

مروری بر کاربرد فیلتر کالمن در ردگیری اشیاء

مهرشاد مهرانفرد
کارشناسی ارشد مخابرات سیستم
m.mehranfard1379@gmail.com

امیرحسین حسنوند
کارشناسی ارشد مخابرات سیستم
mr.amirhosein.hasanvand1@gmail.com

علی هادیان
کارشناسی ارشد مخابرات سیستم
mahan.hadian@hotmail.com

چکیده: این مقاله کاربردهای فیلتر کالمن و انواع توسعه یافته آن را در ردگیری اشیاء بررسی می کند. همچنین این مقاله به بررسی روش هایی مانند فیلتر کالمن تطبیقی (AKF)، فیلتر کالمن غیرمستقیم (UKF)، فیلتر کالمن گسترش یافته (EKF) و فیلتر کالمن عمیق (DKF) در ردگیری تک شیء (SOT) و چند شیء (MOT) می پردازد. عملکرد این روش ها در چندین بنچمارک و مجموعه داده های مختلف ارزیابی شده است. نتایج حاکی از آن است که AKF در محیط های شلوغ، UKF در سیستم های غیرخطی و DKF در سناریوهای پیچیده با یادگیری عمیق، دقت بهتری دارند. هر روش در برابر چالش هایی مانند انسداد، حرکت غیرخطی و نویز محیطی نقاط قوت و ضعف خاص خود را نشان می دهد. این مقاله کارایی روش ها را مقایسه کرده و نقش فیلتر کالمن در غلبه بر موانع ردگیری را تحلیل می کند. همچنین، چالش های موجود و جهت گیری های آینده، از جمله ادغام با یادگیری عمیق، بحث شده است. این پژوهش یک مقایسه جامع برای روش های نوین ردگیری اشیاء ارائه می دهد.

کلید واژه: فیلتر کالمن، ردگیری اشیاء، بینایی ماشین، یادگیری عمیق

(۱) مقدمه

مانند فیلتر کالمن، به دلیل سادگی، کارایی محاسباتی، و توانایی در مدل سازی دینامیک های خطی سیستم ها، همچنان جایگاه ویژه ای در این حوزه دارند. فیلتر کالمن، که در اصل برای مسائل تخمین حالت در سیستم های کنترل توسعه یافته بود، با توانایی خود در ترکیب پیش بینی های مدل و مشاهدات حسگری، راه حلی قدرتمند برای ردگیری اشیاء در شرایط نویزی و پویا ارائه می دهد.

هدف از این مقاله، ارائه یک مرور بر کاربردهای فیلتر کالمن در ردگیری اشیاء است. ما در این مطالعه، ابتدا انواع فیلتر کالمن را به خلاصه شرح داده، سپس مبانی و انواع ردگیری اشیاء و در نهایت کاربردها و جایگاه فیلتر کالمن را در این حوزه بررسی می کنیم. همچنین، نقاط قوت و ضعف چندین روش فیلتر کالمن در زمینه ردگیری اشیاء مورد مقایسه و تحلیل قرار خواهد گرفت تا دیدگاهی کامل برای پژوهشگران و مهندسان فراهم آید. این مقاله می تواند به عنوان نقطه شروعی برای توسعه روش های ترکیبی (Hybrid) مبتنی بر فیلتر کالمن و یادگیری ماشین در آینده عمل کند.

ساختار مقاله:

این مقاله با هدف بررسی کاربردهای فیلتر کالمن در ردگیری اشیاء، به صورت زیر سازمان دهی شده است:

پیش زمینه و مفاهیم اساسی: در این قسمت، مفاهیم پایه ای مرتبط با فیلتر کالمن و ردگیری اشیاء، شامل انواع رایج و مشکلاتشان، تشریح می شود تا زمینه لازم برای فهم بخش های بعدی فراهم گردد.

ردگیری اشیاء (Object Tracking) یکی از مسائل بنیادین و کلیدی در حوزه های مختلف علوم کامپیوتر و مهندسی است که به دلیل کاربردهای گسترده در زندگی مدرن، توجه زیادی را به خود جلب کرده است. این فرآیند شامل شناسایی و دنبال کردن پیوسته یک یا چند شیء در یک دنباله زمانی، معمولاً از طریق داده های تصویری یا حسگری، می شود. اهمیت ردگیری اشیاء در حوزه هایی نظیر رباتیک، سیستم های نظارتی، پردازش ویدئو، و حتی کاربردهای نوظهور مانند خودروهای خودران و واقعیت افزوده، غیرقابل انکار است. با این حال، چالش های متعددی از جمله نویز حسگرها، تغییرات نوری، انسداد (Occlusion)، و پیچیدگی های حرکتی اشیاء، این مسئله را به یکی از دشوارترین مسائل در علوم داده و یادگیری ماشین تبدیل کرده است. در پردازش ویدئو، این فناوری به بهبود کیفیت تجربه کاربری در برنامه هایی مانند ویرایش خودکار ویدئو، تشخیص حرکات، و تحلیل محتوای بصری کمک می کند. علاوه بر این، در کاربردهای پیشرفته تر مانند خودروهای خودران، ردگیری اشیاء برای شناسایی موانع، پیش بینی مسیر حرکت عابران پیاده، و تصمیم گیری ایمن در شرایط پویا، از اهمیت بسزایی برخوردار است. با وجود پیشرفت های چشمگیر در روش های مبتنی بر یادگیری عمیق برای ردگیری اشیاء، محدودیت هایی نظیر نیاز به حجم عظیم داده های آموزشی، پیچیدگی محاسباتی، و عدم تعمیم پذیری به سناریوهای ناشناخته، همچنان وجود دارد. در مقابل، روش های کلاسیک مبتنی بر مدل های ریاضی،

جدول ۱: خلاصه‌ای از انواع تخمین‌زن‌های حالت بر پایه فیلتر کالمن

ویژگی‌ها	هزینه محاسباتی	توزیع مفروض	مدل سیستم	تخمین زن حالت
نمی‌تواند سیستم‌های بیش از حد پیچیده، با تعداد متغیر بالا را پشتیبانی کند	کم	گاوسی	خطی	فیلتر کالمن (KF)
این روش برای سیستم‌های توان بالا مناسب نیست، و به دلیل خطی‌سازی ممکن است واگرایی رخ دهد	کم	گاوسی	خطی موضعی	فیلتر کالمن گسترش یافته (EKF)
با افزایش تعداد متغیرهای حالت، عملکرد کاهش می‌یابد.	متوسط	گاوسی	غیر خطی	فیلتر کالمن غیر مستقیم (UKF)
با استفاده از شبکه‌های عصبی، وابستگی‌های زمانی و عدم قطعیت‌ها را در داده‌های تربیتی مدل‌سازی می‌کند.	زیاد	گاوسی	غیر خطی	فیلتر کالمن عمیق (DKF)
با ادغام یک شبکه عصبی بازگشتی در چارچوب فیلتر کالمن، تخمین وضعیت در سیستم‌های غیرخطی با اطلاعات ناقص ممکن می‌شود.	متوسط	گاوسی	غیر خطی	کالمن نت (Kalman Net)
با استفاده از یک ابرشبکه، پارامترهای شبکه عصبی را بدون نیاز به آموزش مجدد، به‌طور خودکار بر اساس تغییرات سیستم تنظیم می‌کند.	زیاد	گاوسی تطبیقی	غیر خطی	کالمن نت تطبیقی (AKNet)

این فیلتر برای برآورد تغییرات حالت در سیستم‌های مختلف با متغیرهای زمانی چندگانه مناسب است. فیلتر کالمن پایه‌گذار توسعه نظریه کنترل مدرن و پردازش سیگنال در زمان واقعی بوده است. امروزه، KF در برآورد و موقعیت‌یابی، ردگیری اهداف، ارتباطات و پردازش سیگنال، پردازش تصاویر دیجیتال، پیش‌بینی زلزله و بسیاری دیگر از زمینه‌ها در مهندسی توسعه یافته است. بنابراین، این فیلتر یکی از ابزارهای رایج در اطلاعات، کنترل و اتوماسیون فرآیندها به شمار می‌رود. KF کاربردهای زیادی در علم و فناوری، از جمله ردگیری و نظارت بر وسایل نقلیه، به ویژه هواپیماها و فضاپیماها، دارد. KF مفاهیم گسترده‌ای درباره سری‌های زمانی، پردازش سیگنال و اقتصادسنجی را نمایان می‌سازد. این فیلتر به عنوان یکی از مفاهیم پایه در برنامه‌ریزی و نظارت بر ربات‌ها و مدل‌سازی سیستم‌های عصبی در نظر گرفته

معیارهای ارزیابی و دیتاست‌ها: این بخش معیارهای استاندارد ارزیابی عملکرد ردگیری (مانند دقت و پایداری) و دیتاست یا بنچمارک‌های رایج در این حوزه را معرفی می‌کند.

تحلیل و مقایسه: در این قسمت، استفاده مقالات مختلف از انواع فیلتر کالمن در زمینه‌های مختلف ردگیری اشیاء مقایسه شده و نقاط قوت و ضعف آن‌ها در سناریوهای مختلف تحلیل می‌شود.

نتیجه‌گیری: در پایان، یافته‌های اصلی مقاله جمع‌بندی شده و اهمیت آن‌ها در پیشرفت حوزه ردگیری اشیاء برجسته می‌شود.

۲) پیش‌زمینه و مفاهیم اساسی:

۱-۲- فیلتر کالمن:

فیلتر کالمن (KF) که به عنوان تخمین‌زننده مربعی خطی نیز شناخته می‌شود، وضعیت آینده یک سیستم را بر اساس وضعیت‌های قبلی و کنونی پیش‌بینی می‌کند. فیلتر کالمن با یک معادله بیان می‌شود، اما به دو مرحله، شامل پیش‌بینی و به‌روزرسانی تقسیم می‌شود. در مرحله پیش‌بینی، تخمینی برای وضعیت کنونی که از یک سری تخمین‌های وضعیت در بازه‌های قبلی استفاده می‌کند، به دست می‌آید. این تخمین پیش‌بینی‌شده، دانش قبلی محسوب می‌شود زیرا به تخمین‌های قبلی مربوط می‌شود و هیچ مشاهده‌ای برای سیستم در وضعیت کنونی وجود ندارد. در مرحله به‌روزرسانی، تخمین پیشین با مشاهدات کنونی ترکیب می‌شود تا تخمینی از وضعیت کنونی و وضعیت‌های آینده سیستم ارائه شود. این مراحل معمولاً به طور متناوب تکرار می‌شوند؛ یعنی پیش‌بینی تا مشاهده بعدی انجام می‌شود و سپس با استفاده از مشاهدات کنونی به‌روزرسانی صورت می‌گیرد. اگر در یک بازه زمانی هیچ مشاهده‌ای وجود نداشته باشد، چندین پیش‌بینی به‌روزرسانی، انجام خواهد شد تا مشاهده بعدی حاصل شود. به همین ترتیب، اگر چندین مشاهده مستقل در یک بازه زمانی انجام شود، چندین به‌روزرسانی با ماتریس‌های مختلف بر اساس هر مشاهده به دست خواهد آمد.

فیلتر کالمن می‌تواند برای برآورد پارامترهای سیستم استفاده شود و هدف آن کاهش خطای نویز در حین برآوردی است که در شرایط خاص، کوواریانس خطا را به حداقل می‌رساند.

"MNIST", نشان داده و در پرونده‌های پزشکی به کار رفته است که تطبیق‌پذیری آن را نشان می‌دهد. [۴]

کالمن نت (KalmanNet):

کالمن نت یک شبکه عصبی بازگشتی را در چارچوب فیلتر کالمن (KF) ادغام می‌کند و امکان تخمین وضعیت در زمان واقعی را در سیستم‌هایی با دینامیک غیرخطی و اطلاعات ناقص فراهم می‌سازد. این رویکرد ترکیبی، تفسیرپذیری فیلترهای کالمن سنتی را حفظ کرده و در عین حال با یادگیری مبتنی بر داده، قابلیت تطبیق‌پذیری را افزایش می‌دهد و در شرایطی که مدل‌ها دچار عدم تطابق هستند، عملکرد بهتری نسبت به روش‌های کلاسیک فیلترینگ ارائه می‌دهد. [۵]

فیلترهای کالمن تطبیقی (Adaptive Kalman Filters):

فیلترهای کالمن تطبیقی نمایانگر یک تحول در روش‌های تخمین حالت هستند که فیلتر کالمن سنتی را با روش‌های تطبیقی ترکیب می‌کنند تا عدم قطعیت‌های مدل و محیط‌های پویا را مدیریت کنند. این فیلترها پارامترهای خود را در زمان واقعی تنظیم می‌کنند و عملکرد را در سناریوهایی که مدل‌های سیستم به‌طور کامل شناخته نشده یا در حال تغییر هستند، بهبود می‌بخشند.

عملکرد مطلوب فیلتر کالمن به دانش دقیق در مورد ماتریس‌های کوواریانس نویز فرآیند (Q) و نویز اندازه‌گیری (R) بستگی دارد. در بسیاری از کاربردهای عملی، این ماتریس‌ها به‌طور دقیق شناخته نشده‌اند یا با گذشت زمان تغییر می‌کنند، که می‌تواند منجر به کاهش عملکرد یا حتی واگرایی فیلتر شود.

فیلتر کالمن سنتی با پارامترهای ثابت Q و R کار می‌کند. این رویکرد در شرایطی که مشخصات نویز فرآیند و نویز اندازه‌گیری به خوبی شناخته شده و ثابت باشند، مناسب است. با این حال، در بسیاری از کاربردهای واقعی، این شرایط برقرار نیست. برای مثال ممکن است: مشخصات نویز ناشناخته باشد، مشخصات نویز با زمان تغییر کند و یا مدل سیستم دقیق نباشد؛ در چنین شرایطی، فیلتر کالمن تطبیقی (Adaptive Kalman Filter) به عنوان راه حلی برای بهبود عملکرد فیلتر پیشنهاد می‌شود. هدف اصلی فیلتر

می‌شود. با توجه به تأخیر زمانی بین ارسال دستورات و دریافت پاسخ‌ها، استفاده از KF امکان برآورد وضعیت‌های مختلف یک سیستم را فراهم می‌کند.

۲-۲. انواع فیلتر کالمن:

فیلتر کالمن گسترش‌یافته (Extended Kalman Filter):

فیلتر کالمن بر روی مدل‌های خطی کار می‌کند و از آنجا که بیشتر سیستم‌ها غیرخطی هستند، این فیلتر به فیلتر کالمن گسترش‌یافته (EKF) اصلاح شده است. این فیلتر بر روی سیستم‌های غیرخطی کار می‌کند. EKF به‌طور تقریبی مدل غیرخطی را حول تخمین فعلی خطی‌سازی می‌کند و سپس از فیلتر کالمن خطی برای پیش‌بینی‌های بیشتر تخمین استفاده می‌کند. (برای اطلاعات بیشتر درباره مبنای ریاضی فیلتر کالمن به منبع [۲] و برای اطلاعات بیشتر درباره مدل‌های فیلتر کالمن به مرجع [۱] مراجعه کنید)

فیلتر کالمن غیرمستقیم (unscented kf) (UKF):

عملکرد UKF از EKF بهتر است زیرا به جای استفاده از یک نقطه، از چندین نقطه به نام نقاط سیگمای وزن‌دار استفاده می‌کند، که این کار تقریب بهتری را فراهم می‌آورد. UKF در دسته فیلترهای کالمن نقطه سیگما یا فیلتر کالمن رگرسیون خطی قرار می‌گیرد. نقاط در توزیع گاوسی کنونی از طریق یک تابع غیرخطی به توزیع گاوسی پیش‌بینی‌شده نگاشته می‌شوند، که به این ترتیب میانگین و واریانس جدید توزیع گاوسی پیش‌بینی‌شده قابل محاسبه است. UKF شامل فرآیند تبدیل غیرمستقیم، محاسبه مجموعه نقاط سیگما و تخصیص وزن‌ها به هر نقطه سیگما و انتقال این نقاط از طریق تابع غیرخطی، محاسبه توزیع گاوسی پیش‌بینی‌شده و در نتیجه یافتن میانگین و واریانس پیش‌بینی‌شده است. تعداد نقاط سیگما به ابعاد سیستم بستگی دارد.

۳-۲. فیلترهای کالمن عمیق:

فیلتر کالمن عمیق (Deep Kalman Filter=DKF):

این مدل از روش‌های استنتاج واریانس برای یادگیری مدل‌های مولد عمیق استفاده می‌کند و به‌طور مؤثر وابستگی‌های زمانی و عدم قطعیت‌ها را در داده‌های ترتیبی ثبت می‌کند. فیلتر کالمن عمیق توانایی خود را در مدل‌سازی مجموعه داده‌های پیچیده، مانند مجموعه داده "Healing"

باشند، چالش برانگیز است.

۳-۱- انواع ردگیری اشیاء:

ردگیری تک شیء (SOT = Single Object Tracking):

ردگیری تک شیء به معنای ردگیری یک هدف واحد و خاص در طول یک دنباله ویدیویی، حتی در صورت حضور اشیاء دیگر در تصویر یا ویدیو، است.

• فرآیند ردگیری با راه اندازی دستی آغاز می شود و شیء مورد نظر در فریم اول شناسایی می شود.

• سپس ردیاب به طور مداوم موقعیت شیء را با استفاده از تکنیک های ردگیری مبتنی بر ظاهر یا حرکت به روزرسانی می کند.

ردگیری تک هدفه در کاربردهایی مانند شناسایی حرکات، نظارت بر حیات وحش و ردگیری اشیاء با استفاده از پهنپاها مفید است. با این حال، از آنجایی که نیاز به راه اندازی دستی دارد و نمی تواند اشیاء جدیدی که در صحنه ممکن است ظاهر شوند را مدیریت کند، برای سناریوهایی که اشیاء متعدد وارد یا خارج از میدان دید می شوند، ایده آل نیست.

ردگیری اشیاء چند هدفه (MOT = Multi Object Tracking):

ردگیری چند هدفه یک شکل پیشرفته از ردگیری است که در آن چندین شیء شناسایی شده، به هر یک شناسه منحصر به فرد اختصاص داده شده و در طول یک دنباله ویدیویی ردگیری می شوند.

• ردگیری چند هدفه در سناریوهایی مانند رانندگی خودکار، که خودروها و عابران پیاده باید به طور مداوم برای جلوگیری از تصادف ردگیری شوند، حیاتی است.

چالش های اساسی در ردگیری اشیاء و راه های غلبه بر آنها:

هرچند یادگیری عمیق به طور قابل توجهی ردگیری اشیاء را بهبود بخشیده است، اما همچنان چندین دشواری اساسی کارایی و دقت آن را محدود می کند. این چالش ها ناشی از شرایط دنیای واقعی مانند حرکت سریع اشیاء، نویز محیطی، انسدادها و تغییرات مقیاس هستند. غلبه بر این دشواری ها نیازمند مدل های ردیابی پیشرفته، استخراج ویژگی های مقاوم

کالمن تطبیقی، تخمین پویای ماتریس های کوواریانس Q و R برای انعکاس بهتر شرایط واقعی سیستم است.

یک پیشرفت قابل توجه در زمینه فیلتر کالمن تطبیقی، کالمن نت تطبیقی (Adaptive KalmanNet=AKNet) است که توسط Revach معرفی شده است. کالمن نت تطبیقی چارچوب کالمن نت را با اضافه کردن یک ابرشبکه (hypernetwork) که پارامترهای شبکه عصبی را بر اساس یک پارامتر مضمون به نام "وضعیت جهان" (State of the world=SoW) تنظیم می کند، گسترش می دهد. این طراحی به فیلتر این امکان را می دهد که بدون نیاز به آموزش مجدد، به سرعت به تغییرات در مدل فضا-حالت سازگار شود، و محدودیت های فیلترهای مدل سنتی که نسبت به عدم تطابق مدل حساس هستند را برطرف می کند. با بهره گیری از رویکردهای مبتنی بر مدل و یادگیری مبتنی بر داده، کالمن نت تطبیقی عملکرد قوی ای در شرایط مختلف به دست می آورد. [۶]

۳- ردگیری اشیاء:

درک ردگیری اشیاء: اصول و کاربردها:

ردگیری اشیاء یک وظیفه اساسی در بینایی ماشین (کامپیوتر) است که شامل شناسایی یک شیء در یک ویدیو و ردگیری مداوم مسیر آن در چندین فریم می باشد.

ردگیری اشیاء یک وظیفه اساسی در بینایی ماشین (کامپیوتر) است که شامل شناسایی یک شیء در یک ویدیو و ردگیری مداوم مسیر آن در چندین فریم می باشد. هدف اصلی ردگیری اشیاء، حفظ شناسایی مستمر اشیاء در حین حرکت، تغییر جهت یا مواجهه با انسداد است. این فناوری در زمینه های مختلفی از جمله رانندگی خودکار، نظارت، تحلیل ورزشی و صنایع رباتیک که نیاز به نظارت و تصمیم گیری بلادرنگ (زمان واقعی) دارد، بسیار حیاتی است. برخلاف شناسایی ساده اشیاء که اشیاء را در فریم های مستقل و مجزا شناسایی می کند، ردگیری اشیاء بر حفظ تداوم تمرکز دارد و اطمینان حاصل می کند که یک شیء خاص به طور مداوم در طول زمان شناسایی می شود. این کار به ویژه در محیط های دینامیکی، جایی که اشیاء ممکن است به طور غیرقابل پیش بینی حرکت کنند، به دلیل نوع انتشار نور یا انسداد تغییر ظاهر دهند یا با سایر اشیاء در صحنه تعامل و تداخل داشته

برای مقابله با این چالش‌ها، تکنیک‌های کسر پس‌زمینه مانند مدل‌های ترکیبی گاوسی (GMM)، ViBe (استخراج‌کننده پس‌زمینه بصری=Visual Background Extractor) و آستانه‌گذاری تطبیقی استفاده می‌شوند. همچنین، مدل‌های تقسیم‌بندی مبتنی بر یادگیری عمیق، مانند U-Net و DeepLab، با جداسازی دقیق اشیاء از پس‌زمینه، به بهبود ردیابی کمک می‌کنند.

تغییرات مقیاس اشیاء و اعوجاج‌های زاویه‌دید:

اشیاء در یک صحنه ممکن است به دلیل تغییرات پرسپکتیو (زاویه‌دید)، حرکت دوربین یا اثرات زوم در مقیاس‌ها و جهت‌های مختلف ظاهر شوند. این تغییرات باعث می‌شود که الگوریتم‌های ردیابی، به ویژه وقتی که شیء مورد نظر به دوربین نزدیک‌تر یا از آن دورتر می‌شود، نتوانند به طور مداوم اشیاء را شناسایی کنند.

مشکل کلیدی ناشی از تغییرات مقیاس، عدم موفقیت در تشخیص اشیاء کوچک، اشیائی که تنها چند پیکسل در یک فریم را اشغال می‌کنند، است؛ که ممکن است توسط الگوریتم ردگیری نادیده گرفته شوند.

برای کاهش این مشکل، مدل‌های مدرن ردگیری اشیاء تکنیک‌های استخراج ویژگی چند مقیاسی را به کار می‌برند، از جمله: هرم ویژگی.

با استفاده از هرم‌های تصویری و شبکه‌های ادغام ویژگی، ردگیرها می‌توانند به طور مؤثری اشیاء در مقیاس‌های متعدد را کنترل کنند و به این ترتیب، مقاومت ردگیری را بهبود بخشند.

انسداد و ناپدید شدن اشیاء:

انسداد زمانی رخ می‌دهد که یک شیء به طور موقت توسط شیء دیگری مسدود شود، که منجر به شکست در ردگیری یا از دست دادن هویت می‌شود. این مشکل به ویژه در محیط‌های شلوغ، رانندگی خودکار و ردگیری در ورزش که اشیاء به طور مکرر با هم تعامل و همپوشانی دارند بحرانی است. انواع انسداد شامل: انسداد جزئی و انسداد کامل است. الگوریتم‌های ردگیری سنتی معمولاً در سناریوهای انسداد شکست می‌خورند و باعث می‌شود که شیء ردگیری شده گم شود و یا هویت جدیدی به آن اختصاص یابد. برای حل این

و تکنیک‌های پردازش بهینه‌شده است. در زیر، به بررسی مهم‌ترین مسائل در ردیابی اشیاء و راه‌حل‌های توسعه‌یافته برای مقابله با آن‌ها می‌پردازیم.

سرعت ردگیری و کارایی محاسباتی:

ردگیری اشیاء بلادرنگ (زمان واقعی) برای اطمینان از ردیابی بدون تأخیر و با دقت نیازمند پردازش با سرعت بالاست. این چالش به‌ویژه در کاربردهایی مانند رانندگی خودکار، نظارت ویدیویی و رباتیک محسوس است، جایی که حتی کوچک‌ترین تأخیر در شناسایی اشیاء می‌تواند عواقب شدیدی داشته باشد.

عوامل اصلی مؤثر بر سرعت ردگیری شامل موارد زیر است:

- پیچیدگی معماری‌های شبکه عصبی - مدل‌های یادگیری عمیق با دقت بالا معمولاً به منابع محاسباتی قابل توجهی نیاز دارند که منجر به افزایش زمان پردازش می‌شود.
- محدودیت‌های نرخ فریم - پردازش ویدیوها با نرخ فریم بالا نیازمند الگوریتم‌هایی با بهینه‌سازی بالاست.
- محدودیت‌های سخت‌افزاری - در حالی که GPUهای قوی مدل‌های یادگیری عمیق را تسریع می‌بخشند، در دنیای واقعی معمولاً به سیستم‌هایی که فاقد کارت گرافیک مجزا اند و قدرت محاسباتی محدودی دارند، وابسته هستند.

برای بهبود سرعت ردگیری، محققان از معماری‌های CNN سبک مانند MobileNet و YOLO و همچنین شناسگرهای مبتنی بر ناحیه مانند Faster R-CNN استفاده می‌کنند که فرآیند شناسایی را بهینه می‌کند. تکنیک‌هایی مانند هرس (pruning)، کم‌سازی (quantization) و تقطیر مدل (model distillation) نیز به کاهش بار محاسباتی در حالی که دقت حفظ می‌شود، کمک می‌کنند.

پیچیدگی پس‌زمینه و نویز محیطی:

یکی از مشکلات عمده در ردگیری اشیاء، تمایز بین شیء هدف و پس‌زمینه شلوغ و یا دینامیکی است. عناصر پس‌زمینه متحرکی مانند برگ‌ها یا عنصاری که شبیه شیء ردیابی شده هستند، می‌توانند منجر به تشخیص‌های نادرست شوند و دقت ردیابی را کاهش دهند.

طبق بررسی‌های انجام شده، محبوب‌ترین معیار سنجش، معیار مجذور مربع خطای متوسط: RMSE (Root Mean Square Error) است که به صورت زیر تعریف می‌شود:

$$RMSE = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N (x_i - \hat{x}_i)^2 \right)} \quad (1)$$

علاوه بر این، نمره موفقیت (Success score=SS) و نمره دقت (Precision Score=PS) برای ارزیابی درصد فریم‌های موفق در ردگیری استفاده می‌شوند.

برای نمره دقت، یک فریم به‌طور دقیق ردگیری شده در نظر گرفته می‌شود اگر خطای موقعیت مرکز (CLE=Center location error) زیر یک آستانه تعریف شده باشد. CLE به عنوان میانگین فاصله اقلیدسی بین موقعیت مرکز پیش‌بینی شده هدف و واقعیت محاسبه می‌شود. همپوشانی مورد انتظار متوسط (EAO=Expected Average Overlap) میزان همپوشانی‌های بدون بازنشانی مورد انتظار یک ردگیر را در یک دنباله اندازه‌گیری می‌کند. در نهایت، فریم بر ثانیه سرعت ردگیر ارزیابی شده را ارائه می‌دهد.

۵- دیتاست و بنچمارک:

در زمینه ردگیری تک هدفه، یک تحلیل از تعدادی مقاله در زمینه SOT انجام شد و مورد استفاده ترین بنچمارک‌ها شناسایی شدند. پرکاربردترین بنچمارک‌ها شامل: Object Tracking Benchmark (OTB) - Car4 benchmark - KITTI بودند.

با تمرکز به حوزه ردگیری چند هدفه (MOT)، مشخص شد که اکثر مقالات از بنچمارک چالش ردگیری چند شیء (Multiple Object Tracking Challenge) استفاده کرده‌اند، پس آن از دیتاست‌های دیگری مانند SWIR Videos، UA-DETRAC و... استفاده شده است. بنچمارک MOT²⁰ با هدف ارائه یک پایگاه قوی برای مقایسه‌ای منصفانه بین الگوریتم‌های ردگیری چند هدفه در سال ۲۰۱۵ راه‌اندازی شده و هر سال به‌روز رسانی می‌شود و شامل مجموعه‌ای وسیع از داده‌های چالش‌برانگیز موجود و جدید است که به همراه تشخیص‌های پیش‌پردازش شده برای هر دنباله ارائه می‌شود. این بنچمارک به دو بخش آموزش و آزمایش تقسیم شده است. همچنین این بنچمارک دارای ابزاری جامع برای ارزیابی است که شاخص‌های کلیدی عملکرد مانند برآورد (recall)،

مشکل، از مدل‌های مدرن ردگیری اشیاء شامل موارد زیر استفاده می‌شود:

- روش Deep SORT و مدل‌های شناسایی مجدد (ReID) از ویژگی‌های ظاهری مبتنی بر یادگیری عمیق برای شناسایی اشیاء پس از انسداد استفاده می‌کنند.

- تخمین جریان اپتیکال - مسیرهای حرکتی اشیاء را حتی زمانی که به طور موقت مسدود شده‌اند پیش‌بینی می‌کند.

- استراتژی‌های ردگیری بلندمدت - با به خاطر سپردن ظاهرهای گذشته و پیش‌بینی موقعیت‌های آینده، هویت شیء را حفظ می‌کنند.

۲-۳- فیلترهای کالمن در ردگیری اشیاء:

فیلتر کالمن یک ابزار ریاضی بنیادی است که در پیش‌بینی حرکت برای ردگیری اشیاء استفاده می‌شود. این فیلتر بر اساس یک فرآیند تخمین بیزی بازگشتی عمل می‌کند و با استفاده از آن موقعیت آینده یک شیء را بر اساس مشاهدات گذشته پیش‌بینی می‌کند.

چگونگی بهبود بخشیدن ردگیری توسط فیلتر کالمن:

- پیش‌بینی حرکت شیء بر اساس مدل‌های سرعت و شتاب.
- اصلاح خطاهای ردگیری با به‌روزرسانی تخمین‌ها با مشاهدات جدید از هر فریم.

- عملکرد خوبی در سناریوهای ردگیری با پیچیدگی پایین، که روش‌های مبتنی بر یادگیری عمیق ممکن است از نظر محاسباتی سنگین‌تر باشند، دارد.

۴- معیارهای ارزیابی و دیتاست‌ها:

۴-۱- معیارهای ارزیابی:

برای ارائه یک ارزیابی عینی، تمامی مطالعات، من جمله این مرور از معیارهای اثبات‌شده برای کمیت‌سازی عملکرد هر مدل پیشنهادی استفاده می‌کنند. انتخاب معیارها بر اساس اطلاعات موجود در طول ارزیابی صورت می‌گیرد و انواع مختلف سیستم‌های ردگیری، از جمله ردگیری اشیاء تک هدف و ردگیری اشیاء چندهدفه را در نظر می‌گیرد.

Multi-ObjectTracking Accuracy و مقایسه با IOU
Tracker و V-IOU Tracker

Enhanced Kalman Filter with- ۳ Dummy Nodes for ۳D Multi- Object Tracking[۱۱]

- نوع فیلتر کالمن: Enhanced Kalman Filter
- دیتاست: nuScenes
- نوع ردگیری: Multiple
- دقت: بهبود ۱.۸٪ در AMOTA نسبت به CenterPoint
- خلاصه: استفاده از گره‌های جعلی برای بهبود ردگیری در شرایط چالش برانگیز.
- معیار سنجش: AMOTA و مقایسه با CenterPoint و AB^۳DMOT.

Improving Visual Object ۴ Tracking- using General UFIR and Kalman Filters[۱۲]

- نوع فیلتر کالمن: General Kalman Filter
- دیتاست: Car^۴ benchmark
- نوع ردگیری: Single
- دقت: فیلتر UFIR در شرایط اختلال بهتر از GKF عمل می‌کند.
- خلاصه: استفاده از تفریق اندازه‌گیری برای مدیریت اختلالات.
- معیار سنجش: RMSE و مقایسه با GUFIR.

Object Tracking in SWIR-۵ Imaging with Robust Kalman Filters[۱۳]

- نوع فیلتر کالمن: Adaptive M-robustified Kalman Filter (AMKF)
- دیتاست: SWIR Videos
- نوع ردگیری: Multiple
- دقت: برتری در شرایط موانع.
- خلاصه: استفاده از رویکرد هابر برای مدیریت داده‌های نامعتبر.

دقت، و زمان اجرا را اندازه‌گیری و مقایسه می‌کند.

۶- تحلیل و مقایسه:

در این بخش، مجموعه‌ای از مقالات اخیر در زمینه ردگیری اشیاء با بهره‌گیری از فیلتر کالمن و نسخه‌های توسعه‌یافته آن مورد بررسی و مقایسه قرار گرفته‌اند. این مقالات از انواع فیلترهای کالمن استفاده کرده‌اند. ارزیابی این فیلترها بر روی دیتاست‌های متنوعی انجام شده است که هر دو نوع ردگیری تک شیء و چند شیء را در بر می‌گیرد.

۱- Dynamic Siamese Network with Adaptive Kalman Filter for Object Tracking in Complex Scenes[۹]

- نوع فیلتر کالمن: Adaptive Kalman Filter
- دیتاست: ۱۲۸ TC, VOT, OTB
- نوع ردگیری: Multiple
- دقت: بهبود قابل توجهی نسبت به روش‌های سنتی، بدون ذکر اعداد دقیق.
- خلاصه: فیلتر کالمن تطبیقی با تنظیم آنلاین ضریب تقویت‌کننده، جعبه‌های احاطه‌ای و نواحی جستجو را بهینه می‌کند.
- معیار سنجش: دقت ردگیری (Precision) و نرخ موفقیت (Success Rate) با استفاده از AUC.

۲- Efficient Online Tracking-by- Detection with Kalman Filter[۱۰]

- نوع فیلتر کالمن: Unscented Kalman Filter
- دیتاست: UA-DETRAC
- نوع ردگیری: Multiple
- دقت: بهبود کارایی و سرعت نسبت به روش‌های برتر.
- خلاصه: ترکیب فیلتر کالمن با IoU برای ردگیری سریع‌تر.
- معیار سنجش:

- معیار سنجش mAP: و مقایسه با
YOLOv3, v4, v5
- **۹- Trainable Kalman Filter Based on Recurrent Neural Network[۱۷]**
- نوع فیلتر کالمن: Deep Kalman Filter
- دیتاست: داده‌های رادار
- نوع ردگیری: Multiple
- دقت: بهبود دقت نسبت به فیلتر کالمن سنتی
- خلاصه: استفاده از RNN برای پیش‌بینی پارامترهای فیلتر کالمن.
- معیار سنجش: RMSE و مقایسه با فیلتر کالمن سنتی.
- **۱۰- DeepKalPose: Enhanced Deep Learning Kalman Filter for Vehicle Pose Estimation[۱۸]**
- نوع فیلتر کالمن: Deep Kalman Filter
- دیتاست: KITTI
- نوع ردگیری: Single
- دقت: بهبود دقت و ثبات زمانی.
- خلاصه: استفاده از فیلتر کالمن دوطرفه برای تجزیه و تحلیل زمان‌های آینده و گذشته.
- معیار سنجش: ARED و مقایسه با روش‌های موجود.
- **۱۱- Object Tracking in Satellite Videos with Correlation Particle Kalman Filter[۱۹]**
- نوع فیلتر کالمن: Correlation Particle Kalman Filter (CPKF)
- دیتاست: SatSOT
- نوع ردگیری: Multiple
- دقت: برتری نسبت به ۱۵ ردیاب برتر.
- خلاصه: ترکیب فیلتر کالمن با فیلتر ذرات برای ردگیری غیرخطی.
- معیار سنجش: خطای مکان مرکزی (CLE) و امتیاز پوشش (Overlap)
- **۱۲- SMART TRACK: Kalman Filter- Guided Sensor Fusion[۲۰]**
- معیار سنجش: زگرسیون رنج و مقایسه با KCF و فیلتر کالمن معمولی
- **۶- Multi-Pedestrian Tracking in Crowded Scenes with Adaptive Kalman Filter[۱۴]**
- نوع فیلتر کالمن: Adaptive Kalman Filter
- دیتاست: MOT۱۶, MOT۲۰
- نوع ردگیری: Multiple
- دقت: بهبود ۲.۷٪ در MOTA و ۲.۲٪ در IDF۱ نسبت به FairMOT.
- خلاصه: استفاده از مدل نیروی اجتناب برای پیش‌بینی مسیر.
- معیار سنجش: MOTA و IDF۱.
- **۷- Improving Kalman Filter-based Multi-Object Tracking in Occlusion[۱۵]**
- نوع فیلتر کالمن: Revisited Kalman Filter
- دیتاست: MOT۱۷, MOT۲۰, KITTI, DanceTrack
- نوع ردگیری: Multiple
- دقت: عملکرد بالا در شرایط occlusion و حرکت غیرخطی.
- خلاصه: استفاده از مشاهدات واقعی برای ایجاد مسیرهای مجازی.
- معیار سنجش: HOTA و مقایسه با MOTA و IDF۱
- **۸- Vision-Based UAV Detection and Tracking with Deep Learning and Kalman Filter[۱۶]**
- نوع فیلتر کالمن: General Kalman Filter + Extended Kalman Filter
- دیتاست: داده‌های UAV
- نوع ردگیری: Multiple
- دقت: بهبود دقت تشخیص و ردگیری.
- خلاصه: ترکیب یادگیری عمیق با فیلتر کالمن.

Kalman Filter Models". Arch Computat Methods Eng ۳۰:۷۲۷-۷۴۷(۲۰۲۳),<https://doi.org/10.1007/s11831-022-09815-7>.

[۲] TY - CHAP AU - Kumari, Neha AU - Kulkarni, Rohan AU - Ahmed, Mohammed Riyaz AU - Kumar, Naresh PY - ۲۰۲۱/۱۰/۲۲ SP - ۲۱۳ EP - ۲۳۰ SN - ۹۷۸-۳-۰۳۰-۷۷۰۶۹-۳ T۱ - "Use of Kalman Filter and Its Variants in State Estimation: A Review" VL - DO - ۱۰,۱۰۰۷/۹۷۸-۳-۰۳۰-۷۷۰۶۰-۹_۱۳ ER.

[۳] Robert-Bosch-Str.۷ ۶۴۲۹۳ Darmstadt, Germany Deep Learning Object Tracking: A Comprehensive Guide <https://flypix.ai/blog/deep-learning-object-tracking/>

[۴]Rahul G.Krishnan, Uri Shalit, David Sontag "DeepKalmanFilters"<https://arxiv.org/abs/1511.051>.

[۵] Guy Revach, Nir Shlezinger, Xiaoyong Ni, Adria Lopez Escoriza, Ruud J. G. van Sloun, Yonina C. Eldar "KalmanNet: Neural Network Aided Kalman Filtering for Partially Known Dynamics" <https://arxiv.org/abs/2107.10043>.

[۶] Xiaoyong Ni, Guy Revach, Nir Shlezinger "Adaptive KalmanNet: Data-Driven Kalman Filter with Fast Adaptation" <https://arxiv.org/abs/2309.070>

[۷] M. Karasalo and X. Hu," An Optimization Approach to Adaptive Kalman Filtering", <https://doi.org/10.1016/j.automatica.2011.04.004>.

[۸] Nadav Cohen, Itzik Klein," Adaptive Kalman-Informed,Transformer",<https://doi.org/10.48550/arXiv.2401.09>.

[۹]M. Kristan, J. Matas, A. Leonardis, T. Vojř, R. Pflugfelder, G. Fernandez, G. Nebehay, F. Porikli, L. Čehovin,"A novel performance evaluation methodology for single-target trackers", IEEE Trans. Pattern Anal. Mach. Intell. ۳۸ (۱۱) (۲۰۱۶) ۲۱۳۷۲۱۵۵.

[۱۰]Siyuan Chen; Chenhui Shao," Efficient Online Tracking-by-Detection With Kalman Filter", IEEE Access (Volume: ۹),pp. ۱۴۷۵۷۰ – ۱۴۷۵۷۸, ۰۱ November ۲۰۲۱,DOI: ۱۰.۱۱۰۹/ACCESS.2021.3125.

[۱۱]Shaoyu Sun , Chunyang Wang , Bo Xiao , Xuelian Liu , Chunhao Shi , Rongliang Sun and Ruijie Han,

" Enhanced Kalman Filter with Dummy Nodes and Prediction Confidence for Bipartite Graph Matching in۳DMultiObjectTracking",Electronics ۲۰۲۴, ۱۳(۲۴), ۴۹۵۰; ۱۶December۲۰۲۴,<https://doi.org/10.3390/electronics13244950>.

• نوع فیلتر کالمن: General Kalman: Filter (GKF)

• دیتاست: Gazebo, ROS۲, PX۴

• نوع ردگیری: Multiple

• دقت: کاهش خطای RMSE به کمتر از ۱ متر.

• خلاصه: ترکیب یادگیری عمیق (YOLOv۸) با فیلتر کالمن.

• معیار سنجش: RMSE و مقایسه با YOLOv۸

۱۳ - Robust Indoor Device-Free Moving-Object Localization with Kalman Filter[۲۱]

• نوع فیلتر کالمن: General Kalman: Filter (GKF)

• دیتاست: RSSI

• نوع ردگیری: Single

• دقت: کاهش خطای فاصله اقلیدسی به ۱.۳۳ متر

• خلاصه: استفاده از داده‌های RSSI برای ردگیری اشیاء متحرک.

• معیار سنجش: خطای فاصله اقلیدسی و دقت طبقه‌بندی (ACC)

۷- نتیجه‌گیری:

فیلتر کالمن، نسخه‌های پیشرفته آن و ترکیب با یادگیری عمیق ابزارهای قدرتمندی برای ردگیری اشیاء در کاربردهای متنوع هستند. این فیلترها در دیتاست‌های مختلف، در انواع کاربردهای ردگیری، به‌ویژه در شرایط پیچیده مانند انسداد، حرکت غیرخطی و نویز، عملکرد برتری نسبت به روش‌های سنتی نشان داده‌اند. ترکیب فیلتر کالمن با تکنیک‌های مدرن مانند یادگیری عمیق (مانند RNN و DRL) و فیلتر ذرات، دقت و انعطاف‌پذیری ردگیری را افزایش داده است. با این حال، موفقیت این روش‌ها به انتخاب مناسب نوع فیلتر و تنظیم پارامترها بر اساس ویژگی‌های خاص هر کاربرد (مانند نوع دیتاست و شرایط محیطی) وابسته است.

مراجع:

[۱] Khodarahmi, M., Maihami, V. "A Review on

[۲۰] Mohamed Abdelkader; Khaled Gabr; Imen Jarraya; Abdullah AlMusalami; Anis Koubaa, "SMART-TRACK: A Novel Kalman Filter-Guided Sensor Fusion for Robust UAV Object Tracking in Dynamic Environments", IEEE Sensors Journal (Volume: ۲۰, Issue: ۲, January ۲۰۲۰), pp. ۳۰۸۶-۳۰۹۷, DOI: ۱۰.۱۱۰۹/JSEN.۲۰۲۴.۳۵۵۹۹.

[۲۱] Guannan Liu; Prasanga Neupane; Hsiao-Chun Wu; Weidong Xiang; Limeng Pu; Shih Yu Chang,

"Novel Robust Indoor Device-Free Moving-Object Localization and Tracking Using Machine Learning With Kalman Filter and Smoother", IEEE Systems Journal (Volume: ۱۶, Issue: ۴, December ۲۰۲۲), pp. ۶۲۵۳-۶۲۶۴, DOI: ۱۰.۱۱۰۹/JSYST.۲۰۲۲.۳۱۸۹

[۱۲] Eli G. Pale-Ramon; Luis J. Morales-Mendoza; Mario González-Lee; Oscar G. Ibarra-Manzano; Jorge A. Ortega-Contreras; Yuriy S. Shmaliy, "Improving Visual Object Tracking Using General UFIR and Kalman Filters Under Disturbances in Bounding Boxes", IEEE Access (Volume: ۱۱), pp. ۵۷۹۰۵-۵۷۹۱۵, ۲۶ May ۲۰۲۳, DOI: ۱۰.۱۱۰۹/ACCESS.۲۰۲۳.۳۲۸۰۴۲۰.

[۱۳] Miloš Pavlović; Zoran Banjac; Branko Kovačević, "Object Tracking in SWIR Imaging Based on Both Correlation and Robust Kalman Filters", IEEE Access (Volume: ۱۱), pp. ۶۳۸۳۴-۶۳۸۵۱, ۲۲ June ۲۰۲۳, ۲۰۲۳ Electronic ISSN: ۲۱۶۹-۳۵۳۶, DOI: ۱۰.۱۱۰۹/ACCESS.۲۰۲۳.۳۲۸۸۶۹۴.

[۱۴] Jianhong Yan; Shuailing Du; Yanan Wang, "Multi-Pedestrian Tracking in Crowded Scenes by Modeling Movement Behavior and Optimizing Kalman Filter", IEEE Access (Volume: ۱۰), pp. ۱۱۸۵۱۲-۱۱۸۵۲۱, ۰۷ November ۲۰۲۲, DOI: ۱۰.۱۱۰۹/ACCESS.۲۰۲۲.۳۲۲۰۶۳۵.

[۱۵] Kris Kitani, Deva Ramanan, David Held, Zhengyi Luo, "Improving Kalman Filter-based Multi-Object Tracking in Occlusion and Non-linear Motion", CMU-RI-TR-۲۴-۰۸ December ۱۵, ۲۰۲۳.

[۱۶] Nancy Alshaer, Reham Abdelfatah, Tawfik Ismail, Haitham Mahmoud, "Vision-Based UAV Detection and Tracking Using Deep Learning and Kalman Filter", Computational Intelligence, ۱۸ February ۲۰۲۵, <https://doi.org/10.1111/coin.۷۰۰۲۶>.

[۱۷] Yanjun Jiang and Xiangyu Nong, "Trainable Kalman Filter Based on Recurrent Neural Network and its Application in Aviation Surveillance", Journal of Physics: Conference Series, Volume ۱۶۴۲, ۴th International Conference on Artificial Intelligence Applications and Technologies (AIAAT ۲۰۲۰) ۷-۹ August ۲۰۲۰, DOI ۱۰.۱۰۸۸/۱۷۴۲۶۵۹۶/۱۶۴۲/۱/۰۱۲۰۱۰.

[۱۸] Leandro Di Bella, Yangxintong Lyu, "DeepKalPose: An enhanced deep-learning Kalman filter for temporally consistent monocular vehicle pose estimation", Electronics Letters ۲۰۲۴, ۲۵ April ۲۰۲۴, <https://doi.org/10.1049/ell2.۱۳۱۹۱>.

[۱۹] Yangfan Li; Chunjiang Bian; Hongzhen Chen,

"Object Tracking in Satellite Videos: Correlation Particle Filter Tracking Method With Motion Estimation by Kalman Filter", IEEE Transactions on Geoscience and Remote Sensing (Volume: ۶۰), ۰۵ September ۲۰۲۲, DOI: ۱۰.۱۱۰۹/TGRS.۲۰۲۲.۳۲۰۵