

VISIÓN PANORÁMICA DEL ESTADO DEL ARTE DEL MOTOR COGNITIVO PARA RADIOS COGNITIVOS

Rafael Galindo Mier

Instituto de Investigación y Desarrollo de Telecomunicaciones. **LACETEL**

e-mail: galindo@lacetel.cu

RESUMEN

Tradicionalmente, el radio convencional ha utilizado un conjunto fijo de "métodos" de comunicación seleccionados por su operador. Actualmente se espera que un "radio cognitivo full Mitola" (CR), no solo acceda dinámicamente al espectro (DSA) de radiofrecuencia, sino que utilice una gran cantidad de métodos de comunicación actuales y pueda seleccionar el método que mejor cumpla con su objetivo bajo el entorno operativo en que se encuentra. Para hacer posible el CR, se desarrolló un agente inteligente (IA) llamado motor cognitivo (CE), que es en esencia un conjunto de algoritmos de aprendizaje automático, bases de datos, mecanismos de razonamiento y optimizadores. Siendo el CE el núcleo del radio cognitivo, permite que el CR tenga las capacidades de aprendizaje, razonamiento y auto reconfiguración deseadas. Cada algoritmo de motor cognitivo tiene fortalezas y limitaciones que lo hacen más adecuado para ciertos escenarios operativos (condiciones de canal, objetivo operativo, hardware disponible, etc.) que otros algoritmos. Para obtener una mejor comprensión de las funciones y similitudes entre los algoritmos presentados, identificamos dos tareas principales del CR; la clasificación de características de la señal detectada y la toma de decisiones. A partir de una estructura básica, se han desarrollado diferentes arquitecturas de CE, cada una de ellas con sus peculiaridades. A pesar de la escasa literatura disponible sobre el estado del arte del CE, en este artículo ofreceremos de manera didáctica, una visión detallada y abarcadora del CE, sus posibles arquitecturas y los algoritmos que rigen su desempeño.

PALABRAS CLAVES: radio cognitivo, motor cognitivo, arquitecturas, algoritmos, meta-cognición.

PANORAMIC VISION OF THE STATE OF THE ART OF COGNITIVE ENGINE FOR COGNITIVE RADIOS

ABSTRACT

Traditionally, conventional radio has used a fixed set of communication "methods" selected by its operator. It is currently expected that a "full Mitola cognitive radio" (CR), not only dynamically access the radio frequency spectrum (DSA), but use a large number of current communication methods and can select the method that best meets its objective under the operating environment in which it is located. To make CR possible, an intelligent agent (IA) called a cognitive engine (CE) was developed, which is essentially a set of machine learning algorithms, databases, reasoning mechanisms and optimizers. Being the CE the core of the cognitive radio, it allows the CR to have the desired learning, reasoning and self-

reconfiguration capabilities. Each cognitive engine algorithm has strengths and limitations that make it more suitable for certain operating scenarios (channel conditions, operational objective, available hardware, etc.) than other algorithms. To obtain a better understanding of the functions and similarities between the presented algorithms, we identify two main tasks of the CR; the classification of characteristics of the detected signal and decision making. From a basic structure, different CE architectures have been developed, each with its own peculiarities. In spite of the scarce literature available on the state of the art of the CE, in this article we will offer in a didactic way, a specific and comprehensive vision of the CE, its possible architectures and the algorithms that govern its performance.

KEY WORDS: cognitive radio, cognitive engine, architectures, algorithms, meta-cognition.

1. INTRODUCCIÓN

Hay dos configuraciones principales de radio cognitivo; el Radio Cognitivo completo, CR o "full Mitola" (Fig. 1) y el radio cognitivo solo para "detección de espectro". El primero detecta los parámetros del entorno del espectro radioeléctrico circundante, aprende de lo que se sensa en ese entorno y tiene la capacidad de reconfigurarse automáticamente para usar, de manera eficiente para la transmisión, los espacios disponibles del espectro. Mientras tanto, un radio cognitivo para detección de espectro solo detectará la presencia de canales en un espectro de frecuencia.

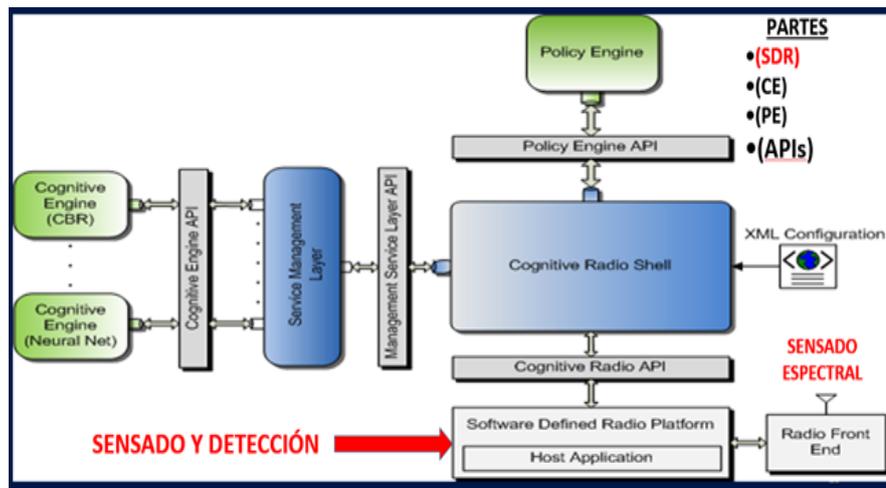


Figura 1: Radio Cognitivo CR "full Mitola".

El CR se soporta sobre una plataforma SDR (Radio Definido por Software) para interactuar con el entorno radioeléctrico y efectuar el sensado y detección del espectro. Los resultados del sensado y detección pasan del "front end" del SDR al soporte del motor cognitivo (Cognitive Radio Shell) a través de un interfaz de aplicación de programa (API) especializado. El motor cognitivo CE es un agente de inteligencia artificial que realiza los procesos de modelado, aprendizaje y optimización necesarios para reconfigurar el propio CR. El motor cognitivo toma información del dominio de usuario (Service Management Layer), del dominio de radio y del motor de políticas a través de diferentes interfaces. El motor de políticas recibe información relacionada con las políticas del dominio de políticas fijado por la Administración de comunicaciones del país en cuestión. Esta información

ayuda al radio cognitivo a decidir sobre las soluciones permitidas (y legales) y bloquea cualquier solución que rompa las regulaciones locales.

A pesar de que en la literatura poco se escribe del avance en el CE, el objetivo de este artículo es ofrecer, de forma didáctica, una visión detallada y completa del desarrollo del motor cognitivo, sus posibles arquitecturas y los algoritmos que rigen su rendimiento. La Sección 2 presenta la arquitectura básica del motor cognitivo CE y la interrelación entre sus bloques. La Sección 3 ofrece una descripción de la etapa de aprendizaje en el radio cognitivo. La Sección 4 resume las tecnologías de IA que soportan al CE. La Sección 5 desarrolla el CE basado en razonamiento de caso (CBR). La Sección 6 muestra un CE meta-cognitivo y la Sección 7 ofrece las Conclusiones.

2. ARQUITECTURA BÁSICA DEL MOTOR COGNITIVO

El Motor Cognitivo CE del Radio Cognitivo CR consiste básicamente en un bloque programador, un núcleo, interfaces de detección, usuario y red (Fig. 2). A su vez, el núcleo (Fig. 3) consiste en una base de datos y bloques de aprendizaje, razonamiento y optimización.

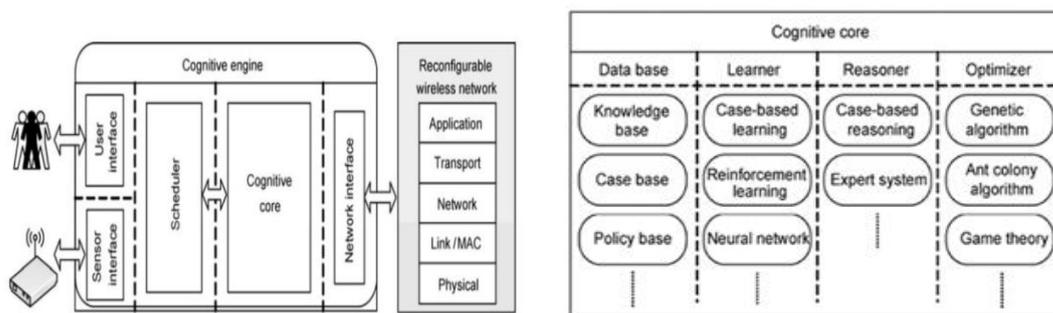


Figura 2: Diagrama básico de bloques de un CE. Figura 3: Diagrama de bloques del “core” del CE.

El motor cognitivo más común, mostrado en la Fig. 2, se compone de:

- Núcleo cognitivo: integra varias tecnologías de inteligencia artificial.
- Programador: hace uso y combina diferentes tecnologías para implementar funciones cognitivas y completar ciertas tareas cognitivas en un entorno particular.
- Interfaz de usuario: proporciona información sobre el dominio del usuario (necesidades y experiencias).
- Interfaz de sensado: recopila información sobre el funcionamiento de la red inalámbrica (por ejemplo, SNR, ocupación del espectro, etc.).
- Interfaz de red: recopila información sobre el dominio de la red.

Como se ilustra en la Fig.3, el núcleo cognitivo es el núcleo del motor cognitivo. Comprende una base de datos y bloques de aprendizaje, razonamiento y optimización. Cada uno de ellos incluye algún tipo de tecnología de inteligencia artificial IA. En el proceso de ejecución del motor cognitivo, el planificador pide ayuda a componentes relacionados del núcleo cognitivo de acuerdo con los diferentes requisitos en el bucle cognitivo. En caso de detección, el programador almacena temporalmente la información en la base de datos del

núcleo cognitivo. A continuación, se auxilia del razonador, que toma la decisión sobre la acción necesaria, y luego del optimizador para optimizar los parámetros. Al final, se solicita al bloque de aprendizaje entrenar nuevos casos y formar nuevos conocimientos. Es obvio que nada sucede en el ciclo cognitivo sin comprometer al núcleo cognitivo.

3. DESCRIPCIÓN DE LA ETAPA DE APRENDIZAJE EN EL CR

Esta sección describe el aprendizaje en el CR y enfatiza cuán crucial es la capacidad de autonomía de aprendizaje en la realización de un dispositivo CR real. En [1] se presenta una encuesta sobre los logros más avanzados en la aplicación de técnicas de aprendizaje automático a los CR.

Como se ilustra en la Fig. 4, existen tres condiciones principales para la inteligencia: 1) Percepción, 2) Aprendizaje y 3) Razonamiento. La percepción es la capacidad de detectar el entorno y los estados internos para adquirir información. El aprendizaje es la capacidad de transformar la información adquirida en conocimiento mediante el uso de metodologías de clasificación automática de modulación de señales (AMC) y generalización de hipótesis. Finalmente, el conocimiento se usa para alcanzar ciertas metas a través del razonamiento. Como resultado, el aprendizaje es el núcleo de cualquier dispositivo inteligente, incluidos, en particular, los CR. El aprendizaje es la herramienta fundamental que le permite a un CR adquirir conocimiento de sus datos observados.

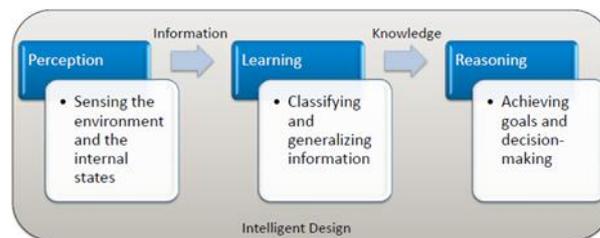


Figura 4: Un diseño inteligente puede transformar la información adquirida en conocimiento mediante aprendizaje.

Primero, la percepción se puede lograr a través de las mediciones de detección del espectro. Esto permite que el CR identifique las actividades de radiofrecuencia (RF) en curso en su entorno circundante. Después de adquirir las observaciones de detección, el CR trata de aprender de ellas para clasificar y organizar las observaciones en categorías adecuadas (conocimiento). Finalmente, la capacidad de razonamiento le permite al CR utilizar el conocimiento adquirido a través del aprendizaje para lograr sus objetivos.

Problemas del aprendizaje en el CR

En este artículo, discutimos varios algoritmos de aprendizaje que pueden ser utilizados por los CR para lograr diferentes objetivos. Para obtener una mejor comprensión de las funciones y similitudes entre los algoritmos presentados, identificamos dos categorías principales de problemas y mostramos los algoritmos de aprendizaje en cada categoría. La organización jerárquica de los algoritmos de aprendizaje y su dependencia se ilustra en la Fig. 5.

Con referencia a la Fig. 5, identificamos dos problemas (o tareas) principales del CR:

- 1) Clasificación de características.
- 2) Toma de decisiones.

Estos problemas son generales en el sentido de que cubren una amplia gama de tareas del CR. Por ejemplo, surgen problemas de clasificación en la detección del espectro, mientras que surgen problemas de toma de decisiones para determinar la política de detección del espectro, el control de potencia o la modulación adaptativa.

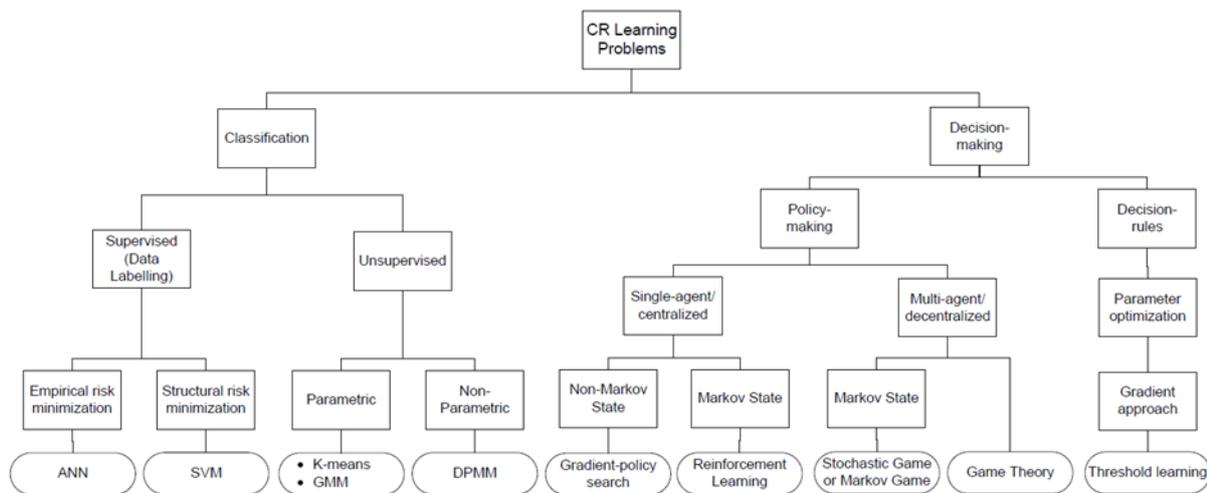


Figura 5: Problemas típicos en el radio cognitivo y sus algoritmos de aprendizaje correspondientes.

Por ejemplo, los algoritmos de clasificación se pueden dividir en dos categorías diferentes: supervisados [2] y no supervisados. Los algoritmos supervisados requieren capacitación con datos etiquetados e incluyen, entre otros, Redes Neuronales Artificiales (ANN) y Máquinas Soportadas Vectorialmente (algoritmos SVM). El algoritmo ANN se basa en la minimización empírica del riesgo y requiere, a diferencia de los modelos estructurales, un conocimiento previo de la distribución observada del proceso. Sin embargo, los algoritmos SVM, que se basan en la minimización del riesgo estructural, han mostrado un rendimiento superior, en particular para pequeños ejemplos de entrenamiento, ya que evitan el problema del sobreajuste.

A diferencia de los enfoques supervisados, los algoritmos de clasificación no supervisados no requieren datos de entrenamiento etiquetados y pueden clasificarse como paramétricos o no paramétricos. Los clasificadores paramétricos no supervisados incluyen los algoritmos de K-means y Modelo de Mezcla Gaussiana (GMM) y requieren un conocimiento previo del número de clases (o grupos). Por otro lado, los clasificadores no supervisados no paramétricos no requieren un conocimiento previo del número de clústeres o agrupamientos y pueden estimar esta cantidad a partir de los datos observados, por ejemplo, utilizando métodos basados en el modelo de mezcla de proceso de Dirichlet (DPMM).

La toma de decisiones es otra tarea importante que ha sido ampliamente investigada en aplicaciones de CR. Los problemas de toma de decisiones a su vez se pueden dividir en

reglas de toma de decisiones y políticas. Los problemas de formulación de políticas se pueden clasificar como centralizados o descentralizados. En un problema descentralizado multi agente [3] de formulación de políticas, se determina un conjunto óptimo de acciones durante un período de tiempo determinado, definiendo así una política óptima (o una estrategia óptima en la terminología de la teoría de juegos). En escenarios de múltiples agentes, la teoría de juegos se propone como una solución que puede capturar la naturaleza distribuida del entorno y las interacciones entre los usuarios. Con una suposición de estado de Markov, el sistema se puede modelar como un juego de Markov o un juego estocástico, mientras que, de lo contrario, se pueden usar modelos de juegos convencionales.

En un escenario centralizado con simple agente con estado de Markov, los algoritmos de aprendizaje reforzado (RL) se pueden utilizar para obtener una solución óptima al Proceso de Decisión de Markov (MDP), sin conocimiento previo de las probabilidades de transición. En entornos que no son de Markov, se pueden obtener políticas óptimas basadas en algoritmos de búsqueda de políticas de gradiente que buscan directamente soluciones en el espacio de políticas. Finalmente, las reglas de decisión forman otra clase de problemas de toma de decisiones que pueden formularse como problemas de prueba de hipótesis para ciertos modelos de observación. En presencia de incertidumbre sobre el modelo de observación, se pueden aplicar herramientas de aprendizaje para implementar una determinada regla de decisión. Por ejemplo, se utiliza un algoritmo de aprendizaje de umbral para optimizar el umbral de la prueba de Neyman-Pearson bajo incertidumbre sobre la distribución del ruido.

En resumen, hasta ahora, hemos identificado dos clases principales de problemas y hemos determinado las condiciones bajo las cuales se pueden aplicar ciertos algoritmos para estos problemas. Por ejemplo, el algoritmo DPMM puede aplicarse para problemas de clasificación si se desconoce el número de grupos, mientras que el SVM puede ser más adecuado si los datos etiquetados están disponibles para el entrenamiento. Los algoritmos de aprendizaje que se presentan en este artículo ayudan a optimizar el comportamiento del agente de aprendizaje, en particular el CR en condiciones de incertidumbre. Por ejemplo, el RL conduce a la política óptima para los MDP, mientras que la teoría del juego conduce al equilibrio de Nash, siempre que exista, de ciertos tipos de juegos. El algoritmo SVM optimiza el riesgo estructural al encontrar un mínimo global, mientras que el ANN solo conduce al mínimo local del riesgo empírico. El DPMM es útil para la clasificación no paramétrica y converge a la distribución de probabilidad estacionaria de la cadena de Markov en el procedimiento de muestreo Gibbs de Montekov de la cadena de Markov de Montecarlo (MCMC). Como resultado, los algoritmos de aprendizaje propuestos logran cierto criterio de optimización dentro de sus contextos de aplicación.

Hay un tercer problema relacionado con el proceso de aprendizaje en un CR que generalmente no se aborda frecuentemente en la literatura. Por lo general, el diseñador de radio analizará cada método de comunicación en términos del objetivo deseado bajo los modelos de canal asumidos. Luego, el diseñador combinará el análisis para llegar al conjunto de reglas de adaptación que mejor cumpla con el objetivo del radio. Realizar el análisis requerido suele ser una tarea larga, que requiere una gran cantidad de esfuerzo, especialmente cuando se trata de una gran cantidad de métodos diferentes. Además, si los modelos de canal no se mantienen o los métodos de comunicación funcionan de una manera

no esperada, el diseño se vuelve discutible. Lo mismo se aplica si el objetivo deseado cambia. Se desea que el radio use los métodos más aplicables y eficientes para aprender y optimizar. Por lo tanto, el objetivo es diseñar un CE que haga posible el comportamiento deseado. Este CE no solo aprende cuál es el mejor método, dado el objetivo y las condiciones del canal, sino que también aprende las habilidades del radio independientemente del objetivo. Si el objetivo cambia, las habilidades conocidas del radio se pueden usar para acelerar el proceso de optimización y minimizar la necesidad de un nuevo aprendizaje.

Para decirlo en términos más clásicos, abordamos el problema de equilibrar la exploración frente a la explotación [4]. La exploración se refiere a probar opciones con resultados beneficiosos desconocidos pero potenciales. Por otro lado, la explotación se refiere al uso de lo que ya se sabe que tiene la métrica de rendimiento más alta. Los métodos centrados en la explotación, en lugar de la exploración, generalmente se conocen como métodos codiciosos o miopes. La exploración implica un riesgo desconocido, mientras que la explotación tiende a ser más segura en términos de expectativas. Dependiendo de la situación, la explotación podría en última instancia limitar el desempeño a largo plazo. En pocas palabras, el problema de exploración vs. explotación es: ¿elegimos una opción que garantice el rendimiento a corto plazo (explotación) o elegimos una opción que pueda dañar el rendimiento a corto plazo, pero mejora el rendimiento a largo plazo del sistema? ¿Cómo equilibramos esos dos objetivos en conflicto? Este es un problema universal y es necesario tomar prestados los resultados de otros campos, como el aprendizaje reforzado y la programación dinámica, y aplicarlos al contexto de selección de la mejor técnica de comunicación en el sistema.

4. TECNOLOGÍAS DE IA QUE SOPORTAN AL CE

El propósito general de esta Sección es presentar adecuadamente las tecnologías de IA que soportan las tecnologías de aprendizaje automático, el razonamiento y la toma de decisiones [5]. Comenzaremos con el análisis teórico de juegos, continuaremos con el aprendizaje reforzado RL, las redes neuronales artificiales ANN, las tecnologías de razonamiento y toma de decisiones y al final presentaremos los algoritmos genéticos GA.

Análisis teórico de juegos. La teoría de juegos es una herramienta matemática que analiza las interacciones estratégicas entre múltiples tomadores de decisiones. Representa la toma de decisiones de múltiples agentes, especialmente cuando el jugador decide sobre sus acciones en función de sus acciones pasadas y las acciones pasadas seleccionadas por otros jugadores. Esto nos permite modelar eficientemente un proceso de aprendizaje de cada jugador y estudiar la estabilidad (equilibrio) del proceso de aprendizaje. Hay algunos beneficios al estudiar los radios cognitivos en un marco teórico de juegos. Primero, el comportamiento y la acción del usuario de la red en términos de intercambio dinámico del espectro se puede analizar en la estructura formal del juego. A continuación, obtenemos varios criterios de optimización para el problema de intercambio de espectro, porque la optimización del uso del espectro es generalmente un problema de optimización de objetivos múltiples que puede ser muy difícil de analizar y resolver. En este caso, la teoría de juegos nos proporciona criterios de equilibrio bien definidos para medir la optimización del juego en varios entornos de juego. Y tercero, el beneficio más importante, es que la teoría de juegos no cooperativa nos permite derivar enfoques distribuidos eficientes para compartir el espectro dinámico

solo con información local. Esto puede ser muy deseable en los casos en que no está disponible el control centralizado (no hay un “fusión center” en la red).

En los modelos teóricos de juegos de las redes de radio cognitivos (CRN), los radios cognitivos son los principales actores que las forman. Los radios cognitivos están tomando acciones como elegir la potencia de transmisión, seleccionar el canal de comunicación, reconfigurar los circuitos de radio para trabajar con diferentes esquemas de modulación y demodulación, etc. Estas acciones se basan en observaciones del entorno operativo, por ejemplo, la disponibilidad de canal, tasa de error de trama o nivel de interferencia. Durante la operación, el radio aprende de sus propias acciones pasadas y de observar las acciones de otros radios en la red y luego puede modificar sus acciones en consecuencia. Dependiendo del modo de operación y colaboración de los jugadores involucrados, tenemos que usar diferentes tipos de juegos para modelar la red de radio cognitivo CRN.

Juegos repetidos. El juego repetido es el concepto teórico del juego más simple. Cada etapa del juego se repite con un horizonte de tiempo generalmente infinito. Un buen ejemplo de juego repetido puede ser múltiples usuarios secundarios (SUs) (radios cognitivos) que compiten por el acceso secundario a los canales cuando el titular principal de la banda de frecuencias (PU) no está activo. En la terminología de los juegos repetidos, sus acciones son la selección de un canal del espectro del usuario primario, y la selección puede verse influenciada por el historial de actividad del usuario primario y el patrón de utilización del canal por parte de los usuarios secundarios. Por ejemplo, un canal que fue ocupado frecuentemente por el usuario primario puede ser evitado por todos los usuarios secundarios. El equilibrio de Nash se aplica fácilmente a los juegos repetidos porque en un perfil de estrategia de equilibrio de Nash ninguno de los jugadores puede aumentar su rentabilidad esperada seleccionando una estrategia diferente.

Juegos potenciales. Como se indicó anteriormente, para una operación estable de una red, es deseable lograr un equilibrio de Nash, que ofrezca la mejor estrategia, dado que todos los demás jugadores también se adhieren a su estrategia de equilibrio. La pregunta aquí es cómo encontrar un equilibrio de Nash en sistemas cognitivos distribuidos. Un buen enfoque es permitir a los jugadores ajustar sus estrategias de forma iterativa en función de sus observaciones pasadas y presentes y, con suerte, en algún momento el proceso podría converger en un punto de equilibrio. En casos especiales, cuando el juego tiene estructuras especiales, las iteraciones pueden converger a un equilibrio de Nash. El juego potencial es uno de esos formatos de juego especiales donde se garantiza la convergencia a un equilibrio de Nash

Juegos de negociación. El juego de negociación es un juego cooperativo en el que las personas intentan llegar a un acuerdo de beneficio mutuo. En este juego, los jugadores tienen conflictos de intereses y no se puede imponer ningún acuerdo a ninguna persona sin su aprobación.

Juegos de coalición. Los juegos de coalición pueden modelar varias acciones en redes de radio cognitivos CRN. En cuanto al juego de coalición, es un tipo de juego cooperativo que describe cómo un conjunto de jugadores puede cooperar con otros formando grupos de cooperación y así mejorar su desempeño el juego.

Juegos estocásticos. En otros tipos de juegos, los jugadores normalmente enfrentan el mismo escenario de juego en cada momento, lo que significa que el juego y las estrategias de los jugadores no dependen del estado actual de la red. Para estudiar los comportamientos de cooperación y competencia de los usuarios cognitivos en un entorno dinámico, la teoría de los juegos estocásticos encaja mejor.

Técnicas de aprendizaje reforzado

El aprendizaje supervisado es una tarea bastante difícil en el campo donde esto implica un mapeo entre situaciones y acciones mientras se interactúa con otros agentes. Es difícil proporcionar las acciones correctas asociadas con la situación actual a los agentes mientras se aprende en un entorno dinámico y no estacionario. Con este fin, las técnicas de aprendizaje reforzado son más versátiles en el dominio de múltiples agentes, ya que les permite a los agentes descubrir de forma autónoma el mapeo de la situación-acción a través del mecanismo de prueba y error. Los agentes están aprendiendo al interactuar con su entorno (incluidos otros agentes) y el mecanismo de aprendizaje es impulsado por recompensas. Además de la recompensa inmediata, los agentes de aprendizaje reforzado deben tener en cuenta el rendimiento a largo plazo.

Aprendizaje reforzado con simple agente. Generalmente, el aprendizaje reforzado se realiza en el proceso de decisión de Markov MDP en el dominio de agente único. La tarea del agente es diseñar una secuencia de pares de estado-acción (es decir, una política) para maximizar la recompensa descontada esperada. El algoritmo Q-learning es un algoritmo sin modelo (no se conocen las funciones de transición de estado y de recompensa) que estima una función óptima de valor de acción denominada función Q. La función Q es el retorno esperado de un par de estado-acción para una política dada.

Aprendizaje reforzado agente múltiple. En el dominio de aprendizaje reforzado de múltiples agentes [3], se ha explorado ampliamente la posibilidad de un uso directo del algoritmo de aprendizaje Q. Las condiciones principales para que el método funcione es ignorar la presencia de otros agentes en el mismo entorno y considerar los resultados de esta interacción como ruido. La presencia de otros agentes provoca un entorno no estacionario, lo que significa que el resultado teórico sobre la convergencia ya no es válido. A pesar de sus limitaciones, el enfoque de aprendizaje Q de múltiples agentes se ha adoptado en la literatura de radio cognitivo. Las aplicaciones de redes de radio cognitivos se caracterizan por la heterogeneidad intrínseca del comportamiento de los radios. Esto favorecerá a los agentes que conocen y, por lo tanto, pueden explotar las estrategias de otros jugadores. Por lo general, un agente elige la mejor respuesta en función de su modelo actual, de las estrategias de los otros agentes. Este modelo se refina repetidamente después de cada observación del movimiento de otros jugadores. En general, los algoritmos de aprendizaje reforzado seleccionan una acción con probabilidad proporcional al premio total recibido en el pasado como resultado de elegir esa acción. Con el fin de lograr un equilibrio entre exploración y explotación, evitando las acciones más insatisfactorias, generalmente se adopta una regla de selección de acciones softmax, donde las acciones se clasifican y ponderan de acuerdo con su utilidad estimada.

Redes neuronales artificiales

Las redes neuronales artificiales están formadas por neuronas interconectadas para imitar las propiedades de las redes neuronales biológicas. Se pueden usar para diferentes problemas de optimización, incluso para resolver problemas de inteligencia artificial en el campo del radio cognitivo. Por lo tanto, las redes neuronales ya se usaban en varias aplicaciones de radio cognitivo, como la selección dinámica de canales, la detección de canales, la predicción del espectro y el aprendizaje. Debido a su naturaleza no lineal, algunos autores examinaron un modelo de red neuronal de perceptrón multicapa (MLP) para el aprendizaje. Un MLP consta de múltiples capas de nodos en un gráfico que está completamente conectado de una capa a la siguiente. MLP utiliza una técnica de aprendizaje supervisado llamada retro-propagación para capacitar a la red. En un ejemplo de una aplicación, algunos autores seleccionaron un sistema WiMax, que puede elegir un cierto modo de modulación para una SNR dada, como una tecnología de radio configurable, con un sensor para medir la SNR en el entorno circundante. La tasa de información como calidad de servicio se representa como la necesidad del usuario y se envía al bloque de aprendizaje a través de la interfaz de usuario y, por último, WiMax envía el rendimiento del sistema en forma de BER y el rendimiento al bloque de aprendizaje a través de la interfaz de radio.

Tecnologías de razonamiento y toma de decisiones

Una parte importante del proceso cognitivo también son los mecanismos de inferencia necesarios para relacionar el conocimiento aprendido y el adquirido, y se denominan mecanismos de razonamiento. Los tipos de razonamiento más destacados utilizados en el campo de las redes de radio cognitivos CRN son: razonamiento proactivo, razonamiento reactivo, razonamiento inductivo, razonamiento deductivo, razonamiento de una sola vez, razonamiento secuencial, razonamiento centralizado y razonamiento descentralizado.

Los mecanismos de razonamiento son parte crucial del proceso cognitivo. Los métodos de razonamiento más relevantes dentro del contexto de las redes cognitivas son: razonamiento restringido distribuido, redes Bayesianas, meta-heurística, heurística, razonamiento multiobjetivo. Las realizaciones de razonamiento son combinaciones de un tipo de razonamiento específico y un método de razonamiento específico. Se conocen realizaciones específicas de razonamiento que pueden implementarse efectivamente en un contexto cognitivo de redes de radio y que se describen brevemente a continuación.

Razonamiento basado en caso CBR. El razonamiento basado en casos es una combinación de razonamiento y aprendizaje. “La base de conocimiento se denomina base de caso, donde los casos son representaciones de experiencias pasadas y sus resultados”. La base de casos está bien estructurada para poder compartirla fácilmente entre diferentes entidades dentro del proceso de cognición y la propia red de radio cognitivo. Al compartir las entidades, se habilita el uso de la experiencia pasada que hace que la red sea más sólida

Razonamiento de subsunción. El razonamiento de subsunción representa una descomposición de la meta objetivo, en sub metas más pequeñas. La descomposición conduce a un conjunto de módulos que funcionan en paralelo, que se construyen uno sobre el otro. Se supone que las capas superiores funcionan a una escala de tiempo más larga y aprovechan las funciones complejas de optimización y aprendizaje, donde las capas inferiores proporcionan un acoplamiento estrecho entre los sensores y la actuación. A

menudo emplean técnicas de aprendizaje reactivo con poco o ningún estado (por ejemplo, árboles de decisión y mapas auto organizados). Como resultado, cada capa aporta su solución parcial (meta secundaria) al objetivo general, en su mayoría complejo.

Fuzzy logic reasoning. Un enfoque prometedor para proporcionar un razonamiento lógico difuso (Fuzzy Logic) en redes de radio cognitivos se denomina Mapas Cognitivos Difusos (FCM). "Los FCM representan un medio para modelar sistemas a través de las relaciones causales que los caracterizan". Se representan gráficamente, donde el nodo representa un evento o un proceso y los bordes entre dos nodos indican una relación causal entre ellos. Son muy potentes porque, a diferencia de las redes bayesianas, pueden manejar bucles de retroalimentación, usan un método de inferencia directo en forma de simple multiplicación y umbral y tienen la capacidad de fusionarse en FCM combinado, que puede suavizar los sesgos discrepantes derivados de la fusión de los FCMs. También hay algunas desventajas en las aplicaciones prácticas de la red de radio cognitivo porque la inferencia de causalidad entre eventos basada solo en datos de observación no es inmediata. Los FCM pueden ser particularmente útiles en las redes de radio cognitivos porque permiten el uso de capas cruzadas y el uso de esta información para razonar dentro del ciclo cognitivo. Por ejemplo, Facchini y Granelli propusieron métodos matemáticos para representar interacciones complejas entre varias capas apiladas de protocolos basadas en FCM.

Razonamiento basado en políticas.

"El razonamiento basado en políticas se basa en el concepto de políticas dinámicamente derivables e intercambiables que superan el firmware tradicional codificado en los dispositivos actuales, ofreciendo una mayor flexibilidad y eficiencia para el proceso cognitivo". Para este fin, las políticas se representan utilizando un lenguaje de políticas específico que consiste en un conjunto de ontologías claramente definidas. Un lenguaje de ontología define el significado de los términos en vocabularios y sus relaciones. En este caso, la arquitectura del sistema basada en políticas comprende tres elementos principales: un servidor de políticas, un motor de políticas (PE) y un bloque de herramientas de manejo de políticas como se muestra en la Fig. 6.

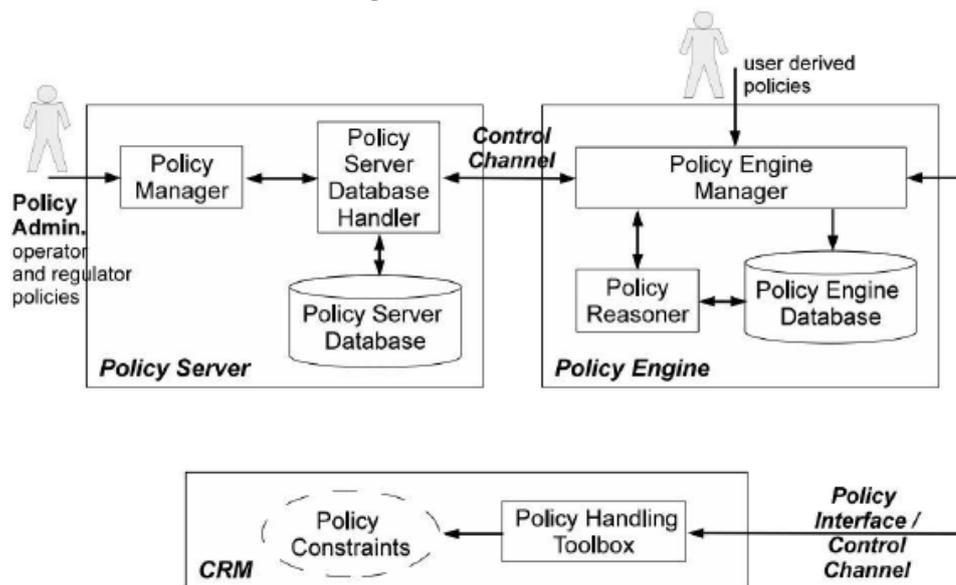


Figura 6: Arquitectura del sistema basado en políticas.

El servidor de políticas es el repositorio central de políticas en la red. Almacena políticas provenientes de operadores y reguladores y consiste en:

- Base de datos del servidor de políticas: para realizar un seguimiento de todos los usuarios activos y las políticas en la red y las asociaciones de usuarios / políticas.
- Controlador de la base de datos del servidor de políticas: para administrar la base de datos, difundir las políticas a los usuarios e informarles sobre los cambios en las políticas.
- Administrador de políticas: para extraer políticas de la base de datos, realizar los cambios apropiados y reflejar los cambios en la base de datos.

El motor de políticas es el punto de decisión de la política (PDP). Está ubicado en un terminal inalámbrico y es responsable de razonar sobre políticas activas y presentar resultados al Administrador de recursos cognitivos y comprende:

- Base de datos del motor de políticas: para el almacenamiento local de políticas externas y derivadas localmente.
- Administrador del motor de políticas: para manejar la comunicación del PE con otras entidades de red.
- Razonador de políticas: para realizar un proceso de razonamiento en el conjunto de políticas después de cada consulta de política recibida y proporcionar el espacio de solución al Administrador de recursos cognitivos.

El Bloque de Herramientas de Manejo de Políticas (Policy Handling Toolbox) es una parte interna del Administrador de Recursos Cognitivos (CRM-Cognitive Resource Manager) que representa el punto de aplicación de políticas (PEP-Policy Enforcement Point) en la arquitectura. CRM es responsable de la optimización, el aprendizaje y la toma de decisiones. El sistema basado en políticas permite operaciones cruciales de las redes de radio cognitivos CRN, tales como detección de oportunidades de espectro, movilidad del espectro, gestión del espectro.

Algoritmos genéticos.

Los algoritmos genéticos GA están diseñados para seleccionar los parámetros de transmisión óptimos y evolucionarlos hasta alcanzar el valor óptimo para un objetivo determinado. Son una clase de razonamiento artificial donde la búsqueda se realiza de manera similar a la evolución genética en ciencias de la vida.

Las soluciones a un conjunto de problemas están representadas por cadenas binarias. Las cadenas que se consideran buenas se dividen y se recombinan con otras cadenas buenas para formar nuevas soluciones y las cadenas pobres o malas pueden morir fuera del conjunto de soluciones. Esas decisiones son tomadas por la función de aptitud (fitness) con parámetros como entradas y una puntuación basada en los objetivos específicos del radio como salida. Las cadenas se someten a un proceso llamado mutación que consiste en voltear aleatoriamente bits para evitar que se produzca una minimización local.

Dada su naturaleza aleatoria, el tiempo de cálculo rápido y la capacidad de generar espontáneamente soluciones únicas, los algoritmos genéticos son buenos candidatos para radios cognitivos. Se utilizan principalmente para determinar el conjunto óptimo de parámetros, cuando el espacio de búsqueda es demasiado grande para utilizar la búsqueda mediante el método de “fuerza bruta”. Por ejemplo, Newmann, implementó un algoritmo genético para radio cognitivo que inicialmente generó una población aleatoria de 100 individuos. Cada miembro de la población contiene un conjunto de soluciones de valores de parámetros de salida representados como un cromosoma.

En la siguiente etapa, la evolución se produjo al dividir y combinar cromosomas para formar nuevas generaciones. Se utilizaron funciones de aptitud (fitness) para impulsar la selección de cromosomas para combinar, y también usaron filtros para evitar que las soluciones no posibles ingresaran al conjunto de soluciones. El tamaño de la población de cada generación era de 50 y las generaciones más nuevas de cromosomas se almacenaban en el radio para su procesamiento futuro.

Se utilizó el algoritmo genético para motor cognitivo CE en la simulación del sistema multi portadora con 64 sub-portadoras y tres escenarios diferentes (modo de baja potencia, modo de emergencia, modo multimedia). Los resultados mostrados en la Fig. 7 validaron que las funciones de aptitud conducen la evolución del algoritmo genético en la dirección correcta para optimizar los objetivos dados para cada escenario.

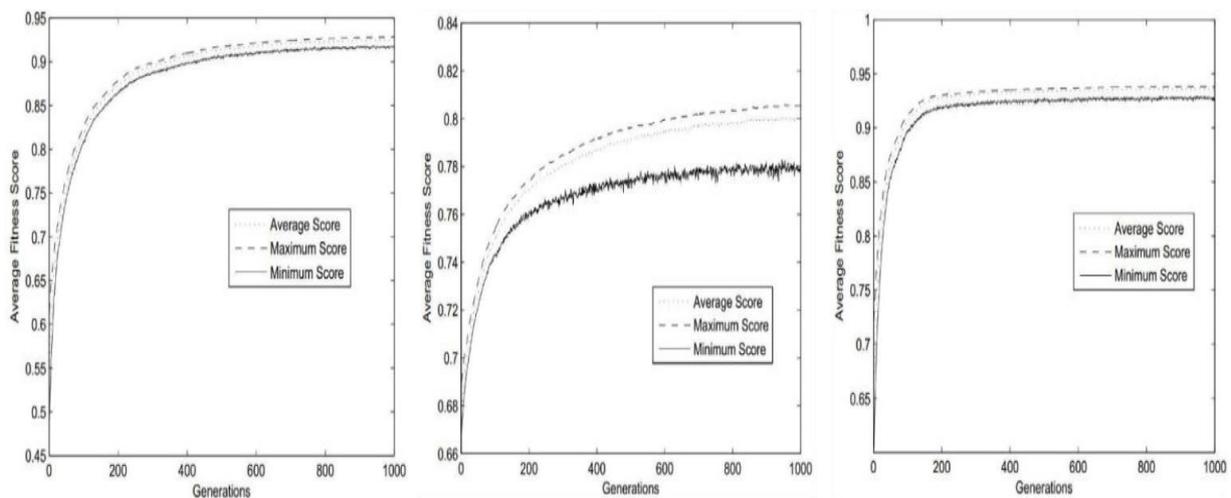


Figura 7: Modos de bajo consumo, emergencia y multimedia.

5. CE BASADO EN RAZONAMIENTO DE CASO

El razonamiento basado en casos se refiere al proceso de razonamiento basado en experiencias registradas anteriores (casos). Un razonador basado en casos es una entidad que realiza un razonamiento basado en casos. En la discusión de este artículo, CBR puede referirse al razonamiento basado en casos o al razonador basado en casos según el contexto. El Razonador Basado en Caso CBR es el módulo central del CBR-CE. Esta sección se centra en el diseño del módulo CBR. Dado que un caso es el elemento fundamental en un sistema CBR, su concepto se discute primero y luego, se explican en detalle las funcionalidades de los diferentes componentes de CBR. Un caso, el elemento fundamental

en un sistema CBR, representa una experiencia. Todos los demás componentes en un sistema CBR toman un caso como entrada o como salida. Un caso se define de la siguiente manera:

"Un caso es un conocimiento contextualizado que representa una experiencia que enseña una lección fundamental para lograr los objetivos del razonador" [6].

Tenga en cuenta que, aunque un caso representa una experiencia, no todas las experiencias son un caso útil. La esencia de un caso radica en su capacidad de "enseñar una lección útil". En otras palabras, una experiencia que vale la pena recordar por el razonador es lo que ayuda al razonador a alcanzar una meta, advierte al razonador contra una falla potencial o especifica una situación inesperada. En general, CBR consiste en la representación e indexación de casos, la selección y recuperación de casos, la evaluación y adaptación de casos, el aprendizaje de casos y el mantenimiento de la base de datos de casos.

Representación de casos e indexación. La representación de casos formatea la información de entrada de modo que esta información pueda ser entendida por otros módulos en el CBR. Un caso generalmente consta de dos partes: el contenido y los índices. El contenido de un caso registra la experiencia o la lección que enseña. Contiene la siguiente información: descripción del problema, la solución y el resultado. El otro aspecto importante de un caso son sus índices, que especifican el contexto donde se obtiene el contenido de un caso y donde es útil, y describen las características distintivas de un caso. Para ayudar a los lectores, ponemos como ejemplo, la estructura de caso utilizada en el diseño CBR-CE que se muestra en la Fig. 8. El campo "Problema" especifica el evento general (por ejemplo, nueva solicitud de servicio del equipo local del usuario (CPE) y detección de usuario primario PU, la condición del canal (pérdidas de ruta) y el requisito de calidad del servicio (QoS) de tasa de bit erróneos (BER). Este campo se usa para formar el índice de un caso. El campo "Solución" incluye información sobre el esquema de modulación y codificación, entrelazado, potencia de transmisión y uso de ancho de banda. Estos son los parámetros del sistema que el CE puede ajustar. El campo "Resultado" incluye información de retroalimentación (utilidad lograda) y guía la actualización del caso en la base de datos de casos.

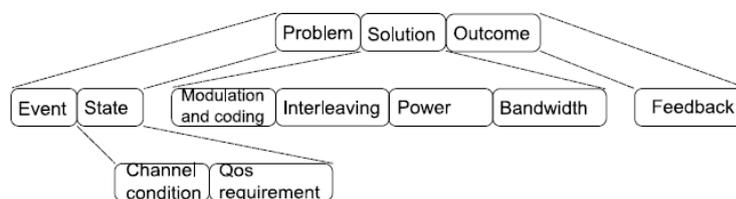


Figura 8: Estructura del caso.

Selección y recuperación de casos. El módulo de selección y recuperación de casos busca en la base de datos de casos, aquellos que satisfagan hasta cierto punto la solicitud. En este diseño CBR-CE, por ejemplo, se desarrolla un proceso de recuperación guiado por políticas. El vector de políticas obtenido del módulo del motor de políticas contiene una máscara de espectro para una banda de frecuencia específica. Los casos se recuperan primero de la base

de datos de casos de acuerdo con sus índices. Luego, los casos recuperados se comparan con el vector de política. Aquellos casos que cumplan con el vector de la política se recopilarán para su posterior procesamiento, los llamamos casos válidos. El criterio de recuperación es el aspecto más importante en la recuperación efectiva de casos.

Evaluación y adaptación de casos. El módulo de evaluación de casos evalúa el rendimiento del caso recuperado a partir del módulo de selección y recuperación de casos mediante el uso de un modelo de rendimiento o aplicando la solución y observando el resultado. Se espera que el caso recuperado sea aplicable al nuevo problema. Sin embargo, la aplicabilidad o el rendimiento no están garantizados. El caso recuperado se registra como una solución a un problema anterior y se recupera como una posible solución al nuevo problema debido a la similitud entre el problema anterior y el nuevo. Si el rendimiento del caso recuperado no es satisfactorio, el módulo de adaptación del caso modifica el caso.

Aprendizaje de casos y Biblioteca de casos / Mantenimiento de bases de datos. El sistema CBR recuerda las experiencias como casos en la base de datos de casos. El CBR obtiene información adicional, o aprende, resolviendo problemas nuevos o recibiendo comentarios. A medida que aumenta la experiencia, se acumulan más casos en la base de datos de casos. También se puede incorporar una nueva experiencia en la base de datos de casos actualizando los casos existentes. De esta manera, el tamaño de la base de datos de casos no aumentará linealmente con el número de problemas nuevos y finalmente puede converger.

Funcionalidades del módulo CE.

En la Fig. 9 podemos apreciar el CBR-CE para aplicación en Red de Área Regional Inalámbrica (WRAN).

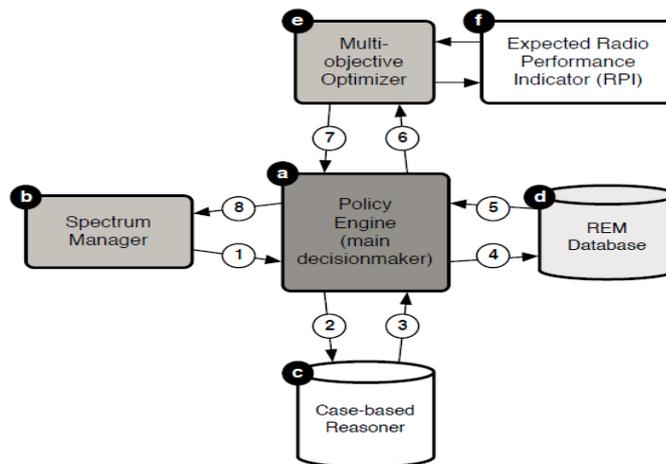


Figura 9: Marco del CBR-CE para aplicación WRAN.

Las funcionalidades son las siguientes:

Administrador de espectro (b) (SM). El SM monitoriza el entorno de radio e interactúa con el hardware de radio físico. Extrae la información del módulo de detección de espectro para el estado del entorno de radio e intercambia información con el módulo de mapa de entorno de radio (d) (REM). Además, asigna recursos que incluyen canales y sub-portadoras de acuerdo con la solución del módulo optimizador de objetivos múltiples (e).

Motor de Políticas PE. En el motor de política (a) se pueden esconder las puertas traseras y los ataques de imitación de un usuario primario no existente (PUE- Primary user emulation) y es por ello que es un elemento clave en la futura adopción de un estándar comercial internacional. El módulo PE especifica las políticas generales, incluidos el estándar, la regulación y la especificación personalizada. Esta información de política general se utiliza para guiar el funcionamiento del módulo de razonamiento basado en casos. El PE verifica la legitimidad de las soluciones devueltas por el módulo de razonamiento basado en casos y el módulo optimizador de objetivos múltiples.

Razonador basado en casos (CBR). El módulo CBR (c) es el módulo central del CBR-CE. Es responsable de proporcionar soluciones candidatas basadas en la solicitud del módulo PE. Como hemos discutido anteriormente en detalles, los componentes básicos del CBR incluyen representación e indexación de casos, selección y recuperación de casos, evaluación y adaptación de casos, y aprendizaje de casos y mantenimiento de la biblioteca / base de datos de casos.

Base de datos del Mapa de Entorno de Radio (REM). La base de datos REM se utiliza para almacenar parámetros específicos de escenarios del sistema, como características geográficas, disponibilidad de red y servicio, estadísticas de espectro, ubicación y actividades de radio, políticas y experiencias.

Optimizador de objetivos múltiples (MOO). El MOO adapta la solución devuelta por el CBR para satisfacer los requisitos específicos de calidad del servicio QoS del nuevo problema.

6. CE METACOGNITIVO

Durante casi dos décadas, los diseñadores de CE han estado trabajando continuamente para comprender y desarrollar mejores técnicas de aprendizaje para el CR. Por lo general, han tomado prestadas ideas del aprendizaje automático y la inteligencia artificial para diseñar sus CE. Ejemplos notables incluyen redes neuronales artificiales ANN, algoritmos genéticos GA y razonamiento basado en caso CBR. Además, se han utilizado técnicas de aprendizaje reforzado, como el índice ϵ -greedy, softmax y Gittins. Además, también se utilizan para crear CE, otras técnicas como la optimización por enjambre de partículas (PSO) y la optimización por colonias de hormigas.

Los diferentes tipos de CE tienen sus propias ventajas y desventajas. Algunos funcionan muy bien en condiciones de alta SNR; otros son más efectivos en condiciones de baja SNR. El aspecto más importante del diseño de algoritmos CE es proporcionar niveles de rendimiento predecibles y más seguros. Por lo tanto, el CE meta-cognitivo [7] se propone para proporcionar el nivel de predicción mencionado para varios tipos de CE. Desde el exterior, un meta-CE parece ser un CE regular, es decir, un CE que proporciona estimaciones de rendimiento esperadas. En el interior, un meta-CE está hecho de uno o más CE.

El primer esfuerzo fue de Gadhiok [8], quien propuso una arquitectura primitiva de meta-cognición. El meta-CE que se describe en este artículo [7] emplea un método general de caracterización del desempeño para evaluar el desempeño de algoritmos de CE individuales. Además, este meta-CE puede identificar distintos escenarios operativos basados en el nivel de rendimiento de los CE individuales. La meta-cognición se define como pensando sobre pensar.

Hay tres componentes interrelacionados para la meta-cognición: conocimiento meta-cognitivo, la monitorización y el control. Estos componentes están integrados con la cognición primaria, que se refiere a pensamientos a nivel de objeto o al proceso de un algoritmo CE individual. El conocimiento meta-cognitivo se deriva de las creencias que los CE individuales generan sobre sus decisiones (por ejemplo, "el CE no considera todos los métodos de comunicación cuando se enfrenta a una baja potencia"). La monitorización meta-cognitiva es el proceso mediante el cual un agente evalúa sus propios pensamientos para compararlos (por ejemplo, "no considerar todos los métodos de comunicación disponibles puede llevar a elegir uno inapropiado para las condiciones del canal"). El control meta-cognitivo se refiere a la regulación del pensamiento del agente (por ejemplo, "si el CE no tiene suficiente potencia o tiempo para considerar todos los métodos de comunicación, debe mantenerse con el método de comunicación más sólido que conoce actualmente").

La Fig. 10 muestra la conexión entre los tres componentes de la meta-cognición y el funcionamiento del meta-CE: el meta conocimiento se traduce en el cálculo de los indicadores principales (KI) que indican el estado del progreso del aprendizaje, y las curvas de aprendizaje y la caracterización del desempeño que analizan el desempeño de los CE individuales. La meta-monitorización se traduce en caracterización de canales, comparando los resultados de desempeño de los CE individuales y monitorizando el desempeño en tiempo real del meta-CE. Finalmente, el control meta-cognitivo se traduce en seleccionar el CE más apropiado y ajustar sus parámetros para el escenario operativo actual.

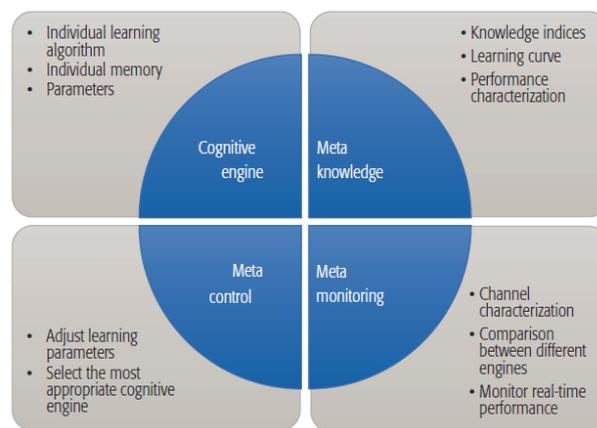


Figura 10: Los componentes meta-cognitivos psicológicos y su aplicación a las funciones de un motor meta-cognitivo.

La Fig. 11 muestra que el funcionamiento del meta-CE se puede resumir en seis pasos. Primero, cualquier información previa disponible (1), como los resultados de la experiencia previa y los resultados del aprendizaje, se utiliza para proporcionar una estimación inicial del rendimiento esperado. En segundo lugar, el módulo de caracterización del rendimiento

Figura 12: Curvas de aprendizaje basadas en la media y la desviación estándar.

Aunque observar los resultados de un algoritmo CE proporciona mucha información sobre cómo aprende, la cantidad real de conocimiento que obtiene un algoritmo CE puede variar. El componente de monitorización meta-cognitivo opera monitorizando regularmente el desempeño en tiempo real del algoritmo CE seleccionado.

La Fig. 13 ilustra la cantidad de conocimiento obtenido por los algoritmos CE. Se muestra que el nivel de conocimiento del CE algoritmo 2, obtenido hasta el paso de tiempo 50 aproximadamente (cada paso es de 0.1 mseg), coincide con el CE algoritmo 3; sin embargo, tienen un rendimiento drásticamente diferente (como se muestra en la Fig. 12). Aunque el CE algoritmo 3 parece tener una ventaja de rendimiento, el conocimiento obtenido sugiere que ambos algoritmos CE mejoraron significativamente. Esto es evidente en el paso 150, en el que el CE algoritmo 2 supera al CE algoritmo 3.

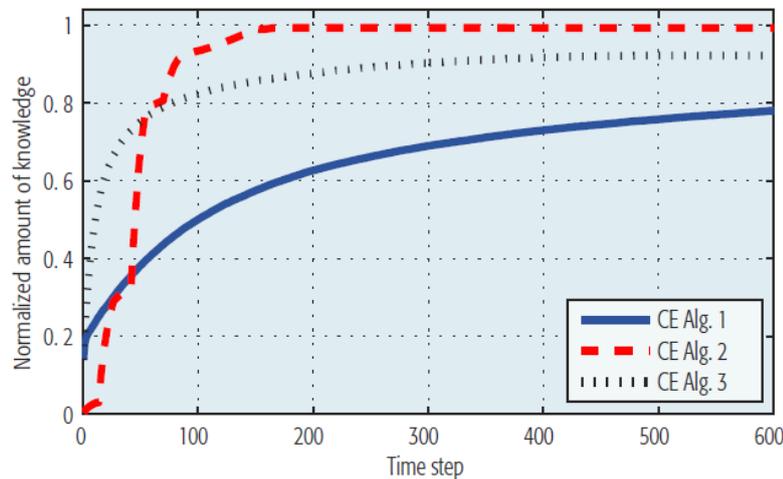


Figura 13: Curva de aprendizaje basada en la cantidad estimada de conocimiento.

Los algoritmos de clasificación utilizados para clasificar los escenarios operativos se actualizan continuamente. El componente de control meta-cognitivo utiliza la información de monitorización actualizada para tomar su decisión crítica de cambiar entre los algoritmos CE disponibles o ajustar los parámetros de aprendizaje de un algoritmo CE particular. El componente de control meta-cognitivo se refiere a la regulación del proceso de aprendizaje. Esta regulación se puede hacer cambiando los parámetros de exploración de los algoritmos de aprendizaje, cambiando entre los diferentes algoritmos o combinando dos o más algoritmos CE para crear uno nuevo. En este ejemplo de implementación que exponemos, el control meta-cognitivo cambia entre los algoritmos CE disponibles mediante el uso de la información proporcionada por los otros componentes (monitorización meta-cognitiva y conocimiento meta-cognitivo), que se basa en los escenarios operativos actuales.

Por ejemplo, en el primer punto de partida, el control meta-cognitivo elige aleatoriamente entre los algoritmos CE, ya que no tiene ninguna información sobre su rendimiento. Sin embargo, al recopilar más datos a través de los componentes de monitorización y meta-

conocimiento, el control meta-cognitivo identifica el algoritmo CE que puede proporcionar el mejor resultado (recompensa) para el escenario operativo en curso.

En la Fig. 14, se muestran los resultados de cada algoritmo CE y el algoritmo meta-CE utilizando la clasificación fuera de línea para BCAC. El algoritmo meta-CE simplemente selecciona el algoritmo CE que se encontró que tiene el mejor rendimiento de adaptación para el escenario operativo actual.

El mejor rendimiento se define como el rendimiento total alcanzado durante la sesión de adaptación. Utilizamos una máquina de vectores de soporte (SVM) como un clasificador fuera de línea para ser entrenado por 200 escenarios de canales operativos. Se supone que las condiciones del canal permanecen estáticas durante 100 pasos de tiempo; por lo tanto, la duración de cada sesión de adaptación también es de 100 pasos de tiempo. Como resultado, en el paso de tiempo 0, 100, ..., 500 los algoritmos tienen que reajustarse a las nuevas condiciones del canal. Se descubrió que el meta-CE selecciona con una probabilidad del 92 por ciento el algoritmo CE que se adapta mejor a las condiciones del canal dado. En la literatura científica también se recogen los avances realizados en la estandarización de los meta-CE como se indica en [9].

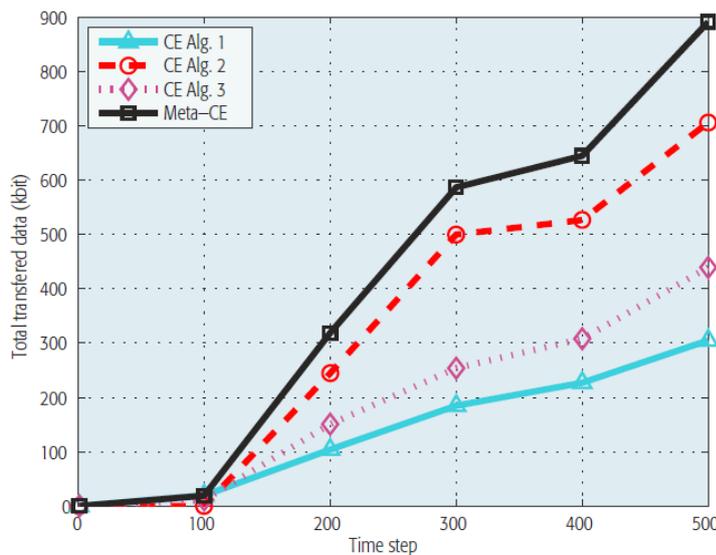


Figura 14: Rendimiento promedio del motor meta-cognitivo (clasificación fuera de línea).

CONCLUSIONES

El CR es la célula básica que conforma las redes de radios cognitivos CRN. Las CRN y sus múltiples arquitecturas y aplicaciones han recibido una amplia atención en la literatura científica a nivel internacional [10] [11] [12] [13]. Sin embargo, una mirada a la literatura sobre CR revela que, en el campo del radio cognitivo, poco se publica sobre las complejidades y especificidades del desarrollo y estado del arte de su “core”, el CE. Se constata que se han propuesto técnicas de aprendizaje supervisadas y no supervisadas para diversas tareas de aprendizaje. Otros autores han considerado el aprendizaje supervisado

basado en redes neuronales y máquinas de vectores de soporte SVM para aplicaciones CR. Por otro lado, el aprendizaje no supervisado, como el aprendizaje reforzado RL, se ha considerado en aplicaciones DSS. Se ha demostrado que el algoritmo de Q-learning distribuido es efectivo en una aplicación de CR particular, por ejemplo, los CR utilizan el Q-learning para mejorar el rendimiento de detección y clasificación de señales primarias. Se pueden encontrar otras aplicaciones de RL a CR. El aprendizaje no paramétrico bayesiano no supervisado basado en el proceso de Dirichlet se ha utilizado para la clasificación de señales

El mayor aporte de este artículo consiste en que a partir de una búsqueda exhaustiva de las publicaciones más recientes y de una manera condensada y didáctica se ofrece el CE CBR y se muestra adicionalmente una línea novedosa, la evolución de motores cognitivos a motores meta-cognitivos para CR y la cuantificación del nivel de experiencia alcanzado por los CE meta-cognitivos [14]. Esta evolución puede allanar el camino para otra generación de CE con mejores rendimientos.

REFERENCIAS

- [1]. Bkassiny, Mario. Student Member, IEEE; Li, Yang. Student Member, IEEE; Jayaweera, Sudharman K. Senior Member, IEEE. “A Survey on Machine-Learning Techniques in Cognitive Radios”. IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL. 15, NO. 3, THIRD QUARTER 2013.
- [2]. Al Qerm, Ismail; Shihada, Basem. “Supervised Cognitive System: A New Vision for Cognitive Engine Design in Wireless Networks”. King Abdullah University of Science and Technology (KAUST), Saudi Arabia. 15th IEEE Annual Consumer Communications & Networking Conference (CCNC). 2018.
- [3]. Snehalika, Lall; Arup Kumar, Sadhu; Amit, Konar; Kalyan Kumar, Mallik. “Multi-agent Reinforcement Learning for Stochastic Power Management in Cognitive Radio Network”. Jadavpur University. Electronics & Telecommunication Engineering Department. Calcuta. India. 2016.
- [4]. Volos, Haris I.; Buehrer, R. Michael. “On Balancing Exploration vs. Exploitation in a Cognitive Engine for Multi-Antenna Systems”. Mobile and Portable Radio Research Group (MPRG), Wireless@Virginia Tech. Bradley Department of Electrical and Computer Engineering. Virginia Polytechnic Institute and State University. 2009.
- [5]. Bregar, Klemen. “Designing and Implementing Cognitive Engine for Reconfigurable Wireless Networks”. Doctoral Degree. Ljubljana. 2014.
- [6]. Gaeddert, Joseph; R. Newman, Timothy; H. Reed, Jeffrey; Morales, Lizabeth; Kyung Kyoon, Bae; Chang-Hyun Park. “Development of a Case-Based Reasoning Cognitive Engine for IEEE 802.22 WRAN Applications”. Mobile Computing and Communications Review, Volume 13, Number 2. 2009
- [7]. Asadi, Hamed; Volos, Haris; M. Marefat, Michael; Bose, Tamal. “Metacognition and the Next Generation of Cognitive Radio Engines”. IEEE Communications Magazine. 2016.
- [8]. Gadhiok, M. “Metacognition: Enhancing the Performance of a Cognitive Radio”. IEEE Int’l. Multi-Disciplinary Conf. Cognitive Methods in Situation Awareness and Decision Support, pp. 198–203. 2011.

- [9]. Asadi, H. "Metacognitive Radio Engine Design and Standardization". Dept. of Electrical and Computer Engr. The University of Arizona. IEEE JSAC, vol. 33, no. 4, pp. 2015.
- [10]. Amjad, M.; Akhtar, F.; Rehmani, M. H.; Reisslein, M.; Umer, T. "Full-Duplex Communication in Cognitive Radio Networks: A Survey," in IEEE Communications Surveys & Tutorials, vol. 19, no. 4, pp. 2158-2191, Fourth quarter. 2017.
- [11]. Hu, F.; Chen, B.; Zhu, K. "Full Spectrum Sharing in Cognitive Radio Networks Toward 5G: A Survey," in IEEE Access, vol. 6, pp. 15754-15776. 2018.
- [12]. Awin, F. A.; Alginahi, Y. M.; Abdel-Raheem, E.; Tepe, K. "Technical Issues on Cognitive Radio-Based Internet of Things Systems: A Survey," in IEEE Access, vol. 7, pp. 97887-97908. 2019.
- [13]. Hu, F.; Chen, B.; Zhu, K. "Full Spectrum Sharing in Cognitive Radio Networks Toward 5G: A Survey," in IEEE Access, vol. 6, pp. 15754-15776. 2018.
- [14]. Asadi, H; Volos, Haris. "On Quantifying the Experience Level of a Cognitive Engine". University of Arizona. Proc. SDRWInnComm 2015. Wireless Innovation Conf. Wireless Commun.

SÍNTESIS BIOGRÁFICA DEL AUTOR

Nacido en La Habana, el 9 de mayo de 1943. Graduado en Ingeniería Eléctrica por la Universidad Tecnológica de La Habana (CUJAE) en 1968. Durante su carrera universitaria, trabaja simultáneamente como especialista principal en el Ministerio de Comunicaciones de Cuba (MINCOM). Graduado de Maestría en Ciencias en 1977, en la especialidad de telecomunicaciones, de las Universidades de la CUJAE y de Toronto. En 1980 fue nombrado Director de Ciencia y Tecnología del Ministerio de Comunicaciones (MINCOM) de Cuba y Constructor Jefe en el CAME, por la República de Cuba, del Sistema Único de Medios Digitales de Técnicas de Conmutación y Transmisión. Investigador Titular desde 1982. En 1985 fue nombrado Director de Desarrollo de MINCOM. Entre 1982 y 1990 fue Tutor de múltiples Tesis de Ingeniería o Maestría en Ciencias y publicó numerosos artículos sobre la especialidad de Telecomunicaciones, Ciencias Empresariales y Macroeconomía. Entre 1990 y 2003 fue nombrado Director General de CUBACEL, la primera empresa celular cubana. Desde el 2003 hasta el 2011 fungió como Asesor del Ministro de Comunicaciones. Ha participado como ponente en múltiples eventos científicos internacionales y nacionales relacionados con la UIT, las Naciones Unidas, el Banco Mundial y el CAME. Ha obtenido múltiples premios nacionales e internacionales. Actualmente es Investigador Titular del Instituto de Investigación y Desarrollo de Telecomunicaciones, LACETEL.