

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشگاه صنعتی شاهرود

دانشکده مهندسی کامپیوتر

رساله دکتری مهندسی هوش مصنوعی

تخمین مدل دمایی برخط برای پردازنده‌های چند هسته‌ای

نگارنده: جواد محبی نجم‌آباد

استاد راهنما

دکتر علی سلیمانی ایوری

استاد مشاور

دکتر علی اکبر پویان

تیر ۱۳۹۷

## تشکر و قدردانی

سپاس فراوندگار حکیم، را که با لطف بیکران خود، آدمی را زیور عقل آراست. فراوندا، آنچه در این مفتحمر آمده است، را تو به من دادی و تو را شاکرم که این لطف و عنایت را به من عطا فرمودی.

این رساله را ضمن تشکر و سپاس بیکران و در کمال افتخار و امتنان تقدیم می‌نمایم به:

روح پاک پدرم و زحمات و عشق مادرم

که عالمانه به من آموختند تا چگونه در عرصه زندگی، ایستادگی را تجربه نمایم و قدردان فرصت‌ها و نعمت‌هایی باشم که فدای بزرگ برای من مهیا کرده است.

فراوند را بسیار شاکرم که مرا با استادی وصف‌ناشدنی، هم از نظر افلاقی و منش انسانی و هم از نظر علمی، جناب آقای دکتر سلیمانی آشنا نمود. از زحمات ایشان، که با حسن خلق و فروتنی، از هیچ کمکی در این عرصه بر من دریغ ننمودند و زحمت راهنمایی این رساله را بر عهده گرفتند، صمیمانه تشکر و قدردانی می‌کنم. از زحمات آقای دکتر پویان که زحمت مشاوره این رساله را قبول کردند فالصانه تشکر می‌کنم. بسیاری از آموخته‌هایم را مدیون حضور و زحمات ایشان هستم.

از زحمات و حمایت‌های همسرم، که صبوری و همدلی‌هایش پشتوانه‌ی انجام این تحقیق بوده است، بسیار قدردانی می‌کنم. در انتها، از فواهر و برادران عزیزم که مرا در این راه طی‌شده یاری کرده و مشوق من بوده‌اند، صمیمانه تشکر می‌کنم.

فدایا پنان کن سرانجام کار، تو فشنود باشی و ما رستگار

## تعهد نامه

این جانب **جواد محبی نجم آباد** دانشجوی دوره دکتری رشته مهندسی کامپیوتر/هوش مصنوعی دانشکده مهندسی کامپیوتر و فناوری اطلاعات دانشگاه صنعتی شاهرود نویسنده‌ی پایان‌نامه **تخمین مدل دمایی برخط برای پردازنده‌های چندهسته‌ای**، تحت راهنمایی **آقای دکتر علی سلیمانی** متعهد می‌شوم:

- تحقیقات در این پایان‌نامه توسط این جانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش‌های محققان دیگر به مرجع مورداستفاده استناد شده است.
- مطالب مندرج در پایان‌نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده‌اند در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری، ضوابط و اصول اخلاق انسانی رعایت شده است.

- تاریخ:
- امضای دانشجو:

### مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه‌های رایانه‌ای، نرم افزارها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان‌نامه بدون ذکر مرجع مجاز نمی‌باشد.

## چکیده

برای افزایش توان محاسباتی، طراحان ریزپردازنده‌ها سیستم‌های چند هسته‌ای را بر روی یک تراشه ساخته‌اند. زیاد شدن تعداد هسته‌ها، سبب افزایش چگالی توان مصرفی و به دنبال آن منجر به افزایش دما می‌شود. برای بازدهی بیشتر و جلوگیری از سوختن پردازنده، دمای آن باید مدیریت و کنترل گردد. برای مدیریت دما، رویکردهای واکنشی و فعال معرفی شده‌اند. برخلاف رویکرد واکنشی، رویکردهای فعال پیش از رسیدن دما به حد آستانه، مدیریت دما را انجام می‌دهند. در این راستا، به مدلی برای پیش‌بینی دما نیاز دارند. عدم استفاده از مدلی با دقت بالا، می‌تواند سبب ایجاد نقاط داغ<sup>1</sup> در پردازنده و یا کاهش عملکرد پردازنده شود. با این وجود، اغلب مدل‌های ارائه شده، با توجه به اطلاعات فرد خبره و با استفاده از تعدادی پارامتر محدود، به پیش‌بینی دما پرداخته‌اند. به همین دلیل، دقت بالایی در پیش‌بینی رفتارهای مختلف دمایی پردازنده، توسط آن‌ها حاصل نمی‌شود.

هدف اصلی این رساله، ارائه رویکردی برای ایجاد یک مدل دمایی است، که بتواند پیش‌بینی با دقت بالایی را برای تغییرات متنوع دمای پردازنده فراهم آورد. در این راستا، امکان پیش‌بینی پاسخ کنترلی حاصل از تصمیم‌های مدیریت دما، از قابلیت‌های مدل دمایی در نظر گرفته شده است. به بیانی دیگر، یکی از چالش‌های اصلی برای یک مدل دمایی، توانایی پیش‌بینی دمای آینده پردازنده، پیش از استفاده از روش‌های کنترل دما است. از دیگر چالش‌ها، ایجاد و انتخاب ویژگی‌های مناسب برای مدل دمایی است. بدون بهره‌گیری از ویژگی‌های مناسب، نمی‌توان دقت بالایی در پیش‌بینی دما ارائه کرد. در نهایت، رویارویی با حالت‌های بسیار متنوعی از تغییرات دما، از دیگر چالش‌هایی است که در این رساله به آن پرداخته شده است. از آنجایی که امکان یادگیری همه‌ی حالت‌ها به صورت برون خط، عملی نیست، امکان یادگیری آن‌ها در زمان اجرا، از توانایی‌های بااهمیت یک مدل دمایی است.

در راه‌کار پیشنهادی در این رساله، از شبکه‌ی پرسپترون چندلایه‌ای<sup>2</sup> (MLP) برای ایجاد مدل پیش‌بینی دما استفاده شده است. در این راستا، ابتدا، با الگوریتم پیشنهادی، به ایجاد یک مجموعه داده‌ی مناسب پرداخته، که شامل تنوع بالایی از تغییرات دمایی پردازنده است. تعدادی از ویژگی‌های مجموعه، با خواندن حسگرهای دمایی و دیگر ابزارهای اندازه‌گیری فراهم می‌شوند. همچنین، با پیش‌پردازش‌های پیشنهادی، تعدادی ویژگی با نام‌های سابقه‌ای و کنترلی، تولید شده‌اند. ویژگی‌های سابقه‌ای به منظور نگهداری آخرین تغییرات پارامترهای دمایی و ویژگی‌های کنترلی برای افزودن امکان پیش‌بینی پاسخ کنترلی، ایجاد می‌شوند. به دلیل تعداد بالای مجموعه ویژگی‌ها، برخی از آن‌ها، با استفاده از دو روش پیشنهادی با نام‌های مربع اختلاف همبستگی و توسعه یافته‌ی آن، به عنوان ورودی‌های مدل دمایی

<sup>1</sup> Hot spots

<sup>2</sup> Multi-Layer Perceptron

انتخاب می‌شوند. از طرفی، برای افزایش دقت پیش‌بینی برای حالت‌هایی که مدل با آن‌ها به‌صورت برون‌خط آموزش نیافته است، یک مدل دمایی برخط پیشنهاد شده است. مدل دمایی، در زمان اجرا برای حالت‌هایی که دقت مدل پایین است به‌روزرسانی می‌شود. مدل دمایی برخط پیشنهادی، مبتنی بر چند فاز دمایی است که برای هر فاز یک شبکه‌ی MLP برای پیش‌بینی دما استفاده می‌گردد. فازهای مختلف دمایی با توجه به پارامترهای مؤثر بر دمای پردازنده و با استفاده از شبکه‌ی نظریه تشدید انطباقی<sup>۱</sup> (ART) شناسایی شده‌اند. ویژگی‌های مناسب برای هر فاز دمایی با الگوریتم پیشنهادی انتخاب می‌شوند. مدل پیشنهادی قادر است در زمان اجرا، در صورت برخورد با فاز دمایی جدید، آن را به مجموعه‌ی فازها اضافه کرده و شبکه عصبی مناسب برای آن را ایجاد کند. درنهایت، با استفاده از مدل دمایی پیشنهادی و یک مدل کنترلی، دمای پردازنده با تعیین فرکانس پردازنده و سرعت فن مدیریت می‌گردد.

نتایج حاصل از ارزیابی‌های متنوعی که در این رساله انجام شده است، نشان از دقت بالای مدل‌های پیشنهادی در مقایسه با دیگر مدل‌های ارائه‌شده تاکنون دارد. دقت مدل دمایی برای پیش‌بینی دمای ۲ تا ۵ ثانیه‌ی آینده محاسبه شده است. در ارزیابی برون‌خط، میانگین قدر مطلق خطای مدل دمایی پیشنهادی، برای فاصله‌های ۲ و ۵ ثانیه‌ی آینده کم‌تر از ۰/۵ و ۰/۷ درجه سانتی‌گراد محاسبه شده است. همچنین، در ارزیابی مدل برخط، خطای کمتر از ۱ درجه سانتی‌گراد برای فاصله‌های مختلف زمانی به‌دست آمده است. درنهایت، مدل کنترل دما مورد ارزیابی و مقایسه با دیگر روش‌های ارائه‌شده قرار گرفته است. خطای مدل کنترل دما، در تعیین مقدار فرکانس پردازنده و سرعت فن، به ترتیب ۲ و ۰/۶ درصد حاصل شده است.

**کلمات کلیدی:** پردازنده‌های چند هسته‌ای، مدیریت دمای پویا، مدل پیش‌بینی دما، خوشه‌بندی، انتخاب ویژگی.

---

<sup>۱</sup> Adaptive Resonance Theory

## مقالات مستخرج از رساله

### • مقالات کنفرانسی

1- Abad, J. M. N., Salami, B., Noori, H., Soleimani, A., & Mehdipour, F., "A neuro-fuzzy fan speed controller for dynamic thermal management of multi-core processors", In *Proceedings of the 11th ACM Conference on Computing Frontiers*, p. 29, May 2014, ACM.

2- Abad, J. M. N., & Soleimani, A., "A neuro-fuzzy fan speed controller for dynamic management of processor fan power consumption", In *Swarm Intelligence and Evolutionary Computation (CSIEC)*, pp. 148-153, March 2016, IEEE.

۳- جواد محبی نجم‌آباد و علی سلیمانی، "پیش‌بینی دما در سیستم‌های چندهسته‌ای با استفاده از خوشه‌بندی عامل‌های مؤثر بر دما"، چهارمین کنفرانس ملی فناوری اطلاعات، کامپیوتر و مخابرات، ۲۳ تیر ۱۳۹۶.

### • مقالات ژورنالی

۴- جواد محبی نجم‌آباد و علی سلیمانی، "پیش‌بینی دما در پردازنده‌های چندهسته‌ای با استفاده از رگرسیون بردار پشتیبان"، مجله هوش محاسباتی در مهندسی برق. بهار ۱۳۹۷.

۵- جواد محبی نجم‌آباد و علی سلیمانی، "مدیریت دمای پویا برای سیستم‌های چندهسته‌ای با کنترل فرکانس پردازنده و سرعت فن"، مجله مهندسی برق دانشگاه تبریز. بهار ۱۳۹۷.

۶- جواد محبی نجم‌آباد، علی سلیمانی و علی پویان، "پیش‌بینی برخط دما در فازهای مختلف دمایی برای سیستم‌های چندهسته‌ای"، مجله مهندسی برق دانشگاه تبریز. تابستان ۱۳۹۷.

7- Abad, J. M. N., & Soleimani, A., "Novel Feature Selection Algorithm for Thermal Prediction Model", *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 2018.

## فهرست مطالب

۱- مقدمه	۱
۱-۱- تعریف مسئله	۶
۲-۱- چالش‌ها	۷
۳-۱- ویژگی‌های یک مدل دمایی	۸
۴-۱- نوآوری‌های رساله	۹
۵-۱- ساختار رساله	۱۱
۶-۱- جمع‌بندی	۱۲
۲- مروری بر مدل‌های پیش‌بینی دما در پردازنده‌های چند هسته‌ای	۱۳
۱-۲- پردازنده‌های چند هسته‌ای	۱۴
۲-۲- روش‌های دریافت اطلاعات دمایی تراشه	۱۷
۳-۲- رویکردهای مدیریت دما	۱۸
۴-۲- مدل‌های پیش‌بینی دما	۲۵
۱-۴-۲- روش‌های مبتنی بر اندازه‌گیری دما	۲۶
۲-۴-۲- روش‌های مبتنی بر اثر بارکاری	۲۹
۳-۴-۲- روش‌های مبتنی بر یادگیری ماشین	۳۱
۵-۲- جمع‌بندی	۳۴
۳- مدل پیشنهادی برون‌خط برای پیش‌بینی دما	۳۷
۱-۳- ایجاد مجموعه داده	۳۹
۲-۳- آماده‌سازی مجموعه داده	۴۷
۳-۳- ساختار مدل	۵۰
۴-۳- ارزیابی مدل	۵۱
۵-۳- الگوریتم پیشنهادی برای انتخاب ویژگی برای مدل دمایی	۵۸
۶-۳- جمع‌بندی	۶۳
۴- مدل پیشنهادی برخط برای پیش‌بینی دما	۶۵
۱-۴- توسعه ساختار اولیه مدل دمایی به صورت برون‌خط	۶۶
۱-۱-۴- خوشه‌بندی رفتارهای دمایی پردازنده	۷۰
۲-۱-۴- توسعه‌ی شبکه‌ی عصبی برای پیش‌بینی دما در هر خوشه	۷۲
۲-۴- بهره‌گیری و آموزش مدل دمایی در زمان اجرا	۷۴



۷۶	۳-۴- جمع بندی
۷۷	۵- مدل پیشنهادی برای کنترل دما
۷۸	۵-۱- جریان کلی رویکرد مدیریت دمای پیشنهادی
۷۹	۵-۲- مدل پیش‌بینی دما
۸۱	۵-۳- مدل کنترل دمای پیشنهادی
۸۲	۵-۳-۱- انتخاب ویژگی‌های مدل کنترل دما
۸۳	۵-۳-۲- توسعه و ارزیابی مدل کنترل دما
۸۵	۵-۴- جمع بندی
۸۷	۶- ارزیابی و نتایج آزمایش‌ها
۸۹	۶-۱- ارزیابی مدل دمایی برون خط برای پیش‌بینی دما
۸۹	۶-۱-۱- انتخاب ساختار شبکه‌ی MLP
۹۰	۶-۱-۲- ارزیابی الگوریتم‌های انتخاب ویژگی پیشنهادی بر روی مدل‌های دمایی مختلف
۹۳	۶-۱-۳- انتخاب مدل رگرسیون مناسب برای پیش‌بینی دما
۹۴	۶-۱-۴- مقایسه روش انتخاب ویژگی ESCD با روش‌های پیشین
۹۶	۶-۱-۵- مقایسه مدل دمایی پیشنهادی با مدل‌های پیشین
۹۸	۶-۲- ارزیابی مدل دمایی برخط برای پیش‌بینی دما
۹۸	۶-۲-۱- انتخاب ویژگی‌های مناسب برای خوشه‌بندی رفتارهای دمایی
۱۰۰	۶-۲-۲- ارزیابی اثر استفاده از مدل خطی برای هر فاز از مدل دمایی
۱۰۱	۶-۲-۳- ارزیابی مدل دمایی برخط پیشنهادی برای فاصله‌های مختلف زمانی
۱۰۳	۶-۲-۴- مقایسه مدل پیشنهادی با رویکردهای مشابه
۱۰۴	۶-۲-۵- ارزیابی اثر استفاده از خوشه‌بندی در دقت مدل دمایی
۱۰۵	۶-۳- ارزیابی رویکرد پیشنهادی برای مدیریت دما
۱۰۵	۶-۳-۱- انتخاب ویژگی‌های مدل پیش‌بینی دما
۱۰۷	۶-۳-۲- مقایسه مدل دمایی پیشنهادی با رویکردهای مشابه
۱۰۸	۶-۳-۳- ارزیابی مدل کنترل دمای پیشنهادی
۱۰۹	۶-۳-۴- مقایسه مدل کنترل دمای پیشنهادی با رویکردهای مشابه
۱۱۵	۷- جمع‌بندی و کارهای آینده
۱۲۰	مراجع

## فهرست تصاویر

- شکل ۱-۲: تراشه‌ی CPU چند هسته‌ای [24] ..... ۱۵
- شکل ۲-۲: ورودی‌ها و خروجی شبیه‌ساز HotSpot برای پیش‌بینی دما ..... ۱۸
- شکل ۱-۳: نمودار جریان جمع‌آوری داده از سیستم ..... ۴۴
- شکل ۲-۳: ساختار شبکه MLP برای پیش‌بینی دما ..... ۵۱
- شکل ۳-۳: مقایسه استفاده از روش‌های MID و FCD برای انتخاب ویژگی ..... ۵۸
- شکل ۴-۳: مقایسه استفاده از روش‌های CD و FCD برای انتخاب ویژگی‌های مدل دمایی ..... ۵۹
- شکل ۵-۳: مقایسه استفاده از SCD با CD و FCD برای انتخاب ویژگی‌های مدل دمایی ..... ۶۰
- شکل ۶-۳: محاسبه‌ی خطای مدل دمایی با افزایش تعداد ویژگی‌های انتخابی با الگوریتم ESCD ..... ۶۲
- شکل ۷-۳: مقایسه استفاده از ESCD با SCD برای انتخاب ویژگی‌های مدل پیش‌بینی دما ..... ۶۳
- شکل ۱-۴: روند ایجاد مدل پیش‌بینی دما شامل فازهای مختلف دمایی و شبکه مناسب برای پیش-بینی در هر فاز ..... ۶۷
- شکل ۲-۴: تغییرات دمایی یک هسته، در پردازنده‌ی چند هسته‌ای ..... ۶۹
- شکل ۳-۴: خطای مدل پیش‌بینی دمایی ۵ ثانیه آینده با افزایش تعداد ویژگی‌ها ..... ۷۱
- شکل ۴-۴: خطای مدل پیش‌بینی با افزایش تعداد فازها ..... ۷۱
- شکل ۵-۴: ساختار اولیه‌ی شبکه ART [43] ..... ۷۲
- شکل ۶-۴: افزایش تعداد ویژگی‌ها در خطای مدل‌های دمایی فازهای مختلف دما برای پیش‌بینی دمایی ۵ ثانیه آینده ..... ۷۳
- شکل ۷-۴: روند آموزش مدل پیش‌بینی دما در زمان اجرا ..... ۷۴
- شکل ۱-۵: جزئیات مختصری از رویکرد مدیریت دمایی پیشنهادی ..... ۷۸
- شکل ۲-۵: افزایش تعداد ویژگی‌های انتخابی با استفاده از روش SCD در دقت مدل پیش‌بینی دمایی ۲ ثانیه آینده ..... ۸۱
- شکل ۳-۵: نتیجه استفاده از الگوریتم NSGA-II برای انتخاب ویژگی‌های مدل کنترل دما ..... ۸۴
- شکل ۴-۵: اثر مدل کنترل دمایی پیشنهادی بر دمایی پردازنده ..... ۸۵
- شکل ۱-۶: نتیجه افزایش تعداد نرون‌ها در دقت مدل پیش‌بینی دمایی ۵ ثانیه آینده ..... ۹۰
- شکل ۲-۶: مقایسه بین روش‌های FCD، CD، SCD و ESCD در انتخاب ویژگی‌ها برای پیش‌بینی دمایی ۵، ۴، ۳ و ۲ ثانیه آینده به ترتیب در نمودارهای الف، ب، ج، د ..... ۹۱
- شکل ۳-۶: مقایسه استفاده از چهار مدل برای پیش‌بینی دمایی ۵ ثانیه آینده ..... ۹۳
- شکل ۴-۶: مقایسه استفاده از چهار روش انتخاب ویژگی برای مدل پیش‌بینی دمایی ۵ ثانیه آینده ..... ۹۵
- شکل ۵-۶: خطای مدل پیش‌بینی دما برای فاصله‌های مختلف زمانی ..... ۹۹
- شکل ۶-۶: دقت مدل پیش‌بینی دما با افزایش تعداد ویژگی‌ها برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده ..... ۱۰۶

- شکل ۶-۷: مقایسه‌ی دقت مدل‌های مختلف با ویژگی‌های یکسان برای پیش‌بینی دما برای فاصله زمانی ۲ ثانیه آینده..... ۱۰۸
- شکل ۶-۸: مقایسه‌ی سه روش کنترل دما برای حفظ دما حول و حوش دمای حدآستانه..... ۱۱۱
- شکل ۶-۹: نمایش جزئیات بیشتری از سه روش کنترل دمای مورد مقایسه..... ۱۱۲
- شکل ۶-۱۰: تغییرهای سرعت فن و فرکانس در روش کنترل دمای پیشنهادی و روش لی..... ۱۱۳

## فهرست جداول

- جدول ۳-۱: لیست ویژگی‌های خوانده شده از سیستم..... ۴۲
- جدول ۳-۲: اثر استفاده از ویژگی‌های سابقه‌ای و کنترلی در پیش‌بینی دمای ۵ ثانیه آینده ..... ۵۳
- جدول ۳-۳: مقدار همبستگی ویژگی‌های مدل دمایی با دمای ۲ ثانیه‌ی آینده ..... ۵۴
- جدول ۳-۴: ادامه‌ی نمایش مقدار همبستگی ویژگی‌های مدل دمایی با دمای ۲ ثانیه‌ی آینده ..... ۵۵
- جدول ۵-۱: پیش‌بینی دمای ۲ ثانیه آینده با پارامترهای مختلف ..... ۸۰
- جدول ۵-۲: تخمین مقدار فرکانس پردازنده و سرعت فن برای کنترل دما تا ۲ ثانیه آینده ..... ۸۴
- جدول ۶-۱: مقایسه انتخاب ویژگی‌ها با استفاده از روش‌های مختلف برای پیش‌بینی دمای ۵ ثانیه آینده ..... ۹۱
- جدول ۶-۲: ویژگی‌های مشترک بین مدل‌های دمایی برای فاصله‌های مختلف زمانی ..... ۹۲
- جدول ۶-۳: مقایسه تعدادی از مدل‌های رگرسیون برای پیش‌بینی دمای ۵ ثانیه آینده ..... ۹۴
- جدول ۶-۴: دقت مدل‌های دمایی مختلف برای پیش‌بینی دما برای فاصله‌های زمانی مختلف ..... ۹۷
- جدول ۶-۵: اثر استفاده از ویژگی‌های انتخابی در خوشه‌بندی فازهای دمایی برای فاصله‌های مختلف زمانی ..... ۱۰۰
- جدول ۶-۶: دقت مدل دمایی پیشنهادی بر پایه‌ی استفاده از LMS برای پیش‌بینی در هر فاز دمایی ..... ۱۰۱
- جدول ۶-۷: دقت مدل پیش‌بینی دمای برخط برای فاصله‌های مختلف زمانی ..... ۱۰۲
- جدول ۶-۸: دقت مدل پیش‌بینی دمای برون خط برای فاصله‌های مختلف زمانی ..... ۱۰۲
- جدول ۶-۹: دقت مدل‌های پیش‌بینی دمای ARMA و ژنگ، برای فاصله‌های مختلف زمانی ..... ۱۰۴
- جدول ۶-۱۰: دقت مدل پیش‌بینی دمای برخط بدون بهره‌گیری از خوشه‌بندی رفتارهای دمایی برای فاصله‌های مختلف زمانی ..... ۱۰۵
- جدول ۶-۱۱: دقت مدل‌های پیش‌بینی دما برای فاصله‌های مختلف زمانی ..... ۱۰۷
- جدول ۶-۱۲: دقت مدل کچران برای پیش‌بینی دما برای فاصله‌های مختلف زمانی ..... ۱۰۸
- جدول ۶-۱۳: تخمین فرکانس و سرعت فن برای فاصله‌های زمانی مختلف ..... ۱۰۹

## فهرست اختصارات

### A

ANFIS Adaptive Neuro-Fuzzy Inference System

ARMA .....Autoregressive-Moving-Average

ART .....Adaptive Resonance Theory

### C

CD .....Correlation Difference

CFS .....Correlation Feature Selection

### D

DTM ....Dynamic Thermal Management

DVFS. Dynamic Voltage and Frequency Scaling

### E

ESCD..... Extended SCD

### G

GPU .....Graphic Processing Unit

### L

LMS..... Least Mean Square

### M

MAE ..... Mean Absolute Error

MMU ..... Memory Management Unit

MI ..... Mutual Information

MID ..... Mutual Information Difference

MLP..... Multi-Layer Perceptron

MPC..... Model Predictive Control

MRMR..... Minimum Redundancy Maximum Relevance

### N

NOP ..... No operation

NSGA-II ..... Non-dominated Sorting Genetic Algorithm-II

### P

PCA ..... Principle Component Analysis

POE ..... Percentage of Outlier Errors

PWM .....Pulse Width Modulation

### R

RC..... Resistance-Capacitance

RPM.....Revolutions Per Minute

### S

SCD ... Square of Correlation Difference

SDAE.....Standard Deviation Absolute Error

SPRT .Sequential Probability Ratio Test

SVR .....Support Vector Regression

### T

TLB ..... Translation Lookaside Buffer



# فصل

## ۱- مقدمه

با توجه به نیاز روزافزون به انجام محاسبات با پردازش‌های بالا، تولید پردازنده‌ها با توان محاسباتی بالا از مهم‌ترین مسائل در تولید سیستم‌ها است. در ابتدا، افزایش فرکانس اعمالی به پردازنده، رویکرد مورد استفاده برای افزایش توان محاسباتی پردازنده‌ها بود. این امر، افزایش گرمای تولیدی در پردازنده‌ها را به صورت نمایی به دنبال داشت. این موضوع همراه با محدودیت مربوط به حداکثر میزان فرکانس اعمالی، موجب ظهور پردازنده‌های چند هسته‌ای شد. از رویکردهای اصلی در افزایش توان محاسباتی پردازنده، افزودن تعداد هسته‌های آن‌ها در یک سطح محدود است. برای ایجاد این نوع پردازنده‌ها، اندازه‌ی ترانزیستورها به طور متوالی کم‌حجم‌تر شده، تا تعداد بیشتری ترانزیستور در یک تراشه<sup>1</sup> مجتمع شوند. افزایش تعداد هسته‌ها در یک ناحیه‌ی محدود، منجر به افزایش چگالی توان مصرفی و به موجب آن افزایش دمای پردازنده می‌شود. از طرفی، افزایش دما منجر به افزایش توان مصرفی پردازنده می‌گردد. این چرخه‌ی ایجادشده، به سرعت دمای پردازنده را زیاد می‌کند. شایان ذکر است که افزایش توان مصرفی باعث افزایش جریان و توان نشتی<sup>2</sup> شده و در اثر افزایش توان نشتی، دما افزایش پیدا می‌کند. از طرفی، افزایش دما نیز باعث افزایش توان نشتی و توان مصرفی می‌شود. از این رو، توان نشتی و دما یک رابطه دوطرفه داشته که باعث افزایش دما در مدت کوتاهی می‌گردد.

افزایش دمای سیستم بر روی جنبه‌های مختلفی از سیستم، از جمله هزینه پیاده‌سازی، قابلیت اطمینان، هزینه‌های خنک کردن، کاهش کارایی و طول عمر سیستم تأثیرگذار است [1]. به همین سبب، از رویکردهای مختلفی به منظور کاهش دما استفاده می‌شود. یکی از راه‌های کاهش دمای تراشه، استفاده از روش‌های مکانیکی است. در این راستا، بیشتر پردازنده‌های چند هسته‌ای از یک فن خنک‌کننده به همراه یک حرارت‌گیر<sup>3</sup>، برای کاهش دمای پردازنده استفاده می‌کنند. به صورت معمول، سرعت فن با توجه به مقدار دریافتی از حسگرهای دمایی روی پردازنده، تعیین می‌شود. به کارگیری تجهیزات سخت-افزاری خنک‌کننده دارای معایبی مانند ایجاد نویز، مصرف انرژی و ایستا بودن تنظیم خنک‌کننده است.

<sup>1</sup> Chip

<sup>3</sup> Heat sink

<sup>2</sup> Leakage power



همچنین، در بیشتر مواقع، میزان فعالیت فن به اندازه‌ای نیست که بتواند به سرعت باعث کاهش دمای پردازنده گردد. به همین سبب، نیاز به استفاده از روش‌های پیچیده‌تر مدیریت دما، برای جلوگیری از افزایش بیش از حد دمای پردازنده است. در این راستا، از روش‌های متنوعی در جهت مدیریت دما بهره گرفته شده است.

برخی از روش‌های مدیریت دما با نام مدیریت دمای ایستا، از روش‌های طراحی آگاه از دما<sup>1</sup> بهره می‌برند. در این راستا، با توجه به نقشه‌ی گیتی پردازنده، تخصیص وظایف به هسته‌های پردازنده، به گونه‌ای انجام شده که دمای هسته‌ها از حد آستانه افزایش پیدا نکند [2]. گروهی دیگر از روش‌های مدیریت دما، با عنوان مدیریت دمای پویا<sup>2</sup> (DTM) معرفی شده‌اند. به صورت کلی DTM شامل دو رویکرد واکنشی<sup>3</sup> و فعال<sup>4</sup> است [3]. در رویکرد واکنشی، هنگامی که یک رخداد خاص، مانند افزایش دما از حد آستانه‌ی پردازنده، اتفاق می‌افتد، از ابزارهای مختلفی برای کاهش دما بهره می‌برند. متداول‌ترین ابزارهای مورد استفاده در DTM برای کنترل دما، تنظیم ولتاژ فرکانس پویا<sup>5</sup> (DVFS) و مهاجرت وظیفه<sup>6</sup> است. در رویکرد واکنشی، از آنجایی که، بعد از رخداد یک رویداد نامطلوب، عملی در جهت رویارویی با آن انتخاب می‌گردد، بهره‌وری کاهش می‌یابد. به بیانی دیگر، روش‌هایی که نیاز است سریع‌تر منجر به کاهش دما شوند، باعث کاهش بیشتر عملکرد سیستم نیز می‌گردند [3]. در مقایسه با رویکرد مذکور، روش‌های فعال DTM، پیش از رسیدن دمای پردازنده به مقدار نامطلوب، از آن جلوگیری می‌کنند. از آنجایی که پیش‌بینی دما پیش از رسیدن به دمای حد آستانه انجام می‌شود، امکان استفاده از روش‌هایی وجود دارد که عملکرد سیستم را کمتر کاهش دهند. اغلب، در یک رویکرد فعال، با استفاده از یک مدل دمایی، دمای آینده‌ی پردازنده پیش‌بینی می‌گردد. از این جهت شاید بتوان، پیش‌بینی دقیق دما برای فاصله‌های زمانی مطلوب را، به عنوان قلب رویکردهای فعال DTM معرفی کرد.

<sup>1</sup> Thermal aware design techniques

<sup>2</sup> Dynamic Thermal Management

<sup>3</sup> Reactive

<sup>4</sup> Proactive

<sup>5</sup> Dynamic Voltage and Frequency Scaling

<sup>6</sup> Task migration

تعدادی از مدل‌های دمایی، با استفاده از روش‌های ریاضی مانند روش‌های درون‌یابی، بر روی مجموعه-داده‌ای از رکوردهای فعالیت، ایجاد شده‌اند [4] [5] [6] [7] [8] [9] [10]. اغلب، این رکوردهای فعالیت شامل دما، توان مصرفی و دیگر اطلاعات وضعیت پردازنده می‌باشند. این اطلاعات در زمان اجرای بارهای کاری<sup>1</sup>، با نظارت حسگرهای پردازنده و شمارنده‌های کارایی، جمع‌آوری می‌شوند [11] [12]. اغلب، این مدل‌ها خطی بوده و دقت بالایی برای رفتارهای مختلف دمایی پردازنده ارائه نمی‌کنند.

تعدادی از مدل‌های دمایی، با توجه به رفتارهای دمایی پردازنده، از تعدادی رابطه برای پیش‌بینی دما استفاده می‌کنند [3] [5] [13]. در این راستا، برای هر نوع تغییر دمای پردازنده، از یک رابطه‌ی مجزا بهره می‌برند. استفاده از تعدادی رابطه، این امکان را به مدل دمایی می‌دهد که بتواند رفتارهای دمایی متفاوت پردازنده را با رابطه‌های سبک‌وزن، با دقت قابل قبولی پیش‌بینی کند. البته، در این رویکرد، تعداد مدل‌های موردنیاز، برای پوشش همه‌ی تغییرات دما، می‌تواند افزایش قابل توجهی پیدا کند.

برای این که مدل دمایی بتواند توانایی پیش‌بینی تغییرات متفاوت دمای پردازنده را داشته باشد از مدل‌های غیرخطی بهره برده‌اند. بدین منظور، برای ایجاد مدل‌های دمایی، از روش‌های هوش مصنوعی و روش‌های یادگیری ماشین استفاده کرده‌اند. در این راستا، در برخی از روش‌ها، از شبکه‌های عصبی برای پیش‌بینی دما استفاده شده است [14] [15] [16] [17] [18].

مدل‌های دمایی با توجه به زمان ایجاد و آموزش، به دو دسته‌ی مدل‌های برخط و برون خط تقسیم‌بندی می‌شوند. مدل‌های برون خط، پیش از اجرای مدل، با توجه به اطلاعات موجود از پردازنده و مجموعه-داده‌ای که شامل رفتارهای دمایی متفاوت پردازنده است، فراهم می‌شوند. اغلب، در ارزیابی این مدل‌ها از یک مجموعه‌داده‌ی مشترک برای آموزش و آزمایش مدل بهره می‌گیرند. البته، بخشی از مجموعه‌داده برای آموزش و بخش دیگر برای آزمایش استفاده می‌شود. از طرفی، در ارزیابی برخی از مدل‌های برون-خط، نتایج حاصل از آزمایش مدل بر روی یک سیستم در حال اجرا ارائه شده است. برخلاف مدل‌های

---

<sup>1</sup> Work load

برون خط، مدل‌های برخط در زمان اجرا، آموزش داده می‌شوند. اغلب، حالت اولیه‌ای از این مدل‌ها به صورت برون خط تهیه شده و سپس آموزش و آزمایش آن‌ها در زمان اجرای سیستم انجام می‌شود. این مدل‌ها، توانایی یادگیری رفتارهای دمایی جدید از پردازنده را، در زمان اجرای مدل دارند.

ایجاد روابط برای برخی از مدل‌های دمایی، به صورت برون خط و با توجه به مجموعه داده‌ی جمع‌آوری شده صورت می‌گیرد [3]. از طرفی، مدل‌های پیش‌بینی دما باید توانایی خوبی در پیش‌بینی حالت‌هایی که با آن‌ها آموزش داده نشده‌اند، داشته باشند. دلیل این ویژگی این است که فراهم کردن مجموعه داده‌ای شامل همه حالت‌های یک سیستم، غیرممکن است. هرچند، مجموعه داده‌ی آموزش، باید شامل حالت‌های گوناگونی باشد که به صورت معمول در سیستم حادث می‌شوند. با این وجود، مدل‌های برون خط در زمان اجرا با حالت‌هایی مواجه خواهند شد که برای آن‌ها آموزش داده نشده‌اند. برای رویارویی با این چالش، از روش‌های برخط برای ایجاد مدل‌های دمایی بهره گرفته‌اند [5] [19]. اغلب مدل‌های دمایی برخط، از آخرین مشاهدات وضعیت دمایی پردازنده، برای ایجاد مدلی برای پیش‌بینی دما استفاده می‌کنند [4] [5].

در صورتی که یک مدل دمایی توجه به پاسخ‌های کنترلی داشته باشد، پیش‌بینی‌هایی با اطمینان بالاتر، ارائه می‌دهد. در مدل کنترل پیش‌بین<sup>1</sup> (MPC)، بر مبنای پیش‌بینی مدل، تصمیم‌های کنترلی گرفته می‌شود. بسیاری از روش‌های مورد استفاده در جهت کاهش دما، باعث کاهش کارایی برنامه می‌شوند. اگر دمای پیش‌بینی شده بیشتر از میزان واقعی در آینده باشد، سطح کارایی برنامه بیشتر از میزان مورد نیاز کاهش خواهد یافت. در مقابل، اگر دمای پیش‌بینی شده کمتر از مقداری باشد که در آینده رخ خواهد داد، قید دمایی رعایت نخواهد شد. بنابراین، میزان تحقق اهداف DTM در MPC به دقت مدل پیش‌بینی دما وابسته است. بر این اساس، DTM می‌تواند از یک مدل دمایی با قابلیت پیش‌بینی پاسخ دمایی، در جهت گرفتن تصمیم‌های کنترلی بهینه، استفاده کند. بهینه بودن این تصمیم‌ها، می‌تواند در

---

<sup>1</sup> Model Predictive Control

راستای حداکثر کردن عملکرد سیستم، با حفظ محدودیت‌های دمایی آن باشد.

## ۱-۱- تعریف مسئله

در این رساله، یک مدل دمایی که مناسب برای پیش‌بینی دما و پاسخ دمایی باشد، با استفاده از شبکه عصبی MLP ایجاد شده است. در این راستا، برخی از ویژگی‌های مناسب برای مدل با استفاده از حسگرهای سیستم خوانده می‌شوند. تعدادی دیگر از ویژگی‌ها، با استفاده از پردازش‌های پیشنهادی فراهم می‌شوند. این ویژگی‌ها برای نگهداری آخرین تغییرات دما و دیگر پارامترهای مؤثر بر دما ایجاد می‌شوند. همچنین، برخی از ویژگی‌ها برای پیش‌بینی اثر ابزارهای کنترل دما فراهم می‌شوند.

برای این که مدل بتواند دقت بالایی را در پیش‌بینی دما برای حالت‌هایی که با آن‌ها آموزش پیدا نکرده، ارائه کند، به ایجاد مدلی برخط برای پیش‌بینی دمای پردازنده پرداخته شده است. بدین منظور، رفتارهای دمایی پردازنده با استفاده از شبکه‌ی نظریه تشدید انطباقی به فازهای مختلفی تقسیم‌بندی می‌شوند. سپس، برای هر فاز یک شبکه‌ی MLP برای پیش‌بینی دما آموزش داده می‌شود. در این راستا، برای هر یک از شبکه‌ها، با توجه به فاز دمایی مربوطه، ویژگی‌های مناسب انتخاب می‌شوند. انتخاب ویژگی‌ها با توجه به اطلاعات متقابل بین ویژگی‌ها با خروجی مدل و همچنین بر اساس اطلاعات متقابل بین مجموعه ویژگی‌های انتخابی انجام می‌شود.

در این رساله، افزون بر معرفی یک مدل دمایی به ایجاد یک مدل کنترلی نیز پرداخته شده است. در انتخاب ابزارهای کنترلی به نکاتی توجه شده که به‌عنوان دو نوع رویکرد مختلف در ادامه معرفی می‌گردند:

۱- تعدادی از روش‌های مدیریت دما، مانند تنظیم فرکانس پردازنده، در مسیر بحرانی اجرای برنامه عمل می‌کنند [20]. هرچند این روش‌ها می‌توانند با سرعت بالایی دما را کاهش دهند، ولی منجر به کاهش ظرفیت محاسباتی پردازنده نیز می‌شوند.

۲- برخی از روش‌های کاهش دما، مانند استفاده از فن خنک‌کننده‌ی CPU، خارج از مسیر بحرانی

اجرای یک برنامه عمل می‌کنند. از این رو، بر ظرفیت محاسباتی سیستم و عملکرد برنامه تأثیر نمی‌گذارد [20]. از آنجایی که این نوع از روش‌ها با تأخیر بیشتری بر دما اثر می‌گذارند [9]، استفاده تنها از آن‌ها، ممکن است باعث کاهش دما، بعد از عبور از دمای بحرانی شود.

استفاده از یک کنترل‌کننده شامل هر دو نوع رویکرد، هم به دمای پردازنده و هم به عملکرد برنامه توجه خواهد داشت. در اغلب رویکردهایی که از چند روش برای کنترل دما بهره می‌برند، برای استفاده از هر روش از یک سیاست کنترلی استفاده می‌شود [9] [20] [21]. به عنوان مثال، ابتدا با افزایش سرعت فن سعی در جلوگیری از افزایش دمای پردازنده داشته و در صورتی که دما به بیش از حد آستانه برسد، از کاهش فرکانس استفاده می‌کنند [20]. در مدل کنترل دمای پیشنهادی، مقدار سرعت فن و فرکانس پردازنده به صورت هم‌زمان و با استفاده از شبکه عصبی چند ورودی چند خروجی MLP تعیین می‌شوند.

## ۱-۲- چالش‌ها

برای ایجاد یک مدل دمایی چالش‌های مختلفی وجود دارد که برخی از آن‌ها عبارت‌اند از:

- تعداد بالایی پارامتر تأثیرگذار بر دمای پردازنده نظیر بارکاری، فرکانس پردازنده و سرعت فن وجود دارند. این پارامترها می‌توانند از چند درجه تا چند ده درجه دمای آینده‌ی پردازنده را در چند لحظه تغییر دهند.
- خواندن مقدار پارامترهای مؤثر بر دما، نیاز به استفاده از ابزارهای گوناگونی دارد که می‌توانند باعث افزایش سرشار محاسباتی یک مدل دمایی شود. یک مدل دمایی، به صورت مداوم در زمان اجرای یک سیستم مورد استفاده قرار می‌گیرد. از این رو، سرشار محاسباتی آن، یکی از چالش‌های اصلی در ایجاد یک مدل دمایی است.
- یک مدل پیش‌بینی دما، توسط یک مدل کنترلی، برای جلوگیری از افزایش دمای پردازنده از دمای حد آستانه مورد استفاده قرار می‌گیرد. در صورتی که دقت بالایی در پیش‌بینی دما وجود نداشته باشد، از طرفی احتمال افزایش دمای پردازنده از حد آستانه وجود دارد و از طرف دیگر،

ممکن است عملکرد پردازنده، بیش از اندازه‌ی موردنیاز کاهش یابد. بنابراین، دقت یک مدل دمایی از دیگر چالش‌های ایجاد یک مدل دمایی است.

از طرفی، در مدل‌هایی که تاکنون برای پیش‌بینی دما معرفی شده‌اند چالش‌هایی وجود دارد که در این رساله به دو مورد توجه شده است:

- اغلب مدل‌های ارائه‌شده تنها قابلیت پیش‌بینی دما با توجه به وضعیت جاری سیستم را دارند. این مدل‌ها توانایی بالایی در پیش‌بینی دما با توجه به اثر استفاده از ابزارهای کنترل دما را ندارد. بر این اساس، امکان پیش‌بینی اثر ابزارهای کنترلی بر دمای آینده پردازنده از چالش‌های یک مدل دمایی مطلوب است.
- اغلب مدل‌های دمایی به صورت برون‌خط ایجاد می‌شوند. این مدل‌ها نمی‌توانند پیش‌بینی دقیقی از دما برای حالت‌هایی ارائه دهند که در زمان ایجاد مدل با آن‌ها آموزش داده نشده باشند. امکان یادگیری حالت‌های جدید در زمان اجرا از چالش‌های مهم در معرفی یک مدل دمایی است. به بیانی دیگر، مدل باید توانایی به‌روز شدن در زمان اجرا با توجه به برخورد پردازنده با شرایط دمایی جدید را داشته باشد.

### ۱-۳- ویژگی‌های یک مدل دمایی

با توجه به چالش‌های مطرح‌شده، برای اینکه یک مدل دمایی بتواند برای استفاده در یک رویکرد DTM فعال مناسب باشد، باید دارای ویژگی‌هایی باشد، که عبارت‌اند از:

- یکی از ویژگی‌های کلیدی برای یک مدل دمایی، سربار محاسباتی آن است. هرچه، مقدار این سربار کم‌تر باشد، باعث عملکرد بهتر رویکرد DTM می‌شود. از آنجایی که یک رویکرد DTM، یک مدل پیش‌بینی دما را در زمان اجرا به صورت تناوبی اجرا می‌کند، سربار ناشی از اجرای مدل، باعث مصرف منابع پردازنده می‌گردد.

- از دیگر ویژگی‌های اصلی یک مدل دمایی، دقت مدل است. دقت بالای مدل، امکان انتخاب ابزار مناسب برای کاهش دما را فراهم می‌کند. از طرفی، انتخاب دقیق مقدار یک ابزار کنترلی، می‌تواند از تغییرات مداوم آن جلوگیری کند.
- مدل‌های دمایی، در یک رویکرد DTM فعال، پیش‌بینی را برای فاصله‌های زمانی مختلف انجام می‌دهند. بازه‌های طولانی‌تر، این قابلیت را به رویکرد می‌دهند که از تنوع بیش‌تری از تصمیم‌های کنترلی، بر اساس اهداف و محدودیت‌های سیستم استفاده کنند. با این وجود، افزایش بازه‌ی زمانی، باعث کاهش دقت پیش‌بینی می‌گردد.
- رفتار دمایی پردازنده، به‌عنوان پاسخی به تصمیم‌های کنترلی، تغییر می‌کند [3]. یکی از ویژگی‌های یک مدل دمایی این است که علاوه بر پیش‌بینی دما با توجه به وضعیت جاری پردازنده، امکان پیش‌بینی پاسخ دمایی را نیز داشته باشد. این ویژگی، به روش‌های مدیریت دما، امکان انتخاب تصمیم کنترلی مناسب را می‌دهد.

## ۱-۴- نوآوری‌های رساله

برای هر دو مدل پیش‌بینی و کنترل دما، تعدادی از ویژگی‌های ورودی، با استفاده از حسگرها و ابزارهای سنجش سیستم خوانده می‌شوند. از طرفی، برای افزایش دقت مدل‌ها، تعداد قابل‌توجهی از ویژگی‌ها با پردازش‌های پیشنهادی محاسبه می‌گردند. همچنین، برای انتخاب مدل مناسب، مقایسه‌ای بین شبکه‌ی MLP، رگرسیون بردار پشتیبان<sup>۱</sup> (SVR)، الگوریتم حداقل میانگین مربع<sup>۲</sup> (LMS) و سیستم استنتاج عصبی-فازی وفقی<sup>۳</sup> (ANFIS) انجام شده است. از دیگر بخش‌های بااهمیت در این رساله، می‌توان به ارزیابی‌های مختلف مدل‌های پیشنهادی و مقایسه آن‌ها با تعداد قابل‌توجهی از رویکردهای مشابه اشاره کرد. تمامی آزمایش‌ها و مدل‌های پیشنهادی، بر روی یک پردازنده‌ی چندهسته‌ای و بدون نیاز به

<sup>1</sup> Support Vector Regression

<sup>3</sup> Adaptive Neuro-Fuzzy Inference System

<sup>2</sup> Least Mean Square

سخت‌افزار اضافی بررسی شده‌اند.

به صورت مختصر، نوآوری‌های رساله در ادامه معرفی می‌شوند:

۱- روشی برای ایجاد ویژگی‌هایی جدید با عنوان‌های سابقه‌ای و کنترلی، برای مدل دمایی، معرفی شده است. این ویژگی‌ها به مدل دمایی پیشنهادی، امکان پیش‌بینی دقیق دما و پاسخ کنترلی را می‌دهد.

۲- دو الگوریتم انتخاب ویژگی جدید با نام‌های مربع اختلاف همبستگی<sup>۱</sup> (SCD) و توسعه‌یافته مربع اختلاف همبستگی<sup>۲</sup> (ESCD)، برای کاهش تعداد ورودی‌های مدل دمایی معرفی شده‌اند. با توجه به آزمایش‌های انجام‌شده، الگوریتم‌های پیشنهادی عملکرد بهتری را در مقایسه با الگوریتم‌های مشابه برای انتخاب ویژگی‌های مدل دمایی ارائه می‌دهند.

۳- برای ایجاد یک مدل دمایی برخط، رفتار دمایی پردازنده با توجه به تعدادی از پارامترهای دمایی سیستم، با بهره‌گیری از شبکه‌ی ART به چندین فاز دمایی تقسیم شده است. پارامترهای مناسب برای شناسایی فازها با روش ESCD انتخاب شده‌اند. در صورت مواجهه با رفتارهای دمایی جدید در زمان اجرای سیستم، برای افزایش دقت مدل تعداد فازها قابل تغییر است. برای هر فاز دمایی، یک مدل پیش‌بینی دما با استفاده از یک شبکه عصبی MLP با رویکرد یادگیری افزایشی ارائه می‌شود. برای هر مدل، ویژگی‌های مناسب با استفاده از روش SCD انتخاب می‌شوند.

۴- مدل چند خروجی MLP، برای کنترل دما با استفاده از تغییرات فرکانس و سرعت فن پیشنهاد شده است. برای آموزش این مدل، مجموعه داده‌ای متنوع از اثر فرکانس و سرعت فن بر دما، با الگوریتم پیشنهادی، ایجاد شده است. ویژگی‌های مناسب برای مدل کنترل دمای پیشنهادی با

---

<sup>1</sup> Square of Correlation Difference

<sup>2</sup> Extended SCD



استفاده از الگوریتم ژنتیک مبتنی بر رتبه‌بندی نامغلوب<sup>1</sup> (NSGA-II) و با توجه به هر دو خروجی فرکانس پردازنده و سرعت فن انتخاب شده‌اند.

## ۱-۵- ساختار رساله

محتویات این رساله در هفت فصل ارائه شده است:

- در فصل دوم، ابتدا به معرفی پردازنده‌های چندهسته‌ای پرداخته می‌شود. سپس، روش‌های مختلفی که برای دریافت دمای هسته‌های پردازنده و یا تخمین دمای آن مورد استفاده قرار گرفته‌اند، معرفی می‌شوند. پس از آن، تعدادی از رویکردهای مختلف مدیریت دما در پردازنده‌های چندهسته‌ای ارائه می‌گردند. در نهایت، تعداد قابل توجهی از مهم‌ترین مدل‌های پیش‌بینی دما معرفی می‌شوند.
- در فصل سوم مدل دمایی پیشنهادی برای پیش‌بینی دما و پاسخ دمایی معرفی می‌شود. مدل پیشنهادی به صورت برون خط ایجاد می‌گردد. در این راستا، ابتدا الگوریتمی برای تولید مجموعه داده مناسب برای آموزش مدل دمایی معرفی می‌شود. سپس، پردازش‌های پیشنهادی برای ایجاد ویژگی‌های مناسب برای پیش‌بینی دما ارائه می‌گردند. در نهایت به معرفی مدل دمایی و الگوریتم‌های پیشنهادی برای انتخاب ویژگی‌های مناسب آن پرداخته می‌شود.
- در فصل چهارم، رویکرد ایجاد مدل دمایی برخط، برای سیستم چندهسته‌ای ارائه می‌گردد. در این بخش، روش تعیین فاز دمایی و ایجاد مدل دمایی مربوطه معرفی می‌شود. در نهایت، جریان مورد استفاده برای به‌روزرسانی مدل در زمان اجرا معرفی می‌گردد.
- رویکرد پیشنهادی برای کنترل دما در فصل پنجم معرفی می‌شود. بدین منظور، از دو مدل به ترتیب برای پیش‌بینی و کنترل دما استفاده شده است. برای هر یک از مدل‌ها، ویژگی‌های مناسب با روش‌های پیشنهادی انتخاب شده‌اند.

---

<sup>1</sup> Non-dominated Sorting Genetic Algorithm-II

- در فصل ششم، نتایج ارزیابی مدل‌های پیشنهادی برای فاصله‌های مختلف زمانی ارائه می‌شوند.
- در فصل هفتم، جمع‌بندی از مدل‌های پیشنهادی ارائه گردیده و در نهایت پیشنهادهایی برای کارهای آینده مطرح شده که در ادامه این رساله انجام شوند.

## ۱-۶- جمع‌بندی

در این فصل، ابتدا به ارائه توضیحاتی مقدماتی در مورد اهمیت مدیریت دمای پردازنده و در راستای آن پیش‌بینی دمای پردازنده پرداخته شده است. سپس تعریفی از مسئله‌ی موردبررسی در این رساله ارائه شده است. پس از آن، به معرفی چالش‌های موجود در پیش‌بینی دمای پردازنده و به دنبال آن چالش‌های بااهمیت‌تر موردبررسی در این رساله، پرداخته شده است. سپس، ویژگی‌های یک مدل دمایی معرفی شده‌اند. آنگاه، نوآوری‌های موجود در این رساله و در نهایت، ساختار رساله معرفی شده است.

# فصل

۲- مروری بر مدل‌های پیش‌بینی  
دما در پردازنده‌های چند هسته‌ای

روش‌های مختلفی برای جلوگیری از افزایش دمای پردازنده در طی سال‌های اخیر پیشنهاد شده‌اند. بخش قابل توجهی از رویکردهای مدیریت دما، نیاز به استفاده از مدلی برای پیش‌بینی دما دارند. بهره‌گیری از یک مدل دمایی با دقت بالا، از مهم‌ترین بخش‌های یک روش مدیریت دما محسوب می‌شود [13] [18] [19] [22] [23].

در این فصل، تعدادی از رویکردهای پیش‌بینی دما در سیستم‌های چند هسته‌ای معرفی شده‌اند. دسته‌بندی‌های مختلفی را برای مدل‌های دمایی می‌توان ارائه کرد. در یک دسته‌بندی، مدل‌ها به برخط و برون‌خط تقسیم‌بندی می‌شوند. از نگاهی دیگر می‌توان مدل‌ها را به مدل‌های خطی و غیرخطی متمایز کرد. برخی از روش‌های پیش‌بینی دما، از چند مدل بهره برده، درحالی‌که برخی دیگر، تنها از یک مدل استفاده می‌کنند. همچنین، تعدادی از مدل‌های دمایی با توجه به نقشه‌ی گیتی پردازنده ارائه شده‌اند، و در مقابل، رویکردهای دیگر قابل‌استفاده برای پردازنده‌های مختلف می‌باشند. از دیگر وجوه تمایز مدل‌های دمایی، بهره‌گیری از ویژگی‌های مختلف برای پیش‌بینی دما می‌باشد. این ویژگی‌های با استفاده از حسگرهای مختلف پردازنده قابل‌خواندن هستند. برای این‌که بتوان به معرفی مدل‌های دمایی پرداخت، توضیحاتی مختصر، در مورد پردازنده‌های چند هسته‌ای و روش‌های دریافت اطلاعات دمایی آن‌ها، مفید است.

## ۲-۱- پردازنده‌های چند هسته‌ای

افزایش تعداد هسته‌های پردازنده، به‌عنوان یک رویکرد جدید برای افزایش کارایی سیستم‌ها معرفی شد. دلایل مختلفی برای معرفی سیستم‌های چند هسته‌ای وجود داشت:

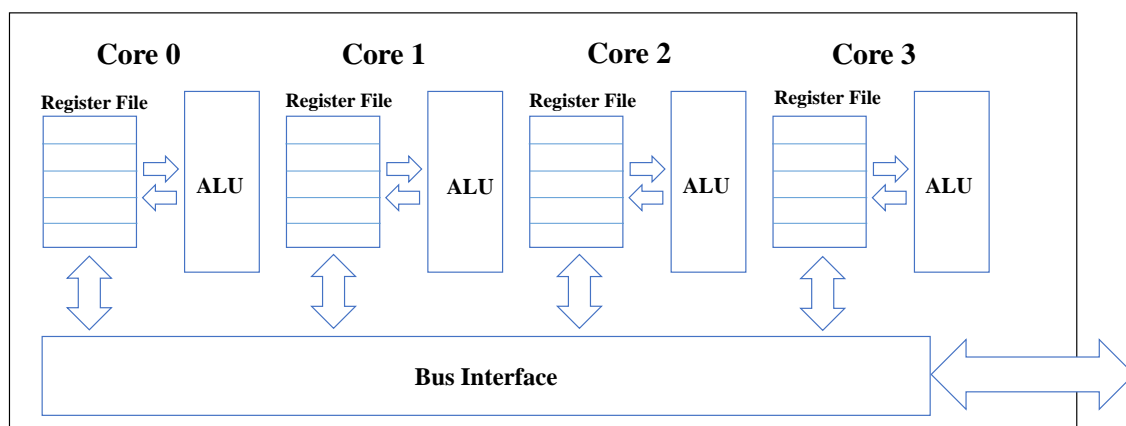
- محدودیت مداری و فناوری در افزایش فرکانس سیستم‌های تک هسته‌ای
- مشکلات موجود در تولید مدار، از قبیل مسائل حرارتی، مسائل موجود در طراحی و بررسی صحت مدار، نیاز به گروه طراحی بزرگ، نیاز به روش‌های خنک‌کننده گران‌قیمت برای سرویس‌دهنده‌ها
- چند نخه بودن تعداد زیادی از برنامه‌ها

- گرایش در معماری کامپیوترها به سمت افزایش موازی سازی

در مواجهه با این چالش‌ها، پردازنده‌های چند هسته‌ای مسیر و جهت جدیدی را در طراحی پردازنده‌ها معرفی کردند. این نوع پردازنده‌ها از چندین هسته بر روی یک تراشه بهره می‌برند [24]. شکل ۱-۲ معماری یک سیستم چند هسته‌ای را نمایش می‌دهد. با توجه به شکل، یک پردازنده‌ی چند هسته‌ای از چند واحد پردازشی مستقل تشکیل شده است که دستورات برنامه‌ها را خوانده و اجرا می‌کنند. هر هسته مجموعه‌ی اختصاصی خود شامل ثبات‌ها، حافظه‌ی میان‌گیر کناری ترجمه<sup>۱</sup> (TLB)، واحد مدیریت حافظه<sup>۲</sup> و حافظه‌ی نهان سطح ۱ و ۲ را دارد. همچنین، برخی از منابع مانند حافظه‌ی اصلی و گذرگاه‌های آدرس و داده، بین هسته‌ها مشترک می‌باشند.

در سیستم چند هسته‌ای قابلیت اجرای موازی هسته‌ها وجود دارد. در تعامل با سیستم‌عامل، هر هسته به‌عنوان یک پردازنده‌ی مجزا در نظر گرفته می‌شود. زمان‌بند، نخ‌ها<sup>۳</sup>/پردازش‌ها<sup>۴</sup> را به هسته‌های مختلف تخصیص می‌دهد. به هر هسته چندین پردازش می‌تواند تخصیص داده شود که در این حالت، زمان‌بندی برای هر هسته مشابه با زمان‌بندی برای یک تک پردازنده است.

ایجاد پردازنده‌های چند هسته‌ای و پس‌از آن افزودن هسته‌های آن‌ها، روشی برای اجرای پردازنده در فرکانس‌های پایین‌تر و دریافت عملکرد بالا است که البته باعث ایجاد چالش‌های جدید گردید. مدیریت



شکل ۱-۲: تراشه‌ی CPU چند هسته‌ای [24]

<sup>۱</sup> Translation Lookaside Buffer

<sup>۳</sup> Thread

<sup>۲</sup> Memory Management Unit

<sup>۴</sup> Process

توان و دما دو نگرانی هستند که به صورت بالقوه با افزایش هسته‌ها در یک سیستم چند هسته‌ای اهمیت بالاتری پیدا می‌کنند. به بیانی دیگر، افزایش تعداد هسته‌ها، همراه با اتلاف توان و گرما بوده که باید قبل از چینش هسته‌ها، گرما در سطح تراشه پخش شود تا نقاط داغ در سطح تراشه ایجاد نگردند. اگر یک پردازنده بسیار گرم شود، امکان ایجاد آسیب‌های سخت‌افزاری از جمله از کار افتادن تراشه وجود دارد [1]. به همین دلیل از فرکانس‌های پایین‌تر در تولید این سیستم‌ها بهره گرفته‌اند.

شایان ذکر است که افزایش دما منجر به افزایش توان نشتی می‌گردد. توان مصرفی کل یک قطعه شامل توان مصرفی پویا<sup>۱</sup> و توان مصرفی ایستا<sup>۲</sup> یا نشتی است [25]. زمانی که مدار فعالیت داشته و کلیدزنی<sup>۳</sup> انجام شود جریانی عبوری از مدار، باعث تولید توان مصرفی پویا می‌شود. این توان با استفاده از فرمول زیر محاسبه می‌گردد:

$$P_{Act} = C_{avg} V_{dd}^2 (Act) f_{clock} \quad (1-2)$$

در این رابطه  $C_{avg}$  بار خازنی متوسط یک ترانزیستور،  $V_{dd}$  و  $f_{clock}$  ولتاژ منبع تغذیه و فرکانس عملیاتی و  $Act$  معیار فعالیت قطعه است. توان مصرفی ایستا ناشی از جریان نشتی است که به‌طور دائم در مدار وجود دارد. این توان، حتی با وجود عدم فعالیت و کلیدزنی مدار نیز بر آن تأثیر می‌گذارد. توان مصرفی ایستا با استفاده از رابطه  $P = V \cdot I$  و با توجه به جریان نشتی هر ترانزیستور محاسبه می‌شود. هرچه فناوری ساخت کوچک‌تر می‌شود، صفحه‌های خازن به یکدیگر نزدیک‌تر شده و باعث عبور جریان نشتی بیشتر می‌شود. بنابراین با افزایش دما، توان مصرفی افزایش یافته و البته با افزایش توان مصرفی، دما افزایش می‌یابد. این وضعیت حلقه‌ای ایجاد کرده که در مدت کوتاهی، می‌تواند منجر به افزایش چشم‌گیر دما شود. بنابراین کنترل دمای سیستم یک مسئله مهم و حیاتی بوده که روی مسائل مختلفی تأثیرگذار است و باید توسط راه‌کارهای مختلف مدیریت شود.

<sup>1</sup> Dynamic power

<sup>3</sup> Switching

<sup>2</sup> Static power

## ۲-۲- روش‌های دریافت اطلاعات دمایی تراشه

برای مدیریت دما، نیاز به دریافت دمای هسته‌های پردازنده است. برای دریافت اطلاعات دمایی، از روش‌های متعددی استفاده شده است. در ادامه تعدادی از روش‌ها به صورت مختصر معرفی می‌گردند.

۱- استفاده از حسگرهای فیزیکی: در اغلب پردازنده‌های امروزی از تعدادی حسگر در قسمت‌های مختلف پردازنده برای خواندن دما استفاده می‌شود. مزیت این روش نسبت به دیگر راه‌کارهای دریافت اطلاعات دمایی، بهره‌گیری از کمترین پیچیدگی محاسبات است. از معایب می‌توان به این نکته اشاره کرد که در این روش تغییرات دمای تراشه، سریع‌تر از سرعت خواندن اطلاعات دمایی با استفاده از حسگرها است [11]. پس احتمال دارد که بخشی از تغییرات دما، در دمای اندازه‌گیری شده‌ای مورد استفاده در روش‌های مدیریت دما، شرکت نکرده و مدیریت دما دچار مشکل شود. از طرفی، به دلیل محدودیت فضای تراشه، امکان قرار گرفتن حسگرها به تعداد دلخواه بر روی تراشه وجود ندارد. همچنین، این حسگرها در مدل‌های مختلف پردازنده در مکان‌های متفاوتی قرار می‌گیرند، که باعث ایجاد عدم دقت در اطلاعات دما می‌شود.

۲- بهره‌گیری از شمارنده‌های کارایی<sup>۱</sup>: در پردازنده‌های مدرن برای نظارت بر فعالیت قطعه‌های مهم پردازنده مانند حافظه نهان و واحد محاسبه و منطق، شمارنده‌هایی وجود دارد [26]. شمارنده‌ها میزان دسترسی و استفاده از قطعات را در یک فاصله‌ی زمانی مشخص، نگهداری می‌کنند. دسترسی زیاد به یک قطعه بدین معنی است که آن قطعه در فاصله‌ی زمانی اخیر، زیاد مورد استفاده قرار گرفته و دمای آن بالا است. برعکس، اگر میزان دسترسی به یک قطعه در فاصله زمانی اخیر کم باشد، معیاری از پایین بودن دمای آن قطعه است. با اندازه‌گیری میزان دسترسی به هر قطعه و استفاده از مدل‌های گرمایی یا ریاضی، تقریبی از دمای قطعات به دست می‌آیند [13].

---

<sup>1</sup> Performance counters

۳- بهره‌گیری از توان مصرفی: از آنجایی که بین توان مصرفی و دمای پردازنده رابطه مستقیم برقرار است می‌توان با تعیین توان پردازنده به تخمین دمای آن پرداخت [10] [18]. در این راستا، از مدل‌های گرمایی برای تعیین دمای بخش‌های مختلف پردازنده بهره می‌برند. یکی از معروف‌ترین مدل‌های گرمایی، HotSpot است [27]. این مدل با دریافت نقشه آرایش قطعات مختلف پردازنده<sup>۱</sup> و توان مصرفی قطعات مختلف پردازنده، به محاسبه‌ی دمای هر یک از قطعات می‌پردازد. در این راستا از روابطی برای تخمین دما بهره می‌برد که از جریان عبوری از قطعات مختلف و انتقال گرمای بین آن‌ها بهره می‌برند [12]. شکل ۲-۲ ورودی و خروجی این مدل را نمایش می‌دهد.



شکل ۲-۲: ورودی‌ها و خروجی شبیه‌ساز HotSpot برای پیش‌بینی دما

در مدل HotSpot، حافظه‌ها با خازن، و قطعه‌هایی که گرما تولید می‌کنند با مقاومت مدل می‌شوند. برای مدل‌سازی توان ورودی، از ولتاژ استفاده کرده و با محاسبه جریان عبوری از هر قطعه، تخمینی از دمای آن قطعه به دست می‌آورد.

## ۲-۳- رویکردهای مدیریت دما

دیدگاه‌های مختلفی در تقسیم‌بندی و معرفی روش‌های مدیریت دما وجود دارد. در یکی از دسته‌بندی‌ها، روش‌ها به دو دسته‌ی آگاه از دما و آگاه از انرژی تقسیم می‌شوند. در روش‌های آگاه از انرژی به‌طور غیرمستقیم به مدیریت دما پرداخته می‌شود. با توجه به اینکه هرچه انرژی مصرفی بیشتر شود، گرمای تولیدشده نیز بیشتر می‌گردد، بنابراین یک رابطه مستقیم بین انرژی یا توان مصرفی با دما وجود دارد که باعث شده تحقیقات در زمینه‌ی کاهش توان مصرفی به منظور کاهش دما صورت گیرد. یکی از اختلاف‌های اصلی بین رویکردهای آگاه از دما و آگاه از انرژی این است که در رویکردهای آگاه از انرژی

<sup>1</sup> Floor plane



هدف کاهش دمای کلی تراشه است و نقاط داغ تراشه در نظر گرفته نمی‌شوند. در صورتی که رویکردهای آگاه از دما هم به نقاط داغ و هم به دمای کل تراشه می‌پردازند [12]. اگر نقاط داغ در بررسی‌ها نادیده گرفته شوند، ممکن است حتی در صورت پایین بودن دمای کلی تراشه، نقاط داغی در آن ایجاد شود که منجر به آسیب رساندن به تراشه گردد.

از دیدگاه دیگر، روش‌های مدیریت دما به دو دسته واکنش‌گرا و فعال تقسیم می‌شوند. در رویکرد واکنش‌گرا، در هنگامی که دما به حالت بحرانی رسیده و زمان زیادی برای تصمیم‌گیری وجود ندارد، با کاهش قابلیت‌های پردازنده مانند کاهش فرکانس، دمای آن کاهش می‌یابد. با اینکه این رویکرد به صورت پویا و در زمان اجرای سیستم استفاده شده، ولی به دلیل نیاز به اثر سریع بر دما، از روش‌هایی مانند DVFS و مهاجرت وظیفه بهره می‌برد که تأثیر منفی بر عملکرد سیستم می‌گذارند. این تأثیر منفی، افزایش زمان اجرای برنامه‌ی در حال اجرا بر روی پردازنده است. از طرفی، زمانی حسگرهای گرمایی یک وضعیت اضطراری را تشخیص می‌دهند که دما به حد آستانه رسیده است. در این حالت، ۱۰۰ تا ۲۰۰ میلی‌ثانیه زمان می‌برد تا کنترل‌کننده‌ی دما، در برابر آن واکنش نشان دهد، و در این مدت دما در وضعیت بحرانی است [7]. در رویکرد فعال، پیش از رسیدن دما به حد بحرانی، با استفاده از روش‌های مختلف، کنترل دما انجام می‌شود. در این دسته، از راه‌کارهای مختلفی که تأثیرهای متفاوتی بر دما و عملکرد سیستم می‌گذارند، می‌توان در جهت کنترل دما استفاده کرد. شایان‌ذکر است که به دلیل وجود فاصله‌ی بین دمای فعلی و دمای بحرانی، می‌توان از ابزارهای متفاوتی در این راستا بهره برد. اغلب در روش‌های فعال از یک مدل دمایی در جهت پیش‌بینی دما استفاده می‌شود.

از طرفی دیگر، برای دسته‌بندی روش‌های مدیریت دما می‌توان استفاده یا عدم استفاده از پیش‌بینی کننده دما را مورد توجه قرار داد. در روش‌هایی که از پیش‌بینی کننده بهره نمی‌برند، از اندازه‌گیری و تخمین وضعیت فعلی تراشه برای مدیریت دما استفاده می‌شود. در صورتی که در روش‌هایی که از پیش-بینی کننده استفاده می‌کنند، از مدل‌های پیچیده‌ای برای پیش‌بینی دمای آینده بهره می‌برند. استفاده

از پیش‌بینی‌کننده به رویکردهای مدیریت دما کمک کرده تا پردازنده کمتر در دماهای بالا قرار بگیرد. نقطه‌ضعف استفاده از آن، پیچیدگی و سرباری است که به سیستم اضافه می‌شود.

روش‌های سخت‌افزاری و نرم‌افزاری، طبقه‌بندی دیگری است که برای رویکردهای مدیریت دما مطرح شده است. روش‌های سخت‌افزاری با استفاده از امکانات سخت‌افزاری و بدون ایجاد تغییر در وظایف یا زمان‌بند سیستم‌عامل به مدیریت دما می‌پردازند. روش‌های سخت‌افزاری نیازمند تغییر در سخت‌افزار بوده و نیازمند امکاناتی در پردازنده‌ها به منظور مدیریت دما می‌باشند. این موضوع باعث افزایش پیچیدگی طراحی و هزینه تولید پردازنده می‌شود. در حالی که رویکردهای نرم‌افزاری، با اعمال تغییراتی در زمان‌بندی سیستم‌عامل به مدیریت دما می‌پردازند. در ادامه به معرفی تعدادی از روش‌های مدیریت دما پرداخته شده که در دسته‌های مختلفی از نظر ایستا و پویا بودن و همچنین سخت‌افزاری و نرم‌افزاری بودن قرار می‌گیرند.

- روش‌های ایستای سخت‌افزاری: در این راستا می‌توان به طراحی آگاه از دمای نقشه پردازنده<sup>۱</sup> اشاره کرد [2]. دمای بیشینه‌ی یک بلاک در یک تراشه، نه‌تنها به چگالی توان مصرفی (توان مصرفی در واحد سطح) آن بلاک بستگی دارد بلکه به چگالی توان مصرفی بلاک‌های مجاور آن نیز بستگی دارد. در نتیجه، چگونگی قرار گرفتن بلاک‌ها در نقشه‌ی یک پردازنده تأثیر زیادی در دمای بیشینه‌ی قطعات دارد. بنابراین در این روش تلاش می‌شود تا بلاک‌هایی که چگالی توان مصرفی بالاتر دارند و گرمای بیشتری تولید می‌نمایند را در سطح تراشه در بین بلاک‌های سردتر توزیع نمایند. با استفاده از این روش افزایش دمای ناشی از اثر بلاک‌های داغ روی یکدیگر را کمتر نموده و باعث تولید گرمای کمتر می‌شوند.

- روش‌های ایستای نرم‌افزاری: این روش‌ها قبل از زمان اجرای وظایف و بدون استفاده از سخت‌افزار اضافی، با تغییری که در کد منبع وظایف در زمان کامپایل داده می‌شود، به مدیریت دما می‌پردازند.

---

<sup>1</sup> Temperature Aware Floorplanning

نمونه‌ای از این روش‌ها، کامپایل آگاه از دمای کد است [1]. بدین منظور، الگوریتمی به نام TempNOP برای مدیریت دما توسط کامپایلر معرفی شده است. در این الگوریتم، زمانی که با توجه به کد برنامه، یک دمای بالا پیش‌بینی می‌شود، در برنامه تعدادی دستور NOP<sup>1</sup> قرار داده می‌شود. با استفاده از این روش، زمانی که دمای واحدهای عملیاتی رو به افزایش است، برای مدتی عملیات محاسباتی و منطقی، استفاده از ثبات‌ها و حافظه نهان متوقف شده تا از گرم شدن بیشتر آن واحدها جلوگیری گردد.

- روش‌های پویای سخت‌افزاری: در این راستا، الگوریتم‌ها و روش‌های متعددی معرفی شده‌اند که در ادامه به معرفی تعدادی از آن‌ها پرداخته می‌شود.

۱- روش توقف اجرا<sup>۲</sup>: در این رویکرد، زمانی که دمای پردازنده از یک مقدار مشخص بیشتر شود، پردازنده عملیات جاری خود را برای یک مدت مشخص متوقف نموده تا دما کاهش پیدا نماید. این رویکرد، با روش‌های مختلفی پیاده‌سازی شده است [28].

۲- Clock-gating: در این روش از کاهش توان پویای مصرفی در جهت کاهش دما استفاده می‌شود. در این روش، بخش‌هایی از مدار را غیرفعال کرده تا حافظه‌های فلیپ فلاپ آن‌ها، نیاز به تغییر وضعیت پیدا نکنند. باید توجه داشت که تغییر وضعیت، باعث افزایش توان مصرفی شده و با عدم تغییر وضعیت توان مصرفی پویا صفر شده و تنها توان مصرفی ایستا یا نشتی باقی می‌ماند.

۳- تنظیم ولتاژ و فرکانس پویا: کاراترین روش مدیریت دمای پویا است. در این روش، با کاهش ولتاژ و یا فرکانس پردازنده، دما با سرعت بالایی کاهش می‌یابد. اغلب پردازنده‌های امروزی دارای تعدادی مشخصی از سطوح فرکانس-ولتاژ هستند که با بالا رفتن دما از حد آستانه، یکی از سطوح پایین‌تر فرکانس-ولتاژ انتخاب شده تا دما کاهش یابد. لازم به ذکر است که با

---

<sup>1</sup> No operation

<sup>2</sup> Stop-go

کاهش سرعت پردازنده زمان اجرای برنامه‌ها افزایش یافته و این امر موجب کاهش کارایی می‌گردد. در پردازنده‌های مختلف، امکان انتخاب فرکانس، به دو روش سراسری و محلی وجود دارد. در روش سراسری، تمامی هسته‌های پردازنده باهم به یک مقدار تنظیم می‌شوند. با این‌که این روش به‌سادگی پیاده‌سازی می‌گردد، ولی می‌تواند منجر به کاهش عملکرد همه‌ی هسته‌ها شود. زیرا، به دلیل افزایش دمای یک هسته، فرکانس همه‌ی هسته‌ها کاهش می‌یابد. در روش محلی برای هر هسته‌ی پردازنده، مقدار فرکانس به‌صورت مجزا تعیین می‌گردد. در این حالت برای کاهش دمای یک هسته، تنها نیاز به کاهش فرکانس همان هسته است. از آنجایی‌که به ازای هر هسته، یک فرکانس مجزا باید انتخاب شود، افزایش تعداد هسته‌ها منجر به افزایش پیچیدگی الگوریتم‌های کنترل دما می‌گردد. لازم به ذکر است که تغییرات فرکانس یک هسته، بر مقدار شمارنده‌های کارایی، توان مصرفی و دمای آن تأثیر مستقیم دارد. از طرفی، بر دمای دیگر هسته‌های پردازنده نیز به‌صورت غیرمستقیم تأثیرگذار است. با در نظر گرفتن تأثیرات مستقیم و غیرمستقیم، تعیین مقدار مناسب فرکانس یک هسته برای مدیریت دما با توجه به عملکرد پردازنده، با افزایش تعداد هسته‌ها، پیچیدگی قابل توجهی پیدا می‌کند.

- روش‌های پویای نرم‌افزاری: دو روش بااهمیت در این دسته، زمان‌بندی وظایف و مهاجرت وظایف است. زمان‌بندی وظایف رویکردی است که در آن وظایف به‌گونه‌ای زمان‌بندی می‌شوند که دمای سیستم را پایین‌تر از حد آستانه نگهداری نمایند. دو نوع زمان‌بندی آگاه از دما، شامل روش به تعویق انداختن اجرای کارهای داغ و روش استفاده از حلقه‌ی سردکننده است [29]. روش به تعویق انداختن اجرای کارهای داغ به این صورت است که هر موقع که اجرای یک وظیفه باعث افزایش دمای هسته از حد آستانه شود، آن را به انتهای صف وظایف منتقل می‌کنند. در روش استفاده از حلقه‌ی سردکننده، زمانی که دمای یک هسته از حد آستانه فراتر رود، وظیفه در حال اجرا معلق شده و یک حلقه‌ی کاری که هیچ عملی انجام نمی‌دهد اجرا می‌گردد. بعد از سرد شدن نقاط داغ

هسته، دوباره اجرای وظیفه‌ی معلق شده از سر گرفته می‌شود. مهاجرت وظیفه، روشی برای کاهش دما با استفاده از پخش نمودن فعالیت روی یک مساحت بزرگ‌تر است [30]. تفاوت این روش با زمان‌بندی وظایف در این است که در روش زمان‌بندی وظایف، وظیفه از هسته‌ای به هسته‌ی دیگر مهاجرت پیدا نمی‌کند. در روش مهاجرت وظایف، زمانی که بارکاری یک هسته از یک مقدار مشخص فراتر رود و هسته‌ای با بارکاری کم وجود داشته باشد، تعدادی وظیفه از هسته با بارکاری بالا به هسته‌ای با بارکاری کم منتقل می‌شوند. در این روش تلاش می‌شود به کمک مهاجرت وظایف تعادل گرمایی بین هسته‌ها ایجاد شده و دمای هسته‌ها نزدیک به هم گردد. در [31] نیز، از مهاجرت وظیفه برای مدیریت دما استفاده شده است. ایشان از یک مدل دمایی بهره گرفته‌اند که هم مبتنی بر مدل پیش‌بینی دمای هسته‌ها و هم مبتنی بر مدل پیش‌بینی دمای برنامه‌ها است. در این روش، برنامه‌ها از هسته‌هایی که احتمال داغ شدن برای آن‌ها وجود دارد به هسته‌ای که سردترین هسته‌ی پیش‌بینی شده است منتقل شده تا دما، کمتر از حد آستانه حفظ شود. پیش‌بینی کننده ارائه شده در [32] جهت بهبود پیش‌بینی، برنامه‌ها را بر اساس رفتار دمایی آن‌ها دسته‌بندی می‌نماید.

- روش‌های پویای ترکیبی: شامل الگوریتم‌های مدیریت دما است که از یک یا چندین ابزار کنترلی برای جلوگیری از افزایش دمای پردازنده از دمای حد آستانه استفاده می‌کنند. به‌عنوان مثال، الگوریتم ارائه شده در [2]، از ترکیب تنظیم ولتاژ و فرکانس پویا و روش نرم‌افزاری مهاجرت وظیفه برای مدیریت پویای دما استفاده می‌کند. الگوریتم، در حالت کلی با روش نرم‌افزاری مهاجرت وظیفه مدیریت دما را انجام می‌دهد. بدین منظور، اگر دمای یک هسته از حد آستانه فراتر رود وظیفه‌ی در حال اجرای آن، به یک هسته‌ی دیگر که دارای دمایی پایینی است مهاجرت داده می‌شود. تغییر مهمی که نویسندگان این مقاله در روش مهاجرت اعمال کرده‌اند این است که در انتخاب هسته‌ی مقصد، دمای هسته‌های مجاور نیز در نظر گرفته شده‌اند. همچنین برای تخمین دمای آینده، دمای فعلی هر هسته و دمای هسته‌های مجاور لحاظ شده‌اند. در روش مهاجرت وظیفه با توجه به بارکاری، ممکن است شرایطی پیش آید که در آن هسته‌ها از نظر گرمایی اشباع شده و دیگر این روش برای

کاهش دما سودمند نباشد. در چنین مواقعی از روش تنظیم ولتاژ و فرکانس پویا استفاده شده است. در این حالت، زمانی که دما از یک حد آستانه فراتر رود، ولتاژ و فرکانس کاری پردازنده، کاهش یافته تا توان مصرفی پردازنده و به دنبال آن، دما کاهش یابد.

روش‌های مدیریت دمایی که تاکنون معرفی شدند، از ابزارهایی برای کاهش دما استفاده کرده که در مسیر بحرانی اجرای برنامه عمل می‌کنند. این روش‌ها باعث کاهش عملکرد پردازنده شده و زمان اجرای برنامه‌ها را افزایش می‌دهند. فن خنک‌کننده، از ابزارهایی است که در خارج از مسیر بحرانی اجرای برنامه، برای کاهش دما مورد استفاده قرار می‌گیرد. با توجه به این ویژگی، تعدادی از رویکردهای مدیریت دما، از تنظیم سرعت فن نیز برای کنترل دما بهره برده‌اند [9] [20] [33] [34]. هرچند افزایش سرعت فن باعث افزایش توان مصرفی آن می‌گردد.

از ANFIS، برای کنترل سرعت فن، با توجه به دما و توان مصرفی استفاده شده است [33] [34]. هدف روش‌های معرفی شده، کاهش توان مصرفی فن با محدودیت حفظ دما حول و حوش دمای حد آستانه است. برای آموزش مدل، مجموعه داده‌ای ایجاد شده که شامل اثر تغییرات سرعت فن بر دمای هسته‌های پردازنده است. همچنین، برای ایجاد مجموعه داده مناسب، برنامه‌های متنوع از نظر نیاز به استفاده از CPU، که از برنامه‌های محک CPU2006 SPEC انتخاب شده‌اند، بر روی هسته‌های پردازنده در شرایط مختلف اجرا می‌شوند.

در [20]، از کنترل سرعت فن و فرکانس پردازنده برای مدیریت دمای پویا استفاده شده است. در روش ارائه شده، برای پیش‌بینی دما، از تغییرات دما، در آخرین مشاهدات سیستم بهره برده‌اند. همچنین، آرایه‌ای فراهم کرده‌اند که در هر سطر آن، برای هر دما، مقدار مناسب سرعت فن و فرکانس پردازنده ذخیره شده است. در زمان اجرا، با توجه به دمای پیش‌بینی شده، برای جلوگیری از کاهش عملکرد سیستم، ابتدا با استفاده از کنترل سرعت فن سعی داشته تا از افزایش دما از حد آستانه ممانعت شود. در صورت افزایش دما از حد آستانه، با کاهش فرکانس، کنترل دما انجام می‌شود. در کار ارائه شده، از

پارامترهای محدودی برای پیش‌بینی دما استفاده شده است. همچنین، از تغییرات مداوم سرعت فن استفاده می‌کنند که مناسب برای این ابزار کنترلی نیست.

در یکی از دیگر از رویکردهای مدیریت دما، معیاری برای کنترل دما بر اساس نسبت بین عملکرد و توان مصرفی پردازنده معرفی شده است [9]. سپس، با توجه به معیار تعریف‌شده، برای هر یک از سه ابزار فرکانس پردازنده، مهاجرت وظیفه و سرعت فن، رابطه‌های لازم محاسبه شده‌اند. برای تعریف رابطه‌ها از شبیه‌ساز HotSpot و معماری پردازنده بهره‌برده‌اند. در روش ارائه‌شده، با توجه به زمان اثر هر یک از ابزارهای کنترلی، در بازه‌های زمانی مختلف، مقدار مناسب هر کدام از ابزارهای کنترلی محاسبه می‌گردد.

## ۲-۴- مدل‌های پیش‌بینی دما

در این بخش به معرفی مدل‌های دمایی پرداخته شده که در روش‌های مدیریت دما برای پیش‌بینی دما استفاده می‌شوند. از طرفی، از دیگر قابلیت‌های یک مدل دمایی، توانایی پیش‌بینی اثر ابزارهای کنترلی بر مقدار دما است. استفاده از این مدل‌ها، به رویکردهای مدیریت دما این امکان را می‌دهد که برای کاهش دما، ابزار کنترلی مناسبی را بر اساس میزان تغییر دما و کارایی انتخاب کنند.

رفتارهای بارکاری از پارامترهای مؤثر بر تغییرات دما است. به‌صورت معمول، مدل‌سازی بارهای کاری به علت وجود رفتارهای پیچیده، به‌سختی انجام می‌شود. غیرقابل‌پیش‌بینی بودن رفتارهای بارکاری از چالش‌های مدیریت دمای فعال است. تعدادی از پردازنده‌ها، این پیچیدگی را با ارائه‌ی روش‌های بازخورد پویا<sup>۱</sup> مدیریت می‌کنند [35] [36]. در این راستا، از حسگرهای سخت‌افزاری برای اندازه‌گیری دما استفاده کرده و در صورتی که دما در محدوده‌ی نامطلوب قرار گیرد، به کاهش توان مصرفی پردازنده می‌پردازند. تعدادی از کارهای اخیر، برای افزایش دقت خروجی‌های دمایی حسگرها، از مدل‌های نرم‌افزاری برای به دست آوردن جزئیات بیشتر درباره‌ی تغییرات دما استفاده می‌کنند [3] [7]. همچنین، در زمان اجرای برنامه‌ها، برخی از مدل‌ها به‌صورت برخط از روش‌های آماری بر روی یک پنجره‌ی شناور از آخرین

---

<sup>1</sup> Reactive feedback techniques

مشاهدات دمایی، برای شناسایی الگوی تغییرات دما استفاده می‌کنند [5]. در این راستا، روش رگرسیون یکی از متداول‌ترین رویکردها، برای تعیین ضریب‌های یک مدل دمایی است. از طرفی، دیگر مدل‌های دمایی به صورت برون خط بر روی مجموعه داده‌ی آموزشی، ضریب‌های مدل دمایی را تعیین می‌کنند [7]. سپس، در زمان اجرا، با معادله‌ی تعیین‌شده، پیش‌بینی برخط دما انجام می‌گردد. در ادامه به معرفی تعدادی از مهم‌ترین مدل‌های دمایی پرداخته می‌شود.

## ۲-۴-۱- روش‌های مبتنی بر اندازه‌گیری دما

تعدادی از مدل‌های دمایی برخط، با استفاده از آمارهای جمع‌آوری‌شده در زمان اجرای برنامه‌ها، ایجاد و یا به‌روزرسانی می‌گردند. اغلب، این مدل‌ها، پنجره‌ای از آخرین مشاهدات دمایی را برای تخمین دمای آینده استخراج می‌کنند. در صورت استفاده از پنجره‌ای با اندازه‌ی  $m$ ، نمونه‌ی  $m$ ام، با اجرای تابعی بر روی  $m$  نمونه‌ی قبلی، پیش‌بینی دما را انجام می‌دهد. به‌عنوان مثال برای تابع  $f(t_{n-1}, t_{n-2}, \dots, t_{n-m})$  که در آن  $t_i$  دمای نمونه‌ی  $i$ ام است، می‌توان از تابع‌های میانگین ساده، وزن‌دار و نمایی برای پیش‌بینی  $t_n$  استفاده کرد [18].

همچنین، راه‌حل‌های پیچیده‌تری برای پیش‌بینی برخط دما، مانند روش‌های تحلیلی سری زمانی، پیشنهاد شده‌اند. به‌طور خاص، مدل‌های خود رگرسیون میانگین متحرک<sup>۱</sup> (ARMA) که همبستگی را در سری‌های زمانی شناسایی می‌کنند، در تعدادی از کارها برای پیش‌بینی دما استفاده شده‌اند [4] [5] [37]. معادله‌ی ARMA که شامل دو بخش خود رگرسیون (AR) و میانگین متحرک (MA) است، با رابطه‌ی ۲-۲ نمایش داده شده است.

$$y_t + \sum_{i=1}^p (a_i y_{t-i}) = e_t + \sum_{i=1}^q (c_i e_{t-i}) \quad (2-2)$$

$y_t$  مقدار دما در زمان  $t$  و  $a_i$  و  $c_i$  به ترتیب، ضریب‌های نمونه‌ی  $i$ ام در بخش AR برای مقدارهای

<sup>1</sup> Autoregressive-Moving-Average



پیشین دما و در بخش MA برای مقدارهای خطای پیش‌بینی پیشین می‌باشند.  $e_t$  یک خطای سفید<sup>۱</sup> است که مقدار آن در زمان تعیین ضریب‌ها، روی پنجره‌ی نمونه‌ها مشخص می‌شود. مقدار خطای پیش‌بینی دما برای نمونه‌ی  $t - i$  با  $e_{t-i}$  مشخص شده است.  $p$  و  $q$  به ترتیب اندازه‌ی پنجره‌ی AR و MA را مشخص می‌کنند. برای پیش‌بینی دما برای هر نمونه، پنجره‌ی از آخرین مشاهدات دمای هسته‌ی پردازنده مورد استفاده قرار می‌گیرد. اندازه‌ی پنجره به صورت تجربی و با انجام آزمایش‌های مختلف انتخاب شده است. از طرفی، پس از انجام پیش‌بینی برای هر نمونه، تفاوت بین دمای پیش‌بینی شده و دمای مشاهده‌شده، به عنوان مقدار خطا ثبت می‌شود. در این حالت با توجه به هر دو پنجره آخرین مشاهدات دمای پردازنده و مقدار خطاهای پیش‌بینی، دما پیش‌بینی می‌گردد. از طرفی برای تعیین ضرایب رابطه، از برازش حداقل مربعات بر روی مجموعه‌ی آموزش استفاده شده است.

از آنجایی که رابطه‌ی مستقیمی بین بارکاری و دما در مدل ARMA وجود ندارد، در یکی از رویکردهای پیشنهادی، برای انطباق مدل دمایی با رفتار متغیر بارکاری، بانکی از ضریب‌های مدل ARMA ایجاد شده است [5]. با استفاده از آزمون نسبت احتمال متوالی<sup>۲</sup> (SPRT)، ضریب‌های مناسب برای مشاهدات دمایی اخیر از بانک ضرایب، با احتمال درستی بالا انتخاب می‌شوند. در صورتی که احتمال درستی تمامی ضریب‌های موجود در بانک پایین باشد، بر روی پنجره‌ی مشاهدات اخیر، ضریب‌های جدیدی برای مدل ARMA آموزش داده شده و به بانک اضافه می‌شود. با این وجود باید به این نکته اشاره کرد که مدل ARMA در صورتی می‌تواند یک پیش‌بینی دقیق با سربار کاری کم ارائه دهد که مشخصه‌های بارکاری در حال اجرا بر روی هسته با گذشت زمان ثابت بماند.

برای پیش‌بینی دما با توجه به بارکاری، از ترکیب دو مدل دمایی مبتنی بر ویژگی‌های هسته‌ی پردازنده و رفتار برنامه استفاده شده است [31]. بدین منظور با استفاده از رابطه‌ی خطی ۲-۳ بر روی خروجی‌های این دو مدل، دما پیش‌بینی می‌گردد.

<sup>1</sup> White noise

<sup>2</sup> Sequential Probability Ratio Test

$$T_{predict} = w_s T_{app} + w_l T_{core} \quad (3-2)$$

$w_s$  و  $w_l$  پارامترهای وزنی، برای تعیین میزان اثرگذاری مدل‌های دمایی مبتنی بر برنامه و مبتنی بر هسته، بر دمای پیش‌بینی هستند.  $T_{app}$  که خروجی مدل دمایی مبتنی بر برنامه است، با استفاده از یک معادله‌ی خطی، بر روی گرادیان‌های دمایی یک هسته اندازه‌گیری می‌گردد.  $T_{core}$  نیز خروجی مدل دمایی مبتنی بر هسته است. برای تعیین  $T_{core}$ ، از دمای حالت پایدار هسته‌ی پردازنده در آزمایش‌ها و توجه به رفتار دمایی دما استفاده می‌شود. این پارامترها با توجه به بارکاری تنظیم می‌شوند. از محدودیت‌های این کار می‌توان به عدم در نظر گرفتن پارامترهای مؤثر بر دما همچون فرکانس پردازنده، توان ابزارهای خنک‌کننده و تأثیر هسته‌های مجاور بر دمای هسته اشاره کرد.

تغییرات دمای یک هسته بر روی یک تراشه‌ی چندهسته‌ای، با فعالیت‌های دمایی همسایه‌هایش رابطه‌ی مستقیم دارد. از این‌رو، بهره‌گیری از تأثیر دمای هسته‌های مجاور یک هسته، می‌تواند باعث بهبود دقت پیش‌بینی دمای آن گردد. بدین منظور، از رابطه‌ی خطی ۲-۴ برای پیش‌بینی دما استفاده شده است [7].

$$T_i^{pred} = \alpha_i T_i^{curr} + \beta_i I_i^{in} + \gamma_i I_i^{nb} \quad (4-2)$$

$T_i^{curr}$  دمای فعلی هسته،  $I_i^{in}$  تغییرات دمایی هسته و  $I_i^{nb}$  میانگین تغییرات دمایی هسته‌های همسایه هستند. همچنین ضریب‌های  $\alpha_i$ ،  $\beta_i$  و  $\gamma_i$  با استفاده از رگرسیون خطی، بر روی اطلاعات ثبت‌شده از دمای هسته‌های پردازنده، به صورت برون‌خط محاسبه می‌شوند. از معایب این کار می‌توان به استفاده از یک ضریب مشترک برای میانگین دمای هسته‌های مجاور یک هسته اشاره کرد. در حقیقت در این حالت تأثیر هسته‌های مجاور بر روی دمای هسته‌ی هدف، یکسان فرض می‌شود. در صورتی که در عمل، هسته‌های همسایه اثرهای متفاوتی را بر دمای یک هسته می‌گذارند. همچنین عوامل مؤثری همچون رفتار برنامه، در این کار نادیده گرفته شده است.

از دیگر رویکردهایی که به تأثیر هسته‌های مجاور در پیش‌بینی دمای هسته توجه داشته است، استفاده

از مدل‌های ظرفیت-مقاومت<sup>۱</sup> (RC) است [9] [10] [38]. در این راستا، لی‌یو و همکاران با فرض داشتن ظرفیت دمایی هریک از هسته‌ها و میزان مقاومت دمایی بین هسته‌های مجاور، یک مدل پیش‌بینی دما بر اساس رابطه‌ی ۲-۵ پیشنهاد نموده‌اند [10]. مقاومت دمایی، یک ویژگی فیزیکی است که نشان-دهنده‌ی مقاومت هر ماده در مقابل انتقال حرارت در اثر تفاوت دما است.

$$T_m = G^{-1}(U_m - CT_{m-1}) \quad (۵-۲)$$

در این رابطه، دمای هسته‌ها در لحظه  $m$ ، از حاصل ضرب بین معکوس مقاومت دمایی هسته‌ها نسبت به یکدیگر ( $G$ )، در تفاضل بین انرژی مصرفی پیش‌بینی‌شده ( $U_m$ ) و انرژی مصرفی در لحظه‌ی قبل هسته‌های پردازنده ( $CT_{m-1}$ ) که توسط تبدیل لاپلاس به معیار مشترکی تبدیل شده‌اند، به دست می‌آید. از عکس تبدیل لاپلاس می‌توان برای به دست آوردن دمای واقعی هسته‌ها استفاده کرد. در این کار برای ارزیابی روش پیشنهادی از شبیه‌ساز HotSpot [27] استفاده شده است، تا میزان مقاومت دمایی میان هسته‌های پردازنده را در اختیار داشته باشد. در سیستم‌های واقعی اطلاع از میزان مقاومت دمایی میان هسته‌های پردازنده، تنها در اختیار شرکت سازنده بوده و استفاده از این مدل دشوار است. در این راستا، از دانش لایه‌های فیزیکی تراشه نیز، برای تعیین مقدار انتقال دما در میان هسته‌ها، استفاده شده است [39]. لازم به ذکر است که مدل‌های RC، اغلب در شبیه‌سازی‌ها مورد استفاده قرار گرفته و کمتر در سیستم‌های واقعی پیاده‌سازی می‌شوند.

## ۲-۴-۲- روش‌های مبتنی بر اثر بارکاری

در [3] [13] [17] [18] [26]، اثر بارکاری بر دمای پردازنده مورد توجه قرار گرفته است. با تغییر در رفتار بارکاری میزان توان مصرفی پردازنده تغییر کرده و در نتیجه روند تغییرات دمای پردازنده دگرگون می‌شود. این در حالی است که رفتار برنامه اغلب یکنواخت نبوده و به بازه‌هایی از زمان قابل تقسیم‌بندی است [3]. در [13] [17] [18] [26]، رفتار برنامه با استفاده از ابزارهای سنجش موجود روی پردازنده،

<sup>1</sup> Resistance-Capacitance

مانند شمارنده‌های کارایی و نشانگرهای توان مصرفی اندازه‌گیری شده است. در این راستا، کومار و همکاران با رابطه‌ی خطی ۲-۶، از ترکیب شمارنده‌های کارایی برای پیش‌بینی دما استفاده کرده‌اند [26].

$$T_{overall} = w_{const} + \sum_{i=1}^{22} w_i \frac{u_i}{t_{total}} \quad (۲-۶)$$

$u_i$ ، که مقدار شمارنده‌ی کارایی نام است، بر تعداد چرخه‌های پردازنده ( $t_{total}$ )، تقسیم می‌شود.  $w_i$ ها ضریب‌های هر یک از شمارنده‌های کارایی هستند. برای تعیین ضرایب، مجموعه‌داده‌ای شامل مقادیر مختلف شمارنده‌های کارایی و دمای پردازنده تهیه شده و با استفاده از درون‌یابی خطی مقدار آن‌ها محاسبه می‌گردد. همچنین،  $w_{const}$  دمای اندازه‌گیری شده‌ی پردازنده، در حالت بیکاری است.

بارکاری در زمان‌های مختلف اجرا، با توجه به اعمالی که در آن لحظه انجام می‌دهد که شامل ترکیبی از اعمال محاسباتی و اعمال ورودی/خروجی است، وضعیت‌های مختلفی را در استفاده از CPU ایجاد می‌کند. افزایش میزان استفاده از CPU باعث افزایش دمای آن می‌شود. در این راستا، می‌توان با توجه به میزان استفاده از CPU توسط یک بارکاری در هر لحظه از اجرا، فازهای مختلفی را برای آن تعریف کرد. کچران و همکاران با استفاده از شمارنده‌های کارایی، فازهای رفتاری بارکاری را شناسایی کرده و در هر فاز از مدل جداگانه‌ای برای پیش‌بینی دما بهره برده‌اند [3]. در این کار، ابتدا مجموعه‌داده‌ای از سیستم تهیه می‌شود که شامل تعداد زیادی شمارنده کارایی، حاصل از اجرای برنامه‌ها بر روی سیستم است. سپس، با استفاده از تحلیل مؤلفه‌های اصلی<sup>۱</sup> (PCA)، خروجی این شمارنده‌ها، به دو جزء اصلی کاهش داده شده است. آنگاه با استفاده از خوشه‌بندی KMeans، نمونه‌های موجود در مجموعه، به تعدادی خوشه تقسیم‌بندی می‌شوند. هر کدام از خوشه‌ها، یک فاز رفتاری برای برنامه محسوب می‌گردد. درنهایت، پیش‌بینی دما با استفاده از رابطه‌ی خطی ۲-۷ انجام می‌شود. این رابطه برای هر فاز از برنامه به صورت مجزا تنظیم می‌گردد.

<sup>۱</sup> Principle Component Analysis

$$g_m[i] = T_m[i] - \sum_{n=1}^N a_{mn} T_n[i-1] - a_m^{idle} \quad (7-2)$$

$T_m[i]$  دمای هسته‌ی  $m$  در زمان  $i$  و  $a_{mn}$  و  $a_m^{idle}$  ضریب‌های مدل از دید هسته  $m$  هستند. در این کار، ابتدا مجموعه داده‌ای از سیستم در حالتی تهیه می‌شود، که تنها یک هسته از پردازنده بیکار بوده، تا ضریب‌های مدل، برای هسته‌ی بیکار با استفاده از این داده‌ها و به‌کارگیری درون‌یابی خطی تعیین شوند. در حالت بیکاری هسته، مقدار  $g_m$  که مربوط به میزان اثر بارکاری است، صفر در نظر گرفته می‌شود. در گام بعد، تلاش می‌شود که مقدار  $g_m$  برای هسته در فرکانس‌ها و فازهای مختلف بارکاری به‌گونه‌ای تخمین زده شود، که معادله‌ی دما با ضریب‌هایی که در زمان بیکاری هسته تعیین شده‌اند، باز هم معتبر باشد. باید به این نکته اشاره کرد، که با افزایش ابعاد پارامترهای مؤثر بر دما همچون سطوح فرکانس، فازهای بارکاری مختلف و تعداد هسته‌های پردازنده، تعداد مدل‌های موردنیاز در این رویکرد بسیار افزایش می‌یابد. درواقع، از آنجایی که برای هر یک از این حالت‌ها، به ضریب‌های جداگانه‌ای برای پیش‌بینی دما نیاز است، مقیاس‌پذیری این روش یک چالش مهم در استفاده از آن است.

در [13]، بارکاری به دو فاز فعالیت بالا و فعالیت معمول تقسیم‌بندی شده است. در این مقاله، دمای هر واحد از پردازنده، با یک رابطه خطی پیش‌بینی شده است. بدین منظور، از دمای پیشین هر واحد، به همراه تعدادی از شمارنده‌های کارایی به‌عنوان ورودی‌های مدل پیش‌بینی دما استفاده کرده‌اند. برای ارزیابی مدل ارائه‌شده، از شبیه‌ساز HotSpot بهره برده‌اند. در این رویکرد نیز از تعداد قابل‌توجهی از پارامترهای مؤثر بر دما نظیر فرکانس و سرعت فن استفاده نشده است.

## ۲-۴-۳- روش‌های مبتنی بر یادگیری ماشین

در دسته‌ای از مدل‌های دمایی، از روش‌های یادگیری ماشین برای پیش‌بینی دما بهره برده‌اند [14] [15] [16] [17] [18] [19]. در این راستا به تعدادی از مدل‌های دمایی اشاره می‌شود که از شبکه‌ی MLP و

SVR استفاده کرده‌اند. با استفاده از شبکه عصبی MLP، مدلی برای پیش‌بینی حداکثر<sup>۱</sup> دمای یک هسته پردازنده، ارائه شده است [16]. ورودی‌های مدل شامل میانگین و حداکثر توان مصرفی بارکاری و نیز دمای هسته‌های مجاور است. در یک مرحله‌ی برون‌خط، میانگین و حداکثر توان مصرفی، از مجموعه داده‌ی حاصل از اجرای بارکاری بر روی هسته‌ی پردازنده، محاسبه می‌شوند. با توجه به این که حداکثر دمای پیش‌بینی شده، یک حد بالا برای دمای هسته است، سعی شده تا نزدیک به حداکثر دمای مشاهده شده در زمان اجرا باشد. با این وجود، شاید بتوان تنها با استفاده از یک بررسی برون‌خط بر روی مجموعه داده‌ی فراهم شده، حد بالای دما را بدون استفاده از یک مدل پیش‌بینی پیچیده، محاسبه کرد. از محدودیت‌های این روش، نیاز به فراهم کردن یک مجموعه داده از اجرای هر بارکاری بر روی هسته‌ی پردازنده، پیش از پیش‌بینی دمای حاصل از آن است. به بیانی دیگر، برای هر بارکاری یک مجموعه داده مجزا باید ایجاد گردد.

[14] و [15] از یک شبکه عصبی ساده برای پیش‌بینی دمای یک هسته بهره گرفته‌اند. در این کارها، از دمای فعلی و توان مصرفی به عنوان ورودی‌های مدل پیش‌بینی دما استفاده کرده‌اند. از معایب این رویکردها، عدم توجه مستقیم به دیگر پارامترهای مؤثر بر دما نظیر فرکانس پردازنده و سرعت فن است. [14] از یک لایه پنهان و نرون‌هایی فاقد تابع فعالیت در ساختار شبکه MLP استفاده کرده است. البته، شبکه در واحد پردازش گرافیکی<sup>۲</sup> (GPU) پیاده‌سازی شده است.

در کار دیگری از شبکه‌ی عصبی MLP با ویژگی‌های مناسب برای پیش‌بینی دما استفاده شده است [19]. ویژگی‌های مناسب از میان پارامترهایی گزینش می‌شوند که با استفاده از ابزارهای اندازه‌گیری سیستم قابل خواندن هستند. ویژگی‌های خوانده شده، شامل ولتاژ پردازنده، دمای پردازنده و ۱۴ شمارنده-ی کارایی می‌شوند. این ویژگی‌ها، با استفاده از الگوریتم انتخاب ویژگی همبستگی<sup>۳</sup> (CFS) انتخاب شده‌اند. مقاله‌ی ارائه شده، برای پیش‌بینی دما، شبکه عصبی MLP را با مدلی بر پایه‌ی رگرسیون خطی

<sup>1</sup> Peak

<sup>2</sup> Graphic Processing Unit

<sup>3</sup> Correlation Feature Selection

و مدل فرایند گوسی مقایسه کرده است. نتایج ارائه شده، دقت بالای مدل MLP را در مقایسه با دیگر مدل‌ها نشان می‌دهد. همچنین، در این مقاله، مدل دمایی در دو حالت ایستا و برخط آموزش داده شده است. خطای پیش‌بینی ایستا، برای مدل دمایی MLP برای برنامه‌های محک مختلف از ۱/۴۶ تا ۵/۳۶ درجه‌ی سانتی‌گراد گزارش شده است. افزون بر آن، برای مدل دمایی برخط خطای حدود ۱ درجه‌ی سانتی‌گراد گزارش شده است.

در [22]، نیز مدل MLP برای تخمین دما استفاده شده است. از شمارنده‌های کارایی به‌عنوان ورودی-های مدل دمایی بهره برده‌اند. عدم توجه به دیگر پارامترهای مؤثر بر دما و از طرفی، عدم انتخاب ویژگی‌های مناسب برای مدل دمایی از معایب این رویکرد است.

در [23]، از خوشه‌بندی KMeans بر روی پارامترهای فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی، برای شناسایی فازهای دمایی یک هسته در پردازنده‌ی چند هسته‌ای استفاده شده است. رفتارهای دمایی یک هسته در پردازنده‌ی چند هسته‌ای، علاوه بر اینکه متأثر از رفتارهای بارکاری در حال اجرا بر روی آن هسته است، به تغییرات فرکانس پردازنده، سرعت فن و دمای دیگر هسته‌های پردازنده نیز بستگی دارد. این ویژگی‌ها به‌عنوان پارامترهای دمایی معرفی شده و به خوشه‌بندی این ویژگی‌ها پرداخته شده است. هر خوشه به‌عنوان یک فاز دمایی معرفی می‌شود. یک فاز دمایی مرحله‌ای از اجرا است که در آن پارامترهای مؤثر بر دمای یک هسته از پردازنده در یک محدوده‌ی تقریباً یکسان از مقادیر قرار گرفته‌اند. برای انتخاب تعداد فازها از شاخص دیویس-بولدین<sup>۱</sup> استفاده شده است. سپس، برای پیش‌بینی دما در هر فاز، از یک شبکه‌ی MLP بهره گرفته‌اند. انتخاب ویژگی‌های مناسب در هر فاز با استفاده از روش MID انجام شده است.

در [18] از یک روش ترکیبی از مدل SVR و ابزار HotSpot برای پیش‌بینی دما بهره برده‌اند. در این کار، ابتدا مجموعه‌داده‌ای شامل شمارنده‌های کارایی و میزان توان مصرفی متناظر با آن‌ها جمع‌آوری

---

<sup>1</sup> Davies-Bouldin

می‌شود که در اثر اجرای بارهای کاری مختلف بر روی پردازنده به دست می‌آیند. سپس، SVR با استفاده از داده‌های جمع‌آوری‌شده، برای پیش‌بینی توان مصرفی هسته‌ی پردازنده آموزش داده می‌شود. آنگاه، توان پیش‌بینی به‌عنوان ورودی، به ابزار پیکربندی‌شده HotSpot داده‌شده، تا دمای هسته پیش‌بینی گردد. یکی از مهم‌ترین چالش‌های این کار، نیاز به داشتن دانش معماری پردازنده، برای پیکربندی ابزار HotSpot است.

استاکمن و همکاران نیز، با استفاده از SVR مدلی برای پیش‌بینی دما ارائه کرده‌اند [17]. در پژوهش انجام‌شده نیز، تنها از ۳۴ شمارنده کارایی برای ورودی‌های مدل دمایی استفاده شده و ویژگی‌های مهمی همچون دمای کنونی، فرکانس پردازنده و سرعت فن در آن لحاظ نشده است. میزان خطای پیش‌بینی، برای فاصله‌ی زمانی کمتر از ۱۰ ثانیه زیر ۱۰٪ گزارش شده است. با این وجود، ارزیابی دقت پیش‌بینی دما با استفاده از معیار درصد خطا چندان منطقی به نظر نمی‌آید.

از طرفی می‌توان به این نکته اشاره داشت که در تمامی روش‌های مدل‌سازی معرفی‌شده، تعدادی از ویژگی‌های پردازنده و بارکاری، به‌عنوان ورودی‌های مدل دما استفاده‌شده‌اند. استفاده از تعداد زیادی ویژگی می‌تواند باعث کاهش دقت مدل و همچنین افزایش سربار آموزش و اجرای آن گردد [40]. از این‌رو، انتخاب حداقل ویژگی‌های مؤثر می‌تواند در افزایش دقت پیش‌بینی مدل اثر قابل‌توجهی داشته باشد. برخی از روش‌ها، ویژگی‌های مناسب را با انجام آزمایش‌های متعدد و با توجه به دانش خبره انتخاب می‌کنند. انتخاب مجموعه ویژگی‌های مؤثر با حداقل تعداد لازم، تأثیر قابل‌توجهی در افزایش دقت مدل‌های پیش‌بینی و کنترل دما دارد.

## ۲-۵- جمع‌بندی

مدل‌های دمایی مختلفی تاکنون معرفی شده‌اند که از پارامترهای مختلفی برای پیش‌بینی بهره می‌برند. از آنجایی که پارامترهای مختلفی، از جمله فرکانس پردازنده، سرعت فن، بارکاری، دمای هسته‌های مختلف پردازنده و دمای محیط بر دمای پردازنده تأثیر می‌گذارند، انتخاب ویژگی‌های مناسب، می‌تواند تأثیر



قابل توجهی در دقت مدل داشته باشد. از طرفی، به علت وجود تعداد پارامترهای زیاد، دقت بالایی از مدل‌های پیش‌بینی خطی حاصل نمی‌شود. بر این اساس، تعدادی از روش‌های مدیریت دما از مدل‌های غیرخطی بهره برده‌اند. از طرفی، در برخی از رویکردها، از چندین مدل خطی استفاده کرده‌اند که هر کدام مناسب برای پیش‌بینی در یک حالت پردازنده می‌باشد.

در نهایت، به علت تنوع بالای رفتارهای دمایی پردازنده، آموزش کامل یک مدل دمایی به صورت برون خط، غیرعملی به نظر می‌آید. به همین دلیل، در تعدادی از رویکردها، برای اینکه دقت بالایی از مدل برای پیش‌بینی همه‌ی تغییرات دمایی پردازنده دریافت کنند، از مدل‌های برخط بهره برده‌اند.



# فصل

۳- مدل پیشنهادی برون خط برای

پیش‌بینی دما

استفاده از یک مدل پیش‌بینی دما، به رویکردهای مدیریت دما این امکان را می‌دهد که بتوانند پیش از رسیدن دما به حدآستانه، از این رخداد مطلع گردند. در این حالت می‌توانند از ابزارهای کنترلی مناسب جهت جلوگیری از این وضعیت نامطلوب استفاده کنند. از طرفی، در صورتی که یک مدل دمایی امکان تخمین پاسخ کنترلی<sup>۱</sup> را داشته باشد، می‌تواند توسط کنترل‌کننده‌ها مورد بهره‌برداری قرار گیرد. در این فصل به ارائه یک مدل دمایی پرداخته شده که افزون بر پیش‌بینی دما، امکان تخمین پاسخ دمایی حاصل از کنترل دما را نیز دارد.

یک مدل دمایی به صورت برون‌خط یا برخط آموزش داده می‌شود. مزیت استفاده از یک مدل برون‌خط این است که سربار آموزش مدل در زمان اجرا را ندارد. از طرفی، دقت یک مدل دمایی مهم‌ترین ویژگی آن محسوب می‌شود. برای این که یک مدل برون‌خط، دقت بالایی در زمان اجرا داشته باشد، باید به‌خوبی آموزش داده شود. یکی از مهم‌ترین پارامترها برای آموزش مدل، استفاده از یک مجموعه‌داده‌ی مناسب است. در این فصل، الگوریتمی برای ایجاد یک مجموعه‌داده متنوع از رفتارهای دمایی پردازنده معرفی شده است. از دیگر پارامترهای مؤثر در دقت یک مدل دمایی، فراهم کردن ویژگی‌های مناسب به‌عنوان ورودی‌های مدل است. در این راستا، در جهت افزایش دقت مدل دمایی، پردازش‌هایی برای تولید ویژگی‌های مناسب برای آن پیشنهاد شده است. از آنجایی که استفاده از همه‌ی ویژگی‌ها افزون بر افزایش سربار اجرایی می‌تواند باعث کاهش دقت مدل نیز گردد، الگوریتم‌هایی برای انتخاب ویژگی‌های مناسب برای مدل دمایی پیشنهاد شده است.

به‌صورت مختصر، در این فصل به معرفی مدل دمایی پیشنهادی در چند مرحله پرداخته می‌شود: ایجاد مجموعه‌داده، آماده‌سازی مجموعه‌ی داده، توسعه و ارزیابی مدل دمایی با شبکه‌ی MLP و درنهایت انتخاب ویژگی‌های مناسب برای مدل دمایی.

---

<sup>1</sup> Control response

### ۳-۱- ایجاد مجموعه داده

بیشتر پردازنده‌ها مجموعه‌ای اختصاصی از شمارنده‌های کارایی را برای هر هسته فراهم آورده‌اند تا امکان نظارت تعدادی از رویدادهای سخت‌افزاری خاص را برای اشکال‌زدایی و تنظیم‌های سیستم ایجاد کنند. با این وجود، حسگرهایی در پردازنده و سیستم هستند که اطلاعات تکمیلی از وضعیت پردازنده، در اختیار کاربر قرار می‌دهند. در این راستا می‌توان به حسگرهای دما، نمایانگر سرعت فن و نمایانگر فرکانس ساعت پردازنده اشاره کرد. تلفیق تمامی این اطلاعات دریافتی از حسگرها و شمارنده‌ها برای ترسیم حالت سیستم، منجر به ایجاد یک فضای حالت گسترده می‌شود.

مدل دمایی پیشنهادی مبتنی بر یادگیری از مشاهده‌ی عملکرد سیستم است. از این‌رو، هر چه تنوع بیشتری از مشاهدات، برای فرآیند یادگیری مدل آماده گردد، دقت مدل در پیش‌بینی دما بهتر خواهد شد. با این وجود، ثبت تمامی حالت‌های ممکن از سیستم غیرعملی است. بنابراین، آزمایشی ترتیب داده‌شده که در آن ترکیب‌های مختلفی از سرعت فن، فرکانس پردازنده و بارکاری، برای ایجاد حالت‌های متنوعی از سیستم فراهم می‌گردد.

آزمایش‌ها بر روی سیستم چهار هسته‌ای Intel's Core i7-950 انجام شده است. سیستم‌عامل مورد استفاده، لینوکس است. برای دریافت اطلاعات دمایی توسط حسگرها، از ابزار Im-sensor [41] استفاده شده است. همچنین از زیرسیستم perf موجود در سیستم‌عامل لینوکس، جهت دریافت اطلاعات شمارنده‌های کارایی بهره گرفته شده است [42]. پردازنده‌ی مورد استفاده، شمارنده‌های سخت‌افزاری متعددی را پشتیبانی می‌کند که می‌توانند به‌طور هم‌زمان با استفاده از پنج ثبات خاص مدل شمارش شوند. این عملیات توسط سیستم‌عامل کنترل می‌شود. بنابراین، هر درخواست نظارت بر رویداد باید توسط سیستم‌عامل مدیریت شود. اگر لیست رویدادهای درخواست شده بیش از تعداد واقعی شمارنده‌ها باشد، سیستم‌عامل ترتیبی را اتخاذ کرده که در آن برخی شمارنده‌ها، زمان شمارش خود را بین چند رویداد به اشتراک می‌گذارند. در چنین مواردی برای تخمین مقدار شمارنده‌های کارایی در یک واحد

زمانی، از مقیاس پذیری مقداری استفاده می‌شود که برای آن‌ها در یک زمان کمتر اندازه‌گیری شده است. بر این اساس، خواندن تعداد کمتر از مقادیر شمارنده‌های کارایی می‌تواند مقداری دقیق‌تر برای آن‌ها ارائه دهد. در این رساله، تعدادی از مهم‌ترین شمارنده‌های کارایی خوانده‌شده که در مقاله‌های مختلف در پیش‌بینی دما مورد استفاده قرار گرفته‌اند. پیش از معرفی شمارنده‌های کارایی مورد استفاده در مدل دمایی، به معرفی مختصر تعدادی از واژه‌های مورد استفاده در آن‌ها پرداخته می‌شود:

اصابت در حافظه پنهان<sup>۱</sup> (CHit): زمانی که داده‌ی مورد ارجاع در حافظه‌ی پنهان یافت شود.

عدم اصابت در حافظه پنهان<sup>۲</sup> (CMiss): زمانی که داده‌ی مورد نیاز در حافظه‌ی پنهان نباشد.

بلوک<sup>۳</sup>: تعداد ثابتی از بایت‌های حافظه اصلی که در حافظه‌ی پنهان در یک عمل انتقال کپی می‌شود. این انتقال زمانی اتفاق می‌افتد که داده‌ی مورد نیاز در حافظه‌ی پنهان نباشد.

صفحه<sup>۴</sup>: یک بلوک با اندازه‌ی ثابت از فضای آدرس حافظه مجازی است که اغلب بین ۱ تا ۴ کیلوبایت است. یک صفحه می‌تواند بر روی حافظه‌ی اصلی و یا دیسک باشد.

نقص صفحه<sup>۵</sup>: وقفه‌ای است که زمانی اتفاق می‌افتد که پردازنده به صفحه‌ای ارجاع می‌دهد که در حافظه‌ی پنهان یا حافظه‌ی اصلی نباشد.

چرخه‌های توقف حافظه<sup>۶</sup> (MSC): تعداد چرخه‌هایی است که پردازنده در دسترسی به حافظه متوقف شده است.

چرخه‌های ساعت CPU<sup>۷</sup> (CLC): زمان مورد نیاز برای رسیدگی به یک CHit و زمانی که پردازنده در طی یک CMiss متوقف شده است.

زمان اجرای CPU (CET) با استفاده از زمان چرخه‌های ساعت (CCT) با رابطه‌ی ۳-۱ محاسبه می‌شود.

---

<sup>1</sup> Cache hit

<sup>2</sup> Cache miss

<sup>3</sup> Block

<sup>4</sup> Page

<sup>5</sup> Page fault

<sup>6</sup> Memory stall cycles

<sup>7</sup> CPU clock cycles

$$CET = (CLC + MSC) \times CCT \quad (1-3)$$

شاخه<sup>۱</sup>: دستوری در یک برنامه کامپیوتری است که منجر به اجرای ترتیب دیگری از دستورات می‌شود. این دستورات برای ایجاد جریان کنترلی در حلقه‌ها و شروط برنامه استفاده می‌شوند. در این راستا، دستورات شاخه‌ای، شمارنده‌ی برنامه‌ی CPU را تغییر می‌دهند.

لیست شمارنده‌های کارایی مورد استفاده به همراه باقی ویژگی‌های مدل پیشنهادی در جدول ۱-۳ نمایش داده شده است. برای این که بتوان اهمیت استفاده از هر ویژگی در پیش‌بینی دما را بررسی کرد، می‌توان از همبستگی بین ویژگی‌ها با دمای آینده بهره برد. بعد از معرفی کامل ویژگی‌های مدل دمایی، مقدار همبستگی آن‌ها با دمای آینده‌ی پردازنده در ادامه این فصل ارائه خواهد شد. به‌عنوان مثال، شمارنده‌های کارایی *Cyc*، *Inst* و *L1Ref* که البته در مقاله‌های متعددی مورد توجه قرار گرفته‌اند بیش‌ترین همبستگی را در بین شمارنده‌ها، با دمای آینده‌ی هسته دارند.

از ابزار *cpufreq* [43] برای تنظیم پویای ولتاژ و فرکانس استفاده شده است. تغییر سرعت فن با استفاده از اسکریپت هسته‌ی *fancontrol* انجام شده است. برای ایجاد حالت‌های مختلف دمایی، از برنامه‌های محک *SPEC CPU2006* استفاده شده، که به‌صورت موازی بر روی هسته‌های پردازنده قابل اجرا هستند. برنامه‌های استفاده‌شده شامل *bzip2*، *hmmmer*، *gcc*، *perlbench*، *libquantum* و *mcf* می‌باشند. این برنامه‌ها که به علت تفاوت آن‌ها در میزان استفاده از CPU، دماهای مختلفی را در پردازنده ایجاد می‌کنند، در مقاله‌های متعددی مورد بهره‌برداری قرار گرفته‌اند [32] [44]. در ادامه به معرفی مختصر این برنامه‌ها پرداخته می‌شود:

- *bzip2*: این برنامه متعلق به مجموعه‌ی برنامه‌های محک اعداد صحیح است که در طبقه‌بندی فشرده‌سازی قرار می‌گیرد. در این برنامه، به‌غیر از خواندن ورودی‌های لازم، I/O دیگری انجام نمی‌شود. تمام فشرده‌سازی‌ها و بازگشایی آن‌ها، به‌طور کامل در حافظه انجام می‌شود. این کار، به مجزا

---

<sup>1</sup> Branch

جدول ۳-۱: لیست ویژگی‌های خوانده‌شده از سیستم

نام ویژگی	توصیف مختصر ویژگی
PROCESSOR	فرکانسی که در آن CPU در حال اجرا است و نمایانگر سرعت پردازنده است
FREQUENCY ( <i>Freq</i> )	
FAN SPEED ( <i>FS</i> )	سرعت فن خنک‌کننده روی CPU
TEMPERATURE OF CPU	دمای همهی هسته‌های CPU
CORE 0, 1, 2, 3 ( <i>PT</i> )	
CONTEXT-SWITCHES	تعداد تعویض متن‌های فرایند در حال اجرا بر روی هسته، بین دو فاصله اندازه-گیری متوالی است
( <i>CS</i> )	
CPU-MIGRATIONS ( <i>CM</i> )	تعداد مهاجرت‌های فرایند در حال اجرا بر روی هسته توسط سیستم عامل
SW_PAGE_FAULTS ( <i>PF</i> )	تعداد نقص صفحه‌های اتفاق افتاده بر روی هسته‌ی در حال اجرا
CYCLES ( <i>Cyc</i> )	تعداد چرخه‌های ساعت پردازنده، بر روی هسته‌ی در حال اجرا بین دو فاصله-ی اندازه‌گیری متوالی است
STALLED_CYCLES_FRO	تعداد چرخه‌هایی که دستورالعمل‌ها در ابتدای خط لوله متوقف شدند
NTEND ( <i>SCF</i> )	
STALLED_CYCLES_BA	تعداد چرخه‌هایی که دستورالعمل‌ها در انتهای خط لوله متوقف شدند
CKEND ( <i>SCB</i> )	
INSTRUCTIONS ( <i>Inst</i> )	تعداد کل دستورالعمل‌های اجرا شده توسط هسته در حال اجرا، بین دو فاصله‌ی اندازه‌گیری متوالی است
BRANCHES ( <i>Br</i> )	تعداد دستورات شاخه‌ای اجرا شده بر روی هسته‌ی در حال اجرا
BRANCH-MISSES ( <i>MBr</i> )	تعداد دستورالعمل‌های شاخه‌ای اشتباه پیش‌بینی‌شده روی هسته در حال اجرا
CACHE-REFERENCES	تعداد درخواست‌ها با آخرین سطح حافظه پنهان توسط هسته‌ی در حال اجرا
( <i>CRef</i> )	
IO_TRANSACTIONS ( <i>IO</i> )	تعداد کل عملیات ورودی و خروجی انجام شده توسط هسته‌ی در حال اجرا
L1D_ALL_REF ( <i>L1Ref</i> )	تعداد ارجاع‌دهی به داده‌های سطح اول حافظه پنهان توسط هسته‌ی در حال اجرا
CACHE-MISSES ( <i>CMiss</i> )	تعداد درخواست‌های از دست رفته در آخرین سطح حافظه پنهان، که توسط هسته در حال اجرا بین دو فاصله‌ی متوالی اندازه‌گیری شده، ناشی شده است

سازی زیرسیستم‌های حافظه و CPU کمک می‌کند. برنامه با زبان C نوشته شده است. ورودی‌های

آن شامل دو تصویر JPEG، یک برنامه دودویی، تعدادی کد منبع در یک فایل tar، یک فایل html و یک فایل ترکیبی است. فایل خروجی شامل اطلاعات مختصری از آنچه اجرا شده است.

• gcc: این برنامه متعلق به مجموعه‌ی برنامه‌های محک اعداد صحیح است که با زبان C نوشته شده



است. این برنامه‌ی محک به‌عنوان یک کامپایلر با تعداد زیادی پرچم‌های بهینه‌سازی اجرا می‌شود. این برنامه، زمان بیشتری را برای تحلیل ورودی‌های کد منبع صرف کرده و بیشتر حافظه استفاده می‌کند. برای این که بتواند زمان بیشتری را برای اجرا صرف کند، باید بارکاری بیشتر به آن داده شود. بدین منظور، ۹ بارکاری مختلف را پردازش می‌کند.

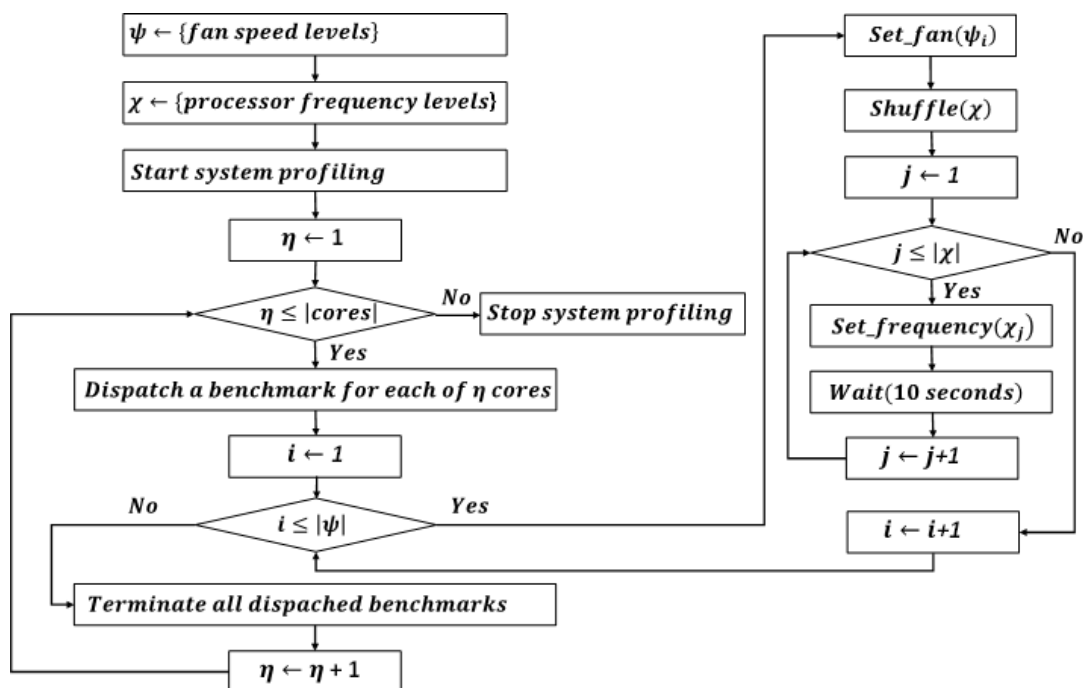
- **hmmer**: این برنامه متعلق به مجموعه‌ی برنامه‌های محک اعداد صحیح است که در دسته‌بندی جستجو در یک پایگاه داده ژن قرار می‌گیرد. در این برنامه از مدل‌های مخفی مارکوف بهره گرفته شده، که مدل‌های آماری توالی چندگانه هستند که در زیست‌شناسی محاسباتی برای جستجوی الگوها در توالی‌های DNA مورد استفاده قرار می‌گیرند. این روش برای انجام جستجوی حساس به پایگاه داده، با استفاده از توصیف آماری اجماع خانوادگی، مورد استفاده قرار می‌گیرد. از این روش برای تجزیه و تحلیل توالی پروتئین بهره می‌گیرند.

- **perlbench**: این برنامه در طبقه‌بندی زبان‌های برنامه‌نویسی قرار می‌گیرد. نسخه‌ی مختصرتری از زبان Perl است. در این نسخه، ویژگی‌های خاص سیستم‌عامل حذف شده است. البته، ماژول‌های متعددی در آن مورد استفاده قرار می‌گیرد.

- **libquantum**: این برنامه از طبقه‌بندی فیزیک یا محاسبات کوانتومی است. به بیانی دقیق‌تر، یک کتابخانه برای شبیه‌سازی یک کامپیوتر کوانتومی است. رایانه‌های کوانتومی بر اساس اصول مکانیک کوانتوم هستند و می‌توانند وظایف محاسباتی سخت را در زمان چندجمله‌ای حل کنند.

- **mcf**: برنامه در طبقه‌بندی بهینه‌سازی ترکیبی یا برنامه‌ریزی واحد انبار خودرو قرار می‌گیرد. این برنامه برای حل مسائل مربوط به برنامه‌ریزی حمل‌ونقل انبوه خودرو طراحی شده است. برنامه، یک انبار واحد و یک ناوگان خودرو همگن را بررسی می‌کند. بر اساس یک طرح خطی و فرکانس سرویس، سفرها با توجه به مکان‌ها و زمان‌های ورود و خروج ثابت برای هر خودرو، زمان‌بندی می‌شوند.

از آنجایی که هر هسته، از شمارنده‌های خاص خود بهره می‌برد، برای پیش‌بینی دمای هر هسته، از یک مدل مجزا استفاده می‌کنیم. در این راستا، مدل پیشنهادی برای یک هسته با عنوان هسته‌ی هدف، بر روی یک سیستم چهار هسته‌ای ایجاد و ارزیابی می‌شود. در شکل ۱-۳، نمودار جریان ایجاد مجموعه داده‌ای شامل حالت‌های متنوع دمایی در سیستم نمایش شده است. برای تولید مجموعه داده، ابتدا سطوح مختلف سرعت فن و فرکانس پردازنده انتخاب شده و به ترتیب در مجموعه‌های  $\psi$  و  $\chi$  قرار می‌گیرند. مجموعه‌ی مربوط به سطوح سرعت فن شامل مقادیر  $\{۵۰، ۸۴، ۱۱۰، ۱۴۰، ۱۸۴، ۲۲۴، ۲۵۵\}$  مدولاسیون پهنای پالس<sup>۱</sup> (PWM) است. انتخاب این مجموعه، با توجه به فن موجود بر روی پردازنده و قابلیت‌های آن انجام شده است. لازم به ذکر است که خواندن سرعت فن با معیار گردش در هر دقیقه<sup>۲</sup> (RPM) انجام می‌شود. مجموعه‌ی سطوح مختلف فرکانسی قابل تنظیم بر روی پردازنده، شامل مقادیر  $\{۳۰۶۰۰۰۰، ۲۹۲۶۰۰۰، ۲۶۶۰۰۰۰، ۲۳۹۴۰۰۰، ۲۱۲۸۰۰۰، ۱۸۶۲۰۰۰، ۱۵۹۶۰۰۰\}$  هرتز<sup>۳</sup> است. برای هر پردازنده، سطوح مختلفی از فرکانس می‌تواند انتخاب شود تا با فرکانس انتخابی،



شکل ۱-۳: نمودار جریان جمع آوری داده از سیستم

<sup>1</sup> Pulse Width Modulation

<sup>3</sup> Hertz

<sup>2</sup> Revolutions Per Minute

پردازنده فعالیت خود را انجام دهد. سپس، یک نخ<sup>۱</sup> مجزا فراخوانی شده (*Start system profiling*) که برای ذخیره‌ی داده‌ها در مجموعه‌داده استفاده می‌شود. داده‌ها شامل دمای هسته‌های پردازنده، فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی هسته هدف برای پیش‌بینی دما است. این نخ که به‌صورت هم‌زمان با الگوریتم اصلی اجرا می‌گردد، برای ثبت داده‌ها در فواصل زمانی یک‌ثانیه‌ای، استفاده می‌گردد.

یکی از دلایل نمونه‌برداری یک ثانیه‌ای ویژگی‌های دمایی، این است که امکان خواندن دمای هسته‌های پردازنده از طریق حسگرها موجود بر روی آن، هر ثانیه یک‌بار امکان‌پذیر است. لازم به ذکر است که دمای کنونی هسته‌های پردازنده، بیش‌ترین همبستگی را با دمای آینده‌ی پردازنده دارد. به همین دلیل، خواندن ویژگی‌های مناسب برای پیش‌بینی دما، در کارهای متعددی در هر ثانیه یک‌بار انجام شده است. از طرفی، از آنجایی که مدل پیش‌بینی دما، مورداستفاده برای یک مدل کنترل دما است، و اغلب روش‌های کنترل دما، به بیش از ۱ ثانیه زمان برای تأثیر بر دما نیاز دارند، زمان یک ثانیه برای خواندن ویژگی‌ها مناسب به نظر می‌رسد. درنهایت، پردازنده‌ی مورداستفاده در این رساله به‌طور هم‌زمان با استفاده از پنج ثبات خاص، مقادیر شمارنده‌های کارایی مختلف را شمارش می‌کند. از آنجایی که لیست رویدادهای درخواست شده بیش از تعداد واقعی شمارنده‌ها است، سیستم‌عامل ترتیبی را اتخاذ کرده که در آن برخی شمارنده‌ها، زمان شمارش خود را بین چند رویداد به اشتراک می‌گذارند. بر این اساس، زمان یک ثانیه، زمان مناسبی برای مقیاس‌پذیری مقدار هر یک از شمارنده‌ها محسوب می‌شود. به‌عنوان مثال، شمارنده‌ی Context-Switch در این بازه‌ی زمانی، اغلب مقداری بین ۱ تا ۵ ارائه می‌دهد، در صورتی که برای حدود ۲۰۰ میلی‌ثانیه مقدار ۰ یا ۱ را ارائه داده که در این حالت، یک ویژگی مناسب برای پیش‌بینی محسوب نمی‌شود.

نمونه‌برداری از همه‌ی ویژگی‌ها، به‌صورت هم‌زمان انجام شده است. دلایل متعددی در این راستا وجود

---

<sup>۱</sup> Thread

دارد که تعدادی از آن‌ها عبارت‌اند از:

- یکی از سربارهای اصلی مربوط به یک مدل پیش‌بینی دما، خواندن ویژگی‌های ورودی مدل از حسگرها و دیگر ابزارهای اندازه‌گیری پردازنده است. بر این اساس، در اغلب مدل‌های پیش‌بینی دما، همه‌ی ویژگی‌های موردنیاز مدل، در یک بازه‌ی زمانی خوانده می‌شوند.
  - خواندن تعداد قابل‌توجهی از پارامترهایی که برای یک مدل پیش‌بینی دما لازم بوده و انتخاب می‌شوند، هر ثانیه یک‌بار امکان‌پذیر بوده، و تنها مقدار تعداد محدودی از پارامترهای انتخابی برای مدل را می‌توان در بازه‌های زمانی متفاوت خواند. به بیانی دیگر، استفاده از بازه‌های زمانی متفاوت برای هر یک از ویژگی‌ها، نمی‌تواند اثر قابل‌توجهی در افزایش دقت مدل دمایی بگذارد.
  - در این رساله، هدف پیش‌بینی دما برای فاصله‌های زمانی ۲ ثانیه به بعد است. دلیل انتخاب این فاصله این است که امکان استفاده از ابزارهای کنترلی متفاوت در کنترل دما فراهم شود. پیش‌بینی دما برای این فاصله‌ها، نیاز به خواندن ویژگی‌ها در بازه‌های زمانی کمتر از یک ثانیه ندارد.
- در الگوریتم پیشنهادی برای جمع‌آوری مجموعه‌داده، از حلقه‌ای استفاده شده که تعداد دفعات اجرای آن برابر با تعداد هسته‌های پردازنده ( $\#cores$ ) است. در هر مرحله، با توجه به مقدار شمارنده‌ی حلقه ( $\eta$ )، تعدادی از هسته‌های پردازنده به‌صورت تصادفی انتخاب شده و به هر یک از آن‌ها یک برنامه‌ی محک به‌صورت تصادفی نسبت داده می‌شود (*Dispatch a benchmark*). به بیانی دیگر، در مرحله‌ی اول تنها بر روی هسته‌ی هدف، یک برنامه‌ی محک اجرا می‌شود. در مرحله بعد، علاوه بر هسته‌ی هدف، یک هسته‌ی دیگر به‌صورت تصادفی انتخاب می‌گردد. به هر دو هسته، به‌صورت تصادفی برنامه‌ی محکی تخصیص داده می‌شود. این مراحل تا جایی ادامه یافته که به همه‌ی هسته‌ها، یک برنامه تخصیص داده شود. انتخاب تصادفی برنامه‌ها، باعث ایجاد تنوع تغییر رفتارهای دمایی پردازنده می‌شود.
- در هر مرحله از اجرای حلقه، با توجه به تعداد سطوح سرعت فن ( $|\psi|$ ) و تعداد سطوح فرکانس پردازنده ( $|\chi|$ ) از حلقه‌های مجزایی بهره گرفته می‌شود. در این راستا، تمامی ترکیب‌های سرعت فن و مقدار

فرکانس به نحوی تعیین شده، که به ازای هر سرعت فن، تمامی سطوح از فرکانس پردازنده به ترتیب انتخاب شده و در حین اجرای برنامه‌ی محک بر روی پردازنده اعمال شوند. به دلیل محدودیت‌های مکانیکی فن، سرعت آن به آهستگی و در سطوح مشخصی، به ترتیب از کم به زیاد افزایش و از زیاد به کم کاهش می‌یابد. اما، میزان تغییرات فرکانس تصادفی بوده تا تغییرات متفاوتی در دمای پردازنده ایجاد گردد. بدین منظور، ابتدا با استفاده از تابع *Shuffle*، لیست سطوح فرکانسی به هم آمیخته می‌شود. به بیانی دیگر، این تابع ترتیب مقادیر موجود در مجموعه‌ی فرکانسی را تغییر داده، تا لیست آن‌ها به صورت صعودی یا نزولی مرتب نباشد. سپس، در لیست جدید به ترتیب، فرکانس‌ها انتخاب شده و به پردازنده اعمال می‌شوند. این تغییرات متفاوت مقدار فرکانس، باعث ایجاد رفتارهایی دمایی متفاوت در پردازنده می‌گردد.

پس از تغییر فرکانس پردازنده، به مدت ۱۰ ثانیه تغییری در فرکانس پردازنده و سرعت فن انجام نشده و در این حین تغییراتی که در دمای پردازنده دیده می‌شود ناشی از تغییرات بارکاری است. تغییرات فرکانس حداکثر تا ۲ ثانیه‌ی آینده اثر خود را بر دما می‌گذارد. از طرفی تغییرات سرعت فن نیز تا ۵ ثانیه اثر خود را بر دما اعمال می‌کند. زمان انتظار بیشتر در الگوریتم برای این است که اثر تغییرات بارکاری بر دما نیز در مجموعه داده ثبت شود.

### ۳-۲- آماده‌سازی مجموعه داده

برای انتخاب پارامترهای ورودی مدل دمایی، پردازش‌هایی بر روی داده‌های جمع‌آوری شده انجام شده است. در این راستا، تعداد قابل توجهی از مقادیر آماری مختلف ارائه شده‌اند که استفاده از آن‌ها می‌تواند تأثیر قابل توجهی در پیش‌بینی دما داشته باشد. برخی از این پارامترها، می‌توانند از طریق ثبت کردن اطلاعات سیستم و برخی دیگر با انجام پردازش بر روی داده‌های جمع‌آوری شده، ایجاد شوند.

دو جنبه‌ی مختلف در تحلیل رویدادهای سیستم وجود دارد. از یک سو، می‌توان رویدادهایی از سیستم را صرف نظر از مقادیر پیش‌بینشان تعیین کرد. از سوی دیگر، رویدادهایی وجود دارند که وابسته به ترتیب

رویدادهای قبلی می‌باشند. در حالت اول، ترتیب نمونه‌ها در مجموعه‌ی داده‌ی ورودی، الگوی معنی‌دار مشخصی ندارد. در این حالت، به هم زدن نمونه‌ها در مجموعه‌داده ورودی، تأثیری در عملکرد مدل ندارد. حالت دوم، بر وابستگی بین نمونه‌های متوالی تکیه داشته و هر نمونه می‌تواند با پردازشی بر روی سری نمونه‌های قبلی، پیش‌بینی شود.

با یک نگاه دقیق، می‌توان رفتار دمایی پردازنده را به حالت دوم نسبت داد. بنابراین، در نظر گرفتن حالت‌های قبلی سیستم، هم‌زمان با حالت فعلی آن می‌تواند پیش‌بینی مطمئن‌تری را فراهم کند. در این راستا، تلاش شده است تا ویژگی‌های جدیدی را از مقادیر آماری اندازه‌گیری شده، ایجاد کرده تا شامل تاریخچه‌ی حالت‌های سیستم برای یک نمونه باشد. در روش پیشنهادی، هر نمونه شامل دو گروه از پارامترها است: سابقه‌ای و کنترلی. پارامترهای سابقه‌ای، تکیه بر رفتار سخت‌افزاری پردازنده و نرم‌افزار در حال اجرا بر روی آن دارد. به‌طور کلی، پیگیری سابقه‌ی اخیر این پارامترها، می‌تواند مدلی از تأثیرات سخت‌افزار و نرم‌افزار بر رفتار دمایی را ارائه دهد. تقریباً تمامی این نوع پارامترها، ریشه در طبیعت طراحی سخت‌افزاری و نرم‌افزاری داشته و اغلب به‌صورت مستقیم توسط زمان‌بند سیستم‌عامل قابل کنترل نیستند. به‌عنوان مثال، مقادیر دریافتی از حسگرهای دمایی و شمارنده‌های کارایی، نمونه‌هایی از پارامترهای سابقه‌ای بوده، که وابسته به مدل پردازنده و برنامه‌ی در حال اجرا است. در مقابل، پارامترهای کنترلی به‌صورت مستقیم زیر نظر سیستم‌عامل می‌باشند. اغلب، مقدار پارامترهای کنترلی زمانی تغییر می‌کند که زمان‌بند سیستم‌عامل واکنشی را انجام می‌دهد. به‌عنوان مثال، فرکانس پردازنده تغییر نمی‌کند تا زمانی که زمان‌بند با سازوکار DVFS مقداری را برای آن تنظیم کند. مقادیر بعدی پارامترهای کنترلی بر اساس تصمیم‌های آینده زمان‌بند سیستم‌عامل و با توجه به وضعیت دما و کارایی سیستم تعیین می‌شوند.

در این رساله، برای هر پارامتر، آخرین مقادیر آن، به‌عنوان تعدادی از پارامترهای سابقه‌ای به مجموعه‌داده افزوده می‌شود. همچنین، با انجام پردازش‌هایی بر روی مجموعه‌داده‌ی اولیه، تعدادی دیگر از پارامترهای

سابقه‌ای ایجاد می‌گردند. به‌طور مشخص، برای ایجاد پارامترهای سابقه‌ای، از تابع گرادیان استفاده می‌گردد. گرادیان پارامتر  $p$  با فاصله‌ی  $d$  با رابطه‌ی ۲-۳ محاسبه می‌شود.

$$\nabla p_t(d) = \frac{p_t - p_{t-d}}{d} \quad (2-3)$$

$p_t$  مقدار پارامتر در نمونه‌ی  $t$  و  $p_{t-d}$  مقدار همان پارامتر در  $d$  نمونه‌ی قبلی است. گرادیان اول، بر روی مقدار اندازه‌گیری شده از پارامترها محاسبه می‌شود. از طرفی، گرادیان دوم با بهره‌گیری از رابطه‌ی ۲-۳ بر روی گرادیان اول محاسبه می‌گردد.

می‌توان به این نکته اشاره کرد که گرادیان اول، میانگین سرعت تغییرات در طی  $d$  نمونه‌ی متوالی است درحالی‌که گرادیان دوم میانگین شتاب تغییرات در همان بازه است. با در نظر گرفتن این واقعیت که تغییرات آینده یک پارامتر ممکن است در امتداد رفتار پیشین آن باشد، استفاده از گرادیان‌های اول و دوم یک پارامتر، به‌عنوان ورودی‌های مدل پیش‌بینی دما، می‌تواند اطلاعات رفتاری غنی‌تری را برای یادگیری مدل فراهم آورد. بنابراین، گرادیان‌های پارامترهای اولیه با فاصله‌های زمانی مختلف با مقادیر اولیه‌شان، به‌عنوان ویژگی‌های سابقه‌ای در مجموعه‌ی داده‌ی آموزش قرار داده می‌شوند.

از طرفی، پارامترهای کنترلی نیز برای تکمیل مجموعه‌داده به آن اضافه می‌گردند. برای محاسبه‌ی این پارامترها، مفهومی تحت عنوان گرادیان‌های آینده در این رساله پیشنهاد شده است. گرادیان آینده‌ی پارامتر کنترلی  $p$  با رابطه‌ی زیر محاسبه می‌شود:

$$\widehat{\nabla} p_t = p_{t+1} - p_t \quad (3-3)$$

که  $p_t$  مقدار پارامتر در نمونه‌ی  $t$  و  $p_{t+1}$  مقدار همان پارامتر در نمونه‌ی بعدی است. واضح است که گرادیان آینده، تغییرات مورد انتظار برای مقدار پارامتر در آینده است. از آنجایی‌که زمان‌بند مقادیر آینده‌ی این پارامترها را تنظیم می‌کند، محاسبه‌ی این تغییرات به‌سادگی انجام می‌شود. به‌عنوان مثال، اغلب زمان‌بند نیاز دارد که دمای آینده را برای تنظیم فرکانس‌های مختلف پردازنده بداند. دمای ایجادشده در اثر تغییر پارامترهای کنترلی را پاسخ کنترلی می‌نامند. در این حالت، فرکانس‌های مختلف

توسط زمان‌بند به مدل دمایی داده شده تا با توجه به دمای پیش‌بینی مدل، مقدار مناسب برای فرکانس آینده را انتخاب کند. به‌طور دقیق‌تر، گرادیان‌های آینده می‌توانند با فراهم کردن اثر تغییرات آتی مقادیر پارامترهای کنترلی، به شکل دادن یک تصویر واضح‌تر از آینده کمک کنند.

یک مرحله‌ی اساسی برای تشکیل یک مجموعه‌ی داده‌ی معتبر، تعیین مقادیر هدف، برای هر نمونه از مجموعه‌داده است. در مجموعه‌داده‌ی مناسب برای پیش‌بینی دما، مقدار هدف برای هر نمونه، دمای آینده‌ی مشاهده‌شده برای آن است. از آنجایی که مدل پیشنهادی، دما را با یک فاصله‌ی مطلوب پیش‌بینی می‌کند، نیاز به تعیین دمای هدف متناظر برای هر نمونه است. بنابراین، مقدار دمای هدف با فاصله‌ی  $d$  نسبت به دمای  $t_i$  برای نمونه‌ی  $i$ ام است. همان‌گونه که مشخص است، مقدار  $d$  باید با توجه به فاصله‌ی زمانی پیش‌بینی و بازه‌های نمونه‌گیری و با رابطه‌ی  $d = \left\lceil \frac{\tau}{I} \right\rceil$  تعیین شود.  $\tau$  فاصله‌ی زمانی بین نمونه‌ی جاری و نقطه‌ی پیش‌بینی هدف است. همچنین،  $I$  بازه‌ی زمانی نمونه‌گیری با واحد زمانی  $\tau$  است.

درنهایت، برای یکسان کردن مقیاس پارامترها، مرحله‌ی نرمال‌سازی انجام شده است. برای نرمال‌سازی پارامترها که شامل تعیین مقدار هر پارامتر در بازه‌ی بین صفر و یک است، از رابطه‌ی ساده زیر استفاده می‌شود:


$$\eta_{i,j} = \frac{v_{i,j} - \min(V_j)}{\max(V_j) - \min(V_j)} \quad (4-3)$$

که  $V_j$  مجموعه‌ی مقادیر پارامتر  $j$ ام و  $v_{i,j} \in V_j$  که  $i$  شماره‌ی نمونه در مجموعه‌داده است.  $\eta_{i,j}$  مقدار نرمال شده‌ی نمونه‌ی  $i$ ام از پارامتر  $j$  است.

### ۳-۳- ساختار مدل

مدل پیشنهادی برای پیش‌بینی دما، MLP سه لایه بوده، که در شکل ۳-۲ نمایش داده شده است. ورودی‌های مدل شامل مقادیر پارامترهای سابقه‌ای دمای هسته‌ی هدف، دمای هسته‌های مجاور و





شکل ۳-۲: ساختار شبکه MLP برای پیش‌بینی دما

مقدارهای شمارنده‌های کارایی و گرادیان آن‌ها در فاصله‌های زمانی  $\{1, 2, 3\}$  ثانیه است. همچنین مقدارهای پارامترهای کنترلی، شامل فرکانس پردازنده، سرعت فن خنک‌کننده و گرادیان آینده‌ی آن‌ها نیز به‌عنوان ورودی به مدل داده می‌شود. خروجی مدل، دمای پیش‌بینی‌شده با فاصله‌ی  $d \geq 1$  است.

### ۳-۴- ارزیابی مدل

در مرحله‌ی پیاده‌سازی، از روش اعتبارسنجی کتایی<sup>۱</sup>، برای انتخاب مجموعه‌های آموزش و آزمایش استفاده شده است. در این رویکرد  $k$  مرحله‌ای، مجموعه‌داده به  $k$  دسته متمایز تقسیم‌بندی می‌شود. در هر مرحله،  $k - 1$  دسته برای آموزش مدل و یک دسته برای آزمایش مدل انتخاب می‌شوند. البته، پیش از تقسیم‌بندی داده‌ها، ابتدا جایگشتی بر روی مجموعه‌داده انجام شده تا نمونه‌ها به‌هم‌ریخته شوند. این به‌هم‌ریختگی باعث تنوع نمونه‌ها در توزیع داده‌ها می‌شود.

در این رساله، برای بررسی دقت پیش‌بینی‌های مدل دمایی پیشنهادی، از معیارهای میانگین قدر مطلق خطا<sup>۲</sup> (MAE)، انحراف معیار قدرمطلق خطا<sup>۳</sup> (SDAE) و مقدار احتمال خطاهای خارج از محدوده<sup>۴</sup> (POE) استفاده شده است. معیار MAE با رابطه‌ی ۳-۵ محاسبه می‌شود.

<sup>1</sup> K-fold Cross Validation

<sup>2</sup> Mean Absolute Error

<sup>3</sup> Standard Deviation Absolute Error

<sup>4</sup> Percentage of Outlier Errors

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad (5-3)$$

$N$  تعداد نمونه‌ها،  $t_i$  دمای هدف و  $y_i$  دمای پیش‌بینی شده برای نمونه‌ی  $i$ ام است. همچنین، SDAE با رابطه‌ی ۶-۳ محاسبه می‌شود.

$$SDAE = \sqrt{\frac{1}{N} \sum_{i=1}^N (|t_i - y_i| - MAE)^2} \quad (6-3)$$

درنهایت، احتمال خطاهای بیش از  $x$  درجه سانتی‌گراد با رابطه‌ی ۷-۳ محاسبه می‌گردد.

$$POE(x) = \frac{|\{ |t_i - y_i| \geq x \mid \forall t_i \in S, \forall y_i \in Y, i \in \{1, 2, \dots, |S|\} \}|}{|S|} \quad (7-3)$$

که در آن  $S$  مجموعه‌ی مورد آزمون و  $Y$  مجموعه‌ی پیش‌بینی‌های مدل است.

همان‌طور که پیش‌تر اشاره شد، برای ورودی‌های مدل دمایی، افزون بر مقدار فرکانس پردازنده، سرعت فن، دمای هسته‌های پردازنده و شمارنده‌های کارایی هسته‌ی هدف، از ویژگی‌های سابقه‌ای و کنترلی نیز استفاده می‌شود. ویژگی‌های سابقه‌ای مورد استفاده در ایجاد مدل دمایی، شامل دمای هسته‌ها و مقدار شمارنده‌های کارایی برای  $\{1, 2, 3\}$  ثانیه قبل است. همچنین، مقدار گرادیان اول و دوم نیز برای همان بازه‌ی ۳ ثانیه‌ای، به‌عنوان ویژگی‌های سابقه‌ای در نظر گرفته شده است. دلیل استفاده از بازه‌ی ۳ ثانیه در مدل پیشنهادی این است که در سیستم مورد آزمایش، در اثر تغییر هر یک از پارامترهای مؤثر بر دما، حداکثر تا ۳ ثانیه، اثر آن بر دمای سیستم اعمال می‌شود. پارامترهای کنترلی مورد بررسی در مدل پیشنهادی، مقدار تغییرات مربوط به فرکانس و سرعت فن است. مجموعه‌ی همه‌ی پارامترهای معرفی‌شده شامل ۱۲۸ پارامتر است که به‌عنوان ویژگی‌ها و ورودی‌های مدل دمایی مورد استفاده قرار می‌گیرد.

برای ارزیابی اثر استفاده از پارامترهای سابقه‌ای و کنترلی، با توجه به مجموعه داده جمع‌آوری‌شده، در

دو حالت مختلف پیش‌بینی دما با استفاده از شبکه عصبی انجام شده است. نتایج این ارزیابی در جدول ۲-۳ نمایش داده شده است. در حالت اول، ورودی‌های شبکه‌ی MLP تنها شامل حالت فعلی سیستم است. حالت فعلی سیستم شامل اطلاعاتی است که توسط حسگرهای سیستم در هر لحظه خوانده می‌شوند. این اطلاعات شامل فرکانس و دمای هسته‌های پردازنده، سرعت فن و شمارنده‌های کارایی هسته‌ی هدف است. تعداد این ویژگی‌ها ۱۹ عدد است. در حالت دوم، از ویژگی‌های سابقه‌ای و کنترلی نیز استفاده می‌گردد. با توجه به نتایج حاصل‌شده، استفاده از ویژگی‌های سابقه‌ای و کنترلی تأثیر قابل‌توجهی بر دقت پیش‌بینی دما ایجاد کرده است. لازم به ذکر است که ساختار شبکه عصبی از جمله تعداد نرون‌ها و نوع تابع فعالیت آن‌ها، با انجام آزمایش‌های مختلف انتخاب شده است. جزئیات بیشتر در مورد ساختار مورد استفاده، در فصل ارزیابی و نتایج آزمایش‌ها ارائه گردیده است.

جدول ۲-۳: اثر استفاده از ویژگی‌های سابقه‌ای و کنترلی در پیش‌بینی دمای ۵ ثانیه آینده

نوع ورودی‌ها	تعداد ورودی‌ها	MAE (°C)	SDAE (°C)	POE(3)
حالت اول	۱۹	۲/۳۶	۳/۰۸	۱۷٪
حالت دوم	۱۲۸	۱/۲۳	۱/۷۷	۸٪

به‌طور کلی در یادگیری ماشین، تعداد زیاد ورودی‌های مدل، باعث کاهش تعمیم مدل و افزایش سربار محاسباتی آن می‌شود. کاهش تعمیم، به معنی کاهش انطباق مدل با داده‌هایی است که آموزش مدل با آن‌ها انجام نشده است. به‌خصوص در مدل پیشنهادی، که با تعداد محدودی از حالت‌های سیستم آموزش انجام می‌شود، کاهش تعداد ویژگی‌های ورودی، می‌تواند باعث افزایش دقت مدل پیش‌بینی گردد. استفاده از مقدار همبستگی ویژگی‌های ورودی نسبت به خروجی مدل، یکی از روش‌های انتخاب ویژگی برای مدل دمایی است. در این راستا، برای ۱۲۸ ویژگی، مقدار همبستگی آن‌ها با دمای ۵ ثانیه آینده در جداول ۳-۳ و ۴-۳ نمایش داده شده‌اند.

جدول ۳-۳: مقدار همبستگی ویژگی‌های مدل دمایی با دمای ۲ ثانیه‌ی آینده

همبستگی	ویژگی	همبستگی	ویژگی	همبستگی	ویژگی
-۰/۰۱۸	گرادیان اول ۳ ثانیه قبل <i>SCB</i>	-۰/۰۰۱	گرادیان اول ۳ ثانیه قبل <i>CM</i>	۰/۴۷۶	<i>Freq</i>
-۰/۰۴۱	گرادیان دوم ۱ ثانیه قبل <i>SCB</i>	-۰/۰۰۲	گرادیان دوم ۱ ثانیه قبل <i>CM</i>	-۰/۰۰۵	<i>FS</i>
-۰/۰۴۱	گرادیان دوم ۲ ثانیه قبل <i>SCB</i>	-۰/۰۰۲	گرادیان دوم ۲ ثانیه قبل <i>CM</i>	۰/۹۶۹	<i>PT0</i>
۰/۳۶۲	<i>Inst</i> یک ثانیه قبل	۰/۰۲۶	<i>PF</i> یک ثانیه قبل	۰/۹۴۴	<i>PT1</i>
۰/۳۲۳	<i>Inst</i> دو ثانیه قبل	۰/۰۳۷	<i>PF</i> دو ثانیه قبل	۰/۹۴۵	<i>PT2</i>
۰/۲۷۷	<i>Inst</i> سه ثانیه قبل	۰/۰۳۶	<i>PF</i> سه ثانیه قبل	۰/۹۰۵	<i>PT3</i>
-۰/۰۲۸	گرادیان اول ۱ ثانیه قبل <i>Inst</i>	۰/۰۰۴	گرادیان اول ۱ ثانیه قبل <i>PF</i>	۰/۰۰۶	<i>CS</i>
-۰/۰۲۸	گرادیان اول ۲ ثانیه قبل <i>Inst</i>	۰/۰۰۴	گرادیان اول ۲ ثانیه قبل <i>PF</i>	۰/۰۰۳	<i>CM</i>
-۰/۰۲۸	گرادیان اول ۳ ثانیه قبل <i>Inst</i>	۰/۰۰۴	گرادیان اول ۳ ثانیه قبل <i>PF</i>	۰/۰۳۲	<i>PF</i>
-۰/۰۸۴	گرادیان دوم ۱ ثانیه قبل <i>Inst</i>	۰/۰۰۷	گرادیان دوم ۱ ثانیه قبل <i>PF</i>	۰/۴۲۵	<i>Cyc</i>
-۰/۰۸۴	گرادیان دوم ۲ ثانیه قبل <i>Inst</i>	۰/۰۰۷	گرادیان دوم ۲ ثانیه قبل <i>PF</i>	۰/۲۸۵	<i>SCF</i>
۰/۱۱۷	<i>Br</i> یک ثانیه قبل	۰/۴۳۱	<i>Cyc</i> یک ثانیه قبل	۰/۰۹۵	<i>SCB</i>
۰/۱۵۵	<i>Br</i> دو ثانیه قبل	۰/۳۸۳	<i>Cyc</i> دو ثانیه قبل	۰/۳۵۸	<i>Inst</i>
۰/۱۳۶	<i>Br</i> سه ثانیه قبل	۰/۳۲۷	<i>Cyc</i> سه ثانیه قبل	۰/۱۶۹	<i>Br</i>
-۰/۰۰۷	گرادیان اول ۱ ثانیه قبل <i>Br</i>	-۰/۱۴۷	گرادیان اول ۱ ثانیه قبل <i>Cyc</i>	۰/۱۳۸	<i>MBr</i>
-۰/۰۰۷	گرادیان اول ۲ ثانیه قبل <i>Br</i>	-۰/۱۴۷	گرادیان اول ۲ ثانیه قبل <i>Cyc</i>	۰/۰۶۸	<i>CRef</i>
-۰/۰۰۷	گرادیان اول ۳ ثانیه قبل <i>Br</i>	-۰/۱۴۷	گرادیان اول ۳ ثانیه قبل <i>Cyc</i>	-۰/۰۵۲	<i>IO</i>
-۰/۰۳۴	گرادیان دوم ۱ ثانیه قبل <i>Br</i>	-۰/۱۰۳	گرادیان دوم ۱ ثانیه قبل <i>Cyc</i>	۰/۳۵۸	<i>L1Ref</i>
-۰/۰۳۴	گرادیان دوم ۲ ثانیه قبل <i>Br</i>	-۰/۱۰۳	گرادیان دوم ۲ ثانیه قبل <i>Cyc</i>	-۰/۰۰۲	<i>CMiss</i>
۰/۱۱۴	<i>MBr</i> یک ثانیه قبل	۰/۲۸۹	<i>SCF</i> یک ثانیه قبل	۰/۰۰۱	<i>CS</i> یک ثانیه قبل
۰/۱۲۶	<i>MBr</i> دو ثانیه قبل	۰/۲۵۶	<i>SCF</i> دو ثانیه قبل	۰/۰۰۲	<i>CS</i> دو ثانیه قبل
۰/۱۱۱	<i>MBr</i> سه ثانیه قبل	۰/۲۱۶	<i>SCF</i> سه ثانیه قبل	۰/۰۰۳	<i>CS</i> سه ثانیه قبل
-۰/۰۰۹	گرادیان اول ۱ ثانیه قبل <i>MBr</i>	-۰/۰۴۳	گرادیان اول ۱ ثانیه قبل <i>SCF</i>	-۰/۰۰۱	گرادیان اول ۱ ثانیه قبل <i>CS</i>
-۰/۰۰۹	گرادیان اول ۲ ثانیه قبل <i>MBr</i>	-۰/۰۴۳	گرادیان اول ۲ ثانیه قبل <i>SCF</i>	-۰/۰۰۱	گرادیان اول ۲ ثانیه قبل <i>CS</i>
-۰/۰۰۹	گرادیان اول ۳ ثانیه قبل <i>MBr</i>	-۰/۰۴۳	گرادیان اول ۳ ثانیه قبل <i>SCF</i>	-۰/۰۰۱	گرادیان اول ۳ ثانیه قبل <i>CS</i>
-۰/۰۳۶	گرادیان دوم ۱ ثانیه قبل <i>MBr</i>	-۰/۰۸۸	گرادیان دوم ۱ ثانیه قبل <i>SCF</i>	-۰/۰۰۴	گرادیان دوم ۱ ثانیه قبل <i>CS</i>
-۰/۰۳۶	گرادیان دوم ۲ ثانیه قبل <i>MBr</i>	-۰/۰۸۸	گرادیان دوم ۲ ثانیه قبل <i>SCF</i>	-۰/۰۰۴	گرادیان دوم ۲ ثانیه قبل <i>CS</i>
۰/۰۷۲	<i>CRef</i> یک ثانیه قبل	۰/۱۰۲	<i>SCB</i> یک ثانیه قبل	۰/۰۶۱	<i>CM</i> یک ثانیه قبل
۰/۰۰۷	<i>CRef</i> دو ثانیه قبل	۰/۰۷۸	<i>SCB</i> دو ثانیه قبل	۰/۰۲۸	<i>CM</i> دو ثانیه قبل
۰/۰۶۶	<i>CRef</i> سه ثانیه قبل	۰/۰۴۸	<i>SCB</i> سه ثانیه قبل	۰/۰۲۷	<i>CM</i> سه ثانیه قبل
-۰/۰۰۷	گرادیان اول ۱ ثانیه قبل <i>CRef</i>	-۰/۰۱۸	گرادیان اول ۱ ثانیه قبل <i>SCB</i>	-۰/۰۰۱	گرادیان اول ۱ ثانیه قبل <i>CM</i>
-۰/۰۰۷	گرادیان اول ۲ ثانیه قبل <i>CRef</i>	-۰/۰۱۸	گرادیان اول ۲ ثانیه قبل <i>SCB</i>	-۰/۰۰۱	گرادیان اول ۲ ثانیه قبل <i>CM</i>

جدول ۳-۴: ادامه‌ی نمایش مقدار همبستگی ویژگی‌های مدل دمایی با دمای ۲ ثانیه‌ی آینده

همبستگی	ویژگی	همبستگی	ویژگی
-۰/۰۲۵	گرادیان اول ۳ ثانیه قبل <i>L1Ref</i>	-۰/۰۰۷	گرادیان اول ۳ ثانیه قبل <i>CRef</i>
-۰/۰۰۸	گرادیان دوم ۱ ثانیه قبل <i>L1Ref</i>	-۰/۰۰۶	گرادیان دوم ۱ ثانیه قبل <i>CRef</i>
-۰/۰۰۸	گرادیان دوم ۲ ثانیه قبل <i>L1Ref</i>	-۰/۰۰۶	گرادیان دوم ۲ ثانیه قبل <i>CRef</i>
-۰/۰۱۹	<i>CMiss</i> یک ثانیه قبل	-۰/۰۵۶	<i>IO</i> یک ثانیه قبل
-۰/۰۲۱	<i>CMiss</i> دو ثانیه قبل	-۰/۰۴۸	<i>IO</i> دو ثانیه قبل
-۰/۰۱۶	<i>CMiss</i> سه ثانیه قبل	-۰/۰۳۹	<i>IO</i> سه ثانیه قبل
-۰/۰۰۲	گرادیان اول ۱ ثانیه قبل <i>CMiss</i>	۰/۰۰۱	گرادیان اول ۱ ثانیه قبل <i>IO</i>
-۰/۰۰۲	گرادیان اول ۲ ثانیه قبل <i>CMiss</i>	۰/۰۰۱	گرادیان اول ۲ ثانیه قبل <i>IO</i>
-۰/۰۰۲	گرادیان اول ۳ ثانیه قبل <i>CMiss</i>	۰/۰۰۱	گرادیان اول ۳ ثانیه قبل <i>IO</i>
-۰/۰۰۳	گرادیان دوم ۱ ثانیه قبل <i>CMiss</i>	۰/۰۰۳	گرادیان دوم ۱ ثانیه قبل <i>IO</i>
-۰/۰۰۳	گرادیان دوم ۲ ثانیه قبل <i>CMiss</i>	۰/۰۰۳	گرادیان دوم ۲ ثانیه قبل <i>IO</i>
۰/۱۴۱	گرادیان اول ۱ ثانیه قبل <i>PTO</i>	۰/۳۶۲	<i>L1Ref</i> یک ثانیه قبل
۰/۱۵۹	گرادیان اول ۲ ثانیه قبل <i>PTO</i>	۰/۳۲۳	<i>L1Ref</i> دو ثانیه قبل
۰/۱۷۶	گرادیان اول ۳ ثانیه قبل <i>PTO</i>	۰/۲۷۸	<i>L1Ref</i> سه ثانیه قبل
۰/۰۴۸	گرادیان آینده فرکانس	-۰/۰۲۵	گرادیان اول ۱ ثانیه قبل <i>L1Ref</i>
۰/۰۱۷	گرادیان آینده سرعت فن	-۰/۰۲۵	گرادیان اول ۲ ثانیه قبل <i>L1Ref</i>

از طرفی، برای انتخاب ویژگی‌های مناسب برای مدل دمایی نیاز است که علاوه بر توجه به همبستگی هر ویژگی با دمای آینده، همبستگی بین ویژگی‌های ورودی نیز بررسی شود. در این راستا، ویژگی‌ها با توجه به بیشینه‌سازی معیار وابستگی آماری با دمای آینده و کمینه کردن اطلاعات متقابل<sup>۱</sup> (MI) در بین مجموعه ویژگی‌های انتخابی، انتخاب می‌شوند. در این راستا، MI بین دو ویژگی  $x$  و  $y$  با رابطه ۳-۸ محاسبه می‌شود.

$$I(x; y) = \iint p(x, y) \log \frac{p(x)}{p(x)p(y)} dx dy \quad (۸-۳)$$

$p(x)$ ،  $p(y)$  و  $p(x, y)$  توابع چگالی احتمال متغیرهای  $x$ ،  $y$  و وقوع هم‌زمان آن‌ها می‌باشند. برای محاسبه‌ی حداکثر وابستگی، همه زیرمجموعه‌های ممکن از مجموعه ویژگی‌های اولیه، با استفاده از رابطه ۳-۸ و با توجه به خروجی مدل، مورد بررسی قرار می‌گیرند. رابطه ۳-۹ برای محاسبه زیرمجموعه‌ی

<sup>1</sup> Mutual Information

ویژگی‌ها با بیش‌ترین مقدار وابستگی، استفاده می‌شود [40].

$$\max V_I(S, h), \quad V_I = \frac{1}{|S|} \sum_{i \in S} I(i, h) \quad (9-3)$$

$S$  زیرمجموعه‌ای از ویژگی‌های اولیه و  $V_I$  مقدار وابستگی  $S$  را با خروجی مدل ( $h$ ) نشان می‌دهد. انتخاب زیرمجموعه بر اساس بیش‌ترین وابستگی، می‌تواند شامل ویژگی‌هایی باشد که خود آن‌ها همبستگی بالایی باهم داشته باشند. بر این اساس، شرط حداقل افزونگی، برای یافتن زیرمجموعه‌ای از ویژگی‌ها با کمترین همبستگی با یکدیگر، ارائه گردیده، که با رابطه ۳-۱۰ محاسبه می‌شود [40].

$$\min W_I(S), \quad W_I = \frac{1}{|S|^2} \sum_{i, j \in S} I(i, j) \quad (10-3)$$

$W_I$  میانگین MI بین ویژگی‌ها در زیرمجموعه  $S$  است. با ترکیب دو رابطه ۳-۹ و ۳-۱۰، مفهومی تحت عنوان کمینه‌ی افزونگی بیشینه‌ی وابستگی<sup>۱</sup> (mRMR) معرفی گردیده است. اساس mRMR با رابطه‌ای ۳-۱۱ تعریف می‌شود [40].

$$\max \varphi(V, W), \quad \varphi = V - W \quad (11-3)$$

که  $\varphi(V, W)$  عملگری برای ترکیب روابط بیشینه‌ی وابستگی و کمینه‌ی افزونگی است. انتخاب لیست بهترین ویژگی‌ها برای مجموعه داده‌ای با تعداد زیادی ویژگی، به دلیل نمایی بودن تعداد محاسبه‌های لازم برای یافتن حداکثر مقدار  $\varphi(V, W)$ ، غیرعملی است. به همین دلیل روش‌هایی برای تخمین آن معرفی گردیده‌اند. از متداول‌ترین روش‌های تخمین mRMR، می‌توان به روش تفاضل اطلاعات متقابل<sup>۲</sup> (MID) اشاره کرد [45]. MID با رابطه ۳-۱۲ محاسبه می‌شود.

$$\max_{i \in \varphi(S)} [I(i, h) - \frac{1}{|S|} \sum_{j \in S} I(i, j)] \quad (12-3)$$

همچنین رابطه‌ی ۳-۱۳ تحت عنوان FCD برای تخمین mRMR برای متغیرهای پیوسته ارائه شده

<sup>1</sup> Minimum Redundancy Maximum Relevance

<sup>2</sup> Mutual Information Difference

است [45].

$$\max_{i \in \varphi(S)} [F(i, h) - \frac{1}{|S|} \sum_{j \in S} c(i, j)] \quad (13-3)$$

که  $c(i, j)$  مقدار همبستگی دو ویژگی  $i$  و  $j$  را نشان می‌دهد. تابع  $F$  با رابطه ۱۴-۳ تعریف شده است.

$$F(g_i, h) = \left[ \sum_k n_k (\bar{g}_k - \bar{g}) / (K - 1) \right] / \sigma^2 \quad (14-3)$$

مقدار تابع  $F$  برای متغیر  $g_i$ ، با توجه به  $K$  دسته‌ای که بر اساس  $h$  تعیین شده، محاسبه می‌شود.  $\bar{g}$  میانگین مقدار  $g_i$  در همه نمونه‌ها و  $\bar{g}_k$  میانگین مقدار در دسته‌ی  $k$ ام است. همچنین  $\sigma^2$  که واریانس تلفیقی است با رابطه‌ی ۱۵-۳ محاسبه می‌شود.

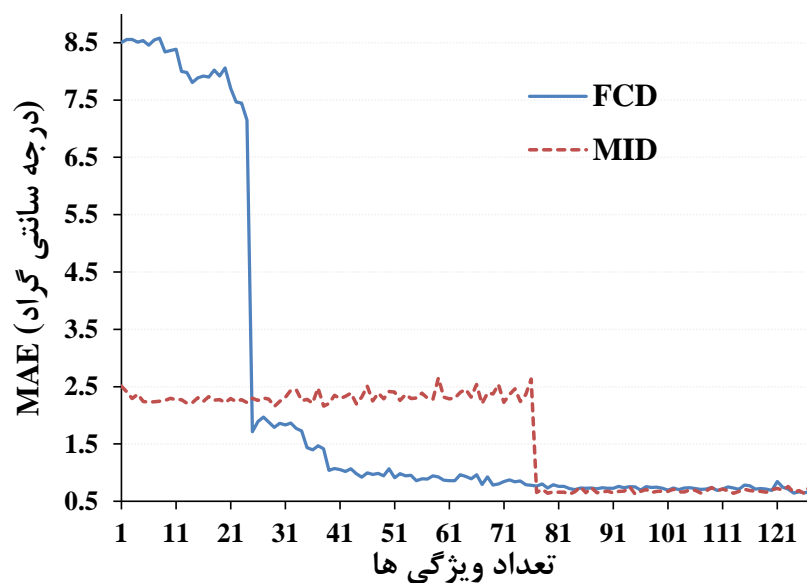
$$\sigma^2 = \left[ \sum_k (n_k - 1) \sigma_k^2 \right] / (n - K) \quad (15-3)$$

که  $\sigma_k^2$  و  $n_k$  واریانس و اندازه‌ی دسته‌ی  $k$ ام است.

از مزیت‌های استفاده از روابط تخمین mRMR می‌توان به این نکته اشاره کرد که با آنکه تخمین قابل‌قبولی از mRMR دارند، ولی پیچیدگی محاسباتی آن‌ها کم است. به بیانی دیگر، سربار پایین، سرعت بالا و قابلیت اطمینان بالا، باعث استفاده از این روش‌های تخمین برای انتخاب ویژگی‌های مناسب گردیده است.

برای انتخاب مجموعه‌ی مؤثر کمینه برای مدل دمایی، ویژگی‌های موجود در مجموعه داده ورودی را یکبار با استفاده از الگوریتم MID و بار دیگر با استفاده از FCD، در بردار  $\zeta$  بر اساس میزان وابستگی ویژگی‌ها با مقدار خروجی اولویت‌بندی می‌شوند. سپس در  $|\zeta|$  گام، زیرمجموعه‌هایی شامل  $1 \leq j \leq |\zeta|$  عنصر ابتدایی از  $\zeta$  را در مدل پیشنهادی ارزیابی کرده و میزان خطای پیش‌بینی برای هر یک اندازه‌گیری می‌گردد. در شکل ۳-۳ مقدار MAE برای پیش‌بینی دمای پنج ثانیه آینده، برای هر زیرمجموعه از ویژگی‌های انتخاب‌شده نمایش داده شده است. باید توجه داشت که برای استفاده از روش

MID نیاز به گسسته‌سازی داده‌ها است. بدین منظور با توجه به مقادیر بین کمینه و بیشینه‌ی دما در سیستم، تعداد بازه‌ها تعیین می‌شود. به‌عنوان مثال برای دمای کمینه ۳۰ و بیشینه ۱۰۰ درجه، تعداد بازه‌ها ۷۰ عدد تعیین می‌شود. در شکل ۳-۳، مشاهده می‌شود که با انتخاب بیش از ۴۰ ویژگی با روش FCD، خطای مدل به مقدار کم‌تر از ۱ درجه سانتی‌گراد می‌رسد. در صورتی که با روش MID نیاز به انتخاب بیش از ۷۰ ویژگی برای رسیدن به خطای کمتر از ۱ درجه است. به بیانی دیگر، روش FCD عملکرد بهتری را نسبت به MID برای انتخاب ویژگی‌های مدل دمایی ارائه می‌دهد. بر این اساس، به بررسی این روش پرداخته شده است.



شکل ۳-۳: مقایسه استفاده از روش‌های MID و FCD برای انتخاب ویژگی

### ۳-۵- الگوریتم پیشنهادی برای انتخاب ویژگی برای مدل دمایی

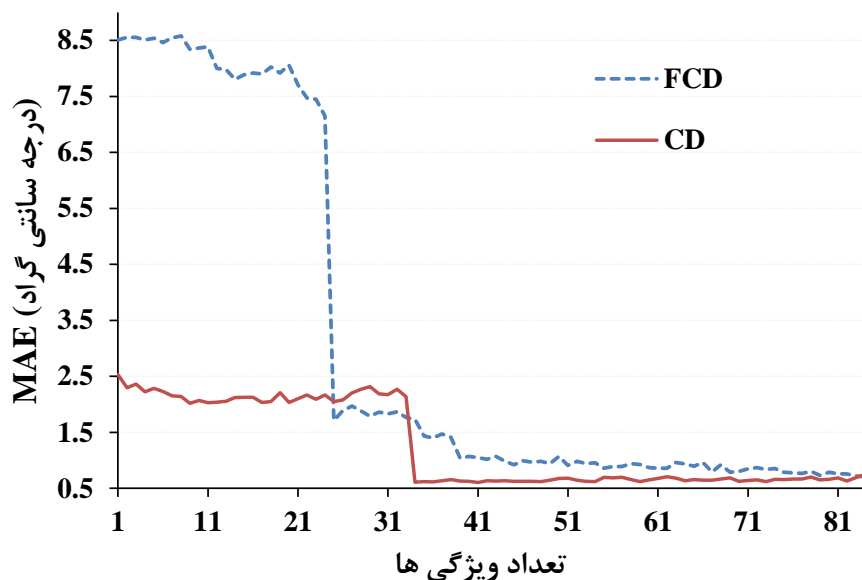
با توجه به شکل ۳-۳، تعداد ویژگی‌های انتخابی با استفاده از روش FCD نیز برای مدل دمایی کم نیست. بر این اساس، به بررسی رابطه‌ی FCD برای هر یک از ویژگی‌های مدل دمایی پرداخته شده است. برای اغلب ویژگی‌ها، مقدار تابع  $F'$  (رابطه ۳-۱۴) نزدیک به صفر به‌دست‌آمده است. پس، برای تعیین وابستگی بین ویژگی‌ها با خروجی مدل، معیارهای دیگر بررسی شدند. در این راستا، به‌جای تابع



F، رابطه همبستگی<sup>۱</sup> مورد ارزیابی قرار گرفت [46]. در این راستا، رابطه‌ی ۳-۱۶ به دست آمده، که در این رساله با نام اختلاف همبستگی<sup>۲</sup> (CD) مورد مراجعه قرار می‌گیرد.

$$\max_{i \in \varphi(S)} [c(i, h) - \frac{1}{|S|} \sum_{j \in S} c(i, j)] \quad (۱۶-۳)$$

برای مقایسه‌ی اولویت‌بندی ویژگی‌ها با دو روش CD و FCD، خطای مدل دمایی با توجه به افزایش تعداد ویژگی‌ها محاسبه شده است. مقدار MAE مربوط به استفاده از روش‌های CD و FCD در شکل ۳-۴ نمایش داده شده است. این شکل نشان می‌دهد که در صورت استفاده از روش CD، با انتخاب ۳۳ ویژگی می‌توان به حداقل خطای مدل دمایی دست یافت. به بیانی دیگر، با روش CD نسبت به FCD، علاوه بر کاهش تعداد ویژگی‌های موردنیاز برای مدل، خطای کمتری نیز برای آن حاصل می‌شود.



شکل ۳-۴: مقایسه استفاده از روش‌های CD و FCD برای انتخاب ویژگی‌های مدل دمایی

با نگاهی دقیق‌تر به رابطه‌ی CD می‌توان مثال‌هایی را یافت که در آن‌ها اولویت‌بندی نامطلوبی برای ویژگی‌ها، با استفاده از رابطه‌ی ارائه شده، انجام خواهد پذیرفت. به عنوان مثال، وضعیتی فرض شود که برای انتخاب ویژگی سوم، دو ویژگی کاندید وجود داشته باشند. برای کاندید اول، همبستگی آن با


<sup>1</sup> Correlation

<sup>2</sup> Correlation Difference

ویژگی‌های اولویت اول و دوم انتخابی، مقدارهای  $\{0/1, 0/9\}$  و مقدار همبستگی آن با خروجی  $0/5$  باشد. همچنین، برای کاندید دوم، همبستگی با اولویت‌های اول و دوم، مقدارهای  $\{0/6, 0/6\}$  و مقدار همبستگی آن با خروجی  $0/55$  باشد. در چنین حالتی CD، اولویت بیش‌تری به کاندید اول می‌دهد. درحالی‌که با توجه به مفهوم و تعریف همبستگی، کاندید دوم اهمیت بالاتری نسبت به کاندید اول دارد. برای رفع این مشکل، در این رساله، رابطه‌ی تخمین جدیدی برای mRMR با عنوان SCD، با رابطه‌ی ۱۷-۳ پیشنهاد شده است. این رابطه، اثر همبستگی بین مجموعه‌ی ویژگی‌های انتخابی را، با اهمیت بالاتری در تعیین اولویت ویژگی‌ها اثر می‌دهد.

$$\max_{i \in \varphi(S)} [c(i, h) - \frac{1}{|S|} \sum_{j \in S} c(i, j)^2] \quad (17-3)$$

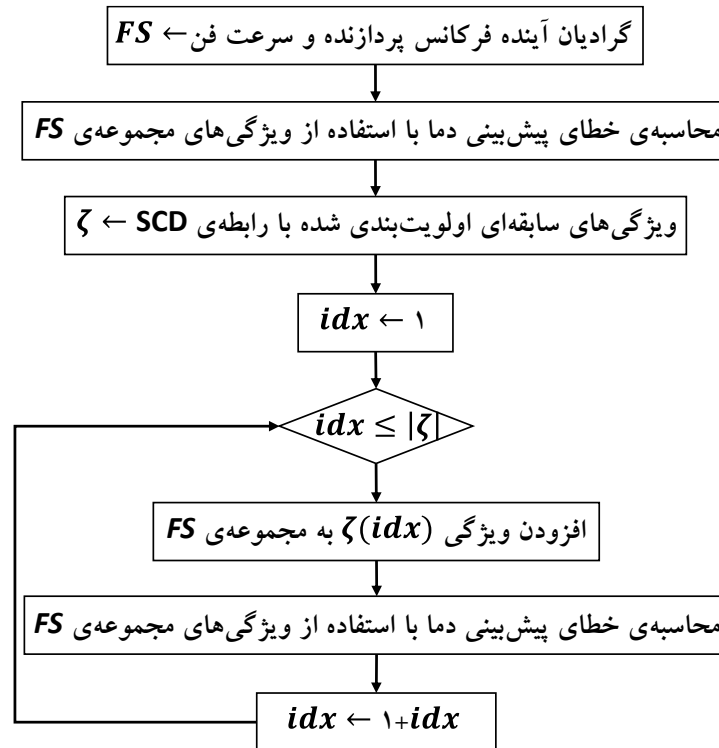
استفاده از توان ۲، باعث افزایش افزونگی ویژگی کاندیدی می‌شود که با مجموعه ویژگی‌های انتخاب شده، همبستگی بیش‌تر دارد. در شکل ۳-۵ مقدار MAE برای مقایسه رابطه‌ی پیشنهادی با رابطه‌های CD و FCD نمایش داده شده است. با توجه به شکل ۳-۵، روش پیشنهادی SCD ویژگی‌های بهتری را برای مدل پیش‌بینی دما انتخاب کرده و با تعداد کم‌تری ویژگی، کم‌ترین مقدار MAE برای مدل به دست



شکل ۳-۵: مقایسه استفاده از SCD با CD و FCD برای انتخاب ویژگی‌های مدل دمایی

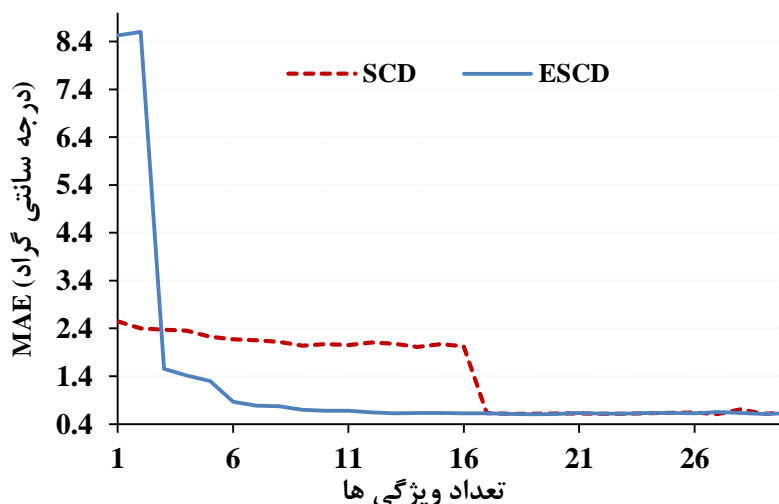


در این راستا، برای انتخاب ویژگی‌های مدل دمایی، الگوریتمی با عنوان ESCD پیشنهاد شده است. در این الگوریتم، گرادیان‌های آینده‌ی پارامترهای کنترلی، به‌عنوان اولین ویژگی‌های مدل پیش‌بینی دما انتخاب می‌شوند. باقی ویژگی‌ها با استفاده از روش SCD تعیین می‌گردند. نمودار جریان محاسبه‌ی خطای حاصل از افزایش تعداد ویژگی‌های انتخابی با روش ESCD در شکل ۳-۶ نمایش داده شده است.



شکل ۳-۶: محاسبه‌ی خطای مدل دمایی با افزایش تعداد ویژگی‌های انتخابی با الگوریتم ESCD

مقایسه نتایج حاصل از اولویت‌بندی ویژگی‌ها برای پیش‌بینی دمای ۵ ثانیه آینده، با روش‌های ESCD و SCD در شکل ۳-۷ نمایش داده شده است. با توجه به شکل، با استفاده از روش پیشنهادی ESCD با تعداد بسیار کمی از ویژگی‌ها می‌توان به حداقل مقدار MAE برای مدل پیش‌بینی دما دست یافت. درنهایت، باید به این نتیجه اشاره کرد که مدل پیشنهادی با انتخاب تعداد ویژگی پایین، دقت بالایی را در پیش‌بینی دما ارائه می‌کند.



شکل ۳-۷: مقایسه استفاده از ESCD با SCD برای انتخاب ویژگی‌های مدل پیش‌بینی دما

### ۳-۶- جمع‌بندی

در این فصل، شبکه عصبی MLP برای پیش‌بینی دمای یک هسته در سیستم چندهسته‌ای پیشنهاد شده است. تعدادی از ورودی‌های این مدل، شامل دمای هسته‌ها، فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی هسته‌ی هدف است. برای افزایش دقت مدل، ویژگی‌های دیگری، با پردازش چند نمونه‌ی متوالی از داده‌ها ایجاد شده‌اند. در این راستا، برای هر ورودی، گرادیان‌های اول و دوم آن تا ۳ ثانیه قبل محاسبه شده است. همچنین، برای اینکه بتوان از مدل برای پیش‌بینی پاسخ کنترلی در اثر تغییر فرکانس پردازنده و سرعت فن استفاده کرد، ورودی‌هایی با عنوان گرادیان‌های آینده به مدل داده می‌شوند. به علت زیاد بودن تعداد این مجموعه ورودی‌ها، انتخاب ویژگی‌ها با هدف حداکثر وابستگی و حداقل افزونگی انجام گردیده است. در این راستا دو روش جدید با نام‌های SCD و ESCD معرفی شده‌اند. با استفاده از ویژگی‌های انتخابی، میانگین قدر مطلق خطا برای ۵ ثانیه آینده کم‌تر از ۰/۷ درجه سانتی‌گراد است. معیارهای انحراف معیار قدرمطلق خطاها و درصد خطای پیش‌بینی بالای ۳ درجه سانتی‌گراد نیز، برای بررسی دقت مدل مورد توجه قرار گرفته است.



# فصل

۴- مدل پیشنهادی برخط برای

پیش‌بینی دما

در این فصل به ارائه مدلی برای پیش‌بینی برخط دما پرداخته شده است. به دلیل وجود رفتارهای دمایی متفاوت در پردازنده و از آنجایی که ایجاد همه‌ی این رفتارها به‌صورت برون‌خط غیرعملی است، به ارائه یک مدل دمایی پرداخته شده که از تعدادی شبکه عصبی برای پیش‌بینی دما بهره می‌برد. در این راستا، رفتار دمایی پردازنده به فازهای مختلفی تقسیم‌بندی می‌شود. برای هر فاز، از یک شبکه‌ی عصبی برای پیش‌بینی دما استفاده می‌گردد. برای شناسایی فازهای دمایی از شبکه‌ی ART بهره گرفته شده است. این شبکه توانایی شناسایی فازهای جدید را به‌صورت برخط و در زمان اجرای مدل دارد. از طرفی، آموزش شبکه‌های عصبی مورد استفاده برای پیش‌بینی دما، در زمان اجرا نیز ادامه می‌یابد.

#### ۴-۱- توسعه ساختار اولیه مدل دمایی به‌صورت برون‌خط

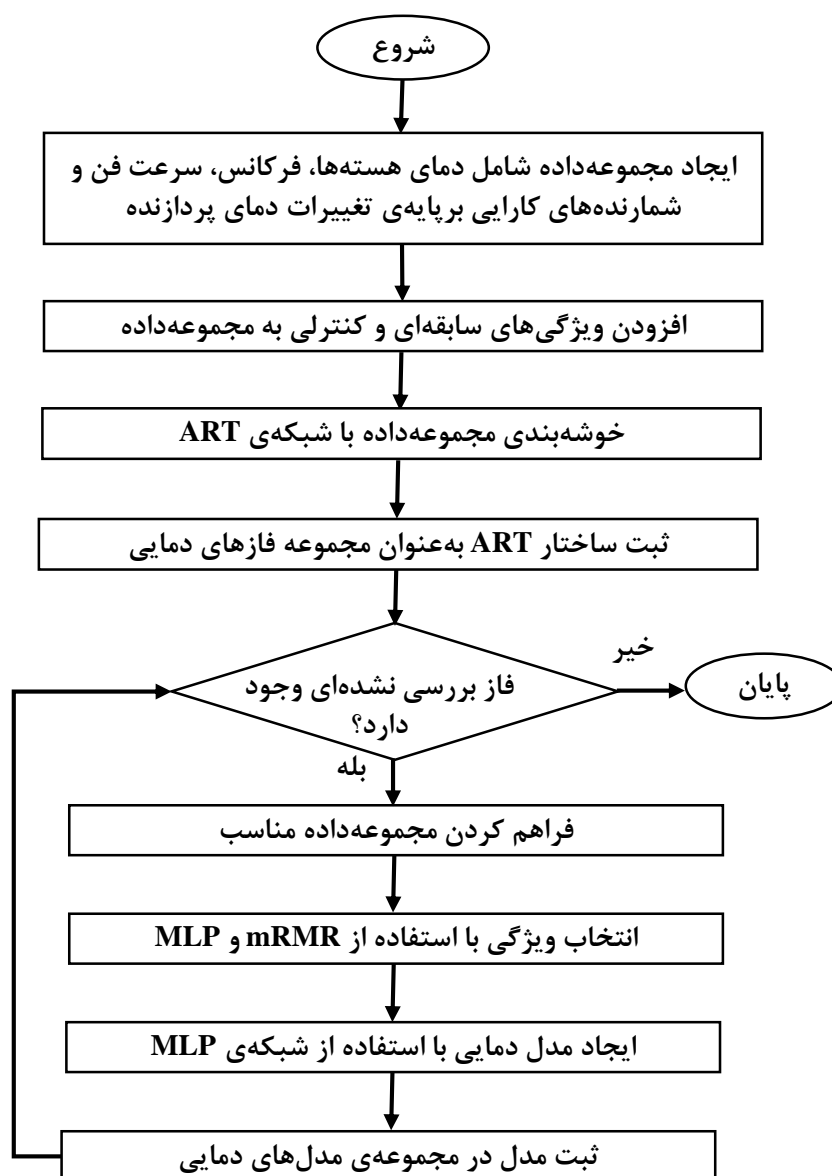
در تعدادی از روش‌هایی پیش‌بینی دما، از چند مدل دمایی بهره برده‌اند [3] [13] [47]. به علت تنوع بالایی که در تغییرات دمایی پردازنده، در اثر تعداد زیاد ویژگی‌های تأثیرگذار وجود دارد، بهره‌گیری از یک مدل ممکن است نتواند پیش‌بینی دقیقی را برای همه‌ی حالات ارائه دهد.

یک مدل دمایی، ممکن است در زمان اجرا با حالت‌هایی برخورد کند که برای آن‌ها آموزش نیافته است. در صورتی که حالت‌های جدید، فاصله قابل توجهی با حالت‌های آموزش یافته داشته باشد، یادگیری آن‌ها از دو نظر می‌تواند برای مدل چالش‌زا باشد. اول آن که یادگیری حالت‌های جدید برای مدل زمان‌بر است. دوم این که، یادگیری حالت‌های جدید می‌تواند باعث کاهش دقت برای حالت‌های پیشین گردد. از این‌رو، برای این که مدل دمایی بتواند رفتارهای دمایی پردازنده را در زمان اجرا و در شرایط مختلف یاد بگیرد، ساختاری متفاوت از ساختار پیشنهادی در فصل ۳ برای آن بررسی شده است. در ساختار پیشنهادی، به‌جای این که از یک شبکه‌ی MLP برای پیش‌بینی دما استفاده گردد، برای رفتارهای متفاوت دمایی پردازنده شبکه‌های مختلف مورد بهره‌برداری قرار گرفته‌اند. به بیانی دیگر، در ساختار پیشنهادی نیاز نیست که یک شبکه را برای همه‌ی رفتارهای دمایی پردازنده آموزش داد. بلکه، در صورت نیاز، می‌توان شبکه‌های عصبی مختلفی را ایجاد کرده که هر یک برای پیش‌بینی بخشی از رفتارهای دمایی استفاده



می‌شود.

مدل دمایی پیشنهادی، برای پیش‌بینی دمای یک هسته در یک سیستم چندهسته‌ای توسعه داده می‌شود. به منظور کاهش سربار محاسباتی آموزش مدل در زمان اجرا، ابتدا تمام تلاش برای ایجاد ساختار اولیه مدل دمایی به صورت برون خط انجام می‌شود. در این راستا، تلاش شده تا مدل برای پیش‌بینی رفتارهای دمایی پردازنده، پیش از اجرای آن، آموزش لازم را ببیند. جریان کلی مرحله برون-خط، در شکل ۴-۱ نمایش داده شده است. برای ایجاد و آموزش مدل دمایی اولیه، از مجموعه داده





شکل ۴-۱: روند ایجاد مدل پیش‌بینی دما شامل فازهای مختلف دمایی و شبکه مناسب برای پیش‌بینی در هر فاز

ایجادشده با الگوریتم نمایش داده‌شده در شکل ۳-۱ استفاده می‌گردد. همچنین، ویژگی‌های سابقه‌ای و کنترلی نیز به آن اضافه می‌گردند.

همان‌طور که پیش‌تر اشاره شد، استفاده از یک مدل دمایی برای پیش‌بینی همه‌ی رفتارهای دمایی پردازنده، دقت بالایی را در همه‌ی حالت‌ها ارائه نمی‌دهد و از طرفی آموزش آن نیز مشکل است. بر این اساس، در تعدادی از رویکردهای ارائه‌شده برای ایجاد یک مدل دمایی، حالت‌های مختلفی برای پردازنده شناسایی و برای هر حالت از یک مدل برای پیش‌بینی دما استفاده می‌شود [3] [5] [13]. در کارهای پیشین، برای تعریف حالت‌های مختلف پردازنده، به بارکاری در حال اجرا بر روی آن توجه شده است. بارهای کاری در الگوهای تکراری و پایدار اجرا می‌شوند [3] [47]. این الگوها در تمام جنبه‌های رفتار بارکاری نظیر اعمال محاسباتی، اعمال حافظه، توان محاسباتی و دمای پردازنده دیده می‌شوند. در این راستا، به شناسایی فازهای مختلفی برای بارکاری پردازنده پرداخته‌اند. در این مفهوم، یک فاز، مرحله‌ای از اجرای بارکاری است که در آن توان مصرفی، دما و مشخصه‌های عملکرد تقریباً یکسان در پردازنده مشاهده می‌شود [47]. این فازها به‌صورت سراسری تعریف شده و به یک بارکاری خاص یا ترکیبی از بارهای کاری نسبت داده نمی‌شود. طبقه‌بندی بارهای کاری یک روش خوب برای ارائه میانگین رفتار بارکاری در یک پنجره‌ی زمانی پردازنده است. در مرحله‌ی طبقه‌بندی، مراکز فازهای بارکاری انتخاب شده و با استفاده از این اطلاعات، یک مدل دمایی فضای حالت برای یادگیری رابطه‌ی بین دما و فاز بارکاری فراهم می‌شود. بدین منظور، در یکی از روش‌ها، فازهای بارکاری به‌صورت تابعی از شماره‌های کارایی پردازنده تعریف شده‌اند [3]. به‌طور کلی، شماره‌های بارکاری، رفتارهای معماری نسبت داده‌شده به فازهای بارکاری را نشان می‌دهند. در این نوع رویکرد، اعتقاد بر این است که تغییرات در رفتار دمایی پردازنده متأثر از تغییرات در مشخصه‌های بارکاری است.

برای نمایش الگوهای تغییر دمای پردازنده، در شکل ۴-۲، دمای یکی از هسته‌های پردازنده در بخشی از آزمایش‌ها نمایش داده شده است. در شکل (الف) نمای کلی‌تر دیده می‌شود. در شکل (ب) بخشی از

شکل (الف) برای نمایش انتخاب شده است. برای نمایش جزئیات بیشتر از شکل (ج) بهره گرفته شده که نمایش قسمتی از شکل (ب) است. الگوهای مختلفی در تغییرات دما مشاهده می شود. یک پردازنده، هم با افزایش دما و هم با کاهش دما روبرو می شود. در شرایط یکسان، افزایش دمای پردازنده، در دماهای بالاتر سرعت بیشتری نسبت به افزایش دما در دماهای پایین تر دارد. برای این که دقت بالایی در پیش بینی دما در رفتارهای متفاوت دمایی پردازنده ارائه شود، می توان برای رفتارهای متفاوت پردازنده از مدل های مجزا استفاده کرد. در این راستا، رفتارهای دمایی پردازنده را با عنوان فازهای دمایی معرفی می کنیم. برای تعیین فازهای دمایی، علاوه بر توجه به شمارنده های کارایی، می توان از دما و فرکانس پردازنده و سرعت فن بهره برد.

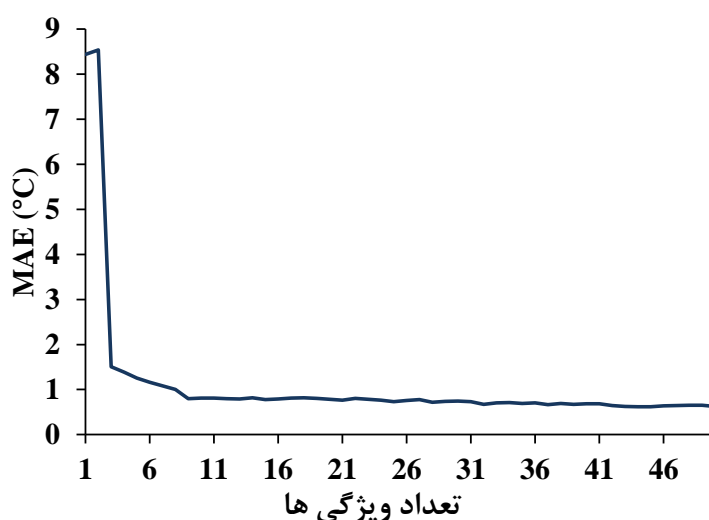


شکل ۴-۲: تغییرات دمایی یک هسته، در پردازنده های چند هسته ای


تعداد فازها، در برخی از رویکردها به صورت برون خط تعیین شده و سپس مدل دمایی مناسب برای آن فاز تعیین می‌گردد [3] [13]. در رویکردهای برخط، امکان تشخیص فاز دمایی جدید و ایجاد مدل دمایی مربوطه، در زمان اجرا وجود دارد [5]. در ادامه، برای افزایش دقت و قدرت تعمیم مدل و همچنین آموزش سریع رفتارهای متفاوت دمایی پردازنده، فازهای دمایی با خوشه‌بندی پارامترهای مؤثر بر دمای پردازنده تعیین می‌شوند. بدین منظور، نیاز به انتخاب پارامترهای مناسب برای خوشه‌بندی است.

#### ۴-۱-۱- خوشه‌بندی رفتارهای دمایی پردازنده

به دلیل اینکه استفاده از همه پارامترهای دمایی، خوشه‌بندی مطلوبی را ارائه نمی‌دهد، به اولویت‌بندی پارامترهای دمایی با استفاده از روش ESCD پرداخته می‌شود. همان‌گونه که پیش‌تر اشاره شده است در روش ESCD، از آنجایی که مدل باید توانایی پیش‌بینی دما با توجه به تغییرهای فرکانس و سرعت فن را داشته باشد، ابتدا ویژگی‌های گرادیان آینده انتخاب می‌شوند. این ویژگی‌ها به بردار  $V$  اضافه می‌گردند. سپس، باقی ویژگی‌ها در مجموعه داده‌ی فراهم‌شده، با توجه به وابستگی با خروجی مدل، که دمای مورد انتظار است، اولویت‌بندی می‌شوند. این اولویت‌بندی با استفاده از روش SCD انجام شده و ویژگی‌ها به بردار  $V$  اضافه می‌شوند. سپس، در هر مرحله، اثر افزایش تعداد ویژگی‌ها در دقت مدل MLP مورد استفاده برای پیش‌بینی دما، محاسبه می‌شود. به‌عنوان نمونه، نتیجه افزایش تعداد ویژگی‌ها در دقت مدل پیش-بینی دمای ۵ ثانیه آینده در شکل ۴-۳ نمایش داده شده است. با توجه به شکل، افزایش تعداد ویژگی‌ها بیش از ۹ ویژگی، کاهش محسوسی در خطای مدل ایجاد نمی‌کند. ۹ ویژگی که برای خوشه‌بندی رفتارهای دمایی پردازنده، برای پیش‌بینی دمای ۵ ثانیه آینده انتخاب شده‌اند شامل گرادیان‌های آینده پارامترهای کنترلی، دمای هسته‌های پردازنده، شمارنده‌های کارایی CYCLES و INSTRUCTIONS و مقدار ۲ ثانیه قبل شمارنده کارایی CPU-MIGRATIONS هستند. از این ویژگی‌ها به‌عنوان ویژگی-های ورودی برای شناسایی فازهای دمایی با شبکه‌ی ART استفاده می‌گردد.

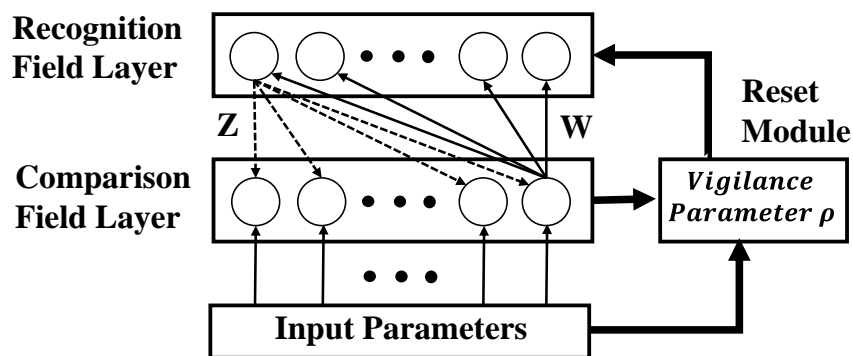


شکل ۳-۴: خطای مدل پیش‌بینی دمای ۵ ثانیه آینده با افزایش تعداد ویژگی‌ها  
تعداد فازهای دمایی، با توجه به میانگین خطای پیش‌بینی دما بر روی مجموعه داده‌ی جمع‌آوری شده، انتخاب شده است. نتیجه‌ی این محاسبه در شکل ۴-۴ نمایش داده شده است. برای پیش‌بینی دمای ۵ ثانیه آینده، تعداد ۴ فاز دمایی ایجاد شده است. سپس، از شبکه MLP برای پیش‌بینی دما برای هر فاز دمایی بهره گرفته می‌شود. خروجی شبکه، دمای پیش‌بینی شده برای  $d \geq 1$  ثانیه بعد است.



شکل ۴-۴: خطای مدل پیش‌بینی با افزایش تعداد فازها

از شبکه‌ی ART که مناسب برای مسائلی است که نیاز به یادگیری برخط دارند، برای تعیین فازهای دمایی استفاده شده است. همان‌طور که در شکل ۴-۵ نمایش داده شده است، این شبکه شامل دو لایه



شکل ۴-۵: ساختار اولیه‌ی شبکه ART [52]

مقایسه<sup>۱</sup> و بازشناسی<sup>۲</sup> است که هر یک از آن‌ها از تعدادی نرون تشکیل شده است. زمانی که شبکه ART برای خوشه‌بندی استفاده می‌گردد، نزدیک‌ترین خوشه با توجه به الگوی بردار ورودی انتخاب می‌شود. سپس خوشه‌ی انتخابی برای نزدیک‌تر شدن به الگوی ورودی به‌روزرسانی می‌شود. مقدار پارامتر مراقبت<sup>۳</sup> ( $\rho$ ) نیز تأثیر قابل توجهی بر عملکرد سیستم دارد. از این پارامتر برای تعریف حد‌آستانه شباهت بین الگوهای ورودی و خوشه‌ها استفاده می‌شود. اگر برای یک الگوی ورودی، میزان شباهت با خوشه انتخابی رعایت نشده باشد، یک خوشه جدید برای رسیدگی به الگو، ایجاد می‌گردد.

#### ۴-۱-۲- توسعه‌ی شبکه‌ی عصبی برای پیش‌بینی دما در هر خوشه

برای آموزش شبکه عصبی برای هر فاز، مجموعه‌داده‌ی مناسب انتخاب شده که شامل نمونه‌های مربوط به آن فاز می‌باشند. نمونه‌های هر فاز از مجموعه‌داده کلی جمع‌آوری شده از سیستم، انتخاب می‌شوند. سپس، ویژگی‌های هر فاز با بهره‌گیری از روش SCD اولویت‌بندی می‌شوند. آنگاه، با توجه به تأثیر افزایش تعداد ورودی‌ها بر دقت مدل، ورودی‌های مناسب برای هر فاز انتخاب می‌گردند. در این راستا، برای هر مجموعه از ویژگی‌های ورودی، از مدل MLP برای پیش‌بینی دما استفاده می‌گردد.


در این راستا، از روش اعتبارسنجی  $k$  تایی، برای انتخاب مجموعه‌های آموزش و آزمایش استفاده شده است. میانگین MAE مربوط به  $k$  مرحله، به‌عنوان خطای خروجی مدل معرفی می‌شود. تأثیر افزایش

<sup>1</sup> Comparison layer

<sup>3</sup> Vigilance parameter

<sup>2</sup> Recognition layer

تعداد ویژگی‌ها در دقت مدل‌های دمایی برای فاصله زمانی ۵ ثانیه آینده در شکل ۴-۶ نمایش داده شده است. نتایج حاکی از آن است که با تعداد محدودی از ویژگی‌ها برای هر فاز، می‌توان به دقت بالایی در پیش‌بینی دما دست یافت. از آنجایی که افزایش بیش از ۲۰ ویژگی نیز، بهبودی در دقت هیچ‌یک از مدل‌ها ایجاد نمی‌کند، نتایج تا ۲۰ ویژگی در شکل ۴-۶ نمایش داده شده است. یکی از مزایای استفاده از فازهای مختلف برای مدل دمایی این است که برای هر فاز نیاز به تعداد ویژگی‌های پایینی برای پیش‌بینی دما است. در این راستا می‌توان به این نتیجه اشاره کرد که برای برخی از فازها با کمتر از ۵ ویژگی می‌توان به دقت بالایی در پیش‌بینی دست یافت. لازم به ذکر است که تعداد پایین ویژگی‌ها منجر به کاهش سرشار اجرایی مدل می‌شود.



شکل ۴-۶: افزایش تعداد ویژگی‌ها در خطای مدل‌های دمایی فازهای مختلف دما برای پیش‌بینی دمای ۵ ثانیه آینده

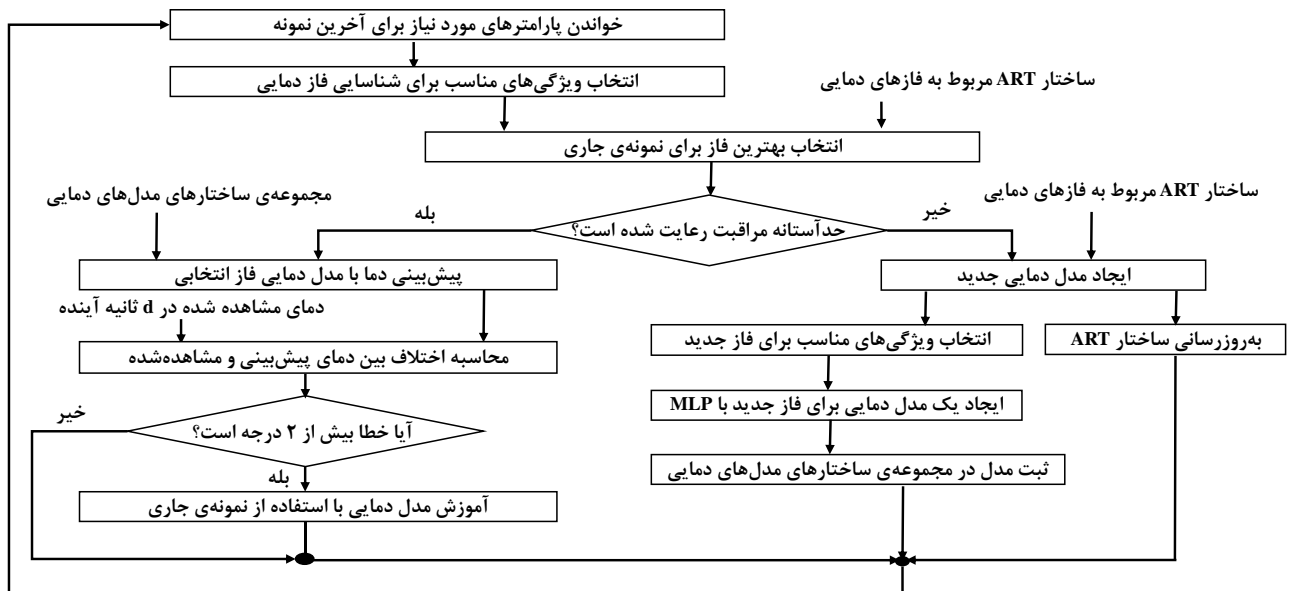
بعد از انتخاب ویژگی‌های مناسب، مدل MLP مجزایی برای هر فاز، با رویکرد افزایشی آموزش داده می‌شود. دلیل استفاده از رویکرد افزایشی برای آموزش مدل این است که بتوان آموزش مدل را در زمان اجرا با توجه به نمونه‌های جدید ادامه داد. از طرفی لازم به ذکر است که تعداد نرون‌های لایه میانی نیز برای شبکه عصبی هر یک از فازها، به صورت مجزا انتخاب می‌گردد. تعداد این نرون‌ها بین ۴ تا ۸ عدد محاسبه شده است. انتخاب تعداد این نرون‌ها با آزمایش‌های مختلف و به صورت برون خط انجام شده است. تعداد پایین نرون‌های لایه میانی نیز در کاهش سرشار محاسباتی مدل تأثیرگذار است. در

انتهای این مرحله، برای هر فاز دمایی، یک مدل MLP، برای پیش‌بینی دما ایجاد می‌شود.

## ۴-۲- بهره‌گیری و آموزش مدل دمایی در زمان اجرا

از مدل دمایی ایجادشده برای پیش‌بینی برخط دما استفاده می‌گردد. در زمان اجرا، داده‌های موردنیاز برای پیش‌بینی دما، با استفاده از ابزارهای اندازه‌گیری سیستم خوانده می‌شوند. همچنین، مدل برای حالت‌هایی که در زمان اجرا، پیش‌بینی دقیقی برای آن‌ها نداشته است آموزش داده می‌شود. در این طراحی، مدل می‌تواند فازهای دمایی جدید را در رویارویی با رفتارهای دمایی جدید یاد بگیرد.

خلاصه روند استفاده از مدل دمایی پیشنهادی در زمان اجرا در شکل ۴-۷ نمایش داده شده است. در ابتدا، برای شناسایی فاز دمایی، ویژگی‌های موردنیاز، با استفاده از ابزارهای اندازه‌گیری و رابطه‌های مربوط به ایجاد ویژگی‌های سابقه‌ای و کنترلی، فراهم می‌شوند. ویژگی‌های انتخابی برای فاصله زمانی ۵ ثانیه آینده پیش‌تر در زیربخش ۴-۱-۱، معرفی شده‌اند. سپس، با استفاده از این ویژگی‌ها و شبکه‌ی ART فراهم‌شده، نزدیک‌ترین فاز به حالت دمایی جاری سیستم انتخاب می‌گردد. از پارامتر مراقبت برای بررسی رعایت حدآستانه‌ی میزان تطابق حالت دمایی جاری با فاز انتخابی، استفاده می‌شود. اگر تطابق کافی با فاز انتخابی وجود داشته باشد، مدل دمایی متناظر با فاز، برای پیش‌بینی دما انتخاب



شکل ۴-۷: روند آموزش مدل پیش‌بینی دما در زمان اجرا



می‌گردد. آنگاه، ویژگی‌های لازم برای مدل دمایی مربوط به فاز انتخابی، خوانده می‌شوند. در نهایت، دمای  $d$  ثانیه آینده، با استفاده از مدل و ویژگی‌های انتخابی، پیش‌بینی می‌گردد. یکی از مهم‌ترین مشخصه‌های مدل پیشنهادی این است که آموزش مدل در زمان اجرا ادامه می‌یابد. بدین منظور، با مشاهده دمای  $d$  ثانیه آینده، خطای مدل محاسبه می‌شود. حدآستانه‌ای برای میزان خطای پیش‌بینی دما در نظر گرفته می‌شود. در مدل پیشنهادی این مقدار برابر با ۲ درجه سانتی‌گراد تعیین شده است. در صورتی که خطای مدل، بیش از ۲ درجه باشد، آموزش مدل دمایی با نمونه جاری انجام می‌شود. این دمای تعیین‌شده برای آموزش مدل، قابل‌تغییر است. البته باید توجه داشت که افزایش این مقدار منجر به کاهش سربار محاسباتی آموزش و از طرفی کاهش دقت مدل می‌شود. این رویکرد، به مدل قابلیت یادگیری نمونه‌هایی را می‌دهد که دقت کافی را برای آن‌ها ارائه نکرده است. با گذشت زمان و افزایش تعداد نمونه‌ها، توانایی مدل برای نمونه‌های مختلف افزایش می‌یابد.

از طرفی، اگر مقدار تطابق حالت دمایی جاری با فاز انتخابی، مقدار پارامتر مراقبت را نقض کند، یک فاز دمایی جدید ایجاد می‌گردد. بدین منظور، فاز جدید به همراه پارامترهای موردنیاز، به شبکه ART اضافه می‌شوند. در این راستا، وزن‌های شبکه‌ی ART نیز بروز می‌گردند. برای فاز جدید، ویژگی‌های مناسب برای پیش‌بینی دما انتخاب می‌شوند. البته، این امکان برای مدل در نظر گرفته شده که با افزایش تعداد نمونه‌های فاز جدید، بتواند با استفاده از الگوریتم SCD پیشنهادی، ویژگی‌های مناسب برای فاز جدید را در زمان اجرا انتخاب کند. لازم به ذکر است که از حداقل ویژگی‌ها، به‌عنوان ورودی‌های مدل دمایی برای فاز جدید استفاده می‌گردد. در نهایت، ساختار مدل دمایی ایجادشده، به مجموعه‌ی مدل‌های دمایی، اضافه گردیده تا برای پیش‌بینی‌های آینده استفاده شود.

تولید یک مجموعه داده مناسب برای آموزش مدل دمایی به‌صورت برون‌خط، این ویژگی را برای مدل دمایی فراهم می‌آورد که در زمان اجرا تغییراتی زیادی در آن نیاز نباشد. تغییرات زیاد مدل در زمان اجرا، سربار محاسباتی اجرای مدل را افزایش می‌دهد. سربار زمان اجرا از معایب یک مدل دمایی است.

پس، مجموعه داده‌ی متنوع از رفتارهای دمایی پردازنده، تأثیر قابل توجهی در ایجاد ساختار مناسب برای یک مدل دمایی دارد.

### ۴-۳- جمع بندی

در این فصل، یک مدل دمایی برخط برای پیش‌بینی دما، برای فاصله‌های زمانی مختلف پیشنهاد و بررسی شده است. مدل پیشنهادی، از تعدادی شبکه‌ی MLP با یادگیری افزایشی تشکیل شده است. هر شبکه برای پیش‌بینی دما در فاز دمایی متناظر با آن استفاده می‌شود. فازهای دمایی به صورت برون‌خط و با استفاده از شبکه‌ی ART تعیین می‌شوند. از طرفی، این امکان برای مدل وجود دارد که در زمان اجرا، در صورت برخورد با فاز جدید، آن را به مجموعه‌ی فازها اضافه کند. برای خوشه‌بندی، ویژگی‌های مناسب، با استفاده از روش ESCD و مدل MLP انتخاب می‌شوند. همچنین، برای هر فاز، ویژگی‌های مناسب آن، به صورت برون‌خط انتخاب می‌شوند. هرچند، این امکان برای مدل فراهم شده که تنها برای فازهای جدید، ویژگی‌های مناسب را در زمان اجرا انتخاب کند. ویژگی‌ها با استفاده از ابزارهای اندازه‌گیری سیستم خوانده می‌شوند. همچنین، بهره‌گیری از ویژگی‌های سابقه‌ای و کنترلی در مدل‌های مربوط به فازهای مختلف، به افزایش دقت آن‌ها کمک قابل توجهی می‌کند.

# فصل

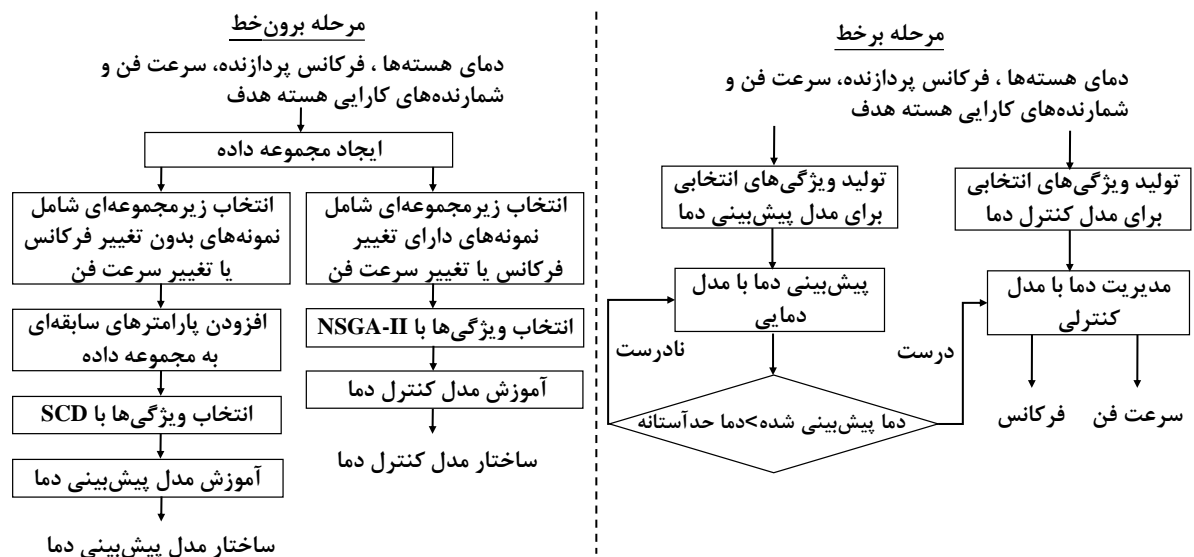
## ۵- مدل پیشنهادی برای کنترل

دما

در این رساله، به اثر تغییرات فرکانس پردازنده و سرعت فن در مقدار دمای آینده پردازنده توجه شده است. بر این اساس، یک کنترل کننده ارائه شده است که به مدیریت دمای پردازنده با استفاده از این دو ابزار کنترلی می پردازد. در رویکرد پیشنهادی، از دو مدل مجزا برای پیش بینی و کنترل دما استفاده می شود. ایجاد مدل ها به صورت برون خط و پیش از بهره گیری از مدل ها انجام می گردد. سپس، از مدل ها در زمان اجرا و به صورت برخط برای کنترل دما بهره گرفته می شود.

## ۵-۱- جریان کلی رویکرد مدیریت دمای پیشنهادی

جریان کلی رویکرد پیشنهادی در هر دو مرحله برون خط و برخط در شکل ۵-۱ نمایش داده شده است. در مرحله برون خط، یک شبکه عصبی MLP برای پیش بینی دما ایجاد می شود. مدل دمایی پیشنهادی، دما را با توجه به وضعیت پردازنده و برنامه های در حال اجرا بر روی آن پیش بینی می کند. اطلاعات لازم از برنامه ی در حال اجرا، از طریق شمارنده های کارایی فراهم می شود. مدل، هم از پارامترهایی نشان-دهنده ی حالت فعلی سیستم و هم از پارامترهای سابقه ای بهره می برد. ویژگی های مناسب مدل، با استفاده از الگوریتم SCD انتخاب می گردد. پس از آموزش مدل، ساختار شبکه ی عصبی برای بهره گیری در زمان اجرا ذخیره می شود.



شکل ۵-۱: جزئیات مختصری از رویکرد مدیریت دمای پیشنهادی

برای مدل کنترل دما نیز، ویژگی‌های مناسب از بین پارامترهای دمایی سیستم انتخاب می‌شوند. مدل کنترلی پیشنهادی، با مدیریت فرکانس پردازنده و سرعت فن، از افزایش دمای پردازنده از دمای حدآستانه جلوگیری می‌کند. با استفاده از یک مجموعه داده مناسب و با توجه به پارامترهای انتخابی، مدل کنترل دما ایجاد می‌گردد. پس از آموزش مدل، ساختار مدل کنترلی نیز برای بهره‌گیری در زمان اجرا ذخیره می‌شود.

در مرحله برخط، دما برای فاصله زمانی دلخواه، با بهره‌گیری از مدل دمایی، پیش‌بینی می‌گردد. در صورتی که دمای پیش‌بینی شده بیش از دمای حدآستانه باشد از مدل کنترل دما استفاده می‌شود. مدل، مقدار سرعت فن و فرکانس پردازنده را به گونه‌ای تخمین می‌زند، که دمای پردازنده در حول و حوش دمای حدآستانه قرار گیرد. بدین منظور، برای داشتن حداکثر عملکرد، حداکثر فرکانس ممکن به صورتی تخمین زده شده، که با بهره‌گیری از سرعت فن، دمای سیستم از حدآستانه سیستم تجاوز نکند.

## ۵-۲- مدل پیش‌بینی دما

مدل دمایی پیشنهادی در فصل‌های قبل، از آنجایی که از ویژگی‌های کنترلی به‌عنوان ورودی‌های مدل بهره می‌برد، افزون بر پیش‌بینی دما، قابلیت پیش‌بینی پاسخ کنترلی را نیز دارد. به بیانی دیگر، مدل دمایی قابلیت پیش‌بینی دما با توجه به تغییرات فرکانس پردازنده و سرعت فن را دارد. استفاده از پارامترهای کنترلی منجر به افزایش پیچیدگی مدل دمایی می‌گردد. به همین دلیل، از یک مدل دمایی با چند شبکه‌ی عصبی برای فازهای مختلف دمایی بهره گرفته شده است.

در رویکرد مدیریت دمای پیشنهادی، از یک مدل دمایی استفاده شده که تنها با توجه به حالت فعلی سیستم و البته روند تغییرات پارامترهای دمایی، دما را پیش‌بینی می‌کند. بر این اساس، به علت کاهش رفتارهای دمایی پردازنده، از یک شبکه‌ی عصبی برای پیش‌بینی دما استفاده شده است.

مجموعه داده مورد استفاده برای آموزش مدل دمایی، زیرمجموعه‌ای از مجموعه داده ایجاد شده با الگوریتم ارائه شده در شکل ۳-۱ است. این زیرمجموعه شامل نمونه‌هایی است که در آن‌ها تغییری در فرکانس

پردازنده یا سرعت فن وجود ندارد. به بیانی دیگر، از نمونه‌هایی برای آموزش استفاده می‌شود، که در آن‌ها بدون تغییر ابزارهای کنترلی، دما تغییر کرده است. ویژگی‌های این مجموعه داده، علاوه بر ویژگی‌های خوانده شده از سیستم، شامل ویژگی‌های سابقه‌ای نیز می‌باشد.


برای بررسی مدل دمایی پیشنهادی، نخست، به مقایسه‌ی اثر استفاده از پارامترهای سابقه‌ای در پیش‌بینی دما، پرداخته می‌شود. در این راستا، در یک آزمایش، تنها از پارامترهای نشان‌دهنده حالت فعلی سیستم، به عنوان ورودی‌های مدل پیش‌بینی دما استفاده می‌گردد. در آزمایش دیگر، علاوه بر استفاده از پارامترهای حالت فعلی سیستم، از پارامترهای پیشنهادی در این رساله، با عنوان پارامترهای سابقه‌ای، نیز برای پیش‌بینی دما استفاده می‌شود. مجموع پارامترها، در این حالت ۱۲۶ عدد است. نتیجه مقایسه در جدول ۵-۱ نمایش داده شده است. استفاده از پارامترهای پیشنهادی، سبب کاهش مقدار MAE مدل پیش‌بینی دما از ۱/۱۷ به ۰/۸۷ درجه‌ی سانتی‌گراد می‌شود. از طرفی، کاهش قابل توجهی در واریانس قدرمطلق خطاها و درصد خطاهای بالای ۳ درجه سانتی‌گراد ایجاد می‌گردد. با این وجود، زمان اجرای مدل، برای پیش‌بینی یک نمونه حدود ۱۰ برابر افزایش می‌یابد.

جدول ۵-۱: پیش‌بینی دمای ۲ ثانیه آینده با پارامترهای مختلف

زمان اجرا برای یک نمونه (μs)	POE(3)	SDAE(°C)	MAE(°C)	تعداد ورودی‌ها	ورودی‌های مدل پیش‌بینی دما
۸/۶۰۶۸	۸٪	۲/۱۳	۱/۱۷	۱۹	حالت فعلی سیستم
۷۷/۸۵۲	۳/۱۳٪	۱/۳۷	۰/۸۷	۱۲۶	حالت فعلی سیستم+پارامترهای سابقه‌ای
۷/۶۵۲۷	۰/۰۴٪	۰/۵۹	۰/۴۹	۱۳	پارامترهای انتخابی با استفاده از SCD

تعداد زیاد ورودی‌های مدل، علاوه بر ایجاد افزایش سرشار محاسباتی برای مدل، می‌تواند منجر به کاهش تعمیم مدل نیز گردد. برای انتخاب مجموعه‌ی مناسب از ورودی‌ها، از الگوریتم پیشنهادی SCD استفاده شده است. در شکل ۵-۲ مقدار MAE برای پیش‌بینی دمای دو ثانیه آینده، برای هر زیرمجموعه از ویژگی‌های انتخاب شده نمایش داده شده است. با توجه به شکل، با انتخاب حدود ۱۳ ویژگی، خطای مدل پیش‌بینی، به میزان قابل توجهی کاهش می‌یابد. بر این اساس، با استفاده از این تعداد ویژگی،

ارزیابی مدل پیش‌بینی دما انجام می‌شود. در جدول ۵-۱ نتیجه‌ی استفاده از پارامترهای انتخابی با الگوریتم SCD نیز نمایش داده شده است. با توجه به نتایج، استفاده از پارامترهای انتخابی با الگوریتم پیشنهادی، علاوه بر اینکه باعث کاهش قابل توجه زمان اجرای مدل شده، دقت مدل را بسیار بهبود می‌بخشد. در این حالت، مقدار میانگین قدرمطلق خطای مدل و واریانس آن، به ترتیب، به کمتر از ۰/۵ و ۰/۶ درجه‌ی سانتی‌گراد کاهش می‌یابد. یکی از مهم‌ترین معیارهای دقت مدل، مقدار درصد خطاهای بالای ۳ درجه سانتی‌گراد است که در این حالت به ۰/۰۴ درصد، کاهش می‌یابد. این مقدار نشان‌دهنده‌ی عدم وجود پیش‌بینی‌های نامطمئن، در مدل پیشنهادی است.



شکل ۵-۲: افزایش تعداد ویژگی‌های انتخابی با استفاده از روش SCD در دقت مدل پیش‌بینی دمای ۲ ثانیه آینده

### ۵-۳- مدل کنترل دمای پیشنهادی

در صورتی که دمای پیش‌بینی شده بیش از دمای حد آستانه پردازنده باشد، با استفاده از تنظیم فرکانس پردازنده و سرعت فن، دمای پردازنده مدیریت می‌شود. برای تعیین مقدار این دو متغیر کنترلی، از مدل MLP استفاده می‌شود. برای آموزش مدل کنترلی، نیاز به جمع‌آوری مجموعه داده‌ی مناسب است. این مجموعه داده شامل اثر تغییرات فرکانس و سرعت فن بر دمای پردازنده است. بدین منظور نیز از داده‌های ایجاد شده با الگوریتم ارائه شده در شکل ۳-۱ استفاده می‌گردد. از نمونه‌هایی برای آموزش مدل کنترلی

استفاده می‌گردد که در آن‌ها مقدار تغییر فرکانس یا تغییر سرعت فن، غیرصفر باشد.

### ۵-۳-۱- انتخاب ویژگی‌های مدل کنترل دما

برای کنترل دقیق دما، نیاز است که ورودی‌ها و خروجی‌های مناسبی برای مدل کنترلی انتخاب شده و در مجموعه داده آموزش مدل قرار گیرند. ورودی‌ها عبارت‌اند از: فرکانس و سرعت فعلی فن، دمای هسته‌ها، شمارنده‌های کارایی و دمای مشاهده شده در  $t$  ثانیه بعد هسته‌ها. خروجی‌های مدل کنترل دما، شامل فرکانس و سرعت فن  $t$  ثانیه بعد است. در زمان بهره‌گیری از مدل برای کنترل دما، دمای  $t$  ثانیه آینده هسته هدف، به‌عنوان دمای حدآستانه یا به بیانی دیگر دمای مورد انتظار برای مدل دمایی استفاده می‌شود.

از بین مجموعه‌ی کلی پارامترهای ورودی معرفی شده، ویژگی‌های مناسب برای مدل کنترلی انتخاب می‌شوند. رابطه‌های SCD و ESCD پیشنهادی در این رساله، در راستای تخمین mRMR پیشنهاد شده است. شایان ذکر است که از این نوع الگوریتم‌ها، برای اولویت‌بندی ویژگی‌ها با توجه به یک خروجی، استفاده می‌گردد. از آنجایی که مدل کنترلی پیشنهادی شامل دو خروجی فرکانس و سرعت فن است، از الگوریتم‌های تخمین mRMR برای انتخاب ویژگی‌ها استفاده نشده و به جای آن از الگوریتم NSGA-II بهره برده شده است. این الگوریتم، می‌تواند برای ارزیابی چندهدفه ویژگی‌ها استفاده شود.

برای استفاده از NSGA-II تنظیم‌هایی بر روی الگوریتم انجام شده، که تعدادی از آن‌ها معرفی می‌شوند. جمعیت الگوریتم، شامل ۴۰ عضو بوده، که هر عضو از ۲۰ مقدار دودویی تشکیل شده است. هر یک از این مقادیر دودویی، مربوط به یکی از ویژگی‌ها بوده، که ابتدا به صورت تصادفی مقداردهی می‌شوند. مقدار ۱ به معنی انتخاب آن ویژگی است. تعداد تکرارهای الگوریتم، ۵۰ بار تنظیم شده است. بخش بااهمیت استفاده از الگوریتم NSGA-II، تعریف تابع هزینه‌ی آن است. برای تابع هزینه، از شبکه‌ی MLP استفاده می‌شود. با توجه به ویژگی‌های انتخابی برای هر عضو، یک شبکه‌ی MLP، ابتدا آموزش یافته و سپس با داده‌های آزمایشی، دقت آن محاسبه می‌گردد. دقت مدل، بر اساس مقدار خطاهای



محاسبه شده در تعیین فرکانس و سرعت فن تعیین می شود. از طرفی، تعداد ویژگی ها نیز به عنوان معیاری دیگر، در انتخاب ویژگی های مناسب، مورد توجه قرار گرفته است. به صورت مختصر، سه معیار شامل مقدار خطا در تخمین فرکانس، خطا در تخمین سرعت فن و تعداد ویژگی ها، در ارزیابی هر عضو از جمعیت برای ایجاد جمعیت پارتو<sup>۱</sup> استفاده می گردد. برای نمایش جمعیت پارتو، از ارائه آن بر روی دو بعد استفاده شده است. بدین منظور، خطای حاصل از تخمین سرعت فن و خطای حاصل از تخمین فرکانس در قالب یک خطای کلی و با رابطه ۵-۱ محاسبه می شود.


$$e_t = \alpha * e_{pf} + (1 - \alpha) * e_{fs} \quad (۱-۵)$$

مقدار  $e_t$  نشان دهنده ی خطای کلی مدل و  $e_{pf}$  و  $e_{fs}$ ، به ترتیب، میزان خطای فرکانس پردازنده و سرعت فن را نشان می دهد. به علت محدوده ی متفاوت سرعت فن و فرکانس پردازنده، نرمال سازی مقادیر آن ها انجام می شود.  $\alpha$  که مقداری بین ۰ و ۱ است، اهمیت مقدار خطاها را نشان می دهد. هر چه میزان  $\alpha$  نزدیک تر به ۱ باشد، ضریب بیشتری برای خطای فرکانس، نسبت به سرعت فن در نظر گرفته می شود. نمودار خطای کلی مدل کنترل دما، با  $\alpha$  برابر با ۰/۵ و بر اساس تعداد ویژگی ها در شکل ۵-۳ نمایش داده شده است. با توجه به شکل، با افزایش تعداد ویژگی ها تا ۶ ویژگی، خطای مدل کاهش می یابد. این ویژگی ها شامل دمای فعلی هسته ی هدف، دمای  $t$  ثانیه آینده ی هسته هدف، دمای داغ ترین هسته، فرکانس فعلی پردازنده، سرعت فعلی فن و شمارنده ی کارایی CYCLES است.

### ۵-۳-۲- توسعه و ارزیابی مدل کنترل دما

با ویژگی های انتخابی و با استفاده از مدل MLP، با توجه به دمای ۲ ثانیه ی آینده و دمای حد آستانه، مقدار مناسب برای فرکانس و سرعت فن تعیین می شود. هدف این کنترل این است که، تفاوت بین دمای ۲ ثانیه ی آینده ی هسته و دمای حد آستانه ی تعیین شده، کمینه گردد. دقت مدل هم به صورت برون خط و هم برخط محاسبه شده است. ارزیابی برون خط، با توجه به مجموعه داده فراهم شده انجام

<sup>1</sup> Pareto



شکل ۳-۵: نتیجه استفاده از الگوریتم NSGA-II برای انتخاب ویژگی‌های مدل کنترل دما


می‌شود. از ۷۰ درصد داده‌های مجموعه داده برای آموزش مدل و از ۳۰ درصد باقیمانده برای آزمایش مدل استفاده شده است. برای هر نمونه از مجموعه داده‌ی آزمایش، علاوه بر پارامترهای نشان‌دهنده‌ی حالت فعلی سیستم، ویژگی‌های فرکانس و سرعت فن t ثانیه‌ی آینده و دمای مشاهده‌شده در t ثانیه بعد ثبت شده است. سپس، با توجه به حالت فعلی سیستم و دمای مشاهده‌شده در t ثانیه آینده، تخمین مقادیر فرکانس و سرعت فن برای t ثانیه آینده انجام می‌شود. آنگاه، از نتایج تخمین و مقادیر صحیح آن در مجموعه داده برای محاسبه دقت مدل پیشنهادی، استفاده می‌شود. در جدول ۲-۵ درصد میانگین قدرمطلق خطا و واریانس قدرمطلق خطا برای هر دو ابزار کنترلی ارائه شده است. حدود ۲ درصد خطا، در تعیین مقدار فرکانس و ۰/۶ درصد خطا در تعیین مقدار سرعت فن، نشان‌دهنده‌ی دقت بالای کنترل کننده است.

جدول ۲-۵: تخمین مقدار فرکانس پردازنده و سرعت فن برای کنترل دما تا ۲ ثانیه آینده

SDAE (%)	MAE (%)	ابزار کنترلی
۴	۲/۱	فرکانس پردازنده
۲/۲	۰/۶	سرعت فن

برای ارزیابی برخط مدل، زمانی که دمای پیش‌بینی شده بیش از دمای حدآستانه مدل باشد، از مدل کنترل دما بهره برده می‌شود. در ارزیابی مدل کنترلی، دمای حدآستانه ۹۰ درجه سانتی‌گراد در نظر

گرفته شده است. با هدف حفظ دما، حول و حوش دمای حدآستانه، مقدار مناسب برای فرکانس و سرعت فن تخمین زده می‌شود. نتیجه استفاده از مدل کنترلی برای ۱۰۰ ثانیه، در شکل ۴-۵ نمایش داده شده است. مدل برای کنترل دما برای ۲ ثانیه آینده، مورد استفاده قرار گرفته است. به بیانی دیگر، با توجه به دمای پیش‌بینی شده برای ۲ ثانیه آینده، از مدل کنترلی برای اثرگذاری بر دما تا ۲ ثانیه آینده و حفظ آن حول و حوش دمای حدآستانه استفاده می‌گردد.



شکل ۴-۵: اثر مدل کنترلی دمای پیشنهادی بر دمای پردازنده

دقت مدل کنترلی، با توجه به تفاوت بین دمای مشاهده شده در پردازنده و دمای حدآستانه ارزیابی شده است. بر این اساس، دو مقدار MAE و SDAE بر اساس کنترل‌های انجام شده با توجه به دمای ۲ ثانیه آینده محاسبه شده که مقادیر حاصل شده به ترتیب ۰/۵ و ۰/۶۲ درجه سانتی‌گراد است. این دقت برای یک مدل کنترلی قابل ملاحظه است. مدل کنترلی پیشنهادی این توانایی را دارد که با توجه به دمای فعلی پردازنده و دمای هدف آن، مقادیر فرکانس و سرعت فن را به شکلی تخمین بزند که با یک فاصله زمانی تعیین شده، اختلاف بین این دو دما کمتر از ۱ درجه سانتی‌گراد باشد.

## ۴-۵- جمع‌بندی

در این فصل، رویکردی در جهت مدیریت دما در سیستم‌های چند هسته‌ای ارائه شده است. بدین منظور از دو مدل MLP استفاده می‌شود. با استفاده از مدل اول دمای آینده، پیش‌بینی می‌گردد. برای ایجاد

مدل، مجموعه داده‌ای شامل نمونه‌هایی با تغییرات مختلف دمایی در سیستم، فراهم می‌شود. ویژگی‌های مجموعه داده، شامل دمای هسته‌های پردازنده، فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی است، که نشان‌دهنده‌ی حالت فعلی سیستم می‌باشند. همچنین، تعدادی ویژگی پیشنهادی برای هر نمونه ایجاد شده است. این ویژگی‌ها گرادیان اول و دوم دما و شمارنده‌های کارایی تا ۳ ثانیه‌ی قبل است. تعدادی از این ویژگی‌ها، با استفاده از الگوریتم SCD برای پیش‌بینی دما انتخاب می‌شوند. از مدل دوم برای کنترل دما، استفاده می‌گردد. ورودی‌های مدل، شامل حالت فعلی سیستم و دمای حدآستانه است. از مدل کنترل دما با هدف داشتن حداکثر عملکرد سیستم، برای حفظ دمای پردازنده، حول و حوش دمای حدآستانه استفاده می‌شود. در این راستا، فرکانس پردازنده و سرعت فن تنظیم می‌گردند. برای انتخاب ویژگی‌های مناسب مدل، از الگوریتم NSGA-II استفاده می‌شود. نتایج حاصل، نشان‌دهنده‌ی دقت بالای مدل‌های پیشنهادی در مدیریت دمای سیستم‌های چند هسته‌ای است.

# فصل

## ۶- ارزیابی و نتایج آزمایش‌ها

در این فصل، به ارائه‌ی نتایج به‌دست‌آمده از ارزیابی‌های مدل‌های پیشنهادی برای پیش‌بینی و کنترل دما پرداخته می‌شود. بخشی از ارزیابی‌ها به‌صورت برون‌خط انجام شده است. لازم به ذکر است که برای ارائه نتایج دقیق‌تر، در همه‌ی مقایسه‌ها از یک مجموعه‌داده‌ی مشترک برای روش‌های موردبررسی استفاده می‌گردد. در این راستا، مجموعه‌های آموزش و آزمایش یکسان برای همه‌ی مدل‌ها انتخاب می‌گردند. همچنین برای ارزیابی برخط مدل‌های دمایی، برای محاسبه‌ی معیارهای مبتنی بر خطای پیش‌بینی، همه‌ی مدل‌های مورد مقایسه به‌صورت هم‌زمان بر روی سیستم در حال اجرا بوده و برای هر نمونه، پیش‌بینی توسط مدل‌های مختلف انجام شده و نتایج ثبت شده‌اند.

در ابتدا، مدل پیشنهادی برای پیش‌بینی دما و پاسخ کنترلی، مورد ارزیابی قرار می‌گیرد. ابتدا، مدل دمایی پیشنهادی به‌صورت برون‌خط ایجاد و ارزیابی شده است. برای بهبود دقت مدل، ویژگی‌های جدیدی در این رساله پیشنهاد شده که با پردازش‌هایی بر روی مقادیر اندازه‌گیری شده از حسگرهای سیستم ایجاد می‌شوند. با استفاده از پارامترهای خوانده‌شده از سیستم و پارامترهای ایجادشده، مجموعه داده‌ای برای آموزش و ارزیابی مدل دمایی فراهم شده است. سپس، روش‌هایی برای انتخاب ویژگی‌های مناسب برای مدل پیشنهاد شده که در این فصل مورد ارزیابی قرار گرفته شده‌اند.

از طرفی، از آنجایی که رفتارهای دمایی یک سیستم بسیار متنوع بوده و جمع‌آوری همه‌ی این رفتارها در یک مجموعه‌داده برای آموزش مدل دمایی، غیرعملی است، رویکردی برای ایجاد یک مدل دمایی برخط ارائه شده است. در این روش، رفتارهای دمایی پردازنده با شبکه‌های عصبی متفاوت آموزش داده می‌شوند. در صورت مواجهه با رفتارهای دمایی جدید، مدل قابلیت یادگیری آن‌ها را در زمان اجرا دارد. این مدل نیز در این فصل مورد ارزیابی قرار گرفته است.

درنهایت، رویکرد مدیریت دمای پویای پیشنهادی در این رساله، ارزیابی شده است. رویکرد پیشنهادی، افزون بر استفاده از یک مدل دمایی برای پیش‌بینی دما، از یک مدل کنترلی بهره می‌برد. مدل کنترلی، با توجه به دمای پردازنده و دمای حدآستانه آن، فرکانس پردازنده و سرعت فن را به صورتی تخمین

می‌زند که دمای پردازنده حول و حوش دمای حدآستانه قرار گیرد. این نوع رویکرد، علاوه بر بهره‌گیری بیشتر از عملکرد پردازنده، قید دمایی آن را رعایت می‌کند.

## ۶-۱- ارزیابی مدل دمایی برون خط برای پیش‌بینی دما

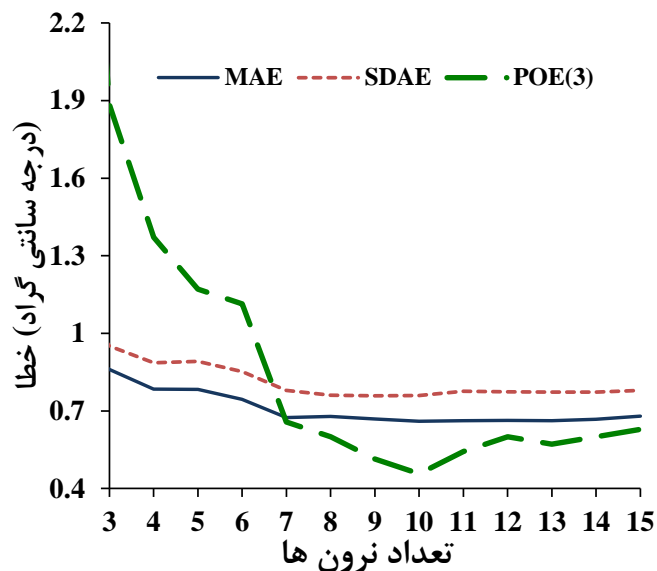
در این بخش به بررسی نتایج استفاده از مدل پیشنهادی، برای پیش‌بینی دما برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده، برای یک هسته در سیستم چند هسته‌ای پرداخته می‌شود. ابتدا برای هر یک از فاصله‌های زمانی یک مجموعه داده‌ی مناسب ایجاد می‌گردد. سپس، با استفاده از شبکه عصبی MLP، پیش‌بینی دما انجام می‌شود. در آزمایش‌های انجام‌شده برای انتخاب نمونه‌های آموزش و آزمایش از اعتبارسنجی متقابل  $k$  تایی استفاده می‌گردد.

### ۶-۱-۱- انتخاب ساختار شبکه‌ی MLP

در ابتدا، ساختار شبکه‌ی MLP مورد استفاده در آزمایش‌ها معرفی شده است. پارامترهای این ساختار به صورت تجربی و با انجام آزمایش‌های مختلف تعیین شده‌اند. از شبکه‌ای سه لایه‌ای استفاده شده است. تعداد نرون‌های لایه‌ی ورودی با توجه به تعداد ویژگی‌های انتخابی برای مدل دمایی انتخاب می‌شود. برای تعیین تعداد نرون‌های لایه‌ی پنهان، آزمایشی بر روی داده‌های تهیه‌شده برای پیش‌بینی دمای ۵ ثانیه آینده، انجام شده است. در این آزمایش، تعداد ۱۲ ورودی برای شبکه انتخاب شده و تعداد نرون‌های لایه پنهان از ۱ تا ۱۵ افزایش می‌یابد. نتیجه آزمایش‌ها در شکل ۶-۱ نمایش داده شده است. با توجه به شکل، افزایش تعداد نرون‌ها از ۱۰ تا ۱۵ باعث بهبود دقت پیش‌بینی دما با شبکه عصبی MLP نمی‌شود. از طرفی، افزایش تعداد نرون‌ها بیش از ۱۰ ویژگی، باعث افزایش مقدار  $POE(3)$  شده که دلیلی بر کاهش دقت مدل دمایی است. بر این اساس، از ۱۰ نرون برای لایه پنهان شبکه‌ی MLP، استفاده می‌شود. در نهایت، از یک نرون به عنوان خروجی شبکه استفاده شده که دمای پیش‌بینی شده برای هسته‌ی هدف را ارائه می‌دهد. شبکه با ۲۵۰ تکرار آموزش می‌یابد. الگوریتم لوببرگ-مارکارد<sup>۱</sup> به عنوان

<sup>1</sup> Levenberg-Marquardt

تابع آموزش شبکه، برای به‌روزرسانی مقادیر وزن‌ها و بایاس استفاده می‌گردد.



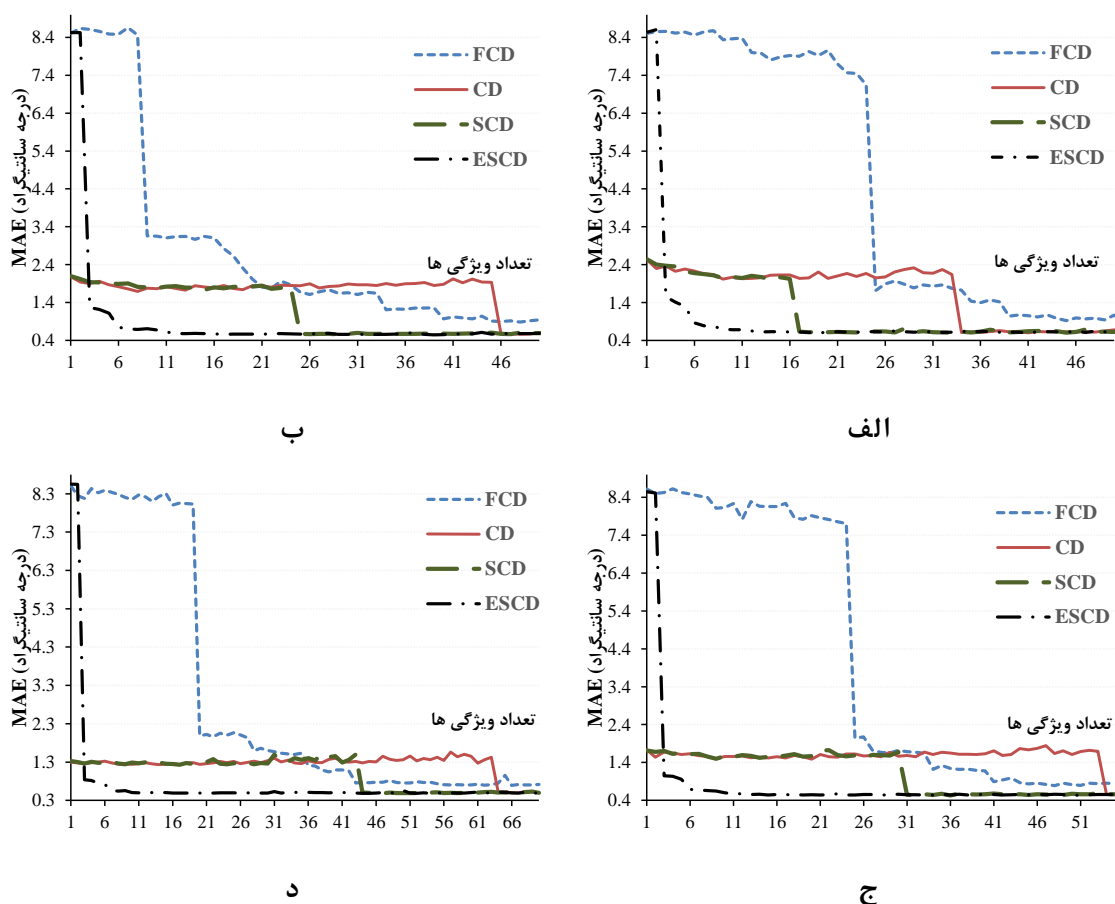
شکل ۶-۱: نتیجه افزایش تعداد نرون‌ها در دقت مدل پیش‌بینی دمای ۵ ثانیه آینده

#### ۶-۱-۲- ارزیابی الگوریتم‌های انتخاب ویژگی پیشنهادی بر روی مدل‌های دمایی مختلف

پس از انتخاب ساختار مناسب برای شبکه عصبی MLP، برای فاصله‌های زمانی ۲ تا ۵ ثانیه، با هر ۴ روش FCD، CD، SCD و ESCD ویژگی‌های مناسب برای پیش‌بینی دما انتخاب می‌شوند. سپس، دقت مدل دمایی ارزیابی می‌گردد. مقدار MAE مربوط به خطای ارزیابی‌ها در شکل ۶-۲ نمایش داده است. با توجه به شکل، در همه‌ی مدل‌ها، با تعداد کم‌تری از ویژگی‌های انتخاب‌شده با استفاده از روش‌های پیشنهادی SCD و ESCD می‌توان به حداقل مقدار MAE دست یافت. در همه‌ی مدل‌ها با انتخاب حدود ۱۱ ویژگی با روش ESCD می‌توان به دقت مناسبی برای پیش‌بینی دما دست یافت.

در جدول ۶-۱، برای مدل پیش‌بینی دمای ۵ ثانیه آینده، معیارهای ارزیابی بیش‌تری ارائه شده است. با انتخاب ۱۳ ویژگی با روش ESCD، مقدار ۰/۶ درجه سانتی‌گراد برای MAE حاصل می‌شود. درحالی‌که برای رسیدن به این مقدار خطا، با روش‌های SCD و CD به ترتیب به ۱۷ و ۳۵ ویژگی نیاز است. افزایش تعداد ویژگی‌ها باعث افزایش زمان اجرای مدل می‌گردد. در این راستا، زمان پیش‌بینی برای هر نمونه محاسبه شده و در جدول نمایش داده شده است. با توجه به نتایج در صورت انتخاب ۳۵ ویژگی، زمان





شکل ۶-۲: مقایسه بین روش‌های FCD, CD, SCD و ESCD در انتخاب ویژگی‌ها برای پیش‌بینی دمای ۲، ۳، ۴، ۵ و ۶ ثانیه آینده به ترتیب در نمودارهای الف، ب، ج، د

اجرا حدود ۶۰ درصد نسبت به انتخاب ۱۳ ویژگی افزایش می‌یابد.

مدل دمایی پیشنهادی، برای یک هسته در سیستم چند هسته‌ای و برای پیش‌بینی فاصله‌های زمانی مختلف ارائه شده است. لیست ورودی‌های انتخاب شده مدل‌های دمایی از ۲ الی ۵ ثانیه آینده با وجود اشتراک بالا، اختلاف‌های بااهمیتی نیز دارد. به همین سبب، استفاده از ویژگی‌های مدل دمایی یک

جدول ۶-۱: مقایسه انتخاب ویژگی‌ها با استفاده از روش‌های مختلف برای پیش‌بینی دمای ۵ ثانیه آینده

زمان اجرا برای یک نمونه (μs)	POE(3)	SDAE	MAE	روش انتخاب ویژگی	تعداد ویژگی‌ها
۳/۳۱۴۱	۰/۵٪	۰/۷۲	۰/۶۲	ESCD	۱۳
۳/۳۸۴۱	۱۳/۶٪	۲/۷۴	۲/۰۷	SCD	۱۳
۳/۸۸۲۳	۰/۵٪	۰/۷۹	۰/۶۲	SCD	۱۷
۲/۹۳۷۶	۱۳/۵٪	۲/۸۶	۲/۰۳	CD	۱۷
۴/۹۲۶۴	۰/۵٪	۰/۷۳	۰/۶۲	CD	۳۵

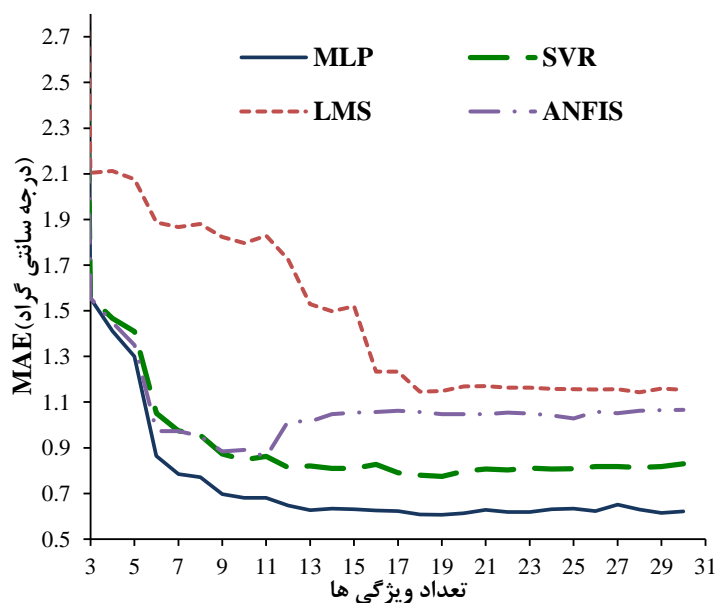
فاصله زمانی، برای فاصله زمانی دیگر نتیجه مناسبی را به همراه ندارد. ویژگی‌های مشترک بین مدل‌های پیش‌بینی دمای مختلف در جدول ۶-۲ نمایش داده شده است. استفاده از این ویژگی‌ها، برای همه‌ی مدل‌های دمایی موردبررسی دقت خوبی را فراهم می‌کند. از طرفی، تفاوت‌هایی نیز بین مدل‌ها برای فاصله‌های مختلف زمانی وجود دارد. به‌عنوان مثال، شمارنده‌ی کارایی INSTRUCTIONS، مقدار یک ثانیه قبل شمارنده‌ی کارایی BRANCHES و گرادیان اول CYCLES به‌عنوان ویژگی‌های مدل پیش-بینی دمای ۲ و ۳ ثانیه آینده انتخاب شده است. البته، این ویژگی‌ها، بهبودی در دقت مدل دمایی برای فاصله‌های ۴ و ۵ ثانیه‌ی آینده ایجاد نمی‌کند. در این راستا، در آزمایشی دیگر، از ویژگی‌های انتخابی برای مدل دمایی برای فاصله زمانی ۲ ثانیه آینده، برای پیش‌بینی دمای ۳ تا ۵ ثانیه آینده استفاده شده است. استفاده از ویژگی‌های انتخابی برای پیش‌بینی دمای ۲ ثانیه آینده، برای ۳ ثانیه آینده نیز دقت قابل قبولی ارائه می‌کند. ولی با افزایش زمان و استفاده از آن ویژگی‌ها برای ۴ و ۵ ثانیه آینده، افزایشی در دقت مدل دمایی دیده نمی‌شود. به‌عنوان مثال، در این آزمایش مقدار MAE مدل‌های دمایی ۳، ۴ و ۵ ثانیه‌ی آینده، ۰/۶۶، ۰/۸۹ و ۱/۰۴ درجه‌ی سانتی‌گراد شده است. این نتایج، دقت کمتری را نسبت به حالتی نشان می‌دهند که برای هر کدام از این فاصله‌های زمانی ویژگی‌های مناسب با الگوریتم انتخاب می‌شوند.

جدول ۶-۲: ویژگی‌های مشترک بین مدل‌های دمایی برای فاصله‌های مختلف زمانی

نام ویژگی
فرکانس پردازنده
گرادیان آینده فرکانس
گرادیان آینده سرعت فن
دمای هسته‌های پردازنده
مقدارهای یک، دو و سه ثانیه قبل دمای هسته هدف
مقدار یک ثانیه قبل شمارنده‌ی کارایی CYCLES
مقدار یک ثانیه قبل شمارنده‌ی کارایی STALLED_CYCLES_FRONTEND
مقدار یک ثانیه قبل شمارنده‌ی کارایی LID_ALL_REF

### ۳-۱-۶- انتخاب مدل رگرسیون مناسب برای پیش‌بینی دما

برای انتخاب مدل مناسب برای پیش‌بینی دما، چندین مدل رگرسیون بررسی شده‌اند. به دلیل رفتارهای دمایی متفاوتی که از برنامه‌های مختلف دیده می‌شود، استفاده از یک مدل خطی، دقت مناسبی در پیش‌بینی دما ارائه نمی‌دهد. از طرفی، رفتار دمایی یک برنامه نیز، در زمان‌های مختلف اجرای آن، متفاوت است. با این وجود، یکی از روش‌های مورد بررسی برای پیش‌بینی دما، LMS است که برای یافتن ضریب‌های فیلتر خطی مناسب برای پیش‌بینی دما استفاده می‌شود. همچنین از SVR و ANFIS که از مدل‌های مناسب برای پیش‌بینی هستند، بهره گرفته شده است. نتیجه استفاده از این مدل‌ها برای پیش‌بینی دمای ۵ ثانیه آینده، در شکل ۳-۶ نمایش داده شده است. از ویژگی‌های یکسان، به عنوان ورودی مدل‌ها استفاده شده است. با توجه به شکل، MLP با یک تفاوت قابل توجه، دقت بالاتری را نسبت به سایر مدل‌ها ارائه می‌دهد. پس از آن، مدل SVR می‌تواند یک انتخاب مناسب برای مدل دمایی باشد.



شکل ۳-۶: مقایسه استفاده از چهار مدل برای پیش‌بینی دمای ۵ ثانیه آینده

برای مقایسه‌ی دقیق‌تر این مدل‌ها، نتایج بیشتری در جدول ۳-۶ نمایش داده شده است. MLP، نسبت به مدل‌های SVR و ANFIS در همه‌ی معیارهای ارزیابی نتایج بهتری را ارائه می‌دهد. هرچند زمان اجرای LMS خیلی کمتر از دیگر مدل‌ها است، ولی دقت آن نیز کاهش قابل توجهی نسبت به مدل

MLP دارد.

جدول ۳-۶: مقایسه تعدادی از مدل‌های رگرسیون برای پیش‌بینی دمای ۵ ثانیه آینده

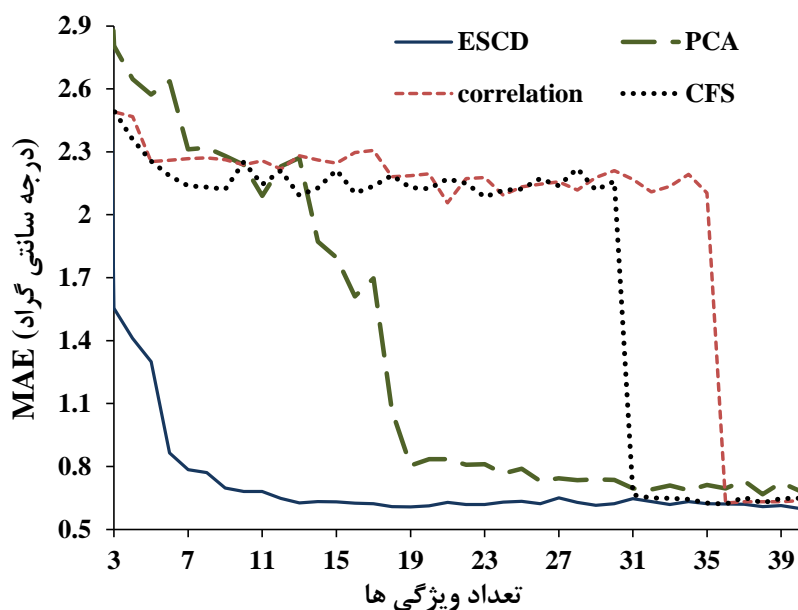
مدل	تعداد ویژگی	MAE	SDAE	POE(3)	زمان اجرا برای یک نمونه (μs)
MLP	۱۳	۰/۶۲	۰/۷۲	۰/۵٪	۳/۳۱۴۱
SVR	۱۳	۰/۸۸	۰/۹۸	۱/۲۶٪	۴/۸۶۵۲
ANFIS	۱۱	۰/۹۱	۱/۱۶	۲/۱۸٪	۴/۱۴۸۷
LMS	۱۸	۱/۱۷	۱/۴۵	۴/۰۷٪	۰/۰۱۲

در تعداد زیادی از روش‌های مدیریت دما، تصمیم‌های کنترلی و پیش‌بینی‌های دمایی، یک‌بار در هر ثانیه انجام می‌شود. یکی از دلایل این امر این است که در اغلب سیستم‌های کاربردی، مقدارهای دمایی با استفاده از حسگرها در هر ثانیه یک‌بار قابل‌خواندن است. یک دلیل دیگر این است که با وجود این محدودیت یک‌ثانیه‌ای در خواندن حسگرهای دمایی، امکان استفاده از الگوریتم‌های مناسب برای جلوگیری از مسائل ناشی از افزایش دمای پردازنده وجود دارد. بنابراین، با توجه به زمان موردنیاز برای مدل MLP پیشنهادی، سربار محاسباتی برای استفاده در روش‌های مدیریت دما، ۰/۰۰۰۳ درصد است. با توجه به این سربار بسیار کم، مدل پیشنهادی می‌تواند برای پیش‌بینی تغییرات دمای حاصل از برنامه‌های مختلف استفاده گردد. به همین دلیل، برای آموزش و آزمایش مدل پیشنهادی، از برنامه‌های متنوع از نظر میزان استفاده از CPU استفاده شده است.

#### ۶-۱-۴- مقایسه روش انتخاب ویژگی ESCD با روش‌های پیشین

روش ESCD با سه روش انتخاب ویژگی دیگر، برای پیش‌بینی دمای ۵ ثانیه‌ای آینده مقایسه شده است. یکی از راه‌کارهای متداول برای کاهش ابعاد ورودی‌های مدل، استفاده از PCA است. PCA، یک تابع آماری است که مجموعه‌ای از متغیرهایی که می‌توانند همبسته باشند را به مجموعه‌ای از متغیرهای به‌صورت خطی غیرهمبسته، با عنوان مؤلفه‌های اصلی تبدیل می‌کند. نتیجه‌ی آزمایش انجام‌شده، در استفاده از PCA برای استخراج ویژگی‌های مناسب برای مدل دمایی، در شکل ۴-۶ نمایش داده شده است. در این راستا، ابتدا تعداد مؤلفه‌ها یک در نظر گرفته می‌شود. سپس، در هر مرحله، یکی به تعداد

مؤلفه‌ها اضافه می‌گردد. نتیجه‌ی افزایش تعداد مؤلفه‌ها برای دقت مدل دمایی در شکل نمایش داده شده است. در مقایسه‌ی دیگر، ویژگی‌ها با توجه به میزان همبستگی با دمای آینده، اولویت‌بندی شده و در لیستی قرار گرفته‌اند. سپس، در هر مرحله،  $k$  ویژگی ابتدایی از لیست انتخاب شده و به‌عنوان ورودی‌های مدل دمایی استفاده شده است. در نهایت، الگوریتم CFS به‌عنوان روش سوم مورد مقایسه قرار گرفته است. این الگوریتم، پیش‌تر برای انتخاب ویژگی‌های مدل دمایی استفاده شده است [19]. نتایج بهره‌گیری از این روش‌ها تا انتخاب ۴۰ ویژگی برای مدل دمایی، در شکل ۶-۴ نمایش داده شده‌اند. با توجه به نتایج، اگر از روش ESCD برای انتخاب ویژگی‌های مدل دمایی استفاده گردد، نیاز به انتخاب تعداد کمی از ویژگی‌ها برای دستیابی به حداقل خطای مدل است. افزایش تعداد ویژگی‌ها، باعث افزایش سربار محاسباتی و کاهش تعمیم مدل می‌گردد. در آزمایش‌های انجام‌شده با انتخاب حدود ۶ ویژگی با روش ESCD می‌توان به کمتر از ۱ درجه خطا در پیش‌بینی دما دست یافت. در صورتی که روش‌های CFS و همبستگی به ترتیب نیاز به انتخاب ۳۱ و ۳۶ ویژگی دارند. از طرفی، روش PCA نیاز به خواندن همه‌ی ویژگی‌ها و تغییر ابعاد ورودی در زمان اجرا دارد که این رویکرد سربار بیشتری به مدل اضافه می‌کند.



شکل ۶-۴: مقایسه استفاده از چهار روش انتخاب ویژگی برای مدل پیش‌بینی دمای ۵ ثانیه آینده

## ۶-۱-۵- مقایسه مدل دمایی پیشنهادی با مدل‌های پیشین

مدل دمایی پیشنهادی با تعدادی از رویکردهای بااهمیت در پیش‌بینی دما برای فاصله‌های زمانی مختلف مقایسه شده است. نتایج در جدول ۴-۶ نمایش داده شده‌اند. در ابتدای جدول، نتایج استفاده از مدل پیشنهادی با عنوان مدل MLP برای پیش‌بینی دمای ۲ تا ۵ ثانیه آینده ارائه شده است. لازم به ذکر است که یکی از دلایل تفاوت زمان اجرای مدل‌ها، نیاز به تعداد ویژگی‌های مختلف برای هر یک از آن‌ها است. با توجه به نتایج، افزایش فاصله‌ی زمانی، با کاهش دقت مدل دمایی مواجه می‌گردد.

زمن<sup>۱</sup> و همکاران [18]، استاکمن<sup>۲</sup> و همکاران [17] و نارایانا<sup>۳</sup> [22] از شمارنده‌های کارایی به‌عنوان ورودی‌های مدل دمایی بهره برده‌اند. از آنجایی که در آزمایش‌های انجام‌شده، مدل MLP نتایج بهتری نسبت به مدل SVR ارائه کرده است، روش پیشنهادی توسط نارایانا پیاده‌سازی و ارزیابی شده است. نتیجه استفاده از رویکرد ایشان در جدول ۴-۶ نمایش داده شده است. مقایسه مدل نارایانا با مدل پیشنهادی حاکی از این است که استفاده از ویژگی‌های پیشنهادی در این رساله، باعث افزایش قابل توجه مدل دمایی پیشنهادی نسبت به مدل نارایانا شده است.

چندین مقاله از مدل ARMA برای پیش‌بینی دما بهره برده‌اند [4] [5]. به همین دلیل، از مدل‌های مورد مقایسه در این رساله است. نتایج نشان از این دارند که با وجود زمان اجرای پایین مدل ARMA نسبت به مدل MLP، دقت بسیار بهتری با مدل پیشنهادی حاصل می‌شود.

کچران<sup>۴</sup> و همکاران یک مدل دمایی شامل چندین مدل خطی برای پیش‌بینی دما معرفی کردند [3]. ایشان، فازهای دمایی مختلف را با توجه به اثر برنامه‌ها بر روی دمای پردازنده شناسایی کردند. سپس، از یک مدل دمایی خطی برای هر فاز بهره برده‌اند. توانایی این رویکرد در پیش‌بینی رفتارهای دمایی مختلف، انگیزه‌ای برای ارزیابی رویکرد کچران و مقایسه آن با مدل MLP شد. نتیجه‌ی استفاده از این رویکرد نیز در جدول ۴-۶ نمایش داده شده است.

<sup>1</sup> Zaman

<sup>2</sup> Stockman

<sup>3</sup> Narayana

<sup>4</sup> Cochran

جدول ۴-۶: دقت مدل‌های دمایی مختلف برای پیش‌بینی دما برای فاصله‌های زمانی مختلف

مدل	فاصله‌ی زمانی	MAE	SDAE	POE(3)	زمان اجرا برای یک نمونه (μs)
MLP	۲	۰/۵	۰/۶۲	۰/۳٪	۲/۸۰۴۷
MLP	۳	۰/۵۴	۰/۶۶	۰/۲۶٪	۳/۱۱۱۳
MLP	۴	۰/۵۷	۰/۷۳	۰/۴۷٪	۲/۸۶۵۲
MLP	۵	۰/۶۲	۰/۷۲	۰/۵٪	۳/۱۳۴۱
نارایانا	۲	۳/۵۱	۳/۱	۲۹٪	۳/۳۷۱۴
نارایانا	۳	۳/۷۳	۳/۲	۳۲٪	۳/۴۲۲۴
نارایانا	۴	۳/۹۲	۳/۷	۳۶٪	۳/۳۱۱۹
نارایانا	۵	۴/۱۹	۴/۱۲	۴۰٪	۳/۳۹۵۷
ARMA	۲	۱/۶۳	۲/۸۳	۱۱٪	۰/۷۵۱۲
ARMA	۳	۱/۷۴	۲/۹۴	۱۱٪	۰/۷۲۱۶
ARMA	۴	۲/۰۹	۳/۴۳	۱۶٪	۰/۷۱۴۵
ARMA	۵	۲/۴۹	۳/۶۷	۱۷٪	۰/۷۱۲۹
کچران	۲	۱/۴۳	۲/۲	۸٪	۲/۹۵۱۵
کچران	۳	۱/۷۲	۲/۵	۱۰٪	۳/۰۰۱۲
کچران	۴	۲/۱۶	۲/۸	۱۶٪	۳/۳۰۱۶
کچران	۵	۲/۵	۳	۱۸٪	۳/۶۵۱۲
ژنگ	۲	۱/۳۷	۲/۲۷	۸/۴٪	۳/۲۰۱۹
ژنگ	۳	۱/۶۱	۲/۴۸	۹/۶٪	۳/۱۹۳۸
ژنگ	۴	۱/۹	۲/۸۶	۱۱/۴٪	۳/۲۵۱۷
ژنگ	۵	۲/۲۱	۲/۹۲	۱۴/۳٪	۳/۲۱۵۸

درنهایت، دقت مدل دمایی پیشنهادی توسط ژنگ<sup>۱</sup> و همکاران در [19]، بررسی شده است. ایشان، ویژگی‌های مناسب برای مدل دمایی را از میان ویژگی‌های فیزیکی و برنامه‌ای با استفاده از الگوریتم CFS انتخاب کرده‌اند. سپس، از ۱۶ ویژگی انتخابی، به‌عنوان ورودی‌های مدل MLP برای پیش‌بینی دما استفاده کرده‌اند. نتیجه استفاده از رویکرد ایشان در انتهای جدول نمایش داده شده است. از تفاوت‌های مدل پیشنهادی با مدل ژنگ، علاوه بر استفاده از الگوریتم‌های انتخاب ویژگی متفاوت، استفاده از ویژگی‌های پیشنهادی در این رساله است. دقت مدل‌های کچران و ژنگ تفاوت زیادی باهم ندارند. با این

<sup>1</sup> Zhang

وجود، مقدار MAE مدل دمایی با رویکرد ژنگ کمتر از رویکرد کچران است. البته، دقت هر دو مدل کمتر از مدل پیشنهادی در این رساله است. به ویژه، مقدار POE(3) مدل MLP پیشنهادی، بسیار کمتر از دیگر مدل‌های دمایی مورد مقایسه است. این پارامتر نشان از دقت مدل پیشنهادی برای رفتارهای مختلف دمایی پردازنده دارد. به صورت کلی، نتایج نشان می‌دهند که مدل پیشنهادی دقت بالاتری را نسبت به همه‌ی مدل‌های دمایی مورد ارزیابی دارد.

## ۶-۲- ارزیابی مدل دمایی برخط برای پیش‌بینی دما

پردازنده رفتارهای دمایی متفاوتی را با توجه به پارامترهای متنوع تأثیرگذار بر دما از خود نشان می‌دهد. فراهم کردن همه‌ی این رفتارها، برای یادگیری مدل دمایی به صورت برون خط غیرعملی است. بر این اساس، به ارائه‌ای مدلی پرداخته شده که در زمان اجرا توانایی یادگیری رفتارهای دمایی پردازنده را داشته باشد. در این بخش، به ارائه نتایج حاصل از ارزیابی مدل دمایی برخط، برای پیش‌بینی دمای ۲ تا ۵ ثانیه‌ی آینده پرداخته می‌شود.

جزئیات قابل توجهی از مدل دمایی برخط، پیش از اجرای مدل و به صورت برون خط انتخاب می‌شود. در این راستا، می‌توان به مدل انتخابی برای پیش‌بینی دما اشاره کرد که از بین مدل‌های SVR، LMS، ANFIS و MLP، با توجه به آزمایش‌های انجام‌شده، مدل MLP برای پیش‌بینی دما انتخاب شده است. از طرفی، علاوه بر ویژگی‌های خوانده‌شده از حسگرهای سیستم، از ویژگی‌های پیشنهادی در این رساله، به عنوان ورودی‌های مدل دمایی استفاده شده است. همچنین، برای انتخاب مجموعه ویژگی‌های کمینه‌ی مؤثر بر دمای پردازنده، الگوریتم‌هایی با نام SCD و ESCD برای تخمین روش mRMR پیشنهاد و بر روی مدل دمایی ارزیابی شده‌اند.

## ۶-۲-۱- انتخاب ویژگی‌های مناسب برای خوشه‌بندی رفتارهای دمایی

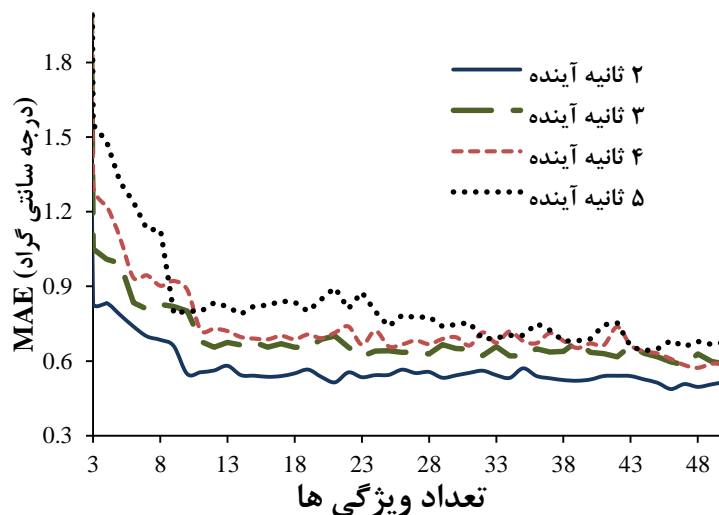
استفاده از یک شبکه‌ی MLP برای پیش‌بینی دما برای همه‌ی رفتارهای دمایی پردازنده، می‌تواند منجر به کاهش دقت پیش‌بینی گردد. بر این اساس، مدل دمایی برخط پیشنهادی، شامل چندین شبکه‌ی



MLP بوده که هر یک از آن‌ها برای پیش‌بینی دما با توجه به بخشی از رفتارهای دمایی پردازنده می‌توانند استفاده شوند. در این راستا، رفتارهای دمایی پردازنده، به تعدادی فاز دمایی تقسیم می‌شود. بدین منظور نیاز به انتخاب ویژگی‌های مناسب برای شناسایی فازهای مختلف دمایی است.

بر این اساس، ابتدا به انتخاب ویژگی‌ها برای خوشه‌بندی فازهای دمایی، برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده، پرداخته شده است. شایان‌ذکر است که ویژگی‌های دمایی شامل دمای هسته‌ها، فرکانس پردازنده، سرعت فن، شمارنده‌های کارایی هسته‌ی هدف، پارامترهای سابقه‌ای و کنترلی دما است. بدین منظور، به‌صورت مجزا، ویژگی‌ها برای هر فاصله زمانی با روش ESCD اولویت‌بندی شده‌اند. سپس، اثر افزایش تعداد ویژگی‌ها، در دقت مدل‌ها برای هر فاصله زمانی محاسبه شده است. نتایج این ارزیابی در شکل ۵-۶ نمایش داده شده است. برای همه‌ی فاصله‌های زمانی، افزایش تعداد ویژگی‌ها تا یک تعداد معین، منجر به کاهش MAE می‌گردد. پس از آن، تغییر محسوسی در دقت مدل دمایی حاصل نمی‌شود. بر این اساس، حداقل ویژگی‌های لازم برای هر فاصله‌ی زمانی انتخاب شده و از آن‌ها برای شناسایی فازهای دمایی استفاده شده است.

حداقل ویژگی‌های انتخابی، به‌عنوان پارامترهای دمایی برای خوشه‌بندی فازهای دمایی با شبکه ART استفاده می‌شوند. در آزمایشی، نتیجه استفاده از ویژگی‌های انتخابی، نسبت به استفاده از همه‌ی ویژگی‌ها



شکل ۵-۶: خطای مدل پیش‌بینی دما برای فاصله‌های مختلف زمانی

برای خوشه‌بندی فازهای دمایی مقایسه شده است. در این مقایسه، یک‌بار با استفاده از ویژگی‌های انتخابی، فاز دمایی هر نمونه شناسایی شده و سپس از مدل MLP مناسب برای پیش‌بینی دما برای آن نمونه استفاده می‌گردد. در حالت دوم از همه‌ی ویژگی‌ها برای تعیین فاز دمایی نمونه استفاده شده و سپس از مدل MLP مربوط به فاز انتخابی برای پیش‌بینی استفاده می‌شود. این مقایسه در جدول ۶-۵ نمایش داده شده است. ارزیابی‌ها بر روی یک مجموعه داده ثابت و به صورت برون خط انجام شده است. با توجه به نتایج، استفاده از ویژگی‌های انتخابی در خوشه‌بندی همه‌ی فاصله‌های زمانی، دقت بالاتری را نسبت به استفاده از همه‌ی ویژگی‌ها ارائه می‌دهد. با اینکه تفاوت زیادی در مدل دمایی با توجه به این دو رویکرد مختلف در خوشه‌بندی نیست، باید توجه داشت که استفاده از ویژگی‌های بیشتر، سربار محاسباتی تعیین فاز دمایی برای هر نمونه را نیز افزایش می‌دهد. بر این اساس، حداقل تعداد ویژگی‌ها برای خوشه‌بندی انتخاب می‌گردند.

جدول ۶-۵: اثر استفاده از ویژگی‌های انتخابی در خوشه‌بندی فازهای دمایی برای فاصله‌های مختلف زمانی

نوع ورودی‌ها	فاصله زمانی	MAE (°C)	SDAE (°C)	POE(3)
ویژگی‌های انتخابی	۲ ثانیه	۰/۶۲	۰/۷۶	۰/۴۴٪
همه‌ی ویژگی‌ها	۲ ثانیه	۰/۷	۰/۹۴	۰/۶۱٪
ویژگی‌های انتخابی	۳ ثانیه	۰/۶۹	۰/۹۳	۰/۵۱٪
همه‌ی ویژگی‌ها	۳ ثانیه	۰/۹۳	۰/۹۶	۰/۸٪
ویژگی‌های انتخابی	۴ ثانیه	۰/۸۵	۱/۰۲	۰/۹۹٪
همه‌ی ویژگی‌ها	۴ ثانیه	۰/۹۵	۱/۲	۱/۱۷٪
ویژگی‌های انتخابی	۵ ثانیه	۰/۹۳	۱/۰۹	۱/۱۹٪
همه‌ی ویژگی‌ها	۵ ثانیه	۱/۰۹	۱/۲۸	۱/۳۸٪

### ۶-۲-۲- ارزیابی اثر استفاده از مدل خطی برای هر فاز از مدل دمایی

در تعدادی از مدل‌های ارائه شده برای پیش‌بینی دما، از یک مدل خطی برای پیش‌بینی در هر فاز بهره برده‌اند [3] [5] [13]. بر این اساس، در آزمایشی که به صورت برون خط انجام شده است، به مقایسه‌ی استفاده از یک مدل خطی برای پیش‌بینی دما در هر فاز، نسبت به استفاده از مدل MLP پرداخته شده است. بدین منظور، پس از خوشه‌بندی فازهای دمایی در مدل پیشنهادی، از LMS برای پیش‌بینی در

هر فاز دمایی استفاده شده است. ویژگی‌های مناسب برای پیش‌بینی در هر فاز با الگوریتم SCD انتخاب شده‌اند. نتایج حاصل در جدول ۶-۶ نمایش داده شده است. با مقایسه‌ی سطرهای مربوط به ویژگی‌های انتخابی در جدول ۶-۵ با سطرهای جدول ۶-۶ می‌توان به این نتیجه اشاره کرد که در همه‌ی فاصله‌های زمانی، استفاده از LMS دقت کمتری را نسبت به MLP، در مدل دمایی پیشنهادی ایجاد می‌کند. همان‌طور که پیش‌تر اشاره شده است، زمان اجرای مدل LMS کمتر از مدل MLP است. اما، از آنجایی که مدل‌ها هر ثانیه یک‌بار مورد استفاده قرار می‌گیرند، سربار محاسباتی هر دو مدل، بسیار ناچیز و قابل صرف‌نظر است.

جدول ۶-۶: دقت مدل دمایی پیشنهادی بر پایه‌ی استفاده از LMS برای پیش‌بینی در هر فاز دمایی

فاصله زمانی (S)	MAE (°C)	SDAE (°C)	POE(3)
۲	۰/۷۱	۰/۸۶	۰/۷۵٪
۳	۰/۸۳	۱/۱۱	۰/۹۶٪
۴	۰/۹۸	۱/۲۳	۱/۶۱٪
۵	۱/۱۶	۱/۳۱	۲/۲۹٪

### ۶-۲-۳- ارزیابی مدل دمایی برخط پیشنهادی برای فاصله‌های مختلف زمانی

مدل دمایی پیشنهادی، امکان یادگیری رفتارهای دمایی را در زمان اجرا دارد. در این راستا، افزون بر این که در زمان اجرا برای پیش‌بینی دما استفاده می‌شود، در مواجهه با مشاهداتی که پیش‌بینی دقیقی از آن‌ها نداشته است، با آن‌ها آموزش پیدا می‌کند. این آموزش همراه با توانایی یادگیری فازهای دمایی جدید نیز است. از مدل پیشنهادی برای پیش‌بینی دما از ۲ تا ۵ ثانیه آینده در زمان اجرا و در حالت‌های مختلف سیستم بهره گرفته شده است. نتیجه‌ی استفاده از مدل در جدول ۶-۷ نمایش داده شده است. لازم به ذکر است شرایط استفاده از سیستم در زمان اجرا با شرایط آموزش سیستم تفاوت داشته است. در این راستا، افزون بر اینکه از برنامه‌های متنوع‌تری استفاده شده، تغییر فرکانس و سرعت فن نیز توسط سیستم عامل کنترل شده است. این آزمایش برای مدت‌زمان حدود ۱ ساعت برای هر فاصله‌ی زمانی بر روی سیستم انجام شده است. با توجه به نتایج حاصل شده، برای همه‌ی فاصله‌های زمانی، میانگین و واریانس قدرمطلق خطاهای مدل پیشنهادی کمتر از ۱ درجه سانتی‌گراد، به دست آمده است. همچنین،

POE(3) برای پیش‌بینی دمای ۲ ثانیه آینده، کمتر از ۱ درصد بوده، که دقت بالای مدل پیشنهادی در مواجهه با رفتارهای مختلف دمایی را نشان می‌دهد. این معیار برای دیگر فاصله‌های زمانی نیز مناسب و قابل توجه است.

جدول ۶-۷: دقت مدل پیش‌بینی دمای برخط برای فاصله‌های مختلف زمانی

POE(3)	SDAE (°C)	MAE (°C)	فاصله زمانی (S)
۰/۹۹٪	۰/۸۲	۰/۷۵	۲
۱/۲٪	۰/۸۵	۰/۸۱	۳
۱/۶٪	۰/۹	۰/۸۹	۴
۱/۹۷٪	۰/۹۲	۰/۹۴	۵

همان‌گونه که پیش‌تر اشاره شده است، برای کاهش سربار محاسباتی یادگیری مدل دمایی، توجه زیادی در جهت آموزش برون خط مدل شده است. بدین منظور، تلاش شده تا از یک مجموعه داده مناسب برای آموزش مدل استفاده گردد. با این وجود، برای ارزیابی اثر استفاده از یک مدل دمایی برخط به جای برون خط، آزمایش دیگری انجام شده است. این آزمایش، مشابه با آزمایش پیشین انجام شده و مدل دمایی برون خط در شرایطی کاملاً مشابه با مدل دمایی برخط ارزیابی شده است. جدول ۶-۷ و ۶-۸ به ترتیب نتایج استفاده از مدل‌های دمایی برخط و برون خط را نشان می‌دهد. مدل برون خط، تنها با توجه به فازهای دیده‌شده در زمان ایجاد مدل، پیش‌بینی را برای همه‌ی نمونه‌ها انجام داده و امکان فراگیری فاز جدید در زمان اجرا را ندارد. به همین سبب و با توجه به نتایج به‌دست آمده، دقت مدل برخط به صورت قابل توجهی بهتر از دقت مدل دمایی ایجادشده به صورت برون خط است. لازم به ذکر است که با افزایش فاصله‌ی زمانی، تفاوت دقت بین مدل‌های برخط و برون خط بسیار محسوس‌تر است.

جدول ۶-۸: دقت مدل پیش‌بینی دمای برون خط برای فاصله‌های مختلف زمانی

POE(3)	SDAE (°C)	MAE (°C)	فاصله زمانی (S)
۲/۴۳٪	۱/۱۱	۰/۹۵	۲
۴/۱٪	۱/۳۴	۱/۲۱	۳
۶/۷٪	۱/۷	۱/۴۱	۴
۸٪	۱/۸۲	۱/۷	۵

## ۶-۲-۴- مقایسه مدل پیشنهادی با رویکردهای مشابه

در ارزیابی مدل دمایی پیشنهادی، مقایسه‌ای با دو مدل دمایی برخط شده است. پیش‌تر نتایج استفاده از این مدل‌ها در جدول ۶-۴ ارائه شده است. با این وجود، به علت برخط بودن این رویکردها، از آن‌ها برای مقایسه با مدل پیشنهادی استفاده شده است. پیش‌تر، این رویکردها با مدل دمایی برون خط مقایسه شده‌اند. لازم به ذکر است که این رویکردها، با شرایط کاملاً یکسان از نظر نوع برنامه‌ها و نوع ارزیابی، دمای محیط و دیگر پارامترهای قابل تنظیم، اجرا شده و مقایسه گردیده‌اند. از رویکردهای برخط ارزیابی‌شده، مدل ARMA است. برای بهره‌گیری از مدل، در زمان اجرا، با توجه به پنجره‌ی مربوط به خطاهای پیش‌بینی، میانگین خطاها محاسبه می‌شود. در صورتی که میانگین حول و حوش صفر باشد، مدل ARMA قابلیت پیش‌بینی خوبی را دارد. در غیر این صورت، مدل دقت لازم را در پیش‌بینی دما ندارد. البته، برای افزایش انعطاف مدل، می‌توان بازه‌ای تعریف کرد که مقدار میانگین در آن قرار گیرد. به‌عنوان مثال، در پیاده‌سازی‌های انجام‌شده در این رساله، بازه‌ی بین ۱- و ۱ درجه سانتی‌گراد برای مقدار مجاز برای میانگین خطا در نظر گرفته شده است. در صورتی که میانگین در بازه‌ی تعریف‌شده قرار نگیرد، با استفاده از آخرین مشاهدات دمایی و مقادیر خطای پیش‌بینی، با بهره‌گیری از برازش حداقل مربعات، ضرایب جدیدی برای معادله ARMA محاسبه می‌شود.

رویکرد دیگر توسط ژنگ و همکاران ارائه شده است. ایشان مدلی پیشنهاد کردند که هم به‌صورت برون خط و هم به‌صورت برخط ارزیابی شده است. در این رساله نیز این رویکرد با هر دو حالت پیاده‌سازی و ارزیابی شده است. در این قسمت نتایج حاصل از ارزیابی روش به‌صورت برخط ارائه می‌گردد. جدول ۶-۹ نتایج استفاده از مدل‌های ژنگ و ARMA را برای پیش‌بینی فاصله‌های مختلف زمانی نشان می‌دهد. مدل ژنگ نسبت به ARMA دقت بالاتری را ارائه می‌دهد. در این راستا، می‌توان به مقدار MAE اشاره کرد که در مدل ژنگ برای فاصله‌های ۲ تا ۵ ثانیه‌ی آینده بین ۱ تا ۱/۵ درجه خطا دارد. با مقایسه‌ی بین جداول ۶-۷ و ۶-۹ می‌توان ارزیابی بهتری را از مدل دمایی پیشنهادی ارائه کرد. نتایج حاکی از دقت بسیار بالاتر مدل پیشنهادی نسبت به مدل‌های دیگر است. از دلایل این دقت بالا، بهره‌گیری از

جدول ۶-۹: دقت مدل‌های پیش‌بینی دمای ARMA و ژنگ، برای فاصله‌های مختلف زمانی

مدل	فاصله زمانی (S)	MAE (°C)	SDAE (°C)	POE(3)
ژنگ	۲	۱/۲	۱/۹۱	۶٪
ژنگ	۳	۱/۳۷	۲/۰۲	۷/۱٪
ژنگ	۴	۱/۴۷	۲/۱۴	۸/۲٪
ژنگ	۵	۱/۵۲	۲/۱۹	۸/۹٪
ARMA	۲	۱/۶۳	۲/۸۳	۱۱٪
ARMA	۳	۱/۷۴	۲/۹۴	۱۱٪
ARMA	۴	۲/۰۹	۳/۴۳	۱۶٪
ARMA	۵	۲/۴۹	۳/۶۷	۱۷٪

ویژگی‌هایی است که در این رساله برای افزایش دقت مدل دمایی پیشنهاد شده‌اند. از دیگر تفاوت‌های رویکرد پیشنهادی نسبت به دو رویکرد مورد ارزیابی، استفاده از چندین مدل برای فازهای دمایی مختلف است.

#### ۶-۲-۵- اثر ارزیابی از خوشه‌بندی در دقت مدل دمایی

می‌توان بین اثر استفاده از خوشه‌بندی در پیش‌بینی دما و استفاده از یک مدل برای پیش‌بینی دما مقایسه‌ای ارائه کرد. بدین منظور، از یک مدل MLP با روش یادگیری افزایشی<sup>۱</sup> برای پیش‌بینی دما برای فاصله‌های ۲ تا ۵ ثانیه آینده استفاده شده است. برای انتخاب ویژگی‌های مناسب برای تنها شبکه‌ی مورد استفاده، از روش ESCD استفاده می‌شود. نتایج استفاده از این روش در جدول ۶-۱۰ نمایش داده شده است. برای مقایسه این رویکرد با مدل دمایی پیشنهادی، توجه شده است که از شرایط یکسان از نظر برنامه‌های در حال اجرا و دیگر پارامترهای قابل کنترل بهره گرفته شود. برای مقایسه‌ی مدل برخط با بهره‌گیری از فازبندی و بدون بهره‌گیری از آن می‌توان از نتایج نمایش داده‌شده در دو جدول ۶-۷ و ۶-۱۰ بهره برد. نتایج گویای دقت بالاتر مدل دمایی، در صورت استفاده از خوشه‌بندی رفتارهای دمایی است. مدل دمایی بدون خوشه‌بندی، از یک شبکه‌ی MLP بهره برده که با هر نمونه جدید و در صورت وجود خطای بیش از ۲ درجه به‌روزرسانی می‌شود. مدل دمایی با خوشه‌بندی، از یک شبکه‌ی ART و

<sup>1</sup> Incremental learning

جدول ۶-۱۰: دقت مدل پیش‌بینی دمای برخط بدون بهره‌گیری از خوشه‌بندی رفتارهای دمایی برای فاصله‌های مختلف زمانی

فاصله زمانی (S)	MAE (°C)	SDAE (°C)	POE(3)
۲	۰/۸۶	۰/۹۸	۲/۳٪
۳	۰/۹۹	۱/۱۲	۳/۱٪
۴	۱/۱۱	۱/۲۳	۴/۳٪
۵	۱/۲	۱/۲۶	۴/۹٪

یک شبکه‌ی MLP برای هر خوشه بهره می‌برد. در این حالت نیز، با توجه به خطای مدل از به‌روزرسانی هر دو مدل برای کاهش خطا در مواجهه‌های بعدی استفاده می‌گردد. برای مدل دمایی ۵ ثانیه‌ی آینده از ۶ فاز دمایی استفاده شده است. مدل بر اساس خوشه‌بندی، از دقت بالاتری برخوردار بوده و در زمان اجرا کمتر نیاز به به‌روزرسانی دارد. از طرفی، در حالت خوشه‌بندی، از ویژگی‌های کمتری برای پیش‌بینی دما در هر فاز بهره می‌برد. با توجه با هر دو مورد ذکرشده، میانگین سربار محاسباتی مدل دمایی با خوشه‌بندی، کمتر از مدل بدون خوشه‌بندی است. در این راستا، میانگین زمان لازم برای پیش‌بینی یک نمونه در حالت خوشه‌بندی ۰/۰۱ میلی‌ثانیه و بدون استفاده از خوشه‌بندی ۰/۰۳ میلی‌ثانیه است.

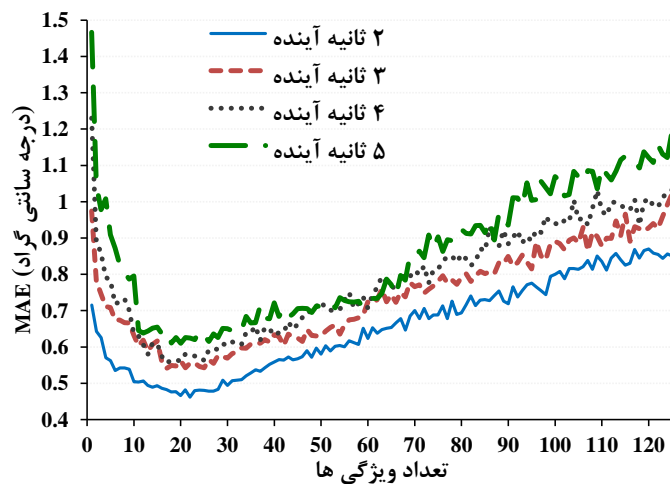
### ۶-۳- ارزیابی رویکرد پیشنهادی برای مدیریت دما

در ادامه، نتایج ارزیابی مدل پیشنهادی برای مدیریت دما ارائه می‌شود. این مدل برای اثرگذاری بر دما با فاصله‌های زمانی ۲ تا ۵ ثانیه آینده استفاده می‌گردد. رویکرد پیشنهادی سعی داشته تا با هدف استفاده از بالاترین عملکرد سیستم، دما را حول و حوش دمای حد‌آستانه حفظ کند. در این راستا، از یک مدل دمایی برای پیش‌بینی و از یک شبکه‌ی عصبی برای کنترل دما استفاده شده است.

#### ۶-۳-۱- انتخاب ویژگی‌های مدل پیش‌بینی دما

مدل پیشنهادی برای پیش‌بینی دما، از پارامترهای فرکانس پردازنده، سرعت فن، دمای هسته‌ها، شمارنده‌های کارایی هسته‌ی هدف و پارامترهای سابقه‌ای بهره می‌برد. تعداد این ویژگی‌ها ۱۲۶ عدد است که از میان آن‌ها، ویژگی‌های مناسب با استفاده از روش SCD انتخاب می‌گردند. لازم به ذکر است که تفاوت مدل پیش‌بینی دمای استفاده‌شده در مدل کنترل دما نسبت به مدل‌های دمایی بررسی‌شده

در بخش‌های قبل این است که در این مدل از پارامترهای کنترلی برای پیش‌بینی دما استفاده نمی‌شود. به بیانی دیگر، از مدل پیش‌بینی دمای پیشنهادی برای پیش‌بینی پاسخ کنترلی استفاده نمی‌گردد. نتایج حاصل از اثر افزایش تعداد ویژگی‌ها، در دقت مدل‌های پیش‌بینی دما برای ۲ تا ۵ ثانیه‌ی آینده در شکل ۶-۶ نمایش داده شده است. با توجه به شکل، افزایش تعداد ویژگی‌ها تا تعداد مشخصی باعث کاهش خطا می‌شود. از نقطه‌ای به بعد، افزایش تعداد ویژگی‌ها، نه تنها تأثیری در بهبود دقت مدل ندارد، بلکه باعث کاهش دقت آن نیز می‌گردد. بر این اساس، ویژگی‌های مناسب برای هر فاصله‌ی زمانی انتخاب می‌شوند.



شکل ۶-۶: دقت مدل پیش‌بینی دما با افزایش تعداد ویژگی‌ها برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده

برای نمایش دقیق‌تر نتایج به دست آمده، از جدول ۶-۱۱ استفاده می‌گردد. در این جدول، تعداد ویژگی‌های مناسب انتخاب شده برای هر فاصله‌ی زمانی، به همراه دقت مدل ایجاد شده برای آن نمایش داده شده است. خطای مدل برای پیش‌بینی ۲ ثانیه‌ی آینده حدود ۰/۵ درجه‌ی سانتی‌گراد و برای ۵ ثانیه‌ی آینده حدود ۰/۶ درجه‌ی سانتی‌گراد است. از مهم‌ترین نتایج حاصل شده، درصد خطاهای بالای ۳ درجه‌ی سانتی‌گراد است، که در همه‌ی مدل‌ها کمتر از ۰/۳ درصد است. البته، دقت مدل‌ها با افزایش فاصله‌ی زمانی از ۲ تا ۵ ثانیه، به مقدار کمی کاهش می‌یابد. به صورت کلی، مدل پیشنهادی برای همه‌ی فاصله‌های زمانی بسیار دقت بالایی دارد.



جدول ۶-۱۱: دقت مدل‌های پیش‌بینی دما برای فاصله‌های مختلف زمانی

فاصله زمانی (S)	تعداد ویژگی‌ها	MAE	SDAE	POE(3)
۲ ثانیه آینده	۱۳	۰/۴۹	۰/۵۹	۰/۰۴٪
۳ ثانیه آینده	۱۶	۰/۵۵	۰/۶۴	۰/۱۴٪
۴ ثانیه آینده	۱۳	۰/۵۷	۰/۶۶	۰/۱۴٪
۵ ثانیه آینده	۱۲	۰/۶۳	۰/۶۹	۰/۲۵٪

برای فاصله‌های مختلف زمانی، تعداد زیادی از ویژگی‌های انتخابی برای پیش‌بینی دما، یکسان هستند. این ویژگی‌ها شامل موارد زیر است: دمای هر ۴ هسته، سرعت فن، مقدار شمارنده‌های کارایی CYCLES و INSTRUCTIONS، مقدار ۱ ثانیه‌ی قبل CYCLES و گرادیان اول ۱ ثانیه‌ی قبل CYCLES. استفاده از این ویژگی‌های مشترک، دقت قابل قبولی برای پیش‌بینی دما فراهم می‌کند. تعدادی محدودی از ویژگی‌ها، در جهت افزایش بیشتر دقت مدل، برای هر فاصله زمانی قابل استفاده است. به‌عنوان مثال، استفاده از گرادیان اول ۲ ثانیه قبل مربوط به دمای هسته‌ی هدف و شمارنده‌ی CYCLES، گرادیان اول ۱ ثانیه قبل L1D\_ALL\_REF، مقدار ۳ ثانیه قبل STALLED\_CYCLES\_FRONTEND برای پیش‌بینی دمای ۳ ثانیه آینده، منجر به کاهش ۰/۰۴ درجه سانتی‌گراد مقدار MAE می‌شود.

### ۶-۳-۲- مقایسه مدل دمایی پیشنهادی با رویکردهای مشابه


در ادامه به مقایسه مدل پیش‌بینی دمای پیشنهادی با مدل ارائه‌شده توسط کچران و همکاران [3] پرداخته می‌شود. لازم به ذکر است که دلیل تفاوت نتایج این بخش با نتایج پیشین، این است که مدل دمایی مورد ارزیابی در این بخش برای پیش‌بینی پاسخ کنترلی استفاده نمی‌گردد. به بیانی دیگر، در این ارزیابی، مدل برای پیش‌بینی دما در حالت‌هایی استفاده می‌شود که تغییری در فرکانس و یا سرعت فن صورت نمی‌گیرد. در واقع دمای پردازنده تنها با توجه به برنامه‌های در حال اجرا بر روی آن تغییر یافته و مدل برای پیش‌بینی این تغییرات استفاده می‌شود. کچران برای فازهای مختلف دمایی از مدل‌های دمایی متفاوت بهره برده است. نتیجه استفاده از مدل ایشان برای پیش‌بینی دما برای فاصله‌های مختلف زمانی در جدول ۶-۱۲ ارائه شده است. با مقایسه جداول ۶-۱۱ و ۶-۱۲ می‌توان به دقت بالای مدل دمایی پیشنهادی نسبت به مدل کچران در همه فاصله‌های زمانی و در همه معیارهای ارزیابی اشاره کرد.

شایان ذکر که دلیل انتخاب مدل کچران برای مقایسه با مدل دمایی پیشنهادی، دقت بالای ایشان با توجه به ارزیابی‌هایی است که در جدول ۶-۴ ارائه شده است.

جدول ۶-۱۲: دقت مدل کچران برای پیش‌بینی دما برای فاصله‌های مختلف زمانی

فاصله زمانی (S)	تعداد ویژگی‌ها	MAE	SDAE	POE(3)
۲ ثانیه آینده	۱۷	۰/۷۱	۰/۷۸	۰/۶۷٪
۳ ثانیه آینده	۱۷	۰/۹۳	۱/۰۲	۲/۵۴٪
۴ ثانیه آینده	۱۷	۱/۰۷	۱/۱۱	۳/۷۳٪
۵ ثانیه آینده	۱۷	۱/۲۷	۱/۳۱	۶/۵۳٪

از طرفی، برای بررسی دقت شبکه‌ی MLP، مقایسه‌ای با دو مدل LMS و SVR انجام شده است. هر دو مدل پیش‌تر هم در مقاله‌های متفاوت و هم در این رساله برای پیش‌بینی دما مورد ارزیابی قرار گرفته‌اند. لازم به ذکر است که ارزیابی‌ها با ویژگی‌ها، مجموعه‌داده و شرایط یکسان انجام شده است. نتیجه مقایسه‌ی این سه مدل در شکل ۶-۷ نمایش داده شده است. با توجه به نتایج، MLP با دقت بیشتری می‌تواند پیش‌بینی دما را انجام دهد.



شکل ۶-۷: مقایسه‌ی دقت مدل‌های مختلف با ویژگی‌های یکسان برای پیش‌بینی دما برای فاصله زمانی ۲ ثانیه آینده

### ۶-۳-۳- ارزیابی مدل کنترل دمایی پیشنهادی

پس از دریافت دمایی پیش‌بینی‌شده از مدل دمایی، تنظیم‌های فرکانس پردازنده و سرعت فن انجام می‌شود. هدف این کنترل دما، این است که فاصله‌ی بین دمای پردازنده و دمای حد آستانه، کمینه گردد. برای ارزیابی مدل کنترل دمایی پیشنهادی، از آن برای کنترل دما، برای ۲ تا ۵ ثانیه‌ی آینده

استفاده می‌شود. به بیانی دیگر، برای کنترل دما در ۲ ثانیه‌ی آینده، مقدار فرکانس و سرعت فن به‌گونه‌ای تعیین می‌شود، که تا ۲ ثانیه‌ی آینده مقدار دما به مقدار مورد انتظار برسد. در این راستا، برای هر یک از فاصله‌های زمانی، یک مجموعه‌داده‌ی مجزا، برای آموزش و آزمایش آن‌ها فراهم می‌شود. ویژگی‌های هر یک از مدل‌های کنترلی، با استفاده از الگوریتم NSGA-II انتخاب می‌شوند. درنهایت، ارزیابی هر یک از مدل‌های کنترلی انجام شده است. جدول ۶-۱۳، نتایج تخمین فرکانس پردازنده و سرعت فن را نشان می‌دهد. به‌صورت کلی، برای همه‌ی فاصله‌های زمانی، دقت بالایی هم در تخمین مقدار مناسب برای فرکانس پردازنده و هم برای سرعت فن دیده می‌شود. هرچند، با افزایش فاصله‌ی زمانی، دقت مدل کنترلی، کاهش می‌یابد. در این راستا، درصد میانگین قدرمطلق خطا، برای مقدار فرکانس از ۲/۱ به ۳/۶ و برای مقدار سرعت فن، از ۰/۶ به ۱/۴ افزایش می‌یابد.

جدول ۶-۱۳: تخمین فرکانس و سرعت فن برای فاصله‌های زمانی مختلف

فاصله زمانی	پارامتر کنترلی	MAE (%)	SDAE (%)
۲ ثانیه	فرکانس	۲/۱	۴
۳ ثانیه	فرکانس	۲/۱	۴
۴ ثانیه	فرکانس	۲/۵	۴/۲
۵ ثانیه	فرکانس	۳/۶	۴/۵
۲ ثانیه	سرعت فن	۰/۶	۲/۲
۳ ثانیه	سرعت فن	۰/۸	۳
۴ ثانیه	سرعت فن	۱/۱	۳/۵
۵ ثانیه	سرعت فن	۱/۴	۴/۱

### ۶-۳-۴ - مقایسه مدل کنترل دمای پیشنهادی با رویکردهای مشابه

در ادامه به مقایسه رویکرد کنترل دمای پیشنهادی، با روش ارائه‌شده توسط لی<sup>۱</sup> و همکاران [20] پرداخته می‌شود. ایشان، ابتدا از تنظیم‌های سرعت فن و در صورت نیاز از فرکانس، برای حفظ دمای سیستم حول و حوش دمای حدآستانه، استفاده کرده‌اند. لازم به ذکر است که در ارزیابی مدل ایشان با مدل پیشنهادی، از یک مدل پیش‌بینی دما استفاده شده است. دلیل این امر، دقت بالای مدل پیش‌بینی

<sup>1</sup> Li

دما در این رساله است. در این آزمایش، دمای حدآستانه ۹۰ درجه سانتی‌گراد تعریف شده است. برای تعیین مقدار سرعت فن و فرکانس، به‌جای استفاده از یک جدول جستجوی ساده که در مقاله‌ی مرجع پیشنهاد شده است، برای هر یک از این متغیرهای کنترلی، از یک شبکه عصبی MLP استفاده شده است. این روش، باعث بهبود دقت مدل کنترلی می‌گردد. برای آموزش هر یک از شبکه‌ها، یک مجموعه داده مناسب فراهم شده است. به‌عنوان مثال، مجموعه‌ی مناسب برای تنظیم فرکانس، شامل نمونه‌های مختلفی از اثر تغییرات فرکانس بر دمای سیستم است. این روش، با نام روش لی یکی از کنترل‌کننده‌هایی است که با مدل کنترل دمای پیشنهادی مقایسه شده است.


استفاده از فرکانس، به‌عنوان پارامتر اصلی در کنترل دما در مقاله‌های متنوعی موردتوجه قرار گرفته است. به‌عنوان نمونه، هانومیاه<sup>۱</sup> و همکاران، در بازه‌ی زمانی بین ۱۰ تا ۲۰ میلی‌ثانیه از تنظیم فرکانس و در بازه‌ی زمانی بین ۱ تا ۳ ثانیه از کنترل سرعت فن برای مدیریت دما بهره می‌برند [9]. در این راستا، ابتدا با استفاده از فرکانس به تنظیم دما پرداخته‌اند. از آنجایی که از تعداد محدودی از مقادیر فرکانسی برای کنترل دما استفاده می‌گردد، برای حفظ دما حول وحوش حدآستانه، نیاز به انتخاب سرعت فن مناسب نیز خواهد بود. در این آزمایش نیز از شبکه عصبی MLP برای کنترل هر یک از متغیرهای کنترلی فرکانس پردازنده و سرعت فن استفاده می‌شود. این رویکرد نیز با نام روش فرکانسی مورد مقایسه قرار گرفته است.

مقایسه‌ی بین روش‌های پیشنهادی، لی و فرکانسی با انجام آزمایش در سه مرحله انجام می‌شود. در مرحله اول تعدادی از برنامه‌های محک انتخاب شده و بر روی هسته‌های مختلف پردازنده اجرا می‌شوند. دما که به ۸۰ درجه سانتی‌گراد می‌رسد کنترل‌کننده پیشنهادی با توجه به دمای حدآستانه ۹۰ درجه سانتی‌گراد فعال می‌شود. پس از انجام کنترل و قرار گرفتن دمای پردازنده در حالت پایدار، یکی از برنامه‌ها از حالت اجرا خارج شده تا دمای پردازنده به دمایی کمتر از دمای آستانه تغییر کند. سپس،

---

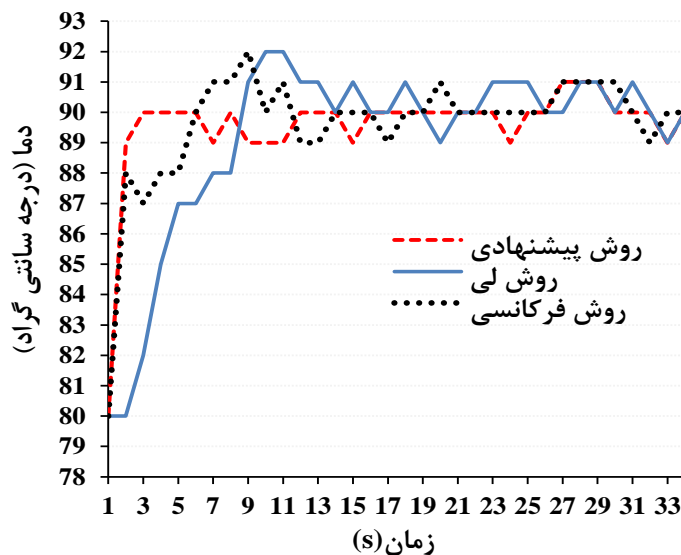
<sup>1</sup> Hanumaiah

مجدد از کنترل کننده برای مدیریت دما استفاده شده تا نتیجه‌ی استفاده از کنترل کننده در یکی دیگر از حالت‌های دمایی پردازنده بررسی شود. این روال بارها و بارها انجام می‌شود. لازم به ذکر است که سعی شده تا با کاهش یا افزایش تعداد برنامه‌های در حال اجرا، دماهایی متفاوتی در پردازنده البته کمتر از دمای حدآستانه پردازنده ایجاد شود. سپس، از کنترل کننده برای مدیریت دما بهره گرفته شده است. از طرفی برای اینکه بتوان مقایسه‌های دقیقی با دیگر روش‌های کنترلی داشت تمامی تغییرات ثبت شده‌اند. در مرحله‌ی دوم، برنامه‌های یکسان با آزمایش قبلی را بر روی هسته‌های پردازنده اجرا کرده تا پردازنده در دمای حالت پایدار یکسان با مرحله‌ی قبل قرار گیرد. آنگاه از روش لی برای کنترل دما استفاده کرده و منتظر شده تا پردازنده در دمای حالت پایدار قرار گیرد. سپس، در عملیاتی کاملاً یکسان با مرحله‌ی قبل، برنامه‌های مختلف از حالت اجرا خارج شده و یا اجرا می‌شوند تا دماهای مختلفی البته یکسان با مرحله‌ی قبل در پردازنده ایجاد شوند. برای هر دمای ایجاد شده، از روش لی برای کنترل دما استفاده می‌شود. در مرحله سوم نیز عملیاتی یکسان با مراحل قبل انجام شده و از روش فرکانسی برای مدیریت دما استفاده می‌شود. نتیجه‌ی بخشی از این آزمایش برای کنترل دما با توجه به فاصله زمانی ۲ ثانیه آینده در شکل ۶-۸ نمایش داده شده است.



شکل ۶-۸: مقایسه‌ی سه روش کنترل دما برای حفظ دما حول و حوش دمای حد آستانه


در شکل ابتدا نتیجه‌ی کنترل دما در زمانی که دمای پردازنده ۸۰ درجه‌ی سانتی‌گراد است دیده می‌شود. پس‌از آن، کنترل دما در حالت‌هایی که دمای پردازنده به ترتیب ۸۳، ۸۵، ۷۵ و ۷۰ درجه است نمایش داده شده است. در همه‌ی حالت‌ها سعی شده با هدف افزایش عملکرد پردازنده، فرکانس در بالاترین مقدار ممکن استفاده شود. با توجه به شکل، با روش پیشنهادی رسیدن به دمای حدآستانه به سرعت اتفاق افتاده و البته اجازه‌ی افزایش دما بیش از حدآستانه نیز داده نمی‌شود. در صورتی که در روش‌های لی و فرکانسی همگرایی به دمای حدآستانه، نیاز به فاصله زمانی بیشتری دارد. برای اینکه جزئیات دقیق‌تری از مقایسه این سه روش دیده شود به نمایش تغییر دما با توجه به یکی از کنترل‌های انجام‌شده، در شکل ۶-۹ پرداخته می‌شود. دما در روش لی بعد از ۱۴ ثانیه به مقدار ۹۰ درجه سانتی‌گراد همگرا می‌شود. در حالی که، در روش پیشنهادی، دما بعد از ۲ ثانیه به ۹۰ درجه می‌رسد. روش فرکانسی بعد از ۱۱ ثانیه به دمای ۹۰ درجه همگرا می‌شود. این زمان همگرایی، نسبت به زمان موردنیاز در روش پیشنهادی تفاوت زیادی دارد.



شکل ۶-۹: نمایش جزئیات بیشتری از سه روش کنترل دمای مورد مقایسه

برای آزمایش انجام‌شده، تغییرهای مقدار سرعت فن و فرکانس در هر دو روش در شکل ۶-۱۰ نمایش داده شده است. در روش پیشنهادی، مقدار مناسب برای فرکانس و سرعت فن، با توجه به دمای فعلی و دمای حدآستانه، با یک انتخاب تعیین می‌شوند. در صورتی که در روش لی، برای تعیین هر یک از مقادیر

سرعت و فرکانس، به صورت مجزا اقدام می‌شود. از طرفی، نیاز به چندین تغییر در روش لی برای رسیدن به دمای حدآستانه وجود دارد.



شکل ۶-۱۰: تغییرهای سرعت فن و فرکانس در روش کنترل دمای پیشنهادی و روش لی





# فصل

## ۷- جمع‌بندی و کارهای آینده

در این رساله، مدلی برای پیش‌بینی دما در سیستم‌های چندهسته‌ای ارائه شده است. از طرفی، مدل پیشنهادی در یک رویکرد مدیریت دمای پویا مورد استفاده قرار گرفته است. جمع‌بندی مدل‌های پیشنهادی در سه بخش معرفی می‌شوند:

- در این رساله، به معرفی یک مدل دمایی برای پیش‌بینی دمای یک هسته در سیستم چندهسته‌ای پرداخته شده است. در این راستا، مدل‌های رگرسیون مختلف مورد بررسی قرار گرفته و با توجه به نتایج به دست آمده، شبکه‌ی MLP برای پیش‌بینی دما انتخاب شده است. برای آموزش مدل دمایی، یک مجموعه داده‌ی مناسب ایجاد شده که شامل تنوع قابل توجهی از تغییرات دمایی در سیستم است. تعدادی از ویژگی‌های این مجموعه داده، شامل دمای هسته‌ها، فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی هسته هدف است. برای افزایش دقت مدل، ویژگی‌های دیگری با پردازش چند نمونه متوالی از داده‌ها ایجاد شده است. در این راستا، برای هر ورودی، گرادیان‌های اول و دوم آن تا ۳ ثانیه قبل محاسبه می‌شود. همچنین، برای اینکه بتوان از مدل برای پیش‌بینی پاسخ کنترلی در اثر تغییر فرکانس پردازنده و سرعت فن استفاده کرد، ورودی‌هایی با عنوان گرادیان‌های آینده به مدل داده می‌شوند. به علت زیاد بودن تعداد این مجموعه ویژگی‌ها، انتخاب یک زیرمجموعه‌ی مناسب از آن‌ها با هدف حداکثر وابستگی و حداقل افزونگی انجام می‌شود. در این راستا دو روش انتخاب ویژگی جدید با نام‌های SCD و ESCD پیشنهاد شده‌اند. این روش‌ها با تعدادی از الگوریتم‌های مشابه، برای انتخاب ویژگی‌های مدل دمایی مقایسه شده‌اند. برای بررسی دقیق‌تر مدل دمایی پیشنهادی، پیش‌بینی دما برای فاصله‌های ۲ تا ۵ ثانیه آینده انجام شده است. از طرفی، مدل پیشنهادی با تعدادی از مدل‌های مهم در پیش‌بینی دمای سیستم‌های چندهسته‌ای مقایسه شده است. در این مقایسه، معیارهای مختلفی مورد ارزیابی قرار گرفته‌اند. نتایج به دست آمده نشان از دقت بالای مدل پیشنهادی نسبت به سایر مدل‌های مشابه دارد. در این راستا، مدل MLP با ویژگی‌های انتخابی با استفاده از الگوریتم ESCD، دارای میانگین قدر مطلق خطای کمتر از ۰/۵ و ۰/۷ درجه سانتی‌گراد است. معیارهای انحراف معیار قدر مطلق خطاها و درصد خطای پیش‌بینی بالای ۳

درجه سانتی گراد نیز، برای پیش‌بینی دمای ۲ تا ۵ ثانیه آینده محاسبه شده است.

- از آنجایی که فراهم کردن یک مجموعه داده کامل از رفتارهای دمایی پردازنده، امری غیرعملی است، آموزش دقیق و کامل یک مدل دمایی به صورت برون خط امکان‌پذیر نیست. در این حالت، مدل در زمان اجرا با حالت‌هایی مواجه می‌شود که آموزش مناسبی برای آن‌ها ندیده و دقت مناسبی برای آن‌ها ارائه نمی‌دهد. بر اساس این، یک مدل دمایی در این رساله پیشنهاد شده است که امکان یادگیری در زمان اجرا را دارد. مدل پیشنهادی از تعدادی شبکه‌ی MLP تشکیل شده است که با یادگیری افزایشی آموزش می‌یابند. هر شبکه برای پیش‌بینی دما در یک فاز دمایی استفاده می‌گردد. فازهای مختلف دمایی پردازنده به صورت برون خط و با استفاده از شبکه‌ی ART تعیین می‌شوند. از طرفی، این امکان برای مدل وجود دارد که در زمان اجرا، در صورت برخورد با فاز جدید، آن را به مجموعه‌ی فازها اضافه کند. برای خوشه‌بندی، ویژگی‌های مناسب، با استفاده از روش ESCD و مدل MLP انتخاب می‌شوند. همچنین، برای هر فاز از مدل دمایی پیشنهادی، ویژگی‌های مناسب آن با استفاده از الگوریتم SCD انتخاب می‌شوند. این امکان برای مدل فراهم شده که برای فازهای جدید، ویژگی‌های مناسب را در زمان اجرا انتخاب کند. برخی از این ویژگی‌ها با استفاده از ابزارهای اندازه‌گیری سیستم خوانده می‌شوند. دیگر ویژگی‌های مدل به‌عنوان پارامترهای سابقه‌ای و کنترلی با استفاده از پردازش‌های پیشنهادی در این رساله، ایجاد می‌شوند. ارزیابی‌های متنوعی بر روی مدل پیشنهادی انجام شده و با مدل‌های مختلفی که برای پیش‌بینی دما ارائه شده‌اند، مقایسه شده است.
- در نهایت، رویکردی در جهت مدیریت دما در سیستم‌های چند هسته‌ای ارائه شده است. بدین منظور از دو مدل MLP به‌عنوان مدل‌های دمایی و کنترلی استفاده می‌شود. با استفاده از مدل دمایی پیش‌بینی دمای پردازنده انجام می‌گردد. ویژگی‌های ورودی مدل، علاوه بر حالت فعلی سیستم که دمای هسته‌های پردازنده، فرکانس پردازنده، سرعت فن و شمارنده‌های کارایی است، شامل پارامترهای سابقه‌ای است که با استفاده از پردازش‌های پیشنهادی تولید شده‌اند. تعدادی از این

ویژگی‌ها، با استفاده از الگوریتم SCD برای پیش‌بینی دما انتخاب می‌شوند. از مدل دوم برای کنترل دما، استفاده می‌گردد. ورودی‌های مدل، شامل حالت فعلی سیستم و دمای حدآستانه است. از مدل کنترل دما با هدف داشتن حداکثر عملکرد سیستم، برای حفظ دمای پردازنده، حول و حوش دمای حدآستانه استفاده می‌شود. در این راستا، فرکانس پردازنده و سرعت فن تنظیم می‌گردند. برای انتخاب ویژگی‌های مناسب مدل کنترلی، از الگوریتم NSGA-II استفاده می‌شود. خطای مدل کنترلی در تخمین ابزارهای مدیریت دمای موردبررسی، کمتر از ۲٪ برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده است. این مقدار نشان‌دهنده دقت بالای مدل‌های پیشنهادی در مدیریت دمای سیستم‌های چند هسته‌ای است.

در انتها برای ادامه این تحقیق پیشنهادهایی ارائه می‌گردند:

- برای پیش‌بینی پاسخ دمایی می‌توان به ابزارهای دیگر مؤثر بر دما توجه کرد. در این راستا، مهاجرت وظایف و تزریق نخ بیکار از روش‌های متداول در رویکردهای مدیریت دما است که اثر آن باید با استفاده از یک مدل دمایی پیش‌بینی گردد.
- توسعه مدل دمایی پیشنهادی با توجه به همه‌ی هسته‌های پردازنده، از دیگر کارهای پیشنهادی است. در این راستا، به شمارنده‌های همه‌ی هسته‌های پردازنده و تغییرات دمای همه‌ی هسته‌ها باید توجه شود.
- ارزیابی رویکرد پیشنهادی برای پیش‌بینی دما، بر روی پردازنده‌های دیگر مانند پردازنده‌هایی که فرکانس‌های مجزا برای هر یک از هسته‌ها بهره می‌برند، از دیگر کارهای آینده خواهد بود.
- اغلب در مدیریت دما، علاوه بر توجه به تغییرات دمای آینده متأثر از ابزارهای کنترل دما، به عملکرد پردازنده نیز اهمیت داده می‌شود. پس، مدل دمایی همراه با مدلی که بتواند عملکرد پردازنده را با توجه به تغییرات ابزارهای کنترلی پیش‌بینی کند، می‌تواند بهبود قابل توجهی در عملکرد یک روش مدیریت دما ایجاد کند.

- در تعدادی از روش‌های مدیریت دما به این نکته اشاره شده است که برای یک کنترل مناسب باید هم‌زمان به توان مصرفی، دمای پردازنده و عملکرد آن توجه شود. پس، نیاز است که برای پیش‌بینی هر یک از این پارامترها، مدل‌ها و ویژگی‌های مناسب آن‌ها انتخاب شوند.
- استفاده از کنترل‌کننده‌های فازی برای مدیریت دما، از دیگر پیشنهادهایی است که می‌تواند از تحقیق‌های مناسب برای آینده باشد.
- توسعه مدل کنترل دمای پیشنهادی با توجه به پیش‌بینی دمای همه‌ی هسته‌های پردازنده، از دیگر کارهای آینده است. در این راستا، بررسی موضوع به لحاظ یک سیستم چند ورودی چند خروجی و بررسی اثر تداخل دمایی پردازنده‌ها روی یکدیگر می‌تواند مورد مطالعه و تحقیق قرار گیرد.

- [1] J. Kong, S. W. Chung and K. Skadron, "Recent Thermal Management Techniques for Microprocessors," *ACM Computing Surveys (CSUR)*, vol. 44, no. 3, 2012.
- [2] Y. Han, I. Koren and C. A. Moritz, "Temperature Aware Floorplanning," in *In Proceedings of the Second Workshop on Temperature-Aware Computer Systems*, 2005.
- [3] R. Cochran and S. Reda, "Thermal Prediction and Adaptive Control Through Workload Phase Detection," *ACM Transactions on Design Automation of Electronic Systems (TODAES)*, vol. 18, no. 1, p. 7, 2013.
- [4] A. K. Coskun, T. S. Rosing and K. C. Gross, "Proactive Temperature Balancing for Low Cost Thermal Management in MPSoCs," in *IEEE/ACM International Conference on Computer-Aided Design*, pp. 250-257, 2008.
- [5] A. K. Coskun, T. S. Rosing and K. C. Gross, "Utilizing Predictors for Efficient Thermal Management in Multiprocessor SoCs," *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, vol. 28, no. 10, pp. 1503-1516, 2009.
- [6] D. Shin, S. W. Chung, E. Y. Chung and N. Chang, "Energy-Optimal Dynamic Thermal Management: Computation and Cooling Power co-optimization," *IEEE Transactions on Industrial Informatics*, vol. 6, no. 3, pp.340-351, 2010.
- [7] G. Liu, M. Fan and G. Quan, "Neighbor-Aware Dynamic Thermal Management for Multi-Core Platform," in *Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pp. 187-192, 2012.
- [8] S. Sharifi, R. Ayoub and T. S. Rosing, "Tempomp: Integrated Prediction and Management of Temperature in Heterogeneous MPSOCS," in *Conference on Design, Automation and Test in Europe*, pp. 593-598, 2012.
- [9] V. Hanumaiah and S. Vrudhula, "Energy-Efficient Operation of Multicore Processors by DVFS, Task Migration, and Active Cooling," *IEEE Transactions on Computers*, vol. 63, no. 2, pp. 349-360, 2014.
- [10] Z. Liu, T. Xu, S. X. D. Tan and H. Wang, "Dynamic Thermal Management for Multicore Microprocessors Considering Transient Thermal Effects," in *In Design Automation Conference (ASP-DAC)*, pp. 473-478, 2013.
- [11] W. Wu, L. Jin, J. Yang, P. Liu and S. X. D. Tan, "Efficient Power Modeling and Software Thermal Sensing for Runtime Temperature Monitoring," *ACM Transaction on Design Automation of Electronic Systems*, vol. 12, no. 3, 2007.
- [12] J. Donald and M. Martonosi, "Techniques for Multicore Thermal Management: Classification and new Exploration," *ACM SIGARCH Computer Architecture News* 34, pp. 78-88, 2006.
- [13] M. Chhablani, I. Koren and C. M. Krishna, "Online Inertia-based Temperature Estimation for Reliability Enhancement," *Journal of Low Power Electronics*, vol. 12, no. 3, pp. 159-171, 2016.
- [14] A. Vincenzi, A. Sridhar, M. Ruggiero and D. Atienz, "Fast Thermal Simulation of 2D/3D Integrated Circuits Exploiting Neural Networks and GPUs," in *In Proceedings of the 17th IEEE/ACM international symposium on low-power electronics and design*, pp. 151-156, 2011.

- [15] P. Kumar and D. Atienza, "Neural Network Based On-Chip Thermal Simulator," in *Proceedings of Circuits and Systems (ISCAS)*, pp. 1599-1602, 2010.
- [16] Y. Ge, Q. Qiu and Q. Wu, "A Multi-Agent Framework for Thermal Aware Task Migration in Many-Core Systems," *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, vol. 20, no. 10, pp. 1758-1771, 2012.
- [17] M. Stockman, M. Awad, H. Akkary and R. Khanna, "Thermal Status and Workload Prediction Using Support Vector Regression," in *International Conference on Energy Aware Computing*, pp. 1-5, 2012.
- [18] M. Zaman, A. Ahmadi and Y. Makris, "Workload Characterization and Prediction: A Pathway to Reliable Multicore Systems," in *International On-Line Testing Symposium (IOLTS)*, pp. 116-121, 2015.
- [19] K. Zhang, A. Guliani, S. Ogren-ci-Memik, G. Memik, K. Yoshii, R. Sankaran and P. Beckman, "Machine Learning-Based Temperature Prediction for Runtime Thermal Management Across System Components," *IEEE Transactions on Parallel and Distributed Systems*, vol. 29, no. 2, 2018.
- [20] D. Li, R. Ge and K. Cameron, "System-level, Unified In-band and Out-of-band Dynamic Thermal Control," in *International Conference Parallel Processing (ICPP)*, pp. 131-140, 2010.
- [21] R. Ayoub, K. Indukuri and T. S. Rosing, "Temperature Aware Dynamic Workload Scheduling in Multisocket CPU Servers," *IEEE transactions on Computer-aided design of integrated circuits and systems*, vol. 30, no. 9, pp. 1359-1372, 2011.
- [22] S. A. Narayana, "An Artificial Neural Networks based Temperature Prediction Framework for Network-on-Chip Based Multicore Platform," Thesis, Rochester Institute of Technology, 2016.
- [۲۳] جواد محبی نجم آباد و علی سلیمانی، "پیش‌بینی دما در سیستم‌های چند هسته‌ای با استفاده از خوشه‌بندی عامل‌های مؤثر بر دما،" در چهارمین کنفرانس ملی فناوری اطلاعات، کامپیوتر و مخابرات، ۲۳ تیر ۱۳۹۶.
- [24] J. Barbic, "Multi-core Architectures," Lecture Notes.[Online]. Available: <http://www.co-array.org/cafvsmipi.htm>, 2007.
- [25] A. Jerraya and W. Wolf, *Multiprocessor Systems-on-Chips*, The Morgan Kaufmann Series in Systems on Silicon. Elsevier/Morgan Kaufman, Boston/San Fran-cisco, 2004.
- [26] A. Kumar, L. Shang, L. S. Peh and N. K. Jha, "HybDTM: A Coordinated Hardware-Software Approach for Dynamic Thermal Management," in *Proc. 43rd annual Design Automation Conference*, pp. 548-553, 2006.
- [27] K. Skadron, M. R. Stan, W. Huang, S. Velusamy, K. Sankaranarayanan and D. Tarjan, "Temperature-aware Microarchitecture: Extended Discussion and Results," *ACM Trans. Architecture Code Optimization*, vol. 1, no. 94-125, 2004.
- [28] H. F. Sheikh, I. Ahmad, Z. Wang and S. Ranka, "An Overview and Classification of Thermal-Aware Scheduling Techniques for Multi-Core Processing Systems," *Sustainable Computing: Informatics and Systems*, 2011.
- [29] C. Jeonghwan, C. Y. Cher, H. Franke, H. Hamann, A. Weger and P. Bose, "Thermal-Aware Task Scheduling at the System Software Level," in *Proceedings of the 2007 international symposium on Low power electronics and design*, pp. 213-218, 2007.
- [30] M. Pierre, A. Sez nec, D. F. Irisa, Y. Sazeides and T. constantinou, "A Study of Thread Migration in Temperature-Constrained Multicores," *ACM Transactions on Architecture and Code Optimization*, vol. 4, no. 2, 2007.

- [31] I. Yeo, C. C. Liu and E. J. Kim, "Predictive Dynamic Thermal Management for Multicore Systems," in *in Proc. of the 45th annual Design Automation Conference*, pp. 734-739, 2008.
- [32] I. Yeo and E. J. Kim, "Temperature-Aware Scheduler Based on Thermal Behavior Grouping in Multicore Systems," in *in Proceedings of the Conference on Design, Automation and Test in Europe*, pp. 946-951, 2009.
- [33] J. M. N. Abad, B. Salami, H. Noori, A. Soleimani and F. Mehdipour, "A Neuro-Fuzzy Fan Speed Controller for Dynamic Thermal Management of Multicore Processors," in *In Proceedings of the 11th ACM Conference on Computing Frontiers*, 2014.
- [34] J. M. N. Abad and A. Soleimani, "A Neuro-Fuzzy Fan Speed Controller for Dynamic Management of Processor Fan Power Consumption," in *In Swarm Intelligence and Evolutionary Computation (CSIEC)*, pp. 148-153, 2016.
- [35] A. Bartolini, M. Cacciari, A. Tilli and L. Benini, "A Distributed and Self-Calibrating Model-Predictive Controller for Energy and Thermal Management of High-Performance Multicores," in *In Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pp. 1-6, 2011.
- [36] F. Zanini, D. Atienza, L. Benini and G. D. Micheli, "Multicore Thermal Management with Model Predictive Control," in *in Circuit Theory and Design, European Conference*, pp. 711-714, 2009.
- [37] K. Coskun, T. S. Rosing and K. C. Gross, "Proactive Temperature Management in MPSoCs," in *in Proc. International symposium on Low Power Electronics & Design*, pp. 165-170, 2008.
- [38] V. Hanumaiah, S. Vrudhula and K. S. Chat, "Performance Optimal Online DVFS and Task Migration Techniques for Thermally Constrained Multicore Processors," in *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, vol. 30, no. 11, pp. 1677-1690, 2011.
- [39] B. Yun, K. G. Shin and S. Wang, "Predicting Thermal Behavior for Temperature Management in Time-Critical Multicore Systems," in *In Real-Time and Embedded Technology and Applications Symposium (RTAS), 2013 IEEE 19th*, pp. 185-194, 2013.
- [40] H. Peng, F. Long and C. Ding, "Feature Selection Based on Mutual Information Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005.
- [41] "Lm sensors Linux hardware monitoring [Online]," Available: <http://www.lmsensors.org>.
- [42] "library to program Hardware Performance Units (PMUs)," Available: <https://linux.die.net/man/3/libpfm>.
- [43] "Linux cpufreq governors, LinuxKernel [Online]," Available: <https://www.kernel.org/doc/Documentation/cpu-freq/governors.txt>, 2017.
- [44] H. Jung, P. Rong and M. Pedram, "Stochastic Modeling of a Thermally-Managed Multi-Core System," in *Design Automation Conference*, pp. 728-733, 2008.
- [45] M. Mandal and A. Mukhopadhyay, "An Improved Minimum Redundancy Maximum Relevance Approach for Feature Selection in Gene Expression Data," in *Procedia Technology*, vol. 10, pp. 20-27, 2013.
- [46] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed., 2009.
- [47] R. Cochran and S. Reda, "Consistent Runtime Thermal Prediction and Control Through Workload Phase Detection," in *Design Automation Conference (DAC)*, 2010.



- [48] B. Yun, K. G. Shin and S. Wang, "Thermal-Aware Scheduling of Critical Applications Using Job Migration and Power-Gating on Multi-core Chips," in *Trust, Security and Privacy in Computing and Communications (TrustCom)*, pp. 1083-1090, 2011.
- [49] J. Yang, X. Zhou, M. Chrobak, Y. Zhang and L. Jin, "Dynamic Thermal Management through Task Scheduling," in *Performance Analysis of Systems and Software*, pp. 191-201, 2008.
- [50] E. Le Sueur and G. Heiser, "Dynamic Voltage and Frequency Scaling: The Laws of Diminishing Returns," in *Proceedings of the 2010 international conference on Power aware computing and systems*, 2010.
- [51] K. Deb, A. Pratab, S. Agarwal and T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE transactions on evolutionary computation*, Vol. 6, No. 2, pp. 182-197, 2002.
- [52] S. Rajasekaran and G. V. Pai, *Neural Networks, Fuzzy Logic and Genetic Algorithm: Synthesis and Applications*, New Delhi: Prentice Hall of India Pvt. Ltd, 2003.

## **Abstract:**

To increase processor computational power, the designers of the microprocessors have built multicore processor on a chip. Adding to the number of cores causes an increase in the power density and subsequently leads to raising the processor temperature. To enhance the processor performance and prevent from burning, its temperature should be managed and controlled. In order to manage the temperature, reactive and proactive approaches have been introduced. Contrary to the reactive approach, proactive methods control the temperature before reaching the temperature threshold. One of the main challenges in proactive methods is the need for a model that predicts the processor temperature with high precision. Learning this model requires a dataset that includes a large variety of processor temperature variations. For this purpose, an algorithm is proposed to create a proper dataset. A number of features are provided by reading temperature sensors and other measuring instruments. Some proposed features, which called historical and control features, have been produced by preprocessing processes. Historical features have been created to keep the last changes in thermal parameters. Control features are used to add the possibility of predicting the thermal response generated by control decisions. Due to the high number of features, some of them are selected as thermal model inputs using two proposed methods with names square of correlation difference and extended SCD. The multi-layer perceptron neural network has been selected as the thermal model by comparing some regression models. The proposed thermal model has been compared with a number of important approaches to predict the temperature of 2 to 5 next seconds. The mean absolute error of the proposed model is calculated to be less than 0.5 and 0.7 ° C for the next 2 and 5 seconds, respectively.

Furthermore, an online thermal model is proposed to increase the accuracy of prediction. In this approach, a thermal model is created in an offline step. Then, the model is updated at runtime for states where the model's accuracy is low. The proposed model consists of several thermal phases. For each phase, an MLP network is used to predict the temperature. Different thermal phases have been identified using the adaptive resonance theory network, according to the parameters affecting the processor temperature. Appropriate features are selected by the proposed algorithm for each thermal phase. The proposed model is capable of adding a new thermal phase to a set of phases and creating a suitable neural network for it at runtime. The proposed model error is less than 1 ° C for

different time distances.

Finally, using the proposed thermal model and a control model, the processor temperature is controlled by determining the processor frequency and fan speed. Proper features are selected for the controller. The error of the thermal control model in determining the processor frequency and fan speed is 2% and 0.6% respectively.

**Keywords:** multicore processors, dynamic thermal management, thermal prediction model, clustering, feature selection.



Faculty of Computer Engineering  
Ph.D. Thesis in Artificial Intelligence Engineering

# Online Thermal Model Estimation for Multicore Processors

A Thesis Submitted in Partial Fulfillment of the Requirement for the Degree of  
Doctor of Philosophy in Computer Engineering

By:  
Javad Mohebbi Najm Abad

Supervisor:  
Dr. Ali Soleimani

Advisor:  
Dr. Ali Pouyan

June 2018