

انتخاب ویژگی پیشنهادی برای مدیریت دمای پویا در سیستم‌های چند هسته‌ای

جواد محبی نجم‌آباد^{۱*}، مرتضی مرادی^۲ و باقر سلامی^۳

^۱گروه مهندسی کامپیوتر، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

^۲گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران

چکیده

افزایش تعداد هسته‌ها، به منظور افزایش توان محاسباتی یک سیستم چند هسته‌ای، منجر به افزایش دمای پردازنده می‌شود. یکی از راه کارهای معمول برای کاهش دما، روش‌های کنش گراست. این روش‌ها، با پیش‌بینی دما پیش از رسیدن به دمای حد آستانه، مدیریت دما را انجام می‌دهند. در این مقاله، اثر استفاده از ویژگی‌های مناسب برای مدیریت دمای پردازنده مورد توجه قرار گرفته است. برای مدیریت دما، سه مدل، به ترتیب برای پیش‌بینی دما، پیش‌بینی پاسخ دمایی و کنترل دما پیشنهاد شده است. در این راستا، از شبکه عصبی پرسپترون چندلایه-ای برای پیش‌بینی دما و پاسخ دمایی و از سامانه استنتاج عصبی-فازی وقتی به منظور مدیریت دما استفاده می‌شود. برای آموزش هر یک از مدل‌ها، مجموعه داده‌ای با تنوع بالا از حالات مختلف دمایی پردازنده، ایجاد و تعدادی از ویژگی‌های هر مجموعه، با نظارت حس‌گرها و شمارنده‌های کارایی پردازنده ایجاد و همچنین، برای افزایش دقت هر یک از مدل‌ها، تعدادی ویژگی با بهره‌گیری از پردازش‌های پیشنهادی فراهم و سپس، ویژگی‌های مناسب برای هر یک از مدل‌ها، با روش‌های پیشنهادی در این مقاله انتخاب می‌شود. ارزیابی مدل پیشنهادی برای پیش‌بینی و کنترل دمای پردازنده برای فاصله‌های زمانی مختلف، کمتر از ۰/۶ درجه سانتی‌گراد خطا دارد.

واژگان کلیدی: پیش‌بینی دما، پاسخ کنترلی، انتخاب ویژگی، پرسپترون چندلایه‌ای، سیستم استنتاج عصبی-فازی وقتی.

Proposed Feature Selection for Dynamic Thermal Management in Multicore Systems

Javad Mohebbi Najm Abad^{1*}, Morteza Moradi² & Bagher Salami³

¹Department of Computer Engineering, Quchan Branch, Islamic Azad University, Quchan, Iran

^{2,3}Department of Computer Engineering, Engineering Faculty, Ferdowsi University of Mashhad, Mashhad, Iran

Abstract

Increasing the number of cores in order to the demand of more computing power has led to increasing the processor temperature of a multi-core system. One of the main approaches for reducing temperature is the dynamic thermal management techniques. These methods divided into two classes, reactive and proactive. Proactive methods manage the processor temperature, by forecasting the temperature before reaching the threshold temperature. In this paper, the effects of using proper features for processor thermal management have been considered. In this regard, three models have been proposed for temperature prediction, control response estimation, and thermal management, respectively. A multi-layered perceptron neural network is used to predict the temperature and to control the response. Also, an adaptive neuro-fuzzy inference system is utilized for controlling temperature. An appropriate data set, which includes a variety of processor

* Corresponding author

*نویسنده عهده‌دار مکاتبات

temperature variations, has been created to train each model. Some features of the dataset are collected by monitoring the thermal sensors and performance counters. In addition, a number of features are created by proposing processes to increase the accuracy of each model. Then, the features of each model are selected by the proposed method. The evaluation of the proposed model for predicting and controlling the processor temperature for different time distances is below 0.6°C .

Keywords: thermal prediction, control response, feature selection, multilayer perceptron, adaptive neuro-fuzzy inference system.

۱- مقدمه

جهت افزایش توان محاسباتی پردازنده‌ها در ابتدا، از افزایش فرکانس اعمالی به پردازنده، استفاده می‌شد؛ این امر، افزایش گرمای تولیدی در پردازنده‌ها را به صورت نمایی به دنبال داشت. از طرفی، در ایجاد پردازنده‌ها، محدودیت در بیشینه میزان فرکانس اعمالی به آن‌ها وجود دارد. این نوع چالش‌ها، موجب ظهور پردازنده‌های چند هسته‌ای شد؛ اما افزایش تعداد هسته‌ها نیز منجر به افزایش چگالی تجمعی در سیستم‌های چند هسته‌ای و به تبع آن، افزایش توان مصرفی و در نتیجه، افزایش دما در پردازنده‌ها می‌شود. در این راستا، با در نظر گرفتن محدودیت‌های دمایی، برای کنترل دمای پردازنده، مجموعه‌ای از روش‌ها با عنوان مدیریت دمای پویا^۱ (DTM)، معرفی شده‌اند [1].

به صورت کلی DTM شامل دو رویکرد واکنشی^۲ و کنش‌گرا^۳ است. در رویکرد واکنشی، هنگامی که یک رخداد خاص، مانند افزایش دما از حد آستانه پردازنده، اتفاق می‌افتد، از روشی برای کاهش دما بهره می‌برند. متداول‌ترین روش‌های مورد استفاده در DTM، تنظیم ولتاژ فرکانس پویا^۴ (DVFS) و مهاجرت وظیفه است. در این رویکرد، از آنجایی که، بعد از رخداد یک رویداد نامطلوب، عملی در جهت رویارویی با آن انتخاب می‌شود، بهره‌وری کاهش می‌یابد. در مقایسه با روش یادشده، رویکردهای کنش‌گرای DTM، پیش از رسیدن دمای پردازنده به مقدار نامطلوب، از آن جلوگیری می‌کنند. اغلب، در یک رویکرد کنش‌گرا، با استفاده از یک روش پیش‌بینی، دمای آینده پردازنده را تخمین می‌زنند. از این جهت شاید بتوان، پیش‌بینی دقیق دما برای فاصله‌های زمانی مطلوب را، به عنوان قلب رویکردهای کنش‌گرای DTM معرفی کرد.

مدل‌های پیش‌بینی دما، سعی در تخمین دقیق دمای

آینده هسته‌های یک پردازنده دارند. برخی از این مدل‌ها، از روش‌های ریاضی، مانند روش‌های درون‌یابی، بر روی مجموعه داده‌ای از رکوردهای فعالیت سیستم، استفاده می‌کنند. اغلب، این رکوردها شامل دما و اطلاعات وضعیت پردازنده هستند. این اطلاعات در زمان اجرای یک بارکاری معمول، با نظارت حس‌گرهای دمایی و شمارنده‌های کارایی پردازنده، جمع‌آوری می‌شوند [2-5]. مدل‌های دمایی دیگر، از روش‌های هوش مصنوعی و روش‌های یادگیری ماشین بهره‌برده‌اند. در این راستا، در برخی از روش‌ها، از شبکه‌های عصبی برای پیش‌بینی دما استفاده شده است [6-11].

برای اینکه یک مدل دمایی بتواند برای استفاده در یک رویکرد DTM کنش‌گرا، مناسب باشد، نیاز به داشتن ویژگی‌هایی دارد. مهم‌ترین ویژگی یک مدل پیش‌بینی دما، دقت آن است. از دیگر ویژگی‌های کلیدی برای یک مدل دمایی، سربار محاسباتی آن است. هرچه مقدار این سربار کمتر باشد، باعث عملکرد بهتر رویکرد DTM می‌شود. مدل‌های دمایی، در یک رویکرد DTM کنش‌گرا، 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. برای ایجاد یک مدل دمایی، نیاز است که هم به مدل و هم به ویژگی‌های ورودی آن توجه شود.

رفتار دمایی پردازنده، به عنوان پاسخی به تصمیم‌های کنترلی، تغییر می‌کند [4]. در این راستا، تعدادی از مدل‌های دمایی، امکان پیش‌بینی دما با توجه به این تصمیم‌ها را با عنوان پیش‌بینی پاسخ کنترلی دارند. این قابلیت به رویکردهای کنترل دما، امکان گرفتن تصمیم‌های مناسب را می‌دهد. برای امکان پیش‌بینی پاسخ کنترلی نیاز است که با توجه به ابزارهایی که برای کنترل دما مورد استفاده قرار می‌گیرند، ویژگی‌های مناسب برای مدل دمایی انتخاب شوند؛ در نهایت، لازم است که مدل مدیریت دما، پس از بهره‌گیری از مدل‌های پیش‌بینی دما و پاسخ کنترلی به کنترل دما

¹ Dynamic Thermal Management

² reactive

³ proactive

⁴ Dynamic Voltage and Frequency Scaling

در ادامه، این مقاله به‌صورت زیر سازمان‌دهی شده است: در بخش دوم پیشینه روش‌های پیش‌بینی و مدیریت دمای پردازنده مورد بررسی قرار گرفته‌اند. تعریف‌های اولیه شامل معرفی سیستم‌های چند هسته‌ای و انتخاب ویژگی بر پایه اطلاعات متقابل در بخش سوم ارائه شده است. در بخش چهارم، ابتدا ویژگی‌های مدل پیشنهادی برای پیش‌بینی دما انتخاب می‌شوند؛ سپس، به معرفی مدل مناسب برای پیش‌بینی پاسخ کنترلی و ویژگی‌های آن پرداخته می‌شود. در انتهای این بخش، مدل کنترل دمای پیشنهادی معرفی می‌شود. نتایج ارزیابی مدل‌های پیشنهادی در بخش پنجم ارائه شده است. در بخش ششم، نتیجه‌گیری مقاله بیان می‌شود.

۲- پیشینه پژوهش

در بسیاری از روش‌های ارائه‌شده برای مدیریت دما، از داده‌های آماری استفاده کرده‌اند. این داده‌ها از اجرای برنامه‌ها بر روی پردازنده جمع‌آوری شده‌اند. بیش‌تر، از این داده‌ها برای تعیین ضرایب یک معادله چندجمله‌ای دمایی استفاده شده است. در این راستا از رویکردهایی بر پایه رگرسیون مانند روش کمینه مربعات بازگشتی^۳ (RLSM) بهره گرفته‌اند [14]. ایجاد مدل‌های مدیریت دما می‌تواند با بهره‌گیری از داده‌های آموزشی و به‌صورت برون‌خط انجام شود [4, 5]؛ سپس، در زمان اجرا، با معادله تعیین‌شده، دما مدیریت شود. برخی از مدل‌های دمایی، در زمان اجرا و به‌صورت برخط، از پنجره‌ای از آخرین مشاهده‌ها برای تعیین ضرایب معادله استفاده کرده‌اند. در این راستا، تابعی را بر روی پنجره‌ای با اندازه m برای ایجاد نمونه m اجرا کرده‌اند. بدین منظور، از تابع‌های میانگین ساده، وزن‌دار و نمایی بهره برده‌اند [6].

بهره‌گیری از مدل‌های برخط و برون‌خط در پیش‌بینی دما در کارهای مختلفی مورد توجه قرار گرفته است. در این راستا، می‌توان به مدل‌های خودرگرسیون میانگین متحرک^۴ (ARMA) اشاره کرد، که به هر دو شکل در پیش‌بینی دما استفاده شده‌اند [2, 3]. معادله ARMA که شامل دو بخش خودرگرسیون (AR) و میانگین متحرک (MA) است، با رابطه (۱) نمایش داده شده است:

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

³ Recursive Least Square Method

⁴ Autoregressive-Moving-Average

بپردازد. تعدادی از مدل‌های کنترلی، با بهره‌گیری از یک رویکرد ساده به تغییر ابزارهای کنترل دما، نظیر فرکانس و سرعت فن می‌پردازند. به‌عنوان نمونه، از کاهش چندسطحی فرکانس پردازنده، بدون پیش‌بینی پاسخ کنترلی استفاده می‌کنند. برخی از روش‌ها، از یک جدول کنترلی استفاده کرده که در آن اثر یک ابزار کنترلی بر دما در وضعیت‌های مختلف سیستم ثبت شده است [12]. انتخاب ویژگی‌های مناسب، برای شناسایی وضعیت سیستم از مهم‌ترین بخش‌های این رویکرد است. رویکردهای دیگر در مدیریت دما، مدلی را برای تعیین مقدار مناسب برای هر ابزار کنترلی انتخاب می‌کنند [13]. در این راستا، نیاز است که برای افزایش دقت مدل کنترلی، ویژگی‌های مناسب برای آن انتخاب شود.

در این مقاله، به انتخاب ویژگی‌های مناسب برای یک مدل مدیریت دمای پویا در سیستم‌های چند هسته‌ای پرداخته شده است. در این راستا، برای پیش‌بینی دما و پاسخ کنترلی دما، از شبکه عصبی پرسپترون چندلایه‌ای^۱ (MLP) استفاده شده است؛ همچنین، برای کنترل دما از سیستم استنتاج عصبی-فازی^۲ (ANFIS) بهره گرفته شده است. تعدادی از ورودی‌های مدل‌ها، شامل فرکانس پردازنده، سرعت فن، دمای هسته‌های پردازنده و تعدادی از شمارنده‌های کارایی هستند همچنین، با هدف افزایش دقت مدل‌ها، پردازش‌هایی برای تولید ویژگی‌های مناسب برای هر یک از مدل‌ها ارائه شده است؛ سپس، از بین همه ویژگی‌های مورد بررسی، ویژگی‌های مناسب برای هر یک از مدل‌های کاربردی در مدیریت دما انتخاب شده‌اند. برای بیان واضح‌تر، نوآوری‌های اصلی این مقاله، در ادامه معرفی می‌شوند:

- پردازش‌هایی برای ایجاد ویژگی‌های مناسب برای مدل‌های پیش‌بینی دما، پاسخ کنترلی و مدل کنترل دما پیشنهاد شده است.
- برای هر یک از مدل‌های مورد بررسی، ویژگی‌های مناسب، در جهت افزایش دقت و کاهش سربار محاسباتی انتخاب شده‌اند. در این راستا، سعی شده تا افزون بر انتخاب یک الگوریتم کارا، روشی در جهت انتخاب‌های مناسب‌تر ارائه شود.
- مدل‌های پیشنهادی، برای فاصله‌های زمانی مختلف مورد ارزیابی و آزمایش‌های متعدد قرار گرفته‌اند. ارزیابی‌ها بر روی یک سیستم چند هسته‌ای و بدون نیاز به سخت‌افزار اضافی انجام می‌شوند.

¹ Multi-Layer Perceptron

² Adaptive Neuro-Fuzzy Inference System

استفاده از رابطه خطی (۳)، از ترکیب شمارنده‌های کارایی برای تخمین دما استفاده کرده‌اند [16].

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

u_i که مقدار شمارنده کارایی نام است، بر تعداد چرخه‌های پردازنده (t_{total})، تقسیم می‌شود. w_i ها که ضریب‌های هر یک از شمارنده‌های کارایی هستند، با استفاده از درون‌یابی خطی تعیین می‌شوند. همچنین، w_{const} دمای اندازه‌گیری شده پردازنده، در حالت بیکاری است.

تعیین مراحل مختلف اجرایی برنامه و استفاده از یک مدل دمایی خطی به‌ازای هر مرحله، از دیگر رویکردهای پیش‌بینی دما است. در این راستا، کچران و همکاران با استفاده از شمارنده‌های کارایی، مراحل رفتاری بارکاری را شناسایی کرده‌اند [4]. برای هر مرحله یک مدل پیش‌بینی دمای مجزا ارائه شده است. پیش‌بینی دما با استفاده از رابطه خطی (۴) انجام شده است.

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

$T_m[i]$ دمای هسته m ام در زمان i و a_{mn} و a_m^{idle} ضریب‌های مدل از دید هسته m هستند. g_m ، سهم دمایی بارکاری را مشخص می‌کند. برای تعیین مقدار این پارامترها، بر روی پردازنده و در حالت‌های مختلف، برنامه‌های مختلفی اجرا و مجموعه داده‌ای شامل دما و حالت پردازنده ایجاد می‌شود؛ سپس، با به‌کارگیری درون‌یابی خطی بر روی مجموعه داده، ضریب‌های مدل برای هسته بیکار تعیین می‌شوند. باید به این نکته اشاره کرد، که با افزایش پارامترهای مؤثر بر دما همچون سطوح فرکانس، مراحل بارکاری و تعداد هسته‌های پردازنده، مقیاس‌پذیری این روش دچار چالش می‌شود؛ زیرا در این روش، برای هر یک از حالت‌های ممکن، به ضریب‌های جداگانه‌ای برای مدل پیش‌بینی دما نیاز است. تعیین مقدار مناسب برای فرکانس پردازنده، روشی است که برای کنترل دما ارائه شده است. در انتخاب فرکانس، پاسخ کنترلی ناشی از آن با استفاده از مدل دمایی ارائه شده، پیش‌بینی می‌شود.

استفاده از دو مرحله فعالیت بالا و فعالیت معمول، برای مجزاسازی رفتار بارکاری، در [5] انجام شده است. ایشان یک روش تخمین دمای سبک‌وزن، برای هر مرحله ارائه کرده‌اند. در این راستا، برای پیش‌بینی دمای آینده هر واحد از تراشه، از یک رابطه بر اساس شمارنده‌های کارایی و مقدارهای پیشین

که در آن y_t مقدار دما در زمان t است و a_i و c_i به ترتیب، ضریب‌های نمونه نام در بخش AR برای مقدارهای پیشین دما و در بخش MA برای مقدارهای خطای پیش‌بینی پیشین هستند. مقدار e_t نیز در زمان تعیین ضریب‌ها بر روی پنجره نمونه‌ها، محاسبه می‌شود. همچنین، مقدار خطای پیش‌بینی دما برای نمونه $i - t$ ام است. p و q به ترتیب اندازه پنجره AR و MA را مشخص می‌کنند. با توجه به رابطه مطرح‌شده، مدل ARMA تنها از دمای پیشین یک هسته در پیش‌بینی دمای آینده آن استفاده کرده است. برای مدیریت دما، برنامه‌ها را با توجه به دمای پیش‌بینی شده از هسته‌های مختلف، زمان‌بندی می‌کنند.

دمای پویای یک هسته بر روی یک پردازنده چند هسته‌ای، با رفتارهای دمایی همسایه‌های ارتباط مستقیم دارد؛ از این رو، بهره‌گیری از دمای همسایه‌های یک هسته به عنوان ویژگی‌های مدل دمایی، می‌تواند تأثیر قابل توجهی در پیش‌بینی دمای آن داشته باشد [4, 15]. در [15] از رابطه (۲) برای پیش‌بینی دما استفاده شده است.

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

که در آن T_i^{core} دمای فعلی هسته، I_i^{in} گرادیان دمایی هسته و I_i^{nb} میانگین گرادیان دمایی هسته‌های همسایه هستند؛ همچنین ضریب‌های α_i ، β_i و γ_i با استفاده از رگرسیون خطی، بر روی اطلاعات ثبت شده از دمای هسته‌های پردازنده، به صورت برون خط محاسبه می‌شوند. پس از پیش‌بینی دمای هسته‌های مختلف، با توجه به دمای حد آستانه، از مهاجرت وظایف برای کنترل دما استفاده می‌شود. از معایب این کار می‌توان به استفاده از یک ضریب مشترک برای میانگین دمای هسته‌های مجاور یک هسته اشاره کرد. همچنین، عوامل مؤثری همچون رفتار بارکاری، در این کار نادیده گرفته شده است.

از دیگر ویژگی‌های مؤثر بر دمای پردازنده که در کارهای متعددی مورد توجه قرار گرفته، بارکاری در حال اجرا بر روی پردازنده است [4, 5, 16-18]. با تغییر در رفتار بارکاری، میزان توان مصرفی پردازنده و در نتیجه آن، روند تغییر دمای پردازنده دگرگون می‌شود [17, 18]. رفتار برنامه با استفاده از ابزارهای سنجش موجود برای پردازنده، مانند شمارنده‌های کارایی و نشان‌گرهای توان مصرفی نیز اندازه‌گیری شده است [16]. در این راستا، کومار و همکاران با

جمع‌آوری شده، برای پیش‌بینی توان مصرفی هسته پردازنده آموزش داده شده است. آنگاه، توان پیش‌بینی شده، به عنوان ورودی به HotSpot داده شده، تا دمای هسته پیش‌بینی شود. استاکمن و همکاران نیز، با استفاده از SVR مدلی برای پیش‌بینی دما ارائه کرده‌اند [7]. در پژوهش انجام شده، هر نمونه از وضعیت سیستم تنها شامل ۳۴ شمارنده کارایی بوده و ویژگی‌های مهمی همچون دمای کنونی، در آن لحاظ نشده است.

رویکردهایی که تاکنون برای پیش‌بینی دما پیشنهاد شده‌اند، برای پیش‌بینی پاسخ کنترلی نیز مورد استفاده قرار گرفته‌اند. بدین منظور، در مدل دمایی ارائه شده، از ویژگی‌های یکسان برای پیش‌بینی دما و پاسخ دمایی استفاده می‌شود. این موضوع می‌تواند منجر به افزایش سربار مدل و کاهش دقت آن شود.

اغلب مدل‌های کنترل دما، برای تعیین مقدار مناسب برای هر ابزار کنترلی از یک مدل بهره می‌برند [13]. بدین منظور، معیارهای مختلفی، از جمله بیشینه دما، توان مصرفی و عملکرد پردازنده برای مدیریت دما معرفی شده‌اند [13]؛ سپس، برای تعیین هر یک از این معیارها، با توجه به مدل انتخابی، ویژگی‌های لازم انتخاب می‌شوند.

در [21، 22]، با هدف حفظ دما حول وحوش دمای حدآستانه و کاهش توان مصرفی، با بهره‌گیری از ANFIS سرعت فن تعیین شده است. بدین منظور، از دمای هسته‌ها و سرعت فن برای آموزش مدل استفاده شده است.

بهره‌گیری از سرعت فن و تنظیم‌های فرکانس، برای مدیریت دما در کارهای مختلفی استفاده شده است [12، 13]. گفتنی است که استفاده از سرعت فن برای کاهش دما، برخلاف فرکانس پردازنده، تأثیری بر عملکرد پردازنده نمی‌گذارد. البته، افزایش سرعت فن باعث افزایش توان مصرفی سیستم می‌شود. لی و همکاران ابتدا از سرعت فن برای کاهش دما استفاده می‌کنند [12]. سرعت فن نمی‌تواند دما را با سرعت بالا و به میزان کافی در برخی حالت‌های پردازنده کاهش دهد. در این حالت‌ها، از کاهش فرکانس پردازنده برای کاهش دما استفاده شده است. هانومیا و همکاران، برای مدیریت دما از فرکانس پردازنده، مهاجرت وظیفه و سرعت فن بهره برده‌اند [13]. تعیین مقدار مناسب هر یک از این ابزارها به صورت مداوم و در بازه‌های زمانی کوتاه مدت انجام می‌شود. در تمامی روش‌های مدل‌سازی اشاره شده، تعدادی از ویژگی‌های پردازنده و بارکاری، به عنوان ورودی مدل‌های مورد استفاده در مدیریت دما انتخاب شده‌اند. استفاده از تعداد

دمای آن بهره برده‌اند. برای تعیین ضرایب رابطه، از رگرسیون استفاده کرده‌اند. ایشان برای ارزیابی روش، از شبیه‌ساز HotSpot [19] بهره برده‌اند. یکی از مهم‌ترین چالش‌های این کار، نیاز به داشتن دانش معماری پردازنده، برای پیکربندی ابزار HotSpot است.

شبکه عصبی MLP، یکی از مهم‌ترین مدل‌ها در پیش‌بینی دما بوده که در مقاله‌های متعددی مورد ارزیابی قرار گرفته است [8-11، 20]. در یکی از کارهای اخیر، مقایسه‌هایی بین شبکه MLP با مدلی بر پایه رگرسیون خطی و مدل فرایند گوسی انجام شده است [20]. نتایج ارائه شده، دقت بالای مدل MLP را در مقایسه با دیگر مدل‌ها نشان می‌دهد. برای شبکه ارائه شده، ویژگی‌های مناسب برای پیش‌بینی دما انتخاب شده‌اند. این ویژگی‌ها، از میان پارامترهایی گزینش می‌شوند که با استفاده از ابزارهای اندازه‌گیری سیستم قابل خواندن هستند. ویژگی‌های خوانده شده، شامل ولتاژ پردازنده، دمای پردازنده و چهارده شمارنده کارایی می‌شوند. این ویژگی‌ها، با استفاده از الگوریتم انتخاب ویژگی همبستگی^۱ (CFS) انتخاب شده‌اند. در مقاله ارائه شده، 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 درجه سانتی‌گراد گزارش شده است. افزون بر آن، برای مدل دمایی برخط خطای پیش‌بینی حدود یک درجه سانتی‌گراد گزارش شده است.

در [8] با استفاده از شبکه عصبی MLP، مدلی برای پیش‌بینی دمای پیک یک هسته پردازنده، ارائه شده است. ورودی‌های مدل شامل میانگین و بیشینه توان مصرفی بارکاری و نیز دمای هسته‌های مجاور است. در مقاله‌های [9-11]، برای پیش‌بینی دمای آینده، از دمای فعلی و توان مصرفی بهره گرفته‌اند. در شبکه‌های پیشنهادی، به صورت مستقیم به فرکانس پردازنده، سرعت فن و بارکاری اجرایی بر روی هر یک از هسته‌های پردازنده توجه نمی‌شود.

از دیگر روش‌های هوشمند می‌توان به یک روش ترکیبی اشاره کرد که از رگرسیون بردار پشتیبان^۲ (SVR) و ابزار HotSpot برای پیش‌بینی دما استفاده کرده است [6]. ابتدا یک مجموعه داده شامل شمارنده‌های کارایی و میزان توان مصرفی متناظر با آن‌ها جمع‌آوری شده است. این مجموعه داده، در اثر اجرای بارهای کاری مختلف بر روی پردازنده به دست می‌آیند؛ سپس، SVR با استفاده از داده‌های

¹ Correlation Feature Selection

² Support Vector Regression

زیادی ویژگی، حتی اگر منجر به کاهش دقت مدل نشود، سبب افزایش سربار محاسباتی آن می‌شود [23]. برخی از رویکردها، ویژگی‌های مناسب را با انجام آزمایش‌های متعدد و با توجه دانش خبره انتخاب می‌کنند. انتخاب کمینه ویژگی‌های مؤثر، می‌تواند در افزایش دقت مدل، تأثیر قابل‌توجهی داشته باشد. در بیش‌تر کارهای مطالعه‌شده، ورودی‌های مدل تنها بر اساس بینش و مهارت‌های فردی پژوهش‌گر تعیین شده‌اند. در نتیجه انتخاب هوشمندانه ویژگی‌های ورودی مدل، ممکن است در افزایش دقت مدل، تأثیر قابل‌توجهی داشته باشد.

۳- تعاریف اولیه

در این بخش، ابتدا به معرفی فضای مسأله پرداخته می‌شود؛ سپس، توضیحات مختصری درباره انتخاب ویژگی بر پایه اطلاعات متقابل و روابط مورد استفاده در آن پرداخته، که از بخش‌های اصلی روش پیشنهادی است.

۳-۱- توصیف مسأله

یک پردازنده چندهسته‌ای بیش از یک هسته پردازشی دارد. هر یک از هسته‌ها دارای اجزای اختصاصی و در بیشتر موارد دارای حس‌گرهای دمایی ویژه است. از طرفی، اغلب پردازنده‌ها امکان کنترل فرکانس ساعت را به‌صورت سراسری برای همه هسته‌ها فراهم کرده‌اند؛ در حالی که برای برخی از پردازنده‌ها، این امکان، به‌صورت محلی برای هر هسته، فراهم شده است. بیشتر پردازنده‌های چندهسته‌ای از یک فن خنک‌کننده به‌همراه یک حرارت‌گیر، برای کاهش دمای پردازنده استفاده می‌کنند. به‌طور معمول، سرعت فن با توجه به مقدار دمای دریافتی از حس‌گرهای دمایی روی پردازنده، تعیین می‌شود. با توجه به اینکه در بیشتر مواقع، میزان فعالیت فن به اندازه‌ای نیست که تأثیر کافی در کاهش دمای پردازنده داشته باشد، نیاز به استفاده از روش‌های پیچیده‌تر DTM برای کاهش دما وجود دارد.

در یک رویکرد از روش‌های مدیریت دما، از یک مدل برای پیش‌بینی دما استفاده می‌شود. دقت بالا در پیش‌بینی دمای آینده، باعث استفاده بهتر از روش‌های DTM می‌شود؛ همچنین، پیش‌بینی دمای آینده با توجه تغییر ابزارهای کنترل دما، این امکان را به روش‌های مدیریت دما می‌دهد تا ابزار مناسب را برای کنترل دما انتخاب کنند. در تعداد قابل

توجهی از راه‌حل‌های DTM برای هر یک از این مدل‌ها، محدوده وسیعی از پارامترهای ورودی، برای پوشش جنبه‌های مختلفی از رفتار دمایی پردازنده مورد توجه قرار گرفته‌اند. تعداد بالای ورودی‌ها منجر به افزایش زمان مصرفی راه‌حل و کاهش عملکرد سیستم می‌شود. بنابراین، یک راه‌حل موفق DTM، به انتخاب کمترین مجموعه از پارامترهای ورودی، با بیشترین پوشش ممکن مسئله، نیاز دارد.

۲-۳- انتخاب ویژگی بر پایه اطلاعات متقابل

برای پیش‌بینی دما در یک پردازنده چندهسته‌ای، ویژگی‌های زیادی می‌توانند مورد استفاده قرار گیرند. استفاده از تمامی آن‌ها به‌عنوان ورودی‌های مدل، علاوه بر اینکه باعث افزایش زمان آموزش مدل می‌شود، ممکن است، عملکرد مدل را نیز کاهش دهد. شیوه‌های مختلفی برای انتخاب ویژگی وجود دارند که ورودی‌های مناسب را بر اساس وابستگی بین داده‌ها با خروجی مدل انتخاب می‌کنند. این انتخاب می‌تواند با توجه به پیشینه‌سازی معیار وابستگی آماری و کمینه کردن اطلاعات متقابل^۱ (MI) در بین مجموعه متغیرهای ورودی، انجام شود. گفتنی است که انتخاب پارامترها، تنها بر اساس اولویت مربوط به اطلاعات متقابل بین پارامترها با خروجی مدل، ممکن است منجر به انتخاب پارامترهایی شود که ناحیه یکسانی از فضای مسأله را پوشش دهند. در این حالت نیاز به استفاده از همه آن پارامترها نیست.

MI بین دو ویژگی x و y با رابطه (۵) محاسبه می‌شود [23]:

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

$p(x)$ ، $p(y)$ و $p(x, y)$ به ترتیب، توابع چگالی احتمال متغیرهای x ، y و وقوع هم‌زمان آن‌ها است.

از رابطه (۶) برای محاسبه زیرمجموعه ویژگی‌ها با بیش‌ترین مقدار وابستگی با ویژگی هدف، استفاده می‌شود [23].

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

S زیرمجموعه‌ای از ویژگی‌های اولیه و V_I مقدار وابستگی S را با ویژگی هدف h نشان می‌دهد.

انتخاب زیرمجموعه بر اساس بیش‌ترین وابستگی، می‌تواند شامل ویژگی‌هایی باشد که خود آن‌ها همبستگی بالایی با هم داشته باشند. بر این اساس، شرط کمینه افزونگی،

^۱ Mutual Information

با هدف افزایش دقت مدل‌ها، با پردازش‌های پیشنهادی، ایجاد شده و به مجموعه داده اضافه می‌شوند. آن‌گاه، توسعه و ارزیابی هر یک از مدل‌های مورد نیاز برای مدیریت دما انجام می‌شود. معیارهایی برای ارزیابی مدل معرفی شده و با توجه به آنها دقت مدل با ویژگی‌های پیشنهادی بررسی می‌شود.

۴-۱- ایجاد مجموعه داده

بیش‌تر پردازنده‌های کنونی، مجموعه‌ای اختصاصی از شمارنده‌های کارایی را برای هر هسته فراهم می‌کنند. با این وجود، حس‌گرهایی در پردازنده و سیستم مانند حس‌گرهای دما، سرعت فن و فرکانس پردازنده هستند که اطلاعات تکمیلی از وضعیت پردازنده، در اختیار کاربر قرار می‌دهند. تلفیق تمامی این اطلاعات برای ترسیم حالت سیستم می‌تواند یک فضای حالت گسترده ایجاد کند، که در آن احتمال رویداد تمامی حالت‌ها با هم یکسان نباشد.

برای ایجاد مجموعه داده، با هدف ایجاد حالت‌های متنوع در سیستم، آزمایشی انجام شده که در آن ترکیب‌های مختلفی از سرعت فن، فرکانس پردازنده و بارکاری فراهم می‌شود. در شکل (۱) نمودار جریان مورد استفاده برای ایجاد مجموعه داده مناسب، نمایش داده شده است. در این الگوریتم، در هر مرحله، برای تعدادی از هسته‌های پردازنده یک برنامه محک به صورت تصادفی انتخاب و بر روی آن‌ها اجرا می‌شود. در هر مرحله، تمامی ترکیب‌های سرعت فن و میزان فرکانس به نحوی تعیین شده، که در آن به ازای هر سرعت فن، چندین سطح از فرکانس پردازنده، بر روی تمامی هسته‌ها اعمال شود. ترتیب انتخاب سطوح فرکانس، به صورت تصادفی تعیین شده تا تغییر حالت‌های تصادفی فرکانس در آزمایش منعکس شود؛ همچنین، به دلیل محدودیت‌های مکانیکی فن، سرعت آن به آهستگی و در سطوح مشخص، به ترتیب از کم به زیاد افزایش و از زیاد به کم کاهش یافته است. در هنگام اجرای آزمایش، در فواصل زمانی یک ثانیه‌ای حالت سیستم ثبت شده است. با بررسی‌هایی که بر روی داده‌های جمع‌آوری شده از سیستم انجام شده است، در اثر تغییر فرکانس یا سرعت فن، در حدود پنج ثانیه زمان برای رسیدن به دمای حالت پایدار سیستم لازم است. بر اساس این، در الگوریتم به مدت ده ثانیه، تغییری در مقدار ابزارهای کنترلی انجام نشده تا اثر عدم تغییر این ابزارها در دمای هسته‌های پردازنده نیز در مجموعه داده ثبت شود.

برای یافتن زیرمجموعه‌ای از ویژگی‌ها با کم‌ترین همبستگی یکدیگر، ارائه شده است. این شرط با رابطه (۷) محاسبه می‌شود [23].

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

W_I میانگین MI بین ویژگی‌ها در زیرمجموعه S است. با ترکیب دو رابطه (۶ و ۷)، مفهومی تحت عنوان کمینه افزونگی بیشینه وابستگی^۱ (mRMR) معرفی شده است. اساس mRMR با رابطه (۸) تعریف می‌شود [23]:

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

$\varphi(V, W)$ عملگری برای ترکیب روابط بیشینه وابستگی و کمینه افزونگی است.

انتخاب فهرست بهترین ویژگی‌ها برای مجموعه داده‌ای که شامل تعداد زیادی ویژگی است، غیرعملی است. این امر به دلیل نمایی بودن تعداد محاسبه‌های لازم برای محاسبه $\max \varphi(V, W)$ است. به همین دلیل روش‌هایی برای تخمین mRMR معرفی شده‌اند. از متداول‌ترین آن‌ها، می‌توان به روش تفاضل اطلاعات متقابل^۲ (MID) اشاره کرد [24]. MID با رابطه (۹) محاسبه می‌شود.

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

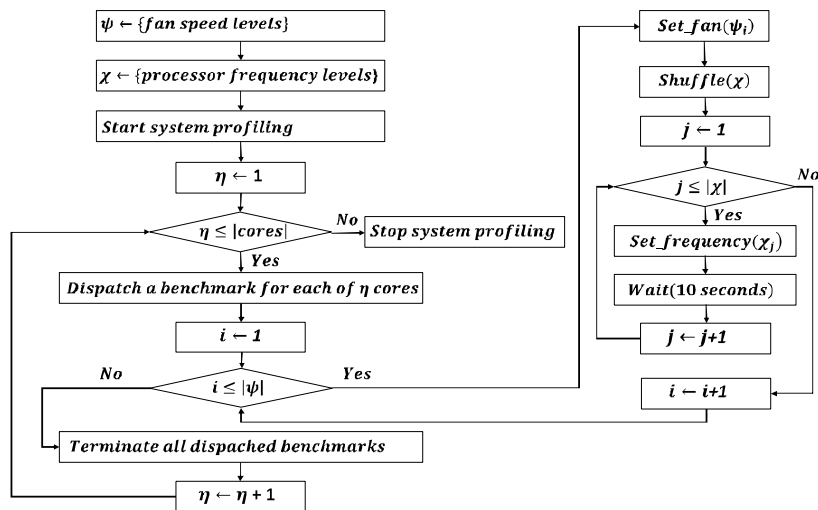
از مزیت‌های استفاده از روابط تخمین mRMR می‌توان به این نکته اشاره کرد که با آنکه تخمین قابل قبولی از mRMR دارد، ولی پیچیدگی محاسباتی آن‌ها کم است. به بیانی دیگر، سربار پایین، سرعت و قابلیت اطمینان بالا، باعث استفاده از این روش‌های تخمین برای انتخاب ویژگی‌های مناسب شده است.

۴- روش پیشنهادی

در توسعه روش پیشنهادی برای ایجاد و انتخاب ویژگی‌های مدل‌های مناسب برای مدیریت دما، ابتدا به ایجاد مجموعه داده مناسب برای آموزش و ارزیابی آن‌ها پرداخته می‌شود. مجموعه داده شامل حالت‌های متنوعی از تغییرات دمایی در سیستم است؛ سپس، تعداد قابل توجهی از ویژگی‌های تکمیلی

^۱ Minimum Redundancy Maximum Relevance

^۲ Mutual Information Difference



(شکل-۱): نمودار جریانی ایجاد یک مجموعه داده مناسب برای آموزش مدل های مدیریت دما
(Figure-1): The flowchart of creating appropriate dataset for training the thermal management models

پارامترها، برای مدل های پیش بینی پاسخ کنترلی و کنترل دما مناسبند.

در این پژوهش، با انجام پردازش هایی، مجموعه داده ای از پارامترهای سابقه ای و کنترلی ایجاد می شوند. به طور مشخص، برای ایجاد پارامترهای سابقه ای، گرادیان پارامترها نشان دهنده حالت پردازنده محاسبه می شود. این پارامترها شامل دمای هسته ها و شمارنده های کارایی است. گرادیان پارامتر p با فاصله d رابطه (۱۰) محاسبه می شود.

$$\nabla p_t(d) = \frac{p_t - p_{t-d}}{d} \quad (10)$$

p_t مقدار پارامتر در نمونه t و p_{t-d} مقدار همان پارامتر در d نمونه قبلی است. درواقع گرادیان نخست، میانگین سرعت تغییرها در طی d نمونه متوالی است، درحالی که گرادیان دوم میانگین شتاب تغییرها در همان بازه است. در این مقاله، گرادیان های پارامترهای اولیه، با فاصله های زمانی مختلف با مقادیر اولیه شان به عنوان ویژگی های سابقه ای در مجموعه داده آموزش قرار داده شده اند. همچنین، از عنوان گرادیان های آینده برای ایجاد پارامترهای کنترلی استفاده می شود. گرادیان آینده پارامتر کنترلی p با رابطه (۱۱) محاسبه می شود.

$$\bar{\nabla} p_t = p_{t+1} - p_t \quad (11)$$

که p_t مقدار پارامتر در نمونه t و p_{t+1} مقدار همان پارامتر در نمونه بعدی است. واضح است که گرادیان آینده تغییر مورد انتظار برای مقدار پارامتر در آینده است. از آنجایی که زمان بند،

۲-۴- آماده سازی مجموعه داده

در این پژوهش، پیش از استفاده از پارامترهای ورودی، تحلیل آن ها در مدل پیشنهادی، انجام شده است. در رفتار دمایی پردازنده، مشاهده می شود که ترتیب نمونه ها در مجموعه داده ورودی، الگوی معنی دار مشخصی دارند. از این رو مدل پیش بینی دما، بر وابستگی بین نمونه های متوالی تکیه داشته و هر نمونه می تواند با یک سری نمونه های قبلی، پیش بینی شود؛ بنابراین، در نظر گرفتن حالت های قبلی سیستم، هم زمان با حالت فعلی آن می تواند پیش بینی مطمئن تری را فراهم کند. در این راستا، تلاش شده است تا ویژگی های مناسبی را از مقادیر آماری اندازه گیری شده، ایجاد کرده تا شامل تاریخچه حالت های سیستم برای یک نمونه باشد. در روش پیشنهادی، هر نمونه شامل دو گروه از پارامترها با نام سابقه ای و کنترلی است.

پارامترهای سابقه ای، تکیه بر رفتار سخت افزاری پردازنده و نرم افزار در حال اجرا روی آن دارد. به عنوان مثال، اندازه گیری های حس گرهای دمایی و مقادیر شمارنده های کارایی، نمونه هایی از پارامترهای سابقه ای بوده، که وابسته به مدل پردازنده و برنامه در حال اجرا هستند. پارامترهای سابقه ای مورد نیاز برای مدل پیش بینی دما هستند.

پارامترهای کنترلی به صورت مستقیم زیر نظر سیستم عامل هستند. بیش تر، مقدار پارامترهای کنترلی زمانی تغییر می کنند که زمان بند سیستم عامل واکنشی را در جهت مدیریت دما و یا تغییر عملکرد پردازنده انجام می دهد. فرکانس پردازنده و سرعت فن از جمله پارامترهای کنترلی هستند. این

شامل تعیین مقدار هر پارامتر در بازه بین صفر و یک است، از رابطه (۱۲) استفاده می‌شود:

$$\eta_{i,j} = \frac{v_{i,j} - \min(V_j)}{\max(V_j) - \min(V_j)} \quad (12)$$


که V_j مجموعه مقادیر پارامتر j ام و $v_{i,j} \in V_j$ که i شماره Z نمونه در مجموعه داده است. پس $\eta_{i,j}$ مقدار هنجارشده نمونه i ام از پارامتر j است.

۳-۴- توسعه مدل پیش‌بینی دما

مدل پیشنهادی، MLP سه‌لایه بوده، که در شکل (۲) نمایش داده شده است. ورودی‌های مدل شامل مقادیر پارامترهای سابقه‌ای دمای هسته، دمای هسته‌های مجاور و مقدارهای شمارنده‌های کارایی و گرادیان آن‌ها در فاصله‌های زمانی $\{1, 2, 3\}$ ثانیه است. خروجی مدل، دمای پیش‌بینی شده با فاصله $d \geq 1$ است

مقادیر آینده این پارامترها را تنظیم می‌کند، محاسبه این تغییر به‌سادگی انجام می‌شود. از این پارامتر، برای محاسبه اثر تغییرات فرکانس و سرعت فن بر دما، استفاده می‌شود.

از دیگر مراحل تشکیل مجموعه داده، تعیین مقدار هدف برای هر نمونه است. تعیین مقدار هدف با توجه به فاصله مطلوب پیش‌بینی دما، انجام می‌شود. بنابراین، θ_{i+d} را به‌عنوان مقدار هدف t_i برای نمونه i ام فرض کرده که دمای اندازه‌گیری شده با فاصله زمانی پیش‌بینی d است. همان‌گونه که مشخص است، مقدار d باید با توجه به فاصله زمانی پیش‌بینی و بازه‌های نمونه‌گیری تعیین شود. واضح است که $d = \lceil \frac{\tau}{I} \rceil$ و τ فاصله زمانی بین نمونه جاری و نقطه پیش‌بینی هدف است. همچنین، I بازه زمانی نمونه‌گیری با واحد زمانی τ است؛ درنهایت، برای یکسان کردن مقیاس پارامترها، مرحله هنجارسازی انجام شده است. برای هنجارسازی پارامترها که



(شکل-۲): ساختار شبکه MLP برای پیش‌بینی دما
(figure-2): The MLP structure for predicting temperature

مطلق خطا^۱ (MAE)، انحراف معیار قدرمطلق خطا^۲ (SDAE) و درصد خطای بیش از سه درجه استفاده شده است. معیار MAE با رابطه (۱۳) محاسبه می‌شود.

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

N تعداد نمونه‌ها، t_i دمای هدف و y_i دمای پیش‌بینی شده برای نمونه i ام است. همچنین SDAE با رابطه (۱۴) محاسبه می‌شود:


برای ارزیابی مدل، ابتدا جایگشتی بر روی مجموعه داده انجام داده تا نمونه‌ها به‌هم‌ریخته شوند. این به‌هم‌ریختگی باعث تنوع نمونه‌ها در توزیع داده‌ها می‌شود؛ سپس، از اعتبارسنجی متقابل K تایی چهارده استفاده می‌شود. در این رویکرد، داده‌ها به K دسته متمایز تقسیم‌بندی شده و دقت مدل در K مرحله محاسبه می‌شود. در هر مرحله، $K-1$ دسته برای آموزش مدل انتخاب شده و یک دسته برای آزمایش استفاده می‌شود؛ درنهایت، از خطاهای همه مراحل برای محاسبه خطای مدل استفاده می‌شود.

برای بررسی دقت پیش‌بینی، از معیارهای میانگین قدر

¹ Mean Absolute Error


² Standard Deviation Absolute Error

گام، زیرمجموعه‌هایی شامل $1 \leq j \leq |\zeta|$ عنصر ابتدایی از ζ را در مدل پیشنهادی ارزیابی کرده و میزان خطای پیش‌بینی برای هر یک اندازه‌گیری می‌شود. در شکل (۳) مقدار MAE برای پیش‌بینی دما برای فاصله زمانی دو ثانیه آینده، برای هر زیرمجموعه از ویژگی‌های انتخاب‌شده با استفاده از MID نمایش داده شده است. باید توجه داشت که برای استفاده از MID نیاز به گسسته‌سازی داده‌ها است. بدین منظور با توجه به مقادیر بین کمینه و بیشینه دما در سیستم، تعداد بازه‌ها تعیین می‌شود. به‌عنوان مثال برای دمای کمینه سی و بیشینه صد تعداد بازه‌ها هفتاد تعیین می‌شود.



(شکل-۳): اثر افزایش تعداد ویژگی‌ها در دقت مدل پیش‌بینی دمای دو ثانیه آینده

(Figure-3): The effect of increasing the number of features on the accuracy of thermal prediction for the next 2 seconds



(شکل-۴): مقایسه پیش‌بینی دمای دو ثانیه آینده با ویژگی‌های مختلف

(Figure-4): Comparing the using different features for thermal prediction for the


با توجه به شکل (۳)، ابتدا افزایش تعداد ویژگی‌ها منجر به کاهش خطای مدل می‌شود؛ ولی با افزایش تعداد ویژگی‌ها از نقطه‌ای به بعد، خطای مدل افزایش می‌یابد. بر این اساس اگر تنها سیزده ویژگی نخست از بین ویژگی‌های

اولویت‌بندی‌شده با روش MID انتخاب شوند، نتیجه ارزیابی، تحت عنوان حالت سوم در شکل (۴) نمایش داده شده است. در شکل (۴)، نتیجه مقایسه هر سه حالت نمایش داده شده است. با توجه به نتایج، بهره‌گیری از ویژگی‌های انتخابی با الگوریتم MID، دقت بسیار بالاتری را نسبت به دو روش دیگر برای پیش‌بینی دما فراهم می‌کند. در این راستا می‌توان به معیار Pe اشاره کرد که در حالت سوم کمتر ۰/۰۴ درصد خطا به‌دست آمده است.


۴-۴- توسعه مدل پیش‌بینی پاسخ کنترلی

برای پیش‌بینی پاسخ کنترلی، افزون بر ویژگی‌هایی که برای پیش‌بینی دما مورد استفاده قرار گرفتند، از ویژگی‌های کنترلی نیز بهره گرفته می‌شود. در پیش‌بینی پاسخ کنترلی، مقدار تغییر دمای پردازنده با توجه به تغییرهای ابزارهای کنترلی مورد توجه قرار دارد. در این مقاله، فرکانس پردازنده و سرعت فن ابزارهای مورد بررسی در کنترل دما هستند. بر این اساس، گرادیان آینده فرکانس و سرعت فن به‌عنوان دیگر ویژگی‌های مدل پیش‌بینی پاسخ کنترلی استفاده می‌شوند. پس، تعداد ویژگی‌های مدل، ۱۲۸ عدد است.

برای بررسی اثر ویژگی‌های پیشنهادی در دقت مدل پیش‌بینی، مشابه با آزمایش‌های انجام‌شده در زیربخش ۳-۴، در سه حالت مختلف دقت مدل محاسبه می‌شود. در حالت نخست، از ویژگی‌هایی به‌عنوان ورودی‌های مدل بهره گرفته می‌شود که در هر لحظه با استفاده از حس‌گرها و سنجه‌های پردازنده خوانده می‌شوند. در این حالت تعداد ویژگی‌های مدل، نوزده عدد است. در حالت دوم، ویژگی‌های سابقه‌ای و کنترلی نیز به مجموعه ویژگی‌های مدل اضافه شده و تعداد ویژگی‌ها ۱۲۸ عدد می‌شود. در حالت سوم، با بهره‌گیری از الگوریتم MID ویژگی‌های مدل پیش‌بینی پاسخ دمایی انتخاب می‌شوند. برای انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی پاسخ کنترلی از الگوریتم نمایش داده‌شده در شکل (۵) استفاده شده است. بدین منظور، ابتدا ویژگی‌های کنترلی که شامل گرادیان آینده فرکانس و سرعت فن است، برای مدل انتخاب، سپس، باقی ۱۲۶ ویژگی با استفاده از MID اولویت‌بندی می‌شوند. آن‌گاه، زیرمجموعه‌هایی شامل ۳ تا ۱۲۸ ویژگی، با توجه به اولویت‌بندی، انتخاب شده و به مدل به‌عنوان ورودی داده می‌شوند. دقت مدل پیش‌بینی پاسخ کنترلی محاسبه شده و در شکل (۶) نمایش داده شده است. با توجه به شکل، افزایش تعداد ویژگی‌ها منجر به کاهش خطا می‌شود. البته از جایی به بعد، افزایش ویژگی‌ها، نه‌تنها باعث



(شکل-۶): اثر افزایش تعداد ویژگی‌ها در دقت مدل پیش‌بینی پاسخ کنترلی دو ثانیه آینده
(Figure-6): The effect of increasing the number of features on the accuracy of control response prediction for the next 2 seconds

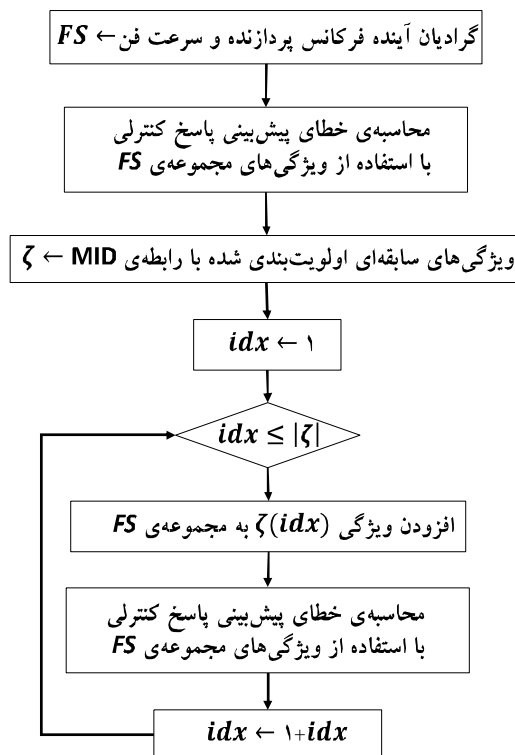


(شکل-۷): مقایسه پیش‌بینی پاسخ کنترلی دو ثانیه آینده با ویژگی‌های مختلف
(Figure-7): Comparing the using different features for control response prediction for the next 2 seconds

۵-۴- توسعه مدل کنترل دما

در این بخش، به انتخاب ویژگی‌های مناسب برای کنترل دمای پردازنده پرداخته می‌شود. در این مقاله، از دو ابزار فرکانس پردازنده و سرعت فن برای مدیریت دما استفاده می‌شود. از طرفی، در این مقاله با هدف کنترل هم‌زمان هر دو ابزار، از یک مدل برای تعیین مقادیر آن‌ها استفاده می‌شود. گفتنی است که استفاده از مدل‌های مجزا برای هر یک از آن‌ها، دو عیب کلی دارد. نخست آن‌که سربار اجرایی استفاده از مدل‌ها افزایش می‌یابد. عیب دیگر این است که میزان نوسان ابزارهای کنترلی با بهره‌گیری از مدل‌های مجزا می‌تواند افزایش یابد. برای تعیین مدل مناسب برای کنترل دما نیاز است که به پارامترهای مختلفی توجه شود. یکی از پارامترها، مدلی است که برای تعیین مقدار مناسب هر یک ابزارهای فرکانس پردازنده و سرعت فن استفاده می‌شود. در این راستا، به مقایسه

افزایش سربار محاسباتی مدل شده، بلکه منجر به کاهش دقت پیش‌بینی نیز می‌شود. بر این اساس، تعداد یازده ویژگی برای مدل انتخاب شده و ارزیابی دقیق‌تری بر روی آن انجام شده است. در این راستا، برای هر سه حالت معرفی شده، محاسبات مربوط به معیارهای ارزیابی، شامل MAE، SDAE و Pe انجام شده و در شکل (۷) نمایش داده شده است. از دیگر معیارهای مقایسه بین این سه حالت، زمان سربار استفاده از مدل در زمان اجرا است. در حالت نخست که از نوزده ویژگی استفاده می‌شود، زمان استفاده از مدل در هر ثانیه $8/6 \times 10^{-5}$ است. در حالت دوم که مدل از ۱۲۸ ویژگی بهره می‌برد، زمان $7/7 \times 10^{-4}$ ثانیه است. در نهایت در حالت سوم که از یازده ویژگی استفاده می‌شود، زمان اجرا $5/6 \times 10^{-5}$ است. نتایج به‌دست‌آمده در تمامی معیارهای ارزیابی، نشان‌دهنده دقت قابل توجه مدل در حالتی است که از ویژگی‌های انتخابی بهره می‌برد. گفتنی است که از مهم‌ترین ویژگی‌های انتخاب‌شده برای مدل پیش‌بینی پاسخ کنترلی، ویژگی‌های کنترلی است که باعث افزایش قابل توجه دقت مدل می‌شود.



(شکل-۵): الگوریتم پیشنهادی برای انتخاب ویژگی‌های مناسب برای مدل پاسخ کنترلی
(Figure-5): Proposed algorithm to select the appropriate features for the control response model

مدل‌های مختلفی نظیر MLP، ANFIS پرداخته شده است. از دیگر پارامترهای مورد توجه، ویژگی‌هایی است که به‌عنوان ورودی مدل باید انتخاب، تا دقت بالایی از مدل کنترلی حاصل شود.

پیشتر، برای مدیریت دما، از مدل ANFIS در جهت کنترل سرعت فن استفاده شده است [21, 22]. از مهم‌ترین دلایل بهره‌گیری از ANFIS می‌توان به سرعت و قابلیت اطمینان بالای آن اشاره کرد. از طرفی با تعداد کمی از ویژگی‌های ورودی و با یک مجموعه داده کوچک می‌تواند به خوبی آموزش یافته و دقت بالایی را ارائه دهد. در نهایت باید به خروجی نرم آن اشاره کرد که مناسب برای ابزارهای کنترل دما است؛ زیرا از نوسات بالای آن‌ها که باعث کاهش طول عمر ابزارهایی مانند فن و البته افزایش سربار کنترل دما می‌شود، جلوگیری می‌کند. بر این اساس، ANFIS می‌تواند مدل مناسبی برای کنترل دمای پردازنده باشد.

برای ایجاد یک مدل کنترلی با ANFIS، نیاز است که یک مجموعه داده مناسب برای آموزش مدل فراهم شود. در این راستا، مجموعه داده‌ای تهیه شده است که شامل اثر تغییرات فرکانس یا سرعت فن، بر دمای t ثانیه آینده پردازنده باشد. بدین منظور آزمایش‌های مختلفی با بهره‌گیری از الگوریتم ارائه شده در شکل (۱) انجام می‌شود. آن‌گاه به آماده‌سازی مجموعه داده نهایی پرداخته می‌شود. ورودی‌های این مجموعه داده شامل دمای فعلی هسته‌ها، فرکانس پردازنده، سرعت فن، شمارنده‌های کارایی هسته هدف در کنترل دما و دمای t ثانیه بعد هسته هدف است. خروجی‌های مجموعه داده مقدار تغییرات فرکانس و تغییرات سرعت فن است.

برای ایجاد مدل کنترل دما، ابتدا به انتخاب ویژگی‌های مناسب برای آن پرداخته می‌شود. برای مدل کنترلی از ویژگی‌هایی استفاده می‌شود که در هر لحظه با بهره‌گیری از حس‌گرها و سنجه‌های پردازنده قابل خواندن هستند. این ویژگی‌ها شامل مقدار فرکانس پردازنده، سرعت فن، دمای چهار هسته پردازنده و سیزده شمارنده کارایی می‌شود. همچنین، دمای حدآستانه پردازنده از ویژگی‌های مورد نیاز برای یک مدل کنترلی بوده که با توجه به آن، تصمیم‌های لازم برای مقدار ابزارهای کنترلی گرفته می‌شود. خروجی مدل کنترل دما، مقدار مناسب برای فرکانس پردازنده و سرعت فن است. در ادامه، مراحل لازم برای انتخاب ویژگی معرفی می‌شوند.

در ابتدا به انتخاب مجموعه داده لازم برای آموزش مدل پرداخته می‌شود. از میان داده‌های ایجاد شده با الگوریتم شکل (۱)، داده‌هایی انتخاب شده که بعد از t ثانیه و بر اثر تغییر سرعت فن و یا فرکانس پردازنده، موجب برابری دمای پردازنده با دمای حدآستانه شده‌اند. از آنجایی که آزمایش‌های متنوع با برنامه‌های مختلف و در شرایط مختلف سیستمی انجام شده است، تعداد قابل توجهی از داده‌ها قابل انتخاب بوده و در مجموعه داده مورد استفاده قرار می‌گیرند.

از آنجایی که مدل کنترلی دارای دو خروجی است، از الگوریتم NSGA-II برای انتخاب ویژگی‌های مناسب مدل استفاده می‌شود. گفتنی است که به دلیل تک‌خروجی بودن مدل‌های پیش‌بینی دما و پاسخ کنترلی، از MID برای اولویت‌بندی ویژگی‌ها با توجه به تنها خروجی مدل پرداخته شده و سپس، به ارزیابی اثر افزایش تعداد ویژگی‌ها در دقت مدل پیش‌بینی پرداخته شده است. این رویکرد، در مدل کنترلی قابل استفاده نیست. برای استفاده از الگوریتم NSGA-II نیاز به انجام تنظیماتی است که بخش قابل توجهی از آن‌ها با انجام آزمایش‌های مختلف انجام می‌شود. در این راستا، هر عضو از جمعیت شامل مقادیری از صفر و یک‌هاست که متناظر با هر ویژگی برای مدل کنترلی است. به بیانی دیگر، به ازای هر یک از ویژگی‌هایی که برای مدل قابل انتخاب است از یک مقدار دودویی استفاده می‌شود. عدد یک به معنای انتخاب ویژگی و صفر به معنای عدم انتخاب آن است؛ سپس، برای هر عضو از جمعیت، با بهره‌گیری از مدل ANFIS، دقت تخمین مقدار فرکانس پردازنده و سرعت فن برای هر نمونه از مجموعه داده محاسبه می‌شود. در حالت کلی، برای ارزیابی هر عضو از جمعیت سه مقدار در نظر گرفته می‌شود: نخست، تعداد ویژگی‌هایی که به‌عنوان ورودی مدل ANFIS برای آن انتخاب شده و معیارهای دوم و سوم به ترتیب مقدار خطاهایی است که در تخمین فرکانس پردازنده و سرعت فن، برای آن به دست آمده است. گفتنی است که مقادیر خطای تخمین فرکانس و تخمین سرعت فن نرمال شده هستند. با توجه به این معیارها، جمعیت پارتو^۱ انتخاب می‌شود. الگوریتم به اندازه‌ای تکرار می‌شود که دیگر در جمعیت پارتو تغییری ایجاد نشود. نتیجه اجرای الگوریتم در جدول (۱) نمایش داده شده است. با توجه به نتایج، انتخاب بیش از شش ویژگی، بهبودی در دقت مدل کنترلی ایجاد نمی‌کند. همچنین، انتخاب شش ویژگی دقت بالایی را برای مدل فراهم می‌کند. این ویژگی‌ها شامل دمای فعلی هسته هدف، دمای گرم‌ترین هسته پردازنده، مقدار فرکانس پردازنده، سرعت فن، شمارنده کارایی CYCLES و دمای t ثانیه بعد هسته هدف است.

^۱ pareto

(جدول-۱): جمعیت پارتوی حاصل از انتخاب ویژگی‌های

مدل کنترلی

(Table-1): The pareto population derived from the features selection of control model

تعداد ویژگی‌ها	خطای تعیین فرکانس	خطای تخمین سرعت فن
1	0.22	0.1
2	0.07	0.03
3	0.023	0.01
4	0.01	0.008
5	0.0047	0.0022
6	0.004	0.002

با استفاده از ویژگی‌های انتخابی و مدل کنترلی آموزش‌یافته با مجموعه داده فراهم شده، به مدیریت دما پرداخته می‌شود. در این آزمایش، هدف استفاده از مدل برای کنترل دما تا t ثانیه آینده است. بدین منظور، خروجی مدل، تغییرات لازم برای فرکانس و سرعت فن را به شکلی تعیین می‌کند که با بهره‌گیری از آن‌ها، دمای پردازنده به مقدار مورد انتظار برای آن برسد. در این آزمایش، هدف حفظ دمای پردازنده، حول و حوش دمای حد آستانه است. با این هدف، سعی می‌شود که بیشینه فرکانس پردازنده و کمینه سرعت فن، به گونه‌ای تعیین شود که از دمای حد آستانه تجاوز نشود. دمای حد آستانه برابر با نود درجه سانتی‌گراد تعریف می‌شود. از مدل پیشنهادی برای کنترل دما برای چند ساعت و برای برنامه‌های مختلف استفاده شده است. با توجه به اختلاف بین دمای مشاهده شده از پردازنده پس از کنترل، با دمای حد آستانه برای محاسبه خطای مدل استفاده شده است. در این راستا، مقدار MAE و SDAE برای کنترل دما برای فاصله‌های زمانی دو تا پنج ثانیه آینده، در جدول (۲) نمایش داده شده است.

(جدول-۲): دقت مدل کنترل دما برای فاصله‌های زمانی

مختلف

(Table-2): The accuracy of the thermal control model for different time distances

فاصله زمانی	MAE(°C)	SDAE(°C)
2	0.49	0.59
3	0.51	0.61
4	0.56	0.68
5	0.59	0.71

۵- ارزیابی مدل پیشنهادی

در این بخش ابتدا سیستم چندهسته‌ای، ابزارها و برنامه‌های مورد استفاده در ارزیابی رویکرد پیشنهادی معرفی و سپس،

نتیجه‌های به دست آمده از آزمایش‌های مختلف، برای ایجاد مدل‌های پیشنهادی برای پیش‌بینی دما و پاسخ دمایی و کنترل دما برای فاصله‌های دو تا پنج ثانیه آینده ارائه می‌شوند.

۵-۱- تنظیم‌های آزمایشگاهی

آزمایش‌ها بر روی سیستم چهار هسته‌ای Intel's Core i7-950 انجام شده است. سیستم عامل مورد استفاده، لینوکس است. برای دریافت اطلاعات دمایی توسط حسگرها، از ابزار lm-sensor [25] استفاده شده است. همچنین از زیرسیستم perf موجود در سیستم عامل لینوکس، جهت دریافت اطلاعات شمارنده‌های کارایی بهره گرفته شده است. فهرست شمارنده‌های کارایی در جدول (۳) نمایش داده شده است.

(جدول-۳): فهرست شمارنده‌های کارایی

(Table-3): The list of performance counters

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

از ابزار cpufreq [26] نیز برای تنظیم پویای ولتاژ و فرکانس استفاده شده است. تغییر سرعت فن با استفاده از اسکریپت هسته fancontrol انجام شده است. برای انجام آزمایش‌ها، از برنامه محک SPEC CPU2006 استفاده شده، که به صورت موازی بر روی هسته‌های پردازنده قابل اجرا هستند.

۵-۲- تحلیل آزمایش‌ها

در این بخش، ابتدا به ارائه نتایج حاصل از استفاده از مدل پیشنهادی برای پیش‌بینی دمای دو تا پنج ثانیه آینده پرداخته می‌شود. بدین منظور، برای هر یک از فاصله‌های زمانی یک مجموعه داده مناسب ایجاد و سپس، به اولویت‌بندی ویژگی‌های مناسب برای هر فاصله زمانی با الگوریتم MID پرداخته می‌شود. آن‌گاه، انتخاب ویژگی‌ها بر اساس اولویت تعیین شده برای آن‌ها انجام می‌شود. آن‌گاه با شبکه MLP، و با انتخاب ویژگی‌ها با توجه به اولویت‌بندی انجام شده، دقت


(جدول-۵): نتایج بهره‌گیری از مدل ژنگ برای پیش‌بینی دما

برای فاصله‌های زمانی مختلف

(Table-2): Results the Zhang model to predict temperature for different time distances

فاصله زمانی	تعداد ویژگی‌ها	MAE (°C)	SDAE (°C)	Pe(%)
2	16	0.6	0.68	0.27
3	16	0.72	0.81	1.65
4	16	0.8	0.84	1.85
5	16	0.84	0.89	2.2

در ادامه به ارائه نتایج حاصل از ارزیابی مدل پیشنهادی برای تخمین پاسخ کنترلی پرداخته می‌شود. تخمین پاسخ کنترلی نیز با مدل MLP انجام می‌شود. برای انتخاب ویژگی‌های مدل، پیشنهاد شده است که ابتدا ویژگی‌های کنترلی برای مدل انتخاب و باقی ویژگی‌ها، با بهره‌گیری از الگوریتم MID، از میان ویژگی‌های سابقه‌ای انتخاب می‌شوند. نتیجه استفاده از این رویکرد، برای پیش‌بینی پاسخ کنترلی دو تا پنج ثانیه آینده در شکل (۹) نمایش داده شده است. در این آزمایش از روش اعتبارسنجی K تایی استفاده شده است.




(شکل-۹): دقت مدل پیش‌بینی پاسخ کنترلی برای

فاصله‌های زمانی مختلف

(Figure-9): The accuracy of the control response prediction model for different time distances

برای ارزیابی دقیق‌تر رویکرد پیشنهادی در ایجاد مدل مناسب برای پیش‌بینی پاسخ کنترلی، به مقایسه مدل پیشنهادی با تعدادی از مدل‌های ارائه‌شده تاکنون پرداخته می‌شود. بدین منظور، مدل‌هایی برای مقایسه انتخاب شده‌اند که نتایج خوبی را در این راستا ارائه کرده‌اند. در ابتدا، نتایج حاصل از استفاده از مدل پیشنهادی برای پیش‌بینی پاسخ کنترلی برای فاصله‌های مختلف زمانی در جدول (۶) نمایش داده شده و سپس، نتایج رویکرد ارائه‌شده توسط کچران [4] ارائه شده است. برای مقایسه مدل کچران با مدل پیشنهادی،

پیش‌بینی دما محاسبه می‌شود. نتایج به‌دست‌آمده در شکل (۸) نمایش داده شده است. در همه فاصله‌های زمانی، افزایش تعداد ویژگی‌ها، از نقطه‌ای به بعد باعث کاهش دقت پیش‌بینی می‌شود. بر این اساس، کمینه تعداد ویژگی‌های لازم برای پیش‌بینی در هر فاصله زمانی انتخاب می‌شود. جدول (۴)، نتایج ارزیابی مدل پیش‌بینی دما را با توجه به ویژگی‌های انتخابی برای هر فاصله زمانی نشان می‌دهد.



(شکل-۸): دقت مدل پیش‌بینی دما برای فاصله‌های

مختلف زمانی

(Figure-8): The accuracy of the thermal prediction model for different time distances

(جدول-۴): ارزیابی معیارهای دقت پیش‌بینی دما برای

فاصله‌های زمانی مختلف

(Table-4): Evaluation of temperature prediction accuracy criteria for different time distances

فاصله زمانی	تعداد ویژگی‌ها	MAE (°C)	SDAE (°C)	Pe(%)
2	17	0.47	0.59	0.04
3	16	0.55	0.64	0.14
4	17	0.55	0.67	0.14
5	12	0.61	0.69	0.2

دقت بالا در همه معیارهای ارزیابی، نشان از ویژگی‌های مناسبی است که برای پیش‌بینی دما انتخاب شده‌اند. با این وجود، برای مقایسه بهتر، از مدل ارائه‌شده توسط ژنگ و همکاران نیز برای پیش‌بینی دما استفاده شده است [20]. ایشان نیز از مدل MLP البته با ویژگی‌هایی متفاوت از ویژگی‌های انتخاب‌شده برای مدل پیشنهادی در این مقاله، برای پیش‌بینی دما استفاده کرده‌اند. نتایج بهره‌گیری از مدل ایشان، در جدول (۵) نمایش داده شده است. مقایسه جدول (۴ و ۵) نشان از دقت بالاتر مدل پیشنهادی با ویژگی‌های انتخاب‌شده برای آن دارد.

مدل پیش‌بینی پاسخ کنترلی، برای یک هسته در سیستم چند هسته‌ای و برای فاصله‌های زمانی مختلف ارائه شده است. فهرست ورودی‌های انتخاب‌شده برای فاصله‌های زمانی مختلف، با وجود اشتراک بالا، اختلاف‌های بااهمیتی نیز دارند. به همین سبب، استفاده از ویژگی‌های مدل پاسخ کنترلی برای یک فاصله زمانی، نتیجه مناسبی برای یک فاصله زمانی دیگر را به همراه ندارد. ویژگی‌های مشترک بین مدل‌های مختلف، شامل گرادیان آینده فرکانس و سرعت فن، دمای هسته‌ها، فرکانس پردازنده، مقدارهای یک، دو و سه ثانیه قبل دمای هسته هدف و مقدار یک ثانیه قبل شمارنده‌های کارایی `cycles_stalled_cycles_frontend` و `l1d_all_ref` هسته هدف است. تفاوت‌هایی نیز بین پارامترهای انتخاب‌شده برای مدل‌های مختلف وجود دارد. به عنوان مثال، شمارنده کارایی `instructions` مقدار یک ثانیه قبل شمارنده کارایی `branches` و گرادیان نخست `cycles` برای تخمین پاسخ کنترلی دو و سه ثانیه آینده انتخاب شده است. گفتنی است که استفاده از ویژگی‌های انتخابی برای پیش‌بینی دو ثانیه آینده، برای پیش‌بینی پاسخ سه ثانیه آینده نیز دقت قابل قبولی ارائه می‌کند. ولی با افزایش زمان و استفاده از آن ویژگی‌ها برای پیش‌بینی پاسخ کنترلی پنج ثانیه آینده، کاهش قابل توجه دقت مدل را به دنبال دارد؛ در نهایت، نتایج ارزیابی مدل کنترل دما با ویژگی‌های انتخابی ارائه می‌شود. در ابتدا، مدل مناسب برای کنترل دما انتخاب می‌شود. در این راستا، مقایسه مدل‌های MLP و ANFIS با ویژگی‌های یکسان انجام می‌شود. برای مقایسه دقیق‌تر، برنامه‌های محک یکسانی برای اجرا بر روی پردازنده انتخاب می‌شوند. همچنین، در زمان اجرای این آزمایش مدام برنامه‌های در حال اجرا تغییر داده می‌شوند تا دمای پردازنده کمتر از دمای حد آستانه شود؛ سپس، از مدل کنترلی انتظار است که با تغییر ابزارهای کنترلی، دما را حول و حوش دمای حد آستانه حفظ کند. قسمتی از نتایج به دست آمده در شکل (۱۰) نمایش داده شده است. همان‌طور که در شکل دیده می‌شود و البته با انجام آزمایش‌های متعدد، این نتیجه به دست آمد که مدل ANFIS سریع‌تر بوده و بیشتر قادر است که دمای پردازنده را حول و حوش دمای حد آستانه حفظ کند. به صورت میانگین دمای پردازنده پس از کنترل با مدل MLP، ۱/۸ درجه سانتی‌گراد با دمای حد آستانه فاصله دارد. در صورتی که با مدل ANFIS، این فاصله حدود ۱/۱ درجه سانتی‌گراد است. همچنین، میزان تخطی از دمای نود درجه با

پیاده‌سازی این رویکرد برای فاصله‌های مختلف زمانی و بر اساس مطالب ارائه شده در بخش پیشینه پژوهش انجام شده است. در این راستا، سیزده شمارنده کارایی با استفاده از PCA به فضایی با دو بعد نگاشت می‌شوند و سپس با خوشه‌بندی، فازهای دمایی پردازنده تعیین شده و برای هر مرحله یک مدل دمایی با بهره‌گیری از رابطه خطی چهار تعیین شده است. نتیجه مقایسه‌ها برای فاصله‌های مختلف زمانی در جدول (۶) نمایش داده شده است. مدل پیشنهادی نتایج دقیق‌تری برای همه فاصله‌های زمانی، نسبت به مدل کچران ارائه می‌دهد. در چند مقاله از مدل ARMA برای پیش‌بینی دما و پاسخ کنترلی استفاده شده است [2, 3]. به همین دلیل، از مدل‌های مورد مقایسه در این مقاله است. همچنین، از مدل پیشنهادی توسط ژنگ^۱ و همکاران برای پیش‌بینی پاسخ کنترلی استفاده شده است [20]. ایشان، ویژگی‌های مناسب برای مدل را از میان ویژگی‌های فیزیکی و برنامه‌ای، با استفاده از الگوریتم CFS انتخاب و سپس، از شانزده ویژگی انتخابی، به عنوان ورودی‌های مدل MLP استفاده کرده‌اند. نتیجه استفاده از رویکرد ایشان با نام مدل ژنگ در انتهای جدول (۶) نمایش داده شده است.


(جدول-۶): ارزیابی تعدادی از مدل‌های پیش‌بینی پاسخ

کنترلی برای فاصله‌های مختلف زمانی

(Table-6): The evaluations of some control response prediction models for different time distances

مدل	فاصله زمانی (s)	MAE (°C)	SDAE (°C)	Pe (%)
پیشنهادی	2	0.94	1.02	3
پیشنهادی	3	1.02	1.1	3.2
پیشنهادی	4	1.24	1.28	4.1
پیشنهادی	5	1.4	1.42	5.2
کچران	2	1.4	2.2	8
کچران	3	1.7	2.5	11
کچران	4	2.1	2.8	15
کچران	5	2.6	3	20
ARMA	2	1.63	2.83	11
ARMA	3	1.74	2.94	11
ARMA	4	2.09	3.46	16
ARMA	5	2.49	3.67	17
ژنگ	2	1.37	2.27	8.4
ژنگ	3	1.61	2.48	9.6
ژنگ	4	1.9	2.86	11.4
ژنگ	5	2.21	2.92	14.3

¹ Zhange




(شکل-۱۱): مقایسه سه روش کنترل دما با هدف حفظ دما حول و حوش دمای حدآستانه
(Figure-11): Comparison of three thermal control methods to maintain temperature around the threshold temperature

۶- نتیجه گیری

در این مقاله، از شبکه عصبی MLP برای پیش‌بینی دما و پاسخ کنترلی یک هسته در سیستم چندهسته‌ای استفاده شده است. تعدادی از ورودی‌های این مدل، 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 می‌شوند. در این راستا، برای هر ورودی، گرادیان‌های نخست و دوم آن تا سه ثانیه قبل محاسبه می‌شوند. همچنین، برای مدل مناسب برای پیش‌بینی پاسخ کنترلی، دو ویژگی دیگر با عنوان گرادیان‌های آینده ایجاد می‌شوند. این ویژگی‌ها، مقدار تغییرات فرکانس پردازنده و سرعت فن را نگهداری می‌کنند. از بین تعداد بالای ویژگی‌ها، تعدادی از آن‌ها با بهره‌گیری از الگوریتم MID برای مدل‌های پیشنهادی انتخاب می‌شوند. خطای استفاده از مدل‌های پیشنهادی برای پیش‌بینی دما برای فاصله‌های زمانی دو تا پنج ثانیه آینده، حدود نیم درجه سانتی‌گراد است. همچنین، مدلی برای کنترل دما پیشنهاد شده است که با ابزارهای فرکانس پردازنده و سرعت فن، با هدف افزایش عملکرد پردازنده، دما را حول و حوش دمای حدآستانه حفظ می‌کند. برای ایجاد مدل پیشنهادی از ANFIS استفاده شده است. با استفاده از مدل پیشنهادی، قدرمطلق فاصله بین دمای مشاهده‌شده از پردازنده و دمای حدآستانه، حدود یک درجه سانتی‌گراد به‌دست آمده است.

مدل‌های MLP و ANFIS، به‌ترتیب حدود هشت و دو درصد است. این نتایج نشان‌دهنده عملکرد بهتر مدل ANFIS نسبت به MLP برای کنترل دما است. از طرفی گفتنی است که مدل ANFIS، با انتخاب مناسب مقدار برای ابزارهای کنترلی، کمتر آن‌ها را تغییر می‌دهد. این امر باعث افزایش طول عمر ابزارهایی مانند فن پردازنده می‌شود.



(شکل-۱۰): کنترل دمای پردازنده با استفاده از مدل‌های

MLP و ANFIS

(Figure-10): processor thermal control using ANFIS and MLP models

برای ارزیابی مدل کنترلی پیشنهادی، با دو کنترل‌کننده مشابه مقایسه شده است. یکی از این کنترل‌کننده‌ها توسط لی و همکاران ارائه شده است [12]. ایشان ابتدا از تغییرات سرعت فن در جهت تغییر دما به سمت حدآستانه استفاده می‌کنند؛ سپس، در صورتی که فن نتواند دما را حول و حوش حدآستانه حفظ کند، از تغییرات فرکانس بهره می‌برند. مدل کنترلی مورد مقایسه دوم، توسط هانومیا و همکاران ارائه شده است [13]. ایشان در بازه‌های زمانی کوتاهی از یک مدل در جهت تعیین مقدار فرکانس استفاده می‌کنند. در بازه‌های زمانی طولانی‌تر، از یک مدل دیگر در جهت تعیین مقدار برای سرعت فن استفاده می‌کنند. پیاده‌سازی و مقایسه این دو رویکرد با مدل کنترلی پیشنهادی انجام شده است. یک بخش جزئی از مقایسه این رویکردها در شکل (۱۱) نمایش داده شده است. در این شکل، هدف نمایش نحوه همگرایی دما به دمای حدآستانه، با رویکردهای کنترلی مختلف است. رویکرد پیشنهادی، افزون بر این که دما را با سرعت بالایی به دمای حدآستانه همگرا می‌کند، از تغییرات مداوم دما نیز جلوگیری می‌کند. لازم به ذکر است که از دلایل اصلی وجود این عملکرد بالا در مدل پیشنهادی، ویژگی‌های مناسبی است که برای آن انتخاب شده است.

- [12] 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)*, 2010, pp. 131-140.
- [13] 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.
- I. Yco, C.C. Liu, and E.J. Kim, "Predictive dynamic thermal management for multicore systems," *Proc. 45th annual Design Automation Conference*, 2008, pp. 734-739.
- [14] G. Liu, M. Fan, and G. Quan, "Neighbor-aware dynamic thermal management for multi-core platform," *Proc. Design, Automation & Test in Europe Conference & Exhibition (DATE)*, 2012 pp. 187-192.
- [15] A. Kumar, L. Shang, L.S. Peh, and N. K. Jha, "HybDTM: a coordinated hardware-software approach for dynamic thermal management," *Proc. Design Automation Conference*, 2006, pp. 548-553.
- [16] K.J. Lee and K. Skadron, "Using performance counters for runtime temperature sensing in high-performance processors," *IEEE International Parallel and Distributed Processing Symposium*, 2005.
- [17] S. J. Lu, R. Tessier, and W. Burleson, "Dynamic On-Chip Thermal Sensor Calibration Using Performance Counters," *IEEE Trans. on Computer-Aided Design of Integrated Circuits and Systems*, vol. 33, no. 6, pp. 853-866, 2014.
- [18] 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.
- [19] K. Zhang, A. Guliani, S. Ogrenci-Memik, G. Memik, K. Yoshii, R. Sankaran, and P. Beckman, "Machine Learning-Based Temperature Prediction for Runtime Thermal Management Across System Components," *IEEE Trans. on Parallel and Distributed Systems*, vol. 29, no. 2, pp. 405-419, 2018.
- [20] J. M. N. Abad, B. Salami, H. Noori, A. Soleimani and F. Mehdipour, "A neuro-fuzzy fan speed controller for dynamic thermal management of multi-core processors," *In Proceedings of the 11th ACM Conference on Computing Frontiers*, 2014, p. 29.
- [21] J. M. N. Abad and A. Soleimani, "A neuro-fuzzy fan speed controller for dynamic management of processor fan power consumption," *In Swarm Intelligence and Evolutionary Computation (CSIEC)*, pp. 148-153, 2016.

7- References

۷- 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] A. K. Coskun, T. S. Rosing, and K. C. Gross, "Utilizing predictors for efficient thermal management in multiprocessor SoCs," *IEEE Trans. on Computer-Aided Design of Integrated Circuits and Systems*, vol. 28, no. 10, pp. 1503-1516, 2009.
- [3] A. K. Coskun, T. S. Rosing, and K. C. Gross, "Proactive temperature balancing for low cost thermal management in MPSoCs," *Proc. IEEE/ACM International Conference on Computer-Aided Design*, 2008, pp. 250-257.
- [4] R. Cochran and S. Reda, "Thermal prediction and adaptive control through workload phase detection," *ACM Trans. on Design Automation of Electronic Systems (TODAES)*, vol. 18, no. 1, p. 7, 2013.
- [5] 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.
- [6] M. Zaman, A. Ahmadi, and Y. Makris, "Workload characterization and prediction: A pathway to reliable multi-core systems," *Proc. International On-Line Testing Symposium (IOLTS)*, pp. 116-121, 2015.
- [7] M. Stockman, M. Awad, H. Akkary, and R. Khanna, "Thermal status and workload prediction using support vector regression," *Proc. International Conference on Energy Aware Computing*, 2012, pp. 1-5.
- [8] Y. Ge, Q. Qiu, and Q. Wu, "A multi-agent framework for thermal aware task migration in many-core systems," *IEEE Trans. on Very Large Scale Integration (VLSI) Systems*, vol. 20, no. 10, pp. 1758-1771, 2012.
- [9] P. Kumar and D. Atienza, "Neural network based on-chip thermal simulator," *Proc. Circuits and Systems (ISCAS)*, pp. 1599-1602, 2010.
- [10] A. Vincenzi, A. Sridhar, M. Ruggiero, and D. Atienza, "Fast thermal simulation of 2D/3D integrated circuits exploiting neural networks and GPUs," *Proc. 17th IEEE/ACM international symposium on low-power electronics and design*, pp. 151-156, 2011.
- [11] A. Sridhar, A. Vincenzi, M. Ruggiero, and D. Atienza, "Neural network-based thermal simulation of integrated circuits on GPUs," *IEEE Trans. on Computer-Aided Design of Integrated Circuits and Systems*, vol. 31, no. 1, pp. 23-35, 2012.



باقر سلامی مدرک کارشناسی خود را در رشته مهندسی کامپیوتر از دانشگاه آزاد اسلامی مشهد در سال ۱۳۸۶ و مدرک کارشناسی ارشد خود را در همین رشته از دانشگاه فردوسی مشهد در سال ۱۳۹۲ دریافت کرده است. تمرکز پژوهشی ایشان در زمینه مدیریت توان مصرفی و دمای پردازنده‌ها است. وی در حال حاضر دانشجوی مقطع دکترای رشته مهندسی کامپیوتر در دانشگاه فردوسی مشهد و علائق پژوهشی ایشان شامل مدیریت کارایی، توان مصرفی و دمای پردازنده‌های چندهسته‌ای، طراحی سیستم‌های نهفته، سیستم‌های چندپردازنده‌ای روی یک تراشه و برنامه‌نویسی موازی است.

نشانی رایانامه ایشان عبارت است از:

bagher.salami@stu-mail.um.ac.ir

- [22] H. Peng, F. Long, and C. Ding, "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," *IEEE Trans. on pattern analysis and machine intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005.
- [23] C. Ding and H. Peng, "Minimum redundancy feature selection from microarray gene expression data," *Journal of bioinformatics and computational biology*, vol. 3, no. 2, pp. 185-205, 2005.
- [24] lm-sensors Linux hardware monitoring [Online]. Available: <http://www.lm-sensors.org>, Jan 2017.
- [25] Linux cpufreq governors, LinuxKernel [Online]. Available: <https://www.kernel.org/doc/Documentation/cpu-freq/governors.txt>. Jan 2017.



جواد محبی نجم‌آباد مقطع کارشناسی و کارشناسی ارشد را در گرایش مهندسی نرم‌افزار گذرانده است. همچنین، مقطع دکترا را در رشته کامپیوتر-گرایش هوش مصنوعی در دانشگاه صنعتی شاهرود به اتمام رسانده است. ایشان عضو هیأت علمی دانشگاه آزاد قوچان از سال ۱۳۸۸ تا کنون است. زمینه‌های پژوهشی ایشان شامل شناسایی و مدل‌سازی سیستم‌ها، پیش‌بینی و مدیریت دما و توان مصرفی در سیستم‌های چندهسته‌ای است. نشانی رایانامه ایشان عبارت است از:

javad.mohebi@gmail.com



مرتضی مرادی مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی کامپیوتر در سال‌های ۱۳۸۶ و ۱۳۹۱ در گرایش مهندسی نرم‌افزار کسب کرده است. در حال حاضر، ایشان در حال کسب مدرک دکترای مهندسی کامپیوتر از گروه کامپیوتر در دانشگاه فردوسی مشهد است. وی مقالاتی در چندین کنفرانس و ژورنال داخلی و بین‌المللی منتشر کرده است. علائق پژوهشی او شامل محاسبات موازی، مدیریت دما و انرژی پردازنده، زیست محاسباتی و الگوریتم‌ها است. نشانی رایانامه ایشان عبارت است از:

moradi.edu@gmail.com