

ỨNG DỤNG MẠNG MỜ - NORON TRONG NHẬN DẠNG VÀ ĐIỀU KHIỂN HỆ PHI TUYẾN

Phan Thanh Tùng- Đại học Thủy lợi

Tóm tắt: Mạng xuyên tâm tổng quát (GRBFN) do M.Azeem đưa ra giúp ta có thể loại bỏ đi vài biến hoặc vài luật trong mạng mờ noron khi nhận dạng một hệ phi tuyến. Mạng mờ-noron hồi quy RNFN của Zhang có khả năng nhận dạng, dự báo tầm xa và điều khiển tốt các đối tượng động học phi tuyến. Bài báo kết hợp ưu điểm của hai mạng trên ta xây dựng mạng mờ-noron để ứng dụng nhận dạng và điều khiển cho đối tượng phức tạp nhiều vào ra. Mạng mờ-noron có hàm liên thuộc mờ tổng quát GFM và cấu trúc mạng hồi quy để mô hình hóa hoặc dự báo hệ thống. Ngoài ra ứng dụng kết quả mạng mờ noron để xây dựng bộ điều khiển dự báo tầm xa dựa trên thuật toán GPC để điều khiển đối tượng động học phi tuyến nhiều vào một ra MISO.

Từ khóa: Generalized radial basis function network (GRBFN), Recurrent Neuro-Fuzzy Network (RNFN), generalized fuzzy model (GFM).

I. GIỚI THIỆU

Mạng noron được chỉ ra có khả năng xấp xỉ hàm rất tốt bằng cách dựa vào tập dữ liệu vào ra. Tuy nhiên một hạn chế khả năng của mạng noron truyền thống là rất khó chứng minh tính bền vững khi sử dụng tập dữ liệu mà ta không hiểu biết được. Một cách tiếp cận để cải tiến tính bền vững của mô hình là kết hợp đồng thời hiểu biết về mô hình và tập dữ liệu vào ra. Thực tế, một quá trình phi tuyến có thể được tuyến tính hóa từng phần xung quanh điểm làm việc riêng lẻ và mô hình tuyến tính hóa cục bộ có hiệu quả trong lân cận điểm làm việc đó.

Trong những đối tượng phi tuyến mà không mang tính chất động học thì cấu trúc mạng mờ noron truyền thống cho kết quả huấn luyện tốt và thời gian huấn luyện nhanh chóng như được chỉ ra ở [1]. Việc xây dựng mạng xuyên tâm tổng quát GRBF do M.Azeem đưa ra giúp ta có thể loại bỏ đi vài biến hoặc vài luật trong mạng mờ noron khi nhận dạng một đối tượng phi tuyến. Nhược điểm: Mạng GRBF chưa ứng dụng được cho nhận dạng và điều khiển đối tượng động học phi tuyến.

Đối tượng có tính động học có thể được xấp xỉ tốt bởi mạng noron hồi quy [2] và [3]. Zhang

[4] đã đưa ra một dạng của mạng mờ noron hồi quy trong đó đầu ra của mạng được phản hồi tới đầu vào qua một vài phần tử trễ. Cả hiểu biết quá trình và dữ liệu vào ra được sử dụng để xây dựng mô hình nhận dạng và mô hình dự báo. Kiến thức quá trình được dùng để phân chia tính phi tuyến quá trình thành nhiều vùng làm việc cục bộ và giúp đỡ cho việc khởi tạo các trọng số mạng tương ứng. Dữ liệu vào ra quá trình được sử dụng để huấn luyện mạng. Hàm liên thuộc của chế độ hoạt động cục bộ được nhận biết và mô hình cục bộ được tìm ra trong suốt quá trình huấn luyện. Do đó, mạng mờ noron hồi quy khi huấn luyện thành công có thể cung cấp các mô hình nhận dạng hoặc mô hình dự báo tốt.

Mô hình mạng mờ noron hồi quy có thể được sử dụng để xây dựng mô hình dự báo có chứa các mô hình tuyến tính cục bộ có dạng chuẩn điều khiển dự báo tự hồi quy có tích phân CARIMA.

$$y_{k+1} + A_1 y_k + \dots + A_{n+1} y_{k-n} = b_1 \Delta u_k + b_2 \Delta u_{k-1} + \dots + b_n \Delta u_{k-n+1} \quad (1)$$

Với mỗi mô hình cục bộ (1) ta có thể dùng bộ điều khiển dự báo GPC [5]. Các bộ điều khiển cục bộ này được kết hợp qua giải mờ trọng tâm COG để xác định mô hình phi tuyến toàn cục.

Mạng RNFN của Zhang có khả năng nhận dạng, dự báo tầm xa và điều khiển tốt các đối tượng động học phi tuyến nhưng nhược điểm là mạng hồi quy nên thời gian huấn luyện mạng lâu không đáp ứng thời gian thực.

Bài báo này nhằm đưa ra mạng mờ neuron GRFN khắc phục các hạn chế trên và trình bày một số ví dụ mô phỏng. Bài báo được chia làm 4 phần: Phần I là giới thiệu tổng quan. Phần II xây dựng mạng mờ-neuron GRFN. Phần III nêu các ứng dụng mạng GRFN trong nhận dạng, xây dựng mô hình dự báo và cuối cùng là sử dụng kết hợp với phương pháp điều khiển dự báo GPC để điều khiển cho đối tượng MISO. Cuối cùng kết luận ở phần IV.

II. MẠNG GRFN

A. Mô hình GFM

Mỗi quy tắc trong mô hình GFM ánh xạ tập mờ con trong không gian đầu vào $A^k \subset R^{n_k}$ thành tập mờ con trong không gian đầu ra $B^k \subset R$ và có dạng :


R^k : Nếu x^k là A^k thì y là $B^k(f^k(x^k), v^k)$ (2)

Với $k=1..m$ luật. Mỗi luật có vector tín hiệu vào $x^k \subseteq x$ vector tín hiệu vào hệ thống đầy đủ. A_i^k và B^k là kí hiệu ngôn ngữ của tập mờ mô tả trạng thái biến đầu vào x_i và biến đầu ra y theo định tính.

Hàm Gauss có dạng tổng quát cho biến tiền đề A_i^k như sau :

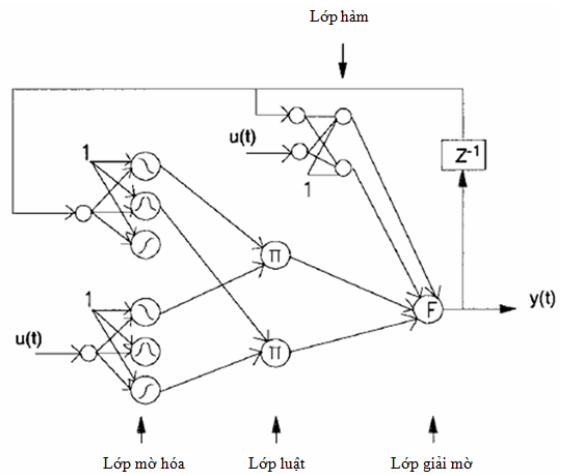
$$\mu_i^k(x_i) = \exp\left(-\left|\frac{x_i - c_{ki}}{\sigma_{ki}}\right|^{l_{ki}}\right) = \exp(-|a_{ki} \cdot (x_i - c_{ki})|^{l_{ki}}) \quad (3)$$

c_{ki} là trọng tâm, σ_{ki} hay $(1/a_{ki})$ là bề rộng, l_{ki} điều khiển hình dạng hàm liên thuộc biến



vào x_i của tập mờ tương ứng với luật k . v_k là tham số.


B. Kiến trúc mạng hồi quy




Hình 1: Kiến trúc mạng RNFN

Mạng hồi quy RNFN gồm 5 lớp : lớp đầu vào, lớp mờ hóa (Fuzzification) , lớp luật hợp thành (Rules) , lớp hàm hay còn gọi là lớp mô hình cục bộ (Function), và lớp giải mờ (Defuzzification) được chỉ ra trong hình 1.

Ta xây dựng mạng GRFN có kiến trúc mạng RNFN và hàm liên thuộc tổng quát GFM. Mạng GRFN giúp ta có thể nhận dạng được đối tượng động học phi tuyến. Ngoài ra mạng truyền thẳng bao giờ cũng huấn luyện nhanh hơn mạng hồi quy nên ta cải biến mạng GRFN từ hồi quy sang truyền thẳng bằng cách lấy tập mẫu đầu ra làm thành đầu vào ảo mạng mờ neuron khiến thời gian huấn luyện mạng nhanh hơn mà vẫn cho kết quả điều khiển đối tượng tốt.



Hình 2a, b: Hàm liên thuộc biến tiền đề trước khi huấn luyện $A_1^1 - A_1^6$ và $A_2^1 - A_2^6$ tương ứng



Hình 3(a). Quá trình huấn luyện và (b)Đáp ứng đầu ra mạng mờ-noron, giá trị mẫu và sai lệch sau khi huấn luyện

III. ỨNG DỤNG MẠNG GRFN

A. Trong nhận dạng

Xét đối tượng phi tuyến có 2 đầu vào là $x=\{x_1, x_2\}$ và 1 đầu ra y được mô tả bởi phương trình (4) dưới đây. Ta sẽ mô hình hóa đối tượng bằng cách chia đối tượng thành 6 vùng tương ứng với 6 luật. Xem xét hàm sau tạo dữ liệu đầu ra:

$$4y = 2 + 2x_1^{1.5} \cos(3y) + 1.5 \sin 3x_2 - \frac{dy}{dt} \quad \text{với } 0 \leq x_1, x_2 \leq 3 \quad (4)$$

Với x là biến liên tục ngẫu nhiên không tương quan với nhau.

Ta khởi tạo các tham số của mạng ngẫu nhiên và chia thành 6 luật như dưới đây, nếu kết quả huấn luyện chưa tốt thì ta tăng dần số luật lên hoặc tăng bậc mô hình cục bộ lên.

Đường cong mờ được dùng để khởi tạo mạng và các luật như sau (hình 2a,b) :

R¹: Nếu x_1 là $A_1^1 \wedge x_2$ là A_2^1 thì y là $B^1 (f^1(x, y(t-1)), 9.5861)$.

R²: Nếu x_1 là A_1^2 thì y là $B^2 (f^2(x, y(t-1)), 10.2096)$.

R³: Nếu x_2 là A_2^3 thì y là $B^3 (f^3(x, y(t-1)), 9.4928)$.

R⁴: Nếu x_2 là A_2^4 thì y là $B^4 (f^4(x, y(t-1)), 11.2521)$.

R⁵: Nếu x_2 là A_2^5 thì y là $B^5 (f^5(x, y(t-1)), 10.4430)$.

R⁶: Nếu x_1 là $A_1^6 \wedge x_2$ là A_2^6 thì y là $B^6 (f^6(x, y(t-1)), 10.2778)$.


R^k: Nếu x_1 là $A_1^k \wedge x_2$ là A_2^k thì y là $B^k (f^k(x, y(t-1)), 10.28)$.

Với $k=1:6$ là thứ tự luật; $f^k(x, y(t-1))$ là mô hình cục bộ của x và y ,

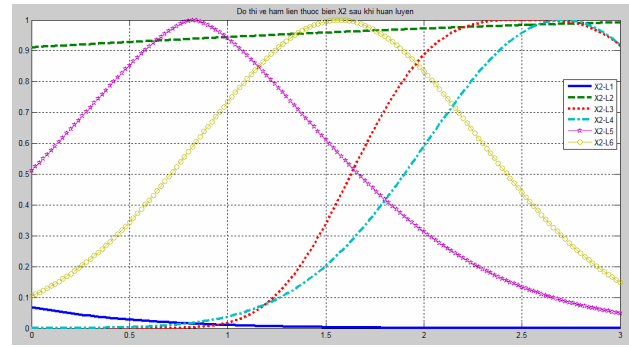
Hình (3a) mô tả quá trình huấn luyện làm giảm giá trị hàm mục tiêu J xuống còn 4.10^{-6} . Ta thấy chỉ sau khoảng 20 lần huấn luyện là cho kết quả đạt yêu cầu.

Nhận xét ta thấy các biến mà có hàm liên thuộc mà gần bằng 1 trong toàn bộ dải xét thì trong phép tích mờ có thể bỏ đi. Từ hình 4a và 4b ta thấy x_1 ở luật 3,4,5 và x_2 ở luật 2 xấp xỉ bằng 1 trong toàn bộ dải quan sát nên ta có thể loại bỏ ra khỏi mệnh đề tiền đề mà không ảnh hưởng đến kết quả.

Như vậy bộ luật sau khi được huấn luyện sẽ như sau (hình 4a,b):



(a)



(b)

Hình 4(a,b). Đồ thị hàm liên thuộc biến $X1$ và $X2$ sau khi huấn luyện

B. Ứng dụng trong điều khiển

Tương tự nhận dạng, mạng mờ noron còn dùng làm mô hình dự báo tầm xa. Cấu trúc liên kết mạng mờ noron đưa ra cùng với mô hình tuyến tính cục bộ cho phép xây dựng bộ điều khiển dự báo tổng quát GPC cho mỗi mô hình dự báo tuyến tính địa phương. Đầu ra bộ điều khiển toàn cục đạt được bằng cách kết hợp đầu ra mô hình con qua phương pháp giải mờ trọng tâm COG. Điều này minh họa rằng để μ_i và u_i là hàm liên thuộc và đầu ra bộ điều khiển cục bộ cho vùng làm việc thứ i , và tính ra giá trị đầu ra toàn cục u như sau :

$$u = \frac{\sum_{i=1}^{nr} \mu_i \cdot u_i}{\sum_{i=1}^{nr} \mu_i} \quad (5)$$

Mô hình tuyến tính cục bộ gián đoạn thời gian của Jang [4] có nhược điểm của mô hình trên là tính giá trị u_k hay Δu_k từ giá trị y_k cùng thời điểm. Điều này là phi thực tế vì ta chưa thể đo được đầu ra ở thời điểm k khi đang tính toán tín hiệu điều khiển. Vì vậy phương trình phải sửa lại thành:

$$y(t) = a_1 \cdot y(t-2) + \dots + a_{no} \cdot y(t-no-1) + b_1 \cdot u(t-1) \dots + b_{ni} \cdot u(t-ni). \quad (6)$$

Điều này là hợp lý vì tín hiệu đầu ra đo được không thể quay trở lại để tính toán tín hiệu điều khiển mà nó phải trễ đi một vài bước vì do bản chất vật lý vốn có của thiết bị đo, của truyền dữ liệu và vi xử lý.

Ví dụ 2 : Thiết kế bộ điều khiển cho đối tượng nêu ở ví dụ 1.

Sử dụng mạng mờ noron để xây dựng mô hình dự báo được chia thành 8 vùng cục bộ cho

đối tượng ở ví dụ 1 như sau : Vùng 1 :

$$y_{k+1} = 0.50y_{k-1} + 0.47y_{k-2} - 0.98y_{k-3} = 0.75\Delta u_k^1 - 2.69\Delta u_k^2 - 0.22\Delta u_{k-1}^1 - 0.15\Delta u_{k-1}^2$$

Vùng 2 :

$$y_{k+1} = 0.4644y_{k-1} - 0.1646y_{k-2} - 0.3711y_{k-3} = 0.4180\Delta u_k^1 + 1.4127\Delta u_k^2 + 0.7770\Delta u_{k-1}^1 + 1.3325\Delta u_{k-1}^2$$


Ứng với mô hình dự báo cục bộ cho mỗi vùng ta sẽ tính ra được tín hiệu điều khiển cục bộ cho mỗi vùng và đầu ra toàn cục hay tín hiệu điều khiển đưa vào đối tượng sẽ được tính toán dựa theo [5].

Kết quả mô phỏng sau khi được điều khiển như hình 5a,b.


IV. KẾT LUẬN

Như vậy ta đã điều khiển được đối tượng động học phi tuyến có nhiều đầu vào một đầu ra MISO vốn luôn khó khăn trong việc sử dụng các phương pháp điều khiển thông thường. Bài báo đã mở rộng minh chứng được khả năng sử dụng mạng mờ noron để điều khiển đối tượng không chỉ là gồm những đặc tính tuyến tính từng đoạn mà còn có thể là phi tuyến. Đồng thời ta đã chỉnh sửa lại phương pháp điều khiển GPC cho phù hợp logic thực tiễn. Mạng hồi quy mà Zhang dùng để xây dựng mô hình dự báo thường có thời gian huấn luyện rất lâu và chậm hội tụ. Ở đây bài báo đã nêu cách thức để huấn luyện mạng dự báo nhanh hơn mà vẫn đáp ứng được kết quả tốt nhờ sử dụng chính tín hiệu mẫu đầu ra quay lại làm tín hiệu đầu vào ảo. Cách thức này đã được Narendra nêu

trong tài liệu [6] và nó giúp cho mô hình có thể phù hợp với đối tượng online.



(a)



(b)

Hình 5 (a) Đáp ứng đối tượng
(b) tín hiệu điều khiển

Tài liệu tham khảo

- [1] –M.F. Azeem : “Generalization of Adaptive Neuro-Fuzzy Inference Systems”- IEEE TRANS.NEURAL NETWORKS, VOL. 11, NO. 6, NOVEMBER (2000)
- [2] H. T. Su, T. J. McAvoy, and P. Werbos, “Long-term prediction of chemical processes using recurrent neural networks: A parallel training approach,” *Ind. Eng. Chemical Res.*, vol. 31, pp. 1338–1352, (1992).
- [3] P. J. Werbos, “Backpropagation through time: what it does and how to do it,” *Proc. IEEE*, vol. 78, pp. 1550–1560, (1990).
- [4]-Zhang and Morris: “Recurrent Neuro-Fuzzy Networks for Nonlinear Process Modeling”- IEEE TRANS.NEURAL NETWORKS, VOL. 10, NO. 2, MARCH (1999).
- [5]- J.A.Rossiter: “Model- Based Predictive Control - A Practical Approach “CRC Press LLC, 2000 N.W. Corporate Blvd.
- [6]- K. S. Narendra and K. Parthasarathy, “Identification and control of dynamical systems using neural networks,” *IEEE Trans. Neural Networks*, vol. 1, pp. 4–27, (1990).
- [7] – Nguyễn Trọng Thuận: “Điều khiển logic và ứng dụng”
- [8] – Nguyễn Doãn Phước, Phan Xuân Minh : “ Lý thuyết điều khiển mờ”.

Tác giả bài báo :

Kĩ sư Phan Thanh Tùng- Đại học Thủy lợi. Số điện thoại : 0913066210.Mail : phanthanhtung86@gmail.com.

Abstract

NEURO-FUZZY NETWORK FOR IDENTIFICATION AND CONTROL OF NONLINEAR SYSTEMS

Unnecessary rule can be eliminated from a rule base and an insignificant variable from a learned rule can be removed using the parameters of learned GRBF network when identified nonlinear system. Jang proposed the recurrent neuro-fuzzy network RNFN which have been shown to possess good function of identification, long-range prediction and control capability for dynamic nonlinear systems. This paper combines the advantages of the two networks to build fuzzy-neural network which identify and control for a complex objects. Fuzzy-neural network with generalized fuzzy function of GFM and recurrent neuro-fuzzy network is used for modeling or forecasting system. Then the results of fuzzy neural network is used to build a long-range predictive controller based on GPC algorithm to control nonlinear dynamics object which is multiple input-single output MISO.