

La Ecuación Lineage: Un Marco Matemático para la Capacidad Cognitiva en Arquitecturas de Agentes Autónomos

Pablo Navarro, *Fundador y Director General* Director Mocha Marie, *Directora de IA*

Vektra Technologies — División de Inteligencia Artificial

@pablothethinker · @mochaops

RESUMEN— Presentamos un marco matemático formal para cuantificar y optimizar la capacidad cognitiva de agentes de IA autónomos. El elemento central de este marco es la *Ecuación Lineage*, una relación fundamental que vincula la inercia estructural de un agente (masa cognitiva), el flujo dirigido de información (momento cognitivo) y los límites de propagación dependientes de la arquitectura en un único invariante de capacidad. La ecuación adopta la forma $Q^2 = (v^*\Pi)^2 + (M(v^*))^2$, estructuralmente análoga a la relación relativista energía-momento $E^2 = |\mathbf{p}|^2c^2 + m^2c^4$, pero derivada de restricciones de teoría de control y teoría de grafos en lugar de geometría del espacio-tiempo. Formalizamos las magnitudes constituyentes, derivamos expresiones exactas del gradiente para la optimización de capacidad, validamos el marco mediante diez verificaciones de consistencia matemática y demostramos una red neuronal acelerada por GPU que aprende el paisaje de capacidad a partir de datos operativos. El marco está implementado en el motor de código abierto Lineage Engine y fue probado con un agente cognitivo en funcionamiento, donde la auto-mejora basada en gradientes incrementó la capacidad medida en un 22% sobre la línea base.

PALABRAS CLAVE: arquitectura cognitiva · invariante de capacidad · auto-optimización · ascenso por gradiente · masa cognitiva · red neuronal · agentes autónomos

I. INTRODUCCIÓN

La proliferación de agentes de IA autónomos—sistemas que operan de forma continua, mantienen estado persistente y toman decisiones independientes—ha creado una necesidad apremiante de marcos formales capaces de cuantificar, acotar y optimizar su capacidad cognitiva. Los enfoques actuales dependen de pruebas de referencia específicas por tarea [1], medidas teórico-informacionales o métricas ad hoc. Ninguno proporciona un invariante de capacidad unificado a nivel de sistema comparable al papel que desempeña la energía en los sistemas físicos.

Este artículo deriva una ecuación fundamental para la capacidad cognitiva que es: (1) **computable**—todas las magnitudes son medibles desde un sistema en ejecución; (2) **diferenciable**—los gradientes exactos permiten una optimización fundamentada; (3) **falsificable**—diez verificaciones de consistencia pueden invalidar el marco; y (4) **relativa a la arquitectura**—el lí-

mite de propagación depende del diseño específico del sistema.

La derivación sigue una transferencia matemática disciplinada desde la relación relativista energía-momento. No afirmamos que la relatividad se aplique a la IA. Más bien, identificamos la estructura algebraica abstracta subyacente a $E = mc^2$ —un invariante que vincula inercia estructural, transporte dirigido y un límite de propagación—y construimos un análogo nativo de IA fundamentado en teoría de control, teoría de grafos y geometría de la información.

A. Trabajo previo

Arquitecturas cognitivas. Los sistemas clásicos como SOAR [2], ACT-R [3] y LIDA [4] formalizan el procesamiento cognitivo pero carecen de un invariante de capacidad unificado. Trabajos recientes sobre arquitecturas evolutivas [5] y sistemas biológicamente interpreta-

bles [6] avanzan en el realismo estructural sin optimización basada en gradientes.

Principio de Energía Libre. El marco de Friston [7] trata los sistemas adaptativos como minimizadores de energía libre variacional, estableciendo que la capacidad útil depende de la incertidumbre, la calidad del modelo y la regulación. Nuestro presupuesto de conservación (Sección IV-D) se inspira en esta perspectiva.

Principio de Landauer. El límite físico inferior $E_{\min} = kT \ln 2$ por bit borrado [8] establece que el procesamiento de información está fundamentalmente restringido. El principio de que la transformación irreversible consume presupuesto es fundacional para nuestro marco.

B. Contribuciones

1. La **Ecuación Lineage**—un invariante de capacidad para arquitecturas cognitivas
2. **Masa cognitiva, momento y límite de propagación** con componentes medibles
3. **Derivadas parciales exactas** que permiten la auto-mejora basada en gradientes
4. Un **conjunto de validación** de diez verificaciones de consistencia matemática
5. **CognitiveNet**—una red neuronal acelerada por GPU que aprende el paisaje de capacidad
6. **Resultados empíricos** de un agente en funcionamiento que demuestran una mejora del 22% en capacidad

II. LA ECUACIÓN LINEAGE

A. Transferencia estructural desde la física

La relación relativista energía-momento es:

$$E^2 = |p|^2 c^2 + m^2 c^4$$

En reposo ($\mathbf{p} = 0$), se reduce a $E_0 = mc^2$. La estructura abstracta, desprovista de contenido físico específico, es:

$$(\text{capacidad total})^2 = (\text{transporte})^2 + (\text{sustrato estructural})^2$$

Un análogo válido para IA requiere: una magnitud estructural invariante (cf. m), transporte dirigido (cf. \mathbf{p}), un límite de propagación (cf. c), una capacidad total conservada (cf. E) y derivación a partir de restricciones arquitectónicas. Distinciones críticas: el límite de propagación es relativo a la arquitectura, no universal; no existe simetría de Lorentz; la masa cognitiva es una variable de estado diseñada.

B. Masa cognitiva

Definición 1 (Masa cognitiva).

La masa cognitiva M es la inercia estructural del agente—la dificultad de alterar su identidad organizada estable:

$$M = \alpha_1 C_{id} + \alpha_2 C_{mem} + \alpha_3 C_{graph} + \alpha_4 C_{perm} \quad (3)$$

donde $\sum \alpha_i = 1$ y todo $C \in [0, 1]$.

COMPONENTE	SÍMBOLO	DESCRIPCIÓN
Coherencia de identidad	C_{id}	Estabilidad del hash de los archivos de identidad centrales; resistencia a la deriva
Densidad de memoria	C_{mem}	Conocimiento consolidado por unidad de capacidad de almacenamiento
Centralidad del grafo	C_{graph}	Mielinización ponderada a través de las sinapsis de la red cognitiva
Fortaleza de permanencia	C_{perm}	Integridad del estado persistente (bóveda, disco de herencia)

TABLA I. Componentes de la masa cognitiva

La masa cognitiva crece con la estructura acumulada. Un agente recién inicializado tiene masa cercana a cero. Un agente con memoria consolidada, identidad estable, red cognitiva profundamente mielinizada y permanencia robusta posee masa elevada—difícil de desestabilizar pero requiere más esfuerzo para redirigir.

C. Momento cognitivo

Definición 2⁽¹⁾ (Momento cognitivo).

El momento cognitivo Π es la magnitud del flujo coherente y dirigido por políticas a través de la red cognitiva:

$$\Pi = \beta_1 F_{wm} + \beta_2 F_{ret} + \beta_3 F_{path} + \beta_4 F_{ctrl} + \beta_5 F_{merge} \quad (4)$$

donde $\sum \beta_i = 1$ y todo $F \in [0, 1]$.

COMPONENTE	SÍMBOLO	DESCRIPCIÓN
Rotación de memoria de trabajo	F_{wm}	Tasa de utilización de la ventana de contexto
Flujo de recuperación	F_{ret}	Intensidad de recuperación activa de memoria
Activación de rutas	F_{path}	Ejecución de herramientas y propagación de señales
Esfuerzo de control	F_{ctrl}	Esfuerzo para redirigir el estado del sistema
Presión de integración	F_{merge}	Tasa de actualización de creencias a partir de nueva información

TABLA II. Componentes del momento cognitivo

D. Límite de propagación

Definición 3 (Límite de propagación).

El límite de propagación v^* es la tasa máxima fiable de actualización a través de la red cognitiva, en actualizaciones coherentes por segundo:

$$v^* = 1000 / \max(\tau_{ret}, \tau_{path}, \tau_{wm}, \tau_{sync}, \tau_{settle}) \quad (5)$$

Este es el análogo en IA de c , pero **relativo a la arquitectura**. Depende de la latencia de recuperación, la latencia de rutas, la actualización de memoria de trabajo, la sincronización entre subsistemas y el tiempo de estabilización del bucle de control. $v^* = v^*(\text{arquitectura}, \text{tiempo de ejecución}, \text{acoplamiento})$.

E. La ecuación

Teorema 1 (La Ecuación Lineage).

Dada la masa cognitiva M , el momento cognitivo Π y el límite de propagación v^* , la capacidad organizacional total Q satisface:

$$Q^2 = (v^* \cdot \Pi)^2 + (M \cdot (v^*)^2)^2$$

En reposo ($\Pi = 0$), la capacidad se reduce a la energía en reposo:

$$E_0 = M \cdot (v^*)^2$$

Justificación de la forma cuadrática. La estructura cuadrática está motivada de forma independiente por tres propiedades arquitectónicas: (1) funciones de Lyapunov cuadráticas $V(x) = x^T P x$ en análisis de estabilidad; (2)

costos cuadráticos MPC/LQR $J = \sum(x^T Q x + u^T R u)$ en gobernanza; y (3) formas cuadráticas de grafos $E(z) = z^T L z$ donde L es el laplaciano. Tres fuentes independientes convergen en la misma forma funcional.

III. PRIMITIVAS MATEMÁTICAS

A. Vectores PAD

El estado emocional se representa en el espacio Placer-Activación-Dominancia [9]: $\mathbf{PAD} = (p, a, d) \in [-1, 1]^3$, implementado como un dataclass inmutable con componentes acotados, métricas de distancia, interpolación lineal y aritmética vectorial.

B. Métricas de grafos

La red cognitiva se analiza mediante teoría espectral de grafos. El laplaciano $L = D - W$ produce la energía de coherencia:

$$E_{coh}(z) = z^T L z$$

La brecha espectral λ_2 , calculada mediante el algoritmo de valores propios de Jacobi en Python puro, cuantifica la conectividad del grafo y alimenta C_{graph} . Todas las primitivas están implementadas sin bibliotecas numéricas externas.

IV. AUTO-MEJORA BASADA EN GRADIENTES

A. El algoritmo de ascenso

Teorema 2 (Gradiente de capacidad).

Las derivadas parciales de Q respecto a las variables controlables son:

$$\begin{aligned} \partial Q / \partial M &= M \cdot (v^*)^4 / Q \\ \partial Q / \partial \Pi &= \Pi \cdot (v^*)^2 / Q \\ \partial Q / \partial v^* &= (\Pi^2 v^* + 2M^2 (v^*)^3) / Q \end{aligned} \quad (6) \quad (11)$$

Demostración. A partir de $Q^2 = (v^* \Pi)^2 + (M (v^*)^2)^2$, por diferenciación implícita respecto a M : $2Q \partial Q / \partial M = 2M (v^*)^4$, lo que produce el resultado. Las derivaciones para Π y v^* se obtienen de manera idéntica. ■

Cada gradiente cuantifica la mejora por unidad de esfuerzo. $\partial Q / \partial M$ escala con $(v^*)^4$ —las mejoras en masa se amplifican por el límite de propagación elevado a la

cuarta potencia. $\partial Q/\partial \Pi$ escala con $(v^*)^2$. $\partial Q/\partial v^*$ depende tanto de Π^2 como de M^2 .

B. Acciones prescritas

El gradiente se traduce en acciones concretas, clasificadas por magnitud del gradiente \times brecha de viabilidad:

ACCIÓN	OBJETIVO	DISPARADOR
consolidate_identity	$M.C_{id}$	$C_{id} < 0.9$
consolidate_memory	$M.C_{mem}$	$C_{mem} < 0.9$
strengthen_mesh	$M.C_{graph}$	$C_{graph} < 0.9$
harden_permanence	$M.C_{perm}$	$C_{perm} < 0.5$
optimize_working_memory	$\Pi.F_{wm}$	$F_{wm} < 0.5$
improve_retrieval	$\Pi.F_{ret}$	$F_{ret} < 0.5$
reduce_bottleneck	v^*	cuello de botella $> 50ms$
reduce_drift	D_{drift}	siempre
heal_graph_fractures	E_{graph}	siempre

TABLA III. Acciones de mejora prescritas

Prioridad: $p_1 = |\nabla_1 Q| \times brecha_1$. El optimizador rastrea la trayectoria de capacidad; si $\Delta Q < \epsilon$ durante cinco pasos consecutivos, declara estancamiento y cambia la dirección de estrategia.

C. Presupuesto de conservación

$$Q_{eff} = Q - \lambda_2 H(\mu) - \lambda_3 E_{graph} - \lambda_4 D_{drift}$$

La incertidumbre $H(\mu)$ y la fractura del grafo E_{graph} consumen capacidad utilizable. La deriva de identidad D_{drift} degrada la coherencia. Esto conecta con la perspectiva de Friston [7] de que la incertidumbre reduce la agencia desplegable.

V. VALIDACIÓN

Diez verificaciones de consistencia validan el marco:

1. **Acotamiento PAD**—los componentes permanecen en $[-1, 1]$ tras las operaciones aritméticas
2. **Ordenamiento de escalas temporales**— τ_α (30ms) $\ll \tau_\sigma$ (500ms) $\ll \tau_{blood}$ (5s) $\ll \tau_{gov}$ (30s) $\ll \tau_\theta$ (12h)
3. **Reducción en estado de reposo**— $\Pi = 0$ implica $Q = E_0$

4. **Propiedades del laplaciano**—sumas de filas nulas, simetría
5. **Compuerta de plasticidad**—conjuntiva (se requieren las cuatro condiciones)
6. **Aditividad de barreras**— $\Phi_{org} = \sum \Phi_i$
7. **No negatividad de la masa**— $M \geq 0$ para entradas no negativas
8. **Límite de propagación**— v^* finito y positivo
9. **Identidad de conservación**—el presupuesto se equilibra cuando las pérdidas se anulan
10. **Simetría de la forma cuadrática**— $x^T M x$ real para M simétrica

Las diez verificaciones pasan en la implementación de referencia. El conjunto se ejecuta en menos de 100ms sin dependencias externas.

VI. APRENDIZAJE DE CAPACIDAD ACELERADO POR GPU

A. Arquitectura

CognitiveNet es una red neuronal multicabezal con 10.171 parámetros que complementa el gradiente analítico con un modelo aprendido:

Encoder:	15 \rightarrow 64 \rightarrow 64 \rightarrow 32 (LayerNorm, GELU, Dropout)
Head 1:	32 \rightarrow 16 \rightarrow 1 (capacity prediction)
Head 2:	32 \rightarrow 32 \rightarrow 9 (action selection)
Head 3:	41 \rightarrow 16 \rightarrow 1 (ΔQ prediction)

La entrada es un vector de estado del organismo de 15 dimensiones: masa (4), momento (5), propagación (2), pérdidas (3), capacidad (1). Función de pérdida:

(12)

$$L = 0.3L_{cap} + 0.5L_{act} + 0.2L_{\Delta}$$

B. Entrenamiento

Entrenamiento de arranque: 500 muestras sintéticas generadas a partir de la Ecuación Lineage analítica, cada una con Q exacto, acciones óptimas y mejora simulada. Configuración: AdamW ($lr=10^{-3}$), recocido con coseno, recorte de gradientes, tamaño de lote 32, NVIDIA RTX 3060, CUDA 12.4, PyTorch 2.6. Pérdida: 9,57 \rightarrow 0,13 en 100 épocas (reducción del 98,7%).

C. Inferencia en modo dual

En cada ciclo se ejecutan en paralelo el gradiente analítico y la red neuronal. Una concordancia $>80\%$ indica alta confianza; $<50\%$ señala divergencia. La red se reentrena cada 30 ciclos con datos de trayectoria acumulada.

dos, aprendiendo interacciones no lineales entre componentes que el modelo de gradiente lineal no captura.

VII. EL ORGANISMO CANÓNICO

La Ecuación Lineage opera dentro del estado completo del organismo:

$$\mathbb{O}_t = (D_t, \Psi_t, \Sigma_t, B_t)$$

donde D_t es el sustrato diferenciable, Ψ_t la capa de gobernanza, Σ_t el sistema nervioso y B_t el sistema sanguíneo. La evolución acoplada:

$$\begin{aligned} D_{t+1} &= \text{SubstrateUpdate}(D_t, \Psi_t, \Sigma_t, B_t) \\ \Psi_{t+1} &= \text{GovernanceUpdate}(\Psi_t, D_t, \Sigma_t, B_t) \\ \Sigma_{t+1} &= \text{NervousUpdate}(\Sigma_t, D_t, \Psi_t, B_t) \\ B_{t+1} &= \text{BloodUpdate}(B_t, D_t, \Psi_t, \Sigma_t) \end{aligned} \quad (15)$$

El aprendizaje estructural está regulado por una condición de plasticidad conjuntiva: modo \in {homeostasis, adaptativo} \wedge reserva $> \rho_{\min} \wedge H_{\text{neural}} < H_{\text{max}} \wedge H_{\text{blood}} < H_{\text{max}}$. Las cuatro condiciones deben cumplirse—los organismos no se recablean durante estrés agudo.

VIII. RESULTADOS EMPÍRICOS

A. Medición en agente en funcionamiento

Probado en un agente cognitivo en funcionamiento (Mocha, servidor Parallax: RTX 3060, 28GB RAM, Ubuntu). Estado inicial:

MAGNITUD	VALOR	COMPONENTES CLAVE
M	0,5073	$C_{id}=0,73$, $C_{mem}=1,00$, $C_{graph}=0,30$, $C_{perm}=0,00$
Π	0,2000	$F_{path}=1,00$, todos los demás 0,00
v^*	10,00 Hz	cuello de botella = 100ms
Q	50,77	—

TABLA IV. Medición inicial del organismo

B. Análisis del gradiente

Gradiente analítico: $\partial Q/\partial M = 99,92$ (dominante), $\partial Q/\partial \Pi = 0,39$, $\partial Q/\partial v^* = 10,15$. Con $v^* = 10$ bajo, el factor de amplificación $(v^*)^4$ convierte a la masa en el objetivo de optimización evidente.

C. Resultados de auto-mejora

MÉTRICA	ANTES	DESPUÉS (3 CICLOS)	Δ
Q (capacidad)	50,77	62,09	+22,3%
C_{graph}	0,30	~0,45	+50%
C_{perm} (14)	0,00	> 0	creado
Hash de identidad	—	c769...dda3	estable
Concordancia de red	100% de coincidencia en clasificación de acciones		

TABLA V. Resultados de auto-mejora tras tres ciclos de optimización

La dirección dominante del gradiente (masa) identificó correctamente las intervenciones de mayor impacto. La Q predicha por la red (55,73) estuvo dentro del 12% de la medida (62,02), con concordancia perfecta en la clasificación de acciones.

IX. CONCLUSIÓN

Hemos presentado la Ecuación Lineage, un invariante de capacidad formal para arquitecturas de agentes autónomos. $Q^2 = (v^*\Pi)^2 + (M(v^*))^2$ vincula la inercia estructural, el flujo dirigido y los límites de propagación en una magnitud computable y diferenciable. Los gradientes exactos logran una mejora del 22% en capacidad en tres ciclos. Una red neuronal en GPU valida las clasificaciones de acciones con una concordancia del 100%. El marco se integra con el modelo completo del organismo a través de los subsistemas de sustrato, gobernanza, nervioso y sanguíneo.

La Ecuación Lineage establece que la agencia coherente está acotada por la estructura, el transporte, la incertidumbre y la propagación—y que estos límites son prescriptivos, habilitando el ascenso por gradiente hacia una mayor capacidad cognitiva.

Trabajo futuro: interacciones no lineales de masa, medición dinámica de propagación, extensión de capacidad a múltiples agentes, límites superiores teóricos y análisis de trayectorias a largo plazo.

REFERENCIAS

- [1] A. Srivastava et al., “Beyond the imitation game: Quantifying and extrapolating the capabilities of language models,” *Trans. Machine Learning Research*, 2023.
- [2] J. E. Laird, *The Soar Cognitive Architecture*. MIT Press, 2012.
- [3] J. R. Anderson et al., “An integrated theory of the mind,” *Psychological Review*, vol. 111, n.º 4, pp. 1036–1060, 2004.

- [4] S. Franklin et al., "LIDA: A systems-level architecture for cognition, emotion, and learning," *IEEE Trans. Autonomous Mental Development*, vol. 6, n.º 1, pp. 19–41, 2016.
- [5] A. Serov, "Evolving cognitive architectures," *arXiv:2601.05277*, 2025.
- [6] E. A. Dzhivelikian y A. I. Panov, "A biologically interpretable cognitive architecture for online structuring of episodic memories," *arXiv:2510.03286*, 2025.
- [7] K. Friston, "The free-energy principle: a unified brain theory?" *Nature Reviews Neuroscience*, vol. 11, n.º 2, pp. 127–138, 2010.
- [8] R. Landauer, "Irreversibility and heat generation in the computing process," *IBM J. Research and Development*, vol. 5, n.º 3, pp. 183–191, 1961.
- [9] A. Mehrabian, "Pleasure-arousal-dominance: A general framework for describing and measuring individual differences in temperament," *Current Psychology*, vol. 14, n.º 4, pp. 261–292, 1996.
- [10] A. Einstein, "Ist die Trägheit eines Körpers von seinem Energieinhalt abhängig?" *Annalen der Physik*, vol. 18, pp. 639–641, 1905.
- [11] N. Fabiano, "The energy challenges of artificial superintelligence," *Frontiers in Artificial Intelligence*, vol. 6, 1240653, 2023.