

فیلتر ذرهای با مدل مشاهده مبتنی بر فیلتر وفقی کرنلی

حمیده حائزی و هادی صدوچی یزدی

نمونه‌گیری و وابستگی نتیجه به تعداد نمونه‌ها است. الگوریتم‌های تخمین حالت نظری فیلتر کالمون و فیلتر ذرهای، با فرض موجودیون مدل‌های فرایند و مشاهده به حل مسئله می‌پردازند. در عمل در برخی از شرایط، کل مدل یا برخی از پارامترهای آن نامعلوم بوده و یا درجه‌ای از عدم قطعیت همراه است. در این موارد لازم است مدل‌های عنوان‌شده هم‌زمان با تخمین حالت، تقریب زده شوند. از دیگر دلایل تخمین تطبیقی مدل، انحراف در پارامترهای مدل‌ها در طول زمان است. در کاربردهای برخط ممکن است به تدریج پارامترهای مدل دست‌خوش تغییرات شوند. در این شرایط روش‌های عنوان‌شده ممکن است منجر به نتیجه ناطلوب شوند. یکی از راه حل‌های عنوان‌شده برای این مشکل، تخمین برخط^۳ مدل با استفاده از روش تطبیقی است. کار حاضر با مجھول در نظر گرفتن مدل مشاهده به استخراج این مدل از روی ذرهای تولیدشده و مشاهدات دریافتی می‌پردازد.

۱-۱ کارهای انجام‌شده در تخمین مدل

روش‌های موجود تخمین حالت با وجود عدم قطعیت در مدل به سه دسته کلی تقسیم می‌شوند: روش‌های تخمین‌گر دوگان^۴، روش‌های مبتنی بر تصمیم^۵ یا تخمین‌گر چندین مدل^۶ و روش‌های دومرحله‌ای مبتنی بر حداقل‌سازی انتظار^۷ (EM).

روش‌های تخمین‌گر دوگان: در این گروه، پارامترهای ناشناخته مدل به عنوان متغیر اضافی حالت، تلقی شده و به بردار حالت افزوده می‌شوند. به این روش‌ها اصطلاحاً تخمین‌گر دوگان گویند. اولیور و کریچ در [۵] از دو فیلتر ذرهای مجزا یکی برای تخمین حالت و دیگری جهت تخمین پارامتر استفاده شده است. در این تخمین‌گر دوگان در هر گام زمانی، حالت فعلی به عنوان ورودی معلوم برای تخمین پارامتر در یکی از فیلترهای ذرهای استفاده می‌شود. در فیلتر دیگر پارامتر تخمین زده شده جهت تخمین حالت استفاده می‌شود. در [۶] در روشی پارامترهای ناشناخته را به بردار حالت افزوده، حالت سیستم را از طریق فیلتر ذرهای و پارامترها را از طریق درست‌نمایی حداقل^۸ به دست آورده‌اند. با داشتن دنباله‌ای از مشاهدات، هدف بیشینه کردن درست‌نمایی با توجه به پارامتر مجھول است. معمولاً روش‌های مبتنی بر تخمین‌گر دوگانه به علت هزینه اجرایی بالا در کاربردهای بلاذرنگ استفاده نمی‌شود.

روش‌های مبتنی بر تصمیم: این گروه از روش‌های مبتنی بر تصمیم را تخمین‌گر مبتنی بر چند مدل نیز گویند. در این روش‌ها یک فیلتر وفقی در حین پرسه تخمین از بین یک سری مدل از پیش تعیین شده، مناسب‌ترین را انتخاب می‌کند. در بسیاری از مسائل مهندسی زمانی که عدم قطعیت در مدل وجود دارد از این روش‌ها استفاده می‌شود. به عنوان

چکیده: هرچند که فیلتر ذرهای ابزاری مؤثر در رדיابی شیء می‌باشد اما یکی از محدودیت‌های موجود، نیاز به وجود مدل دقیق برای حالت سیستم و مشاهدات است. بنابراین یکی از زمینه‌های مورد علاقه محققین تخمین تابع مشاهده با توجه به داده‌های یادگیری است. تابع مشاهده ممکن است خطی یا غیر خطی در نظر گرفته شود. روش‌های موجود در تخمین تابع مشاهده با مشکلاتی مواجه هستند و از جمله این مشکلات، وابستگی به مقدار اولیه پارامترها در روش‌های دومرحله‌ای مبتنی بر ماکسیمم‌سازی انتظار و نیازمندی به یک سری مدل از پیش تعریف شده در روش‌های مبتنی بر چند مدل می‌باشد. در این مقاله، یک روش بدون راهنمایی برای غلبه بر این مشکلات با استفاده از فیلترهای وفقی کرنلی ارائه شده است. به این منظور از فیلترهای وفقی حداقل میانگین مربعات خطای کرنلی یا حداقل مربعات بازگشتی کرنلی برای تخمین تابع غیر خطی مشاهده استفاده می‌شود. با فرض معلوم بودن تابع فرایند و با داشتن دنباله‌ای از مشاهدات، تابع مشاهده مجھول تخمین زده می‌شود. ضمناً برای کاهش هزینه محاسباتی و افزایش سرعت اجراء، از روش تک‌سازی داده‌ها با استفاده از روش وابستگی خطی تقریبی استفاده شده و الگوریتم پیشنهادی در دو کاربرد مورد ارزیابی قرار گرفته است. آزمایش اول بر پیش‌بینی سری‌های زمانی و دیگری روی رادیابی اشیا در ویدئو می‌باشد. نتایج به دست آمده حاکی از برتری روش پیشنهادی در مقایسه با چند روش موجود است.

کلیدواژه: فیلتر ذرهای، حداقل میانگین مربعات خطای کرنلی (KLMS)، حداقل مربعات بازگشتی کرنلی (KRLS)، تخمین مدل.

۱- مقدمه

در سال‌های گذشته فیلتر ذرهای^۱ در مسایل بسیاری اعمال شده است. از جمله این مسایل رادیابی [۱]، هوانوردی [۲]، شناسایی صوت [۳] و رباتیک [۴] است. اخیراً به دلیل افزایش قدرت محاسباتی کامپیوترها، روش‌های مبتنی بر احتمالات نظری نمونه‌برداری متوالی، گسترش پیدا کرده است. فیلتر ذرهای که اساس آن نمونه‌برداری است، ابزار قدرتمندی برای مسایل پویا با مدل غیر خطی و نویز غیر گوسی می‌باشد. ایده اصلی این فیلتر بر پایه تقریب‌زدن تابع چگالی حالت مطلوب، توسط تعدادی نمونه وزن دار است. در یک فرایند متوالی، در هر گام زمانی، نمونه‌ها تولید و بر اساس مشاهدات رسیده، وزن دهنده خواهند شد.

فیلتر ذرهای علی‌رغم مزایای زیادی که دارد دارای نقاط ضعفی نیز هست. از جمله این نقاط ضعف، نیاز به وجود مدل دقیق مشاهده و مدل فرایند، اتحاط نمونه‌ها، انتخاب توزیع پیشنهادی مناسب برای

این مقاله در تاریخ ۱۵ فروردین ماه ۱۳۹۴ دریافت و در تاریخ ۱ اردیبهشت ماه ۱۳۹۴ بازنگری شد.

حمیده حائزی، مؤسسۀ آموزش عالی اقبال لاهوری مشهد، مشهد، (email: haeri@eqbal.ac.ir)

هادی صدوچی یزدی، گروه کامپیوتر و قطب علمی رایانش نرم و پردازش هوشمند اطلاعات، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، (email: h-sadoghi@um.ac.ir)

1. Particle Filter
2. Degeneracy

3. Online

4. Dual Estimators

5. Decision Base Techniques

6. Multiple Model (MM) Estimators

7. Expectation-Maximization

8. Maximum Likelihood

یادگیری مدل مشاهده فیلتر ذرهای دارای تفاوت‌هایی همچون عدم نیاز به گوئی‌بودن نویز مشاهده و فرایند با آنچه که [۱۱] اعمال کرده است دارد. همچنین در صورتی که میزان غیر خطی سیستم زیاد باشد فیلتر کالمن توسعه‌یافته به صورت بهینه عمل نخواهد کرد و تخمین‌های نامناسبی خواهد داشت. غیر خطی بودن بالای سیستم سبب می‌شود که تقریب خطی سیستم غیر خطی بد شده و در نتیجه تابع توزیع احتمال پسین از حالت گوئی‌بودن بسیار منحرف شده و تخمین نهایی خراب شود. بنابراین فیلتر ذرهای برای چنین سیستم‌هایی نتیجه بهتری خواهد داشت [۱۲].

در مقاله مشابه دیگری فیلتر ذرهای با مدل مشاهده مبتنی بر فیلتر وقی خاکل مربعات بازگشتی کردنی که در آن یادگیری با راهنمای انجام می‌شود، ارائه گردیده است [۱۳]. در کار حاضر مشکل مقاله فوق که نیاز به راهنمایی دارد حل می‌شود. قابل ذکر است که در رده‌گیری اشیا راهنمایی روش کاری بسیار مشکل و گاه ناشدنی است. نکته بارز این مقاله، استفاده از بازخورد مناسب خطا در به روز رسانی مدل مشاهده می‌باشد.

ساختار مقاله حاضر به شرح زیر است. فصل ۲ به معرفی مفاهیم اولیه جهت درک مطالب موجود در فصل‌های بعدی می‌پردازد. روش پیشنهادی در فصل ۳ شرح داده خواهد شد. فصل ۴ به شرح آزمایشات و نتایج حاصل از اعمال روش پیشنهادی و مقایسه آن با دیگر روش‌ها اختصاص دارد. در نهایت فصل ۵ به شرح نتیجه‌گیری کلی پرداخته است.

۲- مفاهیم اولیه

۱-۲ فیلتر ذرهای

سیستم زیر را در نظر بگیرید

$$x_t = f(x_{t-1}, v_{t-1}) \leftrightarrow p(x_t | x_{t-1})$$

$$y_t = g(x_t, u_t) \leftrightarrow p(y_t | x_t)$$

که x_t و y_t به ترتیب متغیرهای حالات پنهان و مشاهدات سیستم در زمان t است. دوتابع f و g می‌تواند خطی یا غیر خطی باشد. با استفاده از دوتابع f و g احتمالات $p(x_t | x_{t-1})$ و $p(y_t | x_t)$ قابل محاسبه است. هدف، تقریب توزیع پسین^۷ $(p(x_{\cdot:t} | y_{\cdot:t}))$ توسط فیلتر ذرهای است [۱۴]. طبق قضیه بیز^۸ توزیع پسین به صورت (۱) خواهد بود

$$p(x_{\cdot:t} | y_{\cdot:t}) = \frac{p(y_{\cdot:t} | x_{\cdot:t}) p(x_{\cdot:t})}{\int p(y_{\cdot:t} | x_{\cdot:t}) p(x_{\cdot:t}) dx_{\cdot:t}} \quad (1)$$

ایده فیلتر ذرهای، بازنمایی توزیع پسین مطلوب توسط مجموعه‌ای از نمونه‌های وزن دار است [۱۵]. فرض کنید $\{x_{\cdot:t}^i, w_t^i\}_{i=1}^{N_s}$ مقادیر تصادفی مورد نیاز برای بازنمایی توزیع پسین $(p(x_{\cdot:t} | y_{\cdot:t}))$ باشد که $\{x_{\cdot:t}^i, i=1, \dots, N_s\}$ یک سری نمونه با وزن‌های متناظر $\{w_t^i, i=1, \dots, N_s\}$ بوده و $\{x_{\cdot:t}^j, j=1, \dots, t\}$ مجموعه‌ای از حالات تا زمان t باشد. توزیع پسین به صورت (۲) تقریب زده خواهد شد

$$p(x_{\cdot:t} | y_{\cdot:t}) \approx \sum_{i=1}^{N_s} w_t^i \delta(x_{\cdot:t} - x_{\cdot:t}^i) \quad (2)$$

مثال در رده‌گیری رادار، در این که پژو اوک رادار برای هوایپیمای دوست یا دشمن بوده و یا هشدار اشتباه و یا این که هوایپیما تجاری یا جنگی است، عدم قطعیت وجود دارد. در این گونه مسایل معمولاً سیستم بین مُدّهای^۹ مختلف سویچ می‌کند [۷]. برای تسريع عملکرد فیلتر مبتنی بر مدل چندگانه، ونگ و هان فیتر چندگانه‌ای ارائه دادند که در آن تخمین مدل و تخمین حالت با هم و همزمان انجام می‌شود [۸]. در بین روش‌های مبتنی بر چند مدل، الگوریتم مبتنی بر چند مدل متعامل^{۱۰} (IMM) در کاربردهای کاربردهای رده‌گیری برتری دارد [۹]. این الگوریتم‌ها بین تخمین حالت و شناسایی مدل قابل اعتماد، تعادل برقرار می‌کنند. این روش برای کاربردهای برخط به دلیل سرعت پایین مناسب نیست و همچنین به دیکشنری مدل^{۱۱} به شدت وابسته است.

روش‌های دومرحله‌ای مبتنی بر حداکثرسازی انتظار: در دسته سوم که روشن‌های دومرحله‌ای مبتنی بر حداکثرسازی انتظار است، مسئله تخمین حالت به دو قسمت تخمین حالت و شناسایی مدل تقسیم می‌شود. ابتدا فرض می‌شود که مدل معلوم بوده و حالت تخمین زده می‌شود. سپس از حالت تخمین زده برای شناسایی پارامترهای مدل استفاده می‌شود. این دسته از روش‌ها معمولاً در گروه الگوریتم‌های مبتنی بر حداکثرسازی انتظار (EM) قرار می‌گیرند. ایده اصلی الگوریتم‌های مبتنی بر EM حل مسئله تخمین حالت در حضور عدم قطعیت در دو گام تکرارشونده است. در گام اول (مرحله E) فرض می‌شود که مدل شناخته شده بوده و از الگوریتم‌های استاندارد تخمین برای تخمین حالت سیستم استفاده می‌شود. در گام بعد (مرحله M) از حالت تخمین زده برای شناسایی پارامترهای مدل استفاده می‌شود. در مسایلی که پیچیدگی بالا بوده و یا سایز بردار پارامترها بزرگ باشد تعیین مدل با استفاده از روش‌های تخمین گر دوگانه امکان پذیر نخواهد بود. در این مسایل روش‌های مبتنی بر حداکثرسازی انتظار مقاومتر بوده و تخمین بهتری از مدل خواهد داشت [۱۰]. در عین حال، روش‌های دومرحله‌ای ذکر شده هزینه محاسباتی بالایی داشته و برای کاربردهای برخط مناسب نیست. از دیگر معایب روش‌های مبتنی بر EM، وابستگی به مقدار اولیه پارامترها است.

۲-۱ انگیزه

نظر به این که روش‌های گفته شده دارای مشکلاتی چون هزینه اجرایی بالا در روش‌های تخمین گر دوگان، سرعت پایین اجرا و وابستگی به دیکشنری مدل در روش‌های تخمین گر مبتنی بر چند مدل و وابستگی به مقدار اولیه پارامترها در روش‌های دومرحله‌ای مبتنی بر حداکثرسازی انتظار است و با الهام از روش ارائه شده در [۱۱] بر آن شدیم تا از فیلتر وققی میانگین مربعات خطای کرنلی^{۱۲} (KLMS) یا حداقل مربعات بازگشتی کرنلی^{۱۳} (KRLS) در تخمین مدل مشاهده فیلتر ذرهای استفاده کنیم.

در روش ارائه شده در [۱۱]، تابع مشاهده توسط الگوریتم حداقل مربعات بازگشتی کرنلی تخمین زده می‌شود. در این فیلتر در هر مرحله ابتدا با استفاده از مدل تخمین زده شده مرحله قبل، حالت فعلی از طریق فیلتر کالمن توسعه‌یافته به دست می‌آید. سپس با استفاده از حالت فعلی، تابع مشاهده برای مرحله بعدی تخمین زده خواهد شد. خاطر نشان می‌شود که

1. Mode
2. Interacting Multiple Model
3. Model Dictionary
4. Kernel Least Mean Square
5. Kernel Recursive Least Square
6. Extended Kalman Filter

7. Posterior Distribution

8. Bayes' Theorem

۲-۲ الگوریتم حداقل مربعات بازگشتی کرنلی (KRLS)

یکی دیگر از الگوریتم‌های رگرسیون غیر خطی، روش حداقل مربعات بازگشتی کرنلی است که نرخ همگرایی سریع‌تری نسبت به روش حداقل میانگین مربعات کرنلی دارد [۲۰].

تابع هزینه که در مرحله i کمینه خواهد شد، به صورت (۷) است

$$J(i) = \min_{\Omega} \sum_{j=1}^i \left| d(j) - \Omega^T \Phi(\hat{x}_j) \right|^2 \quad (7)$$

که در آن $d(j)$ خروجی مطلوب در لحظه j است. الگوریتم KRLS تابع هزینه ذکرشده را به صورت بازگشتی حل کرده و وزن‌های Ω موجود را توسط ترکیب خطی از $\{\phi(x_j)\}_{j=1}^i$ به دست خواهد آورد.

$$\Omega = \sum_{j=1}^i a(j) \phi(\hat{x}_j) = \Phi_i a(i) \quad (8)$$

که $a(i) = [\lambda I + \Phi(\hat{x}_i)^T \Phi(\hat{x}_i)]^{-1} d(i)$ ، $\Phi(\hat{x}_i) = [\phi(\hat{x}_1), \dots, \phi(\hat{x}_i)]^T$ و $d(i) = [d(1), \dots, d(i)]^T$ است.

پس از محاسبه وزن‌ها، در نهایت مقدار y تخمینی با توجه به (۹) به دست خواهد آمد

$$y_i = \hat{g}(x) = \sum_{j=1}^i a_j(i) K(x(j), x) \quad (9)$$

که (۹) تابع کرنل است.

۳-۲ فیلتر وفقی تنک^۷

در کاربردهای برخط سیستم یادگیری باید تا حد امکان سریع عمل کند. یکی از مهم‌ترین عیوب روش‌های فیلترینگ وفقی کرنلی، رشد ساختار آن با اضافه شدن هر داده است که در (۷) و (۹) مشاهده می‌شود. به عبارت دیگر پیچیدگی زمانی و فضایی با افزایش حجم داده‌های آموزش، رشد می‌یابد. در بسیاری از موارد، افزونگی داده وجود داشته و فقط برخی از داده‌ها در ساختار فیلتر تاثیرگذار است. مشکل این است که چگونه داده‌های مهم در ساختار فیلتر، انتخاب و داده‌هایی که موجب افزونگی می‌شوند از دیکشنری داده‌ها^۸ حذف شوند.

برای تنکسازی فیلترهای وفقی، چندین روش ارائه شده است. این روش‌ها به سه دسته کلی معیار تازگی^۹ (NC)، وابستگی خطی تقریبی^{۱۰} (ALD) و معیار غافل‌گیری^{۱۱} تقسیم می‌شوند [۲۱]. در مقاله حاضر از روش وابستگی خطی تقریبی با طول دیکشنری محدود استفاده شده است [۲۲].

۳- فیلتر ذرهای با مدل مشاهده وفقی

چنانچه گفته شد در فیلتر ذرهای در برخی از شرایط، کل مدل یا برخی از پارامترهای آن نامعلوم بوده و یا با درجه‌ای از عدم قطعیت همراه است. یک راه حل برای این مشکل تخمین برخط مدل با استفاده از روشی وفقی است. در مقاله حاضر فیلتر ذرهای با مدل مشاهده نامعلوم، مورد مطالعه قرار گرفته است. هر گام از الگوریتم فیلتر ذرهای معمولی، دارای سه مرحله اصلی تولید نمونه‌های جدید، محاسبه وزن نمونه‌ها و

وزن‌های مورد نظر توسط الگوریتم نمونه‌برداری اهمیت^۱ تعیین خواهد شد [۱۶].

برای فیلتر ذرهای نسخه‌های مختلفی ارائه شده است. در این مقاله روش نمونه‌برداری اهمیت مجدد^۲ (SIR) [۱۷] که یکی از متداول‌ترین فیلترهای ذرهای می‌باشد، ارائه شده است.

۲- فیلترهای وفقی کرنلی

فرض کنید هدف، یافتن نگاشت $f: U \rightarrow R$ بر اساس دنباله‌ای از ورودی‌ها و خروجی‌های $\{(x_1, d_1), \dots, (x_n, d_n)\}$ باشد. دامنه $U \subseteq R^L$ ورودی است و فرض بر این است که خروجی یکبعدی باشد. روش‌های فیلتر وفقی چارچوبی برای پیداکردن تابع f ارائه می‌دهند [۱۸]. دو روش حداقل میانگین مربعات^۳ (LMS) و حداقل مربعات بازگشتی^۴ (RLS) از متداول‌ترین فیلترهای وفقی خطی هستند [۱۹].

۲-۱ الگوریتم حداقل میانگین مربعات کرنلی (KLMS)

روش حداقل میانگین مربعات کرنلی^۵ (KLMS) برای حل مسایل غیر خطی، داده‌ها را به فضای ویژگی می‌برد تا شاید روابط خطی بر آنها قابل اعمال شود. این مسئله از روشهای تکراری برای یافتن ضرایب بهینه استفاده می‌کند و به دو فرم اولیه و دوگان مطرح است که در ادامه به توضیح آنها پرداخته شده است.

تابع هدف اولیه KLMS از (۳) به دست می‌آید

$$J = \min_{\Omega} \sum_{i=1}^N (d_i - \Omega(\Phi(x_i)))^2 \quad (3)$$

که Φ و Ω به ترتیب ماتریسی از بردارهای ورودی و ضرایب آنها در حوزه بعد بالا است. در حقیقت KLMS، الگوریتم LMS بر مجموعه $\{y_i = \langle \Omega, \Phi(x_i), d_i \rangle, (\Phi(x_n), d_n)\}$ است که $e_i = d_i - \Omega \Phi(x_i)$ مقدار ضریب $\Omega^{(t)}$ برابر خواهد بود با

$$\begin{aligned} \Omega^{(t)} &= \Omega^{(t-1)} + \eta \hat{\nabla}_w (e_i) = \\ \Omega^{(t-1)} + \eta e_i \Phi(x_i) &= \eta \sum_{i=1}^{t-1} e_i \Phi(x_i) \end{aligned} \quad (4)$$

داشتن ضرایب و بردار ورودی تبدیل یافته به حوزه دیگر دشوار و گاهی غیر ممکن است اما مطلوب ما، داشتن خروجی برای محاسبه خطأ است. از جایگذاری ضرایب در رابطه خروجی، رابطه زیر به دست می‌آید

$$\begin{aligned} y_t &= \Omega \Phi(x_t) = \langle \eta \sum_{i=1}^{t-1} e_i \Phi(x_i), \Phi(x_t) \rangle = \\ \sum_{i=1}^{t-1} e_i \langle \Phi(x_i), \Phi(x_t) \rangle & \end{aligned} \quad (5)$$

که با بهره‌گیری از حقه کرنل^۶

$$y_t = \eta \sum_{i=1}^{t-1} e_i k(x_i, x_t) = \eta K_{t-1}^T e \quad (6)$$

که $K_{t-1} = [k(x_1, x_t), \dots, k(x_{t-1}, x_t)]^T$ است.

1. Importance Sampling

2. Sampling Importance Resampling

3. Least Mean Square

4. Recursive Least Square

5. Kernel Least Mean Square

6. Kernel Trick

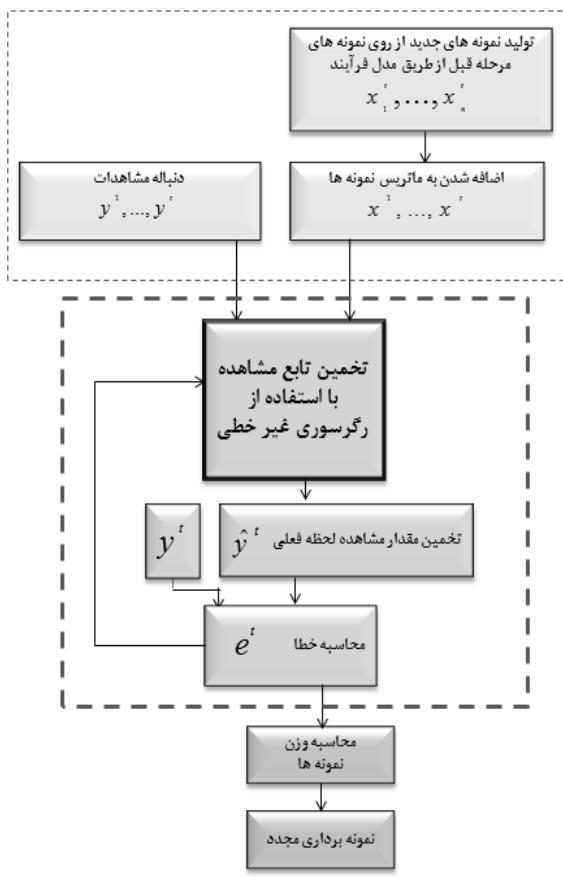
7. Sparse Adaptive Filtering

8. Data Dictionary

9. Novelty Criterion

10. Approximate Linear Dependency

11. Surprise



شکل ۲: شمای کلی روش پیشنهادی.

$$J = \min_{\Omega} \left[\sum_{t=1}^T (y_t - \langle \Omega, \Phi(f(x_{t-1})) \rangle_H)^2 \right] \quad (12)$$

در نهایت پس از تخمین تابع مشاهده شکل کلی آن به صورت رابطه زیر خواهد بود

$$\hat{y}_t = \hat{g}(x_t) = \sum_{j=1}^l a_j(i) k(x(j), x(i)) \quad (13)$$

محاسبه ضریب α با استفاده از روابط KLMS و KRLS در بخش ۲ شرح داده شده است. چنانچه ملاحظه می‌شود در (۱۳) محاسبات از زبرابر ۱ تا t انجام می‌شود که این به معنای ذخیره‌سازی تمام اطلاعات از ابتدای تا زمان فعلی است. در این شرایط استفاده از روش تخمین فوق هزینه اجرایی بالایی خواهد داشت. بنابراین از تنکسازی^۳ به منظور ذخیره ذخیره تعداد محدودی از داده‌ها استفاده شده است.

برای تنکسازی فیلترهای KLMS و KRLS چندین روش ارائه شده که در این مقاله از روش وابستگی خطی تقریبی با طول دیکشنری ثابت ارائه شده در [۲۲] استفاده شده است. برای تنکسازی با استفاده از این روش، فرض بر این است که داده‌های موجود در دیکشنری $X = \{x_i\}_{i=1}^m$ باشد که m تعداد داده‌های فعلی دیکشنری است. برای تست پذیرش و یا رد داده جدید، باید مطمئن شد که داده جدید را با استفاده از ترکیب خطی داده‌های موجود در دیکشنری نمی‌توان نوشت. برای چک کردن این مورد از (۱۴) استفاده می‌شود

$$\delta = \left\| \sum_{i=1}^m a_i \phi(x_i) - \phi(\hat{x}(m+1)) \right\|^2 \quad (14)$$



شکل ۱: چهار مرحله اصلی روش پیشنهادی.

نمونه‌گیری مجدد است. در روش پیشنهادی هر گام چهار مرحله اصلی دارد (شکل ۱).

مدل مشاهده در فیلتر ذرهای ممکن است خطی یا غیر خطی باشد. در روش پیشنهادی در مرحله دوم، مدل مشاهده توسط فیلتر وفقی KRLS و یا KRLMS تخمین زده می‌شود. در ادامه از مدل مشاهده تخمین زده در مرحله وزن‌دهی نمونه‌ها استفاده خواهد شد. بلوک دیاگرام روش پیشنهادی در شکل ۲ نشان داده شده است. در ادامه دیاگرام ارائه شده شرح داده خواهد شد.

۱-۳ شرح دیاگرام

با توجه به شکل ۱ چهار مرحله اصلی سیستم پیشنهادی تولید نمونه‌ها، تخمین مدل مشاهده، وزن‌دهی نمونه‌ها و نمونه‌برداری مجدد است. هر گام از روش پیشنهادی در دیاگرام با یک رنگ مشخص شده است. در گام اول، نمونه‌ها از توزیع پیشنهادی مناسب نمونه‌برداری شده و به ماتریس نمونه‌ها اضافه خواهد شد. در گام بعدی با داشتن دنباله‌ای از مشاهدات از آغاز تا زمان فعلی، تابع مشاهدات توسط یکی از الگوریتم‌های فیلتر وفقی KRLS یا KRLMS تخمین زده می‌شود. با تخمین این تابع، مشاهده تخمینی فعلی (\hat{y}_t) محاسبه خواهد شد. در ادامه با تفاضل این مقدار از مشاهده دریافتی نویزی^۴ مقدار خطأ در لحظه فعلی به دست می‌آید. از مقدار خطأ به دست آمده در تخمین تابع مشاهده در مرحله بعد و همچنین برای وزن‌دهی نمونه‌ها استفاده خواهد شد. این قسمت از روش پیشنهادی با خطچین پرنگ در دیاگرام مشخص شده است.

۲-۳ فرموله کردن مسئله

چنانچه قبل از اینکه شد روش فیلتر ذرهای برای تقریب‌زن حالت سیستم در لحظه t از یک سری مشاهدات متألف $\{y_1, y_2, \dots, y_t\}$ دریافتی تا زمان فعلی استفاده می‌کند. در این مسئله ممکن است نویزها، غیر گوسی و مدل، غیر خطی باشد. در این مقاله فرض شده که مدل فرآیند سیستم (۱۰-الف) معلوم و مدل مشاهدات (۱۰-ب) نامعلوم است. در ادامه روشی مبتنی بر داده‌ها^۱ برای تخمین مدل مشاهدات ارائه شده است

$$x_t = f(x_{t-1}, \omega_{t-1}) \quad (10-\text{الف})$$

$$y_t = g(x_t, v_t) \quad (10-\text{ب})$$

در فیلتر ذرهای برای محاسبه وزن‌های نمونه‌ها نیازمند استفاده از مدل مشاهدات هستیم. به منظور تخمین مدل مشاهده نامعلوم، رابطه مشاهدات g یک تابع غیر خطی به صورت زیر در نظر گرفته شده است

$$\hat{y}_t = \hat{g}(x_t) = \langle \Omega, \Phi(\hat{x}_t) \rangle = \langle \Omega, \Phi(f(x_{t-1})) \rangle \quad (11)$$

که Φ و Ω به ترتیب ماتریسی از بردارهای ورودی در حوزه بعد بالا و ضرایب آنها در حوزه بعد بالا است. با داشتن دنباله زمان فعلی و معلوم‌بودن مدل فرآیند (۱۳-الف)، تابع مشاهده توسط یکی از الگوریتم‌های فیلتر وفقی KRLS و یا KLMS قابل تخمین است. بدین منظور، تابع هزینه زیر باید کمینه گردد

برای راحتی محاسبات، نویز به صورت جمع شونده در نظر گرفته می‌شود

$$\begin{aligned} x_t &= f(x_{t-1}) + \omega_{t-1} \\ y_t &= \hat{g}(x_t) + v_t \end{aligned} \quad (16)$$

در نتیجه با داشتن (16) این توابع احتمالی برابر خواهد بود با

$$\begin{aligned} p(x_t | x_{t-1}) &= p_{\omega_t}(x_t - f(x_{t-1})) \\ p(y_t | x_t) &= p_{v_t}(y_t - \hat{g}(x_t)) \end{aligned} \quad (17)$$

با جایگذاری رابطه تخمین زده شدهتابع مشاهدات (15) در رابطه بالا، تابع درستنمایی برابر خواهد بود با

$$p(y_t | x_t) = p_{v_t}(y_t - \hat{g}(x_t)) \quad (18)$$

که در نهایت از این رابطه می‌توان در فاز محاسبه وزن نمونه‌ها استفاده کرد. پس از محاسبه وزن‌ها، نهایتاً در گام چهارم عمل نمونه‌گیری مجدد انجام می‌شود. این عمل به دلیل کاهش مشکل انحطاط نمونه‌ها بوده که شرح آن در [۲۳] صورت گرفته است.

۴-۳ شرح الگوریتم KRLS_PF و KLMS_PF

در این قسمت الگوریتم پیشنهادی KRLS_PF و KLMS_PF شرح داده می‌شود. این روش با اعمال تغییر در الگوریتم فیلتر ذرهای SIR نوشته شده است. در شروع کار با فرض معلوم بودن توزیع اولیه نمونه‌ها $p(x_t)$ ، N_s نمونه $\{x_i^i, i=1, \dots, N_s\}$ از این توزیع به عنوان نمونه‌های اولیه تولید خواهد شد. وزن اولیه نمونه‌ها مساوی با هم و برابر $1/N_s$ در نظر گرفته خواهد شد. سپس در هر مرحله t ، تعداد N_s نمونه با استفاده از توزیع پیشنهادی $q(x_t | x_{t-1}, y_t)$ تولید می‌شود. چنانچه گفته شد توزیع پیشنهادی $p(x_t | x_{t-1}, y_t)$ در نظر گرفته می‌شود.

در این روش مقادیر اولیه دیکشنری داده‌ها برابر $\{c_i = x_i(1)\}$ می‌شود. در نظر گرفته می‌شود. (۱) بردار x_t نمونه جدید تولیدشده در مرحله پیش‌بینی است. سپس در هر مرحله پیش‌بینی تابع مشاهده، مقدار δ محاسبه و با مقایسه با مقدار آستانه، تصمیم‌گیری برای پذیرش و یا رد آن صورت می‌گیرد. اگر داده جدید پذیرفته شود در صورتی که تعداد داده‌های دیکشنری به حد نصاب نرسیده باشد، به دیکشنری داده‌ها اضافه خواهد شد و در غیر این صورت داده‌ها که کمترین مقدار δ متناظر با این داده جدید جایگزین آن خواهد شد. در انتها تمام مقادیر δ متناظر با هر داده موجود در دیکشنری، به روز رسانی خواهد شد. در ادامه سیستم یادگیری فیلتر وقیی KRLS یا KLMS با توجه به دیکشنری موجود، تابع مشاهده مورد نظر را تخمین زده و الگوریتم فیلتر ذرهای با توجه به آن به تخمین وزن‌های نمونه‌های تولیدی خواهد پرداخت. در نهایت پس از استفاده از روش تنکسازی ذکر شده در الگوریتم KLMS و KRLS رابطه مشاهده تخمین زده شده به صورت (15) خواهد بود.

پس از آن از رابطه به دست آمده جهت محاسبه تابع درستنمایی ($p(y_t | x_t)$) استفاده و در نهایت با استفاده از (۳) وزن‌ها به دست خواهد آمد. به دلیل مشکل انحطاط که در [۱۷] شرح داده شد در انتهای هر گام، عمل نمونه‌گیری مجدد انجام می‌گیرد. در روش استفاده شده با توجه به وزن هر نمونه عمل نمونه‌گیری مجدد انجام می‌شود. نمونه‌هایی که وزن بالاتری دارند، متناسب با وزنشان چندین بار انتخاب شده و نمونه‌های با وزن ناچیز دور اندخته می‌شوند. در نهایت تعداد N_s نمونه جدید از روی نمونه‌های قبلی تولید خواهد شد که وزن همه برابر $1/N_s$ خواهد بود. در انتهای هر مرحله با داشتن N_s نمونه وزن‌دار، توزیع پسین هدف با استفاده از (۲) قابل محاسبه خواهد بود. شکل ۳ یک گام از روش شرح داده شده را نشان می‌دهد.

ورودی‌ها: $\{x_{i,t-1}^i, w_{i,t-1}^i\}_{i=1}^{N_s}$ مجموعه نمونه‌ها و وزن‌های متناظر به دست آمده در مرحله قبل و N_s تعداد نمونه‌ها

خروجی‌ها: $\{x_{i,t}^i, w_{i,t}^i\}_{i=1}^{N_s}$ مجموعه نمونه‌ها و وزن‌های متناظر به دست آمده در مرحله فعلی

رووال یادگیری:

مرحله اول: تولید نمونه x_t^i با استفاده از توزیع $q(x_t | x_{t-1}^i, y_t)$

مرحله دوم: تخمین تابع مشاهده

محاسبه مقدار δ با استفاده از (۱۶)

اگر (آستانه $< \delta$): اضافه شدن نمونه‌های جدید به ماتریس نمونه‌ها

در غیر این صورت: جایگزین شدن بردار نمونه‌های جدید با بردار نمونه‌هایی که

کمترین مقدار δ را دارد.

به روز رسانی مقدار δ ها

تخمین رابطه مشاهدات را با استفاده از (۱۴)

مرحله سوم: محاسبه وزن‌ها

به ازای هر $i = 1 \dots N_s$ تا :

$$w_i^i \propto w_{i,t-1}^i \frac{p(y_t | x_t^i) p(x_t^i | x_{t-1}^i)}{q(x_t^i | x_{t-1}^i, y_t)}$$

محاسبه مجموع وزن‌ها

$$t = \text{sum}[\{w_i^i\}_{i=1}^{N_s}]$$

نرم‌السازی وزن‌ها: به ازای هر $i = 1 \dots N_s$ محاسبه

مرحله چهارم: انجام نمونه‌برداری مجدد

شکل ۳: الگوریتم روش پیشنهادی.

که در آن a_i ضریب وابستگی خطی است. پس از کمینه کردن معیار δ روی a_i ، در نهایت K^{-k} و $\alpha = K^{-k}$ و $\delta = k(x_{m+1}, x_{m+1}) - K^T \alpha$ خواهد شد. در این رابطه $K = k(X, X)$ ماتریس کرنل، $k = k(x_{m+1}, x_{m+1})$ یک مقدار کرنل خواهد بود. با مقایسه مقدار δ به دست آمده با مقدار آستانه η ، تصمیم‌گیری برای پذیرش و یا رد نمونه جدید صورت می‌گیرد. جهت کاهش هزینه اجرایی برای تعداد داده‌های مجاز در دیکشنری حد بالایی در نظر گرفته و در صورت رسیدن به آن حد، یکی از داده‌های موجود حذف و داده جدید جایگزین آن خواهد شد. جهت حذف داده قدیمی دیکشنری، در هر گام مقدار δ برای یک از داده‌های موجود در آن با استفاده از (۱۵) محاسبه می‌شود

$$\delta^i = k(x_i, x_i) - k_{new}^{iT} a_{new}^i \quad (15)$$

اگر تعداد داده‌ها به حد نصاب رسیده باشد، داده با کوچک‌ترین مقدار δ^i انتخاب و داده جدید جایگزین آن خواهد شد. با اضافه شدن و یا پس از جایگزینی هر داده، مقادیر کرنل‌ها و δ^i به روز رسانی خواهد شد.

۳-۳ روش پیشنهادی

در گام اول روش پیشنهادی، مشابه الگوریتم فیلتر ذرهای عمومی، تعداد N_s نمونه یا ذره با استفاده از تابع پیشنهادی ($q(x_t | x_{t-1}, y_t)$)، مناسب، نمونه‌برداری خواهد شد. در این مقاله تابع پیشنهادی، تابع توزیع انتقال حالت ($p(x_t | x_{t-1}, y_t)$) در نظر گرفته شده است. به منظور وزن‌دهی به هر نمونه تولیدشده، نیاز به مدل مشاهدات است که این کار با استفاده از (۱۳) انجام می‌شود و در بخش ۳-۳ به طور مبسوط شرح داده می‌شود. پس از تخمین تابع مشاهدات ($(x_t | \hat{g}(x_t))$ ، وزن‌دهی نمونه‌های تولیدشده توسط تابع پیشنهادی صورت می‌گیرد. از مدل فرایند در محاسبه تابع احتمالی ($p(x_t | x_{t-1})$) و از مدل مشاهدات برای محاسبه تابع درستنمایی ($p(y_t | x_t)$) استفاده خواهد شد. برای محاسبه این تابع، در بیشتر مسایل

جدول ۱: مقایسه دقت و سرعت شش الگوریتم.

		KLMS_PF	KRLS_PF	Spars_KLMS_PF	Spars_KRLS_PF	KRLS_EKF	Em_PF
مدل ۱	RMSE [mean]	۹,۶۲	۸,۹۳۲۵	۷,۰۶	۸,۸۸	۱۰,۷۸	۱۰,۹۲
	Time (s)	۲۲,۱۷	۹,۰۷,۷۴	۴,۱۳	۷,۸۵	۱,۰۸	۲۰,۸,۷۵
مدل ۲	RMSE [mean]	۵,۵۷	۵,۵۵	۳,۳۷	۴,۵۳۳۳	-	۶,۶۱
	Time (s)	۱۸,۶۶	۷۶۳,۸۲	۴,۴۳	۵,۲۷۰۱	-	۲۰,۵,۹۷

در این مثال، x_t حالت سیستم و y_t مشاهده در لحظه t است. نویز حالت $(x_t) \sim N(0, 10)$ و نویز مشاهدات $(y_t) \sim N(0, \sigma^2)$ در نظر گرفته شده

و $N(\mu, \sigma^2)$ توزیع نرمال با میانگین μ و کواریانس σ^2 است. سری زمانی شماره ۲: مدل دوم غیر خطی بوده، نویز مشاهده با توزیع گاما $(\Gamma(3, 2))$ و نویز فرایند با توزیع نرمال $N(0, 0, 0, 0, 0, 1)$ می‌باشد [۲۷]

$$x_t = 0,5x_{t-1} + \sin(0,4\pi t) + 1 + u_t \\ y_t = \begin{cases} \frac{x_t}{5} + v_t, & 1 < t \leq 30 \\ \frac{x_t}{3} - 2 + v_t, & t > 30. \end{cases} \quad (20)$$

آزمایشات با در نظر گرفتن ۱۰۰۰ ذره در ۸۰۰ گام زمانی صورت گرفته است. عمل تخمین مدل مشاهده با استفاده از فیلترهای وفقی KRLS و KLMS و حالت تنکسازی شده آنها انجام شده است. نتیجه تخمین حالت x_t در ۵۰ گام انتهایی برای دو مدل در شکل‌های ۴ و ۵ نمایش داده شده است. در هر مجموعه مورد (الف) تخمین توسط الگوریتم sparse_KLMS_PF و (ب) تخمین توسط الگوریتم sparse_KRLS_PF است.

آزمایش اول- دقت و سرعت الگوریتم پیشنهادی

در جدول ۱ روش پیشنهادی با روش‌های فیلتر ذره‌ای با پیش‌بینیتابع مشاهده مبتنی بر حداکثرسازی انتظار [۲۸] (EM_PF) و روش فیلتر کالمون گسترش‌یافته با تابع مشاهده پیش‌بینی شده توسط KRLS_EKF [۱۱] مقایسه شده و اولین معیار مورد ارزیابی، ریشه متوسط مربعات خطأ است. محاسبه این خطأ با توجه به (۲۱) انجام خواهد شد

$$RMSE = \left\{ \frac{1}{M} \sum_{m=1}^M (x_t - \hat{x}_{t,m})^2 \right\}^{1/2} \quad (21)$$

که M تعداد دفعات اعمال الگوریتم بر مسئله x_t مقدار اصلی حالت در لحظه t و $\hat{x}_{t,m}$ مقدار تخمینی حالت در مرحله m و در لحظه t است. همان‌طور که مشاهده می‌شود، خطای تخمین حالت در الگوریتم پیشنهادی نسبت به دو روش دیگر پایین‌تر است. معیار سرعت اجرایی روش پیشنهادی با دو روش دیگر مورد بررسی قرار گرفته است. همان‌طور که در جدول مشاهده می‌شود، سرعت اجرایی روش KRLS_EKF روش KRLS_EKF نسبت به روش‌های دیگر پایین‌تر بوده اما روش پیشنهادی نسبت به روش EM_PF سرعت قابل توجهی دارد.

در مدل دوم به دلیل غیر گوسی بودن نویز مشاهده و عدم توانایی روش فیلتر کالمون برای تخمین چنین مسایلی، روش پیشنهادی تنها با روش (Em-PF) [۲۸] مورد مقایسه قرار گرفته است. از مقایسه نتایج به دست آمده مشاهده می‌شود روش فیلتر ذره‌ای با تابع مشاهده مبتنی بر الگوریتم KLMS تنگ دقت و سرعت اجرایی بالاتری نسبت به سه روش پیشنهادی دیگر دارد.

۵-۳ اعمال KRLS یا KLMS

ساده‌ترین و رایج‌ترین فیلتر وفقی موجود الگوریتم حداقل میانگین مربعات (LMS) است که صورتی دیگر از آن در حوزه کرنل است. در این روش مقدار طول گام γ در سرعت همگرایی مؤثر است. مقادیر کوچک γ موجب کندی همگرایی KRLS خواهد شد.

در مقایسه با KLMS، فیلتر KRLS سرعت همگرایی بالاتری دارد. هر دوی این روش‌ها مبتنی بر تصحیح خطأ می‌باشند با این تفاوت که KRLS مربعات خطأ را در تکرار n ام کمینه می‌کند در حالی که KLMS مجموع مربعات خطأ را تا زمان n ام کمینه می‌نماید. پس حجم محاسبات KRLS بیشتر خواهد بود. بالا بودن حجم محاسبات موجب پایین‌آمدن سرعت اجرا خواهد شد. اگر پردازنده‌ای موجود باشد که محاسبات بالا را در زمانی اندک حساب کند KRLS می‌تواند گزینه بهتری برای تخمین مدل مشاهده در فیلتر ذره‌ای باشد.

در برخی از مسایل ممکن است مدل غیر ایستا بوده و با زمان تغییر کند. در محیط‌های غیر ایستا عملکرد ریدیابی KLMS نسبت به KRLS بهتر خواهد بود [۱۱]. پس چنانچه مدل غیر ایستا باشد استفاده از KLMS در فاز تخمین مدل نتیجه بهتری خواهد داشت.

۴- آزمایشات و نتایج

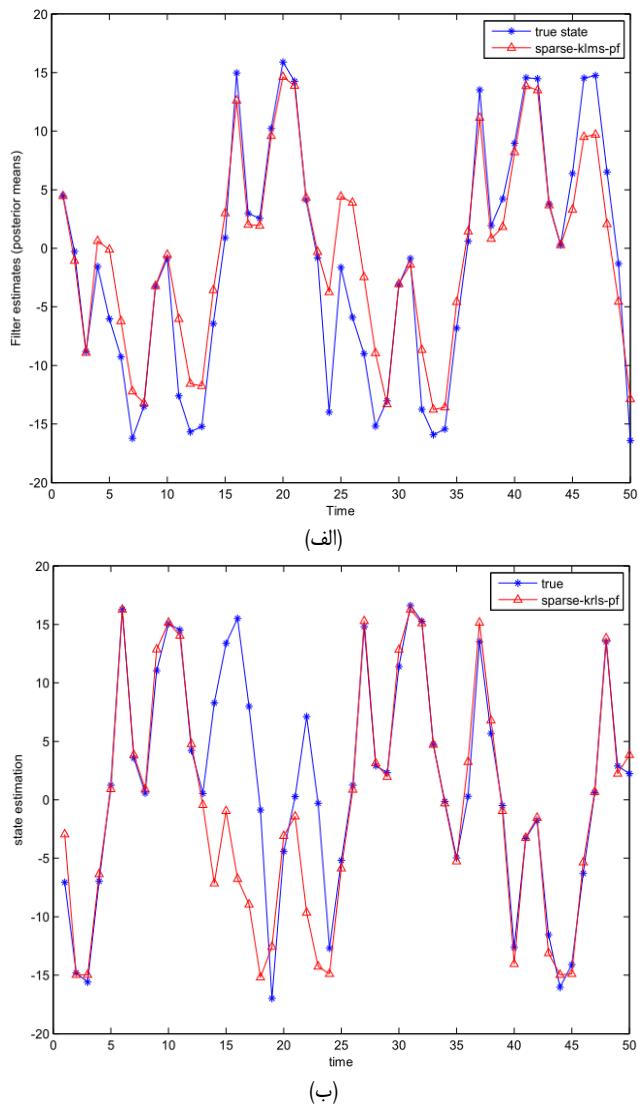
به منظور ارزیابی کارایی روش ارائه شده، در این فصل، روش پیشنهادی روی دو گونه مسئله اعمال می‌شود. مسئله اول پیش‌بینی سری زمانی غیر خطی است که از مراجع برداشت شده است [۲۴] و [۲۵]. دسته دوم، استفاده از روش پیشنهادی برای ریدیابی شیء در تصاویر ویدئویی است. معیارهای ارزیابی مورد استفاده، دقت تخمین فیلتر ذره‌ای پیشنهادی در مقایسه با روش‌های دیگر و سرعت اجرا است.

۴-۱ اعمال الگوریتم روی مسئله پیش‌بینی سری زمانی غیر خطی

تحلیل سری‌های زمانی غیر ایستا، موضوع اصلی مدل‌سازی سیستم‌های متغیر با زمان بوده است. برای چنین سیستم‌هایی، فیلترهای بازگشته و روش‌های هموارسازی در تحلیل و پیش‌بینی به کار می‌روند. در ادامه پیش‌بینی دو سری زمانی مطرح با روش پیشنهادی بررسی شده و با دیگر روش‌ها مقایسه می‌گردد.

سری زمانی شماره ۱: به عنوان اولین مثال، مدل غیر خطی که برای اولین بار در [۲۶] مطرح شد و در بسیاری از مقالات مرتبط با فیلتر ذره‌ای به کار گرفته شده است، مورد بررسی قرار خواهد گرفت

$$x_t = \frac{1}{2}x_{t-1} + \frac{25x_{t-1}}{1+x_{t-1}} + 8 \cos(1,2t) + \omega_t \\ y_t = \frac{x_t}{2} + v_t \quad (22)$$

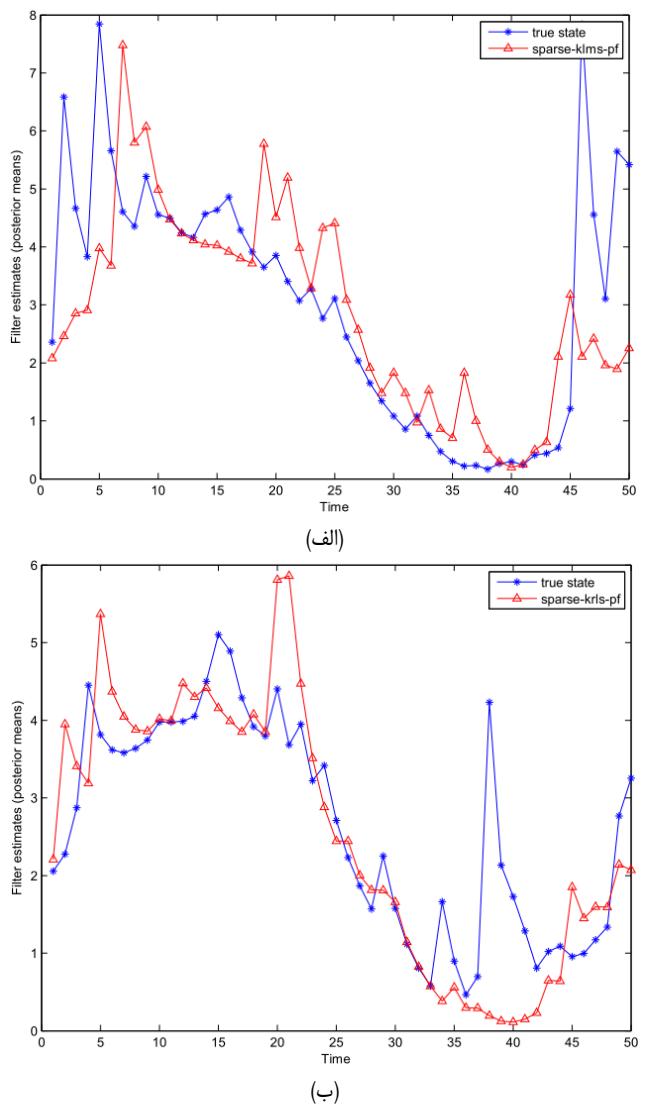


شکل ۵: نتیجه تخمین حالت برای مدل اول در ۵۰ گامنهای توسط الگوریتم (الف) sparse_KRLS_PF و (ب) sparse_KLMS_PF

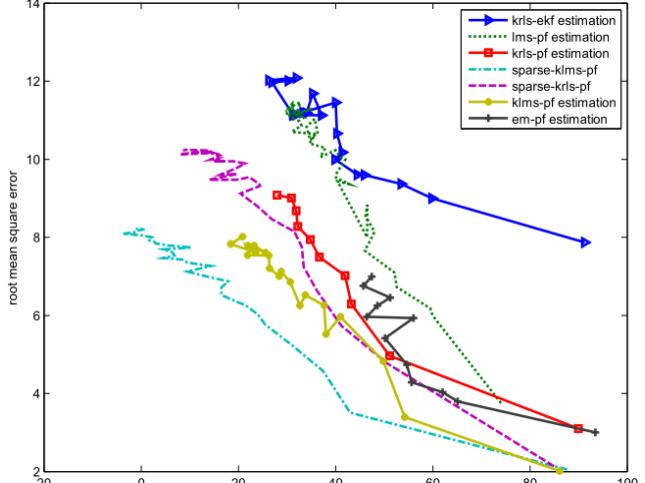
گرفت. نویز حالت به صورت گوسی و کواریانس نویز بین $0.0005 \times I_2$ در نظر گرفته شده است. نسبت سیگنال به نویز (SNR) به ازای نویز با دامنه‌های مختلف برای هر الگوریتم محاسبه شده است. چنانچه در شکل ۶ مشاهده می‌شود ریشه متوسط مربعات خطأ (RMSE) در روشن KRLS-PF تُنک در نرخ سیگنال به نویزهای مختلف، پایین‌تر است.

به عنوان مقایسه، روش فیلتر وقیی خطی حداقل میانگین مربعات LMS برای تخمین مدل مشاهده مورد استفاده قرار گرفته است. نتایج نشان می‌دهد هر چند که در صورت وجود نویز با کواریانس پایین، نتیجه تخمین از دقت قابل توجهی برخوردار است اما در صورت وجود نویز با کواریانس بالا دقت تخمین بسیار کاهش پیدا می‌کند. روش‌های KRLS_EKF و EM_PF نیز به ازای نویزهای مختلف مورد آزمایش قرار گرفته است. مقایسات نشان می‌دهد روش پیشنهادی در نویزهای مختلف خطای کمتری نسبت به دو روش ذکر شده دارد.

1. Signal to Noise Ratio
2. Root Mean Square Error



شکل ۶: نتیجه تخمین حالت برای مدل دوم در ۵۰ گامنهای توسط الگوریتم (الف) sparse_KRLS_PF و (ب) sparse_KLMS_PF

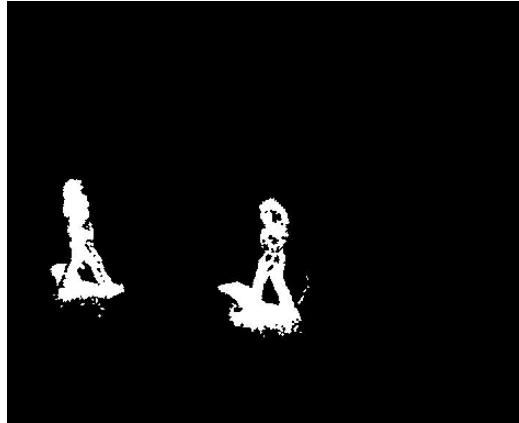


شکل ۷: مقایسه خطای تخمین برای نرخهای مختلف نویز فرایند در هفت الگوریتم برای مدل سری زمانی ۱.

آزمایش دوم- دقت الگوریتم با اعمال نویز با دامنه‌های مختلف
در آزمایشی دیگر با اعمال نویز فرایند با کواریانس‌های مختلف، نتیجه اعمال الگوریتم‌های مختلف روی سری زمانی اول، مورد بررسی قرار



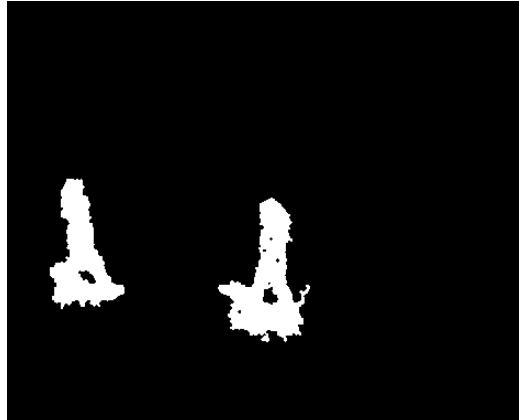
(الف)



(ب)



(ج)



(د)

شکل ۸: نمونه‌ای از خروجی تقطیع‌بافته یک فریم تصویر، (الف) تصویر حاوی افراد متوجه، (ب) تشخیص افراد متوجه با استفاده از روش ترکیب گوسی، (ج) حذف نویز با استفاده از فیلتر میانه و (د) پرکردن نواحی گسسته با استفاده از عملیات مورفولوژی.



شکل ۷: بلوك دیاگرام الگوریتم تشخیص و ردیابی ویدئویی شیء.

۴-۲ اعمال الگوریتم پیشنهادی بر ردیابی شیء مبتنی بر ویدئو

یکی از مسائل مهم بینایی ماشین ردیابی شیء بوده که کاربردهای زیادی نظیر حافظت و تجسس، بازبینی رفتار، سیستم‌های تحلیل ورزشی، رابط انسان و کامپیوتر^۲ و کنترل ترافیک جاده‌ای دارد [۱]، [۲۹] و [۳۰]. معمولاً هدف یافتن مسیر حرکت یک یا چندین شیء در طول زمان با استفاده از اطلاعات دریافتی از حسگرها^۳ است. ردیابی شیء نیازمند پردازش برخط اطلاعات بوده و هزینه زمانی بالایی دارد. دو مرحله تقطیع در سیستم ردیابی، تقطیع حرکت و ردیابی شیء است. در مرحله تقطیع حرکت، هدف تشخیص اشیای متحرک در صحنه، حذف نویز و سایه است. در این مرحله خروجی، تصویر بازبینی فریم کنونی است. در مرحله ردیابی تناظری میان اشیای متحرک فریم جاری و فریم قبل به دست می‌آید. شما می‌توانید این دو فریم را در شکل ۷ نشان داده شده است. از دیدگاه ریاضی پیکسل‌های تصاویر متوالی از یک صحنه که فاقد شیء متحرک باشند، رفتاری منظم دارند که می‌توان این رفتار منظم را با استفاده از یک مدل آماری بیان کرد. اگر چنین مدلی در اختیار باشد، می‌توان پیکسل‌هایی که توسط این مدل آماری توصیف می‌شوند را مربوط به زمینه و پیکسل‌هایی که توسط این مدل توصیف نمی‌شوند را مربوط به اشیای پیش‌زمینه دانست.

یکی از مهم‌ترین روش‌های تقطیع، مدل ترکیب گوسی^۴ [۳۱] و [۳۲] است. روش‌های مبتنی بر مدل‌های گوسی توانایی مقابله با تغییرات روشنایی، نوسانات تکراری جزیی در اشیای زمینه و جایه‌جایی‌های کوچک دوربین را دارند. در این مقاله از این روش برای تقطیع تصاویر متحرک استفاده شده است. در این روش هر پیکسل از زمینه به صورت متوالی توزیع ترکیبی از K توزیع گوسی مدل می‌شود. هر یک از این K توزیع گوسی بیان کننده یک رنگ در این ترکیب می‌باشد. اگر مقدار رنگی یک پیکسل در فریم جاری توسط یکی از توزیع‌های گوسی قابل توصیف باشد، این پیکسل مربوط به زمینه و در غیر این صورت مربوط به پیش‌زمینه خواهد بود. شکل ۸ نمونه‌ای از خروجی تقطیع‌بافته یک فریم تصویر را نشان می‌دهد. شکل (الف) تصویر حاوی افراد متحرک است. در شکل (ب) با استفاده از روش ترکیب گوسی اشیای متحرک از زمینه جدا شده و در ادامه با استفاده از فیلتر میانه نویزها حذف خواهد شد. در نهایت با استفاده از عملیات مورفولوژی نواحی گسسته پر شده و تصویر بازبینی نهایی (د) نمایانگر اشیای متحرک در تصویر خواهد شد.

وظیفه مرحله ردیابی برقراری تناظر میان اشیای تقطیع شده در فریم‌های متوالی و نگهداری مسیر در طول ردیابی است. در این تحقیق مرحله ردیابی توسط فیلتر ذره‌ای پیشنهادی انجام می‌شود. برای این منظور نیاز به معلوم‌بودن مدل حرکت هست. برای حرکت می‌توان مدل دینامیکی خطی در نظر گرفته شود. اگر مدل فوق به صورت برداری نمایش داده شود در این صورت معادلات زیر حاصل خواهد شد

1. Surveillance
2. Human-Computer Interfaces
3. Sensor
4. Gaussian Mixture Model



(الف)



(ب)



(ج)

شکل ۹: نمونه‌ها و وزن متناظر آنها، (الف) فریم تصویر، (ب) نمونه‌های تولید شده پیرامون متجر و (ج) نمونه‌ها و وزن متناظر آنها.

نیز از لحظه زمانی هزینه اجرایی بالایی داشته و برای این کاربرد مناسب نمی‌باشد. بدین منظور در مقایسات از آزمایش روش KRLS_PF نیز بر روی ویدئوهای صرف نظر گردید.

جهت ارزیابی کمی الگوریتم ارائه شده، از مقادیر مثبت درست^(۳) (TP) و مثبت کاذب^(۴) (FP) (تعداد موفقیت‌های تخمین در تشخیص شیء) و مثبت کاذب^(۴) (تعداد تخمین‌هایی که در آن شیء به عنوان پیش‌زمینه در نظر گرفته شده در حالی که عملاً مربوط به زمینه هست) استفاده شده است. معیار مورد

3. True Positive
4. False Positive

جدول ۲: خصوصیات ویدئوهای مورد استفاده.

ویدئوی چهارم	ویدئوی سوم	ویدئوی دوم	ویدئوی اول	تعداد فریم‌ها
۸۰۰	۵۲۰	۳۷۷	۳۶۲	سايز فریم‌ها
۲۸۸×۳۵۲	۲۸۸×۳۵۲	۶۴۰×۲۴۰	۵۷۶×۷۰۴	نرخ فریم‌ها (frames/second)
۲۵	۲۵	۲۵	۳۰	

$$X_{t+1} = AX_t + B \quad (22)$$

و معادله اندازه‌گیری برای این مدل نیز به صورت زیر خواهد بود

$$x_m(t) = h(x_t) + v_t \quad (22)$$

که $x_m(t)$ مکان اندازه‌گیری شده در زمان t و v_t نویز اندازه‌گیری است. در این مقاله این رابطه مجھول در نظر گرفته شده و توسط روش پیشنهادی به تخمین حالت پرداخته شده است. جهت ردیابی شیء در ویدئو با استفاده از فیلتر ذرهای در کام زمانی ۶ام، با توجه به مدل فرایند، تعداد N نمونه جدید با استفاده از نمونه‌های گام زمانی قبل تولید می‌شود. نمونه‌ها پیرامون مکان جسم پراکنده خواهند بود. سپس مشاهده مورد نظر که در اینجا مکان تقریبی جسم است، اندازه‌گیری خواهد شد. مدل مشاهده به صورت کلی (۲۳) در نظر گرفته شده است. پس از تخمین این مدل با استفاده از روش پیشنهادی، با محاسبه تفاضل مشاهده اندازه‌گیری شده و مقدار به دست آمده ازتابع مشاهده تخمینی، مقدار خطای به دست آمده و سپس وزن نمونه‌ها محاسبه می‌شود. با داشتن وزن‌ها، نمونه‌های مرکز در بخش‌های متحرک مورد نظر دارای وزن بیشتر و نمونه‌های دورتر، وزن کمتری خواهند داشت. در نهایت حالت مورد نظر با داشتن نمونه‌های وزن دار تقریب زده می‌شود. در شکل ۹ نمونه‌ها و وزن متناظر آنها نشان داده شده است. جهت درک بهتر اعمال فیلتر ذرهای برای ردیابی اشیاء، دایره‌های موجود در شکل (ج) نمایانگر نمونه‌ها و قطر دایره‌ها نشانگر وزن متناظر با آنها است. نمونه‌های بی‌همیت‌تر وزن کمتر و قطر دایره کمتر و نمونه‌های مهم‌تر وزن بیشتر و قطر دایره بیشتری دارند.

آزمایشات روی مجموعه داده‌های ویدئویی^۱ و VOTD^۲ صورت گرفت. خصوصیات ویدئوهای مورد استفاده در جدول ۲ آمده است.

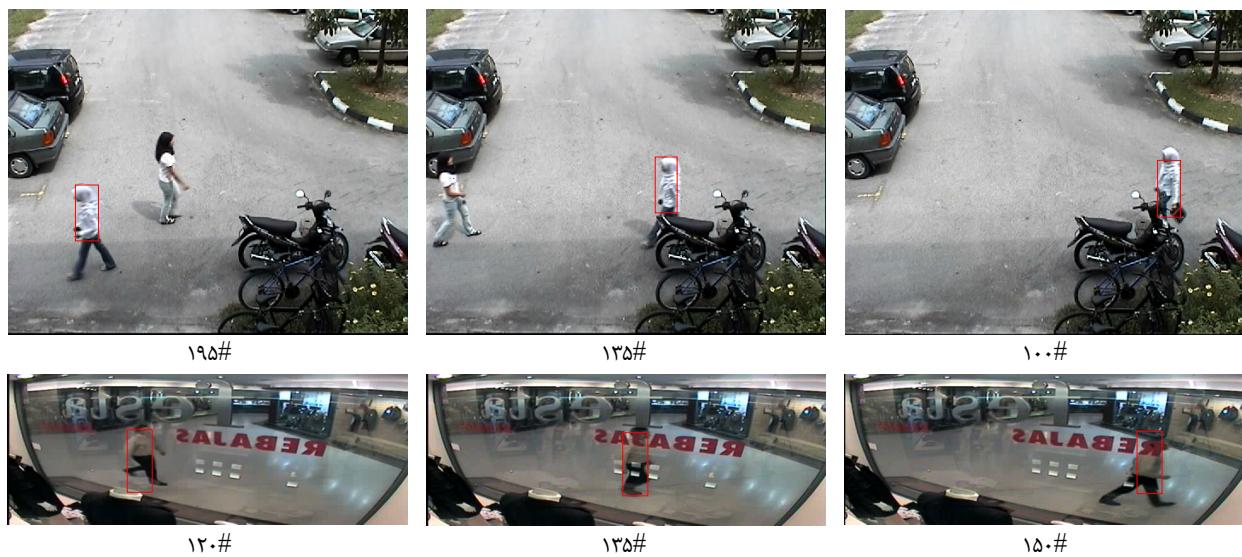
نتیجه حاصل از اعمال الگوریتم روی ویدئوهای معرفی شده در چند فریم مختلف در شکل‌های ۱۰ تا ۱۲ نشان داده شده است. شماره فریم‌ها در زیر هر تصویر درج شده است.

عمل ردیابی با استفاده از الگوریتم EM_PDF مورد آزمایش قرار گرفت. به طور متوسط برای ۱۰۰ فریم، ردیابی در ۲۵ ثانیه صورت گرفت که زمان نسبتاً بالایی است. به جهت بالابدن هزینه زمانی اجرای الگوریتم EM_PDF، تنها از روش KRLS_EKF برای مقایسه با روش پیشنهادی استفاده شده است. اولین معیار ارزیابی مورد استفاده دقت تخمین است. جهت مقایسه، مکان دقیق متحرک در هر فریم به روش دستی به دست آمده است. جدول ۳ خلاصه‌ای از ریشه میانگین محدود خطای تخمین را برای دو روش نشان می‌دهد که عملکرد بهتر الگوریتم پیشنهادی در آن مشاهده می‌شود.

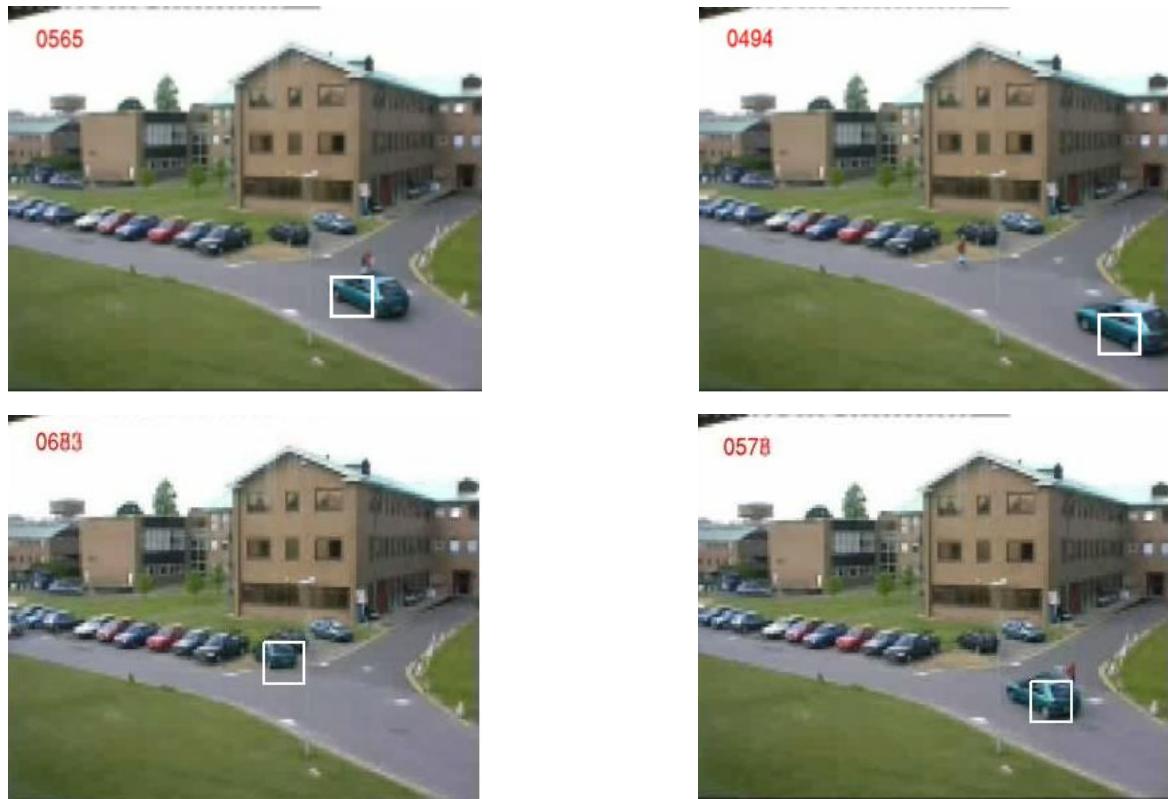
مشابه الگوریتم EM_PDF روش فیلتر ذرهای با تابع مشاهده KRLS

1. <http://www.cvg.rdg.ac.uk/slides/pets.html>

2. http://ibgusm.org/v1/index.php?option=com_content&view=article&id=101&Itemid=64



شکل ۱۰: نتیجه اعمال الگوریتم پیشنهادی به ویدئوی اول و دوم در چند فریم.



شکل ۱۱: نتیجه اعمال الگوریتم پیشنهادی به ویدئوی سوم در چند فریم.

جدول ۳: خطا تخمین حالت در ویدئو در چهار روش.

	RMSE (mean)		ویدئوی چهارم		RMSE (mean)		ویدئوی دوم		RMSE (mean)		ویدئوی اول (mean)	
	X axis	Y axis	X axis	Y axis	X axis	Y axis	X axis	Y axis	X axis	Y axis	X axis	Y axis
KLMS-PF	۲/۱۲۰۹	۲/۱۰۱۴	۲/۱۰۴۹	۲/۱۲۰۱	۲/۱۰۵۳	۲/۱۱۹۸	۲/۱۰۴۷	۲/۰۹۷۹	۲/۱۰۴۷	۲/۰۹۷۹	۲/۱۰۴۷	۲/۰۹۷۹
Sparse-KLMS-PF	۲/۱۱۵۳	۲/۱۰۹۷	۲/۱۱۳۱	۲/۱۰۷۶	۳/۰۹۷۹	۲/۱۰۲۵	۲/۱۴۴۴	۲/۱۱۸۹	۲/۱۰۲۵	۲/۱۴۴۴	۲/۱۱۸۹	۲/۱۱۸۹
Sparse-KRLS-PF	۲/۱۰۸۴	۲/۱۰۱۴	۲/۱۱۳۲	۲/۱۰۹۰	۲/۱۲۳۷	۲/۱۱۰۶	۳/۱۱۹۳	۳/۱۰۹۹	۲/۱۱۰۶	۳/۱۱۹۳	۳/۱۰۹۹	۳/۱۰۹۹
KRLS_EKF	۳/۶۲۱۱	۳/۵۱۰۸	۳/۶۰۸۲	۳/۶۱۰۱	۳/۶۰۹۱	۳/۶۰۹۹	۳/۶۱۱۱	۳/۶۱۱۱	۳/۶۰۹۹	۳/۶۱۱۱	۳/۱۲۵۳	۳/۱۲۵۳

بررسی درصد دقت است که از نسبت تعداد مقادیر مثبت درست به تعداد کل تخمین‌ها (مثبت درست یا مثبت کاذب) به دست می‌آید. جدول ۴ نتیجه این معیار برای ویدئوهای مختلف را نمایش می‌دهد.

در این مقاله یک روش جدید برای تخمین مدل مشاهده در فیلتر ذره‌ای ارائه شده است. فیلتر ذره‌ای یکی از روش‌های فیلتر بیزی است که

۵- نتیجه‌گیری



شکل ۱۲: نتیجه اعمال الگوریتم پیشنهادی به ویدئوی چهارم در چند فریم.

جدول ۴: نتیجه دقت تخمین در ویدئوهای مختلف.

روش ریدیابی	ویدئوی اول	ویدئوی دوم	ویدئوی سوم	ویدئوی چهارم
KLMS-PF	۰,۹۴	۰,۹۵	۰,۹۶	۰,۹۴
Sparse-KLMS-PF	۰,۹۴	۰,۹۶	۰,۹۵	۰,۹۷
Sparse-KRLS-PF	۰,۹۵	۰,۹۵	۰,۹۵	۰,۹۴
KRLS_EKF	۰,۸۸	۰,۸۹	۰,۹۰	۰,۹۱

در هر مرحله توزیع حالت فعلی سیستم را با استفاده از مشاهدات رسیده تا زمان حال تخمین می‌زند. این تخمین با استفاده از تعدادی نمونه وزن دار صورت می‌گیرد. از تابع مشاهده در محاسبه وزن مربوط به نمونه‌ها در هر گام استفاده می‌شود. در روش پیشنهادی با فرض موجودبودن مدل فرایند و مجهول‌بودن مدل مشاهدات و با در اختیار داشتن مشاهدات، تابع مشاهدات در هر گام زمانی با استفاده از فیلترهای تطبیقی کرنلی KRLS یا KLMS تخمین زده شده و در ادامه نمونه‌های هر گام وزن دهنده خواهد شد. روش پیشنهادی در دو کاربرد مورد ارزیابی قرار گرفت. در ابتدا چند مثال ساده از پیش‌بینی سری‌های زمانی ارزیابی شد. دقت و سرعت الگوریتم پیشنهادی با دو روش KRLS_EKF و EM_PF مورد مقایسه قرار گرفت. در مقایسه‌ها نشان داده شد که دقت محاسبات الگوریتم پیشنهادی نسبت به دو روش دیگر بالاتر بوده اما از لحاظ سرعت روش KRLS_EKF به الگوریتم پیشنهادی برتری دارد. همچنین سرعت الگوریتم پیشنهادی نسبت به روش EM_PF بسیار بالاتر است. در ادامه قابلیت ریدیابی الگوریتم پیشنهادی مورد ارزیابی قرار گرفت. در مواردی که مدل مشاهده با زمان تغییر می‌کند، در زمان‌های مختلف الگوریتم اعمال شده که با توجه به تغییر ناچیز در خطای تخمین، قابلیت ریدیابی این روش مشخص می‌شود. در کاربردی دیگر الگوریتم پیشنهادی روی ویدئو مورد ارزیابی قرار گرفت. در مقایسه خطای تخمین روش پیشنهادی با KRLS_EKF برتری روش پیشنهادی نشان داده شده است.

مراجع

- [1] H. Liu and F. Sun, "Efficient visual tracking using particle filter with incremental likelihood calculation," *Information Sciences*, vol. 195, pp. 141-153, Jul. 2012.
- [2] G. G. Rigatos, "Nonlinear kalman filters and particle filters for integrated navigation of unmanned aerial vehicles," *Robotics and Autonomous Systems*, vol. 60, no. 7, pp. 978-995, Jul. 2012.
- [3] S. Park and S. Choi, "A constrained sequential EM algorithm for speech enhancement," *Neural Networks*, vol. 21, no. 9, pp. 1401-1409, Nov. 2008.
- [4] A. Ahmad and P. Lima, "Multi-robot cooperative spherical-object tracking in 3D space based on particle filters," *Robotics and Autonomous Systems*, vol. 61, no. 10, pp. 1084-1093, Oct. 2013.
- [5] L. E. H. Olivier, B. Craig, and I. K. Craig., "Dual particle filters for state and parameter estimation with application to a run-of-mine ore mill," *J. of Process Control*, vol. 22, pp. 710-717, 2012.
- [6] X. Yang, K. Xing, K. Shi, and Q. Pan, "Joint state and parameter estimation in particle filtering and stochastic optimization," *J. of Control Theory and Applications*, vol. 6, no. 2, pp. 215-220, May 2008.
- [7] Z. Messaoudi, A. Ouldali, and M. Oussalah, "Comparison of interactive multiple model particle filter and interactive multiple model unscented particle filter for tracking multiple manoeuvring targets in sensors array," in *Proc IEEE 9th Int. Conf. on, Cybernetic Intelligent Systems, CIS'10*, 6 pp., 1-2 Sep. 2010.
- [8] X. Wang and C. Z. Han, "A multiple model particle filter for maneuvering target tracking based on composite sampling," *Acta Automatica Sinica*, vol. 39, no. 7, pp. 1152-1156, 2013.
- [9] S. Seifzadeh, B. Khaleghi, and F. Karray, "Distributed soft-data-constrained multi-model particle filter," *IEEE Trans. on Cybernetics*, vol. 45, no. 3, pp. 384-394, Mar. 2015.
- [10] B. V. Srinivasan, *Gaussian Process Regression for Model Estimation*, Electrical Engineering, University of Maryland, 2008.
- [11] P. Zhu, B. Chen, and J. C. Principe, "A novel extended kernel recursive least squares algorithm," *Neural Networks*, vol. 32, pp. 349-357, Aug. 2012.
- [12] B. Ristic, S. Arulampalam, and N. Gordon, *Beyond the Kalman Filter: Particle Filters for Tracking Applications*, Artech House, 2004.
- [13] B. Oreshkin and M. Coates, "Bootstrapping particle filters using kernel recursive least squares," in *Proc. IEEE Aerospace Conf.*, 7 pp., 2007.

- tracking," *IEEE Trans. on Signal Processing*, vol. 50, no. 2, pp. 174-188, Feb. 2002.
- [26] M. Netto, L. Gimeno, and M. Mendes, "On the optimal and suboptimal nonlinear filtering problem for discrete-time systems," *IEEE Trans. on Automatic Control*, vol. 23, no. 6, pp. 1062-1067, Dec. 1978.
- [27] H. Zhen-Tao, L. Qi, and L. Xian-Xing, "A novel particle filter based on two stage prediction update," *Energy Procedia*, vol. 13, pp. 7389-7396, 2011.
- [28] T. K. Amin Zia, J. P. Reilly, D. Yee, K. Punithakumar, and S. Shirani, "An EM algorithm for nonlinear state estimation with model uncertainties," *IEEE Trans. on Signal Processing*, vol. 56, no. 3, pp. 921-936, Mar. 2008.
- [29] Y. L. G. Yang and P. Bhattacharya, "A driver fatigue recognition model based on information fusion and dynamic Bayesian network," *Information Sciences*, vol. 180, no. 10, pp. 1942-1954, 15 May 2010.
- [30] S. Zheng, "An intensive restraint topology adaptive snake model and its application in tracking dynamic image sequence," *Information Sciences*, vol. 180, no. 16, pp. 2940-2959, 15 Aug. 2010.
- [31] Z. Zivkovic, "Improved adaptive gaussian mixture model for background subtraction," in *Proc. of the 17th Int'l Conf. on Pattern Recognition, ICPR'04*, vol. 2, pp. 28-31, 2004.
- [32] P. Gorur and B. Amrutur, "Speeded up gaussian mixture model algorithm for background subtraction," in *Proc. of 8th IEEE International Conf. on Advanced Video and Signal-Based Surveillance, AVSS'11*, pp. 386-391, 30 Aug.-2 Sep. 2011.
- حمیده حائری** مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب در سال های ۱۳۸۹ و ۱۳۹۱ در رشته مهندسی کامپیوتر از دانشگاه فردوسی مشهد دریافت کرد. زمینه های علمی مورد علاقه او یادگیری ماشین، شناسایی الگو و پردازش تصویر است.
- هادی صدقی** یزدی هم اکنون استاد گروه کامپیوتر در دانشگاه فردوسی مشهد است. مدرک کارشناسی خود را در دانشگاه فردوسی مشهد و مدارک کارشناسی ارشد و دکتری کترونیک را در دانشگاه تربیت مدرس اخذ نموده است. علاقه مندی او به شناسایی الگو و پردازش سیگنال است.
- [14] J. Yu, Y. Tang, J. Xu, and Q. Zhao, "Research on particle filter based on an improved hybrid proposal distribution with adaptive parameter optimization," in *Proc. Fifth Int. Conf. on Intelligent Computation Technology and Automation, ICICTA'12*, pp. 406-409, 12-14 Jan. 2012.
- [15] S. Kim and J. S. Park, "Sequential Monte Carlo filters for abruptly changing state estimation," *Probabilistic Engineering Mechanics*, vol. 26, no. 2, pp. 194-201, 2011.
- [16] N. J. Gordon, D. J. Salmond, and A. F. M. Smith, "Novel approach to nonlinear/non-Gaussian Bayesian state estimation," *IEE Proc. F: Radar and Signal Processing*, vol. 140, no. 2, pp. 107-113, Apr. 1993.
- [17] W. L. Jose C. Principe, Simon Haykin, *Kernel Adaptive Filtering: A Comprehensive Introduction*, Hoboken, New Jersey: John Wiley & Sons, 2010.
- [18] S. Haykin, *Adaptive Filter Theory*, Prentice Hall, 1996.
- [19] S. B. Chitralekha, J. Prakash, H. Raghavan, R. B. Gopaluni, and S. L. Shah, "A comparison of simultaneous state and parameter estimation schemes for a continuous fermentor reactor," *J. of Process Control*, vol. 20, no. 8, pp. 934-943, Sep. 2010.
- [20] I. P. Weifeng Liu and J. C. Principe, "An information theoretic approach of designing sparse kernel adaptive filters," *IEEE Trans. on Neural Networks*, vol. 20, no. 12, pp. 1950-1961, Dec. 2009.
- [21] D. Nguyen-Tuong and J. Peters, "Incremental online sparsification for model learning in real-time robot control," *Neurocomputing*, vol. 74, no. 11, pp. 1859-1867, May 2011.
- [22] A. Doucet, S. Godsill, and C. Andrieu, "On sequential Monte Carlo sampling methods for Bayesian filtering," *Statistics and Computing*, vol. 10, no. 3, pp. 197-208, Jul. 2000.
- [23] F. Desbouvries, Y. Petetin, and B. Ait-El-Fquih, "Direct, prediction- and smoothing-based Kalman and particle filter algorithms," *Signal Processing*, vol. 91, no. 8, pp. 2064-2077, Aug. 2011.
- [24] A. C. Sankaranarayanan, A. Srivastava, and R. Chellappa, "Algorithmic and architectural optimizations for computationally efficient particle filtering," *IEEE Trans. on Image Processing*, vol. 17, no. 5, pp. 737-748, May 2008.
- [25] M. S. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, "A tutorial on particle filters for online nonlinear/non-gaussian bayesian