



CENTRO DE INVESTIGACIÓN Y ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL

UNIDAD ZACATENCO

DEPARTAMENTO DE COMPUTACIÓN

Análisis de Proporcionalidad Energética en servidores de HPC

Tesis que presenta:

Eduardo Antonio Roque Díaz

Para obtener el grado de:

Maestro en Ciencias en Computación

Director de la tesis:

Dr. Amilcar Meneses Viveros

México, Ciudad de México

Agosto, 2021

Resumen

En la actualidad, las supercomputadoras son una herramienta fundamental en la investigación científica. La simulación de modelos computacionales complejos, así como eventos pasados y futuros, son una ínfima parte de las aplicaciones de estos equipos. Sin embargo, la potenciación de los mismos en términos de rendimiento va de la mano del consumo de potencia. El carácter insostenible de esta situación, debido a su impacto económico y sobre todo ambiental, así como la carencia de un indicador adecuado para con el análisis energético de los servidores de cómputo de alto desempeño, instó el desarrollo del presente estudio. En el que, luego de considerar varios indicadores de proporcionalidad y eficiencia energética, así como técnicas de minería de datos y estadística multivariada, se propone un índice compuesto capaz de describir este fenómeno. Esta investigación, identificó y fundamentó varias de las tendencias actuales del diseño de servidores. Además, evaluó la influencia de configuraciones disímiles de *hardware*, *software* y estrategias de administración de energía, en la proporcionalidad y eficiencia energética de los medios de cómputo. Asimismo, se analizaron las principales limitantes en el diseño de sistemas exaescala, y en qué medida la eficiencia y no la proporcionalidad energética sustenta este fin.

Palabras clave: supercomputadoras, indicadores, cómputo de alto desempeño, proporcionalidad energética, sistemas exaescala.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

Abstract

Nowadays, supercomputers are a fundamental tool in scientific research. The simulation of complex computational models, as well as past and future events, are a tiny part of the applications of these equipments. However, their enhancement in terms of performance goes hand in hand with power consumption. The unsustainable nature of this situation, due to its economic and especially environmental impact, as well as the lack of an adequate indicator for the energy analysis of high-performance computing servers, prompted the development of this study. In which, after considering several energy proportionality and efficiency indicators, as well as data mining techniques and multivariate statistics, a composite index capable of describing this phenomenon is proposed. This research, identified and supported several of the current trends in server design. In addition, it evaluated the influence of dissimilar configurations of hardware, software, and energy management strategies, on the energy proportionality and efficiency of computing means. Likewise, the main limitations in the design of exascale systems were analyzed, and to what extent energy efficiency and not energy proportionality supports this end.

Key words: supercomputers, indicators, high-performance computing, energy proportionality, exascale system.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

Agradecimientos

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por financiar estos dos años de maestría, el seguro médico y todas las gratuidades ofrecidas.

Agradezco al Centro de Investigación y de Estudios Avanzados (CINVESTAV) y específicamente al Departamento de Computación, por aceptarme en la maestría y darme la posibilidad y los medios necesarios para crecer profesionalmente.

Agradezco al Dr. Amilcar Meneses Viveros por la ayuda, guía y conocimientos compartidos durante el desarrollo de esta tesis. Además, al Dr. José Guadalupe Rodríguez García y al Dr. Iván López Arévalo por los comentarios y recomendaciones aportadas durante el desarrollo de esta investigación. Le estoy infinitamente agradecido a los profesores del departamento por sus enseñanzas y su contribución a mi formación profesional. Asimismo, al resto del personal del departamento, especialmente a Sofi, por su afecto y apoyo.

Agradezco a mi familia, por ser mi soporte en los buenos y malos momentos, por su apoyo incondicional y motivarme a ser una mejor persona cada día. También, a mi esposa, por ser mi ancla y fuente de aliento, sobre todo en esta etapa de mi vida.

Agradezco a mis amigos, a los que en Cuba me ayudaron en los preparativos del viaje y desde la distancia me apoyaron, y a los nuevos que conocí con mi llegada a México. Esos que estuvieron a mi lado en mis travesías a migración y el SAT. A Nínive, Alejandra, Leonel, Pedro y mis compañeros de generación, de todo corazón, gracias.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

Dedicatoria

*A mi madre, abuelos y tía, soy quien soy gracias a ustedes.
A dibu y blanca, partes de mi alma.*

Índice general

Resumen	III
Abstract	V
Índice	XI
Índice de figuras	XIII
Índice de tablas	XV
1. Introducción	1
1.1. Motivación	1
1.2. Planteamiento del problema	3
1.3. Propuesta de solución	3
1.4. Objetivos	4
1.5. Justificación	4
1.6. Organización de la Tesis	5
2. Indicadores	7
2.1. Indicadores de proporcionalidad energética	7
2.2. Indicadores de eficiencia energética	12
2.2.1. Otros indicadores	13
2.3. Indicadores multivariados	14
3. Benchmarks y datasets	15
4. Análisis de minería de datos	21
4.1. Análisis descriptivo	21
4.1.1. Distribución	21
4.1.2. Tendencias y Relaciones	22
4.1.3. Análisis de características	28
4.1.3.1. Procesador	28
4.1.3.2. Memorias	30

4.1.3.3. Unidades de almacenamiento	30
4.1.3.4. Entorno de operación	31
4.1.3.5. Gabinete	32
4.2. Preprocesamiento	33
4.2.1. Limpieza de los datos	34
4.2.2. Integración de conjuntos de datos	34
4.2.3. Selección de características	35
4.2.4. Imputación	36
4.2.4.1. Imputación Simple	36
4.2.5. Transformación	37
4.2.6. Discretización	39
4.2.7. Reducción de la dimensionalidad	39
4.2.7.1. Descomposición en Valores Singulares	40
4.2.7.2. Análisis de Componentes Principales	40
4.2.7.3. Análisis de Componentes Principales Robusto	42
4.3. Análisis exploratorio	44
4.3.1. Factores condicionantes de superproporcionalidad	45
4.3.2. Análisis de agrupamiento	48
4.3.2.1. Métricas de distancia	48
4.3.2.2. Algoritmos de agrupamiento	50
4.3.2.3. Resultados del análisis exploratorio	53
4.4. Indicador multivariado	56
4.4.1. Ponderación	57
4.4.2. Agregación	58
4.4.3. Análisis de robustez	60
5. Resultados y discusión	63
6. Conclusiones y trabajo futuro	69
A. Esquemas lógicos	71
B. Selección de características	75
Bibliografía	85

Índice de figuras

2.1. Sistema con $EP = 1$	8
2.2. Sistema con $EP = 0$	8
2.3. SPECpower_ssj2008: IPR de sistema Altos R380 F2.	9
2.4. LD sistema superlineal.	10
2.5. LD sistema sublineal.	10
2.6. LDR sistema superlineal.	11
2.7. LDR sistema sublineal.	11
2.8. Diagrama de retardo de energía.	13
4.1. SPECpower_ssj2008: Curvas de tendencia de los indicadores DR y EP	23
4.2. SPECpower_ssj2008: Curvas de tendencia de los indicadores LD y LDR	23
4.3. SPECpower_ssj2008: Gráfica de dispersión de los indicadores LDR e IPR	24
4.4. SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador EP en términos de los indicadores DR y LD	24
4.5. SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador EP a partir del indicador $L1$	25
4.6. SPECpower_ssj2008: Gráfica de dispersión del SCR y $\frac{\tau_{10}}{P_{10}}$	26
4.7. SPECpower_ssj2008: Gráficas de dispersión de los indicadores EP , SCR y $\frac{\tau_{10}}{P_{10}}$	26
4.8. SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador SCR a partir de los indicadores EP y $\frac{\tau_{10}}{P_{10}}$	26
4.9. SPECpower_ssj2008: Consumo de potencia por nivel de carga.	27
4.10. SPECpower_ssj2008: Eficiencia energética por nivel de carga.	27
4.11. SPECpower_ssj2008: Relación entre la EP y la amplitud de las zonas de alta eficiencia energética.	27
4.12. SPECpower_ssj2008: Curva de tendencia de la frecuencia base del procesador.	28
4.13. SPECpower_ssj2008: Curva de tendencia del número de núcleos por procesador.	28
4.14. SPECpower_ssj2008: Impacto del DVFS en la proporcionalidad energética. .	30
4.15. SPECpower_ssj2008: Impacto de las unidades de almacenamiento en la proporcionalidad energética.	31
4.16. SPECpower_ssj2008: Impacto del sistema operativo en la proporcionalidad energética.	32

4.17. SPECpower_ssj2008: Impacto del tipo de gabinete en la proporcionalidad energética.	33
4.18. Top500: Diagrama de caja y bigotes.	34
4.19. PCA: Análisis de sensibilidad a valores atípicos.	42
4.20. PCA: Análisis de sensibilidad a valores atípicos posterior a la estandarización.	42
4.21. RPCA: Análisis de sensibilidad.	43
4.22. SPECpower_ssj2008: PCA.	44
4.23. Top500: PCA.	44
4.24. <i>Random Forest</i> : <i>Ranking</i> de las 10 características más determinantes en materia de superproporcionalidad energética.	47
4.25. χ^2 : <i>Ranking</i> de las 10 características más determinantes en términos de superproporcionalidad energética.	47
4.26. SPECpower_ssj2008: DMDBSCAN.	54
4.27. Top500: DMDBSCAN.	54
4.28. Top500: Selección de las características a partir de <i>Random Forest</i>	55
4.29. Análisis de calificaciones por niveles de ponderación.	59
4.30. Análisis de ponderaciones en base a la función objetivo.	59
5.1. Top500: Tendencia de los índices a través del <i>ranking</i>	64
5.2. Green500: Tendencia de los índices a través del <i>ranking</i>	64
5.3. <i>REE</i> : Tendencia de los índices a través del <i>ranking</i>	65
5.4. <i>CI</i> : Tendencia de los índices a través del <i>ranking</i>	66
5.5. Top500: <i>CI</i> atípicos.	66
5.6. Top500: Sistemas con <i>CI</i> atípicos.	66
5.7. Top500: Tendencia de los indicadores <i>CI</i> y <i>REE</i>	67
5.8. Green500: Tendencia de los indicadores <i>CI</i> y <i>REE</i>	67
5.9. Top500: Diagrama <i>CI-REE</i>	68

Índice de tablas

1.1. Porcentaje de GEI que se generaron a partir de gas natural, México 2013.	3
1.2. Factor de emisión eléctrico por tipo de combustible, México 2013.	3
3.1. Conjunto de puntos de referencias que integran el <i>benchmark</i> SPEC OMP 2012.	17
3.2. Conjunto de puntos de referencias que integran el <i>benchmark</i> SPEC MPI 2007.	17
3.3. Comparación de los <i>benchmarks</i> de rendimiento y consumo de potencia.	19
4.1. SPECpower_ssj2008: Distribución de las principales variables.	22
4.2. Top500: Distribución de las principales variables.	22
4.3. Listado de procesadores presentes en los servidores superproporcionales.	29
4.4. Métricas de similitud entre atributos.	48
4.5. SPECpower_ssj2008: Análisis de agrupamiento	54
4.6. Top500: Análisis de agrupamiento	54
4.7. Análisis de incertidumbre.	60
4.8. Índices de sensibilidad de primer y segundo orden de los factores de entrada. .	61
5.1. <i>REE</i> : Coeficientes de correlación de Pearson.	65
5.2. <i>CI</i> : Coeficientes de correlación de Pearson.	65
5.3. Número de variaciones por criterio de ordenamiento.	67
A.1. SPECpower_ssj2008: Esquema lógico.	73
A.2. Top500: Esquema lógico.	73
A.3. Green500: Esquema lógico.	74
B.1. SPECpower_ssj2008: Influencia de los atributos en materia de superproporcionabilidad energética.	76
B.2. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de DBS- CAN	77
B.3. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de Esperanza Máxima.	78
B.4. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de Fuzzy C-Means.	80
B.5. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de K-Medoides.	81

B.6. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de <i>Spectral Clustering</i>	82
B.7. SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de K- Means.	83

INTRODUCCIÓN

Durante varias décadas, la eficiencia de los medios de cómputo se cuantificó a partir del rendimiento de los mismos. En consecuencia, los diseñadores de *hardware* enfocaban sus esfuerzos en maximizar el rendimiento de sus productos sin importar qué, lo que propició un incremento desmedido del consumo de energía eléctrica. Además, dichos esfuerzos se centraban principalmente en los niveles de alta utilización, ya que los niveles más discretos se consideraban menos relevantes [Hsu and Poole, 2015]. Como resultado, en la actualidad, estos últimos son puntos críticos del diseño de servidores, pues en estos niveles, los sistemas no suelen cumplir con el principio de energía, y la eficiencia energética decrece abruptamente.

El principio de energía plantea que el consumo de potencia debe estar en proporción con el nivel de utilización [Barroso and Hölzle, 2007]. Por lo tanto, un servidor proporcionalmente energético es aquel que en estado ocioso o *idle* no consume potencia, y la misma se incrementa gradualmente, a medida que aumenta la carga de trabajo. Sin embargo, la propiedad antes mencionada $P_{idle} = 0$, no puede ser satisfecha en realidad por ningún servidor, puesto que, con sólo encenderse, introduce una penalización en materia de energía. No obstante, dicho principio se utiliza en el diseño de servidores, pues define a grandes rasgos, las principales características en términos energéticos, de un sistema de cómputo ideal.

1.1. Motivación

Los servidores de Cómputo de Alto Desempeño (HPC)¹ son de los sistemas informáticos que más sobresalen por su rendimiento. Sin embargo, los mismos consumen una cantidad excesiva de energía eléctrica. Estos servidores, habitualmente procesan grandes cantidades de datos, sobre los cuales realizan un número considerable de operaciones de punto flotante por segundo (FLOPS), por lo que la faena de trabajo de los mismos suele estar comprendida en niveles elevados de utilización. En dichos niveles, si bien la proporcionalidad y eficiencia energética se incrementan, también el consumo de potencia. Motivo por el cual, [Barroso and Hölzle, 2007] resaltaron la relevancia del estudio de la proporcionalidad energética a fin de reducir el consumo de energía, sobre todo, en los niveles de utilización más bajos.

¹El HPC es un campo de actividad que se relaciona con todas las facetas de la tecnología, la metodología y la aplicación, asociadas con el logro de la mayor capacidad informática posible en cualquier momento y tecnología [Sterling et al., 2017].

Más aún, existe una notable diferencia entre las tasas de crecimiento del rendimiento y la eficiencia energética de estos sistemas. De acuerdo con [Feng and Cameron, 2007], en el año 2007 los servidores de HPC poseían un rendimiento 10000 veces mayor que en 1992, mientras que la relación rendimiento por unidad de potencia (FLOPS/W) era apenas 300 veces superior². Asimismo, con el transcurso de los años se incrementó el consumo de potencia. Muchos de los servidores que integran el Top500 requieren hasta 10 Megavatios (MW) de potencia máxima, lo cual equivale al consumo promedio de energía eléctrica de una ciudad de 40000 habitantes [Feng and Cameron, 2007].

[Ryckbosch et al., 2011] plantearon que los costos de compra y mantenimiento representan el 69 % del costo total de propiedad. Sin embargo, la construcción de sistemas de refrigeración apropiados, capaces de disipar el calor que generan estos servidores, puede llegar a ser incluso tan costosa como los mismos [Feng and Cameron, 2007]. De acuerdo con [Barroso and Hölzle, 2007], los costos de refrigeración y aprovisionamiento son proporcionales al consumo energético promedio. Como consecuencia, muchos de los propietarios de servidores de HPC, suelen pagar anualmente cientos de miles o incluso millones de dólares en razón del consumo de energía eléctrica [Feng and Cameron, 2007]³.

En la actualidad, el consumo de potencia es uno de los principales desafíos de la comunidad de HPC, al ser la principal limitante de diseño de sistemas informáticos exaescala [Subramaniam and Feng, 2013]. Por lo que, [Bergman et al., 2008] y [Geller, 2011] analizaron el impacto de disímiles configuraciones de *hardware* y *software* en el diseño de un sistema exaescala, así como los principales retos en este sentido. Además, [Jiang et al., 2017] destacaron la influencia de la adopción de procesadores de microarquitectura en el estancamiento de la proporcionalidad energética, e incremento de la eficiencia energética.

El creciente consumo energético de los servidores de HPC tiene un alto impacto medioambiental. Pues, a medida que éste aumenta, también lo hacen la cantidad de energía eléctrica que generan las termoeléctricas, y el número de toneladas de gases de efecto invernadero (GEI) que se emiten a la atmósfera. Tal es el caso, que la Organización de Naciones Unidas, reportó un incremento del 50 % de las emisiones de dióxido de carbono (CO_2) desde 1990. Asimismo, la Agencia de Protección Ambiental informó que por cada MWh de consumo de energía, se emiten a la atmósfera 0.72 toneladas de CO_2 [Uddin et al., 2015].

Las emisiones de CO_2 representan las dos terceras partes de los GEI (ver tabla 1.1); las cuales, principalmente se deben a la generación de energía eléctrica. Según el Instituto Nacional de Cambio Climático de México, en el año 2015, el sector de energía originó el 70 % de los 683 millones de toneladas de CO_2 equivalentes ($MtCO_2e$) que se emitieron a la atmósfera. También, la perspectiva del sector eléctrico mexicano para el período 2012-2026, predice un crecimiento de la demanda de electricidad en un 72 % [Díaz et al., 2016], donde la energía eléctrica se generará principalmente a partir de gas natural (ver tabla 1.2).

²[Feng and Cameron, 2007] destacaron que la relación rendimiento-espacio (FLOPS/ m^2) creció solamente 65 veces de 1992 al 2007.

³De acuerdo con [Petrini et al., 2004], el Laboratorio Nacional Lawrence Livermore gasta anualmente alrededor de seis millones de dólares en la refrigeración de sus equipos.

Combustible	CO_2	CH_4	N_2O	HFC	SF_6
Porcentaje	71%	21%	6%	1.8%	<1%

Tabla 1.1: Porcentaje de GEI que se generaron a partir de gas natural, México 2013.

Combustible	$CO_2(kgCO_2/TJ)$	$CH_4(kgCH_4/TJ)$	$N_2O(kgN_2O/TJ)$
Carbón	94600	1	1.5
Diesel	74100	3	0.6
Combustóleo	77400	3	0.6
Gas Natural	56100	1	0.1

Tabla 1.2: Factor de emisión eléctrico por tipo de combustible, México 2013.

1.2. Planteamiento del problema

En los últimos años, se han propuesto varios indicadores a fin de analizar la proporcionalidad energética de los medios de cómputo. Éstos, en su mayoría son índices simples, por lo que resultan incapaces de evaluar el impacto energético de múltiples dimensiones. Además, no suelen tener en cuenta la influencia del contexto de trabajo de los sistemas en el consumo de potencia. Asimismo, si bien algunos de esos indicadores son adecuados para el análisis energético de los servidores de centros de datos, no resultan así para servidores de HPC. En este sentido, existen estudios que destacan algunas desventajas del indicador FLOPS/W [Hsu et al., 2005], [Hsu et al., 2012]. En consecuencia, hasta la fecha, no existe un consenso de cómo medir cuán proporcional es el consumo de potencia [Belady, 2007], por lo que se carece de un indicador fehaciente para el análisis energético de los servidores de HPC.

Las principales preguntas de investigación de este estudio son: ¿cuán eficaces son las actuales estrategias de administración de energía e indicadores de proporcionalidad y eficiencia energética, para con el análisis y reducción del consumo de energía eléctrica en los servidores de HPC? ¿cuáles son las futuras directrices en el diseño de servidores de HPC, a fin de reducir el consumo energético de los mismos? ¿qué características debe poseer un indicador adecuado para con el análisis energético de los servidores de HPC?

1.3. Propuesta de solución

En muchas ocasiones, un único indicador resulta insuficiente para capturar la variedad de la información oculta en un conjunto de datos. En tales circunstancias, puede ser provechoso el empleo de un indicador multivariado. Éstos, son capaces de simplificar un concepto multidimensional en un índice simple, razón por la cual, en la actualidad, poseen una gran popularidad en varias áreas de investigación. Tal es el caso, que en los últimos años se definieron disímiles indicadores multivariados, con el objetivo de dar solución al problema expuesto en la sección anterior. Sin embargo, hasta el momento, tales indicadores resultan incapaces de describir el consumo energético de los servidores de HPC. Motivo por el cual, en la presente tesis se propone el diseño de un indicador multivariado ponderado, a partir de la aplicación de técnicas de minería de datos y estadística multivariada.

Este estudio pone a prueba la hipótesis de que los actuales indicadores de proporcionalidad y eficiencia energética, son insuficientes para realizar un análisis energético adecuado de los servidores de HPC. Además, evalúa la presunción de que varias de las vigentes técnicas de administración de energía, son cada vez menos determinantes en la gestión energética de dichos servidores. De ser confirmados estos supuestos, carecería de sentido el empleo de diversas estrategias de calendarización de tareas y gestión de energía. Así pues, estas hipótesis dan origen a los objetivos generales y específicos de la presente investigación.

1.4. Objetivos

Objetivos Generales

Proponer un indicador multivariado ponderado, que contribuya al análisis energético de los servidores de HPC.

Objetivos Específicos

1. Identificar varios de los indicadores de proporcionalidad y eficiencia energética, y las relaciones existentes entre los mismos.
2. Examinar los puntos de referencia o *benchmarks* de rendimiento y consumo de potencia de medios de cómputo.
3. Describir las principales características de los conjuntos de datos Green500 y Top500, así como sus ventajas y desventajas para el análisis energético de servidores de HPC.
4. Analizar el impacto de la técnica de Escalado Dinámico de Frecuencia y Voltaje (DVFS)⁴ en la proporcionalidad energética de los servidores de HPC.

1.5. Justificación

Ante el significativo consumo de potencia de los servidores de HPC, y su influencia en términos económicos y ambientales, resulta de especial interés analizar, qué factores y en qué medida condicionan dicho consumo. Ésto, a fin de evaluar el impacto energético de las actuales tendencias de diseño de servidores y técnicas de administración de energía. La presente investigación, surge de la necesidad de estudiar la proporcionalidad y eficiencia energética de los sistemas de HPC, así como la incidencia de estas últimas en materia de consumo de energía. Este estudio busca proporcionar información útil a los diseñadores de servidores y a la comunidad de HPC, acerca de las principales limitantes y desafíos energéticos del desarrollo de supercomputadoras más potentes, así como el aprovisionamiento de servidores en base al consumo de potencia y la eficiencia energética.

⁴El Escalado Dinámico de Frecuencia y Voltaje es una técnica de ahorro energético que consiste en variar dinámicamente la frecuencia de reloj del procesador y el voltaje de los componentes del sistema con respecto a las demandas computacionales [Le Sueur and Heiser, 2010].

1.6. Organización de la Tesis

El contenido de la presente tesis está desglosado en seis capítulos. En éste, el capítulo 1, se exponen los motivos que alentaron el desarrollo de la misma, así como la problemática a resolver y la propuesta de solución.

En el capítulo 2 se definen los principales conceptos sobre los que se fundamenta el desarrollo de esta investigación. En el mismo, se analizan varios de los indicadores de proporcionalidad y eficiencia energética, sus ventajas y desventajas, y cuán acertados resultan estos para el análisis energético de los servidores de HPC. Además, se describen los indicadores multivariados ponderados definidos por [Strohmaier, 2009] y [Hsu et al., 2012] con el objetivo de solucionar el problema antes expuesto.

En el capítulo 3 se examinan las principales características, ventajas y desventajas de diversos conjuntos de datos y *benchmarks*, a fin de identificar los que resulten más convenientes para el posterior análisis.

En el capítulo 4 se estudia el comportamiento y la relación existente entre varios indicadores energéticos. Asimismo, se considera el impacto de múltiples configuraciones de *hardware* y *software* en la proporcionalidad energética de los sistemas. Además, se presentan los resultados obtenidos del análisis de agrupamiento y la selección de las características de mayor relevancia. También, se detalla el proceso de diseño del indicador multivariado propuesto como solución al problema.

En el capítulo 5 se exponen los resultados alcanzados tras la aplicación del indicador definido, y se reflexiona acerca de éstos. Se compara dicho indicador con otros indicadores, y se destacan sus principales ventajas y desventajas para con el objetivo principal de la investigación. Mientras que, en el capítulo 6 se presentan las conclusiones a las que se arribó como resultado del estudio realizado, y se proponen futuros temas de investigación.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

INDICADORES

En el presente capítulo se analizan varios indicadores de proporcionalidad y eficiencia energética, así como indicadores multivariados. Ésto, teniendo en cuenta la utilidad de los mismos para con el análisis energético de los sistemas, y considerando que los indicadores multivariados se suelen conformar a partir de variables individuales y otros índices compuestos.

2.1. Indicadores de proporcionalidad energética

De acuerdo con el principio de energía, para medir la proporcionalidad energética de un sistema, es necesario analizar qué tan cerca del origen comienza la curva de potencia, y qué tan lineal es la misma. Sin embargo, como se mencionó en la sección 1.2, hasta la fecha no existe un indicador universal de proporcionalidad energética. Motivo por el cual, es necesario el empleo de dos indicadores, uno que mida el rango y otro que mida la linealidad. En la presente sección se describen varios de estos indicadores, sus principales características, ventajas y desventajas.

Rango dinámico. El rango dinámico (DR) [Wong and Annavaram, 2013], solía ser el indicador comúnmente usado para cuantificar la proporcionalidad energética de los medios de cómputo. Éste, indica la porción de la potencia máxima que no se desperdicia al estar el sistema en estado ocioso, es decir, la diferencia del consumo de potencia en los niveles de trabajo *peak* e *idle*, normalizada sobre el consumo de potencia en el nivel *peak*.

$$DR = \frac{P_{peak} - P_{idle}}{P_{peak}}, \quad (2.1)$$

tal que P_{idle} y P_{peak} son las potencias que se utilizan en los niveles de 0 % y 100 % de carga de trabajo respectivamente. DR toma valores comprendidos entre 0 y 1, siendo este último en caso de tratarse de un sistema proporcionalmente energético.

En la actualidad, el empleo de este indicador no resulta totalmente adecuado, sobre todo en el contexto de los centros de datos, pues el mismo no tiene en cuenta el consumo de potencia en los niveles de carga intermedios. Además, si bien pudiese considerarse conveniente para el análisis de la proporcionalidad energética de servidores de HPC, esto no es del todo cierto, pues dichos sistemas no suelen desempeñarse al 100 % de carga de trabajo.

Proporcionalidad energética. El indicador proporcionalidad energética (EP) [Ryckbosch et al., 2011], a diferencia del indicador DR , sí tiene en cuenta el consumo de potencia en los distintos niveles de carga de trabajo, por lo que resulta más apropiado para el análisis energético de los actuales servidores. El mismo, fue propuesto como un indicador ortogonal al aprovisionamiento del conjunto de servidores activos. Además, EP se enfoca en el desperdicio de energía de los servidores parcialmente utilizados [Varsamopoulos et al., 2010].

$$EP = 2 - \frac{\int_{l=0}^{l=1} P(l) \cdot dl}{\int_{l=0}^{l=1} P_E(l) \cdot dl}, \quad (2.2)$$

$$P_E(l) = P(1) \cdot l, \quad (2.3)$$

siendo $P(l)$ el consumo de potencia para un nivel de carga l , tal que $0 \leq l \leq 1$, $P(0) = P_{idle}$, $P(1) = P_{peak}$ y P_E un sistema hipotético de proporcionalidad energética. Además, $\int_{l=0}^{l=1} P(l) \cdot dl$ y $\int_{l=0}^{l=1} P_E(l) \cdot dl$ representan el área bajo la curva de potencia del sistema bajo prueba (SUT) e hipotético respectivamente.

Las figuras 2.1 y 2.2 ilustran la EP de dos SUT. En el caso de la primera, el área bajo la curva de potencia coincide con la de P_E , por lo que describe un consumo proporcional de potencia. Por el contrario, en la figura 2.2 el área bajo la curva de potencia del SUT duplica a la de P_E , de modo que $EP = 0$.

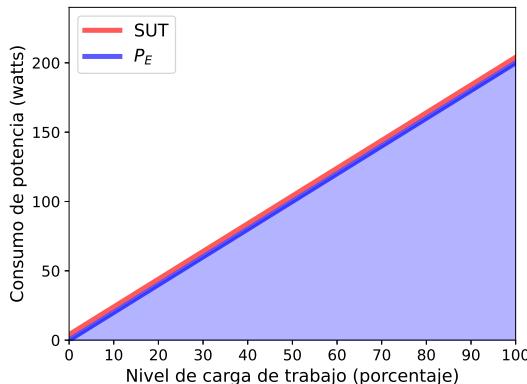


Figura 2.1: Sistema con $EP = 1$.

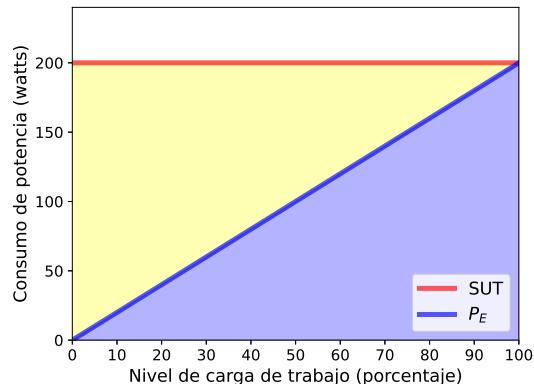


Figura 2.2: Sistema con $EP = 0$.

Por lo tanto, al igual que el indicador DR , la EP de un servidor proporcionalmente energético es 1, es decir, $DR(P_E) = EP(P_E) = 1$. De ahí que, [Hsu and Poole, 2015] enmarcaron ambos indicadores en el mismo rango de valores.

Proporción de potencia inactiva a pico. A diferencia de los anteriores, el indicador proporción de potencia inactiva a pico (IPR) [Varsamopoulos et al., 2010], cuantifica la desproporcionalidad energética de un sistema. Éste, de forma similar al DR , solo analiza el consumo de potencia en los estados *idle* y *peak*, y desconoce el consumo energético en los restantes niveles de carga.

$$IPR = \frac{P_{idle}}{P_{peak}}. \quad (2.4)$$

La IPR se define como el consumo de potencia en el estado *idle*, normalizado con respecto al consumo de potencia en el estado *peak*, por lo que toma valores comprendidos entre 0 y 1. De manera general, este indicador mide la porción de la potencia máxima que se desperdicia al estar un sistema en estado ocioso.

Muchos sistemas consumen una cantidad significativa de potencia en niveles discretos de carga de trabajo. La figura 2.3 muestra el consumo de potencia de un sistema Altos R380 F2, el cual, en estado ocioso, desperdicia aproximadamente la cuarta parte de su potencia máxima. Además, ésta ilustra la relación complementaria existente entre los indicadores DR e IPR , de tal modo que $IPR + DR = 1$, y por ende $IPR(P_E) = 0$.

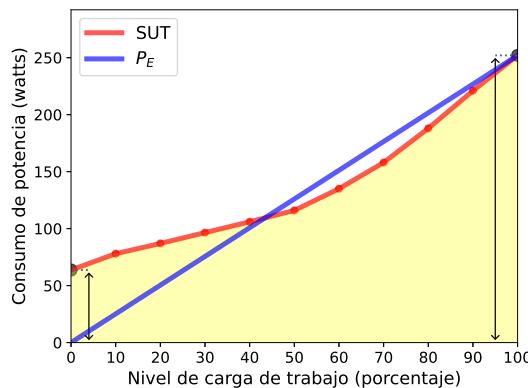


Figura 2.3: SPECpower_ssj2008: IPR de sistema Altos R380 F2.

Brecha de proporcionalidad. La brecha de proporcionalidad energética (PG) [Wong and Annavaram, 2013], cuantifica la desproporcionalidad energética de un sistema en los diferentes niveles de utilización. En los mismos, esta brecha consiste en la diferencia entre el consumo de potencia del SUT con respecto al descrito por P_E , normalizada sobre P_{peak} .

$$PG_l = \frac{P(l) - P_E(l)}{P_{peak}}, \quad (2.5)$$

siendo $P(l)$ y $P_E(l)$ el consumo de potencia del SUT y P_E para un nivel de carga l , tal que $0 \leq l \leq 1$. PG resulta de gran utilidad en el diseño y análisis energético de servidores de centros de datos y HPC, al identificar los niveles de mayor brecha de proporcionalidad.

Al analizar la proporcionalidad energética de un sistema, no solo es relevante cuánta potencia consume el mismo, sino también el comportamiento de dicho consumo. Mientras más lineal sea la curva de potencia de un sistema, menor será la penalización en términos de energía, al distribuir la carga de trabajo entrante por varios nodos homogéneos. En este sentido, el análisis de linealidad resulta de gran provecho, sobre todo en el contexto de trabajo de centros de datos.

Desviación lineal. El indicador desviación lineal (LD) [Wong and Annavaram, 2013], toma como referencia un sistema hipotético de consumo lineal de potencia P_L , y cuantifica la desviación con respecto al mismo.

$$LD = \frac{\int_{l=0}^{l=1} P(l) \cdot dl}{\int_{l=0}^{l=1} P_L(l) \cdot dl} - 1, \quad (2.6)$$

$$P_L(l) = P_{idle} + [P_{peak} - P_{idle}] \cdot l, \quad (2.7)$$

siendo $\int_{l=0}^{l=1} P(l) \cdot dl$ y $\int_{l=0}^{l=1} P_L(l) \cdot dl$ el área bajo la curva de potencia del SUT y P_L respectivamente. Si bien P_L describe un comportamiento lineal de consumo de potencia desde P_{idle} hasta P_{peak} , de modo tal que $LD(P_E) = LD(P_L) = 0$, no necesariamente coincide con P_E . Además, teniendo en cuenta el comportamiento de ambas curvas de potencia, los servidores se clasifican como lineal proporcional a la energía si $LD = 0$, superlineal proporcional a la energía si $LD > 0$ y es sublineal proporcional a la energía si $LD < 0$.

Las figuras 2.4 y 2.5 ilustran la relación existente entre el consumo de potencia de los sistemas superlineales y sublineales proporcionales a la energía, con relación a su respectivo sistema de referencia P_L .

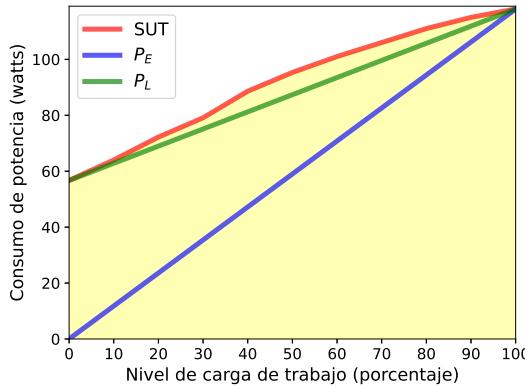


Figura 2.4: LD sistema superlineal.

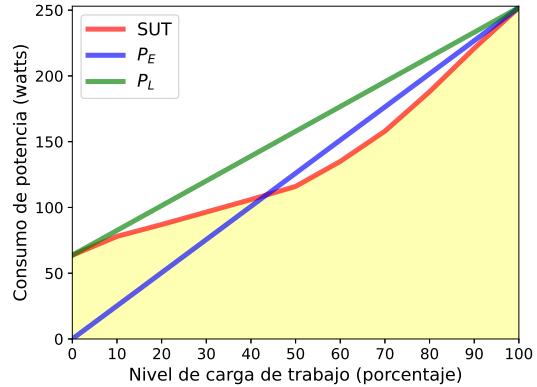


Figura 2.5: LD sistema sublineal.

En la figura 2.4 la curva de potencia del SUT se encuentra por encima de la curva de potencia de P_L , por lo que el indicador LD toma valores positivos. Por el contrario, en la figura 2.5 la curva de potencia del SUT se encuentra por debajo de la curva de potencia de P_L , lo cual significa que LD toma valores negativos. En definitiva, la linealidad del sistema se incrementa a medida que LD tiende a cero, pues mayor es la similitud entre las curvas de potencia del SUT y el hipotético sistema de referencia P_L .

Proporción de desviación lineal. El indicador proporción de desviación lineal (LDR) [Varsamopoulos et al., 2010], cuantifica la desviación lineal como la máxima brecha de separación entre las curvas de potencia del SUT y su respectivo P_L . Es decir, la LDR de un sistema se define como la mayor de las porciones de desviación lineal por nivel de carga, con respecto al sistema de referencia P_L .

$$LDR = \max_l \frac{|P(l) - ((P_{peak} - P_{idle}) \cdot l + P_{idle})|}{(P_{peak} - P_{idle}) \cdot l + P_{idle}}. \quad (2.8)$$

Lo anterior, puede expresarse como

$$LDR = \max_l \frac{|P(l) - P_L(l)|}{P_L(l)}, \quad (2.9)$$

$$LDR = \max_l \frac{|P(l)|}{P_L(l)} - 1. \quad (2.10)$$

Al igual que en el caso del indicador LD , la LDR distingue entre sublinealidad y superlinealidad. Además, se cumple que $LDR(P_E) = LDR(P_L) = 0$. Las figuras 2.6 y 2.7 ilustran el comportamiento de las curvas de potencia de sistemas superlineal y sublineal respectivamente, en relación con su correspondiente sistema de referencia P_L .

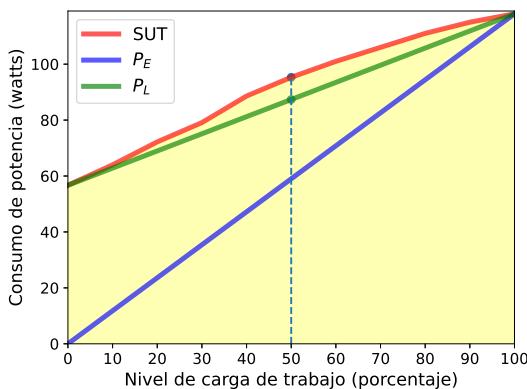


Figura 2.6: LDR sistema superlineal.

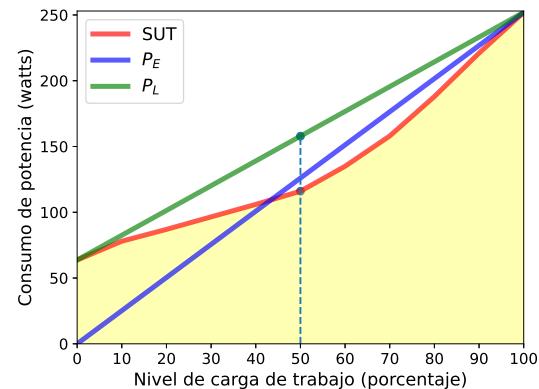


Figura 2.7: LDR sistema sublineal.

Indicadores L_1, L_2, L_∞ . De forma similar, los indicadores L_1, L_2 y L_∞ permiten medir la desviación lineal. Sin embargo, los mismos no suelen utilizarse en el análisis de la proporcionalidad energética [Hsu and Poole, 2015].

$$L_\infty = \max_j |E_j|, \quad (2.11)$$

$$L_1 = \sum_j |E_j|, \quad (2.12)$$

$$L_2 = \sqrt{\sum_j |E_j|^2}, \quad (2.13)$$

siendo

$$E_j = \frac{P_j - P_E(l_j)}{P(1)}, \quad (2.14)$$

la diferencia en el j -ésimo nivel de carga de trabajo, del consumo de potencia del SUT con relación a su respectivo P_E , normalizada sobre P_{peak} . En caso de un sistema proporcionalmente energético, $\forall j E_j = 0$ y por consiguiente $L_\infty(P_E) = L_1(P_E) = L_2(P_E) = 0$.

2.2. Indicadores de eficiencia energética

FLOPS/W. En la actualidad, el indicador FLOPS/W tiene una gran aceptación en la comunidad de HPC. En este entorno, se suele considerar solamente el rendimiento y consumo de potencia en el estado *peak* (ecuación 2.15). Sin embargo, si bien estos servidores no suelen trabajar en niveles discretos de carga de trabajo, rara vez se desempeñan en tal porcentaje. Por lo que, resulta más acertado cuantificar la eficiencia energética a partir del rendimiento y consumo de potencia por nivel de carga de trabajo (ecuación 2.16).

$$\text{Eficiencia energética} = \frac{\text{Rendimiento}_{\text{peak}}}{\text{Potencia}_{\text{peak}}}. \quad (2.15)$$

$$\text{Eficiencia energética} = \frac{\sum_{j=0}^1 \text{Rendimiento}_j}{\sum_{j=0}^1 \text{Potencia}_j}. \quad (2.16)$$

No obstante, varias investigaciones consideran inadecuado el empleo de este indicador para el análisis energético de los servidores de HPC [Hsu et al., 2012]. Éstas, lo describen como un indicador volátil, cuyos resultados dependen de diferentes factores, tales como el tipo de operación, el nivel de carga de trabajo y el *benchmark* con que se evalúe el sistema.

Además, el indicador FLOPS/W describe dos estrategias para maximizar la eficiencia energética de los medios de cómputo, incrementar el rendimiento de los equipos o disminuir el consumo de potencia de los mismos. Por lo que, al tratarse de una métrica intensiva, no es conveniente su uso para clasificar sistemas de computadoras por tamaño, pues los servidores de supercómputo de menor tamaño tendrán mejores calificaciones [Strohmaier, 2009]. Ya que, como expresaron [Feng and Cameron, 2007], a medida que aumenta el número de nodos, aumenta a su vez el consumo de potencia (al menos linealmente), mientras que el rendimiento se incrementa, a lo sumo linealmente para problemas paralelos, y sublinealmente para los restantes problemas.

PUE. El indicador efectividad en el uso de energía (PUE) [Belady et al., 2008], cuantifica qué porción del consumo total de energía emplean los equipos de procesamiento, en contraposición a la energía que utilizan los sistemas de refrigeración y la infraestructura de energía.

$$PUE = \frac{\text{Energía total de instalación}}{\text{Energía de los medios de cómputo}}, \quad (2.17)$$

siendo la *Energía total de instalación* la energía que se consume en la instalación o centro de procesamiento en tareas afines con el mismo. Mientras que, la *Energía de los medios de cómputo* hace referencia a la energía que consumen los equipos computacionales para administrar, procesar o enrutar la información entrante.

PUE puede interpretarse como un indicador de proporcionalidad energética, pues tiene una estrecha relación con el principio de energía. Sin embargo, varios estudios plantean que *PUE* resulta insuficiente, pues sólo tiene en cuenta el uso relativo de energía. En consecuencia, un sistema energéticamente ineficiente, puede tener un valor de *PUE* excelente, si su infraestructura de soporte proporciona un enfriamiento efectivo [Hsu et al., 2012].

2.2.1. Otros indicadores

El consumo promedio de potencia es otro indicador de eficiencia energética comúnmente utilizado. Éste, se puede expresar a partir de las relaciones potencia-tiempo (W/s) y potencia-espacio (W/m^2). La primera, indica el consumo de potencia por unidad de tiempo, y se utiliza en las tecnologías Intel Turbo Boost y AMD Turbo Core en la aplicación de la técnica de DVFS. Mientras que la segunda, en conjunción con el indicador rendimiento-espacio ($FLOPS/m^2$), se emplea en el diseño de servidores y sistemas de refrigeración.

Los indicadores producto de retardo de energía (EDP) y producto cuadrado de retardo de energía (ED^2P), han sido utilizados históricamente para el análisis de la eficiencia energética de los medios de cómputo. El primero, se define como la energía total que se consume al ejecutar una unidad de trabajo, multiplicada por el tiempo de ejecución. Mientras que el segundo, consiste en la energía multiplicada por el cuadrado del tiempo de ejecución, por lo que da mayor relevancia al rendimiento del sistema [Stijn and Eeckhout, 2011].

El Diagrama de retardo de energía (EDD) [Stijn and Eeckhout, 2011], si bien no es un indicador de eficiencia energética, ilustra de forma intuitiva la relación rendimiento-consumo energético de un servidor con respecto a un sistema de referencia.

$$y = \log_2 \left(\frac{\text{Energía}_{prueba}}{\text{Energía}_{referencia}} \right). \quad (2.18)$$

$$x = \log_2 \left(\frac{\text{Tiempo}_{prueba}}{\text{Tiempo}_{referencia}} \right). \quad (2.19)$$

El primer cuadrante representa el caso en el que el sistema de referencia posee una mayor eficiencia energética (menor consumo energético y menor tiempo de ejecución) que el SUT, mientras que el tercer cuadrante ilustra el caso contrario. Por último, el segundo y cuarto cuadrante representan las compensaciones, y el origen del EDD representa al sistema de referencia (ver figura 2.8).

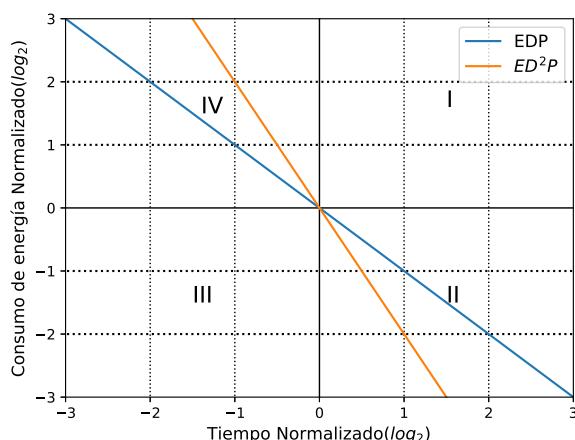


Figura 2.8: Diagrama de retardo de energía.

Entre las principales ventajas del EDD, destaca el hecho de que al hacer uso de los logaritmos de las razones de rendimiento y energía, es sencillo representar los indicadores EDP y ED^2P , por medio de líneas rectas. Por ejemplo, la primera de estas líneas (EDP), denota los puntos donde el SUT y el sistema de referencia son igualmente eficientes en términos energéticos, según este indicador. Lo mismo sucede con la línea que describe al indicador ED^2P .

2.3. Indicadores multivariados

Como señalan [Stijn and Eeckhout, 2011] y [Strohmaier, 2009], realizar el análisis energético de un sistema de cómputo a partir de una única métrica puede resultar engañoso. En consecuencia, en los últimos años se han utilizado técnicas de estadística multivariante, con el objetivo de definir un indicador compuesto que posibilite dicho análisis.

La métrica de utilidad (UM) [Strohmaier, 2009], fue propuesta como un indicador generalizado, a partir del cual realizar el análisis energético de las supercomputadoras (SC).

$$UM(SC) = P^\alpha \cdot \left(\frac{P}{Peak} \right)^\beta \cdot \left(\frac{M}{Peak} \right)^\gamma \cdot \left(\frac{Peak}{Power} \right)^\delta \cdot \left(\frac{Peak}{Space} \right)^\epsilon, \quad (2.20)$$

siendo P el rendimiento sostenido alcanzado, M la cantidad de memoria utilizada, $Power$ la potencia consumida, $Space$ el espacio físico consumido por el sistema y $Peak$ el rendimiento máximo alcanzado. Además, las ponderaciones se distribuyen de forma tal, que $\alpha, \beta, \gamma, \delta, \epsilon \geq 0$ y $\beta + \gamma = \delta + \epsilon$.

Asimismo, [Hsu et al., 2012] definieron un indicador multivariado ponderado a partir del rendimiento y el índice de eficiencia energética FLOPS/W.

$$(rendimiento)^\alpha \cdot (eficiencia\ energética)^\beta. \quad (2.21)$$

En el diseño de este indicador, Hsu et al., dieron igual relevancia al rendimiento y la eficiencia energética, es decir $\alpha = \beta$. Además, definieron un conjunto de propiedades deseables para una métrica de eficiencia energética, entre las cuales se requiere, que no exista un límite superior, capture la proporcionalidad energética de un sistema y no sea sesgado. En adelante, este indicador se referenciará en el documento a través de las siglas REE .

De manera general, ambos indicadores hacen uso del mismo principio de construcción. Éste, consiste en la multiplicación de las características deseadas, tales como el rendimiento y la eficiencia energética; y la división de estas últimas por las características indeseadas, como son el consumo de potencia y el tamaño. Sin embargo, existen diferentes estrategias de agregación y ponderación, cuya aplicación depende de factores, tales como el objetivo del indicador y la escala de las variables.

BENCHMARKS Y DATASETS

La recolección de los datos a analizar es la primera etapa del proceso de Extracción de Conocimiento de Bases de Datos (KDD)⁵. La misma, está sujeta a los objetivos de la investigación, y determina en gran medida la calidad de los resultados a obtener. Así pues, en el presente capítulo se describen las características principales, ventajas y desventajas de varios *benchmarks* y conjuntos de datos, a fin de identificar los que resulten más apropiados para el análisis energético de los servidores de HPC.

SPECpower_ssj2008. SPECpower_ssj2008 es un *benchmark* desarrollado por la Corporación de Evaluación de Desempeño Estándar (SPEC), con el objetivo de examinar el rendimiento y consumo de potencia de uno o múltiples nodos, a través de un enfoque gradual de carga de trabajo. El mismo, consiste en una aplicación Java, que en una primera etapa genera y completa una combinación de transacciones, y posteriormente, mide el rendimiento del sistema, a partir del número de transacciones por segundo (TPS) que se realizan durante un período fijo de tiempo. Además, cuantifica la eficiencia energética en los distintos niveles de utilización en términos de transacciones por segundo por watt. También, utiliza la eficiencia energética general como puntaje (*SCR*) del sistema:

$$SCR = \frac{\sum_{i=1}^n rendimiento_i}{\sum_{i=1}^n potencia_i}, \quad (3.1)$$

siendo $n = 11$ los niveles de carga de trabajo. A diferencia de otros *benchmarks*, SPECpower_ssj2008 gradúa la carga de trabajo desde el estado *idle* hasta el *peak*, de forma tal, que en cada iteración, incrementa ésta en un 10 %.

SPECpower_ssj2008 hace uso de las unidades centrales de procesamiento, cachés, jerarquía de memoria y escalabilidad de la memoria compartida. También, cuenta con una fase de calibración, en la cual, se determina el rendimiento máximo y el número de transacciones a realizar en cada uno de los niveles de carga de trabajo. Además, analiza las características asociadas a la memoria de acceso aleatorio (RAM), el número de nodos, el chasis, el sistema operativo, entre otros componentes de *hardware* y *software*.

⁵KDD se define como el proceso no trivial de identificar patrones válidos, novedosos, potencialmente útiles y, en última instancia, comprensibles en los datos [Kudo and Sklansky, 2000].

Por otra parte, SPECpower_ssj2008 no considera el número de FLOPS, por lo que carece de un enfoque de HPC [Lange, 2009]. Razón por la cual, SPEC desarrolló los *benchmarks* SPEC MPI 2007 y SPEC OMP 2012, los cuales sí contemplan la cantidad de FLOPS. Sin embargo, a diferencia de SPECpower_ssj2008, ambos *benchmarks* carecen de un enfoque gradual de carga de trabajo, puesto que el rendimiento y el consumo energético se evalúan únicamente en el máximo nivel de utilización.

SPEC OMP 2012. El *benchmark* SPEC OMP 2012 mide el rendimiento de los sistemas a partir de aplicaciones basadas en el estándar OpenMP. Éste, se enfoca en las características asociadas al procesador, la memoria, el compilador y las bibliotecas de soporte paralelo. Además, se compone de otros 14 *benchmarks* (ver tabla 3.1), para cada uno de los cuales ejecuta seis pruebas, distribuidas equitativamente, utilizando las optimizaciones conservadora y agresiva de los mismos. De manera general, el proceder en cada uno de los 14 *benchmarks* es el siguiente:

1. Agrupar las pruebas a partir del tipo de optimización del *benchmark* que utiliza.
2. Normalizar el rendimiento y consumo de potencia alcanzado en cada una de las pruebas, con respecto al descrito por el sistema de referencia⁶ en iguales condiciones, es decir, bajo el mismo tipo de optimización.

$$SPECompG_base2012 = \frac{Rendimiento_base_{prueba}}{Rendimiento_base_{referencia}}, \quad (3.2)$$

$$SPECompG_peak2012 = \frac{Rendimiento_peak_{prueba}}{Rendimiento_peak_{referencia}}, \quad (3.3)$$

$$SPECompG_energy_base2012 = \frac{Energía_base_{prueba}}{Energía_base_{referencia}}, \quad (3.4)$$

$$SPECompG_energy_peak2012 = \frac{Energía_peak_{prueba}}{Energía_peak_{referencia}}, \quad (3.5)$$

siendo *base* y *peak* los tipos de optimizaciones conservadora y agresiva respectivamente.

3. Calcular la mediana de las proporciones obtenidas en cada grupo.
4. Por último, los resultados arrojados por SPEC OMP 2012 consisten en la media geométrica de las 14 proporciones de cada tipo de optimización, tanto en términos de rendimiento como de consumo de potencia.

⁶El *benchmark* SPEC OMP 2012 desde el año 2008 utiliza como sistema de referencia el Sun Fire X4140, el cual consta de un procesador AMD Opteron 2384 con una frecuencia de reloj de 2.7 GHz, 2 quad-core y 32 GB de memoria RAM.

Benchmark	Lenguaje	Dominio de aplicación
350.md	Fortran	Física: Dinámica Molecular
351.bwaves	Fortran	Física: Dinámica de Fluidos Computacional (CFD)
352.nab	C	Modelado Molecular
357.bt331	Fortran	Física: Dinámica de Fluidos Computacional (CFD)
358.botsalgn	C	Alineación de Proteínas
359.botsspar	C	Factorización LU
360.ilbdc	Fortran	Lattice Boltzmann
362.fma3d	Fortran	Simulación de Respuesta Mecánica
363.swim	Fortran	Predicción del Clima
367.imagick	C	Procesamiento de Imágenes
370.mgrid331	Fortran	Física: Dinámica de Fluidos Computacional (CFD)
371.applu331	Fortran	Física: Dinámica de Fluidos Computacional (CFD)
372.smithwa	C	Coincidencia Óptima de Patrones
376.kdtree	C++	Ordenamiento y Búsqueda

Tabla 3.1: Conjunto de puntos de referencias que integran el *benchmark* SPEC OMP 2012.

SPEC MPI 2007. El *benchmark* SPEC MPI 2007 cuantifica el rendimiento de los sistemas a partir de la interfaz de paso de mensajes (MPI). Éste, enfatiza en las características asociadas al procesador, la biblioteca MPI, la arquitectura de memoria, los compiladores y el sistema de archivos. Sin embargo, descarta características como el sistema operativo, los aceleradores gráficos y el sistema de entrada/salida. De manera general, SPEC MPI 2007 hace uso de la misma estrategia de estimación de rendimiento y consumo energético que SPEC OMP 2012; siendo el sistema de referencia⁷ y los *benchmarks* que integran la *suite* (ver tabla 3.2) los principales elementos de diferenciación.

Benchmark	Lenguaje	Dominio de aplicación
104.milc	C	Física: Cromodinámica Cuántica (QCD)
107.leslie3d	Fortran	Dinámica de Fluidos Computacional (CFD)
113.GemsFDTD	Fortran	Electromagnetismo Computacional (CEM)
115.fds4	C/Fortran	Dinámica de Fluidos Computacional (CFD)
121.pop2	C/Fortran	Modelado de Océanos
122.tachyon	C	Gráficos: Trazado de Rayos Paralelos
125.RaxML	C	Coincidencia de ADN
126.lammps	C++	Simulación de Dinámica Molecular
127.wrf2	C/Fortran	Predicción del Clima
128.GAPgeomfem	C/Fortran	Transferencia de Calor mediante Métodos de Elementos Finitos (FEM)
129.tera_tf	Fortran	Hidrodinámica Euleriana 3D
130.socorro	C/Fortran	Dinámica Molecular utilizando la Teoría Funcional de la Densidad (DFT)
132.zeusmp2	C/Fortran	Física: Dinámica de Fluidos Computacional (CFD)
137.lu	Fortran	Dinámica de Fluidos Computacional (CFD)
142.dmilc	C	Física: Cromodinámica Cuántica (QCD)
143.dleslie	Fortran	Dinámica de Fluidos Computacional (CFD)
145.lGemsFDTD	Fortran	Electromagnetismo Computacional (CEM)
147.l2wrf2	C/Fortran	Predicción del Clima

Tabla 3.2: Conjunto de puntos de referencias que integran el *benchmark* SPEC MPI 2007.

⁷SPEC MPI 2007 utiliza como sistema de referencia un clúster de 8 nodos de un sistema Celestica A2210, con un procesador AMD Opteron 848 de un solo núcleo, con una frecuencia de reloj de 2200 MHz, 1 MB de caché L_2 y 4 GB de memoria RAM DDR3 por *socket*.

Linpack. El *benchmark* Linpack, examina el rendimiento de los sistemas al resolver un problema general de matriz densa $Ax = b$, así pues, se caracteriza fundamentalmente por un uso intensivo de los FLOPS. A grandes rasgos, el mismo consiste en descomponer una matriz en el producto de matrices simples y bien formadas [Dongarra et al., 2003], por lo que requiere $\Theta(n^3)$ operaciones de punto flotante, específicamente $\frac{2}{3}n^3 + 2n^2$, siendo n el orden de la matriz. Además, éste, a su vez, se compone de otros tres *benchmarks*, asociados a problemas de orden 100, 1000 y un tercero de computación altamente paralela, también conocido como *High Performance Linpack* o HPLinpack.

A continuación, se describen los *benchmarks* antes mencionados:

- Linpack 100 es similar al sistema de referencia original publicado en 1979. El mismo, consiste en la eliminación gaussiana con pivote parcial.
- Linpack 1000 brinda un rendimiento más cercano a los límites del sistema, al proporcionar un problema de mayor tamaño. Sin embargo, tiene como limitante que no es posible reducir la precisión relativa.
- HPLinpack, resulta adecuado para la evaluación de servidores de HPC, al permitir el incremento del orden tanto como sea necesario. Sin embargo, no es acertado en el mismo el uso del algoritmo Strassen, pues distorsiona la tasa de ejecución.

Gradiente conjugado de alto rendimiento. El *benchmark* de Gradiente Conjugado de Alto Rendimiento (HPCG) es un punto de referencia de supercómputo, cuyo objetivo es modelar los patrones de acceso a datos de los sistemas, y evaluar el efecto de las limitaciones del subsistema de memoria. Éste, se caracteriza por una menor intensidad aritmética y una mayor precisión de memoria, lo que lo hace apropiado para la evaluación de servidores de centros de datos [Ruiz et al., 2018]. Además, complementa el análisis de *benchmarks* como Linpack, que no enfatizan en la interconexión interna.

HPCG resuelve un sistema lineal disperso de ecuaciones mediante el método de gradiente conjugado. También, utiliza un preacondicionador aditivo de Schwarz en la descomposición del primer dominio, mientras que cada subdominio se preacondiciona a través de un barrido simétrico de Gauss-Seidel [Dongarra et al., 2013]. HPCG es más “realista” que Linpack, ya que tiene una menor intensidad aritmética que este último, por lo que, sistemas con un alto rendimiento en Linpack, no necesariamente poseen un buen rendimiento en HPCG.

Top500 & Green500. El Top500 es el *ranking* de las 500 supercomputadoras disponibles comercialmente de mayor rendimiento. En éste, los sistemas se ordenan de forma descendente, a partir del número de FLOPS que son capaces de procesar. Dicho rendimiento, se obtiene como resultado de la evaluación del *benchmark* Linpack en cada uno de los sistemas. Además, este conjunto de datos brinda una perspectiva en términos de HPC, al proporcionar los resultados obtenidos de la evaluación del *benchmark* HPCG. Sin embargo, el Consejo de Asesores de Ciencia y Tecnología y Jack Dongarra, fundador del propio listado, destacaron la necesidad de analizar el *ranking* desde un contexto más amplio, pues no solo debía considerarse el número de FLOPS [Geller, 2011], lo que dio paso al surgimiento del Green500.

El Green500, surgió con el objetivo de concientizar acerca del consumo energético que llevan a cabo las supercomputadoras. Por lo cual, se creó un *ranking* a partir de la eficiencia energética de los sistemas que conforman el Top500. Sin embargo, ambos conjuntos de datos carecen de un enfoque gradual de carga de trabajo, pues solamente se analizan el rendimiento, consumo de potencia y eficiencia energética al máximo nivel de utilización, lo que imposibilita un estudio profundo de la proporcionalidad y eficiencia energética.

Por lo tanto, de los *benchmarks* antes expuestos, sólo SPECpower_ssj2008 posee un enfoque gradual de carga de trabajo. Éste, es un *benchmark* apropiado para el análisis energético de los servidores de centros de datos. Sin embargo, al carecer de un enfoque de HPC, resulta desacertado su empleo para el estudio de la proporcionalidad energética de tales sistemas. Por otra parte, los restantes *benchmarks* estudiados, si bien tienen en cuenta los FLOPS, y estresan en mayor o menor medida a los sistemas, no analizan el consumo de potencia por nivel de utilización, por lo que son también insuficientes para el análisis energético de los servidores de HPC (ver tabla 3.3).

<i>Benchmark</i>	Enfoque			Tipo de operación	
	Gradual de carga de trabajo	Centro de datos	HPC	MIPS/TPS	FLOPS
SPECpower_ssj2008	Sí	Sí	No	Sí	No
SPEC OMP 2012	No	No	Sí	No	Sí
SPEC MPI 2007	No	No	Sí	No	Sí
Linpack	No	No	Sí	No	Sí
HPCG	No	No	Sí	No	Sí

Tabla 3.3: Comparación de los *benchmarks* de rendimiento y consumo de potencia.

Como resultado del análisis anterior, se concluyó que se carece de un conjunto de datos general, a partir del que realizar el análisis de proporcionalidad energética en servidores de HPC. Por lo que, el estudio a desarrollar, debe sustentarse en la información existente en los conjuntos de datos de SPECpower_ssj2008, Green500 y Top500, los que se describen con detalle en el apéndice A.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

ANÁLISIS DE MINERÍA DE DATOS

La minería de datos es una etapa intermedia del KDD. Ésta, consiste en la aplicación de técnicas computacionales de diferentes disciplinas, tales como optimización, cómputo evolutivo y teoría de la información, a fin de extraer conocimiento procesable de conjuntos de datos. En el presente capítulo, se detalla el análisis descriptivo y exploratorio realizado en función del rendimiento y consumo energético de los servidores de HPC.

4.1. Análisis descriptivo

El desarrollo de un indicador multivariado, requiere de la selección de los índices más adecuados para explicar el fenómeno de interés, y el análisis de sus tendencias y relaciones. Ésto, a fin de dotar de sencillez y robustez al modelo, al descartar variables redundantes o resultantes de combinaciones de otras. Asimismo, posibilita la inferencia del futuro comportamiento del indicador compuesto y los subíndices que lo integran. En la presente sección, se analizan varias de las tendencias actuales del diseño de servidores de HPC.

4.1.1. Distribución

La distribución de las variables, es una de las características más importantes a considerar durante el desarrollo de una investigación, ya que condiciona las tareas a realizar. La distribución es un resumen de la frecuencia de valores individuales o rangos de valores para una variable. La forma en que se distribuyen las variables es de vital relevancia, tanto en el aspecto cuantitativo como cualitativo.

Existen diversas estrategias para determinar la bondad de ajuste de dos distribuciones de probabilidad entre sí, tales como la prueba de Kolmogorov-Smirnov [Smirnov, 1939], el test de Shapiro-Wilk [Shapiro and Wilk, 1965] y la prueba de Anderson-Darling [Stephens, 1974]. De forma similar, el criterio de información bayesiano [Schwarz, 1978] y el criterio de información de Akaike [Akaike, 1998] son de gran utilidad en este sentido. Si bien, muchas de las técnicas anteriores persiguen diferentes objetivos, todas ellas pueden utilizarse para la selección de la distribución que mejor se ajuste a los datos. Las tablas 4.1 y 4.2 resumen la distribución de las principales variables que componen los conjuntos de datos de SPECpower_ssj2008 y Top500, identificadas a partir de la prueba de Kolmogorov-Smirnov.

Variable	Distribución
Nodes	Generalizada de valores extremos
ssj_ops @ 100 % of target load	Gaussiana inversa
Average watts @ 100 % of target load	Generalizada de valores extremos
Performance/power @ 100 % of target load	Distribución de Pearson
# Cores	Gaussiana inversa
# Chips	Generalizada de valores extremos
# Threads Per Core	Distribución de Pearson
Processor MHz	Normal logarítmica
Memory (GB)	Normal logarítmica
Power Supplies Installed	Normal
Power Supply Rating (watts)	Normal

Tabla 4.1: SPECpower_ssj2008: Distribución de las principales variables.

Variable	Distribución
Total Cores	Normal logarítmica
Accelerator/Co-Processor Cores	Normal
Rmax [TFlop/s]	Pareto
Rpeak [TFlop/s]	Normal logarítmica
Power (kW)	Weibull exponencial
Power Efficiency [GFlops/Watts]	Generalizada de valores extremos
Processor Speed (MHz)	Normal
Cores per Socket	Generalizada de valores extremos

Tabla 4.2: Top500: Distribución de las principales variables.

4.1.2. Tendencias y Relaciones

Varios estudios señalan la existencia de una estrecha relación entre el consumo de potencia y la proporcionalidad energética de los medios de cómputo. Barroso y Hölzle destacaron cómo el incremento de la proporcionalidad energética requiere de futuras mejoras en términos del consumo de potencia [Barroso and Hölzle, 2007]. Sin embargo, [Wong and Annavaram, 2013] demostraron que no en todos los casos la proporcionalidad energética mejora la gestión de energía de los servidores. Aún así, los diseñadores de sistemas computacionales exploran múltiples estrategias de gestión de energía⁸, con el objetivo de minimizar el consumo de potencia y maximizar la proporcionalidad energética de sus productos.

La figura 4.1 ilustra la tendencia creciente de los sistemas en términos de DR y EP . Ésto, como consecuencia de un menor desperdicio de la potencia máxima en el estado ocioso, y la disminución de la brecha energética con respecto a un sistema ideal P_E . En la misma, se observa un incremento abrupto de ambos indicadores a partir del año 2009, el cual varios autores asocian con el empleo del DVFS en la gestión de energía [Hsu and Poole, 2013].

⁸Históricamente han habido tres direcciones para el ahorro de energía: suspender o apagar sistemas, DVFS y la gestión de cargas de trabajo conscientes de la energía.

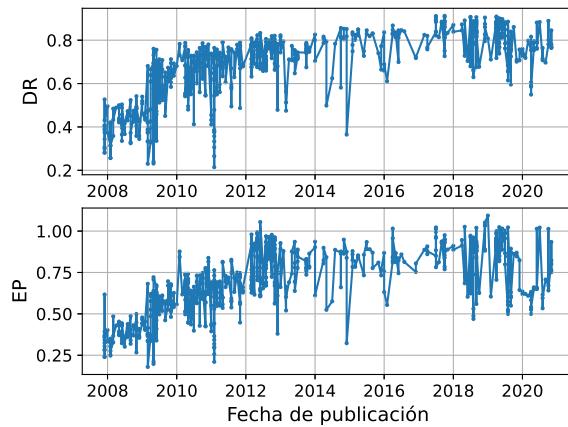


Figura 4.1: SPECpower_ssj2008: Curvas de tendencia de los indicadores DR y EP .

Al analizar la curva de tendencia del indicador EP , destaca la presencia de servidores, en los cuales, este indicador supera el límite definido en la bibliografía. Esta investigación no es ajena a la existencia de servidores con $EP > 1$, en adelante, sistemas *superproporcionales*, ya que [Jiang et al., 2017] así lo constataron. No obstante, Jiang et al., no exploraron las causas de estos valores atípicos, lo cual, da paso a las siguientes interrogantes:

Interrogante 1. *¿Qué factores condicionan este carácter superproporcional?*

Interrogante 2. *¿En qué medida dicho comportamiento se debe al empleo del DVFS?*

Esta segunda interrogante posee gran relevancia, pues [Le Sueur and Heiser, 2010] plantearon que el DVFS, si bien es apropiado para la gestión de potencia en arquitecturas antiguas, no resulta así en arquitecturas modernas, en las que incrementa el consumo energético.

Por otra parte, al analizar el comportamiento histórico de los sistemas en concepto de linealidad, destaca el descenso de la misma, tanto en términos generales como específicos, es decir, el incremento de la LD y LDR de los sistemas (ver figura 4.2). Ésto, corrobora el pronóstico que realizaron [Varsamopoulos and Gupta, 2010], referente al futuro aumento de la desviación lineal y la disminución de la IPR de los sistemas.

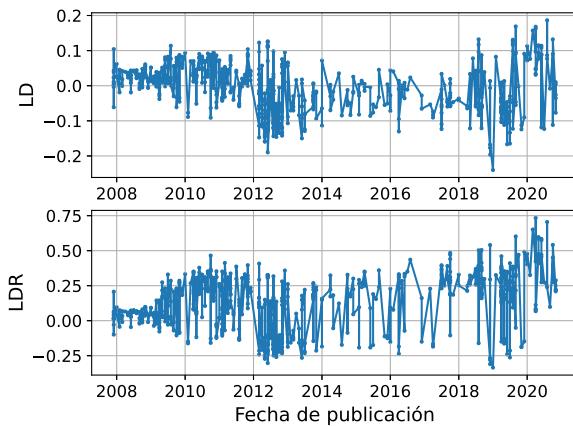


Figura 4.2: SPECpower_ssj2008: Curvas de tendencia de los indicadores LD y LDR .

La figura 4.3 ilustra la relación existente entre los indicadores LDR , IPR y EP . En la misma, se observa cómo a medida que aumenta la EP , disminuye la IPR y se incrementa la LDR . Es decir, los sistemas de menor desviación lineal son los que mayor porción de la potencia máxima desperdician en estado *idle*. Además, muestra la alta desviación lineal que caracteriza a los sistemas superproporcionales, y cuán ineficiente es el indicador EP para capturar la linealidad de un sistema.

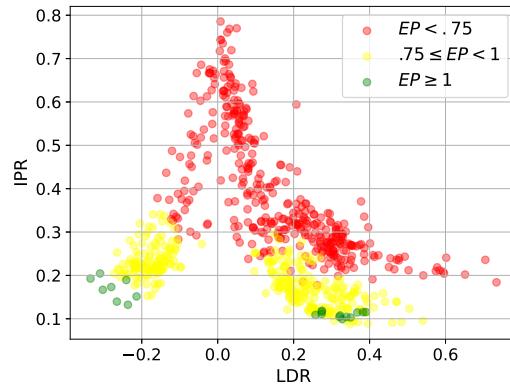


Figura 4.3: SPECpower_ssj2008: Gráfica de dispersión de los indicadores LDR e IPR .

No obstante, EP es uno de los indicadores de mayor aceptación y empleo en el análisis energético de los sistemas de computadora. Razón por la cual, se han definido varias aproximaciones en torno al mismo. Por ejemplo, [Wong and Annavaram, 2013] y [Hsu and Poole, 2015] destacaron la estrecha relación existente entre los indicadores EP , DR y LD , de forma tal, que:

$$EP \approx 2 - (2 - DR)(LD + 1). \quad (4.1)$$

Esta aproximación, propone dos estrategias para la maximización de la EP , el incremento del DR o la disminución de la LD . Sin embargo, teniendo en cuenta las curvas de tendencia de ambos indicadores, resulta más adecuado el empleo de la segunda estrategia, pues los sistemas actuales suelen poseer un DR cada vez más cercano a su límite teórico. La figura 4.4 ilustra la validez de esta aproximación, y cómo en las últimas décadas, el margen de error de dicha aproximación ha estado parcialmente estancado.

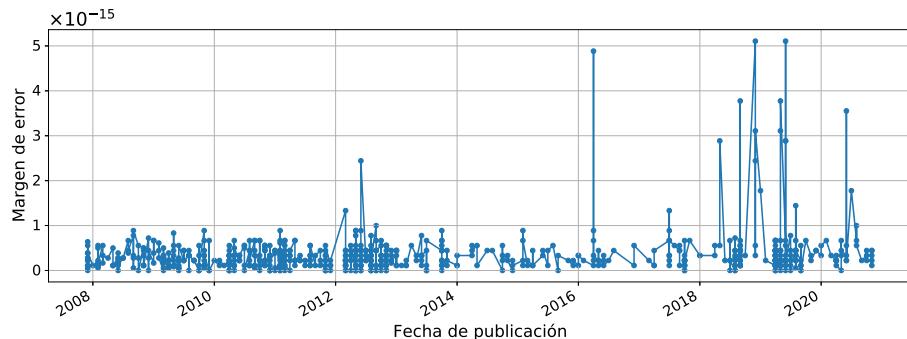


Figura 4.4: SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador EP en términos de los indicadores DR y LD .

De igual forma, [Hsu and Poole, 2015] definieron una aproximación del indicador EP en términos del indicador L_1 .

$$EP \approx 1 - \frac{2L_1}{m - 1}. \quad (4.2)$$

siendo m el número de niveles de carga de trabajo. Además, consideraron la alta correlación existente entre los indicadores L_1 , L_2 y L_∞ . Para los cuales, en la actualidad, la similitud entre sus respectivas curvas de tendencia, en cuanto al coeficiente de correlación de Pearson⁹, es al menos 0.97, y específicamente 0.99 para los indicadores L_1 y L_2 .

Como resultado de la evaluación de esta aproximación, se obtuvo un margen de error significativo, por lo que la misma carece de vigencia (ver figura 4.5). Además, destaca cómo a partir del año 2012 se incrementa el margen de error de esta aproximación, año a partir del cual también la EP de los sistemas no suele variar considerablemente.

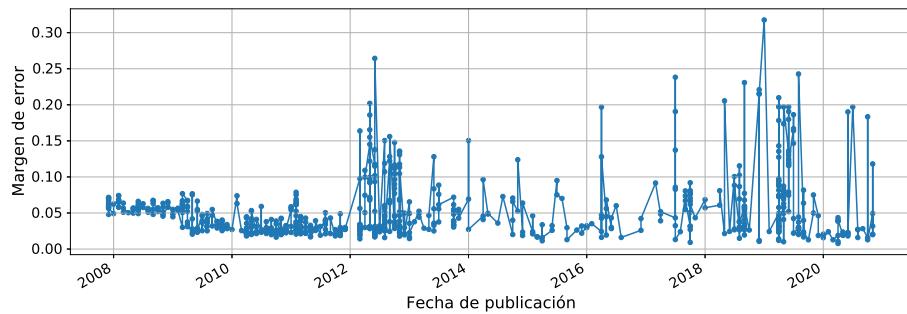


Figura 4.5: SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador EP a partir del indicador L_1 .

Asimismo, con base a la tendencia creciente de la EP y la eficiencia energética de los sistemas, [Hsu and Poole, 2015] definieron la siguiente relación:

$$SCR \approx \left(\frac{\tau_{10}}{P_{10}} \right) \left(\frac{1.1}{2.1 - EP} \right), \quad (4.3)$$

siendo τ_{10} y P_{10} el rendimiento y el consumo de potencia al 100 % de carga de trabajo respectivamente.

Esta aproximación define dos estrategias para el incremento de la eficiencia energética promedio, ya sea a partir del aumento de la EP o la relación rendimiento-potencia en el estado *peak*. Ya que, la EP de los sistemas desde el año 2012 ha estado parcialmente estancada, gran parte de las mejoras en términos de SCR se debe al empleo de la segunda estrategia, es decir, el incremento de la eficiencia energética en el 100 % de utilización (ver figura 4.6).

⁹El coeficiente de correlación de Pearson mide la fortaleza de la relación lineal entre dos variables.

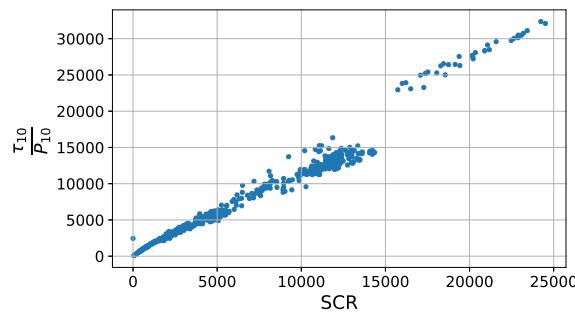


Figura 4.6: SPECpower_ssj2008: Gráfica de dispersión del SCR y $\frac{\tau_{10}}{P_{10}}$.

La figura 4.7 ilustra la relación existente entre el indicador EP y la eficiencia energética. Como se observa, los sistemas superproporcionales poseen valores promedio de SCR y $\frac{\tau_{10}}{P_{10}}$. Lo que reafirma el enunciado de [Varsamopoulos et al., 2010] referente a que no en todos los casos la proporcionalidad energética mejora la gestión de energía.

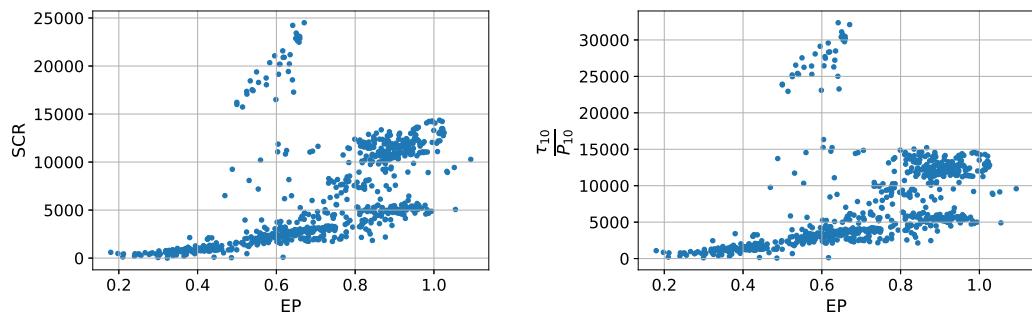


Figura 4.7: SPECpower_ssj2008: Gráficas de dispersión de los indicadores EP , SCR y $\frac{\tau_{10}}{P_{10}}$.

Al evaluar dicha relación se obtuvo un importante margen de error, por lo que no es conveniente el empleo de la misma como aproximación al SCR (ver figura 4.8). También, al igual que en la aproximación 4.2, el margen de error se incrementa a partir del año 2012. En este caso, dicho incremento se debe al aumento de la eficiencia energética en el estado *peak*.

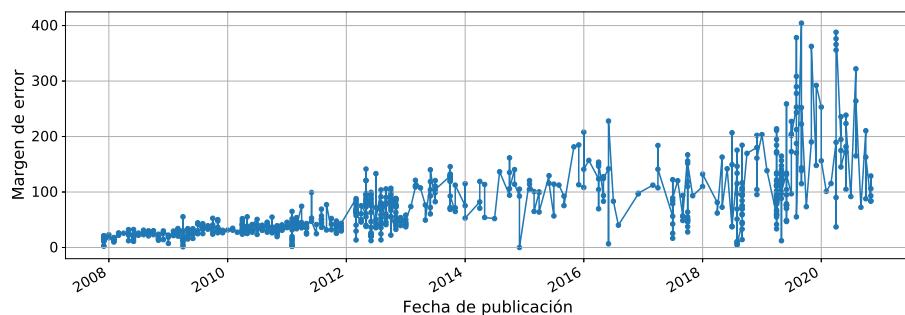


Figura 4.8: SPECpower_ssj2008: Curva de tendencia del margen de error de la aproximación del indicador SCR a partir de los indicadores EP y $\frac{\tau_{10}}{P_{10}}$.

Al analizar el consumo de potencia y la eficiencia energética por nivel de utilización, destaca cómo en el caso del primero, los sistemas de mayor DR y EP se suelen intersecciar con su ideal en niveles discretos de carga de trabajo (ver figura 4.9). De forma tal, que mientras más cercano al estado *idle* es la intersección, mayor tienden a ser los valores de estos indicadores. No obstante, ésto no es del todo absoluto, ya que las curvas de potencia de los SUT y sus respectivos sistemas de referencia pueden intersectarse en más de una ocasión. Además, en este sentido, resulta más importante la brecha de potencia, que el número de niveles de carga, en los cuales el consumo de potencia describió un comportamiento sublineal.

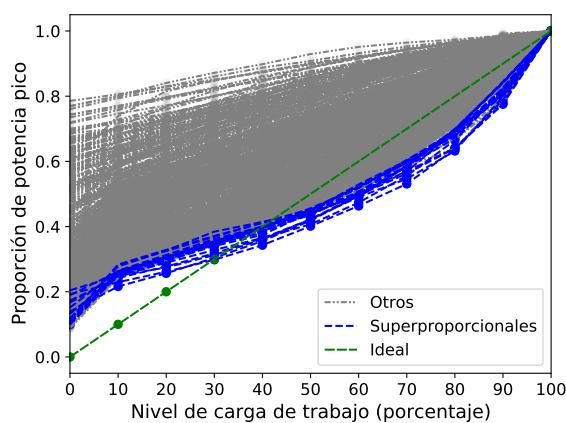


Figura 4.9: SPECpower_ssj2008:
Consumo de potencia por nivel de carga.

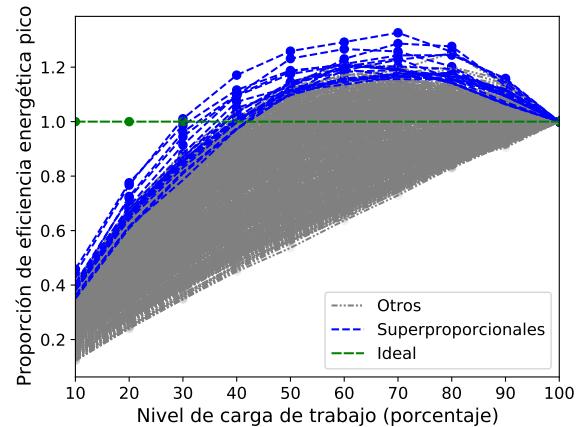


Figura 4.10: SPECpower_ssj2008: Eficiencia energética por nivel de carga.

Asimismo, la figura 4.10 muestra cómo varios sistemas alcanzan su máxima eficiencia energética en niveles de carga intermedios. Las cuales, incluso sobrepasan los límites definidos en el estado *peak*. De acuerdo con [Jiang et al., 2017], la anchura de estas zonas de alta eficiencia energética es superior en los sistemas de mayor EP . Sin embargo, la anterior afirmación es discutible, ya que, durante el análisis descriptivo realizado, se identificó una modesta relación entre estos indicadores. Además, la figura 4.11 refuta dicho planteamiento; en ésta, el sistema de menor EP posee una mayor zona de eficiencia energética.

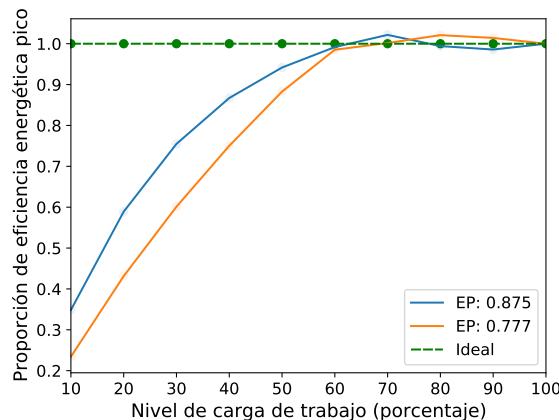


Figura 4.11: SPECpower_ssj2008: Relación entre la EP y la amplitud de las zonas de alta eficiencia energética.

Por lo tanto, se concluye que no existe un vínculo estrecho entre la proporcionalidad y la eficiencia energética de los medios de cómputo. No obstante, el aprovisionamiento de los servidores, debe enfocarse en las zonas de alta eficiencia energética. Entonces, a fin de maximizar estas zonas, es importante analizar el impacto de diferentes configuraciones de *hardware* y *software*, en función de la proporcionalidad y eficiencia energética de los sistemas.

4.1.3. Análisis de características

4.1.3.1. Procesador

El rendimiento de los servidores se suele asociar con el número y características de los procesadores que lo componen. Motivo por el cual, a continuación se analizan varias de estas características y su impacto en términos de proporcionalidad y eficiencia energética.

Frecuencia base. La frecuencia base es el número de ciclos de reloj por segundo, es decir, el número de instrucciones por segundo que la unidad central de procesamiento (CPU) es capaz de recuperar e interpretar. Los servidores actuales poseen una elevada frecuencia base; sin embargo, cada vez se dificulta más el incremento de la misma (ver figura 4.12), como resultado del incumplimiento de la ley de Moore¹⁰. En consecuencia, los diseñadores de *hardware* adoptaron como alternativa el incremento del número de núcleos por procesador, siendo ésta una tendencia en ascenso (ver figura 4.13).

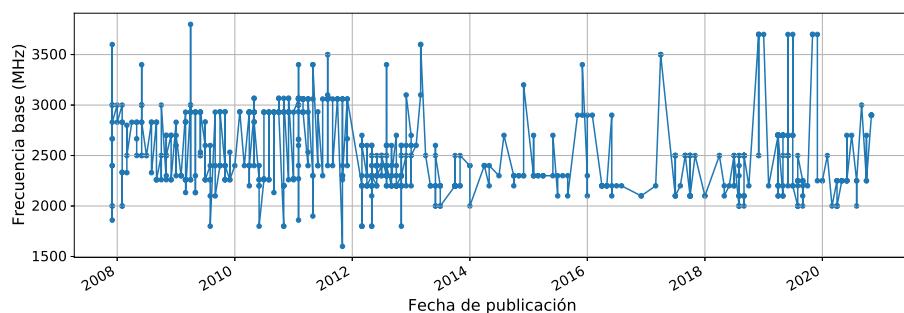


Figura 4.12: SPECpower_ssj2008: Curva de tendencia de la frecuencia base del procesador.

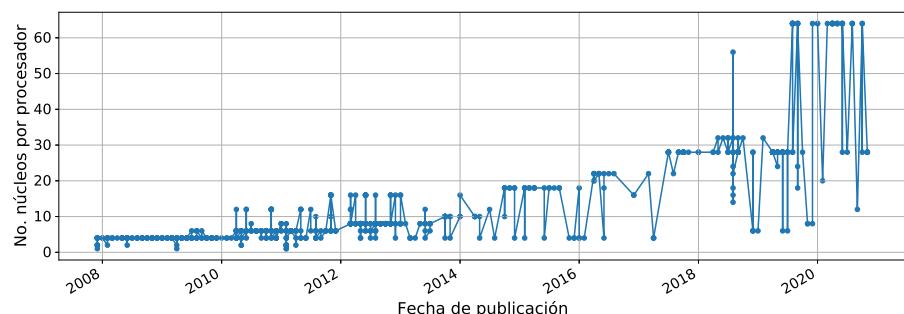


Figura 4.13: SPECpower_ssj2008: Curva de tendencia del número de núcleos por procesador.

¹⁰La ley de Moore plantea que aproximadamente, cada dos años se duplica el número de transistores en un microprocesador [Powell, 2008]. Sin embargo, ésta dejó de cumplirse desde la primera década del siglo XXI, a causa del incremento del consumo de potencia de los procesadores.

No obstante, cada núcleo suele consumir una cantidad de potencia nada despreciable. Por lo que, el número de núcleos a integrar en un mismo procesador está en función del consumo de potencia de este último, al estar el sistema en estado *peak*, es decir, todos los núcleos activos [Woo and Lee, 2008]. De ahí que, maximizar la eficiencia energética de los núcleos de forma individual, es uno de los principales desafíos de los arquitectos de *hardware*.

Al analizar el conjunto de datos de SPECpower_ssj2008, destaca el poco impacto que tiene la frecuencia base del procesador en términos de rendimiento, consumo de potencia, proporcionalidad y eficiencia energética. Además, en concordancia con lo expuesto por la ley de Amdahl (ecuación 4.4)¹¹, el número de procesadores y el total de núcleos existentes en el sistema condicionan de forma significativa el rendimiento de éste. Asimismo, la eficiencia energética de los núcleos presentes por procesador es un elemento determinante en la eficiencia del servidor.

$$Perf = \frac{1}{(1 - f) + \frac{f}{n}}, \quad (4.4)$$

donde n es el número de procesadores y $0 \leq f \leq 1$ es la porción del programa que se puede paralelizar.

DVFS. En el conjunto de datos de SPECpower_ssj2008 existen un total de 20 servidores superproporcionales; todos los cuales, poseen procesadores que hacen uso del DVFS. Sin embargo, si bien los sistemas con elevados valores de *EP* suelen contar con procesadores que aplican esta estrategia de gestión de energía, ésto se debe principalmente a las actuales tendencias de diseño de *hardware*, y no a la existencia de una relación entre el DVFS y la proporcionalidad energética de los sistemas. Por lo que, en respuesta a la interrogante número 2, el DVFS no garantiza la proporcionalidad energética de un sistema, ni el carácter superproporcional del mismo (ver tabla 4.3).

Procesador	Frecuencia (GHz)		No. servidores		EP	
	Base	Aumentada	Total	Superproporcional	Min	Max
Intel Xeon Platinum 8280L	2.70	4.00	8	3	0.920	1.023
Intel Xeon E-2176G	3.70	4.70	6	5	0.985	1.093
Intel Xeon Platinum 8180	2.50	3.80	53	5	0.875	1.022
Intel Xeon Platinum 8176	2.10	3.80	20	2	0.769	1.025
Intel Xeon E5-2698 v4	2.20	3.60	2	1	0.956	1.015
Intel Xeon E5-2470	2.30	3.10	26	1	0.774	1.054
Intel Xeon Platinum 8280	2.70	4.00	57	3	0.705	1.023

Tabla 4.3: Listado de procesadores presentes en los servidores superproporcionales.

En la actualidad, la mayoría de los procesadores modernos hacen uso del DVFS. Los que, en comparación con el resto, suelen alcanzar valores superiores de rendimiento, eficiencia energética y consumo de potencia (ver figura 4.14). No obstante, la tendencia decreciente del voltaje de operación de los núcleos reduce la posibilidad de escalar el voltaje, y por ende, decrementar la frecuencia del CPU y el consumo de energía.

¹¹La ley de Amdahl plantea que el cálculo secuencial de un programa limita en gran medida la máxima aceleración alcanzable [Amdahl, 1967].

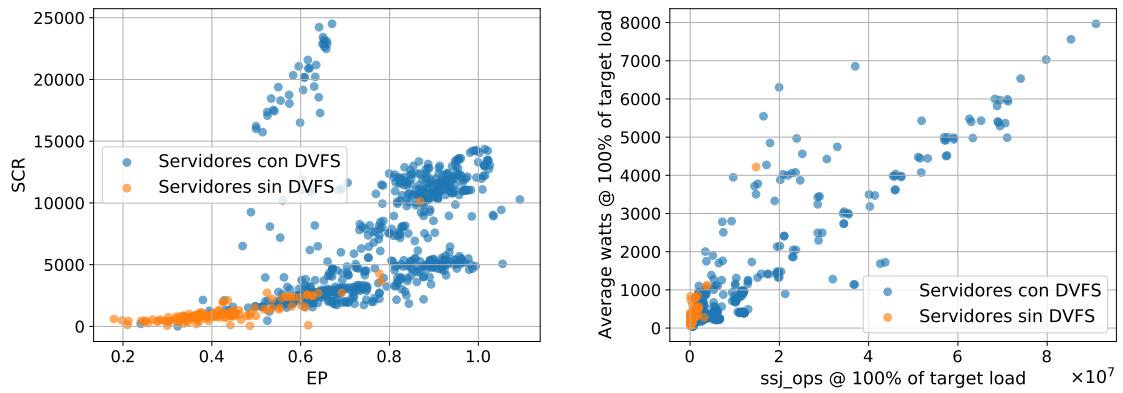


Figura 4.14: SPECpower_ssj2008: Impacto del DVFS en la proporcionalidad energética.

4.1.3.2. Memorias

Las RAMs y cachés son memorias no volátiles, para las cuales, el tiempo de acceso a la información almacenada es considerablemente inferior en comparación con otros dispositivos, tales como discos duros (HDD) y discos de estado sólido (SSD) [Badam and Pai, 2011]. Por lo que, el empleo de las mismas como parte del procesamiento de datos, tienen un impacto significativo en términos de rendimiento.

RAM. Al analizar el conjunto de datos de SPECpower_ssj2008 destaca cómo en términos de rendimiento y consumo de potencia, posee mayor relevancia la capacidad total de almacenamiento, que el número y capacidades individuales de los módulos presentes en el sistema, ya sean módulos de memoria de dos líneas o módulos de memoria de línea única. Sin embargo, las características anteriores carecen de relevancia en cuanto a proporcionalidad y eficiencia energética.

Históricamente, a medida que se incrementa el ancho de banda de las RAMs, también lo hace la latencia de éstas. En consecuencia, los diseñadores de *hardware* optaron como alternativa el desarrollo de memorias cachés de mayor capacidad de almacenamiento y complejidad. Como se mencionó anteriormente, al igual que las RAMs, las memorias cachés tienen un impacto directo en el rendimiento de los sistemas, incluso aún mayor. No obstante, las capacidades de dichas memorias no condicionan sustancialmente la proporcionalidad, ni la eficiencia energética de los sistemas. Además, actualmente existen límites bien definidos de efectividad para las memorias cachés [Bergman et al., 2008].

4.1.3.3. Unidades de almacenamiento

Las unidades de almacenamiento son de los componentes de *hardware* que menos potencia consumen [García-Berná et al., 2021]. Sin embargo, si bien se conoce su impacto en términos de rendimiento, resulta de interés analizar su influencia en la proporcionalidad y eficiencia energética de los servidores de HPC.

Al analizar el conjunto de datos de SPECpower_ssj2008, destaca el predominio de los SSD, tanto en los sistemas superproporcionales, como de manera general. Además, normalmente los sistemas SSD gozan de una mayor eficiencia energética. Asimismo, estos se caracterizan por valores elevados de EP , LD y LDR , por lo que, si bien suelen consumir modestas cantidades de potencia, carecen de linealidad. También, es común que los sistemas SATA posean un alto rendimiento y consumo de potencia, a la vez que su eficiencia energética y EP sobrepasa en su mayoría a los sistemas SAS (ver figura 4.15). Entonces, se concluye que resulta más adecuado el empleo de las unidades SATA y SSD en sistemas de centros de datos y supercómputo respectivamente.

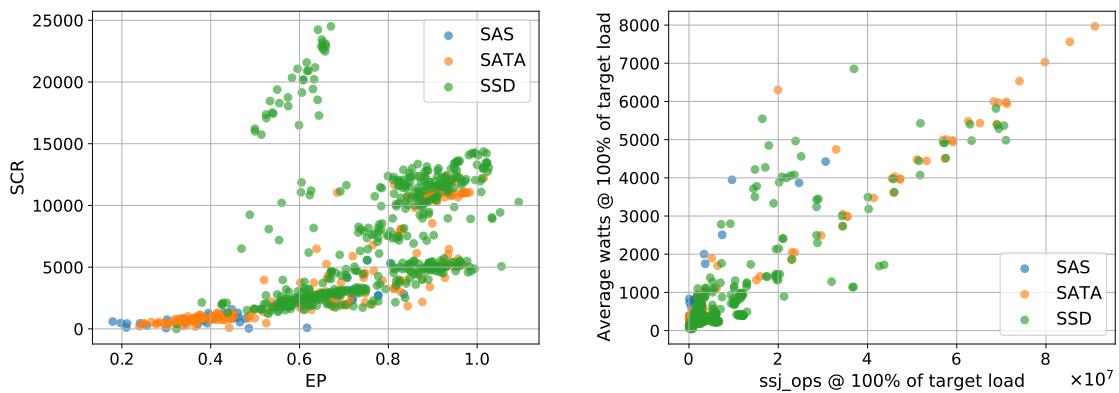


Figura 4.15: SPECpower_ssj2008: Impacto de las unidades de almacenamiento en la proporcionalidad energética.

Por otra parte, al analizar el alcance del número y capacidad de las unidades de almacenamiento, destaca la poca relevancia de los mismos en términos de rendimiento, consumo de potencia, proporcionalidad y eficiencia energética. Ésto, exalta la influencia que tiene la tecnología de almacenamiento en la eficiencia, tanto de la unidad, como de todo el sistema.

4.1.3.4. Entorno de operación

El entorno de operación, consiste en el contexto en el cual se ejecutan los programas. En este sentido, algunos de los principales elementos son la interfaz gráfica, la interfaz de línea de comandos, el administrador de memoria, el calendarizador de procesos y la interfaz de programación de aplicaciones, a partir de la cual se interactúa con los recursos del *hardware*. Por lo que, debe considerarse en qué medida *softwares*, tales como bibliotecas y sistemas operativos, influyen en la proporcionalidad y eficiencia energética de los servidores de HPC.

Sistema operativo. El sistema operativo, en su función de gestor de los recursos de *hardware*, tiene una influencia directa en el consumo de potencia de los sistemas. De acuerdo con [Randhawa et al., 2018], es esencial la gestión de energía a nivel del sistema operativo, para el empleo de modos de bajo consumo de energía en el diseño de los sistemas actuales. Sin embargo, poco se conoce acerca de la incidencia del sistema operativo en términos de rendimiento, proporcionalidad y eficiencia energética.

Al analizar el conjunto de datos de SPECpower_ssj2008 y el listado de sistemas superproporcionales, destaca el predominio de los sistemas *Windows*, en comparación con los restantes sistemas *Linux* y *Mac*. No obstante, las familias de sistemas operativos no son condicionantes absolutos en términos del rendimiento, consumo de potencia, proporcionalidad y eficiencia energética de los sistemas (ver figura 4.16). Aún así, al analizar el impacto de las mismas en servidores de similares características, destaca que los sistemas *Windows* suelen tener una mayor *EP*, mientras que los sistemas *Linux* acostumbran a poseer mayor *SCR*. En consecuencia, se considera conveniente el empleo de los sistemas operativos *Windows* y *Linux* en servidores de centros de datos y HPC respectivamente.

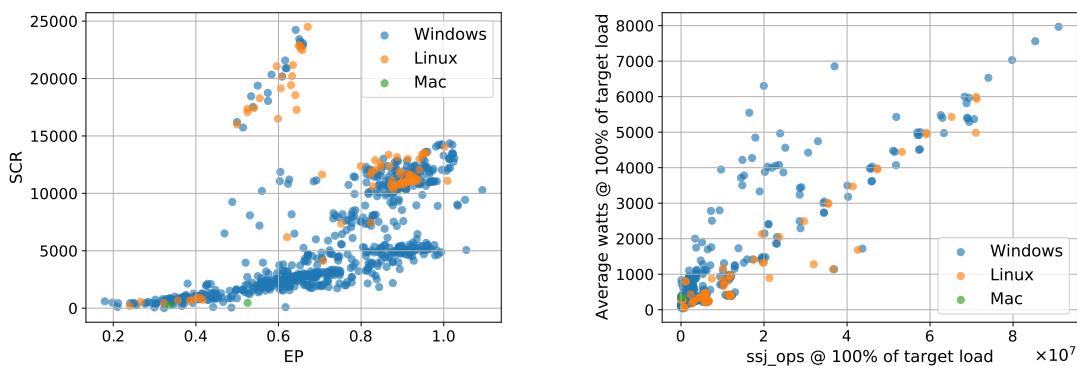


Figura 4.16: SPECpower_ssj2008: Impacto del sistema operativo en la proporcionalidad energética.

Máquina Virtual de Java. Como se mencionó en el capítulo anterior, el *benchmark* SPECpower_ssj2008 hace uso de una aplicación Java para la evaluación de los sistemas. Motivo por el cual, se analizó en qué medida los resultados que éste arroja dependen de la versión de la máquina virtual de Java que utilice el SUT. De este análisis, se concluyó que la versión de la máquina virtual de Java y el número de instancias de la misma utilizadas, no son condicionantes de gran peso en términos del rendimiento, consumo de potencia, proporcionalidad y eficiencia energética.

4.1.3.5. Gabinete

El consumo de energía de los servidores de HPC se cuantifica a partir de la potencia que se utiliza en el procesamiento de los datos y la disipación del calor generado. Sin embargo, los *benchmarks* descritos en el capítulo 3 no tienen en cuenta las características del sistema de refrigeración. Motivo por el cual, a continuación, se analiza el impacto que tiene el tipo de gabinete en términos energéticos.

Al analizar el conjunto de datos de SPECpower_ssj2008, destaca el hecho que de los varios tipos de gabinetes presentes en dicho conjunto, solamente los tipos 1U, 2U, 4U y *tower* están presentes en los servidores superproporcionales. Asimismo, los tipos de gabinetes 1U y 2U se utilizan en los primeros 10 sistemas de mayor eficiencia energética. También, los sistemas de navaja o *blade* suelen tener un mayor rendimiento y consumo de potencia que el resto (ver figura 4.17).

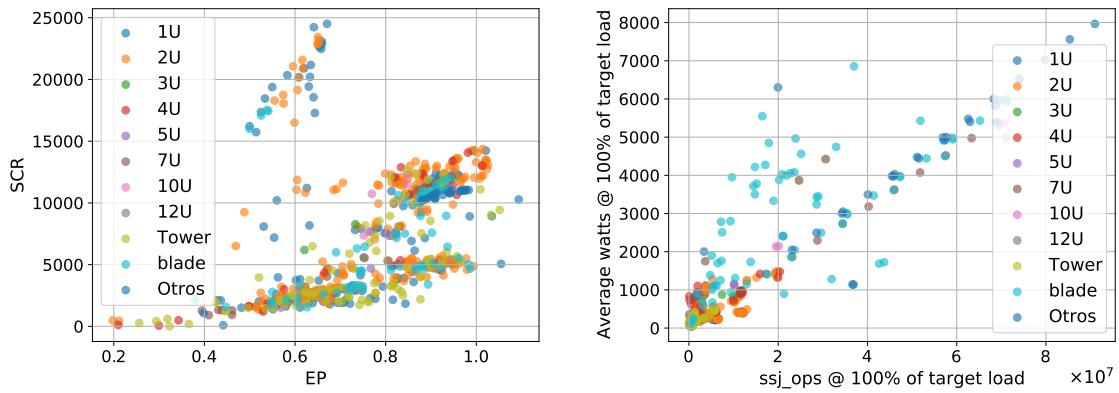


Figura 4.17: SPECpower_ssj2008: Impacto del tipo de gabinete en la proporcionalidad energética.

Además, se analizó la influencia que tiene en este sentido, el número y potencia de las fuentes de energía, obteniéndose que los mismos no son factores de gran relevancia en cuanto al rendimiento, consumo de potencia, proporcionalidad y eficiencia energética de los sistemas.

Como resultado parcial de esta etapa, se concluye que las futuras mejoras a obtener en términos de proporcionalidad y eficiencia energética, están sujetas al desarrollo de nuevas técnicas de gestión de potencia. Si bien en los últimos años se ha incrementado la eficiencia energética de los sistemas, dicho incremento se debe a un aumento del rendimiento de los servidores, y no a una disminución del consumo de potencia de los mismos. Además, el DVFS es cada vez menos determinante en términos de ahorro de energía.

En base al estudio realizado, se deduce que el consumo de potencia, y por consiguiente, la proporcionalidad y eficiencia energética de los sistemas, están condicionados por componentes de diseño físicos y lógicos del servidor. Es decir, la rentabilidad energética de un medio de cómputo se sustenta en la selección de la configuración óptima, que reduzca el consumo de potencia, en base al contexto de trabajo. Por otra parte, las tendencias actuales de diseño de *hardware* tienen un enfoque comercial, y hacen caso omiso a las principales limitantes de diseño de sistemas exaescala. En esta sección, se analizaron las relaciones existentes entre diferentes factores de *hardware*, *software* y proporcionalidad energética. Sin embargo, resulta de interés aplicar técnicas de minería de datos, a fin de identificar la influencia de estos factores en el comportamiento superproporcional antes descrito.

4.2. Preprocesamiento

El preprocesamiento, consiste en la preparación de los datos para su posterior análisis. Ésta, es una etapa determinante del proceso de KDD, ya que condiciona la calidad de los resultados a obtener. Razón por la cual, los profesionales del área de ciencia de datos concuerdan en que durante la construcción de un modelo, se emplea aproximadamente el 75 % del tiempo y esfuerzo en la etapa de preprocesado de datos.

Entre las principales tareas a desarrollar durante el preprocesamiento, se encuentran la limpieza, integración, transformación, reducción y discretización de los datos. La limpieza de los datos, consiste en eliminar registros duplicados, aplicar estrategias de imputación, identificar valores atípicos y corregir inconsistencias. La tarea de integración, es la unión de múltiples conjuntos de datos en un único conjunto unificado. La transformación, consiste en la modificación de los datos a través de estrategias de normalización y estandarización, con el objetivo de que los resultados no dependan de las escalas de las variables. La reducción, consiste en la aplicación de técnicas de reducción de la dimensionalidad. A continuación, se describen y fundamentan las técnicas aplicadas en cada una de estas tareas.

4.2.1. Limpieza de los datos

Al analizar los conjuntos de datos, se obtuvo que en los mismos no existen instancias duplicadas. Sin embargo, la representación de las variables que los componen a partir de diagramas de caja y bigotes¹², permitió identificar la presencia de valores atípicos (ver figura 4.18). No obstante, dichos valores se deben a casos excepcionales, y no a incongruencias en los datos, por lo que no se desecharon.

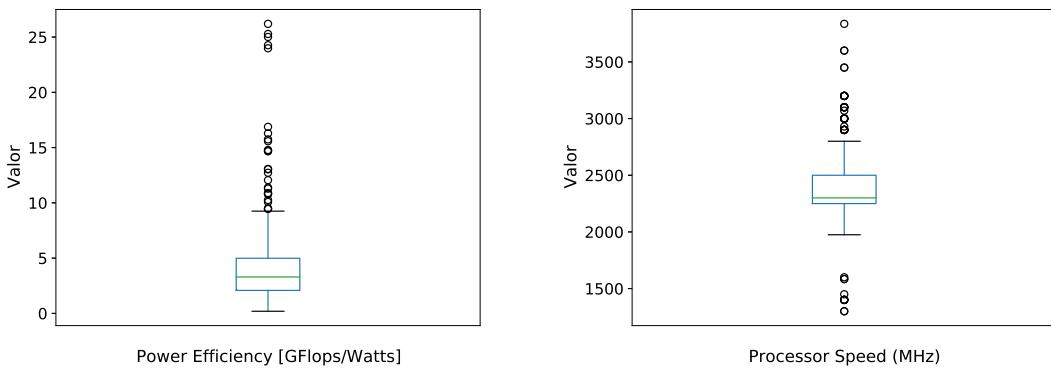


Figura 4.18: Top500: Diagrama de caja y bigotes.

Además, los conjuntos de datos en cuestión, poseen un número significativo de dimensiones, lo cual es una característica indeseada, ya que no garantiza la exactitud, ni la precisión del modelo, pero sí disminuye el rendimiento, e incrementa la complejidad computacional y el riesgo de sobreajuste¹³. Asimismo, en estos conjuntos de datos existen valores faltantes o perdidos; lo que afecta la robustez del modelo, al incrementar la probabilidad de una especificación errónea de este último y disminuir la efectividad de la estimación.

4.2.2. Integración de conjuntos de datos

La integración de conjuntos de datos, si bien suele incrementar el número de variables a considerar, aumenta la exactitud, precisión y robustez del modelo, al reducir las probabilidades de sobreajuste. Motivo por el cual, resulta de gran utilidad en el análisis de datos.

¹²El diagrama de caja y bigotes es una estrategia gráfica de identificación de valores atípicos a partir de la mediana y la dispersión de los datos.

¹³El sobreajuste surge cuando el modelo es muy complejo o el tamaño del conjunto de entrenamiento no es suficiente, lo cual causa una notable diferencia entre los errores de entrenamiento y prueba.

Como se mencionó en el capítulo anterior, el conjunto de datos de SPECpower_ssj2008, resulta insuficiente para el análisis energético de servidores de HPC, al no tener en cuenta el rendimiento de los sistemas en términos de FLOPS. De ahí que, inicialmente, se consideró la integración del mismo con los conjuntos de datos de SPEC OMP 2012 y SPEC MPI 2007. Sin embargo, la información presente en estos últimos, imposibilita establecer con claridad una conexión entre los sistemas presentes en los mismos y los existentes en el conjunto de datos de SPECpower_ssj2008.

Además, sí existe una relación clara entre los conjuntos de datos Top500 y Green500, puesto que el segundo se define a partir del primero. Motivo por el cual, hay una notable coincidencia en la información presente en ambos conjuntos. Sin embargo, las dimensiones existentes en los mismos difieren levemente. Mientras el Top500 describe también el rendimiento de los sistemas en el *benchmark* HPCG, el Green500 lo hace con respecto al *benchmark* HPL (ver apéndice A). Por lo que, se unificaron en el Top500, los datos presentes en éste y en el Green500. En adelante, se continuará el análisis a partir de los conjuntos de datos de SPECpower_ssj2008 y Top500.

4.2.3. Selección de características

La selección de características es una tarea computacionalmente costosa, que consiste en elegir el menor subconjunto de características, capaz de explicar la mayor parte de la varianza de los datos y minimizar el error de clasificación. Esta tarea, no solo reduce la dimensionaldad de los datos al descartar características redundantes o irrelevantes, sino que también disminuye la complejidad del modelo y lo dota de mayor exactitud.

Entre los métodos óptimos de selección de características se encuentran la Búsqueda Exhaustiva (BE) y la Ramificación y Poda o *Branch and Bound* (BB). La principal diferencia entre ambos, radica en que el primero evalúa siempre todos los posibles subconjuntos, mientras que el segundo lo hace en el peor de los casos; sin embargo, para ello requiere que la función de criterio sea monótona. Además, el número de posibilidades a considerar por el algoritmo de BE crece exponencialmente, incluso para subconjuntos de tamaños discretos, por lo que la búsqueda resulta impráctica [Kittler, 1980]. En consecuencia, la BE se suele utilizar cuando se requiere de un algoritmo óptimo, y la función de criterio no satisface la propiedad de monotonía.

Al analizar los conjuntos de datos en cuestión, destaca la ausencia en los mismos de atributos de clase, lo que imposibilita la aplicación de los métodos antes expuestos, así como estrategias robustas de selección de características, tales como regresión, *Random Forest* y eliminación recursiva. En consecuencia, se utilizó como principio de selección la entropía de Shannon y la información mutua de las variables.

La entropía de Shannon $H(X)$ [Shannon, 1948], de una variable aleatoria discreta X , se define como la esperanza matemática de la variable aleatoria asociada $I(X)$, es decir, hace referencia a la cantidad de incertidumbre que aporta una variable.

$$H(X) = E(I(X)) = - \sum_{i=1}^n p(x_i) \cdot \log_2 p(x_i), \quad (4.5)$$

$$I(x_i) = -\log_2 p(x_i), \quad (4.6)$$

siendo x_i , $p(x_i)$ e $I(x_i)$ el i -ésimo valor de la variable X y su respectiva probabilidad e información aportada. Además, teniendo en cuenta su definición, la entropía toma valores comprendidos entre 0 y $\log_2 n$.

Por otra parte, la información mutua $I(X, Y)$, entre dos variables X , Y , cuantifica la reducción en la incertidumbre en X cuando se conoce el valor de Y .

$$I(X, Y) = H(X) + H(Y) - H(X, Y), \quad (4.7)$$

$$H(X, Y) = - \sum_i^n \sum_j^m p(x_i, y_j) \cdot \log_2 p(x_i, y_j), \quad (4.8)$$

donde $p(x_i, y_j)$ es la probabilidad de que el i -ésimo valor de X y el j -ésimo valor de Y sucedan al mismo tiempo.

La aplicación de estos principios de selección posibilitó la eliminación de características intrascendentes, tales como identificadores y campos de tipo fecha. Asimismo, se desecharó la variable *OS Family* del conjunto de datos Top500, ya que la entropía de la misma es cero.

4.2.4. Imputación

Con el objetivo de solventar la existencia de valores faltantes en los conjuntos de datos, se analizaron varias estrategias de imputación, que van desde el empleo de conjuntos de datos completos, hasta estrategias de imputación simple. En este caso, no se consideraron estrategias de imputación múltiple, debido a su alto costo computacional. Además, éstas no son siempre la mejor opción estadística para la sustitución de datos, al depender de la variable que se analice y su respectivo patrón de comportamiento.

Análisis de datos completos. El análisis de datos completos o *listwise* es una de las estrategias más utilizadas [Medina and Galván, 2007b], a pesar de no considerarse la más apropiada, puesto que genera sesgos en los coeficientes de asociación y de correlación [Kaltton and Kasprzyk, 1982]. *Listwise* asume que los datos faltantes siguen un patrón MC, es decir, son una submuestra aleatoria del conjunto original. Por lo que, consiste en trabajar únicamente con las instancias que poseen datos completos y desechar las restantes.

4.2.4.1. Imputación Simple

Media. La imputación a partir de la media es una de las estrategias de imputación más utilizadas, debido a su simplicidad y bajo coste computacional. Sin embargo, el empleo de la misma no resulta correcto, pues distorsiona la distribución de probabilidad de la variable imputada [Little and Rubin, 2019]. Además, se debe tener en consideración que a diferencia de la moda y la mediana, la media es susceptible a valores atípicos.

Regresión. Esta estrategia suele emplearse en patrones de datos faltantes completamente aleatorios [Medina and Galván, 2007a]. Consiste en reemplazar los valores perdidos por los valores predichos por una regresión del elemento faltante. Para lo cual, inicialmente se entrena y evalúa el modelo a partir de un subconjunto del conjunto de datos original, en el que no existen valores perdidos.

Imputación a partir de los k -vecinos más cercanos. Esta estrategia toma como base el algoritmo de clasificación k -vecinos más cercanos. Así pues, los valores faltantes se imputan a partir del promedio de los valores que poseen los k vecinos más cercanos en la variable en cuestión [Troyanskaya et al., 2001].

$$x_{ij*} = \frac{\sum_{n=1}^k v_{nj}}{k}, \quad (4.9)$$

donde x_{ij*} es el valor imputado en la i -ésima instancia y la j -ésima variable, mientras que v_{nj} es el valor que posee el n -ésimo vecino más cercano en dicha variable.

Luego de estudiar diversas estrategias de imputación, muchas de las cuales generan estimadores sesgados, se decidió realizar el análisis de datos completos. Ésto, debido a que después de descartar las instancias con valores perdidos, las restantes continuaban siendo lo suficientemente significativas. Por lo que, se considera que las instancias eliminadas son una submuestra aleatoria de la muestra total.

4.2.5. Transformación

La transformación de los datos, consiste en la modificación de los valores de una o más variables, con el objetivo de que los mismos satisfagan una determinada propiedad. Ésto, no solo facilita la visualización e interpretación de los datos, sino que garantiza que las escalas de las variables no influyan en el resultado final. Por ejemplo, en algoritmos de agrupamiento, resulta conveniente transformar los datos previo a su procesamiento, con el objetivo de que las variables de mayor escala no dominen los resultados del análisis. Sin embargo, la estrategia de normalización a aplicar depende de las características del problema, ya que la aplicación de una u otra producirá diferentes resultados.

Normalización min-max. La normalización min-max reescaliza los valores de una variable a un nuevo rango previamente definido. Usualmente, este último está comprendido entre los límites 0 y 1, es decir, $\forall i, j \ x'_{ij} \in [0, 1]$ (ecuación 4.10); sin embargo, dichos límites pueden seleccionarse de forma empírica (ecuación 4.11). La principal desventaja de min-max radica en el hecho de que incrementa el ruido existente en el conjunto de datos.

$$x'_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)}, \quad (4.10)$$

$$x'_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)}(new_{max} - new_{min}) + new_{min}, \quad (4.11)$$

donde $\min(x_j)$ y $\max(x_j)$ se refieren al mínimo y máximo valor de la variable x_j ; mientras que new_{min} y new_{max} son los límites inferior y superior de la nueva escala.

Normalización *z-score*. Otra estrategia de normalización comúnmente utilizada es el escalado estándar. Ésta, cuantifica la distancia de un valor respecto a su media. Además, transforma los datos a una distribución con media 0 y desviación estándar 1 (ecuación 4.12), permitiendo comparar datos expresados en magnitudes distintas.

$$x'_{ij} = \frac{x_{ij} - \bar{x}_j}{std_desv(x_j)}, \quad (4.12)$$

siendo \bar{x}_j y $std_desv(x_j)$ la media y desviación estándar de la variable x_j .

Normalización por escala decimal. La normalización por escala decimal transforma los datos al rango $(-1, 1)$ (ecuación 4.13).

$$x' = \frac{x}{10^j}, \quad (4.13)$$

donde j es el número entero más pequeño tal que $\max(|x'|) < 1$. Además, al igual que la normalización min-max, las estrategias de normalización *z-score* y escala decimal son susceptibles a la presencia de valores atípicos.

Si bien existen algoritmos de minería de datos donde la información suele transformarse previo a su procesamiento, en otros, tales como árboles de decisión y *Random Forest* no es así. Por lo que, resulta apropiado aplicar estrategias de transformación, solo en los casos en los que sea necesario. Razón por la cual, no se reescalaron ninguna de las variables presentes en los conjuntos de datos de SPECpower_ssj2008 y Top500.

Por otra parte, en ambos conjuntos de datos existen variables categóricas, sobre las cuales resulta imposible la aplicación de varios algoritmos de agrupamiento y reducción de la dimensionalidad, tales como Análisis de Componentes Principales (PCA) y Descomposición en Valores Singulares (SVD). Por lo que, se exploraron varias estrategias, a partir de las cuales transformar datos categóricos en numéricos.

Medición ordinal. La medición ordinal se aplica sobre variables categóricas de tipo ordinal, ya que en las mismas existe una jerarquía u orden. Esta estrategia consiste en la asignación de un valor numérico a cada uno de los elementos que compone la jerarquía, de forma tal, que se satisfaga la condición de transitividad. La condición de transitividad plantea que si A tiene una calificación superior a la de B y B posee una calificación superior a la de C , entonces A tiene una calificación superior a la de C , es decir, si $A > B$, y $B > C$, entonces $A > C$. Si bien las mediciones ordinales son de gran utilidad, éstas no permiten comparar la magnitud de las diferencias entre las categorías.

Variables Ficticias. A diferencia de las variables ordinales, las variables nominales carecen de una disposición u ordenamiento de sus valores, lo cual dificulta establecer distancias entre los mismos. En este sentido, resulta apropiado el empleo de variables ficticias o *reasignación uno de n*. Esta estrategia consiste en la creación de una pseudovariable de valor binario para cada valor de la variable nominal¹⁴ y calcular la distancia en cada una de

¹⁴Para una variable nominal de n valores distintos resulta suficiente con crear $n - 1$ variables ficticias, pues el valor restante se representa al asignar cero a cada una de las anteriores $n - 1$ variables.

las dimensiones. Entonces, para todo par de instancias x_i, x_j , su distancia en términos de una variable nominal de cardinalidad n , es la suma de las distancias en cada una de las n variables ficticias asociadas, es decir, $\forall i, j \ distancia(x_i, x_j) = \sum_{k=1}^n distancia(x_{i,k}, x_{j,k})$, siendo

$$distancia(x_i, x_j) = \begin{cases} 0 & \text{si } x_i = x_j, \\ 1 & \text{si } x_i \neq x_j. \end{cases}$$

$$distancia(x_{i,k}, x_{j,k}) = \begin{cases} 0 & \text{si } x_{i,k} = x_{j,k}, \\ 1 & \text{si } x_{i,k} \neq x_{j,k}. \end{cases}$$

En los conjuntos de datos en cuestión, todas las variables categóricas restantes, luego del proceso de selección de características, son de tipo nominal. En consecuencia, se aplicó la estrategia *reasignación uno de n*, la cual resulta de gran utilidad, a pesar del considerable incremento que supone en términos de dimensionalidad.

4.2.6. Discretización

La discretización, consiste en la transformación de variables continuas a categóricas. Ésta, usualmente se realiza en algoritmos de clasificación, con el objetivo de reducir la complejidad del modelo y disminuir el costo computacional. Sin embargo, la definición de los intervalos óptimos, tanto en número como longitud, no es un proceso trivial. En este sentido, si bien puede resultar de utilidad el empleo de algoritmos de agrupamiento, suelen utilizarse métricas de impuridad como el índice de Gini, la entropía y el error de clasificación.

$$\text{Índice Gini} = 1 - \sum_{i=0}^{c-1} p_i(t)^2, \quad (4.14)$$

siendo c el número total de casos y $p_i(t)$ la frecuencia de la i -ésima clase en el nodo t .

$$\text{Error de clasificación} = 1 - \max(p_i(t)). \quad (4.15)$$

Específicamente, las variables continuas existentes en los conjuntos de datos de SPEC-power_ssj2008 y Top500 hacen referencia a la eficiencia energética de los sistemas presentes en dichos conjuntos. Por lo que, aun cuando la discretización de estas variables pudiese incrementar la robustez del modelo, se decidió realizar esta tarea solo en los casos donde fuese necesario, ya que el empleo de la misma puede también sesgar este último.

4.2.7. Reducción de la dimensionalidad

A fin de reducir la alta dimensionalidad presente en los conjuntos de datos, sobre todo luego de la creación de variables ficticias para la transformación de variables nominales en discretas, se estudiaron varios algoritmos de reducción de dimensionalidad. Si bien estrategias como el análisis factorial (FA), la incrustación localmente lineal (LLE) y el escalamiento multidimensional (MDS) resultan de utilidad en este sentido, se consideraron más acertados la SVD y el PCA.

4.2.7.1. Descomposición en Valores Singulares

SVD consiste en la descomposición de una matriz de datos X , como la multiplicación de tres matrices U , Σ y V^T , de forma tal, que $X = U\Sigma V^T$, donde U y V son matrices unitarias¹⁵ ortogonales referentes a los vectores singulares izquierdos y derechos respectivamente, mientras que Σ es una matriz diagonal asociada a los valores singulares.

$$X = \begin{bmatrix} \vdots & \vdots & \vdots & \vdots \\ x_1 & x_2 & \cdots & x_m \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix}_{n \times m} = \begin{bmatrix} \vdots & \vdots & \vdots & \vdots \\ u_1 & u_2 & \cdots & u_n \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix}_{n \times n} \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_m \end{bmatrix}_{n \times m} \begin{bmatrix} \vdots & \vdots & \vdots & \vdots \\ v_1 & v_2 & \cdots & v_m \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix}_{m \times m}^T$$

Para una matriz de datos $X_{n \times m}$, los valores singulares son los primeros m elementos de la diagonal principal de Σ . Éstos, al ser valores singulares, son no negativos y se ordenan de forma jerárquica descendente, es decir $\forall_{i=1}^m \sigma_i \geq 0$ y $\forall_{i=1}^{m-1} \sigma_i \geq \sigma_{i+1}$; mientras que, los restantes valores de Σ son todos cero. Además, al asociarse el i -ésimo valor singular de Σ con la i -ésima columna de U y V , la jerarquía existente entre los valores de Σ refleja la relevancia de cada una de las columnas de U y V . Es decir, la i -ésima columna de U y V es más relevante que su sucesora, en función de describir la información de X .

A grandes rasgos, la reducción de dimensionalidad, consiste en desechar los valores singulares significativamente pequeños y sus respectivos vectores en las matrices U y V . En consecuencia, se aproximaría la matriz X en términos de los primeros vectores dominantes de U y V , así como sus correspondientes valores singulares.

4.2.7.2. Análisis de Componentes Principales

El PCA consiste en la representación de la varianza de un conjunto de datos $X_{n \times m}$, a partir de variables ortogonales¹⁶ entre sí, nombradas componentes principales. Éstos, no son más que la combinación lineal de los atributos originales, de forma tal, que cada componente principal se asocia a un autovector y un autovalor, los cuales indican la dirección y magnitud en la que se explica la varianza [Brunton and Kutz, 2019]. En otras palabras, el i -ésimo autovector hace referencia a las ponderaciones correspondientes a cada uno de los atributos originales en el i -ésimo componente principal.

De manera general, la aplicación del PCA consta de los siguientes pasos [Brunton and Kutz, 2019]:

1. PCA es equivalente SVD, una vez que los datos se centran. Por lo que se calcula la media de las instancias \bar{x} , la media de todo el conjunto de datos \bar{X} y por último se centran los valores de éste.

$$\bar{x}_j = \frac{\sum_{i=1}^n X_{ij}}{n}, \quad (4.16)$$

¹⁵Al ser U y V matrices unitarias significa que $UU^T = U^T U = I_{n \times n}$ y $VV^T = V^T V = I_{m \times m}$.

¹⁶La correlación entre dos variables ortogonales es cero.

$$\bar{X} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \bar{x}, \quad (4.17)$$

$$B = X - \bar{X}. \quad (4.18)$$

2. Calcular la matriz de covarianza de los puntos (C).

$$C = \frac{B^T B}{n}. \quad (4.19)$$

3. Obtener los vectores y valores propios de C .

$$CV = VD, \quad (4.20)$$

donde V son los autovectores o ponderaciones de cada componente y D son los autovalores o varianza explicada por dichos componentes.

4. Finalmente, a partir de los autovectores se obtienen los componentes principales (T).

$$T = BV. \quad (4.21)$$

Si se descompone B a través de SVD, de forma tal, que $B = U\Sigma V^T$, entonces $T = U\Sigma$, pues $V^T V = I$. Asimismo, existe una estrecha relación entre los autovalores y los valores singulares, de forma tal, que $\lambda = \sigma^2$. De ahí que, el porcentaje de varianza explicada por los primeros k de n componentes principales se cuantifica como:

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i}. \quad (4.22)$$

SVD, PCA y muchos otros algoritmos de reducción de dimensionalidad, son sensibles a ruidos y valores atípicos. Por lo que, la presencia de estos últimos en los conjuntos de datos en cuestión, promueve el análisis del impacto de los valores atípicos en dichos algoritmos, y en qué medida se conserva el carácter atípico de las instancias, luego de la reducción de la dimensionalidad. PCA es un problema de optimización, que consiste en maximizar la varianza explicada por cada uno de los componentes principales. Motivo por el cual, la distorsión de la media a causa, de la presencia de valores atípicos, influye directamente en la varianza y covarianza, y por consiguiente en el PCA. La figura 4.19 ilustra la sensibilidad del PCA ante la presencia de valores atípicos.



Figura 4.19: PCA: Análisis de sensibilidad a valores atípicos.

En este sentido, existen estudios que destacan la relevancia de la estandarización de los datos previo a la reducción de la dimensionalidad. Ésta, no solo elimina cualquier influencia de la escala de las variables en los resultados finales, sino que además, reduce el impacto de los valores atípicos en los algoritmos de reducción de dimensionalidad [Onderwater, 2015]. La figura 4.20 ilustra los resultados obtenidos luego de la aplicación de esta estrategia, donde cabe destacar cómo, para igual número de componentes principales, el porcentaje de varianza explicada en esta figura es significativamente superior con respecto a la figura 4.19.



Figura 4.20: PCA: Análisis de sensibilidad a valores atípicos posterior a la estandarización.

4.2.7.3. Análisis de Componententes Principales Robusto

El Análisis de Componententes Principales Robusto (RPCA), es una estrategia de reducción de dimensionalidad basada en el PCA, pero a diferencia del mismo, posee una gran robustez en presencia de valores atípicos. Éste, consiste en la descomposición de la matriz de datos, como la superposición de un componente de bajo rango L y un componente disperso S .

$$X = L + S. \quad (4.23)$$

De manera general, L y S son los patrones claramente definidos en el conjunto de datos y los valores atípicos respectivamente, de forma tal, que L no es sensible a los valores atípicos y datos corruptos presentes en S (ver figura 4.21).



Figura 4.21: RPCA: Análisis de sensibilidad.

Por otra parte, para toda matriz $X \in \mathbb{R}^{m \times n}$, su rango es menor o igual que el mínimo número de filas y columnas, es decir, $\text{Rango}(X) \leq \min(m, n)$. Sin embargo, en las matrices de bajo rango, su rango es siempre inferior al mínimo número de filas y columnas, es decir, $\text{Rango}(X) < \min(m, n)$. Por lo que, en el caso de estas últimas, siempre se anulará al menos una fila o columna. Entonces, al ser L una matriz de bajo rango, ésta puede ser descompuesta en valores singulares como:

$$L = U\Sigma V^T = \sum_{i=1}^{\text{Rango}(L)} \sigma_i u_i v_i^T. \quad (4.24)$$

Aún así, existen un número infinito de posibles pares L, S ; sobre todo teniendo en cuenta que la cantidad de incógnitas a inferir duplica a las existentes en la matriz de datos X . Por lo que, se define una función objetivo que promueva una solución única y responda al objetivo que se persigue. En el caso de RPCA, la función objetivo consiste en minimizar el rango de L y el número de valores atípicos o datos corruptos presentes en S :

$$\min \text{Rango}(L) + \|S\|_0 \text{ tal que } X = L + S, \quad (4.25)$$

donde $\|\cdot\|_0$ es el número de elementos distintos de cero.

Como conclusión del análisis realizado, si bien algoritmos como RPCA son más eficientes para la gestión de valores atípicos que el PCA clásico, éstos no se consideraron, puesto que descartar los valores atípicos, no resulta conveniente para con el estudio que se plantea. En consecuencia, se adoptó como estrategia de reducción de dimensionalidad la aplicación del PCA, precedido de la estandarización de los datos.

La aplicación del PCA sobre el conjunto de datos de SPECpower_ssj2008 indicó que se requieren diez componentes principales para explicar el 80.4 % de la varianza de los datos (ver figura 4.22). Mientras que, en el conjunto de datos Top500 resultan suficientes cuatro componentes principales para expresar el 83.8 % de la varianza de los datos (ver figura 4.23). No obstante, en este último, resulta innecesario y contraproducente, considerando que luego de las etapas anteriores de preprocesamiento, este conjunto de datos cuenta con nueve dimensiones, por lo que no es un conjunto de alta dimensionalidad¹⁷.

¹⁷Los conjuntos de datos de 11 o más dimensiones suelen considerarse de alta dimensionalidad.

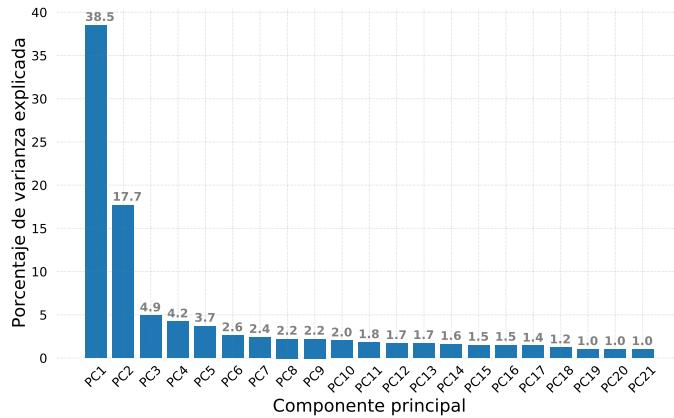


Figura 4.22: SPECpower_ssj2008: PCA.

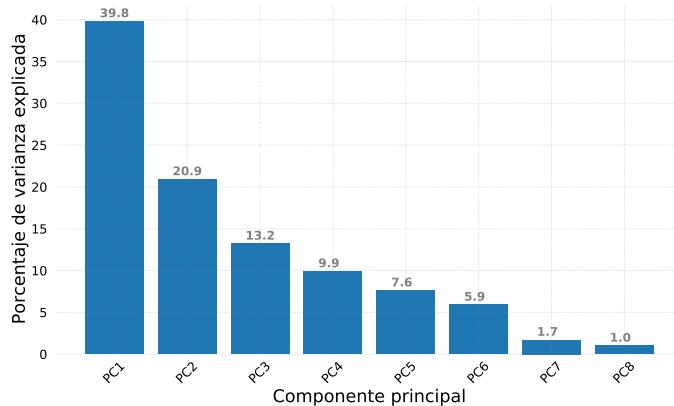


Figura 4.23: Top500: PCA.

Por otra parte, la aplicación de técnicas de reducción de dimensionalidad puede sesgar el comportamiento atípico de los datos [Onderwater, 2015]. Por lo que, se decidió proseguir el análisis sin previa reducción de la dimensionalidad, y hacer uso de las nuevas dimensiones solo en algoritmos de alto coste computacional. Luego del preprocessamiento del conjunto de datos de SPECpower_ssj2008, éste quedó conformado por 644 instancias, cada una de las cuales constaba de 65 atributos. Asimismo, el conjunto de datos Top500 se compuso de 189 muestras, las que a su vez poseían 10 atributos. Además, los sistemas superproporcionales identificados durante el análisis descriptivo persistieron el preprocessamiento de los datos.

4.3. Análisis exploratorio

El análisis exploratorio, consiste en estudiar los conjuntos de datos, identificar los patrones presentes en éstos y las características principales. De acuerdo con [Williams and Simoff, 2006], el análisis exploratorio comprende la construcción de gráficos, la exploración visual e interactiva; y la aplicación de algoritmos analíticos.

4.3.1. Factores condicionantes de superproporcionalidad

El PCA realizado, permitió identificar las variables de mayor relevancia en términos de varianza. Sin embargo, no resulta suficiente para determinar las condicionantes del carácter superproporcional de varios sistemas. En consecuencia, a continuación se analizan varias estrategias de selección de características.

Análisis del umbral de varianza. La selección de características a partir de un umbral de varianza es una técnica no supervisada, que consiste en la eliminación de aquellas características cuya varianza es inferior a un umbral previamente definido. Asimismo, el umbral de decisión suele definirse teniendo en cuenta el equilibrio de clases en el conjunto de datos y los costos asociados a una clasificación errónea [Gao et al., 2009].

Árboles de decisión. Los árboles de decisión son una estrategia de aprendizaje supervisado, donde los nodos hojas representan las etiquetas o atributos de clase, mientras que los restantes nodos y sus respectivas aristas, representan a las características y sus correspondientes valores. Si bien éstos son fáciles de construir e interpretar, y se caracterizan por su robustez en presencia de ruido y valores atípicos, el espacio de búsqueda suele ser exponencialmente grande¹⁸ y no se consideran las interacciones entre las variables. No obstante, su propio principio de construcción posibilita el empleo de éstos como estrategia de selección de características, pues las características se asignan a cada uno de los nodos en base al *radio de ganancia de información* ($Gain_{ratio}$).

$Gain_{ratio}$ ajusta la *ganancia de información*¹⁹ o grado de pureza asociado a la variable ($Gain_{split}$) en base a la entropía del particionado, de forma tal, que se penalizan los casos donde existe un gran número de particiones pequeñas.

$$Gain_{ratio} = \frac{Gain_{split}}{Split_{info}}, \quad (4.26)$$

$$Gain_{split} = H(p) - \sum_{i=1}^k \frac{n_i}{n} H(i), \quad (4.27)$$

$$Split_{info} = - \sum_{i=1}^k \frac{n_i}{n} \log_2 \frac{n_i}{n}, \quad (4.28)$$

siendo p el nodo padre, k el número de intervalos en que se discretiza la variable y n_i el número de instancias o registros pertenecientes al i -ésimo intervalo. Además, con el objetivo de seleccionar un subconjunto de características que maximice la exactitud y precisión del modelo, dicha estrategia suele extenderse a través de la aplicación del algoritmo *Random Forest*, donde la importancia general de cada característica se cuantifica como el promedio de la importancia individual de la misma en todos los árboles del bosque.

¹⁸Las variables continuas presentes en los árboles de decisión, se discretizan con el objetivo de disminuir el espacio de búsqueda e incrementar la robustez del modelo.

¹⁹La ganancia de información cuantifica la calidad de una variable en términos de reducción de entropía.

Filtro basado en correlación rápida. El algoritmo filtro basado en correlación rápida (FCBF) [Yu and Liu, 2003], consiste en seleccionar las características que presentan una alta correlación con la variable objetivo y poca correlación con las restantes variables. Para ello, utiliza como métrica de correlación la incertidumbre simétrica (SU)²⁰, la cual se basa en los conceptos de entropía de Shannon y ganancia de información.

$$SU(X, Y) = 2 \left[\frac{H(X) - H(X, Y)}{H(X) + H(Y)} \right]. \quad (4.29)$$

FCBF, al igual que otros métodos de selección de características a partir de filtros, se desempeña de forma independiente al algoritmo de aprendizaje. Además, es escalable, computacionalmente eficiente y no requiere de un entrenamiento previo. La complejidad temporal de FCBF es $O(n \log_2 n)$. De acuerdo con [Yu and Liu, 2003], FCBF es altamente eficiente y efectivo al tratar datos de alta dimensionalidad.

Varias estrategias de selección de características son sensibles a la presencia de valores atípicos en los datos, condición anteriormente detectada en los conjuntos de datos de SPEC-power_ssj2008 y Top500. En consecuencia, estrategias tales como el análisis del umbral de varianza y máquinas de soporte vectorial (SVM) se descartaron automáticamente. Por lo que, se prosiguió con el análisis a partir de estrategias basadas en árboles de decisión, específicamente los algoritmos CART y *Random Forest*, así como FCBF.

El estudio de superproporcionalidad se desarrolló a partir del conjunto de datos de SPEC-power_ssj2008, ya que, a diferencia del Top500, éste posee un enfoque gradual de carga de trabajo, característica indispensable para el análisis de la proporcionalidad energética. También, fue en el conjunto de datos de SPECpower_ssj2008 en el que se identificó la presencia de 20 sistemas superproporcionales. Entonces, se definió en dicho conjunto un atributo de clase ficticio, binario, y luego se etiquetaron los servidores presentes en SPECpower_ssj2008 en base a su carácter superproporcional.

Por otra parte, el desbalance de clases afecta a los árboles de decisión. Motivo por el cual, la generación de los subconjuntos de entrenamiento y validación se realizó a partir de la técnica *Stratified K-Folds cross-validation*. Ésta, es una variación de la técnica *K-Folds cross-validation*, donde las k particiones disjuntas, se generan preservando el porcentaje de muestras de cada clase. Así pues, garantiza que en todo momento, cada una de las clases, forman parte tanto del entrenamiento, como de la validación del modelo.

La figura 4.24 ilustra las 10 variables de mayor relevancia en términos de superproporcionalidad energética, identificadas a partir de la ejecución del algoritmo *Random Forest*. En este sentido, sobresale la eficiencia energética como factor determinante. Igualmente, destaca la influencia del consumo de potencia en los niveles discretos de carga de trabajo, específicamente en los niveles de 0% y 10% de utilización.

²⁰Un valor SU de 1 indica que a partir de una variable se puede predecir con toda certeza el valor de la otra, mientras que el valor 0 indica que dos características son totalmente independientes.

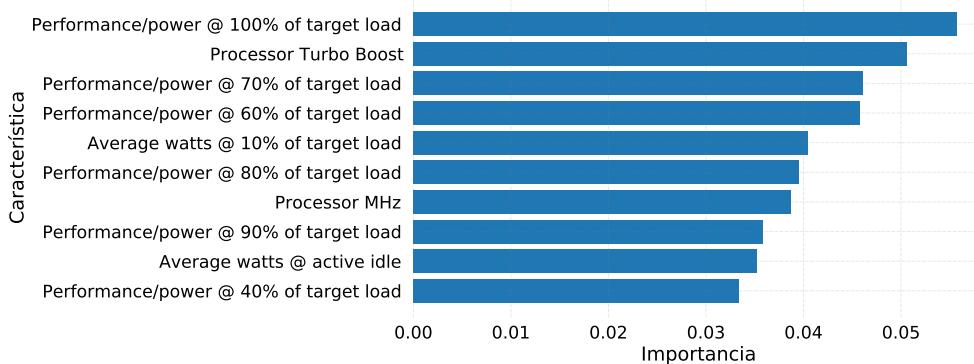


Figura 4.24: *Random Forest: Ranking* de las 10 características más determinantes en materia de superproporcionalidad energética.

Como resultado de la aplicación del algoritmo FCBF, se obtuvo que si bien la eficiencia energética es un factor relevante, también lo son las características asociadas a las unidades de almacenamiento y el tipo de gabinete. Ésto, se corroboró a partir del análisis de dependencia entre cada una de las variables y el atributo de clase, para lo cual se empleó el estadístico chi-cuadrado (χ^2)²¹ (ver figura 4.25). Para más información ver tabla B.1.

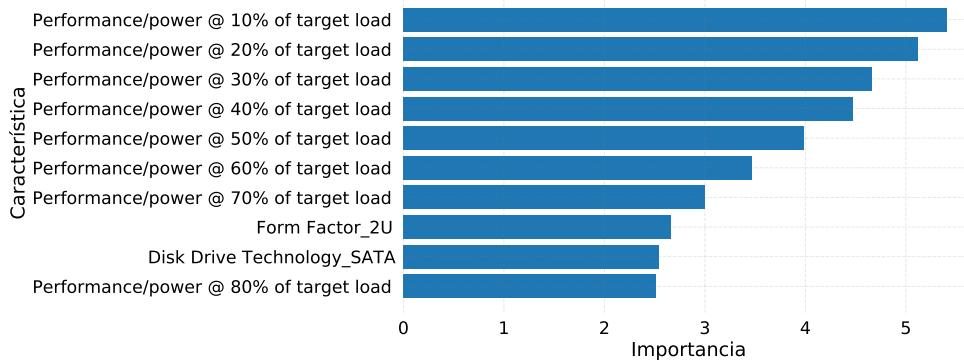


Figura 4.25: χ^2 : *Ranking* de las 10 características más determinantes en términos de superproporcionalidad energética.

Como conclusión del análisis realizado, y en respuesta a la interrogante 1, se determinó que si bien la eficiencia energética, el tipo de gabinete y las características asociadas al procesador y sistema de almacenamiento resultan relevantes en términos de superproporcionalidad energética, existen varios otros factores a considerar al respecto. Lo anterior, reafirma lo expuesto por [Bergman et al., 2008] referente a que el consumo energético de un sistema depende de diversos factores. Por lo que, resulta de interés identificar las variables de distinción en términos de rendimiento y consumo de potencia en servidores de HPC.

²¹Según [Thaseen and Kumar, 2017], el estadístico χ^2 es una prueba numérica que mide la desviación de la distribución esperada considerando que el evento de la característica es independiente del valor de la clase.

4.3.2. Análisis de agrupamiento

El análisis de agrupamiento es una tarea descriptiva de minería de datos, que consiste en segmentar en grupos (clústeres) los elementos que componen el conjunto de datos, de forma tal, que se minimice la varianza intra-clúster²² y se maximice la varianza inter-clúster²³. Con este objetivo, los elementos se agrupan en base a la similitud de sus atributos, así pues, la métrica de disimilaridad (distancia) y el algoritmo de agrupamiento a emplear están condicionados por el contexto del problema. Además, dicho análisis puede utilizarse tanto para agrupar instancias, como para agrupar variables, por lo que permite confirmar o descartar teorías, y a la vez, descubrir relaciones, que de otra forma permanecerían ocultas.

4.3.2.1. Métricas de distancia

En varias técnicas de minería de datos, tales como el análisis de agrupamiento y el algoritmo k -vecinos más cercanos, la calidad de los resultados depende de la métrica de distancia que se emplee. De manera general, las métricas de distancia satisfacen las siguientes condiciones necesarias y suficientes:

1. Semipositiva: $\forall x, y \ d(x, y) \geq 0$ y $d(x, y) = 0 \iff x = y$.
2. Simetría: $\forall x, y \ d(x, y) = d(y, x)$.
3. Desigualdad triangular: $\forall x, y, z \ d(x, z) \leq d(x, y) + d(y, z)$.

Distancia entre atributos. Como se definió anteriormente, la similitud entre dos objetos es un valor numérico que cuantifica el grado de similaridad existente entre dichos objetos para cada uno de los atributos. En este sentido, la métrica a partir de la cual se calcula la distancia existente entre dos objetos para un mismo atributo, está sujeta al tipo de variable que se analice (ver tabla 4.4).

Tipo de atributo	Métrica de disimilitud	Métrica de similitud
Nominal	$d = \begin{cases} 0 & \text{si } x_i = x_j, \\ 1 & \text{si } x_i \neq x_j. \end{cases}$	$s = \begin{cases} 1 & \text{si } x_i = x_j, \\ 0 & \text{si } x_i \neq x_j. \end{cases}$
Ordinal	$d = \frac{ x-y }{n-1}$	$s = 1 - d$
Intervalo	$d = x - y $	$s = -d$ $s = \frac{1}{1+d}$

Tabla 4.4: Métricas de similitud entre atributos.

Distancia *Manhattan*. La distancia *Manhattan* o distancia L_1 , define que la distancia entre dos puntos, es igual a la sumatoria de las distancias entre cada uno de los valores de los mismos.

$$d_{man}(x, y) = \sum_{i=1}^n |(x_i - y_i)|, \quad (4.30)$$

siendo n el número de dimensiones, mientras que x_i y y_i son el valor del i -ésimo atributo en las instancias x y y .

²²La varianza intra-clúster es la distancia entre los elementos de un mismo clúster.

²³La varianza inter-clúster es la distancia entre los clústeres.

Distancia euclideana. La distancia euclideana (L_2) se utiliza en algoritmos de agrupamiento, con el objetivo de definir los centroides como la media de las instancias, y minimizar la suma del cuadrado de la distancia euclideana.

$$d_{euc}(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (4.31)$$

Distancia Minkowski. La distancia *Minkowski* es una generalización de las distancias euclideana y *Manhattan*, donde $r \in [1, \infty]$ de forma tal, que su valor está en correspondencia con el tipo de métrica de distancia a aplicar.

$$d(x, y) = \left(\sum_{i=1}^n |x_i - y_i|^r \right)^{\frac{1}{r}}. \quad (4.32)$$

Coeficiente de coincidencia simple. El coeficiente de coincidencia simple (*SMC*), cuantifica la similaridad entre dos vectores binarios²⁴ x y y a partir de la proporción del número de coincidencias, con respecto al número total de atributos.

$$SMC = \frac{f_{00} + f_{11}}{f_{00} + f_{10} + f_{01} + f_{11}}, \quad (4.33)$$

siendo f_{jk} el número de atributos donde x y y toman valor j y k respectivamente.

Coeficiente de Jaccard. El coeficiente de Jaccard (J), consiste en la proporción del número de coincidencias con respecto al número de atributos, para los cuales, al menos uno de los valores existentes en los vectores es distinto de cero.

$$J = \frac{f_{11}}{f_{10} + f_{01} + f_{11}}. \quad (4.34)$$

Coeficiente de Jaccard Extendido. El coeficiente de Jaccard Extendido (EJ), es una variación del coeficiente de Jaccard para variables continuas.

$$EJ(x, y) = \frac{x \cdot y}{\|x\|^2 + \|y\|^2 - x \cdot y}. \quad (4.35)$$

Coseno de similitud. El coseno de similitud (s_{cosine}), se utiliza como métrica de similitud en vectores, donde cada atributo hace referencia a la frecuencia de ocurrencia de un determinado elemento. Además, s_{cosine} se extrae para identificar el coseno de distancia (d_{cosine}) entre dos vectores, por lo que ambas métricas suelen utilizarse en algoritmos de agrupamiento, ya sea para maximizar s_{cosine} o disminuir d_{cosine} .

$$s_{cosine}(x, y) = \frac{\langle x, y \rangle}{\|x\| \cdot \|y\|}, \quad (4.36)$$

$$d_{cosine}(x, y) = 1 - s_{cosine}(x, y). \quad (4.37)$$

²⁴Un vector binario es aquel cuyos atributos son todos binarios.

Distancia de Mahalanobis. La distancia de Mahalanobis considera la correlación existente entre las variables, al calcularse a partir de la inversa de la matriz de covarianza (Σ). Además, es de gran utilidad cuando los atributos tienen diferentes escalas, y la distribución de los datos es aproximadamente gaussiana [Tan et al., 2016].

$$mahalanobis(x, y) = (x - y)^T \Sigma^{-1} (x - y). \quad (4.38)$$

Correlación. La correlación analiza en qué medida dos variables se relacionan entre sí, por lo que suele utilizarse como métrica de similitud. En este sentido, el coeficiente de Pearson resulta de gran utilidad, al cuantificar la relación lineal existente entre dos variables, sin importar la escala de las mismas.

$$r_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y}, \quad (4.39)$$

donde σ_{xy} es la covarianza de las variables x y y , mientras que σ_x y σ_y representan la desviación estándar de las variables x y y respectivamente.

4.3.2.2. Algoritmos de agrupamiento

K-Means. K-Means es un algoritmo de agrupamiento particional, que consiste en definir k clústeres disjuntos, de forma tal, que se optimice un criterio de agrupamiento [Likas et al., 2003]. Este criterio, usualmente radica en la minimización de la suma del error cuadrado (SSE), es decir, minimizar la suma del cuadrado de la distancia de cada elemento a su respectivo centroide²⁵.

$$SSE = \sum_{i=1}^k \sum_{x \in C_i} distancia(c_i, x)^2, \quad (4.40)$$

donde k y c_i hacen referencia al número de clústeres y el centroide del i -ésimo clúster (C_i) respectivamente. La minimización de la SSE es un problema de optimización continua cóncava, cuya solución mínima local debe ser un número entero [Peng and Xia, 2005]. Motivo por el cual, se han estudiado varias estrategias de reducción de la SSE . Una estrategia para reducir la SSE es incrementar el número de clústeres; sin embargo, dicho incremento reduce la robustez del modelo. Por lo que, un agrupamiento óptimo de K-Means bajo este criterio, es aquel que minimiza la SSE , y hace uso del menor número de clústeres.

K-Means usualmente se asocia con la distancia euclídea y la SSE . Sin embargo, el criterio de agrupamiento y la métrica de distancia a emplear se seleccionan en base a los objetivos del agrupamiento y las características del conjunto de datos. Por ejemplo, otro criterio de agrupamiento válido, es maximizar la similitud entre las instancias que componen cada uno de los clústeres y sus respectivos centroides, lo cual suele conocerse como cohesión del clúster.

$$Total \ cohesion = \sum_{i=1}^k \sum_{x \in C_i} s_{cosine}(c_i, x). \quad (4.41)$$

²⁵De acuerdo con [Tan et al., 2016], el mejor centroide para minimizar la SSE de un clúster es la media de los puntos en el clúster.

K-Means se fundamenta en tres pasos principales: 1) la inicialización aleatoria de los centroides²⁶, 2) la asignación de cada una de las instancias al clúster cuyo centroide esté más próximo y 3) la redefinición de los centroides a partir de la media de las instancias pertenecientes a su respectivo clúster. Luego, el algoritmo itera sobre los pasos dos y tres, hasta que los centroides no varíen o dicha variación sea insignificante. En consecuencia, K-Means converge en pocas iteraciones, de forma tal, que tiene una complejidad computacional de $O(n \cdot k \cdot l \cdot d)$, donde n es el número de instancias, k es el número de clústeres, l es el número de iteraciones y d es el número de atributos.

Entre sus desventajas destaca que el número de clústeres debe definirse previamente, lo cual resulta un inconveniente, teniendo en cuenta que la selección del número de clústeres óptimo es un problema NP-duro²⁷. Motivo por el cual, han sido ideadas disímiles estrategias de selección del número de clústeres, tales como el método del codo y el coeficiente de silueta (S) [Kaufman and Rousseeuw, 2009]. El método del codo, utiliza la *SSE* como métrica de desempeño, y consiste en identificar el valor de k que satisfaga que un incremento del mismo no mejore sustancialmente la distancia media intra-clúster. Mientras que, el análisis de la silueta mide la calidad del agrupamiento a partir de la distancia entre los clústeres, tomando como resultado el valor de k que maximiza la media de los coeficientes de silueta.

$$S = \frac{b - a}{\max(a, b)}, \quad (4.42)$$

donde a y b son la distancia media intra-clúster y la distancia media a las instancias del clúster más cercano respectivamente. El cálculo de las matrices de distancia hace que este algoritmo tenga una complejidad temporal y espacial de $\Theta(N^2)$, siendo desaconsejado su empleo en conjuntos de datos de gran tamaño [Yuan and Yang, 2019].

Por otra parte, K-Means es susceptible a la presencia de valores atípicos en el conjunto de datos, los cuales distorsionan los centroides redefinidos. Asimismo, el carácter aleatorio de los centroides iniciales posibilita la existencia de clústeres vacíos. Motivo por el cual, se han propuesto varias soluciones, tales como el acercamiento incremental, el empleo de algoritmos de agrupamiento jerárquico y K-Means++.

El acercamiento incremental, consiste en la actualización de los centroides luego de cada asignación. Por otra parte, la selección de los centroides iniciales a partir de agrupamiento jerárquico radica en extraer k clústeres del agrupamiento jerárquico realizado y utilizar los centroides de éstos como centroides iniciales. En cambio, K-Means++ supone inicializar el primer centroide aleatoriamente, y elegir cada uno de los centroides restantes como el punto lo más lejos posible de los centroides ya existentes. No obstante, a pesar de las disímiles estrategias propuestas con el objetivo de reducir las sensibilidades de K-Means, éste resulta desacertado ante clústeres de diferentes tamaños, densidades o forma no globular, ya que K-Means tiende a hacer globos y agrupar las zonas más densas.

²⁶En el algoritmo K-Means los centroides iniciales no necesariamente coinciden con instancias ya existentes.

²⁷NP-duro es el conjunto de los problemas de decisión que contiene los problemas H tales que todo problema L en NP puede ser transformado polinomialmente en H .

Agrupamiento jerárquico. El agrupamiento jerárquico, consiste en la generación de conjuntos de clústeres anidados en forma de un árbol jerárquico, usualmente representado a través de un dendograma.

De manera general, existen dos tipos de agrupamiento jerárquico, el aglomerativo y el divisivo. En el primero, se parte de tantos clústeres como instancias, y en cada iteración se unen los dos clústeres más cercanos, hasta que se obtiene un único clúster, o los k clústeres deseados. Mientras que el segundo consiste en el proceso inverso, es decir, se parte de un único clúster compuesto por todas las instancias, y en cada iteración se divide un clúster, hasta que cada clúster contenga una única instancia o existan los k clústeres deseados. Ambas estrategias hacen uso de una matriz de distancia $D_{n \times n}$, la cual es una matriz simétrica, donde cada entrada D_{ij} representa la distancia existente entre el i -ésimo y j -ésimo clúster.

Sin importar el tipo de agrupamiento jerárquico a realizar, como resultado de la selección del par de clústeres más próximos, en cada iteración surge o se elimina un clúster, y por consiguiente, la matriz de distancia se modifica. Para ello, la distancia entre dos clústeres cualesquiera se cuantifica a través del empleo de una de las siguientes estrategias:

- **MIN:** se mide a partir de la mínima distancia existente entre dos instancias de distintos clústeres $A \in C_1$ y $B \in C_2$. La aplicación de esta estrategia tiene una complejidad temporal de $\Theta(n \cdot m)$, siendo n y m el número de instancias existentes en los clústeres.
- **MAX:** esta estrategia consiste en la máxima distancia existente entre dos instancias de distintos clústeres.
- **Group Average:** consiste en el promedio de las distancias de cada par de instancias pertenecientes a diferentes clústeres.
- **Distancia entre centroides:** esta estrategia consiste en la distancia entre los centroides de cada clúster.
- **Método de Ward:** consiste en el incremento de la SSE cuando se combinan dos clústeres.

Si bien el agrupamiento jerárquico no es susceptible a problemas de inicialización, ni requiere la definición previa del número de clústeres, las estrategias anteriores poseen varias ventajas y desventajas. MIN permite la agrupación de clústeres con forma no elíptica; no obstante, al solo considerar el par de instancias más cercanas de diferente clúster, es sensible a ruido y valores atípicos. Asimismo, MAX, *Group Average* y el método de Ward son menos susceptibles a ruido y valores atípicos, pero suelen generar grupos de forma globular.

DBSCAN. El agrupamiento espacial basado en densidad de aplicaciones con ruido (DBSCAN), como su nombre lo indica, es un algoritmo de agrupamiento basado en densidad, donde las regiones de alta densidad están separadas por regiones de baja densidad. Éste, hace uso de un enfoque de clústeres en torno a su centro, por lo que el análisis se fundamenta en la relación existente entre tres tipos de puntos: núcleo, frontera y ruido.

En este enfoque, la densidad para un punto cualquiera, se estima a partir del número de puntos dentro de su radio (Eps). Es decir, un punto de tipo núcleo es aquel que está en el interior de una región densa, y tiene al menos un número específico de puntos ($MinPts$) dentro de su radio. Asimismo, un punto de tipo frontera no es más que la arista o frontera de una región densa, es decir, es aquel que si bien no es un punto de tipo núcleo, se encuentra en el “vecindario” de éste. Mientras que, un punto se clasifica como ruido cuando está en una región escasamente poblada, es decir, es aquel que no es núcleo ni frontera. DBSCAN agrupa en un mismo clúster a cualesquiera dos puntos que estén lo suficientemente cerca dentro de una distancia Eps , asimismo con los puntos de tipo frontera. Por el contrario, omite los puntos que se clasifiquen como ruido; por lo que no produce agrupamientos completos.

DBSCAN es robusto ante ruido, valores atípicos y la existencia de clústeres de diferentes formas y tamaños. No obstante, es sensible ante la presencia de clústeres de diferentes densidades y conjuntos de datos de alta dimensionalidad. Esto último, a causa de la *maldición de la dimensión*²⁸, ya que, a medida que aumenta el número de dimensiones, también lo hace la distancia entre los puntos, lo cual dificulta la determinación del Eps .

4.3.2.3. Resultados del análisis exploratorio

Inicialmente, se estandarizó la información existente en los conjuntos de datos Top500 y SPECpower_ssj2008, y se redujo la dimensionalidad de este último a partir del PCA. Sin embargo, no se disminuyó la dimensionalidad del conjunto de datos Top500, en vista del número discreto de dimensiones presentes en éste y la sensibilidad de los algoritmos de reducción de dimensionalidad a los valores atípicos, aspectos analizados en la sección 4.2.7. Asimismo, se utilizó el coseno de similitud como métrica de similaridad, ya que la semejanza entre documentos suele ser cuantificada a partir de esta métrica. En consecuencia, se empleó la maximización de la cohesión total como criterio de agrupamiento.

Por otra parte, si bien se contempló la aplicación del codo para la selección del número de clústeres, diversos estudios lo clasifican como inadecuado [Yuan and Yang, 2019]. Éstos, destacan la influencia que tiene la relación existente entre los valores de k y SSE , en la identificación del punto de inflexión. Motivo por el cual, si el punto de inflexión no es obvio, puede dificultarse la identificación de k .

También, se consideró elegir el número de clústeres a partir del empleo de técnicas de agrupamiento espectral, tales como el Agrupamiento Espectral del Núcleo (KSC) [Langone et al., 2016] y la Silueta Global Espectral (GS) [Mur et al., 2016]. Sin embargo, dichas estrategias, al basarse en el algoritmo de Agrupamiento Espectral, poseen una alta complejidad computacional²⁹ y no garantizan valores elevados en los índices de validación interna para cada uno de los algoritmos de agrupamiento. En cambio, el coeficiente de silueta es considerada la métrica de validación interna más efectiva y generalizada [Moulavi et al., 2014], [Tomasini et al., 2016]. Así pues, la elección del número de clústeres y la evaluación de los agrupamientos se llevó a cabo a través del análisis de esta métrica.

²⁸El efecto Hughes o *maldición de la dimensionalidad* hace referencia a cómo la exactitud de un modelo tiende a decrecer a medida que el número de características se incrementa [Hughes, 1968].

²⁹El algoritmo Agrupamiento Espectral tiene una complejidad temporal de $O(n^3)$.

Determinar a priori los valores de los factores de entrada Eps y $MinPts$ del algoritmo DBSCAN, no es una tarea sencilla. Razón por la cual, se utilizó el algoritmo M\'etodo Din\'amico DBSCAN (DMDBSCAN) [Rahmah and Sitanggang, 2016], para determinar el valor \'optimo de Eps . DMDBSCAN consiste en calcular para cada punto, la distancia a los n puntos m\'as cercanos, y ordenarlas de forma ascendente. Luego, similar al m\'etodo del codo, se toma como Eps la distancia d\'onde el cambio en la gr\'afica es m\'as pronunciado. Las figuras 4.26 y 4.27 ilustran las distancias entre los sistemas presentes en los conjuntos de datos de SPECpower_ssj2008 y Top500, y sus correspondientes quintos vecinos m\'as cercanos.

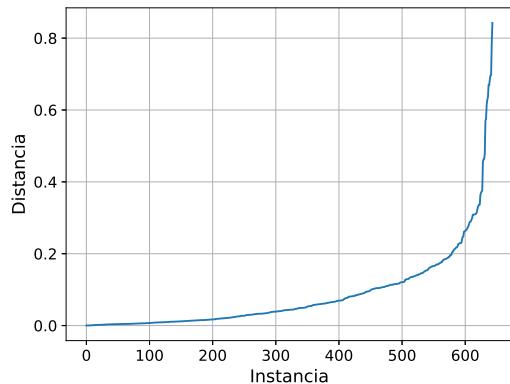


Figura 4.26: SPECpower_ssj2008: DMDBSCAN.

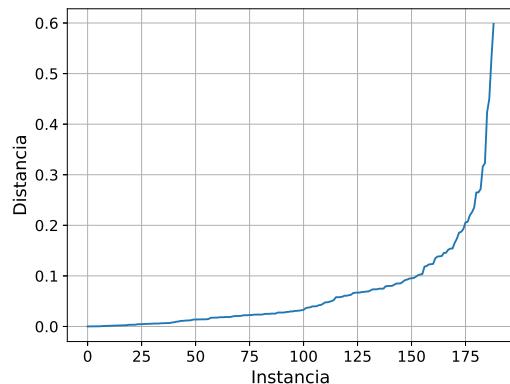


Figura 4.27: Top500: DMDBSCAN.

Las tablas 4.5 y 4.6 resumen los resultados obtenidos de la aplicaci\'on de diversos algoritmos de agrupamiento, en los conjuntos de datos de SPECpower_ssj2008 y Top500. Adem\'as, destaca el variado n\'umero de cl\'usteres utilizados en cada uno de los agrupamientos, a fin de maximizar el coeficiente de silueta, y la disimilitud de dichos coeficientes.

Algoritmo	No. cl\'usteres	No. Ruido	Coeficiente de silueta	Descripci\'on
Fuzzy C-Means	3		0.35643	
K-Medoides	2		0.33237	
DBSCAN	2	4	0.42475	Eps=0.3 MinPts=5
Agrupamiento Espectral	3		0.61612	
Esperanza m\'axima	10		0.15874	
K-means	2		0.34844	

Tabla 4.5: SPECpower_ssj2008: An\'alisis de agrupamiento

Algoritmo	No. cl\'usteres	No. Ruido	Coeficiente de silueta	Descripci\'on
Fuzzy C-Means	3		0.41515	
K-Medoides	4		0.21035	
DBSCAN	2	8	0.54149	Eps=0.16 MinPts=5
Agrupamiento Espectral	3		0.58699	
Esperanza m\'axima	4		0.57038	
K-means	3		0.50167	

Tabla 4.6: Top500: An\'alisis de agrupamiento

No obstante, el número de dimensiones existentes en ambos conjuntos dificultó la visualización de la distribución de los datos, y por consiguiente los clústeres resultantes. Además, una única métrica de validación interna puede resultar insuficiente para evaluar la calidad del agrupamiento, y más aún realizar comparaciones. Sin embargo, el principal objetivo de este análisis, no consistió en el agrupamiento de los datos, sino en la identificación de las variables de mayor relevancia para todos y cada uno de dichos agrupamientos.

Se estudiaron varias estrategias de selección de características, con el objetivo de identificar cuáles variables y en qué cuantía las mismas condicionaban la pertenencia a uno u otro clúster. Entonces, en base al impacto que tienen los valores atípicos en dichas estrategias, el análisis se realizó a partir de *Random Forest* y FCBF. Con este fin, se aplicaron ambas estrategias de selección de características en las particiones de los conjuntos de datos Top500 y SPECpower_ssj2008 generadas por los algoritmos de agrupamiento. Donde, como muestra la figura 4.28, destaca la influencia de las arquitecturas de Procesamiento Paralelo Masivo (MPP)³⁰ y clúster³¹ en la distinción de los sistemas. Para más información ver apéndice B.

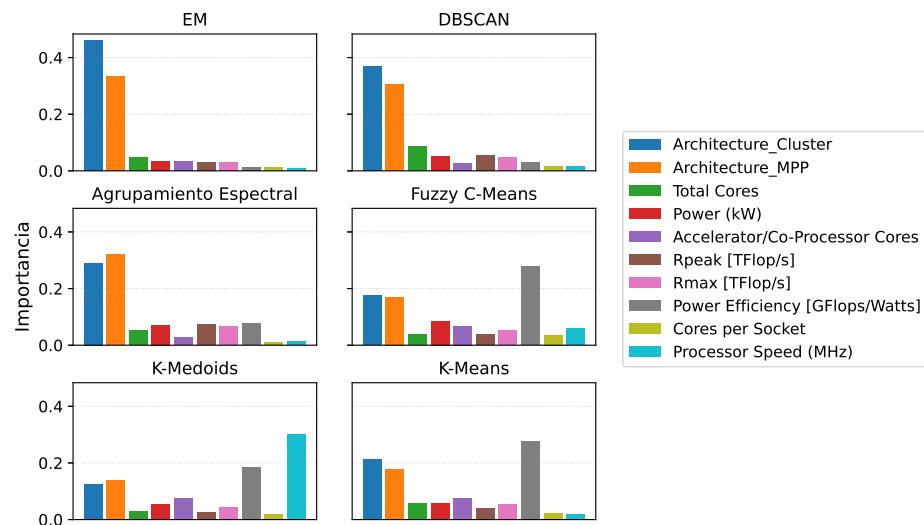


Figura 4.28: Top500: Selección de las características a partir de *Random Forest*.

Si bien la arquitectura es de las variables de mayor relevancia, también lo son el rendimiento, consumo de potencia y eficiencia energética. Sin embargo, resulta curioso la variabilidad de las características de mayor influencia en los distintos agrupamientos. De manera general, varios factores condicionan los resultados de un agrupamiento, tales como el tipo y criterio de agrupamiento, la métrica de distancia y las fortalezas de los diversos algoritmos ante ruido, valores atípicos y clústeres de diferentes formas, tamaños y densidades. Así pues, los resultados obtenidos son razonables, ya que solo la métrica de distancia y el criterio de agrupamiento son los parámetros comunes para los distintos algoritmos de agrupamiento.

³⁰MPP es un diseño de procesamiento paralelo, donde los nodos están herméticamente integrados, e interconectados mediante un enlace de alta velocidad. Además, cada nodo tiene su propio sistema operativo y memoria, por lo que el intercambio de información se realiza a través de la red de interconexión de nodos.

³¹El clúster es un tipo de arquitectura paralela distribuida, conformada por varios servidores independientes e interconectados.

Como resultado del análisis realizado, se concluyó que en los servidores de HPC, la diferenciación entre los sistemas está dada principalmente en función del rendimiento, consumo de potencia y eficiencia energética, sobre todo en niveles de carga discretos. Además, las restantes variables de mayor relevancia están directamente relacionadas con las anteriores, por lo que es innecesario su análisis. Por lo tanto, se procedió con la definición de un indicador multivariado, capaz de cuantificar la idoneidad de los servidores de HPC, en base a las características de su contexto de trabajo, y la influencia de estas últimas en el consumo de potencia. Para ello, se decidió hacer uso del conjunto de datos Top500, pues a diferencia de SPECpower_ssj2008, éste analiza el desempeño de los sistemas desde un entorno de HPC.

4.4. Indicador multivariado

A grandes rasgos, un indicador multivariado o compuesto, consiste en una métrica definida a partir de variables individuales, con el objetivo de describir un fenómeno complejo en general. [Freudenberg, 2003] definió a los indicadores multivariados como índices sintéticos de múltiples indicadores individuales. Asimismo, [Saisana and Tarantola, 2002] los definieron como indicadores basados en subindicadores, que no tienen una unidad de medida significativa común, y no hay una forma obvia de ponderar estos subindicadores.

El diseño de un indicador multivariado es un proceso que consta de diferentes etapas, las que van desde la definición del objetivo, hasta la validación de la propuesta. Sin embargo, diferentes autores destacan la falta de transparencia existente en ocasiones, durante la construcción de un indicador compuesto, fundamentalmente en las etapas de agregación, ponderación y análisis de robustez. Por lo que, a continuación se describen cada una de estas etapas y el análisis realizado en las mismas.

Marco conceptual. La definición del marco conceptual es la primera etapa del proceso de construcción de un indicador multivariado. Ésta, no solo sustenta de manera conceptual el desarrollo del indicador, sino que condiciona el análisis a realizar en las posteriores etapas. En consecuencia, el marco conceptual del presente trabajo, consiste en el planteamiento del problema descrito en la sección 1.2, el cual propició la propuesta del indicador compuesto.

Selección de los indicadores. Una vez definido el marco conceptual, se procede con la selección de las variables e indicadores a sintetizar. Con este fin, es crucial la selección de los índices de mayor relevancia, para con el fenómeno a describir e independencia estadística entre sí. No obstante, este último criterio no es del todo indispensable, pues durante el proceso de ponderación se suele dar menor peso a las variables altamente correlacionadas, a fin de evitar una doble contabilización³².

El estudio realizado en la sección 4.3.2.3 arrojó que el rendimiento, consumo de potencia y eficiencia energética son las variables de mayor relevancia en términos de distinción entre servidores de HPC. No obstante, el análisis multivariado previo destacó la existencia de una alta correlación entre los dos primeros. Por lo que, no tiene sentido el empleo de ambos, ni

³²La doble contabilización se refiere a ponderar implícitamente un indicador por encima del nivel deseado. Esto sucede cuando se incluyen dos indicadores colineales en el proceso de agregación, sin moderar su ponderación para este efecto.

reducir sus respectivos pesos con el objetivo de prevenir una doble contabilización. Asimismo, la eficiencia energética tiene una mayor correlación con el rendimiento que con el consumo de potencia. Motivo por el cual, resulta más adecuado definir el indicador compuesto en términos de potencia y eficiencia enérgética.

Imputación & Normalización. El preprocesamiento de los datos a emplear en el diseño del indicador compuesto, y específicamente la selección de las estrategias de imputación y normalización, condicionan significativamente las restantes etapas del proceso de construcción, y por consiguiente los resultados finales. Tomando como base el análisis realizado en las secciones 4.2.4 y 4.2.5, se decidió proseguir el estudio a partir de datos íntegros y sin previa transformación.

4.4.1. Ponderación

La ponderación es de las etapas de mayor incertidumbre en el diseño de un indicador compuesto, al no existir una metodología genérica para este fin, y dado que la propia ponderación posee múltiples interpretaciones. Por una parte, se refiere a la importancia explícita que se le atribuye a cada índice del indicador compuesto con respecto al resto; mientras que por otra, se relaciona con la importancia implícita de los atributos [Greco et al., 2019]. De ahí que, es deber del diseñador del índice la selección del enfoque que mejor se ajuste a sus objetivos.

No pesos o pesos iguales. Esta estrategia radica en no distribuir ponderaciones a los atributos, es decir, dar la misma importancia a todos los índices que componen el indicador. La misma, es de las técnicas más utilizadas debido a su simplicidad, y en ocasiones a causa de la falta de una estructura teórica, capaz de justificar un esquema de ponderación diferencial.

Pluralidad del sistema de ponderación. El que toma las decisiones elige entre una variedad de esquemas de ponderación, en base a la estructura y calidad de los datos o sus creencias.

Proceso de asignación de presupuesto. Consiste en asignar n puntos a un conjunto de tomadores de decisiones, los que distribuyen dichos puntos en los indicadores o grupos de indicadores, y luego utilizan un promedio de las elecciones de los expertos.

Proceso de jerarquía analítica. Se fundamenta en la traducción de un problema complejo a una jerarquía de tres niveles: el objetivo final, los criterios y las alternativas. Luego, los expertos asignan importancia a cada criterio con respecto al resto; lo cual no solo introduce una medida de coherencia, sino que además, reduce la predisposición de los pesos a errores de juicio.

Pesos basados en datos. Esta estrategia es más objetiva que las anteriores, al considerar enfoques, tales como el análisis de correlación, regresión y componentes principales.

El análisis de correlación tiene en cuenta la estructura y dinámica de los indicadores en el conjunto de datos. Consiste en seleccionar una variable distintiva x y extraer de las restantes variables la de mayor correlación con x , siendo el peso de cada variable el coeficiente de correlación al cuadrado.

Asimismo, el análisis de regresión lineal múltiple define las ponderaciones a partir del vínculo causal entre los subindicadores y el indicador de producto elegido. Por otra parte, el empleo del PCA como una técnica de obtención de peso, radica en utilizar como ponderaciones para los indicadores las cargas factoriales del primer componente. No obstante, en ocasiones, el primer componente resulta insuficiente para explicar una gran porción de la varianza de los datos, y son necesarios más componentes.

4.4.2. Agregación

La agregación, es la última etapa en la formación de un índice compuesto. En ésta, se define la estrategia de integración de los subindicadores en base a las características del problema y de los propios índices.

Agregación lineal. La agregación lineal (LIN) se utiliza cuando todos los indicadores poseen la misma escala. Éste, es un enfoque de agregación compensatoria, donde las ponderaciones deben percibirse como compensaciones entre los pares de indicadores, y no la importancia de las variables.

$$CI_s = \sum_{i=1}^Q w_q I_{qs}, \quad (4.43)$$

siendo CI_s el puntaje de un sistema s compuesto de Q variables, para cada una de las cuales w_q e I_{qs} se refieren al peso y valor respectivamente.

Agregación geométrica. La agregación geométrica (GME) es apropiada cuando los indicadores son estrictamente positivos, y se expresan en diferentes escalas de razón, reduciéndose así la compensabilidad cuando el indicador multivariado contiene indicadores con valores discretos.

$$CI_s = \prod_{i=1}^Q I_{qs}^{w_q}. \quad (4.44)$$

La definición del indicador compuesto se hizo en base al sistema hipotético aspirado por Geller, con un rendimiento de un *exaflop* y un consumo de potencia de 20 MW [Geller, 2011]. Además, se empleó la estrategia de agregación geométrica, pues el consumo de potencia y la eficiencia energética son variables de diferente escala, a la vez que no es objetivo dotar al indicador de un carácter compensatorio.

$$CI_s = \frac{\text{potencia}_s^{-\alpha} \cdot \text{eficiencia energética}_s^{\beta}}{\text{potencia}_{ref}^{-\alpha} \cdot \text{eficiencia energética}_{ref}^{\beta}}. \quad (4.45)$$

Por otra parte, las ponderaciones se definieron de forma tal, que se maximizase la distancia en términos de puntaje, entre el sistema de referencia antes mencionado, y todos los servidores presentes en el conjunto de datos Top500. Para ello, se evaluaron los sistemas que

integran el Top500 a partir de 100 simulaciones, las que consistieron en variar los valores de α y β . Específicamente, ambas ponderaciones, tomaron valores comprendidos entre 0.1 y 1, es decir, $\alpha, \beta \in [0.1, 1]$, siendo 0.1 el grado de relevancia más discreto con que se evaluó cada indicador. Además, se decidió no incrementar el rango de ponderación, a fin de no subestimar, ni sobreestimar ninguno de los índices. Entonces, por cada valor de α , se variaron los valores de β , de manera tal, que en cada iteración se incrementaba β en 0.1, y luego de considerar todos los posibles valores de β en su correspondiente intervalo, se reiniciaba el valor de este último y se incrementaba el valor de α en 0.1.

En este sentido, si bien valores elevados de α y β arrojaban valores superiores de CI , a la vez reducían la distancia entre los SUT y el sistema de referencia (ver figura 4.29). En consecuencia, esta distancia se maximizó solo en los casos donde β tomaba valores considerablemente superiores a los de α , exactamente $\alpha = 0.1$ y $\beta = 0.9$ o $\beta = 1$ (ver figura 4.30). Sin embargo, llamó la atención la modesta relevancia que tiene el consumo de potencia en el indicador propuesto. Así pues, resultó de interés considerar, si esto se debió a que la eficiencia energética, es la característica de mayor distanciamiento con respecto al sistema *exaflop* propuesto por Geller, o a la necesidad de transformar los datos, a fin de que las escalas de las variables no condicionen los resultados finales.

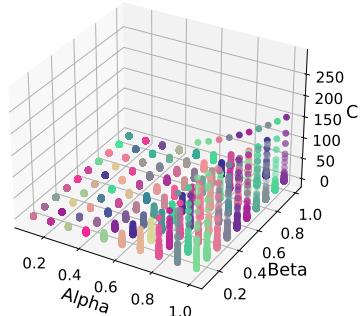


Figura 4.29: Análisis de calificaciones por niveles de ponderación.

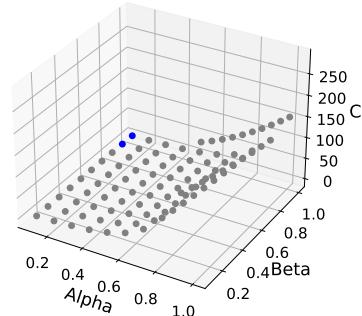


Figura 4.30: Análisis de ponderaciones en base a la función objetivo.

También, la selección de β entre los posibles valores 0.9 y 1, se realizó en términos del desplazamiento promedio (AvS). Éste, indica cuánto varía en promedio las calificaciones de los sistemas bajo diferentes circunstancias.

$$AvS = \frac{\sum_{i=1}^{|S|} |CI_{s_i, f} - CI_{s_i, f^*}|}{|S|}, \quad (4.46)$$

donde s_i es la i -ésima instancia del conjunto de datos S , mientras que f y f^* se refieren a diferentes configuraciones de los factores de entrada. En este caso, con la variación únicamente de β , se obtuvo un desplazamiento promedio de 0.03001. Por lo que, el indicador compuesto se definió de la siguiente forma

$$CI_s = \frac{potencia_s^{-1} \cdot eficiencia_energetica_s}{potencia_{ref}^{-1} \cdot eficiencia_energetica_{ref}}. \quad (4.47)$$

Si bien el proceso de construcción de un indicador compuesto puede ser transparente y bien fundamentado, etapas tales como la imputación, normalización y ponderación están condicionadas por criterios del desarrollador. En consecuencia, es imprescindible la validación del indicador, a fin de identificar cuán sensible es éste a variaciones, tanto de sus parámetros, como de las propias estrategias de diseño.

4.4.3. Análisis de robustez

Dado que la calidad de un modelo depende de la solidez de sus supuestos, es imprescindible la evaluación de las incertidumbres asociadas con el proceso de modelado y las elecciones subjetivas tomadas. Usualmente, la robustez de los indicadores compuestos se evalúa a partir de los análisis de incertidumbre y sensibilidad.

El análisis de incertidumbre se refiere a los cambios que se observan en el resultado final, al variar los factores de composición del índice. Es decir, se basa en simulaciones que se realizan en varias ecuaciones que constituyen el modelo subyacente. Entre los métodos de evaluación destaca la aproximación de Monte Carlo, la cual consiste en múltiples evaluaciones del modelo con k factores de entrada.

Para la simulación de los distintos escenarios de composición, se utilizaron como factores de incertidumbre, la estrategia de imputación (X_1), la estrategia de normalización (X_2), la estrategia de agregación (X_3) y las ponderaciones α y β (X_4 y X_5 respectivamente).

$$X_1 = \begin{cases} 0 & Listwise, \\ 1 & Media, \\ 2 & Moda, \\ 3 & Mediana, \\ 4 & KNN. \end{cases} \quad X_2 = \begin{cases} 0 & No \text{ normalizar}, \\ 1 & Min-Max, \\ 2 & Estandarización. \end{cases} \quad X_3 = \begin{cases} 0 & LIN, \\ 1 & GME. \end{cases}$$

Asimismo, las ponderaciones α y β se variaron a partir de la asignación de diez valores, que van desde 0.1 a 1 con incremento de 0.1. Entonces, las configuraciones se definieron a través de la combinación de los valores de los factores de entrada. Luego, se evaluó en cuáles de estas configuraciones, el sistema de referencia tenía calificaciones superiores a las de todos los SUT. Como resultado, de las 3000 simulaciones realizadas, solo en seis se satisfizo el criterio de selección. En éstas, si bien varió la estrategia de imputación, los valores de los restantes factores permanecieron estáticos (ver tabla 4.7). Además, el desplazamiento promedio de las calificaciones, en base a las distintas configuraciones de los factores de entrada, resultó despreciable.

Estrategia de Imputación	Estrategia de Normalización	Estrategia de Agregación	α	β
<i>Listwise</i>	No normalizar	GME	0.1	0.9
<i>Listwise</i>	No normalizar	GME	0.1	1.0
Media	No normalizar	GME	0.1	0.9
Media	No normalizar	GME	0.1	1.0
Mediana	No normalizar	GME	0.1	0.9
Mediana	No normalizar	GME	0.1	1.0

Tabla 4.7: Análisis de incertidumbre.

Por otra parte, el análisis de sensibilidad evalúa la contribución individual de los factores de entrada a la varianza de los datos, así como la varianza condicional correspondiente a dos o más factores. De manera general, la varianza aportada V_i por el i -ésimo factor de entrada X_i , se cuantifica como la cantidad de varianza esperada que se removería si se determinase el valor de X_i .

$$V_i = V_{X_i}(E_{X \sim i}(Y|X_i)). \quad (4.48)$$

Por lo que, la varianza total de un sistema $V(Y)$ puede ser descompuesta en dos términos, el efecto principal (V_i) y el efecto residual. Este último, representa la cantidad esperada de la varianza de salida que permanecería sin explicación, si el factor X_i fuese dejado en libertad sobre su rango de incertidumbre.

$$V_{X_i}(E_{X \sim i}(Y|X_i)) + E_{X_i}(V_{X \sim i}(Y|X_i)) = V(Y). \quad (4.49)$$

Asimismo, el índice de sensibilidad de primer orden S_i , se cuantifica como la contribución individual de X_i a $V(Y)$.

$$S_i = \frac{V_i}{V(Y)}. \quad (4.50)$$

Mientras que el índice de sensibilidad total S_{Ti} , considera la contribución de X_i a $V(Y)$, tanto en el primer orden, como en órdenes superiores, producto de la interacción con los restantes factores de entrada.

$$S_{Ti} = \frac{V(Y) - V_{X \sim i}(E_{X \sim i}(Y|X \sim i))}{V(Y)} = \frac{E_{X \sim i}(V_{X \sim i}(Y|X \sim i))}{V(Y)}. \quad (4.51)$$

Como resultado de la aplicación del análisis factorial fraccional [Saltelli et al., 2008], se obtuvo que la eficiencia energética y el consumo de potencia son, en todos los órdenes, de los factores de mayor impacto en la varianza del modelo. Mientras que, la ponderación asignada al consumo de potencia, y las estrategias de normalización y agregación poseen una menor relevancia (ver table 4.8).

	Estrategia de Imputación	β	Potencia	Eficiencia energética
Estrategia de Imputación	0.00325	-0.10879	-0.01097	0.00384
β	-0.10879	-0.01293	0.00384	-0.01097
Potencia	-0.01097	0.003841	-0.11094	-0.10879
Eficiencia energética	0.00384	-0.01097	-0.10879	0.36628

Tabla 4.8: Índices de sensibilidad de primer y segundo orden de los factores de entrada.

El análisis de robustez realizado corroboró no solo el impacto de los factores de entrada en las calificaciones finales de los sistemas, sino también, la relevancia de los mismos para con la varianza del modelo. Además, destacó que las escalas de las variables no condicionan la discreta relevancia del consumo de potencia en el indicador propuesto, sino que es la eficiencia energética, el principal elemento de distinción con respecto al sistema exaescala propuesto por Geller. De ahí que, luego de la validación del proceso de construcción del indicador compuesto, resta únicamente analizar las bondades y desventajas de éste, para con el análisis energético de servidores de HPC.

ESTA PÁGINA SE DEJÓ EN BLANCO INTENCIONALMENTE.

RESULTADOS Y DISCUSIÓN

El presente trabajo, se sustentó en el análisis de las tendencias y relaciones de varios indicadores de proporcionalidad y eficiencia energética, así como los factores más influyentes en el contexto de trabajo de los servidores de HPC. En lo que se refiere a indicadores de proporcionalidad energética, se concluyó que los sistemas cada vez desperdician menos potencia en estado inactivo, y de manera general, menor es la brecha de consumo de potencia con respecto a un comportamiento proporcionalmente energético. Sin embargo, la creciente carencia de linealidad en los sistemas, constituye el principal desafío en términos de proporcionalidad energética.

Por otra parte, la eficiencia energética, tanto promedio, como por nivel de utilización, es otro de los índices de mayor crecimiento en los servidores de HPC. No obstante, es errónea la relación que diversos estudios establecen entre la proporcionalidad y la eficiencia energética de los sistemas [Jiang et al., 2017]. Pues, mejoras en un indicador no necesariamente tiene un impacto directo en el otro. De ahí que, la amplitud de las zonas de alta eficiencia energética, no esté condicionada por la proporcionalidad energética de los medios de cómputo.

En términos de proporcionalidad energética, específicamente, con relación a la existencia de sistemas superproporcionales, destacó la influencia de diversos factores, tales como la eficiencia energética y el consumo de potencia en niveles discretos de carga de trabajo. Además, llamó aún más la atención, cuán determinante es en este sentido, la tecnología de los dispositivos de almacenamiento y el tipo de gabinete. Sobre todo, el tipo de gabinete es un elemento interesante a analizar, ya que tiene una estrecha relación con el sistema de disipación de calor, elemento que no suele ser considerado por los *benchmarks* de HPC, ni de consumo de energía.

En otro orden de ideas, durante la definición del indicador *REE*, [Hsu et al., 2012] consideraron la similitud de los *rankings* Top500 y Green500, ya que los sistemas de mayor rendimiento, eran también los de mayor eficiencia energética. Ésto, a causa de la alta correlación existente entre dichos indicadores. Asimismo, analizaron la influencia de la eficiencia energética en el *DR*, concluyendo que los sistemas de mayor proporcionalidad energética, poseían también mayor eficiencia energética. Sin embargo, con el paso de los años, este comportamiento ha variado significativamente. A continuación, se desarrolla el presente análisis a partir de 189 servidores que integran los conjuntos de datos Top500 y Green500.

En el Top500, como resultado del empleo del rendimiento como criterio de calificación, la curva de tendencia de este indicador, describe un comportamiento decreciente, a medida que aumenta la posición en el *ranking*. Además, el consumo de potencia y la eficiencia energética presentan variaciones abruptas, pues los sistemas de mayor rendimiento, no necesariamente son los de mayor eficiencia energética, ni consumo de potencia (ver figura 5.1).

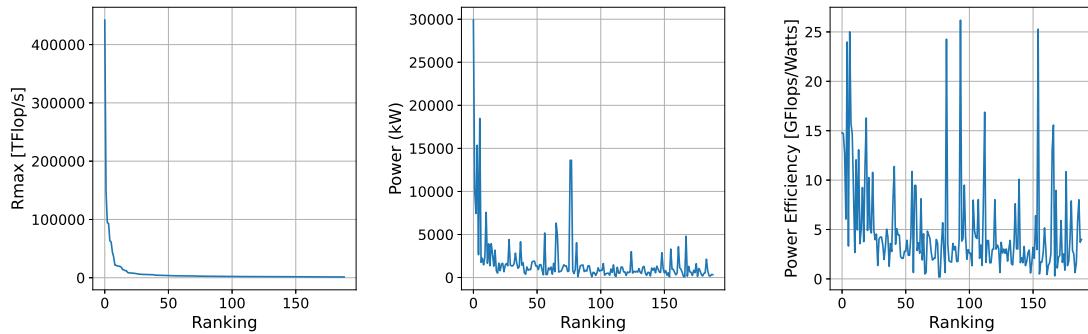


Figura 5.1: Top500: Tendencia de los índices a través del *ranking*.

Asimismo en el Green500, donde, si bien como se indicó en el capítulo 3, la eficiencia energética es el indicador que condiciona la calificación de los sistemas, son las curvas de tendencia del rendimiento y consumo de potencia las que carecen de un comportamiento monótono (ver figura 5.2). También, del empleo de la eficiencia energética como criterio de distinción, se obtuvieron más variaciones en los restantes indicadores, que al utilizar el rendimiento como criterio de calificación.

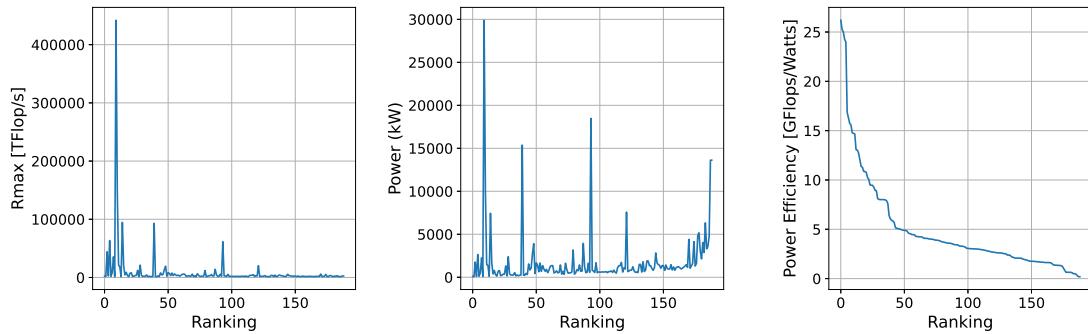


Figura 5.2: Green500: Tendencia de los índices a través del *ranking*.

Además, se estudiaron las bondades del indicador *REE* en relación con el análisis energético de los servidores de HPC. Este estudio, arrojó que dicho indicador resulta insuficiente para explicar los resultados obtenidos del análisis de agrupamiento realizado en la sección 4.3.2.3. Lo cual es lógico, si se considera el número de dimensiones que el PCA indicó son necesarias para explicar aproximadamente el 80 % de la varianza de los datos (ver sección 4.2.7, página 43).

REE tiene estrecha relación con el rendimiento de los sistemas y el total de núcleos existentes en los mismos. Sin embargo, tiene una baja correlación con los núcleos presentes en los aceleradores gráficos, procesadores y co-procesadores, así como con la arquitectura y la frecuencia base. Además, posee una correlación media y baja con el consumo de potencia y la eficiencia energética respectivamente (ver tabla 5.1). Por lo que, las calificaciones que éste asigna están principalmente en función del rendimiento de los equipos. Es decir, los sistemas de mayor calificación, sobresalen por su alto rendimiento y consumo de potencia, mientras que la eficiencia energética no es determinante, a pesar de ser uno de los índices utilizados para la definición de *REE*.

Total Cores	Accelerator/Co-Processor Cores	Rmax [TFlop/s]	Power (kW)	Power Efficiency [GFlops/Watts]	Processor Speed (MHz)	Cores per Socket
0.6120	0.2128	0.9818	0.6971	0.3534	0.0471	0.1658

Tabla 5.1: *REE*: Coeficientes de correlación de Pearson.

La figura 5.3 muestra el comportamiento de los índices de rendimiento, consumo de potencia y eficiencia energética, luego de ordenar descendenteamente los servidores a partir de su valor de *REE*. En esta figura, se observa la tendencia principalmente decreciente de los sistemas en términos de eficiencia energética. No obstante, dicho patrón es resultado de la correlación existente entre la eficiencia energética y el rendimiento, ya que la curva de tendencia de este último describe igual evolución y es menos accidentada.

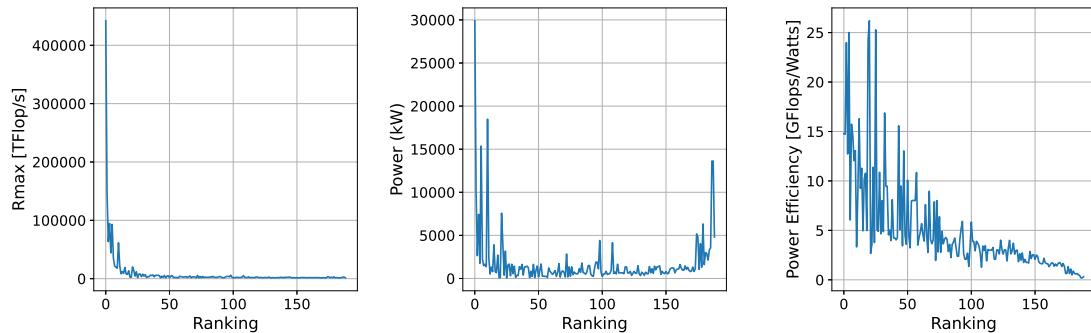


Figura 5.3: *REE*: Tendencia de los índices a través del ranking.

Con respecto al indicador propuesto en el presente trabajo, *CI* está altamente correlacionado con la eficiencia energética del medio de cómputo. Mientras que, posee una baja correlación con el rendimiento, consumo de potencia y características asociadas al procesador y la arquitectura del sistema (ver tabla 5.2). También, al igual que *REE*, el indicador *CI* resulta insuficiente para describir los agrupamientos realizados en la sección 4.3.2.3.

Total Cores	Accelerator/Co-Processor Cores	Rmax [TFlop/s]	Power (kW)	Power Efficiency [GFlops/Watts]	Processor Speed (MHz)	Cores per Socket
0.0523	0.1196	0.1704	-0.0816	0.9802	0.1549	0.1494

Tabla 5.2: *CI*: Coeficientes de correlación de Pearson.

Al calificar y ordenar descendenteamente los sistemas en función del indicador CI , destaca que la curva de tendencia de la eficiencia energética no es del todo decreciente (ver figura 5.4). No obstante, se evidencia el predominio de la eficiencia energética, en comparación con el resto de los índices, en términos de la calificación asignada a cada uno de los sistemas. Además, a diferencia de REE , en CI la curva de tendencia asociada al rendimiento no describe un patrón decreciente. Asimismo, el consumo de potencia no describe un comportamiento monótono, debido a la discreta ponderación asignada a este índice en el indicador CI . En consecuencia, al ser la eficiencia energética el factor preponderante, los sistemas de menor escala se verán beneficiados, puesto que suelen ser éstos los de mayor eficiencia energética.

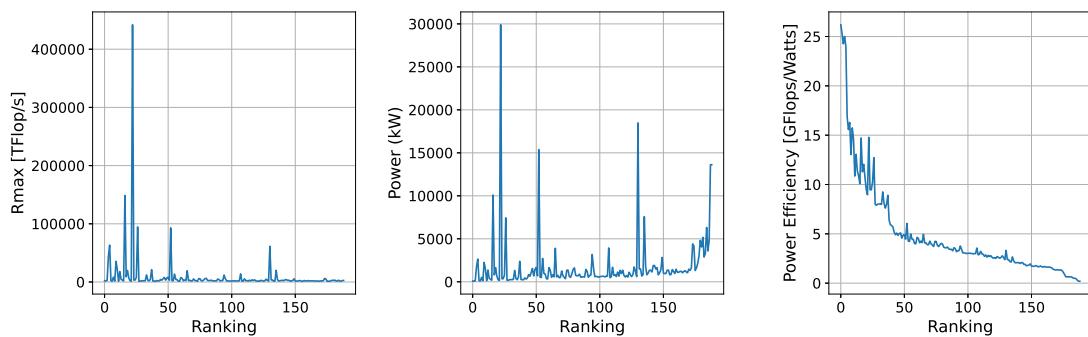


Figura 5.4: CI : Tendencia de los índices a través del *ranking*.

La figura 5.6 ilustra los sistemas cuyos CI se consideran atípicos según la estrategia de caja y bigotes (ver figura 5.5). Estos últimos, son en su mayoría sistemas de elevada eficiencia energética y discreto consumo de potencia. Sin embargo, destaca la existencia entre los sistemas atípicos de un equipo de elevado consumo de potencia. El mismo, es la supercomputadora Fugaku, actual ocupante de la primera y décima posición del Top500 y Green500 respectivamente. Lo que, ilustra cuán dominante es la eficiencia energética en el indicador propuesto. De forma tal, que un sistema de gran consumo de potencia puede alcanzar valores elevados de CI , si su eficiencia energética es lo suficientemente significativa.

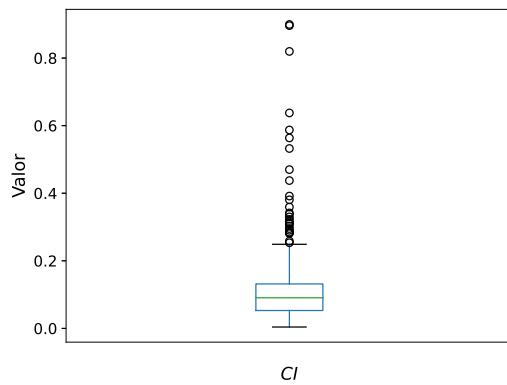


Figura 5.5: Top500: CI atípicos.

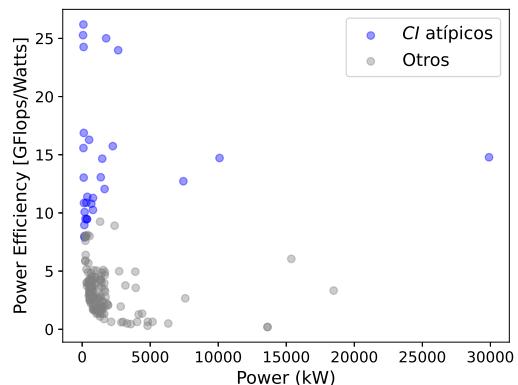


Figura 5.6: Top500: Sistemas con CI atípicos.

Por otra parte, se calificaron los sistemas presentes en el Top500 y Green500 a partir de los indicadores *REE* y *CI*, y se mantuvo la disposición original de ambos conjuntos de datos. Este análisis arrojó una mayor coincidencia entre el orden de los servidores en el Top500 y el *ranking* conformado en función del indicador *REE* (ver figura 5.7). Mientras, el *ranking* definido en base al indicador *CI* se asemeja más a la jerarquía de los sistemas en el Green500 (ver figura 5.8). Ésto, a causa de los índices preponderantes en ambos indicadores. Este estudio además, corroboró que la eficiencia energética es uno de los principales elementos de distinción de los servidores de HPC, siendo el criterio que mayor número de oscilaciones provocó en los restantes índices de análisis (ver tabla 5.3).

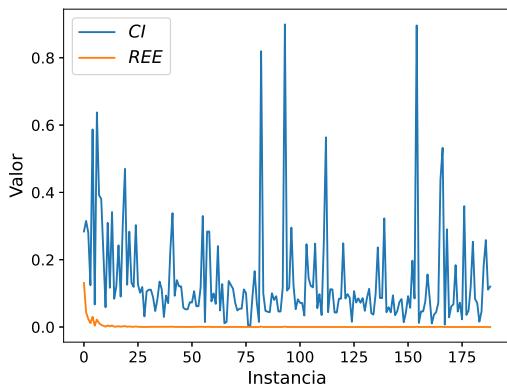


Figura 5.7: Top500: Tendencia de los indicadores *CI* y *REE*.

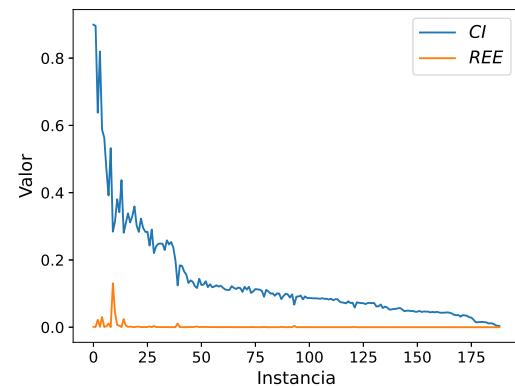


Figura 5.8: Green500: Tendencia de los indicadores *CI* y *REE*.

	Variaciones				Total
	Rmax [TFlop/s]	Power (kW)	Power Efficiency [GFlops/Watts]		
Top500	0	48	42		90
Green500	180	86	0		276
REE	88	93	69		250
CI	83	87	86		256

Tabla 5.3: Número de variaciones por criterio de ordenamiento.

Si bien *CI* a diferencia de *REE* no es susceptible a doble contabilización, las calificaciones que *CI* asigna están parcializadas a favor de la eficiencia energética. Por lo que, se cree aún más acertado el análisis conjunto a partir de los indicadores compuestos *CI* y *REE*. Puesto que, el primero cuantifica en qué medida el incremento de la eficiencia energética se debió a la reducción del consumo de potencia. Mientras que el segundo, si bien tiene en cuenta la eficiencia energética, al considerar el rendimiento de los equipos, centra el análisis en los servidores de HPC. Por lo que se redefiniría *REE* de la siguiente forma:

$$REE = \frac{(rendimiento_s)^\alpha \cdot (eficiencia\ energética_s)^\beta}{(rendimiento_{ref})^\alpha \cdot (eficiencia\ energética_{ref})^\beta}, \quad (5.1)$$

donde las ponderaciones α y β no variarían su valor original, es decir $\alpha = \beta = 1$, puesto que estos valores maximizan la distancia entre el sistema de referencia y los SUT.

Similar al EDD, la construcción de un diagrama a partir de los indicadores CI y REE , permite el análisis de la distancia entre los SUT y el sistema de referencia, en términos de los principales índices. Donde, el sistema de referencia se representa a partir de la coordenada (1,1), y cada uno de los cuadrantes en torno a la misma, agrupa sistemas cuyo rendimiento y eficiencia energética poseen un comportamiento específico, en comparación con el sistema de referencia. De forma tal, que el primer cuadrante aglomera a aquellos SUT que poseen mayor rendimiento y eficiencia energética que el sistema de referencia, el tercer cuadrante ilustra el caso opuesto, y el segundo y cuarto cuadrante representan las compensaciones.

Los sistemas presentes en el Top500 tienen valores inferiores de REE y CI , en comparación con el sistema exaescala propuesto por Geller. Lo cual, es evidente, ya que fue uno de los criterios de construcción del indicador CI , y puesto que el sistema de referencia tiene un mayor rendimiento y eficiencia energética que todos los servidores presentes en el Top500. La figura 5.9 ilustra un mayor distanciamiento de los sistemas exaescala, en términos de rendimiento y eficiencia energética, así como una cada vez mayor influencia de la reducción del consumo de potencia en la eficiencia energética de los sistemas.

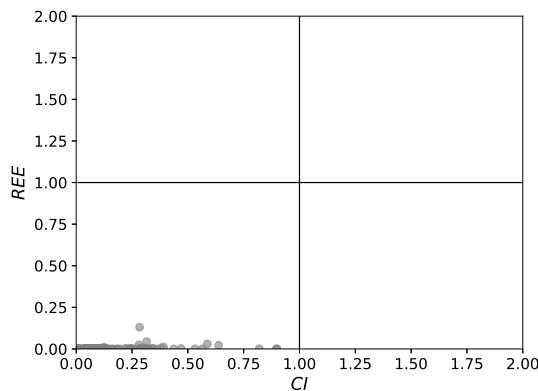


Figura 5.9: Top500: Diagrama CI - REE .

Entonces, al ser la eficiencia energética y el consumo de potencia elementos de distinción entre los servidores de HPC, y ya que, la maximización de la eficiencia energética y la reducción del consumo de potencia son dos de los principales desafíos del desarrollo de sistemas exaescala, el indicador CI resulta un índice de utilidad para el estudio de las tendencias de las actuales y futuras estrategias de administración de energía. Además, como se destacó anteriormente, los indicadores REE y CI dan mayor relevancia a un determinado índice con respecto al resto, no obstante, CI es más equilibrado, por lo que es de utilidad para considerar varias características de los servidores de HPC.

CONCLUSIONES Y TRABAJO FUTURO

El estudio realizado, destacó la relevancia que tienen factores, tales como el tipo de gabinete y el sistema de refrigeración, para con la proporcionalidad energética de los servidores de HPC. A la vez que, rebatió, en función del indicador *EP*, la afirmación que realizaron [Hsu and Poole, 2015] referente a que, las mejoras en la proporcionalidad energética de los sistemas, tienen un impacto directo en la eficiencia energética de los mismos. De ahí que, se rechazara el planteamiento realizado por [Jiang et al., 2017], acerca de que la *EP* de los sistemas condiciona la amplitud de las zonas de alta eficiencia energética.

Si bien el análisis energético desarrollado se centró en el indicador *EP*, los resultados del estudio no habrían variado significativamente, de haberse enfocado la investigación en el indicador *DR*. Ésto, a causa de la alta correlación existente entre dichos indicadores, y el discreto margen de error que se obtuvo de la aproximación de la *EP*, a partir del *DR* y la *LD*. Aproximación mediante la cual, se concluyó que las futuras mejoras en la *EP*, y de manera general en materia de proporcionalidad energética, deben enfocarse principalmente en maximizar la linealidad de los sistemas. Pues, si bien cada vez es menor el consumo de potencia en estado *idle*, en los restantes niveles de utilización dicho consumo es progresivamente menos proporcional. Además, los resultados de esta investigación, muestran la insuficiente contribución de los indicadores de proporcionalidad y eficiencia energética considerados, para con el análisis energético de los servidores de HPC.

Esta investigación dio respuesta a muchas de las interrogantes planteadas por [Varsamopoulos and Gupta, 2010]. Demostró que la técnica DVFS, no solo no garantiza la proporcionalidad energética de los sistemas, sino que en un futuro cercano tendrá una menor incidencia en el ahorro de energía, hasta quedar obsoleta, a causa de un cada vez menor voltaje de operación de los núcleos presentes en los procesadores. También, se considera que la proporcionalidad energética continuará siendo relevante en los modos de suspensión e hibernación de los servidores, pues muchos servidores de HPC consumen una cantidad de potencia considerable en estado inactivo.

Por otra parte, del análisis de las tendencias actuales de diseño de servidores, se vaticina el estancamiento de la frecuencia base de los procesadores, fenómeno con discretas variaciones en la última década. Pues, el incremento de la frecuencia base de los procesadores aumenta el rendimiento de los equipos de cómputo, pero también el consumo de potencia

dinámica, y por consiguiente energía. Además, si bien el número de núcleos presentes en los procesadores continuará en aumento, el incremento de los mismos se verá truncado, a menos que se ideen nuevas estrategias de administración de energía, o se incremente la eficiencia energética de estos últimos. Ya que, seguir aumentando el número de núcleos por *chip*, manteniendo la potencia y la temperatura a un nivel manejable, es en la actualidad, la principal interrogante de muchos trabajos de investigación.

La arquitectura, el rendimiento, el consumo de potencia y la eficiencia energética son varios de los elementos de distinción de los servidores de HPC. Pero, es la eficiencia energética, y no la proporcionalidad energética uno de los principales desafíos en el diseño de sistemas exaescala. Sin embargo, las actuales carencias en ambos conceptos, son resultado de las deficientes estrategias de administración de energía existentes. De ahí que, es vital el desarrollo y empleo de nuevas estrategias de administración de energía, que posibiliten el incremento de la eficiencia energética, en base a la disminución del consumo de potencia, y no el incremento del rendimiento.

El indicador propuesto es insuficiente por si solo para realizar el análisis energético de los servidores de HPC. No obstante, es de gran utilidad en este sentido, pues tiene en cuenta dos de los aspectos más determinantes en el desarrollo de sistemas exaescala. Entonces, se considera que el empleo de *CI* puede resultar beneficioso para el aprovisionamiento de servidores y el desarrollo de estrategias de administración de energía. Por lo que, se recomienda que estudios futuros aborden la tendencia del indicador *CI*, tanto en el estado *peak*, como en los restantes niveles de utilización, y la relación existente entre este indicador y los indicadores de proporcionalidad energética estudiados.

A fin de incrementar la proporcionalidad y eficiencia energética, reducir el consumo de potencia, y finalmente desarrollar sistemas exaescala, se han realizado gran variedad de investigaciones. Sin embargo, la profundidad de las mismas se ha visto limitada a causa de un déficit de información. Además, los *benchmarks* actuales resultan necesarios, pero no suficientes. Por lo que, se carece de un *benchmark* de HPC con un enfoque gradual de carga de trabajo, que considere el impacto energético, tanto de los nodos de forma individual, como de los diferentes componentes de *hardware* y *software*. Asimismo, un *benchmark* idóneo de HPC, debe ser también capaz de simular el usual contexto de trabajo y tareas que suelen procesar estos servidores.

En vista del modesto cúmulo de información de que se dispuso para la realización de este estudio, y la carencia de un *benchmark* adecuado para con el análisis energético de servidores de HPC, se considera provechoso el desarrollo de futuros trabajos investigativos sobre el presente tema, que profundicen en la influencia del DVFS en el ahorro energético en arquitecturas modernas. Además, entre las preguntas que se derivan de los resultados obtenidos en esta investigación se encuentra ¿qué impacto tiene el tipo de gabinete, las arquitecturas heterogéneas y el sistema operativo, en especial el calendarizador de procesos, en materia de proporcionalidad energética? Dado que estas interrogantes requieren investigación adicional, se considera imprescindible desarrollar en el corto plazo, un estudio que examine cuán adecuadas son varias de las vigentes políticas de calendarización, en función del ahorro energético de los servidores de HPC.

APÉNDICE A

ESQUEMAS LÓGICOS

En el presente apéndice, se describen los esquemas lógicos de los conjuntos de datos de SPECpower_ssj2008, Top500 y Green500, con el objetivo de detallar los factores que consideran cada uno de dichos conjuntos, y facilitar la comprensión del análisis realizado durante la etapa de preprocesamiento de datos.

El conjunto de datos de SPECpower_ssj2008, se compone de un total de 734 instancias. Las cuales, a su vez, constan de 87 atributos, distribuidos en 29 variables discretas, 23 variables continuas, 30 variables nominales y 5 variables ordinales, siendo además, todas ellas, variables de entrada (ver tabla A.1).

Característica	Tipo de variable	Descripción
Benchmark	Nominal	Nombre del <i>benchmark</i>
Benchmark Version	Continua	Versión del <i>benchmark</i>
Hardware Vendor	Nominal	Proveedor del <i>hardware</i>
System	Nominal	Nombre del sistema bajo prueba
Nodes	Discreta	Número de nodos
Form Factor	Nominal	Tipo de gabinete
Test Method	Nominal	Método de prueba utilizado
Result	Continua	Eficiencia energética promedio
ssj_ops @ 100 % of target load	Discreta	Rendimiento al 100 % de trabajo
ssj_ops @ 90 % of target load	Discreta	Rendimiento al 90 % de trabajo
ssj_ops @ 80 % of target load	Discreta	Rendimiento al 80 % de trabajo
ssj_ops @ 70 % of target load	Discreta	Rendimiento al 70 % de trabajo
ssj_ops @ 60 % of target load	Discreta	Rendimiento al 60 % de trabajo
ssj_ops @ 50 % of target load	Discreta	Rendimiento al 50 % de trabajo
ssj_ops @ 40 % of target load	Discreta	Rendimiento al 40 % de trabajo
ssj_ops @ 30 % of target load	Discreta	Rendimiento al 30 % de trabajo
ssj_ops @ 20 % of target load	Discreta	Rendimiento al 20 % de trabajo
ssj_ops @ 10 % of target load	Discreta	Rendimiento al 10 % de trabajo
Average watts @ 100 % of target load	Continua	Potencia al 100 % de trabajo
Average watts @ 90 % of target load	Continua	Potencia al 90 % de trabajo
Average watts @ 80 % of target load	Continua	Potencia al 80 % de trabajo
Average watts @ 70 % of target load	Continua	Potencia al 70 % de trabajo
Average watts @ 60 % of target load	Continua	Potencia al 60 % de trabajo
Average watts @ 50 % of target load	Continua	Potencia al 50 % de trabajo
Average watts @ 40 % of target load	Continua	Potencia al 40 % de trabajo
Average watts @ 30 % of target load	Continua	Potencia al 30 % de trabajo
Average watts @ 20 % of target load	Continua	Potencia al 20 % de trabajo
Average watts @ 10 % of target load	Continua	Potencia al 10 % de trabajo
Performance/power @ 100 % of target load	Continua	Eficiencia al 100 % de trabajo

Característica	Tipo de variable	Descripción
Performance/power @ 90 % of target load	Continua	Eficiencia al 90 % de trabajo
Performance/power @ 80 % of target load	Continua	Eficiencia al 80 % de trabajo
Performance/power @ 70 % of target load	Continua	Eficiencia al 70 % de trabajo
Performance/power @ 60 % of target load	Continua	Eficiencia al 60 % de trabajo
Performance/power @ 50 % of target load	Continua	Eficiencia al 50 % de trabajo
Performance/power @ 40 % of target load	Continua	Eficiencia al 40 % de trabajo
Performance/power @ 30 % of target load	Continua	Eficiencia al 30 % de trabajo
Performance/power @ 20 % of target load	Continua	Eficiencia al 20 % de trabajo
Performance/power @ 10 % of target load	Continua	Eficiencia al 10 % de trabajo
# Cores	Discreta	Número total de núcleos
# Chips	Discreta	Número de procesadores
# Cores Per Chip	Discreta	Número de núcleos por procesador
# Threads Per Core	Discreta	Número de hilos por núcleo
Processor	Nominal	Nombre del procesador
Processor MHz	Discreta	Frecuencia base del procesador
Processor Characteristics	Nominal	Descripción del procesador
CPU(s) Orderable	Nominal	Número de CPUs
1st Level Cache	Nominal	Descripción de la caché de 1 ^{er} nivel
2nd Level Cache	Nominal	Descripción de la caché de 2 ^{do} nivel
3rd Level Cache	Nominal	Descripción de la caché de 3 ^{er} nivel
Other Cache	Nominal	Descripción de otras memorias cachés
Memory (GB)	Discreta	Almacenamiento en la RAM
Operating System	Nominal	Nombre del sistema operativo
Operating System Version	Nominal	Versión del sistema operativo
File System	Nominal	Tipo de sistema de archivos
DIMMS	Nominal	Módulos de RAM
Memory Description	Nominal	Descripción de la RAM
Network Controller	Discreta	Número de controladores de red
NICs Connected	Discreta	Tarjetas de red conectadas
NICs enabled (firmware)	Discreta	Tarjetas de red activas en el <i>firmware</i>
NICs enabled (OS)	Discreta	Tarjetas de red activas en el sistema operativo
Network speed	Discreta	Velocidad de red
JVM Vendor	Nominal	Proveedor de la JVM
JVM Version	Nominal	Versión de la JVM
JVM Instances	Discreta	No. de instancias de la JVM
JVM Affinity	Nominal	Comandos utilizados para configurar la afinidad para cada JVM
JVM Bitness	Discreta	Tamaño del puntero
JVM Options	Nominal	Opciones de la línea de comandos de JVM utilizadas
Initial Heap	Discreta	Tamaño inicial de la pila de la JVM
Max Heap	Discreta	Tamaño máximo de la pila de la JVM
System Source	Nominal	Estrategia de ensamblado del sistema
System Designation	Nominal	Clasificación del sistema
Power Provisioning	Nominal	Tipo de fuente de alimentación
Disk Drive	Nominal	Descripción de las unidades de disco
Disk Controller	Nominal	Proveedor del controlador de discos
Power Management	Nominal	Habilitación de las funciones de administración de energía
Power Supply Details	Nominal	Descripción de las fuentes de energía
Power Supplies Installed	Discreta	No. de fuentes de energía instaladas
Power Supply Rating (watts)	Discreta	Potencia total disponible
HW Avail	Ordinal	Fecha en que los requerimientos de hardware estuvieron disponibles
SW Avail	Ordinal	Fecha en que los requerimientos de software estuvieron disponibles
License	Discreta	No. de licencia del probador
Tested By	Nominal	Probador
Test Sponsor	Nominal	Patrocinador de la prueba
Test Date	Ordinal	Fecha de evaluación
Published	Ordinal	Fecha de publicación

Característica	Tipo de variable	Descripción
Updated	Ordinal	Fecha de actualización

Tabla A.1: SPECpower_ssj2008: Esquema lógico.

Asimismo, el conjunto de datos Top500 se compone de 35 atributos, distribuidos en 19 variables nominales, 4 variables continuas y 12 variables discretas, todas ellas variables de entrada (ver tabla A.2).

Característica	Tipo de variable	Descripción
Rank	Discreta	Posición en el <i>ranking</i>
Previous Rank	Discreta	Posición anterior inmediata en el <i>ranking</i>
Name	Nominal	Nombre asignado a la supercomputadora
Computer	Nominal	Descripción general de la supercomputadora
Site	Nominal	Instalación que opera la supercomputadora
Manufacturer	Nominal	Fabricante
Country	Nominal	País
Year	Discreta	Año de instalación o de mayor actualización
Segment	Nominal	Sector de desempeño
Total Cores	Discreta	No. total de núcleos
Accelerator/Co-Processor Cores	Discreta	No. de núcleos en el acelerador o coprocesador
Rmax [TFlop/s]	Continua	Rendimiento máximo en el <i>benchmark</i> LINPACK
Rpeak [TFlop/s]	Continua	Rendimiento máximo teórico
Nmax	Discreta	Tamaño del problema para el cual se obtuvo Rmax
Nhalf	Discreta	Tamaño del problema para lograr la mitad de Rmax
HPCG [TFlop/s]	Continua	Rendimiento alcanzado en el <i>benchmark</i> HPCG
Power (kW)	Discreta	Potencia consumida
Power Source	Nominal	Fuente de alimentación
Power Efficiency [GFlops/Watts]	Continua	Eficiencia energética del sistema
Architecture	Nominal	Arquitectura de diseño
Processor	Nominal	Procesador
Processor Technology	Nominal	Nombre de la tecnología utilizada por el procesador
Processor Speed (MHz)	Discreta	Frecuencia base del procesador
Operating System	Nominal	Sistema operativo
OS Family	Nominal	Familia del sistema operativo
Accelerator/Co-Processor	Nominal	Descripción del acelerador/coprocesador
Cores per Socket	Discreta	No. de núcleos por procesador
Processor Generation	Nominal	Generación del procesador
System Model	Nominal	Modelo del servidor
System Family	Nominal	Familia del servidor
Interconnect Family	Nominal	Familia de red de interconexión
Interconnect	Nominal	Red de interconexión
Continent	Nominal	Continente
Site ID	Discreta	Identificador de la instalación
System ID	Discreta	Identificador del sistema

Tabla A.2: Top500: Esquema lógico.

Por otra parte, el conjunto de datos Green500 se compone de 35 variables, desglosadas en 19 variables nominales, 4 variables continuas y 12 variables discretas (ver tabla A.3).

Característica	Tipo de variable	Descripción
Rank	Discreta	Posición en el <i>ranking</i>
TOP500 Rank	Discreta	Posición en el <i>ranking</i> del Top500
Name	Nominal	Nombre asignado a la supercomputadora
Computer	Nominal	Descripción general de la supercomputadora
Site	Nominal	Instalación que opera la supercomputadora
Manufacturer	Nominal	Fabricante
Country	Nominal	País
Year	Discreta	Año de instalación o de mayor actualización
Segment	Nominal	Sector de desempeño
Total Cores	Discreta	No. total de núcleos
Accelerator/Co-Processor Cores	Discreta	No. de núcleos en el acelerador o coprocesador
Rmax [TFlop/s]	Discreta	Rendimiento máximo en el <i>benchmark</i> LINPACK
Rpeak [TFlop/s]	Discreta	Rendimiento máximo teórico
Power (kW)	Continua	Potencia consumida
Power Source	Nominal	Fuente de alimentación
Power Efficiency [GFlops/Watts]	Continua	Eficiencia energética del sistema
Power Quality Level	Discreta	Nivel de calidad de la energía
Optimized Run (HPL)	Continua	Rendimiento alcanzado en el <i>benchmark</i> HPL
Optimized Run (Peak Power)	Continua	Potencia consumida en el <i>benchmark</i> HPL
Architecture	Nominal	Arquitectura de diseño
Processor	Nominal	Procesador
Processor Technology	Nominal	Nombre de la tecnología utilizada por el procesador
Processor Speed (MHz)	Discreta	Frecuencia base del procesador
Operating System	Nominal	Sistema operativo
OS Family	Nominal	Familia del sistema operativo
Accelerator/Co-Processor	Nominal	Descripción del acelerador/coprocésador
Cores per Socket	Discreta	Número de núcleos por procesador
Processor Generation	Nominal	Generación del procesador
System Model	Nominal	Modelo del servidor
System Family	Nominal	Familia del servidor
Interconnect Family	Nominal	Familia de red de interconexión
Interconnect	Nominal	Red de interconexión
Continent	Nominal	Continente
Site ID	Discreta	Identificador de la instalación
System ID	Discreta	Identificador del sistema

Tabla A.3: Green500: Esquema lógico.

APÉNDICE B

SELECCIÓN DE CARACTERÍSTICAS

La tabla B.1 describe la influencia de las características que integran el conjunto de datos de SPECpower_ssj2008, en términos de superproporcionalidad energética. Ésto, en base a las estrategias de selección de características *Random Forest* y el estadístico χ^2 .

<i>Random Forest</i>		χ^2	
Característica	Score	Característica	Score
Performance/power @ 100 % of target load	0.05570	Performance/power @ 10 % of target load	5.40604
Processor Turbo Boost	0.05058	Performance/power @ 20 % of target load	5.11908
Performance/power @ 70 % of target load	0.04604	Performance/power @ 30 % of target load	4.66256
Performance/power @ 60 % of target load	0.04579	Performance/power @ 40 % of target load	4.47246
Average watts @ 10 % of target load	0.04048	Performance/power @ 50 % of target load	3.98179
Performance/power @ 80 % of target load	0.03955	Performance/power @ 60 % of target load	3.46414
Processor MHz	0.03872	Performance/power @ 70 % of target load	2.99726
Performance/power @ 90 % of target load	0.03582	Form Factor_2U	2.66364
Average watts @ active idle	0.03517	Disk Drive Technology_SATA	2.53922
Performance/power @ 40 % of target load	0.03335	Performance/power @ 80 % of target load	2.50960
Average watts @ 20 % of target load	0.03079	Form Factor_blade	2.21153
Performance/power @ 10 % of target load	0.03070	Performance/power @ 90 % of target load	1.70514
Performance/power @ 30 % of target load	0.02938	Disk Drive Technology_SSD	1.22097
ssj_ops @ 30 % of target load	0.02829	Average watts @ active idle	0.99795
Performance/power @ 50 % of target load	0.02788	Disk Drive Technology_SAS	0.99358
Average watts @ 60 % of target load	0.02645	Processor Turbo Boost	0.95420
Performance/power @ 20 % of target load	0.02638	Processor MHz	0.94021
Average watts @ 100 % of target load	0.02637	Performance/power @ 100 % of target load	0.89872
Average watts @ 90 % of target load	0.02334	Average watts @ 10 % of target load	0.82468
ssj_ops @ 40 % of target load	0.02196	Average watts @ 50 % of target load	0.81903
Average watts @ 30 % of target load	0.02145	Average watts @ 60 % of target load	0.81245
Average watts @ 40 % of target load	0.02111	Average watts @ 40 % of target load	0.81169
ssj_ops @ 20 % of target load	0.01933	Average watts @ 70 % of target load	0.80784
ssj_ops @ 50 % of target load	0.01913	Average watts @ 20 % of target load	0.78960
Average watts @ 70 % of target load	0.01902	Average watts @ 30 % of target load	0.78536
# Cores Per Chip	0.01745	Average watts @ 80 % of target load	0.76514
ssj_ops @ 60 % of target load	0.01737	Form Factor_other	0.73717
Average watts @ 50 % of target load	0.01717	File System_btrfs	0.70512
ssj_ops @ 90 % of target load	0.01690	Nodes	0.67560
Power Supply Rating (watts)	0.01440	Average watts @ 90 % of target load	0.65831
Average watts @ 80 % of target load	0.01437	File System_XFS	0.65034
ssj_ops @ 80 % of target load	0.01419	Form Factor_7U	0.51282
ssj_ops @ 100 % of target load	0.01368	Average watts @ 100 % of target load	0.51164
Power Supplies Installed	0.01303	# Cores Per Chip	0.50199
ssj_ops @ 10 % of target load	0.01279	# Chips	0.44168
ssj_ops @ 70 % of target load	0.01265	Disk Drive Amount	0.35256
# Cores	0.01015	# Cores	0.35214
GB per Disk Drive	0.00790	# Threads Per Core	0.26538

<i>Random Forest</i>		χ^2	
Memory (GB)	0.00686	ssj_ops @ 90 % of target load	0.19001
Operating System Family_Microsoft Windows	0.00506	ssj_ops @ 80 % of target load	0.18984
# Chips	0.00307	Power Supplies Installed	0.18963
Form Factor_1U	0.00246	ssj_ops @ 40 % of target load	0.18963
Form Factor_2U	0.00208	ssj_ops @ 70 % of target load	0.18942
File System_NTFS	0.00136	ssj_ops @ 20 % of target load	0.18936
Disk Drive Technology_SATA	0.00116	ssj_ops @ 50 % of target load	0.18926
File System_XFS	0.00110	ssj_ops @ 10 % of target load	0.18920
Operating System Family_Linux	0.00085	ssj_ops @ 60 % of target load	0.18896
Disk Drive Technology_SSD	0.00046	ssj_ops @ 30 % of target load	0.18889
Form Factor_4U	0.00040	ssj_ops @ 100 % of target load	0.18751
Nodes	8.59E-05	Form Factor_3U	0.16025
Form Factor_7U	0	Form Factor_10U	0.16025
Form Factor_Tower	0	Form Factor_1U	0.15200
Form Factor_bla	0	Form Factor_5U	0.12820
Form Factor_other	0	Memory (GB)	0.11406
Form Factor_3U	0	GB per Disk Drive	0.11079
Form Factor_12U	0	Form Factor_12U	0.06410
Form Factor_5U	0	File System_EXT4	0.03205
File System_NFS	0	File System_NFS	0.03205
Form Factor_10U	0	File System_ext3	0.03205
Disk Drive Amount	0	Form Factor_4U	0.01131
File System_btrfs	0	Form Factor_Tower	0.01104
File System_ext3	0	Operating System Family_Linux	0.00982
Disk Drive Technology_SAS	0	Power Supply Rating (watts)	0.00147
# Threads Per Core	0	Operating System Family_Microsoft Windows	0.00117
File System_EXT4	0	File System_NTFS	0.00031

Tabla B.1: SPECpower_ssj2008: Influencia de los atributos en materia de superproporcionalidad energética.

Asimismo, las tablas a continuación detallan la importancia que tienen los atributos que integran el conjunto de datos de SPECpower_ssj2008, en función de la distinción de los agrupamientos realizados en la sección 4.3.2.3.

<i>Random Forest</i>		χ^2	
Característica	Score	Característica	Score
Form Factor_3U	0.21533	Form Factor_3U	351.419
Form Factor_12U	0.06303	Form Factor_12U	318.509
Power Supply Rating (watts)	0.05381	File System_EXT4	79.5029
# Chips	0.04386	Power Supplies Installed	66.6213
Power Supplies Installed	0.03657	Disk Drive Amount	42.6714
File System_EXT4	0.03374	Memory (GB)	35.3203
Performance/power @ 60 % of target load	0.02939	Power Supply Rating (watts)	27.8022
Memory (GB)	0.02928	Disk Drive Technology_SAS	23.2076
Form Factor_5U	0.02483	Form Factor_5U	20.5322
Average watts @ 60 % of target load	0.02400	Average watts @ active idle	6.2721
ssj_ops @ 80 % of target load	0.02318	Average watts @ 10 % of target load	4.51902
Performance/power @ 100 % of target load	0.02257	Average watts @ 20 % of target load	3.93714
Disk Drive Amount	0.02046	Average watts @ 30 % of target load	3.56929
Performance/power @ 50 % of target load	0.01809	Average watts @ 40 % of target load	3.30306
Average watts @ 30 % of target load	0.01642	File System_NTFS	3.25275
Average watts @ 20 % of target load	0.01620	Average watts @ 50 % of target load	3.05742
Performance/power @ 10 % of target load	0.01609	Average watts @ 60 % of target load	2.82501
Average watts @ 100 % of target load	0.01555	Average watts @ 80 % of target load	2.79996
ssj_ops @ 30 % of target load	0.01420	Average watts @ 70 % of target load	2.71332
ssj_ops @ 40 % of target load	0.01387	Operating System Family_Microsoft Windows	2.71228
Processor Turbo Boost	0.01369	Operating System Family_Linux	2.71228
Average watts @ 50 % of target load	0.01320	Average watts @ 90 % of target load	2.65085

Performance/power @ 20 % of target load	0.01306	Disk Drive Technology_SSD	2.57280
Average watts @ 70 % of target load	0.01239	Average watts @ 100 % of target load	2.51229
Average watts @ 10 % of target load	0.01194	File System_btrfs	2.17056
Processor MHz	0.01180	Form Factor_2U	1.68657
Average watts @ 90 % of target load	0.01171	File System_XFS	1.52514
ssj_ops @ 90 % of target load	0.01123	Form Factor_1U	1.45872
ssj_ops @ 20 % of target load	0.01091	# Chips	0.89148
Performance/power @ 70 % of target load	0.01087	Nodes	0.76609
ssj_ops @ 100 % of target load	0.01080	Form Factor_Tower	0.74925
Performance/power @ 80 % of target load	0.01059	ssj_ops @ 20 % of target load	0.62626
ssj_ops @ 10 % of target load	0.01006	ssj_ops @ 100 % of target load	0.62554
Average watts @ 40 % of target load	0.00954	ssj_ops @ 10 % of target load	0.62466
Average watts @ active idle	0.00950	ssj_ops @ 90 % of target load	0.62380
Average watts @ 80 % of target load	0.00936	ssj_ops @ 70 % of target load	0.62362
Performance/power @ 90 % of target load	0.00865	ssj_ops @ 30 % of target load	0.62347
Performance/power @ 30 % of target load	0.00859	ssj_ops @ 60 % of target load	0.62315
GB per Disk Drive	0.00809	ssj_ops @ 50 % of target load	0.62308
Performance/power @ 40 % of target load	0.00763	ssj_ops @ 40 % of target load	0.62252
ssj_ops @ 70 % of target load	0.00753	ssj_ops @ 80 % of target load	0.62192
Disk Drive Technology_SATA	0.00715	# Cores	0.59468
# Cores	0.00673	Form Factor_bla	0.54603
ssj_ops @ 50 % of target load	0.00668	Disk Drive Technology_SATA	0.53952
# Cores Per Chip	0.00617	# Threads Per Core	0.46384
ssj_ops @ 60 % of target load	0.00588	Performance/power @ 10 % of target load	0.38226
Disk Drive Technology_SAS	0.00542	Performance/power @ 20 % of target load	0.33102
Disk Drive Technology_SSD	0.00364	Performance/power @ 30 % of target load	0.30453
Operating System Family_Linux	0.00208	# Cores Per Chip	0.29971
File System_XFS	0.00187	GB per Disk Drive	0.29921
# Threads Per Core	0.00085	Performance/power @ 40 % of target load	0.27416
Form Factor_1U	0.00068	Performance/power @ 50 % of target load	0.24323
File System_NTFS	0.00054	Processor Turbo Boost	0.22644
Operating System Family_Microsoft Windows	0.00034	Form Factor_4U	0.21434
Nodes	7.83E-05	Performance/power @ 60 % of target load	0.21099
Form Factor_other	0	Performance/power @ 80 % of target load	0.19634
Form Factor_2U	0	Performance/power @ 90 % of target load	0.19423
File System_NFS	0	Performance/power @ 70 % of target load	0.19046
Form Factor_bla	0	Form Factor_other	0.16832
Form Factor_Tower	0	Performance/power @ 100 % of target load	0.16665
File System_btrfs	0	Form Factor_7U	0.11577
File System_ext3	0	Form Factor_10U	0.03554
Form Factor_10U	0	Processor MHz	0.01640
Form Factor_7U	0	File System_NFS	0.00706
Form Factor_4U	0	File System_ext3	0.00706

Tabla B.2: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de DBSCAN

Random Forest		χ^2	
Característica	Score	Característica	Score
Operating System Family_Linux	0.03696	Form Factor_12U	505.40
Operating System Family_Microsoft Windows	0.03491	Memory (GB)	501.35
GB per Disk Drive	0.03408	ssj_ops @ 90 % of target load	443.94
Average watts @ 80 % of target load	0.03027	ssj_ops @ 100 % of target load	443.84
Average watts @ 40 % of target load	0.02831	ssj_ops @ 20 % of target load	443.50
Performance/power @ 100 % of target load	0.02627	ssj_ops @ 80 % of target load	443.48
Average watts @ active idle	0.02562	ssj_ops @ 60 % of target load	443.43
ssj_ops @ 40 % of target load	0.02484	ssj_ops @ 40 % of target load	443.38
Average watts @ 90 % of target load	0.02468	ssj_ops @ 30 % of target load	443.32
ssj_ops @ 30 % of target load	0.02452	ssj_ops @ 50 % of target load	443.18
Average watts @ 70 % of target load	0.02430	ssj_ops @ 70 % of target load	443.11
Average watts @ 50 % of target load	0.02406	ssj_ops @ 10 % of target load	443.02

Random Forest		χ^2	
Performance/power @ 70 % of target load	0.02336	Operating System Family_Linux	393.11
ssj_ops @ 100 % of target load	0.02326	Operating System Family_Microsoft Windows	393.11
ssj_ops @ 10 % of target load	0.02319	# Cores	328.38
ssj_ops @ 70 % of target load	0.02292	Average watts @ 100 % of target load	301.74
ssj_ops @ 60 % of target load	0.02290	Average watts @ 90 % of target load	298.94
File System_NTFS	0.02189	Average watts @ 80 % of target load	285.14
Performance/power @ 80 % of target load	0.02183	Average watts @ 70 % of target load	274.96
ssj_ops @ 80 % of target load	0.02134	Average watts @ 60 % of target load	264.73
Memory (GB)	0.02106	Average watts @ 50 % of target load	250.90
Average watts @ 20 % of target load	0.02042	Average watts @ 40 % of target load	239.76
Average watts @ 60 % of target load	0.02019	Average watts @ 30 % of target load	230.08
# Cores Per Chip	0.02019	Average watts @ 20 % of target load	220.08
Performance/power @ 50 % of target load	0.02003	Average watts @ 10 % of target load	213.05
Performance/power @ 60 % of target load	0.01979	Form Factor_blade	210.66
Performance/power @ 20 % of target load	0.01904	File System_NTFS	209.26
Performance/power @ 90 % of target load	0.01888	Performance/power @ 10 % of target load	177.61
Performance/power @ 40 % of target load	0.01861	Performance/power @ 20 % of target load	176.49
ssj_ops @ 50 % of target load	0.01820	Performance/power @ 30 % of target load	173.99
Performance/power @ 10 % of target load	0.01805	Performance/power @ 40 % of target load	172.95
ssj_ops @ 90 % of target load	0.01790	Performance/power @ 50 % of target load	170.44
# Threads Per Core	0.01781	Performance/power @ 60 % of target load	163.64
# Cores	0.01754	# Chips	158.18
Average watts @ 100 % of target load	0.01734	Average watts @ active idle	155.62
Average watts @ 30 % of target load	0.01675	Performance/power @ 70 % of target load	153.96
Performance/power @ 30 % of target load	0.01623	Performance/power @ 80 % of target load	140.54
ssj_ops @ 20 % of target load	0.01462	Performance/power @ 90 % of target load	125.69
Processor Turbo Boost	0.01318	Disk Drive Technology_SAS	124.11
Disk Drive Technology_SAS	0.01299	Performance/power @ 100 % of target load	115.71
Average watts @ 10 % of target load	0.01164	# Cores Per Chip	115.70
File System_XFS	0.01127	Power Supplies Installed	113.29
Power Supply Rating (watts)	0.01079	Nodes	106.06
Form Factor_blade	0.00966	Form Factor_other	82.156
Form Factor_4U	0.00917	Power Supply Rating (watts)	61.261
# Chips	0.00859	Disk Drive Amount	60.745
Disk Drive Amount	0.00741	File System_XFS	55.359
Nodes	0.00735	Processor Turbo Boost	37.903
Disk Drive Technology_SSD	0.00709	# Threads Per Core	37.431
Power Supplies Installed	0.00679	File System_btrfs	37.253
File System_btrfs	0.00641	Disk Drive Technology_SSD	23.736
Processor MHz	0.00620	GB per Disk Drive	14.578
Form Factor_Tower	0.00488	Form Factor_7U	14.489
Disk Drive Technology_SATA	0.00401	Form Factor_2U	14.465
Form Factor_2U	0.002638	Disk Drive Technology_SATA	12.995
Form Factor_3U	0.00211	Form Factor_Tower	7.3432
Form Factor_7U	0.00128	Form Factor_1U	6.4049
Form Factor_1U	0.00128	Processor MHz	5.0095
Form Factor_other	0.00108	Form Factor_4U	4.6330
Form Factor_12U	0.00096	Form Factor_3U	4.1671
Form Factor_5U	0.00066	Form Factor_10U	3.7584
Form Factor_10U	9.143E-05	Form Factor_5U	3.0273
File System_NFS	3.877E-05	File System_NFS	1.6940
File System_ext3	0	File System_ext3	1.6940
File System_EXT4	0	File System_EXT4	1.1931

Tabla B.3: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de Esperanza Máxima.

Random Forest		χ^2	
Característica	Score	Característica	Score
Performance/power @ 10 % of target load	0.06916	Average watts @ 60 % of target load	964.74
Performance/power @ 70 % of target load	0.05405	Average watts @ 70 % of target load	964.48

Random Forest		χ^2
ssj_ops @ 70 % of target load	0.05355	Average watts @ 80 % of target load
Performance/power @ 50 % of target load	0.05006	Average watts @ 50 % of target load
ssj_ops @ 80 % of target load	0.04555	Average watts @ 90 % of target load
Performance/power @ 60 % of target load	0.04345	Average watts @ 100 % of target load
ssj_ops @ 90 % of target load	0.04143	Average watts @ 40 % of target load
Performance/power @ 20 % of target load	0.03483	Average watts @ 30 % of target load
Nodes	0.03273	Average watts @ 20 % of target load
ssj_ops @ 10 % of target load	0.03247	Performance/power @ 10 % of target load
Average watts @ 100 % of target load	0.03233	Average watts @ 10 % of target load
Performance/power @ 90 % of target load	0.03031	Performance/power @ 20 % of target load
Average watts @ 90 % of target load	0.02965	Performance/power @ 30 % of target load
ssj_ops @ 100 % of target load	0.02942	Performance/power @ 40 % of target load
Average watts @ 10 % of target load	0.02864	Performance/power @ 50 % of target load
Performance/power @ 30 % of target load	0.02862	Performance/power @ 60 % of target load
Performance/power @ 80 % of target load	0.02585	Performance/power @ 70 % of target load
ssj_ops @ 30 % of target load	0.02537	# Cores
Average watts @ 40 % of target load	0.02473	Performance/power @ 80 % of target load
Average watts @ 70 % of target load	0.02451	Average watts @ active idle
Power Supply Rating (watts)	0.02179	ssj_ops @ 90 % of target load
Average watts @ 20 % of target load	0.02093	ssj_ops @ 80 % of target load
# Cores Per Chip	0.01949	ssj_ops @ 30 % of target load
# Chips	0.01825	ssj_ops @ 10 % of target load
Average watts @ 30 % of target load	0.01816	ssj_ops @ 70 % of target load
ssj_ops @ 50 % of target load	0.01753	ssj_ops @ 40 % of target load
ssj_ops @ 20 % of target load	0.01682	ssj_ops @ 20 % of target load
Performance/power @ 40 % of target load	0.01680	ssj_ops @ 60 % of target load
ssj_ops @ 60 % of target load	0.01677	ssj_ops @ 50 % of target load
Average watts @ 60 % of target load	0.01585	ssj_ops @ 100 % of target load
Average watts @ 80 % of target load	0.01453	Performance/power @ 90 % of target load
Average watts @ 50 % of target load	0.01367	# Chips
Performance/power @ 100 % of target load	0.01328	Performance/power @ 100 % of target load
Average watts @ active idle	0.01224	# Cores Per Chip
Memory (GB)	0.00993	Memory (GB)
ssj_ops @ 40 % of target load	0.00529	Nodes
Power Supplies Installed	0.00371	Form Factor _blade
# Cores	0.00273	Power Supply Rating (watts)
Processor MHz	0.00177	Power Supplies Installed
Processor Turbo Boost	0.00062	Processor Turbo Boost
GB per Disk Drive	0.00045	Form Factor _other
Form Factor _blade	0.00035	Operating System Family _Microsoft Windows
Form Factor _1U	0.00034	Operating System Family _Linux
Form Factor _Tower	0.00028	File System _NTFS
Form Factor _4U	0.00022	Form Factor _2U
File System_btrfs	0.00021	Disk Drive Technology _SSD
# Threads Per Core	0.00021	File System_btrfs
Form Factor _other	0.00021	# Threads Per Core
Form Factor _5U	0.00020	File System_XFS
File System_EXT4	0.00011	Disk Drive Technology_SATA
File System_XFS	0.00011	Form Factor _1U
Form Factor _7U	7.840E-05	Form Factor _Tower
Disk Drive Technology_SATA	5.430E-05	GB per Disk Drive
Form Factor _3U	4.819E-05	Form Factor _10U
Form Factor _2U	2.956E-05	Form Factor _7U
Form Factor _12U	0	Disk Drive Technology_SAS
Disk Drive Technology_SAS	0	Disk Drive Amount
File System_ext3	0	Form Factor _12U
Operating System Family_Linux	0	Processor MHz
File System_NTFS	0	File System_EXT4
File System_NFS	0	Form Factor _4U
Operating System Family_Microsoft Windows	0	Form Factor _3U
Form Factor _10U	0	Form Factor _5U
Disk Drive Amount	0	File System_NFS

Random Forest		χ^2	
Disk Drive Technology_SSD	0	File System_ext3	0.3961

Tabla B.4: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de Fuzzy C-Means.

Random Forest		χ^2	
Característica	Score	Característica	Score
# Cores Per Chip	0.10303	Performance/power @ 10 % of target load	1588.7
Performance/power @ 70 % of target load	0.08590	Performance/power @ 20 % of target load	1527.1
ssj_ops @ 50 % of target load	0.05790	Performance/power @ 30 % of target load	1460.5
ssj_ops @ 60 % of target load	0.05701	Performance/power @ 40 % of target load	1408.9
Performance/power @ 10 % of target load	0.05325	Performance/power @ 50 % of target load	1364.4
ssj_ops @ 80 % of target load	0.05192	Performance/power @ 60 % of target load	1299.4
ssj_ops @ 100 % of target load	0.05140	Performance/power @ 70 % of target load	1200.8
ssj_ops @ 70 % of target load	0.04681	Performance/power @ 80 % of target load	1054.7
ssj_ops @ 30 % of target load	0.04550	Performance/power @ 90 % of target load	904.01
Performance/power @ 50 % of target load	0.04039	Performance/power @ 100 % of target load	822.54
Performance/power @ 40 % of target load	0.03879	# Cores Per Chip	779.68
ssj_ops @ 90 % of target load	0.03839	# Cores	285.06
Performance/power @ 60 % of target load	0.03784	ssj_ops @ 90 % of target load	284.01
ssj_ops @ 10 % of target load	0.03772	ssj_ops @ 40 % of target load	283.92
Performance/power @ 90 % of target load	0.03749	ssj_ops @ 10 % of target load	283.90
Performance/power @ 20 % of target load	0.03495	ssj_ops @ 30 % of target load	283.89
ssj_ops @ 20 % of target load	0.03210	ssj_ops @ 20 % of target load	283.88
Performance/power @ 30 % of target load	0.03164	ssj_ops @ 80 % of target load	283.83
Performance/power @ 80 % of target load	0.03109	ssj_ops @ 70 % of target load	283.83
ssj_ops @ 40 % of target load	0.02116	ssj_ops @ 50 % of target load	283.82
Performance/power @ 100 % of target load	0.01527	ssj_ops @ 100 % of target load	283.78
Memory (GB)	0.01005	ssj_ops @ 60 % of target load	283.71
Average watts @ 90 % of target load	0.00487	Memory (GB)	201.44
Average watts @ 100 % of target load	0.00475	Average watts @ 100 % of target load	165.80
Average watts @ 60 % of target load	0.00386	Average watts @ 90 % of target load	160.42
Average watts @ 80 % of target load	0.00329	Average watts @ 80 % of target load	155.34
Average watts @ 70 % of target load	0.00275	Average watts @ 70 % of target load	149.80
Average watts @ 50 % of target load	0.00262	Average watts @ 60 % of target load	145.16
# Cores	0.00252	Average watts @ 50 % of target load	141.11
# Chips	0.00217	Average watts @ 40 % of target load	137.65
Average watts @ active idle	0.00214	Processor Turbo Boost	134.82
Average watts @ 30 % of target load	0.00204	Average watts @ 30 % of target load	132.92
Average watts @ 10 % of target load	0.00172	Average watts @ 20 % of target load	126.20
Processor Turbo Boost	0.00143	Average watts @ 10 % of target load	119.04
Processor MHz	0.00091	Operating System Family_Linux	114.43
Form Factor_3U	0.00089	Operating System Family_Microsoft Windows	114.43
Nodes	0.00067	File System_NTFS	91.083
Average watts @ 20 % of target load	0.00065	# Chips	86.851
GB per Disk Drive	0.00049	Average watts @ active idle	70.854
Operating System Family_Microsoft Windows	0.00049	File System_XFS	56.967
Average watts @ 40 % of target load	0.00045	Nodes	54.592
File System_NTFS	0.00044	# Threads Per Core	44.756
Disk Drive Technology_SAS	0.00031	GB per Disk Drive	39.450
Operating System Family_Linux	0.00029	File System_btrfs	35.145
Power Supply Rating (watts)	0.00027	Form Factor_Tower	34.527
File System_btrfs	7.091E-05	Form Factor_other	31.445
File System_EXT4	7.075E-05	Form Factor_blade	28.130
Power Supplies Installed	3.501E-05	Processor MHz	21.306
Form Factor_1U	1.358E-06	Disk Drive Technology_SAS	16.031
File System_XFS	0	Power Supplies Installed	14.962
File System_NFS	0	Disk Drive Technology_SSD	11.885
File System_ext3	0	Form Factor_1U	11.833
Disk Drive Technology_SATA	0	Disk Drive Amount	11.038
# Threads Per Core	0	Form Factor_10U	7.4572

Random Forest		χ^2	
Form Factor_Tower	0	Form Factor_7U	5.4510
Form Factor_other	0	Form Factor_12U	2.9483
Form Factor_bla	0	Disk Drive Technology_SATA	2.5508
Form Factor_7U	0	File System_EXT4	0.6811
Form Factor_5U	0	File System_NFS	0.6811
Form Factor_4U	0	File System_ext3	0.6811
Form Factor_2U	0	Form Factor_5U	0.1493
Form Factor_12U	0	Form Factor_2U	0.0337
Form Factor_10U	0	Form Factor_4U	0.0091
Disk Drive Amount	0	Power Supply Rating (watts)	0.0051
Disk Drive Technology_SSD	0	Form Factor_3U	0.0005

Tabla B.5: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de K-Medoides.

Random Forest		χ^2	
Característica	Score	Característica	Score
File System_EXT4	0.12776	File System_ext3	90.345
File System_ext3	0.12460	File System_EXT4	86.870
Form Factor_3U	0.05658	Form Factor_3U	79.506
Performance/power @ 80 % of target load	0.04521	Form Factor_7U	20.848
Performance/power @ 30 % of target load	0.03718	Disk Drive Technology_SAS	10.194
Average watts @ 30 % of target load	0.03347	File System_NTFS	9.6548
Average watts @ active idle	0.02887	Operating System Family_Microsoft Windows	8.5421
Performance/power @ 90 % of target load	0.02878	Operating System Family_Linux	8.5421
Performance/power @ 60 % of target load	0.02807	Power Supplies Installed	7.4035
# Chips	0.02559	Processor Turbo Boost	5.7805
ssj_ops @ 70 % of target load	0.02455	# Threads Per Core	4.2680
GB per Disk Drive	0.02402	Power Supply Rating (watts)	1.8723
Power Supplies Installed	0.02376	Disk Drive Technology_SSD	1.6046
ssj_ops @ 80 % of target load	0.02301	GB per Disk Drive	1.1309
ssj_ops @ 50 % of target load	0.02221	Performance/power @ 30 % of target load	0.8411
Performance/power @ 40 % of target load	0.02005	Performance/power @ 20 % of target load	0.8332
Average watts @ 60 % of target load	0.01959	Performance/power @ 40 % of target load	0.8273
Performance/power @ 70 % of target load	0.01792	Performance/power @ 10 % of target load	0.8222
Average watts @ 90 % of target load	0.01769	Performance/power @ 50 % of target load	0.8088
Form Factor_7U	0.01748	Performance/power @ 60 % of target load	0.7728
ssj_ops @ 40 % of target load	0.01669	Performance/power @ 70 % of target load	0.7290
ssj_ops @ 30 % of target load	0.01608	Performance/power @ 80 % of target load	0.6853
Performance/power @ 10 % of target load	0.01546	Performance/power @ 90 % of target load	0.6367
Performance/power @ 50 % of target load	0.01511	Performance/power @ 100 % of target load	0.6152
Memory (GB)	0.01475	Form Factor_2U	0.6102
ssj_ops @ 10 % of target load	0.01426	Average watts @ active idle	0.3754
Operating System Family_Microsoft Windows	0.01320	# Cores Per Chip	0.3640
Performance/power @ 20 % of target load	0.01302	Form Factor_1U	0.3194
ssj_ops @ 90 % of target load	0.01176	Disk Drive Technology_SATA	0.2675
ssj_ops @ 100 % of target load	0.01071	Nodes	0.2398
Nodes	0.01069	Form Factor_Tower	0.1643
Average watts @ 70 % of target load	0.01047	Form Factor_bla	0.1198
Average watts @ 40 % of target load	0.01028	ssj_ops @ 10 % of target load	0.1185
Power Supply Rating (watts)	0.01002	ssj_ops @ 90 % of target load	0.1183
Average watts @ 50 % of target load	0.00987	ssj_ops @ 40 % of target load	0.1183
File System_NTFS	0.00981	ssj_ops @ 50 % of target load	0.1181
Average watts @ 10 % of target load	0.00952	ssj_ops @ 30 % of target load	0.1181
ssj_ops @ 20 % of target load	0.00942	ssj_ops @ 80 % of target load	0.1181
Average watts @ 20 % of target load	0.00782	ssj_ops @ 20 % of target load	0.1181
Processor Turbo Boost	0.00545	ssj_ops @ 60 % of target load	0.1180
Processor MHz	0.00541	ssj_ops @ 100 % of target load	0.1179
Disk Drive Amount	0.00492	ssj_ops @ 70 % of target load	0.1178
Performance/power @ 100 % of target load	0.00267	Memory (GB)	0.0909
File System_NFS	0.00196	# Cores	0.0787

<i>Random Forest</i>		χ^2	
Operating System Family_Linux	0.00137	Average watts @ 10 % of target load	0.0675
# Threads Per Core	0.00113	File System_XFS	0.0608
# Cores	0.00071	Average watts @ 20 % of target load	0.0597
# Cores Per Chip	0.00052	Average watts @ 30 % of target load	0.0539
Disk Drive Technology_SAS	0.00030	Form Factor_4U	0.0470
Form Factor_4U	0	# Chips	0.0428
Disk Drive Technology_SATA	0	Average watts @ 40 % of target load	0.0406
ssj_ops @ 60 % of target load	0	Form Factor_other	0.0369
File System_btrfs	0	File System_btrfs	0.0353
File System_XFS	0	Disk Drive Amount	0.0342
Average watts @ 100 % of target load	0	Average watts @ 50 % of target load	0.0282
Average watts @ 80 % of target load	0	Average watts @ 60 % of target load	0.0154
Form Factor_2U	0	Form Factor_10U	0.0078
Form Factor_10U	0	Form Factor_5U	0.0062
Form Factor_12U	0	Average watts @ 70 % of target load	0.0059
Form Factor_other	0	Average watts @ 100 % of target load	0.0035
Form Factor_bla	0	Form Factor_12U	0.0031
Form Factor_Tower	0	File System_NFS	0.0015
Form Factor_1U	0	Average watts @ 90 % of target load	0.0009
Form Factor_5U	0	Average watts @ 80 % of target load	0.0006
Disk Drive Technology_SSD	0	Processor MHz	1.357E-05

Tabla B.6: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de *Spectral Clustering*.

<i>Random Forest</i>		χ^2	
Característica	Score	Característica	Score
ssj_ops @ 40 % of target load	0.09253	Performance/power @ 10 % of target load	1076.9
ssj_ops @ 70 % of target load	0.08336	Performance/power @ 20 % of target load	1054.0
ssj_ops @ 100 % of target load	0.07819	Performance/power @ 30 % of target load	1023.0
ssj_ops @ 20 % of target load	0.07512	Performance/power @ 40 % of target load	999.07
ssj_ops @ 90 % of target load	0.06088	Performance/power @ 50 % of target load	974.50
ssj_ops @ 80 % of target load	0.05775	Performance/power @ 60 % of target load	936.49
ssj_ops @ 60 % of target load	0.05286	Performance/power @ 70 % of target load	887.65
Performance/power @ 70 % of target load	0.05118	Performance/power @ 80 % of target load	806.91
ssj_ops @ 10 % of target load	0.04886	Performance/power @ 90 % of target load	707.54
ssj_ops @ 50 % of target load	0.04477	# Cores Per Chip	701.37
# Cores Per Chip	0.04000	Performance/power @ 100 % of target load	651.82
Performance/power @ 80 % of target load	0.03843	# Cores	329.77
ssj_ops @ 30 % of target load	0.03711	ssj_ops @ 90 % of target load	319.34
Memory (GB)	0.03306	ssj_ops @ 10 % of target load	319.31
Performance/power @ 50 % of target load	0.02963	ssj_ops @ 40 % of target load	319.28
Performance/power @ 90 % of target load	0.02522	ssj_ops @ 30 % of target load	319.26
# Cores	0.01689	ssj_ops @ 20 % of target load	319.20
Performance/power @ 60 % of target load	0.01629	ssj_ops @ 80 % of target load	319.18
Performance/power @ 40 % of target load	0.01513	ssj_ops @ 50 % of target load	319.18
Performance/power @ 100 % of target load	0.01397	ssj_ops @ 70 % of target load	319.18
Performance/power @ 20 % of target load	0.01212	ssj_ops @ 100 % of target load	319.10
Performance/power @ 30 % of target load	0.01140	ssj_ops @ 60 % of target load	319.05
Performance/power @ 10 % of target load	0.01068	Average watts @ 100 % of target load	227.89
Average watts @ 90 % of target load	0.00849	Memory (GB)	223.48
Average watts @ 70 % of target load	0.00733	Average watts @ 90 % of target load	222.83
Average watts @ 50 % of target load	0.00659	Average watts @ 80 % of target load	220.53
Average watts @ 10 % of target load	0.00431	Average watts @ 70 % of target load	217.25
Average watts @ 20 % of target load	0.00408	Average watts @ 60 % of target load	214.76
Average watts @ 100 % of target load	0.00350	Average watts @ 50 % of target load	212.31
Average watts @ 80 % of target load	0.00333	Average watts @ 40 % of target load	209.82
Average watts @ 30 % of target load	0.00238	Average watts @ 30 % of target load	206.40
Average watts @ active idle	0.00229	Average watts @ 20 % of target load	200.61
# Chips	0.00174	Average watts @ 10 % of target load	194.44
Operating System Family_Microsoft Windows	0.00130	# Chips	140.65

Random Forest		χ^2	
Average watts @ 40 % of target load	0.00122	Average watts @ active idle	135.32
Nodes	0.00108	Processor Turbo Boost	131.20
GB per Disk Drive	0.00093	Operating System Family_Microsoft Windows	130.85
Processor Turbo Boost	0.00091	Operating System Family_Linux	130.85
Processor MHz	0.00083	Nodes	106.35
Average watts @ 60 % of target load	0.00075	File System_NTFS	104.87
Power Supply Rating (watts)	0.00070	File System_XFS	60.857
File System_XFS	0.00053	Form Factor_blade	58.080
File System_NTFS	0.00050	GB per Disk Drive	43.290
Disk Drive Technology_SATA	0.00037	# Threads Per Core	41.671
Disk Drive Technology_SSD	0.00032	File System_btrfs	37.379
File System_btrfs	0.00020	Form Factor_Tower	37.159
Form Factor_other	0.00018	Form Factor_other	33.559
Power Supplies Installed	0.00012	Power Supplies Installed	27.135
Form Factor_blade	0.00012	Form Factor_1U	14.546
Operating System Family_Linux	7.832E-05	Processor MHz	12.790
Form Factor_2U	4.840E-05	Disk Drive Technology_SSD	10.347
File System_EXT4	4.810E-05	Disk Drive Technology_SAS	9.5151
Form Factor_4U	2.439E-05	Disk Drive Amount	8.4508
# Threads Per Core	2.402E-05	Form Factor_10U	7.9105
Form Factor_1U	0	Form Factor_7U	6.0818
Disk Drive Technology_SAS	0	Disk Drive Technology_SATA	3.3318
File System_ext3	0	Form Factor_12U	3.1262
Disk Drive Amount	0	Power Supply Rating (watts)	2.1593
Form Factor_10U	0	File System_EXT4	1.5569
File System_NFS	0	Form Factor_3U	0.9198
Form Factor_Tower	0	Form Factor_2U	0.8298
Form Factor_12U	0	File System_NFS	0.6424
Form Factor_5U	0	File System_ext3	0.6424
Form Factor_3U	0	Form Factor_5U	0.1990
Form Factor_7U	0	Form Factor_4U	0.0182

Tabla B.7: SPECpower_ssj2008: Influencia de los atributos en los agrupamientos de K-Means.

Bibliografía

- [Akaike, 1998] Akaike, H. (1998). Information theory and an extension of the maximum likelihood principle. In *Selected papers of hirotugu akaike*, pages 199–213. Springer.
- [Amdahl, 1967] Amdahl, G. M. (1967). Validity of the single processor approach to achieving large scale computing capabilities. In *Proceedings of the April 18-20, 1967, spring joint computer conference*, pages 483–485.
- [Badam and Pai, 2011] Badam, A. and Pai, V. S. (2011). Ssdalloc: hybrid ssd/ram memory management made easy. In *Proceedings of the 8th USENIX conference on Networked systems design and implementation*, pages 211–224.
- [Barroso and Hölzle, 2007] Barroso, L. A. and Hölzle, U. (2007). The case for energy-proportional computing. *Computer*, 40(12):33–37.
- [Belady, 2007] Belady, C. (2007). In the data center, power and cooling costs more than the it equipment it supports 2007. URL <http://www.electronics-cooling.com/articles/2007/feb/a3>.
- [Belady et al., 2008] Belady, C., Rawson, A., Pfleuger, J., and Cader, T. (2008). Green grid data center power efficiency metrics: Pue and dcie. Technical report, Technical report, Green Grid.
- [Bergman et al., 2008] Bergman, K., Borkar, S., Campbell, D., Carlson, W., Dally, W., Denneau, M., Franzon, P., Harrod, W., Hiller, J., Karp, S., et al. (2008). Exascale computing study: Technology challenges in achieving exascale systems peter kogge, editor & study lead.
- [Brunton and Kutz, 2019] Brunton, S. L. and Kutz, J. N. (2019). *Data-driven science and engineering: Machine learning, dynamical systems, and control*. Cambridge University Press.
- [Díaz et al., 2016] Díaz, A. G., Fernández, E. S., Gibbins, J., and Lucquiaud, M. (2016). Sequential supplementary firing in natural gas combined cycle with carbon capture: A technology option for mexico for low-carbon electricity generation and co2 enhanced oil recovery. *International Journal of Greenhouse Gas Control*, 51:330–345.

- [Dongarra et al., 2013] Dongarra, J., Luszczek, P., and Heroux, M. (2013). Hpcg technical specification. *Sandia National Laboratories, Sandia Report SAND2013-8752*.
- [Dongarra et al., 2003] Dongarra, J. J., Luszczek, P., and Petitet, A. (2003). The linpack benchmark: past, present and future. *Concurrency and Computation: practice and experience*, 15(9):803–820.
- [Feng and Cameron, 2007] Feng, W.-c. and Cameron, K. (2007). The green500 list: Encouraging sustainable supercomputing. *Computer*, 40(12):50–55.
- [Freudenberg, 2003] Freudenberg, M. (2003). Composite indicators of country performance: a critical assessment.
- [Gao et al., 2009] Gao, K., Khoshgoftaar, T. M., and Wang, H. (2009). An empirical investigation of filter attribute selection techniques for software quality classification. In *2009 IEEE International Conference on Information Reuse & Integration*, pages 272–277. IEEE.
- [García-Berná et al., 2021] García-Berná, J. A., Ouhbi, S., Fernández-Alemán, J. L., Carrillo de Gea, J. M., Nicolás, J., Moros, B., and Toval, A. (2021). A study on the relationship between usability of guis and power consumption of a pc: The case of phrs. *International Journal of Environmental Research and Public Health*, 18(4):1385.
- [Geller, 2011] Geller, T. (2011). Supercomputing’s exaflop target. *Communications of the ACM*, 54(8):16–18.
- [Greco et al., 2019] Greco, S., Ishizaka, A., Tasiou, M., and Torrisi, G. (2019). On the methodological framework of composite indices: A review of the issues of weighting, aggregation, and robustness. *Social Indicators Research*, 141(1):61–94.
- [Hsu et al., 2005] Hsu, C.-H., Feng, W.-C., and Archuleta, J. S. (2005). Towards efficient supercomputing: A quest for the right metric. In *19th IEEE International Parallel and Distributed Processing Symposium*, pages 8–pp. IEEE.
- [Hsu et al., 2012] Hsu, C.-H., Kuehn, J. A., and Poole, S. W. (2012). Towards efficient supercomputing: searching for the right efficiency metric. In *Proceedings of the 3rd ACM/SPEC International Conference on Performance Engineering*, pages 157–162.
- [Hsu and Poole, 2013] Hsu, C.-H. and Poole, S. W. (2013). Revisiting server energy proportionality. In *2013 42nd International Conference on Parallel Processing*, pages 834–840. IEEE.
- [Hsu and Poole, 2015] Hsu, C.-H. and Poole, S. W. (2015). Measuring server energy proportionality. In *Proceedings of the 6th ACM/SPEC International Conference on Performance Engineering*, pages 235–240.
- [Hughes, 1968] Hughes, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE transactions on information theory*, 14(1):55–63.
- [Jiang et al., 2017] Jiang, C., Wang, Y., Ou, D., Luo, B., and Shi, W. (2017). Energy proportional servers: Where are we in 2016? In *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*, pages 1649–1660. IEEE.

- [Kalton and Kasprzyk, 1982] Kalton, G. and Kasprzyk, D. (1982). Imputing for missing survey responses. In *Proceedings of the section on survey research methods, American Statistical Association*, volume 22, page 31. American Statistical Association Cincinnati.
- [Kaufman and Rousseeuw, 2009] Kaufman, L. and Rousseeuw, P. J. (2009). *Finding groups in data: an introduction to cluster analysis*, volume 344. John Wiley & Sons.
- [Kittler, 1980] Kittler, J. (1980). Computational problems of feature selection pertaining to large data sets. *Proceedings of pattern recognition in practice*, pages 405–414.
- [Kudo and Sklansky, 2000] Kudo, M. and Sklansky, J. (2000). Comparison of algorithms that select features for pattern classifiers. *Pattern recognition*, 33(1):25–41.
- [Lange, 2009] Lange, K.-D. (2009). Identifying shades of green: The specpower benchmarks. *Computer*, (3):95–97.
- [Langone et al., 2016] Langone, R., Mall, R., Alzate, C., and Suykens, J. A. (2016). Kernel spectral clustering and applications. In *Unsupervised Learning Algorithms*, pages 135–161. Springer.
- [Le Sueur and Heiser, 2010] Le Sueur, E. and Heiser, G. (2010). Dynamic voltage and frequency scaling: The laws of diminishing returns. In *Proceedings of the 2010 international conference on Power aware computing and systems*, pages 1–8.
- [Likas et al., 2003] Likas, A., Vlassis, N., and Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern recognition*, 36(2):451–461.
- [Little and Rubin, 2019] Little, R. J. and Rubin, D. B. (2019). *Statistical analysis with missing data*, volume 793. John Wiley & Sons.
- [Medina and Galván, 2007a] Medina, F. and Galván, M. (2007a). Estudios estadísticos y prospectivos. *Imputación de datos: Teoría y práctica. División Estadística y proyecciones Económicas Naciones Unidas. CEPAL*.
- [Medina and Galván, 2007b] Medina, F. and Galván, M. (2007b). *Imputación de datos: teoría y práctica*. Cepal.
- [Moulavi et al., 2014] Moulavi, D., Jaskowiak, P. A., Campello, R. J., Zimek, A., and Sander, J. (2014). Density-based clustering validation. In *Proceedings of the 2014 SIAM international conference on data mining*, pages 839–847. SIAM.
- [Mur et al., 2016] Mur, A., Dormido, R., Duro, N., Dormido-Canto, S., and Vega, J. (2016). Determination of the optimal number of clusters using a spectral clustering optimization. *Expert Systems with Applications*, 65:304–314.
- [Onderwater, 2015] Onderwater, M. (2015). Outlier preservation by dimensionality reduction techniques. *International Journal of Data Analysis Techniques and Strategies*, 7(3):231–252.
- [Peng and Xia, 2005] Peng, J. and Xia, Y. (2005). A cutting algorithm for the minimum sum-of-squared error clustering. In *Proceedings of the 2005 SIAM International Conference on Data Mining*, pages 150–160. SIAM.

- [Petrini et al., 2004] Petrini, F., Moreira, J., Nieplocha, J., Seager, M., Stunkel, C., Thorson, G., Terry, P., and Varadarajan, S. (2004). What are the future trends in high-performance inter. connects for parallel computers?[panel 1]. In *High-Performance Interconnects, Symposium on*, pages 3–3. IEEE Computer Society.
- [Powell, 2008] Powell, J. R. (2008). The quantum limit to moore’s law. *Proceedings of the IEEE*, 96(8):1247–1248.
- [Rahmah and Sitanggang, 2016] Rahmah, N. and Sitanggang, I. S. (2016). Determination of optimal epsilon (eps) value on dbscan algorithm to clustering data on peatland hotspots in sumatra. In *IOP conference series: earth and environmental science*, volume 31, page 012012. IOP Publishing.
- [Randhawa et al., 2018] Randhawa, R. H., Ahmed, A., and Siddiqui, M. I. (2018). Power management techniques in popular operating systems for iot devices. In *2018 International Conference on Frontiers of Information Technology (FIT)*, pages 309–314. IEEE.
- [Ruiz et al., 2018] Ruiz, D., Mantovani, F., Casas, M., Labarta, J., and Spiga, F. (2018). The hpcg benchmark: analysis, shared memory preliminary improvements and evaluation on an arm-based platform.
- [Ryckbosch et al., 2011] Ryckbosch, F., Polfliet, S., and Eeckhout, L. (2011). Trends in server energy proportionality. *Computer*, 44(9):69–72.
- [Saisana and Tarantola, 2002] Saisana, M. and Tarantola, S. (2002). *State-of-the-art report on current methodologies and practices for composite indicator development*, volume 214. Citeseer.
- [Saltelli et al., 2008] Saltelli, A., Ratto, M., Andres, T., Campolongo, F., Cariboni, J., Gatelli, D., Saisana, M., and Tarantola, S. (2008). *Global sensitivity analysis: the primer*. John Wiley & Sons.
- [Schwarz, 1978] Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, pages 461–464.
- [Shannon, 1948] Shannon, C. E. (1948). A mathematical theory of communication. *The Bell system technical journal*, 27(3):379–423.
- [Shapiro and Wilk, 1965] Shapiro, S. S. and Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4):591–611.
- [Smirnov, 1939] Smirnov, N. V. (1939). Estimate of deviation between empirical distribution functions in two independent samples. *Bulletin Moscow University*, 2(2):3–16.
- [Stephens, 1974] Stephens, M. A. (1974). Edf statistics for goodness of fit and some comparisons. *Journal of the American statistical Association*, 69(347):730–737.
- [Sterling et al., 2017] Sterling, T., Brodowicz, M., and Anderson, M. (2017). *High performance computing: modern systems and practices*. Morgan Kaufmann.
- [Stijn and Eeckhout, 2011] Stijn, K. D. B. T. S. and Eeckhout, P. F. R. L. (2011). Sweep: Evaluating computer system energy efficiency using synthetic workloads.

- [Strohmaier, 2009] Strohmaier, E. (2009). Generalized utility metrics for supercomputers. *Computer Science-Research and Development*, 23(3-4):185–193.
- [Subramaniam and Feng, 2013] Subramaniam, B. and Feng, W.-c. (2013). Gbench: benchmarking methodology for evaluating the energy efficiency of supercomputers. *Computer Science-Research and Development*, 28(2-3):221–230.
- [Tan et al., 2016] Tan, P.-N., Steinbach, M., and Kumar, V. (2016). *Introduction to data mining*. Pearson Education India.
- [Thaseen and Kumar, 2017] Thaseen, I. S. and Kumar, C. A. (2017). Intrusion detection model using fusion of chi-square feature selection and multi class svm. *Journal of King Saud University-Computer and Information Sciences*, 29(4):462–472.
- [Tomasini et al., 2016] Tomasini, C., Emmendorfer, L., Borges, E. N., and Machado, K. (2016). A methodology for selecting the most suitable cluster validation internal indices. In *Proceedings of the 31st Annual ACM Symposium on Applied Computing*, pages 901–903.
- [Troyanskaya et al., 2001] Troyanskaya, O., Cantor, M., Sherlock, G., Brown, P., Hastie, T., Tibshirani, R., Botstein, D., and Altman, R. B. (2001). Missing value estimation methods for dna microarrays. *Bioinformatics*, 17(6):520–525.
- [Uddin et al., 2015] Uddin, M., Darabidabarabkhan, Y., Shah, A., and Memon, J. (2015). Evaluating power efficient algorithms for efficiency and carbon emissions in cloud data centers: A review. *Renewable and Sustainable Energy Reviews*, 51:1553–1563.
- [Varsamopoulos et al., 2010] Varsamopoulos, G., Abbasi, Z., and Gupta, S. K. (2010). Trends and effects of energy proportionality on server provisioning in data centers. In *2010 International Conference on High Performance Computing*, pages 1–11. IEEE.
- [Varsamopoulos and Gupta, 2010] Varsamopoulos, G. and Gupta, S. K. (2010). Energy proportionality and the future: Metrics and directions. In *2010 39th International Conference on Parallel Processing Workshops*, pages 461–467. IEEE.
- [Williams and Simoff, 2006] Williams, G. J. and Simoff, S. J. (2006). *Data mining: Theory, methodology, techniques, and applications*, volume 3755. Springer.
- [Wong and Annavaram, 2013] Wong, D. and Annavaram, M. (2013). Scaling the energy proportionality wall with knightshift. *IEEE Micro*, 33(3):28–37.
- [Woo and Lee, 2008] Woo, D. H. and Lee, H.-H. S. (2008). Extending amdahl’s law for energy-efficient computing in the many-core era. *Computer*, 41(12):24–31.
- [Yu and Liu, 2003] Yu, L. and Liu, H. (2003). Feature selection for high-dimensional data: A fast correlation-based filter solution. In *Proceedings of the 20th international conference on machine learning (ICML-03)*, pages 856–863.
- [Yuan and Yang, 2019] Yuan, C. and Yang, H. (2019). Research on k-value selection method of k-means clustering algorithm. *J—Multidisciplinary Scientific Journal*, 2(2):226–235.