



Benemérita Universidad Autónoma de Puebla
Facultad de Ciencias de la Electrónica
Maestría en Ciencias de la Electrónica, Opción en Automatización

Ponencia Plenaria

GENERACIÓN DE IMÁGENES SINTÉTICAS PARA REALIZAR EL ENTRENAMIENTO DE UNA RED NEURONAL CONVOLUCIONAL

Presenta:

Ing. Yoltic Faustino Gutiérrez Téllez

Directores de investigación:

Dra. María Aurora Diozcora Vargas Treviño (FCE-BUAP)

Colaborador Externo:

Dr. Jesús López Gómez (UJAT)

22 de junio de 2026

¿Qué es una Red Neuronal Convolutiva?

Una RNC es un algoritmo avanzado que procesa matrices de datos (como imágenes). Inicialmente, actúa como una caja negra conformada por miles de conexiones matemáticas llamadas **pesos sinápticos**.

Requisitos para el Aprendizaje:

- **Lote de entrenamiento:** Requiere un volumen masivo de ejemplos de entrada (base de datos).
- **Etiquetas (Labels):** Cada ejemplo debe estar vinculado a su respuesta correcta esperada.
- **Retropropagación:** Es el algoritmo encargado de ajustar los pesos sinápticos iterativamente para que la red aprenda de sus errores y logre predecir la etiqueta correcta.




Figura 2: Esquema general de aprendizaje y extracción de características.

Estructura de la red neuronal

Producción Masiva de Datos Etiquetados

Implementando esta iteración matemática y generando valores aleatorios dentro de límites físicos lógicos, construimos:

- **750,000 imágenes sintéticas** en total.
- Divididas en lotes de 125,000 por cada etapa de la cascada.
- **80 %** para entrenamiento (*Training*).
- **20 %** para validación ciega (*Testing*).




Figura 3: Estructura de la RNC .

El Problema Fundamental: Volumen de datos

Las RNC necesitan aprender de la experiencia

Una red neuronal convolucional funciona como una caja negra que procesa patrones visuales. Para que aprenda a relacionar un comportamiento físico con un parámetro numérico, necesita ser entrenada mediante **retropropagación**.

La limitante experimental

Entrenar una red neuronal profunda requiere una base de datos masiva. Extraer **cientos de miles** de perfiles de torque de manera puramente experimental y manual en el robot es logísticamente inviable, costoso y propenso a desgaste físico del equipo.

La Solución Propuesta: Diseñar un algoritmo generador de **imágenes sintéticas** basadas en el modelo dinámico teórico del robot.

¿De dónde surgen los datos?: El Modelado Dinámico

La Física detrás del Robot

Para generar datos sintéticos que sean útiles y realistas, primero necesitamos una representación matemática exacta del comportamiento físico del robot.

- **Metodología:** Euler-Lagrange con enfoque de parámetros agrupados.
- **Fundamento:** Se basa en el balance de energías del sistema (Energía Cinética, Potencial y Disipativa).
- **Resultado:** Un modelo que describe rigurosamente cómo cada eslabón mecánico (motor, caja reductora, cople, husillo y mesa) interactúa y se resiste al movimiento.

Sistema de Ecuaciones Diferenciales Acopladas

La aplicación de Euler-Lagrange nos entrega estas 6 ecuaciones. Este sistema es el motor generador de nuestros datos.

$$J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} - b_{g1}(G\dot{\theta}_{g1} - \dot{\theta}_{m1}) + \tau_{g1} = \tau_{m1} \quad (1)$$

$$J_{g1}\ddot{\theta}_{g1} + k_{c1}(\theta_{g1} - \theta_{c1}) + b_{g1}G_1(G_1\dot{\theta}_{g1} - \dot{\theta}_{m1}) - b_{c1}(\dot{\theta}_{c1} - \dot{\theta}_{g1}) = G_1\tau_{g1} \quad (2)$$

$$J_{c1}\ddot{\theta}_{c1} - k_{c1}(\theta_{g1} - \theta_{c1}) + k_{s1}(\theta_{c1} - \theta_{s1}) + b_{c1}(\dot{\theta}_{c1} - \dot{\theta}_{g1}) - b_{s1}(\dot{\theta}_{s1} - \dot{\theta}_{c1}) = 0 \quad (3)$$

$$J_{s1}\ddot{\theta}_{s1} - K_{s1}(\theta_{c1} - \theta_{s1}) + b_{s1}(\dot{\theta}_{s1} - \dot{\theta}_{c1}) - R_nb_{n1}(\dot{X}_{t1} - (\dot{X}_{s1} + R_n\dot{\theta}_{s1})) = R_nF_{n1} \quad (4)$$

$$(m_{s1} + m_{s2})\ddot{X}_{s1} + k_{r1}X_{s1} + b_{r1}\dot{X}_{s1} - b_{n1}(\dot{X}_{t1} - (\dot{X}_{s1} + R_n\dot{\theta}_{s1})) = F_{n1} \quad (5)$$

$$(m_{t1} + m_{t2})\ddot{X}_{t1} + b_{n1}(\dot{X}_{t1} - (\dot{X}_{s1} + R_n\dot{\theta}_{s1})) = -F_{n1} - F_{f1} \quad (6)$$

Manipulación Algebraica del Sistema

Las 6 ecuaciones originales acopladas no son prácticas para entrenar a la red. Por ello, se sustituyen las variables desde la mesa de trabajo hacia atrás. El resultado son 6 **nuevas ecuaciones** donde toda la dinámica se refleja puramente como un **torque específico en el motor** (τ_{m11} a τ_{m16}), el cual podremos convertir en imágenes:

$$\tau_{m11} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} - b_{g1}(G_1\dot{\theta}_{g1} - \dot{\theta}_{m1}) + \tau_{g1} \quad (7)$$

$$\tau_{m12} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} + \frac{1}{G_1} \left[J_{g1}\ddot{\theta}_{g1} + k_{c1}(\theta_{g1} - \theta_{c1}) - b_{c1}(\dot{\theta}_{c1} - \dot{\theta}_{g1}) \right] \quad (8)$$

$$\tau_{m13} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} + \frac{J_{g1}\ddot{\theta}_{g1}}{G_1} + \frac{1}{G_1} \left[J_{c1}\ddot{\theta}_{c1} + k_{s1}(\theta_{c1} - \theta_{s1}) - b_{s1}(\dot{\theta}_{s1} - \dot{\theta}_{c1}) \right] \quad (9)$$

$$\tau_{m14} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} + \frac{J_{g1}\ddot{\theta}_{g1} + J_{c1}\ddot{\theta}_{c1}}{G_1} + \frac{1}{G_1} \left[J_{s1}\ddot{\theta}_{s1} - R_{n1}b_{n1}(\dot{X}_{t1} - \dot{X}_{s1} - R_{n1}\dot{\theta}_{s1}) - R_{n1}F_{n1} \right] \quad (10)$$

$$\tau_{m15} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} + \frac{J_{g1}\ddot{\theta}_{g1} + J_{c1}\ddot{\theta}_{c1} + J_{s1}\ddot{\theta}_{s1}}{G_1} - \frac{R_{n1}}{G_1} \left[(m_{s1} + m_{s2})\ddot{X}_{s1} + k_{r1}X_{s1} + b_{r1}\dot{X}_{s1} \right] \quad (11)$$

$$\tau_{m16} = J_{m1}\ddot{\theta}_{m1} + b_{m1}\dot{\theta}_{m1} + \frac{J_{g1}\ddot{\theta}_{g1} + J_{c1}\ddot{\theta}_{c1} + J_{s1}\ddot{\theta}_{s1}}{G_1} + \frac{R_{n1}}{G_1} \left[(m_{t1} + m_{t2})\ddot{X}_{t1} \right] + F_{f1} \quad (12)$$

El Conflicto de las Magnitudes Físicas

¿Por qué no generar una sola imagen para todo?

Si simulamos el torque total del sistema en una sola imagen, las fuerzas dominantes (como la enorme fricción de la mesa de trabajo) opacan visual y matemáticamente a las dinámicas diminutas (como la inercia interna del rotor).

Si le damos a la red neuronal una imagen global intentando que prediga los 18 parámetros simultáneamente, la red ignora los parámetros pequeños. Necesitábamos una estrategia de segmentación de datos.

Transformación Espacial del Torque

Para que la RNC pueda procesar la información física, tomamos la señal simulada del esfuerzo del motor (torque τ) y la convertimos en una imagen bidimensional.

1. Producto Externo: Se crea una matriz cuadrada multiplicando el vector de torque por su transpuesta:

$$A = \tau \tau^T \quad (13)$$

2. Normalización: Se escala al rango $[0, 1]$ para estabilizar los gradientes durante el entrenamiento:

$$Z = \frac{A - \min(A)}{\max(A) - \min(A)} \quad (14)$$




Figura 4: Firma visual del torque (100×100 píxeles).

Validación de la red neuronal

Validación Estocástica Ciega

Antes de ir al robot real, probamos si la red entrenada con *imágenes sintéticas* era capaz de reconstruir un perfil de torque ante parámetros completamente aleatorios que jamás había visto.

Comparación de Torque real(sintetico) vs Torque Reconstruido (Similitud: 99.91%)




Figura 6: Reconstrucción de Fricción Global .

Torque Real (Sintético) vs Torque Reconstruido (Similitud: 100.00%)




Figura 7: Reconstrucción de Dinámica Interna .

Seguimiento de Posición Experimental

Precisión en el mundo físico

Al implementar el control de trayectoria compensado con los parámetros descubiertos por la RNC, el robot logra seguir la posición deseada casi a la perfección, venciendo la inercia y la fricción.




Figura 8: Posición Eje X (Similitud: 99.66 %).




Figura 9: Posición Eje Z (Similitud: 99.97 %).

Validación Experimental en Entorno Real

Del modelo sintético al mundo físico

Inyectamos los parámetros descubiertos por nuestra red neuronal en el controlador PD de la plataforma robótica real para compensar la fricción y la inercia durante su movimiento.




Figura 10: Sin compensación.




Figura 11: Con compensación, el error de posición cae drásticamente.

¡Muchas gracias por su atención!

Ing. Yoltic Faustino Gutiérrez Téllez

Maestría en Ciencias de la Electrónica

Benemérita Universidad Autónoma de Puebla

¿Preguntas o comentarios?