



پیش‌بینی میزان انتشار CO₂ در ایران با استفاده از شاخص‌های مهم اقتصادی و استفاده از مدل‌های یادگیری عمیق

مهدی نجاتی^۱، زین‌العابدین صادقی^۱، محمدعلی عرب‌پور^{۱*}

^{۱*} - گروه اقتصاد، دانشکده مدیریت و اقتصاد، دانشگاه شهید باهنر، کرمان، ایران

نوع مقاله:	چکیده
پژوهشی	افزایش انتشار گازهای گلخانه‌ای در سالیان اخیر باعث نگرانی‌های زیادی برای بسیاری از جوامع و دوستداران محیط‌زیست شده است. یکی از این گازهای گلخانه‌ای مهم، دی‌اکسید کربن (CO ₂) می‌باشد. در این پژوهش با استفاده از متغیرها و شاخص‌های مهم اقتصادی و مجموعه داده‌های سری زمانی سال ۱۹۷۰-۲۰۱۸ که آن‌ها را به ۵ گروه مجزا به همراه یک گروه کل داده‌ها، تقسیم و به پیش‌بینی میزان انتشار CO ₂ در ایران پرداخته شد. برای این موضوع از مدل‌های یادگیری عمیق زیرمجموعه یادگیری ماشین استفاده شده است. این موضوع یک مسأله چند متغیره و یک مجموعه هدف بود که مقدار انتشار CO ₂ برای ۵ سال آینده (۵ سال بعد از سال ۲۰۱۸) پیش‌بینی و در انتها برای راستی آزمایی پیش‌بینی‌ها مقدار پیش‌بینی سال‌های ۲۰۱۹ و ۲۰۲۰ با CO ₂ واقعی این سال‌ها مقایسه شد. نتایج به‌دست‌آمده برای هر ۶ گروه مورد آزمایش نشان می‌دهد که مقدار انتشار CO ₂ در ایران برای سالیان آینده یک روند صعودی را در پی خواهد داشت و برای سال ۲۰۲۳ مقدار انتشار CO ₂ به محدوده ۸۵۰ الی ۹۰۰ میلیون تن خواهد رسید که می‌تواند یک فاجعه محیط‌زیستی و خطری برای انسان‌ها باشد. لذا پیشنهاد می‌شود دولت از یک برنامه بلندمدت با تأکید بر گروه‌های مهم، فرهنگ‌سازی در جامعه و وضع قوانین خاص‌تر برای کنترل مقدار انتشار CO ₂ استفاده نماید.
تاریخچه مقاله:	
دریافت: ۱۴۰۰/۰۸/۲۸	
پذیرش: ۱۴۰۰/۱۲/۱۵	
کلمات کلیدی:	
پیش‌بینی انتشار CO ₂	
یادگیری عمیق	
شبکه‌های عصبی مصنوعی	
آلودگی هوا	

مقدمه

افزایش مرگ‌ومیر ناشی از سکنه مغزی، بیماری‌های قلبی و سایر بیماری‌های تنفسی است (سازمان بهداشت جهانی، ۲۰۲۱). طبق آخرین برآورد سازمان بهداشت جهانی سالانه ۷ میلیون نفر در سراسر جهان بر اثر آلودگی جان خود را از دست می‌دهند. همچنین برخی مطالعات در برخی کشورها نشان می‌دهد که حتی ۶ درصد از کل مرگ‌ومیرها بر اثر آلودگی هوا رخ می‌دهد (Pluhar et al., 2009). Wilson و همکاران نیز در سال ۲۰۰۴ در پژوهشی در آمریکا نشان دادند که بین غلظت آلاینده‌های


آلودگی هوا یک تهدید بسیار بزرگ برای سلامتی انسان‌ها، آب‌وهوا و محیط‌زیست پیرامون ما می‌باشد. روند صعودی آلودگی هوا و تأثیرات زیان‌بار این آلودگی بر سلامت بشر یکی از چالش‌های مهم محیط‌زیستی در چند دهه‌های اخیر بوده است (Xie et al., 2018; Gifford, 1992). طبق آخرین گزارش ارزیابی پانل بین دولتی تغییرات اقلیمی در سال ۲۰۲۰، از دوران پیش صنعتی تاکنون متوسط سطح دمای زمین حدود ۱/۵ درجه گرم‌تر شده است. اثرات ترکیبی آلودگی هوای محیطی و خانگی سالانه باعث میلیون‌ها مرگ زودرس می‌شود که عمدتاً در نتیجه

هوا و افزایش مراجعین به بیمارستان رابطه معناداری وجود دارد (Wilson et al., 2004).

لذا آلودگی محیط زیست و تغییرات اقلیمی ناشی از انتشار گازهای گلخانه‌ای، یک مسأله جدی در سناریوی جهانی فعلی و سناریو تغییرات اقلیمی است (Hong et al., 2019). از جمله آلاینده‌های معمول موجود در هوا می‌توان به SOx، NOx، CO₂، CO و هیدروکربن‌ها اشاره کرد (Kang et al., 2020) که در این بین CO₂ بزرگ‌ترین گاز گلخانه‌ای است که موجب آلودگی هوا می‌شود و از ابتدای دوران پیش صنعتی حدود ۳۰ درصد افزایش یافته است. بر طبق آخرین آمار در سال ۲۰۱۹ میزان انتشار CO₂ در دنیا حدود ۳۶،۴۴ میلیارد تن بود که از این میزان حدود ۷۳۳ میلیون تن را ایران تولید کرده است. در واقع سهم ایران حدود ۲٪ از کل CO₂ دنیا می‌باشد (شکل ۱) (اطلس جهانی کربن، ۲۰۱۹).

بر طبق آخرین آمار جهانی از کشورهایی با بیشترین میزان انتشار CO₂ تا سال ۲۰۲۰، ایران به ترتیب بعد از کشورهای چین، امریکا، هند، روسیه و ژاپن در رتبه ۶ میزان انتشار CO₂ دنیا قرار دارد (شکل ۲) (اطلس جهانی کربن، ۲۰۲۰).


بر طبق آمار و ارقام سایت داده‌های جهان ما میزان مرگ‌ومیر ناشی از آلودگی هوا در ایران و ۵ کشور اول دنیا در انتشار CO₂ در شکل ۳ آورده شده است. با نگاهی ساده به این نمودارها می‌توان دریافت که ایران بعد از هند و چین بیشترین آمار مرگ‌ومیر بر اثر آلودگی هوا را در اختیار دارد. اگرچه میزان مرگ‌ومیر آن از متوسط جهانی پایین‌تر است و روند نزولی دارد، اما متأسفانه در سالیان گذشته روند نزولی مرگ‌ومیر کاهش پیدا کرده است.



شکل ۱- سهم ایران از کل CO₂ دنیا (منبع: اطلس جهانی کربن)

Rank	Country	MtCO ₂
1	China	10175
2	United States of America	5285
3	India	2616
4	Russian Federation	1678
5	Japan	1107
6	Iran	780
7	Germany	702
8	Indonesia	618
9	South Korea	611
10	Saudi Arabia	582

شکل ۲- رتبه ایران در انتشار CO₂ در دنیا (منبع: اطلس جهانی کربن)



شکل ۳- رتبه ایران در مرگ‌ومیر ناشی از انتشار CO₂ (منبع: دنیای ما در داده‌ها)

همیشه جز جدایی‌ناپذیر از انسان بوده است و نیاز مبرم به حفاظت از تنوع زیستی وجود دارد (Bamisile et al., 2021)، میزان و روند انتشار CO₂ به عنوان مهم‌ترین گاز گلخانه‌ای آلوده‌کننده هوا، در ایران علاوه بر اهمیت داخلی، با عنایت به سهم ایران در انتشار این گاز خطرناک در دنیا، از اهمیت بین‌المللی نیز برخوردار است. لذا یک پیش‌بینی دقیق از روند انتشار CO₂ در ایران می‌تواند در تعیین سیاست‌های درست جهت برنامه‌ریزی و کنترل این موضوع کارساز باشد.

از طرفی همان‌طور که می‌دانیم یکی از اهداف کشورها دستیابی به رشد و توسعه اقتصادی بالاتر می‌باشد که در راستای رسیدن به این هدف باید تولید خود را افزایش دهند و افزایش تولید با افزایش مصرف انرژی همراه خواهد بود. به عبارت ساده‌تر افزایش مصرف انرژی رشد اقتصادی را افزایش می‌دهد. در این راستا محمد شهباز و همکاران (۲۰۱۳) معتقدند که در بلندمدت بین انتشار CO₂ و رشد اقتصادی رابطه معناداری وجود دارد. در واقع توسعه اقتصادی انتشار CO₂ را کاهش و رشد اقتصادی باعث افزایش انتشار CO₂ می‌شود. Pata (۲۰۱۸) معتقد است که رشد اقتصادی و توسعه اقتصادی تخریب محیط‌زیست را افزایش می‌دهد. محمد صلاح‌الدین و همکاران (۲۰۱۷) بر این باورند که رشد اقتصادی و سرمایه‌گذاری مستقیم خارجی باعث افزایش انتشار CO₂ در کوتاه‌مدت و بلندمدت می‌شود. Wang و همکاران (۲۰۲۰) دریافتند که بین تولید ناخالص داخلی و انتشار

هم‌چنین بر طبق آخرین گزارش سایت شاخص عملکرد محیط‌زیستی در امتیازدهی و رتبه‌بندی کلی سلامت محیط‌زیست کشورهای دنیا بر اساس بهداشت عمومی، حفظ منابع طبیعی، کاهش انتشار گازهای گلخانه‌ای و کربن و غیره، ایران با ۴۸ امتیاز در رتبه ۶۷ در بین ۱۸۰ کشور دنیا قرار دارد. در این رتبه‌بندی کشورهای اروپایی دانمارک، لوکزامبورگ و سوئیس به ترتیب با امتیاز ۸۲/۵، ۸۲/۳ و ۸۱/۵ در رتبه‌های اول تا سوم دنیا قرار دارند و پس از آن‌ها نیز انگلستان و فرانسه قرار دارند.

طبق آخرین برآورد سازمان بهداشت جهانی تقریباً ۹۹ درصد مردم دنیا هوایی تنفس می‌کنند که حاوی سطوح بالایی از آلاینده‌ها است. با استناد به پژوهش‌ها و مطالعات فراوان علمی- دانشگاهی می‌توان نشان داد این روند رو به رشد آلودگی در دنیا در نتیجه‌ی افزایش سرعت فعالیت‌های اقتصادی صورت می‌گیرد.

امروزه تقریباً فعالیت تمام بخش‌های اقتصادی به آلودگی هوا منجر می‌شود. با توجه به آن‌چه که گفته شد و همان‌طور که در "تغییر جهان ما: برنامه ۲۰۳۰ برای توسعه پایدار" ذکر شده است، طبق سیزدهمین هدف توسعه پایدار، کشورها باید "اقدام فوری برای مبارزه با تغییرات آب‌وهوا و اثرات آن، تقویت انعطاف‌پذیری و ظرفیت سازگار با آب‌وهوا، خطرات و بلایای طبیعی در همه کشورها و ادغام اقدامات تغییر اقلیم در سیاست‌ها، استراتژی‌ها و برنامه‌ریزی‌های ملی انجام دهند" (Mikayilov et al., 2018) و از آن‌جایی که طبیعت


CO₂ رابطه مثبت وجود دارد. Hdom و Fuinhas (۲۰۲۰) معتقدند که تولید ناخالص داخلی باعث کاهش انتشار CO₂ می‌شوند. پروفیسور Li (۲۰۲۰) معتقد است رشد اقتصادی از عوامل اساسی در کاهش انتشار CO₂ هستند. Bamisile و همکاران (۲۰۲۰) نیز بر این باورند که درآمد ناخالص ملی در تمامی بخش‌ها (صنایع، حمل‌ونقل، ساختمان و غیره) با میزان انتشار CO₂ رابطه مثبت دارد. Kang و همکاران (۲۰۱۹) رشد تولید ناخالص داخلی و رشد جمعیت را عوامل مهم در انتشار CO₂ می‌دانند (Hoffmann, 2020). Mohmmmed و همکاران (۲۰۱۹) دریافتند که بین رشد اقتصادی با انتشار CO₂ رابطه قوی وجود دارد. Hu و همکاران (۲۰۲۰) معتقدند که رشد اقتصادی باعث افزایش انتشار CO₂ می‌شود. Zubair و همکاران (۲۰۲۰) نیز به این نتیجه رسیدند که یک رابطه بلندمدت بین انتشار کربن، ادغام تجارت، تولید ناخالص داخلی و سرمایه وجود دارد.

یکی دیگر از اثرات افزایش تولید و رشد اقتصادی افزایش درآمد است. در واقع اثر درآمد بیانگر آن است که رشد اقتصادی واسطه رابطه بین سرمایه انسانی و انتشار است. سرمایه انسانی به افزایش بهره‌وری نیروی کار و رشد اقتصادی کمک می‌کند (Romer, 1990) و از دیدگاه کشورهای در حال توسعه، درآمد ممکن است فقر را کاهش دهد، اما نگرانی‌های محیط‌زیستی را افزایش می‌دهد (Baloch et al., 2020). در همین راستا Le و همکاران (۲۰۲۰) معتقدند که درآمد باعث کاهش انتشار CO₂ می‌شود. Liu و همکاران (۲۰۱۹) نیز عقیده دارند که رشد درآمد باعث افزایش انتشار CO₂ خواهد شد. Zubair و همکاران (۲۰۲۰) به یک وجود رابطه بلندمدت بین انتشار کربن و درآمد پی بردند.

از طرفی با افزایش مصرف انرژی که عمدتاً از طریق افزایش مصرف سوخت‌های فسیلی ممکن است، گازهای گلخانه‌ای موجود در جو افزایش می‌یابد. سال‌هاست که کشورهای توسعه یافته برای دستیابی به رشد اقتصادی بالاتر تمرکز خود را به بهره‌برداری از انرژی پاک قرار داده‌اند. با این حال، قیمت پایین و دسترسی آسان به سوخت‌های معمولی هنوز باعث می‌شود که توجه ویژه‌ای به آن‌ها شود (Cai et al., 2018). این مهم برای کشوری همچون ایران که سرشار از معادن و منابع انرژی و


سوخت‌های فسیلی می‌باشد از اهمیت دوچندانی برخوردار است. در این راستا Muhammad (۲۰۱۹) دریافت که افزایش مصرف انرژی در همه کشورهای مورد مطالعه باعث افزایش انتشار CO₂ می‌شود. Hdom و Fuinhas (۲۰۲۰) معتقدند که انرژی آبی و انرژی‌های تجدیدپذیر باعث کاهش انتشار CO₂ می‌شوند. Li و همکاران (۲۰۲۰) بر این باور است که استفاده از انرژی (انرژی تجدید ناپذیر) و جایگزینی انرژی پاک (انرژی تجدید پذیر) از عوامل اساسی در کاهش انتشار CO₂ هستند. Cheikh و همکاران (۲۰۲۱) معتقدند که یک رابطه غیرخطی بین مصرف انرژی و رشد تولید ناخالص داخلی وجود دارد. Shahbaz و همکاران (۲۰۱۳) نیز به این مهم پی بردند که در بلندمدت بین انتشار CO₂ و مصرف انرژی رابطه معناداری وجود دارد. درواقع مصرف انرژی باعث افزایش انتشار CO₂ می‌شود. Le و همکاران (۲۰۲۰) معتقدند که مصرف انرژی و صنعتی شدن باعث افزایش انتشار CO₂ می‌شود. Salahuddin و همکاران (۲۰۱۸) مصرف برق را دلیل افزایش انتشار CO₂ در کوتاه‌مدت و بلندمدت می‌دانند. Wang و همکاران (۲۰۲۰) به این نتیجه رسیدند که نوآوری در فن‌آوری و مصرف انرژی تجدید پذیر با انتشار CO₂ رابطه منفی دارد. Xia و همکاران (۲۰۲۰) پی بردند که بیش از ۹۰ درصد از انتشار CO₂ در بخش صنعت چین ناشی از مصرف انرژی می‌باشد. همان‌طور که در اینجا به چند مورد اشاره شد، مطالعات زیادی رابطه بین مصرف انرژی و انتشار CO₂ را بررسی کرده‌اند که در همه آن‌ها اتفاق نظر بر این است که افزایش استفاده از سوخت‌های فسیلی باعث افزایش انتشار CO₂ می‌شود و استفاده از فناوری‌های نو، انرژی تجدیدپذیر و انرژی آب می‌تواند در کاهش انتشار CO₂ مؤثر باشد. در این راستا Kang و همکاران (۲۰۱۹) نیز در تحقیقات خود به این نتیجه رسیدند که اتحادیه اروپا به دلیل استفاده زیاد از انرژی پاک و بازده بالای انرژی به تعادل بین کاهش انتشار CO₂ و رشد اقتصادی دست‌یافته‌اند (Hoffmann, 2020).

با توجه به مطالب بیان شده و اهمیت موضوع انتشار گاز CO₂، این پژوهش قصد دارد با در نظر گرفتن عوامل و شاخص‌های مهم و تأثیرگذار، به پیش‌بینی انتشار CO₂ در ایران بپردازد و از آنجایی که انتخاب شاخص‌های



شکل ۴- دیاگرام مدار RNN

که اگر این دیاگرام باز شود همانند شکل ۵ خواهد بود (یک لایه باز شده از شبکه RNN).



شکل ۵- سمت چپ. دیاگرام مدار. مربع سیاه رنگ نمایانگر تأخیر زمانی یک گام زمانی است. سمت راست: همان شبکه که به صورت یک گراف محاسباتی باز شده نمایش داده شده است.

در شکل ۵ هر نود مرتبط با یک زمان خاص است. (اشاره به یک گام زمانی دارد)

در این تصاویر $x_t \in R^M$ یک ورودی، $h_t \in R^N$ حالت مخفی یا همان حافظه و y_t نیز خروجی است. t یا n در این جا اشاره به طول گام‌های زمانی دارد. که با وارد کردن اطلاعات سری زمانی به این مدل از طریق RNN می‌توان خروجی y_t را دریافت کرد. در واقع یک ساختار RNN دارای روابط بین واحدهای مخفی است که می‌توان آن‌ها را به شرح زیر توصیف کرد:

در اینجا: $W_{in} \in R^{N \times M}$ و $W_{rec} \in R^{N \times N}$ و $b \in R^N$ و $W_{out} \in R^{N \times M}$ متغیرهایی هستند که باید آموزش ببینند که به ترتیب ماتریس وزن ورودی، ماتریس وزن مکرر، ماتریس وزن خروجی و سوگیری (بایاس) نامیده می‌شوند. تابع فعال‌ساز و معمولاً یک تابع غیرخطی مثل $\tanh$ ، relu یا selu هستند. N و M نیز به ترتیب ابعاد، ویژگی‌های ورودی و تعداد نوروهای پنهان هستند.

$$h_t = \sigma_h(W_{in}x_t + W_{rec}h_{t-1} + b_h)$$

$$y_t = \sigma_y(W_{out}h_t + b_y)$$

در اینجا: $W_{in} \in R^{N \times M}$ و $W_{rec} \in R^{N \times N}$ و $b \in R^N$ و $W_{out} \in R^{N \times M}$ متغیرهایی هستند که باید آموزش ببینند که به ترتیب ماتریس وزن ورودی، ماتریس وزن مکرر، ماتریس وزن خروجی و سوگیری (بایاس) نامیده می‌شوند.

تابع فعال‌ساز و معمولاً یک تابع غیرخطی مثل $\tanh$ ، relu یا selu هستند. N و M نیز به ترتیب ابعاد، ویژگی‌های ورودی و تعداد نوروهای پنهان هستند.

تأثیرگذار و مرتبط با موضوع، کار بسیار مهم و پیچیده‌ای می‌باشد، در اینجا با توجه به مطالعات گذشته و نتایج بدست آمده در مورد تأثیر و اهمیت هر یک از پارامترها، انتخاب صورت گرفته است.

از طرفی امروزه با توجه به پیشرفت‌های صورت گرفته در حوزه هوش مصنوعی مدل‌های هوشمند و کارآمدی برای پیش‌بینی میزان انتشار CO₂ وجود دارد (Dai et al., 2018). لذا در اینجا با استفاده از مدل‌های یادگیری عمیق داده‌های سری زمانی مربوط به ایران را تحلیل و پیش‌بینی و مقدار CO₂ را برای ۵ سال آینده تخمین زده شد. هم‌چنین بعد انجام این کار مقدار خطای حاصل از هر یک از روش‌ها را به دست آورده و با مقایسه این خطا بهترین و بدترین مدل برای پیش‌بینی مشخص گردید. در آخر نیز برای راستی آزمایی مقدار پیش‌بینی با مقدار واقعی سال‌های ۲۰۱۹ و ۲۰۲۰ مقایسه شد.


مواد و روش‌ها

الگوریتم‌های استفاده‌شده در این پژوهش شامل CNN، LSTM، GRU، Simple RNN و MLP می‌باشند و مسأله‌ای که با آن روبرو هستیم یک سری زمانی چند متغیره (X_i) با یک مجموعه هدف ($Y=CO_2$) است که هدف پیش‌بینی ۵ گام زمانی بعد (۵ سال آینده) آن است. در ادامه به معرفی اجمالی این الگوریتم‌ها می‌پردازیم:

شبکه‌های عصبی بازگشتی

RNN در سال ۱۹۸۶ و بر اساس کار Rumelhart's ساخته شد. همان‌طور که از نام این مدل مشخص است، این نوع از شبکه‌ها به صورت بازگشتی عمل می‌کنند. یعنی یک عملیات برای تک‌تک المان‌های یک سری زمانی انجام می‌گیرید و خروجی آن وابسته به ورودی فعلی و عملیات‌های قبلی است. این کار از طریق تکرار یک خروجی از شبکه در زمان t با ورودی شبکه در زمان $t+1$ انجام می‌شود (یعنی خروجی از مرحله قبل با ورودی تازه در مرحله جدید ترکیب می‌شوند). در واقع این شبکه‌ها دارای حلقه‌ای در درون خود هستند که به وسیله آن می‌توانند اطلاعات را در حین خواندن ورودی از نوروها عبور دهند که این عملیات را می‌توان در شکل ۴ مشاهده کرد.

بردار فعال سازی دلخواه، z_t بردار دروازه به روزرسانی، r_t بردار دروازه بازنشانی، $W - U - b$ پارامترهای ماتریس و بردار تابع فعال ساز، σ_g یک تابع سیگموئید اصلی است. ϕ_h نیز یک تانژانت هایپربولیک است و تصویر کلی این مدل در شکل ۷ نشان داده شده است.




شکل ۷- دیاگرام کلی مدل GRU

پس می توان رابطه مورد نظر را به شکل زیر نوشت:

$$h_t = \tanh(W_{in}x_t + W_{rec}h_{t-1} + b_h)$$

$$y_t = \tanh(W_{out}x_{ht} + b_y)$$

تصویر کلی آن در شکل ۶ قابل مشاهده می باشد.



شکل ۶- دیاگرام کلی مدل RNN

حافظه طولانی کوتاه-مدت (LSTM)

LSTM در سال ۱۹۹۷ میلادی توسط Hochraeter و Schmidber ارائه شد (Hochreiter). یک شبکه عصبی بازگشتی سنتی، اگر به اندازه کافی بزرگ باشد از نظر تئوری باید قادر به تولید دنباله هایی با هر پیچیدگی ای باشد اما در عمل مشاهده می شود که این شبکه در ذخیره سازی اطلاعات مرتبط با ورودی های گذشته به مدت طولانی با مشکل مواجه است (Hochreiter et al., 2001). "فراموشی" قدرت شبکه در بلندمدت را کاهش می دهد و باعث ناپایداری می شود. لذا اگر پیش بینی به ورودی های اخیر که خود تولید کرده است وابسته باشد احتمال جبران اشتباهات کاهش می یابد. حال با وجود یک حافظه بلندمدت تر حتی اگر شبکه نتواند با اطلاعات اخیر مدل سازی قابل قبولی انجام دهد، با نگاه به گذشته پیش بینی خود را می تواند تکمیل کند. یک راه حل برای مدل های شرطی تزریق نویز به پیش بینی های صورت گرفته توسط شبکه قبل از تغذیه آن ها به گام زمانی بعدی است (Taylor & Hinton, 2009). این کار باعث تقویت شبکه در برابر ورودی های غیر قابل پیش بینی می شود. اما یک حافظه بهتر می تواند انتخاب مناسب تری باشد. حافظه طولانی کوتاه مدت یا به اختصار LSTM که یک معماری شبکه عصبی بازگشتی است و برای ذخیره سازی و

Gated Recurrent Unit (GRU)

GRU برای اولین بار در سال ۲۰۱۴ توسط کیونگهیون Cho و همکاران معرفی شدند. GRU را می توان نسخه ی تغییر یافته از LSTM در نظر گرفت. زیرا هر دو این مدل ها طراحی مشابهی دارند و در بعضی از موارد حتی نتایجی مشابه ارائه می دهند. یکی از مشکلاتی که مدل RNN با آن مواجه می شود این است که با زیاد شدن عمق شبکه عصبی با مشکل محوشدگی گرادیان روبرو خواهد شد؛ این عمق در شبکه های عصبی بازگشتی همان گام زمانی می باشد زیرا می دانیم در این شبکه ها هر گام زمانی به منزله یک لایه در شبکه های پیش خور است. مدل GRU برای حل مشکل محوشدگی گرادیان و همچنین کاهش سربار موجود در معماری LSTM ارائه شده است. در این مدل یک دروازه به روزرسانی و دروازه بازنشانی جدید اضافه می شود. درواقع دروازه بازنشانی بررسی می کند چه میزان از اطلاعات گذشته در گام فعلی مورد نیاز نیست و می تواند فراموش شود. لذا می توان چنین نوشت:

$$z_t = \sigma_g(W_zx_t + U_zh_{t-1} + b_z)$$

$$r_t = \sigma_g(W_rx_t + U_rh_{t-1} + b_r)$$

$$\tilde{h}_t = \phi_h(W_hx_t + U_h(r_t \odot h_{t-1}) + b_h)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

که در اینجا: z و r به ترتیب دروازه به روزرسانی و دروازه بازنشانی هستند. x_t بردار ورودی، h_t بردار خروجی،

دارد و بسته به نوع مسئله از یکی از موارد زیر استفاده می‌شود.

CNN یک بعدی: هسته CNN در یک جهت حرکت می‌کند و اغلب برای داده‌های سری زمانی از این مدل CNN استفاده می‌شود.

CNN دو بعدی: هسته CNN در دو جهت حرکت می‌کند و اغلب برای پردازش تصویر سیاه و سفید، بارکد خوان و ... از این مدل CNN استفاده می‌شود.

CNN سه بعدی: هسته CNN در سه جهت حرکت می‌کند و اغلب برای پردازش تصویر رنگی، سی‌تی‌اسکن و غیره از این مدل CNN استفاده می‌شود.

مدل CNN از نورون‌ها با وزن و بایاس تشکیل شده است که نسبت به داده‌های ورودی، عملیات یادگیری را انجام می‌دهند. در حالت یک بعدی که برای پیش‌بینی سری زمانی از آن استفاده می‌شود، داده‌های ورودی به صورت $x = (x_1, x_2, \dots, x_n, cl)$ می‌باشد که در اینجا:

$x_n \in R^d$ و نشان دهنده ویژگی‌های مسئله و $cl \in R$ و نشان دهنده برچسب کلاس می‌باشد.

کانولوشن یک بعدی با اعمال عملیات کانولوشن روی داده‌های ورودی که در بالا بیان شد و با استفاده از فیلتر $w \in R^{fd}$ ، نقشه ویژگی f_m را می‌سازد و F نشان دهنده ویژگی‌های ذاتی داده‌های ورودی می‌باشد که در خروجی تولید می‌شود.

$$hl_i^{fm} = \tanh(W^{fm} x_{i:f-1} + b)$$

در اینجا: $b \in R$ و بایاس می‌باشد.

فیلتر hl برای هر مجموعه‌ای از ویژگی‌های f در داده‌های ورودی تعریف شده به وسیله $\{x_{1:f}, x_{2:f+1}, \dots, x_{n-f+1}\}$

استفاده می‌شود تا نقشه ویژگی زیر به دست آید:

$$hl = [hl_1, hl_2, \dots, hl_{n-f+1}]$$

و در این فرمول: $b \in R$ بایاس و $hl \in R^{n-f+1}$ می‌باشد.

سپس خروجی لایه کانولوشن به لایه ادغام داده می‌شود، در این لایه عملیات نمونه‌برداری انجام می‌شود. هم‌چنین شایان ذکر است که لایه کانولوشن از تابع فعال‌سازی ReLU استفاده می‌کند و حداکثر (x, 0) را برای هر یک از ورودی‌های ReLU با x نشان می‌دهد. در اینجا عملیات حداکثر جمع‌آوری بر روی هر یک از نقشه ویژگی‌ها

دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است.


$$\begin{aligned} i_t &= \sigma(W_{x_i}x_t + W_{h_i}h_{t-1} + W_{c_i}c_{t-1} + b_i) \\ f_t &= \sigma(W_{x_f}x_t + W_{h_f}h_{t-1} + W_{c_f}c_{t-1} + b_f) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_{x_c}x_t + W_{h_c}h_{t-1} + b_c) \\ o_t &= \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + W_{c_o}c_t + b_o) \\ h_t &= o_t \odot \tanh(c_t) \end{aligned}$$

در اینجا:

σ تابع سیگموئید لجستیک، c, f, o, i به ترتیب دروازه ورودی، دروازه فراموشی، دروازه خروجی، بردارهای فعال‌سازی ورودی سلول به سلول می‌باشند. H بردار مخفی، W_{h_i} ماتریس دروازه ورودی مخفی W_{x_o} ماتریس دروازه خروجی مخفی، W_{c_i} ماتریس وزن از سلول به بردار دروازه هستند. پارامتر m در هر بردار دروازه ورودی را از بردار سلول دریافت می‌کند.

نکته: اندازه بردارهای c, f, o, i با بردار h برابر است.

پارامترهای بایاس (که به c, f, o و اضافه می‌شوند) برای درک بهتر حذف شده‌اند و تصویر یک سلول آن در شکل ۸ آمده است.



شکل ۸- دیاگرام کلی مدل LSTM


شبکه عصبی پیچشی CNN

شروع شکل‌گیری CNN از کار Hubel و Wiesel در دهه ۱۹۵۰ و ۱۹۶۰ آغاز شد (Hubel & Wiesel, 2020) و کم‌کم بدر دوره‌های مختلف و توسط دانشمندان مختلف پیشرفت کرد. شبکه عصبی کانولوشن (CNN) نوع خاصی از پرسپترون چند لایه (MLP) می‌باشد (در بخش بعدی به توضیح آن پرداخته خواهد شد). CNN انواع مختلفی


$\overline{hl} = \max\{hl\}$ انجام می‌شود. مهم‌ترین ویژگی‌هایی که بالاترین ارزش را دارند به دست می‌آورد. سپس ویژگی‌های جدید به طور کامل به لایه متصل می‌شوند سپس تابع فعال‌سازی (در اینجا softmax) بر روی آن اعمال می‌شود

و در نهایت مقدار خروجی نهایی را به عنوان y_t از نورون دریافت می‌کند. یک لایه کاملاً متصل از نظر ریاضی به صورت زیر نشان داده می‌شود:

$$y_t = \text{softmax}(W_{hy}hl + b_y)$$



شکل ۹- دیاگرام کلی مدل CNN



شکل ۱۰- دیاگرام کلی مدل MLP

پرسپترون چندلایه

MLP ها یک راه حل رایج برای یادگیری ماشین در دهه ۱۹۸۰ برای حل مسائل تشخیص گفتار، تشخیص تصویر و نرم‌افزار ترجمه ماشینی بودند (Wasserman & Schwartz, 1988). پرسپترون چند لایه، دسته‌ای از شبکه‌های عصبی مصنوعی پیش‌خور هستند که حداقل شامل ۳ گره، یک لایه ورودی، یک لایه پنهان و یک لایه خروجی می‌باشد که هر لایه به طور کامل به لایه قبلی و همچنین لایه بعدی متصل است. نودهای شبکه عصبی یا همان نرون‌ها واحدهای محاسباتی یک شبکه عصبی محسوب می‌شوند. در این شبکه عصبی، از خروجی‌های لایه اول (ورودی)، به عنوان ورودی‌های لایه بعدی (پنهان) استفاده می‌شود. این کار به همین شکل ادامه پیدا می‌کند، تا زمانی که، پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه پنهان به عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. مطابق با شکل زیر به لایه‌هایی که بین لایه ورودی و لایه خروجی قرار می‌گیرند، «لایه‌های پنهان» گفته می‌شود.

به جز گره‌های ورودی، هر گره یک نورون است که از یک تابع فعال‌سازی غیرخطی استفاده می‌کند.


$$a^{(l+1)} = \sigma(W^{(l)}a^{(l)} + b^{(l)})$$

در اینجا l مربوط به یک لایه خاص است و W^l و b^l به ترتیب وزن و بایاس در لایه l هستند. همچنین نمایانگر تابع فعال‌ساز غیرخطی می‌باشد. برای یک پرسپترون چند لایه با m لایه، اولین لایه ورودی برابر خواهد بود با $x = a^{(1)}$ و همچنین آخرین لایه خروجی نیز چنین خواهد بود:

$$h_{(w,b)}(x) = a^{(m)}$$


در اینجا نیز w, b به ترتیب وزن و بایاس می‌باشند.

بحث‌های آماری چنین توابعی، زیان L^2 می‌گویند (شکل ۱۱).



شکل ۱۱- تابع زیان میانگین مربعات

همان‌طور که می‌دانیم توابع زیان زیادی همچون تابع زیان میانگین خطای مطلق و غیره نیز وجود دارد که از طریق آن‌ها نیز می‌توان مقدار خطا را محاسبه کرد و هر کدام از این توابع مزایا و معایبی دارند. اما می‌دانیم که تابعی همچون MAE علی‌الخصوص در شبکه‌های عصبی، مقدار گرادیان آن برای مقدارهای کوچک خطا نیز بزرگ است و این یک مشکل بزرگ و دلیل عدم استفاده از این تابع زیان MAE در محاسبات ما می‌باشد. در صورتی که MSE با این مشکل مواجه نیست و زمانی که خطا بزرگ باشد گرادیان زیاد و زمانی که خطا کم شود، کاهش خواهد یافت (شکل ۱۲).



همان‌طور که می‌دانید در شبکه‌های عصبی، یادگیری با تغییر وزن اتصال پس از پردازش هر قطعه از داده‌ها، مطابق با میزان خطا در خروجی در مقایسه با نتیجه مورد انتظار انجام می‌شود؛ پس تابع هدف ما در اینجا به حداقل رساندن اختلاف بین خروجی‌های پیش‌بینی شده و خروجی‌های مورد نظر است:

$$J(W, b; x, y) = \frac{1}{2} \| h_{(W,b)}(x) - y \|^2$$


تابع زیان میانگین مربعات

برای محاسبه خطا در این پیش‌بینی‌ها ما از تابع زیان میانگین مربعات (MSE) استفاده خواهد شد که یکی از معروف‌ترین و متداول‌ترین توابع زیان در تحلیل رگرسیونی می‌باشد. در واقع این تابع زیان، میانگین مربعات فاصله بین مقدار پیش‌بینی و واقعی را محاسبه می‌کند. که فرمول آن به شکل زیر خواهد بود:

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n}$$

که در اینجا y_i مقدار واقعی، $\hat{y}_i$ مقدار پیش‌بینی و n تعداد کل پیش‌بینی/واقعی شده می‌باشد.

و به دلیل استفاده از ۲ در فرمول محاسبه این تابع زیان، شکل آن به صورت سهمی خواهد بود که در



شکل ۱۲- تفاوت محاسبه توابع MSE (سمت چپ) و MAE (سمت راست)

سپس مطابق با آنچه که در جدول ۱ مشاهده می‌کنید، داده‌ها را به ۵ گروه به علاوه ۱ گروه شامل کل داده‌ها تقسیم کرده و هر کدام از این ۶ گروه را با استفاده از تمامی مدل‌های یادگیری عمیق، X_i و Y موجود سیستم را آموزش داده و سپس به پیش‌بینی مقدار انتشار CO₂ در ایران برای ۵ سال

روش حل

همان‌طور که گفته شد برای حل این مسأله از ۵ الگوریتم و مدل یادگیری عمیق استفاده شده است. در ابتدا با استفاده از تکنیک‌های پیش‌پردازش داده، داده‌ها را نرمال کرده و داده‌های گم شده را با استفاده از متد Bfill جایگزین شد.

گروه ۱	تولید ناخالص داخلی و اجزاء	۱- مصرف خصوصی ۲- صرف دولتی ۳- تشکیل سرمایه ثابت ناخالص (GFCF) ۴- افزایش خالص سهام ۵- صادرات کالا و خدمات (کاهش) ۶- واردات کالا و خدمات ۷ تولید ناخالص داخلی به قیمت بازار
گروه ۲	متغیرهای جمعیتی و عوامل تولید	۱- جمعیت، کل ۲- جمعیت مرد و زن ۳- تعداد کارکنان ۴- کیفیت کار ۵- درآمد نیروی کار ۶- سهم سرمایه (به قیمت فعلی) ۷- ورودی سرمایه (خدمات سرمایه) ۸- درآمد سرمایه ۹- بهره‌وری کل عوامل ۱۰- بهره‌وری نیروی کار (بر اساس ساعات کار)
گروه ۳	شاخص‌های قیمت	۱- تعدیل کننده تولید ناخالص داخلی ۲- شاخص قیمت مصرف کننده ۳- برابری قدرت خرید برای تولید ناخالص داخلی (LCU به ازای هر دلار بین‌المللی) ۴- برابری قدرت خرید برای مصرف خصوصی (LCU به ازای هر دلار بین‌المللی)
گروه ۴	متغیرهای تولید بخش‌های مختلف	۱- کشاورزی، شکار، جنگلداری و ماهیگیری ۲- معدن و استخراج معادن ۳- تولید ۴- ساخت و ساز ۵- تجارت عمده و خرده، تعمیر وسایل نقلیه و لوازم خانگی، هتل و رستوران ۶- املاک و مستغلات
گروه ۵	متغیرهای تولید و مصرف انرژی	۱- تولید نفت - بشکه ۲- مجموع مایعات - مصرف ۳- نفت - ظرفیت پالایش ۴- گاز - تاریخچه ذخایر اثبات شده ۵- تولید گاز - میلیارد متر مکعب ۶- مصرف گاز - میلیارد متر مکعب ۷- مصرف زغال سنگ - EJ ۸- تولید هیدرولیک - TWh ۹- تولید برق ۱۰- تولید برق از نفت ۱۱- تولید برق از گاز

آینده پرداخته شد. در انتها نیز مقدار تابع زیان میانگین مربعات هر یک از روش‌ها را به دست آورده و با هم مقایسه شده است.

سپس برای انتخاب lag بهینه در مدل‌ها از نمودار ACF^1 استفاده شده است. همان‌طور که می‌دانیم برای اینکه بتوان از این روش مقدار lag بهینه را به دست آورد نیاز به سری زمانی ایستا می‌باشد. لذا با استفاده از آزمون ADF ایستایی سری زمانی بررسی و به دلیل ایستا نبود، با استفاده از "تابع تفاوت" ایستا شده است.

در این پژوهش در تمامی مدل‌ها مراحل از ۸۰٪ داده‌ها برای آموزش سیستم و از ۲۰٪ باقی مانده برای آزمون استفاده شده است.

در آخر هم پس از اجرای مدل با استفاده از داده‌های ورودی نتایج حاصل و خروجی در مورد پیش‌بینی مقدار CO_2 برای ۵ سال آینده هر یک از به تفکیک گروه و مدل به دست آورده شد.

داده‌ها

در این پژوهش از داده‌ها در دوره زمانی ۱۹۷۰-۲۰۱۸ مربوط به کشور ایران استفاده شده است. این داده‌های از سایت سازمان بهره‌وری آسیایی و بانک جهانی جمع‌آوری شدند. لیست داده‌های مورد استفاده به تفکیک در جدول ۱ آورده شده است.

همچنین برای تشکیل یک سری زمانی معتبر و رسیدن به جواب‌های منطقی‌تر با استفاده از نرم‌افزار Eviews داده‌های سالیانه به ماهیانه تبدیل شد. طبق برآوردهای انجام شده مشخص شد که تبدیل داده‌ها به ماهیانه باعث می‌شود تا ماشین در یادگیری دقت بیشتر و خطای کمتری داشته باشد.

جدول ۱- داده‌های مورد استفاده در پژوهش به تفکیک گروه


¹ Auto Correlation Plot

نتایج

نتایج حاصل از انجام کار به شرح جدول ۲ می‌باشد:


جدول ۲- نتایج حاصل از هر روش به تفکیک گروه، روش پیش‌بینی و سال

	سال	RNN		GRU		LSTM		CNN		MLP	
		MSE	پیش‌بینی CO ₂	MSE	پیش‌بینی CO ₂	MSE	پیش‌بینی CO ₂	MSE	پیش‌بینی CO ₂	MSE	پیش‌بینی CO ₂
گروه ۱	۲۰۱۹	۰/۰۲۴۲	۵۲۷/۲۳۲۳	۰/۰۰۸	۵۷۴/۹۶۹۸	۰/۰۳۰۳	۵۲۰/۳۲۰۷۴	۰/۱۳۷۸	۵۲۷/۲۳۲۳	۰/۰۲۱۳	۵۶۶/۴۱۸۴۶
	۲۰۲۰		۵۴۷/۷۹۴۷		۵۹۸/۷۶۸۷۴		۵۴۳/۱۹۳۷		۵۴۷/۷۹۴۷		۵۸۷/۳۸۸۸۵
	۲۰۲۱		۵۶۹/۸۱۲۴		۶۱۲/۰۵۸۸۴		۵۶۴/۳۸۰۳		۵۶۹/۸۱۲۴		۶۱۲/۸۳۵۴۵
	۲۰۲۲		۵۹۴/۱۹۵۹		۶۴۸/۲۰۰۸		۵۸۷/۵۱۶۶		۵۹۴/۱۹۵۹		۶۲۵/۲۳۴۱
	۲۰۲۳		۶۱۴/۰۵۵۳		۶۶۷/۸۷۱		۶۰۸/۴۲۷۸		۶۱۴/۰۵۵۳		۶۳۴/۷۲۸۶
گروه ۲	۲۰۱۹	۰/۰۰۳۱	۷۵۲/۲۵۰۶	۰/۰۰۳۹	۶۵۵/۶۷۵۲۳	۰/۰۰۳۵	۷۰۸/۰۸۰۷	۰/۰۸۸۶	۷۵۲/۲۵۰۶	۰/۰۲۰۱	۷۵۰/۳۰۱۹
	۲۰۲۰		۷۸۰/۲۰۰۵۶		۶۸۴/۱۲۴۶		۷۴۰/۸۵۹۶		۷۸۰/۲۰۰۵۶		۷۷۸/۵۵۰۴
	۲۰۲۱		۸۲۶/۱۹۴۶		۷۱۴/۹۶۹۵		۷۵۶/۶۶۸۳۵		۸۲۶/۱۹۴۶		۷۶۲/۳۰۱۹
	۲۰۲۲		۸۵۵/۰۵۸۲		۷۳۵/۵۲۵۷۶		۸۰۴/۸۰۹۹۴		۸۵۵/۰۵۸۲		۸۰۵/۰۳۹۷
	۲۰۲۳		۸۷۳/۱۲۰۳		۷۵۷/۳۶۰۸۴		۸۲۵/۷۵۵۶		۸۷۳/۱۲۰۳		۸۵۱/۷۹۰۵
گروه ۳	۲۰۱۹	۰/۰۰۶۵	۷۱۷/۷۰۴۷	۰/۰۰۵۶	۷۲۵/۲۱۷۳	۰/۰۰۲۶	۶۷۸/۲۶۱۴	۰/۱۰۸۱	۷۱۷/۷۰۴۷	۰/۰۲۷۶	۸۶۱/۶۹۰۵
	۲۰۲۰		۷۴۹/۰۲۹۶۶		۷۵۶/۶۸۷۹		۷۰۳/۴۳۹۸		۷۴۹/۰۲۹۶۶		۸۹۲/۹۶۲
	۲۰۲۱		۷۷۳/۵۳۲۱		۷۸۴/۲۰۳۷۴		۷۳۳/۴۴۵۹		۷۷۳/۵۳۲۱		۹۳۲/۶۵۶۸۶
	۲۰۲۲		۸۰۲/۰۴۲		۸۱۱/۴۳۴۳		۷۵۸/۶۲۹۶۴		۸۰۲/۰۴۲		۹۳۲/۱۹۶۷
	۲۰۲۳		۸۲۸/۰۵۰۲		۸۳۱/۳۳۶۵۵		۷۸۱/۵۱۶۶۶		۸۲۸/۰۵۰۲		۹۰۴/۶۲۹۸
گروه ۴	۲۰۱۹	۰/۰۰۷۸	۵۶۹/۳۶۷۶	۰/۰۰۹۳	۵۶۵/۵۷۴۳	۰/۰۳۴۲	۵۱۵/۵۷۴۷۷	۰/۱۶۵۸	۵۶۹/۳۶۷۶	۰/۰۰۱۴	۶۲۸/۲۲۷۸
	۲۰۲۰		۵۸۹/۹۴۹۴		۵۸۸/۸۷۸۹		۵۴۰/۳۵۲۰۵		۵۸۹/۹۴۹۴		۶۴۴/۵۰۷۵۷
	۲۰۲۱		۶۱۴/۶۸۸۵		۶۱۲/۳۶۸۰۴		۵۶۲/۸۰۵۵		۶۱۴/۶۸۸۵		۶۶۴/۰۱۸۶
	۲۰۲۲		۶۳۵/۳۲۸۲		۶۳۶/۹۶۶		۵۸۷/۲۹۰۴		۶۳۵/۳۲۸۲		۶۹۰/۱۰۳
	۲۰۲۳		۶۵۵/۸۴۷		۶۶۰/۶۷۵۵۴		۶۰۷/۶۰۸۹۵		۶۵۵/۸۴۷		۷۱۲/۵۴۴۴۳
گروه ۵	۲۰۱۹	۰/۰۰۱۷	۶۲۶/۹۱۲۷	۰/۰۰۲۲	۶۲۶/۷۱۴۳	۰/۰۳۰۵	۵۲۲/۳۵۲۴	۰/۰۹۳۳	۵۹۶/۲۴۴۹	۰/۰۰۲۱	۶۲۴/۴۹۴۲۶
	۲۰۲۰		۶۴۲/۴۷۲۵۳		۶۵۳/۹۶۸۲۶		۵۴۸/۳۸۰۰۷		۶۲۲/۷۳۱۷		۶۴۵/۸۹۵۴
	۲۰۲۱		۶۷۷/۹۵۲۶۷		۶۹۷/۸۲۳۵		۵۷۳/۵۲۲۹		۶۴۴/۹۶۹۸		۶۶۹/۶۷۰۶۵
	۲۰۲۲		۷۰۰/۴۸۳۳۴		۷۰۷/۹۱		۵۹۴/۸۷۷۵۶		۶۷۱/۴۱۳۵		۶۹۲/۶۴۸۵۶
	۲۰۲۳		۷۰۷/۱۷۹۴۴		۷۲۳/۵۴۳۷		۶۱۷/۷۹۴۳		۶۹۶/۲۴۸۰۵		۷۰۸/۹۲۷۶
گروه کل	۲۰۱۹	۰/۰۰۷۶	۷۱۶/۴۹۸۸	۰/۰۱۶۷	۷۳۴/۱۶۱۹	۰/۰۰۸۱	۹۶۹/۳۱۳۵۴	۰/۱۳۸۲	۶۵۴/۵۶۷۴۴	۰/۰۰۶۶	۷۹۷/۳۲۱۹
	۲۰۲۰		۷۴۴/۱۷۳		۷۶۱/۰۳۶۷۴		۷۱۷/۴۲۰۸		۶۷۸/۰۸۶۵		۸۳۴/۲۷۵۹
	۲۰۲۱		۷۶۲/۸۷۱۰۳		۷۹۴/۷۹۴۳		۷۵۱/۸۴۳۵۷		۶۹۹/۰۹۰۶		۸۳۷/۲۷۲۶۴
	۲۰۲۲		۷۹۶/۸۴۶۷		۸۲۹/۰۹۷۹		۷۷۶/۶۴۷۵		۷۱۸/۰۴۸۷		۸۵۶/۸۸۹۸
	۲۰۲۳		۸۱۴/۴۸۸۹		۸۵۰/۹۲۶۳		۸۰۷/۱۲۷۳		۷۴۴/۱۹۲۸		۸۹۷/۳۳۸۸۷




شکل ۱۷- خطای گروه ۵ به تفکیک روش ها

پیش‌بینی کل در شکل ۱۸ قابل مشاهده است.




شکل ۱۸- نمودار پیش‌بینی کل به تفکیک روش‌ها

سایر نمودارهای واقعی-پیش‌بینی به تفکیک گروه‌ها نیز در شکل‌های ۱۹ تا ۲۲ آورده شده است.




شکل ۱۹- نمودار پیش‌بینی گروه ۱ به تفکیک روش‌ها




شکل ۲۰- نمودار پیش‌بینی گروه ۲ به تفکیک روش‌ها


هم‌چنین میزان خطا مربوطه نیز به تفکیک گروه و روش حل در اشکال ۱۳ تا ۱۷ قابل مشاهده است.




شکل ۱۳- خطای گروه ۱ به تفکیک روش‌ها



شکل ۱۴- خطای گروه ۲ به تفکیک روش‌ها



شکل ۱۵- خطای گروه ۳ به تفکیک روش‌ها



شکل ۱۶- خطای گروه ۴ به تفکیک روش‌ها

جدول ۴- تفاوت مقدار خطای بین مقدار پیش‌بینی و مقدار واقعی


در سال ۲۰۲۰ بر حسب درصد					
	RNN	GRU	LSTM	CNN	MLP
گروه ۱	۳۶/۰۰	۲۴/۴۲	۳۷/۱۵	۳۶/۰۰	۲۶/۸۳
گروه ۲	۴/۵۱	۸/۹۰	۰/۵۶	۴/۵۱	۴/۳۱
گروه ۳	۰/۵۴	۱/۵۴	۵/۹۱	۰/۵۴	۱۶/۵۷
گروه ۴	۲۶/۲۸	۲۶/۵۱	۳۷/۸۷	۲۶/۲۸	۱۵/۵۹
گروه ۵	۱۵/۹۶	۱۳/۹۲	۳۵/۸۵	۱۹/۶۳	۱۵/۳۴
گروه کل	۰/۱۰	۲/۱۱	۳/۸۴	۹/۸۷	۱۰/۷۰

بحث


با نگاهی به خروجی به‌دست‌آمده در مدل‌ها و مقایسه مقدار خطا در سال‌های مختلف و همچنین در نظر گرفتن موضوع محدودیت دسترسی به داده‌ها مشخص می‌شود که مدل CNN یک بعدی که برای پیش‌بینی سری زمانی از آن استفاده شد بیشترین خطاهای جدول ۳ و جدول ۴ را دارد و از نظر گروهی نیز، گروه‌های کل داده‌ها، ۲ و ۳ کمترین مقدار خطا را به خود اختصاص داده‌اند. اما زمانی که مقدار پیش‌بینی سال ۲۰۱۹ و ۲۰۲۰ با مقدار واقعی این سال‌ها مقایسه شود مشخص می‌شود که پیش‌بینی گروه‌های کل، ۲ و ۳ به واقعیت نزدیک‌تر است. (البته باید این مهم را همیشه مد نظر قرار داد که ماشین نمی‌تواند تمامی عوامل محیطی را در پیش‌بینی خود لحاظ کند و در بهترین حالت می‌تواند نسبت به داده‌های ورودی، یک یادگیری کم نقص داشته و سرانجام پیش‌بینی‌ای با کمترین خطا ارائه دهد).

در دید کلی می‌توان گفت که گروه‌های ۱، ۴ و ۵ (تولید ناخالص داخلی و اجزاء آن، متغیرهای تولید به تفکیک بخش‌های مختلف و متغیرهای تولید و مصرف انرژی) کمترین دقت و بیشترین خطای پیش‌بینی را دارند. شاید بتوان دلیل آن را متمرکز بودن داده‌های این گروه‌ها به یک شاخه خاص از اقتصاد بیان کرد. به‌رحال نتایج نشان می‌دهد که اگر بخواهیم از روش‌های یادگیری عمیق برای پیش‌بینی انتشار CO₂ استفاده کنیم، بهتر است از ترکیب متغیرها در شاخه‌های مختلف استفاده شود.


مطابق با نتایج به دست آمده در قسمت قبل، مشخص می‌شود که به‌جز در مواردی مقدار انتشار CO₂ به صورت پیوسته افزایشی خواهد بود که این نشان از مسیر صعودی انتشار CO₂ در ایران برای سالیان آینده خواهد داشت و می‌توان انتظار



شکل ۲۱- نمودار پیش‌بینی گروه ۳ به تفکیک روش‌ها



شکل ۲۲- نمودار پیش‌بینی گروه ۴ به تفکیک روش‌ها



شکل ۲۳- نمودار پیش‌بینی گروه ۵ به تفکیک روش‌ها

در ادامه به مقایسه مقدار پیش‌بینی شده با مقدار واقعی برای هر کدام از مدل‌ها و گروه‌ها پرداخته خواهد شد: میزان انتشار CO₂ واقعی برای کشور ایران بر طبق سایت داده‌های جهان ما در سال ۲۰۱۹ برابر با ۷۳۳ میلیون تن و در سال ۲۰۲۰ برابر با ۷۴۵ میلیون تن می‌باشد.

جدول ۳- تفاوت مقدار خطای بین مقدار پیش‌بینی و مقدار واقعی

در سال ۲۰۱۹ بر حسب درصد					
	RNN	GRU	LSTM	CNN	MLP
گروه ۱	۳۹/۰۳	۲۷/۴۸	۴۰/۸۷	۳۹/۰۳	۲۹/۴۱
گروه ۲	۲/۵۶	۱۱/۷۹	۳/۵۲	۲/۵۶	۲/۳۱
گروه ۳	۲/۱۳	۱/۰۷	۸/۰۷	۲/۱۳	۱۴/۹۳
گروه ۴	۲۸/۷۴	۲۹/۶۰	۴۲/۱۷	۲۸/۷۴	۱۶/۶۸
گروه ۵	۱۶/۹۲	۱۶/۹۶	۴۰/۳۳	۲۲/۹۴	۱۷/۳۷
گروه کل	۲/۳۰	۰/۱۶	۵/۲۷	۱۱/۹۸	۸/۰۷

و یادگیری ماشین (یادگیری با ناظر) شامل LSTM، MLP، GRU، CNN و RNN استفاده شد. که بیشترین خطاهای این مدل‌ها مربوط به روش CNN بود. نتایج حاصل از این تحقیق به ما نشان داد که روند انتشار CO₂ ایران در سال‌های آینده صعودی می‌باشد که متغیرهای بخش تولید، عوامل تولید و جمعیت و مصرف انرژی تأثیر زیادی بر انتشار CO₂ دارند. همچنین با استفاده از متغیرهای عوامل تولید و جمعیت و شاخص‌های قیمتی نسبت به متغیرهای سایر بخش‌ها، می‌توان به پیش‌بینی دقیق‌تری از روند انتشار CO₂ در ایران دست یافت؛ اما شاید زمانی بتوان به بهترین پیش‌بینی‌ها دست پیدا کرد که تمامی متغیرهای موجود در مجموعه داده‌های این تحقیق را در پیش‌بینی دخیل کرد. مطابق با نتایج به دست آمده مقدار انتشار CO₂ ایران در سال ۲۰۲۳ به میزان ۸۵۰ تا ۹۰۰ میلیون تن خواهد رسید که این روند رو به رشد جای نگرانی دارد و دولت ایران می‌بایست با وضع قوانین سخت گیرانه در انتشار CO₂ بخش‌های مختلف، استفاده از فناوری‌های بروز و دوست دار محیط‌زیست، تنظیم خانواده و فرهنگ‌سازی عمومی در سطح جامعه در جهت راستای کنترل و کاهش انتشار CO₂ اقدام کند.

منابع

1. **Baloch, M. A., Khan, S. U. D., Ulucak, Z. Ş. & Ahmad, A., 2020.** Analyzing the relationship between poverty, income inequality, and CO₂ emission in Sub-Saharan African countries. *Science of the Total Environment*, 740, 139867.
 2. **Bamisile, O., Obiora, S., Huang, Q., Yimen, N., Idriss, I. A., Cai, D. & Dagbasi, M. 2021.** Impact of economic development on CO₂ emission in Africa; the role of BEVs and hydrogen production in renewable energy integration. *International Journal of Hydrogen Energy*, 46, 2755-2773.
 3. **Cai, Y., Sam, C.Y. & Chang, T. 2018.** Nexus between clean energy consumption, economic growth and CO₂ emissions. *Journal of cleaner production*, 182, 1001-1011.
 4. **Cheikh, N.B., Zaid Y.B. & Chevallier, J. 2021.** On the nonlinear relationship between energy use and CO₂ emissions within an EKC framework: Evidence from smooth transition regression in the MENA
- داشت تا پایان سال ۲۰۲۳ میزان انتشار CO₂ در ایران به محدوده ۸۵۰ الی ۹۰۰ میلیون تن برسد. این نتیجه می‌تواند یک فاجعه محیط‌زیستی و خطری عظیم برای سلامتی انسان‌ها، طبیعت و سایر جانداران باشد.
- نتایج حاصل از این تحقیق با روش‌های پیش‌بینی (Hosseini et al., 2019)، سناریوی تجارت معمولی این پژوهش شباهت دارد و روند انتشار CO₂ در ایران را در سالیان آینده به صورت صعودی و با شیب نسبتاً زیاد پیش‌بینی می‌کند.
- لذا در مواجهه با این وضعیت نه چندان خوش‌بینانه، پیشنهاد می‌شود که دولت ایران یک برنامه مفید، کاربردی، کارآمد و بلندمدت برای کنترل انتشار CO₂ در پیش گیرد؛ و از آنجایی که بیشترین مقدار انتشار CO₂ در ایران با توجه به جدول ۱ مربوط به بخش انرژی است و با استناد به تحقیقات کاربردی انجام شده در گذشته نزدیک، پیشنهاد می‌شود تا دولت ایران در بخش انرژی شامل مصرف کارخانه جات، پالایش و پتروشیمی نفت، گاز، فولاد و غیره و سایر زیرمجموعه‌های انرژی، علاوه بر وضع قوانین سخت گیرانه در راستای کنترل میزان انتشار CO₂ این بخش، از فناوری‌های پیشرفته‌تر، تجهیزات بروزتر و دوست‌دار محیط‌زیست و انرژی‌های تجدید پذیر نیز استفاده کند تا مقدار انتشار CO₂ بخش انرژی، به عنوان یکی از اصلی‌ترین منابع تولید گاز دی‌اکسید کربن در ایران را کنترل کرده و کاهش دهد و همچنین با استناد به جدول ۲ و دقت گروه ۲ و ۳ در پیش‌بینی مشخص است که جمعیت و عوامل تولید نقش مهمی در انتشار CO₂ ایران بازی می‌کنند؛ که با تحقیقات (Chong et al., 2019) و (de Souza Mendonca et al., 2020) مطابقت دارد لذا دولت با اجرای سیاست‌های تنظیم خانواده و تولد و همچنین فرهنگ‌سازی عمومی از طریق رسانه می‌تواند اثر جمعیت بر انتشار CO₂ را کنترل کرده و کاهش دهد.
- در این پژوهش جهت پیش‌بینی مقدار انتشار CO₂ کل ایران در ۵ سال آینده با بررسی تحقیقات انجام شده گذشته در این حوزه یک مجموعه دیتای مناسب از شاخص‌ها و متغیرهای مهم و تأثیرگذار بر انتشار CO₂ در بازه زمانی ۱۹۷۰-۲۰۱۸ تشکیل و پیش‌بینی را انجام شد که این پژوهش کاملاً کاربردی می‌باشد و نتایج آن می‌تواند نقشه راهی برای دولت ایران بوده و در تعیین سیاست‌گذاری مناسب جهت کنترل و کاهش انتشار CO₂ یاری‌رسان باشد. در این تحقیق جهت انجام پیش‌بینی از ۵ مدل یادگیری عمیق در حوزه هوش مصنوعی

- dynamical recurrent neural networks. IEEE Press.
14. **Hoffmann, C. 2020.** A power development planning for vietnam under the CO₂ emission reduction targets. *Energy Reports*, 6, 19-24.
15. **Hong, C., Zhang, Q., Zhang, Y., Davis, S.J., Tong, D., Zheng, Y., Liu, Z., Guan, D., He, K. & Schellnhuber, H.J. 2019.** Impacts of climate change on future air quality and human health in China. *Proceedings of the National Academy of Sciences*, 116, 17193-17200.
16. **Hosseini, S.M., Saifoddin, A., Shirmohammadi, R. & Aslani, A. 2019.** Forecasting of CO₂ emissions in Iran based on time series and regression analysis. *Energy Reports*, 5, 619.۶۳۱-
17. **Hu, M., Li, R., You, W., Liu, Y. & Lee, C.C. 2020.** Spatiotemporal evolution of decoupling and driving forces of CO₂ emissions on economic growth along the Belt and Road. *Journal of Cleaner Production*, 277, 123272.
18. **Hubel, D. & Wiesel. T. 2020.** 8. Receptive fields of single neurones in the cat's striate cortex. In *Brain Physiology and Psychology*, 129-150. University of California Press.
19. **Ivakhnenko, A.G.E., Ivakhnenko, A.G., Lapa, V.G.E. & Lapa., V.G.E. 1967.** *Cybernetics and forecasting techniques*. American Elsevier Publishing Company.
20. **Kang, M., Zhao, W., Jia, L. & Liu, Y. 2020.** Balancing carbon emission reductions and social economic development for sustainable development: Experience from 24 countries. *Chinese Geographical Science*, 30, 379-396.
21. **Le, T.H., Le, H.C. & Taghizadeh-Hesary, F. 2020.** Does financial inclusion impact CO₂ emissions? Evidence from Asia. *Finance Research Letters*, 34, 101451.
22. **Li, G., Zakari, A. & Tawiah, V. 2020.** Energy resource melioration and CO₂ emissions in China and Nigeria: Efficiency and trade perspectives. *Resources Policy*, 68, 101769.
23. **Liu, Q., Wang, S., Zhang, W., Li, J. & Kong, Y. 2019.** Examining the effects of income inequality on CO₂ emissions: region. *Research in International Business and Finance*, 55, 101331.
5. **Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. & Bengio, Y. 2014.** Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv: 1406.1078*.
6. **Chong, C.H., Tan, W.X., Ting, Z.J. Liu, P., Ma, L., Li, Z. & Ni, W. 2019.** The driving factors of energy-related CO₂ emission growth in Malaysia: The LMDI decomposition method based on energy allocation analysis. *Renewable and Sustainable Energy Reviews*, 115, 109356.
7. **Dai, S., Niu, D. & Han, Y. 2018.** Forecasting of energy-related CO₂ emissions in China based on GM (1, 1) and least squares support vector machine optimized by modified shuffled frog leaping algorithm for sustainability. *Sustainability*, 10, 958.
8. **de Souza Mendonca, A.K., Barni, G.D. A.C., Moro, M.F., Bornia, A.C., Kupek, E. & Fernandes, L. 2020.** Hierarchical modeling of the 50 largest economies to verify the impact of GDP, population and renewable energy generation in CO₂ emissions. *Sustainable Production and Consumption*, 22, 58-67.
9. **Dechter, R. 1986.** Learning while searching in constraint-satisfaction problems.
10. **Gifford, R. 1992.** Interaction of carbon dioxide with growth-limiting environmental factors in vegetation productivity: implications for the global carbon cycle. In *Advances in Bioclimatology 1*, 24-58. Springer.
11. **Hdom, H.A. & Fuinhas, J.A. 2020.** Energy production and trade openness: Assessing economic growth, CO₂ emissions and the applicability of the cointegration analysis. *Energy Strategy Reviews*, 30, 100488.
12. **Hochreiter, S. Schmidhuber, J. 1997.** "Long Short-Term Memory". *Neural Computation*, 9.
13. **Hochreiter, S., Bengio, Y., Frasconi, P. & Schmidhuber, J. 2001.** Gradient flow in recurrent nets: the difficulty of learning long-term dependenc ies. A field guide to

34. **Shahbaz, M., Solarin, S.A., Mahmood, H. & Arouri, M. 2013.** Does financial development reduce CO₂ emissions in Malaysian economy? A time series analysis. *Economic Modelling*, 35, 145-152.
35. **Taylor, G.W. & Hinton, G.E. 2009.** Factored conditional restricted Boltzmann machines for modeling motion style. In *Proceedings of the 26th annual international conference on machine learning*, 1025-1032.
36. **Wang, R., Mirza, N., Vasbieva, D.G., Abbas, Q. & Xiong, D. 2020.** The nexus of carbon emissions, financial development, renewable energy consumption, and technological innovation: what should be the priorities in light of COP 21 Agreements? *Journal of Environmental Management*, 271, 111027.
37. **Wasserman, P.D. & Schwartz, T. 1988.** Neural networks. II. What are they and why is everybody so interested in them now? *IEEE expert*, 3, 10-15.
38. **Wilson, A.M., Salloway, J.C., Wake, C.P. & Kelly, T. 2004.** Air pollution and the demand for hospital services: a review. *Environment International*, 30, 1109-1118.
39. **Xia, F., Zhang, X., Cai, T., Wu, S. & Zhao, D. 2020.** Identification of key industries of industrial sector with energy-related CO₂ emissions and analysis of their potential for energy conservation and emission reduction in Xinjiang, China. *Science of the total environment*, 708, 134587.
40. **Xie, X., Weng, Y. & Cai, W. 2018.** Co-benefits of CO₂ mitigation for NOX emission reduction: A research based on the DICE model. *Sustainability*, 1.۱۱۰۹, .
41. **Zubair, A.O., Samad A.R.A. & Dankumo, A.M. 2020.** Does gross domestic income, trade integration, FDI inflows, GDP, and capital reduces CO₂ emissions? An empirical evidence from Nigeria. *Current Research in Environmental Sustainability*, 2, 1000.۰۹
- Evidence from non-spatial and spatial perspectives. *Applied Energy*, 236, 163-17.۱
24. **Mikayilov, J.I., Galeotti, M. & Hasanov, F.J. 2018.** The impact of economic growth on CO₂ emissions in Azerbaijan. *Journal of cleaner production*, 197, 1558-1572.
25. **Mohammed, A., Li, Z., Arowolo, A.O., Su, H., Deng, X., Najmuddin, O. & Zhang, Y. 2019.** Driving factors of CO₂ emissions and nexus with economic growth, development and human health in the Top Ten emitting countries. *Resources, Conservation and Recycling*, 148, 157-169.
26. **Muhammad, B. 2019.** Energy consumption, CO₂ emissions and economic growth in developed, emerging and Middle East and North Africa countries. *Energy*, 179, 232-245.
27. **Pata, U.K. 2018.** Renewable energy consumption, urbanization, financial development, income and CO₂ emissions in Turkey: testing EKC hypothesis with structural breaks. *Journal of Cleaner Production*, 187, 770-779.
28. **Pluhar, Z.F., Piko, B.F., Kovacs, S. & Uzzoli, A. 2009.** "Air pollution is bad for my health": Hungarian children's knowledge of the role of environment in health and disease. *Health & place*, 15, 239-246.
29. **Romer, P.M. 1990.** Endogenous technological change. *Journal of Political Economy*.
30. **Rumethart, D. 1986.** Learning representations by back-propagating errors. *Nature*, 323, 533-536.
31. **Russell, S. & Norvig, P. 2002.** Artificial intelligence: a modern approach.
32. **Salahuddin, M., Alam, K., Ozturk, I. & Sohag, K. 2018.** The effects of electricity consumption, economic growth, financial development and foreign direct investment on CO₂ emissions in Kuwait. *Renewable and Sustainable Energy Reviews*, 81, 2002-2010.
33. **Samuel, A.L. 1959.** Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3, 210-229.

Forecasting CO₂ Emissions in Iran Using Important Economic Indicators and Using Deep Learning Models

Mehdi Nejati¹, Zein Al-Abedin Sadeghi¹, Mohammad Ali Arabpour^{1*}

^{1*} Department of Economics, Faculty of Management and Economics, Shahid Bahonar University, Kerman, Iran.

Abstract

The increase in greenhouse gas emissions in recent years has caused great concern to many communities and environmentalists. One of these important greenhouse gases is carbon dioxide (CO₂). In this study, using important economic variables and indicators and time series data series of 1970-2018, which were divided into 5 separate groups with a set of data, and predicted the amount of CO₂ emissions in Iran. For this subject, deep learning models of machine learning subset have been used. It was a multivariate issue and a set of objectives that predicted the amount of CO₂ emissions for the next 5 years (5 years after 2018) and finally compared the forecasts for 2019 and 2020 with the actual CO₂ of these years to verify the forecasts. The results obtained for all 6 experimental groups show that the amount of CO₂ emissions in Iran will follow an upward trend in the coming years and by 2023 the amount of CO₂ emissions will reach 850 to 900 million tons, which could be an environmental and dangerous disaster. Be for humans. Therefore, it is suggested that the government use a long-term plan with emphasis on important groups, culture building in the community and the establishment of more specific laws to control the amount of CO₂ emissions.

Keywords: CO₂ Emission Forecasting, Deep Learning, Artificial Neural Networks, Air Pollution