Ajuste en profundidad

Perceptrones grandes: varias capas

Ajuste en profundidad

- ¿Qué has oído de Deep Learning?

Arquitectura profunda

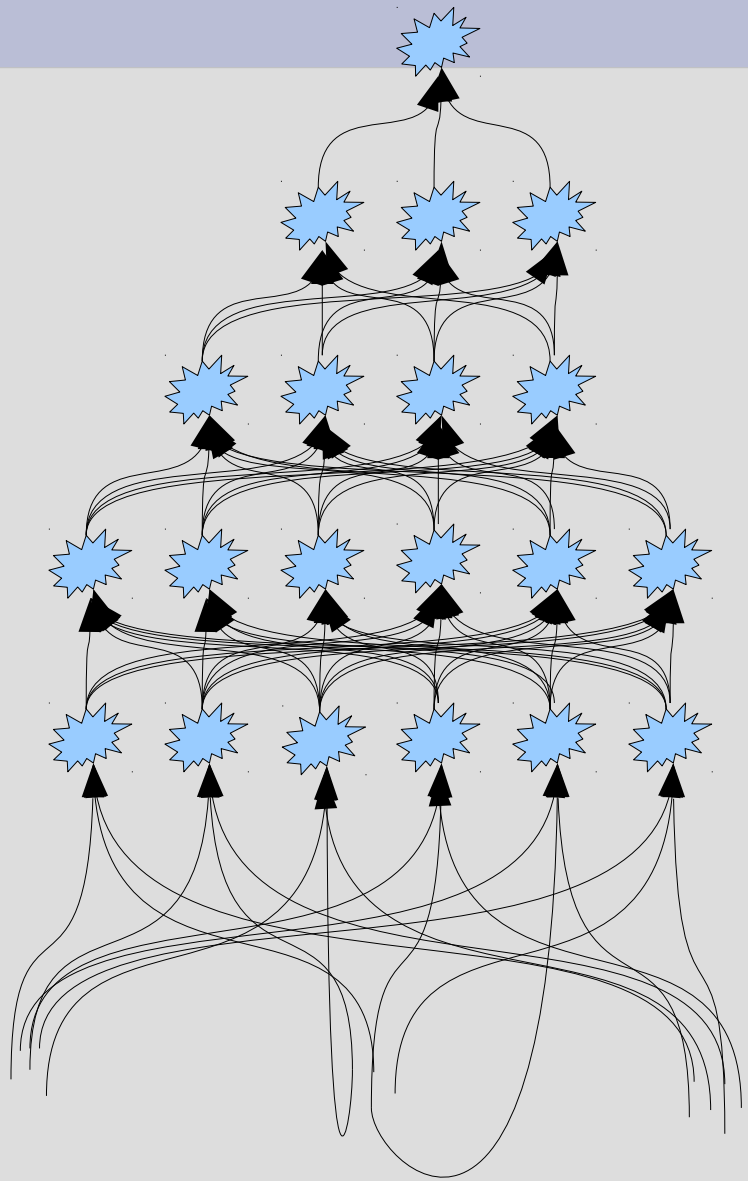

Problemas de ajuste

- Convergencia de los métodos basados en gradiente
  - Gradiente puede hacerse demasiado pequeño o demasiado grande: limitar la magnitud máxima y mínima
  - Cuidado con la inicialización: valores pequeños
- El algoritmo de ajuste tiene que moverse en una dimensión altísima
  - Espacio de búsqueda enorme (iteraciones necesarias, influencia de punto inicial)
  - Función de error con geometría enrevesada, mínimos locales

Problemas de ajuste

- Gradientes. Extiende a 5 capas el caso de 2. Da cotas razonables

$$\frac{\partial E}{\partial p_{ij}} = \left(\sum_k \frac{\partial E}{\partial y_{s_k}} \frac{\partial y_{s_k}}{\partial e_{s_k}} \frac{\partial e_{s_k}}{\partial y_i} \right) \frac{\partial y_i}{\partial e_i} \frac{\partial e_i}{\partial p_{ij}}$$

$$\frac{\partial E}{\partial y_{s_k}} = 2\left(y_{s_k} - c_k\right)$$

$$\frac{\partial y_{s_k}}{\partial e_{s_k}} = 1 - y_{s_k}^2 \quad \frac{\partial y_i}{\partial e_i} = 1 - y_i^2$$

$$\frac{\partial e_{s_k}}{\partial y_i} = p_{s_k i}$$

$$\frac{\partial e_i}{\partial p_{ij}} = y_j$$

- Dimensión: 1000 entradas y capas con 300, 100, 50, 20, 5 y 1 procesador (5 ocultas) ¿Cuántos pesos tiene? No olvides los términos independientes

Normalización

- Cada capa puede considerarse un pequeño perceptrón que se ajusta sobre las anteriores
- Pero como las anteriores se están ajustando también, su entrada se mueve
- La podemos llevar cada ciertas iteraciones a media cero y varianza unidad
- La transformación se compensa con unos parámetros de afinidad que son ajustables

Normalización

- ¿Dónde habías visto esta estrategia antes de ahora? ¿Con qué explicación?

Problemas de generalización

- Demasiados grados de libertad
  - Peligro de que el modelo se ajuste a peculiaridades de la muestra (varianza del modelo, influencia del ruido)
- Procedimientos generales para garantizar extrapolación:
  - Penalizar/forzar que la respuesta sea a veces no nula en los ocultos
  - Reducir el número de pesos libres, porque se usan los mismos en muchos procesadores

Problemas de generalización

- ¿Cuál es la relación en forzar un procesador a 0 y los grados de libertad?
- Vuelve a calcular el número de pesos en la red de 5 capas ocultas si en cada capa son compartidos la mitad de los pesos de cada procesador

¿Por qué lo de que haya muchos nulos?

- Se parece más a lo biológico: hay pocas neuronas activas en cada momento
- Implica dimensión alta:
  - Mejor separabilidad (como SVM)
  - Permite representaciones de tamaño "variable", que son más útiles en muchos problemas
- ~ clasificación: mejor representación
- La función de error tiene mínimos más claros
- Se limitan los grados de libertad locales, pero se permite una flexibilidad global

¿Por qué lo de que haya muchos nulos?

- Si queremos que haya al menos N procesadores activos, pero queremos que sólo sean el P% del total ¿cuántos hay en total? Prueba N y P en decenas

Autocodificadores

- Cada capa se inicializa como un codificador de las entradas
  - Entrada: capa anterior (o entrada externa), quizá perturbada
  - Salida: lo mismo, sin perturbación

Autocodificadores

- Plantea esquema para 6 entradas y capa de 4 procesadores

Autocodificadores-ajuste

- Se preajustan los pesos de las capas inferiores hacia arriba
- En cada caso se intenta hacer un autocodificador: que la salida coincida con la entrada
  - Capa intermedia de tamaño menor
  - Penalizar capa intermedia nula o robusta frente a ruido
  - Obligar a pocos activos evita soluciones triviales: la salida copia la entrada
- Las capas anteriores ya no se ajustan más, excepto al aprender la salida: descenso gradiente estocástico

Autocodificadores-ajuste

- Plantea el proceso para la red de 5 capas ocultas

Máquinas de Boltzmann/creencia profundas

- Cada capa se entrena como si fuera la oculta de una máquina de Boltzmann restringida
- La primera capa se contruye como MBR
- Las capas sucesivas también, pero fijando los pesos de las capas anteriores

Máquinas de Boltzman/creencia profundas

- Busca qué es una máquina de Boltzman restringida

Redes recursivas

- Pequeña red que se aplica para obtener una representación intermedia, sobre la que se vuelve a aplicar, etc. etc.
- Al final es una red profunda pero con la restricción de que los pesos son los mismos en cada copia de la pequeña red

Redes recursivas

- ¿Cuál es la relación con el caso de que los procesadores compartan pesos?

Red recursiva: memoria de largo y corto plazo

- Red modular construida con pequeños bloques que son miniredes realimentadas
- Cada bloque tiene cuatro lotes de entradas
- Se usa recursivamente

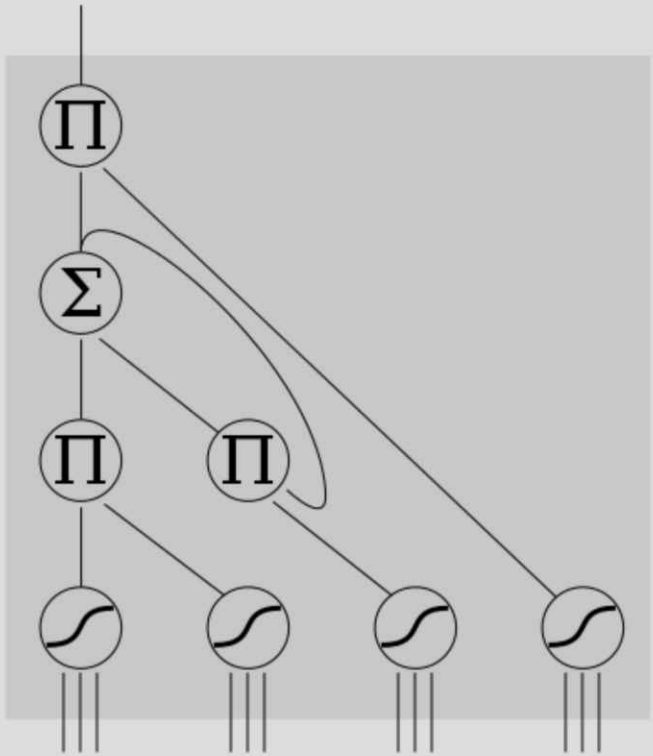

Redes convolutivas - Idea

- Entradas: secuencias, series históricas, señal en el tiempo, imágenes, señales en el espacio
- Capa clásica:

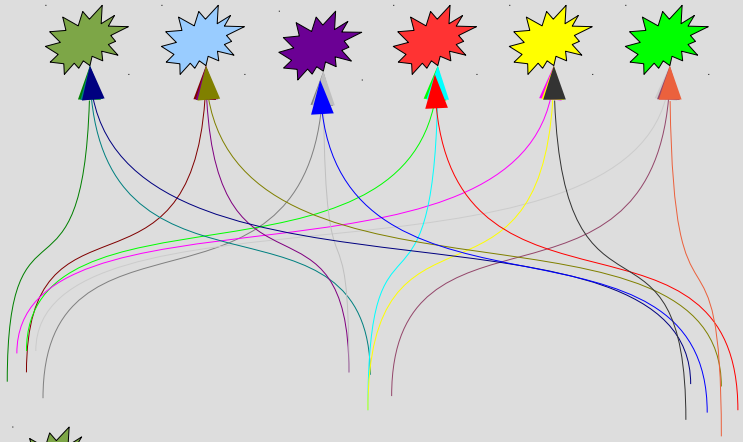

- Capa convolutiva:

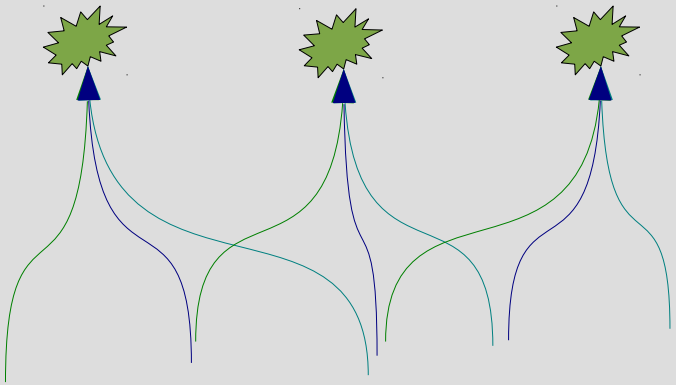

Redes convolutivas - idea

- Comenta un caso de convolución que conozcas

Red profunda no convolutiva

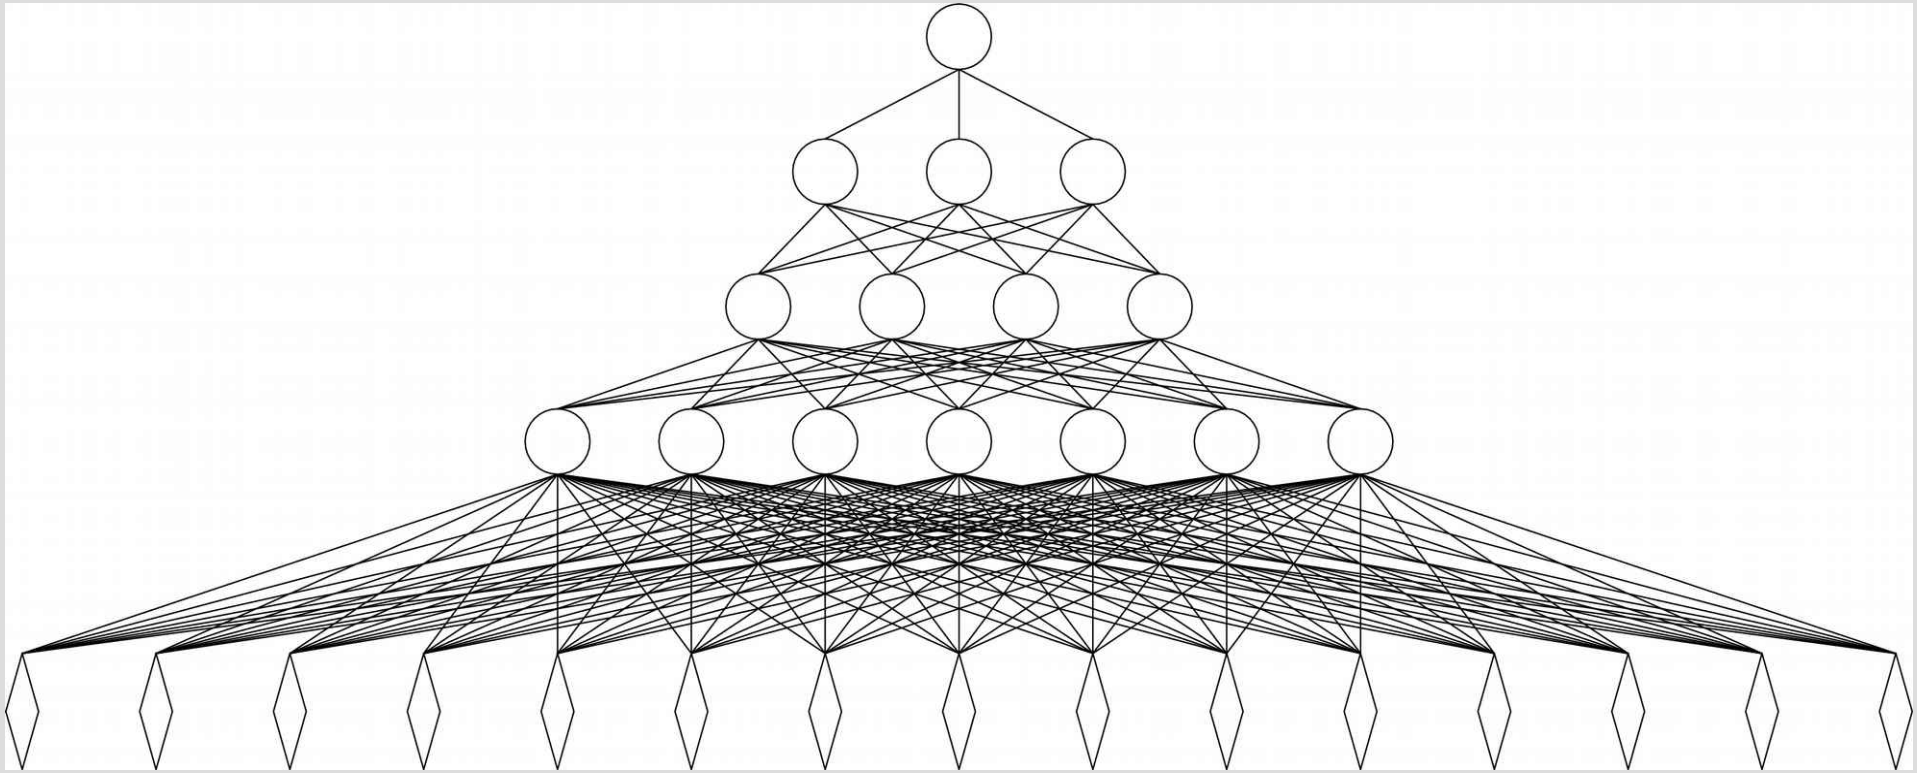

Red profunda no convolutiva

- ¿Cuántos pesos tiene?

Red profunda con conexión convolutiva

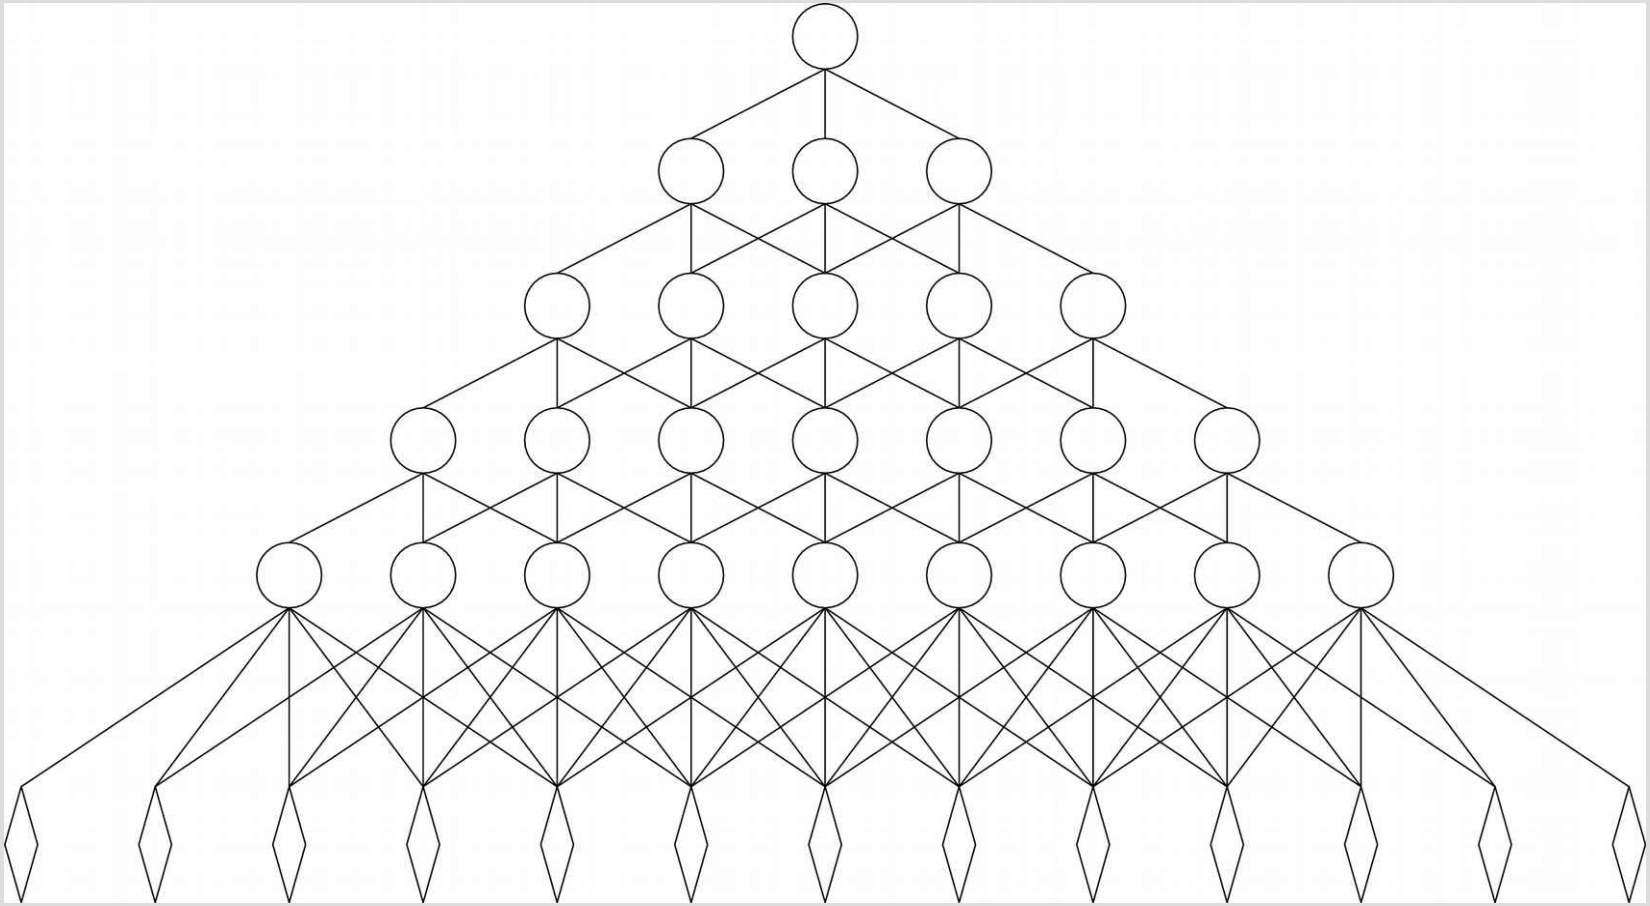

Red profunda con conexión convolutiva

- ¿Cuántos procesadores ocultos hay en realidad?
- ¿Cuántos pesos tiene?

Red profunda convolutiva: hay 1 procesador libre por capa

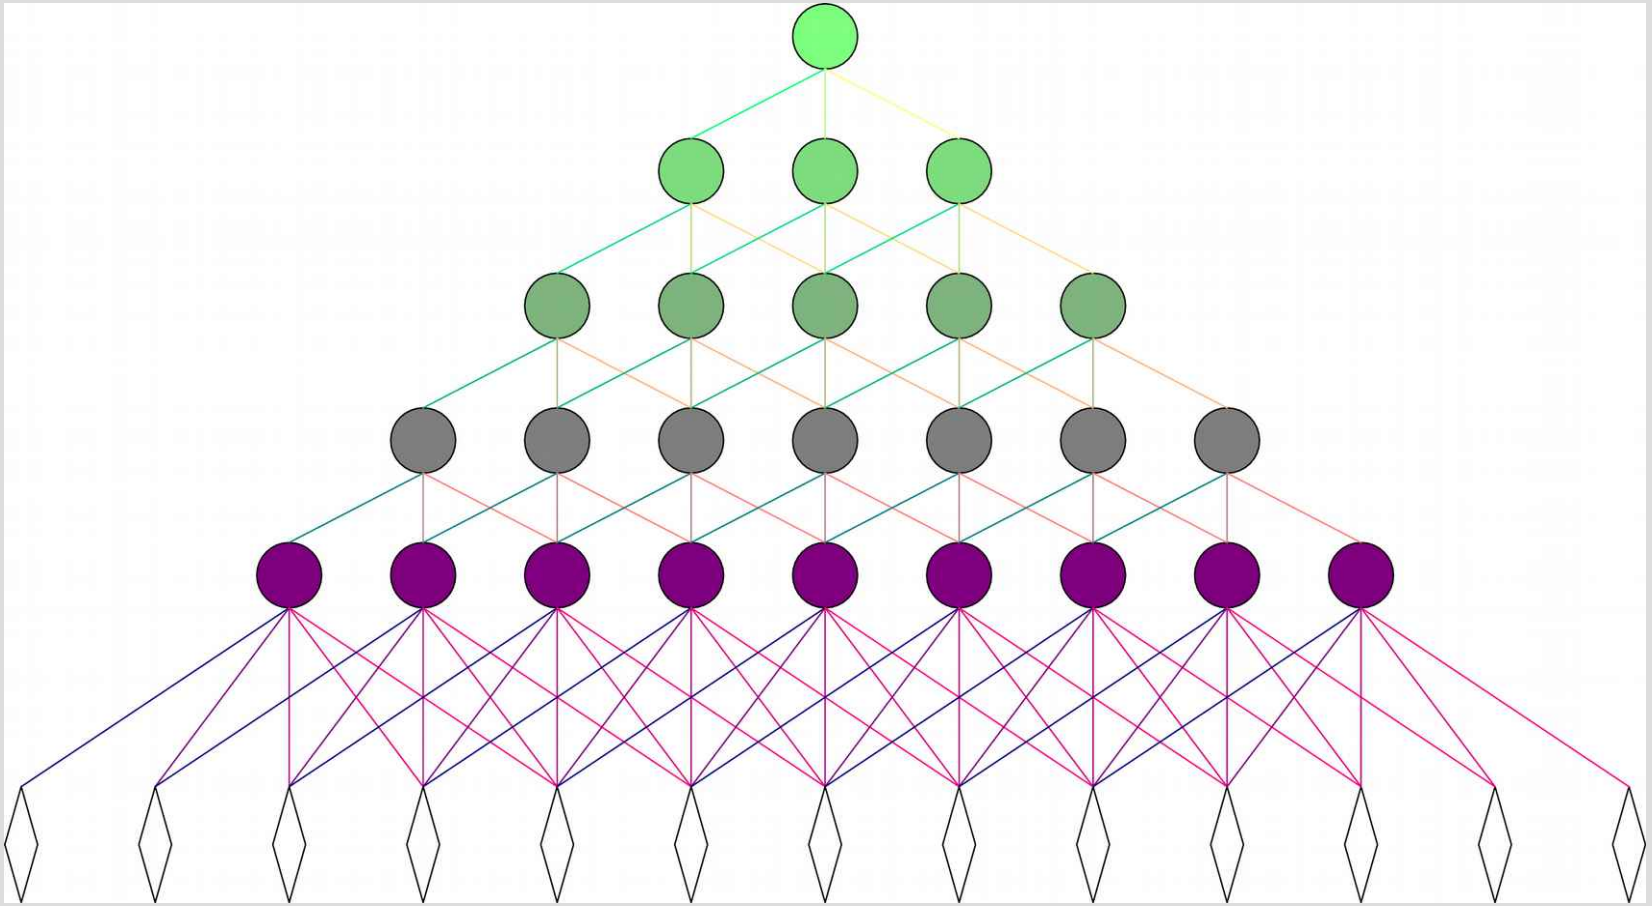

Red profunda convolutiva: 1 procesador libre por capa

- ¿Cuántos pesos tiene?

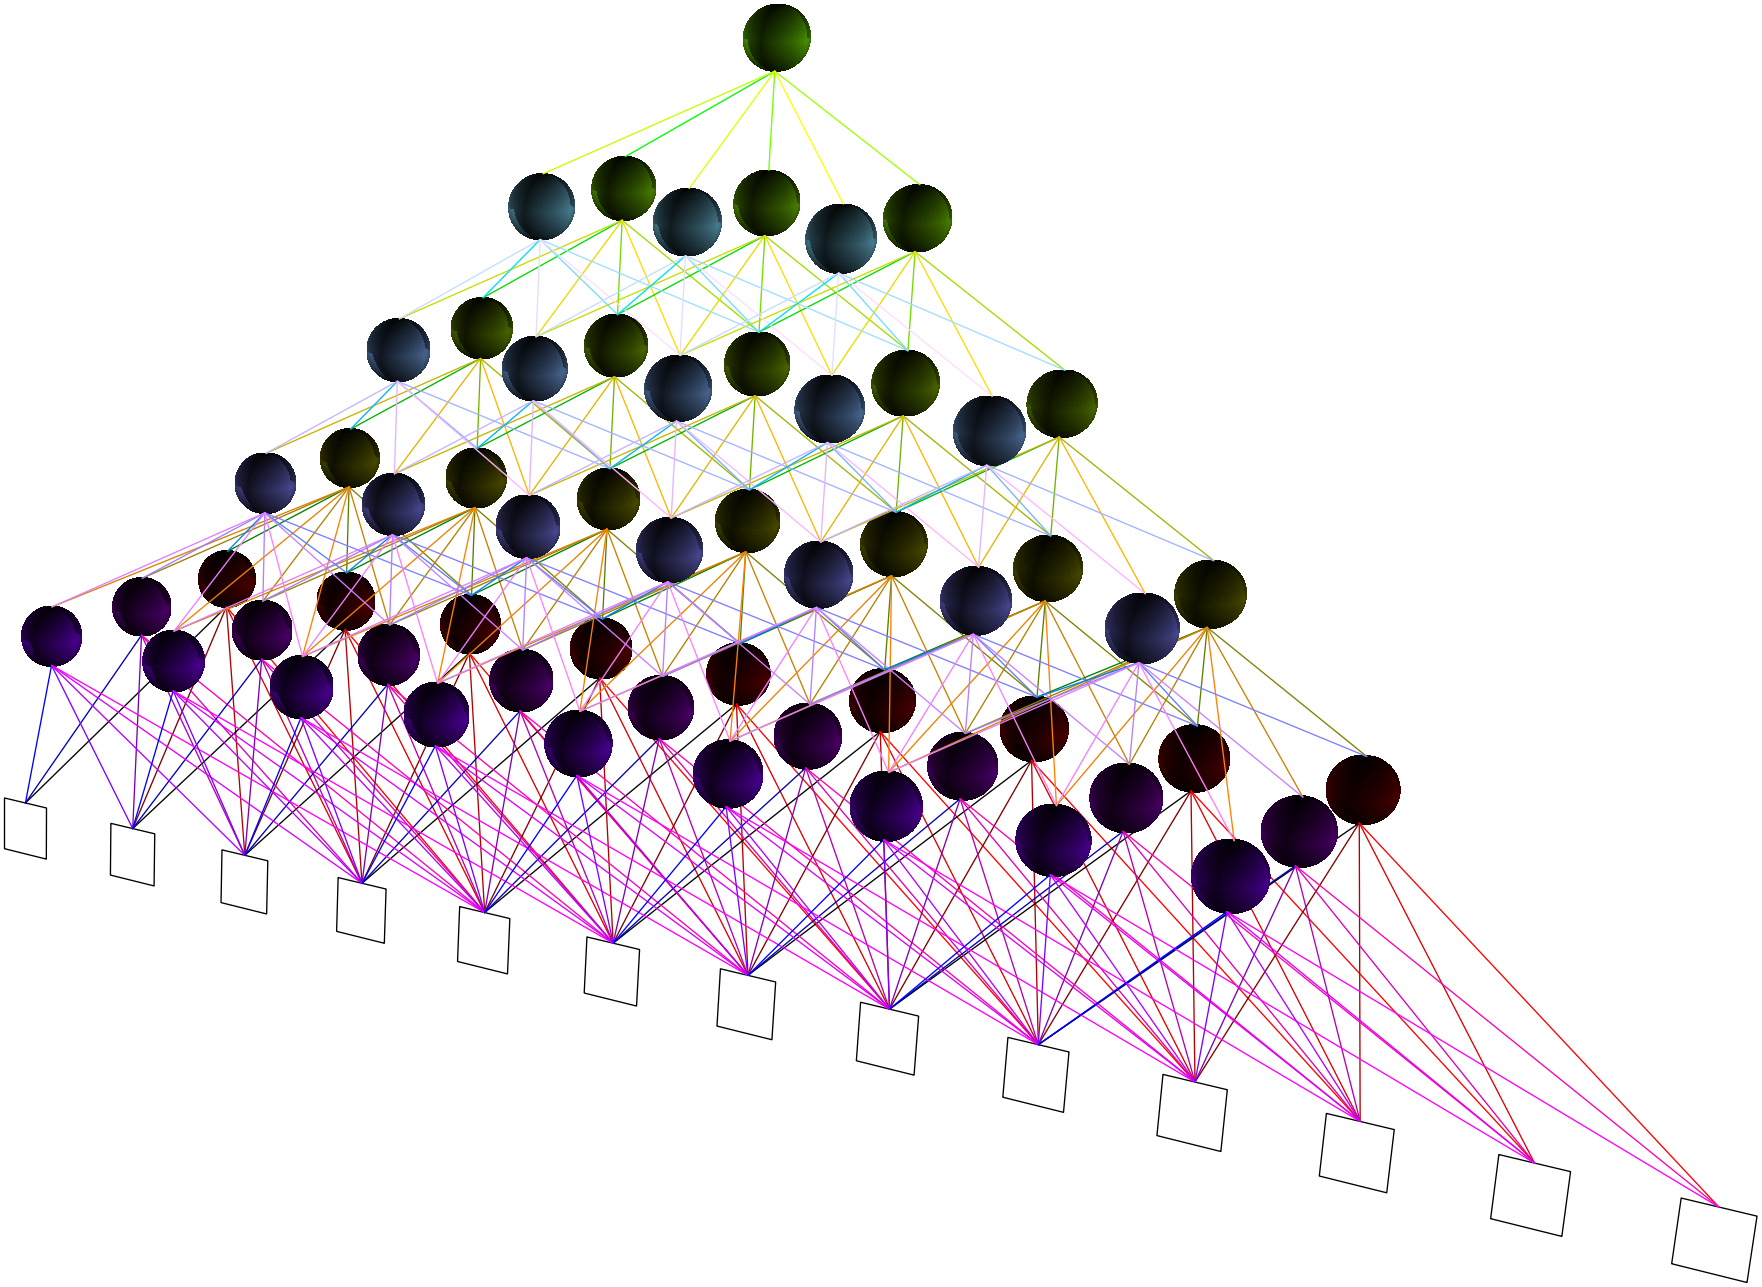

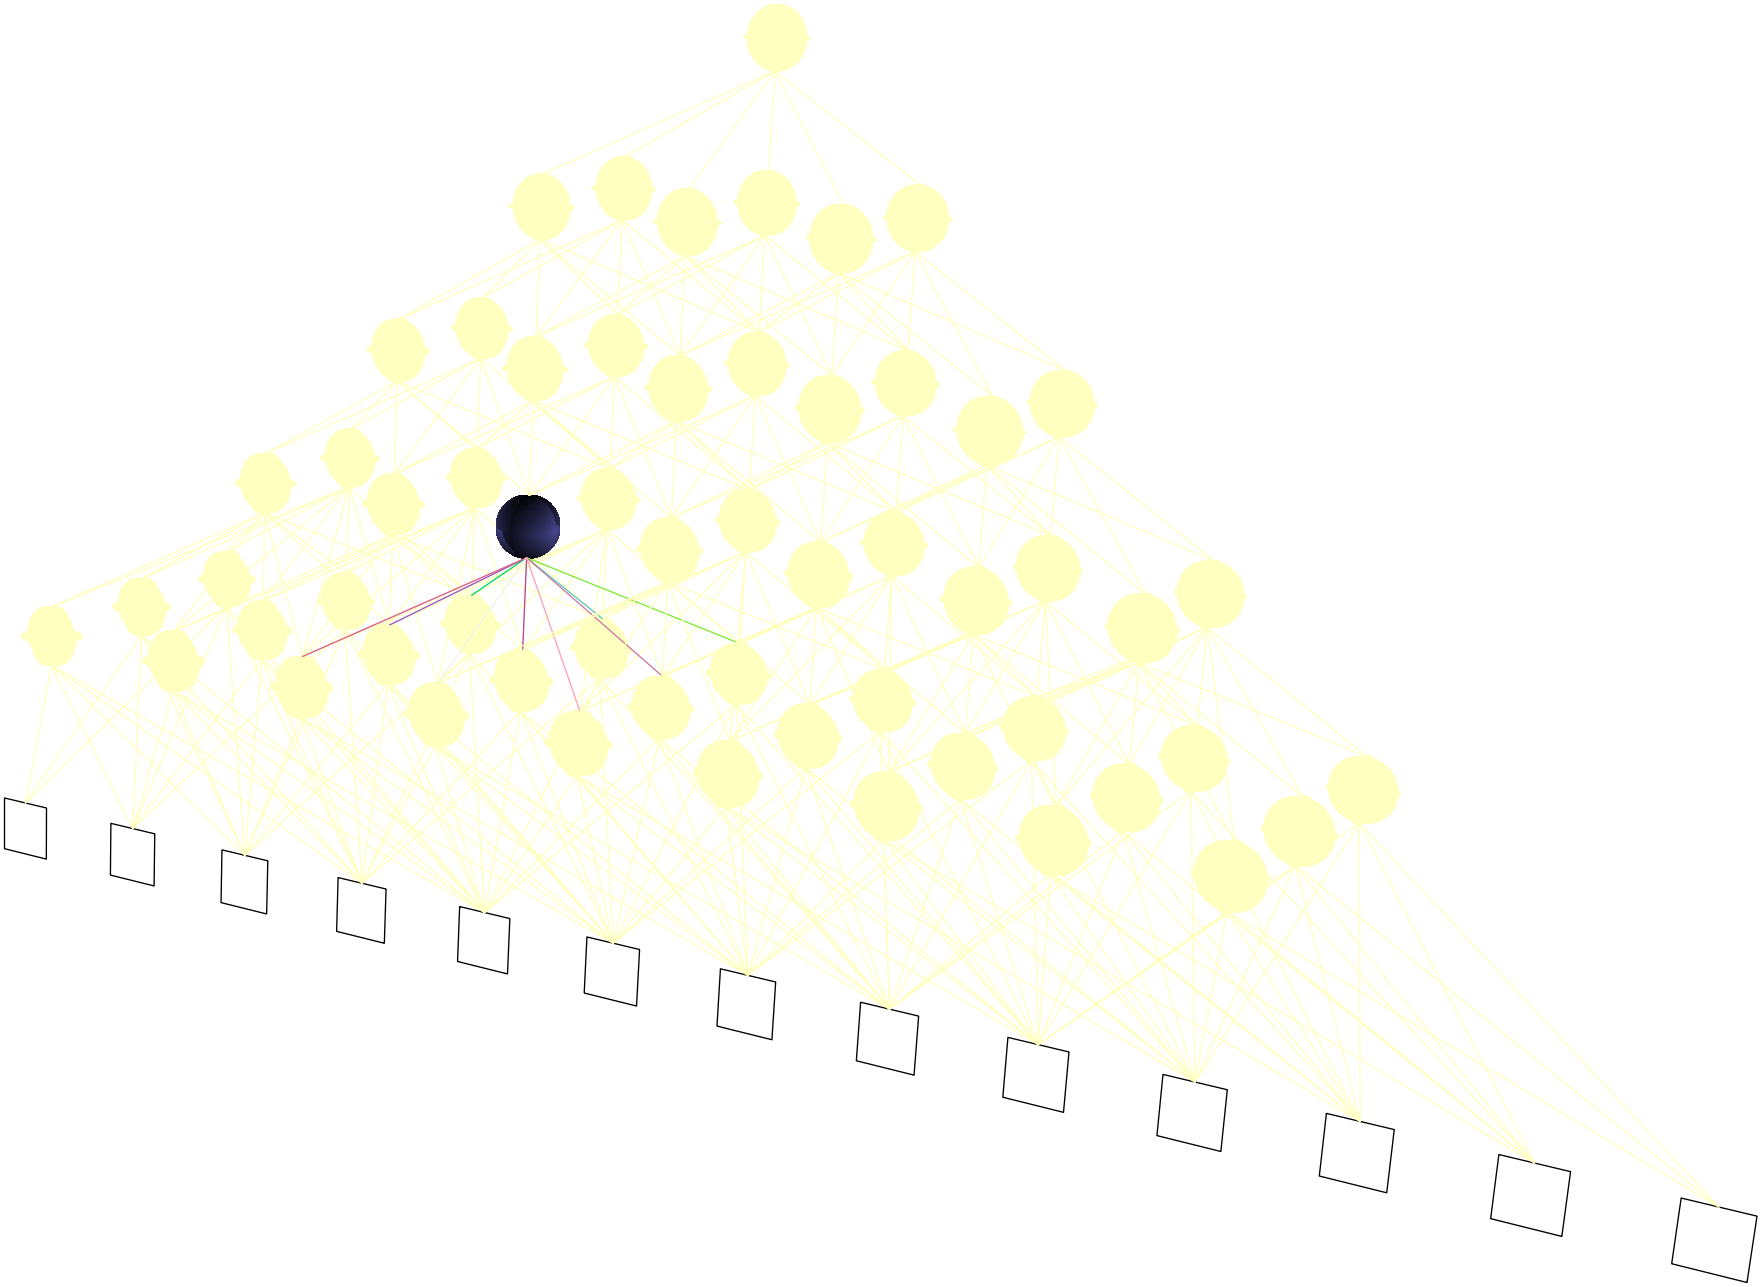

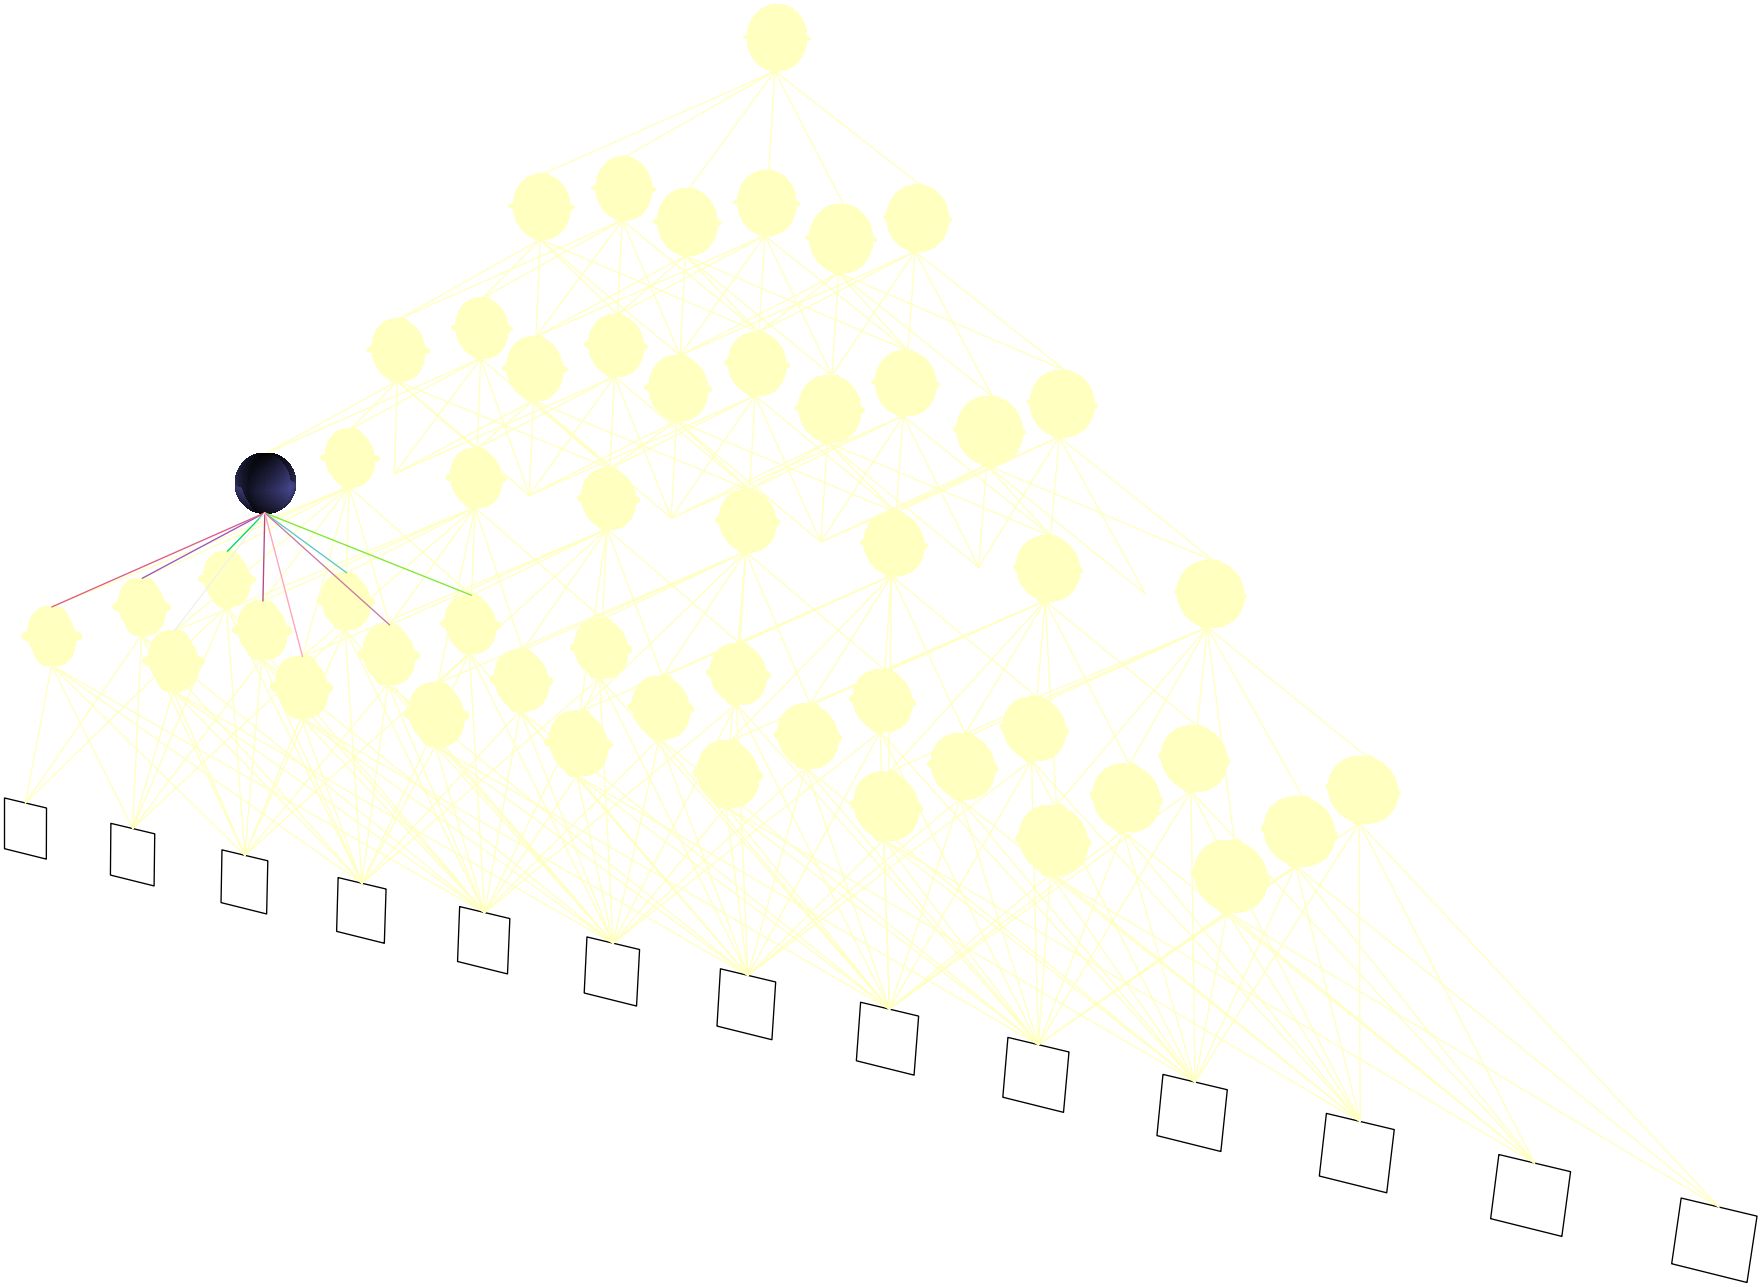

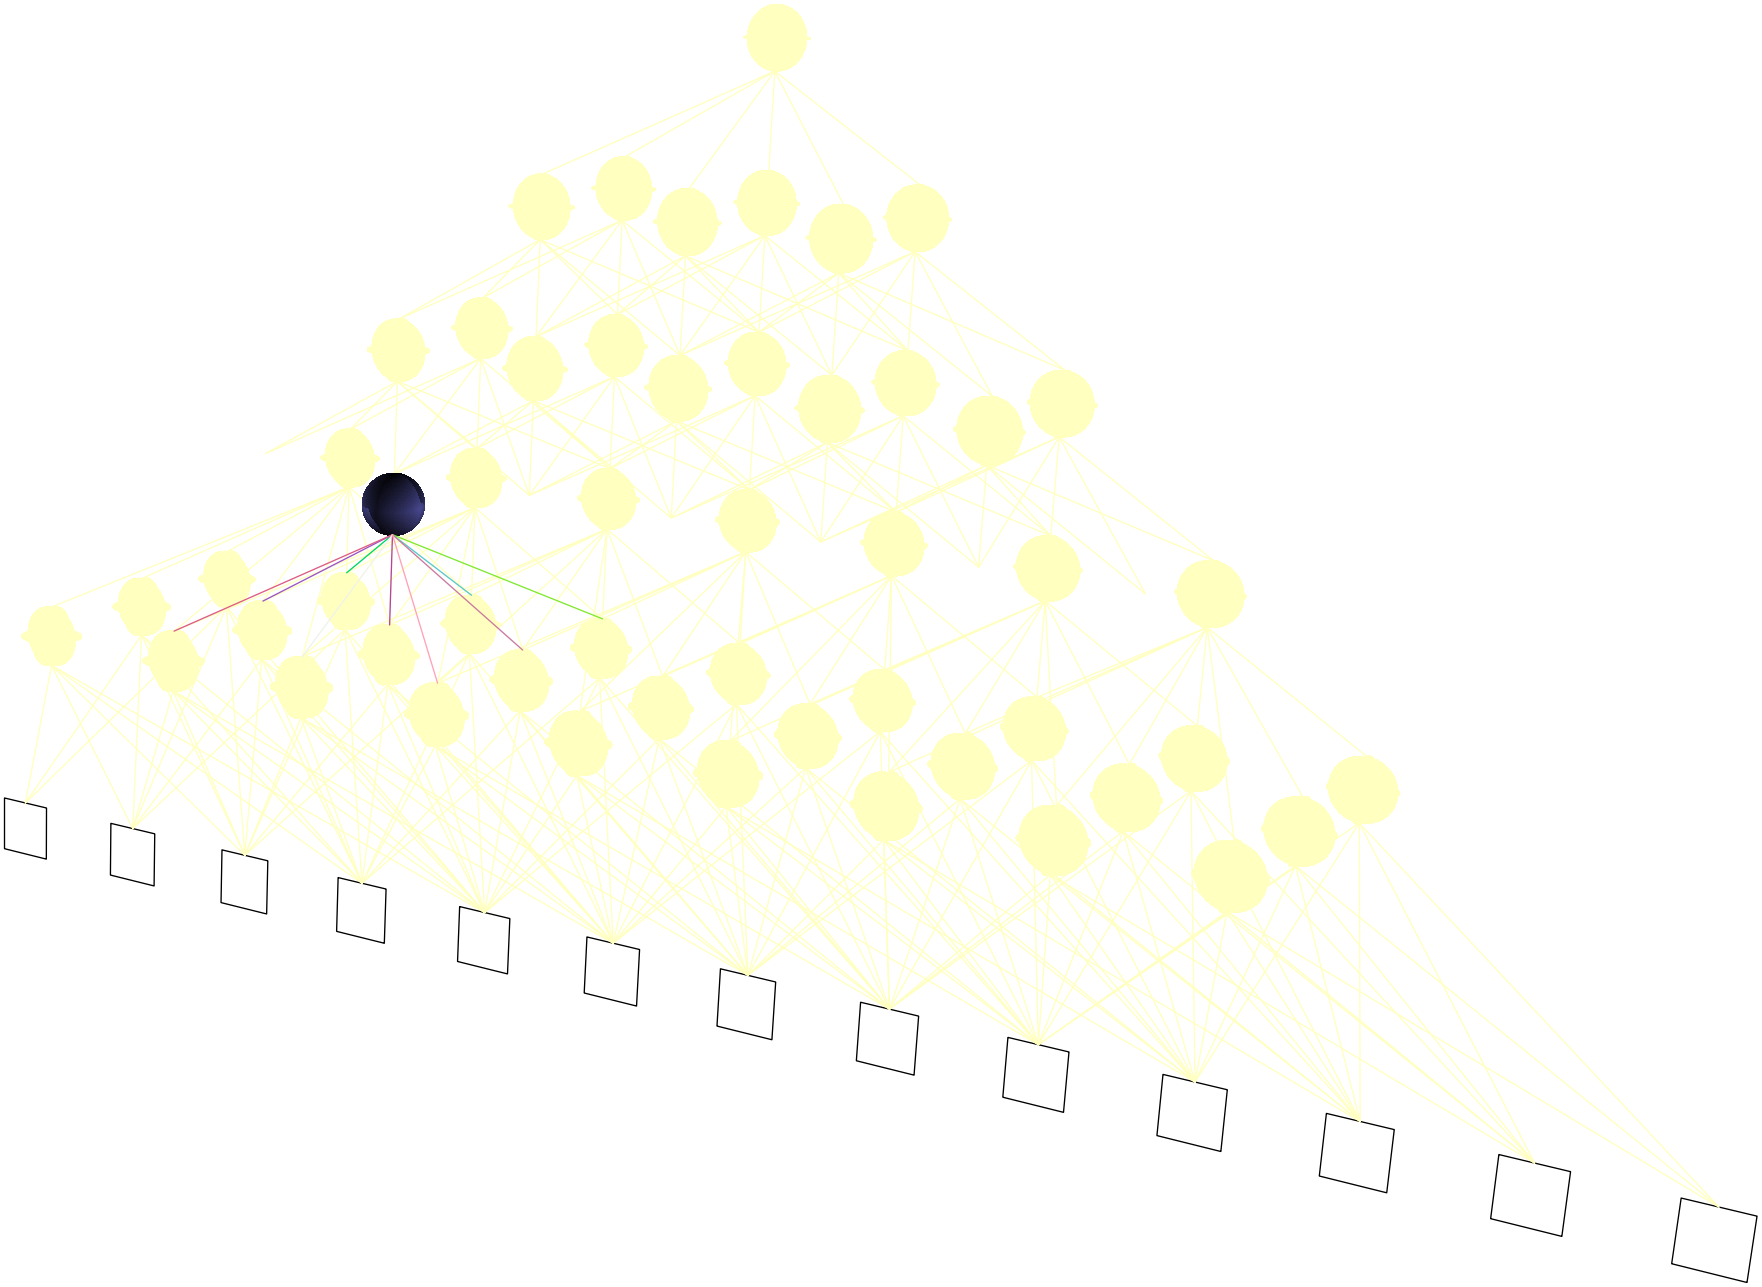

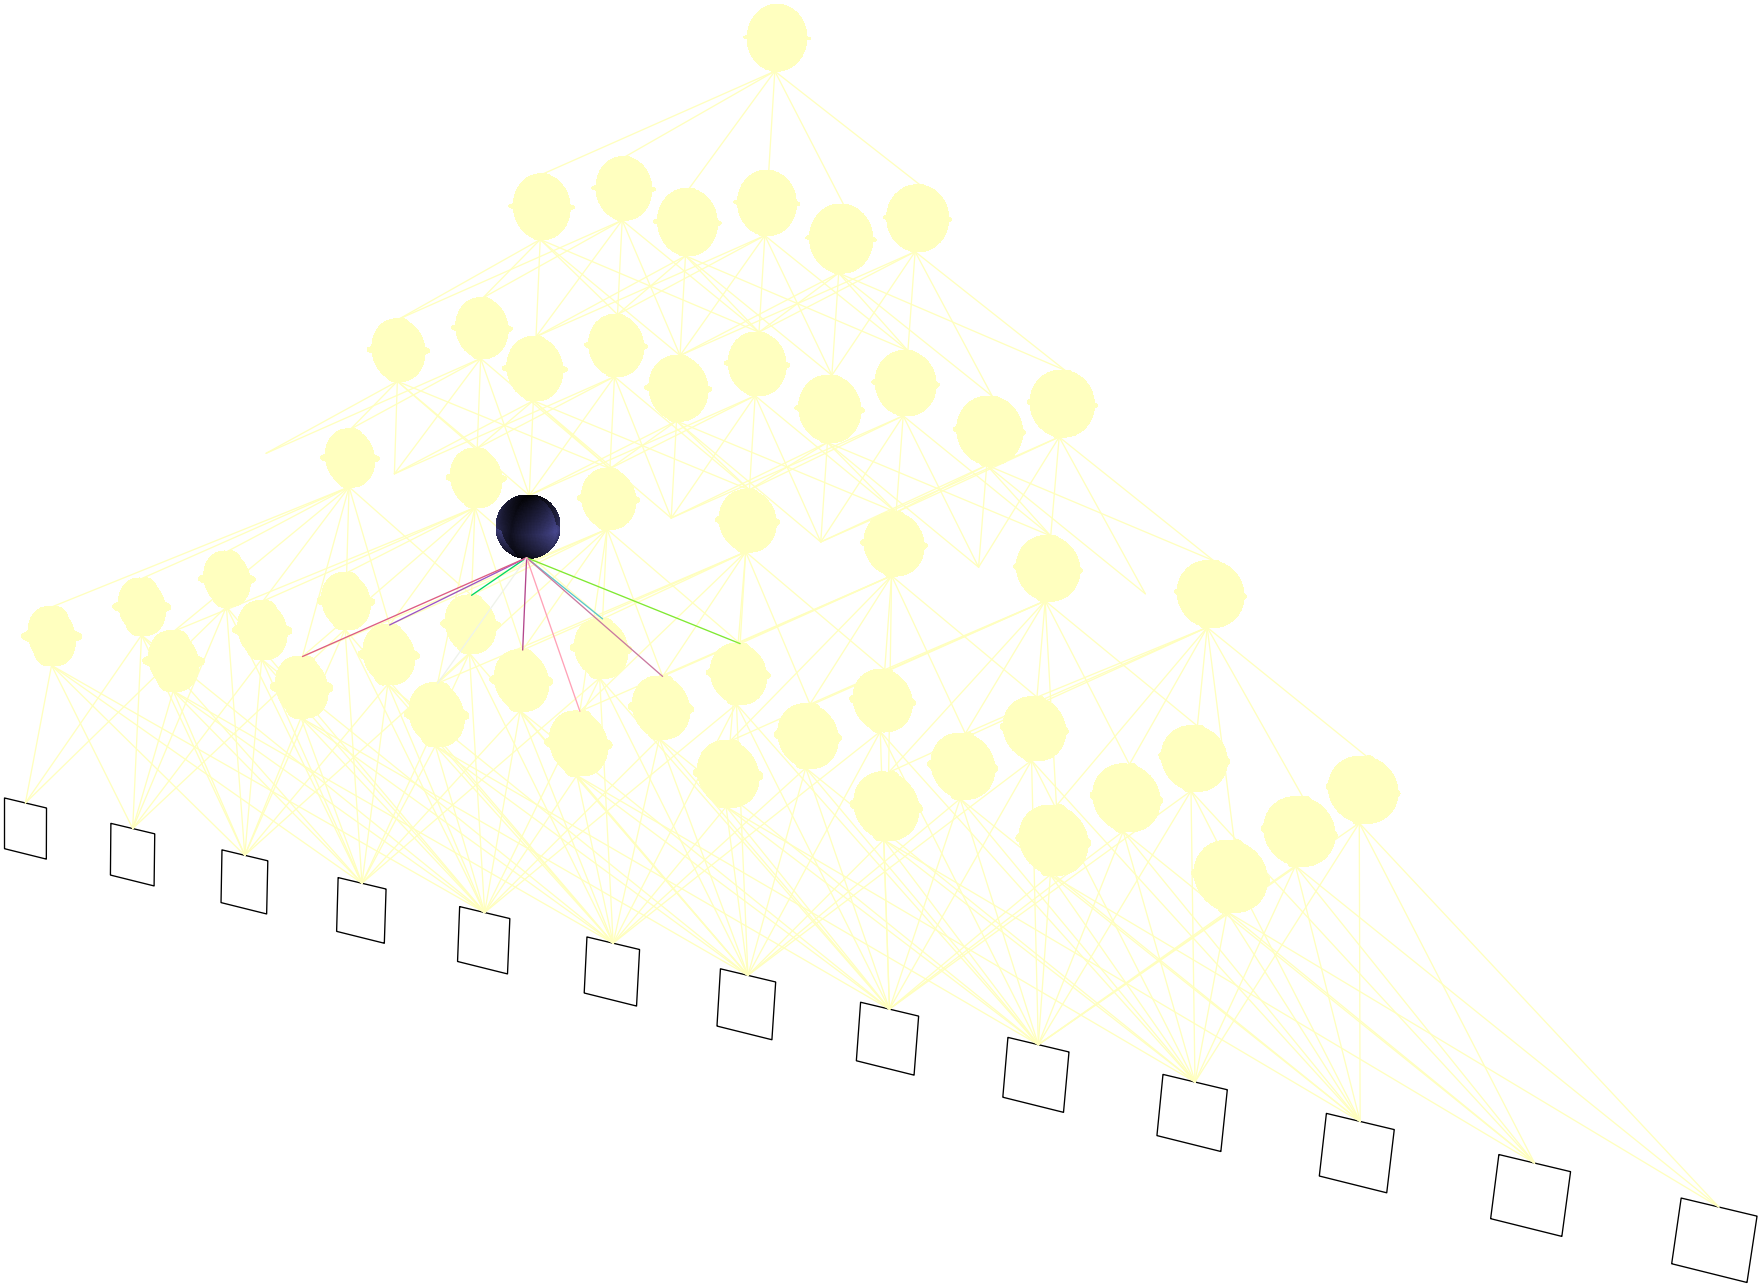

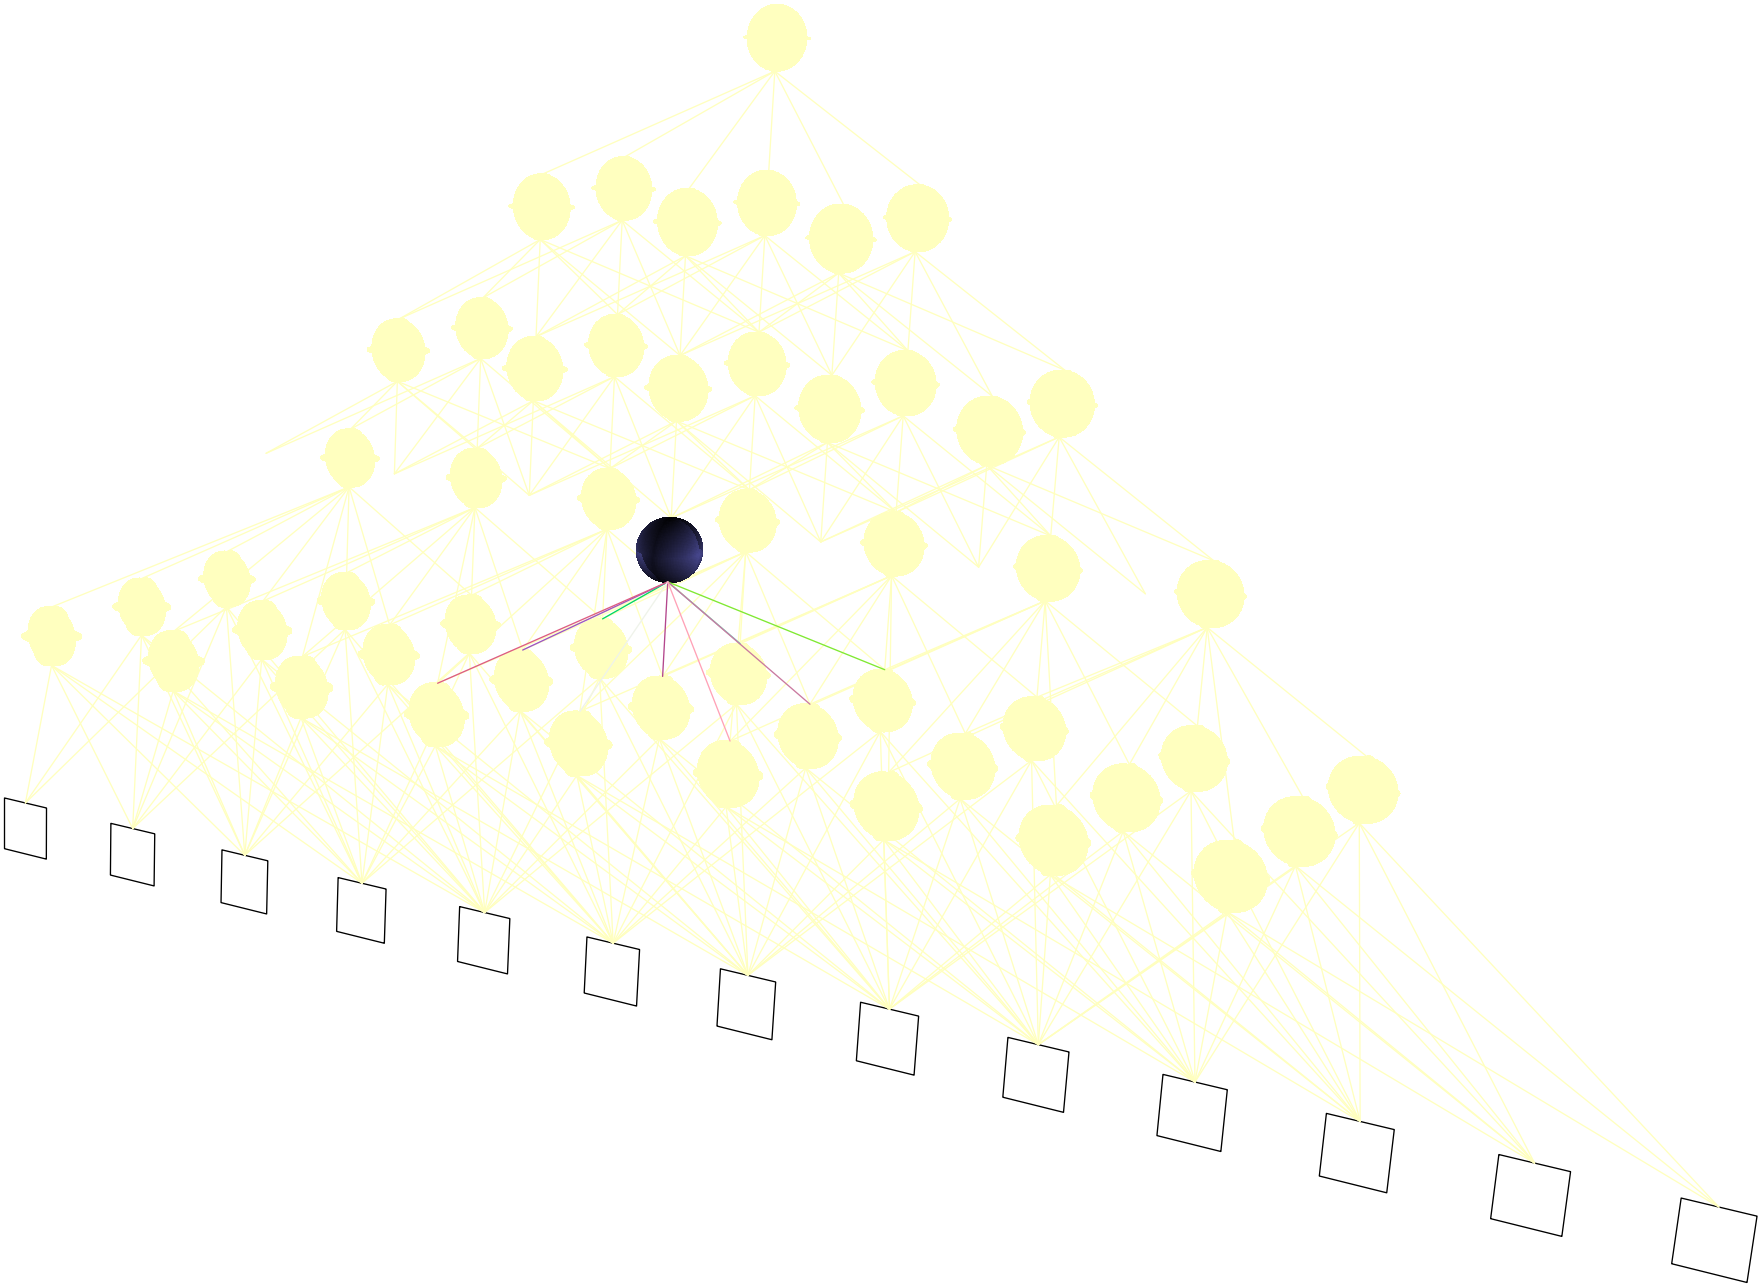

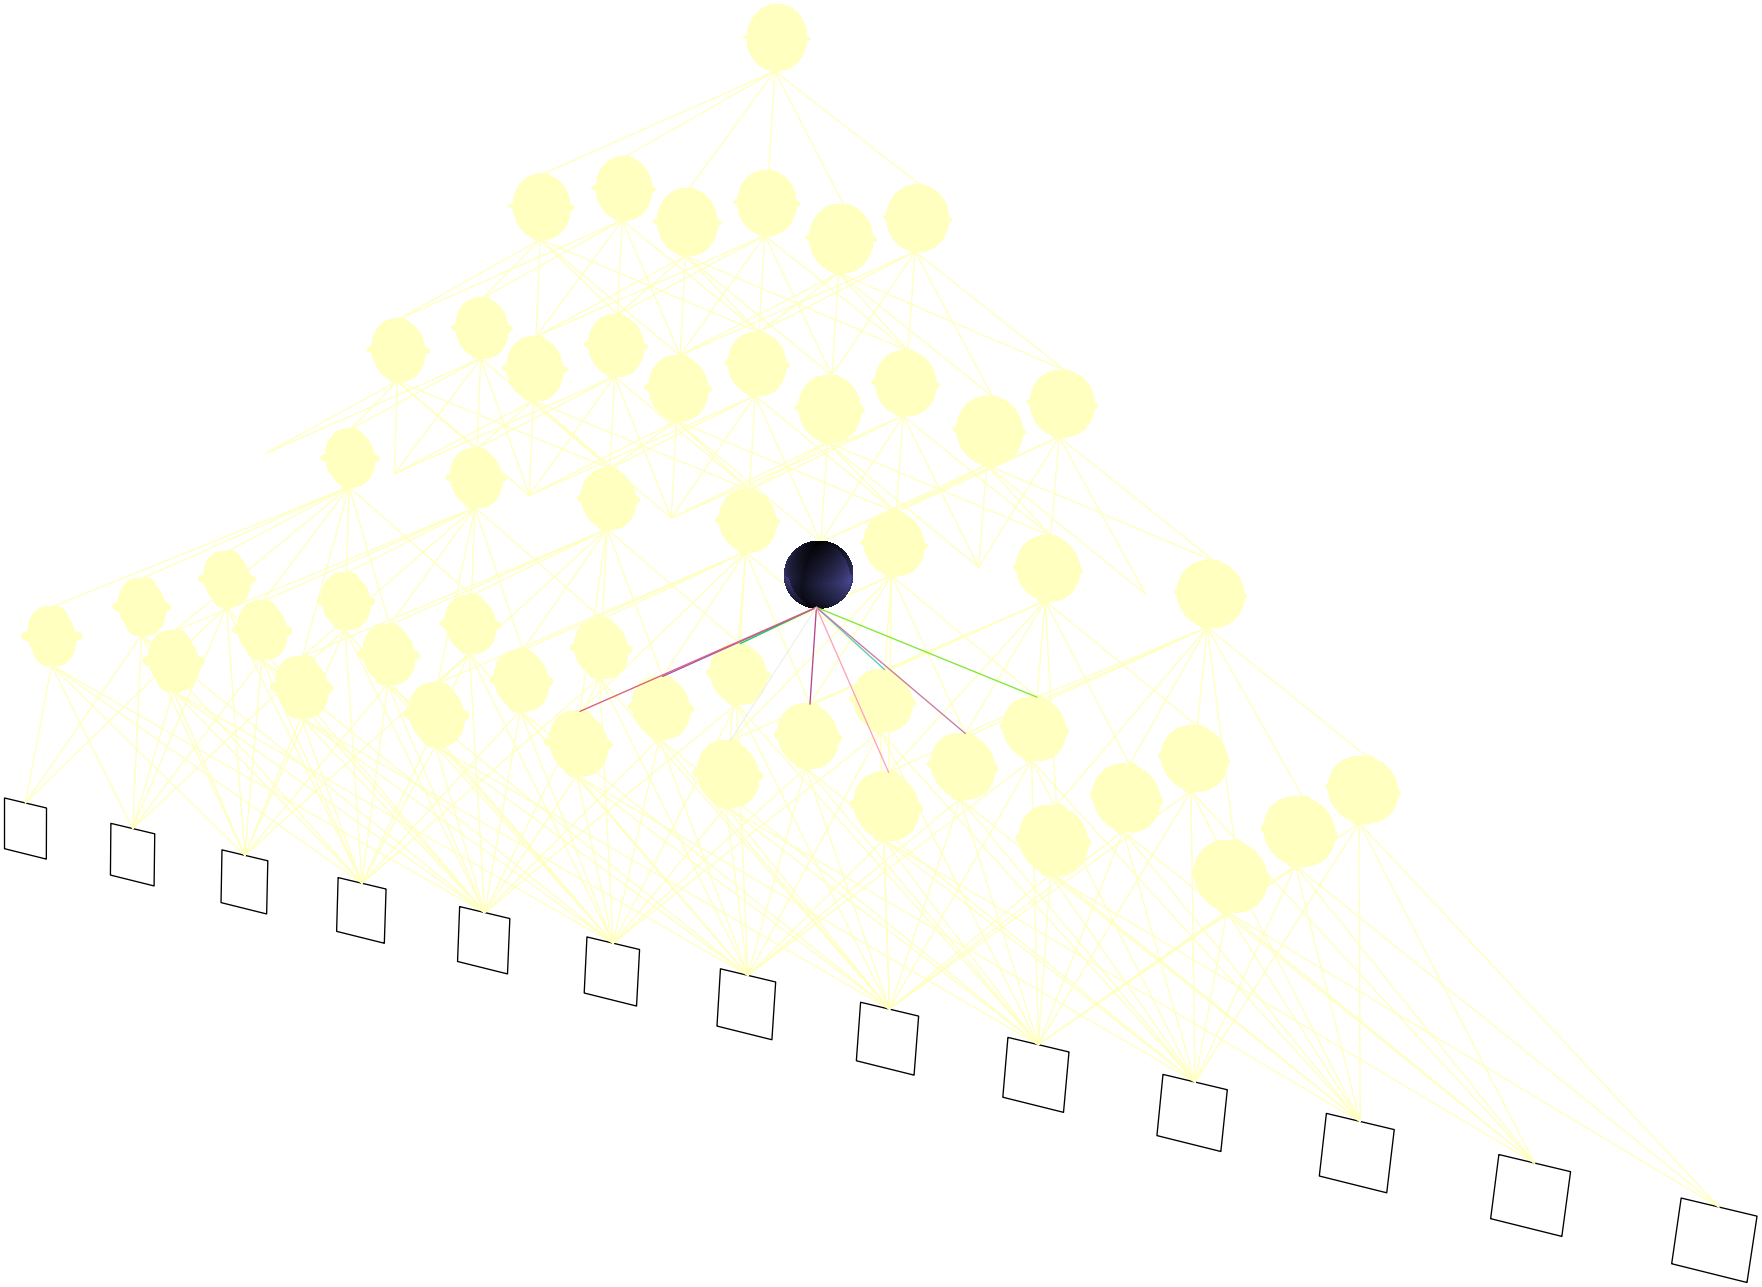

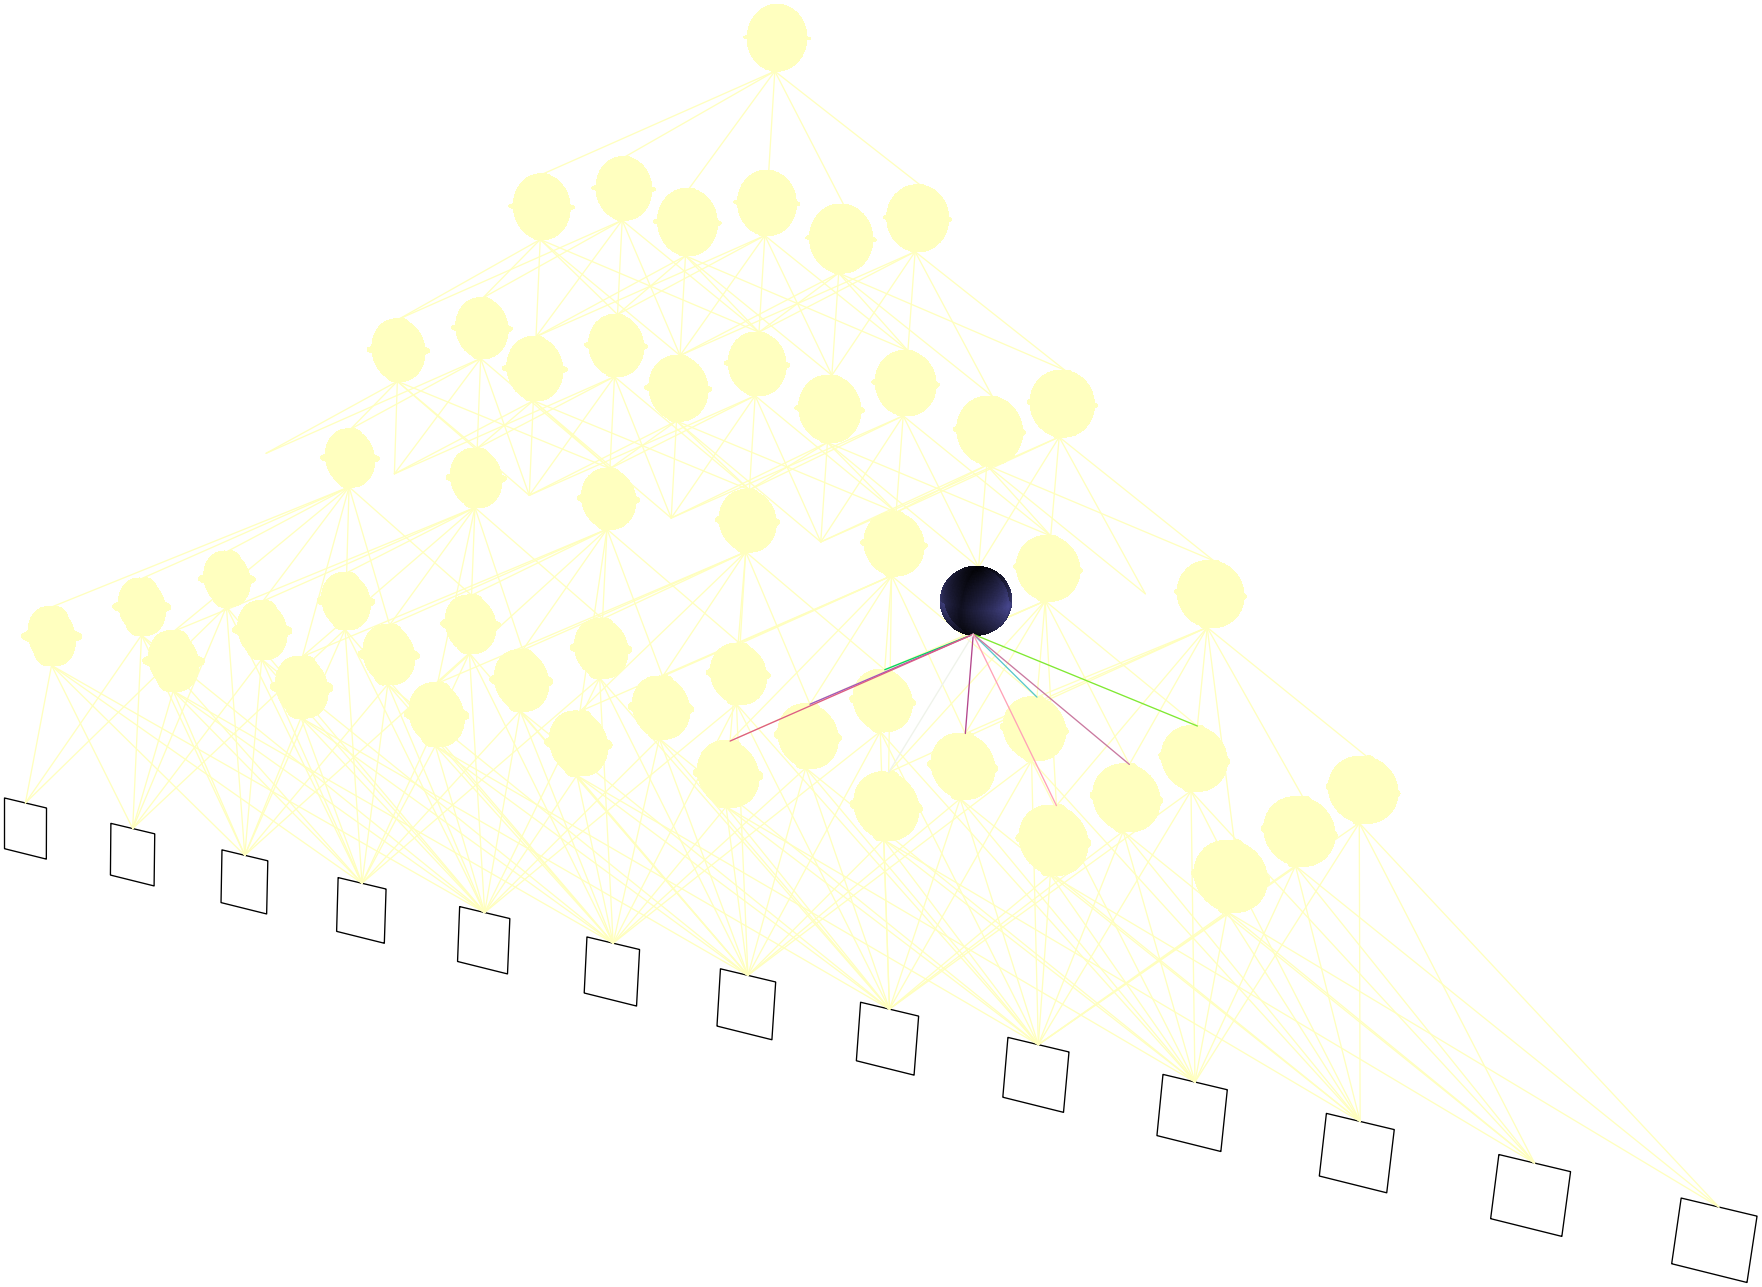

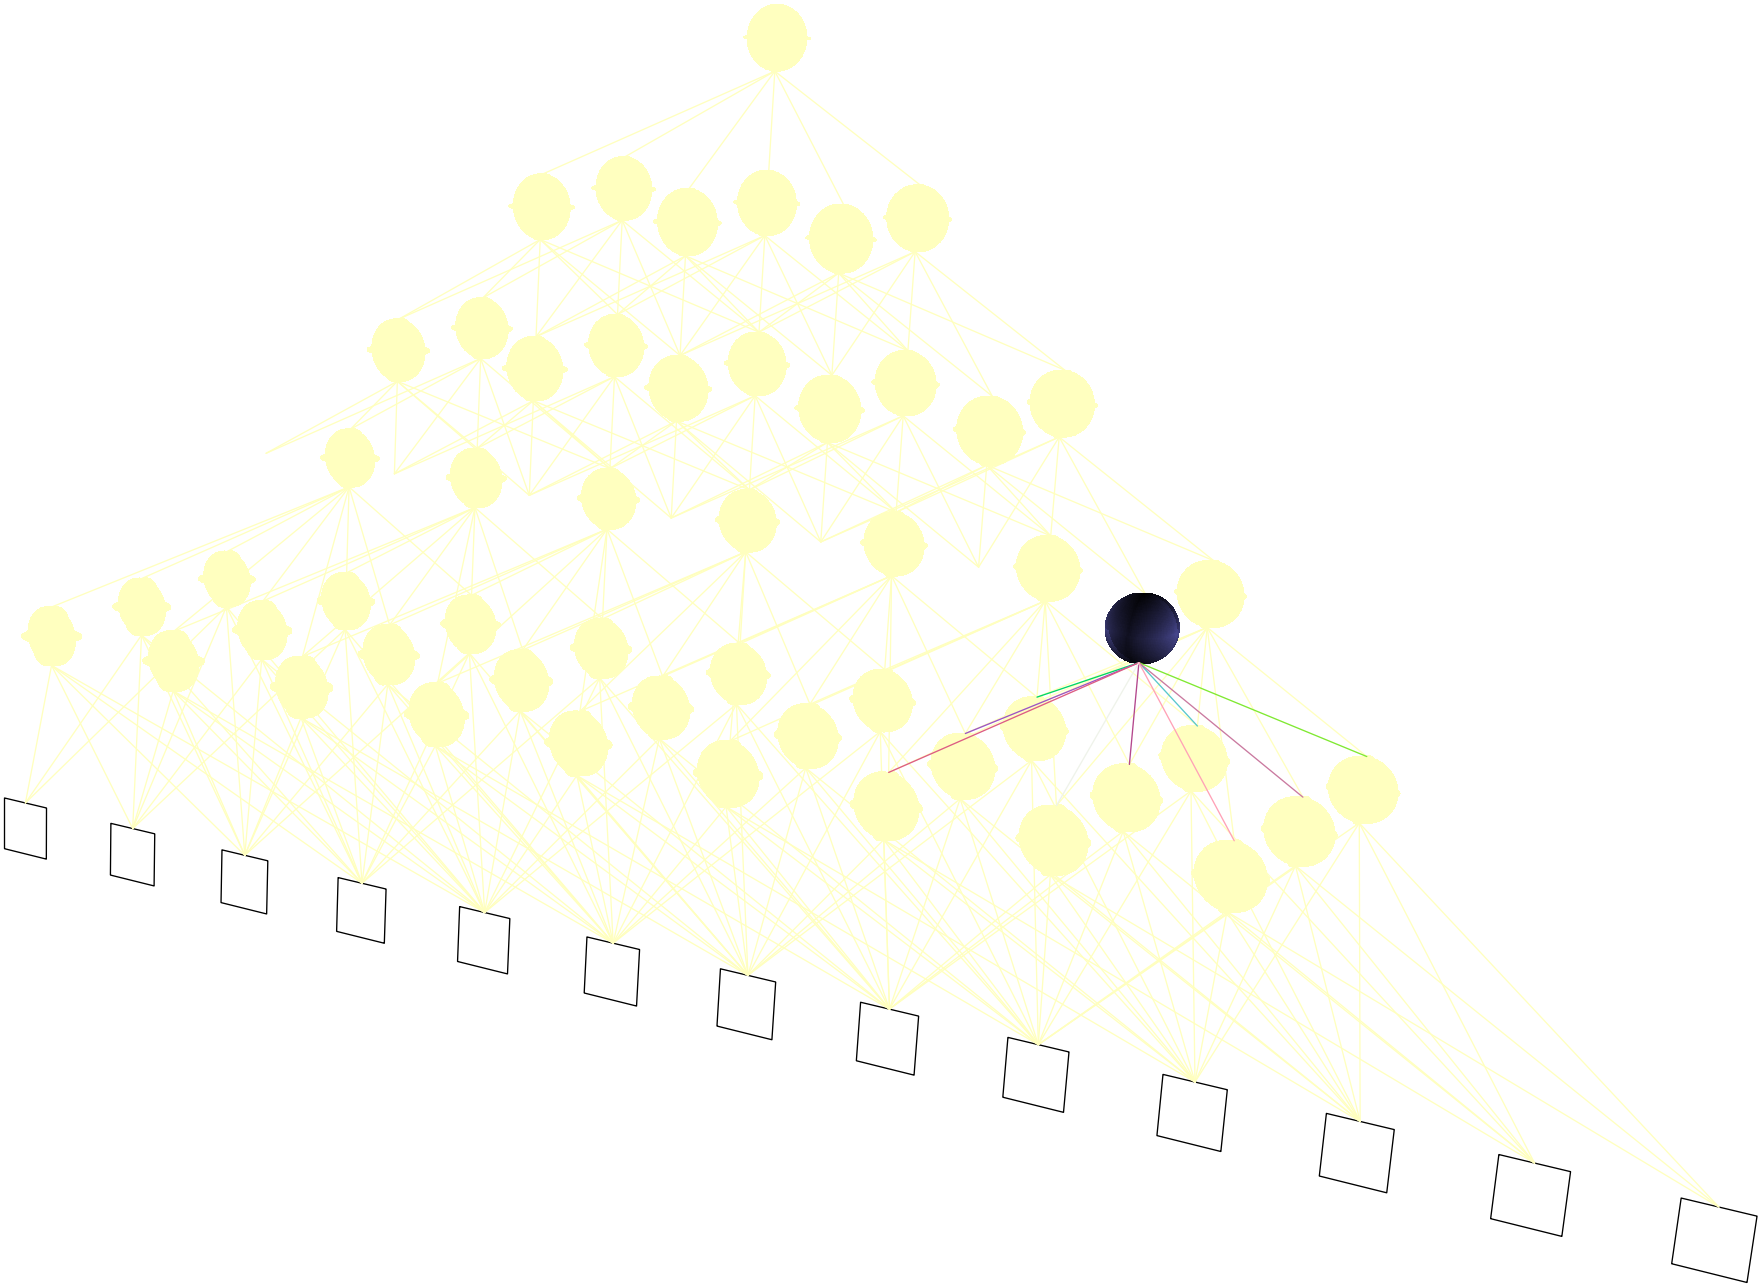

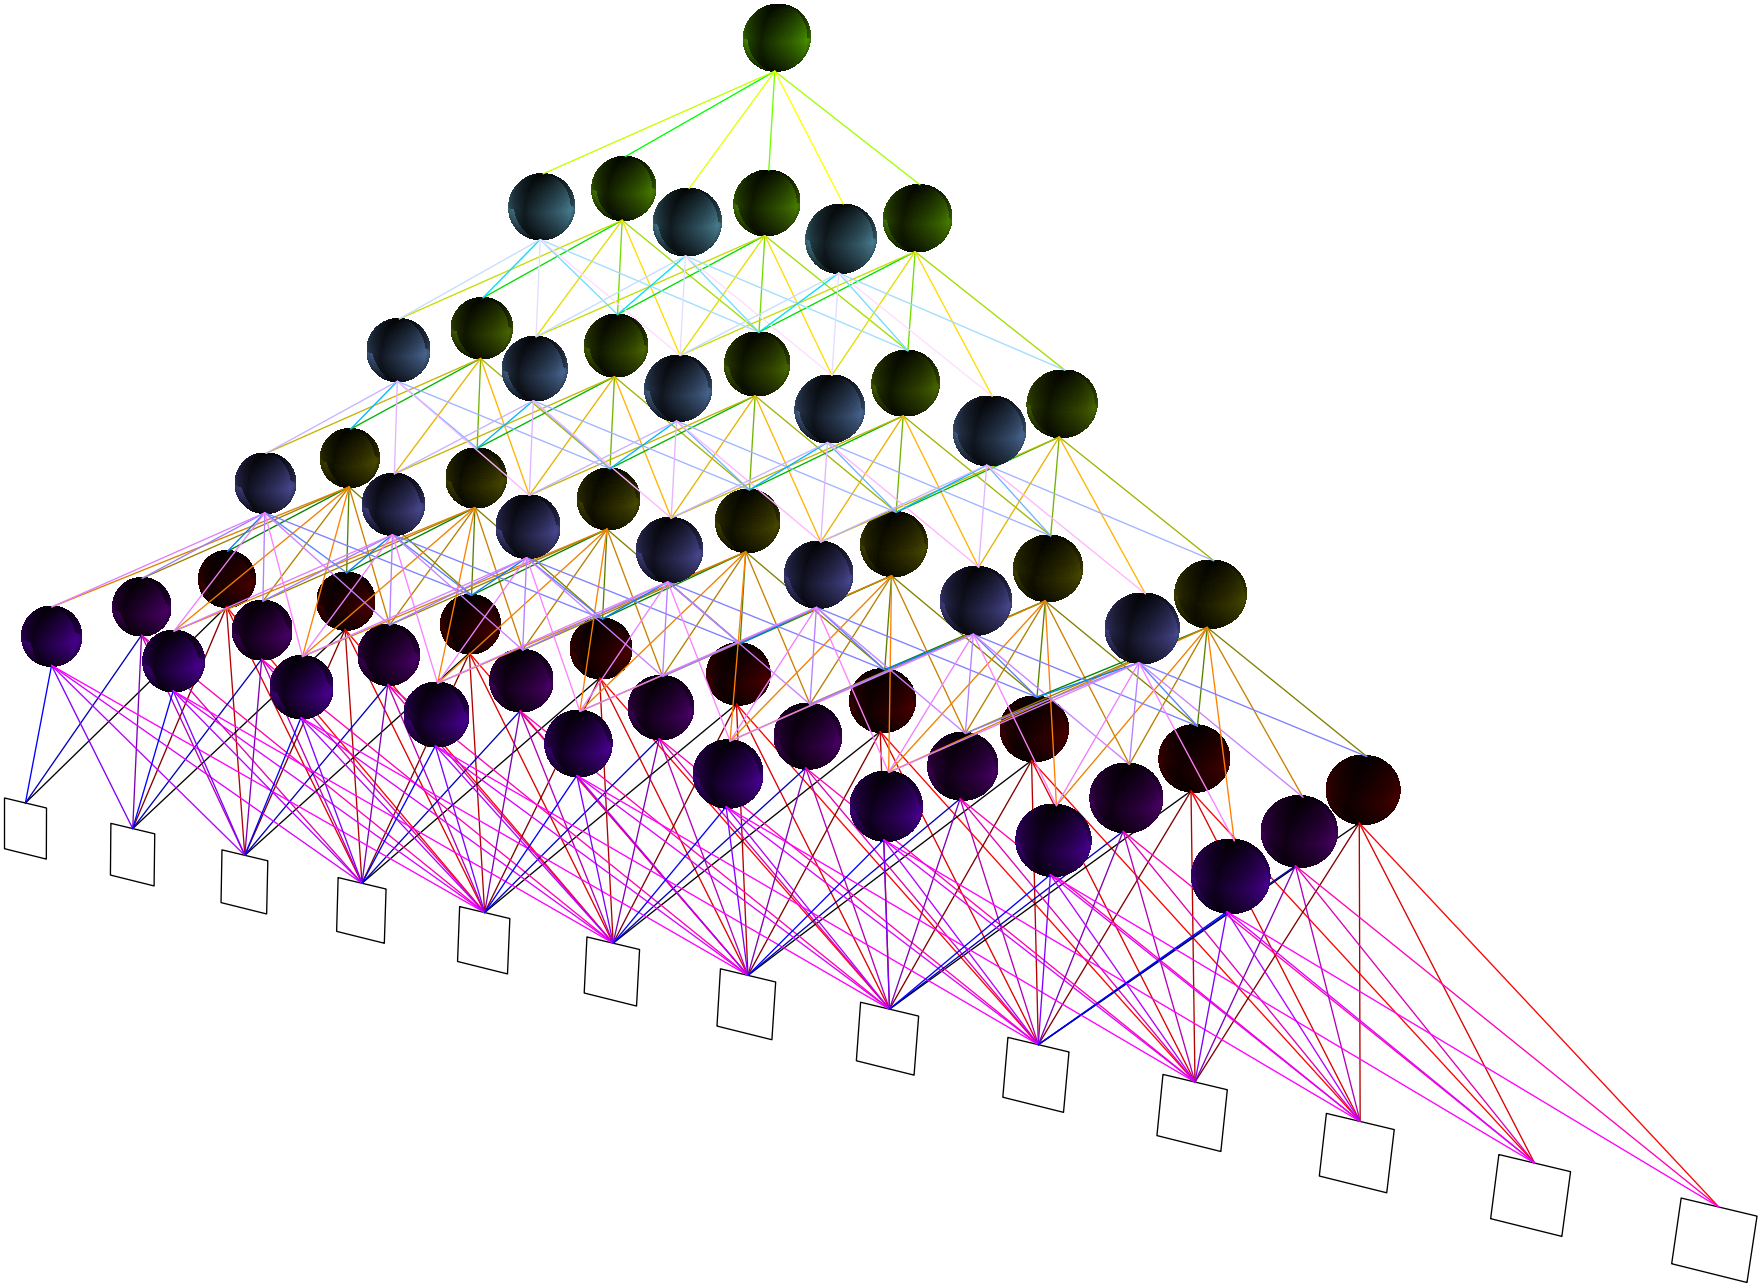

Red profunda convolutiva: varios procesadores libres por capa

- ¿Cuántos procesadores distintos tiene en cada capa?
- ¿Cuántos pesos tiene?

Paso, salto, ancho de convolución

- La capa hace un tipo de filtro de su entrada
- Ancho del filtro (kernel size)
- Paso del filtro (dilation)
- Salto entre filtros (stride)

Paso, salto, ancho de convolución

- En el ejemplo presentado, ¿cuáles son el paso, salto y ancho?
- Plantea un caso de paso 2, salto 2 y ancho 4
- Si la longitud de la entrada es 100, ése es un procesador libre de una capa y hay 4 en esa capa ¿Cuántos pesos tiene la capa?
- Y si es bidimensional (entrada: imagen) ¿hay 1 paso, 1 salto, 1 ancho?

salto=paso=1, ancho=3

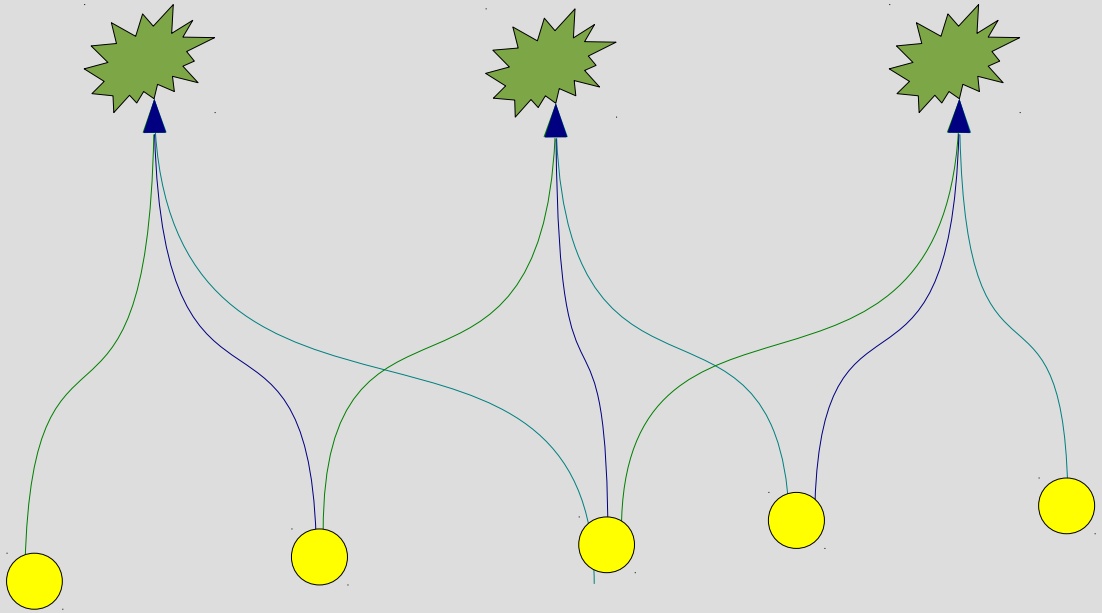

salto=paso=1, ancho=2

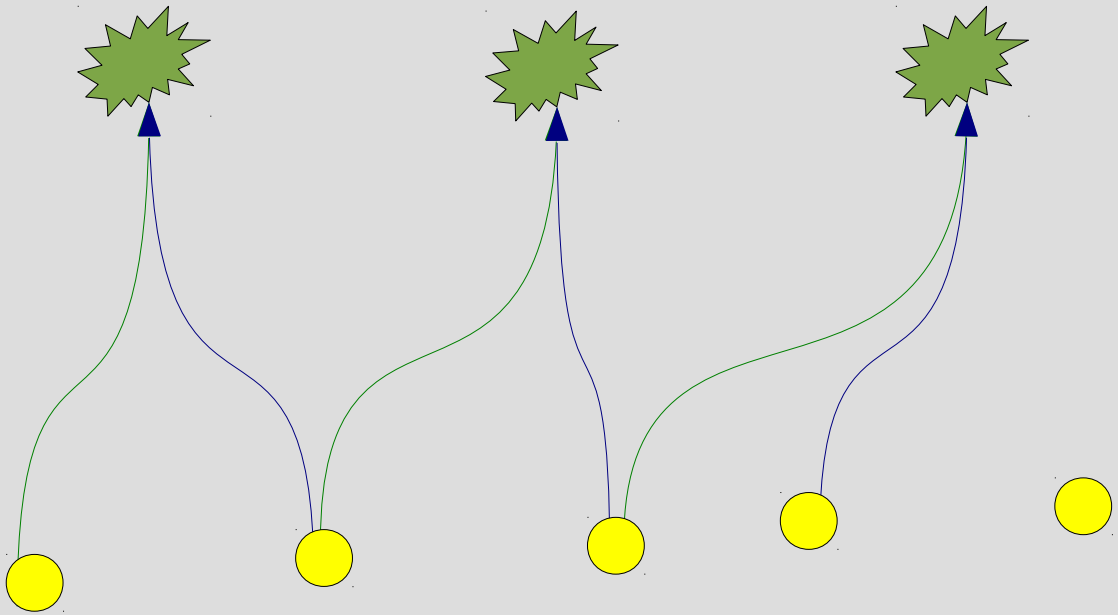

salto=paso=1, ancho=3

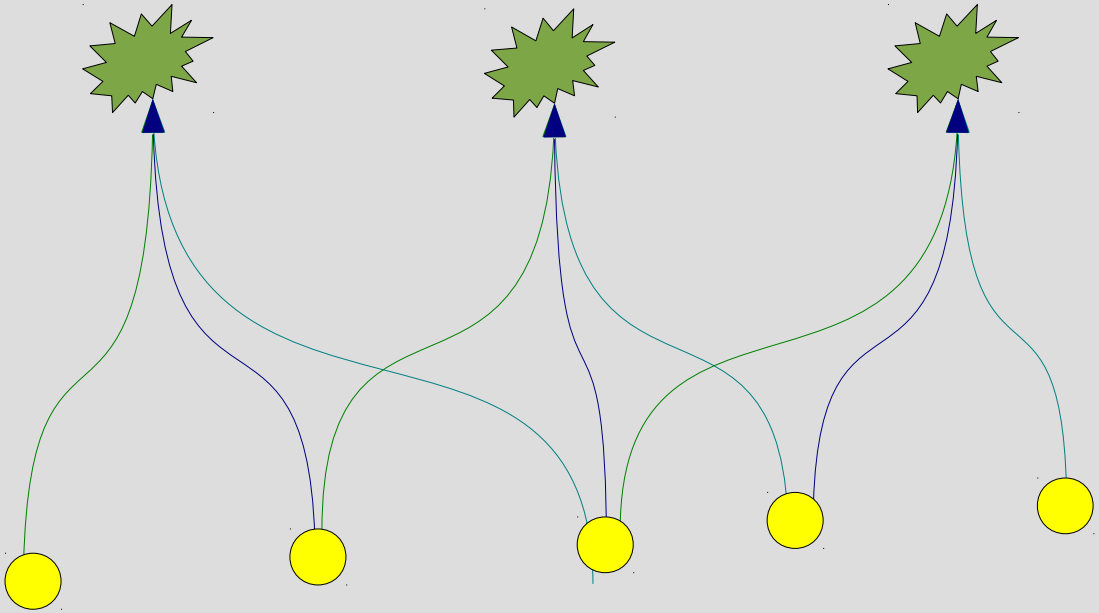

paso=1, ancho=3, salto=2

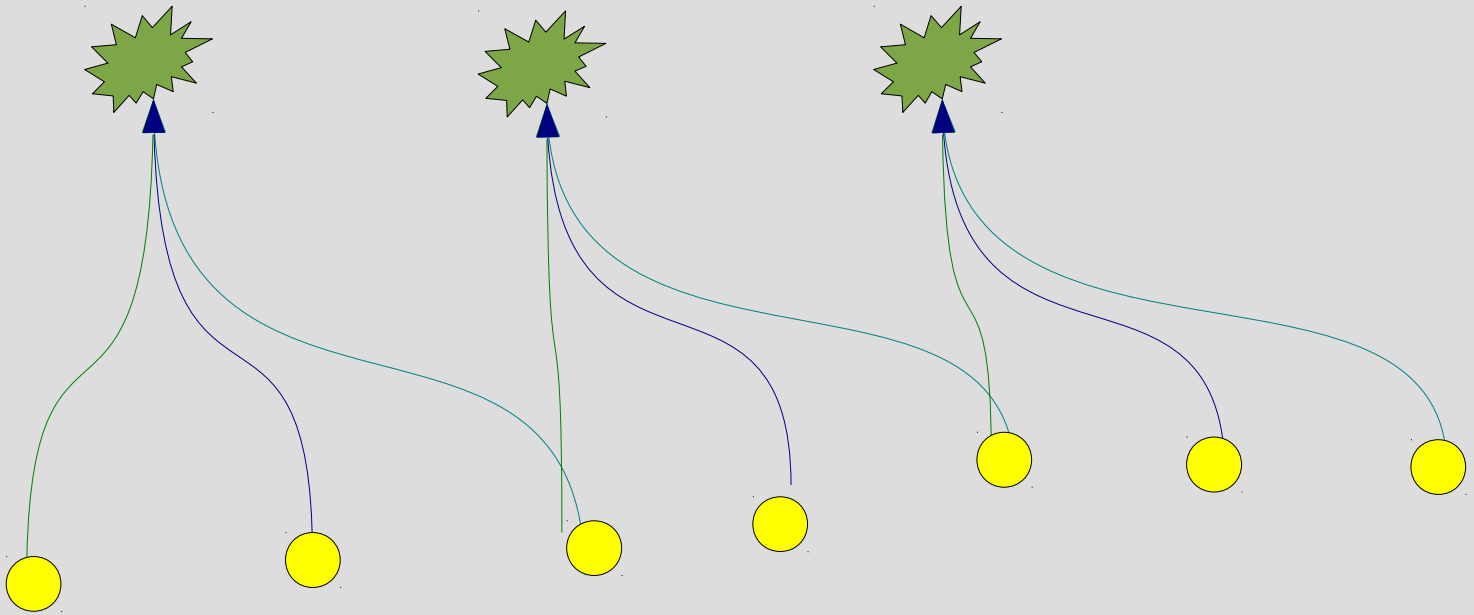

salto=paso=1, ancho=3

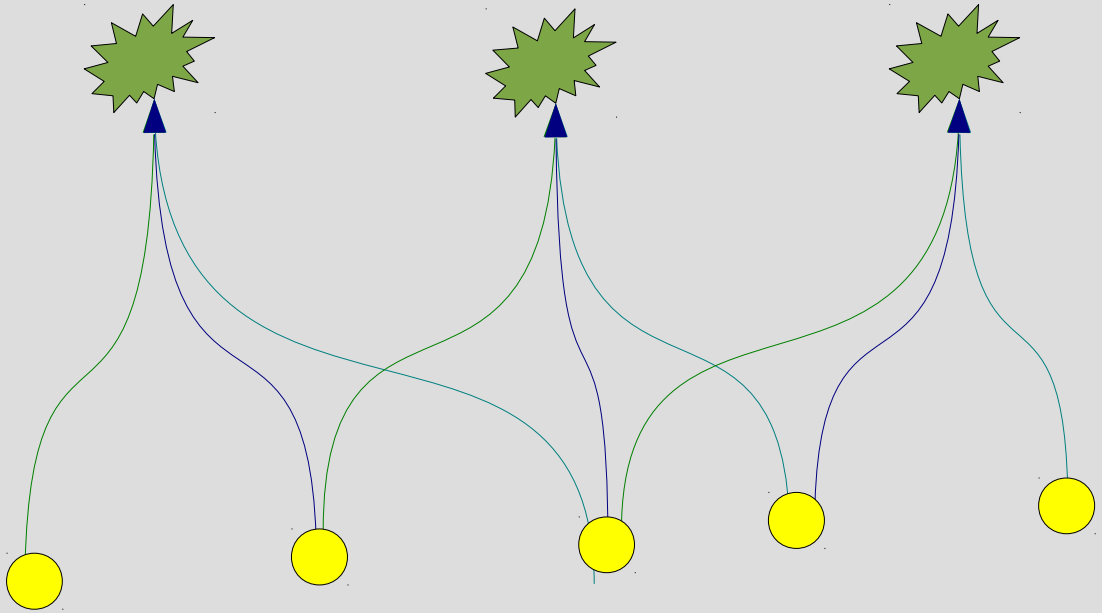

paso=2,salto=1,ancho=3

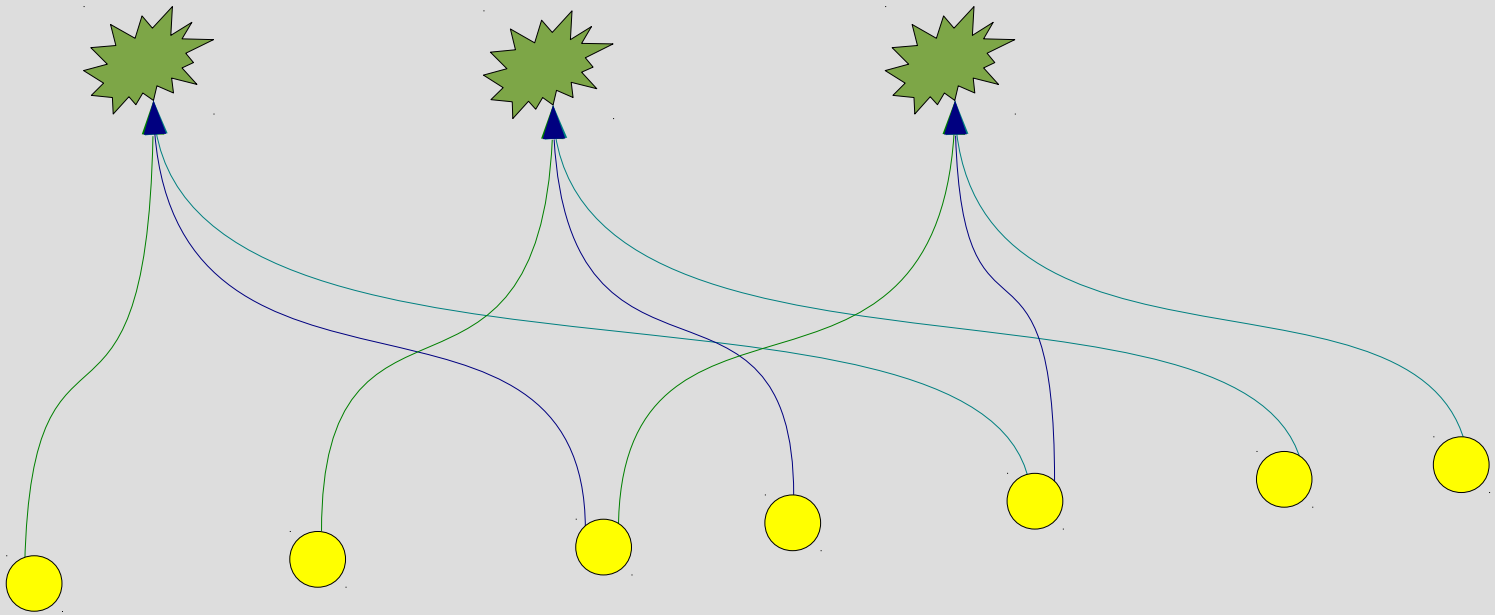

Salto de convolución

- Longitud de salida: $L_{sal} = \left\lfloor \frac{L_{ent} - paso(ancho-1) - 1}{salto} + 1 \right\rfloor$
- salto=paso=1 $L_{sal} = L_{ent} - (ancho - 1)$
  - Disminución aritmética
- paso=1, salto=ancho $L_{sal} = \left\lfloor \frac{L_{ent}}{ancho} \right\rfloor$
  - Disminución geométrica
  - Común: capas **reductoras** alternando normales
    - Sin pesos; máximo, promedio de entradas

Salto de convolución

- Comprueba la salida de capa para el caso anterior ¿Qué longitud tiene?
- Esquematiza los dos casos comentados, para ancho 4
- ¿Qué pasa si el cociente no es entero?

Red profunda alternada

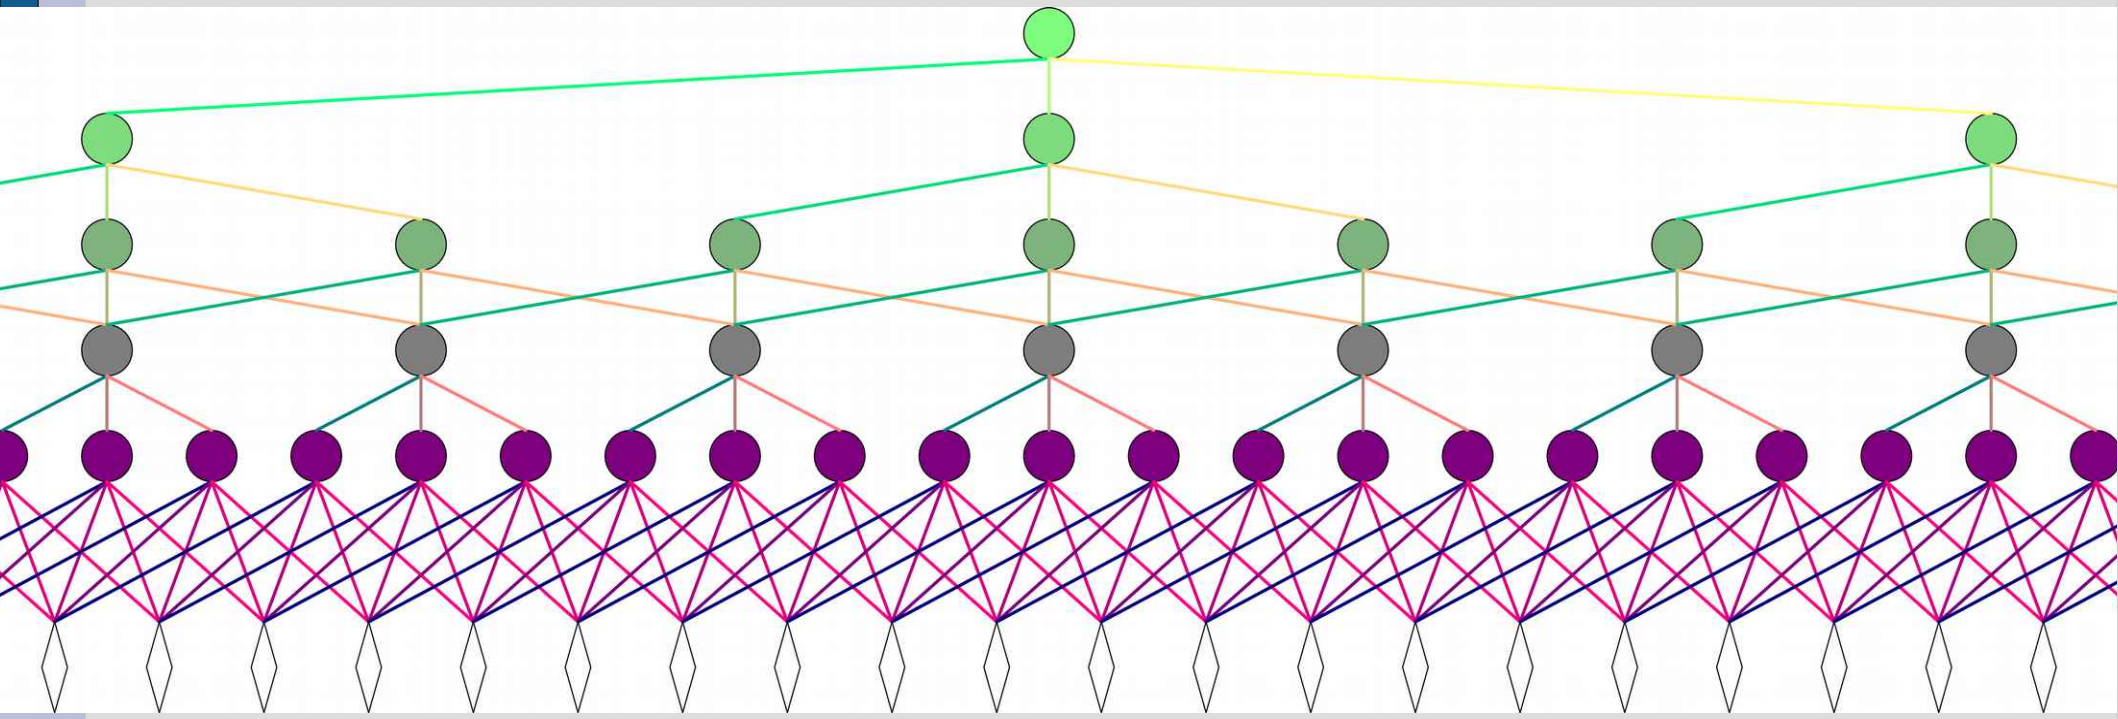

Red profunda alternada

- Con los dos casos de capa previos, alternadamente, y 100 entradas ¿en cuántas capas se nos queda en una salida?

Red profunda con final convencional

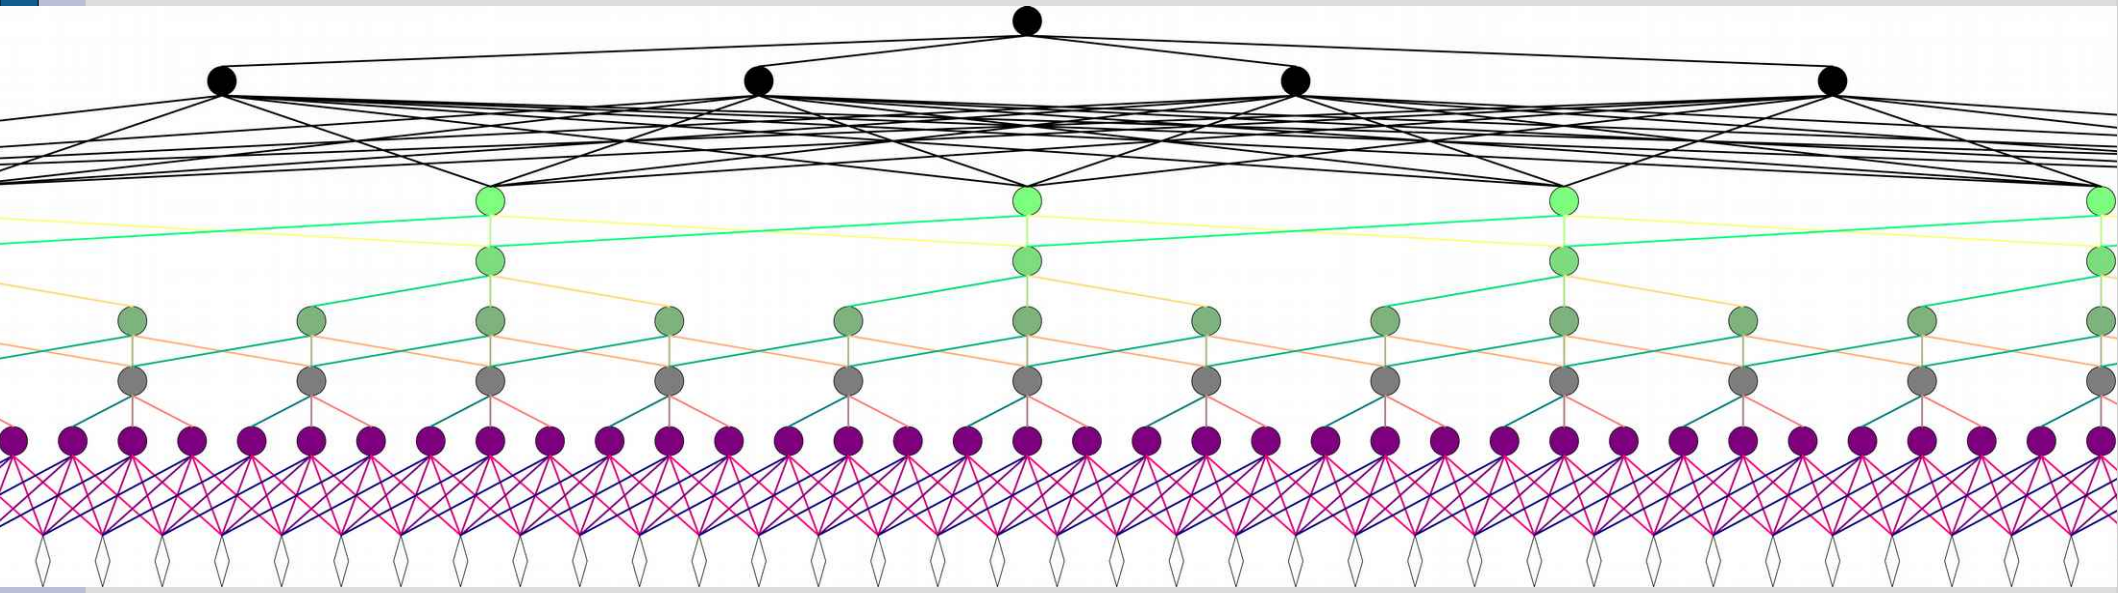

Red profunda con final convencional

- Mismo caso anterior, si pasamos a convencional cuando tengamos 10 variables ¿cuántas capas convolutivas habrá?

Otra forma de graficarlas: una capa, un procesador

- Caso imagen: entradas 2D, cada aplicación del procesador convolutivo de la primera capa se coloca en la misma disposición

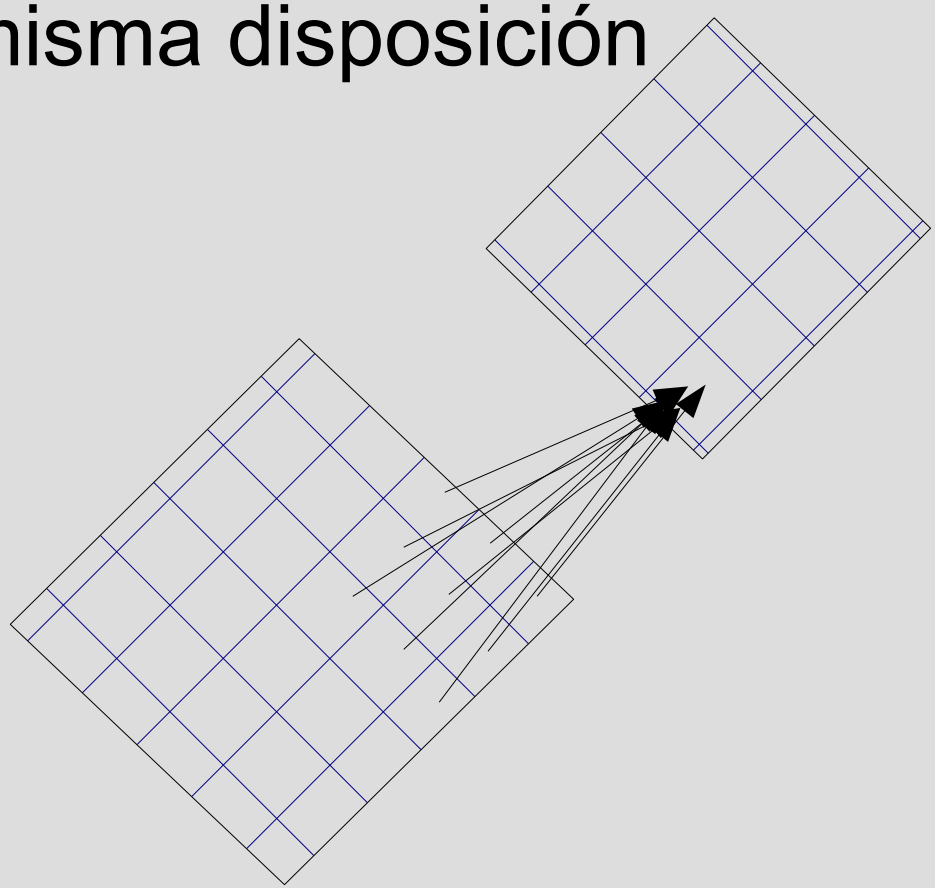

Otra forma de graficarlas: una capa, un procesador

- Si la entrada es 100x100, salto=paso=1, ancho=4 ¿Cómo es el esquema?

Otra forma de graficarlas: una capa, varios procesadores

- Cada procesador (filtro) da una salida-imagen

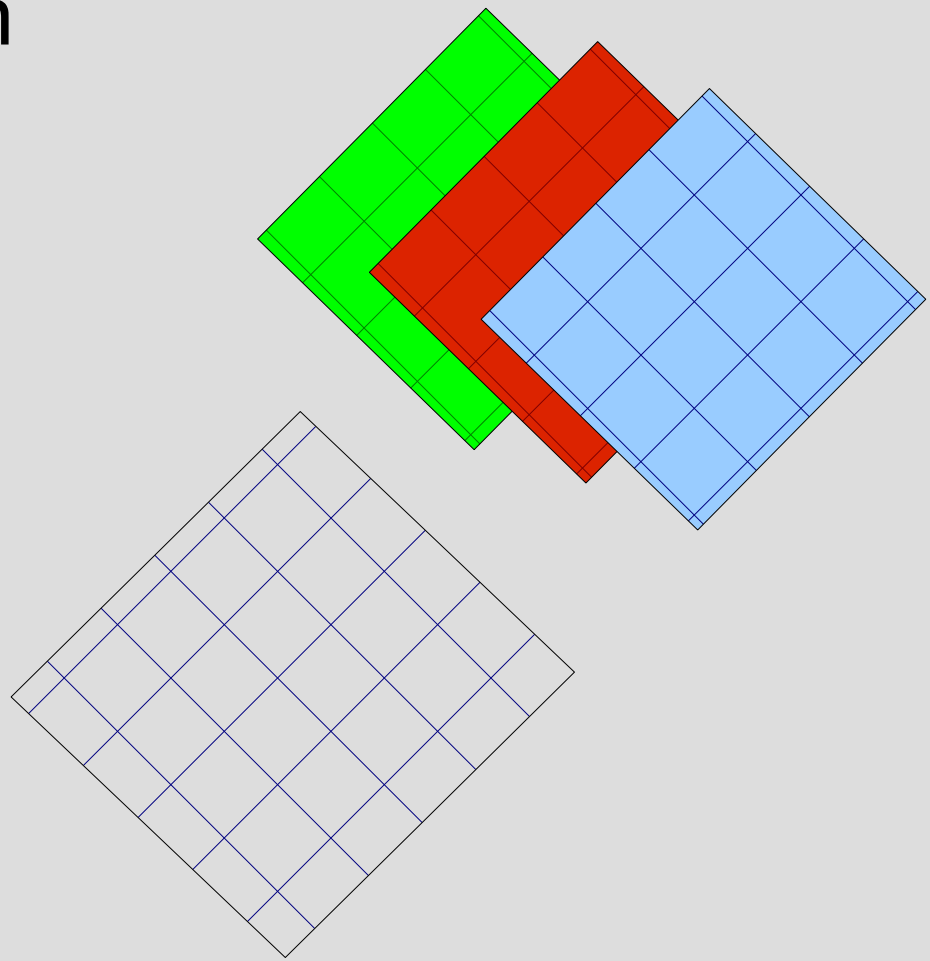

Otra forma de graficarlas: una capa, varios procesadores

- Si hay 5 procesadores en el caso anterior ¿cuántos pesos tiene esa capa?

Otra forma de graficarlas: perspectiva de la segunda capa, un procesador

- El procesador hace la convolución sobre todos los filtros/procesadores previos

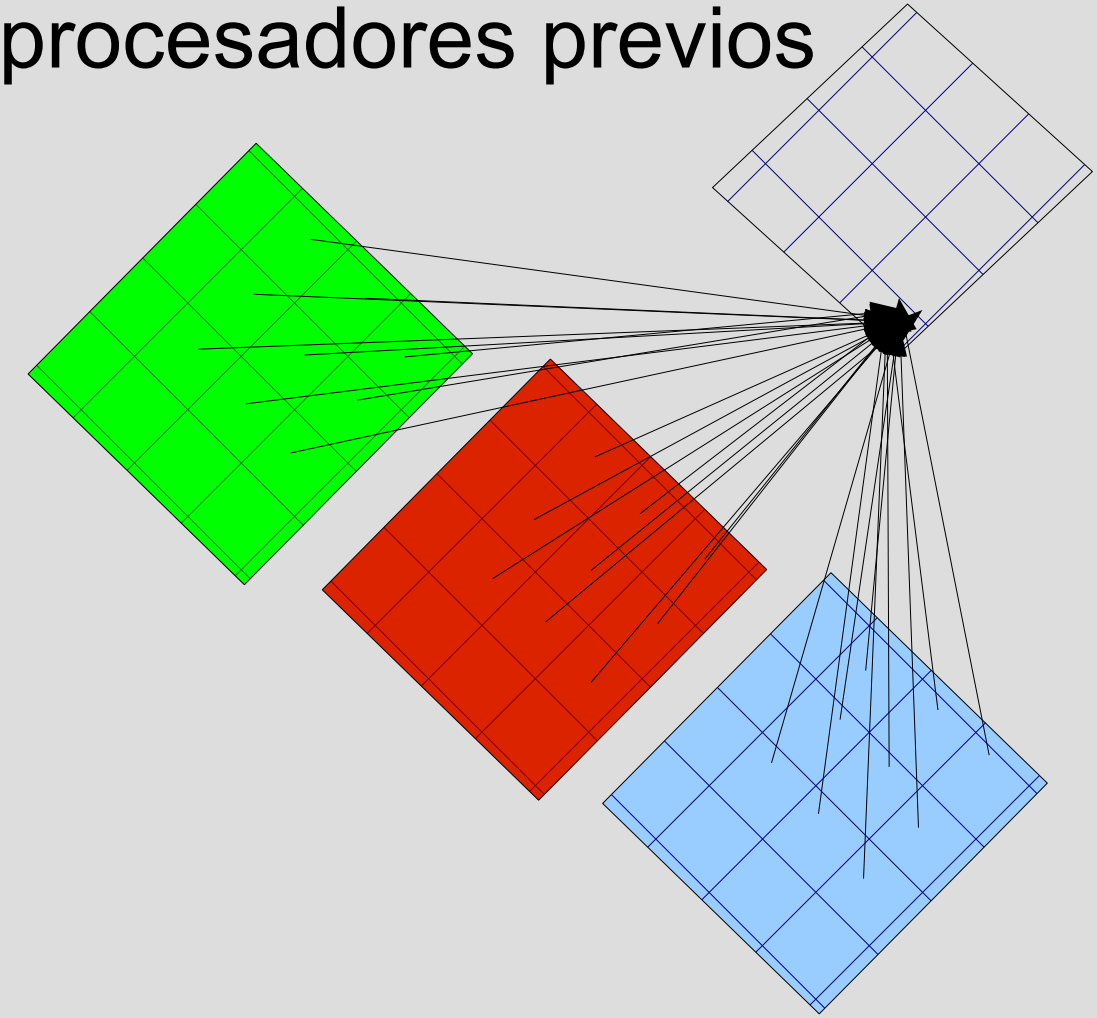

Otra forma de graficarlas: perspectiva de la segunda capa, un procesador

- En el caso anterior ¿qué tamaño tiene la salida?
- ¿Cuánto relleno hay que poner para que la salida tenga el mismo tamaño de la entrada?

Otra forma de graficarlas: varias capas, varios procesadores

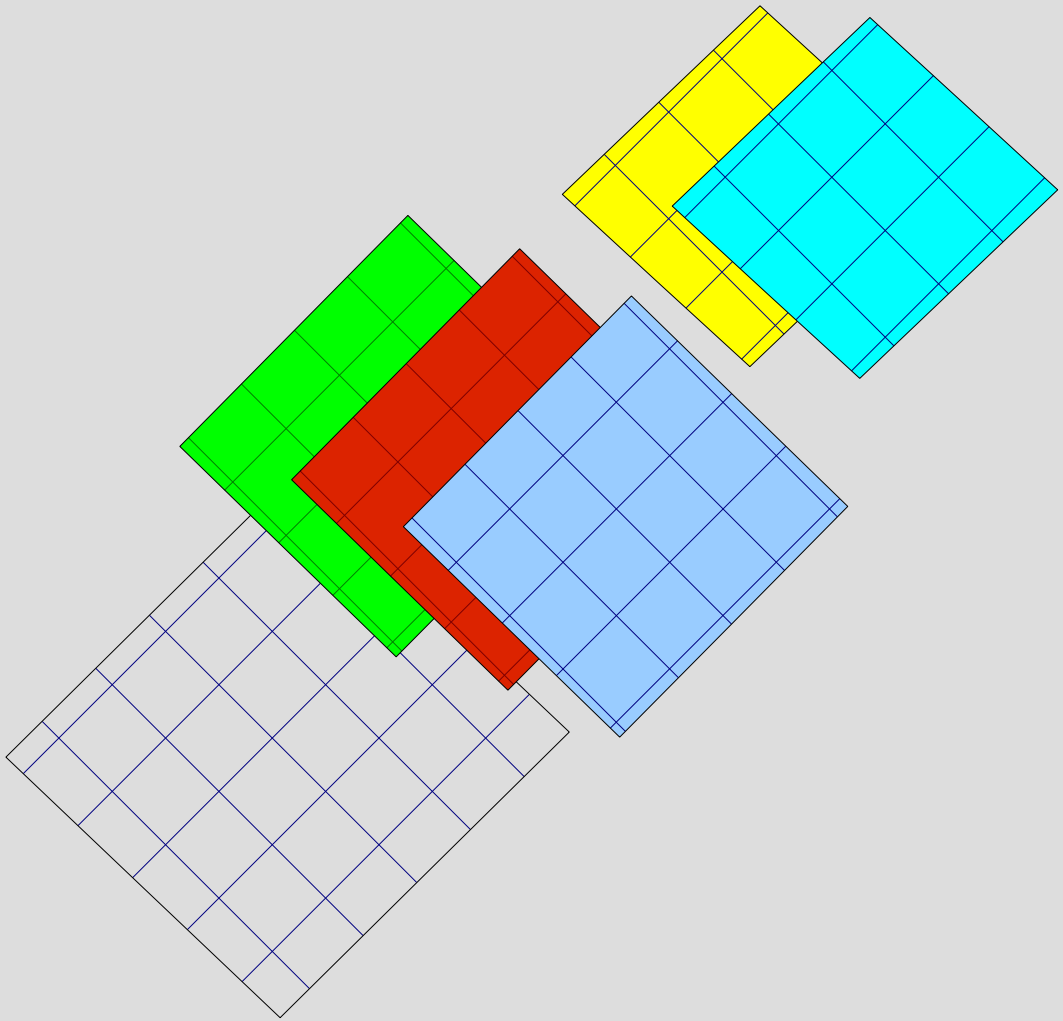

Otra forma de graficarlas, varias capas, varios procesadores

- Pongamos el caso anterior extendido a 5 capas, la primera con 5 procesadores y las siguientes bajando de uno en uno ¿Qué tamaño tiene la salida? ¿Cuántos pesos hay?

Notación compacta de tamaños

- En cada capa, indicar el tamaño de convolución y cuántas convoluciones (procesadores, filtros) se aplican

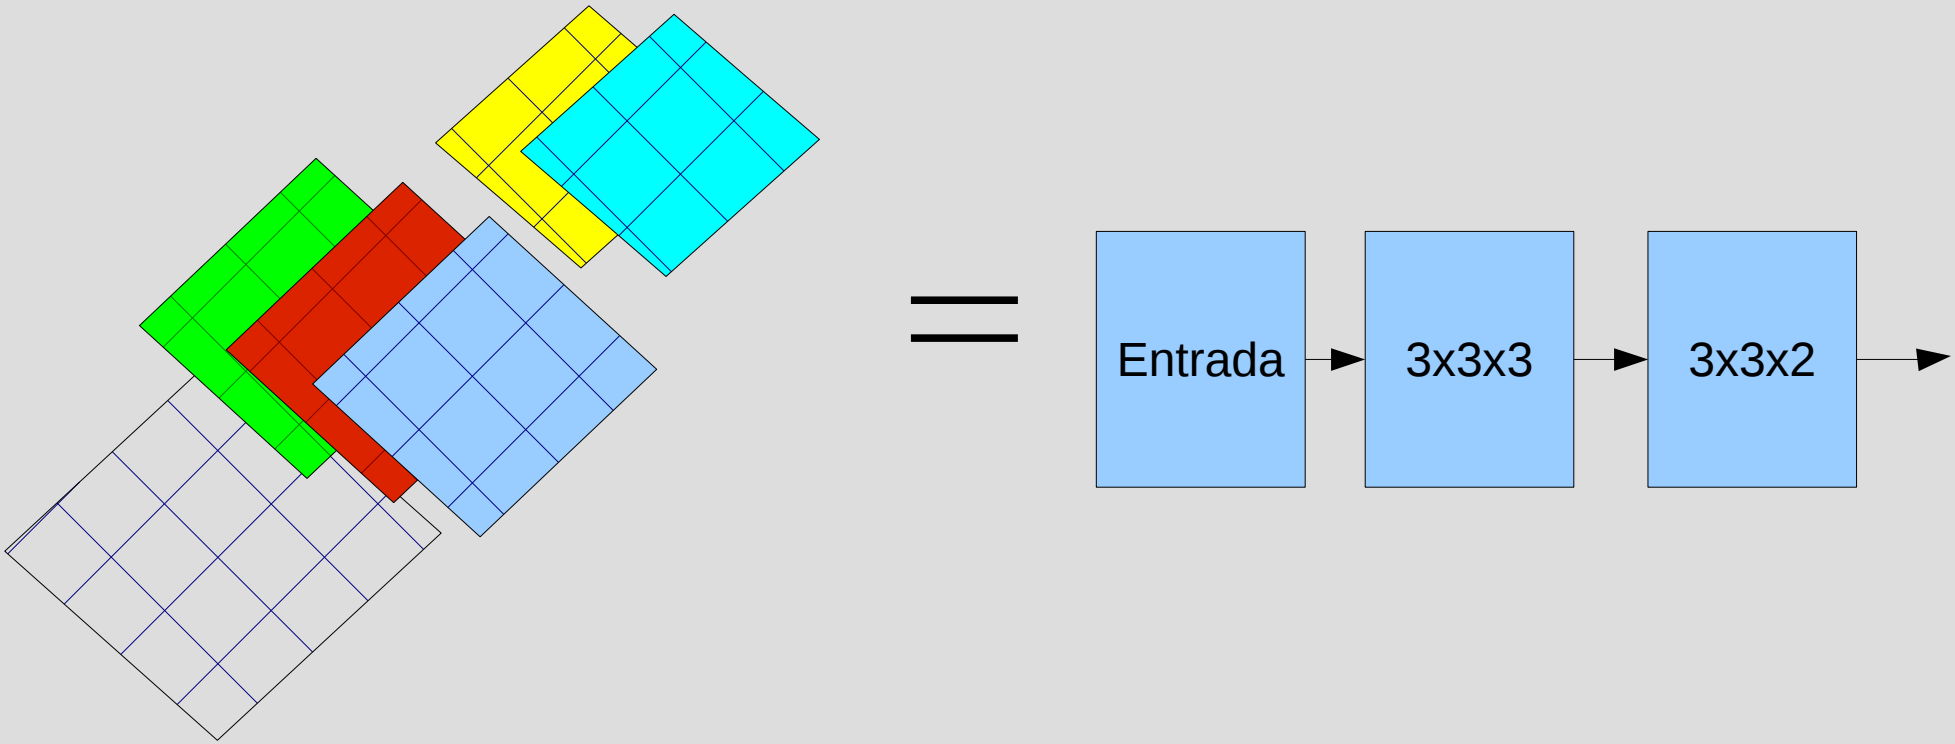

Notación compacta de tamaños

Podemos indicar los tamaños de salida

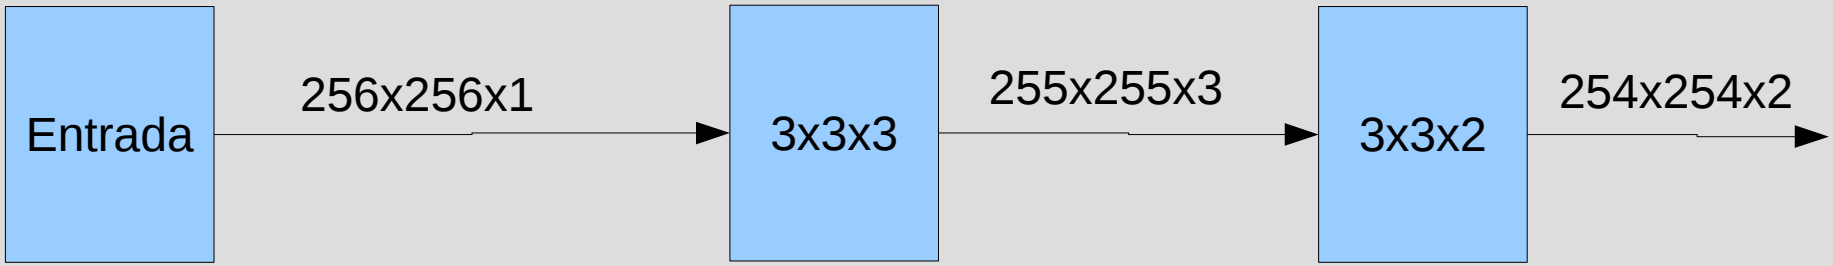

Notación compacta de tamaños

- Presenta el caso anterior
- Pon también los tamaños de salida

Variaciones

- Podemos aplicar en paralelo convoluciones de distintos tamaños (Inception) Para poder concatenar sus salidas, las rellenamos

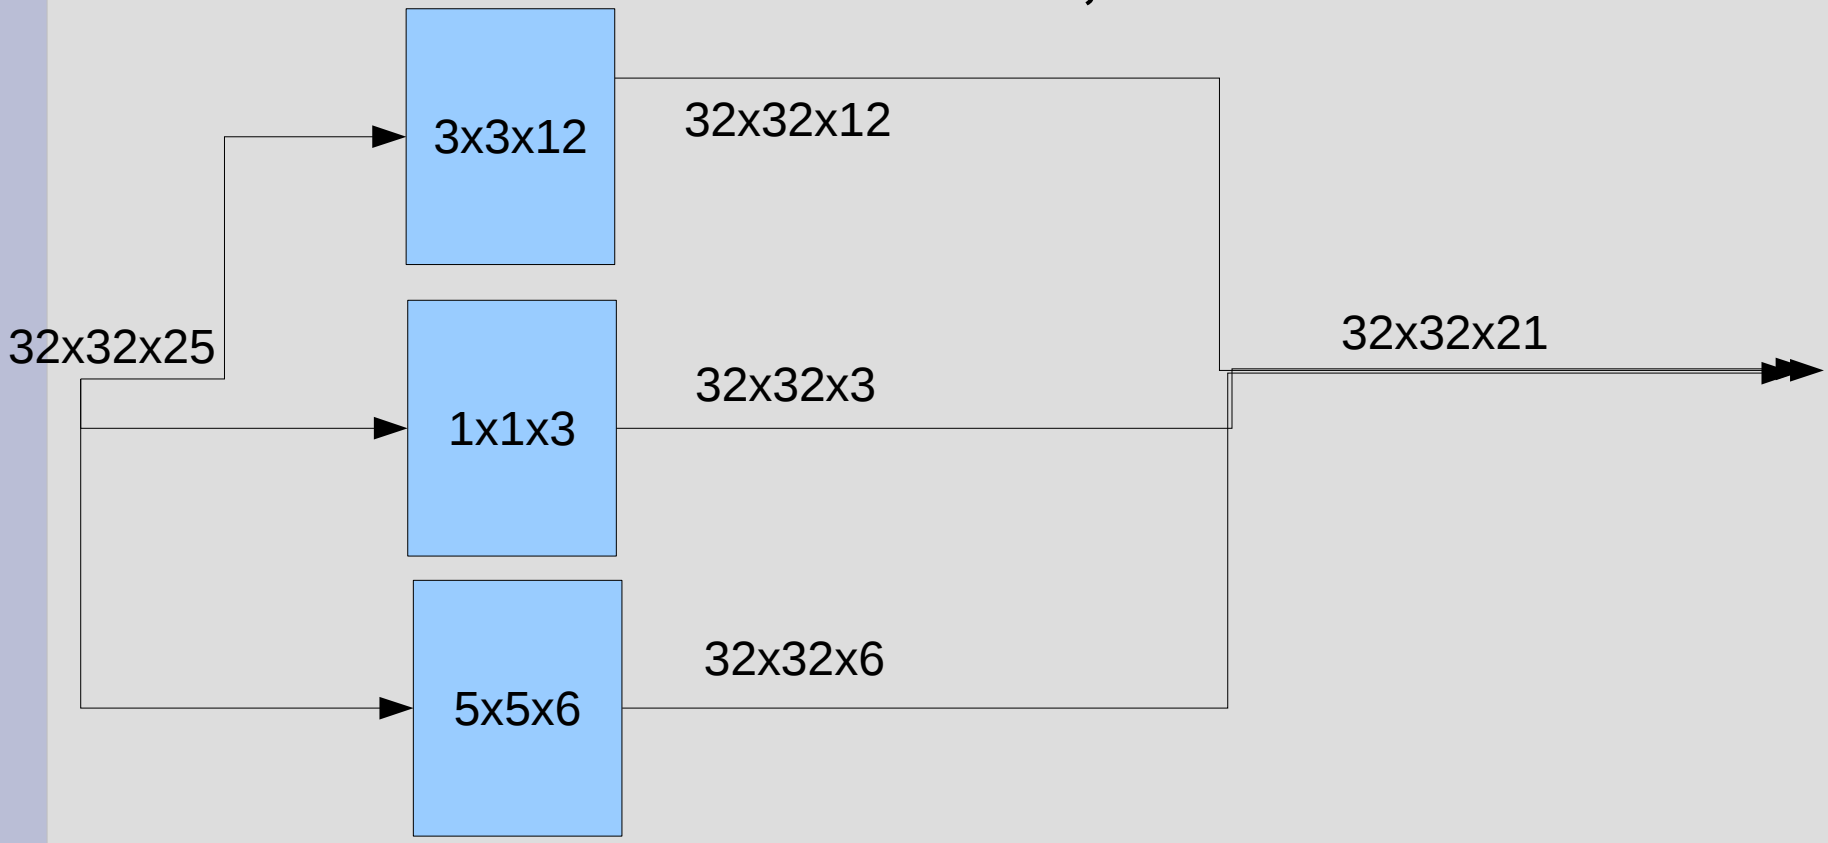

Variaciones

- ¿Cómo se pueden rellenar para que el tamaño de salida coincida?
- Volviendo al caso 100x100 Si la primera capa incluye un bloque de 6 procesadores de ancho 4 y 5 procesadores de ancho 3 ¿Qué tamaño tenemos en la salida?

Variaciones

- Podemos bajar las operaciones de algunos bloques poniéndoles antes una reducción

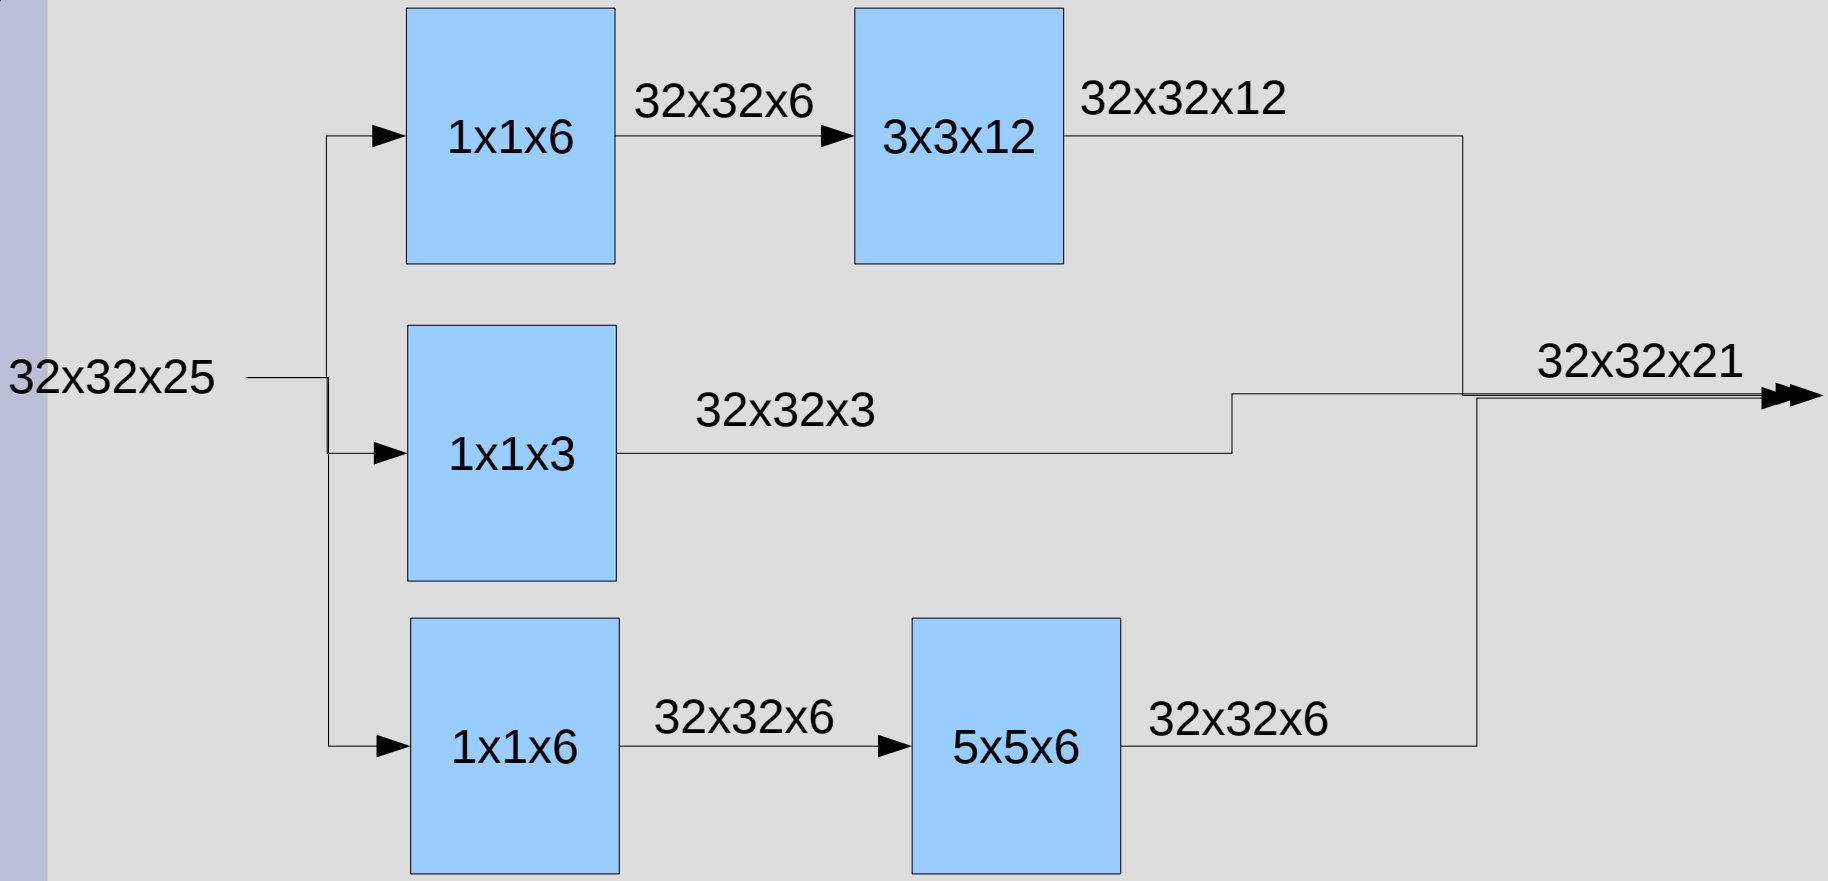

Variaciones

- Si en el caso anterior la segunda capa tiene la misma estructura que la primera, ¿cuántos pesos tiene?
- Esquematiza las conexiones de un bloque en segunda capa que fuese 1x1x3
- Si anteponemos a ambos bloques unos de esos, ¿cuántos pesos va a tener la segunda capa en total?

Variaciones

- Podemos hacer que cada convolución de una capa sólo trabaje con una de las salidas previas (Xception)

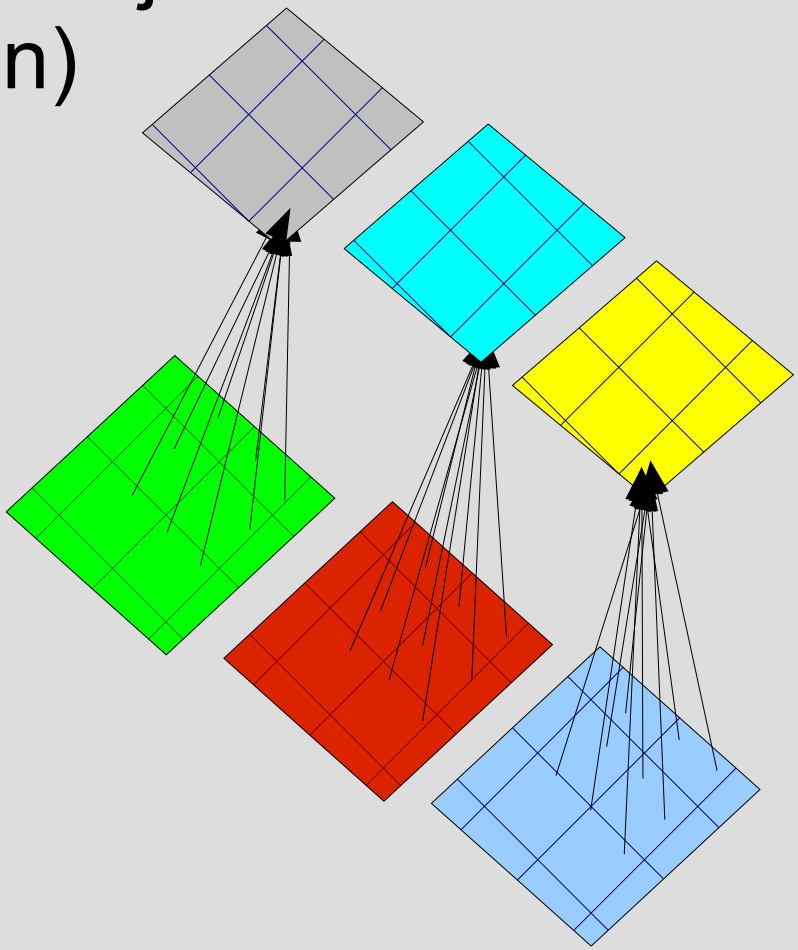

Variaciones

- Podemos hacer que cada convolución de una capa sólo trabaje con una de las salidas previas (Xception)

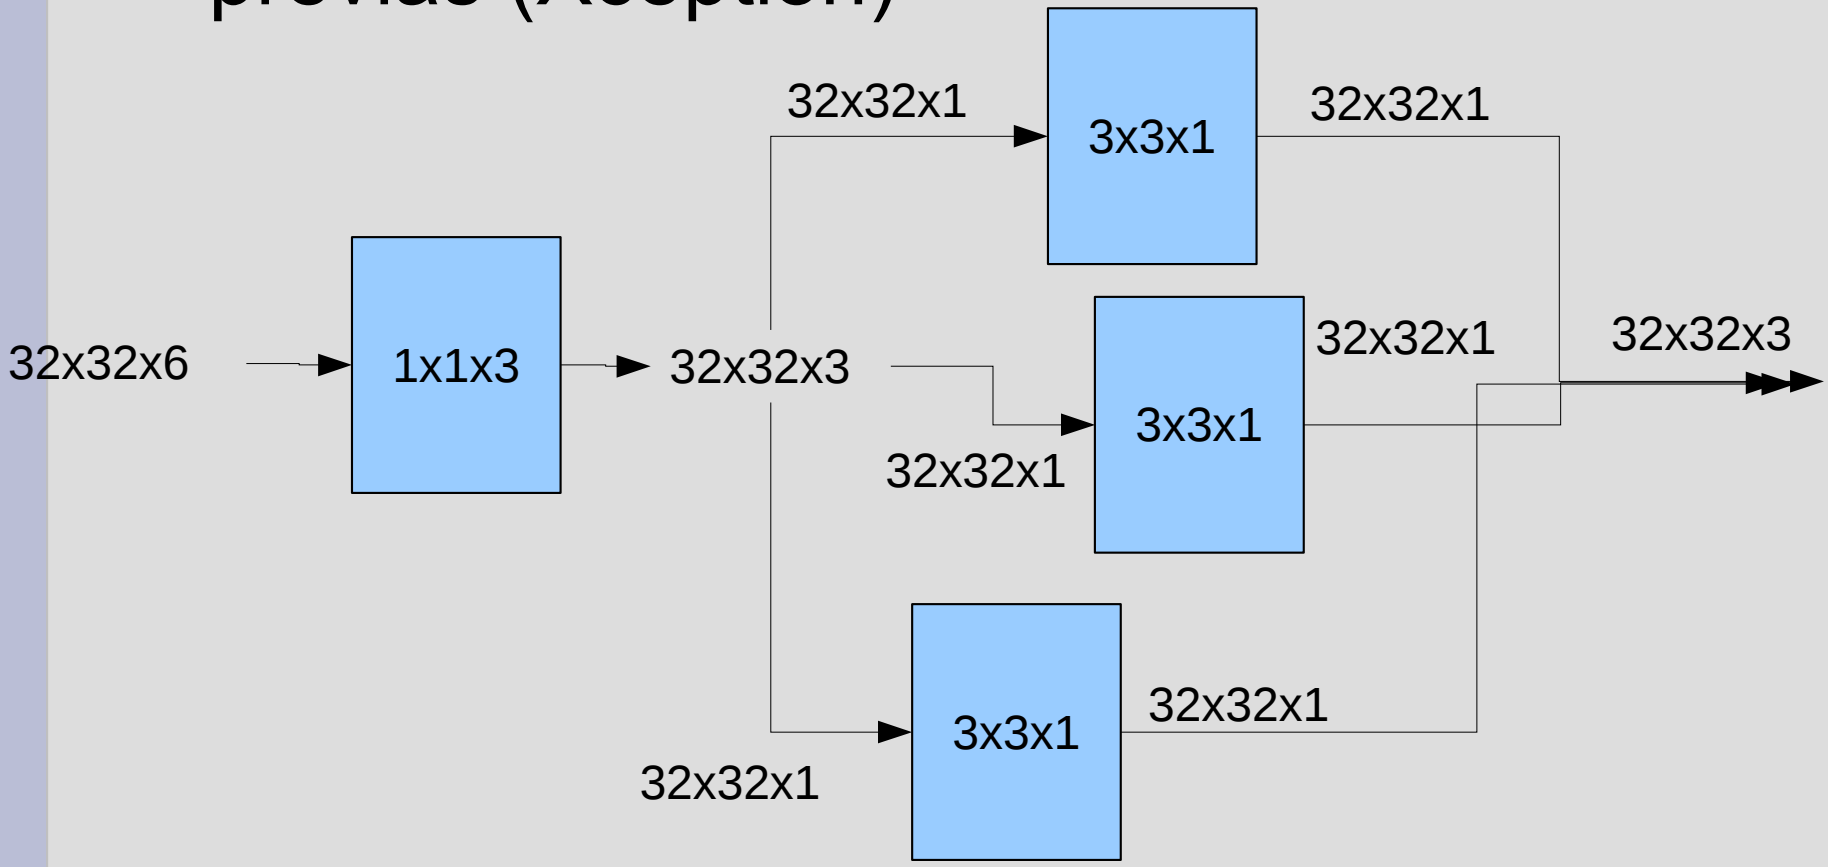

Variaciones

- Volvemos a rediseñar la segunda capa de nuestra red: ahora ponemos un bloque de 1x1x6 y luego ancho 3 con cada salida previa. ¿Tamaño y cantidad de pesos?

Diseño

Pero entonces, hay un montón de posibilidades
¿Qué demonios pongo?

Prueba y error

- Básate en otros ejemplos que hayas visto
- Prueba a aumentar y disminuir en varias direcciones
- ¿Mejora? Sigue por ahí

Pongamos un ejemplo

Búsqueda

- Algoritmos generales de búsqueda discreta
  - Define todas las posibilidades que el algoritmo puede manejar para ir modificando la red
  - Dale gas (prepara hardware y paciencia en cantidades generosas)
- Caso particular: algoritmos evolutivos

¿Qué algoritmos conoces?

Meta-red

- Una red para diseñar redes
  - Va dando una arquitectura
  - Se prueba
  - Se le da la información de error a la meta-red

(Lo dicho: hardware y paciencia)

Busca “reinforcement learning”

Ajuste de la arquitectura

- Define todas las posibilidades en cada punto: p_i
- Toma como resultado: $\sum_i a_i \cdot p_i$
- Optimiza los a_i (normalmente en pasos alternados con los pesos)
- Finalmente, quédate sólo con las posibilidades que tengan a_i significativos
- Puedes apilar varias redes como las encontradas, para mejorar

¿Dónde hemos mencionado algo como el último punto?

Coge fuerte y poda

- Pon una red bien gorda (que te encaje en equipo·tiempo)
- Recórtala de forma que obtengas una buena, pero menor
- Puedes irlo haciendo mientras la ajustas o después
- ¿Cómo? ¡Siguiente tema!

Propón alguna idea