificação One-Hot
0	1000000
1	0100000
2	0010000
3	0001000
4	0000100
5	0000010
6	0000001

Rede Neural Convolucional Binária

Local

- A fim de reduzir a complexidade computacional em CNN convencionais, o LBCNN se baseia nos princípios de LBP, e traz como proposta, Local Binary Convolution (LBC), tornando-se uma poderosa alternativa para a camada convolucional em CNN convencionais;
- Além de reduzir cálculos, e significativamente a quantidade de parâmetros aprendíveis durante a etapa de treinamento devido a sua natureza binária e esparsa, a camada LBC reduz a complexidade do modelo, conseqüentemente, acarretando em economias computacionais e requisitos de memória, tornando-se um modelo aplicável em ambientes reais que possuem recursos escassos e limitados.

Rede Neural Convolucional Binária Local

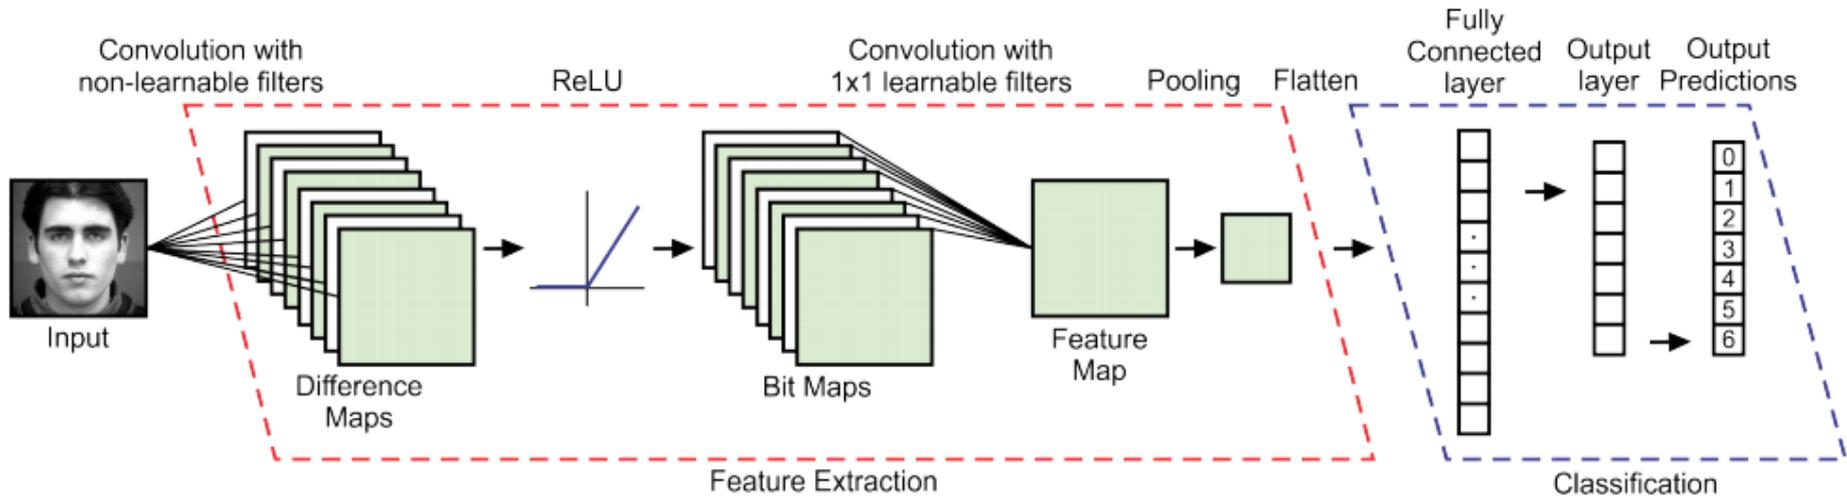
- A camada LBC é composta por, (1) um conjunto de filtros convolucionais de caráter binário, pré-definidos e fixos, ou seja, durante a etapa de treinamento, não são atualizados; (2) seguida por uma função de ativação não linear (ReLU); (3) que é seguida, por um conjunto de pesos lineares 1×1 aprendíveis;
- Nosso modelo constitui-se em cinco camadas LBC, podendo ser ou não, seguida por max-pooling.

Rede Neural Convolucional Binária Local

- Utilizamos a distribuição de Bernoulli como uma generalização dos pesos em um LBP tradicional para gerar aleatoriamente nosso conjunto de filtros convolucionais de caráter binário, pré-definidos e fixos;
- Para isto, definimos para ser utilizado em todos os nossos experimentos, um nível de sparsidade igual a 0.5, em relação aos pesos que podem tolerar valores distintos de zero, em seguida atribuímos aleatoriamente 1 ou -1 a esses pesos.

Rede Neural Convolucional Binária Local

Figura 11: Arquitetura básica do modelo Local Binary Convolutional Neural Network.



Fonte: Adaptado de [3].

Experimentos e Resultados

- A mesma arquitetura utilizada para implementar nosso modelo de CNN convencional serviu como base para implementarmos também nosso modelo de LBCNN;
- Portanto, para fazer uma comparação junta entre as arquiteturas, todos os experimentos foram executados por 100 épocas, com um total de 20.000 iterações;
- Utilizamos uma taxa de aprendizado de $1e-3$, e Adam Optimizer.

Experimentos e Resultados

- Desta forma, o número de filtros convolucionais, o número de camadas convolucionais, o número de unidades escondidas na camada totalmente conectada, foram os mesmos em ambos os modelos de redes;
- Já em relação aos parâmetros do LBCNN, utilizamos filtros de tamanho 3×3 para gerar os filtros não aprendíveis como no LBP tradicional, por apresentar melhores resultados nos experimentos realizados, além de serem gerados aleatoriamente pela distribuição de Bernoulli.

Experimentos e Resultados

- Os resultados obtidos através dos experimentos realizados podem ser vistos nas Tabelas 2 e 3;
- Onde a Tabela 2 mostra a acurácia obtida em cada base de imagem, enquanto a Tabela 3 mostra o tempo gasto na etapa de treinamento em cada base de imagem;
- As Figuras 12 e 13, respectivamente, mostram as matrizes de confusão das acurácias obtidas na etapa de teste do modelo CNN convencional e LBCNN implementadas neste trabalho.

Experimentos e Resultados

Tabela 2: Taxa de acurácia (porcentagem)
na etapa de teste.

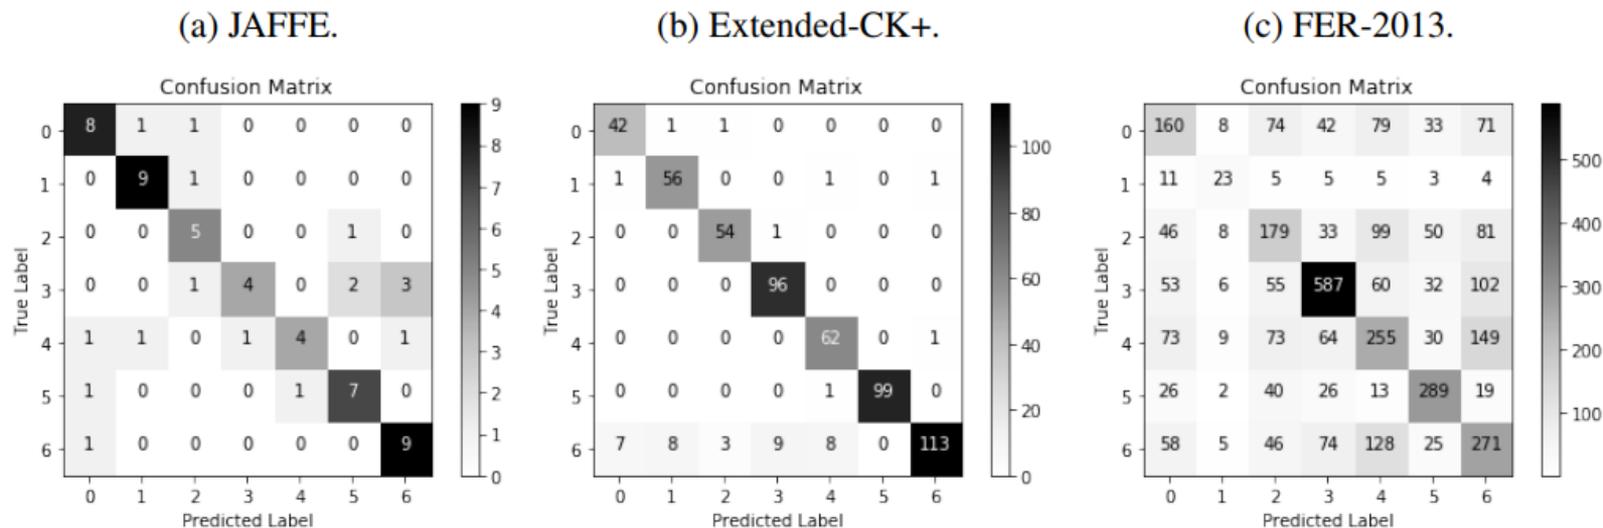
	CNN	LBCNN
JAFFE	73.0	77.8
Extended CK+	92.4	82.1
FER-2013	49.2	41.9

Tabela 3: Tempo gasto (horas)
na etapa de treinamento.

	CNN	LBCNN
JAFFE	0:46:15	0:16:52
Extended CK+	0:46:23	0:16:55
FER-2013	0:46:31	0:04:52

Experimentos e Resultados

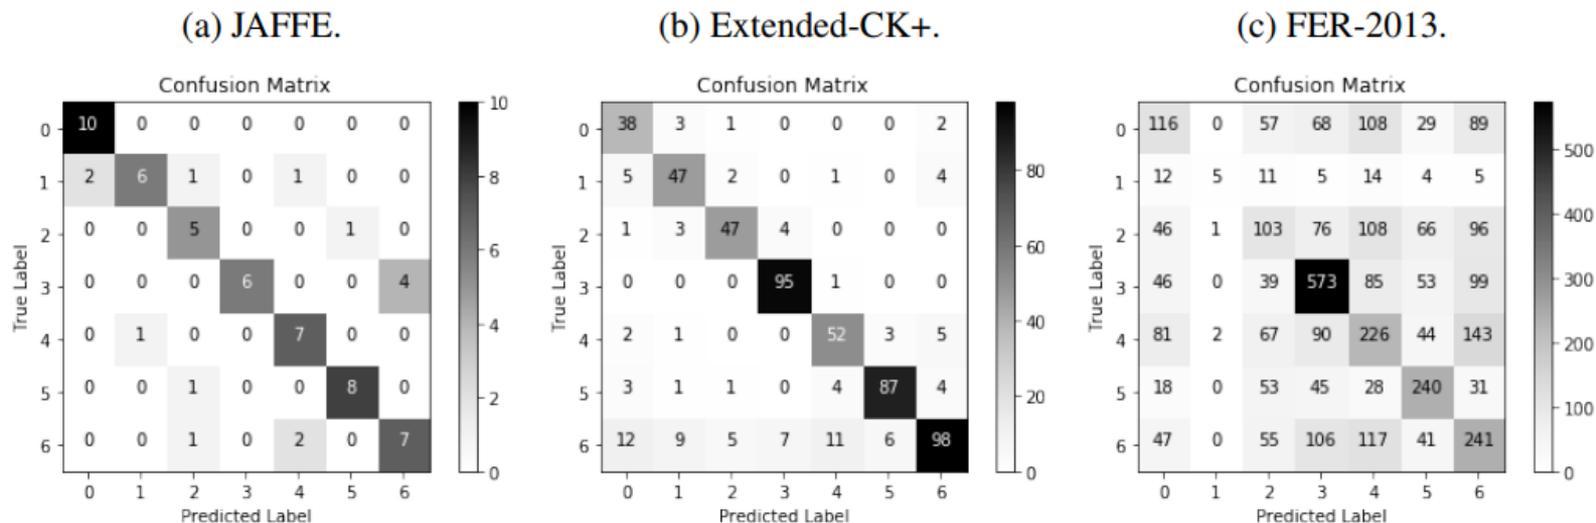
Figura 12: Matrix de Confusão da CNN convencional.



Fonte: Elaborado pela autora.

Experimentos e Resultados

Figura 13: Matrix de Confusão do LBCNN.



Fonte: Elaborado pela autora.

Experimentos e Resultados

- Além disto, foi estimado no GCE o seu custo efetivo ao utilizar a instância de máquina virtual de alto desempenho, onde o custo efetivo (em dólar) gerado ao executar ambos os modelos apresentados pode ser visto na Tabela 3 a seguir:

Tabela 3: Custo efetivo ao executar o modelo LBCNN em comparação ao modelo de CNN convencional.

	Custo	Tempo
CNN	0.639	46
LBCNN	0.222	16

Experimentos e Resultados

- Desta forma, é notável a eficiência e baixa complexidade computacional do LBCNN implementado neste trabalho;
- Sendo possível obter uma taxa de classificação satisfatória nos testes realizados em cada base de imagem com um custo baixo, gerando uma economia de \$ 0.416 ao executar o modelo LBCNN em comparação ao modelo de CNN convencional.

Experimentos e Resultados

- Ressaltamos que o objetivo deste trabalho não é obter uma maior precisão na etapa de teste em relação à CNN convencional, mas sim revelar sua eficiência, economia e baixa complexidade computacional em relação à CNN convencional para a tarefa de FER que resulta em um tempo gasto na etapa de treinamento relativamente baixa em relação a CNN convencional, enquanto a taxa de acurácia obtida é, em vezes relativamente melhor ou insignificamente baixa (se comparado ao tempo gasto na etapa de treinamento).

Considerações Finais

- Neste trabalho, propusemos o uso de LBCNN para a tarefa de FER, portanto, classificar as sete expressões faciais (Raiva, Nojo, Medo, Feliz, Triste e Surpresa) acrescentadas pela expressão neutra, compondo sete emoções básicas;
- O LBCNN foi implementado em Python usando o framework TensorFlow;
- Experimentos foram realizados para comparar sua eficiência com um modelo CNN convencional;
- Nossa abordagem mostrou-se eficiente em relação à sua precisão, custo efetivo e ao tempo gasto na etapa de treinamento, na qual é possível realizar a extração de características mais rapidamente.

Trabalhos Futuros

- Como continuação deste trabalho, propomos incorporar o modelo LBCNN apresentado neste trabalho em uma plataforma robótica autônoma;
- A plataforma robótica consiste de um robô Pioneer 3DX equipado com uma câmera RGBD, um laser de sensor Sick Lms200 e um computador usando o sistema operacional do robô (ROS), como descrito em [11, 12].

Trabalhos Futuros

- Ainda como continuação, pretendemos aplicar outras técnicas não abordadas neste trabalho, a fim de tornar o modelo de LBCNN proposto mais eficiente, tais técnicas como:
 - Validação cruzada (em inglês, Cross-validation) na etapa de treinamento a fim de ajudar a prevenir Overfitting;
 - Precision-Recall para Multiclass;

Trabalhos Futuros

- Regularização Dropout para, durante a etapa de treinamento regularizar as camadas totalmente conectadas da rede a fim de ajudar a prevenir Overfitting;
- Utilização do conjunto de ferramentas de visualização TensorBoard [89] para a otimização e depuração do framework TensorFlow.

Referências

- [1] Kanade, Takeo, Yingli Tian, and Jeffrey F. Cohn. "Comprehensive database for facial expression analysis." *fg*. IEEE, 2000.
- [2] Lucey, Patrick, et al. "The extended cohn-kanade dataset (ck+): A complete dataset for action unit and emotion-specified expression." *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on*. IEEE, 2010.
- [3] Juefei-Xu, Felix, Vishnu Naresh Boddeti, and Marios Savvides. "Local binary convolutional neural networks." *Computer Vision and Pattern Recognition (CVPR), 2017 IEEE Conference on*. Vol. 1. IEEE, 2017.

Referências

- [4] International Federation of Robotics. Executive Summary World Robotics 2017 Industrial Robots. 2017. URL: https://ifr.org/downloads/press/Executive_Summary_WR_2017_Industrial_Robots.pdf (acesso em 11/06/2018).
- [5] International Federation of Robotics. Executive Summary World Robotics 2017 Service Robots. 2017. URL: https://ifr.org/downloads/press/Executive_Summary_WR_Service_Robots_2017_1.pdf (acesso em 11/06/2018).
- [6] Maurice Peemen, Bart Mesman e Henk Corporaal. “Efficiency optimization of trainable feature extractors for a consumer platform”. Em: International Conference on Advanced Concepts for Intelligent Vision Systems. Springer. 2011, pp. 293–304

Referências

- [7] Takeo Kanade, Jeffrey F Cohn e Yingli Tian. “Comprehensive database for facial expression analysis”. Em: Automatic Face and Gesture Recognition, 2000. Proceedings. Fourth IEEE International Conference on. IEEE. 2000, pp. 46–53.
- [8] Patrick Lucey et al. “The extended cohn-kanade dataset (ck+): A complete dataset for action unit and emotion-specified expression”. Em: Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on. IEEE. 2010, pp. 94–101.
- [9] Michael Lyons et al. “Coding facial expressions with gabor wavelets”. Em: Automatic Face and Gesture Recognition, 1998. Proceedings. Third IEEE International Conference on. IEEE. 1998, pp. 200–205. REFERÊNCIAS 65

Referências

- [10] Ian J Goodfellow et al. "Challenges in representation learning: A report on three machine learning contests". Em: International Conference on Neural Information Processing. Springer. 2013, pp. 117–124.
- [11] Angonese, Alberto Torres, and Paulo Fernando Ferreira Rosa. "Integration of people detection and simultaneous localization and mapping systems for an autonomous robotic platform." *Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR), 2016 XIII Latin American*. IEEE, 2016.
- [12] Angonese, Alberto Torres, and Paulo Fernando Ferreira Rosa. "Multiple people detection and identification system integrated with a dynamic simultaneous localization and mapping system for an autonomous mobile robotic platform." *Military Technologies (ICMT), 2017 International Conference on*. IEEE, 2017.