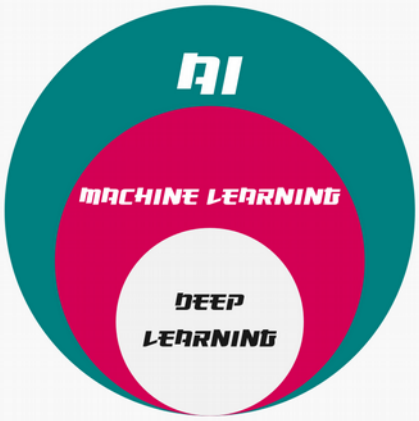

INTRODUCCIÓ AL MACHINE LEARNING

ML

Beques de recerca i creació OSIC· gencat 2021
projecte ***músIA***
Xavi Manzanares
2021 / 2022

MACHINE LEARNING FOR NEWBIES VOL1 INTRO

Aknowledgments:
Molts diagrames i representacions d'aquest tuto són directament inspirats del molt recomanable curs de
Rebecca Fiebrink 'Machine Learning for Musicians and Artists'
https://www.kadenze.com/courses/machine-learning-for-musicians-and-artists-v
on es mostra una overview al ML amb projectes de media & sonic interaction per mitjà del programari ML Wekinator.

En aquest tutorial veurem les diferents tipologies i particularitats del que entenem com a ***Machine Learning****.*
Abans de començar, un parell de qüestions.

La primera i per a què disposem d'un enfoc amb precisió i comunicació pedagògica, com a ***Machine Learning (ML)*** *entendrem com una sèrie de mètodes i tècniques de programació amb les quals una determinada aplicació o conjunt d'aplicacions pugui realitzar un procés iterat d'entrenament (****'training'****) i aprenentatge* ***'learning'****.*
El ***'Deep Learning' (DL)*** *correspon a un tipus de Machine Learning més evolucionat i (sovint) complex en el què s'hi recreen models de* ***xarxes neuronals (ANN o Artificial Neural Networks).*** *Cal recordar que les xarxes neuronals no són de cap manera neurones sintètiques dissenyades a laboratoris bioengineering sinó que són un conjunt d'aplicacions modulars inspirades en la propagació i retropropagació que es produeix a les neurones humanes.*

Per tant, i per a resumir les anteriors frases són com unes nines russes.
La IA és el marc principal, el Machine Learning és una part de la IA i el DeepLearning és una part del Machine Learning.

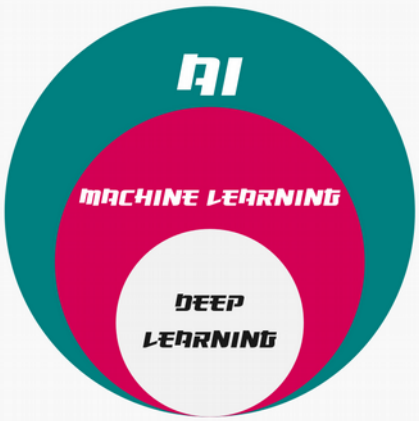

La pregunta habitual, seria la confusió entre ML i AI.
Però podriem entendre que hi han sistemes AI on no es necessitin mètodes d'aprenentatge.
És aquí on entra una qüestió filosòfica en entendre què és intel·ligència.

//....

we have first to understand that AIs still are not self conscious and sensitive entities, therefore maybe we cannot assume that are intelligent beings, in the sense of complexe intelligence : cognitive, sensitive, emotional, propioceptive, intuitive, abstract, creative etc.
When we say intelligence we have to separate as well the property that is often associated only with the brain.
Consciousness is contained in any lifeform, with different layers of complexity. From a single cell which exchanges biochemical information between others in orther to build more complexe functions, structures of functions, organs, and whole organisms.
Also consciousness is a symbiotic process of information through electrical (bio)signals. We'll talk about Margulist Symbiotic theory in other pages.
But what is consciousness? Maybe a sensitive and solving-problem being performing the most tuned and optimized method to do a task after many iterations of trial-error-loop with/in its surround, with the goal to sustain itself and improve their existence in its context.
Even consciousness is often related to Philosophycal domain, is in fact a very common trend in Sciences as well, since the Quantum mechanics theory and after others, suggests the relationship of observation (therefore some type of counscious being to perform the observation) and the very basis of nature and physical laws (at least in subatomic scales). Schröedinger's cat, Quantum Oscillation Wavefunctions and so forth.

[xavi manzanares, from the article Is An AI Genderless? 2021]

... //

En el següent gràfic podem veure 3 tipologies d'intel·ligència artificial > els sistemes ***Generatius*** del qual trobo personalment un context d'estudi fascinant atès que l'aproximació a la intel·ligència va més enllà de la antropocèntrica, així com la *IA 'mono-cognitiva'* i la *IA Dinàmica amb Machine Learning.*

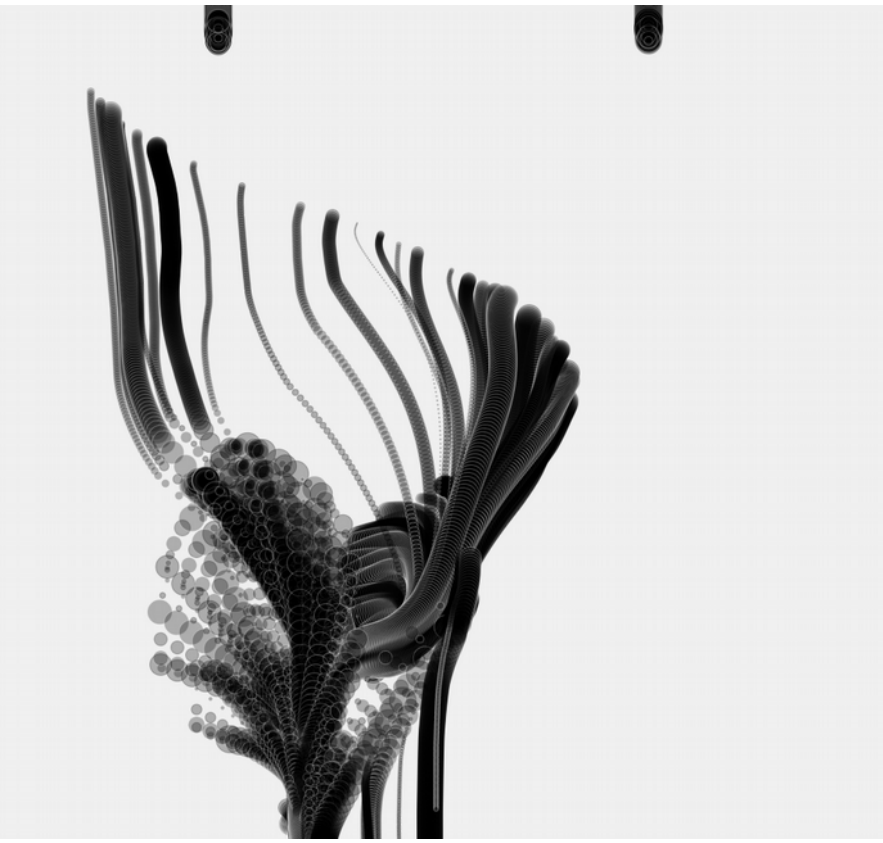

GENERATIVA

No ens centrarem ara en els mètodes generatius ja que aquest tutorial s'enfoca més al ***ML***, però com a recordatori, els mètodes generatius s'inspiren en comportaments que podem trobar a la natura en diverses escales : partícules, fluids, fluxes biològics, swarming, fluxes geològics, atmosfèrics, gravetat, etc

En la present recerca es publicarà el 'toolkit' ***GNRTV.BLOCKS*** orientat per a construir de manera senzilla instruments algorítmics generatius sonors. Aquesta llibreria com a spòiler inclourà mètodes generatius i algunes aproximacions experimentals basades en ML.

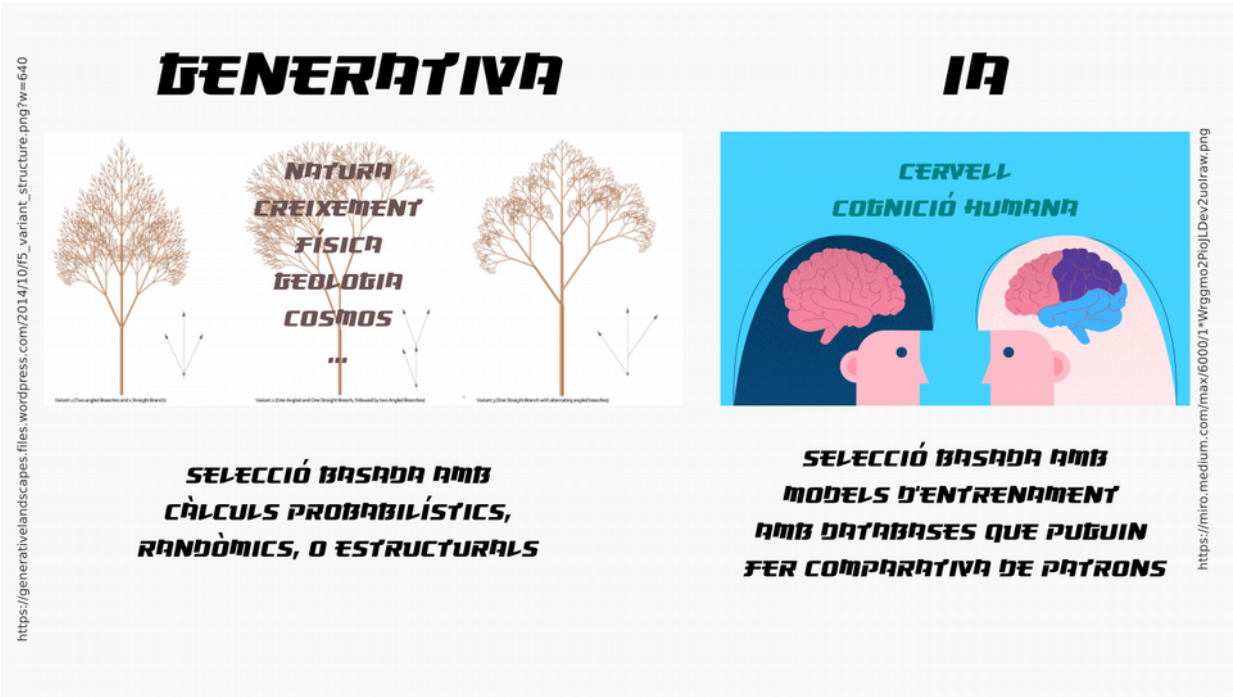

Dins el Machine Learning podrem trobar :
aprenentatge supervisat, [supervised]
aprenentatge no-supervisat, [un-supervised]
aprenentatge reforçat (amb recompensa) [reinforced]
...entre d'altres.

Però anem a enfocar-nos en els dos primers.
Tècnicament el 'Supervised' funcionaria d'una manera ***discretitzada.***
I el 'Un-Supervised' funcionaria d'una manera ***Contínua***

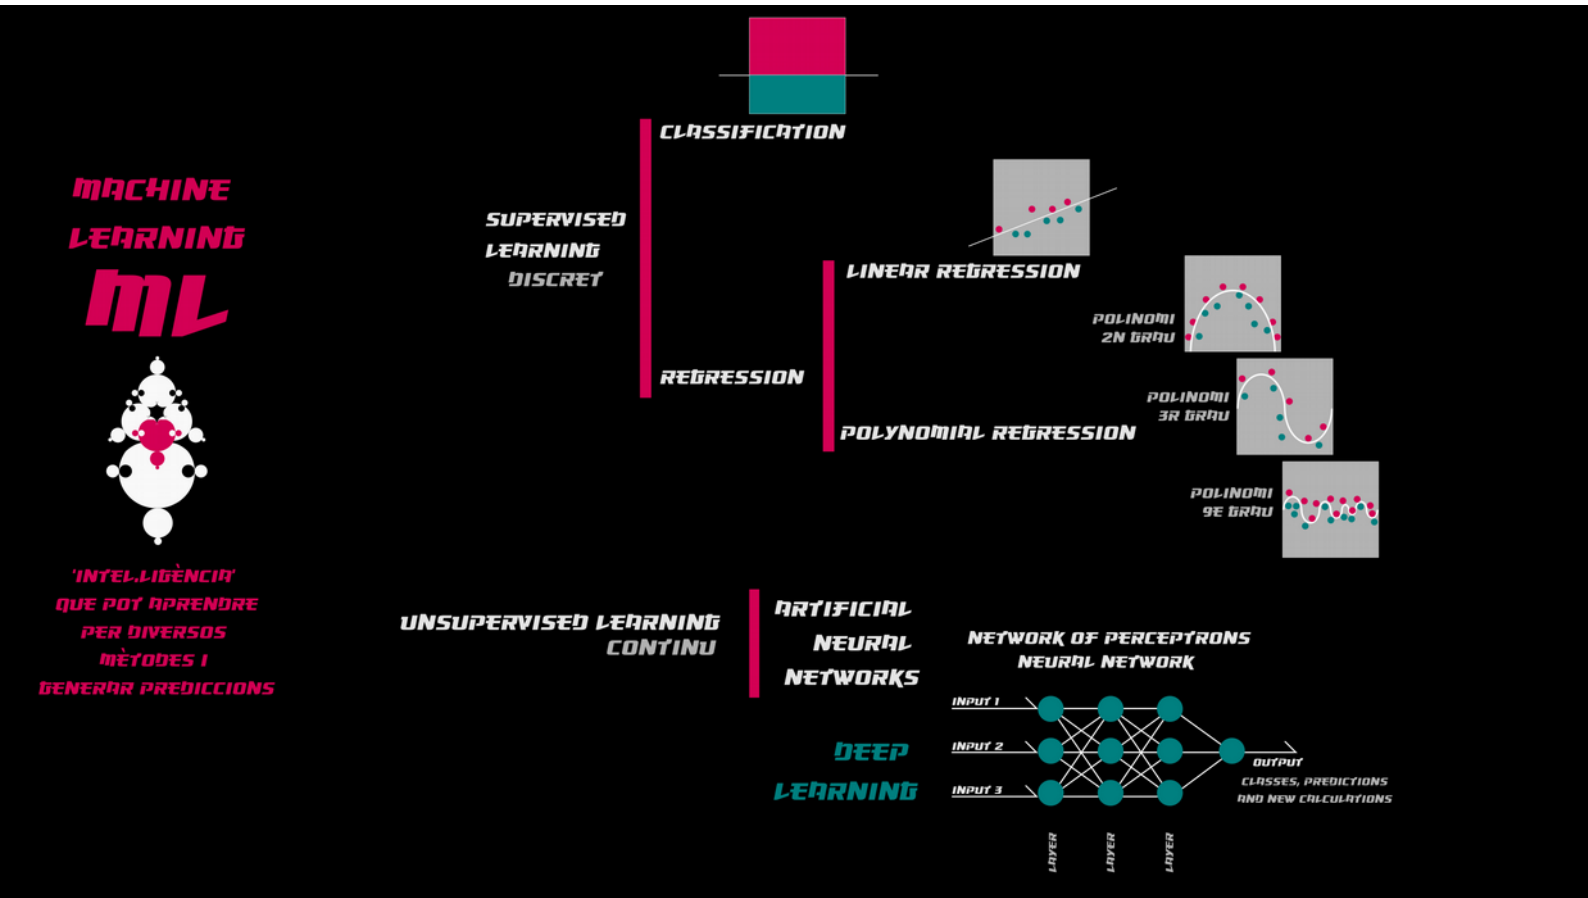

Per a que quedi clar aquest concepte matemàtic,
Imaginem que estem en un passatge molt petit on hi ha tres cases,
-cadascuna d'elles dotada d'un altaveu a la seva entrada-
i volem que es produeixi un so cada cop que passem davant d'una casa en concret.

*En un sistema **discretitzat** els sons seran únics i inequívocs.*
O sonarà el so A, o el B o el C quan passem per davant de la casa

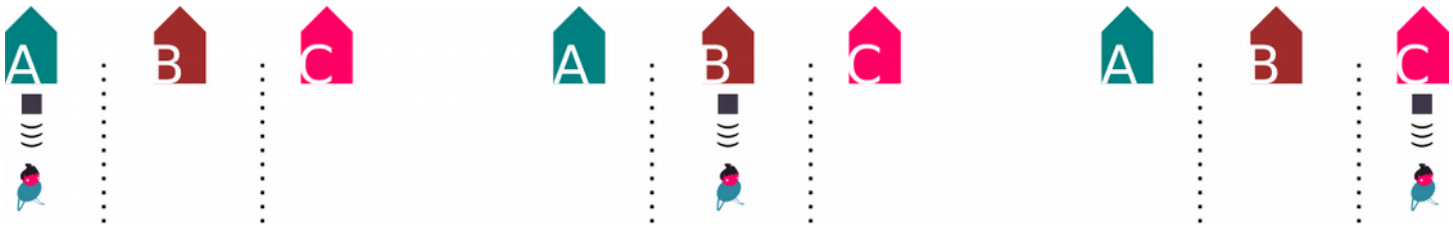

*En un sistema **continu** els sons es fondrien entre els adjacents.*
(A fusionat amb el B, el B fusionat amb l'A i el C i el C fusionat amb el B)

Tecnològicament dins el context del ML les tècniques Supervised o Discretes són sovint més senzilles, de manera que depenent del problema a resoldre anirem amb un o altre mètode.
<u>No hi ha millors mètodes que altres sinó que sempre són contextuals :</u>
Dependran sempre del propòsit a resoldre,
però el minimalisme i la senzillesa sempre ens ajudaran amb més velocitat de computació.

Abans d’entrar amb les tipologies convé explicar un altre concepte transversal del Machine Learning.

El **Fitting.**

Un model serà ***Underfit*** si conté massa imprecisions
Un model serà ***Overfit*** si és massa precís i per tant no pot incloure futurs elements d’aprenentatge dissonants.

En definitiva el més adeqüat és que tendeixi a l’Overfit però deixant marges d’error tant per sorolls i inconsistències en futurs valors d’entrada per a nous entrenaments. (veure model B a la imatge)

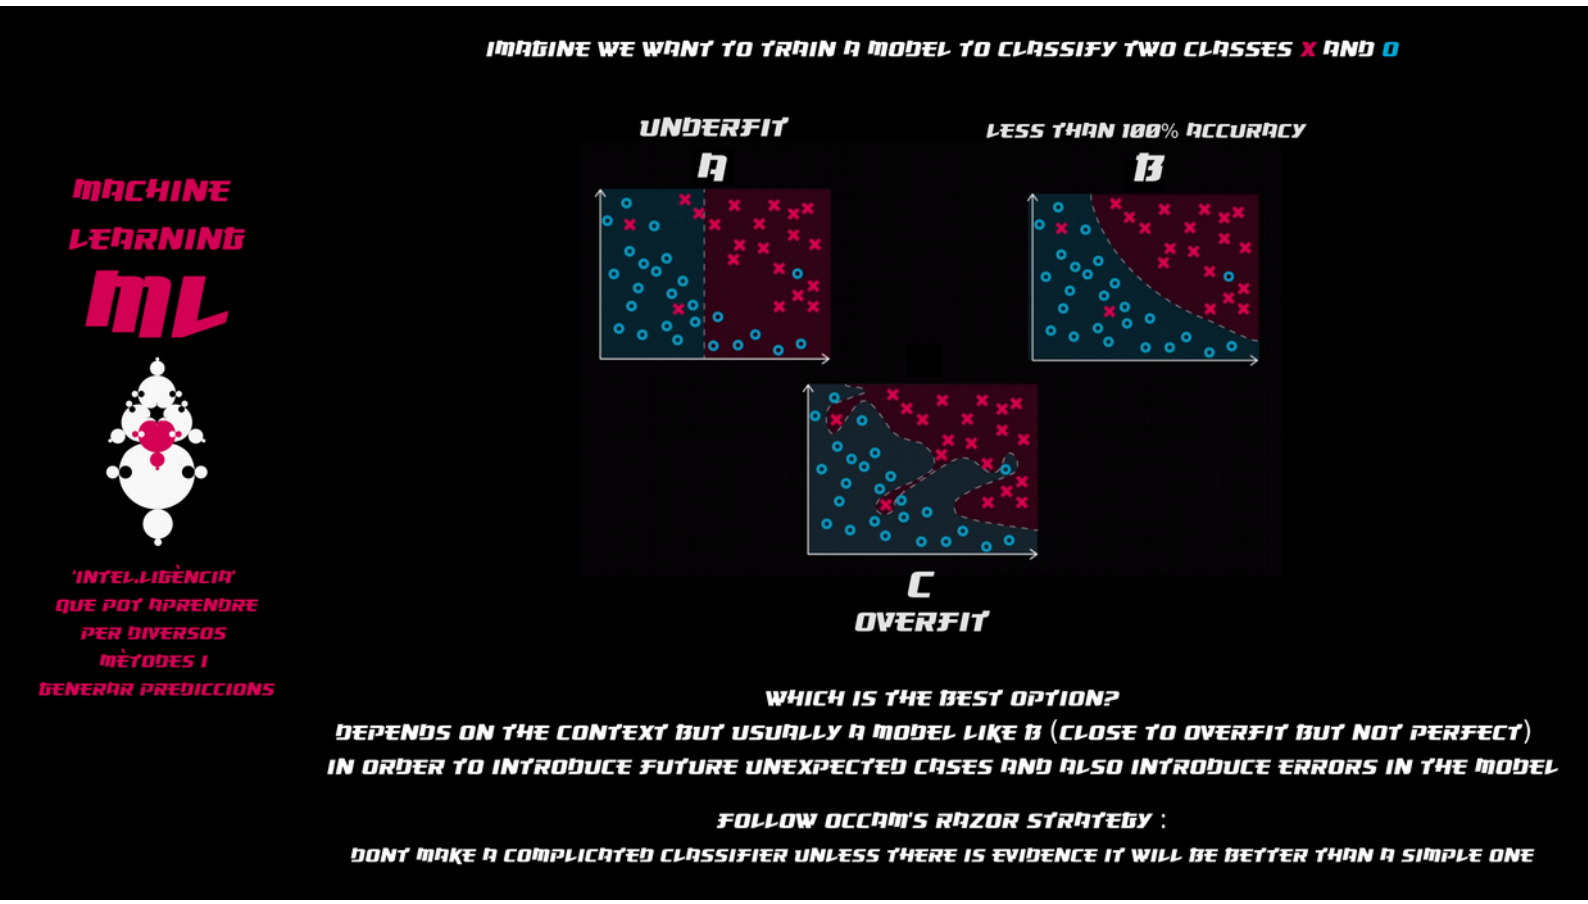

Supervised Learning

*En l'aprenentatge **supervisat** trobem les tècniques de **classificació** i les de **Regressió***

Classificació

En la primera i simplificant molt la idea es tractaria de poder determinar entre 2 classes una sèrie de prediccions (outputs) en base a uns inputs inicials i a un entrenament.

Nota: en les figures apareixen dues classes diferents si bé aquestes poden ser d'ordres elevats.

Imaginem que tenim una piscina quadrada que la veiem zenitalment a vol d'ocell. Si tracem una línia horitzontal imaginària ens generarà un límit el qual podrem classificar quantes persones estan nedant a la part superior (en fucsia) i quantes a la part inferior (turquesa)

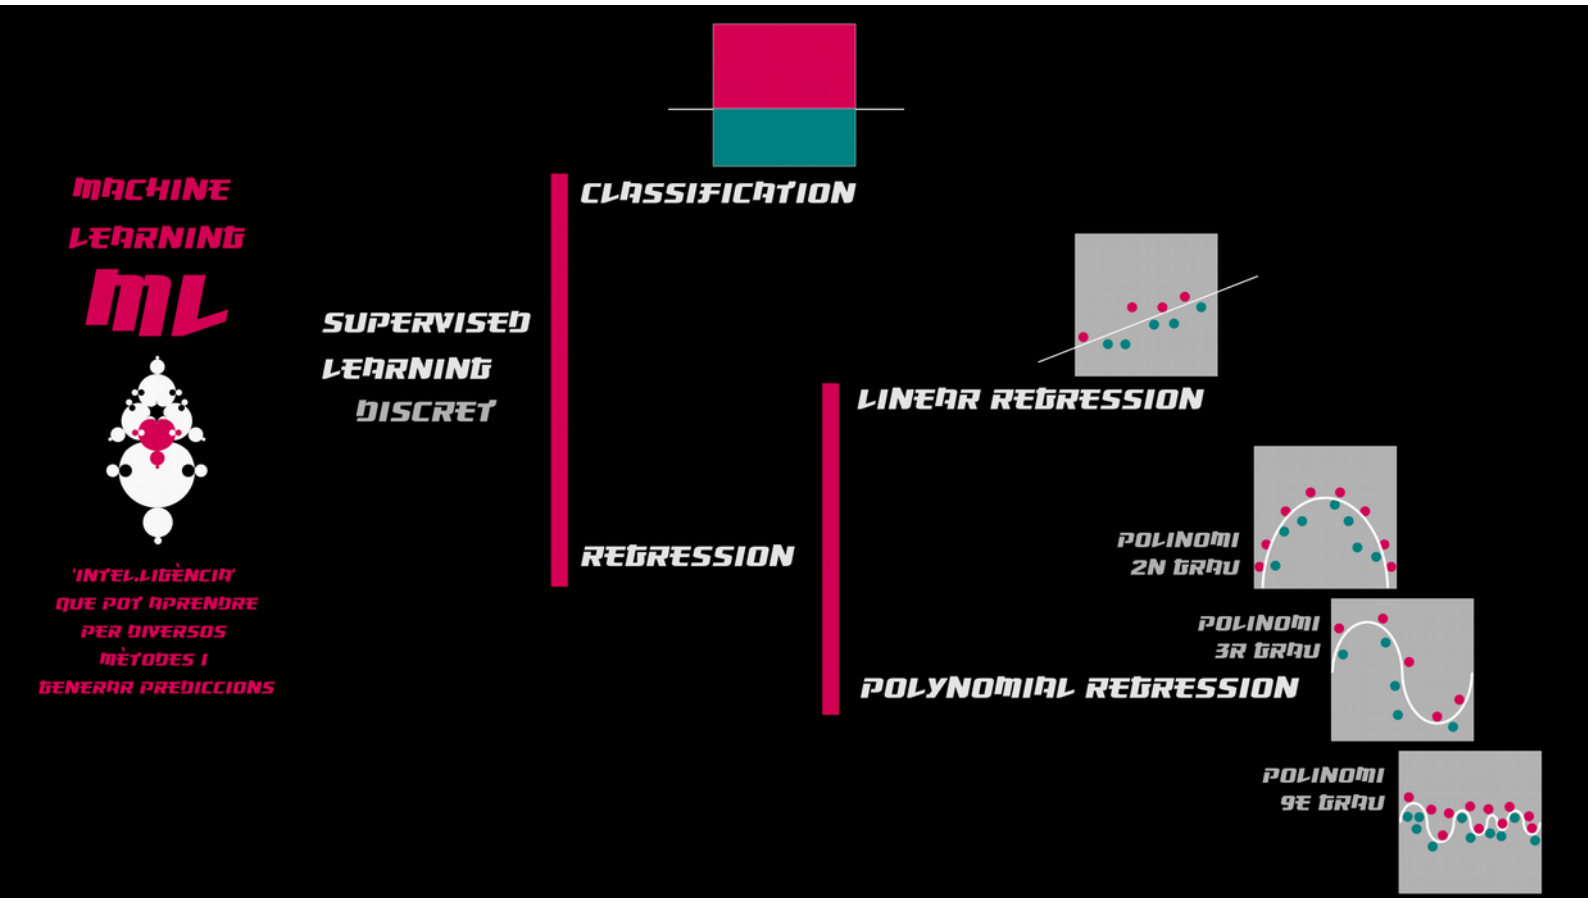

Regressió

Aquest mètode genera com l'anterior una classificació entre dues classes o outputs, si bé en un procés iteratiu de 'nombroses passades'.

A més passades, més precisió però com apuntàvem abans, pot haver-hi imprecisions i soroll també quan hi ha una càrrega de dades d'entrada (inputs) molt elevada.

*Com a tipologies tindrem la **Regressió Lineal** i la **Regressió Polinòmica (de 2^{n}, 3^{r} ,4rt, 5e Grau etc...)**.*

Si bé noteu com matemàticament en realitat la lineal és polinòmica de 1 grau (línia amb pendent)

Segurament a moltes i molts de vosaltres això dels polinomis us sona de la Secundària o altres fases educatives, si bé com a recordatori es tracta de 'vectors amb curvatura'.

<u>La quantitat de curvatures contraposades sumant-li 1 ens indicarà el grau</u>

És a dir si tenim una curvatura com una semielipse o semicircumferencia serà de grau 2

Si tenim dues curvatures contraposades serà de grau 3

....

Si tenim una forma extranya amb 7 curvatures contraposades serà de grau 8

And so Forth...

Unsupervised Learning

En l'aprenentatge ***no supervisat*** *trobem les tècniques de* ***Neural Networks inspirades en les neurones humanes tant del cervell com del sistema nerviós.***
Quan les ANN (Artificial Neural Networks) es complexitzen amb moltes dimensions i ítems esdevé en models de ***Deep Learning*** *d'alta complexitat i sofisticació.*
Ho veurem posteriorment.

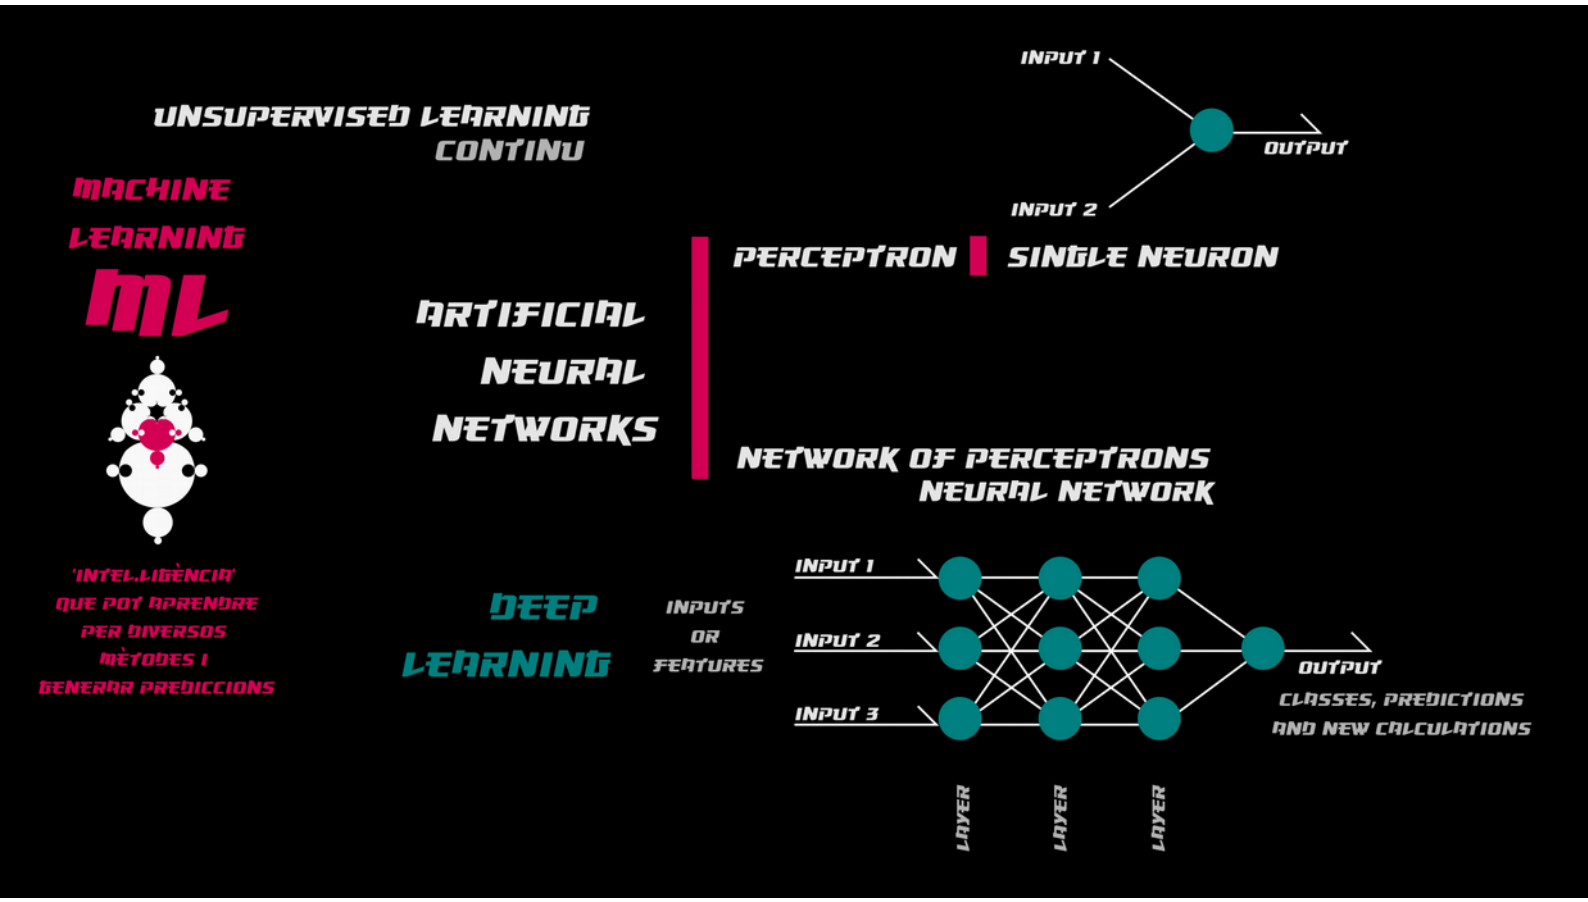

Beques de recerca i creació OSIC· gencat 2021
projecte ***músIA***
Xavi Manzanares
2021 / 2022

MACHINE LEARNING FOR NEWBIES VOL2 SUPERVISED LEARNING CLASSIFICATION

Aknowledgments:
Molts diagrames i representacions d'aquest tuto són directament inspirats del molt recomanable curs de
Rebecca Fiebrink 'Machine Learning for Musicians and Artists'
https://www.kadenze.com/courses/machine-learning-for-musicians-and-artists-v
on es mostra una overview al ML amb projectes de media & sonic interaction per mitjà del programari ML We

MACHINE LEARNING ML

'INTELLIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

REGRESSION

LINEAR REGRESSION

POLINOMI 2N GRAU

POLINOMI 3R GRAU

POLYNOMIAL REGRESSION

POLINOMI 9E GRAU

UNSUPERVISED LEARNING CONTINU

ARTIFICIAL NEURAL NETWORKS

NETWORK OF PERCEPTRONS
NEURAL NETWORK

DEEP LEARNING

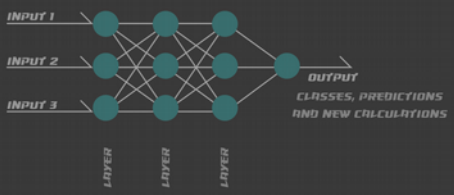

MACHINE LEARNING ML

'INTELLIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

K-NEAREST NEIGHBOUR

TRIGONOMETRY

NAIVE BAYES

PROBABILISTIC

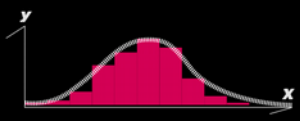

DECISION TREES

CONDITIONAL BLOCKS

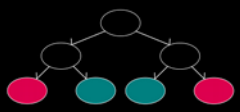

ADA BOOST

META ALGORYTHM

SUPORT VECTOR MACHINES

MULTIDIMENSIONAL SPACE

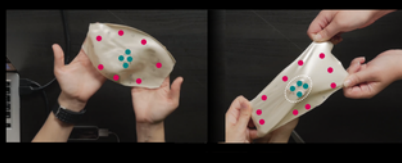

MACHINE LEARNING

ML

'INTEL·LIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

K-NEAREST NEIGHBOUR

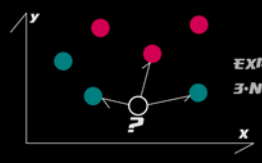

EXAMPLE
3-NEAREST NEIGHBOUR

K= NUMBER OF ELEMENTS TO CALCULATE DISTANCE

DISTANCES CALCULATES BY EUCLIDEAN METHODS
IN CASE ITS ONLY BIDIMENSIONAL IS THE CLASSIC PITAGORIC FORMULA
IN CASE INPUTS ARE MORE THAN 2 THEREFORE HAS SOME MORE DIMENSIONS, CALCULUS GET MORE COMPLICATED

$$\sqrt{\sum_{f=1}^{d} = (X_{fa} - X_{fb})^2}$$

distance between example a and example b with d features or inputs

✓

NO TRAINING TIME

CAPABLE OF ARIBITRARY COMPLEX BOUNDARIES

✗

METHOD THAT GOES WRONG WITH VERY DIFFERENT MAGNITUDES
> NORMALIZE FEATURES OR INPUTS WITHIN A SIMILAR RANGE FROM 0 TO 1

SLOW METHOD FOR LARGE TRAINING EXAMPLES

CAN BE AFFECTED BY NOISE

CAN BE AFFECTED BY IRRELEVANT AND REDUNDANT FEATURES

MACHINE LEARNING

ML

'INTEL·LIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

NAIVE BAYES

PROBABILISTIC METHODS

COMPUTE THE LIKELIHOOD OF THE GIVEN FEATURE VALUES BEING OBSERVED FOR EACH CLASS

COMBINE THIS CONSIDERING THE RELATIVE PROPORTIONS OF CLASSES IN THE WORLD
TO COMPUTE PROBABILITY THAT NEW EXAMPLE IS FROM EACH CLASS

✓

FAST TRAINING AND RUNNING

CAN GET INFO ABOUT PROBABILITY EACH CLASS IS NOT JUST SIBGLE 'BEST' CLASS

NOT AS SENSITIVE TO OUTLIERS OR SINGLE ERRORS, LESS LIKELY TO OVERFIT

✓✗

NOT AS SENSITIVE TO OUTLIERS OR SINGLE ERRORS, LESS LIKELY TO OVERFIT

✗

ASSUMPTION THAT FEATURES ARENT RELATED TO EACH OTHER ISNT ALWAYS EFFICIENT,
CAN LEAD TO WORSE PERFORMANCE

MACHINE LEARNING

ML

'INTEL.LIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

DECISION TREES

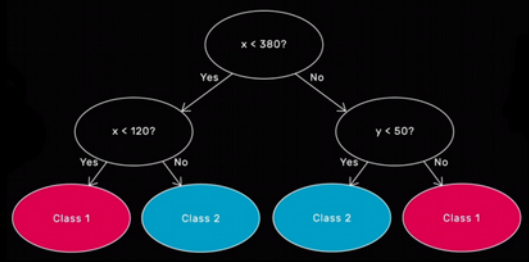

DECISION STUMP IF / CONDITIONALS
A TREE OF DECISION STUMP LOOPS IS A DECISION TREE.
LEAFS ARE ELEMENTS IN DEEPER LAYERS OF THE TREE

ALSO A NICE POINT IS TO INTRODUCE ENTROPY IN THE MODEL AS A MEASURE OF HOMOGENEITY / DIVERSITY

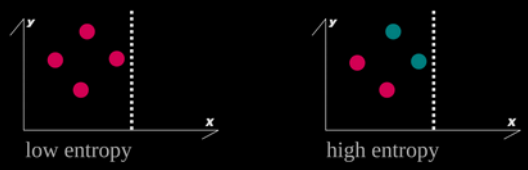

DECISION TREES
C4.5 ALGORYTHM
J48 ALGORYTHM
...

src img > kadenze courseware machine learning for musicians and artists by Rebecca Fiebrink

✓

- FAST TRAINING AND RUNNING
- EASY TO WRITE AS CODE
- IF A FEATURE IS IRRELEVANT DECISION TREES CAN IGNORE IT
- DECISION TREES DONT REQUIRE YOU TO TUNE PARAMETERS

✗

- IS NOT A CUTTING EDGE METHOD TO SOLVE COMPLICATED PROBLEMS.

MACHINE LEARNING

ML

'INTEL.LIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

ADA BOOST

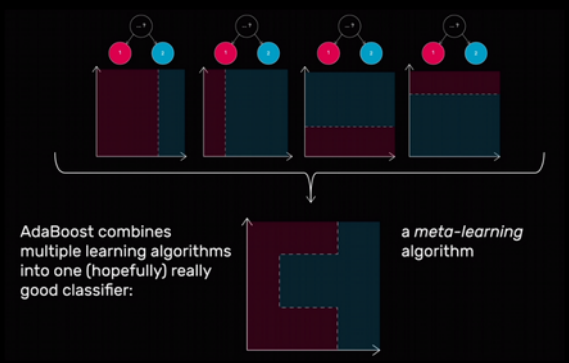

ADAPTATIVE BOOST OF
DIFFERENT MULTIPLE ALGORYHTMS
LIKE DECISION TREES OR DECISION STUMP

src img > kadenze courseware machine learning for musicians and artists by Rebecca Fiebrink

✓

- FAST TRAINING AND RUNNING
- EASY TO TUNE > CAN TUNE TRAINING SPEED BY ADJUSTING NUMBER OF TRAINING ROUNDS
- ICAN DEAL GRACEFULLY WITH IRRELEVANT FEATURES
- THEORETICALLY LESS PRONE TO OVERFITTING
- COMPUTING ON NEW EXAMPLES IS FAST

✓✗

- LESS LIKELY TO OVERFIT, SO NEED TO GIVE MORE DATA TO MAKE MORE COMPLLEX BOUNDARIES

SUPORT VECTOR MACHINES

MACHINE LEARNING

ML

'INTEL.LIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

SUPERVISED LEARNING DISCRET

CLASSIFICATION

USING MORE THAN ONE CLASSIFIER AT ONCE

FEATURES MULTIDIMENSIONAL SPACES TO SOLVE LATER EASY CLASSIFICATIONS IN LOWER DIMENSIONS.

src img > kadenze courseware machine learning for musicians and artists by Rebecca Fiebrink

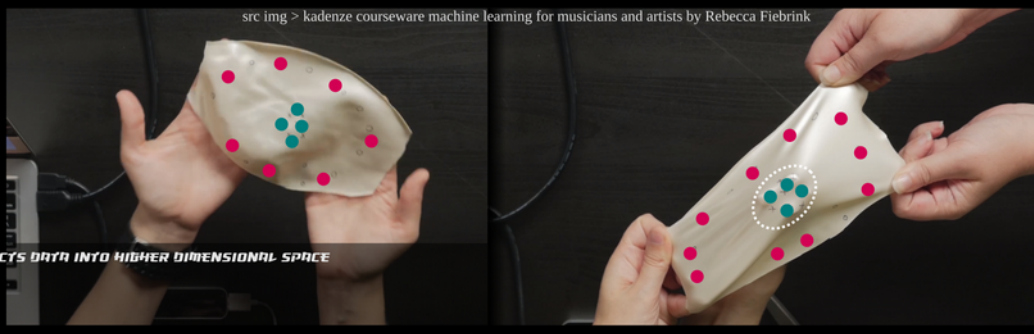

KERNEL PROJECTS DATA INTO HIGHER DIMENSIONAL SPACE

LINEAR

POLYNOMIAL

RBF

FIFFERENT KERNELS AND KERNEL PARAMETERS WILL GIVE DIFFERENT RESULTS

✓

VERY POWERFUL CAN WORK IN COMPLICATED PROBLEMS

SEVERAL KERNEL TYPES

COMPUTATION ON NEW EXAMPLES IS FAST

✗

TRAINING INVOLVES SOLVING OPTIMIZATION THAT CAN BE SLOW FOR LARGE DATASETS

CHOOSING KERNELS AND ITS PARAMETERS CAN BE FRUSTRATING

MIGHT NOT WORK WELL FOR SMALL TRAINING SETS OR COMPLEX COMBINATIONS LIKE DIFFRENT NUMBERS OF EXAMPLES IN EACH CLASS

Beques de recerca i creació OSIC· gencat 2021
projecte ***músIA***
Xavi Manzanares
2021 / 2022

MACHINE LEARNING FOR NEWBIES VOL3 ARTIFICIAL NEURAL NETWORKS

Aknowledgments:
Molts diagrames i representacions d'aquest tuto són directament inspirats del molt recomanable curs de
Rebecca Fiebrink 'Machine Learning for Musicians and Artists'
https://www.kadenze.com/courses/machine-learning-for-musicians-and-artists-v
on es mostra una overview al ML amb projectes de media & sonic interaction per mitjà del programari ML Wekinator.

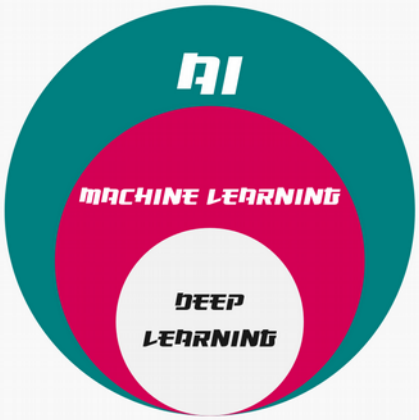
AI
MACHINE LEARNING
DEEP
LEARNING

UNSUPERVISED LEARNING
CONTINU

MACHINE LEARNING

ML

'INTELLIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

ARTIFICIAL NEURAL NETWORKS

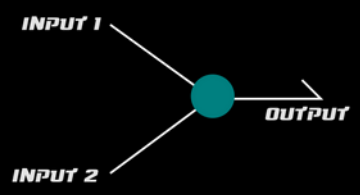

PERCEPTRON | SINGLE NEURON

NETWORK OF PERCEPTRONS
NEURAL NETWORK

DEEP LEARNING

INPUTS OR FEATURES

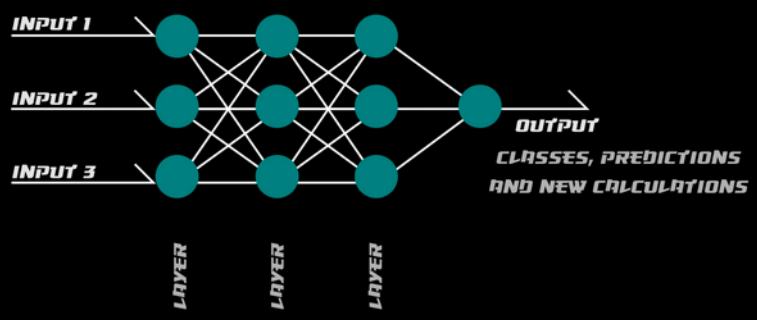

PERCEPTRON | SINGLE NEURON

MACHINE LEARNING

ML

'INTELLIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

ARTIFICIAL NEURAL NETWORKS

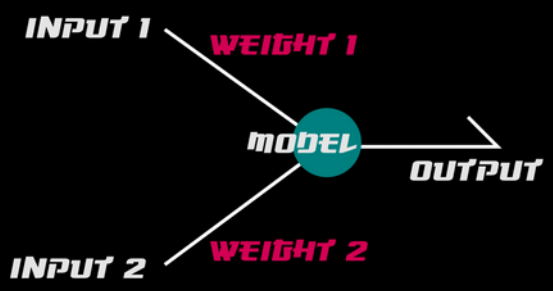

MODEL

SUM = INPUT1 X WEIGHT1 + INPUT2 X WEIGHT2

ACTIVATION FUNCTION
f

LINEAR
SINE
TANG > SIGMOID

ANN
ARTIFICIAL NEURAL NETWORK

MACHINE LEARNING

ML

'INTELLIGÈNCIA' QUE POT APRENDRE PER DIVERSOS MÈTODES I GENERAR PREDICCIONS

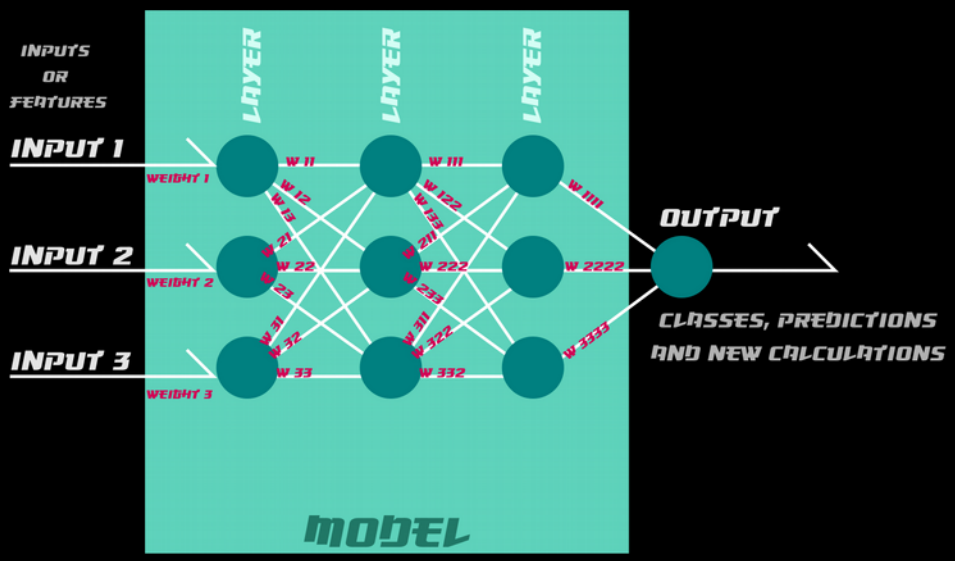

MACHINE LEARNING

ML

PROBLEM :
WE WANT TO TRAIN
A NEURAL NETWORK
TO FIND A CERTAIN COLOR

EXPECTED RESULT

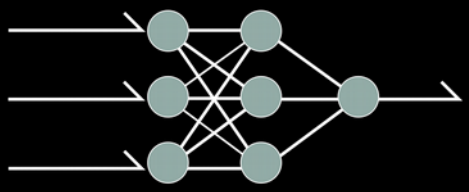

MACHINE LEARNING

ML

EXPECTED RESULT

INPUTS
RANDOM COLOR

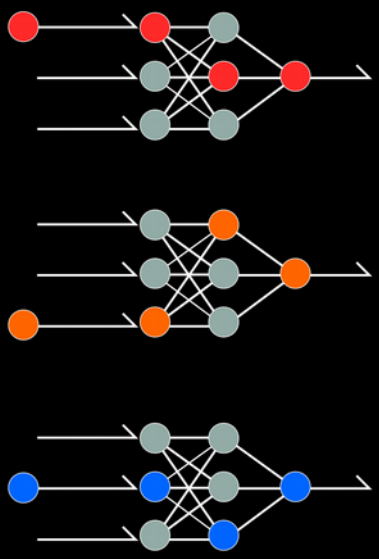

WITH DIFFERENT METHODS
OF COMPARISON BETWEEN ITEMS
EX NEAREST NEIGHBOUR ALGORYTHMS
EXTRACT THE MIX

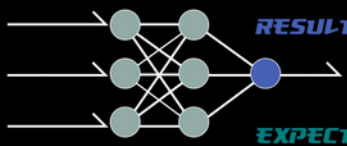

GUESS RESULT

EXPECTED RESULT

ETC

PROPAGATION

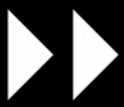

PROBLEM :
WE WANT TO TRAIN
A NEURAL NETWORK
TO FIND A CERTAIN COLOR

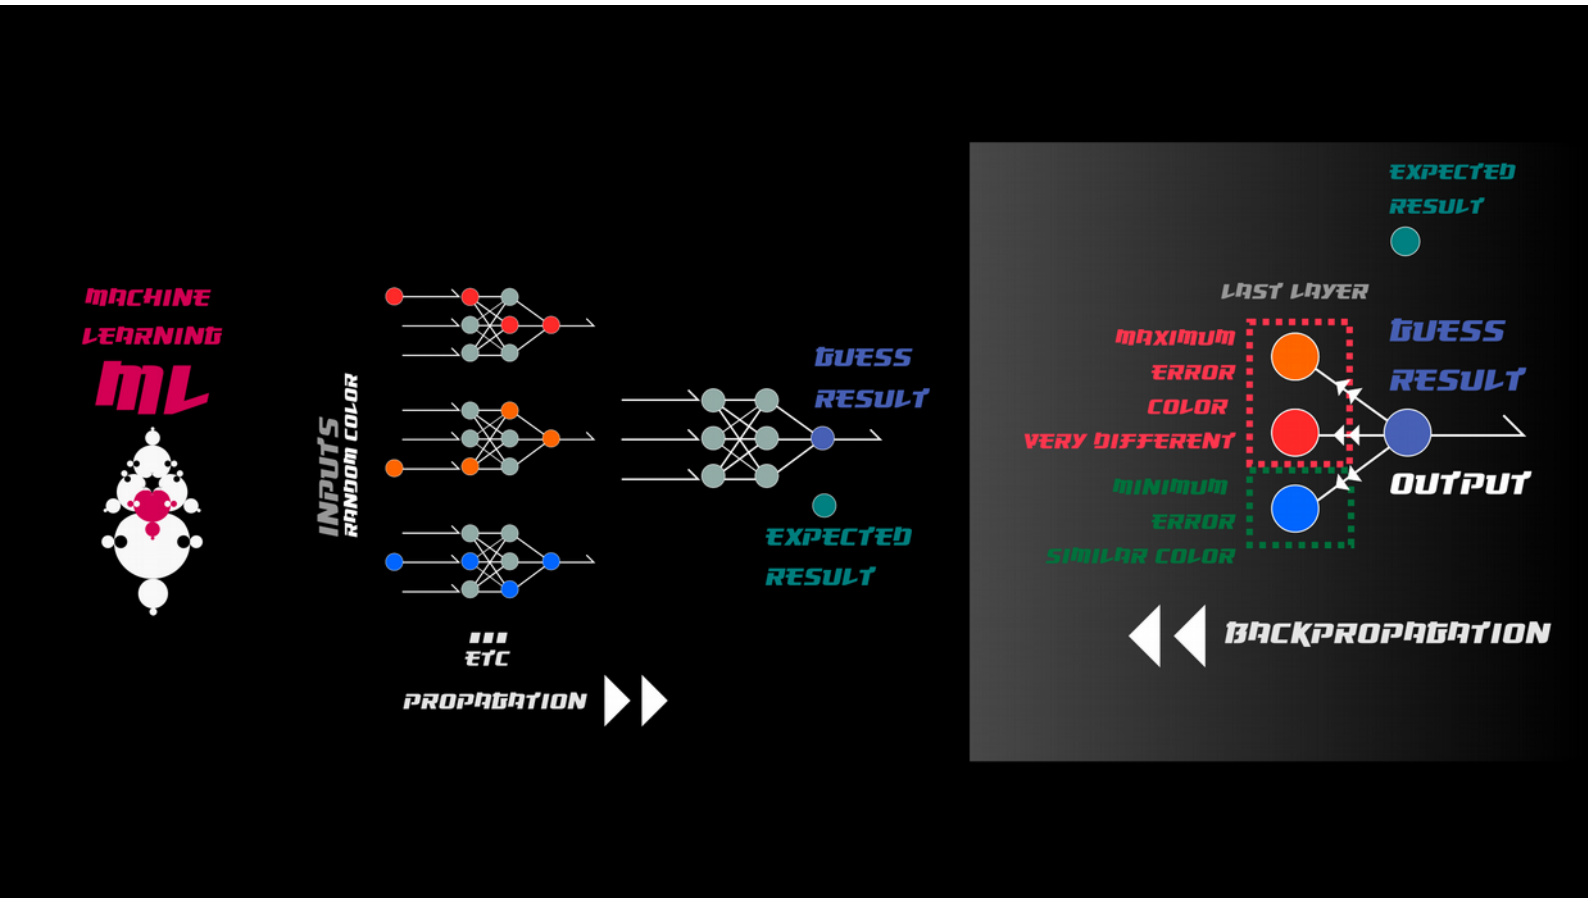
MACHINE
LEARNING
ML
INPUTS
RANDOM COLOR
GUESS
RESULT
EXPECTED
RESULT
...
ETC
PROPAGATION
EXPECTED
RESULT
LAST LAYER
MAXIMUM
ERROR
COLOR
VERY DIFFERENT
GUESS
RESULT
OUTPUT
MINIMUM
ERROR
SIMILAR COLOR
BACKPROPAGATION

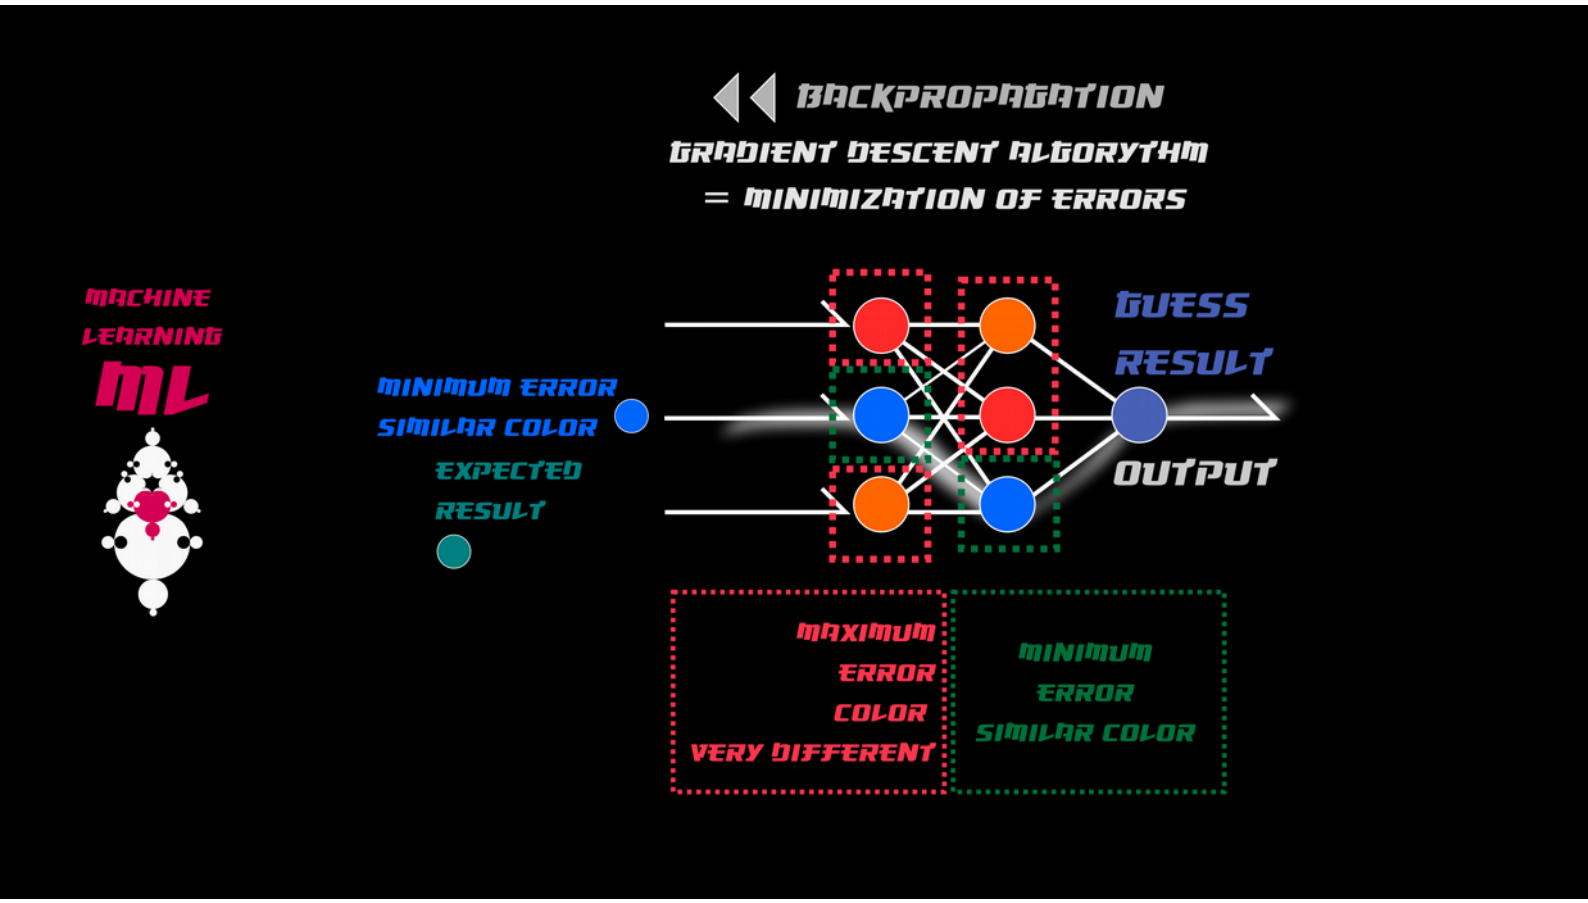
BACKPROPAGATION
GRADIENT DESCENT ALGORYTHM
= MINIMIZATION OF ERRORS
MACHINE
LEARNING
ML
MINIMUM ERROR
SIMILAR COLOR
EXPECTED
RESULT
GUESS
RESULT
OUTPUT
MAXIMUM
ERROR
COLOR
VERY DIFFERENT
MINIMUM
ERROR
SIMILAR COLOR

MACHINE LEARNING

ML

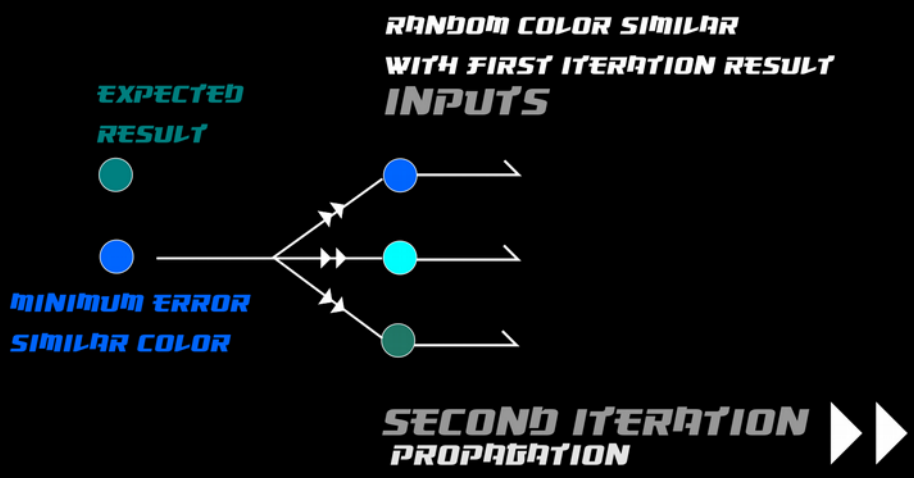

MACHINE LEARNING

ML

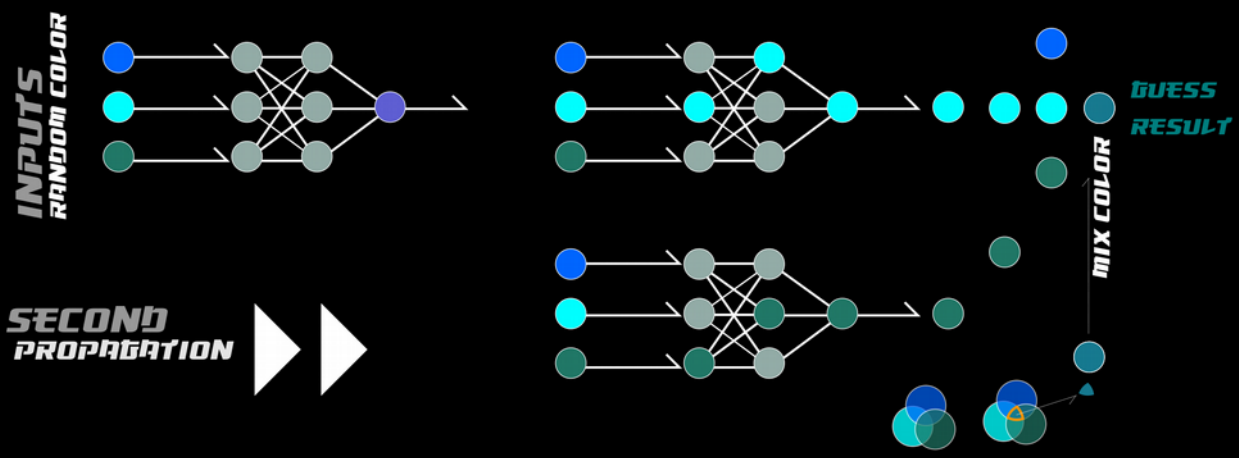

PROBLEM :
WE WANT TO TRAIN
A NEURAL NETWORK
TO FIND A CERTAIN COLOR

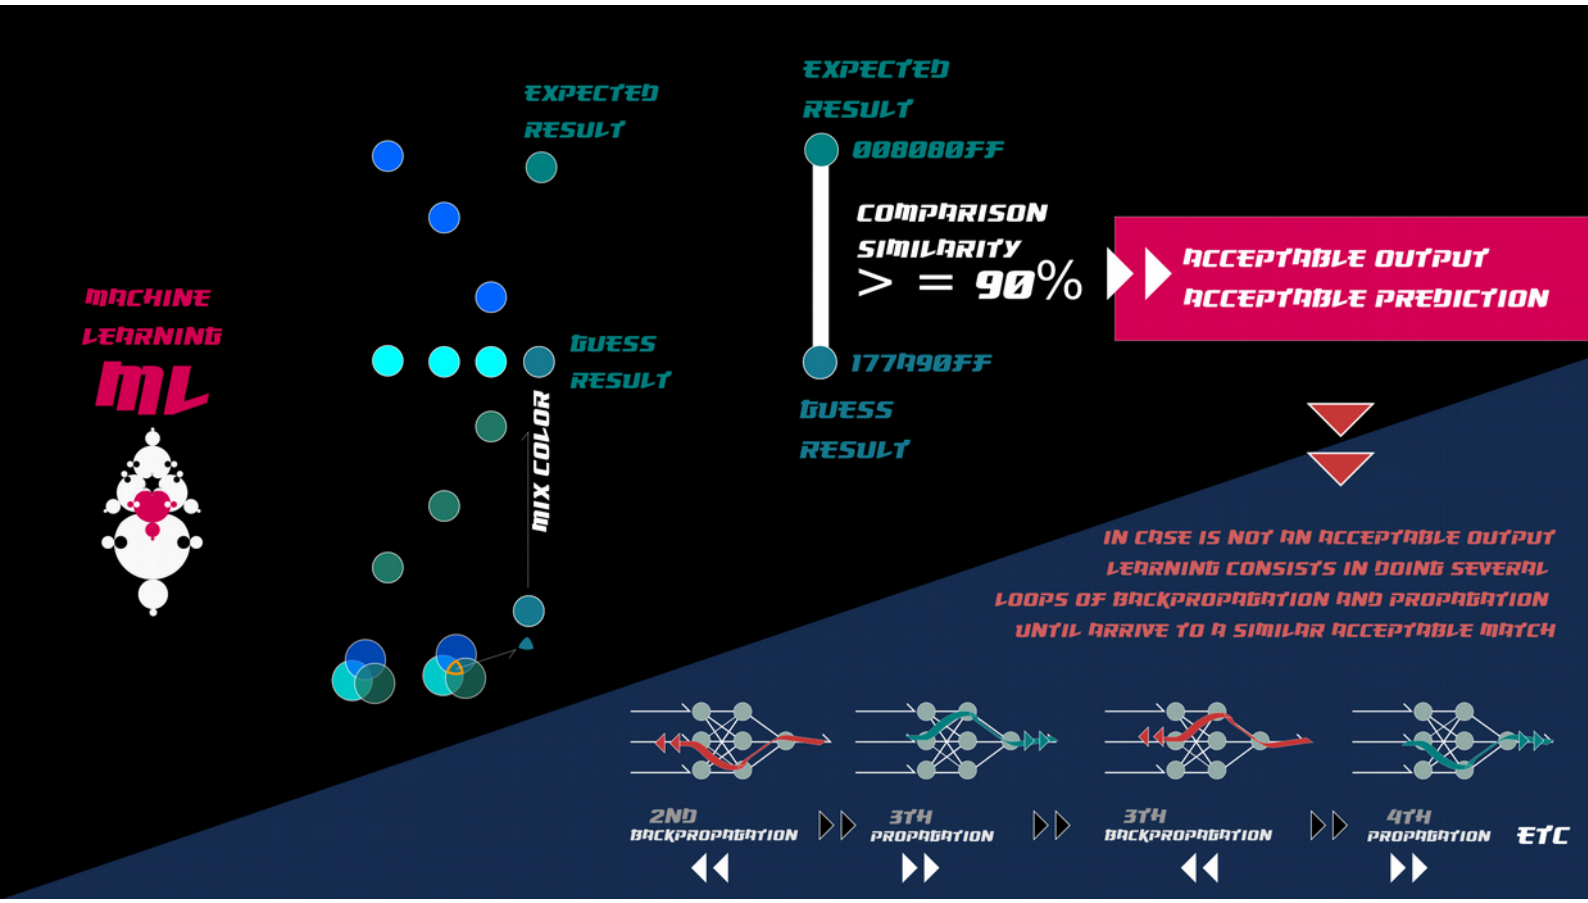
MACHINE LEARNING
ML
EXPECTED RESULT
GUESS RESULT
MIX COLOR
EXPECTED RESULT
008080FF
COMPARISON SIMILARITY
> = 90%
177A90FF
GUESS RESULT
ACCEPTABLE OUTPUT
ACCEPTABLE PREDICTION
IN CASE IS NOT AN ACCEPTABLE OUTPUT LEARNING CONSISTS IN DOING SEVERAL LOOPS OF BACKPROPAGATION AND PROPAGATION UNTIL ARRIVE TO A SIMILAR ACCEPTABLE MATCH
2ND BACKPROPAGATION
3TH PROPAGATION
3TH BACKPROPAGATION
4TH PROPAGATION
ETC