



استخراج داده وکتور جاده از تصویر گوگل ارث

ابوالفضل عبدالهی^{۱*}، حمید رضا ریاحی بختیاری^۲، هانی رضائیان^۳، علی اصغر تراهی^۴

- ۱- دانشجوی کارشناسی ارشد، رشته سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه خوارزمی تهران
- ۲- استادیار، دانشکده جغرافیا گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه خوارزمی تهران
- ۳- استادیار، دانشکده جغرافیا گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه خوارزمی تهران
- ۴- استادیار، دانشکده جغرافیا گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه خوارزمی تهران

چکیده:

به دلیل در دسترس بودن اسکنرهای با وضوح بالا و هزینه کم و همچنین اینترنت، اکنون می‌توان تعداد زیادی از نقشه‌های اسکن شده در فرمت رستری را از منابع مختلف بدست آورد. از اینرو نقشه‌های حاوی شبکه‌های جاده و همچنین نقشه‌های رستری، منبع مهمی از داده‌های برداری جاده برای مناطقی که داده‌های برداری جاده‌ها به آسانی در دسترس نیست می‌باشند. علاوه بر این، داده‌های برداری جاده‌ها می‌تواند به عنوان ویژگی‌هایی برای ثبت نقشه‌ها با سایر داده‌های جغرافیایی مانند تصاویر، و ایجاد یک دیدگاه یکپارچه از مجموعه داده‌های جغرافیایی ناهمگن استفاده شود. در این مقاله از روش اسکلت‌بندی برای استخراج داده وکتور جاده از تصویر گوگل ارث استفاده شده است. در ابتدا پیکسل‌های جاده از تصویر با روش ماشین بردار پشتیبان استخراج و در نهایت از روش اسکلت‌بندی برای بردارسازی استفاده گردیده است. بررسی نتایج نشان می‌دهد که مقدار خطای جذر میانگین مربعات، برابر با ۶/۷۰۵ متر می‌باشد. در نتیجه دقت استخراج داده وکتور جاده بالا بوده و این بیانگر موفقیت کلی روش پیشنهادی در فرآیند بردارسازی می‌باشد.

واژه‌های کلیدی: بردارسازی، اسکلت‌بندی، ماشین بردار پشتیبان



۱- مقدمه

انسانها سابقه‌ای طولانی در استفاده از نقشه دارند. به خصوص، از نقشه‌های کاغذی به طور گسترده‌ای در سال‌های اولیه برای مستند سازی اطلاعات مکانی استفاده می‌کردند. به دلیل در دسترس بودن اسکرهایی با وضوح بالا و هزینه کم و همچنین اینترنت، اکنون می‌توان تعداد زیادی از نقشه‌های اسکن شده در فرمت رستری را از منابع مختلف بدست آورد. از اینرو نقشه‌های حاوی شبکه‌های جاده و همچنین نقشه‌های رستری، منبع مهمی از داده‌های برداری جاده برای مناطقی که داده‌های برداری جاده‌ها به آسانی در دسترس نیست می‌باشند. علاوه بر این، داده‌های برداری جاده‌ها می‌تواند به عنوان ویژگی‌هایی برای ثبت نقشه‌ها با سایر داده‌های جغرافیایی مانند تصاویر، و ایجاد یک دیدگاه یکپارچه از مجموعه داده‌های جغرافیایی ناهمگن استفاده شود [۱]. استخراج داده‌های برداری جاده از نقشه‌های رستری یک کار چالش برانگیز است. اولاً، استخراج پیکسل جاده به دلیل اینکه نقشه‌های رستری اغلب حاوی نویز می‌باشند و همچنین جاده‌ها اغلب با دیگر ویژگی‌های نقشه همپوشانی دارند دشوار است.

علاوه بر این، برای تبدیل پیکسل‌های جاده به فرمت‌های برداری، معمولاً از عملگر نازک شدن Itonaga و همکاران [۲] و یا گروه بندی خط و تکنیک‌های تطبیق موازی خط Bin and Cheong [۳] برای شناسایی مرکز جاده استفاده می‌شود. عملگر نازک شدن خطوط تحریف شده اطراف تقاطع‌ها را تولید می‌کند و از این رو داده‌های برداری جاده استخراج شده بدون تنظیم دستی دقیق نمی‌باشند [۳]. تکنیک‌های گروه‌بندی خطی و تطبیق موازی خط نیاز به تنظیم پارامترهای مختلف به صورت دستی برای شناسایی مرکزی دقیق، از جمله حداکثر اختلاف بین دامنه‌های دو پاره خط ادغام شده دارند [۲]. در این مقاله، یک تکنیک کلی که حداقل ورودی کاربر را نیاز دارد، برای استخراج داده‌های برداری جاده دقیق از نقشه‌های رستری با تغییر پیچیدگی نقشه و کیفیت تصویر ارائه می‌شود.

۲- کارهای مرتبط

کارهای تحقیقاتی بسیاری در زمینه استخراج اطلاعات جاده از نقشه‌های رستری، مانند جدا کردن خطوط از متن Cao and Tan [4] تشخیص تقاطع جاده Habib و همکاران [5] و استخراج داده‌های برداری جاده از نقشه‌های رستری Bin and Cheong [3] انجام گرفته است.

در مورد استخراج متن / گرافیک از نقشه‌های رستری، Cao and Tan [4] و Li و همکاران [6] از آستانه سیاه و سفید از پیش تعیین شده برای حذف پیکسل‌های پیش زمینه از نقشه‌های رستری و سپس شناسایی برجسب‌های متن از لایه‌های پس زمینه باقی مانده استفاده کردند. پیکسل‌های جاده پس از شناسایی پیکسل‌های متن تولید می‌شوند. از آنجا که در این روش‌ها، هدف اصلی شناسایی برجسب‌های متن می‌باشد، در نتیجه نقشه‌های رستری بیشتری را برای استخراج داده‌های برداری جاده‌ها پردازش نمی‌کنند. برخی از پژوهش‌های قبلی یک نوع ساده از نقشه‌های رستری را استفاده کردند.

Habib و همکاران [5] تقاطع‌های جاده را از نقشه‌های رستری که تنها حاوی خطوط جاده بوده استخراج کردند.

Itonaga و همکاران [2] یک روش آرامش تصادفی برای استخراج مناطق جاده از نقشه‌های دیجیتالی تولید شده و سپس از عملگر نازک شدن برای استخراج داده‌های برداری جاده‌ها استفاده کردند. خطوط تحریف شده اطراف تقاطع جاده‌ها بر اساس دقت جاده‌ها، با استفاده از محدودیت‌های مشخص شده توسط کاربر مانند عرض جاده تصحیح شده است.

Bin and Cheong [3] پژوهشی بر روی نقشه‌های اسکن شده برای استخراج داده‌های برداری جاده انجام دادند. به جای استفاده از عملگر نازک شدن، آنها در ابتدا خطوط داخلی جاده‌های موازی را تولید و پس از آن برای تولید



داده‌های برداری جاده آنها را با هم متصل کردند. به طور کلی، نتایج استفاده از خطوط داخلی جاده موازی، برای وکتورسازی خطوط اطراف تقاطع‌ها بسیار دقیق است، اما فرآیند استخراج، به پارامترهای مشخص دستی مانند آستانه‌هایی برای بخش‌های داخلی خطوط و تولید تقاطع جاده نیاز دارد. هدف از این پژوهش نیز استخراج داده برداری جاده از تصویر گوگل ارث می‌باشد. در ابتدا پیکسل‌های راه با روش ماشین بردار پشتیبان^۱ استخراج و سپس از روش اسکلت‌بندی^۲ برای بردار سازی آن استفاده شده است.

۳- روش ماشین بردار پشتیبان

ماشین بردار پشتیبانی یکی از روش‌های یادگیری بانظارت (Supervised learning) است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون نشان داده است [7]. مبنای کاری طبقه‌بندی کننده SVM دسته‌بندی خطی داده‌ها است. SVM از یک فن که kernel trick نامیده می‌شود، برای تبدیل داده‌ها استفاده می‌کند و سپس بر اساس این تبدیل، مرز بهینه بین خروجی‌های ممکن را پیدا می‌کند. به عبارت ساده تبدیلات بسیار پیچیده را انجام می‌دهد، سپس مشخص می‌کند چگونه داده‌ها را بر اساس برجسب‌ها یا خروجی‌های تعریف شده، جدا شوند. الگوریتم SVM جز الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود. از الگوریتم SVM، در هر جایی که نیاز به تشخیص الگو یا طبقه‌بندی اشیاء در کلاس‌های خاص باشد می‌توان استفاده کرد. در یک فرآیند یادگیری که شامل دو کلاس می‌باشد، هدف SVM پیدا کردن بهترین تابع برای طبقه‌بندی می‌باشد به نحوی که بتوان اعضای دو کلاس را در مجموعه داده‌ها از هم تشخیص داد. معیار بهترین طبقه‌بندی برای مجموعه داده‌هایی که به صورت خطی قابل تجزیه هستند، به صورت هندسی مشخص می‌شود. ماشین بردار پشتیبان یک روش یادگیری نسبتاً جدید است که اغلب برای طبقه‌بندی باینری استفاده می‌شود. فرض کنید L مشاهده وجود دارد که هر مشاهده شامل زوج‌هایی است که در آن بردار ورودی یک مقدار دو وضعیت (۱- یا +۱) است. ایده اصلی طبقه‌بندی ماشین بردار پشتیبان به نقشه درآوردن داده‌های چند بعدی به یک فضای با بعد بالاتر است، به گونه‌ای که یک ابر صفحه وجود می‌آید که می‌تواند برای تفکیک خطی داده اصلی مورد استفاده قرار گیرد. در نتیجه مرز (حاشیه) بین طبقات مختلف به حداکثر رسیده و از تداخل بین طبقات جلوگیری می‌شود [8]. براساس داده‌های آموزشی برای کلاس‌هایی که تفکیک آنها با استفاده از مدل خطی مشکل است، ماشین بردار پشتیبان به انجام تفکیک بهینه هر دو کلاس می‌پردازد که این امر از طریق تکرار، تبدیل داده‌ها و برازش دادن یک ابر صفحه برای تفکیک این کلاس‌ها در فضای n بعدی است که از مضارب لاگرانژ و توابع هسته (مانند چند جمله‌ای) استفاده می‌شود. ماشین بردار پشتیبان برای انجام استراتژی چند جفتی و چند کلاسه شبیه روش شبکه عصبی مصنوعی است که در آن به یک لایه ورودی و یک لایه خروجی نیاز است. همانطور که اشاره شد، ماشین بردار پشتیبان یا SVM داده‌ها را با توجه به دسته‌های از پیش تعیین شده آنها به یک فضای جدید می‌برد. به گونه‌ای که داده‌ها به صورت خطی (یا ابر صفحه) قابل تفکیک و دسته‌بندی باشند و سپس با یافتن خطوط پشتیبان (صفحات پشتیبان در فضای چند بعدی)، سعی در یافتن معادله خطی دارد که بیشترین فاصله را بین دو دسته ایجاد می‌کند.

۴- اسکلت‌بندی

اسکلت‌بندی فرآیندی برای کاهش مناطق پیش زمینه در یک تصویر باینری برای باقی گذاشتن اسکلتی می‌باشد که تا حد زیادی محدوده و اتصالات منطقه اصلی را حفظ کرده در حالی که بسیاری از پیکسل‌های اصلی پیش زمینه را حذف می‌کند. اسکلت‌بندی، اسکلت ساده یک تصویر باینری را نشان می‌دهد. اسکلت‌بندی با دو روش اصلی تولید

¹ Support Vector Machine

² Skeleton



می‌شود. اول استفاده از نوعی عملگر نازک شدن^۳ به صورت متوالی برای از بین بردن پیکسل‌های مرز (در حالی که بخش‌های خط حفظ شود)، تا زمانی که هیچ نازک شدن بیشتری در نقاط باقی مانده نزدیک اسکلت امکان پذیر نباشد. روش دیگر این است که ابتدا تبدیل فاصله تصویر محاسبه گردد. سپس اسکلت‌بندی در امتداد نقاط انفرادی (یعنی چین‌ها و یا ناپیوستگی انحنايي) در تبدیل فاصله واقع می‌گردد. درست همانطور که انواع مختلفی تبدیل فاصله وجود دارد، انواع مختلفی از الگوریتم اسکلت‌بندی نیز وجود دارد که همه اندکی نتایج متفاوت تولید می‌کنند. با این حال، اثرات کلی همه مشابه بوده و برای اسکلت‌بندی استفاده می‌شوند. اسکلت‌بندی می‌تواند یک نمایش ساده و فشرده از یک شکل را فراهم کند در حالی که بسیاری از ویژگی‌های توپولوژیک و اندازه شکل اصلی را حفظ می‌کند.

استخراج اسکلت‌بندی یک الگو به معنی باریک کردن الگو به نحوی است که شکل کلی الگو از بین نرود. از اینرو اسکلت یک الگو همانند خود الگو باید قابل تشخیص بوده و توسط آن بتوان شکل کلی الگو را حدس زد. بنابراین اسکلت به دست آمده برای یک الگو باید دارای خصوصیات زیر باشد:

✓ به اندازه کافی باریک باشد.

✓ متصل باشد: یعنی فرآیند اسکلت‌بندی نباید باعث تکه تکه شدن اسکلت الگو شود زمانی که این دو شرط برقرار شد، الگوریتم اسکلت‌بندی متوقف می‌شود.

در حالت کلی الگوریتم‌های استخراج اسکلت الگو بر پایه دو استراتژی مختلف هستند. در استراتژی اول از همه پیکسل‌های تصویر و در استراتژی دوم از پیکسل‌های کانتور تصویر برای این منظور استفاده می‌شود. اسکلت‌بندی ویژگی‌های شکل مبتنی بر ناحیه را فراهم می‌کند. این یک عملیات پیش پردازش رایج در تبدیل رستر به بردار و یا در تشخیص الگو می‌باشد. سه روش عمده اسکلت‌بندی وجود دارد:

✓ تشخیص خط الرأس در نقشه فاصله از نقاط مرزی

✓ محاسبه دیاگرام ورونی^۴ تولید شده توسط نقاط مرزی

✓ سایش لایه به لایه که نازک شدن می‌نامند.

در رابطه با استخراج درست اسکلت دو مورد زیر را باید در نظر گرفت:

✓ توپولوژی (حفظ توپولوژی از شی اصلی)

✓ هندسی (اسکلت‌بندی در وسط شی و تغییر ناپذیری تحت تحول مهم ترین عوامل هندسی از جمله انتقال، چرخش، و مقیاس‌پذیری

شکل ۱ مقایسه روش‌های اسکلت‌بندی را نشان می‌دهد.

³ Thining

⁴ Voronoi



method	geometrical	topological
distance transform	yes	no
Voronoi-skeleton	yes	yes
thinning	no	yes

شکل ۱- مقایسه روش‌های اسکلت‌بندی

Distance transformation – ۱-۴

اسکلت‌بندی بر اساس تغییر فاصله نیاز به ۳ مرحله زیر دارد:

الف) تصویر اصلی (باینری) به عناصر عارضه و غیر عارضه تبدیل می‌شود. عناصر عارضه متعلق به مرز شی می‌باشند. ب) نقشه فاصله، جایی که هر عنصر فاصله‌ای به نزدیکترین عنصر عارضه می‌دهد ایجاد می‌شود. ج) خط الرأس به عنوان نقاط اسکلت شناسایی می‌شوند.

Voronoi diagram – ۲-۴

دیاگرام ورونوی روشی برای تقسیم فضا به تعدادی ناحیه می‌باشد. در این دیاگرام به هر مجموعه‌ای از نقاط، ناحیه‌ای اختصاص داده می‌شود. این نواحی سلول‌های ورونوی نامیده می‌شود. برای یک مجموعه از نقاط دیاگرام ورونوی سطح را به مناطقی تقسیم‌بندی می‌کند که برای هر نقطه از مجموعه نقاط یک منطقه تعریف می‌شود. به طوری که تمام نقاط این منطقه به نقطه تولید کننده آن منطقه نزدیکتر می‌باشد. هر دو مورد (توپولوژیکی و هندسی) در مورد اسکلت‌بندی بر اساس دیاگرام ورونوی قابل انجام است، اما این روش به خصوص برای اشیاء بزرگ و پیچیده یک فرآیند گران می‌باشد.

Thinning – ۳-۴

نازک شدن یک عملیات مورفولوژیکی است که برای حذف پیکسل‌های پیش زمینه انتخاب شده از تصاویر باینری استفاده می‌شود و تا حدودی مانند فرسایش^۵ و یا باز کردن^۶ می‌باشد. نازک شدن برای برنامه‌های مختلفی قابل استفاده است، اما به طور خاص برای اسکلت‌بندی مفید می‌باشد. در این حالت معمولاً برای مرتب کردن خروجی آشکارسازهای لبه با کاهش تمام خطوط به ضخامت تک پیکسل استفاده می‌شود. نازک شدن به طور معمول تنها برای تصاویر باینری استفاده می‌شود، و تصویر باینری دیگری را به عنوان خروجی تولید می‌کند. یکی از رایج‌ترین استفاده‌ها از عملگر نازک شدن، کاهش آستانه خروجی یک آشکارساز لبه مانند عملگر سوبل^۷ برای خطوطی با ضخامت تک پیکسل می‌باشد، در حالی که طول کامل این خطوط حفظ می‌کند. یک الگوریتم ساده برای انجام این کار به شرح زیر است:

تمام پیکسل‌ها در مرزهای مناطق پیش زمینه (یعنی نقاط پیش زمینه که حداقل یک همسایه پس زمینه دارند) را در نظر بگیرید. هر نقطه‌ای که دارای بیش از یک همسایه پیش زمینه بوده حذف گردیده، و این کار تا زمانی که منطقه شامل آن پیکسل بدون ارتباط محلی شود و همگرایی ایجاد گردد تکرار می‌شود. این روش باعث از بین بردن مرزهای اشیاء پیش زمینه تا حد ممکن می‌گردد، اما پیکسل‌ها در انتهای خطوط تأثیر نمی‌گذارد.

⁵ Erosion

⁶ Opening

⁷ Sobel



نازک شدن دارای کاربردهای زیر می باشد:

- ✓ حفظ توپولوژی (حفظ توپولوژی جسم اصلی)
 - ✓ حفظ شکل (ویژگی های قابل توجهی برای شناخت شی و یا طبقه بندی استخراج می کند.
 - ✓ اسکلت بندی را در وسط شی انجام می دهد.
 - ✓ اسکلتی با عرض یک پیکسل تولید می کند.
- در پژوهش حاضر از روش نازک شدن استفاده گردیده است.


۵- نتایج

برای ارزیابی و اجرای روش به کار گرفته شده، به صورت خودکار روش SVM و اسکلت بندی در محیط Matlab صورت گرفته است. همانطور که اشاره شد تصاویر استفاده شده در این پژوهش، تصاویر گوگل ارث می باشند. که در ابتدا آن را دانلود و سپس ژئورفرنس گردید.

شکل ۲ (الف) تصویر اصلی و شکل ۲ (ب) خروجی حاصل از روش SVM را نشان می دهد. همانطور که مشخص است این روش، تصویر را با دقت بالایی طبقه بندی کرده و راه را به جز برخی نواحی با دقت بالایی استخراج کرده است. طبقه بندی تصویر با روش SVM به خصوص راه در محل پیچ ها و تقاطع ها از دقت کمتری برخوردار می باشد و پیکسل های غیره راه به پیکسل های راه و برعکس اختصاص داده شده است.




شکل ۲ (الف)



شکل ۲ (ب)

شکل ۲ نیز وکتور استخراج شده با روش اسکلت بندی را نشان می دهد. همانطور که مشخص است روش اسکلت بندی از دقت بالایی برخوردار می باشد.



شکل ۳. داده وکتور استخراج شده با روش اسکلت بندی

برای ارزیابی دقت، داده وکتور راه و همچنین نقاط تقاطع و ابتدا و انتها به عنوان یک مرجع بطور دستی استخراج شده تا بتوان از آن برای ارزیابی دقت استفاده کرد. از دو معیار Residual و RMSE⁸ برای ارزیابی دقت استفاده شده است. خطای Residual (باقیمانده) نشان دهنده فاصله در واحدهای نقشه بین محل نقطه تصویر که توسط معادله چند جمله‌ای مناسب محاسبه شده و محل نقطه مشخص شده بروی داده GIS می‌باشد. خطای RMSE، تفاوت میان مقدار پیش‌بینی شده توسط مدل آماری و مقدار واقعی می‌باشد. RMSE یک ابزار خوبی برای مقایسه خطاهای پیش‌بینی توسط یک مجموعه داده است و برای مقایسه چند مجموعه داده کاربرد ندارد. مقدار RMSE را می‌توان توسط رابطه (۱) محاسبه کرد.

$$RMSE = \sqrt{\frac{(x_{target}-x_{reference})^2+(y_{target}-y_{reference})^2}{n}} \quad (1)$$

جدول ۱ برآورد میزان خطای Residual و RMSE را برای نقاط انتخاب شده نشان می‌دهد. همانطور که مشاهده می‌شود میزان خطای Residual به جز برخی نقاط مقدار آن پایین می‌باشد. مقدار خطای RMSE نیز ۶/۷۰۵ متر می‌باشد و این مقدار خطا نشان می‌دهد که روش پیشنهادی از دقت مناسبی در بردارسازی داده برخوردار می‌باشد.

جدول ۱. ارزیابی دقت

نقاط	خطای Residual
۱	۲/۵۳۸
۲	۳/۷۱۴
۳	۱۱/۵۰۸
۴	۲/۷۷۴
۵	۶/۴۳۹
۶	۳/۴۹۷
۷	۹/۶۷۸
۸	۷/۲۰۵
خطای RMSE	۶/۷۰۵

⁸ Root-Mean-Square Error



۵- نتیجه گیری

در این پژوهش یک روش بردار سازی داده جاده به صورت خودکار و در محیط Matlab ارائه شده است. در ابتدا پیکسل‌های جاده از تصویر با روش SVM استخراج و در نهایت از روش اسکلت‌بندی برای بردارسازی استفاده گردید. در پژوهشی که Chiang and Knoblock [9] برای استخراج خودکار داده وکتور از نقشه‌های رستری ارائه دادند، دقت ۹۳.۲ درصد را بدست آوردند. همچنین آنها، میانگین خطای RMSE را برابر با ۳/۰۵ متر بدست آوردند که دقت بالایی می‌باشد. در این پژوهش نیز مقدار خطای RMSE، ۶/۷۰۵ متر بدست آمده است. به دلیل اینکه استخراج پیکسل‌های تصویر در بعضی جاها به درستی استخراج نشده‌اند، در نتیجه استخراج بردار جاده نیز دقت آن نسبت به پژوهش ذکر شده در بالا کمتر می‌باشد. ولی در مجموع دقت استخراج داده وکتور جاده بالا بوده و این بیانگر موفقیت کلی روش پیشنهادی در فرآیند بردارسازی می‌باشد.

منابع

- [1] C.C. Chen, C. A. Knoblock, and C. Shahabi, "Automatically and accurately conating raster maps with orthoimagery", *GeoInformatica*, Vol. 12(3), pp. 377-410, 2008.
- [2] W. Itonaga, I. Matsuda, N. Yoneyama, and S. Ito, "Automatic extraction of road networks from map images", *Electronics and Communications in Japan (Part II: Electronics)*, Vol. 86(4), pp. 62{72, 2003.
- [3] D. Bin, and W.K. Cheong, "A system for automatic extraction of road network from maps", In *Proceedings of the IEEE International Joint Symposia on Intelligence and Systems*, pp. 359-366, 1998.
- [4] R. Cao, and C.L. Tan, "Text/graphics separation in maps", In *Proceedings of the Fourth GREC Workshop*, pp. 167-177, 2002.
- [5] A. Habib, R. Uebbing, and A. Asmamaw, "Automatic extraction of road intersections from raster maps", *Project Report Center for Mapping, The Ohio State University*, 1999.
- [6] L. Li, G. Nagy, A. Samal, S.C. Seth, and Y. Xu, "Integrated text and line-art extraction from a topographic map", *IJDAR*, Vol. 2(4), pp. 177-185, 2000.
- [7]- V.N. Vapnik, "The Nature of Statistical Learning Theory", *Spring- Verlag, New York*, p. 188,1995.
- [8]- R. Zhang, D. Sun, Y. Yu, and M.D. Goldberg, "Mapping Nighttime Flood from MODIS Observations Using Support Vector Machines", *Photogrammetric Engineering & Remote Sensing*, Vol. 78, pp. 1151-1161,2012.
- [9] Y.Y. Chiang, and C.A. Knoblock, "A method for automatically extracting road layers from raster maps", In *Proceedings of the Tenth ICDAR*, 2009.



Road vector data extracted from Google Earth images

Abdollahi, A. ^{*1}, Riahi Bakhtiari, H.R. ², Rezaeian, H. ³, Torahi, A.R. ⁴

1- Ms. student of remote sensing in Department of GIS, College of Geography, Karazmi University of Tehran

2- Assistant professor in Department of GIS, College of Geography, Karazmi University of Tehran

3- Assistant professor in Department of GIS, College of Geography, Karazmi University of Tehran

4- Assistant professor in Department of GIS, College of Geography, Karazmi University of Tehran

Abstract

Because of the availability of high resolution scanners and low cost as well as the Internet, we can scan a large number of maps in raster format obtained from various sources. Thus maps of road networks as well as raster maps, an important source of road vector data for areas that are not easily accessible road vector data. In addition, the road vector data can be recorded features for maps and other geographic data such as images, and creating a unified view of heterogeneous geographical data sets used. In this paper, a method to extract the skeleton road vector data from Google Earth image is used. The road pixels extracted from the image using support vector machine and the skeleton method for vectorized is used. Survey results show that the root mean square error, is equal to 6.705 meters. As a result of road vector data extraction accuracy is high and this is the success of the proposed technique Vectorization process.

Keywords: Vectorization, Skeleton, Support Vector Machine