

تخمین چند دوربینی حالت سه بعدی انسان با برازش افکنش مدل اسکلت سه بعدی مفصل دار در تصاویر سایه نما

قاسم خادمی و حسین ابراهیم زاد

آزمایشگاه تحقیقاتی بینایی کامپیوتر، دانشکده مهندسی برق، دانشگاه صنعتی سهند

چکیده

تحلیل و ضبط خودکار حرکت انسان بر اساس تصاویر یا ویدیو به دلیل کاربردهای بسیار زیاد در پویانمایی، نظارت، بیومکانیک، تعامل بین انسان و رایانه، صنعت بازی و سرگرمی اهمیت بسیار زیادی در بینایی رایانه دارد. در این کاربردها، تخمین حالت سه بعدی انسان از قسمت های اساسی است و به همین دلیل دقّت تخمین بر عملکرد این کاربردها تأثیر زیادی دارد. تخمین حالت سه بعدی انسان از مشاهدات تصویری با توجه به بازه وسیع تغییرات در ظاهر و مفصل بندی انسان، ابعاد بالا در فضای حالت انسان و پدیده خودانسدادی، یک مسئله بحث برانگیز است. در این مقاله، روشی جدید برای تخمین حالت سه بعدی انسان در رشتہ ویدئویی چند دوربینی معرفی می شود. در روش پیشنهادی، به جای جستجوی مستقیم فضای حالت ابعاد بالای انسان و استفاده از الگوریتم های استنتاج پیچیده، از یک روش جستجوی سلسه مراتبی، توابع هدف جداگانه برای قسمت های مختلف بدن و روش های بهینه سازی مستقیم استفاده شده است. مزایای روش پیشنهادی، ارزش دهی اولیه خودکار، برچسبزنی قسمت های مختلف کانتور بدن و استفاده از توابع هدف جداگانه برای قسمت های مختلف بدن است. نتایج آزمایش، نشان می دهد که روش پیشنهادی می تواند به طور مؤثری به عنوان یک سامانه بدون نشانه برای تخمین حالت سه بعدی انسان در رشتہ ویدیویی چند دوربینی به کار گرفته شود.

واژگان کلیدی: تخمین سه بعدی حالت انسان، ضبط حرکت انسان، مدل مفصل دار، بهینه سازی، تصاویر سایه نما و اسکلت سه بعدی.

بسیار زیادی دارند. تخمین سه بعدی حالت انسان از قسمت های اساسی در این کاربردها و دقّت تخمین به طور مستقیم بر عملکرد آنها اثرگذار است. برای نمونه، در صنعت بازی های رایانه ای و سرگرمی، حالت سه بعدی تخمین زده شده انسان برای ایجاد پویانمایی های واقعی از حرکات انسان به کار می رود. در علوم ورزشی، بازسازی دقیق حالت سه بعدی انسان به ورزش کاران کمک می کند تا به صورت دیداری حرکات خودشان را برای بهبود عملکرد فعالیت شان تحلیل نمایند. در زمینه فیزیوتراپی، برای شناسایی دلایل اساسی وضعیت های نامطلوب حرکتی بیمار که ممکن است به علت ضربه، فلجه مغزی یا دیگر مشکلات عصبی و عضلانی باشد، از تحلیل راه رفتمن انسان استفاده می شود. در زمینه کاربرد نظارت ویدیویی⁷ با استفاده از دوربین های ارزان

۱- مقدمه

تحلیل و ضبط خودکار حرکت انسان به دلیل پیچیدگی مسئله و کاربردهای بسیار زیادش، یکی از زمینه های تحقیقاتی بسیار فعال است. این زمینه تحقیقاتی شامل تعدادی از مسائل دشوار مانند استنتاج حالت^۱ و حرکت یک جسم سه بعدی غیرصلب^۲ مفصل دار^۳ با خاصیت خودانسدادی^۴ از روی تصاویر است. پیچیدگی این مسائل، تحقیقات در این زمینه را از نقطه نظر آکادمیک بحث برانگیز می سازد. تکنیک های تخمین حالت سه بعدی انسان^۵ که از سامانه های مبتنی بر بینایی^۶ استفاده می کنند، کاربردهای

¹Pose

²Non-rigid

³Articulated

⁴Self-occluding

⁵3D human pose estimation

⁶Vision-based

⁷ Video surveillance

استخراج می‌شوند. همچنین با استفاده از نواحی پوستی آشکارسازی شده چند نقطه کلیدی دیگر به عنوان یک تخمین اولیه مناسب از موقعیت سر و دست‌ها استخراج می‌شوند. با استفاده از نقاط کلیدی دو بعدی استخراج شده در صفحات تصویر می‌توان موقعیت‌های سه بعدی اولیه سر، گردن، دست‌ها و مفاصل را به دست آورد که در هم‌گرایی الگوریتم به پیکربندی حالت صحیح مؤثرند. در ادامه، با استفاده از روش پیشنهادی برچسبزنی کانتور، پیکسل‌های کانتور و نواحی پوست اعضای مختلف بدن از یکدیگر تفکیک و به عنوان ورودی تابع هدف پیشنهادی به منظور تخمین حالت سه بعدی انسان استفاده می‌شوند. همچنین استفاده از یک روش جستجوی سلسله‌مراتبی برای مهارکردن جستجو در این فضای ابعاد بالا پیشنهاد می‌شود؛ به طوری که در هر مرحله فقط پارامترهای مربوط به یک استخوان از بدن انسان با توجه به ترتیب سلسله‌مراتبی در درخت سینماتیک بدن انسان بهینه‌سازی مستقیم برای جستجوی درجه‌های آزادی هر عضو، مواجه‌شدن با کمینه‌های محلی یک مسئله، بحث‌برانگیز است. برای حل این مسئله در روش پیشنهادی، با استفاده از ویژگی‌های استخراج شده در هر فریم و اطلاعات فریمهای قبلی، ارزش‌دهی اولیه مناسب برای پارامترها انجام شد و با به کارگیری روش‌های جستجوی محلی در اطراف مقادیر اولیه پارامترها، پارامترهای مدل بهینه می‌شوند. روش پیشنهادی نیازمند یک تابع هدف برای بهینه‌سازی هر عضو بدن است. این تابع هدف بر مبنای تفاضل فاصله از مرز کانتور هر عضو فرمول‌بندی می‌شود.

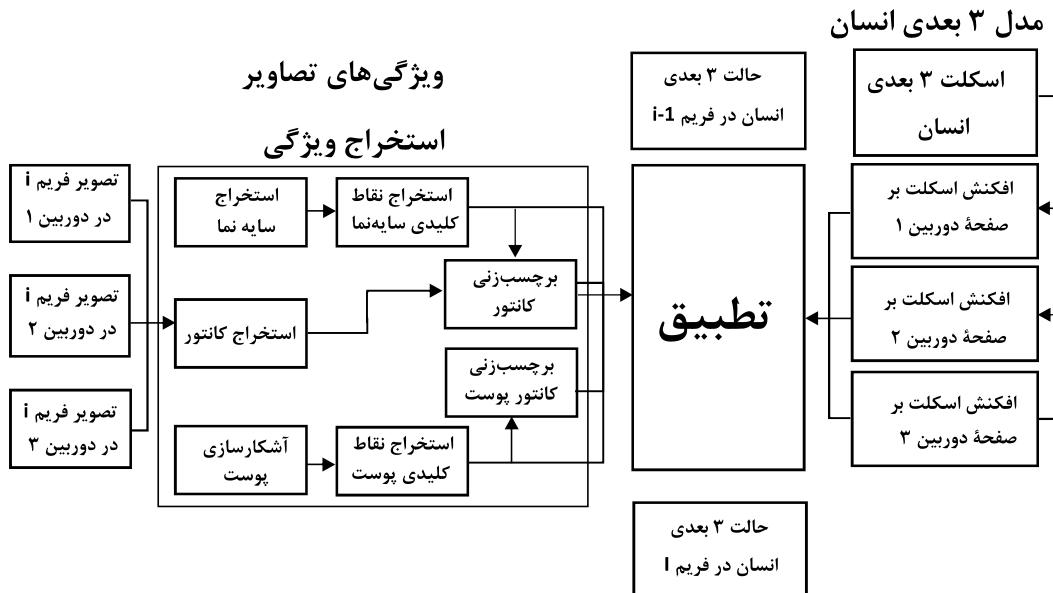
۲- کارهای مرتبط

در سال‌های اخیر کارهای عمده‌ای برای بازیابی حالت کامل بدن انسان از تصاویر و ویدیوهای چند دوربینی انجام شده است. در این بخش، روش‌هایی که مربوط به استنتاج سه بعدی چند دوربینی حالت انسان هستند به صورت کلی توصیف می‌شوند.

قیمت و ایجاد بهبود در قدرت محاسباتی، تحلیل دقیق حالت سه بعدی انسان از ویدیو، می‌تواند اپراتورهای ناظر را برای شناسایی رویدادهایی از قبیل دویدن، راه رفت، دزدی از مغازه‌ها، بالا رفتن از دیوار، پرسه‌زن و دیگر فعالیت‌های غیرطبیعی انسان کمک کند.

در این مقاله، یک روش خودکار برای تخمین و ردیابی حالت بدن انسان در فضای سه بعدی با استفاده از سه دوربین معرفی می‌شود. از یک مدل اسکلتی سینماتیک، برای مدل سازی بدن انسان استفاده می‌شود. این مدل به صورت پانزده نقطه در فضای سه بعدی که معرف مفاصل کلیدی بدن انسان و چهارده خط که معرف استخوان‌ها و یا قسمت‌های صلب بدن انسان هستند، در نظر گرفته می‌شود. تخمین حالت بدن انسان در هر فریم با استفاده از تطبیق اسکلت سه بعدی بر تصاویر سه دوربین از نماهای مختلف انجام می‌شود. پیکربندی اسکلت سه بعدی بهینه زمانی حاصل می‌شود که افکنش خطوط اسکلت سه بعدی در سه نما از دوربین‌های مختلف در وسط مرز عضوهای متناظر بدن انسان قرار گیرد. در واقع جستجوی زوایای اتصال مفاصل با این هدف انجام می‌شود که در تمام نماها تفاضل فاصله‌های افکنش خطوط اسکلت از مرز سایه‌نمای^۱ بدن کمینه شود. با استفاده از این ایده می‌توان درجه‌های آزادی هر یک از اعضای بدن را (زوایای اتصال مفاصل) در فضای سه بعدی تخمین زد. یکی از چالش‌های اصلی در تخمین و ردیابی حالت انسان مواجه شدن با یک فضای جستجوی ابعاد بالاست. از این‌رو بازیابی حالت کامل بدن انسان به طور مستقیم دشوار، اما محاسبه موقعیت هر یک از اعضای بدن به تنهایی راحت‌تر است. (شکل ۱) بلوک دیاگرام روش پیشنهادی را نشان می‌دهد. در روش پیشنهادی، حالت سه بعدی انسان از طریق تطبیق ویژگی‌های تصاویر سه دوربین مختلف و مدل اسکلتی سه بعدی استنتاج می‌شود. ابتدا ویژگی‌های تصویر در هر نما استخراج و سپس ویژگی‌های استخراج شده از هر تصویر دوربین با افکنش مدل سه بعدی انسان بر آن صفحه تصویر از طریق یک تابع هدف پیشنهادی تطبیق داده می‌شوند. همان‌طور که در (شکل ۱) مشاهده می‌شود، ابتدا سایه‌نمای، کانتور و نواحی پوستی بدن انسان از تصاویر سه دوربین مختلف در فریم نام استخراج می‌شوند. چند نقطه کلیدی از سایه‌نمای به عنوان تخمین اولیه از محل ریشه بدن، مفاصل قوزک و زانوی پاها

^۱ Silhouette



(شکل ۱): نمودار جعبه‌ای روش پیشنهادی

پوسته قابل مشاهده این است که بر جدای از پس زمینه تقریباً کامل تکیه دارند. سایه‌نماهای نوفه‌ای حتی فقط از یک دوربین باعث ایجاد سوراخ‌هایی در حجم سه‌بعدی بازسازی شده می‌شود که به‌طور قابل ملاحظه‌ای بیان حجمی را نادرست می‌سازد. برای مقابله با این مشکل، روشی به نام شبکه اشغال احتمالاتی^۲ در (Franco and Boyer 2005) معرفی شده است که در آن پوسته قابل مشاهده معادل با درنظر گرفتن سطح همسان^۳ از چگالی در یک احتمال معین به‌دست می‌آید. هنگامی که حجم بازیابی شد، ردیابی شکل سه‌بعدی با استفاده از روش بهینه‌سازی تصادفی کاهشی متا^۴ (Kehl, Bray et al. 2005) یا الگوریتم نزدیک‌ترین نقطه تکراری^۵ (Mundermann, Corazza et al. 2006) انجام می‌شود.

روش‌های مبتنی بر افکنش مدل (Gavrila and Davis 1996; Deutscher, Blake et al. 2000; Sigal, 2004) از افکنش مدل بر تصاویر نماهای مختلف بدون درنظر گرفتن اجتماع مشاهدات سطح پایین تصویر در تمام نماها استفاده می‌کنند. همچنین، این روش‌ها برخلاف روش‌های مبتنی بر پوسته قابل مشاهده، نیازمند استفاده از داده‌های سایه‌نمای به‌طور تقریبی کامل نیستند. در این روش‌ها، نماهای مختلف با استفاده از یکتابع همانندی، مورد بررسی قرار می‌گیرند که در آنها اغلب، استقلال در تمام نماها فرض می‌شود (Deutscher, Blake et al. 2000).

اکثر روش‌هایی را که با چند دوربین سروکار دارند، می‌توان به دو دسته کلی تقسیم‌بندی کرد: یک دسته روش‌هایی که به صراحت از پوسته قابل مشاهده^۶ استفاده و دسته دیگر روش‌هایی که بدون بازسازی صریح بیان حجمی بدن انسان از افکنش یک مدل سه‌بعدی بر تصاویر استفاده می‌کنند. در هر دو مورد ذکر شده، معلوم‌بودن پارامترهای دوربین (هر دوی پارامترهای داخلی و خارجی) به منظور درنظر گرفتن ارتباط بین اطلاعات در دوربین‌های مختلف ضروری است.

روش‌های مبتنی بر پوسته قابل مشاهده به صراحت از ارتباط ویژگی‌های نماهای مختلف برای بازسازی هندسه محدوده سه‌بعدی تقریبی جسم واقعی استفاده می‌کنند. زمانی که تعداد نماها افزایش پیدا می‌کند، می‌توان نشان داد که پوسته قابل مشاهده، به‌شكل واقعی جسم نزدیک می‌شود. اکثر روش‌های مبتنی بر پوسته قابل مشاهده (Cheung, Baker et al. 2003; Kehl, Bray et al. 2005) یک فرآیند تفرقی پس‌زمینه خوب و سایه‌نماها به‌منظور تعریف مخروط سایه‌نما تکیه می‌کنند. مخروط‌های سایه‌نما با استفاده از مراکز دوربین‌ها و سایه‌نما موجود می‌آیند. اشتراک مخروط‌های دوربین‌های مختلف، کران بالای فضای اشغال شده توسط جسم را تعریف می‌کند. همچنین روش‌هایی وجود دارند که با استفاده از رنگ‌آمیزی و کسل (Cheung, Baker et al. 2003) ثبات رنگ را نیز در تمام نماها در نظر می‌گیرند. مشکل اصلی روش‌های مبتنی بر

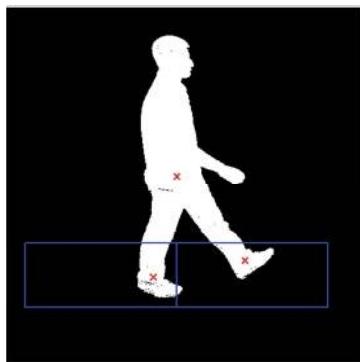
²Probabilistic occupancy grid

³Iso surface

⁴Stochastic Meta Descent (SMD)

⁵Iterative Closest Point (ICP)

⁶Visual hull



(شکل ۲): نمایش نقاط کلیدی سایه‌نما

در روش آنها شامل چهارده نقطه کلیدی بدن انسان است که با توجه به شباهت زیاد مدل اسکلت آنها با مدل اسکلت پیشنهادی در این مقاله، می‌توان نتایج الگوریتم پیشنهادی این مقاله را با روش آنها به صورت کمی مقایسه کرد.

ترکیب همانندی‌های مبتنی بر هر نما می‌تواند یک معیار کلی را برای تطبیق حالت استنتاج نمایند. در روش پیشنهادی نیز از افکنش مدل اسکلت سه‌بعدی انسان بر تصاویر سه‌بعدی دوربین‌ها استفاده شده است.تابع هدف برای هر نما دوربین به صورت مستقل تعریف شده است و تطبیق حالت سه‌بعدی بر مبنای ترکیب توابع هدف تعریف شده انجام شده است. ترکیب توابع هدف به صورت مجموع توابع هدف سه‌بعدی دوربین‌ها در نظر گرفته شده است و تطبیق حالت سه‌بعدی انسان با ویژگی‌های تصاویر سه‌بعدی دوربین با استفاده از کمینه‌سازی تابع هدف ترکیب شده انجام می‌شود.

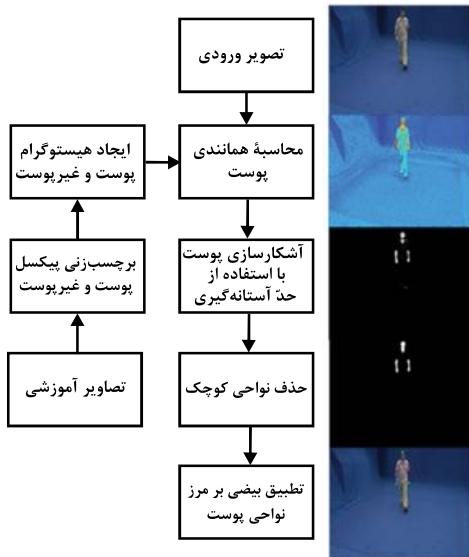
در (Hofmann and Gavrila 2012) یک روش برای تخمین حالت قسمت بالای بدن انسان از روی تصاویر چند دوربین بر اساس ترکیب اطلاعات شکل و بافت ارائه شده است. در این روش، جهت بازیابی حالت شخص در یک فریم مشخص، از یک مرحله تولید فرض که در آن حالت‌های سه‌بعدی نامزد بر اساس مقایسه سلسه‌مراتبی شکل در هر دوربین ایجاد می‌شود، استفاده شده است. سپس در مرحله تأیید فرض، حالات سه‌بعدی نامزد به نهایت دوربین‌های دیگر باز افکنده شده و بر طبق یک اندازه‌سنجی، رتبه‌بندی می‌شوند. در ادامه، فریمهایی که تخمین حالت برای آنها با دقّت خوبی انجام گرفته است، به تعداد مشخصی انتخاب شده و از آنها برای تولید یک مدل بافتی استفاده می‌گردد.

در (Zhu, Dariush et al. 2010) یک روش مبتنی بر مدل برای تخمین حالت سه‌بعدی انسان با استفاده از شناسایی مجموعه‌ای از نقاط کلیدی بدن انسان از روی تصاویر عمق به دست آمده از یک تصویربردار زمان رفت و برگشت^۱ (TOF) معرفی شده است. سامانه پیشنهادی آنها در سه مرحله اصلی انجام می‌شود. در مرحله اول با استفاده از یک آشکارساز مبتنی بر چارچوب بیزین که از اطلاعات مکانی و زمانی در یک رشته ویدیویی استفاده می‌کند، نقاط کلیدی بدن انسان در فضای دو بعدی شناسایی و رديابي می‌شوند. در مرحله دوم با استفاده از قيدهای حرکتی بدن انسان، نقاط دو بعدی شناسایی شده به مدل سه‌بعدی حرکتی انسان نگاشت می‌شوند. در مرحله سوم نیز نقاطی که توسط آشکارساز دو بعدی به علت انسداد شناسایی نشده‌اند، تخمین زده شده و ابهاماتی که در مرحله شناسایی نقاط کلیدی وجود دارد از بین می‌روند. مدل اسکلت سه‌بعدی

^۱ Time-of-flight (TOF)

۳-۱- استخراج سایه‌نما و نقاط کلیدی

سایه‌نما یکی از ویژگی‌های رایج به کار گرفته شده در تخمین حالت انسان است. با استخراج سایه‌نما، بدن انسان در صفحه تصویر مکان‌یابی می‌شود که باعث کاهش فضای جستجوی الگوریتم برای پیکربندی صحیح بدن می‌شود. تفیق



(شکل ۳): آشکارسازی پوست

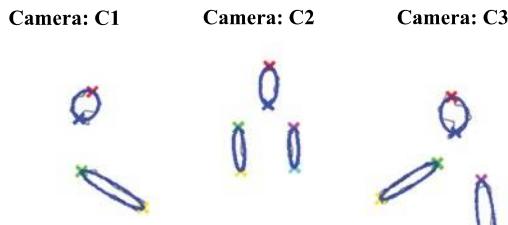
۲-۳- آشکارسازی پوست

یکی از فرض‌های رایج این است که بعضی از قسمت‌های بدن انسان توسط لباس پوشش داده نمی‌شود، که در این صورت می‌توان از رنگ پوست به عنوان یک ویژگی تشخیص برای این قسمت‌ها استفاده کرد. ویژگی‌های رنگ پوست سیگنال‌های مهمی درباره موقعیت سر، بازوها و بعضی از اوقات پaha می‌دهند. برای آشکارسازی پیکسل‌های پوست از بخشی از روش مرجع (Conaire, O'Connor et al. 2007) استفاده شده است. مراحل استخراج ویژگی‌های مبتنی بر پوست در (شکل ۳) نشان داده شده است. روش کار بدین صورت است که ابتدا مجموعه‌ای از تصاویر آموزشی در نظر گرفته می‌شود، سپس در این تصاویر آموزشی پیکسل‌های پوست و غیرپوست، به صورت دستی برچسبزنی می‌شوند. با استفاده از پیکسل‌های برچسب زده شده یک هیستوگرام RGB برای پیکسل‌های غیرپوست ایجاد می‌شود که بعد این هیستوگرام‌ها $32 \times 32 \times 32$ هستند. عدد ۳۲ در هر محور بیان گر تعداد سطوح کوانتیزاسیون در رنگ اصلی متناظر است. همان‌طور که می‌دانیم هر تصویر رنگی دارای سه مؤلفه R, G و B برای هر پیکسل است. هر یک از مقادیر R, G و B دارای گستره ۰ تا ۲۵۵ هستند. یعنی سطح کوانتیزاسیون داریم. به منظور کاهش حجم محاسبات از ۳۲ سطح کوانتیزاسیون استفاده می‌شود که دقّت خوبی برای تشخیص رنگ پوست از غیرپوست دارد.

پس زمینه^۱ فرآیندی است که اغلب برای به دست آوردن سایه‌نما مورد استفاده قرار می‌گیرد. در مواردی که پس زمینه دارای یک رنگ ثابت است، مانند پایگاه داده iD3post (GkaleIis, Kim et al. 2009) که دارای پس زمینه ثابت آبی رنگ است، می‌توان با استفاده از یک حد آستانه‌گیری ساده، سایه‌نمای انسان از پس زمینه را به راحتی استخراج کرد.

در صورت استخراج یک تصویر سایه‌نمای کامل و بدون نویه، از طریق پردازش این داده‌های باینری، می‌توان ویژگی‌هایی برای تخمین اولیه بعضی از مفاصل بدن استخراج کرد. البته، در مواردی که صحنه یا پس زمینه شلوغ باشد، اجسام متحرک دیگری در صحنه حضور داشته باشند، یا تغییرات نوری صحنه زیاد باشد و انسان حاضر در صحنه با اجسام متحرک دیگر دچار انسداد شود، استخراج یک سایه‌نمای کامل و بدون نویه در صحنه دشوار خواهد بود. در این گونه موارد ممکن است حفره‌هایی در سایه‌نما ایجاد و یا اینکه به علت وجود مانع، گسستگی در سایه‌نما ایجاد شود که حتی با استفاده از عملگرهای مورفولوژی نیز سایه‌نمای تمیز و عاری از نویه به دست نیاید. اولین ویژگی، مرکز نقل^۲، سایه‌نمای باینری است. این ویژگی اطلاعاتی در مورد کلیت انسان که چگونه در زمان جابه‌جا می‌شود و همچنین یک تقریب مکانی از مفصل ران^۳ می‌دهد که با استفاده از آن می‌توان محل قسمت‌های دیگر بدن در تصویر باینری را نیز تخمین زد. تقریب مرکز نقل باعث کاهش پیچیدگی محاسباتی در تخمین اولیه محل اسکلت بدن انسان می‌شود. کل سطح سایه‌نمای ایجاد شده از فرآیند تفربیق پس زمینه برای محاسبه مرکز نقل مورد استفاده قرار می‌گیرد. مقدار متوسط تمام موقعیت‌های پس زمینه در محور افقی و عمودی تصویر، معرف مکان مرکز نقل سایه‌نما در تصویر سایه‌نمای مرحله بعدی پیدا کردن موقعیت پا در تصویر سایه‌نماست. مرکز نقل یک پا، تقریبی مکانی از موقعیت قوزک پا در تصویر سایه‌نماست. موقعیت قوزک پا در روشهای تصور کامل مشابه با محاسبه مرکز نقل سایه‌نما به دست می‌آید، با این تفاوت که سطحی که برای محاسبه مرکز نقل به کار می‌رود، باید محدود شود. نواحی در نظر گرفته شده به صورت مستطیل و نقاط کلیدی با علامت ضرب در در (شکل ۲) نشان داده شده‌اند.

¹Background subtraction²Centroid³Hip



(شکل ۴): نمایش بیضی‌های پوست و نقاط نامزد محل سر، پایین گردن، آرنج‌ها و دست‌ها در ۳ نمای دوربین متفاوت

ضربدرهای قرمز و آبی نشان داده شده‌اند. مرحله آشکارسازی پوست به طور خودکار قادر به استخراج این اطلاعات است. از روی اطلاعات به دست آمده به عنوان مثال می‌توان تفسیر کرد که دست چپ در دوربین شماره ۱ توسط نیم‌تنه دچار انسداد شده است و دیده نمی‌شود، بنابراین در فرآیند بهینه‌سازی حالت دست چپ فقط از اطلاعات دوربین شماره ۲ و ۳ استفاده می‌شود.

۳-۳- برچسبزنی کانتور با استفاده از گراف

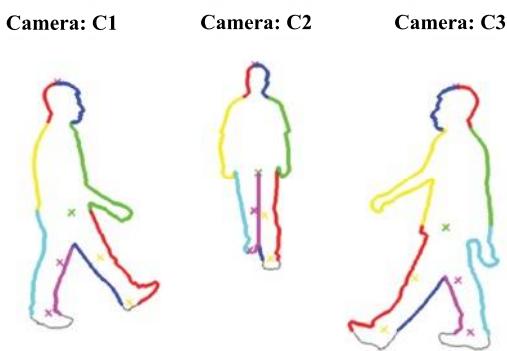
کانتور انسان، لبه کل یا طرح کلی انسان را ارائه می‌دهد؛ اما اینکه چگونه مرزهای قسمت‌های مختلف بدن انسان در یک کانتور از هم تفکیک شوند، یک مسئله بحث‌برانگیز است. در این قسمت روشی با استفاده از تئوری گراف، معرفی می‌شود که می‌تواند پیکسل‌های قسمت‌های مختلف کانتور انسان را از هم تفکیک کند. طرح کلی مسئله از اینجا آغاز می‌شود که چه طور می‌توان روی پیکسل‌های لبه یا کانتور یک شی از یک مبدأ به یک مقصد حرکت کرد، علاوه‌بر این فرض می‌شود که مسیر حرکت، کوتاه‌ترین مسیر ممکن باشد. این مسئله به شکل‌های قوی با استفاده از تئوری گراف برای آنها است و راه حل‌های قوی با استفاده از تئوری گراف برای پیشنهاد شده است. برای نمونه در مسیریابی بسته‌ها در اینترنت، طراحی شبکه تلفن، موتورهای جستجوی وب، برنامه‌ریزی خودکار مسیر سفر و موارد دیگر از تئوری گراف برای مدل‌سازی آنها استفاده شده است. در این بخش از یک مدل گراف برای مدل‌سازی پیکسل‌های کانتور انسان استفاده می‌شود و با استفاده از روش پیدا کردن کوتاه‌ترین مسیر در گراف مربوطه، مسئله برچسبزنی قسمت‌های مختلف کانتور انسان حل می‌شود. بنابراین نخست، تعاریفی در مورد تئوری گراف بیان می‌شود. در اصطلاحات علمی تئوری گراف،

برای هر پیکسل در موقعیت (j,i) با مقادیر رنگ‌های اصلی (r,g,b) میزان همانندی به پوست با استفاده از رابطه (۱) محاسبه می‌شود:

$$L^{(i,j)}(r,g,b) = \log \left(\frac{H^{(i,j)}(r,g,b)}{h^{(i,j)}(r,g,b)} \right) \quad (1)$$

که در این رابطه، H هیستوگرام پوست و h هیستوگرام غیر پوست و L نیز میزان همانندی به پوست برای پیکسل مورد نظر است. برای یک تصویر جدید، میزان شباخته به پوست برای پیکسل‌های تصویر محاسبه می‌شوند و با استفاده از یک حد آستانه‌گیری می‌توان تصمیم به پوست و غیر پوست بودن پیکسل مورد نظر گرفت. پس از حد آستانه‌گیری، نواحی کوچک که به اشتباه به عنوان پوست شناخته شده‌اند حذف و نواحی پوست باقیمانده با استفاده از عملگرهای شکل‌شناسی بهبود می‌شوند. یک بیضی بر مرز هر یک از نواحی که به عنوان پیکسل‌های پوست شناخته شده‌اند، تطبیق داده می‌شود. برای این کار از روش تطبیق حداقل مربعات مستقیم^۱ استفاده شده است، برای جزئیات Pilu, Fitzgibbon et al. (1999; Fitzgibbon, Pilu et al. 1999) مراجعه کرد. بیضی‌های پوست ایجاد شده برای استنتاج موقعیت سر و سایر اعضای بدن به کار می‌روند. البته تفسیر بیضی‌های پوست به نوع لباس انسان وابستگی دارد. به عنوان مثال، اگر شخص لباس آستین کوتاه پوشیده باشد، بیضی پوست بیان گر ساعد دست بوده که نشان‌دهنده موقعیت‌های آرنج و دست است. در حالی که برای لباس آستین بلند، بیضی پوست فقط دست انسان را پوشش می‌دهد و فقط برای استنتاج موقعیت دست به کار می‌رود. بنابراین با استخراج بیضی‌های پوست مجموعه‌های مختلفی از تفاسیر با توجه به فرضیات نوع لباس پوشیدن فراهم می‌شود. برای هر یک از بیضی‌های پوست، دو نقطه انتهایی بیضی در امتداد محور اصلی استخراج می‌شود، این نقاط برای بیضی صورت معرف نامزدهای محل سر و پایین گردن هستند. همچنین برای بیضی‌های دست‌ها، اگر پوشش لباس شخص از نوع آستین کوتاه باشد، این نقاط به عنوان نامزدهای قابل قبول برای محل دست و آرنج هر یک از دست‌های چپ یا راست در نظر گرفته می‌شوند. در (شکل ۴) نقاط نامزد دست چپ با ضربدرهای فیروزه‌ای و سرخ‌آبی، نقاط نامزد دست راست با ضربدرهای سبز و زرد و نقاط نامزد سر و گردن با

^۱Direct least-square fitting



(شکل ۵): نتایج پیاده‌سازی روش برچسبزنی کانتور بدن انسان در ۳ نمای دوربین متفاوت

پیکسل پا برچسبزده شده‌اند که با تعریف یکتابع هدف مناسب که در بخش‌های بعدی ذکر می‌شود، می‌توان نشان داد که اثر این پیکسل‌ها در محاسبه تابع هدف بدون تأثیرند. برچسبزنی پیکسل‌های دست نیز به طور جداگانه بر اساس پیکسل‌های پوست انجام می‌شود.

۴- مدل سازی بدن انسان

در روش پیشنهادی این مقاله، از یک مدل اسکلتی سینماتیک برای مدل سازی بدن انسان استفاده می‌شود. این مدل به صورت پانزده نقطه در فضای سه بعدی که معرف مفاصل کلیدی بدن انسان و چهارده خط که معرف استخوان‌ها و یا قسمت‌های صلب بدن انسان هستند، در نظر گرفته می‌شود. (شکل ۶) مدل در نظر گرفته شده برای بدن انسان را نشان می‌دهد، مدل سه بعدی اسکلتی پیشنهادی به صورت مجموعه‌ای از پانزده نقطه در فضای سه بعدی در نظر گرفته شده است این نقاط در واقع معرف مفاصل کلیدی بدن انسان می‌باشد که در (شکل ۶) به صورت P1 تا P15 نشان داده شده‌اند. این مدل شامل چهارده خط در فضای سه بعدی می‌باشد. هر خط نماینده یکی از استخوان‌های بدن انسان است و هر کدام از آنها تعدادی درجه آزادی دارند که جزئیات آنها در (جدول ۱) آمده است. در واقع، موقعیت هر جسم صلب در فضای سه بعدی و سامانه مختصات جهانی X,Y,Z توسط شش پارامتر مشخص می‌شود که سه پارامتر Rx,Ry,Rz نشان‌دهنده میزان چرخش جسم نسبت به محورهای مختصات x,y,z هستند که در این مقاله از بیان زوایای اوپلر به منظور نشان‌دادن چرخش یک جسم استفاده شده است. همچنین برای هر قسمت صلب از

مدل سازی به صورت مجموعه‌ای از رأس‌ها^۱ (V) و لبه‌ها^۲ (E) در نظر گرفته می‌شود که لبه‌ها معرف اتصالات بین رأس‌ها هستند. بنابراین یک گراف G به صورت $G = (V, E)$ هستند. نشان داده می‌شود. یک مسیر، یک رشته از رأس‌ها $G = (V, E)$ در گراف $\langle v_0, v_1, \dots, v_k \rangle$ است؛ در صورتی که هر یک از لبه‌های (v_i, v_{i+1}) در مجموعه E قرار داشته باشند (یعنی در رشته مربوطه هر رأس به رأس بعدی متصل باشد). در مسئله کوتاه‌ترین مسیر، به هر لبه (u, v) یک وزن $w(u, v)$ داده می‌شود. وزن یک مسیر (یا طول مسیر) برابر مجموع وزن‌های لبه‌های مسیر می‌باشد:

$$w(p) = \sum_{i=0}^{k-1} w(v_i, v_{i+1}) \quad (2)$$

کوتاه‌ترین مسیر از رأس u به رأس v مسیری است که دارای کمینه‌ترین وزن در بین تمام مسیرهای ممکن باشد. برای یادگیری الگوریتم‌های تئوری گراف و نحوه پیاده‌سازی آنها می‌توان به مرجع (Sieki, Lee et al. 2002) مراجعه کرد. برای مدل سازی تصویر باینری کانتور انسان با استفاده از یک گراف، ابتدا باید رأس‌ها، لبه‌ها و وزن بین رأس‌ها تعریف شوند. پیکسل‌هایی که در تصویر متعلق به کانتور انسان هستند (یعنی مقدار یک دارند) به عنوان رأس‌های گراف در نظر گرفته می‌شوند. اتصال بین رأس‌ها نیز با توجه به اتصال هشت‌گانه پیکسل متناظرشان در نظر گرفته می‌شود؛ بنابراین فقط رأس‌هایی که پیکسل متناظرشان در اتصال هشت‌گانه یکدیگر قرار دارند، به هم متصل هستند. اختصاص وزن بین رأس‌های متصل، به صورت فاصله اقلیدسی پیکسل متناظرشان تعريف می‌شود. بنابراین، با استفاده از مدل سازی تصویر کانتور انسان به وسیله یک گراف و مشخص کردن نقاط مبدأ و مقصد، می‌توان عملیات برچسبزنی بین نقاط مبدأ و مقصد مشخص شده را به راحتی انجام داد. (شکل ۵) نتایج پیاده‌سازی روش پیشنهادی را در سه نمای متفاوت از دوربین‌ها نشان می‌دهد. در این شکل مرزهای قسمت‌های مختلف بدن مانند نیم‌تنه، سر و پاهای با رنگ‌های مختلف نشان داده شده‌اند، پیکسل‌های برچسبزده شده در این مرحله به عنوان ورودی الگوریتم بهینه‌سازی حالت برای محاسبه تابع هدف در نظر گرفته می‌شوند. همان‌طور که در (شکل ۵) مشخص است پیکسل‌های کانتور دست به عنوان پیکسل نیم‌تنه و یا در بعضی موارد به عنوان

¹Vertex (V)

²Edges (E)

(جدول ۱): درجه‌های آزادی استخوان‌های مدل اسکلت

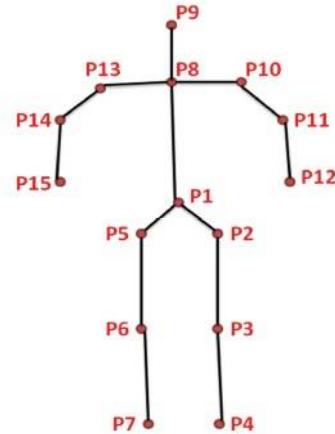
پیشنهادی

درجه آزادی (DOF)	استخوان
$X, Y, Z, R_{Xl}, R_{Yl}, R_{Zl}$	(P1-P8) نیم‌تنه
ندارد	مفصل ران چپ (P1-P2)
R_{X3}, R_{Y3}, R_{Z3}	استخوان ران چپ (P2-P3)
R_{X4}	(P3-P4)
ندارد	مفصل ران راست (P1-P5)
R_{X5}, R_{Y5}, R_{Z5}	استخوان ران راست (P5-P6)
R_{X7}	(P6-P7)
R_{X9}, R_{Y9}, R_{Z9}	(P8-P9)
R_{Y10}, R_{Z10}	(P8-P10) ترقوه چپ
$R_{X11}, R_{Y11}, R_{Z11}$	(P10-P11) بازوی چپ
R_{X12}	(P11-P12) ساعده چپ
R_{Y13}, R_{Z13}	(P8-P13) ترقوه راست
$R_{X14}, R_{Y14}, R_{Z14}$	(P13-P14) بازوی راست
R_{X15}	(P14-P15) ساعده راست
29	تعداد کل (DOF)

ترتیب، سایر نقاط با توجه به ترتیب سلسله‌مراتبی در نظر گرفته شده محاسبه می‌شوند. جستجوی ۲۹ پارامتر مدل بدن انسان در شش مرحله جدا از هم انجام می‌شود (که معادل با جدا کردن فضای جستجوی ۲۹ بعدی به شش زیرفضای جستجو است). در مرحله اول نیم‌تنه، مرحله دوم سر و گردن، مرحله سوم و چهارم دست چپ و راست و درنهایت در مرحله پنجم و ششم پای چپ و راست جستجو می‌شوند. با توجه به روند سلسله‌مراتبی در نظر گرفته شده پارامترهای هر مرحله جداگانه تخمین زده می‌شوند که از این طریق فضای جستجوی ابعاد بالای حالت انسان مهار می‌شود.

۲-۵-تابع هدف

در روش پیشنهادی از یک روش بهینه‌سازی مستقیم برای یافتن پارامترهای حالت بدن انسان استفاده شده است. بنابراین، فرمول‌بندی یک تابع هدف خوب برای فرآیند بهینه‌سازی پارامترهای بدن مورد نیاز است. همان‌طور که ذکر شد، در روش پیشنهادی، از یک روش جستجوی سلسله‌مراتبی برای مهار کردن جستجوی فضای ابعاد بالای حالت بدن انسان استفاده شده است. بنابراین تابع هدف برای



(شکل ۶): مدل بدن انسان

مدل مفصل‌دار انسان یک اندیس در نظر گرفته شده است. به طور مثال، منظور از R_{Xl} زاویه چرخش خط (نیم‌تنه) نسبت به محور X مختصات جهانی است.

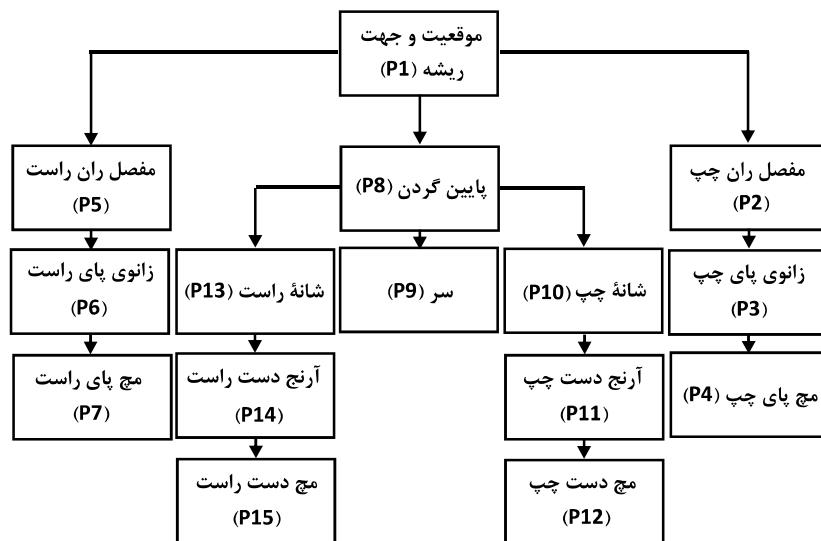
۵-تطبیق مدل با ویژگی‌های تصاویر

در روش پیشنهادی، حالت سه‌بعدی انسان از طریق تطبیق ویژگی‌های تصاویر سه دوربین مختلف و مدل اسکلتی سه‌بعدی استنتاج می‌شود. بنابراین، پس از استخراج ویژگی‌های مناسب، این ویژگی‌های از هر تصویر دوربین با افکنش مدل سه‌بعدی انسان بر آن صفحه تصویر از طریق کمینه‌سازی تابع هدف پیشنهادی تطبیق داده می‌شوند.

۱-۵-جستجوی سلسله‌مراتبی

جستجوی پیکربندی صحیح حالت سه‌بعدی مفصل‌دار انسان در یک فضای جستجوی ۲۹ بعدی از نظر محاسباتی پرهزینه و اغلب مهارنشدنی است. خوشبختانه، استفاده از خاصیت سلسله‌مراتبی در ساختار سینماتیک بدن انسان میسر می‌سازد که جستجو در یک توالی از مراحل انجام شود؛ طوری که در هر مرحله فقط یک زیرمجموعه از ۲۹ پارامتر بهینه شوند. این خاصیت سلسله‌مراتبی به صورت یک درخت سینماتیک است که در (شکل ۷) نشان داده شده است. بهمنظور پیدا کردن پانزده نقطه کلیدی بدن در فضای سه‌بعدی که در بخش قبل معرفی شدند، با توجه به روند سلسله‌مراتبی (شکل ۷)، ابتدا نقطه P1 که معرف ریشه درخت سینماتیک بدن است، تخمین زده می‌شود. سپس با استفاده از نقطه P1، نقطه پایین گردن (نقطه P8) و مفصل ران چپ (نقطه P2 و P5) محاسبه می‌شوند. به همین





(شکل ۷): سلسله مراتب در مدل سینماتیک بدن انسان

استخوان آم در تصویر دوربین شماره ۱ را با $Seg_{1,i}$ نشان می دهیم که به صورت یک خط دو بعدی در صفحه تصویر در نظر گرفته می شود. تعداد N نقطه روی این خط با فاصله یکسان در نظر گرفته می شود؛ این نقاط با $S_{1,i,j} = 1, \dots, N$ نشان داده می شوند. پیکربندی مدل صحیح اسکلت سه بعدی، زمانی به دست می آید که افکنش هر یک از خطوط اسکلت در وسط مرز عضو متناظر ش در سه نمای دوربین ها قرار گیرد. فرض کنید مرز عضو مربوط به $Seg_{1,i}$ را با $Bound_{1,i}$ نشان داده شود، بدینه است که مرز یک جسم شامل دو قسمت است؛ این دو قسمت با $Bound_{1,2,i}$ و $Bound_{1,1,i}$ نشان داده می شود. نقاط متناظر با هر یک از این مرزها با $B_{1,1,i,k}, k = 1, \dots, M_1$ و $B_{1,2,i,k}, k = 1, \dots, M_2$ علامت گذاری می شود که M_1 و M_2 تعداد نقاط هر یک از مرزهای $Bound_{1,1,i}$ و $Bound_{1,2,i}$ می باشند. حال تابع $F_{1,i}(X_{i,t}, I_{1,t})$ به صورت زیر تعریف می شود:

$$F_{1,i}(X_{i,t}, I_{1,t}) = \begin{cases} \sum_{j=1}^N \text{Min}(\|S_{1,i,j} - B_{1,1,i,k}\|) \\ - \sum_{j=1}^N \text{Min}(\|S_{1,i,j} - B_{1,2,i,k}\|) \end{cases} \quad (4)$$

محاسبه $F_{3,i}(X_{i,t}, I_{1,t})$ و $F_{2,i}(X_{i,t}, I_{1,t})$ نیز با توجه به تصاویر متناظر شان مشابه با رابطه (4) انجام می شود. پیکربندی صحیح عضو آم در زمان t با کمینه سازی تابع هدف $F_i(X_{i,t}, I_{1,t})$ (مجموع سه تابع هدف محاسبه شده در سه نمای مختلف) به صورت زیر به دست می آید:

هر یک از اعضای بدن جداگانه تعریف می شوند. پارامترهای بدن انسان در زمان t به صورت X_t تعریف می شود که X_t شامل ۲۹ پارامتر حالت بدن انسان است. با توجه به روند جستجوی سلسله مراتبی، پارامترهای حالت هر یک از اعضای بدن، جداگانه بهینه می شوند. بنابراین، پارامترهای مدل انسان به صورت $X_{i,t}, i = 1, \dots, 14$ در نظر گرفته می شود که $X_{i,t}$ بیان گر پارامترهای آزادی هر عضو انسان در زمان t است. (تعداد درجه های آزادی هر عضو مطابق (جدول ۱) است). تصاویر مشاهده شده در زمان t را با I_t نشان می دهیم. در اینجا هدف، تعریف یک تابع هدف $F_i(X_{i,t}, I_t)$ برای عضو آم بدن انسان است. تابع هدف

$F_i(X_{i,t}, I_t)$ به صورت زیر تعریف می شود:

$$F_i(X_{i,t}, I_t) = F_{1,i}(X_{i,t}, I_{1,t}) + F_{2,i}(X_{i,t}, I_{2,t}) + F_{3,i}(X_{i,t}, I_{3,t}) \quad (5)$$

در رابطه فوق $F_{1,i}(X_{i,t}, I_{1,t})$ ، $F_{2,i}(X_{i,t}, I_{2,t})$ ، $F_{3,i}(X_{i,t}, I_{3,t})$ به ترتیب معرف تابع هدف عضو آم در صفحه تصویر دوربین شماره ۱، دوربین شماره ۲ و دوربین شماره ۳ می باشند و $I_{1,t}$ ، $I_{2,t}$ و $I_{3,t}$ به ترتیب بیان گر تصویر دوربین های شماره ۱، ۲ و ۳ در زمان t هستند. حال با تعریف $F_{1,i}(X_{i,t}, I_{1,t})$ می توان این تعریف را به بقیه حالات تعمیم داد.

همان طور که در بخش های قبل ذکر شد، مدل بدن انسان به صورت مجموعه ای از نقاط (مفاصل) و خطوط (استخوان های صلب بدن) در نظر گرفته می شود. افکنش

بدترین رأس x_{n+1} است. در هر تکرار از الگوریتم، بدترین رأس (x_{n+1}) در سیمپلکس کنار گذاشته می‌شود و یک نقطه دیگر جایگزین آن می‌شود و یا اینکه تمام رأس‌های سیمپلکس بر طبق مقدار بهترین نقطه (x_1) جایگزین می‌شوند. چهار پارامتر عددی برای تعریف روش Nelder-Mead مورد نیاز است. این پارامترها، ضرایب انعکاس^۲ (ρ)، توسعه^۳ (χ)، ادغام^۴ (γ) و انقباض^۵ (σ) هستند. این پارامترها در الگوریتم استاندارد Nelder-Mead به صورت رابطه (۷) در نظر گرفته می‌شوند:

$$\rho = 1, \chi = 2, \gamma = 0.5, \sigma = 0.5 \quad (7)$$

مرکز قلل تمام نقاط به جز نقطه x_{n+1} با استفاده از رابطه $\bar{x} = \sum_{i=1}^n x_i / n$ محاسبه می‌شود. تعدادی رأس دیگر با

استفاده از \bar{x} و پارامترهای الگوریتم محاسبه می‌شوند که محاسبه مقدار این رأس‌ها در روابط زیر نشان داده می‌شود:

$$x_r = (1 + \rho)\bar{x} - \rho x_{n+1} \quad (8)$$

$$x_e = \bar{x} + \chi(x_r - \bar{x}) \quad (9)$$

$$x_c = x_{n+1} + \gamma(\bar{x} - x_{n+1}) \quad (10)$$

$$x_i = x_1 + \sigma(x_i - x_1), i \in \{2, \dots, n+1\} \quad (11)$$

(شکل ۸) نمودار جعبه‌ای الگوریتم جستجوی Nelder-Mead را نشان می‌دهد. رأس‌های سیمپلکس در تکرارهای الگوریتم مطابق نمودار جعبه‌ای (شکل ۸) تغییر می‌نمایند تا زمانی که معیار توقف برآورده شود. شرط توقف الگوریتم بین صورت است که قطع سیمپلکسی که در هر تکرار تولید می‌شود، کمتر از یک تلوانس مشخص شود.

۶- نتایج پیاده‌سازی

در روش پیشنهادی، ورودی به صورت رشتة و بideoیی از سه نمای مختلف در نظر گرفته شده است و خروجی با استفاده از ۲۹ پارامتر حالت سه‌بعدی بدن انسان را بیان می‌کند. تمام مراحل روش پیشنهادی مانند استخراج سایه‌نما، آشکارسازی پوست و برچسبزنی کانتور به صورت خودکار انجام می‌شوند. در مرحله آشکارسازی پوست، برای ایجاد توابع هیستوگرام پوست H و هیستوگرام غیر پوست h ، فریم‌های مختلف از تصاویر دوربین‌های مختلف پایگاه داده *i3DPost*

² Reflection

³ Expansion

⁴ Contraction

⁵ Shrinkage

$$X_{i,t}^* = \arg \min_{X_{i,t}} \left(F_i \left(X_{i,t}, I_t \right) \right) \quad (5)$$

در رابطه (۵) $X_{i,t}^*$ معرف پارامترهای بهینه عضو آم در زمان t است. با توجه به روند سلسله‌مراتبی تعریف شده در بخش‌های قبل، پارامترهای هر یک از عضوهای بدن به طور جداگانه با کمینه‌سازی تابع هدف متناظرشان به دست می‌آیند. بنابراین، پارامترهای بهینه حالت کامل بدن انسان X_t^* در زمان t با استفاده از کنار هم قرار دادن پارامترهای بهینه حالت هر یک از عضوهای بدن به صورت رابطه (۶) به دست می‌آید:

$$X_t^* = \{X_{i,t}^*\}, i = 1, \dots, 14 \quad (6)$$

۳-۵- الگوریتم کمینه‌سازی تابع هدف

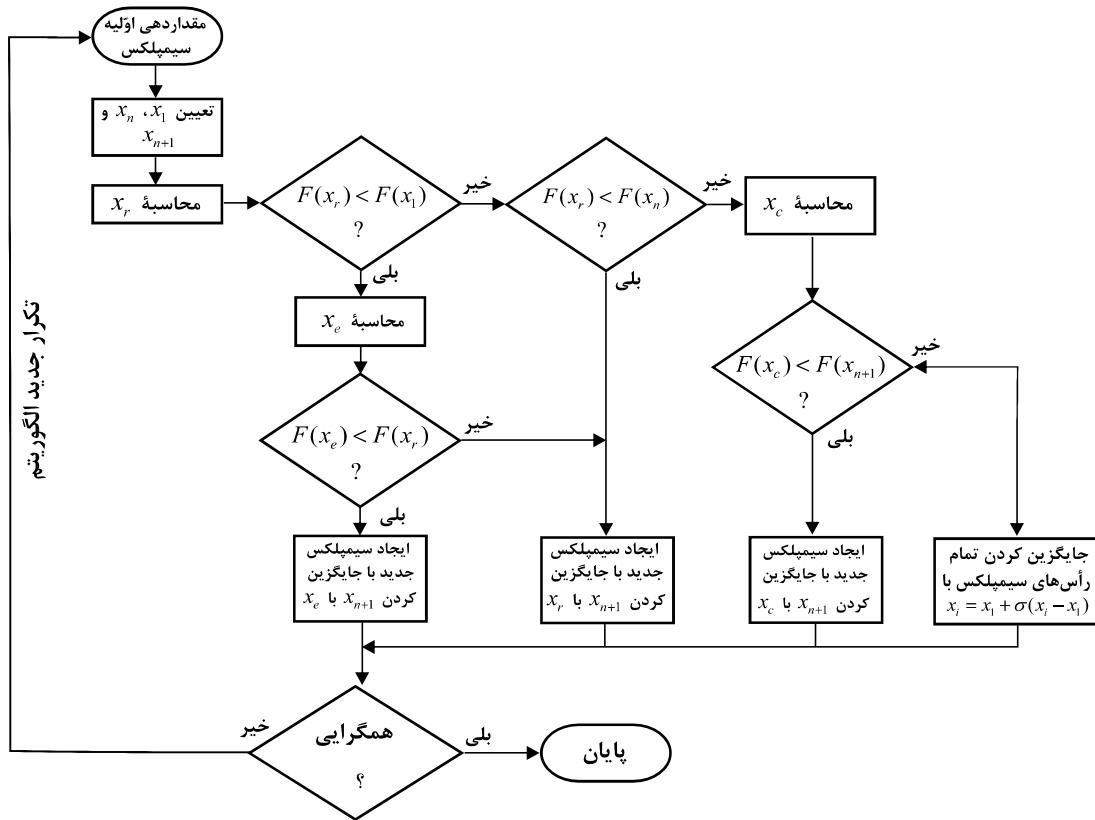
پس از تعریف تابع هدف برای هر یک از اعضای بدن، کمینه‌سازی توابع هدف معرفی شده، به منظور به دست آوردن پارامترهای بهینه حالت هر عضو با استفاده از الگوریتم (Lagarias, Reeds et al. 1998) Nelder-Mead می‌شود. بنابراین در این بخش توضیحات مختصری در مورد این الگوریتم داده می‌شود.

الگوریتم بهینه‌سازی Nelder-Mead یک تکنیک بهینه‌سازی غیرخطی برای کمینه‌سازی یک تابع مقدار حقیقی $f(x) \in R^n$ است. این روش از یک مفهوم به نام سیمپلکس^۱ استفاده می‌کند. سیمپلکس یک چندوجهی با $n+1$ رأس در فضای n بعدی است. مثال‌هایی از سیمپلکس‌ها شامل یک بخش خطی روی یک خط، یک مثلث روی یک صفحه، یک چهاروجهی در فضای سه‌بعدی و غیره است. الگوریتم بهینه‌سازی Nelder-Mead یک الگوریتم تکراری است که در یک فضای n بعدی، ابتدا ۱ رأس $n+1$ یک سیمپلکس را با استفاده از یک مقدار اولیه x_0 ایجاد می‌کند. هدف از هر تکرار الگوریتم، جایگزین کردن بدترین نقطه با یک نقطه بهتر است. این فرآیند تکرار تا زمانی که تمام $n+1$ نقطه روی یک موقعیت با یک تلوانس مشخص هم‌گرا شوند، ادامه پیدا می‌کند.

در هر تکرار الگوریتم، مقدار تابع در هر ۱ رأس $n+1$ سیمپلکس ارزیابی می‌شود و این رأس‌ها به صورت $(x_1) \leq f(x_2) \leq \dots \leq f(x_{n+1})$ مرتب می‌شوند. بهترین رأس x_1 ، بهترین رأس دوم x_2 و به همین ترتیب

¹Simplex



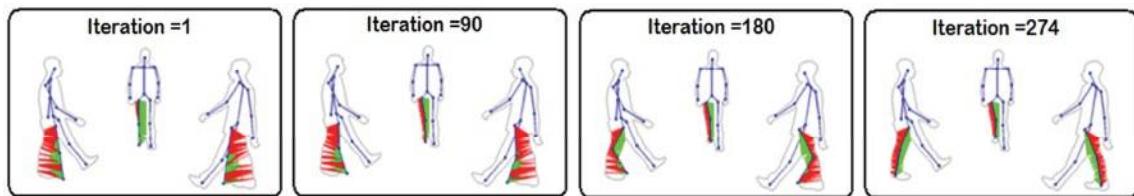


(شکل ۸): نمودار جعبه‌ای الگوریتم جستجوی Nelder-Mead

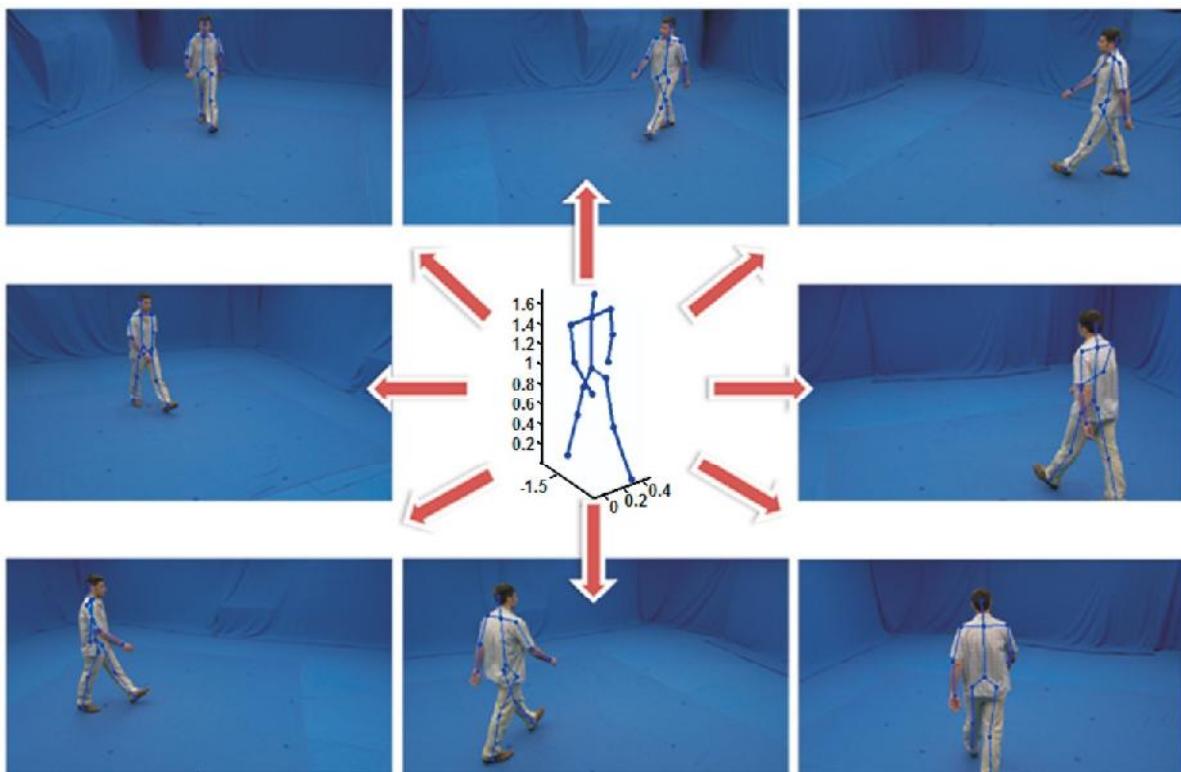
تطبيق داده می‌شوند. پس از استخراج ویژگی از تصاویر سه دوربین مختلف، تطبيق بین افکنش مدل اسکلت سه بعدی با ویژگی‌های تصویر انجام می‌شود. این تطبيق، از طريق کمینه‌سازی توابع هدف حالت اعضای بدن انجام می‌شود. بهینه‌سازی پارامترهای حالت بدن انسان در شش مرحله با توجه به ترتیب سلسله‌مراتبی درخت سینماتیک مدل بدن انسان انجام می‌شود. پیکربندی صحیح اسکلت سه بعدی، زمانی به دست می‌آید که افکنش هر یک از خطوط اسکلت در وسط مرز عضو متناظر در سه نمای دوربین‌ها قرار گیرد. این کار از طریق تعریف تابع هدف پیشنهادی و کمینه‌سازی آن انجام می‌شود. برای نمونه، فرآیند تخمین پارامترهای حالت پای راست در تکرارهای مختلف الگوریتم بهینه‌سازی برای رسیدن به حالت بهینه در (شکل ۹) نشان داده شده است. همان‌طور که در این شکل مشاهده می‌شود در تکرار ۲۷۴ حالت بهینه پای راست حاصل شده است. در (شکل ۹) تعداد یکصد نقطه بر روی افکنش خط بیان‌گر پای راست در سه نما از دوربین‌ها در نظر گرفته شده است. خطوط قرمز و سبز، به ترتیب بیان‌گر کمینه‌ترین فاصله هر یک از این یکصد نقطه از مرز یک و دوی پای راست می‌باشند. با توجه به تابع هدف تعریف شده، هستند.

مورد استفاده قرار گرفته و در مرحله آموزش، نواحی پوست و غیر پوست به صورت دستی انتخاب می‌شود. بدین ترتیب میزان حضور مؤلفه‌های رنگی (r,g,b) در تصاویر پوست به صورت یک هیستوگرام چهار بعدی استخراج می‌شود که در آن مقدار H در هر نقطه دلخواه (r,g,b) از حجم بیان‌گر احتمال پوست بودن آن رنگ است. همچنین مقدار h در هر نقطه دلخواه (r,g,b) از حجم بیان‌گر احتمال غیر پوست بودن آن رنگ است.

باتوجه به اینکه فرض شده شخص در حالت ایستاده است، ابتدا قد شخص تخمین زده می‌شود و طول‌های اولیه استخوان‌های اسکلت به مقیاس قد شخص تغییر داده می‌شوند. حالت شخص در هر فریم به صورت خودکار تخمین زده می‌شود. روش پیشنهادی بر روی رشتۀ ویدیویی چند دوربینی راه رفتن یک شخص از پایگاه داده i3DPost (Gkalelis, Kim et al. 2009) آزمایش شده است. در روش پیشنهادی فقط از سه دوربین استفاده شده است. این دوربین‌ها در پایگاه داده فوق با شماره‌های ۳ و ۵ و ۷ علامت گذاری شده‌اند. همان‌طور که در (شکل ۱) مشاهده می‌شود، ویژگی‌های تصویر از سه نمای مختلف استخراج و با افکنش مدل اسکلت سه بعدی پیشنهادی در سه نمای مختلف



(شکل ۹): نمایش فرآیند تخمین پارامترهای حالت پای راست در تکرارهای مختلف الگوریتم بهینه‌سازی



(شکل ۱۰): نمایش حالت سه‌بعدی بازیابی شده و افکنش آن بر ۸ صفحه دوربین متفاوت

در هر فریم به دست می‌آید که حالت سه‌بعدی بازیابی شده در فریم ۵۲ از رشته ویدیویی راه رفتمن از پایگاهداده i3DPost در (شکل ۱۰) نشان داده شده است.

باتوجه به نامعلوم بودن موقعیت سه‌بعدی واقعی مفاصل بدن شخص، برای ارزیابی کیفی حالت سه‌بعدی بازیابی شده، افکنش پیکربندی اسکلت بازیابی شده بر روی هشت نما از دوربین‌های مختلف در (شکل ۱۰) نشان داده شده است؛ در صورتی که در روش پیشنهادی فقط از سه نما استفاده شده است. نتایج آزمایش، توانمندی روش پیشنهادی در تخمین حالت را بدون داشتن هیچ‌گونه اطلاعاتی در مورد حالت شخص نشان می‌دهد. با فرض اینکه جهش بزرگ در حرکت انسان از یک فریم به فریم بعدی اتفاق نمی‌افتد، پارامترهای تخمین‌زده شده در فریم‌های قبلی به عنوان شرایط اولیه خوبی برای فریم‌های بعدی مورد استفاده قرار می‌گیرند که این در افزایش سرعت هم‌گرایی الگوریتم تأثیرگذار است.

مجموع تفاضل اندازه خطوط قرمز و سبز در هر نما محاسبه می‌شوند. این محاسبه، در رابطه (۴) برای دوربین شماره ۱ و بخش ۱۳ مدل اسکلت بدن انسان نشان داده شده است. در این رابطه مقدار N برابر ۱۰۰ در نظر گرفته شده است. در نهایت با استفاده از رابطه (۵) پارامترهای حالت بهینه پای راست به دست می‌آیند. پس از کمینه‌سازی تابع هدف پای راست، همان‌طور که در (شکل ۹) مشاهده می‌شود، افکنش خط بیان‌گر پای راست در سه نمای متفاوت در وسط مرز پای راست در هر نما قرار گرفته شده است؛ به طوری که تفاضل اندازه خطوط قرمز و سبز در هر نما کمینه شده است. از این طریق پارامترهای بهینه حالت پای راست در فضای سه‌بعدی به دست می‌آید. به طور مشابه، پس از بهینه‌سازی پارامترهای حالت سایر بخش‌های مدل اسکلت سه‌بعدی، افکنش خط بیان‌گر هر بخش اسکلتی در هر نما در وسط مرز عضو متناظرش قرار می‌گیرد. پس از بهینه‌سازی پارامترهای بدن، حالت سه‌بعدی صحیح شخص

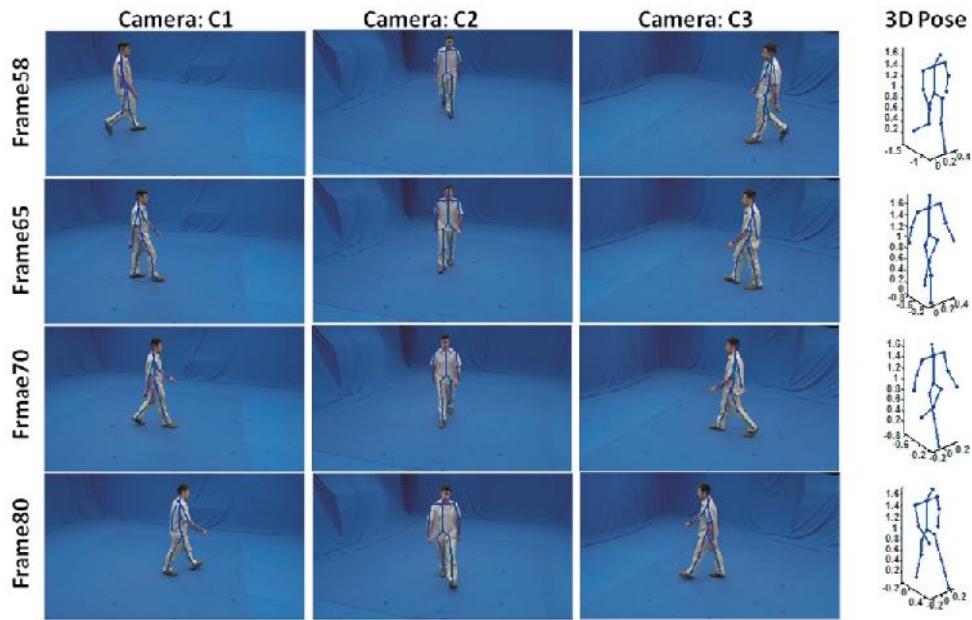
پیشنهادی بر حسب میلی متر در طول پنجاه فریم مطابق با رابطه (۱۲) در (شکل ۱۲) نشان داده شده است. مقدار متوسط خطای در طول پنجاه فریم در این شکل با خط قرمز نشان داده شده است. همان‌طور که در این شکل دیده می‌شود، مقدار متوسط خطای برای رشتة ویدیویی آزمایش شده حدود ۷.۵ سانتی‌متر (۷۵ میلی‌متر) است. نتایج عددی مربوط به اختلاف مکان پانزده نقطه مفروض در دو اسکلت واقعی و اسکلت تخمینی برای روش پیشنهادی و روش (Zhu, Dariush et al. 2010) در (جدول ۲) گزارش شده است. مدل اسکلت سه بعدی مورد استفاده در (Zhu, Dariush et al. 2010) شامل چهارده نقطه کلیدی بدن انسان است که با توجه به شباهت زیاد مدل اسکلت آنها با مدل اسکلت مورد استفاده در این مقاله، می‌توان نتایج الگوریتم پیشنهادی را با روش آنها به صورت کمی مقایسه کرد. در این جدول میانگین و انحراف معیار خطای هر یک از ابعاد نقاط مفروض در مدل اسکلت سه بعدی و همچنین میانگین فاصله اقلیدسی نقاط تخمین‌زده شده با نقاط واقعی برای کل فریمهای حرکتی در ستون‌های جداگانه برای دو روش مذکور نشان داده شده است. مقایسه میانگین خطای روش پیشنهادی با روش (Zhu, Dariush et al. 2010) در هر یک از ابعاد X , Y , Z و همچنین میانگین خطای اقلیدسی (ردیف آخر جدول ۲) حاکی از دقیق بیشتر روش پیشنهادی است. همان‌طور که در (جدول ۲) نیز مشاهده می‌شود از مزایای روش پیشنهادی ما دقیق بسیار خوب در تخمین نقاط مربوط به دسته‌است در صورتی که روش (Zhu, Dariush et al. 2010) دقیق پایینی در تخمین این نقاط است. در لایل دقیق تخمین خوب نقاط کلیدی دست‌ها، استفاده از آشکارساز پوست و عدم انسداد دست چپ و راست در حرکت راه رفتگ است. بیشترین خطای تخمین در روش پیشنهادی ما مربوط به تخمین محل سر است. البته باید توجه داشت که تابع هدف معروف شده به صورت فاصله افکنش هر یک از استخوان‌های بدن از مرز تصاویر متناظرشان در هر نمای دوربین تعريف شده است. بنابراین طبیعی است که در قسمت‌هایی از بدن، که تقارن کامل وجود ندارد (مانند سر)، دقیق تخمین کمتر باشد. البته می‌توان برای اعضای نامتقارن بدن، (مانند سر و نیم‌تنه) تابع هدف را به صورت تفاضل وزن‌دار از مزهایی عضو مورد نظر در نماهای مختلف در نظر گرفت. یکی دیگر از مواردی که از روی اعداد به دست آمده از (جدول ۲) قابل استنتاج است پایین بودن دقیق تخمین در نقاط کلیدی پاهای نسبت به سایر

به‌طور اصولی با استفاده از یک سامانه ضبط حرکت مبتنی بر نشانه^۱ می‌توان محل واقعی مفاصل کلیدی بدن در فضای سه بعدی را به دست آورد. با توجه به عدم دسترسی به پایگاه داده‌ای که شامل داده‌های ضبط حرکت مبتنی بر نشانه نیز باشد، به منظور ارزیابی کمی الگوریتم پیشنهادی در این مقاله از یک روش دستی برای به دست آوردن محل واقعی مفاصل کلیدی بدن انسان استفاده می‌شود. بدین صورت که ابتدا به صورت دستی محل مفاصل‌های کلیدی بدن در تصاویر چند نمای مختلف برچسبزنی می‌شوند. سپس با استفاده از پارامترهای دوربین در هر نما، این نقاط به یک خط در فضای سه بعدی نگاشت می‌شوند. محل تلاقی خطوط نگاشتشده از هر نما در فضای سه بعدی، معرف محل سه بعدی، هر مفصل کلیدی خواهد بود؛ بنابراین با استفاده از روش ذکر شده می‌توان محل واقعی پانزده نقطه مفروض در مدل اسکلت پیشنهادی برای هر فریم از یک رشتة ویدیویی را به دست آورد. فرض کنید محل واقعی پانزده نقطه مفروض در مدل اسکلت پیشنهادی به صورت $\hat{X}_i = \{\hat{P}_1, \hat{P}_2, \dots, \hat{P}_{15}\}$ توسط الگوریتم پیشنهادی به صورت $X_i = \{P_1, P_2, \dots, P_{15}\}$ بیان شوند که در این بیان‌ها $P_k, \hat{P}_k \in \mathbb{R}^3$ موقعیت سه بعدی نقطه k ام در سامانه مختصات جهانی را نشان می‌دهند. با مقایسه این داده‌ها از طریق رابطه (۱۲) می‌توان خطای مکان‌یابی الگوریتم پیشنهادی برای هر فریم را محاسبه کرد.

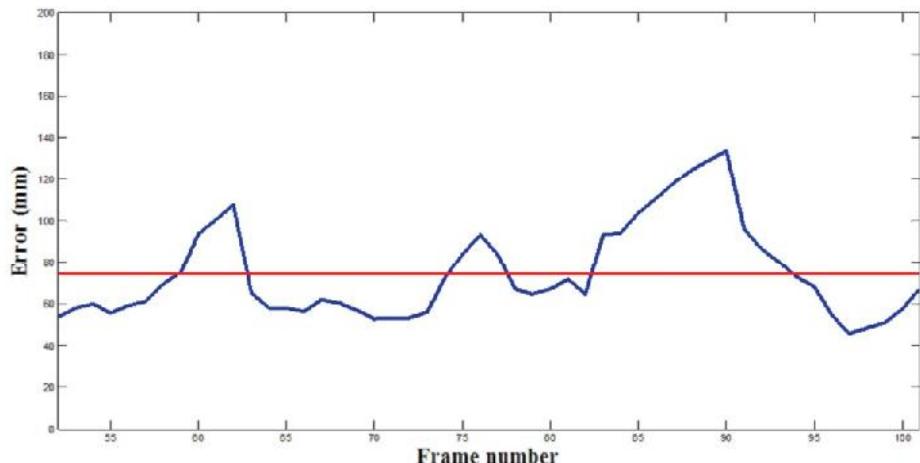
$$Error(X_i, \hat{X}_i) = \frac{1}{15} \sum_{k=1}^{15} \|P_k - \hat{P}_k\| \quad (12)$$

روش پیشنهادی بر روی یک رشتة ویدیویی چند دوربینی، راه رفتن یک شخص از پایگاه داده i3DPost آزمایش شده است. در روش پیشنهادی فقط از سه دوربین استفاده شده است. این دوربین‌ها در پایگاه داده فوق با شماره‌های ۳ و ۵ و ۷ علامت‌گذاری شده‌اند. به دلیل رؤیت کامل بدن انسان در تصویر دوربین‌های در نظر گرفته شده، این رشتة ویدیویی از فریم ۵۲ تا ۱۰۱ در نظر گرفته شده است. نتایج پیاده‌سازی به صورت کیفی و کمی در (شکل‌های ۱۱ و ۱۲) نشان داده شده است. در (شکل ۱۱)، حالت سه بعدی بازیابی شده شخص در چندین فریم نمایش داده شده است که از روی این شکل می‌توان به صورت کیفی و بصیری، عملکرد الگوریتم پیشنهادی را مورد ارزیابی قرار داد. همچنین به منظور ارزیابی کمی روش پیشنهادی، نمودار متوسط خطای تخمین مکان نقاط مفروض در مدل اسکلت

^۱ Marker-based motion capture system



(شکل ۱۱): نتایج تصویری تخمین حالت انسان در رشتۀ ویدیویی راه رفتن از پایگاهداده i3DPost



(شکل ۱۲): نتایج کمی تخمین حالت انسان در رشتۀ ویدیویی راه رفتن از پایگاهداده i3DPost با روش پیشنهادی به صورت خطای میانگین در هر فریم

2012) که یک روش تخمین حالت مبتنی بر چند دوربین می‌باشد، مورد مقایسه قرار گرفته است. لازم به توضیح است که پایگاه داده مورد استفاده در این روش HumanEva است که دارای داده‌های آموزشی، آزمایشی و همچنین برنامه‌هایی برای محاسبه برآورد خطاست. متأسفانه دسترسی به این پایگاه داده برای دانشگاه‌های کشور ایران محدود شده است و در عمل امکان پیاده‌سازی روش پیشنهادی با این پایگاه داده و مقایسه روشها در شرایط یکسان میسر نشد؛ با وجود این، بررسی سکانس‌های ویدیویی مختلف و مقایسه مقدار میانگین خطای مکانی حالت انسان در شرایط فیلمبرداری چنددوربینی که در هر دو پایگاه داده HumanEva¹ و i3DPost² لحاظ شده است، می‌تواند معیار بهنسبه خوبی

نقاط مدل بدن انسان می‌باشد. دلیل این مسئله، مواجهه شدن با انسداد پای چپ و راست در حرکت راه رفتن می‌باشد که در این حالت مرزهای کانتور پای چپ و راست بر روی یکدیگر قرار می‌گیرند و تخمین حالت دقیق پای چپ و راست ناممکن می‌شود. البته با افزایش تعداد دوربین‌ها، می‌توان دقّت تخمین در این نقاط را نیز بهبود داد. در Zhu, Dariush (et al. 2010) می‌توان نتیجه گرفت که بهره‌گیری از سامانه تخمین حالت چنددوربینی و استفاده از اطلاعات مرزی در سایه‌نماها در مقایسه با یک سامانه تخمین مبتنی بر تصاویر عمق دقّت بیشتری برخوردار است. همچنین، به منظور ارزیابی دقّت عملکرد روش پیشنهادی، مقدار میانگین خطای Hofmann and Gavrila (2004) مکانی حالت انسان با روش مقاله (Hofmann and Gavrila 2004)

¹ <http://vision.cs.brown.edu/humaneva/>

² http://kahlan.eps.surrey.ac.uk/i3dpost_action/

(جدول ۲): میانگین و انحراف معیار خطای مکانی اجزای بدن انسان در مدل اصلی و تخمینی در کل فریم‌های حرکتی (میلی متر)

روش پیشنهادی						روش (Zhu, Dariush et al. 2010)						نقاط مفصلی	
$(\mu, \sigma)_{ \Delta X }$		$(\mu, \sigma)_{ \Delta Y }$		$(\mu, \sigma)_{ \Delta Z }$		μ_d	$(\mu, \sigma)_{ \Delta X }$		$(\mu, \sigma)_{ \Delta Y }$		$(\mu, \sigma)_{ \Delta Z }$		
18	20	27	94	17	23	36.6	30	40	71	25	37	18	85.5 P1
22	27	11	79	8	18	25.9	10	79	146	39	6	23	146.5 P2
37	52	38	52	41	43	67.0	33	52	64	106	62	32	95.0 P3
41	53	39	67	45	46	72.3	17	52	56	67	161	34	171.3 P4
25	39	20	71	15	18	35.4	19	72	133	34	22	23	136.1 P5
51	63	46	71	52	61	86.1	52	57	43	121	51	38	84.6 P6
39	49	40	64	41	42	69.3	60	65	29	98	155	56	168.7 P7
11	45	9	14	23	40	27.0	-	-	-	-	-	-	P8
21	53	130	118	12	19	132.2	7	31	22	25	41	26	47.1 P9
9	24	14	33	25	31	30.0	74	39	2	35	10	17	74.7 P10
5	8	12	15	9	15	15.8	58	34	6	47	58	23	82.2 P11
7	6	7	15	5	15	11.1	108	28	20	60	141	51	178.7 P12
14	24	12	18	26	35	31.9	86	20	1	47	11	25	86.7 P13
9	11	7	13	7	24	13.4	46	40	13	36	85	18	97.5 P14
8	21	9	28	3	6	12.4	135	36	21	61	143	43	197.8 P15
21.1	33	28.1	50.1	21.9	29.1	44.4	52.5	46.1	44.8	57.2	70.2	30.5	118.0 متوسط

(جدول ۳): میانگین خطای مکانی تخمین حالت انسان برای چند رشتہ ویدیویی

روش پیشنهادی	(Hofmann and Gavrila 2012)						روش مورد استفاده برای تخمین حالت
i3DPost	HumanEva-I						پایگاه داده مورد استفاده
Walking	Walking-1		ThrowCatch-1		Gestures-1		نام سکانس ویدیویی مورد استفاده
	Subject 2	Subject 1	Subject 2	Subject 1	Subject 2	Subject 1	
7.5	7.4	4.7	8.9	5.8	6.5	6.3	خطای میانگین در کل سکانس (سانتی متر)

قسمت‌های مختلف بدن و از روش‌های بهینه‌سازی مستقیم برای تخمین حالت انسان استفاده شده است. سامانه پیشنهادی قادر به تشخیص انسداد و تخمین بهنگه دقیق اعضای بدن مانند نیم‌تنه، سر و دست‌هاست. از مزایای روش معرفی شده این است که با توجه به معرفی روش برچسب‌زنی کانتور و تابع هدف معرفی شده، حتی با استفاده از ساده‌ترین روش‌های بهینه‌سازی، الگوریتم قادر به هم‌گرایی به حالت صحیح است. از دیگر مزایای روش پیشنهادی ارزش‌دهی اولیه خودکار آن است؛ به طوری که روش معرفی شده قادر به تخمین خودکار حالت انسان در فریم اول یک رشتہ ویدیویی چند دوربینی است. در حالی که سامانه معرفی شده، قادر به تخمین حالت انسان به طور مؤثر است، ولی با این حال لازم به ذکر است که در مواردی روش پیشنهادی دچار شکست می‌شود. یکی از مواردی که روش پیشنهادی در آن دچار مشکل می‌شود مواجه شدن با انسداد پایی چپ و راست است. در این حالت مربّه‌ای کانتور پای چپ و راست بر روی یکدیگر قرار می‌گیرند و تخمین حالت دقیق پای چپ و راست ناممکن می‌شود. البته باید توجه داشت که در این حالت می‌توان با افزایش تعداد دوربین‌ها و یا استفاده از ویژگی‌های لبه تصویر این نقصان را برطرف کرد. یکی دیگر از مواردی که روش پیشنهادی را دچار شکست می‌کند این

برای ارزیابی روش پیشنهادی باشد. نتایج این مقایسه در (جدول ۳) آورده شده و همان‌طور که ملاحظه می‌شود خطای روش پیشنهادی قابل رقابت با خطای روش (Hofmann and Gavrila 2012) است.

آزمایش روش پیشنهادی بر روی یک پردازنده ۲.۲ گیگا هرتزی اینتل با حافظه رم یک گیگا بایت انجام شده است. زمان کلی پردازش برای هر فریم حدود ۱۲۹ ثانیه است، این زمان محاسباتی، سامانه معرفی شده را برای کاربردهای بلاذرنگ^۱ نامناسب می‌سازد. البته باید توجه کرد که پیاده‌سازی بر روی وضوح تصویری بالا 1080×1920 نتایج شده است و با بهینه‌سازی برنامه‌های نوشته شده می‌توان زمان محاسباتی نیز را کاهش داد.

۷- نتیجه‌گیری

در این مقاله، روشی جدید برای تخمین حالت سه‌بعدی انسان در رشتہ ویدیویی چند دوربینی معرفی شد. در روش پیشنهادی، به جای جستجوی فضایی مستقیم ابعاد بالای انسان و استفاده از الگوریتم‌های استنتاج پیچیده، از یک روش جستجوی سلسله‌مراتبی، توابع هدف جدایگانه برای

^۱Real-time

Lee, M. W. and R. Nevatia (2009). "Human pose tracking in monocular sequence using multilevel structured models." *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 31(1): 27-38.

Mündermann, L., S. Corazza, et al. (2006). Measuring human movement for biomechanical applications using markerless motion capture. *Proceedings of SPIE, Citeseer.*

Pilu, M., A. W. Fitzgibbon, et al. (1996). Ellipse-specific direct least-square fitting. *IEEE International Conference on Image Processing, IEEE.*

Siek, J., L. Q. Lee, et al. (2002). *The Boost Graph Library: User Guide and Reference Manual*, Addison-Wesley.

Sigal, L., S. Bhatia, et al. (2004). Tracking loose-limbed people. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.*

Zhu, Y., B. Dariush, et al. (2010). "Kinematic self retargeting: A framework for human pose estimation." *Computer Vision and Image Understanding* 114(12): 1362-1375.



قاسم خادمی در سال ۱۳۸۵ مدرک کارشناسی خود را در رشته مهندسی برق، مخابرات از دانشگاه صنعتی امیرکبیر (پلی‌تکنیک تهران) اخذ و سپس با ادامه تحصیل در دانشگاه صنعتی سهند، مدرک کارشناسی ارشد خود را در گرایش مخابرات سیستم در سال ۱۳۹۰ دریافت کرد. زمینه‌های تحقیقاتی مورد علاقه ایشان بینایی کامپیوتر، پردازش تصویر و شناسایی الگو است.

نشانی رایانامه ایشان عبارتست از:
g_khademi@sut.ac.ir



حسین ابراهیم‌نژاد مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب در سال‌های ۱۳۷۲ و ۱۳۷۵ در رشته مهندسی برق-الکترونیک و برق مخابرات از دانشگاه تبریز و دانشگاه صنعتی خواجه نصیرالدین طوسی اخذ کرد. همچنین مدرک دکتری خود را در گرایش مخابرات سیستم در سال ۱۳۸۶ از دانشگاه تربیت مدرس دریافت کرد. زمینه‌های تحقیقاتی مورد علاقه ایشان بینایی کامپیوتر، پردازش مدل سه‌بعدی، پردازش تصویر، شناسایی الگو و محاسبات نرم بوده و در حال حاضر عضو هیأت علمی دانشگاه صنعتی سهند می‌باشد.

نشانی رایانامه ایشان عبارتست از:
ebrahimnezhad@sut.ac.ir

است که در صحنه‌های واقعی خارج از محیط آزمایشگاه، به دلیل وجود پس زمینه شلوغ، ممکن است سایه‌نما و کانتور استخراج شده آغشته به نوفه باشند که در این حالت ایجاد گیستگی در کانتور بدن انسان، روش برچسب‌زنی کانتور را دچار مشکل خواهد کرد. البته باید توجه داشت که در روش پیشنهادی، فقط از ویژگی‌های سایه‌نما، کانتور و پوست استفاده شده است که می‌توان با استفاده از اطلاعات لبه و بافت، تخمین حالت بدن انسان را به صورت قوی‌تری انجام داد.

- منابع

Cheung, K., S. Baker, et al. (2003). Shape-from-silhouette of articulated objects and its use for human body kinematics estimation and motion capture. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.*

Conaire, C. O., N. E. O'Connor, et al. (2007). Detector adaptation by maximising agreement between independent data sources. *IEEE International Workshop on Object Tracking and Classification Beyond the Visible Spectrum, IEEE.*

Deutscher, J., A. Blake, et al. (2000). Articulated body motion capture by annealed particle filtering. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.*

Fitzgibbon, A., M. Pilu, et al. (1999). "Direct least square fitting of ellipses." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 21(5): 476-480.

Franco, J. S. and E. Boyer (2005). Fusion of multiview silhouette cues using a space occupancy grid. *IEEE International Conference on Computer Vision (ICCV), IEEE.*

Gavrila, D. M. and L. S. Davis (1996). 3-D model-based tracking of humans in action: a multi-view approach. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.*

Gkalelis, N., H. Kim, et al. (2009). The i3dpost multi-view and 3d human action/interaction database. *Conference for Visual Media Production., IEEE.*

Hofmann, M. and D. Gavrila (2012). "Multi-view 3D human pose estimation in complex environment." *International journal of computer vision* 96(1): 103-124.

Kehl, R., M. Bray, et al. (2005). Full body tracking from multiple views using stochastic sampling. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE.*

Lagarias, J. C., J. A. Reeds, et al. (1998). "Convergence Properties of the Nelder-Mead Simplex Method in Low Dimensions." *SIAM Journal on Optimization* 9(1): 112-147.

فصل نهم