

شبکه‌های عصبی گرافی: مروری بر کاربردها و رویکردهای نوین در پردازش داده‌های مکانی-زمانی

محمد تقی عباسی^۱، علی اصغر آل شیخ^{۲*}

^۱ دانشجوی کارشناسی ارشد سیستم‌های اطلاعات مکانی - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه

نصیرالدین طوسی

m.abbasi1@email.kntu.ac.ir

^۲ استاد دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی

(عضو قطب علمی مهندسی فناوری اطلاعات مکانی)

alesheikh@kntu.ac.ir

(دریافت: فروردین ۱۴۰۴، تصویب: خرداد ۱۴۰۴)

چکیده

ساختار هندسی داده‌ها نقش حیاتی در انتخاب روش‌های تحلیلی برای پردازش و مدل‌سازی آن‌ها ایفا می‌کند. در داده‌های اقلیدسی مانند سیگنال‌های یک‌بعدی و تصاویر دوبعدی، مفاهیمی چون فاصله، ترتیب و هم‌جواری به‌طور دقیق تعریف می‌شوند. در مقابل، در بسیاری از پدیده‌های واقعی، داده‌ها معمولاً بر بسترهای غیراقلیدسی مانند گراف‌ها مدل‌سازی می‌شوند، جایی که مفاهیمی مانند فاصله و جهت تعریف دقیقی ندارند و روابط توپولوژیکی و اتصالات گره‌ها مبنای تحلیل قرار می‌گیرد. شبکه‌های عصبی همگشتی (CNNs) به‌طور خاص برای داده‌های اقلیدسی با ساختار منظم و شبکه‌ای طراحی شده‌اند و برای پردازش داده‌های با ساختار نامنظم مانند گراف‌ها که در آن‌ها مفاهیمی مانند فاصله و جهت تعریف دقیقی ندارند، محدودیت دارند. به همین دلیل، شبکه‌های عصبی گرافی (GNNs) به‌عنوان ابزاری مؤثر برای مدل‌سازی و تحلیل داده‌های غیراقلیدسی معرفی شده‌اند. در میان انواع مختلف شبکه‌های عصبی گرافی، تمرکز این پژوهش به‌طور خاص بر شبکه‌های همگشت گرافی (GCNs) است. این مدل‌ها با تعمیم عملیات هم‌گشت به گراف‌ها، امکان انتقال اطلاعات از همسایگان هر گره و یادگیری ویژگی‌های مکانی را فراهم می‌سازند. داده‌های مکانی-زمانی غیراقلیدسی معمولاً به‌صورت گراف مدل‌سازی می‌شوند، به‌طوری که تغییرات مکانی و زمانی به‌صورت نمایی (Snapshots) از روابط پویا میان گره‌ها تفسیر می‌گردند. شبکه‌های همگشت گرافی با استخراج ویژگی‌های متغیر مبتنی بر مکان از بردارهای ویژگی گره‌ها و یال‌ها و ترکیب آن‌ها با مدل‌های یادگیری توالی، به‌طور مؤثر ویژگی‌های زمانی را نیز استخراج می‌کنند. در این پژوهش، گذار مفهومی و ریاضی از شبکه‌های همگشت کلاسیک (CNNs) به شبکه‌های همگشت گرافی (GCNs) بررسی شده و به‌طور ویژه، قابلیت این مدل‌های پیشرفته در پردازش داده‌های مکانی-زمانی در سیستم‌های اطلاعات مکانی (GIS) مورد مطالعه قرار گرفته است. افزون بر این، یک مخزن عمومی در GitHub ایجاد شده است که شامل مجموعه داده‌های رایگان و قابل دسترس برای پیاده‌سازی این کاربردها بوده و به‌صورت مستمر به‌روزرسانی خواهد شد.

واژگان کلیدی: داده‌های غیراقلیدسی، شبکه‌های عصبی گرافی (GNNs)، داده‌های مکانی-زمانی، سیستم‌های اطلاعات مکانی (GIS)

* نویسنده رابط

۱- مقدمه

فضا، از دیدگاه لایبنیتز^۱، چیزی جز شبکه‌ای از روابط میان موجودیت‌های متمایز نیست [۱]. در این رویکرد، پدیده‌های مکانی-زمانی نه به‌عنوان موجودیت‌هایی مستقل در فضایی مطلق، بلکه به‌عنوان برآیند تعاملات پویای بین آن‌ها تعریف می‌شوند [۲]. چنین برداشتی، به‌ویژه در علوم اطلاعات مکانی، زمینه‌ساز توسعه مدل‌هایی شده است که قادرند این پویایی را تحلیل و پیش‌بینی کنند.

بر همین اساس، رویکرد لایبنیتزی به مدل‌سازی گرافی منتهی می‌شود، جایی که گره‌ها نمایانگر موجودیت‌ها و یال‌ها^۲ بازتاب‌دهنده روابط مکانی میان آن‌ها هستند [۳]. در این چارچوب، تکامل پدیده‌ها از طریق تغییرات در ویژگی‌های گره‌ها، وزن یال‌ها و تحول ساختار کلی گراف مدل‌سازی می‌شود، و بُعد زمانی، به شکلی شفاف و منعطف، در دل این ساختار جای می‌گیرد. این مدل، گرچه در نمایش وابستگی‌های مکانی-زمانی کارآمد است، اما تحلیل این روابط و استخراج الگوهای معنادار از آن‌ها مستلزم به‌کارگیری روش‌های محاسباتی پیشرفته است [۴]. ظهور یادگیری عمیق، هم‌زمان با پیشرفت فناوری و افزایش قدرت پردازش گرافیکی (GPU^۳)، این امکان را فراهم آورده است که مدل‌های پیچیده‌تری برای تحلیل داده‌های غیرخطی و وابسته توسعه یابند. شبکه‌های عصبی عمیق، با قابلیت استخراج ویژگی‌های چندلایه و تطبیق‌پذیری بالا، بستری بهینه برای درک ساختارهای پیچیده داده‌های مکانی-زمانی فراهم کرده‌اند. این همگرایی میان فلسفه، مدل‌سازی گرافی و یادگیری عمیق، دریچه‌ای نو به سوی تحلیل و پیش‌بینی پدیده‌های پویا گشوده است.

در پردازش داده‌های سری زمانی، مدل‌هایی همچون شبکه‌های عصبی بازگشتی (RNN^۴) و شبکه‌های حافظه‌ی بلند کوتاه‌مدت (LSTM^۵) به‌عنوان ساختارهای محاسباتی مؤثر در یادگیری وابستگی‌های دنباله‌ای و استخراج الگوهای پنهان از داده‌ها مطرح شده‌اند. این مدل‌ها، با توانایی درک توالی اطلاعات، نه تنها روندهای گذشته را می‌آموزند، بلکه امکان پیش‌بینی مقادیر آینده را نیز فراهم

می‌کنند [۵]. با این حال، تمرکز اصلی این روش‌ها بر وابستگی‌های زمانی است؛ آن‌ها داده‌ها را به‌مثابه رشته‌ای از نقاط مجزا در زمان می‌بینند و به روابط مکانی میان آن‌ها توجهی ندارند. این در حالی است که در تحلیل پدیده‌های مکانی-زمانی، فضا و زمان درهم‌تنیده‌اند و تغییرات یک نقطه در فضا می‌تواند پیامدهایی فراتر از مرزهای آن داشته باشد [۶]. بی‌توجهی به این بُعد مکانی، محدودیتی بنیادین در مدل‌های کلاسیک سری‌زمانی محسوب می‌شود که می‌تواند دقت پیش‌بینی را کاهش داده و تحلیل روابط پیچیده میان داده‌ها را دشوار سازد [۷].

برای رفع این محدودیت، شبکه‌های عصبی همگشتی^۶ توسعه یافته‌اند که به دلیل استفاده از اتصالات محلی و وزن‌های مشترک، قابلیت استخراج ویژگی‌های مکانی را دارند [۸]. این مدل‌ها برای پردازش داده‌های تعریف‌شده بر دامنه‌های منظم اقلیدسی مانند صدا و تصویر مناسب هستند [۹]. با این حال، شبکه‌های عصبی همگشتی هنگام پردازش داده‌های گرافی که بر روی دامنه‌های نامنظم غیراقلیدسی تعریف شده‌اند، به دلیل محدودیت‌هایی همچون تغییرپذیری تعداد همسایگان، نبود ترتیب مشخص در گره‌ها و عدم معناداری افزودن گره‌ها و یال‌های مجازی^۷ برای یکسان‌سازی اندازه و شکل، عملکرد ضعیفی از خود نشان داده‌اند. این محدودیت‌ها باعث شده که شبکه‌های عصبی همگشت گرافی^۸ به عنوان یک موضوع پژوهشی مورد توجه قرارگیرند [۱۰]. در این مطالعه، مفاهیم و روابط ریاضی مرتبط با گذار از شبکه‌های عصبی همگشتی به شبکه‌های عصبی همگشت گرافی ارائه شده و تلاش شده است کاربرد آن‌ها در علم اطلاعات مکانی برای خواننده تبیین شود. ساختار مقاله به شرح زیر است: در بخش دوم، مبانی نظری مربوط به شبکه‌های عصبی همگشتی برای پردازش داده‌های با ساختار منظم بررسی می‌شود و سپس متناظر این مفاهیم در داده‌های گرافی ارائه شده‌است. در بخش سوم، شبکه‌های عصبی همگشت گرافی توضیح داده می‌شود. در بخش چهارم، کاربردهای این شبکه‌ها در علم سیستم‌های اطلاعات مکانی (GIS) مطرح شده و در نهایت، نتیجه‌گیری مقاله در پایان آورده خواهد شد.

۵ Long Short-Term Memory (LSTM)

۶ Convolutional Neural Network (CNN)

۷ Padding

۸ Graph Convolutional Neural Network (GCN)

۱ Leibniz

۲ Edges

۳ Graphics Processing Unit (GPU)

۴ Recurrent Neural Network (RNN)

۲- مبانی نظری تحقیق

۲-۱- تعاریف گراف

منظور از یک گراف G ، دوتایی $G = (V, E)$ است که V مجموعه‌ای ناتهی متناهی و E مجموعه‌ای متناهی از زیرمجموعه‌های دو عضوی V است. مجموعه‌های V و E را به ترتیب مجموعه‌ی گره‌ها و مجموعه یال‌های G می‌نامند. تعداد گره‌ها و تعداد یال‌های گراف G را به ترتیب مرتبه و اندازه‌ی G نامیده و با n و m نمایش می‌دهند [۱۱]. تعداد یال‌های گذرا از گره v را درجه گره v گویند و با $\deg(v)$ نمایش می‌دهند. ماتریس درجه یک گراف، ماتریسی قطری است که اطلاعات مربوط به درجه‌ی هر گره در گراف را در خود جای می‌دهد. به منظور نمایش گراف می‌توان از روش‌های مختلفی استفاده کرد که یکی از متداول‌ترین آن‌ها ماتریس مجاورت است. ماتریس مجاورت یک ماتریس مربعی $n \times n$ است که درایه‌های آن $[A]_{i,j}$ شامل تمام دوتایی گره‌ها $(i,j) \in E$ می‌باشد. اگر گره i با گره j در ارتباط باشد درایه‌ی مربوطه یک و در غیر این صورت صفر خواهد بود. در گراف‌های بدون جهت، ماتریس مجاورت متقارن است. علاوه بر این، یکی از ماتریس‌های پرکاربرد در پردازش گراف‌ها، ماتریس لاپلاسیان است. منظور از ماتریس لاپلاسیان گراف ماتریس $L = D - A$ است که در آن A و D به ترتیب ماتریس مجاورت و ماتریس درجه هستند. به عبارت دیگر، درایه i, j ام ماتریس لاپلاسیان به شکل زیر خواهد بود:

$$L_{i,j} = \begin{cases} -1 & i, j \in E \\ d_i & i = j \\ 0 & otherwise \end{cases} \quad (1)$$


که d_i درجه رأس i ام است. واضح است که ماتریس لاپلاسیان برای یک گراف بدون جهت یک ماتریس متقارن است.

۲-۲- تعاریف پالایه‌همگشت در فضای اقلیدسی

۲-۲-۱- تعریف پالایه^۱

پالایه‌ها، سیستم‌هایی هستند که داده ورودی را دریافت کرده و پس از پردازش، داده خروجی دیگری تولید می‌کنند

[۱۲]. پالایه‌ها در فرآیند استخراج ویژگی از داده‌ها، اطلاعات مرتبط و حیاتی برای انجام یک وظیفه خاص را شناسایی و حفظ کرده و در عین حال داده‌های غیرضروری و زائد را حذف می‌کنند [۱۳]. شکل ۱، نمودار بلوکی پالایه را نشان می‌دهد.



شکل ۱- نمودار بلوکی پالایه [۱۴]

پالایش داده‌ها در یادگیری ماشین و یادگیری عمیق، نقش مهمی در برجسته‌سازی الگوهای معنادار و کاهش پیچیدگی داده‌ها ایفا می‌کند. برای مثال، تحلیل مؤلفه‌های اصلی^۲ شبیه به یک پالایه پایین‌گذر عمل می‌کند که تنها بخش‌هایی از داده را که بیشترین تغییرات را دارند، حفظ می‌کند. همچنین، موفقیت شبکه‌های عصبی همگشت به‌طور عمده به دلیل استفاده از پالایه‌های همگشت در هر لایه است که این امر امکان آموزش بهتر، مقیاس‌پذیری ساده‌تر و بهره‌برداری مؤثر از تغییرات ساختاری در داده‌ها را فراهم می‌آورد [۱۵]. برای طراحی پالایه‌ها، سیستم‌ها به‌طور معمول به صورت خطی و تغییرناپذیر با شیفت^۳ مدل‌سازی می‌شوند [۱۶]. بر اساس این دو فرض، اگر پاسخ ضربه سیستم را داشته باشیم، قادر خواهیم بود خروجی سیستم را از طریق همگشت بین ورودی و پاسخ ضربه پیش‌بینی کنیم. این روش به ما این امکان را می‌دهد که واکنش سیستم را به ورودی‌های مختلف پیش‌بینی کنیم و پالایه‌های بهینه‌ای طراحی نماییم تا داده‌های ضروری را برای انجام وظیفه موردنظر حفظ کرده و اطلاعات غیرضروری را حذف کنند.

۲-۲-۲- تعریف همگشت

در ریاضیات، همگشت یک عملگر ریاضی است که در مطالعه و تحلیل توابع، سیستم‌ها و پردازش داده‌ها مورد استفاده قرار می‌گیرد [۱۷]. همگشت f و g به صورت $f * g$ نوشته می‌شود. این تعریف به صورت انتگرال حاصلضرب دو تابع که یکی از آن‌ها برعکس شده و روی یکدیگر می‌لغزند تعریف می‌شود. با این تعریف، همگشت یک نوع خاص از تبدیل

^۳ Linear Shift-Invariant (LSI)


^۱ Filter

^۲ Principal Component Analysis (PCA)

انتگرالی است. انتگرال همگشت دو تابع $x_1(t)$ و $x_2(t)$ به صورت زیر تعریف می‌شود [۱۸]:

$$x_1(t) * x_2(t) = \int_{-\infty}^{\infty} x_1(t)x_2(t-\tau)d\tau \quad (2)$$

الگوریتم محاسبه همگشت دو دنباله‌ی محدود شامل جمع حاصل ضرب‌های نقطه‌ای عناصر دنباله x_1 و عناصر دنباله x_2 است که در آن x_2 به صورت زمانی معکوس شده و به اندازه τ عنصر در جهت مثبت محور زمان جابجا می‌شود (شکل ۲).



شکل ۲- نمودار الگوریتم محاسباتی برای همگشت دنباله‌های محدود

اگر ورودی یک سیستم خطی و تغییرناپذیر با زمان را به صورت مجموعی از ضربه‌های واحد شیف‌ت یافته و وزن دار در نظر بگیریم و پاسخ سیستم به هر یک از این ضربه‌ها محاسبه شود، آنگاه به کمک خاصیت‌های خطی بودن و تغییرناپذیری زمانی، پاسخ نهایی سیستم برابر با مجموع پاسخ‌های جداگانه خواهد بود [۱۹]. به عبارت دیگر، سیگنال ورودی به عنوان داده اول و پاسخ ضربه سیستم به عنوان داده دوم در نظر گرفته می‌شوند که عملیات همگشت بین این دو داده انجام می‌شود. اگر x را به عنوان داده اول و h را به عنوان پاسخ ضربه سیستم در نظر بگیریم، رابطه همگشت به شکل زیر بیان خواهد شد:

$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] h[n-k] \quad (3)$$

در رابطه (۳)، $x[n]$ نمایانگر سیگنال ورودی در لحظه‌ی زمانی n است و $h[n]$ پاسخ ضربه‌ی سیستم است؛ یعنی خروجی حاصل از تحریک سیستم با تابع ضربه‌ی واحد $\delta[n]$. تابع $\delta[n]$ که به آن دلتای کرونکر نیز گفته می‌شود، تنها در مقدار $n=0$ برابر با ۱ است و در سایر مقادیر صفر می‌باشد.

یکی از مسائل اساسی در اجرای عملیات همگشت، هزینه محاسباتی آنست [۲۰]. استفاده از نمایش در حوزه‌ی فرکانس می‌تواند با کاهش پیچیدگی محاسباتی، سرعت اجرای همگشت را به طور چشم‌گیری افزایش دهد [۲۱]. در ادامه، معادل سازی عملیات همگشت در فضای مکان (یا هر متغیر مستقل دیگری که داده بر اساس آن جمع‌آوری شده است) با فضای فرکانس بررسی خواهد شد.

۲-۳- تبدیل فوریه

تبدیل فوریه، نوعی نگاشت خطی است که یک بردار را از فضای $\mathbb{R}^n$ به فضای $\mathbb{R}^m$ منتقل می‌کند [۲۲]. در این فرآیند، با تغییر پایه به مجموعه‌ای از توابع نوسانی به شکل $e^{i\omega n}$ که پایه‌های مختلط متعامد با فرکانس‌های مشخص هستند، فضای مکانی (یا هر متغیر مستقل دیگری که داده بر اساس آن جمع‌آوری شده است) به فضای فرکانسی نگاشت می‌شود. به بیان دیگر، تبدیل فوریه با یافتن پایه‌های مناسب در فضای فرکانس، بردارها را به فضای فرکانسی نگاشت می‌دهد. پایه‌های تبدیل فوریه، علاوه بر رعایت شرط مستقل خطی بودن، دارای ویژگی‌های تعامد، تطابق با تحلیل فرکانسی، پایداری و قابلیت تبدیل معکوس هستند که امکان تجزیه و تحلیل داده‌ها در حوزه فرکانس را به طور دقیق و مؤثر فراهم می‌آورد [۱۹]. همچنین در تبدیل فوریه، تابع براساس پایه‌های $e^{i\omega n}$ بسط داده می‌شود که این پایه‌ها تابع ویژه عملگر لاپلاسین یک بعدی هستند [۲۳]:

$$-\Delta(e^{i\omega t}) = -\frac{\partial^2}{\partial t^2} e^{i2\pi f t} = (2\pi f)^2 e^{i2\pi f t} \quad (4)$$

در رابطه (۴)، $\omega = 2\pi f$ نمایانگر فرکانس زاویه‌ای است، f فرکانس معمولی، t زمان، و i واحد موهومی است که دارای خاصیت $i^2 = -1$ می‌باشد. برای سری X_t با طول محدود، تبدیل فوریه گسسته یک بعدی به صورت زیر است [۲۴]:

$$X_f = \sum_{t=0}^{T-1} X_t e^{-\frac{i2\pi f t}{T}} \quad (5)$$

و معکوس تبدیل فوریه برابر است با:

$$X_t = \frac{1}{T} \sum_{f=0}^{T-1} X_f e^{\frac{i2\pi f t}{T}} \quad (6)$$

در دو فرمول فوق، $i^2 = -1$ و T طول دنباله است.

قضیه همگشت بیان می‌کند که عملیات همگشت در دامنه مکانی معادل با حاصل ضرب نقطه‌ای در دامنه فوریه است [۲۰]:

$$\mathcal{F}(x * h) = \mathcal{F}(x) \odot \mathcal{F}(h) = X \odot H \quad (7)$$

در رابطه‌ی ۷، F نمایانگر تبدیل فوریه است و X و H به ترتیب نسخه‌های تبدیل شده x و h در حوزه فوریه هستند. این نتیجه، امکان انجام عملیات همگشتی در حوزه فوریه را فراهم می‌آورد که به نوبه خود به کاهش پیچیدگی محاسباتی منجر می‌شود [۲۵]. در ادامه، به معادل‌سازی عملگر لاپلاسین و تبدیل فوریه در داده‌های گرافی می‌پردازیم تا پالایه همگشت را هم در حوزه مکانی و هم در فضای فوریه تعریف کنیم.

۳-۲ تعاریف پالایه همگشت در فضای ناقلیدسی

۳-۲-۱ طیف گراف

در نظریه‌ی طیفی گراف، به مجموعه‌ی مقادیر ویژه‌ی هر ماتریسی که ساختار گراف را نمایش می‌دهد، طیف گراف گفته می‌شود؛ با این حال، ماتریس لاپلاسین به دلیل ویژگی‌های ریاضیاتی و کاربردی خود، متداول‌ترین انتخاب در تحلیل‌های طیفی است [۲۶]. از این رو، طیف گراف به صورت زیر تعریف می‌شود:

$$\sigma(L) = \{\lambda_0, \lambda_1, \dots, \lambda_{N-1}\} \quad (8)$$

که در آن، $\sigma(L)$ نمایانگر طیف ماتریس لاپلاسین، λ_i مقدار ویژه‌ی i -ام این ماتریس و N تعداد کل گره‌های گراف است. طیف گراف از نقطه نظر پردازش داده‌های گرافی بسیار مهم است [۲۷]. در عمل ماتریس لاپلاسین نرمال شده برای تحلیل گراف‌ها استفاده می‌شود زیرا نرمال‌سازی تاثیر مقیاس‌پذیری گره‌ها و وزن‌ها را کاهش می‌دهد که باعث می‌شود نتایج تحلیل مستقل از اندازه و وزن‌های گراف باشد. این کار به پایداری عددی کمک کرده و مقادیر ویژه را در یک بازه محدود (بین صفر تا دو) قرار می‌دهد که تحلیل و تفسیر نتایج را آسان‌تر می‌کند. ماتریس لاپلاسین نرمال شده به صورت زیر تعریف می‌شود:

$$L_N = I - D^{-1/2} A D^{-1/2} \quad (9)$$

که در آن، L_N ماتریس لاپلاسین نرمال شده، I ماتریس واحد، D ماتریس درجه‌ی گراف (شامل درجه‌ی گره‌ها در قطرهای اصلی خود) و A ماتریس مجاورت گراف است که ارتباطات بین گره‌ها را نمایش می‌دهد. همچنین، $D^{-1/2}$ معکوس جذر ماتریس درجه است. در ادامه خواهیم دید که با استفاده از طیف گراف، می‌توان حوزه‌ای مشابه با حوزه فوریه برای داده‌های گراف تعریف کرد.

۳-۲-۲ لاپلاسین گراف

لاپلاسین یک تابع در فضای پیوسته نشان‌دهنده میزان انحنا و تغییرات تابع در هر نقطه است. این عملگر تغییرات یک تابع نسبت به مختصات اطرافش را بررسی می‌کند و در تحلیل‌های فیزیک و مهندسی استفاده می‌شود. در گراف، ماتریس لاپلاسین مشابه همین مفهوم عمل می‌کند، اما به جای یک فضای پیوسته، روی یک شبکه از گره‌ها و یال‌ها تعریف می‌شود. ماتریس لاپلاسین گراف میزان تغییرات یک تابع را در یک گره نسبت به همسایگانش بررسی می‌کند. این ماتریس بر اساس تفاوت مقادیر تابع در گره‌ها و تأثیرات یال‌ها (یا اتصالات) بین آن‌ها محاسبه می‌شود [۲۶]. برای داده‌ای $(h \in \mathbb{R}^N)$ که دامنه آن بر روی گراف تعریف شده است، داریم:


$$(Lh)_i = \sum_{j \in N_i} w_{ij} (h_i - h_j) \quad (10)$$

که N_i بیانگر تمام گره‌هایی است که توسط یالی به گره i -ام متصل شده‌اند. w_{ij} درایه i, j ام ماتریس مجاورت وزن دار است. از این ویژگی ماتریس لاپلاسین در تعریف فوریه استفاده خواهیم کرد.

۳-۳-۲ تبدیل فوریه گرافی

برای تعمیم مفهوم تبدیل فوریه از داده‌های با دامنه‌ی منظم به داده‌های گرافی، از ارتباط میان عملگر لاپلاسین در فضای تابعی و ماتریس لاپلاسین گراف بهره گرفته می‌شود. در داده‌های منظم، پایه‌های تبدیل فوریه از طریق توابع ویژه‌ی عملگر لاپلاسین یک‌بعدی تعیین می‌شوند. به طور مشابه، با توجه به نزدیکی ساختاری میان عملگر لاپلاسین در فضای تابع و ماتریس لاپلاسین گراف، از این مفهوم برای تعریف تبدیل فوریه در گراف‌ها نیز استفاده می‌شود. در این فرآیند، به جای توابع ویژه، از بردارهای ویژه (طیف گراف) در عملیات ماتریسی بهره گرفته می‌شود که امکان تحلیل و

پردازش داده‌های گرافی را فراهم می‌آورد [۲۷]. شکل ۳ نشان می‌دهد که در فضای اقلیدسی، توابع پایه‌ی فوریه شامل سینوس‌ها و کسینوس‌ها هستند، در حالی که در گراف‌ها، بردارهای ویژه‌ی لاپلاسیان می‌توانند ساختارهای پنهان گراف مانند جوامع^۱ یا گره‌های کلیدی را آشکار سازند.



شکل ۳- مقایسه توابع پایه فوریه در فضاهای اقلیدسی و گرافی

ماتریس لاپلاسیان یک گراف بدون جهت، متقارن است. این خاصیت متقارن بودن به این معناست که بردارهای ویژه ماتریس لاپلاسیان متعامد هستند و مقادیر ویژه آن‌ها اعداد حقیقی‌اند. علاوه بر این، هر ماتریس متقارن، از جمله ماتریس لاپلاسیان، قابل تجزیه ویژه است؛ به این معنا که می‌توان ماتریس لاپلاسیان را به صورت

$$L = U\Lambda U^T \quad (11)$$

نوشت که در آن $U = [\vec{U}_0, \vec{U}_1, \dots, \vec{U}_N]$ مجموعه کامل از بردارهای ویژه‌ی ماتریس لاپلاسیان است و Λ ماتریس قطری مقادیر ویژه لاپلاسیان گراف (طیف لاپلاسیان گراف) است. بنابراین تبدیل فوریه داده‌ای که دامنه‌ی آن بر روی گراف واقع شده به صورت زیر تعریف می‌شود [۲۸]:

$$\hat{x} = U^T x \quad (12)$$


و به همین ترتیب معکوس تبدیل فوریه‌ی گرافی به صورت زیر تعریف می‌شود [۲۸]:

$$x = U\hat{x} \quad (13)$$

۲-۳-۴- پالایه‌های گرافی

مشابه با داده‌های با دامنه اقلیدسی، پالایه‌های گرافی به‌صورت سیستم‌هایی تعریف می‌شوند که داده ورودی با دامنه‌ی گرافی را دریافت کرده و پس از پردازش، داده

خروجی دیگری با همان دامنه‌ی گرافی تولید می‌کنند. شکل ۴، نمودار بلوکی پالایه گرافی را نشان می‌دهد.



شکل ۴- نمودار بلوکی پالایه گرافی

در پردازش داده‌های با دامنه گرافی، پالایه با ضرب ماتریسی اعمال می‌شود. مشابه با داده‌های با دامنه اقلیدسی برای طراحی پالایه‌ها، سیستم‌ها به طور معمول به صورت خطی و تغییرناپذیر با شیفت مدل‌سازی می‌شوند. از آنجا که پالایه گرافی با ضرب ماتریس تعریف می‌شود خاصیت خطی بودن را دارا می‌باشد. برای برقرار بودن خاصیت تغییرناپذیری با شیفت، هر پالایه H ای که بر داده ورودی x بر روی گراف G اعمال می‌شود را می‌توان به صورت یک چندجمله‌ای از ماتریس شیفت L نوشت؛ به عبارتی:

$$H = h(L) = \sum_{m=0}^{M-1} h_m L^m \quad (14)$$

با توجه به ثابت بودن گراف G ، در نتیجه عملگر شیفت نیز برای همه آن گراف‌ها ثابت است و تفاوت سیستم‌های خطی و تغییرناپذیر با شیفت گرافی در درجه m و ضرایب $\{h_m\}_{m=0}^{M-1}$ است. با تجزیه‌ی ویژه ماتریس L به مقادیر ویژه (Λ) و بردارهای ویژه (U) ، پالایه بر روی داده‌های گرافی به صورت زیر تعریف می‌شود [۲۷]:

$$y = Hx$$

$$U^T y = \left(\sum_{i=0}^{M-1} h_i \Lambda^i \right) (U^T x) \quad (15)$$

$$y = U \left(\sum_{i=0}^{M-1} h_i \Lambda^i \right) (U^T x)$$

۲-۳-۵- همگشت گرافی


در پالایه همگشت، داده‌ها با وزن‌هایی ترکیب می‌شوند که معادل داده و شیفت‌های آن‌ها با ضرایب مختلف هستند،



شکل ۵- عملگر شیفت گرافی


۲-۳-۶- انواع رویکردهای پالایه همگشت گرافی

پالایش داده‌های گرافی را می‌توان در دو حوزه‌ی مکان (گره‌های گراف) و حوزه‌ی فوریه (طیف گراف) بررسی کرد. در رویکرد مکانی، ویژگی‌های هر گره با توجه به ویژگی‌های همسایگانش به‌روز می‌شود و تمرکز بر تعاملات محلی گراف است [۲۳]. مشابه عملیات همگشت در شبکه‌های CNN برای پردازش تصویر، روش‌های مبتنی بر مکان در گراف همگشت‌ها را بر اساس روابط مکانی گره‌ها تعریف می‌کنند. تصاویر را می‌توان نوعی گراف در نظر گرفت که در آن هر پیکسل نقش یک گره را دارد و به‌طور مستقیم به پیکسل‌های مجاور خود متصل است، (شکل ۶).



شکل ۶- مثالی از پالایه همگشت بر روی تصویر به عنوان نماینده‌ای از داده‌های منظم اقلیدسی

در شکل ۶ پالایه به یک ناحیه 3×3 اعمال می‌شود و میانگین وزنی مقادیر پیکسل‌های گره مرکزی و همسایگان آن در هر کانال (یعنی در هر مؤلفه‌ی بردار ویژگی) محاسبه می‌شود. به‌طور مشابه، همگشت‌های گراف مبتنی بر مکان، نمایه گره مرکزی را با نمایه‌های همسایگان آن همگشت می‌کنند تا نمایه به‌روز شده‌ای برای گره مرکزی حاصل شود (شکل ۷).



شکل ۷- مثالی از پالایه همگشت داده‌های گرافی


که جزئیات این فرآیند در بخش ۲-۲-۲ توضیح داده شد. در داده‌های اقلیدسی، این فرآیند شامل ترکیب داده‌ها با مقادیر شیفت‌شده است. اما در داده‌های گرافی، این عمل با استفاده از عملگر شیفت گرافی انجام می‌شود. ماتریس عمومی $S \in \mathbb{R}^{N \times N}$ به عنوان عملگر شیفت گرافی^۱ برای گراف G تعریف می‌شود. شرط لازم برای معتبر بودن S به عنوان عملگر شیفت گرافی این است که [۱۳]:

$$[S]_{ji} = s_{ji} = 0 \quad \text{whenever } (i, j) \notin \text{Edges for } i \neq j \quad (16)$$

به عبارت دیگر، هر ماتریسی که تنها برای گره‌های متصل به یکدیگر دارای درایه‌های غیر صفر باشد، می‌تواند به عنوان عملگر شیفت گرافی مورد استفاده قرار گیرد. ماتریس‌های مجاورت و لاپلاسین گراف، چه در شکل اصلی و چه نرمال‌شده، دارای این ویژگی هستند و بنابراین گزینه‌های مناسبی برای عملگر شیفت به شمار می‌روند. این ماتریس‌ها نقش کلیدی در انتقال و انتشار اطلاعات در ساختار گرافی ایفا می‌کنند و بسته به نوع کاربرد، می‌توانند تحلیل سیگنال‌های گراف را به گونه‌ای مؤثر پشتیبانی کنند. شکل ۵ این مفهوم را به صورت بصری نشان می‌دهد. گراف سمت چپ ساختار اولیه گراف با گره‌های v_1 تا v_5 و یال‌های بین آن‌ها را نمایش می‌دهد. خطوط قائم روی هر گره نشان‌دهنده مقدار سیگنال روی آن گره هستند که با رنگ‌های متمایز برای تأکید بر گره‌های با مقادیر سیگنال خاص یا نقش متفاوت مشخص شده‌اند. گراف سمت راست نتیجه اعمال عملگر شیفت گرافی S را نشان می‌دهد. به عنوان مثال، در این گراف مشاهده می‌شود که گره v_3 فاقد خط قائم و یال است، که بیانگر صفر شدن سیگنال آن پس از اعمال عملگر شیفت است. این پدیده به دلیل شرط تعریف‌شده برای ماتریس S رخ می‌دهد: از آن‌جا که گره‌های همسایه‌ی v_3 سیگنالی نداشته‌اند، هیچ اطلاعاتی به آن منتقل نشده است؛ در نتیجه، مقدار سیگنال v_3 به همسایگانش منتقل شده و خود آن پس از شیفت، مقدار صفر دارد. این فرآیند نمونه‌ای از انتشار محلی سیگنال در گراف تحت تأثیر ساختار یال‌ها و ماتریس شیفت است.

^۱ Graph shift operator (GSO)

در رویکردهای طیفی برای انجام عملیات همگشت گرافی، داده ورودی ابتدا به حوزه فوریه منتقل می‌شود. در این حوزه، پالایه مورد نظر با پاسخ فرکانسی مطلوب طراحی می‌شود. عملیات همگشت در حوزه فوریه معادل با ضرب نقطه‌ای دو داده است، بنابراین عملیات ضرب نقطه‌ای دو داده انجام می‌گیرد. برای بازگرداندن این داده‌ها به حوزه مکان (که گره‌های گراف هستند)، از تبدیل فوریه معکوس استفاده می‌شود. ترتیب این عملیات در شکل ۸ نشان داده شده است.



۳-۲- شبکه همگشتی گراف^۳

۳- تعاریف یادگیری عمیق هندسی

۳-۱- یادگیری بازنمایی^۱ یا نشان^۲ گراف

The diagram illustrates the input graph and the three layers of a Graph Neural Network (GNN).

INPUT GRAPH: A graph with 6 nodes (A, B, C, D, E, F) and edges. Node A is highlighted as the **TARGET NODE**.

Layer-0: The input features for each node are represented as vectors $X_A, X_B, X_C, X_D, X_E, X_F$.

Layer-1: The features are aggregated into a central node representation (grey square) for each node in the input graph. The aggregation is performed using a function g (indicated by the dashed arrow labeled g).


Layer-2: The features are aggregated into a central node representation (grey square) for each node in the input graph. The aggregation is performed using a function g (indicated by the dashed arrow labeled g).

شکل ۹- مثالی از یادگیری بازنمایی در سطح گره‌های گراف در فضای دوبعدی، [۳۱]

Graph Convolution Networks (GCNs)

৭৮


حالی که شبکه‌های همگشتی گراف به‌عنوان نسخه‌ای تعمیم‌یافته از شبکه‌های عصبی همگشتی، برای پردازش داده‌های با ساختار نامنظم و گرافی توسعه یافته‌اند [۳۴]. در شکل ۱۱، تفاوت عملیات همگشت در شبکه عصبی همگشتی و شبکه همگشتی گراف به‌وضوح نشان داده شده است.



شکل ۱۱- تفاوت عملیات همگشت در شبکه عصبی همگشتی با شبکه همگشتی گراف

۳-۳-۳- روند کلی طراحی شبکه‌های عصبی گراف

مقاله Zhou و همکاران [۳۵] یک رویکرد چهارمرحله‌ای برای طراحی مدل شبکه‌های عصبی گرافی را به‌صورت خلاصه ارائه کرده است که در شکل ۱۲ نشان داده شده است. در ادامه مراحل طراحی یک شبکه عصبی گرافی را مرور کرده و سپس به بررسی کاربردهای عملی این شبکه‌ها در پردازش داده‌های مکانی می‌پردازیم.



شکل ۱۲- مراحل طراحی مدل شبکه عصبی گرافی (مطابق با Zhou و همکاران [۳۵])

۳-۳-۱- مشخص کردن ساختار گراف

اولین مرحله در طراحی یک شبکه عصبی گراف، تعیین ساختار گراف است که شامل شناسایی گره‌ها و نحوه ارتباط آن‌ها از طریق یال‌ها می‌شود [۹]. به طور کلی، برای تعیین ساختار گراف دو رویکرد اصلی وجود دارد: رویکردهای ساختاری و غیرساختاری. در رویکردهای ساختاری، ساختار گراف به طور واضح در شبکه‌ها وجود دارد، مانند شبکه‌های حمل‌ونقل، شبکه‌های تعاملات شیمیایی بین مولکول‌ها در فرایند داروسازی و شبکه‌های پایش کیفیت هوا. در مقابل، در رویکردهای غیرساختاری، گراف‌ها به صورت ضمنی هستند و ابتدا باید ساختار گراف را بر اساس هدف مشخص‌شده ایجاد کنیم، مانند ساختن یک گراف کاملاً متصل از کلمات برای تحلیل متن یا ایجاد گراف برای یک تصویر.

۳-۳-۲- مشخص کردن نوع گراف

بدون وزن یا وزن دار بودن گراف گراف بدون وزن یک گراف $G = (V, E)$ گرافی است که در آن یال‌ها هیچ وزنی ندارند و تنها وجود یا عدم وجود یال‌ها اهمیت دارد. گراف وزن‌دار یک گراف $G = (V, E, W)$ است که از گره‌ها، یال‌ها و وزن‌ها تشکیل می‌شود. W یک نگاشت از مجموعه یال‌ها به مجموعه اعداد حقیقی مثبت است که تابع وزن نام دارد. به بیان دیگر، گراف بدون وزن حالت خاصی از گراف وزن‌دار است که در آن تمام وزن‌ها برابر با ۱ هستند.

جهت‌دار یا جهت‌دار نبودن گراف اگر در یک گراف یال‌ها همگی از یک گره به گره دیگر جهت داشته باشند، به آن گراف جهت‌دار گفته می‌شود. در غیر این صورت، آن را گراف غیرجهت‌دار می‌نامند.

همگن^۱ یا ناهمگن^۲ بودن گراف اگر در یک شبکه تنها یک نوع گره و یک نوع یال وجود داشته باشد، به آن شبکه همگن گفته می‌شود. در غیر این صورت، آن را شبکه ناهمگن می‌نامند.

پویا یا ثابت بودن گراف در بسیاری از شبکه‌های دنیای واقعی، گراف‌ها به مرور زمان تغییر می‌کنند؛ به این معنا که در طول زمان، حداقل یکی از اجزای گراف (گره، یال، ویژگی یا وزن یال) تغییر می‌یابد. این نوع گراف‌ها را گراف‌های پویا می‌نامند. در مقابل، اگر تمام اجزای گراف در طول زمان ثابت بمانند، به آن گراف ساکن گفته می‌شود [۳۶]. این

دسته‌بندی‌ها مستقل از یکدیگر هستند، به این معنا که می‌توان این نوع‌ها را با هم ترکیب کرد. به عنوان مثال، می‌توان با یک گراف ناهمگن پویا و جهت‌دار کار کرد. همچنین چندین نوع گراف دیگر وجود دارد که برای وظایف مختلف طراحی شده‌اند، مانند هایپرگراف‌ها و گراف‌های دارای علامت. ما در اینجا همه انواع گراف‌ها را لیست نمی‌کنیم، اما مهم‌ترین نکته این است که اطلاعات اضافی ارائه‌شده توسط این گراف‌ها را در نظر بگیریم. پس از مشخص کردن نوع گراف، اطلاعات اضافی که این نوع گراف‌ها فراهم می‌کنند باید در فرآیند طراحی بیشتر مورد توجه قرار گیرند.

۳-۳-۳- طراحی تابع خطا

در مرحله سوم، نوع و تنظیم یادگیری باید تعیین شود و بر این اساس، یک تابع خطا مناسب انتخاب می‌شود. در شبکه‌های عصبی گرافی تفاوتی در توابع خطا برای آموزش نسبت به سایر شبکه‌های عمیق وجود ندارد. به عنوان مثال، برای مسائل رگرسیون گره، از میانگین مربعات خطا (MSE^1) در پیش‌بینی سطح آلودگی هوا استفاده می‌شود. برای طبقه‌بندی گره‌ها، آنتروپی متقاطع (Cross-Entropy) در دسته‌بندی انواع کاربران در شبکه‌های اجتماعی کاربرد دارد.

۳-۳-۴- ساخت مدل شبکه عصبی

در مرحله نهایی، مدل شبکه عصبی گرافی با استفاده از ماژول‌های مختلف طراحی و پیاده‌سازی می‌شود. این ماژول‌ها شامل ماژول‌های انتشار (Propagation Modules) برای انتقال اطلاعات بین گره‌ها، ماژول‌های نمونه‌برداری (Sampling Modules) برای کاهش پیچیدگی پردازش در گراف‌های بزرگ، و ماژول‌های تجمیع (Pooling Modules) برای فشرده‌سازی اطلاعات در سطح گره یا کل گراف هستند [۳۷].

۴- کاربرد شبکه‌های همگشت گرافی

پس از معرفی مفاهیم بنیادی شبکه‌های همگشت گرافی، در این بخش به بررسی کاربردهای عملی این مدل‌ها در سیستم‌های اطلاعات مکانی (GIS) خواهیم پرداخت. کاربردهای شبکه‌های همگشت گرافی مکانی-زمانی (ST-)

(GNN) به طور کلی در دو دسته اصلی طبقه‌بندی می‌شوند: پیش‌بینی و درون‌یابی. در ادامه، به تفصیل ویژگی‌ها و چالش‌های خاص هر یک از این دسته‌ها را مورد بررسی قرار خواهیم داد.

۴-۱- پیش‌بینی

پیش‌بینی مبتنی بر داده‌های گرافی مکانی-زمانی معمولاً به دسته‌های مختلفی تقسیم می‌شود که هر یک دارای ویژگی‌ها و چالش‌های خاص خود هستند. این تقسیم‌بندی بر پایه خصوصیات ساختاری داده‌ها و پیچیدگی‌های مرتبط با فرآیند پیش‌بینی صورت می‌گیرد.

۴-۱-۱- پیش‌بینی داده‌های گرافی مکانی-زمانی متراکم^۲

داده‌های گرافی متراکم به داده‌هایی گفته می‌شود که در اغلب زمان‌ها دارای مقادیر معتبر و غیر صفر هستند و تنها در موارد نادری مقدار آن‌ها صفر می‌شود. این نوع داده‌ها معمولاً فاقد چالش‌های پیچیده در پیش‌بینی هستند، زیرا مدل‌ها عمدتاً با پیش‌بینی مقادیر پیوسته و قابل‌دسترسی سروکار دارند. از جمله کاربردهای متداول این نوع داده‌ها می‌توان به پیش‌بینی جریان و سرعت ترافیک، غلظت آلاینده‌هایی نظیر $PM_{2.5}$ ، و شاخص کیفیت هوا اشاره کرد [۳۸]–[۴۰]. در این نوع مسائل، شبکه‌ای از حسگرها (مانند حسگرهای ترافیکی یا ایستگاه‌های پایش آلودگی هوا) به‌صورت یک گراف مکانی-زمانی مدل‌سازی می‌شود؛ به‌گونه‌ای که گره‌ها نمایانگر موقعیت‌های مکانی حسگرها و یال‌ها بیانگر روابط مکانی میان آن‌ها هستند. در مطالعات مختلف، برای تعریف این روابط مکانی از معیارهای گوناگونی مانند فاصله جغرافیایی، همبستگی آماری داده‌ها یا ساختار مسیرهای ارتباطی استفاده می‌شود. علاوه بر ساختار گراف، ویژگی‌های زمانی هر گره (مانند میانگین سرعت خودروها یا سطح آلودگی در یک بازه زمانی مشخص) به‌عنوان ورودی‌های پویا به مدل داده می‌شود [۴۱]. چنین تلفیقی از اطلاعات مکانی و زمانی، بستری مناسب برای تحلیل‌های دقیق‌تر و پیش‌بینی‌های مؤثرتر فراهم می‌آورد. در این میان، داده‌های پیش‌بینی ترافیک نظیر PeMS-Bay و METR-LA به‌صورت عمومی در دسترس بوده و به‌عنوان معیارهای

^۲ Dense spatiotemporal graph data

^۱ Mean Squared Error

استاندارد جهت ارزیابی شناخته می‌شوند. بسیاری از پژوهشگران از این داده‌ها برای ارزیابی و مقایسه عملکرد مدل‌های پیشنهادی خود با مدل‌های پایه بهره می‌برند [۴۲]. به‌منظور تسهیل در انجام این مقایسه‌ها، مجموعه‌ای از این داده‌ها در مخزن GitHub مقاله گردآوری شده است تا پژوهشگران آینده بتوانند ارزیابی‌های دقیق و منصفانه‌تری داشته باشند. همچنین، نمونه‌هایی از مدل‌های مبتنی بر شبکه‌های عصبی گرافی زمانی-مکانی که در زمینه داده‌های متراکم به کار رفتند، در جدول ۱ ارائه شده است.

جدول ۱- نمونه مدل‌ها و داده‌ها در حوزه گراف‌های مکانی-زمانی متراکم

نام مدل	مجموعه داده	کاربرد
CDGNet [۴۰]	METR-LA, PeMS-BAY	سرعت ترافیک
AST-GCN [۴۱]	SZ-taxi, Los-loop	
DCRNN [۴۳]	METR-LA, PeMS-BAY	
GC-LSTM [۳۸]	Jing-Jin-Ji Environmental Data	آلودگی هوا
GCN-LSTM-GRU-Q [۴۴]	Changsha Environmental Data	
GSTGCN [۳۹]	PeMSD4, PeMSD7	جریان ترافیک
HGCN [۴۵]	JiNan, XiAn	

۴-۱-۲- پیش‌بینی داده‌های گرافی مکانی-زمانی پراکنده^۱

پیش‌بینی داده‌های گرافی مکانی-زمانی پراکنده شامل کاربردهایی مانند پیش‌بینی وقوع جرم، شیوع بیماری‌های واگیردار، یا آتش‌سوزی‌های گسترده است. ویژگی مشترک این نوع داده‌ها آن است که در اغلب زمان‌ها مقدار آن‌ها صفر بوده و تنها در بازه‌های زمانی خاص، مقادیر غیر صفر ثبت می‌شود. این پدیده که با عنوان انباشتگی مقادیر صفر^۲ شناخته می‌شود، چالشی جدی برای مدل‌های یادگیری ماشین ایجاد می‌کند؛ چرا که در صورت استفاده از رویکردهای معمول، خروجی مدل‌ها به‌طور عمده صفر خواهد بود و رویدادهای نادر ولی مهم شناسایی نمی‌شوند. در حال حاضر، این چالش اغلب با استفاده از توابع هزینه تقویت‌شده [۴۶]، [۴۷] یا اجزای حساس‌تر در مدل [۴۸] برطرف شده است. به‌عنوان مثال، در مسئله پیش‌بینی وقوع

جرم، شهر به نواحی مجزای جغرافیایی تقسیم می‌شود (برای مثال بر اساس مناطق پستی یا شبکه‌ای از سلول‌های مربعی در نقشه). در این صورت، هر ناحیه به‌عنوان یک گره در گراف در نظر گرفته می‌شود. ارتباط بین نواحی مجاور (مثلاً نواحی هم‌مرز یا دارای شباهت جمعیتی) به‌عنوان یال در نظر گرفته می‌شود و وزن این یال‌ها می‌تواند بر اساس فاصله مکانی، شباهت الگوهای جرائم گذشته یا میزان تعامل اجتماعی بین نواحی تنظیم شود. برای هر گره، سری زمانی مربوط به تعداد جرائم در بازه‌های زمانی معین (مثلاً روزانه یا هفتگی) در نظر گرفته می‌شود. به این ترتیب، مدل گراف مکانی-زمانی قادر خواهد بود نه تنها وابستگی‌های زمانی (وقوع جرائم در گذشته) را بیاموزد، بلکه از الگوهای مکانی انتشار جرم در نواحی مختلف شهر نیز بهره بگیرد. این ساختار گرافی باعث افزایش دقت پیش‌بینی در نقاط حساس و کاهش هشدارهای اشتباه می‌شود.

جدول ۲- نمونه مدل‌ها و داده‌ها در حوزه گراف‌های مکانی-زمانی پراکنده

نام مدل	مجموعه داده	کاربرد
GLDNet [۴۶]	Chicago Crime	وقوع جرم
CrimeForecaster [۴۷]	Los Angeles Crime, Chicago Crime	
AttenCrime [۴۹]	NYC Crime, NYC Anomaly	
STAN [۵۰]	US county-level Covid-19	همه‌گیری
CovidGNN [۵۱]	US county-level Covid-19	

در این حوزه، مجموعه‌داده‌های عمومی و رایگانی وجود دارند که در مطالعات مختلف مورد استفاده قرار گرفته‌اند. از جمله این مجموعه‌داده‌ها می‌توان به داده‌های جرایم شهرهای شیکاگو، نیویورک، سان‌فرانسیسکو، بوستون، لس‌آنجلس، برزیل و لندن اشاره کرد. برای مقایسه منصفانه میان مدل‌های پیشنهادی آینده با مدل‌های پایه، استفاده از داده‌های یکسان ضروری است. به همین منظور، مجموعه‌ای از این داده‌ها در مخزن GitHub مقاله پیش‌رو گردآوری شده‌اند تا زمینه برای ارزیابی دقیق و هم‌راستای پژوهش‌ها فراهم شود. در میان این منابع، مجموعه‌داده جرایم شیکاگو به‌دلیل پوشش زمانی بلندمدت (از سال ۲۰۰۱ تاکنون) و سطح بالای جزئیات، یکی از پرکاربردترین

^۲ Zero-Inflation

^۱ Sparse spatiotemporal graph data

و معتبرترین مجموعه‌ها برای تحلیل‌ها و مدل‌سازی‌های پیش‌بینی‌محور در این حوزه به‌شمار می‌رود. علاوه بر این، در جدول ۲ نمونه‌هایی از مدل‌های مبتنی بر شبکه‌های عصبی گراف‌ی زمانی-مکانی که در زمینه داده‌های پراکنده به‌کار رفته‌اند، آورده شده‌است.

۴-۱-۳- پیش‌بینی داده‌های گراف‌ی مکانی-زمانی نیمه‌متراکم^۱

داده‌های گراف‌ی مکانی-زمانی نیمه‌متراکم، عمدتاً شامل حوزه‌هایی نظیر پیش‌بینی سیلاب، پیش‌بینی مصرف برق، پیش‌بینی تقاضای تاکسی و توصیه مکان‌های جذاب جغرافیایی^۲ می‌شود. این نوع داده‌ها با دو نوع داده‌ی پیشین تفاوت دارند؛ به‌گونه‌ای که در برخی بازه‌های زمانی دارای مقادیر صفر هستند، اما در بازه‌های دیگر، ویژگی‌های داده‌های متراکم را نشان می‌دهند.

جدول ۳- نمونه مدل‌ها و داده‌ها در حوزه گراف‌های مکانی-زمانی نیمه‌متراکم

نام مدل	مجموعه داده	کاربرد
GSTAN [۵۲]	London Electricity	مصرف برق
T-GCN (electric) [۵۳]	Electric Vehicles Charging of Palo Alto city	
HeteroGraphRec [۵۴]	Ciao, Douban, Epinions	توصیه مکان‌های جذاب جغرافیایی
PPR [۵۵]	Foursquare, Gowalla, Brightkite	
STGCN (Flood) [۵۶]	Harris County Flood	سیلاب
StreamGConvGRU [۵۷]	Johnson County Streamflow	
MIFGNN [۵۸]	Barclays Center and Terminal 5	تقاضای تاکسی

از این‌رو، معمول است که پژوهشگران بخش‌هایی از داده را که مقدار آن‌ها صفر است حذف کرده و داده‌های متراکم باقی‌مانده را برای پیش‌بینی وضعیت در لحظات متراکم آینده مورد استفاده قرار دهند [۴۲]. تکنیک‌های به‌کاررفته در این حالت، تقریباً مشابه روش‌های استفاده‌شده برای داده‌های متراکم هستند و تفاوت محسوسی در آن‌ها دیده نمی‌شود. در جدول ۳ نمونه‌هایی از مدل‌های مبتنی بر شبکه‌های عصبی گراف‌ی زمانی-مکانی که در زمینه داده‌های نیمه‌متراکم به‌کار رفته‌اند، ارائه شده‌است.

۴-۲- درون‌یابی

درون‌یابی در چارچوب شبکه‌های هم‌گشت گراف‌ی مکانی-زمانی به معنای برآورد مقادیر مفقود یا اندازه‌گیری‌نشده در نقاط مختلف شبکه بر اساس داده‌های موجود است. این فرآیند نقش بسزایی در بسیاری از حوزه‌های علمی و مهندسی ایفا می‌کند؛ به‌ویژه در زمینه‌هایی نظیر علوم محیط‌زیست، هیدرولوژی، علوم خاک، هواشناسی، ژئوفیزیک، سلامت عمومی، اقیانوس‌شناسی و کشاورزی دقیق که در آن‌ها دستیابی به داده‌های کامل و پیوسته به‌دلیل عواملی نظیر هزینه بالای پایش گسترده، خرابی یا نقص حسگرها، شرایط نامساعد محیطی یا محدودیت‌های عملیاتی، همواره با چالش مواجه است [۵۹]. در تمامی این کاربردها، هدف اصلی آن است که با بهره‌گیری از وابستگی‌های مکانی-زمانی موجود در داده‌های مشاهده‌شده و استخراج الگوهای پنهان در آن‌ها، مقادیر گم‌شده در ابعاد مکانی، زمانی یا ترکیبی از هر دو تخمین زده شود. به عنوان مثال، در مدیریت منابع آب، درون‌یابی برای بازسازی داده‌های بارش یا جریان رودخانه‌ها به منظور پیش‌بینی سیلاب‌ها حیاتی است؛ در مدل‌سازی کیفیت هوا، داده‌های گم‌شده از ایستگاه‌های سنجش آلاینده‌ها جهت تحلیل توزیع مکانی-زمانی آلودگی جوی بازسازی می‌شوند؛ و در اپیدمیولوژی محیطی، تخمین پراکندگی مکانی بیماری‌ها برای پایش سلامت جمعیت مورد استفاده قرار می‌گیرد [۶۰]. همچنین، در حوزه اقیانوس‌شناسی، درون‌یابی برای تکمیل داده‌های مربوط به دما، شوری یا جریان‌های سطحی اقیانوسی در مناطق فاقد پوشش اندازه‌گیری، نقشی اساسی در تحلیل فرآیندهای دریایی ایفا می‌کند [۶۱]. در کشاورزی دقیق نیز، درون‌یابی پارامترهایی مانند رطوبت خاک یا شاخص‌های پوشش گیاهی برای بهینه‌سازی تصمیم‌گیری‌های زراعی بسیار مؤثر است [۶۲].

در طول دهه‌های گذشته، روش‌های متعددی برای برآورد مقادیر ناشناخته در نقاط فاقد داده پیشنهاد شده‌اند [۶۳]. از جمله نخستین رویکردها، می‌توان به روش‌هایی اشاره کرد که بر اساس مجاورت مکانی عمل می‌کنند، مانند روش چندضلعی تیسن^۳ [۶۴] یا میانگین‌گیری فاصله‌وزن‌دار^۴ [۶۵]، که در آن‌ها وزن‌دهی به ایستگاه‌های اطراف بر مبنای

^۳ Thiessen polygon

^۴ Inverse distance weighted (IDW) interpolation

^۱ Semi-dense spatiotemporal graph data

^۲ Geographical POI recommendation

فاصله تا نقطه هدف انجام می‌شود. در دهه‌های بعد، روش‌های زمین‌آمار نظیر کریجینگ^۱ توسعه یافتند که امکان مدل‌سازی ساختار همبستگی مکانی میان ایستگاه‌ها را فراهم می‌کردند. در این میان، کریجینگ معمولی^۲ به‌عنوان یکی از پرکاربردترین روش‌های زمین‌آمار، جایگاه ویژه‌ای در مطالعات درون‌یابی یافته است. این روش به‌طور گسترده مورد استفاده قرار گرفته و در مقایسه با روش‌های ساده‌تری مانند میانگین‌گیری وزن‌دار، دقت و کارایی بالاتری از خود نشان داده است [۶۵]. با وجود دقت بالای این روش‌ها در محیط‌های با همبستگی مکانی قوی، چالش اصلی آن‌ها در پیچیدگی محاسباتی بالا به‌ویژه در مقیاس‌های بزرگ است. در روش کریجینگ، محاسبه وزن‌های بهینه نیازمند تشکیل و معکوس‌سازی ماتریس کوواریانس مشاهدات است. این عملیات، که معمولاً بر روی ماتریسی متقارن و مثبت معین انجام می‌شود، دارای پیچیدگی زمانی در مرتبه $O(n^3)$ است؛ جایی که n نشان‌دهنده تعداد نقاط دارای داده مشاهده‌شده است [۶۶]. حتی در صورت بهره‌گیری از الگوریتم‌های عددی پیشرفته مانند تجزیه چولسکی^۳ یا روش‌های مبتنی بر حل مستقیم دستگاه‌های معادلات خطی، پیچیدگی نظری محاسباتی به‌طور معمول کمتر از $O(n^{2.73})$ نخواهد بود [۶۷]. این سطح از پیچیدگی، کارایی و مقیاس‌پذیری روش‌های زمین‌آمار را در کاربردهایی با حجم بالای داده به‌طور جدی محدود می‌سازد.

در سال‌های اخیر، توسعه‌ی روش‌های یادگیری عمیق و مدل‌سازی گرافی منجر به ظهور رویکردهای نوینی برای درون‌یابی داده‌های مکانی-زمانی شده است. شبکه‌های عصبی گراف مکانی-زمانی به‌عنوان یکی از مهم‌ترین این روش‌ها، امکان مدل‌سازی هم‌زمان وابستگی‌های مکانی و زمانی را فراهم می‌سازند. در این شبکه‌ها، داده‌ها در قالب گراف‌هایی مدل‌سازی می‌شوند که گره‌ها نمایانگر مکان‌های مشاهده‌شده و یال‌ها نمایانگر روابط مکانی (و در برخی معماری‌ها، زمانی) میان آن‌ها هستند. وزن‌دهی به یال‌ها می‌تواند بر اساس اطلاعات زمینه‌ای (مانند موقعیت جغرافیایی، فاصله، جهت باد، یا سایر ویژگی‌های فیزیکی) یا به‌صورت آموخته‌شده در طی فرآیند آموزش انجام شود [۶۸]. برخلاف روش‌های زمین‌آمار که بر پایه‌ی فرضیات آماری مشخص و مدل‌های صریح کوواریانس بنا شده‌اند،

شبکه‌های عصبی گرافی با بهره‌گیری از معماری‌های یادگیری عمیق، قابلیت مدل‌سازی روابط غیرخطی و پیچیده میان متغیرها را دارند و به‌صورت داده‌محور ساختار بهینه‌ی گراف را فرا می‌گیرند [۶۹]. علاوه‌براین، پیچیدگی زمانی مدل‌های گرافی به‌صورت خطی یا شبه‌خطی با تعداد گره‌ها و یال‌ها مقیاس می‌پذیرد، که مزیتی مهم نسبت به روش‌های مبتنی بر معکوس‌سازی ماتریس دارد. در جدول ۴، نمونه‌هایی از مدل‌ها و داده‌های به‌کاررفته در زمینه‌ی گراف‌های مکانی-زمانی برای درون‌یابی گردآوری شده است.

جدول ۴- نمونه‌هایی از مدل‌ها و داده‌های گرافی در کاربردهای درون‌یابی مکانی-زمانی

نام مدل	مجموعه داده	کاربرد
GSI [۶۹]	Raingauge datasets from Hong Kong (HK), China, and Baden-Württemberg (BW), Germany.	بارش باران
SPONGE [۶۸]	Soil organic carbon data in the southern part of Malawi.	کربن آلی خاک
GNN-STI [۷۰]	Air quality monitoring data in China	PM _{2.5}
POGR [۷۱]	U.S. EPA Air Quality System	
DBGNN [۷۲]	METR-LA, PEMS04, PEMS08	ترافیک

۵- جمع بندی

پردازش داده‌های گراف‌محور مستلزم بهره‌گیری از مدل‌هایی است که قادر باشند روابط و وابستگی‌های میان گره‌ها را با استفاده از اطلاعات ساختار همسایگی استخراج کنند؛ فرآیندی که تا حدی با عملکرد شبکه‌های عصبی پیچشی (CNN) در تحلیل داده‌های ساختاریافته قابل مقایسه است. بر همین اساس، در این پژوهش، ابتدا بنیان‌های نظری و ریاضیاتی شبکه‌های عصبی گرافی (GNN) با تمرکز بر پالایه‌های همگشت گرافی مورد بررسی قرار گرفت و تفاوت‌ها و چالش‌های آن‌ها نسبت به شبکه‌های عصبی پیچشی تحلیل شد. در ادامه، کاربردهای این مدل‌ها در زمینه‌های پیش‌بینی و درون‌یابی تحلیل و دسته‌بندی گردید و برای هر یک از این کاربردها، مجموعه‌ای از داده‌های رایگان و در دسترس گردآوری شد. این گردآوری با هدف ارائه تصویری جامع و نظام‌یافته از نحوه بهره‌گیری از گراف‌های مکانی-زمانی در مسائل

۳ Cholesky decomposition

۱ Kriging

۲ Ordinary Kriging

پیش‌بینی و درون‌یابی انجام شده است؛ تصویری که می‌تواند به عنوان مرجعی سودمند، مسیر طراحی مدل‌های نوآورانه را برای پژوهشگران آینده هموار ساخته و از تکرار پژوهش‌های پیشین جلوگیری کند. همچنین، بر این باوریم که مسیرهای تحقیقاتی گسترده‌تری در این حوزه قابل کاوش است، از جمله این کاربردها می‌توان به پیش‌بینی تغییرات بلندمدت نشست زمین با استفاده از داده‌های لرزه‌نگاری و ماهواره‌ای، تحلیل نرخ و مسیر پراکندگی آلودگی‌های محیطی با در نظر گرفتن شرایط جوی و موقعیت منابع آلاینده، و پیش‌بینی جریان ترافیک هوایی یا زمینی با استفاده از اطلاعات بلادرنگ مسیرها و گره‌های حمل‌ونقلی اشاره کرد. همچنین، این مدل‌ها می‌توانند در بهینه‌سازی عملکرد سامانه‌های اخذ عوارض الکترونیکی، تحلیل دسترسی‌پذیری مسیرها در شبکه‌های حمل‌ونقل شهری و کنترل هوشمند چراغ‌های راهنمایی برای کاهش ازدحام کاربرد داشته باشند. افزون بر این، استفاده از

ساختار گراف در مدل‌سازی زنجیره تأمین و لجستیک شهری، با در نظر گرفتن وابستگی‌های مکانی و زمانی میان مراکز توزیع و مسیرهای حمل‌ونقل، می‌تواند منجر به طراحی سامانه‌هایی کارا تر گردد. در حوزه اقتصاد نیز، مدل‌سازی وابستگی‌های مکانی-زمانی میان شاخص‌های مالی و نهادهای اقتصادی می‌تواند امکان پیش‌بینی روندهای بازار را فراهم سازد. از سوی دیگر، تحلیل تعاملات کاربران در شبکه‌های اجتماعی برای شناسایی روندها، مسیرهای انتشار اطلاعات و گروه‌های تأثیرگذار و نیز پیش‌بینی الگوهای مصرف منابع شهری نظیر آب، برق و اینترنت با تکیه بر ساختار گراف شهر، از دیگر چشم‌اندازهای پژوهشی این حوزه به شمار می‌روند. این موارد تنها بخشی از ظرفیت‌های گسترده شبکه‌های عصبی گرافی مکانی-زمانی را نشان می‌دهند و توسعه پژوهش‌های نوآورانه در این زمینه می‌تواند مسیرهای جدیدی را در حل مسائل میان‌رشته‌ای و داده‌محور بگشاید.

داده‌ها

داده‌های مورد استفاده در این تحقیق از لینک زیر قابل دریافت است:

<https://github.com/m-t-abbasi/The-application-of-graph-neural-networks-in-geospatial-information-systems>

مراجع

- [۱] B. Evangelidis, "Space and time as relations: the theoretical approach of Leibniz," *Philosophies*, vol. 3, no. 2, p. 9, 2018.
- [۲] S. Yanchuk and G. Giacomelli, "Spatio-temporal phenomena in complex systems with time delays," *J. Phys. A Math. Theor.*, vol. 50, no. 10, p. 103001, 2017.
- [۳] M. Batty, "Network geography: Relations, interactions, scaling and spatial processes in GIS," *Re-presenting GIS*, pp. 149–170, 2005.
- [۴] G. Del Mondo, P. Peng, J. Gensel, C. Claramunt, and F. Lu, "Leveraging spatio-temporal graphs and knowledge graphs: Perspectives in the field of maritime transportation," *ISPRS Int. J. Geo-Information*, vol. 10, no. 8, p. 541, 2021.
- [۵] A. Sagheer and M. Kotb, "Time series forecasting of petroleum production using deep LSTM recurrent networks," *Neurocomputing*, vol. 323, pp. 203–213, 2019.
- [۶] M. T. Abbasi, A. A. Alesheikh, A. Jafari, and A. Lotfata, "Spatial and temporal patterns of urban air pollution in tehran with a focus on PM2. 5 and associated pollutants," *Sci. Rep.*, vol. 14, no. 1, p. 25150, 2024.
- [۷] H. Cheng and H. Fan, "PM2. 5 Concentration Hourly Multi-Step Prediction Using Spatial-Temporal Synchronous Graph Convolution Network," in *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2024, pp. 5727–5731.
- [۸] G. Yao, T. Lei, and J. Zhong, "A review of convolutional-neural-network-based action recognition," *Pattern Recognit. Lett.*, vol. 118, pp. 14–22, 2019.

- [۹] Y. Jia, J. Wang, W. Shou, M. R. Hosseini, and Y. Bai, "Graph neural networks for construction applications," *Autom. Constr.*, vol. 154, p. 104984, 2023.
- [۱۰] T. Cheng, T. Bi, W. Ji, and C. Tian, "Graph Convolutional Network for Image Restoration: A Survey," *Mathematics*, vol. 12, no. 13, p. 2020, 2024.
- [۱۱] L. Stanković and E. Sejdić, *Vertex-frequency analysis of graph signals*. Springer, 2019.
- [۱۲] A. Sandryhaila and J. M. F. Moura, "Discrete signal processing on graphs," *IEEE Trans. signal Process.*, vol. 61, no. 7, pp. 1644–1656, 2013.
- [۱۳] E. Isufi, F. Gama, D. I. Shuman, and S. Segarra, "Graph filters for signal processing and machine learning on graphs," *IEEE Trans. Signal Process.*, 2024.
- [۱۴] H. S. O. Migdadi, R. A. Abd-Alhameed, H. A. Obeidat, J. M. Noras, E. A. A. Qaralleh, and M. J. Ngala, "FIR implementation on FPGA: Investigate the FIR order on SDA and PDA algorithms," in *2015 Internet Technologies and Applications (ITA)*, IEEE, 2015, pp. 417–421.
- [۱۵] I. Goodfellow, *Deep Learning*. MIT Press, 2016.
- [۱۶] P. Maragos and R. Schafer, "Morphological filters--Part I: Their set-theoretic analysis and relations to linear shift-invariant filters," *IEEE Trans. Acoust.*, vol. 35, no. 8, pp. 1153–1169, 1987.
- [۱۷] S. Abut, H. Okut, and K. J. Kallail, "Paradigm shift from Artificial Neural Networks (ANNs) to deep Convolutional Neural Networks (DCNNs) in the field of medical image processing," *Expert Syst. Appl.*, p. 122983, 2023.
- [۱۸] B. P. Lathi and R. A. Green, *Linear systems and signals*, vol. 2. Oxford University Press New York, 2005.
- [۱۹] A. V Oppenheim, *Discrete-time signal processing*. Pearson Education India, 1999.
- [۲۰] S. O. Ayat, M. Khalil-Hani, A. A.-H. Ab Rahman, and H. Abdellatef, "Spectral-based convolutional neural network without multiple spatial-frequency domain switchings," *Neurocomputing*, vol. 364, pp. 152–167, 2019.
- [۲۱] M. Mathieu, M. Henaff, and Y. LeCun, "Fast training of convolutional networks through ffts," *arXiv Prepr. arXiv1312.5851*, 2013.
- [۲۲] Y. Wang, "Fractional fourier transform and its application," *Theor. Nat. Sci.*, vol. 42, pp. 8–12, 2024.
- [۲۳] S. Zhang, H. Tong, J. Xu, and R. Maciejewski, "Graph convolutional networks: a comprehensive review," *Comput. Soc. Networks*, vol. 6, no. 1, pp. 1–23, 2019.
- [۲۴] L. Gong, Z. Zhou, P. Tong, and S. Zhao, "Statistical properties of one-dimensional binary sequences with power-law power spectrum," *Phys. A Stat. Mech. its Appl.*, vol. 390, no. 17, pp. 2977–2986, 2011.
- [۲۵] T. Highlander and A. Rodriguez, "Very efficient training of convolutional neural networks using fast fourier transform and overlap-and-add," *arXiv Prepr. arXiv1601.06815*, 2016.
- [۲۶] F. R. K. Chung, *Spectral graph theory*, vol. 92. American Mathematical Soc., 1997.
- [۲۷] A. Ortega, P. Frossard, J. Kovačević, J. M. F. Moura, and P. Vandergheynst, "Graph signal processing: Overview, challenges, and applications," *Proc. IEEE*, vol. 106, no. 5, pp. 808–828, 2018.
- [۲۸] D. I. Shuman, S. K. Narang, P. Frossard, A. Ortega, and P. Vandergheynst, "The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains," *IEEE Signal Process. Mag.*, vol. 30, no. 3, pp. 83–98, 2013.
- [۲۹] R. B. Joshi and S. Mishra, "Learning graph representations," in *Principles of Social Networking: The New Horizon and Emerging Challenges*, Springer, 2021, pp. 209–228.
- [۳۰] W. L. Hamilton, R. Ying, and J. Leskovec, "Representation learning on graphs: Methods and applications," *arXiv Prepr. arXiv1709.05584*, 2017.
- [۳۱] M. Zitnik, M. Agrawal, and J. Leskovec, "Modeling polypharmacy side effects with graph convolutional networks," *Bioinformatics*, vol. 34, no. 13, pp. i457–i466, 2018.

- [۳۲] N. A. Asif *et al.*, “Graph neural network: A comprehensive review on non-euclidean space,” *Ieee Access*, vol. 9, pp. 60588–60606, 2021.
- [۳۳] M. Niepert, M. Ahmed, and K. Kutzkov, “Learning convolutional neural networks for graphs,” in *International conference on machine learning*, PMLR, 2016, pp. 2014–2023.
- [۳۴] J. Yan, H. Li, F. Xu, X. Zhou, Y. Liu, and Y. Yang, “Speech Emotion Recognition Based on Temporal-Spatial Learnable Graph Convolutional Neural Network,” *Electronics*, vol. 13, no. 11, p. 2010, 2024.
- [۳۵] J. Zhou *et al.*, “Graph neural networks: A review of methods and applications,” *AI open*, vol. 1, pp. 57–81, 2020.
- [۳۶] J. Tang *et al.*, “Applications of temporal graph metrics to real-world networks,” *Temporal Networks*, pp. 135–159, 2013.
- [۳۷] Y. Wang *et al.*, “Graph pooling in graph neural networks: Methods and their applications in omics studies,” *Artif. Intell. Rev.*, vol. 57, no. 11, p. 294, 2024.
- [۳۸] Y. Qi, Q. Li, H. Karimian, and D. Liu, “A hybrid model for spatiotemporal forecasting of PM2. 5 based on graph convolutional neural network and long short-term memory,” *Sci. Total Environ.*, vol. 664, pp. 1–10, 2019.
- [۳۹] L. Ge, S. Li, Y. Wang, F. Chang, and K. Wu, “Global spatial-temporal graph convolutional network for urban traffic speed prediction,” *Appl. Sci.*, vol. 10, no. 4, p. 1509, 2020.
- [۴۰] Y. Fang *et al.*, “Cdgnet: A cross-time dynamic graph-based deep learning model for traffic forecasting,” *arXiv Prepr. arXiv2112.02736*, 2021.
- [۴۱] J. Zhu, Q. Wang, C. Tao, H. Deng, L. Zhao, and H. Li, “AST-GCN: Attribute-augmented spatiotemporal graph convolutional network for traffic forecasting,” *Ieee Access*, vol. 9, pp. 35973–35983, 2021.
- [۴۲] Y. Wang, “Advances in spatiotemporal graph neural network prediction research,” *Int. J. Digit. Earth*, vol. 16, no. 1, pp. 2034–2066, 2023.
- [۴۳] Y. Li, R. Yu, C. Shahabi, and Y. Liu, “Diffusion convolutional recurrent neural network: Data-driven traffic forecasting,” *arXiv Prepr. arXiv1707.01926*, 2017.
- [۴۴] X. Liu, M. Qin, Y. He, X. Mi, and C. Yu, “A new multi-data-driven spatiotemporal PM2. 5 forecasting model based on an ensemble graph reinforcement learning convolutional network,” *Atmos. Pollut. Res.*, vol. 12, no. 10, p. 101197, 2021.
- [۴۵] S. Guo, Y. Lin, H. Wan, X. Li, and G. Cong, “Learning dynamics and heterogeneity of spatial-temporal graph data for traffic forecasting,” *IEEE Trans. Knowl. Data Eng.*, vol. 34, no. 11, pp. 5415–5428, 2021.
- [۴۶] Y. Zhang and T. Cheng, “Graph deep learning model for network-based predictive hotspot mapping of sparse spatio-temporal events,” *Comput. Environ. Urban Syst.*, vol. 79, p. 101403, 2020.
- [۴۷] J. Sun *et al.*, “Crimeforecaster: Crime prediction by exploiting the geographical neighborhoods’ spatiotemporal dependencies,” in *Machine Learning and Knowledge Discovery in Databases. Applied Data Science and Demo Track: European Conference, ECML PKDD 2020, Ghent, Belgium, September 14–18, 2020, Proceedings, Part V*, Springer, 2021, pp. 52–67.
- [۴۸] C. Wang, Z. Lin, X. Yang, J. Sun, M. Yue, and C. Shahabi, “Hagen: Homophily-aware graph convolutional recurrent network for crime forecasting,” in *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, pp. 4193–4200.
- [۴۹] S. Zhao, R. Liu, B. Cheng, and D. Zhao, “Classification-labeled continuousization and multi-domain spatio-temporal fusion for fine-grained urban crime prediction,” *IEEE Trans. Knowl. Data Eng.*, vol. 35, no. 7, pp. 6725–6738, 2022.
- [۵۰] J. Gao *et al.*, “STAN: spatio-temporal attention network for pandemic prediction using real-world evidence,” *J. Am. Med. Informatics Assoc.*, vol. 28, no. 4, pp. 733–743, 2021.
- [۵۱] A. Kapoor *et al.*, “Examining covid-19 forecasting using spatio-temporal graph neural networks,” *arXiv Prepr. arXiv2007.03113*, 2020.
- [۵۲] J. Shu, X. Zhang, Y. Yao, D. Yi, and B. Gu, “Graph spatio-temporal attention network-based electricity demand forecasting,” in *2021 6th International Conference on Power and Renewable Energy (ICPRE)*, IEEE, 2021, pp. 792–

- 797.
- [۵۳] F. B. Hüttel, I. Peled, F. Rodrigues, and F. C. Pereira, "Deep spatio-temporal forecasting of electrical vehicle charging demand," *arXiv Prepr. arXiv2106.10940*, 2021.
 - [۵۴] A. Salamat, X. Luo, and A. Jafari, "HeteroGraphRec: A heterogeneous graph-based neural networks for social recommendations," *Knowledge-Based Syst.*, vol. 217, p. 106817, 2021.
 - [۵۵] S. Dai, Y. Yu, H. Fan, and J. Dong, "Personalized poi recommendation: spatio-temporal representation learning with social tie," in *Database Systems for Advanced Applications: 26th International Conference, DASFAA 2021, Taipei, Taiwan, April 11–14, 2021, Proceedings, Part I 26*, Springer, 2021, pp. 558–574.
 - [۵۶] F. Yuan, Y. Xu, Q. Li, and A. Mostafavi, "Spatio-temporal graph convolutional networks for road network inundation status prediction during urban flooding," *Comput. Environ. Urban Syst.*, vol. 97, p. 101870, 2022.
 - [۵۷] M. Sit, B. Demiray, and I. Demir, "Short-term hourly streamflow prediction with graph convolutional gru networks," *arXiv Prepr. arXiv2107.07039*, 2021.
 - [۵۸] W. Liao, B. Zeng, J. Liu, P. Wei, and X. Cheng, "Taxi demand forecasting based on the temporal multimodal information fusion graph neural network," *Appl. Intell.*, vol. 52, no. 10, pp. 12077–12090, 2022.
 - [۵۹] H. Junninen, H. Niska, K. Tuppurainen, J. Ruuskanen, and M. Kolehmainen, "Methods for imputation of missing values in air quality data sets," *Atmos. Environ.*, vol. 38, no. 18, pp. 2895–2907, 2004.
 - [۶۰] C.-H. Lin and T.-H. Wen, "How spatial epidemiology helps understand infectious human disease transmission," *Trop. Med. Infect. Dis.*, vol. 7, no. 8, p. 164, 2022.
 - [۶۱] R. E. Thomson and W. J. Emery, *Data analysis methods in physical oceanography*. Elsevier, 2024.
 - [۶۲] R. P. Sishodia, R. L. Ray, and S. K. Singh, "Applications of remote sensing in precision agriculture: A review," *Remote Sens.*, vol. 12, no. 19, p. 3136, 2020.
 - [۶۳] C. Berndt and U. Haberlandt, "Spatial interpolation of climate variables in Northern Germany—Influence of temporal resolution and network density," *J. Hydrol. Reg. Stud.*, vol. 15, pp. 184–202, 2018.
 - [۶۴] A. H. Thiessen, "Precipitation averages for large areas," *Mon. Weather Rev.*, vol. 39, no. 7, pp. 1082–1089, 1911.
 - [۶۵] D. Shepard, "A two-dimensional interpolation function for irregularly-spaced data," in *Proceedings of the 1968 23rd ACM national conference*, 1968, pp. 517–524.
 - [۶۶] J. Stoer, R. Bulirsch, R. Bartels, W. Gautschi, and C. Witzgall, *Introduction to numerical analysis*, vol. 1993. Springer, 1980.
 - [۶۷] D. Coppersmith and S. Winograd, "Matrix multiplication via arithmetic progressions," in *Proceedings of the nineteenth annual ACM symposium on Theory of computing*, 1987, pp. 1–6.
 - [۶۸] M. A. Njifon and D. Schuhmacher, "Graph convolutional networks for spatial interpolation of correlated data," *Spat. Stat.*, vol. 60, p. 100822, 2024.
 - [۶۹] J. Li, Y. Shen, L. Chen, and C. W. W. Ng, "Rainfall spatial interpolation with graph neural networks," in *International conference on database systems for advanced applications*, Springer, 2023, pp. 175–191.
 - [۷۰] S. Yao and B. Huang, "Spatiotemporal interpolation using graph neural network," *Ann. Am. Assoc. Geogr.*, vol. 113, no. 8, pp. 1856–1877, 2023.
 - [۷۱] M. Tang, P. Agrawal, F. Nie, S. Pongpaichet, and R. Jain, "A graph based multimodal geospatial interpolation framework," in *2016 IEEE International Conference on Multimedia and Expo (ICME)*, IEEE, 2016, pp. 1–6.
 - [۷۲] W. Zhu *et al.*, "A dual branch graph neural network based spatial interpolation method for traffic data inference in unobserved locations," *Inf. Fusion*, vol. 114, p. 102703, 2025.