

# تحلیل مکانی-زمانی دمای سطح زمین با استفاده از روش انتخاب مبتنی بر ژنتیک (مطالعه موردی: شهر تهران)

عامر کریمی<sup>۱</sup>، یاسر ابراهیمیان قاجاری<sup>۲\*</sup>

<sup>۱</sup> کارشناس ارشد سیستم‌های اطلاعات مکانی - دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران  
amer.karimi@ut.ac.ir

<sup>۲</sup> استادیار دانشکده مهندسی عمران - دانشگاه صنعتی نوشیروانی بابل  
y.ebrahimian@nit.ac.ir

(تاریخ دریافت تیر ۱۴۰۰، تاریخ تصویب مهر ۱۴۰۰)

## چکیده

امروزه درجه حرارت شهرها به طور قابل ملاحظه‌ای نسبت به حومه شهر بالاتر است که این پدیده ناشی از افزایش دمای سطح زمین و در نتیجه آن ایجاد جزایر گرمایی شهری می‌باشد. از این رو با توجه به توسعه شهرنشینی و تغییر در محیط حرارتی شهری، شناسایی عوامل موثر بر دمای سطح زمین در مناطق شهری با توجه به شرایط مکانی و زمانی آن از اهمیت بالایی برخوردار است و در نتیجه می‌توان در جهت پیشگیری هرچه بیشتر این پدیده با استفاده از آموزش عمومی، وضع قوانین و سیاست‌های مدیریتی کارآمد و نظارت بیشتر جهت مقابله با عوامل محرک افزایش دمای سطح زمین برآییم. هدف از این پژوهش شناسایی عوامل مکانی موثر بر دمای سطح زمین مناطق شهری در طول یک زمان مشخص و پیش‌بینی آن بر اساس عوامل موثر تعیین شده در الگوریتم پیشنهادی است. در این پژوهش یک روش انتخاب برای شناسایی عوامل مؤثر در پیش‌بینی دمای سطح زمین (LST) مناطق شهری از طریق ترکیب الگوریتم ژنتیک و رگرسیون وزن‌دار جغرافیایی زمان‌مند ارائه گردید. جهت ارزیابی روش پیشنهادی، از ۹ لایه اطلاعاتی مختلف از جمله ارتفاع ساختمان‌ها، تراکم ساخت‌وساز، کاربری اراضی، فاصله از راه‌ها، تراکم جمعیت، آلودگی هوا، شیب، جهت و ارتفاع زمین به عنوان عوامل مکانی-زمانی برای پیش‌بینی نقشه LST در شهر تهران در مدت ۵ سال استفاده شد. نتایج پژوهش نشانگر این است که نتایج پیش‌بینی با استفاده از عوامل موثر انتخابی در روش پیشنهادی، دقیق‌تر از همان نتایج با استفاده از تمام لایه‌های اطلاعاتی است. بر همین اساس نتایج تجربی این پژوهش عملکرد مناسب روش پیشنهادی در پیش‌بینی LST را نشان می‌دهد.

**واژگان کلیدی:** دمای سطح زمین، LST، جزایر گرمایی شهری، تحلیل مکانی-زمانی، GTWR، الگوریتم ژنتیک

\* نویسنده رابط

## ۱- مقدمه

گسترش سریع شهرنشینی و رشد جمعیت، تغییر خواص فیزیکی سطح زمین شهری، باعث تنوع قابل توجهی در محیط‌های حرارتی شهری شده است [۱]. یکی از آشناترین اثرات آب و هوایی محلی، پدیده‌ای به نام جزایر گرمایی شهری (UHI)<sup>۱</sup> است، که در آن دمای سطح زمین در مناطق شهری چند درجه بالاتر از مناطق غیرشهری اطراف می‌باشد [۲]. خواص فیزیکی مانند انواع مختلف سطوح شهری، رنگ سطوح، عامل دید به آسمان<sup>۲</sup>، هندسه خیابان‌ها، فشار ترافیکی و فعالیت‌های انسانی از عوامل مهم در تعیین دمای سطح زمین در محیط شهری می‌باشد [۳-۸]. تاکنون در پژوهش‌های متعددی از سنجش از دور و سیستم‌های اطلاعات مکانی برای تشخیص ویژگی‌های حرارتی سطوح شهری استفاده شده است؛ اما در اکثر این پژوهش‌ها تنها بر شاخص‌هایی که از تصاویر ماهواره‌ای قابل تفکیک و استخراج بوده‌اند مانند پوشش گیاهی، سطوح غیرقابل نفوذ و سطوح آبی تمرکز شده است و از سایر عوامل و لایه‌های مکانی تأثیرگذار مانند ارتفاع ساختمان‌ها، تراکم ساخت‌وساز، انواع کاربری اراضی، فاصله از راه‌ها و تراکم جمعیت با سطح تفکیکی به‌طور همزمان استفاده نشده است [۹].

لی و همکاران در سال ۲۰۱۰ [۴] به بررسی عوامل مکانی ساکن و مؤثر در دمای سطح زمین در شهر سنژن چین پرداختند. در این پژوهش چند نوع کاربری اراضی شامل زمین کشاورزی، مناطق ساخته‌شده، جنگل، باتلاق، زمین بایر و چمن‌زار و همچنین ارتفاع زمین و فاصله از راه‌ها به عنوان عوامل مؤثر موردبررسی قرار گرفتند. در پژوهش مذکور برای تولید داده‌های دمای سطح زمین از تصاویر ماهواره‌ای لندست ۵ و ۷ استفاده شد. در سال ۲۰۲۰ کیاوو و همکاران تغییرات نوسازی شهری را در ۱۰ سال متوالی بین سال‌های ۲۰۰۷ تا ۲۰۱۷ برای ۴ شهر مختلف مورد مطالعه قرار دادند که در هر ۴ شهر مکان‌های نوسازی‌شده با کاهش دمای نسبی همراه بودند [۸]. پنگ و همکاران نیز در سال ۲۰۱۷ به بررسی عوامل مؤثر بر دمای سطح زمین در منطقه سیچوان چین پرداختند [۱۰]. در پژوهش آن‌ها عوامل ارتفاع، شیب،

جهت شیب، مناطق ساخته‌شده و کاربری اراضی شامل جنگل، چمن‌زار، باتلاق و زمین بایر موردبررسی قرار گرفت. نتایج حاکی از این بود که ارتفاع زمین و انواع کاربری به‌طور معنی‌داری با LST رابطه دارند و شیب و جهت شیب به عنوان عوامل کم اهمیت‌تر معرفی شد.

در میان پژوهش‌های موجود در این حوزه، پژوهش‌هایی نیز در مورد روابط کمی بین الگوهای مکانی UHI و عوامل اقتصادی، اجتماعی و فیزیکی در جهت کاهش اثرات حرارتی مضر ناشی از توسعه شهری نیز صورت گرفت [۱۱]. در همین راستا هوانگ و همکاران در سال ۲۰۱۱ به بررسی رابطه‌ی الگوهای مکانی دمای سطح زمین و عوامل اجتماعی و اقتصادی در شهر بالتیمور ایالت مریلند در کشور آمریکا پرداختند که نتیجه‌ی آن بالاتر بودن دمای سطح زمین در مناطق فقیرنشین، کم‌سواد و قومی بود. دلیل این افزایش، بالا بودن درصد سطوح غیرقابل نفوذ، فقر پوشش گیاهی و جمعیت زیاد بیان شد [۱۲]. رونالد و همکاران در سال ۲۰۱۷ به بررسی و مقایسه اثرات سطوح غیرقابل نفوذ و پوشش گیاهی بر دمای سطح زمین در مناطق شهری با استفاده از تصاویر لندست-۸ پرداختند که نتیجه آن افزایش دمای ۳ درجه سانتی‌گراد در مناطق غیرقابل نفوذ بود [۱۳]. همچنین چن و همکاران در سال ۲۰۱۷ اقدام به بررسی اثرات انواع پوشش زمین بر تغییرات روزانه‌ی درجه‌ی حرارت شهری با استفاده از تصاویر حرارتی مودیس<sup>۳</sup> و تصاویر چندطیفی اسپات<sup>۴</sup> نمودند [۱۴]. کیاوو و همکاران نیز با استفاده از تصاویر لندست-۵ کاربری اراضی، تراکم ساخت و راه‌ها و همچنین با استفاده از تصاویر پانکروماتیک اسپات ارتفاع ساختمان‌های شهر پکن را استخراج کردند و این عوامل را با استفاده از مدل رگرسیون خطی چندگانه<sup>۵</sup> در دمای سطح زمین مورد بررسی قرار دادند. نتایج این پژوهش نشان داد که جنگل‌ها، زمین‌های کشاورزی و مناطق آبی در بین کاربری اراضی کم‌ترین دما را داشتند و در مقابل مناطق ساخته‌شده با تراکم بالا از بیشترین دمای سطح زمین برخوردار بودند [۱۵]. در پژوهش‌های [۱۶] و [۱۷] از شاخص‌های پوشش گیاهی از جمله شاخص نرمال‌شده-

<sup>۳</sup> MODIS

<sup>۴</sup> SPOT

<sup>۵</sup> Multiple Linear Regression

<sup>۱</sup> Urban Heat Island

<sup>۲</sup> Sky view factor

را برای متغیر نهایی ارائه دهد. علاوه بر این، حالت تصادفی بودن مکانی باقی مانده های مدل GWR مطلوب تر از باقی مانده های بدست آمده از مدل های دیگر است [۲۲].

هدف از این پژوهش، پیش بینی دمای سطح زمین در مناطق شهری بر اساس تعیین عوامل مؤثر بر آن در یک زمان مشخص است. برای تحقق این هدف، از رگرسیون وزن دار جغرافیایی زمان مند (GTWR) با هسته مکعبی سه گانه در ترکیب با الگوریتم ژنتیک استفاده شده است. علاوه بر آن در مطالعه ی حاضر، از داده های لندست ۸ برای بازیابی دمای سطح زمین شهر تهران استفاده شده که اخیراً تصاویر این ماهواره در بسیاری از تحقیقات برای محاسبه دمای سطح زمین و ارتباط آن با عوامل مختلف استفاده گردیده است [۲۳-۲۵]. تأثیر عوامل مکانی مختلفی در دمای سطح زمین مورد بررسی قرار گرفته است که یافتن ترکیبی از این عوامل با بیشترین تأثیر بر دمای سطح زمین از چالش های پیش روی این پژوهش است. برای حل این چالش نیز از الگوریتم ژنتیک استفاده شد. همان گونه که از پژوهش های پیشین بر می آید، در بررسی دمای سطح زمین، تأکید بیشتر بر به کارگیری و بررسی عوامل سطحی بوده است و نه عوامل اتمسفریک [۲۶، ۲۷]. در این مطالعه نیز با توجه به محدودیت های داده ای موجود، از ۹ عامل مکانی وابسته به سطح زمین شامل کاربری اراضی، فاصله از جاده ها، تراکم جمعیت، تراکم ساخت و ساز، آلودگی هوا، جهت شیب، مقدار شیب، ارتفاع ساختمان و ارتفاع سطح زمین مورد بررسی قرار گرفت.

در ادامه در بخش دوم به معرفی منطقه ی مورد مطالعه، داده های مورد استفاده، تابع تقریب GTWR و الگوریتم ژنتیک مورد استفاده جهت یافتن بهترین ترکیب عوامل پرداخته خواهد شد. در بخش سوم نتایج به دست آمده ارائه و پیرامون آن ها بحث شده است و در نهایت، در بخش چهارم به نتیجه گیری از این پژوهش می پردازیم.

## ۲- مواد و روش ها

### ۲-۱- منطقه مورد مطالعه

شهر تهران پایتخت جمهوری اسلامی ایران در طول جغرافیایی ۵۱ درجه و ۶ دقیقه شرقی تا ۵۱ درجه و ۳۸ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۳۴ دقیقه شمالی تا ۳۵ درجه و ۵۱ دقیقه شمالی قرار دارد. گستره ی

ی پوشش گیاهی (NDVI)<sup>۱</sup>، شاخص نرمال شده ی آب (NDWI)<sup>۲</sup> و شاخص نرمال شده ی سازه (NDBI)<sup>۳</sup> برای ایجاد ارتباط بین دمای سطح شهری و کاربری و پوشش اراضی (LULC)<sup>۴</sup> استفاده کردند. پژوهش دیگری در شهر بالتیمور توسط ژوو و همکاران در سال ۲۰۱۱ انجام شد که در آن با استفاده از تحلیل های همبستگی و رگرسیون خطی چندگانه به بررسی تأثیر پوشش اراضی در دمای سطح زمین شهر بالتیمور ایالات متحده پرداختند. در نتایج این مطالعه به مثبت بودن ضرایب رگرسیون مربوط به درصد پوشش ساختمان ها و پیاده روها در LST به معنی تأثیر مثبت در افزایش دمای سطح زمین و منفی بودن ضرایب پوشش گیاهی و آبی به معنی تأثیر کاهنده در دمای سطح زمین اشاره گردید [۱۸].

در بررسی روابط بین متغیرهای مستقل و وابسته اگرچه روابط رگرسیون چند متغیره جهانی جواب های نسبتاً قابل قبولی دارد، اما جوابگوی مسائل مکانی نیست. در حقیقت، الگوها و فرآیندهای مکانی و زیست محیطی در طبیعت، بر خلاف قوانین فیزیکی جهانی، تمایل به داشتن متغیر مکانی دارند [۱۹]. به عبارت دیگر، حتی اگر فرآیندهای طبیعی یک فرآیند جهانی و کلی باشند، الگوهای مکانی واقعی با موقعیت های محلی، متفاوت خواهند بود و رگرسیون جهانی پاسخگوی آنها نیست [۲۰]. تحلیل رگرسیون های معمولی مانند مدل حداقل مربعات معمولی<sup>۵</sup> (OLS) بر پایه ی فرض مشاهدات مستقل است؛ در نتیجه زمانی که به داده های زمین مرجع اعمال می شوند به علت حضور داده های مکانی وابسته با شکست مواجه می شوند [۴]. برای غلبه بر این محدودیت، برانسدون و همکاران یک روش رگرسیون محلی به نام رگرسیون وزن دار جغرافیایی (GWR)<sup>۶</sup> را پیشنهاد کردند [۲۱]. در مقایسه با برخی از مدل های آماری جدید مانند مدل مختلط خطی، مدل تجمعی تعمیم یافته، شبکه عصبی پرسپترون چندلایه و شبکه عصبی تابع پایه شعاعی، مدل GWR می تواند ضرایب رگرسیون را در هر موقعیت مکانی برآورد کند و عملکرد پیش گوینه ی بهتری

<sup>۱</sup> Normalized Difference Vegetation Index

<sup>۲</sup> Normalized Difference Water Index


<sup>۳</sup> Normalized Difference Build-up Index

<sup>۴</sup> Land Use and Land Cover

<sup>۵</sup> ordinary least squares

<sup>۶</sup> Geographically Weighted Regression

این شهر از دامنه جنوبی رشته کوه‌های البرز تا حاشیه شمالی کویر مرکزی ایران است. با حرکت از جنوب به شمال این شهر، ارتفاع افزایش می‌یابد؛ به گونه‌ای که ارتفاع جنوب این شهر ۱۰۵۰ متر و ارتفاع مرکز آن ۱۲۰۰ متر و ارتفاع شمال شهر ۱۸۰۰ متر از سطح آب‌های آزاد می‌باشد. تهران بزرگ‌ترین و پرجمعیت‌ترین شهر ایران با حدود ۱۱ میلیون جمعیت و بیست و پنجمین شهر پرجمعیت جهان با مساحتی حدود ۷۳۰ کیلومتر مربع می‌باشد. رشد جمعیت موجب گسترش شهرسازی و تغییر در ویژگی‌های فیزیکی سطح زمین شده است و این شهر را تبدیل به یک مرکز کلیدی صنعتی، تجاری و مسکونی کرده است. توسعه شهری بی‌رویه و فقدان برنامه‌ریزی مناسب تأثیرات زیادی روی محیط حرارتی این شهر گذاشته است. شکل ۱ موقعیت منطقه مورد مطالعه را نشان می‌دهد.



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه (شهر تهران)


## ۲-۲- داده‌ها

بخشی از داده‌های مورد نیاز این تحقیق با استفاده از تصاویر ماهواره‌ای لندست-۸ و در پنج سال مختلف در ماه آگوست سال‌های ۲۰۱۳ تا ۲۰۱۷ جهت بازیابی دمای سطح زمین شهر تهران با استفاده از روش پنجره مجزا<sup>۱</sup> [۲۹، ۲۸] تولید شد که از داده‌های سال ۲۰۱۳ تا ۲۰۱۶ در فرآیند مدل‌سازی پیش‌بینی دمای سطح زمین و از داده‌ی سال ۲۰۱۷ برای صحت‌سنجی پیش‌بینی استفاده شد. تاریخ‌های انتخابی به دلیل موجود بودن تصاویر و نزدیک بودن زمان آنها در ۵ سال پیاپی جهت مقایسه‌ی بهتر با هم و همچنین قرار داشتن در اواسط تابستان و برجسته بودن خاصیت گرمایی تصاویر و البته نداشتن لکه‌های ابر در آنها مورد بررسی قرار گرفتند. داده‌های دیگر از قبیل مدل رقومی ارتفاعی<sup>۲</sup> (DEM) منطقه، جهت شیب، مقدار شیب، شبکه

راه‌ها و جاده‌ها، کاربری اراضی، تراکم جمعیت، تراکم ساخت‌وساز، ارتفاع ساختمان‌ها و آلودگی هوای مربوط به شهر تهران در سال ۲۰۱۵ با فرمت برداری در دسترس بودند که در بخش‌هایی که نیاز بود این داده‌ها در نرم افزار آرک جی‌آی‌اس<sup>۳</sup> به فرمت رستری تبدیل گردیدند. در مورد لایه‌های تولید شده و نحوه‌ی تولید آنها در بخش پیاده‌سازی توضیحاتی ارائه شده است.

در این پژوهش به بررسی وابستگی بین دمای سطح زمین شهر تهران و ۹ عامل مختلف ارائه شده در مقدمه پرداخته شد. این ۹ عامل با توجه به مطالعات و تحقیقات صورت گرفته در گذشته و محدودیت‌های موجود در دسترسی به داده‌ها انتخاب شده‌اند. دمای سطح زمین شهر تهران از تصاویر ماهواره‌ای لندست-۸ بدست آمد و از مختصات نقاط نیز برای محاسبه وزن جغرافیایی نقاط انتخابی در الگوریتم استفاده شد.

جهت پیاده‌سازی نیاز به تولید نقاط پراکنده در سطح تهران است. از این رو ۱۵۰۰ نقطه به صورت تصادفی در منطقه مورد مطالعه با توزیع تصادفی یکنواخت تولید شد (شکل ۲). سپس، مقادیر همه لایه‌های اطلاعاتی موجود در آنها محاسبه گردید.



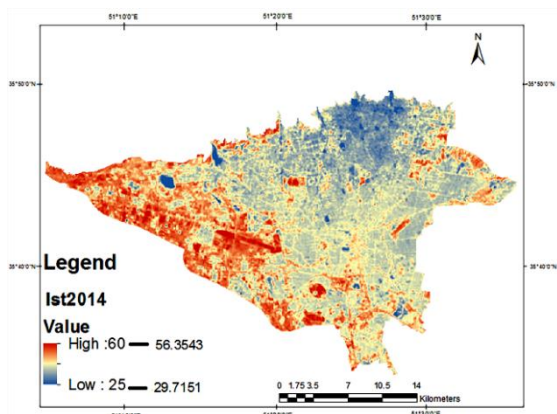
شکل ۲- پراکندگی ۱۵۰۰ نقطه تصادفی در منطقه مورد مطالعه

لایه‌ی آلودگی هوا بر اساس شاخص کیفیت هوای تهران با درون‌یابی کریجینگ و ایستگاه‌های کنترل کیفیت هوا در سال‌های مختلف تولید شد که به‌عنوان نمونه، نقشه تولیدی آلودگی هوا در ۲۵ آگوست ۲۰۱۷ در شکل ۹ نشان داده شد. لایه‌های اطلاعاتی کاربری اراضی، تراکم جمعیت، تراکم ساخت‌وساز، ارتفاع ساختمان‌ها و شبکه‌ی راه‌ها در مقیاس ۱:۲۰۰۰ تهیه شده‌اند که لایه کاربری

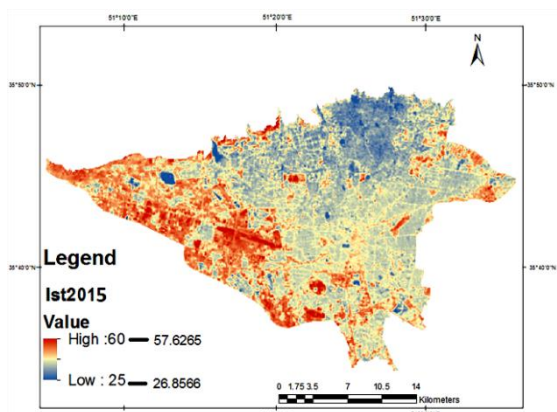
<sup>۳</sup> ArcGIS Software

<sup>۱</sup> Split-window

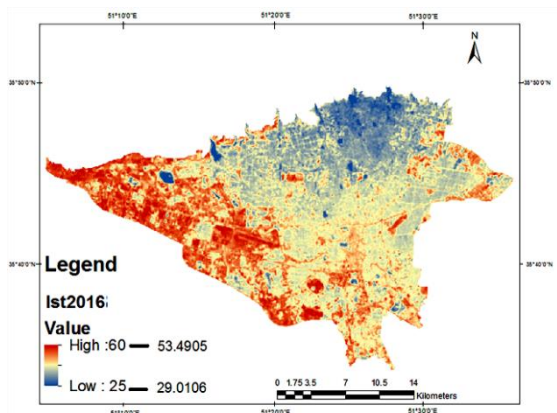
<sup>۲</sup> Digital Elevation Model



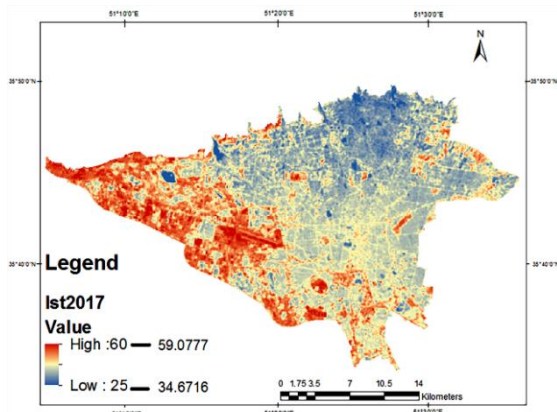
شکل ۴- نقشه LST ۱۸ آگوست ۲۰۱۴ منطقه مورد مطالعه



شکل ۵- نقشه LST ۲۱ آگوست ۲۰۱۵ منطقه مورد مطالعه

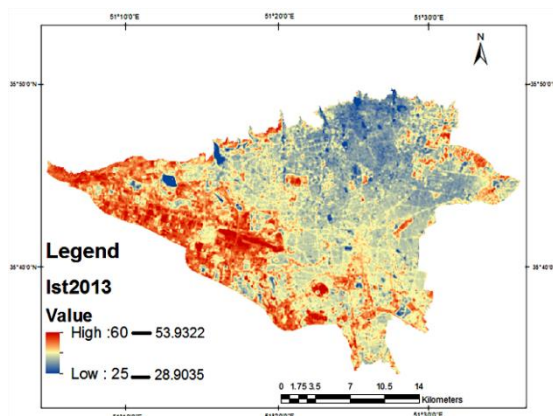


شکل ۶- نقشه LST ۲۳ آگوست ۲۰۱۶ منطقه مورد مطالعه



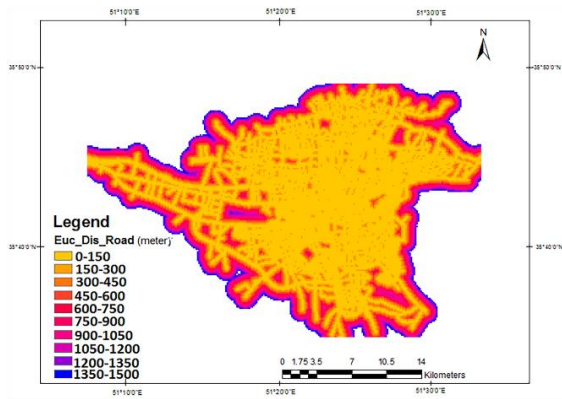
شکل ۷- نقشه LST ۲۵ آگوست ۲۰۱۷ منطقه مورد مطالعه

اراضی شامل ۷ کاربری در شکل ۱۰ نمایش داده شده است. لایه تراکم جمعیت به صورت نسبت جمعیت در هکتار و لایه تراکم ساخت و ساز نسبت مساحت ساخته شده در هکتار می باشد که به ۴ دسته ی تراکم زیر ۲۵٪، تراکم ۲۵٪ تا ۵۰٪، تراکم ۵۰٪ تا ۷۵٪ و تراکم بیش از ۷۵٪ دسته بندی گردید. لایه ارتفاع ساختمان ها بر اساس تعداد طبقات ساختمان ها دسته بندی شد. مدل رقومی ارتفاعی منطقه از سازمان نقشه برداری کشور و با قدرت تفکیک ۳۰ متر تهیه شده و با استفاده از آن در نرم افزار آرک جی آی اس لایه های اطلاعاتی شیب و جهت شیب بر حسب درجه با قدرت تفکیک ۳۰ متر تولید گردید. لایه های اطلاعاتی کاربری اراضی، تراکم جمعیت، تراکم ساخت و ساز، ارتفاع ساختمان ها و شبکه راه ها دارای فرمت برداری بودند. بنابراین با استفاده از نرم افزار آرک جی آی اس به داده های رستری با قدرت تفکیک ۳۰ متر تبدیل شدند. لایه فاصله از راه ها با استفاده از تحلیل مکانی فاصله اقلیدسی تولید شده است و هر موقعیت از نقشه، عددی را نشان می دهد که بیانگر فاصله تا نزدیک ترین راه است. همچنین لایه تعداد طبقات ساختمان ها از لایه بلوک های آماری گرفته شده است که میانگین طبقات یک بلوک را در نظر گرفته است. لازم به ذکر است که نقاطی که داخل بلوک های بزرگی مانند فرودگاه قرار گرفته اند از لحاظ قرار گرفتن بر روی ساختمان یا سطح زمین بررسی گردیده اند. همچنین باید یادآور شد که از دو عامل اتمسفری یعنی فشار و رطوبت در این پژوهش صرف نظر شده است. لایه های اطلاعاتی را می توان در شکل های ۳ تا ۱۴ مشاهده نمود.

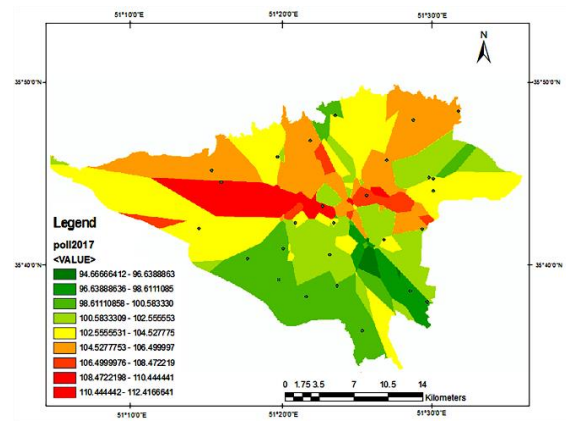


شکل ۳- نقشه LST ۱۵ آگوست ۲۰۱۳ منطقه مورد مطالعه

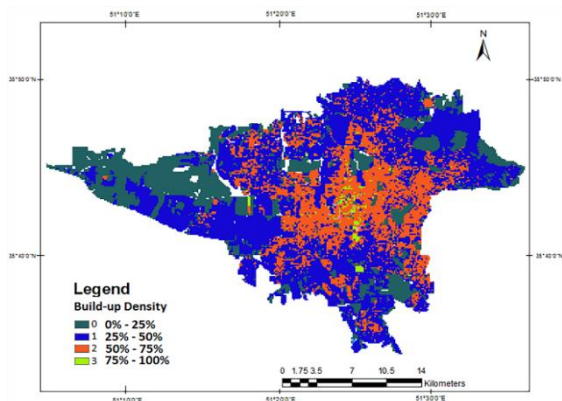




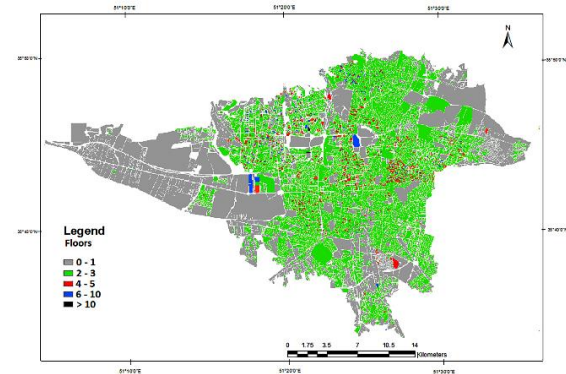
شکل ۱۲- لایه فاصله از راهها (متر) منطقه مورد مطالعه



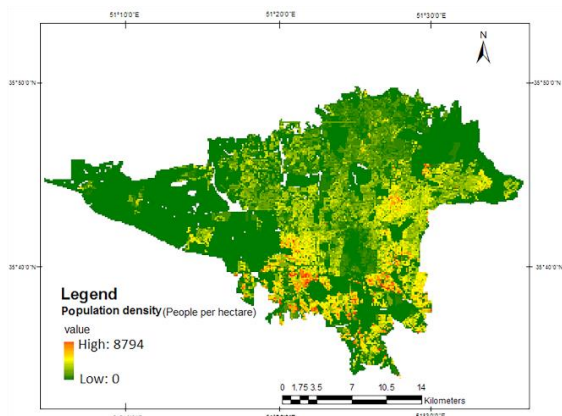
شکل ۸- نقشه تولید شده آلودگی هوا بر اساس شاخص کیفیت هوای تهران با درون‌یابی کریجینگ و ایستگاه‌های کنترل کیفیت هوا



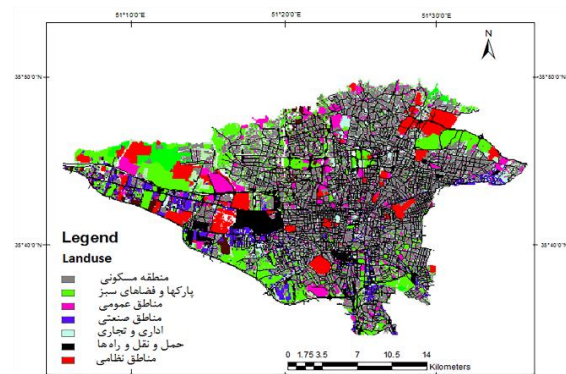
شکل ۱۳- لایه تراکم ساخت‌وساز (چهار دسته ۰-۲۵، ۲۵-۵۰، ۵۰-۷۵ و ۷۵-۱۰۰ درصد) منطقه مورد مطالعه



شکل ۹- لایه تعداد طبقات ساختمان‌ها در منطقه مورد مطالعه



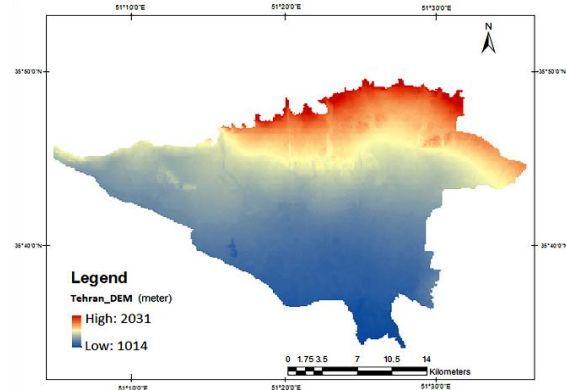
شکل ۱۴- لایه تراکم جمعیت (نفر در هکتار) منطقه مورد مطالعه



شکل ۱۰- لایه کاربری اراضی منطقه مورد مطالعه

## ۲-۳- مدل‌سازی

در این بخش به تشریح الگوریتم ترکیبی پیشنهادی GTWR و ژنتیک پرداخته‌ایم. از آنجا که الگوریتم GTWR نسخه‌ی بهبودیافته‌ی الگوریتم GWR از طریق اعمال بعد زمانی است، ابتدا به تشریح الگوریتم GWR و سپس GTWR و در پایان به روش پیش‌بینی دمای سطح زمین پرداخته خواهد شد.



شکل ۱۱- لایه مدل ارتفاعی زمین (DEM) منطقه مورد مطالعه

## ۲-۳-۱- رگرسیون وزن دار جغرافیایی

$$y_i = \beta_0(u, v) + \sum_{j=1}^p \beta_j(u, v)X_{ij} + \varepsilon_i \quad (2)$$

رابطه فوق همان معادله رگرسیون جهانی است با این تفاوت که موقعیت نقاط مشاهداتی (u,v) به آن اضافه شده است. برخلاف OLS، GWR یک روش سرشکنی وزن دار است و ضرایب رگرسیون را از طریق رابطه زیر بدست می آورد [۲۱]:

$$\hat{\beta}(u, v) = (X^T W(u, v) X)^{-1} X^T W(u, v) y \quad (3)$$

که در آن W ماتریس وزن مشاهدات است که خود تابعی از موقعیت نقاط می باشد. این ماتریس یک ماتریس قطری شامل وزن های جغرافیایی به شکل رابطه (۴) است [۲۱]:

$$W = \begin{bmatrix} W_1(u, v) & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & W_n(u, v) \end{bmatrix} \quad (4)$$

تعیین وزن های جغرافیایی در GWR برای تعیین پارامترها مورد استفاده قرار می گیرد و از اهمیت بالایی برخوردار است. وزن دهی بر اساس نزدیکی مشاهدات به نقطه ویژه i تعیین می شود. به این معنی که فاصله بین مشاهدات و نقطه i وزن مشاهدات را مشخص می کند. جهت تعیین وزن ها از توابعی استفاده می کنند که به هسته<sup>۴</sup> معروف اند. تاکنون هسته های متعددی به عنوان تابع وزن ارائه شده است. دو نمونه از این هسته ها که کارایی بالایی را ثابت کرده اند هسته گوسین و مکعبی سه گانه<sup>۵</sup> می باشند که به ترتیب در روابط (۵) و (۶) نشان داده شده اند [۳۲]:

$$w_{ij} = \varphi \left( \frac{d_{ij}}{\sigma h} \right) \quad (5)$$

$$w_{ij} = f(x) = \begin{cases} \left(1 - \left(\frac{d_{ij}}{h}\right)^3\right)^3, & d_{ij} \leq h \\ 0, & d_{ij} > h \end{cases} \quad (6)$$

که  $W_{ij}$  وزن جغرافیایی مربوط به مشاهده زام در نقطه ام،  $\varphi$  تابع توزیع نرمال استاندارد،  $d_{ij}$  فاصله اقلیدسی دو نقطه i و j،  $\sigma$  انحراف استاندارد مقادیر  $d_{ij}$  به ازای هر نقطه و h پارامتر پهنای باند می باشد. مسئله مهم در

رگرسیون وزن دار جغرافیایی یک روش رگرسیون جهانی است که توسط برانسدون و همکاران برای داده های مکانی ارائه شد [۲۱]. این روش رگرسیون با هدف ایجاد انعطاف در رگرسیون های معمولی توسعه یافته است و در فضای مورد مطالعه به صورت محلی عمل می کند و ضرایب را در مکان های مختلف ثابت و یا یکسان در نظر نمی گیرد [۳۰]. شکل کلی مدل رگرسیون جهانی به صورت رابطه ی زیر است [۲۱]:

$$y_i = \beta_0 + \sum_{j=1}^p \beta_j X_{ij} + \varepsilon_i \quad (1)$$

که در این رابطه  $y_i$  متغیر وابسته،  $X_{ij}$  متغیرهای مستقل و  $\varepsilon_i$  خطای باقیمانده مدل است. در این رابطه هیچ اطلاعاتی از موقعیت جغرافیایی مسئله در نظر گرفته نشده و تمام پارامترها بر اساس میانگین کلی مجموعه داده ها به دست می آیند. بر همین اساس جهت اعمال داده های مکانی روش GWR ارائه شده است که یک تعمیم از رگرسیون جهانی با اضافه کردن داده های مکانی به آن است.

داده های مکانی نوع خاصی از داده ها با ویژگی های منحصر به فرد هستند. دو نمونه از این ویژگی ها عبارتند از (الف) خودهمبستگی مکانی<sup>۱</sup> بر اساس قانون اول تابلر که بیانگر رابطه معکوس وابستگی ها با فاصله است [۳۱] و (ب) نایستایی مکانی<sup>۲</sup> که بیانگر تغییر خودهمبستگی مکانی در فضا و ناهمگونی محیط است. روش کمترین مربعات معمولی<sup>۳</sup> (OLS) نمی تواند با این دو ویژگی سازگار شود زیرا در این روش داده ها کاملاً مستقل از هم فرض می شوند و محیط نیز همگون است. بنابراین OLS بدون در نظر گرفتن وابستگی های مکانی برای تمامی نقاط منطقه یک دسته جواب ارائه می دهد [۴].

در روش GWR، وابستگی های مکانی مشاهدات به صورت ماتریس های وزن در نظر گرفته می شود و به دلیل ناهمگونی محیط و وجود نایستایی مکانی، ضرایب رگرسیون به صورت محلی و برای هر نقطه به طور جداگانه به دست می آید. رابطه کلی GWR در رابطه (۲) بیان شده است [۲۱]:

۴ Kernel  
۵ Tricube

۱ Spatial autocorrelation  
۲ Spatial non-stationarity  
۳ Ordinary Least Squares

تعیین وزن‌های جغرافیایی انتخاب پهنای باند مناسب است؛ زیرا چنانچه این پارامتر بیش از حد بزرگ باشد، نتایج GWR به سمت OLS میل می‌کند و اگر بیش از حد کوچک انتخاب شود، واریانس نتایج به شدت افزایش می‌یابد [۳۳]. روش‌های مختلفی برای تعیین پهنای باند بهینه وجود دارد. یکی از آن‌ها روش اعتبارسنجی متقابل<sup>۱</sup> است که تابع آن به صورت زیر است [۲۱].

$$\sum_{i=1}^n [y_i - \check{y}_i(h)]^2 \quad (7)$$

که  $n$  تعداد مشاهدات،  $y_i$  مشاهده  $i$ ام و  $\check{y}_i$  مقدار برآورد شده مشاهده  $i$ ام با استفاده از سایر مشاهدات است که خود تابعی از پارامتر پهنای باند است و هر پهنای باندی که این تابع را مینیمم کند به عنوان پهنای باند بهینه در نظر گرفته می‌شود.

خروجی GWR شامل پارامترهای متعددی است که از آن میان معمولاً پارامتر ضریب تشخیص<sup>۲</sup>  $R^2$  برای سنجش خوب بودن برازش مدل به کار می‌رود [۳۳].

$$R^2 = 1 - \frac{SS_E}{SS_T} \quad (8)$$

$$SS_E = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$SS_T = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (10)$$

که در آن  $SS_E$  همان خطای باقیمانده مدل یا مجموع مربعات خطاها در زمانی که از متغیرهای مستقل استفاده می‌شود می‌باشد. اما  $SS_T$  مجموع مربعات خطاها است زمانی که از متغیرهای مستقل استفاده نمی‌شود و در واقع تابع تخمین تنها یک عدد ثابت است و  $n$  تعداد مشاهدات،  $y_i$  مشاهده  $i$ ام،  $\hat{y}_i$  مقدار برآورد شده مشاهده  $i$ ام و  $\bar{y}$  میانگین مشاهدات است.

همان‌طور که پیش‌تر ذکر شد، GWR توانایی مدل‌سازی تغییرات محلی و نایستایی مکانی را دارد. آماره ای که می‌توان از آن برای تعیین میزان تغییرپذیری

ضرایب رگرسیون در منطقه مورد مطالعه استفاده نمود، انحراف استاندارد ضرایب رگرسیون است که با رابطه زیر بیان می‌شود [۲۱]:

$$v_j = \sqrt{\sum_i (\beta_{ij} - \beta_j)^2 / n} \quad (11)$$

که  $\beta_{i,j}$  ضریب رگرسیون فاکتور  $j$ ام در مشاهده  $i$ ام،  $\beta_j$  میانگین ضریب رگرسیون فاکتور  $j$ ام در کل مشاهدات و  $n$  تعداد مشاهدات می‌باشد.

همچنین مقادیر خطای جذر میانگین مربعات<sup>۳</sup> (RMSE) و RMSE نرمال شده (NRMSE)<sup>۴</sup> باقیمانده‌های مدل که از روابط زیر به دست می‌آیند، به منظور سنجش توزیع این باقیمانده‌ها به کار می‌روند [۲۱]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (12)$$

$$NRMSE = RMSE / \sigma_{\hat{y}} \quad (13)$$

که در آن‌ها  $n$  تعداد داده‌ها،  $y$  مقدار واقعی متغیر وابسته،  $\hat{y}$  مقدار برآورد شده آن و  $\sigma_{\hat{y}}$  انحراف معیار مقادیر برآورد شده متغیر وابسته است. باید یادآور شد که مقادیر کمتر برای RMSE بهتر است اما هنگام استفاده از دو روش با داده‌های مختلف از NRMSE برای مقایسه بهتر استفاده می‌شود.

همان‌طور که پیش از این اشاره شد، جهت ورود داده‌ها به الگوریتم ابتدا بایستی همبستگی بین متغیرهای مستقل به دست آید. در این راستا به منظور بررسی همبستگی بین متغیرهای مستقل، ضرایب همبستگی برای هر زوج متغیر با توجه به رابطه (۱۴) محاسبه می‌شود [۳۴]:

$$Cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n} \quad (14)$$

$$r = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} \quad (15)$$

که در آن‌ها  $Cov(X, Y)$  کوواریانس دو مجموعه داده  $x$  و  $y$ ،  $\bar{X}$  و  $\bar{Y}$  میانگین این دو مجموعه داده،  $n$  تعداد داده‌های هر مجموعه و  $r$  ضریب همبستگی بین دو مجموعه داده با انحراف معیارهای  $\sigma_X$  و  $\sigma_Y$  است.

<sup>۳</sup> Root Mean Squares Error

<sup>۴</sup> Normal Root Mean Squares Error

<sup>۱</sup> Cross Validation

<sup>۲</sup> Coefficient of Determination



## ۲-۳-۲- رگرسیون وزن دار جغرافیایی زمانمند

مکان و زمان دو بعد اساسی ارائه چارچوبی برای همه فعالیت‌های انسانی، رویدادهای اجتماعی و فرآیندهای زیست‌محیطی هستند. مدل‌سازی مکانی و زمانی به مدت طولانی مورد تمرکز تحقیقات متعددی در زمینه علوم اطلاعات جغرافیایی بوده است [۳۵، ۳۶]. داده‌های مکانی-زمانی می‌توانند اطلاعات ارزشمندی درباره روند پویای یک فرآیند مکانی ارائه دهند و به پیش‌بینی متغیرهای مربوطه کمک کنند. تلاش‌های گسترده‌ای نیز به ترکیب بعد زمانی در رگرسیون فضایی اختصاص داده شده است [۳۶-۴۱].

با توسعه بُعد زمان مدل GWR، به ارائه مدل رگرسیون وزن دار جغرافیایی زمانمند<sup>۱</sup> (GTWR) پرداخته شد که شامل پهنای باند و تابع کرنل مکانی-زمانی می‌باشد. در GTWR فرض می‌شود که داده‌ها علاوه بر خودهمبستگی و نایستایی مکانی دارای خودهمبستگی و نایستایی زمانی نیز می‌باشند. یعنی ضرایب رگرسیون علاوه بر این که از نقطه-ای به نقطه دیگر تغییر می‌کنند برای یک نقطه در زمان-های مختلف نیز متفاوت‌اند. برای تبدیل معمولی به GTWR کافی است بُعد زمان را به همه روابط مربوط به GWR اضافه کنیم. بدین ترتیب روابط ۲ تا ۴ به صورت روابط ۱۶ تا ۱۸ تغییر خواهند کرد [۴۲]:

$$y_i = \beta_0(u, v, t) + \sum_{j=1}^p \beta_j(u, v, t) X_{ij} + \varepsilon_i \quad (16)$$

$$\hat{\beta}(u, v, t) = (X^T W(u, v, t) X)^{-1} X^T W(u, v, t) y \quad (17)$$

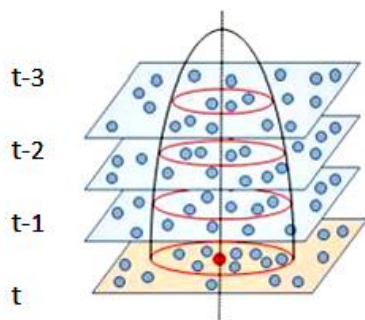
$$W = \begin{bmatrix} W_1(u, v, t) & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & W_n(u, v, t) \end{bmatrix} \quad (18)$$

همچنین سایر روابط GWR به همان شکل اولیه در GTWR نیز به کار می‌روند. با این تفاوت که تعریف فاصله در آن‌ها تغییر می‌یابد. برای تعریف فاصله مکانی-زمانی از رابطه (۱۹) استفاده می‌شود [۴۲]:

$$d_{ij} = \sqrt{\lambda[(u_i - u_j)^2 + (v_i - v_j)^2] + \mu(t_i - t_j)^2} \quad (19)$$

که در آن  $\lambda$  و  $\mu$  فاکتورهای مقیاس مکانی و زمانی هستند که به منظور ایجاد تعادل بین اندازه‌گیری‌های

مکانی و زمانی در رابطه آورده شده‌اند. شکل ۱۵ نمونه‌ای از تعریف پهنای باند مکانی-زمانی را نشان می‌دهد.



شکل ۱۵- پراکندگی نمونه‌ای از پهنای باند مکانی-زمانی [۴۲]

از فاصله تعریف شده در رابطه (۱۹) به منظور تعیین وزن‌های مکانی-زمانی در روابط (۵) و (۶) استفاده می‌شود. همچنین از رابطه (۷) جهت بهینه‌سازی پهنای باندهای مکانی و زمانی استفاده می‌گردد [۴۲].


## ۲-۳-۳- الگوریتم ژنتیک

هدف از این بخش انتخاب زیرمجموعه‌ای از عوامل مؤثری است که الگوریتم GWR با استفاده از آن‌ها بهترین عملکرد را داشته باشد. یکی از روش‌های انتخاب عوامل بهینه در میان چندین عامل مؤثر استفاده از الگوریتم ژنتیک است که در این پژوهش از الگوریتم ژنتیک ارائه شده توسط [۴۳] برای انتخاب عوامل بهینه استفاده شد. این الگوریتم به صورت ضمنی وابستگی بین عوامل را در نظر می‌گیرد و با توجه به آن بهترین زیرمجموعه از عوامل را انتخاب می‌کند. الگوریتم ژنتیک یک الگوریتم اکتشاف جستجوگرایانه<sup>۲</sup> بوده که بر اساس انتخاب طبیعی کار می‌کند. این اکتشاف اغلب برای حل مسائل جستجو و بهینه‌سازی به کار برده می‌شود. در الگوریتم ژنتیک اغلب یک جمعیت از راه‌حل‌های نماینده (کروموزوم) به سمت بهینه کلی حرکت می‌کنند. روند بهینه‌سازی از یک جمعیت (نسل) تشکیل شده از کروموزوم‌های تولیدشده به صورت اتفاقی شروع می‌شود. در هر نسل تابع برازش برای تمامی کروموزوم‌های آن نسل محاسبه می‌شود. این تابع برازش معمولاً تابع هدف مسئله بهینه‌سازی است. همان‌طور که در بخش قبل بیان شد، تابع برازش الگوریتم ژنتیک پیشنهادی  $1-R^2$  و هدف مینیمم نمودن آن است.

<sup>۲</sup> Search Heuristic

<sup>۱</sup> Geographically & Temporally Weighted Regression

بر اساس مکانیسم نخبه‌گرایی<sup>۱</sup>، بهترین کروموزوم هر نسل به صورت مستقیم به نسل بعد منتقل می‌گردد. همچنین، کروموزوم‌های دارای مقدار تابع برازش کمتر به صورت اتفاقی در هر نسل بر اساس مکانیزم انتخاب برگزیده شده و ژنوم<sup>۲</sup> این کروموزوم‌ها با اعمال تغییراتی از سوی عملگرهای ژنتیک (ترکیب ضربی<sup>۳</sup> و جهش<sup>۴</sup>) به نسل بعد انتقال می‌یابند. این نسل جدید از کروموزوم‌های تولید شده در حلقه تکرار بعدی مورد استفاده قرار می‌گیرند. بدین ترتیب، زمانی الگوریتم ژنتیک خاتمه می‌یابد که یا به تعداد بیشینه نسل‌ها و یا به مقدار تابع برازش رضایت‌بخش رسیده باشد. شکل ۱۶ نحوه کدگذاری الگوریتم ژنتیک پیشنهادی برای حل مسئله یافتن عوامل بهینه را نشان می‌دهد. در این شکل  $a_i$  به ژن‌های عامل اشاره دارد.



شکل ۱۶- نحوه کدگذاری هر کروموزوم الگوریتم ژنتیک پیشنهادی برای حل مسئله یافتن عوامل بهینه

### ۲-۳-۴- روش پیش‌بینی LST

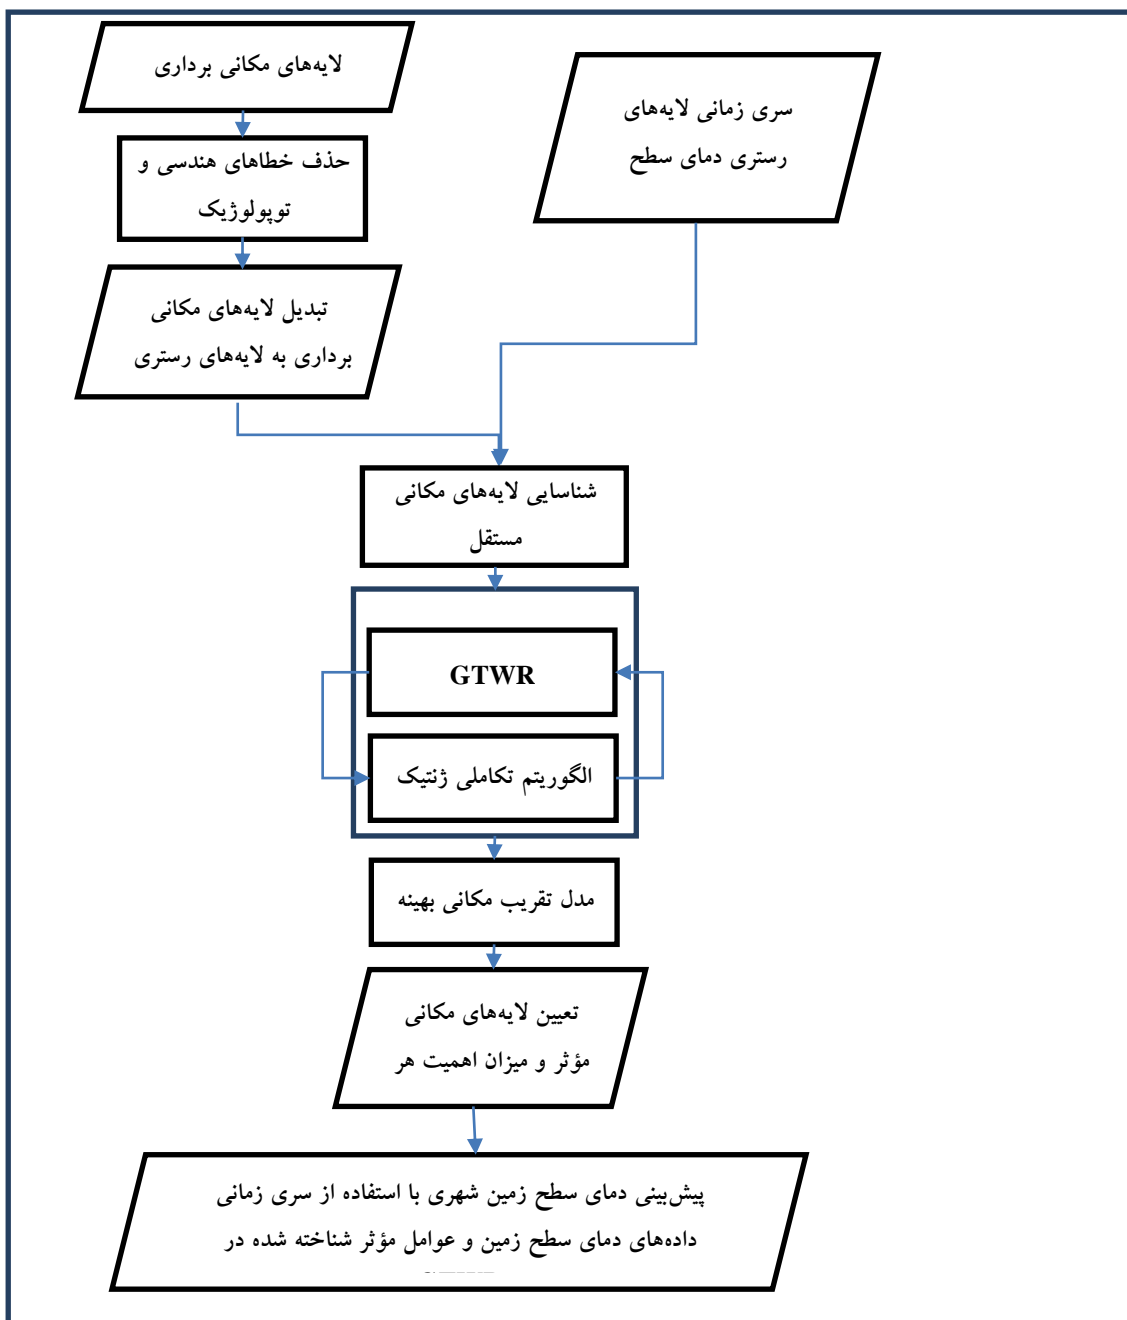
روند کلی در مطالعه‌ی حاضر برای پیش‌بینی LST در شکل ۱۷ ارائه شده است. همان‌طور که از شکل قابل مشاهده است، در مرحله اول عوامل موردنظر و همچنین سری داده‌های دمای سطح زمین از سال ۲۰۱۳ تا ۲۰۱۶ به‌عنوان داده‌های موردنیاز برای مدل‌سازی وارد می‌شوند. سپس ضرایب همبستگی بین عوامل محاسبه می‌شود و داده‌هایی که همبستگی کمتری دارند وارد الگوریتم می‌شوند. برای تعیین عواملی که در تخمین LST مؤثرتر هستند از ترکیب الگوریتم ژنتیک با GTWR استفاده شده

است. لازم به ذکر است که طی فرایند بهینه‌سازی با استفاده از روش پیشنهادی، وزن هر یک از عوامل نیز بر اساس میزان تأثیر آن تعیین می‌شود. در پایان از وزن‌های به دست آمده برای هر یک از عوامل جهت پیش‌بینی دمای سطح زمین استفاده شده است.

### ۳- پیاده‌سازی و ارزیابی

در ابتدا جهت ورود داده‌ها به الگوریتم، همبستگی بین متغیرهای مستقل محاسبه گردید. پس از محاسبه همبستگی بین متغیرها، بیشترین ضریب همبستگی بین ارتفاع ساختمان و تراکم ساخت‌وساز با مقدار ۰,۵۹ به دست آمد و مقادیر ضریب همبستگی بین سایر عوامل کمتر از این مقدار و اکثر آنها بسیار نزدیک به صفر بدست آمد که نشان از عدم همبستگی بین عوامل مورد استفاده می‌باشد. با توجه به اینکه در الگوریتم ژنتیک تحلیل همبستگی و حساسیت به صورت ضمنی بین عوامل یا متغیرهای مستقل صورت می‌گیرد و متغیرهای وابسته از ورود به الگوریتم حذف می‌شوند بنابراین با توجه به نتایج جدول ۱ از تمامی آن‌ها در الگوریتم‌ها استفاده شد.

۱ Elitism  
۲ Genome  
۳ Crossover  
۴ Mutation



شکل ۱۷- روند کلی روش پیشنهادی برای پیش‌بینی LST

جدول ۱- ضرایب همبستگی بین عوامل مؤثر بر دمای سطح زمین شهر تهران


ارتفاع	شیب	جهت شیب	فاصله از راه	کاربری اراضی	ارتفاع ساختمان	تراکم جمعیت	تراکم ساخت	آلودگی هوا
۱	۰/۳۱	۰/۰۳	۰/۰۵	-۰/۰۵	۰/۰۳	-۰/۱۸	-۰/۰۳	۰/۲۱
	۱	۰/۰۲	۰/۰۱	۰/۰۳	-۰/۰۵	-۰/۱۲	-۰/۰۸	۰/۰۱
		۱	۰/۰۲	-۰/۰۲	-۰/۰۳	-۰/۰۲	-۰/۰۵	۰/۰۰
			۱	۰/۰۵	-۰/۱۳	-۰/۱۸	-۰/۱۵	-۰/۰۳
				۱	-۰/۳۶	-۰/۳۷	-۰/۳۴	-۰/۰۴
					۱	۰/۵۰	۰/۵۹	۰/۰۵
						۱	۰/۵۷	۰/۰۳
							۱	۰/۰۶
								۱

آلودگی هوا به‌عنوان عوامل مؤثر در پیش‌بینی LST انتخاب شدند. شکل ۱۹ نتایج حاصل از رگرسیون وزن‌دار جغرافیایی با استفاده از هسته مکعبی سه‌گانه در ترکیب با الگوریتم ژنتیک و برای داده‌های سال ۲۰۱۳ تا ۲۰۱۶ را نشان می‌دهند. بر اساس این عوامل، تصویر LST در سال ۲۰۱۷ پیش‌بینی شد که در شکل ۲۰ نشان داده شده است.

جدول ۲- پارامترهای الگوریتم ژنتیک مورد استفاده



Parameter	Value
Population size	20
Number of Generations	100
Crossover rate	0.8
Migration Fraction	0.2
Migration Interval	20
Scale (Gaussian Mutation)	0.5
Shrink (Gaussian Mutation)	0.7
Elite count	1

برای بهینه‌سازی پارامتر پهنای باند نیز روش اعتبارسنجی متقابل بکارگرفته شد. ۹ عامل مؤثر کروموزوم های الگوریتم ژنتیک را به‌صورت مقادیر دودویی مشابه شکل ۱۸ تشکیل می‌دهند، که مقدار یک به معنی انتخاب عامل و مقدار صفر به‌معنی عدم انتخاب عامل است. مقادیر پارامترهای الگوریتم ژنتیک مورد استفاده در این پژوهش نیز در جدول ۲ آمده است.

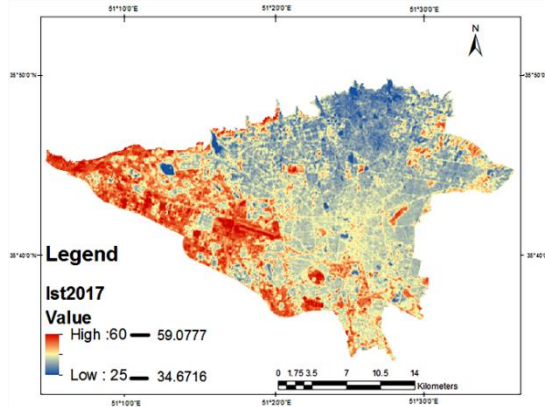
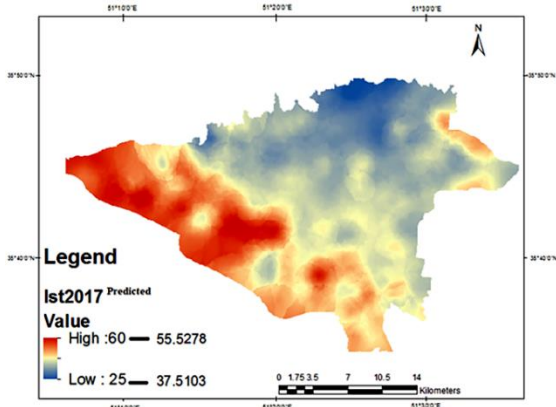


شکل ۱۸- نحوه قرارگیری ژن‌ها (عوامل) در یک کروموزوم

پس از استفاده از الگوریتم پیشنهادی، ۵ عامل شامل ارتفاع، فاصله از راه‌ها، کاربری اراضی، تراکم ساخت‌وساز و



شکل ۱۹- (الف) بهترین مقدار و میانگین مقادیر تابع برازش و (ب) بهترین ترکیب انتخاب شده از عوامل توسط الگوریتم ژنتیک در ترکیب با رگرسیون وزن‌دار جغرافیایی با استفاده از هسته مکعبی سه‌گانه و در تاریخ ۲۰۱۳ تا ۲۰۱۶



شکل ۲۰- نقشه مرجع (سمت راست) و نقشه پیش‌بینی شده LST (سمت چپ) در شهر تهران در سال ۲۰۱۷ با استفاده از ۱۵۰۰ نقطه

جدول ۲- مقایسه نتایج بین تصویر LST پیش‌بینی شده با استفاده از GTWR با همه عوامل و GTWR با عوامل مؤثر انتخابی

NRMSE	RMSE	R <sup>2</sup>	
۰,۲۱۵۶	۰,۷۵۱۱	۰,۹۶۲۱	GTWR با همه عوامل
۰,۱۹۰۸	۰,۵۰۹۷	۰,۹۸۸۲	GTWR با عوامل مؤثر

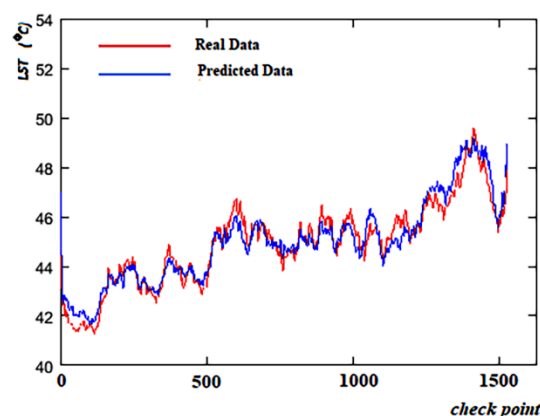
برای ارزیابی بهتر عملکرد روش پیشنهادی، یک بار با استفاده از عوامل انتخاب‌شده و یک بار با استفاده از همه‌ی عوامل، تصویر LST در سال ۲۰۱۷ تولید شد. در این ارزیابی از معیارهای R<sup>2</sup>، RMSE و NRMSE استفاده شد که نتایج آن در جدول ۳ قابل مشاهده است.

ژنتیک مبتنی بر GTWR وارد شدند تا عوامل مؤثر در تخمین و پیش بینی LST را پیدا کنند. از بین این عوامل، ۵ لایه شامل ارتفاع، فاصله از راه‌ها، کاربری اراضی، تراکم ساخت‌وساز و آلودگی هوا به‌عنوان عوامل مؤثر در برآورد LST تعیین شد. بر اساس این عوامل، نقشه LST سال ۲۰۱۷ برای شهر تهران با استفاده از تابع تقریب GTWR پیش‌بینی شد.

تایج این مطالعه نشان می‌دهد که این روش می‌تواند با استفاده از برخی عوامل، نقشه LST را در زمان‌های دلخواه به‌طور مطلوبی پیش‌بینی کند. این عوامل ممکن است از منطقه‌ای به منطقه دیگر متفاوت باشد. بنابراین، برای سایر مطالعات موردی، این روش باید کاملاً تکرار شود تا عوامل مؤثر تعیین گردند. علاوه بر این، آزمایشات نشان داد که انتخاب عوامل مؤثر نسبت به استفاده از همه عوامل موجود، منجر به نتایج دقیق‌تری می‌شود.

با توجه به مشکلات دسترسی به داده‌ها در این پژوهش، پیشنهاد می‌شود در مطالعات آتی تعداد عوامل مورد بررسی به‌خصوص عوامل انسانی افزایش یابد. از جمله عوامل انسانی مهم مؤثر در دمای سطح زمین می‌توان به ترافیک در شهرها، هندسه شهری، جنس انواع کاربری مانند جنس مصالح ساختمانی یا کف خیابان‌ها و یا انواع گیاهان اشاره کرد. همچنین می‌توان به بررسی تأثیر انواع پوشش گیاهی پارک‌ها و فضاهای سبز شهری پرداخت. این کار در سیاست‌های مدیریت و برنامه‌ریزی شهری بسیار کمک‌کننده خواهد بود. یکی دیگر از مسائلی که در این پژوهش دیده نشد، بررسی دمای سطح زمین در یک سری زمانی طولانی مدت بود که می‌توان در پژوهش‌های آتی داده‌ها را در مقیاس زمانی بزرگتری تهیه نمود و با تغییر در انواع کاربری اراضی و دیگر عوامل در یک فصل مشخص به پیش‌بینی دمای سطح زمین در مناطق شهری پرداخت.

همان‌طور که از این جدول مشخص است، درگیر شدن تمام عوامل در پیش‌بینی LST منجر به دقت کمتری نسبت به انتخاب مؤثرترین عوامل می‌شود. علاوه بر آن، برای نشان دادن بصری عملکرد روش پیشنهادی، نمودار LST پیش‌بینی شده و واقعی در ۱۵۰۰ نقطه تصادفی انتخاب شده در شکل ۲۱ نشان داده شده است. همان‌طور که از این شکل دیده می‌شود، مقادیر LST بسیار نزدیک به یکدیگر هستند که دقت بالای پیش‌بینی LST در روش پیشنهادی را نشان می‌دهد.



شکل ۲۱- نمودار LST پیش‌بینی شده و واقعی در ۱۵۰۰ نقطه انتخابی

جدول ۳- مقایسه نتایج بین تصویر LST پیش‌بینی شده با استفاده از GTWR با همه عوامل و GTWR با عوامل مؤثر انتخابی

NRMSE	RMSE	R <sup>2</sup>	
۰,۲۱۵۶	۰,۷۵۱۱	۰,۹۶۲۱	با GTWR
۰,۱۹۰۸	۰,۵۰۹۷	۰,۹۸۸۲	با GTWR

#### ۴- نتیجه‌گیری و پیشنهادات

در این پژوهش، ما روشی را برای انتخاب مؤثرترین عوامل برای پیش‌بینی و تخمین LST پیشنهاد کردیم. در این روش، ابتدا ۹ لایه مختلف اطلاعات به‌همراه تصاویر LST شهر تهران از سال ۲۰۱۳ تا ۲۰۱۶، به یک الگوریتم

#### مراجع

- [1] Xian, G. and M. Crane. Evaluation of urbanization influences on urban climate with remote sensing and climate observations. in Proceedings of the ISPRS joint conference 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005 (5th International Symposium Remote Sensing of Urban Areas (URS 2005) Tempe, AZ. 2005.
- [2] Das, N., et al., Assessment of variation of land use/land cover and its impact on land surface temperature of Asansol subdivision. The Egyptian Journal of Remote Sensing and Space Science, 2021. 24(1): p. 131-149.

- [3] Chudnovsky, A., E. Ben-Dor, and H. Saaroni, Diurnal thermal behavior of selected urban objects using remote sensing measurements. *Energy and Buildings*, 2004. 36(11): p. 1063-1074.
- [4] Li, S., et al., Investigating spatial non-stationary and scale-dependent relationships between urban surface temperature and environmental factors using geographically weighted regression. *Environmental Modelling & Software*, 2010. 25(12): p. 1789-1800.
- [5] Weng, Q., A remote sensing? GIS evaluation of urban expansion and its impact on surface temperature in the Zhujiang Delta, China. *International journal of remote sensing*, 2001. 22(10): p. 1999-2014.
- [6] Streutker, D.R., Satellite-measured growth of the urban heat island of Houston, Texas. *Remote Sensing of Environment*, 2003. 85(3): p. 282-289.
- [7] Pu, R., et al., Assessment of multi-resolution and multi-sensor data for urban surface temperature retrieval. *Remote Sensing of Environment*, 2006. 104(2): p. 211-225.
- [8] Qiao, Z., et al., The impact of urban renewal on land surface temperature changes: a case study in the main city of Guangzhou, China. *Remote Sensing*, 2020. 12(5): p. 794.
- [9] Gohain, K.J., P. Mohammad, and A. Goswami, Assessing the impact of land use land cover changes on land surface temperature over Pune city, India. *Quaternary International*, 2021. 575: p. 259-269.
- [10] Peng, W., et al., Land surface temperature and its impact factors in Western Sichuan Plateau, China. *Geocarto International*, 2017. 32(8): p. 919-934.
- [11] Weng, Q. and S. Yang, Managing the adverse thermal effects of urban development in a densely populated Chinese city. *Journal of Environmental Management*, 2004. 70(2): p. 145-156.
- [12] Huang, G., W. Zhou, and M. Cadenasso, Is everyone hot in the city? Spatial pattern of land surface temperatures, land cover and neighborhood socioeconomic characteristics in Baltimore, MD. *Journal of environmental management*, 2011. 92(7): p. 1753-1759.
- [13] Estoque, R.C., Y. Murayama, and S.W. Myint, Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia. *Science of The Total Environment*, 2017. 577: p. 11.
- [14] Chen, Y.-C., et al., Does urbanization increase diurnal land surface temperature variation? Evidence and implications. *Landscape and Urban Planning*, 2017. 157: p. 12.
- [15] Xiao, R., et al., Land surface temperature variation and major factors in Beijing, China. *Photogrammetric Engineering & Remote Sensing*, 2008. 74(4): p. 451-461.
- [16] Chen, X.-L., et al., Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote sensing of environment*, 2006. 104(2): p. 133-146.
- [17] Guha, S. and H. Govil, An assessment on the relationship between land surface temperature and normalized difference vegetation index. *Environment, Development and Sustainability*, 2020: p. 1-20.
- [18] Zhou, W., G. Huang, and M.L. Cadenasso, Does spatial configuration matter? Understanding the effects of land cover pattern on land surface temperature in urban landscapes. *Landscape and Urban Planning*, 2011. 102(1): p. 54-63.
- [19] Dutilleul, P. and P. Legendre, Spatial heterogeneity against heteroscedasticity: an ecological paradigm versus a statistical concept. *Oikos*, 1993 :p. 152-171.
- [20] Jetz, W., C. Rahbek, and J.W. Lichstein, Local and global approaches to spatial data analysis in ecology. *Global Ecology and Biogeography*, 2005. 14(1): p. 97-98.
- [21] Brunson, C., S. Fotheringham, and M. Charlton, Geographically weighted regression. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 1998. 47(3): p. 431-443.
- [22] Zhang, L., J.H. Gove, and L.S. Heath, Spatial residual analysis of six modeling techniques. *Ecological Modelling*, 2005. 186(2): p. 154-177.
- [23] He, B.-J., et al., An approach to examining performances of cool/hot sources in mitigating/enhancing land surface temperature under different temperature backgrounds based on Landsat 8 image. *Sustainable Cities and Society*, 2019. 44: p. 416-427.
- [24] Lemus-Canovas, M., et al., Estimating Barcelona's metropolitan daytime hot and cold poles using Landsat-8 Land Surface Temperature. *Science of the Total Environment*, 2020. 699: p. 134307.
- [25] Cristóbal, J., et al., An improved single-channel method to retrieve land surface temperature from the Landsat-8 thermal band. *Remote Sensing*, 2018. 10(3): p. 431.
- [26] Sekertekin, A. and E. Zadbagher, Simulation of future land surface temperature distribution and evaluating surface urban heat island based on impervious surface area. *Ecological Indicators*, 2021. 122: p. 107230.



- [27] Yang, J., et al., Understanding land surface temperature impact factors based on local climate zones. *Sustainable Cities and Society*, 2021. 69: p. 102818.
- [28] Sobrino, J., et al., Multi-channel and multi-angle algorithms for estimating sea and land surface temperature with ATSR data. *International Journal of Remote Sensing*, 1996. 17(11): p. 2089-2114.
- [29] Becker, F. and Z.L. Li, Surface temperature and emissivity at various scales: Definition, measurement and related problems. *Remote Sensing Reviews*, 1995. 12(3-4): p. 225-253.
- [30] Fotheringham, A.S., C. Brunson, and M. Charlton, *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*. 2003: Wiley.
- [31] Tobler, W.R., A computer movie simulating urban growth in the Detroit region. *Economic geography*, 1970. 46(sup1): p. 234-240.
- [32] McMillen, D.P. and J.F. McDonald, Locally weighted maximum likelihood estimation: Monte Carlo evidence and an application, in *Advances in spatial econometrics*. 2004, Springer. p. 225-239.
- [33] Charlton, M., S. Fotheringham, and C. Brunson, *Geographically weighted regression*. White paper. National Centre for Geocomputation. National University of Ireland Maynooth, 2009.
- [34] Dale, P., *Mathematical Techniques in GIS*. 2014: CRC Press.
- [35] Cressie, N.A., *Spatial prediction and kriging*. *Statistics for Spatial Data*, Revised Edition, 1993: p. 105-209.
- [36] Cressie, N. and C. Wikle, *Statistics for Spatio-temporal Data*, John Wiley & Sons. Inc., NJ, USA, 2011.
- [37] Anselin, L., *Spatial Econometrics* (Bruton Center, School of Social Sciences). University of Texas, Dallas, 1999.
- [38] Elhorst, J.P., Specification and estimation of spatial panel data models. *International regional science review*, 2003. 26(3): (p. 244-268.
- [39] Gelfand, A.E., et al., The dynamics of location in home price. *The journal of real estate finance and economics*, 2004. 29(2): p. 149-166.
- [40] Di Giacinto, V., A generalized space-time ARMA model with an application to regional unemployment analysis in Italy. *International Regional Science Review*, 2006. 29(2): p. 159-198.
- [41] Crespo, R., S. Fotheringham, and M. Charlton. Application of geographically weighted regression to a 19-year set of house price data in London to calibrate local hedonic price models. in *Proceedings of the 9th International Conference on Geocomputation*. 2007. National University of Ireland Maynooth.
- [42] Fotheringham, A.S., R. Crespo, and J. Yao, *Geographical and temporal weighted regression (GTWR)*. *Geographical Analysis*, 2015. 47(4): p. 431-452.
- [43] Hasanlou, M. and F. Samadzadegan. ICA/PCA base genetically band selection for classification of Hyperspectral images. in *31st Asian Conference on Remote Sensing*. 2011.