Journal of Decisions & Operations Research

Volume 5, Issue 4, Winter 2020

Journal of Decisions and Operational Research

www.journal-dmor.ir

Forecasting of the Number of Cases and Deaths Due to Corona Disease Using Neuro-Fuzzy Networks

Malihe Niksirat[1,*], Seyed Hadi Nasseri[2]

[1]Associate Professor of Department of Computer Science, Faculty of Computer and Industrial Engineering, Birjand University of Technology, Birjand, Iran.
[2]Department of Mathematics, Faculty of Mathematical Sciences, University of Mazandaran, Babolsar, Iran.

Abstract

Corona is currently the world's health crisis and the biggest challenge humans have experienced since World War II. Given the epidemic of the disease, it is invaluable to forecasting the number of cases and the resulting deaths to better understand the current situation and provide a short-term plan by managers. Accordingly, in this paper, a neuro-fuzzy network model is proposed to forecast the number of cases and deaths in countries that are most affected by this disease. The performance of the proposed neuro-fuzzy network has been compared with time series forecasting neural network as well as radial basic functions neural networks. The proposed model is able to predict the number of cases and deaths from the disease for a period of the next 15 days at a lower error rate.

Keywords: Corona, Neuro-fuzzy network, Time series, Forecasting, Approximation function, Classification.

Original Article

Receive: 14/09/2020 Review: 04/10/2020 Revise: 18/11/2020 Accept: 10/12/2020

Citation:

Niksirat, M., & Nasseri, S. H. (2020). Forecasting of the number of cases and deaths due to Corona disease using neuro-fuzzy networks. *Decisions & operations research*, *5*(4), 414-425.

*** Corresponding Author**

Email Address: Niksirat@birjandut.ac.ir

DOI: 10.22105/DMOR.2020.236967.1164

Journal of Decisions & Operations Research, Volume 5, Issue 4, Winter 2020, Page: 414-425

نشریه علمی
تصمیم‌گیری و تحقیق در عملیات
Journal of Decisions and Operational Research
دوره ۵، شماره ۴، زمستان ۱۳۹۹

www.journal-dmor.ir

پیش‌بینی تعداد موارد مبتلا و مرگ‌ومیر ناشی از بیماری کرونا با استفاده از شبکه‌های عصبی-فازی

ملیحه نیک سیرت[۱،*]، سید هادی ناصری[۲]

[۱]استادیار گروه علوم کامپیوتر، دانشکده مهندسی صنایع و کامپیوتر، دانشگاه صنعتی بیرجند، بیرجند، ایران.
[۲]گروه ریاضی کاربردی، دانشکده علوم ریاضی، دانشگاه مازندران، مازندران، ایران.

چکیده

بیماری کرونا در حال حاضر بحران جهانی سلامت و بزرگترین چالشی است که بشر از زمان جنگ جهانی دوم تاکنون تجربه کرده است. با توجه به همه‌گیری این بیماری، پیش‌بینی تعداد موارد مبتلا و مرگ‌ومیر ناشی از آن برای درک بهتر شرایط فعلی و تهیه برنامه کوتاه‌مدت توسط مدیران، بسیار ارزشمند است. بر این اساس، در این مقاله یک مدل شبکه عصبی-فازی برای پیش‌بینی تعداد موارد مبتلا و مرگ‌ومیر ناشی از این بیماری در کشورهایی که بیشتر با این بیماری درگیر هستند پیشنهاد شده است. عملکرد شبکه عصبی-فازی پیشنهادی با شبکه‌های عصبی پیش‌بینی سری زمانی و همچنین شبکه‌های عصبی توابع پایه‌ای شعاعی مقایسه شده است. مدل پیشنهادی قادر است تعداد موارد مبتلا و مرگ‌ومیر ناشی از بیماری را برای یک دوره ۱۵ روز آینده با نرخ خطای کمتر پیش‌بینی کند.

واژه‌های کلیدی: کرونا، شبکه عصبی-فازی، سری زمانی، پیش‌بینی، تابع تقریب، کلاس‌بندی.

مقاله پژوهشی

دریافت: ۱۳۹۹/۰۶/۲۴ داوری: ۱۳۹۹/۰۷/۱۳ اصلاح: ۱۳۹۹/۰۸/۲۸ پذیرش: ۱۳۹۹/۰۹/۲۰

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

۱- مقدمه

در حال حاضر جهان در حال تجربه یک بیماری عفونی همه‌گیر به نام بیماری کرونا است. تصور می‌شود که این بیماری از اواخر دسامبر سال ۲۰۱۹ از یك غذای دریایی در شهر ووهان در چین سرچشمه گرفته است (میزومتو و همکاران[۱]، ۲۰۲۰). علائم کرونا شبیه به سرماخوردگی است، با این حال، عفونت در موارد شدیدتر می‌تواند منجر به ذات‌الریه، نارسایی اعضا، سندرم حاد تنفسی و حتی مرگ شود. افراد مسن و افراد دارای بیماری‌های خاص، بیشترین مرگ‌ومیرهای ناشی از کرونا را به خود اختصاص داده‌اند.

تا ۱۵ مه ۲۰۲۰، مواردی از ابتلا به این بیماری در حدود ۲۱۰ کشور مشاهده شده است. چین در ابتدا کشوری بود که بیشتر تحت تأثیر این بیماری قرار داشت، با این حال ایالات متحده، اسپانیا، روسیه، انگلیس و ایتالیا بیشترین موارد مبتلا را در سراسر جهان دارند. در حال حاضر ایالات متحده آمریکا بیشترین تعداد موارد مبتلا به کرونا و مرگ‌ومیر ناشی از آن را در جهان به خود اختصاص داده است. همچنین تا ۱۵ مه ۲۰۲۰، حدود ۳۰۴٫۲۰۰ مرگ‌ومیر بر اثر ابتلا به کرونا رخ داده است که ایالات متحده بیشترین تعداد مرگ‌ومیر را در جهان گزارش کرده

[۱]Mizumoto et al.

* نویسنده مسئول
آدرس رایانامه: Niksirat@birjandut.ac.ir
شناسه دیجیتال: 10.22105/DMOR.2020.236967.1164

است و رتبه‌های بعدی به ترتیب مربوط به انگلیس و ایتالیا است. سازمان بهداشت جهانی میزان مرگ‌ومیر ناشی از این ویروس را بین سه تا چهار درصد تخمین زده است. گذشته از تأثیرات آشکار این بیماری بر سلامتی انسان، بیماری همه‌گیر کرونا بر اقتصاد جهانی تأثیر فراوانی داشته است. تعداد فزاینده‌ای از مردم در سراسر جهان بر این باورند که کرونا تهدیدی جدی برای اقتصاد کشورشان است.

ادبیات اخیر نشان می‌دهد که جستجو در مورد روش‌های جلوگیری از گسترش بیماری کرونا بسیار مبهم است. برای مثال تعدادی از محققین، بر روی بررسی رفتارهای داروها بر این بیماری به عنوان تحقیقات آتی تمرکز شده است (سینگ و همکاران[۱]، ۲۰۲۰). همچنین، تاثیرات آب‌وهوایی برای جلوگیری از شیوع بیماری کووید ۱۹ بررسی شده است (تاسنو و همکاران[۲]، ۲۰۲۰). به‌علاوه، تاثیرات اجرای سریع فاصله‌گذاری اجتماعی بر شیوع این بیماری نیز بررسی شده است (شیم و همکاران[۳]، ۲۰۲۰). اگرچه پیش‌بینی آینده این بیماری همه‌گیر بسیار دشوار است، زیرا موارد به صورت تصاعدی در حال رشد و داده‌ها غیرخطی و غیرثابت هستند، با این وجود، پیش‌بینی این بیماری برای درک بهتر شرایط فعلی و تهیه برنامه کوتاه‌مدت توسط مدیران، بسیار ارزشمند است. با این‌حال، تحقیقات در زمینه پیش‌بینی همه‌گیری بیماری کرونا هم اندک بوده است. تعدادی از محققین از یک روش سنتی، برای پیش‌بینی تعداد موارد مرگ‌ومیر در کشورهای خاصی استفاده کردند (فانلی و پایازا[۴]، ۲۰۲۰). نتایج به‌دست آمده نشان داد که شرایط خاص کشورهای بررسی شده در میزان مرگ‌ومیر ناشی از این بیماری تاثیرگذار بوده است. برخلاف این روش‌های سنتی، ادبیات موجود بر استفاده از روش‌های نوین یادگیری ماشین برای پیش‌بینی بهتر تاکید دارد. به‌عنوان نمونه، یک روش یادگیری ماشین مبتنی‌بر ابر برای پیش‌بینی کووید ۱۹ معرفی شد که در آن نویسندگان از تلفیق مدل‌های سری زمانی مانند *ARIMA*[۵] با مدل ریاضی پیشنهادی خود استفاده کردند (تلی و همکاران[۶]، ۲۰۲۰). همچنین تلفیق روش‌های تجزیه و *ARIMA* به عنوان راهکاری موثر به منظور پیش‌بینی آینده این بیماری به‌کار گرفته شده است (دو و همکاران[۷]، ۲۰۲۰ و حسان[۸]، ۲۰۲۰). علاوه بر این یک سیستم استنتاج فازی برای پیش‌بینی موارد مبتلای جدید به این بیماری در چین ارایه شده است (القانسه و همکاران[۹]، ۲۰۲۰). با این وجود، در هیچ یک از این مقالات به موضوع خوشه‌بندی فازی داده‌های این بیماری با توجه به عدم استقلال داده‌ها از یکدیگر توجه نشده بود و این موضوع یکی از وجوه تمایز این مطالعه در مقایسه با مطالعات قبلی در این زمینه است که فرآیند پیش‌بینی را سریعتر و دقت پیش‌بینی را در مقایسه با شبکه‌های عصبی معمولی افزایش داده است. به‌طور کلی، پیش‌بینی داده‌های سری زمانی غیرخطی و غیرثابت یک کار مهم در حوزه تحلیلی سلامت است. اخیراً، مدل‌های مختلف داده‌محور غیرخطی مانند شبکه-های عصبی مصنوعی، ماشین بردار پشتیبان و ... برای تحقیقات متعدد در حوزه پیش‌بینی سلامت به‌کار رفته است (منگ و همکاران[۱۰]، ۲۰۱۹). شبکه‌های عصبی مصنوعی به دلیل پردازش موازی قدرتمند و ظرفیت تقریب هر تابعی تا سطح مطلوب، بیشترین کاربرد را در پیش‌بینی سری‌های زمانی دارد. با این وجود، هنوز تحقیقات زیادی برای بهبود دقت پیش‌بینی در این شبکه‌ها در حال انجام است (تن و همکاران[۱۱]، ۲۰۱۸).

در این شرایط که بیماری درمان خاصی ندارد، پیشگیری از بیماری و آماده‌سازی خدمات بهداشتی و درمانی بسیار مهم است. مدل‌سازی و پیش‌بینی موارد مبتلا به بیماری و مرگ‌ومیر در آینده می‌تواند به سیستم درمانی در ارائه خدمات لازم به بیماران جدید کمک کند. در این مطالعه، یک مدل شبکه عصبی-فازی برای پیش‌بینی موارد مبتلا و موارد فوتی جدید پیشنهاد شده است که می‌تواند در آماده‌سازی برای برخورد و کنترل این اپیدمی جهانی مفید باشد. ایده مدل عصبی-فازی پیشنهاد شده، دسته‌بندی داده‌های تاریخی به کلاس‌های مختلف و سپس پیش‌بینی موارد جدید با توجه به کلاس‌های تشکیل شده است. دسته‌بندی داده‌ها در کلاس‌های مختلف، در مدل‌های

---

[۱] Singh et al.
[۲] Tosepu et al.
[۳] Shim et al.
[۴] Fanelli and Piazza
[۵] Autoregressive integrated moving average
[۶] Tuli et al.
[۷] Du et al.
[۸] Hasan
[۹] Al-Qaness et al.
[۱۰] Meng et al.
[۱۱] Tan et al.

پیش‌بینی قبلی نیز مورد استفاده قرار گرفته است (کرینک و همکاران[۱]، ۲۰۱۹). با این‌حال، مهم‌ترین مزیت این روش در مطالعه اخیر این است که می‌توان بر اساس نتایج به‌دست آمده تحلیل‌هایی روی شرایط موثر بر افزایش موارد ابتلا و فوتی جدید و نیز کاهش این موارد ارائه داد. از آنجایی که شرایط تاثیرگذار بر شیوع بیماری و همچنین میزان تاثیر آن‌ها به شدت تحت تاثیر عوامل غیرقطعی قرار دارد، بنابراین دسته‌بندی داده‌ها به روش فازی انجام شده است. مدل شبکه‌های عصبی-فازی در تحقیقات قبلی در حوزه‌های مسئله تخمین و پیش‌بینی پیشنهاد شده است. مرور کاملی بر تکنیک‌ها و کاربردهای شبکه‌های عصبی و شبکه‌های عصبی-فازی تا سال ۲۰۲۰ ارائه شده است (دِ کمپس سوزا[۲]، ۲۰۲۰). همچنین تحقیقات زیادی در زمینه کاربرد شبکه‌های عصبی در مسائل پیش‌بینی انجام شده است که با توجه به تعداد بیشمار مقالات در این زمینه، به مطالعات اخیر در این زمینه اشاره شده است. تنگ و همکاران[۳] (۲۰۱۸) از یک مدل شبکه عصبی تطبیقی برای پیش‌بینی رفتار تغییر لاین رانندگان استفاده کرده‌اند. نویسندگان روش پیشنهادی شبکه عصبی-فازی را با شبکه‌های عصبی، ماشین بردار پشتیبان و رگرسیون خطی چندمتغیره مقایسه کرده‌اند که نتیجه این مقایسه عملکرد بهتر شبکه عصبی-فازی پیشنهادی را در مقایسه با سایر روش‌ها نشان می‌دهد. شایو[۴] (۲۰۱۷) یک مدل شبکه عصبی-فازی ترکیب شده با فیلترسازی بیضوی را برای پیش‌بینی داده‌های سری زمانی پیشنهاد داد. نتایج حاصل از مقایسه روش پیشنهادی با شبکه‌های عصبی پایه‌ای شعاعی، شبکه‌های *ANFIS*[۵] و ماشین بردار پشتیبان نشان‌دهنده این است که روش پیشنهادی عملکرد مطلوب‌تر و پایدارتری داشته است. خسروی و همکاران[۶] (۲۰۱۸) سه روش یادگیری ماشین شبکه عصبی پرسپترون چندلایه، شبکه عصبی پایه‌ای شعاعی ترکیب شده با ماشین بردار پشتیبان و شبکه *ANFIS* ترکیب شده با الگوریتم بهینه‌سازی اجتماع ذرات را برای پیش‌بینی سرعت وزش باد، جهت باد و توان خروجی یک توربین بادی پیشنهاد دادند و عملکرد این سه روش را با یکدیگر مقایسه کردند. تسنگ و هو[۷] (۲۰۱۰) چهار روش مدل لاجیت، مدل لاجیت بازه‌ای درجه دو، شبکه عصبی چند لایه و شبکه عصبی پایه‌ای شعاعی را برای پیش‌بینی ورشکستی، پیاده‌سازی و عملکرد آن‌ها را با یکدیگر مقایسه کردند. غیر از مدل لاجیت، بقیه مدل‌ها به گونه‌ای طراحی شده‌اند که توانایی درنظر گرفتن شرایط عدم قطعیت را دارند. نتایج این تحقیق نشان داده است که شبکه عصبی پایه‌ای شعاعی در شرایط عدم قطعیت، عملکرد بهتری نسبت به سایر روش‌ها دارد. تنگ و همکاران[۸] (۲۰۱۷) یک مدل شبکه عصبی-فازی برای پیش‌بینی سرعت ترافیک در شبکه‌های حمل‌ونقل ارائه کرد. نتایج حاصل از شبکه عصبی-فازی با روش شبکه عصبی، ماشین بردار پشتیبان و روش‌های رگرسیون محور مقایسه شده است که نتایج حاصل از این مقایسه، برتری روش شبکه عصبی-فازی را در مقایسه با سایر روش‌ها نشان می‌دهد. مرور کاملی بر روش‌های فازی-عصبی برای پیش‌بینی داده‌های سری زمانی آشفته در مقاله هن و همکاران[۹] (۲۰۱۸) آمده است. نتایج حاصل از بررسی ادبیات موضوع در زمینه استفاده از شبکه‌های عصبی-فازی برای مسئله پیش‌بینی در کاربردهای مختلف نشان‌دهنده موفقیت این روش در حل این مسائل می‌باشد.

در این مطالعه، داده‌های کشورهایی که بر اساس اعلام سازمان جهانی بهداشت تعداد موارد مبتلا و مرگ‌ومیر بالاتری داشته‌اند مورد تحلیل قرار گرفته است. برای هر یک از این کشورها، پارامترهای مناسب شبکه عصبی-فازی استخراج شده است و پیش‌بینی موارد ابتلا و فوتی برای ۱۵روز آینده انجام شده است. این کشورها شامل ایالت متحده آمریکا، اسپانیا، روسیه، اروپا، ایتالیا، فرانسه، آلمان، برزیل، ترکیه و ایران است. تعداد موارد مبتلا و مرگ‌ومیر ناشی از این بیماری در روز ۱۸ مه ۲۰۲۰ در **شکل ۱** نشان داده شده است.

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

---

[۱] Škrjanc et al.
[۲] de Campos Souza
[۳] Tang et al.
[۴] Xiao
[۵] Adaptive neuro fuzzy inference system
[۶] Khosravi et al.
[۷] Tseng and Hu
[۸] Tang et al.
[۹] Han et al.

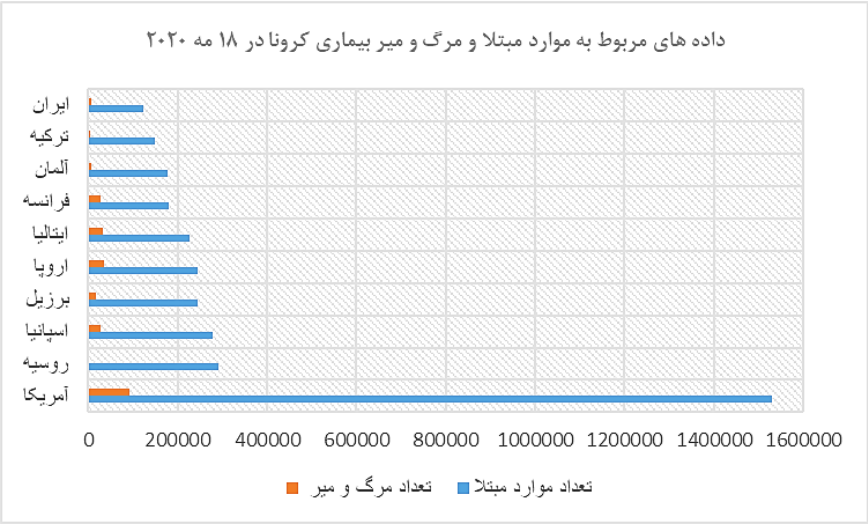

شکل ۱- داده‌های مربوط به بیماری کرونا در کشورهایی که بیشترین درگیری را با این بیماری داشته‌اند.
Figure 1- Corona data in the countries with the highest incidence of the disease.

داده‌های تایید شده روزانه کرونا از وب سایت رسمی سازمان جهانی بهداشت جمع‌آوری و برای ساخت این مدل‌ها مورد استفاده قرار گرفت. این مدل می‌تواند با پیش‌بینی تعداد موارد مبتلا در آینده‌ای نزدیک به آمادگی بهتر کادر درمان و خدمات‌رسانی به موقع به بیماران در این کشورها کمک کند.

۲- روش پژوهش

فرض کنید داده‌های سری زمانی تعداد موارد ابتلا به بیماری کرونا در یک کشور خاص $N_t, t=1,2,...$ باشد که N_t تعداد موارد مبتلا به این بیماری در روز t است. با توجه به تاثیر عوامل مختلف بر موارد مبتلا به این بیماری که مهمترین آن‌ها میزان رعایت موارد بهداشتی و فاصله‌گذاری اجتماعی در روزهای قبل است، وابسته بودن مقدار N_t به تعداد موارد مبتلا در روزهای $t-1$، $t-2$ و ... بدیهی است که می‌توان این ارتباط را به صورت ریاضی به شکل زیر مدل‌سازی کرد:

$$N_t=F(N_{t-1},N_{t-2},...). \quad (۱)$$

تابع $F(.)$ رابطه غیرخطی تعداد موارد مبتلای جدید به تعداد موارد مبتلا در روزهای قبل را نشان می‌دهد که اگر این رابطه شناخته شده باشد به راحتی می‌توان تعداد موارد مبتلای جدید را تعیین و برای برنامه‌ریزی و مدیریت امکانات مراقبتی و بهداشتی به‌کار برد. با این حال بایستی توجه کرد که این تابع به علت تاثیر عوامل مختلف که بسیار متنوع و ذاتاً غیرقطعی هستند، به شدت غیرخطی و البته برای هر کشور متفاوت خواهد بود(فانلی و پایازا، ۲۰۲۰). برای مدل‌سازی تابع غیرخطی $F(.)$ می‌توان از یک شبکه عصبی چند لایه استفاده کرد. در گام آموزش شبکه عصبی، وزن‌ها به گونه‌ای تنظیم می‌شوند که مقادیر پیش‌بینی شده توسط شبکه عصبی بیشترین تطابق را با اطلاعات تاریخی تعداد موارد مبتلا داشته باشد. از آنجایی که وضعیت‌های مختلف شیوع و همه‌گیری بیماری که در الگوهای سبز (بی‌خطر)، سفید (کم‌خطر)، زرد (متوسط)، نارنجی (پرخطر)، قرمز (خیلی پرخطر) طبقه‌بندی می‌شوند، به صورت مستقیم در تنظیم وزن‌های شبکه عصبی چندلایه دیده نمی‌شود، بنابراین زمانیکه ورودی شبکه عصبی شامل داده‌هایی از الگوهای مختلف این بیماری می‌باشد، تعداد تکرارهای لازم برای یافتن بهترین تطبیق بین نتایج شبکه و داده‌های اصلی به طور قابل ملاحظه‌ای افزایش می‌یابد. برای حل این مشکل، تعدادی از محققین پیشنهاد کرده‌اند که داده‌های تاریخی ابتدا بر اساس الگوهای موجود طبقه‌بندی شود و سپس برای هر طبقه یک شبکه عصبی مجزا طراحی شود. مطالعات قبلی در زمینه شبکه‌های عصبی نیز نشان می‌دهد که دسته‌بندی داده‌های تاریخی در چندین کلاس و طراحی یک شبکه عصبی برای هر کلاس زمان آموزش را کاهش می‌دهد(تنگ و همکاران، ۲۰۱۷). از آنجایی که، در مسئله مورد مطالعه مقاله، عوامل متعدد موثر بر گسترش و مرگ‌ومیر این بیماری بشدت تحت تاثیر عدم قطعیت هستند، دسته‌های بوجود آمده نمی‌توانند از یکدیگر مستقل باشند. بنابراین تعریف یک سیستم کلاس‌بندی دقیق برای الگوهای مختلف شیوع و مرگ‌ومیر ناشی از این بیماری بسیار مشکل است. به همین دلیل باید راهکاری اتخاذ شود تا داده‌های تایخی را به شکل فازی کلاس‌بندی کند. برای این منظور در این مقاله یک مدل شبکه عصبی-فازی پیشنهاد شده است که داده‌های تاریخی را به مجموعه‌ای از کلاس‌های فازی تقسیم‌بندی کرده و سپس با استفاده از یک مدل شبکه عصبی به استخراج روابط ورودی-خروجی در هر کلاس می‌پردازد. برای استخراج

نتایج نهایی، توابع عضویت مجموعه‌های فازی به شکلی که در ادامه مقاله تشریح خواهد شد با نتایج شبکه عصبی ترکیب می‌شود. از آنجایی که داده‌های تاریخی با درجات عضویت متفاوت متعلق به تمام کلاس‌های ایجاد شده می‌باشد، بنابراین برای آموزشی شبکه عصبی نیازی به خوشه‌بندی داده‌ها قبل از انجام فرآیند یادگیری نیست.

فرض کنید Ω بردار ورودی باشد؛ مدل عصبی-فازی پیشنهادی، ابتدا Ω را به بردارهای $\Omega_c{:}c\in C$ افراز می‌کند که در آن C مجموعه کلاس‌ها است و $\Omega = \cup_{c\in C}\Omega_c$. تعداد کلاس‌ها به مسأله تحت بررسی وابسته است و با توجه به منابع محاسباتی مورد نیاز تعیین می‌شود. معمولاً، هر چه تعداد کلاس‌ها بیشتر باشد دقت پیش‌بینی شبکه افزایش می‌یابد. با این حال، افزایش تعداد کلاس‌ها زمان لازم برای پیش‌بینی را افزایش می‌دهد. هر کلاس فازی $c\in C$ بوسیله مرکز آن z_c مشخص می‌شود. بردار مراکز $z=(z_c)_{c\in C}$ در ابتدا توسط الگوریتم خوشه‌بندی فازی[1] مقداردهی اولیه می‌شود و سپس توسط الگوریتمی که در ادامه تشریح خواهد شد بردار مراکز به صورت دقیق‌تر مشخص می‌شود. درجه عضویت فازی N_t به یک کلاس فازی $c\in C$ به شکل زیر تعیین می‌شود:

$$\mu_c(N_t)=\frac{1}{\sum_{i\in C}\left(d_{c,t}/d_{i,t}\right)^2}. \qquad (۲)$$

که در آن $d_{c,t}$ یک معیار مشابهت است و با رابطه $d_{c,t}=|N_t - z_c|$ مشخص می‌شود. این تعریف تابع عضویت دو ویژگی مهم دارد. هر چه N_t به مرکز کلاس فازی $c\in C$ نزدیکتر باشد، میزان درجه عضویت آن به این کلاس فازی بیشتر خواهد بود. همچنین مجموع همه درجات عضویت برابر یک است که نشان دهنده نرمال‌سازی میزان درجات عضویت است.

متناظر با هر کلاس فازی تولید شده، یک شبکه عصبی تک-لایه طراحی شده است که ورودی آن $\Omega=(N_{t-1}.N_{t-2}.....N_{t-K})$ است. فرض شده است که شبکه N_t را بر اساس N_{t-1}، N_{t-2}، ... و N_{t-K} پیش‌بینی می‌کند. **شکل ۲** این شبکه را نشان می‌دهد. خروجی شبکه بر اساس رابطه

$$e_c=\sum_{k=1}^{K} N_{t-k}w_{ck}. \qquad (۳)$$

محاسبه می‌شود که در آن e_c مقدار پیش‌بینی شده برای N_t متناظر با کلاس فازی c است. بر این اساس مقدار پیش‌بینی شده برای N_t با توجه به مقادیر پیش‌بینی شده در هر کلاس فازی با رابطه زیر حساب می‌شود.

$$o_t=\sum_{c\in C} e_c\mu_c. \qquad (۴)$$

که در آن C مجموعه کلاس‌های فازی است.

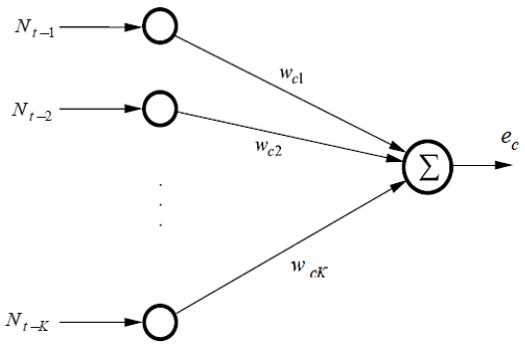

شکل ۲- شبکه عصبی متناظر با کلاس c.

Figure 2- Neural network corresponding to class c.

[1] Fuzzy c-means clustering

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

۱-۲- آموزش شبکه عصبی

داده‌های سری زمانی تعداد موارد مبتلا به بیماری کرونا را با $\Omega=(N_{t-1},N_{t-2},\ldots,N_{t-K})$ نشان می‌دهیم. در ابتدا الگوریتم خوشه‌بندی فازی را با ورودی $\Omega=(N_{t-1},N_{t-2},\ldots,N_{t-K})$ فراخوانی کرده و بردار مراکز اولیه $z=(z_c)_{c\in C}$ را تشکیل می‌دهیم. سپس با استفاده از الگوریتم زیر بردار مراکز بهبود داده می‌شود. الگوریتم آموزش جهت تعیین مراکز کلاس‌های فازی در ادامه تشریح شده است.

گام ۱. قرار دهید $i=1$ و بردار مراکز اولیه کلاس‌های فازی $z^1=(z_c^1)_{c\in C}$ را توسط الگوریتم خوشه‌بندی فازی محاسبه کنید. همچنین میزان خطای قابل قبول ε را مقداردهی اولیه کنید.

گام ۲. مقادیر توابع عضویت μ_c^i را با استفاده از **رابطه (۱)** حساب کنید.

گام ۳. بردار مراکز بروزرسانی شده را طبق رابطه زیر حساب کنید.

$$z_c^i=\frac{\sum_{k=1}^{K}\left(\mu_c^i(N_{t-k})\right)^2 N_{t-k}}{\sum_{k=1}^{K}\left(\mu_c^i(N_{t-k})\right)^2}. \qquad (۵)$$

گام ۴. اگر $\sqrt{\sum_{c\in C}(z_c^i-z_c^{i-1})^2}<\varepsilon$ متوقف شوید؛ در غیر این صورت به i یک واحد اضافه کرده و به گام ۲ بروید.

شکل ۳ فلوچارت فرآیند آموزش شبکه عصبی برای تعیین خوشه‌های فازی را نشان می‌دهد.

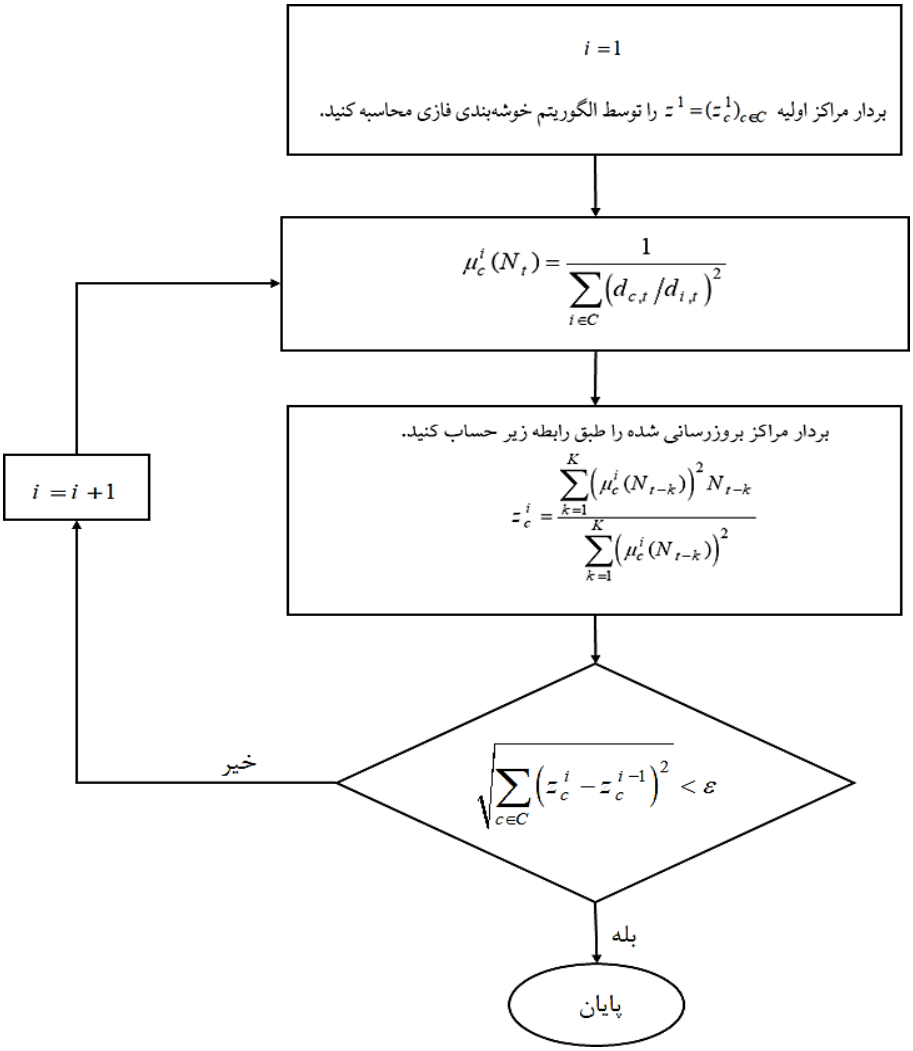

شکل ۳- فلوچارت آموزش شبکه عصبی جهت تعیین خوشه‌های فازی.

Figure 3- Neural network training flowchart to determine fuzzy clusters.

بردار مراکز و توابع عضویت کلاس‌های فازی طبق رابطه زیر برای تعیین مقادیر w_{ck} در مرحله بعد استفاده می‌شود.

$$o_t=\sum_{c\in C} e_c\mu_c=\sum_{c\in C}\left(\sum_{k=1}^{K} N_{t-k}w_{ck}\right)\mu_c\,. \qquad (۶)$$

اگر خطای شبکه برای پیش‌بینی مقدار w_{ck} را طبق رابطه زیر حساب کنیم:

$$E_t=(N_t-o_t)^2$$

آنگاه طبق **رابطه (۶)** می‌توان نوشت:

$$\frac{\partial E_t}{\partial w_{ck}}=-2N_{t-k}\mu_c(N_t-o_t)\,. \qquad (۷)$$

اگر آموزش شبکه عصبی را با روش کاهش گرادیان انجام دهیم، در هر تکرار وزن‌ها بر اساس رابطه زیر بروزرسانی می‌شود:

$$w_{ck}(new)=w_{ck}(old)-\frac{\alpha\left(-2N_{t-k}\mu_c(N_t-o_t)\right)}{\sum_{k=1}^{K}N_{t-k}^2}\,. \qquad (۹)$$

در این رابطه α نرخ آموزش شبکه است که در ابتدا مقدار بزرگی برای آن انتخاب می‌شود، سپس در طی الگوریتم به تدریج مقدار آن کاهش پیدا می‌کند. فرآیند کاهش به نحوی انجام می‌شود که در ابتدای الگوریتم کاهش سریعتر اتفاق می‌افتد تا بتوان فضای جستجوی مسئله را گسترده کرد و از افتادن در بهینه محلی جلوگیری کرد. هر چه به انتهای آموزش شبکه می‌رسیم به منظور جستجوی دقیق‌تر جواب، کاهش پارامتر α کندتر اتفاق می‌افتد. همچنین $-\frac{(-2N_{t-k}\mu_c(N_t-o_t))}{\sum_{k=1}^{K}N_{t-k}^2}$ جهت نرمال‌سازی شده بهبود وزن‌های شبکه عصبی به منظور کاهش میزان خطای شبکه است. فرآیند آموزش برای تعیین وزن‌های شبکه عصبی در ادامه تشریح شده است.

گام ۱. قرار دهید $i=1$. مقدار خطای قابل قبول ε را مقداردهی کنید. مقدار اولیه α را انتخاب کنید. مقادیر اولیه وزن‌ها را به صورت عدد تصادفی تولید شده توسط توزیع یکنواخت در بازه $[0,1]$ تولید کنید (سیچوکی و آنبهان[۱]، ۱۹۹۳).

گام ۲. مقدار o_t را بر اساس **رابطه (۶)** حساب کنید.

گام ۳. وزن‌های بروزرسانی شده را طبق رابطه $w_{ck}(i+1)=w_{ck}(i)-\frac{\alpha(-2N_{t-k}\mu_c(N_t-o_t))}{\sum_{k=1}^{K}N_{t-k}^2}$ محاسبه کنید.

گام ۴. اگر $\sqrt{\sum_{c\in C}\sum_{k=1}^{K}(w_{ck}(i+1)-w_{ck}(i))^2}<\varepsilon$ متوقف شوید در غیر این صورت قرار دهید $i=i+1$، $\alpha=\frac{1}{2}$ و به گام ۲ بروید.

فرآیند یادگیری شبکه عصبی جهت تعیین وزن‌های مرتبط با هر خوشه فازی در **شکل ۴** تشریح شده است.

۳- یافته‌های پژوهش

در این بخش شبکه عصبی-فازی پیشنهاد شده را برای پیش‌بینی موارد مبتلا و مرگ‌ومیر بر اثر بیماری کرونا در ۱۰ کشوری که بیشترین درگیری را با این بیماری داشته‌اند به‌کار برده شده است و نتایج به‌دست آمده با نتایج حاصل از شبکه عصبی و همچنین روش سری زمانی مقایسه شده است. فرض شده است که تعداد کلاس‌ها برابر ۳ و $\alpha=0.4$. لازم به ذکر است که تعداد کلاس‌ها، یک پارامتر در روش پیشنهادی مقاله است که مقدار آن ممکن است در مسائل مختلف و بر حسب داده‌های ورودی مختلف، متفاوت باشد. در مورد داده‌های مورد مطالعه در این مقاله که تعداد موارد مبتلا و مرگ‌ومیر ناشی از بیماری کرونا می‌باشد، با توجه به اینکه کشورهایی که بیشتر درگیر بیماری بوده‌اند درنظر گرفته شده است، با سه وضعیت زرد (متوسط)، نارنجی (پرخطر) و قرمز (خیلی پرخطر) روبرو هستیم. با آگاهی از وضعیت‌های موجود ۳ کلاس برای داده‌ها متصور می‌باشد.

[۱] Cichocki and Unbehauen

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

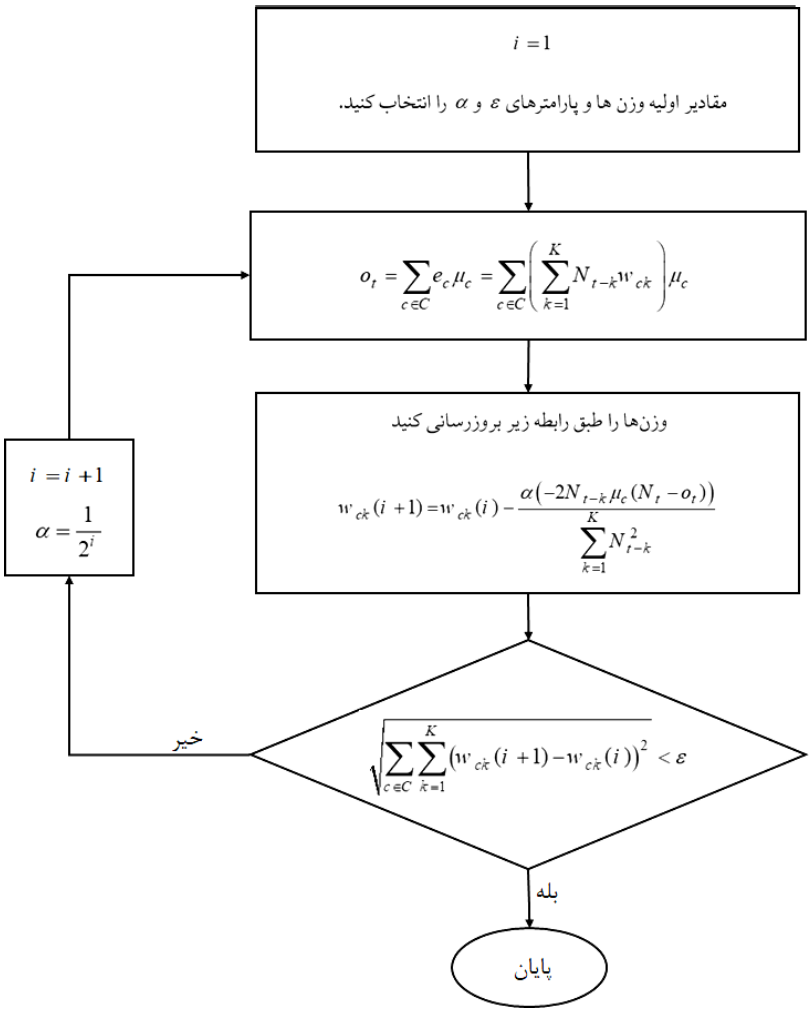

شکل ۴- فلوچارت یادگیری شبکه عصبی جهت تعیین وزن‌های مرتبط با هرخوشه فازی.

Figure 4- Neural network learning flowchart to determine the weights associated with each fuzzy cluster.

در تحلیل اولیه، داده‌های مربوط به مرگ‌ومیر ناشی از بیماری کرونا در کشور ایران از تاریخ ۲۰۲۰/۱۳/۰۴ تا ۲۰۲۰/۲۷/۰۵ درنظر گرفته شده است و عملکرد شبکه عصبی-فازی ارائه شده با شبکه عصبی پرسپترون و شبکه عصبی *RBF*[۱] مقایسه شده است. نتیجه این تحلیل در **شکل ۵** نشان داده شده است. **شکل ۵**، داده‌های واقعی مرگ‌ومیر، نتایج پیش‌بینی شده توسط شبکه عصبی-فازی پیشنهاد شده، نتایج پیش‌بینی شده توسط شبکه عصبی پرسپترون (پیش‌بینی سری زمانی) و تابع پیش‌بینی شده برای شبکه عصبی *RBF* را نمایش می‌دهد. در این آزمایش ۳۰ داده اول از تاریخ ۲۰۲۰/۱۳/۰۴ تا ۲۰۲۰/۱۳/۰۵ به عنوان داده‌های آموزش شبکه‌های عصبی و از ۱۴ داده نهایی از تاریخ ۲۰۲۰/۱۳/۰۵ تا ۲۰۲۰/۲۷/۰۵ به عنوان داده تست شبکه استفاده شده است. همچنین نرخ خطای پیش‌بینی برای هر یک از روش‌های به‌کار رفته محاسبه شده است. نرخ خطا برای شبکه عصبی-فازی برابر ۲/۱۸۷۳، برای شبکه عصبی پرسپترون برابر ۳/۷۲۹۴ و برای شبکه عصبی *RBF* برابر ۲/۲۷۰۶ است. بررسی **شکل ۵** و مقایسه نرخ خطا نشان می‌دهد که شبکه عصبی-فازی پیشنهادی بهترین عملکرد را برای پیش‌بینی داده‌های مرگ‌ومیر مربوط به بیماری کووید ۱۹ در ایران داشته است. نکته قابل توجه دیگر

[۱] Radial basic function

این است که تابع پیش‌بینی شده توسط شبکه عصبی *RBF*، یک تابع تقریبی با نرخ خطای مطلوب برای داده‌های غیرخطی مورد مطالعه تولید کرده است که نشان از قدرت شبکه‌های عصبی *RBF* برای شناسایی تابع *F(.)* برای هر نوع داده است.

شکل ۵- مقایسه عملکرد شبکه عصبی-فازی با شبکه عصبی پرسپترون چند لایه و شبکه عصبی **RBF**.
Figure 5- Comparison of neuro-fuzzy network with multi-layer perceptron and RBF neural network.

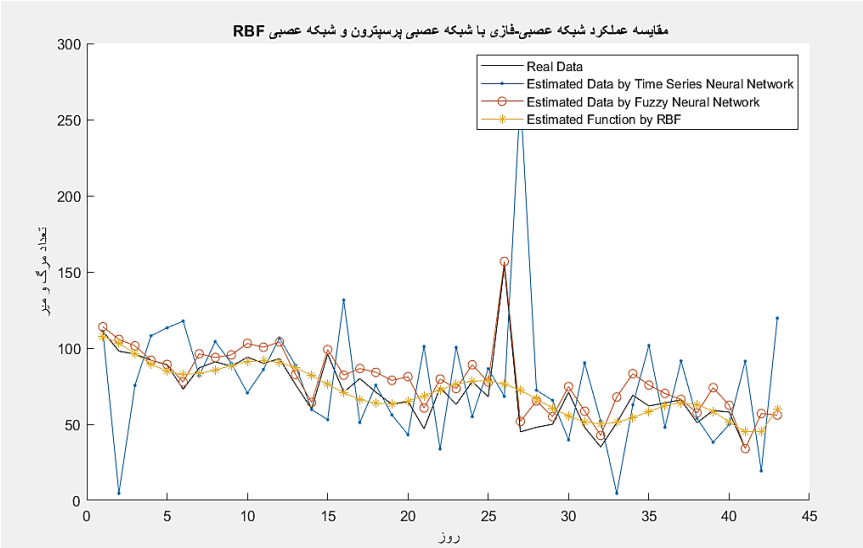

همچنین **شکل ۶** روند همگرایی شبکه عصبی-فازی را نشان می‌دهد. **شکل ۶** نشان می‌دهد که اگر تعداد تکرارهای الگوریتم آموزش شبکه عصبی-فازی به اندازه کافی زیاد باشد در نهایت نرخ خطای پیش‌بینی به سمت صفر میل خواهد کرد که نشان‌دهنده همگرایی الگوریتم آموزش شبکه عصبی-فازی می‌باشد. بررسی دقیق این شکل نشان می‌دهد که بین تکرارهای ۸۰۰ تا ۱۰۰۰، نرخ خطا افزایش و سپس کاهش پیدا کرده است تا در نهایت در محدوده تکرار ۱۴۰۰ به بالا به صفر میل کرده است که نشان از وجود یک جواب محلی در محدوده تکرارهای ۸۰۰ تا ۱۰۰۰ است و نکته قابل توجه این است که ساختار شبکه عصبی-فازی پیشنهادی و الگوریتم آموزش به‌کار رفته توانایی فرار از بهینه محلی و یافتن بهینه سراسری را دارد. علاوه بر این، زمان اجرای روش پیشنهادی شبکه عصبی-فازی برای پیش‌بینی تعداد مرگ‌ومیر ناشی از بیماری کووید ۱۹ در کشور ایران در ۱۵ روز آتی که در نرم‌افزار متلب و در کامپیوتر شخصی با ۱/۶-۱/۸ گیگاهرتز *CPU* و ۶ گیگابایت *RAM* پیاده‌سازی شده است، برابر ۷/۱۴۲ ثانیه بوده است. این زمان برای شبکه‌های عصبی برابر ۱۱/۴۵ ثانیه و برای شبکه‌های عصبی *RBF* برابر ۱۲/۳۲۴ ثانیه است. این نتایج نشان می‌دهد که خوشه‌بندی داده‌های ورودی و طراحی یک شبکه عصبی مجزا برای هر خوشه، زمان پیش‌بینی را برای داده‌های مورد مطالعه کاهش داده است.

جدول ۱ تعداد موارد مبتلای جدید به بیماری کرونا را در کشورهای هند، روسیه، ایران، برزیل و آمریکا از تاریخ اول ژوئن ۲۰۲۰ تا ۱۵ ژوئن ۲۰۲۰ و همچنین مقادیر پیش‌بینی شده توسط شبکه عصبی-فازی را نشان می‌دهد. با توجه به اینکه دوره نهفتگی بیماری کرونا بین ۱ الی ۱۴ روز است، بنابراین به منظور برنامه‌ریزی‌های آتی یک بازه ۱۵ روزه لازم است. هر چند می‌توان بازه پیش‌بینی را افزایش داد و همچنان از روش پیشنهادی استفاده کرد، اما افزایش بازه پیش‌بینی، دقت روش را کاهش می‌دهد. بنابراین در این مقاله بازه ۱۵ روزه پیش‌بینی برای برنامه‌ریزی کوتاه مدت مدیران و کادر درمانی درنظر گرفته شده است. داده‌های واقعی از سایت سازمان جهانی بهداشت استخراج شده است و همچنین نرخ خطای پیش‌بینی برای هر کشور گزارش شده است. برای پیش‌بینی مقادیر گزارش‌شده در **جدول ۱**، از مقادیر داده‌های یک ماه قبل یعنی تعداد موارد مبتلای جدید مربوط به ۱ مه ۲۰۲۰ تا ۳۱ مه ۲۰۲۰ در هر کشور، برای آموزش شبکه استفاده شده است. نتایج حاصل نشان می‌دهد که در همه موارد، روش پیشنهادی توانسته است با نرخ خطای کمتر از ۳، پیش‌بینی نسبتاً دقیقی از آمار جدید ارائه کند که برای پیش‌بینی موارد آینده جهت تصمیم‌گیری‌های درست و آمادگی کادر درمان مفید خواهد بود. همچنین بررسی دقیق‌تر نرخ خطای شبکه نشان می‌دهد که در همه موارد نرخ خطا عددی بین ۲ تا ۳ بوده است که نشان دهنده این موضوع مهم است که عملکرد شبکه عصبی-فازی پیشنهادی به داده‌های ورودی حساس نبود و بنابراین می‌توان آنرا برای پیش‌بینی تعداد موارد مبتلا و مرگ و میر ناشی از این بیماری در همه کشورها به‌کار برد، علی رغم اینکه در این مقاله جهت اختصار نتایج برای ۵ کشور گزارش شده است.

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

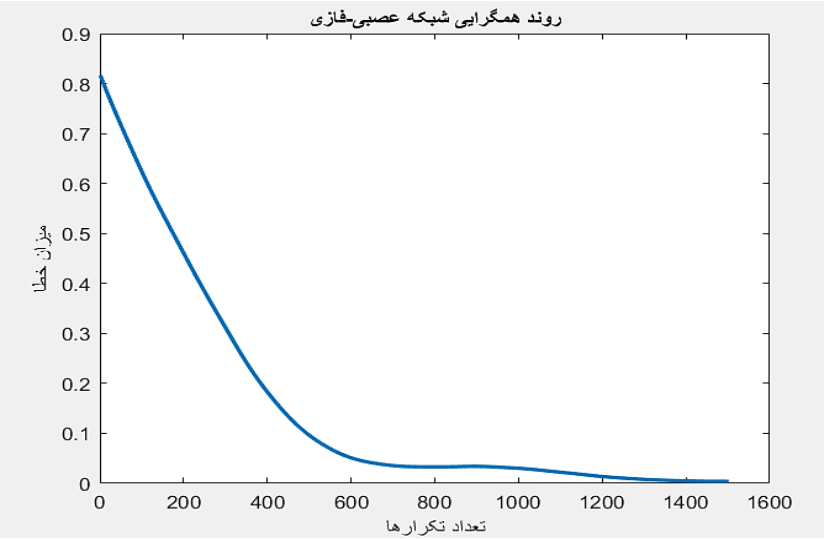

شکل ۶- روند همگرایی شبکه عصبی-فازی.

Figure 6- Neuro-fuzzy network convergence process.

در ادامه از شبکه عصبی-فازی برای پیش‌بینی تعداد موارد مبتلا به این بیماری در ایران برای بازه‌های زمانی ۱۳۹۸/۱۲/۱۵ تا ۱۳۹۸/۱۲/۲۹، ۱۳۹۹/۰۳/۱۵ تا ۱۳۹۹/۰۳/۲۹ و ۹۹/۰۶/۱۵ تا ۱۳۹۹/۰۳/۲۹ استفاده شده است و نرخ خطای پیش‌بینی در هر بازه گزارش شده است. نتایج حاصل از مقایسه نرخ خطا در بازه‌های زمانی مختلف نشان‌دهنده این است که روش پیشنهادی به زمان وابسته نیست زیرا نرخ خطا برای بازه‌های زمانی متفاوت که به ترتیب زمان اوج گیری اولیه بیماری، زمان مهار موج دوم بیماری و زمان شروع موج سوم بیماری تفاوت چشم گیری ندارد. البته برای بازه زمانی آخر، نرح خطا افزایش یافته است که دلیل آن احتمالاً افزایش ناگهانی و غیرقابل پیش‌بینی تعداد موارد مبتلا در این بازه است. داده‌های واقعی هم این مطلب را تصدیق می‌کند. تعداد موارد مبتلا از ۲۰۸۲ نفر در ۱۳۹۹/۰۶/۲۴ به ۲۶۱۹ نفر در ۱۳۹۹/۰۶/۲۵ افزایش یافته است.

۴- جمع بندی مقاله و جهت‌گیری‌های آتی

در این مقاله یک مدل شبکه عصبی-فازی جهت پیش‌بینی تعداد موارد مبتلای جدید و مرگ‌ومیر ناشی از بیماری کرونا در کشورهایی که بیشترین درگیری را با این بیماری داشته‌اند، ارائه شده است. مدل پیشنهادی با استفاده از ایده تجزیه، ابتدا داده‌های ورودی را به صورت فازی طبقه بندی کرده و فرآیند پیش‌بینی را برای هر طبقه انجام می‌دهد. سپس با تلفیق نتایج به‌دست آمده در هر طبقه، مقادیر پیش‌بینی شده نهایی را ارائه می‌دهد. روند همگرایی شبکه پیشنهادی تجزیه و تحلیل شده است و عملکرد آن با شبکه عصبی پیش‌بینی سری زمانی و شبکه عصبی *RBF* مقایسه شده است. همچنین شبکه پیشنهادی برای پیش‌بینی تعداد موارد مبتلای جدید به بیماری کرونا در ۱۵ روز آینده در ۵ کشور آمریکا، روسیه، ایران، هند و برزیل به‌کار رفته است. مقایسه نتایج نشان می‌دهد که در همه موارد شبکه عصبی-فازی پیشنهادی توانسته است با نرخ خطای کمتر، آینده این بیماری را پیش‌بینی کند که برای سیاست‌گذاری‌های آینده و مدیریت فرآیند درمان بسیار مهم است. شناسایی عوامل تاثیرگذار بر شیوع این بیماری و بررسی میزان اهمیت آن‌ها و همچنین تعیین مدل ریاضی شیوع این بیماری با توجه به عوامل تاثیرگذار شناسایی شده و ارائه راهکار عملیاتی جهت حل مدل از جمله اهداف آتی محققین خواهد بود.

نشریه تصمیم‌گیری و تحقیق در عملیات، دوره ۵، شماره ۴، زمستان ۱۳۹۹، صفحه: ۴۲۵-۴۱۴

جدول ۱- داده‌های واقعی مربوط به تعداد موارد مبتلا به بیماری کرونا و مقادیر پیش‌بینی شده توسط شبکه عصبی-فازی.

Table 1- Real data on the number of cases of corona disease and the values predicted by the neuro-fuzzy network.

کشور	هند		روسیه		ایران		برزیل		آمریکا	
تاریخ	مقدار تخمینی	مقدار واقعی	مقدار تخمینی	مقدار واقعی	مقدار تخمینی	مقدار واقعی	مقدار تخمینی	مقدار واقعی	مقدار تخمینی	مقدار واقعی
01/06/2020	8400	8392	9038	9035	2525	2516	33288	33274	23495	23482
02/06/2020	8184	8171	8864	8863	2986	2879	16422	16409	26134	26116
03/06/2020	8916	8909	8553	8536	3117	3117	11614	11598	14707	14692
04/06/2020	9303	9304	8873	8831	3135	3134	28932	28936	24886	24890
05/06/2020	9855	9851	8737	8726	3588	3574	28648	28633	14584	14583
06/06/2020	9906	9887	8868	8855	2900	2886	30928	30925	20087	20069
07/06/2020	9976	9971	8988	8984	2275	2269	30833	30830	28997	28992
08/06/2020	9995	9983	9002	8985	2381	2364	27088	27075	28919	28918
09/06/2020	9988	9987	8612	8595	2056	2043	18924	18912	17855	17848
10/06/2020	9989	9985	8421	8404	2105	2095	15663	15654	17541	17536
11/06/2020	10004	9996	8785	8779	2020	2011	32103	32091	17253	17235
12/06/2020	10958	10956	8990	8987	2252	2238	32914	32913	20326	20315
13/06/2020	11472	11458	8710	8706	2386	2369	30432	30412	21746	21745
14/06/2020	11943	11929	8850	8835	2419	2410	25993	25982	22147	22133
15/06/2020	11516	11502	8248	8246	2484	2472	21714	21704	25323	25314
نرخ خطا	2.68		2.53		2.73		2.18		2.19	

جدول ۲- مقادیر پیش‌بینی شده تعداد موارد مبتلا به بیماری کرونا در بازه‌های زمانی متفاوت در ایران.

Table 2- Predicted values of the number of cases of corona disease in different time periods in Iran.

روز	اسفند ۱۳۹۸		خرداد ۱۳۹۹		شهریور ۱۳۹۹	
	مقدار پیش‌بینی شده	مقدار واقعی	مقدار پیش بینی شده	مقدار واقعی	مقدار پیش‌بینی شده	مقدار واقعی
15	598	591	3144	3134	2038	2026
16	1243	1234	3591	3574	1900	1894
17	1081	1076	2891	2886	1993	1992
18	750	743	2275	2269	2156	2152
19	6043	595	2366	2364	2303	2302
20	8861	881	2061	2043	2320	2313
21	966	958	2107	2095	2063	2063
22	1089	1075	2020	2011	2321	2313
23	1297	1289	2250	2238	2148	2139
24	1368	1365	2379	2369	2088	2082
25	1271	1254	2422	2410	2633	2619
26	1019	1008	2482	2472	2721	2705
27	1185	1178	2463	2449	2986	2981
28	1196	1192	2573	2563	2825	2815
29	1050	1046	2631	2612	3057	3049
نرخ خطا	2.39		2.41		2.51	

سپاسگزاری

نویسندگان مقاله مراتب قدردانی خود را از داوران محترم اعلام می‌دارند. بی‌شک نقطه نظرات ارزشمندشان در بهبود کیفیت مقاله نقش بسزایی داشته است. همچنین ایشان تصدیق می‌کنند اطلاعات و آمار استفاده شده در این مقاله مبتنی‌بر حفظ محرمانه‌بودن اسرار پزشکی بیماران بوده و هیچ‌گونه بهره‌برداری غیرعلمی از آن نخواهد شد.

تعارض با منافع

نویسندگان اعلام دارند که هیچ تضادی در منافع در مورد انتشار این نسخه وجود ندارد.

منابع

Al-Qaness, M. A., Ewees, A. A., Fan, H., & Abd El Aziz, M. (2020). Optimization method for forecasting confirmed cases of COVID-19 in China. *Journal of clinical medicine, 9*(3), 1-15.

Cichocki, A. & Unbehauen R. (1993). *Neural networks for optimization and signal processing*. Wiley.

de Campos Souza, P. V. (2020). Fuzzy neural networks and neuro-fuzzy networks: A review the main techniques and applications used in the literature. *Applied soft computing, 92*. https://doi.org/10.1016/j.asoc.2020.106275

Du, Y., Cai, Y., Chen, M., Xu, W., Yuan, H., & Li, T. (2014). A novel divide-and-conquer model for CPI prediction using ARIMA, gray model and BPNN. *Procedia computer science, 31*, 842-851.

Fanelli, D., & Piazza, F. (2020). Analysis and forecast of COVID-19 spreading in China, Italy and France. *Chaos, solitons & fractals, 134*. https://doi.org/10.1016/j.chaos.2020.109761

Han, M., Zhong, K., Qiu, T., & Han, B. (2018). In terval Type-2 fuzzy neural networks for chaotic time series prediction: a concise overview. *IEEE transactions on cybernetics, 49*, 2720 – 2731.

Hasan, N. (2020). A methodological approach for predicting COVID-19 epidemic using EEMD-ANN hybrid model. *Internet of things, 11*. https://doi.org/10.1016/j.iot.2020.100228

Khosravi, A., Koury, R. N. N., Machado, L., & Pabon, J. J. G. (2018). Prediction of wind speed and wind direction using artificial neural network, support vector regression and adaptive neuro-fuzzy inference system. *Poultry science, 92*, 1138-1142.

Meng, E., Huang, S., Huang, Q., Fang, W., Wu, L., & Wang, L. (2019). A robust method for non-stationary streamflow prediction based on improved EMD-SVM model. *Journal of hydrology, 568*, 462-478.

Mizumoto, K., Kagaya, K., & Chowell, G. (2020). Effect of a wet market on coronavirus disease (COVID-19) transmission dynamics in China, 2019–2020. *International journal of infectious diseases, 97*, 96-101.

Shim, E., Tariq, A., Choi, W., Lee, Y., & Chowell, G. (2020). Transmission potential and severity of COVID-19 in South Korea. *International journal of infectious diseases, 93*, 339-344.

Singh, A. K., Singh, A., Shaikh, A., Singh, R., & Misra, A. (2020). Chloroquine and hydroxychloroquine in the treatment of COVID-19 with or without diabetes: A systematic search and a narrative review with a special reference to India and other developing countries. *Diabetes & metabolic syndrome: clinical research & reviews, 14*(3), 241-246.

Škrjanc, I., Iglesias, J. A., Sanchis, A., Leite, D., Lughofer, E., & Gomide, F. (2019). Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: a survey. *Information sciences, 490*, 344-368.

Tan, Q. F., Lei, X. H., Wang, X., Wang, H., Wen, X., Ji, Y., & Kang, A. Q. (2018). An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of hydrology, 567*, 767-780.

Tang, J., Liu, F., Zhang, W., Ke, R., & Zou, Y. (2018). Lane-changes prediction based on adaptive fuzzy neural network. *Expert systems with applications, 91*, 452-463.

Tang, J., Liu, F., Zou, Y., Zhang, W. & Wang, Y. (2017). An improved fuzzy neural network for traffic speed prediction considering periodic characteristic. *IEEE transactions on intelligent transportation systems, 18*, 2340-2350.

Tosepu, R., Gunawan, J., Effendy, D. S., Lestari, H., Bahar, H., & Asfian, P. (2020). Correlation between weather and Covid-19 pandemic in Jakarta, Indonesia. *Science of the total environment, 725*. https://doi.org/10.1016/j.scitotenv.2020.138436

Tseng, F.-M., & Hu, Y.-C. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert systems with applications, 37*, 1846–1853.

Tuli, S., Tuli, S., Tuli, R., & Gill, S. S. (2020). Predicting the growth and trend of COVID-19 pandemic using machine learning and cloud computing. *Internet of things, 11*. https://doi.org/10.1016/j.iot.2020.100222

Xiao, Q. (2017). Time series prediction using bayesian filtering model and fuzzy neural networks. *Optik, 140*, 104-113.

Licensee Decisions & Operations Research. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (http://creativecommons.org/licenses/by/4.0/).