
Memória Associativa Bidirecional Exponencial Fuzzy Generalizada com Medida de Similaridade Estrutural Aplicada a um Problema de Reconhecimento de Faces

Aline Cristina de Souza¹

Departamento de Matemática Aplicada, IMECC - UNICAMP, Campinas, SP.

Marcos Eduardo Valle²

Departamento de Matemática Aplicada, IMECC - UNICAMP, Campinas, SP.

Resumo. As Memórias Associativas Bidirecionais Exponenciais Fuzzy Generalizadas (GEB-FAMs) são modelos heteroassociativos projetados para o armazenamento e recordação de pares de conjuntos fuzzy. Tais modelos são definidos com base em uma medida de similaridade, função que indica o grau com que dois conjuntos fuzzy são iguais. Neste trabalho, apresentamos a aplicação da GEB-FAM obtida a partir de uma medida de similaridade estrutural à um problema de reconhecimento de faces.

Palavras-chave. Memória Associativa, Medida de Similaridade Estrutural, Reconhecimento de Faces

1 Introdução

Uma memória associativa é um sistema de entrada e saída inspirado na capacidade do cérebro humano de armazenar e recordar informação por meio de associações. Especificamente, uma memória associativa é projetada para o armazenamento e recordação de um conjunto finito de pares, chamado conjunto das memórias fundamentais [4]. Em termos matemáticos, seja $X = \{(\mathbf{x}^\xi, \mathbf{y}^\xi), \xi = 1, \dots, p\}$ o conjunto das memórias fundamentais. Dada uma entrada \mathbf{x} , a memória associativa produz uma saída \mathbf{y} . Em particular, ao apresentar \mathbf{x}^ξ como padrão de entrada, espera-se que a memória produza \mathbf{y}^ξ (ou um padrão suficientemente próximo de \mathbf{y}^ξ) como saída. Espera-se também que a memória tenha certa tolerância a ruído, isto é, que ela seja capaz de recuperar um item mesmo a partir de uma versão corrompida do padrão associado a ele.

Uma memória associativa pode ser classificada de acordo com o tipo das memórias fundamentais a serem armazenadas [4]. No caso em que $\mathbf{x}^\xi = \mathbf{y}^\xi$ para todo $\xi = 1, \dots, p$, a memória é dita autoassociativa, enquanto que, se $\mathbf{x}^\xi \neq \mathbf{y}^\xi$ para algum ξ , a memória é dita heteroassociativa. Além disso, uma memória associativa projetada para armazenamento e recordação de uma família finita de conjuntos fuzzy é chamada memória associativa fuzzy.

¹s.alinedesouza@gmail.com

²valle@ime.unicamp.br

No início dos anos 90, Chiueh e Goodman apresentaram as memórias associativas por correlação exponencial (ECAM, *exponential correlation associative memory*), um modelo autoassociativo para o armazenamento e recordação de vetores bipolares [3]. Na mesma época, Chiueh et. al propuseram a memória associativa bidirecional exponencial (EBAM, *exponential bidirectional associative memory*), também projetada para o armazenamento de pares de vetores bipolares [5]. A EBAM pode ser vista como uma versão heteroassociativa da ECAM.

Apesar do sucesso dos modelos de memória associativa para armazenamento e recordação de vetores bipolares em problemas, algumas aplicações exigem o armazenamento de vetores com coordenadas reais ou conjuntos fuzzy. As memórias associativas recorrentes exponenciais fuzzy generalizadas (GRE-FAMs, *generalized recurrent exponential fuzzy associative memories*) podem ser vistas como uma versão fuzzy da ECAM, isto é, elas podem ser utilizadas para armazenar uma família finita de conjuntos fuzzy [9]. Inspirados na generalização da ECAM oferecida pela EBAM, nós introduzimos recentemente as memórias associativas bidirecionais exponenciais fuzzy generalizadas (GEB-FAMs, *generalized exponential bidirectional fuzzy associative memories*), que estendem as GRE-FAMs para o caso heteroassociativo [8].

As GEB-FAMs, assim como as GRE-FAMs, utilizam em sua definição uma medida de similaridade. Em termos gerais, uma função de similaridade indica o grau de igualdade entre dois conjuntos fuzzy. Na literatura, a definição de medida de similaridade pode variar de acordo com o contexto. Inicialmente, em trabalhos anteriores, consideramos uma versão normalizada da definição proposta por Xuecheng [11]. Neste trabalho, consideramos uma definição mais abrangente de medida de similaridade inspirada pela definição em [2]. Com essa definição, podemos considerar na definição da GEB-FAM a medida de similaridade estrutural (SSIM, *structural similarity index*) proposta por Wang et al. [10]. Nesse trabalho, aplicamos a GEB-FAM baseada na medida SSIM à um problema de reconhecimento de faces.

Este trabalho está organizado da seguinte forma. Na próxima seção apresentaremos a definição da medida de similaridade SSIM. Na Seção 3, recordaremos a definição das GEB-FAMs. Os experimentos computacionais realizados para avaliar o desempenho das GEB-FAMs em um problema de reconhecimento de faces, bem como os resultados obtidos, são descritos na Seção 4. Concluimos o trabalho com as considerações finais na Seção 5.

2 A Medida de Similaridade SSIM

A informação estrutural de uma imagem diz respeito aos atributos que representam a estrutura dos objetos na cena, independentemente da iluminação média e do contraste [10]. Nesta seção, recordaremos a definição da medida de similaridade estrutural proposta por Wang et. al [10] e conhecida por SSIM, do inglês *structural similarity index*.

A medida de similaridade SSIM está baseada numa medida de similaridade estrutural local, denotada por S_l [10]. Em termos gerais, S_l baseia-se nas comparações da iluminação, do contraste e da estrutura das imagens numa certa janela. Formalmente, considere fragmentos $\mathbf{x} = \{x_i : i = 1, \dots, N\}$ e $\mathbf{y} = \{y_i : i = 1, \dots, N\}$ extraídos do mesmo local de

duas imagens a serem comparadas. A medida de similaridade estrutural local é definida por:

$$S_l(\mathbf{x}, \mathbf{y}) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (1)$$

onde C_1 e C_2 são constantes positivas,

$$\mu_x = \frac{1}{N} \sum_{i=1}^N \omega_i x_i, \quad \sigma_x = \left(\frac{1}{N-1} \sum_{i=1}^N \omega_i (x_i - \mu_x)^2 \right)^{\frac{1}{2}}, \quad \sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N \omega_i (x_i - \mu_x)(y_i - \mu_y) \quad (2)$$

e $\Omega = \{\omega_i : i = 1, \dots, N\}$ é uma função de ponderação Gaussiana circular simétrica 11×11 , normalizada de modo que $\sum_{i=1}^N \omega_i = 1$, e com desvio padrão 1,5.

A medida de similaridade estrutural SSIM de duas imagens X e Y é então definida como a média da medida estrutural local de todos os fragmentos. Em termos matemáticos,

$$S(X, Y) = \frac{1}{M} \sum_{j=1}^M S_l(\mathbf{x}_j, \mathbf{y}_j), \quad (3)$$

em que X e Y são as imagens a serem comparadas, \mathbf{x}_j e \mathbf{y}_j são os fragmentos das imagens contidos na j -ésima janela local e M é o número de janelas locais das imagens.

Observemos que a medida SSIM é simétrica, limitada e reflexiva, isto é, $S(X, Y) = S(Y, X)$, $-1 \leq S(X, Y) \leq 1$ e $S(X, Y) = 1 \iff X = Y$.

3 GEB-FAMs

Inicialmente, recordemos que um subconjunto fuzzy X de um conjunto universo U é caracterizado por sua função de pertinência $X : U \rightarrow [0, 1]$ [12]. Dado um elemento $u \in U$, $X(u)$ indica o grau de pertinência de u em X , de modo que $X(u) = 0$ e $X(u) = 1$ indicam, respectivamente, a não pertinência e a pertinência completa de u em X . Denotaremos por $\mathcal{F}(U)$ o conjunto de todos os subconjuntos fuzzy de U .

As memórias associativas bidirecionais exponenciais fuzzy generalizadas (GEB-FAMs) são projetadas para o armazenamento e recordação de um família finita de pares de conjuntos fuzzy. Formalmente, seja $\{(A^\xi, B^\xi), \xi = 1, \dots, p\} \subset \mathcal{F}(U) \times \mathcal{F}(V)$ o conjunto das memórias fundamentais, $\alpha > 0$ um número real, $\mathcal{S}_U : \mathcal{F}(U) \times \mathcal{F}(U) \rightarrow [0, 1]$ e $\mathcal{S}_V : \mathcal{F}(V) \times \mathcal{F}(V) \rightarrow [0, 1]$ medidas de similaridade, G e H matrizes de dimensão $p \times p$. Dado um conjunto fuzzy de entrada $X_0 \in \mathcal{F}(U)$, uma GEB-FAM produz recursivamente seqüências de conjuntos fuzzy $\{X_t\}_{t>0}$ e $\{Y_t\}_{t\geq 0}$ definidos, para todo $t \geq 0$, $u \in U$ e $v \in V$, pelas seguintes equações:

$$Y_t(v) = \varphi \left(\frac{\sum_{\xi=1}^p \sum_{\mu=1}^p g_{\xi\mu} e^{\alpha \mathcal{S}_U(A^\mu, X_t)} B^\xi(v)}{\sum_{\eta=1}^p \sum_{\mu=1}^p g_{\eta\mu} e^{\alpha \mathcal{S}_U(A^\mu, X_t)}} \right) \quad \text{e} \quad X_{t+1}(u) = \varphi \left(\frac{\sum_{\xi=1}^p \sum_{\mu=1}^p h_{\xi\mu} e^{\alpha \mathcal{S}_V(B^\mu, Y_t)} A^\xi(u)}{\sum_{\eta=1}^p \sum_{\mu=1}^p h_{\eta\mu} e^{\alpha \mathcal{S}_V(B^\mu, Y_t)}} \right), \quad (4)$$



Figura 1: Imagens de um indivíduo do conjunto de treinamento.

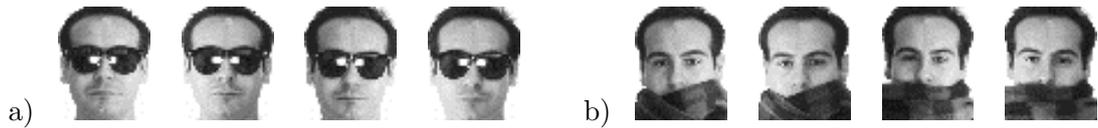


Figura 2: Imagens de teste do indivíduo da Figura 1 nos experimentos a) e b).

em que a função φ , dada por $\varphi(x) = \max(0, \min(1, x))$, garante que $Y_t(v), X_{t+1}(u) \in [0, 1]$, para todo $v \in V, u \in U$ e para todo $t > 0$. Neste trabalho consideramos $G = C^{-1}$, em que $C = (c_{ij})_{p \times p}$ é a matriz definida por $c_{ij} = e^{\alpha S_U(A^i, A^j)}$. Analogamente, $H = D^{-1}$ em que $D = (d_{ij})_{p \times p}$ é definida por $d_{ij} = e^{\alpha S_V(B^i, B^j)}$.

Observemos que, a menos da função φ , Y_t e X_{t+1} são determinados, respectivamente, a partir de combinações lineares dos conjuntos fuzzy B^ξ e A^ξ cujos pesos envolvem exponenciais das similaridades entre esses conjuntos e os conjuntos X_t e Y_t .

4 Experimentos Computacionais e Resultados

Para avaliar o desempenho das GEB-FAMs definidas utilizando a medida de similaridade SSIM, realizamos dois experimentos computacionais utilizando a base de imagens faciais AR [7]. Especificamente, consideramos os mesmos experimentos descritos por Luo et al. em [6]. Com o objetivo de associar uma dada imagem à pessoa a qual ela pertence, utilizamos como base um conjunto de imagens já rotuladas, ao qual chamaremos de conjunto de treinamento ou, equivalentemente, conjunto das memórias fundamentais.

Em ambos os experimentos, consideramos o conjunto de treinamento composto por pares (A^ξ, B^ξ) , em que A^ξ representa uma imagem em tons de cinza e B^ξ indica a qual pessoa a imagem A^ξ pertence. Especificamente, o conjunto $B^\xi \in \mathcal{P}(\{1, 2, \dots, 120\})$ satisfaz $B^\xi(i) = 1$ e $B^\xi(j) = 0$, para todo $j \neq i$, se a imagem A^ξ pertence a i -ésima pessoa. Para o conjunto de treinamento, consideramos 960 pares, referentes a 8 imagens de cada indivíduo de um grupo de 120 pessoas [7]. A Figura 1 representa um exemplo das imagens pertencentes ao conjunto de treinamento para um certo indivíduo.

No primeiro experimento consideramos como conjunto de teste um conjunto com 4 imagens de cada um dos 120 indivíduos com óculos escuros e iluminação em diferentes posições. No segundo experimento, consideramos um conjunto de teste formado por 4 imagens de cada um dos 120 indivíduos com cachecol e iluminação. A Figura 2 contém as imagens do indivíduo da Figura 1 usadas no conjunto de teste dos experimentos: a) óculos+iluminação e b) cachecol+iluminação, respectivamente.

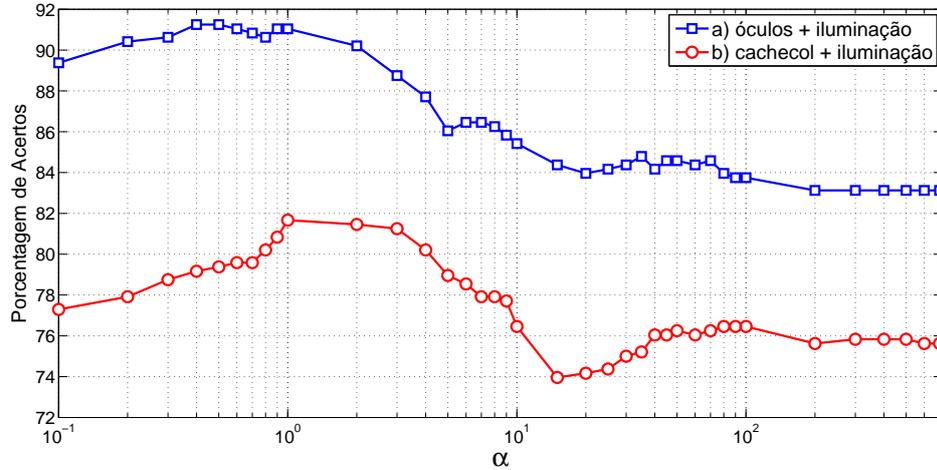


Figura 3: Porcentagem de acertos obtidas pelas GEB-FAMs pelo valor do parâmetro α considerando imagens dos indivíduos com a) óculos+iluminação e b) cachecol+iluminação

A GEB-FAM foi aplicada ao problema de reconhecimento de faces conforme descrito a seguir. Consideremos $\{(A^\xi, B^\xi), \xi = 1, \dots, 960\}$ o conjunto de treinamento, \mathcal{S} a medida de similaridade estrutural SSIM e $\alpha > 0$ um número real. Ao apresentar uma imagem X_0 como padrão de entrada, a GEB-FAM produziu em um único passo o conjunto fuzzy Y_0 dado por (4) com $t = 0$:

$$Y_0(v) = \varphi \left(\frac{\sum_{\xi=1}^p \sum_{\mu=1}^p g_{\xi\mu} e^{\alpha \mathcal{S}(A^\mu, X_0)} B^\xi(v)}{\sum_{\eta=1}^p \sum_{\mu=1}^p g_{\eta\mu} e^{\alpha \mathcal{S}(A^\mu, X_0)}} \right). \tag{5}$$

Associamos a imagem X_0 à i -ésima pessoa, em que i é o primeiro índice tal que $Y_0(i) \geq Y_0(j)$, para todo $j = 1, \dots, 120$.

Os experimentos foram feitos no *software* MATLAB. Para calcular a medida SSIM, utilizamos o algoritmo disponível em [1], com $C_1 = (K_1 L)^2$, $C_2 = (K_2 L)^2$, $K_1 = 0,01$, $K_2 = 0,03$ e $L = 1$, conforme sugerido em [1, 10]. A Figura 3 apresenta o gráfico com as porcentagens de acerto obtidas pelas GEB-FAMs nos experimentos a) e b) para vários valores do parâmetro α . Observemos que o melhor resultado obtido pela GEB-FAM no experimento a) foi uma porcentagem de acertos de 91,25% com $\alpha = 0,4$ e $\alpha = 0,5$. No experimento b) a GEB-FAM atingiu uma porcentagem de acertos de 81,67% com $\alpha = 1$. No pior caso, a GEB-FAM baseada no SSIM produziu uma taxa de acerto de 74% no experimento b).

Para efeitos de comparação, a Tabela 1 mostra as porcentagens de acertos de vários modelos aplicados ao reconhecimento facial usando a base de dados AR, bem como os melhores resultados obtidos pela GEB-FAM considerando outras duas medidas: a medida

Tabela 1: Porcentagem de acertos de diversos modelos aplicados ao reconhecimento de faces usando a base de dados AR.

	LRC	CRC	SRC	CESR	RSC	SSEC	NMR	SNL ₂ R2	SNL ₁ R1
a)	90,2	83,3	95,6	93,5	90,6	75,0	94,6	95,7	96,1
b)	30,4	54,6	54,8	34,8	39,8	23,1	70,4	70,2	71,2
	DNL ₂ R2	DNL ₁ R1	GEB-FAM \mathcal{S}_G		GEB-FAM \mathcal{S}_E		GEB-FAM SSIM		
a)	95,8	96,7	94,38		94,38		91,25		
b)	70,4	72,3	57,92		60,21		81,67		

de similaridade de Gregson e a medida de similaridade de Eisler e Ekman, denotadas respectivamente por \mathcal{S}_G e \mathcal{S}_E [8]. Os resultados dos onze primeiros modelos foram extraídos de [6].

Os experimentos mostraram que a GEB-FAM obteve um ótimo desempenho. De fato, no experimento a) a GEB-FAM obteve resultados competitivos com os obtidos por outros modelos da literatura. No experimento b), a porcentagem de acertos da GEB-FAM baseada na medida SSIM com $\alpha = 1$, superou os resultados obtidos pelos outros modelos. Sobretudo, a pior taxa de acerto produzida pela GEB-FAM supera os melhores resultados da literatura no problema de reconhecimento com cachecol, i.e., experimento b).

5 Considerações Finais

Neste trabalho, propusemos a utilização da medida de similaridade estrutural na definição das GEB-FAMs e aplicamos o modelo obtido à um problema de reconhecimento facial. A GEB-FAM apresentou um ótimo desempenho nos experimentos realizados, atingindo taxas de acertos competitivas com as de outros modelos no experimento a) e um resultado sempre superior ao obtido pelos outros modelos no experimento b).

Em trabalhos futuros, pretendemos estudar outras medidas de similaridades. Com efeito, comparando os resultados obtidos pela GEB-FAM utilizando a medida SSIM com o obtido considerando outras medidas de similaridade, podemos notar que a medida de similaridade escolhida pode ter grande influência no desempenho da GEB-FAM em um determinado problema. Pretendemos também investigar o desempenho da GEB-FAM considerando mais iterações em vez de um único passo.

Agradecimentos

Agradecemos o apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2015/00745-1, e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), processo 305486/2014-4.

Referências

- [1] The SSIM Index for Image Quality Assessment. Disponível em: <http://ece.uwaterloo.ca/~z70wang/research/ssim/> Acesso em Fevereiro, 2017.
- [2] B. D. Baets and H. D. Meyer. Transitivity-preserving fuzzification schemes for cardinality-based similarity measures. *European Journal of Operational Research*, 160(3):726 – 740, 2005. DOI:10.1016/j.ejor.2003.06.036.
- [3] T. D. Chiueh and R. M. Goodman. Recurrent Correlation Associative Memories. *IEEE Transactions on Neural Networks*, 2(2):275–284, 1991. DOI:10.1109/72.80338.
- [4] M. H. Hassoun and P. B. Watta. Associative Memory Networks. In E. Fiesler and R. Beale, editors, *Handbook of Neural Computation*, pages C1.3:1–C1.3:14. Oxford University Press, 1997.
- [5] Y.-J. Jeng, C. C. Yeh, and T. D. Chiueh. Exponential bidirectional associative memories. *Electronics Letters*, 26(11):717–718, 1990. DOI:10.1049/el:19900468.
- [6] L. Luo, J. Yang, J. Qian, and Y. Tai. Nuclear-l1 norm joint regression for face reconstruction and recognition with mixed noise. *Pattern Recognition*, 48(12):3811 – 3824, 2015. DOI:10.1016/j.patcog.2015.06.012.
- [7] A. M. Martinez. The AR face database. *CVC Technical Report*, 24, 1998.
- [8] A. C. Souza and M. E. Valle. Memória Associativa Bidirecional Exponencial Fuzzy Generalizada Aplicada ao Reconhecimento de Faces. In M. E. R. do Valle Mesquita; Graçaliz Pereira Dimuro; Regivan Hugo Nunes Santiago; Estevão Esmi Laureano, editor, *Recentes Avanços em Sistemas Fuzzy*, volume 1, pages 503–514. Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC), São Carlos - SP, 2016. ISBN: 978-85-8215-079-5.
- [9] A. C. Souza, M. E. Valle, and P. Sussner. Generalized Recurrent Exponential Fuzzy Associative Memories Based on Similarity Measures. In *Proceedings of the 16th World Congress of the International Fuzzy Systems Association (IFSA) and the 9th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT)*, volume 1, pages 455–462. Atlantis Press, 2015. DOI: 10.2991/ifsa-eusflat-15.2015.66.
- [10] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4):600–612, 2004. DOI:10.1109/TIP.2003.819861.
- [11] L. Xuecheng. Entropy, distance measure and similarity measure of fuzzy sets and their relations. *Fuzzy Sets and Systems*, 52(3):305–318, 1992. DOI:10.1016/0165-0114(92)90239-Z.
- [12] L. A. Zadeh. Fuzzy Sets. *Information and Control*, 8(3):338–353, 1965. DOI:10.1016/S0019-9958(65)90241-X.