

# Uma abordagem para detecção de lentes de contato baseado em *Deep Representations*

Pedro Silva, David Menotti  
Departamento de Computação  
Universidade Federal de Ouro Preto - UFOP  
Ouro Preto, MG, Brasil, 35400-000  
Email: {pedroh21.silva,menottid}@gmail.com

**Resumo**—Detecção de falsificações é uma tarefa desafiadora em sistemas biométricos, ao diferenciar usuários ilegítimos de genuínos. Apesar da íris ser mais abrangente que as impressões digitais, e também mais precisa para autenticação de pessoas, sistemas de reconhecimentos de íris são vulneráveis a falsificações através de lentes de contato cosméticas. Detecção de falsificações em íris são também referenciadas como detecção de vivacidade (classificação binária de imagem falsa ou real). Neste trabalho, focou-se em um problema de detecção de três classes: imagens com lentes de contato texturizadas (colorida), lentes transparentes, e sem lentes. A abordagem deste trabalho usa uma rede convolucional para construir representações em profundidade e uma camada adicional fortemente conectada com regressão *softmax* para classificação. Os experimentos são conduzidos em comparação com a abordagem estado-da-arte (EDA) em duas bases públicas de imagens de íris para detecção de lentes de contato: 2013 Notre Dame e IIT-Delhi. Os resultados mostram que a abordagem deste trabalho pode atingir resultados melhores que a abordagem EDA na primeira base de dados e comparáveis no último. Apesar da abordagem proposta ainda não segmentar imagens de íris, os resultados para a base IIT-Delhi atinge valores comparáveis aos do EDA, o qual segmenta as imagens. Levando esse fato em conta, conclui-se que os resultados obtidos são promissores.

**Abstract**—Spoofing detection is a challenging task in biometric systems, when differentiating illegitimate users from genuine ones. Although iris scans are far more inclusive than fingerprints, and also more precise for person authentication, iris recognition systems are vulnerable to spoofing via textured cosmetic contact lenses. Iris spoofing detection is also referred to as liveness detection (binary classification of fake and real images). In this work, we focus on a three-class detection problem: images with textured (colored) contact lenses, soft contact lenses, and no lenses. Our approach uses a convolutional network to build a deep image representation and an additional fully-connected single layer with softmax regression for classification. Experiments are conducted in comparison with a state-of-the-art approach (SOTA) on two public iris image databases for contact lens detection: 2013 Notre Dame and IIT-Delhi. The results show that our approach can achieve better results than SOTA on the former database and comparable results on the latter. Despite the proposed approach does not segment iris images, the results for the IIT-Delhi base reaches values comparable to the SOTA, which segments the images. Taking this into account, we conclude that the results are promising.

**Keywords**—Biometria; Íris; Detecção de Lentes de Contato; Aprendizado em Profundidade; Redes Convolucionais.

## I. INTRODUÇÃO

Os sistemas de identificação de pessoas baseado em biometria vêm se desenvolvendo rapidamente nas últimas duas décadas. Além disso, sistemas biométricos baseados no reconhecimento de íris vêm sendo implantados em várias aplicações, tais como sistemas de controle de fronteiras, ambientes controlados, acesso de computadores pessoais e smartphones. A íris é considerada o traço biométrico mais promissor, confiável e preciso, proporcionando textura rica que permite alta discriminação entre pessoas. Além disso, a informação da íris é estável ao longo do envelhecimento dos indivíduos [1].

O primeiro método de reconhecimento de íris funcional foi introduzido por Daugman, em 1993 [1], enquanto que a primeira patente propondo o uso da textura da íris como uma modalidade biométrica ocorreu em 1987 [2]. Daí em diante, várias abordagens de reconhecimento de íris foram propostas na literatura [3]–[5].

Devido ao aumento da utilização da íris como fonte de informação biométrica na última década, a possibilidade de ataques à estes sistemas se tornaram mais comuns [6]–[8]. Esses ataques são usualmente referenciados na literatura como *iris spoofing* (falsificação de íris) e vários trabalhos para lidar com este problema têm sido propostos [9]–[11]. Vários trabalhos na literatura têm abordado o problema de classificação de uma íris como real ou falsa, em que uma imagem falsa não é uma real (por exemplo, uma imagem impressa [6], [10], [12]). Além disso, abordagens para detecção de *spoofing* foram propostas nos últimos anos [13]–[18], em que falsificação de íris com lentes de contato coloridas são consideradas imagens falsas, e imagens de íris com lentes transparentes ou sem são consideradas reais.

Tendo em conta que as lentes de contato cosméticas estão se tornando mais populares, os tipos de ataques com lentes de contato texturizadas que um sistema biométrico baseado em íris pode sofrer são variados. Além do que, a acurácia dos métodos de detecção de lentes de contato texturizadas podem ser afetadas por padrões de lentes de contato e também por fabricantes de sensores, como é mostrado em [17].

Neste contexto, introduz-se o uso de técnicas de aprendizado em profundidade [19] (*Deep Learning*). Nos últimos anos, *Deep Learning* tem permitido resultados promissores

e marcantes para várias e importantes tarefas de análise de imagens, tais como reconhecimento de face [20]–[23], detecção de pedestres [24], reconhecimento de caracteres [25], [26], classificação de sinais de trânsito [27], reconhecimento de objetos em geral em grandes bases de dados categorizadas [28], entre outros. Além do sucesso nestas áreas, o uso de representações em profundidade (*Deep Representations*) para detecção de falsificação de imagens de íris, face, e impressão digital dos dedos também foi proposto recentemente [10], em um problema de detecção de duas classes simples, i.e., imagens falsas e reais.

O presente artigo<sup>1</sup> aborda um problema mais complexo de detecção de imagens de três classes, onde as imagens das íris podem aparecer com lentes de contato texturizadas (coloridas), lentes transparentes, e sem lentes. Propõe-se uma rede convolucional para construir *Deep Representations*, seguidas por uma camada totalmente conectada com regressão *softmax* para classificação. A abordagem deste artigo é baseada no trabalho de Krizhevsky et al. [28], onde os pesos de cada camada são aprendidos por retropropagação.

Em [29], os autores apresentam duas bases de dados de imagens para avaliação de métodos que lidam com o problema de detecção de três classes: a base 2013 *Notre Dame Contact Lens Detection* (NDCL) e a base *IIT-Delhi Contact Lens Iris* (IIT-D). Comparou-se a abordagem proposta com o algoritmo estado-da-arte (EDA), também proposto em [29], levando-se em conta as imagens de cada sensor e de diferentes sensores.

O trabalho está organizado da seguinte forma. Na Seção II, apresenta-se uma breve revisão dos trabalhos relevantes diretamente relacionados ao problema de detecção de falsificação de lentes de contato. Na Seção III, as bases de dados usadas nos experimentos são descritas. A metodologia proposta para lidar com a detecção de falsificação e os resultados experimentais são descritos e discutidos na Seção IV. Por último, as conclusões e direções para trabalhos futuros são delineados na Seção V.

## II. TRABALHOS RELACIONADOS

Nesta seção, são mostrados alguns trabalhos relevantes diretamente relacionados as três classes do problema de imagens de íris tratados neste trabalho, ou seja, estes propõem classificar imagens de íris em lentes de contato texturizadas (coloridas), lentes transparentes (prescritas) e sem lentes.

O primeiro passo do sistema de reconhecimento é capturar as imagens das íris. Devido a dificuldade em identificar texturas da íris em imagens coloridas, sensores devem operar em iluminação *Near-infrared* (NIR). No entanto, lentes de contato cosméticas podem mudar o padrão da íris e sua presença pode ser muito difícil de ser detectada em imagens coletadas em iluminação NIR. Tal característica indesejável é usada contra sistemas de reconhecimento de íris, o qual realiza ataques de falsificação mais facilmente com lentes texturizadas e também aumenta a taxa de falsos negativos para lentes prescritas [14], [16], [30].

Lee et al. [31] propuseram um novo método para detectar íris falsas baseado na imagem de Purkinje. Para adquirir a imagem, uma câmera convencional USB é usada com sensor CCD modificado e iluminação especial. Para realizar os experimentos, o conjunto de dados é construído com 300 íris reais e 15 falsas. Os autores reportaram uma taxa de falsa aceitação (FAR) de 0.33% e a taxa de falsa rejeição (FRR) de 0.33% no conjunto de dados, todavia, uma avaliação mais robusta, em uma base grande e diversa, deve ser considerada para validar propriamente o método.

Wei et al. [13] apresentam três métodos para detectar lentes texturizadas: medição da nitidez da borda da íris, aplicação de *iris-texton* para caracterização das primitivas visuais das texturas da íris, e uso de seleção de características baseadas em matrizes de coocorrência. A taxa de classificação (TC) reportada é de até 100% para experimentos usando características de matrizes de coocorrência.

Em [32], um método baseado na codificação de Padrões Binários Locais (LBP) e aprendizado Adaboost em conjunto com kernel Gaussiano para estimação de densidade alcançam FAR de 0.67% e FRR de 2.64% na discriminação de íris falsas texturizadas das íris reais.

Em [15], é proposto um algoritmo de detecção de lentes de contato baseado em *Scale-Invariant Feature Transform* (SIFT), LBP ponderado e Máquinas de Vetores de Suporte (SVM). De acordo com os autores, a combinação entre SIFT e LBP melhora sua variância à iluminação da escala e distorção local afim. Os autores afirmam que seu método atinge acurácia estado-da-arte na detecção de lentes de contato.

Após Daugman [33] apresentar um método que permite uma detecção de padrões de lentes de contato de maneira simples, muitos autores reportaram taxas de acurácia superiores a 98% [13], [15], [32]. No entanto, uma vez que a tecnologia de lentes de contato está em constante desenvolvimento, detecções robustas vem se tornando mais complexas [9]. Combinada com este fato, alguns estudos encontrados na literatura são favorecidos por sua metodologia, devido à utilização de bases que só possuem lentes de contato de um único fabricante entre os dados de treinamento e teste [9], [13]. De acordo com [17], em cenários mais realistas, métodos cuja precisão é próxima a 100% poderia diminuir para menos de 60%.

Para evitar essa situação, duas bases de dados foram construídas [17] com lentes de contato dos três maiores fabricantes. Várias cores são selecionadas para cada fabricante e também algumas lentes desenhadas para correção de astigmatismo. Autores afirmam que a acurácia de detecção de lentes texturizadas pode cair drasticamente quando testado em lentes de outros fabricantes, e que não estão presentes nos dados de treinamento e quando o sensor é diferente entre os dados de treinamento e os de teste. Uma extensão deste trabalho é apresentada em [29], onde as bases são bem descritas e disponibilizadas sobre requisição. Os autores sugerem que o desenvolvimento de uma abordagem geral e completa para detecção de lentes texturizadas é um problema que ainda necessita de atenção.

Em um trabalho recente [18], um novo método de detecção

<sup>1</sup>Uma versão estendida e em inglês deste trabalho está submetida a trilha principal do SIBGRAPI 2015.




Figura 1. Amostra de imagens da base de dados 2013 Notre Dame Contact Lens Detection (NDCL). Na primeira e segunda colunas, mostram-se imagens adquiridas com os sensores AD100 e LG4000, respectivamente. A primeira, segunda e terceira linhas apresentam amostras com lentes de contatos texturizadas/cosméticas, lentes de contato transparente/prescritas e sem lentes de contato, respectivamente.



Figura 2. Amostra de imagens da base de dados IIIT-Delhi Contact Lens Iris (IIIT). Na primeira e segunda colunas, mostram-se imagens adquiridas com os sensores Cogent e Vista, respectivamente. A primeira, segunda e terceira linhas apresentam amostras com lentes de contatos texturizadas/cosméticas, lentes de contato transparente/prescritas e sem lentes de contato, respectivamente.

de lentes de contato baseado em características de imagens estatisticamente binarizadas reportou acurácias próximas ao ótimo na base NDCL. Porém, neste trabalho, os autores lidam com um problema de classificação de duas classes (lentes transparentes e imagens sem lentes estão na mesma classe).

### III. BASES DE DADOS

Nesta seção, estão descritas as bases de dados usadas nos experimentos. Ambas são disponibilizadas publicamente sobre requisição e especificamente desenvolvidas para avaliação de detecção de lentes de contato em três classes [29]. São sumarizadas as principais características para cada base na Tabela I e são apresentados detalhes adicionais nas seções subsequentes. Note que todas as imagens das duas bases de dados são imagens em escala de cinza com  $640 \times 480$  pixels.

#### A. Notre Dame Contact Lens Database

A base de dados 2013 Notre Dame Contact Lens Detection (NDCLD'13 ou simplesmente NDCL) contem 5100 imagens [34]. Todas as imagens são do tamanho  $640 \times 480$  pixels adquiridas sobre a iluminação NIR usando dois tipos de câmeras, LG4000 e *IrisGuard* AD100. Esta base de dados é dividida em dois subconjuntos: *LG4000* com 3000 imagens para treinamento e 1200 para verificação; *AD100* com 600 imagens para treinamento e 300 para verificação. Estes subconjuntos são de fato utilizados como bases de dados primários para avaliação *intra-camera*, com a fusão dos dois subconjuntos tem-se 3600 imagens para treinamento e 1500 imagens para teste. As imagens são igualmente divididas em três classes: (1) usando lentes de contatos cosméticas, (2) usando lentes de contato transparentes, e (3) não usando lentes de contato. Fig. 1 ilustra algumas amostras da NDCL.

Todas as imagens desta base de dados são anotadas com as seguintes informações: um ID do sujeito a qual ela pertence, olho (esquerdo ou direito), o gênero do sujeito, raça, o tipo de lentes de contato usada, e as coordenadas da pupila e da íris. Essas coordenadas permitem a realização de experimentos considerando a segmentação perfeita da íris. Mais detalhes específicos para esta base podem ser achados em [34, Section II.B].

#### B. IIIT-D Contact Lens Iris Database

A base de dados Indraprastha Institute of Information Technology (IIIT)-Delhi Contact Lens Iris (IIIT-D CLI ou simplesmente IIIT-D) contêm 6583 imagens de íris de 101 sujeitos. Para cada indivíduo: (1) tanto o olho esquerdo quanto o direito são capturados gerando 202 classes de íris (íris diferentes); (2) as imagens foram capturadas sem lentes, lentes transparentes e lentes texturizadas - as três classes consideradas neste trabalho; (3) as lentes texturizadas foram capturadas usando variações nos sensores e nas lentes (coloridas e manufaturadas). As imagens desta base são ilustradas na Fig. 2.

Os sensores usados foram *Cogent dual* e *VistaFA2E single*. Contudo, esta base de dados oferece uma grande variação das lentes de contato texturizadas, a informação da localização da íris não é fornecida<sup>2</sup>. Mais detalhes específicos para esta base podem ser encontrados em [34, Section II.A].

<sup>2</sup>Os experimentos conduzidos nessa base de dados usaram a imagem completa do olho. A segmentação perfeita da íris ou a anotação é planejado como um trabalho futuro.

Tabela I  
PRINCIPAIS CARACTERÍSTICAS DAS BASES DE DADOS CONSIDERADAS E INTRODUZIDAS EM [29].

Database	Sensor	# Treinamento				# Teste/Verificação				# Completo			
		Text.	Trans.	Sem	Total	Text.	Trans.	Sem	Total	Text.	Trans.	Sem	Total
NDCL	<i>IrisGuard</i> AD100	200	200	200	600	100	100	100	300	300	300	300	900
	LG4000 <i>iris camera</i>	1000	1000	1000	3000	400	400	400	1200	1400	1400	1400	4200
	Multi-câmera	1200	1200	1200	3600	500	500	500	1500	1700	1700	1700	5100
IIT	Cogent Scanner	589	569	563	1721	613	574	600	1787	1202	1143	1163	3508
	Vista Scanner	535	500	500	1535	530	510	500	1540	1065	1010	1000	3075
	Multi-scanner	1124	1069	1063	3256	1143	1084	1100	3327	2267	2153	2163	6583




Figura 3. *Spoofnet* - Topologia inicial da rede usada aqui. Fonte: [10].

#### IV. METODOLOGIA, EXPERIMENTOS E RESULTADOS

Nesta seção, são apresentados os experimentos realizados neste trabalho. Começou-se avaliando os grupos de parâmetros que são descritos a seguir para estudar seus comportamentos e obter uma topologia de rede que executa detecções de lentes de contato chamada *CLDnet* (ver Fig. 4). Então, comparou-se a acurácia da abordagem proposta com os resultados estado-da-arte em diferentes cenários.

##### A. Metodologia - Avaliação de parâmetros

Primeiro avaliou-se os parâmetros, a fim de analisar a sua influência na acurácia do método proposto e também projetar uma topologia de rede robusta. Estes experimentos foram conduzidos separadamente somente na base NDCL (AD100 e LG4000), onde a localização da íris está disponível.

Como topologia de rede inicial, considerou-se uma usada em [10], i.e., *Spoofnet*. Esta configuração está ilustrada na Fig. 3. Além disso, 10% de adição de fundo foi selecionado para gerar as imagens de entrada iniciais, sendo que este valor foi decidido através de inspeção visual, pois inclui as bordas da lente de contato na imagem de entrada.

A primeira avaliação é a **metodologia de treinamento**. Verificou-se que, para a taxa inicial de aprendizado de  $10^{-3}$ , o *framework* trava/cai em poucas iterações/épocas. Isso provavelmente ocorre porque a taxa de aprendizado foi muito agressiva. Então, para todos os demais experimentos, uma *taxa inicial de aprendizado* usada foi de  $10^{-4}$ . Começou-se com o *número de épocas iniciais* em 100, contudo, testou-se também com 200, 300 e 400 épocas. Quando 400 épocas foram avaliadas, observou-se que o processo de aprendizado estava em *overfitting* no lote de validação do conjunto de treinamento, então decidiu-se assumir 300 como o número de épocas iniciais, uma vez que ainda se conseguia

Tabela II  
AVALIAÇÃO DA ARQUITETURA DA REDE PARA OS SENSORES AD100 E LG4000 DA BASE NDCL - VARIANDO O NÚMERO DE CAMADAS E O NÚMERO DE FILTROS EM CADA UMA.

Sensor	N. Filtros	TC	N. Filtros	TC
AD100	16	72.33	16-16-16	73.67
	32	68.67	16-16-32	76.00
	64	70.00	16-16-64	77.00
	16-16	75.67	16-32-16	72.33
	16-32	75.00	16-32-32	76.33
	16-64	74.67	16-32-64	71.00
	32-32	76.00	32-32-16	75.00
	32-64	76.00	32-32-64	79.67
	LG4000	16	79.50	16-16-16
32		77.34	16-16-32	83.34
64		80.84	16-16-64	81.17
16-16		84.34	16-32-16	82.92
16-32		84.82	16-32-32	81.75
16-64		84.17	16-32-64	76.92
32-32		85.59	32-32-16	81.34
32-64		85.00	32-32-64	83.75

generalização. Portanto, isto é definido como o protocolo de avaliação para os experimentos restantes.

Então, avaliou-se os parâmetros da **arquitetura da rede**, variando o número de camadas e o número de filtros por camada. Os resultados da taxa classificação (TC) são mostrados na Tabela II. Para *CLDnet*, manteve-se a configuração com duas camadas usando 32 e 64 filtros para a primeira e segunda camadas, respectivamente, uma vez que os resultados parecem mais estáveis para ambos os sensores da base NDCL. Avaliou-se a operação de normalização, contudo o método é insensível a ela. Assim, esta operação foi removida da *CLDnet*.

Por fim, avaliou-se os parâmetros **tamanho da imagem de entrada** e o **número de pixels a serem cortados da borda da imagem** simultaneamente. Os resultados destes experimentos são mostrados na Tabela III. Observou-se que os melhores resultados, na média, são das imagens de  $64 \times 64$  e  $128 \times 128$ , contudo como o tamanho de imagem pode ser um problema em algumas aplicações, preferiu-se o menor tamanho para as imagens de entrada da *CLDnet*. Além disso, os melhores resultados apresentados na Tabela III foram obtidos usando as redes com imagens de  $64 \times 64$  pixel, 4 pixels a serem cortados da borda, e 10% de adição de fundo, de tal forma que a *CLDnet* final é mostrada na Fig. 4.

##### B. Resultados

Nesta seção, comparou-se os resultados obtidos com o método proposto contra os resultados estado-da-arte (EDA)

Tabela III

AValiação DA ARQUITETURA DA REDE PARA OS SENSORES AD100 E LG4000 DA BASE NDCL - AVALIANDO O TAMANHO DA IMAGEM DE ENTRADA, O PARÂMETRO USADO NO CORTE DA BORDA DA IMAGEM, E A ADIÇÃO DE FUNDO A PARTIR DA ANOTAÇÃO DA BASE.

Sensor	Adição de fundo (%)	Tamanho imagem de entrada & Borda cortada											
		64 × 64				128 × 128				256 × 256			
		2	4	6	8	4	8	12	16	8	16	24	32
AD100	0	74.67	73.67	71.00	71.00	74.00	78.00	70.67	70.00	70.33	70.67	71.33	63.33
	10	74.67	<b>78.33</b>	74.00	73.33	73.33	76.00	72.67	65.33	71.33	73.67	68.00	62.33
	20	71.33	76.67	76.00	67.33	69.67	75.33	76.33	68.00	71.33	71.00	73.00	68.33
	30	69.00	70.00	72.67	75.00	68.33	72.33	73.00	75.33	67.33	70.00	72.00	67.00
	40	66.33	69.67	72.67	69.67	73.33	71.67	71.00	68.33	66.67	69.67	75.67	68.33
LG4000	0	82.50	81.92	82.75	82.08	84.25	83.83	84.17	82.08	77.25	76.50	76.00	77.00
	10	83.25	<b>86.00</b>	84.25	82.75	84.58	84.58	85.25	82.92	72.25	75.58	76.25	75.08
	20	81.25	82.83	84.08	80.58	84.75	84.83	85.58	84.33	72.17	74.92	75.83	73.58
	30	82.00	81.92	82.50	80.00	83.42	82.83	84.33	84.42	71.08	70.42	74.50	71.33
	40	80.25	81.42	81.50	82.08	82.17	82.92	84.92	82.67	68.00	70.58	72.08	71.08




Figura 4. CDLnet - rede proposta para Detecção de Lentes de Contato.

em [29]. Tabelas IV, V e VI (MP - método proposto) apresentam TCs para as classes sem lentes (N), com lentes texturizadas (T) e lentes transparentes (S) e o TC global (O) quando analisado as avaliações intra, inter, e multi-sensor, respectivamente. Esses resultados são analisados a seguir.

1) *Avaliação Intra-sensor*: É possível observar que o método proposto superou EDA para os sensores AD100 & LG4000 da base NDCL, onde a localização da íris está disponível, portanto, estabelecendo novos resultados EDA. Uma melhoria marginal é observado para o sensor de imagens AD100, contudo, para o sensor LG4000, o TC aumenta aproximadamente de 81% para 86%. Comparou-se os resultados aos EDA para as imagens provenientes dos sensores Cogent & Vista da base IIIT-D. Neste caso, a localização da íris não é disponibilizada e a imagem inteira do olho foi usada como entrada para o método proposto. No entanto, o método proposto atinge resultados maiores que dos segundos melhores métodos relatados em [29]. O resultado na base IIIT-D pode ser melhor entendido, quando considera-se que EDA conta com um algoritmo de segmentação da íris.

Para executar os experimentos nos sensores da base IIIT-D, usou-se a mesma rede, CDLnet, contudo, houve a necessidade de ajustar a taxa inicial de aprendizado para  $10^{-3}$ . Todos os parâmetros e procedimentos restantes foram mantidos como os usados nos sensores da base NDCL.

2) *Avaliação Inter-sensor*: Novamente, o método proposto atingiu novos resultados EDA neste cenário para a base NDCL, melhorando a TC em 18% e 15%. De certa forma, esses resultados destacam como *Deep Representations* podem ser robustas quando as características são aprendidas diretamente

dos dados. Em contrapartida, resultados desastrosos para a base IIIT-D foram alcançados devido a ausência de localização da íris — uma característica que tem o método que representa resultados EDA.

Tabela IV

RESULTADOS PARA INTRA-SENSOR DAS BASES NDCL E IIIT-D.

	Sensors									
	AD100		LG4000		Cogent		Vista			
	MP	EDA	MP	EDA	MP	EDA	2nd	MP	EDA	2nd
N	73.00	81.00	84.50	76.21	35.50	66.83	59.73	60.80	76.21	49.42
T	97.00	100.00	99.75	91.62	73.00	94.91	91.87	55.88	91.62	99.42
S	65.00	52.00	73.75	67.52	98.21	56.66	52.84	98.30	67.52	59.32
O	<b>78.33</b>	77.67	<b>86.00</b>	80.04	69.05	73.01	68.57	72.08	80.04	69.84

Tabela V

RESULTADOS PARA INTER-SENSOR DAS BASES NDCL E IIIT-D.

Treinamento	Sensors								
	AD100		LG4000		Cogent		Vista		
	MP	EDA	MP	EDA	MP	EDA	MP	EDA	
Teste									
N	75.00	62.25	80.00	74.00	6.00	62.10	48.67	65.99	
T	94.00	88.50	97.00	93.00	89.61	92.95	38.15	80.81	
S	65.00	29.50	49.00	17.00	45.47	75.44	42.25	48.31	
O	<b>78.00</b>	60.08	<b>75.33</b>	61.33	45.51	77.79	43.08	65.29	

3) *Avaliação Multi-sensor*: Finalmente, observou-se que as TCs obtidas através do método proposto supera os resultados EDA em quase 10% no cenário multi-sensor para a base NDCL e, embora a localização da íris não seja fornecida para a base IIIT, um desempenho comparável é alcançado.

Tabela VI

RESULTADOS PARA MULTI-SENSOR DAS BASES NDCL E IIIT-D.

	Bases de dados			
	NDCL		IIIT	
	MP	EDA	MP	EDA
N	77.40	72.60	47.55	62.14
T	99.60	97.00	61.07	94.74
S	71.40	50.00	97.99	61.63
O	<b>82.80</b>	73.20	69.28	72.96

## V. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, foi proposto o uso de *Deep Representations*, por meio de aprendizado de pesos em redes convolucionais seguida de uma camada fortemente conectada, para o problema de detecção de lentes de contato. Os experimentos conduzidos validam o método proposto, o qual pode atingir resultados superiores aos da abordagem estado-da-arte (EDA), sobre a base de dados NDCL e resultados comparáveis na base de dados IIIT-D. Em NDCL, a localização da íris é disponível, a qual permite criar representações em profundidade de regiões de interesse com os pixels da íris. Isso se torna um problema na base IIIT-D, onde nem a segmentação e nem a localização estão disponíveis. O método proposto que apresenta resultados EDA para a base IIIT-D realizou a segmentação da íris, todavia a abordagem apresentada ainda não está preparada para pré-processar a imagem e localizar a íris. Pretende-se adicionar essas características em trabalhos futuros e também avaliar técnicas de aprendizado em profundidade em que a arquitetura da rede é aprendida usando filtros com pesos aleatórios, e depois os pesos são otimizados usando retropropagação.

### AGRADECIMENTOS

Os autores gostariam de agradecer ao suporte financeiro da Pró-reitoria de Graduação (PROGRAD) da UFOP, CAPES, CNPq, FAPEMIG e FAPEPSP para a realização deste trabalho.

### REFERÊNCIAS

- [1] J. G. Daugman, "High Confidence Visual Recognition of Persons by a Test of Statistical Independence," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 15, no. 11, pp. 1148–1161, 1993.
- [2] L. Flom and A. Safir, "Iris Recognition System," US Patent 4 641 394, 1987.
- [3] K. W. Bowyer, K. Hollingsworth, and P. J. Flynn, "Image Understanding for Iris Biometrics: A Survey," *Computer Vision and Image Understanding*, vol. 110, no. 2, pp. 281–307, 2008.
- [4] Y. Song, W. Cao, and Z. He, "Robust Iris Recognition using Sparse Error Correction Model and Discriminative Dictionary Learning," *Neurocomputing*, vol. 137, pp. 198–204, 2014.
- [5] A. F. M. Raffei, H. Asmuni, R. Hassan, and R. M. Othman, "Feature Extraction for Different Distances of Visible Reflection Iris using Multiscale Sparse Representation of Local Radon Transform," *Pattern Recognition*, vol. 46, no. 10, pp. 2622–2633, 2013.
- [6] J. Galbally, S. Marcel, and J. Fierrez, "Image Quality Assessment for Fake Biometric Detection: Application to Iris, Fingerprint, and Face Recognition," *IEEE Transactions on Image Processing*, vol. 23, no. 2, pp. 710–724, 2014.
- [7] P. Gupta, S. Behera, M. Vatsa, and R. Singh, "On Iris Spoofing using Print Attack," in *22nd International Conference on Pattern Recognition*. IEEE, 2014, pp. 1681–1686.
- [8] Z. Sun and T. Tan, "Iris Anti-Spoofing," in *Handbook of Biometric Anti-Spoofing*, ser. Advances in Computer Vision and Pattern Recognition, S. Marcel, M. S. Nixon, and S. Z. Li, Eds. Springer London, 2014.
- [9] K. W. Bowyer and J. S. Doyle, "Cosmetic Contact Lenses and Iris Recognition Spoofing," *Computer*, vol. 47, no. 5, pp. 96–98, 2014.
- [10] D. Menotti, G. Chiachia, A. Pinto, W. Schwartz, H. Pedrini, A. X. Falcão, and A. Rocha, "Deep Representations for Iris, Face, and Fingerprint Spoofing Detection," *IEEE Transactions on Information Forensics and Security*, vol. 10, no. 4, pp. 864–879, 2015.
- [11] R. Raghavendra and C. Busch, "Robust Scheme for Iris Presentation Attack Detection Using Multiscale Binarized Statistical Image Features," *IEEE Transactions on Information Forensics and Security*, vol. 10, no. 4, pp. 703–715, 2015.
- [12] A. Sequeira, H. Oliveira, J. Monteiro, J. Monteiro, and J. Cardoso, "MobiLive 2014 - Mobile Iris Liveness Detection Competition," in *IEEE International Joint Conference on Biometrics*, Sept 2014, pp. 1–6.
- [13] Z. Wei, X. Qiu, Z. Sun, and T. Tan, "Counterfeit Iris Detection based on Texture Analysis," in *International Conference on Pattern Recognition*. IEEE, 2008, pp. 1–4.
- [14] S. E. Baker, A. Hentz, K. W. Bowyer, and P. J. Flynn, "Degradation of Iris Recognition Performance due to non-Cosmetic Prescription Contact Lenses," *Computer Vision and Image Understanding*, vol. 114, no. 9, pp. 1030–1044, 2010.
- [15] H. Zhang, Z. Sun, and T. Tan, "Contact Lens Detection based on Weighted LBP," in *International Conference on Pattern Recognition*, 2010, pp. 4279–4282.
- [16] N. Kohli, D. Yadav, M. Vatsa, and R. Singh, "Revisiting Iris Recognition with Color Cosmetic Contact Lenses," in *International Conference on Biometrics*, 2013, pp. 1–7.
- [17] J. S. Doyle, K. W. Bowyer, and P. J. Flynn, "Variation in Accuracy of Textured Contact Lens Detection based on Sensor and Lens Pattern," in *IEEE International Conference on Biometrics: Theory, Applications, and Systems*, 2013, pp. 1–7.
- [18] J. Komulainen, A. Hadid, and M. Pietikainen, "Generalized Textured Contact Lens Detection by Extracting BSIF Description from Cartesian Iris Images," in *IEEE International Joint Conference on Biometrics*, 2014, pp. 1–7.
- [19] Y. Bengio, A. Courville, and P. Vincent, "Representation Learning: A Review and New Perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 8, 2013.
- [20] F. Schroff, D. Kalenichenko, and J. Philbin, "FaceNet: A Unified Embedding for Face Recognition and Clustering," *arXiv preprint*, pp. 132–142, 2015, available in <http://arxiv.org/pdf/1503.03832.pdf>, submitted on 12 Mar 2015, to appear in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition 2015.
- [21] Y. Taigman, M. Yang, M. Ranzato, and L. Wolf, "DeepFace: Closing the Gap to Human-Level Performance in Face Verification," in *IEEE International Conference on Computer Vision and Pattern Recognition*, 2014, pp. 1701–1708.
- [22] G. Chiachia, A. X. Falcão, N. Pinto, A. Rocha, and D. Cox, "Learning Person-Specific Representations From Faces in the Wild," *IEEE Transactions on Information Forensics and Security*, vol. 9, no. 12, pp. 2089–2099, Dec. 2014.
- [23] D. Cox and N. Pinto, "Beyond Simple Features: A Large-Scale Feature Search Approach to Unconstrained Face Recognition," in *IEEE International Conference on Automatic Face Gesture Recognition and Workshops*. IEEE, 2011, pp. 8–15.
- [24] P. Sermanet, K. Kavukcuoglu, S. Chintala, and Y. LeCun, "Pedestrian Detection with Unsupervised Multi-Stage Feature Learning," in *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2013, pp. 3626–3633.
- [25] D. Menotti, G. Chiachia, A. X. Falcão, and V. Oliveira Neto, "Vehicle License Plate Recognition with Random Convolutional Networks," in *27th SIBGRAPI Conference on Graphics, Patterns and Images*, 2014.
- [26] D. C. Cireşan, U. Meier, L. M. Gambardella, and J. Schmidhuber, "Deep Big Simple Neural Nets For Handwritten Digit Recognition," *Neural Computation*, vol. 22, no. 12, pp. 3207–3220, 2010.
- [27] D. Cireşan, U. Meier, J. Masci, and J. Schmidhuber, "Multi-Column Deep Neural Network for Traffic Sign Classification," *Neural Networks*, vol. 32, pp. 333–338, 2012.
- [28] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [29] D. Yadav, N. Kohli, J. Doyle, R. Singh, M. Vatsa, and K. Bowyer, "Unraveling the Effect of Textured Contact Lenses on Iris Recognition," *IEEE Transactions on Information Forensics and Security*, vol. 9, no. 5, pp. 851–862, 2014.
- [30] S. E. Baker, A. Hentz, K. W. Bowyer, and P. J. Flynn, "Contact Lenses: Handle with Care for Iris Recognition," in *IEEE International Conference on Biometrics: Theory, Applications, and Systems*, 2009.
- [31] E. C. Lee, K. R. Park, and J. Kim, "Fake Iris Detection by using Purkinje Image," in *Advances in Biometrics*. Springer, 2005, pp. 397–403.
- [32] Z. He, Z. Sun, T. Tan, and Z. Wei, "Efficient Iris Spoof Detection via Boosted Local Binary Patterns," in *Advances in Biometrics*. Springer, 2009, pp. 1080–1090.
- [33] J. Daugman, "Demodulation by Complex-Valued Wavelets for Stochastic Pattern Recognition," *International Journal of Wavelets, Multiresolution and Information Processing*, vol. 1, no. 1, pp. 1–17, 2003.
- [34] J. Doyle and B. Kevin, "Notre Dame Image Database for Contact Lens Detection In Iris Recognition-2013: README," Available: <http://www3.nd.edu/~cvrl/papers/CosCon2013README.pdf>, 2014.