

پیش‌بینی برخط دما در فازهای مختلف دمایی برای سیستم‌های چندهسته‌ای

جواد محبی نجم‌آباد^۱، دانشجوی دکتری؛ علی سلیمانی^۲، دانشیار؛ علی پویان^۳، استادیار

۱- دانشکده مهندسی کامپیوتر - دانشگاه صنعتی شاهرود - شاهرود - ایران - javad.mohebi@shahroodut.ac.ir

۲- دانشکده مهندسی برق و رباتیک - دانشگاه صنعتی شاهرود - شاهرود - ایران - solimani_ali@shahroodut.ac.ir

۳- دانشکده مهندسی کامپیوتر - دانشگاه صنعتی شاهرود - شاهرود - ایران - apouyan@shahroodut.ac.ir

چکیده: افزایش تعداد هسته‌ها برای افزودن توان محاسباتی پردازنده‌ها، منجر به افزایش دما در سیستم‌های چندهسته‌ای می‌گردد. لذا مدیریت دما در این پردازنده‌ها از اهمیت بالایی برخوردار است. مدیریت دما با رویکرد فعال، از یک مدل دمایی، برای پیش‌بینی دما پیش از رسیدن به دمای حدآستانه استفاده می‌کند. در این مقاله ویژگی‌های لازم برای پیش‌بینی دما با استفاده از ابزارهای اندازه‌گیری سیستم خوانده شده و از آن‌ها ویژگی‌های سابقه‌ای و کنترلی با استفاده از پردازش‌های پیشنهادی ایجاد شده‌اند. یک مدل دمایی برخط مبتنی بر چند فاز دمایی و برای هر فاز یک شبکه عصبی برای پیش‌بینی دما پیشنهاد شده است. فازهای مختلف دمایی با توجه به پارامترهای مؤثر بر دمای پردازنده با استفاده از شبکه نظریه تشدید انطباقی شناسایی شده‌اند. برای هر یک از شبکه‌های عصبی، حداقل تعداد ویژگی‌های مناسب برای پیش‌بینی در فاز دمایی مربوطه، بر پایه اطلاعات متقابل بین ویژگی‌ها انتخاب شده است. مدل دمایی پیشنهادی قادر است در زمان اجرا، در صورت برخورد با فاز دمایی جدید، آن را به مجموعه فازها اضافه کرده و شبکه عصبی مناسب برای آن را ایجاد کند. نتایج نشان می‌دهد در مدل دمایی پیشنهادی میانگین قدرمطلق خطا برای فاصله‌های زمانی مختلف کمتر از ۱ درجه سانتی‌گراد است.

واژه‌های کلیدی: مدیریت دمای پویا، پیش‌بینی دما، انتخاب ویژگی، پرسپترون چندلایه‌ای، فاز دمایی، شبکه، نظریه تشدید انطباقی.

Online Thermal Prediction in Different Thermal Phases for Multicore Systems

J. Mohebbi Najm Abad¹, PhD student; A. Soleimani², Professor; A. Pouyan³, Professor

1- PhD Student of Computer Engineering, Shahrood University of Technology, Shahrood, Iran,
Email: javad.mohebi@shahroodut.ac.ir

2- Faculty of Electrical Engineering and Robotic, Shahrood University of Technology, Shahrood, Iran,
Email: solimani_ali@shahroodut.ac.ir

3- Faculty of Computer Engineering, Shahrood University of Technology, Shahrood, Iran,
Email: apouyan@shahroodut.ac.ir

Abstract: Increasing the number of cores to enhance computing power of processors leads to an increase in temperature for multicore systems. Thermal management is significant challenge in these processors. A proactive dynamic thermal management uses a thermal model to predict the temperature before processor temperature reaches the threshold. In this paper, some appropriate features for thermal model are read by using system measurement tools. Other features as historical and control features are created using the proposed processes. An online thermal model based on several thermal phase is proposed. For each phase, a neural network is used to forecast temperature. Different thermal phases are identified according to the parameters affecting the processor temperature using the adaptive resonance theory network. For each of the neural networks, the minimum number of proper features is selected based on the mutual information between the features. The proposed thermal model is able to detect new thermal phase at run time. Then, appropriate neural network is created for new phase. The proposed model has been evaluated to predict temperature for different time distances. The results shows the mean absolute error is less than 1 °C.

Keywords: Dynamic thermal management, thermal prediction, feature selection, multilayer perceptron, thermal phase, adaptive resonance theory network.

تاریخ ارسال مقاله: ۱۳۹۶/۱۰/۱۳

تاریخ اصلاح مقاله: ۱۳۹۷/۰۴/۰۸ و ۱۳۹۷/۰۵/۲۷

تاریخ پذیرش مقاله: ۱۳۹۷/۰۶/۱۳

نام نویسنده مسئول: علی سلیمانی

نشانی نویسنده مسئول: ایران - شاهرود - بولوار دانشگاه - دانشگاه صنعتی شاهرود - دانشکده مهندسی برق و کامپیوتر.

۱- مقدمه

رویکرد اصلی برای بهبود عملکرد پردازنده‌ها، افزایش تعداد هسته‌های آن‌ها است. افزایش تعداد هسته‌ها در یک ناحیه^۱ محدود، منجر به افزایش چگالی توان مصرفی و به‌موجب آن افزایش دمای پردازنده می‌شود. از طرفی، افزایش دما منجر به افزایش توان مصرفی پردازنده می‌شود. این چرخه ایجادشده، به‌سرعت دمای پردازنده را زیاد می‌کند. این چالش، می‌تواند منجر به ایجاد نقاط داغ در پردازنده، کاهش قابلیت اطمینان و طول عمر آن گردد [۱].

یکی از رویکردهای مهم در کنترل دمای پردازنده‌ها، مدیریت دمای پویا^۱ (DTM) است. DTM شامل دو رویکرد واکنشی^۲ و فعال^۳ است. در رویکردهای واکنشی، دما پیش از رسیدن به حدآستانه، با استفاده از روش‌هایی که با سرعت بیشتری منجر به کاهش دما می‌شوند، کنترل می‌شوند. اغلب این روش‌ها، کاهش تأثیرگذاری در عملکرد سیستم می‌گذارند. برخلاف واکنشی، در رویکرد فعال، از یک مدل دمایی برای پیش‌بینی دما استفاده می‌شود. سپس، تنوعی از روش‌های مختلف مانند تنظیم ولتاژ فرکانس پویا^۴ (DVFS) و مهاجرت وظیفه، برای کاهش دما پیش از رسیدن به حد آستانه استفاده می‌شوند [۲].

برای این‌که مدل‌های دمایی بتوانند عملکرد مناسبی در مدیریت دمای پردازنده داشته باشند باید دارای ویژگی‌هایی باشند. دقت پیش‌بینی، اصلی‌ترین ویژگی مدل است. برای افزایش دقت، نیاز است که در بازه‌های زمانی کوتاه از مدل استفاده گردد. پس سربار محاسباتی مدل، ویژگی دیگری است که از اهمیت بالایی برخوردار است.

برای کاهش سربار اجرایی مدل، اغلب از مدل‌های برون‌خط برای پیش‌بینی دما استفاده می‌شود [۱۱-۳]. در این رویکرد، مدل‌ها به‌صورت برون‌خط آموزش‌یافته و سپس در زمان اجرا مورد بهره‌برداری قرار می‌گیرند. این مدل‌ها برای آموزش نیاز به مجموعه داده‌ای دارند که شامل همه انواع تغییرات دمای پردازنده در شرایط مختلف باشد [۳]. تغییر دمای پردازنده به پارامترهای زیادی از جمله بارکاری هر یک از هسته‌ها، فرکانس پردازنده، سرعت فن و دمای محیط پیرامون بستگی دارد. از آنجایی‌که ایجاد یک مجموعه داده کامل غیرعملی به نظر می‌آید، مدل دمایی در زمان اجرا با حالت‌هایی مواجه می‌شود که برای آن‌ها آموزش داده نشده است [۱۲]. در این وضعیت، پیش‌بینی‌های دقیقی توسط مدل ارائه نخواهد شد. بر این اساس، تعدادی مدل دمایی ارائه شده‌اند که آموزش آن‌ها به‌صورت برخط انجام شده است [۱۴-۱۲]. این مدل‌ها در صورت مواجهه با رفتارهای دمایی جدید در زمان اجرا، آن‌ها را یاد گرفته تا در برخوردهای بعدی دقت بهتری را ارائه دهند.

به دلیل تنوع بالای رفتارهای دمایی پردازنده، برخی از روش‌های پیش‌بینی دما، از چندین مدل بهره‌برده‌اند [۳، ۱۲، ۱۵]. در این راستا، فازهای مختلفی برای تغییرات دمای پردازنده شناسایی شده و برای هر فاز از یک مدل استفاده شده است.

برای پیش‌بینی دما، از ویژگی‌های مختلفی به‌عنوان ورودی‌های مدل دمایی استفاده کرده‌اند. در تعدادی از مدل‌ها از تعداد بالایی از ویژگی‌ها، بدون توجه به تأثیر آن‌ها بر دمای سیستم بهره گرفته‌اند. استفاده از تعداد بالای ویژگی‌ها، علاوه بر افزایش سربار مدل، می‌تواند باعث کاهش دقت مدل نیز گردد [۱۶]. بر این اساس، به انتخاب ویژگی‌های مناسب پرداخته شده است. اغلب، این ویژگی‌ها با توجه به دانش یک فرد خبره انتخاب شده‌اند. در [۱۴]، انتخاب ویژگی‌ها با استفاده از الگوریتم انتخاب ویژگی همبستگی^۵ (CFS) انجام شده است. انتخاب ویژگی‌های مناسب می‌تواند منجر به افزایش قابل‌توجه عملکرد مدل شود.

در این مقاله یک مدل پیش‌بینی دمای برخط پیشنهاد شده که از تعدادی شبکه عصبی پرسپترون چندلایه‌ای^۶ (MLP) تشکیل شده است. هر شبکه^۷ MLP برای یک فاز از رفتارهای دمایی آموزش داده می‌شود. برای هر شبکه، به‌صورت مجزا ویژگی‌های مناسب انتخاب می‌گردند. مدل پیشنهادی بر روی یک پردازنده چندهسته‌ای و بدون نیاز به سخت‌افزار اضافی بررسی شده است. در ادامه، به‌صورت مختصر نوآوری‌های مقاله معرفی می‌شوند:

- علاوه بر ویژگی‌هایی که با استفاده از ابزارهای اندازه‌گیری سیستم قابل خواندن هستند، تعدادی ویژگی جدید ایجاد شده که تأثیر قابل‌توجهی بر دقت مدل پیش‌بینی دمای پیشنهادی دارند. تعداد زیادی از این ویژگی‌ها با عنوان پارامترهای سابقه‌ای، آخرین تغییرات پارامترهای دمایی را نگهداری می‌کنند. همچنین، برخی از ویژگی‌ها، برای محاسبه اثر پارامترهای کنترلی فراهم شده‌اند.
- با توجه به تعدادی از پارامترهای مؤثر بر دما، رفتارهای دمایی پردازنده به چندین فاز تقسیم شده است. این فازها در مواجهه با رفتارهای دمایی جدید در زمان اجرا، به‌روزرسانی می‌شوند.
- برای هر فاز، 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 تفاضل اطلاعات متقابل^۸ (MID) انتخاب می‌شوند.

این مقاله در چند بخش سازمان‌دهی شده است. مدل‌های مختلفی که برای پیش‌بینی دما ارائه شده‌اند، در بخش دوم معرفی می‌شوند. در بخش سوم به معرفی شبکه مورد استفاده برای خوشه‌بندی و الگوریتم انتخاب ویژگی بر پایه اطلاعات متقابل پرداخته شده است. معرفی روند

بارکاری به‌عنوان یکی از پارامترهای مؤثر بر دمای پردازنده، در تعداد زیادی از رویکردهای پیش‌بینی دما موردتوجه قرار گرفته است [۶-۱۱]. در این راستا، در تعدادی از رویکردها، از شمارنده‌های کارایی، به‌عنوان معرف تأثیر بارکاری بر دمای پردازنده بهره برده‌اند [۱۰، ۱۱، ۱۷]. در این راستا، [۱۷] از ترکیب خطی از شمارنده‌های کارایی برای تخمین دما با رابطه ۳ استفاده کرده است.

$$T_{overall} = w_{const} + \sum_{i=1}^{22} w_i \frac{u_i}{t_{total}} \quad (3)$$

w_i و u_i به ترتیب مقادیر شمارنده کارایی نام و ضریب آن می‌باشند. t_{total} تعداد چرخه‌های پردازنده است. w_{const} نیز به‌عنوان ضریب ثابت، در زمان تعیین ضریب‌های مدل محاسبه می‌شود. ضریب‌های رابطه ۳، به‌صورت برون‌خط محاسبه می‌شوند.

شمارنده‌های کارایی، به‌عنوان ورودی‌های مدل رگرسیون بردار پشتیبان^{۱۰} (SVR) برای پیش‌بینی دما استفاده شده‌اند [۱۰]. در مدل ارائه‌شده، از ۳۴ شمارنده کارایی بهره گرفته‌اند. نتایج حاصل‌شده، کمتر از ۱۰ درصد خطا را برای فاصله زمانی ۱۰ ثانیه‌ای نشان می‌دهد.

در [۱۸]، از شمارنده‌های کارایی به‌عنوان ورودی‌های مدل MLP برای پیش‌بینی دما بهره گرفتند. ایشان مدل را با برنامه‌های محک مختلف ارزیابی کردند. معیار خطای جذر میانگین مربعات^{۱۱} (RMSE) بین ۲/۷ تا ۲/۹ درجه سانتی‌گراد گزارش شده است. به‌صورت کلی، مدل‌هایی که تنها از شمارنده‌های کارایی برای پیش‌بینی دما بهره می‌برند، به بسیاری از پارامترهای مؤثر بر دما، توجهی ندارند. این موضوع، می‌تواند منجر به کاهش دقت مدل گردد.

در [۶]، توان مصرفی پردازنده با استفاده از مدل SVR پیش‌بینی شده است. سپس از ابزار HotSpot [۱۹] برای تخمین دما با توجه به توان مصرفی بهره برده‌اند. از مهم‌ترین چالش‌های این رویکرد، می‌توان به نیاز مدل به استفاده از علم معماری CPU در پیکربندی HotSpot اشاره کرد. از MLP، برای پیش‌بینی حداکثر دمای یک هسته، در یک پردازنده چند هسته‌ای استفاده شده است [۲۰]. بدین منظور، با اجرای یک برنامه، حداکثر و میانگین توان مصرفی آن بر روی یک هسته محاسبه می‌شود. سپس، در زمان اجرای برنامه، با استفاده از این پارامترها و دمای همسایه‌های یک هسته، دمای هسته را پیش‌بینی می‌کنند. در [۲۱]، [۲۲]، از یک شبکه عصبی ساده برای پیش‌بینی دمای یک هسته بهره گرفته‌اند. در این کارها، از دمای فعلی و توان مصرفی برای 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.

ایجاد مدل دمایی به‌صورت برون‌خط در بخش چهارم انجام شده است. در بخش پنجم، نحوه استفاده از مدل دمایی و آموزش آن در زمان اجرا، معرفی می‌گردد. در بخش ششم، مدل پیشنهادی ارزیابی شده و با تعدادی از رویکردهای پیش‌بینی دما، مقایسه می‌شود. در نهایت در بخش هفتم، نتیجه‌ای از مدل پیشنهادی ارائه می‌گردد.

۲- کارهای پیشین

یکی از مهم‌ترین روش‌های پیش‌بینی دما، استفاده از تحلیل آماری سری زمانی، از جمله مدل خود رگرسیون میانگین متحرک^۸ (ARMA) است [۱۳، ۱۲].

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

y_{t-i} و e_{t-i} به ترتیب دما و خطای پیش‌بینی در زمان $t-i$ است. a_i و c_i ضریب‌های نمونه نام به ترتیب در بخش‌های AR و MA هستند. e_t نیز با توجه به داده‌های جمع‌آوری‌شده و در زمان تعیین ضرایب مدل محاسبه می‌شود. p و q به ترتیب اندازه پنجره‌های AR و MA را نشان می‌دهند. در رویکرد برون‌خط مجموعه‌ای از ضریب‌های رابطه ۱، بر اساس دما و بارهای کاری متفاوت تهیه شده و در بانکی از ضرایب ذخیره می‌شوند. در زمان اجرا، برای انطباق مدل دمایی با رفتار متغیر بارکاری، با استفاده از آزمون نسبت احتمال متوالی^۹ (SPRT)، ضریب‌های مناسب برای مشاهدات دمایی اخیر، با احتمال درستی بالا انتخاب می‌شوند. آموزش این مدل به‌صورت برخط نیز انجام شده است [۱۲]. در صورتی که احتمال درستی تمامی ضریب‌های موجود در بانک پایین باشد، بر روی پنجره از مشاهدات اخیر، ضریب‌های جدیدی برای مدل ARMA آموزش داده‌شده و به بانک اضافه می‌گردد. 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.

در تعدادی از مدل‌های دمایی، از دمای همه هسته‌های پردازنده در پیش‌بینی دمای هر هسته، بهره گرفته شده است [۵-۳]. در این راستا، [۴] از رابطه خطی ۲ برای پیش‌بینی دمای هسته i استفاده کرده است.

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

T_i^{curr} و T_i^{pred} به ترتیب معرف دمای فعلی و دمای پیش‌بینی‌شده برای هسته i هستند. تغییرات دمای هسته و میانگین تغییرات دمای هسته‌های مجاور آن در آخرین دوره زمانی، به ترتیب با I_i^{in} و I_i^{nb} نمایش داده شده‌اند. α_i ، β_i و γ_i ضریب‌های رابطه بوده که به‌صورت برون‌خط و با استفاده از یک تابع رگرسیون خطی بر روی یک مجموعه داده از تغییرات دمایی سیستم محاسبه می‌شوند.

استفاده کرده‌اند. برای ارزیابی مدل ارائه‌شده، از شبیه‌ساز HotSpot بهره برده‌اند. در این رویکرد نیز از تعداد قابل توجهی از پارامترهای مؤثر بر دما استفاده نشده است.

۳- تعاریف اولیه

در این بخش به معرفی روش انتخاب ویژگی و شبکه مورد استفاده در مدل دمایی پیشنهادی پرداخته می‌شود.

۳-۱- انتخاب ویژگی بر پایه اطلاعات متقابل

استفاده از تعداد بالای ویژگی‌ها، به‌عنوان ورودی‌های یک مدل، علاوه بر افزایش سربار محاسباتی یک مدل، می‌تواند منجر به کاهش دقت آن نیز گردد. از مهم‌ترین معیارها یک الگوریتم انتخاب ویژگی، حداکثر سازی همبستگی و یا اطلاعات متقابل^{۱۳} (MI) بین مجموعه ویژگی‌های انتخابی با خروجی مدل است. از رابطه ۵ برای محاسبه MI بین دو ویژگی x و y استفاده می‌گردد [۱۶].

$$I(x; y) = \iint p(x, y) \log \frac{p(x)}{p(x)p(y)} dx dy. \quad (5)$$

$p(x)$ و $p(y)$ به ترتیب توابع چگالی احتمال متغیرهای x و y می‌باشند. $p(x, y)$ تابع چگالی احتمال وقوع هم‌زمان هر دو متغیر x و y است. یک رویکرد در انتخاب ویژگی‌های مناسب، محاسبه میانگین MI همه زیرمجموعه‌های ممکن از مجموعه کل ویژگی‌ها، با خروجی مدل است. سپس، زیرمجموعه مناسب با رابطه ۶ انتخاب می‌شود [۱۶].

$$\max V_I(S, h), \quad V_I = \frac{1}{|S|} \sum_{i \in S} I(i, h) \quad (6)$$

S زیرمجموعه‌ای از ویژگی‌ها است. V_I معرف میانگین MI بین ویژگی‌های مجموعه S با خروجی مدل (h) است. از آنجایی که زیرمجموعه انتخابی ممکن است شامل ویژگی‌هایی باشد که مقدار MI بالایی با یکدیگر داشته باشند، از معیار دیگری بهره گرفته می‌شود. بدین منظور، از معیار حداقل افزونگی، برای یافتن زیرمجموعه ویژگی‌هایی که حداقل همبستگی را با هم دارند، استفاده می‌گردد. این معیار با رابطه ۷ محاسبه می‌شود [۱۶].

$$\min W_I(S), \quad W_I = \frac{1}{|S|^2} \sum_{i, j \in S} I(i, j) \quad (7)$$

ترکیب دو رابطه ۶ و ۷ منجر به ارائه مفهومی با نام کمینه افزونگی بیشینه وابستگی^{۱۴} (mRMR) شده است. mRMR با رابطه ۸ محاسبه می‌شود [۱۶].

$$\max \varphi(V, W), \quad \varphi = V - W \quad (8)$$

$\varphi(\cdot)$ تابعی مانند تفاضل، برای ترکیب دو معیار بیشینه وابستگی و کمینه افزونگی است. از آنجایی که تعداد محاسبه‌های لازم برای بررسی

استفاده از پارامترهای مختلف برای یک مدل دمایی، می‌تواند باعث افزایش دقت پیش‌بینی شود. در این راستا، [۱۴] از ترکیبی از ویژگی‌های فیزیکی پردازنده و ویژگی‌های وابسته به برنامه به‌عنوان ورودی‌های مدل دمایی استفاده کرده است. به علت تعداد زیاد ویژگی‌ها، با استفاده از الگوریتم CFS، ۱۶ ویژگی به‌عنوان ورودی‌های مدل دمایی انتخاب شده‌اند. این ویژگی‌ها شامل ۱۴ شمارنده کارایی، ولتاژ پردازنده و دمای فعلی هسته موردنظر برای پیش‌بینی دما است. در حالتی که آموزش مدل به‌صورت برخط انجام شده است، میزان خطای مدل حدود ۱ درجه سانتی‌گراد محاسبه شده است.

تعدادی از رویکردهای ارائه‌شده برای پیش‌بینی دما، از چند مدل به‌جای استفاده از یک مدل، بهره برده‌اند [۳، ۱۲، ۱۵]. این رویکرد، امکان استفاده از مدل‌های خطی با دقت بالا برای پیش‌بینی دما را فراهم می‌کند. برای تعیین تعداد مدل‌ها، بارکاری خوشه‌بندی شده است. بارهای کاری مختلف، در شرایط متفاوت پردازنده، دما را با سرعت‌های متفاوتی تغییر می‌دهند. روند تغییرات دما به‌عنوان رفتار دمایی معرفی می‌شود. بارهای کاری مختلف با توجه به رفتار دمایی که ایجاد می‌کنند به فازهای مختلفی تقسیم می‌شوند. بدین منظور، از شمارنده‌های کارایی برای شناسایی فازهای بارکاری با استفاده از خوشه‌بندی K-means بهره برده‌اند [۳]. پیش از خوشه‌بندی، به دلیل تعداد بالای شمارنده‌های کارایی، از تحلیل مؤلفه‌های اساسی^{۱۵} (PCA) برای کاهش فضای ورودی های خوشه‌بندی استفاده شده است. سپس، برای هر فاز از یک رابطه خطی مجزا با شکل کلی رابطه ۴ برای پیش‌بینی دما بهره برده‌اند.

$$g_m[i] = T_m[i] - \sum_{n=1}^N a_{mn} T_n[i-1] - a_m^{idle} \quad (4)$$


$T_m[i]$ دمای هسته m در زمان i است. a_{mn} ضریب تأثیر تغییر دمای هسته n بر دمای هسته m است. a_m^{idle} با توجه به دمای هسته m و در زمان بیکاری آن محاسبه می‌شود. g_m معرف اثر بارکاری، بر دمای هسته m است. برای محاسبه g_m در فازهای مختلف، برنامه‌های محک متفاوتی در حالت‌های مختلف سیستم بر روی آن اجرا می‌شوند. در مدل ارائه‌شده، دمای یک هسته، با استفاده از یک رابطه خطی از دمای هسته‌های CPU محاسبه می‌گردد. در صورت در نظر گرفتن اثر پارامترهای مختلف در رفتارهای دمایی سیستم، تعداد مدل‌های موردنیاز برای پیش‌بینی دما افزایش قابل توجهی می‌یابد.

در [۱۵]، 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

زمانی که شبکه ART برای خوشه‌بندی استفاده می‌گردد، نزدیک‌ترین خوشه با توجه به الگوی بردار ورودی انتخاب می‌شود. سپس خوشه انتخابی برای نزدیک‌تر شدن به الگوی ورودی بروز می‌شود. پارامتر مراقبت 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- ایجاد مدل پیش‌بینی دمای پیشنهادی

مدل پیشنهادی در دو مرحله برون‌خط و برخط توسعه داده شده است. در مرحله برون‌خط، ابتدا یک مجموعه داده مناسب برای آموزش مدل ایجاد می‌شود. سپس، فازهای مختلف رفتارهای دمایی پردازنده، شناسایی می‌شوند. آنگاه، یک مجموعه داده مناسب برای آموزش هر فاز جمع‌آوری می‌گردد. درنهایت، برای هر فاز یک مدل مناسب برای پیش‌بینی دما ایجاد شده و ساختار آن در یک مجموعه ثبت می‌شود. جریان کلی مرحله برون‌خط، در شکل ۲ نمایش داده شده است.



شکل ۲: روند ایجاد مدل پیش‌بینی دما شامل فازهای مختلف دمایی و شبکه مناسب برای پیش‌بینی در هر فاز


همه زیرمجموعه‌های موجود، با افزایش تعداد ویژگی‌ها به‌صورت نمایی افزایش می‌یابد، از روابطی برای تخمین mRMR بهره گرفته‌اند [۲۳]. در این مقاله از روش MID که از روش‌های متداول بدین منظور بوده و تخمین خوبی از mRMR ارائه می‌دهد، استفاده شده است. این روش با رابطه ۹ محاسبه می‌شود [۲۳].

$$\max_{i \in \varphi(S)} [I(i, h) - \frac{1}{|S|} \sum_{j \in S} I(i, j)] \quad (9)$$

روش‌های متنوعی برای انتخاب ویژگی‌های مناسب برای یک مدل وجود دارد. برخی از روش‌ها، ویژگی‌های مناسب را با انجام آزمایش‌های متعدد و با توجه دانش خبره انتخاب می‌کنند [۲۴]. تعدادی دیگر از رویکردها، از روش‌های فرا اکتشافی بهره می‌برند [۲۵]. بالاین‌حال، رابطه MID، با اینکه دارای سربار محاسباتی پایین است، دقت و قابلیت اطمینان بالایی را ارائه می‌دهد.

۳-۳- شبکه نظریه تشدید انطباقی (ART)

شبکه ART، مناسب برای مسائلی است که نیاز به یادگیری برخط دارند. در این شبکه، که از شبکه‌های عصبی رقابتی خودسازمان‌ده است می‌توان از الگوریتم‌های یادگیری با نظارت و یا بدون نظارت بهره برد. سیستم ART اولیه، یک مدل یادگیری بدون نظارت است. این سیستم شامل دو لایه مقایسه و بازشناسی است که هر یک از آن‌ها از تعدادی نرون تشکیل شده است. همچنین، از پارامتر مراقبت^{۱۵} بهره برده که تأثیر قابل‌توجهی بر عملکرد سیستم دارد. ساختار ART پایه در شکل ۱ نمایش داده شده است. نرون‌های لایه مقایسه، بردار ورودی را دریافت کرده و آن را به نرونی انتقال می‌دهد که بیش‌ترین تطابق را در بین نرون‌های لایه بازشناسی دارد. وزن اتصال نرون انتخابی کمترین فاصله را با بردار ورودی دارد. هر نرون لایه بازشناسی، با توجه به کیفیت تطابق ورودی با نرون انتخابی، یک سیگنال منفی دریافت کرده تا از تولید خروجی جلوگیری کند. از واحد بازشناسی برای مقایسه میزان تطابق بازشناسی با پارامتر مراقبت استفاده می‌شود. اگر حد‌آستانه پارامتر مراقبت نقض شده باشد، آموزش شبکه شروع می‌گردد. در غیر این صورت نرون انتخابی، برای تطابق بیشتر با بردار ورودی تنظیم می‌شود [۲۶].



شکل ۱: ساختار اولیه شبکه ART

۴-۱- ایجاد مجموعه داده

مدل پیش‌بینی دمای پیشنهادی بر روی سیستمی با پردازنده چهار هسته‌ای Intel's Core i7-950 ارائه و ارزیابی شده است. در این پردازنده، هر هسته دارای یک حسگر دمایی است و از ابزار Lm-sensor برای خواندن دما آن‌ها استفاده شده است. در این سیستم، می‌توان به صورت مجزا شمارنده‌های کارایی هر هسته را خواند. جدول ۱ لیست شمارنده‌های استفاده‌شده در ایجاد مدل پیشنهادی را نشان می‌دهد.

جدول ۱: لیست شمارنده‌های کارایی

نام شمارنده کارایی
CONTEXT-SWITCHES
CPU-MIGRATIONS
PERF_COUNT_SW_PAGE_FAULTS
CYCLES
PERF_COUNT_HW_STALLED_CYCLES_FRONTEND
PERF_COUNT_HW_STALLED_CYCLES_BACKEND
INSTRUCTIONS
BRANCHES
BRANCH-MISSES
CACHE-REFERENCES
IO_TRANSACTIONS
LID_ALL_REF
CACHE-MISSES

فرکانس پردازنده به صورت سراسری و یکسان برای همه هسته‌ها با استفاده از ابزار CPUfreq قابل تنظیم است. از فن خنک‌کننده به منظور کاهش مکانیکی دمای پردازنده استفاده می‌شود. برنامه‌های مناسب برای ایجاد رفتارهای دمایی مختلف، از مجموعه داده محک SPEC CPU2006 انتخاب می‌گردند. مدل دمایی پیشنهادی، برای یک هسته با عنوان هسته هدف ارائه شده است.

ایجاد یک مجموعه داده کامل برای آموزش مدل دمایی که شامل همه رفتارهای دمایی سیستم باشد، غیرعملی است. برای ایجاد مجموعه داده مناسب، از الگوریتم معرفی‌شده در شکل ۳ استفاده شده است. در این

۴-۲- تولید ویژگی‌های سابقه‌ای و کنترلی

از آنجایی که روند تغییرات دما نیز، در پیش‌بینی دمای هسته تأثیرگذار است، ویژگی‌هایی در این راستا ایجاد شده و به مجموعه داده اضافه می‌گردند. تعدادی از این ویژگی‌ها با نام ویژگی‌های سابقه‌ای معرفی می‌شوند. این ویژگی‌ها برای حفظ سابقه‌ای از آخرین تغییرهای هر ویژگی از مجموعه داده، ایجاد می‌شوند. برای محاسبه مقادیر آن‌ها، تغییرهای هر ویژگی در چند ثانیه اخیر با رابطه ۱۰ محاسبه می‌گردد.

$$\nabla F_i(t, d) = f_i(t - d) - f_i(t - d - 1) \quad (10)$$

t شماره نمونه جاری و d فاصله تا نمونه جاری است. f_i معرف مقدار ویژگی نام است. از آنجایی که تغییر هر پارامتر دمایی بر دمای پردازنده حداکثر در چند ثانیه اثر می‌گذارد، حداکثر مقدار d با d_{max} معرفی می‌شود. مقدار پارامتر d بین صفر و d_{max} است. به ویژگی‌هایی که با این روش ایجاد می‌شوند، به عنوان گرادیان اول اشاره می‌گردد. گرادیان اول، نشان‌دهنده سرعت تغییر هر ویژگی در چند ثانیه اخیر است. از طرفی، تغییرات گرادیان‌های اول نیز، با رابطه ۱۰ محاسبه می‌شوند. ویژگی‌های ایجادشده با نام گرادیان‌های دوم، نشان‌دهنده شتاب آخرین تغییرات پارامترهای دمایی است. با توجه به آزمایش‌های انجام‌شده، حداکثر در سه ثانیه اثر پارامترهای مختلف بر مقدار دما اعمال می‌شود. به همین دلیل، مقدار d_{max} برابر با سه در نظر گرفته شده است. بر این اساس، تعداد پارامترهای سابقه‌ای ۱۰۷ عدد شده است.

```

ψ ← {fan speed levels}
χ ← {processor frequency levels};
Start system profiling;
for η = 1 to #cores do:
begin
Dispatch a benchmark for each of η cores;
for i = 1 to |ψ| do:
begin
Set_fan(ψi);
Shuffle(χ);
for j = 1 to |χ| do:
begin
Set_frequency(χj);
Wait(10 seconds);
end
end
Terminate all dispatched benchmarks;
end
Stop system profiling;
```


شکل ۳: شبه‌کد جمع‌آوری داده از سیستم

قابل توجهی بر دقت پیش‌بینی دما می‌گذارد. لازم به ذکر است که ساختار شبکه عصبی از جمله تعداد نرون‌ها و نوع تابع فعالیت آن‌ها، با انجام آزمایش‌های مختلف انتخاب شده است.

۴-۳- ایجاد مدل پیش‌بینی دما

استفاده از یک شبکه عصبی برای پیش‌بینی همه رفتارهای دمایی پردازنده، دقت بالایی را در همه حالت‌ها ارائه نمی‌دهد و از طرفی آموزش آن مشکل است. برای افزایش دقت و آموزش سریع در رفتارهای متفاوت دمایی، فازهای دمایی پردازنده با خوشه‌بندی پارامترهای مؤثر بر آن تعیین می‌شوند. بدین منظور، نیاز به انتخاب پارامترهای مناسب برای خوشه‌بندی است.

به دلیل اینکه استفاده از همه پارامترهای دمایی، خوشه‌بندی مطلوبی را ارائه نمی‌دهد، به اولویت‌بندی پارامترهای دمایی با استفاده از روش MID پرداخته می‌شود. بر این اساس، 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 داده فراهم‌شده، با توجه به وابستگی با خروجی مدل، که دمای مورد انتظار است، اولویت‌بندی می‌شوند. این اولویت‌بندی با استفاده از روش MID انجام شده و ویژگی‌ها به بردار V اضافه می‌شوند. سپس، در $|V|$ مرحله زیرمجموعه‌هایی شامل $1 \leq k \leq |V|$ عنصر ابتدایی از بردار V انتخاب می‌گردند. در هر مرحله، دقت مدل MLP با ویژگی‌های انتخابی محاسبه می‌شود. به‌عنوان نمونه، نتیجه افزایش تعداد ویژگی‌ها در دقت مدل پیش‌بینی دمای ۵ ثانیه آینده در شکل ۴ نمایش داده شده است. با توجه به شکل، افزایش تعداد ویژگی‌ها بیش از ۹ ویژگی، کاهش محسوسی در خطای مدل ایجاد نمی‌کند. بر این اساس، این تعداد ویژگی برای خوشه‌بندی فازهای دمایی انتخاب می‌شود.



شکل ۴: خطای مدل پیش‌بینی دمای ۵ ثانیه آینده

همچنین، تعدادی از ویژگی‌های فراهم‌شده در مجموعه داده، به‌منظور تواناسازی مدل در جهت پیش‌بینی دما با توجه به پارامترهای کنترلی ارائه شده‌اند. پارامترهای کنترلی مانند فرکانس پردازنده و سرعت فن، برای کنترل دمای پردازنده مورد استفاده قرار می‌گیرند. اگر سیستم‌عامل، پیش‌بینی دقیقی از اثر متغیرهای کنترلی بر دما داشته باشد، می‌تواند از روش‌های کنترلی بهره‌بردار که حداقل کاهش عملکرد سیستم را موجب شوند. بر این اساس، تغییر فرکانس پردازنده و سرعت فن به‌عنوان ویژگی‌های گرادیان آینده با رابطه ۱۱ محاسبه می‌شود.

$$\nabla f_i(t) = f_i(t+1) - f_i(t) \quad (11)$$

در ادامه، اثر استفاده از ویژگی‌های سابقه‌ای و کنترلی، در پیش‌بینی دما با استفاده از شبکه عصبی MLP مورد ارزیابی قرار گرفته است. برای محاسبه دقت مدل، معیار میانگین قدرمطلق خطا^{۱۶} (MAE) با رابطه ۱۲ محاسبه می‌شود.

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad (12)$$

N تعداد نمونه‌ها در مجموعه داده آزمایش است. y_i مقدار خروجی محاسبه‌شده توسط مدل و t_i مقدار مورد انتظار نمونه نام است. همچنین، دو معیار دیگر شامل انحراف معیار قدرمطلق خطاها^{۱۷} (SDAE) و درصد خطاهای خارج از محدوده^{۱۸} (POE) محاسبه می‌شوند. SDAE با رابطه ۱۳ محاسبه می‌شود.

$$SDAE = \sqrt{\frac{1}{N} \sum_{i=1}^N (|t_i - y_i| - MAE)^2} \quad (13)$$

از رابطه ۱۴، برای محاسبه $POE(x)$ استفاده شده است.

$$POE(x) = \frac{|\{ |t_i - y_i| \leq x \mid \forall i \in \{1, 2, \dots, N\} \}|}{N} \quad (14)$$

$POE(3)$ احتمال خطاهای پیش‌بینی بالای ۳ درجه سانتی‌گراد را نشان می‌دهد.

برای ارزیابی اثر استفاده از پارامترهای سابقه‌ای و کنترلی، با توجه به مجموعه داده جمع‌آوری‌شده، در دو حالت مختلف پیش‌بینی دما انجام شده است. نتایج این ارزیابی در جدول ۲ نمایش داده شده است. در حالت اول، ورودی‌های شبکه MLP تنها شامل حالت فعلی سیستم است. در حالت دوم، از ویژگی‌های سابقه‌ای و کنترلی نیز استفاده می‌گردد. با توجه به نتایج حاصل‌شده، استفاده از ویژگی‌های سابقه‌ای و کنترلی تأثیر

جدول ۲: 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٪

۵- بهره‌گیری و آموزش مدل دمایی در زمان اجرا

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

خلاصه روند استفاده از مدل دمایی پیشنهادی در زمان اجرا در شکل ۶ نمایش داده شده است. در ابتدا، برای شناسایی فاز دمایی، ویژگی‌های موردنیاز، با استفاده از ابزارهای اندازه‌گیری و رابطه‌های پیشنهادی فراهم می‌شوند. سپس، نزدیک‌ترین فاز با حالت دمایی جاری سیستم انتخاب می‌گردد. اگر حالت دمایی جاری، تطابق کافی با فاز انتخابی داشته باشد، مدل دمایی متناظر با آن برای پیش‌بینی دما انتخاب می‌شود. از پارامتر مراقبت برای بررسی حدآستانه تطابق استفاده می‌شود. آنگاه، ویژگی‌های لازم برای مدل دمایی مربوط به فاز انتخابی، خوانده می‌شوند. درنهایت، دما d ثانیه آینده، با استفاده از مدل و ویژگی‌های انتخابی، پیش‌بینی می‌گردد. از طرفی، آموزش مدل در زمان اجرا ادامه می‌یابد. بدین منظور، با مشاهده دمای d ثانیه آینده، خطای مدل محاسبه می‌شود. در صورتی که خطای مدل بیش از ۲ درجه سانتی‌گراد باشد، آموزش مدل دمایی با نمونه جاری انجام می‌شود.

از طرفی، اگر مقدار تطابق حالت دمایی جاری با فاز انتخابی، حدآستانه پارامتر مراقبت را نقض کند، یک فاز دمایی جدید ایجاد می‌گردد. بدین منظور، فاز جدید به همراه پارامترهای موردنیاز، به شبکه ART اضافه می‌شود. در این راستا، وزن‌های شبکه نیز بروز می‌گردند. در این حالت، که به تعداد دفعات پایین در سیستم اتفاق می‌افتد، نیاز است که ویژگی‌های مناسب برای فاز دمایی جدید انتخاب شوند. لازم به ذکر است که با افزایش نمونه‌های مربوط به فاز جدید، ویژگی‌های بهتری برای آن انتخاب می‌گردند. سپس، یک مدل دمایی با استفاده از ویژگی‌های انتخابی برای فاز جدید، ایجاد می‌شود. درنهایت، ساختار مدل دمایی ایجادشده، به مجموعه مدل‌های دمایی، اضافه شده تا برای پیش‌بینی‌های آینده استفاده شود.


۶- ارزیابی مدل پیشنهادی

مدل دمایی برخط پیشنهادی، برای پیش‌بینی دمای یک هسته برای ۲ تا ۵ ثانیه آینده ارزیابی می‌شود. برای اینکه تنوع بالایی از رفتارهای دمایی در انجام آزمایش‌ها ایجاد شود از برنامه‌های استفاده شده است که تفاوت‌های قابل توجهی در میزان استفاده از CPU دارند. این ویژگی باعث


ویژگی‌هایی که برای خوشه‌بندی انتخاب شده‌اند، شامل گرادین‌های آینده پارامترهای کنترلی، دمای هسته‌های پردازنده، شمارنده‌های کارایی CYCLES و INSTRUCTIONS و مقدار ۲ ثانیه قبل شمارنده کارایی CPU-MIGRATIONS هستند. این ویژگی‌ها برای شناسایی فازهای دمایی، به‌عنوان ورودی به شبکه ART داده می‌شوند. سپس، از شبکه MLP برای پیش‌بینی دما برای هر فاز دمایی استفاده می‌شود. خروجی شبکه، دمای پیش‌بینی‌شده برای $d \geq 1$ ثانیه بعد است.

برای آموزش شبکه عصبی برای هر فاز، نمونه‌های مربوطه از مجموعه داده اولیه انتخاب می‌شوند. سپس، اولویت‌بندی ویژگی‌های هر فاز با بهره‌گیری از روش MID انجام می‌شود. آنگاه، با توجه به تأثیر افزایش تعداد ورودی‌ها بر دقت مدل، ورودی‌های مناسب برای هر فاز انتخاب می‌گردند. برای هر مجموعه از ویژگی‌های ورودی، از مدل MLP برای پیش‌بینی دما استفاده می‌گردد. در این راستا، از روش اعتبارسنجی k تایی^{۱۹}، برای انتخاب مجموعه‌های آموزش و آزمایش استفاده شده است. تأثیر افزایش تعداد ویژگی‌ها در دقت مدل‌های دمایی برای فاصله زمانی ۲ ثانیه آینده در شکل ۵ 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 ۵ نمایش داده شده است.

بعد از انتخاب ویژگی‌های مناسب، مدل MLP مجزایی برای هر فاز، با رویکرد افزایشی آموزش داده می‌شود. در این روش، آموزش مدل با توجه به خطای مدل برای هر نمونه انجام می‌گردد. در انتهای این مرحله، برای هر فاز دمایی، یک شبکه عصبی مناسب، برای پیش‌بینی دما ایجاد می‌شود.



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




شکل ۶: روند آموزش مدل پیش‌بینی دما در زمان اجرا

اثر افزایش تعداد ویژگی‌ها، در دقت مدل‌ها برای هر فاصله زمانی محاسبه شده است. نتایج این ارزیابی در شکل ۸ نمایش داده شده است. برای همه فاصله‌های زمانی، افزایش تعداد ویژگی‌ها تا یک تعداد معین، منجر به کاهش MAE می‌گردد. بر این اساس، حداقل ویژگی‌های لازم برای هر فاصله زمانی انتخاب شده‌اند.


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 همه ویژگی‌ها برای خوشه‌بندی فازهای دمایی مقایسه شده است. نتایج این مقایسه، که بر روی یک مجموعه داده ثابت و به‌صورت برون‌خط انجام شده، در جدول ۳ نمایش داده شده است. در حالت اول از ویژگی‌های انتخابی برای خوشه‌بندی استفاده شده است. در حالت دوم، از کل ویژگی‌ها برای خوشه‌بندی فازهای دمایی بهره گرفته شده است. با توجه به نتایج، استفاده از ویژگی‌های انتخابی در خوشه‌بندی رفتارهای دمایی هر ۴

ایجاد دماهای مختلف در پردازنده می‌شود. برنامه‌های محک مورد استفاده شامل libquantum, gcc, perlbench, mcf می‌باشند. در آزمایشی که نتایج آن در شکل ۷ نمایش داده شده است، مدل‌های MLP، SVR و حداقل میانگین مربع^{۲۰} (LMS) برای انتخاب مدل مناسب برای پیش‌بینی دما بررسی شده‌اند. لازم به ذکر است که از SVR برای پیش‌بینی دما در چندین مقاله بهره گرفته‌اند [۶، ۱۰]. همچنین، از LMS برای یافتن ضریب‌های فیلترهای خطی مناسب برای پیش‌بینی دما استفاده می‌شود. LMS، به‌عنوان نماینده‌ای از مدل‌های خطی با دیگر مدل‌ها مقایسه می‌گردد. از آنجایی که MLP نتیجه بهتری را نسبت به سایر مدل‌ها ارائه کرده است، به‌عنوان مدل مناسب در مدل پیشنهادی مورد بهره‌برداری قرار گرفته است.

ویژگی‌های مناسب برای خوشه‌بندی فازهای دمایی، برای فاصله‌های زمانی ۲ تا ۵ ثانیه آینده، انتخاب شده‌اند. بدین منظور، به‌صورت مجزا، ویژگی‌ها برای هر فاصله زمانی با روش MID اولویت‌بندی شده‌اند. سپس،



شکل ۸: خطای مدل پیش‌بینی دما برای فاصله‌های مختلف زمانی



شکل ۷: خطای استفاده از مدل‌های مختلف در پیش‌بینی دمای ۵ ثانیه آینده

جدول ۴: دقت مدل دمایی پیشنهادی بر پایه استفاده از LMS برای هر

فاز دمایی

فاصله زمانی (S)	MAE (°C)	SDAE (°C)	POE(3)
۲	۰/۷۰	۰/۸۶	۰/۶۵٪
۳	۰/۷۹	۱/۱۱	۰/۷۶٪
۴	۰/۹۱	۱/۲۳	۱/۲۱٪
۵	۱/۰۶	۱/۳۱	۱/۸۹٪

جدول ۵: دقت مدل پیش‌بینی دمای برخط برای فاصله‌های مختلف

زمانی

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

کمتر است. به علت دقت بالاتر مدل MLP و از آنجایی که تفاوت زمانی زیادی در زمان اجرا ندارند، از MLP برای توسعه مدل استفاده شده است. مدل پیشنهادی، برای پیش‌بینی دمای برخط استفاده می‌شود. نتیجه استفاده از مدل پیشنهادی برای پیش‌بینی دما از ۲ تا ۵ ثانیه آینده در زمان اجرا و در حالت‌های مختلف سیستم، در جدول ۵ نمایش داده شده است. میانگین و واریانس قدرمطلق خطاهای مدل پیشنهادی کمتر از ۱ درجه سانتی‌گراد برای همه فاصله‌های زمانی، به‌دست‌آمده است. همچنین، $POE(3)$ برای پیش‌بینی ۲ ثانیه آینده، کمتر از ۱ درصد بوده، که دقت بالای مدل پیشنهادی را نشان می‌دهد. برای ارزیابی اثر استفاده از یک مدل دمایی برخط به‌جای برون‌خط آزمایش دیگری انجام شده است. در این آزمایش، پس از ایجاد مدل دمایی به‌صورت برون‌خط، در زمان اجرا ترکیب‌های متفاوتی از برنامه‌ها، بر روی پردازنده اجرا شده‌اند. در این راستا، از برنامه‌هایی که در زمان آموزش مدل در سیستم اجرا نشده‌اند نیز استفاده شده است. جدول ۵ نتایج حالتی را نشان می‌دهد که از مدل برخط برای پیش‌بینی دما استفاده شده است. در جدول ۶ نتایج حالتی نمایش داده شده است که در زمان اجرا آموزش مدل ادامه پیدا نکرده است. در این حالت، مدل تنها با توجه به فازهای دیده‌شده در زمان ایجاد مدل، پیش‌بینی را برای همه نمونه‌ها انجام داده و امکان فراگیری فاز جدید در زمان اجرا را ندارد. به همین سبب، دقت مدل برخط به‌صورت قابل‌توجهی بهتر از دقت مدل دمایی ایجادشده به‌صورت برون‌خط است. در ارزیابی مدل، مقایسه‌ای با تعدادی از مدل‌های قابل‌توجه در پیش‌بینی دما انجام شده است. یکی از مدل‌های مورد مقایسه توسط کچران و همکاران ارائه شده است [۳، ۵]. ایشان با استفاده از یک مدل خطی برای هر فاز دمایی، دما را پیش‌بینی

جدول ۳: اثر استفاده از ویژگی‌های انتخابی در خوشه‌بندی فازهای

دمایی برای فاصله‌های مختلف زمانی

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

فاصله زمانی، دقت بالاتری نسبت به استفاده از همه ویژگی‌ها در خوشه‌بندی به دست می‌آید. از طرفی، استفاده از ویژگی‌های بیشتر، سربار محاسباتی را نیز افزایش می‌دهد.

همچنین، می‌توان بین اثر استفاده از خوشه‌بندی در پیش‌بینی دما و استفاده از یک مدل برای پیش‌بینی دما مقایسه‌ای ارائه کرد. بدین منظور، می‌توان از نتایج نمایش داده‌شده در دو جدول ۲ و ۳ بهره برد. در جدول ۲ نتیجه استفاده از یک مدل MLP در پیش‌بینی دمای ۵ ثانیه آینده ارائه شده است. از طرفی، در جدول ۳، در رکورد مربوط به حالت اول برای پیش‌بینی دمای ۵ ثانیه آینده، نتیجه استفاده از یک مدل MLP برای هر فاز دمایی، نمایش داده شده است. با توجه به مجموعه داده مورد استفاده، در این آزمایش، از ۶ فاز دمایی استفاده شده است. نتایج حاکی از دقت بالاتر مدل دمایی بر اساس خوشه‌بندی است. لازم به ذکر است که استفاده از مدل دمایی بر اساس خوشه‌بندی به زمان اجرای کمتری برای پیش‌بینی نیاز دارد. زیرا در این حالت از ویژگی‌های کمتری برای پیش‌بینی دما در هر فاز بهره می‌برد. به لحاظ حجم محاسباتی، زمان لازم برای پیش‌بینی یک نمونه در حالت خوشه‌بندی ۰/۰۱ میلی‌ثانیه و بدون استفاده از خوشه‌بندی ۰/۰۵ میلی‌ثانیه است. در ادامه، به مقایسه استفاده از یک مدل خطی برای پیش‌بینی دما در هر فاز نسبت به استفاده از مدل MLP پرداخته شده است. در تعدادی از مدل‌های ارائه‌شده برای پیش‌بینی دما، از یک مدل خطی برای پیش‌بینی در هر فاز بهره برده‌اند [۳، ۱۵]. بر این اساس، در مدل پیشنهادی، از LMS برای پیش‌بینی در هر فاز دمایی استفاده شده است. نتایج حاصل در جدول ۴ نمایش داده شده است. با مقایسه حالات اول جدول ۳ با جدول ۴ می‌توان به این نتیجه اشاره کرد که در همه فاصله‌های زمانی، استفاده از LMS دقت کمتری را نسبت به MLP، در مدل دمایی ایجاد می‌کند. از طرفی، زمان لازم برای پیش‌بینی دما بر پایه LMS، ۰/۰۶ میلی‌ثانیه است. این زمان نسبت به استفاده از MLP

دقت بالاتری را در همه معیارهای ارزیابی و برای همه فاصله‌های زمانی ارائه می‌دهد. از طرفی، مقایسه نتایج جداول ۵ و ۷ حاکی از آن است که مدل پیشنهادی در این مقاله، دقت بهتری برای همه فاصله‌های زمانی نسبت به دیگر مدل‌های دمایی مقایسه‌شده دارد.

۷- نتیجه‌گیری

این مقاله، یک مدل دمایی برخط برای پیش‌بینی دما، برای فاصله‌های زمانی مختلف پیشنهاد کرده است. مدل پیشنهادی، از تعدادی شبکه MLP با یادگیری افزایشی تشکیل شده است. هر شبکه برای پیش‌بینی دما در فاز دمایی متناظر با آن استفاده می‌شود. فازهای دمایی به‌صورت برون‌خط و با استفاده از شبکه ART تعیین می‌شوند. از طرفی، این امکان برای مدل وجود دارد که در زمان اجرا، در صورت برخورد با فاز جدید، آن را به مجموعه فازها اضافه کند. برای خوشه‌بندی، ویژگی‌های مناسب، با استفاده از روش MID و مدل MLP انتخاب می‌شوند. همچنین، برای هر فاز از مدل دمایی پیشنهادی، ویژگی‌های مناسب آن، به‌صورت برون‌خط انتخاب می‌شوند. هرچند، این امکان برای مدل فراهم شده که تنها 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 مقاله، ایجاد می‌شوند. ارزیابی‌های متنوعی در این مقاله انجام شده که حاکی از دقت بالای مدل دمایی پیشنهادی است.

مراجع

- [1] J. Kong, S. W. Chung and K. Skadron, "Recent thermal management techniques for microprocessors," ACM Computing Surveys (CSUR), vol. 44, p. 13, 2012.
- [2] 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.
- [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] G. Liu, M. Fan and G. Quan, "Neighbor-aware dynamic thermal management for multi-core platform," Design, Automation & Test in Europe Conference & Exhibition (DATE), pp. 187-192, 2012.
- [5] R. Cochran and S. Reda, "Consistent Runtime Thermal Prediction and Control through Workload Phase Detection," in Proc. 47th Design Automation Conf. (DAC), pp. 62-67, 2010.
- [6] M. Zaman, A. Ahmadi and Y. Makris, "Workload characterization and prediction: A pathway to reliable multi-

جدول ۶: دقت مدل پیش‌بینی دمای برون‌خط برای فاصله‌های مختلف

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

کرده‌اند. مدل‌های دمایی مربوط به فازهای مختلف، برون‌خط تنظیم شده‌اند. نتیجه استفاده از مدل ایشان، برای پیش‌بینی دما بر روی سیستم مورد آزمایش، محاسبه شده و نتایج در جدول ۷ نمایش داده شده‌اند. مدل دمایی دیگری که ارزیابی‌شده، مدل ARMA [۱۳، ۱۲] است. برای مقایسه بهتر و افزایش دقت مدل ARMA، آموزش مدل در زمان اجرا ادامه می‌یابد. یکی دیگر از مدل‌های مورد مقایسه، توسط نارایانا و همکاران ارائه شده است [۱۸]. نارایانا از شمارنده‌های کارایی به‌عنوان ورودی‌های شبکه MLP برای پیش‌بینی دما بهره برده‌اند. نتایج این ارزیابی که در جدول ۷ نمایش داده شده است، نشان‌دهنده دقت پایین این روش نسبت به دیگر مدل‌های مورد بررسی بوده است. آخرین مدل ارزیابی‌شده توسط زنگ و همکاران ارائه شده است [۱۴]. ایشان از شبکه MLP برای پیش‌بینی دما در دو حالت برون‌خط و برخط استفاده کرده‌اند. نتایج ارائه‌شده در این مقاله، حاصل از ارزیابی مدل زنگ به‌صورت برخط هستند. مدل زنگ نسبت به دیگر مدل‌های مورد مقایسه،

جدول ۷: دقت تعدادی از مدل‌های پیش‌بینی دما، برای فاصله‌های

مختلف زمانی

مدل	فاصله زمانی (S)	MAE (°C)	SDAE (°C)	POE(3)
کچران	۲	۱/۳۶	۲/۲۱	۸٪
کچران	۳	۱/۷۸	۲/۴۶	۱۰٪
کچران	۴	۲/۱۶	۲/۹۱	۱۶٪
کچران	۵	۲/۶۵	۳/۱	۱۸٪
ARMA	۲	۱/۶۳	۲/۸۳	۱۱٪
ARMA	۳	۱/۷۴	۲/۹۴	۱۱٪
ARMA	۴	۲/۰۹	۳/۴۳	۱۶٪
ARMA	۵	۲/۴۶	۳/۶۷	۱۷٪
نارایانا	۲	۲/۶۱	۲/۱	۱۹٪
نارایانا	۳	۲/۸۲	۲/۲	۲۱٪
نارایانا	۴	۲/۹۸	۲/۷	۲۳٪
نارایانا	۵	۳/۱۹	۳/۰۳	۲۴٪
زنگ	۲	۱/۲	۱/۹۱	۶٪
زنگ	۳	۱/۳۷	۲/۰۲	۷/۱٪
زنگ	۴	۱/۴۷	۲/۱۴	۸/۲٪
زنگ	۵	۱/۵۲	۲/۱۹	۸/۹٪

- [17] S. J. Lu, R. Tessier and W. Bursleson, "Dynamic On-Chip Thermal Sensor Calibration Using Performance Counters," IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, vol. 33, no. 6, pp. 853-866, 2014.
- [18] S. A. Narayana, "An artificial neural networks based temperature prediction framework for network-on-chip based multicore platform," Thesis, Rochester Institute of Technology, 2016.
- [19] K. Skadron, M. R. Stan, W. Huang, S. Velusamy, K. Sankaran-Arayanan and D. Tarjan, Temperature aware microarchitecture: Extended discussion and results, Technical Report CS-2003-08, University of Virginia, Dept. of Computer Science, 2003.
- [20] 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.
- [21] P. Kumar and D. Atienza, "Neural network based on-chip thermal simulator," Proceedings of Circuits and Systems (ISCAS), pp. 1599-1602, 2010.
- [22] A. Vincenzi, A. Sridhar, M. Ruggiero and D. Atienza, "Fast thermal simulation of 2D/3D integrated circuits exploiting neural networks and GPUs," In Proceedings of the 17th IEEE/ACM international symposium on low-power electronics and design, pp. 151-156, 2011.
- [23] M. Mandal and A. Mukhopadhyay, "An improved minimum redundancy maximum relevance approach for feature selection in gene expression data", Procedia Technology, vol. 10, pp. 20-27, 2013.
- [۲۴] فرید کربلایی، حمیدرضا شعبانی، رضا ابراهیم‌پور، «ارزیابی برون‌خط پایداری گذرا به‌وسیله تعیین دقیق CCT با استفاده از شبکه عصبی با ورودی‌های مبتنی بر توابع انرژی»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۶، شماره ۱، صفحه ۲۸۵-۲۷۷، بهار ۱۳۹۵.
- [۲۵] مرتضی به‌نام، حسین پورقاسم، «شناسایی صرع بر اساس بهینه‌سازی ویژگی‌های ادغامی تبدیل هارتلی با مدل ترکیبی MLP و GA همراه با استراتژی یادگیری ممیتک»، مجله مهندسی برق دانشگاه تبریز، جلد ۲۵، شماره ۴، صفحه ۶۷-۵۱، زمستان ۱۳۹۴.
- [26] 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
- core systems," International On-Line Testing Symposium (IOLTS), pp. 116-121, 2015.
- [7] V. Hanumaiah, D. Desai, B. Gaudette, C. J. Wu and S. Vrudhula, "STEAM: a smart temperature and energy aware multicore controller", ACM Transactions on Embedded Computing Systems (TECS), vol. 13, no. 5s, 2014.
- [8] S. Sharifi, R. Ayoub and T. S. Rosing, "Tempomp: Integrated prediction and management of temperature in heterogeneous mpsoes," in Proc. the Conference on Design, Automation and Test, Europe, pp. 593-598, 2012.
- [9] 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.
- [10] M. Stockman, M. Awad, H. Akkary and R. Khanna, "Thermal status and workload prediction using support vector regression," International Conference on Energy Aware Computing, pp. 1-5, 2012.
- [11] A. Kumar, L. Shang, L.S. Peh and N. K. Jha, "HybDTM: a coordinated hardware-software approach for dynamic thermal management," Design Automation Conference, pp. 548-553, 2006.
- [12] 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.
- [13] A. K. Coskun, T. S. Rosing and K. C. Gross, "Proactive temperature balancing for low cost thermal management in MPSoCs," IEEE/ACM International Conference on Computer-Aided Design, pp. 250-257, 2008.
- [14] K. Zhang, A. Guliani, S. Ogrenici-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, pp. 405-419, 2018.
- [15] 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.
- [16] 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.

زیر نویس‌ها

* Dynamic Voltage and Frequency Scaling

° Correlation Feature Selection

* Multi-Layer Perceptron

* Dynamic Thermal Management

* Reactive

* Proactive

^۷ Mutual Information Difference

^۸ Autoregressive–Moving–Average

^۹ Sequential Probability Ratio Test

^{۱۰} Support Vector Regression

^{۱۱} Root Mean Square Error

^{۱۲} Principle Component Analysis

^{۱۳} Mutual Information

^{۱۴} Minimum Redundancy Maximum Relevance

^{۱۵} Vigilance Parameter

^{۱۶} Mean Absolute Error

^{۱۷} Standard Deviation Absolute Error

^{۱۸} Percentage of Outlier Errors

^{۱۹} K-fold Cross Validation

^{۲۰} Least Mean Square