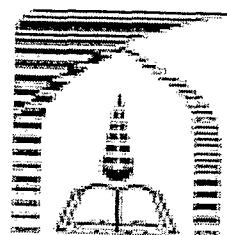


الله اعلم

٩٢٢٢



دانشگاه تربیت مدرس
دانشکده فنی و مهندسی

پایان نامه دوره دکتری مهندسی برق - کنترل

طراحی کنترلگر عاملگرای هوشمند برای ناویگی ربات

ولی درهمی

۱۳۸۷ / ۲ / ۵

استاد راهنمای:

دکتر وحید جوهری مجد



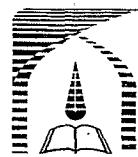
اساتید مشاور:

دکتر مجید نیلی احمد آبادی

دکتر حمید رضا مومنی

پاییز ۱۳۸۶

۹۴۵۷



بسم الله الرحمن الرحيم

تاییدیه اعضای هیات داوران حاضر در جلسه دفاع از رساله دکتری

آقای ولی درهمی رساله ۱۳۹۴ واحدی خود را با عنوان طراحی کنترلگر عامل گرای

هوشمند برای ناوبری ربات در تاریخ ۱۳۸۶/۸/۶ ارائه کردند.

اعضای هیات داوران نسخه نهایی این رساله را از نظر فرم و محتوا تایید کرده و پذیرش آنرا برای تکمیل درجه دکتری مهندسی برق - کنترل پیشنهاد می کنند.

عضوی هیات داوران	نام و نام حائز ادبی	رتبه علمی	امضا
استاد راهنمای	دکتر وحید جوهری مجد	دانشیار	
استاد مشاور	دکتر مجید نیلی احمدآبادی	دانشیار	
استاد مشاور	دکتر حمیدرضا مومنی	دانشیار	
استاد ناظر	دکتر سعید جلیلی	استادیار	
استاد ناظر	دکتر محمد رضا امین ناصری	دانشیار	
استاد ناظر	دکتر نجgar اعرابی	دانشیار	
استاد ناظر	دکتر محمد فرخی	دانشیار	
نمائنده شورای تحصیلات تکمیلی	دکتر سعید جلیلی	استادیار	

دستور العمل حق مالکیت مادی و معنوی در مورد نتایج پژوهش‌های علمی دانشگاه تربیت مدرس

مقدمه:

با عنایت به سیاست‌های پژوهشی دانشگاه در راستای تحقق عدالت و کرامت انسانها که لازمه شکوفایی علمی و فنی است و رعایت حقوق مادی و معنوی دانشگاه و پژوهشگران لازم است اعضا هیات علمی دانشجویان دانش آموختگان و دیگر همکاران طرح درمورد نتایج پژوهش‌های علمی که تحت عنوانین پایان نامه و ساله و طرحهای تحقیقاتی با هماهنگی دانشگاه انجام شده است موارد ذیل را رعایت نمایید:

ماده ۱: حقوق مادی و معنوی پایان نامه‌ها / رساله‌های مصوب دانشگاه متعلق به دانشگاه است و هر گونه بهره‌برداری از آن باید با ذکر نام دانشگاه و رعایت آیین‌نامه‌ها و دستورالعمل‌های مصوب دانشگاه باشد.

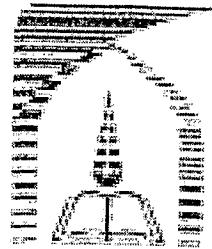
ماده ۲- انتشار مقاله یا مقالات مستخرج از پایان نامه / رساله به صورت چاپ در نشریات علمی و یا ارائه در مجتمع علمی می‌باید به نام دانشگاه بوده و استاد راهنما نویسنده مسئول مقاله باشند. تبصره: در مقالاتی که پس از دانش آموختگی بصورت ترکیبی از اطلاعات جدید و نتایج حاصل از پایان نامه / رساله نیز منتشر می‌شود نیز باید نام دانشگاه درج شود.

ماده ۳- انتشار کتاب حاصل از نتایج پایان نامه / رساله و تمامی طرحهای تحقیقاتی دانشگاه باید با مجوز کتبی صادره از طریق حوزه پژوهشی دانشگاه و بر اساس آیین‌نامه‌های مصوب انجام می‌شود.

ماده ۴- ثبت اختراع و تدوین دانش فنی و یا ارائه در جشنواره‌های ملی، منطقه‌ای و بین‌المللی که حاصل نتایج مستخرج از پایان نامه / رساله و تمامی طرح‌های تحقیقاتی دانشگاه باید با هماهنگی استاد راهنما یا مجری طرح از طریق حوزه پژوهشی دانشگاه انجام گیرد.

ماده ۵- این دستورالعمل در ۵ ماده و یک تبصره در تاریخ ۱۳۸۴/۴/۲۵ در شورای پژوهشی دانشگاه به تصویب رسیده و از تاریخ تصویب لازم الاجرا است و هر گونه تخلف از مفاد این دستورالعمل، از طریق مراجع قانونی قابل پیگیری خواهد بود.

د
دکتر ابراهیمی
نام و نام خانوادگی: ولی
تاریخ و امضاع: ۱۳۸۴/۴/۲۵



آیین نامه چاپ پایان نامه‌های دانشجویان دانشگاه تربیت مدرس

نظر به اینکه چاپ و انتشار پایان نامه‌های تحصیلی دانشجویان دانشگاه تربیت مدرس، مبین بخشی از فعالیتهای علمی- پژوهشی دانشگاه است بنابر این بمنظور آگاهی و رعایت حقوق دانشگاه، دانش آموختگان این دانشگاه نسبت به رعایت موارد ذیل متعهد می‌شوند:

- ماده ۱: در صورت اقدام به چاپ پایان نامه‌های خود، مراتب را قبل از طور کتبی به «دفتر نشر آثار علمی» دانشگاه اطلاع دهد.

• ماده ۲: در صفحه سوم کتاب (پس از برگ شناسنامه)، عبارت ذیل را چاپ کند:
 «کتاب حاضر، حاصل رساله دکتری نگارنده در رشته مهندسی برق - کترل است که در سال ۱۳۸۶ در دانشکده فنی و مهندسی دانشگاه تربیت مدرس به راهنمایی جناب آقای دکتر وحید جوهر مجذد و مشاوره جناب آقایان دکتر مجید نیلی احمد آبادی و دکتر حمید رضا مومنی از آن دفاع شده است.»

- ماده ۳: به منظور جبران بخشی از هزینه‌های انتشارات دانشگاه، تعداد یک درصد شمارگان کتاب (در هر نوبت چاپ) را به «دفتر نشر آثار علمی» دانشگاه اهدا کند. دانشگاه می‌تواند مازاد نیاز خود را به نفع مرکز نشر در معرض فروش قرار دهد.

• ماده ۴: در صورت عدم رعایت ماده ۳، ۵۰٪ بهای شمارگان چاپ شده را به عنوان خسارت به دانشگاه تربیت مدرس، تادیه کند.

- ماده ۵: دانشجو تعهد و قبول می‌کند در صورت خودداری از پرداخت بهای خسارت، دانشگاه می‌تواند خسارت مذکور را از طریق مراجع قضایی مطالبه و وصول کند؛ به علاوه به دانشگاه حق می‌دهد به منظور استیفای حقوق خود، از طریق دادگاه، معادل وجه مذکور در ماده ۴ را از محل توقيف کتابهای عرضه شده نگارنده برای فروش، تامین نماید.

• ماده ۶: اینجانب ولی درهمی دانشجوی رشته مهندسی برق-کترل مقطع دکتری تعهدات فوق و ضمانت اجرایی آن را قبول کرده، به آن ملتزم می‌شوم.

نام و نام خانوادگی: ولی درهمی
 تاریخ و امضای: ۱۳۹۱/۸/۱۵

این رساله را تقدیم می‌کنم به

همسر مهریان و فداکارم

و دو فرزند عزیزم

سara و صدار

تقدیر و تشکر

خداوند را سپاس می‌گوییم بخاطر لطف و مهربانی هایش و اینکه به من لذت توفیق کسب علم را
عطای کرده است و امیدوارم بتوانم تکلیف خود را در برابر آنچه به من ارزانی داشته است بخوبی
بانجام برسانم.

از استاد راهنمای محترم جناب آقای دکتر وحید مجد، بخاطر راهنماییهای مفیدی که نموده اند،
و همچنین صبر و حوصله ای که در اصلاح مقالات و رساله کشیده اند تشکر و سپاسگزاری
می‌نمایم.

از استاد مشاور محترم جناب آقای دکتر مجید نیلی احمدآبادی، بخاطر دلسوزی ها و
راهنماییهای ارزنده ای که نموده اند و وقت زیادی که بسیار بیشتر از آنچه از استاد مشاور انتظار
می‌رود برای مشاوره اختصاص دادند، تشکر و قدردانی می‌نمایم. همچنین از جناب آقای دکتر حمید
رضامونی، استاد مشاور دوم این رساله سپاسگزار هستم.

از زحمات دوست عزیزم آقای دکتر امیر رضا عطارها که در تهیه مقالات انگلیسی کمک بسیار
نمودند، قدردانی فراوان می‌نمایم.

در پایان ممنون از صبر، فداکاری، مهربانی، و دلسوزی همسرم هستم که اگر حمایت های او نبود
هرگز موفق به پایان رساندن این مسیر که همراه با فراز و نشیب های بسیاری برای من و خانواده ام
بود، نمی شدم.

چکیده

عدم وجود تحلیل ریاضی و عدم کاوش مناسب دو نقطه ضعف عمدی در اکثر الگوریتم‌های آموزش تقویتی پیوسته هستند. تحقیقات این رساله بر دو موضوع فوق متمرکز است. یک الگوریتم جدید "آموزش تقویتی فازی" بر مبنای معناری نقاد-تنها، که "آموزش سارسای فازی" (FSL) نامیده می‌شود، ارائه می‌گردد. الگوریتم FSL پارامترهای تالی قواعد سیستم فازی را بصورت روی خط تنظیم می‌کند. انتخاب عمل در هر قاعده بر طبق فرمول جدید ارائه شده در این رساله بنام "بیشینه نرم بهبود یافته" انجام می‌شود. این نحوه انتخاب عمل موجب می‌گردد تا توزیع احتمال انتخاب عمل نهایی در الگوریتم FSL از توزیع بولتزمن که یک توزیع پیوسته است، تبعیت کند. وجود نقاط ایستای منطبق بر نقاط ثابت الگوریتم "تکرار تقریب ارزش عمل" (ارائه شده در این رساله) برای FSL اثبات می‌شود. همچنین همگرایی بردار وزن FSL به مقدار یکتا وقتی که از سیاست انتخاب عمل ایستا استفاده شود اثبات می‌گردد. نتایج شبیه سازی در بکارگیری الگوریتم FSL در مقابل الگوریتم "آموزش Q فازی" (FQL)، حاکی از کیفیت و سرعت بالاتر آموزش FSL نسبت به FQL است. همچنین همگرایی FSL در برابر واگرایی FQL در یک مسئله چند هدفه جاییکه هر دو الگوریتم از سیاست ایستا استفاده می‌نمایند، نشان داده می‌شود. سپس موضوع تعادل میان "کاوش برای کسب تجربه جدید" و "بهره‌برداری از تجربیات گذشته" در آموزش تقویتی فازی پیوسته مورد بررسی قرار می‌گیرد. کیفیت برقراری تعادل وابستگی شدیدی به دقت تابع ارزش عمل تقریب زده شده دارد. بنابراین، در ابتدا تفاوت‌های بین تخمین تابع ارزش در الگوریتم‌های آموزش تقویتی گستته با تقریب آن در آموزش تقویتی پیوسته‌ای که از تقریب زننده استفاده می‌کند شرح داده شده و مشکل "فوق برازش" معرفی می‌گردد. برای رفع این مشکل یک روش جدید محاسبه نرخ آموزش ارائه می‌شود. مقدار نرخ آموزش پیشنهادی رابطه معکوس با مقدار ملاقات فازی حالت جاری دارد و باعث تاثیر تقریباً یکسان داده‌های آموزشی روی پارامترهای وزن تقریب زننده و جلوگیری از فوق برازش می‌گردد. برای ایجاد تعادل بین کاوش و بهره‌برداری، یک سیستم فازی T-S مرتبه صفر که مقدار ضریب دما را برای فرمول بیشینه نرم تولید می‌کند، ارائه می‌گردد. با اضافه نمودن دو تکنیک "نرخ آموزش تطبیقی" و "تعادل دهنده فازی کاوش و بهره‌برداری" به الگوریتم حاصل را EFSL می‌نامیم. نتایج شبیه‌سازی حاکی از برتری قابل توجه در کیفیت و زمان بهبود یافته یا EFSL است. در ادامه راهکارهایی برای چالشهای موجود در بکارگیری آموزش EFSL در مقابل FSL در نظر گرفته شود و ساختار یک کنترلگر فازی برای آن تعیین می‌گردد. در انتها تقویتی در مسئله ناوبری ربات ارائه می‌شود و ساختار یک کنترلگر فازی برای آن تعیین می‌گردد. در انتها عملکرد الگوریتم‌های ارائه شده در تنظیم پارامترهای کنترلگر در مسئله مذکور با یکدیگر مقایسه می‌شود.

کلید واژه‌ها: آموزش تقویتی، کاوش، بهره‌برداری، سیستم‌های فازی، ناوبری ربات

فهرست مطالب

عنوان	صفحة
فهرست شکل‌ها	۵
فهرست جدول‌ها	۹
فصل ۱- مقدمه	۱
۱-۱- پیشگفتار	۱
۱-۲- دو موضوع مهم در آموزش تقویتی پیوسته	۲
۱-۲-۱- تحلیل ریاضی الگوریتم	۲
۱-۲-۲- تعادل بین کاوش و بهره‌برداری از تجربیات	۲
۱-۳- مروری بر مطالعات انجام شده	۳
۱-۳-۱- معماری عملگر- نقاد	۳
۱-۳-۲- معماری نقاد- تنها	۴
۱-۴- هدف و نتایج حاصل از این رساله	۷
۱-۵- ساختار رساله	۹
فصل ۲- آموزش تقویتی	۱۰
۲-۱- مقدمه	۱۰
۲-۲- مفاهیم اولیه در RL	۱۰
۲-۳- آموزش تقویتی گسسته	۱۲
۲-۳-۱- آموزش تفاضل موقتی	۱۲
۲-۳-۲- روش‌های انتخاب عمل برای RL گسسته	۱۳
۲-۳-۳- تعادل در آموزش تقویتی گسسته	۱۶
۲-۴- آموزش تقویتی پیوسته	۱۸
۲-۴-۱- معماری عملگر- نقاد	۱۹
۲-۴-۲- معماری نقاد- تنها	۲۰
۲-۴-۳- روش‌های تعیین نرخ آموزش	۲۳
۲-۴-۴- جمع بندی روش‌های آموزش تقویتی پیوسته	۲۳
فصل ۳- آموزش سارسای فازی (FSL)	۲۴
۳-۱- مقدمه	۲۴
۳-۲- آموزش سارسای فازی (FSL)	۲۴
۳-۳- روش تکرار تقریب ارزش عمل (AAVI)	۲۷
۳-۴- تحلیل ریاضی الگوریتم FSL	۳۰

۳۰	۱-۴-۳- اثبات وجود نقاط ایستا برای الگوریتم FSL
۳۶	۲-۴-۳- همگرایی الگوریتم FSL تحت سیاست ایستا
۳۷	۵-۳- شبیه سازی
۳۷	۱-۵-۳- مسأله هدایت قایق
۴۱	۲-۵-۳- محیط چند هدفه بی بدون مانع
۴۵	۶-۳- جمع بندی و نتیجه گیری
۴۷	فصل ۴- تعادل بین کاوش و بهره برداری از تجربیات در آموزش تقویتی
۴۷	۱-۴- مقدمه
۴۷	۲-۴- تعادل در آموزش تقویتی گستته
۴۷	۱-۲-۴- معرفی چند ایده جدید برای بهبود انتخاب عمل در روش بیشینه ترم
۴۸	۲-۲-۴- شبیه سازی
۵۳	۳-۲-۴- جمع بندی تعادل در آموزش تقویتی گستته
۵۳	۴-۳- تعادل در الگوریتم‌های FRI با معماری نقاد-نها
۵۴	۱-۳-۴- وابستگی انتخاب عمل به دقت تقریب تابع ارزش عمل
۵۵	۲-۳-۴- آموزش سارسای فازی بهبود یافته (EFSL)
۶۰	۳-۳-۴- شبیه سازی
۶۷	۴-۳-۴- جزییات آموزش و نتایج
۶۸	۵-۳-۴- جمع بندی و نتیجه گیری
۷۰	فصل ۵- مسأله ناوی بر ربات
۷۰	۱-۵- مقدمه
۷۱	۲-۵- ربات خپرا
۷۳	۳-۵- محیط شبیه ساز KIKS
۷۶	۴-۵- طراحی ساختار کنترلگر فازی برای مسأله ناوی بر
۷۹	۵-۵- شبیه سازی
۸۶	۶-۵- جمع بندی و نتیجه گیری
۸۷	فصل ۶- نتیجه گیری و کارهای آینده
۸۷	۱-۶- جمع بندی و نتیجه گیری
۸۸	۲-۶- کارهای آینده
۸۸	۱-۲-۶- اضافه کردن شرایط جدید برای الگوریتم FSL جهت یافتن یک شرط قوی تر همگرایی
۸۹	۲-۲-۶- ترکیب آموزش باناظر با الگوریتم FSLE
۸۹	۳-۲-۶- استفاده از الگوریتم EFSL در مسائل چند عامله و استفاده از معیارهای خبرگی برای انتشار سیگنال تقویتی
۸۹	۴-۲-۶- استفاده از خطای تفاضل موقتی ارزش-عمل برای تنظیم توابع عضویت مقدم قواعد فازی

۸۹	۵-۲-۶- بررسی وابستگی راندمان به تابع سیگنال تقویتی
۹۰	۶-۲-۶- مقایسه و تحلیل پدیده سرخوردگی در روانشناسی با مسأله فوق برازش در آموزش تقویتی پیوسته
۹۰	۷-۲-۶- بررسی نحوه مقدار دهی اولیه پارامترهای وزن
۹۰	۸-۲-۶- بررسی و بکارگیری تکنیک نرخ آموزش تطبیقی در دیگر الگوریتم های آموزشی
۹۰	۹-۲-۶- تست ایده های ارائه شده در بخش ناوبری ربات برای یک ربات واقعی
۹۱	۱۰-۲-۶- استفاده از معماری رده بندی در مسأله ناوبری ربات
۹۱	فهرست مراجع
۹۵	واژه نامه فارسی به انگلیسی
۹۷	واژه نامه انگلیسی به فارسی

فهرست شکل‌ها

عنوان	صفحة
شکل ۱-۱: نمونه‌ای از به دام افتادن ربات در بین موائع.	۳
شکل ۱-۲: چهار چوب آموزش تقویتی.	۱۰
شکل ۲-۲: ساختار عملگر- نقاد.	۱۹
شکل ۱-۳ : مسأله هدایت قایق.	۳۸
شکل ۲-۳: توابع عضویت ورودی.	۳۸
شکل ۳-۳: نمونه‌ای از مسیرهای حرکت قایق.	۴۰
شکل ۴-۳: هیستوگرام <i>LDI</i> ها برای <i>FSL</i> .	۴۱
شکل ۵-۳: هیستوگرام <i>LDI</i> ها در <i>FQL</i> .	۴۱
شکل ۶-۳: محیط چند هدفه‌ی بدون مانع.	۴۳
شکل ۷-۳: توابع عضویت ورودی.	۴۳
شکل ۸-۳: مقدارهای وزن در قواعد ۱ و ۲ در <i>FSL</i> .	۴۴
شکل ۹-۳: مقدارهای وزن در قواعد ۳ و ۴ در <i>FSL</i> .	۴۴
شکل ۱۰-۳: منحنی وزن عمل راست در قاعده ۱ برای الگوریتم <i>FQL</i> .	۴۴
شکل ۱-۴: محیط مارپیچ.	۴۹
شکل ۲-۴: مقایسه عملکرد سه روش انتخاب عمل معروف.	۴۹
شکل ۳-۴: مقایسه نتایج عملکرد چهار سیاست پیشنهادی.	۵۰
شکل ۴-۴: مقایسه نتایج عملکرد سیاست بیشینه نرم با سیاست soft-hybrid	۵۱
شکل ۵-۴: محیط MDP تصادفی .	۵۲
شکل ۶-۴: مقایسه نرخ انتخاب راه بهینه در سیاست بیشینه نرم و چهار سیاست پیشنهادی.	۵۲
شکل ۷-۴: مقایسه نرخ انتخاب راه بهینه در سیاست بیشینه نرم و سیاست ترکیبی.	۵۳
شکل ۸-۴: بلوک دیاگرام الگوریتم <i>EFSL</i> .	۵۵
شکل ۹-۴: توابع عضویت مقدم قواعد تعادل دهنده فازی.	۵۹
شکل ۱۰-۴: خروجی تعادل دهنده فازی برای $E=4.5$	۵۹
شکل ۱۱-۴: مقدار ملاقات فازی در فضای آموزش برای <i>EFSL</i> .	۶۳
شکل ۱۲-۴: هیستوگرام <i>LDI</i> ها در <i>FSL</i> .	۶۳
شکل ۱۳-۴: هیستوگرام <i>LDI</i> ها در <i>FSL-V</i> .	۶۳
شکل ۱۴-۴: هیستوگرام <i>LDI</i> ها در <i>FSL-A</i>	۶۴
شکل ۱۵-۴: هیستوگرام <i>LDI</i> ها در <i>EFSL</i>	۶۴
شکل ۱۶-۴: تعداد دفعات ملاقات هر مربع از فضای آموزش در یک مورد از فوق برازش در <i>FSL</i>	۶۴
شکل ۱۷-۴: تعداد دفعات ملاقات هر مربع از فضای آموزش در یک اجرای نمونه در <i>EFSL</i> .	۶۴

شکل ۱۸-۴: مجموع نرخ های آموزش هر مربع در فضای آموزش در یک مورد از فوق برازش در FSL	۶۵
شکل ۱۹-۴: مجموع نرخ های آموزش هر مربع در فضای آموزش در یک اجرای نمونه در EFSL	۶۵
شکل ۲۰-۴: ارزش عمل با بالاترین ارزش در FSL	۶۶
شکل ۲۱-۴: ارزش عمل با بالاترین ارزش در EFSL	۶۶
شکل ۲۲-۴: مسأله آوردن گاری به مرکز	۶۸
شکل ۲۳-۴: هیستوگرام LDI ها در FSL	۶۸
شکل ۲۴-۴: هیستوگرام LDI ها در EFSL	۷۲
شکل ۱-۵: ربات خپرا در مسأله حرکت در کنار دیوار	۷۳
شکل ۲-۵: ربات مینیاتوری خپرا	۷۴
شکل ۳-۵: ارتباط محیط شبیه سازی با MATLAB	۷۵
شکل ۴-۵: مختصات وضعیت ربات و هدف	۷۸
شکل ۵-۵: توابع عضویت ورودی های کنترلگر	۸۰
شکل ۶-۵: محیط آموزشی و نمونه ای از مسیر حرکت ربات در حین آموزش	۸۱
شکل ۷-۵: محیط تست برای رویدادهای ۱ تا ۸ در بخش تست	۸۱
شکل ۸-۵: محیط تست برای رویداد نهم در بخش تست	۸۲
شکل ۹-۵: محیط تست برای رویداد دهم در بخش تست	۸۴
شکل ۱۰-۵: هیستوگرام LDI ها در EFSL با $\alpha_0 = 0/10$	۸۴
شکل ۱۱-۵: هیستوگرام LDI ها در EFSL با $\alpha_0 = 0/1$	۸۴
شکل ۱۲-۵: هیستوگرام LDI ها در FQL با $\alpha_0 = 0/1$	۸۴
شکل ۱۳-۵: هیستوگرام LDI ها در FSL با $\alpha_0 = 0/1$	۸۵
شکل ۱۴-۵: منحنی تغییرات سیزده پارامتر وزن مربوط به عملهای کاندید در تالی قاعده نوزدهم	۸۵

فهرست جدول‌ها

عنوان	صفحة
جدول ۱-۳: نتایج شبیه سازی برای مقادیر متفاوت نرخ آموزش اولیه و ضریب دمای اولیه.	۴۰
جدول ۱-۴: نمایش تعداد انتخاب راه بهینه و متوسط زمان رسیدن به هدف برای سیاست‌های مختلف.	۵۰
جدول ۲-۴: نرخ رسیدن به هدف بهینه برای سیاست‌های مختلف	۵۲
جدول ۳-۴: نتایج شبیه سازی در مسأله هدایت قایق.	۶۲
جدول ۴-۴: مجموع المانهای بردار شدت آتش N برای EFSL	۶۳
جدول ۴-۵: نتایج شبیه سازی در مسأله آوردن گاری به مرکز.	۶۸
جدول ۱-۵: نتایج شبیه سازی در مسأله ناوبری ربات برای سه الگوریتم.	۸۳
جدول ۲-۵: جزییات نتایج شبیه سازی در مسأله ناوبری ربات برای الگوریتم EFSL	۸۵

فصل ۱ - مقدمه

۱-۱- پیشگفتار

طراحی روی خط^۱ کنترلگر بهینه برای سیستم‌های پیچیده در محیط‌هایی که دارای عدم قطعیت^۲ و ناپیویسی^۳ هستند، اگر غیر ممکن نباشد، کار پیچیده‌ای است. بخصوص برای سیستم‌هایی (مانند ناویبری ربات^۴ ها) که می‌خواهند بطور هوشمند با محیط تعامل داشته باشند. با توجه به اینکه عموماً اطلاعات زیادی در خصوص خروجی مطلوب کنترلگر در این نوع سیستم‌ها وجود ندارد، استفاده از از روش‌های آموزش بدون ناظر برای طراحی و تنظیم پارامترهای کنترلگر ارجحیت دارد [۳-۱].

آموزش تقویتی (RL)^۵، یک روش قوی مدرن برای آموزش روی خط استراتژی‌های کنترل از طریق تعامل با محیط است. این روش تنها با استفاده از یک معیار اسکالار راندمان، که سیگنال تقویت یا پاداش^۶ نامیده می‌شود، بدون نیاز به سرپرست قادر به آموزش عاملها در محیط‌های پیچیده، ناقصی و تصادفی می‌باشد [۶-۴]. قابلیتهای مذکور باضافه قدرت کاوش بالای آموزش تقویتی در جهت یافتن پاسخ بهینه، منجر به استفاده روز افزون آن در وظایف کنترلی پیچیده همچون کنترل حرکت ربات‌ها، و ناویبری ربات شده است.

سازماندهی الگوریتم‌های آموزش تقویتی بر مبنای تخمین ارزش^۷ حالت (یا جفت حالت- عمل) می‌باشد [۶، ۷]. در آموزش تقویتی گسسته مقدار ارزش^۸ حالت (یا جفت حالت- عمل) در جدول ارزش ذخیره شده و در هر قدم که آن حالت (یا جفت حالت- عمل) ملاقات شوند به روز رسانی انجام می‌گیرد [۶]. از آنجا که تعداد پارامترهای قابل تنظیم در آموزش تقویتی گسسته، رابطه مستقیمی با عدد اصلی^۹ فضای متغیرهای حالت و عمل مسأله دارد، در مسائل کنترل با فضای حالت- عمل بزرگ و یا پیوسته مانند ناویبری ربات، مشکل تنگنای ابعاد^{۱۰} وجود دارد. بنابراین استفاده از تقریب زننده‌های تابع برای تقریب تابع ارزش^{۱۱} در اینگونه مسائل ضروری است [۸، ۹].

بر این اساس محققین با ترکیب الگوریتم‌های آموزش تقویتی گسسته با تقریب زننده‌هایی همچون شبکه‌های عصبی و منطق فازی، الگوریتم‌های آموزش تقویتی پیوسته را ارائه داده‌اند. کاربردهای گسترده و عملکرد مطلوب سیستم استنتاج فازی در کنترل و مسائل پیچیده و نیز مزایایی چون امکان گنجاندن دانش بشری، ارائه دانش بصورت قواعد اگر- آنگاه، و قابلیت مدل‌سازی و کنترل سیستم‌های غیر خطی با

¹ Online

² Nondeterministic

³ Uncertainty

⁴ Robot navigation

⁵ Reinforcement Learning

⁶ Reward

⁷ Value

⁸ Cardinality

⁹ Cures of dimensionality

¹⁰ Value function

دقت دلخواه [۱۰-۱۲]، باعث شده است تا محققین [۱۳-۲۶] با ترکیب سیستم‌های فازی بعنوان تقریب زننده با روش‌های آموزش تقویتی، الگوریتم‌های آموزش تقویتی فازی (FRL)^۱ را ارائه دهند. تمرکز ما نیز در این رساله بر روی الگوریتم‌های FRL خواهد بود.

توجه شود که در آموزش تقویتی گسسته مقادیر ارزش حالت (یا جفت حالت- عمل) از هم مستقل می‌باشند، در حالیکه در حالت پیوسته به خاطر استفاده از تقریب زننده، مقدار ارزش در هر قدم زمانی بر مبنای پارامترهای تقریب زننده حاصل می‌شود، لذا به روز رسانی پارامترها در هر قدم زمانی بر روی مقادیر ارزش در کل فضا تاثیر می‌گذارد.

۱-۲- دو موضوع مهم در آموزش تقویتی پیوسته

دو موضوع در بکارگیری الگوریتم‌های FRL (یا بطور کلی الگوریتم‌های آموزش تقویتی پیوسته) در مسائل کنترلی مورد توجه ویژه هستند [۲۷]:

۱-۲-۱- تحلیل ریاضی الگوریتم

بر خلاف نتایج و قضایایی که در خصوص همگرایی مقادیر ارزش برای الگوریتم‌های آموزش تقویتی گسسته ارائه شده است [۲۸-۳۰]، اکثر روش‌های آموزش تقویتی پیوسته موجود، قادر تحلیل ریاضی می‌باشند. بنابراین تحلیل ریاضی الگوریتم‌های آموزش تقویتی پیوسته، یک موضوع مورد علاقه برای محققین می‌باشد.

۱-۲-۲- تعادل بین کاوش و بهره‌برداری از تجربیات

در حین آموزش تقویتی دو هدف مخالف باید با هم ترکیب شوند: از یک طرف کلیه جفت‌های حالت- عمل مسأله باید به حد کافی برای بدست آوردن دانش مورد کاوش^۲ قرار گیرند و از طرف دیگر تجربه‌های بدست آمده باید در انتخاب عمل بکار گرفته شوند. از نقطه نظر کاوش، مهمترین سؤال این است که چگونه می‌توان زمان یادگیری را حداقل نمود. متناظراً از نقطه نظر بهره‌برداری از تجربیات^۳ گذشته سؤال این است که چگونه می‌توان جریمه‌ها را کاهش داد [۳۱]. برای آموزش مؤثر، عملها باید بگونه‌ای انتخاب شوند که محیط بطور مناسب آزموده شده و از جریمه‌ها نیز حتی امکان اجتناب گردد. انجام کامل این دو کار بطور همزمان ممکن نیست. در ادامه این رساله برای مختصر نویسی بجای عبارت "تعادل"^۴ بین کاوش و بهره‌برداری از تجربیات" از عبارت "تعادل" استفاده می‌کنیم. برقراری تعادل مناسب، ضمن کاهش زمان آموزش، امکان گریز عامل از نقاط اکسترم محلی را فراهم نموده و منجر به یافتن جواب مطلوب می‌گردد. تعدادی از محققین راهکارهایی برای انتخاب عمل و برقراری تعادل مناسب در آمروش تقویتی گسسته ارائه داده اند، لیکن در خصوص تعادل در آموزش تقویتی پیوسته، نتایج تحقیق جامعی ارائه

¹ Fuzzy Reinforcement Learning

² Exploration

³ Exploitation

⁴ Balance

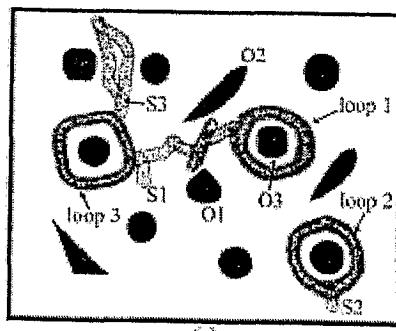
نشده است. بطور کلی مقوله تعادل بین کاوش و بهره‌برداری از تجربیات یک موضوع باز و جدید در آموزش تقویتی پیوسته است که دومین موضوعی است که در این رساله بر روی آن تحقیق می‌شود.

۱-۳-۱- مروری بر مطالعات انجام شده

دو معماری معروف استفاده شده در FRL ها، روش عملگر- نقاد^۱ [۳۲، ۱۰] و نقاد- تنها^۲ [۳۳، ۶] هستند. در اینجا، ابتدا دو معماری مذکور شرح داده شده و سپس مطالعات انجام شده در خصوص تحیل ریاضی و تعادل مرور می‌گردد.

۱-۳-۲- معماری عملگر- نقاد

آموزش عملگر- نقاد فازی(FACL)^۳ دارای دو بخش نقاد و عملگر می‌باشد. بخش نقاد برای تقریب تابع ارزشی حالت و بخش عملگر برای تولید عمل استفاده می‌گردد. در واقع از بخش نقاد برای تخمین خطای ارزش (خطای تفاضل موقتی TD)^۴ و بکارگیری این خطا برای تنظیم پارامترهای بخش عملگر استفاده می‌شود [۱۴]. علیرغم بکارگیری الگوریتمهای FACL در بسیاری از مسائل، هیچ تحلیل ریاضی و یا اثبات همگرایی برای الگوریتمهای FACL موجود که تنها از دو بخش عملگر و نقاد استفاده می‌کنند، موجود نیست. ضعف دیگر ساختار فوق فقدان کاوش مناسب است. در واقع انتخاب عمل در الگوریتم مذکور بر مبنای سیاست حریصانه^۵ می‌باشد و امکان ارزیابی عملهای دیگر در هر حالت را نمی‌دهد. شکل ۱-۱ نمونه‌ای از به دام افتادن ربات در حلقه‌ی بین موانع [۲۰] FACL نشان می‌دهد [۲۰].



شکل ۱-۱: نمونه‌ای از به دام افتادن ربات در بین موانع [۲۰].

¹ Actor-critic

² Critic-only

³ Fuzzy Actor Critic Learning

⁴ Temporal Difference

⁵ Greedy

دلیل رخداد مشکل مذکور، فقدان کاوش در الگوریتم‌های FACL می‌باشد. تعدادی از محققین [۳۴، ۱۹] برای رفع مشکل فوق، خروجی نهایی را با یک مقدار تصادفی برمبنای تابع توزیع چگالی احتمال گوسی با میانگین صفر جمع نموده‌اند. علیرغم بهبودهای صورت گرفته به دلیل لحاظ کردن کاوش در کنترلگر، تعادل مناسبی بین کاوش و بهره‌برداری از تجربیات حاصل نشده و نقاط ضعفی چون توزیع احتمال یکنواخت خروجی حول عمل با بالاترین ارزش، و همچنین فقدان ارتباط میان احتمال انتخاب عمل‌ها با مقدارهای ارزش عمل^۱ همچنان پا بر جاست.

در [۵] یک الگوریتم FRL جدید با ساختاری شبیه عملگر- نقاد ارائه گردیده و همگرایی روش اثبات شده است. در این الگوریتم بخش نقاد به تقریب مقدار ارزش عمل بجای مقدار ارزش حالت می‌پردازد و خروجی بخش عملگر احتمال انتخاب هر عمل می‌باشد. همچنین بخش دیگر نیز برای تقریب مقدار ارزش در نظر گرفته شده است. گرچه این الگوریتم نسبت به روش‌های دیگر FACL دارای تحلیل ریاضی و درجه کاوش بالاتری نسبت به دیگر FACL ها است، لیکن بالاسری محاسباتی بالای آن منجر به عدم گرایش محققین به استفاده از آن شده است. ضمناً به مقوله تعادل بین کاوش و استفاده از تجربیات پرداخته نشده است.

۱-۳-۲- معماری نقاد- تنها

در مقابل معماری عملگر- نقاد، روش تنها فقط دارای، یک بخش نقاد است که برای تقریب تابع ارزش عمل استفاده می‌شود و عمل نهایی با توجه به مقادیر ارزش تقریب زده شده تولید می‌گردد. این نحوه انتخاب عمل ضمن فراهم نمودن امکان درجه کاوش بالا، پتانسیل لازم برای برقراری تعادل بین کاوش و بهره‌برداری از تجربیات را دارا می‌باشد. ضمناً ساختار فوق امکان گنجاندن دانش بشری را براحتی ممکن می‌سازد.

در [۲۶-۲۲]، معماری نقاد- تنها با ترکیب یک سیستم فازی با روش آموزش Q^۲ (که یک روش "مستقل از سیاست"^۳ است) پیاده سازی شده است. یک نسخه کامل از الگوریتم مذکور با نام آموزش Q FQL^۴ در [۲۳] معرفی گردید. در الگوریتم FQL تالی قواعد یک سیستم فازی T-S^۵ مرتبه صفر، بصورت روی خط تنظیم می‌شوند. این الگوریتم در مسائل زیادی از جمله رباتها بکار گرفته شده است [۲۶-۲۲]، اما روش مذکور بر مبنای تجربه بوده و دارای دو ضعف عمده‌ی فقدان تحلیل ریاضی و امکان واگرایی است. مثال‌ها و تحلیل‌هایی از واگرایی الگوریتم FQL و نیز واگرایی الگوریتم‌هایی که از ترکیب آموزش Q با "تقریب زننده‌های تابعی خطی"^۶ (تقریب زننده‌های تابع بصورت ترکیب‌های خطی از

¹ Action value

² Q-Learning

³ Off-policy

⁴ Fuzzy Q-Learning

⁵ Takagi-Sugeno

⁶ Linear function approximators

یک سری توابع پایه^[۹]) استفاده می‌کنند در [۳۵،۸] آمده است. در واقع گرچه قابلیت مستقل از سیاست آموزش Q خوشایند است، لیکن تازه سازی مقدار ارزش جفت حالت- عمل بر طبق یک توزیع متفاوت از دینامیک زنجیره مارکف باعث ناپایداری الگوریتم در حالت پیوسته می‌گردد [۲۶]. بعلاوه الگوریتم‌های آموزش Q ترکیب شده با تقریب زننده‌های تابع، ویژگی مستقل از سیاست را از آموزش Q گستته، به اثر نبرده و مقدار نهایی ارزش جفت حالت- عمل تقریب زده شده به سیاست استفاده شده وابستگی شدید دارد.

بر خلاف نتایج تحلیلی منفی و مثالهایی از واگرایی که برای الگوریتم‌های آموزش تقویتی پیوسته که از تعمیم روش آموزش Q حاصل شده‌اند، موجود است، تعدادی از نتایج تحلیلی مثبت در خصوص ترکیب روش‌های آموزش تقویتی "وابسته به سیاست"^۱ با تقریب زننده‌های تابع وجود دارد [۳۷،۲۷]. وجود نقاط ایستا^۲ در روش تفاضل موقتی خطی که از سیاست انتخاب عمل بیشینه ترم^۳ بهره می‌برد، در [۳۷] اثبات شد. البته این اثبات تنها مربوط به تقریب تابع ارزش حالت است نه تابع ارزش عمل. بعلاوه، با توجه به آنکه در فرمول بیشینه ترم مقدار ارزش عمل مورد نیاز است، در مقاله مذکور مقدار ارزش عمل در هر قدم زمانی، از مقدار تابع ارزش با فرض دانستن مدل محیط محاسبه شده است، در حالیکه در مسائل آموزش تقویتی معمولاً مدل محیط، ناشناخته فرض می‌گردد.

در مقالات [۳۹،۳۸] از ترکیب روش سارسا^۴ (که یک روش وابسته به سیاست است) با تقریب زننده‌های تابعی خطی (ما این ترکیب را سارسای خطی می‌نامیم) برای تقریب تابع ارزش عمل استفاده شده است. در [۳۸] همگرایی پارامترهای وزن سارسای خطی به یک ناحیه در صورت استفاده از یک سیاست ایستا^۵ در همه رویدادها^۶، اثبات شده است. در [۳۹] همگرایی الگوریتم ارائه شده به پاسخ یکتا به شرط ایستا بودن سیاست‌ها در هر اپیسود اثبات گردیده است. الگوریتم مذکور دارای دو ضعف عمدۀ می‌باشد: ۱- نتایج قضیه، تضمینی در خصوص کیفیت سیاست نهایی که الگوریتم به آن همگرا می‌شود ارائه نمی‌دهد، ۲- با توجه به آنکه پس از تعیین هر سیاست جدید باید آموزش تا همگرایی وزنها ادامه یابد، سرعت آموزش کند می‌باشد. در حالیکه در مسائل کنترل با آموزش روی خط، مطلوب آن است که در هر قدم زمانی سیاست انتخاب عمل به روز رسانی گردد. توجه شود که هیچگونه پیاده سازی و شبیه سازی برای سه الگوریتم اشاره شده در بالا [۳۹-۳۷] ارائه نشده و در واقع دو چالش عمدۀ برای پیاده سازی این الگوریتم‌ها وجود دارد: انتخاب تابع تقریب زننده تابعی خطی و نحوه انتخاب عمل، به نحوی که این دو بتوانند شرایط بیان شده در لم‌ها وقضایای بیان شده در مقالات مذکور را ارضاء نمایند.

در مجموع، بر خلاف روش‌های آموزش تقویتی گستته، هیچ قضیه‌ای در خصوص همگرایی آموزش تقویتی (فازی) بر مبنای معماری نقاد-تنها وقتی که سیاست انتخاب عمل ایستا نباشد و یا هنگامی که

¹ On-policy

² Stationary points

³ Softamx

⁴ Sarsa

⁵ Stationary

⁶ Episodes

سیاست بر مبنای مقدار ارزش عمل در هر قدم زمانی به روز رسانی شود، وجود ندارد. لذا این موضوع یکی از مواردی است که در این رساله بر روی آن تحقیق می‌گردد.

در ادامه به روشهای انتخاب عمل بکار رفته در الگوریتم‌های اشاره شده در بالا پرداخته می‌شود. الگوریتم‌های FQL ارائه شده در [۲۵-۲۲] از ایده‌های موجود انتخاب عمل و تعادل در حالت گستته [۶، ۳۱] برای انتخاب یک عمل در هر قاعده فازی استفاده کرده‌اند. همچنین الگوریتم FQL ارائه شده در [۲۲]، برای انتخاب عملها در هر قاعده از ترکیب فرمول بیشینه ترم با روش "نرخ انجام عمل" [۳۱] بهره برده است. در واقع روشهای انتخاب عمل در مقالات مذکور [۲۶-۲۲] یک گسترش روشهای انتخاب عمل در حالت گستته بدون توجه به ویژگی‌های تابع ارزش عمل در حالت پیوسته می‌باشد.

در آموزش تقویتی گستته، تعداد حالت‌ها و عمل‌ها قابل شمارش و محدود می‌باشد. مقادیر حالت‌ها و (یا جفت‌های حالت-عمل) در یک جدول ارزش ذخیره شده و این مقادیر بطور مستقل به روز رسانی می‌گردند. در حالیکه در آموزش تقویتی گستته، تعداد حالت‌ها و عمل‌ها نا محدود و غیر قابل شمارش می‌باشند. با توجه به استفاده از تقریب زننده‌ها برای تقریب تابع ارزش، به روز رسانی پارامترهای تقریب زننده در هر قدم زمانی می‌تواند باعث تغییر مقدار ارزش در کل فضای مسأله گردد. این تفاوت‌ها باعث می‌شود که ایده‌های ارائه شده برای حالت گستته چندان در حالت پیوسته کارآ نباشند.

نکته دیگر آنکه نحوه انتخاب عمل در مقالات فوق [۲۶-۲۲] هیچ تضمینی برای اینکه تابع توزیع احتمال انتخاب عمل نهایی از یک تابع پیوسته تبعیت کند را ارائه نمی‌دهد. در حالیکه یک نکته مهم در آموزش تقویتی پیوسته، تولید عمل نهایی بر طبق یک توزیع احتمال پیوسته است به گونه‌ای که تغییرات کوچک در مقدار ارزش عمل باعث تغییرات شدید در رفتار عامل نشود [۳۹].

یک مشکل دیگر در RL پیوسته، خطای تقریب تابع ارزش است، بعضًا مقدار این خطای بقدرتی بزرگ می‌شود که انتخاب عمل بر مبنای آن عملکرد بسیار ضعیفی را باعث می‌گردد. دلیل این خطای زیاد، غالب شدن اثر داده‌های آموزشی ناحیه و یا نواحی می‌باشد که عامل نسبت به نواحی دیگر بسیار بیشتر ملاقات نموده است. این مشکل را ما "فوق برازش"^۱ می‌نامیم و برای اولین بار در این رساله در فصلهای بعد بطور کامل معرفی می‌گردد. برای رفع این معطل ما یک نرخ آموزش طبیقی را معرفی می‌نماییم. لذا در اینجا اشاره ای هم به نرخ‌های آموزش استفاده شده در FRL‌ها می‌شود.

بعنوان یک نکته عملی در اکثر مسائل RL، نرخ آموزش با تابعی از زمان کاهش می‌باید [۶، ۲۴، ۲۲، ۲۵]. از آنجا که نرخ آموزش مذکور تابعی از زمان است، مقدار آن در هنگام به روز رسانی برای پارامترهای قابل تنظیم قواعدی که در شروع آموزش تحریک نمی‌گردد، بقدرتی کوچک خواهد بود که تغییر این پارامترها محسوس نمی‌باشد. برای رفع مشکل مذکور، در [۴۰] یک نرخ جدید آموزش پیشنهاد گردیده است. در این روش برای پارامترهای قابل تنظیم هر قاعده مستقل از قواعد دیگر یک نرخ آموزش تعیین می‌شود. مقدار نرخ آموزش برای هر قاعده با توجه به مجموع شدت آتش‌های گذشته آن قاعده محاسبه

^۱ Overfitting