

Agentes Virtuales Inteligentes Afectivos (AVIA): Integrando Inteligencia Emocional

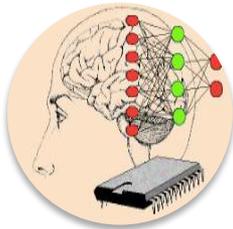
Jose Aguilar

Diciembre 2023

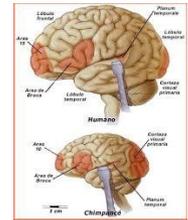
Contenido

- **Introducción a la IA**
- **Modelado de Agentes**
- **Aprendizaje por Reforzamiento**
- **Agente Inteligente interactuando**
- **Agente inteligente siguiendo las emociones**
- **Futuros retos**

Mas del 98% de nuestro genoma es idéntico al chimpancé, pese a que nuestra línea evolutiva se separo hace unos 6 millones de años



El cerebro humano es 3 veces mas grande que el de un chimpancé, con una **red neuronal mas densa e interconectada**, con más de **80 millones de neuronas** que funcionan de manera **conexionista distribuida**, siendo la **base de la inteligencia**



Según el diccionario de la **Real Academia Española**:

- Capacidad para comprender o entender.
- Capacidad para resolver problemas.
- Conocimiento, acto de comprensión.
- Sentido en el que puede tomarse una proposición, un dicho o una expresión.
- Habilidad, destreza y experiencia

....

*Inteligencia: capacidad de **adquirir y usar** conocimiento*

Capacidad de las **computadoras** para **realizar tareas** que normalmente requerirían **inteligencia humana**.

Abarca la **ciencia e ingeniería dedicada a diseñar y programar computadores** que ejecutan **tareas que requieren inteligencia** si la hicieran los seres humanos

Es interdisciplinaria: neurociencias, lógica matemática, psicología, teoría de la información, ciencias de la computación, entre otras.

- **inteligencia artificial estrecha (ANI)**
- **Inteligencia Artificial General (AGI)**
- **Superinteligencia Artificial (ASI)**

Razonamiento:

Resolución de problemas mediante **inferencia**:
deductiva, abductiva o inductiva



Visión Artificial:

Comprender y analizar **imágenes y videos**



En esta década, prácticamente todo software tendrá algo de IA



CC

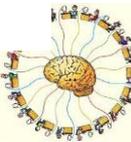
Procesamiento
procesar in
ler

Computación Inteligente:

Abarca las tres técnicas más importantes de la IA: **Redes neuronales artificiales, Lógica difusa, Computación Evolutiva**



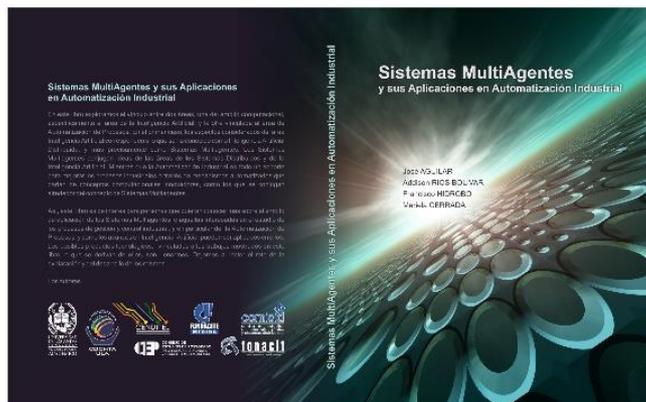
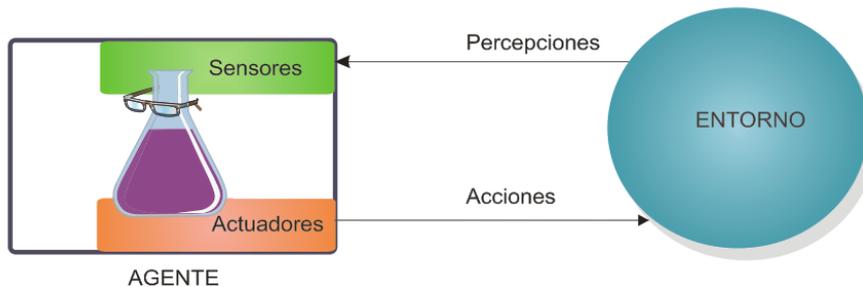
describen los procesos de **aprendizaje grupales**. Muchos bioinspirados como las colonias de insectos: PSO, ACO.



Sistemas auto-organizados y autónomos

Sistemas que se **auto-regulan** con capacidades que **emergen**

Es un sistema (quizas computacional) que está situado en un entorno, que es capaz de realizar acciones autónomas flexibles en ese entorno para alcanzar sus objetivos



Mecanismos para:

- resolver un problema
- planificar sus actividades /tareas
- representar su conocimiento
- razonar
- aprender
- percibir
- comunicarse

Avatar



<https://www.alamy.es/avatar-chica-con-pelo-largo-y-oscuro-avatar-y-rostro-unico-icno-en-el-estilo-de-dibujos-animados-de-simbolos-vectoriales-ilustracion-web-de-stock-image213116418.html>



Robots Sociales



Vehículo Autónomo



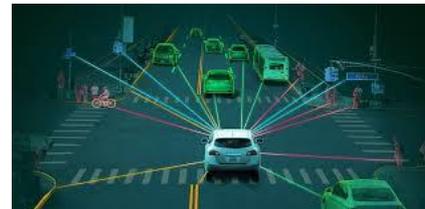


Es un sistema formado por un **grupo de agentes** que **interactúan** entre sí utilizando protocolos y lenguajes de comunicación de alto nivel, para **resolver problemas** que pueden estar más allá de las capacidades o del conocimiento de cada uno.

Enjambre de Robots



Vehículos Autónomos en una ciudad



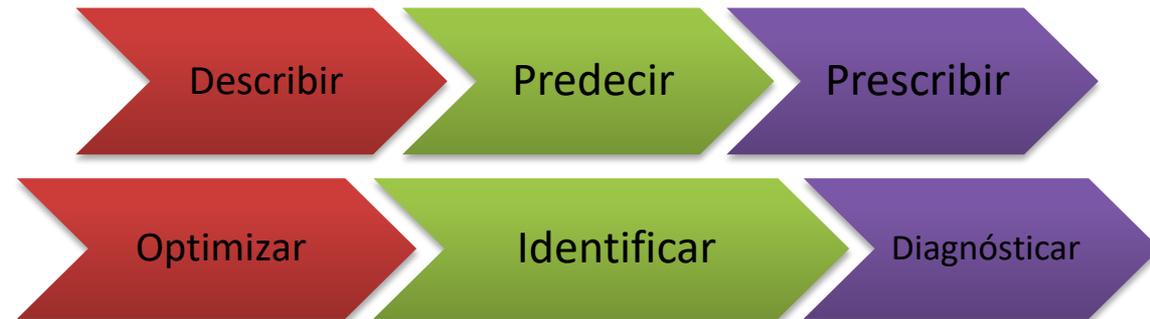
**Los datos son el nuevo
petróleo de la economía**



Análisis de Datos es la ciencia que examina datos en bruto con el propósito de buscar conocimiento, sacar conclusiones, generar información, entre otras cosas.



Los datos pueden "hablar":



y muchos más

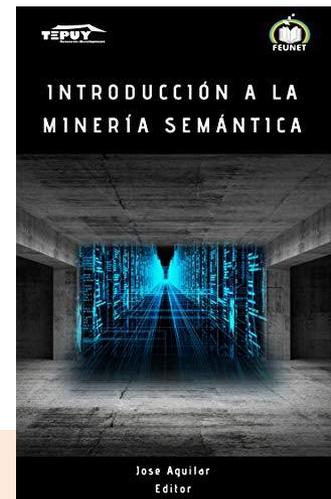


Minería de Datos



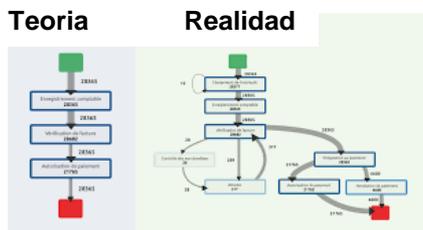
Minería Semántica

Ontológica
De la web
De datos semánticos
Del texto

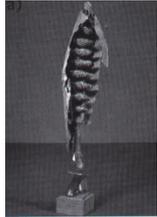


Minería de Cualquier Cosa:
es la electricidad actual de la economía

Minería de Procesos



Minería de Grafos



Comportamiento de un sistema, que **"emerge"** de las interacciones entre sus componentes, difíciles o imposibles de predecir.



Inteligencia Colectiva o Social

Cerebro y colonia de hormigas son la suma de miles de decisiones de sus componentes interactuando

Hormigas



Neuronas

feromonas



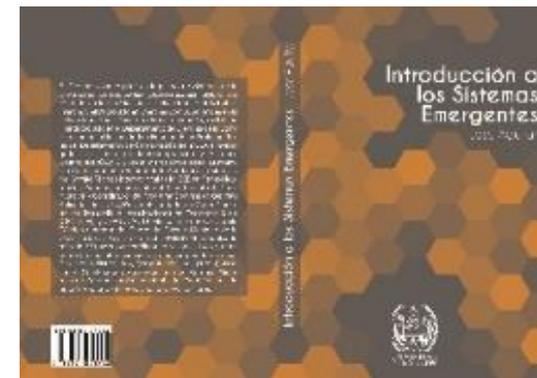
Neurotransmisores

Colonia de hormigas



Cerebro humano

Autonomía vs. Control
Emergente vs. Programado
Distribuido vs. Centralizado



Las Tecnologías de Información, Comunicación y Automatización (TICAs) se están desplegando por todos lados

Es el conjunto de sistemas que hacen posible la adecuación de un ambiente (salón de clases, museos, casas, etc.)

- Integra todos los dispositivos con capacidad **inteligente y autónoma**, en la dinámica de actividades del entorno
- Dispositivos y software se **auto-organizan**



- Los agentes representan un **nuevo nivel de abstracción** que puede ser utilizado por los desarrolladores de software para **entender, modelar y desarrollar** de un modo más natural una clase importante de **sistemas distribuidos**.
- Las técnicas de **desarrollo de software habituales no son adecuadas para esta tarea**, ya que no son capaces de capturar los aspectos únicos de los SMA

Como todo desarrollo de software, se requieren unos estándares de desarrollo.



La metodología debe permitir ir actualizando los agentes en función de la caracterización que sea necesaria en el SMA.

Tener en cuenta las necesidades de especificación de los SMA

- Complejidad de la estructura organizacional
- Planificación de tareas
- Riqueza en sus interacciones
- Movilidad del código
- Comportamiento flexible, autónomo, emergente

La construcción de SMA integra tecnologías de distintas áreas de conocimiento

- Técnicas de *ingeniería de software*
- Técnicas de *inteligencia artificial*
- Programación concurrente y distribuida

Metodología que permite **especificar Sistemas Multi-agentes**, la cual es una extensión de **MAS-CommonKADS**.

Fases

Conceptualización

- Casos de uso (descripción de acciones necesarias para producir un resultado útil)
- Actores (roles desempeñados por alguna persona, una pieza de software, u otro sistema)

Análisis y Diseño

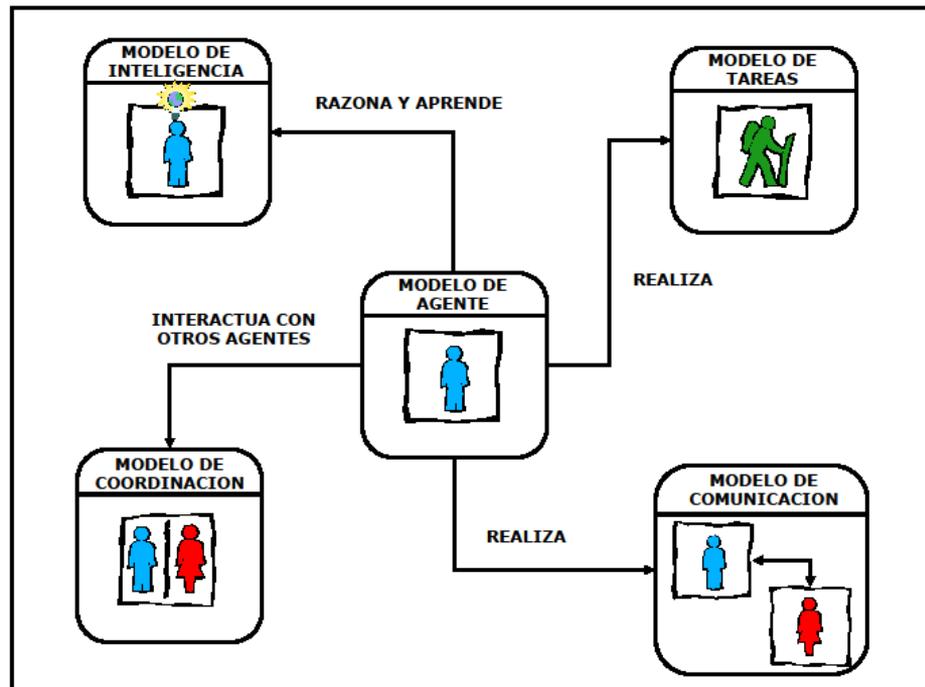
- Modelos para describir los agentes del sistema, sus tareas, su organización y los medios de comunicación.
- Diseño técnico del sistema (modelo de implementación).

Codificación y prueba

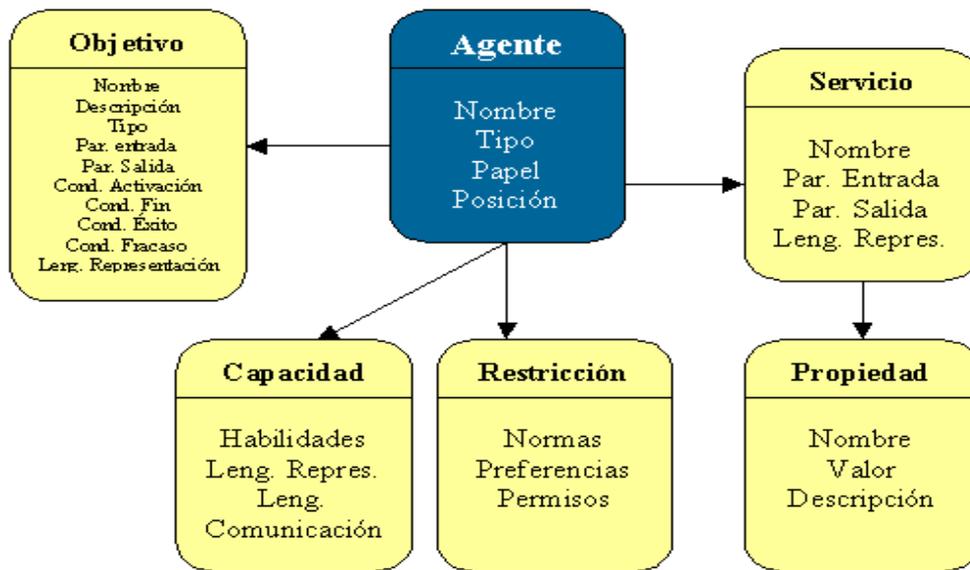
Integración

Operación y mantenimiento

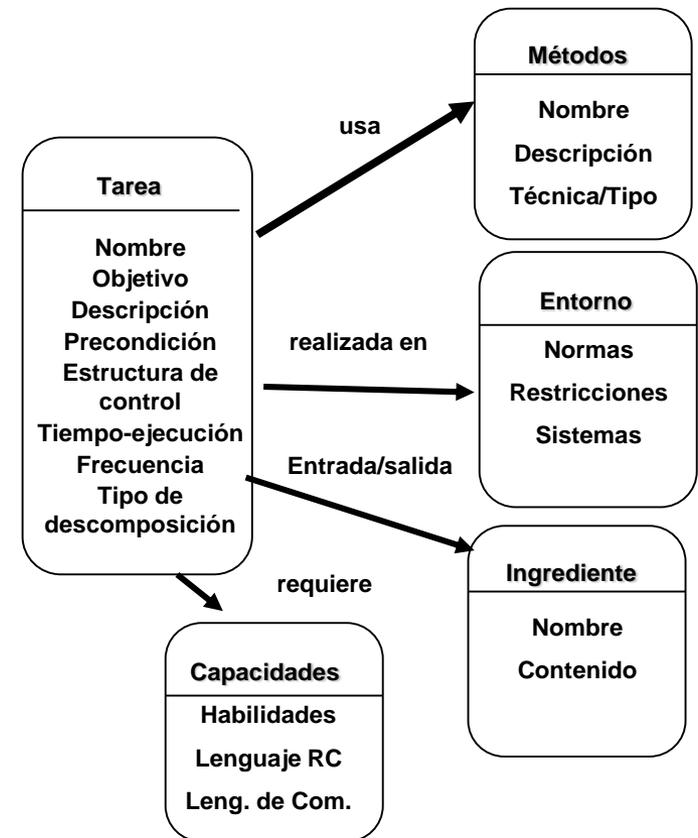
Modelos



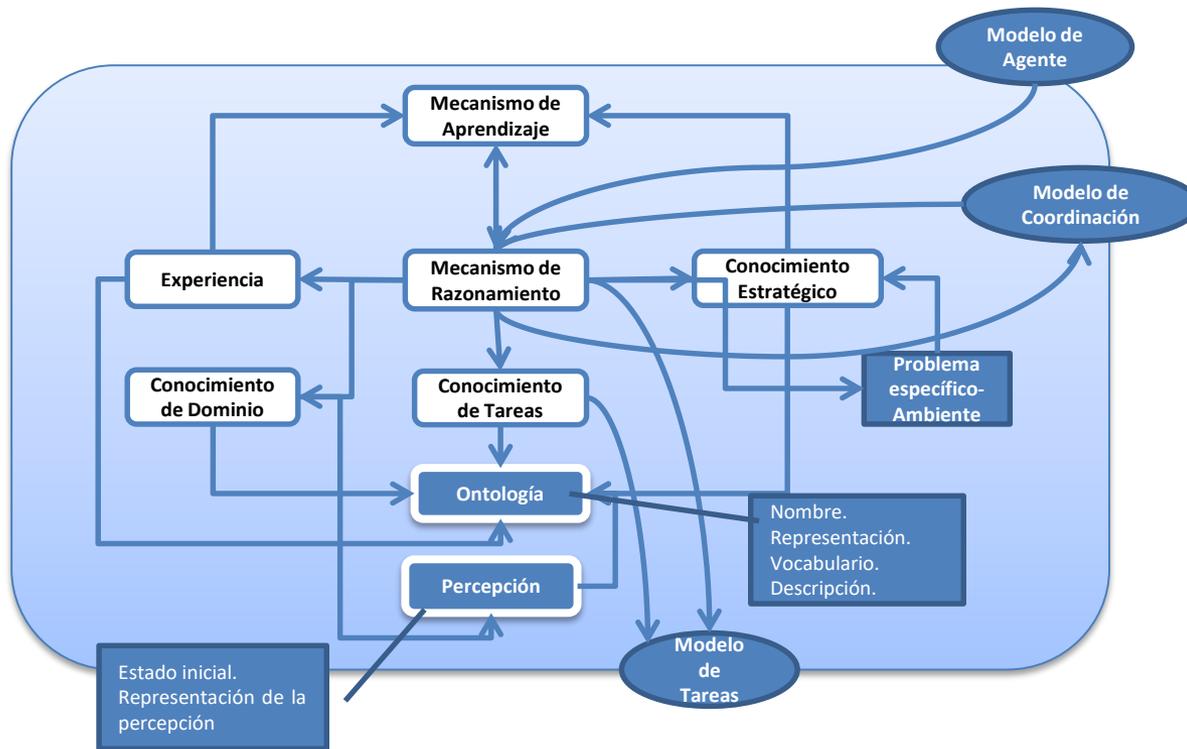
Modelo de Agente



Modelo de Tareas



Modelo de Inteligencia



Mecanismo de Aprendizaje

Nombre

Tipo

Técnica de representación

Fuente de aprendizaje

Mecanismo de actualización

Mecanismo de Razonamiento

Fuente de información

Fuente de alimentación

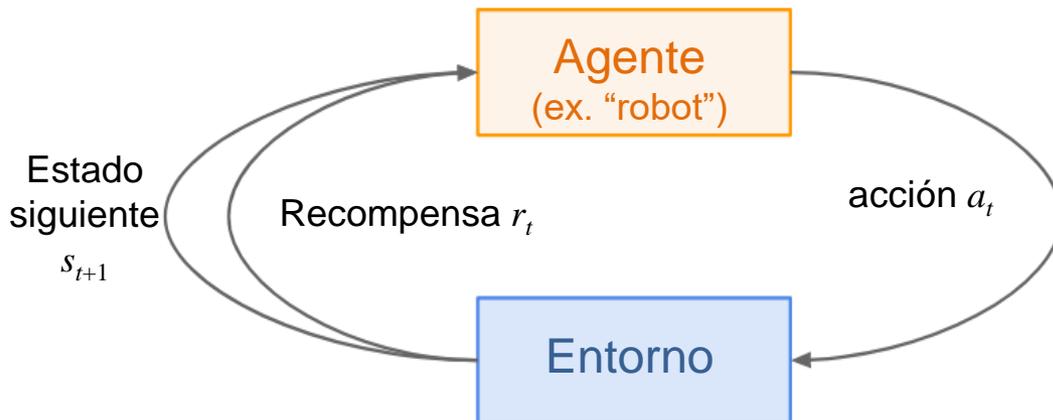
Técnica de inferencia

Lenguaje de representación de conocimiento

Relación tarea-inferencia
(Resultado esperado)

Estrategias de razonamiento

- Consiste en determinar cómo los *agentes* interactúan con el *entorno* a través de *acciones* para obtener la máxima *recompensa*



- **Objetivo:**
 - Aprender qué acciones tomar ("**política óptima**") para maximizar la recompensa

- **Agente**

- Es "quien" interactúa con el entorno (ex. el robot)
- Solo tiene conocimiento parcial del entorno

- **Estados**

- Contienen datos del entorno o del propio agente
- Se pueden obtener mediante "sensado"

- **Acciones**

- Son las señales de control que realiza el agente
- Modifican el entorno

- **Recompensa**

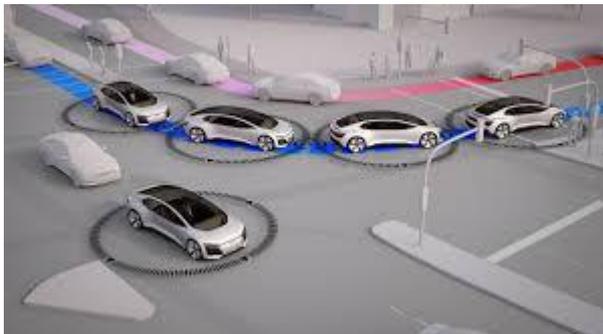
- Son escalares que muestran cuán bien se desempeña el agente en una determinada tarea

Ejemplos de RL

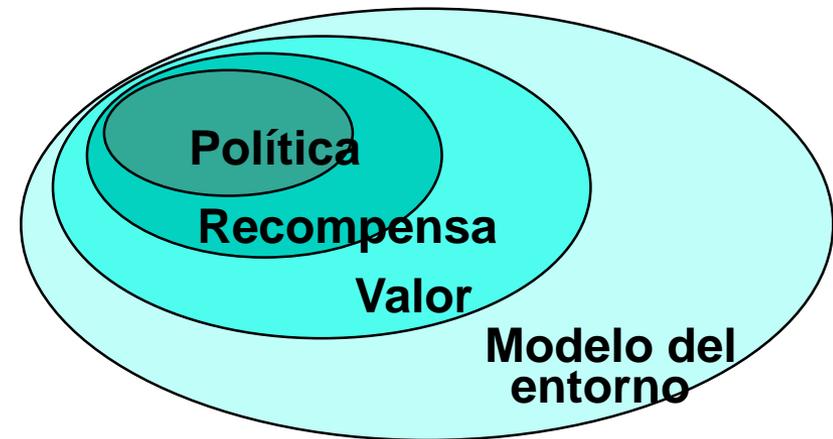
- Aprendizaje de cómo jugar



- Aprendizaje de cómo conducir (Vehículos autónomos)



Los sistemas de aprendizaje por refuerzo tienen **4 elementos principales**:



Política: qué hacer

Recompensa: lo que es bueno

Valor: estimación de la recompensa futura

Modelo: entorno que lo rodea

Regla de Transición (*Dorigo et al.*):

$$P_{rs}^k(t) = \begin{cases} \frac{[\gamma_{rs}(t)]^\alpha [\eta_{rs}]^\beta}{\sum_{u \in J_r^k} [\gamma_{ru}(t)]^\alpha [\eta_{ru}]^\beta} & \text{Si } s \in J_r^k \\ 0 & \text{De lo contrario} \end{cases}$$

$\gamma_{rs}(t)$: Cantidad de feromona,
 η_{rs} : inverso de la distancia
 $J_k(r)$: nodos aun no visitados,
 β y α : parámetros

Regla de actualización de las trazas:

$$\gamma_{rs}(t) = (1 - \rho)\gamma_{rs}(t-1) + \sum_{k=1}^m \Delta\gamma_{rs}^k(t)$$

$(1-\rho)$: tasa de evaporación,
 $\Delta\gamma_{rs}^k(t)$: cantidad de traza que se deja por unidad de longitud
 m : numero de hormigas

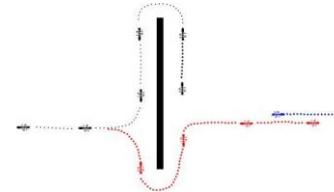
Cantidad dejada de feromona

$$\Delta\gamma_{rs}^k(t) = \begin{cases} \frac{1}{L_k(t)} & \text{Si arco } (r,s) \in \text{tour completado por hormiga } k \\ 0 & \text{de lo contrario} \end{cases}$$

$L_k(r)$: longitud del recorrido de la hormiga k

- **Basado en valor**

- Usa la función de valor
- La política está implícita



- **Basado en política**

- Usa la política
- No calcula la función de valor

- **Libre de modelo**

- Solo usa la política o la función de valor

- **Basado en modelo**

- Tiene la política o función de valor
- Usa el modelo para tomar decisiones

Aprendizaje por refuerzo: Q-learning

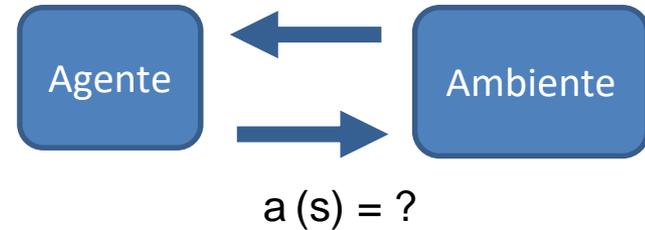
- Actualiza la **política**
- En la regla de actualización, **elige la acción a que maximiza Q dado s_{t+1}** y usa el valor Q resultante (es decir, el valor estimado dado por la función óptima de valor de acción) más la recompensa observada como **objetivo**

$$Q(s, a) = (1 - \alpha)Q(s, a) + \alpha [R(s') + \gamma \max_a Q(s', a')]$$

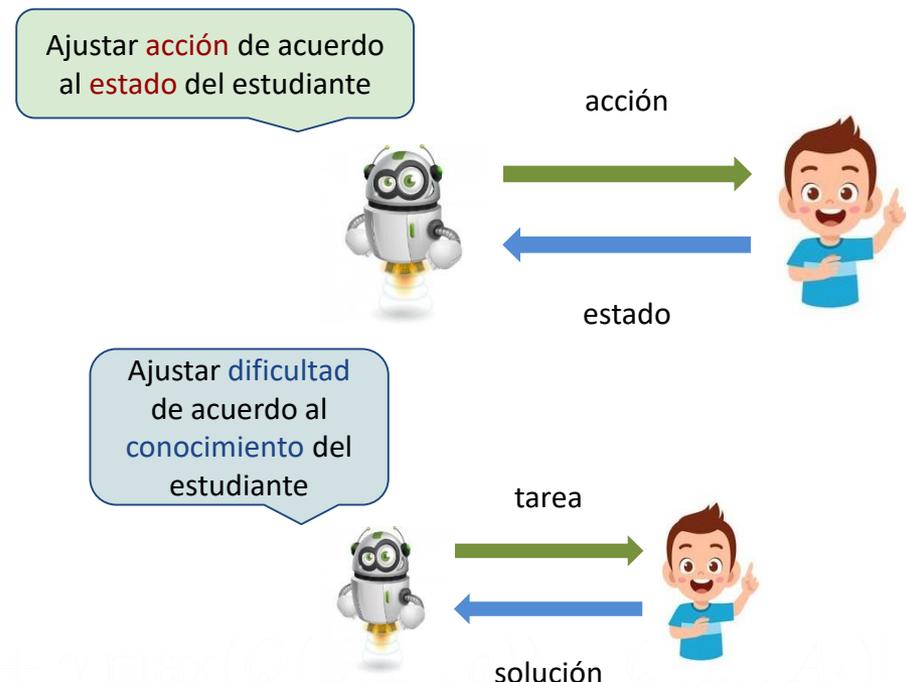
$$\alpha, \gamma \in [0, 1]$$

Explorar o explotar $\epsilon \in [0, 1]$

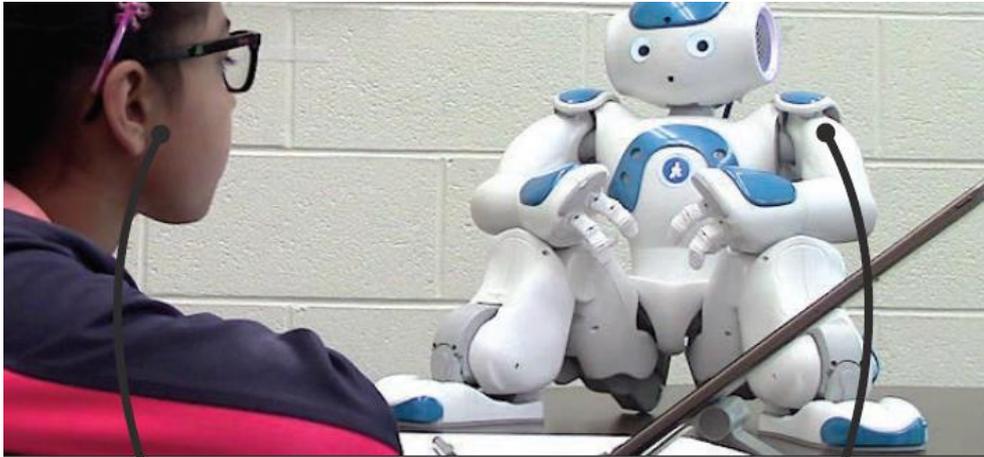
$$a(s) = \begin{cases} \text{random} & \text{with_probability } \epsilon \\ \pi(s) & \text{with_probability } 1 - \epsilon \end{cases}$$



acción **desconocida** o **mejor acción**



$$\pi : S \rightarrow A??$$



Niño

Robot Social NAO

$$PDM = \langle A, S, R \rangle$$

$A = \{\text{tabla 2, tabla 3, tabla 4, tabla 5, tabla 6, tabla 7, tabla 8, tabla 9}\}$

$S = \{\text{dificultad consciente, dificultad inconsciente, dificultad moderada, sin dificultad}\}$

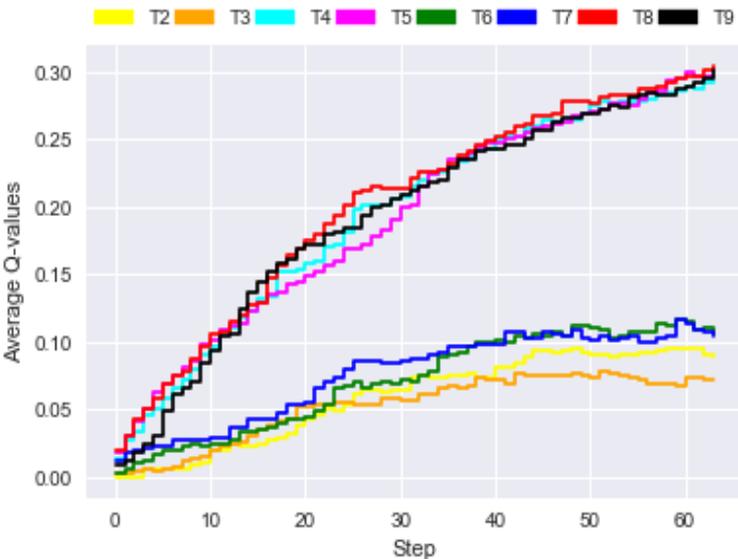
$$R(s) = \begin{cases} 0.99 & \text{si } s = \text{dificultad consciente} \\ 0.66 & \text{si } s = \text{dificultad inconsciente} \\ 0.33 & \text{si } s = \text{dificultad moderada} \\ 0 & \text{si } s = \text{sin dificultad} \end{cases}$$

Los robots sociales deben **aprender** las **dificultades** de cada niño

- **Average Accumulated Reward (AAR):** $AAR = \sum_1^t \frac{(r_1+r_2+\dots+r_t)}{N}$
- **Percentage of Best-Accumulated Reward (PBAR):** $PBAR_t = \frac{\max(r_1+r_2+\dots+r_t)}{BAR}$

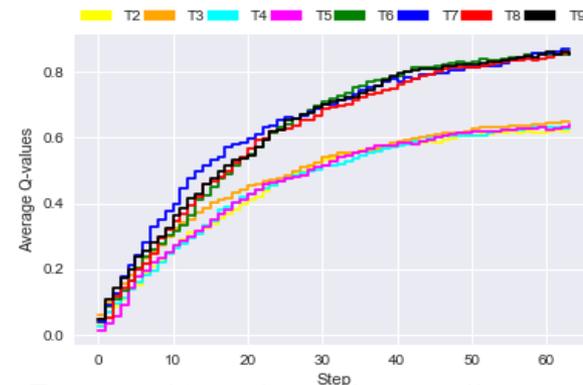
Aprendizaje de perfiles fijos

Se utiliza una instancia del modelo para cada perfil.

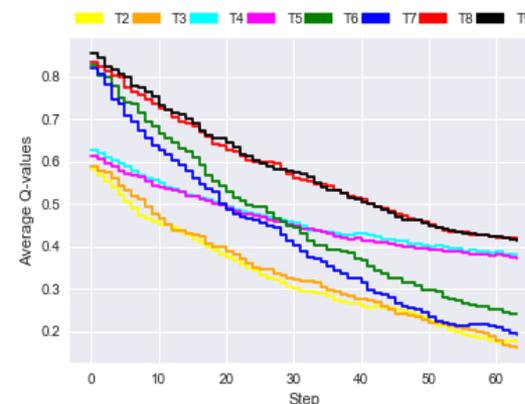


Promedios de valores Q en el aprendizaje del perfil bueno

Aprendizaje de perfiles variables



Promedios de valores Q en el aprendizaje del **perfil inicial (malo)**



Promedios de valores Q en el aprendizaje del **perfil final (bueno)**

MDP

$$MDP = \langle A, S, R \rangle$$

$$A = \{a_1, a_2, \dots, a_k\}$$

$$S = \{s_1, s_2, \dots, s_n\}$$

$$R : S \rightarrow \mathfrak{R}$$

Reward shaping

$$MDP' = \langle A, S, R' \rangle$$

$$R' = R + F$$

$$F : S \rightarrow \mathfrak{R}$$

Potential based reward shaping

$$F(s, a, s') = \gamma\varphi(s') - \varphi(s)$$

$$\varphi : S \rightarrow \mathfrak{R}$$

Contexto

- Los problemas matemáticos de palabras (MWP) son parte del plan de estudios de la escuela primaria.
- Los MWP son importantes porque preparan a los estudiantes para usar las habilidades matemáticas en situaciones cotidianas.
- Los MWP son difíciles para muchos estudiantes.

La formación personalizada es una solución

Ejemplo 1:

If a book costs \$12,
¿What is the cost of 3 books?

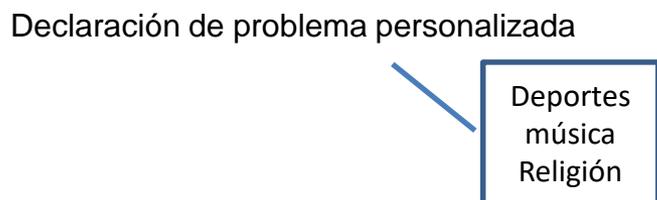
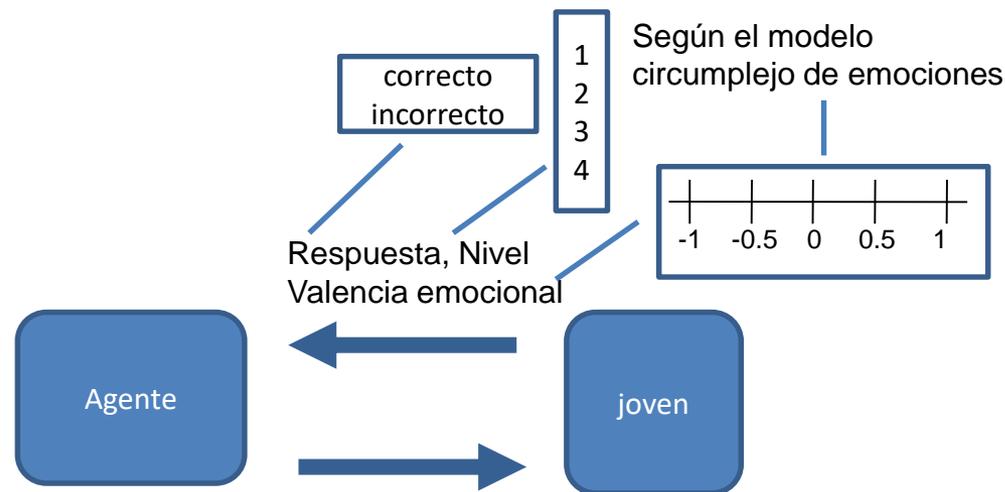


Ejemplo 2:

If a **soccer ball** costs \$12,
¿What is the cost of 3 **soccer balls**?



Contexto



Formalización

$$MDP = \langle S, A, R \rangle \quad MDP' = \langle S, A, R + F \rangle$$

$$A = \{sports, music, geography\}$$

$$S = C \times L$$

$$C = \{incorrect, correct\} \quad L = \{1, 2, 3, 4\}$$

$$R = \begin{cases} 0 & \text{if } c = incorrect \\ i & \text{if } c = correct \wedge l = i \end{cases}$$

$$F = \gamma\varphi(s') - \varphi(s)$$

$$\varphi : S \rightarrow [-1, 1]$$

devuelve un valor real según la emoción del niño (ev) y el nivel l_i

$$\varphi = -(l_i + ev) \quad \text{where } l_i \in L$$

Simulaciones

Datos Simulación

- Answer's profile
- Emotional expressivity profile

Emotional expressivity profile (perfil expresividad)

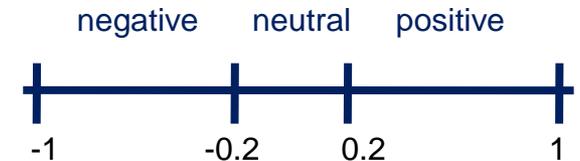
$$E = \{negative, neutral, positive\}$$

Answer's profile (perfil respuestas)

Level	Context	Answer
1	Sports	Correct
	Music	Correct
	Geography	Correct
2	Sports	Correct
	Music	Incorrect
	Geography	Correct
3	Sports	Incorrect
	Music	Incorrect
	Geography	Correct
4	Sports	Incorrect
	Music	Incorrect
	Geography	Correct

$answer(l, c)$

Answer	Emotional expressivity		
	High	Eventual	Low
Correct	P(positive) = 1	P(positive) = 0.5	P(positive) = 0
	P(neutral) = 0	P(neutral) = 0.5	P(neutral) = 1
	P(negative) = 0	P(negative) = 0	P(negative) = 0
Incorrect	P(positive) = 0	P(positive) = 0	P(positive) = 0
	P(neutral) = 0	P(neutral) = 0.5	P(neutral) = 1
	P(negative) = 1	P(negative) = 0.5	P(negative) = 0



$$\varphi(s) = \begin{cases} \text{random}(-1, -0.2) & \text{if } negative \\ \text{random}(-0.2, 0.2) & \text{if } neutral \\ \text{random}(0.2, 1) & \text{if } positive \end{cases}$$

Simulaciones

1. ¿Qué tan rápido aprende el agente los perfiles de respuesta?
2. ¿Los perfiles emocionales mejoran el rendimiento del aprendizaje?

Experimento 1. ¿Qué tan rápido aprende el agente los perfiles de respuesta?

Criterios calidad

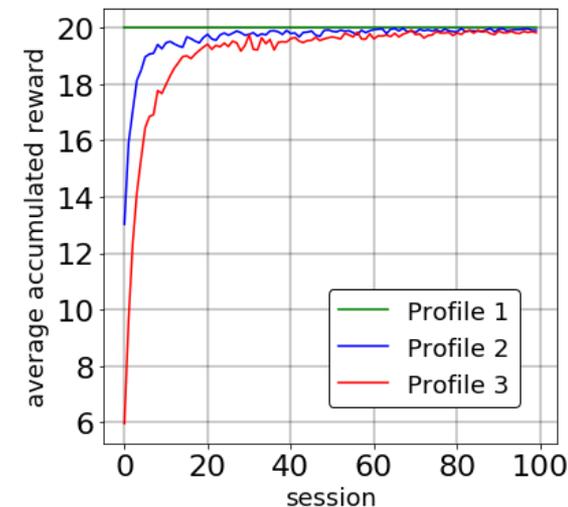
Accumulated reward

$$AR = \sum_{t=1}^8 r_t$$

Optimal accumulated reward

$$AR^*$$

Level	Context	Profile 1	Profile 2	Profile 3
1	Sports	Correct	Incorrect	Incorrect
	Music	Correct	Correct	Incorrect
	Geography	Correct	Correct	Correct
2	Sports	Correct	Incorrect	Incorrect
	Music	Correct	Correct	Incorrect
	Geography	Correct	Correct	Correct
3	Sports	Correct	Incorrect	Incorrect
	Music	Correct	Correct	Incorrect
	Geography	Correct	Correct	Correct
4	Sports	Correct	Incorrect	Incorrect
	Music	Correct	Correct	Incorrect
	Geography	Correct	Correct	Correct



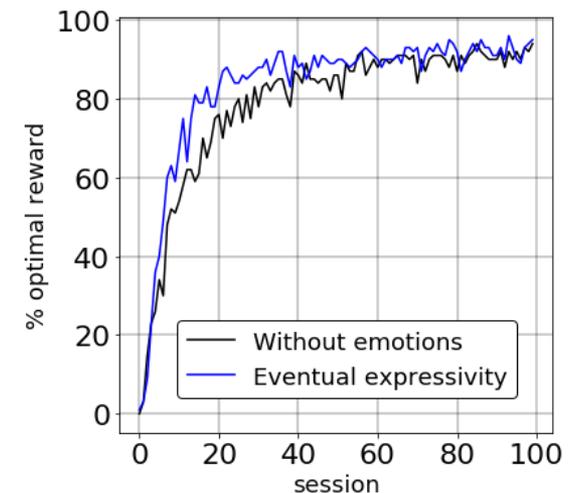
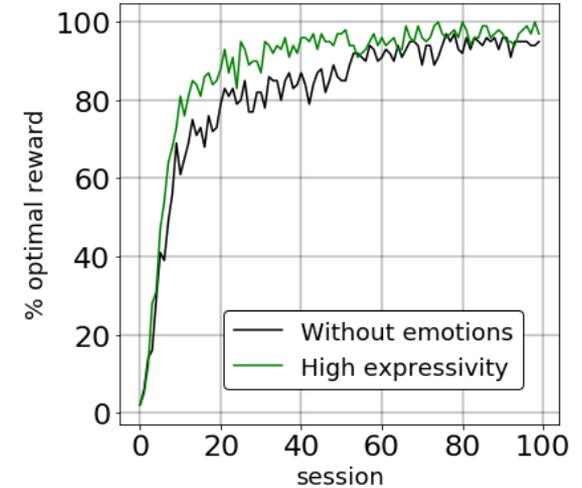
$AR^* = 20$

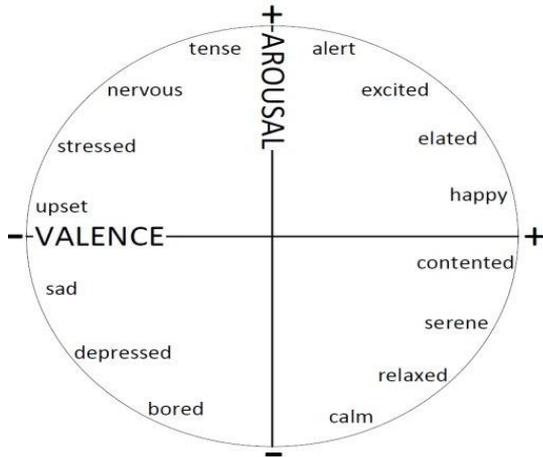
Experimento 2. ¿Los perfiles emocionales mejoran el rendimiento del aprendizaje?

Level	Context	Profile 7
1	Sports	Correct
	Music	Correct
	Geography	Correct
2	Sports	Correct
	Music	Incorrect
	Geography	Correct
3	Sports	Incorrect
	Music	Correct
	Geography	Correct
4	Sports	Incorrect
	Music	Incorrect
	Geography	Correct

• Todos los niveles tienen diferentes respuestas correctas.

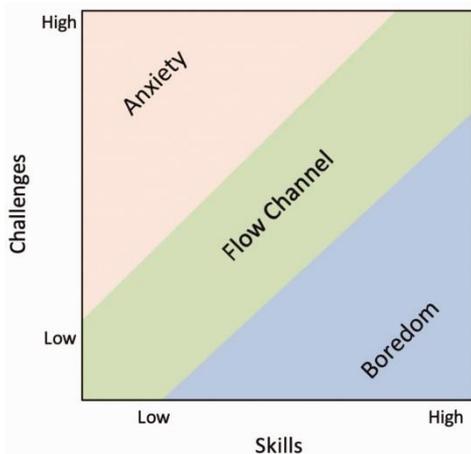
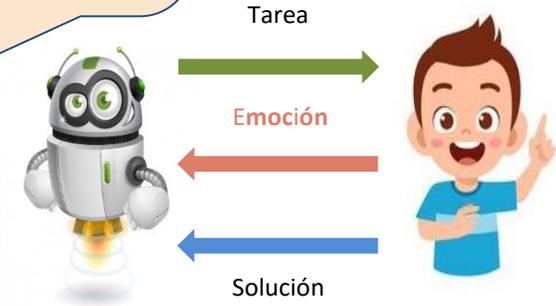
• $AR^* = 20$



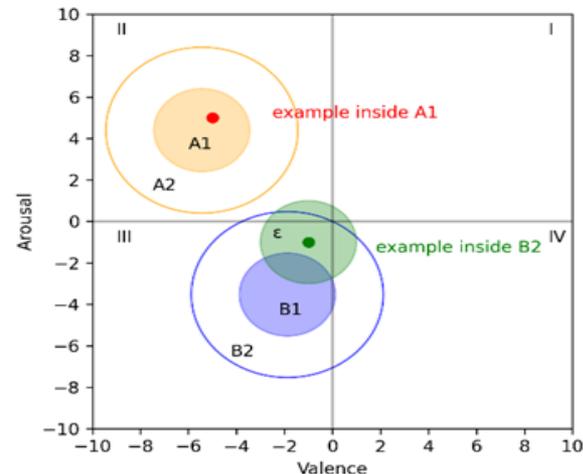


Modelo circunplejo

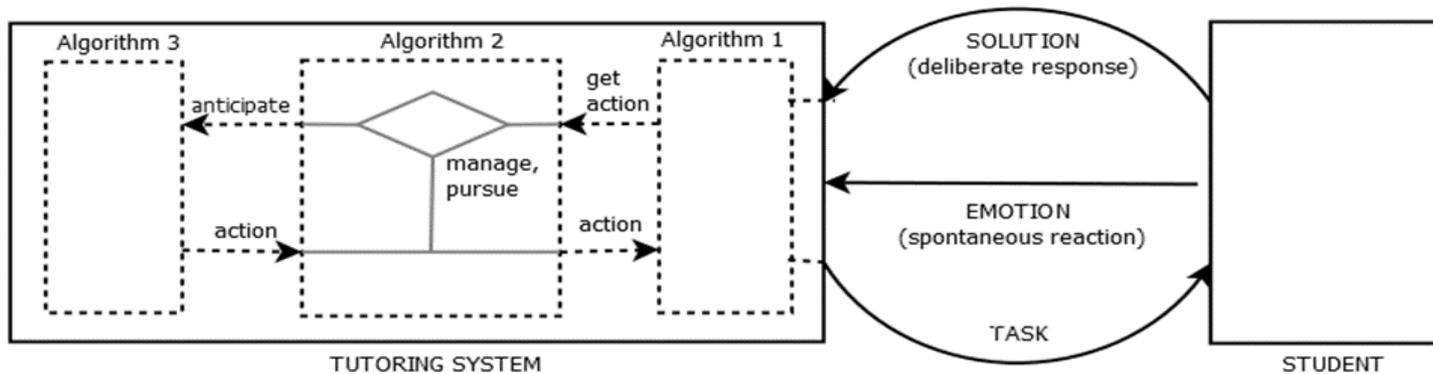
1. Mantener el canal de flujo que está relacionado con la búsqueda de **emociones positivas**.
2. Manejar la ansiedad o el aburrimiento reduciendo o aumentando la **dificultad**.
3. Anticipar la ansiedad o el aburrimiento manejándolos antes de lograrlos



Teoría del flujo



Q-learning: Emociones



Algorithm 1. Main loop

1. Initialize $Q_{performance} = 0$
2. Initialize $Q_{flow} = 0$
3. Initialize *emotion* randomly
4. Loop:
 5. Get *action* from *emotion* using Algorithm 2
 6. Perform *action*
 7. Observe *emotion*, *reward*
 8. Update $Q_{performance}$ using Equation 2
 9. Update Q_{flow} using Equation 2

Equation 2

$$Q(a) = Q(a) + \alpha[r + \gamma \max_{a'} Q(a') - Q(a)]$$

Algorithm 2. Manage and pursue emotions

Input: valance, arousal

1. Create *emotion_point* from *valence* and *arousal*
2. If *emotion_point* in *anxiety_area*:
3. return $\text{argmax}(Q_{performance})$
4. Else if *emotion_point* in *boredom_area*:
5. return $\text{argmin}(Q_{performance})$
- 6.
7. Create *emotion_area* from *emotion_point* and *radius*
8. If *emotion_area* intercepts *anxiety_area* or *boredom_area*
9. return *action* using Algorithm 3
- 10.
11. return $\text{argmax}(Q_{flow})$

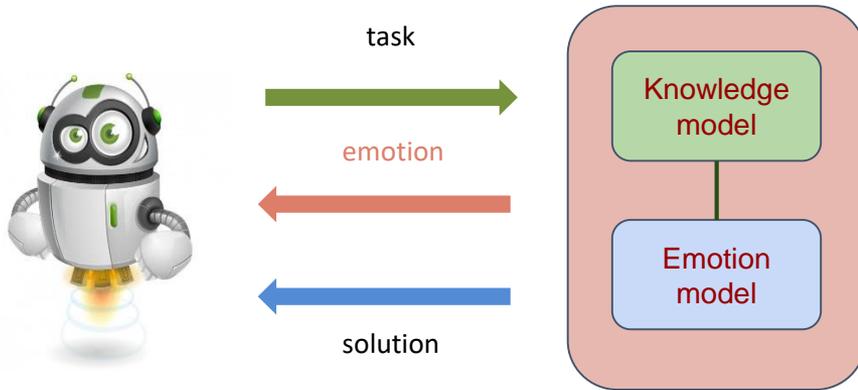
Output: action

Algorithm 3. Anticipate emotions

Input: *current_area*, *nearest_area*

1. Calculate *intercepted_area* using Equation 5
2. $\text{intercepted_proportion} = \text{intercepted_area} / \text{nearest_area}$
3. $\varepsilon = 1 - \text{intercepted_proportion}$
4. With probability ε :
5. return random action
6. If *nearest_area* == *anxiety_area*:
7. return $\text{argmax}(Q_{performance})$
8. If *nearest_area* == *boredom_area*:
9. return $\text{argmin}(Q_{performance})$

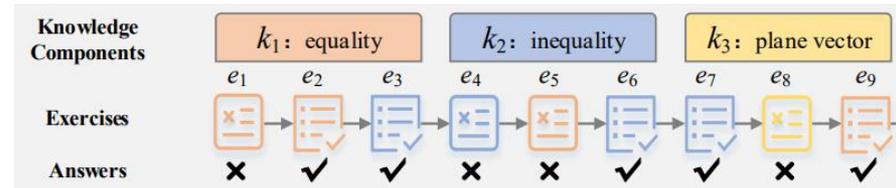
Experimental protocol



Our approach

Data-driven
user simulator

Knowledge model



Cognitive Tutor 2006-
2007 Bridge to Algebra
dataset

Bayesian Knowledge Tracing

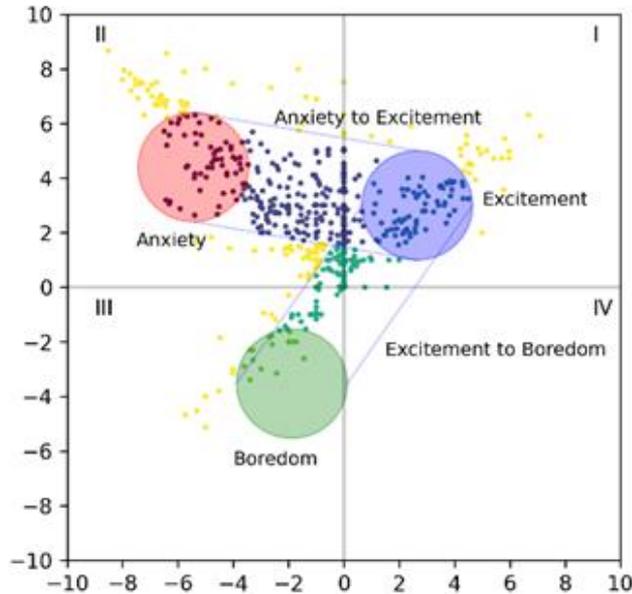
$$P(C_{t+1}) = P(L_{t+1})(1 - P(S)) + (1 - P(L_{t+1}))P(G)$$

$$P(L_{t+1}) = P(L_t|obs_t) + (1 - P(L_t|obs_t))P(T)$$

$$P(L_t|obs_t = 1) = \frac{P(L_t)(1 - P(S))}{P(L_t)(1 - P(S)) + (1 - P(L_t))P(G)}$$

$$P(L_t|obs_t = 0) = \frac{P(L_t)P(S)}{P(L_t)P(S) + (1 - P(L_t))(1 - P(G))}$$

Emotion model



AFEW-VA dataset

$$emotion(p) = \begin{cases} anxiety & 0 < p \leq 0.26 \\ anxiety\ to\ excitement & 0.26 < p \leq 0.48 \\ excitement & 0.48 < p \leq 0.66 \\ excitement\ to\ boredom & 0.66 < p < 0.89 \\ boredom & 0.89 < p \leq 1 \end{cases}$$

where $p = P(C_{t+1})$

Flow theory

Metrics

$$learning\ gain = \frac{posttest\ score - pretest\ score}{max\ score - pretest\ score}$$

$$utility = \sum_{i=1}^n D_i | Q_i\ was\ correctly\ solved$$

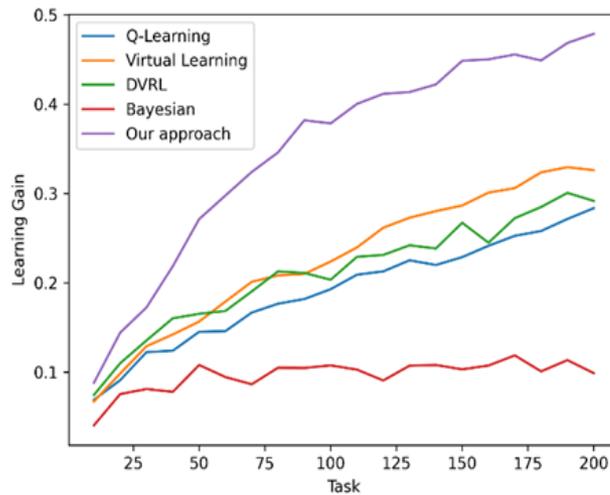
Monitoring

$$selection\ rate_s = \frac{\sum_{i=1}^n 1 | s\ was\ selected}{n} \times 100\%$$

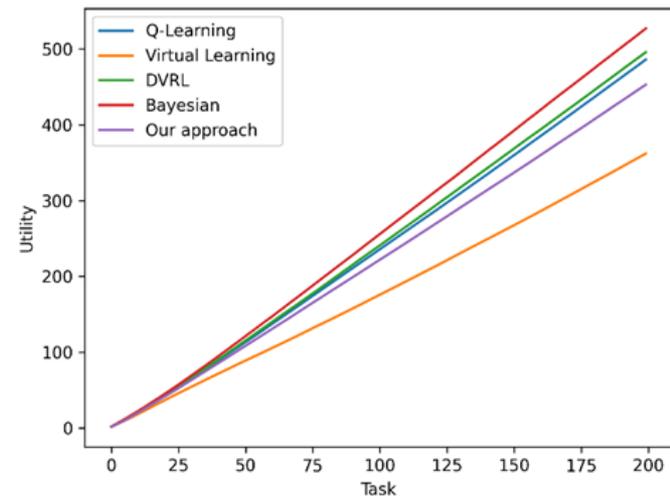
$$percentage_b = \frac{\sum_{i=1}^n 1 | i \in b}{n} \times 100\%$$

Results

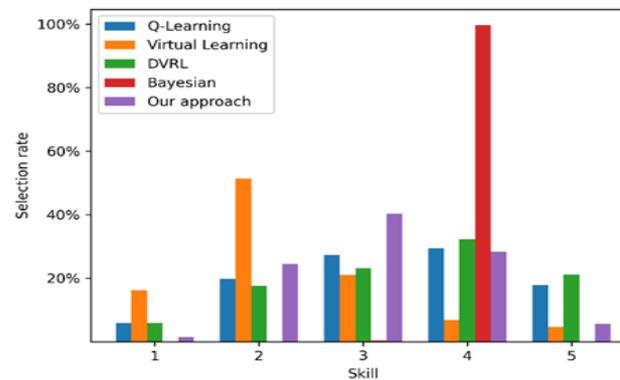
Learning gain



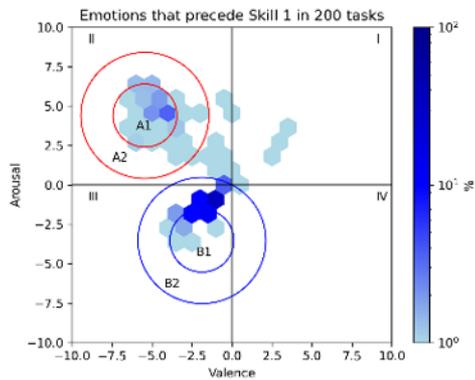
Utility



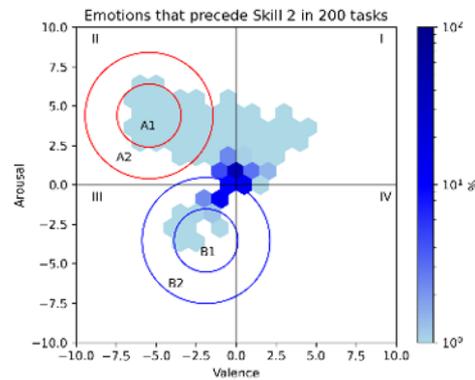
Selection rate



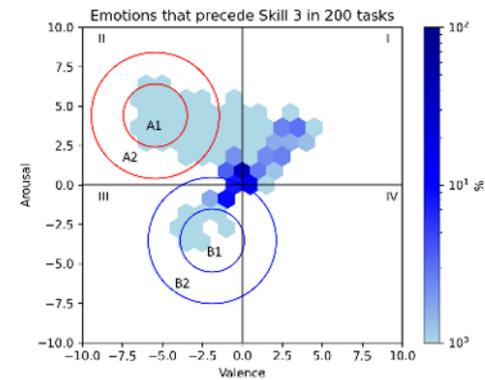
Percentage of emotions



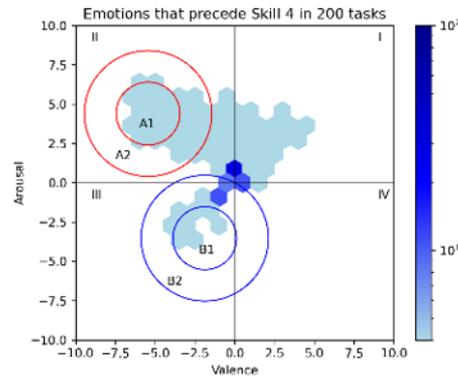
(a)



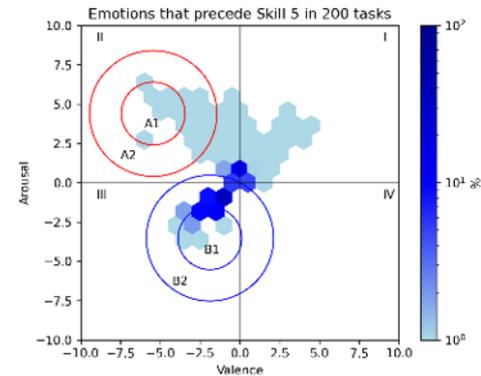
(b)



(c)



(d)



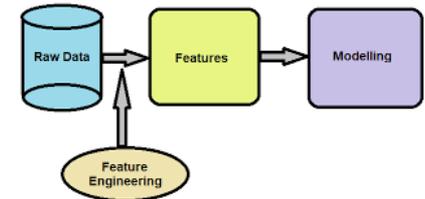
(e)

- Meta-aprendizaje

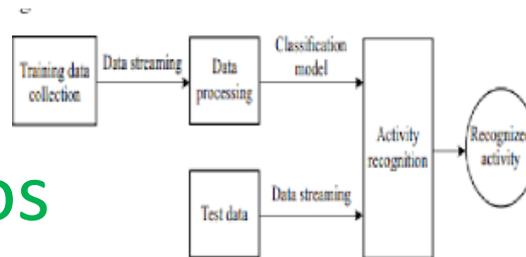


Sistemas Autónomos

- Automatizar ingeniería de descriptores



- Automatizar procesamiento de los datos

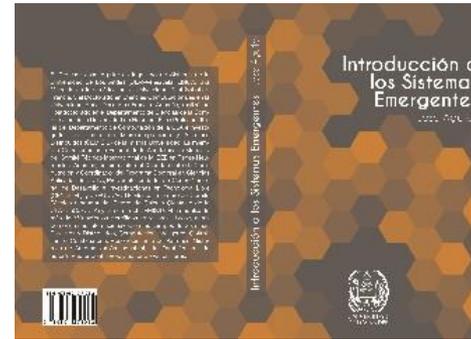


- Aprendizaje federado

- Transferencia de Aprendizaje



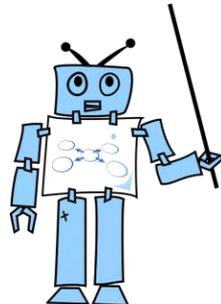
- Control Emergente



<http://bit.do/fSivD>

- Aprendizaje Incremental

- Meta-etiqueta en tareas de diagnóstico



- ML explicativo



TEPUY
Escuela Politécnica Nacional

FEUNET

INTRODUCCIÓN A LA COMPUTACIÓN AFECTIVA

Jose Aguilar, Jhon Edgar Amaya & Ángel Gil
Editores

“Si buscas resultados distintos, entonces no hagas siempre lo mismo”

A. Einstein

www.ing.ula.ve/~aguilar

<http://www.ing.ula.ve/~aguilar/distinciones/conferencias/>

Algunos últimos artículos en el tema

- “An Autonomous System for the Self-supervision of Animal Fattening in the context of Precision Livestock Farming”, Coautores: R. García, A. Pinto, *Future Generation Computer Systems*, Vol. 150, pp. 220-231, 2024 (<https://shorturl.at/xzE78>).
- “A reinforcement learning based energy optimization approach for household fridges” Coautores: J. Giraldo, R. Mejia, *Sustainable Energy, Grids and Networks*, Vol. 36, 2023 (<https://shorturl.at/cEHKV>)
- "Evaluation of digital competence profiles using Dialetheic Logic" Coautores: A. Gonzalez, R. Dos Santos, *International Journal of Artificial Intelligence in Education*, vol. 33, no. 1, pp. 59-87, 2023 (<http://bit.do/fTff6>)
- “Deep Reinforcement Learning Approaches for the Hydro-thermal Economic Dispatch Problem considering the uncertainties of the context”, Coautores: A. Ramirez, M. R-Moreno, *Sustainable Energy, Grids and Networks*, 2023 (<https://shorturl.at/ejnzL>).
- "A Bio-inspired Emergent Control Approach for Distributed Processes", Coautor: M. García, *Applied Soft Computing*, vol. 141, 2023 (<https://shorturl.at/vFY39>).
- “Hybrid Algorithm based on Reinforcement Learning for smart inventory management”, Coautor: C. Cuartas, *Journal of Intelligent Manufacturing*, vol. 34, pp. 123–149, 2023 (<http://bit.do/fU5eM>).
- ”Social Learning Analytics for determining Learning Styles in a Smart Classroom”, Coautores: O Buendia, A. Pinto, J. Gutierrez, *Interactive Learning Environments*, Vol. 30, No. 2, pp. 245-261, 2022 (<http://bit.do/e39V4>).
- “Sentiment analysis in learning resources”, Coautores: C. Salazar, E. Montoya, *Journal of Computers in Education*, 2022 (<http://bit.do/fVa2Z>)
- "Reinforcement Learning for Estimating Student Proficiency in Math Word Problems," Coautores: J. Pérez, E. Dapena, G. Carrillo, XVII Latin American Conference on Learning Technologies (LACLO), 2022 (<http://bit.do/fVXnm>).
- “Affective recommender systems in the educational field. A systematic literature review”, Co-autores: C. Salazar, J. Monsalve, E. Montoya, *Computer Science Review*, Vol. 40, 2021 System for the Fattening (<http://bit.do/fN2Te>).
- “Recognition of the Driving Style in Vehicle Drivers”. Co-autores: J. Cordero, K. Aguilar, D. Chávez, E. Puerto. *Sensors*, MDPI, Vol. 20, No. 9, 2020 (<http://tiny.cc/0978nz>)