

# ELEMENTOS FORMALES

PARA LA CONSTRUCCIÓN DE UN MARCO SOCIOCOGNITIVO  
DE LAS CIUDADES COMO SISTEMAS COMPLEJOS  
HACIA UNA ESTRUCTURA NEUROCOGNITIVA DEL HÁBITAT  
EN EL CONTEXTO DE LA CIENCIA DE LA CIUDAD



JUAN PABLO JIMÉNEZ CERVANTES



Red Internacional Sobre la Enseñanza de la Investigación



Universidad de Guadalajara



Centro Universitario de Los Altos



# Elementos Formales para la Construcción de un Marco Socio- cognitivo de las Ciudades como Sistemas Complejos

Hacia una estructura Neurocognitiva del Hábitat  
en el contexto de la Ciencia de la Ciudad



Juan Pablo Jiménez Cervantes

# Elementos Formales para la Construcción de un Marco Socio- cognitivo de las Ciudades como Sistemas Complejos

Hacia una estructura Neurocognitiva del Hábitat  
en el contexto de la Ciencia de la Ciudad



Red Internacional Sobre la Enseñanza de la Investigación



Universidad de Guadalajara



Centro Universitario de Los Altos

Para garantizar la calidad, pertinencia académica y científica de esta obra, el manuscrito fue sometido a un riguroso arbitraje mediante dictamen a doble ciego, emitido por académicos especialistas en la materia, convocados por el Consejo Editorial del Centro Universitario de Los Altos de la Universidad de Guadalajara, México.



Red Internacional sobre la  
Enseñanza de la Investigación



Universidad de  
Guadalajara



Centro Universitario de  
Los Altos

Primera edición 2026  
DR. © 2026, Universidad de Guadalajara  
Centro Universitario de Los Altos (CUALTOS)  
Ave. Rafael Casillas Aceves 1200, C.P. 47620  
Tepatitlán de Morelos, Jalisco, México.  
<http://www.cualtos.udg.mx>

DR. © 2026, Ediciones RISEI  
Red Internacional sobre la Enseñanza de la Investigación  
Av. Ferroviaria. Cdla Las Acacias Mz. A V3  
Machala, El Oro, Ecuador

ISBN 978-9907-817-03-4

Hecho e impreso en Ecuador  
*Made and Printed in Ecuador*

## **Prefacio**

Las ciudades son, muy probablemente, los constructos artificiales más complejos producidos por el ser humano. Durante décadas, la participación de todos los campos de conocimiento han contribuido a su estudio morfológico, y a la comprensión y búsqueda de solución de sus problemas en todos los niveles de aproximación. Por una parte, las ciencias exactas proveen métodos y herramientas tecnológicas para el análisis, modelado y visualización de fenómenos urbanos, con el objetivo de llegar a decisiones más eficientes respecto a la información obtenida, para el diseño de políticas públicas y herramientas para resolver problemas de seguridad, salud, movilidad, energía, equipamiento urbano o vivienda.

Por otra parte, las ciencias sociales, las humanidades y las ciencias de la conducta ofrecen un panorama principalmente cualitativo, aunque no exento de rigor metodológico y con base en evidencia, sobre la interacción de la ciudadanía, a nivel tanto individual como de grupo, con su entorno natural y edificado y con el otro, en términos de bienestar y desarrollo cultural y social. No obstante, existen indicios de que históricamente, la comunicación e integración entre estos grandes bloques, en términos metodológicos y socialización de hallazgos entre unos y otros ha sido más bien limitada.

Es en esta coyuntura donde la ciencia de la ciudad ha surgido desde hace poco más de una década, como un campo de conocimiento que es aún emergente. La ciencia de la ciudad es un campo transdisciplinar de conocimiento, que tiene como propósito conciliar ambas vías para proponer principalmente, soluciones integrales a problemas urbanos complejos, anteponiéndose a las aproximaciones disciplinares únicas. La arquitectura, que trata con el espacio edificado, y más ampliamente, la relación perceptual y simbólica que el individuo tiene con el medio natural y artificial; y el urbanismo que se enfoca en el diseño, gestión y desarrollo y ordenamiento del territorio, han sido los campos disciplinares en los que tradicionalmente se ha depositado la tarea de configurar y diseñar las ciudades. Sin embargo, estas ya no parecen suficientes por sí mismas, para atender la demanda creciente de atención a fenómenos multivariantes mediados por grandes volúmenes de datos que requieren acciones más profundas y conciliadas con diversas áreas del conocimiento.

Es en este punto donde la perspectiva de la incorporación de la complejidad ante un campo transdisciplinar de conocimiento tiene sentido. Primero, es importante

plantear un panorama general sobre el efecto de la complejidad en las ciencias, y más particularmente, sobre el enfoque de análisis de los sistemas complejos en los estudios arquitectónicos y urbanos, que inciden en la percepción. La complejidad, como primera connotación, es esencialmente abstracta y generalizante e implica una componente más bien filosófica para abordarla epistemológicamente, o al menos, así ha sido desarrollada en el discurso de los últimos veinte años. La filosofía es una componente esencial para entender, definir y explicar fenómenos, y es una disciplina a la que le tengo aprecio y verdadero respeto; sin embargo, en ocasiones la preocupación por definir desde la ontología si el giro en el *rizoma* va hacia un lado o hacia el otro, puede distraernos del enfoque más adecuado, mas riguroso, y sobre todo más formal de implementación en las ciencias, y principalmente, en las ciencias sociales aplicadas al estudio de las ciudades.

El primer eje de este libro se enfoca en la otra acepción del concepto: la de los sistemas complejos, que nos permiten desplegar este rigor de implementación, y en donde la física y la biología han sido determinantes para trazar una trayectoria de estudio formal en todas las ciencias. Al momento de plantear isomorfismos entre disciplinas, sobre todo en la dirección de las ciencias exactas a las ciencias sociales y humanidades, hemos constatado que los supuestos y métodos basados en la física son utilizados para modelar fenómenos urbanos; sin embargo, en el paradigma biológico podemos encontrar también un campo relevante de acción.

Consecuentemente, el segundo eje de este libro busca proveer elementos matemáticos para identificar las diferencias más notables entre los sistemas complejos basados en física, donde surgen conceptos particulares como caos, entropía o autoorganización, y que se entienden y estudian como *máquinas*, y los sistemas complejos biológicos, que integran conceptos como senescencia o anticipación, y que miran a los sistemas como *organismos*. Si especuláramos un poco, la metáfora parece convincente si imaginamos las ciudades como organismos vivos (con sus debidas reservas por supuesto), con capacidad de autoorganización, de evolución, y además, con un esquema predictivo interno que se anticipe en lugar de ser únicamente reactivo ante fenómenos críticos.

Ahora bien, en este contexto existe una connotación importante, que pone al ciudadano en lo individual y a la ciudadanía como colectivo, en el centro del escenario. El concepto de ciudades inteligentes (*smart cities*) parece haber sido ya rebasado, puesto que si bien la ciudad inteligente nos ha dotado de mecanismos de sensores y de elementos para tratar e interpretar datos, no ha podido comprender del todo a la ciudadanía que la habita. Las ciudades inteligentes trabajan para lograr la optimización de servicios con tecnología y automatización, recopilan y analiza datos en tiempo real, son capaces de responder a eventos con sensores IoT y reglas predefinidas. Los ciudadanos acceden a servicios inteligentes, ejecutan acciones basadas en reglas preconfiguradas, mejorando la eficiencia urbana mediante digitalización.

No obstante, una ciudad en la que por ejemplo es posible medir con precisión el tráfico pero ignora cómo el diseño de una avenida altera la construcción conceptual de sus ciudadanos es una ciudad eficiente en términos técnicos, pero no necesariamente está conectada con la componente humana. Los mecanismos de manejo de datos y las soluciones propuestas con base en el paradigma de las *smart cities* han mostrado ser suficientemente eficientes a través de la plataforma que estas han construido, aunque no han logrado resolver del todo, problemas clave que sugieren otro tipo de acercamientos.

Las *ciudades cognitivas* planteadas a su vez, como una progresión de las anteriores, consideran un aprendizaje continuo de los fenómenos urbanos mediante IA e inteligencia contextual, analizan datos y aprende para predecir y adaptarse, evolucionan con el comportamiento humano y ambiental aprendizaje automático y simulación. Implementación de ciencias cognitivas como la neurociencia o la psicología. La ciudad cognitiva aprende de la interacción ciudadana, ya que uno de sus supuestos es que toda persona es un agente cognitivo, puede anticipar problemas y adaptar soluciones sin intervención humana y tienen como propósito, crear un ecosistema urbano adaptativo y en evolución constante.

La transición hacia la Ciudad Cognitiva que se propone en estas páginas implica tender un puente epistemológico entre las ciencias cognitivas y la ciencia de la ciudad, tomando como eje de aplicación dos elementos clave: la neurociencia computacional para el diseño de herramientas y métodos matemáticos y computacionales de diseño y simulación de agentes virtuales inteligentes, y como estructura vinculante de análisis y modelado, los sistemas complejos.

Lo que el lector encontrará en los capítulos siguientes es, en consecuencia, una apuesta por una ciencia social aplicada que se aproxima con mayor decisión al rigor matemático y al horizonte biológico, sin renunciar por ello a la densidad humana y cultural de lo urbano. Este libro propone una inflexión en la manera de concebir los estudios de ciudad: una transición desde una visión predominantemente tecnológica, asociada todavía al marco de las smart cities, hacia una perspectiva biopsicosocial y computacional más amplia, articulada en el contexto de las ciudades cognitivas. A través del modelado formal de los sistemas complejos, se plantea la posibilidad de vincular la escala micro del ser humano, particularmente desde la neurociencia y la construcción conceptual de la experiencia, con la escala macro del territorio, en el contexto general de la ciencia de la ciudad.

Esta articulación entre escalas supone reconocer que la ciudad tiene una lectura desde el nivel de sus grandes infraestructuras, redes institucionales, flujos materiales, dispositivos tecnológicos y configuraciones ecológicas, ni tampoco solo desde los procesos perceptuales, cognitivos, afectivos y corporales del individuo. Entre ambas dimensiones existe una relación de coproducción constante. Los sistemas socioecotécnicos de escala urbana, constituidos por las interacciones entre sociedad, tecnología, ambiente construido y entorno natural, condicionan y modulan la experiencia humana. Por otra parte, los sistemas biopsicofísicos de escala humana, en los que convergen cuerpo, percepción, cognición, emoción y respuesta fisiológica, participan activamente en la manera en que dichos entornos son habitados, interpretados y transformados.

Pensar la comunicación entre lo macro y lo micro implica, por tanto, construir marcos analíticos capaces de describir cómo las estructuras urbanas inciden en la conducta, el bienestar y la toma de decisiones de los sujetos, y cómo, a su vez, los patrones agregados de percepción, acción y adaptación humana reingresan en la ciudad en forma de organización espacial, dinámica social, demanda de infraestructura, conflicto, aprendizaje colectivo y cambio territorial.

Por último, el área de oportunidad que se mantiene abierta consiste en introducir, de manera necesaria y suficiente, un equilibrio entre la capacidad tecnológica de instrumentar, medir y automatizar la ciudad, y la capacidad teórica y metodológica de comprender a quienes la habitan, la perciben y la transforman. Ese equilibrio es posible

con marcos de interpretación que permitan vincular la experiencia humana, los procesos cognitivos y afectivos, y las dinámicas territoriales en una misma arquitectura de análisis.

Esa es, en última instancia, la apuesta de este libro: contribuir a una comprensión de la ciudad como un organismo complejo, que pueda reconocerse también como un sistema cognitivo y alimentar sus esquemas de simulación con estos datos y modelos. Si la ciencia de la ciudad aspira a formular respuestas más profundas frente a los problemas urbanos contemporáneos, entonces deberá ampliar su base epistemológica y metodológica hacia modelos que integren lo biológico, lo cognitivo, lo matemático y lo social. En esa dirección, la ciudad cognitiva se plantea como una hipótesis plausible: una forma de pensar la ciudad desde la complejidad de la vida humana que la hace posible.

Guadalajara, Jalisco  
abril 2026

*Juan Pablo Jiménez Cervantes*  
*City Science Media Lab@Guadalajara*  
Universidad de Guadalajara

# Contenido

## Parte I Los Sistemas Complejos

<b>1. Introducción</b> .....	3
1.1. Complejidad, vida, cognición y ciudad: hacia una representación neurocognitiva de lo urbano .....	3
<b>2. El enfoque tradicional de los sistemas complejos</b> .....	11
2.1. ¿Qué son los sistemas complejos? .....	11
2.1.1. La Teoría General de los Sistemas (TGS) .....	11
2.1.2. La Teoría del caos .....	16
2.1.3. La cibernética .....	21
2.1.4. Los sistemas ciberfísicos: integración entre cómputo, control y mundo físico .....	23
2.2. Los tres grandes problemas de los sistemas complejos .....	26
2.2.1. El problema de la vinculación (binding problem) .....	27
2.2.2. El problema de la emergencia .....	28
2.2.3. El problema de la jerarquía .....	30
2.3. No linealidad y autoorganización .....	31
2.3.1. Autoorganización y emergencia .....	34
2.4. Autopoiesis: concepto, principios y posibilidades de formalización ...	35
2.5. La complejidad computacional .....	38
<b>3. Los sistemas complejos biológicos</b> .....	45
3.1. Los sistemas complejos biológicos: una alternativa plausible de modelado .....	45
3.2. Elementos de matemática conceptual: La teoría de categorías .....	47
3.3. Las hiperestructuras como esquema de representación de los sistemas complejos .....	54
3.3.1. Definición de Hiperestructura .....	54
3.4. Los sistemas anticipatorios .....	58
3.4.1. La anticipación como rasgo definitorio de lo biológico .....	59
3.5. El marco matemático de los sistemas anticipatorios .....	62

3.5.1. El modelo de Metabolismo-Reparación .....	63
3.5.2. El modelo anticipatorio interno. ....	65
3.6. Los sistemas evolutivos de memoria .....	68
3.6.1. Memoria y autorregulación distribuida.....	70
3.6.2. MES, ciencias cognitivas y neurociencia: el modelo de los sistemas evolutivos neuronales de memoria. ....	71
3.7. Propiedades complementarias entre dos enfoques de sistemas complejos	73
 <b>Parte II Las Ciencias Cognitivas para una visión integradora de las ciudades como sistemas complejos</b>	
<b>4. La ciencia cognitiva como dimensión complementaria en la construcción de la ciudad .....</b>	<b>79</b>
4.1. El dilema de los neuros: neuroarquitectura y neurourbanismo .....	81
4.1.1. Modelos Teóricos de la neuroarquitectura .....	82
4.2. La componente neurocognitiva para el diseño de la ciudad .....	85
4.2.1. Arquitecturas cognitivas: una alternativa de IA con base en neurociencias .....	87
4.2.2. Topos: un metamodelo de diseño en entornos complejos .....	93
4.2.3. Formalización del modelo conceptual .....	95
<b>5. La ciencia de la ciudad: entre la complejidad y la cognición .....</b>	<b>103</b>
5.1. Conceptos básicos sobre la ciencia de la ciudad .....	103
5.1.1. Planteamientos Sustentantes en los sistemas complejos en la ciencia de la ciudad .....	103
5.1.2. Modelado Basado en Agentes .....	105
5.1.3. Cityscope: Una plataforma para el modelado de problemas urbanos .....	108
5.2. De las ciudades inteligentes a las ciudades cognitivas .....	111
5.3. Conclusiones .....	118
<b>Referencias .....</b>	<b>121</b>

**Parte I**  
**Los Sistemas Complejos**



# Capítulo 1

## Introducción

*La simplicidad de las leyes naturales se levanta por encima de las complejidades del lenguaje que utilizamos para su expresión. - Eugene Wigner*

### 1.1. Complejidad, vida, cognición y ciudad: hacia una representación neurocognitiva de lo urbano

El objetivo de este texto, es brindar elementos formales para la conciliación de la estructura cognitiva en el ser humano, explicada y estudiada por las ciencias cognitivas, con énfasis en la neurociencia, y su relación con los sistemas biopsicofísicos como una dimensión complementaria a la macroestructura de los sistemas socioecotécnicos. El lugar de enlace y de convergencia entre estas áreas son los sistemas complejos. Las ciudades, como el cerebro humano, pueden ser estudiadas desde este mismo enfoque.

Hablar hoy de sistemas complejos para el diseño, configuración y gestión del territorio, y más específicamente de las ciudades, implica en buena medida, revisar una transformación más profunda del pensamiento científico contemporáneo que suponga que el tránsito desde una visión del mundo basada en la separación de elementos hacia una comprensión relacional, dinámica y multiescalar de los fenómenos es el camino que es necesario intentar. En ese tránsito, la complejidad como forma de pensamiento, sujeta a sólo designa una propiedad de ciertos sistemas, para derivar también en una dificultad del conocimiento y una exigencia metodológica.

Aunque pueda llegar a ser discutible para el investigador social que se involucra en este tema y que busca proponer productos que entren en competencia con lo que las ciencias exactas y las ingenierías proponen desde su lugar, la obra de Edgar Morin resulta especialmente significativa en este punto, porque sitúa la complejidad como la necesidad de pensar conjuntamente lo que la tradición disciplinaria había escindido: orden y desorden, parte y todo, autonomía y dependencia, unidad y multiplicidad (Morin, 1977, 1994, 2008). Para una ciencia de la ciudad que busca resultados concretos y efectivos a los problemas socio-territoriales, esta orientación es decisiva, pues permite abandonar tanto la ilusión de una transparencia total del sistema urbano como la idea opuesta de que su heterogeneidad lo vuelve enteramente inabordable, y es que, por experiencia en la academia, aún después de varias décadas de posicionamiento de esta corriente de pensamiento, aún parece haber conflictos conceptuales sobre la idea de lo complejo contra lo complicado.

No obstante, la componente dura de la complejidad provino de la física, de la teoría de sistemas dinámicos, de la dinámica de los estados fuera de equilibrio y, más tarde, de la teoría de redes y de los estudios sobre emergencia. Esto permitió reconocer que, en determinados niveles de agregación, aparecen propiedades que no pueden deducirse a partir de las unidades elementales, mientras que la noción de jerarquía cuasi-descomponible mostró que muchos sistemas complejos se organizan en niveles relativamente estables, vinculados por interacciones no triviales (Anderson, 1972; Simon, 1962). Esta tradición ofreció herramientas fundamentales para pensar la ciudad en términos de no linealidad, autoorganización, escalamiento, conectividad y formación de patrones (Batty, 2012; Ortman et al., 2020). Gracias a ello, la ciudad dejó de concebirse solamente como un artefacto estático o un contenedor geométrico, para ser entendida como una totalidad abierta compuesta por flujos, infraestructuras, redes de interacción y procesos emergentes.

Sin embargo, cuando este marco se traslada sin mediaciones al estudio de fenómenos humanos, aparece un problema ontológico importante, que deriva además en un efecto colateral tanto epistemológico como metodológico que tiene incidencias operativas, cuando se considera el objeto de estudio, las ciudades desde la agregación de relaciones espaciales o como un sistema de circulación de materia, energía e información. Es necesario contemplar también en la misma canasta, una formación histórica y social habitada por agentes (en toda la extensión del término), que interpretan, recuerdan, anticipan, aprenden, sufren, deciden y modifican el propio medio que los condiciona. En los sistemas urbanos, los componentes son sujetos y colectivos situados en tramas de todas las naturalezas posibles. Por eso, si la complejidad física fue indispensable para romper con el reduccionismo lineal, la complejidad biológica abrió un horizonte adicional cuando admitimos que para los sistemas, la organización no sólo emerge, sino que además se conserva, se adapta, se reconfigura y opera en función de su propia continuidad y existencia.

Tal como veremos más adelante en este libro, la contribución del biólogo teórico Robert Rosen, es particularmente relevante. Su crítica a la reducción mecanicista de lo vivo, mostró que los organismos no pueden ser comprendidos exhaustivamente como sistemas meramente reactivos, pues incorporan formas de anticipación y de organización causal que exceden el esquema simple de entrada y salida (Rosen, 1985a). En una línea distinta pero convergente, Maturana y Varela introdujeron la noción de autopoiesis para caracterizar a los sistemas vivos como redes que producen continuamente los componentes que las constituyen, manteniendo a la vez su organización en acoplamiento con el entorno (Maturana and Varela, 1980, 1992). Con ello, el estudio de la complejidad incorpora autonomía, clausura operacional, historicidad y cognición y se convierte en un escenario en donde el *conocer* y *conservar* la propia identidad se encuentran entrelazados.

La obra filosófica de Maturana permite extraer de esta tradición una consecuencia de gran alcance para la investigación social y urbana. Si toda observación depende de distinciones realizadas por un observador, entonces ningún conocimiento sobre la ciudad puede asumirse como una proyección de una realidad completamente dada (Maturana, 1988, 2009). Esto ayuda a volver más reflexiva la realidad, puesto que conocer exige explicitar desde qué categorías se construye el objeto. En el caso de las ciudades, esto significa reconocer que cada representación de esta (estadística, cartográfica,

morfológica, económica, etnográfica o computacional) se abstrae a únicamente ciertos aspectos del sistema y deja otros parcialmente fuera de campo. La complejidad se vuelve también una advertencia sobre los límites de toda formalización y sobre la necesidad de articular múltiples niveles de descripción sin volver absoluto ninguno de ellos.

Desde aquí se vuelve más clara la conveniencia de incorporar las ciencias cognitivas al campo de la ciencia de la ciudad. Si lo urbano es una realidad producida y vivida por agentes que perciben, se orientan, construyen mapas mentales, asignan valor a los lugares, regulan atención y toman decisiones bajo incertidumbre, entonces la cognición no puede permanecer al margen. Las ciudades son entornos de experiencia por excelencia, una ecología de señales, recorridos, memorias y expectativas. Juval Portugali ha insistido precisamente en esta dimensión al proponer que la ciudad debe analizarse como un sistema complejo en el que se enlazan información, espacio, cognición y autoorganización (Portugali, 2011, 2012). En esta coyuntura, la forma urbana opera como el marco de trabajo desde donde se da el intercambio físico de interacciones, pero además se instaure como medio cognitivo que registra y en ocasiones, condiciona tanto la percepción como el manejo de los imaginarios, y que operan eventualmente, sobre las conductas tanto individuales como colectivas.

La incorporación de la neurociencia profundiza aún más esta perspectiva, siempre que se evite convertirla en una explicación totalizante por una parte, o por otra, en una banalización innecesaria por un efecto del *hype* sobre el área que se ha producido en los últimos años (Gende and García, 2026; Corredor and Cárdenas, 2017). La relevancia de la neurociencia para la ciencia de la ciudad, aterrizada tanto en la arquitectura como en el neurourbanismo, radica en aportar una escala adicional desde la cual comprender cómo el entorno construido participa en la organización de las funciones cognitivas y su interacción con nuestras modalidades sensoriomotoras, que inciden en la regulación de la conducta. La neurociencia contemporánea, especialmente en su vertiente de redes, también ha abandonado imágenes excesivamente localizacionistas del cerebro y lo concibe como un sistema distribuido, multiescalar y sobre todo, complejo (Bassett and Sporns, 2017). A ello se suma el principio de energía libre de Friston, que ha ofrecido un marco poderoso para pensar sistemas adaptativos que deben anticipar e inferir regularidades del entorno para sostener su propia organización (Friston, 2010). Aunque estos desarrollos pertenecen originalmente al estudio del cerebro, dialogan de manera sugestiva con una teoría urbana interesada en acoplamientos entre ambiente, incertidumbre, regulación y acción.

La literatura reciente sobre ciudad y neurociencia sugiere que el entorno urbano añade un factor que participa en la modulación de procesos atencionales, afectivos y de estrés (Lambert et al., 2015; Ancora et al., 2022). Esta constatación significa que entre la configuración espacial de la ciudad y la experiencia socialmente situada de sus habitantes existe una zona de mediación corporal y cognitiva que merece ser investigada con mayor rigor, en donde convergen tanto instancias sociales, como manifestaciones culturales que inducen pertenencia, aspectos territoriales que pesan sobre la psique de la persona, biológicas y físicas. Por ello, incorporar la neurociencia a la ciencia de la ciudad aporta al enriquecimiento del análisis sobre cómo lo social y lo espacial se inscriben en la experiencia vivida desde lo biológico.

Aquí surge además, una aspiración que hace tomar a esta aportación, una saludable distancia de los enfoques neuro- de la neuroarquitectura y el neurourbanismo. Si bien

estas dos subdisciplinas tienen legitimidad y rigor al vincular ambiente con individuo en busca del bienestar mediante la medición de la actividad cerebral producida por un estímulo externo, la intención de ahondar sobre los fundamentos teóricos y matemáticos de los sistemas complejos, y del diseño de un modelo formal tiene como objetivo su implementación en agentes inteligentes virtuales, que puedan observar comportamientos más similares al del ser humano, incluyendo imperfecciones y sesgos de comportamiento naturales. Además calibrar herramientas tecnológicas con mayor precisión, y finalmente implementar herramientas basadas en neurociencias al diseño de políticas públicas.

Otra motivación importante, es que hace aparición un problema metodológico que conviene señalar con claridad. Una parte importante de la investigación social sobre complejidad ha desarrollado una discusión filosófica valiosa, crítica de la reducción y sensible a la heterogeneidad de lo real; pero con frecuencia esa discusión no alcanza a traducirse en estructuras formales capaces de especificar relaciones, mecanismos, jerarquías, temporalidades, restricciones y observables (Byrne and Callaghan, 2013; Barbrook-Johnson and Carrick, 2022). En esas condiciones, la complejidad corre el riesgo de permanecer como una sensibilidad teórica general o como un lenguaje de interdependencia, sin convertirse plenamente en programa analítico. El problema no es, en sentido estricto, que la investigación social filosofe demasiado, sino que a menudo se detiene en la discusión filosófica y concede menos atención a la dimensión matemática, computacional o formal que permitiría transparentar supuestos, comparar escenarios, explorar dinámicas no intuitivas y someter las interpretaciones a un nivel mayor de explicación.

Esta observación es crucial para una ciencia de la ciudad interesada en los sistemas complejos. Si la ciudad es efectivamente una realidad multiescalar y reflexiva, entonces no basta con afirmar que en ella todo está conectado o que sus fenómenos son emergentes. Es necesario construir representaciones capaces de mostrar cómo se organizan esas conexiones, en qué escalas operan, qué umbrales modifican el comportamiento del sistema, cómo se articulan memoria, percepción y decisión, y bajo qué condiciones ciertas perturbaciones se disipan, se amplifican o reestructuran la totalidad. Aquí la matemática y la computación no deben entenderse como un adorno de cientificidad, sino como medios para dotar a la complejidad de precisión analítica. Redes, sistemas dinámicos, simulación basada en agentes, topologías relacionales, formalismos categoriales y otras herramientas pueden cumplir esta función, siempre que se empleen sin perder de vista la historicidad, la normatividad y el carácter situado de los procesos urbanos (de Marchi, 2005; Mershon and Shvetsova, 2019; Klüver et al., 2003).

A su vez, la formalización tampoco puede erigirse en criterio único de verdad. Un modelo matemático puede ser impecable desde el punto de vista técnico y, sin embargo, omitir dimensiones decisivas de la vida urbana: conflicto, desigualdad, poder, simbolización, cuidado, precariedad o experiencia. Por eso, el desafío no consiste en sustituir filosofía por matemática, ni discusión social por neurociencia, sino en construir un marco de articulación entre registros heterogéneos. La complejidad exige precisamente ese equilibrio: reflexión epistemológica para no absolutizar los modelos; formalización suficiente para no quedar en la metáfora; y evidencia empírica diversa para no clausurar el sistema en una sola escala de observación.

Desde esta perspectiva, el paso de la física a la biología, y de allí a las ciencias cognitivas y a la neurociencia, puede entenderse como una ampliación progresiva del horizonte de inteligibilidad de la ciudad. La física aporta instrumentos para pensar no linealidad, redes, emergencia y patrones globales; la biología introduce memoria, adaptación, autonomía y anticipación; las ciencias cognitivas permiten comprender la ciudad como medio de orientación, significación y aprendizaje; y la neurociencia abre una vía para investigar cómo el entorno urbano participa en procesos de atención, emoción y regulación corporal. En conjunto, estas aproximaciones no compiten necesariamente entre sí: pueden integrarse en una visión más rica del sistema urbano como ensamblaje socioecotécnico, histórico y experiencial.

Es en este punto donde la idea de una representación neurocognitiva de la ciudad como un sistema complejo adquiere sentido. Tal representación busca construir puentes entre escalas, principalmente, entre la morfología urbana a nivel *top-down* y la experiencia perceptiva del individuo que se construye y refuerza en grupos, en un esquema *bottom-up*. La expectativa científica y filosófica reside en ofrecer un lenguaje capaz de vincular esos niveles sin colapsarlos, reorientando la ciencia de la ciudad hacia aspectos que trasciendan la aproximación técnica con miras a la optimización de los procesos, al mismo tiempo que implica un estudio formal y de simulación en términos de habitabilidad, salud, aprendizaje colectivo y justicia espacial.

Bajo esta lectura, la complejidad deja de ser una etiqueta general para nombrar lo intrincado y se convierte en un programa de conocimiento exigente. Tal programa pide reconocer que la ciudad no puede comprenderse adecuadamente desde una única tradición disciplinaria, pero también que la integración entre escalas y saberes no puede quedar en el nivel de la mera declaración interdisciplinaria. De ahí que la transición desde la física hacia la biología, la cognición y la neurociencia no deba entenderse como abandono de la formalización, sino como la oportunidad de enriquecerla. En la medida en que la ciencia de la ciudad sea capaz de articular filosofía, matemática, modelización y evidencia empírica, podrá aproximarse mejor a aquello que distingue a los sistemas urbanos humanos: que son, al mismo tiempo, estructuras materiales, procesos evolutivos, mundos vividos y escenarios de anticipación, conflicto y transformación colectiva. Esta tesis encuentra una de sus formulaciones más sugerentes en la obra de Juval Portugali, quien ha insistido en que la ciudad debe analizarse no sólo como sistema complejo, sino como un sistema en el que cognición, información, autoorganización y dinámica urbana se encuentran estrechamente entrelazadas (Portugali, 2000, 2004, 2011, 2012).

La importancia de Portugali radica en que introduce la cognición en el corazón mismo de la teoría urbana de la complejidad. No se trata, en su obra, de añadir un capítulo sobre percepción a un modelo previamente terminado de ciudad, sino de reconocer que la dinámica urbana depende en parte de las capacidades cognitivas de los agentes. En efecto, su propuesta de un enfoque cognitivo de la dinámica urbana parte de la idea de que las ciudades no pueden ser descritas satisfactoriamente si se omite que sus agentes interpretan el entorno, generan representaciones, planifican, recuerdan y actúan sobre la base de mapas cognitivos y repertorios simbólicos (Portugali, 2004). Bajo esta lectura, la cognición no es un nivel accesorio del fenómeno urbano, sino un componente de su causalidad. La forma urbana influye en la cognición, pero la cognición también participa en la producción y reproducción de la forma urbana.

Esta idea tiene un alcance filosófico importante. En la filosofía contemporánea de las ciencias cognitivas se ha cuestionado de manera creciente la idea de que la mente se encuentre enteramente contenida dentro del cerebro. Las corrientes reunidas bajo el paradigma 4E (*embodied, embedded, extended, enactive*) sostienen, con distintos matices, que la cognición depende constitutivamente del cuerpo, del entorno, de la acción y de los artefactos (Varela et al., 1991; Clark and Chalmers, 1998; Hutchins, 1995; Noë, 2004; Gallagher, 2017; Newen et al., 2018). Desde esta perspectiva, la ciudad con todas sus dimensiones y su interactividad con el individuo, forman parte de las condiciones de posibilidad de la cognición urbana. Pensar la ciudad como medio cognitivo significa entonces reconocer que la mente no sólo habita la ciudad: en cierto sentido, piensa con ella.

Aquí la afinidad con Portugali se vuelve particularmente fecunda. Su trabajo puede leerse como una contribución temprana y original a una filosofía urbana de la cognición distribuida. Cuando subraya que la dinámica de las ciudades debe partir de las capacidades cognitivas de los agentes, está sugiriendo que la autoorganización urbana no puede explicarse únicamente por analogía con sistemas físicos o biológicos. Las ciudades difieren de otros sistemas complejos porque los agentes urbanos no sólo interactúan; también conocen, interpretan, imaginan, proyectan y modifican su entorno mediante artefactos materiales y simbólicos (Portugali, 2004, 2011). En sus trabajos más recientes, esta idea se ha profundizado mediante la noción de sistemas complejos híbridos, donde el paisaje artificial de la ciudad no es un simple resultado pasivo de la acción humana, sino una instancia que participa activamente en la coordinación entre agentes (Portugali, 2024). En este punto, la cognición adquiere una centralidad filosófica decisiva: la ciudad no es sólo un objeto complejo observado desde fuera, sino un entramado en el que ambiente, artefactos y agentes co-producen inteligencia práctica, orientación y formas de coordinación.

La filosofía de la neurociencia añade otra capa complementaria a esta discusión. Mientras la neurofilosofía se ha interesado por las consecuencias de las neurociencias para problemas clásicos de la filosofía de la mente, la filosofía de la neurociencia ha examinado con mayor detalle qué tipo de explicaciones produce la propia neurociencia, cuáles son sus niveles de análisis, cómo se relacionan mecanismos, funciones y escalas, y qué límites tiene cualquier intento de reducción (Churchland, 1986; Craver, 2007; Bechtel, 2008; Von Eckardt and Poland, 2004). Esta distinción es especialmente importante para el estudio de la ciudad, porque evita entender la neurociencia como una nueva instancia soberana que vendría a reemplazar la sociología, la geografía o la teoría urbana. Su valor no radica en reducir lo urbano a procesos cerebrales, sino en ofrecer herramientas conceptuales y empíricas para pensar cómo ciertas configuraciones del entorno construido participan en la atención, la percepción, la memoria espacial, la regulación afectiva y la anticipación de la acción.

la tradición enactiva y neurofenomenológica aporta una vía complementaria particularmente sugerente. En lugar de suponer que un sujeto interno representa un mundo exterior ya constituido, Varela, Thompson y Rosch propusieron entender la cognición como un acoplamiento corporizado mediante el cual el organismo enactúa un dominio significativo de mundo (Varela et al., 1991). Más tarde, la neurofenomenología intentó articular la descripción rigurosa de la experiencia vivida con el análisis de la dinámica neural (Varela, 1996). Para una ciencia de la ciudad, esta perspectiva es sumamente

valiosa, ya que fortalece una dimensión constitutiva más inexplorada del sistema urbano mismo, que forma parte del esfuerzo por volver inteligible la ciudad.

En esa medida, su incorporación permite enriquecer tanto la discusión filosófica como la modelización de la ciudad, y abre un camino prometedor para pensar una ciencia urbana capaz de vincular forma, experiencia, cognición y organización sistémica en un mismo horizonte conceptual.



## Capítulo 2

# El enfoque tradicional de los sistemas complejos

*Abandona la tentación de simplificarlo todo, de buscar fórmulas y respuestas fáciles, y empieza a pensar de forma multidimensional, a deleitarte con el misterio y las paradojas de la vida, a no abrumarte por la multitud de causas y consecuencias inherentes a cada experiencia; a apreciar el hecho de que la vida es compleja.— M. Scott Peck*

En este capítulo, se describirán los elementos formales fundamentales que abordan los sistemas complejos

### 2.1. ¿Qué son los sistemas complejos?

Aunque no existe un consenso único y universal, una definición conciliada describe a los sistemas complejos como redes constituidas por una gran cantidad de componentes o agentes que interactúan entre sí de forma no lineal y descentralizada (Sayama, 2015; Mitchell, 2009; Ladyman and Wiesner, 2020; De Domenico et al., 2019; Gershenson, 2025). El rasgo distintivo de estos sistemas es que sus interacciones dan lugar a un comportamiento colectivo macroscópico y a una autoorganización espontánea que no pueden ser explicados ni predichos únicamente mediante el estudio de las partes individuales. La ciencia de la complejidad se construye entonces, como una síntesis interdisciplinaria con raíces profundas en tres teorías principales: La teoría general de sistemas, la teoría del caos, y la cibernética. A continuación, se describen con más profundidad, cada una de estas teorías.

#### 2.1.1. La Teoría General de los Sistemas (TGS)

La teoría general de sistemas introdujo el cambio de paradigma del reduccionismo mecanicista al holismo. Ludwig von Bertalanffy fue pionero en el campo, al proponer la búsqueda de principios y leyes universales aplicables a sistemas en general, independientemente de su naturaleza específica (biológica, física o social).

La teoría general de sistemas (TGS) emergió en el siglo XX como una respuesta a los límites del paradigma analítico-reduccionista que, desde la revolución científica moderna, había favorecido la descomposición de los problemas en partes cada vez más pequeñas. Aunque esa estrategia produjo avances decisivos en numerosas disciplinas, también hizo visible una limitación importante: muchos fenómenos no pueden

comprenderse adecuadamente si se estudian únicamente a partir de sus componentes aislados. La TGS surgió, así, como un esfuerzo por restituir la inteligibilidad del *todo*, sin abandonar el rigor conceptual y analítico propio de la ciencia moderna.

En su formulación clásica, von Bertalanffy impulsó la TGS desde la biología teórica y desde una crítica explícita al mecanicismo. Su propuesta consistió en mostrar que existen principios de organización que reaparecen en dominios distintos y que, por ello, pueden formularse en un lenguaje suficientemente general como para favorecer la transferencia conceptual entre disciplinas (von Bertalanffy, 1950a,b, 1968). En este sentido, la TGS se convirtió en un programa epistemológico orientado a identificar isomorfismos, regularidades y estructuras comunes entre fenómenos biológicos, técnicos, sociales y organizacionales.

Kenneth Boulding contribuyó decisivamente a este programa al describir la teoría general de sistemas como el *esqueleto de la ciencia*, esto es, como una estructura conceptual intermedia entre las matemáticas puras y las teorías especializadas de cada campo (Boulding, 1956). A partir de esta idea, la TGS adquirió una función integradora importante, que es ofrecer un plano de inteligibilidad común que permitiera comparar niveles de complejidad, tipos de organización y formas de comportamiento sistémico.

La teoría general de sistemas puede verse, tanto una reacción filosófica al reduccionismo, como también una respuesta práctica al incremento de complejidad en la ingeniería, la biología y las organizaciones. En este contexto, la TGS aparece como antecedente de un campo sistémico más amplio que incluye la cibernética, la teoría de control, la teoría de sistemas aplicada, la autopoiesis y la ciencia de la complejidad (Dekkers, 2017). Esta ampliación es importante porque muestra que la TGS pudo encajarse desde su formulación clásica, a una trayectoria de desarrollo hacia modelos de regulación, adaptación y reorganización estructural.

Uno de los aportes conceptuales más importantes de esta noción consiste en comprender que un sistema es una configuración organizada de relaciones, más poderosa que una simple suma de elementos. En términos analíticos, un sistema puede ser representado como una entidad compuesta por elementos, relaciones y atributos:

$$S = (E, R, A) \quad (2.1)$$

donde

$$E = \{e_1, e_2, \dots, e_n\}$$

es el conjunto de elementos del sistema,

$$R \subseteq E \times E$$

es el conjunto de relaciones entre dichos elementos, y

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

es el conjunto de atributos relevantes para su descripción.

Esta representación distingue entonces entre *contenido*, *estructura* y *atributos* del sistema. El contenido corresponde al conjunto de elementos; la estructura, al patrón de

interrelaciones internas y externas; y los atributos, a las propiedades del sistema o de sus componentes (Dekkers, 2017). Esta triada permite pasar de una intuición holística general a una descripción más precisa de lo que hace que un sistema sea efectivamente un sistema.

A esta caracterización debe añadirse la noción de *emergencia*. Una propiedad emergente es una propiedad del todo que no puede explicarse de manera exhaustiva por las propiedades aisladas de sus partes. Si se denota por  $P(S)$  el conjunto de propiedades del sistema como totalidad y por  $P(e_i)$  el conjunto de propiedades del elemento  $e_i$ , puede expresarse de manera esquemática que existe emergencia cuando:

$$\exists p \in P(S) \quad \text{tal que} \quad p \notin \bigcup_{i=1}^n P(e_i)$$

Que se lee como: existe una propiedad elemental que pertenece al conjunto de propiedades del sistema, tal que dicha propiedad no se encuentra en la unión de conjuntos de las propiedades elementales del sistema.

La ecuación pretende representar formalmente la intuición central de la TGS: el comportamiento del todo no queda agotado por la simple agregación de propiedades locales. La emergencia introduce, por tanto, una diferencia de nivel entre el análisis de las partes y la comprensión de la organización global. Esta primera aproximación es relevante para lo que nos interesa plantear más adelante.

Otro punto crucial en la teoría general de sistemas es la relación entre *sistema* y *entorno*. Es imposible para la naturaleza de un sistema, existir de manera aislada, sino sólo en interacción con un medio del que recibe influencias y frente al cual despliega funciones. Por ello resulta útil extender la definición anterior e incorporar una referencia explícita al entorno  $\mathcal{E}$  que complementa la sistematización dada por la ecuación [2.1.1](#):

$$S = (E, R, A, \mathcal{E})$$

La frontera del sistema representa una delimitación analítica que permite distinguir entre relaciones internas y relaciones externas. Si  $R_{\text{int}}$  denota las relaciones entre elementos internos y  $R_{\text{ext}}$  las relaciones entre elementos del sistema y elementos del entorno, entonces puede escribirse:

$$R = R_{\text{int}} \cup R_{\text{ext}}$$

Esta distinción es particularmente importante en la tradición sistémica posterior, porque permite comprender que la apertura de un sistema es una condición formal de su inteligibilidad. (Dekkers, 2017) enfatiza este punto al mostrar que la frontera define qué elementos del universo serán considerados entorno efectivo del sistema, y que esa delimitación depende del problema de estudio

La dinámica del sistema puede formalizarse mediante una variable de estado. Si el estado reúne contenido, estructura y atributos en un instante  $t$ , entonces puede representarse como:

$$x(t) = (E(t), R(t), A(t)) \quad (2.2)$$

### 2.1.1.1. Sistemas dinámicos

Un sistema será dinámico si existe al menos un cambio temporal en alguna de estas componentes:

$$\exists t_1 \neq t_2 \quad \text{tal que} \quad x(t_1) \neq x(t_2)$$

que nos dice simplemente que la evaluación de un estado  $x$  en un tiempo  $t_i$ , es diferente si  $t_1 \neq t_2$ .

En una forma más operativa, y especialmente para sistemas abiertos, la evolución puede escribirse como:

$$\dot{x}(t) = f(x(t), u(t), w(t))$$

donde  $u(t)$  representa entradas o acciones de control y  $w(t)$  perturbaciones provenientes del entorno. Si además interesa describir salidas observables, puede añadirse además la siguiente expresión:

$$y(t) = h(x(t), u(t))$$

Estas expresiones son compatibles con el programa general de la TGS, y permiten hacer explícita la intuición de que el comportamiento del sistema depende tanto de su organización interna como de su acoplamiento con el entorno.

De esta forma, es posible articular los principios de la TGS con el enfoque de *caja negra*. Desde esta perspectiva, el sistema puede estudiarse inicialmente a partir de sus entradas y salidas, sin necesidad de abrir de inmediato su estructura interna. Esto equivale a privilegiar la relación entre comportamiento observable y entorno, posponiendo la descomposición interna hasta que el problema lo requiera (Dekkers, 2017). Formalmente, esta estrategia puede expresarse como el estudio de una correspondencia

$$u(t) \mapsto y(t)$$

sin especificar aún la forma explícita de  $f$  ni la composición interna de  $x(t)$ . El valor metodológico de este enfoque radica en que evita la saturación de detalles y obliga a reconocer, desde el comienzo, que el comportamiento del sistema no se entiende sólo desde sus piezas, sino también desde sus acoplamientos externos.

Una noción central en Bertalanffy es la de *equifinalidad*. A diferencia de lo que ocurre en muchos sistemas cerrados, en los sistemas abiertos puede alcanzarse un mismo estado final a partir de condiciones iniciales distintas y a través de trayectorias diferentes. Si  $\phi(t; x_0)$  denota la trayectoria del sistema a partir del estado inicial  $x_0$ , la equifinalidad puede representarse como

$$\forall x_0 \in D, \quad \lim_{t \rightarrow \infty} \phi(t; x_0) = x^*.$$

La importancia de esta idea es profunda: el comportamiento sistémico no queda determinado de manera unívoca por la condición inicial, sino por la organización del sistema y por sus condiciones de intercambio con el medio (von Bertalanffy, 1968). Dekkers retoma esta idea y la vincula explícitamente con la homeostasis, mostrando que

el equilibrio de muchos sistemas abiertos debe entenderse más como una estabilidad dinámica que como inmovilidad (Dekkers, 2017).

En consecuencia, puede distinguirse entre equilibrio estático y equilibrio dinámico. En un sistema abierto, la condición de estabilidad no exige ausencia de flujo, sino balance entre flujos de entrada y salida. Una representación elemental sería:

$$\dot{x}(t) = 0, \quad F_{\text{in}}(t) = F_{\text{out}}(t) \neq 0.$$

Aquí, el estado macroscópico del sistema permanece constante, pero lo hace gracias a intercambios continuos con el entorno. Esa es precisamente la lógica de la homeostasis: la persistencia del sistema se vuelve resultado de procesos de autorregulación.

La cibernética complementó este punto mediante la noción de retroalimentación. Si  $r(t)$  es un estado deseado o referencia, y  $y(t)$  la salida observada, una ley de control elemental puede escribirse como:

$$u(t) = K(r(t) - y(t)),$$

donde  $K$  representa el mecanismo regulador. En términos generales, este formalismo expresa la idea de que un sistema puede corregir desviaciones respecto de un estado objetivo a través de mecanismos de observación e intervención. Aunque este tipo de representación pertenece más claramente a la teoría de control que a la TGS clásica, su incorporación es plenamente coherente con el desarrollo posterior del pensamiento sistémico.

Es importante advertir dos matices importantes a esta discusión. El primero es que los procesos de control y de mantenimiento del equilibrio pueden organizarse en torno a zonas de frontera, esto es, mecanismos de codificación, filtrado, regulación y adaptación localizados en la interfaz entre sistema y entorno. El segundo es que estos modelos de *steady-state* o de equilibrio, no describen el sistema en su totalidad, sino normalmente un *aspecto* específico del mismo (Dekkers, 2017). Esta observación puede formalizarse introduciendo un índice de aspecto  $\alpha$ :

$$S^{(\alpha)} = (E^{(\alpha)}, R^{(\alpha)}, A^{(\alpha)}),$$

con dinámica asociada

$$\dot{x}^{(\alpha)}(t) = f^{(\alpha)}(x^{(\alpha)}(t), u^{(\alpha)}(t), w^{(\alpha)}(t)).$$

De este modo, el análisis sistémico reconoce que un mismo objeto puede ser estudiado bajo distintos aspectos: energético, funcional, logístico, informacional, económico o biológico, sin que todos ellos queden subsumidos en un único modelo operativo. Esta es una aportación particularmente importante de Dekkers, porque obliga a no confundir el sistema real con una representación analítica totalizante (Dekkers, 2017).

A partir de aquí se vuelve posible comprender una de las principales herencias de la TGS para la teoría contemporánea: su proyección hacia sistemas adaptativos, autopoieticos y complejos. Cuando los mecanismos ordinarios de regulación ya no bastan para mantener el equilibrio, el sistema no sólo ajusta parámetros: puede verse obligado a modificar su estructura. En términos formales, esto significa que pueden

cambiar los atributos del estado, pero también las relaciones o incluso el conjunto de elementos:

$$R(t + \Delta t) \neq R(t) \quad \text{o} \quad E(t + \Delta t) \neq E(t).$$

Este tránsito desde la regulación hacia la reestructuración es decisivo, porque muestra que la teoría general de sistemas debe entenderse tanto como una teoría de la estabilidad, como también una base conceptual para pensar la transformación estructural, la autoorganización y la adaptación.

La teoría general de sistemas puede leerse hoy como una matriz epistemológica y metodológica de largo alcance. Su aportación mayor fue el demostrar la conveniencia de desplazar la atención desde los objetos aislados hacia las relaciones, revalorando la interacción de las partes en términos de su organización interna, diferenciando el equilibrio estático de la estabilidad dinámica, y transicionando de la descripción fragmentaria de elementos individuales hacia la articulación entre niveles, fronteras, funciones y procesos. La TGS sigue siendo una base sólida para estudiar problemas complejos, multiescalares e interdisciplinarios.

### 2.1.2. La Teoría del caos

La teoría del caos, como segundo pilar teórico de los sistemas complejos, parte de la teoría de sistemas dinámicos, y demuestra que los sistemas deterministas simples pueden mostrar comportamientos impredecibles a largo plazo debido a la *sensibilidad* a las condiciones iniciales (de donde proviene el famoso efecto mariposa). Proporcionó el lenguaje matemático (atractores, bifurcaciones) necesario para describir la inestabilidad y el orden dentro del desorden.

La teoría del caos constituye uno de los giros más importantes de la ciencia contemporánea para comprender sistemas deterministas cuyo comportamiento puede ser irregular, aperiódico y prácticamente impredecible. Su relevancia radica en demostrar que la presencia de leyes deterministas no garantiza, por sí sola, la posibilidad de predecir con precisión arbitraria el futuro de un sistema. En este sentido, la teoría del caos obligó a distinguir con claridad entre *determinismo* y *predictibilidad*, una distinción que hoy resulta central en la física, la meteorología, la biología, la economía y, en general, en toda disciplina interesada en sistemas dinámicos no lineales (Smith, 2007; Cencini et al., 2010; Bertuglia and Vaio, 2005).

El antecedente histórico determinante de la teoría del caos suele situarse en los trabajos de Henri Poincaré sobre el problema de tres cuerpos a finales del siglo XIX. Este problema se menciona como un caso superior del problema de los dos cuerpos en mecánica celeste, en donde la interacción de dos cuerpos de este tipo se someten a condiciones iniciales de velocidad y posición, y se requiere calcular las posiciones y velocidades de ambos cuando se incorpora la atracción de la gravedad entre ellos. Es posible siempre, encontrar una solución analítica para el cálculo de los elementos requeridos en estas condiciones; sin embargo, cuando se añade un tercer cuerpo, el

escenario se vuelve físicamente caótico, y se vuelve imposible encontrar una solución analítica general.

En este problema surge por primera vez de manera clara, la idea central de que un sistema gobernado por leyes mecánicas exactas podía exhibir una dependencia extremadamente fuerte respecto de sus condiciones iniciales. Es importante destacar que los avances de Poincaré sobre el tema, contribuyeron a desestabilizar el ámbito que irónicamente, había encarnado durante siglos el ideal de regularidad y predicción (Cencini et al., 2010). Sin embargo, ese hallazgo no fue plenamente incorporado al núcleo de la física hasta bien entrado el siglo XX. La consolidación moderna del campo se produjo después, a partir de las contribuciones de Edward Lorenz, Michel Hénon, Boris Chirikov, David Ruelle, Floris Takens y Mitchell Feigenbaum, entre otros (Cencini et al., 2010; Lorenz, 1963; Ruelle and Takens, 1971; Feigenbaum, 1978).

La formulación contemporánea del caos suele comenzar con una aclaración conceptual importante. El caos no equivale a azar puro. Un sistema caótico no es un sistema sin ley, sino un sistema cuyo comportamiento, aun siendo generado por reglas deterministas, puede aparecer irregular debido a la amplificación rápida de incertidumbres muy pequeñas. Leonard Smith insiste en este punto al señalar que el caos matemático se asocia con la combinación de sensibilidad a condiciones iniciales, determinismo y recurrencia o permanencia acotada de las trayectorias; la no linealidad, además, es el mecanismo que permite que pequeñas diferencias produzcan consecuencias desproporcionadas (Smith, 2007). Esta observación es crucial porque evita una confusión frecuente: el caos no implica una destrucción del orden matemático del sistema, mas bien, ayuda a identificar sus límites prácticos de previsión.

En general, un sistema dinámico continuo puede representarse como

$$\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t); \boldsymbol{\mu}) \quad (2.3)$$

donde  $\mathbf{x}(t) \in \mathbb{R}^n$  es el vector de estado y  $\boldsymbol{\mu}$  es un conjunto de parámetros de control. Si el tiempo se discretiza, la evolución adopta la forma

$$\mathbf{x}_{n+1} = \mathbf{F}(\mathbf{x}_n; \boldsymbol{\mu})$$

La teoría del caos estudia aquellos sistemas en los cuales la evolución, aun siendo definida por una función precisa  $\mathbf{f}$  o  $\mathbf{F}$ , puede generar trayectorias muy sensibles a perturbaciones infinitesimales en el estado inicial. Por ello, la pregunta fundamental ya no es sólo si el sistema está determinado por leyes, sino cómo evoluciona la incertidumbre bajo esas leyes.

La noción matemática más característica del caos es la *sensibilidad a las condiciones iniciales*. Si dos estados iniciales muy próximos,  $\mathbf{x}(0)$  y  $\mathbf{x}(0) + \delta\mathbf{x}(0)$ , se separan en el tiempo según una ley aproximadamente exponencial, entonces se tiene

$$\|\delta\mathbf{x}(t)\| \approx \|\delta\mathbf{x}(0)\|e^{\lambda t},$$

al menos en un régimen local y durante un intervalo temporal relevante. Aquí,  $\lambda$  representa una tasa media de expansión. Cuando la máxima tasa de expansión es positiva, el sistema exhibe sensibilidad a condiciones iniciales. Esta idea se formaliza mediante el exponente de Lyapunov máximo:

$$\lambda_{\text{máx}} = \lim_{t \rightarrow \infty} \lim_{\|\delta \mathbf{x}(0)\| \rightarrow 0} \frac{1}{t} \ln \left( \frac{\|\delta \mathbf{x}(t)\|}{\|\delta \mathbf{x}(0)\|} \right)$$

Cencini et. al. presentan precisamente este formalismo como la manera rigurosa de caracterizar la sensibilidad a condiciones iniciales y de cuantificar la inestabilidad media de una trayectoria (Cencini et al., 2010). Si  $\lambda_{\text{máx}} > 0$ , perturbaciones arbitrariamente pequeñas crecen, en promedio, de manera exponencial. En consecuencia, aunque el sistema sea determinista, la predicción detallada sólo es posible durante un horizonte finito.

Ese horizonte de predictibilidad puede escribirse, de forma aproximada, como:

$$T_p \approx \frac{1}{\lambda_{\text{máx}}} \ln \left( \frac{\Delta}{\delta_0} \right),$$

donde  $\delta_0$  es la incertidumbre inicial y  $\Delta$  la tolerancia máxima admisible para la predicción. Esta relación expresa una idea central del caos: la limitación predictiva no proviene necesariamente de la ignorancia de las leyes, sino de la combinación entre incertidumbre inevitable en los datos iniciales y amplificación dinámica de esa incertidumbre. Smith insiste, de hecho, en que uno de los mitos más persistentes sobre el caos consiste en afirmar que vuelve inútil toda predicción; por el contrario, el caos redefine la predicción en términos de horizontes, escalas y distribuciones de incertidumbre (Smith 2007).

Un ejemplo paradigmático de dinámica caótica en tiempo discreto es el mapa logístico:

$$x_{n+1} = r x_n (1 - x_n), \quad 0 \leq x_n \leq 1.$$

Aunque esta ecuación es extremadamente simple, su comportamiento es extraordinariamente rico. Para ciertos valores del parámetro  $r$ , el sistema converge a un punto fijo; para otros, a ciclos periódicos; y, al aumentar  $r$ , atraviesa una cascada de duplicación de período que culmina en caos. Cencini, Ceconi y Vulpiani muestran que existe una sucesión de valores críticos  $r_1, r_2, \dots, r_n, \dots$  tal que, entre  $r_n$  y  $r_{n+1}$ , el sistema presenta un ciclo de período  $2^n$ , y que esta sucesión converge a un valor finito

$$r_\infty = \lim_{n \rightarrow \infty} r_n \approx 3,569945 \dots$$

más allá del cual la dinámica se vuelve caótica (Cencini et al., 2010). Esta transición, conocida como *cascada de Feigenbaum*, es una de las rutas más célebres desde el orden hacia el caos.

La importancia del mapa logístico no es puramente pedagógica. Su estudio reveló una propiedad de gran alcance: la *universalidad*. Feigenbaum mostró que ciertos cocientes asociados a la duplicación de período convergen a constantes universales para una amplia clase de sistemas no lineales. Una de ellas es

$$\delta = \lim_{n \rightarrow \infty} \frac{r_n - r_{n-1}}{r_{n+1} - r_n} \approx 4,6692 \dots$$

lo cual indica que sistemas físicamente distintos pueden compartir una misma estructura progresiva en su transición al caos (Feigenbaum, 1978; Cencini et al., 2010). Este descubrimiento fue decisivo porque mostró que el caos no es un catálogo disperso de rarezas, sino un dominio gobernado por regularidades profundas.

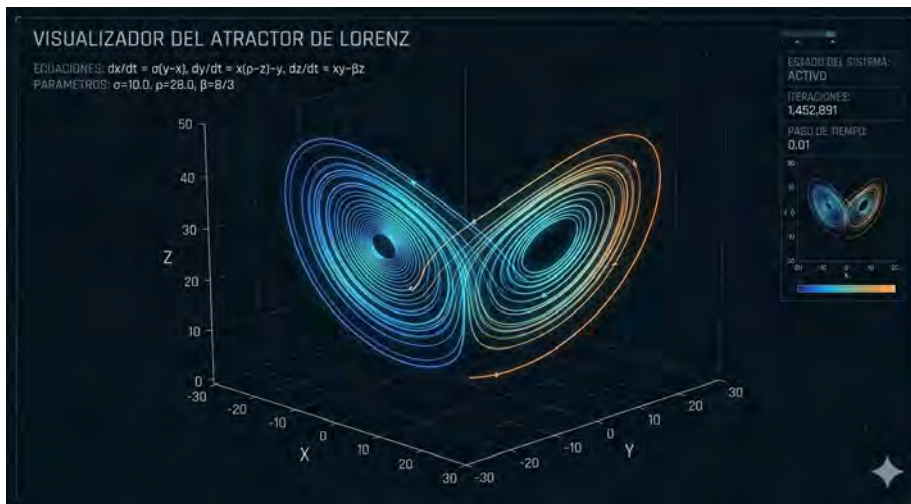
Otro sistema emblemático es el modelo de Lorenz, introducido originalmente como una simplificación de la convección atmosférica:

$$\dot{x} = \sigma(y - x),$$

$$\dot{y} = \rho x - y - xz,$$

$$\dot{z} = xy - \beta z.$$

Con valores apropiados de los parámetros ( $\sigma = 10$ ,  $\rho = 28$  y  $\beta = \frac{8}{3}$ ), este sistema genera el célebre atractor de Lorenz, una figura geométrica acotada y no periódica que se convirtió en un ícono de la teoría del caos. Más allá de su dimensión visual, el interés del sistema reside en que muestra con gran claridad que un sistema de baja dimensión, gobernado por ecuaciones deterministas sencillas, puede exhibir comportamiento aperiódico, inestable y estructuralmente rico (Figura 2.1) (Lorenz, 1963; Cencini et al., 2010).



**Fig. 2.1** El atractor de Lorenz presenta esta característica superficie, sólo cuando sus parámetros son  $\sigma = 10$ ,  $\rho = 28$ ,  $\beta = \frac{8}{3}$  (Visualización generada por IA)

La geometría de las trayectorias caóticas lleva naturalmente al problema de los atractores. En sistemas disipativos, el movimiento tiende a concentrarse asintóticamente en conjuntos particulares del espacio de fases. Algunos de ellos son regulares, como

puntos fijos o ciclos límite; otros presentan una estructura geométrica no entera y reciben el nombre de *atractores extraños*. Bertuglia y Vaio insisten en que conviene distinguir dos nociones que con frecuencia se confunden: un atractor *caótico* lo es por la dinámica que lo genera, mientras que un atractor *extraño* lo es por su geometría fractal (Bertuglia and Vaio, 2005). Smith subraya una idea clave si se analizan la acepciones anglosajonas de ambos conceptos: el término *strange* se refiere a la geometría fractal del atractor, mientras que *chaos* describe la dinámica del sistema (Smith, 2007). La distinción es útil porque no todo atractor caótico tiene por qué ser extraño, ni toda estructura fractal implica por sí misma dinámica caótica.

Una manera elemental de expresar la fractalidad geométrica de un atractor consiste en la dimensión de conteo en cajas:

$$D_B = \lim_{\varepsilon \rightarrow 0} \frac{\log N(\varepsilon)}{\log(1/\varepsilon)}$$

donde  $N(\varepsilon)$  es el número mínimo de cajas de lado  $\varepsilon$  necesarias para cubrir el conjunto. Cuando esta dimensión no es entera, el objeto no pertenece a la geometría euclidiana ordinaria. Bertuglia y Vaio recuerdan precisamente que la introducción de los fractales y de dimensiones no enteras fue decisiva para formalizar la geometría de los atractores extraños (Bertuglia and Vaio, 2005). Cencini, Cecconi y Vulpiani, por su parte, sitúan la geometría fractal como una herramienta fundamental para caracterizar atractores caóticos y no caóticos, como el atractor de Lorenz o el de Feigenbaum (Cencini et al., 2010).

La teoría del caos también ha esclarecido las principales *rutas hacia el caos*. Entre las más importantes se encuentran la cascada de duplicación de período asociada a Feigenbaum, la transición de Ruelle-Takens hacia un atractor extraño y la intermitencia de Pomeau-Manneville (Cencini et al., 2010). Estas rutas muestran que el caos, contrariamente a lo que podría intuirse, no aparece de forma completamente arbitraria, sino a través de reorganizaciones específicas de la estabilidad y de la topología de las trayectorias en el espacio de fases. La transición al caos es, por tanto, un fenómeno estructurado.

Desde una perspectiva epistemológica, la teoría del caos produjo una consecuencia de gran alcance: obligó a abandonar la identificación ingenua entre ley determinista y previsión ilimitada. El mundo caótico sigue siendo, en muchos casos, un mundo gobernado por ecuaciones. Pero el conocimiento de esas ecuaciones no basta si las condiciones iniciales sólo pueden medirse con precisión finita y si la dinámica amplifica exponencialmente esa incertidumbre. En esta línea, Smith subraya que el caos hace visible la importancia de distinguir entre el mundo y nuestros modelos del mundo (Smith, 2007). Bertuglia y Vaio añaden que la presencia de caos priva a los modelos de su valor como máquinas de predicción estricta del futuro, aunque no les quita su papel central como instrumentos de análisis y de inteligibilidad (Bertuglia and Vaio, 2005). En otras palabras, el redefine los alcances de la modelación en un sistema.

Por ello, la teoría del caos debe entenderse menos como una doctrina del desorden absoluto, y más como una teoría de los límites internos de la previsión en sistemas no lineales. Su verdadera aportación consistió en mostrar que puede haber orden dinámico sin periodicidad, ya que existe ley sin previsibilidad ilimitada y estructura geométrica

rica allí donde antes sólo se veía irregularidad. Vista así, la teoría del caos supone una reformulación profunda del problema clásico de la relación entre determinismo, incertidumbre y conocimiento.

### 2.1.3. La cibernética

El tercer pilar teórico de los sistemas complejos está en la cibernética. Fundada por Norbert Wiener y Arturo Rosenblueth (1947), se centró en la teoría del control y la comunicación tanto en máquinas como en organismos vivos. Aportó el concepto vital de retroalimentación circular y la idea de que los sistemas pueden autorregularse para alcanzar metas o adaptarse al entorno.

La cibernética y los sistemas ciberfísicos pertenecen a un mismo origen intelectual, aunque no son necesariamente equivalentes. La primera surgió a mediados del siglo XX como una teoría general de la comunicación, el control, la autorregulación y el comportamiento en máquinas y organismos; los segundos constituyen una familia contemporánea de sistemas ingenieriles en los que procesos físicos y procesos computacionales se integran de manera estrecha mediante sensores, actuadores, algoritmos y redes de comunicación. Si la cibernética formuló los principios generales del control, la retroalimentación y la organización dinámica, los sistemas ciberfísicos pueden entenderse como una implementación tecnológica avanzada de esos principios en contextos donde el tiempo físico, la seguridad, la coordinación distribuida y la interacción con el entorno son determinantes.

La cibernética surgió en el contexto de la posguerra como resultado de la convergencia entre teoría de control, teoría estadística de la información, neurofisiología, ingeniería y matemática aplicada. Su origen histórico suele situarse en las *conferencias Macy*, celebradas entre 1946 y 1953 (y que también fueron relevantes para el desarrollo sistematizado de la interdisciplina y de la ciencia cognitiva), y en la publicación del libro de Norbert Wiener *Cybernetics: Or Control and Communication in the Animal and the Machine*. Desde un principio, la disciplina se propuso estudiar problemas comunes a seres vivos y máquinas: comunicación, control, regulación, autonomía y comportamiento. La elección del término *cybernetics*, derivado del griego *kybernetes*: piloto o timonel), fue particularmente significativa porque desplazaba la atención desde la sustancia de los objetos hacia la conducción de su comportamiento.

Uno de los gestos epistemológicos más importantes de la cibernética consistió en sustituir la causalidad lineal simple por la idea de *causalidad circular*. En la tradición clásica, el comportamiento de un sistema se explicaba como la secuencia lineal de una causa seguida por un efecto. Desde la perspectiva de la cibernética, en cambio, el efecto de una acción puede retornar al sistema como información sobre su propio desempeño y modificar la siguiente acción. Este retorno de información es la base de la retroalimentación. Gracias a ello, la cibernética pudo tratar con rigor, fenómenos que parecían ubicarse entre la causalidad eficiente y la orientación hacia fines, como la homeostasis, la corrección de errores, el seguimiento de trayectorias o la regulación de variables esenciales.

En su formulación más elemental, un sistema regulado puede representarse como

$$\dot{\mathbf{x}}(t) = f(\mathbf{x}(t), \mathbf{u}(t), \mathbf{d}(t)), \quad \mathbf{y}(t) = h(\mathbf{x}(t)), \quad (2.4)$$

donde  $\mathbf{x}(t)$  es el estado del sistema,  $\mathbf{u}(t)$  la acción de control,  $\mathbf{d}(t)$  las perturbaciones y  $\mathbf{y}(t)$  la salida observable. En un esquema de retroalimentación negativa, la acción de control puede escribirse de la siguiente forma:

$$\mathbf{u}(t) = K(\mathbf{r}(t) - \mathbf{y}(t)),$$

donde  $\mathbf{r}(t)$  es la referencia u objetivo y  $K$  representa una ley de control. Si el sistema se vuelve lineal, la dinámica adopta la forma

$$\dot{\mathbf{x}}(t) = A\mathbf{x}(t) + B\mathbf{u}(t) + E\mathbf{d}(t), \quad \mathbf{y}(t) = C\mathbf{x}(t),$$

y la dinámica en bucle cerrado queda dada por:

$$\dot{\mathbf{x}}(t) = (A - BKC)\mathbf{x}(t) + BK\mathbf{r}(t) + E\mathbf{d}(t).$$

En términos de funciones de transferencia, una forma clásica del cierre por retroalimentación negativa es

$$T(s) = \frac{G(s)}{1 + G(s)H(s)},$$

donde  $G(s)$  es la planta (el sistema a controlar) y  $H(s)$  el bloque de realimentación (el proceso de entrada y salida en bucle de la información). Este conjunto de expresiones condensan una de las intuiciones centrales de la cibernética: el comportamiento de un sistema puede estabilizarse, corregirse o dirigirse mediante la comparación continua entre el estado observado y un estado deseado.

A partir de esta idea, la cibernética desarrolló la noción de *homeostasis*. Un sistema es homeostático cuando mantiene dentro de ciertos límites algunas variables esenciales pese a perturbaciones externas. Matemáticamente, esta condición suele asociarse a la existencia de un equilibrio o régimen estacionario

$$f(\mathbf{x}^*, \mathbf{u}^*, \mathbf{d}^*) = 0, \quad (2.5)$$

junto con mecanismos de corrección que devuelven al sistema a una vecindad de  $\mathbf{x}^*$  cuando las perturbaciones lo alejan de ella. La importancia de esta idea no radicó solamente en la regulación técnica, sino en la posibilidad de usar un mismo lenguaje para pensar organismos vivos, máquinas automáticas y, más tarde, organizaciones.

(Ashby, [1956]) profundizó esta línea al redefinir la cibernética como una teoría del comportamiento de las máquinas en lugar de una sobre dispositivos particulares. Su problema central atendía tanto la forma en la que un sistema se regula, como qué repertorio de comportamientos puede desplegar, y cómo este repertorio se relaciona con la complejidad de su entorno. De ahí surgió su formulación más célebre: la *ley de la variedad requerida*. En forma estilizada, si la variedad se mide como el logaritmo del número de estados distinguibles:

$$V(X) = \log_2 |X|,$$

Entonces, una formulación resumida de la ley puede escribirse como:

$$V_O \geq V_D - V_R,$$

Donde  $V_O$  es la variedad residual en los resultados,  $V_D$  la variedad de perturbaciones y  $V_R$  la variedad del regulador. En el caso ideal de regulación perfecta,  $V_O = 0$ , por lo que se obtiene

$$V_R \geq V_D.$$

La interpretación es que para neutralizar perturbaciones diversas, el sistema regulador debe disponer de suficiente diversidad interna de respuestas. La cibernética, se convierte en una teoría que provee reglas de estabilidad y también se vuelve una teoría de la complejidad del control, que no puede gobernar una realidad variada con un repertorio de acciones demasiado escaso.

Otra dirección importante de desarrollo fue la relación entre organización, entropía e información. En la línea de Heinz von Foerster, la autoorganización puede expresarse mediante una reducción relativa de incertidumbre u aumento de orden. Si  $H$  es la entropía de una fuente y  $H_m$  su valor máximo, la redundancia de Shannon puede escribirse como:

$$R = 1 - \frac{H}{H_m}$$

Si el orden interno de un sistema aumenta, una condición indicativa sería:

$$\frac{dR}{dt} > 0$$

Aunque esta formulación no constituye una definición universal de autoorganización, sí ilustra el paso desde la cibernética clásica de la regulación hacia una cibernética ampliada interesada en organización, aprendizaje y observación. Esa ampliación conduciría después hacia la llamada *segunda cibernética*, vinculada a von Foerster, Maturana y Varela, donde el observador, la cognición y la autorreferencia pasan al centro del análisis.

La cibernética entonces, se comprende como una disciplina de umbral. Conserva elementos de la ingeniería de control, pero los proyecta hacia una teoría más amplia del comportamiento, la regulación y la organización. Su legado principal radica en haber hecho pensable un vocabulario común para hablar de estabilidad, adaptación, comunicación, complejidad y control en dominios heterogéneos.

#### **2.1.4. Los sistemas ciberfísicos: integración entre cómputo, control y mundo físico**

Los sistemas ciberfísicos, (o CPS por sus siglas en inglés), constituyen una prolongación contemporánea y tecnológicamente situada de varias intuiciones cibernéticas. Los CPS van más allá del estudio general de la regulación de máquinas y de organis-

mos, y se ocupan de sistemas donde procesos físicos y procesos computacionales están integrados en tiempo real por medio de sensores, actuadores, algoritmos y redes de comunicación. En un CPS, la computación interviene directamente en la modificación de estados físicos del entorno.

Una representación abstracta de un sistema ciberfísico puede escribirse como:

$$CPS = (P, C, I)$$

donde  $P$  es el subsistema físico,  $C$  el subsistema cibernético o computacional, e  $I$  el conjunto de interfaces que conectan ambos dominios, típicamente sensores y actuadores. El subsistema físico evoluciona según leyes del mundo material; el subsistema cibernético observa, calcula y actúa; y la interfaz traduce magnitudes físicas en información y viceversa.

Esta integración puede expresarse mediante un modelo híbrido.

Sea  $q(t)$  un modo discreto de operación y  $\mathbf{x}(t)$  el estado continuo del proceso físico. Entonces una forma general es

$$\dot{\mathbf{x}}(t) = f_{q(t)}(\mathbf{x}(t), \mathbf{u}(t), \mathbf{w}(t)), \quad \mathbf{y}(t) = h_{q(t)}(\mathbf{x}(t)),$$

mientras que las transiciones discretas entre modos satisfacen la siguiente ecuación:

$$q_{k+1} = g(q_k, \mathbf{y}_k, \sigma_k),$$

donde  $\sigma_k$  representa eventos lógicos, decisiones del supervisor o condiciones de conmutación. Esta expresión matemática refleja una característica definitoria de los sistemas ciberfísicos que combina dinámica continua y eventos discretos en una misma arquitectura operacional.

En muchos casos, el controlador digital actúa por muestreo periódico. Entonces el modelo toma la forma de un sistema muestral:

$$\dot{\mathbf{x}}(t) = A\mathbf{x}(t) + B\mathbf{u}(t), \quad t \in [kT_s, (k+1)T_s)$$

con

$$\mathbf{u}(t) = \mathbf{u}_k, \quad \mathbf{u}_k = K\hat{\mathbf{x}}(kT_s)$$

donde  $T_s$  es el periodo de muestreo y  $\hat{\mathbf{x}}(kT_s)$  una estimación del estado en el instante de actualización. Esta representación resume el corazón técnico de un CPS: una planta continua es observada y controlada por un sistema digital que opera en instantes discretos.

Esta expresión matemática anticipa uno de los rasgos que (Kopetz, 2019) subraya con más fuerza: en los sistemas ciberfísicos, el tiempo físico es una variable de primer orden. No basta con que la salida sea correcta en el dominio de valores; debe ser correcta también en el dominio temporal. Por ello, la validez de una acción puede depender no sólo de  $\mathbf{u}$ , sino del instante exacto en el que se aplica. Esta exigencia puede sintetizarse mediante una restricción temporal del tipo

$$\tau_s + \tau_c + \tau_n + \tau_a \leq D$$

donde  $\tau_s$  es el retardo de sensado,  $\tau_c$  el tiempo de cómputo,  $\tau_n$  el retardo de red,  $\tau_a$  el tiempo de actuación y  $D$  la fecha límite impuesta por el proceso físico. El punto decisivo es que, en un CPS, una salida con el valor correcto pero emitida demasiado tarde puede ser funcionalmente errónea o incluso catastrófica.

En sistemas distribuidos, esta prioridad del tiempo obliga a enfrentar el problema de la sincronización. Si  $C_i(t)$  y  $C_j(t)$  representan las lecturas de dos relojes locales en nodos distintos, una condición básica para mantener una noción operativa de tiempo global es

$$|C_i(t) - C_j(t)| \leq \varepsilon,$$

donde  $\varepsilon$  es una cota conocida de desincronización. Esta condición es insuficiente para eliminar completamente las dificultades de simultaneidad y de ordenamiento consistente de eventos, aunque sí permite diseñar arquitecturas temporizadas, protocolos *time-triggered* y mecanismos de coordinación robusta entre componentes distribuidos.

La seguridad funcional es otro rasgo distintivo. Muchos CPS son *safety-critical*: un fallo de hardware, software, sincronización o comunicación puede tener consecuencias directas sobre la vida humana, el ambiente o la economía. Desde esta perspectiva, el análisis de un CPS no puede reducirse al rendimiento promedio; debe considerar además comportamiento en carga máxima, tolerancia a fallos, orden consistente de eventos, y vulnerabilidades de ciberseguridad. La seguridad y la ciberseguridad no son capas adicionales, sino propiedades estructurales del diseño.

En años recientes, el campo CPS también ha incorporado con fuerza la noción de *digital twin*. En una formulación abstracta, un gemelo digital puede escribirse como un modelo dinámico sincronizado con el sistema físico:

$$\hat{\mathbf{x}}_{k+1} = f_d(\hat{\mathbf{x}}_k, \mathbf{u}_k, \boldsymbol{\theta}_k), \quad \hat{\mathbf{y}}_k = h_d(\hat{\mathbf{x}}_k)$$

con un error de seguimiento

$$\mathbf{e}_k = \mathbf{y}_k - \hat{\mathbf{y}}_k$$

Si el modelo se adapta en línea, una regla genérica de actualización paramétrica puede expresarse como

$$\boldsymbol{\theta}_{k+1} = \boldsymbol{\theta}_k + \eta \Phi(\mathbf{e}_k, \hat{\mathbf{x}}_k, \mathbf{u}_k)$$

donde  $\boldsymbol{\theta}_k$  son parámetros del modelo,  $\eta$  una tasa de adaptación y  $\Phi$  una ley de corrección basada en discrepancias entre sistema y modelo. En la práctica, este tipo de estructura permite depuración, validación de algoritmos de control, mantenimiento predictivo y evaluación de estrategias de operación sin intervenir directamente sobre el proceso físico.

Los desarrollos recientes también muestran que la noción clásica de CPS tiende a ampliarse. Annaswamy et al. proponen la categoría de sistemas ciberfísico-humanos para destacar que muchas arquitecturas reales no pueden describirse adecuadamente sin modelar la presencia de personas en el lazo de control, ya sea como parte de la planta, como supervisores, como gestores de la autonomía o como agentes en sistemas

multiagente (Annaswamy et al., 2023). En ese caso, una formulación esquemática podría escribirse como

$$\dot{\mathbf{z}}(t) = F(\mathbf{z}(t), \mathbf{u}_c(t), \mathbf{u}_h(t), \mathbf{w}(t))$$

donde  $\mathbf{z}(t)$  reúne estados físicos, computacionales y humanos,  $\mathbf{u}_c(t)$  denota acciones automáticas y  $\mathbf{u}_h(t)$  acciones o decisiones humanas. Esta ampliación permite mostrar que la frontera contemporánea del campo está desplazándose desde la mera integración entre cómputo y proceso físico hacia sistemas sociotécnicos donde confianza, carga cognitiva, percepción, ética y coordinación humana también deben modelarse.

Tal como las otras bases de los sistemas complejos, ni la cibernética ni los sistemas ciberfísicos consisten de familias de formalismos que buscan describir, estabilizar, coordinar y hacer inteligible el comportamiento de sistemas que interactúan con su entorno. La diferencia central entre ellos es tanto histórica y operativa. La cibernética estableció el marco conceptual general de la retroalimentación, la homeostasis, la variedad y la organización; los sistemas ciberfísicos trasladaron ese marco a entornos ingenieriles y tecnológicos concretos en los que el tiempo físico, el cómputo distribuido, la seguridad y la interacción entre componentes heterogéneos se vuelven condiciones centrales de diseño. Vista así, la relación entre ambos campos es continua. Luego entonces, la cibernética proporciona la gramática del control y la organización, y los sistemas ciberfísicos, su despliegue técnico.

## 2.2. Los tres grandes problemas de los sistemas complejos

En el campo de los sistemas complejos, existen tres problemas de carácter estructural y epistemológico (Ehresmann and Vanbremeersch, 2006): el problema de la vinculación, también conocido como *binding problem*, que trata sobre cómo surge la coherencia entre componentes distribuidos; el problema de la emergencia, sobre cómo dicha coherencia da lugar a propiedades macroscópicas que exigen un nivel propio de descripción, y el problema de la jerarquía, que nos habla sobre cómo esas propiedades se estabilizan, se acoplan y se redistribuyen en arquitecturas multinivel.

Aunque estos problemas proceden de tradiciones intelectuales parcialmente distintas: la neurociencia y las ciencias cognitivas en el primer caso, la filosofía de la ciencia y la teoría de sistemas en el segundo, y la teoría de la organización y la arquitectura de la complejidad en el tercero, su articulación ofrece un marco robusto para el modelado y representación de la integración de los componentes de un sistema complejo, para pensar cómo se integran las partes, cómo surgen propiedades nuevas y cómo se organizan los niveles de un sistema a diferentes escalas y niveles de granularidad observacional. Estos tres problemas muestran que la complejidad de un sistema no puede reducirse ni al mero número de componentes ni al crecimiento cuantitativo de las interacciones, sino que remite, más profundamente, a la producción de coherencia, novedad y organización multinivel en sistemas cuyas dinámicas son no lineales, históricas y relacionales.

Una caracterización suficientemente madura de la complejidad evita la reducción a partir del simple aumento en el número de componentes de un sistema. Lo decisivo

es que dichos componentes interactúan de manera tal que la unidad del conjunto, las propiedades globales y la organización entre niveles no sean triviales. El primero interroga cómo actividades, características o procesos distribuidos pueden integrarse en configuraciones sistémicas coherentes; el segundo examina cómo de tales interacciones surgen propiedades macroscópicas con relativa autonomía descriptiva; y el tercero estudia cómo esas propiedades y procesos se organizan en niveles anidados de subsistemas. En conjunto, los tres problemas expresan una misma tensión: explicar cómo un sistema puede ser simultáneamente múltiple y unitario, local y global, compuesto y coherente.

La aproximación a estos problemas muestran que la complejidad puede tratarse con instrumentos formales capaces de registrar simultáneamente diversidad, dependencia y organización. A continuación, se describen y explican más detalladamente estos problemas.

### 2.2.1. El problema de la vinculación (binding problem)

Uno de los principales problemas que conciernen al tratamiento de la complejidad es el problema de la vinculación o del enlazamiento (Binding problem). En el campo de las ciencias cognitivas, y particularmente en el de la neurociencia, el problema de la vinculación se refiere a cómo un conjunto modular pero interconectado (o distribuido) de receptores puede actuar ante un estímulo en el ambiente, para posteriormente descomponerlo por sus características elementales (Di Lollo [2012]). Entre las particularidades más significativas de este problema, es que a pesar de su identificación en singular, corresponde más bien a una clase plural de problemas que se originan principalmente en el hecho de que diferentes fenómenos pueden referenciarse a un mismo nombre. Esto puede ejemplificarse por medio de las relaciones de correspondencia matemática, donde un elemento en el codominio de una relación puede originarse a partir de múltiples elementos en el dominio (correspondencia no unívoca) o que múltiples elementos del codominio corresponden a un mismo elemento en su dominio (Jiménez [2017]). El *binding problem*, formulado en la tradición de las ciencias cognitivas, designa en su forma más clásica la pregunta por la integración de información distribuida en representaciones unificadas. En una formulación ampliamente citada, el problema consiste en explicar cómo actividades separadas, procesadas por sistemas modulares o por poblaciones neuronales anatómicamente dispersas, llegan a constituir una representación coherente para la percepción, la memoria u otras funciones cognitivas. La literatura reciente ha mostrado además, que este problema no debe restringirse exclusivamente al dominio visual, pues remite de manera más general a la necesidad de preservar correspondencias correctas entre rasgos, objetos, eventos o contenidos dentro de sistemas distribuidos. Visto desde la teoría de sistemas complejos, el *binding* puede reinterpretarse como el problema general de la *coherencia estructural* que asume cómo múltiples elementos locales llegan a pertenecer juntos sin colapsar en una simple agregación indiferenciada. Del problema de la vinculación se deriva el uso de los modelos semánticos categóricos y el estudio de sus dominios y codominios.

### 2.2.2. El problema de la emergencia

Heylighen (1989) expone que la emergencia es un concepto clásico en la teoría de sistemas, que indica el principio de que las propiedades globales que definen sistemas de órdenes mayores o relativas a un todo, no pueden en general, reducirse a las propiedades de subsistemas de orden menor o partes. Estas propiedades irreductibles son llamadas *emergentes*. Una razón importante por la cual se enfoca la atención en el estudio de la emergencia es que las herramientas analíticas estándar usadas en física no parecen ser capaces de describir la generación de novedad. (Boschetti et al., 2005) Una aproximación importante al estudio de la emergencia en los sistemas complejos, es la de los sistemas auto-organizativos (Heylighen, 1989). En la sección 2.4 se hablará con más detalle del concepto de autopoesis, que Humberto Maturana y Francisco Varela utilizan para fundamentar su noción de *sistemas autopoieticos* y de la inclusión del término máquina. Maturana y Varela, desde una postura biológica, aluden a la idea de que los sistemas naturales son máquinas vivientes, homeostáticas y autoconscientes, plantean además, la carencia de un objetivo teleológico (o teleonómico) en la configuración del sistema. (Jiménez 2017)

En el contexto de los autómatas celulares, se ha identificado que el intercambio mutuo de información es un indicador para la transición de fase, del orden al caos. Este indicador es conocido como la *entropía* de un sistema (Boschetti et al., 2005).

Siguiendo la misma noción de autómatas celulares, cuando se asigna un parámetro  $\lambda$  en el flujo de información y se hace variar, La entropía de Shannon en un tiempo  $t$  ( $S^t$ ), está dada como sigue:

$$S^t = - \sum_{i=1}^n \frac{Q_i^t}{n} \log \frac{Q_i^t}{n} \quad (2.6)$$

Donde

- $m$  Es el número de reglas
- $n$  Es el número de células (tamaño del sistema)
- $Q_i^t$  Es el número de veces que la regla  $i$  se usó en el tiempo  $t$  a lo largo del autómata celular

Esta entropía de entrada es altamente variable sólo si la dinámica del sistema es compleja.

$$H(P) - H(P | P') = \sum_{k=1}^m \sum_{k'=1}^m P_{k,k'} \log \frac{P_{k,k'}}{P_k P_{k'}} \quad (2.7)$$

El problema de la *emergencia* introduce un segundo nivel de dificultad. Una propiedad emergente no es una propiedad desligada de la base microscópica, pero tampoco una propiedad que pueda leerse de forma inmediata en cada parte aislada. La formulación contemporánea más consistente de la idea insiste en dos rasgos: **dependencia** respecto de configuraciones de nivel inferior y, al mismo tiempo, cierta **autonomía** o novedad en el nivel superior. Por ello, la emergencia no debe entenderse como un recurso meramente retórico para nombrar lo inexplicado, sino como la necesidad de describir fenómenos cuya inteligibilidad aumenta cuando se atiende a la organización

del sistema en su conjunto y no solo a la suma de sus componentes. En esta dirección, la teoría de la complejidad ha contribuido a hacer menos opaco el proceso emergente al vincularlo con no linealidad, autoorganización, regímenes alejados del equilibrio y formación de patrones macroscópicos.

Del problema de la emergencia se deriva la necesidad de construir una metaestructura dinámica, autoadaptable y multinivel. Por estas restricciones y su dificultad teórico-práctica, se vuelve necesario utilizar métodos y herramientas de simulación y de inteligencia artificial.

Desde esta perspectiva, la emergencia puede ejemplificarse mediante medidas informacionales, en la medida en que estas permiten distinguir entre mera diversidad de estados y organización efectiva del sistema. Para mantener consistencia notacional, conviene reescribir la primera expresión distinguiendo entre el número total de elementos observados y el número de estados posibles. Si la proporción de elementos que ocupa el estado correspondiente en un instante temporal dado se define como

$$p_i^t = \frac{Q_i^t}{N}$$

y si dichas proporciones satisfacen la condición de normalización

$$\sum_{i=1}^r p_i^t = 1$$

entonces la entropía del sistema en ese instante puede expresarse como

$$S^t = - \sum_{i=1}^r p_i^t \log p_i^t$$

Esta magnitud mide la incertidumbre o dispersión de la distribución de estados del sistema. Cuando la probabilidad se concentra en pocos estados, la entropía disminuye; cuando la distribución se reparte de manera más homogénea, la entropía aumenta. En términos de complejidad, esta expresión resulta útil porque cuantifica la **variedad efectiva** del sistema en un momento dado. Sin embargo, su alcance debe precisarse: una entropía elevada indica multiplicidad de configuraciones posibles, pero no demuestra por sí misma la existencia de un patrón emergente, ya que un sistema puramente aleatorio también puede exhibir alta incertidumbre.

Por esa razón, una caracterización más robusta de la emergencia requiere incorporar una medida de dependencia estructural. La segunda expresión, escrita de forma matemáticamente consistente, corresponde a la **información mutua**:

$$I(P; P') = H(P) - H(P | P')$$

y puede desarrollarse como

$$I(P; P') = \sum_{k=1}^m \sum_{k'=1}^m P_{k,k'} \log \left( \frac{P_{k,k'}}{P_k P_{k'}} \right)$$

donde la distribución conjunta viene dada por

$$P_{k,k'} = \Pr(P = k, P' = k')$$

y las distribuciones marginales por

$$P_k = \Pr(P = k)$$

$$P_{k'} = \Pr(P' = k')$$

Esta cantidad expresa cuánto disminuye la incertidumbre sobre una variable cuando se conoce la otra. Si no existe relación estadística entre ambas, la distribución conjunta factoriza como producto de las marginales y la información mutua se anula; si, por el contrario, existe dependencia, la medida crece. Desde el punto de vista de la complejidad, esta expresión resulta especialmente valiosa porque permite detectar si la diversidad observada en el sistema posee **estructura interna**, ya sea entre dos momentos temporales, entre dos subsistemas o entre dos niveles de descripción.

La relevancia de estas expresiones para entender formalmente la emergencia como concepto, puede darse de tal modo que la entropía instantánea permita establecer cuánto repertorio de configuración despliega el sistema; además, la información mutua permite establecer cuánto de ese repertorio está articulado por dependencias no triviales. Si ambas dimensiones se consideran en conjunto, se posibilita distinguir entre tres situaciones analíticamente distintas.

Podemos encontrar:

1. Un sistema altamente ordenado pero rígido
2. Un sistema altamente variable pero puramente estocástico
3. Un sistema que combina diversidad con organización relacional.

Es en este último caso donde la noción de emergencia adquiere mayor densidad teórica, puesto que la pluralidad de estados se encuentra canalizada por correlaciones, restricciones o patrones que aparecen en el nivel colectivo. Esta interpretación mantiene aun en el aire el problema filosófico de la emergencia, pero ofrece una vía formal para representarla sin reducirla a una metáfora o un argumento especulativo.

### 2.2.3. El problema de la jerarquía

El problema de la *jerarquía* completa esta triada estructural. En términos generales, una jerarquía es un sistema compuesto por subsistemas interrelacionados, cada uno de los cuales puede, a su vez, descomponerse en subsistemas adicionales hasta alcanzar algún nivel elemental pragmáticamente definido. La importancia de esta idea en la teoría de la complejidad es decisiva, porque permite comprender que los sistemas complejos no solo contienen muchas partes, sino que están organizados en escalas de descripción y operación relativamente diferenciadas. De ahí que Simon haya sostenido que la complejidad adopta con frecuencia la forma de jerarquía y que los sistemas jerárquicos comparten propiedades estructurales que no dependen por completo de su

contenido particular. La jerarquía, así entendida, no designa únicamente una relación de subordinación, sino una arquitectura multinivel que posibilita tanto la descomposición analítica como la estabilización de comportamientos globales. (Learned-Miller, 2013) Heylighen (1989) apunta además, como una característica esencial de la emergencia, -entendida desde el contexto de la teoría de sistemas- su naturaleza jerárquica o multiniveles: un todo emergente en un nivel, es solamente un componente de un sistema emergente en un nivel más alto, de esto se desprende el uso y estudio de sistemas evolutivos de memoria y su aplicación en el diseño.

### 2.3. No linealidad y autoorganización

La autoorganización constituye uno de los conceptos más importantes dentro del estudio de los sistemas complejos, pues designa la capacidad de un sistema para generar estructura, coherencia funcional o patrones macroscópicos a partir de interacciones locales entre sus componentes, sin que medie necesariamente un controlador central explícito (Haken, 2008), por ejemplo, en el patrón de movimiento de una parvada de aves en vuelo (Figura 2.2). En este sentido, la autoorganización es un fenómeno susceptible de formalización matemática mediante ecuaciones no lineales, parámetros de orden, modelos de difusión, oscilación colectiva y medidas informáticas. (Haken, 2007; Haken and Portugali, 2016).



**Fig. 2.2** Los patrones de vuelo de una parvada de aves son comportamientos autoorganizativos

Desde una perspectiva general, el modelado matemático de la autoorganización puede situarse en el marco de un sistema dinámico no lineal de la forma

$$\frac{d\mathbf{x}}{dt} = \mathbf{F}(\mathbf{x}, \mu), \quad (2.8)$$

donde  $\mathbf{x}$  representa el vector de estado del sistema y  $\mu$  uno o varios parámetros de control. Esta formulación es suficientemente amplia para representar la evolución temporal de un conjunto de variables acopladas, pero adquiere particular interés cuando ciertos valores críticos de  $\mu$  inducen inestabilidades, bifurcaciones o transiciones entre regímenes dinámicos. Precisamente ahí aparece el problema de la autoorganización: el sistema deja de responder únicamente como suma de sus partes y comienza a exhibir configuraciones colectivas emergentes (Haken, 2007, 2008).

En la tradición de la sinérgica, uno de los aportes más relevantes consiste en mostrar que, cerca de una inestabilidad, el comportamiento colectivo del sistema puede describirse por medio de unas pocas variables macroscópicas llamadas *parámetros de orden*. Una de las expresiones más representativas en este contexto es la ecuación de amplitud tipo Ginzburg–Landau,

$$\frac{\partial A}{\partial t} = \mu A - g|A|^2 A + D\nabla^2 A \quad (2.9)$$

donde  $A$  es la amplitud del modo colectivo dominante,  $\mu$  controla el crecimiento de la inestabilidad,  $-g|A|^2 A$  introduce un mecanismo no lineal de saturación y  $D\nabla^2 A$  representa el acoplamiento espacial. Esta ecuación permite describir cómo pequeñas fluctuaciones locales pueden amplificarse y estabilizarse hasta constituir una estructura coherente a escala macroscópica. Su interés en sistemas complejos radica en que formaliza el paso de la interacción micro-local al orden emergente global (Haken, 2007, 2008).

Cuando la autoorganización adopta la forma de patrones espaciales, uno de los formalismos más importantes es el de los sistemas de reacción/difusión. En su forma básica para dos variables acopladas, puede escribirse como:

$$\frac{\partial u}{\partial t} = f(u, v) + D_u \nabla^2 u \quad (2.10)$$

$$\frac{\partial v}{\partial t} = g(u, v) + D_v \nabla^2 v \quad (2.11)$$

Aquí,  $u$  y  $v$  representan concentraciones, densidades o estados locales;  $f(u, v)$  y  $g(u, v)$  describen las interacciones reactivas entre ambas variables; y los términos difusivos modelan la propagación espacial. La relevancia de este sistema consiste en que la competencia entre reacción local y difusión puede romper la homogeneidad inicial y producir estructuras organizadas tales como manchas, franjas, ondas o mosaicos espaciales. En términos de sistemas complejos, este formalismo muestra con claridad que la autoorganización no requiere un diseño externo del patrón final: éste emerge de la dinámica interna del sistema (Nicolis and De Wit, 2007).

Una expresión estrechamente relacionada con el análisis de la formación espontánea de patrones es la ecuación de Swift–Hohenberg,

$$\frac{\partial u}{\partial t} = ru - (1 + \nabla^2)^2 u - u^3, \quad (2.12)$$

donde  $u$  es un campo escalar y  $r$  actúa como parámetro de control. Este modelo ha sido ampliamente utilizado como ecuación prototípica para estudiar la aparición

de patrones estacionarios cerca de una inestabilidad de tipo Turing o de convección. Su valor teórico reside en que permite estudiar la selección de longitudes de onda, la estabilidad de patrones y la transición desde estados uniformes hacia configuraciones periódicas o localizadas. De este modo, ofrece un marco matemático particularmente limpio para analizar el problema de la autoorganización espacial (Swift and Hohenberg, 2008).

Otra vía fundamental para modelar la autoorganización en sistemas complejos es la *sincronización*. En este caso, el interés está principalmente en la coordinación temporal de múltiples unidades dinámicas. El modelo canónico para este fenómeno es el de Kuramoto:

$$\dot{\theta}_i = \omega_i + \frac{K}{N} \sum_{j=1}^N \sin(\theta_j - \theta_i)$$

acompañado por el parámetro de orden

$$r e^{i\psi} = \frac{1}{N} \sum_{j=1}^N e^{i\theta_j}.$$

En estas expresiones,  $\theta_i$  es la fase del oscilador  $i$ ,  $\omega_i$  su frecuencia natural,  $K$  la intensidad del acoplamiento,  $r$  el grado de coherencia colectiva y  $\psi$  la fase media del conjunto. Este modelo muestra que, incluso cuando cada oscilador posee una dinámica individual distinta, el incremento del acoplamiento puede inducir la aparición espontánea de sincronía global. Así, la autoorganización se expresa como la transición desde un régimen disperso hacia un régimen de coordinación colectiva (Pikovsky and Rosenblum, 2007).

La autoorganización también puede adoptar la forma de criticidad autoorganizada, es decir, de una dinámica que conduce espontáneamente al sistema hacia un estado crítico caracterizado por avalanchas, cascadas y distribuciones de escala. En una representación discreta tipo pila de arena, la relajación local de un nodo que supera un umbral puede expresarse como:

$$x_i(t+1) = x_i(t) - d_i$$

$$x_j(t+1) = x_j(t) + 1 \quad \text{para todo } j \in \mathcal{N}_i$$

donde  $d_i$  es el número de vecinos del nodo  $i$  y  $\mathcal{N}_i$  su vecindad. Aunque se trata de una dinámica local simple, el acoplamiento reiterado entre nodos produce cascadas de múltiples tamaños y empuja al sistema hacia un régimen crítico sin necesidad de ajuste externo fino. En este caso, la autoorganización no conduce necesariamente a una configuración estable en sentido clásico, sino a un estado dinámico de equilibrio crítico con propiedades de escala (Hoffmann and Payton, 2018).

Además de los modelos dinámicos, la autoorganización puede abordarse mediante medidas informacionales. Una de las más utilizadas parte de la entropía de Shannon:

$$H(X) = - \sum_i p_i \log p_i \quad (2.13)$$

a partir de la cual es posible construir indicadores relativos de organización, por ejemplo,

$$O = 1 - \frac{H}{H_{\text{máx}}} \quad (2.14)$$

Aquí,  $H(X)$  cuantifica la incertidumbre asociada a la distribución de estados del sistema y  $O$  expresa, de manera normalizada, el grado relativo de organización alcanzado respecto de la entropía máxima posible. Este enfoque no modela directamente el mecanismo generativo del orden, pero sí permite estimar si el sistema ha incrementado su estructura interna, reducido su incertidumbre efectiva o producido una configuración más restringida y coherente. Por ello, tales medidas son especialmente útiles cuando la autoorganización se estudia como propiedad emergente medible más que como pura dinámica generativa (Prokopenko and Gershenson, 2014; Haken and Portugali, 2016).

En conjunto, estos formalismos permiten afirmar que la autoorganización en sistemas complejos puede representarse matemáticamente de manera rigurosa, aunque no mediante una sola ecuación universal. Más bien, su modelación depende del tipo de fenómeno que se desea describir: la emergencia de parámetros de orden, la formación de patrones espaciales, la sincronización temporal, la aproximación espontánea a la criticidad o el aumento cuantificable de organización interna. En todos los casos, sin embargo, subyace una misma intuición teórica: el orden macroscópico no aparece como imposición externa, sino como resultado de la dinámica relacional entre múltiples elementos acoplados (Haken, 2008, 2007).

### 2.3.1. Autoorganización y emergencia

Aunque los conceptos de autoorganización y emergencia están estrechamente relacionados y a menudo se usan de manera intercambiable. A continuación se hace una breve explicación sobre sus diferencias basadas en el tiempo y la escala.

El primer aspecto diferenciador entre un concepto y otro se encuentra en la dimensión del fenómeno. La autoorganización es un proceso que transcurre en el tiempo. Es un proceso dinámico mediante el cual un sistema forma espontáneamente estructuras o comportamientos macroscópicos no triviales a medida que transcurre el tiempo. Se refiere a cómo los componentes individuales interactúan para organizarse a sí mismos sin un control externo o centralizado. Por otra parte, la emergencia se asume como una relación entre escalas. Esta se refiere a la aparición de propiedades en el nivel macroscópico que no pueden reducirse ni predecirse únicamente a partir de las reglas físicas microscópicas que rigen los componentes individuales. La emergencia es, en esencia, una relación no trivial entre las propiedades de un sistema a diferentes escalas (micro vs. macro). (Sayama, 2015; Mitchell, 2009)

Luego, la autoorganización se considera a menudo la explicación dinámica de por qué surgen las propiedades emergentes. Es el mecanismo *bottom-up* donde las fluctuaciones

y las interacciones locales llevan al sistema a explorar nuevos estados hasta alcanzar un nuevo orden o estructura. La emergencia es el resultado o la cualidad observada en el conjunto total. Por ejemplo, la *conciencia* del ser humano, puede suponerse como una propiedad emergente del cerebro (algunos autores la consideran incluso, como un *epifenómeno*), pero los procesos neurofisiológicos que la generan a lo largo del tiempo son procesos de autoorganización.

Las fuentes subrayan que la autoorganización permite que el sistema se mantenga en un estado que permite la emergencia. En sistemas adaptativos, la autoorganización no solo crea orden, sino que permite que el sistema aprenda y evolucione, dando lugar a niveles cada vez más complejos de propiedades emergentes. Podemos determinar que la autoorganización traza el camino mediante una dinámica temporal y la emergencia es el destino que determina una propiedad de escala (Bertuglia and Vaio, 2005; Mitchell, 2009).

## 2.4. Autopoiesis: concepto, principios y posibilidades de formalización

En el marco de los estudios de la complejidad, existe un concepto que ha sido ampliamente utilizado a nivel filosófico y epistemológico cuando se trata de introducirse a la discusión sobre la complejidad (y no necesariamente, sobre los sistemas complejos en términos formales): la autopoiesis. El término *poiesis* proviene del griego *ποίησις* y significa *acto creativo*. Palabras como poesía o poema, comparten también esta misma raíz.

La autopoiesis constituye una de las formulaciones más influyentes para pensar la especificidad de los sistemas vivos desde una perspectiva sistémica. el concepto proviene de los biólogos chilenos Humberto Maturana y Francisco Varela, quienes lo introdujeron para describir sistemas capaces de producir y reproducir continuamente los componentes y procesos que los constituyen como unidad (Dekkers, 2017; Maturana and Varela, 1973, 1980). En este sentido, la autopoiesis se relaciona con los procesos autorregulatorios de un sistema (homeostasis), ubicados en el contexto de lo expuesto previamente sobre los sistemas caóticos pero además, se implica una forma más concreta de auto-producción mientras el sistema preserva su funcionamiento, al mismo tiempo que genera de manera recurrente los componentes y relaciones que hacen posible su identidad.

La autopoiesis aparece como una reacción frente a las formulaciones más estrictamente cibernéticas de la teoría general de sistemas, en la medida en que intenta explicar rasgos distintivos de los sistemas biológicos que no quedan suficientemente descritos por las nociones de control, retroalimentación o equilibrio estacionario (Dekkers, 2017). En esa línea, la autopoiesis desplaza la atención hacia la clausura organizacional del sistema, su autorreferencia y su capacidad de mantener una identidad propia a través de procesos internos de producción y transformación.

La formulación canónica de Maturana y Varela puede resumirse así:

**Definición 2.1** Un sistema autopoietico es una red de procesos de producción, transformación y destrucción de componentes que, a través de sus interacciones, regeneran la misma red que los produjo y, al mismo tiempo, constituyen al sistema como una unidad concreta en el espacio.

(Dekkers, 2017; Maturana and Varela, 1973).

Esta formulación es importante porque permite comprender que la identidad del sistema de una organización recursiva de procesos en lugar de sólo atender la configuración de sus componentes elementales, dirigiendo el núcleo de identidad sobre la continuidad de la red de relaciones productivas que mantiene la unidad sistémica.

Son tres los principios que dominan la teoría de la autopoiesis: la autorreproducción, el cierre estructural y el acoplamiento estructural (Dekkers, 2017). El primero indica que el sistema produce, directa o indirectamente, los mismos tipos de componentes y procesos necesarios para su continuidad. El ejemplo paradigmático es la célula biológica: sus componentes bioquímicos, apoyados en flujos externos de materia y energía, participan en reacciones que sostienen la membrana, el metabolismo y la organización global que, a su vez, hace posibles esas mismas reacciones (Dekkers, 2017). El segundo principio, el cierre estructural, no significa aislamiento respecto del entorno, sino que toda perturbación externa sólo puede operar a través de la organización propia del sistema. El tercero, el acoplamiento estructural, expresa que la relación con el entorno no es externa en sentido fuerte, sino una historia de interacciones recurrentes que modifica al sistema sin anular su clausura operacional.

Desde esta perspectiva, la autopoiesis permite distinguir entre sistemas que se mantienen a sí mismos como unidad de producción y sistemas que producen algo distinto de sí. Dekkers insiste en que las organizaciones sociales suelen pertenecer más propiamente al dominio de la *alopoiesis*: producen bienes, servicios, decisiones o artefactos, pero no se autorreproducen del mismo modo que lo hace una célula o un organismo (Dekkers, 2017). Aunque ciertas teorías organizacionales han tomado prestados principios autopoieticos para pensar aprendizaje, identidad o auto-referencia, el propio Dekkers mantiene la distinción entre autopoiesis y alopoiesis como una diferencia estructural fundamental.

Otro aspecto central es la relación entre autopoiesis, percepción y cognición. Según esta lectura, la cognición se convierte en una dimensión emergente de la interacción recurrente entre sistema y entorno en un organismo. El sistema sólo responde a aquello que puede ser especificado por su propia estructura; por ello, la percepción trasciende la representación literal del medio, y se convierte en una forma estructuralmente mediada de acoplamiento con él (Dekkers, 2017). En los niveles superiores de complejidad, esa auto-referencia da lugar a aprendizaje, comunicación e incluso autoconciencia, lo que explica por qué la autopoiesis ha sido usada también como marco para pensar organismos, cognición y, con cautela, aprendizaje organizacional.

Desde el punto de vista matemático, conviene hacer una precisión metodológica: Cualquier formalización debe entenderse como una reconstrucción analítica compatible con el concepto, ya que no existe una ecuación estándar admitida por la teoría. Aun así, sí es posible expresar algunos de sus rasgos esenciales en un lenguaje matemático general.

Una primera forma de hacerlo consiste en representar un sistema autopoiético como una red de componentes, procesos y frontera:

$$\mathcal{A} = (C, P, \Sigma),$$

donde  $C = \{c_1, c_2, \dots, c_n\}$  es el conjunto de componentes,  $P = \{p_1, p_2, \dots, p_m\}$  el conjunto de procesos de producción y transformación, y  $\Sigma$  la frontera o dominio topológico que delimita la unidad del sistema. La idea autopoiética básica exige que la red de procesos produzca componentes que, a su vez, sostengan o regeneren la misma red de procesos y la frontera que constituye al sistema como unidad.

Si  $x_i(t)$  representa la concentración, cantidad o disponibilidad funcional del componente  $c_i$ , una dinámica genérica puede escribirse como

$$\frac{dx_i}{dt} = \sum_{r=1}^m v_{ir} R_r(\mathbf{x}, \mathbf{u}) - d_i(\mathbf{x}), \quad i = 1, \dots, n,$$

donde  $\mathbf{x} = (x_1, \dots, x_n)$ ,  $R_r$  representa la tasa del proceso  $p_r$ ,  $v_{ir}$  son coeficientes estequiométricos o productivos,  $d_i$  representa degradación o consumo, y  $\mathbf{u}$  recoge flujos externos de materia o energía. Esta ecuación describe una red productiva abierta al intercambio material, pero no dice todavía qué hace a esa red *autopoiética*.

Para acercarse más al concepto, deben añadirse condiciones de clausura organizacional. Una forma abstracta de escribirlas es:

$$\forall p_r \in P, \quad \exists J_r \subseteq \{1, \dots, n\} \text{ tal que } p_r = \phi_r(x_j : j \in J_r),$$

es decir, cada proceso del sistema depende de componentes producidos dentro de la propia red. Y, recíprocamente,

$$\forall c_i \in C, \quad \exists P_i \subseteq P \text{ tal que } c_i \in \text{Out}(P_i),$$

lo cual expresa que cada componente relevante para la organización del sistema debe ser producido por procesos pertenecientes a la propia red. Dicho de otro modo, la red produce componentes y esos componentes regeneran la red.

La frontera sistémica, central en la definición de Maturana y Varela retomada por Dekkers, puede representarse como una función emergente del estado interno:

$$\Sigma(t) = \Psi(\mathbf{x}(t)).$$

Esta expresión indica que la frontera tiene el papel de una configuración material y funcional mantenida por la dinámica interna del sistema. En el caso de una célula, por ejemplo, la membrana no es sólo un límite espacial, sino una estructura producida y sostenida por el propio metabolismo.

Además, para que el sistema conserve su identidad, la dinámica debe permanecer dentro de una región de viabilidad  $\mathcal{V}$  del espacio de estados:

$$\mathbf{x}(t) \in \mathcal{V} \quad \forall t \geq 0.$$

Esta condición expresa que la auto-producción requiere que el sistema mantenga rangos compatibles con su continuidad estructural para garantizar su viabilidad global. Si la trayectoria abandona la región de viabilidad, la organización deja de sostenerse y el sistema pierde su identidad como unidad autopoietica.

Lo más cercano a una formalización más específica aparece cuando conecta la autorreproducción con los conjuntos autocatalíticos de Kauffman (Dekkers, 2017). Desde esa perspectiva, puede pensarse un sistema autopoietico como una red de reacciones en la que los productos de la red catalizan otras reacciones de la propia red, generando cierre productivo. Si bien Dekkers no desarrolla el formalismo, la intuición puede expresarse de modo general diciendo que existe una familia de reacciones  $\mathcal{R}$  tal que:

$$\forall r \in \mathcal{R}, \quad \exists c_i \in C \text{ que participa en la red y favorece } r,$$

y que, colectivamente, las reacciones de  $\mathcal{R}$  son suficientes para regenerar los componentes requeridos por la misma red. Esta representación es incompleta para explicar del todo la autopoiesis, pero sí aproxima su lógica de cierre productivo.

La autopoiesis entonces, puede entenderse como una teoría de la identidad sistémica fundada en la auto-producción recursiva de componentes, procesos y frontera. Su potencia conceptual reside en mostrar que un sistema vivo se define principalmente por una organización que se produce y se conserva a sí misma a través del cambio a la vez que mantiene intercambios con el entorno y busca conservar su propio equilibrio interno. Matemáticamente, puede presentarse una descripción en términos de redes de procesos, clausura organizacional, regiones de viabilidad y, de forma más tentativa, dinámicas autocatalíticas. En ese sentido, la autopoiesis se sitúa en un punto intermedio entre una teoría biológica cualitativa y un programa aún abierto de formalización sistémica.

## 2.5. La complejidad computacional

A diferencia de otros usos del término *complejidad* vistos en el capítulo anterior, como la complejidad dinámica en la teoría del caos, la complejidad organizacional dentro de la teoría general de sistemas o la complejidad regulatoria de la cibernética, la complejidad computacional se ocupa de un problema más preciso: determinar cuántos recursos requiere resolver un problema mediante un procedimiento efectivo. En su formulación moderna, esos recursos son sobre todo tiempo, espacio, aleatoriedad, profundidad de circuito, y comunicación o longitud de demostraciones. Por ello, la complejidad computacional no se limita en conocer simplemente si algo es computable, sino *qué tan costoso* es computarlo y cómo comparar rigurosamente ese costo entre problemas, modelos y clases de algoritmos (Cook, 1983; Arora and Barak, 2009; Kapron, 2023).

El antecedente remoto del campo se encuentra en la teoría de la computabilidad. La *máquina de Turing*, introducida por Alan Turing permitió formalizar la noción de procedimiento efectivo y demostrar la imposibilidad de un algoritmo general para el *Entscheidungsproblem* o el problema de la decisión (Turing, 1937). Una vez fijada la frontera entre lo computable y lo no computable, surgió de manera natural una segunda

pregunta: entre los problemas computables, ¿*Cuáles son fáciles y cuáles son difíciles?*. Esa transición marca el paso de la computabilidad a la complejidad. En la reconstrucción histórica que hace Stephen Cook en su lección Turing, los trabajos fundacionales del área aparecen asociados a Rabin, Hartmanis y Stearns, Cobham, y posteriormente a Cook, Karp, Savitch y Valiant (Cook, 1983; Kapron, 2023).

Uno de los primeros principios de la disciplina fue que el costo de un algoritmo debe definirse respecto de un modelo de cómputo, pero de un modo suficientemente robusto para que el resultado no dependa de detalles irrelevantes de implementación. Si  $M$  es una máquina y  $x$  una entrada, el tiempo de cómputo se expresa como

$$T_M(x)$$

mientras que su complejidad temporal en el peor caso para entradas de longitud ( $n$ ) se define por:

$$T_M(n) = \max_{|x|=n} T_M(x)$$

De forma análoga, si ( $S_M(x)$ ) denota el número de celdas de memoria usadas por  $M$  sobre la entrada  $x$ , entonces la complejidad espacial en el peor caso es:

$$S_M(n) = \max_{|x|=n} S_M(x)$$

Estas definiciones permiten abstraer el comportamiento de un algoritmo respecto de la longitud de la entrada y comparar problemas por su crecimiento asintótico. El paso decisivo fue advertir que, aunque distintos modelos razonables de cómputo no son idénticos, sus diferencias suelen preservarse dentro de factores polinomiales, lo que vuelve especialmente significativa la distinción entre recursos polinomiales y exponenciales (Hartmanis and Stearns, 1965; Cobham, 1965; Arora and Barak, 2009).

Sobre esa base se definieron las clases de complejidad más influyentes. Para tiempo determinista y no determinista, se escriben

$$\text{DTIME}(f(n)) = \{L \mid \exists M \text{ determinista tal que } L = L(M) \text{ y } T_M(n) = O(f(n))\},$$

$$\text{NTIME}(f(n)) = \{L \mid \exists M \text{ no determinista tal que } L = L(M) \text{ y } T_M(n) = O(f(n))\}$$

De modo análogo, para espacio determinista y no determinista:

$$\text{DSPACE}(f(n)) = \{L \mid \exists M \text{ determinista tal que } L = L(M) \text{ y } S_M(n) = O(f(n))\}$$

$$\text{NSPACE}(f(n)) = \{L \mid \exists M \text{ no determinista tal que } L = L(M) \text{ y } S_M(n) = O(f(n))\}$$

A partir de estas familias se introducen las clases clásicas

$$\mathbf{P} = \bigcup_{k \geq 1} \text{DTIME}(n^k), \quad \mathbf{NP} = \bigcup_{k \geq 1} \text{NTIME}(n^k),$$

$$\mathbf{PSPACE} = \bigcup_{k \geq 1} \text{DSpace}(n^k), \quad \mathbf{EXPTIME} = \bigcup_{k \geq 1} \text{DTIME}(2^{n^k})$$

La clase  $\mathbf{P}$  se interpreta tradicionalmente como el dominio de los problemas tratables, no porque todo algoritmo polinomial sea práctico en sentido ingenuo, sino porque la frontera polinomial/exponencial ha demostrado ser conceptualmente robusta y metodológicamente plausible (Cobham, 1965; Cook, 1983; Arora and Barak, 2009).

La clase  $\mathbf{NP}$  admite además una caracterización en términos de verificación eficiente. Un lenguaje  $L \subseteq \Sigma^*$  pertenece a  $\mathbf{NP}$  si existe un verificador determinista en tiempo polinomial  $V(x, y)$  y un polinomio  $p$  tales que

$$x \in L \iff \exists y \in \Sigma^* \text{ con } |y| \leq p(|x|) \text{ y } V(x, y) = 1$$

Esta formulación desplaza la intuición desde el cálculo de soluciones hasta su certificación: los problemas en  $\mathbf{NP}$  son aquellos cuyas soluciones, si se proponen, pueden verificarse eficientemente.

El célebre problema  $\mathbf{P} \stackrel{?}{=} \mathbf{NP}$ , que incluso forma parte de los llamados *problemas del milenio* y por el que el Clay Mathematics Institute ha reservado un premio de un millón de dólares, pregunta entonces si toda solución eficientemente verificable es también eficientemente encontrable (Cook, 1971, 2006; Clay Mathematics Institute, 2026).

El resultado que transformó por completo el campo fue la introducción de la NP-completitud. La idea fundamental es comparar problemas mediante reducciones polinomiales. Dados dos lenguajes  $A, B \subseteq \Sigma^*$ , se dice que  $A$  se reduce en tiempo polinomial a  $B$ , y se escribe

$$A \leq_m^P B,$$

si existe una función  $f : \Sigma^* \rightarrow \Sigma^*$ , computable en tiempo polinomial, tal que

$$x \in A \iff f(x) \in B.$$

Entonces  $B$  es  $\mathbf{NP}$ -completo si satisface dos condiciones:

$$B \in \mathbf{NP},$$

y

$$\forall A \in \mathbf{NP}, \quad A \leq_m^P B.$$

Intuitivamente, un problema  $\mathbf{NP}$ -completo es uno de los más difíciles dentro de  $\mathbf{NP}$ : si uno de ellos estuviera en  $\mathbf{P}$ , entonces todos los problemas de  $\mathbf{NP}$  estarían también en  $\mathbf{P}$ . Cook formuló el primer teorema de este tipo al mostrar que la satisfacibilidad booleana es completa bajo una noción apropiada de reducción; Karp generalizó enseguida el

marco mostrando que una amplia familia de problemas combinatorios clásicos comparte esa condición (Cook, 1971; Karp, 1972; Kapron, 2023).

En la práctica, esta estructura organiza la teoría de la dificultad computacional mediante dos principios. Primero, si  $A \leq_m^P B$  y  $B \in \mathbf{P}$ , entonces  $A \in \mathbf{P}$ . Segundo, si  $A$  es  $\mathbf{NP}$ -completo,  $B \in \mathbf{NP}$  y  $A \leq_m^P B$ , entonces  $B$  es también  $\mathbf{NP}$ -completo. Esto convirtió a las reducciones en el instrumento central para demostrar intractabilidad relativa y estableció una nueva forma de explicación matemática: un problema es difícil no sólo por su forma local, sino por su posición estructural dentro de una red de equivalencias y transformaciones polinomiales (Cook, 1971; Karp, 1972; Ladner, 1975).

Otro eje mayor del desarrollo del campo fue la complejidad espacial. Si bien en muchos contextos el tiempo domina la discusión, el espacio proporciona una perspectiva distinta sobre la estructura de los cómputos. Un resultado clásico es el teorema de Savitch, según el cual para toda función  $s(n) \geq \log n$ ,

$$\mathbf{NSPACE}(s(n)) \subseteq \mathbf{DSPACE}(s(n)^2).$$

En particular,

$$\mathbf{NPSPACE} = \mathbf{PSPACE}.$$

Este resultado es notable porque, a diferencia de lo que ocurre con tiempo, el no determinismo no incrementa dramáticamente la complejidad espacial. En torno a estos problemas crecieron también los estudios sobre compromisos tiempo–espacio, programas de ramificación y pebbling, varios de ellos muy ligados a la obra posterior de Cook y sus colaboradores (Savitch, 1970; Cook, 1983; Kapron, 2023).

La complejidad computacional no se limitó a máquinas secuenciales. Una vez reconocido que el paralelismo es un recurso específico, surgieron clases asociadas a circuitos booleanos y cómputo paralelo uniforme. Si  $C_n$  es un circuito booleano para entradas de longitud  $n$ , con tamaño  $\text{size}(C_n)$  y profundidad  $\text{depth}(C_n)$ , la clase  $\mathbf{NC}$  se define por

$$\mathbf{NC} = \bigcup_{k \geq 1} \mathbf{NC}^k,$$

donde  $\mathbf{NC}^k$  contiene los problemas resolubles por familias uniformes de circuitos de tamaño polinomial y profundidad  $O((\log n)^k)$ . En términos intuitivos,  $\mathbf{NC}$  capta el paralelismo eficiente: muchos procesadores, pero sólo tiempo polilogarítmico. Cook hizo contribuciones decisivas en la formulación de una teoría de la complejidad paralela, conectando circuitos, máquinas alternantes, espacio logarítmico y cómputo sincrónico (Cook, 1981, 1983; Kapron, 2023).

La teoría de circuitos condujo además al problema de los límites inferiores. Si  $f : \{0, 1\}^n \rightarrow \{0, 1\}$  es una función booleana, su complejidad de circuito puede escribirse como

$$C_f(n) = \min\{\text{size}(C_n) \mid C_n \text{ computa } f \text{ en } \{0, 1\}^n\}.$$

En principio, demostrar que  $C_f(n)$  crece superpolinomialmente para una familia explícita  $f_n$  sería una vía natural para separar clases como  $\mathbf{P}$  y  $\mathbf{NP}$ . Sin embargo, el área ha mostrado que estas demostraciones son extraordinariamente difíciles. De hecho,

parte importante de la teoría contemporánea consiste en comprender *por qué* esos límites inferiores son tan esquivos. Los resultados de relativización, *natural proofs* y algebrización indican que varios de los métodos más poderosos disponibles son, por sí solos, insuficientes para resolver grandes separaciones estructurales (Baker et al., 1975; Razborov and Rudich, 1997; Aaronson and Wigderson, 2009; Arora and Barak, 2009).

Una extensión decisiva del campo fue la complejidad de conteo. Mientras **NP** determina si existe al menos un testigo y que haga verdadero a  $V(x, y)$ , la clase **#P** cuestiona cuántos testigos existen. Formalmente, si  $V$  es un verificador polinomial, la función asociada puede expresarse como

$$\#V(x) = \left| \{y \in \{0, 1\}^{\leq P(|x|)} \mid V(x, y) = 1\} \right|.$$

Valiant mostró que esta perspectiva no sólo refina la teoría de decisión, sino que abre una jerarquía propia de dificultad. Su ejemplo paradigmático es el permanente de una matriz  $A = (a_{ij}) \in \{0, 1\}^{n \times n}$ , definido por

$$\text{perm}(A) = \sum_{\sigma \in \mathcal{S}_n} \prod_{i=1}^n a_{i, \sigma(i)}.$$

Aunque esta expresión se parece formalmente al determinante de una matriz de  $n \times n$ , carece de las cancelaciones algebraicas que vuelven a este último computable en tiempo polinomial. Valiant probó que calcular el permanente es **#P**-completo, con lo cual la teoría de conteo quedó establecida como una prolongación natural —y en muchos aspectos más dura— de la NP-completitud (Valiant, 1979).

El volumen editado por Kapron permite además recuperar otra dimensión menos divulgada pero conceptualmente central: la complejidad de pruebas. Cook y Reckhow propusieron formalizar un sistema de pruebas proposicional como una función polinomialmente computable y sobreyectiva

$$P : \Sigma^* \rightarrow \text{TAUT},$$

donde TAUT es el conjunto de tautologías proposicionales. Entonces una cadena  $\pi$  es una prueba de  $\tau$  si

$$P(\pi) = \tau.$$

La pregunta de fondo ya no es sólo si una tautología posee demostración, sino cuán corta puede ser esa demostración en un sistema dado y cómo comparar la eficiencia relativa de distintos sistemas de prueba. Con ello, la complejidad computacional se conecta directamente con la teoría de la demostración, la lógica matemática y la aritmética acotada, lo que explica por qué en la obra de Cook la complejidad no aparece como una teoría aislada, sino como un punto de convergencia entre lógica, autómatas y modelos de computación (Cook and Reckhow, 1979; Kapron, 2023).

Desde una perspectiva histórica más amplia, la complejidad computacional ha ampliado su radio de acción hacia clases probabilísticas, pruebas interactivas, teoría PCP, complejidad promedio, de randomización, complejidad algebraica, complejidad cuántica y teoría parametrizada. Sin embargo, sus preguntas rectoras siguen siendo recono-

cibles: cómo medir recursos, cómo comparar problemas, cómo demostrar límites inferiores y cómo explicar la estructura de la dificultad computacional. En ese sentido, el campo no ha abandonado su problema originario, sino que lo ha refinado y multiplicado.

La complejidad computacional puede entenderse como la teoría matemática de los recursos de la computación. Su desarrollo parte de la computabilidad de Turing, se consolida con la formalización de medidas de tiempo y espacio, alcanza un punto de inflexión con la NP-completitud de Cook y Karp, y se extiende después hacia espacio, paralelismo, circuitos, conteo y complejidad de pruebas. Su importancia reside en haber mostrado que la computación no es una capacidad homogénea, sino un territorio jerarquizado por restricciones de recursos. Gracias a ello, la pregunta “*se puede resolver?*” fue sustituida por otra más rica y más difícil: “*con qué costo estructural puede resolverse?*” (Cook, 1983; Kapron, 2023; Arora and Barak, 2009).

Los conceptos teóricos de los sistemas complejos se resumen entonces en varios pilares fundamentales que caracterizan su dinámica:

1. Emergencia: Es la aparición de propiedades en el sistema total que no poseen sus componentes por separado; es una relación no trivial entre las escalas micro y macroscópicas.
2. Autoorganización: Es el proceso dinámico mediante el cual el sistema forma estructuras o comportamientos complejos de manera espontánea a lo largo del tiempo, sin la necesidad de un controlador central o externo.
3. No linealidad: Los cambios en las salidas del sistema no son proporcionales a las entradas. Pequeñas variaciones pueden generar efectos desproporcionadamente grandes (o nulos) debido a los bucles de retroalimentación.
4. Retroalimentación (Feedback): Las interacciones son iterativas, lo que permite que los resultados de procesos previos influyan en el comportamiento futuro, permitiendo la adaptación o la estabilidad.
5. Redes de interacción: Los sistemas complejos se modelan como redes donde la información y la influencia residen en las conexiones entre los elementos más que en los elementos mismos.
6. Lejanía del equilibrio: Muchos sistemas complejos se mantienen en estados dinámicos lejos del equilibrio, lo que les permite procesar energía e información para crear orden.

A continuación, se tratarán este mismo tipo de aspectos dentro de los sistemas complejos de orientación biológica.



## Capítulo 3

# Los sistemas complejos biológicos

*Nuestro mundo está construido sobre la biología y, una vez que empezamos a entenderla, se convierte en tecnología - Ryan Bethencourt*

La visión tradicional de los sistemas complejos basados en física es un tema recurrente en la investigación científica

### 3.1. Los sistemas complejos biológicos: una alternativa plausible de modelado

Una de las limitaciones más persistentes en el estudio de la ciudad consiste en asumir que los problemas urbanos pueden ser comprendidos de manera suficiente mediante formalismos derivados de la física, particularmente aquellos orientados a describir regularidades espaciales, dinámicas de difusión, comportamientos agregados o procesos de autoorganización entendidos en términos de interacción local y formación de patrones. Sin dejar de conceder la gran importancia de dichas aproximaciones, se postula aquí, que su alcance puede resultar insuficiente en términos de modelado formal, cuando el objeto de análisis va más allá de la configuración material del sistema urbano, y se extiende a su carácter histórico, cognitivo, normativo y adaptativo, pero sobre todo, cuando se mira la componente humana y su biología como parte central de la ecuación. La ciudad como objeto de estudio es propensa a perder su equilibrio cuando se analiza materialmente; es también una organización multiescalar que conserva memoria, anticipa escenarios, reinterpreta su experiencia pasada y modifica sus trayectorias a partir de decisiones individuales y colectivas. En este sentido, los enfoques biológicos de la complejidad, y de manera particular los sistemas anticipatorios de Robert Rosen y los sistemas evolutivos de memoria (MES) de Andrée Ehresmann y Jean-Paul Vanbremeersch, ofrecen una base ontológica, epistemológica y metodológica que puede resultar más adecuada para representar problemas urbanos cuya dinámica depende de procesos de cognición, aprendizaje, jerarquización y orientación al futuro. Rosen define los sistemas anticipatorios como aquellos que contienen modelos predictivos internos de sí mismos o de su entorno y utilizan tales predicciones para el control presente (Rosen, 1958b, 2013, 2011); por su parte, la premisa de Ehresmann y Vanbremeersch es formular sistemas evolutivos jerárquicos como modelos matemáticos de sistemas

naturales, con base neuronal, y con organización interna sujetos a senescencia, múltiples niveles de complejidad y propiedades emergentes formalizables mediante la teoría de categorías (Ehresmann and Vanbreemersch, 2006; Ehresmann and Gomez-Ramirez, 2015).

La conveniencia de aproximarse con rigurosidad formal y metodológica a estos enfoques biológicos radica, en primer lugar, en que desplazan el centro explicativo de un sistema complejo, desde la causalidad puramente retrospectiva (con la consecuente respuesta eminentemente reactiva), hacia una lógica en la que el presente se encuentra modulado por futuros posibles. En los sistemas urbanos, una parte sustantiva de la conducta colectiva no se explica solamente por condiciones antecedentes, sino por expectativas, proyecciones, valoraciones preventivas e imaginarios territoriales que incorporan componentes cualitativas difícilmente medibles. La expansión urbana, la movilidad residencial, la especulación del suelo, la adopción o el rechazo de políticas públicas e incluso la apropiación diferencial del espacio dependen de representaciones anticipadas de seguridad, accesibilidad, rentabilidad, prestigio o vulnerabilidad. Desde la perspectiva de los sistemas anticipatorios, esta orientación al futuro se convierte en un rasgo estructural del sistema cuando sus operaciones presentes están mediadas por modelos internos. Esta formulación resulta particularmente aplicable para el análisis de ciudades, puesto que permite comprender como podría ser posible que la acción urbana reorganice sus estados a partir de futuros imaginados. De esta manera, la ciudad como organismo vivo podría aproximarse a un equilibrio dinámico entre un sistema físico que evoluciona desde condiciones iniciales dadas, y una organización biológica que actúa sobre sí misma mediante representaciones prospectivas.

En segundo lugar, los enfoques biológicos proporcionan un tratamiento más robusto de la memoria y de la dependencia de trayectoria. Los problemas urbanos no emergen en un vacío sin espesor temporal: están condicionados por infraestructuras en muchos casos insuficientes, y en el peor, ineficientes, desigualdades de todas las índoles, culturas organizacionales, hábitos colectivos y decisiones técnicas previas que persisten como restricciones y oportunidades para la acción presente. Aquí la propuesta de Ehresmann y Vanbreemersch resulta especialmente valiosa, porque su propia formulación se orienta a describir sistemas evolutivos cuya organización se mantiene en el tiempo aun cuando cambien sus componentes, y cuya complejidad se estructura por niveles interrelacionados. La memoria, en este contexto se vuelve una condición de posibilidad para la continuidad del sistema, para la integración de nuevas configuraciones y para la emergencia de formas de orden superior. Aplicado al dominio urbano, esto permite comprender la ciudad como una organización cambiante, pero que considera también configuraciones previas, las rearticula y las readapta en su evolución posterior. Frente a modelos basados en física que tienden a privilegiar estados, equilibrios, transiciones o distribuciones, el enfoque evolutivo de los MES, permite tematizar con mayor precisión el hecho de que la ciudad aprende históricamente, acumula restricciones y transforma su propia capacidad de respuesta en función de esa acumulación.

Una tercera ventaja se relaciona con la representación de la jerarquía y de la emergencia. La complejidad de los sistemas urbanos, está constituida por niveles de organización heterogéneos —hogares, redes, barrios, centralidades, instituciones, dispositivos normativos, plataformas tecnológicas, escalas de gobierno— cuyas relaciones no son lineales ni reducibles a una sola temporalidad. Estos modelos buscan describir precisa-

mente sistemas compuestos por niveles crecientes de organización, donde los objetos complejos se forman a partir de patrones de objetos vinculados y donde las propiedades emergentes pueden formalizarse por medio de construcciones categóricas como límites directos. La importancia de este planteamiento para la ciudad es considerable, ya que permite modelar las propiedades urbanas globales como resultados de procesos de integración estructural en los que aparecen cualidades irreductibles al nivel inferior. Esto fortalece la posibilidad de modelar fenómenos como gobernanza multinivel, resiliencia institucional, segregación, formación de centralidades o estabilización de regímenes urbanos sin reducirlos a una mecánica de partículas sociales. Así, el problema a atender, es que la ciudad está compuesta por estratos de organización que producen novedad estructural, y esa novedad requiere un lenguaje matemático más próximo al de los sistemas biológicos complejos que complementa al de los modelos físicos clásicos.

A continuación, se explican los fundamentos de la teoría de categorías, que es el medio matemático por el que dialogan ambos modelos biológicos.

### 3.2. Elementos de matemática conceptual: La teoría de categorías

La teoría de categorías se define como un lenguaje relacional para describir estructuras matemáticas, sus transformaciones y las correspondencias entre distintos dominios formales. Históricamente, surge vinculada con el trabajo de Eilenberg y Mac Lane sobre equivalencias naturales, y de Lawvere, que pero su alcance rebasa con mucho ese origen: la teoría de categorías desplaza la esencia de una estructura, desde la constitución interna de los objetos hacia la red de morfismos que los conecta, de manera que esta deja de formularse prioritariamente en términos de pertenencia y pasa a expresarse en términos de invariancia, composición y universalidad (Eilenberg and Mac Lane, 1945; Rodin, 2014; Bradley et al., 2020).

Antes de introducir los formalismos propios de la teoría de categorías, conviene contextualizarla respecto a un lenguaje matemático más familiar: la teoría de conjuntos. Desde esta última, una gran parte de la matemática puede describirse a partir de colecciones de elementos y de operaciones definidas sobre ellas. De esta forma, las estructuras matemáticas suelen concebirse como conjuntos enriquecidos con relaciones, operaciones o propiedades adicionales. Así, un grupo, un espacio topológico, un espacio vectorial o una relación de orden pueden definirse, en primera instancia, como conjuntos dotados de una organización interna (Pierce, 1988).

La teoría de categorías desplaza el punto de vista central. En lugar de tomar como noción primaria a los elementos de un conjunto, toma como punto de partida a los *objetos* y a las *flechas* o *morfismos* entre ellos. Dicho de otro modo, mientras que la teoría de conjuntos describe las estructuras desde su constitución interna, la teoría de categorías pone el acento en las relaciones estructuralmente significativas entre dichas estructuras (Pierce, 1988; Rodin, 2014). Este desplazamiento es importante porque permite estudiar, bajo un mismo lenguaje, dominios matemáticos muy distintos siempre que en ellos exista una noción razonable de transformación y composición.

Una primera forma de entender esta relación consiste en observar que la teoría de conjuntos aparece naturalmente dentro de la teoría de categorías mediante la categoría

*Set*

En ella, los objetos son conjuntos y los morfismos son funciones totales entre conjuntos:

$$f : A \rightarrow B$$

La composición de morfismos coincide con la composición usual de funciones:

$$g \circ f : A \rightarrow C, \quad \text{si } f : A \rightarrow B \text{ y } g : B \rightarrow C,$$

y para cada conjunto  $A$  existe un morfismo identidad

$$\text{id}_A : A \rightarrow A$$

que deja invariante a cada elemento de  $A$ . Así, la categoría *Set* muestra que la teoría de categorías se mantiene ligada a la matemática elemental como una generalización de la intuición de la teoría de conjuntos, y la dirige hacia un plano más abstracto y relacional (Pierce, 1988).

Desde esta perspectiva, una categoría  $C$  queda determinada por cuatro componentes básicos.

Primero, una colección de objetos, denotada por

$$\text{Ob}(C)$$

Segundo, una colección de morfismos o flechas entre objetos, donde cada flecha

$$f : X \rightarrow Y$$

tiene un dominio  $X$  y un codominio  $Y$ .

Tercero, una operación de composición que permite encadenar morfismos compatibles:

$$\circ : \text{Hom}_C(Y, Z) \times \text{Hom}_C(X, Y) \rightarrow \text{Hom}_C(X, Z)$$

Finalmente, para cada objeto  $X$  existe una flecha identidad

$$\text{id}_X : X \rightarrow X$$

Estos componentes deben satisfacer dos leyes fundamentales. La primera es la *ley asociativa*:

$$h \circ (g \circ f) = (h \circ g) \circ f,$$

para cualesquiera morfismos componibles

$$f : X \rightarrow Y, \quad g : Y \rightarrow Z, \quad h : Z \rightarrow W$$

La segunda es la *ley de identidad*:

$$f \circ \text{id}_X = f \quad \text{y} \quad \text{id}_Y \circ f = f$$

para todo morfismo

$$f : X \rightarrow Y$$

Estas dos leyes son elementales, pero de ellas depende toda la arquitectura de la teoría: garantizan que las transformaciones puedan encadenarse de manera coherente y que cada objeto disponga de una referencia interna mínima para dicha composición (Pierce, 1988; Bradley et al., 2020).

Una diferencia decisiva con el lenguaje de los conjuntos es que, en teoría de categorías el interés principal no recae necesariamente en la naturaleza interna de los objetos. Dos objetos pueden ser muy distintos en su contenido interno y, sin embargo, desempeñar un papel matemáticamente análogo si ocupan posiciones equivalentes dentro de una red de morfismos. De ahí que la teoría de categorías sea especialmente adecuada para estudiar analogías estructurales, invariantes de transformación y principios de organización comunes a dominios diversos (Rodín, 2014; Lawvere and Schanuel, 2009). En este sentido, la teoría de categorías ofrece una forma distinta de fundamentar y comparar estructuras matemáticas.

Esta ventaja es especialmente visible cuando se quiere trabajar con uniformidad y generalidad. En teoría de conjuntos, muchas construcciones se introducen caso por caso, a partir de los elementos y de las operaciones definidas sobre ellos. En teoría de categorías, en cambio, numerosas construcciones pueden caracterizarse por la forma en que se relacionan con otras mediante propiedades universales. Por ello, la pregunta deja de ser únicamente *de qué está hecho un objeto* y pasa a ser también *¿Cómo se relaciona de manera estructural con los demás?* (Lawvere and Schanuel, 2009; Pierce, 1990). Esta es una de las razones por las que la teoría de categorías ha resultado útil en lógica, topología, álgebra y ciencias de la computación.

A nivel introductorio, los elementos básicos que conviene retener son los siguientes. En primer lugar, los *objetos*, que pueden representar conjuntos, espacios, tipos, sistemas algebraicos o incluso estados abstractos de un proceso. En segundo lugar, los *morfismos*, que representan transformaciones preservadoras de estructura; en *Set* son funciones, pero en otras categorías pueden ser aplicaciones continuas, homeomorfismos, transformaciones lineales o relaciones de otro tipo. En tercer lugar, la *composición*, que expresa la posibilidad de concatenar transformaciones compatibles. En cuarto lugar, los *morfismos identidad*, que aseguran la estabilidad formal de cada objeto. Finalmente, aparecen los *diagramas*, que permiten representar configuraciones de objetos y morfismos, y cuya conmutatividad expresa la igualdad entre distintos caminos de composición:

$$g \circ f = k \circ h$$

Los diagramas conmutativos son importantes porque condensan de manera visual y precisa buena parte del razonamiento categórico (Lawvere and Schanuel, 2009; Pierce, 1990).

Los componentes de cualquier sistema natural, existen en diferentes niveles de complejidad. Un objeto puede ser en sí mismo, un sistema de sistemas, de esta manera, un objeto complejo tiene una organización interna consistente en un patrón de sus componentes elementales, con enlaces distintivos entre ellos y el objeto enlaza sus componentes a lo largo de estos enlaces, de cualquier forma, en una categoría, los objetos

mismos no tienen características distintivas y la única información que poseemos de ellas se percibe a través de sus enlaces, (figura 3.1).

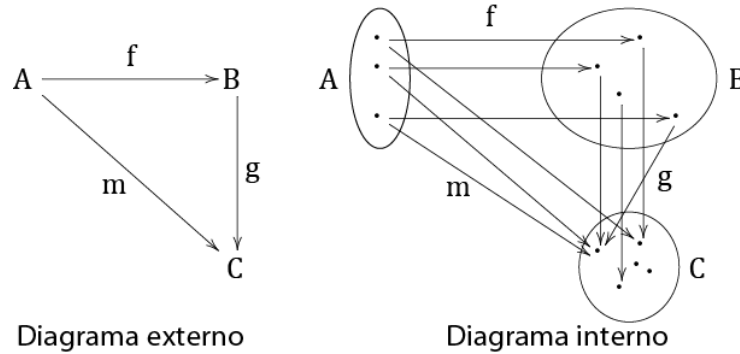


Fig. 3.1 Diagramas interno y externo de una categoría. Adaptado de Lawvere, 2003

Luego entonces, la teoría de categorías puede entenderse como una ampliación del alcance descriptivo de la teoría de conjuntos. Si la teoría de conjuntos ofrece un vocabulario para hablar de colecciones, pertenencia, funciones y operaciones, la teoría de categorías ofrece un vocabulario para hablar de estructuras, traducciones entre estructuras, compatibilidad entre transformaciones y organización global de sistemas matemáticos. Por ello, aunque es plenamente abstracta, su utilidad se manifiesta su capacidad para identificar regularidades profundas entre campos aparentemente distintos (Pierce, 1988; Rodin, 2014; Lawvere and Schanuel, 2009). Una vez asumida esta transición conceptual, resulta más claro por qué los conceptos de funtor, transformación natural, límite, colímite o adjunción son extensiones coherentes de la idea inicial de estudiar matemáticamente no solo objetos, sino también las relaciones estructurales que los constituyen.

En este sentido, una categoría

$$C = (\text{Ob}(C), \text{Hom}_C(-, -), \circ, \text{id})$$

consta de una clase de objetos  $\text{Ob}(C)$ , de conjuntos de morfismos  $\text{Hom}_C(X, Y)$  entre pares de objetos  $X, Y \in \text{Ob}(C)$ , de una ley de composición

$$\circ : \text{Hom}_C(Y, Z) \times \text{Hom}_C(X, Y) \longrightarrow \text{Hom}_C(X, Z), \quad (g, f) \longmapsto g \circ f,$$

y de morfismos identidad  $\text{id}_X : X \rightarrow X$  para todo objeto  $X$ , sujetos a los axiomas

$$h \circ (g \circ f) = (h \circ g) \circ f, \quad f \circ \text{id}_X = f = \text{id}_Y \circ f,$$

para todo  $f : X \rightarrow Y$ ,  $g : Y \rightarrow Z$  y  $h : Z \rightarrow W$  (Bradley et al., 2020; Pierce, 1988; Rydeheard and Burstall, 1988). Esta definición reitera la intuición fundamental de la teoría acerca de que lo que importa no es solo qué *es* un objeto, sino *cómo se relaciona* de manera composicional con otros objetos dentro de un sistema formal.

Sobre este primer nivel de abstracción se introduce el concepto de *funtor*, que permite traducir estructura entre categorías. Un funtor covariante

$$F : C \longrightarrow \mathcal{D}$$

asigna a cada objeto  $X \in C$  un objeto  $F(X) \in \mathcal{D}$  y a cada morfismo  $f : X \rightarrow Y$  un morfismo  $F(f) : F(X) \rightarrow F(Y)$ , preservando composición e identidades:

$$F(g \circ f) = F(g) \circ F(f), \quad F(\text{id}_X) = \text{id}_{F(X)}.$$

Con ello, el funtor formaliza la idea de una traducción estructuralmente fiel entre dominios matemáticos distintos (Bradley et al., 2020; Pierce, 1988). Este aspecto es decisivo tanto en topología como en computación, porque permite transportar propiedades, comparar representaciones y construir semánticas entre niveles distintos de descripción (Pierce, 1988; Rydeheard and Burstall, 1988).

Un tercer nivel de articulación está dado por las transformaciones naturales. Si  $F, G : C \rightarrow \mathcal{D}$  son funtores, una transformación natural

$$\eta : F \Rightarrow G$$

es una familia de morfismos

$$\eta_X : F(X) \longrightarrow G(X), \quad X \in \text{Ob}(C),$$

tal que para todo morfismo  $f : X \rightarrow Y$  en  $C$  se cumple la condición de naturalidad

$$\eta_Y \circ F(f) = G(f) \circ \eta_X.$$

Esta ecuación expresa que el paso de  $F$  a  $G$  es compatible con la estructura interna de la categoría de partida; no se trata de una colección arbitraria de flechas, sino de una comparación coherente entre dos modos de representar la misma estructura (Bradley et al., 2020; Eilenberg and Mac Lane, 1945; Lawvere and Schanuel, 2009; Ehresmann and Vanbremeersch, 2007; Gómez-Ramírez, 2014). Aquí, el lema de Yoneda sintetiza una de las intuiciones más profundas de la teoría: un objeto queda determinado por el sistema de sus relaciones con todos los demás objetos. En una de sus formas,

$$\text{Nat}(C(-, X), F) \cong F(X),$$

para todo funtor  $F : C^{op} \rightarrow \text{Set}$ , lo cual muestra que la información sobre  $X$  puede recuperarse a partir de las transformaciones naturales desde el funtor representable  $C(-, X)$  (Bradley et al., 2020).

La potencia metodológica de la teoría de categorías se vuelve todavía más visible en la noción de propiedad universal. Sea  $D : \mathcal{J} \rightarrow C$  un diagrama; entonces un cono sobre  $D$  con vértice  $X$  puede expresarse como una transformación natural

$$\lambda : \Delta_X \Rightarrow D,$$

donde  $\Delta_X : \mathcal{J} \rightarrow \mathcal{C}$  es el diagrama constante en  $X$ . Un límite de  $D$  es un objeto  $\varprojlim D$  junto con un cono universal

$$\lambda : \Delta_{\varprojlim D} \Rightarrow D$$

tal que para cualquier otro cono  $\lambda' : \Delta_{X'} \Rightarrow D$  existe un único morfismo

$$u : X' \longrightarrow \varprojlim D$$

con la propiedad

$$\lambda_j \circ u = \lambda'_j \quad \text{para todo } j \in \text{Ob}(\mathcal{J}).$$

Dualmente, un colímite de  $D$  es un objeto  $\varinjlim D$  junto con un cocono universal

$$\mu : D \Rightarrow \Delta_{\varinjlim D}$$

tal que para cualquier otro cocono  $\mu' : D \Rightarrow \Delta_{X'}$  existe un único morfismo

$$v : \varinjlim D \longrightarrow X'$$

satisfaciendo

$$v \circ \mu_j = \mu'_j \quad \text{para todo } j \in \text{Ob}(\mathcal{J}).$$

En términos conceptuales, el límite recoge una compatibilidad global de datos locales, mientras que el colímite formaliza un ensamblaje o síntesis global a partir de componentes y relaciones locales (Pierce, 1988; Rydeheard and Burstall, 1988; Bradley et al., 2020). Por eso productos, coproductos, pullbacks, pushouts, igualadores y cocigualadores, a pesar de ser intuitivamente dispersos, son casos particulares de un mismo patrón universal.

Otro núcleo de la teoría lo constituyen las adjunciones. Dados funtores

$$L : \mathcal{C} \rightleftarrows \mathcal{D} : R,$$

se dice que  $L$  es adjunto izquierdo de  $R$ , y se escribe  $L \dashv R$ , si existe un isomorfismo natural

$$\mathcal{D}(LX, Y) \cong \mathcal{C}(X, RY),$$

natural en  $X \in \mathcal{C}$  y  $Y \in \mathcal{D}$  (Bradley et al., 2020; Pierce, 1988). De modo análogo, una adjunción puede describirse mediante la unidad y la co-unidad

$$\eta : \text{Id}_{\mathcal{C}} \Rightarrow RL, \quad \varepsilon : LR \Rightarrow \text{Id}_{\mathcal{D}},$$

sujetas a las identidades triangulares

$$\varepsilon_{LX} \circ L(\eta_X) = \text{id}_{LX}, \quad R(\varepsilon_Y) \circ \eta_{RY} = \text{id}_{RY}.$$

Las adjunciones expresan un principio de traducción óptima entre contextos: una construcción libre en una categoría puede corresponder a una operación de olvido en otra. Desde un punto de vista epistemológico, esto significa que la teoría de categorías tiene

la capacidad de formalizar pasajes sistemáticos entre modos de descripción (Rodin, 2014; Bradley et al., 2020).

Estas herramientas aparecen con una doble función. Por un lado, como fundamento conceptual riguroso para topología y computación; por otro, como lenguaje de modelado para sistemas complejos, cognitivos y biológicos. En topología, la perspectiva categórica permite reinterpretar construcciones clásicas mediante propiedades universales, haciendo explícito que objetos como productos, cocientes, compactaciones o espacios funcionales se comprenden mejor por el papel relacional que desempeñan que por su simple definición extensional (Bradley et al., 2020). En computación, la teoría de categorías organiza semánticas de lenguajes, ecuaciones de dominios recursivos, tipos y construcciones algebraicas bajo un marco uniforme de composición y universalidad (Pierce, 1988; Rydeheard and Burstall, 1988). Esta capacidad de expresar uniformidad estructural explica por qué ha sido tan influyente en ciencias de la computación teórica.

Ahora bien, ahondando en la premisa de que la teoría de categorías puede operar como un lenguaje para pensar sistemas complejos cuyos niveles no son reducibles entre sí, se propone el *colímite* como herramienta para describir estructuras y su comunicación, y se sugiere que el álgebra de dílos sistemas evolutivos neuronales de memoria superior puede servir para formalizar no solo procesos, sino *procesos de procesos*, una formulación especialmente sugerente para dominios donde la organización emerge de múltiples interacciones acopladas (Brown and Porter, 2003).

Gómez-Ramírez sostiene, en una línea afín de modelado desde la neurociencia, que las propiedades universales permiten construir descripciones a la vez generales y descriptivas, y que precisamente ahí radica su valor para la modelación científica; en su propuesta, la teoría de categorías ofrece un marco para pensar representación, memoria y organización funcional en ciencia cognitiva (Gómez-Ramírez, 2014). Ehresmann y Gómez-Ramírez extienden esta intuición al problema del vínculo entre niveles neurales y niveles fenomenológicos, sugiriendo que la formalización categórica puede contribuir a describir la emergencia de procesos mentales de orden superior, e incluso creativos, a partir de dinámicas neuronales organizadas (Ehresmann and Gómez-Ramírez, 2015). Por su parte, Baianu, Brown y Glazebrook insisten en la relevancia de los colímites, biogroupoides y construcciones locales/globales para dar cuenta de niveles de emergencia, jerarquías y meta-procesos en sistemas biológicos y cognitivos de alta complejidad (Baianu et al., 2007, 2011).

Es posible determinar entonces, que la teoría de categorías formaliza con precisión tres intuiciones decisivas: primero, que una estructura se entiende por sus relaciones y no solo por sus componentes; segundo, que los cambios de escala o de dominio pueden modelarse mediante funtores y adjunciones; y tercero, que las configuraciones globales emergentes pueden expresarse mediante límites, colímites y construcciones locales/globales (Rodin, 2014; Brown and Porter, 2003; Baianu et al., 2007; Ehresmann and Vanbremeersch, 2007; Gómez-Ramírez, 2014; Lawvere and Schanuel, 2009). Por ello, más que una teoría abstracta desligada de las aplicaciones, la teoría de categorías puede leerse como una gramática matemática de la organización, particularmente adecuada para problemas donde la jerarquía, la composición, la emergencia y la articulación entre niveles micro y macro son constitutivas del fenómeno estudiado (Gómez-Ramírez, 2014; Ehresmann and Gómez-Ramírez, 2015; Baianu et al., 2011). A continuación, se

describen algunos modelos relevantes de sistemas complejos biológicos y su estructura matemática.

### 3.3. Las hiperestructuras como esquema de representación de los sistemas complejos

Puede introducirse el concepto de hiperestructura como una forma de representación de los sistemas complejos que pone el énfasis en la constitución de niveles superiores de organización a partir de “vínculos” o ensamblajes entre componentes de niveles inferiores; en este sentido, una hiperestructura describe las reglas mediante las cuales esas partes se agrupan, se estabilizan y producen nuevas totalidades con propiedades emergentes. Esta perspectiva resulta especialmente útil para la complejidad porque permite representar de manera explícita la jerarquía, el *binding* y la emergencia como procesos de integración multinivel. Su relación con la teoría de categorías aparece cuando esas totalidades de orden superior se formalizan mediante construcciones universales, en particular colímites, y cuando la dinámica del sistema se describe como una organización relacional capaz de conservar, transformar y rearticular sus propios niveles estructurales, tal como se verá más adelante en los sistemas evolutivos de memoria. Así, las hiperestructuras ofrecen una intuición general sobre cómo se forman niveles complejos de organización, mientras que la teoría de categorías proporciona el lenguaje matemático preciso para describir la coherencia, la composición y la emergencia de esas configuraciones dentro de sistemas biológicos, cognitivos y sociales. (Baas, 2009, 2006)

#### 3.3.1. Definición de Hiperestructura

Sea un conjunto de  $X_0$ , las unidades básicas, tal que, para cada subconjunto o familia de elementos tenemos:

$$S_0 \subset X_0 \quad (3.1)$$

Además, se asignan un conjunto de propiedades o estados,  $\Omega_0(S_0)$  tal que:

$$\Omega_0 : \mathcal{P}(X_0) \rightarrow Sets \quad (3.2)$$

Donde  $\mathcal{P}(X) = \{A \mid A \subset X\}$  el conjunto potencia y el conjunto “Sets”, conforman una base plausible de conjuntos. Dentro del contexto de la teoría de categorías, se consideran como una categoría de subconjuntos, que incluyen

$$\Gamma_0 = \{(S_0, \omega_0) \mid S_0 \in \mathcal{P}(X_0), \omega_0 \in \omega_0(S_0)\} \quad (3.3)$$

$$B_0 : \Gamma_0 \rightarrow Sets \quad (3.4)$$

Donde el conjunto  $X_0$  representa el sistema de agentes ( $S_0$ ).  $\Gamma_0$  representa los observables (Obs),  $B_0$  las interacciones (Int) y una elección específica de  $b_0(S_0) \in B_0(S_0)$  representa el sistema de enlace resultante que da lugar al siguiente nivel de objetos que Baas denomina en trabajos anteriores como  $R$ , como un conjunto de conjuntos, observaciones e interacciones ( $S_i, Obs, Int$ ) (Baas and Emmeche, 1997).

Luego entonces, el siguiente nivel se define como sigue:

$$X_1 = \{b_0 \mid b_0 \in B(S_0\omega_0), S_0 \in \mathcal{P}(X_0), \omega_0 \in \Omega_0 S_0\} \quad (3.5)$$

$$\begin{array}{c} X_1 \\ \downarrow \pi_0 \\ \mathcal{P}(x_0) \end{array} \quad (3.6)$$

Que es por definición, el conjunto imagen de  $B_0$ , y  $\pi_0(b_0) = S_0$ .

$X_1$  es la representación de los enlaces de las colecciones de elementos o interacciones en un contexto dinámico (Baas, 2006). No obstante, estos enlaces ligados a la colección, y que están asociados con morfismos matemáticos, están dirigidos, es decir, tienen una fuente y un objetivo. En una nueva iteración, Baas presenta una estructura adicional:

$$\Omega_1 : \mathcal{P}(X_1) \rightarrow Sets \quad (3.7)$$

En donde:

- $\Omega_1$  representa las propiedades emergentes de la estructura.
- $\Gamma_1 = \{(S_1, \omega_1) \mid S_1 \in \mathcal{P}(X_1), \omega_1 \in \Omega_1(S_1)\}$ .
- $B_1 : \Omega_1 \rightarrow Sets$ .

Luego entonces, se forma el siguiente nivel:

$$X_2 = \{b_1 \mid b_1 \in B(S_1\omega_1), S_1 \in \mathcal{P}(X_1), \omega_1 \in \Omega_1 S_1\} \quad (3.8)$$

Y su correspondiente diagrama:

$$\begin{array}{c} X_2 \\ \downarrow \pi_1 \\ \mathcal{P}(x_1) \end{array} \quad (3.9)$$

Por lo anterior, es posible construir una estructura iterativa hacia un nivel general  $N$ :

$$\begin{array}{l} \Omega_{N-1} : \mathcal{P}(X_{N-1}) \rightarrow Sets, \\ B_{N-1} : \Gamma_{N-1} \rightarrow Sets, \\ X_N = \{b_{N_1} \mid b_{N-1} \in B_{N-1}(S_{N-1}, \omega_{N-1}), S_{N-1} \in \mathcal{P}(X_{N-1}), \omega_{N-1} \in \Omega_{N-1}(S_{N-1})\} \end{array}$$

(Baas and Emmeche, 1997)

Los enlaces de orden superior establecen una extensión entre morfismos y categorías. Finalmente, sea:

$$\begin{aligned}\mathcal{X} &= \{X_0, \dots, X_N\}, \\ \Omega &= \{\Omega_0, \dots, \Omega_{N-1}\}, \\ \mathcal{B} &= \{\Omega_0, \dots, \Omega_{N-1}\}, \\ \pi &= \{\pi_0, \dots, \pi_{n-1}\},\end{aligned}$$

y el diagrama categórico:

$$\begin{array}{ccc} X_{i+1} & & (3.10) \\ \downarrow \pi_i & & \\ \mathcal{P}(x_i) & & \end{array}$$

los elementos  $\pi_i$  se convierten en la relación de correspondencia que generaliza la acción entre los mapas fuente y objetivo. El mecanismo de observaciones está implícito en los objetos  $\Omega_i$ , y para redondear la estructura categórica, se presenta también un morfismo de identidad  $I_i : X_i \rightarrow X_{i+1}$  tal que  $\pi_i \circ I_i = \text{id}$ .

En este punto, se determina la jerarquía de los enlaces dentro de las categorías, en términos de su naturaleza matemática. Baas lo determina como sigue:

- $X_0$  = Objetos como átomos, moléculas, manifolds, genes, organismos...
- Enlaces  $\sim$  relaciones, agregaciones, racimos, interacciones, procesos...
- Enlaces de enlaces  $\sim$  relaciones de relaciones, interacciones de interacciones, procesos de procesos...

Finalmente, un sistema  $\mathcal{H} = \{\mathcal{X}, \Omega, \mathcal{B}, \pi\}$  en donde los elementos se relacionan como se ha descrito anteriormente, tiene por nombre, *hiperestructura de orden n*.

Al traducir al lenguaje de las categorías, Baas hace una transición en donde  $S_0$  consiste en dos elementos ordenados  $(X, Y)$ . El conjunto de enlaces  $B_0(S_0) = B_0(X, Y)$  es el mismo que el conjunto de morfismos  $Mor(X, Y)$

De este modo, se define una categoría como una hiperestructura de orden 1, en donde:

- $X_0$  = conjunto de objetos
- $B_0(X, Y) = Mor(X, Y)$
- $X_1$  = Conjunto de morfismos

y para  $N$ -categorías se tiene la generalización:

- $X_0$  = conjunto de objetos = 0-morfismos
- $X_1$  = Conjunto de 1-morfismos  $\vdots$
- $X_N$  = Conjunto de  $N$ -morfismos

El cambio en la forma de notación se vuelve matemáticamente más natural cuando se entiende que la esencia de una categoría es

Una transición adicional importante a esta hiperestructura, se da cuando se definen estructuras gráficas para la representación de redes más complejas, como los hipergrafos.

Para estos, la estructura se define como:

$$\mathcal{H}_{grafa}(X) = \{E_0, E_1, \dots, E_N\} \quad (3.11)$$

Donde:

$$\begin{aligned} E_0 &= X(0 - \text{aristas o vértices}) \\ E_1 &\subset \mathcal{P}(X)(1 - \text{aristas}) \\ E_2 &\subset \mathcal{P}(E_1) \subset \dots \subset \mathcal{P}^2(X)(2 - \text{aristas}) \\ &\vdots \\ (E_N) &\subset \mathcal{P}(E_{N-1}) \subset \dots \subset \mathcal{P}^N(X)(N - \text{aristas}) \end{aligned}$$

este direccionamiento topológico es relevante, ya que ahora, esta estructura vuelve más identificables sus mapeos. Baas inicia con una relación ordinal como la siguiente.

$$X_1 < X_2 < \dots < X_n$$

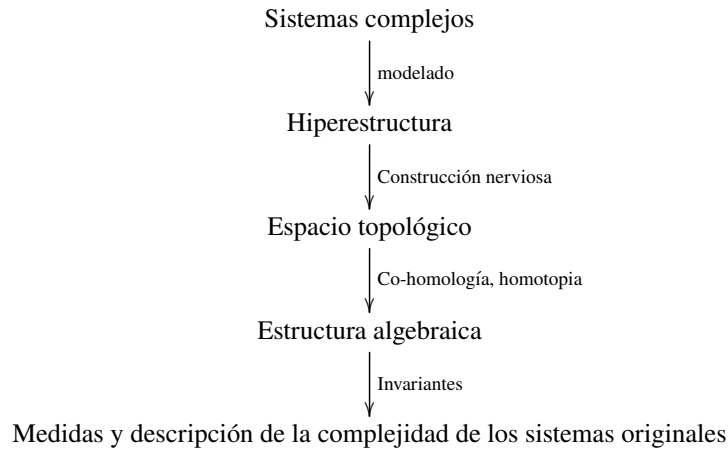
La relación de orden (<) está dada por los mapas

$$s_i : X_i \rightarrow 2^{X_{i+1}} = \mathcal{P}(X_{i+1})$$

Los enlaces están dados por los mapas  $s_i$ , y  $x_i$  es un enlace de los elementos en  $s_i(x_i)$ , que extienden la jerarquía a estados. Se asocia un espacio de estado  $S_i$  para cada  $X_i$  y requieren que los estados estén relacionados en una composición:

$$S_1 \xleftarrow{\varphi_1} S_2 \xleftarrow{\varphi_2} \dots \xleftarrow{\varphi_{n-1}} S_n \quad (3.12)$$

Esta es una representación formal que tiene como principal ventaja, poder organizar la jerarquía de subsistemas en un sistema complejo, y a su vez, identificar en un morfismo, las propiedades emergentes de la estructura.



No obstante, el gran desafío es todavía el superar el esquema de caja negra, que estos modelos producen

### 3.4. Los sistemas anticipatorios

Los sistemas anticipatorios pueden considerarse sistemas complejos biológicos porque su comportamiento está dictado por una organización interna que les permite actuar en el presente basándose en predicciones sobre el futuro. Esta es una capacidad relevante que va más allá de las explicaciones puramente materiales y mecánicas. A diferencia de los sistemas complejos basados en física, cuyos principios implican reduccionismo y un enfoque reactivo, los sistemas complejos anticipatorios admiten la posibilidad de un principio de no causalidad (Baas and Emmeche, 1997; Baas, 2006, 2013), y la reincorporación a la discusión científica, de una orientación teleológica

La premisa central de Robert Rosen define a un sistema anticipatorio como aquel que contiene un modelo predictivo interno de sí mismo y de su entorno, permitiéndole cambiar su estado presente de acuerdo con las predicciones del modelo para propósitos de control (González-Arellano, 2025; Rosen, 2011, 2013). Este enfoque introduce una ruptura con la causalidad lineal newtoniana, sugiriendo que el comportamiento actual de un sistema puede estar determinado por estados futuros percibidos o generados internamente. Durante los últimos diez años, se ha profundizado en la noción de que esta aparente violación de la causalidad es, en realidad, una ilusión generada por la capacidad del sistema para traer el futuro al presente a través de un mecanismo de control de alimentación hacia adelante o *feedforward*.

La formalización de esta teoría de sistemas complejos se apoya en la teoría de categorías, donde Rosen fue pionero al aplicarla a problemas científicos fuera de la matemática pura. La relación de los modelos establece que existe un sistema natural  $\mathcal{N}$  y un sistema formal  $\mathcal{F}$ , vinculados mediante procesos de codificación y decodificación. Cuando las inferencias en el sistema formal corresponden a la causalidad en el sistema natural, se establece una relación de modelamiento exitosa. Esto se alinea con la nece-

idad recurrente de distinguir entre *mecanismos* (sistemas simulables y algorítmicos) y *organismos* (sistemas complejos adaptativos).

Se sostiene que esta distinción es crucial para las ciencias sociales contemporáneas. Mientras que los modelos tradicionales tratan a las sociedades como máquinas reactivas que solo responden a incentivos o presiones externas, la teoría de los sistemas anticipatorios reconoce que los actores sociales actúan en función de sus expectativas y visiones del futuro. La capacidad de anticipación se convierte así en una muestra de la vida, diferenciando a los sistemas biológicos y sociales de los sistemas físicos abstractos.

A continuación, se argumenta esta relación y se detalla la aproximación científica propuesta por Robert Rosen para su estudio:

### 3.4.1. La anticipación como rasgo definitorio de lo biológico

Rosen sostiene que lo que diferencia a los seres vivos de los sistemas inorgánicos no se limita únicamente a los aspectos materiales de su estructura (como el ADN), sino su capacidad de comportarse de manera anticipada.

Un sistema anticipatorio es aquel en el que el cambio de estado presente depende de circunstancias futuras, basándose en un modelo predictivo interno de sí mismo y de su entorno.



**Fig. 3.2** El fototropismo en los girasoles es un ejemplo de sistema anticipatorio

El fototropismo (plantas que se mueven hacia la luz para asegurar humedad o seguridad futura, como puede verse en la figura 3.2), los árboles que pierden sus hojas por el cambio de duración del día (anticipando el frío antes de que llegue) y las rutas biosintéticas con activación hacia adelante son ejemplos de esta anticipación.

Ahora bien, una condición para que un sistema sea anticipatorio, es que debe ser complejo. Para Rosen, la complejidad es una propiedad de la organización interna de los sistemas:

Los sistemas simples, que Rosen denomina como *mecanismos*, son sistemas computables (en términos de máquinas de Turing) que pueden reducirse a sus partes sin pérdida de información esencial, y cuyas leyes se dividen rigurosamente entre estados y leyes dinámicas. Estos sistemas son puramente reactivos y no pueden ser anticipatorios.

En este mismo contexto, los sistemas complejos biológicos poseen modelos no formalizables (o no computables) y manifiestan *bucles cerrados de causalidad*. En estos sistemas, la causalidad relacional es más importante que la causalidad material de las partes.

La aproximación a estos sistemas requiere un cambio de paradigma, pasando de uno reactivo (causa-efecto inmediata) a uno anticipatorio. Los pilares de esta aproximación son:

En lugar de desarmar el organismo para estudiarlo (reduccionismo), esta aproximación trata la organización y la función como elementos primarios. Se enfoca en las homologías de comportamiento entre sistemas físicamente diversos. (Tabla [3.4.1](#)).

Concepto	Paradigma Reactivo (Física)	Paradigma anticipatorio (Biología)
<b>Causalidad</b>	Pasado → Presente	(Futuro modelado) → Presente
<b>Control</b>	Retroalimentación (Feedback)	Pre-activación (Feedforward)
<b>Naturaleza</b>	Máquina / Simulable	Organismo / No simulable
<b>Relación con el Tiempo</b>	Tiempo externo y absoluto	Tiempo interno y secuencial
<b>Enfoque de Modelado</b>	Analítico (reduccionista)	Relacional (organizacional)

**Tabla 3.1** Elementos comparativos entre el paradigma reactivo y el paradigma anticipatorio

La ciencia tradicional ha desestimado la *causa final* (teleología) porque asume que todos los sistemas son máquinas. Sin embargo, en sistemas complejos, es necesario y legítimo utilizar un lenguaje funcional donde un subsistema se define por lo que implica (su función) y no solo por lo que lo produce. Un sistema anticipatorio debe poseer al menos dos modelos del entorno: uno que opera en tiempo real y otro que corre más rápido que el tiempo real para calcular el futuro. Esta complejidad temporal es intrínseca a la organización biológica.

Una consecuencia crítica de esta aproximación es que los sistemas anticipatorios están sujetos a un tipo de falla global llamada *senescencia*. Esta ocurre por una discrepancia creciente entre las predicciones del modelo interno y la realidad del entorno, lo cual no se debe a una falla local de las partes, sino a la naturaleza abstracta y limitada del modelo interno.

La relación entre los sistemas complejos y la biología, bajo la perspectiva de Robert Rosen, es fundamental y constitutiva: la vida es una consecuencia de una organización compleja de carácter relacional.

La biología se relaciona con la complejidad a través de la no-computabilidad. Rosen sostiene que los organismos poseen modelos no formalizables; es decir, su comportamiento total no puede ser capturado por un algoritmo o un programa de computadora (máquina de Turing). Mientras que la física tradicional busca un modelo *más grande* (reduccionista), la complejidad biológica implica múltiples descripciones o codificaciones del sistema que son lógicamente independientes y no pueden reducirse entre sí.

Un sistema es complejo si manifiesta bucles cerrados de causalidad eficiente. En los mecanismos (sistemas simples), las categorías de causalidad aristotélica hilemórfica (material, eficiente, formal y final) están segregadas. En la biología, estas categorías se entrelazan. Rosen argumenta que un organismo es complejo porque es *cerrado* a la causalidad eficiente; por ejemplo, en sus modelos relacionales ( $M, R$ ), el metabolismo y la reparación se causan mutuamente de manera que el sistema se auto-mantiene y auto-produce (replicación).

La visión tradicional considera que la biología es un caso especial y marginal de la física. Rosen argumenta lo contrario: La física contemporánea es en realidad un caso limitado y *degenerado* que solo trata con sistemas simples (mecanismos). La biología es la ciencia más general porque estudia los sistemas complejos, los cuales son mucho más genéricos y abundantes en la naturaleza que los sistemas simples. De este modo, la biología enseña un tipo diferente de lecciones sobre la materia que la física tradicional no puede percibir.

Los sistemas complejos con enfoque biológico son adecuados para proveer un marco conceptual que explica la vida como una propiedad emergente de la organización relacional, la anticipación y la causalidad cerrada, superando las limitaciones del reduccionismo mecánico. La construcción de estructuras mediante sub-ensamblajes jerárquicos se considera altamente eficiente, especialmente en sistemas biológicos, debido a su capacidad para gestionar errores, optimizar el rendimiento y resistir interrupciones. En cualquier proceso de ensamblaje existe una probabilidad finita de error al unir dos unidades. Si se intenta construir una estructura grande (por ejemplo, de 1000 unidades) mediante la adición sucesiva de una pieza a la vez, un solo error en cualquier paso arruina todo el proceso, haciendo que la probabilidad de éxito final sea casi nula. En cambio, al construir bloques intermedios (subensamblajes), un error solo invalida el bloque pequeño en cuestión, permitiendo que el resto del material correcto se utilice en otros subensamblajes, lo que aumenta drásticamente el rendimiento final de estructuras perfectas.

Por otra parte, Rosen sostiene también que el análisis matemático de estos procesos demuestra que la estrategia más eficiente para producir la mayor cantidad de unidades correctas es utilizar una descomposición en factores primos para determinar el número de etapas y unidades por etapa. Por ejemplo, es mucho más eficiente construir una estructura de 1000 unidades en seis etapas siguiendo sus factores primos que intentar hacerlo en una sola etapa de mil unidades o en tres etapas de diez en diez. Herbert Simon plantea una metáfora pertinente sobre este punto, hablando sobre dos relojeros. Uno construye sus relojes de forma jerárquica, de modo que si es interrumpido, solo se desmorona el sub-ensamblaje en el que está trabajando actualmente. El otro ensambla pieza por pieza de forma lineal; si se interrumpe, el reloj entero se desarma hasta sus componentes más básicos. El relojero que utiliza una organización jerárquica es mucho más productivo y su trabajo es más estable frente a perturbaciones externas.

El ensamblaje jerárquico permite que la información necesaria para construir la estructura sea compacta, utilizando subrutinas anidadas en lugar de especificaciones detalladas para cada par de conexiones. Este proceso es formalmente análogo a la codificación utilizada en la teoría de la información para transmitir los sistemas evolutivos neuronales de memoria a través de canales con ruido, apoyándose en la redundancia para asegurar la fidelidad de los sistemas evolutivos neuronales de memo-

riaaje biológico. En sistemas de auto-ensamblaje activo, donde las sub-unidades tienen afinidades intrínsecas, la organización jerárquica confiere una estabilidad notable. Si una parte de la estructura se rompe, las sub-unidades pueden repararla o reconstituirla espontáneamente sin necesidad de nueva información externa, ya que las instrucciones de ensamblaje son intrínsecas a las propiedades de las partes.

la jerarquía se vuelve una estrategia de diseño óptimo que permite la emergencia de complejidad funcional minimizando el costo de los errores y las perturbaciones del entorno.

### 3.5. El marco matemático de los sistemas anticipatorios

El marco matemático propuesto por Robert Rosen para los sistemas anticipatorios y biológicos se aleja del reduccionismo tradicional (física de partículas y fuerzas) para centrarse en la organización relacional, utilizando la teoría de categorías como su lenguaje fundamental.

Su punto de partida histórico se encuentra en la tradición inaugurada por Nicolas Rashevsky, según la cual la biología no debe limitarse a describir componentes materiales, sino que debe identificar las relaciones funcionales que hacen de un agregado material un sistema organizado. Rosen radicaliza este planteamiento al sostener que, en los organismos, la clave explicativa no reside únicamente en la composición físico-química, sino en la red de dependencias funcionales que mantiene, repara y orienta al sistema como un todo (Rosen, 1958a,c, 1999, 2012).

Desde esta perspectiva, la teoría de los sistemas anticipatorios responde a un problema más amplio que el de la simple predicción. Su objetivo es mostrar que la vida no puede describirse adecuadamente si se la reduce a cadenas causales lineales del tipo estímulo-respuesta, ni tampoco si se la interpreta como un mecanismo cuyas partes agotan la explicación del todo. Rosen argumenta que los organismos exhiben una forma de causalidad organizacional en la que el mantenimiento del sistema depende de redes cerradas de producción funcional, y en la que el cambio presente puede quedar afectado por un modelo interno que representa estados ulteriores posibles (Rosen, 1985b, 1999, 2012).

Esta formulación permite además vincular la teoría anticipatoria con tres problemas clásicos de la complejidad. En primer lugar, con la *emergencia*, porque Rosen sostiene que muchas novedades observadas en sistemas complejos aparecen cuando el comportamiento efectivo del sistema bifurca respecto del comportamiento de un modelo simple que hasta cierto momento lo representaba adecuadamente; así, la emergencia es el límite de estabilidad de una relación de modelado (Rosen, 2012). En segundo lugar, con la *jerarquía*, porque un mismo sistema puede requerir distintos niveles de codificación y descripción, y porque la propia teoría distingue entre el sistema efectivo, el subsistema formal que lo modela y el subsistema dinámico sobre el cual dicho modelo actúa (Rosen, 2012, 1985b). En tercer lugar, con la *causalidad organizacional*, porque Rosen cuestiona la prohibición clásica de los bucles causales cerrados y sostiene que precisamente su ausencia caracteriza a los sistemas simples o mecánicos, mientras que su presencia es constitutiva de los sistemas complejos y vivientes (Rosen, 1985b, 1999).

Bajo esta luz, la teoría de los sistemas anticipatorios se inserta de manera natural en una discusión más amplia sobre complejidad, jerarquía y organización biológica.

Antes de introducir la anticipación propiamente dicha, Rosen necesitó construir un modelo relacional mínimo de la célula que mostrara cómo un sistema vivo puede persistir más allá de la duración funcional de sus partes. Ese modelo es el esquema metabolismo-reparación, usualmente denotado  $(M, R)$ , que constituye la antesala formal de la teoría anticipatoria (Rosen, 1972, 1985b). Su importancia radica en que desplaza la explicación biológica desde una ontología de componentes hacia una ontología de funciones: en lugar de preguntar qué sustancias componen una célula, pregunta qué transformaciones deben existir para que el sistema siga siendo capaz de producir y reproducir las funciones que lo constituyen.

### 3.5.1. El modelo de Metabolismo-Reparación

Es una herramienta relacional para caracterizar la organización mínima de una célula. Estos sistemas muestran que las funciones biológicas (como la replicación) pueden derivarse de la organización misma, independientemente de la base física. Rosen parte de una representación general de sistema de entrada-salida. En su forma más amplia, un componente puede expresarse como una aplicación

$$F : A_1 \times A_2 \times \cdots \times A_n \longrightarrow B_1 \times B_2 \times \cdots \times B_m. \quad (3.13)$$

Para el desarrollo del modelo celular, sin embargo, Rosen se concentra en componentes con una sola clase de salida, descritos por aplicaciones del tipo

$$f : A \longrightarrow B.$$

Aquí,  $A$  representa la clase de insumos que el componente puede procesar, y  $B$  la clase de productos que genera. Lo decisivo es que  $f$  no representa un objeto material particular, sino una *función organizacional* que puede ser una transformación metabólica, una operación efectiva del sistema o una capacidad de producción (Rosen, 1972, 1958a).

El problema biológico aparece de inmediato. Si toda función metabólica  $f$  posee una duración finita, entonces un sistema compuesto únicamente por transformaciones del tipo

$$A \xrightarrow{f} B$$

acabará perdiendo la capacidad que lo mantiene operativo. Para que el sistema persista, debe incluir procesos capaces de restituir la propia función metabólica. Esta exigencia conduce a un segundo nivel organizacional: el de la *reparación*. Si  $f \in H(A, B)$ , donde  $H(A, B)$  denota el conjunto de aplicaciones de  $A$  en  $B$ , entonces un reparador adecuado debe producir precisamente un elemento de  $H(A, B)$ . En la forma mínima del esquema, esto puede escribirse como

$$\Phi_f : B \longrightarrow H(A, B),$$

mientras que en la formulación más general, Rosen considera aplicaciones del tipo

$$\Phi_{f_i} : \prod C_i \longrightarrow H(A_i, B_i),$$

donde las salidas  $C_i$  del propio sistema alimentan la reconstrucción de los componentes metabólicos  $f_i$  (Rosen, 1972). El reparador, por tanto, produce una *función*. La célula deja así de aparecer como una red de reacciones y pasa a entenderse como una red de aplicaciones que producen aplicaciones.

En su expresión más compacta, el esquema metabolismo–reparación puede representarse como

$$A \xrightarrow{f} B \xrightarrow{\Phi_f} H(A, B). \quad (3.14)$$

La primera flecha representa el metabolismo; la segunda, la restauración de la capacidad metabólica perdida. Con ello, Rosen formaliza una de sus intuiciones centrales: un sistema vivo no se caracteriza sólo por transformar insumos en productos, sino por mantener activamente la posibilidad misma de seguir transformándolos (Rosen, 1972, 1985b, 1999). Este desplazamiento es fundamental para una teoría de la complejidad biológica, porque muestra que la organización del sistema no se agota en el inventario de sus partes, sino en la clausura funcional que enlaza producción y reproducción de capacidades.

Esta clausura funcional introduce una forma no trivial de dependencia causal. Los componentes metabólicos dependen de procesos de reparación, y éstos, a su vez, dependen de salidas provenientes del metabolismo. El resultado es una red de dependencias recursivas cuya estructura no puede reducirse a una causalidad lineal de parte a parte. Rosen muestra, en consecuencia, que todo sistema  $(M, R)$  contiene al menos un componente que no puede ser restaurado indefinidamente por una cadena interna de reparaciones, de modo que la autorreparación nunca equivale a una redundancia mecánica ilimitada (Rosen, 1972). Este resultado es importante porque dirige la discusión desde la mera robustez funcional hacia una arquitectura de interdependencias que la hace posible, y al mismo tiempo limita la autonomía del sistema.

Rosen agrega además una restricción temporal. Si  $M$  designa un componente metabólico y  $R$  un componente capaz de repararlo, y si el tiempo total requerido para reparación y transporte es  $T$ , entonces la pérdida temporal de  $M$  sólo deja de ser fatal si la función reparadora actúa antes de que el daño se vuelva irreversible. De manera esquemática,

$$T = \Delta_R + \Delta_{M \rightarrow R},$$

y una inhibición de  $M$  durante un tiempo  $t \geq T$  compromete irreversiblemente la continuidad funcional del sistema (Rosen, 1972). En este punto se advierte que la clausura organizacional de lo vivo no es únicamente topológica o relacional, sino también temporal: la vida exige que ciertas cadenas funcionales se cierren dentro de intervalos compatibles con la conservación del sistema.

El formalismo alcanza uno de sus puntos más profundos cuando Rosen muestra que, bajo ciertas condiciones, la propia actividad metabólica puede engendrar la función

reparadora. Sean  $X$  y  $Y$  conjuntos arbitrarios. Para cada  $x \in X$ , se define la aplicación de evaluación

$$\varepsilon_x : H(X, Y) \longrightarrow Y, \quad \varepsilon_x(g) = g(x).$$

Esta construcción induce una inmersión de  $X$  en el conjunto  $H(H(X, Y), Y)$ . Si para cierto  $x$  la aplicación  $\varepsilon_x$  resulta invertible, existe entonces una inversa

$$\varepsilon_x^{-1} : Y \longrightarrow H(X, Y).$$

Tomando ahora

$$X = B, \quad Y = H(A, B),$$

se obtiene, para ciertos  $b \in B$ , una transformación

$$\beta_b := \varepsilon_b^{-1} : H(A, B) \longrightarrow H(B, H(A, B)).$$

Si además  $b = f(a)$  para algún  $a \in A$  y se satisface

$$\Phi_f(f(a)) = f,$$

entonces se sigue que

$$\beta_b(f) = \Phi_f.$$

El sentido organizacional de esta identidad es notable: cierta salida del metabolismo puede generar la aplicación que restituye la función que la produjo. De este modo, metabolismo y reparación quedan enlazados por una clausura funcional interna que ya prefigura el tipo de circularidad causal que Rosen atribuirá a los sistemas complejos y vivientes (Rosen, 1959, 1972, 1985b). La cuestión no es aquí la circularidad lógica vacía, sino una estructura de producción funcional en la que el sistema sostiene desde dentro las condiciones de su propia actividad.

### 3.5.2. El modelo anticipatorio interno.

Sobre la base del esquema  $(M, R)$ , Rosen introduce la teoría de los sistemas anticipatorios. En su formulación clásica, un sistema anticipatorio es aquel que contiene un modelo predictivo de sí mismo y/o de su entorno, y que puede cambiar de estado en el presente de acuerdo con predicciones referidas a un instante posterior (Rosen, 2012). Esta definición es importante porque marca una ruptura con la prohibición clásica de permitir que el futuro afecte el cambio presente de estado, prohibición que Rosen identifica críticamente con el ideal de objetividad de la ciencia mecanicista (Rosen, 1999). La anticipación, en consecuencia, se incorpora como un problema formal, que es cómo describir rigurosamente un sistema cuyo presente se modula mediante un modelo interno temporalmente adelantado.

El concepto técnico que hace posible esta formulación es la *relación de modelado*. Sea  $S$  un sistema natural y  $M$  un sistema formal. Un modelo es para Rosen, una estructura formal en la que ciertas inferencias pueden interpretarse como predicciones

sobre el comportamiento de  $S$  (Rosen, 2012). Si dos sistemas naturales  $S_1$  y  $S_2$  pueden codificarse en un mismo sistema formal  $M$ , entonces existe una situación del tipo

$$S_1 \xrightarrow{E_1} M \xleftarrow{E_2} S_2.$$

En tal caso,  $S_2$  contiene un modelo de  $S_1$  en el sentido de que la relación  $E_2^{-1}E_1$  permite interpretar estados de  $S_1$  dentro de  $S_2$ . Sin embargo, esta condición es necesaria pero todavía insuficiente para hablar de anticipación (Rosen, 2012).

La primera condición adicional es que el subsistema modelizador no agote la organización total de  $S_2$ . Formalmente,

$$E_2^{-1}E_1(S_1) \neq S_2.$$

Esto significa que deben existir aspectos de  $S_2$  que no quedan absorbidos por el modelo. Si se introduce un observable adicional  $f$ , no incorporado en  $M$ , Rosen señala que la representación conjunta del sistema en términos del modelo y de ese observable no recorre todas las combinaciones imaginables entre ambos. En otras palabras, el sistema real sólo ocupa una parte de ese espacio posible, porque el modelo y los demás rasgos del sistema no varían de manera completamente independiente. Por ello, Rosen concluye que una descripción más adecuada consiste en representar a  $S_2$  como compuesto por dos partes diferenciables: una que realiza el modelo interno,  $M$ , y otra que recoge las variables no incluidas en él,  $X$ . De este modo, la representación

$$S_2 \longrightarrow M \times X$$

permite expresar con mayor claridad que el modelo interno no agota la totalidad del sistema, aunque sí forma parte de su organización efectiva (Rosen, 2012), donde  $X$  es una variedad coordinada por observables no incorporados en  $M$ , y donde la aplicación total es sobreyectiva (Rosen, 2012). Esta descomposición no sólo distingue niveles internos de organización, sino que introduce una verdadera jerarquía funcional entre el subsistema modelizador  $M$  y el subsistema dinámico  $X$  sobre el que el modelo puede actuar.

La segunda condición es que el modelo modifique efectivamente el cambio de estado presente del sistema. Aunque las coordenadas que describen  $M$  y  $X$  sean ortogonales en el nivel del estado, las tasas de cambio en  $X$  deben depender del estado actual de  $M$ .

$$\dot{x} = F(x, m), \quad x \in X, m \in M.$$

Si la dinámica de  $x$  fuera independiente de  $m$ , el modelo sería una representación pasiva; en cambio, cuando  $\dot{x}$  depende de  $m$ , el modelo se convierte en una instancia de control predictivo (Rosen, 2012). En este punto aparece con claridad la causalidad organizacional propia del sistema anticipatorio: una modulación interna del comportamiento presente por parte de una estructura formal que el sistema mismo contiene.

La tercera condición es temporal. Sea

$$T_t : S_1 \longrightarrow S_1$$

la dinámica efectiva del sistema modelado, y sea

$$\tilde{T}_{\tau(t)} : M \longrightarrow M$$

la dinámica del modelo interno. Para que  $M$  funcione como modelo predictivo de  $S_1$ , debe cumplirse la conmutatividad

$$E_1 \circ T_t = \tilde{T}_{\tau(t)} \circ E_1,$$

con una conversión temporal tal que

$$\tau(t) < t.$$

Esta desigualdad complementa con la anterior el núcleo matemático de la anticipación: el estado presente del modelo corresponde, bajo una misma referencia temporal, a un estado futuro del sistema modelado (Rosen, 2012). Por ello, cuando el sistema consulta su modelo interno, está operando con una representación formalmente adelantada respecto de la dinámica efectiva. La anticipación implica aquí una organización interna en la que el modelo discurre en una temporalidad distinta y más rápida que el proceso que representa.

Este punto permite conectar la teoría anticipatoria con el problema de la emergencia. Rosen sostiene que toda relación de modelado posee un dominio finito de estabilidad: durante cierto intervalo, el sistema complejo puede comportarse como si fuera el sistema simple que lo modela; pero cuando ese dominio se agota, el comportamiento efectivo y el del modelo bifurcan, y entonces aparecen nuevas propiedades observables que, desde la perspectiva del modelo previo, cuentan como emergentes (Rosen, 2012).

Así entendida, la *emergencia* evidencia la manifestación de que una descripción simple ha dejado de capturar el régimen organizacional dominante. La anticipación, en este marco, puede interpretarse como una estrategia interna del sistema para prolongar, reconfigurar o explotar ese dominio de estabilidad mediante modelos que corren por delante de la dinámica efectiva.

Por lo tanto, la relación entre el esquema  $(M, R)$  y el sistema anticipatorio es profunda. El primero muestra cómo un organismo mantiene y reproduce internamente las funciones que lo constituyen; el segundo muestra cómo esa organización puede incorporar un modelo interno que modula el presente en función de estados ulteriores posibles. Ambos formalismos remiten, en última instancia, a una misma intuición: que los sistemas vivos no se dejan agotar por una descripción mecanicista basada exclusivamente en partes y cadenas causales lineales, porque en ellos la organización misma desempeña un papel causal (Rosen, 1985b, 1999, 2012). Por lo tanto, la teoría de los sistemas anticipatorios amplía la biología relacional de Rosen, ofreciendo también un marco particularmente útil para pensar la complejidad biológica en términos de emergencia, jerarquía y causalidad organizacional.

### 3.6. Los sistemas evolutivos de memoria

Los sistemas evolutivos de memoria, o *Memory Evolutive Systems* (MES), fueron propuestos por Andrée Ehresmann y Jean-Paul Vanbreemeersch como un marco matemático para describir sistemas complejos cuya organización no puede entenderse ni como una simple suma de partes, ni como una máquina gobernada por un único centro de control (Ehresmann and Vanbreemeersch, 2007; Baas, 2009, 2006). La intuición de partida es relativamente simple: muchos sistemas biológicos, sociales y cognitivos sobreviven, aprenden y se reorganizan porque conservan huellas de su historia, integran esas huellas en distintos niveles y reutilizan esa experiencia acumulada para responder a situaciones nuevas. En esa medida, la memoria toma un papel preponderante como una dílos sistemas evolutivos neuronales de memoriaión organizacional del propio sistema.

Desde esta perspectiva, MES intenta responder a una pregunta central de la teoría de sistemas complejos: ¿cómo puede un sistema históricamente cambiante conservar cierta coherencia global y, al mismo tiempo, generar novedades estructurales? La respuesta de Ehresmann y Vanbreemeersch consiste en articular tres ideas en un mismo formalismo: primero, que los sistemas complejos están organizados jerárquicamente; segundo, que nuevas unidades funcionales emergen por integración de configuraciones previas; y tercero, que esa integración ocurre sobre una organización evolutiva dotada de memoria y de mecanismos distribuidos de autorregulación (Ehresmann and Vanbreemeersch, 2007; Brown, 2009). Por ello, los sistemas evolutivos de memoria pueden leerse como una teoría de la complejidad histórica que describe cómo está organizado un sistema en un instante, a la vez que representa cómo su historia de reorganizaciones modifica las condiciones mismas de su comportamiento futuro.

Los antecedentes de esta propuesta se encuentran en los *Hierarchical Evolutive Systems* desarrollados por los mismos autores a finales de la década de 1980 para enfrentar tres problemas clásicos de la complejidad: el problema del *binding*, el de la emergencia y el de la jerarquía (Ehresmann and Vanbreemeersch, 2007). El primero pregunta cómo componentes relativamente simples pueden integrarse en una totalidad que actúa como unidad; el segundo, cómo aparecen propiedades nuevas en esa totalidad; y el tercero, cómo se forman niveles cada vez más complejos de organización sin reducirse unos a otros. Este modelo amplía esa primera formulación al introducir una memoria flexible y una red de reguladores parciales que permiten explicar no sólo la integración estructural, sino también la adaptación, el aprendizaje y la reorganización continua del sistema (Ehresmann and Vanbreemeersch, 2007; Baas, 2006).

La relevancia de esta teoría para las ciencias cognitivas y, en particular, para la neurociencia, proviene de que ofrece una gramática matemática para pensar problemas que suelen aparecer dispersos entre distintos lenguajes disciplinares: la formación de objetos mentales a partir de ensamblajes neurales distribuidos, la estabilidad de la memoria semántica, la coordinación entre múltiples escalas temporales, la emergencia del sí mismo y, en general, la articulación entre procesos neurales locales y configuraciones cognitivas globales (Ehresmann and Vanbreemeersch, 2009; ?, Gómez-Ramírez, 2014; Ehresmann and Gómez-Ramírez, 2015). Así, los sistemas evolutivos de memoria buscan construir un formalismo en el que la organización, la memoria, la emergencia y la cognición puedan describirse dentro de un mismo espacio conceptual.

La estructura categórica de un sistema evolutivo.

El formalismo de MES se apoya también en la teoría de categorías. En un instante  $t$ , el sistema se representa mediante una categoría

$$K_t,$$

cuyos objetos modelan componentes del sistema y cuyos morfismos modelan interacciones, dependencias o vínculos funcionales entre esos componentes (Ehresmann and Vanbremeersch, 2007). La ventaja de esta elección es que el sistema ya no se describe como una colección estática de partes, sino como una red de relaciones composicionales. Para representar la evolución temporal, el sistema completo se modela por una familia de categorías enlazadas por funtores parciales:

$$\mathcal{K} = \left( T, \{K_t\}_{t \in T}, \{k(t, t')\}_{t \leq t'} \right),$$

donde

$$k(t, t') : K_t \longrightarrow K_{t'}$$

representa la transición entre dos configuraciones sucesivas del sistema. Estas transiciones satisfacen una condición de coherencia:

$$k(t', t'') \circ k(t, t') = k(t, t''), \quad t \leq t' \leq t'',$$

cuando la composición está definida (Ehresmann and Vanbremeersch, 2007). De este modo, el tiempo no aparece como un parámetro externo a la estructura, sino como una dilos sistemas evolutivos neuronales de memoria interna de una organización que se conserva parcialmente mientras cambia.

El problema de la *vinculación* se resuelve en este modelo, mediante el concepto categórico de *colímite*. Si  $P$  es un patrón de componentes enlazados en  $K_t$ , una nueva unidad funcional de nivel superior puede surgir como el colímite de ese patrón:

$$N \cong \text{colim}(P).$$

La idea conceptual es que  $N$  representa la forma más económica y universal en que una configuración distribuida puede actuar como un todo. Si  $(c_i : N_i \rightarrow N)$  es el cocono colimitante, entonces para cualquier otro cocono  $(f_i : N_i \rightarrow N')$  existe un único morfismo

$$f : N \longrightarrow N'$$

tal que

$$f_i = f \circ c_i.$$

Esto significa que toda manera coherente de integrar el patrón  $P$  factoriza a través de  $N$ . Por ello, el colímite se convierte en la formalización de una unidad emergente, una nueva entidad cuya función no se reduce a la simple yuxtaposición de sus componentes (Ehresmann and Vanbremeersch, 2007; Brown, 2009). En términos jerárquicos, un

sistema es complejo cuando algunos objetos de nivel superior son colímites de configuraciones de niveles inferiores, y cuando esa integración puede repetirse iterativamente para producir organizaciones cada vez más complejas.

Los sistemas evolutivos de memoria utilizan un esquema particular para identificar la emergencia dentro de la formación de una unidad jerárquica. Para evitar que el colímite se convierta en una simple abreviatura descriptiva, Ehresmann y Vanbreemeersch introducen el *principio de multiplicidad*, según el cual un objeto emergente puede admitir varias descomposiciones distintas, no equivalentes, que lo tengan como colímite (Ehresmann and Vanbreemeersch, 2007). Esta idea enlaza directamente con la noción de degeneración funcional propuesta por Edelman, y con la de *equifinalidad* de los sistemas complejos físicos, ya que una misma función o identidad de orden superior puede realizarse a través de configuraciones locales diferentes (Edelman, 1989). De ahí que la emergencia en los sistemas evolutivos de memoria se materialice con la aparición de objetos cuya identidad se mantiene a través de múltiples realizaciones posibles. Este punto es crucial para la teoría de sistemas complejos, porque permite describir robustez, plasticidad y variación estructural sin perder coherencia funcional.

El mecanismo dinámico por el cual el sistema enriquece su jerarquía recibe el nombre de *complejificación*. De manera esquemática, dada una categoría  $K$  y una estrategia  $S$  que especifica qué componentes se conservan, transforman, absorben o reorganizan, el resultado puede representarse como

$$K' = \text{Comp}_S(K).$$

La complejificación es un mecanismo que reordena la arquitectura del sistema, forma nuevas unidades colimitantes y reconfigura sus vínculos. Por ello, las sucesivas transiciones

$$K_0 \rightsquigarrow K_1 \rightsquigarrow K_2 \rightsquigarrow \dots$$

describen una historia de reorganizaciones irreductibles, en la que la trayectoria del sistema importa tanto como su estructura instantánea (Ehresmann and Vanbreemeersch, 2007; Baas et al., 2004). De este modo, los sistemas evolutivos de memoria ofrecen una formulación rigurosa de la idea de que la complejidad es inseparable de la historia interna del sistema.

### 3.6.1. Memoria y autorregulación distribuida.

Lo que distingue propiamente a un sistema evolutivo de memoria de su antecesor en los sistemas evolutivos jerárquicos, es la introducción simultánea de una memoria flexible y de una red de reguladores internos parciales, los *co-reguladores* (Ehresmann and Vanbreemeersch, 2007). Cada co-regulador opera sobre una escala temporal propia y sólo accede a una parte del sistema. No existe, por tanto, un centro único de control; la regulación es distribuida, local y multitemporal. Esta idea resulta particularmente valiosa para el estudio de sistemas complejos, porque permite representar conflictos,

asincronías, compensaciones y ajustes parciales entre distintos subsistemas sin reducir la dinámica total a un mando central.

Durante un paso temporal de un co-regulador  $CR$ , el sistema le aparece bajo la forma de un *landscape* o paisaje local  $L_t$ , que recoge sólo la porción del sistema accesible desde su punto de vista. La relación entre ese paisaje y el sistema global puede expresarse mediante un funtor parcial

$$\delta_t : L_t \longrightarrow MES,$$

que mide precisamente el carácter incompleto y perspectivo de la información disponible para el regulador (Ehresmann and Vanbremeersch, 2007, 2009). A partir de ese paisaje, el co-regulador selecciona un procedimiento, anticipa un paisaje esperado y compara después esa expectativa con el resultado efectivo. Si la discrepancia es pequeña, la regulación local se considera exitosa; si es excesiva, aparece una *fractura*, es decir, una ruptura local de coherencia que puede exigir reacomodos posteriores o resincronización con otros co-reguladores (Ehresmann and Vanbremeersch, 2007). Así, la memoria y la regulación quedan formalmente unidas: la memoria no sólo conserva el pasado, sino que participa activamente en la selección de procedimientos y en la evaluación de sus consecuencias.

En este contexto, un recuerdo se concibe como una unidad emergente integrada a partir de registros parciales. Si  $R_E$  es el patrón de perspectivas o receptores mediante los cuales un co-regulador  $E$  accede a un ítem, el registro parcial puede modelarse como

$$M_E = \text{colim}(R_E).$$

Un recuerdo más global puede surgir, a su vez, como el colímite de un patrón  $Q$  de registros parciales:

$$M = \text{colim}(Q).$$

Con esto, MES formaliza una intuición importante para las ciencias cognitivas: recordar no equivale a recuperar una copia exacta del pasado, sino a reconstituir una unidad significativa a partir de huellas distribuidas y parcialmente coordinadas (Ehresmann and Vanbremeersch, 2007).

### 3.6.2. MES, ciencias cognitivas y neurociencia: el modelo de los sistemas evolutivos neuronales de memoria.

La aplicación de esta teoría al sistema nervioso central recibe el nombre de *Memory Evolutive Neural System* (los sistemas evolutivos neuronales de memoria). En este caso, el nivel básico del sistema está constituido por neuronas y trayectorias sinápticas, mientras que las complejificaciones sucesivas generan nuevas entidades funcionales llamadas *cat-neurons* o *category-neurons*, destinadas a modelar objetos mentales de complejidad creciente (Ehresmann and Vanbremeersch, 2009; ?). Si  $P$  es un patrón sincrónico de neuronas o de cat-neuronas ya constituidas, su integración produce una nueva cat-neurona:

$$c_P = \text{colim}(P).$$

La tesis de fondo es que una unidad mental relativamente estable puede emerger de ensamblajes neurales distribuidos sin requerir una localización puntual única. Esta propuesta resulta especialmente atractiva para la neurociencia porque ofrece una formulación matemática del paso entre actividad neural distribuida y organización cognitiva de orden superior.

En este punto, los sistemas evolutivos neuronales de memoria se relacionan directamente con el problema neurocientífico del *binding*. Una asamblea sincrónica de neuronas no se interpreta sólo como una coactivación transitoria, sino como el soporte físico posible de una unidad funcional colimitante (Ehresmann and Vanbreemersch, 2007). Asimismo, el principio de multiplicidad permite representar la degeneración neural: una misma entidad mental puede corresponder a diferentes realizaciones neurales, lo que coincide con la idea de que funciones semejantes no requieren necesariamente un único sustrato microestructural (Edelman, 1989). En consecuencia, los sistemas evolutivos neuronales de memoria ofrecen un lenguaje capaz de describir simultáneamente integración, plasticidad y robustez, tres problemas fundamentales para cualquier teoría contemporánea del cerebro.

La conexión con las ciencias cognitivas se vuelve aún más clara en la formalización de la memoria semántica. Para un co-regulador  $E$ , la traza de un recuerdo  $M$ , denotada  $\text{Tr}_E(M)$ , recoge los aspectos del recuerdo reconocibles desde su perspectiva. El concepto asociado a esa clase de invariancia puede modelarse como el límite de la traza:

$$C_E^M = \varprojlim (\text{Tr}_E(M)).$$

Si este límite existe,  $M$  puede interpretarse como una instancia de ese concepto. La importancia de esta construcción es que el concepto surge como una estabilización abstracta de invariantes distribuidos a través de múltiples experiencias (Ehresmann and Vanbreemersch, 2007). Esto vuelve a a estos sistemas especialmente pertinentes para las ciencias cognitivas, porque permite describir la formación conceptual, la clasificación semántica y la generalización sin abandonar el carácter histórico y distribuido del sistema.

En animales superiores, esta dinámica culmina en la formación de una memoria semántica relativamente estable y, más allá de ella, de un *archetypal core* o núcleo arquetípico: un subsistema de registros duraderos, fuertemente interconectados y altamente significativos, que integra experiencias corporales, perceptivas, afectivas, procedimentales y semánticas (Ehresmann and Vanbreemersch, 2007, 2009). Ehresmann y Vanbreemersch lo presentan como la base formal del sí mismo (*self*), en la medida en que sobre ese núcleo pueden desplegarse procesos de retrospección, prospección y unificación de la experiencia. Se trata, por tanto, de describir una organización multiescalar capaz de integrar temporalmente experiencias significativas dentro de una memoria personal.

La relación con la neurociencia se refuerza todavía más en trabajos posteriores que conectan este formalismo con la representación hipocampal y con el problema de cómo se forman unidades espaciales y semánticas de orden superior. Gómez-Ramírez propone que las construcciones categóricas, y en particular los colímites, ofrecen una

manera rigurosa de pensar el *gluing* o ensamblaje de patrones neurales distribuidos en representaciones globales, especialmente en relación con el hipocampo (Gómez-Ramírez, 2014). A su vez, Ehresmann y Gómez-Ramírez sostienen que este enfoque permite articular procesos neurales y fenomenológicos sin reducir unos a otros, precisamente porque el formalismo categórico preserva la multiescalaridad, la emergencia y el carácter histórico del devenir cognitivo (Ehresmann and Gómez-Ramírez, 2015). En este sentido, los sistemas evolutivos neuronales de memoria se ofrecen como una propuesta para repensar la relación entre cerebro, mente y experiencia.

La aportación de los sistemas evolutivos de memoria a las ciencias cognitivas y a la neurociencia reside en ofrecer una gramática formal para describir cómo se integran ensamblajes locales en unidades globales, cómo esas unidades conservan identidad a través de realizaciones múltiples, cómo la memoria participa activamente en la adaptación del sistema y cómo pueden emerger objetos mentales y procesos semánticos a partir de redes neuronales distribuidas.

### **3.7. Propiedades complementarias entre dos enfoques de sistemas complejos**

De acuerdo con lo presentado hasta este punto, podemos identificar claramente

El recorrido desarrollado en los capítulos precedentes permite afirmar que la formalización matemática de los sistemas complejos responde a un campo de aproximaciones heterogéneas complementarias que privilegian distintos rasgos de la organización, la dinámica y la transformación de los sistemas. En particular, la comparación entre la complejidad basada en física y la complejidad basada en biología muestra que ambas comparten una preocupación común por la emergencia de propiedades globales a partir de interacciones locales, pero divergen de manera importante en la naturaleza de los sistemas que toman como referencia, en el tipo de regularidades que buscan describir y en el alcance explicativo de sus formalizaciones. Como se sintetiza en la Tabla 3.2, esta diferencia puede apreciarse con claridad al contrastar la naturaleza del sistema, el tipo de complejidad privilegiado, las herramientas principales y el grado de predictibilidad que cada enfoque suele admitir.

La tradición físico-matemática ha sido especialmente fecunda para modelar sistemas generalmente idealizados, relativamente homogéneos y, en muchos casos, cercanos al supuesto de cierre operacional. Desde esta perspectiva, la complejidad se expresa en la formación de patrones colectivos, en la aparición de estructuras emergentes, en las transiciones entre regímenes dinámicos y en la sensibilidad a condiciones iniciales o perturbaciones. Sus herramientas principales han sido la mecánica estadística, las ecuaciones diferenciales no lineales, la teoría de redes, la teoría del caos y, en general, los marcos capaces de describir la autoorganización, la estabilidad, la fluctuación y la aparición de orden macroscópico. Bajo condiciones ideales, este tipo de formalización conserva además un grado relativamente alto de predictibilidad, al menos en comparación con dominios donde la historia y la adaptación alteran continuamente el espacio de estados posible.

En contraste, la complejidad basada en biología parte de sistemas abiertos, adaptativos, evolutivos e históricamente situados, cuya organización no puede comprenderse de manera suficiente como simple resultado de interacciones físicas locales. En ellos, la fortaleza de su complejidad reside en la capacidad del sistema para conservar memoria, modificar su propia organización, integrar niveles heterogéneos, producir novedad funcional y responder de manera diferenciada a contingencias del entorno. Por ello, su formalización requiere incorporar a la ecuación, la historia, jerarquía y reorganización estructural. En este marco adquieren relevancia nociones como las hiperestructuras, los sistemas anticipativos de Rosen, los *Memory Evolutive Systems* y su proyección hacia los *Memory Evolutive Neural Systems* (MENS), todos ellos orientados a pensar cómo un sistema vivo transforma su arquitectura relacional, integra múltiples escalas y opera en función de posibilidades futuras además de condiciones presentes.

La comparación con el enfoque computacional ayuda a precisar todavía más este contraste. Mientras la complejidad computacional se concentra en la dificultad de resolver, simular o decidir formalmente ciertos problemas, por ejemplo, en términos algorítmicos, de clases de complejidad o de restricciones de cómputo, los enfoques físico y biológico se orientan más directamente a la inteligibilidad ontológica y organizacional del sistema estudiado. Dicho de otro modo, la perspectiva computacional interroga la tratabilidad formal de los problemas; la física, la emergencia de patrones y regularidades globales en sistemas idealizados; y la biología, la adaptación, la coevolución, la memoria y la historicidad de sistemas abiertos. Esta distinción, resumida también en la Tabla [3.2](#) resulta importante porque muestra que no toda complejidad remite al mismo problema: en unos casos predomina la cuestión de la predictibilidad y la simulación; en otros, la de la organización, la integración funcional y la producción de novedad.

Aun así, las similitudes entre los enfoques físico y biológico son profundas y constituyen la base de su interés conjunto. Ambos rechazan las explicaciones lineales y estrictamente reduccionistas; ambos reconocen que el comportamiento global de un sistema no puede derivarse de manera trivial a partir del análisis aislado de sus componentes; ambos requieren pensar en términos de múltiples niveles de organización, interacciones no lineales, acoplamientos entre escalas y restricciones recíprocas entre dinámicas micro y macro. En ambos casos, la complejidad aparece allí donde la arquitectura relacional del sistema importa tanto como los elementos que la componen, y donde la emergencia obliga a repensar la relación entre estructura, dinámica y función.

Sin embargo, la diferencia más importante entre ambos registros radica en el tipo de organización que cada uno toma como problema central. En la complejidad basada en física, la pregunta dominante suele ser cómo un conjunto de elementos interactuantes produce configuraciones globales estables, inestables o metaestables, y bajo qué condiciones tales configuraciones pueden describirse matemáticamente. En la complejidad basada en biología, en cambio, la cuestión decisiva es cómo un sistema logra mantener identidad a través del cambio, integrar funciones heterogéneas, aprender de su trayectoria, reorganizar sus niveles internos y anticipar cursos de acción o de evolución posibles. La primera privilegia la dinámica de estados; la segunda, la constitución histórica y jerárquica de la organización. La primera ilumina con gran potencia los mecanismos de acoplamiento, sincronización y autoorganización; la segunda extiende la formalización hacia dimensiones de memoria, representación, diferenciación funcional y anticipación.

Aspecto	Física	Computacional	Biología
<b>Naturaleza del sistema</b>	Generalmente cerrado, relativamente homogéneo e idealizado	Abstracciones formales: problemas, algoritmos, autómatas y estructuras de decisión	Abierto, adaptativo, evolutivo e históricamente situado
<b>Tipo de complejidad</b>	Emergencia física, no linealidad y formación de patrones globales	Dificultad de resolución, simulación o decisión formal	Adaptación, coevolución, memoria, organización jerárquica e historia
<b>Herramientas principales</b>	Mecánica estadística, ecuaciones diferenciales, teoría del caos y modelos de redes	Teoría de la computación, análisis algorítmico, autómatas y clases de complejidad	Redes complejas, algoritmos evolutivos, simulaciones, hiperestructuras y modelos anticipativos
<b>Grado de predictibilidad</b>	Relativamente alto en condiciones ideales o controladas	Dependiente de la clase del problema y de la tratabilidad computacional	Comparativamente bajo, debido a contingencias, adaptación y evolución histórica

**Tabla 3.2** Comparación sintética entre los enfoques físico, computacional y biológico de la complejidad. Fuente: elaboración propia.

los enfoques de sistemas complejos basados en biología resultan especialmente significativos porque destacan todas estas características en conjunto, puesto que se representan como sistemas donde la organización es capaz de plegar sobre sí misma su propia historia, generar nuevos niveles de integración y producir formas internas de mediación entre componentes heterogéneos. La noción de hiperestructura incorpora relaciones de orden superior entre relaciones, permitiendo representar sistemas cuya unidad depende de mecanismos de articulación multiescalar. Por su parte, los sistemas anticipativos introducen una ruptura decisiva con la imagen puramente reactiva del sistema, al subrayar que ciertos sistemas vivos actúan en función de sus registros de estado actuales, pero también en relación con sus propios modelos internos, expectativas, restricciones proyectadas o futuros posibles. Finalmente, los sistemas evolutivos de memoria y, de forma más específica, su vertiente neuronal, ofrecen un marco capaz de enlazar memoria, evolución, emergencia jerárquica y diferenciación funcional, abriendo una vía formal especialmente sugerente para abordar fenómenos cognitivos y neurales.

En otras palabras, el verdadero déficit de muchos modelos físicos sería más ontológico que matemático, ya que se presupone un tipo de sistema menos rico que aquel que efectivamente caracteriza a lo urbano.

El siguiente capítulo se ocupará de explorar ese punto de convergencia. Las ciencias cognitivas y la neurociencia constituyen el terreno donde la complejidad se convierte

también en un problema de representación, integración, memoria y anticipación. Allí, las preguntas por el *binding*, la emergencia y la jerarquía reaparecen bajo una nueva forma: cómo múltiples procesos distribuidos llegan a constituir experiencias unificadas, cómo emergen funciones cognitivas de redes neurales heterogéneas y cómo se articulan entre sí los distintos niveles de organización del sistema nervioso central.

Finalmente, podemos comprobar que los modelos tanto en su origen como en su destino, integran una componente cognitiva importante. A continuación explicaremos la manera en la que las ciencias cognitivas y particularmente, la neurociencia se han incorporado en el estudio formal de las ciudades, y cómo funciona su modelado.

## **Parte II**

# **Las Ciencias Cognitivas para una visión integradora de las ciudades como sistemas complejos**

Use the template *part.tex* together with the document class `S\mono` (monograph-type books) or `S\mult` (edited books) to style your part title page and, if desired, a short introductory text (maximum one page) on its verso page.

## Capítulo 4

# La ciencia cognitiva como dimensión complementaria en la construcción de la ciudad

*El cerebro humano tiene 100 billones de neuronas, cada una conectada a otras 10 mil neuronas. Sobre tus hombros está el objeto más complicado del universo conocido - Michio Kaku.*

La palabra inteligencia proviene de los términos latinos *inter-legere*, que significa *leer entre líneas* o *escoger entre opciones*. En esencia, la inteligencia es la capacidad de comprender y resolver problemas con un nivel variable de información. Podemos vernos obstaculizados para tomar una decisión o resolver una tarea a causa del ruido en el ambiente, o evaluar apropiadamente las opciones, resolver conflictos entre estímulos y tomar acciones concretas. Por otro lado, cognición proviene de *com-gnoscere*, que significa “conocer en conjunto”. Se refiere al acto de adquirir conocimiento a través de nuestras facultades mentales. Estas facultades obedecen a un espectro modular más amplio, que abarca la inteligencia, pero que además, incorpora la planeación, el razonamiento, la memoria de largo y corto plazo, la percepción, la atención, la motivación e incluso, factores emocionales para lograr, no solo capacidad de elección, sino discernimiento efectivo y obtención de conocimiento.

Estos conceptos son relevantes aquí, porque es posible extrapolar estas categorías en las formas que se verifica la inteligencia, tanto en los agentes artificiales, más orientados hacia el primer término, como en la inteligencia humana, más cercana al segundo concepto.

Pero entonces ¿En qué difieren ambas inteligencias? Hay una idea, proveniente de John Guttag que coloca sobre la mesa el estatus real actual de los agentes computacionales *inteligentes*, tanto de sus capacidades explícitas, como de sus limitaciones intrínsecas:

Una computadora puede hacer dos cosas, y solo dos cosas: realizar cálculos y recordar el resultado de estos cálculos, pero hace estas dos cosas extremadamente bien...

Los agentes computacionales inteligentes tienen una capacidad de cálculo y memoria infinitamente superior a la del ser humano; sin embargo, nosotros podemos responder a ellos con juicios contextuales integrales, pensamiento lateral, evaluación intuitiva de posibilidades y muchas otras cosas. Los parámetros de comparación y diferenciación son numerosos; Sin embargo, me centraré en tres aspectos relevantes antes de aterrizar estas ideas sobre las ciudades: La creatividad, el aprendizaje y el conocimiento.

De acuerdo con Margaret Boden, quien ha tratado ampliamente el tema de la creatividad y de la inteligencia artificial, existen tres tipos de creatividad: combinatoria, exploratoria y transformacional. La inteligencia humana es capaz de generar ideas

originales, combinar conceptos y de exhibir comportamientos fuera de lo establecido (Pensamiento lateral). La inteligencia artificial destaca ampliamente en términos de la creatividad combinatoria y exploratoria y puede producir combinaciones nuevas, pero siempre dentro de patrones ya existentes, ya que las salidas que produce, se obtienen principalmente por métodos de combinatoria matemática, o, por dar otro ejemplo, de cruces y mutaciones propias de algoritmos genéticos; no obstante, está confinada a los numerosos casos posibles, pero no es capaz de proponer soluciones que requieran pensamiento “out of the box” y es imposible hasta este momento, que pueda alcanzar la creatividad transformacional.

El aprendizaje humano está mediado por las experiencias, por el contexto sociocultural, y biológicamente, por la integración de diferentes modalidades sensoriomotoras que refuerzan la adquisición y asimilación de nuevos conceptos que se convierten progresivamente en conocimiento. Hay personas que aprenden mejor viendo, otras escuchando, y otras incluso, tocando. De igual forma, la motivación y la atención son funciones cognitivas que juegan un papel importante en este. En el caso de los agentes artificiales inteligentes, el concepto de aprendizaje busca reconocer patrones a través del entrenamiento conducido o autónomo, (Existe el aprendizaje supervisado, y el aprendizaje no supervisado) en donde las decisiones generadas obedecen principalmente a criterios estadísticos y de probabilidad sobre una base de conocimiento predefinida.

El conocimiento se puede tomar como el conjunto integral de recursos adaptativos a los que recurrimos para resolver un problema o realizar una tarea. Es algo que permanece disponible, se transforma y se adapta contextualmente y no se limita a nuestra enciclopedia mental, es decir nuestro bagaje de experiencias, recuerdos, sino a cómo utilizamos el juicio y el discernimiento para abordar distintas situaciones. En términos de capacidad, un modelo artificial inteligente como un LLM utilizan enormes cantidades de datos para dar respuestas consistentes- un transformador convierte una instrucción en una respuesta congruente mediante redes neuronales que procesan secuencias de datos, es preentrenado porque ya cuenta con el procesamiento de miles de datos, y es generativo porque está en capacidad de dar respuestas “nuevas”, generativamente hablando.

Cuando tomamos estos conceptos para definir los términos aplicables a las ciudades, podemos darnos cuenta que el concepto en inglés, “smart” en smart cities, corresponde funcionalmente, a la idea de inteligencia como capacidad de elección, e intelligent responde más a la concepto de una cognición integral. con base en lo explicado anteriormente, ésta sería la base, desde un estudio de los términos, para lograr un desplazamiento de las smart cities a las cognitive cities.

Ahora bien, la ciencia cognitiva aloja en su dominio, a la psicología, la filosofía, la inteligencia artificial, la neurociencia, la lingüística y la antropología. Todos estos campos de conocimiento han tenido, de forma individual o colectiva, una relación epistemológica con el estudio de las ciudades, para impulsar su desarrollo entre ellas mismas. Las ciencias computacionales ya han demostrado el aprovechamiento de las instancias de la neurociencia para la presentación de sus modelos. Como dos ejemplos fundamentales, tenemos la representación de los potenciales de acción químicos de sodio (Na) y potasio (K) en el fascinante modelo de Hodgkin-Huxley;

$$\begin{aligned}
I_{Na} &= \bar{g}_{Na} m^3 h (V - E_{Na}) \\
I_K &= \bar{g}_K n^4 (V - E_K) \\
I_L &= \bar{g}_L (V - E_L)
\end{aligned}$$

Que conducen a la ecuación:

$$C_m \frac{dV}{dt} = I_{\text{ext}} - I_{Na} - I_K - I_L$$

y por otra parte, el modelo de neurona de McCullough-Pitts cuya expresión fue la base para el desarrollo de las redes neuronales computacionales.

$$y(t+1) = \begin{cases} 1, & \text{si } \sum_{i=1}^n x_i(t) \geq \theta \text{ y } z_j(t) = 0 \forall j \\ 0, & \text{en otro caso} \end{cases}$$

donde  $x_i(t)$  son entradas excitatorias binarias y  $z_j(t)$  representan entradas inhibitorias.

A pesar de su naturaleza mecanicista, su contribución al campo ha sido de importancia trascendental. El punto aquí es que, de acuerdo con lo visto anteriormente en este libro, es posible encontrar intuitivamente, un grupo robusto de conexiones entre los sistemas complejos, tanto físicos como biológicos, que posibilitan escenarios para postular modelos integrados que expliquen fenómenos urbanos complejos, ya sea analítica o computacionalmente, o bien, como una combinación de ambos. El propósito es señalar que la oportunidad d

continuando con las aproximaciones individuales de las áreas bajo el término de ciencia cognitiva en los estudios de la ciudad, primero se discute sobre las aproximaciones que desde la arquitectura y el urbanismo se han efectuado hacia la neurociencia. A continuación se expondrán conceptos generales sobre estas subdisciplinas, sus ventajas y desventajas, para luego plantear otras aproximaciones más generales de la ciencia cognitiva y cómo pueden incorporarse dentro del contexto de la ciencia de la ciudad.

## 4.1. El dilema de los neoros: neuroarquitectura y neurourbanismo

La neuroarquitectura es un campo interdisciplinario que surge de la integración de la neurociencia, la arquitectura, la psicología y la fisiología. Se define como el estudio de cómo el entorno construido, sus características de diseño, organización espacial y estímulos sensoriales, impactan directamente en los mecanismos cerebrales, el comportamiento y el bienestar físico y mental de sus ocupantes (de Paiva, 2018; Assem et al., 2023; de Paiva and Jedon, 2019). Su origen formal se remonta a 2003 con la fundación de la Academia de Neurociencia para la Arquitectura (ANFA) en San Diego. (Attaianesi et al., 2025)

El propósito fundamental de esta subdisciplina es transitar de un diseño basado puramente en la intuición hacia uno fundamentado en evidencia científica para mejorar la

calidad de vida de los usuarios (Ritchie, 2021; Maleki and Bayzidi, 2017). Sus objetivos principales incluyen la creación de espacios saludables y significativos, el diseño de entornos que promuevan la salud emocional y física, optimizando la experiencia humana en el espacio; utilizar el conocimiento sobre el cerebro para diseñar escuelas que mejoren el aprendizaje y la memoria, hospitales que aceleren la recuperación de los pacientes y oficinas que fomenten la colaboración y la creatividad. Existe también una preocupación por reducir el estrés ambiental, identificando qué cualidades espaciales (como la iluminación, el color o la acústica) contribuyen a disminuir la ansiedad y mejorar el estado de ánimo. Por último, se abre un campo de estudio para la investigación sobre cómo los sentidos y el sistema nervioso interactúan con los espacios para generar respuestas afectivas y cognitivas (Assem et al., 2023; de Paiva, 2018; de Paiva and Jedon, 2019; Metzger, 2018).

La neuroarquitectura emplea una metodología experimental y científica para medir las reacciones humanas ante los estímulos del entorno, superando las limitaciones de las encuestas subjetivas de opinión.

A nivel experimental, se utilizan herramientas como la resonancia magnética funcional (fMRI) para mapear áreas cerebrales activadas por el diseño, Resonancia Magnética Funcional (fMRI): Se utiliza para mapear la activación cerebral mediante el seguimiento de los niveles de oxigenación en la sangre (señales BOLD), permitiendo identificar qué áreas del cerebro se activan ante espacios agradables o desagradables. Es especialmente útil por su alta resolución espacial, permitiendo localizar circuitos cerebrales complejos involucrados en tareas de neuroarquitectura. la electroencefalografía (EEG) para registrar la actividad eléctrica cerebral en tiempo real y la espectroscopía funcional de infrarrojo cercano (fNIRS) para monitorear la oxigenación sanguínea neuronal.

Se busca también, reportar resultados a partir de recursos de monitoreo fisiológico: Registro de respuestas del sistema nervioso autónomo, como la variabilidad del ritmo cardíaco, la conductancia de la piel (sudoración) y el seguimiento ocular (eye tracking) para determinar qué elementos visuales captan la atención o generan interés. La realidad virtual (VR) permite crear entornos inmersivos y controlados de laboratorio donde los investigadores pueden modificar variables aisladas (como la altura del techo o el color de las paredes) y medir las reacciones de los sujetos de manera precisa antes de que los edificios sean construidos. (Chiamulera et al., 2017; Rad et al., 2021; Assem et al., 2023; de Paiva, 2018) utilizando también, modelos cíclicos de interacción. El proceso se entiende como un bucle continuo donde la arquitectura actúa como un estímulo que genera respuestas emocionales y cognitivas, las cuales pueden incluso provocar cambios neurológicos permanentes a través de la neuroplasticidad.

Este enfoque permite a los arquitectos programar el impacto deseado en el cerebro del usuario, convirtiendo los edificios en agentes activos para promover el bienestar. En la tabla 4.1 se presentan sintéticamente, los métodos experimentales más utilizados.

#### 4.1.1. Modelos Teóricos de la neuroarquitectura

La neuroarquitectura se apoya de diferentes modelos teóricos (Attaianese et al., 2025; Rad et al., 2021; Assem et al., 2023). Ejemplificando algunos casos, encontramos el

Categoría	Técnica / herramienta	Descripción y aplicación
Neuroimagen y registro cerebral	EEG	Registra actividad eléctrica cerebral en tiempo real con alta resolución temporal; su portabilidad favorece estudios en movimiento y en entornos urbanos.
Neuroimagen y registro cerebral	fNIRS	Detecta cambios en la oxigenación cortical asociados con la actividad neuronal mediante una técnica óptica no invasiva.
Neuroimagen y registro cerebral	MEG	Mide campos magnéticos derivados de la actividad cerebral y permite explorar procesos cognitivos complejos, incluida la cognición espacial.
Neuroimagen y registro cerebral	PET	Visualiza la respuesta cerebral a estímulos ambientales y permite estimar características funcionales del tejido cerebral.
Monitoreo fisiológico y conductual	Eye Tracking	Registra movimientos oculares, atención visual y dilatación pupilar para identificar interés, carga cognitiva y estrés.
Monitoreo fisiológico y conductual	GSR/EDA	Mide la conductancia de la piel como indicador de activación fisiológica y respuesta emocional.
Monitoreo fisiológico y conductual	HRV	Se utiliza para estimar estados de estrés, activación y relajación vinculados al entorno.
Monitoreo fisiológico y conductual	Facial Coding y EMG	Analizan expresiones y actividad muscular facial para inferir respuestas emocionales no verbalizadas.
Metodologías experimentales	VR e IVE	Generan simulaciones inmersivas y controladas para evaluar el efecto de variables de diseño antes de la construcción.
Metodologías experimentales	EBD	Sustenta las decisiones de diseño en evidencia empírica obtenida mediante evaluaciones y análisis espaciales.

**Tabla 4.1** Síntesis de técnicas y metodologías para el estudio de la relación entre espacio construido, cognición y respuesta biopsicológica.

modelo Cíclico de la Neuroarquitectura, que propone una interacción continua donde la arquitectura actúa como estímulo que genera respuestas emocionales y cognitivas, las cuales pueden incluso provocar cambios neurológicos a largo plazo mediante la neuroplasticidad. La simulación Encarnada (Embodied Simulation) se basa en el sistema de neuronas espejo, este modelo sugiere que los humanos simulan internamente las formas, materiales y espacios arquitectónicos a través de su cuerpo y sus sentidos. Se utilizan modelos de la psicología ambiental como el de Placer-Activación (Arousal) de Mehrabian y Russell para dimensionar las reacciones afectivas a los espacios. Una aproximación interesante es la Neurofenomenología, que es un programa de investigación que combina la neurociencia con la fenomenología para estudiar la experiencia consciente y la mente como una experiencia encarnada en el espacio vivido.

El Diseño Centrado en el Cerebro (Brain-centric Design o BcD) y la neuroarquitectura son disciplinas distintas pero profundamente interconectadas, ya que ambas utilizan la neurociencia como base fundamental para optimizar la experiencia humana, aunque se aplican a diferentes áreas: la primera al aprendizaje y la comunicación, y la segunda al espacio físico. Ambas disciplinas buscan transitar de un enfoque basado en la intuición hacia uno fundamentado en la evidencia científica. Su objetivo compartido es mejorar el bienestar, el rendimiento y la salud de las personas, comprendiendo cómo reacciona el sistema nervioso ante estímulos específicos. La relación es más evidente en el diseño de escuelas y centros de capacitación: La Neuroarquitectura se encarga del continente: investiga cómo variables físicas (como la luz natural, la altura de los techos o los colores fríos) pueden hacer que áreas del cerebro sean más receptivas al aprendizaje. El Brain-centric Design se encarga del contenido y el proceso: es un marco pedagógico que estructura la presentación de la información para que el cerebro la acepte y retenga mejor, utilizando modelos como el *Challenge Wheel*. Esto sugiere que el Diseño Centrado en el Cerebro requiere de una arquitectura que no sea neutral, sino que actúe como un agente activo que apoye los procesos cognitivos.

Ahora bien, mientras que la neuroarquitectura manipula el espacio físico (geometría, materiales, iluminación) para influir en el estado mental, el BcD manipula los procesos

de pensamiento y la interacción social (mediante la reflexión y el intercambio de ideas) para fortalecer las redes neuronales y la neuroplasticidad. Ambas reconocen que el cerebro está en constante interacción con su entorno y que esta relación determina el comportamiento humano.

la neuroarquitectura crea el escenario físico óptimo para que el cerebro prospere, mientras que el Diseño Centrado en el Cerebro proporciona la metodología de interacción y aprendizaje que aprovecha al máximo ese potencial biológico. (Carr and O'Mahony, 2019; Assem et al., 2023; de Paiva and Jedon, 2019; Ritchie, 2021)

La neuroarquitectura, pese a su gran potencial para transformar el diseño, enfrenta actualmente una serie de limitaciones críticas que dificultan su consolidación y aplicación práctica generalizada. De acuerdo con diversos autores, estas limitaciones se pueden agrupar en las siguientes categorías:

### 1. Limitaciones metodológicas y experimentales

- Aislamiento de variables: Es extremadamente difícil aislar el efecto de un solo elemento sensorial (como la luz o el color) en entornos físicos reales donde una gran cantidad de variables cambian simultáneamente de forma no sistemática.
- Falta de validez ecológica: Muchos estudios se realizan en entornos de laboratorio controlados o mediante Realidad Virtual (VR), los cuales, aunque útiles, son abstracciones que no logran replicar la complejidad multisensorial de la realidad física. Las simulaciones en VR a menudo tienen limitaciones de resolución, brillo y sensación de profundidad que pueden distorsionar los resultados.
- Restricciones de las técnicas de medición: Los instrumentos como la resonancia magnética (fMRI) requieren que el sujeto permanezca inmóvil, eliminando la interacción real con el espacio. Por otro lado, las técnicas portátiles como el EEG pueden verse afectadas por ruidos ambientales y artefactos de movimiento que comprometen la calidad de los datos.
- Inconsistencia de datos: Existe una falta de procedimientos estandarizados para el análisis de datos, lo que hace difícil comparar resultados o establecer correlaciones entre distintos experimentos.

### 2. Sesgos en las muestras de población

- Falta de diversidad: La literatura actual está fuertemente sesgada hacia participantes jóvenes, sanos y occidentales, evaluando frecuentemente a grupos específicos como estudiantes universitarios.
- Omisión de grupos vulnerables: Existe una exploración insuficiente de cómo el entorno afecta a adultos mayores, personas con discapacidades o grupos con necesidades específicas, lo que limita la generalización de los hallazgos a toda la población. (Assem et al., 2023; de Paiva, 2018; Attaianesi et al., 2025)
- Tamaños de muestra reducidos: Muchos estudios son exploratorios y cuentan con pocos participantes, lo que restringe la representatividad estadística.

### 3. Desafíos Conceptuales y de Interpretación

- Reduccionismo biológico: Existe el riesgo de intentar explicar la compleja experiencia humana únicamente en términos fisiológicos, ignorando factores culturales, sociales y memorias personales que moldean la percepción individual.

- Ambigüedad en las definiciones: No existe un consenso claro sobre términos fundamentales (como *experiencia estética*), lo que provoca disparidad en los resultados de investigaciones que intentan medir las mismas reacciones cerebrales.
- Interpretación de la actividad cerebral: Dado que una misma área del cerebro puede estar involucrada en múltiples procesos, existe el riesgo de realizar inferencias inválidas al asignar una sola emoción o función a un área activada.

#### 4. Brecha entre la Ciencia y la Práctica Arquitectónica

- Criterios de diseño genéricos: Las recomendaciones derivadas de la neuroarquitectura a menudo resultan vagas, incoherentes o demasiado generales, careciendo de la especificidad necesaria para servir como guías prescriptivas para arquitectos.
- Conflicto con otros factores: Incorporar criterios neuroarquitectónicos puede ser difícil al chocar con variables como el coste, la seguridad, la estética tradicional o la eficiencia energética de un edificio.
- Altos costos: El acceso a tecnología de neuroimagen avanzada y la programación de simulaciones inmersivas representan una inversión económica y de tiempo que no siempre es asequible para las firmas de arquitectura.

Aunque la neuroarquitectura ofrece una base científica prometedora, actualmente se encuentra en una etapa formativa donde la escasez de experimentos *in situ* y la falta de una metodología común impiden que sus hallazgos se traduzcan de manera efectiva en reglas de diseño para el mundo real.

Otro factor a tener en cuenta para abordar con cuidado esta asociación entre neurociencia y la ciencia de la ciudad, es que en la última década ha podido percibirse una tendencia que ha afectado a diferentes campos de conocimiento, en donde cualquier disciplina se ha visto complementada por el prefijo *neuro-*: neuroeconomía, neurodiseño, neuromarketing, neuroeducación, neurourbanismo, neuroarquitectura. La lista puede seguir, lo importante aquí, es presentar una postura clara sobre el tema, y marcar una saludable distancia a estos, para evitar lo más posible, el fenómeno del *neurohype* (Gende and García, 2026), (Corredor and Cárdenas, 2017) y banalizar la importancia y rigurosidad de la participación de la neurociencia como una dimensión complementaria a la construcción rigurosa de modelos. El enfoque humano ayudaría a ajustar los mecanismos de resolución para una predicción más precisa.

## 4.2. La componente neurocognitiva para el diseño de la ciudad

Las ciudades hoy en día producen enormes volúmenes de datos mediante sensorizaciones, pero no siempre cuentan con sistemas capaces de transformarlos en información realmente útil para la vida cotidiana de los ciudadanos. Para los autores, una ciudad mejora cuando puede filtrar, interpretar y utilizar datos en función de contextos concretos, necesidades situadas y preferencias humanas. Esto no solo incrementa la eficiencia de los servicios urbanos, sino también la experiencia de usuario y la calidad de vida. En ese sentido, la ciudad no debe limitarse a acumular tecnología; debe aprender a organizarla alrededor de las necesidades de sus habitantes, empresas, instituciones y

demás grupos de interés. Desde esta perspectiva, una ciudad verdaderamente inteligente requiere diálogo continuo con la ciudadanía, capacidad de adaptación y aprendizaje a partir de cambios imprevistos en el entorno urbano. (D'Onofrio and Portmann, 2017), (Raimbault, 2020)

uno de los principales desafíos en la toma de decisiones urbanas es que gran parte de la información relevante es *lingüística, ambigua e imprecisa* (D'Onofrio and Portmann, 2017). Las personas no suelen hablar de la ciudad solo en términos cuantitativos; usan expresiones como *la calidad del aire es mala*, “el tráfico está insoportable” o “esta zona se siente insegura”. Este tipo de información, aunque difusa, es decisiva para gobernar una ciudad. Por eso, la computación cognitiva se presenta como una vía para que los sistemas urbanos puedan trabajar con lenguaje natural, incertidumbre y percepciones humanas. Entre las herramientas disponibles para acercarse a lograrlo están el soft computing, la lógica difusa, los conjuntos difusos, el granular computing y el enfoque de *computing with words*.

El ejemplo de la calidad del aire es particularmente ilustrativo. Evaluaciones cualitativas como *muy buena, buena, satisfactoria o mala* tienen significado para los ciudadanos, aunque no correspondan a fronteras numéricas rígidas. La lógica difusa permite traducir estas expresiones a grados de pertenencia dentro de categorías como *sin riesgo, preocupante o riesgosa*. De esta forma, una ciudad podría interpretar mejor información incompleta o ambigua y convertirla en base útil para la decisión pública. El cómputo granular complementa este enfoque al permitir organizar la información en distintos niveles de detalle, reduciendo la complejidad y haciéndola más comprensible. Finalmente, el *computing with words* posibilita procesar argumentos expresados en lenguaje natural mediante reglas del tipo “si la calidad del aire es buena, entonces el nivel de contaminantes es bajo”. La relevancia de este planteamiento es enorme: el artículo sugiere que una ciudad inteligente del futuro debe ser capaz no solo de medir, sino de comprender, clasificar e interpretar la forma en que los ciudadanos hablan y perciben su entorno.

Destacan aquí, tres enfoques conceptuales que amplían la dimensión cognitiva del problema. El conectivismo subraya que el conocimiento está distribuido en redes y que aprender implica integrar las experiencias y percepciones de otros; esto refuerza la idea de que la toma de decisiones urbanas debe estar abierta a una comunicación entre expertos técnicos, y otros múltiples actores. El pensamiento computacional permite descomponer problemas complejos, abstraerlos y automatizar partes de su tratamiento. Y el *intelligence amplification loop* propone una interacción continua entre seres humanos y sistemas, de modo que ambos aprendan mediante retroalimentación mutua. En conjunto, estas ideas permiten entender la computación cognitiva no como una automatización cerrada, sino como una inteligencia ampliada que emerge del intercambio entre tecnología, instituciones y ciudadanía.

Una ciudad inteligente conecta datos y servicios; una ciudad cognitiva agrega la capacidad de interpretar lenguaje natural, aprender del comportamiento pasado de los usuarios, detectar cambios en sus patrones y reaccionar ante ellos. Para esta evolución, el artículo identifica cinco condiciones estratégicas: visión compartida, organización, compromiso de los grupos de interés, finanzas y tecnología. A ello suma una reflexión muy sugerente desde el diseño ontológico: todo lo que la ciudad diseña termina también moldeando a sus ciudadanos. La infraestructura, las plataformas y los sistemas urbanos

no solo resuelven problemas, sino que reconfiguran hábitos, percepciones y formas de vida. Así, la ciudad cognitiva aparece como una ciudad más sensible, atenta y adaptativa, capaz de responder mejor a las necesidades cambiantes de sus habitantes.

El cómputo cognitivo puede fortalecer la sostenibilidad, la satisfacción ciudadana y hasta el equilibrio entre vida personal y trabajo, al hacer más eficientes y realistas los procesos urbanos. Sin embargo, es patente la necesidad de incorporar la dimensión de las emociones en la relación entre personas y sistemas; por otro, la urgencia de atender la ciberseguridad, pues ninguna infraestructura inteligente está exenta de vulnerabilidades.

#### 4.2.1. Arquitecturas cognitivas: una alternativa de IA con base en neurociencias

En términos generales, la neuroarquitectura y el neurourbanismo se apoyan de la neurociencia para contar con una retroalimentación que les permita mejorar sus objetos y procesos en pos del bienestar del usuario. Sin embargo, es necesario profundizar más en la construcción transdisciplinar de esta vinculación con la ciencia de la ciudad, y es en la inteligencia artificial donde existe un área de oportunidad para lograrlo efectivamente.

La inteligencia artificial, de acuerdo con las definiciones que la NASA proporciona (May, 2024), se compone de:

- Cualquier sistema artificial que desempeña tareas bajo circunstancias variantes e impredecibles sin supervisión humana significativa, o que puede aprender de la experiencia y mejorar el desempeño cuando se expone a conjuntos de datos.
- Sistemas artificiales desarrollado por software, hardware físico o cualquier otro contexto que resuelve tareas que requieren percepción, cognición, planeación, aprendizaje, comunicación o acción física parecida a la del ser humano.
- Un sistema artificial diseñado para pensar o actuar como ser humano, incluyendo arquitecturas cognitivas y redes neuronales.
- Un conjunto de técnicas, incluyendo el *machine learning*, que está diseñado para aproximar una tarea cognitiva.
- Un sistema artificial diseñado para actuar racionalmente, incluyendo agentes de software inteligentes, o embodied robots, que alcanzan metas usando percepción, planeación, razonamiento, aprendizaje, comunicación, toma de decisiones y actuación.

De estas definiciones, destacan para nuestro interés, las que se remiten a aquellos sistemas que tienen por objetivo, el pensar o comportarse de forma similar a un ser humano. Dentro del contexto de la inteligencia artificial, hay dos grandes aproximaciones. La primera se conoce como *Narrow Artificial Intelligence* o inteligencia artificial estrecha, en donde el *machine learning* se ha ganado el lugar de máximo exponente. Este tipo de IA se entrena para realizar una tarea específica, o un conjunto limitado de funciones de forma muy eficiente. Por otra parte, la *General Artificial Intelligence* o inteligencia artificial general, en desarrollo y de corte más teórico, tiene la posibilidad de ejecutar múltiples tarea, y posee la capacidad de entender, aprender y aplicar conocimiento para

resolver problemas con una inteligencia similar a la humana. En este último campo, se encuentran las arquitecturas cognitivas, que dependiendo de su origen, modelan las funciones ejecutivas del ser humano como la memoria, la planeación y el razonamiento, considerando un sistema de múltiples agentes distribuidos.

Las arquitecturas cognitivas han sido relevantes precisamente porque permiten desplazar la discusión desde una inteligencia artificial concebida como una colección de técnicas aisladas hacia una inteligencia artificial entendida como organización funcional. Dicho de otro modo, una arquitectura cognitiva es un marco de integración para funciones tales como memoria, atención, percepción, planeación, decisión y aprendizaje, orientado a producir comportamiento coherente bajo restricciones contextuales (Jiménez et al., 2021; Vargas et al., 2021). Por ello, su interés reside también en su capacidad para articular conocimiento procedente de la psicología, la neurociencia, la filosofía de la mente y las ciencias computacionales en una sola estructura de modelado.

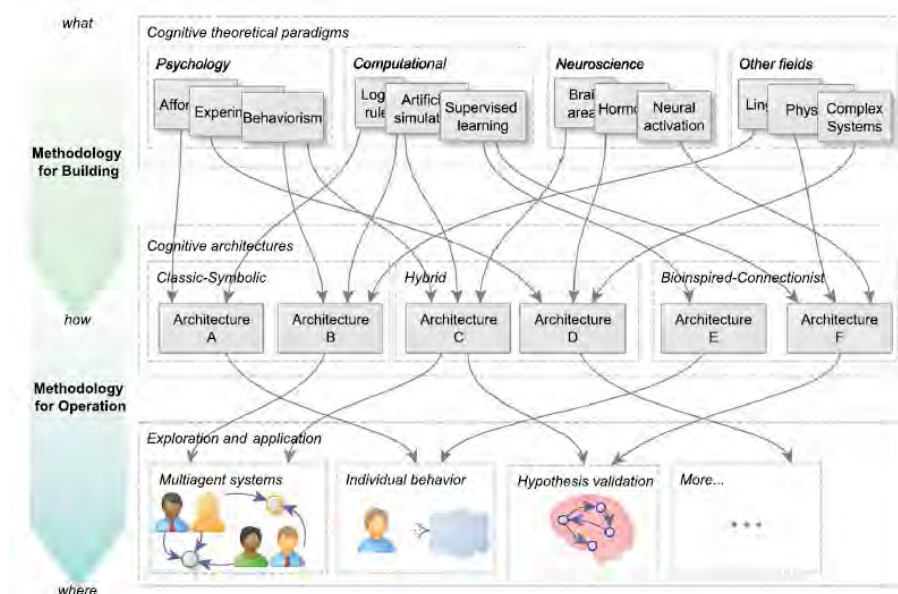
Esta caracterización permite distinguir a las arquitecturas cognitivas de otras vertientes de la inteligencia artificial. Mientras una parte importante de la IA contemporánea ha privilegiado clasificadores, sistemas estadísticos, aprendizaje profundo, minería de datos o, más recientemente, el procesamiento de lenguaje natural, con los grandes modelos de lenguaje (LLM's) desprendiéndose de este, las arquitecturas cognitivas se han ocupado de un problema diferente, que es cómo organizar de manera explícita los procesos que transforman información en conducta inteligible. Tal como se mencionó antes, la IA estrecha suele resolver tareas concretas con gran eficacia, pero con frecuencia deja subespecificado el modo en que múltiples funciones interactúan entre sí para dar lugar a una dinámica cognitiva relativamente estable (Jiménez et al., 2021). Por el contrario, una arquitectura cognitiva pretende hacer visible esa interacción. Por ello resulta especialmente pertinente en escenarios donde no basta con reconocer patrones, sino que se requiere mantener objetivos, priorizar estímulos, filtrar distractores, coordinar módulos y actualizar estados internos de acuerdo con las exigencias del entorno.

Las características más importantes de una arquitectura cognitiva pueden resumirse en cinco rasgos conceptuales. El primero es que es *multinivel*: una arquitectura de este tipo trabaja en múltiples escalas explicativas, que enlazan niveles neurobiológicos, funcionales, conductuales y computacionales. El segundo es que es *modular*, ya que las funciones cognitivas se descomponen en módulos relativamente diferenciables, pero que son interdependientes. El tercero es la *conurrencia*, puesto varios procesos pueden operar al mismo tiempo, intercambiando información y modulándose mutuamente. El cuarto es la *capacidad de integración*. es importante que la arquitectura debe poder incorporar nuevas funciones sin perder coherencia. El quinto es su *orientación representacional* además de operar, debe ofrecer una descripción explícita de cómo circula, se transforma y se organiza la información en el sistema (Jiménez et al., 2021). En este sentido, una arquitectura cognitiva ejecuta y también formaliza, y precisamente por ello se vuelve útil para el estudio de sistemas complejos.

Para construir la propuesta metodológica que se presenta aquí, fue necesario distinguir entre dos niveles que con frecuencia se confunden: el nivel de construcción y el nivel de operación de la arquitectura (Jiménez et al., 2021), como puede verse en la figura 4.1. El primero corresponde a las decisiones de alto nivel que definen el alcance del sistema, su paradigma teórico, las funciones que serán modeladas, el lenguaje de representación y los criterios de validación. El segundo corresponde a la manera en que

esas decisiones se traducen en ciclos cognitivos, módulos, flujos de datos, componentes ejecutables y pruebas concretas.

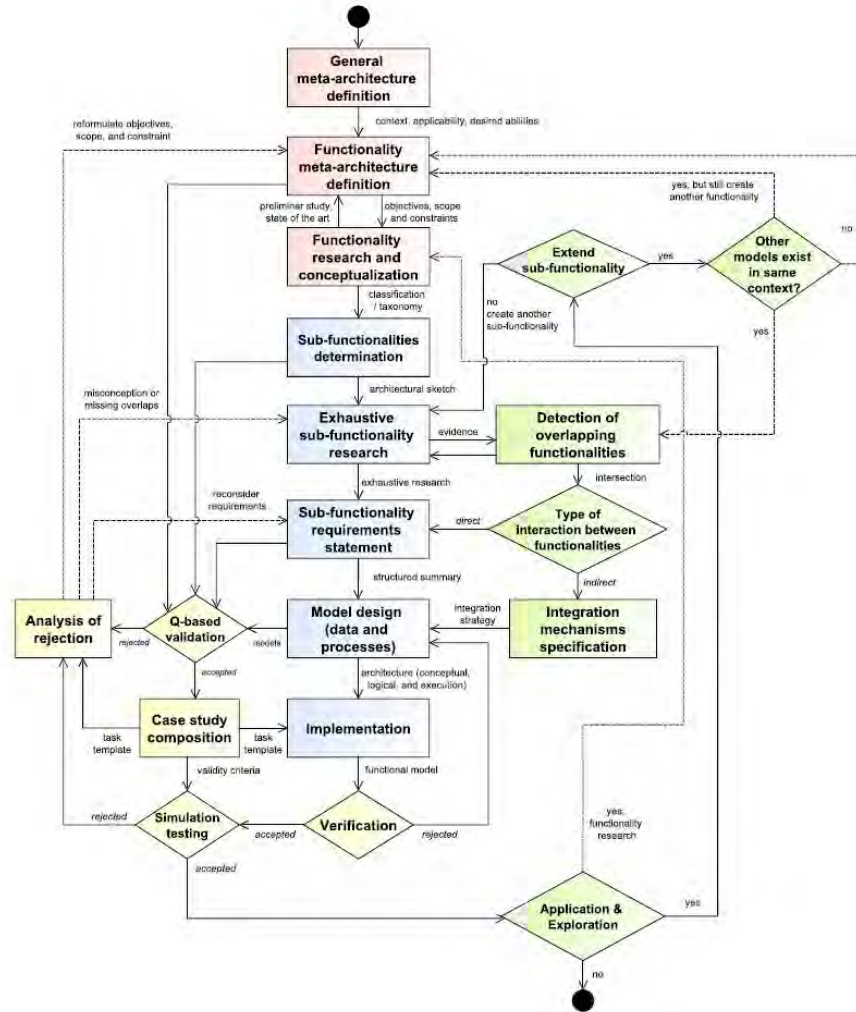
Esta distinción es relevante porque antes de una arquitectura se supone una *meta-arquitectura*, es decir, un conjunto de decisiones conceptuales sobre qué tipo de sistema se quiere construir, qué funciones son relevantes, qué evidencia neurocientífica o psicológica se tomará como base y cuál será la granularidad adecuada para representar cada proceso. Por eso, en el desarrollo metodológico se propone comenzar con una definición general de meta-arquitectura, continuar con una meta-arquitectura específica para cada función, pasar después a la investigación y conceptualización de subfunciones, formular requerimientos funcionales, diseñar los modelos conceptual, lógico y de ejecución, e integrar finalmente las funciones mediante mecanismos explícitos de intersección, validación y refinamiento (Jiménez et al., 2021).



**Fig. 4.1** Niveles taxonómicos de las arquitecturas cognitivas (Fuente: Jiménez et. al. 2021)

Lo que esta metodología busca evitar es un problema muy frecuente en el campo: la ilusión de que basta con identificar módulos para haber explicado la cognición. En realidad, la dificultad no reside sólo en nombrar funciones, sino en describir sus acoplamientos. Por esa razón, en el artículo subrayé que una arquitectura cognitiva debe ser al mismo tiempo extensible y verificable: extensible, porque nuevas funcionalidades deben poder integrarse sin destruir la coherencia general; verificable, porque cada nivel del modelo necesita ser contrastado con tareas o experimentos que permitan evaluar si la función propuesta se comporta de un modo compatible con la evidencia empírica (Jiménez et al., 2021). Esta exigencia es particularmente importante cuando la base

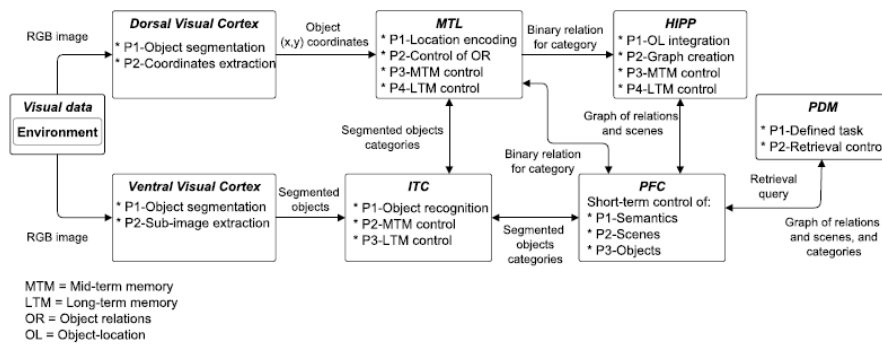
de modelación es neurocientífica, ya que en ese caso no basta con abstraer una función; también es necesario justificar por qué ciertas áreas o circuitos son mapeados en determinados componentes y cómo su interacción puede traducirse en un flujo computacional plausible. En la figura 4.2 se muestra el diagrama de flujo de la metodología para desarrollar arquitecturas cognitivas basadas en neurociencia.



**Fig. 4.2** Diagrama de flujo metodológico para el desarrollo de arquitecturas cognitivas basadas en neurociencia (Fuente: Jiménez et. al. 2021)

La discusión se vuelve todavía más clara cuando se consideran los flujos conceptuales y de activación mostrados en los modelos de memoria de trabajo, reconocimiento visual

y control atencional descendente. En el caso de la memoria de trabajo declarativa, el flujo propuesto parte de la idea de que la información relevante es una organización dinámica distribuida entre corteza prefrontal, corteza temporal inferior, lóbulo temporal medial, hipocampo y sistemas perceptuales (Jiménez et al., 2021). En el esquema conceptual, la corteza prefrontal ocupa un papel regulador, seleccionando información relevante para la tarea, la mantiene activa, la actualiza, la ordena por prioridad y emite señales descendentes para sostener representaciones cuando éstas tienden a degradarse. El lóbulo temporal medial y el hipocampo participan en la recuperación y ensamblaje de relaciones semánticas, espaciales y episódicas, mientras que las áreas visuales extraen rasgos y objetos que pueden ser integrados en escenas. La lógica general de este flujo es neurocognitiva, funcionando modularmente como una interacción entre buffers, trazas, relaciones y mecanismos de control.



**Fig. 4.3** procesos asociados con áreas corticales, ejecutados por cada componente del modelo (Fuente: Jiménez et. al. 2021)

En el modelo de reconocimiento visual de alto nivel se aprecia otro flujo relevante, esta vez sobre el eje ventral de la percepción. La secuencia va desde las cortezas visuales  $V_1/V_2$ , donde se extraen rasgos básicos, hacia  $V_4$ , donde se generan mapas de contorno y segmentación, y de ahí hacia la corteza inferotemporal posterior y anterior, donde se comparan primero rasgos generales y después rasgos locales, hasta producir un identificador de clase que es enviado a memoria y a control ejecutivo (Jiménez et al., 2021). Aquí es tan importante el recorrido *feedforward*, como también la presencia de *feedback*. La información no asciende de manera puramente lineal; las áreas de memoria perceptual, atención y control aportan sesgos, expectativas y filtros que modifican la interpretación del estímulo. Esta fue una de las razones por las que el modelado debía incorporar flujos bidireccionales.

Ese mismo principio aparece con todavía mayor nitidez en el modelo de control atencional descendente. En ese trabajo, la atención fue formulada como un proceso guiado por metas, estrechamente ligado a la memoria de trabajo y al *task-set* de la tarea de búsqueda visual (Vargas et al., 2021; Jiménez et al., 2021). Conceptualmente, el flujo puede dividirse en tres momentos.

1. *Preparación*. A partir de la meta presente en memoria de trabajo, el sistema extrae los atributos relevantes del objetivo y forma una plantilla atencional.
2. *Generación*: esa plantilla se combina con la información perceptual disponible para producir un mapa de activación en el que ciertos atributos, por ejemplo color, orientación o forma, reciben mayor peso.
3. *Ejecución*: el sistema selecciona una región probable, fija ahí la atención y determina si el elemento corresponde al objetivo o a un distractor; si no lo es, la búsqueda se actualiza y continúa (Vargas et al., 2021).

Lo decisivo de este esquema es que muestra con claridad cómo una meta abstracta, mantenida internamente, modula el acceso al campo visual. En términos neurocientíficos, se trata de una formalización de la influencia *top-down* de áreas de control sobre sistemas perceptuales; en términos computacionales, es una arquitectura de sesgo y selección.

Esta clase de formalización tiene un valor que rebasa el ámbito estricto de la robótica cognitiva o de la simulación de laboratorio. Su verdadero potencial aparece cuando se la traslada a dominios complejos, y uno de ellos es la ciencia de la ciudad. Una ciudad puede entenderse como un sistema socioecotécnico saturado de flujos heterogéneos: movilidad, imágenes, lenguaje ciudadano, reportes administrativos, sensores ambientales, patrones de uso del espacio, conflictos, preferencias y restricciones normativas. En ese contexto, una arquitectura cognitiva ofrece una ventaja decisiva frente a modelos puramente estadísticos: permite organizar esos flujos en niveles funcionales. Por ejemplo, un módulo perceptual podría procesar imágenes urbanas o señales provenientes de sensores; una memoria de trabajo podría mantener activas metas de política pública, criterios normativos o estados críticos del sistema; un mecanismo atencional podría priorizar anomalías territoriales o zonas de riesgo; un módulo de planeación podría comparar escenarios y un módulo decisional podría proponer acciones condicionadas por reglas, contextos y objetivos. En otras palabras, la arquitectura cognitiva convierte la ciudad en un problema de cognición distribuida y no sólo de optimización aislada.

Aquí aparece una articulación especialmente sugerente con los grandes modelos de lenguaje (LLM's). los LLM's pueden complementarse con las arquitecturas cognitivas de manera muy fértil (Sun, 2025, 2024). Un LLM puede operar como interfaz semántica de alto nivel: interpretar reportes ciudadanos, resumir reglamentos, extraer entidades de documentos de planeación, generar hipótesis, traducir lenguaje natural a estructuras de consulta o facilitar el diálogo entre especialistas y sistemas computacionales. Sin embargo, por sí mismo, un LLM no ofrece una organización suficientemente explícita de memoria operativa, control atencional, acoplamiento perceptual, persistencia de metas ni validación conductual. Ahí es donde la arquitectura cognitiva se vuelve relevante. Esta puede actuar como estructura de control, como memoria de contexto, como sistema de selección y como mecanismo de coordinación entre módulos especializados, incluido el propio LLM. En una ciencia de la ciudad orientada hacia ciudades cognitivas, el LLM podría encargarse de la mediación lingüística y del razonamiento textual, mientras la arquitectura cognitiva mantendría la coherencia entre objetivos urbanos, datos territoriales, percepción multimodal, filtros de relevancia y decisiones situadas.

Dicho de otro modo, la combinación entre arquitecturas cognitivas y LLMs permitiría pasar de un uso meramente conversacional de la inteligencia artificial a una forma

de inteligencia urbana más estructurada. Por ejemplo, un agente cognitivo urbano podría leer quejas ciudadanas, asociarlas con capas geoespaciales, priorizar eventos en función de metas públicas, contrastar sus inferencias con datos de sensores, consultar memorias de episodios previos y proponer respuestas graduadas. En ese tipo de ensamblaje, la arquitectura cognitiva aportaría control, trazabilidad y organización funcional; el LLM, amplitud semántica y capacidad de interacción en lenguaje natural. Esta articulación sería especialmente útil en movilidad, seguridad, monitoreo ambiental, gestión de infraestructura, participación ciudadana y análisis de controversias urbanas, favoreciendo la transición más robusta desde la noción de ciudad inteligente hacia la de ciudad cognitiva.

Las arquitecturas cognitivas ofrecen un vocabulario y una metodología particularmente adecuados para representar la complejidad de sistemas donde el problema central no es sólo calcular, sino coordinar funciones bajo objetivos, restricciones y contextos cambiantes. El trabajo que desarrollé sobre su metodología general, así como el modelo de control atencional descendente, apuntan en la misma dirección: la cognición no debe entenderse como la suma de módulos independientes, sino como una dinámica de acoplamientos entre memoria, percepción, atención y decisión. Al trasladar esta idea a la ciencia de la ciudad, lo que emerge es una agenda de investigación capaz de vincular la microdinámica biopsicofísica de agentes humanos o artificiales con la macroestructura socioecotécnica del espacio urbano. En esa intersección, las arquitecturas cognitivas dejan de ser solamente un tema de IA y se convierten en una pieza conceptual para pensar cómo sistemas complejos orientados por metas pueden habitar, interpretar y transformar la ciudad.

#### 4.2.2. Topos: un metamodelo de diseño en entornos complejos

En este capítulo se presenta también, una aportación propia a la construcción de modelos de diseño en entornos complejos, que toma como eje central, la construcción conceptual en el ser humano, atendiendo a su base neurobiológica, y por otra parte, a la estructura de modelado de un sistema complejo. Se aborda aquí los lineamientos filosóficos y formales de la construcción conceptual, y su relación con lo mencionado hasta este momento.

Un concepto es una unidad básica de pensamiento, un puente entre percepciones y acciones (Gärdenfors, 2005) y, en general, se entiende como una forma de pensamiento que constituye una unidad de nuestro conocimiento del mundo. (Blunden, 2012).

Mediante el concepto y el proceso de conceptualización, se representan imágenes, procesos, objetos y entidades de diversos dominios teóricos y prácticos.

Se asume que, para incluir una estructura de esta naturaleza, es necesario considerar tanto los procesos que implican percepciones sensibles como aquellos que permiten el razonamiento.

En su momento, se optó por un enfoque cognitivo que descompone el proceso de diseño desde la génesis de elementos compositivos mínimos dotados de significado progresivo, hasta los medios expresivos disponibles, que no solo abarcan entidades espaciales, sino también elementos abstractos que amplían la base de conocimiento

disponible. En este esquema, se propone una aproximación general inicial al camino que el diseñador tiene ante sí.

En el campo de la filosofía, Immanuel Kant pretende demostrar que solo mediante la aplicación de conceptos o categorías es posible encontrar unidad y universalidad en la naturaleza como un conjunto de síntesis sucesivas (de la sensibilidad, la imaginación y el entendimiento) que determinan un fenómeno a través de conceptos. Esto se deriva de la definición primordial de *Topos*, cuando se percibe que la naturaleza para Kant no es un texto, sino más bien un lugar, en el que la gramática de los conceptos del entendimiento adquiere significado.

Resulta notable la similitud que Kant tiene con Aristóteles en la noción de categoría. Las categorías son de fundamental importancia; sin ellas, no es posible formular proposiciones ni definiciones, y estas son los instrumentos insustituibles de inferencia, prueba y demostración. En resumen, las categorías no persiguen otro propósito que el de señalar los conceptos supremos y hallar las leyes que los rigen para alcanzar el verdadero conocimiento.

Cassirer, en su obra fundamental sobre las formas simbólicas, establece una conexión trascendental entre los dominios de la aprehensión, la reproducción y el conocimiento, relacionándolos respectivamente con la intuición, la imaginación y el concepto. Un concepto es una unidad de conocimiento, un presupuesto de la experiencia y una condición de posibilidad. Cassirer define un concepto de la siguiente manera:

Reconocer un objeto no significa otra cosa que someter la multiplicidad de la intuición a una regla que la determina con respecto a su orden. Y el concepto no es más que la conciencia de dicha regla y de la unidad que se postula a través de ella.

Esta es una primera aproximación filosófica a la binomía (regla de correspondencia-objeto); además, la referencia retórica a una variedad (como lugar para la multiplicidad) adquiere un sentido geométrico-topológico.

Para encontrar una vía para categorizar conceptos, observamos una analogía de varios dominios semánticos generales y su descomposición morfológica en partes atómicas, estructuradas de manera similar, como se representa en la tabla.

UNIVERSO	FORMA	SUSTANCIA	MAPEO	ELEMENTOS ATÓMICOS
Características formales lingüísticas	Espacio-tiempo	Representación Formal/cognitiva del espacio-tiempo	Conjunto $L_{\text{parcial}}$ de expresiones lingüísticas	expresión atómica lingüística
teoría de la homología	Grupos de homología	Grupos de co-cadenas	simplicial complexes orientados	Simplex
Manifolds Topológicos	Manifold	Atlas	Cartas	Puntos
Ontologías semánticas	Concepto	Instancia	Relación	Axioma
Estructura relacional extensiva	Universo de discurso	conjunto de mundos posibles	conjunto de relaciones sobre un espacio	ontologías

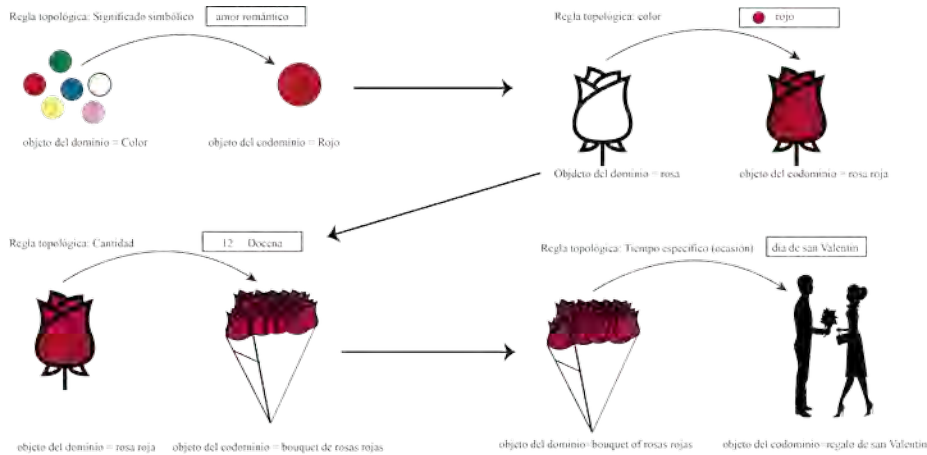
**Tabla 4.2** Dominios semánticos y sus correlativos conceptuales

En la tabla anterior, se pretende conciliar universos heterogéneos desde el lenguaje, las matemáticas y las ciencias computacionales que comparten características comunes como las siguientes:

- Una Forma: En sentido de la existencia de un objeto emergente, indiscernible por la suma de sus partes constitutivas (la representación misma).
- Una sustancia: Una descripción de lo que el objeto es el sujeto mismo.
- Un Mapeo: El camino por el cual la sustancia se transforma en un sujeto específico y no en algo más.

- Elementos atómicos: los mínimos constitutivos esenciales.

Un proceso conceptual trata sobre cómo podemos vincular estas unidades de pensamiento, a fin de alcanzar objetivos específicos. Los conceptos como esta representación, son encapsulados en función de contextos de acción específicos, como se ilustra en la figura 4.4:



**Fig. 4.4** Agregación de características y significantes en un objeto para construir un concepto. Fuente: Elaboración propia, 2018

Un objeto de un dominio arbitrario se asocia a una regla de correspondencia topológica que le confiere un atributo (color, significado simbólico, cantidad y tiempo). El codominio contiene el mismo objeto tras pasar por esta regla de correspondencia. Este conjunto de unidades conceptuales atómicas se vinculan intuitivamente para cumplir con una convención social. Un concepto limita nuestras opciones según el contexto y permite elegir una sola entre innumerables posibilidades.

Desde una perspectiva filosófica, observamos una transición entre el concepto como unidad atómica del conocimiento y su organización en categorías para la construcción de estructuras complejas. En el sentido de (Gärdenfors, 2005), necesitamos una estructura geométrica para la representación conceptual.

En la figura 4.5 se presenta un diagrama que relaciona ambas ópticas de los sistemas complejos, que comparten en las matemáticas, un lenguaje común

### 4.2.3. Formalización del modelo conceptual

Se presenta una sistematización que define un sistema complejo:

$$K = \{H_k, P, F, idA, clP, cP\} \quad (4.1)$$



un objeto externo a él. La verticalidad se concibe por medio de la comunicación entre los elementos emergentes del patrón y su límite. El colímite y su funtor  $\mu$  son elementos importantes para la determinación de esta acción, porque el colímite al ser isomorfo al patrón puede considerarse, ya sea como otra representación de la emergencia del sistema o bien un elemento conceptual de un patrón con un nivel de complejidad  $i + 1$ . La combinación categórica de ontologías permite lograr generalizaciones abstractas de las relaciones entre elementos arbitrarios de un patrón.

Esta sistematización presenta los agentes principales y las relaciones que permiten estructurar

Un concepto  $c$  es un par ordenado  $\{o, t\}$ , donde  $o$  es un objeto y  $t$  es una regla de correspondencia topológica. Consideramos una relación de equivalencia entre conceptos como elementos atómicos para la significación de la realidad y grafos orientados. Como concepto, [bib18] define los grafos orientados como una disposición dirigida de objetos para representar sistemas, como se muestra en la figura [fig8].

Un grafo  $G = \{E, V\}$  es un par ordenado de objetos llamados aristas y un conjunto de acciones etiquetadas llamadas vértices. Las aristas contienen un objeto, y los vértices cumplen una regla de correspondencia topológica con otras aristas [(Xiao et al., 2009)]. se (Erciyev, 2014) define una red compleja como una red con características topológicas no triviales y la describe esencialmente de la siguiente manera:

- Son grandes y constan de cientos o miles de elementos.
- Los patrones de conexión no son regulares ni puramente aleatorios.
- Cambian dinámicamente.
- Forman la base de los sistemas complejos.

La relación de equivalencia entre conceptos aislados y este tipo de representación en grafos orientados se define de la siguiente manera:

$$[c = \{o, t\}] \sim [G = \{E, V\}] \quad (4.2)$$

Este funtor de transición es  $Os$ , de sistematización orientada. En otras palabras, un concepto atómico debe agruparse con otros conceptos para construir un sistema estructurado. Estas interacciones tienen un orden y una dirección específicos para la construcción de patrones precisos, dependiendo del contexto en el que se encuentren. Un grafo es, de hecho, un esquema topológico.

$$Os : [C = \{o, t\}] \rightarrow [G = \{E, V\}]$$

El funtor  $Ck$  corresponde al núcleo conmutativo; al igual que su contraparte en hardware computacional, un núcleo es la unidad responsable que oculta la complejidad mediante abstracciones de máquina.

$$[T = \{X, \omega\}] \sim [K = \{O, \phi\}]$$

Al igual que en un espacio topológico, de manera similar, se establece una relación de equivalencia entre espacios topológicos y categorías de la siguiente manera:

$$H_{chain} : [T = \{X, \omega\}] \longrightarrow [K = \{O, \phi\}]$$

Definición: Sea  $K$  el *simplicial complex* consistente en todas la caras propias del estandar  $(n + 1)\Delta^{n+1} = \Delta$  (Whitehead, 2012). (Eilenberg and Mac Lane, 1945)

se categorizan secuencialmente los elementos mínimos de los espacios, denominando complejos simpliciales como transitorios a grupos de homología de la siguiente manera:

1. Espacio - Complex
2. Complex - Complex orientado
3. Complex orientado - Grupos de cadenas
4. Grupos de cadenas - Grupos de homología

Un cocono  $\mu$  de una cadena- $\omega$   $\Delta$ , es un objeto  $K$  y una colección de  $K$ -flechas  $K$ .  $\{\mu_i : D_i \rightarrow X | i \geq 0\}$  tal que  $\mu_i = \mu_{i+1} \circ f_i \forall i \geq 0$ . Un cocono se define también como  $\mu \Delta \rightarrow X$  (Ehresmann and Vanbreemersch, 2007) lo denominan enlace colectivo). De forma similar, un colímite  $\mu : \Delta \rightarrow X$  es un cocono con la propiedad de que si  $\nu : \Delta \rightarrow X'$  también es un cocono, entonces existe una única flecha mediadora  $k : X \rightarrow X'$  tal que para todo  $i \geq 0$ ,  $\nu_i = K \circ \mu_i$ .

Un patrón conceptual  $K$ , representado en un complejo simplicial (figura 4.6), es una conformación de instancias semánticas mínimas que aporta significado a un conjunto conceptual; un cocono es una declaración de esta conformación y depende del contexto (por ejemplo, la unión conceptual de ladrillos, mortero y cerramientos conforma una pared; sin embargo, esta pared puede ser un componente de una sala de estar o de un almacén); un colímite es un objeto atómico complejo que reúne toda la información contenida en un patrón y la sustituye en patrones más complejos.





Fig. 4.6 Un simplex (a), Un complejo simplicial (b) (Fuente: Elaboración propia, 2017)

Debido a la naturaleza topológica de los conceptos y, por ende, a las posibilidades que ofrece la adición de diagramas en un atlas complejo, la calidad de nuestra propuesta destaca principalmente porque relaciona estos grupos de homología con las instancias conceptuales del diseño. Ambos se componen de un conjunto de objetos y una colección de reglas; un grafo orientado es una representación esquemática de dichas colecciones y sus flechas.



**Fig. 4.7** Un colímite es un isomorfismo del patrón que agrupa la complejidad de un patrón K y se convierte en un concepto atómico de un patrón más complejo. (Fuente: Elaboración propia, 2017)

con el Cocono y colímite sobre un complejo simplicial se conforma un patrón conceptual  $K$  con álgebra de  $\omega$ -cadena adjunta. Un cocono describe el comportamiento colectivo interno del patrón como un objeto emergente y dependiente del contexto. En la figura 4.7 se identifican todos los objetos mencionados aquí.

Así, el diagrama categórico completo que establece una relación esquemática entre conceptos, grafos orientados, espacios topológicos y categorías se representa de la siguiente manera:

$$\begin{array}{ccc}
 c = \{o, t\} & \xrightarrow{Os} & G = \{E, V\} \\
 \downarrow M_{atlas} & & \downarrow Ck \\
 T = \{X, \omega\} & \xrightarrow{H_{chain}} & K = \{O, \phi\}
 \end{array}$$

Un concepto, como noción mental, puede utilizarse para categorizar información u objetos, como instancias o bloques de construcción de pensamientos que representan

un pequeño fragmento de la realidad. También se define como abstracciones cognitivas que representan clases de objetos, eventos o ideas, o como objetos que comparten propiedades similares y se designan con el mismo signo o símbolo. Es posible observar que estas definiciones comparten un factor común: la organización y gestión de los objetos que se perciben, almacenan y eligen como respuesta racional o física a contextos específicos.

Es relevante analizar los fundamentos de cómo se construye esta imagen o formulación mental. ¿Cómo y mediante qué procesos y objetos es posible discernir qué es algo y cómo se determina que debe ser? ¿Es posible llegar a una generalización? Se asume que, para incluir una estructura de esta naturaleza, es necesario considerar tanto los procesos que implican percepciones sensibles como aquellos que permiten el razonamiento.

Hay puntos recurrentes en la ciencia cognitiva para la construcción y representación del conocimiento basado en conceptos, por ejemplo: un sistema de sociedades-agentes (organizaciones-agentes), un criterio de emergencia para estas organizaciones y un esquema jerárquico de categorización. Se busca entonces la secuenciación del proceso de generación conceptual a partir de su origen biológico en la recepción de estímulos en el ambiente por modalidades sensoriomotoras, la integración de múltiples funcionalidades a través de un esquema adecuado de representación.

Los temas de la ciencia cognitiva relacionados con la biología del cerebro humano implementan patrones de activación y un registro descriptivo del conjunto de áreas cerebrales relacionadas con la generación conceptual (Martin (2007b), Martin (2007a)). Hay transiciones de instancias de bajo nivel a redes de alto nivel, a pesar de que sus herramientas de interpretación (fMRI, BOLD, EEG, PET) no dan cuenta de los procesos cognitivos, sino solo de las activaciones corticales, Poldrack (2010), Wang et al. (2013), Wang et al. (2010), Poldrack (2006), lo que hace casi imposible asegurar que el conjunto de actividades electroquímicas corresponda a un comportamiento específico. Se hace en la literatura una distinción entre conceptos concretos y abstractos Wang et al. (2013), Wang et al. (2010), Martin (2007b), Martin (2007a) Existen modelos neuropsicológicos estadísticos que aproximan la unión entre ambos dominios. Palestro et al. (2018), Cassey et al. (2016); por otro lado, el conocimiento conceptual de alto nivel tiende a pasar por alto instancias presimbólicas para realizar operaciones entre conceptos consolidados sobre una base semántica, lingüística e incluso metafórica.

Partimos de la base de que la generación de conceptos es un pilar fundamental de la cognición humana. La transición que desde el siglo XIX produjo la investigación de la mente, desde la filosofía a la psicología, y que posteriormente allanó el camino para el estudio científico de la mente y permitió la consolidación de las ciencias cognitivas Trehub (1991)

A través de una revisión de la literatura es posible encontrar un conjunto de componentes fundamentales que se argumentan para la generación conceptual desde un punto de vista neurocognitivo. La generación conceptual puede determinarse en una primera etapa por: La actividad de las modalidades sensoriomotoras que reciben y procesan estímulos (información potencialmente asimilable) del entorno. e induce al agente a dar respuestas sensatas; los sesgos emocionales y motivacionales subjetivos de las representaciones que se consolidan y almacenan en la memoria; los mecanismos de identificación y categorización perceptiva Gordon (2004), el almacenamiento, la

recuperación y la interpretación de esas entidades perceptivas en la memoria, y sus interacciones categóricas para la consolidación y el aprendizaje de imágenes visuoespaciales.

En un nivel superior: La estructura semántica en la que se basan y el significado generado al vincularse con esta estructura [Binder et al. \(2009\)](#), [Binder and Desai \(2011\)](#); la representación egocéntrica de la entidad y su concurrencia con la ubicación aloécéntrica [Land \(2014\)](#), [Pöhlmann \(2017\)](#), [Stein \(1989\)](#); modulación y control de la atención en la construcción semántica [Bowman et al. \(2006\)](#), [Posner and Rothbart \(2007\)](#);

Generación de un contexto espacio-temporal [Dourish \(2004\)](#), [Cassens and Wegener \(2008\)](#); Constitución de estructuras lingüísticas específicas [Jackendoff and Jackendoff \(2002\)](#), [Hagoort and Indefrey \(2014\)](#), [Indefrey and Levelt \(2004\)](#), [Ben Shalom and Poeppel \(2008\)](#), [Friederici \(2011\)](#), [Bornkessel-Schlesewsky and Schlewsky \(2016\)](#); la acción que la semántica ejerce en la memoria y en su asimilación subjetiva por parte del agente [Pulvermüller \(2018\)](#), [Irish and Piguet \(2013\)](#); los procesos de aprendizaje y las instancias anticipatorias; conceptos abstractos contextuales [Cassens and Wegener \(2008\)](#); comprensión de metáforas [Fernandino et al. \(2016\)](#), [Gibbs Jr \(2006\)](#).

La neurociencia cognitiva requiere explicaciones neuronales de las funciones cognitivas, que involucran lo perceptivo, lo cognitivo, lo afectivo y lo volitivo. A diferencia del campo empírico mencionado, las cuestiones conceptuales (concepto de mente y memoria, relaciones lógicas entre conceptos y la relación entre diferentes campos conceptuales) constituyen un campo adecuado para la filosofía. Esta influye en las formas de representación (aunque parece que la filosofía se encarga de la cuestión conceptual en la definición de preposiciones epistemológicamente utilizables). En el caso de las ciencias computacionales, los modelos inspirados en la neurociencia presentan divisiones claras, con el fin de construir modelos eficientes para replicar el razonamiento inteligente y que afectan principalmente la toma de decisiones, y para modelos de comportamiento, sin involucrarse profundamente en procesos relacionados con la génesis de las estructuras cognitivas.

La capacidad humana para generar conceptos es uno de los grandes desafíos aún sin resolver en las ciencias computacionales.

La generación conceptual es un proceso cognitivo que busca el uso sinérgico de nociones, ideas y aspiraciones individuales para organizar representaciones internas. Además, la noción de concepto en el campo de las ciencias cognitivas implica una unidad básica significativa para la representación mental, originada por la generación conceptual. Ambas están intrínsecamente relacionadas.

La generación conceptual se produce cuando las representaciones mentales internas, tanto abstractas como concretas, interactúan para consolidar una idea. Sin embargo, se trata de un fenómeno sumamente complejo que requiere un estudio exhaustivo del conocimiento. Además, la generación conceptual está completamente ligada a procesos biológicos y no puede explicarse por sí sola.

Los trabajos y avances sobre la inspiración biológica en los sistemas cognitivos computacionales [Lieto \(2014\)](#) determinan una plataforma de trabajo que emplea métodos y herramientas que divergen en ocasiones, de las estructuras cognitivas tradicionales de inteligencia artificial.

El trabajo en curso se centra en el uso de modelos para identificar y predecir problemas de diseño en diferentes niveles, desde el diseño de un objeto simple hasta la

construcción de un sistema urbano complejo (el sistema espacial más complejo). Existen puntos filosóficos esenciales, como las formas sintéticas a priori, las representaciones arquetípicas y el topos retórico, que históricamente alternan su proximidad al cuerpo de estudio de las categorías matemáticas, las instancias conceptuales, las representaciones simbólicas y abstractas, que serán objeto de estudio en trabajos posteriores, ya que constituyen sectores del conocimiento aún inexplorados. también se ha desarrollado una línea de investigación sobre procesos creativos anticipatorios, basada en el diseño y desarrollo de patrones categóricos, siguiendo dos directrices principales: un principio de multiplicidad y un núcleo arquetípico, que modifica el comportamiento de los patrones mediante el proceso de complejización y se consolida como una estructura polisémica multidominio.

## Capítulo 5

# La ciencia de la ciudad: entre la complejidad y la cognición

*“Las ciudades son un conjunto de muchas cosas: memorias, deseos, signos de un lenguaje; son lugares de trueque, como explican todos los libros de historia de la economía, pero estos trueques no lo son sólo de mercancías, son también trueques de palabras, de deseos, de recuerdos. - Ítalo Calvino*

### 5.1. Conceptos básicos sobre la ciencia de la ciudad

La Ciencia de la Ciudad es un cuerpo de conocimiento organizado que busca la comprensión formal de cómo las ciudades se ordenan y estructuran. La esencia de esta nueva ciencia se basa en un cambio de paradigma que rechaza el reduccionismo de la ciencia clásica, y postula que, para entender las ciudades, debemos verlas como sistemas complejos contruidos más como organismos que como máquinas, centrándose en ellas como constelaciones de interacciones, comunicaciones, relaciones, flujos y redes, en lugar de meras ubicaciones. La Ciencia de la Ciudad puede verse como la ingeniería de un ecosistema urbano que aplica los principios de la ecología, las redes y la autoorganización para comprender, con herramientas matemáticas de complejidad, por qué el bosque (la ciudad) crece y se transforma de manera impredecible a partir de las interacciones locales de millones de semillas y organismos (los agentes y sus flujos).

El enfoque de razonamiento se construye principalmente de abajo hacia arriba (bottom-up), enfatizando que la ubicación es una síntesis de interacciones, y utilizando herramientas y métodos reproducibles para representar, analizar, simular, predecir e informar el diseño urbano. Un marco de referencia más amplio para la ciencia de la ciudad abarca la economía urbana y regional, la modelización, la teoría, la física social (escalamiento, rank-size, alometría) y su enfoque analítico a través de la geometría fractal, la teoría del caos y la complejidad.

#### 5.1.1. Planteamientos Sustentantes en los sistemas complejos en la ciencia de la ciudad

Los siguientes enfoques teóricos y matemáticos sustentan la nueva ciencia de las ciudades, tal como se describe en la literatura:

### Teoría de la Complejidad y Sistemas Adaptativos

Es intrínseca a esta ciencia de la ciudad y está a la vanguardia de estos desarrollos. Se centra en la emergencia de estructuras a nivel global a partir de reglas simples a nivel local. Las ciudades se ven como sistemas lejos del equilibrio. (Portugali and Stolk 2016a; Portugali, 2011, 2004; Bettencourt, 2021)

### Teoría General de Sistemas

Como se vio anteriormente, es considerada la precursora de la complejidad, sugiriendo que el todo es más que la suma de sus partes.

### Sinérgica (Synergetics)

Propone que la autoorganización es una propiedad tanto de lo Natural como de lo Artificial (incluida la ciudad), permitiendo una reducción de la complejidad mediante parámetros de orden. (Bettencourt, 2013; Batty, 2018)

### Modelado Basado en Agentes y Autómatas Celulares

Estos modelos representan un cambio de paradigma hacia la micro-dinámica desagregada y las explicaciones individualistas del comportamiento urbano: Modelos Basados en Agentes (Agent-Based Models, ABM): Se centran en explorar las implicaciones colectivas de la toma de decisiones a nivel individual. Permiten la experimentación controlada para descubrir leyes sobre procesos complejos.

### Autómatas Celulares

Se basan en una teselación espacial (células) con reglas de transición que dependen del vecindario local y que generan patrones de orden superior. Existen modelos de CA con valores continuos y aquellos que incorporan lógica difusa para el proceso de decisión.

### Modelos de Microsimulación

Implican enfoques genéricos y detallados, a menudo vinculados a ABM y modelos de dinámica de sistemas.

El enfoque dual de flujos y redes es fundamental. Integra la teoría de la Interacción Espacial / Física Social, que proporciona la base para los modelos gravitacionales utilizados para simular el transporte, la migración y otros flujos. La Ciencia de Redes (Network Science) se utiliza para representar las relaciones y conexiones. Las redes

pueden describirse mediante grafos bipartitos (relaciones entre dos conjuntos de objetos, como actores y factores). De igual modo, la sintaxis Espacial como morfología urbana, utiliza la teoría de grafos para representar la estructura urbana, principalmente redes de calles y sus intersecciones. Utiliza conceptos de accesibilidad y distancia topológica en lugar de solo la distancia euclidiana. (D'Acci, 2019; Bettencourt, 2021; Batty, 2013).

Las leyes de escalamiento y geometría matemática describen las regularidades que persisten en el tiempo y el espacio en los sistemas urbanos, por ejemplo, las leyes de escalamiento describen cómo varias propiedades de las ciudades cambian de forma superlineal o sublineal a medida que aumenta el tamaño de la población. La ley de Zipf se aplica a la distribución del tamaño de las ciudades (rank-size) y los modelos estocásticos multiplicativos, como el de Simon, se han utilizado para explicar la aparición de distribuciones de ley de potencia en el tamaño de las ciudades. También, la geometría fractal se ha empleado para describir la auto-similitud y la jerarquía en la morfología urbana. El crecimiento a partir de reglas locales puede generar patrones fractales, que son característicos de las ciudades reales.

EN el contexto de los marcos de decisión y dinámicas evolutivas para las ciudades, la lógica Difusa (Fuzzy Logic) es apropiada para la modelización urbana, ya que los factores físicos y la toma de decisiones humanas se caracterizan por la incertidumbre. Se utiliza en autómatas celulares para definir los estados de las células o en las reglas de transición y para describir los criterios de decisión de los agentes, como la atracción o la rentabilidad. Los procesos Markovianos se utilizan para modelar procesos de diseño y toma de decisiones (Máquinas de Diseño Markovianas) donde el sistema carece de memoria, progresando hacia un consenso o un estado estacionario mediante el promedio sucesivo de factores o intereses.

Finalmente, el crecimiento urbano se considera invariante evolutivo. Modelos como SIMPOP para el software *R* buscan simular la coevolución de los sistemas urbanos y su capacidad de reacción y adaptación a condiciones cambiantes.

### 5.1.2. Modelado Basado en Agentes

La evaluación rigurosa de la incertidumbre y el poder predictivo de los Modelos Basados en Agentes (ABMs, por sus siglas en inglés) es un desafío fundamental, dada la naturaleza compleja, no lineal y a menudo estocástica de los sistemas que modelan. El enfoque riguroso se basa en un proceso iterativo de Verificación, Calibración y Validación (CVV), complementado con estrategias específicas para manejar la complejidad y la incertidumbre, como el Modelado Orientado a Patrones (POM).

La evaluación de los ABMs se estructura típicamente en tres etapas principales, que en conjunto aseguran que el modelo esté bien construido y que represente adecuadamente el sistema objetivo.

La verificación es el proceso de asegurar que un modelo implementado coincida con su diseño. Trata de construir el modelo correctamente y a menudo implica verificar la lógica del modelo a través de su programa informático. Es esencial para asegurar la validez interna del modelo. Dado que los ABMs, especialmente los complejos, son susceptibles a errores de programación y a errores de representación digital (como

la precisión de punto flotante), la visualización de datos y salidas es esencial para identificar errores que se introducen durante el ensamblaje de datos y la codificación.

La calibración es el ajuste de los parámetros y especificaciones del modelo para ajustarse a ciertas teorías o datos reales. Se realiza utilizando datos del mundo real antes de que se validen los resultados del modelo. Puede involucrar métodos de optimización eficientes, como los Algoritmos Genéticos (AG), para encontrar la configuración óptima de parámetros al tratar el modelo como una caja negra.

La validación es el proceso de asegurar que un modelo implementado coincida con el mundo real que intenta simular. Un modelo no se clasifica simplemente como válido o inválido, sino que puede tener un cierto grado de validez.

Se distinguen tres tipos principales de validación:

- Validación Replicativa: Los resultados del modelo se comparan con datos obtenidos del mundo real.
- Validación Predictiva: El modelo es capaz de predecir comportamientos que no ha visto antes o que podrían ocurrir en el futuro.
- Validación Estructural: El modelo no solo reproduce el comportamiento observado del sistema, sino que realmente refleja la forma en que opera el sistema real para producir ese comportamiento.

La validación estructural se logra mediante una secuencia de cuatro procesos clave, que a menudo se realizan de forma iterativa:

#### Validación de Apariencia (Face Validation)

Se aplica en la fase inicial para garantizar que los procesos y los resultados iniciales sean razonables y plausibles dentro del marco teórico básico del sistema real. Incluye: Evaluación de Animación: Observación de la animación del sistema simulado o de agentes individuales, siguiendo sus comportamientos particulares. Evaluación Inmersiva: Monitoreo de la dinámica de un agente específico durante la ejecución del modelo. Evaluación de Salida: Asegurar que las salidas caigan dentro de un rango aceptable de valores reales y que las tendencias sean consistentes en diferentes simulaciones.

#### Análisis de Sensibilidad (Sensitivity Analysis)

Evalúa el efecto de diferentes parámetros y sus valores en los comportamientos o resultados generales del modelo. Este análisis es crucial para seleccionar los parámetros significativos que luego requerirán calibración. Puede llevarse a cabo sistemáticamente utilizando técnicas estadísticas como el Diseño de Experimentos (DOE) y el metamodelado para evitar simplificaciones excesivas y capturar posibles interacciones entre parámetros de entrada.

### Validación de Salidas (Output Validation)

Implica hacer coincidir gráficamente y estadísticamente las predicciones del modelo con un conjunto de datos reales. La elección de la métrica de evaluación depende del objetivo de la validación. Aquí están a disposición dos métodos: *Relative Operating Characteristic (ROC)* Utilizado para evaluar el rendimiento de un esquema de clasificación o predicción y *Multiple Resolution Goodness-of-fit (MRG)* Considerado un método más adecuado para evaluar la idoneidad de las salidas espaciales en comparación con los métodos convencionales. El MRG captura los detalles de los patrones espaciales y temporales en los datos, a diferencia de otras métricas de ajuste. Otras métricas incluyen el Error Cuadrático Medio (MSE), el Índice Kappa de Acuerdo (KIA) y el Análisis Fractal.

La incertidumbre en los ABMs surge usualmente del error en los datos de entrada, la parametrización y la forma del modelo, y se propaga de manera problemática en sistemas no lineales. Además, la naturaleza inherentemente compleja de los sistemas sociales hace que la predicción fuerte sea poco probable o inapropiada; el rol de los modelos se enfoca en informar y explorar escenarios de *¿Qué pasaría si...?* No obstante, debido a la naturaleza estocástica de los ABMs, cada ejecución produce un resultado diferente. Para subsanar el problema, se utiliza el muestreo de Monte Carlo (Monte Carlo testing) para incluir errores de tipo aleatorio (ruido) en el modelo. Esto se logra ejecutando el modelo varias veces, muestreando al azar la distribución de cada variable de entrada y/o parámetro dentro de rangos controlados. Los resultados se tratan probabilísticamente, proporcionando una distribución de resultados.

De igual forma, para inyectar rigor y limitar la incertidumbre en el diseño y la parametrización, se emplea el Modelado Orientado a Patrones (Pattern-Oriented Modelling, POM). Esta estrategia consiste en identificar múltiples patrones de comportamiento (hechos estilizados) observados en el sistema real o en sus agentes. Estos patrones se utilizan de manera sistemática y explícita para decidir qué entidades, variables y procesos deben incluirse en el modelo para que sea lo suficientemente complejo pero no innecesariamente complejo. Solo las combinaciones de parámetros que logran reproducir múltiples patrones observados simultáneamente se consideran válidas. Uno de los usos más comunes, es utilizar el ABM como un laboratorio virtual para probar teorías o submodelos alternativos de comportamiento agente.

Por otra parte, la comunicación de los ABMs es crucial para su credibilidad científica. El protocolo ODD (Overview, Design concepts, Details) es un estándar para describir ABMs que asegura la transparencia y proporciona todos los detalles necesarios para la replicación del modelo. ODD ayuda a los investigadores a pensar y diseñar el ABM de manera estructurada. La evaluación también debe abordar los problemas inherentes a la modelización de sistemas complejos, que se relacionan con tópicos revisados anteriormente aquí. Por ejemplo la *equifinalidad* se traduce aquí en el problema de que diferentes procesos o variables puedan conducir al mismo resultado observado. El uso de múltiples pruebas y la Validación Estructural (como el POM) ayuda a distinguir modelos que replican patrones por las razones correctas. La incertidumbre es una propiedad intrínseca de los sistemas urbanos complejos. El valor predictivo se ve mermado por la sensibilidad a las condiciones iniciales y la no linealidad (dependencia de la trayectoria).

Evaluar la incertidumbre y la predictibilidad de un ABM es como construir y probar un simulador de tráfico para una ciudad caótica. La Verificación asegura que los semáforos y los coches sigan las reglas de la codificación. La Calibración ajusta la agresividad de los conductores para que las velocidades promedio coincidan con los datos reales. La Validación confirma que la congestión emerge en los mismos puntos que en la realidad (Validación Replicativa) y que si se añade un nuevo carril, la simulación predice el cambio de flujo de manera plausible (Validación Predictiva). El Modelado Orientado a Patrones (POM) garantiza que el modelo reproduzca fenómenos complejos conocidos, como la ley de Zipf en la distribución de atascos, lo que da confianza en que la microdinámica de los agentes (conductores) captura la esencia del tráfico real, a pesar de que el resultado de un viaje individual específico sigue siendo impredecible.

### 5.1.3. Cityscope: Una plataforma para el modelado de problemas urbanos

En el campo contemporáneo de la ciencia de la ciudad, una de las dificultades más persistentes consiste en traducir la complejidad urbana en dispositivos de análisis que no reduzcan la ciudad a una colección de variables independientes ni a un esquema puramente descriptivo. La ciudad es, en rigor, una configuración dinámica de actores, infraestructuras, prácticas, flujos, restricciones espaciales y decisiones institucionales, cuya interacción produce regularidades, tensiones y comportamientos emergentes.

Desde esta perspectiva, el interés de CityScope Guadalajara radica en proponerse como una mediación entre el conocimiento científico de los sistemas urbanos, la simulación computacional y la deliberación pública sobre escenarios de intervención. Su objetivo de fondo puede leerse, por tanto, como el intento de construir un entorno donde la ciudad pueda ser experimentada como sistema complejo: manipulable en sus componentes, observable en sus efectos y discutible en sus implicaciones.

El valor metodológico del trabajo reside en que parte de una secuencia epistemológicamente más robusta: delimitar el fenómeno urbano, identificar sus actores y relaciones, traducir esa estructura a un modelo computacional, implementar dicho modelo en una plataforma de simulación y, finalmente, someterlo a contraste mediante escenarios y ejercicios de validación.

Esta secuencia es importante porque restituye a la modelación su estatuto científico: antes de producir imágenes o indicadores, es necesario construir una representación operativa del sistema. En este caso, esa representación se apoya en el modelado basado en agentes y se implementa en *GAMA platform*, lo cual permite trabajar simultáneamente con entidades individuales, configuraciones espaciales, reglas de comportamiento y procesos de agregación. El caso del Distrito Cultural Universitario de la Universidad de Guadalajara ofrece un terreno particularmente fértil para este ejercicio, porque se trata de un espacio en transformación donde convergen expectativas de crecimiento residencial, equipamiento cultural, movilidad y reorganización funcional del territorio.

Ahora bien, la originalidad de CityScope Guadalajara se hace más visible cuando se observa la forma en la que su arquitectura integra el modelo del espacio de discusión. La plataforma articula una interfaz tangible basada en una maqueta tridimensional del

área de estudio, un sistema de reconocimiento de marcadores, una capa de comunicación de datos, un modelo basado en agentes que recalcula el estado del sistema y un conjunto de visualizaciones que devuelven indicadores y mapas de calor al usuario. Esta composición es teóricamente significativa.

En lugar de dejar el modelo encerrado en el dominio experto del software, lo proyecta hacia una experiencia de interacción material y colectiva. La ciudad simulada aparece como una configuración que puede ser modificada, observada y debatida en tiempo real. El modelo, en este sentido, calcula y traduce, de relaciones complejas a formas visibles, convierte decisiones espaciales en consecuencias comparables y habilita una comprensión situada de la relación entre intervención y comportamiento sistémico. (Palomo et al., 2025; Roldán et al., 2025)

Esta capacidad de traducción vuelve especialmente relevante a la plataforma en contextos donde la planeación urbana suele oscilar entre dos extremos problemáticos: de un lado, la visión tecnocrática que concentra el conocimiento en especialistas y, del otro, la discusión pública desvinculada de herramientas analíticas capaces de anticipar efectos. El CityScope Guadalajara propone una tercera vía: una infraestructura de simulación participativa en la que actores con distintos niveles de *expertise* pueden intervenir sobre una representación material del territorio y observar el modo en que esa intervención altera indicadores urbanos clave. El modelo se convierte así en una interfaz cognitiva y política porque hace inteligibles interdependencias que de otro modo permanecerían ocultas, y porque facilita que la discusión sobre el territorio se apoye en escenarios comparables y no solo en intuiciones, deseos o narrativas aisladas.

Sin embargo, el aporte más profundo está en la forma en que la plataforma permite pensar la planeación urbana como un problema de compensaciones sistémicas. El contraste entre el escenario actual y el escenario derivado del plan maestro muestra con claridad que ciertos cambios mejoran la diversidad de actividades y aumentan la densidad poblacional, pero al mismo tiempo pueden reducir coberturas o proximidades que también resultan decisivas para la calidad urbana, como el acceso relativo a áreas verdes o al transporte público. Esta constatación es crucial para un enfoque de complejidad. Por ello, el CityScope Guadalajara como una interfaz de simulación y evaluación contribuye a revelar que toda decisión territorial redistribuye ventajas, restricciones y oportunidades entre dimensiones que no siempre evolucionan en la misma dirección. La herramienta es útil, precisamente, porque obliga a pensar la ciudad como un campo de equilibrios inestables y relaciones cruzadas.

#### Elementos matemáticos del modelo

Si la utilidad de CityScope Guadalajara depende de su capacidad para hacer visible la complejidad urbana, ello se debe en gran medida a la estructura matemática que sustenta el modelo. El artículo no se conforma con proponer categorías generales de evaluación, sino que formaliza tres dimensiones —diversidad, funcionalidad e impacto ambiental— como sistemas de indicadores susceptibles de cálculo, comparación y representación espacial. Esta decisión es metodológicamente decisiva, porque transforma conceptos ampliamente utilizados en planeación urbana en variables operativas que pueden incorporarse a un entorno de simulación. En otras palabras, la plataforma no solo visualiza la ciudad: la cuantifica de acuerdo con una gramática matemática que permite relacionar formas urbanas, comportamientos y resultados agregados.

El primer componente matemático de especial relevancia es la medición de la diversidad mediante la entropía de Shannon.

La elección no es menor. La entropía introduce en el análisis urbano una lógica probabilística capaz de captar el grado de equilibrio o concentración entre distintos tipos de actividad. En este caso, las actividades se clasifican en diurnas, nocturnas, de interacción y de conocimiento intensivo, y la diversidad de una región se expresa como función de la proporción relativa de cada una de ellas.

Lo importante aquí es conceder que un territorio diverso es aquel donde la distribución funcional evita la dominancia extrema de una sola categoría. La matemática de la entropía hace visible, así, una propiedad típicamente compleja del sistema urbano: la mezcla funcional requiere una medida que capture la estructura de distribución. En este punto, el modelo avanza más allá del inventario urbano convencional y se aproxima a una lectura relacional del territorio.

La funcionalidad, por su parte, incorpora una matemática más heterogénea, en la que convergen razones espaciales, criterios de accesibilidad y condiciones de cobertura. En el nivel de la compacidad, aparecen indicadores de densidad que vinculan población, vivienda y actividades con la superficie. Estas expresiones son aparentemente elementales, pero su importancia radica en que convierten magnitudes físicas y sociales en relaciones comparables dentro del territorio.

La densidad poblacional se vuelve una forma de leer la intensidad con la que una porción de ciudad concentra vida, residencia y uso. En la práctica del modelo, esta lógica desciende incluso al nivel del bloque, donde el área se transforma a hectáreas para calcular población por unidad de superficie. Este paso muestra cómo la formalización matemática no permanece en el nivel conceptual, sino que se codifica en algoritmos concretos que operan sobre entidades espaciales precisas.

La segunda dimensión de la funcionalidad, vinculada con la habitabilidad y la movilidad, introduce un aspecto especialmente significativo para el estudio de fenómenos complejos: la matemática de los umbrales de acceso. En estos indicadores, lo decisivo ya no es solo cuánto equipamiento existe, sino qué proporción de la población puede efectivamente acceder a él bajo determinadas condiciones. Educación, cultura, salud y alternativas de transporte se modelan entonces mediante reglas que consideran cercanía, disponibilidad y mínimos requeridos.

Esta formulación desplaza el análisis desde la mera oferta física hacia la relación entre agentes y entorno. La ciudad deja de aparecer como una suma de objetos territoriales y comienza a representarse como una red de posibilidades diferenciales de acceso. El algoritmo de movilidad es especialmente ilustrativo en este sentido: identifica para cada persona los medios de transporte más próximos —autobús, BRT, tren eléctrico y ciclovía— y evalúa su accesibilidad a partir de distancias umbral. Matemáticamente, esto significa que el modelo trabaja con una espacialidad efectiva, no solo geométrica: importa menos la presencia abstracta de una infraestructura que la posibilidad concreta de que un agente la incorpore a su campo de acción. (Palomo et al., 2025; Roldán et al., 2025)

En cuanto al impacto ambiental, el artículo propone una estructura de cálculo basada en requerimientos de energía, agua y generación de residuos a escala de bloque, seguidos de procedimientos de agregación y normalización. Este punto es relevante porque pone de manifiesto que el modelo no persigue únicamente representar dinámicas so-

ciales o morfológicas, sino también vincularlas con costos metabólicos del territorio. El hecho de normalizar estos indicadores en una misma escala permite compararlos con otras dimensiones del sistema y evita que queden aislados como simples externalidades. Desde una perspectiva matemática, la normalización cumple aquí una función de traducción interdimensional: vuelve legibles dentro de un mismo tablero variables heterogéneas, permitiendo que la evaluación urbana adopte una lógica multicriterio. Este procedimiento es indispensable cuando se trabaja con sistemas complejos, porque en ellos ninguna dimensión por sí sola agota la comprensión del fenómeno.

Con todo, la aportación matemática más importante de la plataforma se supone en el modo en que estos quedan inscritos en una arquitectura de agentes. El sistema distingue agentes primarios —personas, bloques, áreas de intervención, proyectos, unidades económicas y el caso de estudio— y agentes auxiliares vinculados a la infraestructura y al entorno. Esta organización permite articular escalas micro y macro de una forma que resulta central para la teoría de la complejidad: los comportamientos locales de agentes individuales o de unidades espaciales específicas pueden agregarse y producir configuraciones globales del sistema. La matemática del modelo es, en este sentido, inseparable de su lógica computacional, planteando reglas de transición, activación de escenarios, procesos iterativos, dependencias espaciales y mecanismos de agregación que hacen posible el paso de la interacción situada al patrón emergente. CityScope Guadalajara muestra así que el modelado urbano complejo no se reduce a calcular indicadores sobre un mapa, sino que requiere construir un sistema formal en el que las propiedades del conjunto emerjan de la dinámica de sus componentes.

Bajo esta lectura, el interés de los elementos matemáticos del artículo es doble. Por una parte, proporcionan un lenguaje de formalización que vuelve mensurables atributos urbanos frecuentemente tratados de manera vaga o exclusivamente normativa. Por otra, permiten que esa formalización se inserte en una plataforma de simulación donde los resultados se actualizan espacial y temporalmente al modificarse el escenario. La matemática funciona aquí como una condición de posibilidad para que la visualización tenga espesor analítico y para que la participación disponga de una base rigurosa de comparación.

En consecuencia, CityScope Guadalajara puede entenderse como una propuesta donde la modelación matemática, el enfoque basado en agentes y la visualización tangible convergen en una misma operación de conocimiento: representar la ciudad como sistema complejo para hacer más reflexiva, informada y discutible la intervención urbana.

## 5.2. De las ciudades inteligentes a las ciudades cognitivas

Las ciudades inteligentes (*smart cities*) nacieron como respuesta a la necesidad de gestionar sistemas urbanos crecientemente interdependientes mediante tecnologías de información y comunicación, sensores, analítica de datos y plataformas digitales (Nam and Pardo, 2011; Batty et al., 2012; Townsend, 2013; Goldsmith and Crawford, 2014). La ciudad cognitiva (*cognitive city*) prolonga este mismo horizonte, partiendo de la base instrumental de la ciudad inteligente, pero añadiendo capacidades de interpretación,

aprendizaje, memoria, anticipación y coproducción humano-máquina de conocimiento urbano (Mostashari et al., 2011; Finger and Portmann, 2016; Tabacchi et al., 2019; Menon, 2022).

Los antecedentes de ambas visiones de ciudad son múltiples. Por un lado, la ciudad inteligente recoge herencias de la *digital city*, la *intelligent city*, la *ubiquitous city* y la *responsive city*, es decir, de tradiciones que entendieron el espacio urbano como una infraestructura informacional capaz de mejorar eficiencia, conectividad, sostenibilidad y capacidad de respuesta (Kominos, 2002; Nam and Pardo, 2011; Townsend, 2013; Goldsmith and Crawford, 2014). Por otro lado, la ciudad cognitiva se enlaza con una tradición distinta pero complementaria bajo una visión de ciudad como sistema complejo, adaptativo y cognitivo, en la que confluyen la teoría de la complejidad, la autoorganización, la construcción de mapas cognitivos, la inteligencia colectiva y, más recientemente, la computación cognitiva y el aprendizaje automático (Portugali, 1996; Portugali and Stolk, 2016b; Portugali, 2023).

En su formulación dominante, la ciudad inteligente fue concebida como una plataforma de integración de datos. Su premisa básica era que, si los distintos subsistemas urbanos se sensorizaban, interconectaban y analizaban en tiempo real, la ciudad podría operar de modo más eficiente y sostenible (Batty et al., 2012; Townsend, 2013; Goldsmith and Crawford, 2014). Esta visión produjo avances concretos, pero también recibió críticas importantes. Una de las más relevantes es que el paradigma *smart* tiende a ser tecnocrático y *top-down*, privilegiando el control, la medición y la optimización, pero dejando en segundo plano la complejidad social, la diversidad de valores, la creatividad ciudadana y los procesos de aprendizaje colectivo (Colding et al., 2018; Finger and Portmann, 2016; Tabacchi et al., 2019). Es decir, la ciudad inteligente puede volverse tener una base de obtención, gestión y análisis de datos muy robusta sin llegar por ello a comprender la ciudad. Las ciudades inteligentes recopilan y analizan datos en tiempo real, y cuentan con una densa capa de sensorización mediante IoT que provee un gran volumen de datos, utilizando métodos de optimización computacional se toman decisiones que inciden en temas como movilidad, gobernanza, energía, seguridad y muchos otros. Su propósito es la optimización y automatización de procesos urbanos. es en efecto, técnicamente impecable, pero no termina de resolver los problemas urbanos a este nivel. Portmann llama a esto, el cumplimiento de un *desafío de eficiencia* que resuelve técnicamente, pero que no toma en cuenta necesariamente, los requerimientos de las personas dentro de las ciudades (Portmann et al., 2018)

Las ciudades cognitivas consideran la interacción de los individuos, tomándolos como *sujetos cognitivos*, lo que promueve una inteligencia colectiva, que nutre a esta como si se tratara, con sus debidas reservas, claro está, de un ente que observa cierta autonomía, y que toma en cuenta, información multimodal que las ciudades inteligentes pueden no considerar. Las ciudades cognitivas parten de la base tecnológica de las ciudades inteligentes, pero observan una mayor disposición a la adaptabilidad y la resiliencia. las ciudades cognitivas aprenden constantemente, tanto de los datos estadísticos, como del comportamiento de sus propios agentes cognitivos (la ciudadanía). A través de la interacción ciudadanía-ciudad, esta puede actualizar el conocimiento y ajustar sus respuestas. Dentro de la IA generativa, utilizada como una plataforma para diseñar entornos urbanos, puede establecerse un canal de comunicación con módulos diseñados con ba-

ses neurocientíficas, para medir con mayor rigor, respuestas perceptuales-emocionales que producirían sesgos en métodos ordinarios de optimización

Mostashari et. al. describen la ciudad cognitiva como una ciudad en la que los sistemas urbanos no solo perciben estados del entorno, sino que ajustan su comportamiento en función de experiencias previas y de objetivos negociados entre múltiples actores (Mostashari et al., 2011). Menon resume esta evolución señalando que una ciudad cognitiva es aquella que puede sentir, entender, aprender y responder a cambios en entornos urbanos complejos mediante la convergencia entre IoT, big data, inteligencia artificial y sistemas ciberfísico-sociales (Menon, 2022). En este marco, la inteligencia urbana trasciende la infraestructura, y se asienta en la red de relaciones entre infraestructura, datos, interpretación y participación.

Desde el punto de vista formal, la ciudad inteligente puede representarse como un sistema dinámico multiobjetivo, donde un estado urbano agregado  $x_t$  evoluciona según entradas de control  $u_t$ , perturbaciones  $w_t$  y observaciones  $y_t$ :

$$x_{t+1} = f(x_t, u_t, w_t), \quad y_t = h(x_t) + v_t$$

donde  $v_t$  representa ruido o error de observación. En esta formulación, la gobernanza *smart* por ejemplo, consiste en estimar el estado urbano y seleccionar acciones  $u_t$  que optimicen ciertos objetivos operativos. Una formulación genérica es

$$u_{0:T-1}^* = \arg \min_{u_{0:T-1}} J = \arg \min_{u_{0:T-1}} \sum_{t=0}^{T-1} (\alpha_1 E_t + \alpha_2 T_t + \alpha_3 C_t - \alpha_4 Q_t)$$

sujeta a la dinámica del sistema, donde  $E_t$  puede representar consumo energético,  $T_t$  congestión o tiempo de viaje,  $C_t$  emisiones o costes operativos, y  $Q_t$  calidad de servicio o bienestar urbano; los coeficientes  $\alpha_i$  ponderan prioridades de política pública. Esta es una formalización típica del horizonte *smart*: observación, predicción y optimización (Batty et al., 2012; Townsend, 2013; Finger and Portmann, 2016).

Sin embargo, la ciudad cognitiva exige un formalismo más rico, por lo expuesto anteriormente. Una primera ampliación consiste en representar la ciudad como sistema multicapa:

$$\mathcal{U} = (G_{\text{phy}}, G_{\text{cyb}}, G_{\text{soc}}, x_t, u_t, y_t)$$

donde  $G_{\text{phy}}$  es la red física de infraestructuras,  $G_{\text{cyb}}$  la red digital y computacional, y  $G_{\text{soc}}$  la red de actores, instituciones y comunidades. Si  $A_{\text{phy}}, A_{\text{cyb}}, A_{\text{soc}}$  son sus matrices de adyacencia, una representación compacta de la ciudad multicapa es

$$A_{\mathcal{U}} = A_{\text{phy}} \oplus A_{\text{cyb}} \oplus A_{\text{soc}} + A_{\text{inter}}$$

donde  $A_{\text{inter}}$  codifica los acoplamientos entre capas. La diferencia decisiva es que, en la ciudad cognitiva, la capa social se considera como una fuente activa de conocimiento, interpretación y reconfiguración del sistema (Mostashari et al., 2011; Finger and Portmann, 2016; Tabacchi et al., 2019).

La transición desde lo *smart* hacia lo cognitivo también puede describirse como un paso desde la información hacia el conocimiento. Una forma elemental de representar

la complejidad informacional urbana proviene de la teoría de la información. Si un sistema urbano puede encontrarse en  $Z$  estados distinguibles, la información asociada a una observación puede expresarse como

$$I = \log_2 Z$$

En forma más general, si una variable urbana discreta  $X$  presenta distribución  $\{p_k\}_{k=1}^m$ , su entropía de Shannon es:

$$H(X) = - \sum_{k=1}^m p_k \log p_k$$

Estas expresiones permiten medir variedad, incertidumbre e información en sistemas urbanos sensorizados (Portugali and Stolk, 2016b). Pero una ciudad cognitiva no se define por maximizar datos ni por reducir ciegamente entropía, sino por convertir información dispersa en orientación significativa para la acción. Por eso Portugali insiste en que la ciudad compleja cuenta con una estructura material, pero con igual importancia, una estructura informacional y cognitiva (Portugali, 1996, 2023).

Otra formalización decisiva para pensar la ciudad como sistema complejo es la ley de escalamiento urbano. Si  $N$  es la población y  $Y$  una magnitud agregada de la ciudad (infraestructura, ingreso, innovación, crimen, consumo energético, etc.), una relación de escalamiento toma la forma

$$Y(N) = Y_0 N^\beta$$

En forma logarítmica,

$$\log Y = \log Y_0 + \beta \log N$$

Si  $\beta < 1$ , la magnitud escala sublinealmente (como ocurre a menudo con infraestructuras); si  $\beta = 1$ , escala linealmente; y si  $\beta > 1$ , escala superlinealmente, como en varios indicadores de innovación o interacción socioeconómica (Bettencourt, 2013). Esta formulación es relevante para la transición a la ciudad cognitiva porque muestra que el crecimiento urbano no implica solo más infraestructura o más datos, sino también nuevas propiedades emergentes derivadas de la densidad de interacciones humanas. La ciudad cognitiva puede entenderse, entonces, como un intento de gobernar reflexivamente esas externalidades cognitivas de la escala.

En este punto cobra especial relevancia la tradición de los mapas cognitivos. Desde Portugali, el estudio de la ciudad ha incorporado la idea de que los agentes no actúan sobre el espacio urbano tal cual es, sino sobre representaciones internas, compartidas o negociadas de ese espacio (Portugali, 1996). Si un mapa cognitivo se representa como un grafo dirigido

$$M = (C, W)$$

donde  $C = \{c_1, \dots, c_n\}$  es el conjunto de conceptos relevantes y  $W = [w_{ij}]$  una matriz de influencias causales entre esos conceptos, entonces la ciudad cognitiva puede ser modelada como una ecología de mapas cognitivos parciales e interdependientes.

Cuando esos mapas se formalizan como *mapas cognitivos difusos* (FCM), cada nodo  $c_i$  toma un nivel de activación  $a_i^{(t)} \in [0, 1]$ , y la dinámica del sistema puede escribirse como

$$a_i^{(t+1)} = \sigma \left( a_i^{(t)} + \sum_{j \neq i} w_{ji} a_j^{(t)} \right), \quad i = 1, \dots, n,$$

donde  $\sigma(\cdot)$  es una función de activación, habitualmente sigmoïdal o de saturación. En forma vectorial,

$$\mathbf{a}^{(t+1)} = \sigma \left( W^T \mathbf{a}^{(t)} + \mathbf{a}^{(t)} \right)$$

Este formalismo permite representar relaciones causales difusas entre variables urbanas como percepción de seguridad, congestión, satisfacción con el transporte, cohesión barrial o confianza institucional. En una ciudad cognitiva, el interés no consiste solo en predecir el estado del sistema, sino en explicitar y aprender cómo los actores urbanos entienden esas causalidades (Kosko, 1986; Portmann et al., 2019).

Una prolongación particularmente interesante de esta línea, presente en los textos de Portmann y colaboradores, es la verbalización de conocimiento urbano por medio de resúmenes lingüísticos. Si  $S$  es un predicado difuso que resume una propiedad urbana por ejemplo, *alto consumo energético* o participación elevada y  $Q$  un cuantificador difuso relativo como *la mayoría* o *casi todos*, la validez de un resumen lingüístico básico se calcula como (Hudec, 2019)

$$v(Qx(P(x))) = \mu_Q \left( \frac{1}{n} \sum_{i=1}^n \mu_S(x_i) \right)$$

donde  $n$  es el número de elementos observados,  $\mu_S(x_i)$  es el grado de pertenencia del caso  $x_i$  al resumidor  $S$ , y  $\mu_Q$  es la función de pertenencia del cuantificador difuso. Si además se introduce una restricción  $R$  —por ejemplo “edificios antiguos” o “ciudadanos jóvenes”—, la validez del resumen con restricción toma la forma

$$v(Qx(P(x) | R(x))) = \mu_Q \left( \frac{\sum_{i=1}^n t(\mu_S(x_i), \mu_R(x_i))}{\sum_{i=1}^n \mu_R(x_i)} \right),$$

donde  $t$  es una  $t$ -norma. Este tipo de formalismo es especialmente relevante para la ciudad cognitiva porque conecta datos masivos con formas de expresión comprensibles para los actores urbanos.

La transición hacia la ciudad cognitiva también puede entenderse como el paso desde una lógica reactiva hacia una lógica anticipatoria. En ese contexto resulta sugerente el formalismo de la energía libre variacional, que Portugali recupera para pensar la relación entre cognición y ciudad a partir de Friston (Friston, 2010; Portugali, 2023). Si  $o$  representa observaciones urbanas y  $s$  estados latentes del sistema, la energía libre puede escribirse como

$$F[q(s)] = \mathbb{E}_{q(s)} [\log q(s) - \log p(o, s)] = D_{\text{KL}}(q(s) \| p(s | o)) - \log p(o)$$

donde  $q(s)$  es una distribución aproximada sobre estados latentes y  $D_{KL}$  es la divergencia de Kullback–Leibler. Minimizar  $F$  equivale a reducir incertidumbre y mejorar la inferencia sobre las causas ocultas de las observaciones. Trasladado al caso urbano, este formalismo permite pensar una ciudad como un sistema que aprende modelos de su entorno y ajusta sus expectativas, sus intervenciones y sus umbrales de alarma e intenta inferir patrones, anticipar disrupciones y aprender de la experiencia.

Existe, además, una dimensión propiamente política de esta transición. La ciudad cognitiva no solo requiere más inteligencia algorítmica, sino también una madurez participativa mayor. En el modelo de Terán, Kaskina y Meier, la participación electrónica urbana puede representarse como una variable ordinal

$$m \in \{1, 2, 3, 4, 5\}$$

donde  $m = 1$  corresponde a *eInforming*,  $m = 2$  a *eConsulting*,  $m = 3$  a *eDiscussion*,  $m = 4$  a *eParticipation* y  $m = 5$  a *eEmpowerment* (Terán et al., 2016). Esta formalización es simple, pero relevante: indica que el paso de lo *smart* a lo cognitivo implica conducirse mediante procesos de comunicación, colaboración y empoderamiento ciudadano horizontal.

En conjunto, estos formalismos muestran que la ciudad cognitiva no es una simple etiqueta *pos-smart*. Es el resultado de una ampliación conceptual precisa. Mientras la ciudad inteligente opera principalmente con modelos de sensado, coordinación y optimización, la ciudad cognitiva exige además modelos de interpretación, aprendizaje, representación causal, expresión lingüística, anticipación y participación reflexiva. En este sentido, la transición entre ambas visiones puede resumirse así: la ciudad inteligente busca hacer más eficiente el sistema urbano; la ciudad cognitiva busca hacer a la ciudad capaz de aprender de sí misma y de sus ciudadanos (Mostashari et al., 2011; Finger and Portmann, 2016; Tabacchi et al., 2019; Menon, 2022).

La definición y funcionamiento de una ciudad cognitiva se fundamentan en: Gobernanza y Aprendizaje: La ciudad cognitiva implica la existencia de aprendizaje, creación de memoria y recuperación de experiencias para la mejora continua de la gobernanza urbana. Es una ciudad que aprende y adapta su comportamiento para detectar, comprender y responder a los cambios en el entorno. Simbiosis Humano-Máquina: El concepto se basa en el diseño de la comunicación, la interacción y el juego de la ciudad, vista como un sistema de sistemas, mediante sistemas cognitivos. Se enfoca en la comunicación entre las partes interesadas (stakeholders) y los sistemas cognitivos para crear una simbiosis humano-máquina, en la que humanos y máquinas interactúan directamente. Servicios Proactivos: Una ciudad cognitiva permitirá a cada ciudadano y negocio obtener beneficios proactivamente de la ciudad sin necesidad de tener que iniciar sesión y solicitar la administración. La ciudad recopila, analiza y distribuye información de manera inteligente a través de tecnologías, aprovechando los datos para tomar decisiones y satisfacer las necesidades de los usuarios. La diferencia principal entre una ciudad cognitiva y una *smart city* radica en el enfoque en la cognición, el aprendizaje y la participación ciudadana, superando las limitaciones tecnológicas de la *smart city*.

Mientras que una *smart city* es un término que designa un entorno urbano que utiliza sensores para gestionar y rastrear sistemas de manera eficiente, con el objetivo de mejorar el estilo de vida de las personas, la ciudad cognitiva va un paso más allá

Aspecto	Smart City (SC)	Ciudad Cognitiva (CC)
<b>Enfoque Principal</b>	Se centra en la aplicación de TIC para lograr la eficiencia y el desarrollo sostenible.	Se centra en el aprendizaje (a través de la memoria y la experiencia) y la resiliencia.
<b>Rol del Ciudadano</b>	Tradicionalmente vista como un enfoque altamente tecnocrático, con falta de participación de los interesados.	El ciudadano es un elemento activo de la gobernanza urbana y un sensor, participando directamente en la toma de decisiones y el diseño de la ciudad.
<b>Manejo de Datos</b>	Utiliza principalmente métodos estadísticos para optimizar la eficiencia y el análisis de datos.	Complementa los métodos con técnicas de <i>soft computing</i> (como la lógica difusa) y métodos cognitivos para manejar datos imprecisos, inciertos y vagos (que reflejan percepciones).
<b>Relación Humano-Máquina</b>	La tecnología es el principal impulsor del desarrollo.	Se busca la colaboración entre humanos y sistemas cognitivos para crear una simbiosis humano-máquina.

**Tabla 5.1** Comparación entre el enfoque de Smart City y el de Ciudad Cognitiva.

al integrar la inteligencia artificial y la cognición humana para mejorar la toma de decisiones y la asignación de recursos. Este enfoque es más que simplemente optimizar los sistemas existentes con sensores; implica la integración de capacidades cognitivas en la infraestructura.

Las ciudades cognitivas abordan un amplio espectro de desafíos urbanos, especialmente aquellos que las smart cities no logran resolver completamente con un enfoque puramente tecnológico y centrado en la eficiencia. Al integrar la cognición, el aprendizaje y la participación, las ciudades cognitivas buscan la resiliencia y la sostenibilidad a largo plazo.

Los desafíos que las ciudades cognitivas se proponen abordar se dividen en tres categorías principales:

1. **Desafíos Ambientales y de Recursos** Las ciudades cognitivas se centran en los desafíos generados por la urbanización acelerada, la degradación ambiental y la limitada disponibilidad de recursos.

**Mitigación de emisiones y cambio climático:** Las zonas urbanas son responsables de más del 70 % del consumo mundial de energía y las emisiones de  $CO_2$

Las ciudades cognitivas buscan un desarrollo sostenible de cero emisiones de carbono para reducir la salida de gases de efecto invernadero.

**Contaminación y salud ecológica:** Buscan superar los problemas ecológicos y de salud mediante el control de la contaminación y el monitoreo de la calidad del aire.

**Gestión de recursos críticos:** Los marcos de las ciudades cognitivas abordan la escasez de recursos vitales y la necesidad de sistemas inteligentes para la administración del agua. Un desafío principal es cómo reducir la huella de carbono generada por la

industria, las áreas residenciales y comerciales, el sector del transporte y el sector de residuos.

**Adaptación ambiental:** Las ciudades cognitivas buscan responder al aumento de las concentraciones de  $CO_2$  que conducen a la alteración de la temperatura global, el cambio climático, el aumento del nivel del mar, las inundaciones por tormentas y los episodios de calor extremo.

**2. Desafíos Operacionales y de Infraestructura** Las ciudades cognitivas se enfocan en optimizar los sistemas de infraestructura para mejorar la calidad de vida de los ciudadanos y la seguridad operativa. **Tráfico y movilidad urbana:** Las ciudades cognitivas abordan la congestión de vehículos, la contaminación y los accidentes automovilísticos causados por el aumento del transporte de pasajeros y carga. También buscan optimizar el flujo de tráfico y prevenir accidentes mediante el monitoreo.

**Salud y bienestar:** Proponen sistemas de atención médica electrónica (e-health) para la adquisición automática de información de salud y la toma de decisiones eficientes. Esto incluye el monitoreo constante de la salud y la identificación de problemas médicos antes de su ocurrencia y la mitigación de enfermedades. **Seguridad pública:** Las ciudades cognitivas buscan garantizar la seguridad y protección de las personas y sus propiedades. Esto se logra mediante sistemas de videovigilancia inteligentes capaces de interpretar situaciones y reconocer automáticamente anomalías. **Mantenimiento y fallas:** Las ciudades cognitivas buscan superar los problemas de mantenimiento inadecuado y las fallas en los sistemas de monitoreo que afectan las operaciones de la ciudad. Esto incluye la reparación automatizada de problemas relacionados con agua, energía, gas y residuos detectados por sensores en vehículos o medidores inteligentes. **3. Desafíos de Gobernanza y Sociales** Las ciudades cognitivas abordan las limitaciones de los modelos tecnocráticos de las SCs, buscando la inclusión humana y la toma de decisiones informada. **Falta de participación y enfoque tecnocrático:** El concepto de ciudad cognitiva busca compensar el déficit de la SC, cuyo enfoque altamente tecnocrático a menudo se acompaña de una falta de participación de los interesados en la mejora de los procesos urbanos. Las ciudades cognitivas buscan fomentar la participación cívica activa y la cooperación entre la tecnología y las mentes humanas.

**Complejidad y conflicto de intereses:** La gobernanza urbana se complica porque los intereses de los diversos actores (stakeholders) a menudo no están bien definidos o no están alineados (complejidad evaluativa). Las ciudades cognitivas buscan soluciones satisfactorias a estos conflictos (como equilibrar la eficiencia frente a la dignidad en el transporte para ancianos)

**Preservación del conocimiento:** Un desafío clave es la creación y preservación continua del conocimiento urbano, o inteligencia urbana, que evoluciona mediante la combinación y el juego de inteligencias individuales (personas, dispositivos electrónicos)

### 5.3. Conclusiones

Una de las conclusiones principales de este trabajo es que la ciencia de la ciudad requiere asumir a los sistemas complejos no sólo como una metáfora general de interdependencia, sino como una base formal de modelado para la comprensión de los

sistemas socioecotécnicos que constituyen la realidad urbana. A lo largo de los capítulos se mostró que la teoría general de sistemas, la teoría del caos, la cibernética, la auto-organización, la emergencia, la jerarquía y, posteriormente, los enfoques biológicos de la complejidad, proporcionan un horizonte más adecuado para pensar la ciudad como una totalidad abierta, multiescalar, no lineal y evolutiva.

#### Los sistemas complejos como base de modelado de los sistemas socioecotécnicos

Desde esta perspectiva, la ciudad se reconoce como una configuración dinámica en la que interactúan sociedad, tecnología, ambiente construido y entorno natural. En este marco, dos aportaciones del manuscrito adquieren especial relevancia. La primera es el modelo categórico del *Topos*, propuesto como un metamodelo matemático capaz de formalizar relaciones, acoplamientos, niveles de organización y procesos emergentes sin reducir la complejidad urbana a una simple agregación de variables. Su importancia consiste en ofrecer una gramática relacional para representar cómo se vinculan y transforman estructuras heterogéneas dentro de entornos complejos. La segunda es *CityScope*, cuya utilidad excede la visualización técnica y se proyecta como una plataforma de modelado, simulación y deliberación para problemas urbanos complejos. Su valor radica en hacer operativa la complejidad, al permitir observar cómo decisiones locales producen efectos globales, cómo distintas variables territoriales interactúan entre sí y cómo los escenarios urbanos pueden discutirse a partir de representaciones comparables. Estas herramientas fortalecen la capacidad de la ciencia de la ciudad para estudiar los sistemas socioecotécnicos con un rigor formal que mantenga y acepte su heterogeneidad, al mismo tiempo que la vuelve inteligible y analíticamente tratable.

#### Las ciencias cognitivas como eje transversal de los sistemas urbanos biopsicofísicos

La segunda conclusión de fondo es que la complejidad urbana no puede comprenderse de manera suficiente mientras la experiencia humana permanezca relegada a un plano secundario del análisis. El manuscrito sostuvo que la ciudad no sólo se organiza en la escala de sus redes, flujos e infraestructuras, sino también en la escala de la percepción, la memoria, la atención, la emoción, la orientación y la decisión de quienes la habitan. En este sentido, las ciencias cognitivas y, con particular énfasis, la neurociencia, aparecen como un eje transversal necesario para el estudio de los sistemas urbanos biopsicofísicos. Esta incorporación busca reconocer que entre el entorno construido y la acción humana existe una zona de mediación corporal, cognitiva y afectiva que participa activamente en la producción y reproducción de lo urbano.

Aquí se sitúa la tercera aportación principal del libro: la metodología de arquitecturas cognitivas basadas en neurociencia, entendida como una vía para traducir funciones cognitivas humanas en estructuras artificiales explícitas y operables. Su interés para la ciencia de la ciudad reside en la posibilidad de diseñar agentes virtuales inteligentes capaces de modelar de manera más verosímil procesos de percepción, aprendizaje, memoria de trabajo, atención selectiva y toma de decisiones bajo incertidumbre. Gracias a ello, la intersección entre sistemas socioecotécnicos y sistemas biopsicofísicos

puede formularse con mayor precisión: las estructuras urbanas condicionan la experiencia humana al modular cargas cognitivas, trayectorias, exposiciones, posibilidades de interacción y formas de bienestar o estrés; al mismo tiempo, los patrones agregados de percepción, adaptación, comportamiento y aprendizaje reingresan a la ciudad como transformación espacial, demanda de infraestructura, conflicto, apropiación del entorno y reorganización territorial. La ciudad cognitiva se perfila así como un marco en el que la escala macro de la organización urbana y la escala micro de la experiencia humana dejan de tratarse como dominios escindidos y comienzan a entenderse como dimensiones acopladas de un mismo sistema complejo.

Este trabajo concluye que la transición desde la ciudad inteligente hacia la ciudad cognitiva exige una ampliación simultánea del lenguaje teórico, del aparato formal y de las herramientas de simulación de la ciencia de la ciudad. Las arquitecturas cognitivas ofrecen un plano metodológico para incorporar funciones humanas en agentes y modelos; el *Topos* proporciona un plano matemático-relacional para representar estructuras complejas sin colapsar su diversidad; y *CityScope* constituye un plano operativo y experimental para explorar escenarios, visualizar interdependencias y abrir la modelación urbana a procesos de deliberación más informados. La convergencia de estas tres aportaciones permite sostener que una ciencia de la ciudad verdaderamente adecuada a los problemas contemporáneos debe ser capaz de articular complejidad, cognición, matemáticas y territorio en una misma arquitectura de análisis. Sólo en esa intersección será posible avanzar hacia modelos urbanos que no se limiten a optimizar la ciudad como artefacto técnico, sino que permitan comprenderla también como sistema vivo, cognitivo y evolutivo, producido y transformado continuamente por la relación entre sus macroestructuras socioecotécnicas y la experiencia humana que les da sentido.

## Referencias

- Aaronson, S. and Wigderson, A. (2009). Algebrization: A new barrier in complexity theory. *ACM Transactions on Computation Theory*, 1(1):2:1–2:54.
- Ancora, L. A., Blanco-Mora, D. A., Alves, I., Bonifácio, A., Morgado, P., and Miranda, B. (2022). Cities and neuroscience research: A systematic literature review. *Frontiers in Psychiatry*, 13:983352.
- Anderson, P. W. (1972). More is different. *Science*, 177(4047):393–396.
- Annaswamy, A. M., Khargonekar, P. P., Lamnabhi-Lagarrigue, F., and Spurgeon, S. K., editors (2023). *Cyber-Physical-Human Systems: Fundamentals and Applications*. Wiley-IEEE Press, Hoboken, NJ.
- Arora, S. and Barak, B. (2009). *Computational Complexity: A Modern Approach*. Cambridge University Press, Cambridge.
- Ashby, W. R. (1956). *An Introduction to Cybernetics*. Wiley, New York.
- Assem, H. M., Khodeir, L. M., and Fathy, F. (2023). Designing for human wellbeing: the integration of neuroarchitecture in design—a systematic review. *Ain Shams Engineering Journal*, page 102102.
- Attaianesi, E., Barilà, M., and Perillo, M. (2025). Exploring neuroscientific approaches to architecture: Design strategies of the built environment for improving human performance. *Buildings*, 15(19):3524.
- Baas, N. A. (2006). Hyperstructures as abstract matter. *Advances in Complex Systems*, 9(03):157–182.
- Baas, N. A. (2009). Hyperstructures, topology and datasets. *Axiomathes*, 19(3):281–295.
- Baas, N. A. (2013). On structure and organization: an organizing principle. *International Journal of General Systems*, 42(2):170–196.
- Baas, N. A., Ehresmann, A. C., and Vanbreemersch, J.-P. (2004). Hyperstructures and memory evolutive systems. *International Journal of General Systems*, 33(5):553–568.
- Baas, N. A. and Emmeche, C. (1997). On emergence and explanation. *Intellectica*, 25(2):67–83.
- Baianu, I. C., Brown, R., and Glazebrook, J. F. (2007). Categorical ontology of complex spacetime structures: The emergence of life and human consciousness. *Axiomathes*, 17(3–4):223–352.
- Baianu, I. C., Brown, R., and Glazebrook, J. F. (2011). A category theory and higher dimensional algebra approach to complex systems biology, meta-systems and ontological theory of levels: Emergence of life, society, human consciousness and artificial intelligence. *Acta Universitatis Apulensis*, pages 176–298. Special Issue on Understanding Complex Systems.
- Baker, T., Gill, J., and Solovay, R. (1975). Relativizations of the  $P = ?NP$  question. *SIAM Journal on Computing*, 4(4):431–442.
- Barbrook-Johnson, P. and Carrick, J. (2022). Combining complexity-framed research methods for social research. *International Journal of Social Research Methodology*, 25(6):835–848.

- Bassett, D. S. and Sporns, O. (2017). Network neuroscience. *Nature Neuroscience*, 20(3):353–364.
- Batty, M. (2012). Building a science of cities. *Cities*, 29:S9–S16.
- Batty, M. (2013). *The new science of cities*. MIT press.
- Batty, M. (2018). *Inventing future cities*. MIT press.
- Batty, M., Axhausen, K. W., Giannotti, F., Pozdnoukhov, A., Bazzani, A., Wachowicz, M., Ouzounis, G., and Portugali, J. (2012). Smart cities of the future. *The European Physical Journal Special Topics*, 214(1):481–518.
- Bechtel, W. (2008). *Mental Mechanisms: Philosophical Perspectives on Cognitive Neuroscience*. Routledge, New York.
- Ben Shalom, D. and Poeppel, D. (2008). Functional anatomic models of language: assembling the pieces. *The Neuroscientist*, 14(1):119–127.
- Bertuglia, C. S. and Vaio, F. (2005). *Nonlinearity, chaos, and complexity: The dynamics of natural and social systems*. OUP Oxford.
- Bettencourt, L. M. (2021). *Introduction to urban science: evidence and theory of cities as complex systems*. MIT press.
- Bettencourt, L. M. A. (2013). The origins of scaling in cities. *Science*, 340(6139):1438–1441.
- Binder, J. R. and Desai, R. H. (2011). The neurobiology of semantic memory. *Trends in cognitive sciences*, 15(11):527–536.
- Binder, J. R., Desai, R. H., Graves, W. W., and Conant, L. L. (2009). Where is the semantic system? a critical review and meta-analysis of 120 functional neuroimaging studies. *Cerebral Cortex*, 19(12):2767–2796.
- Blunden, A. (2012). *Concepts: A critical approach*. Brill.
- Bornkessel-Schlesewsky, I. and Schlesewsky, M. (2016). The argument dependency model. In *Neurobiology of language*, pages 357–369. Elsevier.
- Boschetti, F., Prokopenko, M., Macreadie, I., and Grisogono, A.-M. (2005). Defining and detecting emergence in complex networks. In *International Conference on Knowledge-Based and Intelligent Information and Engineering Systems*, pages 573–580. Springer.
- Boulding, K. E. (1956). General systems theory—the skeleton of science. *Management Science*, 2(3):197–208.
- Bowman, H., Su, L., and Barnard, P. (2006). Semantic modulation of temporal attention: Distributed control and levels of abstraction in computational modelling. *Kent Academic Repository*.
- Bradley, T.-D., Bryson, T., and Terilla, J. (2020). *Topology: A Categorical Approach*. The MIT Press, Cambridge, MA.
- Brown, R. (2009). Review: Memory evolutive systems. *Axiomathes*, 19(3):271–280.
- Brown, R. and Porter, T. (2003). Category theory and higher dimensional algebra: Potential descriptive tools in neuroscience. In Singh, N., editor, *Proceedings of the International Conference on Theoretical Neurobiology*, volume 1, pages 80–92, Delhi. National Brain Research Centre.
- Byrne, D. and Callaghan, G. (2013). *Complexity Theory and the Social Sciences: The State of the Art*. Routledge, London.
- Carr, R. and O’Mahony, K. (2019). *Brain-centric design: The surprising neuroscience behind learning with deep understanding*. Carr Knowledge.

- Cassens, J. and Wegener, R. (2008). Making use of abstract concepts—systemic-functional linguistics and ambient intelligence. In *IFIP International Conference on Artificial Intelligence in Theory and Practice*, pages 205–214. Springer.
- Cassey, P. J., Gaut, G., Steyvers, M., and Brown, S. D. (2016). A generative joint model for spike trains and saccades during perceptual decision-making. *Psychonomic bulletin & review*, 23(6):1757–1778.
- Cencini, M., Cecconi, F., and Vulpiani, A. (2010). *Chaos: From Simple Models to Complex Systems*. World Scientific, Singapore.
- Chiamulera, C., Ferrandi, E., Benvegnù, G., Ferraro, S., Tommasi, F., Maris, B., Zandonai, T., and Bosi, S. (2017). Virtual reality for neuroarchitecture: cue reactivity in built spaces. *Frontiers in psychology*, 8:185.
- Churchland, P. S. (1986). *Neurophilosophy: Toward a Unified Science of the Mind-Brain*. MIT Press, Cambridge, MA.
- Clark, A. and Chalmers, D. (1998). The extended mind. *Analysis*, 58(1):7–19.
- Clay Mathematics Institute (2026). P vs np. <https://www.claymath.org/millennium/p-vs-np/>. Consultado el 7 de abril de 2026.
- Cobham, A. (1965). The intrinsic computational difficulty of functions. In Bar-Hillel, Y., editor, *Logic, Methodology and Philosophy of Science: Proceedings of the 1964 International Congress*, pages 24–30. North-Holland, Amsterdam.
- Colding, J., Colding, M., and Barthel, S. (2018). The smart city model: A new panacea for urban sustainability or unmanageable complexity? *Environment and Planning B: Urban Analytics and City Science*, 45(1):179–187.
- Cook, S. (2006). The p versus np problem. In Jaffe, A., editor, *The Millennium Prize Problems*, pages 87–104. Clay Mathematics Institute, Cambridge, MA.
- Cook, S. A. (1971). The complexity of theorem-proving procedures. In *Proceedings of the Third Annual ACM Symposium on Theory of Computing*, pages 151–158.
- Cook, S. A. (1981). Towards a complexity theory of synchronous parallel computation. *L'Enseignement Mathématique*, 27(1–2):99–124.
- Cook, S. A. (1983). An overview of computational complexity. *Communications of the ACM*, 26(6):400–408.
- Cook, S. A. and Reckhow, R. A. (1979). The relative efficiency of propositional proof systems. *The Journal of Symbolic Logic*, 44(1):36–50.
- Corredor, K. and Cárdenas, F. P. (2017). Neuro-«lo que sea»: inicio y auge de una pseudociencia para el siglo xxi. *Revista Latinoamericana de Psicología*, 49(2):89–90.
- Craver, C. F. (2007). *Explaining the Brain: Mechanisms and the Mosaic Unity of Neuroscience*. Clarendon Press, Oxford.
- D'Acci, L. (2019). *The Mathematics of Urban Morphology*. Birkhäuser, Cham, Switzerland.
- De Domenico, M., Brockmann, D., Camargo, C., Gershenson, C., Goldsmith, D., Jeschonnek, S., Kay, L., Nichele, S., Nicolás, J., Schmickl, T., et al. (2019). Complexity explained.
- de Marchi, S. (2005). *Computational and Mathematical Modeling in the Social Sciences*. Cambridge University Press, Cambridge.

- de Paiva, A. (2018). Neuroscience for architecture: how building design can influence behaviors and performance. *Journal of Civil Engineering and Architecture*, 12(2):132–38.
- de Paiva, A. and Jedon, R. (2019). Short-and long-term effects of architecture on the brain: Toward theoretical formalization. *Frontiers of architectural research*, 8(4):564–571.
- Dekkers, R. (2017). *Applied systems theory*. Springer.
- Di Lollo, V. (2012). The feature-binding problem is an ill-posed problem. *Trends in cognitive sciences*, 16(6):317–321.
- Dourish, P. (2004). What we talk about when we talk about context. *Personal and ubiquitous computing*, 8(1):19–30.
- D’Onofrio, S. and Portmann, E. (2017). Cognitive computing in smart cities. *Informatik-Spektrum*, 40(1):46–57.
- Edelman, G. M. (1989). *The Remembered Present: A Biological Theory of Consciousness*. Basic Books, New York.
- Ehresmann, A. C. and Gomez-Ramirez, J. (2015). Conciliating neuroscience and phenomenology via category theory. *Progress in Biophysics and Molecular Biology*, 119(3):347–359.
- Ehresmann, A. C. and Gómez-Ramírez, J. (2015). Conciliating neuroscience and phenomenology via category theory. *Progress in Biophysics and Molecular Biology*, 119(3):347–359.
- Ehresmann, A. C. and Vanbremeersch, J.-P. (2006). The memory evolutive systems as a model of rosen’s organisms–(metabolic, replication) systems. *Axiomathes*, 16(1-2):137–154.
- Ehresmann, A. C. and Vanbremeersch, J.-P. (2007). *Memory evolutive systems; hierarchy, emergence, cognition*, volume 4. Elsevier.
- Ehresmann, A. C. and Vanbremeersch, J.-P. (2009). Mens, a mathematical model for cognitive systems. *Journal of Mind Theory*, 0(2):129–180.
- Eilenberg, S. and Mac Lane, S. (1945). The general theory of natural equivalences. *Transactions of the American Mathematical Society*, 58(2):231–294.
- Erciyes, K. (2014). *Complex networks: an algorithmic perspective*. CRC Press.
- Feigenbaum, M. J. (1978). Quantitative universality for a class of nonlinear transformations. *Journal of Statistical Physics*, 19(1):25–52.
- Fernandino, L., Binder, J. R., Desai, R. H., Pendl, S. L., Humphries, C. J., Gross, W. L., Conant, L. L., and Seidenberg, M. S. (2016). Concept representation reflects multimodal abstraction: A framework for embodied semantics. *Cerebral Cortex*, 26(5):2018–2034.
- Finger, M. and Portmann, E. (2016). What are cognitive cities? In Portmann, E. and Finger, M., editors, *Towards Cognitive Cities: Advances in Cognitive Computing and its Application to the Governance of Large Urban Systems*, pages 1–11. Springer, Cham.
- Friederici, A. D. (2011). The brain basis of language processing: from structure to function. *Physiological reviews*, 91(4):1357–1392.
- Friston, K. (2010). The free-energy principle: A unified brain theory? *Nature Reviews Neuroscience*, 11(2):127–138.

- Gallagher, S. (2017). *Enactivist Interventions: Rethinking the Mind*. Oxford University Press, Oxford.
- Gärdenfors, P. (2005). Concept learning and nonmonotonic reasoning. In *Handbook of Categorization in Cognitive Science*, pages 823–843. Elsevier.
- Gende, I. M. and García, J. A. M. (2026). Neurocosas: Por qué el prefijo “neuro” no convierte cualquier idea en ciencia. *The Conversation*.
- Gershenson, C. (2025). Complexity, artificial life, and artificial intelligence. *Artificial Life*, 31(3):289–303.
- Gibbs Jr, R. W. (2006). Metaphor interpretation as embodied simulation. *Mind & Language*, 21(3):434–458.
- Goldsmith, S. and Crawford, S. (2014). *The Responsive City: Engaging Communities Through Data-Smart Governance*. Jossey-Bass, San Francisco.
- Gómez-Ramírez, J. (2014). *A New Foundation for Representation in Cognitive and Brain Science: Category Theory and the Hippocampus*, volume 7 of *Springer Series in Cognitive and Neural Systems*. Springer, Dordrecht.
- González-Arellano, S. (2025). Cities as anticipatory systems. In *Cities as Anticipatory Systems*, pages 13–30. Springer.
- Gordon, I. E. (2004). *Theories of visual perception*. Psychology Press.
- Hagoort, P. and Indefrey, P. (2014). The neurobiology of language beyond single words. *Annual review of neuroscience*, 37:347–362.
- Haken, H. (2007). Synergetics. *Scholarpedia*, 2(1):1400.
- Haken, H. (2008). Self-organization. *Scholarpedia*, 3(8):1401.
- Haken, H. and Portugali, J. (2016). Information and selforganization: A unifying approach and applications. *Entropy*, 18(6):197.
- Hartmanis, J. and Stearns, R. E. (1965). On the computational complexity of algorithms. *Transactions of the American Mathematical Society*, 117:285–306.
- Hoffmann, H. and Payton, D. W. (2018). Optimization by self-organized criticality. *Scientific Reports*, 8:2358.
- Hudec, M. (2019). Possibilities for linguistic summaries in cognitive cities. In Portmann, E., Tabacchi, M. E., Seising, R., and Habenstein, A., editors, *Designing Cognitive Cities*, pages 47–84. Springer, Cham.
- Hutchins, E. (1995). *Cognition in the Wild*. MIT Press, Cambridge, MA.
- Indefrey, P. and Levelt, W. J. (2004). The spatial and temporal signatures of word production components. *Cognition*, 92(1-2):101–144.
- Irish, M. and Piguet, O. (2013). The pivotal role of semantic memory in remembering the past and imagining the future. *Frontiers in behavioral neuroscience*, 7:27.
- Jackendoff, R. and Jackendoff, R. S. (2002). *Foundations of language: Brain, meaning, grammar, evolution*. Oxford University Press, USA.
- Jiménez, J. P., Martín, L., Dounce, I. A., Ávila-Contreras, C., and Ramos, F. (2021). Methodological aspects for cognitive architectures construction: a study and proposal. *Artificial Intelligence Review*, 54(3):2133–2192.
- Jiménez, J. P. (2017). *Topos como metaconstrucción para el diseño en arquitectura: del espacio analógico al metaespacio conceptual*. Phd thesis, UAEMEX, Cerro de Coatepec S/N. Available at <http://hdl.handle.net/20.500.11799/49191>
- Kapron, B. M., editor (2023). *Logic, Automata, and Computational Complexity: The Works of Stephen A. Cook*. Association for Computing Machinery, New York.

- Karp, R. M. (1972). Reducibility among combinatorial problems. In Miller, R. E. and Thatcher, J. W., editors, *Complexity of Computer Computations*, pages 85–103. Plenum Press, New York.
- Klüver, J., Stoica, C., and Schmidt, J. (2003). Formal models, social theory and computer simulations: Some methodical reflections. *Journal of Artificial Societies and Social Simulation*, 6(2):8.
- Komninos, N. (2002). *Intelligent Cities: Innovation, Knowledge Systems and Digital Spaces*. Spon Press, London.
- Kopetz, H. (2019). *Simplicity is Complex: Foundations of Cyber-Physical System Design*. Springer, Cham.
- Kosko, B. (1986). Fuzzy cognitive maps. *International Journal of Man-Machine Studies*, 24(1):65–75.
- Ladner, R. E. (1975). On the structure of polynomial time reducibility. *Journal of the ACM*, 22(1):155–171.
- Ladyman, J. and Wiesner, K. (2020). *What is a Complex System?* Yale University press.
- Lambert, K. G., Nelson, R. J., Jovanovic, T., and Cerdá, M. (2015). Brains in the city: Neurobiological effects of urbanization. *Neuroscience & Biobehavioral Reviews*, 58:107–122.
- Land, M. F. (2014). Do we have an internal model of the outside world? *Philosophical Transactions of the Royal Society B: Biological Sciences*, 369(1636):20130045.
- Lawvere, F. W. and Schanuel, S. H. (2009). *Conceptual mathematics: a first introduction to categories*. Cambridge University Press.
- Learned-Miller, E. G. (2013). Entropy and mutual information. *Department of Computer Science, University of Massachusetts, Amherst*, 4.
- Lieto, A. (2014). A computational framework for concept representation in cognitive systems and architectures: Concepts as heterogeneous proxytypes. *Procedia Computer Science*, 41:6–14.
- Lorenz, E. N. (1963). Deterministic nonperiodic flow. *Journal of the Atmospheric Sciences*, 20(2):130–141.
- Maleki, M. R. and Bayzidi, Q. (2017). Application of neuroscience on architecture: The emergence of new trend of neuroarchitecture. *Kurdistan Journal of Applied Research*, 2(3):383–396.
- Martin, A. (2007a). Neural foundations for conceptual representations: Evidence from functional brain imaging. *Neural basis of semantic memory*, pages 302–330.
- Martin, A. (2007b). The representation of object concepts in the brain. *Annu. Rev. Psychol.*, 58:25–45.
- Maturana, H. R. (1988). Reality: The search for objectivity or the quest for a compelling argument. *The Irish Journal of Psychology*, 9(1):25–82.
- Maturana, H. R. (2009). *La realidad: ¿objetiva o construida?* Universidad Iberoamericana, México.
- Maturana, H. R. and Varela, F. J. (1973). Autopoiesis: The organization of living systems, its characterization and a model. *Biosystems*, 5(4):187–196.
- Maturana, H. R. and Varela, F. J. (1980). *Autopoiesis and Cognition: The Realization of the Living*, volume 42 of *Boston Studies in the Philosophy of Science*. D. Reidel Publishing Company, Dordrecht.

- Maturana, H. R. and Varela, F. J. (1992). *The Tree of Knowledge: The Biological Roots of Human Understanding*. Shambhala, Boston.
- May, K. (2024). What is artificial intelligence? <https://www.nasa.gov/what-is-artificial-intelligence/>. Accessed: 2026-4-9.
- Menon, V. G. (2022). Cognitive smart cities: Challenges and trending solutions. *Expert Systems*, 39:e12981.
- Mershon, C. and Shvetsova, O. (2019). *Formal Modeling in Social Science*. University of Michigan Press, Ann Arbor.
- Metzger, C. (2018). *Neuroarchitektur*. Jovis.
- Mitchell, M. (2009). *Complexity: A guided tour*. Oxford university press.
- Morin, E. (1977). *La Méthode 1: La Nature de la Nature*. Seuil, Paris.
- Morin, E. (1994). *Introducción al pensamiento complejo*. Gedisa, Barcelona.
- Morin, E. (2008). *On Complexity*. Advances in Systems Theory, Complexity, and the Human Sciences. Hampton Press, Cresskill, NJ.
- Mostashari, A., Arnold, F., Mansouri, M., and Finger, M. (2011). Cognitive cities and intelligent urban governance. *Network Industries Quarterly*, 13(3):4–7.
- Nam, T. and Pardo, T. A. (2011). Conceptualizing smart city with dimensions of technology, people, and institutions. In *Proceedings of the 12th Annual International Digital Government Research Conference: Digital Government Innovation in Challenging Times*, pages 282–291, New York. ACM.
- Newen, A., De Bruin, L., and Gallagher, S., editors (2018). *The Oxford Handbook of 4E Cognition*. Oxford University Press, Oxford.
- Nicolis, G. and De Wit, A. (2007). Reaction-diffusion systems. *Scholarpedia*, 2(9):1475.
- Noë, A. (2004). *Action in Perception*. MIT Press, Cambridge, MA.
- Ortman, S. G., Lobo, J., and Smith, M. E. (2020). Cities: Complexity, theory and history. *PLoS ONE*, 15(12):e0243621.
- Palestro, J. J., Bahg, G., Sederberg, P. B., Lu, Z.-L., Steyvers, M., and Turner, B. M. (2018). A tutorial on joint models of neural and behavioral measures of cognition. *Journal of Mathematical Psychology*, 84:20–48.
- Palomo, G. A., Padilla-Lepe, A., Gómez, M., Padilla, R., Álvarez, J. R., Jiménez, J. P., Siller, M., Vega, C., Alonso, L., Grignard, A., Roldán, S., Larson, K., and Gamboa, M. (2025). Cityscope guadalajara: An integrative city-science-based tool for improving decision making in urban planning. In *Proceedings of the 2025 International Conference of the Computational Social Science Society of the Americas (preprint)*, pages 1245–1270.
- Pierce, B. C. (1988). A taste of category theory for computer scientists. Technical Report CMU-CS-88-203, Computer Science Department, Carnegie Mellon University, Pittsburgh, PA.
- Pierce, B. C. (1990). A taste of category theory for computer scientists.
- Pikovsky, A. and Rosenblum, M. (2007). Synchronization. *Scholarpedia*, 2(12):1459.
- Pöhlmann, F. (2017). *Being Somewhere: Egocentric Spatial Representation as Self-Representation*. Springer.
- Poldrack, R. A. (2006). Can cognitive processes be inferred from neuroimaging data? *Trends in cognitive sciences*, 10(2):59–63.
- Poldrack, R. A. (2010). Mapping mental function to brain structure: how can cognitive neuroimaging succeed? *Perspectives on psychological science*, 5(6):753–761.

- Portmann, E., Tabacchi, M. E., Seising, R., and Habenstein, A. (2018). *Designing cognitive cities*, volume 176. Springer.
- Portmann, E., Tabacchi, M. E., Seising, R., and Habenstein, A., editors (2019). *Designing Cognitive Cities*. Springer, Cham.
- Portugali, J., editor (1996). *The Construction of Cognitive Maps*. Kluwer Academic Publishers, Dordrecht.
- Portugali, J. (2000). *Self-Organization and the City*. Springer Series in Synergetics. Springer, Berlin and Heidelberg.
- Portugali, J. (2004). Toward a cognitive approach to urban dynamics. *Environment and Planning B: Planning and Design*, 31(4):589–613.
- Portugali, J. (2011). *Complexity, Cognition and the City*. Understanding Complex Systems. Springer, Berlin and Heidelberg.
- Portugali, J. (2012). Complexity theories of cities: Achievements, criticism and potentials. In Portugali, J., Meyer, H., Stolk, E., and Tan, E., editors, *Complexity Theories of Cities Have Come of Age: An Overview with Implications to Urban Planning and Design*, pages 47–62. Springer, Berlin and Heidelberg.
- Portugali, J. (2023). Schrödinger's What Is Life?: Complexity, cognition and the city. *Entropy*, 25(6):872.
- Portugali, J. (2024). Complexity, coordination dynamics and the urban landscape. *Buildings*, 14(5):1327.
- Portugali, J. and Stolk, E. (2016a). Complexity, cognition, urban planning and design. In *Post-Proceedings of the 2nd Delft International Conference. Switzerland: Springer*. Springer.
- Portugali, J. and Stolk, E., editors (2016b). *Complexity, Cognition, Urban Planning and Design: Post-Proceedings of the 2nd Delft International Conference*. Springer, Cham.
- Posner, M. I. and Rothbart, M. K. (2007). Research on attention networks as a model for the integration of psychological science. *Annu. Rev. Psychol.*, 58:1–23.
- Prokopenko, M. and Gershenson, C. (2014). Entropy methods in guided self-organisation. *Entropy*, 16(10):5232–5241.
- Pulvermüller, F. (2018). Neurobiological mechanisms for semantic feature extraction and conceptual flexibility. *Topics in cognitive science*, 10(3):590–620.
- Rad, P. N., Behzadi, F., Yazdanfar, A., Ghamari, H., Zabehe, E., and Lashgari, R. (2021). Cognitive and perceptual influences of architectural and urban environments with an emphasis on the experimental procedures and techniques.
- Raimbault, J. (2020). Cities as they could be: Artificial life and urban systems. *arXiv preprint arXiv:2002.12926*.
- Razborov, A. A. and Rudich, S. (1997). Natural proofs. *Journal of Computer and System Sciences*, 55(1):24–35.
- Ritchie, I. (2021). *Designing with the mind in mind*. John Wiley & Sons, Incorporated.
- Rodin, A. (2014). *Axiomatic Method and Category Theory*, volume 364 of *Synthese Library*. Springer, Cham.
- Roldán, S., Gamboa, M., Jiménez, J. P., Gómez, M., Palomo, G., and Padilla-Lepe, A. (2025). *Ciudad cebolla*. Editorial Universidad de Guadalajara, Zapopan, 1.<sup>a</sup> ed. edition. eISBN: 9786075816029.

- Rosen, R. (1958a). A relational theory of biological systems. *Bulletin of Mathematical Biophysics*, 20:245–260.
- Rosen, R. (1958b). The representation of biological systems from the standpoint of the theory of categories. *The bulletin of mathematical biophysics*, 20(4):317–341.
- Rosen, R. (1958c). The representation of biological systems from the standpoint of the theory of categories. *Bulletin of Mathematical Biophysics*, 20:317–341.
- Rosen, R. (1959). A relational theory of biological systems ii. *Bulletin of Mathematical Biophysics*, 21:109–128.
- Rosen, R. (1972). Some relational cell models: The metabolism-repair system. In Rosen, R., editor, *Foundations of Mathematical Biology, Volume II: Cellular Systems*, pages 217–253. Academic Press, New York.
- Rosen, R. (1985a). *Anticipatory Systems: Philosophical, Mathematical and Methodological Foundations*. Pergamon Press, Oxford.
- Rosen, R. (1985b). Organisms as causal systems which are not mechanisms: An essay into the nature of complexity. In Rosen, R., editor, *Theoretical Biology and Complexity: Three Essays on the Natural Philosophy of Complex Systems*, pages 165–203. Academic Press, Orlando, FL.
- Rosen, R. (1999). *Essays on Life Itself*. Columbia University Press, New York.
- Rosen, R. (2011). *Anticipatory systems*. Springer.
- Rosen, R. (2012). *Anticipatory Systems: Philosophical, Mathematical, and Methodological Foundations*. Springer, New York, 2 edition.
- Rosen, R. J. (2013). *Foundations of Mathematical Biology: Supercellular Systems*. Academic Press.
- Ruelle, D. and Takens, F. (1971). On the nature of turbulence. *Communications in Mathematical Physics*, 20(3):167–192.
- Rydeheard, D. E. and Burstall, R. M. (1988). *Computational Category Theory*. Prentice Hall International, Hemel Hempstead.
- Savitch, W. J. (1970). Relationships between nondeterministic and deterministic tape complexities. *Journal of Computer and System Sciences*, 4(2):177–192.
- Sayama, H. (2015). *Introduction to the modeling and analysis of complex systems*. Open SUNY Textbooks.
- Simon, H. A. (1962). The architecture of complexity. *Proceedings of the American Philosophical Society*, 106(6):467–482.
- Smith, L. A. (2007). *Chaos: A Very Short Introduction*. Oxford University Press, Oxford.
- Stein, J. (1989). Representation of egocentric space in the posterior parietal cortex. *Quarterly Journal of Experimental Physiology: Translation and Integration*, 74(5):583–606.
- Sun, R. (2024). Can a cognitive architecture fundamentally enhance llms? or vice versa? *arXiv preprint arXiv:2401.10444*.
- Sun, R. (2025). Enhancing computational cognitive architectures with llms: A case study. *arXiv preprint arXiv:2509.10972*.
- Swift, J. and Hohenberg, P. C. (2008). Swift-hohenberg equation. *Scholarpedia*, 3(9):6395.

- Tabacchi, M. E., Portmann, E., Seising, R., and Habenstein, A. (2019). Designing cognitive cities. In Portmann, E., Tabacchi, M. E., Seising, R., and Habenstein, A., editors, *Designing Cognitive Cities*, pages 3–29. Springer, Cham.
- Terán, L., Kaskina, A., and Meier, A. (2016). Maturity model for cognitive cities. In Portmann, E. and Finger, M., editors, *Towards Cognitive Cities: Advances in Cognitive Computing and its Application to the Governance of Large Urban Systems*, pages 37–59. Springer, Cham.
- Townsend, A. M. (2013). *Smart Cities: Big Data, Civic Hackers, and the Quest for a New Utopia*. W. W. Norton & Company, New York.
- Treuhub, A. (1991). *The cognitive brain*. MIT press.
- Turing, A. M. (1937). On computable numbers, with an application to the Entscheidungsproblem. *Proceedings of the London Mathematical Society*, 42(1):230–265.
- Valiant, L. G. (1979). The complexity of computing the permanent. *Theoretical Computer Science*, 8(2):189–201.
- Varela, F. J. (1996). Neurophenomenology: A methodological remedy for the hard problem. *Journal of Consciousness Studies*, 3(4):330–349.
- Varela, F. J., Thompson, E., and Rosch, E. (1991). *The Embodied Mind: Cognitive Science and Human Experience*. MIT Press, Cambridge, MA.
- Vargas, N., del Valle-Padilla, J. L., Jimenez, J. P., and Ramos, F. (2021). A model of top-down attentional control for visual search based on neurosciences. In *Brain-Inspired Cognitive Architectures for Artificial Intelligence: BICA\* AI 2020: Proceedings of the 11th Annual Meeting of the BICA Society 11*, pages 541–546. Springer.
- von Bertalanffy, L. (1950a). An outline of general system theory. *The British Journal for the Philosophy of Science*, 1(2):134–165.
- von Bertalanffy, L. (1950b). The theory of open systems in physics and biology. *Science*, 111(2872):23–29.
- von Bertalanffy, L. (1968). *General System Theory: Foundations, Development, Applications*. George Braziller, New York.
- Von Eckardt, B. and Poland, J. S. (2004). Mechanism and explanation in cognitive neuroscience. *Philosophy of Science*, 71(5):972–984.
- Wang, J., Baucom, L. B., and Shinkareva, S. V. (2013). Decoding abstract and concrete concept representations based on single-trial fmri data. *Human brain mapping*, 34(5):1133–1147.
- Wang, J., Conder, J. A., Blitzer, D. N., and Shinkareva, S. V. (2010). Neural representation of abstract and concrete concepts: A meta-analysis of neuroimaging studies. *Human brain mapping*, 31(10):1459–1468.
- Whitehead, G. W. (2012). *Elements of homotopy theory*. Springer Science & Business Media.
- Xiao, W., Peng, L., and Parhami, B. (2009). On general laws of complex networks. In *International Conference on Complex Sciences*, pages 118–124. Springer.

Elementos formales para la construcción de un marco socio-cognitivo de las ciudades como sistemas complejos. Hacia una estructura neurocognitiva del hábitat en el contexto de la ciencia de la ciudad.

Se terminó de editar en abril de 2026 en los talleres gráficos de RISEI.

El tiraje consta de 300 ejemplares.

En la investigación científica sobre los problemas urbanos, existe una connotación humana importante que sitúa al individuo en el centro de la ecuación.

La ciudad contemporánea ha dejado de ser un simple contenedor de interacciones humanas para convertirse en el constructo más complejo producido por nuestra especie. Durante décadas, las ciencias sociales y el urbanismo la han diseccionado desde la superficie: flujos económicos, estructuras de poder o trazados geométricos. Sin embargo, el surgimiento de la ciencia de la ciudad y el acceso a herramientas de modelado formal nos obligan hoy a profundizar en una dimensión poco explorada, lo que nos conduce a una analogía tentadora: "la ciudad como un sistema neurocognitivo distribuido". Este libro nace de una inquietud fundamental: la insuficiencia del paradigma de la *Smart City*. Si bien la ciudad inteligente nos ha dotado de sensores y datos, ha fallado en comprender al sujeto que la habita. Una ciudad que mide el tráfico pero ignora cómo el diseño de una avenida altera la construcción conceptual de sus ciudadanos es una ciudad técnica, pero no humana. La transición hacia la Ciudad Cognitiva que se propone en estas páginas exige un puente epistemológico entre las ciencias cognitivas, las ciencias sociales y la ciencia de la ciudad, tomando como eje de aplicación la neurociencia computacional y como estructura vinculatoria de análisis y modelado, los sistemas complejos.

El argumento central que atraviesa este trabajo es que al entender cómo el cerebro procesa el entorno espacial y cómo las estructuras urbanas emergen de reglas de interacción complejas, podemos empezar a diseñar políticas públicas basadas en evidencia científica real y no solo en intuiciones sociológicas.

Esta integración no sería posible sin un cambio en la formación del capital humano. Por ello, este texto vincula la investigación de frontera con la educación STEAM. También es necesario que el científico social del siglo XXI sea capaz de entender y utilizar lenguajes de programación, aproximarse operativamente a la ciencia de datos y al código, modelar sistemas dinámicos y comprender la plasticidad cerebral, sin perder la mirada crítica sobre las desigualdades que definen nuestro territorio.

Lo que el lector encontrará en los capítulos que integran esta obra es una apuesta por una ciencia social aplicada que se acerque al rigor matemático y a la biología, y que, en última instancia, busca que nuestras ciudades dejen de ser máquinas de habitar para convertirse en espacios de entendimiento.

