

## پیش‌بینی پارامترهای هواشناسی به‌وسیله سیستم فازی تطبیق‌پذیر

محمدسعید ابراهیمی سعدآبادی و محمد تشنه‌لب

دانشگاه خواجه نصیرالدین طوسی، دانشکده مهندسی برق، گروه مهندسی برق

### چکیده

پیش‌بینی فرایندهای طبیعی که رفتار دقیقی ندارند همواره یکی از زمینه‌های مرد علاقه انسان بوده است تا بتواند با اطلاع قبلی از اتفاق پیش‌رو برنامه‌ریزی‌های بهتری برای خود انجام دهد. یکی از ابزارهای بسیار قدرتمند در این راستا سیستم‌های هوشمند به ویژه شبکه‌های فازی-عصبی می‌باشند. در این مقاله قصد داریم تا با استفاده از این ساختار به پیش‌بینی میزان مطلق رطوبت هوا بپردازیم. برای آموزش پارامترهای قسمت تالی شبکه فازی-عصبی از روش گرادیان نزولی و برای پارامترهای قسمت مقدم شبکه از الگوریتم ژنتیک استفاده شده است به صورتی که تابع هزینه با هدف کمینه شدن مجموع مربعات خطا در نظر گرفته شده است. همچنین در این مقاله برای آموزش پارامترهای غیرخطی قسمت مقدم از الگوریتم ژنتیک بهره برده شده است.

**Mathematics Subject Classification (2010):** 62H25 ; 03F72 , **Email:** teshnehlab@email.kntu.ac.ir.

عبارات و کلمات کلیدی: شبکه‌های فازی-عصبی، گرادیان نزولی، الگوریتم ژنتیک

۱۳۹۷ (انجمن سیستم‌های فازی ایران)

## ۱ مقدمه

پیش‌بینی رفتار پدیده‌ها و سیستم‌ها بر اساس گذشته‌ی موجود آن‌ها همواره یکی از مسائلی بوده که بشر به دنبال یافتن راه حلی برای دستیابی به این کار با بالاترین دقت ممکن بوده است. پیش‌بینی سری‌های زمانی شاخه‌ای از علم آمار و احتمال است که کاربردهای زیادی در اقتصاد، تجزیه و تحلیل آب و هوا و پیش‌بینی جریان ترافیک دارد [۷]. یکی از فرایندهایی که مورد توجه بوده است، همواره پیش‌بینی وضعیت رطوبت در یک منطقه است که می‌تواند نقش بسیار موثری در بسیاری از فرایندهای تولید انرژی و همچنین خطوط هوایی و بسیاری از امور دیگر داشته باشد. استنتاج فازی با بهره‌گیری از قواعد اگر-آنگاه فازی و استفاده از دانش بازه‌ای بجای استفاده از ابزارهای رایج ریاضیاتی می‌تواند به مانند انسان در برخورد با پدیده‌ها از انعطاف‌پذیری بسیار بالاتری برخوردار باشد و نتایج بهتری نیز در بسیاری از امور مانند پیش‌بینی، تولید کند [۱]. این نوع مدل‌سازی فازی اولین بار در سال ۱۹۹۱ به صورت سیستماتیک معرفی شد و تاکنون کاربردهای عملی بسیاری در اموری مانند کنترل، پیش‌بینی و تصمیم‌گیری پیدا کرده است [۹]. از جمله کاستی‌هایی که می‌تواند در این ساختار به آن اشاره کرد آن است که هیچ راه دقیق و مشخصی برای انتقال دانش فرد خبره به شبکه وجود ندارد و همچنین می‌توان به آن که همچنان برای آموزش پارامترهای توابع تعلق مشکلاتی بر سر راه است، مانند محو شدن اثر گرادیان در عبور از لایه‌های پشت سر هم و همچنین دشواری محاسبه گرادیان در مسیرها، اشاره کرد [۱۰][۴]. برای پیش‌بینی ابزارهای دیگری مانند رگرسیون خطی، فیلتر کالمن [۳]، شبکه عصبی مصنوعی نیز وجود دارد. رگرسیون خطی حجم محاسبات سبکی دارد ولی از خاصیت انطباق‌پذیری کمی برخوردار است. فیلتر کالمن به خوبی انطباق‌پذیر است ولی ذاتاً خطی است و در برخورد با مسائل با درجه غیر خطی و پیچیده‌گی بالا به مشکل خواهد خورد. شبکه عصبی مصنوعی می‌تواند هر تابع غیر خطی را تقریب بزند ولی تفسیرپذیر نیست. سیستم‌های فازی-عصبی، اصولاً سیستم‌های فازی هستند که از شباهت تابعی شبکه‌های عصبی با سیستم‌های فازی ایجاد می‌شوند. بنابراین، رفتار سیستم فازی-عصبی می‌تواند هم بر اساس قوانین قابل فهم انسانی باشد و هم می‌تواند از ویژگی مدل‌سازی هر تابع غیر خطی توسط شبکه عصبی مصنوعی بهره‌بردار [۸]. به هر حال نتیجه مهم ترکیب این وجه نمایشی مدل‌های فازی و مکانیزم یادگیری شبکه‌های عصبی، رقابتی است بین تفسیرپذیر بودن و عملکرد مدل ایجاد شده. در این مقاله ما نتیجه شبیه‌سازی‌های انجام شده برای پیش‌بینی سری زمانی کیفیت هوا می‌پردازیم [۹]. نتیجه ارائه شده توسط شبکه با معیار میانگین مربعات خطا سنجیده شده است. در قسمت بعدی به توضیح

در مورد مفاهیم اساسی شبکه فازی-عصبی و نحوه آموزش آن می‌پردازیم. در بخش سه به معرفی سری‌های زمانی استفاده شده و روشی که برای شبیه سازی استفاده شده است و در بخش چهار به ارائه نتایج بدست آمده از شبیه‌سازی‌های خود می‌پردازیم و در قسمت پنج به نتیجه‌گیری و معرفی مختصری درباره کارهای آینده خواهیم پرداخت.

## ۲ شبکه‌های فازی-عصبی

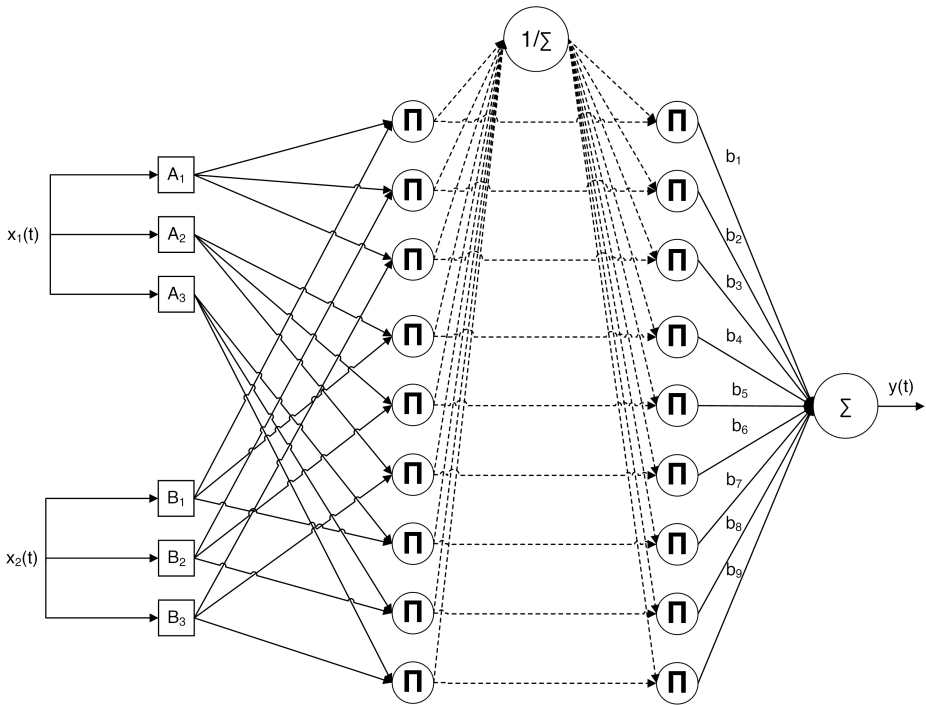
یک سیستم فازی که تنها بر اساس دانش فرد خبره ایجاد می‌شود، معمولاً هنگامی که بکار برده می‌شود نمی‌تواند نیازهای کاربر را برآورده نماید، زیرا فرد خبره ممکن است در مورد موقعیت مجموعه‌های فازی، شکل توابع تعلق یا در تعداد قوانین دچار اشتباه شود. یک تنظیم دستی در راستای اصلاح پارامترهای مجموعه قوانین، جهت بهبود شرایط، بایستی در اینگونه مدلسازی‌ها اعمال شود. این کار بسیار زمان‌بر و پرهزینه می‌باشد. همچنین در بسیاری موارد دانش فرد خبره یا جزئی است یا در بعضی شرایط اصلاً وجود ندارد. بنابراین مفید خواهد بود اگر روش‌های آموزش خودکار بر اساس داده‌های نمونه برداری شده را، در راستای آموزش پارامترهای سیستم فازی بکار ببندیم. این کار در صورتی مقدور است که اجزای تشکیل دهنده سیستم فازی را بتوانیم در شکل و فرم پارامتریک بنویسیم. یک سیستم استنتاج فازی در فرم پارامتریک قابل آموزش است. این ایده، پایه مدل‌های فازی-عصبی است [۱۱][۲][۶]. ماحصل آن خروجی یک سیستم سوگنو مرتبه صفر با فازی ساز منفرد، موتور استنتاج ضرب و غیرفازی ساز میانگین مراکز به فرم رابطه (۱) و رابطه (۲) است.

$$y = \left\{ \sum_{k=1}^K \frac{\mu_{A^k}(x)}{\sum_{h=1}^K \mu_{A^h}(x)} \right\} b^k \quad (1)$$

$$\mu_{A^k}(x) = \prod_{i=1}^n \mu_{A_i^k}(x_i) \quad (2)$$

در رابطه (۱) پارامتر  $\mu$  برابر با مقدار فعال شدن هر یک از قانون‌ها می‌باشد و  $b$  پارامتر خطی بخش تالی است که در لایه آخر با مقدار نرمال شده هر یک از قوانین جمع می‌شود،  $k$  تعداد قوانین تولید شده است، همچنین مشاهده می‌شود که خروجی یک سیستم مددانی به فرم یک ترکیب خطی از توابع پایه غیرخطی (نرمال شده)

که می‌تواند به عنوان یک تکنیک مدل‌سازی محلی بکار بسته شود [۲]. معمولاً به دلیل سخت بودن آموزش مقادیر متغیر توابع تعلق صرفاً به آموزش وزن‌های لایه خروجی با روش گرادینان نزولی پرداخته می‌شود.




شکل ۱: ساختار شبکه فازی-عصبی تطبیقی پیاده‌سازی شده

### ۳ سری‌های زمانی و ساختار پیاده‌سازی شده

#### ۱.۳ سری زمانی میزان رطوبت هوا

این دیتاست شامل بیش از ۹۰۰۰ نمونه از اندازه‌گیری‌های دستگاه سنجش کیفیت هوا است که اعداد نمایش داده شده توسط این دستگاه در واقع میانگین اندازه‌گیری پنج سنسور که در این دستگاه نصب شده‌اند می‌باشد. این دستگاه در یکی از جاده‌های درون شهری در یکی از شهرهای ایتالیا نصب شده است و در فاصله زمانی مارچ ۲۰۰۴ تا فوریه ۲۰۰۵ این اندازه‌گیری‌ها را انجام داده است که در شکل ۲ نشان داده شده است [۵].



شکل ۲: سری زمانی میزان رطوبت هوا در بازه یک سال

### ۲.۳ ساختار پیاده سازی شده

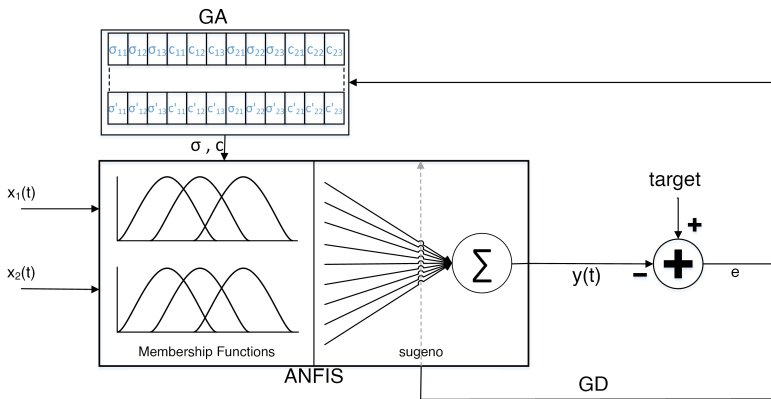
در این مقاله ما از یک ساختار شبکه فازی-عصبی که در قسمت مقدم آن برای هر یک از ورودی‌ها از سه تابع تعلق گوسی و در قسمت تالی از ساختار سوگنو مرتبه صفر استفاده شده است و برای آموزش مقادیر وزن‌های لایه سوگنو آن از روش گرادیان نزولی استفاده شده است. روابط پیشرو شبکه مانند رابطه یک می‌باشد و همچنین تابعی که برای ارزیابی استفاده شده است همان مجموع مربعات خطا می‌باشد.

$$e = target - y \quad (۳)$$

$$E = \frac{1}{2} e^2 \quad (۴)$$

$$\Delta b(k) = -\eta \frac{\partial E}{\partial b} = -\eta \frac{\partial E}{\partial e} \frac{\partial e}{\partial y} \frac{\partial y}{\partial b} \quad (۵)$$

$e$  بیانگر میزان اختلاف خروجی تولید شده توسط شبکه و  $target$  مقدار خروجی دلخواه است و  $\eta$  گام آموزش است. برای آموزش مقادیر میانگین و واریانس توابع تعلق نیز از الگوریتم بهینه سازی ژنتیک استفاده شده است، به این صورت که ابتدا با در نظر گرفتن مقادیر ثابت وزن‌های لایه اخر به آموزش مقادیر قسمت مقدم با استفاده از الگوریتم ژنتیکی که تابع هزینه آن همان میانگین مربعات خطای شبکه به ازای تمامی داده‌های آموزشی است، پرداخته شده است. به این صورت که شبکه ما در قسمت مقدم خود دارای ۱۲ پارامتر قابل آموزش است، پس در الگوریتم ژنتیک هر کروموزوم دارای ۱۲ ژن است. در نهایت با استفاده از گرادیان نزولی به آموزش وزن‌های لایه خروجی پرداخته‌ایم، که در شکل ۳ نشان داده شده است.



شکل ۳: شماییک ساختار پیاده سازی شده شبکه فازی-عصبی با آموزش گرادیان نزولی + ژنتیک


$$x_1(t) = x(t) \tag{۶}$$

$$x_2(t) = x(t - 1) \tag{۷}$$

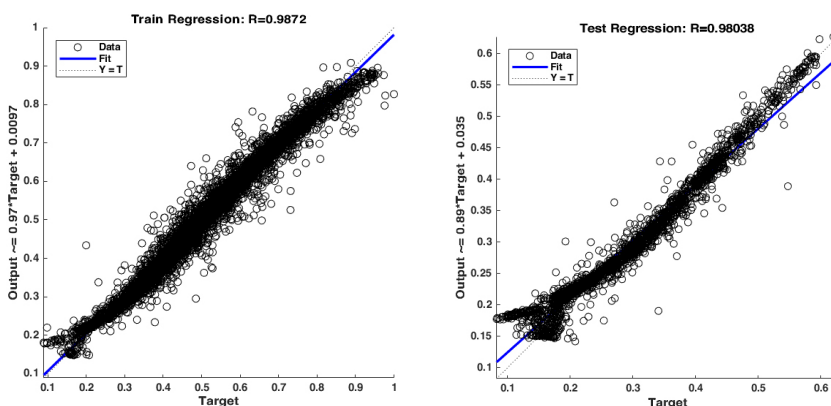
$$y = x(t + 1) \tag{۸}$$

## ۴ نتایج شبیه سازی

در دیتاست استفاده شده مقدار ۲۰۰- به معنی مقداری است که اندازه‌گیری آن درست انجام نشده است) طبق توضیحات موجود در سایت ارائه دهنده دیتاست [۵]. پس ابتدا باید این مقادیر را از دیتاست حذف کرد که بعد از این کار، مجموعاً ۸۹۹۱ داده برای آموزش و آزمون شبکه در اختیار است. ابتدا پیاده سازی برای حالتی انجام شد که صرفاً وزن‌های قسمت تالی شبکه با استفاده از گرادیان نزولی آموزش داده شده است سپس پیاده سازی برای حالتی انجام شد که ابتدا مقادیر بهینه مراکز دسته به ازای مقدار وزن‌های ثابت قسمت تالی، توسط الگوریتم ژنتیک بدست آید و سپس به آموزش وزن‌های قسمت تالی پردازیم، همانطور که در شکل ۳ نشان داده شده است.



شکل ۴: نتایج بدست آمده با آموزش گرادین نزولی برای داده های آزمون و آموزشی




(ب) داده‌های آموزش

(آ) داده‌های آزمون


شکل ۵: رگرسیون بدست آمده با آموزش گرادین نزولی

در شکل‌های ۴ الی ۷ مقادیر نمایش داده شده، به ازای نرمال سازی ورودی‌های شبکه است که البته با توجه به آن که ماکزیمم مقدار ورودی تقریباً ۲ و کمترین مقدار تقریباً صفر است در جواب نهایی تغییر زیادی ایجاد نخواهد کرد. همچنین در جدول ۱ میتوان مقدار عددی خطای آزمون دو ساختار را به ازای ۲۰ بار تکرار در اجرای الگوریتم مشاهده کرد.

قابل ذکر است که خروجی‌های ذکر شده در جدول ۱ با پردازنده Intel Core™ i7 و در نرم افزار متلب در ویندوز ۱۰ انجام شده است [۷].



شکل ۶: نتایج بدست آمده با آموزش گرادین نزولی به همراه الگوریتم ژنتیک برای داده‌های آزمون و آموزشی



(ب) داده‌های آموزش

(آ) داده‌های آزمون

شکل ۷: رگرسیون بدست آمده با آموزش گرادین نزولی به همراه الگوریتم ژنتیک

## ۵ نتیجه‌گیری

در این مقاله به بررسی کاربرد شبکه‌های فازی-عصبی در کاربردهای پیش‌بینی میزان رطوبت هوا با استفاده از دو داده (که بیانگر میزان رطوبت هوا در دو نمونه برداری قبل است) ورودی پرداختیم. نشان داده شد که در شبکه‌های فازی-عصبی با وجود آن که یکی از نقصان‌های آن‌ها سختی آموزش پارامترهای بخش تالی است و معمولاً تنها می‌توان وزن‌های قسمت مقدم را آموزش داد، با این وجود کارایی نسبتاً خوبی از خود نشان می‌دهند. همچنین نشان دادیم که در صورتی که بتوان پارامترهای بخش تالی را با روش‌های آموزش سراسری آموزش داد می‌توان به میزان خطای بسیار کمتری (تقریباً ۴ برابر کمتر در داده‌های آزمون) رسید که



جدول ۱: نتایج بدست آمده برای هر دو حالت آموزش

مدت زمان آموزش (ثانیه)	وارianس $MSE$ داده‌های آزمون	$MSE$ داده‌های آزمون	$MSE$ داده‌های آموزشی	روش آموزش
۶۷.۵۰۳	$۲.۴ * ۱۰^{-۹}$	$۱.۲ * ۱۰^{-۲}$	$۵.۰۱ * ۱۰^{-۲}$	گرایان نزولی بخش تالی + ژنتیک بخش مقدم
۹۶.۲۳	$۱.۰۷ * ۱۰^{-۷}$	$۴.۸ * ۱۰^{-۲}$	$۹.۷ * ۱۰^{-۲}$	گرایان نزولی بخش تالی

با در نظر گرفتن آنکه معمولاً آموزش شبکه به صورت آفلاین انجام می‌شود، پس اگر پارامترهای مقدم را نیز آموزش دهیم میتوانیم با هزینه زمان بیشتر به دقت بیشتری دست یابیم.

## مراجع

- [1] Pano-Azucena, Ana Dalia, Esteban Tlelo-Cuautle, and Sheldon X-D. Tan. "Prediction of chaotic time series by using ANNs, ANFIS and SVMs." *Modern Circuits and Systems Technologies (MOCASST)*, 2018 7th International Conference on, IEEE, (2018)
- [2] M. Brown and C. J. Harris, Prentice Hall, Hemel Hempstead, *Neurofuzzy Adaptive Modelling and Control*, (1994).
- [3] J. Castro and M. Delgado, "Fuzzy Systems with Defuzzification are Universal Approximators", *IEEE Trans. on Systems, Man and Cybernetics*, **Vol. 26**, (1996), pp. 149-52.
- [4] Chen, De-Wang, and Jun-Ping Zhang. "Time series prediction based on ensemble ANFIS." *Machine Learning and Cybernetics*, Proceedings of 2005 International Conference on. **Vol. 6. IEEE**, (2005).
- [5] S. De Vito, E. Massera, M. Piga, L. Martinotto, G. Di Francia, On field calibration of an electronic nose for benzene estimation in an urban pollution monitoring scenario, *Sensors and Actuators B: Chemical*, **Volume 129, Issue 2**, (2008), Pages 750-757, ISSN 0925-4005.

- [6] Jang, J-SR, and C-T. Sun. "Functional equivalence between radial basis function networks and fuzzy inference systems." *IEEE transactions on Neural Networks*, **Vol. 4.1**, (1993), 156-159.
- [7] E. Lotfi and M. Akbarzadeh-T., "Adaptive brain emotional decayed learning for online prediction of geomagnetic activity indices", *Neurocomputing*, **Vol. 126**, (2014), pp. 188-196.
- [8] E. H. Mamdani and S. Assillan, "An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller", *Int. Journal of Man-Machine Studies*, **Vol. 7**, (1975), pp. 1-13.
- [9] Sarıca, Busenur, Erol Eğrioglu, and Barış Aşıkçıl. "A new hybrid method for time series forecasting: AR–ANFIS." *Neural Computing and Applications*, **Vol. 29.3**, (2018), 749-760.
- [10] Soman, Saurabh S., et al. "A review of wind power and wind speed forecasting methods with different time horizons." *North American power symposium (NAPS)*, (2010. IEEE).
- [11] L. Wang and J. M. Mendel, "Fuzzy Basis Functions, Universal Approximation, and Orthogonal Least Squares", *IEEE Trans. on Neural Networks*, **Vol. 3**, (1992), pp. 807-814.