

**Carrera/ Plan:****Sistemas Distribuidos y Paralelos***Ingeniería en Computación Plan 2008 / 2011***Año:** 5**Régimen de Cursada:** Semestral**Carácter (Obligatoria/Optativa):** Obligatorio**Correlativas:** Concurrencia y Paralelismo**Profesor/es:** Dr. Adrian Pousa**Hs. semanales:** 6**Año 2025****FUNDAMENTACIÓN**

La evolución tecnológica de los procesadores ha motivado el procesamiento paralelo. Formar al alumno (que ya tiene conocimientos previos de Concurrencia y sus aplicaciones) en los fundamentos de los sistemas paralelos, los paradigmas de programación paralela y las métricas de rendimiento asociadas resulta un aporte fundamental para el futuro profesional. Esta tarea de formación se combina con trabajo experimental sobre sistemas paralelos concretos, disponibles en la Facultad.

**OBJETIVOS GENERALES**

Caracterizar los problemas de procesamiento paralelo desde dos puntos de vista: la arquitectura física y los lenguajes de programación, poniendo énfasis en la transformación de algoritmos secuenciales en paralelos.

Describir los modelos de cómputo paralelo y los paradigmas de programación paralela.

Estudiar las medidas de performance asociadas al paralelismo.

Plantear casos concretos de procesamiento paralelo, resolubles sobre distintas arquitecturas multiprocesador.

**EJES TRANSVERSALES**

01. Diseño e implementación de diversas Arquitecturas de Computadoras y todos los subsistemas relacionados. (2-Medio)
03. Especificación, proyecto y Desarrollo de Software y Sistemas Conjuntos de Hardware y Software haciendo uso de conceptos, métodos y herramientas de gestión de proyectos, ingeniería de software, base de datos, experiencia del usuario, elicitación, análisis, especificación y validación de requerimientos. (2-Medio)
04. Desarrollo de Redes de Computadoras y de Redes de Computadoras de área amplia, locales, inalámbricas y móviles. (1-Bajo)
05. Sistemas de Gestión de Recursos de Hardware y Software a sistemas generales, de tiempo real, distribuidos, para dispositivos fijos y móviles. (2-Medio)
06. Proyecto, desarrollo, dirección, control, construcción, operación y mantenimiento de Sistemas de Procesamiento de Señales, Sistemas Embebidos y sus periféricos incluido en software de soporte, Sistemas Computarizados de automatización y control y Sistemas Conjuntos de Hardware y Software. (2-Medio)
07. Certificación del funcionamiento, condición de uso o estados de Sistemas de Procesamiento de Señales, Sistemas Embebidos, Sistemas Computarizados de automatización y control, Sistemas Conjuntos de Hardware y Software. (1-Bajo)
08. Proyecto, Dirección y Aseguramiento de la calidad en lo referido a Seguridad Informática. (1-Bajo)
09. Identificación, formulación y resolución de problemas de ingeniería en computación. (2-Medio)
10. Concepción, diseño y desarrollo de proyectos de ingeniería en computación. (1-Bajo)

- 
12. Utilización de técnicas y herramientas de aplicación en la ingeniería en computación. (2-Medio)  
13. Generación de desarrollos tecnológicos y/o innovaciones tecnológicas. (2-Medio)  
14. Fundamentos para el desempeño en equipos de trabajo. (1-Bajo)

### **CONTENIDOS MINIMOS**

Arquitecturas de procesamiento paralelo.  
Modelos de comunicación. Métricas de performance.  
Memoria compartida, Memoria distribuida, esquemas mixtos.  
Lenguajes y sistemas operativos para procesamiento paralelo.  
Paradigmas de resolución de sistemas paralelos.  
Adaptación entre arquitectura y software.  
Aplicaciones.

### **PROGRAMA ANALÍTICO**

#### **Unidad 1: Conceptos básicos**

Concurrencia y Paralelismo. Objetivos del procesamiento paralelo. Concepto de Sistema Paralelo. Software de un Sistema Paralelo. Hardware de un Sistema Paralelo. Motivación de los Sistemas Paralelos. Áreas de aplicación. Limitaciones actuales de hardware. Ley de Moore. Conceptos de paralelismo implícito y explícito. Paralelismo implícito. Conceptos de Segmentación/Pipelining y división funcional. Transparencia. Procesador Escalar y Superescalar. Paralelismo explícito. Comportamiento de las aplicaciones: CPU-Bound, Memory-Bound, I/O-Bound, Híbridos por fases. Etapas en el diseño de algoritmos paralelos: Descomposición, Comunicación, Aglomeración y Mapeo. Herramientas de desarrollo. Herramientas basadas en el modelo de memoria compartida, Herramientas basadas en el modelo de memoria distribuida, Modelos híbridos. Características del procesamiento paralelo en los lenguajes de programación y los sistemas operativos. Características del desarrollo de aplicaciones paralelas. Concepto de High Performance Computing (HPC).

#### **Unidad 2: Sistema de memoria**

Sistema de memoria. Limitaciones. La importancia de la memoria caché. Conceptos asociados a la memoria cache (Estados, Niveles, Contención y Coherencia) Principio de localidad: Localidad Temporal y Espacial.

Principio de localidad aplicado a la multiplicación de matrices

Minimizando el espacio de memoria. Caso de estudio matrices triangulares.

Conceptos de contadores hardware para evaluar el comportamiento del sistema de memoria.

#### **Unidad 3: Arquitecturas Paralelas**

Clasificación de arquitecturas paralelas. Por Organización lógica: mecanismo de control (Taxonomía de Flynn: SISD, SIMD, MISD y MIMD) y modelos de comunicación, (arquitecturas de memoria compartida UMA-NUMA y de memoria distribuida). Por Organización física: organización del espacio de direcciones, redes de interconexión y granularidad de los procesadores.

Evolución y Tendencias en las arquitecturas paralelas. Multiprocesadores, Clusters, Multiclusters, Grid, Multicores (homogéneos, heterogéneos y asimétricos), Manycores (GPUs y otros coprocesadores), Cloud para HPC. Computación cuántica.

Top 500 y Green 500.

Redes de comunicación en sistemas paralelos y distribuidos orientadas a HPC: Ethernet, Infiniband, Myrinet.

---

## Unidad 4: Principios de diseño de algoritmos paralelos

Paralelismo explícito. Etapas de diseño de algoritmos paralelos: Descomposición, Comunicación, Aglomeración y Mapeo.

Etapas de Descomposición. Descomposición en tareas: Descomposición de Datos o de Dominio y Descomposición Funcional. Dependencias de tareas, Grafo de dependencias. Embarrassingly Parallel Problems. Características de las tareas: Tareas estáticas y dinámicas, Comportamiento uniforme y no uniforme, Volumen de tareas y Granularidad. Técnicas de descomposición de datos: recursiva, basada en datos (de salida, de entrada - problema de la frontera, de entrada/salida y de datos intermedios), exploratoria y especulativa. Técnica de descomposición híbrida.

Etapas de asignación/aglomeración. Reducción del volumen de tareas. Asignación, balance de carga. Aglomeración, localidad.

Etapas de Comunicación. Patrones de comunicación: Global/Local, Estructurado/No Estructurado, Estático/Dinámico, Síncrono/Asíncrono. Overhead de las comunicaciones.

Etapas de Aglomeración. Reducción de overhead y optimización de la localidad. Conservación de la escalabilidad. Costos asociados a la Ingeniería de Software.

Etapas de Mapeo. Mapeo estático. Estrategias de mapeo estático: basado en datos (arrays y grafos), en particiones de tareas y jerárquico. Mapeo dinámico. Estrategias de mapeo dinámico: centralizados y distribuidos. Mapeo dinámico y balance de carga.

Diseño sobre arquitecturas modernas. Heterogeneidad e integración: arquitecturas, sistemas operativos, herramientas y compiladores. Afinidad.

## Unidad 5: Programación de algoritmos paralelos. Modelo de memoria compartida

Conceptos del Modelo de Programación sobre Memoria Compartida. Concepto de thread. Herramientas de desarrollo Posix Threads (Pthreads) y OpenMP.

Pthreads: Gestión de hilos, Sincronización, Afinidad.

OpenMP: modelo Fork-Join, Estructura de control paralela, Distribución de trabajo entre hilos, Gestión de entorno de datos, Sincronización, Funciones y variables de ambiente, Afinidad.

Resolución de aplicaciones específicas.

## Unidad 6: Programación de algoritmos paralelos. Modelo de memoria distribuida

Conceptos del Modelo de Programación sobre Memoria Distribuida. Antecedentes: Herramienta de desarrollo PVM. Herramientas de desarrollo MPI: Funcionamiento y Estructura de programa, Comunicación Punto a Punto y Colectiva. Ocultamiento de la latencia.

Resolución de aplicaciones específicas.

## Unidad 7: Programación de algoritmos paralelos. Modelo híbrido

Arquitecturas Paralelas Híbridas y desafíos en la programación paralela. Modelos de Programación Híbridos: MPI-Pthreads y MPI-OpenMP. Compilación y Modularidad.

Resolución de aplicaciones específicas.

## Unidad 8: Métricas

Importancia de las métricas en los sistemas paralelos. Métricas de rendimiento, Speedup, Speedup Absoluto y Relativo. Speedup lineal, Speedup perfecto, Speedup superlineal. Eficiencia. Overhead. Balance de carga. Escalabilidad en los sistemas paralelos: Ley de Amdahl y Ley de Gustafson, Definición de Escalabilidad, Modelo de Isoeficiencia.

Métricas en arquitecturas heterogéneas. Concepto de potencia de cómputo relativa (PCR). Limitaciones del speedup. Ejecución Paramétrica.

---

## Unidad 9: Paradigmas

Paradigmas de programación paralela: Paralelismo de Datos SIMD/SPMD, Divide y Vencerás, Pipelines, Algoritmos sistólicos, Master-Worker, Task pools. Modelos híbridos.

Ejemplos de resolución de aplicaciones específicas.

## Unidad 10: Introducción a la programación sobre GPUs

Era Manycore - Introducción al concepto de GPGPU. Características paralelas de las GPUs.

Arquitectura Nvidia: Sistema de procesamiento y Sistema de memoria. Modelo de programación Nvidia CUDA: Declaración de variables, Gestión de la memoria global, Gestión de hilos, Kernel, Modularidad, Variables Built-in y Thread ID, Planificación, Multithreading por Hardware.

CUDA Capability.

Jerarquía de memoria Nvidia. Memorias On-Chip vs Memorias Off-Chip. Capacidades, Velocidades y Ancho de Banda. Conceptos de Latencia, Alcance y Tiempo de Vida. Memoria Global: patrón de acceso, unificación de transacciones y minimización de volumen de lectura. Memoria de Constantes y Memoria de Texturas. Memoria compartida: Bancos y Conflictos de Bancos. Registros y Memoria Local. Limitaciones. Optimizaciones Nvidia CUDA: Coalescencia y prefetching. Divergencia. Mezcla y granularidad de instrucciones. Ocupación y asignación de recursos.

CUDA Streams: Impacto de las transferencias H2D y D2H. Ocultamiento de la latencia mediante CUDA Streams. Concurrencia a nivel Kernel y a nivel de memoria. Copia de memoria asíncrona.

Ejemplos de resolución de aplicaciones específicas.

## **BIBLIOGRAFIA**

- “An Introduction to Parallel Computing. Design and Analysis of Algorithms” Grama, Gupta, Karypis, Kumar, 2003.
- “Foundations of Multithreaded, Parallel and Distributed Programming” Andrews, 2000.
- “Introduction to HPC for Scientists and Engineers” Hager, Wellein, 2011.
- “An introduction to parallel programming” Peter Pacheco, 2011.
- “Parallel Programming for Multicore and Cluster Systems” Rauber, 2010.
- “Parallel programming in C with MPI and OpenMP” Quinn, 2003.
- “Sourcebook of Parallel Computing” Dongarra, Foster, Fox, 2003.
- Jason Sanders, Edward Kandrot “CUDA by Example An Introduction to General Purpose GPU Programming”. NVIDIA Corporation, Addison Wesley, 2011.
- M. F. Piccoli, “Computación de Alto Desempeño utilizando GPU”. XV Escuela Internacional de Informática. Editorial Edulp, 2011.
- John Cheng, Max Grossman, Ty McKercher, “Professional CUDA C Programming”, John Wiley & Sons, 2014.
- David B. Kirk, Wen-mei W. Hwu, “Programming Massively Parallel Processors - A Hands-on Approach” 3ed, NVIDIA Corporation and Wen-mei W. Hwu, Elsevier, 2017.

---

## **METODOLOGÍA DE ENSEÑANZA**

La asignatura se estructura con clases teóricas y clases prácticas experimentales, ambas presenciales.

Las clases teóricas introducen los conceptos teóricos de la asignatura aplicables en las clases prácticas.

Las clases prácticas experimentales se desarrollarán en una de las Salas de Cómputo de la Facultad y equipamiento especial del III-LIDI accedido de forma remota. Estas clases consisten de un conjunto de problemas que los alumnos deben resolver sobre las arquitecturas disponibles. Durante los días de práctica pueden incluirse explicaciones introductorias al trabajo en la sala y relacionadas a la utilización del equipamiento.

Las consultas se realizarán durante los días de clases prácticas. Eventualmente, se responderán consultas mediante alguna plataforma virtual de forma asincrónica (entorno IDEAS) o sincrónica (Webex o similar) cuando involucren dudas puntuales de menor complejidad.

### Redictado

La cátedra no considera la necesidad de realizar un redictado.

### Alcance de los ejes transversales

Los temas desarrollados durante el transcurso de la materia abarcan aspectos de hardware y software muy amplios. Partiendo del hardware de bajo nivel se introduce al concepto de arquitectura paralela. Se clasifican y describen en profundidad las distintas arquitecturas paralelas actuales, su diseño e implementación. Se explica la interacción de estas con el Sistema Operativo, el sistema de comunicaciones y su seguridad, el sistema de entrada salida, el sistema de memoria y su jerarquía, los lenguajes y herramientas de programación paralela. Asimismo, se introduce a la gestión de este tipo de recursos, su implementación, puesta a punto y administración.

Se cubre todo el proceso de desarrollo, implementación y evaluación de aplicaciones paralelas. Partiendo de algoritmos secuenciales se aplican las técnicas para poder identificar las partes del algoritmo que pueden ser paralelizadas. Luego, se atraviesan las distintas etapas de diseño hasta idear una o varias implementaciones de un algoritmo paralelo. Las distintas implementaciones dependerán de las herramientas utilizadas y la arquitectura donde el algoritmo será ejecutado. En este punto, se estará en condiciones de diseñar adecuadamente el conjunto de escenarios para realizar las pruebas experimentales a fin de evaluar, mediante distintas métricas, el rendimiento y otros aspectos del algoritmo paralelo. Mediante una evaluación y análisis exhaustivos se podrán determinar qué soluciones, herramientas de software y hardware serán más adecuadas para la resolución de un problema específico.

## Evaluación

La materia se aprueba al cumplir con la evaluación satisfactoria de dos aspectos: los conceptos teóricos y los conceptos prácticos.

Durante la cursada se evalúan los conceptos prácticos mientras que los conceptos teóricos se avalúan mediante un examen final.

Los conceptos prácticos, o simplemente cursada, se aprueban a partir de un trabajo experimental integrador y una defensa del mismo.

El trabajo es individual y consiste en resolver uno o más problemas específicos sobre arquitecturas paralelas, utilizando las herramientas vistas en clase y realizando el análisis de escalabilidad de las soluciones propuestas.

Para los trabajos entregados que no cumplan con los requerimientos mínimos, establecidos oportunamente por la cátedra, habrá una única re-entrega. Una vez que la cátedra considere satisfactorio el trabajo se pasará a la instancia de defensa.

La defensa del trabajo experimental consiste en contestar preguntas relacionadas al trabajo y soluciones relacionadas a las prácticas experimentales. En cada caso, la cátedra determinará si se realiza mediante un coloquio oral o de manera escrita. Cabe aclarar que la defensa no tiene instancia recuperatoria.

Una vez aprobada la cursada, podrán presentarse a rendir el examen final en cualquiera de las mesas establecidas en el calendario académico publicado por la Facultad, previa inscripción. Este examen incluye los temas del programa analítico tratados en clase.

La nota final de la materia es la nota del examen final.

Serán eximidos del examen final quienes aprueben la promoción.

La promoción es un mecanismo que permite evaluar los conceptos teóricos de la materia en el semestre en curso y la aprobación de la misma exime de rendir el examen final.

### Régimen de Promoción

Para acceder a la promoción se deben cumplir los siguientes requisitos:

- Estar inscripto en modalidad Promoción.
- 80% de asistencia a las clases teóricas.

*Quienes cumplan con lo anterior podrán realizar el trabajo experimental integrador en grupo de a lo sumo dos personas.*

- Aprobar la cursada sin haber re-entregado el trabajo experimental integrador.
- Aprobar con nota 6 o más un examen de promoción. El mismo incluye los temas del programa analítico tratados en clase y no tiene instancia recuperatoria.
- Tener aprobadas las materias correlativas antes de diciembre del corriente año.

La nota final de la materia es la nota del examen de promoción.

Cabe aclarar que no se evaluará a ningún alumno que no se encuentre inscripto en actas, ya sea de cursada, de promoción o de final; o que no cumplan con los requisitos antes establecidos.

### Evaluación de los ejes transversales

Durante las prácticas experimentales es posible evaluar el desempeño de equipos de trabajo ya que se podrían armar grupos de dos o más personas para resolver los distintos problemas que se planteen.



Para el trabajo experimental existe la posibilidad de conformar grupos de a lo sumo dos personas. Además, durante el trabajo experimental y su posterior defensa se evalúa la capacidad de idear, diseñar e implementar algoritmos paralelos utilizando distintas herramientas de software. Asimismo, se evalúa la capacidad de comprender en profundidad las arquitecturas paralelas y cómo utilizarlas adecuadamente para la correcta ejecución de los algoritmos implementados.

Se evalúa también la capacidad de generar el conjunto de escenarios de pruebas, la aplicación de métricas, el análisis de resultados y las conclusiones.

Los conceptos teóricos se evalúan mediante un examen individual.

### Uso adecuado de los recursos provistos por la cátedra

La ejecución de los experimentos para el trabajo experimental integrador se llevará a cabo sobre recursos computacionales provistos por la cátedra. Específicamente, el Cluster de Cómputo del III-LIDI, que será compartido por todos los alumnos. La ejecución compartida será gestionada mediante un administrador de recursos y un sistema de colas, que permiten organizar las distintas ejecuciones de usuario sin ser interrumpidas.

Los alumnos deberán comprender y respetar las normas mínimas de ejecución sobre el cluster, que estarán debidamente documentadas y explicadas por la cátedra.

El uso indebido de esos recursos, ya sea que perjudique al resto de los alumnos, bloquee los accesos, interrumpa el servicio o genere un daño físico o lógico, será sancionado, por ejemplo: con la pérdida de la cursada y el recursado de la materia.

### **Cronograma de clases y evaluaciones**

Cronograma de clases teóricas:

| Clase | Fecha           | Contenidos/Actividades                                                                                                                                |
|-------|-----------------|-------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1     | Semana del 3/3  | Unidad 1 (Conceptos básicos)<br>Unidad 2 (Sistema de memoria)                                                                                         |
| 2     | Semana del 10/3 | Unidad 3 (Arquitecturas Paralelas. Clasificación. Evolución y Tendencias)                                                                             |
| 3     | Semana del 17/3 | Unidad 4 (Principios de Diseño de algoritmos paralelos)                                                                                               |
| 4     | Semana del 24/3 | Unidad 5 (Programación de algoritmos paralelos. Modelo de memoria compartida)<br>Pthreads y OpenMP                                                    |
|       | Semana del 31/3 | FERIADO                                                                                                                                               |
| 5     | Semana del 7/4  | Unidad 6 (Programación de algoritmos paralelos. Modelo de memoria distribuida MPI)<br>Unidad 7 (Programación de algoritmos paralelos. Modelo híbrido) |
| 6     | Semana del 14/4 | Unidad 8 (Métricas)                                                                                                                                   |
| 7     | Semana del 21/4 | Unidad 9 (Paradigmas)                                                                                                                                 |
| 8     | Semana del 28/4 | Unidad 10 (Programación sobre GPUs. Modelo de programación CUDA. Jerarquía de memoria Nvidia)                                                         |
| 9     | Semana del 5/5  | Unidad 10 (Programación sobre GPUs. Optimizaciones. CUDA Streams. Modelos Híbridos)                                                                   |

Cronograma de prácticas experimentales:

| Clase | Fecha           | Contenidos/Actividades                                                   |
|-------|-----------------|--------------------------------------------------------------------------|
| 1     | Semana del 10/3 | Práctica 1 – Optimización de algoritmos secuenciales                     |
| 2     | Semana del 17/3 | Práctica 1 – Optimización de algoritmos secuenciales                     |
| 3     | Semana del 24/3 | Práctica 2 y 3 – Modelo de memoria compartida – Pthreads y OpenMP        |
|       | Semana del 31/3 | FERIADO                                                                  |
| 4     | Semana del 7/4  | Práctica 2 y 3 – Modelo de memoria compartida – Pthreads y OpenMP        |
| 5     | Semana del 14/4 | Práctica 4 y Práctica 5 – Modelo de memoria distribuida – MPI e Híbridos |
| 6     | Semana del 21/4 | Práctica 4 y Práctica 5 – Modelo de memoria distribuida – MPI e Híbridos |
| 7     | Semana del 28/4 | Práctica 5 – Introducción a la programación sobre GPUs                   |
| 8     | Semana del 5/5  | Práctica 5 – Introducción a la programación sobre GPUs                   |

---

Cronograma de entregas y defensas:

| Fecha tentativa             | Contenidos/Actividades                                                        |
|-----------------------------|-------------------------------------------------------------------------------|
| Semana del 5/5              | Presentación del trabajo a entregar                                           |
| Semana del 26/5             | Entrega                                                                       |
| Semana del 2/6              | Resultados de Entrega                                                         |
| Semanas del 2/6, 9/6 y 16/6 | Defensa del trabajo a quienes cumplieron satisfactoriamente con la Entrega    |
| Semana del 16/6             | Re-entrega                                                                    |
| Semana del 23/6             | Resultados de Re-entrega                                                      |
| Semanas del 23/6 y 30/6     | Defensa del trabajo a quienes cumplieron satisfactoriamente con la Re-Entrega |

## Evaluaciones:

| Fecha tentativa | Evaluación previstas |
|-----------------|----------------------|
| 2/7             | Examen de Promoción  |

## Contactos de la cátedra:

Mail: [apousa@lidi.info.unlp.edu.ar](mailto:apousa@lidi.info.unlp.edu.ar)Plataforma virtual: IDEAS (<https://ideas.info.unlp.edu.ar>)

Firma del profesor responsable