

# Memórias Associativas Recorrentes Exponenciais Fuzzy Generalizadas Aplicadas à Classificação de Padrões

Aline Cristina de Souza<sup>1</sup>

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

Marcos Eduardo Valle<sup>2</sup>

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

**Resumo.** Memórias associativas são modelos matemáticos biologicamente inspirados para o armazenamento e recordação de um conjunto finito de itens. As memórias associativas recorrentes exponenciais *fuzzy* generalizadas (GRE-FAMs) podem ser efetivamente utilizadas para o armazenamento e recordação de uma família finita de conjuntos *fuzzy*. Neste trabalho, descrevemos como uma GRE-FAM pode ser aplicada em um problema de classificação de padrões. Experimentos computacionais mostraram que a acurácia obtida pelos classificadores definidos com base nas GRE-FAMs é competitiva comparada a outros classificadores da literatura.

**Palavras-chave.** Memórias Associativas, Medidas de Similaridade, Classificação de Padrões.

## 1 Introdução

Memórias associativas são modelos matemáticos motivados pela capacidade do cérebro humano de armazenar e recordar informações por meio de associações [2,4]. Tais modelos têm como objetivo armazenar um conjunto de associações  $\mathcal{X} = \{(\mathbf{x}^1, \mathbf{y}^1), \dots, (\mathbf{x}^p, \mathbf{y}^p)\}$ , chamado conjunto das memórias fundamentais. Além disso, espera-se que uma memória associativa recupere um item armazenado  $\mathbf{y}^\xi$  mesmo a partir da apresentação de uma versão corrompida  $\tilde{\mathbf{x}}^\xi$  de  $\mathbf{x}^\xi$ . No caso em que  $\mathbf{x}^\xi = \mathbf{y}^\xi$ , para todo  $\xi = 1, \dots, p$ , a memória é dita autoassociativa. Memórias associativas projetadas para o armazenamento e recordação de conjuntos *fuzzy* são chamadas memórias associativas *fuzzy* [5,8].

As memórias associativas recorrentes exponenciais *fuzzy* generalizadas (GRE-FAMs, do inglês *generalized recurrent exponential fuzzy associative memories*) podem ser efetivamente utilizadas para implementar uma memória autoassociativa para o armazenamento e recordação de uma família finita de conjuntos *fuzzy* [7].

Um problema de classificação de padrões consiste em associar a cada padrão um rótulo, o qual representa sua classe. Para sintetizar um classificador, geralmente utilizamos um conjunto de padrões já rotulados, denominado conjunto de treinamento. Neste trabalho, apresentaremos uma aplicação das GRE-FAMs a problemas de classificação de padrões.

---

<sup>1</sup>s.alinedesouza@gmail.com

<sup>2</sup>valle@ime.unicamp.br

Este trabalho está organizado da seguinte maneira: na próxima seção relembramos alguns conceitos importantes e apresentamos as memórias associativas recorrentes exponenciais *fuzzy* generalizadas. Na Seção 3, descrevemos como as GRE-FAMs podem ser aplicadas a problemas de classificação de padrões. Os resultados dos experimentos computacionais realizados para avaliar o desempenho dos classificadores baseados nas GRE-FAMs são apresentados na Seção 4. Finalizamos o trabalho na Seção 5 com as considerações finais.

## 2 Memórias Associativas Recorrentes Exponenciais *Fuzzy* Generalizadas

Iniciaremos esta seção recordando alguns conceitos importantes para o desenvolvimento do trabalho, incluindo as definições de conjuntos *fuzzy* e medidas de similaridade. Posteriormente, apresentaremos a definição das memórias associativas recorrentes exponenciais *fuzzy* generalizadas.

Um subconjunto *fuzzy*  $X$  de um universo  $U$  é definido por meio de sua função de pertinência  $X : U \rightarrow [0, 1]$ , de forma que, dado um elemento  $u \in U$ ,  $X(u)$  indica o grau de pertinência de  $u$  ao subconjunto *fuzzy*  $X$ . Nos casos em que o universo  $U$  é finito, digamos  $U = \{u_1, \dots, u_n\}$ , um subconjunto *fuzzy*  $X$  de  $U$  pode ser identificado com um vetor  $X = [X(u_1), \dots, X(u_n)]^T$  pertencente ao hipercubo unitário  $n$ -dimensional  $[0, 1]^n$ . Denotaremos por  $\mathcal{F}(U)$  o conjunto dos subconjuntos *fuzzy* de  $U$  e por  $\mathcal{P}(U)$  o conjunto das partes de  $U$ .

Dados  $A, B \in \mathcal{F}(U)$ , dizemos que  $A$  é subconjunto de  $B$  e escrevemos  $A \subset B$ , se  $A(u) \leq B(u)$ , para todo  $u \in U$ . Além disso, o complemento de um conjunto *fuzzy*  $A \in \mathcal{F}(U)$ , denotado por  $\bar{A}$ , é definido por  $\bar{A}(u) = 1 - A(u)$ , para todo  $u \in U$ .

Uma medida de similaridade é uma função que associa a cada par de conjuntos *fuzzy* um número pertencente ao intervalo  $[0, 1]$ , o qual indica o quanto esses conjuntos são iguais. Neste trabalho, adotaremos uma versão normalizada da definição proposta por Xuecheng [11]:

**Definição 2.1** (Medidas de Similaridade). *Uma medida de similaridade é uma função  $\mathcal{S} : \mathcal{F}(U) \times \mathcal{F}(U) \rightarrow [0, 1]$  que satisfaz, para quaisquer conjuntos *fuzzy*  $A, B, C, D \in \mathcal{F}(U)$ , as seguintes propriedades:*

1.  $\mathcal{S}(A, B) = \mathcal{S}(B, A)$ .
2.  $\mathcal{S}(A, A) = 1$ .
3. Se  $A \subseteq B \subseteq C \subseteq D$ , então  $\mathcal{S}(A, D) \leq \mathcal{S}(B, C)$ .
4.  $\mathcal{S}(A, \bar{A}) = 0$ , para todo subconjunto clássico  $A \in \mathcal{P}(U)$ .

Além disso, dizemos que  $\mathcal{S}$  é uma **medida de similaridade forte** se  $\mathcal{S}(A, B) = 1$  implica  $A = B$ .

As memórias associativas recorrentes exponenciais *fuzzy* generalizadas (GRE-FAMs, do inglês *generalized recurrent exponential fuzzy associative memories*) são projetadas para o armazenamento e a recordação de uma família finita de conjuntos *fuzzy*. Especificamente, dado um conjunto *fuzzy* inicial  $X_0 \in \mathcal{F}(U)$ , as GRE-FAMs produzem uma sequência de conjuntos *fuzzy*  $X_t \in \mathcal{F}(U)$ , os quais são obtidos a partir de uma combinação afim das memórias fundamentais conforme a definição a seguir [7]:

**Definição 2.2** (GRE-FAM). *Considere uma família finita de memórias fundamentais  $\mathcal{A} = \{A^1, A^2, \dots, A^p\} \subseteq \mathcal{F}(U)$ , um número real  $\alpha > 0$  e uma medida de similaridade  $\mathcal{S} : \mathcal{F}(U) \times \mathcal{F}(U) \rightarrow [0, 1]$ . Além disso, considere  $C = (c_{ij})$  a matriz definida por  $c_{ij} = e^{\alpha \mathcal{S}(A^i, A^j)}$ , para todo  $i, j = 1, \dots, p$  e defina  $G = C^{-1}$ . Dado um conjunto *fuzzy* inicial,  $X_0 \in \mathcal{F}(U)$ , a GRE-FAM produz uma sequência de conjuntos *fuzzy*  $\{X_t\}_{t \geq 0}$  definidos, para quaisquer  $u \in U$  e  $t = 0, 1, \dots$ , por:*

$$X_{t+1}(u) = \varphi \left( \sum_{\xi=1}^p w_{\xi t} A^\xi(u) \right), \tag{1}$$

em que os pesos  $w_{\xi t}$  são dados pela expressão

$$w_{\xi t} = \frac{\sum_{\mu=1}^p g_{\xi \mu} e^{\alpha \mathcal{S}(A^\mu, X_t)}}{\sum_{\eta=1}^p \sum_{\mu=1}^p g_{\eta \mu} e^{\alpha \mathcal{S}(A^\mu, X_t)}} \tag{2}$$

e a função  $\varphi : \mathbb{R} \rightarrow [0, 1]$ , definida por

$$\varphi(x) = \max\{0, \min\{1, x\}\}, \tag{3}$$

garante que  $X_{t+1}(u) \in [0, 1]$ , para quaisquer  $t \geq 0$  e  $u \in U$ .

**Observação 2.1.** *Na definição 2.2, consideramos  $G = C^{-1}$ , pois dessa forma, as memórias fundamentais são pontos fixos da GRE-FAM [9]. Caso a matriz  $C$  não seja invertível, consideramos  $G = C^\dagger$ , em que  $C^\dagger$  denota a pseudo-inversa de  $C$  [3].*

### 3 Classificação de Padrões utilizando GRE-FAMs

Em problemas de classificação, o objetivo é atribuir uma determinada classe a um dado padrão  $X$ . Tal tarefa é realizada com base em um conjunto de padrões já rotulados, ao qual chamaremos de conjunto de treinamento. Nesta seção, inspirados pelos classificadores de representação esparsa [10], definiremos um classificador com base nas GRE-FAMs. Em outras palavras, associaremos cada subconjunto *fuzzy*  $X$  de  $U$  a uma classe  $\ell \in \mathcal{L}$  utilizando as GRE-FAMs.

Consideremos o conjunto de treinamento

$$\mathcal{A}_{\mathcal{L}} = \{(A^\xi, \ell_\xi) : \xi = 1, \dots, p\} \subseteq \mathcal{F}(U) \times \mathcal{L}, \tag{4}$$

onde  $\mathcal{L}$  é um conjunto de rótulos e  $A^\xi$  são subconjuntos *fuzzy* de  $U$  distintos e não vazios. Os modelos de classificadores de representação esparsa [10] se baseiam na hipótese de que uma amostra  $X$  de uma determinada classe  $i \in \mathcal{L}$  pode ser escrita, aproximadamente, como combinação linear dos padrões de treinamento pertencentes a esta classe, isto é,

$$X(u) = \sum_{\xi: \ell_\xi=i} \alpha_\xi A^\xi(u) = \sum_{\xi=1}^p \alpha_\xi A^\xi(u), \quad \forall u \in U, \quad (5)$$

em que  $\alpha_\xi = 0$ , se  $\ell_\xi \neq i$ .

Agora, se  $X$  é uma versão ruidosa de um padrão pertencente à classe  $i$ , esperamos que o padrão  $X_1$ , produzido pela GRE-FAM em uma iteração com  $X_0 = X$ , também pertença a esta classe. Por um lado, das equações (1) e (2) com  $t = 0$ , temos que:

$$X_1(u) = \varphi \left( \sum_{\xi=1}^p w_{\xi 0} A^\xi(u) \right), \quad \forall u \in U. \quad (6)$$

Por outro lado, inspirados pelos modelos de representação esparsa, esperamos que

$$X_1(u) \approx \sum_{\xi=1}^p \alpha_\xi A^\xi(u), \quad \forall u \in U, \quad (7)$$

com  $\alpha_\xi = 0$ , se  $\ell_\xi \neq i$ .

Motivados pelas equações (6) e (7), definimos os coeficientes  $\alpha_\xi$ ,  $\xi = 1, \dots, p$  em (7) da seguinte forma:

$$\alpha_\xi = w_{\xi 0} \chi_i(\ell_\xi), \quad (8)$$

em que  $\chi_i : \mathcal{L} \rightarrow \{0, 1\}$  é definida por  $\chi_i(x) = 1$ , se  $x = i$  e  $\chi_i(x) = 0$  caso contrário. Assim, temos que  $\alpha_\xi = w_{\xi 0}$ , se  $\ell_\xi = i$  e  $\alpha_\xi = 0$ , se  $\ell_\xi \neq i$ .

Dessa forma, se o padrão  $X$  pertence a classe  $i$ , teremos

$$X_1(u) \approx \sum_{\xi=1}^p w_{\xi 0} \chi_i(\ell_\xi) A^\xi(u), \quad \forall u \in U. \quad (9)$$

Na prática, porém, não sabemos a que classe um dado padrão  $X$  pertence. Então, atribuímos a  $X$  a classe  $\ell$  que minimiza a distância entre  $X_1$  e as combinações lineares  $\sum_{\xi=1}^p w_{\xi 0} \chi_\ell(\ell_\xi) A^\xi$ . Formalmente, atribuímos a  $X$  a classe  $\ell$ , em que  $\ell$  satisfaz:

$$d_2 \left( X_1, \sum_{\xi=1}^p w_{\xi 0} \chi_\ell(\ell_\xi) A^\xi \right) \leq d_2 \left( X_1, \sum_{\xi=1}^p w_{\xi 0} \chi_i(\ell_\xi) A^\xi \right), \quad \forall i \in \mathcal{L}, \quad (10)$$

onde  $d_2$  denota a distância  $L_2$ .

## 4 Experimentos Computacionais

Experimentos computacionais foram realizados para avaliar a acurácia do classificador baseado na GRE-FAM. Consideramos o parâmetro  $\alpha = 15$  e a matriz  $G = C^{-1}$  conforme a Definição 2.2. Utilizamos a medida de similaridade de Gregson [12] definida por:

$$S_G(A, B) = \frac{\sum_{j=1}^n \min\{a_j, b_j\}}{\sum_{j=1}^n \max\{a_j, b_j\}}. \quad (11)$$

Realizamos os experimentos com seis conjuntos de dados disponíveis em [6], a saber: *Haberman survival*, *Liver disorders*, *Pima Indians diabetes*, *Breast Cancer Wisconsin (Original)*, *Heart disease* e *Hepatitis disease*.

Primeiramente, cada conjunto de dados foi dividido em duas partes, sendo uma delas, formada por 70% dos padrões, utilizada como conjunto de treinamento e os 30% restantes utilizados como conjunto de teste. Depois, aplicamos uma transformação nos dados a fim de representá-los por conjuntos *fuzzy*. Especificamente, dado um par  $(\mathbf{v}, \ell)$  pertencente a um conjunto de dados, associamos  $\mathbf{v} = [v_1, \dots, v_n]^T$  ao conjunto *fuzzy*  $X = [x_1, \dots, x_n]^T$  definido por:

$$x_i = \frac{1}{1 + e^{-(v_i - \mu_i)/\sigma_i}} \in [0, 1], \quad \forall i = 1, \dots, n, \quad (12)$$

onde  $\mu_i$  e  $\sigma_i$  representam, respectivamente, a média e o desvio padrão da  $i$ -ésima componente de todos os padrões pertencentes ao conjunto de treinamento. Dessa forma, obtivemos como conjunto de treinamento uma família de conjuntos *fuzzy* correspondentes a 70% dos dados.

A Tabela 1 mostra a acurácia do classificador baseado na GRE-FAM, para o conjunto de teste, em cada um dos seis problemas citados acima, bem como a acurácia de outros 21 classificadores da literatura considerados anteriormente por Aldape-Pérez et al. em [1]. A última coluna da tabela é formada pelas médias das acurácias obtidas por cada classificador nos seis problemas. Os valores da acurácia obtidos pelos 21 primeiros classificadores, bem como maiores detalhes sobre os conjuntos de dados e sobre os outros classificadores considerados na Tabela 1 podem ser encontrados em [1]. Os maiores valores de acurácia para cada problema estão destacados em negrito.

Os resultados da Tabela 1 mostram que o classificador baseado na GRE-FAM apresentou bom desempenho. De fato, o classificador baseado na GRE-FAM obteve a maior acurácia em três dos seis problemas de classificação, bem como a maior média considerando as acurácias obtidas em todos os problemas. Foram realizados também experimentos considerando outros problemas de classificação, os resultados podem ser encontrados em [9].

## 5 Considerações Finais

Inicialmente, apresentamos as memórias associativas recorrentes exponenciais *fuzzy* generalizadas [7]. Resumidamente, dado um conjunto *fuzzy* inicial, as GRE-FAMs produzem

Tabela 1: Acurácia de classificação obtida para o conjunto de teste utilizando 70% dos dados como conjunto de treinamento. A acurácia dos 21 primeiros algoritmos foram extraídos de [1].

Algorithm	Haberman	Liver	Diabetes	Breast	Heart	Hepatitis	Average
1. AMBC	<b>77.30</b>	59.59	70.18	97.64	83.33	<b>84.86</b>	78.82
2. AdaBoostM1	73.52	68.98	74.08	95.16	82.96	62.58	76.21
3. Bagging	73.20	72.17	75.13	95.75	81.11	64.51	76.98
4. BayesNet	72.22	58.55	74.73	97.36	82.96	69.03	75.81
5. Dagging	73.85	58.26	73.95	96.63	83.33	65.16	75.20
6. DecisionTable	72.22	58.55	74.86	93.99	80.37	69.67	74.94
7. DTNB	72.22	58.55	75.52	97.07	82.59	65.80	75.29
8. FT	73.20	69.85	77.21	96.92	82.22	57.41	76.14
9. LMT	73.85	71.59	76.69	96.63	<b>84.44</b>	63.87	77.85
10. Logistic	74.18	66.37	76.69	96.48	83.33	61.29	76.39
11. MultiClassClassifier	74.18	66.37	76.69	96.48	83.33	61.29	76.39
12. NaiveBayes	75.49	56.23	75.78	96.33	83.33	72.25	76.57
13. NaiveBayesSimple	75.49	55.07	75.78	96.19	84.07	70.32	76.15
14. NveBayesUpdateable	75.49	56.23	75.78	96.33	83.33	72.25	76.57
15. RandomCommittee	64.70	68.40	73.30	95.60	80.37	62.58	74.16
16. RandomForest	67.64	66.37	73.56	96.33	78.88	60.64	73.90
17. RandomSubSpace	74.50	67.53	73.43	95.90	78.14	61.93	75.24
18. RBFNetwork	73.52	61.73	74.34	96.33	82.59	71.61	76.69
19. RotationForest	74.18	70.72	75.39	97.36	83.70	63.22	77.43
20. SimpleLogistic	73.85	67.82	76.69	96.63	<b>84.44</b>	65.16	77.43
21. SMO	73.52	57.68	77.47	96.48	84.07	64.51	75.62
22. GRE-FAM	70.65	<b>75.96</b>	<b>79.65</b>	<b>98.10</b>	78.89	80.85	<b>80.68</b>

recursivamente uma sequência de conjuntos *fuzzy* obtidos a partir de uma combinação afim das memórias fundamentais.

Neste trabalho, motivados pelos modelos de representação esparsa, descrevemos como uma GRE-FAM pode ser aplicada a problemas de classificação de padrões. Apresentamos também os resultados dos experimentos computacionais obtidos em seis problemas de classificação disponíveis em [6]. Tais resultados mostraram que a acurácia obtida pelo classificador baseado nas GRE-FAMs é competitiva se comparada a de outros classificadores da literatura [1]. De fato, o classificador baseado nas GRE-FAMs obteve a maior acurácia em três dos seis problemas considerados, bem como a maior acurácia média.

## 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] M. Aldape-Pérez, C. Yáñez-Márquez, O. Camacho-Nieto, and A. J. Argüelles-Cruz. An associative memory approach to medical decision support systems. *Computer methods and programs in biomedicine*, 106(3):287–307, 2012. DOI: 10.1016/j.cmpb.2011.05.002.
- [2] J. Austin. Associative Memory. In E. Fiesler and R. Beale, editors, *Handbook of Neural Computation*, pages F1.4:1–F1.4:7. Oxford University Press, 1997.
- [3] G. Golub and C. van Loan. *Matrix Computations*. John Hopkins University Press, Baltimore, MD, 3th edition, 1996.
- [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] B. Kosko. *Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*. Prentice Hall, Englewood Cliffs, NJ, 1992.
- [6] M. Lichman. UCI machine learning repository, 2013.
- [7] 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.
- [8] P. Sussner and M. E. Valle. Fuzzy Associative Memories and Their Relationship to Mathematical Morphology. In W. Pedrycz, A. Skowron, and V. Kreinovich, editors, *Handbook of Granular Computing*, chapter 33, pages 733–754. John Wiley and Sons, Inc., New York, 2008.
- [9] M. E. Valle and A. C. Souza. Pattern classification using generalized recurrent exponential fuzzy associative memories. A ser publicado.
- [10] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2):210–227, Feb 2009. DOI: 10.1109/TPAMI.2008.79.
- [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] R. Zwick, E. Caristein, and D. V. Budescu. Measures of Similarity Among Fuzzy Concepts: A Comparative Analysis. *International Journal of Approximate Reasoning*, 1(2):221–242, apr 1987. DOI: 10.1016/0888-613X(87)90015-6.