



دانشگاه صنعتی امیر کبیر  
 (پلی‌تکنیک تهران)  
 دانشکده مهندسی کامپیوتر و فناوری اطلاعات

پایان نامه کارشناسی ارشد هوش مصنوعی

عنوان :

یادگیری تقویتی مبتنی بر نقشهٔ خودسازمان ده تطبیقی با زمان

توسط:  
 حسام منتظری

استاد راهنما:  
 دکتر رضا صفابخش

بسمه تعالی



دانشگاه صنعتی امیرکبیر

(پلی تکنیک تهران)

معاونت پژوهشی

## فرم اطلاعات پایان نامه

### کارشناسی ارشد و دکترا

تاریخ:

پیوست:

نام و نام خانوادگی: حسام منتظری

شماره دانشجویی: ۸۳۱۳۱۲۳۱

نام و نام خانوادگی استاد راهنما: دکتر رضا صفابخش

عنوان پایان نامه به فارسی: یادگیری تقویتی مبتنی بر نقشه خودسازمانده تطبیقی با زمان

عنوان پایان نامه به انگلیسی: Reinforcement Learning using Time-Adaptive Self Organizing Map

پنونه پروژه: کارشناسی ارشد  
دکترا

تاریخ شروع: ۸۴/۸/۱

سازمان تأمین کننده اعتبار: -

واژه های کلیدی به فارسی: یادگیری تقویتی، نقشه خودسازمانده رشدیابنده، نقشه خودسازمانده تطبیقی با زمان، کنترل ترافیک

واژه های کلیدی به انگلیسی: Reinforcement Learning, Growing SOM, TASOM, Traffic Light Control

نظرها و پیشنهادها به منظور بهبود فعالیت های پژوهشی دانشگاه:

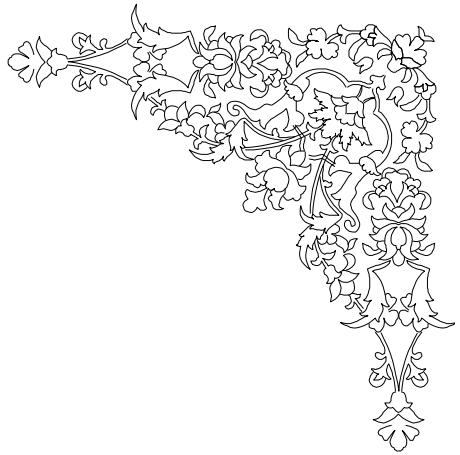
استاد راهنما:

دانشجو:

تاریخ: امضاء استاد راهنما:

نسخه ۱: معاونت پژوهشی

نسخه ۲: کتابخانه و به انتظام دو جلد پایان نامه به منظور تسويه حساب با کتابخانه و مرکز اسناد و مدارک علمی



تقدیم به

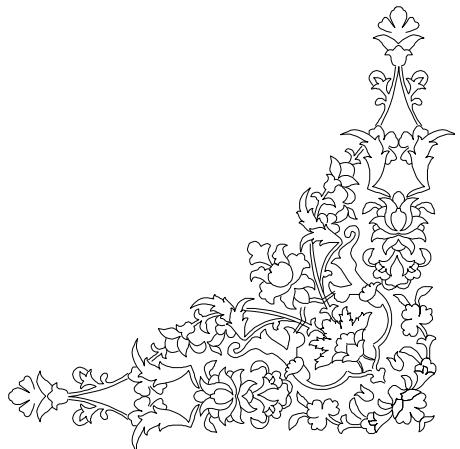
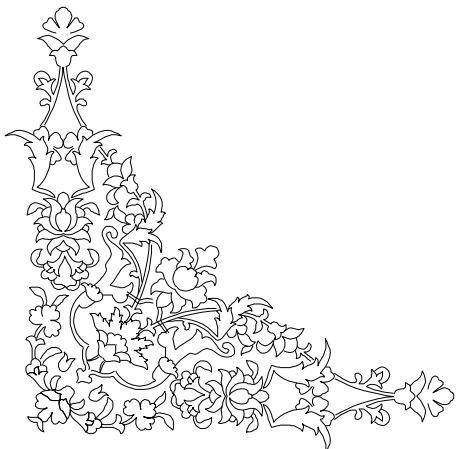
پدر و مادر مهربان

و

همسر عزیزم

که در همه حال پشتیبان و یاور من

بوده‌اند.



از استاد راهنمای خود، جناب آقای دکتر رضا صفابخش، به پاس  
راهنمایی‌های گرانقدر ایشان در طول مدت تحصیل در دوره کارشناسی ارشد و  
بویژه طی انجام این پژوهش، کمال تشکر را دارم.

## چکیده

یادگیری تقویتی، نگاشت وضعیت‌ها به عمل‌ها با هدف ماقریزم کردن سیگنال پاداش دریافتی را بررسی می‌کند. در این نوع یادگیری، به عامل گفته نمی‌شود که چه عملی را انتخاب کند، بلکه عامل باید عملی را انتخاب کند که پاداش دریافتی از محیط را بیشینه کند. در چالش برانگیزترین حالات، پاداش عمل‌ها بلا فاصله مشخص نمی‌شود. یادگیری تقویتی، از یک سو دارای پشتونه قوی از قضایا و اثبات‌های ریاضی است؛ و از سویی دیگر، این روش در مسائل مختلفی همچون مسیریابی ربات، اجتناب از مانع، تصمیم‌گیری در بازی‌ها، مسائل مهارت‌ها در روبوکاپ، و کنترل ترافیک به طور موفق عمل کرده است. یکی از مسائل مهمی که در مورد این روش مطرح می‌شود، بسط و توسعه روش به مسائلی با فضای وضعیت پیوسته است. برای حل مسائل با فضای وضعیت پیوسته، روش‌های مختلفی مانند شبکه‌های عصبی پرسپترونی چند لایه، کیمک، درخت‌های تصمیم، و نقشه‌های خودسازمان ده ارائه شده است. نشان داده شده است که یادگیری تقویتی با استفاده از نقشه‌های خودسازمان ده استاندارد در حل بسیاری از مسائل با فضای وضعیت پیوسته و حتی فضای عمل پیوسته موفق بوده‌اند. اما نقشه خودسازمان ده استاندارد نمی‌تواند یک تابع هدف متغیر را به خوبی ارائه کند و برای توابع هدفی که با تپولوژی نقشه همخوانی ندارد مورد استفاده واقع نمی‌شود. در این پایان‌نامه، یادگیری تقویتی مبتنی بر نقشه خودسازمان ده تطبیقی برای حل مشکل تابع هدف متغیر ارائه شده است. تابع هدف متغیر در یادگیری تقویتی منحصر به داده‌های فضای ورودی نیست، بلکه داده‌هایی که به عنوان ورودی نقشه خروجی داده می‌شود همیشه توزیع چگالی متغیر با زمان دارد. باید توجه داشت در یادگیری تقویتی عامل با گذشت زمان عملکرد خود را بهبود می‌دهد، در نتیجه داده‌های ورودی به نقشه خروجی با گذشت زمان تغییر می‌کنند و توزیع چگالی آن نایستا است روش دیگری که در این پایان‌نامه ارائه شده است روش یادگیری تقویتی با استفاده از نقشه خودسازمان ده رشدیابنده است. این روش برای حل هر دو مشکل ذکر شده ارائه شده است. ترکیب یادگیری تقویتی با نقشه‌های خودسازمان ده رشدیابنده به سادگی امکان‌پذیر نیست و ترکیب این نوع نقشه با الگوریتم‌هایی که جدول کیو آن در طول زمان ثابت است، میسر نمی‌باشد. در این پایان‌نامه الگوریتم جدیدی مبتنی بر نقشه‌های خودسازمان ده رشد یابنده ارائه شده است که جدول کیو آن در طول زمان بزرگ و کوچک می‌شود. نشان داده شده است این الگوریتم در حل مسائل مختلف از بقیه روش‌ها موفق‌تر بوده است.

## فهرست مطالب

۱	۱- مقدمه
۴	<b>۲- یادگیری تقویتی</b>
۴	۲-۱ مسئله یادگیری تقویتی
۴	۲-۱-۱ رابط عامل و محیط
۵	۲-۱-۲ هدفها و پاداشها
۶	۲-۱-۳ بازگشت
۷	۲-۱-۴ خصوصیت مارکف
۷	۲-۱-۵ فرآیند تصمیم‌گیری مارکف
۸	۲-۱-۶ توابع ارزش
۱۰	۲-۱-۷ توابع ارزش بهینه
۱۰	۲-۲ تفاضل زمانی
۱۰	۲-۲-۱ پیش‌بینی یا ارزیابی تفاضل زمانی
۱۱	۲-۲-۲ روش سارسا
۱۳	۲-۲-۳ یادگیری کیو
۱۳	۲-۲-۴ تفاضل زمانی لاندا
۱۸	۲-۲-۵ سارسا لاندا
۱۸	۲-۲-۶ یادگیری کیو لاندا
۲۱	۳-۲ جمع‌بندی
۲۲	<b>۳- نقشه‌های خودسازمان ده</b>
۲۲	۳-۱ نقشه خودسازمان ده استاندارد
۲۶	۳-۲ نقشه خودسازمان ده تطبیقی با زمان
۲۶	۳-۲-۱ نقشه خودسازمان ده تطبیقی با نرخ‌های یادگیری جداگانه و پویا
۲۹	۳-۲-۲ نقشه خودسازمان ده تطبیقی با نرخ‌های یادگیری و مجموعه‌های همسایگی جداگانه و پویا
۳۲	۳-۲-۳ شبکه خودسازمان ده تطبیقی با نرخ‌های یادگیری و تابع‌های همسایگی جداگانه و پویا
۳۳	۳-۳ نقشه‌های خودسازمان ده رشدیابنده
۳۴	۳-۳-۱ شبکه گاز عصبی
۳۵	۳-۳-۲ یادگیری هبی رقابتی
۳۵	۳-۳-۳ شبکه گاز عصبی با یادگیری هبی رقابتی
۳۶	۳-۳-۴ شبکه گاز عصبی رشدیابنده
۳۸	۳-۴-۵ ساختار سلولی رشدیابنده
۳۹	۳-۴-۶ توری بزرگ شونده
۴۲	۴-۴ جمع‌بندی
۴۳	<b>۴- یادگیری تقویتی مبتنی بر نقشه‌های خودسازمان ده</b>
۴۳	۴-۱ روش کیو کوهون
۴۴	۴-۲ نقشه موتوری
۴۵	۴-۲-۱ تابع چگالی نرمال چندبعدی
۴۶	۴-۲-۲ یادگیری کواریانسی
۴۸	۴-۳-۲-۴ استفاده از یادگیری کواریانسی در پیدا کردن عمل‌ها

.....۴۹	۴-۲-۴ استفاده از تجربه برای بهبود یادگیری
.....۵۰	۳-۴ جمع‌بندی
.....۵۱	۵- مدل‌های پیشنهادی
.....۵۱	۱-۵ مدل تطبیقی
.....۵۲	۲-۵ مدل رشدیابنده
.....۵۴	۳-۵ جمع‌بندی
.....۵۵	۶- نتایج تجربی در مسائلی از رباتیکز
.....۵۵	۱-۶ مسئله بازوی ربات دومفصلی - نگاشت یک به یک
.....۶۹	۲-۶ مسئله بازوی ربات دومفصلی- نگاشت چند به یک
.....۸۱	۳-۶ جمع‌بندی
.....۸۲	۷- نتایج تجربی در کنترل چراغ راهنمایی
.....۸۲	۱-۷ شبیه‌ساز ترافیکی
.....۸۳	۲-۷ آزمایش‌های انجام شده
.....۸۹	۳-۷ جمع‌بندی
.....۹۰	۸- نتیجه‌گیری و پیشنهادات
.....۹۰	۱-۸ نتایج
.....۹۱	۲-۸ پیشنهادات
.....۹۳	مراجع
.....۹۶	ضمیمه الف- نتایج روشها در وضعیت‌های ترافیکی متوسط و سنگین

## فهرست اشکال

.....۵	.....۱-۲ تعامل عامل و محیط در یادگیری تقویتی
.....۹	.....۲-۲ نمودار پشتیبان برای $V^\pi$
.....۱۲	.....۳-۲ تفاضل زمانی جدولی برای تخمین $V^\pi$
.....۱۲	.....۴-۲ نمودار پشتیبان تفاضل زمانی
.....۱۲	.....۵-۲ دنباله وضعیتها و زوجهای عمل-وضعیت در اپیزود
.....۱۳	.....۶-۲ شبیه کد الگوریتم سارسا
.....۱۳	.....۷-۲ شبیه کد الگوریتم یادگیری کیو
.....۱۴	.....۸-۲ پشتیبان‌های مختلف تفاضل زمانی
.....۱۶	.....۹-۲ پشتیبان ترکیبی از پشتیبانهای دو-گام و چهار-گام
.....۱۷	.....۱۰-۲ پشتیبان تفاضل زمانی لاندا
.....۱۷	.....۱۱-۲ تصویر نشان تجمعی
.....۱۸	.....۱۲-۲ شبیه کد تفاضل زمانی جدولی لاندا ONLINE
.....۱۹	.....۱۳-۲ نمودار پشتیبان سارسا لاندا
.....۱۹	.....۱۴-۲ شبیه کد سارسا جدولی لاندا
.....۲۰	.....۱۵-۲ نمودار پشتیبان یادگیری کیو.
.....۲۱	.....۱۶-۲ نسخه جدولی الگوریتم یادگیری کیو WATKIN'S
.....۲۳	.....۱-۳ توپولوژی نورون‌های شبکه روی لایه خروجی.
.....۲۴	.....۲-۳ نگاشت یک بردار از ابعاد بالاتر به فضایی با ابعاد کوچکتر در نقشه خودسازمانده استاندارد
.....۲۴	.....۳-۳ تعیین مجموعه نورونهای همسایه با توجه به نورون برنده در زمانهای $T$ و $T+1$
.....۲۵	.....۴-۳ تابع گاسی همسایگی برای $\sigma(t) = 3$
.....۲۸	.....۵-۳ تابع نرمالیزه کننده $f(z) = \frac{z}{1+z}$
.....۲۸	.....۶-۳ تابع نرمالیزه کننده $f(z) = \frac{1-e^{-z}}{1+e^{-z}}$
.....۴۳	.....۱-۴ یادگیری کیو با استفاده از نقشه خودسازمانده به روش کیو کوهون
.....۴۴	.....۲-۴ انتخاب بهترین عمل برای انجام در هر موقعیت در روش کیو کوهون
.....۴۶	.....۳-۴ پیشنهاد عمل‌های نمونه در نقشه موتوری
.....۴۷	.....۴-۴ جهت تقریبی برای بروزرسانی به سمت عمل هدف در روش نقشه موتوری
.....۴۸	.....۵-۴ در این شکل جهت کواریانسی به درستی پیدا شده است ولی اندازه گام بزرگ است.
.....۴۹	.....۶-۴ استفاده نامناسب از تجربه در یادگیری کواریانسی
.....۵۲	.....۱-۵ مدل یادگیری تقویتی مبتنی بر نقشه خودسازمانده استاندارد



..... ۷۲	..... شکل ۶-۲۸ نقشه خودسلزمانده تطبیقی ورودی حاصل از اعمال روش تطبیقی در مسئله ۲-الف
..... ۷۳	..... شکل ۶-۲۹ مکان نوک بازوی ربات در صورت بکارگیری روش اسمیت در مسئله ۲-الف
..... ۷۳	..... شکل ۶-۳۰ مکان نوک بازوی ربات در صورت بکارگیری روش اسمیت در مسئله ۲-ب
..... ۷۴	..... شکل ۶-۳۱ نمودار میانگین پاداش دریافتی روش تطبیقی برحسب زمان برای مسئله ۲-الف
..... ۷۵	..... شکل ۶-۳۲ نمودار میانگین پاداش دریافتی روش تطبیقی برحسب زمان برای مسئله ۲-ب
..... ۷۵	..... شکل ۶-۳۳ نقشه خودسلزمانده تطبیقی ورودی حاصل از اعمال روش تطبیقی در مسئله ۲-الف
..... ۷۶	..... شکل ۶-۳۴ نقشه خودسازمانده تطبیقی خروجی حاصل از اعمال روش تطبیقی در مسئله ۲-الف
..... ۷۶	..... شکل ۶-۳۵ مکان نوک بازوی ربات در صورت بکارگیری روش تطبیقی در مسئله ۲-الف
..... ۷۷	..... شکل ۶-۳۶ مکان نوک بازوی ربات در صورت بکارگیری روش تطبیقی در مسئله ۲-ب
..... ۷۸	..... شکل ۶-۳۷ نمودار میانگین پاداش دریافتی روش رشدیابنده برحسب زمان برای مسئله ۲-الف
..... ۷۸	..... شکل ۶-۳۸ نمودار میانگین پاداش دریافتی روش رشدیابنده برحسب زمان برای مسئله ۲-ب
..... ۷۹	..... شکل ۶-۳۹ نقشه ورودی حاصل از اعمال روش رشدیابنده در مسئله ۲-الف
..... ۸۳	..... شکل ۷-۱ تصویری از شبیه‌ساز ترافیکی
..... ۸۵	..... شکل ۷-۲ نمودارهای حاصل از اعمال روش اسمیت در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک
..... ۸۷	..... شکل ۷-۳ نمودارهای حاصل از اعمال مدل تطبیقی در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک
..... ۸۸	..... شکل ۷-۴ نمودارهای حاصل از اعمال مدل رشدیابنده در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک
الـ۱.....	..... شکل الف-۱ نمودارهای حاصل از اعمال روش اسمیت در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی متوسط
الـ۲.....	..... شکل الف-۲ نمودارهای حاصل از اعمال مدل تطبیقی در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی متوسط
الـ۳.....	..... شکل الف-۳ نمودارهای حاصل از اعمال مدل رشدیابنده در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی متوسط
الـ۴.....	..... شکل الف-۴ نمودارهای حاصل از اعمال روش اسمیت در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی سنگین
الـ۵.....	..... شکل الف-۵ نمودارهای حاصل از اعمال مدل تطبیقی در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی سنگین
الـ۶.....	..... شکل الف-۶ نمودارهای حاصل از اعمال مدل رشدیابنده در مسئله کنترل چراغ راهنمای برای وضعیت ترافیکی سنگین

## فهرست جدول‌ها

.....۵۷.	جدول ۱-۶ پارامترهای مورد استفاده روش اسمیت در کنترل بازوی ربات دو مفصلی ایستا
.....۶۰.	جدول ۲-۶ پارامترهای مورد استفاده روش تطبیقی در کنترل بازوی ربات دو مفصلی ایستا
.....۶۳.	جدول ۳-۶ پارامترهای روش رشیدیابنده در کنترل بازوی ربات دو مفصلی ایستا
.....۶۹.	جدول ۴-۶ مقایسه زمان اجرای روش‌های ارائه شده
.....۷۱.	جدول ۵-۶ پارامترهای مورد استفاده روش اسمیت در آزمایش کنترل بازوی ربات دو مفصلی متغیر با زمان
.....۷۴.	جدول ۶-۶ پارامترهای مورد استفاده روش تطبیقی در آزمایش کنترل بازوی ربات دو مفصلی متغیر با زمان
.....۷۷.	جدول ۷-۶ پارامترهای مورد استفاده روش رشیدیابنده در آزمایش کنترل بازوی ربات دو مفصلی متغیر با زمان
.....۸۴.	جدول ۱-۷ پارامترهای مورد استفاده روش اسمیت در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک
.....۸۶.	جدول ۲-۷ پارامترهای مورد استفاده روش تطبیقی در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک
.....۸۶.	جدول ۳-۷ پارامترهای مورد استفاده روش رشیدیابنده در مسئله کنترل چراغ راهنمای در وضعیت ترافیکی سبک

# فصل اول

## مقدمه

تکنیک های یادگیری ماشین معمولاً به سه دسته اصلی تقسیم می شوند: یادگیری با نظارت، یادگیری بی نظارت، و یادگیری تقویتی. یادگیری با نظارت به نمونه هایی از ورودی و خروجی تابع هدف (داده های آموزشی) نیازمند است. در یادگیری بی نظارت داده هدف وجود ندارد و فقط بر روی داده های ورودی پردازش صورت می گیرد. یادگیری تقویتی از نظر ارزیابی از سوی محیط، در حد فاصل دو روش قبلی است. یادگیری تقویتی مانند روش بانظارت خروجی صحیح را دریافت نمی کند، اما سیگنالی را از محیط دریافت می کند که صرفاً خوب بودن انجام عمل قبلی را نشان می دهد. اثبات شده است که بسیاری از روش های یادگیری تقویتی همیشه به سیاست بهینه همگرا خواهند شد [۲۸، ۳]. از جنبه کاربردی نیز روش یادگیری تقویتی در مسائل مختلفی همچون اجتناب از مانع در مسیر یابی ربات ها [۲۴]، کنترل ترافیک [۱، ۴] تصمیم گیری در بازی ها [۳۲]، مهارت های عامل ها در لیگ های روبوکاپ [۲۷]، و غیره به طور گسترده مورد استفاده قرار گرفته است.

یکی از مسائل مهمی که در مورد یادگیری تقویتی مطرح می شود، حل مسائل با فضای وضعیت و عمل پیوسته است. بیشتر نظریه هایی که در مورد یادگیری تقویتی است، مبتنی بر فرض گسسته بودن فضای وضعیت است. برای حل مسائل پیوسته یادگیری تقویتی، روش های مختلفی همچون شبکه های عصبی پرسپترونی چند لایه [۱۴، ۳]، کیمک [۲۶، ۲۸، ۲]، و نقشه های خود سازمان ده مطرح می شود [۳۱، ۲۴].

این پایان نامه استفاده از نقشه های خودسازمان ده در یادگیری تقویتی را مورد توجه قرار داده است. کارهای مختلفی در این زمینه صورت گرفته است. Q-Kohon روش تقویتی مبتنی بر این نقشه است که توسط توزئن ارائه شده است [۱۸]. در Q-Kohon جدول وضعیت-عمل با نقشه خودسازمان ده جایگزین شده است. هر نورون شامل سه گانه وضعیت، عمل، و ارزش کیو است. در این روش، انتخاب نورون برای اجرا مبتنی بر مقدار وضعیت و ارزش کیو انجام می شود، اما انتخاب نورون برای یادگیری بر اساس مقدار وضعیت و عمل است. روش دیگری که برای حل مسئله یادگیری تقویتی از نقشه خودسازمان ده استفاده کرده است، روش نقشه موتوری (Motoric Map) است [۳۱]. در این روش، یک نقشه خودسازمان ده در ورودی قرار می گیرد. هر نورون این نقشه شامل وزن عمل و مقدار کیو است. در نقشه موتوری تخمین مقدار کیو با استفاده از روش سارسا (sarsa) انجام می شود و عمل بهینه متناظر هر نورون با استفاده از روشی به نام یادگیری کواریانسی محاسبه می گردد.

مهترین کاری که در این زمینه صورت گرفته است، روش اسمیت است که از یادگیری کیو به عنوان تکنیک یادگیری تقویتی استفاده می کند و فضای ورودی و خروجی را به طور مجزا با استفاده از نقشه های خودسازمان ده استاندارد گسسته می کند [۲۵، ۲۴]. جدول کیو بر روی فضای ورودی و خروجی گسسته شده تشکیل می شود و مطابق با الگوریتم استاندارد یادگیری کیو (Q-Learning) بروز می شود. نقشه ورودی با ورودی هایی که از محیط می گیرد، به روز می شود. اما برای بروزرسانی نقشه خروجی داده مستقیمی وجود ندارد. اسمیت با مطرح کردن ایده نویزی کردن عمل اولیه (نورون برنده در فضای خروجی)، مشکل کاوش در فضای عمل را حل نموده است. نشان داده شده است که عملکرد این روش در کاربردهایی از رباتیک موفق بوده است [۲۵].

کاری که در این پژوهه صورت گرفته است، توسعه ای بر روشن اسمیت از دو نقشه خودسازمان ده استاندارد برای ارائه فضای ورودی و خروجی استفاده می کند. اما نقشه خودسازمان ده استاندارد از سویی نمی تواند تابع هدف متغیر را به خوبی ارائه کند و از سویی قادر نیست توابع هدفی که با تپیلوژی نقشه همخوانی ندارد را ارائه کند. در این پایان نامه، یادگیری تقویتی مبتنی بر نقشه خودسازمان ده تطبیقی برای حل مشکل تابع هدف متغیر ارائه شده است. تابع هدف متغیر در یادگیری تقویتی منحصر به داده های فضای ورودی نیست، بلکه داده های ورودی به نقشه خروجی همیشه توزیع چگالی متغیر با زمان دارد. باید توجه داشت در یادگیری تقویتی عامل با گذشت زمان عملکرد خود را بهبود می دهد، در نتیجه داده های ورودی به نقشه خروجی با گذشت زمان تغییر می کنند و توزیع چگالی آن نایستا است. روش یادگیری تقویتی با استفاده از نقشه خودسازمان ده رشدیابنده برای حل هر دو مشکل ذکر شده ارائه شده است. ترکیب یادگیری تقویتی با نقشه های خودسازمان ده رشدیابنده به سادگی امکان پذیر نیست و ترکیب این نوع نقشه با الگوریتم اسمیت که جدول کیو آن در طول زمان ثابت است، امکان پذیر نیست. در این پایان نامه الگوریتم جدیدی مبتنی بر نقشه های خودسازمان ده رشدیابنده ارائه شده است که جدول کیو آن در طول زمان بزرگ و کوچک می شود. نشان داده شده است این الگوریتم در حل مسائل مختلف از بقیه روش ها موفق تر بوده است.

نتایج حاصل از اعمال روش های پیشنهادی بر روی مسائل کلاسیکی از رباتیکز بررسی شده است. همه روش ها در مسائل ایستا عملکرد تقریباً مناسبی دارند. اما روش رشدیابنده نسبت به دیگر روش ها عملکرد بهتری دارد. از سویی میانگین پاداش دریافتی این روش بیشتر از دیگر روش ها است و از سوی دیگر روش نسبت به دیگر روش ها پایدارتر است. نقشه های ورودی و خروجی در روش رشدیابنده بهتر از روش های دیگر ارائه کننده توزیع ورودی هستند. در مسائل نایستا، یادگیری تقویتی با استفاده از نقشه خودسازمان ده استاندارد نسبت به دیگر روش ها عملکرد بدتری دارد. این روش پایداری کمی در برابر تغییرات محیط دارد. اما دو روش یادگیری تقویتی با نقشه خودسازمان ده تطبیقی و رشدیابنده نسبت به تغییرات محیط پایدارتر هستند و عملکرد قابل قبولی را ارائه می کنند.

مسئله کنترل چراغ راهنمای قلمرو ترافیک شهری کاربرد دیگری است که برای ارزیابی مدل های پیشنهادی استفاده شده است. مشکل ترافیک از مسائل پیچیده شهری است که به عوامل مختلفی همچون تردد بیش از حد خودرو از جاده ها، عدم کنترل صحیح چراغ های راهنمای، تصادفات، عدم پیروی رانندگان و عابران پیاده از قوانین راهنمایی و رانندگی، ورودی های خیابان های فرعی به اصلی، و دوربرگردن ها بستگی دارد. جهت انجام آزمایش ها یک شبیه ساز ترافیکی پیاده سازی شد که وضعیت های مختلف ترافیکی همانند ترافیک سبک و سنگین را ایجاد کند. استفاده از روش های پیشنهادی این پایان نامه در حل مسئله کنترل چراغ راهنمای نشان داد که از ترکیب چندین عامل یادگیری تقویتی می توان برای حل مسائل پیچیده استفاده نمود. در بین روش های بررسی شده، عملکرد مدل رشدیابنده در سه وضعیت ترافیکی سبک، متوسط، و سنگین از روش های دیگر بهتر است. لازم به ذکر است عملکرد مدل تطبیقی نیز در این مسئله قابل قبول است و کارایی و قابلیت اطمینان این روش در وضعیت های مختلف ترافیکی از روش اسمیت بهتر است.

این پایان نامه از هشت فصل تشکیل شده است. فصل دوم به معرفی روش یادگیری تقویتی می پردازد. در این فصل مسئله یادگیری تقویتی و روش های کلاسیک حل آن بررسی می شود. نقشه های خودسازمان ده و انواع آن در فصل سوم شرح داده می شوند. در این فصل نقشه های خودسازمان ده استاندارد، تطبیقی با زمان، و رشدیابنده ارائه می شوند. فصل چهارم پیشینه پژوهش در ترکیب یادگیری تقویتی با نقشه های خودسازمان ده را بررسی می کند. مدل های پیشنهادی ترکیب یادگیری تقویتی با نقشه خودسازمان ده تطبیقی و نقشه خودسازمان ده رشدیابنده در فصل پنجم مورد بررسی واقع می شوند. فصل های ششم و هفتم نتایج تجربی مدل ها را بررسی می کنند. فصل ششم دو کاربرد از رباتیکز که در کارهای قبلی مورد توجه قرار گرفته است را بررسی می کند. در فصل هفتم مسئله ترافیکی

معرفی و نتایج حاصل از مدل های پیشنهادی ارائه و مقایسه می شود. این پایان نامه در فصل هشتم با بیان نتیجه گیری و پیشنهادات به پایان می رسد.

## فصل دوم

### یادگیری تقویتی

در این فصل به معرفی و بیان روش یادگیری تقویتی می پردازیم. در ابتدای این فصل، مسئله یادگیری تقویتی<sup>۱</sup> را تعریف می کنیم. در ادامه، روش تفاضل زمانی<sup>۲</sup> معرفی می شود. روش تفاضل زمانی یکی از مهمترین روش های حل مسئله یادگیری تقویتی است که در قسمت دوم این فصل مورد بررسی قرار می گیرد.

#### ۱-۲ مسئله یادگیری تقویتی

در این قسمت به بیان مسئله یادگیری تقویتی می پردازیم. از آنجایی که همه روش های حل این مسئله از جمله روش های یادگیری تقویتی به شمار می روند، این مسئله تعریف کننده شاخه یادگیری تقویتی است. در این قسمت همچنین حالت ایدهآل ریاضی مسئله یادگیری تقویتی را بیان می کنیم. در انتهای این قسمت اشاره ای به روابط عناصر اصلی آن مانند توابع ارزش و معادلات بلمن می شود.

#### ۱-۱-۲ رابط<sup>۳</sup> عامل و محیط

مسئله یادگیری تقویتی، چارچوب مناسبی را برای یادگیری در حین تعامل (با محیط) و رسیدن به هدف ایجاد می کند. یادگیرنده یا تصمیم گیرنده را عامل گویند و آن چیزی که با آن تعامل می شود، شامل هر چیزی خارج از عامل، محیط نامیده می شود. این تعامل به طور پیوسته صورت می پذیرد و عامل عملی را انتخاب می کند و محیط پاسخ آن را می دهد و عامل را در وضعیت جدیدی قرار می دهد. محیط همچنین پاداش<sup>۴</sup> عمل های عامل را می دهد. پاداش مقدار عددی است که عامل باید آن را در طول زمان ماقزیم کند [۲۸].

عامل و محیط در بازه های زمانی گسسته ... , ۰, ۱ =  $t$  با یکدیگر تعامل می کنند و در هر بازه زمانی  $s_t$  عامل وضعیتی<sup>۵</sup> ( $s_t$ ,  $a_t$ ) را از محیط دریافت می کند که  $s_t \in S$  و  $a_t \in A(s_t)$  همه وضعیت های ممکن محیط است و بر مبنای آن عملی<sup>۶</sup> ( $a_t$ ) را انتخاب می کند که مجموعه عمل هایی است که در وضعیت  $s_t$  موجود می باشند. در بازه زمانی بعد، و در نتیجه عملش، عامل مقدار عددی  $R \in R$  را دریافت می کند و در وضعیت جدید  $s_{t+1}$  قرار می گیرد. در شکل ۱-۲ چگونگی تعامل عامل و محیط ترسیم شده است.

در هر بازه زمانی، عامل نگاشتی از وضعیت ها به احتمال انتخاب هر عمل ممکن را انجام می دهد. این نگاشت سیاست<sup>۷</sup> عامل نامیده و با  $\pi$  داده می شود که  $\pi(s, a)$  احتمال انتخاب عمل  $a$  در وضعیت  $s$  است و یا احتمال  $a_t = a$  در وضعیت  $s_t = s$  است. روش های یادگیری تقویتی چگونگی تغییر سیاست عامل در اثر کسب تجربه را بررسی می کنند.

<sup>1</sup> Reinforcement Learning Problem

<sup>2</sup> Temporal Difference

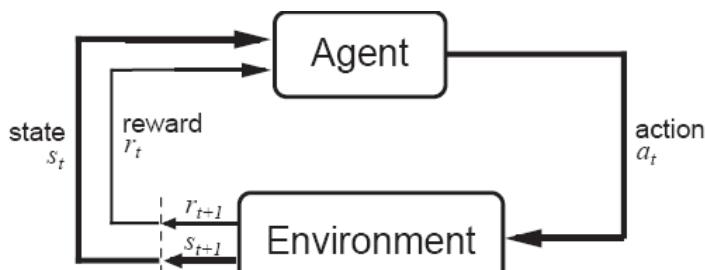
<sup>3</sup> Interface

<sup>4</sup> Reward

<sup>5</sup> state

<sup>6</sup> action

<sup>7</sup> policy



شکل ۱-۲ تعامل عامل و محیط در یادگیری تقویتی [۲۸]

این چارچوب کاملاً مجرد و انعطاف‌پذیر است و می‌تواند به مسائل مختلف و با روش‌های گوناگون اعمال شود. برای مثال، نیازی به ثابت بودن طول بازه‌های زمانی نیست و بازه‌ها می‌توانند مراحل متوالی و دلخواه تصمیم‌گیری و عمل کردن باشند. اعمال می‌توانند کنترل سطح پایین، مانند ولتاژ اعمالی به بازوی ربات، یا تصمیم‌گیری سطح بالا مانند صرف نهار یا رفتن به دانشگاه باشند. به طور مشابه، وضعیت‌ها می‌توانند اشکال گوناگونی داشته باشند. وضعیت‌ها می‌توانند با ورودی‌های سطح پایین، همچون دریافت‌های مستقیم حس‌گر<sup>۱</sup>، و یا سطح بالای مجرد مانند توصیف سمبولیک یک شیء در اتاق توصیف شوند. وضعیت‌ها می‌توانند بر مبنای حافظه‌ای از دریافت‌های گذشته و یا حتی کاملاً ذهنی باشند. برای مثال، عامل می‌تواند در وضعیتی باشد که مکان شیء خاصی را نداند. به همین ترتیب بعضی از عمل‌ها کاملاً ذهنی یا محاسباتی هستند. مثلًا بعضی از عمل‌ها کنترل می‌کنند که عامل درباره چه چیزی فکر کند. به طور کلی، عمل‌ها می‌توانند هر تصمیمی باشند که می‌خواهیم چگونگی اتخاذ آن را یاد بگیریم، و وضعیت‌ها هر چیزی که در اتخاذ چنین تصمیمی مفید هستند می‌باشند.

وضعیت‌ها و عمل‌ها از کاربردی تا کاربرد دیگر تغییر می‌کنند و چگونگی ارائه<sup>۲</sup> آن‌ها تاثیر زیادی در کارایی دارد. در یادگیری تقویتی همانند دیگر روش‌های یادگیری، انتخاب نوع ارائه بیش از آن که علم باشد، هنر است.

## ۱-۲ هدف‌ها و پاداش‌ها

در یادگیری تقویتی، هدف<sup>۳</sup> عامل براساس سیگنال پاداش که از محیط دریافت می‌کند فرموله شده است. در هر بازه زمانی، پاداش، عددی حقیقی ( $r_t \in R$ ) می‌باشد و هدف عامل ماکزیمم کردن مجموع پاداش‌ها در طول زمان است که به این معنی است که پاداش بلافاصله را ماکزیمم نمی‌کند، بلکه مجموع پاداش دریافتی در طول زمان<sup>۴</sup> را ماکزیمم می‌کند [۱۱].

استفاده از سیگنال تقویتی، ویژگی متمایز یادگیری تقویتی است. در ابتدا ممکن است این روش فرموله کردن، محدود کننده به نظر برسد، ولی در عمل اثبات شده است که کاملاً انعطاف‌پذیر و عملی است. برای اینکه چگونگی استفاده از سیگنال تقویتی کاملاً مشخص شود به مثال‌های زیر توجه شود. برای مثال، رباتی می‌خواهد فرار از ماز<sup>۵</sup> را یاد بگیرد. به این منظور، پاداش همیشه مقدار صفر دارد مگر اینکه عامل از ماز خارج شود که پاداش  $+1$  می‌گیرد. روش دیگر پاداش دهی مسئله ماز عبارت است از پاداش  $-1$  در هر بازه زمانی و پاداش صفر در صورت فرار از ماز. که این نحوه پاداش دهی باعث فرار ربات از ماز در کمترین زمان ممکن می‌شود. برای عاملی که

<sup>1</sup> sensor

<sup>2</sup> representation

<sup>3</sup> goal

<sup>4</sup> long run

<sup>5</sup> maze

می خواهد شطرنج یاد بگیرد. پاداش دهی معمول عبارت است از:  $1 + \text{برای بخت}, 1 - \text{برای برد}$ , و پاداش صفر در صورت تساوی و همهٔ حالت‌های غیر پایانی دیگر.

در مثال‌های بالا، عامل ماکریم کردن مقادیر پاداش را یاد می‌گیرد. اگر بخواهیم که عامل مسئله‌ای را حل کند باید پاداش دهی را به گونه‌ای تعریف کنیم که ماکریم شدن آن در طول زمان، باعث حل مسئله شود بنابراین تعیین نوع پاداش دهی مناسب برای حل مسئله کاملاً ضروری است. یکی از نکات دیگر پاداش دهی این است که سیگنال‌های تقویتی باید دانش ما را به عامل منتقل کنند و همچنین باید چگونگی رسیدن به هدف را مشخص نمایند، بلکه تنها باید هدف و آن چیزی را که عامل می‌خواهد به آن برسد را نشان دهند.

نکته دیگری که وجود دارد این است که محاسبهٔ پاداش در خارج از عامل و در محیط صورت می‌گیرد. به عبارت دیگر پاداش دهی خارج از کنترل عامل است و عامل باید قادر به تغییرات این سیگنال باشد. البته عامل می‌تواند پادash‌های داخلی برای خود تعریف کند (بسیاری از روش‌های یادگیری تقویتی از چنین پادash‌هایی استفاده می‌کنند).

## <sup>۱</sup> ۲-۳ بازگشت<sup>۱</sup>

گفته شد هدف عامل، ماکریم کردن مجموع پاداش دریافتی در طول زمان است، اما چگونه آن را به صورت فرمول نشان می‌دهیم؟ اگر دنبالهٔ پادash‌های دریافتی بعد از بازه زمان  $t$  را  $r_{t+1}, r_{t+2}, r_{t+3}, \dots$  تعریف کنیم، بطور کلی می‌خواهیم مقدار بازگشت مورد انتظار<sup>۲</sup> را ماکریم کنیم. بازگشت دارای تعاریف مختلفی است که در ساده‌ترین حالت عبارت است از:

$$R_t = r_{t+1} + r_{t+2} + r_{t+3} + \dots + r_T$$

که  $T$  بازه زمانی پایانی اپیزود است. این تعریف در کاربردهای عملی، بسیار مورد استفاده قرار می‌گیرد. زیرا عموماً ارتباط عامل و محیط به زیردنباله‌هایی از بازه‌ها تقسیم می‌شوند که اپیزود<sup>۳</sup> نام دارند. مثالی از آن انجام بازی فرار از ماز، و یا هر تعامل تکراری دیگر است. هر اپیزود در وضعیت خاصی که وضعیت پایانی نامیده می‌شود، پایان می‌باید و ابتدای اپیزود بعدی، در وضعیت شروع استانداردی قرار می‌گیرد. مسائل با ویژگی‌های فوق را مسائل اپیزودیک گویند. بعضی اوقات در مسائل اپیزودیک مجموعهٔ وضعیت‌های غیر پایانی را با  $S^0$  و مجموعهٔ وضعیت‌های غیر پایانی و پایانی را با  $S^+$  نشان می‌دهند. غیر از تعامل اپیزودیک، تعامل غیر اپیزودیک عامل و محیط نیز وجود دارد که در [۱۱، ۲۸] شرح داده شده است و ارتباط این دو حالت تعامل با محیط مورد بررسی قرار گرفته است.

نرخ کاهندگی<sup>۴</sup> مفهوم دیگری است که بایستی تعریف شود. اگر از نرخ کاهندگی در تعریف بازگشت استفاده شود، عامل عمل‌هایی را انتخاب می‌کند که مجموع پادash‌های کاهش یافته<sup>۵</sup> که در آینده دریافت می‌کند را ماکریم کند. در این حالت رابطهٔ بازگشت عامل به صورت زیر تعریف می‌شود:

$$R_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots = \sum_{k=0}^T \gamma^k r_{t+k+1}$$

<sup>1</sup> return

<sup>2</sup> expected return

<sup>3</sup> episode

<sup>4</sup> discounting

<sup>5</sup> discounted

که پارامتر  $\gamma$ ،  $(0 \leq \gamma \leq 1)$  نرخ کاهندگی است. نرخ کاهندگی، مقدار فعلی پاداش های آینده را مشخص می کند. پاداشی که در  $k$  بازه زمانی بعد دریافت می شود  $\gamma^{k-1}$  برابر پاداشی است که مستقیماً دریافت می شود.

## ۴-۲ خصوصیت مارکف

مناسب است که سیگنال وضعیتی، همه دریافت های گذشته را خلاصه کند و همه اطلاعات مربوط به آنها را نگهداری کند. به صورت عادی برای تحقق این مورد، نیاز به چیزی بیش از یک دریافت مستقیم است. البته این نیاز فراتر از کل دریافت های گذشته نمی شود. سیگنال وضعیتی که موفق در نگهداری همه اطلاعات گذشته می باشد، دارای خصوصیت مارکف است. برای مثال، مکان مهره های شطرنج دارای خصوصیت مارکف است. زیرا دنباله کل حرکاتی که به این وضعیت رسیده است را خلاصه می کند. اگرچه اکثر اطلاعاتی که منجر به این وضعیت شده است از دست رفته اند، ولی همه نکات مهم برای ادامه بازی نگهداری شده است. به این خصوصیت گاهی خصوصیت مستقل از مسیر<sup>۱</sup> هم گویند که به این معنا است که وضعیت فعلی، مستقل از مسیر و تاریخچه سیگنال های گذشته است.

با فرض تعداد محدود وضعیت و مقادیر پادشاهها، تعریف ریاضی خصوصیت مارکف را بیان می کنیم. توجه کنید که یک محیط بطور کلی در زمان  $t+1$  به عمل زمان  $t$  پاسخ می دهد و در کلی ترین حالت، این پاسخ ممکن است به همه پاسخ های گذشته ارتباط داشته باشد. در این حالت دینامیک محیط با توزیع احتمال کامل زیر مشخص می کنیم:

$$\Pr\{s_{t+1} = s', r_{t+1} = r | s_t, a_t, r_t, s_{t-1}, a_{t-1}, \dots, r_1, s_0, a_0\} \quad (1-2)$$

برای همه  $r, s$  ها و همه مقادیر ممکن رویدادهای گذشته:  $s_0, a_0, r_1, s_1, a_1, \dots, r_t, a_t, s_t$ . ولی در حالتی که سیگنال وضعیت، دارای خصوصیت مارکف باشد، پاسخ محیط در زمان  $t+1$  فقط بستگی به وضعیت و عمل در زمان  $t$  دارد که در این حالت دینامیک محیط فقط با رابطه زیر بیان می شود:

$$\Pr\{s_{t+1} = s', r_{t+1} = r | s_t, a_t\} \quad (2-2)$$

برای همه مقادیر  $a_t, r_t, s_t, a'_t, r'_t, s'_t$ . به عبارت دیگر می گوییم سیگنال وضعیت دارای خصوصیت مارکف است، در صورتی که دو رابطه ۱-۲ و ۲-۲ برای همه مقادیر  $r, s$  و گذشته های  $s_0, a_0, r_1, s_1, a_1, \dots, r_t, a_t, s_t$  معادل یکدیگر باشند. در این حالت اصطلاحاً گفته می شود که محیط دارای خصوصیت مارکف است. محیط هایی که دارای خصوصیت مارکف هستند باعث سادگی حل مسئله می شوند. حتی برای سیگنال وضعیتی که خصوصیت مارکف ندارد می توانیم فرض کنیم که سیگنال تقریبی از خصوصیت مارکف را دارد.

## ۵-۱ فرآیند تصمیم گیری مارکف

نمونه ای از مسئله یادگیری تقویتی که دارای خصوصیت مارکف است را فرآیند تصمیم گیری مارکف<sup>۲</sup> گویند. اگر فضای وضعیت ها و اعمال محدود باشند، آنگاه فرآیند تصمیم گیری مارکف متناهی<sup>۳</sup> است. فرآیند تصمیم گیری مارکف متناهی برای درک روش یادگیری تقویتی بسیار مهم می باشد. فرآیند تصمیم گیری مارکف متناهی توسط مجموعه وضعیت ها و اعمالش در دینامیک یک مرحله بعد محیط تعریف می شود. برای هر وضعیت و عمل داده شده  $r, s$ ، احتمال انتقال به وضعیت بعدی  $s'$  برابر است با:

$$P_{ss'}^a = \Pr\{s_{t+1} = s' | s_t = s, a_t = a\}$$

<sup>1</sup> independence of path

<sup>2</sup> Markov Decision Process (MDP)

<sup>3</sup> finite MDP

این مقادیر را احتمال های انتقال گویند. بطور مشابه برای هر وضعیت و عمل فعلی  $r, s$  و با وضعیت بعدی  $s'$ ، امید ریاضی مقدار حالت بعدی عبارت است:

$$R_{ss'}^a = E\{r_{t+1} | s_t = s, a_t = a, s_{t+1} = s'\}$$

این مقادیر  $R_{ss'}^a$  و  $P_{ss'}^a$ ، کاملاً ویژگی های مهم دینامیک فرآیند تصمیم گیری مارکف متناهی را بیان می کنند.

## ۱-۲ توابع ارزش

همه الگوریتم های یادگیری تقویتی، بر مبنای تخمین توابع ارزش<sup>۱</sup> هستند. توابع ارزش، توابعی از وضعیت ها (یا زوج های وضعیت عمل) هستند که خوب بودن عامل در وضعیتی خاص را تخمین می زنند (یا خوب بودن انجام عمل داده شده در وضعیتی خاص را تخمین می زنند). خوب بودن را با پاداش های دریافتی در آینده تعریف می کنیم. واضح است پاداش هایی که عامل، انتظار دریافت آن را در آینده دارد وابسته به عمل فعلی است. بنابراین، توابع ارزش با توجه به سیاست انتخابی تعریف می شوند.

همانگونه که ذکر شد  $\pi$  نگاشتی از وضعیت  $s \in S$  و عمل  $a \in A(s)$  به احتمال انتخاب عمل  $a$  در وضعیت  $s$  یا  $\pi(s, a)$  است. ارزش وضعیت  $s$  در سیاست  $\pi$ ،  $V^\pi(s)$ ، امید ریاضی بازگشت است در صورتی که حالت اولیه  $s$  باشد و سیاست  $\pi$  در ادامه اپیزود انتخاب شود. تابع ارزش وضعیت برای فرآیند تصمیم گیری مارکف به صورت زیر تعریف شده است:

$$V^\pi(s) = E_\pi\{R_t | s_t = s\} = E_\pi\left\{\sum_{k=0}^T \gamma^k r_{t+k+1} | s_t = s\right\}$$

که  $E_\pi\{\cdot\}$  نشان دهنده امید ریاضی بازگشت در صورت اتخاذ سیاست  $\pi$  است. توجه کنید که ارزش وضعیت های پایانی در صورت وجود، صفر می باشد.  $V^\pi$  را تابع ارزش وضعیت برای سیاست  $\pi$  می نامیم.

بطور مشابه،  $Q^\pi(s, a)$  ارزش انتخاب عمل  $a$  در وضعیت  $s$  در صورت اتخاذ سیاست  $\pi$  است. در واقع  $Q^\pi(s, a)$  امید ریاضی بازگشت است در صورتی که از وضعیت  $s$  شروع و عمل  $a$  را انتخاب کنیم و پس از آن سیاست  $\pi$  را پیش بگیریم.

$$Q^\pi(s, a) = E_\pi\{R_t | s_t = s, a_t = a\} = E_\pi\left\{\sum_{k=0}^T \gamma^k r_{t+k+1} | s_t = s, a_t = a\right\}$$

را تابع ارزش عمل برای سیاست  $\pi$  می نامیم.

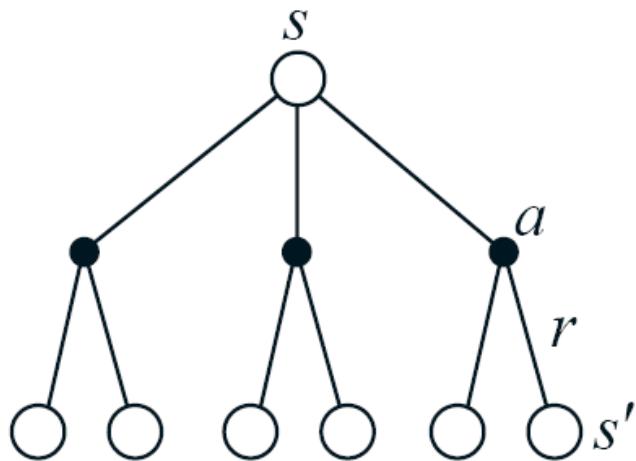
می توان تابع ارزش  $V^\pi$  و  $Q^\pi$  را با استفاده از تجربه، تخمین زد. برای مثال، فرض کنید عامل سیاست  $\pi$  را اتخاذ کرده باشد و برای هر وضعیتی که مواجه می شود میانگینی از بازگشت واقعی که پس از آن وضعیت دریافت می کند را نگه دارد. در صورت زیاد شدن تعداد دفعات مشاهده وضعیت، این میانگین به ارزش وضعیت  $(s) V^\pi$  همگرا خواهد شد. اگر میانگین های مجزایی برای هر زوج وضعیت عمل نگه داری شود، این میانگین ها به مقادیر عمل  $(s, a) Q^\pi$  همگرا خواهند شد. به این گونه روش های تخمین، روش های مونت کارلو [۲۸، ۱۱] گویند. البته، اگر تعداد وضعیت ها زیاد شود، آنگاه عملی نیست که برای هر وضعیت مستقل، میانگینی نگه داری شود. در مقابل  $V^\pi$  و  $Q^\pi$  را به صورت توابعی پارامتری بیان می کنیم و پارامترها را به گونه ای که بهتر با بازگشت های مشاهده شده منطبق باشند، تعیین می کنیم.

دارا بودن رابطه بازگشتی، یکی از خصوصیت اساسی توابع ارزش می باشد. برای هر سیاست  $\pi$  و هر وضعیت  $s$ ، رابطه زیر بین ارزش وضعیت  $s$  و ارزش وضعیت های ممکن بعدی آن وجود دارد:

<sup>1</sup> value function

$$\begin{aligned}
 V^\pi(s) &= E\{R_t | s_t = s\} = \\
 &= E_\pi\left\{\sum_{k=0}^T \gamma^k r_{t+k+1} | s_t = s\right\} \\
 &= E_\pi\{r_{t+1} + \gamma \sum_{k=0}^T \gamma^k r_{t+k+2} | s_t = s\} \\
 &= \sum_a \pi(s, a) \sum_{s'} P_{ss'}^a [R_{ss'}^a + \gamma E_\pi\left\{\sum_{k=0}^T \gamma^k r_{t+k+2} | s_{t+1} = s'\right\}] \\
 &= \sum_a \pi(s, a) \sum_{s'} P_{ss'}^a [R_{ss'}^a + \gamma V^\pi(s')] \tag{۳-۲}
 \end{aligned}$$

که  $(s, a) \in A(s)$  و  $s' \in S^+$  است. معادله (۳-۲) را معادله بلمن<sup>۱</sup> برای  $V^\pi$  گوییم که رابطه بین ارزش یک وضعیت و ارزش وضعیتهای بعدی آن را بیان می‌کند. تغییر از یک وضعیت به وضعیتهای ممکن بعدی در شکل ۲-۲ نشان داده شده است. در این شکل هر دایره سفید نمایانگر یک وضعیت و هر دایره سیاه نشان دهنده زوج وضعیت-عمل است. با شروع از وضعیت  $s$  گره ریشه در شکل ۲-۲، عامل می‌تواند مجموعه‌ای از عمل‌ها را انتخاب کند (سه عمل در شکل نشان داده شده است). با انتخاب هر کدام از عمل‌ها، محیط به یکی از وضعیتهای بعدی،  $s'$ ، می‌رود و پاداش  $r$  را به عامل می‌دهد. معادله بلمن (۳-۲) میانگین وزن‌دار همه حالات ممکن و احتمال وقوع را به صورت وزن دار بیان می‌کند. ارزش وضعیت اولیه برابر امید ریاضی (کاهش یافته) وضعیت بعدی، به اضافه امید ریاضی پاداش دریافتی تا زمان بعدی است. این نمودار را نمودار پشتیبان<sup>۲</sup> می‌گویند و برای شرح تصویری الگوریتم‌ها استفاده می‌شود.



شکل ۲-۲ نمودار پشتیبان برای  $V^\pi$

این نمودار را از آن جهت پشتیبان گویند که شامل عملیات پشتیبان یا به روز رسانی می‌باشد که هسته اصلی روش‌های یادگیری تقویتی است. عمل پشتیبان ارزش وضعیتهای بعدی را به وضعیت قبلی منتقل می‌کند.

<sup>1</sup> Bellman equation  
<sup>2</sup> backup